

# 非弃水期葛洲坝水电站下游水位变化过程预测新方法

徐 杨,樊启祥,尚毅梓,阮燕云,张玉柱,刘志武

(中国长江三峡集团公司,北京 100038)

**摘要:**由于现有的水电站下游水位预测方法计算误差较大,选择葛洲坝水电站为研究对象,提出一种新的电站在不弃水情况下的下游水位变化过程预测方法。该方法基于BP神经网络算法,利用水电站监控数据实现电站下游水位的高精度预测,满足电站实时调度需求。对比现有的水位流量曲线查值法和非恒定流经验公式法,该方法有如下优势:①无需采用出库流量进行预测,避免了流量计算误差的影响;②建模过程中考虑了下游水位变化“后效性”影响,大幅提升水电站调峰时的预测精度;③可直接计算下游水位变化过程,计算结果稳定,精度更高,尤其在非弃水期葛洲坝水电站大调峰工况下,预测精度明显提高。

**关键词:**水电站;下游水位;预测预报;BP神经网络;葛洲坝水电站

中图分类号:TV697.1

文献标志码:A

文章编号:1006-7647(2019)03-0050-06

**A novel forecasting method for downstream water level variation of Gezhouba Hydropower Station during non-abandoning water period**//XU Yang, FAN Qixiang, SHANG Yizi, RUAN Yanyun, ZHANG Yuzhu, LIU Zhiwu(*China Three Gorges Corporation, Beijing 100038, China*)

**Abstract:** Since the existing methods of water level forecasting in the downstream of a hydropower station have a larger computational error, Gezhouba Hydropower Station was taken as a research object to establish a novel method for downstream water level variation forecasting during the non-abandoning water period. Based on the BP neural network and the hydropower station monitoring data, the downstream water level forecasting with high accuracy was realized, which can satisfy the needs of real-time scheduling. Compared with the methods of water level-discharge relationship and the empirical formula for unsteady flows, the present forecasting method has the following advantages: (1) It does not use the storage outflow data to calculate the water level, and the influence of the outflow calculation error can be avoided; (2) The hysteretic nature effects of the downstream water level variation is considered during the model construction process, so the forecast accuracy during the hump modulation periods can be greatly improved; (3) It can forecast the downstream water level changing process directly with stable calculation results and higher calculation accuracy, which can significantly improve the forecast accuracy under large peak shaving operating conditions of Gezhouba Hydropower Station during the non-abandoning water period.

**Key words:** hydropower station; downstream water level; forecasting; BP neural network; Gezhouba Hydropower Station

葛洲坝水电站是三峡水电站的反调节电站,两者相距38 km,水力联系紧密,区间无较大支流汇入,三峡下泄流量基本等于葛洲坝入库流量。在实际调度过程中,若葛洲坝水电站上游水位控制出现偏差,仅能通过2种方式来调整水位:一是向电网申请修改发电计划;二是开启泄洪闸进行弃水。现实情况下,为保证电站效益和运行安全,弃水情况较少,非弃水期占全年运行期的80%以上。因此,非弃水期葛洲坝水电站下游水位的精准预测,对于编制葛洲坝水电站发电计划,提升发电效益具有十分重要的意义。

水电站下游水位受多种因素影响,尤其在承担调峰、调频任务时,电站出力和出库流量变化剧烈,会在下游河道形成水位、流速急剧变动的非恒定水流。这种下游水位的复杂变化不仅与当前的电站出力、上游水位等参数有关,还与以前的工作状态有关,即具有一定的“后效性”<sup>[1]</sup>。目前,葛洲坝水电站下游水位预测方法主要有水位流量曲线查值法与非恒定流经验公式法。水位流量曲线查值法原理简单,计算速度快,日常调度中应用最多,但存在以下不足:①所建立水位流量曲线是静态的,一般采用恒

