

一种增量式模块化回声状态网络

李凡军^{1,2}, 乔俊飞¹

(1. 北京工业大学 a. 电子信息与控制工程学院, b. 计算智能与智能系统北京市重点实验室, 北京 100124; 2. 济南大学 数学科学学院, 济南 250022)

摘要: 针对传统回声状态网络(ESN)难以解决多振荡子叠加(MSO)问题, 提出一种增量式模块化回声状态网络(IM-ESN). 该网络储备池由多个相互独立的子储备池组成. 利用矩阵的奇异值分解(SVD)构造每个子储备池的权值矩阵, 并依据分块对角矩阵原理, 将子储备池逐一添加至网络中. 在网络增长过程中, IM-ESN 无需放缩权值矩阵便能保证网络的状态回声特性. MSO 问题的仿真结果表明, IM-ESN 能够自主确定与问题复杂度相匹配的网络规模, 具有较好的预测性能和鲁棒性.

关键词: 回声状态网络; 储备池; 多振荡子叠加问题; 奇异值; 预测

中图分类号: TP273

文献标志码: A

An incremental modular echo state network

LI Fan-jun^{1,2}, QIAO Jun-fei¹

(1a. College of Electronic Information and Control Engineering, 1b. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing University of Technology, Beijing 100124, China; 2. School of Mathematical Science, University of Ji'nan, Ji'nan 250022, China. Correspondent: LI Fan-jun, E-mail: ss_lifj@ujn.edu.cn)

Abstract: An incremental modular echo state network(IM-ESN) is proposed to solve the multiple superimposed oscillator(MSO) problem, which is difficult to be solved by conventional ESNs. The reservoir of IM-ESN is made up of sub-reservoirs which are mutually independent. The weight matrices of sub-reservoirs are designed via the singular value decomposition(SVD) method. Based on the block diagonal matrix theory, the generated sub-reservoirs are added to the existing network one by one. During the growth of the network, IM-ESN can guarantee the echo state property without posterior scaling of the weights. The experiment results on the MSO problem show that the IM-ESN can determine its network complexity to match the given applications automatically, with better prediction performance and robustness.

Keywords: echo state network; reservoir; MSO problem; singular value; prediction

0 引言

回声状态网络(ESN)是一种新型的递归神经网络^[1-2]. 与传统递归神经网络不同, ESN拥有一个随机、庞大、稀疏连接的动态储备池. 当储备池的权值矩阵满足一定的代数条件时, ESN具有很好的稳定性和动态特性. 在网络训练过程中, ESN只需要通过线性回归算法确定储备池及输入层与输出层的连接权值, 保持其他权值固定不变. 简单有效的训练方法使得ESN避免陷入局部极小, 具有非常快的学习速度^[2]. 近十几年来, ESN引起了人们的广泛关注, 已成功地应用于时间序列预测、控制、非线性系统

辨识、语音识别等领域^[3-7]. 然而, 传统ESN难以解决MSO (multiple superimposed oscillator) 问题^[8].

MSO问题是由多个不同频率正弦波叠加而成的时间序列预测问题. 学习产生一个正弦曲线比较容易, 但多个不同频率的正弦波叠加, 波长变得非常长, 甚至失去周期特性, 预测异常困难, 传统ESN难以解决^[9]. 因此, MSO问题已成为ESN研究领域的标杆问题, 引起诸多研究者的关注^[8-9]. 多频率信号叠加问题在信号处理、振动系统、语音识别及气象学等领域较为常见^[10], 因而解决MSO问题具有现实意义.

储备池神经元间的耦合特性是传统ESN难以解

收稿日期: 2015-07-19; 修回日期: 2015-11-13.

基金项目: 国家自然科学基金项目(61203099, 61225016, 61533002); 北京市自然科学基金项目(Z141100001414005); 北京市教委基金项目(km201410005001, KZ201410005002); 中国博士后基金项目(2014M550017).

作者简介: 李凡军(1977-), 男, 副教授, 博士生, 从事智能信息处理及神经网络结构优化设计的研究; 乔俊飞(1968-), 男, 教授, 博士生导师, 从事智能控制与智能信息处理等研究.

