

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

崔东文

(云南省文山州水务局, 云南 文山 663000)

摘要:采用 5 个标准测试函数对多组群教学优化 (MGTLO) 算法进行仿真验证, 并将仿真结果与基本教学优化 (TLBO) 算法、混合蛙跳算法 (SFLA)、差分进化 (DE) 算法和粒子群优化 (PSO) 算法的仿真结果进行对比。利用 MGTLO 算法搜寻基于广义回归神经网络 (GRNN)、径向基神经网络 (RBF)、支持向量机 (SVM) 模型单元的组合模型的最佳模型参数和组合权重系数, 提出 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 4 种组合预测模型, 以新疆伊犁河雅马渡水文站和云南省某水文站年径流量预测为例进行了实例分析, 并将预测结果与 MGTLO-GRNN、MGTLO-RBF、MGTLO-SVM 和 GRNN、RBF、SVM 6 种单一模型的结果进行对比分析。结果表明: MGTLO 算法寻优精度优于 TLBO、SFLA、DE 和 PSO 算法, 具有较好的收敛速度和全局极值寻优能力; 组合模型融合了 MGTLO 算法与 GRNN、RBF、SVM 模型单元的优点, 在预测精度、泛化能力等方面均优于单一模型; MGTLO 算法能有效优化各组合模型的相关参数和权重系数, MGTLO-GRNN-RBF-SVM 模型预测精度最高。

关键词:径流预测; 多组群教学优化算法; 广义回归神经网络; 径向基神经网络; 支持向量机; 参数优化
中图分类号:TV213 **文献标志码:**A **文章编号:**1006-7647(2019)04-0041-08

Combined model of multi-group teaching optimization algorithm-neural network-support vector machine in runoff prediction application//CUI Dongwen (*Wenshan Water Bureau of Yunnan Province, Wenshan 663000, China*)

Abstract: Five standard test functions were used to verify the multi-group teaching optimization (MGTLO) algorithm, and the simulation results were compared with those of the basic teaching optimization (TLBO) algorithm, shuffled frog leaping algorithm (SFLA), differential evolution (DE) algorithm and particle swarm optimization (PSO) algorithm. MGTLO was used to search for the optimum model parameters and the weight coefficients of the combined model based on the generalized regression neural network (GRNN), the radial basis function neural network (RBF) and the support vector machine (SVM) model elements. Four combined prediction models, including MGTLO-GRNN-RBF, MGTLO-GRNN-SVM, MGTLO-RBF-SVM, and MGTLO-GRNN-RBF-SVM were proposed and case studies of the runoff prediction were performed at the Yamadu Hydrological Station of the Yili River in Xinjiang and a hydrological station in Yunnan Province. The predicted results were compared with the following six single models, MGTLO-GRNN, MGTLO-RBF, MGTLO-SVM, GRNN, RBF and SVM. The results show that the optimization accuracy of MGTLO algorithm is better than that of TLBO, SFLA, DE and PSO, with good convergence speed and global optimization ability. The combined model merges the advantages of MGTLO algorithm, GRNN, RBF, and SVM model elements. It is superior to single models in terms of prediction accuracy and generalization ability. MGTLO algorithm can effectively optimize the parameters and weight coefficients of the combined models and the MGTLO-GRNN-RBF-SVM model has the highest prediction accuracy.

Key words: runoff forecasting; multi-group teaching optimization algorithm; generalized regression neural network; radial basis function neural network; support vector machine; parameter optimization

由于河川径流预测的复杂性、非线性、随机性和不确定性, 传统回归分析、数理统计等方法往往难以达到理想的预测效果。广义回归神经网络 (generalized regression neural network, GRNN)、径向

基神经网络 (radial basis function, RBF) 和支持向量机 (support vector machines, SVM) 因所具有的高容错性、智能化和自学习等能力已在水文预测预报中得到广泛应用^[1-6]。然而, 在径流预测预报中,

GRNN、RBF、SVM 模型存在两方面不足:①单一预测模型存在一定的局限性,如 GRNN 存在因训练样本过度训练而导致检验样本预测精度下降等不足;RBF 存在因训练样本训练不充分而导致泛化能力降低等问题;SVM 存在惩罚因子、核函数参数等难以确定的缺点。②难以合理选取 GRNN、RBF、SVM 模型参数,如 GRNN 的光滑因子、RBF 的均方误差、径向基函数扩展速度、SVM 的惩罚因子、核函数参数等。实例研究表明,模型参数的合理选取是提高 GRNN、RBF、SVM 模型预测精度的关键因素。目前 GRNN、RBF、SVM 模型参数的选取普遍采用人工试错的方法进行调试确定,极大地制约了 GRNN、RBF、SVM 在水文预测预报中的应用。为提高水文预测预报精度,组合预测模型^[7-8]被提出。组合模型的构成单元主要有回归模型单元^[9]、神经网络模型单元^[7]、混合组合模型单元^[10]等;组合模型的组合方法主要有加权平均法^[8,11]、线性组合法^[12]等。

近年来,基于模仿生物机制或自然现象的随机优化技术越来越受到各行业领域的重视,各种基于某一生物社会群体行为或自然物理现象的随机优化算法被一一提出,如多元优化算法^[2]、果蝇优化算法^[13]、蚁群优化算法^[14]、人工鱼群算法^[15]、粒子群优化算法^[6]、灰狼优化算法^[16]、花授粉算法^[16]等,并成功用于优化 GRNN、RBF、SVM 模型相关参数。

为进一步提高年径流量预测精度,本文通过 5 个标准测试函数对多组群教学优化 (multi-group teaching-learning optimization, MGTLO) 算法进行仿真验证,提出基于 MGTLO 算法与 GRNN、RBF、SVM 模型单元融合的 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合预测模型,以新疆伊犁河雅马渡水文站和云南省某水文站年径流量预测为例进行实例研究。

