

# 基于LS-SVM的光伏最大功率跟踪控制方法\*

蔡纪鹤<sup>1</sup> 孙玉坤<sup>2</sup> 李蓓<sup>1</sup> 徐艳<sup>1</sup>

(1.常州工学院电子信息与电气工程学院,常州 213002; 2.江苏大学电气信息工程学院,镇江 212013)

**摘要:**为解决自然环境剧烈变化条件下,传统光伏最大功率跟踪控制中存在的控制精度低和误跟踪现象,建立了基于最小二乘支持向量机的最大工作点电压预测模型,通过该模型预测光伏发电系统的最大工作点电压,并用预测电压来修正恒电压控制法的参考电压,从而实现光伏发电系统的最大功率跟踪控制。仿真结果表明预测模型具有较高的精度,相对误差在0.04以内,控制方法能够快速、稳定地实现光伏发电系统的最大功率跟踪,有效避免误跟踪现象。

**关键词:**光伏发电 最大功率跟踪 最小二乘支持向量机

**中图分类号:** TM615 **文献标识码:** A **文章编号:** 1000-1298(2014)S0-0213-06

## 引言

光伏阵列是光伏发电系统的重要组成部分,其输出特性受外界环境影响,呈现强烈的非线性<sup>[1-2]</sup>。为进一步提高光伏系统的发电利用率,必须对光伏发电系统进行最大功率跟踪(Maximum power point tracking, MPPT)控制,使其输出的能量最大化<sup>[3-4]</sup>。传统光伏MPPT控制无法准确判断光伏阵列输出功率变化是由扰动还是由外界环境的变化而引起,在太阳光辐射度剧烈变化情况下,控制精度低、容易发生误跟踪现象<sup>[5]</sup>,从而造成最大功率跟踪控制系统性能下降,系统能量损失。

为克服传统最大功率跟踪方法存在的不足,引入一种新的数据挖掘方法——最小二乘支持向量机(Least square support vector machine, LS-SVM)法。文献[6]根据历史发电量、太阳光辐射度和大气温度作为模型输入,采用基于鲁棒学习的最小二乘支持向量预测光伏发电的输出功率。文献[7]根据开路电压、时间和温度作为模型输入,采用粒子群算法对支持向量机参数进行寻优,进而对MPPT的输出电压进行预测。本文在此基础上,建立最大工作点电压、太阳光辐射度和环境温度的最大工作点电压预测模型,用LS-SVM回归方法来预测光伏发电系统最大工作点电压,在此基础上结合传统的恒电压法,构造MPPT控制系统。充分发挥LS-SVM拟合能力与泛化能力强的特点,在太阳光辐射度剧烈变

化情况下,实现光伏阵列最大工作点的准确预测,大幅提高MPPT控制系统的性能。

## 1 LS-SVM原理

### 1.1 支持向量机原理

支持向量机<sup>[8-10]</sup>是从数据分类问题研究中发展而来的。在数据分类问题中,若采用传统的神经网络方法,可以这样简单的描述:系统随机产生一个超平面并移动它,直到数据集属于不同类的点正好位于超平面的不同侧面。该处理机制决定了采用神经网络进行数据分类方法最终获得分类超平面,靠近训练集中的点在绝大多数情况下,它并不是最优解。与神经网络方法不同,支持向量机通过寻找一个满足分类要求的超平面,并且使训练集中的点距离分类面尽可能远,即寻找一个分类面使它两侧的空白区域最大,如图1所示, $H$ 为分类线, $H_1$ 和 $H_2$ 分别为过两类中离分类线最近的样本且平行于分类线的直线。

设线性可分样本集 $(x_1, y_1), \dots, (x_l, y_l)$ ,其中 $x \in \mathbf{R}^n, y \in \{-1, +1\}$ ,分类线方程为 $x \cdot w + b = 0$ ,对它归一化处理,使上述线性可分样本集满足

$$y_i[(w \cdot x_i) + b] - 1 \geq 0 \quad (i = 1, 2, \dots, l) \quad (1)$$

这样的分类间隔等于 $2/\|w\|$ 最大,满足式(1)并且使分类间隔最大的优分类面就是最优分类面。 $H_1$ 和 $H_2$ 上的训练样本称作支持向量。通过使分类间隔最大提高泛化能力,这是支持向量机的

