

文章编号: 1001-0920(2011)01-0022-05

回响状态网络输出连接权重中的一个稳定训练方法

宋青松^{1,2}, 冯祖仁¹, 李人厚¹

(1. 西安交通大学 系统工程研究所, 西安 710049; 2. 长安大学 信息工程学院, 西安 710064)

摘要: 鉴于在回响状态网络 (ESN) 的应用中常使用 Wiener-Hopf 方程学习输出连接权重, 但该方法难以保证自治 ESN 的稳定性, 首先分析了导致该稳定性丧失的原因, 提出并证明了自治 ESN 具备 Lyapunov 稳定性的一个充分条件; 然后将输出连接权重学习问题转化为一个非线性约束的最优化问题, 并采用粒子群优化算法求解. 仿真结果表明, 所提方法既能确保 ESN 获取高精度的预测输出, 又能保证 ESN 的 Lyapunov 稳定性.

关键词: 神经网络; 回响状态网络; Lyapunov 稳定性; 粒子群最优化

中图分类号: TP301

文献标识码: A

Stable training method for output connection weights of echo state networks

SONG Qing-song^{1,2}, FENG Zu-ren¹, LI Ren-hou¹

(1. Institute of Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. School of Information Engineering, Chang'an University, Xi'an 710064, China. Correspondent: SONG Qing-song, E-mail: qssong@sei.xjtu.edu.cn)

Abstract: In applications of echo state network (ESN), the Wiener-Hopf equation is usually used to learn the ESN's output connect weights, but can hardly ensure the stability of the autonomous ESNs. Therefore, The reasons for the loss of the stability are analyzed firstly, and a sufficient condition of the Lyapunov stability for the autonomous ESNs is proposed and proved. Then the output connect weight learning problem is translated into an optimization problem with a nonlinear constraint. Particle swarm optimization algorithm is employed to solve the optimization problem. Finally, the simulation results show that the method proposed can not only result in high-precision prediction outputs of the ESN, but also ensure its Lyapunov stability.

Key words: neural network; echo state network; Lyapunov stability; particle swarm optimization

1 引言

回响状态网络 (ESN)^[1] 是一类新型的回归神经网络 (RNN), 在混沌和非线性动态系统建模、辨识和控制等方面取得了成功应用. 如, 对 Mackey-Glass(MG) 混沌时间序列的前向第 84 步预测, ESN 获取的归一化均方根误差 (NRMSE) 约为 $10^{-4.2}$, 而常见预测方法对该任务获取的 NRMSE 仅为 $10^{-1.2} \sim 10^{-2.0}$.

ESN 体系结构通常由一个大规模稀疏连接的 RNN (称为“库”) 和一个线性读取器构成. 与常见的 RNN 方法相比, ESN 方法最重要的特征是在所有连接权重中, 仅从库到读取器的连接权重需要训练, 其他所有连接权重在初始化过程中随机设置, 之后保持

固定. 此外, 由于库对外界输入具有丰富的表达能力, 简单的线性回归方法即可完成其权重学习任务, 从而有效回避了常规 RNN 方法中遭遇的局部极小、收敛慢甚至不收敛等权重训练难题^[2].

然而, 当 ESN 方法用于轨迹生成或模式发生等任务时, 输出反馈会形成闭合环路, ESN 在自治模式下运行, 其 Lyapunov 稳定性丧失, 直接表现为实际输出远远偏离期望输出. 神经网络的稳定性是成功应用神经网络的前提. 近年来, 有关 Hopfield 型神经网络、细胞神经网络、双向联想记忆 (BAM) 网络等网络模型的稳定性研究已取得丰硕成果, 其中构造适当的 Lyapunov 泛函是研究诸网络稳定性最常见的方

收稿日期: 2009-10-21; 修回日期: 2009-12-28.

基金项目: 国家自然科学基金项目(60875043); 国家重点基础研究发展计划项目(2007CB311006).

