

DOI: 10.7667/PSPC151675

一种基于改进灰色 BP 神经网络组合的光伏出力预测方法

王新普¹, 周想凌², 邢杰², 杨军¹

(1. 武汉大学电气工程学院, 湖北 武汉 430072; 2. 湖北省电力公司运营监测(控)中心, 湖北 武汉 430077)

摘要: 光伏发电具有典型的间歇性、波动性等特点。准确预测光伏出力对电网调度、电网规划、提升新能源发电竞争力具有重要意义。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, 采用常规 GM(1,1) 模型、幂函数变换 GM(1,1)模型、基于残差修正的 GM(1,1)模型以及等维新息 GM(1,1)四种模型, 利用 BP 神经网络对光伏出力的单一灰色预测结果进行优化组合输出, 并根据输出值和期望值的偏差自动调整组合权值。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系数, 避免了数值求解权系数的复杂过程, 能够得到更为精确的预测结果。采用湖北某地光伏系统实际出力数据对该预测方法进行了验证。计算结果表明该基于改进灰色 BP 神经网络组合的光伏出力预测方法能够明显提高光伏出力预测精度。

关键词: BP 神经网络; 组合权重; 灰色模型; 光伏出力预测; 模糊 c-均值

A prediction method of PV output power based on the combination of improved grey back propagation neural network

WANG Xinpu¹, ZHOU Xiangling², XING Jie², YANG Jun¹

(1. School of Electrical Engineering, Wuhan University, Wuhan 430072, China;

2. Operation Monitoring Center, Hubei Electric Power Company, Wuhan 430077, China)

Abstract: Photovoltaic (PV) power generation has the typical characteristics of intermittence and volatility. Therefore, it is of great importance to accurately predict solar output for optimization of power grid scheduling, power grid planning, and improving the competitiveness of the renewable energy power generation. Based on the modified grey back propagation (BP) neural network, this paper proposes a multi-model combination photovoltaic output power prediction method. The conventional grey model, the power function transformation grey model, the residual modification grey model and the equal-dimension-newly-information grey model are used and all single grey forecasting results are optimized combination by utilizing BP neural network. The combination weights are automatically adjusted according to the deviation of the output values and expected values. This method avoids the complex process of calculating weight coefficient. By integrating multiple single prediction results as the sample to train the BP neural network, it can finally obtain the optimal weights and accurate prediction results. The forecasting is realized based on real PV data of Hubei power grid. Example calculation demonstrates that the proposed method can significantly improve the prediction accuracy of photovoltaic output.

This work is supported by National Natural Science Foundation of China (No. 51277135 and No. 50707021).

Key words: BP neural network; combination weight; grey model; photovoltaic output power prediction; fuzzy c-means

0 引言

目前, 地球上的能源直接或间接都是来自太阳, 如水力、太阳辐射、风力等, 其中太阳能成

为取代化石能源的理想能源之一, 同时也是光伏发电系统中的清洁可再生的重要动力能源^[1]。光伏发电功率输出受环境影响较大, 大规模并网将会给整个电网带来较大的影响^[2]。因此, 为保证光伏系统并入后电网能继续稳定运行, 必须对光伏出力进行准确的预测。

目前, 对于光伏出力预测的研究工作已有一定

基金项目: 国家自然科学基金项目(51277135, 50707021);
湖北省电力公司科技项目资助

基础。单一的预测方法^[3-5]实现起来较为简单,如人工神经网络预测、卡尔曼滤波预测、马尔科夫链预测等,但其预测的准确性严重依赖于样本以及输入量的选取。将若干个单一预测方法进行组合,能够在不同角度上综合利用单个模型的有用信息,全面反映系统规律,以提高预测精度。文献[6]将神经网络和遗传算法(GA)进行组合,利用GA初始化神经网络的权值和阈值,提高了预测速度和精度。文献[7-8]利用组合预测的方法,先将原数据进行分解,对各个子序列进行优化预测,最后通过组合叠加获得较优预测结果。文献[9]利用灰色模型求解得到的微分方程结果作为马尔科夫链微分转移概率矩阵;同时为了提高预测精度,还给出了光伏出力预测值的范围及相应的概率。以上文献涉及到的组合方法大都能够获得优于单一预测的结果,提高预测精度;但组合预测的模型数量相对较少^[10],不能充分体现组合预测多角度、全方位反映系统规律的特点;而当组合模型较多时,利用数值方法精确求解系数将变得很复杂。

