

文章编号: 1672-6987(2019)05-0112-07; DOI: 10.16351/j.1672-6987.2019.05.017

# 基于 Elman 神经网络的日总辐射曝辐量预估

邹丽萍<sup>1</sup>, 宫响<sup>1,2\*</sup>, 庄述鹏<sup>1</sup>

(1. 青岛科技大学 数理学院, 山东 青岛 266061; 2. 中国海洋大学 环境科学与工程学院, 山东 青岛 266100)

**摘要:** 太阳辐射的预估研究对太阳能资源的有效利用有重要意义。应用山东省福山、莒县、济南三所气象站 2000—2003 年的数据, 建立 Elman 神经网络模型, 对日总辐射曝辐量进行时间序列预估研究。结果表明: Elman 神经网络预估效果受天气状况影响较大, 晴好天气下日总辐射预估结果较精确, 福山站预估与观测差值最小, 范围在  $-2 \sim 2 \text{ MJ} \cdot \text{m}^{-2}$ 。城市大气污染对日曝辐量影响比较显著, 模型中不考虑大气污染因素, 污染较重的济南市预估效果最差, 平均百分比误差变大了 20%, 均方根误差变大 7%。Elman 神经网络模型预估结果优于广义回归神经网络模型结果, 3 个站平均百分比误差降低 5%~18%, 均方根误差平均减小了  $0.506 \text{ MJ} \cdot \text{m}^{-2}$ 。Elman 神经网络模型适应于山东省日总辐射曝辐量的长时间预估。

**关键词:** Elman 神经网络; 日总辐射曝辐量; 大气污染; 气溶胶光学厚度

中图分类号: TP 181 文献标志码: A

引用格式: 邹丽萍, 宫响, 庄述鹏. 基于 Elman 神经网络的日总辐射曝辐量预估[J]. 青岛科技大学学报(自然科学版), 2019, 40(5): 112-118.

ZOU Liping, GONG Xiang, ZHUANG Shupeng. Estimate of daily irradiation exposure of global radiation using Elman neural network[J]. Journal of Qingdao University of Science and Technology(Natural Science Edition), 2019, 40(5): 112-118.

## Estimate of Daily Irradiation Exposure of Global Radiation Using Elman Neural Network

ZOU Liping<sup>1</sup>, GONG Xiang<sup>1,2</sup>, ZHUANG Shupeng<sup>1</sup>

(1. College of Mathematics and Physics, Qingdao University of Science and Technology, Qingdao 266061, China;  
2. College of Environmental Science and Technology, Ocean University of China, Qingdao 266100, China)

**Abstract:** Using the data of three meteorological stations at Fushan, Juxian and Jinan, 2000—2003, the Elman neural network model was established to estimate the daily total radiation exposure. The results of Elman neural network was greatly affected by the weather conditions, and the estimated daily total radiation exposure under the clear weather was more accurate than that in other weathers. The difference between the estimated and observed daily total radiation exposure was smallest at Fushan stations among the three meteorological stations, ranging from  $-2$  to  $2 \text{ MJ} \cdot \text{m}^{-2}$ . The urban air pollution has a significant impact on the daily total radiation exposure. If not considering the factors of air pollution in our model, both mean percentage error and root mean square error increased, especially at Jinan station (by 20%, 7%, respectively). Our results also showed that, compared with the the

收稿日期: 2018-10-09

基金项目: 国家自然科学基金项目(41406010)

作者简介: 邹丽萍(1992—), 女, 硕士研究生。\* 通信联系人。

generalized regression neural network model, the average percentage error decreased by 5%—18%, and the root mean square error decreased by  $0.506 \text{ MJ} \cdot \text{m}^{-2}$  on average at the three meteorological stations. The Elman neural network model is better to estimate the daily total radiation exposure than the generalized regression neural network model. Elman neural network model is suitable for Shandong province radiation exposure to long-term projections.

