

# 基于免疫堆叠降噪自编码机网络的运动想象脑电信号识别

郝矿荣, 原博炜, 陈磊<sup>†</sup>, 丁永生

(1. 数字化纺织服装技术教育部工程研究中心, 上海 201620; 2. 东华大学 信息科学与技术学院, 上海 201620)

**摘要:** 针对运动想象(MI)脑电信号识别精度低的实际问题, 提出一种结合免疫优化算法和决策机制的堆叠降噪自编码机网络(ISDAE)。ISDAE模型通过多层DAE对MI脑电信号分层提取最优特征向量, 再通过最后一层神经网络(NN)对所得特征向量进行识别; 同时, 添加决策机制, 并结合免疫优化算法对模型进行参数寻优, 最终得到识别准确率更高的ISDAE脑电信号识别模型。实验结果表明, 所提出的ISDAE模型对粗糙的脑电数据具有强大的特征学习能力和较高的MI脑电信号识别率, 可为MI脑电信号的识别提供一种有效的方法。

**关键词:** 堆叠降噪自编码机; 免疫优化算法; 决策机制; 运动想象; 脑电信号识别

中图分类号: TP242.6

文献标志码: A

## Recognition of motor imagery EEG based on immune stacked denoising auto-encoders network

HAO Kuang-rong, YUAN Bo-wei, CHEN Lei<sup>†</sup>, DING Yong-sheng

(1. Engineering Research Center of Digitized Textile & Apparel Technology of Ministry of Education, Shanghai 201620; 2. College of Information Science and Technology, Donghua University, Shanghai 201620, China)

**Abstract:** In order to solve the problem about the low classification accuracy of the motor imagery electroencephalography(EEG), this paper proposes an improved stacked denoising auto-encoders(ISDAE) network combined with the immune optimization algorithm and decision-making mechanism. The ISDAE network extractes the most effective feature vectors by multi-layer DAE, and then identifies these feature vectors by the neural network. Meanwhile, the decision-making mechanism is obtained, and the immune optimization algorithm is used to optimize parameters of ISDAE network, thus the improved ISDAE model with higher classification accuracy is obtained. The experimental results show that, the proposed ISDAE model has a strong ability for feature learning from raw EEG data and a higher recognition rate, which provides an efficient technique for the recognition of the motor imagery EEG.

**Keywords:** stacked denoising auto-encoders; immune optimization algorithm; decision-making mechanism; motor imagery; recognition of EEG

## 0 引言

随着计算机技术的飞速发展和在脑科学领域的不断延伸, 人们开始尝试搭建一种全新的不依赖大脑外围肌肉与神经组织的环境信息交互通道, 由此形成了脑-机接口(BCI)系统<sup>[1]</sup>。BCI系统为人们提供了只需依靠人脑思维的全新人机交互方式, 在辅助康复、交通控制、军事策略和游戏娱乐方面都有很大的研究应用价值<sup>[2-3]</sup>, 其中的关键技术就是实现对脑电信号的特征提取和识别分类。

目前, 脑电信号的特征提取和识别分类往往是独

立完成的, 其中常用的特征提取方法都集中在时域特征提取、频域特征提取和空域特征提取等方面<sup>[4-6]</sup>; 而有关识别分类的方法则包含神经网络<sup>[7]</sup>、支持向量机(SVM)<sup>[8]</sup>等算法。脑电信号的识别过程往往是对原始脑电信号进行预处理, 然后采用上述算法进行特征提取, 再采用相关的识别分类方法对提取到的特征向量进行模式分类。这一脑电信号识别流程已经在各种BCI系统中取得了良好的分类效果, 但是对于运动想象脑电信号(MI EEG)的识别, 上述方法仍存在过程复杂、对多维脑电数据适应度低、识别精度不够等

收稿日期: 2017-04-01; 修回日期: 2017-06-20.

基金项目: 科技部国家重点研发计划项目(2016YFB0302701); 国家自然科学基金项目(61473078); 上海市科学技术委员会国际合作项目(16510711100); 教育部长江学者奖励计划项目(2015-2019).

