

# 一种用于心电图分类的改进神经网络算法

尘昌华<sup>1</sup>, 乔凤娟<sup>2</sup>, 李 彬<sup>2</sup>

(1. 上海开放大学奉贤分校, 上海 201499;

2. 齐鲁工业大学(山东省科学院) 数学与统计学院, 山东 济南 250353)

**摘要:** 心血管疾病的死亡率在所有疾病中居于首位, 心电图能够反映人体的电信号活动情况, 它已成为医生用来诊断心血管疾病的重要依据。随着计算机辅助 ECG 诊断技术的快速发展, 深度学习方法已能够实现 ECG 信号的特征提取和分类。为了较好地提高 ECG 信号的分类识别率和处理效率, 该文提出了一种新的心电图分类方法。首先, 对原始数据进行去噪, 提出了基于经验小波变换(EWT)的提升小波阈值去噪方法。然后, 重构经过提升小波阈值去噪技术处理过的模态分量。在训练过程中, 设计了基于局部感受野的极限学习机(ELM-LRF)和双向长短时记忆网络(BLSTM)结合的神经网络算法, 并利用注意力机制优化该算法, 提出了 LRF-BLSTM-Attention 模型。最后, 在 CCDD 和 MIT-BIH 数据集上对提出算法的性能进行验证, 准确率分别达到 86.12% 和 99.87%, 证明了该算法在临床心血管疾病智能诊断中的实用性。与其他模型相比, 该模型的收敛速度更快, 收敛的损失值更小。

**关键词:** 极限学习机; 局部感受野; 双向长短时记忆网络; 注意力机制; 心电图

中图分类号: TP183

文献标识码: A

文章编号: 1673-629X(2023)01-0178-09

doi:10.3969/j.issn.1673-629X.2023.01.027

## An Improved Neural Network Algorithm for ECG Classification

CHEN Chang-hua<sup>1</sup>, QIAO Feng-juan<sup>2</sup>, LI Bin<sup>2</sup>

(1. Shanghai Open University Fengxian Branch, Shanghai 201499, China;

2. School of Mathematics and Statistics, Qilu University of Technology (Shandong Academy of Sciences), Jinan 250353, China)

**Abstract:** The mortality of cardiovascular disease ranks first among all diseases. ECG can reflect the activity of human electrical signals, which has become an important basis for doctors to diagnose cardiovascular diseases. With the rapid development of computer-aided ECG diagnosis technology, deep learning method has been able to realize the feature extraction and classification of ECG signals. In order to better improve the classification and recognition rate and processing efficiency of ECG signals, a new ECG classification method is proposed. First of all, the original data is denoised and an improved wavelet threshold denoising method based on empirical wavelet transform (EWT) is proposed, and then the modal components processed by lifting wavelet threshold denoising technology are reconstructed. In the training process, a neural network algorithm combining local receptive fields based extreme learning machine (ELM-LRF) and bidirectional long short-term memory network (BLSTM) is designed, and the attention mechanism is introduced to optimize the model. Finally, the performance of the proposed algorithm is verified on CCDD and MIT-BIH Arrhythmia Datasets. The classification accuracy rates have reached 86.12% and 99.87%, respectively, proving the algorithm's practicability and effectiveness in clinical intelligent diagnosis of cardiovascular diseases. Compared with other models, the convergence speed of such model is faster and the loss of convergence is smaller.

**Key words:** extreme learning machine; local receptive field; bidirectional long short-term memory network; attention mechanism; electrocardiogram

## 0 引言

据统计, 心血管疾病的死亡率在所有疾病中居于

首位, 远高于恶性肿瘤、呼吸系统疾病等。心电图(Electrocardiogram, ECG)能够反映人体的电信号活动情

收稿日期: 2021-12-16

修回日期: 2022-04-19

基金项目: 山东省高等学校青创科技支持计划(2019KJN011); 山东省自然科学基金项目(ZR2020MF097); 济南市“新高校20条”项目(2021GXRC100)

作者简介: 尘昌华(1979-), 男, 讲师, 研究方向为分布式计算、机器学习; 通讯作者: 李 彬(1979-), 男, 博士, 教授, 研究方向为机器学习、机器人运动控制。

况,是医生用来诊断心血管疾病的重要依据。由于 ECG 中包含各种噪声,如基线漂移、肌电干扰和工频干扰等,医生在诊断时往往需要先忽略干扰较多的波形再进行判断。

近年来,计算机辅助 ECG 诊断技术有了较大发展。现有的诊断技术主要包括三个步骤:去噪、特征提取和分类。常用的去噪方法主要有:基于小波变换的方法<sup>[1]</sup>、基于数字滤波器的方法<sup>[2]</sup>以及基于阈值的方法<sup>[3]</sup>等。Singh<sup>[4]</sup>将经验小波变换(Empirical Wavelet Transform, EWT)用于 ECG 信号的去噪,证明了该算法的有效性;Sai<sup>[5]</sup>证明了在 ECG 信号的去噪过程中,提升小波变换(Lifting Wavelet Transform, LWT)的去噪性能优于中值滤波。

深度学习方法能够同时实现 ECG 信号的特征提取和分类,近年来在 ECG 辅助诊断方面取得了令人满意的成果。Acharya 等<sup>[6]</sup>设计了一种九层的卷积神经网络结构,在 MIT-BIH 数据集上实现了 94.03% 的识别准确率;Chauhan 等<sup>[7]</sup>采用 LSTM 网络对正常心跳和异常心跳进行分类,准确率为 96.45%;Shu 等<sup>[8]</sup>将 LSTM 与 CNN 相结合,开发了一种新的处理变长心电信号的混合结构,在 MIT-BIH 数据集上的识别准确率为 98.10%。但是,现有的大多数算法都是仅基于 MIT-BIH 这一个数据集得出的结论,该数据集仅采集了 47 个人的心电图,算法的泛化性和实用性难以得到验证。

