



(12)发明专利申请

(10)申请公布号 CN 110613445 A

(43)申请公布日 2019.12.27

(21)申请号 201910913304.X

(22)申请日 2019.09.25

(71)申请人 西安邮电大学

地址 710061 陕西省西安市长安南路563号

(72)发明人 包志强 邢瑜 王宇霆 张燕

(74)专利代理机构 西安科果果知识产权代理事

务所(普通合伙) 61233

代理人 李英俊

(51)Int.Cl.

A61B 5/0476(2006.01)

A61B 5/00(2006.01)


权利要求书2页 说明书7页 附图4页

(54)发明名称

一种基于DWNN框架的心电信号的识别方法

(57)摘要

本发明公开了一种基于DWNN框架的心电信号的识别方法,心电图作为原始数据进入小波层,小波层通过小波分解和随机加权重构,提取出心电图中的深层数据特征,池化层对提取到的数据特征经过池化操作降维,全连接层是将降维的数据特征综合起来,输出层利用softmax函数输出分类结果。在800个测试心电信号中,本发明总共有794个信号预测正确,6个信号预测错误,本发明的预测正确率为99.25%;结果表明本发明具有更为明显的分类识别结果。



1. 一种基于DWNN框架的心电信号的识别方法,其特征在于,包括以下操作:

1) 构建包括深层特征构造模块、全连接层和输出层的DWNN框架模型,其中深层特征提取模块包括n个由小波层和池化层构成的子模块,心电信号交替进入小波层和池化层,小波层通过小波分解和随机加权重构提取出心电信号中的深层数据特征,池化层对提取到的深层数据特征进行池化降维,交替处理后得到小波构造的深层特征;全连接层将小波构造的深层特征综合后交给输出层;输出层采用softmax函数输出心电信号分类概率;

2) 对构建的DWNN框架模型利用训练集,通过前向传播进行学习训练,并通过反向传播调节各层的网络权值和小波重构时的权重,用损失函数来度量,多轮迭代后使得预测结果与实际结果误差最小;

3) 将心电信号输入训练好的DWNN框架模型,依次经过小波层、池化层、全连接层的处理,由输出层输出各分类结果的概率,并以概率值最大的类型作为心电信号分类识别的结果。

2. 如权利要求1所述的基于DWNN框架的心电信号的识别方法,其特征在于,所述的小波层采用二维离散小波变换对输入的心电信号进行分解,得到多个子图像;然后对子图像进行p次随机加权再进行小波逆变换,重构得到p张小波特征图,p是大于等于1的整数;

所述的池化层是将重构的小波特征图进行降维操作,去除冗余信息。

3. 如权利要求2所述的基于DWNN框架的心电信号的识别方法,其特征在于,所述小波层在分解时将心电图图像分解成四个子图像:原图的近似值、水平细节、垂直细节和对角线细节;其中,信号能量主要集中在低频部分,而高频部分是图像细节;再将四个子图像进行小波逆变换得到近似原图的小波重构图。

4. 如权利要求1或2所述的基于DWNN框架的心电信号的识别方法,其特征在于,心电信号在进入小波层时,小波变换可以采用任意的n层小波分解;

心电信号交替进入小波层和池化层,直到上一层池化后的数据尺寸不再可以进行小波分解为止;每增加一个小波层,重构的特征图的个数变为前一层的s倍,最后一个池化层生成特征图的个数为 $(p*q*\dots*s)$,其中, $p,q,\dots,s \geq 1$ 。

5. 如权利要求1所述的基于DWNN框架的心电信号的识别方法,其特征在于,所述的全连接层中含有m个神经元数,全连接层将小波构造的深层特征进行提纯和综合,然后交给输出层;

所述的输出层采用softmax函数进行分类识别,softmax函数将输入映射为0-1之间的实数,输出是每个分类被取到的概率。

6. 如权利要求1所述的基于DWNN框架的心电信号的识别方法,其特征在于,所述的DWNN框架模型的学习训练采用以下操作:

1) 前向传播:前向传播是输入的原始图像信号从小波层开始,最后到softmax层的变换,实现特征的自动提取和预分类;

2) 反向传播:用于调节各层的网络权值,并用下式的损失函数来度量,使得预测结果与实际结果误差最小;

$$L = - \sum_k t_k \log y_k$$

其中,y为softmax函数的输出,t为真实结果,k为分类的个数;t用one-hot表示:正确标

签的概率值为1,其余标签的概率值为0;

