

# 基于 FSVM 光伏系统最大功率跟踪算法及仿真研究

彭永供, 王名发, 何秦慰

(南昌大学 信息工程学院, 江西 南昌 330031)

**摘要:** 针对光伏组件中常用的最大功率跟踪方法存在的不足, 提出并建立了模糊支持向量机(FSVM)的最大功率点工作电压预测模型。通过对实测气象光强数据进行的仿真分析表明, 与 BP 神经网络模型相比, FSVM 的模型实现了结构风险最小化原则, 对未来的样本有较好的泛化能力, 具有更高的预测精度和稳定性。

**关键词:** 光伏系统; 模糊支持向量机; 可再生能源; 最大功率跟踪; 神经网络

中图分类号: TP301.6

文献标识码: A

## The algorithm and simulation research of MPPT using FSVM for PV system

PENG Yong Gong, WANG Ming Fa, HE Qin Wei

(School of Information Engineering, Nanchang University, Nanchang 330031, China)

**Abstract:** As the traditional ways of MPPT suffers from some dissatisfaction, this paper presents a kind of fuzzy support vector Machines for the prediction and simulation of the voltage of the maximum power output in PV module. The simulation and analysis of the measured data of meteorological light intensity shows that compared with BP neural network, the FSVM model achieved the minimization principle of structural risk, have better ability of generalization to the future samples, and a higher prediction accuracy and stability.

**Key words:** PV System; FSVM; renewable energy; MPPT; neural network

太阳能发电作为一种新的电能生产方式, 以其无污染、无噪音、维护简单等特点显示出无比广阔的发展空间和应用前景。但是, 由于光伏发电系统主要问题是电池的转换效率低、价格昂贵, 因此, 如何进一步提高太阳能电池的转换效率, 如何充分利用光伏阵列转换的能量, 一直是光伏发电系统研究的主要方向。本文针对常规跟踪算法在快速跟踪最大功率点的过程中存在的精度低、适应性差和跟踪效率低等诸多弱点, 尝试应用一种新的机器学习方法——模糊支持向量机 FSVM(Fuzzy Support Vector Machine)来实现最大功率(MPP)工作电压的预测<sup>[1-2]</sup>。与神经网络的启发式学习方式与实现时带来的经验成份相比, FSVM 具有更严格的理论和数学基础, 实现了结构风险最小化原则, 对未来的样本有较好的泛化能力, 比神经网络更具有稳定性。

### 1 FSVM 算法简介<sup>[1]</sup>

FSVM 在 SVM 的基础上, 将模糊数学引入其中, 根

据不同输入样本对分类的贡献不同, 赋以相应的隶属度, 可减小野值和噪声的影响, 提高 SVM 的分类性能。

假定输入训练向量  $x_i \in R^d, i=1, \dots, n, x$  属于两类中的一类, 用  $y_i \in \{-1, 1\}$  作为标记,  $\tau_i$  是隶属度, 表明  $x_i$  属于  $Y_i$  程度, 其中,  $0 \leq \tau_i \leq 1$ 。

$$(x_1, y_1, \tau_1), \dots, (x_i, y_i, \tau_i), \dots, (x_n, y_n, \tau_n)$$

设  $z = \varphi(x)$  是输入空间向量  $x$  通过  $\varphi$  映射到特征  $Z$  的相应特征向量。 $\omega$  是分类超平面间距离的倒数,  $\xi_i$  是度量样本的错分程度,  $\tau_i$  是模糊隶属度, 表示  $x_i$  对分类贡献的程度,  $\tau_i \xi_i$  是带有不同权重的样本错分性的度量。

模糊隶属度  $\tau_i$  表明  $x_i$  属于两类之中一类的程度。和 SVM 一样, 目标是建立超平面, 它能把两类分开, 且使超平面到两类的距离最大。优化问题变为

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \tau_i \xi_i \quad (1)$$

$$\text{Subject to } y_i(\omega x_i + b) \geq 1 - \xi_i \quad i=1, \dots, n \quad (2)$$

## 技术与方法 Technique and Method

$$\xi_i \geq 0 \quad (3)$$

注意到  $\tau_i$  在一定程度上减小了参数  $\xi_i$  在 SVM 中的影响力,同时影响了相应的输入样本  $x_i$  在 SVM 中作用,  $\tau_i$  越小,相应的输入样本  $x_i$  在 SVM 中作用就越低,达到了按规则对输入样本的重要性进行划分的目的,该规则可直接作用于  $\tau_i$ ,所以  $\tau_i$  的选取尤为重要。

