

文章编号: 1671-7104(2019)02-0086-04

# 基于稀疏连接残差网络的 心脏传导阻滞精确定位的自动识别

**【作者】** 齐继<sup>1,2</sup>, 张瑞卿<sup>1</sup>, 沈阳<sup>1</sup>, 常世杰<sup>1</sup>, 沙宪政<sup>1</sup>  
1 中国医科大学生物医学工程系, 沈阳市, 110122  
2 中国医科大学附属第四医院, 沈阳市, 110032

**【摘要】** **目的** 实现对右束支阻滞、左束支阻滞和正常心电信号进行自动分类。**方法** 以MIT-BIH数据库为实验数据来源, 从中提取训练集和测试集数据用于训练和测试网络模型, 基于卷积神经网络提出核心算法: 稀疏连接残差网络。将稀疏连接残差网络与已有的经典网络模型进行对比, 以评估模型的识别效果。**结果** 稀疏连接残差网络的测试集准确率为95.2%, 识别结果优于经典网络模型。**结论** 该文提出的算法能够辅助医生进行心脏传导阻滞类疾病的诊断, 有一定的临床应用价值。

**【关键词】** 心脏传导阻滞; 深度学习; 卷积神经网络

**【中图分类号】** R318.04

**【文献标志码】** A

doi: 10.3969/j.issn.1671-7104.2019.02.003

## Automatic Identification of Heart Block Precise Location Based on Sparse Connection Residual Network

**【Writers】** QI Ji<sup>1,2</sup>, ZHANG Ruiqing<sup>1</sup>, SHEN Yang<sup>1</sup>, CHANG Shijie<sup>1</sup>, SHA Xiangzheng<sup>1</sup>  
1 Department of Biomedical Engineering, China Medical University, Shenyang, 110122  
2 The Fourth Affiliated Hospital of China Medical University, Shenyang, 110032

**【Abstract】** **Objective** To classify Right Bundle Branch Block(RBBB), Left Bundle Branch Block(LBBB) and normal ECG signals automatically. **Methods** The MIT-BIH database was used as experimental data sources. The training set and test set were extracted for training and testing network models. Based on convolutional neural network, this paper proposed the core algorithm: sparse connection residual network. Compared the sparse connected residual network with classic network models, then evaluated the recognition effect of the model. **Results** The accuracy of the test set the MIT-BIH database was 95.2%, the result is better than classic network models. **Conclusion** The algorithm proposed in this paper can assist doctors in the diagnosis of heart block related disease and place a high value on clinical application.

**【Key words】** heart block, deep learning, CNN

### 0 引言

心脏传导阻滞指由于心肌传导组织发生病理性改变, 导致起搏细胞发出的动作电位的传递出现障碍, 产生传导被阻或传导延缓的现象, 是心律失常的表征之一。心脏传导阻滞常见于急性心肌梗死、病毒性心肌炎、心内膜炎等心血管病<sup>[1]</sup>。心脏传导阻滞按部位分为完全左、右束支阻滞, 不完全左、右束支阻滞, 及左前分支、左后分支阻滞, 按严重程度分为I°、II°和III°传导阻滞<sup>[2]</sup>。对于大多数心脏传导阻滞的诊断, 临床检查最常用的方法是心电图。利用传统的数字信号处理方法, 如小波变换等对心电数据进行处理, 能够达到较高的识别率<sup>[3]</sup>。但如果想利用数字信号处理

的方法识别心电数据特征, 则需要人工提取每一种特征。深度学习技术使用大数据对设计的模型进行训练, 使得模型能够自动提取数据之间隐含的特征, 进而能够识别心电信号所表现出的疾病。

在心电识别领域, KIRANYAZ等<sup>[4]</sup>基于MIT-BIH数据库, 利用卷积神经网络(Convolutional Neural Network, CNN)<sup>[5]</sup>模型进行训练, 对心室异位节拍的识别准确率为99%, 对室上性异位节拍的识别准确率为97.4%; RAJPURKAR等<sup>[6]</sup>基于实验室构建的心电数据库, 利用CNN模型对14种心律失常数据进行研究, 得到80.9%的平均识别准确率; ISIN等<sup>[7]</sup>基于MIT-BIH数据库, 利用CNN对MIT-BIH数据进行三分类, 得到92.4%的准确率。目前, 还没有心脏传导阻滞定位的相关研究。

