

## 基于人工智能的癫痫发作预测研究综述

汪文杰<sup>1,2</sup>, 姚旭峰<sup>2</sup>

(1.上海理工大学健康科学与工程学院, 上海 200093;

2.上海健康医学院医学影像学院, 上海 201318)

✉ 1176728277@qq.com; yao6636329@hotmail.com



**摘要:**癫痫属于神经系统疾病,反复发作和持久倾向将导致机体损伤,因此提前发现癫痫发作有助提升患者的生活质量。为了全面且深入地探究人工智能在预测癫痫发作方面的研究进展及趋势,首先介绍了目前常用的预测癫痫的脑电公开数据集、评价指标和预处理技术,其次将基于人工智能的癫痫发作预测研究划分为基于机器学习和基于深度学习两类,并分别进行分析。分析结果显示,基于深度学习的癫痫发作预测,准确率能达到95%以上。基于以上研究结果得出人工智能应用于癫痫发作预测具有良好的发展前景。

**关键词:**癫痫发作预测;深度学习;机器学习;脑电图

中图分类号:TP391 文献标志码:A

## A Review of Epilepsy Prediction Based on Artificial Intelligence

WANG Wenjie<sup>1,2</sup>, YAO Xufeng<sup>2</sup>

(1.School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2.College of Medica Imaging, Shanghai University of Medicine & Health Sciences, Shanghai 201318, China)

✉ 1176728277@qq.com; yao6636329@hotmail.com

**Abstract:** Epilepsy is a neurological disorder, and recurrent seizures and persistent tendencies will lead to physical damage. Therefore, early detection of epilepsy seizures can help improve patients' quality of life. In order to comprehensively and deeply explore the research progress and trends of Artificial Intelligence (AI) in predicting epilepsy seizures, this paper first introduces commonly-used and publicly available EEG (Electroencephalogram) datasets for predicting epilepsy, evaluation indicators, and preprocessing techniques. Then, it divides the research on AI-based epilepsy seizure prediction into two categories: machine learning and deep learning, and analyzes them separately. The analysis results show that in deep learning-based epilepsy seizure prediction, the accuracy can reach over 95%. Based on the above research results, it can be concluded that the application of AI in epilepsy seizure prediction has promising prospects.

**Key words:** epilepsy seizure prediction; deep learning; machine learning; Electroencephalogram

## 0 引言(Introduction)

癫痫(Epilepsy)是一种由异常的大脑活动引起的大脑神经系统疾病,其特征是反复发作并具有持久倾向,患病人群涉及全年龄段个体,并且近年来患病人数呈持续增长趋势<sup>[1-2]</sup>。癫

痫发作的患者会出现意识丧失和抽搐行为,给机体带来严重的损伤<sup>[3]</sup>。预测癫痫发作可以降低疾病发作给患者机体带来的损伤风险,改善患者的疾病预后。相较于基于人工提取特征的经典机器学习模型,因为深度学习具有自主提取与学习关键特

征的优势,所以在癫痫发作预测研究中展现出重要的价值。本文首先概述了癫痫发作预测常用的数据集、评价指标和预处理技术,其次分别介绍了机器学习技术、深度学习技术在癫痫发作预测中的具体应用,并分析了两种技术的优点和缺点,最后总结了未来癫痫发作预测研究中需要解决的问题。

## 1 数据集和评价指标 (Datasets and evaluation indicators)

### 1.1 数据集

脑电图(Electroencephalogram, EEG)具有非侵入性且可以提供大脑的全局信息,因此被广泛用于癫痫的发作预测研究<sup>[4]</sup>。目前,常用的预测癫痫的脑电公开数据集有波士顿儿童医院和麻省理工学院联合创建的癫痫脑电图数据集(Children's Hospital Boston and Massachusetts Institute of Technology, CHB-MIT)<sup>[5]</sup>、弗莱堡医院创建的癫痫脑电图数据集(Freiburg)<sup>[6]</sup> 和美国癫痫协会(American Epilepsy Society, AES)创建的数据集<sup>[7]</sup>。癫痫发作预测模型常用数据集如表1所示。

表1 癫痫发作预测模型常用数据集

Tab.1 Common datasets for seizure prediction models

数据集	脑电类型	患者/人	采样率/Hz	采样通道/个	发作次数/次
CHB-MIT	头皮	22	256	22	198
Freiburg	颅内	13	256	6	59
AES	颅内	2	5 000	16	48

