

一种基于改进暂态混沌神经网络的信道分配算法

朱晓锦 陈艳春 马世伟 秦霆镐

(上海大学机电工程与自动化学院上海市电站自动化技术重点实验室 上海 200072)

摘要: 该文针对暂态混沌神经网络(TCNN)求解信道分配问题(CAP), 分析混沌神经网络模型及其混沌性态, 依据其按自反馈连接权值的减小, 由混沌态通过逆分岔而收敛到稳定状态的特性, 提出了一种对暂态混沌神经网络进行分段退火的策略, 即依据混沌神经网络运行过程中, 对应 Lyapunov 指数的变化特性而确定分段点, 使网络能有效地利用混沌态进行全局搜索和加快收敛; 在 7 小区的信道分配中, 网络收敛速度提升了 30%左右, 在 25 小区的 Kunz 基准测试程序的仿真中, 收敛速度也提升了近 15%; 仿真结果表明其有效减少了网络运算的迭代步数, 提高了网络的搜索效率; 通过相应理论和仿真结果的分析, 对网络的搜索性能、参数的选择与设置进行了进一步的讨论。

关键词: 混沌神经网络; Hopfield 神经网络; 模拟退火; 混沌噪声; 信道分配问题

中图分类号: TN916.9

文献标识码: A

文章编号: 1009-5896(2007)09-2230-05

A New Algorithm Based on the Improved Transient Chaotic Neural Network for Cellular Channel Assignment

Zhu Xiao-jin Chen Yan-chun Ma Shi-wei Qin Ting-gao

(School of ElectroMechanical Engineering & Automation Shanghai Key Laboratory of Power Station Automation Technology, Shanghai University, Shanghai 200072, China)

Abstract: In this paper, the Transient Chaotic Neural Network(TCNN) is used to solve the Channel Assignment Problem(CAP), and a new method named two-stage annealing method in TCNN is proposed. The neural network gradually convergences, through the transient chaos, to a stable equilibrium point according to the damping of the self-feedback connection weight, and the dividing point in the new model is chosen according to the change of the corresponding Lyapunov exponent. The two-stage annealing method can make sure the network take good advantage of the chaos to search the global minimum and enhance the convergence rate. In the 7-cell cellular network, the convergence rate is 30% higher than the TCNN model, and is also upgraded 15% in the Kunz's benchmark test. Simulated results show that the new model has a higher searching ability and lower computing time in searching the global minimum. The searching ability and the choosing of the parameters are also discussed based on the simulated results.

Key words: Chaotic neural network; Hopfield neural network; Simulated annealing; Chaotic noise; Channel assignment problem (CAP)

1 引言

随着移动电话用户数量的飞速增长, 通信网络的容量也不断扩张, 由于实际业务中可以利用的频谱资源非常有限, 因此频谱资源的有限性和用户数量快速增长之间的矛盾就变得越来越突出。解决这个矛盾一个行之有效的方法就是进行频率复用, 即将同一信道在不同小区之间进行重复使用, 但由于相同或相邻的信道之间一般存在着干扰, 因此合理进行信道的优化分配就彰显出重要性。信道分配问题(CAP), 就是在满足信道干扰限制的前提下, 将需求的信道数量有效地分配到各小区之中, 由于其所要解决的是一类NP完全问题, 而传统的算法在面对信道规模的增长, 以及由此引起的计算

时间随指数级增加等问题面前显得力不从心, 于是近年来越来越多的启发式算法被用来探索解决这类问题, 如模拟退火算法、禁忌搜索算法、遗传算法、人工神经网络方法等。

鉴于人工神经网络具有强大的并行运算能力和非线性逼近能力, 多年来在国内外学术界得到广泛的重视和深入的研究, 同样也被探索用来解决CAP问题^[1-3]。如 1991 年Kunz首次采用Hopfield神经网络来解决CAP问题^[1], 但由于Hopfield神经网络极易陷入局部极小而难以达到全局最优, 使得研究结果具有很大的局限性。近年来伴随着混沌理论不断发展, 人们开始探索将混沌引入神经网络进行组合优化问题的求解, 以期利用混沌丰富的动态特性实现跳出局部极小并达到全局最优^[4-10], 如Aihara提出了一种暂态混沌神经网络(TCNN), 它由具有混沌动态特性的神经元组成, 并在模型中引入一个按“温度”变化的退火过程并利用混沌的动态特性, 用暂态混沌空间进行全局搜索, 成功用于TSP问题

