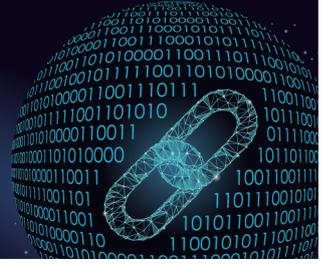




中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于强化学习的储层神经元筛选优化方法

郭伟, 姚欢, 张昭昭, 朱应钦

引用本文:

郭伟, 姚欢, 张昭昭, 朱应钦. 基于强化学习的储层神经元筛选优化方法[J]. 控制与决策, 2024, 39(9): 2876–2884.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0444>

您可能感兴趣的其他文章

Articles you may be interested in

一种基于池计算的宽度学习系统

A broad learning system based on reservoir computing

控制与决策. 2021, 36(9): 2203–2210 <https://doi.org/10.13195/j.kzyjc.2019.1729>

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>

基于近端强化学习的股价预测方法

Method of stock prices forecast based on proximal reinforcement learning

控制与决策. 2021, 36(4): 967–973 <https://doi.org/10.13195/j.kzyjc.2019.1245>

基于近端强化学习的股价预测方法

Method of stock prices forecast based on proximal reinforcement learning

控制与决策. 2021, 36(4): 967–973 <https://doi.org/10.13195/j.kzyjc.2019.1245>

基于深度强化学习与迭代贪婪的流水车间调度优化

Scheduling optimization for flow-shop based on deep reinforcement learning and iterative greedy method

控制与决策. 2021, 36(11): 2609–2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

基于强化学习的储层神经元筛选优化方法

郭伟¹, 姚欢^{1†}, 张昭昭², 朱应钦³

- 西安科技大学 通信与信息工程学院, 西安 710054;
- 西安科技大学 计算机科学与技术学院, 西安 710054;
- 墨西哥国立理工学院高级研究中心 控制科学与工程系, 墨西哥 07360)

摘要: 随机生成的回声状态网络动态储层存在大量冗余神经元, 导致网络高维状态空间矩阵产生共线性问题而影响网络预测性能. 为解决该问题, 提出一种基于强化学习的储层神经元筛选优化方法 (SC-ESN), 其实质是基于集成学习的思想构建多个初始储备池, 利用互信息度量储层池中每个神经元对网络性能的贡献, 并结合强化学习的决策机制筛选出对网络输出有效的神经元, 进而达到优化网络结构、提高网络预测性能的目的. 基于人工数据集和实际数据集的实验表明, 所提出的 SC-ESN 模型与其他预测模型相比, 该模型在保证预测性能的前提下具有最小结构.

关键词: 回声状态网络; 互信息; 强化学习; 集成学习; 结构优化

中图分类号: TP183 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2023.0444

引用格式: 郭伟, 姚欢, 张昭昭, 等. 基于强化学习的储层神经元筛选优化方法 [J]. 控制与决策, 2024, 39(9): 2876-2884.

Optimization method for reservoir neuron selection based on reinforcement learning

GUO Wei¹, YAO Huan^{1†}, ZHANG Zhao-zhao², ZHU Ying-qin³

- College of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710054, China;
- College of Computer Science and Technology, Xi'an University of Science and Technology, Xi'an 710054, China;
- Department of Control Automatic, Center for Research and Advanced Studies of the National Polytechnic Institute, Mexico City 07360, Mexico)

Abstract: The dynamic reservoir of the randomly generated echo state network (ESN) contains a significant amount of redundant neurons, which leads to collinearity in the high-dimensional state space matrix of the network and subsequently affects its prediction performance. In order to address this issue, this paper proposes a self-organizing choice ESN (SC-ESN) structure optimization model based on reinforcement learning. The essence of the SC-ESN model lies in its construction of multiple initial reserve pools, which is founded upon the idea of ensemble learning. The contribution of each neuron in the reservoir pool to the network performance is then measured using mutual information, and the decision mechanism of reinforcement learning is utilized to screen out effective neurons for network output. The purpose of this optimization is to improve the network's structure and prediction performance. Results of experiments conducted on both manual and actual datasets show that the SC-ESN model proposed has a more streamlined structure while still maintaining superior prediction performance compared to other prediction models.

Keywords: echo state network; mutual information; reinforcement learning; ensemble learning; structure optimization

0 引言

回声状态网络 (echo state network, ESN) 因网络结构和训练算法的不同而被称为一种特殊的循环神经网络 (recurrent neural network, RNN)^[1], 由于其具有

结构简单、训练速度快、能够避免梯度下降等优点, 在非线性动力系统建模^[2]、函数逼近^[3]、时间序列预测^[4-7] 等领域得到了广泛的应用. ESN 动态储层 (dynamic reservoir, DR) 是随机生成的, 但储层的随机

收稿日期: 2023-04-10; 录用日期: 2023-09-21.

基金项目: 陕西省自然科学基金基础研究计划陕煤联合基金项目 (2019JLZ-08); 陕西省自然科学基金基础研究计划项目 (2020JM-522, 2021JM-396); 国家重点研发计划项目 (2018YFC1900800-5, 2018YFC1900801).

责任编辑: 侯忠生.

[†]通讯作者. E-mail: 2565986657@qq.com.

性可能导致ESN不清晰的动态特性,一般需要多次尝试寻找高效的储层结构来改善ESN性能.因此,如何根据具体任务设计和构造最优的回声状态网络结构是研究的难点之一.

