

## 基于层连优化的新型小世界神经网络

王爽心, 杨成慧

(北京交通大学 机械与电子控制工程学院, 北京 100044)

**摘要:** 对多层前向小世界神经网络的网络参数、权值修正策略以及网络结构进行改进, 提出一种基于层连优化的改进算法。通过对比现有各种不同形式的小世界神经网络, 验证了上述改进的必要性。仿真结果表明, 改进模型比现有小世界神经网络收敛速度更快, 逼近精度更高, 模型稳定性更强。

**关键词:** 小世界网络; 多层前向神经网络; 层连优化; BP算法; 函数逼近

中图分类号: TP273

文献标志码: A

### Novel small-world neural network based on topology optimization

WANG Shuang-xin, YANG Cheng-hui

(School of Mechanical, Electronic and Control Engineering, Beijing Jiaotong University, Beijing 100044, China.  
Correspondent: WANG Shuang-xin, E-mail: shxwang1@bjtu.edu.cn)

**Abstract:** Aiming at the method of adjusting weights, parameters and the structure of the network, an improved algorithm for the small-world neural network is proposed based on topology optimization. Simulation results show that the novel network model has a better performance of fast convergence rates, high approximation accuracy and strong stability on the comparison with different kinds of existed small-world neural networks.

**Key words:** small-world network; multilayer feed-forward neural network; topology optimization; BP algorithm; function approximation

### 0 引言

人工神经网络在节点种类、连接方式、实现功能等方面与生物神经网络有着较大差距。1998年, Watts和Strogatz<sup>[1]</sup>指出, 现实网络在结构上多为处于规则网络和随机网络之间的网络模型, 定义为WS小世界网络; 随后Newman和Watts<sup>[2]</sup>又对其进行改进, 提出了NW小世界网络模型。

小世界网络的提出, 为人工神经网络在拓扑结构上更趋同于生物神经网络提供了新的解决方案。例如Zheng等<sup>[3]</sup>、Morelli等<sup>[4]</sup>及Li<sup>[5]</sup>分别将小世界网络与Hopfield网络及Attractor网络相结合, 将新型网络应用于联想记忆及模式识别中, 并通过实践验证了新型网络模型连接冗余大大减少, 而学习速率明显加快的显著优点。

近年来, 针对函数逼近及统计预测问题, 多层前向小世界神经网络模型成为了该领域的研究热点。Li<sup>[6]</sup>对人工神经网络、生物神经网络以及小世界网络进行比较, 讨论了人工神经网络与小世界网络的结合

方法。Simard等<sup>[7]</sup>验证了小世界神经网络比规则网络和随机网络具有更快的收敛速度。Yang等<sup>[8]</sup>将WS小世界模型与神经网络相结合, 应用优化算法确定了隐含层的结构, 证明了该方法的优越性能。李小虎等<sup>[9]</sup>参考WS模型, 对多层前向规则神经网络中的连接依重连概率 $p$ 进行重连, 并借鉴函数逼近问题来揭示在不同重连概率下结构不同的神经网络的网络容错性能<sup>[10]</sup>。张瑞成<sup>[11]</sup>对NW小世界神经网络进行了研究, 但该方法只研究了加边概率对神经网络函数逼近性能的影响, 没有给出WS与NW小世界神经网络的优劣性对比。

上述研究表明, 小世界神经网络模型能够在很大程度上改进规则神经网络收敛速度慢、易陷入局部极小的缺点, 但上述改进的网络模型结构仍然比较简单, 网络模型的聚集系数偏低, 且可能孤立有用的神经元。同时缺乏对网络参数、拓扑结构等网络结构问题的优化设计, 尤其在解决模型辨识、统计预测等实际问题时, 网络的泛化能力和模型精度尚有欠缺。

收稿日期: 2012-09-21; 修回日期: 2012-12-02.

基金项目: 国家自然科学基金项目(50776005).

作者简介: 王爽心(1965—), 女, 教授, 博士生导师, 从事复杂系统智能控制、过程建模与优化等研究; 杨成慧(1989—), 男, 硕士生, 从事小世界神经网络及其应用的研究。

基于 WS 和 NW 两类典型多层前向小世界神经网络(以下简称小世界神经网络),本文提出了应用全局层连优化来改进网络结构的优化设计理念,构建了新型小世界神经网络模型.仿真结果表明,新型网络在收敛速度、逼近精度、模型稳定性等方面均优于规则神经网络及现有小世界神经网络.

