

基于经验模态分解和 ELM 神经网络的 逐时太阳能辐照量预测

王守相¹,王亚旻¹,刘 岩²,张 娜¹

(1. 天津大学 智能电网教育部重点实验室,天津 300072;2. 中国电力科学研究院(国网计量中心),北京 100192)

摘要: 准确的太阳能辐照量预测对于光伏发电系统具有重要意义。提出一种基于经验模态分解(EMD)和 ELM 神经网络的逐时辐照量组合预测模型。首先,根据预测日的环境信息,构建相似日逐时辐照量时间序列;然后,将时间序列进行 EMD,分解为具有不同频率的信号,并对每个信号建立 ELM 神经网络预测模型;最后,将不同信号的预测值相加便可得到原始辐照量序列的预测值。算例比较表明,所提方法比传统的预测方法具有更高的预测准确度和更快的运算速度。

关键词: 经验模态分解; ELM 神经网络; 太阳能; 辐照量; 预测; 模型

中图分类号: TM 615

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2014.08.002

0 引言

太阳能辐照量是影响光伏出力最直接、最显著的因素。受大气云层、湿度等环境因素的影响,辐照量具有典型的非平稳性和随机性。因此,准确的太阳能辐照量预测对于光伏出力预测、光伏接入电网、光伏系统规划和调度等具有极其重要的意义。

受测量设备不足等因素的影响,国内对辐照量预测的研究较少,而国外学者已对辐照量预测的研究进行了大量工作。辐照量预测方法可以分为 2 类。第 1 类基于详尽的数值天气预报(NWP),利用观测的数值天气信息与辐照量的物理计算模型,对超短期辐照量进行高精度预测^[1]。这一类方法虽然预测精度高,但是需要复杂的卫星观测信息及分析方法,在我国现阶段实行比较困难。第 2 类通过对历史数据建模,模拟出辐照量的变化规律,然后预测未来辐照量。如文献[2]基于大量历史数据,计算辐照量的分布区间和频率,建立了统计性模型。云层是影响辐照量最为显著的环境因素,文献[3]根据 11 种不同云层覆盖信息,建立了 11 个动态自回归(ARIMA)模型,对短期辐照量的预测具有很高的预测精度。但单一的 ARIMA 模型无法考虑各种环境因素,其应用具有局限性。人工智能方法如神经网络(ANN)^[4]已在辐照量的预测中应用十分广泛。此类方法可以综合考虑各种环境因素,但是通常具有训练速度慢、易陷入局部最优解等缺点。研究发现,组合预测方法可以

有效利用多种预测方法的优点,通常比单一预测方法预测精度高^[5]。小波分解(wavelet decomposition)^[6]及经验模态分解(EMD)^[7-8]已经在非线性随机时间序列的组合预测中得到广泛应用。这一类预测方法先将时间序列分解为多个不同频率的序列,对不同的序列分别建立预测模型以减少不同特征信息间的相互影响,最后将预测结果重构便可获得原始序列的预测值。其中,EMD 算法实现简单,分解速度快,它吸取了小波分解多分辨的优势,同时克服了小波分解中需要选取小波基、确定分解尺度的困难。

虽然分解类组合预测方法可以提高预测精度,但由于要对分解后的信号分别建立预测模型,其训练和预测时间通常较长。最近提出的一种 ELM (Extreme Learning Machine)神经网络^[9]克服了传统机器学习算法参数设定困难、训练时间长等缺点。ELM 已被证实在回归分析、分类、预测等领域具有极快的学习速度^[10-11]。本文综合利用不同算法的优点,建立了基于 EMD 和 ELM 神经网络的逐时辐照量组合预测模型。该组合模型解决了基于 EMD 预测时整体预测时间过长的缺点并首次将 ELM 神经网络应用到光伏预测中。合适的数据样本可以极大提高机器学习类预测算法的预测精度。因此本文建立的预测模型首先利用环境因素构建相似日时间序列,然后对相似日时间序列进行 EMD,分解后的各个信号分别作为 ELM 算法的训练、测试样本并进行预测,最后将各个预测值相加便可得到对原始序列的预测值,可为电力系统调度运行提供参考。由于环境因素只参与相似日序列的构建,没有参与神经网络的训练与预测,因此提出的预测模型具有普适性。