**Key words:** Elman neural network; daily total radiation exposure; air pollution; aerosol optical depth

太阳能作为一种新能源,是人类可以利用的最丰富、洁净的能源。太阳辐射的预估研究对太阳能资源的有效利用有重要意义。目前,我国大部分地区太阳辐射观测站的数目相对较少,且分布不均匀,而无法满 足科研及工程上的应用,因此建立太阳总辐射估算模型,预测太阳总辐射量尤为重要。太阳辐射量与许多环境参数有关,如气温、气压、日照、降水、大气污染程度等,且这些环境参数与太阳辐射量之间是复杂的非线性关系。如,大气污染程度加剧,除直接影响太阳辐射量,也可能使得日照时数减少,进而导致太阳辐射量降低;而降水量增大,可通过清洁大气影响太阳辐射量,但同时日照时数也减少,太阳辐射量随之降低。神经网络能够以任意精度逼近任何复杂的非线性映射,目前很多学者都在运用神经网络对太阳总辐射进行预估研究。BOSEHA 等<sup>[1]</sup>建立了基于人工神经网络的全球太阳辐射预测模型,应用内华达山脉国家公园北面的 12 个不同站点的 3 天辐射数据对模型结果进行了实例分析,结果指出人工神经网络是一种高效简便的方法,可应用于复杂地形区域的太阳辐射量预测。LAM 等<sup>[2]</sup>建立了预计气候区域人工神经网络模型,使用中国不同气候带 40 个观测站的日照时数观测数据进行实验,结果表明人工神经网络模型可用于估计仅有日照时数参数的各个区域的太阳辐射量。王卫东等<sup>[3]</sup>应用 BP 神经网络模型预测了兰州市 1996—2000 年的日太阳总辐射月均值,结果表明预测结果与实际观测结果拟合度较好,BP 神经网络模型可以运用到无辐射观测地区的太阳辐射预测中,但该模型对于地形较为复杂地区太阳辐射的预测精度有待提高。朱良山等<sup>[4]</sup>建立了基于 LM\_BP 神经网络的总辐射日曝辐量计算模型,对澳门气象站 2002—2009 年总辐射日曝辐量进行了预测,计算结果精度较高,能较为合理的反应太阳辐射量与各因子之间的关系。庄述鹏等<sup>[5]</sup>采用广义回归神经网络模型 (GRNN)对山东烟台市福山气象站 2000—2003 年日总辐射曝辐量进行预估,并将模型结果与 LM-BP

神经网络模型的预估结果进行对比,发现 GRNN 网络适用于烟台市福山站日总辐射曝辐量的预估。Elman 神经网络是具有局部记忆单元和局部反馈连接的递归神经网络,其特点是通过存储内部状态使其具备映射的动态特征功能,从而使系统具有适应时变特性的能力。王中凯等<sup>[6]</sup>以吉林省中部某平原区降水入渗补给的多年动态变化为例,建立了 Elman 神经网络动态预测模型,结果表明:该模型的预测精度较高,且能够反映该地区降水入渗补给的周期性变化特征。本研究尝试建立 Elman 神经网络模型,对山东省日总辐射曝辐量的时间序列进行预估,并对比了 Elman 神经网络与 GRNN 的预估结果,讨论了城市大气污染程度对日总辐射曝辐量的影响。

## 1 数据与方法

### 1.1 数据选取

本研究选取了山东省福山、莒县、济南气象站 2000—2003 年的太阳日辐射曝辐量观测数据,运用 Elman 神经网络模型对这三个气象站的日总辐射曝辐量进行了预估。Elman 神经网络输入量的确定参考相关文献<sup>[4-5]</sup>,包含日照时数、日平均气压、日平均气温、日最高气温、日相对湿度以及气溶胶光学厚度 6 个变量,输出量为日总辐射曝辐量。其中,日照时数、日平均气压、日平均气温、日最高气温、日相对湿度及日辐射曝辐量数据均来自中国气象数据网。气溶胶光学厚度 (aerosol optical depth, AOD) 用于表征城市大气污染程度,其数据来自 MODIS 遥感数据。2000 年 1、2 月的气溶胶光学厚度数据缺失,缺失的数据取 2001—2003 年 1、2 月 AOD 数据平均值代替缺失数据。

本研究分别选取 3 个气象站 2000 年 1 月至 2003 年 9 月 (共 1 461 d) 的实测总辐射日辐射曝量数据作为模型的训练数据,2003 年 10 月至 12 月 (120 d) 的实测数据作为模型的验证数据。

## 1.2 数据预处理

由于不同变量取值的量纲不同,为保证数据的数量级相一致,要对神经网络的输入数据和输出数据进行归一化处理。将所有数据归一化到 $[0, 1, 0.9]$ 范围内,以消除变量形式不同带来的不利影响。将数据按如下公式进行归一化处理:

$$y = 0.1 + \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (0.9 - 0.1). \quad (1)$$