2006-08-07 收到, 2007-05-15 改回

上海市教委“曙光计划”项目(04SG41), 上海市重点学科建设项目(T0103)和教育部留学回国人员科研启动基金资助课题

的求解,显示出比Hopfield网络更优的性能,但其收敛速度仍有待于进一步提高。

本文提出一种对应于 TCNN 模型的分段退火策略,其着眼于对 TCNN 收敛速度的提高,即通过对混沌模型进行分段退火,使得在保证网络收敛效率的前提下,进一步减少迭代步数和加快收敛速度。通过将分段后的 TCNN 模型应用于不同规模的 CAP 问题仿真,在 7 小区的信道分配中,网络收敛速度提升了 30%左右,在 25 小区的 Kunz 基准测试程序的仿真中,收敛速度也提升了近 15%;从而表明基于改进策略的 TCNN 模型可使网络收敛速度得到有效提高,同时文中也对相关参数的选择及其对网络性能的影响进行了进一步的讨论。

2 信道分配问题(CAP)

对蜂窝通信进行信号分配的关键是频率复用,由于存在同频/邻频干扰等相关干扰因素,使得频率复用的程度必须限定在一定的范围之内,因此信道分配必须满足信道干扰的约束条件,一般受到以下几个条件的限制^[5]:

(1)同信道约束(CCC):同一信道不能在其同频干扰范围内再次使用;同一簇的小区必须分配不同的信道。

(2)邻信道约束(ACC):不能同时把相邻信道分配给相邻小区使用。

(3)同小区约束(CSC):同一小区内所有信道之间必须有一定的频率间隔,通常要大于 ACC 的要求。

假设一个由 n 个小区组成的蜂窝系统,考虑到上述提到的 3 种信道干扰约束,则可以定义一个 $n \times n$ 维的对称矩阵,称之为约束矩阵 C ,如图 1 所示为 7 小区信道分配问题的约束矩阵。

$$C = \begin{matrix} & \begin{matrix} C_1 & C_2 & C_3 & C_4 & C_5 & C_6 & C_7 \end{matrix} \\ \begin{matrix} C_1 \\ C_2 \\ C_3 \\ C_4 \\ C_5 \\ C_6 \\ C_7 \end{matrix} & \begin{pmatrix} 5 & 3 & 3 & 3 & 3 & 3 & 3 \\ 3 & 5 & 3 & 0 & 0 & 0 & 3 \\ 3 & 3 & 5 & 3 & 0 & 0 & 0 \\ 3 & 0 & 3 & 5 & 3 & 0 & 0 \\ 3 & 0 & 0 & 3 & 5 & 3 & 0 \\ 3 & 0 & 0 & 0 & 3 & 5 & 3 \\ 3 & 3 & 0 & 0 & 0 & 3 & 5 \end{pmatrix} \end{matrix}$$

图 1 7 小区信道分配问题的约束矩阵

其中非对角线元素 C_{ij} 表示分配给第 i 小区信道与第 j 小区信道之间的最小间隔,而矩阵 C 中的对角线元素 C_{ii} 表示分配给第 i 小区一组信道之间的最小频点间隔。因此 CCC 可以用 $C_{ij}=1$ 表示,而 ACC 和 CSC 可以分别用 $C_{ij} \geq 2$ 和 $C_{ij} \geq 1$ 表示, $C_{ij}=0$ 即表示小区可以使用相同的信道。通过对系统中每个小区的话务量分析,可以定义一个 n 维的需求矢量 D 来表示每个小区的信道需求,其中 D 中的第 i 个元素 d_i 表示第 i 个小区需要的信道数。令 f_{ik} 为分配给第 i 个小区的第 k 个信道,其中 $i=1,2,\dots,n$, $k=1,2,\dots,d_i$,则系统所需信

道数可表示为 $M=\max\{f_{ik}\}$,且 $|f_i - f_j| > C_{ij}$ 。

3 TCNN 模型与网络结构的确定

3.1 CNN 和 TCNN

Aihara 等将混沌引入神经网络^[6],提出了一个 CNN 混沌神经元模型如下:

$$v_i(t) = \frac{1}{1 + e^{-y_i(t)/b}} \quad (1)$$

$$y_i(t+1) = h \cdot y_i(t) + \alpha \cdot \left[\sum_{j=1, j \neq i}^n w_{ij} \cdot v_j(t) + I_i \right] - z_i \cdot v_i(t) \quad (2)$$

