

DOI:10.3880/j.issn.1004-6933.2020.06.020

# 基于人工生态系统优化算法的组合生长需水预测模型

崔东文<sup>1</sup>, 包艳飞<sup>2</sup>

(1. 云南省文山州水务局, 云南 文山 663000; 2. 云南省水文水资源局曲靖分局, 云南 曲靖 655000)

**摘要:**为提高需水预测精度, 拓展生长模型在需水预测中的应用, 提出基于人工生态系统优化(AEO)算法的组合生长需水预测模型。结合实例, 选取 6 个标准测试函数在不同维度条件下对 AEO 算法进行仿真验证, 并与鲸鱼优化算法(WOA)、灰狼优化(GWO)算法、教学优化(TLBO)算法和传统粒子群优化(PSO)算法的仿真结果进行比较。基于 Weibull、Richards、Usher 3 种单一生长模型构建 Weibull-Richards-Usher、Weibull-Richards、Weibull-Usher、Richards-Usher 4 种组合生长模型, 利用 AEO 算法同时对组合模型参数和权重系数进行优化, 提出 AEO-Weibull-Richards-Usher、AEO-Weibull-Richards、AEO-Weibull-Usher、AEO-Richards-Usher 需水预测模型, 并构建 AEO-Weibull、AEO-Richards、AEO-Usher、AEO-SVM、AEO-BP 模型作对比, 以上海市需水预测为例进行实例验证, 利用实例前 30 组和后 8 组统计资料对各组合模型进行训练和预测。结果表明, 在不同维度条件下, AEO 算法寻优精度优于 WOA、GWO、TLBO、PSO 算法, 具有较好的寻优精度和全局搜索能力。4 种组合模型对实例预测的平均相对误差绝对值、平均绝对误差分别在 0.94% ~ 1.17%、0.30 亿 ~ 0.37 亿 m<sup>3</sup> 之间, 预测精度优于 AEO-Weibull 等其他 5 种模型。4 种组合模型均具有较好的预测精度和泛化能力, 表明 AEO 算法能同时有效优化组合生长模型参数和权重系数, 基于 AEO 算法的组合生长模型用于需水预测是可行和有效的。

**关键词:**需水预测; 人工生态系统优化算法; 组合生长模型; Weibull 模型; Richards 模型; Usher 模型; 参数优化

中图分类号: TV213.4 文献标志码: A 文章编号: 1004-6933(2020)06-0122-09

**Combined growth water demand forecasting model based on artificial ecosystem optimization algorithm** // CUI Dongwen<sup>1</sup>, BAO Yanfei<sup>2</sup> (1. Wenshan Water Affairs Bureau of Yunnan Province, Wenshan 663000, China; 2. Qujing Branch of Yunnan Hydrology and Water Resources Bureau, Qujing 655000, China)

**Abstract:** In order to improve the accuracy of water demand forecasting and expand the application of growth model in water demand forecasting, a combined growth water demand prediction model based on artificial ecosystem optimization (AEO) algorithm was proposed. Combined with an example, six standard test functions were selected to simulate AEO algorithm in different dimensions, and the simulation results were compared with those of Whale optimization algorithm (WOA), gray wolf optimization (GWO), teaching optimization (TLBO) algorithm and traditional particle swarm optimization (PSO). Based on the combination of three single growth models (Weibull, Richards, and Usher), Weibull-Richards-Usher, Weibull-Richards, Weibull-Usher and Richards-Usher were constructed. The AEO algorithm was used to optimize the parameters and weight coefficients of the four combined growth models. The AEO-Weibull-Richards-Usher, AEO-Weibull-Richards, AEO-Weibull-Usher, AEO-Richards-Usher water demand forecasting models were proposed and AEO-Weibull, AEO-Richards, AEO-Usher, AEO-SVM, AEO-BP models were constructed for comparison. Taking the water demand forecast of Shanghai as an example, the combined models were trained and predicted by using the statistical data of the first 30 groups and the last 8 groups. The results show that the optimization accuracy of AEO algorithm is better than that of WOA, GWO, TLBO and PSO algorithms in different dimensions, and has better optimization accuracy and global search ability. The average absolute relative error and the average absolute error of the four combined models are 0.94%—1.17% and 30 million—37 million m<sup>3</sup>, respectively. The prediction accuracy is better than the other five models such as AEO-Weibull. The results show that the AEO algorithm can effectively optimize the parameters and weight coefficients of the

combined growth model, and the combined growth model based on AEO algorithm is feasible and effective for water demand prediction.

**Key words:** water demand forecast; artificial ecosystem optimization algorithm; combined growth model; Weibull model; Richards model; Usher model; sparameter optimization

提高城市需水预测精度对城市建设规划和供水系统优化调度等具有重要意义。目前需水预测方法主要有神经网络法<sup>[1-5]</sup>、投影寻踪回归法<sup>[6]</sup>、马尔可夫链模型法<sup>[7]</sup>、随机森林法<sup>[8]</sup>、优选 GM(0, N) 模型法<sup>[9]</sup>、组合模型法<sup>[10-11]</sup>等。生长模型作为趋势外推法的一种重要方法,除用于描述和预测生物个体的生长发育以外,已在某些技术、经济特性等领域得到广泛应用<sup>[12]</sup>。常用的生长模型有 Logistic 模型、Richards 模型、MMF 模型、Hyperbola 模型、Korf 模型、Weibull 模型、Gompertz 模型、Usher 模型等,已在人口预测<sup>[13]</sup>、林火预测<sup>[14]</sup>、地表沉降<sup>[15-17]</sup>、林分断面积研究<sup>[18]</sup>、油气田产量预测<sup>[19]</sup>、电能消费量预测<sup>[20]</sup>、径流预测<sup>[21]</sup>等行业领域得到应用,但在需水预测相关研究中应用较少。研究表明,制约生长模型应用的关键在于模型相关参数的合理确定,目前主要采用四点法、三段法、最小二乘法等进行参数估算,不但求解复杂,且效率不高。虽然遗传算法(GA)<sup>[22]</sup>、粒子群优化(PSO)算法<sup>[20,23-24]</sup>、果蝇优化算法(FOA)<sup>[25]</sup>、差分进化(DE)算法<sup>[26]</sup>已尝试用于 Weibull 模型、Gompertz 模型、Richards 模型、Usher 模型参数的选取,具有较好的实际意义,但存在 GA、PSO 等传统智能算法收敛速度慢和易陷入局部极值、仅针对单一生长模型参数进行优化、所选用算法缺乏优化性能评估等问题。

为拓展需水预测模型及方法,进一步提高需水预测精度,本文选取 Weibull、Richard、Usher 3 种单一生长模型进行组合,构建 Weibull-Richards-Usher、Weibull-Richards、Weibull-Usher、Richards-Usher 4 种组合生长模型,提出基于人工生态系统优化(artificial ecosystem-based optimization, AEO)算法<sup>[27]</sup>的组合生长需水预测模型,利用 AEO 算法同时优化各组合生长模型参数和组合权重系数,构建不同组合需水预测模型,以上海市需水预测为例进行验证,旨在验证基于 AEO 算法的组合生长模型应用于城市需水预测的可行性和有效性。

