

DOI: 10.19650/j.cnki.cjsi.J2006094

基于深度网络迁移学习的致痫区脑电识别*

曲桂果,袁琦,李彦

(山东师范大学物理与电子科学学院 山东省医学物理图像处理技术省级重点实验室 济南 250358)

摘要:致痫区脑电识别能够为癫痫外科手术提供重要的参考价值。提出了一种基于深度网络迁移学习的致痫区脑电识别算法。首先利用连续小波变换(CWT)对脑电信号进行时频分析,获得脑电信号时频图;然后迁移学习 AlexNet 网络模型,调整网络结构使之适应于致痫区脑电识别,将模型第7层全连接层输出作为脑电信号时频图的特征表示,最后利用支持向量机(SVM)、BP神经网络、长短期记忆网络(LSTM)、基于稀疏表达分类算法(SRC)、线性判别分析(LDA)等分类算法进行特征分类。基于开源脑电数据集采用十折交叉验证的方法对算法进行了验证,比较6种分类器的效果,得到SVM算法的平均特异性为88.81%,灵敏度为88.07%,准确率为88.44%,证明了该方法识别致痫区脑电信号的有效性。

关键词:癫痫;脑电;深度学习;迁移学习;时频分析

中图分类号: TP391 TH776 文献标识码: A 国家标准学科分类代码: 310.6110 520.2060

Focal EEG recognition based on deep network with transfer learning

Qu Guiguo, Yuan Qi, Li Yan

(Shandong Province Key Laboratory of Medical Physics and Image Processing Technology,
School of Physics and Electronics, Shandong Normal University, Jinan 250358, China)

Abstract: Focal EEG recognition can provide important reference value for epilepsy surgery. This paper proposes a focal EEG recognition algorithm based on deep network with transfer learning. Firstly, the continuous wavelet transform (CWT) is used to perform time-frequency analysis on the EEG signals and obtain the time-frequency map of the EEG signals. Then transfer learning is performed on the AlexNet model, and the network structure is adjusted to adapt to focal EEG recognition. The output of the seventh fully connected layer of the model is used as the characteristic presentation of the time-frequency images. Finally, the classification algorithms of SVM, BP, LSTM, SRC and LDA are used to classify the features. In this paper, based on the open source EEG dataset, the 10-fold cross-validation algorithm is adopted to verify the algorithm, the effects of the six classifiers are compared. The average specificity, sensitivity and accuracy of the SVM algorithm are 88.07%, 88.81% and 88.44%, respectively, which proves the effectiveness of the method in focal EEG recognition.

Keywords: epilepsy; electroencephalogram (EEG); deep learning; transfer learning; time-frequency analysis

0 引言

癫痫是一种由脑部神经元异常放电引起的慢性神经系统疾病^[1]。根据世界卫生组织最新数据显示,全球约有5000万癫痫患者^[2],其中约有30%的癫痫患者无法通过药物控制其发作,形成难治性癫痫^[3]。对于耐药局灶性癫痫患者,手术治疗是获得完全癫痫发作自由的最

佳选择。然而,目前很难在术前明确癫痫病灶的位置及范围。因此需要一种新的算法来获得更好的定位效果。

癫痫定位方法甚多,但临床中主要使用的是脑电图(electroencephalogram, EEG)和磁共振成像(magnetic resonance imaging, MRI)^[4]。随着癫痫外科与脑电图学的飞速发展,临床医师对致痫区的认识更为深刻^[5]。在传统的方法中,医生主要通过人工视觉分析信号的方法对脑电信号进行分类,但是这种方法不仅耗费时间长而

且容易受到个人主观意识的影响,导致较大误差的出现,进而影响致痫区脑电识别的准确性^[6]。为解决这一问题,本文提出了一种基于深度网络迁移学习的致痫区脑电识别算法。

深度学习(deep learning, DL)是机器学习(machine learning, ML)领域中一个新的研究方向^[7]。DL的实质是利用机器模拟人类大脑活动处理复杂模式识别问题的过程^[8]。近年来,在癫痫研究领域引入了DL算法,在复杂的癫痫脑电信号特征提取方面DL算法比传统的特征提取算法更具有优势^[9]。Petrosian等^[10]将循环神经网络(recurrent neural network, RNN)同脑电信号的小波分解系数相结合用于癫痫预测研究。Mirowski等^[11]在癫痫发作的预测研究中将L1正则化的逻辑回归(logistic regression, LR),卷积神经网络(convolutional neural networks, CNN)和支持向量机(support vector machine, SVM)3种分类算法进行对比。Xia等^[12]基于颅内和头皮脑电数据集,利用CNN提出一种广义的回顾性和患者特异性癫痫预测方法。Truong等^[13]还提出一种高效的硬件统一性良好的Integer-Net。Acharya等^[14]还提出一种高效的硬件统一性良好的整数卷积神经网络(Integer-Net)。Achilles等^[15]将CNN用于学习患者在发作期和发作间期的睡眠运动,达到检测各种类型的癫痫发作的目的。

本文提出了一种基于深度网络迁移学习的致痫区脑电识别算法,迁移学习预先训练好的AlexNet模型,调整网络结构,使之适应于致痫区脑电识别,将第7层全连接层输出作为特征表示^[16]。然后利用SVM将提取到的致痫区脑电特征进行分类,进而达到识别致痫区脑电的目的。

1 研究方法

1.1 脑电信号的时频分析

时频分析是指在时间-频率域上对信号进行分析。建立一个用时间以及频率来表征信号能量密度的函数,通过此函数,求出信号的时频分布,从而得出信号在某段时间内的频率变化特性^[17]。常用的时频分析方法有:傅里叶变换(Fourier transform, FT)、短时傅里叶变换(short-time Fourier transform, STFT)以及小波变换(wavelet transform, WT)。其中,FT在处理信号时只能反应频域或者时域信息,而脑电信号的随机性和非平稳性决定了其在处理过程中需要同时兼顾信号的时域与频域变化。STFT中大小固定形状不变的时间窗使其无法兼顾脑电信号的频率与时间分辨率。而WT的窗函数形状可变,在处理脑电信号中可以同时反应频域和时域的变化。因此本文选取连续小波变换(continuous wavelet transform, CWT)用于致痫区脑电信号的时频分析。脑电

