

DOI:10.19853/j.zgjsps.1000-4602.2023.09.008

基于多粒度泄漏积分回声状态网络的日供水量预测

白云¹, 严政杰¹, 张晋², 李川¹

(1. 重庆工商大学 管理科学与工程学院, 重庆 400067; 2. 河海大学长江保护与绿色发展研究院 水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098)

摘要: 针对多粒度因子耦合对城市日供水量产生的不确定性影响,提出一种基于多粒度挖掘与泄漏积分型回声状态网络(LiESN)的组合预测模型X11+LiESN,以提高城市日供水量预测精度。利用重庆市某水厂2018年1月1日—2020年12月31日的日供水量数据对该方法进行有效性验证。结果表明,所提出模型的平均绝对百分比误差(MAPE)为3.42%,决定系数(R^2)为0.862。与单一的LiESN、极限学习机(ELM)和BP神经网络(BPNN)相比,该模型预测精确度高,能够更好地描述日供水量变化趋势,显示出了其有效性和应用潜力。

关键词: X11分解算法; 粒度挖掘; 回声状态网络; 水量预测

中图分类号: TU991 **文献标识码:** A **文章编号:** 1000-4602(2023)09-0050-07

Prediction of Daily Water Supply Based on Multi-granularity Leakage Integral Echo State Network

BAI Yun¹, YAN Zheng-jie¹, ZHANG Jin², LI Chuan¹

(1. School of Management Science and Engineering, Chongqing Technology and Business University, Chongqing 400067, China; 2. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Yangtze Institute for Conservation and Development, Hohai University, Nanjing 210098, China)

Abstract: Aiming at the uncertain impact of multi-granularity factor coupling on urban daily water supply, a combined prediction model X11+LiESN based on multi-granularity mining and leakage integral echo state network (LiESN) was proposed to improve the prediction accuracy of urban daily water supply. The effectiveness of the model was verified by using daily water supply data of a water treatment plant in Chongqing from January 1, 2018 to December 31, 2020. The mean absolute percentage error (MAPE) of the proposed model was 3.42%, and the coefficient of determination (R^2) was 0.862. Compared with single models of LiESN, extreme learning machine (ELM) and BP neural network (BPNN), the model exhibited higher prediction accuracy and better description of daily water supply trend, and thus showed its effectiveness and application potential.

Key words: X11 decomposition algorithm; granularity mining; echo state network; water supply prediction

基金项目: 国家自然科学基金资助项目(72271036、71801044、42077156、52121006); 重庆市自然科学基金资助项目(CSTB2022NSCQ-MSX0510)

通信作者: 张晋 E-mail: jin.zhang@hhu.edu.cn

城市日供水量预测对于城市合理规划和可持续发展具有重要意义^[1],准确的城市日供水量预测可为供水系统高效运行和稳定维护提供安全保障。在智慧城市建设的推动下,城市智能供水系统的完善显得尤为重要,同时也是城市供水系统在未来发展的趋势。

近年来,高精度且高效的的城市日供水量预测技术越来越受到学者的关注。城市供水量预测技术一般可分为传统预测技术与机器学习预测技术。传统预测技术如ARIMA^[2]、指数平滑^[3]等模型的结构简单,但在处理复杂和非线性时间序列方面存在局限性,导致预测精度低^[4]。基于大数据的机器学习技术能挖掘数据间的隐含关系,可用于细粒度、非平稳的日供水量预测,如关联向量机^[5]、长短期记忆神经网络^[6]、深度信念网络^[7]等,并表现出了优异的预测效果。目前,机器学习技术为预测领域的主流建模工具,可通过其自学习能力构建一个复杂的网络模型。标准回声状态网络(ESN)是一种新型递归神经网络,其隐层为具有多个神经元稀疏连接的储备池。储备池的生成过程与标准ESN的训练过程相独立,在训练过程中仅需使用线性方法计算其输出层连接权值以完成训练学习,简化了网络训练过程,具有网络全局最优性高、计算复杂度低的优点^[8]。ESN模型已被大量应用到多个领域中,如故障检测^[9]、机器人控制^[10]等,尤其在时间序列预测领域^[11-13]取得了较为突出的贡献。作为标准ESN的改进,泄漏积分型回声状态网络(LiESN)通过泄漏率的调节,实现对慢特性和连续动态系统的学习,是一种学习能力更强的动态递归神经网络^[14]。由于日供水量影响因素耦合的复杂性,为减少原始时间序列中的波动性和随机性,常采用时间序列分解的数据预处理技术挖掘出若干规律性较强、波动性较弱的粒度,从而有效提高预测精度。

