

基于支持向量机(SVM)的祁连山典型小流域日降水-径流模拟研究

于海姣^{1,2}, 温小虎¹, 冯起¹, 何志斌¹

(1. 中国科学院寒区旱区环境与工程研究所, 甘肃兰州 730000; 2. 中国科学院大学, 北京 100049)

摘要: 及时准确的日径流预测在流域水资源的合理规划、利用及管理中具有十分重要的作用。本文以支持向量机(SVM)模型为基础,以祁连山典型小流域-排露沟流域为研究区域,建立了流域日降水-径流模型,对流域未来1~7 d的日径流量进行了模拟预测。为检验SVM模型的有效性,模拟结果与人工神经网络(ANN)模型预测结果进行了对比。结果表明:SVM和ANN均表现出了很高的精度;但相比于传统的ANN模型,SVM模型的预测精度显著提高。表明SVM模型在半干旱山区小流域径流预测中有更好的适用性,可以用于流域中长期日径流预测,是资料有限的条件下中长期日径流预测的有效工具。

关键词: 小流域; 日降水-径流模拟; 日径流量; 支持向量机; 祁连山

中图分类号:P338.2

文献标识码:A

文章编号:1672-643X(2015)02-0026-06

Simulation of daily rainfall-runoff in a small typical catchment of Qilian mountains based on support vector machine

YÜ Haijiao^{1,2}, WEN Xiaohu¹, FENG Qi¹, HE Zhibin¹

(1. Cold and Arid Regions Environmental and Engineering Research Institute, Chinese Academy of Sciences, Lanzhou 730000, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: To predict daily runoff timely and accurately plays an important role in the reasonable planning, utilization and management of water resources. This paper built daily rainfall-runoff model to predict daily runoff for seven days in Pailugou catchment in a typical catchment of Qilian mountains based on support vector machine(SVM). In order to test the validity of the developed model, it compared the results between SVM model and traditional artificial neural network(ANN) model in terms of different evaluation criteria during validation period. Results showed that both SVM and ANN presents very high precision and SVM model performed better than ANN model. The SVM model may be considered as an effective tool to establish a medium and long-term daily runoff forecast model in semiarid mountain regions under limited data condition.

Key words: small catchment; daily rainfall-runoff simulation; daily runoff; support vector machine; Qilian mountains

实时准确的日径流预测不仅是水文研究的重要组成部分,更是水资源规划的重要环节^[1],尤其是预测时间在3 d以上的中长期日径流预测^[2],在流域防洪、水利规划等方面均具有十分重要的作用^[3]。然而,目前中长期日径流预测研究仍处于发展阶段,相对于短期日径流预测来说,滞后于生产实际的需要^[4]。因此,开展中长期日径流预报研究在

流域水资源管理中具有重要的科学与现实意义。特别是在干旱区,水资源是制约社会经济发展、影响生态安全的决定性因素,而干旱区出山径流量往往代表着整个地区的水资源量^[5]。因此,准确地预测径流量变化,为当地工农业和生态环境的可持续发展提供可靠的依据具有十分重要的意义。常用的径流预报模型主要有基于物理过程的分布式水文模

收稿日期:2014-10-14; 修回日期:2015-03-17

基金项目:国家自然科学基金项目(41271524,31370466); 国家科技支撑项目(2012BAC08B05)

作者简介:于海姣(1990-),女,山东人,硕士研究生,从事地下水数值模拟研究。

通讯作者:温小虎(1978-),男,甘肃人,副研究员,硕士生导师,从事地下水模拟研究。

型^[6-8]和数据驱动模型。分布式水文模型虽能准确描述流域内的水文物理过程,但一般需要大量的水文、气象数据作为模型输入。受资料条件的限制,分布式水文模型不能完全发挥参数都具有物理意义的优势,最终趋向于集总参数化模型^[9]。数据驱动模型则不需要描述水文物理过程的参数,而是通过挖掘数据本身潜在的规律进行精确的模拟。近年来,数据驱动模型如人工神经网络(ANN)由于算法简单且易于实现,广泛地应用于径流预测^[10-12]。然而,ANN 极易陷于局部极小、不易收敛且网络性能不稳定,这也使 ANN 的预测受到限制^[13]。支持向量机(SVM)是继神经网络之后机器学习领域新的热点,该方法最大的特点是改变了神经网络的经验最小化原则,实现了结构风险最小化,具有很强的泛化性能,可以很好地解决小样本、非线性等实际问题。目前 SVM 以其简单的结构和良好的性能也越来越多的应用到径流预测中^[14-16]。