收稿日期:2014-06-30 修回日期:2014-08-18

\*国家自然科学基金资助项目(51077047)、江苏省2010年研究生创新计划资助项目(CX10B\_267Z)和常州工学院校级科研基金资助项目(YN1302)

作者简介:蔡纪鹤,讲师,主要从事光伏并网发电技术研究,E-mail: crane19810202@163.com

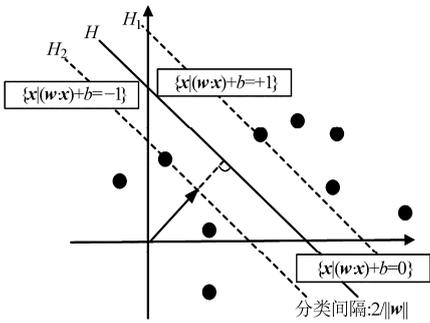


图1 支持向量机最优超平面分割

Fig.1 Optimal hyperplane segmentation chart of LS-SVM

核心思想。

统计学习理论指出,在  $N$  维空间中,设样本分布在一个半径为  $R$  的超球范围内,则满足条件  $\|w\| \leq A$  的正则超平面构成的 VC 维满足的界为

$$h \leq \min([R^2 A^2], n) + 1 \quad (2)$$

因此,使  $\frac{1}{2} \|w\|^2$  最小就是使 VC 维的上界最小,从而实现结构风险最小化准则中对函数复杂性的控制。

在式(2)约束下,最小化  $\frac{1}{2} \|w\|^2$ ,可以定义

Lagrange 函数

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \{a_i y_i [(x_i \cdot w) + b] - 1\} \quad (3)$$

式中, Lagrange 乘子  $a_i \geq 0$ 。对  $w, b$  最小化  $L(w, b, a)$ ,由最优解满足的条件(Karush - Kuhn - Tucker, KKT 条件)得

$$\begin{cases} \frac{\partial L(w^*, b^*, a^*)}{\partial b} = 0 \Rightarrow \sum_{i=1}^l a_i^* y_i = 0 \\ \frac{\partial L(w^*, b^*, a^*)}{\partial w} = 0 \Rightarrow \sum_{i=1}^l a_i^* x_i y_i = w \end{cases} \quad (4)$$

基于 Lagrange 函数的对偶原理,将原始问题转换成对偶问题

$$\begin{cases} \max \left\{ \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j (x_i \cdot x_j) \right\} \\ \text{s. t. } a_i \geq 0 \quad (i = 1, 2, \dots, l) \\ \sum_{i=1}^l a_i y_i = 0 \end{cases} \quad (5)$$

求解结果即得  $a_i^*$  解,  $a_i^*$  不为零的项所对应的样本就是支持向量。得到的最优分类面函数为

$$f(x) = \text{sgn}(w^* \cdot x + b^*) = \text{sgn} \left( \sum_{i=1}^l a_i^* y_i (x_i \cdot x) + b^* \right) \quad (6)$$

式中  $b^*$  ——分类阈值,可以用任意满足式(6)的支持向量求得

对于线性不可分情况,分类函数可能出现错分样本的情形。为了对错分样本数进行控制,在式(1)中引入松弛因子  $\xi_i \geq 0$ ,即将式(1)改写为  $y_i(w \cdot x_i + b) + \xi_i \geq 1$ ,同时将  $\frac{1}{2} \|w\|^2$  改写为  $\gamma \sum_{i=1}^l \xi_i$ ,即综合考虑使错分样本数最小又使分类间隔最大,即所谓的广义最优分类面,其中  $\gamma \geq 0$  体现了分类面对错分样本的惩罚程度。线性不可分的情况和线性可分的情况差别就在于,将线性可分情况下的约束条件  $a_i \geq 0$  换为更严格的约束条件  $0 \leq a_i \leq \gamma$ 。

