

DOI: 10.7667/PSPC170035

计及光伏电站功率预测的电力系统优化分析

杨秋霞¹, 刘同心², 高辰¹, 李茂林³

(1. 燕山大学电气工程学院, 河北 秦皇岛 066000; 2. 华润电力(沧州运东)有限公司, 河北 沧州 061004;
3. 国网山东邹平县供电公司, 山东 滨州 256200)

摘要: 光伏功率预测多采用间接预测法, 由预测太阳辐照度数值结合光转电模型来预测光伏出力。为了解决传统BP算法在短期太阳辐照度预测中易陷入局部最优和收敛速度慢的问题, 引入了自适应调节学习率和陡度因子建立太阳辐照度预测模型。在双极性 Sigmoid 函数中加入陡度因子以提高BP算法的收敛速度, 为了便于数据处理将输入数据归一在[-1, 1], 同时引入自适应调节学习率以调整网络权值, 提高收敛性能。为了研究含光伏电站的电力系统优化问题, 建立了系统日综合成本最小和日废气排放量最少的双目标优化模型, 并采用双目标细菌群体趋药性算法进行优化。算例证明: 改进BP神经网络算法能有效地提高预测精度, 增强神经网络模型的泛化能力, 具有较好的实用性; 预测光伏出力能够统筹安排机组出力, 合理消纳光伏资源。

关键词: 太阳辐照度预测; 改进BP神经网络; 自适应调节学习率; 双目标优化; 预测值比较

Power system optimization analysis considering power prediction of PV power station

YANG Qiuxia¹, LIU Tongxin², GAO Chen¹, LI Maolin³

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066000, China; 2. China Resources Power (Cangzhou Yun Dong) Co., Ltd, Cangzhou 061004, China; 3. State Grid Zouping Power Supply Company, Binzhou 256200, China)

Abstract: The indirect prediction method is used to forecast the PV power, and the solar irradiance forecast is combined with the light-to-electric model to predict the PV output. In order to solve the shortcomings that the traditional BP algorithm in the short-term solar irradiance prediction is easy to fall into the local optimum and has slow convergence rate, the adaptive adjustment learning rate and the steepness factor are introduced to establish the solar irradiance prediction model. In the bipolar Sigmoid function, the steepness factor is added to improve the convergence speed of the BP algorithm, the normalized input data is limited to [-1, 1] to facilitate data processing, and the adaptive adjustment learning rate is introduced to adjust network weight and to improve convergence performance. In order to study the optimization of power system with PV power station, a double objective optimization model to minimize daily composite cost and daily waste gas emission of system is established. And the two-target bacterial population chemotaxis algorithm is used to optimize the system. Examples show that the improved BP neural network algorithm can effectively improve the prediction accuracy and enhance the generalization ability of the neural network model, and it has good practicability. Forecasting the PV output can arrange the unit output and rationally absorb the PV resources.

This work is supported by National Natural Science Foundation of China (No. 61573303) and Natural Science Foundation of Hebei Province (No. E2016203092).

Key words: solar irradiance prediction; improved BP neural network; adaptive adjustment learning rate; double objective optimization; predictive value comparison

0 引言

伴随着经济的快速发展和常规能源的日益枯竭, 人类开始开发利用太阳能资源^[1-2]。太阳能发电

具有绿色、环保以及无污染等优点, 越来越多的国家开始实施太阳能发展战略。随着光伏发电技术日趋成熟, 光伏系统世界总装机容量在逐年上升^[3-5]。光伏电站接入电力系统, 必然会改变系统机组出力状况, 进而影响系统的发电成本。准确预测光伏电站输出功率对电力系统的规划设计、开停机计划安排、电力系统安全运行以及提高经济效益等都具有

基金项目: 国家自然科学基金资助项目(61573303); 河北省自然科学基金资助项目(E2016203092)

重要意义^[6-10]。

文献[11]详细介绍了光伏功率预测技术,给出了光伏功率预测的方法和算法。文献[12]用遗传算法优化了BP神经网络的参数,在短期内提高了预测精度,但静态前馈神经网络容易陷入局部最优,且收敛速度慢。文献[13]建立了光伏出力的随机模型并对配电网进行无功优化,但其随机预测光伏出力值并未能真实预测光伏出力情况。文献[14]分析了不同运营模式下的光伏并网策略,给出了光伏并网的最优经济方案,有助于解决光伏并网的成本效益问题,但只考虑了成本效益问题,未涉及到环境保护问题。文献[15]考虑了分布式电源的随机性和模糊性等特征,建立了节能减排和投资费用最优的优化模型,达到了节能减排的目的,但粒子群算法容易陷入局部最优,效果可能不甚理想。文献[16]引入了碳交易机制理念,兼顾了电力系统运行的经济性、低碳性和可靠性,建立了考虑光伏电源和CO₂排放经济价值的优化调度模型,但其只考虑CO₂的排放问题,未考虑其他污染物的问题。