式中 $i=1,2,\dots,n$; v_i , y_i , z_i 分别为神经元 i 的输出、内部状态变量(即神经元接受的信息量)和自反馈连接权值,其中 z_i 为一常数。 w_{ij} 为神经元 j 到神经元 i 的连接权值; I_i 为神经元 i 的输入偏差; b 为 $v_i(t)$ 的陡度参数; h 为神经元的衰减因子; α 为输入的正值缩放因子。

CNN 具有良好的动态特性,但对于网络的收敛问题难以解决,于是 Chen 和 Aihara 又提出了基于退火策略的暂态混沌神经网络(TCNN),较好地解决了这个问题。模型如下所示:

$$v_i(t) = \frac{1}{1 + e^{-y_i(t)/b}} \quad (3)$$

$$y_i(t+1) = h \cdot y_i(t) + \alpha$$

$$\cdot \left[\sum_{j=1, j \neq i}^n w_{ij} \cdot v_j(t) + I_i \right] - z_i(t)(v_i(t) - I_0) \quad (4)$$

$$z_i(t+1) = (1-r)z_i(t) \quad (5)$$

式中 $z_i(t)$ 由 CNN 中的常量变为一个可变量, r 为 $z_i(t)$ 的衰减因子。

TCNN 模型一个显著特征就是混沌是暂时产生的,并用于搜索和自组织以达到跳出局部极小的目的,因此通过一个暂态的混沌,神经网络就逐渐接近于 Hopfield 神经网络的动态结构,并最终收敛于一个稳定的平衡点。暂态混沌神经网络(TCNN)的动态特性敏感依赖于自反馈连接权值 $z_i(t)$,它类似于随机模拟退火中的温度,是动态变化的,因此式(5)代表了一种退火方案。实际上如果固定一个 $z_i(t)$,神经元就是混沌神经元,网络具有混沌特性;若 $z_i(t)=0$,网络就变为一般的 Hopfield 神经网络,收敛于一个稳定点,因此 $z_i(t)$ 的演化策略对优化性能有很大的影响。

3.2 $z_i(t)$ 演化策略与改进分段退火 TCNN 模型

权值 $z_i(t)$ 的退火策略对网络运行有很重要的影响,一般从混沌到平衡点的演变可分为两个过程,即粗搜索和细搜索过程。第一阶段表现为粗搜索,属于混沌搜索阶段,对应于暂态混沌动态过程,有丰富的动态特征,这一过程完成相空间的搜索行为;当 $z_i(t)$ 下降到某一值时,逆分岔结束,则混沌现象消失,转到稳定收敛阶段,是类似于 Hopfield 网络的收敛进程,即细搜索阶段。 $z_i(t)$ 的下降速度直接影响到优化算法的两个重要指标:准确性和速度。若 $z_i(t)$ 下降速度快,将通过很短的搜索阶段直接进入收敛过程,因此算法的整体

速度较快, 但因为没有充分利用混沌的动态特性, 网络容易陷入局部极小值, 准确性就会大大降低; 反之如果 $z_i(t)$ 下降速度慢, 就可以充分利用混沌动态以提高准确性, 但是网络运行速度却大大降低。

分段退火策略的提出即依据在混沌动态结束后, 加快稳定收敛的进程来进行优化, 这样既充分利用混沌动态, 又较大幅度减少了迭代次数, 使网络性能得到进一步提高和优化。由于常用的退火策略是指数退火策略 $z(t+1) = (1-r)z(t)$, 虽然能使混沌动态有足够长的进程以提高粗搜索性能, 但是在进入细搜索阶段后, 能量函数收敛较慢。因此考虑在进入细搜索阶段后采用线性退火策略, 即 $z(t+1) = z(t) - r_1$, 其优点是随着时间进程的增加, $z_i(t)$ 线性减小, 可以使网络很快地收敛到稳定状态, 适合于网络在逆分岔结束后的演变。通过改进退火机制, 考虑把指数退火策略和线性退火结合起来, 即在逆分岔结束之前采用指数退火策略, 之后采用线性退火策略, 则既能够保证粗搜索阶段有足够长的进程以提高搜索性能, 有效避免局部极小值, 又可在细搜索阶段使网络以尽量快的速度收敛到稳定状态, 具体改进模型如下:

$$v_i(t) = \frac{1}{1 + e^{-y_i(t)/b}} \quad (6)$$

$$y_i(t+1) = h \cdot y_i(t) + \alpha \cdot \left[\sum_{j=1, j \neq i}^n w_{ij} \cdot v_j(t) + I_i \right] - z_i(v_i(t) - I_0) \quad (7)$$

$$z(t+1) = \begin{cases} z(t)(1-r), & z \geq d \\ z(t) - r_1, & z < d \end{cases} \quad (8)$$

