



Output Prediction of Photovoltaic Power Station Based on Nonlinear Combined Model

Xi Fang*, An Yuan, Yao Jiang, Wei Qian, Wang Yuyao

Institute of Water Resources and Hydro-electric Engineering, Xi'an University of Technology, Xi'an, China

Email address:

1354226264@qq.com (Xi Fang), 864890175@qq.com (Yao Jiang), 402488878@qq.com (Wei Qian)

*Corresponding author

To cite this article:

Xi Fang, An Yuan, Yao Jiang, Wei Qian, Wang Yuyao. Output Prediction of Photovoltaic Power Station Based on Nonlinear Combined Model. *Science Discovery*. Vol. 4, No. 6, 2016, pp. 353-359. doi: 10.11648/j.sd.20160406.11

Received: October 23, 2016; **Accepted:** November 22, 2016; **Published:** November 24, 2016

Abstract: The output prediction of photovoltaic (PV) power station is necessary because the weather, environment and seasonal factors lead to the unstable PV power generation, which will affect the planning and scheduling of power system. Compared with the single model method, the linear combination method could improve the prediction accuracy of the output of PV power station. However, the linear combination forecast method is a simple convex combination of different prediction methods and is lack of general applicability. This paper presents a nonlinear combination method based on BP neural network and ARMA model to predict the output of PV power plant. This method based on the nonlinear relationship between the results of two single prediction models and the actual value, and utilize the nonlinear fitting ability of BP neural network, predicted the power generation capacity of PV power station. The nonlinear prediction theory and algorithm are given at the end of the article, and also compare nonlinear combined model with linear combined model of the power plant output prediction, the results show that the proposed method has a high accuracy and an extensive applicability.

Keywords: PV Power Station, Output Prediction, BP Neural Network Model, ARMA Model, Nonlinear Combination Model

基于非线性组合模型的光伏电站出力预测

习方*, 安源, 姚江, 魏倩, 王禹尧

水利水电学院, 西安理工大学, 西安, 中国

邮箱

1354226264@qq.com (习方), 864890175@qq.com (姚江), 402488878@qq.com (魏倩)

摘要: 光伏发电出力易受天气、环境、季节等因素的影响, 会对电力系统的规划与调度带来影响, 因此有必要对光伏电站进行出力预测。线性组合方法对光伏电站出力的预测相比于单一模型方法的预测精度得到了提高, 然而线性组合预测只是不同预测方法之间的值的一种凸组合, 不具有普遍适用性。本文提出一种基于BP神经网络和ARMA模型的非线性组合预测方法, 该方法针对两种单一模型的预测结果与实际值之间的非线性关系, 采用基于BP神经网络的非线性拟合能力预测光伏电站发电量。文章给出了非线性预测的原理及算法, 并利用实例对比分析了非线性和线性组合模型的电站出力预测精度, 结果表明, 所提出的方法预测更准确, 精度更高, 具有实用性。

关键词: 光伏电站, 出力预测, BP神经网络, ARMA模型, 非线性组合模型

1. 引言

随着传统能源的日益紧缺,新能源的开发与利用得到世界各国的广泛关注,其中太阳能光伏发电得到了迅速发展,正在逐渐从独立的系统向大规模并网方向发展[1]。太阳能是一种绿色无污染的可再生能源,太阳能光伏发电具有环保、可靠性好、使用寿命长、安装维护简单等优点,光伏发电不仅可以节约大量的不可再生能源,而且运行过程中无噪声、无污染,减少对环境保护的资金再投入[2]。但是由于光的随机波动性和谐波、不对称、闪变等问题影响光伏发电的电能质量,因此光电接入电网时必然会对大电网造成极大的冲击,同时对电力系统的安全及电能质量带来严峻挑战[3-4]。为了使光伏发电量对大电网的影响降到最低,光伏电站的高精度出力预测是现今急需解决的问题。

光伏发电预测方法根据数学模型的不同,大致可以分为原理预测法[5],统计预测法[6],智能预测法[7]和不确定理论预测法[8-9]等。其中统计预测方法较为成熟,具有程序简单明确,应用广泛,预测准确等优点[10]。