定流模式<sup>[2]</sup>,当电站出库流量变化剧烈时,不能完全反映水流的动态过程,预测误差较大;②为保证水位流量关系曲线的单一性,一般选用电站日均出库流量与日均下游水位数据建立相关关系,而时段下游水位预测时直接采用基于日均数据建立的关系曲线,误差较大;③无法解决受多种因素影响的复杂水位预测问题,更无法解决电站下游水位变化的“后效性”等问题。非恒定流经验公式法是通过提出经验公式来反映水电站下游水位的不稳定波动。该方法计算速度快,一定程度上考虑了水位顶托、非恒定流等因素的影响,在复杂条件下的下游水位预测中,如流量变幅较大且受回水影响的条件下,较水位流量曲线查值法更为精确。然而非恒定流经验公式法是复杂下游水位变化关系的简单近似,无法对下游水位变化过程进行精确计算,且公式中参数率定依赖所选用的调度运行数据,具有一定局限性;日常调度应用中发现该方法存在适用性不强、计算结果稳定性不高等问题。

葛洲坝水电站作为世界上最大的低水头、大流量径流式水电站,电站调峰较大时,下游水位小时变幅可能超过1 m,累计变幅超过3 m,占电站额定水头18.6 m的16%,现用的2种下游水位预测方法均存在计算精度不高,无法有效对水位变化过程进行预测等问题。另外,水电站出库流量也存在计算误差,通过流量查算水位会带来误差累积等问题。因此实际调度中2种方法仅可用于对下游水位的初步估算。随着大数据战略的全面推进,数据挖掘技术不断延伸到各研究领域,一些学者采用神经网络(ANN)<sup>[3]</sup>建模的方法来解决受复杂条件影响的水位预测问题。神经网络是受生物大脑启发而设计的非线性复杂网络系统,其基本单元是节点,节点之间的连接方式通过学习不断优化。神经网络的通用性和强大性使其可以很好地解决大型和高度复杂的学习任务,是目前机器学习的最新趋势之一。将神经网络应用于水文序列的预测,可以不必预先确定样本数据的数学模型,仅通过学习样本数据即可挖掘出其中的隐含规律<sup>[4]</sup>。鉴于此,本文针对葛洲坝水电站非弃水期可直接测量读取的电站运行过程与下游水位变化过程数据,采用BP神经网络算法,建立了一种基于监控数据的水电站下游水位变化过程预测方法。该方法计算简单快捷,较现用方法预测精度提高较多,对水电站的调度运行具有重要的现实意义。

## 1 水电站下游水位预测方法

### 1.1 水位流量曲线查值法

该方法通过水电站历史日均出库流量与下游水

位数据点绘制水位流量关系曲线或函数,然后根据曲线或函数,输入(时段或者日均)出库流量直接查算对应下游水位。

水电站下游水位计算公式为

$$Z = f(Q) \quad (1)$$

式中: $Z$ 为下游水位; $Q$ 为出库流量; $f$ 为下游水位与出库流量关系曲线或函数。

实际调度中发现用当前时段曲线查算下游水位的误差与之前时段的计算误差有关,为了提高精度,可采用前 $i$ 日计算误差的平均值作为当日下游水位计算的误差修正值。

### 1.2 非恒定流经验公式法

该方法认为电网上游放水时下游水位涨幅与出库流量线性相关,闸门关闭时下游水位按指数规律消落<sup>[5]</sup>。若水电站较长时间没有工作,则下游将出现最低水位 $Z_0$ 。若让水电站增大出库流量一段时间,则下游将出现某一水位 $Z_t$ ,该水位与下游最低水位和出库流量有关<sup>[6]</sup>:

$$Z_t = Z_0 + bQ_t \quad (2)$$

式中: $Z_t$ 为增流后 $t$ 时刻下游水位; $Q_t$ 为 $t$ 时刻电站出库流量; $b$ 为比例系数。

若某时刻后减去这一增大流量,下游水位将按与下游河谷特性有关的常数 $k$ 指数规律消落:

$$Z_{t+\Delta T} = Z_0 + \Delta Z_t e^{-\Delta T/k} \quad (3)$$

式中: $Z_{t+\Delta T}$ 为减流历时 $\Delta T$ 后下游水位消落后的水位; $\Delta Z_t$ 为减流前下游水位与最低水位 $Z_0$ 的差值。