信号在经过预处理后,有助于提升算法的准确率^[18]。

脑电信号是一种非平稳信号,在时频分析过程中,当信号变化剧烈时,需有较高时间分辨率的窗函数;而在信号变化缓慢期间,低频信号的窗函数需要有较高的频率分辨率^[19]。本文以每20s的脑电信号片段为一个样本建立时频表示。首先建立滤波器组,然后对滤波器进行归一化,使所有通带的峰值幅度近似等于2^[20]。滤波器组是为具有10240个样本点的信号设计的。使用Morlet小波作为分析小波,默认尺度为大约每个8度48个小波的带通滤波器。利用滤波器组提取信号的前1024个点的CWT,并从系数中获取散射图,生成RGB时频图像,为了适应AlexNet神经网络的输入,图像大小被定义为227×227×3,如图1所示。

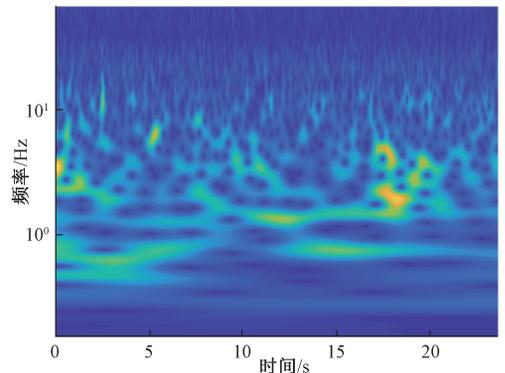


图1 CWT生成的RGB时频图像

Fig.1 The RGB time-frequency image generated with continuous wavelet transform

1.2 基于深度网络迁移学习的特征提取

本文提出了基于深度网络迁移学习的致痫区脑电识别算法。采用基于模型迁移学习的方法迁移学习预先训练好的深度卷积网络模型,然后通过调整网络的结构,添加自适应层对源域和目标域进行适配,使之适应于致痫区脑电识别,将训练好的迁移网络作为特征提取器。迁移学习深度网络流程如图2所示。

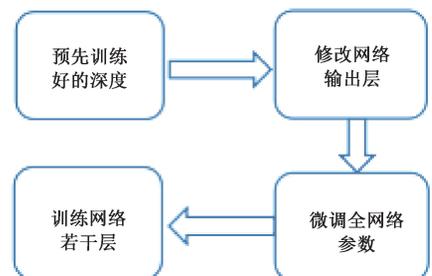


图2 深度网络模型迁移学习流程

Fig.2 The schematic diagram of transfer learning of deep network model

经典浅层神经网络一般只含有3个层:输入层、单隐藏层和输出层。这是因为经典的学习方法很难收敛深层神经网络结构^[21]。它们经常陷入梯度消失问题,这意味着随着迭代次数的增加,梯度值趋于0,网络中的参数难以更新^[22]。CNN通过增加卷积层,使得模型的性能优于浅层神经网络。

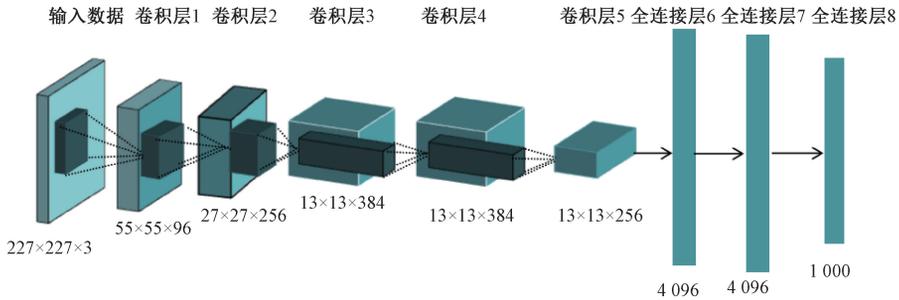


图3 AlexNet 网络结构模型

Fig.3 AlexNet network structure model

AlexNet 是一种拥有 6 000 万个参数和 65 万个神经元的深度网络模型,包括 5 层卷积层 (convolution layer, conv), 3 层全连接网络层 (fully connected layer, FC), 最终的输出层是 1 000 通道的 softmax 层^[26]。为了训练这些参数 Krizhevsky 对 AlexNet 做了一些改进^[27]。

首先 AlexNet 在激活函数方面进行了改进。神经网络在选择激活函数时,一般选择 logistic 函数、tanh 函数和 arctan 函数。但在深度神经网络模型中,传统的梯度饱和和函数在计算梯度时随着 x 增大其梯度几乎接近于 0,甚至梯度消失^[28]。ReLU (整流单元、线性固定线性单元) 是一种不饱和和非线性激活函数。在梯度下降方面快于 tanh 和 arctan 函数。而且 ReLU 函数比传统的激活函数具有更快的学习性能,在大模型 (深度和宽度) 以及非常大的数据集上的应用无疑是非常重要的^[22]。ReLU 的定义是:

$$ReLU(x) = \max(x, 0) \quad (1)$$

式中: x 为输入值,如果输入值不小于 0,那么 ReLU 的梯度始终保持为 1。深度网络中的 ReLU 函数相比于 tanh 函数,其收敛速度更快。这种加速在训练过程中起到了很大的作用。

