

一种简单的短时辐照度预测研究

钟志峰¹, 张 艺¹, 张田田¹, 杨晨茜¹, 苏 勇²

(1. 湖北大学 计算机与信息工程学院, 武汉 430062; 2. 华中科技大学 光学与电子信息学院, 武汉 430074)

摘要: 准确的辐照度预测是光伏发电系统预测输出功率的关键, 而辐照度受纬度、天气类型、海拔等因素的影响巨大, 不同地区差异较大; 目前对辐照度的短时预测研究中复杂的气象数据获取难度大, 因此提出了一种利用便于获取气象数据进行辐照度短时预测的简单方法; 根据武汉市特有的地理位置特点, 将天气类型分为四类, 将环境监测仪实时测量的温度、辐照度数据及不同时刻的太阳高度角作为网络的输入, 用多变量 BP 神经网络模型对 05:00 到 20:00 时的每小时辐照度进行短期预测; 将得到的预测结果与仅用历史辐照度数据作为输入得到的预测结果进行对比, 该模型准确性有很大的提高; 最终以持续性方法为基准得出预测技能; 结果显示该模型在 A、B 类天气时预测技能均在 0.75 以上, 大部分分布在 0.80~0.85, 表明该模型在仅利用便于获取的气象信息的基础上能够较准确地对短时辐照度进行预测。

关键词: 辐照度短时预测; 太阳高度角; BP 神经网络模型; 预测技能

Research on a Simple Short-term Forecast of Irradiation

Zhong Zhifeng¹, Zhang Yi¹, Zhang Tiantian¹, Yang Chenxi¹, Su Yong²

(1. School of Computer Science and Information Engineering, Hubei university, Wuhan 430062, China;

2. School of Optical and Electronic Information, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: The precise prediction of irradiation is the critical factor of predicting the output power of photovoltaic power generation system, yet the irradiation vary from region to region because of the different latitude, weather types and altitude etc. Because complicated meteorological data in currently research about the forecast of short-term irradiation is hard to be collected, this paper proposes a simple method for short-term prediction of irradiance only using the meteorological data which easy to obtain. In consideration of the unique geographical location of Wuhan, the weather is classified to four types. The input variables are temperature, irradiance measured by real-time environmental monitoring and solar elevation angle at different times. Then the irradiation is calculated per hour from 05:00 to 20:00 using the multivariate backward feedback neural network model. Contrasting the result obtained from the model mentioned above and that only taking historical irradiation data as input, the former has a better outcome. At last, the forecasting skills is calculated based on the Persistence Method. The final results show that all the skills of the proposed model are greater than 0.75, almost distributed between 0.80 and 0.85 for the weather type A and B, which demonstrates the model proposed in this paper is capable of predicting short-term irradiation accurately based on the meteorological information which easy to be obtained.

Keywords: forecast of short-term irradiation; solar elevation angle; BP neural network model; forecasting skills

0 引言

太阳能是一种绿色无污染、潜能巨大、可持续发展的新型能源。目前对太阳能的利用主要是进行光伏并网发电, 而光伏发电系统中辐照度是影响发电量的决定性因素。以往预测辐照度的算法大体可以分为两类, 一类是直接利用历史辐照度的数据进行单变量的预测, 另一类是用温度、气压、湿度、云层信息等气象数据进行单变量或多变量的预测。其中复杂的气象信息的搜集难度大, 运算过程复杂, 本文利用便于获取的实时温度数据和历史辐照度数据, 再结合整点时刻太阳高度角, 以这 3 个量为输入变量来预测 05:00 时到 20:00 时的辐照度。对辐照度进行预测的方法较常用的几种模型有神经网络算法模型^[1-2], 经验模型和统计分析^[3]、小波变换算法模型^[4-5], 支

