



武汉大学学报(信息科学版)

*Geomatics and Information Science of Wuhan University*

ISSN 1671-8860, CN 42-1676/TN

## 《武汉大学学报(信息科学版)》网络首发论文

题目： 结合季节调整和 NAR 神经网络的流域地下水储量预测  
作者： 王杰龙, 杨玲, 陈义, 沈云中  
DOI: 10.13203/j.whugis20210584  
收稿日期: 2022-04-02  
网络首发日期: 2022-04-17  
引用格式: 王杰龙, 杨玲, 陈义, 沈云中. 结合季节调整和 NAR 神经网络的流域地下水储量预测[J/OL]. 武汉大学学报(信息科学版).  
<https://doi.org/10.13203/j.whugis20210584>



**网络首发:** 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

**出版确认:** 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

## 用格式：

王杰龙, 杨玲, 陈义, 等. 结合季节调整和 NAR 神经网络的流域地下水储量预测[J]. 武汉大学学报·信息科学版, 2022, DOI: 10.13203/j.whugis20210584 (WANG Jielong, YANG Ling, CHEN Yi, et al. Prediction of Watershed Groundwater Storage Based on Seasonal Adjustment and NAR Neural Network[J]. *Geomatics and Information Science of Wuhan University*, 2022, DOI: 10.13203/j.whugis20210584)

## 结合季节调整和 NAR 神经网络的流域地下水储量预测

王杰龙<sup>1</sup> 杨玲<sup>1</sup> 陈义<sup>1</sup> 沈云中<sup>1</sup>

1 同济大学测绘与地理信息学院, 上海, 200092

**摘要：**利用重力场恢复与气候实验 (gravity recovery and climate experiment, GRACE) 卫星反演的陆地水储量和全球陆地数据同化系统 (global land data assimilation system, GLDAS) 水文模型, 从流域降雨分布信息出发, 结合季节调整技术和非线性自回归 (non-linear autoregressive, NAR) 神经网络对流域地下水储量变化进行预测, 并与未经过季节调整的 NAR 神经网络、自回归 (autoregressive, AR) 模型以及季节性自回归差分移动平均 (seasonal autoregressive integrated moving average, SARIMA) 模型进行对比分析。以长江流域、勒拿河流域、鄂毕河流域以及叶尼塞河流域为例, 结果表明, 经过季节调整后的流域降雨和地下水分别服从独立分布和一阶自回归模型, 为 NAR 神经网络时延数的确定提供了新的途径。经过季节调整后的 NAR 神经网络的预测结果在四个流域的模型表现优于传统的 AR 模型和 SARIMA 模型, 均方误差在 1 cm 以内, 相关系数超过 0.96。结合季节调整和 NAR 神经网络提高了流域地下水储量预测精度, 减少了训练参数, 加快了神经网络的收敛速度。

**关键词：**季节调整; 地下水储量; 非线性自回归神经网络; 自回归模型

---

收稿日期：2022-04-02

项目资助：国家自然科学基金 (41974002)。

第一作者：王杰龙, 博士生, 主要从事深度学习和 GRACE 数据分析。 wangjielong@tongji.edu.cn

通讯作者：沈云中, 博士, 教授。 86060@tongji.edu.cn

地下水储量作为最为宝贵的自然资源之一，对人类社会生活、工农业发展以及环境保护具有重要作用。全球约有 50% 的饮用水和 40% 的工业用水来自地下水<sup>[1]</sup>，开采地下水资源便成为维持经济建设和生活用水需求的关键途径。但是，地下水资源的过度开采将会引发地面沉降、水土流失和生态恶化等问题<sup>[2]</sup>。在现有的地下水开采方案下，华北平原鲁北地区地面沉降在未来十年仍会继续发展<sup>[3]</sup>。因此，找到一种合适的方式来预测地下水储量变化对地下水的合理开发与利用具有显著的现实意义。

地下水储量监测主要依靠实际水位观测数据，但是稀疏的地下水观测数据导致地下水储量的分析受限。重力恢复与气候实验（gravity recovery and climate experiment, GRACE）卫星观测数据与水文模型相结合<sup>[4-5]</sup>，革新了地下水储量变化的监测、分析和预测方式。文献<sup>[6]</sup>从 GRACE 卫星反演得到的陆地水储量中扣除全球陆地数据同化系统（global land data assimilation system, GLDAS）模拟输出的土壤水和雪水，发现 2003—2016 年土耳其地下水月消耗速率约 6 cm 等效水厚（equivalent water thickness, EWT）。文献<sup>[7]</sup>则将 GRACE 卫星和 WaterGAP 全球水文模型（WaterGAP global hydrology model, WGHM）结合，探测到中国鄂尔多斯和山西地区在 2003—2014 年间，地下水每年约分别减少 0.65 cm 和 1.16 cm。文献<sup>[8]</sup>将 GRACE 数据与水文模型进行融合，提高了对澳大利亚东南部和古尔本河流域地下水储量的估计精度。

目前，结合 GRACE 卫星和水文模型或实际观测值分析地下水储量变化的研究较多<sup>[9-11]</sup>，但利用 GRACE 卫星相关数据预测流域地下水储量变化的研究较少。一方面，传统的地下水储量预测依赖地下水埋深数据、水文循环以及含水层地质构造等复杂信息，同时地下水储量的变化受到人类活动、水岩作用过程、土壤以及降雨调节等自然因素的共同影响<sup>[12]</sup>。另一方面，传统的预测模型，

