

文章编号:1001-9081(2014)02-0496-05

doi:10.11772/j.issn.1001-9081.2014.02.0496

## 基于量子免疫克隆算法的神经网络优化方法

祁 浩<sup>1\*</sup>, 王福豹<sup>1</sup>, 邓 宏<sup>2</sup>, 段渭军<sup>1</sup>, 赵 昆<sup>3</sup>, 王 亮<sup>3</sup>, 马 颖<sup>1</sup>

(1. 西北工业大学电子信息学院, 西安 710072; 2. 西安元智系统技术有限责任公司, 西安 710077;

3. 秦始皇帝陵博物院 保管部, 西安 710600)

(\*通信作者电子邮箱 qihao8205@163.com)

**摘要:**为降低神经网络的冗余连接及不必要的计算代价,将量子免疫克隆算法应用于神经网络的优化过程,通过产生具有稀疏度的权值来优化神经网络结构。算法能够有效删除神经网络中的冗余连接和隐层节点,并同时提高神经网络的学习效率、函数逼近精度和泛化能力。该算法已应用于秦始皇帝陵博物院野外文物安防系统。经实际检验,算法提高了目标分类概率,降低了误报率。

**关键词:**神经网络;量子免疫克隆算法;目标分类;冗余连接;网络优化

**中图分类号:** TP273    **文献标志码:**A

### Quantum-inspired clonal algorithm based method for optimizing neural networks

QI Hao<sup>1\*</sup>, WANG Fubao<sup>1</sup>, DENG Hong<sup>2</sup>, DUAN Weijun<sup>1</sup>, ZHAO Kun<sup>3</sup>, WANG Liang<sup>3</sup>, MA Ying<sup>1</sup>

(1. School of Electronics and Information, Northwest Polytechnical University, Xi'an Shaanxi 710072, China;

2. Microwise System Company Limited, Xi'an Shaanxi 710077, China;

3. Department of Storage, Emperor Qinshihuang's Mausoleum Site Museum, Xi'an Shaanxi 710600, China)

**Abstract:** In order to reduce the redundant connections and unnecessary computing cost, quantum-inspired clonal algorithm was applied to optimize neural networks. By generating neural network weights which have certain sparse ratio, the algorithm not only effectively removed redundant neural network connections and hidden layer nodes, but also improved the learning efficiency of neural network, the approximation of function accuracy and generalization ability. This method had been applied to wild relics security system of Emperor Qinshihuang's mausoleum site museum, and the results show that the method can raise the probability of target classification and reduce the false alarm rate.

**Key words:** neural network; quantum-inspired clonal algorithm; target classification; redundant connection; network optimization

## 0 引言

神经网络已经被广泛地应用于模式分类、函数逼近、信号预测等各种领域,是近年来的研究热点之一<sup>[1-2]</sup>。在应用过程中,研究人员发现,当神经网络的规模过大时会产生连接数量冗余大、计算代价过高的问题,降低了大规模神经网络的实用性。针对此问题,研究人员提出了多种方法在保持神经网络的前提下优化神经网络的结构和参数权值。Leung 等<sup>[3-4]</sup>改进了传统的遗传算法(Genetic Algorithm, GA)并将其应用于神经网络的结构和权值优化过程,利用遗传算法的快速收敛性来提高神经网络的学习速度,其缺点在于当目标函数维数过大时容易陷入局部最优。Xiao 等<sup>[5]</sup>使用混合优点(Hybrid Good Point, HGP)优化前向神经网络的参数和结构,避免权值陷入局部最优,但其对网络结构的优化没有达到最优。Shu 等<sup>[6]</sup>提出正交模拟退火(Orthogonal Simulated Annealing, OSA)算法,使用退火算法和正交算法的优点来同时优化神经网络结构和参数,其算法收敛速度快、鲁棒性好,缺点则在于计算代价较大。杜文莉等<sup>[7]</sup>提出了使用量子差分进化(Cooperative Quantum Differential Evolution, CQDAE)算法来

优化神经网络权值,使用量子遗传算法优化网络结构和隐层节点数,算法综合了量子遗传算法和量子差分算法的优点,收敛速度快,但其缺点在于需要同时协同两种算法的优化结果,算法复杂度较高,且容易陷入局部最优。Tsai 等<sup>[8]</sup>提出混合田口遗传算法(Hybrid Taguchi Genetic Algorithm, HTGA),将传统的 GA 与 Taguchi 方法结合起来,使得算法具有鲁棒性好、收敛性快等优点,但其缺点在于获得最优解的计算代价较大。

