

基于 AOD 估计的晴空太阳辐射强度滚动预测

刘卫亮, 刘长良, 林永君, 李 静, 熊 峰, 李金拓

(华北电力大学新能源电力系统国家重点实验室, 保定 071003)

摘 要: 针对工程实际中大气气溶胶光学厚度(AOD)参数难以实时获取的问题,首先基于地面空气质量监测站点的PM浓度数据以及气温、空气相对湿度等气象数据,采用BP神经网络方法建立AOD估计模型;然后选取AOD与可降水量为主要变化参数,对多波段大气辐射传输计算模型REST2进行简化;最后基于实时发布的PM浓度信息以及精细天气预报信息,利用简化的REST2模型对晴空太阳辐射强度进行滚动预测。实验结果表明,所提出的晴空太阳辐射强度滚动预测方法具有较高精度,且易于工程实现。

关键词: 太阳辐射强度; 气溶胶光学厚度; PM浓度; BP神经网络; 辐射传输模型

中图分类号: TM464

文献标识码: A

0 引 言

太阳辐射强度的预测对于开展太阳能资源的评估及利用有着重要意义。已有的预测方法可分为统计预测方法以及基于大气辐射传输模型的物理预测方法。相对于统计预测方法,物理预测方法具有计算直观、不依赖于历史数据的优点,但其预测精度受模型参数的影响较大^[1]。

大气气溶胶光学厚度(aerosol optical depth, AOD)是大气辐射传输模型中最重要的参数,用于描述气溶胶对光的衰减作用,其获取方式有卫星观测方式与地基观测方式^[2]。卫星观测方式指基于遥感卫星搭载的中分辨率成像光谱仪(MODIS)监测数据反演AOD,受卫星过境时间与数据发布周期影响,反演的实时性较差,且精度不高;地基观测方式指通过地基观测站点的多波段光度计测量数据反演AOD,反演精度较卫星观测方式高,但是光度计的标定工作颇为复杂,且已建成的地基观测站点较少。因此,如何实时、准确而又便捷的获取AOD,成为太阳辐射强度物理预测方法应用的关键问题。

近年来,中国出现大范围的雾霾天气。雾和霾分别指悬浮于大气中的细微水滴和灰尘颗粒,是大气气溶胶的重要组成部分。2012年,国家环保部环境空气监测网络开始实时发布空气质量指数(air

quality index, AQI)以及PM₁₀浓度、PM_{2.5}浓度等6项分指数的监测数据,至今已设置国家、省、市、县4个层级共5000余个空气质量监测站点。国家环保部还建立了全国重点区域及主要城市空气质量预测预报系统,并于2016年1月1日起,正式向社会发布空气质量预测预报信息。

同时,出于地面大气质量形势分析和预测目的,有不少学者开始利用卫星观测反演的AOD估算PM浓度。文献[3]在研究意大利北部PM₁₀浓度,指出MODIS AOD产品有应用在空气质量监测方面的潜力。Wang Jun等^[4]用美国阿拉巴马州地区的MODIS数据计算AOD,并和当地的PM_{2.5}浓度数据进行统计分析,证明它们之间具有良好的相关性。Liu Yang等^[5]则考虑边界层高度、气温等影响因素,建立线性回归模型对MISR AOD和MODIS AOD估算近地面PM_{2.5}浓度的能力进行比较。Koelemeijer等^[6]的研究进一步引入空气相对湿度等气象因子,得到了较高的MODIS AOD与PM₁₀浓度的相关系数。张文宗等^[7]将河北省11个城市地面监测站PM₁₀浓度与对应的AOD作相关分析,发现两者的相关系数达0.54。陈良富等^[8]通过对MODIS气溶胶光学厚度产品进行垂直订正和湿度订正,用来推算PM_{2.5}浓度和PM₁₀浓度,结果表明估算的PM_{2.5}浓度更加精确。郭建平^[9]考虑空气相

收稿日期: 2017-02-21

基金项目: 中央高校基本科研业务费专项资金(2016MS142; 2015ZD17); 北京市自然科学基金(4182061)