如自回归（autoregressive, AR）模型，由于其线性性质导致地下水储量预测精度有限<sup>[13]</sup>。而神经网络的出现提高了地下水储量预测的可靠性。文献<sup>[14]</sup>使用一种机器学习的方法即支持向量机，验证了 GRACE 卫星预测地下水储量的可行性；文献<sup>[15]</sup>将降雨和温度作为驱动因子，采用带外部输入的非线性自回归（non-linear autoregressive with exogenous input, NARX）神经网络成功预测了 3 种不同类型含水层的地下水储量；文献<sup>[16]</sup>利用温度、降雨和 GRACE 反演的陆地水储量作为输入变量，证实了多层感知机（multilayer perceptron, MLP）神经网络可以提高对地下水水位的预测精度。

随着全球气候变化加剧，研究和预测流域地下水储量变化对调节区域水文循环和改善生态环境具有重要意义<sup>[17]</sup>。尽管神经网络可以提高预测地下水储量的精度，但是不同的网络类型和网络结构具有不同的预测表现。MLP 属于静态神经网络，预测能力有限；而 NARX 神经网络虽然具有反馈连接，但是外部输入或者驱动因子通常难以确定<sup>[18]</sup>。而非线性自回归（non-linear autoregressive, NAR）神经网络具有动态机制，同时无需外部输入，仅仅依赖目标序列进行预测<sup>[19]</sup>。当外部输入未知或者驱动数据难以获得时，NAR 神经网络体现出其优越性。本文从流域降雨分布出发，提出一种季节调整和 NAR 神经网络结合的流域地下水储量预测方法，在提高地下水储量预测精度的同时，减少网络训练参数，从而加快网络的收敛速度。本文首先对流域的降雨和地下水储量进行季节调整，然后依据经过季节调整后的降雨分布导出季节调整后的地下水分布；接着利用 NAR 神经网络对季节调整后的地下水储量进行预测，并与未经季节调整的 NAR 神经网络、AR 模型以及季节性自回归差分移动平均（seasonal autoregressive integrated moving average, SARIMA）模型进行对比。以长江流域、勒拿河流域、鄂毕河流域和叶尼塞河流域为例，分析和验证地下水储量的预

测结果。

## 1 方法和数据

### 1.1 降雨分布与地下水分布

如果某一流域降雨是独立分布的, 满足关系式<sup>[20]</sup>:

$$P_t - \mu_p = \varepsilon_t \quad (1)$$

式中,  $P_t$  是流域降雨时间序列;  $\mu_p$  是其均值;  $t$  为观测时段;  $\varepsilon_t$  是独立分布的时间序列, 其均值为 0, 方差为  $\sigma_\varepsilon^2$ 。

流域降雨量与径流量和地下水储量关系如图 1 所示, 该流域当月的地下水储量  $G_t$  一部分来自地表渗透  $aP_t$ ,  $a$  为渗透系数, 另一部分来自上个月滞留的地下水储量  $(1-c)G_{t-1}$ ,  $c$  为地下径流系数。考虑流域降雨均值  $\mu_p$  与地下水储量均值  $\mu_G$  的影响, 则有:

$$G_t - \mu_G = (1-c)(G_{t-1} - \mu_G) + a(P_t - \mu_p) \quad (2)$$

将式 (1) 代入式 (2) 可得:

$$G_t - \mu_G = (1-c)(G_{t-1} - \mu_G) + a\varepsilon_t \quad (3)$$

从式 (3) 可以看出, 如果降雨是独立分布的, 那么地下水储量服从一阶自回归即 AR(1) 分布。

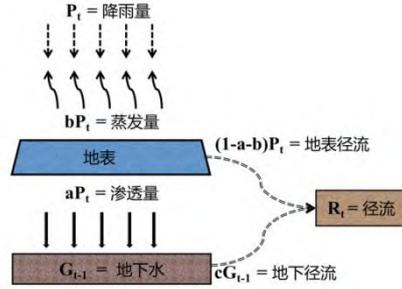
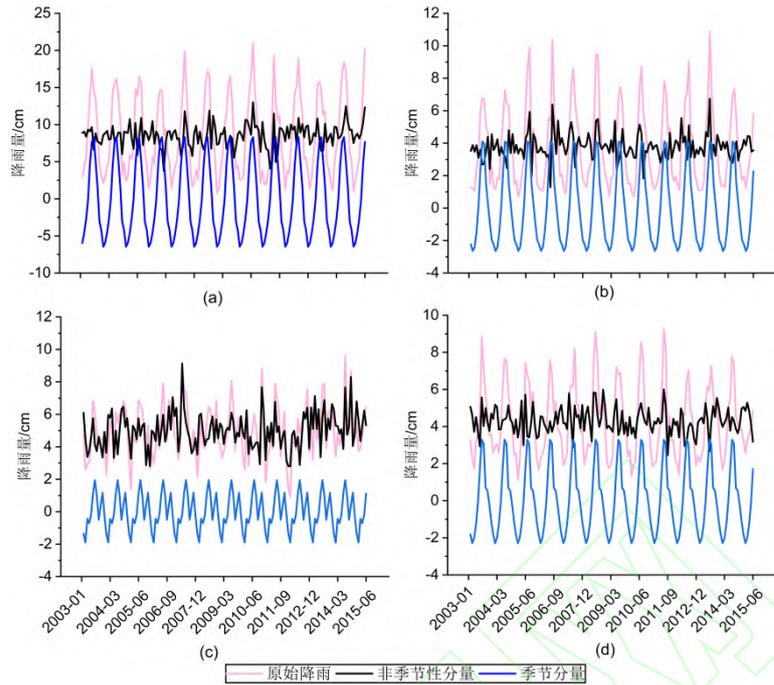