决 MSO 问题的主要原因^[8-9]. 因此, Xue 等^[8]提出了解耦回声状态网络 (DESN), 其储备池由多个子储备池组成, 子储备池间引入侧抑制连接, 促进储备池神经元间部分解耦, 实现了对两个不同频率正弦波叠加信号的预测. 薄迎春等^[11]设计了具有小世界特性的状态回声网络, 以削弱储备池神经元间的耦合特性, 较好地解决了两个正弦波叠加的 MSO 问题. Fiers 等^[12]通过硬件构造纳米光子储备池, 产生周期信号, 在两个正弦波叠加的 MSO 问题上取得了优于传统 ESN 的预测效果. Song 等^[13]提出了类皮层储备池复杂状态回声网络 (CESN), 并在实验中添加适当噪声, 对两个正弦波的 MSO 问题取得了 $1 \text{ e-}5$ 量级的预测精度. 宋青松等^[14]利用粒子群优化 ESN 输出权值以获得稳定输出, 成功解决了两个正弦波的 MSO 问题. 然而, 上述方法仅限于讨论两个正弦波的叠加, 对于多个正弦波叠加的 MSO 问题未曾涉及.

Schmidhuber 等^[15]通过改进的 LSTM (long short-term memory) 网络, 分别对 2、3、4、5 个不同频率的正弦波叠信号加进行预测, 均取得了成功, 但后两种情况预测精度不高. Holzmann 等^[16]将滤波神经元及延时读取神经元引入传统 ESN, 对多个正弦波叠加的 MSO 问题, 取得了优于文献 [15] 的预测效果. Koryakin 等^[17]通过平衡输出反馈及内部状态递归对储备池内部动态的影响, 提出平衡回声状态网络 (BESN), 解决了多个正弦波叠加的 MSO 问题. BESN 可以设计非常小的输出反馈及内部状态递归, 使得储备池神经元在激活函数的线性区域响应近似于线性 ESN. 尽管线性 ESN 比较容易解决 MSO 问题, 但其稳定性较差. Jaeger 等^[18]通过对学习过程添加噪声, 获得了相对稳定的测试结果. 而在训练过程中添加噪声则意味着降低网络的预测精度^[2].

鉴于上述分析, 本文提出一种增量式模块化回声状态网络 (IM-ESN). IM-ESN 拥有一个增量式模块化结构, 其储备池由相互独立的子储备池逐一添加而成, 可以实现储备池部分神经元解耦. 子储备池的权值矩阵由给定的奇异值谱基于奇异值分解 (SVD) 构造, 无需对权值矩阵放缩即可确保网络的稳定性. 根据检验误差设置网络增长终止条件, IM-ESN 能够自主确定与给定问题相匹配的网络规模. 针对多个正弦波叠加的 MSO 问题仿真, 均获得了较高且稳定的预测精度, 从而表明了算法的有效性.

1 MSO 问题

MSO 是由两个或更多不同频率正弦波叠加而成的准周期时间序列, 即

$$d(t) = \sum_{i=1}^M \sin(\alpha_i t). \quad (1)$$

其中: M 为正弦波的数量, α_i 为第 i 个正弦波的频率, t 为序列时间. 本文讨论 2 ~ 8 个正弦波叠加的 MSO 问题, 记为 MSO x ($x = 2, 3, 4, 5, 6, 7, 8$), 其中 x 表示正弦波的个数. 根据文献 [17], 频率分别设为: $\alpha_1 = 0.2$, $\alpha_2 = 0.311$, $\alpha_3 = 0.42$, $\alpha_4 = 0.51$, $\alpha_5 = 0.63$, $\alpha_6 = 0.74$, $\alpha_7 = 0.85$, $\alpha_8 = 0.97$. 显然, 各频率相互不存在最小公倍数, 叠加信号不满足周期条件, 是准周期时间序列. 图 1 给出了 MSO 时间序列 400 ($1 \leq t \leq 400$) 步的图像 (自上而下分别为 MSO2、MSO4、MSO6 及 MSO8). 如图 1 所示, 随着正弦波叠加数量的增加, 其信号幅值及波长逐渐增大, 震荡加剧, 预测难度增加.




