

基于改进粒子群算法优化回声状态网络的时间序列预测

张亚楠, 赵丽娜

长安大学理学院, 陕西 西安
Email: 3086057318@qq.com, 2304613460@qq.com

收稿日期: 2021年7月2日; 录用日期: 2021年7月30日; 发布日期: 2021年8月6日

摘要

由于结构简单、收敛速度快等优点, 回声状态网络(Echo State Network, ESN)已被广泛的用于时间序列的预测。针对回声状态网络中随机生成权值矩阵带来的不适用于特定时间序列的问题, 本文提出利用改进的粒子群优化算法来优化回声状态网络部分随机权值。与标准粒子群优化算法相比, 惯性权重和学习因子自适应调整, 以提高算法的寻优性能。为验证本文方法的有效性, 对Mackey-Glass时间序列、非线性自回归滑动模型(Nonlinear Auto Regressive Moving Average, NARMA)和Lorenz时间序列进行仿真实验。实验结果表明, 本文提出的方法可以进一步提升回声状态网络对时间序列的预测精度。

关键词

时间序列预测, 回声状态网络, 粒子群优化算法

Time Series Forecasting Based on Echo State Network Optimized by Improved Particle Swarm Algorithm

Yanan Zhang, Lina Zhao

School of Science, Chang'an University, Xi'an Shaanxi
Email: 3086057318@qq.com, 2304613460@qq.com

Received: Jul. 2nd, 2021; accepted: Jul. 30th, 2021; published: Aug. 6th, 2021

Abstract

Echo State Network (ESN) has been widely used in time series prediction due to its simple struc-

ture and fast convergence speed. In order to solve the problem that random weight matrix generated in ESN is not applicable to specific time series, an improved particle swarm optimization (PSO) algorithm is proposed to optimize partial random weights in ESN. Compared with the standard particle swarm optimization algorithm, the inertia weight and learning factor are adjusted to improve the optimization performance of the algorithm. To verify the effectiveness of the proposed method, the Mackey-Glass time series, the nonlinear autoregressive sliding model (NARMA) and the Lorenz time series are simulated. Experimental results show that the method proposed in this paper can further improve the prediction accuracy of ESN for time series.

Keywords

Time Series Prediction, ESN, Particle Swarm Optimization Algorithm

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

时间序列预测就是通过分析时间序列, 根据历史数据的发展过程、方向和趋势对未来进行预测。时间序列预测在人类生活的各个领域都有着广泛的应用, 如生物学领域的基因表达谱[1]、金融领域的股票价格[2]、社会领域的城市交通流量[3]、工业领域风能评估[4]和气候领域的温度变化预测[5]等。然而, 实际中的时间序列往往表现出复杂的特性, 如非平稳、随机性、高维性、非线性和非周期性等, 时间序列的预测研究仍然面临着巨大的挑战。

对于时间序列数据的预测方法, 主要有线性方法和非线性方法。其中, 线性方法主要有: 自回归[6]、自回归滑动平均[7]、自回归综合滑动平均[8]等, 这些线性方法适合持续时间较长、变化较为缓慢的时间序列的预测。非线性方法主要有: 支持向量机[9]、最小二乘支持向量机[10]、人工神经网络[11]等。随着网络规模和复杂程度的不断提高, 非线性方法可以很好地处理时间序列的非平稳、随机性、高维性、非线性和非周期性等问题。虽然非线性方法能够很好的处理复杂时间序列, 但是也存在一些局限性, 例如支持向量机和最小二乘支持向量机当训练样本过大时, 会存在运行时间过长且效果不佳的问题。前向神经网络存在训练算法复杂, 网络结构难以确定, 网络计算量较大的问题[9]。回声状态网络预测方法(ESN)[12]作为一种基于储备池计算的神经网络, 只需采用一个大规模的稀疏连接的储备池即可保证模型对非线性数据的处理能力。因其训练过程简单, 计算量小, ESN 已被广泛用于时间序列的应用中[12][13][14][15][16]。然而, ESN 输入连接权值、储备池内部连接权值和反馈连接权值的随机性赋值, 使得模型性能不确定、收敛速度慢, 无法满足时间序列准确有效的预测需求[17][18][19]。