为解决优化问题,构造拉格朗日函数

$$L_p(\omega, \xi, b, \alpha, \beta) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \tau_i \xi_i - \sum_{i=1}^n \alpha_i [y_i(\omega x_i + b) - 1 + \xi_i] - \sum_{i=1}^n \beta_i \xi_i \quad (4)$$

其中:  $0 \leq \tau_i \leq 1; \alpha_i, \beta_i \geq 0$ 。

$L$  分别对  $L_p, \xi, b$  求偏导,并令其等于 0,代入(4)式,并利用已知的核函数知识,上述问题变成如下的二次优化问题:

$$\max Q_p(\alpha) = -\frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j) \quad (5)$$

$$\text{subject to } 0 \leq \alpha_i \leq \tau_i C$$

$$\sum_{i=1}^n \alpha_i y_i = 0, i = 1, \dots, n \quad (6)$$

$\alpha_i$  为与每个样本对应的 Lagrange 乘子。

若  $\alpha_i^*$  为最优解,则

$$\omega^* = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (7)$$

$b^*$  是分类阈值,可用任何支持向量  $x_i$  求得。

(5)、(6)式所示的优化问题,是不等式约束下二次函数极值问题,存在唯一解,解中将只有一部分(通常是少部分)  $\alpha_i$  不为零,这些  $\alpha_i$  对应的样本就是支持向量。

最终得到的决策函数为

$$f_p(x) = \text{sgn} \left( \sum_{i=1}^n \alpha_i^* y_i k(x_i, x) + b^* \right) \quad (8)$$

由于非支持向量对应的  $\alpha_i$  均为 0,因此式中的求和实际上只对支持向量进行。

## 2 光伏 MPPT 系统及 FSVM 建模

光伏组件的最大功率跟踪系统基本框图如图 1 所示,监测光伏电池单体用来获得参考的开路电压  $V_{oc}$ 。DC/DC 包含 1 个双向全桥电路,可以用来调节输出电压  $V_{dc}$ 。最大功率跟踪结构主要基于 FSVM 预测器,通过 PC 或者微处理机来实现。通过 FSVM 预测器可以得到最大功率点工作电压  $V_{mp}$ ,然后通过 PID 闭环反馈到 DC/DC,调整实际输出电压  $V_{dc}$ ,使其工作在  $V_{mp}$  处,此时光伏组件对负载输出呈最大功率状态<sup>[2]</sup>。

光伏组件的最大功率点工作电压  $V_{mp}$  主要取决于光照强度和光伏电池单体的表面温度。以下用光伏组件的开路电压  $V_{oc}$  作为影响  $V_{mp}$  的有效参数,并建立它们之间合适的映射关系<sup>[3]</sup>。

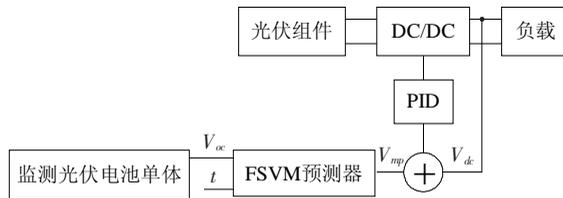


图 1 光伏组件结构图

为了准确实现对  $V_{mp}$  的预测,FSVM 回归预测模型的建立主要是要寻找  $V_{oc}$  和  $V_{mp}$  之间的非线性关系,同时考虑到时间因素  $t$  的影响,通过非线性映射  $\phi$ ,将数据  $V_{oc}, t$  映射到高维特征空间  $F$ ,并在这个空间进行线性回归,即

$$V_{mp} = f(V_{oc}, t) = (\omega \cdot \phi(V_{oc}, t)) + b \quad (9)$$

$$\phi: R^2 \rightarrow F, \omega \in F \quad (10)$$

式中:  $\omega$  是参数列矢量,  $\phi(V_{oc}, t)$  为函数列矢量,它把一维输入样本从输入空间映射到特征空间,  $b$  是阈值。

