

基于可调 Q 因子小波变换和迁移学习的癫痫脑电信号检测



罗婷瑞 贾建 张瑞

西北大学数学学院 西安 710127

西北大学医学大数据研究中心 西安 710127

(18740390600@163.com)

摘要 针对癫痫脑电信号的检测问题,提出一种基于可调 Q 因子小波变换和迁移学习的癫痫脑电信号检测方法。首先,对 EEG 信号进行可调 Q 因子小波变换,并选择能量差异较大的子带进行部分重构,重排重构信号,将其表示为二维彩色图像数据;其次,通过对现有的癫痫发作自动检测算法和深度可分离卷积网络 Xception 模型的分析,使用 ImageNet 数据集分类的预训练模型参数进行网络参数初始化,得到深度可分离卷积网络 Xception 的预训练模型;最后,利用迁移学习方法将 Xception 模型的预训练结果迁移至癫痫发作自动检测任务。所提方法在 BONN 癫痫数据集上的准确度达到 99.37%,敏感度达到 100%,特异度达到 98.48%,证明了该模型在癫痫发作自动检测任务上具有良好的泛化能力。与传统检测方法和其他深度学习方法相比,所提自动检测方法达到了较高的准确率,避免了人工设计和提取特征的过程,具有较好的应用价值。

关键词: 癫痫;可调 Q 因子小波变换;迁移学习;深度可分离卷积网络;自动检测

中图法分类号 TP391.4

Epileptic EEG Signals Detection Based on Tunable Q-factor Wavelet Transform and Transfer Learning

LUO Ting-ru, JIA Jian and ZHANG Rui

School of Mathematics, Northwest University, Xi'an 710127, China

Medical Big Data Research Center, Northwest University, Xi'an 710127, China

Abstract Aiming at the detection of epileptic EEG signals, a method of detecting epileptic EEG signals based on Tunable Q-factor wavelet transform and transfer learning is proposed. Firstly, the EEG signals are transformed by Tunable Q-factor wavelet transform, and the subbands with large energy differences are selected for partial reconstruction. The reconstructed signals are rearranged and expressed as two-dimensional color image data. Secondly, through the analysis of the existing automatic seizure detection algorithm and the Xception model of deep separable convolutional networks, the parameters of the pre-training model classified by the ImageNet dataset are used to initialize the network parameters, and the pre-training model of the depth separable convolution network Xception is obtained. Finally, the transfer learning method is used to transfer the pre-training results of the Xception model to the automatic seizure detection task. The performance of this method is verified on the BONN epilepsy dataset, and the accuracy, sensitivity and specificity reaches 99.37%, 100% and 98.48% respectively, proving that the model has good generalization ability in automatic seizure detection task. Compared with traditional detection methods and other deep learning methods based, the automatic detection method proposed in this paper achieves higher accuracy, avoids the process of artificial design and feature extraction, and has better application value.

Keywords Epilepsy, Tunable Q-factor wavelet transform, Transfer learning, Depth separable convolutional network, Automatic detection

1 引言

癫痫是一种神经活动异常变化而导致的慢性脑部疾病。其主要特征表现为大脑神经元同步化放电及中枢神经暂时性

的功能障碍^[1]。脑电图(Electroencephalogram, EEG)作为一种低廉且有效的记录脑电活动的技术,已被广泛用于癫痫的检测和研究^[2]。作为一种非侵入式的脑电活动检测工具,其记录了大量脑电信息,有利于医生确定发病灶进而进行有

到稿日期:2020-02-04 返修日期:2020-05-08 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:陕西省创新人才推进计划(2018TD-016);陕西省重点研发计划(2019ZDLSF02-09-02)

This work was supported by Innovative Talents Promotion Plan of Shaanxi(2018TD-016) and Key Research and Development Program of Shaanxi(2019ZDLSF02-09-02).

