

基于 EEG 的癫痫自动检测: 综述与展望

彭睿旻¹ 江军² 匡光涛² 杜浩² 伍冬睿¹ 邵剑波²

摘要 癫痫是一种由脑部神经元阵发性异常超同步电活动导致的慢性非传染性疾病,也是全球最常见的神经系统疾病之一. 基于 EEG 的癫痫自动检测是指通过机器学习、分布检验、相关性分析和时频分析等数据分析方法,对癫痫发作阶段的 EEG 信号进行自动识别的研究问题,能够为癫痫诊疗与评估提供客观参考依据,从而减轻医生工作负担并提高治疗效率,因此具有十分重要的理论意义与实际应用价值. 本文详细介绍基于 EEG 的癫痫自动识别整体框架,以及对应用于各个步骤所涉及的典型方法. 针对核心模块,即特征提取与分类器选择,进行方法总结与理论解释. 最后,对癫痫自动检测研究领域的未来研究方向进行展望.

关键词 癫痫, 头皮脑电, 特征提取, 分类

引用格式 彭睿旻, 江军, 匡光涛, 杜浩, 伍冬睿, 邵剑波. 基于 EEG 的癫痫自动检测: 综述、比较与展望. 自动化学报, 2021, XX(X): X-X

DOI 10.16383/j.aas.cxxxxxx

EEG-Based Automatic Epilepsy Detection: Overview and Outlook

PENG Ruimin¹ JIANG Jun² KUANG Guangtao² DU Hao² WU Dongrui¹ SHAO Jianbo²

Abstract Epilepsy is a chronic non-communicable disease caused by the abnormal supersynchronous electrical activity of brain neurons. It is also one of the most common neurological diseases in the world. EEG-based automatic epilepsy detection can relieve the burden of medical professions, and may also improve the detection accuracy. This paper first introduces the flowchart of EEG-based automatic epilepsy detection, and then describes typical feature extraction and classification approaches in detail. Finally, future research directions are pointed out.

Key words Epilepsy, EEG, feature extraction, classification

Citation PENG Ruimin, JIANG Jun, KUANG Guangtao, DU Hao, WU Dongrui, SHAO Jianbo. EEG-Based Automatic Epilepsy Detection: Overview, Comparison, and Outlook. *Acta Automatica Sinica*, 2021, XX(X): X-X

癫痫 (Epilepsy) 是影响全年龄人群的一种由脑部神经元阵发性异常超同步电活动导致的慢性非传染性疾病^[1],也是全球最常见的神经系统疾病之一. 由于大脑异常电活动的起始位置和传播方式存在差异,癫痫临床表现呈现多样化、复杂化的特点. 反复癫痫发作会对患者的精神与认知功能造成持续性的负面影响,甚至危及生命. 因此,癫痫诊断和治疗的研究具有非常重要的临床意义^[2].

1964 年,国际抗癫痫联盟首次提出了癫痫发作分类方案^[3],并于 1969 年对其增订. 该方案指出,根据发作时癫痫患者的脑电图表现,可将癫痫疾病的发作定义成五类亚型,并明确了发作状态 (Ictal)、

发作间状态 (Inter-ictal) 的头皮脑电图特征和患者的临床表现具有同等诊断意义.

脑电图 (Electroencephalogram, EEG) 是放置于头皮特定位置的电极采集获得的大脑内同步神经元活动产生的微伏级电信号^[1]. EEG 作为最常用、最经济的非侵入式脑电波检测手段,已有 70 余年的研究历史,是癫痫相关疾病诊断最有效的方法,例如对癫痫发病进行识别、预测和病灶定位等.

为了克服传统诊断手段的局限性、提高医疗效率,基于 EEG 的癫痫自动检测已成为行业研究热点. 癫痫自动检测可细分为两个任务: 癫痫发作事件检测 (Seizure Event Detection, SED) 和癫痫发作检测 (Seizure Onset Detection, SOD)^[4]. SED 目的是从多个 EEG 中尽可能准确地识别癫痫发作信号, SOD 目的是在连续脑电监测过程中,当患者癫痫发作时,系统能以尽可能短的延时 (Latency) 识别发作的开始,并描述持续时间.

临床上脑电的识读与分析主要依赖医疗工作者的视觉检测与手工标注,这也是目前基于 EEG 的癫痫检测金标准^[5]. 但是癫痫的发作时间和时长具有不确定性,从海量的脑电数据中读取发病期数据从

武汉市应用基础前沿项目 (2020020601012240),湖北省技术创新专项资助项目 (2019AEA171) 资助

Supported by Wuhan Application Foundations and Frontiers Project (2020020601012240), Technology Innovation Project of Hubei Province of China (2019AEA171)

1. 华中科技大学人工智能与自动化学院图像信息处理与智能控制教育部重点实验室 武汉 430074 2. 武汉儿童医院 武汉 430000

1. Ministry of Education Key Laboratory on Image Information Processing and Intelligent Control, School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074. 2. Children's Hospital, Wuhan 430000.

而分析病情工作繁琐,且极大依赖检查者主观判断.因此,为了克服传统诊断手段的局限性、提高医疗效率,从1982年Gotman^[6]提出基于EEG的癫痫自动识别方法起,已积累了大量SED相关研究.

同时,在癫痫治疗过程中,对抗癫痫药物治疗无效的患者需要采取手术治疗,需要准确识别手术切除的致痫灶.致痫灶分为始发区、激惹灶、致痫病变区与功能缺失区,其中始发区是最有效的标志区,被看作是致痫灶的替代指标^[7].临床上可通过在癫痫起始发作时,使用不同类型的示踪剂来判断始发区位置^[8].SOD也因此具有重要的临床意义.Grewal和Gotman^[9]设计了一种可根据用户自身数据调节参数的癫痫发作监测系统,使得系统的敏感度达到89.7%,平均时延17.1秒.Kharbouch等^[10]对用户敏感方法进行了特征提取的改进并使得系统在80%的被试数据上敏感度达到100%,时延控制在3.25-18.5秒.Sorensen等^[11]则提出了一种基于匹配追踪算法的SOD方法使得分类敏感度达到78%-100%,延时控制在5-18秒.近年来,高采样率设备逐渐普及,研究者们发现80Hz以上的癫痫脑电中存在的高频振荡节律(High Frequency Oscillation)也可作为一种新的始发区指示标志^[12-14].

无论SED还是SOD,癫痫自动检测的核心是对癫痫波的检测.1972年,Stevens等^[2]首次尝试从长时程EEG信号中提取痫样棘波.此后,根据痫样棘波的特性,人们提出了基于形态学^[15,16]、信号相关性^[17,18]、子带分解^[19]、特征工程^[20,21]等的棘波检测算法,对癫痫脑电信号进行自动检测.近年来,随着人工智能的不断发展,特别是机器学习与数据挖掘领域成果的不断积累,基于机器学习的癫痫自动检测方案大量涌现^[6,22-25].这类能够从数据中学习分类规则,并能随着数据的扩充而提高性能的自动化算法,是极具潜力的癫痫自动检测解决方案.该研究课题也因其理论背景和应用价值,引起了来自生物、医学、认知和计算机科学等众多领域研究者的广泛兴趣.

癫痫自动检测的核心问题可以归纳为特征提取和分类器设计两个子问题.其中,深度学习通过神经网络将特征提取与分类器设计融为一体.本文将从特征提取和分类器选择的角度比较癫痫自动检测中各个方法的优缺点,并结合该领域目前所面临的挑战,对未来研究方向进行展望,以期为该领域研究提供有益参考.

本文的主要贡献如下:

1. 对基于EEG的癫痫自动检测算法流程进行了详细阐述,总结了各个模块中的典型方法和研究进展,针对核心研究问题给出了详细的说明.

2. 全面介绍了时域、频域、时频域和非线性分析等四类常见特征.
3. 对癫痫检测中的分类模型做了详细归纳整理.
4. 对癫痫自动检测领域未来研究方向给出了建议与展望.

本文剩余部分安排如下:第1节详细阐述基于EEG的癫痫自动检测流程,并对各个步骤的典型方法进行详细陈述.第2节介绍癫痫自动检测的四类特征.第3节介绍癫痫自动检测中的分类模型.第4节对癫痫自动检测研究进行总结和展望.

1 癫痫自动检测流程

本节详细介绍癫痫自动检测流程,如图1所示.该流程通常包括四个步骤:信号采集、信号预处理、特征提取、分类模型学习与评估.下面将对此四步进行逐一介绍.

1.1 数据采集与输入

癫痫发作状态的脑电图异常主要表现为棘波、尖波、棘慢波、尖慢波散发或出现各种节律等.棘波是EEG信号中痫样放电的典型特征之一,表现为由皮质表面定向引起的表面负偏斜.上升支和下降支陡峭、整体形状如同荆棘的尖刺,是大脑皮层神经细胞异常放电在EEG信号中引起的波形变化.棘波周期通常为20-70ms,突出于背景信号,幅度大于20 μ V,为背景信号1.5倍以上^[6].因此,临床上通常选择提取癫痫发作期的痫样棘波和尖波,并通过定量分析获取癫痫相关的病理信息.

从采集方式可将EEG信号分为颅内EEG和头皮EEG两类.其中颅内EEG是通过颅骨钻孔或开颅手术等,将条形或网状电极安置在脑硬膜外并记录不同部位的脑电活动信号.头皮EEG则是利用脑电帽在人体头皮的固定位置安置电极并记录脑电活动信号.通过上述方法采集的EEG信号可作为癫痫自动检测的输入信号.

目前研究中,一部分研究数据来自于医院的非公开患者数据,大部分则采用公开数据集.表1列出了目前癫痫自动识别相关研究中常见的数据集.

1.2 数据预处理

原始的EEG信号具有很强的非平稳性和动态性,且头皮EEG本身幅值较小,采集程序会受到50Hz或60Hz的工频信号影响.此外癫痫发作中伴随着意识丧失和肢体动作,采集过程中极易受到外界不可控因素干扰,因此头皮EEG往往具有一定的随机性.为了后续对脑电信号的特征进行研究分析,首先需要在不丢失有效信息的前提下,从原始脑电信号中剔除伪迹,提高信噪比,以降低分类错误率.




图 1 基于 EEG 的癫痫自动检测流程.

Fig. 1 Flowchart of EEG-based automatic epilepsy detection.

表 1 常见癫痫数据集.

