

# 控制与决策

Control and Decision

## 一种基于池计算的宽度学习系统

杨刚, 陈鹏, 戴丽珍, 杨辉

引用本文:

杨刚, 陈鹏, 戴丽珍, 等. 一种基于池计算的宽度学习系统[J]. 控制与决策, 2021, 36(9): 2203–2210.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1729>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于数据分布特性的代价敏感宽度学习系统

Data distribution-based cost-sensitive broad learning system

控制与决策. 2021, 36(7): 1686–1692 <https://doi.org/10.13195/j.kzyjc.2019.1484>

### 基于生成对抗网络学习被遮挡特征的目标检测方法

Object detection via learning occluded features based on generative adversarial networks

控制与决策. 2021, 36(5): 1199–1205 <https://doi.org/10.13195/j.kzyjc.2019.1319>

### 基于HI-DD-AdaBoost.RT的锂离子动力电池SOH预测

Prediction of Li-ion battery SOH based on HI-DD-AdaBoost.RT

控制与决策. 2021, 36(3): 686–692 <https://doi.org/10.13195/j.kzyjc.2019.0764>

### 一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

### 基于强化学习的倒立摆分数阶梯度下降RBF控制

Reinforcement learning based fractional gradient descent RBF neural network control of inverted pendulum

控制与决策. 2021, 36(1): 125–134 <https://doi.org/10.13195/j.kzyjc.2019.0816>

# 一种基于池计算的宽度学习系统

杨刚, 陈鹏, 戴丽珍<sup>†</sup>, 杨辉

(1. 华东交通大学 电气与自动化工程学院, 南昌 330013; 2. 江西省先进控制与优化重点实验室, 南昌 330013)

**摘要:** 宽度学习系统(BLS)是一种基于RVFLN的高效增量学习系统,具有快速且精度高的特点. 为了实现BLS对时间序列的精确预测,结合回声状态网络(ESN)的储备池结构,提出一种基于池计算的宽度学习系统(RCBLs). 该系统通过在强化层引入简单环型储备池连接,以并行的储备池代替原系统中的前馈连接,使RCBLs具有一定的回声状态特性且方便设计. 同时,应用增量学习保证了系统的实时性能. 基于MSO时间序列预测问题,针对不同规模数据样本分别研究不同储备池结构RCBLs的性能. 结果表明:多储备池结构的RCBLs大大提高了模型的泛化能力和稳定性.

**关键词:** 宽度学习; 回声状态网络; 时间序列预测; 增量学习; 池计算

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1729

开放科学(资源服务)标识码(OSID):



引用格式: 杨刚,陈鹏,戴丽珍,等. 一种基于池计算的宽度学习系统[J]. 控制与决策, 2021, 36(9): 2203-2210.

## A broad learning system based on reservoir computing

YANG Gang, CHEN Peng, DAI Li-zhen<sup>†</sup>, YANG Hui

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China; 2. Key Laboratory of Advanced Control & Optimization of Jiangxi Province, Nanchang 330013, China)

**Abstract:** Broad learning system(BLS), which has characteristics of fast and accuracy, is an efficient incremental learning systems based on random vector function-link network(RVFLN). In order to realize the precise prediction of time-series, a broad learning system based on reservoir computing reservoir computing broad learning systems(RCBLs) is proposed combined with the reservoir structure of echo state network(ESN). A simple circle reservoir connection is introduced in the RCBLs's enhancement layer to replace the feedforward connection of BLS, which makes the RCBLs have certain echo state characteristics and convenient for design. At the same time, incremental learning is applied to ensure RCBLs's real-time performance. Based on the multiple superimposed oscillator(MSO) time series prediction problems, the performance of the RCBLs with different reservoir structures under different scales of data sample is studied respectively. The results show that the RCBLs with multi-reservoir structure improves the generalization performance and stability greatly.

**Keywords:** broad learning; echo state network; time series prediction; incremental learning; reservoir computing

## 0 引言

宽度学习系统(broad learning system, BLS)<sup>[1]</sup>是一种基于随机向量函数型网络(random vector function-link network, RVFLN)<sup>[2-6]</sup>的学习框架,继承了RVFLN在线增量学习算法并增加了映射层,使其能够适用于大量数据的场合. 不同于深度学习, BLS致力于神经网络的横向拓展而非纵向拓展. BLS具有通用逼近能力<sup>[7]</sup>,且在MINIST等数据集上的应用表明, BLS可以获得不亚于主流深度学习(deep learning, DL)模型的预测精度. 然而,由于BLS只需

要训练输出权值,学习速度极快,且对计算机硬件系统要求不高. 因此,宽度学习已经得到了学术界和工业界的广泛关注. 其中, Jin等<sup>[8]</sup>使用正则化的方法设计了一种正则化鲁棒宽度学习系统,相比于传统的BLS,其提高了在噪声条件下模型的鲁棒性. Kong等<sup>[9]</sup>设计了一种半监督宽度学习系统,在高光谱图像分类中取得了比一般分类器以及深度学习更高的精度. Liu等<sup>[10]</sup>将宽度学习应用于类增量学习之中,在实现网络动态实时更新的同时解决了灾难性遗忘的问题. 此外,在宽度学习的基础上,通过引入 $p$ -范数作

收稿日期: 2019-12-10; 修回日期: 2020-02-27.