引入符号 $a = e^{-\Delta T/k}$ ,并将方程改为通用的形式如下:

$$Z_t = Z_0 + a\Delta Z_{t-1} \quad (4)$$

式中: $Z_t$ 为减流后 $t$ 时刻下游水位; $\Delta Z_{t-1}$ 为 $t-1$ 时刻下游水位与最低水位 $Z_0$ 的差值。

若某一时刻又重新让水电站增大出库流量,则该时刻下游水位相对于 $Z_0$ 的偏离值由2个阶段的变幅之和决定,即

$$Z_t = Z_0 + a\Delta Z_{t-1} + bQ_t \quad (5)$$

实际调度中,最低水位 $Z_0$ 和比例系数 $a$ 、 $b$ 可通过历史数据进行率定,然后输入出库流量以及上一时刻的下游水位,即可利用式(5)计算出水电站该时刻的下游水位。

### 1.3 基于监控数据的水电站非弃水期下游水位变化过程BP神经网络预测模型

#### 1.3.1 BP神经网络

BP神经网络模型是一种多层前馈网络模型,拓扑结构包括输入层、隐含层和输出层<sup>[7]</sup>。网络的学习分为正向传播过程和反向传播过程。正向传播的信号通过输入层经由隐含层,最终传到输出层。如

果输出结果不满足期望误差,则进入反向传播,在反向传播中误差信号逆向传播并逐层修正各层神经元节点之间的阈值、权值,经过多次迭代,直至达到终止条件。

为避免电站出库流量的计算误差,本文选取可直接测量读取的电站运行与下游水位变化过程监控数据作为建模数据。当电站不发生弃水时,水库出库流量与当前时段的电站出力、上游水位、下游水位等相关<sup>[8-9]</sup>;且下游水位回水顶托与电站该时段之前的出库流量及下游水位有关;同时,由于下游水位站点一般分布在库岸两侧,其水位变化也受分电站出力变化的影响。因此,本文将电站总出力、分电站出力、上游水位以及前期下游水位等电站运行状态作为下游水位变化的影响因素,构建预测模型。

模型的输入为:①前  $n$  小时内的逐小时电站总出力序列;②前  $n$  小时内的逐小时分电站出力序列;③前  $n$  小时内的逐小时上游水位序列;④前  $n-m$  小时内逐小时电站下游水位序列。模型的输出为:  $m$  小时内的逐小时电站下游水位序列(其中  $m \in n$ ,  $n, m$  为自然数)。

### 1.3.2 预测模型构建

设计 BP 神经网络时,需确定网络的拓扑结构,包括隐含层数、每层神经元数以及神经元的激活函数。此外,还需考虑数据的标准化、参数的初始化、模型训练的优化算法等。

**a. 确定网络的拓扑结构。**由于 3 层网络可模拟任意复杂的非线性问题,能够形成任意复杂区域<sup>[10]</sup>,因此,本文选用 3 层 BP 神经网络来构建水电站下游水位变化过程的预测模型,每层都包括若干个神经元,上下层之间的各神经元实现全连接,而同层之间的各神经元无连接。

激活函数能够为神经网络加入一些非线性因素,提高其解决复杂问题的能力。本文采用应用最广泛的 tanh 函数作为激活函数,以保证模型的输出在  $[-1, 1]$  以内。确定隐含层神经元个数的常用方法是试探法<sup>[11]</sup>。本文将训练数据分为训练集和验证集,采用训练集训练模型,采用验证集验证模型的准确率。在对第 1~16 个隐含层神经元进行试探后,发现隐含层神经元个数为 10 时,验证集的误差最小,因此选择隐含层神经元个数为 10。

**b. 数据处理。**由于选用的变量指标互不相同,且各变量指标的数量级差别较大,会对模型产生影响,因此在建模之前,需要对数据进行无量纲处理,减少因数据差异带来的误差。本文对输入输出数据进行如下归一化处理:

$$Y = \frac{(Y_{\max} - Y_{\min})(X - X_{\min})}{X_{\max} - X_{\min}} + Y_{\min} \quad (6)$$

其中  $Y_{\max} = 1$   $Y_{\min} = -1$

式中:  $Y$  为标准化之后的变量数据;  $X$  为原始数据;  $X_{\max}$ 、 $X_{\min}$  分别为变量  $X$  的最大值、最小值。