其中: $x$ 为待归一化原始数据; $x_{\max}$ 和 $x_{\min}$ 分别为原始数据中最大值和最小值; $y$ 为归一化以后的数据。

## 1.3 Elman 神经网络模型

1990年,ELMAN提出了新的网络模型,将承接层添加到前馈式网络中,添加的承接层起到记忆的作用,这种模型被称为Elman神经网络<sup>[6]</sup>。Elman神经网络具有延时输入的反馈动力学系统;而模型中神经元状态发生变化的过程就是它学习的过程,当神经元的状态不再发生变化时,该模型便完成了学习。Elman神经网络与BP神经网络这类的静态反馈神经网络不同,Elman神经网络能够通过承接层单元来记忆隐含层前一时刻输出值并自联到隐含层的输入,从而能够更直接的反映系统的动态特性<sup>[7]</sup>。Elman网络在其隐藏层中具有Tansig神经元,在其输出层中具有Purelin神经元<sup>[8]</sup>。这种组合是特别的,因为具有这些传递函数的两层网络可以准确地预测任何数据(有限次数)。Elman神经网络的结构<sup>[9-10]</sup>如图1所示,相比于BP神经网络,Elman神经网络除了具有输入层、隐含层(中间层)和输出层以外,还有一个特有的承接层。起到信号传输作用的是输入层;起到线性加权作用的是输出层;承接层的作用是记录中间层前一刻的输出数值,并将它返还给网络;而中间层的连接与前馈式网络的连接相近<sup>[11-12]</sup>。

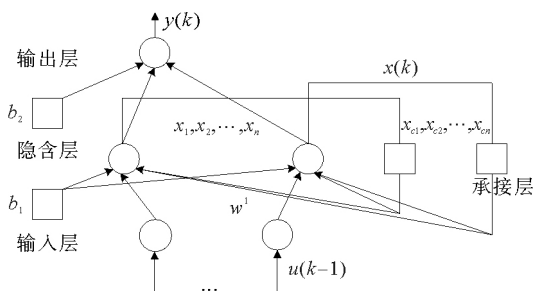


图1 Elman神经网络结构示意图

Fig.1 Structure of Elman neural network

图1中, $y$ 表示1维输出节点向量; $x$ 代表 $m$ 维隐含层节点单元向量; $u, x_c$ 分别是 $n$ 维输入向量和

$m$ 维反馈状态向量; $w^1, w^2$ 和 $w^3$ 分别表示承接与中间层间的权值、输入与中间层间的权值,及中间与输出层间的权值; $b_1, b_2$ 分别为输入层与隐含层中选择的阈值。

Elman神经网络中隐含层神经元的数目对整个网络的性能有较大影响,这种影响直接关系到预测的精度。若隐含层的神经元数量太少,那么网络可能无法进行全面的学习,导致网络输出结果误差增大。若隐含层神经元的数目太多,则会增加神经网络的复杂程度,不但会降低网络的学习速度,而且可能导致“过拟合”现象的产生。本研究根据下列公式来确定隐含层神经元的数目:

$$N_h = \sqrt{N_i + N_j} + a. \quad (2)$$

其中: $N_h$ 为隐含层节点数目, $N_i$ 为输入层节点数目, $N_j$ 为输出层的节点数目; $a$ 的取值范围通常为1~8之间的常数。多次训练模型,以误差达到最小值为选择目标,本研究建立的模型包含两个隐含层,两个隐含层节点数目都选取为14个。

## 1.4 模型评价指标

本研究采用了平均百分比误差(mean percentage error, MPE)和均方根误差(root mean square error, RMSE)2种评价指标对模型进行评估,其计算式为

$$MPE = \frac{1}{N} \sum_{i=1}^n \left( \frac{Q_{\text{sim},i} - Q_{\text{obs},i}}{Q_{\text{obs},i}} \times 100 \right), \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{\text{sim},i} - Q_{\text{obs},i})^2}{n}}. \quad (4)$$

其中: $n$ 为样本数据总数; $Q_{\text{sim},i}$ 为太阳辐射日曝辐量的预测值; $Q_{\text{obs},i}$ 为太阳辐射日曝辐量的观测值。