粒子群优化算法(PSO)作为一种元启发式算法, 由于简单容易实现、搜索能力强, 已被广泛应用于神经网络结构的优化[20], 电力[21], 工业[22]等领域。文献[15]中, 作者利用标准粒子群算法对回声状态网络中部分随机权值进行优化, 提升了网络的预测性能。然而, 标准 PSO 存在易陷入局部极小值和全局搜索能力不足等问题。为了克服标准 PSO 算法的这些缺点, 本文采用改进的粒子群算法(IPSO)对回声状态网络输入连接权值、储备池连接权值和反馈连接权值进行优化。试验结果表明该方法有效地减少了随机生成权值矩阵带来的不适用于特定任务的局限性, 进一步提高 ESN 的预测性能。

2. 回声状态网络

ESN 基本原理

回声状态网络(ESN)由 Jaeger 和 Haas 教授于 2001 提出, 它是由输入层、储备池和输出层组成的简单三层递归神经网络(如图 1 所示)。 $\mathbf{u}(t)$, $\mathbf{x}(t)$, $\mathbf{y}(t)$ 分别表示 t 时刻的输入单元、储备池内部的神经元状态以及输出单元。 \mathbf{W}^{in} , \mathbf{W} , \mathbf{W}^{out} 和 \mathbf{W}^{back} 分别代表网络的输入层到储备池、储备池内部的神经元、输入层到输出层、储备池到输出层和输出层到储备池之间的连接权值矩阵。当 \mathbf{W}^{back} 存在时, ESN 可以进行多步预测; 否则, 它只能进行单步预测。在 ESN 中, 通过随机初始化产生输入层到储备池、储备池的内部及输出层到储备池的连接权值, 且在训练过程中保持不变。因此, ESN 只需要训练储备池到输出层的连接权值。大规模的储备池来代替全连接的隐藏层, 增强了复杂时间序列的建模能力。只需要训练储备池到输出层的连接权值可避免传统神经网络基于梯度下降原理的收敛速度缓慢, 且在寻找最优解的时候可能会陷入局部最优的问题。




Figure 1. Standard structure of ESN
图 1. 回声状态网络的标准结构

在 ESN 中, 当信号 $\mathbf{u}(t+1)$ 输入到网络时, 储备池内部神经元状态和网络输出的更新规则如下:

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

其中 f 和 f^{out} 分别表示储备池和输出单元的激活函数, f 一般为双曲正切函数 \tanh , f^{out} 一般为恒等函数。

当 f^{out} 为恒等函数时, 模型输出 $\mathbf{y}(t)$ 可简单地表示为:

$$\mathbf{y}(t) = \mathbf{W}^{\text{out}}\mathbf{x}(t). \quad (2)$$

在模型训练过程中, 希望得到的 \mathbf{W}^{out} 能够使模型的输出 $\mathbf{y}(t)$ 与目标值 $\hat{\mathbf{y}}(t)$ 间的误差最小, 即需要求解如下的优化问题:

$$\mathbf{W}^{\text{out}} = \arg \min_{\mathbf{W}^{\text{out}}} \sum_{t=1}^k \|\hat{\mathbf{y}}(t) - \mathbf{W}^{\text{out}}\mathbf{x}(t)\|_2^2. \quad (3)$$

其中 k 为训练的样本数。

3. 基于粒子群算法优化的回声状态网络

在回声状态网络的学习过程中, 仅调节储备池到输出层之间的连接权值, 而其他连接权值被随机赋

值后保持不变。如果这些被随机赋值的连接权值设置不合适,那么也会直接影响 ESN 的预测性能。因此,文献[15]利用标准粒子群算法(PSO)对回声状态网络中部分随机权值进行优化,进而提高 ESN 的预测性能。虽然标准粒子群算法寻优速度较快、效率高、算法简单,但也存在自身的缺陷。因此,本文将尝试引入自适应调整的惯性权重和动态学习因子对标准的粒子群算法进行改进,进而应用改进的粒子群算法(IPSO)对 ESN 的部分随机连接权值进行优化,进一步提升 ESN 的预测精度。

