

doi: 10.12068/j.issn.1005-3026.2019.01.022

# 一种改进 AFSA – Elman 边坡位移预测网络

王述红, 任艺鹏, 邢观华

(东北大学 资源与土木工程学院, 辽宁 沈阳 110819)

**摘 要:** Elman 网络在边坡位移序列预测的应用中,对于网络隐含层神经元个数、阈值的选取没有具体的定论,且收敛速度慢,容易陷入局部解.基于此,将人工鱼群算法与 Elman 网络相结合,建立了改进的 AFSA – Elman 边坡位移预测网络,修正鱼群算法的步长,并利用经改进后鱼群算法强大的寻优能力,对 Elman 网络的初始权值和阈值进行优化,提高了 Elman 网络的预测精度和收敛速度.将改进的 AFSA – Elman 网络与传统 Elman 网络以及 AFSA – BP 网络进行对比,并模拟了 3 种网络的迭代过程,发现改进的 AFSA – Elman 预测网络较以上两种预测网络具有较高的精度,收敛性更好,更适用于边坡位移的预测.

**关 键 词:** 人工鱼群算法;Elman 网络;边坡;神经网络;位移

**中图分类号:** TU 45      **文献标志码:** A      **文章编号:** 1005-3026(2019)01-0115-06

## An Improved AFSA-Elman Slope Displacement Prediction Network

WANG Shu-hong, REN Yi-peng, XING Guan-hua

(School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: WANG Shu-hong, E-mail: wangshuhong@mail.neu.edu.cn)

**Abstract:** In the prediction of slope displacement sequence, there is no specific conclusions on the number of neurons and thresholds in the Elman network hidden layer. The convergence speed is slow, and it is easy to fall into the local solution. Based on this, the improved AFSA-Elman slope displacement prediction network was established by combining the artificial fish swarm algorithm with the Elman network. In order to improve the prediction accuracy and convergence speed of Elman network, the step size of artificial fish swarm algorithm was modified and the initial weights and thresholds of Elman network were optimized by using the powerful optimization ability of the improved fish swarm algorithm. The improved AFSA-Elman network was compared with the traditional Elman network and AFSA-BP network, and the iterative process of the three networks was simulated. The result found that the improved AFSA-Elman prediction network has higher precision and convergence speed than those of the above two prediction network, and it is more suitable for the prediction of slope displacement.

**Key words:** artificial fish swarm algorithm; Elman network; slope; neural network; displacement

位移信息的变化,对于开挖边坡或者边坡变形来说是非常直观的信息,根据边坡位移的变化规律来准确推演位移信息的变化趋势,能大大减少人力和物力的损耗;掌握边坡变形的规律,对边坡破坏的超前预测以及判断边坡的稳定状态具有非常重要的影响.因此对边坡位移的准确预测,对于研究边坡稳定来说就显得尤为重要.近年来,依

托越来越成熟的计算机技术,神经网络方法被用于边坡位移的预测.经查阅文献知,边坡位移的预测方法一般分为以下几种:①神经网络与各类算法相结合,包括 PSO 和时间序列<sup>[1]</sup>,神经网络和遗传算法<sup>[2]</sup>;②考虑边坡位移的模糊性,采用时间序列及其衍生方法,包括时间序列与灰色系统<sup>[3]</sup>,时间序列与神经网络<sup>[4]</sup>,混沌时间序列<sup>[5]</sup>;

③小波变换和神经网络<sup>[6]</sup>等方法. 上述几种方法在用于边坡位移预测中有的受制于测量误差和方法精度的影响, 预测结果差强人意.

本文将人工鱼群算法( AFSA) 与 Elman 网络相结合, 建立了改进的 AFSA – Elman 边坡位移预测网络, 将改进的 AFSA – Elman 网络与传统 Elman 网络以及 AFSA – BP 网络进行对比, 发现改进的 AFSA – Elman 预测网络较以上两种预测网络具有较高的精度, 收敛性更好, 更适用于边坡位移的预测.

# 1 改进 AFSA – Elman 边坡位移预测网络

## 1.1 人工鱼群算法( AFSA)

鱼群算法是李晓磊等提出的一种智能寻优算法<sup>[7-8]</sup>, 通过模拟人工鱼群的各种行为进行搜索, 并达到寻优的目的. 鱼群趋向于食物浓度高而且周边个体少的地方, 以此不断进行各种行为, 最后达到寻找到最优个体. 主要参数有样本集  $N$ 、人工鱼移动步长  $S$ 、视野范围  $V$ 、迭代次数  $t$ 、最大迭代次数  $T_{\max}$ .