为了较好地提高 ECG 信号的分类识别率和处理效率,该文提出了基于 EWT 的提升小波阈值去噪方法:对含噪信号进行经验小波分解,得到多频率的模式分量 IMFs;对 IMFs 作提升小波阈值去噪处理;用经过提升小波阈值去噪技术处理过的模式分量进行重构,得到最终去噪后的信号。然后,设计了 LRF-BLSTM-Attention 模型,利用三个交替的随机卷积层和最大池

化层提取 ECG 信号的空间特征,利用 BLSTM 获得 ECG 信号的时间特征,在 BLSTM 隐藏层的输出中引入注意力机制,给重要的特征分配更多的注意力,进一步挖掘序列信息的相关性,提高 ECG 识别的准确率。最后,基于 CCDD 和 MIT-BIH 数据集进行仿真实验,验证该所提出模型算法结构的实用性。

针对心电信号的自动分类工作进行研究,首先,现有的算法大多都是基于 MIT-BIH 数据集,该数据集的心电信号来自于少数个体,代表性不强。这造成有些算法在该数据集上能够取得很好的识别准确率,在临床应用上的识别效果很差。该文不仅采用了 MIT-BIH Arrhythmia 数据集,还采用了 CCDD 数据库,该数据库数据量大,且背景噪声较多,共有 17 万条来自不同病人的心电信号,更具有临床代表性。同时,现有的心电信号自动分类方法多是针对单导联数据进行分类,不能考虑其他导联的特征信息。该文考虑了导联之间的相关性,提出了多通道模型,能够实现多导联心电信号的分类。

## 1 基于 EWT 的提升小波阈值去噪方法

经验小波变换<sup>[9]</sup>是 Gilles 结合经验模态分解和小波分析而提出的信号处理方法。

首先,将信号频谱范围规范化到  $[0, \pi]$ ,并将其分割为连续的  $N$  段,每段为  $\Lambda_n$ ,即:

$$\bigcup_{n=1}^N \Lambda_n = [0, \pi] \quad (1)$$

假设为以  $\omega_n$  为中心,即  $\Lambda_n = [\omega_{n-1}, \omega_n]$ ,则宽度为  $T_n = 2\tau_n$ 。

对信号频谱进行分割后,构建经验小波滤波器组进行滤波。经验小波滤波器组的构建借鉴了 Mayer 小波,其经验小波尺度函数  $\varphi(\omega)$  和经验小波函数  $\psi(\omega)$  见式(2)、(3)。

$$\varphi(\omega) = \begin{cases} 1, & |\omega| \leq \omega_n - \tau_n \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right], & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0, & \text{其他} \end{cases} \quad (2)$$

$$\psi(\omega) = \begin{cases} 1, & \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1} \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_{n+1}}(|\omega| - \omega_{n+1} + \tau_{n+1})\right)\right], & \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin\left[\frac{\pi}{2}\beta\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right], & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0, & \text{其他} \end{cases} \quad (3)$$

其中,  $\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3)$ 。

接下来,根据传统小波变换理论构建经验小波变换,其细节系数  $w_f^e(n, t)$  和逼近系数  $w_f^e(0, t)$  为:

$$w_f^e(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau =$$

$$(\hat{f}(\omega) \hat{\psi}_n(\omega))^V \quad (4)$$

$$w_f^e(0, t) = \langle f, \varphi_1 \rangle = \int f(\tau) \overline{\varphi_1(\tau - t)} d\tau =$$

$$(\hat{f}(\omega) \hat{\varphi}_1(\omega))^V \quad (5)$$

其中,  $f(t)$  为待测信号,  $\psi_n(t)$  和  $\varphi_1(t)$  为经验小波函

数和尺度函数,  $\hat{\psi}_n(\omega)$  和  $\hat{\varphi}_1(\omega)$  分别为  $\psi_n(t)$  和  $\varphi_1(t)$  的 Fourier 变换,  $\overline{\varphi_1(t)}$  为  $\varphi_1(t)$  的复共轭。

提升小波法<sup>[10]</sup>是 Swelden 在小波变换的基础上提出的第二代小波算法,继承了第一代小波算法的多分辨率特性,且不依赖于傅里叶变换,大大降低了算法复杂度和内存需求,是目前对离散信号进行分析的重要方法。

提升小波法主要分为分裂、预测、更新三个步骤:首先,根据原始信号  $x(n)$  的奇偶性分解为两个互不重叠的奇序列  $\{x_o(k) = x(2k+1)\}$  和偶序列  $\{x_e(k) = x(2k)\}$ ;根据相关性原则,利用偶序列来预测奇序列,产生细节信号  $d(k) : d(k) = x_o(k) - P(x_e(k))$ ;根据完整性原则,对偶序列进行更新,得到信号的逼近序列  $c(k)$ ,更新公式为  $c(k) = x_e(k) + U(d(k))$ ,  $U$  为更新算子。

文中所使用的阈值去噪方法是 Donoho 等人提出的软阈值去噪法,软阈值函数为:

$$\omega(x, \lambda) = \begin{cases} \text{sign}(x) (|x| - \lambda), & |x| > \lambda \\ 0, & |x| \leq \lambda \end{cases} \quad (6)$$