基于以上分析,笔者提出了一种基于多粒度挖掘与LiESN的城市日供水量预测模型。首先,利用经典X11分解算法对原始时间序列进行粒度挖掘;然后,根据各粒度特征分别构建LiESN预测模型;最后,将分预测模型的预测结果进行重构,得到最终预测值。以重庆市某水厂的供水量数据集作为案例,将所提出的模型与单一LiESN模型、极限学习机(ELM)模型、BP神经网络(BPNN)模型的预测结果进行对比分析。

1 数学模型

1.1 经典X11分解算法

时间序列中每一时间段的数据都是由许多不同的因素同时发生作用的综合结果,根据各因素的影响效果,可将各因素分为长期趋势、季节变动和残差三大类,认为时间序列是由这三大类变化形式叠加而成的结果。同样,供水量数据包含长期趋势、季节变动等信息,为提取这几种粒度信息,设供水量序列 Y_t 有 t 个按日期排列数据,即 $Y_t = (y_1, y_2, \dots, y_t)$,选用经典时序分解中的X11分解法对该序列进行分解。长期趋势是时间序列在较长时间内连续不断地向一定方向持续发展,反映的是供水量序列随时间变化的总体趋势;季节变动是由于自然条件和社会条件的影响,体现序列在某一时期依一定周期规则性的变化规律;残差项是各种外界因素随机引起的变动,反映了序列随其他影响因素的变化规律。

X11分解算法能处理加法模型和乘法模型,整个过程对于时间序列中的异常值和数据变动具有很强的鲁棒性,其加法与乘法分解公式如下:

$$Y_t = T_t + S_t + R_t \quad (1)$$

$$Y_t = T_t \times S_t \times R_t \quad (2)$$

式中: Y_t 为 t 时期内的时间序列值, $t=1, 2, 3, \dots, l$; T_t 为趋势粒度; S_t 为季节粒度; R_t 为残差粒度。

经典时序分解算法步骤相对简单,同时也是其他分解算法的基础,将其用到简单滑动平均法中,具体如下:

$$T_t = \frac{1}{m} \sum_{j=-k}^k y_{t+j} \quad (3)$$

式中: T_t 为滑动平均后的时间序列,即为趋势粒度; y_t 为第 t 天的供水量; m 为滑动平均的时期个数, $m=2k+1$,即第 t 天的滑动平均值为向前 k 个值与向后 k 个值的均值。

X11分解算法过程为:①首先利用移动平均式(3)计算得到移动平均数序列,即为供水量时间序列的趋势粒度 \hat{T}_t ;②计算去掉趋势的时间序列 $Y_t/\hat{T}_t = S_t \times R_t$,将观测值除以移动平均数得到的比率值只包含季节粒度和残差粒度;③由于残差粒度是随机的、没有固定模式的、围绕均值上下波动的因素,因此通过平均便能剥离残差粒度的影响,利

用 $\overline{S_i \times R_i} = S_i$, 其中 $\overline{S_i \times R_i}$ 表示季节粒度的 m 个平均值, 该季节粒度无量纲; ④最后利用 $R_i = Y_i/S_i$ 得到残差粒度, 该残差粒度无量纲, 多粒度供水信息挖掘完成。

1.2 LiESN 模型构建

标准 ESN 是一种新型的递归神经网络(RNN), 通过使用大规模随机稀疏网络(储备池)作为信息处理媒介, 将输入信号从低维输入空间映射到高维状态空间, 并在高维状态空间采用线性回归方法对输出权值矩阵 W^{out} 进行训练。为达到高逼近能力, 它必须满足回声状态特性(ESP), 标准 ESN 的网络结构如图 1 所示。LiESN 与标准 ESN 的结构相似, LiESN 在标准 ESN 的模型里引入泄漏积分神经元, 使网络能够记忆其上一时刻状态的同时逐渐失去收集的信息, 能够显著提高 LiESN 的短期记忆能力, 更适合描述连续变化的动态系统^[15]。

