

基于和声搜索 - 高斯过程混合算法的光伏功率预测

李元诚, 王 蓓, 王旭峰

(华北电力大学 新能源电力系统国家重点实验室, 北京 102206)

摘要: 光伏发电并网后会对电网产生冲击, 影响电网稳定。通过对光伏发电功率的特性分析, 在研究高斯过程算法原理的基础上, 建立了基于高斯过程的光伏发电功率预测模型。针对传统高斯过程中优化超参数采用共轭梯度法存在的缺陷, 提出采用和声搜索算法代替共轭梯度法, 得到一种基于和声搜索优化的混合高斯过程模型。仿真结果表明, 采用和声搜索优化后的高斯过程混合算法比传统高斯过程方法的预测精度更高。

关键词: 并网; 光伏; 发电; 输出功率; 预测; 高斯过程; 和声搜索; 优化; 模型

中图分类号: TM 615

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2014.08.003

0 引言

光伏产业近年来发展迅猛, 以年均 30% 以上的速度快速增长。可以预见, 在 21 世纪, 光伏发电不仅将替代部分传统发电方式, 而且将成为全球电力供应的主体^[1]。

光伏产业在迅猛发展的同时也面临一个危险趋势, 即仅仅关注兆瓦级甚至吉瓦级的产能, 而忽视并网时对大电网的安全保护。由于光伏发电输出功率的特殊性, 以及由于天气突变造成短时间输出功率急剧变化的特点, 并网后会对电网产生冲击, 影响电网的安全稳定运行。因此针对含有光伏发电系统的电网进行发展规划和并网运行时, 需要对光伏发电功率进行预测, 从而解决大电网中电力调度、负荷分配等问题, 有效地减轻光伏发电并网后对电网安全性的影响^[2]。

在 20 世纪 90 年代初, 光伏发电功率预测主要沿用了传统预测技术, 采用的方法主要为时间序列法^[3]。到 90 年代中后期, 随着人工智能领域机器学习方法的快速发展, 许多先进的机器学习算法应用到光伏发电功率预测中, 采用的模型主要有神经网络 (ANN) 模型^[4-6]、支持向量机 (SVM) ^[7-8] 等。这些方法在预测过程中除了采用历史功率数据外, 还考虑了气象因素、环境因素和特殊事件等许多随机因素, 从而使光伏发电功率预测的精度得到提高。然而 ANN 本身在网络结构选择上具有随意性, 存在过拟合和易陷入局部极小等本质上的问题, 鲁棒性差。SVM 基于小样本统计学习理论, 具有强大的自学习、抗噪声、泛化能力, 能够较好地解决小样本、非线性等实际问题, 取得了比 ANN 更好的预测效果。但是 SVM 也存在一些问题, 例如怎样选取特定问题中的核函数和核参数等。从 21 世纪初开始, 集成 (integrated) 模型和混合 (hybrid) 模型^[9] 被引入到功率预测领域, 由于这些模型在参数选取等方面存在一些随意

性, 可以采用启发式算法对模型参数进行优化选取, 从而获得含有最优参数的预测模型, 进一步提高预测精度。

本文在对光伏功率预测相关方法进行研究的基础上, 建立了基于高斯过程 GP (Gaussian Process) 的光伏发电功率预测模型。相比 SVM^[10], GP 是一种具有概率意义的学习机, 能克服 SVM 难以估计输出的缺点, 且更容易实现。针对传统 GP 中优化超参数采用的共轭梯度法存在一些缺陷, 如优化效果对初值依赖性强、迭代次数难以确定和易陷入局部最优等, 提出采用和声搜索 HS (Harmony Search) 算法代替共轭梯度法优化 GP 的超参数, 得到一种基于 HS 优化的混合 GP 模型并应用于光伏功率预测问题中。最后通过 MATLAB 仿真, 对提出的混合预测算法的有效性进行了验证。

1 光伏功率特性分析

光伏发电具有很强的周期性, 出力大体集中在每天 07:00—19:00, 这段时间和电力负荷有一定的重合, 在负荷高峰时期光伏发电能提供相当数量的用电量, 起到了调峰作用。

