

文章编号: 1001-0920(2012)03-0383-06

一种具有 small world 特性的 ESN 结构分析与设计

薄迎春, 乔俊飞, 张昭昭

(北京工业大学 电子信息与控制工程学院, 北京 100124)

摘要: 针对回声状态网络 (ESN) 结构设计复杂、参数选择难度大的问题, 提出一种具有 small world 特性的 ESN (SWESN). 首先采用神经元空间增长算法在平面区域生成 small world 拓扑网络; 然后根据网络节点与基准点的 Euclidean 距离将网络节点进行重新排序, 并将平面上的物理节点及其连接映射为 SWESN 的内部神经元连接矩阵, 从而使动态神经元池具有 small world 特性. 实验表明, SWESN 动力学特性比常规 ESN 更为丰富, 在鲁棒性、抗干扰能力等方面均优于常规的 ESN.

关键词: 回声状态网络; 小世界; 动态神经元池; 动力学特性

中图分类号: TP273

文献标识码: A

Analysis and design on structure of small world property ESN

BO Ying-chun, QIAO Jun-fei, ZHANG Zhao-zhao

(College of Electronic and Control Engineering, Beijing University of Technology, Beijing 100124, China.

Correspondent: BO Ying-chun, E-mail: boyingchun@sina.com)

Abstract: For the problems of complex structure design and hard parameters selection on echo state network (ESN) frame, this paper proposes a structure design method of dynamic neurons reservoir (DNR) with the small world structure (SWESN). Design method of SWESN is introduced in detail. Neurons space growth algorithm is used to generate network with small world topology structure on 2-D plane. Then the neurons are rearranged by Euclidean distance from network's nodes to the fiducial node, and the physical nodes of the plane region and their internal connections are mapped to the connection matrixes of ESN internal neurons. This design method makes the DNR have small world property. The simulation experiments show that, the proposed ESN can create more abundant dynamic behavior than conventional ESN, and both robustness and anti-interference ability of SWESN are better than that of conventional ESN.

Key words: echo state network; small world; dynamic neurons reservoir; dynamic behavior

1 引言

回声状态网络^[1](ESN)是一种新型的递归神经网络,其结构核心是一个动态神经元池(DNR),池内包含的成百上千个神经元以完全随机和稀疏的方式连接. Mustafa 等人^[2]指出, ESN 在结构上更接近于生物学网络,如神经元反馈、稀疏连接等,只需确定隐层与输出层的连接权值即可,使得其学习非常快速,同时缓解了传统人工神经网络学习过程中易陷入局部极小的问题. 近十几年来, ESN 在系统辨识、时间序列预测等领域表现出较强的应用前景^[3-4], 逐渐成为人工神经网络领域研究的热点之一.

目前, ESN 的结构设计问题仍然是限制 ESN 广

泛应用的瓶颈, 研究认为^[5-7], ESN 内部动力学特性的丰富程度对于系统性能有较大影响. 动力学特性越丰富, 其逼近及记忆能力越强. 而 ESN 内部动力学特性与内部神经元个数、谱半径、稀疏度等多个参数相关, 为了获得较好的性能, 不得不对多个参数进行不断的测试, 所以 ESN 结构参数选择难度较大. 一些学者针对 ESN 的结构设计问题进行了相应的研究, 文献 [6] 采用模块化思想将 DNR 进行分解, 简化了 ESN 的设计, 为不同的 DNR 设置不同的谱半径, 从而使 ESN 内部产生多个不同的状态, 丰富了 ESN 内部的动力学行为, 成功解决了 MSO (multiple superimposed oscillator) 问题. [7] 提出了一种基于 Renyi 二次型熵的

收稿日期: 2010-10-20; 修回日期: 2011-05-18.

基金项目: 国家自然科学基金重点项目(61034008); 国家自然科学基金项目(60873043); 北京市自然科学基金项目(4092010); 教育部博士点基金项目(200800050004); 北京市属高等学校人才强教计划项目(PHR201006103).

作者简介: 薄迎春(1977-), 男, 博士生, 从事神经计算与智能优化控制的研究; 乔俊飞(1968-), 男, 教授, 博士, 从事智能控制与智能信息处理等研究.