## 1 基于 AEO 算法的组合生长模型

### 1.1 AEO 算法

AEO 算法是 Zhao 等<sup>[27]</sup>于 2019 年通过模拟地球生态系统中能量流动而提出一种新型元启发式优

化算法,该算法通过生产算子、消费算子和分解算子对生态系统中的生产、消费和分解行为进行模拟来达到求解优化问题的目的。生产算子旨在加强 AEO 算法勘探和开发之间的平衡能力;消费算子用于改进 AEO 算法的探索能力;分解算子旨在提升 AEO 算法的开发性能。与传统群智能算法相比,AEO 算法不但实现简单,除群体规模和最大迭代次数外,无需调整其他任何参数,且具有较好的寻优精度和全局搜索能力。

AEO 算法遵行以下 3 个准则:①生态系统作为种群包括 3 种生物:生产者、消费者和分解者,且种群中分别只有一个个体作为生产者和分解者,其他个体作为消费者;②每个个体都具有相同的概率被选择为食肉动物、食草动物或杂食动物;③群体中每个个体的能量水平通过适应度值进行评价,适应度值按降序排序,适应度值越大表示最小化问题的能量水平越高。参考文献<sup>[27]</sup>,AEO 算法数学描述简述如下:

a. 生产者。生态系统中,生产者可以利用 CO<sub>2</sub>、水和阳光以及分解者提供的营养来产生食物能量。在 AEO 算法中,种群中的生产者(最差个体)通过搜索空间上下限和分解者(最优个体)进行更新,更新后的个体将引导种群中的其他个体搜索不同的区域。模拟生产者行为的数学模型如下:

$$x_{1,t+1} = [1 - (1 - t/T)r_1]x_n + (1 - t/T)r_1x_{\text{rand},t} \quad (1)$$

其中  $x_{\text{rand}} = r(U - L) + L$   
式中: $x_1$  为生产者个体空间位置; $x_n$  为当前群体中最佳个体空间位置; $n$  为种群规模; $T$  为最大迭代次数; $t$  为当前迭代次数; $x_{\text{rand}}$  为搜索空间中随机生成的个体空间位置; $U$ 、 $L$  分别为空间上、下限; $r$ 、 $r_1$  为  $[0, 1]$  之间的随机数。

b. 消费者。生产者提供食物能量后,每个消费者均可随机选择能量水平较低的消费者或生产者或两者兼有获得食物能量。如果消费者被随机选择为食草动物,它只以生产者为食;如果消费者被随机选择为食肉动物,它只能随机选择能量水平较高的消费者为食;如果消费者被随机选择为杂食动物,它可以同时选择能量水平较高的消费者和生产者为食。

模拟食草动物、食肉动物、杂食动物消费行为的数学模型分别为

$$x_{i,t+1} = x_{i,t} + Cx_{i,t} - x_{1,t} \quad (i = 2, 3, \dots, n) \quad (2)$$

$$\begin{cases} x_{i,t+1} = x_{i,t} + C(x_{i,t} - x_{j,t}) & (i = 3, 4, \dots, n) \\ j = \text{randi}(2i - 1) \end{cases} \quad (3)$$

$$\begin{cases} x_{i,t+1} = x_{i,t} + C[r_2(x_{i,t} - x_{1,t}) + \\ (1 - r_2)(x_{i,t} - x_{j,t})] \\ (i = 3, 4, \dots, n) \\ j = \text{randi}(2i - 1) \end{cases} \quad (4)$$

其中  $C = 0.5v_1/|v_2|$   $v_1 \sim N(0,1)$   $v_2 \sim N(0,1)$  式中:  $x_i$  为第  $i$  个消费者个体空间位置;  $C$  为具有 levy 飞行特性的消费因子;  $N(0,1)$  为呈正态分布、均值为 0、标准差为 1 的概率密度函数;  $x_j$  为具有较高能量水平的消费者和生产者;  $r_2$  为  $[0, 1]$  范围内的随机数。

**c. 分解者。**就生态系统功能而言,分解是一个非常重要的过程,它为生产者提供必要的养分。为提高算法的开发性能,AEO 算法允许每个个体的下一个位置围绕最佳个体(分解者)传播,并通过调节分解因子  $D$  和权重系数  $e, h$  来更新群体中第  $i$  个消费者的空间位置。其模拟分解行为的数学模型为

$$x_{i,t+1} = x_{n,t} + D(ex_{n,t} - hx_{i,t}) \quad (i = 1, 2, \dots, n) \quad (5)$$

$$\begin{aligned} \text{其中} \quad D &= 3u \quad u \sim N(0,1) \\ e &= r_3 \text{randi}(1,2) - 1 \quad h = 2r_3 - 1 \end{aligned}$$

式中  $r_3$  为  $[0, 1]$  之间的随机数。

## 1.2 组合生长模型

**a. Weibull 模型。**Weibull 模型最早由瑞典工程师 Waloddi Weibull 于 1951 年提出并逐渐发展而来,目前已在油气田产量<sup>[19]</sup>、地基沉降<sup>[22]</sup>、泥石流预警<sup>[28]</sup>、药物溶出曲线评价<sup>[29]</sup>等领域得到应用。Weibull 模型表述形式多样,本文利用式(6)所示函数模型进行需水预测。

$$W'_1 = \alpha \left[ 1 - \exp \left( - \sum_{o=1}^m \beta_o \hat{z}'_o \right) \right]^\gamma \quad (6)$$

式中:  $W'_1$  为 Weibull 模型需水预测值;  $\hat{z}'_o$  为第  $b$  个需水预测影响因子归一化值,即第  $o$  维输入向量;  $\alpha, \gamma, \beta_o$  ( $o = 1, 2, \dots, m$ , 本文需水预测影响因子有 7 个,  $m = 7$ ) 为待优化参数。

**b. Richards 模型。**Richards 模型是描述生物生长的非线性回归方程,含有 4 个参数,目前已在碳排放量预测<sup>[30]</sup>、人口预测<sup>[13]</sup>、地表沉降<sup>[15]</sup>等领域得到应用。Richards 模型表述形式多样,本文利用式(7)所示函数模型进行需水预测。

$$W'_2 = a \left[ 1 + \exp \left( b - \sum_{o=1}^m c_o \hat{z}'_o \right) \right]^{-2/d} \quad (7)$$

式中:  $W'_2$  为 Richards 模型需水预测值;  $a, b, c_o, d$  为待优化参数。

**c. Usher 模型。**Usher 模型最早由美国学者 Usher 于 1980 年提出用于描述增长信息随时间变化的数学模型,目前已在围岩变形预测<sup>[21]</sup>、油田开发<sup>[31]</sup>、沉降预测<sup>[22,32]</sup>等领域得到应用。Usher 模型表述形式多样,本文利用式(8)所示函数模型进行需水预测。

$$W'_3 = \frac{A}{\left[ 1 + B \exp \left( - \sum_{o=1}^m C_o \hat{z}'_o \right) \right]^D} \quad (8)$$

