DOI: 10.3901/JME.2015.22.128

一种基于脑网络的分层模块化回声状态网络*

李丁园^{1,2,3} 刘 富¹ 乔俊飞^{2,3}

(1. 吉林大学通信工程学院 长春 130022;

2. 北京工业大学电子信息与控制工程学院 北京 100124;

3. 北京工业大学计算智能与智能系统北京市重点实验室 北京 100124)

摘要: 针对回声状态网络(Echo state network, ESN)结构设计问题, 提出一种基于脑网络的分层模块化回声状态网络(Hierarchical modular echo state network, HMESN)。脑网络的拓扑结构使功能网络具有丰富的动力学特性, 因此, 从生物仿生学角度出发, 对 HMESN 的储备池进行分层设计, 各层级上的神经元采用小世界网络构建算法生成模块化结构, 并引入层级连接。基于脑网络分层模块化的拓扑特征弱化了神经元间的耦合程度, 从而使神经元的动力学特性更为丰富, 在功能与结构上更接近于真实生物神经网络, 有效地提高了网络处理问题的能力。采用 Mackey-Glass 时间序列预测和非线性系统辨识对网络进行验证, 证明该网络的有效性和可行性。

关键词: 回声状态网络; 脑网络; 储备池; 时间序列预测

中图分类号: TP183

A Hierarchical Modular Echo State Network Based on Brain Networks

LI Dingyuan^{1,2,3} LIU Fu¹ QIAO Junfei^{2,3}

(1. College of Communication Engineering, Jilin University, Changchun 130022;

2. College of Electronic Information and Control Engineering, Beijing University Technology, Beijing 100124;

3. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing University Technology, Beijing 100124)

Abstract: For the structure design of echo state network (ESN), a novel hierarchical modular echo state network (HMESN) based on brain networks is established. The topology of brain networks makes functional networks with rich dynamic behavior. Therefore, from a biological bionic point of view, the reservoir of HMESN for hierarchical design, each level of neurons using small world network construction algorithm to generate modular structure, as well as considered the hierarchical connection. Based on the topological characteristics of hierarchical modular in brain network, it weakens the coupling intensity among neurons, and enriches the dynamics of internal neurons. HMESN's reservoir is closer to the real biological neural networks from both structural and functional perspectives, which effectively improves the information processing ability of network. Finally, this proposed network is used for the Mackey-Glass time series prediction and the non-linear system identification to prove its validity and feasibility.

Key words: echo state network; brain networks; reservoir; time series prediction

0 前言

回声状态网络(Echo state network, ESN)由 JAEGER^[1]于 2001 年提出的一种新型递归神经网络。ESN 训练速度快且全局最优, 避免了传统递归神经网络(Recurrent neural network, RNN)普遍存在

的训练易陷入局部极优及稳定性分析困难等固有特性。因此, ESN 在语音识别^[2], 语言建模^[3], 非线性系统建模和控制^[4]等领域表现出较强的应用前景, 尤其在 Mackey-Glass 时间序列预测精度上实现了质的飞跃^[5-6], 现已成为人工神经网络领域研究的热点之一。