目前,国内外学者提出了许多ESN参数优化和网络结构优化的方法.就ESN参数优化而言,人们常用进化算法^[8]、粒子群算法等智能算法对ESN的重要参数进行优化^[9].Zhang等^[10]采用新颖搜索ESN行为空间,解决了参数选择困难的问题,提供了一种新的优化思路.另一类常用的优化策略为网络结构优化.Rodan等^[11]提出了简单环形储备池(simple cycle reservoir, SCR),其结构简单,预测性能与ESN相当.Cui等^[12]提出了多种新型DR结构,其实验结果表明储层连接方式的调整能极大增强预测性能.而储层规模的调整也不例外.Qiao等^[13]探讨了增长型回声状态网络(growing ESN, GESN),在现有的储层中依次增加子储层单元来改变储层结构,消除储层神经元之间的耦合效应,但储层规模的扩大增加了计算成本.Wang等^[14]根据敏感迭代剪枝算法来优化储层,利用灵敏度剔除内部不敏感的神经元,缩小储层规模,但未说明如何确定储层的数目.王磊等^[15]在模块化ESN中利用灵敏度判断子储层模块的贡献度,并根据网络规模适应度确定子储层模块的个数,删除灵敏度低的子模块.然而修剪方法需要对已更新的储层权重再次训练才能得到新的状态矩阵,增加了计算成本.信息熵能衡量储层神经元的动态行为,Qz Turk等^[16]探讨了用信息论度量DR,提出用平均状态熵来评估DR的丰富度.Li等^[17]采用信息熵来衡量储层神经元对网络输出的贡献度,并将贡献低的输出权值进行修剪,而修剪阈值的判断存在人为因素的影响,也并未涉及对储层结构寻优问题.强化学习的寻优搜索有很强的应用潜力.Liu等^[18]通过增加卷积神经网络的深度,使用强化学习来选择最佳的子网络结构.因此,回声状态网络储层结构优化的关键问题是如何对储层神经元全局筛选,提取储层有效信息,并确定储层神经元的数量,以使网络结构最小化.

鉴于此,本文提出一种基于强化学习的储层神经元筛选优化方法,其创新之处在于设计强化学习的神经元筛选策略来降低神经元的共线性和高耦合问题.由于单个储层中存在神经元高耦合现象,导致预测的不稳定,本文采用集成学习的思想,从多个初始储层池中利用强化学习的策略选择对网络输出有效的神经元.针对难以直接选择有效神经元的问题,采用互信息来衡量储层神经元对实际输出的贡献.针

对储层神经元全局筛选问题,利用贡献度结合强化学习决策机制,保留贡献度高的储层神经元,剔除贡献度低的冗余神经元以简化模型.最后,实验结果表明,相较于原始模型,该简化模型具有更低的预测误差.

1 回声状态网络

回声状态网络由输入层、储层和输出层3部分构成.其中,动态储层是由许多神经元随机组成的稀疏网络,通过调节网络内部权重的特征来实现对数据的短期训练和记忆功能^[19].

假设输入层、储层和输出层神经元的个数分别是 K 、 N 和 L ,则储层状态可按下式计算:

$$\tilde{x}(t) = f(W_{in}[1; u(t)] + Wx(t-1)), \quad (1)$$

$$x(t) = (1 - \alpha)x(t-1) + \alpha\tilde{x}(t). \quad (2)$$

其中: $x(t)$ 为 t 时刻储层神经元的激活状态, $\tilde{x}(t)$ 为 $x(t)$ 的更新, $[;]$ 表示垂直向量(或矩阵)连接, $f(\cdot)$ 为储层神经元的激活函数, $\alpha \in (0, 1]$ 为泄露率, W_{in} 和 W 分别为 $N \times (K + 1)$ 的输入权重矩阵和 $N \times N$ 的储层权重矩阵.

ESN的输出 $y(t)$ 可表示为

$$y(t) = W_{out}[1; u(t); x(t)], \quad (3)$$

其中 W_{out} 是 $L \times (N + K + 1)$ 的输出矩阵,可采用岭回归方法计算,即

$$W_{out} = Y_{target}X^T(XX^T + \beta I)^{-1}. \quad (4)$$

β 为正则化系数; I 为单位矩阵; Y_{target} 表示训练时期望目标输出向量 y_{target} 的集合,即

$$Y_{target} = \begin{bmatrix} y_{target}(n) \\ y_{target}(n+1) \\ \vdots \\ y_{target}(n+k+1) \end{bmatrix}, \quad (5)$$

大小为 $L \times T$ (T 表示训练周期 $t = 1, 2, \dots, T$); X 表示储层神经元的状态 $x(t)$ 的集合,即

$$X = \begin{bmatrix} x^T(n) \\ x^T(n+1) \\ \vdots \\ x^T(n+k+1) \end{bmatrix}, \quad (6)$$

大小为 $(N + K + 1) \times T$.

式(5)和(6)中: n 为对应初始瞬态过程的长度, k 为训练样本的数量.

回声状态网络中,储层的高维状态空间容易产生共线性问题,导致冗余神经元的产生,从而影响网络性能.因此,本文的目标是选择储层中部分神经元,以实现近似或超越原始储层全部神经元的效果^[20].

定义1 若状态矩阵 X 的行秩 $R(X)$ 满足

$$R(X) = N + K + 1, \quad (7)$$

则表示行向量不存在共线性问题,说明储层神经元间不存在信息冗余;反之,若满足

$$R(X) < N + K + 1, \quad (8)$$

则表示行向量存在共线性问题,说明储层神经元存在信息冗余,已有信息需被代替。

2 回声状态网络的结构优化

为了简化网络结构,缩小储层结构规模,降低网络复杂度,提高网络性能,本文提出一种基于强化学习的储层神经元筛选优化方法(SC-ESN)。本文从算法框架、基于互信息的神经元初筛、基于强化学习的结构优化和SC-ESN算法流程等方面依次展开论述。

2.1 算法框架

回声状态网络的储层随机生成,往往需要一个较大的储层网络来精确地拟合训练数据,但缺乏泛化能力。相反,一个很小的储层网络可以节省计算成本,但可能无法解决目标问题,因此难以匹配到最优网络结构。由于储层神经元在训练时,其对整个网络的贡献度不同,可将贡献度低的直接剔除。但对于单个ESN而言,储层内神经元信息总量较小,特性单一,剔除冗余神经元可能导致模型丢失部分重要信息;而对于多个ESN网络,由于每个网络不同的参数,不同层次的特征和交互关系能更好地保留重要信息,在冗余神经元剔除时增加了选择的多样性。因此,本文提出SC-ESN模型,其算法由3部分构成:创造筛选环境,衡量储层神经元和简化储层结构,如图1所示。