人工鱼群主要有聚群、追尾、觅食三种行为: 觅食行为是人工鱼群通过移动来寻找食物浓度较高的地方; 聚群行为是人工鱼群通过聚集, 进行觅食行为, 更容易寻找到最优的食物浓度位置; 追尾行为是人工鱼群寻找到当中拥有最大食物浓度的伙伴, 并朝该个体进行聚集.

## 1.2 Elman 网络

Elman 网络较传统 BP 网络, 其网络结构中加入了承接层和延迟单元, 局部反馈能力得到加强, 由于延迟单元的存在, Elman 网络表现出较强的记忆性和时序性, 因此在关于时间序列的问题上有较好的适配度, 式(1), 式(2), 式(3)为 Elman 网络结构的基本表达式, 网络结构图如图 1 所示,  $U(k-1)$ ,  $X(k)$ ,  $Y(k)$ ,  $X_c(k)$  分别是网络输入层、隐含层、输出层和承接层.

$$Y(k) = g(w_3X(k)) , \tag{1}$$

$$X(k) = f(w_1X_c(k) + w_2U(k-1)) , \tag{2}$$

$$X_c(k) = \alpha X_c(k-1) + X(k-1) . \tag{3}$$

式中:  $w_1, w_2, w_3$  分别为各层连接权值;  $g(\cdot)$ ,  $f(\cdot)$  分别为神经元输出层传递函数以及神经元中间层传递函数, sigmoid 函数一般被使用在传递函数中;  $Y = [Y(1), Y(2), \cdots, Y(k)]$ ,  $X = [X(1), X(2), \cdots, X(k)]$ ,  $U = [U(1), U(2), \cdots, U(k-1)]$ ,  $X_c = [X_c(1), X_c(2), \cdots, X_c(k)]$ ,  $\alpha$  分别为

节点输出向量、节点隐含层向量、网络输入向量、节点承接层向量以及变换系数.




图 1 Elman 神经网络  
Fig. 1 Elman neural network

## 1.3 改进 AFSA – Elman 网络

### 1.3.1 参数设定

利用上述鱼群算法对 Elman 网络进行改造, 鱼群算法寻找的是群体中最优的个体, 即食物浓度最大的位置(误差最小的位置), 令网络适应度函数为

$$G = \frac{1}{Q} . \tag{4}$$

式中:  $G$  代表权值变化中适应度最大的位置;  $Q$  为网络期望输出与实际输出的误差, 误差越大, 代表适应度越小, 反之与其相反.

输入层、隐含层、输出层构成了传统网络的一般结构, 承接层的存在是 Elman 网络区别于 BP 网络的特点, 选取 4 层 Elman 网络, 令  $n$  为网络输入层神经元个数,  $m$  为网络输出层神经元个数,  $p$  为网络隐含层神经元个数,  $e$  为网络承接层神经元个数, 在鱼群中选取任意两条人工鱼为  $R_m$  和  $R_x$ , 每条人工鱼都代表一条完整的神经网络, 考虑权值变化, 利用各层神经元来计算各层连接之间输入与输出的欧氏距离, 任意两条人工鱼  $R_m$  和  $R_x$  之间的距离为

$$d_{R_m, R_x} = \sum_{i=1}^p \sum_{j=1}^n [w_{ij}(R_m) - w_{ij}(R_x)]^2 + \sum_{g=1}^e \sum_{i=1}^p [w_{gi}(R_m) - w_{gi}(R_x)]^2 + \sum_{k=1}^m \sum_{g=1}^e [w_{kg}(R_m) - w_{kg}(R_x)]^2 + \sum_{i=1}^p [w_{i0}(R_m) - w_{i0}(R_x)]^2 + \sum_{g=1}^1 [w_{g0}(R_m) - w_{g0}(R_x)]^2 + \sum_{k=1}^m [w_{k0}(R_m) - w_{k0}(R_x)]^2 . \tag{5}$$

式中:  $w_{ij}$  为  $i$  层隐含层神经元和  $j$  层输入层神经元权值;  $w_{gi}$  为  $g$  层承接层神经元和  $i$  层隐含层连接权值;  $w_{kg}$  为输出层  $k$  层神经元和  $g$  层承接层神经元权值;  $w_{i0}$  为隐含层神经元阈值;  $w_{g0}$  为承接层神经元阈值;  $w_{k0}$  为输出层神经元阈值。