3.1. 标准粒子群算法

粒子群优化算法是美国心理学家 Kennedy 和电气工程师 Eberhart 受鸟类觅食行为的启发,于 1995 年提出了粒子群优化算法。PSO 是一种基于群体智能的全局随机寻优算法,它模仿鸟类的觅食行为,将问题的搜索空间类比于鸟类的飞行空间,将每只鸟抽象成为一个粒子,用以表征问题的一个候选解,所需要寻找的最优解等同于要寻找的食物。算法为每个粒子给定位置和速度,每个粒子通过更新速度来更新其自身的位置。通过迭代搜索,种群可以不断地找到更好的粒子位置,从而得到优化问题的较优解。

粒子群优化算法的原理:在维度为 D 的解空间中有 n 个飞行粒子,每个飞行粒子的状态可用位置向量和飞行速度向量进行描述。假设向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 为飞行粒子 i 当前的位置,向量 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{id})$ 为飞行粒子 i 当前的飞行速度,其中 $1 \leq i \leq n$, $1 \leq d \leq D$ 。定义适应度函数,计算每一个飞行粒子的适应度值,根据适应度值大小选取飞行粒子个体当前的最优位置 $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{id})$ 。同时进行信息共享,筛选出整个种群当前的最优位置 $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 。当算法开始运行时,对飞行粒子的位置和飞行速度进行初始设置,利用以下公式对飞行粒子状态进行更新:

$$\begin{aligned} V_{id}(t+1) &= wV_{id}(t) + c_1r_1(P_{id}(t) - X_{id}(t)) + c_2r_2(P_{gd}(t) - X_{id}(t)), \\ X_{id}(t+1) &= X_{id}(t) + V_{id}(t+1), \end{aligned} \quad (4)$$

其中常数 w 为惯性权重,其大小对算法的全局搜索能力和局部搜索能力有较大的影响;常数 c_1 和 c_2 分别为认知因子和社会因子,分别表示粒子对自身和整个群体的认知; r_1 和 r_2 为 $[0,1]$ 之间的随机数。

3.2. 惯性权重的改进

在标准的 PSO 中,惯性权重 w 的取值对粒子的速度大小有着很大的影响。 w 取值较大时,虽然粒子全局搜索能力强,但是收敛能力变差。 w 取值较小时,容易导致局部搜索能力变小,最终陷入局部最优。因此,本文将采取(5)式的非线性变化权重进一步提升 PSO 的搜索性能。

$$w = w_{\min} + (w_{\max} - w_{\min}) \times e^{-\frac{t}{t_{\max}}}. \quad (5)$$

其中 w_{\max} 和 w_{\min} 为最大和最小的惯性权重, t_{\max} 为最大迭代次数, t 为当前迭代次数。当 t 较小时, w 接近 w_{\max} 且 w 的减少速度也比较慢,这保证了算法的全局寻优能力;随着 t 的增大, w 非线性递减,并且随 w 的减少速度迅速增加,保证了算法的局部寻优能力。从而使算法灵活的调整全局寻优能力和局部寻优能力。

3.3. 学习因子 c_1 和 c_2 的改进

在标准的 PSO 中,学习因子 c_1 和 c_2 设置为固定的常数。因此,在整个迭代的过程中粒子受到个体信息和群体信息的影响是不变的。因此,在后期搜索阶段粒子的位置缺乏多样性,容易陷入局部最优和收敛速度慢等问题。因此引入了动态学习因子的方法[21],改进的 c_1 和 c_2 如下:

$$\begin{aligned} c_1(t) &= 1 - \ln 2 \cdot \left(\frac{t}{t_{\max}} \right), \\ c_2(t) &= 1 + \ln 2 \cdot \left(\frac{t}{t_{\max}} \right). \end{aligned} \quad (6)$$