Table. 1 Popular epilepsy datasets.

数据集名称	受试数量	总发作次数	信号类型	采样频率 (Hz)	总时长 (小时)
Freiburg ^[64]	21	87	颅内 EEG	256	708
CHB-MIT ^[65]	22	163	头皮 EEG	256	844
Bonn ^[66]	10	100	颅内 EEG	256	708
Kaggle ^[67]	2(人) 5(狗)	48	颅内 EEG	400 5,000	627
Barcelona ^[68]	5	3,750	颅内 EEG	512	83

主要的方法包括^[22]:

- 阈值初筛: EEG 信号的特征取值, 如振幅、等效曲线下面积等, 超过一定的阈值时, 此信号被认为是异常.
- 专家特征: 常见的伪迹包括眼电伪迹、肌电伪迹、电极移位、散发伪迹以及弥漫性快速尖锐的 α 波等^[23]. 可利用专家经验对典型的干扰波特征进行筛选, 从而除去相应的伪迹.
- 滤波等信号处理: 脑电的有效信息大多集中于 1-60Hz 之间, 因此带通滤波^[26]是一种常见的 EEG 信号预处理方法. Oikonomou 等^[25]提出一种基于卡尔曼滤波的方法, 在预处理阶段增强 EEG 信号的信噪比, 从而提高棘波检出率. 但由于伪迹频段也部分重叠于目标信号, 单纯的滤波无法完全消除伪迹, 因此亦可使用独立成分分析^[27]和主成分分析^[28]等方法计算经小波

分解的 EEG 信号组分中的伪迹信号和脑电信号的混合矩阵, 从而实现信噪分离. 此外, 半波处理^[6]也是常见的信号处理方法, 能够对 EEG 信号中存在的尖峰和毛刺进行平滑.

1.3 特征提取与选择

通过对信号进行分析, 提取出有效的特征作为分类依据, 是实现癫痫自动检测的重要步骤. 合理、典型的癫痫 EEG 特征能够全面地表征 EEG 的信号模式, 同时有效地描述发作和正常等各种状态下 EEG 信号的区别, 突出棘波与背景信号的差异, 从而帮助分类模型对癫痫的发作进行有效甄别. 特征的好坏严重影响最终的分类性能.

一般来说, 用于癫痫检测的特征可分为以下四类: 针对序列波形和序列互相关性等的时域特征^[6, 29-31], 以功率谱密度为代表的对信号能量进行刻画的频域特征^[32-34], 利用时频变换方法将原始 EEG 信号转换而成的时频域特征^[35-37], 以及基于非线性分析的样本熵 (Sample entropy)^[38, 39]、排列熵 (Permutation entropy)^[40]、Hurst 参数^[41]和高阶谱分析^[42-44]等衡量信号不确定性的非线性特征.

特征矩阵可再经奇异值分解、主成分分析、独立成分分析和相关性分析^[45]等方法进行特征重新映射提取, 达到降低特征维度的目的. 进行特征选择时, 单因素方差分析 (Analysis of variance, ANOVA) 是最常用的手段. Ong 等^[46]提出的布谷鸟搜索算法 (cuckoo search algorithm) 能够对经过小波分解后的信号分量特征进行特征选择, 使最终

分类准确度提高到 98.43-100%.

1.4 分类模型学习与评估

根据癫痫的脑电特征, 选择有效的分类模型进行学习和评估是癫痫自动检测的核心. 常见的分类模型可按分类判断依据划分为统计分析和机器学习两种类型.

对于统计分析模型, 除了直接指定信号特征的阈值判断发作状态外, 也包括分布检验、相关性分析^[47]等方法. 通过对待测信号进行形态学分析^[48]、时频分析^[49]等, 比较待测信号和模板癫痫发作信号对应特征的数量、分布、相关性等差异, 实现癫痫自动检测.

随着人工智能的发展, 机器学习模型被广泛用于癫痫自动检测, 包括对手工提取的特征直接分类的传统机器学习^[37, 50-52]、基于神经网络的深度学习^[53-58]、克服脑电个体差异的迁移学习^[59, 60]、融合多个特征视图的多视图学习^[61]、融合多个基分类器的集成学习^[62]、以及优化标注样本的主动学习^[63]等.

2 癫痫自动检测中的特征

本节将基于线性和非线性分析, 讨论基于 EEG 的癫痫信号分析中使用最广泛的 4 类手工提取的特征及其计算方式.

时域特征是在 EEG 信号处理中最基础的特征, 主要是通过直接对原始信号的观察计算提取出相应的特征. 其优势在于计算简捷, 便于研究者直观理解. 但由于 EEG 信号本身的非平稳性, 个体差异和外界干扰等都容易影响时域特征.

频域特征的依据来自于癫痫发作时 EEG 的能量发生明显变化, 但依然以背景 EEG 是近似平稳的为假设. 大部分频域特征都来自于对信号功率谱的特征研究, 在进行谱特征提取时可采用多种参数估计方法, 参数的准确度也影响频域特征的质量.

若考虑特征所包含的信息量, 单纯的时域特征或频域特征都不能完备地对一段 EEG 信号进行刻画, 并且基于平稳性假设的 EEG 分析也并不严谨. 因此研究者便将目光投向了时频分析方法, 通过时频变换等手段将非平稳的 EEG 信号重新表示并提取相应特征.

随着神经科学的发展, 许多研究也将大脑看作一个非线性系统, 并从对系统的复杂度、持久性和同步性等变化的描述中总结了相应的非线性特征. 这些特征不受到 EEG 信号非平稳性的影响, 同时在应对多通道关联和通道缺失等问题时也更加灵活.

表 2 总结了近年来癫痫自动检测问题中涉及的四类特征及对应的参考文献.

2.1 时域特征

Katz 分形维数^[69]能够表现一段时间序列的复杂程度, 因此能够作为癫痫自动识别的潜在特征. 曲线弧长 (Curve length, CL)^[70]作为 Katz 分形维数的估计量, 通过计算相邻采样点之间的差异来反映信号的复杂度. 对于一段具有 N_s 个采样点的离散 EEG 信号 $x(n)$, 其曲线弧长的计算方法为:

$$CL(x(n)) = \sum_{i=2}^{N_s} |x_i - x_{i-1}|. \quad (1)$$

非线性能量算子 (Nonlinear energy, NE)^[71]是一种对信号进行能量测度的方法, 凸显信号的高频部分, 同时抑制低频部分. 通过对采样点的非线性能量算子取平均, 可得到 EEG 信号片段的非线性能量算子. 连续信号 $x(t)$ 在 t_0 时刻的 NE 计算方法为:

$$NE(x(t_0)) = x^2(t_0) - x(t_0)x''(t_0). \quad (2)$$

对于离散信号, 采样点 x_i 的 NE 计算方法为:

$$NE(x_i) = x_i^2 - x_{i-1}x_{i+1}. \quad (3)$$

直接对原始 EEG 信号进行计算, 可获得振幅的均方根 (Root mean squared amplitude, RMSAmp)、极值的出现次数 (Number of local maxima and minima)^[72]、过零率 (Zero crossing rate)^[72]等特征. 其中, 对于离散信号 $x(n)$ 而言, 在连续函数背景下的导数概念被差分替代, 因此研究中一般通过设定阈值 ε 的方法近似 0 值. 例如极值的定义为一阶差分小于设定阈值 ε ($\varepsilon = 0.01V$) 的采样点, 过零点需满足 $x_i < \varepsilon$ 和 $x_{i+5} > \varepsilon$.

峰度 (Kurtosis, *kurt*) 与偏态 (Skewness, *skew*) 是衡量数据分布情况的特征. 其中峰度表现分布的平坦程度, 偏态表现分布的对称程度, 若均值大于中位数则为右偏态, 反之为左偏态:

$$kurt(x(n)) = \frac{\frac{1}{N_s} \sum_{i=1}^{N_s} (x_i - \bar{x})^4}{\left(\frac{1}{N_s} \sum_{i=1}^{N_s} (x_i - \bar{x})^2\right)^2}. \quad (4)$$

$$skew(x(n)) = \frac{\frac{1}{N_s} \sum_{i=1}^{N_s} (x_i - \bar{x})^3}{\left(\frac{1}{N_s} \sum_{i=1}^{N_s} (x_i - \bar{x})^2\right)^{\frac{3}{2}}}. \quad (5)$$

在许多 EEG 研究中都用到了 Hjorth 特征^[73], 其中包括活动性 (Activity, σ^2)、移动性 (Mobility, δ) 和复杂度 (Complexity, λ) 三个参数:

$$\sigma_x^2 = var(x(n)) = \frac{1}{N} \left(\sum_{n=1}^N (x(n)) - \bar{x} \right)^2 \quad (6)$$

表 2 癫痫自动检测特征总结.

Table. 2 Summary of features used in automatic seizure detection.

文献	特征	类型
Gotman ^[6] Hjorth ^[73] Chandaka 等 ^[29] Kalatzis 等 ^[96] Putten 等 ^[72]	振幅、均值、变异系数等 Hjorth 参数 互相关图的图心、等效宽度等 平均绝对信号斜率、峰间值、峰间斜率 极值次数、过零率	时域特征
Park 等 ^[97] Alkan 等 ^[32] Gotman 等 ^[76] Naghsh-Nilchi 和 Aghashahi ^[34]	$\alpha, \beta, \theta, \gamma, \delta$ 波的功率谱并求其均值、方差、标准差等特征 功率谱 峰值频率、主频峰值带宽 频谱边缘频率	频域特征
Kiyimik 等 ^[35] Hernandez 等 ^[75] Pachori 和 Patidar ^[86] Ghayab 等 ^[98] Oweis 和 Abdulhay ^[99]	短时傅里叶变换 离散小波变换, 并提取均值、方差、标准差、最大值等特征 经验模态分解获得本征模态函数 使用可调 Q 因子小波变换进行时频变换 并提取均值、方差、标准差、偏态、峰度、中值等特征 希尔伯特-黄变换	时频域特征
Achary 等 ^[100] Tian 等 ^[101] Nicolaou 和 Georgiou ^[40] Azami 等 ^[102] Shayegh 等 ^[103] Mirowski 等 ^[104] Wang 等 ^[94] Faul 等 ^[105]	香浓熵、对数能量、近似熵、排列熵、Renyi 熵、模糊熵 谱熵 排列熵 多尺度模糊熵、样本熵 最大 Lyapunov 指数分量 最大互相关指数 Hurst 参数 奇异值分解熵、Kolmogorov 复杂度、条件熵、排列熵、 奇异谱的 Fisher 信息量、最大 Lyapunov 指数分量	非线性特征

$$\delta_x = \frac{\sigma'_x}{\sigma_x} = \sqrt{\frac{\text{var}(x'(n))}{\text{var}(x(n))}} \quad (7)$$

$$\lambda_x = \frac{\delta'_x}{\delta_x} = \frac{\sigma_x \sigma''_x - \sigma'^2_x}{\sigma'_x \sigma_x} \quad (8)$$