DNR 设计方法, 指出 ESN 的设计应使神经元池的信息熵最大化. 上述两种方法在一定程度上提高了 ESN 的泛化能力, 但仍需要不断测试 DNR 的参数 (尤其需要选择合适的谱半径) 才能取得较好的效果, 参数选择难度仍然较大. 研究表明^[8], 动物顶骨皮层的神经元相当于一系列基函数, 这些基函数将输入信息编码到一个高维空间, 从而为后续的处理做准备, 而后续处理可能非常简单, 这与 ESN 的原理较为类似. [9] 指出生物体神经元的结构具有 small world 特性, 该特性使生物神经元出现明显的模块化结构. 不同模块包含的神经元个数不同, 采用的神经元类型各异, 从而使生物体内部的动力学特性极为丰富, 增强了生物体处理信息的能力^[10]. 完全随机的连接导致所有神经元之间存在较强的耦合, 限制了神经元的动力学特性^[6]. 而生物体的 small world 特性则可以弱化神经元之间的耦合程度, 从而使神经元的动力学特性更为丰富, 进而使网络具有较强的参数适应能力.

针对 ESN 设计中结构参数选择困难的问题, 本文提出了一种具有 small world 特性的 ESN-SWESN. 在 SWESN 中, 不同的神经元群体可以采用不同类型的神经元. 仿真研究表明, 与常规 ESN 相比, SWESN 的参数适应性较强, 在较为宽泛的参数取值范围内, SWESN 的鲁棒性、抗干扰能力均优于常规 ESN.

2 ESN 分析

传统 ESN 的结构如图 1 所示, 包括输入层、动态神经元池及输出层.




图 1 ESN 结构

设网络输入为 $u(n) = [u_1(n), u_2(n), \dots, u_K(n)]^T$, 状态为 $x(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T$, 输出为 $y(n) = [y_1(n), y_2(n), \dots, y_L(n)]^T$. 其中: K 为输入维数, N 为内部神经元个数, L 为输出维数. 有

$$x(n+1) = f(W^{\text{in}}u(n+1) + Wx(n) + W^b y(n)), \quad (1)$$

$$y(n+1) = f^o(W^o x(n+1)). \quad (2)$$

其中: W^{in}, W, W^b 分别为输入、内部状态、输出到内部状态的连接权值矩阵, 维数分别为 $N \times K, N \times N, N \times L$; W^o 为内部状态到输出的连接权值矩阵, 维数为 $N \times L$; $f = (f_1, f_2, \dots, f_N)$ 为内部神经元激活函数; f^o 为输出函数, 一般取为线性函数. ESN 的 W, W^{in} 和 W^b 均在学习前确定, 且在学习和测试过程中保持不变, 即 ESN 的学习只需确定 W^o 的值. 为了分

析方便, 令 $L = 1, f^o$ 取线性函数, 即

$$Y = XW^o. \quad (3)$$

ESN 采用的学习算法通常如下: 设训练样本个数为 N_s , 期望输出为 $Y^* = [d_1, d_2, \dots, d_{N_s}]^T$, 有

$$W^o = (X)^+ Y^*. \quad (4)$$

其中: X 为训练过程中内部神经元状态序列矩阵, 且

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1N} \\ x_{21} & x_{22} & \dots & x_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N_s 1} & x_{N_s 2} & \dots & x_{N_s N} \end{bmatrix};$$

$X^+ = (X^T X)^{-1} X^T$ 为 X 的 Moore-Penrose 逆. 显然, 若 $X^T X$ 奇异, 则会引起 W^o 的不稳定. 文献 [11] 采用岭回归学习方法解决 $X^T X$ 奇异问题, 但该方法中岭参数的选择与观测数据有关, 选择过程较为复杂. 文献 [4] 采用奇异值分解方法, 通过舍弃小的奇异值将近似相关的问题转化为近似不相关. 由于常规 ESN 的节点完全随机连接, 且连接权值只在较小的范围内取值, 节点间的相关度较高, 导致绝大部分 $X^T X$ 的奇异值非常小, 从而使大部分奇异值被舍弃, 这必然会导致 W^o 的误差增大.

解决上述问题的根源在于 $X^T X$ 的奇异性, 这与内部神经元状态密切相关. 若内部神经元状态的相关性较强 (内部神经元状态趋同), 则 $X^T X$ 奇异性较强, 此时会产生较多小的奇异值, 导致式 (4) 的解不稳定; 若内部神经元状态的相关性弱 (内部神经元状态多样化), 则 $X^T X$ 奇异性较弱, 此时产生的小奇异值较少. 所以, 提高 ESN 内部神经元状态的多样性 (或内部动力学特性的丰富程度) 是解决问题的关键.

