

DOI:10.16356/j.1005-2615.2023.01.014

人工蜂群优化 BP 神经网络的太阳能电池阵电流预测

闫国瑞, 韩延东, 王启宁, 林博轩, 苏 蛟

(航天东方红卫星有限公司, 北京 100094)

摘要: 通过对卫星太阳能电池阵输出电流影响因子进行分析, 提出了一种基于人工蜂群 (Artificial bee colony, ABC) 算法优化 BP 神经网络的太阳能电池阵输出电流预测方法。将太阳入射角、卫星太阳能电池阵工作温度、卫星星时等遥测量变换后作为神经网络输入, 进行输出电流预测。考虑到神经网络对初始权值及偏置敏感的特点, 采用 ABC 改进算法对神经网络初始参数进行优化。该模型可用于卫星太阳能电池阵电流输出能力分析、太阳能电池阵预警及异常检测等。实验测试表明, 模型能够取得较高预测精度, 同星预测均方根误差 (Mean squared error, MSE) 为 0.10 A, 跨星预测均方根误差为 0.12 A, 其精度明显优于传统数据拟合方法。利用该模型及本文提出的预警策略进行预警, 对于 7 年 5 个月的正常卫星数据没有发生误报, 对于某异常卫星数据能够及时进行预警。

关键词: 卫星; 太阳能电池阵; BP 神经网络; 预测; 人工蜂群

中图分类号: V442 **文献标志码:** A **文章编号:** 1005-2615(2023)01-0116-07

Solar Array Output Current Prediction of Optimized BP Neural Network Based on Artificial Bee Colony Algorithm

YAN Guorui, HAN Yandong, WANG Qining, LIN Boxuan, SU Jiao

(DFH Satellite Co. Ltd, Beijing 100094, China)

Abstract: By analyzing influence factors of the satellite solar array output current, a solar array output current prediction method based on artificial bee colony (ABC)-BP neural network is proposed. Sunlight incident angle, solar array working temperature, satellite time are used as the input of neural network to predict the output current. An improved ABC algorithm is used to optimize initial parameters considering neural network's sensitivity to the initial weights and bias. The trained model can be used for output current analyzing, detecting and alarming abnormality of the solar array. The results show that the trained model can achieve high prediction accuracy. The mean squared error (MSE) is 0.10 A for the same satellite and 0.12 A for different satellites, which are obviously better than those of the traditional data fitting method. By using this model and the proposed alarm method, there is no false alarm for the normal satellite data of 7 years and 5 months, and the abnormal satellite data can be alarmed timely.

Key words: satellite; solar array; BP neural network; prediction; artificial bee colony

卫星在轨运行期间, 利用太阳能电池阵将光能转化为电能, 给星上设备供电以及蓄电池充电, 满足卫星的功率需求。目前太阳能电池阵是绝大多数卫

星能量的唯一来源, 其健康状态直接决定了卫星的工作状态及寿命。

国内外一些学者在太阳能电池阵输出电流拟合、

收稿日期: 2021-10-18; **修订日期:** 2022-06-30

通信作者: 闫国瑞, 男, 高级工程师, E-mail: yanguorui 5000@qq.com。

引用格式: 闫国瑞, 韩延东, 王启宁, 等. 人工蜂群优化 BP 神经网络的太阳能电池阵电流预测[J]. 南京航空航天大学学报, 2023, 55(1): 116-122. YAN Guorui, HAN Yandong, WANG Qining, et al. Solar array output current prediction of optimized BP neural network based on artificial bee colony algorithm[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(1): 116-122.

太阳能电池阵衰减等方面进行了深入研究,鄢婉娟等首先对影响因素——太阳入射角进行电流归一化处理,再对归一化后的电流数据利用多项式及余弦函数进行拟合,得到太阳能电池阵归一化输出电流随时间变化的模型^[1]。左子瑾等通过分析地球同步轨道卫星太阳能电池阵输出电流与太阳入射光强等影响因素之间的量化关系,利用数据拟合的方法,得出太阳能电池阵输出电流拟合公式,并引入形变因子和衰减因子进行修正,基于拟合结果,采用了基于门限的方法进行了太阳能电池阵输出电流的动态监测报警^[2]。Bian等利用多项式三角函数进行数据拟合,对太阳能电池阵输出电流进行预测^[3]。李强等通过拟合电流归一化的方法,对太阳能电池阵功率衰减进行了估计^[4-5]。文献[6-7]分别对Akebono卫星及TacSat-4太阳能电池阵功率衰减进行了分析。