其中,  $\lambda$  为阈值,  $x$  为高频小波系数。

在上文所述基础上,提出了 EWT 的提升小波阈值去噪方法<sup>[11]</sup>,该方法的主要操作过程如下:首先,对含噪的原始信号进行经验小波分解,得到多频率的模式分量 IMFs;然后,对 IMFs 作提升小波阈值去噪处理;最后,重构经过提升小波阈值去噪技术处理过的模式分量,即可得到最终去噪后的信号。

## 2 相关模型

### 2.1 基于局部感受野的极限学习机

基于局部感受野的极限学习机 (Local Receptive Fields Based Extreme Learning Machine, ELM-LRF) 是在极限学习机的基础上引入局部感受野的概念而提出的一种网络模型,能够实现特征的自动提取和分类,具有模型复杂度低、速度快的优点<sup>[12]</sup>。

ELM-LRF 模型的网络结构主要包括随机卷积层、池化层和输出层三个部分,如图 1 所示。




图 1 ELM-LRF 模型的网络结构

(1) 随机卷积层。随机卷积的概念借鉴于卷积神经网络中的卷积操作。不同点在于:随机卷积过程中,卷积核中的每一个元素都根据概率分布随机生成并确

定,不需要进行迭代、微调。假设模型的输入是大小为  $d \times 1$  的向量,卷积核的大小为  $r \times 1$ ,第  $k$  个特征图的权重表示为  $a_k \in R^{r \times 1}$ ,输出节点  $(i, 1)$  处的值  $c_{i,1,k}(x)$  为:

$$c_{i,1,k}(x) = \sum_{m=1}^r x_{i+m-1,1} a_{m,1,k} \quad i = 1, 2, \dots, (d-r+1) \quad (7)$$

(2) 最大池化层。利用最大池化去除冗余信息,减少特征维数。设池化大小为  $s \times 1$ ,第  $k$  个特征图在节点  $(p, 1)$  处的值  $h_{p,1,k}$  为:

$$h_{p,1,k} = \max(c_{i,1,k}), \quad i = p - s/2, \dots, p + s/2 \quad (8)$$

其中,  $p, q = 1, 2, \dots, (d-r+1)$ 。

(3) 输出层。通过最后一个隐藏层的输出  $H$  求解输出权重  $\beta$ ,计算公式为:

$$\begin{cases} \beta = H^T \left( \frac{1}{C} + HH^T \right)^{-1} T, & N \leq (d-r+1)^2 \\ \beta = \left( \frac{1}{C} + HH^T \right)^{-1} H^T T, & N > (d-r+1)^2 \end{cases} \quad (9)$$

### 2.2 BLSTM

LSTM 是循环神经网络<sup>[13]</sup> (Recurrent Neural Network, RNN) 的一种变型,能够避免 RNN 训练过程中出现的梯度消失或梯度爆炸问题,目前已广泛应用于文本分类<sup>[14]</sup>、电力预测<sup>[15]</sup>等多个领域。

一般的 LSTM 记忆单元结构如图 2 所示。LSTM 网络由输入层、隐藏层和输出层组成,与传统 RNN 不同的是, LSTM 网络的隐藏神经元由 LSTM 记忆单元构成,每个记忆单元包括遗忘门 (Forget Gate)、输入门 (Input Gate)、输出门 (Output Gate) 三个部分,遗忘门确定当前的细胞状态中的舍弃信息,输入门确定更新当前细胞状态的信息,输出门确定隐藏层的输出状态。

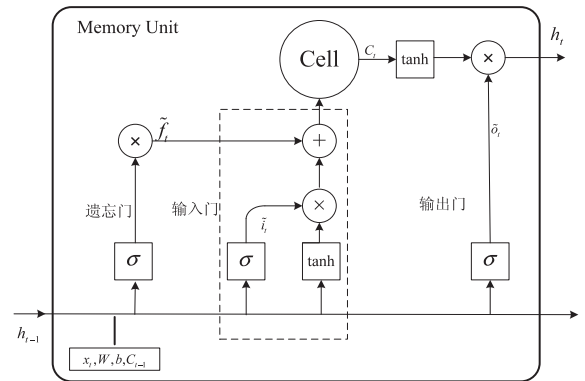


图 2 一般的 LSTM 记忆单元结构

LSTM 的计算过程如下:

$$f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \quad (10)$$

$$i_t = \sigma(W_i[x_t, h_{t-1}] + b_i) \quad (11)$$

$$g_t = \tanh(W_g[x_t, h_{t-1}] + b_g) \quad (12)$$

$$o_t = \sigma(W_o[x_t, h_{t-1}] + b_o) \quad (13)$$

$$c_t = f_t \odot c_{t-1} + i_t \quad (14)$$

$$h_t = o_t \odot \tanh(c_t) \quad (15)$$

其中,  $f_t$ 、 $i_t$ 、 $o_t$ 、 $c_t$  分别表示遗忘门、输入门和输出门和细胞状态在  $t$  时刻的输出,  $W_f$ 、 $W_i$  和  $W_o$  分别表示各个门结构的权重,  $b_f$ 、 $b_i$  和  $b_o$  分别表示它们的偏置。  $x_t$  表示  $t$  时刻的输入,  $c_t$  表示  $t$  时刻的细胞状态,  $h_t$  表示隐藏层在时刻  $t$  的输出,  $\sigma$  表示 sigmoid 函数,  $\tanh$  表示双曲正切激活函数,  $\odot$  表示 Hadamard 乘积。