域的特征^[37, 75], 如能量 (Power, P)、均值 (Mean, μ)、一阶差分 (1^{st} difference, d_1) 及其标准化形式 (Normalized 1^{st} difference, nd_1)、二阶差分 (2^{nd} difference, d_2) 及其标准化形式 (Normalized 2^{nd} difference, nd_2):

其中 \bar{x} 表示信号 $x(t)$ 的均值. $x'(t)$ 表示信号 $x(t)$ 的一阶导数. σ'_x 表示信号 $x(t)$ 一阶导数的标准差. σ''_x 表示信号 $x(t)$ 二阶导数的标准差. 活动性表示信号的平均功率, 移动性可用于计算信号的平均频率, 复杂度测算信号的带宽. 直观上, 这 3 个量分别从振幅、斜率与斜率变化率的角度描述了 EEG 信号在时域上的特点, 被广泛应用. 对于长时 EEG 信号片段可取 Hjorth 参数的最大值、均值和方差作为特征.

此外, 由于 EEG 也广泛被用于情感计算、心理相关疾病研究、认知负荷评估^[74]等问题中, 现有的癫痫自动检测问题也借鉴了应用于上述研究领

$$P(x(n)) = \frac{1}{N_s} \sum_{i=1}^{N_s} |x_i|^2 \quad (9)$$

$$\mu_x = \frac{1}{N_s} \sum_{i=1}^{N_s} x_i \quad (10)$$

$$d_1(x(n)) = \frac{1}{N_s - 1} \sum_{i=1}^{N_s - 1} |x_{i+1} - x_i| \quad (11)$$

$$nd_1(x(n)) = \frac{d_1(x(n))}{\sigma_x} \quad (12)$$

$$d_2(x(n)) = \frac{1}{N_s - 2} \sum_{i=1}^{N_s-2} |x_{i+2} - x_i| \quad (13)$$

$$nd_2(x(n)) = \frac{d_2(x(n))}{\sigma_x} \quad (14)$$

2.2 频域特征

频域中最常用来刻画能量特征的物理量为功率谱密度 (Power spectral density, PSD). 图 2 为 Bonn 数据集 A (正常)、C (发作间期)、E (发作期) 子集^[66]各第一个样本的功率谱密度示例. 发作时 EEG 的 PSD 与其他状态有明显差异, 因此 PSD 是癫痫自动检测问题中经典的频域特征.




图 2 癫痫自动检测中脑电功率谱密度示例 (Bonn 数据集^[66]).

Fig. 2 EEG PSD for automatic seizure detection (Bonn dataset^[66]).

一般利用数据窗将信号切分为具有 m 个采样点的 N 个片段, 并计算对应的周期图, 利用平均周期图估计信号的功率谱. 对于信号 $x(n)$, 若第 p 个片段对应的周期图为 P_{x_p} , 则功率谱密度为:

$$PSD = \frac{1}{N} \sum_{p=0}^{N-1} P_{x_p}. \quad (15)$$

此外, Gotman 等^[76]将峰值频率 (Peak frequency) 和主频峰值带 (Band width) 用于对新生儿的癫痫发作检测. 利用 Zibrandtsen 等提出的频谱边缘频率 (Spectral edge frequency, SEF) 特征^[77], 可以求出不同频率范围下对应的 SEF (一般取总频谱功率 80%、90%、95% 之外的边缘频率), 同理利用 PSD 求出该对应频率范围的频谱总功率 (Total spectral power, TSP). 对每一子带的 PSD, 可提取均值、方差和熵等参数作为频域特征^[78, 79].

2.3 时频域特征

仅从时域或频域提取特征并不能全面表征癫痫问题中 EEG 的全部特性, 且 EEG 本质上并不能看

作近似平稳的信号. 因此一些研究通过时频变换得到 EEG 信号新的表示形式并提取相应特征, 进行癫痫自动检测.

将原始 EEG 信号转化成时频域表示有多种方法, 例如短时傅里叶变换 (Short time Fourier transform, STFT)、小波变换 (Wavelet transform, WT)^[80, 81]、经验模态分解 (Empirical mode decomposition, EMD)^[71, 82-84]、希尔伯特-黄变换 (Hilbert-Huang transform, HHT)^[72]、平均振幅谱 (Mean amplitude spectrum, MAS)^[85]等. 图 3 展示了 Bonn 数据集 A (正常)、E (发作期) 子集^[66]各第一个样本脑电经 $db4$ 小波分解后得到的各个子波分量. 其中原始 EEG 信号由红色表示, 各个子波分量如蓝色所示. 发作期脑电的各个小波分量的振幅、频率等都与正常状态脑电有较为明显的差异.

经离散小波变换 (Discrete wavelet transform, DWT) 得到的子带信号中, 可以提取对应频带小波系数的均值、方差、极值、均方根、递归能量效率 (Recursive energy efficiency, REE)^[75, 80]、模糊近似熵^[81]等特征, 以实现癫痫发作自动检测. 经 EMD 分解后得到若干个本征模态函数 (Intrinsic mode function, IMF), 采用 IMF 的绝对值^[82, 86]、能量^[83]、平均频率^[84, 87]、互信息^[88]能够得到相应的时频域特征. 对 IMF 进行 HHT 可获得其瞬时频率, 其均值与方差能够用以表征时频信息^[89].

2.4 非线性特征 (Nonlinear Analysis)

熵 (Entropy, En) 是能够表征脑电复杂度的物理量. 研究表明发作期脑电的不确定度会明显降低^[90], 因此围绕与熵有关的特征提取有大量的研究. 例如, Fisher 信息 (Fisher information, FI)、谱熵 (Spectral entropy, $SpEn$)^[71, 91]、香农熵 (Shannon's entropy, $ShEn$)^[92]、近似熵 (Approximate entropy, $ApEn$)^[38, 81]等:

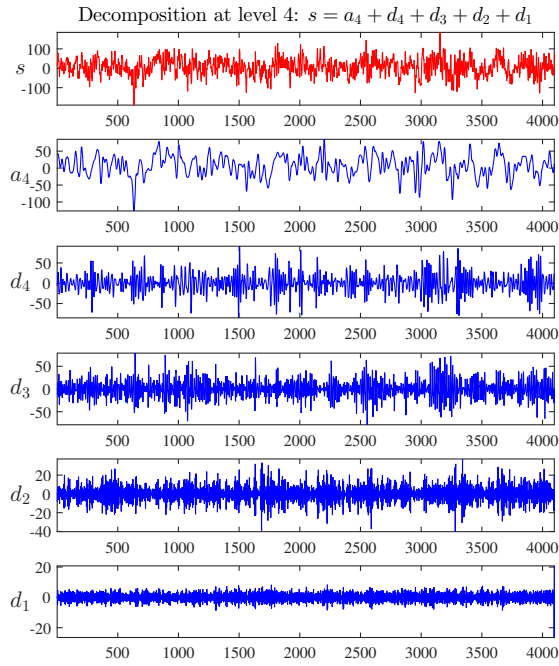
$$FI(x(n)) = - \sum_{i=1}^{N_s} \frac{(x_{i+1} - x_i)^2}{x_i} \quad (16)$$

$$SpEn(x(n)) = - \frac{1}{\log N_f} \sum_f P_f(x(n)) \ln P_f(x(n)) \quad (17)$$

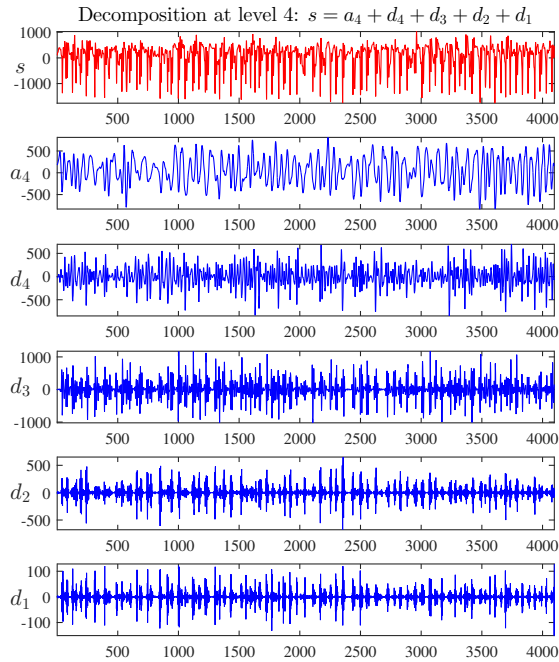
$$ShEn(x(n)) = - \sum_f P_h(x(n)) \ln P_h(x(n)) \quad (18)$$

$$ApEn = \phi^{d_E-1}(r) - \phi^{d_E}(r) \quad (19)$$

其中, P_f 为该 EEG 信号的概率密度函数, N_f 为频率分量个数, P_h 为概率密度函数的周期图估计, $\phi^{d_E}(r)$ 表示相邻两点的近似程度, r 为相似距离, d_E



(a) Wavelet transform for normal EEG.




(b) Wavelet transform for seizure EEG.

图 3 脑电图经小波变换后各分量示例 (Bonn 数据集^[66]).Fig. 3 Wavelet transforms for automatic seizure detection (Bonn dataset^[66]).

为嵌入的维度.

此外, 样本熵 (Sample Entropy)^[93]和排列熵 (Permutation entropy)^[40]等也可作为特征. 图 4 为 Bonn 数据集 A (正常)、C (发作间期)、E (发作期) 子集^[66]各第一个样本的样本熵示例.

图 4 癫痫自动检测中的脑电样本熵示例 (Bonn 数据集^[66]).Fig. 4 Sample entropy for automatic seizure detection (Bonn dataset^[66]).