考虑到光伏出力与季节类型、天气类型、光照强度等多种气象因素有关,精确描述其系统规律较为困难。本文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,采用常规GM(1,1)模型、幂函数变换GM(1,1)模型、基于残差修正的GM(1,1)模型以及等维新息GM(1,1)四种模型^[11],利用BP神经网络对光伏出力的单一灰色预测结果进行优化组合输出,根据输出值和期望值偏差自动调整组合权值。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系数,避免了数值求解权系数的复杂过程,能够得到更为精确的预测结果。基于本文建立的预测模型可以对不同天气类型下一天各时段的出力进行预测。基于预测结果,制定微网储能装置出力计划,选择合适的电网运行方式,对光伏输出功率进行协调控制,保障微电网系统输出功率稳定,减少光伏出力不稳定对系统的影响。

1 预测样本选取

预测模型的样本选取关系到模型输出的精度^[12]。文献[13]分析得出影响光伏出力的主要气象因素包括太阳辐照度、大气温度、相对湿度、风速、天气类型等。考虑到太阳辐照度数据有时难以获取,本文主要选取日最高温度、日平均温度、日最低温度、日类型、日平均风速作为影响光伏出力的特征量,并利用模糊c-均值法进行样本分类。

1.1 模糊c-均值聚类

本文采用模糊c-均值方法^[14-15]进行光伏出力预测样本数据的选取,基于聚类准则建立目标函数,通过逐步迭代每次沿着目标函数减小的方向进行,最终实现模糊划分,具体算法流程如下:

(1) 选择 n 个研究对象的 m 个特征量,构造特征量矩阵,即论域 $\mathbf{X}=\{x_1, x_2, \dots, x_n\}$ 。

(2) 初始化模糊划分矩阵 U , 并确定分类数 c 。

$$U = \begin{bmatrix} u_{11} & \cdots & u_{1j} & \cdots & u_{1n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ u_{i1} & \cdots & u_{ij} & \cdots & u_{in} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ u_{c1} & \cdots & u_{cj} & \cdots & u_{cn} \end{bmatrix}$$

其中: c 为常数; $u_{ik} \in [0, 1]$ 且 $\sum_{i=1}^c u_{ik} = 1, \forall k$ 。

(3) 根据论域 \mathbf{X} 和模糊矩阵 U 计算聚类中心。

$$w_i^{(s)} = \frac{\sum_{k=1}^n (u_{ik}^{(s)})^g x_k}{\sum_{k=1}^n (u_{ik}^{(s)})^g}$$

其中: s 代表迭代次数; g 为模糊化程度常数,一般 g 在 $[0, 2]$ 之间。

(4) 修正模糊矩阵,并重新计算聚类中心, $W^{s+1} = [w_1^{s+1}, w_2^{s+1}, \dots, w_c^{s+1}]$, 模糊矩阵修正公式

$$u_{ik}^{(s+1)} = \left[\sum_{j=1}^c (L_{ik}^{(s)} / L_{jk}^{(s)})^{2/(g-1)} \right]^{-1}, \text{ 式中 } L_{ik} = \|x_k - w_i\|$$

表示样本与聚类中心的距离。

(5) 计算两个相邻目标函数 $|J^{s+1} - J^s|$ 的偏差,

且 $J(U, W) = \min \left\{ \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^g \|x_k - w_i\|^2 \right\}$ 。如果偏差

小于设定值或者迭代次数达到最大设定次数,结束迭代;否则返回第(3)步。

(6) 迭代完成后,可求得模糊划分矩阵,根据模糊划分矩阵对样本进行分类。

1.2 基于模糊c-均值光伏出力样本聚类

利用已知的气象信息,将各个因素进行量化并映射^[16]至 $[0, 1]$ 区间,并利用上述模糊c-均值方法进行聚类。

聚类分析得出结果后,利用式(1)计算各类聚类中心:

$$\bar{x}_{ik} = \frac{1}{h} \sum_{j=1}^h x_{jk}, k = 1, 2, \dots, m \quad (1)$$

根据预测日的天气预报信息,分别求取预测日与上述各类聚类中心的距离,取距离最小的作为预测日的类别^[14]。在确定预测日的类别后,进一步求

取该类每一个样本与预测日的相似度值, 并按从大到小排序, 在确定样本数后即可选择与预测日相似度最大的前 t 个历史样本数据进行预测。 t 为用来进行预测的历史数据样本个数。