有学者利用数据驱动模型对半干旱山区的径流进行了模拟研究:徐中民^[17]等将 ANN 模型应用于黑河流域莺落峡年径流预报中,结果表明利用 ANN 进行径流量预报是可行的;陈仁升^[9]等利用广义回归神经网络(GRNN)计算了黑河出山口月径流量,研究表明 GRNN 神经网络可以用于径流模拟预测;He Zhibin 等^[18]利用 SVM、ANN 和自适应神经模糊推断系统(ANFIS)进行了排露沟流域日径流短期模拟,结果表明 3 个模型均可用于日径流量的短期预报。上述径流预测研究包括了日径流、月径流和年径流 3 个方面,然而,目前在半干旱山区,利用数据驱动模型进行中长期日径流预报的相关研究还不多见。因此,本文以祁连山典型小流域-排露沟流域作为研究区域,利用该流域日降水、径流时间序列数据,以 SVM 模型为基础建立了流域日降水-径流模型,对流域未来 1~7 d 的日径流量进行了预测;为检验 SVM 模型的有效性,与传统的 ANN 模型进行对比。

1 支持向量机的基本原理

支持向量机(Support Vector Machine, SVM)是由 Vapnik^[19]根据统计学理论提出的,目前 SVM 方法常用于分类和回归分析。SVM 回归方法的基本思想是:对于给定的样本数据集 $\{(x_i, y_i) \mid i = 1, 2, \dots, k\}$, x_i 为输入向量, y_i 为输出向量,要求拟合的函数形式为: $f(x) = \omega \cdot \varphi(x) + b$ 。根据结构风险最小化原则要寻找最优回归超平面使

$$\min\left(\frac{1}{2} \|w\|^2 + CR_{emp}^\varepsilon\right) \quad (1)$$

$$R_{emp}^\varepsilon = \frac{1}{l} \sum_{i=1}^l |y_i - f(x_i)| \quad (2)$$

式中: C 为调节训练误差和模拟复杂度之间折中的正则化函数; ε 为不灵敏损失函数。这样支持向量机的回归问题就等价于解决一个二次规划问题:

$$\min_{\omega, b, \varepsilon} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (3)$$

$$\text{s. t.} \begin{cases} y_i - \langle w, \phi(x_i) \rangle \leq b + \xi + \varepsilon \\ \langle w, \phi(x_i) \rangle - y_i \leq \xi_i^* - b + \varepsilon \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, l \end{cases} \quad (4)$$

在引入核函数后,上式求得的非线性回归函数为:

$$\begin{aligned} f(x) &= w\phi(x) + b \\ &= \sum_{SV} (\alpha_j - \alpha_j^*) K(x_i, x_j) + b \end{aligned} \quad (5)$$

式中: $K(x_i, x_j) = \phi(x_i)\phi(x_j)$ 为核函数,核函数的选择需要满足 Mercer 条件。在应用中,常见的核函数有多项式核函数、径向基核函数及神经网络核函数。本文选取高斯径向基核函数 $K(x_i, x_j) = \exp(-\|x_i - x_j\|^2/\sigma^2)^d$, 在 MATLAB 环境下,运用 Libsvm^[20]工具箱实现 SVM 模型的建模。

2 模型构建

2.1 数据获取与处理

本文以祁连山中段典型小流域-排露沟流域(100°17'E, 38°24'N)为研究区,流域总面积为 2.85 km²,呈中卵形,长 4.25 km,纵坡比降 1: 4.19,海拔 2 650~3 800 m。研究区降水量随海拔上升而增加,平均每上升 100 m 增加 4.3%,在海拔 2 700 m 处,年均降水量为 375.5 mm。气温随着海拔上升则逐渐降低,从研究区海拔 2 650 m 处的 2℃ 逐渐降低到海拔 3 800 m 处的 -6.3℃。本研究所用数据为排露沟流域 2009-2013 年观测的日降水、径流资料。日降水量和径流量数据分别来源于排露沟流域出口处(海拔 2 700 m)布设的雨量观测点和三角围堰径流观测点。以 2009-2011 三年的日降水、径流数据作为训练样本,用以率定模型;用 2012-2013 年的日降水、径流数据作为测试样本以验证模型。

排露沟流域日降水量、径流量数据的基本统计资料见表 1。由表 1 可知,日径流数据的变异系数均大于 1,日降水数据的变异系数也均大于 3,两者的变异系数数值均较高,这可能会对模拟精度产生影响。此外,由于降水和径流具有不同的量纲,为保证

模型精度及有效性,在进行网络训练前先对原始数据进行归一化处理。本文所采用的预处理算法为:

$$Q = a \log(q + b) \quad (6)$$

$$\text{反归一化算法为: } q = 10^{Q/a} - b \quad (7)$$

表1 日降水量、径流量的基本统计值

样本	统计值	平均值	最大值	最小值	标准差	变异系数	偏度
训练样本	降水/mm	0.69	29.40	0	2.32	3.35	5.28
	径流/(m ³ ·d ⁻¹)	559.74	8841.10	9.15	1082.26	1.93	3.97
测试样本	降水/mm	1.14	29.70	0	3.46	3.03	4.41
	径流/(m ³ ·d ⁻¹)	501.27	5396.80	11.02	801.47	1.60	2.12
总样本	降水/mm	0.87	29.70	0	2.84	3.26	5.01
	径流/(m ³ ·d ⁻¹)	536.35	8841.12	9.15	979.83	1.83	3.69

