

基于粒子群优化支持向量机的太阳能电池温度预测

赵志刚 张纯杰 苟向锋 桑虎堂

Solar cell temperature prediction model of support vector machine optimized by particle swarm optimization algorithm

Zhao Zhi-Gang Zhang Chun-Jie Gou Xiang-Feng Sang Hu-Tang

引用信息 Citation: *Acta Physica Sinica*, 64, 088801 (2015) DOI: 10.7498/aps.64.088801

在线阅读 View online: <http://dx.doi.org/10.7498/aps.64.088801>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2015/V64/I8>

---

您可能感兴趣的其他文章

Articles you may be interested in

三结太阳能电池在非均匀光照下光斑强度和覆盖比率的优化研究

Optimization of light spot intensity and coverage to a triple-junction solar cell under non-uniform illumination

物理学报.2014, 63(16): 168801 <http://dx.doi.org/10.7498/aps.63.168801>

与太阳能电池研究相适配的双原点坐标系

Dual-origin coordinate system for solar cells

物理学报.2014, 63(11): 118801 <http://dx.doi.org/10.7498/aps.63.118801>

选择性发射极晶体硅太阳能电池的二维器件模拟及性能优化

Two-dimensional device simulation and performance optimization of crystalline silicon selective-emitter solar cell

物理学报.2014, 63(6): 068801 <http://dx.doi.org/10.7498/aps.63.068801>

$\alpha$ -Si: H/SiN<sub>x</sub> 叠层薄膜对晶体硅太阳能电池的钝化

Passivation property of  $\alpha$ -Si: H/SiN<sub>x</sub> stack-layer film in crystalline silicon solar cells

物理学报.2013, 62(19): 198801 <http://dx.doi.org/10.7498/aps.62.198801>

平板集热太阳热电器件建模及结构优化

Modelling and structure optimization of flat-panel thermal concentrated solar thermoelectric device

物理学报.2013, 62(3): 038802 <http://dx.doi.org/10.7498/aps.62.038802>

# 基于粒子群优化支持向量机的太阳能电池温度预测

赵志刚<sup>†</sup> 张纯杰 苟向锋 桑虎堂

(兰州交通大学机电工程学院, 兰州 730070)

(2014年10月31日收到; 2014年11月25日收到修改稿)

建立通用而精确的太阳能电池热模型对光伏系统的建模、输出功率与转换效率的损失分析至关重要. 基于复杂的太阳能电池温度机理, 分别研究了太阳能电池温度的稳态热模型 (steady state thermal model, SSTM) 和支持向量机 (support vector machines, SVM) 方法建立的精确预测热模型. 首先, 基于空气温度、太阳辐射强度、风速 3 个最主要因素与太阳能电池温度的近似线性关系, 在已有 SSTM 的基础上, 建立并校正了太阳能电池的 SSTM 并采用差分进化算法提取模型的未知参数. 其次, 为提高 SVM 的模型预测精度, 采用粒子群优化 (particle swarm optimization, PSO) 算法对 SVM 的核参数和惩罚因子进行动态寻优, 在确定输入/输出样本集并划分训练集和测试集的基础上, 建立了基于粒子群优化支持向量机 (PSO-SVM) 的太阳能电池温度精确预测热模型. 最后, 搭建实验平台, 在实验操作过程中减弱空气湿度、太阳入射角和热迟滞效应等因素对太阳能电池温度的耦合. 通过实验对比表明, 建立的预测热模型性能可靠、全面、简洁, 其参数寻优算法优于遗传算法和交叉校验法, 模型预测精度优于反向传播神经网络 (back propagation neural network) 和 SSTM.

**关键词:** 太阳能电池温度, 热模型, 支持向量机, 粒子群优化算法

**PACS:** 88.40.fc, 88.40.jj

**DOI:** 10.7498/aps.64.088801

## 1 引言

为充分利用太阳能资源, 提高太阳能电池转换效率, 需要在建立精确太阳能电池模型的基础上进行最大功率点的追踪. 然而对于工作在外界环境影响下的太阳能电池而言, 温度作为一个重要的参数, 以影响太阳能电池模型参数的方式贯穿整个发电系统. 首先, 太阳能电池温度的升高引起短路电流的增大和开路电压的减小<sup>[1]</sup>; 其次, 温度的升高导致太阳能电池材料的带宽减小, 随后降低光伏发电效率<sup>[2]</sup>, 影响最大功率点的追踪; 最后, 温度的升高会增强太阳能电池的电容效应, 影响整个光伏发电系统的稳定性. 因此, 建立可靠、精确的太阳能电池热模型对太阳能电池的建模、最大功率点的追踪和随后光伏发电系统的功率损失分析有着重要意义.