责任编委: 侯忠生.

作者简介: 郝矿荣(1964—), 女, 教授, 博士生导师, 从事机器视觉、模式识别、智能机器人等研究; 原博炜(1992—), 男, 硕士生, 从事智能系统、生物智能、智能机器人的研究.

<sup>†</sup>通讯作者. E-mail: leichen@dhu.edu.cn

问题<sup>[9]</sup>.

针对这一问题,本文提出结合免疫优化算法和决策机制进行改进的堆叠降噪自编码网络(SDAE),利用该网络模型可以得到更优的MIEEG识别效果.SDAE将多个降噪自编码器(DAE)堆叠起来形成深度神经网络,用来对粗糙的原始数据进行高效的特征提取,具备强大的分类能力<sup>[10]</sup>,而免疫优化算法是基于生物免疫学和基因进化机理构建的一类高效优化搜索算法.本文采用免疫优化算法对堆叠降噪自编码器进行关键参数优化,并添加多重决策机制,最终形成更为高效准确的改进堆叠降噪自编码网络(ISDAE)模型,实现对运动想象脑电信号粗糙数据的特征学习和准确识别,并与支持向量机、深度信念网络(DBN)等模型进行比较.实验结果表明,ISDAE模型能够在一定程度上提高准确率,相比于传统方法,该模型提供了一种有效的算法.

## 1 决策分类堆叠降噪自编码模型

### 1.1 运动想象脑电信号数据集

本文中运动想象实验数据来自第3届国际BCI竞赛数据集data set III,该数据集由奥地利Graz科技大学提供.该数据集对应的实验任务为:3个身体健康的测试者根据视觉提示想象左手、右手、脚部或者舌部运动<sup>[11]</sup>.脑电信号的采集频率为250 Hz,经过1~50 Hz初始滤波,采集导联取用60个通道.

### 1.2 降噪自编码器

传统自编码器在不添加生成约束的条件下,容易陷入输入向量到输出向量只产生微小改动的困境,这往往会造成模型的性能表现很差<sup>[12]</sup>.为此,需要在自编码器的基础上,给输入项加入噪声干扰,构成DAE,提高模型的鲁棒性和准确性.

对于DAE的算法结构,设原始输入数据为 $\mathbf{x}$ ,加入高斯随机噪声以后得到含噪输入 $\tilde{\mathbf{x}}$ ,如下所示:

$$\tilde{\mathbf{x}} = \mathbf{x} + \varepsilon, \varepsilon \sim N(0, \sigma^2 I). \quad (1)$$

根据编码函数 $f$ 将含噪输入进行函数映射,得到隐含层输出,即得到特征表达 $\mathbf{h}$ ,编码过程表达为

$$\mathbf{h} = f(\tilde{\mathbf{x}}) = s_f(\mathbf{w}\tilde{\mathbf{x}} + \mathbf{p}). \quad (2)$$

其中: $s_f$ 为编码器激活函数,通常取用Sigmoid函数.

得到特征表达 $\mathbf{h}$ 后,将 $\mathbf{h}$ 作为输入,通过解码函数 $g$ 映射到输出层,得到输入数据的重构 $\mathbf{y}$ ,解码过程表达为

$$\mathbf{y} = g(\mathbf{h}) = s_g(\tilde{\mathbf{w}}\mathbf{h} + \mathbf{q}). \quad (3)$$

其中: $s_g$ 为解码器激活函数,通常也取用Sigmoid函

数;权值矩阵 $\tilde{\mathbf{w}}$ 通常取 $\mathbf{w}^T$ .

整个过程中,通过对网络参数 $\{\mathbf{w}, \mathbf{p}, \mathbf{q}\}$ 的不断训练,使得 $\mathbf{y}$ 和 $\mathbf{x}$ 尽可能接近,网络的损失函数定义为重构误差,即

$$J_{\text{DAE}}(\mathbf{w}, \mathbf{p}, \mathbf{q}) = \sum_{\mathbf{x} \in S} L(\mathbf{x}, g(f(\tilde{\mathbf{x}}))) = - \sum_{i=1}^n [x_i \ln(g(f(\tilde{x}_i))) + (1 - x_i) \ln(1 - g(f(\tilde{x}_i)))] \quad (4)$$

通过梯度下降法对上述损失函数作最小化处理,即可求得对应的网络参数 $\{\mathbf{w}, \mathbf{p}, \mathbf{q}\}$ ,进而得到完整的DAE.