式中: q 为原始序列, Q 为经过标准化处理后的转换序列, a 、 b 均为任意实数, 为避免 \log 函数中出现 0 值, 将 b 值设定为 1。数据经标准化处理后会加快模型的收敛速度, 更有利于网络训练。

2.2 模型构建及输入向量选择

对降水-径流模型来说, 降水和径流的动态数据构成时间序列 $\{Q_i\} = \{Q_1, Q_2, Q_3, \dots, Q_n\}$ 和 $\{R_i\} = \{R_1, R_2, R_3, \dots, R_n\}$ 。依据时间序列的理论, 时间序列的历史数据能揭示现象随时间变化的规律, 并且这种规律可以延伸到未来以进行预测。对日径流 $Q_{t+1}, Q_{t+2}, Q_{t+3}, \dots, Q_{t+7}$ 进行预测, 就是要寻找 $Q_{t+1}, Q_{t+2}, Q_{t+3}, \dots, Q_{t+7}$ 与前 m 个时刻降水 $R_t, R_{t-1}, \dots, R_{t-m+1}$ 和前 n 个时刻径流 $Q_t, Q_{t-1}, \dots, Q_{t-n+1}$ 之间的关系, 即:

$$Q_{t+i} = f(R_t, R_{t-1}, \dots, R_{t-m+1}, Q_t, Q_{t-1}, \dots, Q_{t-n+1}) \quad (8)$$

$(i = 1, 2, \dots, 7)$

因此, 日降水-径流模型的构建可以分成两部分: 第一部分是确定模型输入向量; 第二部分是分别利用确定的输入向量, 设置模型运行的基本控制参数, 建立中长期日径流预测 SVM 和 ANN 模型。数据驱动模型的输入向量直接影响着整个模型的模拟结果, 因此模型输入向量的选择是一项很重要的工作。目前互相关法是水文模型中选择输入向量最常用的方法^[21], 但这种方法一般只能找到输入和输出之间的线性关系。对于日降水-径流模型来说, 降水和径流之间很难用简单的线性关系来描述^[22]。因此, 本文选择相对百分比误差^[23] (Relative percentage error, RPE) 方法来确定径流预测模型的输入向量, 该方法通过逐次增加输入项的时滞数, 计算模型的均方根误差来选择最佳时滞数, 其计算公式为:

$$RPE = \frac{RMSE(L) - RMSE(L+1)}{RMSE(L)} \times 100 \quad (9)$$

式中: $RMSE(L)$ 和 $RMSE(L+1)$ 分别是时滞数为 L 和 $L+1$ 模型的均方根误差。当 $RPE < 5\%$ 时, L 便为最佳时滞数。利用该方法确定了公式(8)中 m 和 n 的最佳取值分别为 2 和 3。因此, 日径流预测模型可写为:

$$Q_{t+i} = f(R_t, R_{t-1}, Q_t, Q_{t-1}, Q_{t-2}) \quad (10)$$

$(i = 1, 2, \dots, 7)$

2.3 模型评价指标

为定量评价 ANN 和 SVM 的模拟效果, 模拟结果使用相关系数 (R)、均方根误差 ($RMSE$) 及效率系数 (NS) 作为评价指标。它们的计算公式如下:

(1) 相关系数 (R)

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (Q^o(i) - \bar{Q}^o)(Q^p(i) - \bar{Q}^p)}{\sqrt{\sum_{i=1}^n (Q^o(i) - \bar{Q}^o)^2} \sqrt{\sum_{i=1}^n (Q^p(i) - \bar{Q}^p)^2}} \quad (11)$$

(2) 均方根误差 ($RMSE$)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q^p(i) - Q^o(i))^2}{n}} \quad (12)$$

(3) 效率系数 (NS)

$$NS = 1 - \frac{\sum_{i=1}^n (Q^o(i) - Q^p(i))^2}{\sum_{i=1}^n (Q^o(i) - \bar{Q}^o(i))^2} \quad (13)$$

式中: n 是输入样本的个数; Q 和 \bar{Q} 分别指径流和径流的平均值; Q^o 和 Q^p 则分别代表径流的实测值和模拟值。 R 值和 NS 值越接近 1, $RMSE$ 值越接近 0 时, 模拟值与实测值的变化趋势越一致, 模拟精度越高。当模型取值: $R = 1, RMSE = 0, NS = 1$ 时, 可认为该模型为最佳模型。