光伏阵列的输出功率还具有非线性, 并在很大程度上受到光照强度、环境温度等因素影响。光照强度对光伏发电功率具有重要影响, 光伏电池、组件的光电流与光照强度成正比, 当光照强度在 100~1000 W/m² 范围内变化时, 光电流始终随光照强度的增长而线性增长; 而光照强度对电压的影响很小, 当光照强度在 400~1 000 W/m² 范围内变化时, 光伏电池、组件的开路电压基本保持不变。可见光伏电池的功率与光照强度也基本保持正比关系。

温度对光伏发电功率也有一定影响。总体而言, 温度每升高 1℃, 功率减少 0.35%。虽然当温度降低时太阳电池的光电转换效率会有所提高, 但是还是有一个临界值, 当温度无限降低时光伏阵列的输出不会无限增大, 而一般情况下, 气温低于 0℃ 和

0℃ 时相比,出力值基本没有差别。所以在本文中当气温低于 0℃ 时,都按 0℃ 处理^[11]。

天气类型对光伏发电的功率变化起重要作用。天气类型可以分为晴、晴间多云、多云、雾、阴、雨、雪、扬沙等。不同的天气类型下气象因素一定会有很大的差别,所以要根据预测日天气情况来选取历史功率数据作为样本。

综上所述,本文在构建样本集及建模时,主要考虑 3 种因素:光照强度、环境温度、天气类型。另外考虑到光伏发电出力的集中时间,选取 07:00—19:00 时段内的数据点作为样本点。

2 优化 GP 模型的建立

在研究 GP 算法原理的基础上,本文建立了基于 GP 的光伏发电功率预测模型。但由于传统的 GP 算法采用共轭梯度法进行参数优化,而共轭梯度法存在优化效果对初值依赖性强、迭代次数难以确定和易陷入局部最优等缺陷,因而本文提出采用 HS 算法代替共轭梯度法来优化超参数,从而得到一种基于 HS 优化的混合 GP 模型。

2.1 共轭梯度法优化的传统 GP

GP^[12]是基于高斯随机过程和贝叶斯^[13]学习理论发展起来的一种新的机器学习方法,适于处理高维、小样本、非线性的复杂问题,在非线性回归、分类、概率密度估计等领域已得到成功应用。

假设有 n 个观察数据的学习样本集 $D=(X, y)$, X 表示 $d \times n$ 维输入矩阵, y 表示输出矢量。

假设观察值 y 被噪声腐蚀,它与函数输出值 f 相差 ε ,即:

$$y=f(x)+\varepsilon \quad (1)$$

其中, x 为输入向量(自变量); ε 为独立的随机变量,符合高斯分布,如式(2)所示。

$$\varepsilon \sim N(0, \sigma_n^2) \quad (2)$$

其中, σ_n^2 为噪声的方差。

观察目标值 y 的先验分布为:

$$y \sim N(0, K + \sigma_n^2 I) \quad (3)$$

其中, I 为单位矩阵; $K=K(X, X)$ 为输入矩阵 X 对应的对称正定的协方差矩阵。

假设有新的输入向量 x^* 相对应的输出值 y^* , 那么 n 个训练样本输出矢量 y 和 1 个测试样本输出值 y^* 形成的联合高斯先验分布为:

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N \left(0, \begin{bmatrix} K(X, X) + \sigma_n^2 I & K(X, x^*) \\ [K(X, x^*)]^T & k(x^*, x^*) \end{bmatrix} \right) \quad (4)$$

其中, $K(X, x^*)$ 为测试点 x^* 与训练集的所有输入点 X 的 $n \times 1$ 维协方差矩阵; $k(x^*, x^*)$ 为测试点 x^* 自身的协方差。

本文采用的协方差函数为:

$$k_y(x_p, x_q) = \sigma_f^2 \exp \left[-\frac{1}{2l^2} (x_p - x_q)^2 \right] + \sigma_n^2 \delta_{pq} \quad (5)$$

