

毛西耶子, 孙若辰, 段青云. 单目标和多目标优化在 SWAT 模型率定中的对比[J]. 南水北调与水利科技(中英文), 2023, 21(2): 289-300. MAO X Y Z, SUN R C, DUAN Q Y. Comparison of single-objective and multi-objective optimization in SWAT model calibration[J]. South-to-North Water Transfers and Water Science & Technology, 2023, 21(2): 289-300. (in Chinese)

# 单目标和多目标优化在 SWAT 模型率定中的对比

毛西耶子<sup>1,2</sup>, 孙若辰<sup>1,2,3</sup>, 段青云<sup>1,2,3</sup>

(1. 河海大学水文水资源与水利工程科学国家重点实验室, 南京 210098; 2. 河海大学水文水资源学院, 南京 210098; 3. 中国气象局水文气象重点开放实验室, 南京 210098)

**摘要:**为评估不同优化方法在分布式水文模型参数率定中的效率和效果, 分别使用基于代理模型的多目标优化方法(multi-objective adaptive surrogate modeling-based optimization, MO-ASMO)、NSGA-II 和 SCE-UA 对 SWAT 模型进行参数率定。基于四湖流域 2008—2021 年的实测流量数据以及高程、土地利用、土壤类型等数据, 构建 SWAT 模型, 并针对 3 种不同优化方法的参数率定结果, 采用相对误差百分比( $P_{BIAS}$ )、Nash-Sutcliffe 效率系数( $E_{NS}$ )、均方根误差( $E_{RMS}$ )和 Kling-Gupta 效率指标( $E_{KG}$ )4 种评价指标对比不同优化算法的优化效果, 此外还创新性量化不同统计指标的不确定性, 以更全面地评估不同算法优化结果的稳健性与可靠性。结果表明, 与单目标优化方法 SCE-UA 相比, 多目标优化方法的参数率定结果表现出更好的可靠性和稳健性, 在多目标优化方法中, MO-ASMO 方法能以显著更少的模型运行次数达到与 NSGA-II 相似的优化效果。

**关键词:** 水文模型; 参数率定; 多目标优化; 代理模型; SWAT 模型

**中图分类号:** TV121.7 **文献标志码:** A **DOI:** 10.13476/j.cnki.nsbdqk.2023.0029

水文模型参数率定是水文领域的重要研究内容, 模型参数的合理性会直接影响水文模型的预报性能<sup>[1]</sup>。传统的水文模型参数自动率定方法主要为单目标优化, 常用算法有 SCE-UA<sup>[2]</sup>、遗传算法<sup>[3]</sup>、单纯形法<sup>[4]</sup>等。Gupta 等<sup>[5]</sup>认为将水文模型输出和观测值中的信息压缩为单个统计指标并使用该统计指标来决定多个模型参数的取值无法充分捕获和利用数据中的全部信息。Fenicia 等<sup>[6]</sup>同样指出使用单一统计指标可能会以牺牲其他方面特征的模拟效果为代价来提高与适应要素的某一特征。大量实践经验<sup>[7-9]</sup>也表明, 水文模型单目标优化率定不能很好地衡量水文要素(如径流)的所有特征, 因此需要通过多个目标函数来同时约束水文要素的多个特征。目前应用较广泛的多目标优化算法有 SPEA2<sup>[10]</sup>、PAEA<sup>[11]</sup>、MOSCEM-UA<sup>[12]</sup>、NSGA-II<sup>[13]</sup>等, 许多研究将其应用于水文模型多目标参数率定, 如王宇晖等<sup>[14]</sup>用 MOSCEM-UA 算法对 Hymod 模型的洪水流量及枯水流量进行多目标优化, Ercan 等<sup>[15]</sup>使用

NSGA-II 对 SWAT 模型进行多目标参数率定并得到了良好的模型模拟结果。

尽管在过去的几十年里, 计算机技术飞速发展, 但使用多目标优化算法率定水文模型(尤其是复杂的物理性的分布式水文模型)仍然会产生很大的计算负担, 因此研究高效可靠的多目标优化方法具有重要的工程应用价值<sup>[1]</sup>。Gong 等<sup>[16]</sup>在 2016 年提出了基于代理模型的多目标优化方法 MO-ASMO (multi-objective adaptive surrogate modeling-based optimization), 其内核为在优化过程中使用廉价的统计代理模型代替原本计算昂贵的物理模型, 旨在显著降低计算量的同时保持优化效果。MO-ASMO 方法在优化陆面模式多个输出变量和复杂分布式水文模型洪水预报过程的多个水文统计指标中均得到了较好的应用<sup>[16-18]</sup>, 结果证明了 MO-ASMO 的高效率。

以往利用基于代理模型优化算法的研究通常只关注优化算法的计算效率, 而对于参数优化结果的

收稿日期: 2022-10-11 修回日期: 2023-02-08 网络出版时间: 2023-04-13

网络出版地址: <https://kns.cnki.net/kcms/detail/13.1430.TV.20230412.1040.019.html>

基金项目: 国家自然科学基金项目(42101046;51979004); 水利部重大科技项目(SKS-2022001); 中国科学院战略性先导科技专项(XDA2006040104); 河海大学引进高层次人才科研启动基金项目(522020012)

作者简介: 毛西耶子(1998—), 女, 湖南岳阳人, 主要从事水文不确定性理论与应用研究。E-mail: [maoxiyezi@163.com](mailto:maoxiyezi@163.com)

通信作者: 孙若辰(1991—), 男, 陕西西安人, 副研究员, 主要从事陆面水文模型不确定性研究。E-mail: [sunrc@hhu.edu.cn](mailto:sunrc@hhu.edu.cn)

可靠性评估同样重要。Clark 等于 2021 年提出对于广泛用于水文研究和实践的 Nash-Sutcliffe 效率系数<sup>[19]</sup>( $E_{NS}$ )和 Kling-Gupta 效率指标<sup>[20]</sup>( $E_{KG}$ ), 当使用其作为目标函数进行参数率定时, 优化的结果可能会受到少量数据点的严重影响, 导致  $E_{NS}$  和  $E_{KG}$  统计指标存在很大的不确定性, 从而影响模型参数率定后的模拟效果<sup>[21]</sup>。因此, 传统上仅通过统计指标的好坏判断参数率定结果的合理性与可靠性的做法存在着不足和缺陷, 很容易受“异参同效”现象的影响而出现不合理的参数值。Clark 等<sup>[21]</sup>也明确建议, 在判断水文模拟结果的好坏时需要考虑统计指标的不确定性。Ritter 等<sup>[22]</sup>使用 Bootstrap 方法量化统计指标  $E_{NS}$  的不确定性, 但尚未有研究通过量化不同水文统计指标的不确定性来评估不同优化算法结果的可靠性和稳健性。因此, 本研究从新的角度出发, 不仅关注优化算法计算效率与统计指标好坏, 还着重考虑率定结果的合理性与稳健性。

以四湖流域为研究区域, 采用 MO-ASMO 方法对 SWAT 模型进行多目标参数率定, 并与经典的多目标优化方法 NSGA-II 和单目标优化方法 SCE-UA 进行比较, 利用 4 种统计评价指标全面比较不同优化算法的优化效果, 探究 MO-ASMO 方法在 SWAT 模型参数优化中的适用性。除此之外, 本研究的创新之处在于, 使用稳健性检验方法 Bootstrap 与 Jackknife 对不同算法优化结果的统计指标  $E_{NS}$ 、 $E_{KG}$  进行不确定性量化, 从而进一步检验 3 种优化方法参数优化结果的可靠性和稳健性。