## 1 WS 及 NW 多层前向小世界神经网络模型

基于文献[9, 11],本文对 WS 及 NW 小世界神经网络的模型建立过程归纳如下.

**Step 1:** 给定网络参数.神经网络层数为  $n$ , 输入层神经元个数为  $\text{num}_{\text{in}}$ , 隐含层神经元个数为  $\text{num}_{\text{hid}}$ , 输出层神经元个数为  $\text{num}_{\text{out}}$ , 重连概率为  $p$ . 命名输入层为第 1 层, 隐含层为第 2 层~第  $n$  层, 输出层为第  $n+1$  层.

**Step 2:** 生成规则多层前向神经网络的权值矩阵. 其中, 规则网络的隐含层权值矩阵  $W_{\text{hid}}$  为

$$W_{\text{hid}} = \begin{bmatrix} 0 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 0 & W^{(23)} & 0 & \cdots & 0 \\ 0 & 0 & 0 & W^{(34)} & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & W^{((n-1)n)} \end{bmatrix}, \quad (1)$$

$W^{(st)}$  为第  $s$  层到第  $t$  层的权值连接矩阵.

**Step 3:** 选定一条权值连接边  $W_{\text{hid}}(i, j, s, s+1)$ , ( $1 \leq i, j \leq \text{num}_{\text{hid}}$ ,  $2 \leq s \leq n-2$ ). 若  $\text{rand}(i, j, s) > p$ , 则转 Step 6, 否则继续.

**Step 4:** 选定新的权值连接目标层  $\text{newlayer}$  及神经元  $\text{newneuron}$ , 且满足条件

$$\begin{cases} 1 \leq \text{newneuron} \leq \text{num}_{\text{hid}}, \\ s+2 \leq \text{newlayer} \leq n, \\ W_{\text{hid}}(i, \text{newneuron}, s, \text{newlayer}) = 0. \end{cases} \quad (2)$$

**Step 5:** 若为 WS 网络, 则随机重连公式为

$$W_{\text{hid}}(i, \text{newneuron}, s, \text{newlayer}) = \begin{cases} W_{\text{hid}}(i, j, s, s+1), & \text{rand}(i, j, s) \leq p; \\ 0, & \text{rand}(i, j, s) > p; \end{cases} \quad (3)$$

$$W_{\text{hid}}(i, j, s, s+1) = \begin{cases} W_{\text{hid}}(i, j, s, s+1), & \text{rand}(i, j, s) > p; \\ 0, & \text{rand}(i, j, s) \leq p. \end{cases} \quad (4)$$

若为 NW 网络, 则随机加边公式只有式(3)而没有式(4).

**Step 6:** 若重连未完成, 则选定下一条需要重连的边, 并返回 Step 3, 否则算法终止.

调整后的隐含层权值矩阵变为

$$W_{\text{hid}} = \begin{bmatrix} 0 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 0 & W^{(23)} & W^{(24)} & \cdots & W^{(2n)} \\ 0 & 0 & 0 & W^{(34)} & \cdots & W^{(3n)} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & W^{((n-1)n)} \end{bmatrix}, \quad (5)$$

其中新添加的项即为跨层连接的权值.

## 2 多层前向小世界神经网络的结构优化设计

### 2.1 初始连接权值的选择

通常情况下, 网络初始权值应取  $(-1, 1)$ ,  $(0, 1)$  或  $(0, 2)$  之间的随机值. 对于多层前向神经网络, 若初始权值取  $(0, 1)$  或  $(0, 2)$  之间的随机数, 则因神经网络的逐层叠加效应, 激活函数的输入值在经过一定层数之后, 很可能超出激活函数的灵敏范围. 因此, 应考虑如下方法:

1) 选取  $(-1, 1)$  之间的随机值. 同时存在正值与负值的网络权值可抵消网络中不良的叠加效应.

2) 选取比  $(0, 1)$  范围更小的随机值. 按照网络节点的求和原理, 应选取初始权值为  $(0, 1/\text{num}_{\text{in}})$  或  $(-1/\text{num}_{\text{in}}, 1/\text{num}_{\text{in}})$ , 其中  $\text{num}_{\text{in}}$  为神经网络输入层神经元个数. 加入阈值的初始权值可将网络的累加值有效地限制在神经元激活函数的灵敏范围之内.