通信作者: 李 静(1979—), 女, 硕士、工程师, 主要从事光伏发电功率预测方面的研究。7536005@qq.com

对湿度、气温、边界层高度等多个影响因素,利用 BP 网络建立 $PM_{2.5}$ 浓度的估计模型。

综上所述,鉴于 PM 浓度与 AOD 具有较高的相关性,且已由覆盖颇为全面的空气质量监测站点向公众实时发布,本文尝试利用 PM 浓度以及气温、空气相对湿度等气象数据建立 AOD 的估计模型,进而基于大气辐射传输模型开展晴空天气下的太阳辐射强度滚动预测。

1 AOD 介绍及相关因素分析

1.1 AOD 介绍

大气气溶胶是指大气分子及悬浮在大气中的固体和液体微粒组成的多相体系,其粒径的尺度大小分布于 $0.001\sim 100\ \mu\text{m}$ 。AOD 的定义为大气介质的消光系数在垂直方向上从地表到大气层顶的积分,是描述气溶胶对光的衰减作用的无量纲物理量,其值越高表示气溶胶对光的衰减作用越强,大气能见度越低。

Ångström^[10]给出了波长 λ 对应的 AOD 的计算方式为:

$$\tau_{\lambda} = \beta \lambda^{-\alpha} \quad (1)$$

式中, β —— Ångström 浊度系数,与大气气溶胶的浓度有关; α —— Ångström 波长指数,与大气气溶胶中的粒径分布有关。

现阶段对于 AOD 的观测方式主要包括卫星观测方式和地基观测方式。卫星观测方式是指通过对 Terra 和 Aqua 这 2 颗卫星搭载的中分辨率成像光谱仪(MODIS)监测数据进行反演获取 AOD,存在反演精度不高的缺点,另外,受卫星的过境时间限制,对于地面上的某一位置,一般仅能获取其某一特定时间段的 AOD,且数据发布存在一定的滞后周期。地基观测方式是指通过 NASA 和 LOA-PHOTONS 联合建立的全球地基气溶胶遥感自动观测网(AERONET)获取 AOD,该网络在全球共布设了多个站点,使用多波段太阳光度计的长期观测数据反演 AOD,反演精度较卫星观测方式高,但光度计需定期标定,过程颇为复杂。另外,我国布设的 AERONET 地基观测站点较为稀疏,且所发布的 AOD 仅适用于本地局部地区。

1.2 AOD 相关因素分析

PM_{10} (可吸入颗粒物)、 $PM_{2.5}$ (细颗粒物)分别指

空气动力学当量直径小于等于 $10\ \mu\text{m}$ 与小于等于 $2.5\ \mu\text{m}$ 的颗粒物,能较长时间悬浮于空气中,对空气质量与能见度有重要的影响。 PM_{10} 浓度、 $PM_{2.5}$ 浓度与 AOD 与有着较强的相关性,已有研究在利用 AOD 推算地面的 PM_{10} 浓度、 $PM_{2.5}$ 浓度时,通常还需要考虑空气相对湿度、边界层高度、气温等多个因素的影响。

1) 空气相对湿度

空气相对湿度可改变气溶胶粒子的大小、形态和消光特性,从而影响 AOD 的大小。目前地面空气质量监测站点提供的 PM_{10} 浓度、 $PM_{2.5}$ 浓度为经过 $50\ ^\circ\text{C}$ 高温烘干后的颗粒物质量浓度。因此,在分析 AOD 与 PM 浓度的关系时,已有研究多通过湿度影响因子对 PM_{10} 浓度、 $PM_{2.5}$ 浓度进行订正。常见湿度影响因子模型有单参数模型、双参数模型以及可反映颗粒物潮解点的散射吸湿增长因子模型^[11]。由于上述湿度影响因子模型及其模型参数均针对特定的区域和气溶胶化学组成,通用性较差。

2) 边界层高度

边界层高度是影响气溶胶在边界层内混合和分布情况的关键参数,其值越低,则气溶胶越集中于近地面,使得 AOD 和 PM 浓度相关性越好。在大气气溶胶粒子浓度随高度指数下降的假定下,气溶胶标高反映了大气边界层气溶胶的特征厚度。因此,分析 AOD 和 PM 浓度的关系时,边界层高度可近似取为气溶胶标高。