其中, x_p 和 x_q 为 2 个任意样本的输入向量, $p \in \{1, 2, \dots, n\}$, $q \in \{1, 2, \dots, n\}$; σ_f , σ_n 和 l 均为超参数, l 用于关联性测定,值越大表示输入与输出之间的相关性越小, σ_f 控制局部相关性程度; δ_{pq} 为 Kronecker 符号,当 $p=q$ 时 $\delta_{pq}=1$, 否则 $\delta_{pq}=0$ 。

超参数的选择对预测结果有重要的影响^[14]。在训练 GP^[15]模型时,可以通过学习样本的对数似然的极大化自适应获得,称之为共轭梯度法。

根据贝叶斯回归原理,GP 模型以学习样本集为基础获取 X 与 y 的关系,进而预测与 x^* 对应的最可能的输出值 y^* ,其预测分布也是高斯型的。

在统计理论上,协方差是一个对称正定的函数,故协方差函数等同于核函数。核函数可以将映射到高维特征空间的非线性关系数据转换为线性关系数据,从而使得复杂非线性问题转化为简单线性问题求解。

2.2 基于 HS 的 GP 超参数优化

为了克服传统 GP 算法中采用共轭梯度法优化超参数的缺陷,本文提出采用 HS 算法^[16-17]对样本训练过程的 GP 模型进行超参数优化,从而得到和声搜索-高斯过程(HS-GP)混合算法。

HS 算法首先产生 s_{HM} 个初始解(和声)放入和声记忆库 HM(Harmony Memory)内;然后在 HM 内以记忆库取值概率 r_{HMC} 搜索新解,即随机产生 0~1 之间的随机数 rand,如果 $rand < r_{HMC}$,则新解在 HM 内随机搜索得到;否则以 $1-r_{HMC}$ 的概率在 HM 外变量可能的值域中搜索;再以微调概率 r_{PA} 对取自 HM 内的新解产生局部扰动;最后,判断新解目标函数值是否优于 HM 内的最差解的目标函数值,若是,则由新解替换最差解,并不断迭代,直至达到预定迭代次数 T_{max} 为止。

算法通过引入 r_{HMC} 和 r_{PA} 2 个参数,期望达到算法对解空间开发、探索能力的平衡,但是针对如何取值的问题,并没有理论基础。Z. W. Geem 等人认为 r_{HMC} 应取较大值, r_{PA} 应取较小值,这与遗传算法^[18]中交叉概率与变异概率的取值规律类似。

2.2.1 设定 HS 的参数

首先要确定每一个解向量的参数个数 N_A 和本文使用的 GP 协方差函数中的 3 个超参数。 s_{HM} 是 HS 算法的一个重要参数,一般而言, s_{HM} 与算法的全局寻优能力成正比,但由于 HS 从多点同时开始,随着 s_{HM} 不断增大,计算量也会增大,从而影响到搜索的寻优速度。 r_{HMC} 是 HS 算法的另一个重要参数,取值一般在 0~1 之间,它决定每次迭代过程中新解产生的方式。因新解中的每一个变量都依赖 r_{HMC} ,一般 r_{HMC} 取 0~1

之间较大的值。 r_{PA} 在算法中起到控制局部搜索的作用,避免陷入局部最优,其值一般取 0.1~0.5 之间。音调调节带宽 W_B 用于保证调节幅度不会超出取值范围。根据上述分析,本文中各参数的取值如表 1 所示。

表 1 HS 的参数设定
Tab.1 Setting of HS parameters

参数	取值	参数	取值
N_A	3	r_{PA}	0.3
s_{HM}	6	W_B	0.01
r_{HMC}	0.9	T_{max}	5000

2.2.2 初始化 HM

HS 算法可以随机给出初始解,形成 HM,也可以使用其他算法构成一个较好的初始 HM。由于 HS 算法是基于邻域搜索的,初始解的好坏对搜索性能的影响很大^[19],尤其是相对复杂的优化问题,随机生成的初始解一般不可行。将 2.1 节中 GP 采用的协方差函数的超参数 σ_f, σ_n 和 l 作为一组解向量 ω ,即 HS 算法中的一组和声 $\omega = \{\sigma_f, \sigma_n, l\}$,随机取出 s_{HM} 个 ω_i ,采用实数编码,作为初始 HM,即 $\{\omega_1, \omega_2, \dots, \omega_{s_{HM}}\}$,HM 为和声 ω 的 s_{HM} 元组。