深度学习是机器学习的分支, 是人工智能应用

收稿日期: 2018-08-24

基金项目: 辽宁省教育厅科学研究一般项目(L2015563); 辽宁省创新创业教育改革试点专业(2016年12号)

通信作者: 常世杰, E-mail: 121161415@qq.com  
沙宪政, E-mail: xzsha@mail.cmu.edu.cn

的一部分,在图像分析、语音识别、自然语言处理等领域均表现出强大的性能。其主要框架<sup>[8-12]</sup>有卷积神经网络(Convolutional Neural Network, CNN)、循环神经网络(Recurrent Neural Networks, RNN)等,其中CNN在数据识别中的应用较为广泛,CNN的变体如GoogLeNet<sup>[13]</sup>、VGG<sup>[14]</sup>、ResNet<sup>[15]</sup>等网络,对于复杂数据有更好的分类效果。本文在CNN的基础上提出多分辨率稀疏连接残差网络,该网络能够应用于心脏传导阻滞定位的自动识别,并可以辅助医生进行心血管疾病的诊断,有一定的临床意义。

## 1 深度神经网络算法

### 1.1 卷积神经网络(CNN)及其改进算法

CNN是一种复杂的神经网络(如图1所示),它的中间层有若干组卷积层与池化层组成,卷积层对输入层数据进行卷积运算,产生特征映射图,完成局部特征提取的第一步,确定局部特征与其他特征之间的位置关系,然后根据池化窗口的大小,对特征映射图进行池化操作,融合相似的局部特征,再通过激活函数得到特征映射图。用同样的方法进行 $n$ 次卷积和池化操作,最后输入到全连接层,得到输出。




图1 卷积神经网络  
Fig.1 Convolutional neural network

CNN的卷积层和池化层可以用下式表示:

$$\text{卷积层: } y_j^l = f(\sum_{i \in M_j} y_i^{l-1} * k_{ij} + b_j^l) \quad (1)$$

$$\text{池化层: } y_j^l = f(\beta_j^l \text{down}(y_j^{l-1}) + b_j^l) \quad (2)$$

其中,  $y_j^l$ 表示第 $l$ 层的 $j$ 个输出,  $M_j$ 表示特征映射图的集合,  $f$ 是激活函数,  $k$ 为权值矩阵的对应值,  $b$ 表示加法偏置,  $\beta$ 表示乘法偏置,  $\text{down}$ 表示下采样函数。

ResNet是CNN的一种变体,用来解决退化以及网络过深时无法训练的问题<sup>[15]</sup>。如图2所示,ResNet的主要特点是跨层连接,它通过引入短连接技术将输入跨层传递后与卷积之后的结果相加。ResNet使得底层的网络能够得到充分训练,准确率也随着深度的加深而得到显著提升。

通过预实验,利用上述传统方法处理心脏传导阻滞数据时,遇到了网络模型在训练过程中无法收敛的问题。




图2 残差网络模块  
Fig.2 A block of residual networks

### 1.2 稀疏连接残差网络(Sparsely Connected ResNet, RSCR)

本研究设计了如图3所示的网络结构,它有1个输入层和1个输出层,隐藏层由1个卷积层、2个最大池化(Max Pool)层和3组ResNet模块构成,每组ResNet模块含有10个卷积层,本网络结构共有31个卷积层。卷积核的大小是 $1 \times 9$ 。第一个卷积层对应的输出节点数为32,每组ResNet模块分别对应128、128、256个输出节点。