量子免疫克隆算法<sup>[9-12]</sup>(Quantum-inspired Immune Clonal Algorithm, QICA)也称为量子遗传算法(Quantum Genetic Algorithm, QGA),其将量子搜索机制和免疫算法克隆选择原理相结合,利用量子编码的叠加性和随机性构造抗体,利用遗传算法的克隆操作产生原始种群和克隆子群实现种群扩张,使搜索空间扩大,提高了局部搜索能力;同时借助全干扰交叉操作避免陷入局部最优。QICA 采用了多状态量子比特编码方式和通用的量子旋转门操作,引入动态调整旋转角机制和量子交叉<sup>[11]</sup>。QICA 在组合优化问题中具有良好的表现。

针对上述问题,提出了使用量子克隆免疫算法对神经网络的结构和连接权值同时进行优化,通过产生具有一定稀疏

收稿日期:2013-08-02;修回日期:2013-11-06。 基金项目:国家科技支撑计划项目(2010BAK67B09,2012BAK14B01)。

作者简介:祁浩(1982-),男,甘肃兰州人,博士研究生,主要研究方向:无线传感器网络、目标分类;王福豹(1964-),男,山西运城人,教授,主要研究方向:计算机网络、无线传感器网络;邓宏(1968-),男,陕西西安人,硕士,主要研究方向:计算机工程,无线传感网络、文化遗产保护。

度的连接权值对网络隐层数量和连接权值进行优化,提高了算法的效率和收敛速度,避免了算法陷入局部最优。

## 1 带开关权值的神经网络模型

在经典的神经网络理论中,网络结构在初始化后便不再变动,仅通过权值的变化来计算产生结果,这种算法增加了神经网络的结构复杂性,在实际应用中增加了计算结果的代价。Leung 等<sup>[3-4]</sup>提出了带开关权值的神经网络,通过调整开关的通断就能调整神经网络的结构和连接数量,从而减少计算代价。带开关权值的神经网络模型如图 1 所示<sup>[7]</sup>。

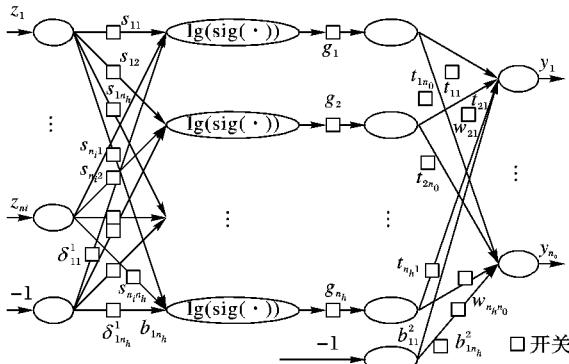


图 1 带开关权值的神经网络模型

图 1 所示的神经网络的输入输出关系如式(1)所示:

$$y_k(t) = \sum_{j=1}^{n_h} \omega_{jk} t_{jk} g_{nj} \lg \left( \text{sig} \left( \sum_{i=1}^{n_i} v_{ij} s_{ij} z_i(t) - b_{jl} \delta_{jl} \right) - \delta_{nl}^l \lg(\text{sig}(b_{nl}^2)) \right) \quad (1)$$

其中: $z_i(i=1,2,\dots,n_i)$ 为网络输入; $y_k(k=1,2,\dots,n_o)$ 为网络输出; $n_i$ 为输入变量数量; $n_o$ 为输出变量数量; $n_h$ 为隐层节点数量; $v_{ij}$ 为第*i*个输入与第*j*个隐层节点的连接权值; $\omega_{jk}$ 为第*j*个隐层节点与第*k*个输出层节点的连接权值; $b_{jl}$ 为隐层节点阈值, $b_{nl}$ 为输出层节点阈值; $g_{nj}$ 为隐层节点间的连接开关,为1时表示有此隐层节点,为0时表示无此隐层节点; $\delta_{jl}$ 和 $\delta_{nl}$ 表示隐层节点和输出层节点的阈值开关,开关值为1表示节点有连接,反之表示没有连接; $s_{ij}$ 为第*i*个输入和第*j*个隐层节点的连接开关。 $\lg(\text{sig}(\cdot))$ 表示 S 型对数函数:

$$\lg(\text{sig}(\alpha)) = \frac{1}{1 + e^{-\alpha}}; \alpha \in \mathbb{R} \quad (2)$$