在 2.1 节的 GP 算法的学习过程中,可以自适应地得到多组超参数,如表 2 所示,并将其作为 HM。

表 2 高斯过程模型参数
Tab.2 Parameters of GP model

σ_f	σ_n	l
0.3787	1.2597	0.0045
0.3441	1.2911	0.0050
0.3067	1.3278	0.0056
0.3537	1.2546	0.0049
0.3264	1.2999	0.0051

2.2.3 产生新解

新解的第一个变量 ω'_1 有 r_{HMC} 的取值概率选择 HM 中 $\omega_1^1 \sim \omega_{s_{HM}}^1$ 的任何一个值,有 $1-r_{HMC}$ 的取值概率选择 HM 外(且在变量范围内)的任何一个值。同样,其他变量的生成方式如下:

$$\omega'_i = \begin{cases} \omega_i \in (\omega_1^1, \omega_i^2, \dots, \omega_{s_{HM}}^1) & \text{rand} < r_{HMC} \\ \omega_i \in Z_i & \text{其他} \end{cases} \quad (6)$$

其中, $i=1, 2, \dots, N$; rand 表示 $[0, 1]$ 上均匀分布的随机数; Z_i 为变量范围; $\omega_i^j (j=1, 2, \dots, s_{HM})$ 为第 i 次产生的 HM 的第 j 个解。

如果新的和声 ω'_i 来自 HM,要对其进行微调。具体操作如下:

$$\omega'_i = \begin{cases} \omega_i + \text{rand} \cdot W_B & \text{rand} < r_{PA} \\ \omega_i & \text{其他} \end{cases} \quad (7)$$

其中, $i=1, 2, \dots, N$ 。

2.2.4 更新 HM

对新解进行评估,就是计算新解的适应度值。如

果优于 HM 所有解中适应度值最差的一个,则将新解更新至 HM 中,具体操作如下:

$$\text{If fitness}(\omega') < \text{fitness}(\omega^{\text{worst}}) \text{ then } \omega^{\text{worst}} = \omega'$$

2.2.5 检查停止准则

重复 2.2.3 和 2.2.4 节,直至迭代次数达到 T_{max} 为止。此时的 HM 中的最优解即为 GP 协方差函数超参数的最优值。

表 3 为利用 HS 算法优化后得到的结果。

表 3 优化后高斯过程模型参数
Tab.3 Parameters of optimized GP model

σ_f	σ_n	l
0.3067	1.3024	0.0050

3 基于优化 GP 的光伏发电功率预测

3.1 构建样本集

3.1.1 样本分析

首先,光伏系统只在有日照的时间段内输出功率。由于季节影响,每天的日出、日落和日照时间长度不尽相同,所以光伏出力的时间段也不尽相同,尤其是在季节变化明显的中国北部,几天之后的天气状况截然不同,所以没有必要选取过多的样本点。为了统一光伏出力格式,本文规定每天光伏出力数据采样从 07:40 开始,到 19:40 结束,每间隔 15 min 是一个采样点,全天一共 49 个采样点,对于小于标准的数据赋值为零,分别采得每个时刻的发电功率、光照强度、气温。

其次,由于光伏发电的出力特性是由光资源的特性决定的,不同的天气类型下气象因素一定会有很大的差别,所以要根据预测日天气情况来选取历史功率数据作为样本。本文将光伏发电功率按照晴、晴间多云、多云(雾)、阴(雨、雪、扬沙)4 种天气类型划分。若不考虑其他因素,越靠近预测日的样本与预测日的功率特性越接近。本文为了将天气类型作为样本的一个特征,将每种天气类型进行数值化处理,见表 4。这样就可以将相同天气类型的光伏出力数据组成关联性很强的数据序列,作为 GP 的训练样本集。