本文在太阳辐照度预测模型中加入了陡度因子和自适应调节速率,结合数据的归一化与反归一化处理建立太阳辐照度预测模型。该模型能够对网络数据进行尺度变化,自适应调整网络权值,提高网络收敛速度。进而结合光转电模型来预测光伏电站输出功率。最后对接入光伏电站的电力系统进行优化研究,在光伏电站输出功率已知的情况下,合理安排机组出力能够有效提高系统的经济效益。

1 光伏电站输出功率预测

1.1 BP神经网络模型

BP算法的学习过程由信号的正向传播与误差的反向传播组成。基本思想是:正向传播过程中,输入样本在输入层传入,经各隐层逐层处理后,传出到输出层。当输出层的实际输出与期望的输出不符时,转入误差的反向传播阶段。误差的反向传播是将输出误差以某种形式通过隐层向输入层逐层反传,并将误差分配给各层单元,从而获得各层单元的误差信号。此过程会循环进行到网络的输出误差减少到可接受的程度,或达到预先设定的学习次数为止。

BP神经网络模型如图1所示。在网络模型中,输入向量 $\mathbf{X}=(x_1, x_2, \dots, x_i, \dots, x_n)^T$;隐层输出向量 $\mathbf{Y}=(y_1, y_2, \dots, y_i, \dots, y_m)^T$;设置 $x_0 = -1$ 是为了引入隐层神经元的阈值, $y_0 = -1$ 同样是为了引入输出层神

经元阈值;输出层输出向量 $\mathbf{O}=(o_1, o_2, \dots, o_k, \dots, o_l)^T$;期望输出向量为 $\mathbf{d}=(d_1, d_2, \dots, d_k, \dots, d_l)^T$;输入层到隐层的权值矩阵 $\mathbf{V}=(V_1, V_2, \dots, V_j, \dots, V_m)$,其中 V_j 为隐层第 j 个神经元对应的权向量;隐层到输出层的权值矩阵 $\mathbf{W}=(W_1, W_2, \dots, W_k, \dots, W_l)$,其中列向量 W_k 为输出层第 k 个神经元对应的权向量。

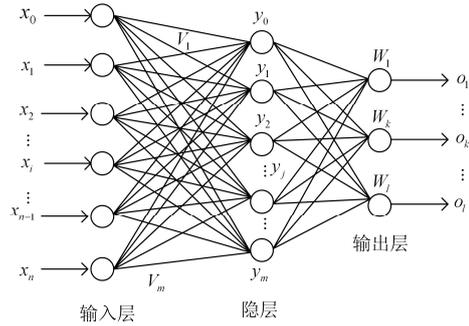


图1 BP神经网络结构图

Fig. 1 Structure diagram of BP neural network

各层信号之间具有如下的数学关系。对于输出层,有

$$\begin{cases} o_k = f(\text{net}_k) & (k=1, 2, \dots, l) \\ \text{net}_k = \sum_{j=0}^m w_{jk} y_j & (k=1, 2, \dots, l) \end{cases} \quad (1)$$

对于隐层,有

$$\begin{cases} y_j = f(\text{net}_j) & (j=1, 2, \dots, m) \\ \text{net}_j = \sum_{i=0}^n w_{ij} x_i & (j=1, 2, \dots, m) \end{cases} \quad (2)$$

转移函数 $f(x)$ 均为双极性Sigmoid函数。

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3)$$

如此,便构成了BP神经网络的数学模型。

1.2 BP神经网络学习算法

在BP神经网络中,当网络输出与期望输出不符时,会产生输出误差 E , E 定义如下:

$$E = \frac{1}{2} (d - o)^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 \quad (4)$$

将上述的误差定义式展开至隐层,有

$$E = \frac{1}{2} \sum_{k=1}^l [d_k - f(\text{net}_k)]^2 = \frac{1}{2} \sum_{k=1}^l \left[d_k - f\left(\sum_{j=0}^m w_{jk} y_j\right) \right]^2 \quad (5)$$