## 2 结果与分析

### 2.1 福山站 Elman 神经网络模型预估结果分析

Elman神经网络模型对福山站日总辐射曝辐量进行预估,实验结果与实际观测值之间的平均百分比误差如图2所示,平均百分比误差为18%,但其中日序号为2、25、40、85这4d平均百分比误差较大,均超过110%。通过对原始数据分析发现,这4d的日照时数及日总辐射曝辐量较其前后两天有明显变化,且这4d的相对湿度较大。例如第40d的日照时数为0h,日总辐射曝辐量为 $23 \text{ MJ} \cdot \text{m}^{-2}$ ,相对湿度达93%,而其前一天的日总辐射曝辐量为 $568 \text{ MJ} \cdot \text{m}^{-2}$ ,而第41d的日照时数与日总辐射曝辐量分别为8h和 $1430 \text{ MJ} \cdot \text{m}^{-2}$ 。日照时数是指

太阳每天在垂直于其光线的平面上的辐射强度超过或等于  $120 \text{ W} \cdot \text{m}^{-2}$  的时间长度。较小的日照时数对应相对较大的湿度,表明阴雨天时日总辐射曝辐量预估效果较差,这与文献[13]的研究结果一致。

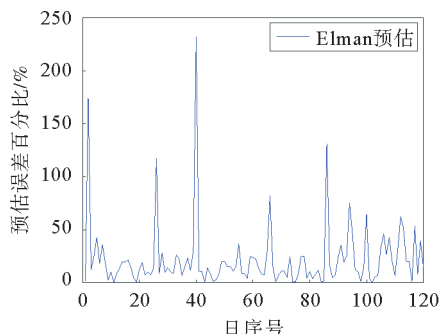


图 2 福山站 Elman 神经网络预估百分比误差

Fig. 2 Percentage error by the Elman neural network model at Fushan meteorological station

实验的预估结果与实际观测值之间的均方根误差为  $1.70 \text{ MJ} \cdot \text{m}^{-2}$ ,由其散点拟合图(图 3)可见,预估较观测值略大,拟合优度达到  $88.3\%$ ,拟合效果比较显著。




图 3 福山站 Elman 神经网络预估散点拟合图

Fig. 3 Scatter fitting diagram of Elman neural network prediction at Fushan meteorological station

图 4 为福山气象站 Elman 神经网络预估结果与观测值的时间序列对比图,总体上,预估结果与实际观测值的变化趋势一致,差值变化范围为  $-3 \sim 4 \text{ MJ} \cdot \text{m}^{-2}$ ,但其中日序号在  $45 \sim 60$  以及  $106 \sim 120$  这两个时间段内的数据差值比较大。分析气象统计数据发现,在这两个时间段的天气状况不太稳定,阴雨天气比较多。而日序号在  $61 \sim 105$  这段区间内的预测结果较好,预估与观测差值范围在  $-2 \sim 2 \text{ MJ} \cdot \text{m}^{-2}$ (图 4)。分析气象统计数据发现,烟台市  $9 \sim 11$  月大都为晴天,天气状况比较稳定,而 12 月份雨雪天较多。表明 Elman 神经网络模型在天气变化剧烈时预估效果较差,而对良好天气状况下的日总辐射预估结果比较精确。

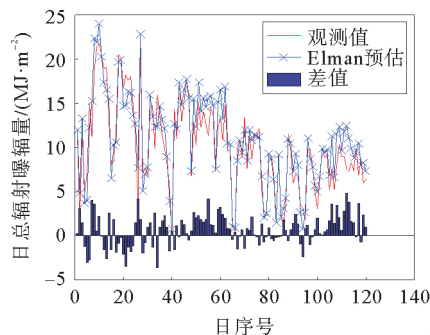


图 4 福山站 Elman 预估值与真实值对比

Fig. 4 Comparison of Elman estimates and actuals at Fushan meteorological station

### 2.2 莒县站 Elman 神经网络模型预估结果分析

图 5 给出的是莒县站日总辐射曝辐量模型预估结果与观测值间的百分比误差,其平均误差百分比为  $19.7\%$ 。预估值与观测值间的均方根误差为  $1.99 \text{ MJ} \cdot \text{m}^{-2}$ 。与福山站相比,平均百分比误差及均方根误差均略偏大。此外,由图 5 可以看出,日序号为  $66, 95, 118$  这 3 d 预估的百分比误差较大,分析发现,其原因与福山站类似,都与这 3 d 的日照时数、日相对湿度及日总辐射曝辐量变化较大有关。

