

基于 ACO-BP 神经网络的光伏系统发电功率预测

陈智雨,陆金桂

(南京工业大学 机械与动力工程学院,江苏 南京 211816)

摘要:为准确预测光伏发电量,减少并网光伏对大电网的影响,引入相似日概念,对夏季预测日的平均温度、最高温度、最低温度以及天气类型进行分析。在历史数据中选取具有相似天气特征的发电功率数据和天气数据作为神经网络的训练样本,建立 ACO-BP 神经网络光伏发电功率预测模型,并将预测结果与传统 BP 神经网络和 PSO-BP 神经网络预测结果相比较。实验结果表明,该模型具有较高的预测精度。

关键词:光伏发电系统;光伏发电功率预测;神经网络;蚁群优化

中图分类号:TM615 **文献标志码:**A **文章编号:**1671-5276(2020)01-0173-03

Photovoltaic System Generating Efficiency Forecasting Based on ACO-BP Neural Network

CHEN Zhiyu, LU Jingui

(School of Mechanical and Power Engineering, Nanjing University of Technology, Nanjing 211816, China)

Abstract: To accurately predict photovoltaic power generation and reduce the impact of grid-connected photovoltaic on the large power grid, this paper introduces the concept of similar day, analyzes average, maximum and minimum temperature and weather type of summer forecast day, and selects the power generation data and the weather data with similar weather characteristics as training samples of neural network from the historical data. Based on the analysis of the characteristics of the photovoltaic power generation and its affecting factors, an ACO-BP neural network photovoltaic power prediction model is established, and the prediction results are compared with the traditional BP neural network and PSO-BP neural network prediction results. Experimental results show that the model is of high prediction accuracy.

Keywords: photovoltaic power generation system; photovoltaic generating efficiency forecasting; neural network; ant colony optimization

0 引言

光伏发电系统的出力具有不确定性和不连续性^[1],其受到很多因素的影响,如太阳光照强度、光伏阵列的转换效率、安装角度、温度以及其他一些因素都会对光伏阵列的输出特性产生影响。随着光伏发电容量越来越大,为了减少并网光伏对电网的冲击,对其发电量进行预测,可以提高电网的稳定性和安全性^[2-3]。

常用的预测方法有时间序列法、支持向量机、神经网络、马尔可夫链等^[4]。目前常用的方法大多采用 BP 神经网络对光伏发电进行预测,但单纯的 BP 算法易陷入局部最优,无法获得最优解。本文引入相似日概念,采用 ACO-BP 算法对光伏发电功率建立神经网络模型,进行光伏发电功率预测。

1 光伏系统

对于具体的光伏发电系统来说,其所有的历史数据都来源于同一个发电系统,所以它发电功率的历史时间序列具有高度的自相关性^[5]。因此,如果利用历史数据来预测发电功率会使得到的数据更加准确。

研究以某大学浦江宿舍光伏发电系统为例,总容量为 100 kW,发电供浦江宿舍片区 38 盏(60 W/盏) LED 路灯

照明和太阳能-空气源热泵热水系统用电设备使用。

2 相似日搜索和训练样本的确定

首先确定预测日的天气类型、日最高温度、日最低温度以及日平均温度,在历史数据中筛选出和预测日相同天气条件的历史记录,形成样本集 A。计算预测日和样本集 A 中历史记录的最高温度、最低温度和日平均温度的欧式距离 d_k, d_k 的计算公式见式(1)。

$$d_k = \left[\sum_{j=1}^3 (Y_j - X_{kj})^2 \right]^{\frac{1}{2}}, k = 1, 2, \dots, n \quad (1)$$

式中: Y_1, Y_2, Y_3 分别为预测日的最高温度、最低温度和日平均温度; X_{k1}, X_{k2}, X_{k3} 分别为样本集 A 中第 k 条历史记录的最高温度、最低温度和日平均温度。将欧氏距离集 $\{d_1, d_2, \dots, d_n\}$ 按照值的大小升序排序,将排序的欧氏距离前 $k(1 < k \leq n)$ 个日期的历史记录生成训练样本 B,对神经网络进行训练。

3 ACO-BP 算法

传统的 BP 神经网络训练采用的是误差反向传播学习算法,它的优化目标函数相对复杂,较容易出现陷入局部最优、收敛速度慢等问题^[6]。由于 BP 神经网络的训练算法实质上是对网络权值和阈值进行迭代调整,因此用