表 4 天气类型数值化表
Tab.4 Quantization of weather types

天气类型	取值
晴	0.9
晴间多云	0.7
多云(雾)	0.3
阴(雨、雪、扬沙)	0.1

最后,选取关联性强的历史数据作为样本,有利于模型的收敛。若取过多的历史数据作为输入,会增加模型的学习复杂度,收敛速度慢;若取过少的历史数据,又会增大模型的预测误差,导致模型泛化能力

和连续多步预测能力差。

3.1.2 样本构建

根据上面的样本分析,本文只选择预测日前 5 天中相同天气类型的历史数据。对光伏发电功率进行预测时,首先通过天气预报获得预测日的天气类型,然后选择与预测日天气类型相同的历史数据,将这些数据作为训练样本集。本文将样本集构成因素归纳为下面几类。

a. 天气类型 W 。通过天气预报获得,分为晴、晴间多云、多云(雾)、阴(雨,雪,扬沙)4 种类型。

b. 温度属性 T 。 $T=\{t_1,t_2,t_3,t_4,t_5\},t_1,t_2,t_3,t_4,t_5$ 分别为预测日前 5 天中同一时刻的温度。

c. 光照强度 S 。 $S=\{s_1,s_2,s_3,s_4,s_5\},s_1,s_2,s_3,s_4,s_5$ 分别为预测日前 5 天中同一时刻的光照强度。

d. 历史光伏出力数据 P 。 $P=\{p_1,p_2,p_3,p_4,p_5\},p_1,p_2,p_3,p_4,p_5$ 分别为预测日前 5 天中同一时刻的发电功率值。

根据上述理论,GP 回归模型的训练样本集中,输入为与预测日天气类型相同的前 5 天中头 4 天同一时刻的光伏发电功率值、气温和光照强度。输出为前 5 天中第 5 天同一时刻的发电功率值、气温和光照强度。测试样本集中,输入为前 5 天中第 5 天同一时刻光伏发电功率值、气温和光照强度,输出则是预测日当天该时刻的发电功率值。

3.2 建立 HS-GP 预测模型

构建基于 HS-GP 功率预测模型步骤如下。

a. 由若干实测功率、光照强度和温度建立训练样本 (x,y) ,输入向量 x 为预测日前 5 天中头 4 天的数据,输出向量 y 为预测日前 5 天中第 5 天的数据。

b. 当影响发电量的各主要因素的数量级相差较大或同一控制因素的离散性太大时,将不利于 GP 的学习,需要对实际采集数据和预测样本数据进行归一化处理。

c. 取式(5)协方差函数,利用 3.1 节构建的学习样本进行学习,通过 HS 算法获得最优的超参数,生成 HS-GP 模型。

d. 将测试样本代入到 HS-GP 预测模型中,测试样本的输入向量由预测日前一天的 49 个发电功率、光照强度和环境温度构成,输出向量即为预测日的 49 个发电功率数据。

HS-GP 预测模型的流程如图 1 所示。

4 算例分析

本文采用龙源西藏羊八井太阳能电站远程监测平台数据,选取 2012 年 4 月某 5 天相同天气类型的数据样本,每天 49 个样本点,共 245 个样本,包含发电功率、天气类型、光照强度以及温度。将前 4 天的




图 1 HS-GP 预测模型

Fig.1 HS-GP forecasting model

数据作为训练样本,然后将第 5 天的数据作为测试样本,对第 6 天(预测日)的 49 个功率进行预测。表 5 为光伏电站一段时期内的天气类型。

表 5 天气类型
Tab.5 Weather type

日期	天气类型	日期	天气类型
2012-04-20	晴	2012-04-24	多云(雾)
2012-04-21	晴	2012-04-25	多云(雾)
2012-04-22	晴	2012-04-26	晴
2012-04-23	晴	2012-04-27	晴