太阳能电池阵输出电流主要受太阳入射角、太阳光强度、卫星太阳能电池阵工作温度及电池阵衰减等因素影响,很难掌握其精确的数学变化规律,目前缺乏高准确度的定量分析方法。文献[1]建立了太阳能电池阵输出电流归一化模型,其相对误差约为2%;文献[2]建立了适时修正的数据拟合模型,预测相对误差约为3%。在故障预警及检测方面,文献[4-7]对太阳能电池阵功率衰减进行了分析,但太阳能电池阵功率衰减分析方法一般不能直接用于故障检测;文献[2]基于拟合结果,提出利用门限的方法进行太阳能电池阵输出电流预警,报警门限阈值跨度设置为5 A。如果门限值设置较大,则不利于及时预警。

神经网络具有“自学习”等特点,理论上可以任意精度拟合非线性模型,近年来神经网络以及以神经网络为基础的深度学习在预测、模式识别等领域有着非常成功的应用^[8-9]。利用神经网络进行预测在航空航天领域也得到了广泛关注与应用^[10-12]。本文利用神经网络较强的非线性映射能力,分析卫星太阳能电池阵输出电流的影响因素,建立太阳能电池阵输出电流神经网络预测模型,通过数据学习建立影响因素与太阳能电池阵输出电流之间的映射关系,进行电流预报。其中太阳入射角影响因子、卫星太阳能电池阵工作温度影响因子来自卫星相关遥测。对于日地距离影响因子、太阳能电池阵衰影响因子,本文利用卫星星时遥测信息进行处理后输入模型,降低了模型应用的复杂度。另外,本文针对神经网络训练过程中容易陷入局部最优而无法获取全局最优的特点,采用改进的人工蜂群(Artificial bee colony, ABC)算法寻求神经网络模型的全局最优权值和偏置,进一步提高了神经网络太阳能电池阵输

出电流预报的精度。

1 模型及算法

1.1 输出电流影响因子

太阳能电池阵工作原理是通过光生伏特效应将光能转换为电能,由于星上母线电压保持基本恒定,太阳能电池阵输出电流可表征其输出功率。输出电流主要影响因素包括太阳入射角、日地距离、卫星太阳能电池阵工作温度及电池阵衰减等,具体分析如下。

太阳能电池阵输出功率受太阳有效光强影响最为直接,太阳有效光强与太阳能电池阵法线和太阳光线夹角的余弦成正比,并且和日地距离平方成反比。定义太阳能电池阵法线与太阳光线的夹角为太阳入射角 α ,当太阳入射角 α 为 0° ,即太阳光线垂直照射太阳能电池阵时,太阳能电池阵输出功率达到最大。

太阳光强度与日地距离的平方成反比,日地距离越大,光通量越小,太阳能电池阵的输出功率和电流会降低。日地距离变化规律以年为周期,在冬至前后达到最小,在夏至前后达到最大^[13]。

由于粒子辐照、紫外辐照等复杂空间环境辐射积累效应的影响,太阳能电池阵光电转化效率随着卫星在轨时间的推移而逐渐降低造成太阳能电池阵衰减。其中粒子辐照及紫外辐照衰减因子主要依靠太阳能电池阵粒子辐照、紫外辐照等地面试验获得,但因为空间环境通常较为复杂,其衰减并不能准确预估。

太阳能电池阵转换效率与温度相关,太阳能电池阵的输出功率随温度变化而变化。太阳能电池的基本结构为二极管,利用P-N结的光伏效应将光能转化为电能,其电流、电压与温度之间关系较为复杂,直流模型电流方程为^[14]

$$I = I_{ph} - I_{pn} \left\{ \exp \left[\frac{q(V + IR_s)}{nkT} \right] - 1 \right\} - \frac{V + IR_s}{R_{sh}} \quad (1)$$