基金项目: 国家自然科学基金项目(61663012, 61673172, 61733005).

责任编辑: 侯忠生.

<sup>†</sup>通讯作者. E-mail: bjdailz@163.com.

为损失函数,提出一种基于最小 $p$ -范数的宽度学习系统(LP-BLS)<sup>[11]</sup>. LP-BLS增强了BLS在复杂噪声情况下的抗干扰能力,在脑机图分类上取得了比LDA、KNN、SVM、ELM以及BLS更高的精度. Lin等<sup>[12]</sup>设计了一种四元数宽度学习系统(QBLS),作为多维滤波器用于遥操作的震颤估计和消除. Zhong等<sup>[13]</sup>基于在序列模糊宽度学习系统设计了RFID读卡器故障自适应定位系统.

实际上,大多数的工业生产系统都是动态的,并且可以看作是一个时间序列问题. 然而,BLS以及上述基于BLS的方法,多是基于前馈型网络设计的. 由于前馈网络本身缺少对系统动态特性的处理能力,在使用时有诸多限制. 对于基于神经网络的方法而言,结构往往决定了功能. 因此,为了捕捉时间序列的动态特性,Xu等<sup>[14]</sup>在BLS的增强单元引入了递归连接,提出了一种循环宽度学习系统(RBLS),并成功提升了时间序列的预测精度. 尽管RBLS通过增强单元的递归连接具备了一定的动态特性,然而RBLS放弃了BLS增量学习这一突出优点. 为了实现大规模噪声混沌时间序列的预测,Feng等<sup>[15]</sup>设计了鲁棒流形宽度学习系统(RM-BLS). 综上,通过对BLS网络结构的设计,可应用于动态系统的问题求解.

不同于传统前向型神经网络,回声状态网络(echo state network, ESN)<sup>[16]</sup>是一种典型的循环神经网络(RNN),具有较好的动态特性,开启了池计算(reservoir computing, RC)研究的大门. ESN把RNN简化为3层结构:输入层、储备池和输出层. 其中,输入层对输入数据进行缩放处理,储备池将数据映射到高维空间之中,而输出层将高维的数据在特定的低维空间中表达. ESN需要训练的是输出层权值,通常采用线性回归的方法,尽管输入层与储备层权值不需要训练,但其结构和参数的设置极大地影响了ESN的性能. 因此,对ESN的研究主要集中在储备池的优化以及输出权值的训练上. 传统ESN的储备池,其内部神经元是随机连接的. 需要提前设置的参数主要有谱半径 $\rho$ 、稀疏度以及储备池的规模,即储备池神经元数量. 这种基于储备池的方法极大地简化了递归神经网络的设计步骤,使得递归神经网络的应用范围得到了拓展,特别是Jeager<sup>[17]</sup>将回声状态网络用于无线通信,对含有噪声的时间序列预测精度提高了2400倍.

为了提升ESN的性能,众多学者关注ESN的结构优化设计问题. 其中,储备池优化设计是ESN结构优化设计中的一个重要内容,主要包括储备池拓扑

结构优化、储备池参数优化以及神经元模型优化3个方面<sup>[18]</sup>. 其中,在储备池拓扑结构优化方面,Rodan等<sup>[19]</sup>提出ESN具有3种基本拓扑结构,分别为延迟线型、带反馈延迟线型和环型结构. 实验和理论研究表明:环型结构的储备池具备了足够的回声状态特性. 此外,Deng等<sup>[20]</sup>提出了一种具有小世界特性的ESN,实验结果表明其性能明显优于随机储备池ESN;李凡军等<sup>[21]</sup>提出了一种模块化ESN结构,其储备池由多个子储备池构成,相当于把子储备池作为最小记忆单元,可根据预期的精度调节子储备池数量;Ma等<sup>[22]</sup>提出了一种层次化结构的深度ESN,其通过多个串联的储备池,在不同的尺度来挖掘数据的内在信息;Gallicchio等<sup>[23]</sup>运用李雅普诺夫方法分析了深度ESN的稳定性. 为了实现多变量时间序列的准确预测,Yao等<sup>[24]</sup>设计了一种多储备池的宽度回声状态网络(Broad-ESN).

为了使BLS适用于动态系统问题求解(时间序列预测),本文拟结合ESN中的储备池结构研究基于池计算的宽度学习系统(reservoir computing broad learning system, RCBL)设计方法,主要包含储备池结构设计及其增量学习算法研究,旨在通过对系统动态特性的提取,提升BLS的性能.

## 1 回声状态网络

经典的ESN是一种典型的递归随机映射神经网络,结构如图1所示,主要由以下两个部分组成:

- 1) 稀疏、随机连接的递归网络——储备池,接受外部激励.
- 2) 可调的输出权值,连接储备池和输出节点.