作者简介: 宋青松(1980—), 男, 博士生, 从事大规模神经网络的研究; 冯祖仁(1953—), 男, 教授, 博士生导师, 从事控制理论与控制工程等研究.

法^[3]. 但有关ESN闭环运行稳定性的研究报道较少. 文献[4]使用岭回归方法和噪声去干扰策略训练输出连接权重, 但其结果表明该方法不能保证每一次训练都能得到稳定的ESN.

本文综合考虑预测输出精度要求和Lyapunov稳定性约束条件, 将ESN输出权重学习问题转化为一个具有非线性约束的最优化问题, 并利用粒子群最优化(PSO)算法求解. 仿真实验结果表明, 本文所提方法能够高效获取既满足输出精度要求又满足稳定性约束的ESN输出权重.

2 问题提出

ESN的体系结构由3部分组成: 前端输入、中间大量神经元组成的库、后端读取器输出, 如图1所示. 设定ESN具有 L 个输入, M 个输出, 库由 N 个漏积分神经元构成. 其中输入连接权重矩阵、库连接权重矩阵、输出连接权重矩阵以及输出反馈连接权重矩阵分别记为 \mathbf{W}^{in} , \mathbf{W} , \mathbf{W}^{out} 和 \mathbf{W}^{back} , 规模分别为 $N \times L$, $N \times N$, $M \times N$ 和 $N \times M$. 图1中虚箭头所示部分(即 \mathbf{W}^{out})是ESN学习过程中唯一需要调整的部分.

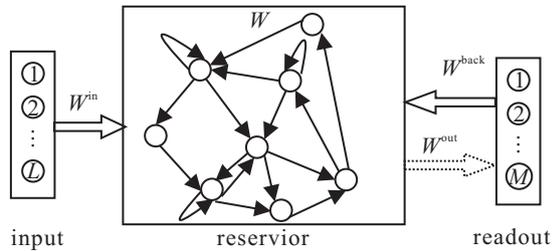


图1 ESN体系结构

ESN的实施过程包含3个阶段: 状态收集、训练 \mathbf{W}^{out} 和测试训练得到的ESN. 假定所有待处理对象(即训练用和测试用的时间序列)有界.

2.1 状态收集

首先设定 \mathbf{W}^{in} 和 \mathbf{W}^{back} 的取值, 其元素取值通常为区间 $[-1, 1]$ 内的均匀分布随机数. 给定长度为 T_t 的训练用时间序列 $\mathbf{Y}_d(k)$, $k = 1, 2, \dots, T_t$. \mathbf{W} 是规模为 $N \times N$ 的稀疏矩阵, 设置其谱半径 $\rho(\mathbf{W})$ 小于1, 连通密度 D 取值0.02~0.5. ESN的库状态 $\mathbf{X}(k)$ 根据下式更新, 状态收集阶段不考虑ESN输出:

$$\mathbf{X}(k+1) = (1 - a\gamma)\mathbf{X}(k) + \gamma f^{PE}(\mathbf{W}^{\text{in}}u(k) + \mathbf{W}\mathbf{X}(k) + \mathbf{W}^{\text{back}}\mathbf{Y}_d(k) + \mathbf{v}(k)). \quad (1)$$

其中: a 和 γ 是漏积分神经元参数, $a > 0$, $\gamma > 0$, $a\gamma \leq 1$; f^{PE} 是双曲正切函数; $\mathbf{v}(k)$ 是均匀噪声项; $u(k)$ 是定常偏置输入; $\mathbf{X}(0) = \mathbf{0}$; \mathbf{Y}_d 经过 \mathbf{W}^{back} 送入ESN库^[4-5]. 从 $k = T_0 + 1$ 到 $k = T_t$, 库状态 $\mathbf{X}(k)$ 和 $\mathbf{Y}_d(k)$ 依次被收集到矩阵 \mathbf{M} 和矩阵 \mathbf{T} . 为了消除库状态零初始态的影响, T_0 时刻之前的库状态不被收集.