为了分析内部神经元的相关性, 引入 Pearson 相关系数

$$r(x_i, x_j) = \frac{\sum_{k=1}^{N_s} (x_{ik} - E(x_i))(x_{jk} - E(x_j))}{N_s \sigma_{x_i} \sigma_{x_j}}. \quad (5)$$

其中: x_i 和 x_j 为内部神经元的输出序列, $E(x_i)$ 为 x_i 的期望, σ_{x_i} 为 x_i 的方差. Pearson 相关系数反映了两个神经元输出的线性相关程度. 实验表明, 无论参数如何选择, 常规 ESN 大部分神经元的相关度均在较高的水平. 令

$$r_a = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N u(r(x_i, x_j) - \delta). \quad (6)$$

$$u(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases} \quad (7)$$

其中: δ 为相关强度阈值, 若 $r(x_i, x_j) > \delta$, 则认为 x_i, x_j 的线性相关程度较高, 否则认为 x_i, x_j 的线性相关程度较低, 本文取 $\delta = 0.7$; r_a 反映了相关程度高的内

部神经元所占的比重,将其定义为内部神经元的线性综合相关度.仿真表明,常规 ESN 的线性综合相关度较高,约为 0.8.这表明 ESN 内部神经元状态趋同,导致内部动力学特性的丰富性降低.引起此问题的原因在于 ESN 内部神经元是完全随机连接的,每个神经元的地位等同,连接度相同,这使得所有神经元之间存在较强的耦合,从而限制了 DNR 内部动力学特性的多样性.而 small world 特性可以将神经元整体分组,不同组之间只有稀疏的连接,导致不同组之间的耦合程度大大降低,即使在同一组内,各神经元也只与邻近的神经元存在较强的连接,而与相对较远的神经元连接较弱,从而使不同组之间,甚至同一组内部的神经元状态的多样性增加,ESN 内部动力学特性更为丰富. small world 结构的模块化特性也为不同神经元群体配置不同的激活函数提供了方便.

3 SWESN 的设计

3.1 SWESN 结构设计

文献 [12] 提出了一种基于空间增长模型的 small world 网络生成方法,并成功地模拟了猫的脑皮层结构.该方法首先在平面上随机选定一个点作为初始节点,后续节点以概率 P 与已存在节点连接,有

$$P(u, v) = \beta e^{-\alpha d(u, v)}. \quad (8)$$

其中: β 为密集度系数, α 为空间范围系数, $d(u, v)$ 为新增节点 u 与已存在节点 v 之间的 Euclidean 距离.显然,新增节点与已存在节点间的连接概率随节点间距离的增加呈指数下降,从而保证了距离近的节点连接紧密,距离较远的节点连接稀疏.通过选择合适的参数 α 和 β , 使生成的网络具备 small world 特性.

上述方法虽然可以生成 small world 网络,但生成的群集个数不易控制,无法实现双向连接及自反馈.所以,本文对文献 [12] 的方法进行了改进,引入支撑节点个数和自反馈概率等参数,以实现具有特定群集个数、双向连接并具有自反馈的 small world 网络.具体步骤如下:

Step 1: 选定平面区域范围 $x \in [0, 1], y \in [0, 1]$. 根据式 (8), 新增节点总是优先与距离近的节点连接,因此,在 (0,1) 与 (1,0) 两点确定的轴线上平均放置 N_c 个支撑节点,第 i 个支撑节点坐标为

$$x_i = \frac{i}{N_c + 1}, y_i = 1 - \frac{i}{N_c + 1}. \quad (9)$$

支撑节点引导后续节点向支撑节点集中,从而引导网络生成 N_c 个群集, N_c 个支撑节点为双向全连接.以 N_c 个支撑节点构成的网络为初始网络,其节点数为 N_c , 连接数为 $N_c(N_c - 1)$.

Step 2: 在初始网络的基础上,新增节点按式 (8) 与已存在节点进行连接,已存在节点也按式 (8) 与新

增节点进行连接,构成双向连接.若新增节点与已存在节点未形成连接,则将该节点舍弃,重复 Step 2,直到节点数量达到设定的节点数上限 N_{\max} 为止.

Step 3: 网络生成后,每个节点以概率 P_s 进行自反馈连接.网络生成过程中,节点坐标信息及连接信息分别存储到 N_I 及 L_I 数组中.采用上述算法生成的网络结构如图 2 所示,图 2 中, $N_c = 2, N_{\max} = 200$.