## 1 研究区域与数据

### 1.1 研究区域概化

四湖流域地处长江中游北岸, 面积约为 11 547 km<sup>2</sup>, 土地利用类型以农业用地为主, 流域多年平均降雨量 1 000~1 350 mm, 属亚热带季风湿润区, 流域内水系复杂、河网纵横, 水资源较为丰富<sup>[23]</sup>。四湖流域是江汉平原重要的组成部分, 也是湖北省乃至全国重要的粮棉油水产品生产基地。选取四湖流域内 22 个雨量站及福田寺水文站 2008—2021 年的数据资料进行 SWAT 模型模拟研究, 研究区域概化图见图 1。

### 1.2 数据类型及来源

SWAT 模型模拟需要的数据主要包括数字高程 (DEM)、土地利用、土壤数据和水文气象数据, 模型构建前需要根据不同的研究区域建立土壤数据

库和气象数据库。选取流域内 22 个雨量站 2008—2021 年的逐日降水数据作为模型输入数据, 气象数据来自中国区域地面气象要素驱动数据集, 主要包括气温、湿度、日照时数以及风速, 选取福田寺水文站 2008—2021 年的逐日平均流量数据作为实测流量数据。数据类型及来源见表 1。

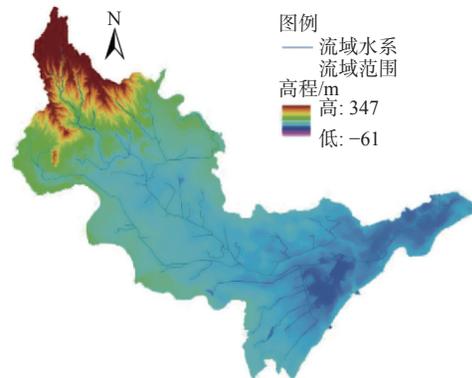


图 1 四湖流域高程与水系

Fig. 1 Elevation and drainage of Sihubai basin

表 1 水文模型数据类型及来源

Tab. 1 Types and sources of hydrological model data

数据类型	数据描述	数据来源
数字高程	30 m × 30 m 栅格数据	地理空间数据云 ASTER GDEM 数据
土地利用	1 km × 1 km 栅格数据	国家青藏高原科学数据中心
土壤数据	1 km × 1 km 栅格数据	南京土壤所第二次全国土地调查 1 : 100 万土壤数据
气象数据	气象要素 逐日数据	中国区域地面气象要素驱动数据集
雨量站与水文站数据	降水、流量 逐日数据	长江流域水文年鉴
水系数据	矢量数据	OpenStreetMap

## 2 研究方法

### 2.1 SWAT 模型

#### 2.1.1 模型介绍

SWAT 模型是一个计算连续时间序列降雨-径流过程的分布式水文模型, 在世界各地应用于水文水质模拟, 可对复杂下垫面条件的大尺度流域进行长序列模拟, 适用于以农业用地为主的地区<sup>[24]</sup>。SWAT 模型将流域划分为由河流网络连接的子流域, 并进一步细分为由不同土地覆盖、土壤和坡度组成的水文响应单元 (HRU) 再进行计算<sup>[25]</sup>。SWAT 模型水文模拟模块的水量平衡方程为

$$S_{w,t} = S_{w,0} + \sum_{i=1}^t (R_{\text{day}} - Q_{\text{surf}} - E_a - W_{\text{seep}} - Q_{\text{gw}}) \quad (1)$$

式中:  $S_{w,t}$  为土壤最终含水量, mm;  $S_{w,0}$  为第  $i$  天的土壤初始含水量, mm;  $t$  表示时间, d;  $R_{\text{day}}$  表示第  $i$  天的降水量, mm;  $Q_{\text{surf}}$  表示第  $i$  天的地表径流量, mm;  $E_a$  表示第  $i$  天的蒸散发量, mm;  $W_{\text{seep}}$  表示第  $i$  天从土壤剖面进入包气带的水量, mm;  $Q_{\text{gw}}$  表示第  $i$  天回归流水量, mm。

### 2.1.2 模型构建与参数选择

SWAT 模型可以在 ArcGIS 平台作为插件进行可视化操作, 本研究使用 ArcSWAT 对 DEM 和河网进行数据预处理, 将研究区域划分为 68 个子流域,

土壤、土地利用和坡度栅格数据阈值设置为 5%, 将流域细分为包含不同下垫面特征的 813 个 HRU, 进行流域径流模拟计算。径流模拟周期为 2008—2021 年, 其中: 2008 年作为预热期; 2009—2019 年作为率定期; 2020—2021 年为验证期。参考 SWAT 模型使用手册和相关文献, 利用 SWAT-CUP 软件计算四湖流域 SWAT 模型的径流模拟参数的敏感度, 其中:  $t$  检验值代表参数的敏感性,  $t$  值的绝对值越大表示敏感性越大;  $p$  值是  $t$  检验值对应的概率值,  $p$  值体现了敏感性的显著水平,  $p$  值越接近 0 表示敏感性越大。表 2 列出了本研究选取的 12 个径流模拟敏感参数。

表 2 SWAT 模型参数取值范围与敏感度排序  
Tab. 2 SWAT model parameter value range and sensitivity ranking

模型参数	参数类型	物理意义及单位	取值范围	$t$ 值	$p$ 值	排序
CN2	mgt	湿润条件 II 下的初始SCS径流曲线数	35 ~ 98	-10.11	0	1
GW_DELAY	gw	地下水延迟时间/d	0 ~ 500	3.18	0	2
SOL_K(1)	sol	土壤饱和水力传导度/(mm·hm <sup>-2</sup> )	0 ~ 200	2.56	0.01	3
SOL_BD(1)	sol	土壤饱和容重/(mg·m <sup>-1</sup> )	1.1 ~ 1.9	-2.11	0.04	4
ALPHA_BF	gw	基流系数	0 ~ 1.00	1.63	0.10	5
HRU_SLP	hru	平均坡度	0 ~ 0.6	1.60	0.11	6
ESCO	hru	土壤蒸发补偿系数	0.01 ~ 1.00	-1.60	0.11	7
OV_N	hru	坡面漫流的曼宁系数 $n$ 值	0 ~ 0.8	-1.10	0.27	8
SOL_Z(1)	sol	土壤表层到底层的深度/mm	0 ~ 1 000	-1.07	0.28	9
CANMX	hru	最大冠层截留量/mm	0 ~ 100	0.89	0.37	10
GWQMN	gw	发生回归流所需的浅层含水层的水位阈值/mm	0 ~ 5 000	0.83	0.41	11
SOL_AWC(1)	sol	土壤有效含水量/(mm·mm <sup>-1</sup> )	0 ~ 1	-0.80	0.42	12

## 2.2 优化方法

### 2.2.1 SCE-UA 算法

SCE-UA 算法结合了随机搜索算法、单纯形法、聚类分析及生物竞争演化等多种方法的优点, 能有效解决目标函数响应面存在的粗糙、不敏感区及不凸起等问题, 是一种高效的模型参数率定全局单目标优化算法<sup>[26]</sup>, 在水文领域得到了广泛应用<sup>[2, 27]</sup>。

### 2.2.2 NSGA-II 算法

NSGA-II 算法是一种高性能的多目标优化进化算法, 已广泛应用于各个学科<sup>[13]</sup>。NSGA-II 算法在 NSGA 的基础上采用快速非支配的排序算法, 降低计算非支配排序的复杂度; 引入精英策略, 扩大了采样空间, 防止最佳个体的丢失, 提高算法的运算速度和鲁棒性; 引入拥挤度和拥挤度比较算子, 将