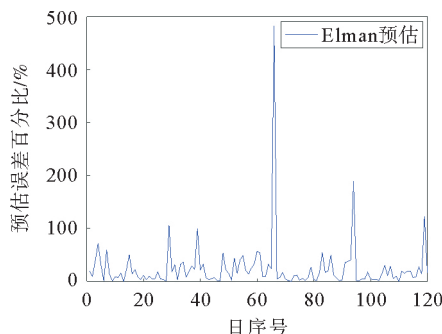


图 5 莒县站 Elman 神经网络预估百分比误差

Fig. 5 Percentage error by the Elman neural network model at Juxian meteorological station

图 6 为莒县站 Elman 神经网络预估值与观测值的散点拟合图,二者的拟合优度为  $83.5\%$ ,可以看出,预估值比观测值多数偏大。图 7 为莒县站 Elman 神经网络预估结果与观测值的时间序列对比图,可以看出,除日序号在  $50 \sim 65$  这个时间段内,其他时间模型预估结果与观测值总体趋势基本一致,两者差值在  $-2 \sim 5 \text{ MJ} \cdot \text{m}^{-2}$  之间,特别是日序号在  $65 \sim 120$  这段时间内的预估值与观测值的差值比较稳定。分析气象统计数据发现,其原因与福山站类似,预估值与观测值偏差大小均与天气状况的稳定性有关。




图6 莒县站 Elman 神经网络预估散点拟合图

Fig. 6 Scatter fitting diagram of Elman neural network prediction at Juxian meteorological station

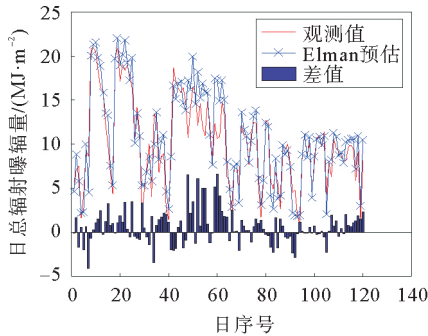


图7 莒县站 Elman 预估与真实值对比

Fig. 7 Comparison of Elman estimates and actuals at Juxian meteorological station

### 2.3 济南站 Elman 神经网络预估结果分析

Elman 神经网络模型对济南站日总辐射曝辐量进行预估的实验结果与实际观测值之间的平均百分比误差如图8所示,平均百分比误差为21.3%。均方根误差为 $2.02 \text{ MJ} \cdot \text{m}^{-2}$ 。相比福山站和莒县站,模型预估的平均百分比误差和均方根误差都有增大,这可能与济南市的大气污染较重有关。分析济南站的 AOD 数据发现,其值普遍比福山站和莒县站的数值高,济南站2000—2003年 AOD 平均值为0.822,莒县站和福山站的 AOD 平均值分别为

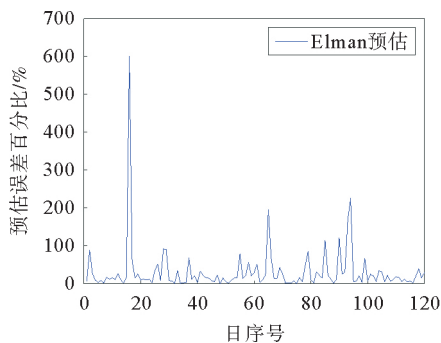


图8 济南站 Elman 神经网络预估百分比误差

Fig. 8 Percentage error by the Elman neural network model at Jinan meteorological station

0.368 和 0.346。气溶胶光学厚度数值范围在0~1之间,0代表完全不透明大气,1代表完全透明大气,气溶胶光学厚度越大,表明大气透过率越低<sup>[14]</sup>,这可能导致日照时数也随之减少,例如,济南站2000—2003年平均日照时数为5.07 h,莒县站和福山站的日照时数平均值分别为5.31和6.07 h。