3) 气温

气温不仅对大气边界层高度、大气稳定度等大气污染扩散条件有重要影响,同时对气溶胶颗粒的干湿状态、半挥发性组分存在状态以及“气—粒”转换光化学进程有一定影响,进而影响 PM 浓度与 AOD 相关关系。

考虑 AOD 与 PM 浓度之间的关系受上述多个因素影响,进行精确的机理分析较为困难,本文通过采集大量样本,利用神经网络方法建立 AOD 的估计模型。

2 基于 BP 神经网络的 AOD 估计模型

BP 神经网络为基于误差反向传播算法的多层前馈神经网络,其特点为网络学习分为正向传播输出和反向传播调整 2 个过程,具有强大的非线性映

射能力与较好的泛化能力,因而得到广泛应用。

2.1 BP神经网络结构

选取 t 时刻的 PM_{10} 浓度 $C_0(t)$ 、 $\text{PM}_{2.5}$ 浓度 $C_1(t)$ 、空气相对湿度 $R(t)$ 、气溶胶标高 $H(t)$ 、气温 $T(t)$ 作为输入变量,以 t 时刻的 440 nm 波长的 $\text{AOD}\tau_{440}(t)$ 与 1020 nm 波长的 $\text{AOD}\tau_{1020}(t)$ 作为输出变量,建立一个含 5 个输入神经元、 N 个隐含神经元、2 个输出神经元的 3 层 BP 神经网络,结构如图 1 所示。




图1 AOD估计模型的BP神经网络结构

Fig. 1 BP neural network structure of AOD estimation model

2.2 训练数据来源

1) AOD

AOD 数据取自于 AERONET 北京观测站点(地理坐标为 $116.583^\circ \text{E}/39.783^\circ \text{N}$),其质量等级为 Level 1.5,已进行过云处理,因此可视为 AOD 的真值。

2) PM 浓度

$\text{PM}_{2.5}$ 浓度与 PM_{10} 浓度数据取自北京朝阳奥体中心空气质量监测站,该站点距 AERONET 北京观测站点约为 1.2 km。中国空气质量在线监测分析平台网站 (<https://www.aqistudy.cn>) 可进行数据下载。

3) 气温与相对空气湿度

气温与相对空气湿度数据取自北京市,通过中国空气质量在线监测分析平台网站进行查询。

4) 气溶胶标高

气溶胶标高的变化主要受季节影响,对于华北地区,气溶胶标高取春、夏、秋、冬季的季均值,分别为 2.864、3.298、2.284 和 $1.597 \text{ km}^{[12]}$ 。

以上训练数据的采样时间范围为 2015 年 1 月 1 日~2016 年 8 月 31 日,筛选其中的晴空天气,共获得训练数据 1858 组,其中,随机抽取其中的 1703 组作为网络训练样本,其余 155 组作为网络检验样本。

2.3 模型训练

通过 Matlab 神经网络工具箱进行所建 BP 神经网络模型的训练,主要包括数据归一化处理、隐含层神经元数量确定以及训练精度检验等步骤。

1) 数据归一化处理

由于 BP 神经网络的多个输入变量取值范围有较大差异,需要对各输入变量进行归一化处理,以消除数据量纲。本文对所有输入变量取值范围归一化至 $[-1, +1]$,采用的归一化公式为:

$$v_{\text{norm}} = 2 \times \frac{v - v_{\min}}{v_{\max} - v_{\min}} - 1 \quad (2)$$

式中, v 、 v_{norm} ——归一化前后的变量; v_{\max} 、 v_{\min} ——变量 v 的最大值与最小值。

2) 隐含层神经元数量确定

根据经验公式,隐含层神经元数量 N 通常取值为 8~15 之间为宜。本文采用试探方法对 N 的取值进行确定:对于 N 的某一取值,设置隐含层神经元以及输出层神经元的激励函数分别为 tansig 函数和 logsig 函数,随机初始化网络权值和阈值,取迭代次数为 30000 次,采用 traingdx 学习函数在训练样本上重复训练 10 次,并计算 10 次训练结果的均方误差 (MSE) 平均值,如表 1 所示,以所得 MSE 平均值最小为准则,确定隐含层神经元数量为 14。