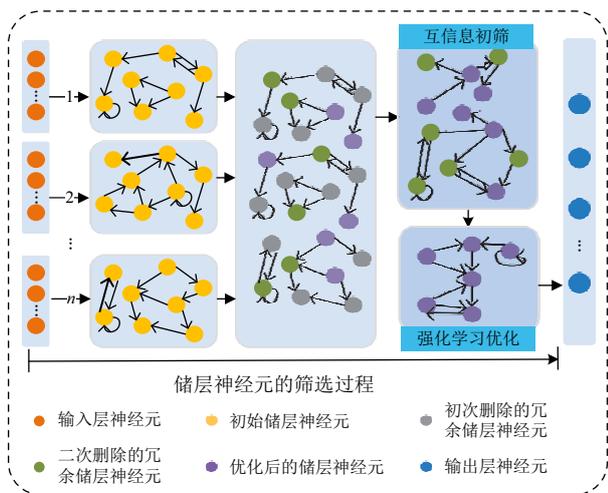


图1 SC-ESN算法框架

首先,在预筛选前,根据集成学习的思想构建多个原ESN储备池来获得先验知识,整合储备池内的神经元作为筛选的初始环境;其次,基于ESN和信息

熵的理论知识,储备池内神经元的状态矩阵与期望输出存在特殊关系,可利用互信息计算池内每个神经元对网络性能做出的贡献;最后,在筛选过程中,利用强化学习的决策函数,将贡献高的储层神经元保留,贡献低的储层神经元剔除,从而达到简化模型的目的。需要说明的是,算法的核心在于简化储层结构,通过强化学习的决策函数,能够提取神经元中的有用信息,使网络结构最小。

2.2 基于互信息的神经元初筛

回声状态网络将传入的时间序列信号转换为高维的状态空间,但并不是每个维度都对解决方案有帮助。对于ESN网络输出没有直接贡献的特征应该完全排除^[21],即将储层神经元激活状态相对较低的完全删除,以降低训练的复杂度。而互信息能够度量随机变量之间线性和非线性的依赖程度^[22]。因此,本文使用互信息(mutual information, MI)来度量储层神经元状态 X 与期望目标输出 Y_{target} 之间的依赖程度,即

$$I(X; Y_{\text{target}}) = H(X) + H(Y_{\text{target}}) - H(X, Y_{\text{target}}). \quad (9)$$

其中: $H(X)$ 和 $H(Y_{\text{target}})$ 分别为储层神经元和期望输出的信息量; $H(X, Y_{\text{target}})$ 为联合信息熵,描述两个变量之间共享的信息量。

根据信息熵,可将式(9)改写为

$$H(X) = - \sum_{x \in X} \rho(x) \log \rho(x), \quad (10)$$

$$H(Y) = - \sum_{y_{\text{target}} \in Y_{\text{target}}} \rho(y_{\text{target}}) \log \rho(y_{\text{target}}), \quad (11)$$

$$H(X, Y) = - \sum_{x \in X} \sum_{y_{\text{target}} \in Y_{\text{target}}} \rho(x, y_{\text{target}}) \log \rho(x, y_{\text{target}}), \quad (12)$$

$$I(X, Y_{\text{target}}) = - \sum_{x \in X} \sum_{y_{\text{target}} \in Y_{\text{target}}} \left(\rho(x, y_{\text{target}}) \times \log \frac{\rho(x, y_{\text{target}})}{\rho_X(x) \rho_{Y_{\text{target}}}(y_{\text{target}})} \right). \quad (13)$$

其中: $\rho(x)$ 和 $\rho(y_{\text{target}})$ 分别是 X 和 Y_{target} 的边缘概率密度, $\rho(x, y_{\text{target}})$ 是 X 和 Y_{target} 的联合概率密度。本文采用核密度估计方法计算两个变量的互信息^[23]。对于 $x_1, x_2, \dots, x_k \in x_i$ 的核密度估计为

$$K(x) = \frac{1}{k} \sum_{i=1}^k \phi(x - x_i, h). \quad (14)$$

其中: $K(x)$ 是带宽为 h 的核密度估计函数, $\phi(\cdot)$ 是多维高斯核函数. 多维高斯核函数数学描述为

$$\phi(x - x_i, h) = \frac{1}{(\sqrt{2\pi}h)^m |C^{\frac{1}{2}}|} \exp\left(-\frac{(x - x_i)^T C^{-1} (x - x_i)}{2h^2}\right). \quad (15)$$

其中: m 是维数, C 是 X 与 y_{target} 之间的协方差矩阵. 由式 (14) 和 (15) 可知, x 距离 x_i 越近, 选择合适的 h , $\phi(x - x_i, h)$ 就越接近真实值.

由以上分析可知, 储层中第 i 个神经元对期望输出的信息量 m_i , 其与储层神经元 x_i 和期望输出向量 y_{target} 之间的依赖性有关, m_i 的估算数学描述为

$$m_i = \frac{I(x_i; y_{\text{target}})}{\sqrt{H(x_i)H(y_{\text{target}})}}. \quad (16)$$

因此, 储层中第 i 个神经元在动态储层中的贡献为

$$c_i = \frac{m_i}{N}, \quad N > 0, \quad (17)$$

$$\sum_{i=1}^N m_i$$

其中 N 表示储层神经元的个数. 根据 c_i 并不能确定整个网络结构最优的节点数, 所以引入强化学习对储层神经元再次筛选, 使其寻找最优网络结构.

2.3 基于强化学习的结构优化

强化学习强调模型在与环境相互作用的过程中通过试错得到最优决策, 进而得到最优结构. 强化学习模型一般由学习主体、环境、动作、状态和奖励 5 个主要部分组成, 其运行可以描述为状态 (S)、动作 (A) 和奖励 (R) 的循环. 本文采用 Q -learning 算法. 设 $S = \{s_1, s_2, \dots, s_m\}$ 是环境状态的集合, $A = \{a_1, a_2, \dots, a_m\}$ 是可执行的动作集. 在每次迭代中, 给代理一个状态并要求选择一个要执行的动作, 代理可以根据累积的价值表 Q -table 执行一个最优的动作, 在执行的动作发生后, 环境给出一个奖励 r_{t+1} 和一个新的状态 S_{t+1} , 获得的信息被智能体学习并形成对应的价值表 $Q(s_t, a_t)$, 以实现每个状态-动作的评估. 价值表 $Q(s_t, a_t)$ 的更新方程为

$$Q_{s_t, a_t}^{t+1} = Q(s_t, a_t) + \alpha[r_t + \gamma \max_a Q(s_{t+1}, a_t) - Q(s_t, a_t)]. \quad (18)$$

其中: r 为环境返回的奖惩值, 学习率 α 和折现因子 γ 值选择在 $[0, 1]$ 范围内.