Hurst 参数 (Hurst exponent, HE)^[94]是一种衡量时间序列随机性的指标. 一般来说, 未发作阶段 EEG 信号更具有随机性, 发作期由于具有典型棘慢波, 序列的局部趋势性越强, Hurst 指数更接近 1. 与之类似, 去趋势波动指标通过对局部趋势进行拟合并计算信号与之的 RMS, 也能表征信号的随机性. 由于发作期神经元同步放电, 通道间的同步性特征也被用于癫痫自动检测研究, 如 Lyaounov 指数 (Lyapunov exponent) 的差异性、最大互相关指数^[92, 95]等.

3 癫痫自动检测的分类模型

本节讨论基于 EEG 的癫痫自动检测中常见的统计分析模型和机器学习模型. 表 3 总结了近年研究中用到的机器学习分类方法与对应结果.

3.1 统计分析

统计分析模型可对待测信号的特征统计量或与模板信号之间的分布差异、相关性等设定阈值, 实现棘波检测. Li 等^[106]利用 Kullback-Leibler 测度衡量 EEG 信号时频分析的 Choi-Williams 分布 (CWD) 差异, 再经奇异值分解并结合阈值分析, 达到超过 90% 的棘波检测正确率. Huan 等^[49]通过瞬时频率的时频分析获得离散 CWD, 使用相关性分析计算待测 EEG 信号离散 CWD 的高频部分和基本棘波的中心瞬时频谱之间的相关系数, 实现棘波检测. Huan 等^[47]通过计算统一尺度下离散 CWD 的频谱差变化并与阈值比对, 实现 89.5% 棘/尖波检出

表 3 癫痫自动检测机器学习方法总结.

Table. 3 Summary of automatic seizure detection methods.

作者	数据集	特征	分类器	结果
Guo 等 ^[131]	Bonn	ApEn	ANN	Acc: 98.27 %
Liang 等 ^[44]	Bonn	ApEn、频域特征	LDA、SVM、ANN	Acc: 97.82-98.51%
Samiee 等 ^[50]	Bonn	时频域特征	NB、LR、SVM、K近邻、ANN	Acc: 98.3%
Zhang 等 ^[132]	Bonn	频率切片小波变换	SVM	Acc: 98.33%
Yan 等 ^[133]	Bonn	SAE	SVM	Acc: 100.0%
Ahmed 等 ^[109]	未公开数据	时域、频域、非线性特征	SVM、RBF-SVM	Sen: 82.6%, Spec: 90%
Acharya 等 ^[56]	Bonn	DCNN	DCNN	Acc: 88.67%
Qiu 等 ^[134]	Bonn	DSAE	LR	Acc: 100.0%
Yuan 等 ^[135]	CHB-MIT	SAE	PSVM	Acc: 96.61%
Ahmedt 等 ^[136]	QUT、MAEUnit	CNN	SVM	Acc: 95.19%
Hussein 等 ^[137]	Bonn	时域、频域、时频域	Softmax	Acc: 100.0%
Roy 等 ^[138]	Bonn	CNN、RNN	LR、MLP	Acc: 82.04%
Thomas 等 ^[139]	MGH	CNN	SVM	Acc: 83.86%
Daoud 等 ^[140]	Bonn	非线性特征	DCNN、MLP	Acc: 98.6%
Hu 等 ^[85]	CHB-MIT	MAS+CNN	SVM	Acc: 86.25%
Jaafar 等 ^[141]	Freiburg	LSTM	Softmax	Acc: 97.75%
Chen 等 ^[142]	Bonn	DWT+非线性特征	SVM	Acc: 99.5%
Tian 等 ^[61]	CHB-MIT	时域、频域、时频域	NB、DT、SVM、K近邻、TSK-FS	Acc: 98.33%
Cao 等 ^[143]	CHB-MIT	CNN	SVM、KNN、ELM、KELM、RF	Acc: 99.33%
Zhang 等 ^[144]	TUH	CNN	RF、KNN、SVM	Acc: 97.4%

率. Yadav^[107]利用形态学分析 (Morphology Analysis), 统计尖峰斜率和尖峰间隔时间, 与设定阈值对应比较实现棘波检测, 在线检测误报率为 0.1/h, 平均时延 9.1s.

统计分析模型进行分类时, 模型的判断依据计算简单、易于理解和实现. 其缺陷在于: 1. 判别严重依赖专业化的参数设置或参与比对的模板信号, 而 EEG 信号个体差异显著且具有非平稳性, 使得这类模型的通用性受限; 2. 专家特征往往是实际物理量, 这类模型无法处理特征之间的隐关系以及隐藏的深度特征, 使得模型的准确性受限.

3.2 传统机器学习

常用传统机器学习模型包括支持向量机 (Support vector machine, SVM)^[37, 53, 108, 109]、线性判别分析 (Linear discriminant analysis, LDA)^[51]、朴素贝叶斯 (Naïve Bayes, NB)^[50]、逻辑回归 (Logistic regression, LR)、随机森林 (Random forest, RF)^[54]等. Li 等^[110]利用双重密度离散小波变换并提取各个分量的非线性特征, 并使用 ANOVA 选择 Hurst 参数、模糊熵等作为分类特征, 采用 SVM 进行分类. Reddy 等^[111]计算可调 Q 因子小波变换所得小波分量的中心相关熵, 并采用 RF、LR、

多层感知机等模型进行癫痫信号识别. Jaiswal 和 Banka^[52]提出了局部梯度模式转换的特征提取方法, 并采用 K 近邻、SVM、决策树等分类方法进行癫痫检测.

传统机器学习模型的优势在于模型的复杂度低、可解释性强, 但需要研究人员对癫痫的生理机理和临床表现有深入理解. 由于依赖专家经验, 深层特征不易被观察和提取, 因此模型准确性受限. 此外, 若对被测信号提取特征的过程耗时过长, 实际场景中模型效率受影响.

3.3 深度学习

随着深度学习近年来在图像、语音、文本等领域的迅猛发展, 深度神经网络 (Deep neural network, DNN) 模型在癫痫自动检测中也逐渐得到应用. 提取深度特征可消除对手工特征的依赖, 且在处理多通道数据时相较于传统模型有显著优势.

常用的基于 EEG 的深度学习癫痫自动检测方法包括 3 类: (1) 卷积神经网络模型 (Convolutional neural network, CNN); (2) 循环神经网络模型 (Recurrent neural network, RNN); (3) 自编码器模型 (Autoencoders, AE).

CNN 类模型通过池化和卷积提取输入数据的

特征. 根据模型输入数据的维度数分为 1D-CNN 和 2D-CNN 两种机制. 其中 2D-CNN 一般将原始 EEG 信号通过时频变换等方式转换成 2 维图像信号并利用 CNN 实现癫痫自动检测. 例如, Avcu 等^[112]提出的 seizureNet 通过傅里叶变换将原始信号转换成时频图再利用卷积层学习实现癫痫自动检测. Covert 等^[113]提出时间图网络算法将原始 EEG 信号转换成时间图并利用 5 种不同层数的 CNN 网络实现癫痫自动检测. Li 等^[114]同时提取信号的多尺度时、频域特征, 将压缩-激励网络 (Squeeze-and-Excitation Networks, SENet) 嵌入 CNN 模型, 实现自动检测, 在癫痫发作事件检测和癫痫发作期检测的实验中, 都取得了很高的准确率和敏感性. Thodoroff 等^[115]将原始 EEG 信号利用快速傅里叶变换和电极采样位置的 2 维投影合成并进行三次样条插值, 得到的平滑图像后利用循环卷积神经网络 (Recurrent CNN, RCNN) 实现自动检测, 获得了极高的敏感性和较低的误报率. Bizopoulos 等^[57]使用 LeNet、AlexNet、VGGNet、ResNet、DenseNet 作为检测模型对图像化的 EEG 信号进行癫痫自动检测. 1D-CNN 适合直接对 EEG 信号进行处理, 具有相对于 2D-CNN 更直观的网络结构, 且更小的运算符代价. 同时, 将原始 EEG 信号转化为时频图像可能带来一定的信息损失, 因此 1D-CNN 能够更大程度的利用数据信息. 常见思路是将原始信号按照时间窗切分后以一维形式输入 CNN 网络.

针对音频、视频等随时间变化的数据, 常用的深度学习模型为 RNN, 以长短时记忆 (Long-Short term memory, LSTM) 与门控循环单元 (Gated recurrent unit, GRU) 结构为主. LSTM 解决了模型学习之前时间对当前时间数据信息的影响, 和反向传播时梯度消失的问题. Chen 等^[63]利用 3 层 LSTM 网络进行特征提取后通过 sigmoid 函数分类, 得到 96.82% 的准确率. GRU 是 LSTM 的变体, 将 LSTM 中的输入门和遗忘门合并为更新门, 降低了 LSTM 模型的复杂度. Roy 等^[117]设计了 5 层 GRU 网络 ChronoNet, 通过 softmax 函数分类得到 92.84% 的准确率.

AE 是一种无监督深度学习结构, 通过对原始数据的降维表示实现分类. AE 包含编码器和解码器两个部分. 编码器可将高维的输入数据降维, 并得到与输入数据对应的隐藏层表示. 隐藏层表示重新通过解码器恢复为原始维度, 从而实现原始输入的重构. Sharathappriyaa 等^[118]首先使用 Harmonic 波包变换, 再将子带信号进行特征提取并使用 AE 进行癫痫诊断. Rajaguru 等^[119]利用多层自编码器和期望最大化主成分分析方法确定输入数据的重新表示, 再利用遗传算法分类, 实现 93.78% 的癫痫检

测正确率.

相较于传统机器学习模型, 深度学习模型可学习无法手工提取的深度特征或模式, 以此提升最终分类效果. 同时, 深度学习模型融合了传统模型中特征提取与分类两步, 在训练数据足够的情况下能取得更好的学习效果, 且节省检测时间. 然而, 深度学习模型往往依赖大量数据, 否则容易因参数过拟合影响模型泛化性能^[56].

3.4 迁移学习

上述癫痫自动检测模型是基于训练数据与测试数据具有相同数据特征分布的假设. 但 EEG 信号个体差异显著, 实际应用中, 测试数据和模型的训练数据往往不服从独立同分布假设, 因此克服个体差异的通用癫痫自动检测模型更有实际价值. 迁移学习^[120]是利用相关域的标注数据或知识结构, 完成或改进对目标域的学习的机器学习模型. 对于通用的癫痫自动检测模型, 用于训练模型的数据和实际测试数据可能来自于不同的个体, 其信号的分布或存在较大的差异, 且训练数据量受限, 因而可通过迁移学习模型提高癫痫自动检测模型的泛化性能和正确率. 如何进行有效迁移以提高模型泛化性能是迁移学习考虑的重点.