持向量机^[6], 遗传算法^[7]模型等。每种算法模型都有各自的优势和缺陷。由于辐照度的影响因素很多, 能够测得的影响因素与辐照度的关系是无法用特定函数描述的非线性关系。而 BP 神经网络拥有强大的非线性拟合能力, 在样本充足的情况下, 对内部机制复杂的系统进行求解十分方便, 本研究正是利用该优势来建立预测模型。将最终预测结果与持续性方法对比得出预测技能。

1 影响辐照度的因素

影响辐照度测量值大小的因素一般可以分为两大类: 一类是固有因素, 如测试仪器自身的精确度及摆放的地理位置, 仪器摆放角度等; 另一类是外界环境因素, 包括太阳高度角、天气类型、总云量等。针对前一类因素, 对辐照度预测的影响已经包含在历史辐照度数据中; 对于后一类因素, 在某一特定地区, 太阳高度和入射角是主要因素, 天气类型和云量是辐照度的反映量, 为间接因素。由于云量信息很难获取, 考虑到辐照度的多少对环境温度的高低有直接的影响, 而实测温度数据便于获取, 因此本文将太阳高度角和环境温度作为预测辐照度的主要考虑因素。

收稿日期:2017-01-03; 修回日期:2017-02-06。

作者简介: 钟志峰(1971-), 男, 湖北黄冈人, 副教授, 硕士研究生导师, 主要从事雷达系统和信号处理以及光伏发电和系统集成等方向的研究。

通讯作者: 张 艺(1992-), 女, 河南安阳人, 硕士研究生, 主要从事信号处理及光伏发电方向的研究。

1.1 太阳高度角

太阳光线与地平面的夹角即为某地点的太阳高度角, 用 e 表示。地球的运动分为自转和公转, 以地球为参照物, 自转造成了太阳高度角在一天之内不停的发生变化; 公转造成了太阳以年为周期在南北回归线之间移动, 因此太阳高度角的变化有日变化规律和年变化规律。其的计算公式为:

$$\begin{aligned}\cos(90^\circ - e) &= \sin(90^\circ - \delta)\sin(90^\circ - \varphi)\cos t + \\ &\cos(90^\circ - \delta)\cos(90^\circ - \varphi)\end{aligned}\quad (1)$$

化简可得:

$$\sin e = \sin \delta \sin \varphi + \cos \delta \cos \varphi \cos t \quad (2)$$

式中, φ 为本地的纬度值, δ 为太阳赤纬角, t 为太阳时角。 φ, δ 的取值均为北正南负; 当 $e > 0$ 时, 表示太阳在地平面之上 (白天); 当 $e < 0$ 时, 太阳在地平线之下 (夜晚)。正午时 $t = 0$, 上午为负, 下午为正^[8]。

太阳赤纬角 δ 的计算公式为:

$$\delta = 23.45 \sin\left(360 \times \frac{284 + N}{365}\right) \quad (3)$$

其中: N 为日期序号, 1 月 1 日为 1, 以此类推。本文地理纬度 φ 取北纬 30.5° , 太阳时角的计算公式为:

$$t = 15 \times (ST - 12) \quad (4)$$

式中, ST 为真太阳时, 以 24 小时计。

由本地实测数据得到的太阳高度角和辐照度的关系如图 1。




图 1 太阳高度角和辐照度的关系

从图中可以看出辐照度和太阳高度角的变化趋势相同, 当太阳高度角增加时, 辐照度也增加; 太阳高度角减小时, 辐照度也减小; 太阳高度角到达峰值的时间略早于辐照度到达峰值时间。

1.2 温度与辐照度的关系

辐照度是单位时间内投射到单位面积上的辐射能量, 是影响环境温度的主要因素。本文可通过环境监测仪获得每一时刻该地环境温度数据, 辐照度与温度的关系如图 2。

从图中可以看出, 两者曲线变化趋势相同, 走势虽不是完全对应, 但辐照度增加时温度增加, 辐照度降低时温度降低, 因此温度的高低可以在一定程度上反映该时刻的辐照度。