**c. 模型训练。**在模型训练的优化算法方面,本文采用 Levenberg-Marquardt 优化算法,其收敛速度较快,精度较高,对于中等规模的网络来说是一种较优的训练算法。在 MATLAB 中,神经网络的 Levenberg-Marquardt 优化算法即为“trainlm”训练函数<sup>[12]</sup>。

**d. 模型预测。**将归一化后的输入、输出数据代入模型,采用梯度下降法进行训练,达到设定的终止条件后,保存训练好的模型。预测时,将预测数据归一化后代入模型,模型的输出结果按照下述公式进行反归一化处理:

$$X' = \frac{(Y' - Y_{\min})(X'_{\max} - X'_{\min})}{Y_{\max} - Y_{\min}} + X'_{\min} \quad (7)$$

式中:  $X'$  为下游水位预测值;  $Y'$  为模型输出值;  $X'_{\max}$ 、 $X'_{\min}$  分别为归一化过程中存储的下游水位的最大值、最小值。

## 2 3 种预测方法在葛洲坝水电站中的应用

葛洲坝水电站分为大江电厂和二江电厂,两电厂被泄洪闸门分开,上游代表站水位为 5 号站水位,下游代表站水位为 7 号站水位。葛洲坝水电站装机 23 台,大江、二江、电源电站分别装机 7、15、1 台,设计装机容量为 273.5 万 kW。葛洲坝水电站弃水时通常不参与系统调峰,不弃水时根据三峡出库流量和电网需求确定调峰容量。一般情况下,出库流量较小时,调峰量小于 15 万 kW,机组无需开停机或开停机 1~2 台,下游水位变化不超过 0.3 m;出库流量较大时,调峰量大于 60 万 kW,机组开停机超过 7 台,下游水位变化可超过 2 m。

分别采用现有方法和本文方法进行预测,分析葛洲坝水电站不弃水时,不同方法对下游水位的预测效果。选用 2012—2014 年数据进行模型构建和参数率定,2015 年数据进行模型试验验证。

### 2.1 水位流量曲线查值法参数设置

2012—2014 年葛洲坝水电站日均出库流量与 7 号站下游水位关系曲线如图 1 所示。采用二次多项式拟合的水位流量关系函数为

$$Z = -0.000000002Q^2 + 0.000441631Q + 37.728892735 \quad (8)$$

式中:  $Z$  为葛洲坝水电站 7 号站下游水位;  $Q$  为葛洲坝水电站出库流量。计算采用前 3 日曲线查值计算误差的平均值作为当日下游水位计算的误差修正值。

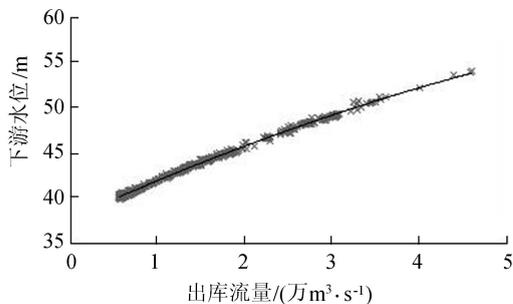


图1 葛洲坝日均出库流量与下游水位相关关系

## 2.2 非恒定流经验公式法参数设置

从2012—2014年葛洲坝2h运行数据(流量数据2h计算1次)中按流量分级选出典型过程,采用最小二乘法率定式(5)中参数 $a$ 、 $b$ 值,如表1所示。

表1 葛洲坝水电站非恒定流经验公式参数

出库流量/( $10^4 \text{ m}^3 \cdot \text{s}^{-1}$ )	$Z_0/\text{m}$	$a$	$b/10^{-3}$
(0.55, 0.65]	39.90	0.8718	0.1867
(0.65, 0.80]	39.90	0.7858	0.4322
(0.80, 1.00]	39.90	0.8602	0.3444
(1.00, 1.50]	39.90	0.7343	0.8143
(1.50, 2.00]	39.90	0.6507	1.1297
(2.00, 3.00]	39.90	0.5880	1.3601
(3.00, $\infty$ )	39.90	0.8072	0.6212