采用梯度下降法进行反向传播,在修正各层权值时,更新偏置系数、全连接层权重和小波重构特征图时的权重;

每迭代一次训练数据集,使用Loss值观察模型的分类效果,Loss值计算为:

$$\text{Loss} = \sum_{i=1}^x -\log P_i$$

式中, P_i 表示第*i*张图像通过分类模型后对应的分类概率。

7.如权利要求1所述的基于DWNN框架的心电信号的识别方法,其特征在于,所述的训练集采用MIT-BIH数据库中的五类标注心电图信号,包括为正常心搏、左束支传导阻滞心搏、右束支传导阻滞心搏、室性早搏和起搏心搏;每种类型分别选取840个心拍数据作为训练模型使用,160个测试数据作为评估模型使用。

8.如权利要求1所述的基于DWNN框架的心电信号的识别方法,其特征在于,输出层的输出分类包括正常搏动型、左束支传导阻滞型、右束支传导阻滞型、室性早搏型以及房性早搏型;选择概率值最大的类型作为DWNN框架模型对输入的心电信号作为分类识别结果。

一种基于DNN框架的心电信号的识别方法

技术领域

[0001] 本发明属于医疗器械技术领域,涉及心电信号的智能分类,特别涉及一种基于DNN框架的心电信号的分类与识别方法。

背景技术

[0002] 随着人工智能的迅速发展,图像分类在模式识别和机器学习中发挥着重要的作用。如何利用计算机自动提取图像特征和自动进行图像分类,已经发展成人工智能和计算机视觉领域的重要研究课题之一。图像分类是机器学习在商业、医学、技术、研究、金融等领域的众多应用之一。机器学习是人工智能领域的一个重要方向,随着机器学习中神经网络算法的深入研究,深度学习的网络算法也日益完善。深度学习方法的应用已经越来越普遍,如图像分类、目标检测、自然语言翻译、机器人控制等领域。其中,卷积神经网络(Convolutional Neural Networks, CNN)为图像分类领域带来巨大的提升与进步。

[0003] 小波变换在时域和频域内具有良好的局部化特性,自身具备多分辨率图像表示性能,被誉为信号分析的“数学显微镜”,是傅里叶分析发展史上里程碑式的发展。小波分析也在信号分析、语音合成、图像分类识别及信息压缩等领域受到越来越多学者的重视。

[0004] 如何从原始信号中自主地学习出深层特征已成为研究热点。结合小波变换和机器学习分类器的分类算法很多,张慧娜等提出Haar-CNN模型,该模型提取了LL一个分量作为小波变换提取的主要图像块,为后续的分类器提供特征,这虽提高了图像分类精确度,却忽略了原图像的其他三个细节分量。文献D.Gao, Y. Zhu, X. Wang, K. Yan and J. Hong, "A Fault Diagnosis Method of Rolling Bearing Based on Complex Morlet CWT and CNN," 2018 Prognostics and System Health Management Conference (PHM-Chongqing), Chongqing, 2018, pp. 1101-1105. 利用小波变换将信号分解为不同的时频域子图,全部处理后作为卷积神经网络的输入,通过训练集调整网络权值并验证权值实际准确度,最终得到分类准确率最高的卷积神经网络模型。T. Williams等将小波分解的四张子图,通过单独或多个组合的方式分别进入卷积神经网络,使用OR操作符组合所有结果,以获得最终分类; Jen-Tzung Chien等将小波分解的子特征图,送入最近邻分类器,取得不错的分类效果。卷积神经网络本身具有自主提取特征的优势, Jie Ren等使用CNN自动提取特征, SVM进行分类,有效地提高了无线网络通信中的资源配置管理;除此之外, L. Li等(L. Li, J. Wu and X. Jin, "CNN Denoising for Medical Image Based on Wavelet Domain," 2018 9th International Conference on Information Technology in Medicine and Education (ITME), Hangzhou, 2018, pp. 105-109.) 对小波分解后的子图,进行多层的卷积操作,最终通过小波逆变换得到去噪的原图; P. Liu等(P. Liu, H. Zhang, W. Lian and W. Zuo, "Multi-Level Wavelet Convolutional Neural Networks," in IEEE Access, vol. 7, pp. 74973-74985, 2019) 交替地使用离散小波分解和CNN提取特征,再通过交替的离散小波逆变换和CNN重构原图,所提出的MWCNN对于图像处理、JPEG伪影去除和目标分类等任务都是有效的。以上现有技术都是将小波变换提取好的特征图做不同的处理,后送入分类器进行学习,并