表1 取不同隐含层神经元数量的模型训练结果

Table 1 Model training results for different number of hidden layer neurons

N	8	9	10	11	12	13	14	15
MSE 平均值 $\times 10^{-2}$	7.07	7.01	6.70	6.71	7.07	7.42	6.64	6.70

3) 精度检验

设置精度目标为 $MSE=6 \times 10^{-2}$,对 BP 神经网络模型进行重新训练,迭代过程的 MSE 曲线如图 2 所示,经过 58462 次迭代后,训练结束,模型在训练样

本上的估计结果如图 3 所示,可知,模型对 440 nm 波长 AOD 与 1020 nm 波长 AOD 的估计结果在趋势上均与 AOD 的真值具有较高的一致性,说明模型对训练样本具有较好的拟合能力。




图2 迭代过程均方误差曲线

Fig. 2 Mean square error curve of iteration process




图3 模型在训练样本上的估计结果

Fig. 3 Model estimation results on training samples

为验证模型的泛化能力,计算其在检验样本上的绝对误差,如图4所示。可知模型在1020 nm波长AOD检验样本上的平均绝对误差为0.1222,其中绝对误差小于0.2的检验样本数量占检验样本总数的87.7%;模型在440 nm波长AOD检验样本的平均绝对误差为0.2185,其中绝对误差小于0.3的




图4 模型在检验样本上的估计结果

Fig. 4 Model estimation results on test samples

检验样本数量占检验样本总数的81.9%,这说明所建立的BP神经网络AOD估计模型具有良好的泛化能力以及较高的估计精度。

3 REST2模型简化及精度验证

已出现的大气辐射传输模型主要有Bird模型、CPC2模型、REST2模型等,适合于计算晴空条件下的太阳辐射强度^[13]。Gueymard等^[14,15]的研究工作表明,与CPC2等模型相比,REST2模型具有更高的精度。

3.1 REST2模型简化

REST2模型分别计算波段1(0.29~0.70 μm)与波段2(0.7~4.0 μm)的太阳直射辐射强度和散射辐射强度,所涉及的参数较多,包括气溶胶光学厚度AOD τ_a 、可降水量 w 、臭氧浓度 u_o 、二氧化氮浓度 u_n 等。其中,气溶胶光学厚度AOD τ_a 与可降水量 w 是影响大气传输辐射最为重要的2个参数^[16]。考虑到臭氧浓度 u_o 、二氧化氮浓度 u_n 等参数对模型的影响较小,为便于计算,本文对它们的影响予以忽略,则简化后的REST2模型的直射辐射强度计算公式为:

$$\begin{cases} E_{bn} = E_{bn1} + E_{bn2} \\ E_{bni} = T_{ai} T_{wi} T_{Ri} E_{oni} \end{cases} \quad (3)$$

式中, E_{bn} ——总直射辐射强度; E_{bni} ——波段 i 直射辐射强度, $i=1,2$; E_{oni} ——波段 i 大气层外直射辐射强度,且有 $E_{on1}=635.4 \text{ W/m}^2$, $E_{on2}=709.7 \text{ W/m}^2$; T_{ai} ——波段 i 气溶胶传输衰减系数,计算公式为:

$$T_{ai} = \exp(-m_a \tau_{ai}) \quad (4)$$

T_{wi} 为波段 i 可降水量衰减系数,计算公式为:

$$T_{w1} = (1 + h_1 m_w) / (1 + h_2 m_w) \quad (5)$$

$$T_{w2} = (1 + c_1 m_w + c_2 m_w^2) / (1 + c_3 m_w + c_4 m_w^2) \quad (6)$$

T_{Ri} 为波段 i 雷利系数,各波段计算公式为:

$$T_{R1} = \frac{(1 + 1.8169 m_R' - 0.033454 m_R'^2)}{(1 + 2.063 m_R^2 + 0.31978 m_R'^2)} \quad (7)$$

$$T_{R2} = (1 - 0.010394 m_R') / (1 - 0.00011042 m_R'^2) \quad (8)$$

以上式中参数 m_a 、 h_1 、 h_2 、 m_w 、 c_1 、 c_2 、 c_3 、 c_4 、 m_R' 详见文献[14,15]。

简化后的REST2模型的散射辐射强度计算公式为:

$$\begin{cases} E_d = E_{d1} + E_{d2} \\ E_{di} = E_{dpi} + E_{ddi} \\ E_{dpi} = T_{wi}[B_{Ri}(1 - T_{Ri})T_{ai}^{0.25} + B_a F_i T_{Ri}(1 - T_{asi}^{0.25})]E_{0i} \quad (9) \\ E_{0i} = E_{0ni} \cos Z \\ E_{ddi} = \rho_{gi} \rho_{si} (E_{bi} + E_{dpi}) / (1 - \rho_{gi} \rho_{si}) \end{cases}$$

式中, E_d ——总散射辐射强度, $i=1, 2$; E_{bi} ——波段 i 散射辐射强度; E_{dpi} ——波段 i 入射散射强度分量; E_{ddi} ——波段 i 反向散射强度分量; B_a ——气溶胶前向散射因子; B_{Ri} ——波段 i 雷利衰减的前向散射因子; F_i ——波段 i 修正系数; T_{asi} ——波段 i 气溶胶散射系数; ρ_{gi} ——波段 i 地表反照率; ρ_{si} ——波段 i 天空反照率。以上参数取值详见文献[14,15]; Z ——太阳天顶角, 其计算方式为:

$$Z = \arccos(\sin \varphi \sin \delta + \cos \varphi \cos \delta \cos \theta_h) \quad (10)$$

式中, φ ——观测点纬度; δ ——赤纬角; θ_h ——太阳时角, 且有:

$$\delta = 23.45^\circ \times \sin\left(2\pi \times \frac{284 + d}{365}\right) \quad (11)$$

$$\theta_h = (12 - H_s) \times 15^\circ \quad (12)$$

式中, H_s ——太阳时; d ——一年中当日的序号。

在本文中, 波段 1 的 AOD τ_{a1} 与波段 2 的 AOD τ_{a2} 分别取自 BP 神经网络估计模型得出的 440 nm 波长的 AOD τ_{440} 与 1020 nm 波长的 AOD τ_{1020} , 可降水量 w 采用李超等^[17]提出的线性拟合模型计算, 即:

$$w = -0.518 + 0.177 \cdot SVP \quad (13)$$

式中, SVP ——地面水汽压, 可根据空气相对湿度与气温求得:

$$SVP = R \cdot e_{s0} \cdot 10^{\frac{aT}{b+T}} \quad (14)$$

式中, R ——空气相对湿度; e_{s0} ——0℃时的饱和水汽压, $e_{s0}=6.1078$ hPa, 经验系数 $a=7.5$, $b=237.3$; T ——气温。

3.2 太阳辐射强度计算及精度验证

计算得出直射辐射强度与散射辐射强度之后, 对于法线沿太阳直射方向的地表斜面, 其接收的总辐射强度为:


$$E_x = E_{bn} + \frac{1}{2} E_d (1 + \cos Z) \quad (15)$$

对于地表水平面, 其总辐射强度为:


$$E_g = E_{bn} \cos Z + E_d \quad (16)$$

为了评估所提简化 REST2 模型的计算精度, 需

采集太阳辐射强度实际数据进行对比验证。本文选取 2016 年 7~11 月之间的晴空天气, 以保定市华北电力大学二校区为实验地点, 利用 TES-1333R 型光度计开展了太阳辐射强度的手动测量, 其中, 光度计的布置方向始终对准太阳, 测量值即为沿太阳直射方向的总辐射强度; 考虑到中午时分的太阳辐射强度测量数据精度最高, 从中选出 65 组, 采集对应时刻华北电力大学二校区空气质量监测站的 PM_{2.5} 浓度、PM₁₀ 浓度数据以及中国天气网发布的空气相对湿度与气温数据, 利用所建立的 BP 神经网络模型估计 440 nm 波长与 1020 nm 波长的 AOD, 代入简化 REST2 模型, 并依据式(15)计算沿太阳直射方向的总辐射强度, 然后与实测数据进行对比, 如图 5 所示, 平均相对误差为 9.87%, 说明简化 REST2 模型具有较高的计算精度。