其次,为了避免过拟合现象, AlexNet 增加了 Dropout 操作。Dropout 操作通常用于全连接层,一般被设置为 0.5 或 0.3^[27]。Dropout 可以作为训练深层神经网络的一个技巧。在正向传播过程中将某个概率为 p 的神经元的激活值设置为 0^[28],而神经元的缺失迫使神经元与其他神经元相互协作,降低了神经元之间的关节适应性,提高了泛化能力,使模型更加一般化^[29]。在此过程中,该网络每次输入时都会采用不同的网络结构,但是这些网络结构的权重是共享的。虽然对于每个单独的子网络,在

CNN 是一种通过观察生物过程模拟人脑不同层次功能的深度学习神经网络^[23]。在图像处理中 CNN 是一种非常有效的算法^[24]。CNN 有不同的架构,如 Le-Net、Alex-Net、Google-Net、Convo-Net、Res-Net 等^[25]。AlexNet 架构相比于其他架构在处理复杂性方面具有更好的计算能力。其网络结构模型如图 3 所示。

一定程度上可能会存在过拟合,但它们共享相同的损失函数。整个网络的输出是子网络的平均值。因此,Dropout 也提高了鲁棒性^[27]。

卷积作为一种信号分析技术,使用卷积和池化的方法实现特征的自动提取和约简。给定大小为 (m, n) 的图像 M ,卷积定义为:

$$C(m, n) = (M * w)(m, n) = \sum_k \sum_l M(m-k, n-l) w(k, l) \quad (2)$$

式中: (k, l) 为卷积核 w 的大小。通过卷积使模型能够从图像中学习特征,其参数共享降低了模型的复杂度^[29]。池化层 (pooling layers, PL) 一般在 CNN 的卷积层之后,用于特征提取,利用池化技术对卷积层之后得到的小邻域内的特征点进行集成,得到新的特征^[30]。既防止了无用参数增加时间复杂度又增加了特征的集成程度。AlexNet 采用了最大池化来避免产生模糊效果^[31]。

AlexNet 使用了局部响应归一化 (local response normalization, LRN), 为局部神经元的活动建立竞争机制,激发反馈较大的神经元,抑制其他反馈较小的神经元,提高了模型的泛化能力^[32]。AlexNet 网络中 LRN 的具体的计算公式如下:

$$b_{x,y}^i = \frac{a_{x,y}^i}{\left(k + \alpha \sum_{j=\max(0, i-n/2)}^{\min(N-1, i+n/2)} (a_{x,y}^j)^2\right)^\beta} \quad (3)$$

式中: a 表示经卷积和池化后的四维输出结果; $a_{x,y}^i$ 表示在这个输出结构中的一个位置 $[a, b, c, d]$; N 表示通道数。 $a, n/2, k, \alpha, \beta$ 分别表示函数中的 input, depth-radius, bias, alpha, beta, 其中 $n/2, k, \alpha, \beta$ 都是自定义的, i 表示第 i 个核在位置 (x, y) 运用激活函数 ReLU 后的输

出, n 是同一位置上临近的 kernel map 的数目。

全连接层在 CNN 中起着“分类器”的作用^[30]。在 AlexNet 结构中,经过多个卷积层和池化层后,连接 3 个全连接层。相邻全连接层的神经元直接连接,如图 4 所示。全连接层中的每个神经元都与前一层中的所有神经元完全连接。为了提高 CNN 的性能,通常采用 ReLU 函数作为全连接层各神经元的激活函数。

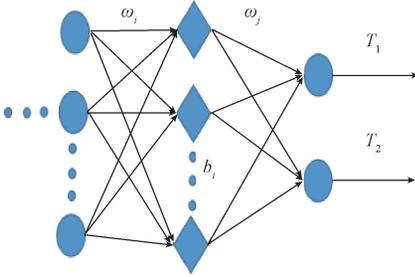


图 4 全连接层

Fig.4 Schematic diagram of fully connected layers

将最后一个全连接层的输出值传递给一个输出,该输出可以使用 softmax 回归进行分类,这些层中的激活函数称为 softmax,可以表示为:

$$softmax(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \quad (4)$$

Softmax 可以将输出限制在 (0, 1) 的范围内,从而保证神经元的激活。

迁移学习是指利用预先训练好的模型生成支持新任务的神经网络模型。迁移学习是在已训练好的网络模型的基础上进行参数的迁移,设计和训练一个全新的网络,节省了大量的计算资源和训练时间^[33]。整个迁移网络结构分为预训练网络和迁移网络两部分。预训练网络已经为各种图像学习了丰富的特征表示。所提取的特征能够达到很好的分类效果,网络中的参数只需要进行微调,以适应新的图像。而迁移网络中的参数在整个网络中占有很小的一部分,适合在小数据集上进行训练。因此,在脑电数据样本不足的情况下,迁移学习是一种非常方便有效的训练深度神经网络的方法^[33]。此外,训练深度网络需要高性能的 GPU 和 CPU,而迁移学习可以在普通的个人计算机上实现。大大节约了训练时间。本文迁移学习 AlexNet 模型如图 5 所示。

在迁移学习过程中,AlexNet 模型的最后 3 层替换为包含两个节点的全连接层(本文的分类任务是一个二分类),softmax 层和最终分类层。其中预训练网络中的参数已对 100 多万幅图像进行了训练。只需要进行参数微调,以便于适应致痫区脑电信号的时频图像。

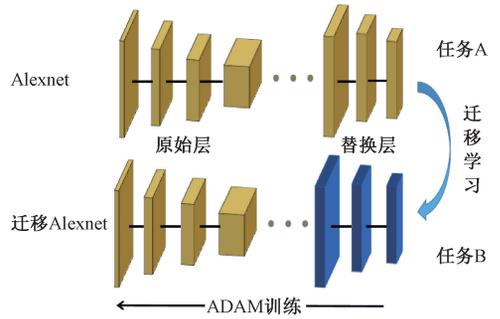


图 5 AlexNet 模型的迁移学习过程

Fig.5 Transfer learning process of the AlexNet model

在训练迁移的 AlexNet 模型过程中,根据控制变量法改变网络求解器、MinBatchSize 和 MaxEpochs 3 个参数。首先改变其中的网络求解器训练参数,保持其余训练参数不变,获得在网络求解器 m 情况下的最佳脑电识别效果;然后在确定网络求解器为 m 的情况下,改变 MinBatchSize 的值,在 MinBatchSize 为 n 时,获得最佳的致痫区脑电识别效果;最后在确定训练参数网络求解器和 MinBatchSize 的情况下,改变 MaxEpochs 的值,保持其他训练参数不变,在 MaxEpochs 值为 k 时,获得最佳的致痫区脑电识别效果。