1 多组群教学优化算法及其验证

1.1 多组群教学优化算法

教学优化(TLBO)算法是 Rao 等^[17]于 2012 年提

出的新型全局优化算法,该算法分为教师阶段和学生阶段,教师阶段通过教师传授学生知识来提高班级学习成绩;学生阶段通过学生之间互相学习提高班级创造性,通过这两个阶段不断提高学生成绩来获得问题最优解。TLBO 算法调节参数少,算法简单,但存在收敛速度慢,寻优精度低等不足^[18]。多组群教学优化 (MGTLO) 算法是 Kommadath 等^[19]提出的一种基于多组群改进的教学优化算法,该算法利用分组策略定义学生(种群)数量、组数和每组学生数量,通过选择每组学生中适应度值最好的学生作为该组教师并对各组教师适应度值进行比较,最终确定所有组学生中适应度值最好的学生作为教师,即待优化问题最优解,该算法的具体实现步骤参见文献[19]。

1.2 算法验证

为验证 MGTLO 算法寻优能力,选取 5 个标准测试函数(表 1)对其进行仿真验证,求测试函数的极值,并将其结果与基本 TLBO 算法以及混合蛙跳算法 (shuffled frog leaping algorithm, SFLA)、差分进化 (differential evolution, DE) 算法、粒子群优化 (particle swarm optimization, PSO) 算法的仿真结果进行对比。

5 种算法参数设置如下:MGTLO 算法最大迭代次数 $T=1000$, 学生规模(种群) $N=50$, 组数 $G=5$; TLBO 算法 $T=1000$, $N=100$; SLFA 算法 $T=1000$, $N=50$, 子群数 $K=5$, 子群内青蛙个数 $N_p=10$, 子群数局部进化次数 $T_1=10$; DE 算法 $T=1000$, $N=50$, 上下限的尺度因子分别为 0.8、0.2, 交叉率 $C_r=0.2$; PSO 算法 $T=1000$, $N=50$, 惯性因子 $\kappa=0.729$, 局部学习因子、全局学习因子 $c_1=c_2=2.0$, 个体速度限制为 $[-0.1, 0.1]$ 。

采取 5 种算法均对测试函数寻优 20 次,利用 20 次寻优结果的平均值、标准差及平均单次运行时间(表 2)对各种算法的优化性能进行评估。其中,平均值用于反映算法的寻优精度;标准差用于反映算法的稳定性;平均运行时间用于反映算法的寻优时效性。

表 1 基准函数

函数名	表达式	维数 D	取值范围	理论最优解
Quartic	$g_1 = \sum_{i=1}^D ix_i^4 + \text{rand}()$	30	$[-1.28, 1.28]$	$\text{ming}_1 = 0$
Rosenbrock	$g_2 = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2) + (1 - x_i)^2]$	30	$[-10, 10]$	$\text{ming}_2 = 0$
Griewank	$g_3 = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	$\text{ming}_3 = 0$
Rastrigin	$g_4 = \sum_{i=1}^D [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	$\text{ming}_4 = 0$
Ackley	$g_5 = -20\exp\left(-0.2\sqrt{\frac{1}{D}\sum_{i=1}^D x_i^2}\right) - \exp\left[\frac{1}{D}\sum_{i=1}^D \cos(2\pi x_i)\right] + 20 + e$	30	$[-32, 32]$	$\text{ming}_5 = 0$

表 2 函数优化对比结果

函数名	算法	平均值	标准差	平均单次寻优时间/s
Quartic	MGTLO	2.01×10^{-4}	8.96×10^{-5}	0.468
	TLBO	4.87×10^{-4}	1.45×10^{-4}	5.860
	SFLA	4.04×10^{-3}	1.91×10^{-3}	20.600
	DE	2.26×10^{-2}	5.54×10^{-3}	4.070
	PSO	2.03×10^{-2}	4.44×10^{-3}	2.350
Rosenbrock	MGTLO	19.20	3.03×10^{-1}	0.322
	TLBO	23.70	6.27×10^{-1}	4.010
	SFLA	21.80	1.41×10^1	17.500
	DE	27.40	4.50	6.480
	PSO	99.30	5.71×10^1	0.537
Griewank	MGTLO	0	0	0.784
	TLBO	0	0	3.520
	SFLA	9.72×10^{-3}	1.11×10^{-2}	25.500
	DE	9.81×10^{-11}	9.83×10^{-11}	8.210
	PSO	6.69×10^{-1}	2.15×10^{-1}	8.890
Rastrigin	MGTLO	0	0	0.978
	TLBO	7.24×10^{-1}	1.08×10^3	5.480
	SFLA	69.70	14.40	22.800
	DE	59.40	5.48	10.700
	PSO	47.20	1.36×10^1	10.900
Ackley	MGTLO	4.11×10^{-15}	7.88×10^{-16}	0.814
	TLBO	6.70×10^{-15}	1.69×10^{-15}	6.320
	SFLA	2.88×10^{-1}	5.02×10^{-1}	17.700
	DE	6.22×10^{-7}	1.38×10^{-7}	8.290
	PSO	2.10	4.84×10^{-1}	8.600

从表 2 可以得出:①从单峰函数 Quartic 和 Rosenbrock 的寻优效果来看, MGTLO 算法的寻优平均值、标准差均优于其他 4 种算法, 表明 MGTLO 算法具有较好的寻优精度和稳定性能。从多峰函数 Griewank 的寻优效果来看, MGTLO 算法、TLBO 算法的寻优平均值、标准差均为 0, 寻优精度和稳定性优于 SFLA、DE 和 PSO 算法; 对于 Rastrigin 和 Ackley 函数, MGTLO 算法寻优精度和稳定性优于其他 4 种算法。以上表明 MGTLO 算法具有较好的跳出局部极值能力、全局极值寻优能力。②从平均运行时间来看, MGTLO 算法对 5 个函数的平均运行时间在 0.322 ~ 0.978 s 之间, 平均不到其他 4 种算法平均运行时间的 1/5, 表现出较好的寻优时效性。由此可见, 对于单峰或多峰函数, MGTLO 算法无论是从算法的寻优精度和稳定性能上看, 还是算法的寻优时效性和跳出局部极值的能力而言, 其寻优效果均优于其他 4 种算法。