2 实现辐照度短时预测的模型

2.1 BP 神经网络模型的基本原理

BP 神经网络模型^[9]采用信号正向传播以及误差反向传播方式对网络进行训练。网络可包含多变量输入层, 多个隐含层, 多变量输出层。BP 神经网络采用数据流的前向传播和误差信号的反向传播机制, 正向传播时, 每层神经元的状态只影响下一层神经元。其中每个神经元的基本功能为加权、求和及




图 2 辐照度与温度的关系

转移。每个神经元的输入输出如图 3。




图 3 每个神经元的输入输出示意图

神经元输出为式:

$$y_j = f(S_j) \quad (5)$$

其中:

$$S_j = \sum_{i=1}^n w_{ji} \cdot x_i + b_j = W_j X + b_j \quad (6)$$

式中, $x_1, x_2, \dots, x_i, \dots, x_n$ 分别代表来自前一层神经元 $1, 2, \dots, i, \dots, n$ 的输入; $w_{j1}, w_{j2}, \dots, w_{ji}, \dots, w_{jn}$ 则分别为上层对应神经元与该神经元的连接权值, 令 $X = [x_1, x_2, \dots, x_i, \dots, x_n]^T$, $W_j = [w_{j1}, w_{j2}, \dots, w_{ji}, \dots, w_{jn}]$, b_j 为阈值, $f(\cdot)$ 为有界单调上升的传递函数, y_j 为第 j 个神经元的输出。若令 $x_0 = 1, w_{j0} = b_j$, 将这两个量加入 X 和 W_j 向量中, 则 $X = [x_0, x_1, x_2, \dots, x_i, \dots, x_n]^T$, $W_j = [w_{j0}, w_{j1}, w_{j2}, \dots, w_{ji}, \dots, w_{jn}]$ 。

则节点 j 的净输入 S_j 可表示为:

$$S_j = \sum_{i=0}^n w_{ji} \cdot x_i = W_j X \quad (7)$$

该净输入量通过传递函数 $f(\cdot)$ 后, 便得到此神经元的输出 y_j 为:

$$y_j = f(S_j) = f\left(\sum_{i=0}^n w_{ji} x_i\right) = F(W_j X) \quad (8)$$

当输出层得到的结果与期望不符时, 误差信号开始进行反向传播。

本文输入变量有 3 个, 输出变量有 16 个, 输入样本有 800 组, 即 n 的值为 3, m 的值为 16, s 的值为 800, 每组样本用 $a_1, a_2, \dots, a_q, \dots, a_s$ 来表示, 输入第 q 个样本时的输出误差为:

$$E_q = \frac{1}{2} \sum_{j=1}^m (t_j^q - y_j^q)^2 \quad (9)$$

其中: t_j^q 为第 q 个样本作为输入时的期望输出, y_j^q 为第 q 个样本作为输入时的实际输出, j 为输出向量的维数 ($j = 1, 2, \dots, m$)。

对于 s 个样本, 全局误差为:

$$E = \frac{1}{2} \sum_{q=1}^s \sum_{j=1}^m (t_j^q - y_j^q)^2 = \sum_{q=1}^s E_q \quad (10)$$

输出层各神经元的权值调整公式为:

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial}{\partial w_{jk}} \left(\sum_{q=1}^n E_q \right) = \sum_{q=1}^n -\eta \frac{\partial E_q}{\partial w_{jk}} \tag{11}$$

其中: w_{jk} 为隐含层与输出层之间的权值, η 表示学习率。
隐含层各神经元的权值调整公式为:

$$\Delta v_{ki} = -\eta \frac{\partial E}{\partial v_{ki}} = -\eta \frac{\partial}{\partial v_{ki}} \left(\sum_{q=1}^n E_q \right) = \sum_{q=1}^n -\eta \frac{\partial E_q}{\partial v_{ki}} \tag{12}$$