图 2 small world 网络结构

3.2 small world 网络到 W 矩阵的映射

DNR 结构的确定实质上是矩阵 W 的确定.所以,需将前面生成的 small world 网络结构映射到 W 中.将 W 改写为

$$W = \begin{bmatrix} W_1 & \cdots & L_1 \\ \vdots & \ddots & \vdots \\ L_2 & \cdots & W_{N_c} \end{bmatrix}. \quad (10)$$

其中: $W_c (c = 1, 2, \dots, N_c)$ 为第 i 个内部神经元群体的连接矩阵; L_1, L_2 为所有群体间的连接. small world 网络到 W 矩阵的映射主要包括节点序号重排、神经元所属群集确定、连接强度确定 3 部分:

1) 节点序号重新排列.由式 (10) 可见,同一群集内部神经元的编号是连续的,而生成的 small world 网络中属于同一群集的节点其物理位置也是相近的.生成 small world 网络时,节点序号按照节点出现的先后顺序排列,使得物理位置相近的节点序号未必相近,所以首先要实现物理位置与序号的对应,使物理位置相近节点的序号也相近.具体做法如下:

Step 1: 选取某一平面区域某一点作为基准点,计算各节点与基准节点的 Euclidean 距离 $d_i (i = 1, 2, \dots, N_{\max})$.

Step 2: 对 d_i 按照升序排列,与 d_i 对应的 small world 网络的节点在 W 中编号为 i .

Step 3: 将 N_I 和 L_I 中的节点信息进行同步更新.

经过节点重新排序后, small world 网络节点的物理位置相邻的节点在 W 中的编号也是相邻的.

2) 神经元所属群集的确定.每个群集内部神经元个数可以是不同的,即每个 W_c 中包含的元素个数可以不同,因此必须对每个 W_c 包含的神经元进行甄别.支撑节点可以视为群集的中心,神经元所属群集通过下式判断:

$$C_i = \arg(c) \min(d(N_{I_i}, Z_c). \quad (11)$$

其中: C_i 为第 i 个神经元所属群集序号; Z_c 为第 c ($c = 1, 2, \dots, N_c$) 个支撑神经元坐标; $d(N_{I_i}, Z_c)$ 为第 i 个神经元到第 c 个支撑神经元的 Euclidean 距离. 根据式 (11), 神经元 i 属于与群集中心距离最近的群集.

3) 连接强度确定. 连接强度确定实质上是确定 W 中的元素, 神经元的连接可分为神经元的自反馈 S_{self} , 群集内部的连接 S_{in} , 群集之间的连接 S_{out} 三种情况, 由下式进行判断:

$$\begin{cases} LI_k \in S_{\text{self}}, N_{I_i} = N_{I_j}; \\ LI_k \in S_{\text{in}}, N_{I_i} \neq N_{I_j}, C_i = C_j; \\ LI_k \in S_{\text{out}}, N_{I_i} \neq N_{I_j}, C_i \neq C_j. \end{cases} \quad (12)$$

其中: N_{I_i}, N_{I_j} 为第 i, j 个神经元的坐标; C_i, C_j 为第 i, j 个神经元所属群集; $LI_k(i, j)$ 为第 k 个连接 (其起点和终点神经元编号分别为 i, j). W 中的元素体现了神经元之间的连接强度, 谱半径 ρ 是 DNR 设计的一个重要参数, 有

$$\rho(W) = \max|\lambda_i|. \quad (13)$$

其中: $\rho(W)$ 为 W 的谱半径, λ_i ($i = 1, 2, \dots, N$) 为 W 的特征值. Jaeger^[1]指出, 当 $\rho(W) < 1$ 时, ESN 是稳定的. 为 W_c ($c = 1, 2, \dots, N_c$) 设置不同的谱半径即可使不同的神经元群集具有不同的动力学特性, 从而增强 DNR 内部状态的多样化. 谱半径的设置如下^[1-2]: 令 $\mathbf{a}_c = [a_c, -a_c]$ ($c = 1, 2, \dots, N_c$), $\mathbf{b} = [b, -b]$, $\mathbf{s} = [s, -s]$ 分别为第 c 个神经元群集内部、群集之间以及自反馈的强度备选值. 若神经元 i, j 之间存在连接, 则 W_{ij} 由下式确定:

$$W_{ij} = \begin{cases} ps - (1-p)s, LI_k \in S_{\text{self}}; \\ pa_c(1-p)a_c, LI_k \in S_{\text{in}}, C_i = c; \\ pb(1-p)b, LI_k \in S_{\text{out}}. \end{cases} \quad (14)$$