心电图信号的分类识别依赖于过去和未来的时间特征信息,而 LSTM 只能考虑过去的信息,不能考虑未来的信息,在一定程度上影响了心电图的识别效果。BLSTM 模型是在 LSTM 的基础上提出的<sup>[13]</sup>,能够弥补 LSTM 模型的不足,通过正向 LSTM 传播和反向 LSTM 传播能够分别学习心电信号的前向特征和后向特征。二者结合,就能得到心电信号的总体特征。

### 2.3 注意力机制

注意力机制 (Attention Mechanism) 于 2014 年由 Bahdanau 提出<sup>[15]</sup>,模仿了人类大脑中特有的图像处理机制。该方法能够根据需要有选择地分配注意力,提高计算机进行信息处理的效率。注意力机制目前广泛应用于各种深度学习领域,如机器翻译<sup>[16]</sup>、图像处理<sup>[17]</sup>、文本分类<sup>[18]</sup>等。注意力机制在 BLSTM 中的计算过程如下:

首先,根据当前时刻信号过去和未来信号的依赖关系,对 BLSTM 网络隐藏层输出的信号特征  $h_t$  赋予注意力权重  $a_t$ 。其计算公式为:

$$a_t = \tan(h_t) \quad (16)$$

接着,通过 softmax 函数对注意力权重  $a_t$  进行归一化处理。计算公式表示为:

$$p_t = \exp(a_t) / \sum_{i=1}^n a_i \quad (17)$$

最后,分配注意力权重。根据注意力权重的大小给特征向量  $h_t$  分配注意力资源,增强信号的特征表达能力。计算公式表示为:

$$y_t = \sum_{i=1}^n p_i h_i \quad (18)$$

在心电图识别任务中,通过随机卷积层和池化层能够获得心电信号的局部空间特征,通过 BLSTM 网络能够进一步得到心电信号的时间特征表示。然而,这两部分都没有突出心电信号当前采样点与之前、之后采样点之间的关联性,不利于长时间的心电信号识别任务。为了增强距离较远采样点之间的相关性,该文引入了注意力机制,即有选择地给与不同重要程度的采样点不同的注意力资源。在模型中引入注意力机制,不仅能够获得心电信号的局部特征和时间特征,还能够考虑当前采样点和上下文时刻采样点的关联性,使得模型在具有重要信息的区域获得更多的注意力资源,提高心电图分类识别的准确率。

## 3 文中方法

### 3.1 模型

结合 ELM-LRF、BLSTM 和注意力机制,该文提出了一种新的网络结构,记为 LRF-BLSTM-Attention 模型。下面以多导联数据的心电信号自动分类任务为例,介绍该模型的网络结构。如图 3 所示,该模型由输入层、ELM-LRF 特征提取器、BLSTM 网络层和注意力层四大部分组成。

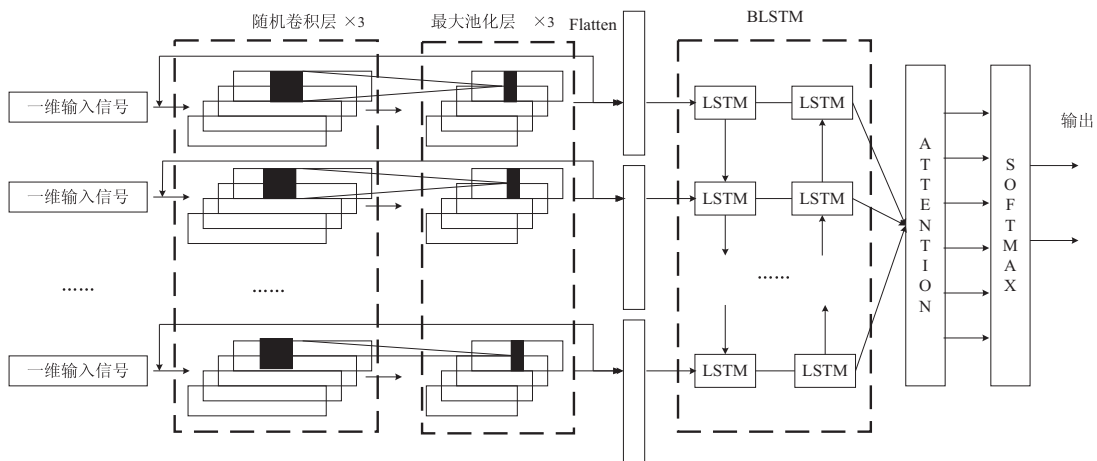


图 3 LRF-BLSTM-Attention 模型结构

#### (1) 输入层。

该模型的输入是去噪后的心电信号,以每一个导联分别作为输入,训练多个 ELM-LRF 特征提取器。设一段心电信号共有  $m$  个导联,  $n$  个采样点,则该信号可以表示为:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix}_{m \times n} \quad (19)$$



共训练  $m$  个 ELM-LRF 特征提取器,第  $i$  个特征提取器的输入是  $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 。

#### (2) ELM-LRF 特征提取器。

ELM-LRF 特征提取器通过三个堆叠的随机卷积层和最大池化层对输入的心电信号进行深层特征提取,随机卷积层和池化层交替出现。首先,利用第一个随机卷积层对心电信号特征提取,并将输出作为第一个最大池化层的输入,该层的输出为第二个随机卷积层的输入,依此循环,共有三个随机卷积层和三个最大池化层。将最后一个最大池化层的所有特征子图合并,传送到 BLSTM 部分。