进一步展开至输入层,有

$$E = \frac{1}{2} \sum_{k=1}^l \left\{ d_k - f \left[\sum_{j=0}^m w_{jk} f(\text{net}_k) \right] \right\}^2 = \frac{1}{2} \sum_{k=1}^l \left\{ d_k - f \left[\sum_{j=0}^m w_{jk} f \left(\sum_{i=0}^n v_{ij} x_i \right) \right] \right\}^2 \quad (6)$$

通过上式可以观察到, 网络误差为各层权值 w_{jk} 和 v_{ij} 的函数, 故调整权值可改变误差 E 。显然, 调整权值的原则是使误差不断减小, 因此应使权值的调整量与误差的梯度下降成正比, 即

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} \quad (j=0, 1, 2, \dots, m; k=1, 2, \dots, l) \quad (7)$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} \quad (i=0, 1, 2, \dots, n; j=1, 2, \dots, m) \quad (8)$$

式中, 负号表示梯度下降, 常数 $\eta \in (0, 1)$ 表示比例系数, 在训练中反映了学习速率。

由上式可观测出, 学习速率的改变随着权值改变, 在训练过程中调整学习率的大小会改变权值进而影响网络系统的收敛性能, 为此, 本文在基本 BP 神经网络的基础上, 加入了自适应学习率的修正公式, 如式(9), 通过自适应修正学习率以提高网络的快速性和收敛性能。

$$\eta(q+1) = \begin{cases} 1.05\eta(q) & E(q+1) < E(q) \\ e^{-\xi}\eta(q) & E(q+1) \geq E(q) \end{cases} \quad (9)$$

式中: ξ 为常数, $0.001 \leq \xi \leq 0.01$; E 为网络训练值; q 为训练次数。

在双极性 Sigmoid 函数中加入了陡度因子 λ 来提高算法的收敛速度。对于输出向量 o_k , 有

$$o_k = \frac{1}{1 + e^{-\text{net}_k / \lambda}} \quad (10)$$

1.3 改进 BP 神经网络算法步骤

1) 初始化。对权值矩阵 W 、 V 赋随机数, 样本模式计数器 p 和训练次数计数 q 置为 1, 误差 E 置 0, 学习率 η 设为 $(0, 1]$ 内的小数, 网络训练后达到的精度 E_{\min} 设为一正的小数。

2) 归一化输入训练样本对, 计算各层输出。用下式归一化处理输入样本, 用样本 X^p 、 d^p 对向量数组 X 、 d 赋值, 计算 Y 和 O 中各分量。

$$x_{\text{mid}} = \frac{x_{\max} + x_{\min}}{2} \quad (11)$$

$$x^* = \frac{x_i - x_{\text{mid}}}{\frac{1}{2}(x_{\max} - x_{\min})} \quad (12)$$

式中: x_{mid} 为样本数据平均值; x_{\max} 为样本数据最大值; x_{\min} 为样本数据最小值; x^* 为样本数据归一

化值; x_i 为样本数值。

3) 计算网络输出误差。设网络共有 P 对训练样本, 采用均方根误差 $E_{\text{RME}} = \sqrt{\frac{1}{P} \sum_{p=1}^P (E^p)^2}$ 作为网络的总误差。

4) 计算各层误差信号。

$$\delta_k^o = (d_k - o_k) o_k (1 - o_k) \quad (13)$$

$$\delta_j^y = \left[\sum_{k=1}^l (d_k - o_k) f'(\text{net}_k) w_{jk} \right] f'(\text{net}_j) = \left(\left(\sum_{k=1}^l \delta_k^o w_{jk} \right) y_j (1 - y_j) \right) \quad (14)$$

5) 调整各层学习速率与权值。

$$\begin{cases} \Delta w_{jk} = \eta (d_k - o_k) o_k (1 - o_k) y_j \\ \Delta v_{ij} = \eta \left(\sum_{k=1}^l \delta_k^o w_{jk} \right) y_j (1 - y_j) x_i \end{cases} \quad (15)$$

计算 W 、 V 中各分量。

6) 所有样本是否完成一次轮训, 若 $p < P$, 计数器 p 、 q 增 1, 返回步骤 2), 否则转步骤 7)。

7) 检查网络总误差是否满足精度要求, 若满足, $E_{\text{RME}} < E_{\min}$, 训练结束, 否则 E 置 0, p 置 1, 返回步骤 2) 继续训练。