注: $Z_0$ 为7号站的下游水位

## 2.3 本文方法参数设置

由2012—2014年葛洲坝水电站1h运行过程数据分析可知,电站出力变化后,下游水位大致在4~6h达稳定状态,故将当前时段下游水位的前期影响时段定为6h。初步试算并结合调度需求,将模型的有效预测时段定为6h。因此,模型输入变量为:①前12h的逐小时平均全厂总出力;②前12h的逐小时二江电厂出力;③前12h的逐小时5号站水位;④前12h至前7h的逐小时7号站水位。模型输出变量为剩余6h的逐小时7号站水位。

对输入、输出变量数据归一化处理,选用BP神经网络算法工具箱,设定隐含层神经元个数为10,最大迭代次数为10000次,选择“trainlm”训练函数进行训练,训练精度为0.0000001。训练完成后,将模型输出结果进行反归一化处理,至此,非弃水期葛洲坝下游水位变化过程预测模型构建完毕。

## 3 预测结果对比分析

### 3.1 预测结果对比

2015年葛洲坝水电站不弃水时2h预见期下游水位实测值及各方法预测误差对比见表2(由于葛洲坝出库流量2h计算1次,故现有方法仅能做2h预测)。

由表2可知,不弃水时3种方法均表现出低水

表2 2015年葛洲坝水电站不弃水时下游

水位3种方法预测误差对比

m

特征值	下游水位 实测值	水位流量 曲线查值法		非恒定流 经验法		本文方法	
		预测值	误差	预测值	误差	预测值	误差
平均值	41.97	41.902	-0.068	42.047	0.077	41.966	-0.004
中位值	41.33	41.272	-0.058	41.403	0.073	41.327	-0.003
最大值	45.79	46.904	1.114	46.703	0.913	45.993	0.203
最小值	39.87	38.877	-0.993	39.018	-0.852	39.720	-0.150

注:基于监控数据预测模型误差为1h和2h预测的平均值与7号站实际2h平均水位之差。

位误差小,高水位误差大的现象,这是由于出库流量较小时,调峰量也较小,导致下游水位低,变幅小,预测相对准确;而出库流量较大时,调峰量一般也较大,此时下游水位较高,非恒定流现象明显,预测误差大。相比而言,基于监控数据的预测模型无论是对高/低水位或汛期/非汛期预测精度均较高,中位值稳定且较小,预测误差的绝对值最小。本文方法优于现用两种方法原因在于:低水位、小流量下,由于流量的计算误差,现用两种方法采用水位流量数据转换会使误差进一步放大,而本文方法在预测时直接读取电站出力计划曲线和控制方式,可以避免误差累积;高水位、大流量下,现用两种方法无法很好地解决非恒定流过程中水位流量存在的复杂绳套关系,而本文方法在建模过程中考虑多种因素的影响,精度更高。

结合表2、表3可知,葛洲坝水电站不弃水时,本文方法的逐小时水位过程预测精度也较高,其中低水位预测精度比高水位预测精度稍高,预见期6h内最大预测误差绝对值均小于0.3m。同时,随着预见期的增加,误差的均值和中位值在缓慢增加,但增加幅度不大,且误差的最大值、最小值并未随着预见期的增加而线性增加,说明该模型在预见期内预测误差无明显过程累积效应,可一次进行准确的多时段序列预测。

表3 2015年基于监控数据预测模型的葛洲坝水电站不弃水时下游水位预测误差

m

特征值	不同预见期时的水位误差					
	1h	2h	3h	4h	5h	6h
平均值	-0.003	-0.005	-0.007	-0.009	-0.012	-0.013
中位值	-0.003	-0.005	-0.006	-0.007	-0.010	-0.012
最大值	0.150	0.182	0.217	0.176	0.199	0.276
最小值	-0.125	-0.176	-0.217	-0.222	-0.250	-0.266

总体看来,本文方法预测精度最高,曲线查值法和非恒定流经验公式法预测精度相当;同时,高水位、大调峰下,本文方法依然保持足够高的精度,而现有两种方法在下游水位超过43m后,预测误差的绝对值基本大于0.5m,最大绝对误差达1.114m,占