其中 t_{\max} 为最大迭代次数, \mathbf{W}^{in} 为当前迭代次数。学习因子 \mathbf{W} 随迭代递减, 而学习因子 \mathbf{W}^{back} 随迭代递增。因此, 在迭代的前期, 粒子主要受到个体信息的影响, 这有助于增加种群的多样性; 在迭代的后期, 粒子主要受群体信息影响, 这有助于粒子向全局最优解靠近, 获得最优解。

3.4. 基于 IPSO 优化的 ESN 的训练流程

基于 IPSO 优化的 ESN 模型(ESN-IPSO)的训练过程分为以下几个步骤:

Step 1. 数据预处理。为消除量纲, 提升模型的收敛速度和预测精度, 对原时间序列数据进行归一化处理。

Step 2. ESN 权值初始化。将 ESN 的权重进行随机赋值。

Step 3. 选择优化权值。选择的权值包括: 从输入到隐藏(\mathbf{W}^{in})、隐藏到隐藏(\mathbf{W})和输出到隐藏(\mathbf{W}^{back})连接的部分的权值。为了保持 ESN 的独特性, 节约计算成本, 建议选择少量的权值。

Step 4. 优化选择权值。将选择的权值构成粒子群, 利用改进的粒子群算法对选择权值进行优化。

Step 5. ESN 的输出权值训练。在 Step 4 确定的权值下, 对 ESN 网络中的输出权值进行训练。

4. 数值仿真实验

为验证所提 ESN-IPSO 模型的有效性, 本文选择 Mackey-Glass 时间序列、非线性自回归滑动模型(NARMA)和 Lorenz 时间序列进行仿真实验, 并与标准的 ESN 模型和标准粒子群优化的 ESN 模型(ESN-PSO)进行数值仿真比较。

4.1. 实验的性能评估标准与模型参数设置

本文利用均方根误差(Root Mean Square Error, RMSE)对模型预测性能进行评估, RMSE 的定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{k} \sum_{t=1}^k (\hat{y}_t - y_t)^2}. \quad (7)$$

其中 \hat{y}_t 和 y_t 分别表示 t 时刻的预测值和真实值, k 表示预测值的个数。

在数值模拟中, 储备池的规模设置 50, 输入单元的数目和输出单元的数目均设置为 1。 \mathbf{W}^{in} , \mathbf{W} 和 \mathbf{W}^{back} 的连通性分别为 1, 0.1 和 0.1。对于 IPSO, 设置最大惯性权重 w_{\max} 和最小惯性权重 w_{\min} 分别为 0.9, 0.4, 粒子的数量 n 为 10, 最大迭代次数 t_{\max} 设置为 50。

4.2. 仿真算例

在深度学习中, 对数据集进行归一化操作是非常有必要的预处理步骤。因为归一化操作不仅可以消除量纲, 将数据统一到相同的尺度上, 还可以提升模型的收敛速度和预测精度。本文利用归一化将原始时间序列变换到 (0,1) 范围之间, 归一化函数可表示为:

$$x^* = \frac{x - x_{\text{mean}}}{x_{\max} - x_{\min}}. \quad (8)$$

其中 x^* 为归一化的标准时间序列, x 为原始时间序列, x_{mean} 为原始时间序列的均值, x_{\max} 为原始时间序

列的最大值, x_{\min} 为原始时间序列的最小值。

数值模拟中, 使用 500 个数据样本作为训练数据集, 500 个样本作为测试数据集。为避免预测结果的随机性, 独立运行实验 10 次, 取 10 次运行结果的平均值作为最终的预测结果, 以保证实验结果的可靠性。

4.2.1. Mackey-Glass 时间序列

Mackey-Glass 时间序列是时间序列预测常用基准之一, 具有很强的代表性, 已多次被用来测试 ESN 网络的预测性能。Mackey-Glass 时间序列的产生模型可描述如下:

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^c(t-\tau)}bx(t). \quad (9)$$

其中参数 $\alpha=0.2, b=0.1$ 和 $c=10$, τ 为可调参数。当 ($\tau > 16.8$) 时, 系统(10)呈现混沌运动状态, 在文献中 τ 经常被设置为 17 或 30。预测结果和预测误差如图 2 和图 3 所示, 表 1 和表 2 列出了 ESN-IPSO 模型和其他模型的预测结果对比。




Figure 2. Mackey-Glass time series prediction ($\tau = 17$)

图 2. Mackey-Glass 时间序列预测($\tau = 17$)

Table 1. Model error comparison

表 1. 模型误差对比

Method	RMSE
ESN	4.03e-03
ESN-PSO	2.97e-03
ESN-IPSO	9.27e-04




Figure 3. Mackey-Glass time series prediction ($\tau = 30$)

图 3. Mackey-Glass 时间序列预测($\tau = 30$)

Table 2. Model error comparison

表 2. 模型误差对比

Method	RMSE
ESN	9.01e-02
ESN-PSO	5.11e-03
ESN-IPSO	2.31e-03

从图 2, 图 3 中可以看出, ESN-IPSO 对 Mackey-Glass 时间序列的预测取得了较好的结果, 不仅能够预测时间序列变化的趋势, 且真实值和预测值之间的误差较小, 说明本文提出的模型取得了较高的预测精度。从表 1 中可以看出, ESN-IPSO 模型达到了最佳性能, 其 RMSE 值 $9.27e-04$ 。同时, ESN-IPSO 的预测精度分别比 ESN, ESN-PSO 提升 77%, 69%。从表 2 中可以看出, ESN-IPSO 模型具有最小的 RMSE 误差值, 这意味着它在本次的 Mackey-Glass 预测任务中具有最佳的泛化性能。同时, 与原始 ESN, ESN-PSO 相比, ESN-IPSO 的预测精度分别提高了 97%, 54%。显然, 通过 IPSO 算法优化 ESN 部分随机连接权值, 模型的性能得到了一定的提高。

4.2.2. 非线性自回归滑动模型(NARMA)

NARMA 是广泛应用于 ESN 测试的混沌时间序列之一。NARMA 序列的特点是其不可预测的复杂性, 以及高度的混乱性和输入的非相关性。其动力学方程式, 如下式所示:

$$y(t+1) = c_1 y(t) + c_2 y(t) \sum_{i=1}^k y(t-i) + c_3 x(t - (k-1)) x(t) + c_4. \quad (10)$$

其中的 $y(t)$ 和 $x(t)$ 分别是系统在时间 t 时的输出和输入, 常数 c_i 设置为 0.3, 0.05, 1.5 和 0.1。常数 k 决定了 NARMA 的复杂性, 本论文 k 取值为 30。数据预处理后, 用 ESN-IPSO 模型进行训练和预测, 预测

结果和预测误差如图 4 所示, 表 3 列出了 ESN-IPSO 模型和其他模型的预测结果对比。




Figure 4. NARMA time series prediction ($k = 30$)

图 4. NARMA 时间序列预测($k = 30$)

Table 3. Model error comparison

表 3. 模型误差对比

Method	RMSE
ESN	1.96e-01
ESN-PSO	1.17e-02
ESN-IPSO	4.35e-03

图 4 所显示的 NARMA 时间序列预测结果很好地表现了 ESN-IPSO 的预测性能, 在测试集上, 模型的预测结果误差较小, 精度较高, 非常接近真实值。从表 3 也可以看出, ESN 的 RMSE 值最高, 为 $1.96e-01$ 。而所提出的 ESN-IPSO 模型的 RMSE 值最低, 为 $4.35e-03$ 。同时, 与 ESN 和 ESN-PSO 模型相比, ESN-IPSO 的预测精度分别提高了 98% 和 63%。说明本文提出的模型预测精度高, 预测性能较好。