### 1.2 评价指标

灵敏度(Sensitivity, SEN)和特异性(Specificity, SPE)是评估癫痫发作预测方法性能的重要指标<sup>[8]</sup>。灵敏度衡量的是真阳性概率(True Positive Rate, TPR),而特异性则表示真阴性概率(True Negative Rate, TNR)。通常,可以通过公式(1)和公式(2)定义灵敏度和特异性,其中TP为真阳性,即正确分类为阳性类;TN为真阴性,即正确分类为阴性类;FP为假阳性,即阴性类预测为阳性;FN为假阴性,即阳性类预测为阴性。在癫痫发作预测中,癫痫发作前的状态被认为是阳性,癫痫发作期间的状态被认为是阴性。

$$SEN = \frac{TP}{TP + FN} \quad (1)$$

$$SPE = \frac{TN}{TN + FP} \quad (2)$$

评价指标还有受试者的工作特征曲线(Receiver Operator Characteristic, ROC)及其曲线下的面积(Area Under Curve, AUC)<sup>[9]</sup>。ROC是对癫痫发作间歇期和癫痫发作前期的TPR与FPR进行评估,AUC是对TPR与FPR进行分类算法性能排名<sup>[10]</sup>。

癫痫的发作预测是在癫痫发作前发出警报,在理论条件下,应该预测获得癫痫发作的确切时间,但是在实际中,只能是预测癫痫大概率发作的时间段。因此,癫痫发作期(Seizure Occurrence Period, SOP)和癫痫发作预测期(Seizure Prediction

Horizon, SPH)也是评估癫痫发作预测方法性能的指标。SOP为可能发生癫痫的时间段,SPH为发出警报到SOP起始时的时间段<sup>[11]</sup>。

## 2 癫痫发作预测方法与模型(Methods and models for epileptic seizure prediction)

患者癫痫发作时的脑电状态可划分为4个时期,分别为发作前期、发作期、发作后期和发作间歇期<sup>[12]</sup>。如图1所示,发作前期是指患者癫痫发作前的几秒到几个小时的时间段,在此期间患者的脑电信号表现出相应的异常,可通过检测异常信号进行发病预测;发作期是指患者癫痫发作的时间段;发作后期是指患者癫痫发作结束后与发作间歇期开始的时间段;发作间歇期是指患者脑电活动正常的时间段<sup>[13]</sup>。预测癫痫发作的前提是能及时且准确地检测患者癫痫发作前的脑电状态,因此预测癫痫发作可转化为发作前期和发作间歇期的二分类问题。

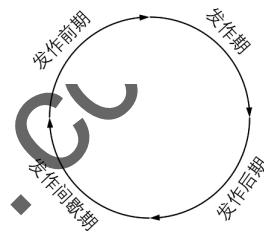


图1 患者癫痫发作时的脑电状态

Fig. 1 EEG status of a patient during epileptic seizures

### 2.1 预处理技术

未处理的脑电信号往往包含各种伪迹,伪迹分为生理伪迹和非生理伪迹两类。生理伪迹一般来源于人体本身,常见的是眼动、心跳、呼吸时肌肉运动和汗腺分泌等产生的生理电信号;非生理伪迹通常来自外界环境的干扰,如市电干扰、电极与头皮接触不良等环境干扰因素<sup>[14]</sup>。因此,需要对采集的脑电数据进行预处理,尽可能减少或消除伪迹的影响,保留原始真实的信息,进而更准确地表征大脑神经信号,这对于癫痫的发作预测具有重要意义。低通、高通、带通和陷波滤波器是目前消除伪迹的常见解决方案<sup>[15]</sup>,但是滤波器只有在伪迹的频率不重叠时才有效,而在频率重叠的情况下,则可以采用小波变换(Wavelet Transform, WT)<sup>[16]</sup>、回归法<sup>[17]</sup>、盲源分离(Blind Source Separation, BSS)<sup>[18]</sup>、经验模态分解(Empirical Mode Decomposition, EMD)<sup>[19]</sup>、滤波法(Filtering)<sup>[20-21]</sup>及稀疏分量分析(Sparse Component Analysis, SCA)<sup>[22]</sup>等方法(图2)。除了使用上述方法外,还可以将经验模态分解与盲源分离相结合<sup>[23]</sup>、小波与盲源分离相结合<sup>[24]</sup>等混合方法消除伪迹。