本文首先讨论辐照量与光伏出力的关系,接着介绍相似日逐时辐照量时间序列的构造原理,然后提出 EMD 和 ELM 相结合的辐照量预测算法,最后采用

收稿日期:2013-08-22;修回日期:2014-07-04

基金项目:国家自然科学基金资助项目(51077098);国家高技术研究发展计划(863 计划)项目(2011AA05A107);国家电网公司科技项目(ZDK/GW021-2012)

Project supported by the National Natural Science Foundation of China(51077098),the National High Technology Research and Development Program of China(863 Program)(2011AA05A107) and Science and Technology Program of SGCC(ZDK/GW021-2012)

算例对多个不同天气特点的典型日进行预测结果分析,论述 EMD 和 ELM 相结合的预测算法相比于单独的 ELM 和 EMD 的优势,并给出结论。

1 辐照量与光伏出力的关系

光伏发电系统输出功率的工程模型为^[12]:

$$P_{pv}=N_{pv}\eta_1\eta_2\eta_3AR_{\beta}[1-a(T_c-25)] \tag{1}$$

其中, N_{pv} 为正常工作的光伏组件个数; η_1 为光伏组件在额定工作条件下的光电转换效率; η_2 为最大功率点跟踪 MPPT(Maximum Power Point Tracking)的工作效率; η_3 为逆变器效率; A 为光伏组件的面积; R_{β} 为光伏阵列斜面太阳总辐照度, β 为阵列的倾角; a 为光伏组件的温度系数; T_c 为光伏组件的板温。

当光伏板的规格确定后,根据大量运行数据可确定式(1)中各个效率值。板温与辐照强度、环境温度、运行时间等因素相关性很大,不具有明显随机性,它的预测或测量难度不大。因此,辐照量是影响光伏出力最直接、最显著的因素,正是辐照量的随机性导致光伏出力的不确定性。准确的辐照量预测对光伏出力的预测以及光伏系统的规划具有重要意义。

2 逐时辐照量时间序列构成原理

2.1 影响辐照量的因素分析

为了提升神经网络训练及预测效果,首先构建与预测日环境因素相似的相似日逐时辐照量序列。到达地面水平面上的可利用全局辐照量 R_{glo} 会受到云层、大气中水珠等因素的影响,在多环境因素并存的情况下识别对辐照量预测影响最大的气象因素非常重要^[12]。采用距离分析法中皮尔森相似度分析辐照量 R_{glo} 与中低云总云量 C_t 、高云量 C_o 、湿度 H 、风速 W_s 、大气压 P 的相关性系数,式(2)为 2 个 $1\times n$ 维向量 $\boldsymbol{x}$ 和 $\boldsymbol{y}$ 的皮尔森相关系数计算公式。

$$r_{xy}=\frac{\sum_{i=1}^n(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_{i=1}^n(x_i-\bar{x})^2}\sqrt{\sum_{i=1}^n(y_i-\bar{y})^2}} \tag{2}$$

其中, x_i,y_i 分别为向量 $\boldsymbol{x}$ 和 $\boldsymbol{y}$ 中的第 i 个元素; $\bar{x},\bar{y}$ 分别为向量 $\boldsymbol{x}$ 和 $\boldsymbol{y}$ 中元素的平均值。

本文所有数据来自美国国家太阳能数据库(NSRD),从该数据库可免费获取美国 1454 个能观测站 1991 年至 2010 年辐照量及环境数据。本文选取旧金山数据库为研究对象,数据均为逐时数据。将 1991 年至 2010 年旧金山数据代入式(2)计算全局辐照量与各环境因素之间的相关系数,结果见表 1。

从表 1 可以看出辐照量与中低云总云量 C_t 、高云量 C_o 、湿度 H 相关性较大,因此选取这 3 个环境因素体现每日特征。考虑到国内仅可实现天气的预测,云量值的预测实现困难,可利用中低云总云量 C_t

和天气 W_d 的对应关系进行换算,对应关系见表 2。

表 1 辐照量与各环境因素的相关系数
Tab.1 Correlation coefficients between radiation and environment factors