2 组合预测模型

2.1 单一模型

2.1.1 广义回归神经网络

GRNN 是一种高度并行径向基网络, 由输入层、模式层、求和层和输出层组成^[2,20-21], 应用 Parzen 非参数估计的方法可知在输入为 \mathbf{X} 的条件下, 网络的

输出 $\hat{Y}(\mathbf{X})$ 为

$$\hat{Y}(\mathbf{X}) = \frac{\sum_{i=1}^n Y_i \exp\left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}\right]} \quad (1)$$

式中: \mathbf{X}_i 、 Y_i 为两个随机变量的样本观测值; n 为样本容量; σ 为高斯函数的宽度系数, 即光滑因子。

光滑因子 σ 的合理选取是提高 GRNN 预测精度的关键, 当 σ 取值较大时, $\hat{Y}(\mathbf{X})$ 近似于所有样本的均值, 网络欠拟合; 当 σ 取值较小趋于 0 时, $\hat{Y}(\mathbf{X})$ 和训练样本非常接近, 网络过拟合; 只有当 σ 取值适中时, $\hat{Y}(\mathbf{X})$ 才会考虑到所有训练样本的因变量^[2,20-21]。本文基于 Matlab 神经网络工具箱, 利用 MGTLO 算法寻优 Matlab 神经网络工具箱中 newgrnn() 函数的最佳 Spread 参数值, 即光滑因子 σ 。

2.1.2 径向基神经网络

RBF 是前向神经网络, 由输入层、隐含层和输出层组成, 其数学模型为^[22]

$$y = \sum_{i=1}^n \varphi_i \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\gamma^2}\right) \quad (2)$$

式中: y 为输出值; \mathbf{x} 为 RBF 输入向量; φ_i 为 RBF 隐含层和输出层之间的权值; \mathbf{c}_i 为 RBF 中心节点向量; γ 为中心节点宽度。

研究表明, 径向基函数扩展速度 s 对 RBF 预测精度有着关键性影响, s 越大, 函数拟合越平滑, 但过大的 s 意味着需要更多的神经元以适应函数的快速变化; s 过小, 则会导致网络拟合效果不理想。均方误差 e 设置过小, 会导致网络过拟合而降低其泛化能力; e 设置过大则会导致网络欠拟合而得不到理想的预测效果。设置合理的神经元最大数目 M 和两次显示之间所添加神经元数目 F 可有效平衡 RBF 的收敛速度和预测精度。本文基于 Matlab 神经网络工具箱, 利用 MGTLO 算法搜寻 Matlab 神经网络工具箱中 newrb() 函数的最佳参数 e 、 s 、 M 、 F 。

2.1.3 支持向量机

SVM 是通过核函数将低维空间中非线性回归问题映射到高维特征空间, 然后在高维特征空间中求解凸优化问题。设含有 l 个训练样本的集合为 $\{(\mathbf{x}_i, y_i), i=1, 2, \dots, l\}$, $\mathbf{x}_i \in \mathbf{R}^D$ 为第 i 个训练样本输入列向量, $y_i \in \mathbf{R}$ 为第 i 个样本输出变量的实测值^[16,23], 则在高维特征空间中建立的最终回归函数为

$$f(\mathbf{x}) = \sum_{i=1}^l (a_i - a_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \quad (3)$$

式中: a_i^* 、 a_i 为二次规划中 Lagrange 乘子; b 为超平面的偏移量; $K(\mathbf{x}_i, \mathbf{x})$ 为满足 Mercer 条件的核函数, $K(\mathbf{x}_i, \mathbf{x}) = \Phi(\mathbf{x}_i) \Phi(\mathbf{x})$, $\Phi(\mathbf{x})$ 为非线性映射函数。

选择径向基核函数作为 SVM 核函数,径向基核函数表达式为

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-g \|\mathbf{x} - \mathbf{x}_i\|^2) \quad (4)$$

式中: g 为核函数参数, $g > 0$ 。

研究表明,惩罚因子 C 、核函数参数 g 和不敏感系数 ε 的合理选取决定着 SVM 性能^[16,23]。 C 取值过小易导致网络欠拟合, C 取值过大则网络过拟合,导致网络泛化能力差; g 代表 RBF 带宽, g 取值小则拟合误差小,但过小的 g 值会导致模型过拟合; ε 值用于控制模型的预测能力, ε 值小易导致模型欠拟合, ε 值大则易导致模型过拟合。本文基于 libsvm 工具箱,利用 MGTLO 算法优化 SVM 的参数 C 、 g 和 ε 。

2.2 组合模型构建及实现步骤

本文提出的 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合模型构建的基本思路是:基于

$$\begin{cases} \min f_1(\sigma, e, s, M, F, \omega_{\text{GRNN}}) = \omega_{\text{GRNN}} f_{\text{GRNN}} + (1 - \omega_{\text{GRNN}}) f_{\text{RBF}} = \omega_{\text{GRNN}} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} + (1 - \omega_{\text{GRNN}}) \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \\ \text{s. t. } \sigma \in [\sigma_{\min}, \sigma_{\max}], e \in [e_{\min}, e_{\max}], s \in [s_{\min}, s_{\max}], M \in [M_{\min}, M_{\max}], F \in [F_{\min}, F_{\max}], \omega_{\text{GRNN}} \in [0, 1] \end{cases} \quad (5)$$

$$\begin{cases} \min f_2(\sigma, C, g, \varepsilon, \omega_{\text{GRNN}}) = \omega_{\text{GRNN}} f_{\text{GRNN}} + (1 - \omega_{\text{GRNN}}) f_{\text{SVM}} = \omega_{\text{GRNN}} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} + (1 - \omega_{\text{GRNN}}) \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \\ \text{s. t. } \sigma \in [\sigma_{\min}, \sigma_{\max}], C \in [C_{\min}, C_{\max}], g \in [g_{\min}, g_{\max}], \varepsilon \in [\varepsilon_{\min}, \varepsilon_{\max}], \omega_{\text{GRNN}} \in [0, 1] \end{cases} \quad (6)$$