2.2 训练输出连接权重

设定ESN为线性输出, 输出方程为

$$\mathbf{Y}(k+1) = \mathbf{W}^{\text{out}}\mathbf{X}(k+1). \quad (2)$$

已知矩阵 \mathbf{M} 和矩阵 \mathbf{T} , 在最小均方误差意义下, 使用Wiener-Hopf方程学习 \mathbf{W}^{out} , 这是ESN应用中最常见的输出连接权重学习算法^[5], 有

$$\mathbf{W}^{\text{out}} = ((\mathbf{M}^T\mathbf{M})^{-1}(\mathbf{M}^T\mathbf{T}))^T. \quad (3)$$

其中: \mathbf{M}^T 是 \mathbf{M} 的转置, \mathbf{M}^{-1} 是 \mathbf{M} 的逆.

2.3 测试训练所得的ESN

将 \mathbf{W}^{out} 植入ESN, 得到学习后的ESN. 给定长度为 T_e 的测试用时间序列 $\mathbf{Y}(k)$, $k = 1, 2, \dots, T_e$, $T_e \gg T_0$. $\mathbf{Y}(k)$ 和 $\mathbf{Y}_d(k)$ 来自同一个动力系统, 但具有不同的初始值($\mathbf{Y}(0) \neq \mathbf{Y}_d(0)$). 当 $k \leq T_0$ 时, 将 $\mathbf{Y}(k)$ 作为 $\mathbf{Y}_d(k)$ 经由 \mathbf{W}^{back} 送入ESN库, 以活跃库内神经元的活性, 此时库状态 $\mathbf{X}(k)$ 根据式(1)更新. 从 $k = T_0 + 1$ 到 $k = T_e$, $\mathbf{X}(k)$ 和预测输出 $\hat{\mathbf{Y}}(k)$ 分别为

$$\mathbf{X}(k+1) = (1 - a\gamma)\mathbf{X}(k) + \gamma f^{PE}(\mathbf{W}^{\text{in}}u(k) + \mathbf{W}\mathbf{X}(k) + \mathbf{W}^{\text{back}}\hat{\mathbf{Y}}(k)), \quad (4)$$

$$\hat{\mathbf{Y}}(k+1) = \mathbf{W}^{\text{out}}\mathbf{X}(k+1). \quad (5)$$

比较式(1)和(4), 可见从 $k = T_0 + 1$ 到 $k = T_e$, ESN的预测输出 $\hat{\mathbf{Y}}(k)$ 形成反馈回路, 如图2所示(假定 $u(k) = 0$).

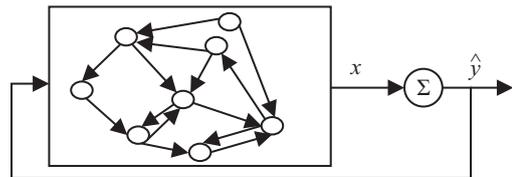


图2 自治ESN体系结构

ESN作为一个自治系统, 执行一步迭代预测任务. 显然, 保证式(1)渐近稳定的充分条件 $\rho((1 - a\gamma)\mathbf{I} + \mathbf{W}) < 1$ ^[4]不能保证式(4)也是渐近稳定的. 式(4)表达的自治ESN差分动力系统的稳定性由式(6)描述的矩阵 $\tilde{\mathbf{W}}$ 的谱半径决定, 称 $\rho(\tilde{\mathbf{W}})$ 为该ESN的有效谱半径(ESR), 有

$$\tilde{\mathbf{W}} = \mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}}. \quad (6)$$

定理1 对于式(4)表达的自治ESN差分动力系统, $\text{ESR} \leq a$ 是保证该系统Lyapunov稳定性的一个充分条件.