## 3 实际仿真比较及结果分析

采用 FSVM 算法来实现预测<sup>[4]</sup>,使用修改过的 SVM light(另一种 SVM 算法)和序列最小优化(SMO)中的工作集选择法,给出了工作集的确定方法,使得优化问题成为典型的一次优化问题,并使其具有解析解。此算法占用内存少,而且计算速度更快,精度更高。

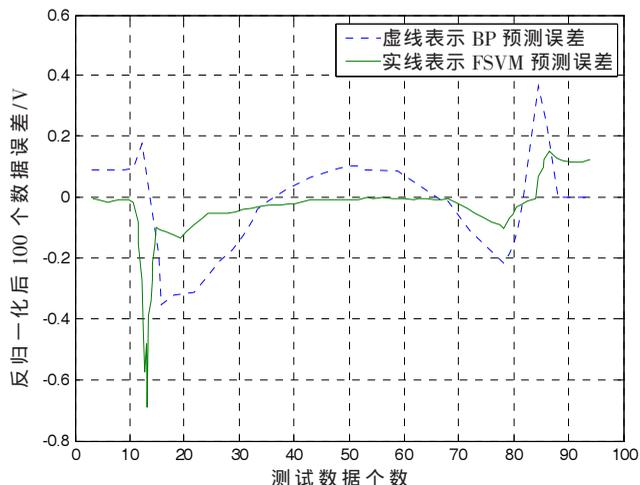
### (1) 数据的选取和预处理

选用某一年 5 月份其中一天的 100 个统计数据作为训练数据,另一天的 200 个数据作为测试数据。为了降低建模误差,将这 2 组数据的输入输出进行归一化处理,对  $V_{oc}, t, V_{mp}$  均采用如下公式:  $x = (X - X_{\min}) / (X_{\max} - X_{\min})$  对其归一化处理,使其在区间 0 和 1 之间。

### (2) FSVM 参数的选择及预测

在进行模型训练时,主要是选择 FSVM 相应的参数,即核函数和常数  $C$ 。选择 RBF 函数作为核函数,通过交叉验证和最速下降的方法,最后确定  $C=8, \gamma=0.6, \varepsilon=0.001$ ,采用最终预报误差(FPE)准则优化选取 FSVM 的嵌入维数  $m=5$ 。当  $m=5$  时, FPE 值达到最小的数值  $3.626e^{-5}$ ,这样建立了函数预测模型,偏差计算结果均方误差(MSE)= $3.012 \times 10^{-8}$ 。

采用模型训练完成后的数据进行预测,为了说明 FSVM 的优越性,同时训练了具有一个隐藏层的 BP 神经网络。为了方便比较,神经网络采用与支持向量机完全一样的输入输出参数和个数。根据 Kolmogorov 定理(映射存在定理),采用 5 个隐藏神经元、1 个输出神经元。训练和测试数据与 FSVM 的数据相同,分别采用 FSVM 与 BP 神经网络进行预测的绝对误差比较如图 2 所示。2 种预测方法都有很高的精确度,但在  $V_{mp}$  突变时,预测都有较大的绝对误差值。对于这种非线性函数的逼近,FSVM 模型的效果明显好于 BP 模型,预测误差更小、更平稳。两种方法预测的相对误差分布见表 1。

图2  $V_{mp}$  预测误差曲线

从表 1 可知, BP 网络模型的预测精度较低, 尤其出现比例较高的较大误差。产生的主要原因在于神经网络采用梯度下降法进行训练, 易陷入局部最优, 并基于经验风险最小化(ERM)的训练容易产生训练误差变小, 预测误差变大的过学习问题, 而且对于连接权的初值也主要是凭经验选取。

表 1 两种方法预测相对误差对比

相对误差的 绝对值/%	误差分布/%	
	FSVM 模型	BP 网络模型
0~0.8	96.413	64.587
0.8~1	2.524	28.941
1~5	1.063	6.472

FSVM 模型则基于结构风险最小化综合考虑了样本误差和模型复杂度, 使实际风险最小。同时 FSVM 在确定输入节点后, 连接权由算法最优确定, 因此模型具有较好的预测性能。以 FSVM 为基础建立的 MPP 输出电压预测模型是对光伏组件 MPPT 预测研究的探索, 虽具有较高的预测精度, 但仍存在一定的误差, 主要是影响光伏组件 MPP 的因素众多, 要对其做出准确的预测, 需有完备的资料。在不断积累资料的同时扩大训练样本, 并对 FSVM 回归模型做出相应的调整, 不断提高精度, 达到更好的预测效果。