$$\begin{cases} \min f_3(e, s, M, F, C, g, \varepsilon, \omega_{\text{RBF}}) = \omega_{\text{RBF}} f_{\text{RBF}} + (1 - \omega_{\text{RBF}}) f_{\text{SVM}} = \omega_{\text{RBF}} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} + (1 - \omega_{\text{RBF}}) \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \\ \text{s. t. } e \in [e_{\min}, e_{\max}], s \in [s_{\min}, s_{\max}], M \in [M_{\min}, M_{\max}], F \in [F_{\min}, F_{\max}], C \in [C_{\min}, C_{\max}], g \in [g_{\min}, g_{\max}], \\ \varepsilon \in [\varepsilon_{\min}, \varepsilon_{\max}], \omega_{\text{RBF}} \in [0, 1] \end{cases} \quad (7)$$

$$\begin{cases} \min f_4(\sigma, e, s, M, F, C, g, \varepsilon, \omega_{\text{RBF}}) = \omega_{\text{GRNN}} f_{\text{GRNN}} + \omega_{\text{RBF}} f_{\text{RBF}} + (1 - \omega_{\text{GRNN}} - \omega_{\text{RBF}}) f_{\text{SVM}} = \omega_{\text{GRNN}} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} + \\ \omega_{\text{RBF}} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} + (1 - \omega_{\text{GRNN}} - \omega_{\text{RBF}}) \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \\ \text{s. t. } \sigma \in [\sigma_{\min}, \sigma_{\max}], e \in [e_{\min}, e_{\max}], s \in [s_{\min}, s_{\max}], M \in [M_{\min}, M_{\max}], F \in [F_{\min}, F_{\max}], C \in [C_{\min}, C_{\max}], \\ g \in [g_{\min}, g_{\max}], \varepsilon \in [\varepsilon_{\min}, \varepsilon_{\max}], \omega_{\text{GRNN}} \in [0, 0.5], \omega_{\text{RBF}} \in [0, 0.5] \end{cases} \quad (8)$$

式中: f_1 、 f_2 、 f_3 、 f_4 分别为 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合模型的适应度函数; \hat{y}_i 为第 i 个样本输出变量的模拟值; f_{GRNN} 、 f_{RBF} 、 f_{SVM} 分别为 GRNN、RBF、SVM 的适应度函数; ω_{GRNN} 、 ω_{RBF} 分别为 GRNN 模型、RBF 模型的权重系数;下标 min 和 max 分别表示变量的最小值和最大值。

步骤 3 初始化参数。设置算法最大迭代次数 T 、学生规模(种群) N 和组数 G 、变量维度 D 及变量上、下限值;设置当前迭代次数 $t=0$ 。

步骤 4 基于式(5)~(8)计算每组学生适应度值,确定组内具有最佳适应度 f_{best} 的学生作为该

GRNN、RBF、SVM 模型单元两两组合及全部组合,得到 GRNN-RBF、GRNN-SVM、RBF-SVM、GRNN-RBF-SVM 4 种组合模型,确定各组合模型待优化目标函数和相关参数、组合权重系数搜索范围,利用 MGTLO 算法对各组合模型进行优化,将优化获得的最佳参数和权重系数代入各组合模型进行预测。

4 种组合模型预测实现步骤可归纳如下:

步骤 1 选取训练样本和检验样本并对其进行归一化处理,设定组合模型 σ 、 e 、 s 、 M 、 F 、 C 、 g 、 ε 、模型单元权重系数 ω 的搜寻范围。由于 M 、 F 需为整数,本文采用 fix 函数对其进行取整。

步骤 2 确定各组合模型适应度函数。适应度函数是描述种群个体优劣程度的主要指标,本文选用平均相对误差绝对值之和作为适应度函数。各组合模型适应度函数描述如下:

组教师 \mathbf{X}_{best} ,并确定该组决策变量平均值 $\bar{\mathbf{X}}$,利用式(9)确定该组中成员 g 的教学因子 T_g :

$$T_g = \frac{f_g}{f_{\text{best}}} \quad (9)$$

式中: f_g 为学生 \mathbf{X}_g 的适应度值。如果 $f_{\text{best}}=0$,那么 T_g 被赋值 1。

步骤 5 随机分配给该组中每个成员一个合作伙伴,利用下式生成潜在学生 \mathbf{X}_{new} :

$$\mathbf{X}_{\text{new}}(t) = \begin{cases} \mathbf{X}_g(t) + [\mathbf{X}_{\text{best}}(t) - T_g \bar{\mathbf{X}}(t)] \mathbf{r}' \\ a_g \mathbf{r}' [\mathbf{X}_p(t) - \mathbf{X}_g(t)] & \text{rand}[0, 1] < 0.5 \\ \mathbf{X}_g(t) + a_g \mathbf{r}' [\mathbf{X}_p(t) - \mathbf{X}_g(t)] + \\ [\mathbf{X}_{\text{best}}(t) - E_g \mathbf{X}(t)] \mathbf{r}' & \text{rand}[0, 1] \geq 0.5 \end{cases} \quad (10)$$

式中： r, r' 为 $[0, 1]$ 之间生成的随机向量； X_p 为 X_g 的合作伙伴； a_g 为参数，如果 f_g 优于 X_p 的适应度值 f_p ，则参数 $a_g = -1$ ；否则，参数 $a_g = 1$ ； E_g 为 $[1, 2]$ 上随机选择的探索因子。

步骤6 对潜在学生 X_{new} 进行约束，并计算其适应度值 f_{new} ，如果 f_{new} 优于 f_g ，则 X_{new} 代替 X_g ，否则舍去 X_{new} 。

步骤7 合并所有组学生，并确定所有组学生中适应度值最好的学生作为教师。

步骤8 令 $t=t+1$ ，判断算法是否达到最大迭代次数 T 。若达到，则输出所有组学生中最佳适应度值及对应教师；否则转至步骤4，直到满足算法终止条件，算法结束。