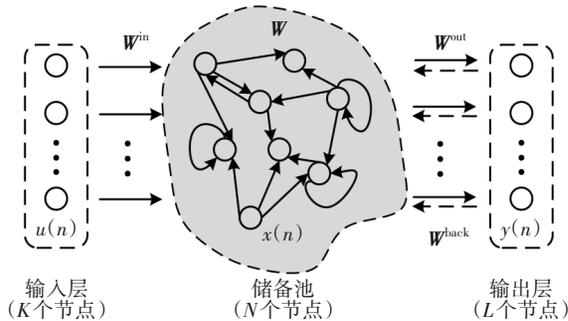


图 1 ESN 网络结构示意图

Fig.1 Schematic diagram of ESN network structure

由图 1 可知, LiESN 同其他递归神经网络相同, 由输入层、隐藏层、输出层组成。网络在 n 时刻的输入向量 $u(n)$ 、储备池计算向量 $x(n)$ 及输出向量 $y(n)$ 分别见式(4)~(6)。

$$u(n) = [u_1(n), u_2(n), \dots, u_k(n)]^T \quad (4)$$

$$x(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T \quad (5)$$

$$y(n) = [y_1(n), y_2(n), \dots, y_L(n)]^T \quad (6)$$

式中: 离散时间 $n=1, 2, \dots, k$ 。

由于引入了储备池计算模式, LiESN 的核心为隐藏层动态储备池, 通过使用大规模随机稀疏网络(储备池)作为信息处理媒介, 将输入信号从低维输入空间映射到高维状态空间, 并且通过调整内部权值的特性达到记忆数据的功能。在连续时间内 LiESN 储备池的状态更新微分方程表示为:

$$\frac{dx(n)}{dn} = \beta \{-ax(n) + f[W^{in}u(n) + \rho Wx(n) + W^{back}y(n)]\} \quad (7)$$

式中: a 为泄漏率, $a>0$; β 为时间系数, $\beta>0$; W^{in} 为 $N \times K$ 的输入连接权值矩阵; W 为 $N \times N$ 的储备池连接权值矩阵, W 的谱半径为 ρ ; W^{out} 为 $L \times (K + N)$ 的输出连接权值矩阵; W^{back} 为 $N \times L$ 的输出反馈连接权值矩阵; f 为储备池中的激活函数, 选取 tanh 函数。

将式(7)离散化, 便得到给定网络输入 $u(n)$ 的状态方程:

$$x(n+1) = (1 - a\beta)x(n) + \beta f[W^{in}u(n+1) + \rho Wx(n) + W^{back}y(n)] \quad (8)$$

当式(8)中 a 和 β 均取 1 时, 式(8)即变换为标准 ESN 储备池的状态方程。若 $a>0, \beta>0$, 且 $a\beta \leq 1$, 谱半径 $\rho \in [0, 1)$, 则网络具有 ESP 特性。当 a, β, ρ 之一发生改变时, 其对结果的影响可由其他参数弥补, 并不会影响网络的 ESP 特性^[16]。因此, 为简化模型, 使 $\beta=1$, 则式(8)简化为:

$$x(n+1) = (1 - a)x(n) + f[W^{in}u(n+1) + \rho Wx(n) + W^{back}y(n)] \quad (9)$$

LiESN 在高维状态空间采用线性回归方法计算输出权值矩阵 W^{out} , 而 W^{in} 和 W 随机生成, 并在网络训练过程中始终保持不变, 则其网络输出表示为:

$$y(n+1) = g\{W^{out}[x(n+1); u(n+1); y(n)]\} \quad (10)$$

式中: g 为输出激活函数, 选取恒等函数。

1.3 日供水量组合预测模型

利用 X11 分解法对供水量时间序列进行挖掘得到 3 个粒度后, 使用 LiESN 对各粒度建立分预测模型, 取得预测值后, 将各分量值利用原分解公式进行重构得到最终的预测值。综上, 基于多粒度泄漏积分回声状态网络的城市日供水量预测模型建模流程如图 2 所示。具体建模步骤如下: ①利用 X11 技术对供水量时间序列进行分解, 挖掘获得趋势粒度 T_i 、季节粒度 S_i 和残差粒度 R_i ; ②为归纳统一样本的统计分布性, 将得到的每个粒度序列数据进行归一化处理, 范围在 $[0, 1]$; ③对趋势粒度 T_i 、季节粒度 S_i 和残差粒度 R_i 分别建立 LiESN 模型进行预测; ④为建立 LiESN 的 ESP 特性, 调节网络各参数, 并将储备池内部的连接权值矩阵谱半径设置在 $[0, 1)$;

⑤将各分预测模型的预测值反归一化后进行数据重构,得到最终预测值。

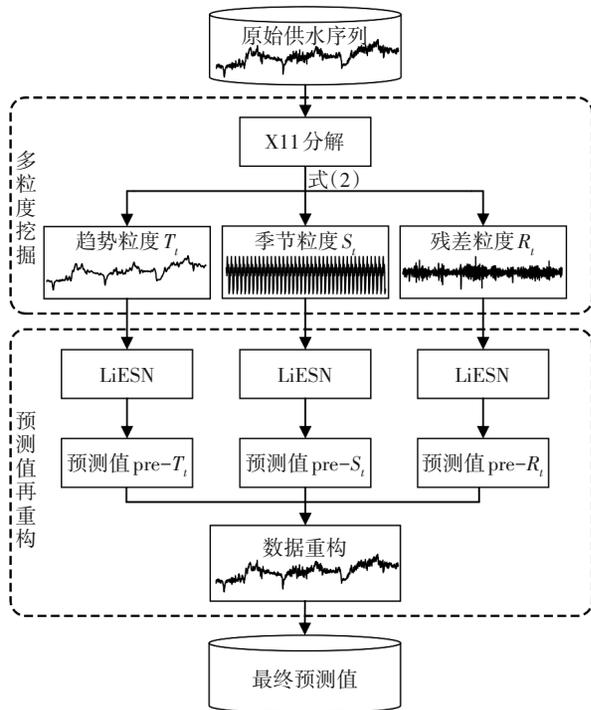


图2 建型流程

Fig.2 Modeling process

2 实验数据与评价指标

2.1 实验数据

实验数据来自重庆市某水厂2018年—2020年的供水量数据。该数据集包含1 096个数据点,其中2018年1月1日—2019年12月31日的日供水序列数据作为训练集(共730个数据),将2020年1月1日—12月31日的日供水序列数据作为测试集(共366个数据)。其原始时间序列如图3所示。

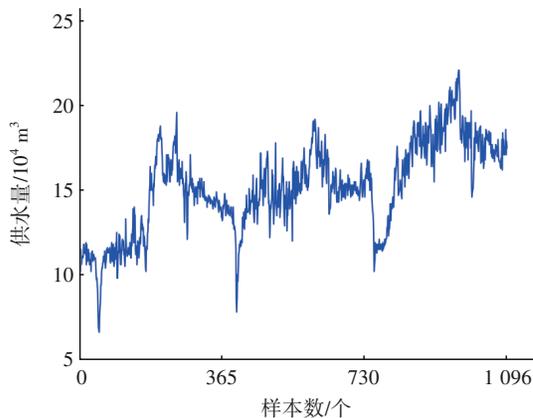


图3 供水量序列数据

Fig.3 Water supply data sequence

2.2 评价指标

为衡量城市日供水量预测模型的性能,采用了4个评价标准:平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)、决定系数(\$R^2\$),计算公式如下:

$$MAE = \frac{1}{E} \sum_{e=1}^E |y_e - \hat{y}_e| \quad (11)$$

$$MAPE = \frac{100}{E} \sum_{e=1}^E \left| \frac{y_e - \hat{y}_e}{y_e} \right| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{E} \sum_{e=1}^E (y_e - \hat{y}_e)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{e=1}^E (y_e - \hat{y}_e)^2}{\sum_{e=1}^E (y_e - \bar{y})^2} \quad (14)$$