2.4 SC-ESN 算法流程

ESN 的储层结构影响网络性能. 对于单个 ESN 而言: 储层结构过小, 网络信息处理能力受限; 储层结

构过大, 处理信息不能有效利用资源, 导致泛化能力不佳. 本文所提出的 SC-ESN 模型优化算法具体步骤如下:

$$X_n = \begin{bmatrix} x_1(1) & x_1(2) & \dots & x_1(N_s) \\ x_2(1) & x_2(2) & \dots & x_2(N_s) \\ \vdots & \vdots & \ddots & \vdots \\ x_N(1) & x_N(2) & \dots & x_N(N_s) \\ \vdots & \vdots & \ddots & \vdots \\ x_{nN}(1) & x_{nN}(2) & \dots & x_{nN}(N_s) \end{bmatrix}. \quad (19)$$

step 1: 创建 n 个原始 ESN 网络, 初始化网络参数 (W_{in}, W), 给出 K, N, L .

step 2: 利用训练数据驱动储层, 并根据式 (1) 和 (2) 更新储层, 整合储层状态矩阵并记为 X_n . 如式 (19), n 为网络集成的个数, N_s 为训练样本的长度. 将训练时的期望目标输出向量 y_{target} 收集到目标矩阵 Y_{target} 中.

step 3: 根据式 (9) ~ (17) 计算储层中每个神经元的贡献值并进行排序, 随机选择储层中 p 个神经元节点 ($p = [N, 1.5N]$), 得到优化后 ESN 的新状态矩阵

$$X_{c1} = [x_1, x_2, \dots, x_{N_p}], \quad (20)$$

其中 N_p 为所选贡献值较高的储层神经元个数.

step 4: 通过式 (4) 计算得到 W_{out} . 训练误差 $E(X_{c1})$ 按下式计算:

$$E(X_{c1}) = \frac{1}{N} \sum_{i=1}^{N_s} |y(i) - \hat{y}_{c1}(i)|. \quad (21)$$

其中: $y(i)$ 是训练集中的实测数据, $\hat{y}_{c1}(i)$ 是初次网络结构优化的实际输出. 若 $E(X_{c1})$ 小于 $E_m(X)$, 则执行 step 5, 进行神经元二次筛选; 反之, 执行 step 3, 继续进行神经元初次筛选. $E_m(X)$ 为 n 个原始 ESN 网络训练误差的平均值.

step 5: 构造强化学习的状态矩阵 S 、动作矩阵 a . 状态矩阵为 X_{c1} , 动作矩阵如下式所示:

$$a = \begin{cases} -1, & \text{不激活神经元;} \\ 0 \text{ 或 } 1, & \text{激活神经元.} \end{cases} \quad (22)$$

step 6: 构造决策函数 L 、奖励函数 R 、评价函数 Q . 有

$$L = \frac{1}{N_s} \sum_{i=1}^{N_s} |y(i) - \hat{y}_{c2}(i)| - E_m(X). \quad (23)$$

$$R = \begin{cases} 1, & L_{m+1} < L_m; \\ -1, & L_{m+1} > L_m. \end{cases} \quad (24)$$

$$Q_{m+1}(S_m, a_m) =$$

$$Q_m(S_m, a_m) + \gamma_m(R(S_m, a_m) + \lambda \max Q_m(S_{m+1}, a_{m+1}) - Q_m(S_m, a_m)). \quad (25)$$

其中: $y(i)$ 是训练集中的实测数据, $\hat{y}_{c2}(i)$ 是二次网络结构优化的实际输出, γ 是折扣率, λ 是学习率.

step 7: 根据当前状态 S , 代理执行动作 a . 根据如下 ϵ -greedy 策略^[24] 选择动作:

$$a_m = \begin{cases} \text{action based max} Q, & 1 - \epsilon; \\ \text{random action}, & \epsilon. \end{cases} \quad (26)$$

其中 $\epsilon \in (0, 1)$ 为探索概率.

step 8: 计算决策函数 L , 得到奖励 R , 计算评价函数 Q , 更新 Q -table 值.

step 9: 当条件满足时, 迭代停止, 状态矩阵 S 是目前最优的储层节点状态矩阵; 否则, 重复 step 7、step 8.

step 10: 将测试集输入具有最优节点数的神经网络模型中, 得到预测结果.

3 仿真实验

实验中每个任务的数据集都被划分为训练集和测试集, 训练集和测试集的长度分别为 L_{train} 、 L_{test} . 初始瞬态过程的长度为 L_{washout} , 用于减小初始状态的影响. 本文仿真实验均通过 20 次重复实验取平均值, 所有的数据输入都归一化到范围 $[-1, 1]$ 中, 所有实验都是在 2020 版 Matlab 中进行. 实验采用均方根误差 (RMSE) 来检验实验模型的性能, 有

$$\text{RMSE} = \sqrt{\frac{1}{N_s} \sum_{n=1}^{N_s} (y(n) - \hat{y}(n))^2}. \quad (27)$$

其中: $y(n)$ 表示期望输出, $\hat{y}(n)$ 表示预测输出, N_s 表示数据长度. RMSE 的值越小, 表明优化后网络模型的性能越好.