因此,在利用致痫区脑电时频图的训练集训练网络过程中,将网络求解器、MinBatch-Size 和 MaxEpochs 3 个参数设置为 $[m, n, k]$ 时,迁移学习 AlexNet 网络可获得最佳的致痫区脑电识别效果。在确定最佳的网络训练参数时,提取致痫区脑电信号时频图的特征,以模型的某一层输出作为致痫区脑电时频图的特征表示。

1.3 分类算法

本文利用多种不同的分类算法对提取到的脑电时频图特征进行分类。具体分类算法如下:

SVM 是一种利用训练集构造超平面对测试样本进行分类的核学习方法^[32]。SVM 算法的独特之处是使用了内积核函数。其最终决策函数取决于少数的支持向量,这不但可以避免大量的冗余样影响算法的效果,而且注定了 SVM 算法具有更为突出的鲁棒性^[33]。计算的难易程度一般是由支持向量的数量决定且不会受到空间维数的影响。是一种几乎能够实现结构零风险的方法。与已有的统计方法相比,SVM 基本不需要涉及到大数据定律等。从本质上看,SVM 省去了从归纳到演绎的过程,使其在通常的分类和回归等问题方面得到了大大的简化^[33]。

BP 神经网络(back propagation, BP)的核心思想是反应输出与输入之间的映射,其激活函数一般用 S 型函数。在解决内部机制复杂的问题方面具有明显的优势。在容错性和处理速度方面比较突出。此外 BP 神经网络

的概括能力和自适应能力相比于其他算法也具有明显的优势^[34],对于BP神经网络的输入与输出之间的关系,在学习过程中并不需要提前指出。BP神经网络在学习速率上具有明显的缺陷,容易产生“锯齿形现象”,造成算法的效率过低;另外,一旦BP神经网络结构过于复杂时,采用误差逆传播算法不仅会浪费大量的时间,而且得不到最优的结果。

长短期记忆网络(long short-term memory, LSTM)的内部结构包括忘记阶段、选择记忆阶段以及输出阶段3部分。相比于RNN算法,当信息送入网络中时,LSTM算法可根据判别信息是否有用的处理器留下符合条件的信息,将不符合条件的信息送入遗忘门^[35]。LSTM是一种普适性很高的能够快速处理长序依赖问题的方法^[36]。LSTM结构如图6所示,当输入门的值为1时,表示来自其他节点的所有流都将通过。而遗忘门在神经网络的连续运行中有着不可替代的作用。输出门的最终输出值是由一个存储器单元通过乘以内部状态和输出门的值产生。自循环结构存在于每个内部状态。

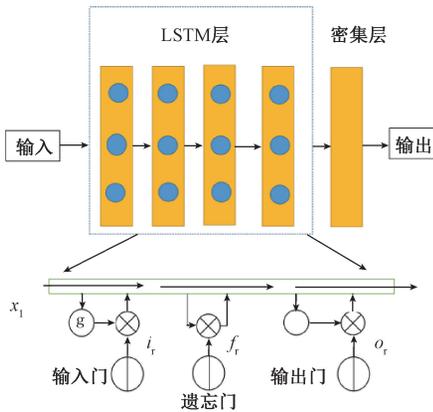


图6 LSTM模型

Fig.6 LSTM model

LSTM模型的完整算法公式如下:

$$g^{(t)} = \varphi(W^{gx}x^{(t)} + W^{gh}h^{(t-1)} + b_g) \quad (5)$$

式中: g 表示输入节点,其时间区间为 $t-1$ 的隐藏层到时间为 t 的输入层中接收激活信号的节点。采用Tanh函数为激活函数,其作用是输入信号聚集权重。输入节点 g 与输入层 x 之间的权重用 W^{gx} 表示,输入节点与隐藏层 h 之间的权重用 W^{gh} 表示,输入节点的偏置用 b_g 表示。公式中权重和偏置是相同的。

稀疏表达分类算法(sparse representation-based classifier, SRC)是由Wright等^[37]提出的一种将稀疏编码的方法用于分类的机器学习算法。当具有足够多的各个类别训练样本时,测试样本并不会受到其他类样本的影响,仅需要利用训练样本就可对测试样本进行线性表示,从而将一般信号的分类问题转化为了一种

稀疏表示问题。相对于其他算法而言,数据缺失对于SRC的分类效果并没有影响,所求系数只要足够稀疏,特征空间的选取对于SRC分类效果几乎没有影响;这也是SRC分类效果优于其他算法的原因所在^[38]。SRC的求解就是求方程的稀疏解,常用的求解方法包括贪婪算法和基追踪算法。根据原子和测试样本之间的关系来确定位置是贪婪算法的核心思想,最小二乘法用来估计幅值。常用的贪婪算法有匹配追踪、正交匹配追踪算法等。基追踪算法是求解未知参量最小化范数的方法。使用一种对已知系数稀疏化、将优化问题中的L0范数转化为L1范数的求解。

线性判别分析(linear discriminant analysis, LDA)是一种常用于二分类问题的线性学习方法。其基本思想包括两点:1)不同类别的点尽可能远离;2)相同类别的点尽可能相近^[39]。相比于传统的分类算法而言LDA有效地避免了在一般非线性算法中常遇到的局部最小问题,从而使LDA在不平衡模式类的处理中具有明显的优势。与神经网络方法相比,LDA不存在选择学习参数和优化权重以及激活函数的问题,在某些实际情形中,LDA在推广性能及计算效率方面比SVM更具有优势。