然而, 影响太阳能电池温度的机理复杂, 建立精确的太阳能电池热模型困难. 首先, 由于太阳能电池材料的差异和安装倾角的不同, 引起太阳能电池接收到

太阳辐射的差异, 需要建立相应的光学模型; 其次, 外界环境影响太阳能电池的温度, 需要建立太阳能电池的热模型; 再次, 太阳能电池的温度影响光伏发电系统的输出特性, 需要建立相应的电学模型; 最后, 太阳辐射的突变会引起太阳能电池温度的迟滞响应 (热迟滞效应), 需要在分析动态特性的基础上建立相应的动态模型<sup>[3]</sup>. 综上, 太阳能电池热模型是一个包含热迟滞效应的光学/热/电学模型的耦合.

当前, 太阳能电池温度的早期研究集中在稳态热模型 (SSTM), 即忽略热迟滞效应, 基于基本气象条件 (太阳辐射、空气温度和风速) 建立起的半经验模型. 由于忽略了某些内部环境 (如电池材料、安装方式以及电池放电产生的自加热效应), 建立的 SSTM 在不同地域条件下估测精度低, 不能满足实际条件的需要. 但从上述模型中可以看出, 太阳总辐射强度、空气温度和风速对太阳能电池温度的影响近似呈线性<sup>[4]</sup>. 在光学模型方面, 梁齐兵等<sup>[5]</sup> 分别建立了光照分布模型和温度分布计算模型. 随着研

<sup>†</sup> 通信作者. E-mail: zhaozhg@mail.lzjtu.cn

究的深入, 考虑影响太阳电池温度的多种因素的耦合模型被一些学者建立: 在光/热耦合方面, Hoang 等<sup>[6]</sup>重点考虑了太阳电池内部环境影响下的光学特性, 建立了太阳电池的光/热耦合模型, 但建立的模型复杂, 同时忽略了电池放电过程中的自加热效应; 在电/热耦合方面, Górecki 等<sup>[7]</sup>考虑了太阳电池放电产生的自身加热效应, 建立了相应的电/热耦合模型. 因以上耦合模型需要充分考虑太阳电池的温度机理, 为避开复杂的太阳电池温度机理, 一些学者提出了太阳电池温度间接测量方法: 由于太阳电池最大功率点电压/电流<sup>[1]</sup>、开路电压/短路电流<sup>[2]</sup>以及等效结电容等<sup>[8]</sup>模型参数随温度的变化近似呈线性关系, 运用上述原理建立了相应的太阳电池温度的间接估测热模型. 但温度的估测精度强烈依赖于太阳电池模型的参数, 需要精确提取太阳电池的相应参数. 在太阳电池温度机理方面, 文献<sup>[9]</sup>在理论上详细论述了热迟滞效应, 并建立了相应的动态热模型.

以上研究方法不可避免地存在以下三个问题: 第一, 在不同地域下, 建立的 SSTM 估算误差较大; 第二, 没有从理论或实验方面减弱太阳电池的热迟滞效应; 第三, 没有全面考虑太阳电池温度机理, 无法建立理想的太阳电池模型. 为建立精确的太阳电池模型, 同时避免复杂的机理建模, 人工智能方法得到应用. İlhan 等<sup>[10]</sup>将反向传播神经网络 (back propagation neural network, BPNN) 逼近理论应用于太阳电池的温度预测, 但 BPNN 需要预先确定拓扑结构, 主观性较强. 作为一种新的、有效的机器学习方法——支持向量机 (SVM) 可以有效避免神经网络的缺陷, 且具有很强的泛化能力, 被广泛应用于故障诊断、模式识别及函数逼近等领域<sup>[11]</sup>. 在 SVM 的相关应用方面, 文献<sup>[12, 13]</sup>采用最小二乘支持向量机 (least squares support vector machine, LS-SVM) 逼近混沌系统的映射函数. LS-SVM 虽然降低了收敛时间, 但降低了解的稀疏性和鲁棒性. SVM 预测模型的精确建立需要调用优化算法优化 SVM 模型参数. 在 SVM 参数优化方面, 文献<sup>[14, 15]</sup>采用遗传算法 (GA) 优化 SVM 建立了相应的预测热模型, 取得了较好的效果.