表 6 为不同日期同一个时刻的训练样本集(以 07:40 为例)。其中,每一天的输出发电功率是第 2 天输入的发电功率。

表 6 训练样本集
Tab.6 Training sample sets

日期	输入				输出发电功率/kW
	天气类型	发电功率/kW	光照强度/(kW·m ⁻²)	温度/℃	
2012-04-20	0.9	144.02	50.99	-10.48	177.02
2012-04-21	0.9	177.02	60.99	-10.20	168.86
2012-04-22	0.9	168.86	52.99	-10.35	191.42
2012-04-23	0.9	191.42	58.99	-10.38	178.92

表 7 为某一个时刻测试样本集(以 07:40 为例)。将 4 月 26 日的数据作为测试样本的输入,输出即为 4 月 27 日(预测日)的预测功率值。

将 HS 优化的超参数代入 GP 的协方差函数中,即利用优化的 GP 模型进行预测,图 2 是优化模型

表 7 测试样本集
Tab.7 Test sample set

日期	输入				输出发电功率/kW
	天气类型	发电功率/kW	光照强度/(kW·m ⁻²)	温度/℃	
2012-04-26	0.9	178.92	55.99	-10.29	待预测

的预测结果。方差表示预测值的误差允许范围。由图 2 可知,所得预测值均在误差允许范围内,优化后的 GP 模型取得了较高的预测精度。




图 2 HS-GP 预测模型预测结果图
Fig.2 Effect of HS-GP forecasting model

优化后的 GP 模型(HS-GP)和传统 GP 模型预测结果的比较见表 8,表中 δ_{RE} 表示相对误差。HS-GP 采用 HS 算法优化超参数,而传统 GP 模型默认采用共轭梯度法优化超参数。HS-GP 模型和传统 GP 模型的最大相对误差分别为 20.06%、34.2%,平均相对误差分别为 5.578%、5.801%,HS-GP 模型进行预测的最大相对误差和平均相对误差均小于传统 GP 模

表 8 预测结果对比
Tab.8 Comparison of forecasting results

时刻	观测值/ kW	传统 GP 模型		HS-GP 模型	
		预测值/kW	$\delta_{RE}/\%$	预测值/kW	$\delta_{RE}/\%$
07:40	161.21	106.0730	34.200	140.330	12.950
07:55	298.91	282.9170	5.350	259.799	13.080
08:10	520.17	479.9250	7.737	499.760	3.924
08:25	616.16	694.0270	12.640	600.877	2.480
08:40	861.68	921.5130	6.944	831.866	3.460
08:55	1050.20	1158.2000	10.280	1176.270	12.000
09:10	1446.92	1399.5900	3.271	1502.600	3.848
09:25	1644.54	1641.1000	0.209	1675.270	1.869
09:40	1873.96	1878.1300	0.223	1922.320	2.581
09:55	2074.08	2106.3000	1.553	2156.500	3.974
10:10	2297.11	2321.4900	1.061	2293.530	0.156
10:25	2781.23	2519.9900	9.393	2488.050	10.540
10:40	2674.06	2698.6400	0.919	2659.970	0.527
10:55	2784.02	2854.8600	2.544	2804.370	0.731
11:10	2887.68	2986.8400	3.434	2991.980	3.612
11:25	3011.51	3093.6400	2.727	3050.780	1.304
11:40	3104.89	3175.2800	2.267	3162.710	1.862
11:55	3215.94	3232.8200	0.525	3285.900	2.175
12:10	3225.94	3268.3300	1.314	3306.910	2.510
12:25	3219.15	3284.8500	2.041	3311.600	2.872
12:40	3250.14	3286.1600	1.108	3337.460	2.687
12:55	3240.03	3276.5100	1.126	3288.010	1.481
13:10	2800.11	3260.2400	16.430	3280.960	17.170
13:25	3199.24	3241.3500	1.316	3167.220	1.001