### 1.3 堆叠降噪自编码分类模型

相对于传统的浅层神经网络而言,深度网络具有更多的非线性隐含层,进而可以逐层提取特征向量,得到更具表达能力的高维特征向量,提高网络的分类性能.因此,本文在DAE的基础上,由下向上逐层构建DAE,使得上一层DAE隐含层的输出作为下一层DAE隐含层的输入,最终得到具有深度网络结构的堆叠降噪自编码器<sup>[12]</sup>.由于SDAE不具备分类能力,本文于SDAE的最顶层添加具有分类能力的神经网络层(NN),即得到具有良好分类能力的堆叠降噪自编码分类模型.对于SDAE深度分类网络的训练,可以分为预训练和微调整,说明如下.

预训练:以无监督的方式逐层训练深度网络,每一层的输出作为下一层的输入,且将每一层的输出与其输入作最小化重构误差.

微调整:根据预训练的结果对权值和偏置等网络参数进行初始化,随机选取有标签的样本采用BP算法对深度网络进行有监督训练,根据输出与输入之间的重构误差修正权值和偏置,直至满足相应的性能指标.

### 1.4 利用决策机制对模型改进

SDAE分类网络将多类运动想象脑电信号进行分类识别.然而,由于脑电信号具有差异性、复杂性和多维性,SDAE分类网络面对众多不同的脑电样本可能会出现性能下降,为保证分类性能的稳定性,进一步提高准确率,本文引入多专家决策机制对分类模型加以改进<sup>[13]</sup>.

根据多专家决策机制,本文构建多个SDAE分类网络,每次随机取定2/3样本对各个SDAE网络进行训练优化,进而得到一个由多个SDAE分类器构成的决策分类网络,该网络的结构示意如图1所示.

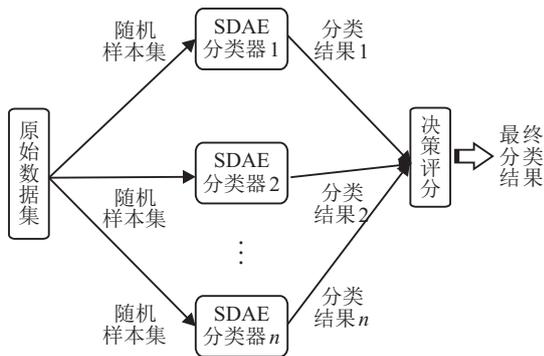


图1 决策分类网络结构

综上所述,在执行脑电信号的识别过程中,会得到由多个SDAE分类器得到的分类结果.将众多的分类结果输入决策评分器中,得到各分类结果的评分表达式

$$\text{Score}_i = \frac{n_i}{k}. \quad (5)$$

其中:  $\text{Score}_i$  为每类结果的得分;  $n_i$  为第  $i$  类结果在所有分类结果中出现的次数,可知  $i \in (1, 2, 3, 4)$ , 分别表示想象左手、右手、脚部和舌部的运动;  $k$  表示共有  $k$  个SDAE分类器的分类结果.由此即可根据某个样本分属于不同类别的得分进行分类.后续实验表明,决策机制的引入切实提高了模型的分类准确率和鲁棒性.

## 2 融合免疫优化机制的ISDAE算法

### 2.1 免疫优化算法

免疫优化算法是基于生物免疫系统识别多样性、免疫自我调节和免疫记忆特性而设计的<sup>[14-15]</sup>.其中,免疫遗传算法(IGA)模拟了生物免疫系统产生抗体抵御外来入侵抗原的自适应能力,把所解决问题的候选解看作抗体,待解决的问题看作抗原,利用抗体的浓度选择机制,实现对抗体的促进和抑制作用,进行抗体的多样性保持,最终得到最优搜索结果.