式中:\$e=1, 2, \dots, E\$, \$E\$是输出数据序列的长度;\$y_e\$为第\$e\$天的实测值;\$\hat{y}_e\$为第\$e\$天的预测值;\$bar{y}\$为实测值的平均值。

3 结果与分析

3.1 多粒度挖掘

结合图3可知,供水量总体呈上升趋势,趋势性的强弱随着时间推移而发生变化,故选择X11法的乘法分解。为体现供水量的周效应,设置滑动平均时期个数\$m=7\$,其分解后的各粒度时序数据见图4。

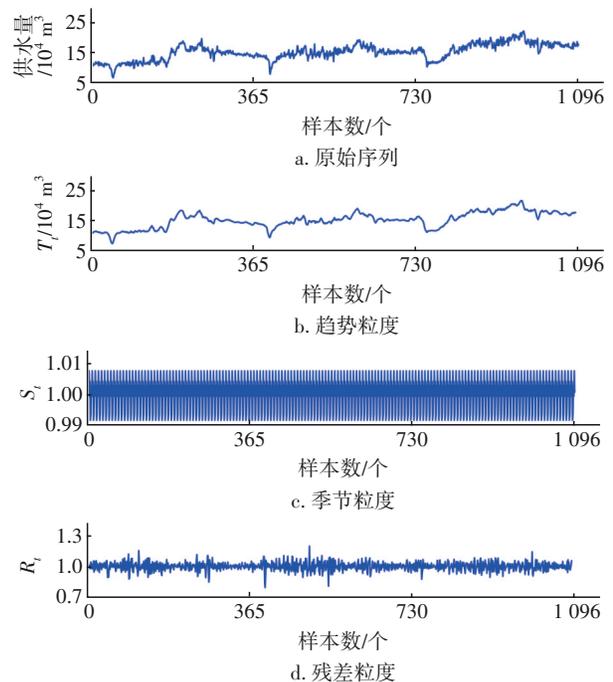


图4 供水序列分解结果

Fig.4 Decomposition results of water supply sequence

图 4(b)反映了 3 年供水量总体呈上升趋势,相较于图 4(a),趋势粒度序列数据曲线更为平滑,这是 X11 分解法对数据进行滑动平均的效果;图 4(c)中季度粒度按照一定周期不断循环变动;而图 4(d)的残差粒度则由于外界因素的随机干扰,未呈现任何变化规律。

3.2 供水量预测模型的建立

基于 Matlab R2020a 工具平台建立模型。为确定 LiESN 中的关键参数,经实验验证,各子预测模型中的关键参数,如泄漏率(α)、储备池权值矩阵谱半径(ρ)、储备池神经元数(RU)、输入缩放尺度因子(IS)、稀疏度(C)设置见表 1。

表 1 各分预测模型关键参数

Tab.1 Key parameters of each sub-prediction model

LiESN	α	ρ	RU	IS	C
趋势粒度	0.5	0.7	16	0.9	0.625
季节粒度	0.9	0.8	20	0.9	0.500
残差粒度	0.5	0.6	20	0.5	0.500

3.3 LiESN 预测

根据多粒度挖掘的结果,对每个粒度分别建立分预测模型,并且将每个分模型重复运行 20 次预测值的平均值作为分模型的预测值,最后将预测数据进行重构输出作为最终的预测结果。X11+LiESN 在重构 3 种粒度测试集数据时,加入残差与去掉残差的预测结果如图 5 所示,各模型误差结果如表 2 所示。从图 5 可以看出,所提出的模型能够在短期尺度上基本还原真实供水量曲线的变化趋势。并且,结合表 2 能够发现,加入残差的结果具备更高的预测精度。