对于非线性分类问题<sup>[11]</sup>,在原始空间中的简单最优分类面无法得到满意的分类结果,这时可以通过非线性变换转化为某个高维空间中的线性问题,即在变换空间求最优分类面。但这种空间变换可能非常复杂,一般情况下不易实现,而 SVM 通过核函数变换巧妙解决了这个问题。该方法的思路是用非线性变换  $\varphi$  将  $n$  维矢量空间中的向量  $x$  映射到高维特征空间,然后在高维特征空间中进行线性分类。

由此可知,不论是寻优函数还是分类函数都只涉及到样本之间的内积运算  $x_i \cdot x_j$ 。根据泛函理论,只要一种核函数  $K(x_i, x_j)$  满足 Mercer 条件,它就对应某一变换空间中的点积。因此,在最优分类面中采用适当的内积函数  $K(x_i, x_j)$  就可以实现一非线性变换后的线性分类,而计算复杂度并没有增加,此时目标函数式变为

$$Q(a) = \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j K(x_i, x_j) \quad (7)$$

相应的分类函数为

$$f(x) = \text{sgn} \left( \sum_{i=1}^l a_i^* y_i K(x_i \cdot x) + b^* \right) \quad (8)$$

支持向量机就是通过内积函数定义的非线性变换将输入向量映射到高维特征空间,并在该特征空间中构造最优分类面。

## 1.2 支持向量机回归

支持向量机回归的基本思想是通过一个非线性映射  $\varphi(\cdot)$  将数据映射到高维特征空间  $F$  (Hilbert 空间),然后在这个空间中进行线性回归,即

$$f(x) = w^T \varphi(x) + b \quad (9)$$

式中  $\varphi(\cdot)$  ——非线性函数

$w$  ——权值  $b$  ——阈值

这样,在高维特征空间的线性辨识就对应于低维输入空间的非线性辨识。

给定  $l$  对训练样本集  $\{x_i, y_i\} (i = 1, 2, \dots, l)$ ,根据统计学理论中的结构风险最小化准则,在特

征空间进行最优化逼近的  $f(\mathbf{x})$  应使得风险函数最小。

$$J = \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + \gamma \sum_{i=1}^l L(f(\mathbf{x}_i), y_i) \quad (10)$$

式中  $\gamma$ ——正规化参数

$L(\cdot)$ ——惩罚函数

通常取线性  $\varepsilon$  敏感函数, 定义为

$$L(f(\mathbf{x}), y) = \max(0, |f(\mathbf{x}) - y| - \varepsilon) \quad (11)$$

通过对偶原理、Lagrange 乘子与核函数技术, 将式(11)的最小化风险函数等价于二次规划问题

$$\begin{cases} \min_{a_i^*} \frac{1}{2} \sum_{i,j=1}^l (a_i^* - a_i)(a_j^* - a_j) K(\mathbf{x}_i \cdot \mathbf{x}_j) + \\ \quad \varepsilon \sum_{i=1}^l (a_i^* + a_i) - \sum_{i=1}^l y_i (a_i^* - a_i) \\ \text{s. t.} \quad \sum_{i=1}^l (a_i - a_i^*) = 0 \\ 0 \leq a_i, a_i^* \leq \gamma \quad (i = 1, 2, \dots, l) \end{cases} \quad (12)$$

式中, 核函数  $K(\cdot, \cdot)$  是满足 Mercer 条件的任意对称函数, 对应于特征空间的点积, 即

$$K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i) \varphi(\mathbf{x}_j) \quad (13)$$

求解上述二次规划问题, 即可得到  $a_i^*$  和  $a_i$ , 然后结合 KKT 条件可得到阈值  $b$ , ( $a_i^* - a_i$ ) 不为零时对应的输入样本即是支持向量。回归函数  $f(\mathbf{x})$  可表达为

$$f(\mathbf{x}) = \sum_{i=1}^l (a_i^* - a_i) K(\mathbf{x}_i, \mathbf{x}) + b \quad (14)$$