## 2 基于 QICA 的神经网络优化方法

### 2.1 算法的改进

由式(1)可以看出, $v_{ij}s_{ij}$ 实际分别只有两种情况,如式(3)所示:

$$v_{ij}s_{ij} = \begin{cases} v_{ij}, & s_{ij} = 1 \\ 0, & s_{ij} = 0 \end{cases} \quad (3)$$

$\omega_{jk}t_{jk}$ 也具有同样的特点,若将连接开关 $s_{ij}$ 和 $t_{jk}$ 省去,在算法初始化连接权值时将 $v_{ij}$ 和 $\omega_{jk}$ 生成为具有一定稀疏度的数据集,即该集合中有若干数量的权值为0,则同样可以达到减少隐层连接的目的,还可以减少计算代价。

改进后的神经网络输出为式(4):

$$y_k(t) = \sum_{j=1}^{n_h} \omega_{jk} \lg \left( \text{sig} \left( \sum_{i=1}^{n_i} v_{ij} z_i(t) - v_{ij} b_{jl} \right) - \right.$$

$$\left. v_{ij} \lg(\text{sig}(b_{nl}^2)) \right) \quad (4)$$

式中: $z_i(i=1,2,\dots,n_i)$ 为网络输入; $y_k(k=1,2,\dots,n_o)$ 为网络输出; $n_i$ 为输入变量数量; $n_o$ 为输出变量数量; $n_h$ 为隐层节点数量; $v_{ij}$ 为第*i*个输入与第*j*个隐层节点的连接权值; $\omega_{jk}$ 为第*j*个隐层节点与第*k*个输出层节点的连接权值; $\omega_{jl}$ 为输出节点阈值开关,计算时将其列为 $\omega_{jk}$ 的最后一个元素; $v_{ij}$ 为输入层节点*i*与隐层节点*j*连接权值, $v_{ij}$ 为隐层节点阈值开关,计算时将其列为 $v_{ij}$ 的最后一个元素; $b_{jl}$ 为隐层节点阈值; $b_{nl}$ 为输出层节点阈值。

### 2.2 权值计算及优化方法

根据量子克隆免疫理论,将神经网络权值计算及优化过程分为以下四个过程。

#### 2.2.1 权值抗体初始化

量子克隆免疫算法是基于量子计算和遗传算法组成的,其抗体的编码方式采用量子比特编码。一个抗体中的量子位的状态是不确定的,可以为0或1,其状态表示为式(5):

$$|\Psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (5)$$

其中 $\alpha, \beta$ 表示相应状态出现概率的两个复数,其关系为 $\alpha^2 + \beta^2 = 1$ 。

具有*n*个量子比特位的抗体可以描述为式(6):

$$\mathbf{q}_i^t = \begin{bmatrix} \alpha_1^t & \alpha_2^t & \cdots & \alpha_m^t \\ \beta_1^t & \beta_2^t & \cdots & \beta_m^t \end{bmatrix} \quad (6)$$

其中:*m*为量子位数,*t*表示种群代数。结合神经网络的应用实际来讲,*m*表示连接权值的数量。规模为*n*的量子种群表示为: $Q(t) = \{q_1^t, q_2^t, \dots, q_n^t\}$ , $Q(t)$ 即为神经网络权值优化的解空间。

#### 2.2.2 抗体编码

这里摒弃经典量子理论的坍塌观测解码方法,对式(6)中的量子位采用文献[9]方法进行实数编码,其规则如式(7)所示:

$$v_{ik} = 0.5 \cdot [rangeMax(1 + \alpha_{ik}) + rangeMin(1 - \alpha_{ik})]; \quad k = 1, 2, \dots, m \quad (7)$$

这使得抗体长度与神经网络连接权值的数目相同, $v_{ij}$ 就表示第*i*个输入节点与第*j*个隐层节点的连接权值。同理, $\omega_{jk}$ 也可以按照此种编码方法进行处理。