图 1 流域水文循环模型(改自文献[20])

Fig.1 Environmental Systems Model of a Watershed (Modified from Reference [20])

### 1.2 季节调整

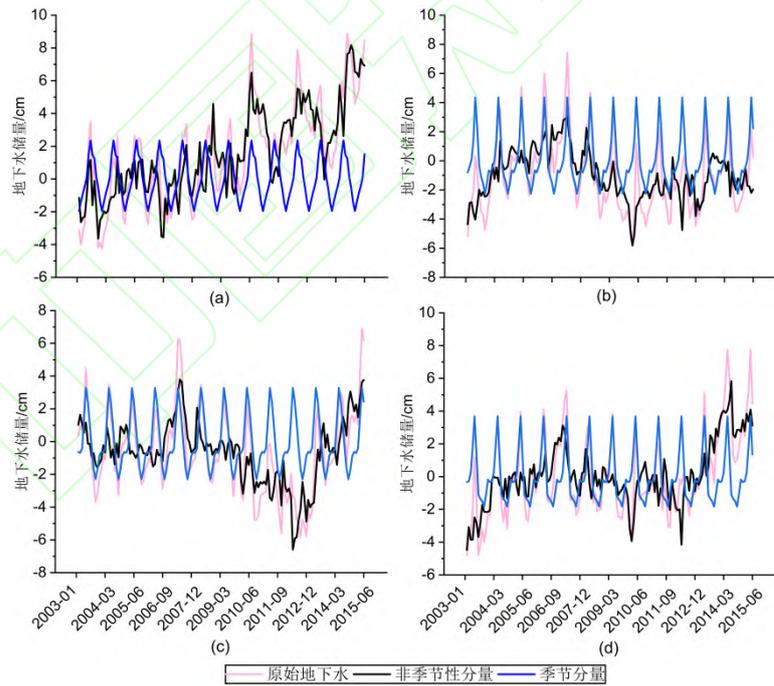
由于流域降雨通常具有季节性变化特征, 地下水储量必定也是季节性变化的, 因此采用稳定季节性滤波的季节调整方法<sup>[21]</sup>, 将原始的降雨序列和地下水序列分别分解成非季节性分量和季节分量, 结果如图 2 和图 3 所示。其中, 地下水和降雨序列的时间跨度均为 2003-01—2015-06, 时间分辨率为月。该方法假定季节分量是稳定的, 即每年的季节性变化是一致的, 因此对经过季节调整后的地下水进行预测时, 加回季节分量便得到原始地下水储量的预测。本文还利用单位根检验对经过季节调整后的地下水进行检验<sup>[22]</sup>, 结果表明, 在显著性水平为 5% 的情况下, 经过季节调整后的地下水序列为平稳序列。



(a) 长江流域 (b) 勒拿河流域 (c) 鄂毕河流域 (d) 叶尼塞河流域

图2 原始降雨序列、非季节性分量和季节分量

Fig.2 Time Series of Precipitation, Deseasonalized Component and Seasonal Component



(a) 长江流域 (b) 勒拿河流域 (c) 鄂毕河流域 (d) 叶尼塞河流域

图3 原始地下水序列、非季节性分量和季节分量

Fig.3 Time Series of Groundwater, Deseasonalized Component and Seasonal Component

### 1.3 模型评价指标

本文采用4种指标评价模型的预测能力<sup>[18]</sup>。

1) 均方误差 (root mean square error, RMSE), 用来衡量预测模型的全局拟合度:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - o_t)^2}{n}} \quad (4)$$

式中,  $y_t, o_t, n$  分别为模型输出值、实际观测值及其样本数量。

2) 相关系数  $R$ , 用来衡量模型的预测能力:

$$R = \frac{\sum_{t=1}^n (y_t - \bar{y})(o_t - \bar{o})}{\sqrt{\sum_{t=1}^n (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^n (o_t - \bar{o})^2}} \quad (5)$$

式中,  $\bar{y}$  和  $\bar{o}$  分别为模型输出值和实际观测值的均值。

3) 标准化均方误差 (scaled RMSE):

$$R^* = \frac{RMSE}{\sigma_o}$$

式中,  $\sigma_o$  为观测值标准方差。

4) 纳什系数 (Nash-Sutcliffe efficiency, NSE):

$$NSE = 1 - \frac{\sum_{t=1}^n (y_t - o_t)^2}{\sum_{t=1}^n (o_t - \bar{o})^2} \quad (6)$$

根据文献<sup>[18]</sup>, 我们认为: 当  $NSE > 0.75, R^* < 0.5$  时, 模型表现为“优”; 当  $NSE > 0.65, R^* < 0.6$  时, 模型表现为“良”; 当  $NSE > 0.5, R^* < 0.7$  时, 模型表现为“中”; 否则模型表现属于“一般”。特别地, 当  $NSE$  取值为负时, 模型预测能力不如均值预测。

### 1.4 数据

本文使用的降雨数据取自全球降雨测量 (global precipitation measurement, GPM) 数据产品, 作为热带降雨测量任务 (tropical rainfall measuring mission, TRMM) 卫星的替代品<sup>[23]</sup>, 时间分辨率为月, 空间分辨率为  $0.1^\circ \times 0.1^\circ$ 。地下水储量估计是从 GRACE 卫星