ESN 采用随机稀疏连接的神经元组成的储备池作为隐含层, 预先设定储备池权值矩阵的谱半径保证网络的稳定。网络训练时, 只需要确定隐含层

* 国家自然科学基金资助项目(61034008, 61203099, 61225016)。
20150228 收到初稿, 20150823 收到修改稿

与输出层的连接权值。ESN 内部动力学特性越丰富, 网络性能越好^[7], 而网络内部动力学特性与储备池拓扑结构相关, 为获得较好的性能, 许多学者致力于储备池拓扑结构设计研究。RODAN 等^[8]分别提出三种具有最小复杂度的储备池拓扑结构设计方法: 延迟线型储备池、有反馈连接的延迟线型储备池和简单环形储备池, 三种储备池拓扑结构只需要调节一至两个结构参数, 大大降低了网络的计算成本, 但仅简单环形储备池获得与传统 ESN 随机拓扑结构可比拟的性能。为了进一步提高网络的预测性能, SONG 等^[9]受大脑皮层生长发育过程启发, 提出一种类皮层结构的储备池, 对非线性时间序列预测取得较好预测精度。CUI 等^[10]将复杂网络理论引入到储备池的设计中, 提出一种兼有小世界和无标度特性的混合 ESN, 试验表明混合 ESN 具有较多复杂网络的基本特性, 对时间序列预测具有较好的预测性能, 然而关键神经元选取没有生物理论支撑。MEUNIER 等^[11]研究模块化在各层级上脑网络社团结构的皮层表面绘图, 发现脑网络具有分层模块化的组织。KAISER^[12]分析在脑区间连接的宏观层面上和神经元间连接的微观层面上连接组的拓扑和空间组织, 证实脑网络具有分层模块化的拓扑特征, 其独有的拓扑结构增强了大脑处理信息的能力。研究表明, ESN 随机连接储备池拓扑结构导致池内神经元之间存在较强的耦合, 限制了神经元的动力学特性^[7]。脑网络分层模块化的拓扑结构, 可弱化神经元间的耦合程度, 从而使神经元的动力学特性更为丰富, 进而提高网络处理问题的能力。

因此, 本文从仿生学的角度出发, 提出一种基于脑网络的分层模块化回声状态网络(Hierarchical modular echo state network, HMESN)。模拟脑网络的拓扑结构, HMESN 的储备池中引入层级连接, 不同层级之间、甚至同一层级上的神经元具有模块化结构, 即模块内神经元存在较强的连接, 模块间的神经元连接较弱, 弱化了神经元之间的耦合程度, 丰富了储备池内部动力学特性, 并将 HMESN 用于 Mackey-Glass 混沌时间序列预测和非线性系统辨识对其有效性进行验证。

1 ESN 模型

ESN 主要由输入层、储备池和输出层三部分组成, 储备池采用大量随机产生且稀疏连接的神经元组成, 取代传统 RNN 中的隐含层。储备池蕴含系统的运行状态, 并具有短期记忆功能, 一旦随机产生将不再修改, 这样简化了网络的训练过程, ESN

的结构如图 1 所示。

图 1 ESN 的结构图

整个网络在采样时刻 k 的输入变量 $\mathbf{u}(k)$ 、储备池的状态变量 $\mathbf{x}(k)$, 及输出变量 $\mathbf{y}(k)$ 可分别表示为

$$\mathbf{u}(k) = (u_1(k), u_2(k), \dots, u_K(k))^T \quad (1)$$

$$\mathbf{x}(k) = (x_1(k), x_2(k), \dots, x_N(k))^T \quad (2)$$

$$\mathbf{y}(k) = (y_1(k), y_2(k), \dots, y_L(k))^T \quad (3)$$

式中, K 、 N 和 L 分别为网络输入层、储备池和输出层神经元的个数。因此, 第 i 个神经元在 k 时刻的输入量为 $u_i(k)$, $i=1, 2, \dots, K$; 第 j 个神经元在 k 时刻的状态量为 $x_j(k)$, $j=1, 2, \dots, N$; 第 l 个神经元在 k 时刻的输出量为 $y_l(k)$, $l=1, 2, \dots, L$ 。

定义网络输入权值矩阵为 $\mathbf{W}^{\text{in}}$, 维数为 $N \times K$; 储备池内部状态的连接权值矩阵为 $\mathbf{W}$, 维数为 $N \times N$; 输出层到储备池内部状态的反馈连接权值矩阵为 $\mathbf{W}^{\text{back}}$, 维数为 $N \times L$; 网络的输出权值矩阵为 $\mathbf{W}^{\text{out}}$, 维数为 $L \times (K+N+L)$ 。ESN 储备池的内部状态变量的更新过程表示如下

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{W}^{\text{in}}\mathbf{u}(k+1) + \mathbf{W}\mathbf{x}(k) + \mathbf{W}^{\text{back}}\mathbf{y}(k)) \quad (4)$$