### 2.2 权值修正策略的改进

前向神经网络一般应用 BP 算法进行训练. 在误差反向传播阶段, 未能满足精度要求的误差信号由输出端开始, 以一定方式逐层向前传播, 并将误差分摊给各层的所有单元. 当网络层数较多时, 网络中每一层的权值调整值都较小, 使网络的收敛速度较慢. 因此, 将输出层的误差有效地分配到各层之中, 将会在一定程度上提高神经网络的收敛速度.

规则 BP 神经网络隐含层的误差计算公式为

$$\delta_p^{(k-1)} = f^{(k-1)'}(\text{net}_p)(w_{p1}\delta_1^k + \cdots + w_{pm}\delta_m^k) = f^{(k-1)'}(\text{net}_p) \cdot \sum_{q=1}^m w_{pq}\delta_q^k. \quad (6)$$

其中:  $\delta_p^{(k-1)}$  为第  $(k-1)$  隐含层神经元  $p$  的误差,  $f^{(k-1)'}$  为第  $(k-1)$  层神经元  $p$  激活函数的微分函数值,  $w_{pq}$  ( $q=1, 2, \dots, m$ ) 为第  $(k-1)$  层的神经元  $p$  到第  $k$  层神经元  $q$  的连接权值,  $\delta_q^k$  ( $q=1, 2, \dots, m$ ) 为第  $k$  层神经元  $q$  的误差.

若第  $k$  层为输出层, 则由于  $(k-1)$  层误差为输出层误差的直接反向传播, 根据式(6)计算及调整最为有效; 若第  $k$  层不为输出层, 则将式(6)修改为下式:

$$\delta_p^{k-1} = f^{(k-1)' }(\text{net}_p) \cdot \sum_{q=1}^m w_{pq}\delta_q^k +$$

$$f^{(k-1)'(\text{net}_p)} \cdot \sum_{s=1}^t w_{ps}^{n(n+1)} \delta_s^{n+1}. \quad (7)$$

其中:  $n$  为网络层数 ( $n+1$  层为输出层),  $t$  为输出层神经元个数,  $w_{ps}^{n(n+1)}$  ( $q = 1, 2, \dots, t$ ) 为第  $n$  层神经元  $p$  到输出层神经元  $s$  的连接权值,  $\delta_s^{n+1}$  ( $q = 1, 2, \dots, t$ ) 为输出层神经元  $s$  的误差. 式(7)将输出层的误差通过隐含层到输出层的权值加权直接反向传递到所有隐含层, 并与规则BP算法得出的误差值相叠加, 这使得网络对于位置较为靠前层的权值调整更加有效, 同时也减少了网络的学习次数.

### 2.3 输入与输出层的网络重构设计

实际应用中, 输入、隐含及输出层节点数目通常都不相同, 并且输出节点较少. 本文拟构建基于不同层间节点数及不同连接方式下的小世界神经网络, 使其更具普适性. 以输入、隐含及输出层节点数目分别为4、5、1的WS小世界神经网络模型为例来说明网络拓扑结构的优化设计.

1) 第1层(输入层)至第2层的连接参与重构的小世界神经网络如图1所示. 输入层至隐含层的权值应以三维矩阵  $W_{in}$  表示, 随机重连公式为

$$W_{in}(i, j, 2) = \begin{cases} W_{in}(i, j, 2), & \text{rand}(i, j, 2) > p; \\ 0, & \text{rand}(i, j, 2) \leq p; \end{cases} \quad (8)$$

$$W_{in}(i, \text{newneuron}, \text{newlayer}) = \begin{cases} W_{in}(i, j, 2), & \text{rand}(i, j, 2) \leq p; \\ 0, & \text{rand}(i, j, 2) > p. \end{cases} \quad (9)$$

其中  $W_{in}(i, j, k)$  表示输入层节点  $i$  至第  $k$  (隐含) 层节点  $j$  的连接权值.