本文首先从分析太阳电池温度机理出发, 在已有模型的基础上, 以空气温度、太阳总辐射强度和风速为太阳电池的主要影响因素, 通过实验, 对比校正了太阳电池的 SSTM 并对模型中未知参数进行提取, 就此得出太阳电池的辨识 SSTM; 其次, 为

尽量避免太阳电池的热迟滞效应, 在实验中采取提高采样频率的方法, 同时使用双轴太阳能自动追踪台架消除太阳电池组安装倾角对太阳电池温度的影响; 随后划分训练集和测试集, 确定空气温度、太阳总辐射强度和风速作为输入变量, 太阳电池温度作为输出变量; 最后将粒子群优化支持向量机 (PSO-SVM) 理论运用于太阳电池温度的预测, 为验证模型的准确性, 对比了 PSO-SVM, BPNN 和辨识 SSTM 的太阳电池温度预测结果, 预测结果表明, PSO-SVM 预测热模型具有更高的预测性能.

## 2 太阳电池温度机理

引起太阳电池温度变化的机理复杂, 可以概括为气象条件、电池内部环境以及电池的充放电过程. 其温度机理示意图如图 1 所示.

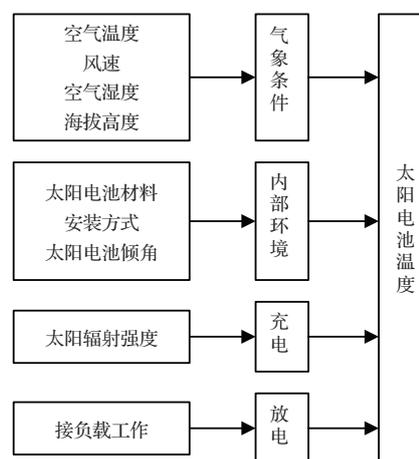


图 1 太阳电池温度示意图

Fig. 1. Schematic diagram of solar cell temperature.

其中, 太阳辐射强度、空气温度和风速不仅是影响太阳电池的主要因素, 而且可以通过实验轻松获得, 因此可以作为模型输入变量. 材料热导性能体现于太阳电池材料中, 在实验中难以获得; 空气湿度、太阳电池倾角等因素在本次实验操作中被减弱.

## 3 太阳电池的 SSTM

为极大地降低光/电模型对热模型的耦合, 采用太阳追踪装置——双轴太阳能自动追踪台架减弱安装倾角对太阳电池温度的影响; 同时使太阳电池处于开路状态, 消除电池放电过程中的自加热效应, 则电池充电过程和气象条件对太阳电池温

度的影响占主要地位. 兼顾模型的精度和复杂程度, 采用文献 [16] 提出的 SSTM:

$$T_c = T_a + (b_1 + b_2 W_s + b_3 W_s^2) + G (b_4 + b_5 W_s + b_6 W_s^2), \quad (1)$$

式中,  $T_c$  为太阳电池温度,  $T_a$  为空气温度,  $W_s$  为风速,  $G$  为太阳总辐射强度,  $b_1$ — $b_7$  为待辨识系数. 需要注意的是, 实验测得的数据受测量误差和噪声的干扰, 影响太阳电池初始温度的确立. 所以在模型 (1) 的基础上进行修正:

$$T_c = a_1 T_a + (b_1 + b_2 W_s + b_3 W_s^2) + G (b_4 + b_5 W_s + b_6 W_s^2). \quad (2)$$

引入参数  $a_1$ , 考虑了实验误差和噪声的影响, 对太阳电池的初始温度进行了校正. 其中, 模型中包含 7 个未知参数, 采用差分进化算法 (DE) 结合实测数据对未知参数进行辨识, 获得结果如下:

$$a_1 = 1.136, \quad b_1 = 2.622, \quad b_2 = -0.237, \quad b_3 = 0.004, \\ b_4 = 0.025, \quad b_5 = 0.001, \quad b_6 = -0.005.$$

#### 4 太阳电池温度预测热模型的建立

上述建立的 SSTM 忽略了太阳电池的放电过程和电池某些内部环境的差异以及空气湿度和海拔高度等因素对太阳电池的影响. 但在实际条件中, 上述因素不能忽略; 同时, 全面考虑太阳电池温度机理增加了建模的难度, 提高了模型的复杂程度. 为避免复杂机理的建模, 提高建模精度, 需采用人工智能算法——SVM 回归理论建立太阳电池温度的预测热模型.