3 结果与讨论

3.1 SVM 模型模拟结果分析

SVM 在 $t+1 \sim t+7$ d 的预测结果见表 2。由表 2 可知,随着预测时间的增加,SVM 的预测精度逐渐降低,但 SVM 在训练期的模拟精度高于测试期的。测试期时,SVM 在 $t+1 \sim t+7$ d 的 R 值均大于 0.7,表明 SVM 模型的模拟值和实测值之间具有很高程度的线性相关性;SVM 在 $t+1$ d 的 $RMSE$ 值为 $274.25 \text{ m}^3/\text{d}$,在 $t+7$ d 达到了 $550.86 \text{ m}^3/\text{d}$;从 NS 值来看,SVM 在 $t+1 \sim t+7$ d 的 NS 值均大于 0.5,这样的模拟精度是可以接受的^[24]。综上所述,随着预测时间的增加,SVM 的预测精度虽逐渐降低,但仍可以模拟到 $t+7$ d,这说明 SVM 模型可用于中长期日径流预测且有较高的预测精度。

表 2 SVM 在 $t+1 \sim t+7$ d 的模拟、预测结果

时间	R		$RMSE/(\text{m}^3 \cdot \text{d}^{-1})$		NS	
	训练	测试	训练	测试	训练	测试
$t+1$	0.96	0.94	324.43	274.25	0.91	0.88
$t+2$	0.94	0.91	393.06	329.41	0.87	0.83
$t+3$	0.94	0.86	366.67	437.57	0.89	0.70
$t+4$	0.94	0.84	386.56	457.00	0.87	0.68
$t+5$	0.89	0.82	500.14	470.19	0.79	0.66
$t+6$	0.87	0.76	537.28	525.75	0.75	0.57
$t+7$	0.85	0.75	585.53	550.86	0.71	0.53

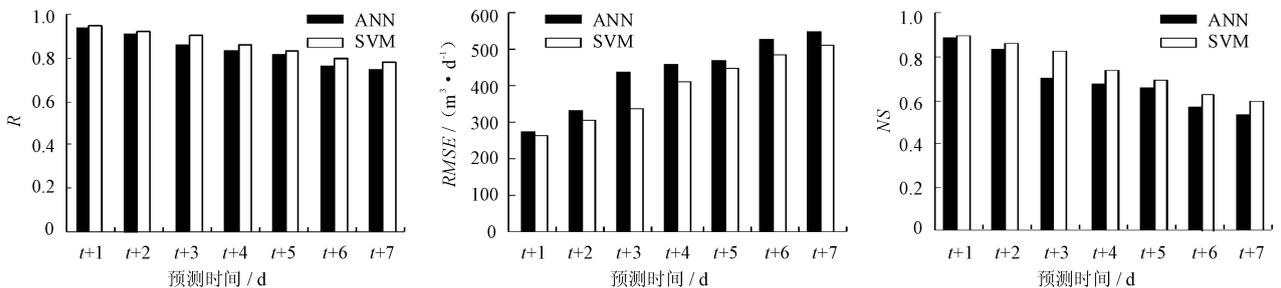


图 1 测试期中 SVM 和 ANN 在 $t+1 \sim t+7$ d 的评价指标值

随着预测时间的增加,SVM 和 ANN 模型的预测精度均逐渐降低(图 1)。从 R 值来看,SVM 和 ANN 的 R 值分别从 $t+1$ d 的 0.94 和 0.93 下降到 $t+7$ d 的 0.75 和 0.73,说明随着模拟天数的增加,径流预测值和实测值之间的线性相关性越来越弱,但 SVM 和 ANN 在 $t+7$ d 仍大于 0.73 的相关性也是比较高的。同时,SVM 在 $t+1$ d 的 $RMSE$ 值为 $274.25 \text{ m}^3/\text{d}$,到 $t+7$ d 达到了 $550.86 \text{ m}^3/\text{d}$,增加了 100.9%。ANN 的 $RMSE$ 值从 $t+1$ d 的 $308.23 \text{ m}^3/\text{d}$ 增加到 $t+7$ d 的 $563.74 \text{ m}^3/\text{d}$,增加了 82.9%。

3.2 模型预报精度对比分析

为验证 SVM 的有效性,在相同向量输入情况下,采用 ANN 方法进行对比研究。ANN 模型是在 MATLAB 环境下用 BP 神经网络算法通过循环训练实现。隐含层和输出层传递函数分别采用 tansig 和 purelin,训练函数采用 trainlm,利用试错法选取 BP 网络各个隐层神经元数,设定期望误差为 0.05,最大训练轮回为 20000 次。经过多次运行,最终确定日径流预测 ANN 模型。本文选取 SVM 和 ANN 模型在更为重要的测试期的表现进行对比。