### 1.3 LS-SVM

LS-SVM 是支持向量机的特例, 在保持了支持向量机优越性能的基础上, 解决了支持向量机不等式约束的二次规划问题所带来的计算复杂性, 极大简化了计算, 提高了求解问题的速度<sup>[12-13]</sup>。LS-SVM 的回归算法描述如下:

给定  $l$  对训练样本集  $\{(\mathbf{x}_i, y_i)\}_{i=1}^l$ , 定义优化问题

$$\begin{cases} \min J(\mathbf{w}, b, \boldsymbol{\xi}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^l \xi_i^2 \\ \text{s. t.} \quad y_i = \mathbf{w}^T \varphi(\mathbf{x}_i) + b + \xi_i \quad (i = 1, 2, \dots, l) \end{cases} \quad (15)$$

式中  $\xi$ ——松弛因子

为求解式(15)的优化问题, 构造 Lagrange 函数

$$L(\mathbf{w}, b, \boldsymbol{\xi}, \mathbf{a}) = J(\mathbf{w}, b, \boldsymbol{\xi}) - \sum_{i=1}^l a_i (\mathbf{w}^T \varphi(\mathbf{x}_i) + b + \xi_i - y_i) \quad (16)$$

$\mathbf{a} = (a_1, a_2, \dots, a_l)^T \in \mathbf{R}^l, \boldsymbol{\xi} = (\xi_1, \xi_2, \dots, \xi_l)^T \in \mathbf{R}^l$ 。根据 KKT 优化条件

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^l a_i \varphi(\mathbf{x}_i) \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^l a_i = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \Rightarrow a_i = C \xi_i \quad (i = 1, 2, \dots, l) \\ \frac{\partial L}{\partial a_i} = 0 \Rightarrow \mathbf{w}^T \varphi(\mathbf{x}_i) + b + \xi_i - y_i = 0 \quad (i = 1, 2, \dots, l) \end{cases} \quad (17)$$

计算后消去  $\xi_i, \mathbf{w}$ , 则优化问题可转化为求解方程组

$$\begin{bmatrix} 0 & \mathbf{I}^T \\ \mathbf{I} & \mathbf{K} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (18)$$

式中,  $\mathbf{y} = [y_1, y_2, \dots, y_l]^T, \mathbf{I} = [1, 1, \dots, 1]^T, \mathbf{K} = K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j)$  为核函数, 这样最小二乘支持向量机的函数辨识为

$$f(\mathbf{x}) = \sum_{i=1}^l a_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (19)$$

式中,  $a, b$  可由式(19)解出。LS-SVM 结构如图 2 所示。

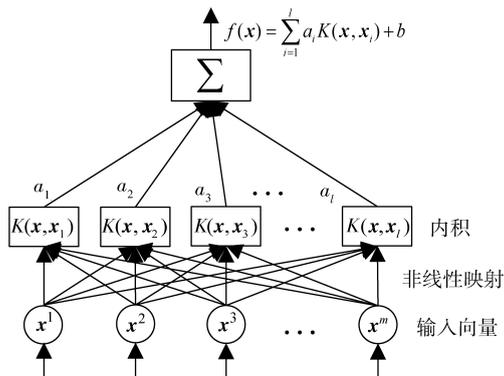


图 2 LS-SVM 预测器结构图

Fig. 2 Structure of LS-SVM prediction

### 1.4 LS-SVM 建模

光伏组件内部参数, 如并联电阻、串联电阻、P-N 结面积、导带和价带的有效态密度、主杂质和施主杂质的浓度、半导体材料的带隙、二极管系数等与光伏组件材料自身性能及生产工艺有关, 难以确定; 另外, 光伏组件补偿系数也是通过近似计算获得, 对于某一具体型号的光伏组件难以适用。因此, 采用基于物理特性和外特性模型的光伏组件模型与实际产品存在一定的差距, 当对大型光伏并网发电系统进行 MPPT 控制时会造成较大误差, 从而导致较大功率的损失。

通过研究发现, 在特定条件下, 光伏组件内部参数和补偿系数对某一具体型号的光伏组件而言为常数, 光伏组件的最大工作点电压  $V_m$  主要取决于太阳辐照度  $S$  和光伏组件工作温度  $T$ 。