2 实验

2.1 实验数据

本文采用开放获取的Bern-Barcelona脑电数据集,该实验数据包含了5例长期存在药物耐受性颞叶癫痫患者的脑电记录^[40]。所有患者都在伯尔尼大学神经内科接受了长期的颅内脑电图记录^[40]。所有脑电信号通过四阶巴特沃斯滤波器采用正向和反向滤波的方式进行滤波,以便减小相位畸变。信号采样频率为512或1024 Hz,取决于采集通道是否超过64个。这些颅内脑电信号都可以定位癫痫发作的大脑区域并且不会有神经缺陷的危险。5例患者均获得良好的手术效果。其中3例患者获得完全癫痫发作自由,2例患者术后仅出现先兆,无需进一步手术^[41]。5名患者均以书面形式同意其EEG数据用于癫痫相关的研究。

此数据集中包含3750段焦点信号以及3750段非焦点信号。标签1和-1分别代表焦点和非焦点信号,Bern-Barcelona脑电数据库的焦点和非焦点信号片段如图7所示。每个片段的时间长度为20s,采样率为512 Hz。由于Bern-Barcelona数据集样本量不足,为了充分利用脑电数据集对算法效果进行检验,本文采用了十折交叉验证法将脑电数据集随机分为10个子集,每次使用1个子集作为测试集,其余9个子集作为训练集。训练集与测试集的分布情况如表1所示。

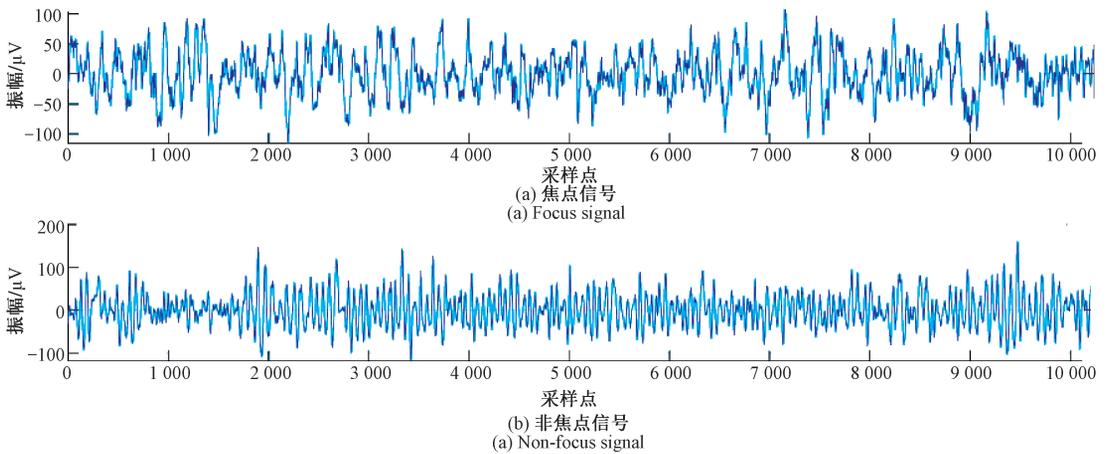


图 7 Bern-Barcelona 脑电数据库焦点和非焦点信号片段示例

Fig.7 The example of Bern-Barcelona EEG database focus and non-focus signal fragments

表 1 训练集和测试集

Table 1 Training set and test set

数据集	焦点信号	非焦点信号
训练集	6 750	6 750
测试集	750	750

2.2 实验条件及过程

本实验为了验证本文算法的基于深度网路迁移学习的致痫区脑电识别算法性能,所使用的硬件设备是 64 bit 计算机,其操作系统为 Windows 10,采用 i7-7770CPU 和 NVIDIA Quadro K620 GPU 在 MATLAB R2018a 软件进行编程实现。经过训练的网络结构可以在任何安装 MATLAB 的个人计算机上运行。

整个实验过程主要分为 4 部分:实验数据预处理、深度网络迁移学习、特征提取和特征分类。预处理阶段,利用 CWT 生成符合深度网络输入要求的致痫区脑电时频图。在深度网络迁移学习阶段,将预先训练好的深度网络 ALexNet 模型结合迁移学习构成新的网络结构。在特征提取阶段,本文利用迁移学习的 ALexNet 网络第 7 层输出作为特征表示。特征分类阶段,采用支持向量机、BP 神经网络、长短期记忆网络、基于稀疏表达的分类算法、线性判别分析等分类算法进行特征分类,比较各种分类算法结果获得最佳的分类结果。

表 2 所示给出了基于深度网络迁移学习算法经过十折交叉验证法验证,获得的 10 次分类结果混淆矩阵,利用该矩阵可以获得最终的脑电信号分类结果。而本文的评估方式是基于时间片段的方法,比较致痫区或者非致痫区的标识同神经专家给出来的分类参数做对比,获取最终的评估结果。灵敏度、特异性和准确率 3 种传统的统计测量指标被用于评估系统性能,其定义如下:

1) 灵敏度:正确检测到的致痫区焦点信号片段(TP)与脑电图学专家所标记的焦点信号片段的比率。TP 表示一个被标记为焦点信号的实验结果和专家标识参数为焦点信号。

2) 特异性:正确检测到的非致痫区非焦点信号片段(TN)与脑电图学专家所标记的非焦点片段的比率。TN 代表一个被标记为非焦点的实验结果和专家标识参数都为非焦点信号。