通信作者:贾建(jiajian@nwu.edu.cn)

效治疗。然而,由于癫痫发作具有不确定性,无法在短期内观测到,因此需要对 EEG 信号进行长期观测并捕获相关信息。传统癫痫检测是由医生对长时程的脑电图进行人工检查,这一过程效率低且非常耗时^[3],故自动化检测癫痫发作的方案变得尤为重要。

关于癫痫的自动检测算法,目前已取得了部分研究成果。针对 EEG 信号的非平稳特性,已有多种基于小波变换的方法被用于实现癫痫发作的自动检测。Patidar 等^[4]采用可调 Q 因子小波变换 (Tunable-Q Wavelet Transform, TQWT) 来分解脑电信号,以 Kraskov 熵为特征,采用最小二乘支持向量机 (Least Squares Support Vector Machine, LS-SVM) 进行分类。Sharma 等^[5]采用时频灵活分析小波变换 (Analytic Time-Frequency Flexible Wavelet Transform, ATFFWT) 和分形维数 (Fractal Dimension, FD) 来检测癫痫发作,用最小二乘支持向量机进行分类。此外, Peker 等^[6]采用双树复小波变换 (Dual-Tree Complex Wavelet Transform, DTCWT) 对癫痫脑电信号进行处理,也获得了较好的分类结果。除小波变换外,经验模式分解方法也被广泛用于癫痫发作的自动检测。Saxena 等^[7]运用经验模式分解 (Empirical Mode Decomposition, EMD) 得到的本征模函数计算振幅调制带宽 (Amplitude Modulation, AM) 和频率调制带宽 (Frequency Modulation, FM),并以此作为分类特征,采用 LS-SVM 进行分类。Jia 等^[8]基于完全集合经验模式分解 (Complete Ensemble Empirical Mode Decomposition, CEEMD) 来提取谱特征,并将随机森林 (Random Forest, RF) 作为分类器来检测癫痫的发作。Riaz 等^[9]利用经验模式分解得到本征模函数计算谱特征,再结合支持向量机 (Support Vector Machine, SVM) 设计癫痫自动识别的方案。此外, Mutlu^[10]采用希尔伯特振动分解 (Hilbert Vibration Decomposition, HVD), 提取最大能量分量的瞬时频率值作为 LS-SVM 的特征以检测癫痫发作。Lu 等^[11]提取混合特征对单通道脑电信号进行分类,将希尔伯特黄变换 (Hilbert-Huang Transform, HHT) 的 Kraskov 熵、本征模函数的瞬时区域值和可调 Q 因子小波变换的 Kraskov 熵作为特征,利用 LS-SVM 进行分类。

以往工作大多是先对变换后的信号进行人为提取并筛选具有良好区别能力的特征,再选择不同分类器进行分类,这是一个需要精心设计且极为耗时的复杂过程。考虑到深度卷积神经网络具有强大的非线性拟合能力和特征自主学习能力,以及迁移学习策略在小样本数据集分类识别方面的优越性^[12],本文提出了一种基于 TQWT 变换和迁移学习的癫痫发作自动检测方案。首先,将一维 EEG 信号表示为适合作为深度卷积神经网络输入的二维图像格式;其次,使用 ImageNet 数据集分类的预训练模型参数进行 Xception 模型网络参数的初始化;最后,迁移预训练模型的部分参数,对高层网络参数进行冻结,对底层网络参数进行重新训练和更新,并用二分输出层代替原模型的全连接层。实验表明,基于迁移学习的深度可分离卷积神经网络 Xception 模型在癫痫信号检测中具有良好的泛化能力,能有效检测癫痫的发作期和发作间期。

2 可调 Q 因子小波变换与深度可分离卷积神经网络

2.1 可调 Q 因子小波变换

可调 Q 因子小波变换^[13]是一种灵活的、离散的小波变

换,已成为处理振荡信号的一种有效手段。该变换通过控制品质因子 Q 、冗余度 r 和分解层数 j 来灵活分解信号^[14],其中 Q 为中心频率和带宽的比值,反映了小波的振荡特性; r 为冗余度,主要控制过度振铃现象,起到局域化信号特征的作用; j 决定了子带数目,表征低频分量的细化程度。

可调 Q 因子小波变换的分解原理与传统的小波变换相似^[15],主要采用迭代的双通道滤波器对信号进行分解。图 1 为 TQWT 的滤波器组分解与重构级联图。在每个分解阶段, $x(n)$ 被分解为采样频率为 αfs 的低通子带 $c(n)$ 和采样频率为 βfs 的高通子带 $d(n)$,其中 $H_0(\omega)$ 和 $H_1(\omega)$ 为低通滤波器和高通滤波器的频率响应, $H_0^*(\omega)$ 和 $H_1^*(\omega)$ 为其复共轭, α 和 β 分别为低通缩放尺度因子和高通缩放尺度因子。 j 级分解的分解流程图如图 2 所示。