2 灰色预测建模

灰色模型建模数据少, 能够利用分析系统因素间相互影响强度、相异程度来寻找系统变化规律^[17]。基于对原始数据的处理方式以及对预测结果的修正方式不同, 可以建立不同的 GM 模型。考虑到 BP 神经网络多用于输入量较多的复杂问题, 输入量太少不易发挥 BP 神经网络的函数逼近能力, 但输入量太多又会使得预测方法太过复杂, 不利于实际运用。因此本文选择如下 4 种预测模型。

2.1 灰色 GM(1, 1)模型

常规 GM(1, 1)模型较为简单, 通过对原始非负数据进行一阶累加处理, 弱化原始数据的随机性。记原始数列为

$$x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)\} \quad (2)$$

上标代表累加的次数, 则一阶累加生成序列为

$$x^{(1)} = \{x^{(1)}(1), x^{(1)}(2), x^{(1)}(3), \dots, x^{(1)}(n)\} \quad (3)$$

其中

$$\begin{cases} x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i) = x^{(1)}(k-1) + x^{(0)}(k) \\ k = 1, 2, \dots, n \end{cases} \quad (4)$$

对累加序列建立微分方程:

$$dx^{(1)}/dt + ax^{(1)} = u \quad (5)$$

根据最小二乘法, 求解发展系数 a 和灰作用量 u 。

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)), 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)), 1 \\ \dots \dots \dots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)), 1 \end{bmatrix} \quad (6)$$

$$Y_n = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad \begin{bmatrix} a \\ u \end{bmatrix} = (B^T B)^{-1} B^T Y_n \quad (7)$$

预测方程可表示为

$$\begin{cases} \hat{x}^{(0)}(k) = (1 - e^a)(x^{(0)}(1) - u/a)e^{-a(k-1)} \\ k = 2, 3, \dots \end{cases} \quad (8)$$

2.2 幂函数变换 GM(1,1)模型

GM(1,1)模型仅适用于原始数据序列非负、符合或基本符合指数规律变化且变化速度不是很快的

场合^[18]。为提高预测精度, 可以对原始数据取幂函数变换, 即新的序列为

$$x_{\text{new}}^{(0)} = \{b^{x^{(0)}(1)}, b^{x^{(0)}(2)}, b^{x^{(0)}(3)}, \dots, b^{x^{(0)}(n)}\} \quad (9)$$

其中, $b > 1$ 。对于上述数列, 在原始数据大于 0 的范围, 随着 $x^{(0)}(k)$ ($k=1, 2, 3, \dots, n$) 的一个微小变化, 指数函数值将产生较大变化, 因此要对原始数据先进行处理再进行幂函数变换。将原始灰序列映射到 $[-1, 0]$ 的区间:

$$x^{(0)}(i) = \frac{x^{(0)}(i) - \min(x^{(0)})}{\max(x^{(0)}) - \min(x^{(0)})} - 1 \quad (10)$$

经过归一化处理并进行幂函数变换后的灰序列, 可按照 2.1 节的方法进行灰色预测。其最后预测结果依式(11)进行还原:

$$\hat{x}^{(0)}(k) = (\log_b \{(1 - e^a)(b^{x^{(0)}(1)} - u/a)e^{-a(k-1)} + 1\} + 1) \cdot ((\max(x^{(0)}) - \min(x^{(0)})) + \min(x^{(0)})) \quad (11)$$

2.3 基于残差修正的 GM(1,1)模型

根据传统的 GM(1,1)方法求得预测序列后, 与真实值进行运算可得残差序列:

$$\varepsilon^{(0)} = \{\varepsilon^{(0)}(1), \varepsilon^{(0)}(2), \varepsilon^{(0)}(3), \dots, \varepsilon^{(0)}(n)\}$$

将残差序列进行正数化:

$$\varepsilon^{(0)' } = \text{abs}(\min\{\varepsilon^{(0)}(1), \varepsilon^{(0)}(2), \varepsilon^{(0)}(3), \dots, \varepsilon^{(0)}(n)\}) + \{\varepsilon^{(0)}(1), \varepsilon^{(0)}(2), \varepsilon^{(0)}(3), \dots, \varepsilon^{(0)}(n)\} + p \quad (12)$$

P 为一个正常数, 通过上式将残差序列转化为一个正数序列。

对灰色残差序列建立 GM(1,1)模型, 得到预测序列:

$$\hat{\varepsilon}^{(0)'}(k+1) = (1 - e^{a_2})[\varepsilon^{(0)'}(1) - u_2/a_2]e^{-a_2 k} \quad (13)$$