其中

$$p = \begin{cases} 1, \text{rand}() \leq 0.5; \\ 0, \text{rand}() > 0.5. \end{cases} \quad (15)$$

这样, 通过选择合适的连接强度参数 a_c , 可以使 $\rho(W_c)$ ($c = 1, 2, \dots, N_c$) 不同, 从而使每个神经元群集有不同的内部状态. 通过调整 b, s 的值, 可以对 $\rho(W)$ 进行调整, 以保证 ESN 的稳定性.

4 仿真实验与分析

为了验证 SWESN 的性能, 选择鲁棒性、干扰敏感性两个指标与常规 ESN 进行对比分析.

4.1 鲁棒性分析

定义神经网络的鲁棒性如下:

$$\rho(\theta) = \frac{\sum_{i=1}^K u(e_i - \theta)}{K}. \quad (16)$$

其中: K 为 Monte Carlo (MC) 测试次数^[6], e_i 为第 i 次测试的均方误差, θ 为阈值, $\rho(\theta)$ 能够反映神经网络测试的成功率, 函数 u 功能同式 (7). 选择 ESN 的典型问题 MSO 问题作为研究对象, 描述如下:

$$y(k) = \sin 0.2k + \sin 0.311k, k = 1, 2, \dots \quad (17)$$

MSO 问题是两个不同频率正弦波叠加成的时间序列预测问题. 按照式 (17) 产生 1000 个时间离散的样本点, 前 700 个用于学习, 后 300 个用于测试. 在 $[-1, 1]$ 区间随机初始化所有内部神经元状态. 在参数不变的情况下, 对常规 ESN, SWESN₁, SWESN₄ 各进行 500 次测试, SWESN _{m} 表示 SWESN 内部共采用 m 种不同类型的神经元. 测试中取 $N_c = 4, \theta = 0.0034$ ^[6], 测试结果如表 1 所示.

表 1 ESN 和 SWESN 的鲁棒性测试结果

	ESN	SWESN ₁	SWESN ₄
r_a	0.81	0.65	0.36
$\rho(W)$	0.88	0.89	0.89
$\rho(\theta)/\%$	86.2	96.1	97.8

由表 1 可见, 在谱半径适当的情况下, SWESN 的鲁棒性高于常规 ESN. SWESN₁ 的综合相关度较常规 ESN 低, 这表明 SWESN 的内部神经元状态更为丰富, 其原因在于 SWESN 降低了神经元之间连接的耦合程度. 采用不同类型的神经元时 (SWESN₄ 采用的 4 种神经元类型分别为 sigmoid, tan, sin, cos 函数) 这种特性更为明显. 谱半径是 ESN 设计中的重要参数, 与神经元个数、稀疏度、备选连接权值大小等多个参数密切相关. 所以, 需要研究谱半径变化对于 ESN 及 SWESN 的性能影响. 对 ESN 和 SWESN 在相近谱半径下各进行 50 次测试, 共选择 15 组谱半径进行测试 (测试总数为 750 次).

图 3 和图 4 分别为 ESN 与 SWESN 的鲁棒性和每组测试均方误差平均值随谱半径变化的情况. 由图 3 和图 4 可见, 随着谱半径的增加, 常规 ESN 的鲁棒性有增加的趋势, 误差有减小的趋势. SWESN₁ 的鲁棒性及测试误差随谱半径的变化较常规 ESN 明显减弱. 这说明 small world 特性增强了内部神经元的动力学行为. SWESN₄ 采用不同类型的神经元进一步提高了内部神经元的动力学的丰富性. 这表明 SWESN 对于参数变化的适应性比常规 ESN 明显增强. SWESN₄ 在较为宽泛的谱半径范围内具有较高的鲁棒性, 进一步表明了 ESN 内部动力学特性的丰富程度与网络性能关系密切, 这与文献 [1,5-7] 的研究结果是一致的. 表 2 为常规 ESN 与 SWESN 中 $X^T X$ 矩阵的奇异值分布情况. 从表 2 可以看出, SWESN 的小奇异值比常规 ESN 明显降低, 从而可知 SWESN 能够提高学习精度. 对混沌 (Mackey-Glass) 系统的仿真实验

也得到上述结论.