蚁群优化算法替代BP算法完成对神经网络权阈值的迭代调整,并最终完成神经网络的训练。

a) ACO-BP 算法基本思路

蚁群算法解决优化问题的基本思路为:用蚂蚁的行走路径表示待优化问题的可行解,整个蚂蚁群体的所有路径构成待优化问题的解空间。路径较短的蚂蚁释放较多的信息素。经过一定时间,信息素浓度在较短的路径上累积较高,所有选择此路径的蚂蚁也逐渐增多,最终,整个蚁群会在正反馈的作用下集中在最佳路径上,此时对应的便是待优化问题的最优解。

首先根据权值和阈值的取值范围,将值的定义域划分成 S 个等长区间,即每个区间的长度被作 S 等分,将区间的临界值或选择区间中的随机值作为候选值。确定参数个数 n ,包括网络中所有的权阈值。每个参数 $P_i (i=1,2,\dots,n)$ 对应一个有 S 个元素的集合 I_{P_i} ,这些元素为 P_i 的可能取值。

b) 具体步骤

1) 参数初始化:将所有权值和阈值进行 S 等分,所有区间初始信息素 0,信息素残留系数 λ ,信息素浓度 Q ,当前区间信息表为 Tabu,最大迭代次数 C ,网络全局误差 E ,最大学习次数 N ;

2) 权值和阈值选择:蚁群 m 只蚂蚁,对于蚂蚁 k 依据概率公式(2)的寻路规则进行选择节点所在区间,蚁群迭代一次则完成一次解的构造:

$$P[\tau_j^k(I_{P_i})] = \frac{\tau_j(I_{P_i})}{\sum_{j=1}^S \tau_j(I_{P_i})} \quad (2)$$

式中 $\tau_j(I_{P_i})$ 为集合 I_{P_i} 中第 j 个元素的信息素值;

3) 蚁群寻优判断:蚁群迭代一次得到的构造解,则是当前迭代后得到误差最小的一组解,计算误差 E_c ,判断是否达到蚁群要求,若是则转到 4),否则转到 5);

4) 网络训练:将蚁群迭代得到的最优构造解,作为初始权值和阈值,选取数据集对网络进行训练,直到满足结束条件即最大学习次数,完成学习。否则,继续学习;

5) 更新信息素:根据式(3)、式(4)、式(5)对所有区间信息素全局更新,并重置信息表:

$$\tau_j(I_{P_i})(t+h) = \rho\tau_j(I_{P_i})(t) + \Delta\tau_j(I_{P_i}) \quad (3)$$

$$\Delta\tau_j(I_{P_i}) = \sum_{k=1}^m \Delta\tau_j^k(I_{P_i}) \quad (4)$$

$$\Delta\tau_j^k(I_{P_i}) = \begin{cases} Q/e^k, & \text{第 } i \text{ 只蚂蚁选择元素 } P_j(I_{P_i}) \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中: Q 为信息素固定值; e^k 为第 k 只蚂蚁对应的神经网络输出误差;

6) 蚁群遍历:重复步骤 2) 到步骤 3)。

其算法如图 1 所示。

4 ACO-BP 预测模型设计

4.1 BP 神经网络

人工神经网络(artificial neural network, ANN)被视为预测太阳辐射强度和光伏发电系统输出功率的一种有效方法。BP神经网络能够学习、处理大量的输入-输出模式映射关系,而不需要提前明确对应的映射关系,是目前