a. 太阳辐射强度计算结果



b. AOD 估计结果

图5 简化REST2模型的计算精度

Fig. 5 Calculation precision of simplified REST2 model

4 晴空天气下太阳辐射强度滚动预测

本文对晴空天气下的太阳辐射强度进行整点逐时滚动预测, 所采用预测方法的流程如图 6 所示。首先基于 BP 神经网络估计模型预测下一整点时刻的 AOD, 故需要以下一整点时刻的 PM_{2.5} 浓度、PM₁₀ 浓度、空气相对湿度、气温、气溶胶标高的预测值作为模型输入。考虑逐小时发布的 PM_{2.5} 浓度、PM₁₀ 浓度数据随时间变化较为缓慢, 且具有较强的自相关性^[18], 本文采用加权移动平均预测法计算下

一整点时刻的 $\text{PM}_{2.5}$ 浓度、 PM_{10} 浓度预测值,气溶胶标高的预测值通过季节判断取所在季度的平均值,空气相对湿度与气温的预测值取自 Accweather 公司的逐小时气象预报信息;同时,采用线性拟合模型预测可降水量;然后,利用简化的 REST2 模型分别预测直射辐射强度与散射辐射强度,从而预测地表总辐射强度。

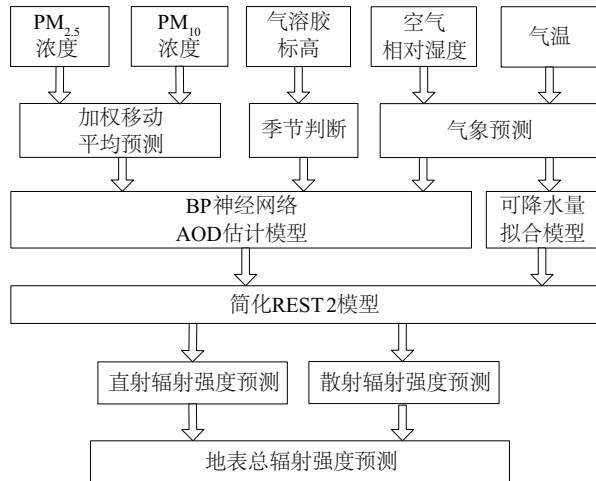


图6 预测方法流程图

Fig. 6 Flow chart of forecast method

加权移动平均预测法即对各期参数观测值赋予不同权重的移动平均预测方法。通常对近期参数观测值给予较大的权重,对较远的参数观测值给予较小的权重。给定移动跨度 N 以及各期参数观测值权重 w_N, w_{N-1}, \dots, w_1 , 已知预测时间点 $t+1$ 前 N 个时间点的观测值 $L_t, L_{t-1}, \dots, L_{t-N+1}$, 则可得出预测时间点 $t+1$ 的参数 L_{t+1} 预测值为:


$$\hat{L}_{t+1} = \frac{\sum_{i=1}^N w_i L_{t-i+1}}{\sum_{i=1}^N w_i} \quad (17)$$

本文取移动跨度 $N=2$, 参数观测值权重 $w_1=0.2, w_2=0.8$ 。


5 实验验证

为了验证所提太阳辐射强度滚动预测方法的精度,仍以保定市华北电力大学二校区为研究地点,选择晴朗无云的 2016 年 12 月 14 日(空气质量为优)以及 12 月 16 日(空气质量为重度污染),对 09:00~15:00 各整点时刻沿太阳直射方向的总辐射强度进行逐时滚动预测,并与 TES-1333R 型光度计

