文章编号: 2096-1472(2023)-01-05-04

基于BP神经网络和小波神经网络的太阳辐射强度预测

鲁玉军,周世豪,胡小勇

(浙江理工大学机械与自动控制学院,浙江 杭州 310018) ⊠luet_lyj@zstu.edu.cn; 1240219752@qq.com; 944498378@qq.com



摘 要:针对太阳辐射的波动对太阳能相关系统的不利影响,提出了一种基于BP神经网络和小波神经网络的混合 预测模型,对太阳逐时辐射强度进行预测。首先,利用相关性分析确定对太阳辐射强度影响较大的气象因素,然后,分 别对BP和小波神经网络进行优化,确定两种神经网络的最优结构,再次,利用小波分解对太阳逐时辐射强度进行小波 三层分解,对分解后的分量分别用优化后的神经网络进行预测,最后,将各神经网络输出结果叠加,得到太阳辐射强度 的逐时预测值。通过MATLAB软件进行仿真,并与BP神经网络、小波神经网络及国内相关模型进行对比,结果表明: 所提出的混合预测模型能有效减小太阳辐射预测的误差。

关键词: BP神经网络;小波神经网络;太阳辐射强度;小波分解 中图分类号: TP183 文献标识码: A

Prediction of Solar Radiation Intensity based on BP and Wavelet Neural Network

LU Yujun, ZHOU Shihao HU Xiaoyong

(Department of Mechanical Engineering and Automation, Zhejiang University of Science and Technology, Hangzhou 310018, China) [Science and Technology, Hangzhou 310018, China] [Science and Technology, Hangzhou 310018, China]

Abstract: In view of the adverse effect of solar radiation fluctuations on solar energy related systems, this paper proposes a hybrid prediction model based on BP (Back Propagation) and wavelet neural network, in order to predict solar radiation intensity. Firstly, the meteorological factors which have great influence on solar radiation intensity are determined by correlation analysis. Then, BP and wavelet neural networks are optimized to determine the optimal structure of the two neural networks. Next, wavelet decomposition is used to decompose the hourly solar radiation intensity in three layers, and the decomposed components are predicted by the optimized neural network. Finally, the hourly predicted value of solar radiation intensity is obtained by superimposing the output results of each neural network. The simulation is carried out by MATLAB software and the proposed model is compared with BP neural network, wavelet neural network and domestic related models. The results show that the proposed hybrid prediction model can effectively reduce the error of solar radiation prediction.

Keywords: BP neural network; wavelet neural network; solar radiation intensity; wavelet decomposition

1 引言(Introduction)

目前,太阳辐射预测应用最多的是光伏发电领域,为了 解决太阳逐时辐射强度的时变性导致的光伏发电功率不稳定 问题,需要对太阳辐射强度进行高精度的预测。我国的太阳 辐射观测站较少,因此建立精确的模型对太阳辐射进行精准 预测非常必要^[1-3]。

国内外对太阳辐射预测进行了大量的研究,国内学者主要基于神经网络的预测方法进行研究^[4]。文献[5]和文献[6]利用优化后的BP神经网络预测光伏电站的输出功率,对太阳辐射预测具有参考意义,但是单纯的BP神经网络的预测精度有

限。文献[7]和文献[8]在引入气象因素时考虑不够全面,忽略 了大气压强等气象因素对太阳辐射的影响。

在参考国内外相关研究的基础上,本文结合小波分解提 出了一种基于BP神经网络和小波神经网络的混合预测模型, 预测结果表明:所提出的混合预测模型能有效减小太阳辐射 预测的误差。

2 输入输出相关性分析(Input and output correlation analysis)

太阳辐射强度与气象因素具有很强的相关性,选择合适 的气象参数能够提高辐射预测的精度,本文选取的气象因素 包括太阳辐射强度、温度、空气湿度、云量和大气压强。网络输入的不同会带来网络输出的差异,选取对输出变量具有 更强影响的输入变量能够提高网络的预测准确度。因此,需 要进行输入输出相关性分析,根据不同输入变量与输出变量 相关性的大小确定网络输入的数目,其计算公式如下¹⁹。