其中 d 为 $z(t)$ 的分断点, r, r_1 分别为指数退火和线性退火的退火参数。

3.3 能量函数 E , 网络权值 w 和偏流 I 的确定

首先, 对 n 个小区 m 个信道系统来说, 共需要 $n \times m$ 个神经元, 第 ij 个神经元的输出 v_{ij} 用来表示 j 信道是否分配给了 i 小区; 若已分配, 则 $v_{ij} = 1$, 否则 $v_{ij} = 0$ 。根据信道分配的约束条件, 网络能量函数确定如下:

$$E = \frac{A}{2} \sum_{i=1}^n \left(\sum_{j=1}^m v_{ij} - d_i \right)^2 + \frac{B_1}{2} \sum_{i=1}^n \sum_{j=1}^m \sum_{q=j-(c_{ii}-1)}^{j+(c_{ii}-1)} v_{iq} v_{ij} + \frac{B_2}{2} \sum_{i=1}^n \sum_{j=1}^m \sum_{p=1}^n \sum_{q=j-(c_{ip}-1)}^{j+(c_{ip}-1)} v_{pq} v_{ij} \quad (9)$$

$p \neq i$
 $c_{ip} > 0$

式中系数 A, B_1, B_2 分别表示信道需求、同小区约束和邻信道约束在能量函数中所占的比重, 反映不同约束对网络能量的影响大小; 而Hopfield网络标准能量函数的形式为

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} v_i v_j - \sum_{i=1}^n v_i I_i \quad (10)$$

式(9)和式(10)相比较可得:

$$w_{ijpq} = -A\delta_{ip} - B_1\delta_{ij}(1 - \delta_{jq})\alpha_{jq}(c_{ii} - 1) - B_2(1 - \delta_{ip})\alpha_{jq}(c_{ip} - 1) \quad (11)$$

$$I_{ij} = A d_i \quad (12)$$

其中式(11)中所用到的函数定义如下:

$$(1) \delta_{ij} = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (2) \alpha_{ij}(x) = \begin{cases} 1, & |i - j| \leq x \\ 0, & |i - j| > x \end{cases}$$

至此, 改进的分段退火 TCNN 网络结构得以确定。

4 仿真结果与分析

4.1 网络参数的选取原则与确定

(1)缩放因子 α : α 控制 $\partial E / \partial v$ 对网络性能的影响 α 太小使能量函数不能有效影响神经元的动态特性, 易使网络收敛到一个非法解; α 太大使能量函数的影响过大而又不利于产生混沌动态, 因此本文仿真过程中取 $\alpha = 0.015$, 从而使网络能有较好的性能。

(2)衰减因子 r (亦可称之为退火参数): Chen 的退火函数 $z(t)$ 的值随迭代步数的增加而不断变化, 对不同的 $r, z(t)$ 取值的不同变化曲线对比如图 2 所示, 可见 r 越大则退火函数在开始时下降越快, 对特定 r 随着迭代步数的增加, 变化将越来越慢, 表明 r 的大小直接影响迭代步数和网络混沌态的持续时间。 r 太大会使混沌动态消失过快, 混沌动态不足则易于陷入局部极小点; 而 r 太小会使混沌动态持续时间过长, 导致网络收敛过慢。一般选取 r 的取值范围在 0.0035 到 0.0055 之间时, 网络的适应性较强, 较易得到全局最优解, 当然随着网络规模的增大或减小, 也可相应增加或减小 r 的值。




图 2 退火函数 $z(t)$ 对应衰减因子 r 的不同取值的变化曲线对比图

(3)分断点 d 依据网络对应 Lyapunov 指数的变化特性而确定。其值过大, 即网络过早进入线性退火过程, 混沌状态结束过快, 不利于充分利用网络的混沌特性; d 过小会使得分段退火失去意义, 不能发挥其提高收敛速度的特性。

(4)参数 A, B_1, B_2, b 的增减也会影响网络的动态特性, 增加其中任何一个都会增加网络混沌过程持续的时间, 因此可通过对这些参数的合理调整来改变网络的混沌动态特性, 从而使其具备更好的适应性和寻优能力。