拥挤度作为种群中个体之间的比较准则, 可保证种群的多样性。

### 2.2.3 MO-ASMO 算法

MO-ASMO 方法是基于代理模型的多目标优化方法<sup>[16]</sup>, 同系列的算法还有基于代理模型的单目标优化方法 ASMO<sup>[28]</sup>、基于自适应代理模型的参数优化和后验分布估计方法 ASMO-PODE<sup>[29]</sup>、适用于分布式模型的 MO-ASMOGS 方法<sup>[30]</sup>和基于多目标自适应代理模型的约束混合优化方法 MO-ASMOCH<sup>[30]</sup>。MO-ASMO 使用高斯过程回归构建代理模型以代替原始的物理模型, 在代理模型上运行传统多目标优化算法, 得到近似的帕累托最优解集, 方法流程见图 2, 主要步骤包括初始采样、构建代理模型和自适应采样强化训练<sup>[16]</sup>。

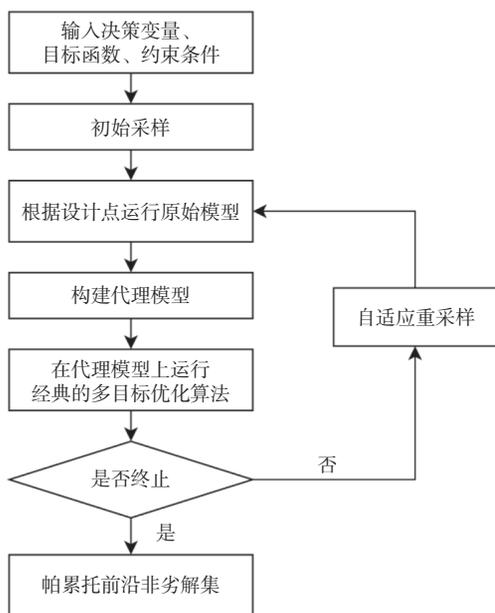


图 2 MO-ASMO 方法流程

Fig. 2 Flow chart of MO-ASMO method

### 2.2.4 算法参数设置

SCE-UA 算法参数设置为: 决策变量维数  $N=12$ , 目标函数为单一目标, 复形个数 10, 每个复形中的点数  $2N+1=25$ , 单纯形点数  $N+1=13$ , 总采样点数即种群规模  $10 \times (2N+1)=250$ , 复形混合前的进化代数  $2N+1=25$ , 运行次数上限 10 000 次, 设置收敛条件为最近 10 次迭代前后目标函数改进不到 0.1%。

NSGA-II 算法参数设置为: 决策变量维数 12, 目标函数维数 3, 种群规模 100, 进化代数为  $n$  次, 交叉概率 0.9, 变异概率 1/20, 原模型共运行  $100n$  次。

MO-ASMO 算法参数设置为: 决策变量维数 12, 目标函数维数 3, 初始采样  $n$  次, 响应曲面上运行 NSGA-II 算法的种群规模 100、进化代数 100, 代理模型强化训练迭代次数  $x$  次, 重采样比例 0.2, 原模型共运行  $(n+20x)$  次。

对于 SCE-UA 算法的参数设置, 该方法原始文献给出明确建议, 且其总运行次数由收敛条件或运行次数上限决定<sup>[26]</sup>, 即按照其建议进行参数设置。NSGA-II 算法的种群规模通常人为设定, 依据原始文献的建议设为 100<sup>[13]</sup>, 且优化效果主要取决于进化代数, 一般进化代数越高, 优化效果越好。MO-ASMO 算法的参数较多, Gong 等<sup>[16]</sup> 在提出该方法时指出针对不同优化问题需要考虑构建替代模型的初始样本点数以及重采样迭代次数, 参考其推荐的参数设置, 并研究不同初始样本点数以及重采样迭代次数对于优化算法性能的影响。多目标优化的收敛一般没有定量的条件, 本文定性地通过判断

3 个目标函数的箱形图(最大值、最小值、中位数特征)在迭代过程中均没有明显改进时即认定为收敛。

### 2.3 水文模型统计指标

选用 3 个统计指标作为模型多目标优化的目标函数: 强调水量平衡的统计指标 ( $P_{BIAS}$ )、均方根误差 ( $E_{RMS}$ ) 以及强调低流量的统计指标 ( $E_{MSL}$ )。其中, 均方根误差  $E_{RMS}$  偏向于强调拟合水文图的高流量部分, 而对数均方误差  $E_{MSL}$  由于对数运算的作用使小流量的拟合误差更为敏感, 因而更侧重于低流量的拟合。统计量表达式为

$$P_{BIAS} = \frac{\sum_{i=1}^N (Q_i - S_i)}{\sum_{i=1}^N Q_i} \times 100\% \quad (2)$$

$$E_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i - S_i)^2} \quad (3)$$

$$E_{MSL} = \frac{1}{N} \sum_{i=1}^N (\ln Q_i - \ln S_i)^2 \quad (4)$$

式中:  $Q_i$  为实测流量,  $m^3/s$ ;  $S_i$  为模拟流量,  $m^3/s$ ;  $N$  为要素序列的数据量。

为了更加全面地评估参数优化结果, 除了使用作为参数率定目标函数的  $P_{BIAS}$  和  $E_{RMS}$  作为模型率定结果的评价指标, 还使用了 Nash-Sutcliffe 效率系数 ( $E_{NS}$ ) 和 Kling-Gupta 效率指标 ( $E_{KG}$ )。表 3 列出了这几种水文模型评价指标的评价标准<sup>[31]</sup>。其中均方根误差  $E_{RMS}$  随着流量的增大而增加, 因此没有统一的评价标准, 误差越小, 表示模拟效果越好。

表 3 水文模型评价指标的评价标准

Tab. 3 Evaluation criteria for evaluation indexes of hydrological models

评价指标	取值范围	评价结果
$E_{NS}$	$>0.75 \sim \leq 1.00$	优秀
	$>0.65 \sim \leq 0.75$	良好
	$>0.50 \sim \leq 0.65$	合格
	$\leq 0.50$	不合格
$P_{BIAS}$	$>0 \sim \leq 10$	优秀
	$>10 \sim \leq 15$	良好
	$>15 \sim < 25$	合格
	$\geq 25$	不合格
$E_{KG}$	$>0.75 \sim \leq 1.00$	优秀
	$>0.65 \sim \leq 0.75$	良好
	$>0.50 \sim \leq 0.65$	合格
	$\leq 0.50$	不合格

## 2.4 DISO 方法

在多目标优化实际应用中,针对多个目标函数,多目标优化方法将生成一系列优化方案(非劣解集),即优化结果不唯一,非劣解集中的每个解对应的参数组合都是最优解,不能说某一个解比另一个更好,即这些解之间在改善一个目标的同时可能会引起另一个或者几个目标变差,不同解的优化结果侧重不同的目标函数。为了便于不同算法之间进行比较,在多目标优化方案的决策中,本研究综合考虑 3 个目标函数,选取综合性能最好的一组参数进行模型优化结果评价,采用基于点间距离来评估整体模型性能的方法(distance between indices of simulation and observation, DISO)对所有非劣解进行综合评估<sup>[32]</sup>。DISO 值描述模型在不同方面的综合模拟性能,是对模型输出多维度评估的综合量化,DISO 值越小,表示综合性能越好。三维评估表达式和权重计算公式为

$$V_{\text{DISO}} = \sqrt{(w_1 c_1)^2 + (w_2 c_2)^2 + (w_3 c_3)^2} \quad (5)$$

$$\left\{ \begin{aligned} w_1 &= \frac{\sum_{i=1}^n c_1^i}{\sum_{i=1}^n c_1^i + \sum_{i=1}^n c_2^i + \sum_{i=1}^n c_3^i} \\ w_2 &= \frac{\sum_{i=1}^n c_2^i}{\sum_{i=1}^n c_1^i + \sum_{i=1}^n c_2^i + \sum_{i=1}^n c_3^i} \\ w_3 &= \frac{\sum_{i=1}^n c_3^i}{\sum_{i=1}^n c_1^i + \sum_{i=1}^n c_2^i + \sum_{i=1}^n c_3^i} \end{aligned} \right. \quad (6)$$