式中:  $W'_3$  为 Usher 模型需水预测值;  $A, B, C_o, D$  为待优化参数。

利用 AEO 算法对 Weibull-Richards-Usher、Weibull-Richards、Weibull-Usher、Richards-Usher 模型参数和权重系数进行优化,得到待优化的 4 种组合生长模型:

$$W'_{W-R-U} = \omega_W W'_1 + \omega_R W'_2 + (1 - \omega_W - \omega_R) W'_3 \quad (9)$$

$$W'_{W-R} = \omega_W W'_1 + (1 - \omega_W) W'_2 \quad (10)$$

$$W'_{W-U} = \omega_W W'_1 + (1 - \omega_W) W'_3 \quad (11)$$

$$W'_{R-U} = \omega_R W'_2 + (1 - \omega_R) W'_3 \quad (12)$$

式中:  $W'_{W-R-U}$ 、 $W'_{W-R}$ 、 $W'_{W-U}$ 、 $W'_{R-U}$  分别为 Weibull-Richards-Usher、Weibull-Richards、Weibull-Usher、Richards-Usher 组合生长模型需水预测值;  $\omega_W, \omega_R$  分别为 Weibull、Richards 模型权重系数。

## 1.3 仿真实验

本文实例优化维度有 3 维、9 维、10 维、20 维、21 维、31 维和 118 维,为验证 AEO 算法在不同维度条件下的寻优能力,选取 Sphere、Schwefel 2.22、Schwefel 1.2、Griewank、Rastrigin、Ackley 6 个典型测试函数在 5 维、10 维、20 维 30 维和 100 维条件下对 AEO 算法进行仿真实验,并与当前寻优能力较好的 WOA、GWO、TLBO 算法和传统 PSO 算法的仿真结果进行比较。上述 6 个函数变量取值范围分别为  $[-100, 100]$ 、 $[-10, 10]$ 、 $[-100, 100]$ 、 $[-600, 600]$ 、 $[-5.12, 5.12]$ 、 $[-32, 32]$ ,理论最优解值均为 0。其中,函数 Sphere、Schwefel 2.22、Schwefel 1.2 为单峰函数,主要用于测试算法的寻优精度;函数 Griewank、Rastrigin、Ackley 为多峰函数,主要用于测试算法的全局搜索能力。基于 Matlab 2018 a M 语言实现 5 种算法对 6 个标准测试函数的 20 次寻优,利用平均值对 5 种算法寻优性能进行评估,见表 1。试验参数设置如下: AEO、WOA、GWO、TLBO、PSO 5

种算法最大迭代次数  $T = 1000$ , 种群规模  $n = 50$ 。其中, WOA 对数螺旋形状常数  $b = 2$ ; TLBO 算法参数  $T_F$  为  $1 \sim 10$  之间随机整数; PSO 算法惯性权重  $w_{\max}$ 、 $w_{\min}$  分别取值  $0.9$  和  $0.6$ , 自我学习因子、社会学习因子  $c_1$ 、 $c_2$  均取值  $2.0$ 。其他参数采用各算法默认值。

对于单峰函数 Sphere, AEO 算法在不同维度条件下 20 次寻优均获得理论最优值 0, 寻优精度优于 WOA、TLBO、GWO 算法, 远优于 PSO 算法; 对于具有明显转折点的非线性函数 Schwefel 2.22, AEO 算法在不同维度条件下寻优精度较其他 4 种算法提高 100 个数量级以上, 具有较好的寻优精度; 对于倒锥形非线性函数 Schwefel 1.2, AEO 算法在不同维度条件下 20 次寻优均获得理论最优值 0, 寻优精度优于 TLBO、GWO 算法, 远优于 WOA、PSO 算法。对于上述单峰函数, AEO 算法寻优效果基本不受维变化的影响, 而随着维度的增加, WOA、TLBO、GWO、PSO 算法寻优精度下降显著。

对于典型多峰多模态函数 Griewank, AEO 算法

在不同维度条件下 20 次寻优均获得了理论最优值 0, 低维条件下 (5 维、10 维) 寻优精度远优于 WOA、TLBO、GWO 和 PSO 算法。随着维度的增加, TLBO、WOA 算法寻优精度不降反升; 对于典型易陷入局部极值多峰函数 Rastrigin, AEO 算法 20 次寻优获得理论最优值 0, 寻优精度优于 10 维、20 维条件下的 WOA 和高维 (30 维和 100 维) 条件下的 GWO 算法, 远优于不同维条件下的 PSO 算法和 10 维、20 维、30 维和 100 维条件下的 TLBO 算法; 对于连续旋转不可分多峰函数 Ackley, AEO 算法在不同维度条件下 20 次寻优均获得相对理论最优值  $8.88 \times 10^{-16}$ , 寻优精度优于 WOA、TLBO、GWO 算法, 远优于 PSO 算法。对于上述多峰函数, AEO 算法寻优效果不受维变化的影响。

可见, AEO 算法在 5 维、10 维、20 维、30 维和 100 维条件下对上述 6 个标准测试函数均获得理想的寻优效果, 寻优精度优于 WOA、TLBO、GWO 算法, 远优于 PSO 算法, 且寻优精度基本不受维度变化的影响, 具有较好的寻优精度和全局搜索能力。