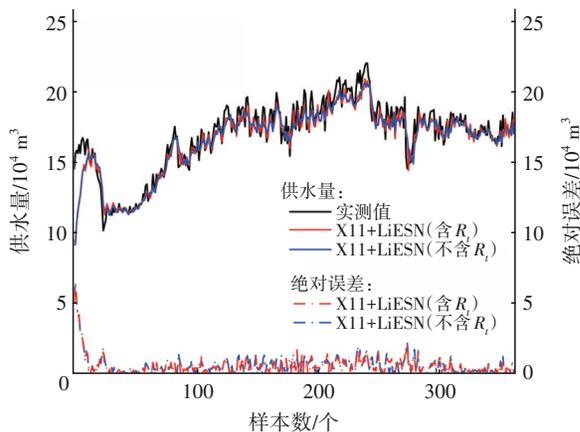


图 5 X11+LiESN 对测试集的预测结果

Fig.5 Prediction results of X11+LiESN on test set

表 2 各模型误差结果

Tab.2 Error results of each model

模型	MAE/ ($\text{m}^3 \cdot \text{d}^{-1}$)	RMSE/ ($\text{m}^3 \cdot \text{d}^{-1}$)	MAPE/%	R^2
X11+LiESN(含 R_t)	5 827	9 077	3.42	0.862
X11+LiESN(不含 R_t)	6 198	9 518	3.64	0.849

加入残差后,MAE降低了 371 m^3/d ,RMSE降低了 441 m^3/d ,MAPE降低了 0.22%, R^2 提高了 0.013。说明日供水量存在外界因素的随机干扰,且在重构数据时加入分解出的残差粒度能提升模型的精度。在测试集的前 9 d,虽然所提出的模型表现性能欠佳(与其他模型相比,仍处于优势),但之后迅速跟踪实际数据变化曲线,表现出了优秀的回归能力。

3.4 效果分析

为了检验所提出的组合预测模型的有效性,使用相同的供水序列对单一 LiESN 模型、BPNN 模型与 ELM 模型进行建模仿真,每个模型同样重复运行 20 次取其平均值作为最终预测值,各模型预测曲线和绝对误差曲线如图 6 所示。

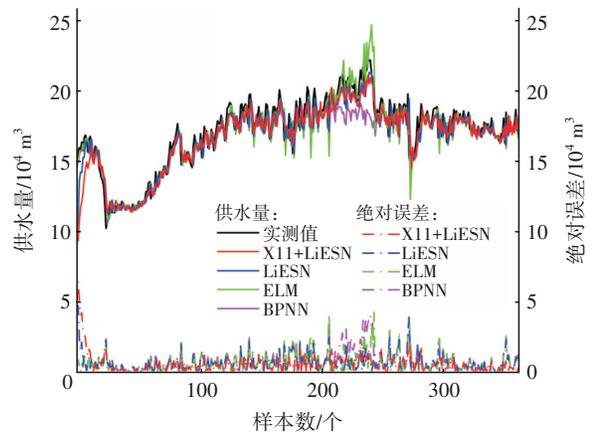


图 6 不同模型的预测曲线和绝对误差曲线

Fig.6 Prediction curves and absolute error curves of different models

由图 6 可知,由于 2020 年年初受新冠疫情影响,多数工厂停工,1 月底至 3 月中旬的供水量较往年明显降低,各神经网络预测模型能够较好地描述这段时期日供水量的趋势变化。而在夏季供水量高峰时,所提出模型和 LiESN 模型的供水量预测曲线能够反映真实供水量的趋势变化,单一 BPNN 模型和 ELM 模型的预测效果无法准确反映夏季供水量的趋势变化。比较整体预测效果,所提出模型与 LiESN 模型能够较好地抵御外界因素对日供水量的

干扰。

从图6还可知,所提出模型的预测绝对误差较其他3个单一模型的误差小(X11+LiESN、LiESN、ELM、BPNN模型的平均绝对误差分别为5 827、7 080、7 536、8 238 m^3/d),说明X11法挖掘影响城市供水量的粒度因子利于提高预测精度。同时可以看出,单一ELM模型和BPNN模型在夏季高供水期间的预测绝对误差较大,说明供水量增大时,单一ELM模型和BPNN模型不能很好地学习其变化趋势,而单一LiESN模型能够描述供水量的动态行为,表明LiESN能对连续、非平稳、非线性的动态系统完成复杂建模,具有很好的应用潜力。

为展现各模型预测值的绝对误差分布情况,绘制了绝对误差箱线图,如图7所示。所提出模型的离群点数为13, LiESN的离群点数为15, ELM的离群点数为14, BPNN的离群点数为17。从箱线图上限看,所提出模型的上限更低;从箱身高度看(上四分位数与下四分位数的差值),所提出模型的箱身高度更低。从箱身中位线看,所提出模型的误差中位线更低。因此, X11+LiESN模型预测效果最佳。