图 1 TQWT 的滤波器组分解与重构级联图

Fig. 1 Filter bank decomposition and reconstruction cascade diagram of TQWT




图 2 TQWT 的 j 级分解流程图

Fig. 2 j -level decomposition flow chart of TQWT

原始信号 $x(n)$ 经过双通道滤波和尺度变换后被分解成低通子带 $c^1(n)$ 和高通子带 $d^1(n)$,高通子带 $d^1(n)$ 被保留作为本层的输出信号,而 $c^1(n)$ 则作为下一层的输入信号继续进行分解。不断重复此过程,经过 j 层分解后,TQWT 将输入信号 $x(n)$ 分成 $j+1$ 个子带。

TQWT 的品质因子 Q 及冗余度 r 的定义如下:

$$Q = \frac{2-\beta}{\beta}, r = \frac{\beta}{1-\alpha} \quad (1)$$

TQWT 中使用的滤波器具有合理的传递函数,因此计算效率高,且该变换继承了小波变换的完美重构性。重构过程中, α 和 β 服从以下关系: $0 < \alpha < 1, 0 < \beta \leq 1$ 且 $\alpha + \beta > 1$ 。

2.2 卷积神经网络

卷积神经网络 (Convolutional Neural Networks, CNN) 是深度学习的代表性算法之一,因具有良好的自主学习能力和泛化能力而被广泛应用于图像分类^[16-17]、目标检测^[18-19]等领域。传统的 CNN 通过搭建多个隐藏层,依据目标任务来完成对图像底层细节到高层表征的学习过程。CNN 的主要结构包括卷积层、池化层和全连接层等^[20],如图 3 所示(以 LeNet-5 网络为例)。




图 3 卷积神经网络的基本结构图

Fig. 3 Basic structure of convolutional neural network

卷积层主要通过卷积核提取图像的局部特征。池化层通常位于卷积层之后,对特征图进行降维,保证局部特征不变并减少计算量。全连接层的主要功能是连接得到的所有特征,并利用分类器进行分类而得到结果。

2.3 深度可分离卷积网络

Google 通过对 Inception V3^[21] 中 Inception 模块的改造,得到了 Xception^[22] 模型,其中 Inception V3 模块的结构如图 4(a)所示。Inception 模块主要将 1×1 , 3×3 , 5×5 的卷积核

和池化层等结构组合,以减少参数,降低计算开销,从而达到更有效的特征学习。其主要思想之一是实现卷积操作在空间和通道间的相互独立。首先使用 1×1 的卷积核将特征图的各个通道映射到一个新的空间,学习通道间的相关性,再通过 3×3 和 5×5 的卷积核进行空间卷积,学习空间上的相关性和通道间的相关性。当 3×3 和 5×5 的卷积核都仅对含有一个通道的特征图操作时,就实现了空间上的相关性和通道间的相关性的完全分离。