反演的陆地水储量中扣除 GLDAS 水文模型模拟输出的水分量<sup>[24]</sup>, 即:

$$GWSA = TWSA - (SMSA + SWEA + CWSA) \quad (7)$$

式中,  $GWSA$  是地下水储量变化;  $SMSA, SWEA$  和  $CWSA$  分别是 GLDAS 水文模型模拟输出的土壤水、雪水和植物冠层水变化, 空间分辨率为  $1^\circ \times 1^\circ$ ; 而陆地水储量  $TWSA$  是采用由喷气推进实验室 (jet propulsion laboratory, JPL) 最新发布的 Mascon Level-3 解, 空间分辨率为  $0.5^\circ \times 0.5^\circ$ 。具体的处理步骤如低阶项的替换、泄露误差的改正等参见文献<sup>[25]</sup>。

## 2 结果和讨论

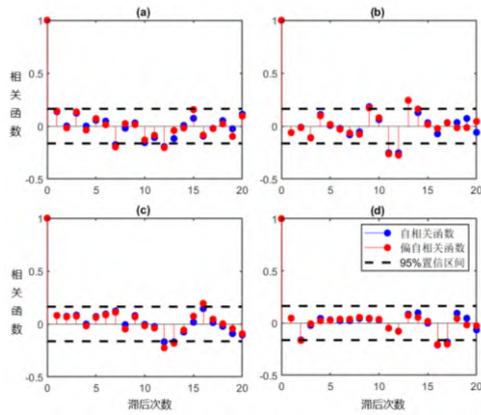
### 2.1 自相关函数和偏自相关函数

图4是经过季节调整后的降雨的样本自相关函数和样本偏自相关函数。尽管个别滞后次数的自相关函数值超出置信区间 (可能归咎于数据的不确定性和自相关函数计算的偶然性<sup>[20]</sup>), 但是大部分自相关函数取值均落于 95% 置信区间内。因此可以得出4个流域的非季节性降雨是独立分布的结论。图5为经过季节调整后的地下水样本自相关函数和样本偏自相关函数。由图5可以看出, 4个流域的自相关函数都呈现出衰减形式, 而偏自相关函数都在滞后次数等于1处显著自相关。因此, 可以推定4个流域的非季节性地下水储量变化均满足一阶自回归模型即  $AR(1)$ 。

为了核实  $AR(1)$  模型对4个流域的非季节性地下水储量进行拟合的正确性, 本文对残差依次进行正态性检验、异方差性检验和独立性检验。正态性检验采用核密度估计, 异方差性检验是通过计算平方残差自相关函数, 独立性检验则是直接计算残差的自相关函数<sup>[21]</sup>。各流域的检验结果类似, 因篇幅

所限，图 6 仅展示勒拿河流域的检验结果。从图 6 可以看出，残差满足正态、独立和方差一致性条件。因此，结合图 5 和图 6 的

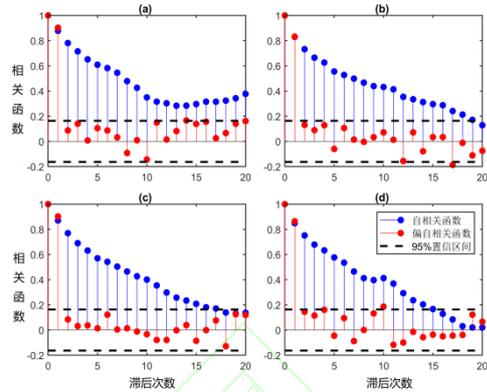
结果，可以得出经过季节调整后的地下水储量确实满足 AR(1)模型。



(a) 长江流域 (b) 勒拿河流域 (c) 鄂毕河流域 (d) 叶尼塞河流域

图4 非季节性降雨的样本自相关函数和样本偏自相关函数

Fig.4 Sample Autocorrelation Function and Partial Autocorrelation Function of Deseasonalized Precipitation

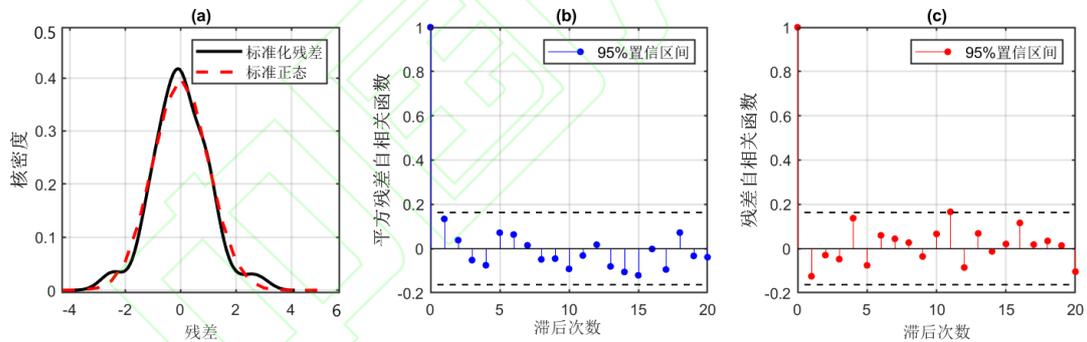


(a) 长江流域 (b) 勒拿河流域

(c) 鄂毕河流域 (d) 叶尼塞河流域

图5 非季节性地下水的样本自相关函数和样本偏自相关函数

Fig.5 Sample Autocorrelation Function and Partial Autocorrelation Function of Deseasonalized Groundwater:



(a) 正态性检验

(b) 异方差性检验

(c) 独立性检验

图 6 勒拿河流域非季节性地下水残差检验

Fig.6 Residual Test of Deseasonalized Groundwater in the Lena Basin

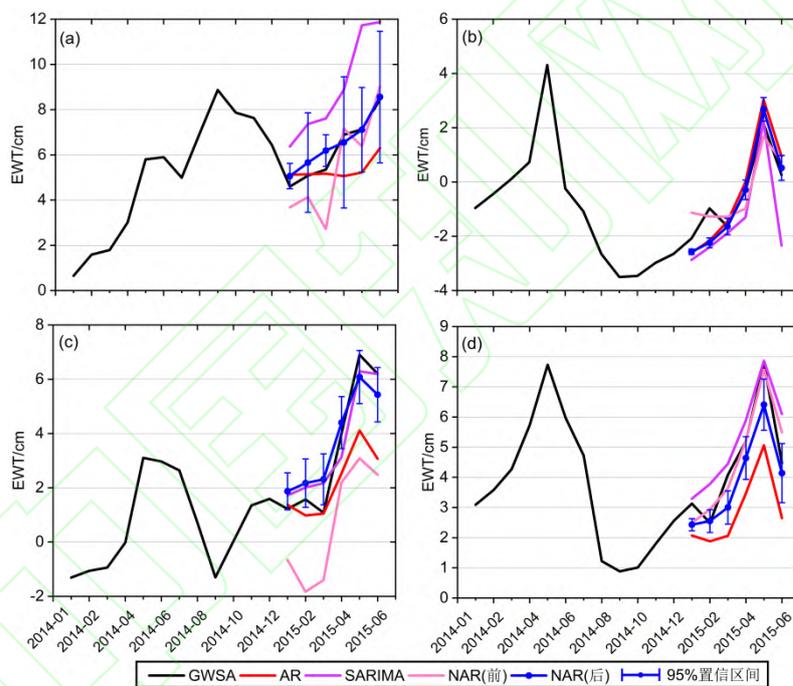
## 2.2 地下水储量的预测

考虑到 AR 模型的线性性质导致其预测能力有限，因此结合季节调整技术和 NAR 神经网络对 4 个流域地下水储量进行预测，并与未经季节调整的 NAR 神经网络、AR(1) 以及 SARIMA 模型的预测结果进行对比。两种 NAR 神经网络均采用单一隐藏层，隐藏

层的激活函数为双曲正切函数，输出层的激活函数采用线性函数。经过季节调整后的 NAR 神经网络（记为 NAR(后)）的时延数根据 § 3.1 结果确定为 1，隐藏神经元的数目则通过从 1 递增到 24 的方式来确定不同流域的最佳神经元数目。而季节调整前的 NAR 神经网络（记为 NAR(前)）的神经元数目和时延数均采用从 1~24 逐个递增的方式确定。输入数据按照 70%、15%、15%划分为训练集、验证集和测试集，同时采用随机初始权

值方法对每个 NAR 神经网络训练 100 次，取 100 次训练结果的平均值和 2 倍标准差分别作为最终的预测结果和对应的 95% 置信区间。NAR(后)与 AR(1)模型都是对经过季节调整后的地下水储量进行预测，然后加上季节分量得到地下水储量的预测结果；SARIMA 模型则是对原始序列进行季节性差分，季节性差分阶数和非季节性自回归阶数都为 1。输入数据集是 2003-01—2014-12 的地下水序列，预测时间为 2015-01—2015-06。图 7 是不同方法在不同流域预测结果对比（为了更直观地进行比较，横轴限制在 2014-01—2015-06）。由图 7 可以看出，在长江流域，

NAR(后)神经网络表现明显优于 NAR(前)、AR(1)和 SARIMA 模型；在勒拿河流域，NAR(后)和 NAR(前)模型预测结果与实际观测值的符合程度优于 AR(1)和 SARIMA 模型；在鄂毕河流域，NAR(前)神经网络和 AR(1)模型表现明显不如 NAR(后)和 SARIMA 模型；在叶尼塞河流域，SARIMA 模型和 NAR(前)在峰值处的符合程度优于 NAR(后)与 AR(1)模型。图 7 还展示了 NAR(后)预测结果的 95% 置信区间，可以看出，在显著性水平为 5% 的情况下，NAR(后)预测结果落在地下水实际观测值范围内。



(a) 长江流域 (b) 勒拿河流域 (c) 鄂毕河流域 (d) 叶尼塞河流域

图 7 地下水储量的预测结果对比

Fig.7 Comparison of Groundwater Prediction Results

表 1 统计了不同预测方法的 4 种评价指标，由表 1 可以看出，AR(1)模型在长江流域、鄂毕河流域以及叶尼塞河流域表现“一般”，且在长江流域和叶尼塞河流域 NSE 取值为负，说明 AR 模型预测能力在这两条流域内不如简单的均值预测。SARIMA 模型仅在鄂毕河流域表现为“优”，而在长江流域和勒拿河流域表现“一般”。NAR(后)与 NAR(前)神经网络预测结果的 RMSE 均在 1 cm 以内，

