

# 一种基于降噪自动编码器和宽度学习的 增量式疾病预测模型

漆华妹, 胡宇轩, 袁正一  
(中南大学计算机学院, 湖南长沙 410075)

**摘要:** 疾病预测模型通过利用收集到的医疗数据,能够在患者疾病发作前准确地进行疾病预测。目前在疾病预测方面深受欢迎的深度神经网络,它依靠增加网络层数来提升模型的准确率,利用梯度下降来进行权重的更新,而这导致了模型梯度爆炸、训练速度慢等问题。一旦数据更新,深度神经网络需要重新训练,进而导致模型更新困难。宽度学习(Broad Learning System, BLS)无须梯度下降的特性与其可通过增量学习快速重构的优势为有效解决上述问题提供了技术方案,但是BLS无法提取到隐藏在医疗数据中深层次的特征,其在复杂的医疗环境下仍然表现不佳。针对该问题,本文提出一种基于降噪自动编码器(Denoising AutoEncoder, DAE)与宽度学习的增量式疾病预测模型——DAE-BLS。所提模型将DAE引入BLS的架构设计中,结合了DAE在混乱环境下的降噪能力与BLS的简洁快速的特点,既保证了高效的运算能力又增强了特征提取能力,因而更适用于复杂医疗环境。将DAE-BLS在包含不同格式以及不同数据量的糖尿病、心力衰竭、心电异常和乳腺癌数据集上进行模拟预测实验,实验结果表明,DAE-BLS能够在保留宽度结构的神经网络快速高效特点的同时,在不同格式的数据上表现出很好的性能,分别达到96.62%, 94.53%, 98.50%与83.64%的准确率,并能在需要更改模型结构时通过增量学习技术快速重构以适应用户不断变化的疾病数据。

**关键词:** 神经网络;自动编码器;疾病预测;宽度学习;增量学习;智慧医疗

**中图分类号:** TP183

**文献标识码:** A

**文章编号:** 0372-2112(2023)06-1474-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20211320

## An Incremental Disease Prediction Model Based on Denoising Autoencoder with Broad Learning System

QI Hua-mei, HU Yu-xuan, YUAN Zheng-yi

(School of Computer Science and Engineering, Central South University, Changsha, Hunan 410075, China)

**Abstract:** Disease prediction models use collected medical data to accurately predict a patient's disease before its onset. At present, deep neural network, which is popular in disease prediction, relies on increasing the number of network layers to improve the accuracy of the model, and uses gradient descent to update the weight, which leads to problems such as model gradient explosion and slow training speed. At the same time, once the data is updated, the deep neural network needs to be retrained, which makes it difficult to update the model. Broad learning system (BLS), which does not need gradient descent and has the advantage of rapid reconstruction through incremental Learning, provides a technical solution to solve the above problems effectively. However, BLS cannot extract the deep features hidden in medical data, and still performs poor in complex medical environment. To solve this problem, we propose an incremental disease prediction model based on denoising autoencoder (DAE) and BLS, called DAE-BLS. In the proposed model, DAE is introduced into the architecture design of BLS. The model combines the denoising ability of DAE in chaotic environment with the simplicity and speed of BLS, which not only ensures the efficient computing capability of the model but also enhances the feature extraction capability of the model, making it more suitable for complex medical environment. Applying DAE-BLS to prediction experiments on diabetes, heart failure, ECG abnormalities and breast cancer datasets with different formats and data volumes, experimental results show that DAE-BLS can retain the fast and efficient characteristics of BLS, and show good performance in different data formats, reaching 96.62%, 94.53%, 98.50% and 83.64% accuracy respectively, and can be rapid-

ly reconstructed to adapt to users' changing disease data through incremental learning techniques when the model structure needs to be changed.

**Key words:** neural network; auto-encoder; disease predictions; broad learning system; incremental learning; smart healthcare

## 1 引言

目前我国社会已经开始进入老龄化阶段,预计到2025年,60岁以上的人口将会突破3亿人,中国也将成为超老年型国家<sup>[1]</sup>。老龄化趋势明显,患有慢性病的人群也逐渐增长。老年患者和慢性病患者需要进行长时间的察看与医治,而这类人群通常只能按期到医院复查诊治,对病人的治疗效果不佳,除浪费人力、财力之外,对病人的生理和心理也都造成了很大的影响。因此对相关疾病进行早期预测对患者来说是相当重要的。

近年来,随着物联网技术的快速发展,医疗保健领域也出现了相关的应用,如患者身份识别、疾病诊断和

云数据存储<sup>[2,3]</sup>、生理信号检测<sup>[4,5]</sup>等。而结合了这些应用的远程社区医院的建立<sup>[6]</sup>能够将同一个区域内的医疗资源整合在一起,建立一个整体性的医疗资源库,很大程度上缓解了医疗资源不足的压力。远程社区医院以专家团队为中心,以社区内各个治疗点共享的电子病历为基础,帮助基层社区患者解决问题。该种模式大大加强了社区成员与社区医院的联系,打破了以往看病时间和地点的限制。而如何利用社区医院内的医疗数据进行快速、准确的疾病预测,是一个需要解决的问题。

结合了人体传感器的远程社区医院的疾病预测的结构可分为以下不同的层次,如图1所示。

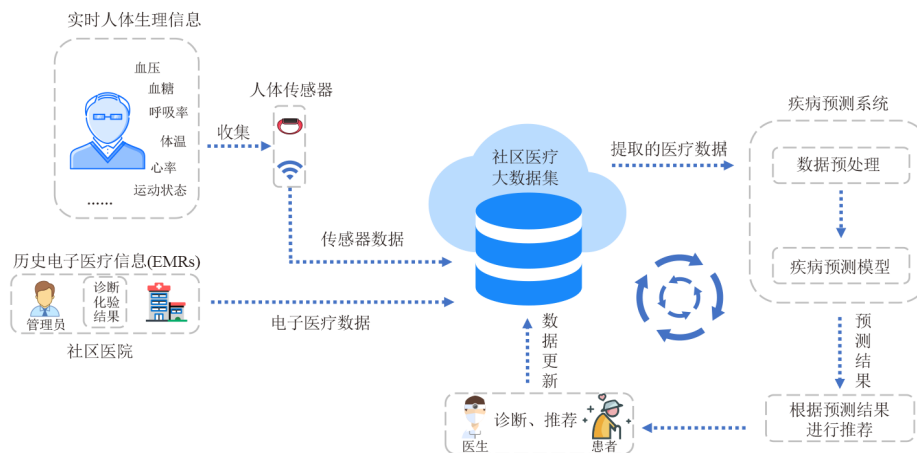


图1 远程社区医院的疾病预测场景

在该场景下,系统利用智能手环作为可穿戴传感器收集患者的生理信息,同时结合社区医院中存储的历史电子医疗记录,构建一个社区医疗大数据集,然后将数据集中与所要预测的疾病相关数据输入疾病预测系统中得到预测结果。预测系统中首先要对相关数据进行预处理,并从中提取出有价值的特征。但是从医疗数据中提取有价值的特征是相当困难的,这是由于很多收集到的医疗数据会受到大量异常数据的影响(比如缺失值、噪声等),而这些都会导致预测模型性能下降。除此之外,数据规模也会随着每天的医疗检查不断增加。因此设计预测模型应当注重如何解决这些问题。