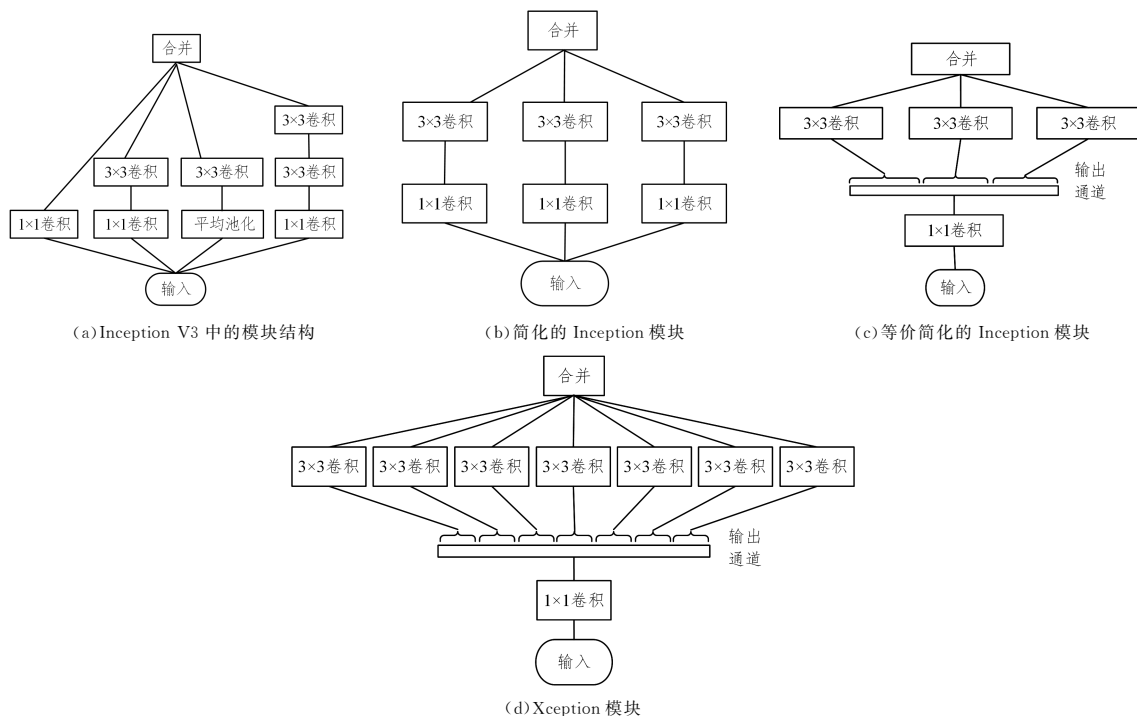


图 4 Xception 模块演化图
Fig. 4 Evolution diagram of Xception module

基于上述 Inception 模块的主要思想,简化 Inception V3 中的 Inception 模块,仅保留 3×3 卷积,并且不含平均池化,得到的结果如图 4(b)所示。将所有 1×1 卷积核进行拼接,得到等价简化的 Inception 模块,如图 4(c)所示。再增加 3×3 卷积核的分支数量,使它与 1×1 的卷积核输出的通道相等,此时每个 3×3 的卷积核仅对含有一个通道的特征图进行操作,得到图 4(d)所示的模块,称之为 Xception 模块。Xception 模型具有多层网络结构,能够逐步实现图像的底层基础特征到高层语义特征的学习。其底层网络更靠近输入层,用于提取图像的底层基础特征,代表图像的结构信息;其高层网络更加靠近输出层,用于提取图像的高层语义特征,代表图像的抽象特征。本文定义 Xception 模型的前 N 层为底层网络,将 $N+1$ 层至二分类输出层定义为高层网络,其中 N 为 100。基于此种定义的 Xception 模块,构建 Xception 网络,将类似 Resnet^[23] 的残差连接机制加入 Xception 中,显著加快了 Xception 的收敛,提升了模型精度。

2.4 迁移学习

迁移学习通过采用已学习到的知识,来解决识别任务数据匮乏的问题^[24]。由于 Xception 模型在 ImageNet^[25] 数据集上学习到的底层特征代表图像的基础特征,往往具有较好的普适性和共享性,而高层学习到的特征更能够代表图像的抽

象特征,因此可以通过微调预训练模型的部分层来完成图像识别任务。因此,本文构建了一种结合深度可分离卷积网络 Xception 的癫痫发作自动检测模型,通过迁移学习共享 Xception 预训练模型的卷积层权值和偏差,分别微调底层网络、高层网络及全部网络以进行癫痫发作的自动检测。

3 实验数据与预处理

3.1 实验数据

本文所使用的实验数据来自于德国 BONN 大学癫痫研究中心数据库^[26],数据采样频率为 173.61 Hz,采样时间为 23.6 s,包含 5 组数据集,分别用 A, B, C, D, E 表示,每个数据集测试的对象为 5 个受试者。其中每个数据集包含 100 个样本,每个样本包含 4097 个采样点。数据库的详细介绍如表 1 所列。

表 1 BONN 癫痫数据库介绍

Table 1 Introduction of BONN epilepsy database

数据集名称	记录位置	记录状态
A	皮质	健康,清醒时睁眼
B	皮质	健康,清醒时闭眼
C	致痫灶外	患者,发作间期
D	致痫灶内	患者,发作间期
E	致痫灶内	患者,发作期

本文主要对癫痫发作间期和发作期的脑电信号进行分类与检测,故选择 D、E 数据集作为实验数据集,其原始 EEG 片段如图 5 所示。




图 5 癫痫发作间期、发作期的原始 EEG 信号

Fig. 5 Original inter-seizure EEG signals and seizure EEG signals

3.2 基于 TQWT 的癫痫脑电信号的数据表示

本文利用深度可分离卷积神经网络 Xception 模型进行训练与测试,因此需要将实验数据集的一维信号数据表示为二维图片数据,作为该模型的输入信号。

数据表示流程如下:

步骤 1 信号数据分段。为得到足够的训练样本,对每个样本以 1024 个点为一段,即将每个样本平均分为 4 段,各样本最后一个点舍弃,共得到 800 个样本。

步骤 2 信号数据分解。根据文献[34]的经验及本文的多次实验,以参数 $Q=1.5, r=3, j=6$ 对分段后的信号进行 TQWT 变换。计算各子带系数的二阶范数与所有子带系数的二阶范数的比值,定义其为各子带的平均能量占比,用于衡量能量分布的差异,如图 6 所示。

步骤 3 子带重构。由图 6 可得,数据集 D 和 E 的 1,2,3 子带能量占比均为最低;4,5,6 子带能量占比表现为数据集

E 能量占比高,数据集 D 能量占比低;而 7 子带能量占比呈现出数据集 E 能量占比低,数据集 D 能量占比高。因此,将 1,2,3 子带重构为信号 a ,将 4,5,6 子带重构为信号 b ,将 7 子带重构为信号 c 。

步骤 4 数据归一化。对重构信号 a, b, c 进行无量纲化,依据重构信号的最大值和最小值,采用 min-max^[27] 方法将样本数据线性映射到 $[0, 255]$ 。该方法将不同分量映射到同一个坐标系,统一了数据集 D 和 E 中样本的衡量标准。

步骤 5 转换图像数据。将步骤 4 的重构信号 a, b, c 视为三通道来构造图像,将其作为 Xception 模型的输入图像。





图 6 各子带的平均能量占比图

Fig. 6 Average energy ratio of each subband

在实验中,规定数据集 D 的样本标签为“0”,数据集 E 的样本标签为“1”。随机抽取两组数据集的 20% 作为测试集。Xception 模型的输入图像如图 7 所示。



(a) 发作间期表示图像

(b) 发作期表示图像

图 7 EEG 数据表示图像

Fig. 7 Image represented by EEG data

3.3 基于迁移学习的癫痫发作自动检测

本文结合迁移学习策略构建深度可分离卷积神经网络 Xception 的癫痫发作自动检测模型,如图 8 所示。

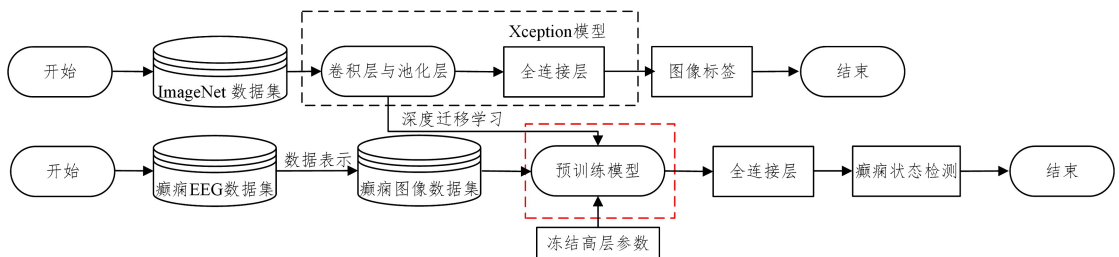


图 8 基于迁移学习的癫痫发作自动检测 Xception 模型

Fig. 8 Xception model for automatic detection of seizures based on transfer learning

训练过程中,将 ImageNet 数据集上的 Xception 模型的训练参数作为初始化参数,使用二标签分类器代替原有的全连接层。由于 ImageNet 数据集上的预训练参数是面向自然图像的,而本文所用的图像数据集均由一维信号转换得到,与自然图像的基本特征存在差异,因此对预训练模型的高层参数进