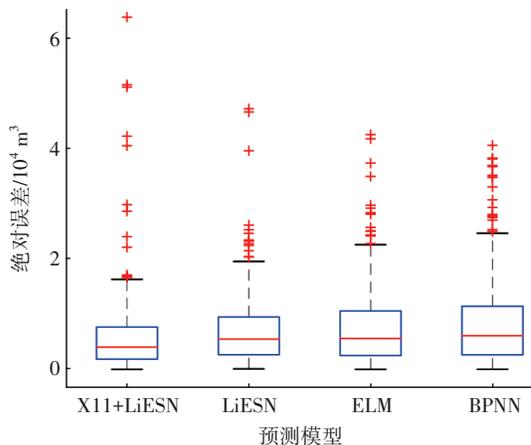


图7 不同预测模型的绝对误差箱线图

Fig.7 Absolute error box diagrams of different prediction models

为进一步体现各模型的预测效果,从4个维度绘制了评价指标雷达图,如图8所示。所提出的模型在横轴以上,由MAE、 R^2 、MAPE所围成的三角形越高,其底边越窄;在横轴以下,由MAE、RMSE、MAPE所围成的三角形面积更小,表明所提出模型能够挖掘到城市日供水量的细粒度特征,并对各粒度特征表现出优异的跟踪能力。从图8可知,所提出的组合预测模型优于单一LiESN预测模型,是由

于X11算法中的滑动平均法挖掘出的趋势粒度平滑了原始序列中的峰值,并且挖掘出的季节粒度体现了供水量的周效应,使之更容易预测。单一LiESN模型优于ELM模型和BPNN模型,是因为LiESN储备池内部生成随输入不断变化的复杂动态空间,以及其网络拥有的记忆能力,能进一步对数据进行复杂变换和映射,发现数据间的隐含关系。

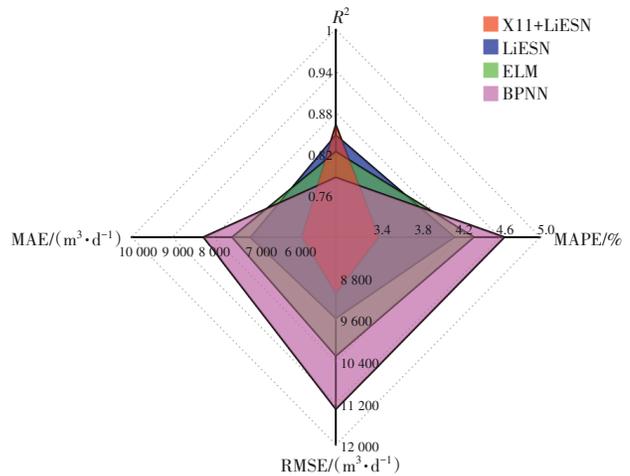


图8 不同预测模型评价指标雷达图

Fig.8 Evaluation indexes radar charts of different prediction models

4 结论

① 通过经典时序分解挖掘粒度因子,能将日供水量时序中隐含的、基本的、潜在的模式和随机波动区分开来,能够深度挖掘更多更充分的时序信息,明晰其内在信息。因此,将粒度概念引入到日供水量预测中具有非常重要的意义。

② X11+LiESN组合模型的预测评价指标均优于单一LiESN模型、ELM模型、BPNN模型,说明城市日供水量受到多因素耦合影响而产生非平稳性和非线性的时间序列数据,组合预测模型通过挖掘多粒度因子进行局部建模预测能使单一预测模型的预测精度有明显提升。

参考文献:

- [1] 朱波,郑飞飞,刘业政,等.面向智慧城市的合肥智慧供水规划与建设[J].中国给水排水,2021,37(6):143-148.
ZHU Bo, ZHENG Feifei, LIU Yezheng, et al. Planning and construction of smart water supply for smart city in Hefei[J]. China Water & Wastewater, 2021, 37(6): 143-148(in Chinese).