基于手工提取的特征, Yang 等^[59]提出利用特征空间内大间隔直推式迁移学习的 LMPROJ 方法最小化训练数据与目标数据手工提取的特征之间的分布均值差, 实现 EEG 信号自适应识别, 分类准确率超过 93%, 显著优于传统机器学习. Jiang 等^[121]把测试数据和训练数据的最大均值差异融合到 TSK 模糊系统模型中, 对原始 EEG 信号通过小波包变换、STFT 和核主成分分析等得到的手工特征进行分类, 检测正确率相比于无迁移学习有大幅提升.

深度学习和迁移学习也可融合, 进行深度迁移学习. Zhang 等^[60]对 VGG16、VGG19 和 ResNet50 三种 CNN 网络参数进行迁移, 并将原始 EEG 信号通过时频变换转换为时频图, 在跨用户的癫痫自动检测实验中平均准确率超过 96%. Zhu 等^[122]引入迁移学习中的元学习 (Meta learning), 在模型层面上通过记忆增强相关结构使模型通过少量样本快速学习, 同时改进距离矩阵的运算, 再通过经预训练的基学习器和元学习器, 不断优化参数实现稳定分类.

3.5 多视图学习

多视图学习^[123]基于视图一致性和互补原则, 利用多个不同视图之间的差异性和相似性, 提高模型分类精度. 多视图学习包括协同训练、多核学习和子空间学习等类别. 协同训练通过对不同视图执行交替训练, 最大化视图一致性; 多核学习通过使用不同的内核训练模型并关联到不同的视图, 再通过内

核的线性或非线性组合提高学习性能;子空间学习则通过获得多个视图的公共子空间,提高数据一致性.如何最大化视图间的信息互补和对应模型的一致性是多视图学习的难点.

在癫痫自动检测中,Tian等^[61]利用CNN模型提取EEG信号的时域、频域和时频域深度特征,并构建为三个视图,通过多视图TSK模糊系统进行多视图学习,提升了相较于单一视图的分类检测效果.Yuan等^[124]通过通道感知技术,利用AE提取多通道EEG信号的通道特征和通道内的时频特征两类视图,实现多视图癫痫自动检测.Liu等^[125]利用用户敏感模型进行通道选择,再针对选择的通道各个子频段提取时频特征构成多视图特征.通过公共空间投影矩阵提取数值和形态学特征,并利用最大平均差异自编码器提取通道间时频域特征,实现多视图的癫痫自动检测.

3.6 集成学习

集成学习模将多个基分类器(弱分类器)集成成强分类器以提高分类效果,主要包括Bagging、Boosting和Stacking三种学习策略^[126].Bagging随机改变训练集的分布而产生多个训练子集,对应训练多个基学习器再进行集成.Boosting在弱学习器的基础上,增大上一轮被错误分类的样本的权重并训练新模型,最终组成强学习器.Stacking首先训练多个不同的基学习器,再把其输出作为输入训练一个新的分类模型.集成学习的难点是如何同时提高基学习器的准确性和多样性.

在癫痫自动检测中,Hosseini等^[127]对手工提取的特征进行了子空间划分,并使用基于Bagging的集成学习模型实现癫痫自动检测.Abualsaud等^[128]通过压缩感知对原始EEG信号进行重构,再使用Stacking融合多个传统机器学习模型实现癫痫发作期分类.Akyol^[129]使用多个DNN基学习器分别对原始EEG输入信号进行学习,然后将其分类结果输入下一层的元学习器进行Stacking融合,达到较好的分类性能.

3.7 主动学习

主动学习从大量无标注样本中选择最用的样本进行标注,从而可以通过更少的标注样本达到要求的分类效果.主动学习很适合癫痫检测,因为EEG信号很容易获取,但在实际训练癫痫检测模型时,为信号打标签非常费时乏味,给医生带来很大负担,而主动学习可有效缓解这一问题.主动学习的核心在于如何选择对构建分类模型最有用的样本.

在癫痫自动检测中,Chen等^[63]提出了double-DNN模型,主DNN模型运用最小置信度估计样本不确定性,副DNN模型根据主DNN模型的输出

计算样本的误分类代价,并通过欧式距离估计候选样本与已知样本的差异程度确定样本的多样性,结合上述三个指标选择最有用的EEG样本进行标注.Ramachandran等^[130]对EEG手工特征进行分类,对于超过阈值的样本通过基于伯努利-高斯混合模型的主动学习模型重新确定其不确定度,进而不断优化分类模型,提高模型对分类边界处样本的感知能力.

4 结论与展望

癫痫自动检测,即自动识别癫痫的发作状态,能够大幅减轻医疗工作者负担,并降低医生主观判断病情的不确定性.鉴于EEG是一种低成本、易获取且无创的临床生理信号,基于EEG的癫痫自动检测是提高癫痫检测、治疗效率的有效手段.本文首先系统地阐述了基于EEG的癫痫自动检测流程,并对其各个步骤中所涉及到的具体方法进行了详细、全面的调研和总结.其中特征提取与分类器是该流程的核心模块,因此本文对典型的脑电特征和常用分类器进行了详细的描述.

根据上述调研与分析,结合基于EEG的癫痫自动检测实际应用场景需求,本文从以下几个方面对该领域今后的研究方向进行展望:

1. 使用传统机器学习方法时,提取出有效的分类特征是癫痫检测的关键.通过传统方法进行癫痫发作检测目前已经能够达到较高的检出水平,但如何区分癫痫亚型疾病、如何区别发作期与发作间期以实现癫痫疾病的预测,仍然是值得探讨的问题.
2. 当前的癫痫自动检测效果主要受限于现有的公开数据集数量和质量.很多研究是在非公开数据集上进行的,这也导致其模型的可靠度与可重复性大大降低.因此,建立大型的高质量癫痫EEG数据集是非常有必要的,有助于公平、透明地对比不同检测模型的效果.
3. 近年来兴起的迁移学习方法可以通过由源域向目标域迁移,利用更多源域数据,提高分类性能,为提高单一数据来源的癫痫自动检测模型鲁棒性提供新的解决思路.
4. 对于不同类别的癫痫疾病识别也需进一步探索.首先,医学研究显示,某些类型的癫痫会导致特定的肢体动作和肌肉活动,与此相关的伪迹信号应该如何剔除值得深入研究.其次,如何设计高效的分类模型进行多类癫痫识别,并提高不同类型癫痫间的区分能力具有相当大的临床意义,特别是对于医疗资源欠发达地区而言.
5. 随着可穿戴设备的不断发展,除了现有针对

EEG 信号的特征提取外, 其他生理特征的融合也具有相当的研究价值. 既往研究显示^[145] 血氧饱和度 (Blood oxygen saturation, SpO₂) 与癫痫发作的终止有关. 将诸如此类的其他特征指标与 EEG 结合, 并运用多视图等机器学习方法进行癫痫自动检测, 有望进一步提高检测准确度.

6. 近年随着深度学习的迅猛发展, 大量基于深度学习的自动检测方法被广泛地应用于癫痫自动检测, 并取得了良好效果. 但该类方法也存在许多挑战. 第一, 深度学习往往依赖于大量数据, 但实际研究中受限于数据集, 很难获得大量的训练样本, 这对于模型的准确性和鲁棒性都会造成较大影响. 第二, 现有的公开数据集几乎都是 EEG 信号片段, 与实际场景中连续实时信号存在差异, 在解决实际问题时, 利用 EEG 片段信号训练的神经网络模型可能并不能很好地适应现实数据. 最后, 由于实际使用中计算资源受限, 轻量级的神经网络模型将会更实用.