目前疾病预测领域大多数算法模型以神经网络为主。Poplin等人<sup>[7]</sup>通过深度学习预测视网膜中的心血管危险因素。Rajendra等人<sup>[8]</sup>设计了一个卷积神经网络通过ECG信号自动检测心肌梗。Tuli等人<sup>[9]</sup>提出一种名

叫Healthfog的基于深度神经网络的心脏病检测框架。这些基于深度结构的神经网络为了获得更好的准确率,往往是使用更多的参数与更深的网络结构,大多数网络的训练过程非常耗时并且硬件要求高,这也使得从理论上分析深层结构非常困难。除此之外,深度神经网络的另一个挑战是被称为“灾难性遗忘”<sup>[10]</sup>的问题,即当定义神经网络的结构时,必须确认隐藏层的数量、神经元的数量、次数和学习速率等这些固定的参数,且之后这些参数不会再更改,除非重新设计网络模型并重新训练,这意味着每当新的检测数据产生时,都需要使用全部数据重新训练。

为了克服目前深度学习存在的这些问题,Chen等人<sup>[11]</sup>提出了宽度学习系统(Broad Learning System, BLS)。BLS模型因结构简单,运算速度快,逐渐被应用到图像分类<sup>[12]</sup>、时间序列预测<sup>[13]</sup>等领域中。BLS与神经网络的结构有很大不同。相比“深度”结构,BLS更

倾向于将网络向“宽度”的方向构造,由于没有多层连接,宽度网络不需要利用梯度下降来更新权值,所以训练非常快速。最重要的是,BLS的网络结构不是固定的,而是随着学习不断改变的。因此当数据产生变化时,BLS非常适用于使用增量学习方法<sup>[11]</sup>来快速实现模型的重建。增量学习思想<sup>[14]</sup>可以描述为:每当新增数据时,不需要重建所有的知识库,而是在原有知识库的基础上,仅对由于新增数据所引起的变化进行更新。但原始BLS中输入层与映射层的权重是随机生成的。对于不同的学习任务,权重的生成完全独立于样本,这种赋值方式缺少可解释性,不适用于越来越复杂且高维的医疗数据的预测。如何从混乱高维的医疗数据中提取出具有鲁棒性的特征是构建预测模型需要解决的难题。针对这一问题,研究者们选择训练自动编码器进行特征提取<sup>[15]</sup>。而降噪自动编码器<sup>[16]</sup>的提出旨在从破损版本的原始数据中提取出足以重构原始数据的特征,因此也就具有很强的鲁棒性,更适用于混乱环境。

针对目前疾病预测模型训练耗时、更新困难及BLS不适应复杂数据环境的问题,本文提出一种基于降噪自动编码器与宽度学习(DAE-BLS)的增量式预测模型。该模型适用于复杂数据环境,使用降噪自动编码器作为BLS的映射层进行特征提取,能够在保证原始BLS的高效率的同时提高精确度,也能利用增量学习进行快速重构保证其实时性能。

## 2 相关工作

疾病预测是指通过利用采集到的医疗数据,如患者的社会和经济状况、临床信息及生理信号等信息,构建一个算法模型,以确定患者未来是否会发作疾病。但由于医疗数据本身存在的复杂性,因此首先如何从混乱复杂的数据中提取具有较强鲁棒性的特征是一个值得研究的方向。许多研究者都考虑使用无监督的算法进行特征提取,在这一个方面,自动编码器被进行了非常广泛的研究。

### 2.1 基于自动编码器的特征提取

自动编码器是一种常用于进行特征提取的无监督机器学习算法,由三层的神经网络组成:输入层、隐藏层(编码层)和解码层。该网络的目的是重构输入,使其隐藏层学习到原始输入的鲁棒特征。最早来自Rumelhart等人<sup>[17]</sup>发表的论文,随后Bourlard等人<sup>[18]</sup>对其进行了详细的阐述。自动编码器最典型的改进算法是堆叠自动编码器<sup>[19-21]</sup>,它是一个浅层自动编码器模型的堆叠,首先通过对输入数据进行编码,然后重建它来学习输入数据的特征。随后,为了从复杂的图像数据中提取特征,Masci等人<sup>[22]</sup>提出了一种被称为卷积自动编码器的深度网络,研究者将卷积层与池化层引入自动编

码器的结构,它直接将图像数据作为输入,对自动编码器进行卷积训练,在图像数据中取得了更好的效果。

Vincent等人<sup>[16]</sup>认为一个好的特征提取应该能够捕获输入信号的稳定结构,具有一定的鲁棒性,因此提出了降噪自动编码器(Denoising Autoencoder, DAE)。而DAE与传统自动编码器最大的区别就是,DAE通过向原始输入中注入噪声,然后利用含噪声的损坏版本的样本去重构不含噪声的原始版本的输入。因此通过这种训练策略也使得DAE学习到的特征更能反映原始输入数据的特点,尤其适用于数据混乱的环境。

在特征提取后,需要建立合适的算法模型来进行疾病预测。在医学领域,目前已有许多通过深度神经网络来预测或评价疾病的方法被提出,但由于医疗数据的复杂性,在这一过程中仍面临许多挑战。

### 2.2 基于深度神经网络的预测模型

Liu等人<sup>[23]</sup>设计了一种用于疾病风险预测的双向循环神经网络模型,分别选择三种发病率较高的慢性病进行单个疾病风险预测。Jin等人<sup>[24]</sup>在疾病风险预测模型设计中引入多模态学习策略,即对异构医学数据采用多模态学习并融合学习到的特征,并用于疾病风险预测。而在文献[25]中,研究人员将支持向量机和深度信念网络有机地结合在一起,设计了一个混合疾病风险预测模型。Hannun等人<sup>[26]</sup>设计了一种深层卷积神经网络模型来进行动态心电图心律失常检测和分类,并取得了心电专家级别的预测结果。