式中, a_2 和 u_2 分别为残差序列的 GM(1,1)参数。则修正模型预测算法为

$$\hat{x}^{(0)}(k+1) = (1 - e^a)(x^{(0)}(1) - u/a)e^{-a(k-1)} + (1 - e^{a_2})[\varepsilon^{(0)'}(1) - u_2/a_2]e^{-a_2 k} \quad (14)$$

2.4 等维新息 GM(1,1)模型

灰色预测的准确性建立在可靠的历史数据之上。离原点数据较近的点受历史数据影响较大, 变化趋势较为一致, 预测精度较高; 对于离原点数据较远的点, 随着时间推移将会出现新的随机因素, 使得预测值发生较大偏差。因此在建立预测模型过程中, 随时将进入系统的新信息置入 $x^{(0)}$ 中, 同时将旧信息删除, 通过新陈代谢过程保证预测精度。基于等维新息的 GM(1,1)模型通过不断更新数据同时维持模型维数不变来提高预测精度。

2.5 四种灰色模型组合

每种灰色模型都能够对系统光伏出力进行有效预测，且改进方法只能提高整体预测精度，即常规的预测方法可能在某些时刻的预测精度要高于改进预测方法。因此本文利用多种灰色模型，结合 BP 神经网络的优化组合能力进行光伏出力预测，充分发挥组合方法的优势。

3 基于改进灰色 BP 神经网络组合模型

BP 神经网络能够对多个输入量通过权值组合逼近期望输出，且不需要系统的模型，同时避免复杂的数值计算。因此本文将多种灰色模型预测得到的结果作为 BP 神经网络的输入信号，通过样本训练获得最优的神经网络权值，最后将预测日的预测值输入训练好的网络，得到最终的输出预测结果。

3.1 GM 模型的建立

灰色预测模型需要的数据较少，本文的光伏数据采用湖北某地光伏系统 2014 年 7 月至 12 月的光伏出力。原始数据为整天 24 h 的数据，5 min 一个测量点。考虑到每天 8 点到 18 点有光伏功率输出，取 11 个小时整点时刻的平均输出功率作为研究对象。本文选取 8 月 15 号作为预测日。根据历史光伏出力数据对应的气象信息，利用第 2 节的方法对数据进行分类。本文中分类数选为 5，同时用来预测的样本数也为 5，即 $t=5$ 。通过计算可以得出与预测日相似度最大的前 5 天的光伏出力如图 1 所示。

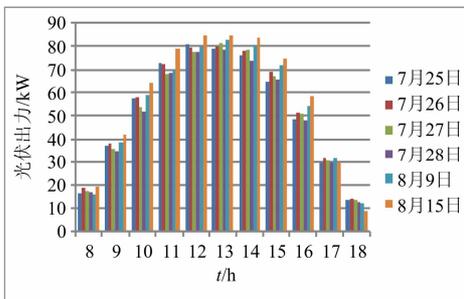


图 1 预测样本集
Fig. 1 Predicting samples

通过图 1 可以看出，所选样本出力曲线变化趋势大致相同，即利用模糊 c-均值聚类可以获得相似度较大的样本，能够有效地进行光伏出力预测。

3.2 预测模型的建立

在预测过程中，选择前 5 组数据作为训练样本，最后一组数据为测试样本。通过灰色预测方法分别求得 5 个训练样本和 1 个测试样本的预测值；将 5

个训练样本每天相同的整点时刻的 4 个预测值作为 BP 神经网络的输入，将对应的整点时刻的实际值作为期望输出进行训练。最后将预测日对应的整点时刻的预测值输入训练好的网络，得到最终的输出预测值。基于 BP 神经网络组合权重的 GM 光伏预测流程图如图 2 所示。