式中, $\mathbf{f}(\cdot) = (f_1, f_2, \dots, f_N)^T$ 为储备池内部状态的激活函数, 通常选用 Sigmoid 型函数 $\tanh(\cdot)$, 使 ESN 具有良好的非线性特性。特别的, 为保证网络内部状态是稳定的, ESN 储备池内部连接权值矩阵 $\mathbf{W}$ 的谱半径小于 1。储备池内部连接权值矩阵 $\mathbf{W}$ 的谱半径依据式(5)调整

$$\mathbf{W} = a(\mathbf{W}^r / |\lambda_{\max}|) \quad (5)$$

式中, $\mathbf{W}^r$ 为随机矩阵, $\lambda_{\max}$ 为 $\mathbf{W}^r$ 的最大特征值, 即 $|\lambda_{\max}| = \max \{|\lambda_i(\mathbf{W}^r)|\}$, λ_i 是 $\mathbf{W}^r$ 的第 i 个特征值, $i=1, 2, \dots, N$ 。放缩因子 a 取值在 $(0, 1)$ 之间, 则储备池内部连接权值矩阵 $\mathbf{W}$ 的谱半径小于 1, 网络稳定运行。网络的输出方程可表示为

$$y(k+1) = f^{\text{out}}(W^{\text{out}}x(k+1)) \quad (6)$$

式中, $f^{\text{out}}(\cdot) = (f_1^{\text{out}}, f_2^{\text{out}}, \dots, f_N^{\text{out}})^T$ 为输出单元的激活函数。为了分析方便, 本文 f^{out} 选取线性函数, 则式(6)可写为

$$Y = W^{\text{out}}X \quad (7)$$

由式(7)可见, ESN 的学习过程实质上是一个线性回归过程, 进而可以用伪逆法求得输出权值矩阵 W^{out} , 避免了基于误差梯度学习算法容易陷入局部极小的问题^[1]。

2 HMESN 结构设计

脑网络拓扑结构具有分层模块化的拓扑特征, 基于脑网络拓扑结构设计一种基于脑网络的 HMESN, 相对于 ESN 随机稀疏连接的储备池拓扑结构, 能更真实地反映哺乳动物脑网络的生物学机制。

2.1 HMESN 结构设计

脑网络拓扑结构的研究表明, 脑网络模块化的组织出现在大脑皮层的不同层级上, 即表现为每个模块包括多个种群, 每一种群又包括多个子种群, 以此类推, 脑网络拓扑结构具有分层模块化的特性^[12]。因此, 本文提出一种基于脑网络的 HMESN, 模拟大脑皮层内神经元存在不同层级上的模块化连接, 建立分层模块化的储备池拓扑结构。

HMESN 的储备池中具有两个重要参数, 即层级数和每一层包含的模块个数, 依次记为 h 和 m 。为了方便数学描述 HMESN 的储备池生成过程, 本文以 $h=2, m=4$ 为例, 其储备池的拓扑结构如图 2 所示。

图 2 HMESN 的储备池拓扑结构图

HMESN 的储备池先从最低层开始生成 m 个模块, 再将每一个模块看作第二层, 生成相同数目的子模块, 以此类推。当前层的模块个数计算公式如下

$$N_c = N / N_i \quad (8)$$

式中, N 为储备池中神经元的个数; N_i 为每个模块内包含的节点个数, 由式(9)确定

$$N_i = N \times (1/m)^i \quad i=1, 2, \dots, h-1 \quad (9)$$

HMESN 储备池拓扑结构的构建, 是内部状态的连接权值矩阵 W 的确定, 将网络每一层的拓扑结构映射到 W 中, W 改写为如下矩阵形式

$$W = \begin{pmatrix} W_1 & \dots & C_1 \\ \vdots & & \vdots \\ C_2 & \dots & W_{m_i} \end{pmatrix} \quad (10)$$

式中, $W_{m_i} (m_i=1, 2, \dots, N_c)$ 为当前层上第 i 个模块的连接权值矩阵; C_1 、 C_2 为所有模块间的连接权值矩阵。

