

基于集合 Kalman 滤波的中长期径流预报

刘源¹, 纪昌明¹, 马皓宇², 王弋¹, 张验科¹, 马秋梅¹, 杨涵³

(1. 华北电力大学水利与水电工程学院, 北京 102206; 2. 中国长江电力股份有限公司, 湖北 宜昌 443002;
3. 长江科学院水资源综合利用研究所, 湖北 武汉 430010)

摘要:为降低中长期径流预报的不确定性,增加水电站水库的发电效益,针对现有方法侧重于提高单一预报模型确定性预报结果的准确性以降低径流预报不确定性的问题,提出一种基于集合 Kalman 滤波的入库径流确定性预报方法。以旬为预见期的锦西水库实例验证结果表明:相比传统的单一预报模型和传统的信息融合预报模型,基于集合 Kalman 滤波的中长期径流预报可使 RMSE 降低 $4.78 \text{ m}^3/\text{s}$,合格率可提高 0.56% ,且更有效地降低了汛期预报的不确定性,得到了更加准确、可靠的确定性径流预报结果,可为开展流域梯级水电站优化调度提供技术支持。

关键词:中长期径流预报;数据融合;集合 Kalman 滤波;锦西水库

中图分类号:P338+.2 **文献标志码:**A **文章编号:**1004-6933(2024)01-0093-07

Medium and long-term runoff forecast based on ensemble Kalman filter//LIU Yuan¹, JI Changming¹, MA Haoyu², WANG Yi¹, ZHANG Yanke¹, MA Qiumei¹, YANG Han³(1. School of Water Resources and Hydropower Engineering, North China Electric Power University, Beijing 102206; 2. China Yangtze Power Co., Ltd., Yichang 443002, China; 3. Water Resources Comprehensive Utilization Institute, Changjiang River Scientific Research Institute, Wuhan 430010, China)

Abstract: To reduce the uncertainty of medium and long-term runoff forecast and increase the power generation efficiency of hydropower reservoirs, a deterministic inflow runoff forecast method based on ensemble Kalman filtering is proposed to address the issue of existing methods focusing on improving the accuracy of deterministic forecast results of a single forecasting model to reduce the uncertainty of runoff forecast. Taking the Jinxi Reservoir as the research object and ten days as the foresight period, conduct a case study. The results show that compared with traditional single forecast models and traditional information fusion forecast models, the medium-and long-term runoff forecast based on ensemble Kalman filtering reduces RMSE by $4.78 \text{ m}^3/\text{s}$ and improves qualification rate by 0.56% . And it effectively reduces the uncertainty of flood season forecasting, obtaining more accurate and reliable deterministic runoff forecasting results, which can provide technical support for the optimization and scheduling of cascade hydropower stations in the basin.

Key words: medium and long-term runoff forecast; data fusion; ensemble Kalman filter; Jinxi Reservoir

伴随着径流预报技术的发展,径流预报产品被越来越多应用于水库调度管理中,有效地发挥了已建水库的综合利用效益^[1-3]。通常随着预见期的增长,预报不确定性随之增加^[4]。短期径流预报的预见期较短,因此预报不确定性较低,对水库调度管理工作具有很高的价值;中长期径流预报的不确定性虽然较高,但其对于水库调度管理工作仍具有重要作用^[5-6]。中长期径流预报模型可分为物理模型、概念模型和经验模型三类^[7],其中,经验模型不需要考虑流域水循环的具体过程,具有建模简单、计算复杂度低等优点,被广泛应用于中长期径流预报领

域^[8-10]。经验模型又可分为基于数理统计的传统模型和基于机器学习的现代智能模型两大类^[11]。传统模型中,基于平稳时间序列分析的差分自回归滑动平均模型和基于多要素综合分析的多元回归模型及其改进模型广泛应用于早期径流预报领域^[12]。随着基于机器学习和深度学习的现代智能算法与模型的飞速发展,典型的智能方法包括反向传播(back propagation, BP)神经网络、支持向量机(support vector machine, SVM)、长短期记忆(long short term memory, LSTM)神经网络等模型开始被应用于水文径流时间序列的预报,这类模型具有较强非线性拟

基金项目:国家自然科学基金项目(52179016,52109016);广东省科技计划项目(2020B1111530001)