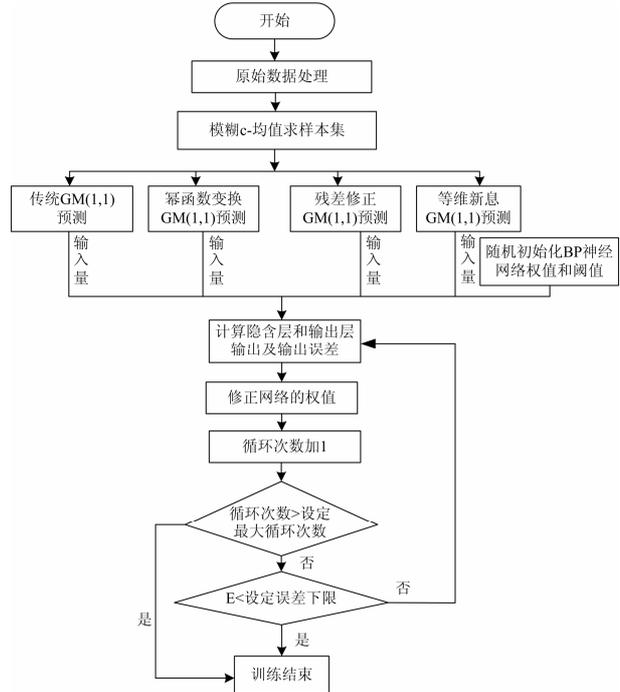


图 2 预测流程图

Fig. 2 Forecast flow chart

4 算例分析

通过以上分析，利用湖北某地光伏系统 2014 年实际历史光伏出力数据，在 Matlab 环境下进行算例验证，并对预测结果进行分析。

4.1 基于 BP 权重组合预测模型预测结果

通过第 3 节已求得与预测日相似度最大的样本序列，利用该样本序列建立 4 种灰色预测模型。前 3 种预测模型均以图 1 中前 5 日的的数据序列作为灰色模型的原始数据。基于等维新息的 GM(1,1)模型利用前 3 组的数据预测第 4 组的数据，再剔除第 1 组的数据；利用 2 到 4 组的数据预测第 5 组的数据，然后依此方法求解整个样本集的预测值。预测日的预测值如表 1 所示。

基于灰色模型得到样本集 6 天的预测数据序列，利用前 5 天的数据作为训练样本，8 月 15 日的的数据作为测试样本。基于 BP 神经网络组合权重的灰色预测结果列于表 1。图 3 为相应的预测日光伏出力曲线。

表 1 8 月 15 日光伏出力预测值
Table 1 Photovoltaic output forecast on August 15

时间	传统 GM(1,1)	幂函数变换 GM(1,1)	残差修正 GM(1,1)	等维新息 GM(1,1)	灰色 BP 神经网络组合	真实值
8:00	15.12	17.95	15.92	17.92	15.64	19.32
9:00	37.10	40.51	37.07	36.73	40.10	42.30
10:00	56.01	57.96	55.93	55.11	61.36	64.09
11:00	68.32	67.99	68.89	69.96	76.26	78.79
12:00	78.93	82.56	78.73	78.08	80.64	84.55
13:00	81.66	83.65	81.20	79.96	84.81	84.55
14:00	78.16	81.70	77.98	77.23	82.64	83.55
15:00	70.30	73.12	69.68	67.70	74.44	74.26
16:00	52.49	56.15	52.04	50.53	55.21	58.31
17:00	30.50	29.88	30.60	30.68	32.38	29.48
18:00	11.37	9.99	12.04	13.51	12.02	8.67