表 1 函数优化对比结果

Table 1 Comparison results of function optimization

函数	算法	不同维度的 AEO 算法对各测试函数的寻优结果				
		5 维	10 维	20 维	30 维	100 维
Sphere	AEO	0	0	0	0	0
	WOA	$3.70 \times 10^{-190}$	$5.70 \times 10^{-174}$	$4.73 \times 10^{-173}$	$1.85 \times 10^{-169}$	$5.56 \times 10^{-168}$
	GWO	$2.10 \times 10^{-237}$	$3.07 \times 10^{-143}$	$1.74 \times 10^{-108}$	$1.52 \times 10^{-70}$	$1.45 \times 10^{-34}$
	TLBO	$1.24 \times 10^{-264}$	$2.18 \times 10^{-218}$	$2.02 \times 10^{-202}$	$1.21 \times 10^{-177}$	$9.09 \times 10^{-160}$
	PSO	$7.85 \times 10^{-19}$	$7.54 \times 10^{-9}$	$8.26 \times 10^{-5}$	$9.92 \times 10^{-4}$	$6.25 \times 10^{-1}$
Schwefel 2.22	AEO	$4.77 \times 10^{-246}$	$1.13 \times 10^{-225}$	$7.59 \times 10^{-214}$	$6.90 \times 10^{-215}$	$4.41 \times 10^{-213}$
	WOA	$1.76 \times 10^{-118}$	$2.31 \times 10^{-112}$	$3.05 \times 10^{-108}$	$9.95 \times 10^{-107}$	$5.46 \times 10^{-106}$
	GWO	$1.62 \times 10^{-130}$	$1.15 \times 10^{-85}$	$4.72 \times 10^{-63}$	$5.93 \times 10^{-41}$	$8.44 \times 10^{-21}$
	TLBO	$1.27 \times 10^{-134}$	$8.41 \times 10^{-110}$	$5.53 \times 10^{-94}$	$1.22 \times 10^{-88}$	$1.41 \times 10^{-80}$
	PSO	$1.07 \times 10^{-9}$	$1.15 \times 10^{-6}$	$2.04 \times 10^{-4}$	$6.19 \times 10^{-2}$	$4.95 \times 10^0$
Schwefel 1.2	AEO	0	0	0	0	0
	WOA	$4.52 \times 10^{-13}$	$1.05 \times 10^0$	$3.15 \times 10^1$	$1.26 \times 10^4$	$6.69 \times 10^5$
	GWO	$1.64 \times 10^{-137}$	$1.47 \times 10^{-68}$	$1.37 \times 10^{-44}$	$6.19 \times 10^{-21}$	$1.01 \times 10^0$
	TLBO	$8.41 \times 10^{-175}$	$1.27 \times 10^{-96}$	$6.34 \times 10^{-52}$	$9.33 \times 10^{-38}$	$4.16 \times 10^{-16}$
	PSO	$1.82 \times 10^{-17}$	$1.86 \times 10^{-6}$	$3.21 \times 10^{-3}$	$6.82 \times 10^{-1}$	$1.89 \times 10^3$
Griewank	AEO	0	0	0	0	0
	WOA	$3.61 \times 10^{-2}$	$1.51 \times 10^{-1}$	$2.93 \times 10^{-2}$	$8.57 \times 10^{-3}$	0
	GWO	$9.10 \times 10^{-3}$	$5.65 \times 10^{-3}$	$5.46 \times 10^{-3}$	$2.94 \times 10^{-3}$	$2.44 \times 10^{-3}$
	TLBO	$1.05 \times 10^{-2}$	$5.60 \times 10^{-3}$	$4.58 \times 10^{-12}$	0	0
	PSO	$7.60 \times 10^{-1}$	$5.06 \times 10^0$	$1.44 \times 10^1$	$2.71 \times 10^1$	$1.18 \times 10^2$
Rastrigin	AEO	0	0	0	0	0
	WOA	0	$1.29 \times 10^{-15}$	$2.58 \times 10^{-15}$	0	0
	GWO	0	0	0	$5.17 \times 10^{-15}$	$1.13 \times 10^{-14}$
	TLBO	0	$2.11 \times 10^0$	$6.10 \times 10^0$	$8.68 \times 10^0$	$4.83 \times 10^0$
	PSO	$2.08 \times 10^0$	$8.99 \times 10^0$	$1.55 \times 10^1$	$3.66 \times 10^1$	$2.03 \times 10^2$
Ackley	AEO	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$	$8.88 \times 10^{-16}$
	WOA	$2.83 \times 10^{-15}$	$3.79 \times 10^{-15}$	$4.60 \times 10^{-15}$	$4.17 \times 10^{-15}$	$3.96 \times 10^{-15}$
	GWO	$2.66 \times 10^{-15}$	$4.93 \times 10^{-15}$	$6.22 \times 10^{-15}$	$1.09 \times 10^{-14}$	$7.05 \times 10^{-14}$
	TLBO	$1.37 \times 10^{-15}$	$4.44 \times 10^{-15}$	$4.76 \times 10^{-15}$	$6.86 \times 10^{-15}$	$7.99 \times 10^{-15}$
	PSO	$4.00 \times 10^{-12}$	$1.59 \times 10^{-6}$	$2.86 \times 10^{-4}$	$2.43 \times 10^{-1}$	$1.13 \times 10^0$

## 1.4 组合生长模型预测实现步骤

**步骤 1:** 选取需水预测影响因子, 构造上述 4 种需水预测组合生长模型的输入、输出向量, 合理划分训练样本和预测样本, 利用式 (13) 对实例数据序列进行归一化处理; 设定组合生长模型参数和权重系数搜寻范围。

$$z' = \frac{z - 0.5z_{\min}}{2z_{\max} - 0.5z_{\min}} \quad (13)$$

式中:  $z'$  为经过归一化处理的数据;  $z$  为原始数据;  $z_{\max}$  和  $z_{\min}$  分别为序列中的最大值和最小值。

**步骤 2:** 确定组合生长模型适应度函数。本文选用训练样本均方误差作为适应度函数, 描述如下:

$$\left\{ \begin{array}{l} \min W_{W-R-U}(\alpha, \beta_o, \gamma, a, b, c_o, d, A, B, C_o, D, \omega_W, \omega_R) = \\ \omega_W \sum_{i=1}^k (\hat{W}_i - W_{1i})^2 + \omega_R \sum_{i=1}^k (\hat{W}_i - W_{2i})^2 + \\ (1 - \omega_W - \omega_R) \sum_{i=1}^k (\hat{W}_i - W_{3i})^2 \\ \text{s. t.} \quad \alpha_{\min} \leq \alpha \leq \alpha_{\max} \quad \beta_{\min} \leq \beta_o \leq \beta_{\max} \\ \gamma_{\min} \leq \gamma \leq \gamma_{\max} \quad a_{\min} \leq a \leq a_{\max} \\ b_{\min} \leq b \leq b_{\max} \quad c_{\min} \leq c_o \leq c_{\max} \\ d_{\min} \leq d \leq d_{\max} \quad A_{\min} \leq A \leq A_{\max} \\ B_{\min} \leq B \leq B_{\max} \quad C_{\min} \leq C_o \leq C_{\max} \\ D_{\min} \leq D \leq D_{\max} \quad 0 \leq \omega_W \leq 0.5 \\ 0 \leq \omega_R \leq 0.5 \end{array} \right. \quad (14)$$

$$\left\{ \begin{array}{l} \min W_{W-R}(\alpha, \beta_o, \gamma, a, b, c_o, d, \omega_W) = \omega_W \sum_{i=1}^k (\hat{W}_i - W_{1i})^2 + \\ (1 - \omega_W) \sum_{i=1}^k (\hat{W}_i - W_{2i})^2 \\ \text{s. t.} \quad \alpha_{\min} \leq \alpha \leq \alpha_{\max} \quad \beta_{\min} \leq \beta_o \leq \beta_{\max} \\ \gamma_{\min} \leq \gamma \leq \gamma_{\max} \quad a_{\min} \leq a \leq a_{\max} \\ b_{\min} \leq b \leq b_{\max} \quad c_{\min} \leq c_o \leq c_{\max} \\ d_{\min} \leq d \leq d_{\max} \quad 0 \leq \omega_W \leq 1 \end{array} \right. \quad (15)$$