作者简介:刘源(1996—),男,博士研究生,主要从事水文水资源研究。E-mail:lightwing@ncepu.edu.cn

通信作者:王弋(1977—),女,教授,博士,主要从事水文模型研究。E-mail:51102473@ncepu.edu.cn

合能力,可以很好地挖掘和表达预测对象与观测数据间的复杂数据关系^[13-16]。由于不同经验模型在模型结构、参数上存在差异,导致不同模型在不同预报情景下的预报准确性也存在不同^[17]。为了利用从不同模型得出的预报信息,多模型融合预报方式通过综合多种模型预报结果的优势提高预报结果的精度,使得融合预报结果优于各单一模型预报结果。多模型融合预报方法主要分为线性融合和非线性融合两大类。线性融合采用权重集成和线性回归集成等方式对多模型的预报结果进行融合^[18];非线性融合则采用神经网络、SVM 等非线性模型将多模型的预报结果进行融合^[19-20]。然而,现有的融合预报方法多属于静态融合方法,无法有效根据前期预报信息更新对后期预报结果进行校正。随着预报的向前滚动进行,预报信息被逐步更新,如何基于前期预报信息对后期预报结果进行校正以达到动态融合预报的目的仍需深入探讨。

基于此,本文引入集合 Kalman 滤波(ensemble Kalman filter, EnKF)提出中长期入库径流预报的多模型融合预报方法,并以雅砻江流域锦西水库为实例对象,验证该方法的有效性及其适用性,以期为中长期水库优化调度提供参考。

1 研究方法

1.1 预报因子筛选

当采用经验模型构建预报输入与输出之间的函数映射关系时,模型输入因子集的选取是决定预报结果好坏的一个重要因素。当输入因子的数目过少时,输入样本所含有的有效信息不足以表达模型内部复杂的结构特征,难以发挥经验模型的预测优势^[21]。当输入因子的数目过多时,模型的复杂度不断上升,导致信息的传递效率逐渐下降,当因子个数达到某一临界值时,增加一个因子所带来的信息增长无法弥补信息传递效率降低导致的信息损失,此时继续增加因子对预报有害无益。目前,相关系数(correlation coefficient, CC)、偏相关分析(partial correlation analysis, PCA)、互信息(mutual information, MI)、随机森林(random forest, RF)方法因具有简单适用且效果较好的特点而被广泛应用^[14, 22-23],因此本文选取了以上 4 种模型对预报因子集合进行筛选。

1.2 单一预报模型

本文选取 6 种模型构建单一径流预报模型,包括 RF、SVM、BP 神经网络、LSTM 神经网络、多元线性回归(multiple linear regression, MLR)以及差分自回归滑动平均(autoressive integrated moving

average, ARIMA)模型。所选择的 6 种单一模型在水文预报领域应用广泛,具有较强的代表性。

1.3 基于 EnKF 的融合预报模型

EnKF 是 Evensen 在 1994 年提出的一种经典滤波算法,其根据集合预测结果估计状态值和观测值之间的协方差,然后基于观测值和协方差对预测值进行更新^[24-26]。假设一个系统在 t 时刻的状态矩阵为 $\mathbf{X}_t$,其由 N 个成员构成且每个成员具有 n 个状态值,则 $\mathbf{X}_t$ 可表示为

$$\mathbf{X}_t = (\mathbf{x}_{t,1}, \mathbf{x}_{t,2}, \dots, \mathbf{x}_{t,N}) \quad (1)$$

式中 $\mathbf{x}_{t,i}$ 为第 i 个状态向量, $\mathbf{x}_{t,i} \in \mathbf{R}^{n \times 1}$ 。扰动矩阵 $\mathbf{X}'_t \in \mathbf{R}^{n \times N}$ 可表示为

$$\mathbf{X}'_t = \mathbf{X}_t - \bar{\mathbf{X}}_t = \mathbf{X}_t(\mathbf{I} - \mathbf{I}_N) \quad (2)$$

其中

$$\bar{\mathbf{X}}_t = \mathbf{X}_t \mathbf{I}_N$$

式中: $\bar{\mathbf{X}}_t$ 为集合平均, $\bar{\mathbf{X}}_t \in \mathbf{R}^{n \times N}$; $\mathbf{I}_N$ 为每个元素均为 $1/N$ 的矩阵, $\mathbf{I}_N \in \mathbf{R}^{n \times N}$ 。假设 t 时刻观测值的为 $\mathbf{z}_t$ ($\mathbf{z}_t \in \mathbf{R}^M$, M 为观测值的数量),对每个观测添加扰动向量 $\boldsymbol{\varepsilon}_{t,i}$ 构成观测矩阵 $\mathbf{Z}_t$:

$$\mathbf{Z}_t = (\mathbf{z}_{t,1}, \mathbf{z}_{t,2}, \dots, \mathbf{z}_{t,N}) \quad (3)$$