##### 4.1 基于 SVM 模型

为检验算法训练的精度, 需要将实验测得的数据样本划分为  $m$  个训练集样本和  $n$  个测试集样本. 将  $T_a$ ,  $G$  和  $W_s$  三个主要特征量的测量值作为 SVM 模型的输入  $x_i = [T_a, G, W_s]_i$ ,  $T_c$  的测量值作为模型的输出  $y_i = [T_c]_i$ , 就此得出训练样本集. 随后, 首先定义一个线性回归函数:

$$f(x) = \omega^T \cdot \varphi(x) + b. \quad (3)$$

对于非线性问题, 需要进行线性转换: 应用非线性映射  $\varphi(\cdot)$  将样本数据映射到一个高维特征空间 (Hilbert) 中并采用极小化上界风险的方法进行非

线性回归. (3) 式中,  $\omega$  为权向量,  $\omega \in H$ ;  $b$  为截距,  $b \in \mathbb{R}$ .

考虑到测量数据中不可避免地含有噪声, 需要对理想状况下的线性回归函数 (3) 进行修正: 引入  $\varepsilon$  线性不敏感损失函数和惩罚因子  $C$ ; 若允许拟合误差, 引入数值上大于零的松弛变量  $\xi_i$  和  $\xi_i^*$ . 由此, 求解凸二次规划问题成为求解函数回归问题的关键:

$$\min \left( \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \right), \\ \text{s.t. } y_i - \omega^T \cdot \varphi(x_i) - b \leq \varepsilon + \xi_i, \\ \omega^T \cdot \varphi(x_i) + b - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i \geq 0, \quad \xi_i^* \geq 0, \quad (4)$$

即问题转换为求解带约束的目标函数 (4) 极小化的  $\omega$  和  $b$ . 为使 (4) 式更容易求解, 将约束问题转化为拉格朗日 (Lagrange) 对偶问题:

$$L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \\ - \sum_{i=1}^m \alpha_i (\varepsilon + \xi_i - y_i + \omega^T \cdot \varphi(x_i) + b) \\ - \sum_{i=1}^m \alpha_i^* (\varepsilon + \xi_i^* + y_i - \omega^T \cdot \varphi(x_i) - b) \\ - \sum_{i=1}^m (\eta_i \cdot \xi_i - \eta_i^* \cdot \xi_i^*). \quad (5)$$

需要注意的是, 非线性 SVM 的回归是采用内积形式映射到高维特征空间的, 为避免较多的样本产生“维数灾难”, 采用核函数代替内积, 并由方程 (5) 结合自身的约束条件求得最终的回归函数:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot K(x_i, x_j) + b, \quad (6)$$

式中,  $K(x_i, x_j)$  为核函数, 它的选择对学习机的泛化能力影响较大. 选用灵活性和通用性较高的高斯径向基函数 (RBF) 作为核函数, 表示为

$$K(x_i, x_j) = \exp \left( -g \cdot \|x_i - x_j\|^2 \right), \quad (7)$$

式中,  $g$  为核参数,  $g > 0$ ;  $\|\cdot\|^2$  为 2-范数.

##### 4.2 PSO 参数寻优

由于建立精确的非线性 SVM 预测热模型需要确立惩罚因子  $C$  和 RBF 的核参数  $g$ . 过大或者过小的  $C$  影响模型的泛化能力或训练误差; 过大或者过

小的  $g$  可能会引起过拟合或者欠学习现象<sup>[17]</sup>. 即参数  $C$  和  $g$  的确定本质上为一个动态寻优的过程, 合理选取优化算法对 SVM 最佳参数的确立至关重要. 选用 PSO 进行参数寻优: PSO 于 1995 年被提出, 来源于对鸟类捕食行为的研究, 是近年来迅速发展起来的一种新的进化算法. 该算法首先初始化一群随机粒子, 然后通过迭代, 粒子通过跟踪两个“极值”更新自己的位置, 从而找到最优解. 采用 PSO 优化算法对惩罚因子  $C$  和核参数  $g$  寻优的步骤如下.

**步骤 1 初始化.** 对样本数据进行  $[-1, 1]$  的归一化处理并读取样本数据. 设定参数运动范围, 设定学习因子 ( $c_1$  和  $c_2$ ), 进化代数 ( $E$ ), 惩罚因子  $C$  和核参数  $g$ .