采用ARMA模型可以有效的对光伏电站进行出力预测,但是采用单一的ARMA模型进行出力预测具有预测精度不高等缺点[11]。采用BP神经网络模型进行出力预测同样具有预测精度不高等缺点,文献[12]针对这一问题进行改善,对数值天气预测数据进行模糊识别,建立了基于模糊识别的神经网络发电预测模型。该模型所采用的数据模糊识别方法有利于提高神经网络的预测精度,但是该算法具有易陷入局部极小点、收敛速度慢等缺点。文献[13]提出了一种基于改进BP神经网络的光伏发电系统输出功率短期预测模型,为了提高模型的预测精度,提出了相似日选择算法和训练样本确定方法,针对文献[12]所用方法的缺点,利用增加动量项和可变学习率相结合的方法对其进行了改进,但是这种单一预测方法的准确性严重依赖于样本以及输入量的选取。

以上方法均采用单一预测模型,而单一模型往往具有适用范围小,预测精度低等问题。采用两种及以上模型结合起来进行预测,综合考虑各模型的特点,将不同模型的优势相结合,可以得到更为精确的预测结果。文献[14]提出了一种基于改进灰色BP神经网络的多模型组合光伏出力预测方法,该方法通过将多个单一预测结果组合成样本训练BP神经网络来获得较优权重系数,能够得到更为精确的预测结果。文献[15]采用线性组合方法构建模型进行预测,根据最优算法得到最优的预测结果,提高预测精度,但此方法不具有普遍适用性。

本文采用非线性拟合方法对光伏电站出力进行预测,该方法在单一预测模型的基础上进行非线性组合,相比于线性组合模型具有更广泛的适用性与更高的精度。

本文首先选取数据资料齐全的某光伏电站的历史数据作为模型输入,对其历史数据进行归一化和零均值化、平稳化处理,再分别利用BP神经网络模型和ARMA模型预测结果,并计算误差指标,最后将这两种模型预测结果进行非线性组合预测,并将结果与线性组合方法进行对比及分析。结果表明,本文所提出的方法,具有更高的预测精度,可以有效的减少光伏出力不稳定对电网的影响。本文结构安排如下,第一章为引言;第二章介绍BP神经网络模型和ARMA模型;第三章为BP神经网络模型和ARMA模型的具体构

建过程,第四章介绍本文所采用的非线性组合预测方法,并给出评价指标;第五章应用实际算例进行预测分析并将预测结果与现有方法加以对比;第六章给出结论。

2. BP神经网络模型和ARMA模型

2.1. BP神经网络模型

BP神经网络一般是多层的,模型中除了输入层和输出层外,还具有多个隐含层,每层之间全连接,同一层之间的神经元无连接。这样的结构层设计,使得我们可以从输入层中找到更多更有用的信息,更好地完成更复杂的任务。

对于BP神经网络模型的学习训练,包括两个过程,即输入样本的正向传播过程和输出误差的反向传播过程。在BP网络中,训练网络权值和阈值时,沿着误差减少最快的方向,即负梯度方向。随着学习的不断进行,最终的误差会越来越小[16]。

2.2. ARMA模型

ARMA(自回归滑动平均)方法是一种短期时间序列预测方法,将预测指标随时间推移而形成的数据序列看作是一个随机序列,这组随机变量所具有的依存关系体现着原始数据在时间上的延续性。其基本思想是:一组随时间变化且相关的数字序列,可近似的用一定的数学模型进行模拟,通过对模型的分析,可以更加深刻的认识到其内在的相关及复杂性,从而达到最佳预测。而且基于ARMA模型的预测尤其在数据统计不完善的情况下更有效[17]。

3. BP神经网络模型和ARMA模型的构建

3.1. BP神经网络模型的构建

3.1.1. 网络结构的设计

BP神经网络包含:输入层、隐含层、输出层。其中隐含层可以是多层。要构建一个神经网络,就要确定网络层数以及各层节点数,还要确定每一层的所用的传递函数和相关参数。

通常情况下,BP神经网络的层数越多,输出误差的反向传播在靠近输入层时误差较大,越难得到我们想要的最佳模型。一般情况下,我们选用的BP神经网络的层数为3层。输入层神经元的个数就是我们实际问题中涉及到的输入参数的个数,输出层神经元的个数是我们期望得到的输出参数的个数。关于隐含层节点数的选择,这是该网络模型预测最为关键的步骤,对于预测的结果是否理想具有决定性的意义。可以采用试凑法来确定隐含层的节点数,即先选取较少的节点数进行训练,然后再逐步增加试算来得到最佳的节点数。