### 1.3.2 鱼群行为描述

借鉴粒子群算法中粒子运动时粒子更新速度, 对鱼群引入鱼群游速  $\omega^{[9]}$ , 使得 AFSA 更接近真实鱼群活动过程。

1) 觅食行为. 对于指定人工鱼  $R_m$  和  $R_x$ , 若  $R_x$  处食物浓度较大 (误差小), 则  $R_m$  执行觅食行为, 向  $R_x$  靠近; 反之,  $R_m$  向任意方向进行随机移动, 网络权值和阈值被改变, 移动公式为

$$\left. \begin{aligned} w_{ij}(R_m + 1) &= \omega \cdot w_{ij}(R_m) + \\ &\text{Rand} \cdot S \cdot \frac{w_{ij}(R_x) - w_{ij}(R_m)}{d_{R_m, R_x}}, \\ G_{R_x} &> G_{R_m}; \\ w_{ij}(R_m + 1) &= \omega \cdot w_{ij}(R_m) + \text{Rand} \cdot S, \\ G_{R_x} &\leq G_{R_m}. \end{aligned} \right\} \quad (6)$$

其中,  $\omega = \omega_{\min} + \frac{(\omega_{\max} - \omega_{\min})(T_{\max} - t)}{T_{\max}}$ . 同理可得, 其他层神经元觅食行为与上述  $w_{ij}$  方式一致. 式(6)中  $S$  为人工鱼移动步长;  $\text{Rand}$  为  $0 \sim 1$  中 1 个随机数;  $T_{\max}$  为最大迭代次数;  $w_{ij}(R_m)$ ,  $w_{ij}(R_m + 1)$  分别为人工鱼当前状态和进行移动后的下一步状态。

2) 聚群行为. 状态为  $R_m$  的人工鱼群视野中, 视野内人工鱼群集合可表示为

$$S_c = \{R_m | d_{R_m, R_x} \leq V\}. \quad (7)$$

式中:  $V$  代表着人工鱼群的视野, 即为权值的变换集合;  $S_c$  为人工鱼群集合 (网络集合)。

若  $S_c \neq \emptyset$ , 则在集合内部寻找在中心处的人工鱼  $R_{\text{cen}}$ , 搜寻公式为

$$\left. \begin{aligned} w_{ij}(R_{\text{cen}}) &= w_{ij0}(R_{\text{cen}}) + w_{ij}(R_m), \\ w_{gi}(R_{\text{cen}}) &= w_{gi0}(R_{\text{cen}}) + w_{gi}(R_m), \\ w_{kg}(R_{\text{cen}}) &= w_{kg0}(R_{\text{cen}}) + w_{kg}(R_m), \\ w_{i0}(R_{\text{cen}}) &= w_{i00}(R_{\text{cen}}) + w_{i0}(R_m), \\ w_{g0}(R_{\text{cen}}) &= w_{g00}(R_{\text{cen}}) + w_{g0}(R_m), \\ w_{k0}(R_{\text{cen}}) &= w_{k00}(R_{\text{cen}}) + w_{k0}(R_m). \end{aligned} \right\} \quad (8)$$

式中:  $w_{ij}$ ,  $w_{gi}$ ,  $w_{kg}$ ,  $w_{i0}$ ,  $w_{g0}$ ,  $w_{k0}$  为鱼群中初始个体移动权值;  $w_{ij}(R_{\text{cen}})$  为人工鱼  $R_{\text{cen}}$  输入层和隐含层的连接权值

视野中鱼群扫描完全后, 可以计算视野中人工鱼中心参数, 见式(9)。

$$\left. \begin{aligned} w_{ij}(R_{\text{cen}}) &= \sum_1^f w_{ij}(R_{\text{cen}})/f, \\ w_{gi}(R_{\text{cen}}) &= \sum_1^f w_{gi}(R_{\text{cen}})/f, \\ w_{kg}(R_{\text{cen}}) &= \sum_1^f w_{kg}(R_{\text{cen}})/f, \\ w_{i0}(R_{\text{cen}}) &= \sum_1^f w_{i0}(R_{\text{cen}})/f, \\ w_{g0}(R_{\text{cen}}) &= \sum_1^f w_{g0}(R_{\text{cen}})/f, \\ w_{k0}(R_{\text{cen}}) &= \sum_1^f w_{k0}(R_{\text{cen}})/f. \end{aligned} \right\} \quad (9)$$