行迁移,并冻结高层网络参数,对底层的网络参数重新进行训练和更新,使基于癫痫数据的底层特征更好地兼容高层特征。

4 实验结果与分析

通过结合 TQWT 变换和迁移学习策略,本文提出了一

种癫痫发作自动检测算法,。针对所提检测方案,以准确度、灵敏度、特异度^[28] 3 个指标来衡量其对发作间期、发作期的脑电信号的检测性能。


$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (3)$$


$$Specificity = \frac{TN}{TN+FP} \quad (4)$$

其中, TP 代表正确分类的正类样本数, TN 代表正确分类的负类样本数, FP 代表被错误分类的负类样本数, FN 代表被错误分类的正类样本数。

为验证所提模型的有效性,采用癫痫脑电信号的表示图像进行实验,通过 3 种方式训练 Xception 模型。3 种训练方式分别为:1)训练 Xception 模型的底层网络,即模型的高层网络参数冻结,利用癫痫脑电信号的表示图像更新底层网络参数;2)训练 Xception 模型的高层网络,即模型的底层网络参数冻结,利用癫痫脑电信号的表示图像更新高层网络参数;3)训练 Xception 模型的全部网络,即利用癫痫脑电信号的表示图像训练全部网络参数。所有训练过程以 Adam 算法为优化方法,交叉熵函数为损失函数,随机选取训练集的一个批样本进行训练,批样本大小设置为 64,每个实验运行 200 个 Epochs,采用 Tensorflow+Keras 框架进行实验,实验结果如图 9 所示。



(a) 底层网络训练精度与测试精度曲线



(b) 底层网络训练损失与测试损失曲线


图 9 基于底层网络模型的训练测试结果

Fig. 9 Training and test results based on the Low-level network model


由图 9 可知,随着 Epochs 的增加,基于底层网络训练的模型对癫痫发作检测的准确率逐步提升,损失值逐渐降低,少量迭代后,训练损失值即可收敛到 0;当 Epochs 为 30 时,训练精度保持不变,且损失值不再减少,说明训练参数合适,不存在过拟合现象;当 Epochs 为 186 时,模型即可平稳收敛,此时获得最高识别准确率,为 99.37%。

图 10(a)为基于高层网络的训练测试准确率曲线,当 Epochs 为 3 时该模型就已收敛,训练准确率达到 100%;经过 200

个 Epochs 后,测试精度并未提升,准确率为 69.37%,模型学习能力较弱,产生了严重过拟合现象。图 10(b)展示了基于全部网络的训练测试准确率曲线,随着 Epochs 的增加,训练精度逐步提升,测试曲线出现明显抖动;当 Epochs 为 124 时,模型趋于收敛;经过 154 个 Epochs 后,测试精度达到最高;当 Epochs 为 180 时,测试精度略微下降,最终获得的最高准确率为 96.88%。



(a) 高层网络训练精度与测试精度



(b) 全部网络训练精度与测试精度

图 10 基于高层网络和全部网络的训练测试结果

Fig. 10 Training and test results based on high-level networks and all networks

表 2 列出了 3 种训练方法在 BONN 数据库上的性能比较结果。通过对比可知,基于底层网络的训练策略结果最好,基于全部网络训练策略的结果次之,基于高层网络的训练策略的结果最差。基于底层网络的训练策略在测试集上获得了 99.37% 的准确度和 98.48% 的特异度,相比全部网络的训练策略和高层网络的训练策略的准确度分别提升了 2.49% 和 30%,特异性分别提升了 4.81% 和 68.48%。

表 2 各种训练方法在 BONN 数据库上的性能比较

Table 2 Performance comparison of various training methods on BONN database

识别方法	Accuracy	Sensitivity	Specificity
训练底层网络	99.37	100	98.48
训练高层网络	69.37	100	30.00
训练全部网络	96.88	100	93.67

(单位:%)

之所以基于高层网络的训练结果最差,是由于该策略没有考虑癫痫数据集表示图像与自然图像的基础特征差异,导致模型严重过拟合,测试准确率相比训练准确率严重下降。基于全部网络训练的结果虽好于高层网络的训练结果,但需要对全部网络进行整体训练,耗时耗力。对比上述两种训练策略,基于底层网络的训练策略取得了最好的结果,该策略考虑到不同数据集图像的基础特征差异,训练底层网络来更好地兼容高层特征,在保证高准确率的同时,节约了计算成本。

将本文方法与已有研究方法进行对比,在 BONN 数据库

上的部分研究结果如表 3 所列。相比已有算法,本文方法在各度量标准上都取得了较好的性能。由表 3 可知,本文方法得到了最高的准确度 99.37% 和最高的敏感度 100%;尽管 Zhang 等^[32]的方法的特异度略高于本文方法,但其准确度和敏感度指标均低于本文方法。对比 Sharma 等^[5]的研究方法,本文在与其保持相同敏感度的情况下,具有更高的准确度和特异度。与其他方法相比,本文方法在整体性能上都有明显优势。