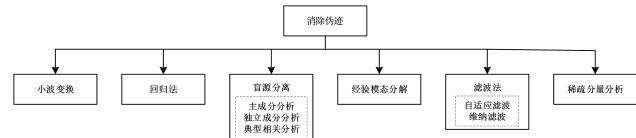


图2 脑电信号消除伪迹的方法

Fig. 2 Method of removing artifacts from EEG signals

## 2.2 基于传统机器学习的癫痫发作预测

如图3所示,基于传统机器学习的癫痫发作预测是从脑电信号中提取特征并选择最佳特征,然后将特征分类为发作间歇期和发作前期,识别出癫痫发作前期的脑电信号,从而实现癫痫发作预测。



图3 基于传统机器学习的癫痫发作预测流程图

Fig. 3 Flow chart of epileptic seizure prediction based on traditional machine learning

### 2.2.1 特征提取与选择

EEG可提供与癫痫发作前密切相关的高灵敏度特征信息,特征提取是将脑电信号中最具鉴别意义的信息提取出来的过程。特征提取前,脑电信号通常被分割成特定长度的窗口,不同的窗口长度对预测结果有较大的影响<sup>[25-26]</sup>。EEG特征通常从时域分析、频域分析、时频域分析和非线性分析中提取,常用的特征有Hjorth参数、功率谱密度、Lyapunov指数和排列熵等<sup>[27-28]</sup>。YANG等<sup>[29]</sup>提取排列熵特征用于测量时间序列的复杂程度,结果表明,该特征在癫痫发作预测中有巨大的潜力。

特征选择是选择最佳特征以提高分类器性能的过程。提取的特征通常存在多余的信息,这些信息会干扰模型学习核心特征信息,影响模型性能。因此,减少特征数量可以同时减少分类器待优化参数的数量,提高预测速度和预测准确度。HUSSEIN等<sup>[30]</sup>使用模拟退火法寻找区分癫痫发作前和癫痫发作间歇期达到最佳性能的特征。ZHANG等<sup>[31]</sup>使用3个连续的算法分步进行特征选择:首先删除标准差较小的特征;其次保留权重较大的重要特征以供进一步分析;最后细化特征子集以消除冗余。

### 2.2.2 分类

分类是传统机器学习(Machine Learning,ML)算法的常见任务之一,它使用选定的特征分类器区分癫痫患者的发作前期<sup>[9]</sup>。常用的机器学习模型有支持向量机(Support Vector Machine,SVM)、逻辑回归(Logistic Regression,LR)、决策树(Decision Trees,DTs)、随机森林(Random Forest,RF)、朴素贝叶斯(Naive Bayes,NB)和K-最近邻算法(K-Nearest Neighbors,KNN)等。

USMAN等<sup>[32]</sup>应用EMD进行EEG预处理,并提取时域和频域特征,分别应用了KNN、NB和SVM进行分类预测,灵敏度达到92.23%,最大预期时间为33 min,平均预测时间为23.6 min。MAHMOODIAN<sup>[33]</sup>等使用Freiburg癫痫脑电数据集和交叉双谱方法提取非线性多变量特征输入SVM来预测癫痫发作,获得了100%的灵敏度。SAVADKOOGHI等<sup>[34]</sup>利用巴特沃斯滤波、傅里叶变换和小波变换分别在时间域、频域和时频域提取脑电特征,并用T检验和序贯向前浮点选择进行特征选择,采用SVM和KNN对脑电信号进行分类,SVM应用于癫痫发作预测时,在灵敏度和特异性方面优于其他类型的分类器。ML用于癫痫发作预测的主要局限性是必须进行人

工干预才能提取有效的特征,手动提取的特征具有高度的主观性,并依赖于人工对该领域专业知识的掌握程度。因此,引入深度学习进行癫痫发作预测具有重要意义。

## 2.3 基于深度学习的癫痫发作预测

脑电信号中存在的噪声和伪迹使得特征提取的处理非常复杂。深度学习(Deep Learning,DL)是机器学习的一个分支,它可以自动从脑电信号中提取特征并学习关键信息,基于深度学习的癫痫发作预测流程图如图4所示。因此,与手动特征提取的机器学习方法相比,自动提取特征的深度学习具有显著优势,使其逐渐成为癫痫发作预测领域的研究热点。