4.2.3. Lorenz 吸引子

作为一个最经典的混沌模型, Lorenz 系统的研究纵贯整个混沌科学的发展, 几乎与所有混沌科学的重要发展都密切相关。因此 Lorenz 系统的研究对整个非线性科学的发展具有重要的意义。Lorenz 混沌系统基本形式如下:

$$\begin{aligned}
 \frac{dx}{dt} &= \alpha(y - x), \\
 \frac{dy}{dt} &= -y - xz + \gamma x, \\
 \frac{dz}{dt} &= xy - bz.
 \end{aligned} \tag{11}$$

其中在 $\alpha = 10, \gamma = 28$ 和 $b = 8/3$ 时呈现混沌态。对 Lorenz 系统的时间序列 $x(t)$ 经过数据预处理后, 用 ESN-IPSO 模型进行训练和预测, 预测结果和预测误差如图 5 所示。表 4 则列出了 ESN-IPSO 模型和其他模型的预测结果对比。




Figure 5. Lorenz-x(t) time series prediction
图 5. Lorenz-x(t)时间序列预测

Table 4. Model error comparison
表 4. 模型误差对比

Method	RMSE
ESN	2.69e-02
ESN-PSO	2.01e-03
ESN-IPSO	1.08e-03

从图 5 中可以看出, ESN-IPSO 模型在 Lorenz-x(t)时间序列的预测上仍然具有较好的表现, 能够很好地预测序列的变化趋势。从表 4 中也能看出, 在 Lorenz 样本集上本文提出的 ESN-IPSO 模型表现依然出色, 且 ESN-IPSO 的预测性能明显优于 ESN, ESN-IPSO 模型。

5. 结论

本论文针对不同的时间序列, 利用改进的粒子群算法来动态选择回声状态网络的部分随机权值, 以适应不同时间序列的动力学特性, 从而提高预测精度和泛化性能。对于标准的粒子群算法有两方面改进, 一是对粒子群算法的权值进行改进, 二是对粒子群算法的学习因子进行改进。对三组常见的混沌时间序列进行预测, 仿真实验结果表明本文所提出的预测模型对 ESN-PSO 和 ESN 有了很大的改善, 具有较高的预测精度。值得注意的是本文使用的是基本结构的回声状态网络, 其自身性能可能会受到一定的限制。在未来, 可以研究使用其他更加有效的元启发式算法优化具有复杂结构的回声状态网络的随机连接权值矩阵, 进一步提升回声状态网络的性能。