证明 根据式(4), 有

$$\|\mathbf{X}(k+1)\| = \|(1 - a\gamma)\mathbf{X}(k) + \gamma f^{PE}((\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\mathbf{X}(k))\|.$$

又因为 f^{PE} 为双曲正切函数, 有

$$\|f^{PE}(\mathbf{X}(k))\| \leq \|\mathbf{X}(k)\|,$$

进而

$$\begin{aligned} & \|\mathbf{X}(k+1)\| = \\ & \|(1-a\gamma)\mathbf{X}(k) + \gamma f^{PE}((\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\mathbf{X}(k))\| \leq \\ & \|(1-a\gamma)\mathbf{X}(k)\| + \gamma \|f^{PE}((\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\mathbf{X}(k))\| \leq \\ & \|(1-a\gamma)\mathbf{X}(k)\| + \gamma \|(\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\mathbf{X}(k)\| \leq \\ & (|1-a\gamma| + \gamma \|(\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\|)\|\mathbf{X}(k)\|. \end{aligned} \quad (7)$$

又因为 $a\gamma \leq 1$, 所以只需 $\|(\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\| \leq a$ 即可有 $|1-a\gamma| + \gamma \|(\mathbf{W} + \mathbf{W}^{\text{back}}\mathbf{W}^{\text{out}})\| \leq 1$. \square

直观上, 图 2 所示自治系统的环路增益小于 1 能够保证系统的 Lyapunov 稳定性.

3 PSO 算法求解输出连接权重

根据第 2 节的描述可知, \mathbf{W}^{out} 不仅决定预测输出的精度, 而且影响训练后 ESN 的 Lyapunov 稳定性. 式 (3) 描述的 ESN 学习方法, 仅考虑了输出精度要求, 却忽略了稳定性约束. 本文综合考虑, 将输出连接权重学习问题转化为一个约束优化问题, 即

$$\begin{aligned} & \min \sum_{k=T_0+1}^{T_t} (y_d(k) - \mathbf{W}^{\text{out}}\mathbf{X}(k))^2, \\ & \text{s.t. } \rho(\tilde{\mathbf{W}}) \leq a - \varepsilon_\rho. \end{aligned} \quad (8)$$

其中 ε_ρ 为稳定裕量常数, $\varepsilon_\rho > 0$. 事实上很难找到求解式 (8) 的一个基于梯度的确定性算法, 因而寻求随机优化算法. 粒子群优化算法 (PSO) 源于对鸟类捕食行为的模拟, 适用于连续优化问题, 且已在多个优化问题中得到成功应用^[6], 本文利用它来求解式 (8).

首先将式 (8) 中的目标函数和稳定性约束综合为一个评价函数, 即

$$\Phi(\mathbf{W}^{\text{out}}) = f(\mathbf{W}^{\text{out}}) + r_1\theta h(\mathbf{W}^{\text{out}})^{r_2}, \quad (9)$$

$$f(\mathbf{W}^{\text{out}}) = \frac{1}{T_t - T_0} \sum_{k=T_0+1}^{T_t} (y_d(k) - \mathbf{W}^{\text{out}}\mathbf{X}(k))^2, \quad (10)$$

$$h(\mathbf{W}^{\text{out}}) = \max[0, (\rho(\tilde{\mathbf{W}}) - a + \varepsilon_\rho)]. \quad (11)$$

其中: $f(\mathbf{W}^{\text{out}})$ 为训练均方误差; $h(\mathbf{W}^{\text{out}})$ 为约束违反量; 参数 r_1, r_2 和 θ 为动态罚函数.

粒子群中每个粒子由位置 \mathbf{p} 和速度 \mathbf{V} 两个量刻画. 粒子位置 \mathbf{p} 直接编码问题的可能解, 即 \mathbf{p} 的每一个取值都代表 \mathbf{W}^{out} 的一个可能取值, \mathbf{p} 的取值 $\Phi(\mathbf{p})$ 是对该粒子的优劣评价. 在每个时间步, \mathbf{V} 和 \mathbf{p} 根据式 (12) 和 (13) 更新, 直至最大进化步数, 或者评价函数值 $\Phi(\mathbf{p})$ 达到某个阈值, 即

$$\begin{aligned} & \mathbf{V}(\text{step} + 1) = \\ & \chi(\mathbf{V}(\text{step}) + c_1 \text{rand}()(\mathbf{p}_{\text{best}}(\text{step}) - \mathbf{p}(\text{step})) + \\ & c_2 \text{rand}()(\mathbf{g}_{\text{best}}(\text{step}) - \mathbf{p}(\text{step}))), \end{aligned} \quad (12)$$

$$\mathbf{p}(\text{step} + 1) = \mathbf{p}(\text{step}) + \mathbf{V}(\text{step} + 1). \quad (13)$$