由图 1 可知, $t+1$ d 时,SVM 和 ANN 的 R 值均大于 0.93, NS 值均大于 0.88,表明两个模型的模拟精度均较高;但 SVM 的 $RMSE$ 值 ($274.25 \text{ m}^3/\text{d}$) 要小于 ANN 的 ($308.23 \text{ m}^3/\text{d}$),说明 SVM 的模拟效果优于 ANN。因此,当预测时间为 1 d 时,SVM 和 ANN 均可用于日径流预测且预测精度非常高,但 SVM 的预测效果要优于 ANN。

He Zhibin 等^[18]在用数据驱动模型对排露沟流域进行短期($t+1$) d 日径流预测时也同样得出了 SVM 优于 ANN 的结论。其 SVM 在测试期中的 $RMSE$ 值为 $364.56 \text{ m}^3/\text{d}$,高于本文测试期中的 SVM 在 $t+1$ d 的 $RMSE$ 值 ($274.25 \text{ m}^3/\text{d}$),表明本文建立的 SVM 在短期日径流预测时表现出了更高的预测精度,这可能是由于本文日降水-径流模型的建立考虑了降水因素,使得模拟精度提高。

此外,SVM 和 ANN 在 $t+1$ 、 $t+2$ d 的 NS 值均在 0.8 以上,说明 SVM 和 ANN 在 $t+1$ 、 $t+2$ d 的预测精度非常高^[25];在 $t+3 \sim t+5$ d 的 NS 值均达到了 0.6,说明模型在 $t+3 \sim t+5$ d 的预测精度很高;在 $t+6$ 、 $t+7$ d 的 NS 值均大于 0.5,说明模型在 $t+6$ 、 $t+7$ d 的预测精度是可以接受的。以上分析表明 SVM 和 ANN 在 $t+1 \sim t+7$ d 的模型精度越来越低,预测能力逐渐变弱,但仍可预测到 $t+7$ d;相比于 ANN 模型,SVM 模型具有更高的预测精度。

为全面分析 SVM 和 ANN 的预报精度,还需考虑

两个模型的误差分布。由累积误差图(图2)可知,SVM和ANN在 $t+1 \sim t+7$ d的累积误差曲线坡度逐渐变缓,表明两个模型的预测精度逐渐降低。但整体来看,SVM的误差累积曲线大都在ANN的上方,这可从误差分布角度说明SVM的预测精度要高于ANN的。

洪峰预测是径流预测的重要内容,准确预测洪峰可以为制定合理的防洪预案提供重要依据。对比分析SVM和ANN在径流峰值的模拟效果(图3)发现,SVM和ANN的模拟结果均与实测值有较大误差,SVM和ANN都不能很好的模拟未来7 d的洪峰。