其中

$$\mathbf{z}_{t,i} = \mathbf{z}_t + \boldsymbol{\varepsilon}_{t,i}$$

$$\boldsymbol{\gamma}_t = (\boldsymbol{\varepsilon}_{t,1}, \boldsymbol{\varepsilon}_{t,2}, \dots, \boldsymbol{\varepsilon}_{t,N}) \quad (4)$$

式中: $\mathbf{Z}_t$ 为 t 时刻的观测矩阵, $\mathbf{Z}_t \in \mathbf{R}^{M \times N}$; $\mathbf{z}_{t,i}$ 为第 i 个集合的观测向量; $\boldsymbol{\varepsilon}_{t,i}$ 为第 i 个集合的扰动向量; $\boldsymbol{\gamma}_t \in \mathbf{R}^{M \times N}$ 为扰动矩阵。对于动态系统,其状态方程和测量方程的形式为

$$\mathbf{x}_{t,i} = f(\mathbf{x}_{t,i}^-) \quad (5)$$

$$\mathbf{z}_{t,i} = \mathbf{H}_t \mathbf{x}_{t,i} + \mathbf{v}_t \quad (6)$$

式中: $\mathbf{x}_{t,i}^-$ 为第 i 个观测向量在 t 时刻的预测值, $\mathbf{x}_{t,i}^- \in \mathbf{R}^{n \times 1}$; f 为系统状态的转移算子; $\mathbf{z}_{t,i}$ 为第 i 个成员在 t 时刻的观测值, $\mathbf{z}_{t,i} \in \mathbf{R}^{M \times 1}$; $\mathbf{v}_t$ 为噪声向量, $\mathbf{v}_t \in \mathbf{R}^{M \times 1}$; $\mathbf{H}_t$ 为系统在 t 时刻的观测算子。

EnKF 在每个时刻的计算过程可以分为时间更新和测量更新两个步骤。在时间更新步中, EnKF 计算公式为

$$\mathbf{X}_t = f(\mathbf{X}_{t-1}^-, \mathbf{U}_{t-1}) \quad (7)$$

式中: $\mathbf{X}_{t-1}^-$ 为 $t-1$ 时刻的状态更新值; $\mathbf{U}_{t-1}$ 为 $t-1$ 时刻的驱动。

在测量更新步中,首先根据式(8)和式(9)计算状态的误差协方差矩阵 $\mathbf{P}_t$ ($\mathbf{P}_t \in \mathbf{R}^{n \times n}$)和测量的误差协方差阵 $\mathbf{R}_t$ ($\mathbf{R}_t \in \mathbf{R}^{M \times M}$),然后采用公式(10)计算 Kalman 增益矩阵 $\mathbf{K}_t$ ($\mathbf{K}_t \in \mathbf{R}^{n \times M}$),最后采用式(11)将状态矩阵更新为 $\mathbf{X}_{t-1}^-$ ($\mathbf{X}_{t-1}^- \in \mathbf{R}^{n \times N}$)。

$$\mathbf{P}_t = \mathbf{X}'_t (\mathbf{X}'_t)^T / (N - 1) \quad (8)$$

$$\mathbf{R}_t = \boldsymbol{\gamma}_t \boldsymbol{\gamma}_t^T / (N - 1) \quad (9)$$

$$\mathbf{K}_t = \mathbf{P}_t \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_t \mathbf{H}_t^T + \mathbf{R}_t)^{-1} \quad (10)$$

$$X_i^- = X_i + K_i(Z_i - H_iX_i) \tag{11}$$

1.4 用于对比的融合预报模型

线性融合采用权重集成和线性回归集成等方式对多模型的预报结果进行融合。本文选取基于均方根误差 (root mean square error, RMSE) 的加权平均法作为线性融合方式的代表,选取 SVM 作为非线性融合模式的代表对本文所提模型进行验证分析。

1.5 评价指标

为了比较不同数据驱动模型的效果,选取纳什效率系数 (Nash-Sutcliffe efficiency, NSE)、相关系数 (R)、预报合格率 (qualified rate, QR)、RMSE、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 共 6 项指标对模型性能进行评价。

2 实例验证

2.1 研究区概况

选取四川省雅砻江流域锦西水库进行实例分析。雅砻江是金沙江第一大支流,发源于青海省玉树市境内的巴颜喀拉山南麓。雅砻江上游径流以夏季降水补给为主,季节性积雪融水补给为辅,冬季主要通过地下水补给,因此属于雨水、融雪水混合补给类型的河流。流域枯水期为 1—3 月和 12 月,过渡