光伏组件的工作温度  $T$  和环境温度  $T_c$  关系为<sup>[14]</sup>

$$T = T_c + K_r S \quad (20)$$

式中  $K_r$ ——比例系数

式(20)表示光伏组件的工作温度与环境温度及太阳光辐射度有关,但对于某一具体型号的光伏组件来说是常数。因此,可以用太阳光辐射度  $S$ 、环境温度  $T_c$  作为影响最大工作点电压  $V_m$  的有效参数,并通过 LS-SVM 建立它们之间的映射关系,其中太阳光辐射度可以用辐射计测得,环境温度可以用温度计测得。

为了准确实现  $V_m$  预测,LS-SVM 回归预测模型的建立主要是寻找  $P_m$ 、 $V_m$  与  $S$ 、 $T_c$  之间的非线性关系,通过一个非线性映射  $\varphi(\cdot)$ ,将数据  $S$  和  $T_c$  映射到高维空间  $F$ ,并在这个空间进行线性回归<sup>[17]</sup>,即

$$\begin{cases} V_m = f(S, T_c) = (\mathbf{w} \cdot \varphi(S, T_c)) + b \\ \varphi: R^2 \rightarrow F, \mathbf{w} \in F \end{cases} \quad (21)$$

式中  $\varphi(S, T_c)$ ——一个函数列矢量,它把二维输入样本从输入空间映射到特征空间

## 2 基于 LS-SVM 的光伏最大工作点电压预测

### 2.1 数据的选取和预处理

选用镇江 2013 年 3 月份某晴天的 73 个统计数据作为训练数据,2012 年 1 月份某雾天的 73 个数据作为测试数据。为了降低建模误差,将这两组数据的输入输出进行归一化处理,对  $V_m$ 、 $S$  和  $T_c$  均采用如下公式:  $x = (X - X_{\min}) / (X_{\max} - X_{\min})$  对其进行归一化处理,使其在区间 0~1 之间。

### 2.2 LS-SVM 参数的选择及预测

LS-SVM 模型性能的关键是合理选择相应参数,即  $\gamma$  与  $\sigma^2$ ,选择高斯核函数  $K(\mathbf{x}, \mathbf{x}) = \exp(-\|\mathbf{x} - \mathbf{x}_k\|^2 / (2\sigma^2))$  作为核函数,利用  $k$ -折交叉验证法确定 LS-SVM 的参数  $\gamma$ 、 $\sigma^2$ 。具体过程如下:

首先将归一化后的训练样本数据集  $\{\{S, t\}, V_m\}$  随机分为  $k$  个子集  $S_1, S_2, \dots, S_k$ ,各子集中的元素个数可以不等;然后给定 LS-SVM 的初始参数值  $\gamma_0$ 、 $\sigma_0^2$ ,分别使用  $k-1$  个子集对 LS-SVM 进行训练,并用剩下的集合作为测试集,分别对  $k-1$  个 LS-SVM 进行测试,得到  $k-1$  个 LSSVM 输出值  $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_k$ ,并分别计算平方和误差

$$E_i = \sqrt{\frac{1}{k-1} \sum_{i=1}^{k-1} (\hat{x}_i - x_i)^2} \quad (i=1, 2, \dots, k-1) \quad (22)$$

调整最小的所对应的 LSSVM 参数为  $\gamma_1$ 、 $\sigma_1^2$ ,按此迭代  $k$  次则可确定 LS-SVM 的最优参数值。本文选取  $k=5$ ,将训练集随机分为 5 个子集,对每个子集按照  $\min J(e) = \sum_{i=1}^4 \frac{(x_i - \hat{x}_i)^2}{k-1}$  的原则进行迭代,选定目标函数最小值所对应的参数为 LS-SVM 最优参数。