式中:  $V_{\text{DISO}}$  为 DISO 值;  $c_i$  为统计量归一化后的欧几里德距离;  $w_1$ 、 $w_2$ 、 $w_3$  为 3 种评价指标的权重系数,  $w_1 + w_2 + w_3 = 1$ ;  $n$  为多目标优化非劣解集个数。

## 2.5 稳健性检验方法

稳健性检验考察的是统计量对模拟结果评价的鲁棒性,即当改变某些样本时,统计量是否仍然能对评价结果保持一个比较一致、稳定的解释,同时也能侧面反映参数率定结果的合理性。为量化水文统计量  $E_{\text{NS}}$ 、 $E_{\text{KG}}$  的不确定性, Clark 等<sup>[21]</sup>采用 Bootstrap 与 Jackknife 方法进行量化评估,并提出有必要使用多个统计指标进行优化率定的展望。为探究多目标优化是否能减小模型参数优化结果的不确定性,使用 Bootstrap 与 Jackknife 方法量化两

种多目标优化算法(MO-ASMO、NSGA-II)和单目标优化算法 SCE-UA 的优化结果的不确定性,以此判断参数优化结果的可靠性和稳健性。量化统计量标准误差表达式为

$$s_{\text{jack}}(\hat{\theta}) = \sqrt{\frac{n-1}{n} \sum_{i=1}^n (\hat{\theta}_0 - \hat{\theta}_i)} \quad (7)$$

$$s_{\text{boot}}(\hat{\theta}) = \sqrt{\frac{1}{B-1} \sum_{b=1}^B (\hat{\theta}_0^* - \hat{\theta}_b)} \quad (8)$$

式中:  $\hat{\theta}$  是构造的观测值与估计值的统计量;  $n$  为观测值的个数;  $B$  为 Bootstrap 重采样次数;  $\hat{\theta}_0$  与  $\hat{\theta}_0^*$  分别为 Jackknife 与 Bootstrap 所有子样本统计量的平均

$$\text{值, } \hat{\theta}_0 = \frac{\sum_{i=1}^n \hat{\theta}_i}{n}, \hat{\theta}_0^* = \frac{\sum_{b=1}^B \hat{\theta}_b}{B}。$$

## 3 结果分析

### 3.1 多目标优化非劣解集比较

以  $P_{\text{BIAS}}$ 、 $E_{\text{RMS}}$ 、 $E_{\text{MSL}}$  作为目标函数,用 Python 分别调用 MO-ASMO 和 NSGA-II 两种多目标优化算法对 SWAT 模型进行参数优化率定,在 Linux 远程服务器上运行模型和优化算法。由于在代理模型上运行优化算法的时间和模型运行时间相比可以忽略不计,因此默认不同优化算法消耗的时间与原始模型运行次数成正比,下文的运行次数均指原始模型运行次数。

#### 3.1.1 运行次数及优化结果

MO-ASMO 算法优化结果见图 3。训练样本越多,越能拟合接近真实的相应曲面,但随着样本数量的增加,也会为训练时间带来一定的负担<sup>[16]</sup>。分别考虑不同初始采样次数(初始训练样本数)的优化结果,设置初始采样为 1 000 次和 2 000 次,图 3 展示了初始采样为 1 000 时迭代 15、20、30 次及初始采样为 2 000 时迭代 10、15、20 次的结果。

由于本研究的多目标优化问题无法获取真实的帕累托前沿作为判断收敛条件,因此以优化得到的前沿不再有明显改进时的迭代结果作为收敛后的优化结果。由图 3 可知初始采样为 2 000 次时,优化结果整体比初始采样为 1 000 次好,且当迭代次数为 15 次和 20 次时,3 个目标函数均没有明显的改进,判定迭代次数为 15 次时已经接近收敛。因此选取初始采样为 2 000、迭代 15 次的结果进行模型模拟精度评价,运行次数为 2 300 次。

NSGA-II 算法优化结果见图 4, 算法种群规模为 100, 分别设置进化代数数为 100、200 次, 对应的运行次数分别为 10 000 次和 20 000 次, 进化代数分别为 100 和 200 时 3 个目标函数均没有明显的改进, 判定进化代数数为 100 时接近收敛。同时为了公平比

较两种算法的效率, 使用相同的原始模型运行次数进行对比, 因此额外设置进化代数数为 23 次作为对比参考。分别选取进化代数数为 23 和 100 次的优化结果进行模型模拟精度评价, 运行次数分别为 2 300 次和 10 000 次。