8) 反归一化数据处理, 输出预测样本数值。

1.4 光转电模型

通常情况下, 生产厂家会给出光伏电池在标准状况下的光伏电池短路电流、开路电压、最大功率点电流和最大功率点电压这 4 个参数。随着外界温度和辐射强度的变化, 可得到最大功率点处电流 I_{\max} 与电压 U_{\max} 的关系为

$$I_{\max} = I_m \frac{S}{S_{\text{ref}}} (1 + a\Delta T) \quad (16)$$

$$U_{\max} = U_m (1 - c\Delta T) \ln(e + b\Delta S) \quad (17)$$

式中: I_m 为标况下最大功率点电流, A; U_m 为标况下最大功率点电压, V; 系数 a 、 b 、 c 一般取典型值, $a=0.0025/^\circ\text{C}$, $b=0.5/(\text{W}/\text{m}^2)$, $c=0.00288/^\circ\text{C}$;

$\Delta S = \frac{S}{S_{\text{ref}}} - 1$; $\Delta T = T - T_{\text{ref}}$; S 为外界辐射强度, W/m^2 ; T 为外界温度, $^\circ\text{C}$; S_{ref} 为标况下外界辐射强度, 一般取 $1000 \text{ W}/\text{m}^2$; T_{ref} 为标况下外界温度, 一般取 $25 \text{ }^\circ\text{C}$ 。

光伏电池只能发出直流电, 只有通过逆变器将直流电转化为交流电才可并入电网, 考虑到光伏逆变器效率等因素, 光伏电站的有效输出功率可表示为

$$P_{\text{PV}} = \eta_1 \eta_2 \eta_3 \eta_4 N_{\text{PV}} P^* \quad (18)$$

$$P^* = U_m I_m \frac{S}{S_{ref}} (1 + a\Delta T)(1 - c\Delta T) \ln(e + b\Delta S) \quad (19)$$

式中: η_1 为光伏电池长期运行性能衰减系数, 取 0.8; η_2 为逆变器效率, 取 0.85; η_3 为光伏电池表面覆尘及温升造成出力下降的修正系数, 取 0.82; η_4 为光伏系统内部线损系数, 取 0.95; N_{PV} 为系统中光伏电池数量; P^* 为光伏电池的输出功率, W。

本文采用光伏功率预测的间接短期预测法, 即通过对太阳辐照度的预测, 结合预测日温度与光伏电池相关参数, 将数值代入上述光转电模型公式, 即可预测出某日光伏电站的输出功率。

2 含光伏电站的电力系统优化

在保证系统可靠运行与节能减排的前提下, 本文提出了以系统日综合发电成本最小和日废气排放量最少为目标函数的双目标优化方案。

2.1 双目标函数

目标函数 1: 系统日综合发电成本 F_T 最小

$$\min F_T = \min(F_F + F_{PV} - F_S) \quad (20)$$

F_F 为火电机组日发电成本, 元。

$$F_F = \sum_{t=1}^T \left(\sum_{i=1}^N a_i + b_i P_i^t + c_i (P_i^t)^2 \right) \quad (21)$$

F_{PV} 为光伏电站日投资运行成本, 元。

$$F_{PV} = \frac{F_C + F_R}{z \times 365} = \frac{N_{PV} C_{PV} + F_R}{z \times 365} \quad (22)$$

F_S 为每日因光伏发电而节约的燃煤成本, 元。

$$F_S = R \sum_{t=1}^T \left(\sum_{j=1}^{N_{PV}^*} P_{PV,j}^t \right) \quad (23)$$

式中: N 为火电机组数量; T 为机组日运行时间, h; a_i 、 b_i 、 c_i 为机组 i 的耗量特性参数, 元/h、元/MW·h、元·(MW)²h⁻¹; P_i^t 为 t 时刻机组 i 的发电量, MW; F_C 为光伏电站投资成本, 元; F_R 为光伏电站运行维护成本, 元, 取投资成本的 8%; N_{PV} 为光伏电池数量; C_{PV} 为单个光伏电池组件单价, 元; z 为光伏电池的工程年限, 取为 20; R 为因光伏发电而节约的单位环境成本, 取 1.23 元/kW·h; $P_{PV,j}^t$ 为 t 时刻光伏电站 j 的输出功率, MW; N_{PV}^* 为光伏电站数量。