- [2] JAMIL R. Hydroelectricity consumption forecast for Pakistan using ARIMA modeling and supply-demand analysis for the year 2030 [J]. *Renewable Energy*, 2020, 154: 1–10.
- [3] SU Y, GAO W J, GUAN D J, *et al.* Dynamic assessment and forecast of urban water ecological footprint based on exponential smoothing analysis [J]. *Journal of Cleaner Production*, 2018, 195: 354–364.
- [4] GUO G C, LIU S M, WU Y P, *et al.* Short-term water demand forecast based on deep learning method [J]. *Journal of Water Resources Planning and Management*, 2018, 144(12): 4018076.
- [5] BAI Y, WANG P, LI C, *et al.* A multi-scale relevance vector regression approach for daily urban water demand forecasting [J]. *Journal of Hydrology*, 2014, 517: 236–245.
- [6] 苟非洲, 程玉婷. 基于长短期记忆网络的日供水量预测方法研究 [J]. *中国给水排水*, 2019, 35(17): 79–83.
GOU Feizhou, CHENG Yuting. Daily water supply forecasting method based on long short-term memory network [J]. *China Water & Wastewater*, 2019, 35(17): 79–83 (in Chinese).
- [7] XU Y B, ZHANG J, LONG Z Q, *et al.* Daily urban water demand forecasting based on chaotic theory and continuous deep belief neural network [J]. *Neural Processing Letters*, 2019, 50(2): 1173–1189.
- [8] ZHONG S S, XIE X L, LIN L, *et al.* Genetic algorithm optimized double-reservoir echo state network for multi-regime time series prediction [J]. *Neurocomputing*, 2017, 238: 191–204.
- [9] LEMOS T, CAMPOS L F, MELO A, *et al.* Echo state network based soft sensor for monitoring and fault detection of industrial processes [J]. *Computers & Chemical Engineering*, 2021, 155: 107512.
- [10] CALANDRA M, PATANE L, SUN T, *et al.* Echo state networks for estimating exteroceptive conditions from proprioceptive states in quadruped robots [J]. *Frontiers in Neurorobotics*, 2021, 15: 655330.
- [11] BAI Y L, LIU M D, DING L, *et al.* Double-layer staged training echo-state networks for wind speed prediction using variational mode decomposition [J]. *Applied Energy*, 2021, 301: 117461.
- [12] NA X D, REN W J, XU X H. Hierarchical delay-memory echo state network: a model designed for multi-step chaotic time series prediction [J]. *Engineering Applications of Artificial Intelligence*, 2021, 102: 104229.
- [13] PENG L, LV S X, WANG L, *et al.* Effective electricity load forecasting using enhanced double-reservoir echo state network [J]. *Engineering Applications of Artificial Intelligence*, 2021, 99: 104132.
- [14] 李军, 李青. 基于 CEEMDAN-排列熵和泄漏积分 ESN 的中期电力负荷预测研究 [J]. *电机与控制学报*, 2015, 19(8): 70–80.
LI Jun, LI Qing. Medium term electricity load forecasting based on CEEMDAN-permutation entropy and ESN with leaky integrator neurons [J]. *Electric Machines and Control*, 2015, 19(8): 70–80 (in Chinese).
- [15] 伦淑娴, 林健, 姚显双. 基于小世界回声状态网的时间序列预测 [J]. *自动化学报*, 2015, 41(9): 1669–1679.
LUN Shuxian, LIN Jian, YAO Xianshuang. Time series prediction with an improved echo state network using small world network [J]. *Acta Automatica Sinica*, 2015, 41(9): 1669–1679 (in Chinese).
- [16] 李军, 岳文琦. 基于泄漏积分型回声状态网络的软测量动态建模方法及应用 [J]. *化工学报*, 2014, 65(10): 4004–4014.
LI Jun, YUE Wenqi. Dynamic soft sensor modeling and its application using leaky-integrator ESN [J]. *CIESC Journal*, 2014, 65(10): 4004–4014 (in Chinese).

作者简介:白云(1985–),男,山西阳泉人,博士,副教授,硕士生导师,主要研究方向为智能预测建模及水资源管理。

E-mail:yunbai@ctbu.edu.cn

收稿日期:2022-02-20

修回日期:2022-07-11

(编辑:任莹莹)