时刻	观测值/ kW	传统 GP 模型		HS-GP 模型	
		预测值/kW	$\delta_{RE}/\%$	预测值/kW	$\delta_{RE}/\%$
13:40	3184.61	3223.0400	1.207	3228.680	1.384
13:55	3207.36	3207.3100	0.001	3199.640	0.241
14:10	3150.09	3194.7000	1.416	3189.070	1.238
14:25	3099.31	3184.1000	2.736	3162.630	2.043
14:40	3147.16	3172.8100	0.815	3137.200	0.317
14:55	3090.90	3156.7700	2.131	3094.560	0.119
15:10	3071.39	3130.9400	1.939	3108.620	1.213
15:25	3144.46	3089.8700	1.736	3103.650	1.298
15:40	3033.02	3028.2900	0.156	3082.080	1.617
15:55	2845.79	2941.7500	3.372	2991.000	5.103
16:10	2765.71	2827.1400	2.221	2887.940	4.419
16:25	2693.86	2683.1000	0.399	2724.120	1.123
16:40	2613.36	2510.2900	3.944	2515.880	3.730
16:55	2290.03	2311.3500	0.931	2373.690	3.653
17:10	2170.36	2090.7700	3.667	2100.830	3.204
17:25	1990.81	1854.5100	6.847	1620.090	18.620
17:40	1741.47	1609.5000	7.578	1488.240	14.540
17:55	1485.81	1363.1100	8.258	1539.110	3.587
18:10	1253.50	1122.5900	10.440	1120.280	10.630
18:25	832.77	894.5230	7.415	920.730	10.560
18:40	620.85	684.4210	10.240	727.553	17.190
18:55	432.63	496.4650	14.760	470.704	8.801
19:10	347.56	333.3390	4.092	287.919	17.160
19:25	213.20	196.2420	7.954	170.434	20.060
19:40	109.24	84.9994	22.190	123.073	12.660

型,表明用 HS 算法代替共轭梯度法取得了较好的预测效果。

由仿真结果可见,HS-GP 模型进行预测的相对误差波动较小,稳定在 20%以内,而传统 GP 模型进行预测的相对误差在 2 个时刻大于 20%,波动较大。从而表明了本文提出的采用 HS 优化的 GP 模型对光伏功率预测的有效性和可行性。

5 结论

针对采用共轭梯度法优化传统 GP 模型超参数时存在的一些缺陷,本文提出采用 HS 算法对样本训练过程中的 GP 模型进行最优超参数自动搜索,构造了 HS-GP 混合算法,并将混合算法应用在光伏发电功率的预测中。算例仿真结果表明,HS-GP 混合算法的预测精度优于传统 GP 方法。

参考文献:

[1] LIU T,XU G,CAI P. Development forecast of renewable energy power generation in China and its influence on the GHG control strategy of the country[J]. Renewable Energy,2011,36(2): 1284-1292.

[2] LIU L Q,WANG Z X,ZHANG H Q. Solar energy development in China—a review[J]. Renewable and Sustainable Energy Reviews, 2010,14(1):301-311.

[3] REIKARD G. Predicting solar radiation at high resolutions:a comparison of time series forecasts[J]. Solar Energy,2009,83(3): 342-349.