图 1 MSO 时间序列

传统 ESN 难以解决 MSO 问题的主要原因是: 储备池神经元相互耦合, 难以同时产生多个不同频率的振荡器^[8-9]. 线性储备池可以获得较高精度的训练精度, 但其在自治测试阶段稳定性较差^[18]. 训练过程中添加噪声, 可以获得相对稳定的输出, 但也会降低预测精度. 设计稳定精确的 MSO 发生器或预测模型是 ESN 研究领域的标杆问题之一, 即 MSO 问题.

2 IM-ESN

2.1 传统 ESN

传统 ESN 的储备池神经元稀疏随机连接, 彼此耦合在一起, 方程描述如下:

$$\begin{aligned} \mathbf{x}(n+1) = & \\ f(\mathbf{W}\mathbf{x}(n) + \mathbf{W}^{\text{in}}\mathbf{u}(n+1) + \mathbf{W}^b\mathbf{y}(n)), & \quad (2) \end{aligned}$$

$$\mathbf{y}(n+1) = f^o(\mathbf{W}^o\mathbf{x}(n+1)). \quad (3)$$

其中: $\mathbf{u}(n)$ 、 $\mathbf{x}(n)$ 、 $\mathbf{y}(n)$ 分别为网络的输入信号、储备池神经元状态及输出信号; \mathbf{W}^{in} 、 \mathbf{W} 、 \mathbf{W}^b 、 \mathbf{W}^o 分别为网络的输入、储备池、输出反馈、输出权值矩阵; f 、 f^o 分别为储备池神经元及输出神经元激活函数. 在网络的训练过程中, \mathbf{W}^{in} 、 \mathbf{W} 、 \mathbf{W}^b 随机生成并保持不变. 自 $n_{\min} + 1$ 时刻开始收集内部状态 $\mathbf{H} = [\mathbf{x}(n_{\min} + 1), \mathbf{x}(n_{\min} + 2), \dots, \mathbf{x}(n_{\max})]^T$, 教师信号 $\mathbf{D} = [\mathbf{d}(n_{\min} + 1), \mathbf{d}(n_{\min} + 2), \dots, \mathbf{d}(n_{\max})]^T$, 若 f^o 为线性函数, 则由最小二乘法可求出 \mathbf{W}^o 为

$$\mathbf{W}^o = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{D}. \quad (4)$$

与传统的递归神经网络相比, ESN 训练简单有效, 但参数较多, 设计过程需要大量尝试甚至运气, 而且储备池神经元的耦合特性难以解决 MSO 问题^[8].

2.2 IM-ESN 设计

IM-ESN 的储备池具有增量式模块化拓扑结构, 如图2所示. 由相互独立的子储备池逐一添加, 直至满足给定的终止条件.




图2 IM-ESN 结构

增量式模块化储备池对应的权值矩阵为准对角分块矩阵, 即

$$\mathbf{W} = \begin{bmatrix} \Delta \mathbf{W}_1 & & & \\ & \ddots & & \\ & & \Delta \mathbf{W}_k & \\ & & & \ddots \end{bmatrix}. \quad (5)$$

对角线上 $\Delta \mathbf{W}_k (k \geq 1)$ 为第 k 个子储备池对应的权值矩阵, 增加子储备池相当于在准对角阵的对角线上增加一个子矩阵.

子储备池的规模可以相同, 也可以不同, 根据经验一般设为 2 ~ 5. 子储备池稀疏度为 1, 其权值矩阵由给定奇异值谱构造的对角矩阵, 以及随机生成的两个正交矩阵, 基于 SVD 构造而成, 即

$$\mathbf{W}^{\text{in}} = \begin{bmatrix} \Delta \mathbf{W}_1^{\text{in}} \\ \vdots \\ \Delta \mathbf{W}_k^{\text{in}} \\ \vdots \end{bmatrix}, \quad \mathbf{W}^b = \begin{bmatrix} \Delta \mathbf{W}_1^b \\ \vdots \\ \Delta \mathbf{W}_k^b \\ \vdots \end{bmatrix}. \quad (6)$$

IM-ESN 的输入权值矩阵 \mathbf{W}^{in} 及输出反馈矩阵 \mathbf{W}^b 同步增长, 其中 $\Delta \mathbf{W}_k^{\text{in}}$ 和 $\Delta \mathbf{W}_k^b$ 分别为第 k 个子储备池对应的输入权值矩阵和输出反馈权值矩阵, 随机生成并保持不变.

由式(2)~(6)便可得到 IM-ESN 的方程描述.