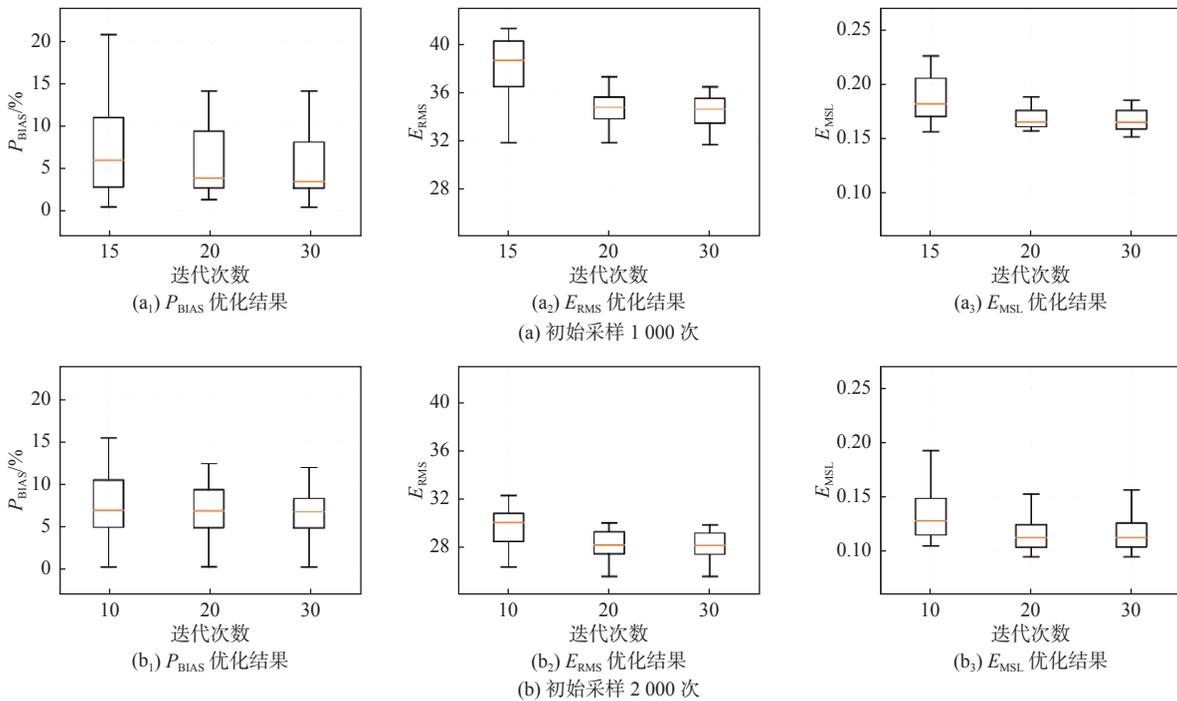


图 3 MO-ASMO 算法优化结果

Fig. 3 Optimization results of MO-ASMO algorithm

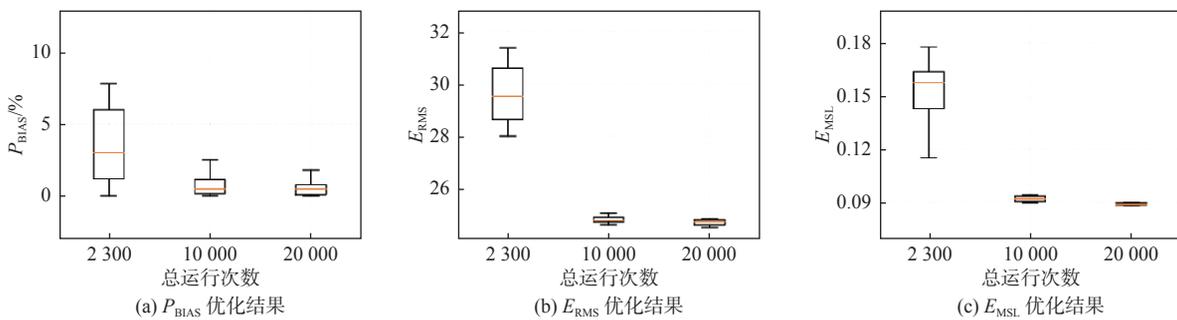


图 4 NSGA-II 算法优化结果

Fig. 4 Optimization results of NSGA-II algorithm

### 3.1.2 帕累托前沿比较

图 5 为 MO-ASMO 与 NSGA-II 两种优化方法得到的帕累托前沿, 由图 5 可知目标函数之间存在明显的非劣关系, 即无法同时达到最优, 从而达到多目标权衡的效果, 由于 3 个目标函数都是求最小值 0, 因此距离原点越近, 优化效果越好。MO-ASMO 与 NSGA-II 分别在运行次数为 2 300 次与 10 000 次时接近收敛, 两种方法收敛后能达到相似

的优化效果, 当两种算法运行次数均为 2 300 次时, 消耗的模型运行时间相同, 但 MO-ASMO 方法比 NSGA-II 收敛得更快。

### 3.1.3 非劣解集排序

用 DISO 方法对多目标优化非劣解集的 3 个目标函数进行综合量化, 计算公式见式(5)。考虑到水量平衡统计指标( $P_{BIAS}$ )的“异参同效”作用比其他两个目标函数更突出, 可能对模型输出造成更大的

不确定性<sup>[33]</sup>,因此侧重于其他两个目标函数( $E_{MSL}$ 、 $E_{RMS}$ )来计算权重,权重计算公式见式(6), $P_{BIAS}$  权重计算结果往小取整, $E_{MSL}$ 、 $E_{RMS}$  权重计算结果往大取整,权重计算结果精确到小数点后一位。DISO 值越小,表示综合性能越好,表 4 列出了计算得到的各多目标算法优化结果的 DISO 值排序前三的非劣解,

选取各算法 DISO 值最小的方案进行多目标参数优化结果评估。其中值得注意的是,DISO 值只能在同一非劣解集中进行比较,这是由于计算过程中经过了非劣解集归一化和对应的权重计算等处理,因此不同算法得到的非劣解集的 DISO 值无法进行比较。

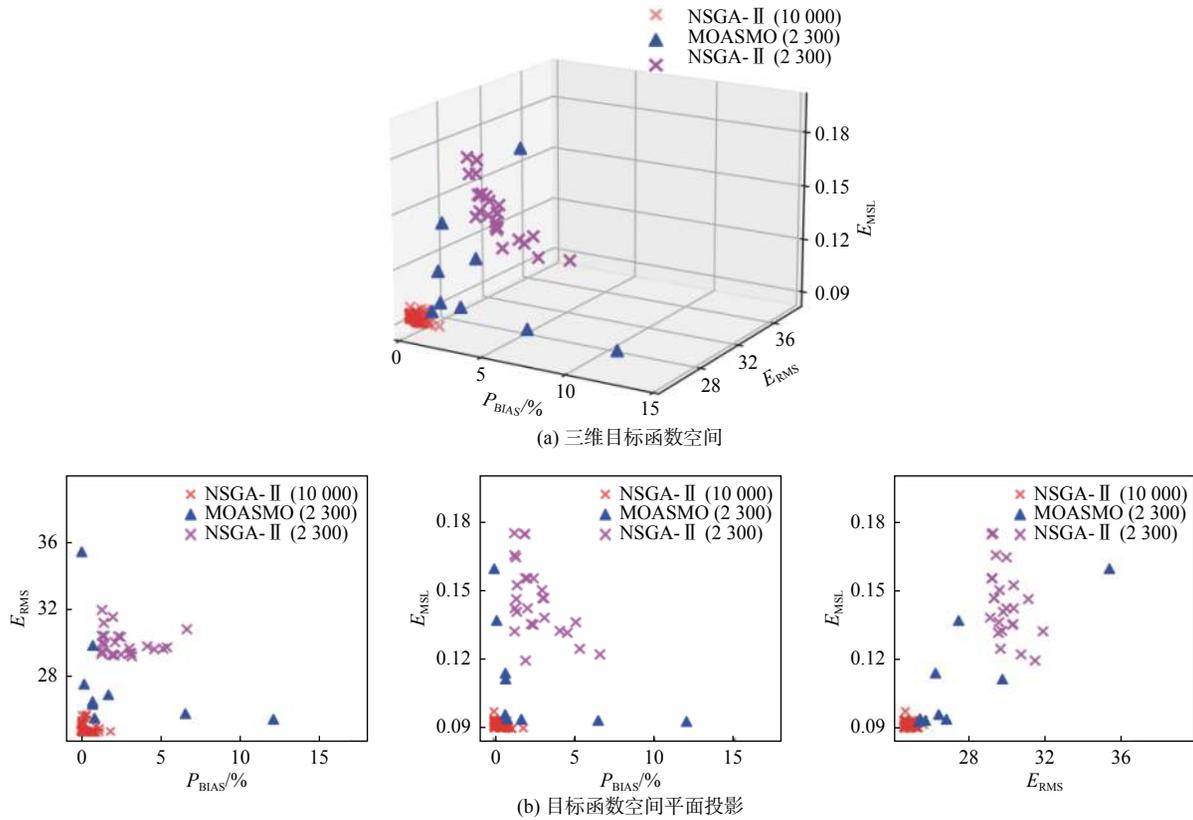


图 5 多目标优化结果

Fig. 5 Multi-objective optimization results

表 4 DISO 方法对非劣解集排序结果

Tab. 4 The DISO method sorts the results of the non-inferior solution set

算法 (运行次数)	排序	$P_{BIAS}$	权重	$E_{MSL}$	权重	$E_{RMS}$	权重	$V_{DISO}$
MO-ASMO (2 300)	1	1.71		0.09		25.53		0.146
	2	6.12	0.1	0.09	0.4	26.25	0.5	0.153
	3	0.83		0.10		26.30		0.180
NSGA- II (2 300)	1	2.25		0.13		28.40		0.193
	2	3.35	0.2	0.12	0.4	28.69	0.4	0.201
	3	1.98		0.13		29.29		0.228
NSGA- II (10 000)	1	0.71		0.09		24.34		0.132
	2	0.91	0.2	0.09	0.4	24.68	0.4	0.137
	3	0.74		0.09		24.68		0.150