参考文献

- [1] Bar-Joseph, Z., Gerber, G.K., Gifford, D.K., Jaakkola, T.S. and Simon, I. (2003) Continuous Representations of Time-Series Gene Expression Data. *Journal of Computational Biology: A Journal of Computational Molecular Cell Biology*, **10**, 341-356. <https://doi.org/10.1089/10665270360688057>
- [2] 李兴. 金融时间序列的建模与预测[D]: [硕士学位论文]. 杭州: 杭州电子科技大学, 2018.
- [3] 张帆. 基于神经网络的交通流时间序列预测[J]. 现代信息科技, 2020, 4(23): 87-89, 93.
- [4] Billinton, R., Hua, C. and Ghajar, R. (1996) Time-Series Models for Reliability Evaluation of Power Systems Including Wind Energy. *Microelectronics Reliability*, **36**, 1253-1261. [https://doi.org/10.1016/0026-2714\(95\)00154-9](https://doi.org/10.1016/0026-2714(95)00154-9)
- [5] Ghil, M. and Vautard, R. (1991) Interdecadal Oscillations and the Warming Trend in Global Temperature Time Series. *Nature*, **350**, 324-327. <https://doi.org/10.1038/350324a0>
- [6] Chisci, L., Mavino, A., Perferi, G., Sciandrone, M., Anile, C., Colicchio, G., et al. (2010) Real-Time Epileptic Seizure Prediction Using AR Models and Support Vector Machines. *IEEE Transactions on Biomedical Engineering*, **57**, 1124-1132. <https://doi.org/10.1109/TBME.2009.2038990>
- [7] Laner, M., Svoboda, P. and Rupp, M. (2013) Parsimonious Fitting of Long-Range Dependent Network Traffic Using ARMA Models. *IEEE Communications Letters*, **17**, 2368-2371. <https://doi.org/10.1109/LCOMM.2013.102613.131853>
- [8] Narendra, B.C. and Eswara, R.B. (2014) A Moving-Average Filter Based Hybrid ARIMA-ANN Model for Forecasting Time Series Data. *Applied Soft Computing*, **23**, 27-38. <https://doi.org/10.1016/j.asoc.2014.05.028>
- [9] 孟庆芳, 陈珊珊, 陈月辉, 冯志全. 基于递归量化分析与支持向量机的癫痫脑电自动检测方法[J]. 物理学报, 2014(5): 1-8.
- [10] Li, K., Han, Y. and Huang, H.Q. (2016) Chaotic Time Series Prediction Based on IBH-LSSVM and Its Application to Short-Term Prediction of Dynamic Fluid Level of the Oil Wells. *Information and Control*, **45**, 241-247.
- [11] 梁智琿. 遗传算法优化前向神经网络结构和权重矢量研究[J]. 信息与电脑(理论版), 2019(14): 37-38, 43.
- [12] Jaeger, H. and Haas, H. (2004) Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication. *Science*, **304**, 78-80. <https://doi.org/10.1126/science.1091277>
- [13] 韩莹, 井元伟, 金建宇, 李琨. 基于改进黑洞算法优化ESN的网络流量短期预测[J]. 东北大学学报(自然科学版), 2018, 39(3): 311-315.
- [14] Wang, H.S. and Yan, X.F. (2015) Optimizing the Echo State Network with a Binary Particle Swarm Optimization Algorithm. *Knowledge Based Systems*, **86**, 182-193. <https://doi.org/10.1016/j.knsys.2015.06.003>
- [15] Chouikhi, N., Ammar, B., Rokbani, N. and Alimi, A.M. (2017) PSO-Based Analysis of Echo State Network Parameters for Time Series for Ecasing. *Applied Soft Computing*, **55**, 211-225. <https://doi.org/10.1016/j.asoc.2017.01.049>
- [16] 彭宇, 王建民, 彭喜元. 基于回声状态网络的时间序列预测方法研究[J]. 电子学报, 2010, 38(z1): 148-154.
- [17] Chen, H.C. and Wei, D.Q. (2021) Chaotic Time Series Prediction Using Echo State Network Based on Selective Opposition Grey Wolf Optimizer. *Nonlinear Dynamics*, **104**, 3925-3935. <https://doi.org/10.1007/s11071-021-06452-w>
- [18] 任条娟, 钟陈健, 刘半藤, 郑启航. 基于弹性小世界回声状态网络的非线性时间序列预测[J]. 计算机应用与软件, 2021, 38(6): 256-261.
- [19] Li, D.Y., Liu, F., Qiao, J.F. and Li, R. (2019) Structure Optimization for Echo State Network Based on Contribution. *Tsinghua Science and Technology*, **24**, 97-105. <https://doi.org/10.26599/TST.2018.9010049>
- [20] 史柏迪, 庄曙东, 韩祺. 基于改进的粒子群优化神经网络粗糙度预测模型[J]. 组合机床与自动化加工技术, 2021(2): 30-33+38.
- [21] 张春韵, 邹德旋, 沈鑫. 改进的粒子群算法在电力经济调度中的应用[J]. 制造业自动化, 2021, 43(1): 53-57+64.
- [22] 韩顺杰, 单新超, 于爱君, 符金鑫. 基于改进粒子群算法的工业机器人轨迹规划[J]. 制造技术与机床, 2021(4): 8-14.