式中, v_{ki} 为输入层与隐含层之间的权值, η 表示学习率。
前向传播与反向传播交替进行, 在权向量空间执行误差函数梯度下降策略, 动态迭代搜索一组权向量, 使网络误差函数达到最小值, 最终逼近期望输出, 进而完成信息提取和记忆过程。

2.2 BP 神经网络理论模型算法实现

通过对影响辐照度的相关因素的分析, 结合多变量 BP 神经网络模型综合考虑太阳高度角和实测温度数据建立预测模型, 取一部分数据对神经网络进行训练, 另外一部分数据用来验证神经网络预测精度。训练阶段, 通过对样本的学习, 建立输出与输入之间的映射关系; 在测试阶段, 利用该映射关系对新的输入产生新的输出, 从而完成预测功能。本文模型的建模过程如下:

- 1) 从数据库读取辐照度、温度的所有历史数据;
 - 2) 计算不同日期的每一时刻对应的太阳高度角;
 - 3) 设置训练样本和测试样本;
 - 4) 设置神经网络初始化参数, 本文将神经网络的训练参数分别设置为目标误差 $1e-6$, 学习速率 0.05, 最大训练次数 1000;
 - 5) 可以通过划窗方式进行连续几天的辐照度预测;
 - 6) 计算均方误差和预测技能 skill;
- 根据算法步骤得出流程图如图 4。

3 实验结果及分析

本文所用到的软件为 MATLAB R2012b, 数据取自武汉国际博览中心光伏电站, 共获得 2015 年 10、11、12 月以及 2016 年 1、2、3 月共 6 个月的辐照度及温度数据。数据库中的数据是每隔两分钟一场, 且每天的辐照度数据是从零开始的累积量, 所以需要 对数据进行预处理。从原始数据中整理出每天 05:00 到 20:00 每个整点时刻的温度和辐照度数据, 用后一时刻的辐照度测量值减去前一时刻的辐照度测量值的差值表示该时刻内的累计辐照度, 并计算出每一时刻对应的太阳高度角。同时从网络获取以上六个月的天气类型, 进行分类^[10], 见表 1。

表 1 广义天气类型

广义天气类型	天气类型(气象部门)
A 类	晴、晴转多云、多云转晴
B 类	多云、阴、阴转多云、多云转阴、雾
C 类	阵雨、雷阵雨、雨夹雪、小雨、小雪、阵雪、冻雨、小到中雨、小到中雪
D 类	中雨、大雨、暴雨、大暴雨、特大暴雨、中雪、大雪、暴雪、中到大雨、大到暴雨、暴雨到大暴雨、中到大雪、大到暴雪、沙尘暴