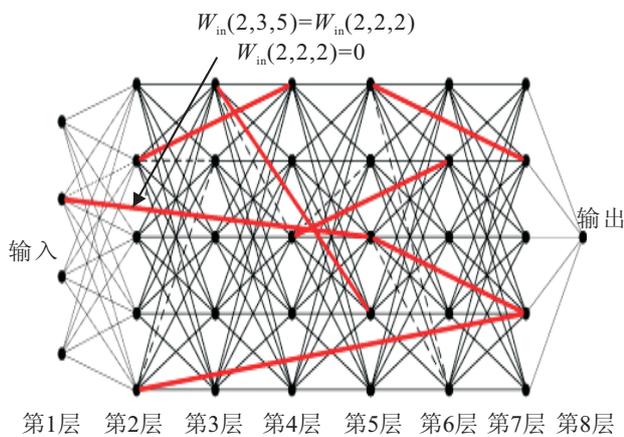


图1 输入层至隐含层连接参与重构的WS小世界神经网络

2) 第6层至第7层(最后1层为隐含层)的连接参与重构的小世界神经网络如图2所示. 根据第1节中的随机重连算法, 第6层至第7层的连接只能选取输

出层节点进行重连, 故设定输出层节点数为1. 此时, 若从第6层同一节点出发的两条边都需要重连, 则由于两节点间只能有一条边连接, 程序无法选出一个重连的终点, 这会使模型的建立过程进入死循环, 导致模型构建失败.

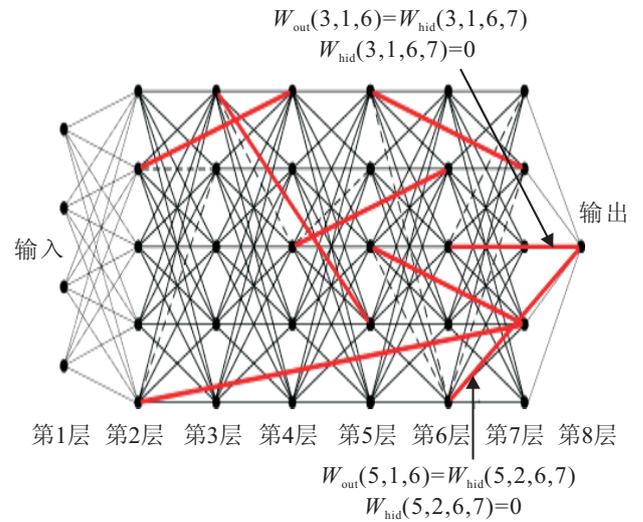


图2 隐含层至输出层连接参与重构的WS小世界神经网络

为了解决上述问题, 对重连步骤进行改进, 即增加用于检测选定连接的输入节点到所有输出层节点的连接判断环节. 若存在此连接, 则说明该节点的重连已经饱和, 不能继续选择该节点作为输入节点进行重连. 为了保证此次重连按判定的顺利进行, 应选择前面隐含层或输入层中未被重连的边实现重连过程.

隐含层至输出层权值  $W_{out}$  随机重连公式为

$$W_{out}(i, 1, n-1) = \begin{cases} W_{hid}(i, j, n-1, n), & \text{rand}(i, j, n-1) \leq p; \\ 0, & \text{rand}(i, j, n-1) > p; \end{cases} \quad (10)$$

$$W_{hid}(i, j, n-1, n) = \begin{cases} W_{hid}(i, j, n-1, n), & \text{rand}(i, j, n-1) > p; \\ 0, & \text{rand}(i, j, n-1) \leq p. \end{cases} \quad (11)$$

其中  $W_{out}(i, 1, n-1)$  表示第  $n-1$  (隐含) 层节点  $i$  至输出层节点 (只有一个) 的连接权值.

### 2.4 层内连接网络结构设计

针对文献[9]缺乏网络层内连接以致网络模型的聚集系数偏低的问题, 本文在隐含层中加入了层内两节点之间的权值连接. 在模型构建及计算过程中, 可将其等价为一前向网络模型. 该网络结构打破了规则网络中隐含层节点数相同的情况, 使其结构更加趋近于不规则的生物神经网络.

### 3 新型网络模型训练过程

#### 3.1 前向传播过程

神经网络每层输入分别为

$$\text{net}^k = \begin{cases} X \cdot W_{\text{in}}^k + \sum_{h=2}^{k-1} O^h \cdot W_{\text{hid}}^{hk} + \\ O^k \cdot W_{\text{self}}^k, & 2 \leq k \leq n-1; \\ X \cdot W_{\text{in}}^k + \sum_{h=2}^{k-1} O^h \cdot W_{\text{hid}}^{hk}, & k = n; \\ X \cdot W_{\text{io}} + \sum_{h=2}^n O^h \cdot W_{\text{out}}^h, & k = n+1. \end{cases} \quad (12)$$

其中:  $\text{net}^k$  为神经网络第  $k$  层的输入,  $X$  为输入向量,  $O^h$ 、 $O^k$  分别为神经网络第  $h$  层和第  $k$  层的输出.