卷积核大小的不同代表局部感受野的不同,能够提取到不同层次的特征。在实际任务中,随机卷积层中卷积核的大小和池化大小根据经验确定大致范围,并通过试凑法确定。

#### (3) BLSTM 网络层。

ELM-LRF 特征提取器的输出表示为  $(s_1, s_2, \dots, s_n)$ , 以此作为 BLSTM 网络层的输入。BLSTM 网络可以看作一个正向 LSTM 和一个反向 LSTM, 隐层输出分别表示为  $h_f = (h_{f1}, h_{f2}, \dots, h_{fn})$  和  $h_b = (h_{b1}, h_{b2}, \dots, h_{bn})$ , 将  $h_f$  和  $h_b$  进行拼接, 得到  $h = (h_f; h_b)$ , 即为 BLSTM 网络层所提取的特征向量, 反映了输入序列的时间信息和依赖关系。

#### (4) 注意力层。

为了进一步凸显心电信号的主要特征, 引入注意力机制。将 BLSTM 网络层所提取的特征向量  $h = (h_f; h_b)$  进行整合, 得到注意力层的输入, 表示为  $H: (h_1, h_2, \dots, h_n)$ 。由式(16)、(17)、(18), 得到最终的特征向量, 并利用 softmax 函数得到分类结果。

### 3.2 模型训练

所提出模型算法中, 随机卷积层的参数是根据概率分布随机确定的, 不需要通过迭代调整。因此, 仅需要训练 BLSTM 和注意力机制中的参数。本模型在最后一个 Dense 层利用 softmax 进行分类, 计算公式如下:

$$P(y_i = j | x_i) = \frac{\exp(x_i^T w_j)}{\sum_{n=1}^N \exp(x_i^T w_n)} \quad (20)$$

其中,  $j$  为类别,  $x_i$  表示输入的第  $i$  个样本,  $P(y_i = j | x_i)$  为获得第  $i$  个样本的类标签的概率函数。  $N$  表示样本数目,  $w$  表示模型中的参数。

在训练过程中, 优化器选择 Nadam<sup>[19]</sup>, 损失函数为交叉熵损失函数, 计算公式为:

$$L(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^m (y_i \log(P(y_i = j | x_i))) \quad (21)$$

其中,  $y_i$  为第  $i$  个样本的类标签,  $m$  为类别总数。

为了防止过拟合, 在训练时引入 Dropout, 以一定的概率丢弃一些隐层神经元。为了提高运行速度, 降低对内存的要求, 实验采用分批次训练方法, 批次大小设为 128。

## 4 仿真实验

### 4.1 实验环境及评价指标

实验所利用的处理器是 3.70 GHz Intel(R) Core(TM) i7-8700K, 内存为 32 GB, 使用的编程语言为 MATLAB R2018a 和 Python 3.5, 调用的库主要有: Keras、Numpy、wfdb、matplotlib、pandas、scipy、math 等。

为了验证所提出方法的有效性, 以特异性、灵敏度和准确率作为模型性能的评价指标。

### 4.2 数据集描述

#### (1) 中国心血管疾病数据集。

中国心血管疾病数据集 (Chinese Cardiovascular Disease Database, CCDD) 是针对中国的心血管疾病患者而建立的<sup>[20]</sup>, 数据库的所有数据均来自于医院的临床数据。该数据库中共包含 17 万多条数据, 每条数据都来自不同的患者, 共包含十二导联数据, 采样时间为 10 s 左右, 采样频率为 500 Hz。

#### (2) MIT-BIH Arrhythmia 数据集。

MIT-BIH 心律失常数据集<sup>[21]</sup> 包含了来自 Beth Israel Hospital (BIH) 住院患者的 48 条心电图信号记录。每一个心电信号都超过 30 分钟, 并由心血管疾病专家进行注释。在该数据集上, 以单个的心拍为单位进行分类。首先, 对数据下采样到 250 Hz<sup>[22]</sup> 并去噪, 通过 pan-tompkin 算法检测 R 峰<sup>[23]</sup>, 并取 R 峰前 100、后 149 个采样点组成一个完整的心拍。本实验中, 共使用四种心拍类型, 分别是正常窦性心律 (Normal Sinus Rhythm, NSR)、左束支传导阻滞 (Left Bundle Branch Block, LBBB)、右束支传导阻滞 (Right Bundle Branch Block, RBBB)、室性早缩 (Ventricular Premature Contraction, VPC)。

### 4.3 CCDD 的预处理

(1) 读取数据。由于导联数据的正交性, 实验中读取八个导联的数据, 分别是 II、III、V1、V2、V3、V4、V5、V6 导联, 其他导联的数据可由这八个导联推导得出。

(2) 剔除标签为“0x00”(无效) 和采样时间不足 9 s 的心电记录。由于操作失误等原因可能会导致心电信号一直为 0, 将这类记录也剔除。

(3) 考虑到内存需求和数据平衡性要求, 在剩下的数据中选择前 5 万正常数据和前 5 万异常数据作为本次实验的数据集, 共计 10 万数据。将实验数据集随机打乱, 并按照 7:3 的比例分为训练集和测试集。

(4)为了降低模型训练的复杂度,根据文献[22],实验中将 CCDD 的数据下采样到 250 Hz。

(5)去噪。对 CCDD 数据库中的心电记录进行基于 EWT 的提升小波阈值去噪实验。

#### 4.4 实验设计和结果

##### (1)CCDD。

LRF-BLSTM-Attention 模型用于 CCDD 数据集时的结构设计如表 1 所示。第一至六层为特征提取器,随机卷积层和最大池化层交替出现,随机卷积层中分别采用 4、8、16 个大小为  $7 \times 1$ 、 $6 \times 1$ 、 $5 \times 1$  的卷积核;第七层和第八层分别为 BLSTM 层和 Attention 层,第九层为 Dense 层,利用 softmax 函数输出心电信号的类别概率。