图3 鲁棒性随谱半径变化曲线




图4 测试均方误差随谱半径变化曲线

表2 不同网络 X^TX 的奇异值分布

奇异值	ESN	SWESN ₁	SWESN ₄
≤ 1.4 × 10 ⁻⁴	0.949	0.942	0.842
≤ 3.1 × 10 ⁻⁶	0.512	0.242	0.128
≤ 2.5 × 10 ⁻⁸	0.424	0	0

4.2 抗干扰性分析

常规 ESN 对干扰较为敏感^[5-6,11], 在样本中加入较小的扰动就会大幅度降低 ESN 的泛化精度. 为了测试 SWESN 的抗干扰能力, 在式 (17) 样本中加入 [-0.05, 0.05] 范围内的随机干扰. 对 3 种网络各进行 100 次测试, 取误差最小的 20 次进行对比. 图 5 为在噪声学习情况下 3 种网络的测试均方误差变化情况.




图5 3种网络在样本存在噪声情况下的测试误差曲线

由图 5 可见, 加入噪声后, 3 种网络的泛化精度均大幅降低, 这说明 3 种网络对于噪声都比较敏感, 但相比之下, SWESN 受噪声干扰的程度比常规 ESN 约降低 7 倍, 表明 SWESN 比常规 ESN 具有更好的噪声学习能力.

由于实际测量的数据都是带有噪声的, 选取实际观测数据集-太阳黑子数据集^[13]进行预测研究, 以

检验 SWESN 解决实际问题的能力. 该数据集中包含 3 141 个数据, 取前 2 000 个数据, 前 1 000 个样本用于训练, 后 1 000 个样本用于测试, 采取 10 步预测, 即期望值为 $y(k + 10)$ ^[11], $k = 1, 2, \dots$, 预测结果如图 6 所示.




图6 SWESN₄对太阳黑子时间序列预测曲线

表 3 为 SWESN₄ 与 ESN 对太阳黑子预测的相对误差及样本分布表. 由表 3 可见, SWESN₄ 预测中, 95.1% 的样本测试误差在 10% 以内, 86.3% 的样本测试误差在 5% 以内, 测试均方误差为 1.083; 常规 ESN 的均方差为 2.804, 测试误差在 10% 以内的样本为 87.6%. 从表 3 可以看出, SWESN 在一定的精度范围内总体预测效果优于常规 ESN.

表3 太阳黑子预测相对误差与样本分布表

相对误差	≤ 1%	≤ 2%	≤ 5%	≤ 10%
样本个数 (SWESN)	252	538	863	951
样本个数 (ESN)	269	452	748	876

5 结 论

从仿生学的角度研究生物体神经网络的结构及其信息处理方式是神经网络的发展方向之一, 本文模拟生物体的网络结构设计了一种具有 small world 特性的 SWESN. 与常规 ESN 相比, SWESN 具有如下优点:

1) 神经元间 small world 特性的连接方式降低了神经元间的耦合程度, 提高了 DNR 内部神经元动力学特性的丰富程度.

2) 动力学特性丰富程度的提高增强了 SWESN 参数适应性, 即使在谱半径较小的情况下, SWESN 也可以表现出较丰富的动力学特性.

3) 动力学特性丰富程度的提高降低了内部神经元输出的线性相关性, 减少了 $X^T X$ 小奇异值数量, 提高了学习的精确性.

参考文献(References)

[1] Herbert J. The echo state approach to analysing and training recurrent neural networks[R]. German National Research Center for Information Technology, 2001, 12(8): 1-43.