济南站模型预估值与观测值散点拟合图(图9)显示:模型的预估结果与观测值较为吻合,拟合优度为85.2%,拟合效果比较显著。图10为济南气象站 Elman 神经网络预估结果与观测值的对比图,可以看出,实验的预估结果与实际观测的太阳日总辐射曝辐量总体变化趋势一致,差值都在 $-4 \sim 4 \text{ MJ} \cdot \text{m}^{-2}$ 之间。其中,日序号在0~60这个时间段内数据的观测值与预估结果二者的差值较大,而日序号在70~120这段时间内的预估值与观测值的差值较小(图10)。分析发现,相对11~12月,济南市9~10月份阴雨天较多,导致这段时间模型预估效果变差。




图9 济南站 Elman 神经网络预估散点拟合图

Fig. 9 Scatter fitting diagram of Elman neural network prediction at Jinan meteorological station

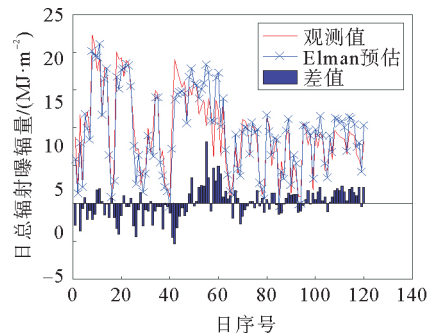


图10 济南站 Elman 预估与真实值对比

Fig. 10 Comparison of Elman estimates and actuals at Jinan meteorological station

## 3 讨论

### 3.1 与 GRNN 网络结果对比分析

GRNN 网络是建立在数理统计基础上的径向基

函数网络,具有较强的非线性映射能力和学习速度<sup>[12]</sup>。庄述鹏等<sup>[5]</sup>应用 GRNN 网络预估了烟台福山站日总辐射曝辐量。本研究将 Elman 神经网络模型得出的福山站的实验结果与 GRNN 网络模型的预估结果<sup>[5]</sup>进行对比,同时本研究运用 GRNN 网络分别对莒县和济南进行了预估,对比结果如表 1 所示。

表 1 Elman 神经网络预估与 GRNN 神经网络预估比较结果

Table 1 Comparison results of Elman neural network prediction and GRNN neural network estimation

站点	MPE/%		RMSE/(MJ·m <sup>-2</sup> )	
	Elman	GRNN	Elman	GRNN
福山	12.3	15.8	1.70	2.18
莒县	19.7	24.6	1.99	2.66
济南	21.3	23.4	2.02	2.47

注:MPE 与 RMSE 数据均取 10 次实验结果的最小值。

显然,Elman 神经网络模型预估结果的平均百分比误差以及均方根误差都优于 GRNN 网络模型结果。平均百分比误差降低 5%~18%,均方根误差平均减小了 0.506 MJ·m<sup>-2</sup>。说明 Elman 神经网络模型描述实验数据具有较高的精确度。

### 3.2 大气污染对日总辐射曝辐量的影响

大气中的气溶胶会通过吸收和散射对太阳辐射产生影响,使得太阳总辐射下降而散射辐射增加<sup>[13]</sup>。因此本研究考虑把 AOD 作为模型的输入量之一对日总辐射曝辐量进行预估,并将预估结果与不考虑气溶胶光学厚度的预估结果进行比较,对比结果如表 2 所示。结果表明:模型中不考虑 AOD,3 个站的平均百分比误差和均方根误差均变大,拟合优度降低。大气污染最重的济南站平均百分比误差变大约 20%,莒县站和福山站误差变化较小,约 6%~8%。济南站均方根误差变大 6.8%,莒县站变大 4.5%,福山站变

表 2 AOD 因子对模型预估结果的比较

Table 2 Comparison of AOD factors on prediction results of models

站点	AOD	MPE/%	RMSE/(MJ·m <sup>-2</sup> )	拟合优度
福山	含 AOD	19.3	1.88	0.86
	不含 AOD	20.9	1.93	0.83
莒县	含 AOD	20.3	2.23	0.80
	不含 AOD	21.9	2.33	0.77
济南	含 AOD	22.4	2.07	0.84
	不含 AOD	26.8	2.21	0.83

注:MPE、RMSE 及拟合优度值均取 10 次实验结果的平均值。

大了 2.7%。实验结果表明:AOD 作为输入向量对预估结果的影响比较明显,济南市大气污染较重,模型中不考虑 AOD,预估效果最差,福山站的大气污染较轻,AOD 对预估结果的影响不大。