其中: χ 是收缩因子, c_1 和 c_2 是加速常数, $\text{rand}()$ 是一个随机数, step 是 PSO 算法进化代数, \mathbf{p}_{best} 和 \mathbf{g}_{best} 分别是该粒子所经过的最佳位置和该群体所经过的最佳位置. 为了保证该 PSO 算法收敛, 取 $\chi = 0.729, c_1 = c_2 = 2.05$ ^[7].

设定 ESN 参数, 包括 $L, M, N, \rho(\mathbf{W}), D, a$ 和 γ , 随机产生 $\mathbf{W}^{\text{in}}, \mathbf{W}$ 和 \mathbf{W}^{back} , 求得矩阵 \mathbf{M} 和矩阵 \mathbf{T} . 设定粒子群的规模、粒子群最大进化代数以及罚函数参数 r_1, r_2 和 θ . 所提 PSO 算法的流程如下:

Step 1: 在 N 维搜索空间中随机初始化粒子群中各粒子的位置 \mathbf{p} 和速度 \mathbf{V} . 记 $\text{step} = 1$.

Step 2: 根据式 (9) 初始评价该粒子群中的每个粒子. 将每个粒子的当前位置记为 $\mathbf{p}_{\text{best}}(1)$, 当前评价值 $\Phi(\mathbf{p})$ 记为该粒子经历过的最佳评价值. 求取该粒子群中对应最小评价值的 $\mathbf{p}_{\text{best}}(1)$, 记为 $\mathbf{g}_{\text{best}}(1)$.

Step 3: 采用收缩因子 PSO 算法, 根据式 (12) 和 (13) 更新当前粒子群中每个粒子的 \mathbf{V} 和 \mathbf{p} , 得到一个新的粒子群.

Step 4: 比较新粒子群中每个粒子的当前评价值 $\Phi(\mathbf{p}(\text{step}))$ 与 $\mathbf{p}_{\text{best}}(\text{step} - 1)$ 对应的评价值 $\Phi(\mathbf{p}_{\text{best}}(\text{step} - 1))$. 若 $\Phi(\mathbf{p}(\text{step})) < \Phi(\mathbf{p}_{\text{best}}(\text{step} - 1))$, 则更新该粒子经历过的最佳位置和评价值.

Step 5: 将当前所有粒子的 $\Phi(\mathbf{p}(\text{step}))$ 与 $\mathbf{g}_{\text{best}}(\text{step} - 1)$ 对应的评价值作比较. 更新 $\mathbf{g}_{\text{best}}(\text{step})$. 令 $\text{step} = \text{step} + 1$.

Step 6: 重复执行 Step 3~Step 5, 若达到最大进化代数, 则终止程序, 输出 $\mathbf{g}_{\text{best}}(\text{step})$ 作为 \mathbf{W}^{out} 取值, 完成 ESN 输出连接权重的学习.

4 实验结果

多振荡子叠加 (MSO) 问题是衡量 ESN 建模性能的基准问题之一^[10]. 在该问题中, 期望 ESN 产生一个长周期信号, 该信号由一组频率互不为整数倍的正弦波相互叠加而成, 即 $y_d(k) = \sum_{i=1}^n \sin(\alpha_i k)$, 其中 α_i ($i = 1, 2, \dots, n$) 互不为整数倍. 典型地, 取 $n = 2, \alpha_1 = 0.2, \alpha_2 = 0.311$. 本文通过该问题评价所提方法的性能, 将网络参数 $L, M, N, \rho(\mathbf{W}), D$ 和 γ 分别设定为 0, 1, 10, 0.8, 0.4 和 0.02, a 的取值依次从 0.1~2, 间隔 0.1, 再从 2.4~10, 间隔 0.4, 共 40 个. 实验结果表明, 自治 ESN ($\text{step} = 500$) 的性能 (以 E_{mse} 和 S_{ratio} 为例, 见式 (17)~(19)) 与 a 的取值无关, 且获取的有效谱半径 $\rho(\tilde{\mathbf{W}})$ 均趋近于并总小于相应的 a 值. 本文仅给出 $a = 1$ 情形下的实验结果.