步骤9 输出教师所处空间位置及所对应的适应度值，即待优化问题最优解及最优适应度值。

步骤10 将 MGTLO 算法优化获得的 $\sigma, e, s, M, F, C, g, \varepsilon$ 和权重系数 ω 代入各组合模型进行预测。

3 算例分析

3.1 数据来源

3.1.1 算例1

以新疆伊犁河雅马渡水文站径流预测为例进行实例分析，数据来源参见文献[24]。影响径流预测的4个预报因子分别为： X_1 为前1年11月至当年3月伊犁气象站的总降水量； X_2 为前1年8月欧亚地区月平均纬向环流指数； X_3 为前1年6月欧亚地区月平均径向环流指数； X_4 为前1年6月2800 MHz 太阳射电流量。

为便于与相关文献[24-28]进行对比，将 $X_1 \sim X_4$ 作为年径流量预测的影响因子，以前17年实测资料为训练样本，后6年资料作为预测样本，并利用下式对该站各径流序列进行归一化处理：

$$\hat{x} = 0.1 + (0.9 - 0.1) \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中： \hat{x} 为经过标准化处理的数据； x 为原始数据； x_{\max} 和 x_{\min} 分别为数据序列中的最大数和最小数。

3.1.2 算例2

以云南省某水文站1962—2005年44年的实测资料为例进行实例研究，利用SPSS软件分析该站年径流量与1—10月月均流量的相关性，分析结果见表3。

从表3可以看出，年径流量与1—10月月均流量均呈正相关关系，相关系数在0.056~0.727之间，相关性并不十分显著。本文选取在0.01水平(双侧)上显著相关的该站5—10月月均流量作为年径流量预

测的影响因子，以1962—1991年共30年实测资料为训练样本，1992—2005年共14年资料为预测样本，利用式(11)对该站各径流序列进行归一化处理。

表3 年径流量与1—10月月均流量的相关系数

月份	相关系数	月份	相关系数
1	0.056	6	0.681**
2	0.185	7	0.593**
3	0.088	8	0.727**
4	0.374*	9	0.713**
5	0.576**	10	0.684**

注：“**”表示在0.01水平(双侧)上显著相关；“*”表示在0.05水平(双侧)上显著相关。

3.2 模型构建与参数设置

3.2.1 模型构建

基于 Matlab R2011b 软件环境创建4输入、1输出的 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合模型及 MGTLO-GRNN、MGTLO-RBF、MGTLO-SVM、GRNN、RBF、SVM 单一模型对雅马渡水文站年径流量进行预测，创建6输入、1输出的4个组合模型和6个单一模型对云南省某水文站年径流量进行预测。选取平均相对误差绝对值(M_{RE})和均方根误差(R)对各模型的预测效果进行评价。

3.2.2 参数设置

两个算例的参数设置均相同，即 MGTLO 算法 $T=100, N=50, G=5$ 。各模型待优化参数搜索空间设置为： $\sigma \in [0.0001, 10]$ 、 $e \in [0.001, 10]$ 、 $s \in [0.001, 10]$ 、 $M \in [1, 100]$ 、 $F \in [1, 100]$ 、 $C \in [2^{-10}, 2^{10}]$ 、 $g \in [2^{-10}, 2^{10}]$ 、 $\varepsilon \in [2^{-10}, 2^{10}]$ 、 $V=5$ 。MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 模型 D 分别为6、5、8和10；权重系数搜索空间见2.2节中的设定值。

3.3 预测结果

3.3.1 算例1

利用 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合模型及 MGTLO-GRNN、MGTLO-RBF、MGTLO-SVM、GRNN、RBF、SVM 单一模型对雅马渡水文站年径流量进行预测，预测结果见表4， M_{RE} 与文献[24-28]结果的对比见表5，23年的拟合和预测效果见图1。

MGTLO-GRNN-RBF 模型优化结果如下： $f_1 = 118.57, \sigma = 0.0051, e = 7.6962, s = 10.0, M = 1, F = 1, \omega_{GRNN} = 0.3931$ ；MGTLO-GRNN-SVM 模型优化结果如下： $f_2 = 135.12, \sigma = 0.0047, C = 2^{6.9160}, g = 2^{-7.7548}, \varepsilon = 2^{-10}, \omega_{GRNN} = 0.1036$ ；MGTLO-RBF-SVM 模型优化结果如下： $f_3 = 139.47, e = 0.0010, s = 3.6194, M = 39, F = 30, C = 2^{2.9734}, g = 2^{-3.9956}, \varepsilon =$

表4 新疆伊犁河雅马渡站年径流量预测结果

模型	$M_{RE}/\%$	R
MGTLO-GRNN-RBF 模型	4.31	21.8
MGTLO-GRNN-SVM 模型	4.54	23.0
MGTLO-RBF-SVM 模型	4.70	23.1
MGTLO-GRNN-RBF-SVM 模型	3.28	21.0
MGTLO-GRNN 模型	8.30	36.3
MGTLO-RBF 模型	7.16	30.1
MGTLO-SVM 模型	5.78	24.5
GRNN 模型	8.98	38.1
RBF 模型	10.45	48.4
SVM 模型	9.53	35.2

表6 云南省某水文站年径流量预测结果

模型	$M_{RE}/\%$	R
MGTLO-GRNN-RBF 模型	3.10	1.70
MGTLO-GRNN-SVM 模型	3.23	1.52
MGTLO-RBF-SVM 模型	2.14	1.40
MGTLO-GRNN-RBF-SVM 模型	2.10	1.15
MGTLO-GRNN 模型	5.18	2.18
MGTLO-RBF 模型	3.63	1.59
MGTLO-SVM 模型	4.21	2.15
GRNN 模型	8.63	4.16
RBF 模型	6.69	3.07
SVM 模型	4.91	2.25