式中:  $f$  为视野内搜索的人工鱼个数. 执行聚群移动策略, 移动方式如式(10)所示:

$$w_{ij}(R_m + 1) = w_{ij}(R_m) + \text{Rand} \cdot S \cdot \frac{w_{ij}(R_{\text{cen}}) - w_{ij}(R_m)}{d_{R_m, R_x}}. \quad (10)$$

若  $S_c = \emptyset$ , 人工鱼执行前述觅食行为, 其他层神经元移动方式与  $w_{ij}$  一致, 文中不再赘述。

3) 追尾行为. 人工鱼视野中寻找食物浓度最大 (期望输出与实际输出误差最小) 的个体  $R_{\text{max}}$ , 寻找到之后执行追尾移动策略, 移动方式如式(11)所示:

$$w_{ij}(R_m + 1) = w_{ij}(R_m) + \text{Rand} \cdot S \cdot \frac{w_{ij}(R_{\text{max}}) - w_{ij}(R_m)}{d_{R_m, R_x}}. \quad (11)$$

式中,  $w_{ij}(R_{\text{max}})$  为视野浓度最大处个体的权值, 其他层移动方式与  $w_{ij}$  一致, 文中不再赘述。

### 1.4 适应度评价

网络架构时, 执行文中上述觅食、聚群、追尾等行为, 并选择适应度较大的移动行为, 即为网络期望输出与实际输出误差较小的那个行为, 并在算法中记录每次移动得到的适应度, 将最优的值计入公告板中, 每次移动与最优值进行比较, 迭代过程中若寻找到更优的一个值, 对公告板进行更新, 运算流程如图 2 所示,  $z$  为行为尝试最大次数。

### 1.5 迭代步长修正

步长的影响对于算法收敛至关重要, 增加迭代步数的过程中, 动态调整步长, 防止迭代过程中跳过最优解. 本文将迭代步长进行修改, 修正公式为

$$S = [S_{\max} - \frac{(S_{\max} - S_{\text{mean}}) \cdot t}{T_{\max}}]. \quad (12)$$

式中:  $T_{\max}$  为最大迭代次数;  $t$  为迭代次数, 设置最大迭代次数为 200;  $S_{\max}$ ,  $S_{\text{mean}}$  为最大迭代步长和平均迭代步长。

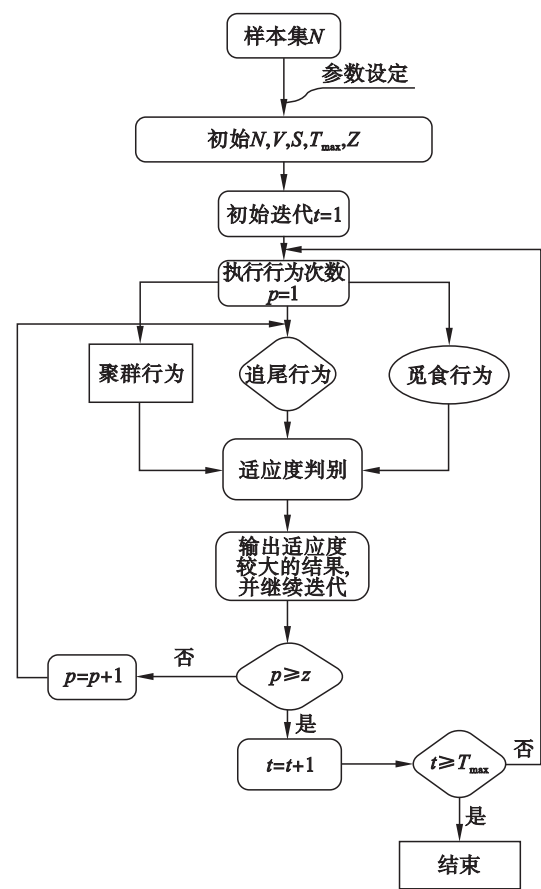


图2 改进 ASFA – Elman 流程图  
Fig. 2 Improving ASFA-Elman flowchart

1. 6 位移序列网络参数取值

针对位移序列的时效性与模糊性,权值变化对于网络预测精度以及迭代速度具有非常重要的影响,在执行觅食、追尾、聚群三种行为之后,对误差进行测试,如果测试误差较大,则按照式(12)修正步长,经过多次测试,通过采用不同人工鱼(神经元)个数以及初始权值,对比误差和迭代速度,设置网络人工鱼个数  $N = 15$ ,视野和最大迭代步长分别为 0.6 和 0.3。