未实现小波与后续分类器的紧耦合。

发明内容

[0005] 本发明解决的技术问题在于提供一种基于DWNN框架的心电信号的识别方法,实现了小波分析与CNN框架的紧密结合的,以基于深度小波神经网络的框架进行二维心电图的识别。

[0006] 本发明是通过以下技术方案来实现:

[0007] 一种基于DWNN框架的心电信号的识别方法,包括以下操作:

[0008] 1) 构建包括深层特征构造模块、全连接层和输出层的DWNN框架模型,其中深层特征提取模块包括n个由小波层和池化层构成的子模块,心电信号交替进入小波层和池化层,小波层通过小波分解和随机加权重构提取出心电信号中的深层数据特征,池化层对提取到的深层数据特征进行池化降维,交替处理后得到小波构造的深层特征;全连接层将小波构造的深层特征综合后交给输出层;输出层采用softmax函数输出心电信号分类概率;

[0009] 2) 对构建的DWNN框架模型利用训练集,通过前向传播进行学习训练,并通过反向传播调节各层的网络权值和小波重构时的权重,用损失函数来度量,多轮迭代后使得预测结果与实际结果误差最小;

[0010] 3) 将心电信号输入训练好的DWNN框架模型,依次经过小波层、池化层、全连接层的处理,由输出层输出各分类结果的概率,并以概率值最大的类型作为心电信号分类识别的结果。

[0011] 所述的小波层采用二维离散小波变换对输入的心电信号进行分解,得到多个子图像;然后对子图像进行p次随机加权再进行小波逆变换,重构得到p张小波特征图,p是大于等于1的整数;

[0012] 所述的池化层是将重构的小波特征图进行降维操作,去除冗余信息。

[0013] 所述小波层在分解时将心电图图像分解成四个子图像:原图的近似值、水平细节、垂直细节和对角线细节;其中,信号能量主要集中在低频部分,而高频部分是图像细节;再将四个子图像进行小波逆变换得到近似原图的小波重构图。

[0014] 进一步的,心电信号在进入小波层时,小波变换可以采用任意的n层小波分解;

[0015] 心电信号交替进入小波层和池化层,直到上一层池化后的数据尺寸不再可以进行小波分解为止;每增加一个小波层,重构的特征图的个数变为前一层的s倍,最后一个池化层生成特征图的个数为 $(p*q*\dots*s)$,其中, $p, q, \dots, s \geq 1$ 。

[0016] 所述的全连接层中含有m个神经元数,全连接层将小波构造的深层特征进行提纯和综合,然后交给输出层;

[0017] 所述的输出层采用softmax函数进行分类识别,softmax函数将输入映射为0-1之间的实数,输出是每个分类被取到的概率。

[0018] 所述的DWNN框架模型的学习训练采用以下操作:

[0019] 1) 前向传播:前向传播是输入的原始图像信号从小波层开始,最后到softmax层的变换,实现特征的自动提取和预分类;

[0020] 2) 反向传播:用于调节各层的网络权值,并用下式的损失函数来度量,使得预测结果与实际结果误差最小;

$$[0021] \quad L = - \sum_k t_k \log y^k$$

[0022] 其中, y 为softmax函数的输出, t 为真实结果, k 为分类的个数; t 用one-hot表示: 正确标签的概率值为1, 其余标签的概率值为0;

[0023] 采用梯度下降法进行反向传播, 在修正各层权值时, 更新偏置系数、全连接层权重和小波重构特征图时的权重;

[0024] 每迭代一次训练数据集, 使用Loss值观察模型的分​​类效果, Loss值计算为:

$$[0025] \quad \text{Loss} = \sum_{i=1}^x -\log P_i$$

[0026] 式中, P_i 表示第 i 张图像通过分类模型后对应的分类概率。

[0027] 所述的训练集采用MIT-BIH数据库中的五类标注心电图信号, 包括为正常心搏、左束支传导阻滞心搏、右束支传导阻滞心搏、室性早搏和起搏心搏; 每种类型分别选取840个心拍数据作为训练模型使用, 160个测试数据作为评估模型使用。

[0028] 与现有技术相比, 本发明具有以下有益的技术效果:

[0029] 现有技术都是将小波变换提取好的特征图做不同的处理, 后送入分类器进行学习, 并未将小波变换融合到CNN的框架中, 也没有实现小波与后续分类器的紧耦合。为了改进图像分类中小波所提取特征与后续分类器的分离问题, 发掘小波变换提取深层特征的优势, 本发明提出基于DWNN框架的心电信号的识别方法, 利用小波变换替代CNN中提取特征的卷积层, 从而结合小波变换在信号多分辨分析上的优势, 以及卷积神经网络在模式分类领域的突出贡献以进行心电图识别和分类; DWNN结构允许图像多次交替进入小波层和池化层, 得到深层特征, 然后送入全连接层和softmax层, 得到最终分类结果。其中, 小波层利用小波分解与加权重构, 提取了深层特征, 同时利用反向传播, 实现了小波分析与CNN框架的紧密结合。

[0030] 通过本发明与CNN结构两种网络模型在心电图数据集上的对比, 本发明的网络模型在120次迭代后的LOSS值小于卷积神经网络, 测试集精确率高于卷积神经网络; 在800个测试心电信号中, 本发明总共有794个信号预测正确, 6个信号预测错误, 本发明的预测正确率为99.25%。作为对比, 在800个测试心电信号中, 现有CNN结构中总共有763个信号预测正确, 37个信号预测错误, 现有CNN预测正确率为95.38%; 结果表明本发明具有更为明显的分类识别结果。

附图说明

[0031] 图1为本发明DWNN的整体结构图, 图中输入数据尺寸以48*48为例。

[0032] 图2为本发明的整体流程图。

[0033] 图3为本发明的识别流程图。

[0034] 图4为包含一个卷积层的CNN结构图。

[0035] 图5为DWNN的结构图。

[0036] 图6为在MIT-BIH心电图数据集上, CNN与DWNN两种模型随迭代次数的Loss值变化情况。

具体实施方式

[0037] 下面结合实施例对本发明做进一步详细描述,所述是对本发明的解释而不是限定。

[0038] 参见图1-图3、图5,本发明提供的基于DWNN框架的心电信号的识别方法,包括以下操作:

[0039] 1) 构建包括深层特征构造模块、全连接层和输出层的DWNN框架模型,其中深层特征提取模块包括n个由小波层和池化层构成的子模块,心电信号交替进入小波层和池化层,小波层通过小波分解和随机加权重构提取出心电信号中的深层数据特征,池化层对提取到的深层数据特征进行池化降维,交替处理后得到小波构造的深层特征;全连接层将小波构造的深层特征综合后交给输出层;输出层采用softmax函数输出心电信号分类概率;

[0040] 2) 对构建的DWNN框架模型利用训练集,通过前向传播进行学习训练,并通过反向传播调节各层的网络权值和小波重构时的权重,用损失函数来度量,多轮迭代后使得预测结果与实际结果误差最小;

[0041] 3) 将心电信号输入训练好的DWNN框架模型,依次经过小波层、池化层、全连接层的处理,由输出层输出各分类结果的概率,并以概率值最大的类型作为心电信号分类识别的结果。

[0042] 进一步的,所述的小波层采用二维离散小波变换对输入的心电信号进行分解,得到多个子图像;然后对子图像进行p次随机加权再进行小波逆变换,重构得到p张小波特征图,p是大于等于1的整数;

[0043] 所述的池化层是将重构的小波特征图进行降维操作,去除冗余信息。

[0044] 具体的,所述小波层在分解时将心电图图像分解成四个子图像:原图的近似值、水平细节、垂直细节和对角线细节;其中,信号能量主要集中在低频部分,而高频部分是图像细节;再将四个子图像进行小波逆变换得到近似原图的小波重构图。

[0045] 具体的,心电信号在进入小波层时,小波变换可以采用任意的n层小波分解;

[0046] 心电信号交替进入小波层和池化层,直到上一层池化后的数据尺寸不再可以进行小波分解为止;每增加一个小波层,重构的特征图的个数变为前一层的s倍,最后一个池化层生成特征图的个数为 $(p*q*\dots*s)$,其中, $p, q, \dots, s \geq 1$ 。

[0047] 下面给出具体的实施例。

[0048] 一种基于DWNN框架的异常心电信号的识别方法,其特征就在于,包括以下操作:

[0049] 1) DWNN模型的构建

[0050] 1.1) 构建小波层;采用二维离散小波变换对心电图图像进行分解,得到分别包括信号能量、图像细节的多个子图像,然后将多个子图像进行小波逆变换,原本的小波逆变换中,子图像的权重都为1,本发明对子图像进行p次随机加权,然后进行小波逆变换,得到p张小波特征图,p是大于等于1的整数。