**步骤 2 适应度评价.** 计算个体适应度值, 初始化个体最优和全局最优.

**步骤 3 比较寻优.** 更新粒子的速度和位置产生新种群, 计算新种群的个体适应度值. 分别比较当前参数  $C$  和  $g$  的适应值和自身历史最优值及种群最优值, 更新种群参数  $C$  和  $g$  的全局最优值.

**步骤 4 检查结束条件.** 寻优达到最大进化代数, 结束寻优, 输出最佳参数  $C$  和  $g$ .

随后将优化的参数  $C$  和  $g$  代入 SVM 模型并检测 SVM 建模精度, 若达不到相应精度则返回 PSO 寻优步骤重新训练.

## 5 实验平台的搭建

根据理论和实验的要求, 搭建了基于铂电阻 (PT100)、风速传感器、日射强度计的太阳能电池测温平台. 其采集示意图见图 2.

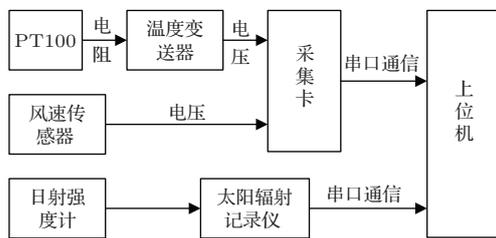


图 2 太阳能电池测温示意图

Fig. 2. Schematic diagram of the measurement for solar cell temperature.

PT100 温度变送器和风速传感器中转换的电压信号送入采集卡, 实时采集电压信号, 并以串口通信方式发送到上位机; 同时, 太阳总辐射强度被日射强度计采集并以太阳辐射记录仪的方式将信

号实时发送到上位机. 太阳能电池测温平台硬件实物图如图 3 所示.



图 3 太阳能电池测温实验平台 1, 工控机; 2, 采集工作箱; 3, 贴片式 PT100(2个); 4, 支架; 5, 风速传感器; 6, 日射强度计; 7, 太阳能电池模组; 8, 双轴太阳能自动追踪台架

Fig. 3. Experimental platform for measuring solar cell temperature. 1, IPC; 2, data acquisition box; 3, PT100; 4, support; 5, wind speed sensor; 6, pyranometer; 7, solar module; 8, dual-axis solar tracker.

其中, 太阳总辐射强度的采集使用商家提供的太阳总辐射采集软件; 温度和风速采集上位机程序在 LabVIEW 环境下开发 (图 4).

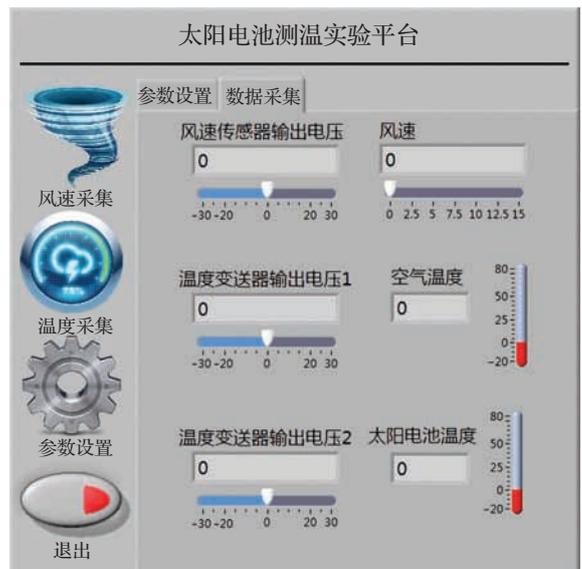


图 4 基于 LabVIEW 太阳能电池测温实验平台上位机

Fig. 4. Experimental PC platform for measuring solar cell temperature based on LabVIEW software.

在实际操作中, 还应注意:

- 1) 保持太阳能电池板表面洁净;
- 2) 选用型号相同、精度高 (1/3B 级精度) 的两个贴片式 PT100, 将其中一个贴在太阳能电池表面, 用于测量太阳能电池温度, 另外一个暴露在空气中, 用于测量空气温度;
- 3) 硬件采集部分集成于工作箱, 提高实验操作效率;

4) 温度、风速和太阳辐射强度需要在同一台工控机下完成数据采集;

5) 采集实验日期选择连续的晴朗天气(空气湿度维持在一个较低而且稳定的范围内), 避免阴雨后的次日晴朗天, 降低空气湿度对太阳电池温度的影响.