式中: I 为电流; V 为电压; T 为温度; I_{ph} 为光生电流; I_{pn} 为反向饱和电流; R_s 为串联电阻; R_{sh} 为并联电阻; n 为二极管影响因子; q 为电子电荷常数, $q = 1.6 \times 10^{-19}$ C; k 为玻尔兹曼常数, $k = 1.38 \times 10^{-23}$ J/K。

1.2 预测模型

太阳能电池阵输出电流预测模型的结构如图1所示,模型包括输入转换模块以及神经网络模块。输入转换模块完成卫星遥测量到神经网络输入层的变换,神经网络模块为4层网络结构,包括1个输入层、2个隐藏层和1个输出层。




图1 基于神经网络太阳电池阵输出电流预测模型

Fig.1 Prediction model for solar array output current based on neural network

1.2.1 转换模块

直接使用卫星遥测量,建立卫星遥测与日地距离、太阳入射角、卫星太阳电池阵工作温度和太阳电池阵衰减等4种影响因素的映射关系,能够简化神经网络模型输入特征的获取流程,降低模型应用的复杂度,提高模型应用的易用性。转换模块负责完成卫星遥测量到神经网络输入层的变换。

对于太阳电池阵的工作温度 T 来自卫星遥测,直接输入至神经网络模型,由神经网络直接完成工作温度与输出电流的映射。对于太阳入射角 α ,利用卫星太阳星历等遥测计算,对太阳入射角 α 取余弦 $\cos\alpha$ 后输入神经网络模型。

对于日地距离周期因子以及太阳电池阵衰减因子,卫星没有直接遥测反映其变化,本文利用卫星星时秒遥测进行处理。卫星星时秒遥测为相对某一时间纪元的累积秒,为了训练后的模型能够跨型号应用,纪元时刻统一设为2009年1月1日0时0分0秒(记为 UTC_0)。因日地距离呈年周期规律变化,本文对星时秒遥测按照式(2)进行处理,模拟日地距离周期因子为

$$\tilde{F}_d = \frac{\cos[2\pi \times \text{mod}(s, y)/y] + 1}{2} \quad (2)$$

式中: s 代表星时累积秒; y 为回归年秒值, $y = 24 \times 3600 \times 365.242$; mod 代表取余。

随着卫星在轨时间的推移,太阳电池阵光电转化效率逐渐降低,太阳电池阵衰减因子是卫星在轨运行时间的函数,模拟太阳电池阵衰减因子处理如下

$$\tilde{F}_1 = (s - (UTC_0 - UTC_L))/y \quad (3)$$

式中: UTC_L 代表卫星发射时间; UTC_0 代表星时秒遥测纪元时刻。

经转换模块处理后得到 $[T, \cos\alpha, \tilde{F}_d, \tilde{F}_1]$,作为神经网络模块的输入, \tilde{F}_d, \tilde{F}_1 分别为模拟的日地

距离周期因子及衰减线性因子,太阳电池阵输出电流与真实的日地距离因子及太阳电池阵衰减因子复杂的非线性关系将由神经网络模块负责映射。

1.2.2 神经网络模块

神经网络由输入层、中间层(隐藏层)和输出层组成,如图2所示。神经网络中每个节点(神经元)将前一层节点的输出作为输入,各层之间存在连接权值 w_{ji}^{l+1} 及偏置 b_j^{l+1} ,连接权值的大小是神经元之间连接强度的反映。研究表明,只要中间层神经元的个数足够多,神经网络就可以无限逼近非线性映射关系,从而能够保证对复杂连续映射关系的刻画能力^[15]。




图2 神经网络参数

Fig.2 Parameters of neural network

目前如何设计网络结构以得到最优的预测结果尚无成熟的理论公式^[16],本文通过实验对比,并结合网络结构复杂度和预测精度,将神经网络结构设计为 $4 \times 3 \times 2 \times 1$,即输入层节点数为4,输出层节点数为1,分别对应输入数据特征维数及输出电流;设置2个中间层,节点数分别为3和2。中间层激活函数采用Sigmoid函数,有