小于目前 GRACE 卫星反演地下水储量的不确定性。NAR(后)神经网络在 4 个流域的表现结果均为“优”，相关系数超过 0.96；而 NAR(前)在长江和鄂毕河流域表现“一般”。在勒拿河和鄂毕河流域，尽管 NAR(前)神经网络的 RMSE 值小于 NAR(后)，但是由于 NAR(后)神经网络的神经元数目和时延数减少，显著提高了网络的收敛速度。由图 8 可见，在勒拿河流域，NAR(前)神经网络在第 5

个历元收敛，而 NAR(后)仅需要一个历元就完成模型训练。因此，结合季节调整和 NAR 神经网络不仅有效地提高了流域地下水储

量的预测精度，同时减小了网络训练参数和收敛时间。

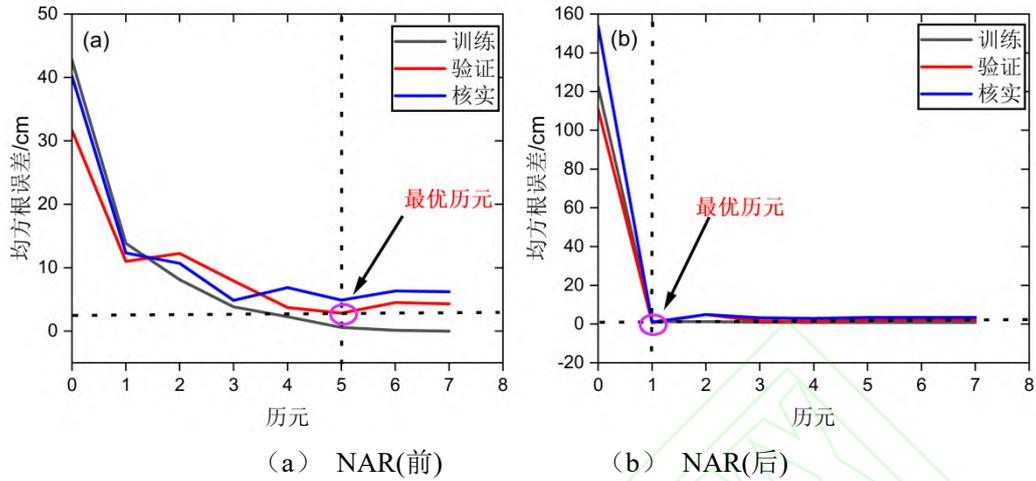


图 8 勒拿河流域 NAR 模型训练过程

Fig.8 Training Procedure of NAR Models in the Lena Basin

表 1 预测结果的评价指标

Tab.1 Performance Indexes of Prediction Results

预测方法	流域	RMSE/cm	R*	NSE	R	模型评价
AR	长江	1.407	2.958	-9.502	0.732	一般
	勒拿河	0.717	0.469	0.736	0.964	良
	鄂毕河	1.831	0.703	0.406	0.973	一般
	叶尼塞河	1.790	0.963	-0.113	0.969	一般
SARIMA	长江	2.896	1.241	-0.848	0.936	一般
	勒拿河	1.320	0.864	0.105	0.862	一般
	鄂毕河	0.678	0.261	0.919	0.973	优
	叶尼塞河	0.910	0.490	0.712	0.941	良
NAR (前)	长江(19,23)	1.267	0.859	0.114	0.940	一般
	勒拿河(19, 14)	0.580	0.380	0.827	0.914	优
	鄂毕河(20, 17)	2.971	1.142	-0.564	0.942	一般
	叶尼塞河(2, 12)	0.562	0.302	0.890	0.947	优
NAR (后)	长江(8,1)	0.480	0.392	0.815	0.966	优
	勒拿河(11,1)	0.604	0.396	0.812	0.968	优
	鄂毕河(17,1)	0.787	0.303	0.890	0.990	优
	叶尼塞河(2,1)	0.810	0.436	0.772	0.973	优

注：流域名称括号内的第一个数字代表神经元数目，第二个数字代表时延数。

## 2.3 讨论

首先,本文提出的预测方法的前提是假定季节分量是稳定的,因为非季节性分量通常受到极端气候的影响。因此预测误差除了数据本身的不确定性外,还可能来自于季节分量的变化。其次,本文预测的时间长度为6个月,这是因为地下水储量变化受到人类活动、降雨以及各种复杂的气候变化影响,超过半年的预测可靠性降低<sup>[26]</sup>。NAR神经网络预测的峰值略低于实际观测值(图7),这是因为本文采用的损失函数是RMSE,而更合理的损失函数应该顾及误差的季节性特征<sup>[20]</sup>,这将在未来的研究中持续改进。SARIMA预测结果在鄂毕河流域略优于NAR神经网络(表1),这是因为SARIMA模型对原始序列进行了一阶季节性差分处理。这也间接证明了对原始序列进行预处理,如季节性差分或者季节调整等,可以提高流域地下水储量的预测精度。同时,季节调整处理也为NAR神经网络时延数的确定提供了有效途径,从而降低神经网络收敛时间。各模型在不同流域的表现不同,除了与模型结构和实验方式有关外,可能与流域地理气候和位置等特征有关,这将在未来的研究中继续完善。最后,从流域降雨分布信息出发,推导出诸如地表水、径流等分布信息,不仅具有明确的物理背景,也会提高我们对区域水文循环的理解,为水资源的合理利用提供政策支持。

## 3 结语

本文将季节调整技术和NAR神经网络结合,分别对长江流域、勒拿河流域、鄂毕河流域和叶尼塞河流域的地下水储量进行预测,主要结论有:(1)经过季节调整后的降雨和地下水分别满足独立分布和一阶自回归模型;(2)季节调整技术在有效确