### 2.2 模型参数优化

已有研究表明,初始参数的设置对于SDAE分类网络的训练效果具有很大的影响<sup>[16]</sup>.对于特定的数据集,如果网络的隐层节点数、学习效率、含噪比例等关键参数的初始值设置不合适,则会使分类器的分类性能急剧下降.对于网络参数的初始化往往是根据设计者的经验设定的,这就造成了分类器性能的不确定性,且随着数据集的变化,分类器的鲁棒性也难以保证,因此本文在构建SDAE分类网络时,将IGA应用于参数优化,再将经过优化的网络参数用于构建分类网络,最终得到经过免疫算法优化提升的堆叠降噪自编码分类网络.

由于本文设计的SDAE分类网络含有两层隐含层,取定两个隐含层的神经元个数  $N_{h1}$ 、 $N_{h2}$ ,网络的学习效率  $\alpha$  和噪声添加比例系数  $\beta$  共计4个关键参数作为待优化参数.此后,将上述4个参数作为抗体生成;将网络的分类准确率作为适应度计算概率,分类准确率越高,适应度越大,反之则适应度越小.

另一方面,在IGA算法中,对优化结果存在影响的参数共涉及种群规模、记忆库容量、迭代次数、交叉概率和变异概率.其中,前3个参数取较大值会更利于找到最优解,但会造成时间复杂度变大.考虑到实时性需求,将种群规模设定为15,记忆库容量设定为5,迭代次数设定为200;而关于交叉概率(一般应大于等于0.5)和变异概率(一般小于0.5),进化前期的新个体主要由交叉操作产生,进化后期则是变异操作更易影响新生代,适当增加变异概率可以防止陷入局部最优解,考虑到本文欲搜寻全局最优解,将交叉概率设定为0.5,变异概率设定为0.4.

根据上述设定,采用IGA算法对4个参数进行迭代优化,利用优化结果构建分类模型,可得到经过IGA算法提升的ISDAE分类网络,再将所得ISDAE应用于图1所示的决策机制,替换原本的SDAE,即可实现最终的分类网络,进而得到更优的运动想象脑电信号的识别效果.

## 3 实验与分析

为了验证结合IGA算法和决策机制优化改进的ISDAE分类网络的性能表现,本文选用BCI大赛数据集,涉及3位实验者共18次实验的3568组数据.由于每组数据的采集情况基本相同,随机选取2854组样本作为训练集,剩余714组样本作为测试集,各自9等分后随机组合成9个不同的样本集,利用所得样本设计完成如下对比实验.

### 3.1 网络深度对于分类性能的影响

为了验证深度网络相对于传统浅层神经网络分类性能的优越性,本文采用传统的单隐含层的DAE和含有多隐含层的SDAE分别对样本数据集进行特征提取,所得特征向量输入结构相同的神经网络分类层,得到各自对应的分类结果,各样本集对应两种方法的识别正确率如表1中“浅层DAE”和“SDAE”对应的列区域所示.

从实验结果可以看出,面对不同样本,深层SDAE网络对应的88.17%平均分类正确率高于浅层DAE网络对应的81.15%.由此可以说明,深层网络相较于浅层网络,可以得到更具表达能力的高维特征向量,

表1 不同方式改进下的分类网络识别准确率比较

Method	浅层DAE	SDAE	决策-SDAE	ISDAE	CSP+SVM	DBN
Sample1	87.63	87.86	88.47	94.69	89.53	91.37
Sample2	84.22	90.20	94.92	94.67	93.60	74.78
Sample3	79.98	82.83	89.49	94.22	92.44	81.74
Sample4	87.37	94.76	95.98	97.55	87.79	92.36
Sample5	76.48	86.63	96.40	96.68	86.10	83.33
Sample6	65.56	80.12	94.85	96.98	93.89	82.56
Sample7	85.28	88.86	94.26	96.36	82.26	83.33
Sample8	87.35	96.36	97.66	96.66	86.91	83.91
Sample9	76.45	85.94	93.04	97.25	85.17	83.72
Average	81.15	88.17	93.90	96.12	88.73	84.13

进而可以提升分类准确率,有利于MI EEG信号的识别处理.