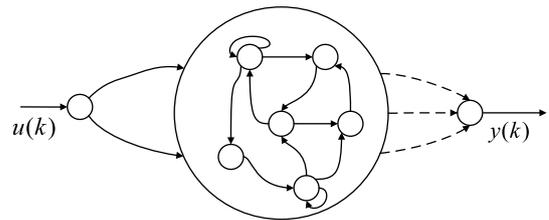


图1 ESN结构

ESN的数学表达式为

$$\begin{cases} x(k+1) = g(W_{in}u(k+1) + W_x x(k)), \\ y(k+1) = w^T x(k+1). \end{cases} \quad (1)$$

其中: $W_{in} \in R^{n \times d}$ 为连接输入层和储备池的输入权值矩阵; $W_x \in R^{n \times n}$ 为储备池内部连接权值矩阵; $w \in R^{n+1}$ 为连接储备池和输出层的输出权值向量(为简化表示,将输出节点的偏置值作为第 $n+1$ 个输出权值); $x(k) \in R^n$ 为 $k$ 时刻的 $n$ 维储备池状态向量( $n$ 为储备池规模); $u(k) \in R^d$ 为回声状态网络在

$k$ 时刻的输入向量; $u(k+1) \in R$ 为回声状态网络在 $k+1$ 时刻的输入向量; $y(k+1) \in R$ 为回声状态网络在 $k+1$ 时刻的输出(不失一般性,本文选择标量输出); $g(\cdot)$ 为激活函数,一般取双曲正切函数.由式(1)可知,回声状态网络 $k+1$ 时刻的输出 $y(k+1)$ 不仅与 $k+1$ 时刻的输入 $u(k+1)$ 有关,而且与网络 $k$ 时刻的内部状态 $x(k)$ 有关.

对于传统的回声状态网络,影响其性能的主要因素为储备池神经元数量、谱半径 $\rho$ 和稀疏度.尽管随机连接的储备池结构为网络提供了丰富的动态特性,但却难以保证良好的稳定性.因此,储备池的结构优化设计非常重要.

## 2 基于池计算的宽度学习系统

### 2.1 随机函数链接网络

随机向量函数链接网络(RVFLN)是一种单隐含层的前馈神经网络(single-layer feedforward neural network, SLFN),与一般的SLFN不同之处在于RVFLN具有从输入层直接到输出层的连接权值,其结构如图2所示,包含输入层、强化层和输出层.

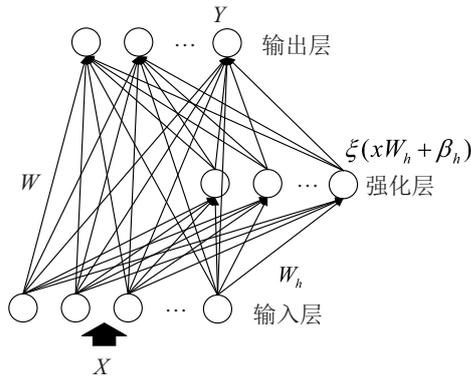


图2 RVFLN结构

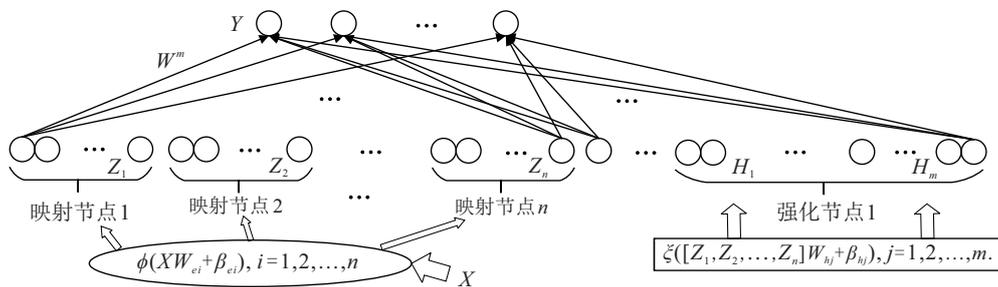


图3 BLS结构

BLS的输出表示为

$$Y(t) = [Z_1(t), Z_2(t), \dots, Z_n(t)] \\ H_1(t), H_2(t), \dots, H_m(t)]W^m = \\ [Z^n(t)|H^m(t)]W^m = A^mW^m. \quad (7)$$

其中: $W^m$ 表示输出权值矩阵,可通过线性回归计算

RVFLN的输出表达式为

$$Y = [X|\xi(XW_h + \beta_h)]W. \quad (2)$$

其中: $X$ 为网络输入, $W_h$ 为强化层权值矩阵, $\beta_h$ 为强化层偏置, $\xi(\cdot)$ 为非线性激活函数, $W$ 为唯一需要训练的输出权值.

### 2.2 宽度学习系统

宽度学习系统(BLS)最初是为前向神经网络设计的学习框架,其基本结构如图3所示. BLS有3层基本结构,分别为映射层、强化层和输出层.相比于RVFLN, BLS以映射层代替了输入层.映射层的输出表达式为

$$Z_i(t) = \phi(X(t)W_{ei} + \beta_{ei}), i = 1, 2, \dots, n, \quad (3)$$

$$Z^n(t) \triangleq [Z_1(t), Z_2(t), \dots, Z_n(t)] \in \mathbf{R}^{1 \times \sum_{i=1}^n k_i} \quad (4)$$

其中: $W_{ei}$ 和 $\beta_{ei}$ 分别为特征映射层权值和偏置值,可由稀疏自编码(sparse auto-encode, SAE)得到; $n$ 为映射层节点数; $k_i$ 为映射层各节点的神经元个数; $\phi(\cdot)$ 为非线性激活函数.相比于随机初始化, SAE方法能更加高效地提取特征.