额定水头 5% 以上,严重影响该电站发电计划的制作精度。此外,本文方法延长了预见期,能实现下游水位逐小时变化过程(6 h)预测,且预测效果较好。

### 3.2 不同工况下的预测效果对比

2015 年葛洲坝水电站调峰日数为 320 d,年均调峰容量为 30 万 kW 左右,最小月均调峰容量为 7 万 kW (1 月),最大月均调峰容量为 70 万 kW (7 月)。本文针对汛期、非汛期,选择大调峰(80 万 kW 左右),中调峰(30 万 kW 左右),小调峰(10 万 kW 左右)3 种典型运行工况,共 6 种计算情景,对比分析 3 种方法的预测效果,见图 2、图 3。

由图 2 可知,随着调峰量的增加,现有方法的预测误差不断增加,而本文方法的预测误差变化不大,精度均较高且结果稳定。葛洲坝水电站汛期、非汛期小调峰下 3 种方法精度均较高,但现有两种方法预测误差的绝对值基本在 0.3 m 以内,本文方法预测误差的绝对值基本在 0.1 m 以内。葛洲坝水电站非汛期中等调峰下,现有两种方法的精度一般,预测误差的绝对值最大为 0.45 m,非恒定流经验法较曲线查值法精度稍高,而本文方法的精度最高,预测误差的绝对值基本在 0.2 m 以内;而汛期中等调峰下,现有两种方法预测误差的绝对值最大均超过 0.6 m。汛期、非汛期大调峰下现有两种方法预测误差的绝对值最大接近 1 m,且预测结果不稳定,误差偏差范围大,而本文方法的精度依然较高,预测误差的绝对值基本在 0.25 m 以内。