 $R(X,Y) = Cov(X,Y) / \sqrt{Var(X)Var(Y)}$ (1) 式(1)中, Cov(X,Y)为X与Y的协方差, Var(X)为X的方 差, Var(Y)为Y的方差。

本文需要对t时刻的太阳辐射强度进行预测,即确定网络的输出层神经元数目为1,接着将t时刻前5h的相关气象因素 作为网络输入变量的待确定项。为了确定与输出变量相关性 强的输入变量,将选择的输入输出变量作相关性分析,利用 MATLAB软件读取和处理历史数据,得到的结果如表1所示。

表1 输入输出变量相关系数表

Tab.1 Correlation number of input and output variables

气象因素	t-1时刻	t-2时刻	t-3时刻	t-4时刻	t-5时刻
辐射强度	0.9162	0.7588	0.5543	0.3372	0.1262
温度	0.2192	0.1568	0.0946	0.0379	0.0090
空气湿度	-0.3510	-0.1934	-0.0353	-0.1108	-0.2332
云量	-0.2110	-0.1956	-0.1900	-0.1900	-0.1919
大气压强	0.2995	0.2928	0.2839	0.2742	0.2644

由表1可知,t-1时刻与t-2时刻的辐射强度、t-1时刻的 温度、t-1时刻的空气湿度、t-1时刻与t-2时刻的云量、t-1时 刻与t-2时刻的大气压强共8个输入变量与太阳辐射的相关系 数大于同气象因素下其他时刻的相关系数。此外,对前一日t 时刻与当日t时刻的辐射强度做相关性分析,得出相关系数为 0.7805,因此将前一天t时刻的辐射强度加入输入变量之中。 最终,确定网络输入层神经元数目为9个。

3 BP神经网络和小波神经网络结构优化(Structure optimization of BP and wavelet neural network)

3.1 BP神经网络结构优化

BP神经网络作为常用的经典神经网络,其结构包含输入 层、输出层和隐含层三层网络,其功能是通过信号前向传递 和误差反向传递实现的。BP神经网络结构图如图1所示^[10]。



图1 三层BP神经网络结构图

Fig.1 Structure diagram of three—layer BP neural network 图1中, n表示输入层神经元的个数, N表示隐含层神经元 的个数, m表示输出层神经元的个数。

BP神经网络隐含层节点数会影响预测的精度,本文根据前人研究总结的公式确定隐含层节点数^[11]。根据小节2内

容分析,由经验公式确定隐含层神经元数量为4—13个。为确定具体的神经元数量,以单隐含层结构为研究对象,使用 MATLAB软件进行仿真实验,对神经元匹配结构的预测均方 根误差结果进行对比,最终取13个神经元数量,得出的结果 如表2所示。

表2 BP神经网络单隐含层结构结果对比

Tab.2 Comparison of single hidden layer structure of BP neural network

序号	隐含层神经元个数/个	训练RMSE	预测RMSE _p
1	13	185.4688	226.7039
2	12	186.2197	228.3671
3	11	190.8927	230.4384
4	10	189.2863	228.7268
5	9	191.6557	231.9095

其中,均方根误差(RMSE)定义为式(2)所示。

$$SF = \sqrt{\frac{1}{N}} \sum_{i=1}^{N} (Y_f - Y_i)^2$$
(2)

式(2)中,*N*为样本数,*Y*₅为网络预测值,*Y*₅为实际值。 为了提高预测精度,在隐含层神经元个数取13个的条件

下,比较双隐含层结构下的预测结果,得出的结果如表3所示。 隐藏层节点数计算,如式(3)所示。

$$N = \sqrt{(n+m)} + a \tag{3}$$

(3)中, n为输入层神经元的数量, m为输出层神经元的 发量, a为1—10区间内的不定常数, N为隐含层节点的数量。

表3 BP神经网络双隐含层结构结果对比

Tab.3 Comparison of double hidden layers structure of BP neural network

序号	隐含层1 神经元个数/个	隐含层2 神经元个数/个	训练RMSE	预测RMSE _p
1	10	3	183.4865	216.4322
2	9	4	183.6909	216.7927
3	8	5	183.8550	226.7205
4	7	6	182.4482	208.9592
5	6	7	187.8245	213.1232