表 3 本文方法与其他方法在 BONN 数据库上的性能比较

Table 3 Performance comparison of this method and other methods on BONN database

(单位: %)				
算法	方法	Accuracy	Sensitivity	Specificity
文献[29]算法	DWT+近似熵+ANN	93.00	94.00	92.00
文献[30]算法	DSTFT+统计特征+MLP	94.90	95.60	94.10
文献[28]算法	CEEDAN+统计特征+LPBoost	97.00	97.40	98.25
文献[5]算法	ATFFWT+FD+LS-SVM	98.50	100.00	97.00
文献[31]算法	CNN	91.00	95.00	87.00
文献[32]算法	TCNN	98.00	96.77	100.00
文献[33]算法	LSTM	97.78	96.77	98.85
本文方法	TQWT+CNN	99.37	100.00	98.48

多数机器学习方法采用适当的变换,识别变换域具有显著差异的特征,再结合分类器获得分类结果,虽能获得较高精度,但识别流程复杂。而深度卷积神经网络具有从数据中自主学习特征的能力,不需要人工设计特征,将其与迁移学习策略相结合,共享已训练模型卷积层的权值和偏差,可移植性较好,在保证检测精度的基础上,简化了学习任务。

结束语 本文针对癫痫脑电信号的性质及传统癫痫脑电信号检测方案操作繁杂等不足,提出了一种结合 TQWT 变换和迁移学习的方法来自动检测癫痫发作。该方案首先对癫痫脑电信号进行 TQWT 变换分解与重构,将一维重构信号表示成适合深度卷积神经网络输入的二维图像;然后构建基于深度可分离卷积神经网络 Xception 的癫痫发作自动检测模型;通过迁移底层特征和高层特征,再采用癫痫脑电信号图像进行微调,最后实现了对癫痫发作期和发作间期的有效检测,提高了检测精度,简化了检测任务。

实验结果表明,本文方法相比现有的大多数检测方法具有更高的准确度、灵敏度和特异度,能够对癫痫脑电信号做出准确分类。目前,本文的工作仅针对于癫痫发作自动检测任务,后续将利用该模型较好的可移植性来完成其他领域的脑电信号的检测识别任务。

参考文献

[1] HASSAN A R, SIJULY S, ZHANG Y. Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating[J]. *Computer Methods and Programs in Biomedicine*, 2016(137): 247-259.

[2] SHAFIQUE A, SAYEED M, TSAKALIS K. Nonlinear Dynamical Systems with Chaos and Big Data: A Case Study of Epileptic

Seizure Prediction and Control[M]. Cham: Springer International Publishing, 2018.

[3] SHARMA R, PACHORI R B. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions[J]. *Expert Systems with Applications*, 2015, 42(3): 1106-1117.

[4] PATIDAR S, PANIGRAHI T. Detection of epileptic seizure using Kraskov entropy applied on tunable-Q wavelet transform of EEG signals[J]. *Biomedical Signal Processing and Control*, 2017, 34: 74-80.

[5] SHARMA M, PACHORI R B, RAJENDRA A U. A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension[J]. *Pattern Recognition Letters*, 2017, 94: 172-179.

[6] PEKER M, SEN B, DELEN D. A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers[J]. *IEEE Journal of Biomedical and Health Informatics*, 2016, 20(1): 108-118.

[7] SAXENA S, HEMANTH C, SANGEETHA R G. Classification of normal, seizure and seizure-free EEG signals using EMD and EWT[C] // *International Conference on Nextgen Electronic Technologies: Silicon to Software (ICNETS2)*. IEEE, 2017: 360-366.

[8] JIA J, BALAJI, SONG J L, et al. Automated identification of epileptic seizures in EEG signals based on phase space representation and statistical features in the CEEMD domain [J]. *Biomedical Signal Processing and Control*, 2017, 38: 148-157.

[9] RIAZ F, HASSAN A, REHMAN S, et al. EMD-Based Temporal and Spectral Features for the Classification of EEG Signals Using Supervised Learning[J]. *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, 2016, 24(1): 28-35.

[10] MUTLU A Y. Detection of epileptic dysfunctions in EEG signals using Hilbert vibration decomposition[J]. *Biomedical Signal Processing and Control*, 2018, 40: 33-40.

[11] LU Y, MA Y, CHEN C, et al. Classification of single-channel EEG signals for epileptic seizures detection based on hybrid features[J]. *Technology and Health Care*, 2018, 26(S1): 337-346.