2 工程实例

本文在 MATLAB 环境下采用辽宁省建兴高速公路沿线小盘岭岩质边坡作为算例进行建模,小盘岭岩质边坡属于开挖边坡,坡体较碎裂,开挖时期坡体变形较为剧烈,边坡现场图如图 3 所示。

在小盘岭隧道上布设位移监测点,全程采用高精度全站仪徕卡 1201 + 对竖直位移进行检测。选取现场第四级边坡开挖时台阶上 2 号测点,测点布设见图 4,在 2 号测点上选取 2013 年 10 月—2014 年 6 月 103 个位移变化量,按照时间的先后顺序,前 78 个位移变化序列作为训练样本,构建

改进 AFSA – Elman 神经网络,后 25 组位移变化值则作为测试样本,检测网络的预测能力,并与单一 Elman 和 AFSA – BP 网络预测结果进行对比,网络预测结果如图 5 所示,位移预测误差如图 6 所示。



图3 小盘岭边坡  
Fig. 3 Xiaopanling slope




图4 监测点布设示意图  
Fig. 4 Layout of monitoring points




图5 预测结果对比  
Fig. 5 Comparison of prediction results

误差评估采用平均误差 AE (average error)、绝对平均百分误差 MAPE (mean absolute percentage error) 两项指标<sup>[10]</sup>对几种预测方法进行精度判别,计算方法如下:

$$AE = \frac{1}{n} \left( \sum_{i=1}^n |v_i - d_i| \right), \quad (13)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{v_i - d_i}{d_i} \right|. \quad (14)$$

式中: $n$  为位移样本的个数; $v_i$  为预测高程数值; $d_i$  为实际边坡高程值,误差分析结果如表 1 所示。






图 6 位移预测误差  
Fig. 6 Displacement prediction error

表 1 误差分析  
Table 1 Error analysis

评价指标	AFSA - Elman	Elman	AFSA - BP
AE/mm	0. 080 04	0. 193 32	0. 121
MAPE/%	2. 062	4. 741	3. 395

由图 5,图 6 可以看出,改进 AFSA - Elman 网络预测精度相较于 Elman 以及 AFSA - BP 网络有了显著的提升,曲线平滑度和拟合程度也更优,并减少了突变点的产生,与实测序列具有较高的贴合度。

由表 1 可以看出,改进 AFSA - Elman 网络 AE 和 MAPE 分别为 0. 080 04 和 2. 062,其网络预测精度要远远优于其他两种网络。

分别对三种网络的收敛性以及运行速度进行测试,采用均方误差 MSE 作为迭代误差评估指标,计算方法如式 (15) 所示,得到迭代时步分别为 50,100,150,200 时三种网络的误差下降收敛曲线,限于文章篇幅,选取迭代 50 步和 200 步时 ( $T_{max}$  为 200),对均方误差 (MSE) 进行统计,见表 2. 三种方法的迭代次数的误差下降收敛曲线见图 7,图 8,迭代过程迭代速度与内存占用见表 3.

$$MSE = \sqrt{\frac{1}{25} \sum_{i=1}^{25} \left( \frac{v_i - d_i}{d_i} \right)^2}.$$

(15)




图 7 迭代 50 次三种方法迭代误差  
Fig. 7 Iteration error of three methods by iterating 50 times  
(a)—AFSA - BP; (b)—Elman; (c)—AFSA - Elman.

由图 7 可以看出,当设置迭代步数为 50 时, Elman 网络在第 45 步完成收敛,误差为 0. 084 281; AFSA - BP 在第 50 步完成迭代,误差为 0. 077 62;改进 AFSA - Elman 网络在第 42 步完成收敛,误差为 0. 068 234,迭代速度与精度都有明显提高。




图 8 迭代 200 次三种方法迭代误差  
Fig. 8 Iteration error of three methods by iterating 200 times  
(a)—AFSA - BP; (b)—Elman; (c)—AFSA - Elman.

由图 8 可看出,三种方法均在第 200 步完成收敛,Elman 误差为 0.026 443,AFSA – BP 为 0.023 117,改进 AFSA – Elman 为 0.019 823,且改进 AFSA – Elman 精度要远远优于 Elman 以及 AFSA – BP 网络.