在进行实数编码后,算法按照预先设定的稀疏度随机选择 $k < m$ 个位置,将其权值置为0。

#### 2.2.3 抗体种群克隆

设克隆前的种群为 $Q(t) = \{q_1^t, q_2^t, \dots, q_n^t\}$ ,则克隆操作后的种群为 $\bar{Q}(t) = \{Q(t), C(t)\}$ ,其中 $C(t)$ 为克隆产生的抗体子群,其种群中的每个抗体的稀疏度与原种群抗体稀疏度相同,仅是位置发生了变化。 $C(t)$ 的种群规模采用轮盘赌方法,其克隆规模由式(8)给出:

$$m_i = \lceil n_c \cdot (f(q_i) / \sum_{k=1}^N f(q_k)) \rceil; i = 1, 2, \dots, N \quad (8)$$

式中: $m_i$ 为种群中第*i*个个体的克隆规模, $n_c$ 是与克隆规模无关且大于种群规模*N*的常数,本算法中设置为种群规模的1.5倍, $f(q_i)$ 为第*i*个抗体的适应度,「·」表示向上取整函数。

#### 2.2.4 抗体种群更新

量子克隆免疫算法中,量子抗体通过量子旋转门和全局交叉来实现更新操作。采用的量子旋转门如式(9):

$$U(\theta) = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \quad (9)$$

旋转角度  $\theta = k \cdot \frac{\pi}{maxgen}$ , 其中  $k \in [0.01\pi, 0, 15\pi]$ ,  $n$  为当前进化代数,  $maxgen$  为最大进化代数。

在进行量子旋转门进行更新的基础上, 为了构造更加健壮的交叉操作, 避免算法陷入局部最优, 算法采用了全干扰交叉操作。假设一个种群包含 5 个长度为 8 的抗体, 其具体交叉方法见表 1。

表 1 全干扰交叉操作

编号	抗体							
1	A(1)	E(2)	D(3)	C(4)	B(5)	A(6)	E(7)	D(8)
2	B(1)	A(2)	E(3)	D(4)	C(5)	B(6)	A(7)	E(8)
3	C(1)	B(2)	A(3)	E(4)	D(5)	C(6)	B(7)	A(8)
4	D(1)	C(2)	B(3)	A(4)	E(5)	D(6)	C(7)	B(8)
5	E(1)	D(2)	C(3)	B(4)	A(5)	E(6)	D(7)	C(8)

### 2.3 算法步骤及流程

本文算法流程如图 2 所示。

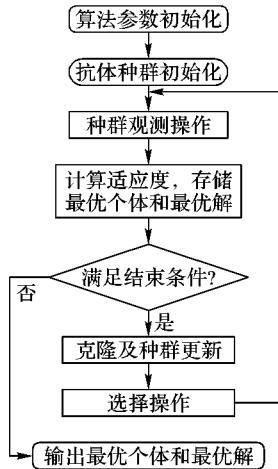


图 2 算法流程

算法具体过程如下:

1) 种群初始化。设置算法相关参数, 包括种群规模  $sizepop$ , 算法最大迭代次数  $maxgen$ , 种群稀疏度  $sparseratio$ 。

2) 根据预置参数产生原始种群, 种群中每个抗体的稀疏度均为  $sparseratio$ 。

3) 将式(4)计算得到的输出  $y$  与目标输出  $target$  代入式(10)计算适应度, 这里设目标输出为  $n$  维向量:

$$fitness = 0.5 \sum_{i=1}^n (y(i) - target(i))^2 \quad (10)$$

4) 对原有种群进行克隆及更新操作, 计算新种群的适应度值, 保留新种群中前  $sizepop$  个最优个体组成下一代种群。

5) 若没有达到算法停止条件, 则记录当前最优个体及最优结果, 然后转向步骤 3, 若达到停止条件, 则输出最优个体, 及抗体中权值为 0 的位置信息。

6) 根据抗体中数值为 0 的权值的位置信息, 对原有神经网络进行优化, 删除对应位置的隐层节点。

### 3 实验及结果分析

量子克隆免疫算法能够根据预设的稀疏度对神经网络进

行优化, 提高神经网络的计算速度, 降低计算复杂度。经过优化后的算法对典型的非线性函数进行逼近以及对微地震信号实现目标分类, 证明该方法的有效性。

#### 3.1 算法复杂度分析

量子克隆免疫算法的实质是通过量子理论的随机特性提供丰富的种群数量, 并通过使用遗传算法对种群进行淘汰和进化, 因此其算法的复杂度等于种群生成算法的复杂度: 假设神经网络有  $x$  个输入, 其隐层节点数量为  $N$ , 输出为  $y$ , 则网络中的输入与隐层节点间的连接权值  $\omega$  的数量为:  $x * N$ , 隐层节点与输出层的连接权值  $v$  的数量为:  $N * y$ 。种群生成需要对所有节点进行权值初始化, 并将随机位置的  $n$  ( $n \ll N$ ) 个节点的权值设置为 0, 其算法复杂度为  $O(n^2)$ 。而克隆免疫算法在种群克隆及抗体选择过程中使用遗传算法, 因此其算法的复杂度与传统遗传算法相同, 其算法复杂度也为  $O(n^2)$ 。因此, 使用量子免疫克隆的神经网络优化算法的复杂度为  $O(n^2)$ 。

#### 3.2 非线性函数逼近

选取复杂交互非线性函数 (Complicated Interaction Function, CIF):

$$y = 1.9(1.35 + e^{x_1} \sin(13(x_1 - 0.6))^2 e^{x_2} \sin(7x_2)) \quad (11)$$

其中  $0 < x_1, x_2 < 1$ 。非线性函数 CIF 经常用于检测神经网络的性能<sup>[13]</sup>。

选取样本 700 组, 其中 500 组用于训练, 其余 200 组用于检测性能。神经网络的初始隐层神经元设置为 20 个, 初始网络结构为: 2-20-1, 初始连接权值为随机值。在此条件下验证不同稀疏度条件下对 CIF 的二维逼近效果如图 3 所示。

图 3 显示随着稀疏度的不断降低, 神经网络的逼近能力有所减弱, 逼近误差则逐渐增大。这主要是因为神经网络中的连接权值数量降低, 造成神经网络的适应性差。具体逼近效果见表 2。

表 2 CIF 函数逼近效果

稀疏度	函数逼近精度/%	隐层节点数量
0.9	98.0	18
0.8	94.0	16
0.7	91.5	14
0.6	89.5	12

从表 2 中可以看出, 隐层节点数量直接影响着神经网络的性能。高稀疏度条件下的计算量大, 但逼近精度高; 低稀疏度条件下的计算量小, 但逼近精度较差。实验表明当稀疏度大于 0.6 时, 算法的逼近精度高于 90%, 优化后的网络具有较好的非线性逼近能力。当神经网络隐层节点数量低于 12 时逼近精度大幅下降, 说明此时神经网络处理信息的能力也随之大幅减弱, 隐层节点的最合适数量为 12~14 个, 这也符合文献[14]的实验结果。

图 4 为不同稀疏度下, 算法适应度的收敛情况。可以看出量子克隆免疫算法具有很好的收敛特性, 算法收敛速度很快, 能够在很短的进化次数内收敛至极值, 且稀疏度越低, 神经网络的连接权值数量越少, 算法收敛速度越低, 最优适应度越差。