虽然目前深度学习在疾病预测方面的研究在精度上达到了令人满意的结果,但是深层结构的神经网络往往是依靠增加网络层数来提升模型的精准度,利用逐层梯度下降来进行权重的更新,这导致了模型训练速度慢、梯度爆炸等问题<sup>[27]</sup>,也就使得目前的神经网络模型训练需要昂贵的硬件与漫长的训练时间。另外,每当数据产生变化时,深度神经网络需要重新进行训练,效率极低。

### 2.3 宽度学习系统

针对以上提到的深度学习中存在的问题,Chen等人<sup>[11,27]</sup>提出了宽度学习系统BLS,模型先将原始输入通过映射节点学习稀疏的映射特征,然后经由增强节点非线性扩展得到增强特征,并联两种特征表达作为最后的总输入送到输出层进行识别,对训练数据达到高度拟合。宽度结构的神经网络由于没有层与层之间的耦合,网络结构十分简洁。同样,由于没有多层连接,BLS亦不需要利用梯度下降来更新权值,所以计算速度大大优于深度学习。Chen等人<sup>[11]</sup>借用矩阵伪逆的运算理论<sup>[28]</sup>,推导出在数据更新时如何快速得到新的权重,从而将增量学习引入BLS。因此,比起深度神经网络,宽度学习还可以使用增量学习的方法动态的扩充网络

结构。

但是原始 BLS 在复杂环境上表现不够好,因此许多研究选择结合其他的算法提高原始 BLS 的特征学习能力,从而被广泛运用于许多领域。在图像分类领域<sup>[11]</sup>,BLS 展现出比 CNN 更高的准确率并且只需要比 CNN 短得多的训练时间。而 Liu 等人<sup>[29]</sup>提出先用 K-means 对图像进行特征提取,再将提取出的特征输入传统 BLS 进行分类,达到了比传统 BLS 更好的效果。在回归领域,许多研究者也针对 BLS 提出了一些改进。比如针对一些概率分布不确定的回归任务,Jim 等人<sup>[30]</sup>提出了一种具有鲁棒性的 BLS,用来减少数据中噪声对模型的影响。Zhou 等人<sup>[31]</sup>由于原始 BLS 的层次较浅,其特征学习能力不够强,因此在原始 BLS 隐藏层上再增加 1~3 个隐藏层对提取的特征进行再学习。此外,宽度学习在控制领域<sup>[32]</sup>、地理探测领域<sup>[33]</sup>和船舶调度领域<sup>[34]</sup>等都有所应用。

从现有的研究来看,对疾病预测模型的研究已经出现了很多优秀的成果,但是仍然存在着几个方面的问题:

(1) 尽管深度神经网络已经取得了相当高的预测精度,但是深度神经网络的训练方法导致其训练困难,往往需要漫长的训练时间。同时,实际情况中的医疗数据是在不断膨胀的,而现有的预测模型无法保存以往的训练得到的知识,需要在数据更新时利用全部数据重新进行训练。

(2) BLS 模型训练速度很快,并且能通过增量学习快速重构模型,但是其原始结构的特征学习能力不强,不适用于复杂的数据环境。

为解决上述问题,本文提出一种基于降噪自动编码器与宽度学习(DAE-BLS)的预测模型,接下来,详细阐述其构建过程。

### 3 基于降噪自动编码器与宽度学习(DAE-BLS)的预测模型

这一节将给出本文所提模型的具体实现过程,模型结构如图 2 所示。本文模型大致可分为两个模块:预处理模块和 DAE-BLS 模块。模型使用通过可穿戴医疗设备及电子医疗病历所收集到的数据作为输入,在经过预处理模块后,DAE-BLS 模型利用患者的数据高效地预测患者未来患病的可能性,同时利用新产生的数据增量更新模型参数以提高模型适应性。该模型的优点是简单、高效且对混乱环境有着较强的适应性,因此可以及时利用模型预测的结果从而做出有效决策。

#### 3.1 数据预处理

实际采集的医疗数据因存在噪声,且具有不完整性和不一致性,往往不能直接用于预测任务,因此,需

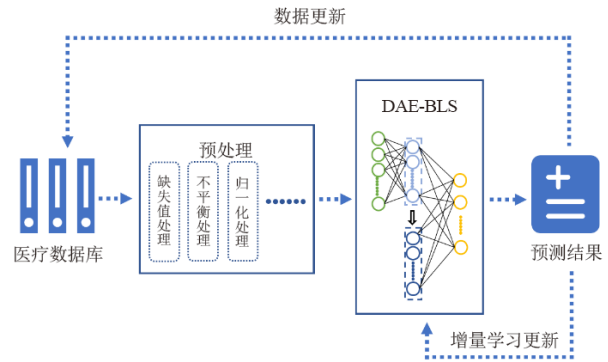


图 2 疾病预测模型结构

要在进行分析之前进行数据预处理步骤,以提取有效的数据特征。数据预处理包括缺失值处理、数据标准化处理、数据不平衡处理等。预处理流程如算法 1 所示。

#### 算法 1 预处理流程

```

输入: 数据输入  $X = \{x_1, x_2, \dots, x_n\}$ 
输出: 预处理后的数据  $Z$ 
FOR IN  $X$  //从输入中取出每一条数据
  IF  $x'$  无效 THEN
    Delete  $x'$  //删除重复无效的数据
END FOR
FOR  $x$  IN  $X$  //从输入中取出每一个特征
  IF  $x$  缺失值过多 THEN
    Delete  $x$  //删除缺失值过多的特征
  IF  $x$  使用 ICD-9 编码 THEN
     $x = \text{ICD-9}(x)$  //ICD-9 编码转换
  IF  $x$  是预测标签 THEN
     $x = \text{转换}(x)$  //预测标签转换
  IF  $x$  存在缺失值 THEN
     $x = \text{KNN}(x)$  //使用 KNN 算法进行缺失值填补
  IF  $x$  是标签数据 THEN
     $x = \text{One-Hot Encoding}(x)$  //标签数据用独热编码处理
END FOR
 $X = \text{SMOTE}(X)$  //使用 SMOTE 算法处理数据不平衡
 $Z = \text{Z-score}(X)$  //使用 Z-score 归一化处理

```

在采集的医疗数据中,缺失值产生的原因有很多,如病人为了保护个人隐私、护士操作失误和病人体检不完全等。直接使用缺失数据进行分类时,会对准确率造成影响。因此针对数据缺失问题,本文使用更具有解释性的 k-近邻(k-Nearest Neighbor, KNN)<sup>[35]</sup>算法用于缺失值的填补。该算法利用与缺失值样本在特征空间中的  $k$  个最相邻的样本进行填补。

医疗数据中不同评价指标往往具有不同的量纲和单位,这会影响到数据分析的结果。为消除指标之间的量纲影响,同时考虑到逐日增加的医疗数据对参数定

义的影响,本文选择使用 Z-score 标准化方法进行归一化处理.该方法给予原始数据的均值和标准差进行数据的标准化,这样经过处理的数据符合标准正态分布,即均值为0,标准差为1,转化函数为

$$X^* = \frac{x - \mu}{\sigma} \quad (1)$$

其中,  $\mu$  为所有样本数据的均值,  $\sigma$  为所有样本.