期为 4—5 月和 10—11 月,汛期为 6—9 月。锦西水库具有年调节能力,是流域下游梯级水电站的龙头水库,对流域整体的水资源利用及防洪安全具有十分重要的影响。研究数据包括:锦西水库 1961—2016 年各旬入库径流数据,清水 (qs)、石渠 (sq)、甘孜 (gz)、色达 (sd)、道孚 (df)、新龙 (xl)、理塘 (lt)、康定 (kd)、木里 (ml)、九龙 (jl) 气象站 1961—2016 年的日降水数据。以旬为预见期,将日尺度降水数据经过处理转化为旬降水数据,并划分训练期和验证期。训练期为 1961—2006 年,验证期为 2007—2016 年。

2.2 研究区预报因子筛选

考虑到预报因子对径流的影响存在滞后效应,将锦西水库上游 10 个气象站点前期 36 个旬的实测降水量以及锦西水库前期 36 个旬的实测入库径流量共 396 个因子作为待选的预报因子集驱动预报模型运行。为了保证输入预报信息的有效性,分别采用 CC、PCA、MI 和 RF 方法对待选因子进行评价得到预报因子的重要性排序,其中排序为 1 的因子重要性评分最高,往后依次递减。锦西入库径流与不同滞后时间下各站点因子基于重要性评分的排序见图 1。

由图 1 可见,对于同一站点而言,采用不同遴选




图 1 不同遴选方法下预报因子色块图

Fig. 1 Color maps of prediction factors under different selection methods

方法对不同滞后时间下预报因子重要性排序结果有所不同。采用 CC 和 MI 方法进行评价时,由同一站点的预报因子色块深浅可以看出,随着滞后时间的增加,预报因子对锦西入库径流的重要性呈现先降低、后增加、再增加、最后降低的趋势。而采用 PCA 和 RF 方法进行评价时,预报因子对锦西入库径流的重要性在时序上没有明显变化规律。但对于不同遴选方法而言,同一站点下,锦西入库径流与前一旬相应预报因子密切相关。

为了验证预报因子集对预报模型训练和验证的影响,将实测水文数据用于驱动 RF 模型,将排序靠前的因子逐个增加至预报因子集合,然后对不同预报因子集下的预报结果的 RMSE 进行分析,结果见图 2。由图 2 可见,对预报模型进行训练和验证时,随着预报因子个数的增加, RMSE 值呈现下降趋势,表征模型预报性能逐渐增加。然而,当预报因子超过一定数量时,随着预报因子的个数逐渐增加,模型预报性能的增加并不显著甚至开始降低,模型的运行时间也会随之增加。此外,对于不同遴选方法而言,输入因子数目相同时,模型的预报性能也会存在明显差异。因此,为了得到不同单一模型的最优预报结果,通过对预报方法和预报因子个数进行遴选,将能够使训练期各模型 RMSE 指标最优的输入因子集作为各单一预报模型的预报因子集,结果见表 1,其中, Q 为锦西入库径流值; P 为各站点实测降雨值,其下标为各站点名缩写。




图 2 不同遴选方法下预报结果的 RMSE
Fig.2 RMSE of prediction results under different selection methods

2.3 单一预报模型结果分析

图 3 为不同单一预报模型下锦西水库入库径流的预报结果。由图 3 可见,就各模型的训练结果

表 1 不同预报模型对应最优预报因子集
Table 1 Optimal prediction factor sets corresponding to different forecast models

预报模型	最优预报因子集
RF	$Q_{t-1}、P_{ml,t-1}、Q_{t-2}、P_{jl,t-1}、Q_{t-36}、P_{xl,t-1}、P_{lt,t-1}、P_{ml,t-2}、Q_{t-35}、P_{df,t-1}、P_{df,t-2}、P_{jl,t-2}、P_{gz,t-2}、P_{df,t-3}、P_{gz,t-3}、P_{gz,t-1}$
SVM	$Q_{t-1}、P_{ml,t-1}、Q_{t-2}、P_{jl,t-1}、Q_{t-36}、P_{xl,t-1}、P_{lt,t-1}、P_{ml,t-2}、Q_{t-35}、P_{df,t-1}、P_{df,t-2}、P_{jl,t-2}、P_{gz,t-2}、P_{df,t-3}、P_{gz,t-3}、P_{gz,t-1}$
BP	$Q_{t-1}、P_{ml,t-1}、Q_{t-2}、P_{jl,t-1}、Q_{t-36}、P_{xl,t-1}、P_{lt,t-1}、P_{ml,t-2}、Q_{t-35}$
LSTM	$Q_{t-1}、P_{lt,t-1}、Q_{t-36}、Q_{t-2}、P_{jl,t-1}、P_{xl,t-1}、P_{ml,t-1}、Q_{t-35}、P_{sd,t-1}、P_{df,t-1}、Q_{t-3}、P_{gz,t-1}、Q_{t-17}$