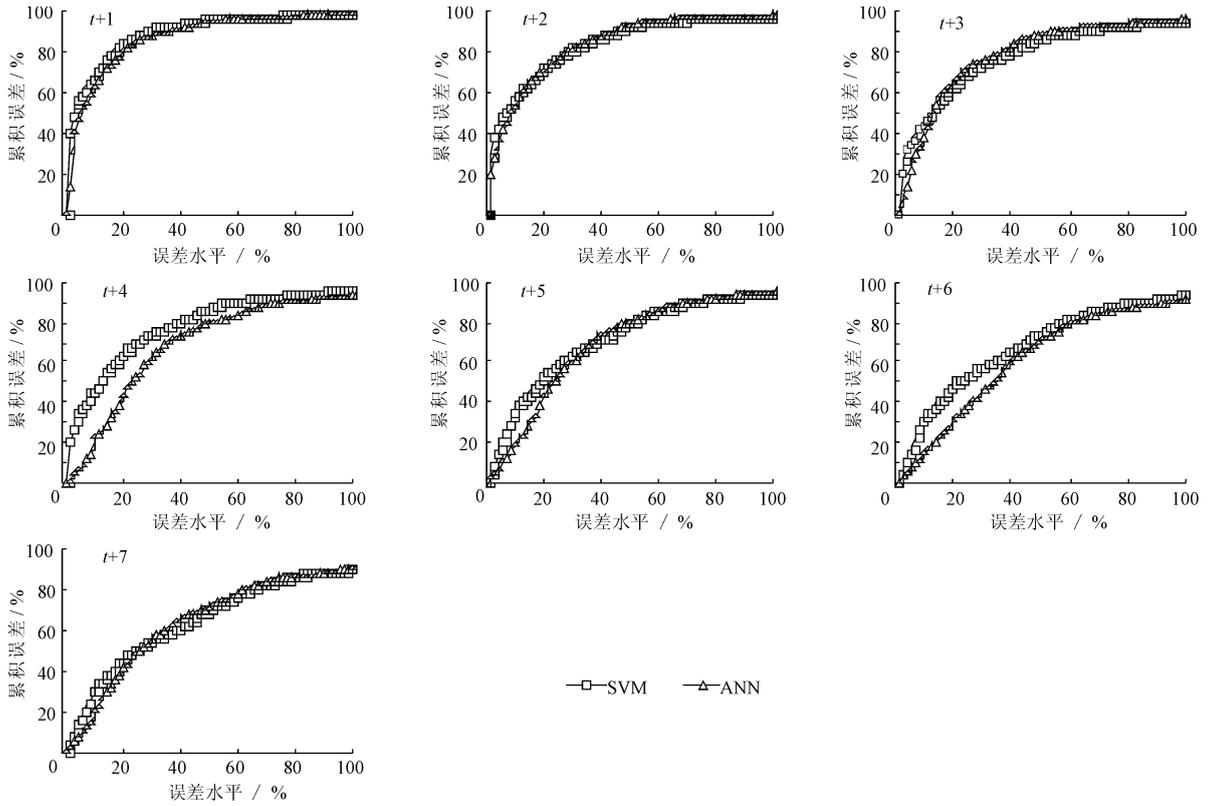


图2 测试期中SVM和ANN在 $t+1 \sim t+7$ d的累积误差

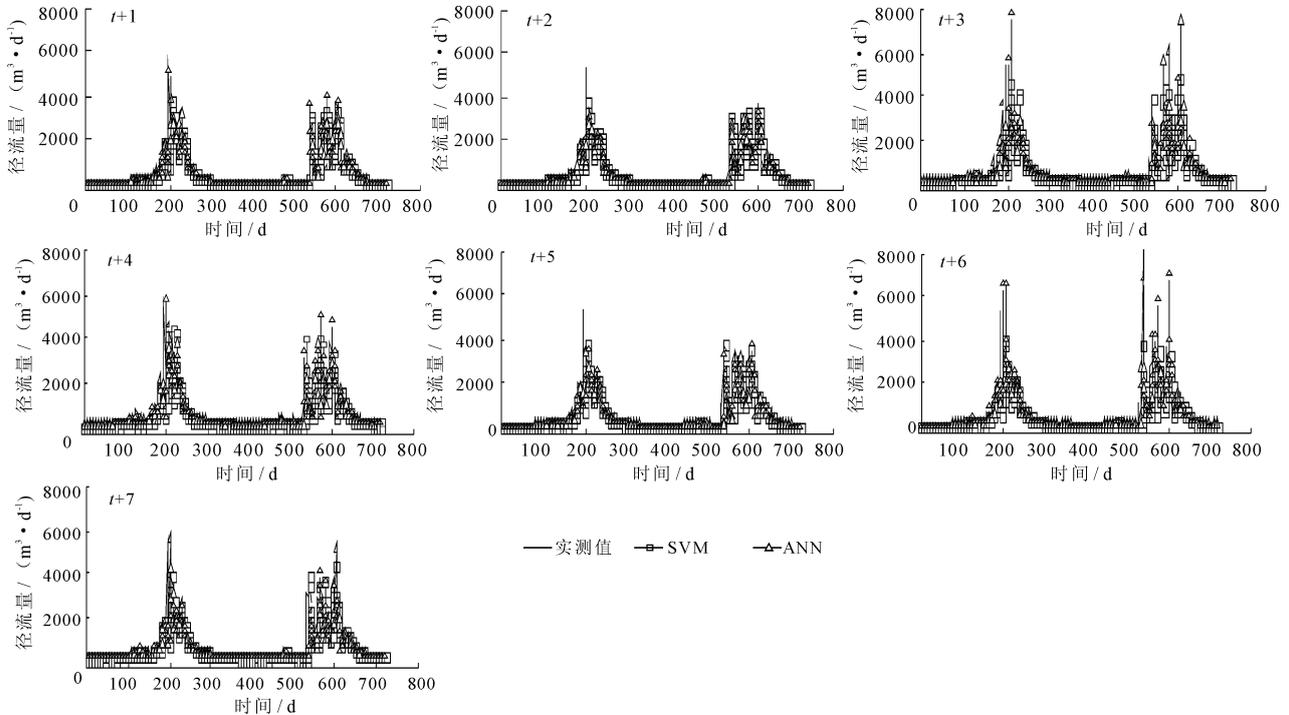


图3 测试期中SVM和ANN在 $t+1 \sim t+7$ d的预测径流与实测径流

但从整体的峰值预测上看(图 3),SVM 预测的峰值比 ANN 预测的峰值更接近实测值。这是由于 SVM 以结构风险最小化原则得到现有条件下的最优解,改变了 ANN 传统的经验最小化原则,得到的是全局最优解,而不是局部最小点,解决了 ANN 方法中无法避免的局部极值问题^[13]。