3.1.2. 网络构建

(1) 输入输出数据预处理

采用BP神经网络建立预测模型,由于原始数据具有不同的量纲,不同的数量级,可能对建立模型有所影响,无法建立准确的模型。为了消除原始数据不同量纲对模型的影响,同时也为了进一步提高其预测精度和效率,必须要

对原始数据进行归一化处理。即通过一些变换将输入输出原始数据限制在 $[0, 1]$ 或 $[-1, 1]$ 之间。可以利用matlab中的mapminmax函数将输入输出的原始数据进行归一化处理。在预测结束得到预测结果后,再用反归一化函数把预测值还原为原来的量纲。

(2) BP网络设计及训练

BP网络的设计主要是确定隐含层的神经元的个数,这和输入层的神经元的个数是紧密相关的。现在关于隐含层节点数的选取,还没有比较好的理论方法,大多数情况下是根据经验公式或者试凑法来得到最佳的隐含层节点数。输入输出层以及隐含层都采用logsig函数,训练算法采用trainlm函数。再对神经网络进行训练,其中训练参数如下:最大训练次数为1000次,训练目标为0.0001,学习速率为0.1。

3.2. ARMA模型的构建

3.2.1. 数据的预处理

首先对原始数据序列进行零均值化、平稳化处理。数据经过预处理后,我们得到了一组发电量的零均值平稳数据序列。建模的时候,我们采用Box-Jenkins建模方法。Box-Jenkins建模方法的核心思想是以序列的自相关函数和偏自相关函数为依据,找到一个可能适应的模型然后对其进行估计。

3.2.2. 模型的识别与定阶

对上述得到的平稳数据序列,我们要进行模型的识别与定阶。根据样本的自相关函数和偏自相关函数以及他们的截尾性和拖尾性来对模型进行定阶。表1是ARMA模型的序列特征表,可对模型进行初步定阶。

表1 ARMA (p, q) 模型的序列特征表。

模型	自相关函数	偏相关函数
AR (p)	拖尾	截尾 $k=p$ 处
MA (q)	截尾 $k=p$ 处	拖尾
ARMA (p, q)	拖尾	拖尾

ARMA (p, q) 中p, q参数的确定:

p, q值可分别先从平稳序列的偏自相关图和自相关图进行初步选择,然后不断的修正参数,求出附近的一系列模型,最终找到一个最优模型。或者运用AIC准则对序列进行拟合,使AIC值达到极小的模型就可以认为是最佳模型。准确来说,AIC值最小,拟合函数的残差方差也就最小,由此得到的p, q值为最佳选择[18]。

3.2.3. 模型的参数估计与适应性检验

(1) 参数估计

在确定模型类型及模型阶数的情况下,我们就需要进行模型参数估计。一般情况下,采用最小二乘估计,这种估计法是线性模型中较为常用的方法,具有优良的统计性,而且计算简单。

(2) 模型残量的自相关检验

序列经过平稳处理,并建立了相应的模型后,为了考核所建模型的优劣,还要对模型进行进一步检验,即白噪

声检验。如果一个序列是由不相关的随机变量的序列构成的,则称其为纯随机过程。对于一个纯随机过程来说,若其期望和方差均为常数,则称之为白噪声过程。白噪声过程的样本实称成为白噪声序列,简称白噪声。如果经检验是白噪声序列,则我们所建立的模型是合理的,否则就应重新改进模型直到得到最佳模型。

4. 组合预测模型

传统组合预测方法是将实际值与预测值看成是一种线性关系,在基于预测误差绝对值达到最小的情况下,利用数学方法求出的最优线性组合。本文采用一种非线性组合预测的方法,利用BP神经网络的非线性拟合能力来进行预测。