强化层的输入为特征映射层的输出,节点数量可根据实际情况进行调整.强化层输出计算公式为

$$H_j(t) = \xi_j(Z^n(t)W_{hj} + \beta_{hj}), \quad (5)$$

$$H^m(t) \triangleq [H_1(t), H_2(t), \dots, H_m(t)] \in \mathbf{R}^{1 \times \sum_{j=1}^m p_j} \quad (6)$$

其中:权值 $W_{hj}$ 和 $W_{xj}$ 以及偏置 $\beta_{hj}$ 都随机初始化产生, $\xi_j(\cdot)$ 表示非线性激活函数, $m$ 表示强化层节点数, $p_j$ 表示强化层各节点维数.

$A^m$ 的广义逆获得,亦可通过岭回归计算获得,分别为

$$W^m = [A^m]^+Y, \quad (8)$$

$$W^m = [(A^m)^T A^m + CI]^{-1}(A^m)^T Y. \quad (9)$$

### 2.3 基于池计算宽度学习系统

为了提升BLS对系统动态特性的捕捉能力,本文将池计算引入宽度学习系统架构的设计中,提出

基于池计算的宽度学习系统(RCBLs),其结构如图4所示.RCBLs采用递归连接的储备池取代了BLS强化层中前向连接的神经元,构成储备池层.储备池层使RCBLs具有了回声状态特性,可以映射系统“过去”和“未来”的对应关系.其特征映射层的输出 $Z^n = [Z_1, \dots, Z_n]$ 与BLS相同,储备池层输出 $H^m = [H_1, \dots, H_m]$ 为状态矩阵. $H_j$ 为各子储备池的状态

矩阵,有

$$H_j(k+1) = s\xi(W_{hj}Z^n(k+1) + W_jH(k)) + (1-s)H_j(k). \quad (10)$$

其中: $k = 1, 2, \dots, l$ ( $l$ 为数据样本个数), $s$ 为漏积分系数, $\xi(\cdot)$ 为非线性激活函数, $W_{hj}$ 为映射层到储备池层的权值矩阵, $W_j$ 为储备池神经元连接矩阵.

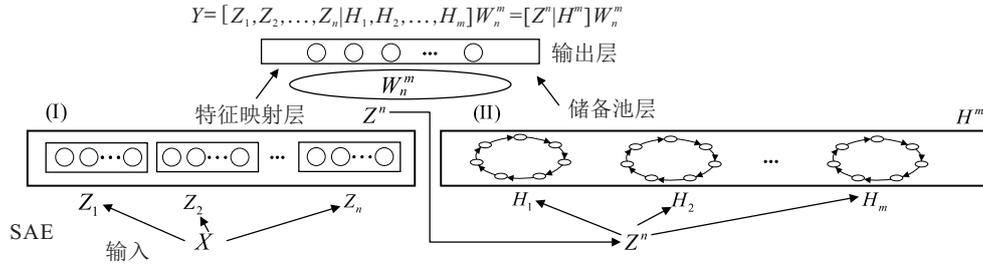


图4 RCBLs结构

RCBLs输出为

$$Y = [Z_1, Z_2, \dots, Z_n | H_1, H_2, \dots, H_m] W_n^m = [Z^n | H^m] W_n^m = A_n^m W_n^m, \quad (11)$$

$$W_n^m = [(A_n^m)^T A_n^m + \alpha I]^{-1} (A_n^m)^T Y. \quad (12)$$

其中: $W_n^m$ 为输出权值矩阵, $\alpha$ 为正则化参数.

为了保证RCBLs的性能,当RCBLs增加新的储备池时,储备池层状态矩阵的快速更新方法设计如下.

step 1: 增加新的子储备池以后,更新储备池层的状态矩阵

$$A_n^{m+1} \equiv [A_n^m | H_{m+1}], \quad (13)$$

其中 $A_n^m = [Z^n | H^m]$ .

step 2: 计算 $A_n^{m+1}$ 的伪逆矩阵

$$(A_n^{m+1})^+ = \begin{bmatrix} (A_n^m)^+ - DB^T \\ B^T \end{bmatrix}. \quad (14)$$

step 3: 更新输出权值矩阵 $W_n^{m+1}$ ,有

$$W_n^{m+1} = \begin{bmatrix} W_n^m - DB^T Y \\ B^T Y \end{bmatrix}. \quad (15)$$

其中

$$\begin{cases} D = (A_n^m)^+ H_{m+1}^+; \\ B^T = \begin{cases} (C)^+, & C \neq 0; \\ (1 + D^T D)^{-1} B^T (A_n^m)^+, & C = 0; \end{cases} \\ C = H_{m+1} - A_n^m D. \end{cases} \quad (16)$$

该方法无需每次都重新计算储备池层的状态矩阵的伪逆 $(A_n^{m+1})^+$ ,只需要在 $A_n^m$ 的基础上通过少量的计算得到,这使得输出权值的动态更新成为了可能.

RCBLs的子储备池设计方法灵活多样,既可以设计为随机网络也可以设计为规则网络,并且各个子储备池亦可进行独立设计,从而保证网路丰富的动态特性.若储备池设计为规则网络,则可考虑如图5所示的延迟线型储备池(a)、带反馈延迟线型储备池(b)和简单环型储备池(c).由于规则网络不仅可以避免过拟合,而且简单环型网络亦具备与随机网络相当的短期记忆能力<sup>[19]</sup>,本文选择简单环型储备池结构设计RCBLs.