通过将分段后的改进 TCNN 模型应用于不同规模的 CAP 问题进行仿真分析, 可以验证前述网络模型的运算性能和综合特性。

4.2 7 小区 21 信道分配方案

基于改进的混沌神经网络对 7 小区 21 信道进行仿真研究, 小区的形状如图 3 所示:

选取约束矩阵为图 1 所示的约束矩阵 C , 各参数选取为: $h=0.9, b=1/180, \alpha=0.015, z(0)=0.08$; 选取 $r_1=0.0035$;

选取需求向量 $D=[2, 1, 2, 3, 2, 1, 2]$ ，首先采用Chen的指数退火函数，得到信道分配仿真结果如图 4 所示。





图 3 7 小区信道结构示意图 图 4 7 小区信道分配结果图

然后采用分段退火机制，首先选择合适的分段临界点，通过网络运行过程中 Lyapunov 指数的变化可知，一般情况下在 $\varepsilon=0.02$ 时逆分岔已经结束，所以取这个点为分界点，其他系数同上，则得到信道分配仿真结果仍如图 3 所示。可以看出，两种退火函数的分配结果完全相同，但分段退火机制在网络的收敛速度上要比分段前大大加快，性能有了明显的提高。图 5 显示了网络运行过程中的能量函数的变化曲线，可以看出能量突跳反映了网络的混沌状态，随着迭代的进行，能量逐渐稳定并趋于 0；图 6 所示为单个神经元细胞的变化态，可以清楚看到随着迭代步数的增加，网络由混沌状态通过逆分岔逐渐收敛到稳定状态，从而进入网络的细搜索阶段。根据约束条件，可以看到指数退火函数迭代了 527 步得出全局最优解，而分段退火只迭代了 393 步就得到了全局最优解，信道的复用率很高，寻优过程也大大加快。




图 5 7 小区能量函数变化图




图 6 单个神经元输出结果变化示意图

对 200 个不同的需求向量，进行仿真运算得到统计结果如表 1 所示。从表 1 中可以看出，对于退火参数的不同取值，网络的收敛效率有较大差别，而且对于不同的退火参数，迭代效率提升的百分比也不同，但至少要有 30%左右的提升。可见采用分段退火策略后网络收敛速度明显加快，而且网络效率也得到了显著的提高。

表 1 不同退火参数下的分段退火 TCNN 模型求解统计结果

退火参数	不分段平均迭代步数	分段平均迭代步数	不分段最优解个数	分段最优解个数	迭代效率提升百分比 (%)
0.0025	784	563	184	184	28.2
0.0035	569	398	192	192	30.1
0.005	495	312	188	190	37.0

4.3 25 小区 73 信道分配方案

25 小区 73 信道的信道分布示意图和约束矩阵分别如图 7, 图 8 所示。




图 7 25 小区信道分布示意图




图 8 25 小区信道分配约束矩阵

在此采用文献[1]提出的一个基准测试程序，该程序由 Kunz 根据在芬兰首都赫尔辛基的一块 24km×21km 区域内话务量的统计信息提出，同时提出了一个具有代表性的需求向量 D ： $D=[10,11,9,5,9,4,5,7,4,8,8,9,10,7,7,6,4,5,5,7,6,4,5,7,5]$ 。

通过将该基准测试程序和需求向量用于上述几种模型进行性能对比，并采用分段退火网络模型进行仿真实验，得到信道分配结果如图 9 所示。




图 9 25 小区信道分配结果图

通过对 200 个不同的需求向量进行仿真实验，迭代终止条件为能量函数变化值连续 20 次小于 10^{-4} ，同时设定迭代次数的上限为 500 次，能量函数变化图如图 10 所示，单个神经元输出结果变化图如图 11 所示。

从图 10 可以看出，规模较大的 25 小区的信道分配中，能量函数的变化范围明显比 7 小区的大，而且由于约束矩阵规模的增大，每一次迭代所耗费的时间也相应增加，这就要求在满足一定收敛率的前提下，尽可能减少网络运行的迭代步数，图 11 则表示了在此规模下单个神经元细胞的变化状

态。




图 10 25 小区信道分配
能量函数变化图




图 11 单个神经元输出
结果变化图

表 2 中将 TCNN 模型和分段退火混沌神经网络模型的仿真结果和文献[2,3]的结果进行对比,由此可以看出采用分段退火策略后模型性能不但在收敛效率上有了一定提升,而且在收敛速度上也比分段前加快了近 15%,同其他文献结果的对比也同样显示出采用分段退火机制可使网络具有更高的收敛率,能更好地达到全局最优。