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

输出层激活函数采用线性函数,损失函数为均方误差(Mean square error, MSE)。

1.3 基于ABC优化的神经网络训练

神经网络训练是求解最佳权值和偏置的过程,神经网络训练对初始权值及偏置敏感,易陷入局部最优,需要多次尝试不同的初始值对网络进行训练,然后筛选出最优网络供实际使用。若通过大量人工重复试验,试验任务繁重且结果具有相对较大的随机性。本文采用ABC算法优化神经网络模型,通过改进的ABC算法寻求神经网络模型的全局最优权值和偏置,能够进一步提高神经网络预报的精度。

Karaboga等模拟蜂群的采蜜行为提出了ABC算法^[17-18],该算法模拟蜂群采蜜机制,将各蜂种在

采花觅食过程中密切配合的工作过程抽象为数学模型。在ABC算法中,蜂群包含NP个个体,每个个体X代表一个候选解,个体维数为D,即待优化问题的维度。ABC算法将蜂群划分为3个蜂种:引领蜂(Leader)、跟随蜂(Follower)和侦查蜂(Scouter),标准ABC算法包括下述3个关键步骤。

(1) 引领蜂搜索:蜂群中适应度较优的一半个体(SN=NP/2)构成引领蜂,其工作是在已找到收益度较高的区域内进行食物源的搜索工作,对于第g代引领蜂第i个体 X_i^g ,随机选择引领蜂中另一个个体 X_k^g ,按照式(5)进行交叉,产生新个体V。

$$V(j) = X_i^g(j) + \varphi_j \times [X_i^g(j) - X_k^g(j)] \quad (5)$$

式中: φ_j 为[-1, 1]区间的随机数, $j \in \{1, 2, \dots, D\}$ 。

选择适应度较优的个体替换原个体,有

$$X_i^{g+1} = \begin{cases} V & \text{fit}(V) > \text{fit}(X_i^g) \\ X_i^g & \text{fit}(V) \leq \text{fit}(X_i^g) \end{cases} \quad (6)$$

式中fit为适应度函数。

(2) 跟随蜂搜索:蜂群中适应度较差的另一半个体构成跟随蜂,其工作是利用引领蜂的共享信息寻找食物源。跟随蜂按照一定概率选择一个引领蜂按照式(5)进行交叉搜索,引领蜂适应度越优,被选择的概率越大,被选概率为

$$P_i = \frac{\text{fit}_i}{\sum_{i=1}^{\text{SN}} \text{fit}_i} \quad (7)$$

式中: P_i 为个体i被选中的概率; fit_i 为个体i的适应度。

(3) 侦查蜂搜索:若某个体未更新的次数达到了设定的最大值limit,则相应个体转变为侦查蜂,随机寻找新的蜜源。

考虑到使用ABC算法进行神经网络优化时,limit具体值难以确定,本文以一定概率将某个体转变为侦查蜂,其转变概率为

$$\text{CP}_i = 1 - e^{-\frac{2 \times t_i}{G}} \quad (8)$$

式中: CP_i 为个体转变为侦查蜂的概率;G为总的进化次数(迭代次数); t_i 代表个体i未更新的次数, t_i 越大,被选中转换为侦查蜂的概率越大。

使用ABC进行神经网络优化的具体过程如下:

步骤1 编解码:设置个体维数D等于神经网络权值和偏置的个数,编码是将网络权值和偏置组织成一个一维向量(即一个个体)的过程;解码是将

个体反变换为神经网络权值和偏置的过程。

步骤2 初始化:初始化进化次数G,随机生成含有NP个个体的初始种群。

步骤3 适应度计算:将个体解码,并使用误差反向传播算法进行神经网络训练,计算个体适应度,适应度函数用来评价个体的好坏

$$\text{fit} = \frac{1}{1 + \text{MSE}_{\text{net}}} \quad (9)$$

式中 MSE_{net} 代表神经网络输出的均方误差。

步骤4 按式(5~8)进行引领蜂搜索、跟随蜂搜索、侦查蜂搜索迭代,寻找最优个体。

步骤5 达到最大迭代次数,将最优个体解码,形成神经网络初值,利用该初值使用误差反向传播算法训练神经网络。

2 实验结果分析

2.1 电流预测应用

为消除遥测数据异常点及地球反射率对太阳能电池阵输出电流的影响,训练及预测前对数据进行预处理,对一天的数据去除一部分最高值和一部分最低值,然后求平均值。分别从同星预测和跨星预测两方面对本文模型进行验证,计算平均绝对误差(Mean absolute error, MAE)、平均绝对误差百分比(Mean absolute percentage error, MAPE)、均方根误差(Root mean square error, RMSE)以及相关系数作为模型的评价指标,其定义如下