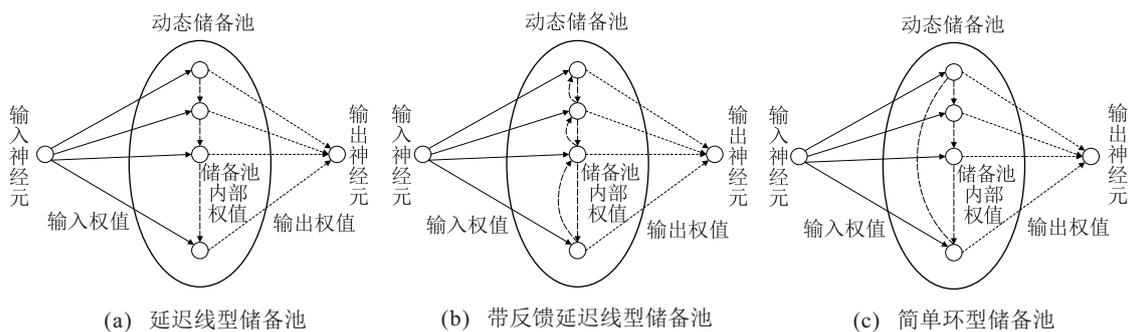


图5 3种基本的规则网络结构

综上所述,基于池计算的宽度学习系统设计步骤如下.

- step 1: 初始化特征映射层权值  $W_{ei}$  和  $\beta_{ei}$ , 设置最大容许误差  $\varepsilon$ , 确定储备池的结构和参数;
- step 2: 计算特征映射层输出  $Z^n$ ;
- step 3: 计算储备池层输出  $H^m$ ;
- step 4: 计算  $A_n^m$  的伪逆以及输出权值  $W_n^m$ ;
- step 5: 初始化新增子储备池的结构和参数;
- step 6: 计算新增子储备池输出  $H_{m+1}$ ;
- step 7: 计算  $A_n^{m+1}$  的伪逆以及输出权值  $W_n^{m+1}$ ;
- step 8: 计算误差, 若实际误差小于最大容许误差则停止, 否则返回 step 5 继续执行.

### 3 实验仿真与分析

为了验证本文所设计 RCBLs 的学习能力, 选择时间序列预测基准问题进行仿真研究. 本文所有仿真研究均是基于 Matlab 2018a 进行的, 运行环境为 Intel Core I7-8700, 16 GB 内存的 Windows 10 操作系统.

MSO (multiple superimposed oscillator) 时间序列预测实际上是预测一个多种频率正弦波叠加的时间序列, 常用于神经网络性能测试. 因为各频率没有最小公倍数, 随着叠加波形数量的增加, 其整体波长会变长, 预测也越发困难. 此外, 在实际的生产应用中, 多种频率的叠加问题也非常常见<sup>[25]</sup>. 因此, 本文通过 MSO 时间序列预测仿真, 验证 RCBLs 的学习能力. MSO 的数学表达式为

$$y(t) = \sum_{i=1}^k \sin(\alpha_i t), \quad t = 1, 2, \dots, n. \quad (17)$$

其中:  $\alpha_i$  为正弦波的频率, 通常设置为  $\alpha_1 = 0.2, \alpha_2 = 0.311, \alpha_3 = 0.42, \alpha_4 = 0.51, \alpha_5 = 0.63, \alpha_6 = 0.74, \alpha_7 = 0.85, \alpha_8 = 0.97$ . MSO2 时间序列即为预测频率为  $\alpha_1, \alpha_2$  的正弦波叠加的时间序列. 前 300 组数据如图 6 所示.

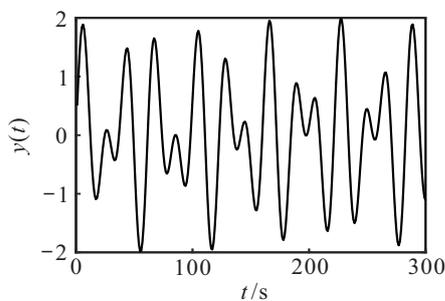


图 6 MSO2 序列

一方面, 神经网络的性能主要由其结构决定, 因此, RCBLs 中储备池的结构 (含连接模式, 储备池的数量及储备池内神经元的数量) 将直接影响网络的

性能. 另一方面, 神经网络建模是基于数据样本工作的, 因而网络的性能与数据样本对问题的覆盖程度密切相关. 亦即, 包含更多、更全面系统信息的大规模数据样本有利于提升神经网络建模的准确性. 为了全面研究 RCBLs 的性能, 拟结合 MSO2 时间序列预测问题, 分别研究小规模样本和大规模样本下单一储备池和多储备池结构 RCBLs 的学习能力.

#### 3.1 基于小规模数据样本的性能测试

在基于小规模数据样本的性能测试中, 分别选择  $t \in [1, 700]$  和  $t \in [701, 1000]$  的样本用于训练和测试. 单一储备池结构的 RCBLs 参数设置如下:  $n = 5, k = 10, r = 0.99$ . 其中:  $n$  为特征映射层节点个数,  $k$  为每个节点的神经元数量,  $r$  为储备池神经元权值.