疾病类数据是明显的不平衡数据,患病类别的数量远远少于正常类别的数量,为解决数据不平衡的问题,本文使用 SMOTE 算法<sup>[36]</sup>进行预处理.该算法与基于简单复制少数类样本的过采样技术不同,它将已有的少数类样本经过线性插值合成新的少数类样本.

### 3.2 DAE-BLS 模型

#### (1) 模型结构

DAE 是自动编码器的一个有效变体,它的主要思想是:先对原始输入数据手动添加随机噪声,使其变成损坏版本;再训练自动编码器,使其可以从损坏版本的数据重构原始输入. DAE 结构如图 3 所示.

图 3 中, D 是指往原始输入  $X$  中增加随机噪声使其变成损坏版本  $\hat{X}$ , 随即令  $T = f(\theta\hat{X} + \beta)$ . 其中,  $\theta$  是一个待学习的映射矩阵,  $\beta$  是一个偏差向量, 得到的  $T$  就是编码后得到的隐藏层, 也就是希望提取到的原始数据的

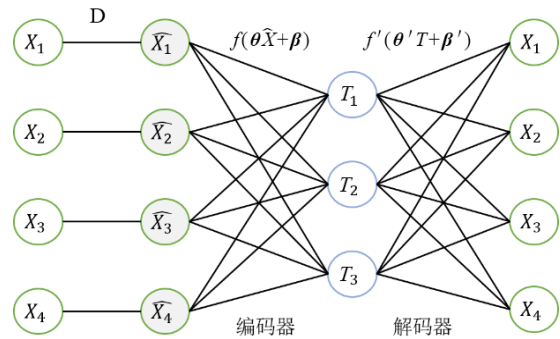


图3 DAE结构

特征. 而解码器部分就是依靠特征表示  $T$  去重构回原始数据  $X$ , 通过最小化构造误差优化自编码器的参数. 从噪声污染后的样本中提取到的特征更能表示原始输入的本质, 并且更适应噪声较大的环境.

BLS 简单高效, 但是其是直接使用原始数据进行简单的处理后输入系统中, 无法从复杂的、噪声较大的医疗数据中提取足够的特征, 导致预测模型准确率不高. 针对医疗数据复杂混乱的环境, 为了提升 BLS 的特征提取能力, 本文将 DAE 引入到 BLS 的架构设计中, 从而提出了 DAE-BLS 模型, 其结构如图 4 所示. DAE-BLS 模型结合了 DAE 与 BLS 的特点, 既保证了模型的高效运算能力, 又增强了模型的特征提取能力.

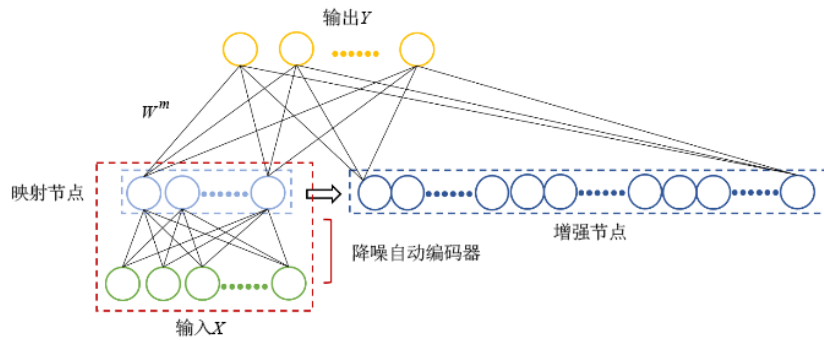


图4 DAE-BLS模型结构

#### (2) 模型的复杂性分析

大多数深度神经网络的训练包括两个阶段: 前向传播与反向传播. 前向传播是从输入层到输出层, 逐层计算每个神经元的输出. 反向传播是从输出层到输入层, 通过损失函数逐层更新神经元的权重. 其中各神经元的权重是通过逐层求梯度的方法更新的, 因此当网络层数较多时, 深度神经网络很容易陷入局部最优、梯度消失或梯度爆炸、收敛速度慢等的问题.

在不使用增量学习的情况下, DAE-BLS 模型训练过程与大多数神经网络相同, 制定好样本数以及网络参数进行训练. 其中, 如图 4 所示, 模型的隐藏层包含两部分: 映射节点和增强节点.

DAE-BLS 模型使用 DAE 提取到的特征  $T^n$  作为映射层,  $T^n = [T_1, T_2, \dots, T_n]$ . 随后将映射层得到的特征输入模型中的增强层部分, 使用  $H_j$  表示增强层中的第  $j$  组增强节点, 则有

$$H_j = \zeta_j(T^n W_{hj} + \beta_{hj}), j = 1, 2, \dots, m \quad (2)$$

其中,  $\zeta_j$  是非线性激活函数;  $W_{hj}$  和  $\beta_{hj}$  分别是随机权重和偏置. 随后, 将  $m$  组增强节点拼接为  $H^m = [H_1 \cdot H_2, \dots, H_m]$ . 最后将增强层的输出与映射层的输出拼接起来, 记为  $A = [T^n | H^m]$ , 模型最终输出为

$$Y = AW^m \quad (3)$$

其中,  $W^m$  为隐藏层到输出层的权重. 由于上文中提到

增强层中的  $W_{hj}$  和  $\beta_{hj}$  是随机产生的,并在训练过程中保持不变,作为映射层的 DAE 的参数也保持不变,因此整个网络需要学习的权重只有  $W^m$ ,而  $W^m$  可以通过岭回归快速计算出来.对于普通的神经网络,利用一个一个的样本使用梯度下降来逐步更新权重.而对于宽度学习系统来说,没有权重更新过程,而是一步直接计算出权重.

相较于含有多个隐藏层的深度神经网络,DAE-BLS 模型结构简单,需要更新的参数少,权重求解方便.而相较于原始的 BLS 模型,模型因为在映射层中引入了 DAE 结构,从而拥有更强的特征提取能力.除此之外,相比起其他的深度神经网络模型,在训练过程中本文所提模型结构也是动态的,可以通过增量学习高效地更新,进一步提升了模型的训练效率.

### (3) 模型的增量学习方法

普通的神经网络在训练的过程中,网络结构往往是固定不可变的,因此许多模型都是通过不断修改网络结构然后重复训练来达到提高精度的目的.而动态的增量学习算法可以利用好已经训练好的模型动态地进行模型结构的扩充,为模型的权值更新提供了一种高效便捷的方法.