HMESN 储备池内部状态连接权值矩阵 W 主要包括各层级上神经元模块化连接权值确定和层级间神经元连接权值确定。

2.1.1 各层级上模块化的生长算法

研究表明生物体神经元的结构具有小世界特性, 该特性使其出现明显的模块化结构^[13]。因此, HMESN 的储备池中各层级上的模块采用 NEWMAN 等^[14]提出的小世界网络进行构建, 具体构造算法如下。

(1) 首先从一个具有 N_i 个节点的规则网络开始, 每个节点都与离它最近的 $k/2$ 个节点相连接, 其中 k 是一个远小于 N_i 的正整数。

(2) 进行随机化加边, 先将边的一端神经元保持不变, 然后以概率 p ($0 < p < 1$) 随机地将边的另一端换为其他神经元。这样直到所有的神经元间的连接都被重连, 得到每个模块的连接权值矩阵 W_{m_i} 。

2.1.2 层级间连接的生长算法

虽然脑网络的不同脑区具有不同功能, 但要完成一项即使十分简单的任务时要依赖多个脑区之间的相互作用, 共同构成一个网络发挥其功能。因此, 储备池中不同层级之间, 甚至同一层级上不同模块化的神经元是相互关联的, HMESN 的层级间神经元的连接权值生成算法如下。

(1) 初始化设置激活节点个数 i 和初始激活程度 i_0 , 从 1 到 i_0 个节点中随机选取 i ($i < i_0$) 个节点被激活。将 HMESN 储备池中所有的内部神经元分为两类: 激活神经元和未激活神经元。通常, 激活神经元的个数小于未激活神经元个数, 可通过调节 i 取值设定储备池中激活神经元占的百分比, 调节 i_0 取值设定内部神经元的激活范围。

(2) 如果一个未激活神经元至少与 k 个当前激

活的邻近神经元相连(一个神经元的邻近神经元是指与其存在直接相连的神经元), 则其被激活。

(3) 激活神经元以概率 v 在下一时刻变为未激活的神经元, 或者仍保持激活态, 直到生成一个具有回声特性的储备池权值矩阵 W 。

2.2 HMESN 训练过程

HMESN 的训练过程是根据训练样本 $\{u(k), y_d(k)\} (k=1, 2, \dots, T)$ 确定输出权值矩阵 W^{out} , 可作如下描述。

(1) 设置 HMESN 初始参数, 包括储备池的神经元个数 N , 层级数 h , 模块数 m , W 的谱半径 ρ , 输入单元尺度参数、输入、输出神经元个数等。

(2) 初始化输入权值矩阵 W^{in} 和反馈连接权值矩阵 W^{back} , 按照第 2.1 节所述的方法生成 HMESN 的储备池内部状态的连接权值矩阵 W 。

(3) 依次将教师信号 $y_d(k)$ ($k=1, 2, \dots, T$) 分别送入网络的输入层与输出层, 根据式(4)进行网络更新并收集最终的状态变量, 储备池神经元激活函数选取双曲正切函数。

(4) 采用伪逆算法求解输出权值矩阵 W^{out} , 计算公式如下

$$W^{\text{out}} = M^{-1}Y^* \quad (11)$$

式中, M 为(舍弃长度为 T_0 的初始暂态过程后)储备池内部神经元的状态变量矩阵, 维数为 $(T-T_0+1) \times (K+N+L)$; 同样收集对应的 $(T-T_0+1) \times L$ 教师信号 Y^* , 至此, HMESN 训练完毕。

3 仿真试验

为了验证 HMESN 的有效性, 将 HMESN 用于 Mackey-Glass 时间序列预测和非线性系统辨识, 并与一些主流方法的预测结果进行对比。每一个仿真试验均独立运行 40 次选取其中 20 次最佳结果取其平均值进行比较, 以最大限度地消除随机因素对试验结果的影响。