下面给出 IM-ESN 算法的详细步骤.

设训练序列 $\{(\mathbf{u}(n), \mathbf{d}(n)) | \mathbf{u}(n) \in R^K, \mathbf{d}(n) \in R^L, n = 1, 2, \dots, n_{\max}\}$ 取自某紧集, 储备池神经元激活函数为 \tanh , 输出神经元激活函数为线性函数.

Step 1: 参数初始化. 子储备池个数 $k = 0$, 内部状态收集起点 $n_{\min} + 1$, $\mathbf{D} = [\mathbf{d}(n_{\min} + 1), \dots, \mathbf{d}(n_{\max})]^T$ 为相应目标输出.

Step 2: 更新子储备池个数 $k = k + 1$, 构造第 k 个子储备池的权值矩阵 $\Delta \mathbf{W}_k$.

按照某概率分布生成随机对角矩阵

$$\mathbf{S}_k = \text{diag}(\lambda_1^k, \lambda_2^k, \dots, \lambda_{n_k}^k), \quad 0 < a \leq \lambda_i^k \leq b < 1,$$

以及随机正交矩阵

$$\Delta \mathbf{U}_k = (u_{ij})_{n_k \times n_k}, \quad \Delta \mathbf{V}_k = (v_{ij})_{n_k \times n_k}.$$

其中: $-1 \leq u_{ij}, v_{ij} \leq 1$. 令 $\Delta \mathbf{W}_k = \Delta \mathbf{U}_k \mathbf{S}_k \Delta \mathbf{V}_k$.

Step 3: 按照某概率分布随机生成子储备池输入权值矩阵 $\Delta \mathbf{W}_k^{\text{in}} = (w_{ij})_{n_k \times K}$, 以及输出反馈矩阵 $\Delta \mathbf{W}_k^b = (w_{ij})_{n_k \times L}$.

Step 4: 计算子储备池的内部状态

$$\begin{aligned} \Delta \mathbf{x}_k(n+1) = & \\ f(\Delta \mathbf{W} \Delta \mathbf{x}_k(n) + \Delta \mathbf{W}_k^{\text{in}} \mathbf{u}(n+1) + \Delta \mathbf{W}_k^b \mathbf{y}(n)). & \quad (7) \end{aligned}$$

Step 5: 收集新添子储备池内部状态

$$\Delta \mathbf{H}_k = [\Delta \mathbf{x}_k(n_{\min} + 1), \dots, \Delta \mathbf{x}_k(n_{\max})]^T. \quad (8)$$

Step 6: 计算网络的输出权值

$$\mathbf{W}_k^o = ((\mathbf{H}_k^T \mathbf{H}_k)^{-1} \mathbf{H}_k^T \mathbf{D})^T, \quad (9)$$

其中 $\mathbf{H}_k = [\mathbf{H}_{k-1}, \Delta \mathbf{H}_k]$ 为网络储备池的内部状态矩阵. 在处理实际问题时, 网络的输出权值一般采用含有岭回归的计算公式, 即

$$\mathbf{W}_k^o = ((\mathbf{H}_k^T \mathbf{H}_k + \beta \mathbf{I})^{-1} \mathbf{H}_k^T \mathbf{D})^T, \quad (10)$$

其中 $0 < \beta < 1$ 称为岭参数.

Step 7: 更新网络权值矩阵, 有

$$\mathbf{W}_k = \text{diag}(\mathbf{W}_{k-1}, \Delta \mathbf{W}_k), \quad (11)$$

$$\mathbf{W}_k^{\text{in}} = [(\mathbf{W}_{k-1}^{\text{in}})^T, (\Delta \mathbf{W}_k^{\text{in}})^T]^T, \quad (12)$$

$$\mathbf{W}_k^b = [(\mathbf{W}_{k-1}^b)^T, (\Delta \mathbf{W}_k^b)^T]^T. \quad (13)$$

Step 8: 计算训练误差 $E_k = \|H_k(W_k^o)^T - D\|$, 检验误差 $E_k^v = \|H_k^v(W_k^o)^T - D^v\|$, 其中 H_k^v 、 D^v 分别为检验样本对应的储备池内部状态矩阵及目标输出。

Step 9: 计算终止条件 $SC_k^l = E_k^v - E_{k-1}^v$, 如果 $SC_k^l \leq 0$, 则转 Step 2, 否则转 Step 10.