表5 M_{RE} 值与相关文献预测结果比较

模型/文献	$M_{RE}/\%$	模型/文献	$M_{RE}/\%$
MGTLO-GRNN-RBF 模型	4.31	MGTLO-SVM 模型	5.78
MGTLO-GRNN-SVM 模型	4.54	文献[24]	9.17
MGTLO-RBF-SVM 模型	4.70	文献[25]	8.18
MGTLO-GRNN-RBF-SVM 模型	3.28	文献[26]	8.50
MGTLO-GRNN 模型	8.30	文献[27]	6.83
MGTLO-RBF 模型	7.16	文献[28]	7.64

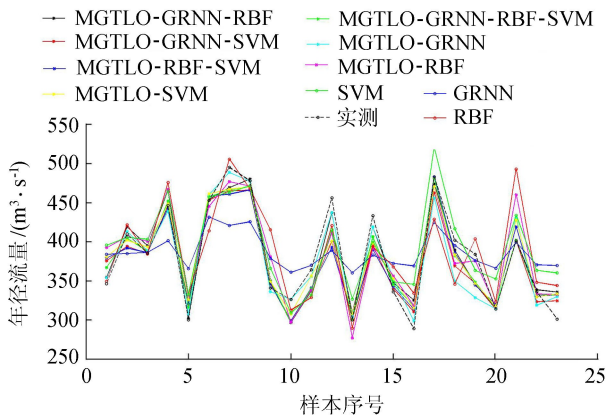


图1 新疆伊犁河雅马渡站年径流量拟合和预测效果

$2^{-8.9191}$ 、 $\omega_{RBF} = 0.1776$; MGTLO-GRNN-RBF-SVM 模型优化结果如下: $f_4 = 115.26$ 、 $\sigma = 0.0051$ 、 $e = 9.7770$ 、 $s = 9.9636$ 、 $M = 1$ 、 $F = 100$ 、 $C = 2^{6.7535}$ 、 $g = 2^{2.6153}$ 、 $\varepsilon = 2^{-9.9327}$ 、 $\omega_{GRNN} = 0.1672$ 、 $\omega_{RBF} = 0.2331$; MGTLO-GRNN 模型优化结果如下: $f_5 = 205.75$ 、 $\sigma = 0.1647$; MGTLO-RBF 模型优化结果如下: $f_6 = 158.30$ 、 $e = 8.37$ 、 $s = 1.4722$ 、 $M = 57$ 、 $F = 7$; MGTLO-SVM 模型优化结果如下: $f_7 = 154.84$ 、 $C = 2^{-0.7237}$ 、 $g = 2^{0.3657}$ 、 $\varepsilon = 2^{-10}$; GRNN 模型优化结果如下: $\sigma = 0.50$; RBF 模型优化结果如下: $e = 10$ 、 $s = 0.5$ 、 $M = 20$ 、 $F = 5$; SVM 模型优化结果如下: $C = 2^5$ 、 $g = 2^{-5}$ 、 $\varepsilon = 2^{-3}$ 。

3.3.2 算例2

利用4种组合模型及6种单一模型对云南省某水文站年径流量进行预测,预测结果见表6,44年的拟合和预测效果见图2。

MGTLO-GRNN-RBF 模型优化结果如下: $f_1 = 72.37$ 、 $\sigma = 0.0144$ 、 $e = 0.0010$ 、 $s = 9.9994$ 、 $M = 12$ 、

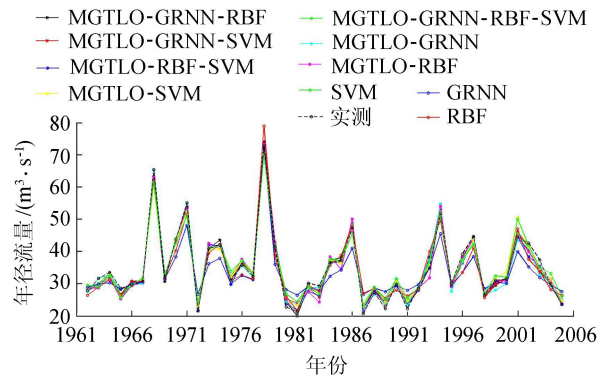


图2 云南某水文站年径流量拟合和预测效果

$F = 18$ 、 $\omega_{GRNN} = 0.2047$; MGTLO-GRNN-SVM 模型优化结果如下: $f_2 = 76.67$ 、 $\sigma = 0.0132$ 、 $C = 2^{8.1607}$ 、 $g = 2^{-9.9386}$ 、 $\varepsilon = 2^{-7.5922}$ 、 $\omega_{GRNN} = 0.1620$; MGTLO-RBF-SVM 模型优化结果如下: $f_3 = 49.15$ 、 $e = 0.0010$ 、 $s = 0.3530$ 、 $M = 84$ 、 $F = 49$ 、 $C = 2^{8.6689}$ 、 $g = 2^{-10}$ 、 $\varepsilon = 2^{-7.9129}$ 、 $\omega_{RBF} = 0.3858$; MGTLO-GRNN-RBF-SVM 模型优化结果如下: $f_4 = 50.44$ 、 $\sigma = 0.0275$ 、 $e = 0.0760$ 、 $s = 0.4352$ 、 $M = 1$ 、 $F = 7$ 、 $C = 2^{2.6752}$ 、 $g = 2^{-4.9757}$ 、 $\varepsilon = 2^{-4.9992}$ 、 $\omega_{GRNN} = 0.1472$ 、 $\omega_{RBF} = 0.0433$; MGTLO-GRNN 模型优化结果如下: $f_5 = 127.49$ 、 $\sigma = 0.1234$; MGTLO-RBF 模型优化结果如下: $f_6 = 83.68$ 、 $e = 0.0010$ 、 $s = 0.7086$ 、 $M = 33$ 、 $F = 43$; MGTLO-SVM 模型优化结果如下: $f_7 = 102.26$ 、 $C = 2^{0.8580}$ 、 $g = 2^{-3.6930}$ 、 $\varepsilon = 2^{-5}$; GRNN 模型优化结果如下: $\sigma = 0.30$; RBF 模型优化结果如下: $e = 20$ 、 $s = 1$ 、 $M = 100$ 、 $F = 10$; SVM 模型优化结果如下: $C = 2^{10}$ 、 $g = 2^{-4}$ 、 $\varepsilon = 2^{-4}$ 。