辐照量	相关系数				
	C_t	C_o	W_s	H	P
R_{glo}	-0.337	-0.323	0.030	-0.549	0.028

表 2 逐时天气 W_d 与中低云总云量 C_t 的对应关系
Tab.2 Relationship between weather data W_d and C_t

天气	C_t	数值表示 W_d
晴	<2/10	1
少云	2/10~3/10	2
多云	4/10~7/10	3
阴	>7/10	4

因通常日出之前、日落以后辐照量为零,只选取 06:00—20:00 间的 15 个整时点作为每日预测时刻。设每日的特征向量^[13] $\boldsymbol{T}$ 包括 06:00—20:00 的逐时阴晴数据 W_{di} 和逐时湿度 H_i 数据共 30 个元素,即:

$$\boldsymbol{T}=[W_{di} \ H_i] \tag{3}$$

其中, $6\leq i\leq 20$; W_{di} 取值范围为 1~4; H_i 为百分比数值,为降低量纲对后续分析的影响,将湿度归一化到 $[1,4]$ 上。

2.2 相似日的选取原理

为了找出环境因素数值与变化规律均和预测日相似的日期组成时间序列,选取欧氏距离和余弦相似度 2 个指标表征相似性。

欧氏距离 d_{ij} 可描述任意第 i 天特征向量 $\boldsymbol{T}^i$ 和预测日第 j 天特征向量 $\boldsymbol{T}^j$ 间的气象因素总体差异度:

$$d_{ij}=\sqrt{\sum_{k=1}^m(T_k^i-T_k^j)^2} \tag{4}$$

余弦相似度 $D_{\cos ij}$ 可描述任意第 i 天特征向量 $\boldsymbol{T}^i$ 和预测日第 j 天特征向量 $\boldsymbol{T}^j$ 间变化趋势相似性:

$$D_{\cos ij}=\frac{\sum_{k=1}^mT_k^iT_k^j}{\sqrt{\sum_{k=1}^m(T_k^i)^2}\sqrt{\sum_{k=1}^m(T_k^j)^2}} \tag{5}$$

其中, T_k^i,T_k^j 分别为第 i 天和第 j 天特征向量的第 k 个元素; m 为特征向量的总元素数,本文中 $m=30$ 。

欧氏距离为大于 0 的数值,越小表示越相似;余弦相似度数值在区间 $[0,1]$ 中,越接近 1 表示越相似。为了和余弦相似度一致,将欧氏距离利用式(6)进行转换,这样转换后的距离也为区间 $[0,1]$ 中的数值,且越接近 1 越相似。

$$D_{ij}=\cos\left[\frac{\pi}{2}\frac{d_{ij}}{\max(d_{ij})}\right] \tag{6}$$

其中, $\max(d_{ij})$ 指所有 d_{ij} 中的最大值。

转换后就可以将 2 个指标综合成一个指标表征相似性,记为 D_{simij} 。

$$D_{simij}=\alpha D_{ij}+(1-\alpha)D_{\cos ij} \tag{7}$$

其中, α 为经验权重系数,不同天气情况下取值会不

同。若阴晴、湿度在一天内有明显变化趋势, α 应取值靠近 0, 否则靠近 1。

为了尽量避免季节因素对辐照量预测的影响, 只计算 1991 年至 2010 年数据库中在预测日前 28 天(忽略年份)内的相似性, 取相似性最高的 28 天组成相似日时间序列。

3 EMD 和 ELM 神经网络结合的辐照量预测算法

3.1 EMD 预测算法

EMD 是 Hilbert-Huang 变换的核心内容, 该方法假设任何复杂的信号都是由简单的本征态函数 IMF (Intrinsic Mode Function) 组成, 且各 IMF 都是相互独立的^[14]。IMF 有如下 2 个特点: 整个函数中极值点(极大值和极小值)数目和过零点数目相等或最多相差 1 个; 在任何点, 由局部极大值构成的上包络线和由局部极小值构成的下包络线相应点的均值为零。