对于单一储备池结构的 RCBLs, MSO2 时间序列预测的均方误差 (MSE) 随储备池神经元数量的变化如图 7 所示. 由图 7 可知: 当神经元数量过少时, 由于模型欠拟合, 会产生较大的测试误差, 甚至出现发散, 而泛化能力也较差; 当神经元数量过多时, 过拟合则使得测试误差随神经数量的增加而增大, 而泛化能力变差. 仿真结果表明, 储备池内神经元数量  $N_R = 550$  时系统的测试误差最小, 此时平均训练误差和平均测试误差分别为  $7.99e-14$  和  $2.65e-11$ , 表明模型复杂度与数据基本匹配.

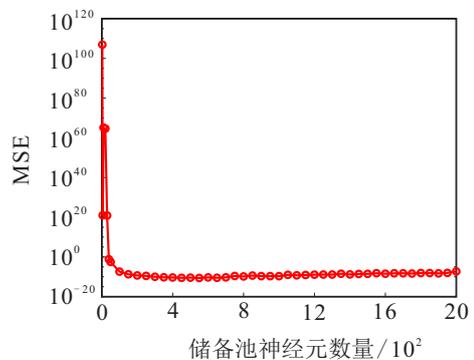


图 7 单储备池结构的 RCBLs 测试误差

为了深入研究储备池结构对 RCBLs 性能的影响, 在小规模数据样本情况下, 以最佳储备池神经元数量  $N_R = 550$  为基准, 分别研究  $N_R = 550$  和  $N_R > 550$  时的系统性能.

1)  $N_R = 550$  时, 分别测试表 1 所示的 3 种网络结构, 并比较各自性能差别.

表 1 多储备池 RCBLs 对 MSO2 测试误差

	RCBLs-1	RCBLs-2	RCBLs-3
储备池数量	2	5	11
每个储备池的神经元数量	275	110	50
MSE	1.46e-11	4.40e-10	3.28e-08

2)  $N_R > 550$ 时,测试了  $n + 1$  种储备池结构的 RCBLs. 其中一种为单一储备池结构,其他  $n$  种结构的储备池层神经元数量是550的整数倍,系统误差性能对比如图8所示. 由实验结果可知,随着网络规模的增加,单一储备池结构 RCBLs 的预测精度持续降低,这是由模型的过拟合所致. 而对于多储备池结构 RCBLs,预测精度波动不大.

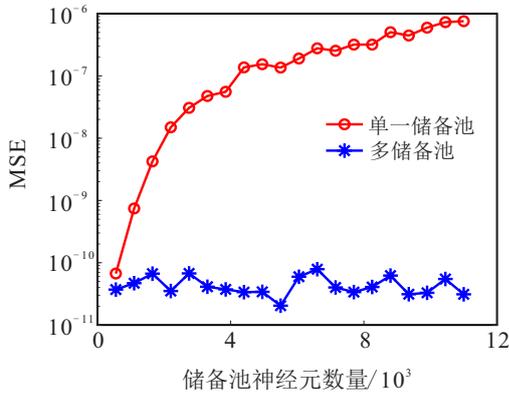


图8 小规模数据样本下不同结构RCBLs泛化误差对比

表2中给出了RCBLs与多种改进ESN对MSO2的平均预测误差(MSE),设计成功率( $R(0.0034)$ )<sup>[26]</sup>在不同储备池神经元数量  $N$  下的性能对比,相关数据来自于相应文献,“/”表示文献未提供.

表2 多种改进ESN对MSO2预测误差

METHODS	MSE	$R(0.0034)$	$N$
RCBLs	6.9e-12	1	700
IM-ESN <sup>[21]</sup>	2.4e-11	1	46
CESN <sup>[27]</sup>	1.4e-10	/	300
PSO+ESN <sup>[28]</sup>	5.0e-04	1	10
SWESN <sup>[29]</sup>	/	0.978	/
DESN+MaxInfo <sup>[26]</sup>	3.0e-04	0.635	400

当储备池层神经元总数为700,储备池数量为2时,测试跟踪曲线和绝对误差曲线如图9所示.

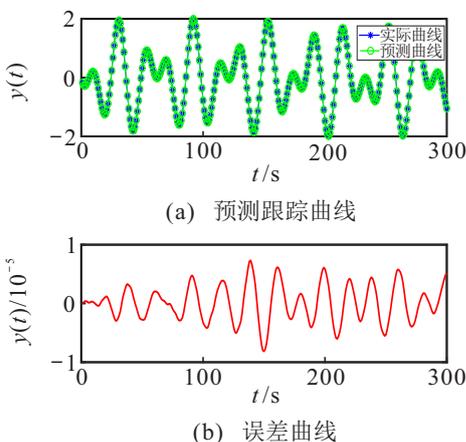


图9 多储备池RCBLs的MSO2序列预测曲线

上述实验结果表明,RCBLs在求解MSO2问题时,可以获得优于其他同类方法的预测精度,且稳定性好( $R = 1$ ). 同时,在网络规模相等的情况下多个储备池结构的RCBLs具有比单一储备池结构更优的泛化能力;而在网络规模较大时,多储备池结构的RCBLs仍具有较好的泛化能力. 因此,多储备池结构的RCBLs有望解决复杂系统的大量数据.