$$\left\{ \begin{array}{l} \min W_{W-U}(\alpha, \beta_o, \gamma, A, B, C_o, D, \omega_W) = \omega_W \sum_{i=1}^k (\hat{W}_i - W_{1i})^2 + \\ (1 - \omega_W) \sum_{i=1}^k (\hat{W}_i - W_{3i})^2 \\ \text{s. t.} \quad \alpha_{\min} \leq \alpha \leq \alpha_{\max} \quad \beta_{\min} \leq \beta_o \leq \beta_{\max} \\ \gamma_{\min} \leq \gamma \leq \gamma_{\max} \quad A_{\min} \leq A \leq A_{\max} \\ B_{\min} \leq B \leq B_{\max} \quad C_{\min} \leq C_o \leq C_{\max} \\ D_{\min} \leq D \leq D_{\max} \quad 0 \leq \omega_W \leq 1 \end{array} \right. \quad (16)$$

$$\left\{ \begin{array}{l} \min W_{R-U}(a, b, c_o, d, A, B, C_o, D, \omega_R) = \omega_R \sum_{i=1}^k (\hat{W}_i - W_{2i})^2 + \\ (1 - \omega_R) \sum_{i=1}^k (\hat{W}_i - W_{3i})^2 \\ \text{s. t.} \quad a_{\min} \leq a \leq a_{\max} \quad b_{\min} \leq b \leq b_{\max} \\ c_{\min} \leq c_o \leq c_{\max} \quad d_{\min} \leq d \leq d_{\max} \\ A_{\min} \leq A \leq A_{\max} \quad B_{\min} \leq B \leq B_{\max} \\ C_{\min} \leq C_o \leq C_{\max} \quad D_{\min} \leq D \leq D_{\max} \\ 0 \leq \omega_R \leq 1 \end{array} \right. \quad (17)$$

式中:  $\hat{W}_i$  为第  $x_i$  个训练样本实际值;  $W_{1i}$ 、 $W_{2i}$ 、 $W_{3i}$  分别为 Weibull、Richards、Usher 模型第  $x_i$  个训练样本预测输出值;  $\omega_W$ 、 $\omega_R$  分别为 Weibull、Richards 模型权重系数;  $k$  为训练样本数量。

**步骤 3:** 设置 AEO 算法种群规模  $n$ 、最大迭代次数  $T$  和算法终止条件; 随机初始化生态系统  $x_i$ , 计算适应度值, 保留当前最佳个体空间位置  $x_{\text{best}}$ 。令当前迭代次数  $t=0$ 。

**步骤 4:** 利用式 (1) 更新生产者空间位置。

**步骤 5:** 在  $[0, 1]$  之间生成随机数  $r$ , 若  $r < 1/3$ , 利用式 (2) 更新消费者个体空间位置; 若  $1/3 \leq r \leq 2/3$ , 利用式 (3) 更新消费者个体空间位置; 其他利用式 (4) 更新消费者个体空间位置。计算每个个体空间位置适应度值, 找到并保留当前最佳个体空间位置  $x_{\text{best}}$ 。

**步骤 6:** 利用式 (5) 更新分解过程中消费者个体空间位置, 计算每个个体适应度值, 找到并保留当前最佳个体空间位置  $x_{\text{best}}$ 。

**步骤 7:** 比较并保存最佳个体空间位置, 即算法最优解  $x_{\text{best}}$ 。

**步骤 8:** 令  $t = t + 1$ 。判断算法是否达到终止条件, 若是, 输出全局最优解  $x_{\text{best}}$ , 算法结束; 否则重复步骤 4~8。

**步骤 9:** 输出最优适应度值及全局最优位置  $x_{\text{best}}$ ,  $x_{\text{best}}$  即为各组合生长模型参数和权重系数向量。将参数  $x_{\text{best}}$  代入各组合生长模型进行需水预测。

## 2 实例应用

### 2.1 数据来源

在充分考虑需水预测影响因子和指标获取难易程度的基础上, 依据 2018 年上海统计年鉴, 以 1980—2017 年为时间系列, 选取 7 个指标作为上海市需水预测的影响因子:  $z_1$  为第一产业总产值、 $z_2$  为第二产业总产值、 $z_3$  为第三产业总产值、 $z_4$  为户籍人口、 $z_5$  为农业总产值、 $z_6$  为工业总产、 $z_7$  为建筑业总

产值。利用 SPSS 软件分析此 7 个影响因子与需水量的相关系数分别为 0.984、0.906、0.798、0.940、0.988、0.890、0.830。利用 1980—2009 年统计数据作为训练样本,2010—2017 年作为预测样本。

## 2.2 参数设置

设置 4 种组合生长模型参数的搜索范围为 [0, 10], Weibull、Richards 模型权重系数搜索范围见式 (14) ~ (17); Weibull、Richards、Usher 单一模型对应的参数搜索范围同组合模型; SVM 模型惩罚因子  $P$ 、核函数参数  $g$ 、不敏感系数  $\varepsilon$  搜索范围均为  $[2^{-5}, 2^5]$ , 交叉验证折数  $V = 3$ ; BP 网络结构为 7-13-1, 隐含层和输出层传递函数均分别采用 logsig 和 purelin, 训练函数采用 trainlm, 设定期望误差为 0.001, 最大训练轮回为 100 次, 搜索空间为  $[-1, 1]$ 。AEO 算法参数设置同上; SVM、BP 模型采用  $[0.1, 0.9]$  对原始数据进行归一化处理。

## 2.3 模型构建及预测

分别构建 AEO-Weibull-Richards-Usher、AEO-Weibull-Richards、AEO-Weibull-Usher、AEO-Richards-Usher、AEO-Weibull、AEO-Richards、AEO-Usher、AEO-SVM、AEO-BP 模型对实例需水量进行训练及预测。选取平均相对误差绝对值  $R_{EM}$ 、平均绝对误差  $A_{EM}$ 、最大相对误差绝对值  $R_{EMmax}$  和适应度值  $\min W$  作为评价指标, 利用此 9 种模型对实例需水进行预测, 结果见表 2, 并给出 9 种模型不同系列长度的训练、预测阶段的相对误差和绝对误差结果见图 1。

由表 2 及图 1 可见, 4 种组合生长模型对实例训练样本拟合的  $R_{EM}$ 、 $A_{EM}$  分别在 1.56% ~ 2.22%、0.26 亿 ~ 0.40 亿  $m^3$  之间, 拟合精度均优于 3 种单

- AEO-Weibull-Richards-Usher模型
- AEO-Weibull-Richards模型
- AEO-Weibull-Usher模型
- AEO-Richards-Usher模型
- AEO-Richards模型
- AEO-Usher模型
- AEO-SVM模型
- AEO-BP模型
- AEO-Weibull模型




图 1 9 种模型不同系列长度的训练、预测阶段的相对误差和绝对误差

Fig.1 Relative error and absolute error results of training and prediction stages of 9 models with different series lengths

一生长模型和 AEO-SVM 模型; 对实例预测样本的  $R_{EM}$ 、 $A_{EM}$  分别在 0.94% ~ 1.17%、0.30 亿 ~ 0.37 亿  $m^3$  之间, 尤以 AEO-Weibull-Richards-Usher 模型预测精度最高, 其  $R_{EM}$ 、 $A_{EM}$  分别达到了 0.94% 和 0.30 亿  $m^3$ , 4 种组合生长模型预测精度均优于 AEO-Weibull、AEO-Richards、AEO-Usher、AEO-SVM、AEO-BP 模型,