随机生成 \mathbf{W} 和 \mathbf{W}^{back} . 对于 MSO 信号, 设定采样步长为 1, $T_0 = 100, T_t = 400, T_e = 1100$, 得到训练

和测试序列. 选择这样的参数设置, 是为了便于与文献[8]中的结果进行比较.

根据第2.1节所述方法, 求得矩阵 \mathbf{M} 和矩阵 \mathbf{T} . 采用上述PSO算法取代第2.2节描述的算法求得 \mathbf{W}^{out} . 设定粒子群的规模为30, 粒子群最大进化代数为500, 罚函数参数 r_1 , r_2 和 θ 分别如式(14)~(16)所示. 一方面, 随着进化代数增加, 逐渐加大对不可行解($\rho(\tilde{\mathbf{W}}) \geq 1$)的惩罚力度; 另一方面, 约束违反量越大, 惩罚力度也越大. 有

$$r_1 = (\text{step})^{3/2}. \quad (14)$$

$$r_2 = \begin{cases} 3, & h(\mathbf{W}^{\text{out}}) \geq 2; \\ 2, & 1 \leq h(\mathbf{W}^{\text{out}}) < 2; \\ 1, & h(\mathbf{W}^{\text{out}}) < 1. \end{cases} \quad (15)$$

$$\theta = \begin{cases} 20, & h(\mathbf{W}^{\text{out}}) \geq 2; \\ 5, & 1 \leq h(\mathbf{W}^{\text{out}}) < 2; \\ 1, & h(\mathbf{W}^{\text{out}}) < 1. \end{cases} \quad (16)$$

仿真实验在PC奔腾2.4 G, Matlab 7.0平台上进行, 运行一次平均耗时约为4 min. 取20次独立实验结果的平均值作为性能度量取值.

图3和图4分别为 $f(\mathbf{W}^{\text{out}})$ (训练MSE)和 $\rho(\tilde{\mathbf{W}})$ (ESR)的演化过程, 图中“I”字形垂直线与曲线的交点为对应均值, “I”字形垂直线长度为对应标准差. 两图表明, 粒子群进化到第200代时, $f(\mathbf{W}^{\text{out}})$ 值和 $\rho(\tilde{\mathbf{W}})$ 值已经全局收敛. 此外, 图4表明, ESR最终收敛到0.99998, 接近于1但总小于1, 从而保证了自治ESNs的Lyapunov稳定性.

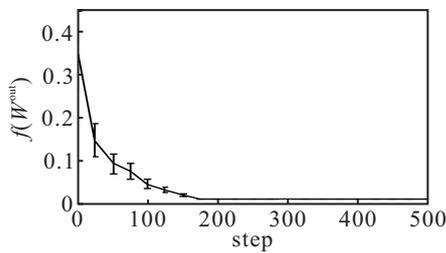


图3 训练误差演化过程

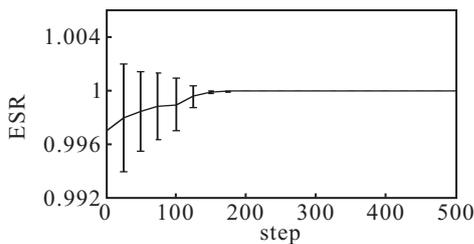


图4 ESR演化过程

测试过程中, 采用 E_{mse} 和 S_{ratio} 作为性能度量指标: E_{mse} 为泛化均方差; S_{ratio} 为在网络参数固定前提下, 网络对随机生成的 \mathbf{W} 和 \mathbf{W}^{back} 的鲁棒性, 有