神经网络每层的输出为

$$O^k = \begin{cases} f_{\text{hid}}(\text{net}^k), & 2 \leq k \leq n; \\ f_{\text{out}}(\text{net}^k), & k = n+1. \end{cases} \quad (13)$$

其中  $f_{\text{hid}}$  和  $f_{\text{out}}$  分别为隐含层和输出层的激活函数.

#### 3.2 误差反向传播过程

1) 神经元误差的计算.

用  $\text{delta}^{n+1}$  表示输出层神经元的误差, 其公式为

$$\text{delta}^{n+1} = f'_{\text{out}}(\text{net}^{n+1}) \odot (Y - O^{n+1}). \quad (14)$$

其中:  $\text{net}^{n+1}$  为输出层的输入,  $Y$  为输入样本,  $O^{n+1}$  为输出层的输出,  $\odot$  表示矩阵按对应元素相乘.

隐含层神经元从第  $k$  层到第 2 层的误差为

$$\text{delta}^k = f'_{\text{hid}}(\text{net}^k) \odot \left( W_{\text{out}}^n \cdot \text{delta}^{n+1} + W_{\text{self}}^k \cdot \text{delta}^k + \sum_{h=k+1}^n W_{\text{hid}}^{kh} \cdot \text{delta}^h \right). \quad (15)$$

2) 权值调整值的计算.

以  $\Delta W^{hk}$  表示第  $h$  层到第  $k$  层的权值连接的调整值. 根据 Delta 法则, 有

$$\Delta W^{hk} = \begin{cases} \beta \cdot \Delta W^{hk} + (1 - \beta) \cdot \alpha \cdot \text{delta}^k \cdot O^h, & 2 \leq h \leq n; \\ \beta \cdot \Delta W^{1k} + (1 - \beta) \cdot \alpha \cdot \text{delta}^k \cdot X, & h = 1. \end{cases} \quad (16)$$

其中:  $\beta$  为动量常数,  $\alpha$  为学习速率.

### 4 仿真实验与结果分析

#### 4.1 测试数据及误差评价标准

选取如下两个例子作为新算法的测试数据.

例 1 一元函数的函数逼近.

$$y(x) = 0.1 \sin(5\pi x) + 0.3 \sin(3\pi x) +$$

$$0.4 \sin(8\pi x), \quad x \in [0, 1]. \quad (17)$$

例 2 统计预测实例. 选用城市交通路网中某交通路段 4 天的交通流量数据<sup>[12]</sup>, 时间间隔为 15 min, 共 384 个时间点, 用前 4 个时间点的值预测下一个时间点的流量数据. 此网络的输入为 4, 输出为 1, 选择隐含层节点数为 6.

选用误差平方和 (SSE) 以及平均绝对百分比误差 (MAPE) 作为误差评价标准.

#### 4.2 初始连接权值的选择对网络性能的影响

针对例 1 探讨初始权值分别取 (0,1)(初值 1)、(-1, 1)(初值 2)、(0, 1/num<sub>in</sub>) (初值 3) 或 (-1/num<sub>in</sub>, 1/num<sub>in</sub>) (初值 4) 之间的随机数时, 不同学习速率  $\alpha$  对网络函数逼近性能的影响. 网络模型选用 NW 小世界神经网络, 重连概率  $p = 0.08$ , 最大迭代次数为 10000, 动量常数  $\beta = 0.9$ ; 采样点数为 50, 样本个数为 5, 学习速率  $\alpha \in [0.08, 1.35]$ . 图 3 给出了运行 100 次不同初始连接权值下的迭代次数随  $\alpha$  的变化曲线.

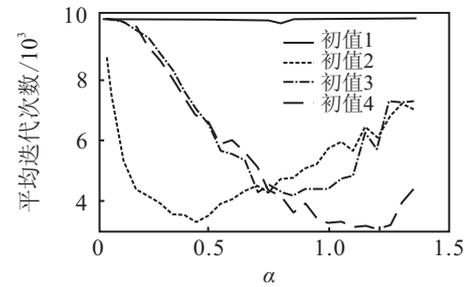


图 3 不同初始连接权值下的迭代次数随  $\alpha$  的变化曲线

从图 3 可以看出, 对于每类初值的最优平均迭代次数, 初值 2、初值 3 及初值 4 要明显小于初值 1; 不同初值的最优平均迭代次数对应于不同的最优  $\alpha$  值, 这说明网络权值相对较小时, 可适当增大  $\alpha$  以减少网络的训练次数, 提高训练速度.