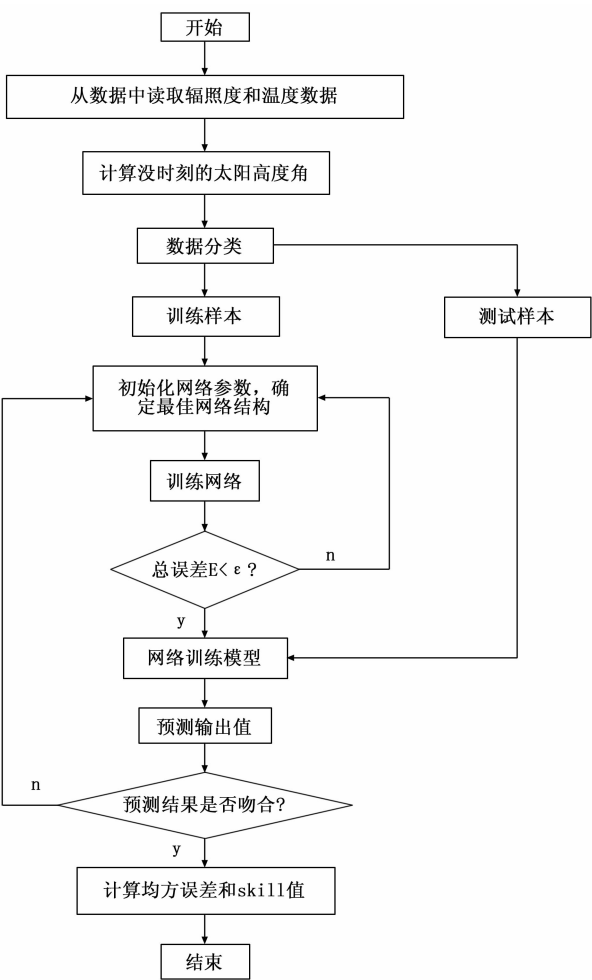


图 4 算法流程图

4 种广义的天气类型在这 6 个月中的分布见表 2。

表 2 广义天气类型分布

广义天气类型	天数/d	所占比例/%
A 类	69	37.70
B 类	75	40.98
C 类	38	20.77
D 类	1	0.55

由表 2 可以看出, 在这 6 个月中 A、B 两类天气占大多数, C、D 两类天气所占比例不到 25%, 因此在本研究中 A、B 两类天气的辐照度预测准确度为主要研究对象。

用第二部分的模型对辐照度进行训练和预测。A、B 类天气的预测结果如图 5。

图中带圆圈的实线是每一时刻辐照度的实际测量值, 带点的虚线为仅通过历史辐照度数据得到的预测结果, 带三角的虚线为该文提出的模型得到的辐照度预测结果。由图可以看出, 仅通过历史辐照度数据预测的辐照度与实际值有较大的偏差, 其中 12 月 18 日的正午时段预测曲线与原始数据的曲线趋势明显不符, 预测失效。本文模型虽利用最易于获取的气象数据——环境温度, 但是得到的预测结果与实际值保持相同的变化趋势, 且每一时刻的预测值与实际值基本吻合, 总体贴合程度




图 5 A、B 类天气预测结果对比图

较理想，这在一定程度上表明加入了环境温度这一气象数据比只用历史辐照度数据进行预测准确性提高。

本文模型得到的预测值与实际值的相关性散点图如图 6。




图 6 预测值与实际值的相关性散点图

图中可以看出，通过本文提出的模型得到的预测值与实际值相关性点都在 $y = x$ 的直线附近，即相关性接近 1，表明本文模型得出的预测值与实际值的相关性非常大。

为了进一步通过数据来说明该算法的可行性，下面将该算法与持续性方法 (persistence method, 以下简称 PM) 得到的均方根误差 (RMSE) 进行对比分析。

PM 是一种最早也是最简单的预测算法，依赖于经验值，也就是已经获取的信息。该算法假设下一时刻的值与上一时刻相同，也就是用当前值作为下一时刻的预测值。该算法原理简单操作简便，常作为一个基准，来计算其他算法的预测技能 skill，计算公式为：

$$skill = 1 - \frac{E_s}{E_p} \tag{13}$$

其中： E_s 为本文算法的均方根误差， E_p 为 PM 的均方根误差， $skill$ 为本文算法的预测技能。而均方根误差 (RMSE) 的计算公式为：

$$\bar{E} = \sqrt{\frac{\sum_{i=1}^m (B_i - b_i)^2}{n - 1}} \tag{14}$$

其中： $B_i (i = 1, 2, \dots, m)$ 为真实值， $b_i (i = 1, 2, \dots, m)$ 为预测值。

skill 的值越接近 1 说明该算法与 PM 相比预测性能越好。一般情况下，skill 值在 0.8 左右时是最理想也是最现实的状态，此时该算法有一定的工程应用价值。

A、B 类天气预测值与实际值的均方根误差 (RMSE) 以及 skill 值见表 3。

表 3 A、B 类天气预测技能

日期	BP RMSE/%	PM RMSE/%	skill
12.16	14.01	82.52	0.83
12.17	12.55	78.48	0.84
12.18	12.96	80.47	0.84
12.19	10.54	56.38	0.81