3.1 Mackey-Glass 时间序列预测

Mackey-Glass 混沌时间序列预测是验证神经网络处理能力的一个典型基准问题^[15], 其混沌动力学方程定义如下

$$\frac{dx(t)}{dt} = ax(t) + \frac{bx(t-\tau)}{1+x(t-\tau)^{10}} \quad (12)$$

考虑到 Mackey-Glass 序列呈现出混沌特性的条件为 $\tau > 16.8$, 因此, 本试验各参数分别选取: $a = 0.1$, $b = 0.2$, $\tau = 17$, 初始值 $x(0) = 1.2$ 。使用 Matlab

工具中的函数 `dde23` 求解式(12), 得到一个长度为 3 600 步的 Mackey-Glass 时间序列, 舍掉前 1 000 步序列以消除初始暂态过程, 从第 1 001 时刻取 2 000 个时间序列作为训练样本, 后 600 个时间序列作为测试样本, 并采用第 T_p 步标准化方均根误差作为评价标准^[7], 其定义如下

$$\text{NRMSE}_{T_p} = \sqrt{\frac{\sum_{i=1}^{N_r} \left(\hat{y}_i(T_p) - y_i(T_p) \right)^2}{N_r \cdot \sigma^2}} \quad (13)$$

式中, $\hat{y}_i(T_p)$ 和 $y_i(T_p)$ 分别是 HMESN 进行第 i 次独立试验第 T_p 步的网络预测输出和期望输出, N_r 为 HMESN 进行独立运行试验的次数, σ^2 为期望输出的标准差。

采用 HMESN 对 Mackey-Glass 时间序列预测, 在测试过程中样本的期望值与网络输出值、网络误差以及四个状态变量 $x(t)$ 的输出值, 如图 3 所示。

图 3a 表明提出的 HMESN 具有较强的预测能力, 网络预测输出曲线较好地拟合了模型的期望输出曲线。图 3b 为 HMESN 与 ESN 测试误差对比, 与 ESN 相比, HMESN 的测试误差曲线更平缓, 限定在一个较小范围内, 达到一个较高的预测精度。试验中 HMESN 的储备池选取 4 个模块, 在图 3a 不能直观地看出各层级中每个模块是否较好地学习系统的动力学特性, 因此随机从储备池的模块中选取一个状态变量进行观测, 由图 3c 可知, HMESN 的储备池内部状态的动力学特性, 在网络仅输入当前时刻激励的情况下, HMESN 各个模块均能够记忆历史信息, 很好地学习该系统的动力学特性, 说明 HMESN 储备池拓扑结构具备了丰富的动力学特性, 能以较高的精度预测 Mackey-Glass 混沌时间序列。

表 1 给出了 HMESN 与 ESN^[1]、SCR-ESN^[8]以及 CESN^[9]解决 Mackey-Glass 混沌时间序列预测问题的性能对比。在储备池的神经元个数相同($N=500$)的情况下, HMESN 达到较高的测试精度 ($\text{NMSE}_{84}=0.001\ 65$), 比 ESN 随机稀疏连接的储备池拓扑结构的预测精度提高约 67.9%, 相比 CESN 类皮层结构的储备池的预测精度提高大约 39.3%, 进一步证明了 HMESN 在处理混沌时间序列预测问题时, 能够达到较高的预测精度, 网络具有较强的预测性能。

(a) HMESN 的测试结果

(b) HMESN 与 ESN 测试误差对比

(c) 四个状态变量的响应曲线

图 3 Mackey-Glass 时间序列预测

表 1 MG 时间序列预测性能对比

模型	ESN	SCR-ESN	CESN	HMESN
NRMSE ₈₄	0.003 2	0.007 6	0.002 8	0.001 7

3.2 非线性系统的辨识

采用一个标准的二阶非线性系统进行试验, 该基准问题常被用于验证神经网络结构及算法的性能^[16]。本文通过对此系统的自适应辨识, 验证 HMESN 的性能。非线性系统描述如下

$$y(t+1) = \frac{y(t)y(t-1)y(t-2)u(t-1)[y(t-2)-1]+u(t)}{1+y^2(t-1)+y^2(t-2)} \quad (14)$$