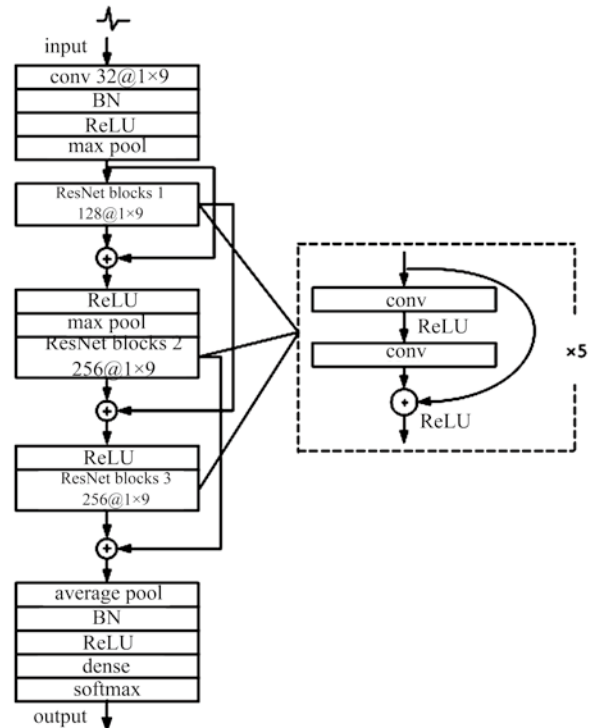


图3 稀疏连接残差网络  
Fig.3 Sparsely connected ResNet

训练步骤如下:

(1) 训练集数据进入第1层卷积层,通过修正线性单元(Recitified Linear Units, ReLU)函数进行激活,ReLU可以有效克服梯度消失问题,并提高训练效率<sup>[16]</sup>。

(2) 第2层为最大池化(Max Pool)层,再通过ReLU激活后的输出分为两个支路,其中一个支路继续沿着主框架向下进行训练,另一个支路保留数据信息,连接到第1组ResNet模块的输出端。

(3) 第1组的ResNet模块间的输出分为两个支路,其中一条支路经ReLU激活函数和Max Pool层处理后,沿主框架向下训练,另一条支路直接连接到第2组ResNet模块的输出端。

(4) 第2组的ResNet模块间的输出分为两个支路,其中一条支路经ReLU激活后,沿主框架向下训练,另一条支路直接连接到第3组ResNet模块的输出端。

(5) 最后通过平均池化(Average Pool)层、全连接层和softmax分类器得到最终输出。

需要指出的是,每个卷积层之后都伴随一个批量归一化(Batch Normalization, BN)层, BN层是一种训练优化方法,用来解决Covariate Shift的问题,即把每层网络任意神经元的输入值限制为均值为0方差为1的正态分布,使得梯度变大,训练过程收敛快,加快训练速度,避免梯度消失问题<sup>[17]</sup>。

这里将该网络结构称为稀疏连接残差网络(Sparsely Connected ResNet, RSCR)。

## 2 数据处理与提取

本文采用MIT-BIH标准数据库进行训练和验证。

MIT-BIH是美国麻省理工学院提供的研究心律失常的数据库,该数据库采集了48位患者的心电数据并以心拍的形式进行记录,采样率为360 Hz。本文根据MIT-BIH数据注释文件的特点设计提取的规则为:选择二导联数据,先找到注释文件中标注阻滞注释的心拍,之后以此为中心截取10 s的数据长度,形成一个样本,每条样本提取3 600个电位数据,之后进行线性插值运算,使每个样本具有5 600个数据点,从而实现数据的扩增。

从MIT-BIH数据库提取的训练集与测试集数据分布如表1所示,训练集数据有右束支传导阻滞(RBBB)、左束支阻滞(LBBB)和正常(NORMAL)心电数据各1 000条,共计3 000条;测试集有RBBB、LBBB、NORMAL各250条共计750条数据。

表1 训练集与测试集的数据分布  
Tab.1 The distribution of training set and test set

数据集	RBBB	LBBB	NORMAL	合计
训练集	1 000	1 000	1 000	3 000
测试集	250	250	250	750

## 3 结果

### 3.1 模型训练方法

本文采用较为精短的LeNet34、Vgg16、ResNet34、RAJPURKAR<sup>[6]</sup>提出的模型与本文提出的RSCR进行对比。利用MIT-BIH训练集数据对五种模型分别进行训练,测试集数据输入到训练好的模型中,得出模型的分类结果。

本文采用的开发平台是Windows 10操作系统,CNTK 2.0,编程语言是python 3.5.2。计算机配置: Intel Core i3-2120 3.3 GHz,显卡为NVIDIA GeForce GTX1080,显存大小为8 GB,内存大小为16 GB。

本文采用的RSCR网络模型参数设置如下:

学习率设置为0.000 025~0.000 1,训练集和测试集的输入数据矩阵大小均为 $1 \times 1 \times 5\ 600$ ,故输入层的节点数为5 600,隐藏层的节点数为32~256。