表 2 需水预测各模型测试结果

Table 2 Test results of various models for water demand prediction

模型	时间序列	$R_{EM}/\%$	$A_{EM}/\text{亿 } m^3$	$R_{EMmax}/\%$	优化维度	$\min W$
AEO-Weibull-Richards-Usher	1980—2009 年	1.56	0.26	5.34	31 维	3.3205
	2010—2017 年	0.94	0.30	2.51		
AEO-Weibull-Richards	1980—2009 年	2.08	0.39	7.99	20 维	8.9098
	2010—2017 年	1.11	0.35	2.66		
AEO-Weibull-Usher	1980—2009 年	2.22	0.40	7.48	20 维	8.6818
	2010—2017 年	1.17	0.37	2.15		
AEO-Richards-Usher	1980—2009 年	2.09	0.34	9.55	21 维	7.5769
	2010—2017 年	1.07	0.34	2.66		
AEO-Weibull	1980—2009 年	3.60	0.60	13.57	9 维	16.3237
	2010—2017 年	1.42	0.45	2.45		
AEO-Richards	1980—2009 年	2.37	0.42	8.17	10 维	9.3541
	2010—2017 年	1.35	0.43	2.63		
AEO-Usher	1980—2009 年	2.32	0.41	8.46	10 维	9.1741
	2010—2017 年	1.38	0.44	2.50		
AEO-SVM	1980—2009 年	3.60	0.60	12.42	3 维	15.5815
	2010—2017 年	3.64	1.14	6.18		
AEO-BP	1980—2009 年	1.36	0.22	5.44	118 维	2.3813
	2010—2017 年	2.33	0.73	3.59		

具有较好的预测精度和泛化能力,表明 Weibull、Richards、Usher 模型间具有互补性,AEO 算法能同时有效优化各组合生长模型参数和权重系数,基于 AEO 算法的组合生长模型用于需水预测是可行和有效的。

从各组合生长模型参数和权重系数优化结果来看,对于 AEO-Weibull-Richards-Usher 模型,Usher 权重系数为 0.424 2,大于 0.33,表明 Usher 占主导地位;对于 AEO-Weibull-Richards 模型,Weibull 权重系数 0.9559,大于 0.5,表明 Weibull 占绝对主导地位;对于 AEO-Weibull-Usher 模型,Usher 权重系数 0.679 3,大于 0.5,表明 Usher 占主导地位;对于 AEO-Richards-Usher 模型,Usher 权重系数 0.836 1,大于 0.5,表明 Usher 占主导地位。3 种含有 Usher 的组合模型中,Usher 模型均占主导地位,表明 Usher 模型对该实例具有较好的拟合-预测效果(从 AEO-Usher 模型的拟合、预测结果亦可看出)。

AEO-Weibull、AEO-Richards、AEO-Usher 3 种单一生长模型的预测效果在伯仲之间,其对实例 2010—2017 年需水预测的  $R_{EM}$ 、 $A_{EM}$  分别在 1.35% ~ 1.42%、0.43 亿 ~ 0.45 亿  $m^3$  之间,预测精度优于 AEO-SVM、AEO-BP 模型,表明单一生长模型在需水预测中同样具有较好的预测效果,其关键之处在于合理选取模型的相关参数。相对而言,AEO-Weibull 模型拟合效果劣于 AEO-Richards、AEO-Usher 模型。

从 AEO-SVM、AEO-BP 模型拟合、预测结果来看,AEO-SVM 模型拟合、预测精度均不佳,存在“欠拟合”现象;AEO-BP 模型拟合精度较好,但预测效果较差,存在“过拟合”现象。经笔者反复调试,AEO-SVM、AEO-BP 模型均不能获得较好的预测效果,原因在于输入向量,即 7 个需水预测影响因子均随时间呈逐年增加趋势,影响因子间相关性较好,存在多重共线性问题。

本实例虽然采用 AEO 算法对 BP、SVM 模型关键参数进行优化,具有一定的智能化水平,但 BP 模型的隐层节点数、隐含层和输出层传递函数、期望误差等参数均需人为设定,在一定程度上影响了模型的预测精度;SVM 模型的交叉验证折数  $V$  需人为设定, $V$  值过大或过小均会导致模型出现“过拟合”或“欠拟合”现象,从而影响 AEO-SVM 模型的预测效果。本文提出的 AEO-Weibull-Richards-Usher、AEO-Weibull-Richards、AEO-Weibull-Usher、AEO-Richards-Usher 组合生长模型所有参数和权重系数均由 AEO 算法优化获得,无须人为设定,具有较高的智能化水平和较好的实际应用价值。

### 3 结 论

a. 在不同维度条件下,AEO 算法寻优精度优于

WOA、GWO、TLBO 算法,远优于 PSO 算法,具有较好的寻优精度和全局搜索能力。

b. 4 种组合生长模型的预测精度均优于 AEO-Weibull 等 5 种模型,表明 Weibull、Richards、Usher 模型间具有互补性,AEO 算法能同时有效优化各组合生长模型参数和权重系数,基于 AEO 算法的组合生长模型用于需水预测是可行和有效的,组合生长模型具有较好的预测精度和泛化能力,模型及方法可为需水预测及其他相关预测研究提供新的途径和方法。

c. 解决了各组合模型及 Weibull、Richards、Usher 单一生长模型参数选取困难的实际问题,各组合生长模型权重系数由 AEO 算法优化获得,无需人为计算或设定,具有较高的智能化水平和较好的实际应用价值。

### 参考文献:

- [1] 杨利纳,李文竹,刘心. 基于灰色遗传 BP 神经网络的校园区间需水预测研究[J]. 水资源与水工程学报, 2019,30(3): 133-138. (YANG Lina, LI Wenzhu, LIU Xin. On campus interval water demand prediction based on grey genetic BP neural network[J]. Journal of Water Resources and Water Engineering, 2019,30(3): 133-138. (in Chinese))
- [2] 郭强,李文竹,刘心. 基于贝叶斯 BP 神经网络的区间需水预测方法[J]. 人民黄河, 2018,40(12): 76-80. (GUO Qiang, LI Wenzhu, LIU Xin. Interval water demand prediction method based on bayesian BP network[J]. Yellow River, 2018,40(12): 76-80. (in Chinese))
- [3] 崔东文. 基于相空间重构原理的遗传神经网络模型在城市需水预测中的应用[J]. 水利水电科技进展, 2014, 34(1): 85-89. (CUI Dongwen. Application of genetic neural network model to urban water demand prediction based on theory of phase space reconstruction[J]. Advances in Science and Technology of Water Resources, 2014,34(1): 85-89. (in Chinese))
- [4] 桑慧茹,王丽学,陈韶明,等. 基于主成分分析的 RBF 神经网络在需水预测中的应用[J]. 水电能源科学, 2017(7): 58-61. (SANG Huiru, WANG Lixue, CHEN Shaoming, et al. Water demand forecast model of RBF neural networks based on principle component analysis[J]. Water Resources and Power, 2017(7): 58-61. (in Chinese))
- [5] 许银山,吕孙云,梅亚东,等. 等维新息径向基神经网络模型在需水预测中的应用[J]. 水资源保护, 2012, 28(2): 8-11, 16. (XU Yinshan, LU Sunyun, MEI Yadong, et al. Application of equi-dimensional information renewal radial basis function neural network model to urban water demand forecast[J]. Water Resources Protection, 2012, 28(2): 8-11, 16. (in Chinese))