总体来看,葛洲坝水电站调峰运行的典型工况

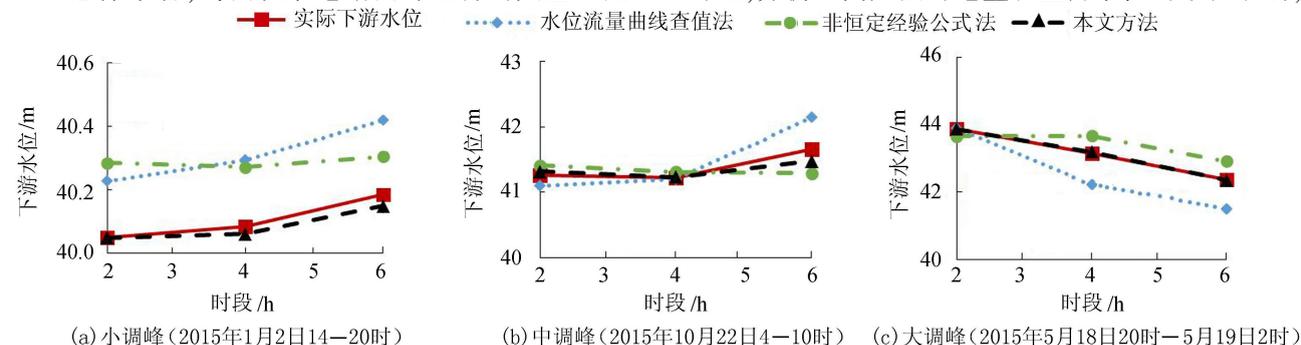


图 2 2015 年(非汛期)葛洲坝水电站 2 h 平均下游水位预测过程与实际过程对比

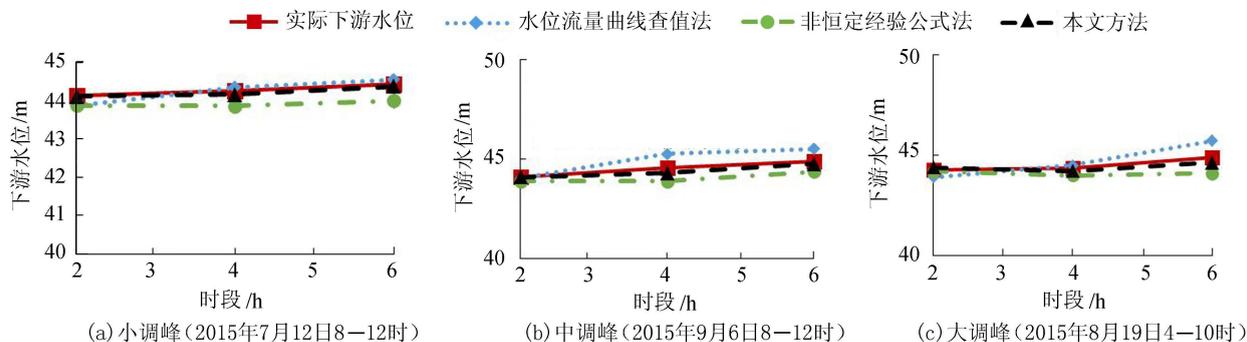


图 3 2015 年(汛期)葛洲坝水电站 2 h 平均下游水位预测过程与实际过程对比

下,本文方法精度最高,且计算结果稳定,非恒定流经验公式精度次之,曲线查值法精度低。对比现有两种方法,本文方法无论在预测精度还是预测频次方面均有大幅提高,葛洲坝水电站下游水位最大 6 h 变幅接近 1.5 m 时,该方法仍可快速准确地预测下游水位变化过程。

### 3.3 电量及上游水位控制偏差的累积效应分析

在实际调度中,非弃水期葛洲坝水电站需根据入库流量、电网下达的出力计划反算葛洲坝上游水位是否能按预定方案运行,若引起上游水位变化超出控制范围,则需重新计算发电计划,并向电网申请修改当前发电计划来控制上游水位。下游水位计算误差将影响发电水头的计算,使得水电站出力计算出现偏差;按此出力计划执行,将导致电站上游水位和电量预测存在偏差。另外,发电计划误差对电站上游水位和电量呈非线性累积的影响,例如葛洲坝下游水位预测值跟实际值相差 0.5 m 时,在发电流量  $18000 \text{ m}^3/\text{s}$ 、电站调峰 30 万 kW 左右的情况下,1 h 时段末上游水位计算偏差将超过 0.1 m,发电量计算偏差将超 6 万 kW · h;2 h 时段末上游水位计算偏差将超过 0.3 m,发电量计算偏差将超 15 万 kW · h。本文将以上文设定的葛洲坝水电站非汛期、汛期,调峰小、中、大工况的实际上游水位和电量作为基准,采用现有方法与本文方法连续预测未来 6 h 下游水位过程,反算电站发电量和时段末上游水位,并与基准对比,分析不同方法对电量和上游水位的累积影响,

见表4、表5。

表4 2015年不同工况6h内电量偏差对比 万kW·h

预测方法	非汛期与实际电量偏差			汛期与实际电量偏差		
	小调峰	中调峰	大调峰	小调峰	中调峰	大调峰
	水位流量曲线查值法	6.2	10.7	26.9	11.0	38.7
非恒定经验公式法	5.2	9.7	20.3	26.5	37.0	34.2
本文方法	0.7	3.6	1.3	3.6	9.5	10.5

表5 2015年不同工况预测6h末上游水位控制累积偏差对比 m

预测方法	非汛期与实际上游水位偏差			汛期与实际上游水位偏差		
	小调峰	中调峰	大调峰	小调峰	中调峰	大调峰
	水位流量曲线查值法	0.04	0.08	0.20	0.09	0.33
非恒定经验公式法	0.03	0.07	0.15	0.17	0.30	0.28
本文方法	0.004	0.03	0.009	0.03	0.08	0.10

由表4、表5可知,随着调峰量的增加,现有方法计算的电量偏差和上游水位控制累积偏差也不断增加,且上游水位控制累积偏差呈指数增长状态,即前期水位计算误差将对后期水位计算造成巨大影响;而本文方法的预测精度随调峰量的增加偏差变化不大,计算结果稳定,误差最小。水位流量曲线查值法6h电量累积偏差最大达38.7万kW·h,上游水位控制累积偏差最大达0.33m,而本文方法6h电量累积偏差最大仅为10.5万kW·h,上游水位控制累积偏差最大仅为0.10m,无论在电量计算还是水位控制精度均有大幅提高,有力地保障了电站效益和安全运行。