如果模型经过训练后不能达到预期的精度,常用的解决方案是插入额外的增强节点以获得更好的性能.而为了保证模型的性能,本文在基于 BLS 增量学习算法<sup>[11]</sup>的基础上使用适用于 DAE-BLS 的增量学习算法,过程如下.

Step 1: 保证模型结构不变,令增强节点增加后,新的隐藏层变为

$$A^{m+1} = \left[ A \mid \xi(T^n W_{m+1} + \beta_{m+1}) \right] \quad (4)$$

其中,  $\xi$  为激活函数;  $W_{m+1}$  和  $\beta_{m+1}$  分别为增强层新的随机权重与随机偏置.

Step 2: 计算  $A^{m+1}$  的伪逆矩阵,即

$$(A^{m+1})^+ = \begin{bmatrix} A^+ - DB^T \\ B^T \end{bmatrix} \quad (5)$$

其中,

$$B^T = \begin{cases} C^+, & C \neq 0 \\ (1 + D^T D)^{-1} B^T A^+, & C = 0 \end{cases},$$

$$C = \xi(T^n W_{m+1} + \beta_{m+1}) - AD,$$

$$D = A^+ \xi(T^n W_{m+1} + \beta_{m+1}).$$

Step 3: 更新输出权重  $W^{m+1}$  为

$$W^{m+1} = \begin{bmatrix} W^m - DB^T Y \\ B^T Y \end{bmatrix} \quad (6)$$

该方法只需要在原来隐藏层的基础上计算新增增强节点的伪逆,而不需要对整个  $A^{m+1}$  进行计算,从而大大减少了更新时间,使得输出权值的动态更新成

为了可能.

综上所述, DAE-BLS 模型的训练步骤如算法 2 所示.

#### 算法 2 DAE-BLS 训练步骤

```

数据输入  $X = \{x^1, x^2, \dots, x^n\}$ , 实际预测结果 P
TRAINING DAE() //初始化并训练 DAE
INITIALIZE PARAMETER //初始化模型参数
T=DAE(X) //使用 DAE 提取输入特征作为映射层
H=ENHANCEMENT(T) //将映射层输入增强层
A=[TH] //将增强层和映射层拼接为隐藏层
Y=AW //计算最终输出
E=Y-P //计算最终输出与实际结果
WHILE(E<EXPECTATION) //如果实际误差小于期望值则训练结束
  ADD ENHANCEMENT NODES //增加增强节点
  A'=[A|N] //更新隐藏层
  (A')^+=PI(A') //计算伪逆
  W'=UNPATE((A')^+) //更新输出权重
  Y'=A'W' //计算最终输出
  E=Y'-P //计算最终输出与实际结果
END WHILE
END

```

## 4 实验及分析

### 4.1 实验环境

本文在不同格式不同数据量的数据集上进行了多次模拟实验以验证所提出模型的性能,本次实验以 Python 语言与 Tensorflow 和 PyWavelets 等框架为基础,硬件条件为 NVIDIA GeForce RTX 2070 SUPER 的 GPU, AMD Ryzen 536006-Core Processor 3.60 GHz 的 CPU, 16GB 内存.

### 4.2 结构化数据

#### 4.2.1 实验数据集介绍

本文使用 Diabetes 130-US hospitals 糖尿病数据集<sup>[37]</sup>进行仿真实验.糖尿病数据集收集了美国 130 家医院和 IDNs 的 10 年(1999—2008 年)临床护理信息.数据集内一共包含 101 766 例病例与医院收集到的患者的 50 多个特征,包括患者人数、种族、性别、年龄、入院类型、住院时间、入院医师的医学专科、实验室检测次数、HbA1c 检测结果、诊断、用药数、糖尿病用药数、住院前一年的急诊次数等.本文利用所构建的模型对患者再入院情况进行一个预测.数据集中再入院标签分为三类:30 天内再入院、30 天后再入院与不再入院.

另一个数据集是心力衰竭住院患者的数据集<sup>[38]</sup>,该数据集使用从 2016 年至 2019 年在中国四川一家医院住院的患者收集的电子健康数据,包括 2 008 名心力衰竭患者的 168 个变量.虽然西方国家已经建立了几个心力衰竭数据集,但由中国提供的数据却很匮乏.大

部分的实验都是基于西方国家收集的心力衰竭数据库,但中国与其他国家在患者群体和医疗体系上存在明显差异,因此该数据集更能适用于中国的医疗体系.该数据中存在多个预测标签,取28天内死亡与28天内再入院作为预测标签.

#### 4.2.2 预处理过程

(1)删除重复无效的数据.两个数据集中都包含了一些患者的多次住院访问,实验只保留了患者的第一次住院记录,除此之外数据集中还包括一些已经死亡或者濒临死亡的人,因为他们不会再重新入院,因此这些记录也被删除.

(2)删除缺失值过多的特征.糖尿病数据集中“weight”“payer\_code”“medical\_specialty”这三个属性由于缺失值过多而被删除,而“encounter\_id”与“patient\_nbr”由于是对实验无意义的信息也被删除.而心力衰竭数据集中有很多缺失值过多的特征,删除掉了其中缺失值超过80%的特征.

(3)icd-9 编码转换.糖尿病数据集中“diag\_1”“diag\_2”与“diag\_3”通过 icd-9 编码将其转换为对应的九个类.

(4)预测标签转换.糖尿病数据集中的“readmitted”属性的“>30”和“NO”归为同一类,因为只预测30天内是否重新入院.而心力衰竭数据集内存在多个预测标签,而这次实验只保留“death.within.28.days”和“re.admission.within.28.days”两个预测标签,删去其他的预测标签.接着将目标两个特征合并成一个特征即“28天内死亡或者再入院”作为最终的预测目标.

(5)对两个数据集中仍然存在的缺失值使用KNN算法进行填补.

(6)对所有的标签数据进行独热编码处理.

(7)处理过后的数据仍然存在数据不平衡的情况,例如糖尿病数据集中30天内未重新入院的人数远远大于重新入院的人数,因此我们应用SMOTE算法<sup>[36]</sup>对其进行处理.

(8)由于不同特征之间存在着不同的量纲和量纲单位,这样的情况会影响到数据分析的结果,为了消除指标之间的量纲影响,使用Z-score归一化处理消除了特征量纲的影响

(9)Holdout 检验是最普遍使用的方法,它一次性将所有数据划分为训练集与测试集,一般采取的方式有70%训练集/30%测试集或者是60%训练集/40%测试集.本次实验将最后得到的数据集的70%作为训练集,30%作为测试集.同时为了预防划分测试集与训练集的随机性影响实验结果,在划分的过程中保证训练集与测试集中预测标签的比例与总体数据集中的比例一致.