采用提高采样频率的方法避免太阳电池的热迟滞效应: 分别在2014年6月18, 21, 23, 26和30日采集, 每天采集时间从早上的9:00持续到下午的14:00, 每隔5 s采集一次(采集地点为兰州市安宁区). 同时, 剔除由于热迟滞效应产生的明显误差数据, 挑选出较短时间间隔内数据波动范围较小的600组数据作为样本数据, 将其划分为500组训练集样本和100组测试集样本.

### 6 结果分析与预测

图5给出了2014年7月30日早上9:00到下午5:00同步采集的太阳电池温度与太阳辐射强度分布图(采样周期为5 s, 共采集5772组数据, 采集地点为兰州市安宁区). 从图5可看出: 太阳电池温度受风速和太阳辐射影响上下波动; 太阳辐射强度最高点/最低点不能与太阳电池温度的最高点/最低点在相同的时刻下完全对应, 且温度的波动略滞后于太阳辐射. 同时, 在16:47由于大面积乌云遮挡太阳, 造成太阳辐射的急剧降低并趋于某一低辐射值(黑色圆点); 相应地, 太阳电池温度于16:53降低至大约34.8 °C(蓝色方点), 并趋于平稳. 两者相比, 太阳电池温度响应迟滞了大约6 min.

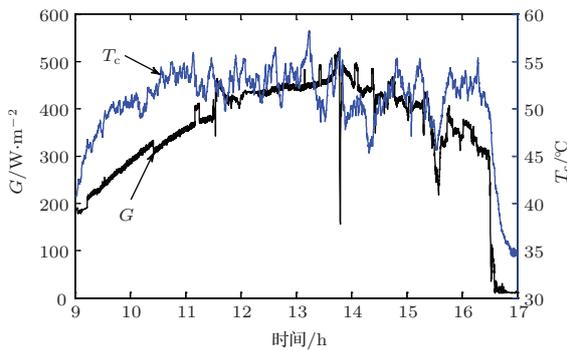


图5 (网刊彩色) 同一时刻下的太阳总辐射强度和太阳电池温度

Fig. 5. (color online) Solar global radiation intensity and solar cell temperature at the same time.

为选择出最优参数, 对训练集分别采用交叉校验法(CV), GA和PSO, 其优化结果列于表1. PSO

的初始参数设置为: 种群数量为40, 进化代数数为500, C和g的寻优范围分别设置为 $[2^2, 2^7]$ 和 $[2^{-8}, 2^2]$ , 局部学习因子为2.0, 全局学习因子为2.05.

表1 参数优化对比  
Table 1. Contrast of parameter optimization.

寻优算法	相关系数 $R^2$	均方根误差	C	g
CV	0.980	1.039	97.01	0.016
GA	0.978	1.073	100.01	0.026
PSO	0.984	0.911	100.80	0.044

为验证前文提出的预测热模型的精度, 基于相同的训练集样本和测试集样本, 采用BPNN进行建模和预测, 并引入前文建立的太阳电池SSTM, 最后比较两种算法和SSTM的建模性能. BPNN的训练参数设置为: 输入层节点数为3, 分别为 $T_a$ , G和 $W_s$ ; 隐层个数为1, 节点数为10, 输出层节点数为1, 即 $T_c$ ; 隐层和输出层的传递函数分别选用tansig函数和logsig函数激发, 训练次数为1000, 学习速率为0.01, 目标误差为0.0001. 采用DE算法对太阳电池SSTM进行辨识, 其辨识参数设置为: 种群数为40, 变异因子为0.9, 交叉因子为0.9, 最大迭代次数为5000. 基于500组测试集样本, 在已辨识SSTM基础上, BPNN和PSO-SVM通过机器学习, 建立相应的预测模型. 三种模型的预测性能对比如图6和图7所示. 其中, 图6将三种模型的预测值与测试样本做了比较; 图7将三种模型的预测值分别与实测值作相对误差. 由图6和图7可知, PSO-SVM, BPNN和SSTM的相对误差都在允许