目标函数 2: 日废气排放量 T 最小。

$$\min T = \min(T_{CO_2} + T_{SO_2} + T_{NO_x}) \quad (24)$$

$$T_{CO_2} = \sum_{t=1}^T \left(\sum_{i=1}^N \alpha_{Ci} + \beta_{Ci} P_i^t + \gamma_{Ci} (P_i^t)^2 \right) \quad (25)$$

$$T_{SO_2} = \sum_{t=1}^T \left(\sum_{i=1}^N \alpha_{Si} + \beta_{Si} P_i^t + \gamma_{Si} (P_i^t)^2 \right) \quad (26)$$

$$T_{NO_x} = \sum_{t=1}^T \left(\sum_{i=1}^N \alpha_{Ni} + \beta_{Ni} P_i^t + \gamma_{Ni} (P_i^t)^2 \right) \quad (27)$$

式中: T_{CO_2} 、 T_{SO_2} 、 T_{NO_x} 分别为 CO₂、SO₂ 与 NO_x 的排放量, kg; α_{Ci} 、 β_{Ci} 、 γ_{Ci} 为机组 i 的 CO₂ 排放函数系数, kg/h、kg/MW·h、kg·(MW)²h⁻¹; α_{Si} 、 β_{Si} 、 γ_{Si} 为机组 i 的 SO₂ 排放函数系数, kg/h、kg/MW·h、kg·(MW)²h⁻¹; α_{Ni} 、 β_{Ni} 、 γ_{Ni} 为机组 i 的 NO_x 排放函数系数, kg/h、kg/MW·h、kg·(MW)²h⁻¹。

2.2 双目标优化约束

1) 系统功率平衡约束

$$\sum_{i=1}^N P_i^t + \sum_{j=1}^{N_{PV}} P_{PV,j}^t = P_L^t \quad (28)$$

式中, P_L^t 为 t 时刻的负荷出力, MW。

2) 火电机组出力上下限约束

$$P_{i,\min} \leq P_i \leq P_{i,\max} \quad (29)$$

式中, $P_{i,\max}$ 、 $P_{i,\min}$ 为机组 i 出力的上下限值, MW。

3) 光伏电站出力约束

$$0 \leq P_{PV,j}^t \leq P_{PV,j} \quad (30)$$

式中, $P_{PV,j}$ 为光伏电站 j 的额定功率, MW。

4) 旋转备用容量约束

$$\sum_{i=1}^N P_{i,\max} + P_{PV,j} \geq P_L^t (1 + L\%) \quad (31)$$

式中, $L\%$ 为系统负荷的旋转备用率。

5) 爬坡率约束

$$\begin{cases} -R_{D,i} \leq P_i^t - P_i^{t-1} \leq R_{U,i} & P_{i,t-1} \geq P_{i,\min} \\ R_{O,i} \leq |P_i^t - P_i^{t-1}| \leq R_{C,i} & 0 < P_{i,t-1} < P_{i,\min} \end{cases} \quad (32)$$

式中: $R_{D,i}$ 、 $R_{U,i}$ 分别为机组 i 的下坡率下限和上坡率上限; $R_{O,i}$ 、 $R_{C,i}$ 分别为机组 i 在开启和关闭过程中的上、下坡限制。

3 光伏电站在电力系统中的优化调度

取某地区太阳辐照度记录数值为改进 BP 神经网络的样本数据, 在网络中, 时间、温度、湿度、天气状况和季节为输入量, 太阳辐照度为输出量, 预测某日的太阳辐照度, 并与实际值进行对比, 预测结果如表 1 所示。

从表 1 可以看出, 相较于基本 BP 算法, 改进 BP 算法预测绝对误差百分数 11.1% 要更小一些, 其预测结果与实际值更为接近。在日出日落时段, 因

气象因素变化较大, 改进 BP 算法计算结果误差偏大。但是, 其余时刻预测误差均符合 20% 以内的工程要求, 与实际值较贴合, 可见, 该改进算法能够运用于太阳辐照度预测, 且预测精度较高, 满足工程要求。