3) 识别准确率:正确检测到焦点信号片段和非焦点信号片段之和与脑电信号片段总数的比值。

表 2 混淆矩阵

Table 2 Confusion matrix

信号	焦点信号	非焦点信号
焦点信号	6 605	895
非焦点信号	839	6 601

本文利用训练集和测试集的致痫区脑电数据对迁移学习深度网络模型进行评估测试。训练集和测试集无重叠现象。训练过程中,利用控制变量法改变训练参数:网络求解器、MinBatchSize 以及 MaxEpochs 大小,选出最佳的 1 组训练参数。结果显示 10 次训练网络平均准确率为 96.4%,训练损失最终达到 0.1 左右。平均测试准确率为 85.47%。测试损失达到 0.1 左右。结果表明在网络训练过程中并未出现过拟合现象。利用表 2 所示的混淆矩阵,可以计算出准确性、灵敏性和特异性。本文提出的基于深度网络迁移学习方法在准确率、灵敏度和特异性方面均达到了较好的结果。

3 结果与讨论

图 8 所示为选择在不同训练网络求解器下,采用基

于深度网络迁移学习算法,所获得的准确率,特异性和灵敏度。在采用 sdgm 训练网络求解器时,其准确率和特异性分别为 84.47% 和 85.04%。低于求解器 adam 和 rmsprop 的准确率和特异性。而其灵敏度为 83.91%,高于 rmsprop 求解器,低于 adam 求解器。而在求解器 rmsprop 的情况下,其灵敏度为 83.28%,低于求解器 sdgm 和 adam 的灵敏度。求解器 adam 的准确率、灵敏度和特异性为 87.45%、86.13% 和 88.77,明显高于 sdgm 和 rmsprop 求解器的值。综上所述,本实验中,训练网络求解器选择 adam 可获得最优结果。

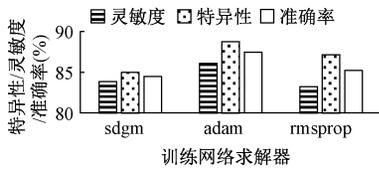


图8 不同训练网络求解器下的特异性、灵敏度、准确率情况
Fig.8 The specificity, sensitivity and accuracy for different training network solvers

本实验中,在确定训练网络求解器为 adam 的基础上,分别选择不同 MiniBatchSize 值再次进行调试比较。在 MiniBatchSize 值为 [8, 16, 32, 64, 128] 范围内,不同值的灵敏性、特异性和准确性结果如图 9 所示。从图 9 可以看出,MiniBatchSize 值为 32 时特异性明显优于其他 4 个 MiniBatchSize 值的特异性,最高达到 88.77%。在 MiniBatchSize 值为 64 时,其灵敏度达到 86.8%,高于 MiniBatchSize 值为 [8, 16, 32, 128] 的情况。同样在 MiniBatchSize 值为 32 时,其准确率为 87.45%,是 MiniBatchSize 值为 [8, 16, 32, 64, 128] 的情况下得到最优结果。综上所述,在 MiniBatchSize 值为 32 时,可获得最佳结果。因此,本实验中 MiniBatchSize 的值被设置为 32。

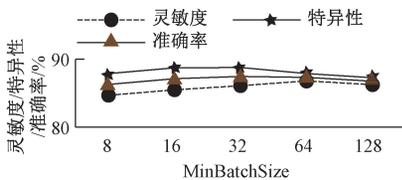


图9 在 MiniBatchSize 值为 [8, 16, 32, 64, 128] 范围内,不同的敏感性、特异性和准确性情况
Fig.9 Different sensitivities, specificities and accuracies when the value of MiniBatchSize is [8, 16, 32, 64, 128]

本实验中,在训练网络求解器为 adam 和 MiniBatchSize 值为 32 的情况下,调整 MaxEpochs 的值。在其值被设置为 [1 3 5 7 9] 的情况下,获得其特异性、灵

感和准确率,结果如图 10 所示。当 MaxEpochs 的值为 1 时特异性、灵敏度和准确率分别为 87.72%、84.52% 和 85.86%,相比于其他 4 个值 [3 5 7 9],明显处于最低结果。在 MaxEpochs 值为 5 的情况下,其特异性为 89.28%,达到最高结果。而当 MaxEpochs 值被设置为 7 时,其准确度和灵敏度达到最优结果,分别为 88.44% 和 88.07%。综上所述,在 MaxEpochs 值为 5 和 7 的情况下,获得的结果相对较好,而在值为 7 的情况下,相对而言可达到最佳效果。因此,本实验中,将 MaxEpochs 的值设置为 7。

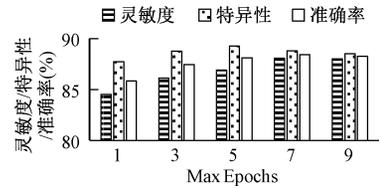


图10 在 MaxEpochs 值为 [1, 3, 5, 7, 9] 时,不同的敏感性、特异性和准确性情况
Fig.10 Different sensitivities, specificities and accuracies when the value of MaxEpochs is [1, 3, 5, 7, 9]

表 3 所示给出了在不同分类器中对于时频图特征的分类效果。可以看出 BP 神经网络、LSTM 以及 SRC 3 种算法准确率相差不大,BP 神经网络的灵敏度较好,而 SRC 算法的特异性较好。对于 LDA 算法其分类效果略低于 SVM 高于其他算法。Softmax (AlexNet 网络的全连接层)在这几种分类算法中效果最差,低于 SVM 算法约 3%。SVM 分类算法在准确率、灵敏度及特异性方面最有优势。因此,本实验中将 SVM 作为最终的分类算法。

表3 不同分类器结果比较

Table 3 The result comparison of different classifiers %

分类算法	准确率	灵敏度	特异性
BP 神经网络	86.95	87.626	86.29
LSTM	86.147	86.814	85.48
SRC	86.707	85.09	88.32
LDA	87.499	87.08	87.92
Softmax	85.47	85.20	85.73
SVM	88.44	88.07	88.81