References

- Casson A, Yates D, Smith S, Duncan J, Rodriguez-Villegas E. Wearable Electroencephalography. *IEEE Transactions on Engineering in Medicine and Biology Magazine*, 2010, **29**(3): 44–56
- Stevens J R, Lonsbury B L, Goel S L. Seizure occurrence and interspike interval: telemetered electroencephalogram studies. *Archives of neurology*, 1972, **26**(5): 409–419
- Gastaut H, Magnus O, Caveness W F, Merlis J K, Landolt H, Pond D A, et al. A proposed international classification of epileptic seizures. *Epilepsia*, 1964, **5**: 297–306
- Gandhi T, Panigrahi B K, Bhatia M, Anand S. Expert model for detection of epileptic activity in EEG signature. *Expert Systems with Applications*, 2010, **37**(4): 3513–3520
- Noachtar S, Rémi J. The role of EEG in epilepsy: A critical review. *Epilepsy & Behavior*, 2009, **15**(1): 22–33.
- Gotman J. Automatic recognition of epileptic seizures in the EEG. *Electroencephalography and Clinical Neurophysiology*, 1982, **54**(5): 530–540
- Geertsema E E, Visser G H, Velis D N, Claus S P, Zijlmans M, Kalitzin S N. Automated seizure onset zone approximation based on nonharmonic high-frequency oscillations in human interictal intracranial EEGs. *International Journal of Neural Systems*, 2015, **25**(5): 1550015.
- Khan Y U, Farooq O, Sharma P. Automatic detection of seizure onset in pediatric EEG. *International Journal of Embedded Systems and Applications*, 2012, **2**(3): 81–89
- Grewal S, Gotman J. An automatic warning system for epileptic seizures recorded on intracerebral EEGs. *Clinical Neurophysiology*, 2005, **116**(10): 2460–2472
- Kharbouch A, Shoeb A, Gutttag J, Cash S S. An algorithm for seizure onset detection using intracranial EEG. *Epilepsy & Behavior*, 2011, **22**(1): S29–S35
- Sorensen T L, Olsen U L, Conradsen I, Henriksen J, Kjaer T W, Thomsen C E, et al. Automatic epileptic seizure onset detection using Matching Pursuit: a case study. In: *Proceedings of the 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*. Buenos Aires, Argentina: IEEE, 2010. 3277–3280
- Worrell G A, Gardner A B, Stead S M, Hu S, Goerss S, Cascino G J, et al. High-frequency oscillations in human temporal lobe: simultaneous microwire and clinical macro-electrode recordings. *Brain : a Journal of Neurology*, 2008, **131**(4): 928–937
- Jacobs J, LeVan P, Chander R, Hall J, Dubeau F, Gotman J. Interictal high-frequency oscillations (80-500Hz) are an indicator of seizure onset areas independent of spikes in the human epileptic brain. *Epilepsia*, 2008, **49**(11): 1893–1907
- Chaibi S, Sakka Z, Lajnef T, Samet M, Kachouri A. Automated detection and classification of high frequency oscillations (HFOs) in human intracerebral EEG. *Biomedical Signal Processing and Control*, 2013, **8**(6): 927–934
- Spanedda F, Cendes F, Gotman J. Relations Between EEG Seizure Morphology, Interhemispheric Spread, and Mesial Temporal Atrophy in Bitemporal Epilepsy. *Epilepsy*, 1997, **38**(12): 1300–1314
- Zhang J, Zou J, Wang M, Chen L, Wang C, Wang, G. Automatic detection of interictal epileptiform discharges based on time-series sequence merging method. *Neurocomputing*, 2013, **110**(13): 35–43
- Karacor D, Nazlibilek S, Sazli M H, Akarsu E S. Discrete Lissajous figures and applications. *IEEE Transactions on Instrumentation and Measurement*, 2014, **63**(12): 2963–2972
- Sun Yu-Bao, Wu Min, Wei Zhi-Hui, Xiao Liang, Feng Can. EEG Spike Detection Using Sparse Representation. *Acta Electronica Sinica*, 2009, **37**(9): 1971–1976(in Chinese) (孙玉宝, 吴敏, 韦志辉, 肖亮, 冯灿. 基于稀疏表示的脑电棘波检测算法研究. *电子学报*, 2009, **37**(9): 1971–1976)
- Casson A J, Rodriguez-Villegas E. Toward online data reduction for portable electroencephalography systems in epilepsy. *IEEE Transactions on Biomedical Engineering*, 2009, **56**(12): 2816–2825
- Fürbass F, Hartmann M, Halford J J, Koren J P, Herta J, Gruber A, et al. Automatic detection of rhythmic and periodic patterns in critical care EEG based on American Clinical Neurophysiology Society (ACNS) standardized terminology. *Neurophysiologie Clinique/Clinical Neurophysiology*, 2015, **45**(3): 203–213
- Hussein A F, Arunkumar N, Gomes C, Alzubaidi A K, Habash Q A, Santamaria-Granados L, et al. Focal and non-focal epilepsy localization: a review. *IEEE Access*, 2018, **6**: 49306–49324
- Liu Chang-Yuan, Zhang Fu-Hao, Wei Qi. Intelligent diagnosis and research of epileptic diseases based on EEG signals. *Journal of Harbin University of science and technology*, 2018, **23**(3): 91–98(in Chinese) (柳长源, 张付浩, 韦琦. 基于脑电信号的癫痫疾病智能诊断与研究. *哈尔滨理工大学学报*, 2018, **23**(3): 91–98)
- Li Ying, Ouyang Kai. Study of automatic detection of epileptiform waves in children EEG. *Chinese Journal of Biomedical Engineering*, 2005, **24**(5): 541–545(in Chinese) (李莹, 欧阳楷. 自动检测儿童脑中癫痫波的方法研究. *中国生物医学工程学报*, 2005, **24**(5): 541–545)

- 24 Shoeb A, Gutttag J. Application of machine learning to epileptic seizure detection. In: Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel, 2010
- 25 Oikonomou V, Tzallas A, Fotiadis D. A Kalman filter based methodology for EEG spike enhancement. *Computer Methods and Programs in Biomedicine*, 2007, **85**(2): 101–108
- 26 Ille N, Berg P, Scherg M. Artifact correction of the ongoing EEG using spatial filters based on artifact and brain signal topographies. *Journal of Clinical Neurophysiology*, 2002, **19**(2): 113–124
- 27 Delorme A, Sejnowski T, Makeig, S. Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis. *NeuroImage*, 2007, **34**(4): 1443–1449
- 28 Kevric J, Subasi A. The effect of multiscale PCA de-noising in epileptic seizure detection. *Journal of Medical Systems*, 2014, **38**(10): 131–289
- 29 Chandaka S, Chatterjee A, Munshi S. Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Systems with Applications*, 2009, **36**(2): 1329–1336
- 30 Altunay S, Telatar Z, Eroglu O. Epileptic EEG detection using the linear prediction error energy. *Expert Systems with Applications*, 2010, **37**(8): 5661–5665
- 31 Joshi V, Pachori, R B, Vijesh A. Classification of ictal and seizure-free EEG signals using fractional linear prediction. *Biomedical Signal Processing and Control*, 2014, **9**: 1–5
- 32 Alkan A, Koklukaya E, Subasi A. Automatic seizure detection in EEG using logistic regression and artificial neural network. *Journal of Neuroscience Methods*, 2005, **148**: 167–176
- 33 Subasi A, Ercebebi E, Alkan A, Koklukaya E. Comparison of subspace-based methods with AR parametric methods in epileptic seizure detection. *Computers in Biology and Medicine*, 2006, **36**(2), 195–208
- 34 Naghsh-Nilchi A R, Aghashahi M. Epilepsy seizure detection using eigen-system spectral estimation and Multiple Layer Perceptron neural network. *Biomedical Signal Processing and Control*, 2010, **5**(2): 147–157
- 35 Kıymık M K, Güler İ, Dizibüyük A, Akın M. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Computers in biology and medicine*, 2005, **35**(7): 603–616
- 36 Sadati N, Mohseni H R, Maghsoudi A. Epileptic Seizure Detection Using Neural Fuzzy Networks. In: Proceedings of the 2006 IEEE International Conference on Fuzzy Systems. Vancouver, Canada: IEEE, 2006. 596–600
- 37 Li S, Zhou W, Yuan Q, Geng S, Cai D. Feature extraction and recognition of ictal EEG using EMD and SVM. *Computers in Biology and Medicine*, 2013, **43**(7): 807–816
- 38 Richman J S, Moorman J R. Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology*, *American Physiological Society*, 2000, **278**(6): 2039–2049
- 39 Conigliaro D, Manganotti P, Menegaz G. Multiscale sample entropy for time resolved epileptic seizure detection and fingerprinting. In: Proceedings of the 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Florence, Italy: IEEE, 2014. 3582–3585
- 40 Nicolaou N, Georgiou J. Detection of epileptic electroencephalogram based on Permutation Entropy and Support Vector Machines. *Expert Systems with Applications*, 2012, **39**(1): 202–209
- 41 Hurst H E. Methods of using long-term storage in reservoirs. *Hydrological Sciences Journal*, 1956, **1**(3): 13–27
- 42 Acharya U R, Sree S V, Suri J S. Automatic detection of epileptic EEG signals using higher order cumulant features. *International Journal of Neural Systems*, 2011, **21**(5): 403–414
- 43 Yao D. Electroencephalography inverse problem by subspace decomposition of the fourth-order cumulant matrix. *Journal of biomedical engineering*, 2000, **17**(2): 174–178(in Chinese)
(尧德中. 基于四阶累积量矩阵自空间分解的脑电逆问题算法. 生物医学工程学杂志, 2000, **17**(2): 174–178)
- 44 Liang S-F, Wang H-C, Chang W-L. Combination of EEG complexity and spectral analysis for epilepsy diagnosis and seizure detection. *EURASIP Journal on Advances in Signal Processing*, 2010, 853434
- 45 Kuhlmann L, Cook M J, Fuller K, Grayden D B, Burkitt A N, Mareels I. Correlation analysis of seizure detection features. In: Proceedings of the 2008 International Conference on Intelligent Sensors, Sensor Networks and Information Processing. Sydney, Australia: IEEE, 2008. 309–314
- 46 Ong P, Zainuddin Z, Lai K H. A novel selection of optimal statistical features in the DWPT domain for discrimination of ictal and seizure-free electroencephalography signals. *Pattern Analysis and Applications*, 2018, **21**: 515–527
- 47 Huan Fei, Wang Zhi-zhong, Zheng Chong-xun. Automatic detection of epileptiform spikes in EEG based on time-frequency analysis. *Acta Biophysica sinica*, 2000, **16**(3): 539–546(in Chinese)
(宦飞, 王志中, 郑崇勋. 基于时频分析检测EEG中癫痫样棘/尖波的方法. 生物物理学报, 2000, **16**(3): 539 – 546)
- 48 Yadav R, Shah A, Loeb J, Swamy M, Agarwal R. Morphology-Based automatic seizure detector for intracerebral EEG recordings. *IEEE Transactions on Biomedical Engineering*, 2012, **59**(7) :1871-1881
- 49 Huan Fei, Zheng Chong-xun, Huang Yuan-gui. Correlation detection of spikes in EEG based on time-frequency distribution. *Chinese Journal of Scientific Instrument*, 1999, **20**(5):446–450(in Chinese)
(宦飞, 郑崇勋, 黄远桂. 基于时频分布的EEG中棘波的相关检测. 仪器仪表学报, 1999, **20**(5): 446–450)
- 50 Samiee K, Kovacs P Gabbouj M. Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform. *IEEE Transactions on Biomedical Engineering*, 2015, **62**(2): 541–552
- 51 Qaraqe M, Ismail M, Serpedin E, Zulfi H. Epileptic seizure onset detection based on EEG and ECG data fusion, *Epilepsy & Behavior*, 2016, **58**: 48–60
- 52 Jaiswal A K, Banka H. Local pattern transformation based feature extraction techniques for classification of epileptic EEG signals. *Biomedical Signal Processing and Control*, 2017, **34**: 81–92