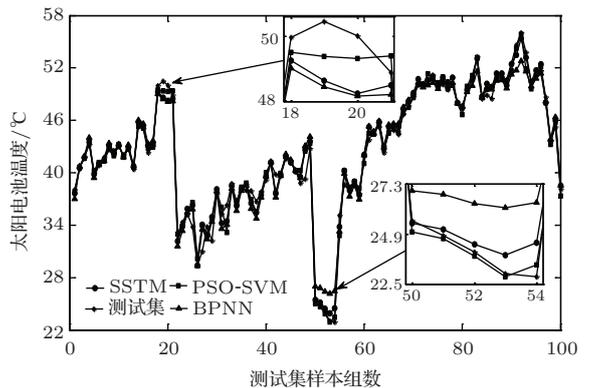


图6 SSTM, BPNN和PSO-SVM的预测值与实测值的比较

Fig. 6. Comparison between the predictive values from SSTM BP, PSO-SVM and the measured values.

误差范围之内. 最大相对误差绝对值分别为0.096, 0.155和0.099, 平均相对误差分别为0.002, 0.003

和0.005. 所以 PSO-SVM 模型预测精度略高于 BPNN 和辨识 SSTM; 同时, PSO-SVM 保持了较强的泛化能力, 在太阳电池温度最低点处和部分最高点处 (示于图 6 局部放大图) 表现明显. 综上, 验证了 PSO-SVM 进行太阳电池温度预测的可行性.

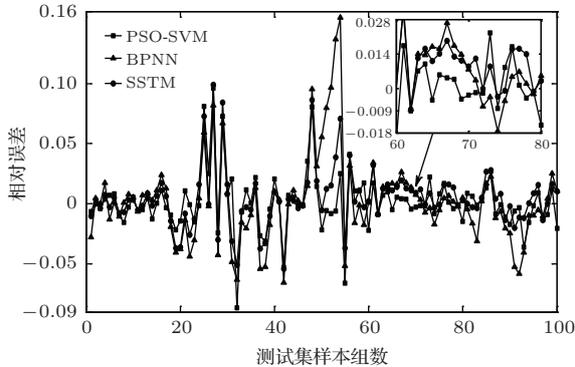


图 7 BPNN 和 PSO-SVM 预测热模型的输出相对误差  
Fig. 7. Relative error between BPNN model and PSO-SVM model.

## 7 结 论

基于引起太阳电池温度变化的机理, 分别建立了太阳电池温度的 SSTM 和 PSO-SVM 预测热模型. 在建模过程中, 两者共同引入空气温度、太阳辐射强度和风速 3 个最重要的变量作为模型的输入变量. 前者基于已提出的模型, 选择并建立了太阳电池温度的多项式模型, 并采用 DE 算法提取了模型的未知参数, 计算时间短, 且拟合性能好. 但由于忽略了空气湿度、海拔高度、放电过程以及电池材料等因素, 建立的模型简单, 但从模型中 (参数差异) 中体现了上述因素的影响, 可用于近似估算太阳电池温度. 若考虑负载或空气相对湿度对太阳电池温度的影响, 则在建立 SSTM 的过程中需要将上述因素作为自变量考虑进模型中, 增加了建模和实验的难度的同时, 需要对部分实验条件进行理想化处理. 后者采用 PSO 对 SVM 模型中的核参数  $g$  和惩罚因子  $C$  进行了动态寻优, 代替了参数选择的盲目性, 与 BPNN 的输出特性对比分析表明, PSO-SVM 具有较强的泛化能力和预测精度. 在建模机理方面, 虽然也没有将上述忽略的因素添加到模型输入中, 但通过一定的机器学习, 避开了复杂

机理的建模, 且预测的数据引入了上述被忽略因素但没有增加模型的复杂程度, 在降低实验难度的同时更加贴近实际条件, 因而预测热模型具有较高的可信度和精度.