来看,各时段预报径流与实测径流涨跌趋势吻合。在波谷段的预报结果与实测结果基本吻合,但是在波峰段与实测径流预报结果相差较大,这说明各模型在非汛期预报结果要比汛期更加准确。




图 3 单一预报模型锦西水库入库径流预报结果
Fig.3 Runoff forecast results of Jinxi Reservoir with single forecast models

表 2 为各单一预报模型在模型训练期的预报结果评价指标值。由表 2 可见,就模型训练结果而言, RF 模型的各评价指标结果均优于其余 5 个预报模型,故选取 RF 模型的预报结果作为融合预报的观测指标值。就其余 5 预报模型而言, ARIMA 模型训练结果的各指标值均劣于另外 4 个模型。

表 2 训练期单一预报模型径流预报评价结果
Table 2 Evaluation results of single forecast models in train period

预报模型	NSE	R	RMSE/ (m³/s)	MARE	MAE/ (m³/s)	合格率/%
RF	0.95	0.98	283.58	7.99	143.74	83.15
SVM	0.85	0.92	503.75	17.15	268.73	54.38
BP	0.87	0.93	466.58	14.64	248.77	65.37
LSTM	0.88	0.94	452.47	22.61	276.07	41.85
MLR	0.85	0.92	490.38	21.08	290.65	44.01
ARIMA	-0.32	0.61	1474.14	48.87	775.65	40.56

为对比模型预报结果的差异,对 6 个模型在不同时段预报结果的 RMSE 进行了分析,结果如图 4 所示。由图 4 可见,就各时段的 RMSE 结果而言, 6 个单一预报模型在非汛期的 RMSE 值相近,说明

各模型在非汛期的预报训练结果相近。然而,就过渡期和汛期的各模型训练结果而言,RF 模型要优于其余模型,ARIMA 模型的要劣于其余模型,SVM、BP、LSTM 和 MLR 4 个模型在各时段 RMSE 指标互有优劣。故选取 SVM、BP、LSTM 和 MLR 4 个模型的预报结果作为融合模型的预测值。




图4 训练期各单一预报模型在各时段的 RMSE
Fig.4 RMSE of single forecast models of each time period in train period

2.4 融合预报模型结果分析

基于被选取的预报模型开展融合预报,图5 为5 种单一预报模型和3 种融合预报模型在验证期的预报结果。由图5 可见,各模型在波谷段的预报值与实测值结果相近,说明各模型在实测径流量级较低时的预报结果较为准确。在波峰段,各模型预报结果与实测值相差较大。此外,由于该流域年内来水分布多呈现双峰结构,且对峰现时间与峰值量级难以准确预测,导致对于整个汛期预测结果较差。




图5 验证期不同预报模型锦西水库入库径流预报结果
Fig.5 Runoff forecast results of Jinxi Reservoir with different forecast models in test period

表3 为验证期8 种预报模型的预报精度评价结果。由表3 可见,单一预报模型中,RF 模型的6 种评价指标均取得最优值。融合预报模型中,基于EnKF 融合的预报模型的6 种评价指标均取得最优值,并且优于 RF 模型的评价结果。对比6 种单一预报模型,基于 RMSE 融合的预报模型在 RMSE 指标上具有明显优势,而其余5 种指标则互有优劣。基于 SVM 融合的预报模型与6 种单一预报模型相比,没有一种指标具有完全优势。

表3 验证期不同预报模型径流预报评价结果

Table 3 Evaluation results of runoff forecast of different forecast models in test period

预报模型	NSE	R	RMSE/ (m ³ /s)	MARE	MAE/ (m ³ /s)	合格率/%
RF	0.89	0.94	361.92	13.01	206.11	70.83
SVM	0.88	0.94	377.10	16.36	225.36	48.89
BP	0.88	0.94	370.24	13.07	206.83	69.44
LSTM	0.87	0.93	393.01	16.91	233.82	55.00
MLR	0.88	0.94	381.41	19.49	249.48	43.06
EnKF 融合	0.90	0.95	350.09	12.23	196.86	71.39
RMSE 融合	0.89	0.94	354.87	15.27	213.32	56.67
SVM 融合	0.86	0.93	408.26	16.02	239.15	64.17