- 53 Boashash B, Ouelha S. Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG seizure case study. *Knowledge-Based Systems*, 2016, **106**(15): 38–50
- 54 Alam S M S, Bhuiyan M I H. Detection of seizure and epilepsy using higher order statistics in the EMD domain. *IEEE Journal of Biomedical and Health Informatics*, 2013, **17**(2): 312–318
- 55 Wei, Z, Zou J, Zhang J, Xu J. Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain. *Biomedical Signal Processing and Control*, 2019, **53**: 101551
- 56 Acharya U R, Oh S L, Hagiwara Y, Tan J H, Adeli H. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, 2018, **100**(1): 270–278
- 57 Bizopoulos P, Lambrou G I, Koutsouris D. Signal2image modules in deep neural networks for eeg classification. In: Proceedings of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Berlin, Germany: IEEE, 2019. 702–705
- 58 Kiral-Kornek I, Roy S, Nurse E, Mashford B, Karoly P, Carroll T, et al. Epileptic Seizure Prediction Using Big Data and Deep Learning: Toward a Mobile System. *EBioMedicine*, 2018, **27**: 103–111
- 59 Yang Chang-jian, Deng Zhao-hong, Jiang Yi-zhang, Wang Shi-tong. Adaptive recognition of epileptic EEG signals based on transfer learning. *Journal of Frontiers of Computer Science and Technology*, 2014, **8**(3): 158–164(in Chinese) (杨昌健, 邓赵红, 蒋亦樟, 王士同. 基于迁移学习的癫痫EEG信号自适应识别. *计算机科学与探索*, 2014, **8**(3):158–164.)
- 60 Zhang B, Wang W, Xiao Y, Xiao S, Chen S, Chen S, et al. Cross-Subject Seizure Detection in EEGs Using Deep Transfer Learning. *Computational and Mathematical Methods in Medicine*, 2020: 7902072
- 61 Tian X, Deng Z, Ying W, Choi K, Wu D, Qin B, et al. Deep multi-view feature learning for EEG-based epileptic seizure detection. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, **27**(10): 1962–1972
- 62 Abualsaud K, Mahmuddin M, Saleh M, Mohamed A. Ensemble Classifier for Epileptic Seizure Detection for Imperfect EEG Data. *The Scientific World Journal*, 2015: 945689.
- 63 Chen X, Ji J, Ji T, Li P. Cost-sensitive deep active learning for epileptic seizure detection. In: Proceedings of the 2018 ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics. Washington D.C.: ACM, 2018. 226 - 235
- 64 Ihle M, Feldwisch-Drentrup H, Teixeira C A, Witon A, Schelter B, Timmer J, et al. Epilepsiae-a european epilepsy database. *Computer methods and programs in biomedicine*. 2012, **106**(3): 127–138
- 65 Shoeb A H. Application of machine learning to epileptic seizure onset detection and treatment. [Ph.D dissertation], MIT, 2009
- 66 Andrzejak R G, Lehnertz K, Mormann F, Rieke C, David P, Elger C E. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 2001, **64**(1): 061907
- 67 American epilepsy society seizure prediction challenge [Online], available: <https://www.kaggle.com/c/seizure-prediction/>, November 17, 2014
- 68 Andrzejak R G, Schindler K, Rummel C. Nonrandomness nonlinear dependence, and nonstationarity of electroencephalographic recordings from epilepsy patients. *Physical Review E*, 2012,**86**(4): 046206
- 69 Katz M J. Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 1988, **18**(3): 145–156
- 70 Esteller R, Echaz J, Tchong T, Litt B, Pless B. Line length: an efficient feature for seizure onset detection. In: Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Istanbul, Turkey: IEEE, 2001. 1707-1710
- 71 D’Alessandro M, Esteller R, Vachtsevanos G, Hinson A, Echaz J, Litt B. Epileptic seizure prediction using hybrid feature selection over multiple intracranial EEG electrode contacts: a report of four patients. *IEEE Transactions on Biomedical Engineering*, 2003, **50**(5): 603–615
- 72 van Putten M J, Kind T, Visser F, Lagerburg V. Detecting temporal lobe seizures from scalp EEG recordings: A comparison of various features. *Clinical Neurophysiology*, 2005, **116**(10): 2480–2489
- 73 Hjorth B. EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 1970, **29**(3): 306–310
- 74 Chen Long, Wang Wei, Qu Jue, Hu Bo, Cai Rui, Zhao Minrui. Influence of display characteristics of EEG power on cognitive load. *China Safety Science Journal*, 2020, **30**(2) : 183–189(in Chinese) (陈龙, 王巍, 瞿珏, 胡波, 蔡睿, 赵敏睿. EEG 功率信息显示特征对认知负荷的影响. *中国安全科学学报*, 2020, **30**(2): 183-189)
- 75 Hernandez D E, Trujillo L, Z-Flores E, Villanueva O M, Romo-Fewell O. Detecting Epilepsy in EEG Signals Using Time, Frequency and Time-Frequency Domain Features. *Computer Science and Engineering—Theory and Applications*, 2018, 167–182
- 76 Gotman J, Flanagan D, Zhang J, Rosenblatt B. Automatic seizure detection in the newborn: methods and initial evaluation. *Electroencephalography and Clinical Neurophysiology*, 1997, **103**: 356–362
- 77 Zibrandtsen I C, Weisdorf S, Ballegaard M, Beniczkyd S, Kjaerabc T W. Postictal EEG changes following focal seizures: Interrater agreement and comparison to frequency analysis. *Clinical Neurophysiology*, 2019,**130**(6): 879–885
- 78 Halliwell M. Doppler ultrasound: physics, instrumentation and signal processing (Second Edition). *Physiological Measurement*, 2000, **21**(3): 425–426
- 79 Faul S, Boylan G, Connolly S, Marnane L, Lightbody G. An evaluation of automated neonatal seizure detection methods. *Clinical Neurophysiology*, 2005, **116**(7): 1533–1541
- 80 Jahankhani P, Kodogiannis V, Revett K. EEG signal classification using wavelet feature extraction and neural networks. In: Proceedings of the IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing. Sofia, Bulgaria: IEEE, 2006. 120-124
- 81 Kumar Y, Dewal M, Anand R. Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine. *Neurocomputing*, 2014, **133**(10): 271–279

- 82 Tafreshi A K, Nasrabadi A M, Omidvarnia A H. Epileptic seizure detection using empirical mode decomposition. In: Proceedings of the 2008 IEEE International Symposium on Signal Processing and Information Technology. Vancouver, Canada: IEEE, 2008. 238-242
- 83 Orosco L, Laciari E, Correa A G, Torres A, Graffigna J. An epileptic seizures detection algorithm based on the empirical mode decomposition of EEG. In: Proceedings of the 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Minneapolis, MN: IEEE, 2009. 2651-2654
- 84 Pachori R B. Discrimination between ictal and seizure-free EEG signals using empirical mode decomposition, *Research Letters in Signal Processing*, 2008: 293056
- 85 Hu W, Cao J, Lai X, Liu J. Mean amplitude spectrum based epileptic state classification for seizure prediction using convolutional neural networks. *Journal of Ambient Intelligence and Humanized Computing*, 2019
- 86 Pachori R B, Patidar S. Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions. *Computer Methods and Programs in Biomedicine*, 2014, **113**(2): 494-502
- 87 Bajaj V, Pachori R B. EEG Signal Classification Using Empirical Mode Decomposition and Support Vector Machine. In: Proceedings of the International Conference on Soft Computing for Problem Solving. Jaipur, India: Springer, 2012. 623-635
- 88 Guarnizo C, Delgado E. EEG single-channel seizure recognition using Empirical Mode Decomposition and normalized mutual information. In: Proceedings of the IEEE 10th International Conference on Signal Processing Proceedings. Beijing, China: IEEE, 2010. 1-4
- 89 Fu K, Qu J, Chai Y, Dong Y. Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM. *Biomedical Signal Processing and Control*, 2014, **13**: 15-22
- 90 Lehnertz K, Elger C E. Can epileptic seizures be predicted? Evidence from nonlinear time series analysis of brain electrical activity. *Physical Review Letters*, 1998, **80**: 5019-5022
- 91 Mirzaei A, Ayatollahi A, Gifani P, Salehi L. Spectral entropy for epileptic seizures detection. In: Proceedings of the 2010 2nd International Conference on Computational Intelligence, Communication Systems and Networks. Liverpool, UK: IEEE, 2020. 301-307
- 92 Gao J, Hu J, Tung W. Entropy measures for biological signal analyses. *Nonlinear Dynamics*, 2011, **68**, 431-444
- 93 Song Y, Lio P. A new approach for epileptic seizure detection: sample entropy based feature extraction and extreme learning machine. *Journal of Biomedical Science and Engineering*, 2010, **3**(6): 556-567
- 94 Wang S, Chaovalitwongse W A, Wong S. Online seizure prediction using an adaptive learning approach. *IEEE Transactions on Knowledge and Data Engineering*, 2013, **25**(12): 2854-2866
- 95 Aarabi A, He B. A rule-based seizure prediction method for focal neocortical epilepsy. *Clinical Neurophysiology*, 2012, **123**(6): 1111-1122
- 96 Kalatzis I, Piliouras N, Ventouras E, Papageorgiou C C, Rabavilas A D, Cavouras D. Design and implementation of an SVM-based computer classification system for discriminating depressive patients from healthy controls using the p600 component of ERP signals. *Computer Methods and Programs in Biomedicine*, 2004, **75**(1): 11-22
- 97 Park Y, Luo L, Parhi K K, Netoff T. Seizure prediction with spectral power of EEG using cost-sensitive support vector machines. *Epilepsia*, 2011, **52**(10): 1761-1770
- 98 Al Ghayab H R, Li Y, Siuly S, Abdulla S. A feature extraction technique based on tunable Q-factor wavelet transform for brain signal classification. *Journal of Neuroscience Methods*, 2019, **312**: 43-52
- 99 Oweis, R J, Abdulhay E W. Seizure classification in EEG signals utilizing Hilbert-Huang transform. *BioMed Eng On-Line*, 2011, **10**: 38
- 100 Acharya U R, Hagiwara Y, Koh J E W, Oh S L, Tan J H, Adam M, San Tan R. Entropies for automated detection of coronary artery disease using ecg signals: A review. *Biocybernetics and Biomedical Engineering*, 2018, **38**(2): 373 - 384
- 101 Tian Y, Zhang H, Xu W, Zhang H, Yang L, Zheng S, Shi Y. Spectral entropy can predict changes of working memory performance reduced by short-time training in the delayed-match-to-sample task. *Frontiers in Human Neuroscience*, 2017, **11**: 437
- 102 Azami H, Fernandez A, Escudero J. Refined multiscale fuzzy entropy based on standard deviation for biomedical signal analysis. *Medical & Biological Engineering & Computing*, 2017, **55**(11): 2037-2052
- 103 Shayegh F, Sadri S, Amirfattahi R, Ansari-Asl K. A model-based method for computation of correlation dimension, Lyapunov exponents and synchronization from depth-EEG signals. *Computer Methods and Programs in Biomedicine*, 2014, **113**(1): 323-337
- 104 Mirowski P, Madhavan D, Lecun Y, et al. Classification of Patterns of EEG Synchronization for Seizure Prediction. *Clinical Neurophysiology*, 2009, **120**: 1927-1940
- 105 Faul S, Boylan G, Connolly S, Marnane W, Lightbody G. Chaos theory analysis of the newborn EEG - is it worth the wait? In: Proceedings of the 2005 IEEE International Workshop on Intelligent Signal Processing. Faro, Portugal: IEEE, 2005. 381-386
- 106 Li Xiao-bing, Chu Meng, Qiu Tian-shuang, Bao Hai-ping. A method of Epileptic EEG Spike Detection Based on Time-Frequency Analysis. *Chinese Journal of Biomedical Engineering*, 2006, **25**(6): 678-682(in Chinese)
(李小兵, 初孟, 邱天爽, 鲍海平. 一种基于时频分析的癫痫脑电棘波检测方法. 中国生物医学工程学报, 2006, **25**(6): 678-682)
- 107 Yadav R, Agarwal R, Swamy M. A novel morphology-based classifier for automatic detection of epileptic seizures. In: Proceedings of the 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. Buenos Aires, Argentina: IEEE, 2010. 5545-5548
- 108 Liu Y, Zhou W, Yuan Q, Chen S. Automatic seizure detection using wavelet transform and SVM in long-term intracranial EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2012, **20**(6): 749-755