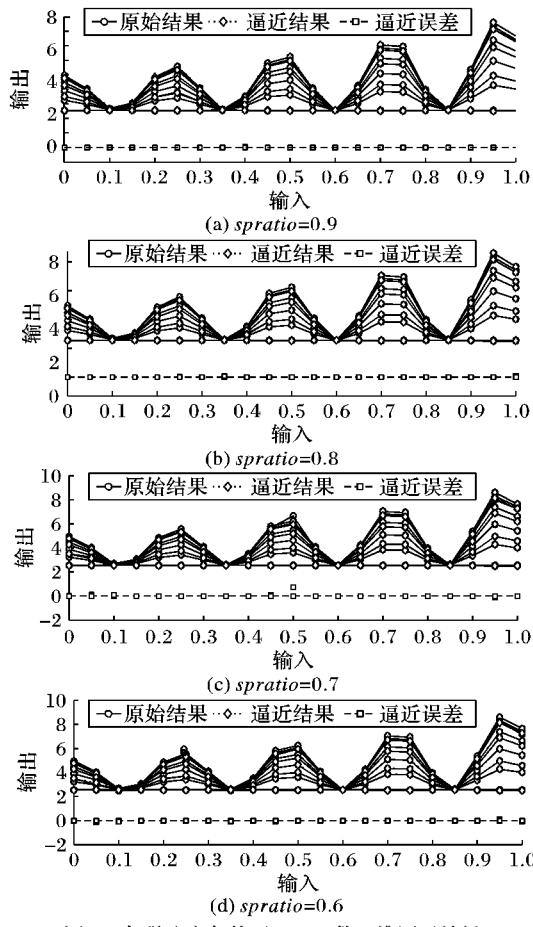


图3 各稀疏度条件下 CIF 函数二维逼近效果

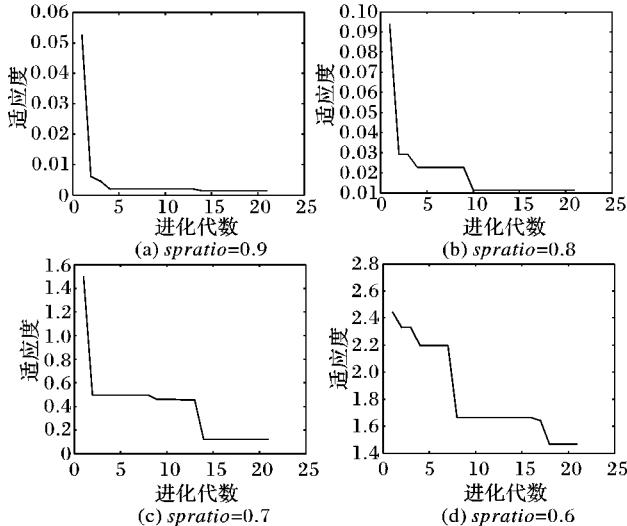


图4 不同稀疏度下算法收敛速度

表3为相同条件下,不同算法的最优计算结果,包括目标分类的准确度、隐藏层节点数量等。可以看出,当稀疏度高于0.8时,本文算法收敛性和适应度均优于混沌粒子群(Chaotic Particle Swarm Optimization, CPSO)<sup>[15]</sup>、粒子群优化算法(Particle Swarm Optimization, PSO)<sup>[16]</sup>、混合田口遗传算法[Hybrid Taguchi-Genetic Algorithm, HTGA]<sup>[8]</sup>等其他算法,说明算法具有很好的收敛速度、寻优精度和鲁棒性。

### 3.3 微地震信号目标分类

实验场地选择在秦始皇兵马俑博物馆内K9901号坑旁。

所有传感器节点沿公路一侧直线部署,距离公路1 m左右。可能产生地震波的活动物体包括人员行走、机动车和挖掘活动。将采集到的微地震信号进行滤波、分帧、特征提取等处理后输入至神经网络进行模式识别。

表3 不同算法的最优计算结果

算法	适应度	算法	适应度
本算法(spratio = 0.9)	$1.7 \times 10^{-4}$	CPSO	0.0450
本算法(spratio = 0.8)	0.0165	PSO	0.0460
本算法(spratio = 0.7)	0.125	CQGADE	0.0405
本算法(spratio = 0.6)	1.469	HTGA	0.0460

实验参数及算法参数设置如表4及表5所示。

表4 实验参数

项目	参数	项目	参数
传感器节点数量	5	通信频率	433 MHz
覆盖区域范围	$20\text{ m} \times 20\text{ m}$	数据包长度	50 B
网络拓扑结构	Star	通信频率	433 MHz
无线通信速率	<19 200 b/s	地质条件	夯土
土壤温度	20~29°C	土壤含水率	18%~29%
人员行走速度	0.7~1/(m/s)	车辆行驶速度	15~20 km/h
每秒挖掘数	2~3	传感器监测范围	<20 m

表5 算法参数

参数	值	参数	值
输入层节点数量	200	隐层初始化数量	300
输出层节点数量	3	训练数量	50
最大进化代数	20	种群规模	30

系统对传感器采集到的数据进行分帧,并使用功率谱二次分析<sup>[17]</sup>算法对其进行处理,最后将经过预处理的数据输入至神经网络对其进行分类。根据其活动特点,将输出目标分为三类:人员活动、挖掘活动以及机动车辆活动。传感器采集到的三类活动的经典波形如图5所示。