## 4 结论

a. 非弃水期水电站下游水位的变化过程受多种因素影响,本文针对现有方法水位预测误差较大的情况,提出利用BP神经网络算法模拟电站运行过程与下游水位变化过程之间的关系,建立了基于监控数据的水电站下游水位变化过程预测模型。实际应用表明预测模型计算精度较高,该方法可以直接用于生产调度实践。

b. 基于数据挖掘原理的BP神经网络模型预测效果较好,尤其针对运行时间长、资料详实的日调节或径流式电站,如葛洲坝水电站。其原因在于径流式电站运行水位变幅小,且电站运行时间长,数据多,建模时输入数据中已包含各种工况,因此模型预测效果好。实际应用表明模型预见期内最大预测误差的绝对值小于0.25m。

c. 本文提出的预测方法还有其他方法不可比拟的优势,譬如:可实现通过监控数据中直接测量的电站运行数据和下达的发电计划数据直接预测下游水位变化过程;可进行计算时段为1h的水电站下游水位连续过程预测,较现有方法计算结果稳定,同时避

免了现有方法预测过程的误差累积;计算时间短,计算精度较高。然而,BP神经网络模型的应用需水电站拥有多年详实的监测运行数据,在后期研究中可进一步分析缺少资料条件下的BP神经网络建模。

## 参考文献:

- [1] 刘俊伟,王建军.葛洲坝水电站下游水位经验计算方法探索[J].水电自动化与大坝监测,2011,35(4):77-80. (LIU Junwei, WANG Jianjun. Exploration of empirical calculation method about tailwater level in Gezhouba Hydropower Station [J]. Hydropower Automation and Dam Monitoring, 2011, 35(4):77-80. (in Chinese))
- [2] 尚毅梓,郭延祥,李晓飞,等.小南海水电站日调节非恒定流对通航的影响[J].水利水电科技进展,2015,35(4):65-69. (SHANG Yizi, GUO Yanxiang, LI Xiaofei, et al. Influence of daily regulation unsteady flow on navigation for Xiaonanhai Hydropower Station [J]. Advances in Science and Technology of Water Resources, 2015,35(4):65-69. (in Chinese))
- [3] 苑希民,李鸿雁,刘树坤,等.神经网络和遗传算法在水科学领域的应用[M].北京:中国水利水电出版社,2002.
- [4] 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.
- [5] 张英贵.电力系统中水电厂群日优化运行[M].武汉:华中理工大学出版社,1994.
- [6] 徐鼎甲.进行日调节时水电站下游水位的计算[J].水利水电技术,1995(4):2-4. (XU Dingjia. Computing method on downstream water level of daily regulation hydropower station[J]. Water Resources and Hydropower Engineering, 1995(4):2-4. (in Chinese))
- [7] KANANINA E D. A simple procedure for pruning back-propagation trained neural networks[J]. IEEE Trans on Neural Networks, 1990, 1(2): 239-242.
- [8] 刘志武.三峡-葛洲坝梯级电站耗水率计算方法改进[C]//大型水轮发电机组技术论文集[C].北京:中国水力发电工程学会,2008:327-332.
- [9] 王蒙蒙,戴凌全,戴会超,等.基于支持向量回归的洞庭湖水快速预测[J].排灌机械工程学报,2017,35(11):40-47. (WANG Mengmeng, DAI Lingquan, DAI Huichao, et al. Support vector regression based model for predicting water level of Dongting Lake [J]. Journal of Drainage and Irrigation Machinery Engineering (JDIME), 2017,35(11): 40-47. (in Chinese))
- [10] 侯媛彬,杜京义,汪梅.神经网络[M].西安:西安电子科技大学出版社,2008.
- [11] 葛哲学,孙志强.神经网络理论与MATLAB R2007实现[M].北京:电子工业出版社,2007.
- [12] 崔东文.多重组合神经网络模型在年径流预测中的应用[J].水利水电科技进展,2014,34(2):59-63. (CUI Dongwen. Application of multiple combined neural network model in annual runoff prediction[J]. Advances in Science and Technology of Water Resources, 2014,34(2):59-63. (in Chinese))

(收稿日期:2018-03-30 编辑:骆超)