4.1. 最优线性组合预测

假设某一时期的实际发电量观测样本为 x_t , $t=1, 2, \dots, m$, m 为观测样本的数量,现有两种预测方法对发电量分别进行预测,预测结果记为 \hat{x}_{1t} 和 \hat{x}_{2t} ,则预测误差可以分别表示为 $e_{1t} = \hat{x}_{1t} - x_t$ 和 $e_{2t} = \hat{x}_{2t} - x_t$ 。那么经过线性组合后的预测误差为:

$$e_t = k_1(\hat{x}_{1t} - x_t) + k_2(\hat{x}_{2t} - x_t) = k_1 e_{1t} + k_2 e_{2t} \quad (1)$$

式中, k_1, k_2 分别为两种预测方法的加权系数,为了保持无偏性,应满足条件 $k_1 + k_2 = 1$ 。

使组合误差达到最优,即使(1)式中所有样本的绝对值误差之和最小, R 表示预测误差绝对值之和,写为:

$$R = \sum_{t=1}^m |e_t| = \sum_{t=1}^m |k_1 e_{1t} + k_2 e_{2t}| \quad (2)$$

式中, R 非负,那么使式(2)中 R 达到最小可以转化为求解 $\sum_{t=1}^m (k_1 e_{1t} + k_2 e_{2t})^2$ 的最小值问题。

4.2. BP神经网络非线性拟合预测

BP神经网络是误差反向传播神经网络的简称,具有信息分布存储、信息并行处理、容错性及自组织、自适应特点,这些特点决定了它特有的能力[19]。其中,BP神经网络的最显著的特征是具有强大的非线性处理能力,理论上,对于一个3层或3层以上的神经网络,只要隐含层的神经元的个数足够多,那么该网络就能以任意精度去逼近一个非线性函数[20]。这为解决非线性问题提供了一种独特的处理思路。

BP神经网络将非线性复杂系统看成是一个功能系统,该系统由大量的具有非线性功能的神经元构成。神经元是一个非线性单元且具有多输入单输出的结构,计算着来自其他神经元的输入数据的加权和,最后通过加权和的非线性函数输出一个值。图1为神经元的结构图。

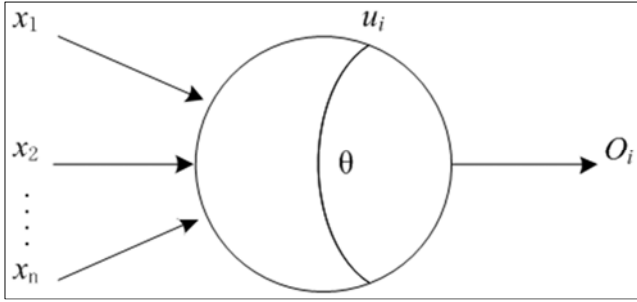


图1 神经元结构图。

图中 x_i 为神经元的输入， O_i 是神经元的输出，表达式为 $O_i = f(\sum w_{ij} \times x_i - \theta_i) = \frac{1}{1 + e^{-(\sum w_{ij} \times x_i - \theta_i)}}$ ，其中BP神经网络神经元的激活函数一般采用S型函数 $f(x) = \frac{1}{1 + e^{-x}}$ ，S型函数是一个连续可微的非线性函数，它可以严格利用梯度法进行推算。S型函数不仅可以完成分类所需的非线性特性，而且也比较接近于人脑神经元的输入-输出特性[21]。S型函数赋予了网络基本单元的非线性特性，即BP神经网络是以非线性为基点进行训练的，网络从一开始就非常重视非线性这一特性，用非线性的视角来处理非线性问题，并没有寻求传统的线性方法来解决此类问题。因此本文选用了BP神经网络并结合两种单一预测模型的结果来预测光伏电站的发电量。

以各模型的预测值作为BP神经网络的输入，光伏电站的实际值作为输出来进行网络的训练。设光伏电站发电量的实际样本值为 A_t ， $t=1, 2, \dots, m$ ， m 为样本个数，每个单一预测模型的第 t 次预测结果分别为 A_{1t} 和 A_{2t} ，他们之间的非线性关系可以表示为：

$$\sum_{t=1}^m |A_t - f(A_{1t}, A_{2t})|^2 \quad (3)$$

其中， f 为预测结果的非线性映射，本文采取3层BP神经网络拟合算法使得上述非线性映射更接近实际值，即让式(3)值达到最小，因此将各模型的预测值作为神经网络的输入，实际值作为神经网络的输出，经过神经网络的训练后，得到的值即为光伏电站出力的预测值。