- [ 6 ] 崔东文. 飞蛾火焰优化算法-投影寻踪回归模型在需水预测中的应用[J]. 华北水利水电大学学报(自然科学版), 2017, 38(2): 25-29. ( CUI Dongwen. Application of projection pursuit regression model optimized by moth-flame optimization algorithm in prediction of water demand prediction[J]. Journal of North China University of Water Resources and Electric Power(Natural Science Edition), 2017, 38(2): 25-29. (in Chinese))
- [ 7 ] 杨皓翔, 梁川, 崔宁博. 基于加权灰色-马尔可夫链模型的城市需水预测[J]. 长江科学院院报, 2015, 32(7): 15-21. ( YANG Haoxiang, LIANG Chuan, CUI Ningbo. Prediction of urban water demand by using weighted grey-markov chain model [ J ]. Journal of Yangtze River Scientific Research Institute 2015, 32 ( 7 ): 15-21. ( in Chinese ))
- [ 8 ] 王盼, 陆宝宏, 张瀚文, 等. 基于随机森林模型的需水预测模型及其应用[J]. 水资源保护, 2014, 30(1): 34-37. ( WANG Pan, LU Baohong, ZHANG Hanwen, et al. Water demand prediction model based on random forests model and its application[J]. Water Resources Protection, 2014, 30(1): 34-37. (in Chinese))
- [ 9 ] 黄朔, 彭勇, 张小丽, 等. 优选 GM(0, N) 模型在大连市城区需水预测中的应用[J]. 水电能源科学, 2016(12): 12-15. ( HUANG Shuo, PENG Yong, ZHANG Xiaoli, et al. Application of optimized GM(0, N) model to waterdemand forecast in Dalian City[J]. Water Resources and Power, 2016(12): 12-15. (in Chinese))
- [ 10 ] 李晓英, 苏志伟, 田佳乐, 等. 基于 GRA-MEA-BP 耦合模型的城市需水预测研究[J]. 水资源与水工程学报, 2018, 29(1): 50-54. ( LI Xiaoying, SU Zhiwei, TIAN Jiale, et al. Research on GRA-MEA-BP coupling model for water demand prediction[J]. Journal of Water Resources and Water Engineering, 2018, 29(1): 50-54. (in Chinese))
- [ 11 ] 崔东文. 加权平均集成神经网络模型在城市需水预测中的应用[J]. 水资源保护, 2014, 30(2): 27-32. ( CUI Dongwen. Application of weighted average integrated neural network model to urban water demand forecasting [ J ]. Water Resources Protection, 2014, 30(2): 27-32. (in Chinese))
- [ 12 ] 赵宜宾, 胡顺田, 赵永安, 等. 生长曲线数学模型的一般形式及新的构建方法[J]. 防灾科技学院学报, 2003, 5(3): 11-16. ( ZHAO Yibin, HU Shuntian, ZHAO Yongan, et al. General form of mathematical model of growth curve and new construction method [ J ]. Journal of Institute of Disaster Prevention, 2003, 5(3): 11-16. (in Chinese))
- [ 13 ] 刘锋, 何卓, 谭祥勇. Richards 模型与 Logistic 模型在人口预测中的比较[J]. 重庆工商大学学报(自然科学版), 2017, 34(1): 6-9. ( LIU Feng, HE Zhuo, TAN Xiangyong. Comparison of richards model and logistic model in population prediction [ J ]. Journal of Chongqing Technology and Business University ( Natural Science Edition ), 2017, 34 ( 1 ): 6-9. ( in Chinese ))
- [ 14 ] 陈岱. 基于 Logistic 回归模型的大兴安岭林火预测研究[J]. 林业资源管理, 2019(1): 116-122. ( CHEN Dai. Prediction of forest fire occurrence in Daxing'an Mountains based on logistic regression model [ J ]. Forest Resources Management, 2019(1): 116-122. (in Chinese))
- [ 15 ] 王正帅, 邓喀中. 采动区地表动态沉降预测的 Richards 模型[J]. 岩土力学, 2011, 32(6): 1664-1668. ( WANG Zhengshuai, DENG Kazhong. Richards model of surface dynamic subsidence prediction in mining area [ J ]. Rock and Soil Mechanics, 2011, 32 ( 6 ): 1664-1668. ( in Chinese ))
- [ 16 ] 王军保, 刘新荣, 李鹏, 等. MMF 模型在采空区地表沉降预测中的应用[J]. 煤炭学报, 2012, 37(3): 411-415. ( WANG Junbao, LIU Xinrong, LI Peng, et al. Study on prediction of surface subsidence in mined-out region with the MMF model [ J ]. Journal of China Coal Society, 2012, 37(3): 411-415. (in Chinese))
- [ 17 ] 高艳平, 杨洋, 王杰, 等. Hyperbola-Logistic 叠加模型预测地基沉降[J]. 南水北调与水利科技, 2017(2): 198-202. ( GAO Yanping, YANG Yang, WANG Jie, et al. Prediction of foundation settlement by hyperbola-logistic superposition model [ J ]. South-to-North Water Diversion and Water Conservancy Technology, 2017(2): 198-202. (in Chinese))
- [ 18 ] 吴恒, 朱丽艳, 李华, 等. 昆明市 4 个主要针叶树种林分断面积生长模型研究[J]. 西南林业大学学报(自然科学), 2018, 38(4): 119-125. ( WU Heng, ZHU Liyan, LI Hua, et al. Stand basal area growth models for 4 main coniferous species in kunming [ J ]. Journal of Southwest Forestry University, 2018, 38 ( 4 ): 119-125. ( in Chinese ))
- [ 19 ] 周鹏, 陈明, 王庆勇, 等. 预测油气田产量和可采储量的广义 Weibull 模型[J]. 大庆石油地质与开发, 2017(5): 93-97. ( ZHOU Peng, CHEN Ming, WANG Qingyong, et al. Generalized Weibull model for predicting the production and recoverable reserves of oil and gas fields [ J ]. Petroleum Geology & Oilfield Development in Daqing, 2017(5): 93-97. (in Chinese))
- [ 20 ] 单葆国, 李昊洋, 霍沫霖, 等. 基于粒子群优化改进 Gompertz 模型的终端电能消费量分析[J]. 供用电, 2018, 35(11): 59-63. ( SHAN Yiguo, LI Haoyang, HUO Molin, et al. analysis of terminal power consumption using improved gompertz model based on particle swarm optimization [ J ]. Distribution & Utilization, 2018, 35 ( 11 ): 59-63. (in Chinese))
- [ 21 ] 崔东文. 多组群教学优化算法-神经网络-支持向量机组合模型在径流预测中的应用[J]. 水利水电科技进展, 2019, 39(4): 41-48. CUI Dongwen. Combined model of multi-group teaching optimization algorithm-neural network-support vector machine in runoff prediction application [ J ]. Advances in Science and Technology of