[12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 770-778.


[13] SELESNICK, IVAN W. Wavelet Transform with Tunable Q-Factor[J]. *IEEE Transactions on Signal Processing*, 2011, 59(8): 3560-3575.

[14] BAYRAM I, SELESNICK I W. Frequency domain design of overcomplete rational-dilation wavelet transforms [J]. *IEEE Transactions on Signal Processing*, 2009, 57(8): 2957-2972.

[15] CHEN W Z, WANG X X, ZHANG T. Research of Discrimination Between Left and Right Hand Motor Imagery EEG Patterns Based on Tunable Q-Factor Wavelet Transform[J]. *Journal of Electronics & Information Technology*, 2019, 41(3): 530-536.

[16] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[J].

- Advances in Neural Information Processing Systems, 2012, 25(2):1097-1105.
- [17] ZHANG Z Z, GAO J Y, LV G, et al. Pathological Image Classification of Gastric Cancer Based on Depth Learning[J]. Computer Science, 2018, 45(S2):263-268.
- [18] YU J Y, DING P C, WANG C. Overview; Application of Convolutional Neural Network in Object Detection [J]. Computer Science, 2018, 45(S2):17-26.
- [19] WANG H L, QI X L, WU G S. Research Progress of Object Detection Technology Based on Convolutional Neural Network in Deep Learning[J]. Computer Science, 2018, 45(9):11-19.
- [20] ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6):1229-1251.
- [21] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C] // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition. 2016;2818-2826.
- [22] CHOLLET F. Xception: Deep learning with depth wise separable convolutions[C]//Proc. of the IEEE Conference on Computer Vision and Pattern Recognition. 2017;1251-1258.
- [23] HU H G, KONG X Y, ZHOU Q W, et al. Melanoma Classification Method by Integrating Deep Convolutional Residual Network [J]. Computer Science, 2019, 46(5):247-253.
- [24] TAJBAKHS N, SHIN J Y, GURUDU S R, et al. Convolutional Neural Networks for Medical Image Analysis: Fine Tuning or Full Training? [J]. IEEE Transactions on Medical Imaging, 2016, 35(5):1299-1312.
- [25] JIA D, WEI D, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[C]//Proc of IEEE Computer Vision & Pattern Recognition. 2009;248-255.
- [26] ANDRZEJAK R G, LEHNERTZ K, MORMANN F, et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. Physical Review E, 2001, 64(6):061907.
- [27] POWERS D M W. Visualization of tradeoff in evaluation: from precision-recall & PN to LIFT, ROC & BIRD[J]. arXiv:1505.00401, 2015.
- [28] HASSAN A R, SUBASI A. Automatic identification of epileptic seizures from EEG signals using linear programming boosting [J]. Computer Methods and Programs in Biomedicine, 2016, 136:65-77.
- [29] KUMAR Y, DEWAL M L, ANAND R S. Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network[J]. Signal, Image and Video Processing, 2014, 8(7):1323-1334.
- [30] SAMIEE K, KOVACS P, GABBOUJ M. Epileptic Seizure Classification of EEG TimeSeries Using Rational Discrete Short-Time Fourier Transform[J]. IEEE Transactions on Biomedical Engineering, 2015, 62(2):541-552.
- [31] AHMEDT-ARISTIZABAL D, FOOKES C, NGUYEN K, et al. Deep classification of epileptic signals[C]// 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2018;332-335.
- [32] ZHANG J, WU H, SU W, et al. A New Approach for Classification of Epilepsy EEG Signals Based on Temporal Convolutional Neural Networks[C]// 11th International Symposium on Computational Intelligence and Design (ISCID). IEEE, 2018;80-84.
- [33] ABBASI M U, RASHAD A, BASALAMAH A, et al. Detection of Epilepsy Seizures in Neo-Natal EEG Using LSTM Architecture[J]. IEEE Access, 2019, 7:179074-17908.
- [34] HE W P, YANG Y, et al. Tunable Q-factor wavelet transform denoising with neighboring coefficients and its application to rotating machinery fault diagnosis[J]. Science China (Technological Sciences), 2013(8):126-135.



LUO Ting-ru, born in 1996, postgraduate. Her main research interests include machine learning and medical signal processing.



JIA Jian, born in 1977, Ph.D, professor. His main research interests include pattern recognition and intelligent information processing.