[0051] 所述对心电图图像分解成四个子图像:原图的近似值、水平细节、垂直细节和对角线细节;其中,信号能量主要集中在低频部分,而高频部分是图像细节。以一层小波分解为例,四张子图像包含一张低频图像和三张高频图像。

[0052] 1.2) 构建池化层,将重构的小波特征图进入池化层进行降维操作,以去除冗余信息;

[0053] 1.3) 一个小波层、池化层构成子模块, n个子模块组成深层特征深层特征构造模块, 这样心电信号可多次交替进入小波层和池化层, 从而获得小波构造的深层特征;

[0054] 在每个小波层中, 小波变换可以采用任意的n层小波分解; 小波层和池化层多次交替, 直到上一层池化后的数据尺寸不再可以进行小波分解为止;

[0055] 每增加一个小波层, 特征图的个数变为前一层的s倍, 最后一个池化层生成特征图的个数为 $(p*q*\dots*s)$, 其中, $p, q, \dots, s \geq 1$;

[0056] 1.4) 构建全连接层, 深层特征进入全连接层, 全连接层中含有m个神经元数, 全连接层将前面提取到的特征进行高度提纯, 交给最后的输出层。

[0057] 1.5) 构建输出层, 输出层采用softmax函数进行最终的分类预测, 对于多分类问题, softmax函数能将输入映射为0-1之间的实数, 即它的输出是每个分类被取到的概率。

[0058] 具体的, softmax函数将多个神经元的输出映射到(0, 1)区间, 通过softmax函数, 依次计算出属于每种类型疾病的概率, 这些概率总和为1, 将概率最大的类型作为该网络预测输出。

[0059] 2) DWNN模型的学习

[0060] 选用美国麻省理工学院提供的MIT-BIH数据库中的五类心电图信号进行训练。所选取的五种标注类型, 分别为正常心搏、左束支传导阻滞心搏、右束支传导阻滞心搏、室性早搏和起搏心搏, 每种类型分别选取840个心拍数据作为训练模型使用, 160个测试数据作为评估模型使用。具体的, 使用的MIT-BIH心电图数据集包含4200个训练图像, 800个测试图像。其中每个图像尺寸为48*48。利用所提出的DWNN训练模型, 记录训练过程中的Loss值, 并观察测试集上的精确率。

[0061] 2.1) 前向传播: 前向传播是输入的原始图像信号从小波层开始, 最后到softmax层的变换, 实现了特征的自动提取和预分类; 其中, 心电图作为原始数据进入小波层, 小波层通过小波分解和随机加权重构, 提取出心电图中的深层数据特征, 池化层对提取到的数据特征经过池化操作降维, 全连接层是将降维的数据特征综合起来, 输出层利用softmax函数输出分类结果及概率;

[0062] 2.2) 反向传播: 用于调节各层的网络权值, 以最小化损失函数, 使得预测结果与实际结果误差最小。

[0063] 机器学习模型中, 单个样本的预测值与真实值的差称为损失, 损失越小, 模型越好, 模型每一次预测的好坏用损失函数来度量。损失函数有很多, 具体采用交叉熵作为损失函数, 如式(1)所示:

$$[0064] \quad L = - \sum_k t_k \log y^k \quad (1)$$

[0065] 其中, y表示网络的预测输出, t表示真实结果, k表示数据的维数。本文中, y是softmax函数的输出, 即属于各个分类的概率值; t是用one-hot表示的, 即正确标签的概率值为1, 其余标签的概率值为0。k是实际分类的个数。

[0066] 反向传播调节网络参数, 最常使用的方法为梯度下降法。修正各层权值时, 除了更新偏置系数、全连接层权重等之外, 还需更新小波重构特征图时的权重, 实现小波与后续网络的紧耦合。经过多轮迭代得到优异的网络参数。

[0067] 具体的, 实现网络的前向传播后, 得到每一层每一个节点的输出值, 其次确定网络

的优化函数,在输出层计算出预测值和样本真实值的残差,并分别计算出其他各层各节点的残差,最后分别求出优化函数对于权值和偏置的偏导数,根据梯度下降法更新权值和偏置。更新小波层的重构权重时,其残差为池化层反向传播过来残差的对应小波分解值。