辐照量序列的 EMD 算法步骤^[14]如下。

a. 对于构建的相似日辐照量时间序列 $z(t)$, 首先找出它所有的极大值点和极小值点。用三次样条插值法分别将所有极大值点、极小值点连成曲线, 称为上包络线和下包络线。设 $m(t)$ 为上、下包络线的均值, $h(t)$ 为序列 $z(t)$ 与 $m(t)$ 差值, 即:

$$h(t)=z(t)-m(t) \quad (8)$$

b. 将 $h(t)$ 作为新的原始序列, 重复 k 次步骤 **a** 中的过程直到 $h_k(t)$ 是 IMF。判断 $h_k(t)$ 是否为 IMF 的标准为:

$$R_k=\frac{\sum_{t=0}^T\left|h_{k-1}(t)-h_k(t)\right|^2}{\sum_{t=0}^T\left|h_{k-1}(t)\right|^2} \quad (9)$$

如果 R_k 小于预先给定的阈值, 则 $h_k(t)$ 可以判断为一个 IMF。设得到的第 1 个 IMF 为 $IMF_1(t)=h_k(t)$ 。

c. 得到 $IMF_1(t)$ 之后, 再用原始辐照量序列减去 $IMF_1(t)$, 获得余项 $r_1(t)$, 即:

$$r_1(t)=z(t)-IMF_1(t) \quad (10)$$

将 $r_1(t)$ 当作 $z(t)$ 重复步骤 **a** 和步骤 **b** 获得第 2 个 IMF, 即 $IMF_2(t)$, 设 $r_2(t)=r_1(t)-IMF_2(t)$, 将 $r_2(t)$ 当作 $z(t)$ 接着重复上述步骤。为了得到所有 IMF, 重复该过程直到余项函数 $r(t)$ 为单调函数或者小于预先给定的阈值。最后的余项函数 $r(t)$ 被称为余项。

以旧金山 2010 年 4 月 4 日(阴)逐时辐照量预测为例, 对辐照量序列进行 EMD 后得到 7 个 IMF 和 1 个余项, 构建的相似日辐照量序列及 EMD 结果如图 1 所示。从图 1 中可以看出 IMF_1 的频率较高, 它主要反映原始序列的随机噪声信息; IMF_2 — IMF_7 及余项 r 变化频率低, 主要反映原始序列的周期性和趋势性信息, 其预测效果非常准确。这样即使 IMF_1 的预测难度较大, 总体的预测精度也会大幅提高。




图 1 相似日逐时辐照量序列及 EMD 结果
Fig.1 Hourly radiation sequence of similar days and its EMD results

3.2 ELM 神经网络预测算法

ELM 是一种单隐含层前向神经网络, 它的隐含层神经元可以很多, 隐含层权值、阈值是随机产生的。ELM 具有很好的全局搜索能力和简单易行的特点, 与传统的梯度学习算法(如 BP 算法)和 SVM 相比, ELM 的学习速度更快, 可以克服传统梯度算法常有的局部极小、过拟合和学习率的选择不合适等问题, 并且有更好的泛化能力^[9]。

ELM 的典型结构如图 2 所示, 设网络有 p 个输入层神经元, l 个隐含层神经元, 输入层和隐含层之间的激活函数为 f , 数据样本集为 $\{X_i, y_i\}_{i=1}^N$, 其中 $X_i=[x_i^1, x_i^2, \dots, x_i^p]^T \in \mathbf{R}^p$, N 为样本集总个数。那么输入和输出的数学关系为:

$$\sum_{j=1}^l f_j(W_j, b_j, X_i) \eta_j = o_i \quad i=1, 2, \dots, N \quad (11)$$




图 2 典型 ELM 的结构图
Fig.2 Typical structure of ELM

其中, W_j 为第 j 个隐含层神经元与输入向量 X_i 间的权值向量; b_j 为第 j 个隐含层神经元的阈值; η_j 为第 j 个隐含层神经元与输出层节点间的权值; o_i 为第 i 个样本的输出。本文中激活函数选为 sigmoid 函数, 设变量为 u , 则该函数为:

$$f(u)=\frac{1}{1+e^{-u}} \tag{12}$$

在 ELM 预测过程中, 首先将辐照量样本划分为训练集、测试集和预测集, 各输入数据需要归一化。然后通过训练集、测试集确定最优的隐含层节点数, 解出相应的 η 。最后, 将确定的各参数应用到预测集, 实现预测。ELM 预测过程如图 3 所示。