3.4 预测结果分析

由表4~表6及图1和图2可以看出:

a. 对于算例1,4种组合模型预测的平均相对误差绝对值在3.28%~4.70%之间,均方根误差在21.0~23.0之间,优于6种单一模型和文献[24-28]的预测精度,尤以MGTLO-GRNN-RBF-SVM模型预测效果最好;对于算例2,4种组合模型预测的平均相对误差绝对值在2.10%~3.23%之间,均方根误差在1.15~1.70之间,优于6种单一模型,

尤以 MGTLO-GRNN-RBF-SVM 模型预测精度最高,表明 MGTLO-GRNN-RBF-SVM 组合模型能有效融合 GRNN、RBF、SVM 模型单元的优点,利用 MGTLO 算法优化 GRNN、RBF、SVM 模型相关参数和 GRNN 权重系数 ω_{GRNN} 、RBF 权重系数 ω_{RBF} 能有效提高组合模型的预测精度和泛化能力。组合的模型单元数越多,预测效果越好,但同时优化算法的寻优能力要求也较高。

b. 从各组合模型预测效果和适应度函数寻优值来看,适应度函数值越小,各单一模型间的互补性越强,组合模型的预测精度越高,表明 MGTLO 算法能有效优化各组合模型相关参数和权重系数。

c. 从图 1 和图 2 来看,组合模型对训练样本和预测样本具有较好的拟合和预测效果。对于单一模型,MGTLO-GRNN 模型的拟合效果好,但泛化能力差,表现出过拟合特征;MGTLO-RBF 模型的拟合效果差,但预测效果好,表现出欠拟合特征;MGTLO-SVM 模型拟合、预测效果均较好,但拟合、预测效果劣于各组合模型。

d. 从两个实例预测效果来看,MGTLO-GRNN、MGTLO-RBF、MGTLO-SVM 模型预测精度均优于其对应的 GRNN、RBF、SVM 模型,表明 MGTLO 能有效优化 GRNN、RBF、SVM 关键参数,优于传统的人工试凑法。

4 结 论

a. 通过 5 个典型测试函数对 MGTLO 算法进行仿真验证,并与基本 TLBO 算法以及 SFLA、DE、PSO 算法的仿真结果进行对比,结果表明 MGTLO 算法具有较好的寻优精度、收敛速度和全局极值寻优能力,是一种全新高效的全局优化算法。

b. 利用 MGTLO 算法优化基于 GRNN、RBF、SVM 模型单元的组合模型的适应度函数以获得各组合模型的相关参数和权重系数,提出 MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合预测模型。实例预测结果表明,组合模型能有效融合 MGTLO 算法和 GRNN、RBF、SVM 模型单元的优点,从而大大提高了组合模型的预测精度;MGTLO-GRNN-RBF、MGTLO-GRNN-SVM、MGTLO-RBF-SVM、MGTLO-GRNN-RBF-SVM 组合模型用于年径流量预测是合理可行的,模型具有较好的预测精度和泛化能力,是提高预测精度的有效方法。

c. 从 MGTLO 算法优化各组合模型适应度函数获得的结果来看,其适应度函数值越小,组合模型的预测效果越好,其中尤以 MGTLO-GRNN-RBF-SVM

模型预测精度最高,表明 MGTLO 算法能有效优化各组合模型的相关参数和权重系数;组合的模型单元越多,预测效果越好。

参考文献:

- [1] 覃光华,宋克超,周泽江,等. 基于 WA-GRNN 模型的年径流预测[J]. 四川大学学报(工程科学版),2013,45(6): 39-46. (QIN Guanghua, SONG Kechao, ZHOU Zejiang, et al. Research on annual runoff prediction based on WA-GRNN model[J]. Journal of Sichuan University (Engineering Science Edition), 2013, 45(6): 39-46. (in Chinese))
- [2] 崔东文,吴盛华. MVO-GRNN 模型在年径流丰枯分类中的应用[J]. 人民珠江,2015,36(6): 50-54. (CUI Dongwen, WU Shenghua. Application of MVO-GRNN model in the classification of annual runoff bleeding[J]. Pearl River, 2015, 36(6): 50-54. (in Chinese))
- [3] 黄剑竹. 改进 RBF-Adaboost 模型及其在年径流预测中的应用[J]. 人民珠江,2015,36(1): 32-36. (HUANG Jianzhu. Modified RBF-Adaboost model and its application in annual runoff prediction[J]. Pearl River, 2015, 36(1): 32-36. (in Chinese))
- [4] 任磊,岳春芳,何训江. RBF 神经网络模型在金沟河流域径流预测中的应用[J]. 水资源与水工程学报,2011,22(1): 94-97. (REN Lei, YUE Chunfang, HE Xunjiang. Application of RBF neural network model to the prediction of runoff in Jingouhe River Basin[J]. Journal of Water Resources and Water Engineering, 2011, 22(1): 94-97. (in Chinese))
- [5] 崔东文. 基于多元变量组合的回归支持向量机集成模型及其应用[J]. 水利水运工程学报,2014,39(1): 66-73. (CUI Dongwen. A regression support vector machine integrated model based on multivariate combinations and its application[J]. Hydro-Science and Engineering, 2014, 39(1): 66-73. (in Chinese))
- [6] 崔东文,金波. 基于改进的回归支持向量机模型及其在年径流预测中的应用[J]. 水力发电学报,2015,34(2): 7-14. (CUI Dongwen, JIN Bo. Improved support vector machine regression model and its application to annual runoff forecasting[J]. Journal of Hydroelectric Engineering, 2015, 34(2): 7-14. (in Chinese))
- [7] 崔东文. 多重组合神经网络模型在年径流预测中的应用[J]. 水利水电科技进展,2014,34(2): 59-63. (CUI Dongwen. Application of multiple combined neural network model in annual runoff prediction[J]. Advances in Science and Technology of Water Resources, 2014, 34(2): 59-63. (in Chinese))
- [8] 韩锐,董增川,王雪薇,等. 加权平均集成模型在径流预测中的应用[J]. 人民黄河,2017,39(6): 16-20. (HAN Rui, DONG Zengchuan, WANG Xuewei, et al.