表 4 所示为在选择不同迁移网络的情况下,识别脑电信号的情况,本文主要选择了 AlexNet 网络和 GoogleNet 网络模型进行迁移。从表 4 中可看出迁移学习 GoogleNet 网络模型对脑电信号的识别效果明显低于迁移学习 AlexNet 网络模型的识别效果,两者相差约为 6%。因此本文最终选择 AlexNet 网络作为最终的迁移网络。

表4 不同迁移网络脑电识别效果

Table 4 The EEG recognition results for different transfer networks

迁移网络	准确率	灵敏度	特异性	%
GoogleNet	82.4	81.8	83.0	
AlexNet	88.44	88.07	88.81	

4 结 论

本文提出了一种基于深度网络迁移学习的致痫区脑电信号自动识别算法,通过 CWT 的方法构建出每个样本的 RGB 时频图像,采用深度网络迁移学习的方法在改变训练网络求解器、MinBatchSize 以及 MaxEpochs 参数的情况下提取时频图像的特征表示,最后利用 6 种分类算法对特征进行分类。与传统的方法相比,本文算法不需要使用设计好的特征,而是通过训练数据自动学习致痫区脑电特征。本文采用迁移学习深度网络模型,对预先训练好的模型进行调整。比起重新建立网络模型,本文方法大大减少了重新训练网络的时间,对目标数据的需求量低。最终结果显示在选择 adam 训练网络求解器,MinBatchSize 以及 MaxEpochs 被设置为 32 和 7 的情况下,SVM 算法的平均分类准确率可达 88.44%,其灵敏度和特异性达到 88.07% 和 88.81%。该结果表明,采用基于深度网络迁移学习算法能够有效识别致痫区脑电信号,对于临床判断患者致痫区具有重要作用。

参考文献

- [1] WEI X Y, ZHOU L, ZHANG ZH, et al. Early prediction of epileptic seizures using a long-term recurrent convolutional network [J]. Journal of Neuroscience Methods, 2019,327: 108395.
- [2] MAHJOUR C, LE B J R, LAJNEF T, et al. Epileptic seizure detection on EEG signals using machine learning techniques and advanced preprocessing methods [J]. Biomedizinische Technik/Biomedical Engineering, 2020, 65(1): 33-50.
- [3] ENJEL J J. Early identification of refractory epilepsy[J]. Nengl Jmed, 2009, 342(5): 314-319.
- [4] MATTHEW W, DAVID P, LISA G, et al. Automatic detection of the epileptogenic zone: An application of the fingerprint of epilepsy [J]. Journal of Neuroscience Methods, 2019,325: 108347.
- [5] THOMSCHEWSKI A, HINCAPIE A, FRANSCHER B.

Localization of the epileptogenic zone using high frequency oscillations[J]. Frontiers in Neurology, 2019, 10:94.

- [6] LI Y H, YE X L, LIU Q Q, et al. Localization of epileptogenic zone based on graph analysis of stereo-EEG[J]. Epilepsy Research, 2016,128: 149-157.
- [7] CHRISTOPHER W, GREGOY W, BIN H. Graph analysis of epileptogenic networks in human partial epilepsy[J]. Epilepsia, 2011;52(1): 84-93.
- [8] ZHAO H ZH, LIU F X, ZHANG H, et al. Research on a learning rate with energy index in deep learning [J]. Neural networks: The Official Journal of the International Neural Network Society, 2018,110: 225-231.
- [9] WEI Z C, ZOUJ ZH, ZHANG J, et al. Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain [J]. Biomedical Signal Processing and Control, 2019, 53: 101551.
- [10] PETROSIAN A, PROKHOROV D, HOMAN R, et al. Recurrent neural network based prediction of epileptic seizures in intra-and extracranial EEG [J]. Neurocomputing, 2000,30 (1-4): 201-218.
- [11] MIROWSKI P W, MADHAAN D. Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG [C]. Processing of IEEE International Conference on Machine Learning for Signal Workshop, IEEE, 2008: 244-249.
- [12] XIA M, CLARENCE W D S. Gear transmission fault classification using deep neural networks and classifier level sensor fusion [J]. Instrumentation, 2019, 6(2): 101-109.
- [13] TROUND N D, NGUYEN A D, KUHLMANN L, et al. Integer convolutional neural network for seizure detection[J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 2018,08(4): 849-857.
- [14] ACHARYA U R, OH S L, HAGIWARA Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals [J]. Computers in Biology and Medicine, 2018, 100: 270-278.
- [15] ACHILLES F, TOMBARI F. Convolutional neural network for real-time epileptic seizure detection [J]. Computer Methods in Biomechanics and Biomedical