#### 4.2.3 实验结果

##### (1)心力衰竭再入院预测

在经过以上预处理后,得到包含2516条172维的医疗数据的心力衰竭数据集,注意到该数据集数据量相对较少,在该数据集上进行多种算法实验比较,结果如表1所示.结果对比如图5所示.

表1 心力衰竭预测实验结果

方法	训练集 准确率/%	测试集 准确率/%	训练时间/s
逻辑回归	86.25	82.64	0.06
随机树	97.72	91.12	0.13
深度神经网络(DNN)	99.05	94.64	13.51
卷积神经网络(CNN)	99.54	96.42	6.96
宽度神经网络(BLS)	99.17	96.83	0.12
DAE-BLS	99.25	96.62	1.25

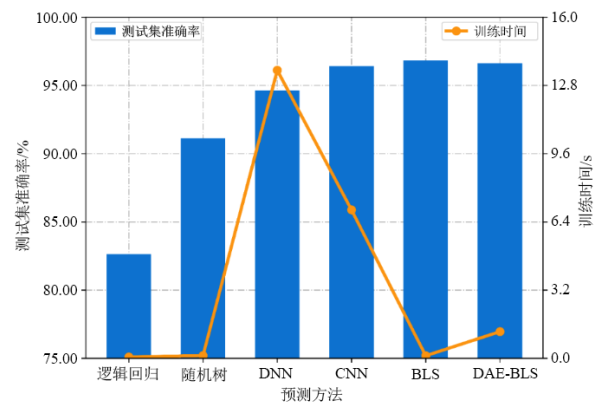


图5 心力衰竭实验结果对比

通过比较可以看出,在保证预测准确率的前提下,比起深度神经网络,宽度结构的神经网络(BLS与DAE-BLS)不仅达到了最好的准确度(96.83%和96.62%),而且大大降低了训练所需要的时间,有效地提升了性能,这是由于宽度神经网络结构简洁,不需要通过梯度下降求解.但是由于该数据集的大小有限,产生的结果可能存在一些偏差,因此接下来将使用数据量更多、数据更混乱的糖尿病数据集进行实验.

##### (2)糖尿病再入院预测

在经过以上预处理后,得到了127386条包含111维的医疗数据的糖尿病数据集.比起心力衰竭数据库,该糖尿病数据库特征众多、数据量较大.随后也将同样的算法应用在该糖尿病数据集上也进行了实验比较,结果如表2所示.结果对比如图6所示.

通过实验结果,首先可以直观地看出,在这种数据量众多、特征复杂的数据环境中,原始BLS的准确率出现下降,而本文提出的预测模型DAE-BLS无论是在精

表 2 糖尿病预测实验结果

方法	训练集 准确率/%	测试集 准确率/%	训练时间/s
逻辑回归	71.51	71.36	2.03
随机树	90.64	89.56	1.56
神经网络(DNN)	94.58	94.39	96.79
卷积神经网络(CNN)	94.12	93.92	108.96
宽度神经网络(BLS)	93.518	92.72	50.16
DAE-BLS	94.86	94.52	58.63




图 6 糖尿病实验结果对比

精度上还是在训练时间上都存在着很大的优势,在原始 BLS 的基础上进一步提高了近 2% 的准确率,而仅仅只是多花费了 8 s 左右的训练时间,与其余深度结构的神经网络相比,仍然是一个高效的算法. 这是因为降噪自动编码器增强了原始 BLS 的特征提取能力.

### 4.3 心电数据

#### 4.3.1 实验数据集介绍

本文使用 MIT-BIH 心律失常数据库<sup>[39]</sup>进行仿真实验. 该数据库是由美国麻省理工学院提供的研究心律失常的数据库,是三个得到国际承认可以被用作临床标准的心电数据库之一. MIT-BIH 心律失常数据库包含 48 条双通道动态心电信号记录,每一条都超过了 30 min,这些记录来自 BIH 心律失常实验室在 1975 年至 1979 年研究的 47 名受试者,其中受试者为 25 名年龄在 32~89 岁之间的男子和 22 名年龄在 23~89 岁之间的女性,共计 109 500 个心拍,其中异常心拍约占 30%. 本文利用所提模型对异常心拍进行预测.

#### 4.3.2 预处理过程

(1)对心电信号进行去噪预处理. 这是因为在心电信号采集或者数模转换的过程中,会产生噪声,包括工频干扰、肌电干扰、基线漂移这三种. 本文使用 Py-Wavelets 小波分析库的阈值过滤器中对心电信号进行初步去噪处理.

(2)使用 Z-score 归一化处理. 不同变量往往

量纲不同,归一化可以消除量纲对结果的影响.

(3)对心电信号进行心拍划分. 心电信号中的异常波形大多都会具体表现在单个心拍中,因此在实际应用前还需要对心电信号进行心拍划分. 心拍信号截取的常见方法之一是以 R 波位置作为定位点,前后分别截取估计的采样点数. 本文使用的数据集中带有的专家标注的 R 波位置进行心拍划分,得到了 100 012 条心拍数据.

(4)类别不平衡的处理. 上述处理后得到的心拍数据存在着类别不平衡的情况,五类心拍中正常心拍(N类心拍)占据 75% 以上,因此本文使用重采样的方法对数据的类别进行平衡,最终得到了五类各 5 000 条的平衡的心拍数据.

(5)训练集测试集的划分. 本次实验中将最终得到用于分类的心拍数据的 80% 作为训练集,20% 作为测试集. 同时为了预防划分测试集与训练集的随机性影响实验结果,在划分的过程中保证训练集与测试集中预测标签的比例与总体数据集中的比例一致.

#### 4.3.3 心拍异常实验结果

在经过以上预处理后的心拍异常数据集中,本文进行了一系列算法实验比较,实验结果如表 3 所示. 结果对比如图 7 所示.