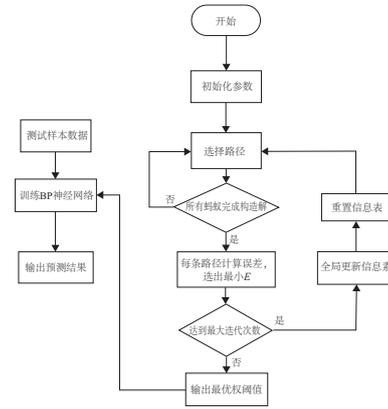


图 1 ACO-BP 算法流程图

应用广泛的神经网络模型之一^[7]。本文提出的光伏发电功率神经网络预测模型结构如图 2 所示。

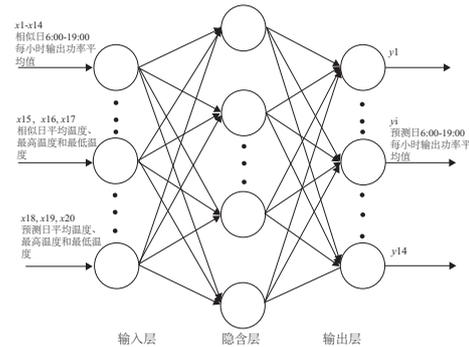


图 2 光伏发电功率预测神经网络模型结构图

4.2 预测模型设计

1) 输入层与输出层

预测模型的输入变量为相似日 6:00-19:00 每小时的输出功率、日平均温度、日最高温度,日最低温度以及预测日的天气数据,输入层节点数为 20 个;输出层的变量为预测日 6:00-19:00 期间每小时的输出功率平均值,因此输出层的节点数为 14 个。

2) 隐含层层数及节点数

增加隐含层数可以降低神经网络训练误差,过多的隐含层数会使模型结构变得复杂化,出现“过拟合”现象,降低估算精度。本文选用一个隐含层的神经网络结构完成对光伏发电功率的预测。

神经网络隐含层节点数按目前常用经验公式进行计算,本文采用的计算公式如式(6)所示。

$$N = \sqrt{m+n} + a \quad (6)$$

式中: N 为隐含层节点数; m 为输入层节点数; n 为输出层节点数; a 为在区间 $[0,10]$ 内的常数。

为进一步提高神经网络预测的准确性,本文选取 5 个样本日对隐含层节点数进行数值实验,计算其平均相对误差,确定最佳的隐含层节点数为 9。

4.3 数据归一化处理

为了更好地对 BP 神经网络进行训练和验证,避免直

接使用原始数据进行训练而引起神经元过饱和,在构造神经网络模型之前将训练样本数据和预测样本数据进行归一化处理。本文选择单极性 Sigmoid 函数作为隐含层和输出层的激活函数,归一化公式如式(7)所示。

$$X_n = \frac{X_n - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式中 X_n 、 X_{\max} 、 X_{\min} 分别为原始输入数据、原始输入数据中的最大值、最小值。

5 预测结果分析

5.1 预测结果

为验证 ACO-BP 神经网络预测模型的准确性,将粒子群算法(PSO)也引入 BP 模型参数的选取中,将 PSO-BP 神经网络预测模型的预测结果与 ACO-BP 相比较,验证 ACO-BP 模型的优越性。

根据本文的分析,需要对日照类型进行分类。按照相似日将这些历史数据分为晴天、阴天和雨天不同组的数据,并将每日的平均温度、日最高温度和日最低温度作为输入量输入模型。研究取各种天气类型相似日中的一天(非样本数据)作为预测日,并用 ACO-BP 预测模型进行功率预测。为方便分析,同时采用传统 BP 算法和 PSO-BP 算法训练的模型预测,对 3 个预测日:2018 年 9 月 29 日(晴)、2018 年 9 月 6 日(阴)和 2018 年 9 月 20 日(雨)进行光伏发电功率预测,最终得出如图 3、图 4 和图 5 所示的结果。

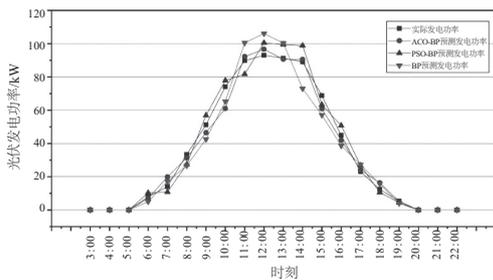


图 3 9月29日晴

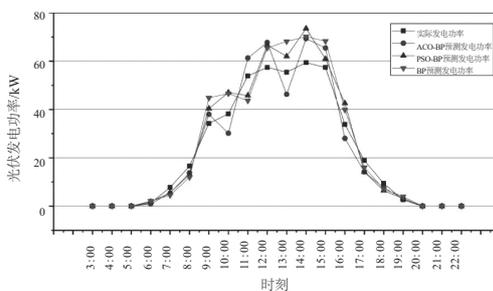


图 4 9月6日阴

从上述功率预测图中可看出:

1) 在晴天天气类型下,3 种模型的预测效果相比于其他天气类型要高。晴天天气下,太阳辐射强度较高,而其他天气因为日照类型不同、日最高最低温度和平均温度的不同等原因,增加了光伏系统发电功率预测的不确定和随机性,导致模型的预测精度降低。

2) 在 3 种天气类型下,ACO-BP 神经网络模型预测结果与实际光伏发电功率的吻合度相比于 BP 神经网络

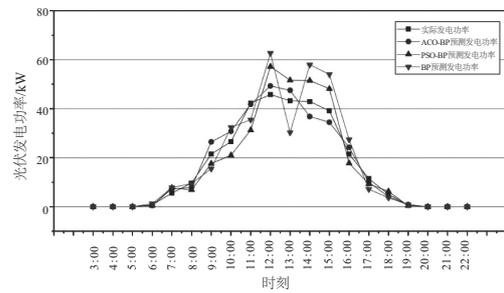


图 5 9月20日雨

和 PSO-BP 神经网络都要高。

5.2 不同天气类型误差比较

针对构造的预测模型,采用平均绝对百分比误差 MAPE 对其预测的发电结果进行分析,评估整体的预测能力,其计算式(8)如下:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_{fore,i} - P_{act,i}}{P_{act,i}} \right| \times 100\% \quad (8)$$

式中: $P_{act,i}$ 为光伏阵列发电量实际值; $P_{fore,i}$ 为光伏阵列发电量预测值; N 为预测样本数量。对图 3 中晴天的光伏阵列发电预测及实际值进行预测误差指标分析,其预测结果如表 1 所示,误差结果如表 2 所示。

表 1 2018 年 9 月 29 日预测值和实际值 单位: W

时间	BP 预测结果	PSO-BP 预测结果	ACO-BP 预测结果	实际值
06:00	5 046	10 327	6 978	7 883
07:00	17 165	10 834	17 914	14 070
08:00	26 755	27 424	31 398	33 444
09:00	42 549	56 903	46 481	51 261
10:00	65 245	77 849	61 032	74 147
11:00	100 518	81 671	92 214	89 748
12:00	106 129	100 544	96 624	93 096
13:00	100 406	99 493	90 675	91 271
14:00	73 008	98 828	90 582	89 034
15:00	57 105	63 298	60 914	68 803
16:00	38 633	50 761	41 934	44 922
17:00	27 230	26 768	24 091	23 079
18:00	15 691	10 624	16 350	12 354
19:00	4 027	4 457	5 223	5 375

从表 2 中可以看出:ACO-BP 预测模型比其他两种模型预测得效果要好。在晴天天气类型下,其预测精度相比于 BP 预测模型高 34.21%,相比于 PSO-BP 预测模型高 10.73%;在阴天天气类型下,其预测精度相比于 BP 预测模型高 29.97%,相比于 PSO-BP 预测模型高 12.63%;在雨天天气类型下,其预测精度相比于 BP 预测模型高 31.04%,相比于 PSO-BP 预测模型高 9.67%。

表 2 各种天气类型下每个模型的预测误差 单位: %

误差指标 MAPE	BP 预测模型	PSO-BP 预测模型	ACO-BP 预测模型
晴天	18.71	13.79	12.31
阴天	27.86	22.33	19.51
雨天	32.93	25.14	22.71

(下转第 187 页)