Nayak 等^[1]在利用数据驱动模型 ANFIS 模型进行短期洪水预测时,也出现了峰值预测误差大的情况,主要原因有两点:一是数据不足,二是只将日降水、径流数据作为模型输入过于单一。对于本研究而言,可能的原因还有:本研究区降水事件主要以 0~5 mm 降水为主,作为模型输入之一的降水序列即便经归一化处理仍有大量的 0 值,而大量 0 值的存在模型运行过程时会影响到径流峰值的模拟结果与精度,此时便容易出现模拟值和实测值误差较大的情况。

以上分别从模型的评价指标、误差分布以及洪峰预测 3 个方面对比分析了测试期中 SVM 和 ANN 的预测效果。结果表明,随着预测时间的增加,SVM 和 ANN 模型在未来 7 d 的径流预测精度也逐渐降低,但 SVM 和 ANN 在 $t + 7$ d 的预测也保持了较高的精度。另外,SVM 和 ANN 在径流峰值部分误差较大,都不能很好的模拟洪峰。但从整个径流序列上来看,除在峰值预测上误差较大之外,SVM 和 ANN 的模拟值和实测值均具有较好的拟合效果。总体而言,SVM 模型在日降水-径流模拟中的结果优于 ANN 模型。

4 结 语

SVM 和 ANN 在径流低值部分模拟结果很好,但在洪峰部分模拟结果较差,存在很大误差。不过 SVM 和 ANN 模型均可用于黑河上游排露流域的日径流短期模拟,且模拟精度较高。但随着预测时间的增加,SVM 和 ANN 模型的预测精度均呈降低的趋势,SVM 和 ANN 在 $t + 7$ d 的预测也保持了较高的精度。总体而言,SVM 模型优于 ANN 模型,说明 SVM 模型在排露流域具有更好的适用性,可以用于中长期日径流预测,为半干旱山区中长期水文预报提供了新的方法和思路,在资料有限的条件下能成为径流预测的有效工具。

但是本文建立的日降水-径流预测模型仍存在较多不足:首先在模拟洪水期的径流峰值时,明显偏低实测值;其次,SVM 模型参数精度不高也可能是峰值预测结果较差的原因;此外,由于研究区内冰川

积雪、冻土广布,形成了该区域特殊的寒区水文过程,温度、蒸发、冻融作用等都是影响日径流量变化的重要因素,只将日降水、径流数据作为模型输入过于单一。因此今后需要更多改进模型的尝试,以便真实地反映流域日径流的变化规律,提高预测精度。

参考文献:

- [1] Nayak P C, Sudheer K P, Rangan D M, et al. Short-term flood forecasting with a neuro fuzzy model[J]. *Water Resource Research*, 2005, 41(4): 1-16.
- [2] 杨旭, 栾继虹, 冯国章. 中长期水文预报研究评述与展望[J]. *西北农业大学学报*, 2000, 28(6): 203-207.
- [3] Wang Wenchuan, Chau K W, Cheng Chuantian, et al. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series[J]. *Journal of Hydrology*, 2009, 374(3-4): 294-306.
- [4] 张兰影, 庞博, 徐宗学, 等. 基于支持向量机的石羊河流域径流模拟适用性评价[J]. *干旱区资源与环境*, 2013, 27(7): 113-118.
- [5] 康尔泗, 程国栋, 蓝永超, 等. 西北干旱区内陆河流域出山径流变化趋势对气候变化响应模型[J]. *中国科学(D 辑)*, 1999, 29(Z1): 47-54.
- [6] 薛天柱, 马灿, 魏国孝, 等. 甘肃梨园河流域 SWAT 径流模拟预报[J]. *水资源与水工程学报*, 2011, 22(4): 61-65.
- [7] 宋倩, 穆振侠, 姜卉芳. SWAT 模型在天山西部山区的应用[J]. *水资源与水工程学报*, 2013, 24(3): 46-49.
- [8] 邢坤, 雷晓云, 雷晓辉, 等. 分布式水文模型 EasyDHM 在玛纳斯河流域径流模拟中的应用[J]. *水资源与水工程学报*, 2014, 25(4): 20-23.
- [9] 陈仁升, 康尔泗, 张济世. 基于小波变换和 GRNN 神经网络的黑河出山径流模型[J]. *中国沙漠*, 2001, 21(Z1): 12-16.
- [10] Lance E B, Donna M R, Paul R B, et al. Advances in ungauged streamflow prediction using artificial neural network[J]. *Journal of Hydrology*, 2010, 386(1-4): 27-37.
- [11] Maheswaran R, Khosa R. Wavelet-Volterra coupled model for monthly stream flow forecasting[J]. *Journal of Hydrology*, 2012, 450/451: 320-335.
- [12] Kisi O, Shiri J, Tombul M. Modeling rainfall-runoff process using soft computing techniques[J]. *Computer & Geosciences*, 2013, 51: 108-117.
- [13] 汪丽娜, 李粤安, 陈晓宏. 基于支持向量机的降雨-径流预测研究[J]. *水文*, 2009, 29(1): 13-16.
- [14] Lin Gwofong, Chen Guorong, Huang Peiyu, et al. Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warming periods[J]. *Journal of Hydrology*, 2009, 372(1-4): 17-29.