相较于福山站、莒县站,2000—2003 年济南站的大气污染比较严重,其气溶胶光学厚度较大。为进一步探讨城市大气污染对太阳日曝辐量的影响,本研究分别将济南站 AOD 大小变为遥感观测值的 2 倍、3 倍进行实验,实验结果如表 3 所示。2 倍 AOD 的实验结果与 1 倍 AOD 相比,平均百分比误差比变大了 10%,3 倍 AOD 相比 1 倍 AOD,平均百分比误差变大了 20%。从实验结果可以看出,AOD 变大,大气污染严重,实验结果变差。这可能是由大气污染对日曝辐量的非线性作用导致的,如,大气污染加重,同时可能使得日照时数变小,从而影响模型预估的准确度。

表 3 济南站 AOD 对结果日曝辐量的影响

Table 3 Effect of AOD on daily results exposure in Jinan station

AOD	MPE/%	RMSE/(MJ·m <sup>-2</sup> )
AOD(1 倍)	22.4	2.07
AOD(2 倍)	24.6	2.07
AOD(3 倍)	26.9	2.08

注:MPE 与 RMSE 均取 10 次实验结果的平均值。

## 4 结 语

应用山东省福山、莒县、济南三所气象站 2000—2003 年共 1 461 d 的数据,建立 Elman 神经网络模型,对日总辐射曝辐量进行时间序列预估。选取日照时数、平均气压、平均气温、日最高气温、相对湿度五个气象参数为模型的输入量,同时引入 AOD,共 6 个输入量,以日总辐射曝辐量作为输出量,对模型进行训练,然后通过 2003 年 9~12 月 120 d 的预估日总辐射曝辐量与实际日总辐射曝辐量相对比,证明了 Elman 神经网络模型对山东省日总辐射曝辐量预估的有效性。Elman 神经网络预估效果受天气状况影响较大,阴雨天气时预估效果略差,晴好天气下日总辐射预估结果比较精确。城市大气污染对日曝辐量影响较大。Elman 神经网络模型中不考虑大气污染因素,模型预估效果变差,特别在大气污染较重的城市,加大污染,模型对日曝辐量的预估越准确。此外,Elman 神经网络模型的激活函数会影响模型的预估精度,今后的研究中可从改进模型的激活函数入手,提高预估的精确度。