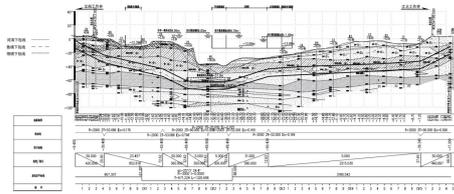


图1 苏通 GIL 综合管廊纵断面图

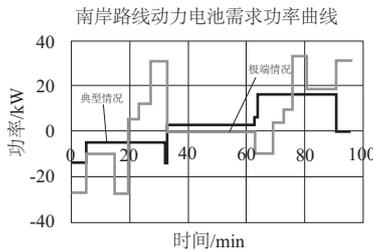


图2 南岸路线动力电池输出功率曲线

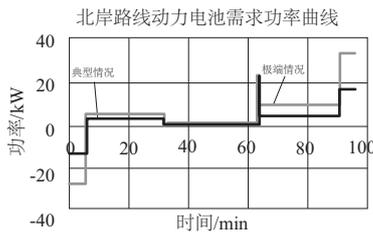


图3 北岸路线动力电池输出功率曲线

3 动力电池类型的选择

由于苏通 GIL 运输专用机具是为了适应苏通 GIL 综合管廊预留的有限运输空间,其尺寸设计较为紧凑,所以能力密度更高的锂离子动力电池是优选技术路线。

目前,国内工业化程度最高的锂离子动力电池是磷酸铁锂型动力电池和三元聚合物动力电池。综合比对这两种动力电池可以发现,三元锂电池在比能量、比功率、大倍

率充电、低温性能等方面具有优势,而在循环性能方面磷酸铁锂电池优势更为明显。相比于三元锂电池,磷酸铁锂电池体积、质量较大、价格较高^[3]。

从安全性指标来看^[4],在整体制造工艺等因素相同情况下,三元材料热稳定性较差,在 200℃ 左右的外界温度下就会分解,并释放出氧气,一旦着火容易造成“热失控”,在极短的时间内就会产生爆燃。而磷酸铁锂热稳定性好,在 800℃ 左右的外界温度下才会产生分解,即使分解也不会释放氧气。所以磷酸铁锂电池燃烧需要外部提供氧气,一旦氧气源被切断,火就能熄灭。在极端情况下,磷酸铁锂的燃烧也不激烈,且火势扩大较为缓慢,起火也比较容易被扑灭。

对于苏通 GIL 专用运输机具来说,两种类型的锂离子动力电池方案质量、尺寸均可满足,但从本质安全性角度考虑,应选用磷酸铁锂型动力电池。

4 结语

本文通过对苏通 GIL 运输专用机具对动力电池的需求以及各种常见动力电池特点及其优缺点的分析,并通过综合比选,最终确定了苏通 GIL 运输专用机具采用磷酸铁锂型动力电池,为苏通 GIL 运输专用机具的研制明确了技术路线。苏通 GIL 运输专用机具的成功研制,必将助力苏通 GIL 综合管廊工程安全、优质、高效地施工,助推我国电力建设事业的高速、健康发展。

参考文献:

[1] 张思杨. 汽车维修行业应对新能源汽车时代策略分析[J]. 内燃机与配件,2018(1):148-151 .

[2] 严益平. 试论新能源汽车维修中电子诊断技术的应用[J]. 技术与市场,2017(12):1-5 .

[3] 何志静. 新能源汽车维修的关键技术研究[J]. 汽车与驾驶维修(维修版),2017(7):11-12.

[4] 王明华,李在元,代克化. 新能源导论[M]. 北京:冶金工业出版社,2014.

收稿日期:2019-12-04

(上接第 175 页)

6 结语

本文采用蚁群算法,利用其优秀的全局寻优能力,对神经网络初始权阈值进行了优化,在一定程度上避免了 BP 神经网络易陷入局部最优的问题,并将改进的 ACO-BP 模型用于光伏发电功率预测。从预测结果表明:结合了蚁群算法与 BP 神经网络的优点,ACO-BP 神经网络模型相比于传统 BP 模型有更好的预测效果。通过与 PSO-BP 神经网络预测结果对比发现:ACO-BP 神经网络光伏系统发电功率预测模型的预测性能略优于 PSO-BP 神经网络,验证了本模型的合理性和准确性,方便电网调度机构制定更加合理的光伏发电运行方式,加强光伏发电并网的能力。

参考文献:

[1] 樊磊. 基于改进 BP 神经网络光伏系统发电功率预测[C]. 燕山:中国高等学校电力系统及其自动化专业第 27 届学术年会,2011.

[2] XU RD, CHEN H, SUN XY. Short-term photovoltaic power forecasting with weighted support vector machine [J]. Logistics, 2012, 17(4):248-253.

[3] CHENG Z, LI SY, HAN IJ, et al. PV power generation forecast based on data mining method [J]. Acta Energeiae Solaris Sinica, 2017(3):726-733.

[4] 耿博,白恒远. 结合相似日 GA-BP 神经网络的光伏发电预测[J]. 电力系统及其自动化学报,2017,29(6):118-123.

[5] 张鹏华. 基于神经网络的分布式光伏电站短期功率预测[D]. 淮南:安徽理工大学,2017.

[6] 郝娟. 基于粒子群算法优化 BP 神经网络的 SRM 磁链模型[J]. 机械制造与自动化,2018,47(2):130-132.

收稿日期:2018-10-22