表6中给出了算法的最优计算结果,包括不同稀疏度条件下神经网络的隐藏层节点数量、最优适应度以及分类准确率等。可以看出,算法能够有效减少冗余的隐藏层节点数量,并降低节点连接数量。算法的稀疏度越高,其适应度越好,其分类的准确性越好,但稀疏度高带来的则是计算代价增大、计算复杂度增加。当稀疏度低于0.7时,算法的适应度变差,目标的识别率为90%,在实际应用过程中带来了误判率较高的问题,降低了实用性。因此在秦始皇帝陵博物院野外文物安防系统中使用了稀疏度为0.7的算法对模式识别的神经网络进行优化。

表6 算法计算结果

稀疏度	隐藏层 节点数	输入层与隐层 连接权值数量	隐层与输出层 连接权值数量	最优 适应度	分类准 确率/%
0.9	270	54 000	810	$1.7 \times 10^{-4}$	94.0
0.8	240	48 000	720	0.0165	93.5
0.7	210	42 000	630	0.125	92.0
0.6	180	36 000	540	1.469	90.0

### 4 结语

本文提出了基于量子免疫克隆算法的神经网络优化算

法,该算法在训练神经网络优化权值的同时删除了冗余连接和多余的隐层节点,实现了神经网络结构和网络权值的优化。通过经典非线性函数逼近和目标识别检验,算法能够有效地优化神经网络,提高神经网络的优化效率,减少计算复杂度。使用优化后的神经网络已经用于秦始皇帝陵博物院野外文物安防系统中。