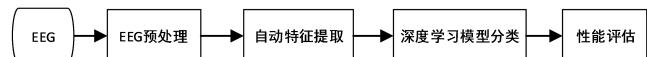


图4 基于深度学习的癫痫发作预测流程图

Fig. 4 Flow chart of epileptic seizure prediction based on deep learning

卷积神经网络(Convolutional Neural Network,CNN)与其他DL网络相比,在癫痫发作预测中的应用更广泛,通常采用2D-CNN预测癫痫何时发作。2D-CNN应用于预测癫痫发作时,首先使用预处理方法将脑电信号转换为二维图像,其次将这些图像输入CNN进行分类预测。TRUONG等<sup>[35]</sup>提出了一种适用于所有患者的癫痫发作预测方法,在30 s的脑电窗口上使用短时傅里叶变换(Short-Time Fourier Transform,STFT)提取频域和时域的信息,自动为每一位患者生成优化的特征,对发作前期和发作间歇期的EEG进行二分类,获得的灵敏度为81.2%。1D-CNN模型因实现简单使其在癫痫发作预测研究中具有特殊的地位。JANA等<sup>[36]</sup>提出了一种基于最小通道CNN的癫痫发作预测方法用于癫痫患者的自动特征提取和分类,通过将22个脑电通道优化为6个,获得了平均分类准确率为99.47%、平均灵敏度为97.83%、平均特异性为92.36%的优异性能。

由于EEG信号本质上是高度动态的、非线性的时序数据,因此长短期记忆(Long Short-Term Memory,LSTM)在此领域的应用比CNN更具有优势,它可以分离出不同状态下大脑活动的时间特征。TSIOURIS等<sup>[37]</sup>在癫痫发作预测中引入了LSTM网络,提取了时域和频域特征,能够预测所有185次癫痫发作。SINGH等<sup>[38]</sup>提出了一个基于频谱特征的两层LSTM网络模型用于癫痫发作预测,并使用30 s的脑电片段,获得的平均分类准确率为98.14%、平均灵敏度为98.51%、平均特异性为97.78%。USMAN等<sup>[39]</sup>使用EMD去除脑电信号中的噪声,并使用生成对抗网络生成发作前的样本,以处理类别不平衡的问题。用三层CNN自动提取特征,用LSTM进行发作前和发作间歇期的分类,得到93%的灵敏度和92.5%的特异性。实际应用中,LSTM仅被训练为用于特定患者的癫痫发作预测,泛化能力较弱。

为了提高模型的泛化能力,可以考虑使用集成学习(Ensemble Learning,EL)的方法。集成学习是通过训练多个

学习器并将它们结合起来解决一个问题,通常结合了多个学习器的集成学习模型比单个学习器的性能更好。MUHAMMAD 等<sup>[40]</sup>提出了一种基于深度学习的集成学习方法用于预测癫痫发作,提出了一种三层定制的 CNN 用于从预处理的 EEG 信号中自动提取特征并将其与手动提取特征相结合,以获得全面的特征集。分类器使用无模型元学习 (Model Agnostic Meta Learning, MAML) 将 SVM、CNN 和 LSTM 的输出组合,应用在 CHB-MIT 数据集中,得到的平均灵敏度为 96.28%,平均特异性为 95.65%,平均预期时间为 33 min。

### 3 结论(Conclusion)

目前,对于建立癫痫发作预测模型,传统机器学习算法面临一些问题,例如需要手动提取特征并泛化性较差。然而,深度学习算法能够自动提取特征并调整网络结构并参数以适应不同的数据,这使得其在处理各种类型和变化的脑电信号时更加灵活和可靠,但仍有问题亟须解决。未来,癫痫发作预测研究需开发具有成本效益、低功耗、实时性的用于监测与采集脑电信号的硬件设备,以及构建具有可解释性和高性能的预测模型。