- Sciences,2012,13:1383 – 1394.
- [32] Garnier J, Nemery J, Billen G, et al. Nutrient dynamics and control of eutrophication in the Marne River system: modeling the role of exchangeable phosphorus [J]. *Journal of Hydrology*,2005,304(1 – 4):397 – 412.
- [33] Wang Shuo, Xu Ling, Yang Fenglin, et al. Assessment of water ecological carrying capacity under the two policies in Tieling City on the basis of the integrated system dynamics model [J]. *Science of The Total Environment*, 2014,472:1070 – 1081.
- [34] Garrido L, Sánchez O, Ferrera I, et al. Dynamics of microbial diversity profiles in waters of different qualities. Approximation to an ecological quality indicator [J]. *Science of The Total Environment*, 2014,468/469:1154 – 1161.
- [35] Gu Kangkang, Liu Jingshuang, Wang Yang. Analysis and prediction of ecological carrying capacity in mining cities of central Liaoning by system dynamics approach [J]. *Progress in Geography*,2009,28(6):870 – 876.
- [36] Davis A M, Thorburn P J, Lewis S E, et al. Environmental impacts of irrigated sugarcane production; Herbicide runoff dynamics from farms and associated drainage systems [J]. *Agriculture, Ecosystems & Environment*,2013,180:123 – 135.
- [37] Tan Yayi, Wang Xuan. An early warning system of water shortage in basins based on SD model [J]. *Procedia Environmental Sciences*,2010,2:399 – 406.
- [38] 刘振乾,王建武,骆世明,等. 基于水生态因子的沼泽安全阈值研究——以三江平原沼泽为例 [J]. *应用生态学报*, 2002,13(12):1610 – 1614.
- [39] Du Jing, Li Binghua, Xu Ling, et al. A multi-objective system dynamic model for urban ecological water demand simulation: a case study of Dalian city, China [C]// *International Conference on Energy and Environmental Science*,2011.
- [40] 杨怀宇,杨正勇. 池塘养殖(青虾)生态系统服务价值的系统动力学模型 [J]. *自然资源学报*,2012,27(7):1176 – 1185.
- [41] Zhang Z, Lu W X, Zhao Y, et al. Development tendency analysis and evaluation of the water ecological carrying capacity in the Siping area of Jilin Province in China based on system dynamics and analytic hierarchy process [J]. *Ecological Modelling*,2014,275:9 – 21.
- [42] Xu Yi, Sun Caizhi. Simulation of water resources carrying capacity based on a system dynamic model in Dalian [J]. *Journal of Safety and Environment*,2008,8(6):71 – 74.
- (上接第 31 页)
- [15] Guo Jun, Zhou Jianzhong, Qin Hui, et al. Monthly streamflow forecasting based on improved support vector machine model [J]. *Expert Systems with Applications*, 2011, 38(10):13073 – 13081.
- [16] 胡昌军. 基于改进相空间重构原理的支持向量机月径流模拟 [J]. *水资源与水工程学报*,2013,24(4):210 – 216.
- [17] 徐中民,蓝永超,程国栋. 人工神经网络方法在径流预报中的应用 [J]. *冰川冻土*,2000,22(4):372 – 375.
- [18] He Zhibin, Wen Xiaohu, Liu Hu, et al. A comparative study of artificial neural network, adaptive neuro – fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region [J]. *Journal of Hydrology*, 2014,509:379 – 386.
- [19] Vapnik V N. *The nature of statistical learning theory* [M]. New York: Springer,1999.
- [20] Chang Chihchung, Lin Chihjen. LIBSVM: a Library for support vector machines [J]. *ACM Transactions on Intelligent Systems and Technology*,2011,2(3):1 – 27.
- [21] Bowden G J, Dandy G C, Maier H R. Input determination for neural network models in water resource applications. Part I – Background and methodology [J]. *Journal of Hydrology*,2005,301(1 – 4):75 – 92.
- [22] 张立杰,赵文智,何志斌,等. 祁连山典型小流域降水特征及其对径流的影响 [J]. *冰川冻土*,2008,30(5):776 – 782.
- [23] Lin Gwofong, Chen Guorong, Wu Mingchang, et al. Effective forecasting of hourly typhoon rainfall using support vector machines [J]. *Water Resources Research*, 2009, 45:1 – 11.
- [24] 中华人民共和国水利部. SL250 – 2000 水文情报预报规范 [S]. 北京:中国水利水电出版社,2000.
- [25] Shu C, Ouarda T B M J. Regional flood frequency analysis at ungauged sites using the adaptive neural – fuzzy inference system [J]. *Journal of Hydrology*,2008, 349(1 – 2):31 – 43.