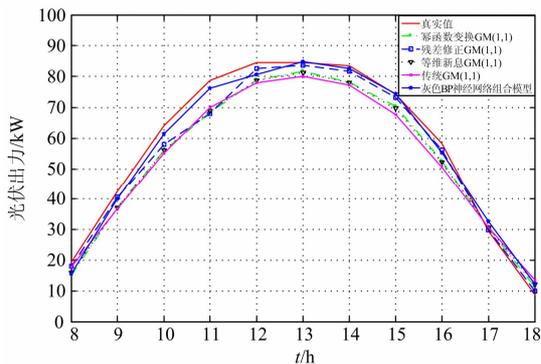


图 3 晴天光伏出力

Fig. 3 Photovoltaic output of sunny day

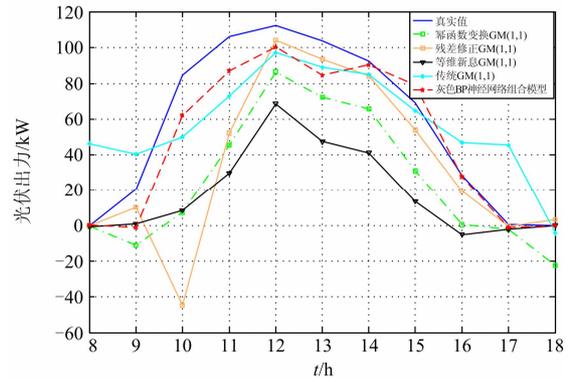


图 4 非聚类模式下光伏出力

Fig. 4 Photovoltaic output without classification

4.2 多种模式下 BP 权重组合预测模型分析

为验证上述方法的有效性, 本节考虑样本处理方式的变化、灰色模型数量的变化、以及天气类型的变化等三个方面, 对 BP 权重组合模型预测方法的有效性进行校验。

4.2.1 非聚类模式下 BP 权重组合模型预测分析

4.1 节在进行光伏出力预测分析前, 对数据样本进行分类。为分析样本聚类对预测精度的影响, 本节提取上述湖北某地光伏系统连续 7 天的数据进行分析, 图 4 为相应的光伏出力预测曲线。通过曲线图可以看出, 在不进行样本分类的情况下, 整体预测精度较差, 而本文提出的基于 BP 权重组合预测模型较其他灰色预测方法具有更高的准确度。表 2 列出非聚类情况下各种预测方法的均方根误差值。

4.2.2 变灰色模型模式下 BP 权重组合模型预测分析

4.1 节的预测分析以 4 种灰色模型作为 BP 神经网络的输入变量, 获得较高的预测精度。本节分别考虑两种灰色模型和三种灰色模型作为神经网络的输入时, 各种 BP 权重组合模型预测的有效性。

表 2 均方根误差

Table 2 RMS errors of models

	模型 1	模型 2	模型 3	模型 4	模型 5
聚类模型					
均方根误差(晴天)	5.61	3.99	5.66	6.20	2.66
聚类模型					
均方根误差(阴天)	21.97	14.33	11.64	11.03	7.09
非聚类模型					
均方根误差	42.95	37.89	26.54	46.71	13.37

利用 4.1 节相同的晴天数据, 两种灰色模型组合时, 两个灰色模型分别为幂函数变换 GM(1, 1)模型和等维新息 GM(1, 1)模型, 三种灰色模型组合时, 增加的灰色模型为传统 GM(1, 1)模型。图 5 为 3 种情况下相应的光伏出力预测曲线, 表 3 列出了 3 种情况下相应的均方根误差值。从表 3 可以看出, 在灰色模型数量变化时, BP 权重组合模型的预测精度变化不大; 当灰色模型数较多时, 预测精度

有一定的提高。综合分析可知, BP 模型输入层神经元过多, 能提高网络的识别率, 但同时也使网络结构复杂, 取样空间增加; 神经元过少, 一定程度上能简化网络结构, 缩短取样空间, 但又会使网络识别率降低^[19]。因此在确定 BP 神经网络输入层神经元数时, 需综合考虑网络结构复杂度和预测精度两方面的要求。

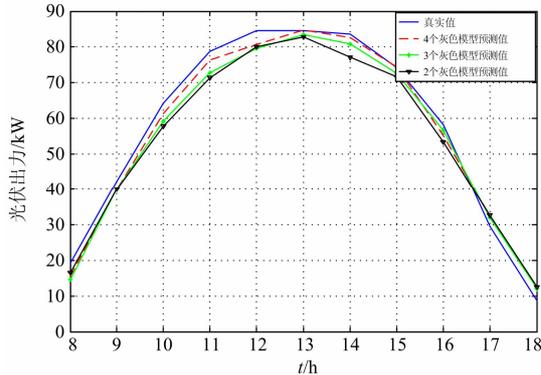


图 5 不同灰色模型组合时光伏出力
Fig. 5 Photovoltaic output with different combination of grey models

表 3 不同灰色模型组合时均方根误差

Table 3 RMS errors of combination for different grey models

	2 个灰色模型	3 个灰色模型	4 个灰色模型
均方根误差	4.58	3.61	2.66

4.2.3 阴天模式下 BP 权重组合模型预测分析

为验证 BP 权重组合预测模型在各种天气类型情况下均适用, 本节提取该光伏系统中阴天的数据进行光伏出力预测。

利用 4.1 节的方法, 对数据样本进行分类并分别利用灰色模型进行初步预测, 最后通过 BP 权重组合预测模型获得相应预测日的光伏出力, 结果如图 6 所示。基于 BP 权重组合预测模型能够获得较好的预测精度。各种预测方法的均方根误差列于表 2。