### 参考文献(References)

- [1] FISHER R S, ACEVEDO C, ARZIMANOGLOU A, et al. ILAE official report:a practical clinical definition of epilepsy[J]. Epilepsia, 2014,55(4):475-482.
- [2] 韩芳,樊登贵,张丽媛,等. 神经系统疾病与认知动力学(I):癫痫发作的动力学与控制[J]. 力学进展, 2022, 52(2):339-396.
- [3] CHERIAN R, KANAGA E G. Theoretical and methodological analysis of EEG based seizure detection and prediction: an exhaustive review [J]. Journal of neuroscience methods, 2022, 369:109483.
- [4] CRAIK A, HE Y T, CONTRERAS VIDAL J L. Deep learning for electroencephalogram (EEG) classification tasks;a review[J]. Journal of neural engineering, 2019, 16(3):031001.
- [5] CHEN X, ZHENG Y J, DONG C X, et al. Multi-dimensional enhanced seizure prediction framework based on graph convolutional network[J]. Frontiers in neuroinformatics, 2021, 15:605729.
- [6] IHLE M, FELDWISCH-DRENTRUP H, TEIXEIRA C A, et al. EPILEPSIAE-a European epilepsy database [J]. Computer methods and programs in biomedicine, 2012, 106(3):127-138.
- [7] HUSSEIN R, LEE S, WARD R, et al. Semi-dilated convolutional neural networks for epileptic seizure prediction[J]. Neural networks, 2021, 139:212-222.
- [8] OSORIO I, FREI M G, WILKINSON S B. Real-time automated detection and quantitative analysis of seizures and short-term prediction of clinical onset[J]. Epilepsia, 1998, 39(6):615-627.
- [9] RASHEED K, QAYYUM A, QADIR J, et al. Machine learning for predicting epileptic seizures using EEG signals;a review[J]. IEEE reviews in biomedical engineering, 2020, 14:139-155.
- [10] MAIMAITI B, MENG H M, LV Y D, et al. An overview of EEG-based machine learning methods in seizure prediction and opportunities for neurologists in this field[J]. Neuroscience, 2022, 481:197-218.
- [11] CHEN H H, CHERKASSKY V. Performance metrics for online seizure prediction[J]. Neural networks, 2020, 128: 22-32.
- [12] BOU ASSI E, NGUYEN D K, RIHANA S, et al. Towards accurate prediction of epileptic seizures:a review[J]. Biomedical signal processing and control, 2017, 34:144-157.
- [13] KUHLMANN L, LEHNERTZ K, RICHARDSON M P, et al. Seizure prediction-ready for a new era[J]. Nature reviews neurology, 2018, 14:618-630.
- [14] STONE D B, TAMBURRO G, FIEDLER P, et al. Automatic removal of physiological artifacts in EEG: the optimized fingerprint method for sports science applications[J]. Frontiers in human neuroscience, 2018, 12:96.
- [15] LI S F, ZHOU W D, YUAN Q, et al. Seizure prediction using spike rate of intracranial EEG[J]. IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE engineering in medicine and biology society, 2013, 21(6):880-886.
- [16] SLIMEN I B, BOUBCHIR L, MBARKI Z, et al. EEG epileptic seizure detection and classification based on dual-tree complex wavelet transform and machine learning algorithms[J]. Journal of biomedical research, 2020, 34(3):151-161.
- [17] MAHAMUNE R, LASKAR S H, DHARMALE N, et al. Ocular artifacts removal from EEG signals using Discrete Wavelet Transform and Quadratic Regression Method[C]// IEEE. Proceedings of the IEEE: 2022 IEEE India Council International Subsections Conference (INDICON). Piscataway: IEEE, 2022:1-7.
- [18] CORSINI J, SHOKER L, SANIEI S, et al. Epileptic seizure predictability from scalp EEG incorporating constrained blind source separation[J]. IEEE transactions on bio-medical engineering, 2006, 53(5):790-799.
- [19] HASSAN A R, SUBASI A, ZHANG Y C. Epilepsy seizure detection using complete ensemble empirical mode