- Application of weighted average integrated model in runoff forecasting[J]. Yellow River, 2017, 39(6): 16-20. (in Chinese))
- [9] 李佩,彭斯俊.一种新的组合权重在组合预测模型中的应用[J].河南科技大学学报(自然科学版),2018, 39(2): 87-93. (LI Pei, PENG Sijun. Application of new combination weight to combination forecasting model[J]. Journal of Henan University of Science and Technology (Natural Science), 2018, 39(2): 87-93. (in Chinese))
- [10] 马辉,孙颖桃,肖艳,等.基于灰色-BP神经网络组合模型的水位预测案例[J].人民黄河,2016, 38(12): 89-92. (MA Hui, SUN Yingtao, XIAO Yan, et al. Case analysis of water level prediction based on grey-BP neural network combinational model[J]. Yellow River, 2016, 38(12): 89-92. (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 tourban water demand forecasting[J]. Water Resources Protection, 2014, 30(2): 27-32. (in Chinese))
- [12] 谢劲峰,余娣,王新桥.变形预测的一种最优线性组合模型[J].人民黄河,2017, 39(6): 99-101. (XIE Shaofeng, SHE Di, WANG Xinqiao. An optimal linear combined model of deformation prediction [J]. Yellow River, 2017, 39(6): 99-101. (in Chinese))
- [13] 刘翠玲,张璐璐.基于FOA-GRNN油井计量原油含水率的预测[J].计算机仿真,2012, 29(11): 243-246. (LIN Cuiling, ZHANG Lulu. Application of FOA-GRNN to prediction of moisture content in crude oil of well metering[J]. Computer Simulation, 2012, 29(11): 243-246. (in Chinese))
- [14] 白继中,师彪,冯民权,等.自我调节蚁群-RBF神经网络模型在短期径流预测中的应用[J].水力发电学报,2011, 30(3): 50-56. (BAI Jizhong, SHI Biao, FENG Minquan, et al. Short-term runoff prediction based on adaptive regulation ant colony system and radial basis function neural network hybrid algorithm[J]. Journal of Hydroelectric Engineering, 2011, 30(3): 50-56. (in Chinese))
- [15] 赵丽虹,范敬柱.量子鱼群算法优化RBF网络的浮选预测模型[J].辽宁科技大学学报,2015, 38(1): 46-50. (ZHAO Lihong, FAN Jingzhu. Application of RBF-net in flotation prediction model based on quantum artificial fish school algorithm[J]. Journal of University of Science and Technology Liaoning, 2015, 38(1): 46-50. (in Chinese))
- [16] 崔东文.几种智能算法与支持向量机融合模型在中长期月径流预测中的应用[J].华北水利水电大学学报(自然科学版),2016, 37(5): 51-57. (CUI Dongwen. Application of several intelligent algorithms and support vector machine fusion model in medium and long term runoff forecasting[J]. Journal of North China University of Water Resources and Hydropower University (Natural Science), 2016, 37(5): 51-57. (in Chinese))
- [17] RAO R V, SAVASNI V J, VAKHARIA D P. Teaching-learning-based optimization: an optimization method for continuous non-linear large scale problems [J]. Information Sciences, 2012, 183(1): 1-15.
- [18] 陈得宝,魏华,邹锋,等.模拟退火教学式优化算法[J].计算机应用研究,2014, 31(12): 3353-3356. (CHEN Debao, WEI Hua, ZOU Feng, et al. Simulated annealing teaching-learning-based optimization algorithm [J]. Application Research of Computers, 2014, 31(12): 3353-3356. (in Chinese))
- [19] KOMMADATH R, SIVADURGAPRASAD C, KOTECHA P. Single phase multi-group teaching learning algorithm for single objective real-parameter numerical optimization (CEC2016) [C]//2016 IEEE Congress on Evolutionary Computation (CEC). Vancouver: IEEE, 2016: 1165-1172.
- [20] 谢习华,徐雷,谭耀,等.基于PSO-GRNN的直升机旋翼不平衡故障诊断[J].噪声与振动控制,2015, 35(2): 175-179. (XIE Xihua, XU Lei, TAN Yao, et al. Fault diagnosis of helicopter rotor's unbalance based on PSO-GRNN algorithms [J]. Noise and Vibration Control, 2015, 35(2): 175-179. (in Chinese))
- [21] 王拂晓,谭志祥,邓喀中.基于GA-GRNN的地表下沉系数预测方法研究[J].煤炭工程,2014, 46(7): 94-96. (WANG Fuxiao, TAN Zhixiang, DENG Kazhong. Study on the prediction method of surface subsidence coefficient using GA-GRNN[J]. Coal Engineering, 2014, 46(7): 94-96. (in Chinese))
- [22] 邱建东,蒋兆远.基于NLAPSO-RBF的铁路货运量预测研究[J].计算机工程与应用,2013, 49(22): 253-257. (QIU Jiandong, JIANG Zhaoyuan. Research of railway freight volume prediction based on NLA-PSO-RBF [J]. Computer Engineering and Applications, 2013, 49(22): 253-257. (in Chinese))
- [23] 刘伟,王建平,刘长虹,等.基于粒子群寻优的支持向量机番茄红素含量预测[J].农业机械学报,2012, 43(4): 143-147. (LIU Wei, WANG Jianping, LIU Changhong, et al. Lycopene content prediction based on support vector machine with particle swarm optimization [J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(4): 143-147. (in Chinese))
- [24] 廖杰,王文圣,李跃清.支持向量机及其在径流预测中的应用[J].四川大学学报(工程科学版),2006, 38(6): 24-29. (LIAO Jie, WANG Wensheng, LI Yueqing. Support vector machine method and its application to prediction of runoff[J]. Journal of Sichuan University (Engineering Sciences Edition), 2006, 38(6): 24-28. (in Chinese))

(下转第84页)