## 参 考 文 献

- [1] BOSEHA J L, LOPEZB G, BATLLES F J. Daily solar irradiation estimation over a mountainous area using artificial neural networks [J]. *Renewable Energy*, 2008, 33(7): 1622-1628.
- [2] LAM J C, KEVIN K W W, LIU Y. Solar radiation modelling using ANNs for different climates in China [J]. *Energy Conversion and Management*, 2008, 49(5): 1080-1090.
- [3] 王卫东, 李净, 张国飞. 基于 BP 神经网络的太阳辐射预测 [J]. *干旱区资源与环境*, 2014, 28(2): 185-189.  
WANG Weidong, LI Jing, ZHANG Guofei. Simulation of solar radiation in Lanzhou based on BP neural network [J]. *Journal of Arid Land Resources and Environment*, 2014, 28(2): 185-189.
- [4] 朱良山, 林婵, 王起峰. LM\_BP 神经网络在总辐射日曝辐量计算中的应用研究 [J]. *太阳能学报*, 2013, 34(7): 1202-1205.  
ZHU Liangshan, LIN Chan, WANG Qifeng. Applications of LM\_BP network in daily irradiation exposure of global radiation calculate [J]. *Acta Energiae Solaris Sinica*, 2013, 34(7): 1202-1205.
- [5] 庄述鹏, 宫响, 张淑华, 等. 基于广义回归神经网络的日总辐射曝辐量预估 [J]. *太阳能学报*, 2019, 40(1): 17-22.  
ZHUANG Shupeng, GONG Xiang, ZHANG Shuhua, et al. Estimate of daily irradiation exposure of global radiation using generalized regression neural network [J]. *Acta Energiae Solaris Sinica*, 2019, 40(1): 17-22.
- [6] 王中凯, 梁秀娟, 肖长来, 等. Elman 神经网络在平原区降水入渗补给预测中的应用 [J]. *节水灌溉*, 2013, 25(7): 42-44.  
WANG Zhongkai, LIANG Xiujuan, XIAO Changlai, et al. Application of Elman neural networks in rainfall infiltration recharge predication in plain area [J]. *Water Saving Irrigation*, 2013, 25(7): 42-44.
- [7] 何定, 徐鹏. Elman 与 BP 神经网络应用于交通流预测的对比研究 [J]. *工业工程*, 2010, 13(6): 97-100.  
HE Ding, XU Peng. Comparative study of Elman and BP neural networks applied to traffic flow prediction [J]. *Industrial Engineering Journal*, 2010, 13(6): 97-100.
- [8] MATLAB 中文论坛. MATLAB 神经网络 30 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2010.  
MATLAB Chinese Forum. 30 Case Studies of MATLAB Neural Network [M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2010.
- [9] 艾格林, 孙永辉, 卫志农, 等. 基于 MEA-Elman 神经网络的光伏发电功率短期预测 [J]. *电网与清洁能源*, 2016, 32(4): 119-125.  
AI Gelin, SUN Yonghui, WEI Zhinong, et al. Short-term photovoltaic power forecasting based on MEA and Elman neural network [J]. *Power System and Clean Energy*, 2016, 32(4): 119-125.
- [10] 周晋, 吴业正, 晏刚, 等. 利用神经网络估算太阳辐射 [J]. *太阳能学报*, 2005, 24(4): 509-512.  
ZHOU Jin, WU Yezheng, YAN Gang, et al. Solar radiation estimation using artificial neural networks [J]. *Acta Energiae Solaris Sinica*, 2005, 24(4): 509-512.
- [11] 张靠社, 杨剑. 基于 Elman 神经网络的短期风电功率预测 [J]. *电网与清洁能源*, 2012, 28(12): 87-91.  
ZHANG Kaoshe, YANG Jian. Short-term wind power forecasting based on the Elman neural network [J]. *Power System and Clean Energy*, 2012, 28(12): 87-91.
- [12] IDRIS K, DANISH K. Photovoltaic power forecasting based on theoretical solar radiation and Elman neural network [C]// ICSESS. 7th IEEE International Conference on Software Engineering and Service Science, Beijing, 2016.
- [13] 成驰, 陈正洪, 张礼平. 神经网络模型在逐时太阳辐射预测中应用 [J]. *太阳能*, 2012(3): 30-33.  
CHENG Chi, CHEN Zhenghong, ZHANG Liping. Application of neural network model in predicting hourly solar radiation [J]. *Solar Energy*, 2012(3): 30-33.
- [14] 越昆. 大气气溶胶光学厚度对长三角地区太阳辐射的影响 [D]. 南京: 南京信息工程大学, 2016.  
YUE Kun. Effect of Atmospheric Aerosol Optical Thickness on Solar Radiation in the Yangtze River [D]. Nanjing: Nanjing University of Information Science and Technology, 2016.

(责任编辑 姜丰辉)

(上接第 111 页)

- [8] 张雅琼, 张慧, 林基艳. 基于 K-Means 聚类的无线传感网分层路由算法研究 [J]. *榆林学院学报*, 2018, 28(6): 101-104.  
ZHANG Yaqiong, ZHANG Hui, LIN Jiyuan. Study on hierarchical routing algorithm of wireless sensor network based on K-means clustering [J]. *Journal of Yulin College*, 2018, 28(6): 101-104.
- [9] 刘海谊, 赵汝文, 丁勇. 一种基于密度峰和 K-means 算法的图像分割算法 [J]. *桂林电子科技大学学报*, 2018(5): 385-388.  
LIU Haiyi, ZHAO Ruwen, DING Yong. An image segmentation algorithm based on density peak and K-means algorithm [J]. *Journal of Guilin University of Electronic Technology*, 2018(5): 385-388.
- [10] 戴月明, 王明慧, 张明, 等. SVD 优化初始簇中心的 K-means 中文文本聚类算法 [J]. *系统仿真学报*, 2018, 30(10): 3835-3842.  
DAI Yueming, WANG Minghui, ZHANG Ming, et al. K-means chinese text clustering algorithm for SVD optimization initial cluster center [J]. *Journal of System Simulation*, 2018, 30(10): 3835-3842.
- [11] 王盛慧, 夏永丰. 基于搜寻者优化算法的 K-means 聚类算法 [J]. *燕山大学学报*, 2018, 42(5): 422-426.  
WANG Shenghui, XIA Yongfeng. K-means clustering algorithm based on searcher optimization algorithm [J]. *Journal of Yanshan University*, 2018, 42(5): 422-426.

(责任编辑 姜丰辉)