表 1 太阳辐照度预测结果对比

Table 1 Comparison of prediction results of solar irradiance

时刻	W/m ²				
	太阳辐照度实际数值	改进 BP 算法预测值	基本 BP 算法预测值	改进 BP 算法预测误差	基本 BP 算法预测误差
7:00	52.32	12.25	51.79	-76.57%	-1.01%
8:00	237.21	195.08	307.66	-17.76%	29.70%
9:00	587.37	556.81	885.82	-5.20%	50.81%
10:00	846.28	817.61	758.85	-3.39%	-10.33%
11:00	1075.93	1094.86	1060.73	1.76%	-1.41%
12:00	1172.92	1163.69	1104.76	-0.79%	-5.81%
13:00	1242.73	1251.35	1177.07	0.69%	-5.28%
14:00	1177.45	1174.31	1183.56	-0.27%	0.52%
15:00	1109.72	1135.26	1101.76	2.30%	-0.72%
16:00	975.2	1001.42	919.37	2.69%	-5.72%
17:00	445.92	376.37	476.14	-15.60%	6.78%
18:00	35.83	24.32	90.15	-32.10%	151.62%
19:00	0	0	0	0	0
平均绝对误差百分数	—	—	—	11.1%	16.1%

一般条件下, 光伏电池生产厂家会提供光伏电池的相关参数, 具体参数情况如表 2 所示。

表 2 光伏电池参数

Table 2 Photovoltaic cell parameters

参数名称	数值
输出功率/W	200
工作电压/V	36
工作电流/A	5.5
开路电压/V	43.5
短路电流/A	5.56
工作温度范围/℃	-40~+85
单价/元	828

由第 2 节的光转电模型, 结合表 1 预测的太阳辐照度数值以及测试日温度数值与表 2 中光伏电池参数, 可计算出装机容量为 17 MW 的光伏电站所需的光伏电池数量, 进而可根据式(18)和式(19)计算出光伏电站的出力数值。本文比较了 1.4 节光转电模型计算数值、常规光伏电站随机出力模型^[11]计算数值和光伏电站的实际输出数值三者的大小, 关系曲线图如图 2 所示。

从图 2 可以看出, 文中所提光转电模型的预测

数值与实际数值更为接近, 且预测曲线较为平滑, 预测效果较为理想。通过计算可得, 光转电模型的绝对误差百分数为 12.67%, 常规随机出力模型的绝对误差百分数为 22.4%, 光转电模型的绝对误差百分数 12.67% 小于常规随机出力模型的 22.4%, 光转电模型的误差百分数要更低一些, 光转电模型的预测数值与实际值更为贴近。可以得知, 该光伏预测方法能够有效提高光伏电站的预测精度, 此方法具有一定的可行性与实用性, 适用于光伏电站的功率预测。

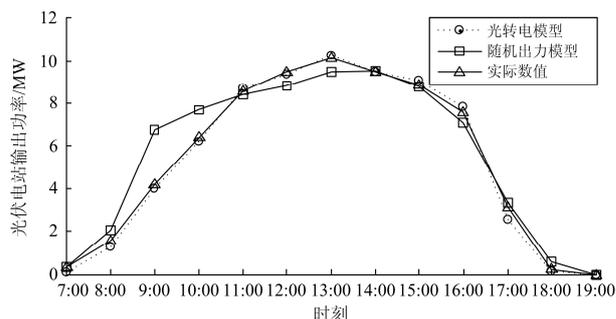


图 2 光伏电站输出功率值比较

Fig. 2 Comparison of output power values of photovoltaic power plants

本文对某地区的电力系统进行双目标优化调度研究。该系统由 4 台火电机组和 2 个光伏电站组成, 火电机组装机容量分别为 80 MW、85 MW 和 2 个 50 MW, 光伏电站的单个装机容量为 17 MW, 具体火电机组参数参见文献[17]。以 13:00 处为例, 结合 2.1 节的目标函数及 2.2 节的约束条件, 应用双目标细菌群体趋药性 (Mult-objective Bacterial Colony Chemotaxis, MOBCC) 算法对不同光伏出力预测值下的电力系统进行优化分析, 计算结果如表 3 所示。

表 3 优化结果对比

Table 3 Comparison of optimization results

	改进 BP 算法预测计算	随机出力模型计算	不预测 (取某一数值)	实际情况
光伏总出力/MW	20.4279	18.9738	19.5	20.2578
目标一/元	40 643	42 658	41 922	40 945
目标二/kg	4934.3	4958.1	4947.6	4938.0
光伏出力误差/%	0.84	-6.34	-3.74	—
目标一误差/%	-0.74%	4.18	2.38	—
目标二误差/%	-0.075	0.41	0.19	—