实测数据进行对比,如图 7 所示。由图 7 可知,由于距离冬至日(2016 年 12 月 21 日)较近,太阳天顶角较大,14 日与 16 日的太阳辐射强度整体上较低。由于 14 日的空气质量好,AOD 数值小,其太阳辐射强度明显高于雾霾严重的 16 日。另外,在早晚时分,由于大气质量(AM)数值大,雾霾天气对太阳辐射强度的削弱影响最为显著,使得 14 日与 16 日对应时刻的太阳辐射强度之差较大;在中午时分,大气质量(AM)数值小,雾霾天气对太阳辐射强度的影响较早晚时分要小,因而 14 日与 16 日对应时刻的太阳辐射强度之差较小。计算 14 日与 16 日的太阳辐射强度预测的平均相对误差,为 11.5%,说明所提晴空天气下的太阳辐射强度滚动预测方法具有较高的精度。



a. 太阳辐射强度预测结果



b. PM 浓度

图7 太阳辐射强度逐时滚动预测实验

Fig. 7 Hourly rolling forecast test of solar radiation intensity

6 结 论

1) 基于 $\text{PM}_{2.5}$ 浓度、 PM_{10} 浓度、空气相对湿度、气温、气溶胶标高数据以及地基观测 AOD 数据,利用 BP 神经网络建立了 AOD 估计模型,实验结果表明该模型具有较高的估计精度。由于 BP 神经网络的训练精度受样本数量以及训练目标、隐含层节点数、学习函数、激励函数等多个因素影响,在将来可基于更多的数据积累,继续优化 BP 神经网络模型的训练过程,以进一步提高 AOD 的估计精度。

2) 基于 PM 浓度预测以及精细天气预报信息,

采用建立的 AOD 估计模型与 REST2 简化模型对晴空天气下的太阳辐射强度进行滚动预测,具有较高的预测精度,且易于工程实现。本文的下一步工作是在预测方法中考虑将云量这一影响因素,从而实现有云天气下的太阳辐射强度滚动预测。

[参考文献]

- [1] 龚莺飞, 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—151.
- [1] Gong Yingfei, Lu Zongxiang, Qiao Ying, et al. An overview of photovoltaic energy system output forecasting technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140—151.
- [2] 牛峰, 李成才, 毛节泰. 利用TERRA和AQUA共同反演陆地上空的气溶胶光学厚度[J]. 遥感学报, 2006, 10(4): 456—462.
- [2] Niu Feng, Li Chengcai, Mao Jietai. A synergic application of TERRA and AQUA on retrieving aerosol optical depth overland[J]. Journal of Remote Sensing, 2006, 10(4): 456—462.
- [3] Chu D A, Kaufman Y J, Zibordi G, et al. Global monitoring of air pollution over land from the Earth Observing System-Terra Moderate Resolution Imaging Spectroradiometer (MODIS)[J]. Journal of Geophysical Research, 2003, 108: 21.
- [4] Wang Jun, Christopher S A. Intercomparison between satellite-derived aerosol optical thickness and PM_{2.5}: implications for air quality studies[J]. Geophysical Research Letters, 2003, 30(21): 2095—2098.
- [5] Liu Yang, Franklin M, Kahn R, et al. Using aerosol optical thickness to predict ground-level PM_{2.5} concentrations in the St. Louis area: A comparison between MISR and MODIS[J]. Remote Sensing of Environment, 2007, 107(1-2): 33—44.
- [6] Koelemeijer R B A, Homan C D, Matthijsen J. Comparison of spatial and temporal variations of aerosol optical thickness and particulate matter over Europe[J]. Atmospheric Environment, 2006, 40(27): 5304—5315.
- [7] 张文宗, 赵春雷, 李二杰. 利用MODIS遥感监测PM₁₀的方法研究[J]. 河北遥感, 2009, (3): 6—8.
- [7] Zhang Wenzong, Zhao Chunlei, Li Erjie. Study on the method of PM₁₀ monitoring by MODIS remote sensing[J]. Remote Sensing of Hebei, 2009, (3): 6—8.
- [8] 陈良富, 陈水森, 钟流举, 等. 卫星数据和地面观测结合的珠三角地区颗粒物浓度统计估算方法[J]. 热带地理, 2015, 35(1): 7—12.
- [8] Chen Liangfu, Chen Shuisen, Zhong Liuju, et al. Statistic method of particulate matter concentration based on the satellite observations combining with ground measurements in PRD[J]. Tropical Geography, 2015, 35(1): 7—12.
- [9] 郭建平, 吴业荣, 张小曳, 等. BP网络框架下MODIS气溶胶光学厚度产品估算中国东部PM_{2.5}[J]. 环境科学, 2013, 34(3): 817—825.
- [9] Guo Jiangping, Wu Yerong, Zhang Xiaoye, et al. Estimation of PM_{2.5} over eastern china from MODIS aerosol optical depth using the back propagation neural network[J]. Environmental Science, 2013, 34(3): 817—825.
- [10] Ångström A. The parameters of atmospheric turbidity[J]. Tellus, 1964, 16(1): 64—75.
- [11] 朱于红. MODIS C006气溶胶产品评估及其在省域大气污染数据研究中的应用[D]. 杭州: 浙江大学, 2015.
- [11] Zhu Yuhong. Evaluation of MODIS aerosol product collection 006 and its application to air pollution research in Zhejiang Province[D]. Hangzhou: Zhejiang University, 2015.
- [12] 成贺玺, 王卫, 杜玮璐, 等. 河北省气溶胶标高时空变化及其成因[J]. 环境科学研究, 2015, 28(2): 190—197.
- [12] Cheng Hexi, Wang Wei, Du Weilu, et al. Simulation of temporal and spatial variations and causes of aerosol scale height in Hebei province[J]. Research of Environmental Sciences, 2015, 28(2): 190—197.
- [13] 张海龙, 刘高焕, 姚玲, 等. 复杂地形任意天气情形下太阳直接辐射量模拟[J]. 中国沙漠, 2010, 30(6): 1469—1476.
- [13] Zhang Hailong, Liu Gaohuan, Yao Ling, et al. Direct solar radiation simulation in all-weather and complex terrain conditions[J]. Journal of Desert Research, 2010, 30(6): 1469—1476.
- [14] Gueymard C A. REST2: High-performance solar radiation model for cloudless-sky irradiance, illuminance, and photosynthetically active radiation—Validation with a benchmark dataset[J]. Solar Energy, 2008, 82(3): 272—285.
- [15] Gueymard C A. Direct solar transmittance and irradiance predictions with broadband models. Part I: detailed theoretical performance assessment[J]. Solar