对比表2和表3中的结果可知,双隐含层结构下的预测精 度更高,同时由表3得出第四种网络隐含层结构更好,即第一 层和第二层隐含层神经元数量分别取7个和6个。构建BP神经 网络需要选择合适的训练函数,经过实验对比,trainlm训练 函数的训练速度更快,结果精度更高,因此更适合本文网络 的结构和规模。神经元传递函数选择tansig,训练的最大迭代 次数设为2,000,目标精度设为0.01。

3.2 小波神经网络结构优化

小波神经网络按照组成结构的不同分成紧凑型与松散型。紧凑型小波神经网络在结构组成上与常规神经网络类 似,不同的是将神经元传递函数替换为满足条件的小波函数,松散型小波神经网络是对原始信号时间序列进行小波分 解,得到低频子序列和不同层次的高频子序列,然后将分解



图2紧凑型小波神经网络结构简图

Fig.2 Structure diagram of compact wavelet neural network



图3 松散型小波神经网络结构简图

Fig.3 Structure diagram of loose wavelet neural network

小波神经网络一般采用单隐含层的网络结构,通过实验 仿真寻找最佳的隐含层神经元数量,最终选择隐含层神经元 个数为20个,隐含层结构结果对比如表4所示。经过仿真对 比,基于Morlet小波基函数的神经网络更适合当前网络结 构,预测精度更高,因此采用Morlet小波基函数代替常规神 经网络的基函数作为隐含层传递函数。训练的最大迭代次数 设为10,000,目标精度设为0.001,训练算法采用梯度下降 算法。

表4 小波神经网络隐含层结构结果对比 Tab.4 Comparison of hidden layer structure of wavele

neural network

序号	隐含层神经元个数/个	训练 <i>RMSE</i>	•预测RMSE _p
1	10	212.4126	242.4401
2	20	210.0141	238.8699
3	30	210.9439	240.9651

4 基于BP和小波神经网络的混合预测模型(Hybrid prediction model based on BP and wavelet neural network)

小波分解能够改变时间窗和频率窗,在处理准周期性 和不确定性时间序列信号时非常有效,太阳辐射强度也符合 这一特点。因此,可以对太阳辐射强度时间序列进行小波分 解,得到包含信号大致轮廓的低频分量和包含信号具体细节 的高频分量,低频分量和高频分量具有不同的权重和功能作 用,对原信号预测值的贡献也不同。因此,可以利用Mallat算 法将信号划分为主体信息和细节信息,并将划分后的两种信 息分别作为网络输入构建神经网络,可以对太阳辐射强度进 行更加精细的分析^[13]。

在函数空间内,多分辨率分析采用一系列近似函数描述 函数。这种方法可以有效地提高数值计算精度和效率,函数 的三层分解树如图4所示^[14]。



图4 二层多分拆平分胜树

Fig.4 Three-layer multi-resolution decomposition tree 其中,A表示分解信号得到的低频分量,D表示分解信号 得到的高频分量。由图4可知,初始信号与分解后得到的分量 的关系为f=A3+D3+D2+D1。

受紧凑型小波神经网络和松散型小波神经网络的启发, 本文考虑到小波分解的特点,提出了基于BP神经网络和小 波神经网络的混合预测模型,其主要思想如下:首先对太阳 辐射强度时间序列进行小波三层分解,得到低频分量A3和高 频分量D1、D2、D3;然后将相关气象参数数据和分量A3与 D1、D2、D3分别作为网络的输入进行训练预测,最后将四个 分量通过训练得到的预测量进行叠加得到/时刻太阳辐射强度的 预测值。通过实验结果比对得出,分量A3对应的神经网络可以 选择紧凑型小波神经网络,而分量D1、D2、D3对应的神经网 络可以选择BP神经网络。构建的混合预测模型如图5所示。