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (10)$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (12)$$

$$\rho = \frac{\text{cov}(\hat{y}_i, y_i)}{\sigma(\hat{y}_i)\sigma(y_i)} \quad (13)$$

式中:N为测试样本集数; \hat{y}_i 和 y_i 分别代表太阳能电池阵输出电流的预测值及实测值;cov为协方差; σ 为标准差。

2.1.1 训练与比较

训练集为型号A的2013年8月~2016年6月的遥测数据,测试集1为同型号A的2016年7月~2021年3月的遥测数据,测试集2为型号B的2018年6月~2021年3月的遥测数据。

本文实验了4-3-1、4-3-2-1、4-5-3-2-1三种不同网络结构,使用本文1.3节的训练方法进行训练。

针对测试集1和测试集2,其预测误差比较如表1所示。

表1 不同网络结构预测精度比较(测试集1/测试集2)

Table 1 Comparison of prediction results for different neural networks (Test set 1/Test set 2)

| 网络结构 | RMSE / A | MAE / A | MAPE / % | ρ |
|-----------|-----------|-----------|-----------|-----------------|
| 4-3-1 | 0.14/0.17 | 0.11/0.13 | 0.25/0.30 | 0.991/ 0.983 |
| 4-3-2-1 | 0.10/0.12 | 0.08/0.10 | 0.18/0.22 | 0.995/ 0.990 |
| 4-5-3-2-1 | 0.09/0.11 | 0.07/0.09 | 0.15/0.21 | 0.996/ 0.988 |

另外,随机尝试100次不同的初始值,使用误差反向传播算法进行神经网络训练,得到100个神经网络模型,然后从中选取最优的网络模型,与本文经ABC算法优化的神经网络模型预测误差比较,如表2所示。

表2 ABC优化与未优化模型预测精度比较

Table 2 Comparison of prediction results for ABC optimized and unoptimized BP neural network

| 参数 | RMSE / A | MAE / A | MAPE | ρ |
|-----|-----------|-----------|-----------|-------------|
| 未优化 | 0.13/0.20 | 0.10/0.16 | 0.23/0.36 | 0.993/0.970 |
| 优化 | 0.10/0.12 | 0.08/0.10 | 0.18/0.22 | 0.995/0.990 |

通过表1、2得出:经ABC算法优化的神经网络模型提升了预测精度,针对本文的电流预测问题,增加网络隐藏层及其节点数量,使网络结构变为4-5-3-2-1,并没有明显提高预测精度,而4-3-2-1网络结构相对4-3-1网络结构预测精度有明显提高。最终综合预测精度和网络结构的复杂度,本文选取了经ABC算法优化的4-3-2-1神经网络模型,其训练集相关系数为0.996。

2.1.2 预测应用

(1)同星预测

利用经ABC算法优化的4-3-2-1神经网络模型对本型号2016年7月~2021年3月的太阳电池阵输出电流进行预测,预测效果如图3所示,其中RMSE为0.10 A,MAE为0.08 A,MAPE为0.18%, $\rho=0.995$ 。

(2)跨星预测

利用上述神经网络对型号B的2018年6月~2021年3月的太阳电池阵输出电流进行预测,预测效果如图4所示,其中RMSE为0.12 A,MAE为0.10 A,MAPE为0.22%, $\rho=0.990$ 。

本文针对优化的神经网络模型,计算了




图3 同星预测结果(卫星A)

Fig.3 Prediction results of the same satellite (Satellite A)




图4 跨星预测结果(卫星B)

Fig.4 Prediction results of different satellites (Satellite B)

RMSE、MAE、MAPE等多种评价指标,与文献[2-3]传统拟合算法比较如表3所示,结果显示其精度优于传统数据拟合方法。

表3 不同算法预测精度比较

Table 3 Comparison of prediction results for different algorithms

| 参数 | RMSE / A | MAE / A | MAPE / % |
|-------|-----------|-----------|-----------|
| 本文 | 0.10~0.12 | 0.08~0.10 | 0.18~0.22 |
| 文献[2] | 0.47~0.58 | | |
| 文献[3] | 0.37 | | |