$$E_{\text{mse}}^i = \left(\sum_{k=101}^{1100} (\hat{y}(k) - y_d(k))^2 \right) / 1000, \quad (17)$$

$$E_{\text{mse}} = \left(\sum_{i=1}^{20} E_{\text{mse}}^i \right) / 20, \quad (18)$$

$$S_{\text{ratio}} = \left(\sum_{i=1}^{20} \delta^T (E_{\text{mse}}^i - \theta) \right) / 20. \quad (19)$$

其中: $\hat{y}(k)$ 和 $y_d(k)$ 分别是PSO算法训练得到的ESN在测试中第 k 时刻的实际输出和期望输出, E_{mse}^i 是20次独立实验中第 i 次得到的实际输出误差, θ 是一个误差阈值. 若 $E_{\text{mse}}^i < \theta$, 则 $\delta^T = 1$; 反之, 若 $E_{\text{mse}}^i \geq \theta$, 则 $\delta^T = 0$. 为了便于比较, 本文取 $\theta = 0.0034^{[8]}$.

图5给出采用本文方法训练得到的一个自治ESN的泛化输出. 图5中, 虚线对应PSO进化到第100代得到的 \mathbf{W}^{out} 所对应的ESN实际输出, 点划线对应PSO进化到第500代得到的 \mathbf{W}^{out} 所对应的ESN实际输出, 实线表示期望输出. 可见, 采用本文方法, 仅进化到第100代即可得到一个稳定的ESN (ESR约为0.999), 但实际输出精度不足 (E_{mse} 约为0.02). 同样条件下继续进化到第500代, 即可得到一个准确的长时段实际输出, 实际输出与期望输出良好地吻合 (E_{mse} 约为0.0005).

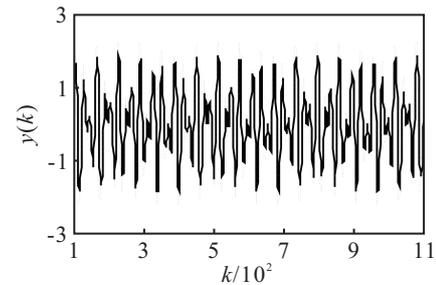


图5 PSO算法训练获取的稳定ESN输出

使用同样的训练和测试序列, 比较不同ESNs的性能, 结果如表1所示. 综合库规模 N , E_{mse} 和 S_{ratio} 可见, 本文所提基于PSO的训练方法优势明显: 能够在 \mathbf{W}^{out} 空间中高效地搜索并获取所期望的 \mathbf{W}^{out} . 该 \mathbf{W}^{out} 对应的自治ESNs能够以较小的代价(N 值小), 获取良好的泛化性能(E_{mse} 值小), 并对随机产生的 \mathbf{W} 和 \mathbf{W}^{back} 具有良好的鲁棒性(S_{ratio} 值大).

表1 不同ESNs获取的性能度量值

Method	N	E_{mse}	S_{ratio}
ESN ^[11]	400	/	0
DESN+RP ^[8]	400	0.0021	0.228
DESN+MaxInfo ^[8]	400	0.0003	0.635
Evolino+LSTM ^[9]	10	0.0034	-
Our algorithm	10	0.0005	1

5 结论

本文分析了ESN在自治运行情形下Lyapunov稳

定性丧失的原因,给出了保证自治 ESN 具备 Lyapunov 稳定性的一个充分条件;然后将输出连接权重学习问题转化为一类有约束的最优化问题,并给出求解该问题的 PSO 算法. 仿真结果表明,所提出的基于 PSO 算法的输出连接权重学习方法能够有效兼顾 ESN 的预测精度要求和 Lyapunov 稳定性条件约束,从而为训练 ESN 输出连接权重提供了一个更有效的解决方案.