进一步比较不同预报模型在不同预报时段的差异,图6 为验证期不同预报模型在各时段的 RMSE 的差异。由图6 可见,与单一预报模型训练结果相似,各融合预报模型在枯水期预报结果较好,在过渡期和汛期的预报结果较差。此外,尽管 RF 模型的整体预报结果要优于其余4 个单一预报模型,但 RF 预报结果在各时段的 RMSE 并非全部优于其余单一预报模型。从各时段预报结果来看,枯水期 RF 的预报结果均优于其余4 个单一预报模型,而在过渡期和汛期,其余4 个单一预报模型的预报结果均出现了优于 RF 预报模型的情况,因此采用其余4 个单一预报模型预报结果对于 RF 预报结果进行改善是合理的。就 RMSE 指标而言,在非汛期,3 种融合模型预报结果与 RF 预报结果相近,并且优于其余4 种单一预报模型。在过渡期和汛期,基于 RMSE 和基于 EnKF 的融合预报结果与5 个单一预报模型预报结果的较优值接近,基于 SVM 的融合预报结果则劣于另外两种融合预报结果。




图6 验证期不同预报模型在各时段的 RMSE
Fig.6 RMSE of different forecast models of each time period in test period

表4 为不同时期融合预报模型的评价指标值与 RF 模型的对比情况,表中正值表示融合预报相应指标值高于 RF 模型,负值则相反。由表4 可见,在枯水期,3 种融合模型的各项指标均未朝向优化方向改进,故 RF 模型预报结果优于3 种融合模型的预报结果。在过渡期,除 R 指标外,基于 EnKF 的融合

表 4 不同时期融合预报模型与 RF 模型的评价指标对比

Table 4 Comparison of evaluation indexes between fusion models and RF model in different periods

时期	预报模型	NSE	R	RMSE/(m ³ /s)	MARE	MAE/(m ³ /s)	合格率/%
枯水期	EnKF 融合	-0.07	0.00	2.78	0.45	2.32	0.00
	RMSE 融合	-1.38	-0.16	42.19	8.32	41.02	-34.17
	SVM 融合	-0.35	-0.05	13.23	2.96	13.53	-7.50
过渡期	EnKF 融合	0.08	-0.01	-5.14	-0.51	-6.28	0.83
	RMSE 融合	-0.24	-0.08	13.09	0.89	4.63	-6.67
	SVM 融合	-0.37	-0.08	29.29	2.32	28.95	-5.83
汛期	EnKF 融合	0.19	0.02	-22.04	-2.27	-23.78	0.83
	RMSE 融合	0.21	0.01	-21.91	-2.43	-24.03	-1.67
	SVM 融合	-0.33	-0.07	72.29	3.74	56.64	-6.67

预报模型的其余 5 项评价指标均优于 RF 模型评价指标值,故基于 EnKF 的融合对 RF 模型预报起到了改善效果,而基于 SVM 和 RMSE 的融合预报则表现不佳。就 6 种指标而言,基于 SVM 的融合预报比单一 RF 模型预报结果差,而基于 EnKF 和 RMSE 的融合预报均优于单一 RF 模型预报,且后两者对于不同指标的改善程度互有优劣。

3 结 语

考虑单一预报模型确定性预报结果的准确性有限,本文提出一种基于 EnKF 算法的中长期入库径流确定性预报方法。该方法将 EnKF 技术与多种单一预报模型相结合,产生融合预报结果,其可通过前期更新的预报信息对后期预报结果进行校正,实现预报结果的动态校正。以四川省雅砻江流域的锦西水库为实例,开展以旬为预见期的中长期径流预报。结果表明基于多种方法对预报因子进行遴选,可以在提高单一预报模型计算效率的同时提高模型的准确性。其中单一预报模型中,RF 模型要明显优于其余单一预报模型,SVM、BP、LSTM 和 MLR 4 种模型结果相近,ARIMA 模型结果最差。各单一模型在非汛期预报结果均优于过渡期和汛期。3 种融合预报模型中,基于 EnKF 的融合预报结果要优于单一 RF 模型预报结果,其在枯水期对单一模型预报精度的影响不大,但可以显著改善过渡期和汛期单一预报模型的预报精度,从而整体提高了单一预报模型的预报准确性。此外,与传统的基于线性权重和基于机器学习的融合模型相比,基于 EnKF 融合预报的动态校正属性可以更加有效地提高径流预报的准确性。