### 3.2 参数优化结果评价

表 5 列出了 MO-ASMO、NSGA-II 和 SCE-UA 方法优化结果的  $P_{BIAS}$ 、 $E_{NS}$ 、 $E_{RMS}$  和  $E_{KG}$  4 种评价指标评估结果。评价结果显示,3 种优化方法在率定期的优化结果均较好,相对误差百分比  $P_{BIAS}$  均控制在 10% 以内, $E_{KG}$  与  $E_{NS}$  两个指标均达到 0.75 以上,评价为优秀。通过对比两种多目标方法优化结果

可知,MO-ASMO 方法不论是在率定期还是验证期,各项评价指标都与收敛后的 NSGA-II 方法非常接近,这表明两种多目标优化方法收敛后能得到相似的优化结果;而在运行次数均为 2 300 时,NSGA-II 优化结果评价不论在率定期还是验证期都比 MO-ASMO 差,这表明在相同运行次数下,MO-ASMO 方法优化结果优于 NSGA-II。

表 5 不同算法参数优化结果评价  
Tab. 5 Evaluation of parameter optimization results of different algorithms

算法 (运行次数)	率定期(2009—2019年)				验证期(2020—2021年)			
	$P_{BIAS}$	$E_{NS}$	$E_{RMS}$	$E_{KG}$	$P_{BIAS}$	$E_{NS}$	$E_{RMS}$	$E_{KG}$
MO-ASMO (2 300, 收敛)	1.710	0.805	25.533	0.896	<b>13.214</b>	0.653	<b>19.825</b>	0.801
NSGA-II (2 300)	2.252	0.768	28.404	0.850	15.655	0.600	21.092	0.754
NSGA-II (10 000, 收敛)	<b>0.711</b>	0.818	24.675	<b>0.907</b>	13.294	<b>0.655</b>	19.863	<b>0.802</b>
SCE-UA	6.482	<b>0.823</b>	<b>24.342</b>	0.894	25.488	0.517	23.040	0.712

另外,单目标优化 SCE-UA 方法以纳什效率系数  $E_{NS}$  作为目标函数,优化结果的率定期评价结果较好,但在验证期模拟效果显著退化, $P_{BIAS}$  超过 25% 评价为不合格, $E_{NS}$  评价为及格, $E_{KG}$  评价为良好,出现了过拟合的情况,从结果来看,单目标优化结果存在较大的不稳定性。

图 6 为单目标与多目标优化结果的径流模拟过程线,可知在低流量的拟合中多目标优化表现得比单目标更好,这是由于在多目标优化过程比单目标增加了拟合低流量的目标函数  $E_{MSL}$ ,与原本只侧重高流量部分的  $E_{RMS}$  指标形成了非劣权衡、共同优化的效果。

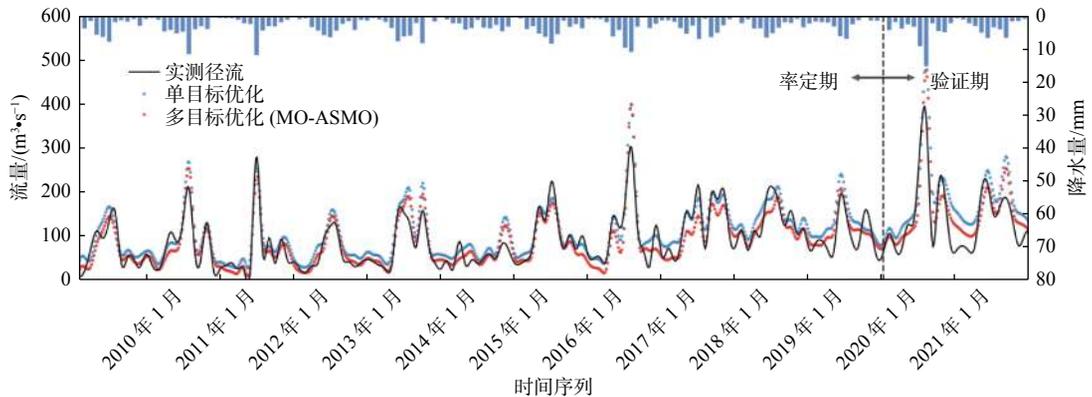


图 6 单目标与多目标优化径流过程

Fig. 6 Runoff process of single-objective and multi-objective optimization results

### 3.3 稳健性检验和结果分析

检验不同算法的参数优化结果的可靠性是本研究的一个研究和分析重点。使用 Bootstrap 与 Jackknife 方法量化径流统计指标的不确定性,以  $E_{NS}$  和  $E_{KG}$  作为统计指标,对不同优化算法的径流模拟结果进行重采样,计算子样本的统计指标及标准误差,标准误差计算公式见式(7)和式(8),其中

Bootstrap 重采样次数设置为 10 000。表 6 列出了不确定性量化的计算结果,3 种优化方法优化结果的不确定性量化排序为 NSGA-II (10 000)  $\approx$  MO-ASMO (2 300)  $<$  NSGA-II (2 300)  $<$  SCE-UA, 多目标优化方案的不确定性总体较小,其中:MO-ASMO (2 300) 和 NSGA-II (10 000) 的优化结果稳健性最好,不确定性较小;NSGA-II (2 300) 的结果次

之;而单目标优化下的模型参数优化结果不确定性较大。

表 6 水文统计量不确定性量化结果

Tab. 6 Results of uncertainty quantification of hydrological statistics

算法(运行次数)	Bootstrap		Jackknife	
	$E_{NS}$	$E_{KG}$	$E_{NS}$	$E_{KG}$
MO-ASMO(2 300, 收敛)	0.056 4	<b>0.050 6</b>	0.053 7	0.041 3
NSGA-II(2 300)	0.062 3	0.061 2	0.063 1	0.045 7
NSGA-II(10 000, 收敛)	<b>0.053 7</b>	0.051 4	<b>0.051 2</b>	<b>0.041 1</b>
SCE-UA	0.084 3	0.076 1	0.080 7	0.069 9

注:加粗部分为不确定性最小值。

由于模型结构、输入数据和参数优化过程等多方面不确定性因素,“异参同效”是模型参数优化中不可避免的问题,尤其是将模型输出和实测数据的全部信息用单一的统计指标来表示会导致率定后出现参数的补偿效应,率定得到的不合理参数值反而补偿了其他来源不确定性导致的误差。结合表 5 和表 6 的结果来看,单目标优化结果在验证期的统计指标退化明显,说明在率定期出现过拟合的现象,且统计指标不确定性较大,表明即使是全局单目标优化算法 SCE-UA 也不能很好地处理“异参同效”的问题。

根据前人的相关研究<sup>[21]</sup>,减小水文模型参数优化过程中不确定性可以使用额外的统计指标作为目标函数以获取更多水文要素的信息<sup>[21]</sup>,即多目标优化方法。本文通过对比统计指标的不确定性量化结果,能够从侧面反映出“异参同效”现象对模型率定结果的影响,结果表明多目标优化可以减小参数优化的不确定性,比单目标优化得到的优化结果更具稳健性,在一定程度上减小了“异参同效”作用。

从非劣解集来看,MO-ASMO 能够以显著更少的运行次数达到与 NSGA-II 同样好的非劣解集前沿;从不同统计指标的统计结果评价来看,MO-ASMO 与 NSGA-II 达到收敛后的优化结果均较好,但在同样运行次数下(2 300 次),NSGA-II 结果比 MO-ASMO 差。对于单目标优化与多目标优化方法,SCE-UA 在率定期出现了过拟合的情况,因此在验证期评价结果不如 MO-ASMO 和 NSGA-II;从稳健性检验结果来看,SCE-UA 的参数优化结果不确定性较大,说明其容易受“异参同效”现象的影响,可靠性比 MO-ASMO