- Water Resources, 2019, 39(4):41-48. (in Chinese))
- [22] 林达, 陈志坚. 基于遗传算法与 Weibull 模型的软土地基沉降预测[J]. 中国煤炭地质, 2016, 28(8):63-67. (LIN Da, CHEN Zhijian. Settlement prediction of soft soil foundation based on genetic algorithm and Weibull model [J]. Coal Geology of China, 2016, 28(8):63-67. (in Chinese))
- [23] 燕振刚, 胡贺年, 李广. 基于粒子群优化算法的 Richards 模型参数估计和算法有效性[J]. 计算机应用, 2014, 34(10):2827-2830. (YAN Zhen'gang HU Henian, LI Guang. Parameter estimation of Richards model and algorithm effectiveness based on particle swarm optimization algorithm [J]. Journal of Computer Applications, 2014, 34(10):2827-2830. (in Chinese))
- [24] 杜勇立. 单桩承载力预测的 PSO-Gompertz 模型研究[J]. 公路工程, 2012, 37(5):87-91. (DU Yongli. PSO-Gompertz model for prediction of single pile bearing capacity [J]. Highway Engineering, 2012, 37(5):87-91. (in Chinese))
- [25] 牛亚超. 基于变步长 FOA-Richards 模型的地表沉降动态预计[J]. 黑龙江工程学院学报, 2019, 33(4):17-19, 45. (NIU Yachao. Dynamic prediction of surface subsidence based on variable step size FOA-Richards model [J]. Journal of Heilongjiang Institute of Technology, 2019, 33(4):17-19, 45. (in Chinese))
- [26] 许小健, 干洪, 张金轮. 沉降预测广义 Usher 模型参数确定的优化算法[J]. 水利水电科技进展, 2010, 30(5):73-76. (XU Xiaojian, QIAN Hong, ZHANG Jinlun. Optimization algorithm for parameter determination of generalized Usher model for settlement prediction [J]. Advances in Science and Technology of Water Resources, 2010, 30(5):73-76. (in Chinese))
- [27] ZHAO W, WANG L, ZHANG Z. Artificial ecosystem-based optimization; a novel nature-inspired meta-heuristic algorithm [J]. Neural Computing and Applications, 2019(4):1-43.
- [28] 魏兰婷, 许强, 杨琴. 基于三参 Weibull 分布的泥石流降雨动态预警模型[J]. 科学技术与工程, 2015, 15(34):144-149. (WEI Lanting, XU Qiang, YANG Qin. The dynamic precipitation forecasting model of debris flow based on Weibull distribution [J]. Science Technology and Engineering, 2015, 15(34):144-149. (in Chinese))
- [29] 耿东升. 改良 Weibull 模型对药物溶出曲线的评价[J]. 药物分析杂志, 2016(11):2067-2073. (GENG Dongsheng. Evaluation of drug dissolution curve by modified weibull model [J]. Chinese Journal of Pharmaceutical Analysis, 2016(11):2067-2073. (in Chinese))
- [30] 高洁, 王建伟, 李琳娜. 基于 Richards-BP 神经网络的交通运输碳排放量组合预测模型[J]. 长安大学学报(自然科学版), 2013, 33(4):99-105. (GAO Jie, WANG Jianwei, LI Linna. A combined model of Richards model and BP neural network to predict transportation carbon emission [J]. Journal of Chang'an University (Natural Science Edition), 2013, 33(4):99-105. (in Chinese))
- [31] 陈国飞, 孙艾茵, 唐海, 等. 基于 Usher 模型及水驱特征曲线的综合预测模型[J]. 新疆石油地质, 2016, 37(2):231-235. (CHEN Guofei, SUN Aiyin, TANG Hai, et al. A comprehensive prediction model based on usher model and water drive characteristic curves [J]. Xinjiang Petroleum Geology, 2016, 37(2):231. (in Chinese))
- (收稿日期:2019-11-26 编辑:王芳)

(上接第 121 页)

- [26] ZHANG Chiqian, LIANG Zhihua, HU Zhiqiang. Bacterial response to a continuous long-term exposure of silver nanoparticles at sub-ppm silver concentrations in a membrane bioreactor activated sludge system [J]. Water Research, 2014, 50(3):350-358.
- [27] 江用彬. 莱茵衣藻(*Chlamydomonas reinhardtii*)对镉污染水体的生物修复研究[D]. 北京:首都师范大学, 2007.
- [28] JOO S H, ZHAO D. Environmental dynamics of metal oxide nanoparticles in heterogeneous systems: a review [J]. Journal of Hazardous Materials, 2016, 322:29-47.
- [29] 支田田, 程丽华, 徐新华, 等. 藻类去除水体中重金属的机理及应用[J]. 化学进展, 2011(8):1782-1794. (ZHI Tiantian, CHENG Lihua, XU Xinhua, et al. Advances on heavy metals removal from aqueous solution by algae [J]. Progress in Chemistry, 2011(8):1782-1794. (in Chinese))
- [30] 苗令占, 王沛芳, 侯俊, 等. 金属纳米材料对不同微生物聚集体的毒性研究进展[J]. 水资源保护, 2019, 35(1):73-78. (MIAO Lingzhan, WANG Peifang, HOU Jun, et al. Research progress on toxicity of metallic nanomaterials to different microbial aggregates [J]. Water Resources Protection, 2019, 35(1):73-78. (in Chinese))
- [31] BAALOUSHA M, SIKDER M, PRASAD A, et al. The concentration-dependent behaviour of nanoparticles [J]. Environmental Chemistry, 2016, 13(1):1-3.
- [32] 侯俊, 次瀚林, 吕博文, 等. 典型人工纳米材料的水环境行为研究进展[J]. 水资源保护, 2017, 33(6):1-8. (HOU Jun, CI Hanlin, LYU Bowen, et al. Research progress of water environment behavior of typical engineered nanomaterials [J]. Water Resources Protection, 2017, 33(6):1-8. (in Chinese))
- [33] VALE G, MEHENNAOUI K, CAMBIER S, et al. Manufactured nanoparticles in the aquatic environment-biochemical responses on freshwater organisms: a critical overview [J]. Aquatic Toxicology, 2016, 170(4):162-174.
- [34] 马偲. 水中纳米颗粒的自团聚及与藻细胞的异团聚[D]. 杭州:浙江大学, 2014.
- (收稿日期:2019-04-10 编辑:王芳)