图 3 ELM 预测算法流程图

Fig.3 Flowchart of ELM forecasting algorithm

文献[9]证明了 ELM 理论的可行性, η_j 的具体求解过程在文献[10-11]中有详细介绍, 不再赘述。

3.3 EMD 与 ELM 相结合的辐照量预测算法

本文提出的 EMD 和 ELM 神经网络结合的辐照量预测算法首先利用环境因素构建相似日时间序列, 然后对相似日时间序列进行 EMD, 分解后的各个信号分别作为 ELM 算法的训练、测试样本并进行预测, 最后将各个预测值相加便可得到对原始序列的预测值。算法流程如图 4 所示。




图 4 EMD 与 ELM 组合预测算法流程图

Fig.4 Flowchart of hybrid forecasting algorithm based on EMD and ELM

EMD 与 ELM 组合预测算法保留了 EMD 预测算法预测精度高的优点, 并通过 ELM 极快的学习速度克服了为每个分解出的信号建立预测模型带来的

运算速度慢的缺点。因此, 该组合预测算法可以实现既快速又准确的预测。

4 算例分析

4.1 ELM 神经网络预测效果分析

本节以图 1 中模态分解的 IMF_2 预测为例, 对 IMF_2 分别应用 BP 神经网络、GA-BP 神经网络、支持向量机(SVM)、ELM 进行预测并比较预测结果。以上算法中输入均为预测时刻前 3 h 的数值, 输出为预测时刻数值, 该过程为滚动预测过程。BP、GA-BP 神经网络都为单隐含层, 输入层与隐含层之间、隐含层与输出层之间的激活函数都为式(12)中的 sigmoid 函数。SVM 的各参数设定和样本集的划分不再详细叙述。ELM 不同隐含层节点数对训练、测试的影响如图 5 所示。从图中可以看出, 可将 ELM 的隐含层节点数设为 20, 此时测试误差最小。不同算法预测的时间和精度结果如表 3 所示, 运算环境为 3.0 GHz、2.0 G 的内存, 测试软件为 MATLAB R2011b, 使用 tic/toc 指令测试程序运算时间。




图 5 不同隐含层节点数 ELM 的效果比较

Fig.5 Chart of ELM effect vs. hidden layer neuron number

表 3 不同预测方法效果比较

Tab.3 Comparison of effect among different forecasting methods

预测方法	运算时间/s	$\delta_{MAPE}/\%$	δ_{RMSE}
BP 神经网络	1.96	3.0	0.93
GA-BP 神经网络	42.47	2.6	1.11
SVM	4.86	8.2	2.97
ELM	0.01	3.45	1.22

选取平均绝对百分比误差(MAPE)和均方根误差(RMSE)对预测结果进行评估。

$$\delta_{MAPE}=\frac{1}{T} \sum_{i=1}^T \left| \frac{y_i-f_i}{y_i} \right| \tag{13}$$

$$\delta_{RMSE}=\sqrt{\frac{1}{T} \sum_{i=1}^T (y_i-f_i)^2} \tag{14}$$

其中, y_i 和 f_i 分别为实测值和预测值; T 为预测时间点的个数。考虑到日出、日落后辐照量值接近 0, 进行误差分析的时段选为 08:00—17:00。

从表 3 结果可以看出, ELM 的运算速度具有很大优势, 也具有较高的预测精度。GA-BP 神经网络通过遗传算法寻找最优的初始参数, 虽然可以提升预测精度, 但牺牲了大量运算时间。SVM 通常在输

入、输出维度较高时有很好的预测效果,但 SVM 在此次滚动预测方面效果并不好,并且运算时间也比较长。EMD 得到的 IMF 通常接近 10 个,需要为每个 IMF 建立预测模型,可以假设每个 IMF 的运算时间大致相同,这样即使是运算较快的 BP 神经网络的总的运算时间也大致为 $1.96 \times 10 = 19.6(\text{s})$,而 ELM 只需要接近 $0.01 \times 10 = 0.1(\text{s})$ 。