从表 3 可知, 文中所提模型计算光伏功率精度较高, 出力与目标函数值的计算误差均在 1% 以内, 低于其他情况下的误差百分数。在文中光伏功率的

预测下，系统综合发电成本和废气排放量均低于其他情况计算值，能够得到最优控制。对光伏电站输出功率进行预测，可在一定程度上节约系统综合成本，减少废气排放量，起到节能减排的作用。文中所提光伏电站输出功率预测方法能够准确预测光伏电站出力，满足工程要求。在该日光伏电站输出功率预测的基础上对系统进行 24 h 优化调度，机组出力与负荷出力情况如图 3 所示。

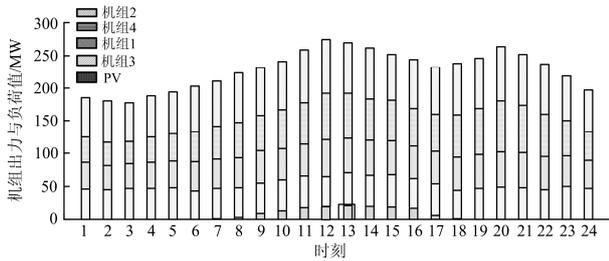


图 3 机组出力与负荷值

Fig. 3 Unit output and load value

由图 3 可以直观地看出 24 时刻各机组的出力与负荷值情况。对电力系统中的光伏电站输出功率进行预测，能够合理安排机组出力，节约煤炭资源，减少废气排放，提高经济效益，做到真正意义上的节能减排。

4 结论

本文提出了一种光伏电站输出功率的间接短期预测方法，并在此基础上对含光伏电站的电力系统进行了优化调度。在对太阳辐照度预测的改进 BP 神经网络算法中加入的调整因子能够提高算法的收敛性能，避免陷入局部最优。文中采用改进 MOBCC 算法对含光伏电站的电力系统进行优化分析，结果验证了对光伏电站的输出功率进行预测的必要性，同时也验证了文中所提光伏功率预测模型的准确性。总的来说，对光伏电站的输出功率进行预测并调度机组出力符合国家减排政策要求，有利于未来电力系统的可持续发展。

参考文献

[1] 杨秋霞, 姜培培, 刘同心, 等. 含光伏电源配电网的复合序网自适应保护[J]. 电力系统保护与控制, 2016, 44(18): 24-30.
 YANG Qiuxia, JIANG Peipei, LIU Tongxin, et al. Photovoltaic power distribution network in composite sequence network adaptive protection[J]. Power System Protection and Control, 2016, 44(18): 24-30.

[2] 杨秋霞, 李坤, 王虎, 等. PDFI 控制下单相光伏并网逆变器的混合阻尼控制策略[J]. 电力系统保护与控制,

2016, 44(16): 22-27.

YANG Qiuxia, LI Kun, WANG Hu, et al. Hybrid damping strategy for single-phase grid-connected PV inverter under the control of PDFI[J]. Power System Protection and Control, 2016, 44(16): 22-27.

[3] FENG Lin, ZHANG Jingning, LI Guojie, et al. Cost reduction of a hybrid energy storage system considering correlation between wind and PV power[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 86-94. DOI 10.1186/s41601-016-0021-1.

[4] YANG H T, LIAO J T. MF-APSO-based multiobjective optimization for PV system reactive power regulation[J]. IEEE Transactions on Sustainable Energy, 2015, 6(4): 1346-1355.

[5] 杨秋霞, 刘大鹏, 王海臣, 等. 光伏并网发电与电能质量调节统一控制系统[J]. 电力系统保护与控制, 2015, 43(5): 69-74.
 YANG Qiuxia, LIU Dapeng, WANG Haichen, et al. A combined control approach for grid-connected photovoltaic and power quality regulatory systems[J]. Power System Protection and Control, 2015, 43(5): 69-74.

[6] 彭春华, 谢鹏, 陈臣. 大规模光伏电站接入电网可调节鲁棒优化调度[J]. 中国电机工程学报, 2014, 34(25): 4324-4332.
 PENG Chunhua, XIE Peng, CHEN Chen. Adjustable robust optimal dispatch of power system with large-scale photovoltaic power stations[J]. Proceedings of the CSEE, 2014, 34(25): 4324-4332.

[7] 张璐, 唐巍, 丛鹏伟, 等. 含光伏发电的配电网有功无功资源综合优化配置[J]. 中国电机工程学报, 2014, 34(31): 5525-5533.
 ZHANG Lu, TANG Wei, CONG Pengwei, et al. Optimal configuration of active-reactive power sources in distribution network with photovoltaic generation[J]. Proceedings of the CSEE, 2014, 34(31): 5525-5533.