4.3. 评价指标

预测具有不确定性，预测误差是客观存在的[22]。为了验证预测结果的优劣，本文采用平均绝对误差(MAE)和均方根误差(RMSE)这两个评价指标作为检验模型的评价标准，计算公式如下：

平均绝对误差：

$$MAE = \frac{\sum_{t=1}^m |P_t - \hat{P}_t|}{Cap \times m} \quad (4)$$

均方根误差：

$$RMSE = \sqrt{\frac{\sum_{t=1}^m (P_t - \hat{P}_t)^2}{Cap^2 \times m}} \quad (5)$$

式中： P_t 为 t 时刻的实际功率， \hat{P}_t 为 t 时刻的预测功率， Cap 为装机容量， m 为样本个数。

其中，均方根误差能对预测误差较大的情况进行放大，采用均方根误差这一评价指标作为模型预测评估方法能够保证模型预测误差的平稳性[23]。

5. 算例分析

本文采用某光伏电站2016年1月1日~9月30日的实际数据作为样本，应用非线性组合预测方法对发电量进行预测，并与线性预测及单一预测的预测结果进行对比分析。

5.1. BP神经网络实例模型

影响光伏发电的因素众多，本文主要考虑温度、日累计辐照量、平均辐照度因素，因此BP神经网络的输入层神经元的个数是3；从输出层来说，我们主要预测光伏电站的日发电量，所以输出层神经元的个数为1；由于我们输入层的神经元有3个，根据经验公式我们可以得出隐含层的神经元个数为3~7个，经过多次的试验发现当隐含层的神经元个数为7时，预测的效果最佳。建立的模型如图2所示。

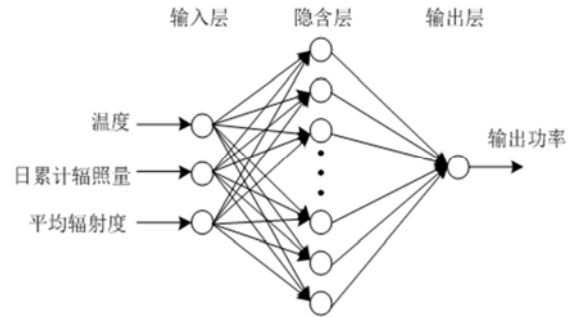


图2 BP神经网络模型。

选用2016年1月1日~9月30日的温度，日累计辐照量，平均辐照度，发电量总共有274组数据作为样本，选用1月1日~7月18日的样本数据作为训练样本建立BP神经网络模型，通过该模型预测7月19日到9月30日的发电量以检验预测误差是否满足函数要求。图3所示是光伏电站实际功率与BP神经网络模型预测功率的对比图，图中蓝色实线代表光伏电站的实际功率，红色虚线是BP神经网络模型预测的结果。从图中可以看出基于BP神经网络预测的光伏电站输出功率与实际输出功率的变化趋势基本相同，但是当实际发电容量大于100kWh时，预测结果偏离实际输出较多，误差较大。

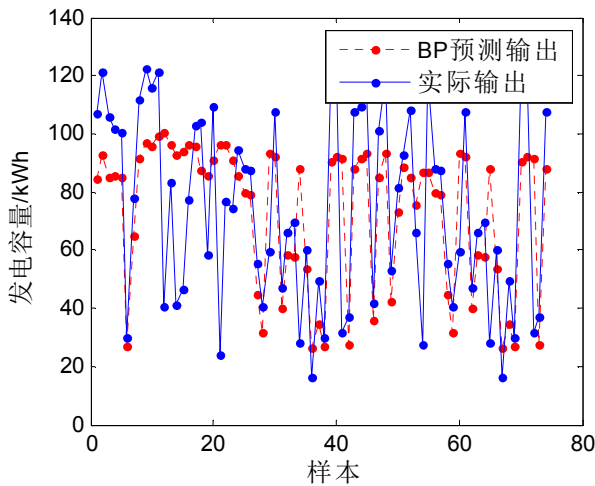


图3 BP神经网络模型预测结果。

5.2. ARMA实例模型

我们选取和上一小节相同的时间样本进行ARMA模型预测发电量。分别对选取的样本数据进行自相关和偏自相关处理，其中自相关函数和偏自相关函数分别如图4、图5所示。自相关函数值和偏自相关函数值在分别经过6步和8步后逐渐衰减到0，通过AIC准则定阶及ARMA模型的序列特征的截尾性、拖尾性可以判断该时间序列符合ARMA(6, 8)模型。