表 3 心拍异常预测实验结果

方法	训练集 准确率/%	测试集 准确率/%	训练时间/s
逻辑回归	85.96	85.10	25.00
随机树	97.91	93.13	19.05
神经网络(DNN)	99.34	98.24	55.67
卷积神经网络(CNN)	99.25	98.47	124.23
宽度神经网络(BLS)	99.39	98.06	8.57
DAE-BLS	99.71	98.50	10.73




图 7 心拍异常实验结果对比

通过实验结果可以看出,基于宽度学习系统的模型相比于其他深度学习模型显著提高了模型的训练速

度,而 DAE-BLS 虽然一定程度上提升了宽度学习系统的准确率,但是提升得不够明显,这可能是因为在该数据集集中模型的准确率本身已经较高(近 99%)。

#### 4.4 图像数据

##### 4.4.1 实验数据集介绍

BreaKHis 数据库<sup>[40]</sup>通过 2014 年 1 月至 2014 年 12 月的临床研究收集图像,包含良性和恶性乳腺肿瘤的显微活检图像。每个病例的最终诊断由经验丰富的病理学家进行,并通过免疫组织化学分析等辅助检查进行再确认。图像数据被保存在三通道 RGB 中,是未经标准化或颜色标准化的原始图像。本次实验最终使用的数据库来自于 Kaggle (<https://www.kaggle.com/forederation/breakhis-400>),其仅取 BreaKHis 数据库中 400 倍光学变焦的部分样本,并且已经用不同的文件夹划分训练数据和测试数据。

##### 4.4.2 乳腺癌检测实验结果

上述数据集中,本文得到的图像数据格式为  $224 \times 224 \times 3$ , 1 148 张图像为训练集, 545 张图像为测试集。本文在其中进行了一系列模拟实验,结果如表 4 所示。结果对比如图 8 所示。

表 4 癌症 ct 图片预测实验结果

方法	训练集准确率/%	测试集准确率/%	训练时间/s
逻辑回归	99.56	75.41	85.08
随机树	99.30	71.55	76.73
深度神经网络(DNN)	90.76	80.55	293.36
卷积神经网络(CNN)	85.54	85.19	4 598.31
宽度神经网络(BLS)	89.06	77.61	36.04
DAE-BLS	84.44	83.64	95.67




图 8 心拍异常实验结果对比

通过实验结果可以看出, DAE 在宽度学习系统中引入显著提升了原始 BLS 的效果, 大约提升了 5% 的准确率, 但明显也花费了更多的训练时间(多花费了 30 s

左右), 可能是由于降噪自动编码器对图像数据的处理需要花费更多的训练时间。尽管如此, 与其他的算法模型相比, DAE-BLS 模型仍然是一个快速、高效的模型。

#### 4.5 增量学习

本文在前文使用过的 Diabetes 130-US hospitals 糖尿病数据集上设计实验证明用在 DAE-BLS 模型的增量学习的可行性。首先, 将模型的初始增强节点设置为 1 000, 然后在初始模型训练好的情况下, 使用增量学习增加 1 000 个增量节点进行快速重构, 与重新训练一个模型进行对比, 结果如表 5 所示。结果对比图示如图 9 所示。

表 5 增量学习实验结果

增强节点数/个	训练集准确率/%	测试集准确率/%	训练时间/s
1 000	93.67	92.70	3.78
2 000	94.25	93.63	25.45
1 000→2 000	93.91	93.77	8.59




图 9 增量学习训练时间与准确率对比

通过实验数据可以看出, 使用增量学习算法将增强节点从 1 000 个重构为 2 000 个时仅仅花了 8.59 s, 相比之下重新训练一个 2 000 个增强节点的模型需要花费 25.45 s, 节省了将近 17 s 的训练时间。实验结果显示, 所提模型在模型结构需要更改时, 可以实现快速重构。DAE 的引入加强了 BLS 的特征提取能力, 同时没有破坏其宽度结构的优越性, 因此保留了 BLS 训练高效与增量学习的特点。

## 5 结论

提高医疗健康服务一直是我国高度重视的工作, 疾病预测是其中一项非常具有意义的工作。本文针对目前疾病预测模型训练速度慢、提取特征困难等问题提出了一种基于降噪自动编码器与宽度学习的疾病预测模型 DAE-BLS, 在原始 BLS 的基础上, 使用降噪自动

编码器作为 BLS 的映射层进行特征提取,在保留了原始 BLS 快速高效的特点的基础上提高了 BLS 在复杂混乱的医疗数据上的性能表现。

本文提出的预测模型尽管在多个真实的疾病数据集上都表现出很好的性能,但仍然存在一些问题需要进一步研究。例如:在糖尿病患者数据集中,无论是原始 BLS 还是 DAE-BLS 提升的训练速度并没有心力衰竭数据集上的明显,这可能跟数据集本身的大小以及混乱程度有关,因此可能仍需在更大样本量、更复杂的数据库中进行进一步实验;在乳腺癌数据集中,DAE-BLS 相比 BLS 明显花费了比其他数据集更多的时间,这可能是由于所设计的 DAE 对图像数据的处理需要花费很多的时间,因此如果想要进一步提升模型在图像数据上的性能,可能需要对 DAE 的结构做进一步改进。在未来的研究中,将考虑结合相关疾病的医学先验知识对数据进行解释性更强的处理,进一步优化预测模型,并将所提方法扩展到其他的医疗场景。

#### 参考文献

- [1] 李静,吴美玲. 中国城乡人口老龄化发展质量: 差异和预测[J]. 宏观质量研究, 2020, 8(5): 1-13.
- [2] DIMITROV D V. Medical Internet of Things and big data in healthcare[J]. Healthcare Informatics Research, 2016, 22(3): 156-163.
- [3] LI W, CHAI Y B, KHAN F, et al. A comprehensive survey on machine learning-based big data analytics for IoT-enabled smart healthcare system[J]. Mobile Networks and Applications, 2021, 26(1): 234-252.
- [4] 张学军, 景鹏, 何涛, 等. 基于变分模态分解的癫痫脑电信号分类方法[J]. 电子学报, 2020, 48(12): 2469-2475.
- [5] 成娟, 陈勋, 彭虎. 基于样本熵的肌电信号起始点检测研究[J]. 电子学报, 2016, 44(2): 479-484.
- [6] 李婧, 张红, 薛万刚, 等. 医院与社区协同的远程心电诊断服务模式设计与实现[J]. 中国数字医学, 2020, 15(1): 47-49.
- [7] LI J, ZHANG H, XUE W G, et al. Design and implementation of remote ECG diagnosis service model based on cooperation between hospital and communities[J]. China Digital Medicine, 2020, 15(1): 47-49. (in Chinese)
- [8] POPLIN R, VARADARAJAN A V, BLUMER K, et al. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning[J]. Nature Biomedical Engineering, 2018, 2(3): 158-164.
- [9] RAJENDRA ACHARYA U, FUJITA H, OH S L, et al. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals[J]. Information Sciences, 2017, 415/416: 190-198.
- [10] TULI S, BASUMATARY N, GILL S S, et al. HealthFog: An ensemble deep learning based Smart Healthcare System for Automatic Diagnosis of Heart Diseases in integrated IoT and fog computing environments[J]. Future Generation Computer Systems, 2020, 104: 187-200.
- [11] XIAN Y Q, HU H F. Enhanced multi-dataset transfer learning method for unsupervised person re-identification using co-training strategy[J]. IET Computer Vision, 2018, 12(8): 1219-1227.
- [12] CHEN C L P, LIU Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [13] 赵慧敏, 郑建杰, 郭晨, 等. 基于流形正则化框架和 MMD 的域自适应 BLS 模型[J/OL]. 自动化学报, (2021-06-28)[2021-07-23]. <http://www.aas.net.cn/article/doi/10.16383/j.aas.c210009>.
- [14] ZHAO H M, HENG J J, GUO C, et al. Domain adaptive BLS model based on manifold regularization framework and MMD[J/OL]. Acta Automatica Sinica, (2021-06-28)[2021-07-23]. <http://www.aas.net.cn/article/doi/10.16383/j.aas.c210009>. (in Chinese)
- [15] XU M L, HAN M, CHEN C L P, et al. Recurrent broad learning systems for time series prediction[J]. IEEE Transactions on Cybernetics, 2020, 50(4): 1405-1417.
- [16] BELOUADAH E, POPESCU A, KANELLOS I. A comprehensive study of class incremental learning algorithms for visual tasks[J]. Neural Networks, 2021, 135: 38-54.
- [17] LEE J, SUN S, YANG S M, et al. Bidirectional recurrent auto-encoder for photoplethysmogram denoising[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(6): 2375-2385.