[8] 张丽, 徐玉琴, 王增平, 等. 包含分布式电源的配电网无功优化[J]. 电工技术学报, 2011, 26(3): 168-174.
 ZHANG Li, XU Yuqin, WANG Zengping, et al. Reactive power optimization for distribution system with distributed generators[J]. Transactions of China Electrotechnical Society, 2011, 26(3): 168-174.

[9] 高海东, 高林, 樊皓亮, 等. 火电机组实现智能优化控制技术[J]. 热力发电, 2017, 46(12): 1-5.
 GAO Haidong, GAO Lin, FAN Haoliang, et al. Discussions on practical intelligent optimization control technologies for thermal power units[J]. Thermal Power Generation, 2017, 46(12): 1-5.

[10] 赵越, 蒙毅, 李仁义. 基于粒子群优化算法分析约束条件对配煤最优价格的影响[J]. 热力发电, 2017,

- 46(12): 99-104.
ZHAO Yue, MENG Yi, LI Renyi. Influence of constraints on optimal price of blending coal: by particle swarm optimization algorithm[J]. Thermal Power Generation, 2017, 46(12): 99-104.
- [11] 龚英飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(4): 140-149.
GONG Yingfei, LU Zongxiang, QIAO Ying, et al. Photovoltaic power prediction technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140-149.
- [12] 庞清乐. 基于粗糙集理论的神经网络预测算法及其在短期负荷预测中的应用[J]. 电网技术, 2010, 34(12): 165-173.
PANG Qingle. A rough set-based neural network load forecasting algorithm and its application in short-term load forecasting[J]. Power System Technology, 2010, 34(12): 165-173.
- [13] 郭康, 徐玉琴, 张丽, 等. 计及光伏电站随机出力的配电网无功优化[J]. 电力系统保护与控制, 2012, 40(10): 53-58.
GUO Kang, XU Yuqin, ZHANG Li, et al. Reactive power optimization of distribution network considering PV station random output[J]. Power System Protection and Control, 2012, 40(10): 53-58.
- [14] 苏剑, 周莉梅, 李蕊. 分布式光伏发电并网的成本/效益分析[J]. 中国电机工程学报, 2013, 33(34): 50-56.
SU Jian, ZHOU Limei, LI Rui. Cost-benefit analysis of distributed grid-connected photovoltaic power generation[J]. Proceedings of the CSEE, 2013, 33(34): 50-56.
- [15] 袁越, 曹阳, 傅质馨, 等. 微电网的节能减排效益评估及其运行优化[J]. 电网技术, 2012, 36(8): 12-18.
YUAN Yue, CAO Yang, FU Zhixin, et al. Assessment on energy-saving and emission reduction benefit of microgrid and its operation optimization[J]. Power System Technology, 2012, 36(8): 12-18.
- [16] 娄素华, 胡斌, 吴耀武, 等. 碳交易环境下含大规模光伏电源的电力系统优化调度[J]. 电力系统自动化, 2014, 38(17): 91-96.
LOU Suhua, HU Bin, WU Yaowu, et al. Optimal dispatch of power system integrated with large-scale photovoltaic generation under carbon trading environment[J]. Automation of Electric Power Systems, 2014, 38(17): 91-96.
- [17] 张晓花, 赵晋泉, 陈星莺. 节能减排多目标机组组合问题的模糊建模及优化[J]. 中国电机工程学报, 2010, 30(22): 71-76.
ZHANG Xiaohua, ZHAO Jinquan, CHEN Xingying. Multi-objective unit commitment fuzzy modeling and optimization for energy-saving and emission reduction[J]. Proceedings of the CSEE, 2010, 30(22): 71-76.

收稿日期: 2017-01-06; 修回日期: 2017-08-25

作者简介:

杨秋霞(1972—), 女, 博士, 副教授, 主要研究方向为光伏发电及并网控制、电力系统保护与控制; E-mail: yangqx_fly@163.com

刘同心(1991—), 女, 通信作者, 硕士研究生, 主要研究方向为含光伏系统的配电网潮流计算、优化规划; E-mail: 18713513294@163.com

高辰(1992—), 女, 硕士研究生, 主要研究方向为微电网的经济运行调度。

(编辑 魏小丽)