表 1 CCDD 的 LRF-BLSTM-Attention 结构设计

名称	卷积核大小	卷积核个数	输出大小
输入层	-	-	$8 \times 2$ 250
随机卷积层	$7 \times 1$	4	$8 \times 2$ $244 \times 4$
最大池化层	$4 \times 1$	4	$8 \times 561 \times 4$
随机卷积层	$6 \times 1$	8	$8 \times 556 \times 8$
最大池化层	$4 \times 1$	8	$8 \times 139 \times 8$
随机卷积层	$5 \times 1$	16	$8 \times 135 \times 16$
最大池化层	$3 \times 1$	16	$8 \times 45 \times 16$
BLSTM	32 Unit	-	$8 \times 128$
Attention	-	-	$8 \times 128$
Dense	-	-	2
Dense	-	-	2

利用 Dropout 防止过拟合处理中,选择合适的丢弃概率对网络模型的训练至关重要,如果丢弃概率太小,可能难以达到消除过拟合的作用,如果丢弃概率太大,则可能会丢失数据中的重要信息。实验中分别选择不同的 Dropout 值进行多次实验,结果如图 4 所示。当 Dropout 取值为 0.3 时,测试集的准确率达到最高,为 86.12%,因此,最终 Dropout 的取值为 0.3。




图 4 不同 Dropout 值下的测试集准确率

为了进一步评估所提出的 LRF-BLSTM-

Attention 模型在心电图信号识别领域的性能,将该模型与 LSTM、BLSTM、LRF-BLSTM(未引入注意力机制)、LRF-BGRU-Attention(Bidirectional Gated Recurrent Unit)和 LRF-BLSTM-Attention 模型进行对比,结果如图 5 所示。




图 5 各模型的 loss 变化曲线

由图 5 可以看出,随着迭代次数的增加,所有模型的损失值逐渐下降并最终收敛趋于稳定。LSTM 模型和 BLSTM 模型收敛较快,但 loss 函数最终收敛的值偏大,说明这两种模型的学习能力较差。而 LRF-BLSTM 模型、LRF-BGRU-Attention 模型、LRF-BLSTM-Attention 模型的 loss 函数最终收敛的值较小,说明 ELM-LRF 与 BLSTM 模型的结合提高了模型的学习能力。

在这三种模型中,LRF-BLSTM 模型在训练约 90 轮后 loss 曲线趋于平稳,而 LRF-BGRU-Attention 模型和 LRF-BLSTM-Attention 模型的 loss 函数达到最终收敛大约需要经过 50 轮迭代训练。这说明注意力机制的引入加强了序列信息之间的关联性,进一步优化了模型的特征表达能力,从而使得 loss 函数达到收敛所需的迭代次数降低。

各模型在 CCDD 上的识别结果如表 2 所示。可以看出,LSTM 模型的识别准确率为 75.43%,BLSTM 模型的识别准确率为 75.91%,这是因为单项 LSTM 模型只能学习时间序列的历史信息,而 BLSTM 模型能够同时学习历史和未来的信息,优化了模型的特征表达能力,因此接下来的实验中均采用 BLSTM 层 LRF-BLSTM-Attention 模型的 loss 值比 LRF-BGRU-Attention 模型低,说明 LRF-BLSTM-Attention 模型具有更好的特征表达能力。相较于其他对比模型,所提出的 LRF-BLSTM-Attention 模型的灵敏度和识别准确率均最高,分别为 89.32% 和 86.12%。同时,可以发现使用未去噪数据的 LRF-BLSTM-Attention 模型(No Denoising)准确率为 84.26%,相较于使用去噪数据的 LRF-BLSTM-Attention 模型准确率较低,证

明了所提出的去噪算法(基于 EWT 的提升小波阈值去噪方法)的实用性。

表 2 不同算法在 CCDD 上的识别结果 %

模型	特异性	灵敏度	准确率
LSTM	74.20	76.67	75.43
BLSTM	72.07	79.77	75.91
LRF-BLSTM	80.13	87.09	83.59
LRF-BGRU-Attention	84.14	84.19	84.17
No Denoising	83.22	85.30	84.26
LRF-BLSTM-Attention	82.94	89.32	86.12

表 3 列出了不同算法训练一轮的时间。可以看出,LSTM 在 CCDD 数据上训练一轮所需要的时间是 41 s,BLSTM 需要 61 s。对比 LSTM 模型和 BLSTM 模型,LRF-BLST 模型训练一轮仅需要 29 s,这是因为 LRF 模型能够通过卷积和池化操作减少输入特征的维数,进而减少训练时间。LRF-BGRU-Attention 模型训练一轮的时间为 27 s,比 LRF-BLSTM 模型的时间少,这是因为 BGRU 模型比 BLSTM 模型的复杂度更低,但是 BGRU 模型的震荡幅度较大,说明该模型的稳定性较差。LRF-BLSTM-Attention 模型训练一轮的时间为 45 s,比 LRF-BLSTM 所需的时间多,说明进入注意力机制的 LRF-BLSTM-Attention 模型复杂度更高,所需的训练时间更长。由图 5 和表 3,相比于其他对比模型,LRF-BLSTM-Attention 模型达到最小 loss 值所需要训练的轮数更少,loss 值也最小,因此,认为增加模型复杂度是有必要的。

表 3 不同算法训练一轮的时间对比

模型	时间/s
LSTM	41
BLSTM	61
LRF-BLSTM	29
LRF-BGRU-Attention	27
LRF-BLSTM-Attention	45