2.2 故障预警应用

(1)某在轨发生太阳电池阵异常案例应用

某卫星C发射后太阳电池阵发生故障,出现了电流下降的质量问题,但由于太阳电池阵输出电流受日地距离、太阳入射角、帆板温度等多种因素综合影响,由于当时缺乏准确定量分析方法,造成该故障并没有被及时发现。采用本文方法训练的模

型对该卫星太阳电池阵输出电流进行预测,并与实测值进行比对如图5所示,可以发现卫星发射6个月后电流开始出现下降,发射一年后卫星电流与上一年同期相比电流下降约2.5 A,可见本模型可以有效地进行太阳电池阵故障预警及检测。




图5 对某在轨卫星C故障检测
Fig.5 Fault diagnosis of Satellite C

(2) 预警应用

基于模型预测的准确度,提出预警策略如下

alarm(i)=

$$\begin{cases} 1 & \frac{\hat{y}_j - y_j}{y_j} > \lambda \times \text{MAPE} \quad \forall j \in \{i-2, i-1, i\} \\ 0 & \frac{\hat{y}_j - y_j}{y_j} \leq \lambda \times \text{MAPE} \quad \exists j \in \{i-2, i-1, i\} \end{cases} \quad (14)$$

式中:1代表警告;0代表正常;其中λ为预警系数,默认为3。式(14)应用于卫星A、B、C,结果如图6~8所示。结果表明:应用于正常卫星A及卫星B,能够有效过滤随机抖动,对于多年的遥测数据均没有发生误报;对于故障卫星C,发生故障后能够及时预警及检测出异常,证明了预测模型及预警策略的有效性。




图6 预警策略应用于卫星A
Fig.6 Alarm strategy applied to Satellite A




图7 预警策略应用于卫星B
Fig.7 Alarm strategy applied to Satellite B




图8 预警策略应用于卫星C
Fig.8 Alarm strategy applied to Satellite C

3 结 论

本文提出了一种基于改进ABC算法优化神经网络的太阳电池阵输出电流预测方法,可以应用于分析并评价太阳电池阵的输出能力、太阳电池阵异常检测及预警、太阳电池阵输出电流仿真等方面。

利用优化后的神经网络模型对太阳电池阵输出电流进行同星长时间(4年8个月)预测,以及跨星长时间(2年9个月)预测,均取得了较高精度的结果,结果显示其精度优于传统数据拟合方法。本模型可以及时准确地进行太阳电池阵输出电流在轨异常检测及预警,证明了基于优化神经网络的预测模型应用于太阳电池阵输出电流预测、预警与异常检测的可行性和有效性。另外本模型的4个输入均直接来自卫星遥测,降低了模型应用的复杂度,可直接装载在卫星上,用于在线的太阳电池阵预警及异常检测。

参考文献:

[1] 鄢婉娟,苏蛟,刘元默.一种太阳电池阵在轨输出电

- 流预计方法[J]. 电源技术, 2017, 41(8): 1142-1145.
YAN Wanjuan, SU Jiao, LIU Yuanmo. Method of one predicting solar array output current in orbit[J]. Chinese Journal of Power Sources, 2017, 41(8): 1142-1145.
- [2] 左子瑾, 金迪, 田华东. GEO卫星太阳电池阵输出电流拟合算法研究[J]. 航天器工程, 2017, 26(2): 84-90.
ZUO Zijin, JIN Di, TIAN Huadong. Fitting algorithm research on solar array output of GEO satellite [J]. Spacecraft Engineering, 2017, 26(2): 84-90.
- [3] BIAN Y S, XU C, LI J F, et al. Modelling and application of output current of the solar array for satellite in sun synchronous orbit[C]//Proceedings of IOP Conference Series: Earth and Environmental Science.[S. l.]:IOP, 2018.
- [4] 李强, 马强, 王洪浩, 等. 晨昏轨道卫星硅太阳电池阵功率衰减估计[J]. 计算机测量与控制, 2019, 27(12): 146-150.
LI Qiang, MA Qiang, WANG Honghao, et al. Estimation to silicon solar cell degradation of dawn-dusk satellite[J]. Computer Measurement & Control, 2019, 27(12): 146-150.
- [5] 李强, 洪涛, 林乐天, 等. 一种晨昏轨道卫星地球反照系数估计方法[J]. 宇航学报, 2016, 37(1): 68-73.
LI Qiang, HONG Tao, LIN Letian, et al. Earth albedo coefficient estimation for dawn-dusk orbit satellite [J]. Journal of Astronautics, 2016, 37(1): 68-73.
- [6] MIYAKE W, MIYOSHI Y, MATSUOKA A. An empirical modeling of spatial distribution of trapped protons from solar cell degradation of the Akebono satellite[J]. Advances in Space Research, 2015, 56(11): 2575-2581.
- [7] JENKINS P, BENTZ D, BARNDS J, et al. TACSAT-4 solar cell experiment: Two years in orbit[C]//Proceedings of the 10th European Space Power Conference. Noordwijkerhout, Netherlands: [s.n.], 2014.
- [8] 耿博, 高贞彦, 白恒远, 等. 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.
GENG Bo, GAO Zhenyan, BAI Hengyuan, et al. PV generation forecasting combined with similar days and GA-BP neural network[J]. Proceedings of the CSU-EPSA, 2017, 29(6): 118-123.
- [9] 王晨阳, 段倩倩, 周凯, 等. 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测[J]. 物理学报, 2020, 69(10): 100701.
WANG Chenyang, DUAN Qianqian, ZHOU Kai, et al. A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm[J]. Acta Physica Sinica, 2020, 69(10): 100701.
- [10] 吕栋, 欧吉坤, 于胜文. 基于MEA-BP神经网络的卫星钟差预报[J]. 测绘学报, 2020, 49(8): 993-1003.
LYU Dong, OU Jikun, YU Shengwen. Prediction of the satellite clock bias based on MEA-BP neural network[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(8): 993-1003.
- [11] 邓旭东, 胡和平. 基于神经网络模型的襟翼主动控制旋翼减振分析[J]. 南京航空航天大学学报, 2017, 49(2): 189-194.
DENG Xudong, HU Heping. Vibration reduction in ACF rotor based on neural network[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2017, 49(2): 189-194.
- [12] 霍冠良, 宁志华. 基于BP神经网络的含褶皱复合材料强度预测[J]. 南京航空航天大学学报, 2020, 52(3): 460-467.
HUO Guanliang, NING Zhihua. Strength prediction of laminates containing embedded fiber wrinkles using BP neural networks[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020, 52(3): 460-467.
- [13] 国志磊, 安雪滢, 罗宗富, 等. 轨道动力学方法用于太阳位置精确解算的比较研究[J]. 太阳能学报, 2020, 41(6): 188-195.
GUO Zhilei, AN Xueying, LUO Zongfu, et al. Comparative research of solar position precise algorithm based on methods of orbital mechanics[J]. Acta Energeticae Solaris Sinica, 2020, 41(6): 188-195.
- [14] 翟载腾, 程晓舫, 杨臧健, 等. 太阳电池一般电流模型参数的解析解[J]. 太阳能学报, 2009, 30(8): 1078-1082.
ZHAI Zaiteng, CHENG Xiaofang, YANG Zangjian, et al. Analytic solutions of solar cell model parameters [J]. Acta Energeticae Solaris Sinica, 2009, 30(8): 1078-1082.
- [15] 焦李成, 杨淑媛, 王士刚, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8): 1697-1716.
JIAO Licheng, YANG Shuyuan, WANG Shigang, et al. Seventy years beyond neural networks: Retrospect and prospect[J]. Chinese Journal of Computers, 2016, 39(8): 1697-1716.
- [16] KARSOLIYA S. Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture [J]. International Journal of Engineering Trends and Technology, 2012, 3(6): 714-717.
- [17] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm[J]. Journal of Global Optimization, 2007, 39(3): 459-471.
- [18] KARABOGA D, BASTURK B. On the performance of artificial bee colony (ABC) algorithm [J]. Applied Soft Computing, 2008, 8(1): 687-697.