- [4] 王晓兰,葛鹏江. 基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J]. 电力自动化设备, 2013, 33(1): 100-103.
WANG Xiaolan, GE Pengjiang. PV array output power forecasting based on similar day and RBFNN[J]. Electric Power Automation Equipment, 2013, 33(1): 100-103.
- [5] 陈昌松,段善旭,殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.
CHEN Changsong, DUAN Shanxu, YIN Jinjun. Design of photovoltaic array power forecasting model based on neural network[J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.
- [6] 丁明,王磊,毕锐. 基于改进BP神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制, 2012, 40(11): 93-99.
DING Ming, WANG Lei, BI Rui. A short-term prediction model to forecast output power of photovoltaic system based on improved BP neural network[J]. Power System Protection and Control, 2012, 40(11): 93-99.
- [7] SHI J, LI W J, LIU Y Q, et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines[J]. IEEE Transactions on Industry Applications, 2012, 48(3): 1064-1069.
- [8] 栗然,李广敏. 基于支持向量机回归的光伏发电出力预测[J]. 中国电力, 2008, 41(2): 74-78.
LI Ran, LI Guangmin. Photovoltaic power generation output forecasting based on support vector machine regression technique[J]. Electric Power, 2008, 41(2): 74-78.
- [9] LI Y L, WOLFS P J. A hybrid model for residential loads in a distribution system with high PV penetration[J]. IEEE Transactions on Power Systems, 2013, 28(3): 3372-3379.
- [10] LIU Y Q, SHI J, YANG Y P, et al. Short-term wind-power prediction based on wavelet transform-support vector machine and statistic-characteristics analysis[J]. IEEE Transactions on Industry Applications, 2012, 48(4): 1136-1141.
- [11] CHOU C T, TANG W L, TAI Y. Effect of substrate temperature on orientation of subphthalocyanine molecule in organic photovoltaic cells[J]. Thin Solid Films, 2012, 520(6): 2289-2292.
- [12] ALVAREZ M A, LUENGO D, LAWRENCE N D. Linear latent force models using gaussian processes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2693-2705.
- [13] SORIA-OLIVAS E, GOMEZ-SANCHIS J, JARMAN I H, et al. BELM: bayesian extreme learning machine[J]. IEEE Transactions on Neural Networks, 2011, 22(3): 505-509.
- [14] 孙斌,姚海涛,刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报, 2012, 32(29): 104-109.
SUN Bin, YAO Haitao, LIU Ting. Short-term wind speed forecasting based on Gaussian process regression model[J]. Proceedings of the CSEE, 2012, 32(29): 104-109.
- [15] RASMUSSEN C E. Gaussian processes for machine learning[M]. Cambridge, Massachusetts, USA: The MIT Press, 2006: 35-50.
- [16] SRINIVASA R R, NARASIMHAM S V L, RAMALINGA R M, et al. Optimal network reconfiguration of large-scale distribution system using harmony search algorithm[J]. IEEE Transactions on Power Systems, 2011, 26(3): 1080-1088.
- [17] GEEM Z. Optimal cost design of water distribution networks using harmony search[J]. Engineering Optimization, 2006, 38(3): 259-280.
- [18] 崔挺,孙元章,徐箭,等. 基于改进小生境遗传算法的电力系统无功优化[J]. 中国电机工程学报, 2011, 31(19): 43-50.
CUI Ting, SUN Yuanzhang, XU Jian, et al. Reactive power optimization of power system based on improved niche genetic algorithm[J]. Proceedings of the CSEE, 2011, 31(19): 43-50.
- [19] MASHINCHI M H, ORGUN M A, MASHINCHI M, et al. A tabu-harmony search-based approach to fuzzy linear regression[J]. IEEE Transactions on Fuzzy Systems, 2011, 19(3): 432-448.

作者简介:



李元诚

李元诚(1970-),男,山东烟台人,教授,博士,从事智能电网与信息安全技术等方面的研究(E-mail: dflyc@163.com);

王蓓(1989-),女,山东滨州人,硕士研究生,从事智能电网新能源方面的研究;

王旭峰(1982-),男,河北石家庄人,硕士研究生,从事光伏发电功率预测方面的研究。

Photovoltaic power forecasting based on harmony search and Gaussian process algorithms

LI Yuancheng, WANG Bei, WANG Xufeng

(State Key Laboratory for Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China)

Abstract: The integration of photovoltaic power generation into power grid has impact on its stability. The power characteristics of photovoltaic power generation are analyzed and the principle of Gaussian process algorithm is researched, based on which, a photovoltaic power forecasting model is built. Instead of the conjugate gradient method, the harmony search algorithm is applied in the built model to optimize the hyper-parameter. Simulative results show that, the Gaussian process algorithm optimized by the harmony search has higher accuracy than the traditional one.

Key words: grid-connection; photovoltaic cells; electric power generation; output power; forecasting; Gaussian process; harmony search; optimization; models