- [16] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Proceedings of the 25th International Conference on Machine Learning. Helsinki: ACM, 2008: 1096-1103.
- [17] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [18] BOURLARD H, KAMP Y. Auto-association by multilayer perceptrons and singular value decomposition[J]. *Biological Cybernetics*, 1988, 59(4): 291-294.
- [19] IJINA E P, KRISHNA M C. Classification of human actions using pose-based features and stacked auto encoder [J]. *Pattern Recognition Letters*, 2016, 83(3): 268-277.
- [20] TIAN S W, YAN Y L, YU L, et al. Prediction of anti-HIV activity on the basis of stacked auto-encoder[J]. *Journal of Chemometrics*, 2017, 31(10): 2970-2987.
- [21] WANG L, WANG Z W, ZHAO G Y, et al. Automatic voice quality evaluation method of IVR service in call center based on Stacked Auto Encoder[J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 827(1): 012021.
- [22] MASCI J, MEIER U, CIREŞAN D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction [C]//Artificial Neural Networks and Machine Learning. Berlin: Springer, 2011: 52-59.
- [23] LIU J S, ZHANG Z, RAZAVIAN N. Deep EHR: Chronic disease prediction using medical notes[EB/OL]. (2018) [2021]. <https://arxiv.org/abs/1808.04928>.
- [24] JIN M Q, BAHADORI M T, COLAK A, et al. Improving hospital mortality prediction with medical named entities and multimodal learning[EB/OL]. (2018) [2021]. <https://arxiv.org/abs/1811.12276>.
- [25] LIANG Z, ZHANG G, HUANG J X, et al. Deep learning for healthcare decision making with EMRs[C]//2014 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Belfast: IEEE, 2015: 556-559.
- [26] HANNUN A Y, RAJPURKAR P, HAGHPANAHI M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. *Nature Medicine*, 2019, 25(1): 65-69.
- [27] CHEN C L P, LIU Z L. Broad learning system: A new learning paradigm and system without going deep[C]//2017 32nd Youth Academic Annual Conference of Chinese Association of Automation (YAC). Hefei: IEEE, 2017: 1271-1276.
- [28] BEN-ISRAEL A, GREVILLE T N E. *Generalized Inverses: Theory and Applications*[M]. 2nd ed. New York: Springer, 2003.
- [29] LIU Z L, ZHOU J, CHEN C L P. Broad learning system: Feature extraction based on K-means clustering algorithm [C]//2017 4th International Conference on Information, Cybernetics and Computational Social Systems (ICCS). Dalian: IEEE, 2017: 683-687.
- [30] JIN J W, PHILIP CHEN C L. Regularized robust Broad Learning System for uncertain data modeling[J]. *Neurocomputing*, 2018, 322: 58-69.
- [31] ZHOU Q M, HE X P. Broad learning model based on enhanced features learning[J]. *IEEE Access*, 2019, 7: 42536-42550.
- [32] LIN J T. Three-domain fuzzy wavelet broad learning system for tremor estimation[J]. *Knowledge-Based Systems*, 2020, 192: 105295.
- [33] LEI M, RAO Z Y, LI M, et al. Identification of coal geographical origin using near infrared sensor based on broad learning[J]. *Applied Sciences*, 2019, 9(6): 1111.
- [34] 滕菲, 单麒麟, 李铁山. 智能船舶综合能源系统及其分布式优化调度方法[J]. *自动化学报*, 2020, 46(9): 1809-1817.
- TENG F, SHAN Q H, LI T S. Intelligent ship integrated energy system and its distributed optimal scheduling algorithm[J]. *Acta Automatica Sinica*, 2020, 46(9): 1809-1817. (in Chinese)
- [35] LIU Y Z, GOPALAKRISHNAN V. An overview and evaluation of recent machine learning imputation methods using cardiac imaging data[J]. *Data*, 2017, 2(1): 8.
- [36] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. *Journal of Artificial Intelligence Research*, 2002, 16: 321-357.
- [37] STRACK B, DESHAZO J P, GENNINGS C, et al. Impact of HbA1c measurement on hospital readmission rates: Analysis of 70, 000 clinical database patient records [J]. *BioMed Research International*, 2014, 2014: 781670.
- [38] ZHANG Z, CAO L, ZHAO Y, et al. Hospitalized patients with heart failure: integrating electronic healthcare records and external outcome data (version 1.2)[EB/OL]. (2020)[2021]. <https://doi.org/10.13026/8a9e-w734>.
- [39] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. *IEEE Engineering in Medicine*

and Biology Magazine, 2001, 20(3): 45-50.

- [40] SPANHOL F A, OLIVEIRA L S, PETITJEAN C, et al. A dataset for breast cancer histopathological image classification[J]. IEEE Transactions on Bio-Medical Engineering, 2016, 63(7): 1455-1462.

#### 作者简介



漆华妹 女,1978年出生,江西南昌人.中南大学计算机学院副教授,硕士生导师.主要研究方向为机器学习、边缘计算、云计算、物联网、5G通信等.

E-mail: qhm@csu.edu.cn



胡宇轩 男,1999年出生,湖南娄底人.中南大学计算机学院硕士研究生.主要研究方向为机器学习与智慧医疗.

E-mail: 204712249@csu.edu.cn



袁正一 男,2001年出生,江西南昌人.中南大学计算机学院本科生.主要研究方向为机器学习与智能算法.

E-mail: 2250100280@qq.com