[0068] 利用梯度下降法,通过不断地迭代,训练出更利于分类的小波特征图,使输出值与目标值的误差最小。每迭代一次训练数据集,使用Loss值观察模型分类效果,Loss值计算如式(2)所示:

$$[0069] \quad \text{Loss} = \sum_{i=1}^x -\log P_i \quad (2)$$

[0070] 式(2)中, P_i 表示第*i*张图像通过分类模型后对应其label的分类概率,可以看出: P_i 越大,Loss值越小。随着迭代次数增加,每张图的分类准确率不断提高时,Loss值才会越来越小。这一评价指标说明了模型中不断更新的参数是否能让模型分类效果变得更好。

[0071] 模型训练完成之后,测试集上的分类准确率,一般用accuracy表示,它的值等于测试集上分类正确的个数除以总的测试集图片个数。这一评价指标表明了该模型的泛化能力。

[0072] 3) 对心电图的分类识别

[0073] 将训练好的网络模型作为未知心电信号自动识别的网络,将测试集的心电信号输入训练好的网络,依次经过小波层、池化层、全连接层的处理,由输出层的softmax函数输出各分类结果的概率,并以概率值最大的类型作为心电信号分类的结果。

[0074] 本发明提出的DWNN框架结构示意图如图5所示。其中,小波层先采用一层小波分解,得到四张包含不同分量信息的子图像;加权重构时, p 取20,即得到20张小波特征图; m 取50, k 根据MIT-BIH数据集选为5。这个结构经过一次小波分解、一次小波加权重构、一次平均池化,生成20张特征图,送入全连接层和softmax层,得到最终分类结果。经过120次迭代后,训练集的LOSS值为168.4。在800个测试心电信号中,总共有794个信号预测正确,6个信号预测错误,该模型的预测正确率为99.25%。

[0075] 对比较的CNN结构中,同样需要利用一次卷积层提取出20张特征图,然后进入平均池化,全连接层神经元个数为50,最终softmax层得到分类结果。对比较的CNN结构示意图如图4所示。卷积核的尺寸选为5*5,步长为1。经过120次迭代后,训练集的LOSS值为273.4。在800个测试心电信号中,总共有763个信号预测正确,37个信号预测错误,该模型的预测正确率为95.38%。

[0076] 两个模型中,收敛步长都选为0.0005,训练模型时数据集的迭代次数为120。对比较CNN与DWNN两个模型的Loss值和分类精确率,结果如表1所示,Loss值随迭代次数iter的变化情况如图6所示。首次迭代时,CNN具有较小的Loss值,经过120次迭代后,DWNN1模型的Loss值为168.4,而CNN模型的Loss值为273.4,很明显,DWNN1具有较小的Loss值;在两种模型分类精确率上,CNN的分类准确率为95.38%,DWNN1的分类准确率为99.25%,DWNN模型分类精确率明显高于CNN模型。

[0077] 表1 CNN与DWNN1两个模型的具体Loss值和分类精确率

[0078]

| 模型 | CNN | DWNN1 |
|-------------|--------|--------|
| Loss值(首次迭代) | 6736.7 | 6789.1 |

| | | |
|----------------|--------|--------|
| Loss值 (120次迭代) | 273.4 | 168.4 |
| accuary (测试集上) | 95.38% | 99.30% |

[0079] 所以,本发明提出的DWNN框架模型以小波分解和加权的小波重构替代了CNN中提取特征的卷积层,实现了小波与CNN框架的紧耦合,同样达到了学习深层特征,利于分类的效果。随着迭代次数的增加,Loss值降低的同时,图像分类的精确率上也得到了提升。

[0080] 通过两种网络模型在心电图数据集上的对比,本发明的网络模型在120次迭代后的LOSS值小于卷积神经网络,测试集精确率高于卷积神经网络,体现了本发明网络模型有较好的结果。

[0081] 以上给出的实施例是实现本发明较优的例子,本发明不限于上述实施例。本领域的技术人员根据本发明技术方案的技术特征所做出的任何非本质的添加、替换,均属于本发明的保护范围。