- Engineering: Imaging & Visualization, 2018, 6 (3) : 264-269.
- [16] MUHAMMED T, ULAS B B, ÖZAL Y, et al. Application of deep transfer learning for automated brain abnormality classification using MR images[J]. Cognitive Systems Research, 2018,54: 176-188.
- [17] JOYCE B W, NATASHA M M, BAUKE M J. EEG time-frequency analysis provides arguments for arm swing support in human gait control[J]. Gait & Posture, 2019, 70: 71-78.
- [18] MICHEL X C. A better way to define and describe morlet wavelets for time-frequency analysis [J]. NeuroImage, 2019,199: 81-86.
- [19] BARILE C, CASAVOLA C, PAPPALETTERA G, et al. Experimental wavelet analysis of acoustic emission signal propagation in CFRP [J]. Engineering Fracture Mechanics, 2019, 210: 400-407.
- [20] DENNIS B, BEAT G, RAINER K, et al. Effects of motor practice on learning a dynamic balance task in healthy young adults: A wavelet-based time-frequency analysis[J].Gait & Posture,2019, 70: 264-269.
- [21] MANUEL L M, BELEN C, ANTONIN S, et al. Shallow neural network with kernel ap proximation for prediction problems in highly demanding data networks[J]. Expert Systems with Applications, 2019,124: 196-208.
- [22] 陶聪,施云,张丽艳.基于卷积神经网络的汉字编码标记点检测识别 [J]. 仪器仪表学报, 2019, 40 (8) : 191-200.
- TAO C, SHI Y, ZHANG L Y. Detection and recognition of Chinese character coding marker points based on convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2019,40(8) : 191-200.
- [23] WANG X Y, TANG M, YANG S, et al. Automatic hypernasality detection in cleft palate speech using CNN[J]. Circuits, Systems, and Signal Processing, 2019,38(8) : 3521-3547.
- [24] ANJU U, SOWMYA V, SOMAN K P. Deep alexnet with reduced number of trainable parameters for satellite image classification [J]. Procedia Computer Science, 2018, 143:931-938.
- [25] AN F P, LIU ZH W, BARBARA P. Medical image segmentation algorithm based on feedback mechanism CNN[J]. Contrast Media & Molecular Imaging, 2019, 53: 101589.
- [26] 温江涛,王涛,孙洁娣,等.基于深度迁移学习的复杂环境下油气管道周界入侵事件识别[J].仪器仪表学报, 2019,40(8) :12-19.
- WEN J T, WANG T, SUN J D, et al. Identification of oil and gas pipeline boundary intrusion in complex environment based on deep migration learning [j]. Chinese Journal of Scientific Instrument, 2019, 40 (8) : 12-19.
- [27] LU S Y, LU ZH H, ZHANG Y D. Pathological brain detection based on alexnet and transfer learning [J]. Journal of Computational Science, 2019,30: 41-47.
- [28] WANG R, XU J W, TONY X H. Object instance detection with pruned alexnet and extended training data[J]. Signal Processing: Image Communication, 2019,70: 145-156.
- [29] HU H F, LIAO ZH K, XIAO X. Action recognition using multiple pooling strategies of CNN features [J]. Neural Processing Letters, 2019, 50(1) : 379-396.
- [30] SWAPNA P, JAYASANKA R, LALITH B, et al. An improved machine learning approach to classify sleep stages and apnea events [J]. Instrumentation, 2019, 6(2) :30-40.
- [31] 李帷韬,韩慧慧,焦点,等.基于深度迁移学习的大雾等级智能认知方法研究[J].电子测量与仪器学报,2020, 34(2) :88-96.
- LI W T, HAN H H, JIAO D, et al. Research on intelligent cognitive method of fog level based on deep transfer learning[J]. Journal of Electronic Measurement and Instrument, 2020,34(2) :88-96.
- [32] XUE W D, CHAI Y, LI Q G, et al. Short-term relay quality prediction algorithm based on long and short-term memory[J]. Instrumentation, 2018,5(4) :46-54.
- [33] MURUGAN A, NAIR S A H, KUMAAR K P S. Detection of skin cancer using SVM, random forest and KNN classifiers[J]. Journal of Medical Systems, 2019, 43(8) : 1-9.
- [34] RAGHU S, SRIAAM N, TEMEL Y, et al. Performance evaluation of DWT based sigmoid entropy in time and frequency domains for automated detection of epileptic seizures using SVM classifier[J]. Computers in Biology and Medicine,2019,110: 127-143.
- [35] 董珍一,林莉,孙旭,等.基于BP神经网络的超声表面

- 波定量表征金属表层裂纹深度研究[J].仪器仪表学报,2019,40(8):31-38.
- DONG ZH Y, LIN L, SUN X, et al. Ultrasonic surface wave quantitative characterization of metal surface crack depth based on BP neural network[J]. Chinese Journal of Scientific Instrument, 2019,40(8):31-38.
- [36] CHO M, HA J, PARK C, et al. Combinatorial feature embedding based on CNN and LSTM for biomedical named entity recognition [J]. Journal of Biomedical Informatics, 2020,103: 103381.
- [37] WRIGHT J, MA Y, MAIRAL J, et al. Sparse representation for computer vision and pattern recognition[J]. Proceedings IEEE, 2010, 98 (6): 1031-1044.
- [38] LU P Y, CHEN N, MAO SH J, et al. LSTM based encoder-decoder for short-term predictions of gas concentration using multi-sensor fusion [J]. Process Safety and Environmental Protection, 2020,137: 93-105.
- [39] CANONICI A, BROWNE A L, IBRAHIM M F K, et al. Combined targeting EGFR and SRC as a potential novel therapeutic approach for the treatment of triple negative breast cancer [J]. Therapeutic Advances in medical Oncology, 2020,12: 1758835919897546.
- [40] WIESER H G, BLUME W T, FISH D, et al. ILAE commission report. proposal for a new classification of outcome with respect to epileptic seizures following epilepsy surgery[J]. Epilepsia, 2001, 42(2): 282-286.
- [41] ATEMANGO B P, DANIEL T. Epileptic seizures detection based on some new laguerre polynomial wavelets, artificial neural networks and support vector machines[J]. Informatics in Medicine Unlocked, 2019, 16: 100209.

作者简介



曲桂果,2017年于山东师范大学获得学士学位,现为山东师范大学硕士研究生,主要研究方向为生物医学信息处理和模式识别。

E-mail: 1124297874@qq.com

Qu Guiguo received B. Sc degree from Shandong Normal University in 2017. Now, he is an M. Sc. candidate in Shandong Normal University. His main research interests include biomedical information processing and pattern recognition.



袁琦(通信作者),2014年于山东大学获得博士学位,现为山东师范大学物理与电子科学学院副教授、硕士生导师,主要研究方向为生物医学信息处理和模式识别。

E-mail: yuanqi@sdu.edu.cn

Yuan Qi (Corresponding author) received his Ph. D. degree from Shandong University in 2014. Now, he is an associate professor and master student supervisor in School of Physics and Electronics, Shandong Normal University. His main research interests include biomedical information processing and pattern recognition.