定NAR神经网络的时延数的同时,减少网络训练参数,可以提高对地下水储量的预测精度和收敛速度;(3)经过季节调整后的NAR神经网络的预测结果优于传统的AR模型和SARIMA模型,预测结果的RMSE小于目前GRACE卫星反演地下水储量的不确定性,相关系数高达0.96。

尽管地下水储量变化模式复杂,受到诸如气候变化和人类活动等影响,但是从流域水文循环的物理背景出发,经过季节调整后使得对地下水储量的预测变得简单、可行,同时也体现了神经网络在对水文时间序列预测的表现优于传统模型。

## 参考文献

- [1] Yin Z J, Xu Y Y, Zhu X Y, et al. Variations of Groundwater Storage in Different Basins of China over Recent Decades[J]. *Journal of Hydrology*, 2021, 598: 126282
- [2] Shi Yun, Li Weixuan, Tang Yaming, et al. Time Series InSAR Measurement for Earth Environmental Monitoring and Resource Management: A Case Study of Jiaocheng-Qingxu Area[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(11): 1613-1621 (师芸, 李伟轩, 唐亚明, 等. 时序 InSAR 技术在地球环境监测及其资源管理中的应用: 以交城-清徐地区为例[J]. *武汉大学学报·信息科学版*, 2019, 44(11): 1613-1621)
- [3] Di Shengtong, Jia Chao, Zhang Shaopeng, et al. Regional Characteristics and Evolutionary Trend Prediction of Land Subsidence Caused by Groundwater over Exploitation in North Shandong of the North China Plain[J]. *Acta Geologica Sinica*, 2020, 94(5): 1638-1654 (狄胜同, 贾超, 张少鹏, 等. 华北平原鲁北地区地下水超采导致地面沉降区域特征及演化趋势预测[J]. *地质学报*, 2020, 94(5): 1638-1654)
- [4] Chen J L, Rodell M. Applications of

- Gravity Recovery and Climate Experiment (GRACE) in Global Groundwater Study[M]//Global Groundwater. Amsterdam: Elsevier, 2021: 531-543
- [5] Long D, Chen X, Scanlon B R, et al. Have GRACE Satellites Overestimated Groundwater Depletion in the Northwest India Aquifer? [J]. *Scientific Reports*, 2016, 6: 24398
- [6] Khorrami B, Gunduz O. Evaluation of the Temporal Variations of Groundwater Storage and Its Interactions with Climatic Variables Using GRACE Data and Hydrological Models: A Study from Turkey[J]. *Hydrological Processes*, 2021, 35(3): 1-9
- [7] Chen X H, Jiang J B, Lei T J, et al. GRACE Satellite Monitoring and Driving Factors Analysis of Groundwater Storage under High-Intensity Coal Mining Conditions: A Case Study of Ordos, Northern Shaanxi and Shanxi, China[J]. *Hydrogeology Journal*, 2020, 28(2): 673-686
- [8] Tangdamrongsub N, Han S C, Yeo I Y, et al. Multivariate Data Assimilation of GRACE, SMOS, SMAP Measurements for Improved Regional Soil Moisture and Groundwater Storage Estimates[J]. *Advances in Water Resources*, 2020, 135: 103477
- [9] Castle S L, Thomas B F, Reager J T, et al. Groundwater Depletion during Drought Threatens Future Water Security of the Colorado River Basin[J]. *Geophysical Research Letters*, 2014, 41(16): 5904-5911
- [10] Joodaki G, Wahr J, Swenson S. Estimating the Human Contribution to Groundwater Depletion in the Middle East, from GRACE Data, Land Surface Models, and Well Observations[J]. *Water Resources Research*, 2014, 50(3): 2679-2692
- [11] Mohamad N, Ahmad A, Din A M. Monitoring Groundwater Depletion Due to Drought Using Satellite Gravimetry: A Review[J]. *IOP Conference Series: Earth and Environmental Science*, 2020, 540(1): 012054
- [12] Yang Ping, Wang Xinmin, Lu Laijun. Predicting the Trends of Pollutant Concentrations in Groundwater Based on the Combined Method of the Improved Quantification Theory and RBF Artificial Neural Network[J]. *Earth Science Frontiers*, 2016, 23(3): 151-155 (杨平, 王新民, 路来君. 基于改进的数量化理论和 RBF 神经网络组合方法的地下水水质预测[J]. *地学前缘*, 2016, 23(3): 151-155)
- [13] Sun Z L, Long D, Yang W T, et al. Reconstruction of GRACE Data on Changes in Total Water Storage over the Global Land Surface and 60 Basins[J]. *Water Resources Research*, 2020, 56(4): 1-21
- [14] Malakar P, Mukherjee A, Bhanja S N, et al. Machine-Learning-Based Regional-Scale Groundwater Level Prediction Using GRACE[J]. *Hydrogeology Journal*, 2021, 29(3): 1027-1042
- [15] Wunsch A, Liesch T, Broda S. Forecasting Groundwater Levels Using Nonlinear Autoregressive Networks with Exogenous Input (NARX)[J]. *Journal of Hydrology*, 2018, 567: 743-758
- [16] Sun A Y. Predicting Groundwater Level Changes Using GRACE Data[J]. *Water Resources Research*, 2013, 49(9): 5900-5912
- [17] Yin W J, Fan Z W, Tangdamrongsub N, et al. Comparison of Physical and Data-Driven Models to Forecast Groundwater Level Changes with the Inclusion of GRACE - a Case Study over