5 实验及结果分析(Experiment and result analysis)

本文采用的数据为杭州地区2019 年全年太阳辐射强度及 相关气象数据,包括太阳辐射强度、温度、空气湿度、云量 和大气压强,数据采样间隔为1 h,全年共8,760 个数据。为 了对提出的混合预测模型进行验证,对于本次实验的8,760 个 数据进行处理,其中前355 天的8,520 个数据作为网络的训练 数据,后10 天的240 个数据作为检验数据。对原始太阳辐射 强度时间序列进行小波三层分解,经过实验对比,基于db4函 数分解的结果更理想,分解后各分量如图6所示。



Fig.6 Results of three-layer wavelet decomposition

在确定了网络的输入和输出后,需要采用数据归一化的 方法,避免了原始数据绝对值过高导致的"饱和现象",从 而使结果超出了有效处理范围。故采取数据归一化的处理方 法,将通过相关性分析确定的输入因素数据归一化到[0,1]的 范围内。

以{*X*(*i*),*i*∈*Z*}表示准备归一化的目标数据,{*Y*(*i*),*i*∈*Z*}表示完成归一化的输出结果,转化关系如公式(4)所示。当网络输出预测值时,需要用反归一化处理输出的数值,反归一化的转化关系如公式(5)所示。

$$Y(i) = \frac{X(i) - \min\{X(i)\}}{\max\{X(i)\} - \min\{X(i)\}}$$
(4)

 $X(i) = (\max\{X(i)\} - \min\{X(i)\}) \times Y(i) + \min\{X(i)\}$ (5)

进行归一化处理后,利用结构优化后的BP神经对高频分量进行预测,并利用结构优化后的小波神经网络分别对低频 分量进行预测,将各网络训练的预测分量进行叠加,接着对 叠加后的数据进行反归一化处理,即可获得太阳辐射强度的 预测值。最终本文提出的基于BP神经网络和小波神经网络的 混合模型的预测效果如图7所示。











图9 横向模型预测效果对比图

Fig.9 Comparison diagram of transverse model prediction effects

为了检验混合预测模型的预测精度,分别计算出上述方 法预测结果的均方根误差,结果如表5所示。对比五种预测模 型的均方根误差,可看出本文模型的预测误差相比其他模 型有所降低,进一说明了本文提出的混合预测模型的优 良性。

表5 预测误差对比

Comparison diagram of prediction errors

项目名称	BP神经网络	小波神经网络	文献[5]	文献[7]	本文模型
训练误差RMSE	183.8532	209.1563	180.2843	181.7648	172.3565
顶测误差RMSE _P	211.1985	237.5968	162.5546	164.7132	151.4825

与结论(Conclusion)

本文根据小波分解的原理构建了基于BP神经网络和小 波神经网络的混合预测模型。首先,分析了网络输入输出的 相关性,从而确定了网络的输入项;其次,优化了BP神经网 络和小波神经网络的结构;再次,对太阳辐射强度历史序列 进行了小波分解,并用优化后的小波神经网络预测分解得到 低频分量,用优化后的BP神经网络预测分解得到各高频分 量;最后,将所有预测结果进行叠加得到太阳辐射强度的预 测值。通过实验仿真表明:本文提出的基于BP神经网络和 小波神经网络的混合预测模型可以减少太阳辐射预测结果的 误差。

参考文献(References)

- [1] 于志.多种太阳能新技术在示范建筑中的应用研究[D].合肥: 中国科学技术大学,2014.
- [2] 路绍琰,吴丹,马来波,等.中国太阳能利用技术发展概况及趋势[J].科技导报,2021,39(19):66-73.
- [3] JENKINS P, ELMNIFI M, YOUNIS A, et al. Enhanced oil recovery by using solar energy: case study[J]. Journal of Power and Energy Engineering, 2019, 6:59–64.
- [4] 曹其梦,于瑛,杨柳.太阳逐时总辐射计算模型适用性分析——以我国部分地区为例[J].太阳能学报,2018,39(04):
 917-924.