## 参考文献

- [1] Farivar G, Asaei B, Haghdam N, Iman-Eini H 2011 *2nd Power Electronics, Drive Systems and Technologies Conference* Tehran, The Islamic Republic of Iran, February 16–17, 2011 p336
- [2] Ju X, Vossier A, Wang Z F, Dollet A, Flamant G 2013 *Sol. Energy* **93** 80
- [3] Torres-lobera D, Valkealahti S 2014 *Sol. Energy* **105** 632
- [4] Trinuruk P, Sorapipatana C, Chenvidhya D 2009 *Renew. Energy* **34** 2515
- [5] Liang Q B, Shu B F, Sun L J, Zhang Q Z, Chen M B 2014 *Acta Phys. Sin.* **63** 168801 (in Chinese) [梁齐兵, 舒碧芬, 孙丽娟, 张奇淄, 陈明彪 2014 物理学报 **63** 168801]
- [6] Hoang P, Bourdin V, Liu Q, Caruso G, Archambault V 2014 *Sol. Energy Mater. Sol. Cells* **125** 325
- [7] Górecki K, Górecki P, Paduch K 2014 *J. Phys. Conf. Ser.* **494** 1
- [8] Anantha Krishna H, Misra N K, Suresh M S 2011 *IEEE Trans. Aerosp. Electron. Syst.* **47** 782
- [9] Torres-Lobera D, Valkealahti S 2013 *Sol. Energy* **93** 183
- [10] İlhan C, Erkaymaz O, Gedik E, Gürel A E 2014 *Case Studies Therm. Eng.* **3** 11
- [11] Sun Z H, Jiang F 2010 *Chin. Phys. B* **19** 110502
- [12] Tang Z J, Ren F, Peng T, Wang W B 2014 *Acta Phys. Sin.* **63** 050505 (in Chinese) [唐舟进, 任峰, 彭涛, 王文博 2014 物理学报 **63** 050505]
- [13] Tian Z D, Gao X W, Shi T 2014 *Acta Phys. Sin.* **63** 160508 (in Chinese) [田中大, 高宪文, 石彤 2014 物理学报 **63** 160508]
- [14] Chen A L, Feng L N, Du C S, Zhang C H 2011 *Trans. CES* **26** 140 (in Chinese) [陈阿莲, 冯丽娜, 杜春水, 张承慧 2011 电工技术学报 **26** 140]
- [15] Chen W G, Teng L, Liu J, Peng S Y, Sun C X 2014 *Trans. CES* **26** 44 (in Chinese) [陈伟根, 滕黎, 刘军, 彭尚怡, 孙才新 2014 电工技术学报 **26** 44]
- [16] Matsukawa H, Koshiishi K, Koizumi H, Kurokawa K, Hamada M, Bo L 2003 *Sol. Energy Mater. Sol. Cells* **75** 537
- [17] Wang W J, Men C Q 2014 *Support Vector Machine Modeling and Its Application* (Beijing: Science Press) p211 (in Chinese) [王文剑, 门昌骞 2014 支持向量机建模及应用 (北京: 科学出版社) 第 211 页]

# Solar cell temperature prediction model of support vector machine optimized by particle swarm optimization algorithm

Zhao Zhi-Gang<sup>†</sup> Zhang Chun-Jie Gou Xiang-Feng Sang Hu-Tang

(School of Mechatronic Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

( Received 31 October 2014; revised manuscript received 25 November 2014 )

## Abstract

Establishing a general and precise solar cell temperature model is of crucial importance for photovoltaic system modeling, the loss analysis of output power, and conversion efficiency. According to the complex mechanism of solar cell temperature, in this paper we study the steady state thermal model (SSTM) of solar cell temperature and accurate prediction model of method of support vector machine (SVM). Firstly, based on the approximate linear relationship among air temperature, solar radiation intensity, wind speed and solar cell temperature, the polynomial model of solar cell temperature is established and the unknown parameters of the model are extracted with the improved differential evolution algorithm. Secondly, in order to improve the accuracy of SVM prediction model, the particle swarm optimization algorithm is adopted to optimize the parameters (including kernel parameter  $g$  and penalty factor  $C$  from the radial basis function kernel) of SVM. After the input/output sample set is determined and the training set and test set are classified, a prediction model of solar cell temperature based on particle swarm optimization support vector machine is established. Finally, experimental acquisition platform is built to reduce the influences of air humidity, solar incidence angle, and thermal hysteresis effects on PV cell temperature. Through contrasting experiments, it is shown that the established fitting of the SSTM is better than the models given in other literature, and the prediction model is reliable, comprehensive and simple. The selected parameter optimization algorithm is superior to genetic algorithm and cross-validation method established on the optimization performance, and the accuracy of prediction model is superior to the prediction performance of back propagation neural network and identified SSTM.

**Keywords:** solar cell temperature, thermal model, support vector machines, particle swarm optimization

**PACS:** 88.40.fc, 88.40.jj

**DOI:** [10.7498/aps.64.088801](https://doi.org/10.7498/aps.64.088801)

---

<sup>†</sup> Corresponding author. E-mail: [zhaozhg@mail.lzjtu.cn](mailto:zhaozhg@mail.lzjtu.cn)