3.1 人工数据集实验

任务 1 Mackey-Glass (MG) 是作为时间序列预测的基准数据集, 其具有混沌吸引子, 用于评估预测任务的各种模型. MG 序列由下面的微分方程产生:

$$\frac{d(x)}{d(t)} = \frac{ax(t - \tau)}{1 + x^c(t - \tau)} - bx(t). \quad (28)$$

其中: $a = 0.2, b = 0.1, c = 10$. 式 (28) 的因子一旦固定, 就会产生一个具有相应混沌程度的系统, 并且在混沌系统中 τ 越大, 吸引子的维数越大. 如果 $\tau > 16.8$, 则系统属于混沌状态, 本次实验取 $\tau = 17$, $L_{\text{train}} = 2000, L_{\text{test}} = 800, L_{\text{washout}} = 100$, 谱半径

$= 0.9$, 稀疏度 $= 0.01$.

任务 2 Lorenz 时间序列是检验 ESN 最常用的数据集, 其动力系统方程描述如下:

$$a = \begin{cases} \frac{d(x)}{d(t)} = a(y - x), \\ \frac{d(y)}{d(t)} = -xz + b(x - y), \\ \frac{d(z)}{d(t)} = xy - cz. \end{cases} \quad (29)$$

其中: 参数 $a = 10, b = 28, c = 8/3$. 引入步长为 0.01 的四阶 Runge-Kutta 方法生成 2800 个样本数据集, 同时, 为了增加实验的可靠性, 在生成的样本数据集中加入高斯噪声, 均值为 0, 方差为 0.01. 混沌系统的初始值 $x(0) = 12, y(0) = 2, z(0) = 9$, 利用 y 维样本进行时间序列预测. $L_{\text{train}} = 2000, L_{\text{test}} = 800, L_{\text{washout}} = 100$, 谱半径 $= 0.9$, 稀疏度 $= 0.01$.

3.2 优化模型的有效性

基于 MG 和 Lorenz 人工数据集的实验结果如表 1 和表 2 所示. 由表 1 和表 2 可知, 对单个储层结构进行优化, 当储层结构为 200 时, 针对两种不同的数据, 最多剔除 5% 的神经元. 其原因是, 单个储层由于信息量少, 虽然神经元之间冗余信息较少, 但各个神经元之间存在耦合效应, 使得神经元之间依赖性很强, 导致过拟合现象. 当增加储层集成的个数, 增加筛选的特征维度, 扩大筛选的多样性时, SC-ESN 能剔除大量的冗余神经元, 减小神经元间的依赖性. 针对 MG 和 Lorenz 数据集, 强化学习筛选过程能剔除 80% 以上的无效神经元, 说明多个网络中的神经元存在多

表 1 基于 SC-ESN 的不同储层尺寸的预测 (MG)

储层尺寸	预测误差 (RMSE)		优化后储层尺寸 (差值)
	平均值	标准差	
50 × 1	8.639 e-4	5.580 e-4	49 (1)
100 × 1	6.754 e-4	3.585 e-4	98 (2)
200 × 1	4.535 e-4	3.181 e-4	190 (10)
50 × 2	6.111 e-4	5.323 e-4	54 (46)
100 × 2	2.900 e-4	2.316 e-4	59 (141)
200 × 2	1.239 e-4	1.454 e-4	111 (289)
50 × 3	3.889 e-4	3.141 e-4	30 (120)
100 × 3	2.173 e-4	1.672 e-4	48 (252)
200 × 3	1.096 e-4	0.911 e-4	101 (499)
50 × 4	3.752 e-4	2.376 e-4	28 (172)
100 × 4	1.518 e-4	1.237 e-4	52 (348)
200 × 4	1.058 e-4	0.925 e-4	99 (701)
50 × 5	3.895 e-4	2.614 e-4	25 (225)
100 × 5	2.141 e-4	1.660 e-4	49 (451)
200 × 5	1.034 e-4	0.861 e-4	97 (903)

表2 基于SC-ESN的不同储层尺寸的预测(Lorenz)

储层尺寸	预测误差(RMSE)		优化后储层尺寸(差值)
	平均值	标准差	
50 × 1	6.980 e-4	4.809 e-4	50(0)
100 × 1	2.344 e-4	2.648 e-4	99(1)
200 × 1	1.408 e-4	1.754 e-4	193(7)
50 × 2	6.064 e-4	9.081 e-4	48(2)
100 × 2	1.087 e-4	1.535 e-4	95(105)
200 × 2	1.320 e-4	3.087 e-4	199(201)
50 × 3	4.214 e-4	4.379 e-4	55(95)
100 × 3	1.321 e-4	2.131 e-4	58(242)
200 × 3	0.911 e-4	0.494 e-4	186(414)
50 × 4	5.585 e-4	5.430 e-4	48(152)
100 × 4	1.9208 e-4	2.838 e-4	45(355)
200 × 4	0.484 e-4	0.451 e-4	179(621)
50 × 5	0.328 e-4	8.227 e-4	27(223)
100 × 5	1.685 e-4	2.319 e-4	59(441)
200 × 5	0.323 e-4	0.451 e-4	176(824)

重共线性,即解释变量间存在高度相关,当带有噪音的数据输入时,将会极大影响预测性能. 本文提出的SC-ESN算法能筛选出对储层贡献度高的神经元,可以降低状态矩阵中存在的数据冗余,不仅提高了预测的精度,还能使网络结构得到简化.

根据不同任务测试误差分析,在具有相同的集成个数不同的储层尺寸下,MG数据集在储层尺寸为200的预测误差RMSE比储层尺寸为50的RMSE降低了47%~79%,Lorenz数据集在储层尺寸为200的预测误差比储层尺寸为50的RMSE降低了2%~91%. 而在具有相同的单个储层尺寸不同的集成个数下,单个储层尺寸为50、100和200时,MG数据集的RMSE依次降低了56%、77%和77%,Lorenz数据集的RMSE依次降低了95%、53%和77%. 以上说明SC-ESN极大地提高了网络预测性能,其原因是,SC-ESN的多储层筛选有助于对未知信息特征的识别,并非单储层ESN存在预测不稳定问题,所以采用集成学习的思想,既增强了预测模型的稳定性,又提高了网络预测性能.