### 3.2 基于不同网络的识别结果分析

本文从MIT-BIH数据库选取如表1所示的训练集与测试集数据,分别基于LeNet34、Vgg16、ResNet34、MRSCR以及RAJPURKAR<sup>[6]</sup>提出的网络模型进行训练,识别结果如表2所示,RSCR的准确率为95.2%,均高于其他四种网络。

表2 RSCR与经典模型测试集识别准确率对比

Tab.2 Comparison of RSCR and classic models' identify precision on test data

网络模型	准确率(%)
LeNet34	67.6
Vgg16	85.0
ResNet34	68.7
RAJPURKAR	32.9
RSCR	95.2

进一步分析实验结果,为了体现训练集数据在训练过程中的收敛情况,得到上述五种模型的收敛曲线如图4所示。可见相较于其他网络,RSCR收敛曲线更加平滑,收敛效果更好。在训练过程中RSCR的识别错误率能够降得较低,并且维持在比较稳定的水平。

## 4 讨论

本文提出MRSCR网络并将其用于心脏传导阻滞精确定位的自动识别。首先,从MIT-BIH数据库中提取训练集数据用于训练神经网络模型,提取测试集数据用于评估模型识别效果。然后,将传统的深度神经网络与RSCR进行对比。最后,对RSCR模型的结果进行可视化处理。

对MIT-BIH数据库进行三分类,RSCR的识别准确率均高于RAJPURKAR提出的模型以及LeNet34等其他深度学习模型;在RAJPURKAR等<sup>[6]</sup>的试验中,

临床专家对完全心脏传导阻滞的识别准确率为70%，RSCR模型的识别准确率为95.2%，高于临床专家的识别准确率；在ISIN等<sup>[7]</sup>的试验中，识别准确率为92.4%，与前者相比，RSCR准确率略高，并省去了噪声处理、数据预处理等复杂的人工特征提取步骤。由实验可知，在心脏传导阻滞定位识别方面，RSCR

有较高的准确率和较好的临床诊断效果，可以应用于临床心电图辅助诊断任务，也可以与硬件相结合，开发带有辅助诊断功能的家用心电图监护便携设备，用于家庭日常监护诊断和预警。在以后的研究中，将对心脏传导阻滞以外的心电数据进行深度神经网络训练，使其能够识别更多种类的心血管疾病，从而在临床心电图数据自动诊断中实现更广泛的应用。

#### 参考文献

- [1] 钟杭美. 临床12导联同步静态心电图[M]. 北京: 中国医药科技出版社, 2013.
- [2] 王龙. 心脏房室传导阻滞的分类与心电图表现[J]. 中华全科医师杂志, 2009, 8(6): 429-430.
- [3] 邓勇, 施文康, 刘琪. 小波变换的信号分形分析及其在心电信号处理中的应用研究[J]. 物理学报, 2002, 51(4): 759-762.
- [4] KIRANYAZ S, INCE T, GABBOUJ M. Real-Time Patient-Specific ECG Classification by 1D Convolutional Neural Networks.[J]. IEEE Trans Biomed Eng, 2016, 63(3): 664.
- [5] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proc IEEE, 1998, 86(11): 2278-2324.
- [6] RAJPURKAR P, HANNUN A Y, HAGHPANAHI M, et al. Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks[J]. arXiv preprint arXiv: 1707.01836, 2017.
- [7] ISIN A, OZDALILI S. Cardiac arrhythmia detection using deep learning[J]. Proc Comput Sci, 2017, 120: 268-275.
- [8] ROBINSON A J. An application of recurrent nets to phone probability estimation[J]. IEEE T Neural Network, 1994, 5(2): 298-305.
- [9] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neur Comput, 2006, 18(7): 1527-1554.
- [10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Comput, 1997, 9(8): 1735-1780.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]. International Conference on Neural Information Processing Systems. MIT Press, 2014: 2672-2680.
- [12] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines[C]. Proceedings of the 27th international conference on machine learning (ICML-10). Haifa, 2010: 807-814.
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 1-9.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Comput Sci, 2014.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Computer Vision and Pattern Recognition. IEEE, 2015: 770-778.
- [16] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks[C]. Proceedings of Advances in Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1097-1105.
- [17] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]. Proc 32nd Int Conf Mach Learn, 2015, 37: 448-456.




图4 在训练集中RSCR与经典模型的收敛曲线对比

Fig.4 Comparison of RSCR and classic models' convergent curve on train data