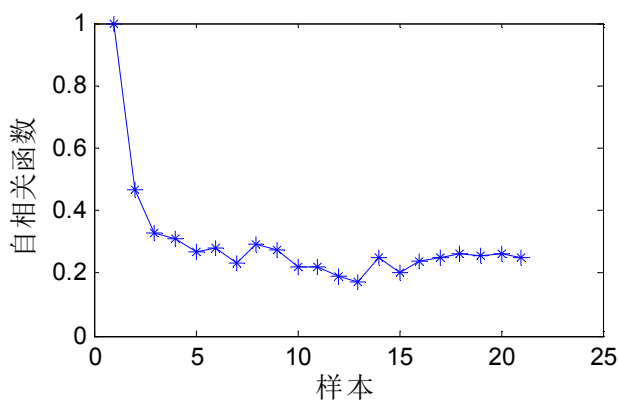


图4 自相关函数图。

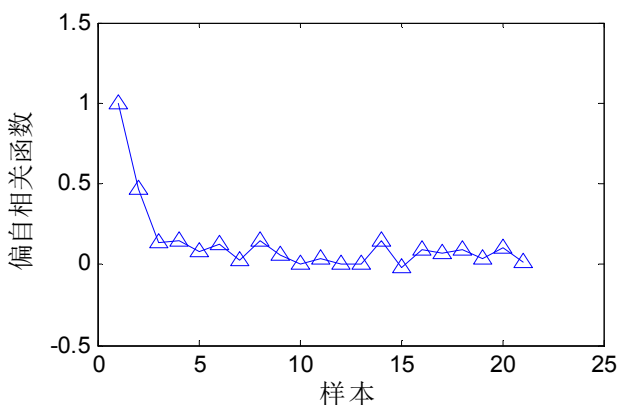


图5 偏自相关函数图。

在判定模型为ARMA的情况下，我们进行参数估计。可以得到，模型的系数是统计显著的，AIC准则是6.8225，BIC准则是6.7879，残差平方和是854.468。

由于我们选取的样本均来自于光伏电站的真实数据，且样本容量足够大，所以可对其进行残量的自相关检验来判断是否为白噪声序列。从图6可以看出，我们所建立模型的残差序列的自相关系数基本控制在0.1之内，认为是白噪声序列，即模型是合理的。

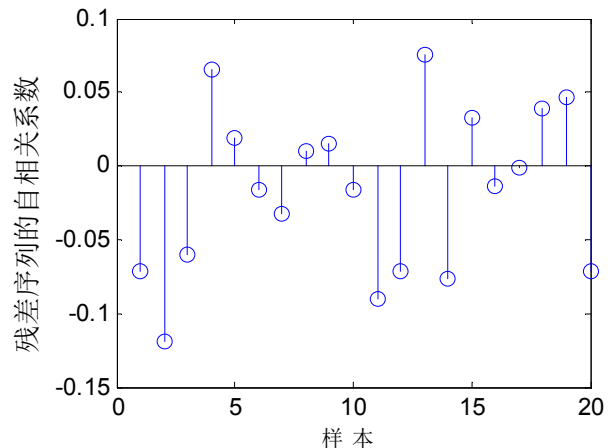


图6 残差序列的自相关系数图。

我们采用建立的ARMA模型对光伏电站的发电量进行预测，结果如图7所示，其中蓝色实线代表光伏电站的原始数据，红色虚线代表ARMA模型预测的结果。从图中可以看出基于ARMA模型的光伏电站出力预测与实际值变化趋势基本一致，但是其中有部分样本的预测效果并不是很理想，与实际发电量相比误差较大。