### 3.2 决策机制对于分类性能的提升

本文采用加入决策机制的SDAE网络和单一的SDAE网络分别对样本数据集进行特征提取和识别的对比实验,得到各自对应的识别正确率,如表1中“SDAE”和“决策-SDAE”对应的列区域所示.

从实验结果可以看出,决策机制使得SDAE网络对于样本的平均识别准确率由88.17%提升到93.90%,由此说明,多专家决策系统可以提升对于MI EEG信号的分类性能.同时,随着多专家决策机制的引入,样本识别率方差由26.98降低至9.56,大大减小了识别准确率波动,使得系统可以尽可能地减小由于样本差异带来的识别误差影响,提升了SDAE分类网络模型的鲁棒性.

### 3.3 免疫优化对于分类性能的提升

为了验证免疫优化对于分类性能的提升,本文同时建立两个引入决策机制的SDAE网络:其中一个SDAE网络在初始化时进行人工经验赋值,即针对两个隐含层的神经元个数 $N_{h1}$ 、 $N_{h2}$ ,网络的学习效率 $\alpha$ 和噪声添加比例系数 $\beta$ 等4个关键参数分别设置为50,30,0.1和0.5,引入决策机制后得到未经参数优化的SDAE分类模型;对于另一个SDAE网络则按照2.2节所述方法,采用IGA算法对初始化参数进行优化,得到的优化参数 $N_{h1}$ 、 $N_{h2}$ 、 $\alpha$ 和 $\beta$ 分别为78,7,0.5698和0.2129,引入决策机制后得到经过免疫优化的ISDAE分类模型.取这两个分类模型分别对样本数据集进行特征提取和识别的对比实验,得到各自对应的识别正确率,如表1中“决策-SDAE”和“ISDAE”对应的列区域所示.由此可以看出,免疫优化机制的引入使得分类模型进一步提升了识别准确性,使得ISDAE网络对于不同样本的MI EEG信号有了更优的识别性能表现.

### 3.4 ISDAE分类网络的性能优越性

为了验证基于免疫优化与决策机制的ISDAE网络在识别准确率上同样优于目前已有的主流分类算法,本文提出3种脑电信号处理方案以进行对比实验.

方案1:采用传统的特征提取和分类识别独立进行的识别流程,即首先采用CSP算法提取脑电信号的特征向量,再利用SVM算法对提取的特征向量进行识别,此处的SVM核函数采用RBF核函数.

方案2:采用深度置信网络(DBN)对脑电信号进行特征提取,再利用Softmax算法对特征向量进行识别分类,根据经验,这里设定的DBN网络拥有4层神经元.

方案3:采用本文提出的结合免疫算法和专家决策机制优化后的ISDAE分类网络对脑电信号进行识别处理,同样设定分类网络为4层结构.

根据不同受试者取用不同样本集,各样本在不同方法下的识别正确率如表1中“CSP+SVM”、“DBN”和“ISDAE”对应的列区域所示.

从实验结果可知,面对不同的运动想象脑电信号样本集,各种方法得出的识别准确率不尽相同:关于最优准确率与最差准确率之间的差别,CSP+SVM方法达到了11.63%,DBN网络达到了17.58%,而本文提出的改进ISDAE网络仅仅为3.33%.由此可见,融入决策机制和免疫优化的ISDAE网络具有更高的容错性和鲁棒性,可以更好地适应不同的样本集;另一方面,就总体平均识别准确率而言,ISDAE网络达到了96.12%,优于CSP+SVM和DBN算法,可见ISDAE网络不仅鲁棒性良好,而且拥有更优的分类性能.

## 4 结论

本文提出了结合免疫优化算法和决策机制改进的ISDAE深度分类网络.实验表明,该网络对于多类运动想象脑电信号具有较好的分类性能,在一定程度

上优于目前常用的分类方法. 同时, 面对不同的信号样本集, ISDAE 也具有良好的鲁棒性. ISDAE 分类网络为多类运动想象脑电信号的分类识别提供了一种有效的方法.