参考文献:

[1] 纪昌明,李荣波,田开华,等. 基于来水不确定性的梯级水电站负荷调整耦合模型:以锦官电源组梯级水电站为例 [J]. 水利学报, 2017, 48 (1): 1-12. (JI Changming, LI Rongbo, TIAN Kaihua, et al. A coupling model of load adjustment for cascade hydropower stations

based on inflow uncertainty: a case study of Jinping-Guandi cascade hydropower stations [J]. Journal of Hydraulic Engineering, 2017, 48 (1): 1-12. (in Chinese))

[2] 韩世亮,陈泰霖. 气候变化影响下黄河上游梯级水库群未来发电量预测 [J]. 水利水电科技进展,2022,42 (3):32-38. (HAN Shiliang, CHEN Tailin. Future power generation prediction of cascade reservoirs in upper reaches of the Yellow River under climate change [J]. Advances in Science and Technology of Water Resources, 2022,42(3):32-38. (in Chinese))

[3] 唐国磊,周惠成,李宁宁,等. 一种考虑径流预报及其不确定性的水库优化调度模型 [J]. 水利学报,2011,42 (6): 641-647. (TANG Guolei, ZHOU Huicheng, LI Ningning, et al. Optimal operation model for hydropower station considering the inflow forecast and its uncertainty [J]. Journal of Hydraulic Engineering,2011,42(6):641-647. (in Chinese))

[4] 陈璐,卢韦伟,周建中,等. 水文预报不确定性对水库防洪调度的影响分析 [J]. 水利学报,2016,47(1):77-84. (CHEN Lu, LU Weiwei,ZHOU Jianzhong, et al. Effect of streamflow forecast uncertainty on reservoir operation [J]. Journal of Hydraulic Engineering,2016,47(1):77-84 (in Chinese))

[5] XU Wei,ZHANG Chi,PENG Yong, et al. A two stage Bayesian stochastic optimization model for cascaded hydropower systems considering varying uncertainty of flow forecasts [J]. Water Resources Research,2017,50:9267-9286.

[6] 赵钢铁. 考虑水文预报不确定性的水库优化调度研究 [D]. 北京:清华大学,2013.

[7] 何飞飞. 不确定性负荷、径流预测及其在水库优化调度中的应用 [D]. 武汉:华中科技大学,2020.

[8] WANG Wenchuan,DU Yujin,CHAU Kwokwing, et al. An ensemble hybrid forecasting model for annual runoff based on sample entropy, secondary decomposition, and long short-term memory neural network [J]. Water Resources Management,2021,35(14):4695-4726.