和 NSGA-II 差。

## 4 结论

以长江中游四湖流域为研究区域,构建分布式水文模型 SWAT 模型,分别使用 3 种全局优化算法(MO-ASMO、NSGA-II、SCE-UA)对 SWAT 模型进行参数率定,为评估不同优化算法结果的可靠性和稳健性,本文基于 4 种统计指标对优化结果进行评价分析。除了计算水文统计指标外,还通过稳健性检验方法 Bootstrap 与 Jackknife 量化了水文统计量的不确定性,以此判断参数率定结果的合理性与可靠性,并得到以下结论:

根据多目标优化帕累托前沿和评价指标结果表明,MO-ASMO 方法通过构建代理模型,用 2 300 次的模型运行次数得到与用 NSGA-II 方法运行模型 10 000 次相似的优化效果,节约了约 75% 的模型优化运行时间,针对 SWAT 模型这种耗时较长的计算连续时间序列的分布式水文模型有较大的应用价值。

通过 Bootstrap 与 Jackknife 方法量化不同算法优化结果的水文统计量  $E_{NS}$ 、 $E_{KG}$  的不确定性,研究结果显示,多目标优化结果普遍比单目标优化结果的不确定性小 30% 以上,这说明有必要在对水文模型参数优化过程中使用多个性能指标,减小传统单目标优化导致的参数补偿效应,从而在一定程度上减小“异参同效”所造成的影响,使得参数优化结果更加合理可靠。

MO-ASMO 方法在计算效率上要显著优于 NSGA-II,在优化结果的可靠性和稳健性上要优于 SCE-UA,因此能够被较好地应用于 SWAT 模型的多目标参数率定。MO-ASMO 的代码完全开源,可以为 SWAT 模型用户提供一个可靠的参数率定选择。

### 参考文献:

- [1] 郭俊,周建中,周超,等.概念性流域水文模型参数多目标优化率定[J]. *水科学进展*, 2012, 23(4): 447-456. DOI: 10.14042/j.cnki.32.1309.2012.04.019.
- [2] 王维,冯忠伦,杨伟,等.基于 SCE-UA 算法的新安江模型与垂向混合产流模型参数优化应用研究[J]. *中国农村水利水电*, 2017(3): 26-30. DOI: 10.3969/j.issn.1007-2284.2017.03.006.
- [3] 周焕,舒全英,林文扬.遗传算法在水箱径流模型参

- 数优选中的应用[J]. *人民黄河*, 2014, 36(6): 78-79. DOI: [10.3969/j.issn.1000-1379.2014.06.025](https://doi.org/10.3969/j.issn.1000-1379.2014.06.025).
- [4] 李致家, 周轶, 哈布·哈其. 新安江模型参数全局优化研究[J]. *河海大学学报(自然科学版)*, 2004(4): 376-379. DOI: [10.3321/j.issn:1000-1980.2004.04.004](https://doi.org/10.3321/j.issn:1000-1980.2004.04.004).
- [5] GUPTA H V, WAGENER T, LIU Y. Reconciling theory with observations: elements of a diagnostic approach to model evaluation[J]. *Hydrological Processes*, 2008, 22(18): 3802-3813. DOI: [10.1002/hyp.6989](https://doi.org/10.1002/hyp.6989).
- [6] FENICIA F, SAVENIJE H H G, MATGEN P, et al. A comparison of alternative multiobjective calibration strategies for hydrological modeling[J]. *Water Resources Research*, 2007, 43(3). DOI: [10.1029/2006WR005098](https://doi.org/10.1029/2006WR005098).
- [7] GUPTA H V, SOROOSHIAN S, YAPO P O. Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information[J]. *Water Resources Research*, 1998, 34(4): 751-763. DOI: [10.1029/97WR03495](https://doi.org/10.1029/97WR03495).
- [8] GUO J, ZHOU J, LU J, et al. Multi-objective optimization of empirical hydrological model for streamflow prediction[J]. *Journal of Hydrology*, 2014, 511: 242-253. DOI: [10.1016/j.jhydrol.2014.01.047](https://doi.org/10.1016/j.jhydrol.2014.01.047).
- [9] HERNANDEZ-SUAREZ J S, NEJADHASHEMI A P, DEB K. A novel multi-objective model calibration method for ecohydrological applications[J]. *Environmental Modelling & Software*, 2021, 144: 105161. DOI: [10.1016/j.envsoft.2021.105161](https://doi.org/10.1016/j.envsoft.2021.105161).
- [10] KIM M, HIROYASU T, MIKI M, et al. SPEA2+: Improving the performance of the strength Pareto evolutionary algorithm 2, Berlin, 2004[C]. Springer, 2004: 742-751. DOI: [10.1007/978-3-540-30217-9\\_75](https://doi.org/10.1007/978-3-540-30217-9_75).
- [11] KNOWLES J, CORNE D. The Pareto archived evolution strategy: A new baseline algorithm for Pareto multiobjective optimisation, 1999[C]. IEEE, 1999, 1: 98-105. DOI: [10.1109/CEC.1999.781913](https://doi.org/10.1109/CEC.1999.781913).
- [12] JASPER A, VRUGT H V G L. Effective and efficient algorithm for multiobjective optimization of hydrologic models[J]. *Water Resources Research*, 2003, 39(8): 1214. DOI: [10.1029/2002WR001746](https://doi.org/10.1029/2002WR001746).
- [13] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 2(6): 182-197. DOI: [10.1109/4235.996017](https://doi.org/10.1109/4235.996017).
- [14] 王宇晖, 雷晓辉, 蒋云钟. 基于MOSCEM-UA算法的水文模型参数优化[J]. *人民长江*, 2010, 41(19): 95-99. DOI: [10.3969/j.issn.1001-4179.2010.19.024](https://doi.org/10.3969/j.issn.1001-4179.2010.19.024).
- [15] ERCAN M B, GOODALL J L. Design and implementation of a general software library for using NSGA-II with SWAT for multi-objective model calibration[J]. *Environmental Modelling & Software*, 2016, 84: 112-120. DOI: [10.1016/j.envsoft.2016.06.017](https://doi.org/10.1016/j.envsoft.2016.06.017).
- [16] GONG W, DUAN Q, LI J, et al. Multiobjective adaptive surrogate modeling: Based optimization for parameter estimation of large, complex geophysical models[J]. *Water Resources Research*, 2016, 52(3): 1984-2008. DOI: [10.1002/2015WR018230](https://doi.org/10.1002/2015WR018230).
- [17] SUN R, DUAN Q, HUO X. Multi-objective adaptive surrogate modeling: Based optimization for distributed environmental models based on grid sampling[J]. *Water Resources Research*, 2021, 57(11): e2020WR028740. DOI: [10.1029/2020WR028740](https://doi.org/10.1029/2020WR028740).
- [18] 汤岭, 王海军, 李致家, 等. 代理模型参数率定方法在TOPKAPI模型中的应用[J]. *河海大学学报(自然科学版)*: 1-12. <http://kns.cnki.net/kcms/detail/32.1117.TV.20221121.1715.004.html>.
- [19] NASH J E, SUTCLIFFE J V. River flow forecasting through conceptual models: Part I, A discussion of principles[J]. *Journal of Hydrology*, 1970, 10(3): 282-290. DOI: [10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).
- [20] GUPTA H V, KLING H, YILMAZ K K, et al. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling[J]. *Journal of Hydrology*, 2009, 377(1-2): 80-91. DOI: [10.1016/J.JHYDROL.2009.08.003](https://doi.org/10.1016/J.JHYDROL.2009.08.003).
- [21] CLARK M P, VOGEL R M, LAMONTAGNE J R, et al. The abuse of popular performance metrics in hydrologic modeling[J]. *Water Resources Research*, 2021, 57(9): e2020WR029001. DOI: [10.1029/2020WR029001](https://doi.org/10.1029/2020WR029001).
- [22] RITTER A, MUNOZ-CARPENA R. Performance evaluation of hydrological models; statistical significance for reducing subjectivity in goodness-of-fit assessments[J]. *Journal of Hydrology*, 2013, 480: 33-45. DOI: [10.1016/j.jhydrol.2012.12.004](https://doi.org/10.1016/j.jhydrol.2012.12.004).
- [23] 尹述政, 许峰, 王文荟, 等. 四湖流域径流及蓝水绿