Step 10: 选择检验误差最小的网络进行测试。

2.3 稳定性分析

引理 1^[2] 对于传统的 ESN ($W^b = 0$), 储备池激活函数为 \tanh , 如果储备池权值矩阵 W 的最大奇异值 $\sigma_{\max} < 1$, 则该网络具有状态回声特性。

定理 1 (稳定性定理) 对于 IM-ESN ($W^b = 0$), 储备池激活函数为 \tanh , 如果子储备池权值矩阵 $\Delta W_k (k \geq 1)$ 的奇异值 $\lambda_i^k (1 \leq i \leq n_j)$ 满足 $0 < a \leq \lambda_i^k \leq b < 1$, 则 IM-ESN 具有状态回声特性。

证明 由 IM-ESN 的 Step 2 及 Step 7 可得

$$\begin{aligned} W_k &= \text{diag}(\Delta W_1, \dots, \Delta W_k) = \\ &= \text{diag}(\Delta U_1 S_1 \Delta V_1, \dots, \Delta U_k S_k \Delta V_k) = \\ &= U_k \text{diag}(\lambda_1^1, \dots, \lambda_{n_1}^1, \dots, \lambda_1^k, \dots, \lambda_{n_k}^k) V_k. \end{aligned} \quad (14)$$

其中: $U_k = \text{diag}(\Delta U_1, \dots, \Delta U_k)$ 和 $V_k = \text{diag}(\Delta V_1, \dots, \Delta V_k)$ 为正交矩阵。所以 $\lambda_i^j (1 \leq j \leq k, 1 \leq i \leq n_j)$ 为 W_k 的全部奇异值。又因为 $0 < a \leq \lambda_i^k \leq b < 1$, 所以 W_k 的最大奇异值 $\sigma_{\max} < 1$ 。由引理 1 可知, IM-ESN 具有状态回声特性。□

3 仿真研究

本节针对 MSO2~MSO8 进行仿真研究, 分析 IM-ESN 的预测性能。按照式 (1) 产生 1000 ($1 \leq t \leq 1000$) 个样本点, 分成 3 部分: 400 ($1 \leq t \leq 400$)、300 ($401 \leq t \leq 700$)、300 ($701 \leq t \leq 1000$), 分别用于训练、检验与测试, 内部状态收集起始点为 100。将均方误差 (MSE) 及标准均方根误差 (NRMSE) 选作预测性能评价指标, 计算公式如下:

$$MSE = \frac{1}{T} \sum_{i=1}^T (d(i) - y(i))^2, \quad (15)$$

$$NRMSE = \sqrt{\frac{\sum_{i=1}^T (d(i) - y(i))^2}{T\sigma_d^2}}. \quad (16)$$

其中: T 为测试样本数, $d(i)$ 为目标输出, $y(i)$ 为网络输出, σ_d^2 为目标输出的方差。对于每个子储备池, 规模相同取为 2, 奇异值服从 $[0.75, 0.99]$ 上的均匀分布, 输入权值矩阵 ΔW_k^{in} 的元素服从 $[-0.1, 0.1]$ 上的均匀分布, 输出反馈权值矩阵 ΔW_k^{b} 的元素服从 $[-1e-6, 1e-6]$ 上的均匀分布。所有实验程序运行环境为: 联想台式计算机 (CPU 3.4 Hz, 内存 4 G), 操作系统 Windows 7,

Matlab 软件版本 2010a。

3.1 网络性能分析

为了测试网络的随机初始化对网络性能的影响, 定义神经网络鲁棒性度量公式 (设计成功率)^[8] 为

$$R(\theta) = \frac{\sum_{i=1}^J u(e_i - \theta)}{J}; \quad (17)$$

$$u(x) = \begin{cases} 1, & x \leq 0; \\ 0, & x > 0. \end{cases} \quad (18)$$

其中: J 为蒙特卡洛实验次数; e_i 为第 i 次测试误差; θ 为阈值; $R(\theta)$ 反映神经网络测试误差不大于 θ 的成功率, 成功率越高, 说明网络对随机初始化参数的鲁棒性越好。