- [2] Mustafa C O, Xu D M, Principe J C. Analysis and design of echo state networks[J]. *Neural Computation*, 2007, 19(1): 111-138.
- [3] Herbert J. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. *Science*, 2004, 204(5667): 78-80.
- [4] 刘颖, 赵珺, 王伟, 等. 基于数据的改进回声状态网络在高炉煤气发生量预测中的应用[J]. *自动化学报*, 2009, 35(6): 732-738.
(Liu Y, Zhao J, Wang W, et al. Improved echo state network based on data-driven and its application to prediction of blast furnace gas output[J]. *Acta Automatic Sinica*, 2009, 35(6): 732-738.)
- [5] Herbert J. Reservoir riddles: Suggestions for echo state network research (extended abstract)[C]. *Proc of Int Joint Conf on Neural Networks*. Montreal, 2005: 1460-1461.
- [6] Xue Yan-bo, Yang Le, Simon Haykin. Decoupled echo state networks with lateral inhibition[J]. *Neural Networks*, 2007, 20(3): 365-376.
- [7] Ozturk M C, Xu D, Principe J C. Analysis and design of echo state networks[J]. *Neural Computation*, 2007, 19(1): 111-138.
- [8] Pouget R, Terrence J S, Alexandre P. Spatial transformations in the parietal cortex using basis functions using basis functions[J]. *J of Cognitive Neuroscience*, 1997, 9(2): 222-237.
- [9] Watts D J, Strogatz S H. Collective dynamics of small-world networks[J]. *Nature*, 1998, 393(4): 440-442.
- [10] Gail A C. Large-scale neural systems for vision and cognition[C]. *Proc of Int Joint Conf on Neural Networks*. Piscataway: IEEE Press, 2009: 14-19.
- [11] 史志伟, 韩敏. ESN岭回归学习算法及混沌时间序列预测[J]. *控制与决策*, 2007, 22(3): 258-267.
(Shi Z W, Han M. Ridge regression learning in ESN for chaotic time series prediction[J]. *Control and Decision*, 2007, 22(3): 258-267.)
- [12] Marcus K, Claus C H. Modelling the development of cortical systems networks[J]. *Neurocomputing*, 2004, 58(58): 297-302.
- [13] National aeronautics and space administration[EB/OL]. (2010-02-16)[2010-04-02]. <http://solarscience.msfc.nasa.gov/greenwch/>, 2010.

(上接第382页)

- [2] 周东华, Ding X. 容错控制理论及其应用[J]. *自动化学报*, 2000, 26(6): 788-797.
(Zhou D H, Ding X. Theory and applications of fault tolerant control[J]. *Acta Automatica Sinica*, 2000, 26(6): 788-797.)
- [3] Grossman J P. Analytically modeling a fault-tolerant messaging protocol[J]. *IEEE Trans on Computers*, 2004, 53(7): 870-878.
- [4] Li W Q, Chen Z J. Signal reconfiguration method for aircraft's pitch angular rate[J]. *Flight Dynamics*, 2004, 22(2): 26-29.
- [5] Liu G J, Wang D J, Li Y C. Active fault tolerant control with actuation reconfiguration[J]. *IEEE Trans on Aerospace and Electronic Systems*, 2004, 40(3): 1110-1117.
- [6] 徐延万. 控制系统[M]. 北京: 宇航出版社, 1991: 16-18.
(Xu Y W. Control system[M]. Beijing: China Astronautics Publishing House, 1991: 16-18.)
- [7] 胡昌华, 许化龙. 控制系统故障诊断与容错控制的分析与设计[M]. 北京: 国防工业出版社, 2000: 225-227.
(Hu C H, Xu H L. Design and analysis of fault-tolerant control and fault diagnosis for control system[M]. Beijing: National Defence Industry Press, 2000: 225-227.)
- [8] 陈世年. 控制系统设计[M]. 北京: 宇航出版社, 1996: 488-494.
(Chen S N. Design of control system[M]. Beijing: China Astronautics Publishing House, 1996: 488-494.)
- [9] 宿敬亚, 张瑞峰, 王新华, 等. 基于滤噪微分器的四旋翼飞行器控制[J]. *控制理论与应用*, 2009, 26(8): 827-832.
(Su J Y, Zhang R F, Wang X H, et al. Controlling a four-rotor aircraft based on noise-attenuation differentiator[J]. *Control Theory & Application*, 2009, 26(8): 827-832.)
- [10] Wang X H, Chen Z Q, Yang G. Finite-time-convergent differentiator based on singular perturbation technique[J]. *IEEE Trans on Automatic Control*, 2007, 52(9): 1731-1737.
- [11] Davaid Kincaid, Ward Cheney. Numerical analysis: Mathematics of scientific computing[M]. Warsworth Group, 2002: 383-385.
- [12] 刘湘崇, 梁彦, 程咏梅, 等. 导弹控制系统的容错控制研究[J]. *控制与决策*, 2006, 21(10): 1185-1189.
(Liu X C, Liang Y, Cheng Y M, et al. On fault-tolerant control of missile control systems[J]. *Control and Decision*, 2006, 21(10): 1185-1189.)