为了进一步评估所提出算法的性能,表 4 给出了在 CCDD 上多种模型的识别结果比较。Wang L P 等<sup>[24]</sup>提出了 ECG-MTHC (Multi-way Tree Based Hybrid Classifier,MTHC)模型,以牺牲特异性为代价,达到了较高的灵敏度,最终识别准确率为 77.70%。Jin L P<sup>[25]</sup>针对多导联心电图,设计了多导联卷积神经网络,达到了 83.66% 的识别准确率。Li H H<sup>[26]</sup>首先筛选异常数据,然后使用导联卷积神经网络进行分类,识别准确率达到 84.77%。与其他的识别算法比,LRF-BLSTM-Attention 模型的识别准确率最高,为 86.12%,特异性和灵敏度分别为 82.94% 和 89.32%。

该实验证明了 LRF-BLSTM-Attention 模型在计算机辅助心血管疾病诊断领域的实用性和高效性。

表 4 在 CCDD 上多种模型的识别结果比较 %

模型	特异性	灵敏度	准确率
Wang L P <sup>[23]</sup>	54.62	95.13	77.70
Jin L P <sup>[24]</sup>	83.43	83.84	83.66
Li H H <sup>[25]</sup>	84.45	85.19	84.77
LRF-BLSTM-Attention	82.94	89.32	86.12

## (2) MIT-BIH 数据集。

由于目前大多数心电识别算法的评估都是基于 MIT-BIH 数据集进行的,为了进一步验证所提出的 LRF-BLSTM-Attention 模型的性能,实验中也该模型用于 MIT-BIH 数据集的识别。在 MIT-BIH 数据库的识别任务中,一条心拍的长度为 250,因此模型的输入为 250×1,相比于 CCDD 数据集中一条记录的长度为 2 250 少了很多。为了防止在训练过程中丢失过多信息,实验中减小了池化层中的核的大小,其具体设计如表 5 所示。

表 5 MIT-BIH 数据库的 LRF-BLSTM-Attention 结构设计

名称	核大小	滤波器个数	输出大小
输入层	-	-	250×1
随机卷积层	7×1	4	244×4
最大池化层	2×1	4	122×4
随机卷积层	5×1	8	118×8
最大池化层	2×1	8	59×8
随机卷积层	6×1	16	54×16
最大池化层	2×1	16	27×16
BLSTM	64 nit	-	1×128
Attention	-	-	128×1
Dense	-	-	4

各模型的 loss 曲线如图 6 所示。对比其他模型,LRF-BLSTM-Attention 模型的 loss 曲线达到稳定状态所需的训练论数最少,并且达到的 loss 值最小,说明了所提出模型的优越性。




图 6 各模型的 loss 变化曲线



与大多数现有的心电图分类模型相比,所提出的算法具有优势。不同模型的识别结果如表6所示。Elhaj<sup>[27]</sup>通过多种特征提取方式进行特征提取并融合,利用SVM进行分类,得到98.91%的识别准确率;Acharya<sup>[6]</sup>通过9层的CNN实现心电信号的自动分类,识别准确率为94.03%;Yang<sup>[28]</sup>利用PCANet提取特征,并利用SVM分类,实现97.08%的识别准确率;Yang<sup>[29]</sup>结合ICA和PCANet对心电信号进行识别,识别准确率达到98.63%;在之前的文章中,利用LRF-BLSTM模型分别实现了99.32%,97.15%的准确率和灵敏度<sup>[30]</sup>。与对比模型相比,所提出的算法在MIT-BIH数据集上达到较高的识别准确率,为99.87%。

表6 MIT-BIH上不同模型识别结果

文献	识别方法	准确率/%
Elhaj <sup>[27]</sup>	PCA+DWT+HOS+ICA+SVM	98.91
Acharya <sup>[6]</sup>	CNN	94.03
Yang <sup>[28]</sup>	PCANet+SVM	97.08
Yang <sup>[29]</sup>	ICA+PCANet	98.63
Qiao <sup>[30]</sup>	LRF-BLSTM	99.32
文中	LRF-BLSTM-Attention	99.87

#### 4.5 结果分析

ELM-LRF能够学习心电信号的空间信息。卷积操作通过构建随机滤波器平滑时间序列,学习其特征表示;池化操作能够去掉冗余特征,减小输入的特征维数,具有平移不变性、旋转不变性和尺度不变性等特点。BLSTM模型能够充分学习历史和未来的时间信息,获得序列的时间特征表示。LRF-BLSTM模型结合ELM-LRF模型和BLSTM模型的优点,使得模型的识别效率提高。在LRF-BLSTM中引入注意力机制,能够加强当前时间信息与历史、未来信息的关联性,利用分配注意力权重的大小凸显特征向量的重要程度,从而进一步优化模型的特征提取和表达能力。因此,所提出的LRF-BLSTM-Attention模型能够强化心电信号的特征表示,实现较高的识别准确率,在CCDD和MIT-BIH数据集上分别达到了86.12%和99.87%。

在时间复杂度方面,由于ELM-LRF模型能够降低输入特征的维数,减少训练时间,因此LRF-BLSTM模型训练一轮所需的时间比单一的BLSTM模型少。LRF-BLSTM-Attention模型由于引入了注意力机制,使得模型复杂度增加,但loss曲线收敛速度加快,总体训练时间减少。

实验结果表明,LRF-BLSTM-Attention模型在心血管疾病的计算机临床辅助诊断中具有较好的实用性和计算效率。

#### 5 结束语

针对心电图识别问题,提出了一种基于EWT的提升小波阈值去噪方法,并设计了LRF-BLSTM-Attention模型。ELM-LRF、BLSTM和注意力机制的结合能够提高模型的特征提取能力,进而提高识别准确率。分别在CCDD和MIT-BIH数据集上进行实验,识别准确率分别为86.12%和99.87%,验证了LRF-BLSTM-Attention模型在心电图识别问题上的优势。注意力机制的引入增加了模型复杂度,在未来的心电图识别中,将进一步改进该模型,降低时间复杂度,处理更多、更复杂的心电图数据。