- decomposition with adaptive noise[J]. Knowledge-based systems, 2020, 191: 105333.
- [20] GARCÉS CORREA A, OROSCO L L, DIEZ P, et al. Adaptive filtering for epileptic event detection in the EEG[J]. Journal of medical and biological engineering, 2019, 39(6): 912-918.
- [21] SHANG Y Z, LONG S L. EEG signal classification with optimized LSTM: a meta-heuristic approach[C]//IEEE Proceedings of the IEEE; 2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications(AEECA). Piscataway: IEEE, 2022: 922-929.
- [22] WU Y L, ZHANG H X, WANG H Q, et al. The sparse decomposition and compression of ECG and EEG based on matching pursuits [C] // IEEE. Proceedings of the IEEE; 2010 IEEE 3rd International Conference on Bio-medical Engineering and Informatics. Piscataway: IEEE, 2010: 1094-1097.
- [23] JIANG X, BIAN G B, TIAN Z A. Removal of artifacts from EEG signals: a review [J]. Sensors, 2019, 19(5): 987.
- [24] YAN X T, BOUDRIAS M H, MITSIS G D. Removal of transcranial alternating current stimulation EEG artifacts using blind source separation and wavelets [J]. IEEE transactions on bio-medical engineering, 2022, 69(10): 3183-3192.
- [25] ALOTAIBY T N, ALSHEBEILI S A, ALOTAIBI F M, et al. Epileptic seizure prediction using CSP and LDA for scalp EEG signals [J]. Computational intelligence and neuroscience, 2017, 2017: 1240323.
- [26] CHO D, MIN B, KIM J, et al. EEG-based prediction of epileptic seizures using phase synchronization elicited from noise-assisted multivariate empirical mode decomposition[J]. IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE engineering in medicine and biology society, 2017, 25(8): 1309-1318.
- [27] USMAN S M, HASSAN A. Efficient prediction and classification of epileptic seizures using EEG data based on univariate linear features [J]. Journal of computers, 2018, 13(6): 616-621.
- [28] FICICI C, EROGUL O, TELATAR Z. Epileptic activity detection in EEG signals using linear and non-linear feature extraction methods[C]//IEEE. Proceedings of the IEEE: 2019 IEEE 11th International Conference on Electrical and Electronics Engineering (ELECO). Piscataway: IEEE, 2019: 449-455.
- [29] YANG Y L, ZHOU M N, NIU Y, et al. Epileptic seizure prediction based on permutation entropy[J]. Frontiers in computational neuroscience, 2018, 12: 55.
- [30] HUSSEIN H M, ABDALLA K K. Seizure prediction algorithm based on simulated annealing and machine learning[J]. International journal of nonlinear analysis and applications, 2023, 14(1): 1499-1508.
- [31] ZHANG Y D, YANG S H, LIU Y, et al. Integration of 24 feature types to accurately detect and predict seizures using scalp EEG signals[J]. Sensors, 2018, 18(5): 1372.
- [32] USMAN S M, USMAN M, FONG S. Epileptic seizures prediction using machine learning methods[J]. Computational and mathematical methods in medicine, 2017, 2017: 9074759.
- [33] MAHMOODIAN N, HADDADNIA J, ILLANES A, et al. Seizure prediction with cross-higher-order spectral analysis of EEG signals[J]. Signal, image and video processing, 2020, 14(4): 821-828.
- [34] SAVADKOOHI M, OLADUNNI T, THOMPSON L. A machine learning approach to epileptic seizure prediction using electroencephalogram (EEG) signal[J]. Biocybernetics and biomedical engineering, 2020, 40(3): 1328-1341.
- [35] TRUONG N D, NGUYEN A D, KUHLMANN L, et al. Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram [J]. Neural networks, 2018, 105: 104-111.
- [36] JANA R, MUKHERJEE I. Deep learning based efficient epileptic seizure prediction with EEG channel optimization[J]. Biomedical signal processing and control, 2021, 68: 102767.
- [37] TSIOURIS K M, PEZOULAS V C, ZERVAKIS M, et al. A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals [J]. Computers in biology and medicine, 2018, 99: 24-37.
- [38] SINGH K, MALHOTRA J. Two-layer LSTM network-based prediction of epileptic seizures using EEG spectral features[J]. Complex & intelligent systems, 2022, 8(3): 2405-2418.
- [39] USMAN S M, KHALID S, BASHIR Z. Epileptic seizure prediction using scalp electroencephalogram signals[J]. Biocybernetics and biomedical engineering, 2021, 41(1): 211-220.
- [40] MUHAMMAD USMAN S, KHALID S, BASHIR S. A deep learning based ensemble learning method for epileptic seizure prediction[J]. Computers in biology and medicine, 2021, 136: 104710.

## 作者简介:

汪文杰(1997-),男,硕士生。研究领域:医学图像处理。

姚旭峰(1976-),男,博士,教授。研究领域:人工智能与计算机图像处理。本文通信作者。