对 MSO2~MSO8 分别做 100 次蒙特卡洛实验, 图 3 给出了成功率相对于阈值的变化曲线。由图 3 可以看出, 随机初始化虽然对网络的预测性能有一定影响, 但对于阈值 $1e-2$, 实验成功率均为 100%。特别对于 MSO2 预测, 最小 NRMSE 达到了 $5e-4$, 对于 MSO3~MSO7 预测, 最小 NRMSE 达到了 $5e-3$ 。但随机初始化对 BESN 的预测性能影响较大, 不能实现 100% 的成功预测; 对 MSO2 测试, NRMSE 甚至高达 $1e+24$ ^[16]。




图 3 IM-ESN 预测成功率

图 4 给出了网络储备池神经元数 (N) 及平均测试误差 (NRMSE)。由图 4 可以看出, 随着问题复杂度




图 4 IM-ESN 训练误差曲线

的增加, 预测更加困难, 网络规模及测试误差相应增大, 说明 IM-ESN 能够自动确定与问题复杂度相匹配的网络规模.

为了验证算法的收敛性, 将训练误差设为 $1e-8$, 图 5 给出了 IM-ESN 的学习误差 (NRMSE) 曲线. 由图 5 可以看出, 随着子储备池的添加, IM-ESN 的学习误差快速下降, 在有限的时间内即可下降到一个较小范围, 直至趋近于零.




图 5 IM-ESN 训练误差曲线

图 6(a) 展示了 IM-ESN 对 MSO8 的预测输出 $y(t)$ 与目标输出 $d(t)$, 图 6(b) 展示了相应的预测误差 $y(t) - d(t)$. 图 6 展示的结果说明, IM-ESN 能够有效解决多个正弦波叠加的 MSO 问题.




图 6 MSO8 预测效果

3.2 预测性能比较

表 1 给出了 IM-ESN 与 DESN + MaxInfo^[8]、SWESN^[11]、CESN^[13]以及 PSO + ESN^[14]对 MSO2 的平均预测误差 (MSE)、设计成功率 ($R(0.0034)$) 和网络储备池神经元数 (N). 与 PSO + ESN 及 DESN +

MaxInfo 相比, IM-ESN 的预测精度提高了 106 倍. 与 CESN 相比, IM-ESN 以较小的网络规模获得了较高的预测精度. 对于阈值 $\theta = 0.0034$, IM-ESN 和 PSO + ESN 均获得了 100% 的设计成功率. 实际上由图 3 可以看出, 对于更小阈值 $\theta = 0.00005$, IM-ESN 已经取得了 100% 的设计成功率.

表 1 不同 ESNs 对 MSO2 的预测性能比较

Methods	MSE	$R(0.0034)$	N
IM-ESN	$2.4e-011$	1	46
CESN ^[13]	$1.4e-010$	—	300
PSO+ESN ^[14]	$5.0e-004$	1	10
SWESN ^[11]	—	0.978	—
DESN+MaxInfo ^[8]	$3.0e-004$	0.635	400

表 2 给出了 IM-ESN 和 BESN 对 MSO2 ~ MSO8 的最小预测误差 (NRMSE). 尽管 IM-ESN 对 MSO2 ~ MSO4 的预测误差高于 BESN, 但对于更复杂的 MSO5 ~ MSO8, IM-ESN 取得了更好的预测效果.

表 2 IM-ESN 和 BESN 对 MSO x 的最小预测误差比较

Problems	IM-ESN (NRMSE)	BESN (NRMSE)
MSO2	$3.05e-008$	$2.51e-012$
MSO3	$1.44e-007$	$4.57e-010$
MSO4	$5.75e-007$	$5.72e-008$
MSO5	$8.48e-007$	$1.06e-006$
MSO6	$1.43e-006$	$8.43e-005$
MSO7	$1.70e-006$	$1.01e-004$
MSO8	$1.91e-006$	$2.73e-004$

4 结 论

针对传统回声状态网络 (ESN) 储备池神经元耦合连接难以解决 MSO 时间序列预测问题, 本文提出了一种新的增量式模块化回声状态网络 (IM-ESN). 与传统的 ESN 相比, IM-ESN 具有以下几个特点:

- 1) IM-ESN 储备池由多个相互独立的子储备池组成, 实现了储备池内神经元的部分解耦, 并以较高的预测精度及较强的鲁棒性解决了 MSO 问题.
- 2) IM-ESN 每个子储备池的权值矩阵由给定的奇异值构成, 在网络增长过程中可以确保网络的状态回声特性, 无须对权值矩阵进行放缩.
- 3) IM-ESN 能够自动确定与给定问题相匹配的网络结构复杂度, 无须事先设定.