### 3.2 大规模样本测试

在基于大规模数据样本的性能测试中,分别选择  $t \in [1, 2100]$  和  $t \in [2101, 3000]$  的样本用于训练和测试,其他参数设置均与小规模数据样本性能测试一致. 在相同网络规模下,单一储备池与多储备池结构 RCBLs 的泛化误差对比如图10所示.

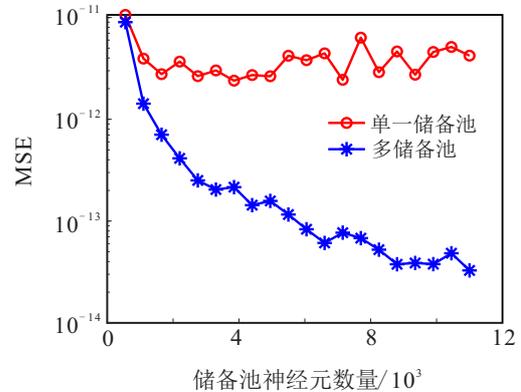


图10 大规模数据样本下不同结构RCBLs泛化误差对比

由图10可知,在大规模数据样本情况下,无论是单一储备池结构还是多储备池结构的RCBLs性能均有一定程度的提高,但单一储备池结构的RCBLs性能改善非常有限,而多储备池结构的RCBLs性能则随着神经元数量的增加持续提高. 当储备池层神经元数量达到  $N_R = 11000$  时,两者的平均均方误差分别为  $4.22e-12$  和  $3.27e-14$ .

此外,若分别选择  $t \in [1, 7000]$  和  $t \in [7001, 10000]$  组样本用于训练和测试,储备池神经元数量设为  $N_R = 16500$  时,单一储备池结构 RCBLs 和多储备池结构(即储备池数量为30,每个储备池神经元数量为550) RCBLs 的平均均方误差分别为  $4.1634e-13$  和  $6.1324e-16$ ,性能差别更加明显. 由此可知,多储备池结构的RCBLs可用于处理大规模数据.

### 3.3 计算量分析

不同于深度网络,基于宽度学习的BLS不需要计算梯度而大大减少了计算量. 而RCBLs采用类似BLS的增量学习架构,同样具有快速性的特点. 与同类ESN相比,多储备池结构RCBLs因采用储备池层状态矩阵快速更新算法而不需要直接求解大型矩阵

的伪逆,从而大大减少了计算量.本节将通过对比网络训练时间,验证RCBLS的计算量.因此,采用与3.2节完全相同的实验设置,对比ESN的计算性能,结果如图11所示.

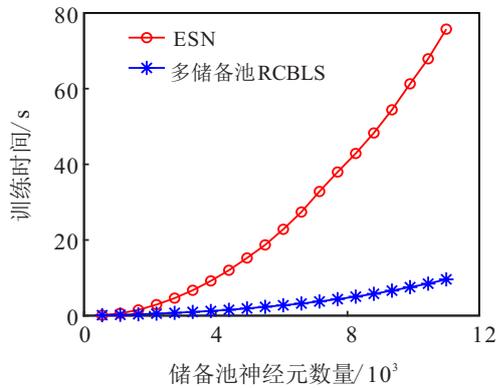


图11 ESN与RCBLS计算量对比

由图11可知,从训练时间的角度出发,RCBLS的计算量明显小于ESN.而随着储备池神经元数量的增加,RCBLS的优势更加明显.比如,当储备池神经元数量为11000时,ESN的训练时间为76s,RCBLS的训练时间仅为9.6s.由此可知,尽管多储备池结构RCBLS的结构复杂度提高了,但其计算复杂度仍然较低,有利于在实际应用中的推广.

## 4 结论

为了提升BLS对系统动态特性的捕捉能力,针对BLS的结构设计问题,结合ESN的储备池结构,提出了一种基于池计算的宽度学习系统(RCBLS).该系统在宽度学习架构基础上,在强化层采用递归连接的储备池结构代替原系统的前向连接,并使用增量学习方法.储备池结构的引入,使BLS具备了一定的回声状态特性,通过提取时间信息,有助于在动力学系统中的应用.为了深入分析RCBLS的性能,结合MSO时间序列预测问题,分别研究了小规模和大规模数据样本下不同储备池结构RCBLS的性能.实验结果表明:无论数据样本的规模如何,多储备池结构的RCBLS性能均普遍优于单一储备池结构的RCBLS;随着网络规模的增大,多储备池RCBLS能有效避免过拟合并持续提高精度;在同等网络规模下,多储备池RCBLS的计算量远小于ESN的计算量.此外,基于简单环型结构的储备池连接,在保证系统性能的前提下,简化了RCBLS的设计步骤,方便操作应用.

## 参考文献(References)

[1] Chen C L P, Liu Z. Broad learning system: An effective and efficient incremental learning system without the need

for deep architecture[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.