由表 3 可以看出 12 月 16 日到 19 日四天的 skill 值均在 0.8 以上，表明该算法在 A、B 类天气时可以很好的对辐照度进行预测。

用上面的预测方法对 C、D 类天气的辐照度进行预测，效果不是很理想，因此将这两类天气单独提出，单独训练，同时通过改变隐含层数量，最终得到适合 C、D 类天气辐照度预测的各项参数值，结果如图 7。




图 7 C、D 类天气预测结果

图 7 中带圆圈的实线为辐照度的实际测量值，带三角的虚线为本文算法得到的辐照度预测值。从图中可以看到，C、D 类天气预测结果偏差略大。究其原因，主要为雨雪天气云层变化较为复杂，到达地面的太阳辐射瞬息万变，因此导致这类天气的辐照度预测准确性低，但从预测结果曲线可以看出，预测值与实际测量值的变化趋势基本保持一致，且峰值基本上出现在相同的时刻，因此 C、D 类天气时用该算法得到的预测值有一定的参考价值。C、D 类天气预测值与实际值的 RMSE 以及 skill 值见表 4。

表 4 C、D 类天气预测技能

日期	BP RMSE/%	PM RMSE/%	skill
02.11	14.43	65.46	0.78
03.05	23.22	78.11	0.70
03.07	28.92	63.03	0.54
03.20	35.85	86.24	0.58

从表 4 可以看出，在 C、D 类天气时 skill 值均在 0.5 以上。由于 A、B 类天气在该研究中所占的天数比重超过百分之七十五，因此为本文主要研究对象，由以上预测曲线和表格数据可以看出该模型在 A、B 类天气时具有良的预测效果，与 PM 相比均方根误差大幅度减小，同时 skill 值基本在 0.8~

0.85 之间; 在大雨雪天时预测值与实际测量值有一定的误差, 但整体趋势保持一致, 且 skill 值均在 0.5 以上。因此该优化模型在综合考虑实测温度数据和太阳高度角, 且没有考虑云量等复杂气象信息的条件下可以较好地预测 05:00 到 20:00 时每小时辐照度, 在实际的预测中, 历史辐照度值可以从数据库中调取, 温度数据根据设备所在地区相应气象站的天气预报信息即可, 不同时刻的太阳高度角根据第一小节的公式计算得出。

4 结论

本文运用多变量 BP 神经网络算法根据武汉市特有的地理位置特点, 将天气类型进行分类, 通过便于获取的实测温度数据和历史辐照度数据, 结合不同时刻的太阳高度角来对 05:00 到 20:00 时每小时辐照度进行预测。对得到的最终预测结果的分析可知, 采用该模型对每小时辐照度进行预测时, A、B 类天气 skill 值在 0.80~0.85 之间, 预测效果良好; 若天气情况复杂, 由于云层变化迅速且很难预测, 则导致预测结果与实际值之间有一定的误差, 但整体趋势一致。考虑到本研究阶段 A、B 类天气所占比重较大, 对此两类天气情况下辐照度的预测精度高, 算法的输入变量获取便捷, 算法简单, 因此该模型可以较好的应用于光伏系统中辐照度的预测。

参考文献:

[1] 胥芳, 张任, 吴乐彬, 等. 自适应 BP 神经网络在光伏 MPPT 中的应用 [J]. 太阳能学报, 2012, 33 (3): 468-472.
[2] Amrouche B, Pivert X L. Artificial neural network based daily local