采用模型训练完成后的数据进行预测,LS-SVM 预测值与实际值曲线如图 3 所示,图 4 为预测值与实际值之间的相对误差曲线。

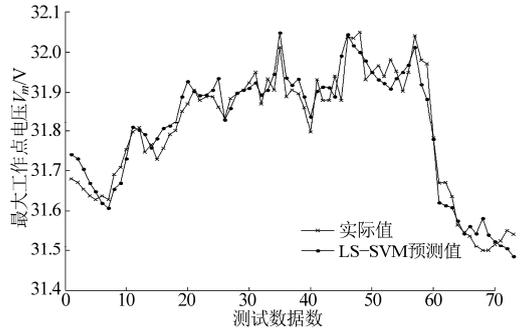


图 3 最大工作点电压曲线

Fig. 3 Maximum power point voltage curve

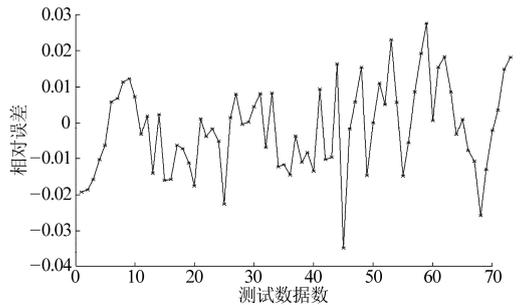


图 4 最大工作点电压相对误差曲线

Fig. 4 Relative error curves of maximum power point voltage

从图 4 中可以看出,最大工作点电压  $V_m$  的最大相对误差小于 0.04,其变化趋势很好地逼近了真实情况。

## 3 基于 LS-SVM 预测的最大功率跟踪控制策略

基于 LS-SVM 预测的 MPPT 控制原理是:测量太阳光辐射度  $S$  和环境温度  $T_c$ ,确定 LS-SVM 回归模型的最佳参数,用 LS-SVM 回归方法来预测光伏发电系统最大工作点电压  $V_m$ ,并将预测的最大工作点电压  $V_m$  设定为恒电压控制法的参考电压  $V_{mref}$ ;当光伏发电系统的工作环境发生变化时,实时根据预测到的  $V_m$  来修改  $V_{mref}$ ,从而达到 MPPT 跟踪的目的。其控制系统如图 5 所示。

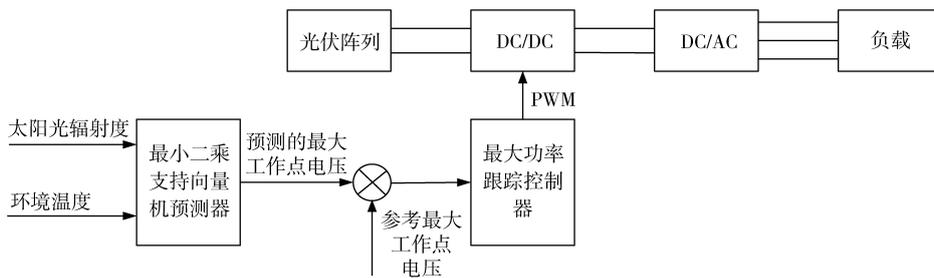


图5 基于 LS-SVM 预测的 MPPT 控制系统

Fig. 5 MPPT control system based on LS-SVM

## 4 仿真分析

在太阳光辐射度在  $1\ 000 \sim 600\ \text{W}/\text{m}^2$  之间变化的情况下,测试基于 LS-SVM 预测 MPPT 控制方法适应能力以及动态响应能力。在  $S = 1\ 000\ \text{W}/\text{m}^2$ 、 $T_c = 25\ ^\circ\text{C}$  及  $S = 600\ \text{W}/\text{m}^2$ 、 $T_c = 25\ ^\circ\text{C}$  的条件下,LS-SVM 预测的  $V_m$  分别为  $37.49\ \text{V}$  和  $34.51\ \text{V}$ ,再根据光伏阵列串联的光伏组件数量,得出  $V_{mref}$  分别为  $224.98\ \text{V}$  和  $207.06\ \text{V}$ ,其仿真结果如图 6~8 所示。