3.3 模型性能分析

本实验以初始储层神经元尺寸100×3为例,将集结的全部储层神经元作为初筛环境,训练结束后MG的储层尺寸为48,Lorenz的储层尺寸为58. 图2和图3给出了MG数据集下的SC-ESN输出预测和误差,图4和图5为Lorenz数据集下的SC-ESN输出预测和误差. 显然,图2和图4预测输出能很好地拟合原始数

据,图3和图5两者的SC-ESN测试误差比储层尺寸为100的误差低. 实验结果表明,该优化模型在网络结构最简的前提下达到了非常好的预测效果.

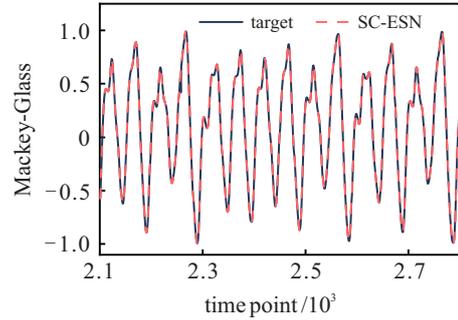


图2 基于MG的SC-ESN预测曲线

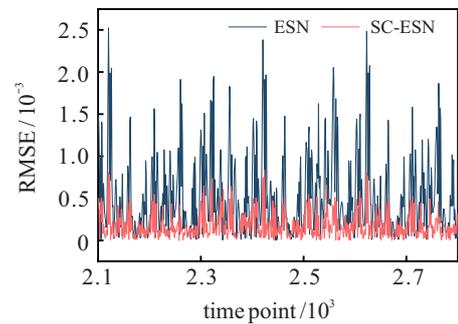


图3 ESN(N × 3)和SC-ESN的预测误差(MG)

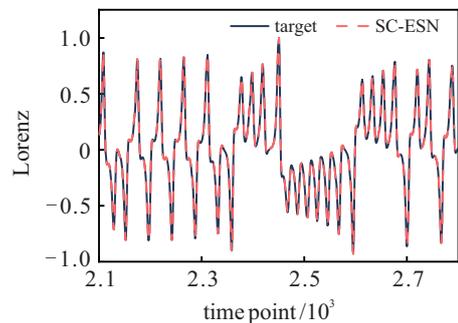


图4 基于Lorenz的SC-ESN预测曲线

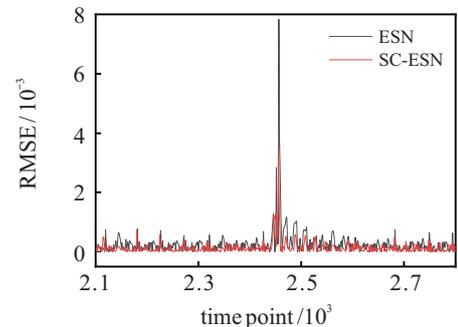


图5 ESN(N × 3)和SC-ESN的预测误差(Lorenz)

3.4 预测模型性能对比

为进一步验证SC-ESN模型的性能,本文分别在Mackey-Glass(MG)和Lorenz混沌时间序列下,将SC-ESN与传统ESN^[19]、深度ESN(3层,每层尺寸100)^[25]、无逆ESN(inverse-free ESN, IFESN)^[26]、具

有多个子储层的不断增长的ESN (GESN)^[14]、粒子群优化 GESN (particle swarm optimization GESN, PSO-GESN)^[27]、模块化回声状态网络剪枝算法 (pruning algorithm for modular echo state network, PMESN)^[15]和增量式正则化 ESN (incremental regularized ESN, IRESN)^[28]进行对比实验. 在算法模型对比中使用均方根误差 (RMSE) 和优化后网络结构大小进行衡量, 如表3和表4所示.

表3 不同模型MG时间序列预测结果比较

网络模型	预测误差 (RMSE)	储层尺寸	
		初始	结束
ESN	6.215 e-4	300	300
DeepESN	5.853 e-4	100	300
IFESN	4.958 e-4	2	383
GESN	3.521 e-4	50	300
PSO-ESN	3.081 e-4	50	300
PMESN	2.904 e-4	50	164
IRSN	2.727 e-4	300	148
SC-ESN	2.173 e-4	100×3	48

表4 不同模型Lorenz时间序列预测结果比较

网络模型	预测误差 (RMSE)	储层尺寸	
		初始	结束
ESN	4.177 e-4	300	300
DeepESN	4.019 e-4	100	300
IFESN	3.702 e-4	2	87
GESN	1.789 e-4	50	300
PSO-ESN	1.590 e-4	50	300
PMESN	1.588 e-4	50	196
IRSN	1.362 e-4	300	165
SC-ESN	1.321 e-4	100×3	58

从表3和表4可以看出, SC-ESN在MG和Lorenz数据集上使用最少神经元的前提下, 预测误差RMSE均比其他预测模型低. 就MG数据而言: SC-ESN仅需48个神经元, 仅占整个储层的16%, 其预测误差RMSE比传统ESN提高了65%, 相对于最优预测模型IRESN提高了20%; 而Lorenz数据集, SC-ESN仅需58个神经元, 仅占整个储层的20%, 其预测误差RMSE比传统ESN提高了68%, 相对于结构最简化的IFESN提高了64%, 相对于最优预测模型IRESN提高了3%, 说明SC-ESN能提高网络的性能, 并且表明储层可以根据不同任务需求进行相应的结构优化.

3.5 实际数据集PM2.5的预测

PM2.5体积小, 可以在空气中悬浮很长时间, 当人呼吸时被血液深层吸收, 因此它对人类健康构成

威胁. PM2.5浓度的合理预测是环境卫生研究的基本问题之一, 它在保护自然环境和人类健康发展方面起着至关重要的作用. 本实验数据来源为某气象局2019年1月1日~2019年12月30日记录的北京每一小时的PM2.5的值, 其中取3500个样本点进行实验, $L_{train} = 2500$, $L_{test} = 1000$, $L_{washout} = 100$, 谱半径 = 0.9, 稀疏度 = 0.01.