参考文献(References)

[1] Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.

- [2] Herbert J. The echo state approach to analysing and training recurrent neural networks[R]. Sankt Augustin: German National Research Center for Information Technology, 2001, 12(8): 1-43.
- [3] Li D, Han M, Wang J. Chaotic time series prediction based on a novel robust echo state network[J]. *IEEE Trans on Neural Networks and Learning Systems*, 2012, 23(5): 787-799.
- [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(7): 1146-1151.
(Qiao J F, Bo Y C, Han G. Application of ESN-based multi indices dual heuristic dynamic programming on wastewater treatment process[J]. *Acta Automatica Sinica*, 2013, 39(7): 1146-1151.)
- [5] Pan Y, Wang J. Model predictive control of unknown nonlinear dynamical systems based on recurrent neural networks[J]. *IEEE Trans on Industrial Electronics*, 2012, 59(8): 3089-3101.
- [6] Skowronski M D, Harris J G. Automatic speech recognition using a predictive echo state network classifier[J]. *Neural Networks*, 2007, 20(3): 414-423.
- [7] Chen Y, Hu J, Kasabov N, et al. NeuCubeRehab: A pilot study for EEG classification in rehabilitation practice based on spiking neural networks[J]. *Springer Lecture Notes in Computer Science*, 2013, 8228(1): 70-77.
- [8] Xue Y, Yang L, Haykin S. Decoupled echo state networks with lateral inhibition[J]. *Neural Networks*, 2007, 20(3): 365-376.
- [9] Schmidhuber J, Wierstra D, Gagliolo M, et al. Training recurrent networks by evolino[J]. *Neural Computation*, 2007, 19(3): 757-779.
- [10] 支蓉, 龚志强, 王启光, 等. 全球增暖和极端事件对全球温度场关联性的影响[J]. *气象学报*, 2012, 70(4): 728-735.
(Zhi R, Gong Z Q, Wang Q G, et al. The influence of global warming and extreme events on the correlation of the global temperature field[J]. *Acta Meteorologica Sinica*, 2012, 70(4): 728-735.)
- [11] 薄迎春, 乔俊飞, 张昭昭. 一种具有small world特性的ESN结构分析与设计[J]. *控制与决策*, 2012, 27(3): 383-388.
(Bo Y C, Qiao J F, Zhang Z Z. Analysis and design on structure of small world property ESN[J]. *Control and Decision*, 2012, 27(3): 383-388.)
- [12] Fiers M A A, Van Vaerenbergh T, Wyffels F, et al. Nanophotonic reservoir computing with photonic crystal cavities to generate periodic patterns[J]. *IEEE Trans on Neural Networks and Learning Systems*, 2014, 25(2): 344-355.
- [13] Song Q, Feng Z. Effects of connectivity structure of complex echo state network on its prediction performance for nonlinear time series[J]. *Neurocomputing*, 2010, 73(10): 2177-2185.
- [14] 宋青松, 冯祖仁, 李人厚. 回响状态网络输出连接权重的一个稳定训练方法[J]. *控制与决策*, 2011, 26(1): 22-26.
(Song Q S, Feng Z R, Li R H. Stable training method for output connection weights of echo state networks[J]. *Control and Decision*, 2011, 26(1): 22-26.)
- [15] Schmidhuber J, Wierstra D, Gagliolo M, et al. Training recurrent networks by evolino[J]. *Neural Computation*, 2007, 19(3): 757-779.
- [16] Holzmann G, Hauser H. Echo state networks with filter neurons and a delay & sum readout[J]. *Neural Networks*, 2010, 23(2): 244-256.
- [17] Koryakin D, Lohmann J, Butz M V. Balanced echo state networks[J]. *Neural Networks*, 2012, 36(1): 35-45.
- [18] Jaeger H, Lukoševičius M, Popovici D, et al. Optimization and applications of echo state networks with leaky-integrator neurons[J]. *Neural Networks*, 2007, 20(3): 335-352.

(责任编辑: 李君玲)