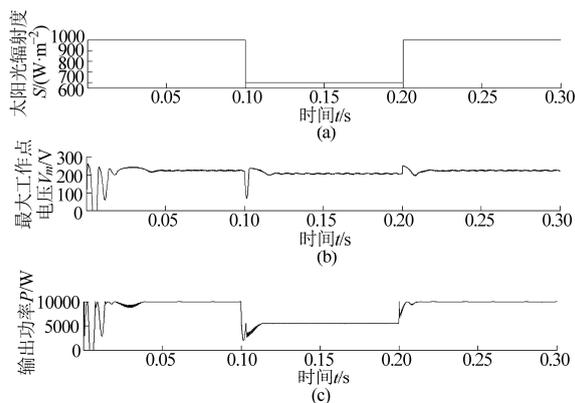


图6 不同太阳光辐射度下光伏阵列的电压、功率曲线

Fig. 6 Voltage curves and power curves of PV array

under different radiations

(a) 太阳光辐射度曲线 (b) 最大工作点电压曲线

(c) 输出功率曲线

从图 6 所示动态响应曲线可以看出,基于 LS-SVM 预测的 MPPT 控制法具有满意的调节效果,具有动态响应快、稳态误差小等优点;当太阳光辐射度剧烈变化时,光伏阵列的工作点迅速变化到最大功率点附近。

比较图 7 和图 8 发现,在太阳光辐射度变为  $600\ \text{W}/\text{m}^2$  时,采用 LS-VSM 预测的 MPPT 控制系统

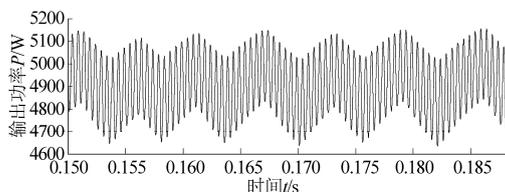
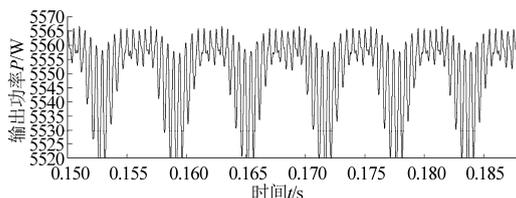
图7 恒电压法功率曲线 ( $S = 600\ \text{W}/\text{m}^2$ )

Fig. 7 Power curve of constant voltage method

( $S = 600\ \text{W}/\text{m}^2$ )

图8 LS-SVM 法功率曲线 ( $S = 600\ \text{W}/\text{m}^2$ )Fig. 8 Power curve of LS-SVM method ( $S = 600\ \text{W}/\text{m}^2$ )

的输出功率大约为  $5\ 555\ \text{W}$ ,而采用恒电压法的 MPPT 控制系统的输出功率大约为  $4\ 900\ \text{W}$ 。采用恒电压法损失了一部分功率,其差值大约为  $655\ \text{W}$ ,对于一个  $10\ \text{kW}$  的系统来说,相当于系统最大功率输出的  $6.5\%$ ,对于 MW、GW 级的光伏电站来说,采用恒电压法的功率损失将更加严重。

## 5 结论

(1) 基于 LS-SVM 的最大工作点电压预测算法,通过对已知数据的挖掘,能够准确、有效地实现最大工作点处的输出电压的跟踪,为 MPPT 控制算法的改进提供了一种新的思路。

(2) 基于 LS-SVM 的 MPPT 控制算法克服了传统 MPPT 控制算法控制精度低、容易发生误跟踪的缺点,实现光伏阵列最大工作点的准确预测,大幅提高 MPPT 控制系统的性能。

## 参考文献

- 丁明,王伟胜,王秀丽,等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1): 1-14.  
Ding Ming, Wang Weisheng, Wang Xiuli, et al. A review on the effect of large-scale PV generation on power systems [J]. Proceedings of the CSEE, 2014, 34(1): 1-14. (in Chinese)