- Energy, 2003, 74(5): 355—379.
- [16] Zhong Xiaohui, Kleissl J. Clear sky irradiances using REST2 and MODIS [J]. Solar Energy, 2015, 116: 144—164.
- [17] 李 超, 魏合理, 刘厚通, 等. 整层大气水汽含量与地面水汽压相关性的统计研究[J]. 武汉大学学报: 信息科学版, 2008, 33(11): 1170—1173.
- [17] Li Chao, Wei Heli, Liu Houtong, et al. Statistics of correlation of integrated water vapor and surface vapor pressure [J]. Journal of Wuhan university: Geomatics and Information Science, 2008, 33(11): 117—1173.
- [18] 余 辉, 袁 晶, 于旭耀, 等. 基于ARMAX的PM_{2.5}小时浓度跟踪预测模型[J]. 天津大学学报: 自然科学与工程技术版, 2017, 50(1): 105—111.
- [18] Yu Hui, Yuan Jing, Yu Xuyao, et al. Tracking prediction model for PM_{2.5} hourly concentration based on ARMAX [J]. Journal of Tianjin University: Science and Technology, 2017, 50(1): 105—111.

ROLLING FORECAST OF SOLAR RADIATION INTENSITY IN CLEAR SKY BASED ON AOD ESTIMATION

Liu Weiliang, Liu Changliang, Lin Yongjun, Li Jing, Xiong Feng, Li Jintuo

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources,
North China Electric Power University, Baoding 071003, China)

Abstract: Atmospheric aerosol is one of the most important factors that cause the random variation of solar radiation intensity. Firstly, focus on the issues that the atmospheric aerosol optical depth (AOD) is difficult to obtain real-time with high accuracy, BP neural network method is adopted to establish the AOD estimation model based on PM concentration, air temperature and air relative humidity that from air quality monitoring stations; then, take AOD and precipitable water as main change parameters, atmospheric radiative transfer multi-band model REST2 is simplified; at last, rolling forecast of solar radiation intensity in clear sky is implemented based on real-time PM concentration as well as fine weather forecast information. Experimental results show that the proposed rolling forecast method for solar radiation intensity is of high precision and easy to be realized.

Keywords: solar radiation intensity; aerosol optical depth; particulate matter; BP neural network; radiative transfer model