- the State of Victoria, Australia[J]. *Journal of Hydrology*, 2021, 602: 126735
- [18] Wang J L, Chen Y. The Applicability of Using NARX Neural Network to Forecast GRACE Terrestrial Water Storage Anomalies[J]. *Natural Hazards*, 2022, 110(3): 1997-2016
- [19] Patil K, Deo M C, Ghosh S, et al. Predicting Sea Surface Temperatures in the North Indian Ocean with Nonlinear Autoregressive Neural Networks[J]. *International Journal of Oceanography*, 2013, 2013: 302479
- [20] Hipel K W, McLeod A I. Time Series Modelling of Water Resources and Environmental Systems[M]. Amsterdam: Elsevier, 1994
- [21] Brockwell P J, Davis R A. Introduction to Time Series and Forecasting[M]. New York: Springer New York, 2002
- [22] Xiao Z J, Phillips P C B. An ADF Coefficient Test for a Unit Root in ARMA Models of Unknown Order with Empirical Applications to the US Economy[J]. *The Econometrics Journal*, 1998, 1(2): 27-43
- [23] Prakash S, Mitra A K, Pai D S, et al. From TRMM to GPM: How Well can Heavy Rainfall Be Detected from Space? [J]. *Advances in Water Resources*, 2016, 88: 1-7
- [24] Liu Renli, She Dunxian, Li Min, et al. Using Satellite Observations to Assess Applicability of GLDAS and WGHM Hydrological Model[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(11): 1596-1604 (刘任莉, 佘敦先, 李敏, 等. 利用卫星观测数据评估 GLDAS 与 WGHM 水文模型的适用性 [J]. *武汉大学学报·信息科学版*, 2019, 44(11): 1596-1604)
- [25] Watkins M M, Wiese D N, Yuan D N, et al. Improved Methods for Observing Earth's Time Variable Mass Distribution with GRACE Using Spherical Cap Mascons[J]. *Journal of Geophysical Research: Solid Earth*, 2015, 120(4): 2648-2671
- [26] Ahmed M, Sultan M, Elbayoumi T, et al. Forecasting GRACE Data over the African Watersheds Using Artificial Neural Networks[J]. *Remote Sensing*, 2019, 11(15): 1769

# Prediction of Watershed Groundwater Storage Based on Seasonal Adjustment and NAR Neural Network

WANG Jielong<sup>1</sup> YANG Ling<sup>1</sup> CHEN Yi<sup>1</sup> SHEN Yunzhong<sup>1</sup>

<sup>1</sup> College of Surveying and Geo-informatics, Tongji University, Shanghai 200092, China

**Abstract: Objectives:** Accurate and reliable prediction of watershed groundwater storage can help ensure the sustainable use of a watershed's aquifers for urban and rural water supply.

**Methods:** On the basis of precipitation information, gravity recovery and climate experiment (GRACE), and global land data assimilation system (GLDAS), the prediction of groundwater storage is performed by using the seasonal adjustment and non-linear autoregressive (NAR) neural network. Then the NAR model without the seasonal adjustment, the autoregressive (AR) model, and the seasonal autoregressive integrated moving average (SARIMA) model are compared.

**Results:** Taking Changjiang Basin, Lena Basin, Ob Basin and Yenisey Basin as case studies, the results indicate that the deseasonalized precipitation and groundwater using the seasonal adjustment are independent and good fit to AR(1), while laying the foundations of deciding the number of a time delay of the NAR network. The performance of the NAR neural network using the seasonal adjustment falls into the excellent category for each basin and shows superiority over AR model and SARIMA model, with root mean square error (RMSE) less than 1 cm and correlation coefficient more than 0.96. **Conclusions:** The integration of seasonal adjustment technique and NAR neural network can not only improve the prediction accuracy of groundwater storage, but also reduce the convergence time. The proposed method can effectively forecast the groundwater storage with improved performance due to the seasonal adjustment that reduces the data complexity.

**Keywords:** seasonal adjustment; groundwater storage; non-linear autoregressive neural network; autoregressive model

**First author:** WANG Jielong, PhD candidate, specializes in deep learning and GRACE data analysis. E-mail: wangjielong@tongji.edu.cn

**Corresponding author:** SHEN Yunzhong, PhD, professor. E-mail: 86060@tongji.edu.cn

**Foundation Support:** The National Natural Science Foundation of China (41974002).

**网络首发:**

**标题:** 结合季节调整和NAR神经网络的流域地下水储量预测

**作者:** 王杰龙, 杨玲, 陈义, 沈云中

**DOI:** 10.13203/j.whugis20210584

**收稿日期:** 2022-04-02

**引用格式:**

王杰龙, 杨玲, 陈义, 等. 结合季节调整和 NAR 神经网络的流域地下水储量预测[J]. 武汉大学学报·信息科学版, 2022, DOI: 10.13203/j.whugis20210584 (WANG Jielong, YANG Ling, CHEN Yi, et al. Prediction of Watershed Groundwater Storage Based on Seasonal Adjustment and NAR Neural Network[J]. *Geomatics and Information Science of Wuhan University*, 2022, DOI: 10.13203/j.whugis20210584)

**网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!**

---

您感兴趣的其他相关论文:

**利用 Forward-Modeling 方法反演青藏高原水储量变化**

李婉秋, 王伟, 章传银, 文汉江, 钟玉龙

武汉大学学报·信息科学, 2020, 45(1): 141-149.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20180263>