- 2 汤叶华, 谢建. 光伏技术的发展现状[J]. 可再生能源, 2005, 121(3): 68-69.  
Tang Yehua, Xie Jian. Status and expectation of photovoltaic technology[J]. Renewable Energy, 2005, 121(3): 68-69. (in Chinese)
- 3 周林, 武剑, 栗秋华, 等. 光伏阵列最大功率点跟踪控制方法综述[J]. 高电压技术, 2008, 34(6): 1145-1154.  
Zhou Lin, Wu Jian, Li Qiuhua, et al. Survey of maximum power point tracking techniques for photovoltaic array[J]. High Voltage Engineering, 2008, 34(6): 1145-1154. (in Chinese)
- 4 何人望, 邱万英, 吴迅, 等. 基于 PSIM 的新型扰动观察法的 MPPT 仿真研究[J]. 电力系统保护与控制, 2012, 40(7): 56-59.  
He Renwang, Qiu Wanying, Wu Xun, et al. Simulation study of new perturbation and observation method in MPPT based on PSIM [J]. Power System Protection and Control, 2012, 40(7): 56-59. (in Chinese)
- 5 赵争鸣, 陈剑, 孙晓瑛, 等. 太阳能光伏发电最大功率点跟踪技术[M]. 北京: 电子工业出版社, 2012.
- 6 李洪珠, 贾威, 聂苓, 等. 基于鲁棒 LS-SVM 在光伏发电预测中的应用[J]. 计算机测量与控制, 2013, 21(5): 1166-1170.  
Li Hongzhu, Jia Wei, Nie Ling, et al. Application of robust learning LS-SVM in photovoltaic prediction research[J]. Computer Measurement & Control, 2013, 21(5): 1166-1170. (in Chinese)
- 7 董晨晖, 巩晓静. 基于 LS-SVM 的太阳能最大功率点跟踪的研究[J]. 城市建设理论研究, 2013(7): 1-4.
- 8 Suykens J K, Vandewalle J. Least squares vector machines[M]. Singapore: World Scientific, 2002.
- 9 Wang X D, Zhang C J, Zhang H R. Sensor dynamic modeling using least square support vector machines [J]. Chinese Journal of Scientific Instrument, 2006, 27(7): 730-733.
- 10 杨志民, 刘广利. 不确定支持向量机: 算法及应用[M]. 北京: 科学出版社, 2012.
- 11 Fang R M. Gas leakage detection based on clustering support vector machine[J]. Chinese Journal of Scientific Instrument, 2007, 28(11): 2028-2033.
- 12 Desai K, Badhe Y, Kulkarni B D, et al. Soft-sensor development for fed-batch bioreactors using support vector regression[J]. Bio-chemical Engineering Journal, 2006, 27(3): 225-239.
- 13 Li Y F, Yuan J Q. Prediction of key state variables using support vector machines in bioprocesses [J]. Chemical Engineering and Technology, 2006, 29(3): 313-319.
- 14 王长江. 基于 MATLAB 的光伏电池通用数学模型[J]. 电力科学与工程, 2009, 25(4): 11-14.  
Wang Changjiang. Versatile model for photovoltaic cell based oil MATLAB[J]. Electric Power Science and Engineering, 2009, 25(4): 11-14. (in Chinese)
- 15 李应红, 尉询楷, 刘建勋. 支持向量机的工程应用[M]. 北京: 兵器工业出版社, 2004: 1-10.

## Research of MPPT Control Based on LS-SVM

Cai Jihe<sup>1</sup> Sun Yukun<sup>2</sup> Li Bei<sup>1</sup> Xu Yan<sup>1</sup>

(1. School of Electrical and Electrical Engineering, Changzhou Institute of Technology, Changzhou 213002, China

2. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China)

**Abstract:** In order to solve the low control accuracy and tracking error in the maximum power point tracing (MPPT) control in traditional photovoltaic, which was easily occurred under the natural dramatically changing environment, the paper presented a voltage predicting model based on least squares support vector machine (LS-SVM) for the prediction of the voltage of the maximum power output in the PV system, through which the maximum operating point voltage could be predicted, then the reference voltage of constant voltage control method could be modified and MPPT control of the PV system could be eventually realized. Simulation results showed that the model had higher accuracy in prediction, the relative error was less than 0.04, and the modified control method could guarantee maximum power tracking of the PV system quickly and stably, avoided the phenomenon of tracking error.

**Key words:** Photovoltaic power generation Maximum power point tracking Least squares support vector machine