本实验初始储层神经元尺寸设置为 3×100 , 训练结束后储层的尺寸为59. 图6为PM2.5数据下原ESN的储层神经元和SC-ESN储层神经元的贡献度分布情况, 从中可以看出, 原ESN内储层神经元对原ESN的贡献不同, 每个原ESN的储层对SC-ESN预测做的贡献不同, 且每个原ESN贡献的储层神经元个数也不同, 表明在设计 and 训练神经网络时, 选择合适的神经元是非常重要的, 并且能对网络性能产生巨大的影响. 预测结果如图7和图8所示.

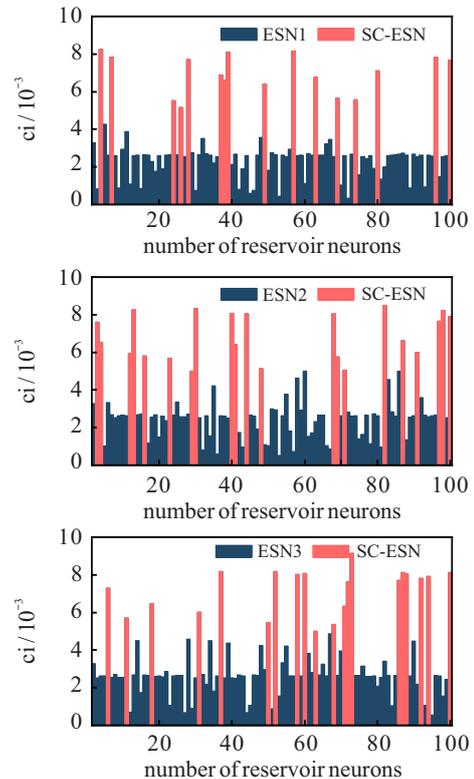


图6 基于ESN和SC-ESN的神经元贡献(PM2.5)

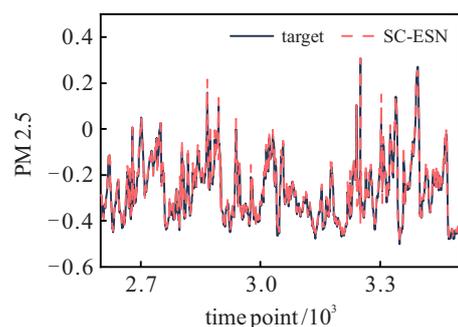


图7 基于PM2.5的SC-ESN预测曲线

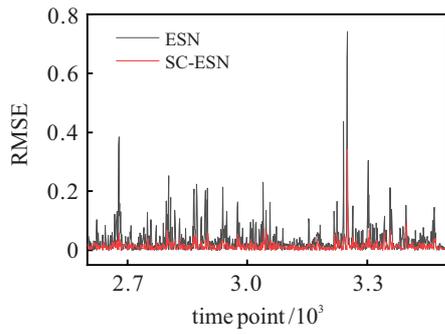


图8 ESN($N \times 3$)和SC-ESN的预测误差(PM 2.5)

由图7和图8可以看出,本文提出的SC-ESN模型对PM2.5数据依然具有很高的拟合度,并能预测PM2.5的走势,同时预测误差小,从而表明本模型的预测性能较佳。

为了进一步验证SC-ESN的性能,在PM2.5数据集中,SC-ESN对不同储层尺寸下ESN优化结果如表5所示。从实验结果可以看出,储层的最终尺寸都不同程度地减小,当只有单个储层进行优化时,储层的冗余神经元极少,几乎不能对储层的神经元进行剔除。而随着集成个数的增加,能删除高达80%的储

表5 基于SC-ESN的不同储层尺寸的预测(PM 2.5)

储层尺寸	预测误差(RMSE)		优化后储层尺寸(差值)
	平均值	标准差	
100 × 1	0.0601	0.1022	99(1)
200 × 1	0.0524	0.0596	198(2)
100 × 2	0.0448	0.0519	90(110)
200 × 2	0.0365	0.0609	190(210)
100 × 3	0.0340	0.0511	59(241)
200 × 3	0.0264	0.0554	150(450)
100 × 4	0.0319	0.0530	64(336)
200 × 4	0.0247	0.0542	143(657)
100 × 5	0.0301	0.0529	68(432)
200 × 5	0.0203	0.0509	139(861)

表6 不同模型PM 2.5时间序列预测结果比较

网络模型	预测误差(RMSE)	储层尺寸	
		初始	结束
ESN	0.0631	300	300
DeepESN	0.0527	100	300
IFESN	0.0349	2	120
GESN	0.0454	50	300
PSO-ESN	0.0401	50	300
PMESN	0.0397	50	187
IRESN	0.0372	300	158
SC-ESN	0.0340	100×3	58

层神经元,将剩余携带有用信息的神经元进行预测,预测性能得到提高。与不同的预测模型进行对比,如表6所示,SC-ESN仅需59个神经元,仅占整个储层的20%,其预测误差RMSE比传统ESN提高了46%,相对于结构最简化和最优预测模型IFESN提高了2%,说明SC-ESN能在最简化的网络结构下具有较好的预测性能。

4 结论

本文针对回声状态网络储层计算的状态矩阵存在大量冗余信息的问题,提出了基于强化学习的回声状态网络结构优化模型(SC-ESN),通过衡量贡献度并使用强化学习进行选择,筛选出对输出实际有效的储层神经元,解决了冗余信息对网络预测的干扰问题。此外,本文还采用了集成学习的思想,使得模型在筛选过程中能够准确地提取出多个储层池中对网络输出有贡献的神经元的有效信息,从而选择出合适的神经元,进一步优化了网络结构,提高了网络预测性能。对Mackey-Glass、Lorenz和PM2.5三组数据进行了仿真实验,初始条件以 100×3 为例,结果显示本文提出的算法模型不仅将储层的神经元控制在20%以内,而且取得了更好的预测结果。与其他优化方法相比,本文SC-ESN模型在得到最小储层结构的同时,网络性能也得到了极大的提升和优化。

参考文献(References)