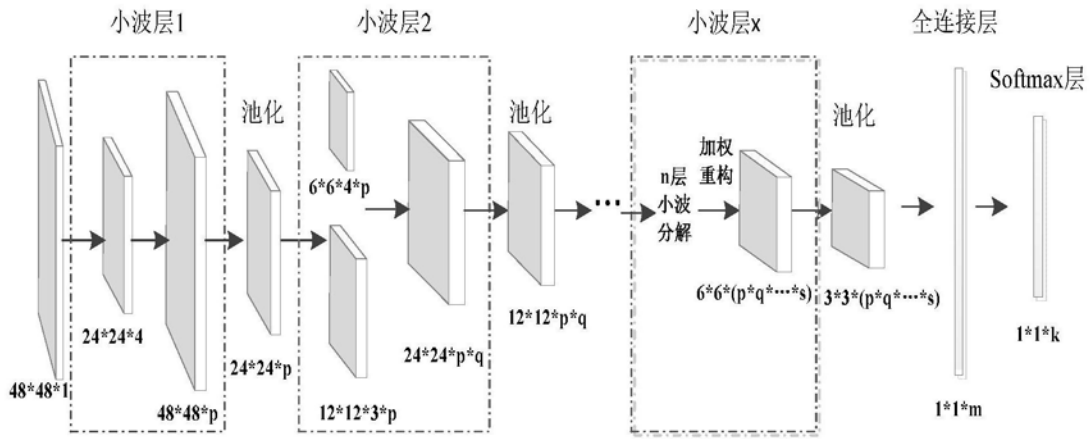


图1

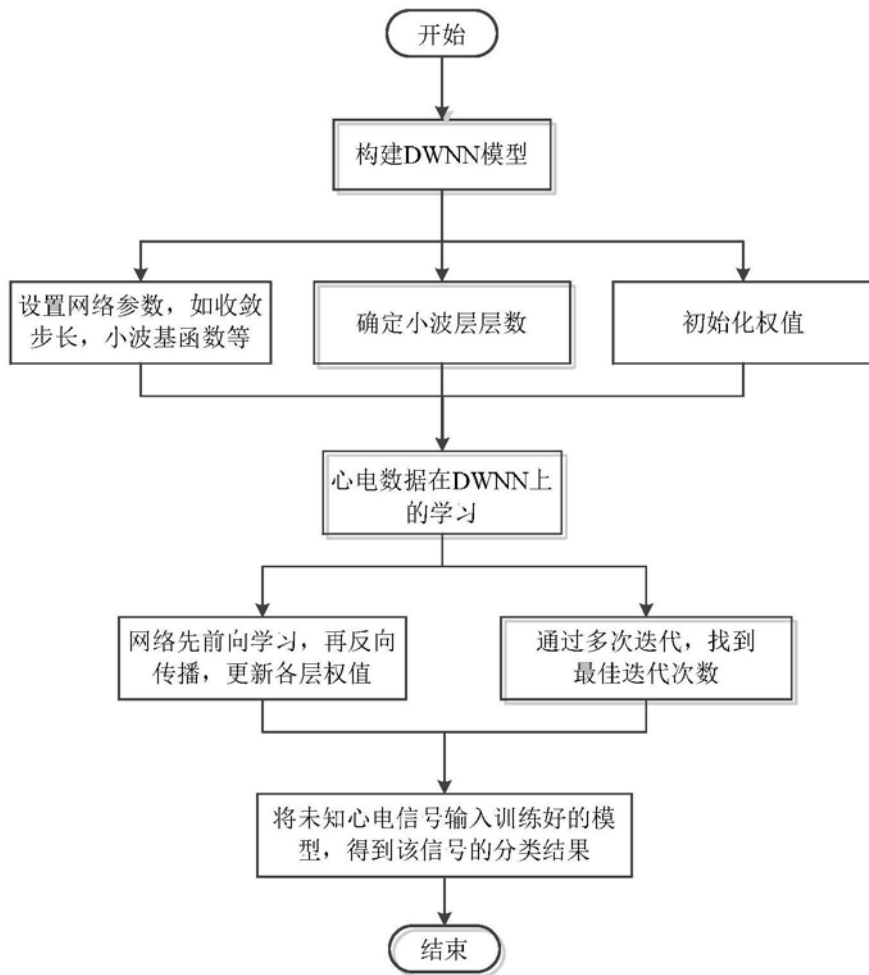


图2

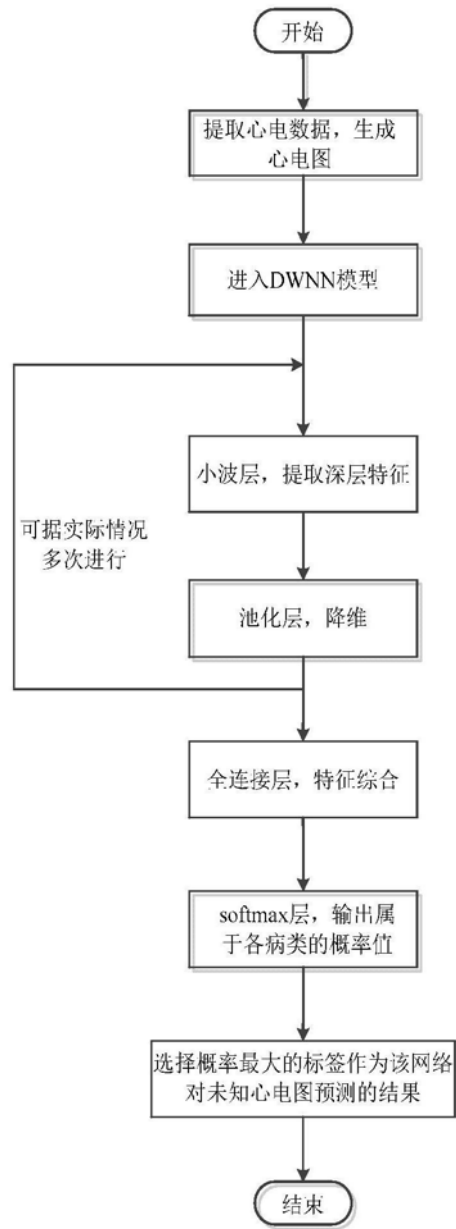


图3




图4

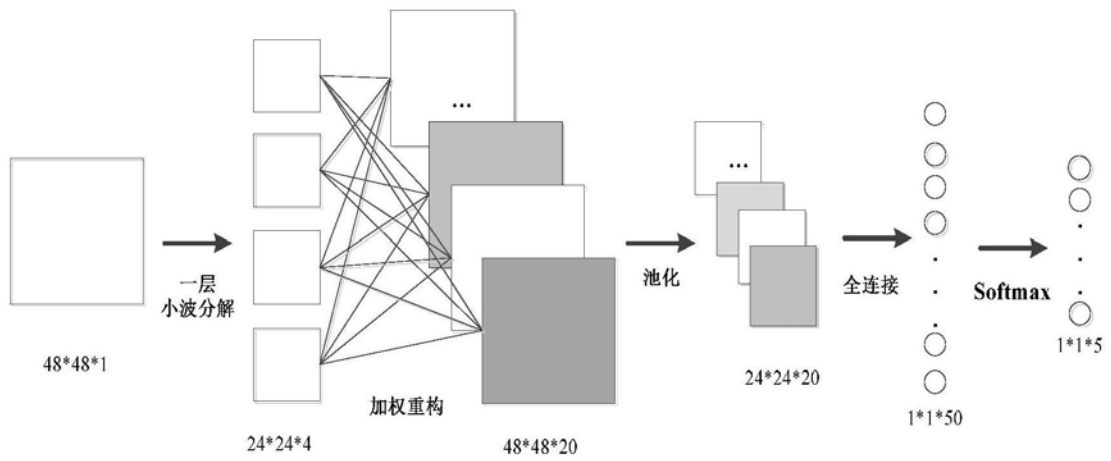


图5




图6

| | | | |
|----------------|--|---------|------------|
| 专利名称(译) | 一种基于DWNN框架的心电信号的识别方法 | | |
| 公开(公告)号 | CN110613445A | 公开(公告)日 | 2019-12-27 |
| 申请号 | CN201910913304.X | 申请日 | 2019-09-25 |
| [标]申请(专利权)人(译) | 西安邮电大学 | | |
| 申请(专利权)人(译) | 西安邮电大学 | | |
| 当前申请(专利权)人(译) | 西安邮电大学 | | |
| [标]发明人 | 包志强 邢瑜 王宇霆 张燕 | | |
| 发明人 | 包志强 邢瑜 王宇霆 张燕 | | |
| IPC分类号 | A61B5/0476 A61B5/00 | | |
| CPC分类号 | A61B5/0476 A61B5/7203 A61B5/7225 A61B5/7264 | | |
| 代理人(译) | 李英俊 | | |
| 外部链接 | Espacenet SIPO | | |

摘要(译)

本发明公开了一种基于DWNN框架的心电信号的识别方法，心电图作为原始数据进入小波层，小波层通过小波分解和随机加权重构，提取出心电图中的深层数据特征，池化层对提取到的数据特征经过池化操作降维，全连接层是将降维的数据特征综合起来，输出层利用softmax函数输出分类结果。在800个测试心电信号中，本发明总共有794个信号预测正确，6个信号预测错误，本发明的预测正确率为99.25%；结果表明本发明具有更为明显的分类识别结果。