针对初值 2、初值 3 以及初值 4 对应的最优  $\alpha$  区间, 图 4 给出了迭代次数为 15000 次时, 运行 100 次的逼近精度落在各个区间的概率. 从图 4 中可以看出, 初值 4 对应的网络逼近精度更高, 稳定性更强.

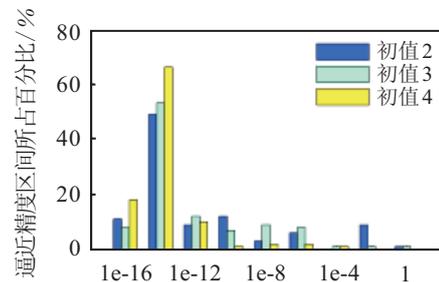


图 4 不同初值下的网络逼近精度对比

### 4.3 改进后的权值修正策略对比

针对例1, 分别对先修正输出层权值的基本BP算法(方法1)、后修正输出层权值的基本BP算法(方法2)、先修正输出层权值的改进算法(方法3)、后修

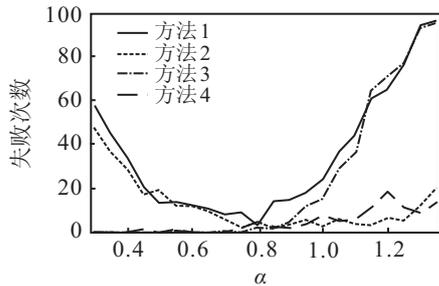


图5 初值为  $(-1/\text{num}_{in}, 1/\text{num}_{in})$  时权值修正对比

正输出层权值的改进算法(方法4)进行仿真, 设最大迭代次数为10000. 图5给出了SSE = 0.01时, 网络训练100次的失败次数. 同时计及平均迭代次数, 可以看出, 方法3与方法4都明显小于方法1和方法2, 说明其模型稳定性更强, 逼近速度更快, 且两者在实现最优网络性能方面并无明显差别.

### 4.4 神经网络拓扑结构的对比

选取应用性较强的例2作为对比测试数据, 初始权值选取  $(-1/\text{num}_{in}, 1/\text{num}_{in})$  之间的随机数. 设定最大迭代次数为10000, 并选用4.3节中的方法3作为权值修正策略. 表1给出了不同拓扑结构下分别独立运行100次的平均训练误差及测试误差.

表1 不同拓扑结构的小世界神经网络性能对比

Case	网络拓扑结构	WS 小世界神经网络误差		NW 小世界神经网络误差	
		训练集	测试集	训练集	测试集
1	现有的小世界神经网络, 只有隐含层重连(加边)	1.638 7	0.203 8	1.635 8	0.203 9
2	输入层到隐含层有重连(加边)	1.613 9	0.191 2	1.615 3	0.192 0
3	隐含层到输出层有重连(加边)	1.609 3	0.194 8	1.612 7	0.195 4
4	输入层到隐含层, 隐含层到输出层都有重连(加边)	1.665 9	0.225 8	1.653 6	0.219 4
5	输入层到隐含层, 隐含层到输出层都有重连(加边), 且存在输入层到输出层的直连	1.806 9	0.252 6	1.823 7	0.266 1
6	只有隐含层重连(加边), 存在隐含层层内连接	1.609 5	0.192 7	1.590 8	0.181 2
7	输入层到隐含层有重连(加边), 存在隐含层层内连接	1.635 4	0.197 8	1.641 2	0.201 7
8	隐含层到输出层有重连(加边), 存在隐含层层内连接	1.687 3	0.236 7	1.658 8	0.200 8
9	输入层到隐含层, 隐含层到输出层都有重连(加边), 存在隐含层层内连接	1.732 5	0.230 1	1.732 8	0.232 4
10	输入层到隐含层, 隐含层到输出层都有重连(加边), 存在输入层到输出层的直连, 且存在隐含层层内连接	1.802 4	0.268 3	1.823 2	0.273 7

分析上述结果可知:

1) WS与NW小世界神经网络并无绝对的优劣关系, 在同一种拓扑结构下, 其精度相差不大.

2) Case 2、Case 3比Case 1(现有小世界神经网络)的模型精度有所提高.