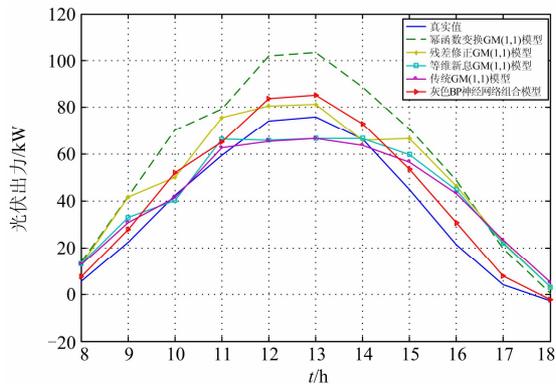


图 6 阴时光伏出力

Fig. 6 Photovoltaic output of overcast sky

4.3 结果分析

利用均方根误差对上述各种方法的综合预测效果进行比较分析。

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - \hat{P}_i)^2} \quad (15)$$

均方根误差计算结果如表 2 所示。各模型依次对应为模型 1: 幂函数变换 GM(1, 1)模型; 模型 2: 残差修正 GM(1, 1)模型; 模型 3: 等维新息 GM(1, 1)模型; 模型 4: 传统 GM(1, 1)模型; 模型 5: 基于改进灰色 BP 神经网络组合模型。可以看出模型 5-基于改进灰色 BP 神经网络组合模型的预测效果最好, 能够提高整体预测精度, 有实用价值。

5 结论

光伏发电受光照强度等因素的影响, 其输出功率不稳定, 会给电网规划、系统调度和电网的可靠、稳定运行带来诸多问题, 因此研究光伏发电功率预测具有重要意义。本文提出了一种基于改进灰色 BP 神经网络组合的光伏出力预测方法, 采用模糊 c-均值对历史光伏出力进行分类, 并选取与预测日相似度最大的历史数据作为样本; 在此基础上将多个单一灰色预测结果作为 BP 神经网络样本来训练神经网络, 进行非线性组合来逼近期望输出。该方法能够多方面、多角度获取系统规律, 充分发挥组合预测的优势, 避免了变权组合预测模型的主观与繁琐。以湖北某地光伏系统 2014 年实际历史光伏出力数据为样本进行了仿真计算, 计算结果表明该方法能够明显提高光伏出力预测精度, 具有一定实用价值。

参考文献

- [1] 姚致清, 张茜, 刘喜梅. 基于 PSCAD/EMTDC 的三相光伏并网发电系统仿真研究[J]. 电力系统保护与控制, 2010, 38(17): 76-81.
YAO Zhiqing, ZHANG Qian, LIU Ximei. Research on simulation of a three-phase grid-connected photovoltaic generation system based on PSCAD/EMTDC[J]. Power System Protection and Control, 2010, 38(17): 76-81.
- [2] 姚致清, 于飞, 赵倩, 等. 基于模块化多电平换流器的大型光伏并网系统仿真研究[J]. 中国电机工程学报, 2013, 33(36): 27-33.
YAO Zhiqing, YU Fei, ZHAO Qian, et al. Simulation research on large-scale PV grid-connected systems based on MMC[J]. Proceedings of the CSEE, 2013, 33(36): 27-33.
- [3] 孔波利, 崔丽艳, 丁钊, 等. 基于风光混合模型的短期功率预测方法研究[J]. 电力系统保护与控制, 2015, 43(18): 62-66.