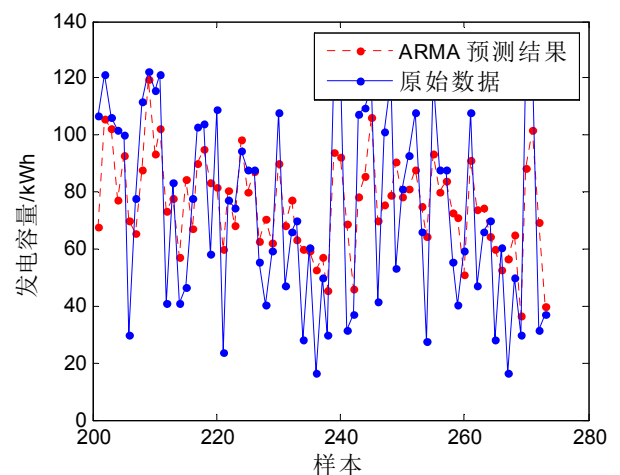


图7 ARMA模型预测结果。

5.3. 组合预测实例模型

根据4.1节介绍的线性组合预测方法，采用ARMA和BP神经网络的线性组合预测算法，计算出最优的组合系数解为 $k_1=0.6980$ ， $k_2=0.3020$ 。组合预测可以表达为 $x_t=0.6980x_{1t}+0.3020x_{2t}$ ，式中 x_{1t} 为BP神经网络预测模型， x_{2t} 为ARMA预测模型， x_t 为组合预测模型。

前面4.2节详细介绍了BP神经网络的非线性拟合原理，可以知道BP神经网络从输入到输出的非线性映射关系并不是采用非线性模型来建立非线性体系，而是利用自己本身的非线性结构以及对非线性问题处理的能力来模拟预测的。本文在基于BP神经网络模型和ARMA模型单一预测的结果上结合BP神经网络的非线性拟合能力对光伏电站的发电量进行预测。

为了说明非线性组合预测方法的优越性，现将两种组合预测模型的结果进行对比，选取某光伏电站一段时期内的数据进行建模预测，预测的33个结果与实际发电量进行比较，如图8所示。图中蓝色实线为实际发电量数据，红色点线为线性组合的预测发电量结果，黑色虚线为本文采用的非线性组合发电量预测结果。从图中可以看出，非线性组合预测结果相比线性组合预测更接近光伏电站实际发电量，具有更高的预测精度，与实际情况更相符。

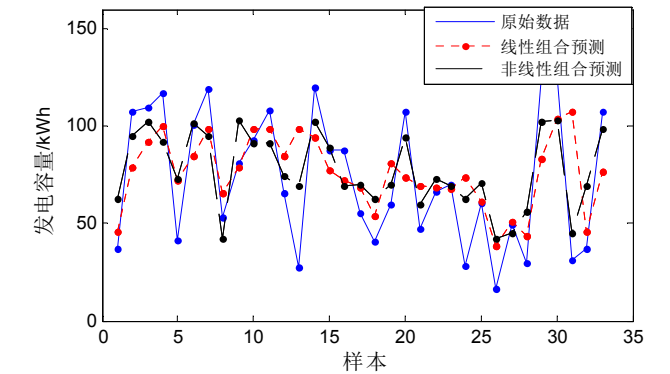


图8 非线性和线性组合预测结果。

为了更直观的说明非线性组合的预测优势，本文分别基于MAE和RMSE评价指标对比了4种预测模型的结果，如表2所示。从表2可以看出，本文采用的基于非线性拟合预测光伏电站出力的预测方法，分别以BP神经网络模型和ARMA模型预测出的结果组合为输入，以实际值为输出，得到的平均绝对误差和均方根误差分别为0.092和0.1084，与线性组合模型0.0941和0.1399的预测误差相比，非线性组合预测的总体误差分别减小了2.23%与2.25%，指标计算结果也再次证明使用该方法进行出力预测误差更小，更接近实际值。

表2 不同预测模型的结果对比。

预测方法	评价指标	
	MAE	RMSE
BP神经网络	0.1026	0.1511
ARMA模型	0.1213	0.1607
线性组合模型	0.0941	0.1399
非线性组合模型	0.0920	0.1084

6. 结论

光伏发电受光照强度等多种因素的影响，其输出功率不稳定，会给电网规划、系统调度和电网的可靠、安全运行带来很多问题，因此研究光伏发电功率预测具有重要意义。相比线性组合模型预测方法，非线性组合模型预测方