- 水资源时空分布模拟[J]. *环境工程*, 2022, 40(5): 133-140. DOI: [10.13205/j.hjgc.202205019](https://doi.org/10.13205/j.hjgc.202205019).
- [24] 周铮, 吴剑锋, 杨蕴, 等. 基于SWAT模型的北山水库流域地表径流模拟[J]. *南水北调与水利科技(中英文)*, 2020, 18(1): 66-73. DOI: [10.13476/j.cnki.nsb-dqk.2020.0008](https://doi.org/10.13476/j.cnki.nsb-dqk.2020.0008).
- [25] BEKELE E G, NICKLOW J W. Multi-objective automatic calibration of SWAT using NSGA-II[J]. *Journal of Hydrology*, 2007, 341(3): 165-176. DOI: [10.1016/j.jhydrol.2007.05.014](https://doi.org/10.1016/j.jhydrol.2007.05.014).
- [26] DUAN Q, SOROOSHIAN S, GUPTA V. Effective and efficient global optimization[J]. *Water Resources Research*, 1992, 4(28): 1015-1031. DOI: [10.1029/91WR02985](https://doi.org/10.1029/91WR02985).
- [27] 雷晓辉, 蒋云钟, 王浩, 等. 分布式水文模型Easy-DHM(II): 应用实例[J]. *水利学报*, 2010, 41(8): 893-899. DOI: [10.13243/j.cnki.slxb.2010.08.001](https://doi.org/10.13243/j.cnki.slxb.2010.08.001).
- [28] WANG C, DUAN Q, GONG W, et al. An evaluation of adaptive surrogate modeling : Based optimization with two benchmark problems[J]. *Environmental Modelling and Software*, 2014(60): 167-179. DOI: [10.1016/j.envsoft.2014.05.026](https://doi.org/10.1016/j.envsoft.2014.05.026).
- [29] GONG W, DUAN Q. An adaptive surrogate modeling-based sampling strategy for parameter optimization and distribution estimation (ASMO-PODE)[J]. *Environmental Modelling and Software*, 2017(95): 61-75. DOI: [10.1016/j.envsoft.2017.05.005](https://doi.org/10.1016/j.envsoft.2017.05.005).
- [30] SUN R, DUAN Q, MAO X. A multi-objective adaptive surrogate modelling-based optimization algorithm for constrained hybrid problems[J]. *Environmental Modelling and Software*, 2022, 148: 105272. DOI: [10.1016/j.envsoft.2021.105272](https://doi.org/10.1016/j.envsoft.2021.105272).
- [31] MORIASI D N. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations[J]. *Transactions of the ASABE*, 2007, 50(3): 885-900. DOI: [10.13031/2013.23153](https://doi.org/10.13031/2013.23153).
- [32] ZHOU Q, CHEN D, HU Z, et al. Decompositions of Taylor diagram and DISO performance criteria[J]. *International Journal of Climatology*, 2021, 41(12): 5726-5732. DOI: [10.1002/joc.7149](https://doi.org/10.1002/joc.7149).
- [33] 李致家, 张昊, 姚成, 等. 单目标与多目标的全局优化算法在新安江模型参数率定中的耦合应用研究[J]. *水力发电学报*, 2013, 32(5): 6-12.

## Comparison of single-objective and multi-objective optimization in SWAT model calibration

MAO Xiyezi<sup>1,2</sup>, SUN Ruochen<sup>1,2,3</sup>, DUAN Qingyun<sup>1,2,3</sup>

( 1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. School of Hydrology and Water Resources, Hohai University, Nanjing 210098, China; 3. China Meteorological Administration Hydro-Meteorology Key Laboratory, Hohai University, Nanjing 210098, China )

**Abstract:** The traditional automatic calibration of hydrological model parameters are mainly focusing on single-objective optimization, but the optimization based on a single objective can not capture and utilize all the characteristic information of hydrological observations. Several studies have shown that the single-objective calibration of hydrological models can not reproduce all the characteristics of hydrological factors (such as runoff) well, so it is necessary to constrain multiple features of hydrological factors by multiple objective functions. At present, many studies apply classical multi-objective optimization algorithms to calibrating hydrological models. Compared with the single-objective optimization methods, the classical multi-objective optimization algorithms need to run the model tens of thousands of times to find the optimal solutions. Despite the rapid development of computer technology in the past decades, the use of multi-objective optimization algorithms in hydrological models (especially complex physical distributed hydrological models) still causes a large computational burden. Therefore, the study of efficient and reliable multi-objective optimization methods has important engineering application value. In 2016, Professor Duan's group proposed MO-ASMO, a multi-objective optimization method based on a surrogate model. The core of MO-ASMO is to use cheap statistical surrogate models to replace the original computationally

expensive physical models in the optimization process, aiming to significantly reduce the computational burden while maintaining the optimization effect.

Clark et al pointed out that it is necessary to quantify the uncertainty of statistical performance metrics in the process of parameter calibration of hydrological models. This is because when the Nash-Sutcliffe efficiency coefficient ( $E_{NS}$ ) and Kling-Gupta efficiency coefficient ( $E_{KG}$ ) are used as objective functions for parameter calibration, the optimization results may be seriously affected by a small number of data points. It leads to great uncertainty in the statistical metrics, which will affect the simulation effect after the model parameters are calibrated. The distributed hydrological model SWAT model was constructed in the Siyu basin. The MO-ASMO method was used to calibrate the parameters of SWAT model. The results were compared with the classical multi-objective optimization method NSGA-II and the single-objective optimization method SCE-UA. At the same time, to further evaluate the reliability and robustness of the parameter optimization results, Bootstrap and Jackknife methods were used to quantify the uncertainty of the statistical metrics.

The following conclusions were obtained: (1) According to the Pareto front and evaluation metrics of the multi-objective optimization, MO-ASMO and NSGA-II were close to convergence when the number of runs are 2 300 and 10 000, respectively. The two methods can achieve similar optimization results after convergence, but MO-ASMO can greatly reduce the running time of the model in the process of multi-objective optimization. The optimization results of the single-objective optimization method were good during the calibration period, but the simulation effect degraded significantly during the validation period, indicating that there is a situation of overfitting and the optimization results are unstable. (2) The uncertainty of statistics metrics  $E_{NS}$  and  $E_{KG}$  of optimization results of different algorithms was quantified by Bootstrap and Jackknife methods. The uncertainty order of the optimization results of the three optimization methods is NSGA-II (10 000)  $\approx$  MO-ASMO(2 300) < NSGA-II (2 300) < SCE-UA.

The optimization results of MO-ASMO (2 300) and NSGA-II (10 000) have the best robustness and less uncertainty. The results of NSGA-II (2 300) are the second, and the optimization results of model parameters under single-objective optimization are less robust. The results of multi-objective optimization have less uncertainty than those of single-objective optimization, which indicates that it is necessary to use multiple objective functions in the process of hydrological model parameter optimization to avoid problems of compensatory parameters caused by traditional single-objective optimization, to reduce the uncertainty of parameter optimization.

**Key words:** hydrological model; model calibration; multi-objective optimization; surrogate model; SWAT model