- 109 Ahmed R, Temko A, Marnane W P, Boylan G, Lightbody G. Exploring temporal information in neonatal seizures using a dynamic time warping based SVM kernel. *Computers in Biology and Medicine*, 2017, **82**: 100–110
- 110 Li M, Chen W, Zhang T. Automatic epilepsy detection using wavelet-based nonlinear analysis and optimized SVM. *Biocybernetics and Biomedical Engineering*, 2016,**36**(4): 708–718
- 111 Reddy G S, Rao R. Automated identification system for seizure EEG signals using tunable-Q wavelet transform. *Engineering Science and Technology*, 2017, **20**(5): 1486–1493
- 112 Avcu M T, Zhang Z, Chan D W S. Seizure detection using least EEG channels by deep convolutional neural network. In: Proceedings of the 2019 IEEE International Conference on Acoustics, Speech and Signal Processing. Brighton, UK: IEEE, 2019. 1120–1124
- 113 Covert I C, Krishnan B, Najm I, Zhan J, Shore M, Hixson J, et al. Temporal Graph Convolutional Networks for Automatic Seizure Detection. In: Proceedings of Machine Learning Research. Ann Arbor, Michigan, 2019
- 114 Li Y, Liu Y, Cui W, Guo Y, Huang H, Hu Z. Epileptic Seizure Detection in EEG Signals Using a Unified Temporal-Spectral Squeeze-and-Excitation Network. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, **28**: 782–794
- 115 Thodoroff P, Pineau J, Lim A. Learning robust features using deep learning for automatic seizure detection. In: Proceedings of the Machine Learning and Healthcare Conference. Los Angeles, CA: 2016.
- 116 Craley J, Johnson E, Venkataraman A. Integrating convolutional neural networks and probabilistic graphical modeling for epileptic seizure detection in multichannel EEG. In: Proceedings of the International Conference on Information Processing in Medical Imaging. Hong Kong, China: Springer, 2019. 291–303
- 117 Roy S, Kiral-Kornek I, Harrer S. Chrononet: a deep recurrent neural network for abnormal EEG identification. In: Proceedings of the Conference on Artificial Intelligence in Medicine in Europe. Poznan, Poland: Springer, 2019. 47–56.
- 118 Sharathappriyaa V, Gautham S, Lavanya R. Auto-encoder based automated epilepsy diagnosis. In: Proceedings of the 2018 International Conference on Advances in Computing, Communications and Informatics. Bangalore, India: IEEE, 2018. 976–982
- 119 Rajaguru H, Prabhakar S. Multilayer autoencoders and EM-PCA with genetic algorithm for epilepsy classification from EEG. In: Proceedings of the 2018 Second International Conference on Electronics, Communication and Aerospace Technology. Coimbatore, India: IEEE, 2018. 353–358.
- 120 Pan S, Yang Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 2010, **22**(10):1345–1359
- 121 Jiang Y, Wu D, Deng Z, Qian P, Wang J, Guanjin Wang G. Seizure Classification From EEG Signals Using Transfer Learning, Semi-Supervised Learning and TSK Fuzzy System. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, **25** (12): 2270–2284
- 122 Zhu Y, Saqib M, Ham E, Belhareth S, Hoffman R, Wang M. Mitigating Patient-to-Patient Variation in EEG Seizure Detection using Meta Transfer Learning. In: 2020 IEEE 20th International Conference on Bioinformatics and Bioengineering. Cincinnati, OH: IEEE, 2020. 548–555
- 123 Zhao J, Xie X, Xu X, Sun S. Multi-view learning overview: Recent progress and new challenges. *Information Fusion*, 2017, **38**: 43–54
- 124 Yuan Y, Xun G, Jia K, Zhang A. A Multi-View Deep Learning Framework for EEG Seizure Detection. *IEEE Journal of Biomedical and Health Informatics*, 2019, **23**(1): 83–94
- 125 Liu Y, Li Y. A Multi-View Unified Feature Learning Network for EEG Epileptic Seizure Detection. In: Proceedings of the 2019 IEEE Symposium Series on Computational Intelligence. Xiamen, China: IEEE, 2019. 2608–2612
- 126 Zhou Z-H. Ensemble Methods: Foundations and Algorithms, Boca Raton, FL: Chapman & Hall/CRC, 2012.
- 127 Hosseini M, Hajisami A, Pompili D. Real-time epileptic seizure detection from EEG signals via random subspace ensemble learning. In Proceedings of the 2016 IEEE International Conference on Autonomic Computing (ICAC). Wuerzburg, Germany: IEEE, 2016. 209–218
- 128 Abualsaud K, Mahmuddin M, Saleh M, Mohamed A. Ensemble Classifier for Epileptic Seizure Detection for Imperfect EEG Data. *The Scientific World Journal*, 2015: 945689.
- 129 Akyol K. Stacking ensemble based deep neural networks modeling for effective epileptic seizure detection. *Expert Systems with Applications*, 2020, **148**(15):113239
- 130 Ramachandran VR K, Alblas H J, Le D V, Meratnia N. Towards an online seizure advisory system—an adaptive seizure prediction framework using active learning heuristics. *Sensors*, 2018, **18**(6):1698.
- 131 Guo L, Rivero D, Pazos A. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks. *Journal of Neuroscience Methods*, 2010, **193**(1): 156–163
- 132 Zhang T, Chen W, Li M. Automatic seizure detection of electroencephalogram signals based on frequency slice wavelet transform and support vector machine. *Acta Physica Sinica*, 2016, **65**(3): 038703(in Chinese)
(张涛, 陈万忠, 李明阳. 基于频率切片小波变换和支持向量机的癫痫病电信号自动检测. 物理学报, 2016, **63**(3):038703)
- 133 Yan B, Wang Y, Li Y, Gong Y, Guan L, Yu S. An EEG signal classification method based on sparse auto-encoders and support vector machine. In: Proceedings of the 2016 IEEE/CIC International Conference on Communications in China. Chengdu, China,: IEEE 2016. 1–6
- 134 Qiu Y, Zhou W, Yu N, Du P. Denoising Sparse Autoencoder-Based Ictal EEG Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2018, **26**(9): 1717–1726
- 135 Yuan Y, Xun G, Ma F, Suo Q, Xue H, Jia K, et al. A novel channel-aware attention framework for multi-channel EEG seizure detection via multi-view deep learning. In: Proceedings of the 2018 IEEE EMBS International Conference on Biomedical & Health Informatics. Las Vegas, NV: IEEE, 2018. 206–209
- 136 Ahmedt-Aristizabal D, Fookes C, Nguyen K, Denman S, Sridharan S, Dionisio S. Deep facial analysis: A new phase i epilepsy evaluation using computer vision. *Epilepsy & Behavior*, 2018, **82**: 17–24

- 137 Hussein R, Palangi H, Wang Z J, Ward R. Robust detection of epileptic seizures using deep neural networks. In: Proceedings of the 2018 IEEE International Conference on Acoustics, Speech and Signal Processing. Calgary, Canada: IEEE, 2018. 2546-2550
- 138 Roy S, Kiral-Kornek I, Harrer S. Deep Learning Enabled Automatic Abnormal EEG Identification. In: Proceedings of the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Honolulu, HI: IEEE, 2018. 2756-2759
- 139 Thomas J, Comoretto L, Jin J, Dauwels J, et al. EEG classification via convolutional neural network-based interictal epileptiform event detection. In: Proceedings of the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Honolulu, HI: IEEE, 2018. 3148-3151
- 140 Daoud H G, Abdelhameed A M, Bayoumi M. Automatic epileptic seizure detection based on empirical mode decomposition and deep neural network. In: Proceedings of the 2018 IEEE 14th International Colloquium on Signal Processing & Its Applications. Penang, Malaysia: IEEE, 2018. 182-186
- 141 Jaafar S T, Mohammadi M. Epileptic seizure detection using deep learning approach. *UHD Journal of Science and Technology*, 2019, **3**(2):41-50
- 142 Chen S, Zhang X, Chen L, Yang Z. Automatic diagnosis of epileptic seizure in electroencephalography signals using nonlinear dynamics feature. *IEEE Access*, 2019, **7**: 61046-61056
- 143 Cao J, Zhu J, Hu W, Kummert A. Epileptic signal classification with deep EEG features by stacked CNNs. *IEEE Transactions on Cognitive and Developmental Systems*, 2020, **12**(4): 709-722
- 144 Zhang X, Yao L, Dong M, Liu Z, Zhang Y, Li Y. Adversarial Representation Learning for Robust Patient-Independent Epileptic Seizure Detection. *IEEE Journal of Biomedical and Health Informatics*, 2020, **24**(20): 2852-2859
- 145 Goldenholz D M, Kuhn A, Austermuehle A, Bachler M, Mayer C, Wassertheurer S, et al. Long-term monitoring of cardiorespiratory patterns in drug-resistant epilepsy. *Epilepsia*, 2016, **58**(1): 77-84