式中, $u(t)$ 和 $u(t-1)$ 分别为系统的当前时刻及前一时刻的延迟输入, $y(t)$ 、 $y(t-1)$ 和 $y(t-2)$ 分别为系统的当前时刻、前一时刻及历史输出; 由此可知, 系统的当前输出不仅依赖于前一时刻的输入和输出信号, 还依赖于历史输出。选取式(15)所示的输入信号进行仿真研究

$$u(t) = \begin{cases} \sin\left(\frac{\pi t}{25}\right) & 0 < t < 250 \\ 1.0 & 250 \leq t < 500 \\ -1.0 & 500 \leq t < 750 \\ 0.3\sin\left(\frac{\pi t}{25}\right) + 0.1\sin\left(\frac{\pi t}{32}\right) + 0.6\left(\frac{\pi t}{10}\right) & 750 \leq t < 1\,000 \end{cases} \quad (15)$$

采用式(16)所示的方均根误差作为网络的性能指标

$$\text{RMSE} = \sqrt{\frac{\sum_{t=0}^T \left(y(t+1) - \hat{y}(t+1) \right)^2}{T}} \quad (16)$$

式中, $\hat{y}(t+1)$ 和 $y(t+1)$ 分别是在 $t+1$ 时刻网络的预测输出和期望输出, T 是样本总数。选取系统的 $y(t)$ 、 $y(t-1)$ 、 $y(t-2)$ 、 $u(t)$ 和 $u(t-1)$ 数据作为 HMESN 的输入样本, 预测系统的输出 $y(t+1)$ 。试验过程中选取 $t \in [0, 800]$ 时的样本训练网络, $t \in [801, 1\,000]$ 时的样本作为测试样本, 用于检验网络的性能。

网络经过学习后, HMESN 对式(14)所示的非线性系统的辨识结果与系统期望输出的对比曲线如图 4 所示。结果表明 HMESN 可以较好地逼近非线性动力学系统, 在给定输入的情况下, HMESN 能够较好地预测系统的输出, 不但验证了 HMESN 结构设计的有效性, 而且证明了 HMESN 对复杂非线性动态系统的建模具有较好的逼近能力。

图 4 非线性系统的辨识

表 2 为 HMESN 和 ESN 对非线性系统辨识的结

果对比(储备池结构参数选取独立运行 40 次试验中网络训练结果最佳时取值), HMESSN_h 表示 HMESSN 内部采用 h 层模块化拓扑结构。结果表明在储备池神经元个数相同($N=400$)的初始条件下, HMESSN₁ 性能优于 ESN(Testing MSE= 8.98×10^{-4} , Testing RMSE = 0.030 0), 说明 HMESSN 辨识非线性系统具有较高的预测精度, 其原因在于 HMESSN 储备池中模块化的结构降低了神经元之间连接的耦合程度, 丰富了储备池内神经元的动力学特性, 从而提高了 HMESSN 的预测精度。HMESSN₂ 采用两层模块化拓扑结构, 精简后的网络($N=350$), 比 ESN 的预测精度提高约 19.7%, 与 HMESSN₁ 相比, 其预测精度提高约 10.3%, 证明储备池的分层模块化拓扑结构进一步提高了网络处理问题的能力, 使网络预测性能更优, 能很好地对非线性系统进行建模。

表 2 HMESSN 与 ESN 辨识结果对比

模型	ESN	HMESSN ₁	HMESSN ₂
Testing MSE	0.0011	8.98×10^{-4}	7.21×10^{-4}
Testing RMSE	0.033 5	0.030 0	0.026 9
Reservoir size	400	400	350

4 结论

本文依据生物仿生学原则, 基于脑网络模块化和层次化的拓扑特征, 设计一种基于脑网络的分层模块化回声状态网络。该网络可以使神经元的动力学特性更为丰富, 提高网络处理问题的能力。与 ESN 相比, HMESSN 具有以下几个特点。

(1) HMESSN 的储备池各层级神经元具有模块化结构, 各个模块均能够很好地记忆历史信息, 学习系统的动力学特性, 尤其对混沌时间序列预测, 具有较高的预测精度。