- KONG Boli, CUI Liyan, DING Zhao, et al. Short term power prediction based on hybrid wind-PV forecasting model[J]. Power System Protection and Control, 2015, 43(18): 62-66.
- [4] 赵书强, 王明雨, 胡永强, 等. 基于不确定理论的光伏出力预测研究[J]. 电工技术学报, 2015, 30(16): 213-220.
- ZHAO Shuqiang, WANG Mingyu, HU Yongqiang, et al. Research on the prediction of PV output based on uncertainty theory[J]. Transactions of China Electrotechnical Society, 2015, 30(16): 213-220.
- [5] LI Y, NIU J. Forecast of power generation for grid-connected photovoltaic system based on Markov chain[C] // Power and Energy Engineering Conference, 2009. APPEEC 2009. Asia-Pacific. IEEE, 2009: 1-4.
- [6] 罗建春, 晁勤, 罗洪, 等. 基于 LVQ—GA-BP 神经网络光伏电站出力短期预测[J]. 电力系统保护与控制, 2014, 42(13): 89-94.
- LUO Jianchun, CHAO Qin, LUO Hong, et al. PV short-term output forecasting based on LVQ-GA-BP neural network[J]. Power System Protection and Control, 2014, 42(13): 89-94.
- [7] 田中大, 李树江, 王艳红, 等. 基于小波变换的风电场短期风速组合预测[J]. 电工技术学报, 2015, 30(9): 112-120.
- TIAN Zhongda, LI Shujiang, WANG Yanhong, et al. Short-term wind speed combined prediction for wind farms based on wavelet transform[J]. Transactions of China Electrotechnical Society, 2015, 30(9): 112-120.
- [8] 王贺, 胡志坚, 张翌晖, 等. 基于聚类经验模态分解和最小二乘支持向量机的短期风速组合预测[J]. 电工技术学报, 2014, 29(4): 237-245.
- WANG He, HU Zhijian, ZHANG Yihui, et al. A hybrid model for short-term wind speed forecasting based on ensemble empirical mode decomposition and least squares support vector machines[J]. Transactions of China Electrotechnical Society, 2014, 29(4): 237-245.
- [9] LI Yingzi, LUAN Ru, NIU Jincang. Forecast of power generation for grid-connected photovoltaic system based on grey model and Markov chain[C] // Industrial Electronics and Applications, 2008. ICIEA 2008. 3rd IEEE Conference on. IEEE, 2008: 1729-1733.
- [10] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测[J]. 电力系统自动化, 2012, 36(19): 37-41.
- WANG Shouxiang, ZHANG Na. A model to forecast short-term output power of photovoltaic system based on grey and neural network theory[J]. Automation of Electric Power Systems, 2012, 36(19): 37-41.
- [11] 牛东晓. 电力负荷预测技术及其应用[M]. 2 版. 北京: 中国电力出版社, 2009: 163-178.
- [12] 姜强鑫. 基于小波神经网络的分布式光伏发电出力预测[D]. 南昌: 南昌大学, 2012.
- [13] 代倩, 段善旭, 蔡涛, 等. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究[J]. 中国电机工程学报, 2011, 31(34): 28-35.
- DAI Qian, DUAN Shanxu, CAI Tao, et al. Short-term PV generation system forecasting model without irradiation based on weather type clustering[J]. Proceedings of the CSEE, 2011, 31(34): 28-35.
- [14] 白俊良, 梅华威. 改进相似度的模糊聚类算法在光伏阵列短期功率预测中的应用[J]. 电力系统保护与控制, 2014, 42(6): 84-90.
- BAI Junliang, MEI Huawei. Improved similarity based fuzzy clustering algorithm and its application in the PV array power short-term forecasting[J]. Power System Protection and Control, 2014, 42(6): 84-90.
- [15] 张园园, 龚庆武, 刘栋, 等. 基于改进 PSO-FCM 的暂态稳定机组分群方法[J]. 电网技术, 2011, 35(9): 92-98.
- ZHANG Yuanyuan, GONG Qingwu, LIU Dong, et al. A unit clustering approach used in transient stability analysis based on improved PSO-FCM algorithm[J]. Power System Technology, 2011, 35(9): 92-98.
- [16] 康重庆, 程旭. 一种规范化的处理相关因素的短期负荷预测新策略[J]. 电力系统自动化, 1999, 23(18): 32-35.
- KANG Chongqing, CHENG Xu. A new unified approach to short-term load forecasting considering correlated factors[J]. Automation of Electric Power Systems, 1999, 23(18): 32-35.
- [17] 翁小杰. 基于灰色理论和神经网络的预测方法研究与应用[D]. 长沙: 中南民族大学, 2009.
- [18] 吉培荣, 洪磊一. GM (1, 1) 模型建模的一种方法[J]. 天津理工学院学报, 1999, 15(3): 72-74.
- JI Peirong, HONG Leiyi. A modelling method for GM (1,1) model[J]. Journal of Tianjin Institute of Technology, 1999, 15(3): 72-74.
- [19] 郭江龙, 张树芳, 姚力强, 等. 汽轮机性能预测 BP 神经网络输入层神经元筛选方法[J]. 汽轮机技术, 2010, 52(2): 147-149.
- GUO Jianglong, ZHANG Shufang, YAO Liqiang, et al. A method for screening input nodes in BP artificial neural network on performance forecasting of steam turbine[J]. Turbine Technology, 2010, 52(2): 147-149.

收稿日期: 2015-09-19; 修回日期: 2015-12-16

作者简介:

王新普(1989-), 男, 通信作者, 硕士, 研究方向为电力系统自动化; E-mail: 2009301760033@whu.edu.cn

杨军(1977-), 男, 教授, 博士生导师, 研究方向为电力系统继电保护等。E-mail: jyang@whu.edu.cn

(编辑 葛艳娜)