#### 参考文献:

- [1] 张绘娟,张达敏,闫威,等.基于改进阈值函数的小波变换图像去噪算法[J].计算机应用研究,2020,37(5):1545-1548.
- [2] 章原发,张京晶,高婕.基于数字滤波的图像去噪方法[J].现代计算机,2020,31(1):58-63.
- [3] 张迅,李决龙,邢建春,等.基于混沌蜂群算法的高耸结构振动信号小波阈值去噪方法研究[J].建筑结构学报,2016,37(1):467-474.
- [4] SINGH O, SUNKARIA R K. ECG signal denoising via empirical wavelet transform[J]. Australasian Physical & Engineering Sciences in Medicine, 2017, 40(1): 219-229.
- [5] SAI R, MESSAOUD M B, KACHOURI A, et al. Analysis of the electrocardiogram signal by the lifting scheme[C]//Proceedings of international symposium on control, communications and signal processing. Hammamet: IEEE, 2004: 263-266.
- [6] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats[J]. Computers in Biology and Medicine, 2017, 89: 389-396.
- [7] CHAUHAN S, VIG L. Anomaly detection in ECG time signals via deep long short-term memory networks[C]//Proceedings of the IEEE international conference on data science and advanced analytics. Paris: IEEE, 2015: 1-7.
- [8] OH S L, NG E Y, TAN R S, et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats[J]. Computers in Biology & Medicine, 2018, 102: 278-287.
- [9] 吴建章,梅飞,潘益,等.基于改进经验小波变换的电能质量扰动检测新方法[J].电力自动化设备,2020,40(6):142-148.
- [10] 张帆,张峰,张士文.基于提升小波的时间序列分析法的电力负荷预测[J].电气自动化,2017,39(3):72-76.
- [11] LI Wei, LI Bin, MENG Hailong, et al. The QRS complex detection of ECG signal based on IPCMM algorithm[C]//Proceedings of the 39th Chinese control conference. [s. l.]: IEEE, 2020: 6225-6230.



- [12] HUANG G, BAI Z, KASUN L, et al. Local receptive fields based extreme learning machine[J]. IEEE Computational Intelligence Magazine, 2015, 10(2): 18–29.
- [13] GREGOR K, DANIHELKA I, GRAVES A, et al. DRAW: a recurrent neural network for image generation[C]//Proceedings of international conference on machine learning. Lille: PMLR, 2015: 1462–1471.
- [14] 张默涵. 基于字词混合向量的 CNN-LSTM 短文本分类[J]. 信息技术与信息化, 2019(1): 77–80.
- [15] 于惠鸣, 张智晟, 龚文杰, 等. 基于深度递归神经网络的电力系统短期负荷预测模型[J]. 电力系统及其自动化学报, 2019, 31(1): 112–116.
- [16] CHEN K, WANG R, UTIYAMA M, et al. Neural machine translation with sentence-level topic context[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2019, 27(12): 1970–1984.
- [17] 刘航, 汪西莉. 基于注意力机制的遥感图像分割模型[J]. 激光与光电子学进展, 2020, 57(4): 162–172.
- [18] 卢玲, 杨武, 王远伦, 等. 结合注意力机制的长文本分类方法[J]. 计算机应用, 2018, 38(5): 1272–1277.
- [19] LI L T, XU W Z, YU H. Character-level neural network model based on nadam optimization and its application in clinical concept extraction[J]. Neurocomputing, 2020, 414: 182–190.
- [20] ZHANG J W, LIU X, DONG J. CCDD: an enhanced standard ECG database with its management and annotation tools[J]. International Journal on Artificial Intelligence Tools, 2012, 21(5): 672–676.
- [21] MARK R, MOODY G. MIT-BIH arrhythmia database[EB/OL]. (2005-02-24). <http://ecg.mit.edu/dbinfo.html>.
- [22] 许金茹, 马奎庭. YY 1139-2000 单道和多道心电图机版 1.0[S]. 北京: 中国标准出版社, 2000.
- [23] PAN J, TOMPKINS W J. A real-time QRS detection algorithm[J]. IEEE Transactions on Biomedical Engineering, 1985, 32(3): 230–236.
- [24] 王丽苹. 融合领域知识的心电图分类方法研究[D]. 上海: 华东师范大学, 2013.
- [25] JIN L P, DONG J. Deep learning research on clinical electrocardiogram analysis[J]. Science China: Information Sciences, 2015, 45(3): 398–416.
- [26] LI H H, JIN L P. An ECG classification algorithm based on heart rate and deep learning[J]. Space Medicine & Medical Engineering, 2016, 29(3): 189–194.
- [27] ELHAJ F A, SALIM N, HARRIS A R, et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals[J]. Computer Methods and Programs in Biomedicine, 2016, 127: 52–63.
- [28] YANG W, SI Y, WANG D, et al. Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine[J]. Computers in Biology and Medicine, 2018, 101: 22–32.
- [29] YANG W, SI Y, WANG D, et al. A novel method for identifying electrocardiograms using an independent component analysis and principal component analysis network[J]. Measurement, 2020, 152: 107363.
- [30] QIAO F J, LI B, ZHANG Y, et al. A fast and accurate recognition of ECG signals based on ELM-LRF and BLSTM algorithm[J]. IEEE Access, 2020, 8: 71189–71198.