(2) HMESSN 分层模块化的拓扑结构, 提高了 HMESSN 处理问题的能力, 在储备池规模较小的情况下, 网络仍表现出较好的预测能力。

(3) 在复杂系统辨识方面, HMESSN 能够达到较高精度, 为神经网络在复杂系统中的应用提供了技术支持。

参 考 文 献

- [1] JAEGER H. The “echo State” Approach to analyzing and training recurrent neural networks[R]. Berlin: German National Research Center for Information Technology, 2001.
- [2] SKOWRONSKI M D, HARRIS J G. Minimum mean squared error time series classification using an echo state network prediction model[C]//Proceedings of the International Symposium on Circuits and Systems. Island of Kos: Circuits and Systems, 2006: 3153-3156.
- [3] TONG M H, BICKETT A D, CHRISTIANSEN E M, et al. Learning grammatical structure with echo state networks[J]. Neural Network, 2007, 20(3): 424-432.
- [4] 乔俊飞, 薄迎春, 韩广. 基于 ESN 的多指标 DHP 控制策略在污水处理过程中的应用[J]. 自动化学报, 2013, 39(2): 1146-1151.
QIAO Junfei, BO Yingchun, HAN Guang. Application of ESN-based multi indices dual heuristic dynamic programming on wastewater treatment process[J]. Acta Automatic Sinica, 2013, 39(2): 1146-1151.
- [5] JAEGER H, HAAS H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.
- [6] 韩敏, 穆大芸. 回声状态网络 LM 算法及混沌时间序列预测[J]. 控制与决策, 2011, 26(10): 1469-1478.
HAN Min, MU Dayun. LM algorithm in echo state network for chaotic time series prediction[J]. Control and Decision, 2011, 26(10): 1469-1478.
- [7] XUE Y B, YANG L, HAYKIN S. Decoupled echo state networks with lateral inhibition[J]. Neural Networks, 2007, 20(3): 365-376.
- [8] RODAN A, TINO P. Minimum complexity echo state network[J]. IEEE Transaction on Neural Networks, 2011, 22(1): 131-144.
- [9] SONG Qingsong, FENG Zuren. Effects of connectivity structure of complex echo state network on its prediction performance for nonlinear time series[J]. Neurocomputing, 2010, 73(10-12): 2177-2185.
- [10] CUI Hongyan, LIU Xiang, LI Lixiang. The architecture of dynamic reservoir in the echo state network[J]. Chaos, 2012, 22(3): 033127.
- [11] MEUNIER D, LAMBIOTTE R, BULLMORE E T. Modular and hierarchically modular organization of brain networks[J]. Frontiers in Neuroscience, 2010, 200: 1-11.
- [12] KAISER M. A tutorial in connectome analysis: Topological and spatial features of brain networks[J]. NeuroImage, 2011, 57(3): 892-907.
- [13] WATTS D J, STROGATZ S H. Collective dynamics of ‘small-world’ networks[J]. Nature, 1998, 393(6684): 440-442.
- [14] NEWMAN M E J, WATTS D J. Renormalization group

- analysis of the small-world network model[J]. Physics Letters A, 1999, 263(4-6): 341-346.
- [15] MACKEY M C, GLASS L. Oscillation and chaos in physiological control systems[J]. Science, 1977, 197(4300): 287-289.
- [16] HAN Honggui, QIAO Junfei. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm[J]. IEEE Transactions on Neural Network, 2010, 18(6): 1129-1143.

作者简介: 李丁园, 女, 1987 年出生, 博士研究生。主要研究方向为智能信息处理及神经网络结构优化设计。

E-mail: dyli@mails.jlu.edu.cn

刘富, 男, 1968 年出生, 博士, 教授。主要研究方向为计算机视觉及模式识别等。

E-mail: liufu@jlu.edu.cn

乔俊飞(通信作者), 男, 1968 年出生, 博士, 教授。主要研究方向为智能控制与智能信息处理。

E-mail: ixibox@sina.com