图 3 为采用 FSVM 预测模型和改进的爬山算法模型仿真结果, 从图中可以看出改进的爬山算法确实比 CVT、P&O 和 INC 几种方法具有明显优势<sup>[5]</sup>, 但是仍然存在波动。而采用本文中提出的 FSVM 预测算法, 不仅波动小, 效率也很高, 如图 4 所示。

用 FSVM 回归的方法来进行光伏组件 MPP 的输出电压预测。首先用交叉校验和最速下降方法确定了支持向量机回归模型的最佳参数, 进而建立起基于开路电压  $V_{oc}$  和时间参数  $t$  的 MPP 输出电压预测模型。从预测结

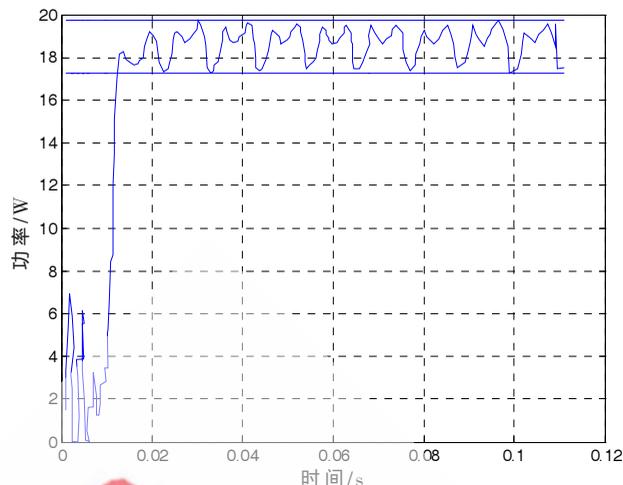


图3 采用改进爬山算法功率曲线图

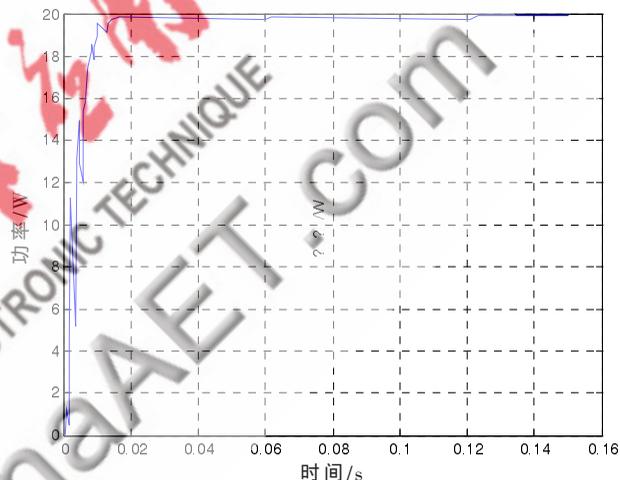


图4 采用 FSVM 算法功率曲线图

果比较分析可知方法较神经网络方法具有更高的精度和稳定性, 且具有很好的数学理论基础, 较改进的爬山算法具有更小的波动和更高的效率, 所以采用支持向量机的方法进行 MPPT 预测有很好的应用前景。

#### 参考文献

- [1] 马永军, 李孝忠, 王希雷. 基于模糊支持向量机和核方法的目标检测方法研究[J]. 天津科技大学学报, 2005, 20(3).
- [2] 唐彬, 马颖, 崔岩, 等. 基于 SVM 的光伏最大功率跟踪的预测研究[J]. 西安工业大学学报, 2007, 27(4).
- [3] CHUNG C, LIN C. LIBSVM: a library for SVMs (Version 2.3) [DB/OL]. (2001-06-08)[2008-04-15]. Http://www.csie.ntu.edu.
- [4] HIYAMA T, KOUZUMA S. Identification of optimal operating point of PV modules using neural network for real time maximum power tracking control [J]. IEEE Transaction on Energy Conversion, 1995, 10(2):360.
- [5] 崔岩, 蔡炳煌, 李大勇, 等. 太阳能光伏系统 MPPT 控制算法的对比研究[J]. 太阳能学报, 2006, 27(6).

(收稿日期: 2009-06-03)