4.2 EMD 和 ELM 结合的预测效果分析

本节建立 3 种模型比较说明构建相似日时间序列和 EMD 与 ELM 结合对提升预测精度的作用。模型 1 为传统预测模型,直接选取预测日前 28 天数据构成序列值,对序列值直接构建 ELM 神经网络进行预测。神经网络的输入为历史时间点的辐照量数据、阴晴、湿度信息,及预测时间点的阴晴信息,输出为预测时间点的辐照量。在模型 1 中,环境信息作为神经网络的输入,旨在通过神经网络的训练过程建立辐照量与各个环境信息的关系。模型 2 首先利用环境因素构建相似日时间序列,再直接建立 ELM 预测模型。考虑到辐照量应和前 2~3 h 的辐照量关系较大,ELM 神经网络的输入为预测时间点前 3 h 的辐照量值,输出为预测时刻辐照量值。该过程为单步滚动预测,环境数据未参与神经网络的训练与预测。模型 3 为 EMD 和 ELM 组合预测模型,各神经网络的输入均为预测时刻前 3 h 的数值,输出为预测时刻数值。

为了验证预测模型在不同天气及季节状况下的预测效果,分别选取 2010 年 4 月 4 日、2010 年 4 月 7 日、2010 年 8 月 29 日和 2010 年 11 月 27 日为例进行预测。3 种模型对不同日期辐照量的预测结果如图 6 所示,预测误差如表 4 所示。模型 3 的总预测时间均在 1 s 以内。

从表 4 结果看出,模型 1 的预测误差很大,这说明虽然辐照量与阴晴、湿度的相关性很大,但单纯通过神经网络训练的方式,让神经网络自身建立辐照量和环境因素的关系并不好。这需要大量的参数调节过程,并且很难将神经网络训练到理想的状况。模型 2 的预测结果比模型 1 更精确,说明了构建相似日时间序列的重要性。模型 3 的预测结果明显比其他 2 个模型精确,说明了 EMD 在提升辐照量预测精度上的有效性。但是,11 月 27 日的 δ_{MAPE} 为 62.21%,误差很大。通过分析发现 11 月 27 日环境信息显示其全天为晴,但是辐照量却很低。造成这种情况的原因可能是云层观测、记录出现错误^[3],导致模型 3 中通过云层信息构造的相似日时间序列不适合 11 月 27 日的辐照量预测。本文专门列出 11 月 27 日的情况是为了说明,在构建相似日时间序列时,利用的是全天的环境数据,当前几小时预测误差很大时,可以通过更新正确的实际环境数据来更新相似日时间序列,这样可以降低后面时刻预测的误差。




图 6 3 种模型对不同日期辐照量预测结果
Fig.6 Radiation forecasting results of three models for different days

表 4 3 种模型预测结果误差分析
Tab.4 Error analysis for three forecasting models

日期	$\delta_{\text{MAPE}}/\%$			$\delta_{\text{RMSE}}/\%$		
	模型 1	模型 2	模型 3	模型 1	模型 2	模型 3
2010-04-04	71.47	39.72	20.41	143.28	99.33	38.77
2010-04-07	15.93	6.63	5.12	103.42	43.88	38.37
2010-08-29	23.92	22.94	16.40	103.42	43.88	38.37
2010-11-27	137.80	89.97	62.21	175.59	119.66	60.80

5 结论

本文提出的逐时辐照量组合预测模型,首先利用环境因素构建相似日时间序列,然后利用 EMD 和 ELM 各自的优点,实现既快速又准确的预测。

通过算例分析得到如下结论:构建的相似日时间序列可以有效提升 ELM 神经网络的预测效果;ELM 预测算法具有极快的运算速度;EMD 算法可以有效提高预测精度;EMD 与 ELM 组合预测算法可以实现既快速又准确的预测。

此外,EMD 与 ELM 组合预测模型还具有自我更新修正能力,这也是以后重点研究的方向。

参考文献:

- [1] ELKE L, HURKA J, DETLEV H, et al. Irradiance forecasting for the power prediction of grid-connected photovoltaic systems[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2009, 2(1): 2-10.
- [2] NOMIYAMA F, ASAI J, TAKUMA M, et al. A study on global solar radiation forecasting models using meteorological data and their application to wide area forecast[C]//IEEE International Conference on Power System Technology (POWERCON). Fukuoka, Japan: IEEE, 2012: 1-6.
- [3] YANG Dazhi, PANID J, WILFRED M. Hourly solar irradiance time series forecasting using cloud cover index[J]. Solar Energy, 2012, 86(12): 3531-3543.
- [4] CHRISTOPHE P, CYRIL V, MARC M, et al. Forecasting of pre-processed daily solar radiation time series using neural networks[J]. Solar Energy, 2010, 84(12): 2146-2160.
- [5] WU Ji, CHAN C K. Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN[J]. Solar Energy, 2011, 85(5): 808-817.
- [6] 谢宏, 陈志业, 牛东晓, 等. 基于小波分解与气象因素影响的电力系统日负荷预测模型研究[J]. 中国电机工程学报, 2001, 21(5): 5-10.
XIE Hong, CHEN Zhiye, NIU Dongxiao, et al. The research of daily load forecasting model based on wavelet decomposing and climatic influence[J]. Proceedings of the CSEE, 2001, 21(5): 5-10.
- [7] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2001, 31(31): 102-107.
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2001, 31(31): 102-107.
- [8] 刘兴杰, 米增强, 杨奇逊. 一种基于 EMD 的短期风速多步预测方

法[J]. 电工技术学报, 2010, 25(4): 165-170.

- LIU Xingjie, MI Zengqiang, YANG Qixun. A novel multi-step prediction for wind speed based on EMD[J]. Transactions of China Electrotechnical Society, 2010, 25(4): 165-170.
- [9] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006 70(1-3): 489-501.
- [10] CHEN Xia, DONG Zhaoyang, MENG Ke, et al. Electricity price forecasting with extreme learning machine and bootstrapping[J]. IEEE Transactions on Power Systems, 2012, 27(4): 2055-2062.
- [11] XIA Min, ZHANG Yingchao, WENG Liguang, et al. Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs[J]. Knowledge-Based System, 2012, 36: 253-259.
- [12] 代倩, 段善旭, 蔡涛. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究[J]. 中国电机工程学报, 2011, 31(34): 28-35.
DAI Qian, DUAN Shanxu, CAI Tao. Short-term PV generation system forecasting model without irradiation based on weather type clustering[J]. Proceedings of the CSEE, 2011, 31(34): 28-35.
- [13] 李建红, 陈国平, 葛鹏江, 等. 基于相似日理论的光伏发电系统输出功率预测[J]. 华东电力, 2012, 40(1): 153-157.
LI Jianhong, CHEN Guoping, GE Pengjiang, et al. Output power forecasting of PV generation system based on similar day theory[J]. East China Electric Power, 2012, 40(1): 153-157.
- [14] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A, 1998, 454: 903-995.

作者简介:



王守相

王守相(1973-),男,山东潍坊人,教授,博士研究生导师,研究方向为分布式发电、微网与智能配电网(E-mail: sxwang@tju.edu.cn);

王亚旻(1990-),男,山东聊城人,硕士研究生,研究方向为分布式发电出力预测(E-mail: mygreat2008@163.com);

张娜(1981-),女,内蒙古呼伦贝尔人,博士研究生,研究方向为智能配电网和分布式发电出力预测(E-mail: zhangna2010337@163.com)。

Hourly solar radiation forecasting based on EMD and ELM neural network

WANG Shouxiang¹, WANG Yamin¹, LIU Yan², ZHANG Na¹

(1. Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China;

2. China Electric Power Research Institute(State Grid Metering Center), Beijing 100192, China)

Abstract: Accurate solar radiation forecasting is essential for photovoltaic generation system. An hourly solar radiation forecasting model based on EMD(Empirical Mode Decomposition) and ELM neural network is proposed. The hourly solar radiation sequence of similar days is built according to the environmental information of the forecast day, which is then decomposed to signals with different frequencies by EMD. An ELM neural network forecasting model is built for each signal. The forecasting value of original solar radiation sequence is obtained by adding up the forecasting values of different signals. Case study shows that, compared with the traditional forecasting methods, the proposed method has higher forecasting accuracy and faster computation speed.

Key words: EMD; ELM neural network; solar energy; radiation; forecasting; models