表 2 预测方法对比

Table 2 Comparison of prediction methods

测试方法	迭代均方误差变化			
	$t=50$	$t=100$	$t=150$	$t=200$
AFSA – Elman	0.068	0.047	0.033 9	0.019 8
Elman	0.084 2	0.065 7	0.039 7	0.026 4
AFSA – BP	0.077	0.058 1	0.038	0.023 1

表 3 迭代速度与内存占用 ( $t=200$ )

Table 3 Iteration speed and memory usage ( $t=200$ )

评价指标	AFSA – Elman	Elman	AFSA – BP
迭代速度/s	5	7	8
内存占用/kb	488	672	691

由表 3 可看出,无论是运行速度还是内存占比,改进 AFSA – Elman 网络都要更优.

### 3 结 论

1) 改进 AFSA – Elman 网络,相比较单一 Elman 网络与经鱼群算法改进后的 BP 网络,网络的预测精度有了大大提高,运算速度和内存占比都更优,适合边坡位移的预测.

2) 本文提出的改进 AFSA – Elman 网络对位移时变序列表现出较好的预测度,因此,对于其他岩土工程涉及时变序列的问题,如地基沉降、基坑沉降预测等问题,在本文提出方法的基础上可以进行深入探究.

#### 参考文献:

[ 1 ] Zhou C, Yin K L, Cao Y, et al. Application of time series analysis and PSO-SVM model in predicting the Bazimen landslide in the Three Gorges Reservoir, China [ J ].

*Engineering Geology*,2016,204:108 – 120.

[ 2 ] Du J, Yin K, Lacasse S. Displacement prediction in Colluvial landslides, Three Gorges Reservoir, China [ J ]. *Landslides*, 2013,10(2):203 – 218.

[ 3 ] Sun Q, Zhang L, Ding X L, et al. Slope deformation prior to Zhouqu, China landslide from InSAR time series analysis [ J ]. *Remote Sensing of Environment*,2015,156:45 – 57.

[ 4 ] 李克钢,张重庆. 基于时间序列的神经网络建模及边坡位移预测 [ J ]. 地下空间与工程学报,2009,5 ( sup ): 1418 – 1421.

( Li Ke-gang, Zhang Chong-qing. Neural network modeling and slope displacement prediction based on time series [ J ]. *Chinese Journal of Underground Space and Engineering*, 2009,5 ( sup ):1418 – 1421. )

[ 5 ] Huang F, Huang J, Jiang S, et al. Landslide displacement prediction based on multivariate chaotic model and extreme learning machine [ J ]. *Engineering Geology*,2017,218:173 – 186.

[ 6 ] Ren F, Wu X, Zhang K, et al. Application of wavelet analysis and a particle swarm-optimized support vector machine to predict the displacement of the Shuping landslide in the Three Gorges, China [ J ]. *Environmental Earth Sciences*,2014,73 ( 8 ):4791 – 4804.

[ 7 ] 李晓磊,邵之江,钱积新. 一种基于动物自治体的寻优模式:鱼群算法 [ J ]. 系统工程理论与实践,2002,22 ( 11 ): 32 – 38.

( Li Xiao-lei, Shao Zhi-jiang, Qian Ji-xin. An optimizing method based on autonomous animats; fish-swarm algorithm [ J ]. *Systems Engineering—Theory & Practice*, 2002, 22 ( 11 ):32 – 38. )

[ 8 ] 李晓磊,冯少辉,钱积新,等. 基于人工鱼群算法的鲁棒 PID 控制器参数整定方法研究 [ J ]. 信息与控制,2004,33 ( 1 ):112 – 115.

( Li Xiao-lei, Feng Shao-hui, Qian Ji-xin, et al. Parameter tuning method of robust PID controller based on artificial fish school algorithm [ J ]. *Information and Control*,2004,33(1): 112 – 115. )

[ 9 ] Eberhart C, Kennedy J. A new optimizer using particle swarm theory [ C ] // Proceedings of the 6th International Symposium on Micro Machine and Human Science. Piscataway:IEEE,1995:39 – 43.

[ 10 ] 姚传安,姬少龙,余泳昌,等. 基于小波变换 Elman 神经网络的短期风速组合预测 [ J ]. 可再生能源,2012,30 ( 8 ): 42 – 45,49.

( Yao Chuan-an, Ji Shao-long, Yu Yong-chang, et al. Short-term combination forecasting of wind speed based on wavelet transform and Elman neural network [ J ]. *Renewable Energy Resources*,2012,30(8):42 – 45,49. )