forecasting for global solar radiation [J]. Applied Energy, 2014, 130 (5): 333-341.
[3] Besharat F, Dehghan A A, Faghhi A R. Empirical models for estimating global solar radiation: A review and case study [J]. Renewable & Sustainable Energy Reviews, 2013, 21 (21): 798-821.
[4] Zhou H, Sun W, Liu D, et al. The Research of Daily Total Solar Radiation and Prediction Method of Photovoltaic Generation Based on Wavelet-Neural Network [A]. Asia-Pacific Power and Energy Engineering Conference [C]. IEEE Computer Society, 2011: 1-5.
[5] Zhang P, Takano H, Murata J. Daily solar radiation prediction based on wavelet analysis [A]. Sice Conference [C]. 2011: 712-717.
[6] Mohammadi K, Shamshirband S, Tong C W, et al. A new hybrid support vector machine-wavelet transform approach for estimation of horizontal global solar radiation [J]. Energy Conversion & Management, 2015, 92 (3): 162-171.
[7] Wang S, Liu C, Li Q. On the use of niching genetic algorithms for variable selection in solar radiation estimation [J]. Renewable Energy, 2013, 50 (3): 168-176.
[8] 钱允祺. 关于任意纬度太阳高度角的查算 [J]. 气象, 1978 (10): 31-33.
[9] 王飞, 米增强, 杨奇逊, 等. 基于神经网络与关联数据的光伏电站发电功率预测方法 [J]. 太阳能学报, 2012, 33 (7): 1171-1177.
[10] 米增强, 王飞, 杨光, 等. 光伏电站辐照度 ANN 预测及其二维变尺度修正方法 [J]. 太阳能学报, 2013, 34 (2): 251-259.

(上接第 180 页)




图 5 剩余飞行时间估计误差

有良好的跟踪性能; 利用 EKPF 算法估计结果计算出的剩余飞行时间达到了较高的估计精度, 实现了剩余飞行时间估计的目的, 为制导引信一体化技术实现自适应起爆控制功能提供了条件。

参考文献:

[1] 苏志谋, 简金蕾, 任宏滨, 等. 基于制导引信一体化的自适应起爆控制 [J]. 导弹与航天运载技术, 2012 (3): 47-51.
[2] 刘斌, 樊养余. 制导引信一体化技术及其典型应用 [J]. 航空兵器, 2006 (6): 33-36.

[3] 孙博, 栗金平, 郑建强, 等. 防空导弹红外成像制导引信一体化应用研究 [J]. 弹箭与制导学报, 2013 (2): 57-60.
[4] 温银放, 王琼. 空空导弹制导引信一体化信息融合技术研究 [J]. 计算机仿真, 2016 (4): 67-70.
[5] 刘剑锋, 庄志洪. 利用导引头测角信息进行遭遇段剩余飞行时间估计的算法 [J]. 兵工学报, 2006 (1): 27-31.
[6] Caglar Yardim, Peter Gerstoft, William S. Tracking Refractivity from Clutter Using Kalman and Particle Filters [J]. IEEE Transactions on Antennas and Propagation, 2008, 56 (4): 1058-1070.
[7] 汤晓云, 樊小景, 李朝伟. 相控阵雷达导引头综述 [J]. 航空兵器, 2013 (6): 25-30.
[8] Howard D D. Radar Target Glint in Tracking and Guidance System Based on Echo Signal Phase Distortion [J]. Proc. NEC, 1959, 15: 840-849.
[9] 朱志宇. 粒子滤波算法及其应用 [M]. 北京: 科学出版社, 2010.
[10] 单甘霖, 周云峰. 一种改进的不敏粒子滤波算法 [J]. 系统仿真学报, 2010 (10): 2287-2290.
[11] 周宏仁, 敬忠良, 王培德. 机动目标跟踪 [M]. 北京: 国防工业出版社, 1991.
[12] Zhou H R, Kumar K S P. A current statistical model and adaptive algorithm for estimating maneuvering targets. AIAA Journal of Guidance, 1984; 7 (5): 596-602.
[13] 何友, 王国宏, 陆大劲, 等. 多传感器信息融合及应用 [M]. 北京: 电子工业出版社, 2010.
[14] 徐琰珂, 梁晓庚, 贾晓洪. 雷达/红外双模导引头信息融合算法研究 [J]. 计算机测量与控制, 2013, 21 (1): 129-132.