法更具普遍适用性。本文采用了用于光伏电站出力预测的非线性拟合方法，详细介绍了非线性拟合算法的原理并给出了预测模型的评价指标。通过对某光伏电站的历史数据进行了预测，结果验证了该预测方法相比于传统的线性预测方法具有更高的预测精度，说明非线性拟合预测方法能够较准确地预测光伏电站的输出功率，有效地解决光伏发电的随机性问题。并且该非线性拟合预测方法能够普遍适用光伏电站出力预测，算法灵活简便，实用性好。

参考文献

[1] 袁晓玲, 施俊华, 徐杰彦, 等. 计及天气类型指数的光伏发电短期出力预测[J]. 中国电机工程学报, 2013, 33(34)。

[2] 李芬, 陈正洪, 何明琼, 等. 太阳能光伏发电的现状 & 前景[J]. 水电能源科学, 2011, 29(12)。

[3] 赵争鸣, 雷一, 贺凡波, 等. 大容量并网光伏电站技术综述[J]. 电力系统自动化, 2011, 35(12):101-107。

[4] 丁明, 王伟胜, 王秀丽, 等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1)。

[5] Radziemska E. The effect of temperature on the power drop in crystalline silicon solar cells [J]. Renewable Energy, 2003:28.

[6] 李光明, 刘祖明, 何京鸿, 等. 基于多元线性回归模型的并网光伏发电系统发电量预测研究[J]. 现代电力, 2011, 28(2)。

[7] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9)。

[8] Li Yingzi, Luan Ru, Niu Jincang. Forecast of power generation for grid-connected photovoltaic system based on grey model and Markov chain [C]. 3rd IEEE Conference on Industrial Electronics and Applications. Singapore, 2008.

[9] Li Yingzi, Jin-cang Niu, Shao-yi Wang. Forecast of power Generation for Grid-Connected Photovoltaic System Based on Pawlak Attribute Importance Algorithm of Rough Sets [C]. IEEE PES ISGT ASIA 2012.

[10] 李春来, 朱慧敏, 景满德, 等. 并网型光伏电站功率预测方法和探讨[J]. 电工技术, 2010, 12: 27-28。

[11] 兰华, 廖志民, 赵阳, 等. 基于ARMA模型的光伏电站出力预测[J]. 电测与仪表, 2011, 48(542)。

[12] 陈昌松, 段善旭, 蔡涛, 等. 基于模糊识别的光伏发电短期预测系统[J]. 电工技术学报, 2011, 26(7)。

[13] 丁明, 王磊, 毕锐, 等. 基于改进BP神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制, 2012, 40(11)。

- [14] 王新普, 周想凌, 邢杰, 等. 一种基于改进灰色BP神经网络组合的光伏出力预测方法[J]. 电力系统保护与控制, 2016, 44(18)。
- [15] 曾鸣, 李树雷, 王良, 等. 基于ARMA模型和BP神经网络组合优化算法的风电预测模型[J]. 华东电力, 2013, 41(2)。
- [16] 刘晓楠, 王胜辉, 金月新, 等. 基于BP神经网络的风电场发电功率短期预测[J]. 沈阳工程学院学报, 2015, 11(1)。
- [17] 党睿, 张俊芳. 基于自回归滑动平均模型的风电功率预测[J]. 安徽工业大学学报(自然科学版), 2015, 32(3)。
- [18] 沃尔特, 恩德斯. 时间序列分析[M]. 杜江, 谢志超, 译. 北京: 高等教育出版社, 2006。
- [19] 郝中华. BP神经网络的非线性思想[J]. 洛阳师范学院学报, 2008, 4。
- [20] 张宝堃, 张宝一. 基于BP神经网络的非线性函数拟合[J]. 电脑知识与技术, 2012, 27(8)。
- [21] 郑君里, 杨行峻. 人工神经网络[M]. 北京: 高等教育出版社. 1992。
- [22] 谷兴凯, 范高峰, 王晓蓉, 等. 风电功率预测技术综述[J]. 电网技术, 2007, 31(Supplement2):335-338。
- [23] 邓雅, 胡书举, 孟岩峰, 等. 光伏发电系统功率预测研究方法综述[J]. 电器制造, 2013, 6: 50-53。