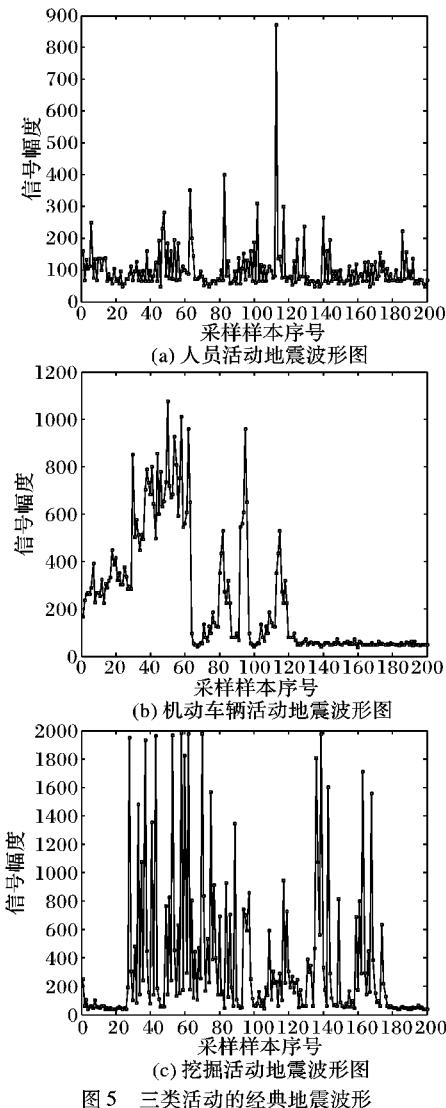


图5 三类活动的经典地震波形

#### 参考文献:

- [1] QIAO H, ZHOU Y, SHAO N, et al. Software reliability prediction based on learning vector quantization neural network[J]. Journal of Computer Applications, 2012, 32(05): 1436 – 1438. (乔辉, 周雁舟, 邵楠, 等. 基于学习向量量化神经网络的软件可靠性预测[J]. 计算机应用, 2012, 32(5): 1436 – 1438.)
- [2] PAN Y, DENG Y, ZHANG Q, et al. Deterministic prediction of wavelet neural network model and its application[J]. Journal of Computer Applications, 2013, 33(4): 1001 – 1005. (潘玉民, 邓永红, 张全柱, 等. 小波神经网络模型的确定性预测及应用[J]. 计算机应用, 2013, 33(4): 1001 – 1005.)
- [3] LEUNG H F, LAM H F, LING S F, et al. Tuning of the structure and parameters of neural network using an improved genetic algorithm[C]// Proceedings of the 27th Annual Conference of IEEE Industrial Electronics Society. Piscataway: IEEE, 2001: 25 – 30.
- [4] LEUNG H F, LAM H F, LING S H, et al. Tuning of the structure and parameters of a neural network using an improved genetic algorithm[J]. IEEE Transactions on Neural Network, 2003, 14(1): 79 – 88.
- [5] XIAO C, CAI Z, WANG Y, et al. Tuning of the structure and parameters of a neural network using a good points set evolutionary strategy[C]// Proceedings of the 9th International Conference for Young Computer Scientists. Piscataway: IEEE, 2008: 1749 – 1754.
- [6] SHU L, HO S Y, HO S J. Tuning the structure and parameters of a neural network using an orthogonal simulated annealing algorithm [C]// Proceedings of the 2009 Joint Conferences on Pervasive Computing. Piscataway: IEEE, 2009: 789 – 792.
- [7] DU W, ZHOU R, ZHOU L, et al. Cooperative quantum differential evolution algorithm based method for optimizing neural networks[J]. Journal of Tsinghua University: Science and Technology, 2012, 52(3): 331 – 335. (杜文莉, 周仁, 赵亮, 等. 基于量子差分进化算法的神经网络优化方法[J]. 清华大学学报: 自然科学版, 2012, 52(3): 331 – 335.)
- [8] TSAI J, CHOU J, LIU T. Tuning the structure and parameters of a neural network by using hybrid Taguchi-genetic algorithm[J]. IEEE Transactions on Neural Network, 2006, 17(1): 69 – 80.
- [9] LI Y, JIAO L. Quantum-inspired immune clonal algorithm and its application[C]// Proceedings of the 2007 International Symposium on Intelligent Signal Processing and Communication Systems. Piscataway: IEEE, 2007: 670 – 673.
- [10] JIAO L, LI Y, GONG M, et al. Quantum-inspired immune clonal algorithm for global optimization[J]. IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics, 2008, 38(5): 1234 – 1253.
- [11] ZHOU C, QIAN F. Improvement of quantum genetic algorithm and its application[J]. Journal of Computer Applications, 2008, 28(2): 286 – 288. (周传华, 钱峰. 改进量子遗传算法及其应用[J]. 计算机应用, 2008, 28(2): 286 – 288)
- [12] ZHOU Q, JIANG S, ZHAO X, et al. Improved quantum genetic algorithm and its application in test data generation[J]. Journal of Computer Applications, 2012, 32(2): 557 – 560. (周琦, 姜淑娟, 赵雪峰, 等. 改进的量子遗传算法及其在测试数据生成中的应用[J]. 计算机应用, 2012, 32(2): 557 – 560.)
- [13] QIAO J, LEE Y G, SCOTT D S, et al. Self-organizing radial basis function network for real-time approximation of continuous-time dynamical systems[J]. IEEE Transactions on Neural Networks, 2008, 19(3): 460 – 474.
- [14] HAN H, QIAO J, BO Y, et al. On structure design for RBF neural network based on information strength[J]. Acta Automatica Sinica, 2012, 38(7): 1083 – 1090. (韩红桂, 乔俊飞, 薄迎春, 等. 基于信息强度的RBF神经网络结构设计研究[J]. 自动化学报, 2012, 38(7): 1083 – 1090.)
- [15] ZHAO L. Fuzzy identification and neural networks learning based on cooperative PSO algorithm[D]. Shanghai: Shanghai Jiao Tong University, 2008. (赵亮. 基于协同PSO算法的模糊辨识与神经网络学习[D]. 上海: 上海交通大学, 2008.)
- [16] LI B C, SUN L. Neural network prediction based on particle swarm optimization[J]. Journal of Xinjiang University: Natural Science, 2007, 24(11): 481 – 485. (李丙春, 孙蕾. 基于粒子群优化的神经网络预测模型[J]. 新疆大学学报: 自然科学版, 2007, 24(11): 481 – 485)
- [17] QI H, WANG F, DENG H. A novel approach to research on feature extraction of seismic wave signal based on wireless sensor networks[J]. Acta Physic Sinica, 2013, 62(10): 270 – 277. (祁浩, 王福豹, 邓宏. 基于无线传感器网络的地震信号特征提取方法研究[J]. 物理学报, 2013, 62(10): 270 – 277.)