- [2] Chen C L P, Wan J Z. A rapid learning and dynamic stepwise updating algorithm for flat neural networks and the application to time-series prediction[J]. IEEE Transactions on Systems, Man, and Cybernetics: Part B, 1999, 29(1): 62-72.
- [3] Chen C L P. A rapid supervised learning neural network for function interpolation and approximation[J]. IEEE Transactions on Neural Networks, 1996, 7(5): 1220-1230.
- [4] Igel'nik B, Pao Y. Stochastic choice of basis functions in adaptive function approximation and the functional-link net[J]. IEEE Transactions on Neural Networks, 1995, 6(6): 1320-1329.
- [5] Pao Y H, Park G H, Sobajic D J. Learning and generalization characteristics of the random vector functional-link net[J]. Neurocomputing, 1994, 6(2): 163-180.
- [6] Pao Y H, Takefuji Y. Functional-link net computing: Theory, system architecture, and functionalities[J]. Computer, 1992, 25(5): 76-79.
- [7] Chen C, Liu Z, Feng S. Universal approximation capability of broad learning system and its structural variations[J]. IEEE Transactions on Neural Networks Learning Systems, 2019, 30(4): 1191-1204.
- [8] Jin J W, Chen C L P. Regularized robust broad learning system for uncertain data modeling[J]. Neurocomputing, 2018, 322: 58-69.
- [9] Kong Y, Wang X, Cheng Y, et al. Hyperspectral imagery classification based on semi-supervised broad learning system[J]. Remote Sensing, 2018, 10(5): 685.
- [10] Liu W, Yang H, Sun Y, et al. A broad neural network structure for class incremental learning[C]. International Symposium on Neural Networks. Cham: Springer, 2018: 229-238.
- [11] 郑云飞, 陈霸东. 基于最小 $p$ -范数的宽度学习系统[J]. 模式识别与人工智能, 2019, 32(1): 51-57. (Zheng Y F, Chen B D. Least  $p$ -norm broad learning system[J]. Pattern Recognition and Artificial Intelligence, 2019, 32(1): 51-57.)
- [12] Lin J, Liu Z, Chen C L P, et al. Quaternion broad learning system: A novel multi-dimensional filter for estimation and elimination tremor in teleoperation[J]. Neurocomputing, 2020, 380: 78-86.
- [13] Zhong D, Liu F. RF-OSFBLs: An RFID reader-fault-adaptive localization system based on online sequential fuzzy broad learning system[J]. Neurocomputing, 2020, 390: 28-39.
- [14] Xu M, Han M, Chen C L P, et al. Recurrent broad learning

- systems for time series prediction[J]. IEEE Transactions on Cybernetics, 2020, 54(4): 1405-1417.
- [15] Feng S, Ren W, Han M, et al. Robust manifold broad learning system for large-scale noisy chaotic time series prediction: A perturbation perspective[J]. Neural Networks, 2019, 117: 179-190.
- [16] Jaeger H. The “echo state” approach to analysing and training recurrent neural networks-with an erratum note[J]. Bonn: German National Research Center for Information Technology GMD Technical Report, 2001, 148(34): 13.
- [17] Jaeger H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.
- [18] Lukoeviius M, Jaeger H. Reservoir computing approaches to recurrent neural network training[J]. Computer Science Review, 2009, 3(3): 127-149.
- [19] Rodan A, Tino P. Minimum complexity echo state network[J]. IEEE Transactions on Neural Networks, 2011, 22(1): 131-144.
- [20] Deng Z, Zhang Y. Collective behavior of a small-world recurrent neural system with scale-free distribution[J]. IEEE Transactions on Neural Networks, 2007, 18(5): 1364-1375.
- [21] 李凡军, 乔俊飞. 一种增量式模块化回声状态网络 [J]. 控制与决策, 2016(8): 1481-1486.  
(Li F J, Qiao J F. An incremental modular echo state network[J]. Control and Decision, 2016, 31(8): 1481-1486.)
- [22] Ma Q, Shen L, Cottrell G W. Deep-ESN: A multiple projection-encoding hierarchical reservoir computing framework[J]. 2017, arXiv: 1711.05255.
- [23] Gallicchio C, Micheli A, Silvestri L. Local Lyapunov exponents of deep echo state networks[J]. Neurocomputing, 2018, 298: 34-45.
- [24] Yao X, Wang Z. Broad echo state network for multivariate time series prediction[J]. Journal of the Franklin Institute, 2019, 356(9): 4888-4906.
- [25] Thornhill N F, Huang B, Zhang H. Detection of multiple oscillations in control loops[J]. Journal of Process Control, 2003, 13(1): 91-100.
- [26] Xue Y, Yang L, Haykin S. Decoupled echo state networks with lateral inhibition[J]. Neural Networks, 2007, 20(3): 365-376.
- [27] 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(10/11/12): 2177-2185.
- [28] 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 output connection weights of echo state networks[J]. Control and Decision, 2011, 26(1): 22-26.)
- [29] 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.)

### 作者简介

杨刚(1983—), 男, 副教授, 博士, 从事复杂系统建模、控制与优化、计算智能方法及应用等研究, E-mail: hankyang@yeah.net;

陈鹏(1994—), 男, 硕士生, 从事计算智能方法及应用的研究, E-mail: samchenpen@163.com;

戴丽珍(1983—), 女, 讲师, 博士, 从事人工智能方法及应用、机器人技术的研究, E-mail: bjdailz@163.com;

杨辉(1965—), 男, 教授, 博士生导师, 从事复杂工业过程建模、控制及优化、轨道交通自动化与运行优化等研究, E-mail: yhshuo@263.net.

(责任编辑: 孙艺红)