3) Case 4的精度降低了, 这是因为网络的结构相对改动较大, 使得网络的稳定性降低. 同理, Case 5时的精度相对变化较大, 说明此直接连接破坏了神经网络原有的逐层逼近式的结构.

4) 除Case 6会使精度提高之外, 在其他拓扑结构中加入层内连接(Case 7~Case 10)会使精度降低. 这说明层内连接, 即小世界神经网络的聚集系数, 与网络性能并无绝对的关系.

## 5 结 论

构造稳健性更强的人工神经网络是当前神经网络的热门研究课题. 本文对现有多层前向小世界神经网络存在的不足进行了深入研究, 提出了基于WS和NW小世界神经网络的改进方法, 并通过各种

不同形式小世界神经网络的建模仿真, 得出以下结论:

1) 网络初始权值选取  $(-1/\text{num}_{in}, 1/\text{num}_{in})$  之间的随机数, 权值修正策略为先修正输出层权值, 再根据式(7)计算隐含层误差时, 网络的稳定性、收敛速度逼近精度将得到大幅提高.

2) WS与NW小世界神经网络在同一种拓扑结构下并无优劣差别; 输入层到隐含层有重连(加边)、隐含层到输出层有重连(加边)、只有隐含层重连(加边)并存在隐含层层内连接这3种拓扑结构的小世界神经网络逼近精度较高.

本文研究增强了小世界神经网络在数据统计预测方面的实际应用能力. 关于改进算法的收敛性证明以及小世界神经网络在神经网络控制方面的性能分析是今后的研究方向.

### 参考文献(References)

- [1] Watts D J, Strogatz S H. Collective dynamics of small-world networks[J]. Nature, 1998, 393(4): 440-442.

- [2] Newman M E J, Watts D J. Renormalization group analysis of the small-world network model[J]. *Physics Letters A*, 1999, 263(4): 341-346.
- [3] Zheng P S, Tang W S, Zhang J X. A simple method for designing efficient small-world neural networks[J]. *Neural Networks*, 2010(23): 155-159.
- [4] Morelli L G, Abramson G, Kuperman M N. Associative memory on a small-world neural network[J]. *European Physical Journal B*, 2004, 38: 495-500.
- [5] Li C G. Memorizing morph patterns in small-world neuronal network[J]. *Physica A*, 2009, 388(15): 240-246.
- [6] Li S W. Analysis of contrasting neural network with small-world network[C]. 2008 Int Seminar on Future Information Technology and Management Engineering, UK: Leicestershire, 2008: 57-60.
- [7] Simard D, Nadeau L, Kroger H. Faster learning in small-world neural networks[J]. *Physics Letters A*, 2005, 336(1): 8-15.
- [8] Yang S Z, Luo S W, Li J Y. Building multi-layer small world neural network[J]. *Lecture Notes in Computer Science*, 2006, 3971: 695-700.
- [9] 李小虎, 杜海峰, 张进华, 等. 多层前向小世界神经网络及其函数逼近[J]. *控制理论与应用*, 2010, 27(7): 836-842.
- (Li X H, Du H F, Zhang J H, et al. Multilayer feedforward small-world neural networks and its function approximation[J]. *Control Theory & Applications*, 2010, 27(7): 836-842.)
- [10] 李小虎, 杜海峰, 张进华, 等. 多层前向小世界神经网络的逼近与容错性能[J]. *西安交通大学学报*, 2010, 44(7): 59-63.
- (Li X H, Du H F, Zhang J H, et al. Approximation and fault-tolerance performances of multilayer, feedforward small world neural network[J]. *J of Xi'an Jiaotong University*, 2010, 44(7): 59-63.)
- [11] 张瑞成, 李冲. 小世界人工神经网络模型及其应用研究[J]. *计算机仿真*, 2008, 28(10): 95-98.
- (Zhang R C, Li C. Model of NW multilayer feedforward small-world artificial neural networks and it's applied[J]. *Computer Simulation*, 2008, 28(10): 95-98.)
- [12] 欧海涛, 张文渊, 杨煜普, 等. 高速公路交通流的RBF神经网络建模[J]. *上海交通大学学报*, 2000, 34(5): 665-668.
- (Ou H T, Zhang W Y, Yang Y P, et al. Freeway traffic flow modeling with RBF neural network[J]. *J of Shanghai Jiaotong University*, 2000, 34(5): 665-668.)

(责任编辑: 李君玲)