- [1] Jaeger H. The “echo state” approach to analysing and training recurrent neural networks-with an erratum note[J]. German National Research Center for Information Technology GMD Technical Report, 2001, 148(34): 13.
- [2] Yang C L, Nie K Z, Qiao J F, et al. Robust echo state network with sparse online learning[J]. Information Sciences, 2022, 594: 95-117.
- [3] 韩敏, 穆大芸. 基于贝叶斯回归的多核回声状态网络研究[J]. 控制与决策, 2010, 25(4): 531-534. (Han M, Mu D Y. Research on multi-reservoir ESN based on Bayesian regression[J]. Control and Decision, 2010, 25(4): 531-534.)
- [4] Gao R B, Li R L, Hu M H, et al. Dynamic ensemble deep echo state network for significant wave height forecasting[J]. Applied Energy, 2023, 329: 120261.
- [5] Ding L, Bai Y L, Fan M H, et al. Serial-parallel dynamic echo state network: A hybrid dynamic model based on a chaotic coyote optimization algorithm for wind speed prediction[J]. Expert Systems with Applications, 2023, 212: 118789.
- [6] Wang L, Su Z, Qiao J F, et al. A pseudo-inverse decomposition-based self-organizing modular echo state network for time series prediction[J]. Applied Soft

- Computing, 2022, 116: 108317.
- [7] 张昭昭, 朱应钦, 乔俊飞, 等. 一种基于行为空间的回声状态网络参数优化方法[J]. 信息与控制, 2021, 50(5): 556-565.
(Zhang Z Z, Zhu Y Q, Qiao J F, et al. An echo state network parameter optimization method based on behavior space[J]. Information and Control, 2021, 50(5): 556-565.)
- [8] 许美玲, 王依雯. 基于改进差分进化和回声状态网络的时间序列预测研究[J]. 自动化学报, 2021, 47(7): 1589-1597.
(Xu M L, Wang Y W. Time series prediction based on improved differential evolution and echo state network[J]. Acta Automatica Sinica, 2021, 47(7): 1589-1597.)
- [9] 王磊, 乔俊飞, 李晓理. 一种回声状态网络的权值初始化方法[J]. 控制与决策, 2018, 33(2): 356-360.
(Wang L, Qiao J F, Li X L. A weight initialization method for echo state network[J]. Control and Decision, 2018, 33(2): 356-360.)
- [10] Zhang Z Z, Zhu Y Q, Wang X H, et al. Optimal echo state network parameters based on behavioural spaces[J]. Neurocomputing, 2022, 503: 299-313.
- [11] Rodan A, Tino P. Minimum complexity echo state network[J]. IEEE Transactions on Neural Networks, 2011, 22(1): 131-144.
- [12] Cui H Y, Liu X, Li L X. The architecture of dynamic reservoir in the echo state network[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2012, 22(3): 1-10.
- [13] Qiao J F, Li F J, Han H G, et al. Growing echo-state network with multiple subreservoirs[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(2): 391-404.
- [14] Wang H S, Yan X F. Improved simple deterministically constructed cycle reservoir network with sensitive iterative pruning algorithm[J]. Neurocomputing, 2014, 145: 353-362.
- [15] 王磊, 乔俊飞, 杨翠丽, 等. 基于灵敏度分析的模块化回声状态网络修剪算法[J]. 自动化学报, 2019, 45(6): 1136-1145.
(Wang L, Qiao J F, Yang C L, et al. Pruning algorithm for modular echo state network based on sensitivity analysis[J]. Acta Automatica Sinica, 2019, 45(6): 1136-1145.)
- [16] Ozturk Mustafa C, Xu D M, Príncipe José C. Analysis and design of echo state networks[J]. Neural Computation, 2007, 19(1): 111-138.
- [17] Li D, Liu F, Qiao J, et al. Structure optimization for echo state network based on contribution[J]. Tsinghua Science and Technology, 2018, 24(1): 97-105.
- [18] Liu C, Zoph B, Neumann M, et al. Progressive neural architecture search[C]. Proceedings of the European Conference on Computer Vision (ECCV). Munich, 2018: 19-34.
- [19] Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.
- [20] Meyer-Bäse A, Moradi Amani A, Meyer-Bäse U, et al. Pinning observability of competitive neural networks with different time-constants[J]. Neurocomputing, 2019, 329: 97-102.
- [21] Kobialka H U, Kayani U. Echo state networks with sparse output connections[C]. Artificial Neural Networks — ICANN 2010: The 20th International Conference. Thessaloniki, 2010: 356-361.
- [22] Kraskov A, Stögbauer H, Grassberger P. Estimating mutual information[J]. Physical Review E: Statistical, Nonlinear, and Soft Matter Physics, 2004, 69(6): 138-151.
- [23] Chen Y C. A tutorial on kernel density estimation and recent advances[J/OL]. 2017, arXiv: 1704.03924.
- [24] Liu H, Yu C M, Yu C Q, et al. A novel axle temperature forecasting method based on decomposition, reinforcement learning optimization and neural network[J]. Advanced Engineering Informatics, 2020, 44: 101089.
- [25] Gallicchio C, Micheli A, Pedrelli L. Design of deep echo state networks[J]. Neural Networks, 2018, 108: 33-47.
- [26] Chen X F, Luo X, Jin L, et al. Growing echo state network with an inverse-free weight update strategy[J]. IEEE Transactions on Cybernetics, 2023, 53(2): 753-764.
- [27] Li Y, Li F J. PSO-based growing echo state network[J]. Applied Soft Computing, 2019, 85: 105774.
- [28] 王磊, 苏中, 乔俊飞, 等. 基于增量式学习的正则化回声状态网络[J]. 控制与决策, 2022, 37(3): 661-668.
(Wang L, Su Z, Qiao J F, et al. Design of incremental regularized echo state network[J]. Control and Decision, 2022, 37(3): 661-668.)

作者简介

郭伟(1977—), 女, 副教授, 硕士, 从事智能信息处理、神经网络结构设计等研究, E-mail: 412764666@qq.com;

姚欢(1998—), 女, 硕士生, 从事神经网络结构设计的研究, E-mail: 2565986657@qq.com;

张昭昭(1973—), 男, 副教授, 博士, 从事智能信息处理、神经网络结构优化设计等研究, E-mail: zzzhao123@126.com;

朱应钦(1997—), 男, 博士生, 从事池网络结构优化设计的研究, E-mail: yzhu@ctrl.cinvestav.mx.