[9] 谭乔凤,陈然,朱阳,等. 基于多因子最近邻抽样回归模

- 型的径流相似性预报[J]. 河海大学学报(自然科学版), 2020, 48(6): 521-527. (TAN Qiaofeng, CHEN Ran, ZHU Yang, et al. Runoff similarity forecast based on multi-factor nearest neighbor bootstrapping regressive model [J]. Journal of Hohai University (Natural Sciences), 2020, 48(6): 521-527. (in Chinese))
- [10] 朱跃龙, 赵群, 余宇峰, 等. 基于时空特征挖掘的流量过程智能模拟方法[J]. 河海大学学报(自然科学版), 2021, 49(1): 7-12. (ZHU Yuelong, ZHAO Qun, YU Yufeng, et al. Intelligent simulation method of runoff process based on spatiotemporal feature mining [J]. Journal of Hohai University (Natural Sciences), 2021, 49(1): 7-12. (in Chinese))
- [11] 徐炜. 考虑中期径流预报及其不确定性的水库群发电优化调度模型研究[D]. 大连: 大连理工大学, 2014.
- [12] BOX G E P, JENKINS G M. Time series analysis; forecasting and control [J]. Journal of Time, 1976, 31(4): 238-242.
- [13] 唐振宇, 梁国杰, 张利平, 等. 百色水库入库径流中长期预测方法比较研究[J]. 中国农村水利水电, 2023(1): 82-88. (TANG Zhenyu, LIANG Guojie, ZHANG Liping, et al. Comparative research on the mid-term and long-term runoff forecasting method for baise reservoir's inflow [J]. China Rural Water and Hydropower, 2023(1): 82-88. (in Chinese))
- [14] YANG T, ASANJAN A A, WELLES E, et al. Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information [J]. Water Resources Research, 2017, 53(4): 2786-2812.
- [15] 岳兆新, 艾萍, 熊传圣, 等. 基于信息熵与改进极限学习机的中长期径流预测[J]. 水利水电科技进展, 2021, 41(4): 7-14. (YUE Zhaoxin, AI Ping, XIONG Chuansheng, et al. Medium-long term runoff forecasting based on information entropy and improved extreme learning machine [J]. Advances in Science and Technology of Water Resources, 2021, 41(4): 7-14. (in Chinese))
- [16] 荣艳淑, 胡玉恒, 冯瑞瑞, 等. 广义相加模型在乌江夏季径流预报中的应用[J]. 河海大学学报(自然科学版), 2021, 49(2): 121-126. (RONG Yanshu, HU Yuheng, FENG Ruirui, et al. Application of generalized additive model in summer runoff forecasting of Wujiang Basin [J]. Journal of Hohai University (Natural Sciences), 2021, 49(2): 121-126. (in Chinese))
- [17] 熊怡, 周建中, 贾本军, 等. 基于随机森林遥相关因子选择的月径流预报[J]. 水力发电学报, 2022, 41(3): 32-45. (XIONG Yi, ZHOU Jianzhong, JIA Benjun, et al. Monthly runoff prediction based on teleconnection factors selection using random forest model [J]. Journal of Hydroelectric Engineering, 2022, 41(3): 32-45. (in Chinese))
- [18] 贺玉琪. 日径流组合预报模型的研究与应用[D]. 南京: 南京大学, 2021.
- [19] 李福威, 孙凯昕, 丁伟. 基于多模型融合的中期径流预报[J]. 中国农村水利水电, 2023(2): 9-15. (LI Fuwei, SUN Kaixin, DING Wei. Medium-term runoff forecasting based on information fusion models [J]. China Rural Water and Hydropower, 2023(2): 9-15. (in Chinese))
- [20] 徐炜, 张弛, 彭勇, 等. 基于多模型预报信息融合的中长期径流预报研究[J]. 水力发电学报, 2013, 32(6): 11-18. (XU Wei, ZHANG Chi, PENG Yong, et al. Study on medium and long term hydrological forecasting based on data fusion [J]. Journal of Hydroelectric Engineering, 2013, 32(6): 11-18. (in Chinese))
- [21] 纪昌明, 俞洪杰, 阎晓冉, 等. 基于联合互信息的水文预报因子集选取研究[J]. 水力发电学报, 2017, 36(8): 12-21. (JI Changming, YU Hongjie, YAN Xiaoran, et al. Selecting hydrological forecast factor sets based on joint mutual information [J]. Journal of Hydroelectric Engineering, 2017, 36(8): 12-21. (in Chinese))
- [22] 赵泽谦, 黄强, 明波, 等. 基于多模型随机组合的水文集合预报方法研究[J]. 水力发电学报, 2021, 40(1): 76-87. (ZHAO Zeqian, HUANG Qiang, MING Bo, et al. Hydrological ensemble forecasting method based on stochastic combination of multiple models [J]. Journal of Hydroelectric Engineering, 2021, 40(1): 76-87. (in Chinese))
- [23] 张轩, 张行南, 王高旭, 等. 长江上游水库入库流量的中长期预报[J]. 水资源保护, 2022, 38(4): 131-136. (ZHANG Xuan, ZHANG Xingnan, WANG Gaoxu, et al. Medium and long term forecast of reservoir inflow in upper reaches of the Yangtze River [J]. Water Resources Protection, 2022, 38(4): 131-136. (in Chinese))
- [24] 刘永伟, 王文, 刘元波, 等. 水文模型模拟预报的多源数据同化方法及应用研究进展[J]. 河海大学学报(自然科学版), 2021, 49(6): 483-491. (LIU Yongwei, WANG Wen, LIU Yuanbo, et al. Advances in multi-source data assimilation approach and application in simulation and forecast of hydrological model [J]. Journal of Hohai University (Natural Sciences), 2021, 49(6): 483-491. (in Chinese))
- [26] 刘哲源, 刘攀, 李赫. 水风光互补适应性调度的集合卡尔曼滤波方法[J]. 水力发电学报, 2022, 41(8): 42-53. (LIU Zheyuan, LIU Pan, LI He. An ensemble Kalman filter method for adaptive operation of hydro-wind-solar hybrid power systems [J]. Journal of Hydroelectric Engineering, 2022, 41(8): 42-53. (in Chinese))
- [26] 季颖生. 基于集合卡尔曼滤波的 SVM 参数优化方法研究[D]. 北京: 清华大学, 2015.

(收稿日期: 2023-02-24 编辑: 王芳)