参考文献(References)

- [1] Jaeger H, Haass H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. *Science*, 2004, 304(5667): 78-80.
- [2] Jang J S R, Sun C T, Mizutani E. *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*[M]. New Jersey: Prentice Hall, 1997.
- [3] Michel A N, Liu D. *Qualitative analysis and synthesis of recurrent neural networks*[M]. New York: Marcel Dekker, 2002.
- [4] Jaeger H, Lukosevicius M, Popovici D, et al. Optimization and applications of echo state networks with leaky-integrator neurons[J]. *Neural Networks*, 2007, 20(3): 335-352.
- [5] Jaeger H. Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach[R]. Sankt Augustin: GMD Forschungszentrum Informationstechnik, 2002.
- [6] Kennedy J, Eberhart R. Particle swarm optimization[C]. *Proc of IEEE Int Conf on Neural Networks*. Perth: IEEE, 1995: 1942-1948.
- [7] Clerc M, Kennedy J. The particle swarm: Explosion, stability and Convergence in a multidimensional complex space[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(1): 58-73.
- [8] Xue Y, Yang L, Haykin S. Decoupled echo state networks with lateral inhibition[J]. *Neural Networks*, 2007, 20(3): 365-376.
- [9] Wiestra D, Gomez F, Schmidhuber J. Modeling systems with internal state using evolino[C]. *Proc of GECCO*. New York: ACM, 2005: 1795-1802.

(上接第21页)

- [13] 夏蔚军, 吴智铭, 王丽亚. 采购量折扣情况下基于改进AHP 的供应商选择[J]. *上海交通大学学报*, 2007, 41(4): 541-545.
(Xia W J, Wu Z M, Wang L Y. Supplier selection with improved AHP in volume discount environments[J]. *J of Shanghai Jiaotong University*, 2007, 41(4): 541-545.)
- [14] 姜康, 曹文钢, 于振华. 基于遗传算法和模糊决策的大规模联盟伙伴选择方法研究[J]. *系统工程理论与实践*, 2007, 27(1): 169-174.
(Jiang K, Cao W G, Yu Z H. Study of partner selection algorithm based on GAS and fussy decision making[J]. *Systems Engineering — Theory and Practice*, 2007, 27(1): 169-174.)
- [15] 孟繁晶, 邓家禔. 合作伙伴的可拓综合评价方法[J]. *计算机集成制造系统*, 2005, 11(6): 869-874.
(Meng F J, Deng J T. Extensive comprehensive evaluation approach for partner selection[J]. *Computer Integrated Manufacturing Systems*, 2005, 11(6): 869-874.)
- [16] 陈菊红, 汪应洛, 孙林岩. 虚拟企业伙伴选择过程及方法研究[J]. *系统工程理论与实践*, 2001, 21(7): 48-53.
(Cheng J H, Wang Y L, Sun L Y. Study on the processes and methods of partner selection in virtual organization[J]. *Systems Engineering — Theory and Practice*, 2001, 21(7): 48-53.)
- [17] 闫书丽, 杨万才. 混合型多属性决策的一种新方法[J]. *数学的实践与认识*, 2007, 37(16): 111-115.
(Yan S L, Yang W C. A new method for hybrid multiple attribute decision making[J]. *Mathematics in Practice and Theory*, 2007, 37(16): 111-115.)
- [18] Qlcer A I, Odabasi A Y. A new fuzzy multiple attributive group decision making methodology and its application to propulsion/manicuring system selection problem [J]. *Fuzzy Sets and System*, 2005, 166(1): 93-114.
- [19] Chen S J, Hwang C L. *Fuzzy multiple attribute decision-making: Methods and applications*[M]. New York: Springer Verlag, 1992.
- [20] 王威, 崔明明. 混合型多属性决策问题的熵方法[J]. *数学的实践与认识*, 2007, 37(3): 64-68.
(Wang W, Cui M M. A technique of entropy for hybrid multiple attribute decision making problems[J]. *Mathematics in Practice and Theory*, 2007, 37(3): 64-68.)