未来可以从以下几个方面进行更深入的探究: 优化网络结构和算法, 提高分类网络的学习速度以及增强实时性; 优化更多的网络参数, 提高稳定性和准确率, 以应对更复杂的脑电信号分析.

#### 参考文献(References)

- [1] 王行愚, 金晶, 张宇, 等. 脑控: 基于脑-机接口的人机融合控制[J]. 自动化学报, 2013, 39(3): 208-211.  
(Wang X Y, Jin J, Zhang Y, et al. Brain control: Man-machine fusion control based on brain-computer interface[J]. Acta Automatica Sinica, 2013, 39(3): 208-211.)
- [2] Ortner R, Allison B Z, Korisek G, et al. An SSVEP BCI to control a hand orthosis for persons with tetraplegia[J]. IEEE Trans on Neural Systems & Rehabilitation Engineering, 2011, 19(1): 1-5.
- [3] Escolano C, Antelis J M, Minguez J. A telepresence mobile robot controlled with a noninvasive brain-computer interface[J]. IEEE Trans on Systems Man & Cybernetics Part B, 2012, 42(3): 793-804.
- [4] Li M, Chen W, Zhang T. Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble[J]. Biomedical Signal Processing & Control, 2017, 31: 357-365.
- [5] Chuang C H, Ko L W, Lin Y P, et al. Independent component ensemble of EEG for brain-computer interface[J]. IEEE Trans on Neural Systems and Rehabilitation Engineering, 2014, 22(2): 230-238.
- [6] Wang X H. Optimizing spatial filters for single-trial EEG classification via a discriminate extension to CSP: The fisher criterion[J]. Medical and Biological Engineering and Computing, 2011, 49(9): 997-1001.
- [7] Mkh H, Erfanian A. An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network[J]. Medical Engineering & Physics, 2010, 32(7): 730-739.
- [8] Berta R, Bellotti F, De Gloria A, et al. Electroencephalogram and physiological signal analysis for assessing flow in games[J]. IEEE Trans on Computational Intelligence and AI in Games, 2013, 5(2): 164-175.
- [9] Kevric J, Subasi A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system[J]. Biomedical Signal Processing & Control, 2017, 31: 398-406.
- [10] 潘广源, 柴伟, 乔俊飞. DBN网络的深度确定方法[J]. 控制与决策, 2015, 30(2): 256-260.  
(Pan G Y, Chai W, Qiao J F. Calculation for depth of deep belief network[J]. Control and Decision, 2015, 30(2): 256-260.)
- [11] Schlögl A, Lee F, Bischof H, et al. Characterization of four-class motor imagery EEG data for the BCI-competition 2005[J]. J of Neural Engineering, 2005, 2(4): 14-22.
- [12] Vincent P, Latochelle H, Lajoie I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. The J of Machine Learning Research, 2010, 11: 3371-3408.
- [13] 周延年, 朱怡安. 基于灰色系统理论的多属性群决策专家权重的调整算法[J]. 控制与决策, 2012, 27(7): 1113-1116.  
(Zhou Y N, Zhu Y A. Algorithm for adjusting weights of decision-makers in multi-attribute group decision-making based on grey system theory[J]. Control and Decision, 2012, 27(7): 1113-1116.)
- [14] Ding Y S, Hu Z H, Zhang W B. Multi-criteria decision making approach based on immune co-evolutionary algorithm with application to garment matching problem[J]. Expert Systems with Applications, 2011, 38(8): 10377-10383.
- [15] Han H, Ding Y S, Hao K R, et al. Liang, An evolutionary particle filter with the immune genetic algorithm for intelligent video target tracking[J]. Computers & Mathematics with Applications, 2011, 62(7): 2685-2695.
- [16] Luo S, Zhu L, Althoefer K et al. Knock-knock: Acoustic object recognition by using stacked denoising autoencoders[J]. Neurocomputing, 2017, 267: 18-24.

(责任编辑: 闫妍)