表 2 各神经网络模型在解决 CAP 问题时的对比结果

	不分段	分段	文献[3]结果	文献[2]结果
最优解比率(%)	81	85	62	9
平均迭代步数	381.57	327.21	279.9	294

5 结束语

对于 TCNN 的全局搜索能力,式(4)中第 2 项实际上就是 $-\alpha \cdot \partial E / \partial \nu$,在 HNN 中能量函数按 $\partial E / \partial \nu$ 下降方向单调减小,即随着迭代步数的增加,其值不断减小,无法产生跳变,遇到局部极小无法跳出,从而网络陷入局部极小,无法达到全局最优。TCNN 通过自反馈项引入混沌噪声就保证了网络能轻易的跳出局部极小,而且 TCNN 的搜索范围极为有限,仅是整个状态空间中的一个很小的分形结构,由于其范围非常小,相对于状态空间的 Lebesgue 测度就为 0。但 Chen 在文献[8]中证明了 TCNN 具有一个全局吸引集,其吸引集中不仅包括对应于目标函数的局部最小点,还有全局最小点,因而能保证网络进行全局性的搜索。

本文面向 TCNN 模型提出了一种新的分段退火策略和分段退火函数,并基于 CAP 问题进行了仿真研究和验证,得到了良好的实验效果,尤其收敛时间减少了近 30%,极大地提高了网络的运行效率,文中亦对网络参数的选择及其对网络性能的影响进行了探讨。同时仿真研究也表明,虽然采用分段退火策略实现了网络收敛速率的较大提高,但最优解比率并没有特别明显的增加,因此在保证收敛速率条件下如何提高最优解比率,并更好地应用于 CAP 问题,还有待进

一步的深入研究。

参 考 文 献

[1] Kunz D. Channel assignment for cellular radio using neural

networks [J]. *IEEE Trans. on Veh. Technol*, 1991, 40(1): 188-193.

[2] Funabiki N and Takefuji Y. A neural network parallel algorithm for channel assignment problems in cellular radio networks [J]. *IEEE Trans. on Veh. Technol*, 1992, 41(3): 430-436.

[3] Kim J S, et al. Cellular radio channel assignment using a modified Hopfield network [J]. *IEEE Trans. on Veh. Technol*, 1997, 46(4): 957-967.

[4] Chen L and Aihara K. Transient chaotic neural networks and chaotic simulated annealing [C]. proceeding of Toward the Harnessing of Chaos, M. Yamaguti, Ed. Amsterdam, The Netherlands: Elsevier, 1994: 347-352.

[5] Gamst A and Rave W. On frequency assignment in mobile automatic telephone systems [C]. Proc GLOBECOM'82, Miami, FL, 1982: 309-315.

[6] Aihara K, Takabe T, and Toyoda M. Chaotic neural networks [J]. *Phys. Lett. A*, 1990, 144(6): 333-340.

[7] Chen L and Aihara K. Chaotic simulated annealing by a neural network model with transient chaos [J]. *Neural Networks*, 1995, 8(6): 915-930.

[8] Chen L and Aihara K. Global searching ability of chaotic neural networks [J]. *IEEE Trans. on Circuits and Systems - I: Fundamental theory and applications*, 1999, 46(8): 974-993.

[9] 何国光, 朱萍, 曹志彤, 陈宏平. 混沌神经网络的 Lyapunov 指数与混沌区域[J]. *浙江大学学报(理学版)*, 2004, 31(4): 387-390.

He Guo-guang, et al. Lyapunov exponent and chaotic area distribution of a chaotic neural network. [J]. *Journal of Zhejiang University (Science Edition)*, 2004, 31(4): 387-390.

[10] Lu Hongtao and Van Leeuwen C. Synchronization of chaotic neural networks via output or state coupling [J]. *Chaos, Solitons and Fractals*, 2006, 30(1): 166-176.

朱晓锦: 男, 1965年生, 副教授, 博士, 主要研究方向为计算机测控技术与智能结构、自适应控制方法与信号处理、人工神经网络与智能计算等。

陈艳春: 男, 1984年生, 硕士, 研究方向为自适应控制方法与信号处理、人工神经网络与智能计算等。

马世伟: 男, 1965年生, 副教授, 博士, 主要研究方向为信号处理与分析、智能检测和控制、微系统集成等。

秦霆镐: 男, 1955年生, 副教授, 主要研究方向为检测技术与信息处理、计算机测控技术与系统等。