

## 基于 SVR 的用电负荷特征三维回归模型

汤 强, 谢明中, 罗元盛

(长沙理工大学 计算机与通信工程学院, 长沙 410114)

**摘 要:** 针对用电负荷的周期性特点, 将用电负荷特征学习建模为小时、天数、负荷数 3 个维度的回归问题, 提出一种基于支持向量回归机的三维回归模型。将支持向量机的核函数设计为多个核函数的线性组合分别进行参数训练, 并给出多路径逐步逼近的参数训练算法。仿真结果表明, 与三层神经网络、最小二乘非线性拟合模型相比, 该模型具有较好的用电负荷特征学习与预测能力。

**关键词:** 用电负荷特征; 支持向量回归机; 三维回归模型; 参数训练算法; 参数自适应

**中文引用格式:** 汤 强, 谢明中, 罗元盛. 基于 SVR 的用电负荷特征三维回归模型[J]. 计算机工程, 2017, 43(9): 300-303, 309.

**英文引用格式:** TANG Qiang, XIE Mingzhong, LUO Yuansheng. SVR Based Three Dimensional Regression Model of Power Load Characteristics[J]. Computer Engineering, 2017, 43(9): 300-303, 309.

## SVR Based Three Dimensional Regression Model of Power Load Characteristics

TANG Qiang, XIE Mingzhong, LUO Yuansheng

(School of Computer and Communication Engineering, Changsha University of Science and Technology, Changsha 410114, China)

**[Abstract]** According to the periodic characteristics of electric load, a Three Dimensional Regression Model studies are (TDRM) based on Support Vector Regression (SVM) is proposed. The power load characteristics studies are modeled as three dimensional regression problems, such as hours, days and loads. The kernel functions of Support Vector Machines (SVM) are designed as linear combinations of multiple kernel functions for separate parameter training, and the parameter training algorithm is designed to gradually approach the optimum from multiple different paths. Simulation results show that compared with the three layer neural network and the least square nonlinear fitting model, this model has better performance in power load characteristics learning and prediction.

**[Key words]** power load characteristics; Support Vector Regression (SVR); Three Dimensional Regression Model (TDRM); parameter training algorithm; parameter adaptation

DOI: 10.3969/j.issn.1000-3428.2017.09.051

### 0 概述

随着智能电网出现, 以神经网络、支持向量机 (Support Vector Machine, SVM) 等为代表的非线性预测工具, 已被广泛应用于电网负荷预测领域中<sup>[1]</sup>。由于支持向量机是一种基于核的学习方法, 有利于降低经验风险和减小置信范围<sup>[2]</sup>, 因此被众多预测模型所采用, 例如将支持向量回归机 (Support Vector Regression, SVR) 用来预测短期的交通流<sup>[3]</sup>; 用于生态旅游经济的预测<sup>[4]</sup>; 用于预测提供给火电厂的煤炭质量<sup>[5]</sup>等。在电力行业, SVR 模型也得到了普遍应用。

文献[6]提出了一个基于多元负荷的支持向量回归局部负荷预测框架。该框架基于预测的日负荷高峰, 研究了不同季节、平常上班日以及节假日对用

电负荷的影响。文献[7]提出了一种针对短期电力负荷预测的混沌蚁群 (Chaotic Ant Swarm, CAS) 算法支持向量回归负荷预测模型, 该模型结合了蚁群算法和自组织混沌行为, 克服了进化算法过早收敛和局部最优的问题。文献[8]提出了基于最小二乘支持向量机 (Least Squares Support Vector Machine, LS-SVM) 的短期负荷预测模型, 基于正规化、可自动调整的内核参数, 可实现对预测误差和模型复杂性的权衡。文献[9]提出了一种分层分区的自适应动态预测模型, 最上层负荷的预测通过递推最小二乘支持向量机实现。文献[10]提出的基于模拟退火的支持向量机参数训练方法, 具有耗时少的优点。文献[11]解决 SVR 参数问题是依靠微分进化策略, 依

**基金项目:** 国家自然科学基金 (61303043); 湖南省自然科学基金 (13JJ4052); 湖南省教育厅科学研究项目 (13C1023)。

**作者简介:** 汤 强 (1982—), 男, 讲师、博士, 主研方向为无线传感器网络、智能电网; 谢明中, 硕士研究生; 罗元盛, 讲师、博士。

**收稿日期:** 2016-07-28      **修回日期:** 2016-10-04      **E-mail:** tangqiangcsust@163.com

靠该方法较强的全局搜索能力, 最终得到较好的预测效果。文献[12]等提出了基于人工蜂群参数训练优化算法的支持向量机负荷预测模型, 避免了训练过程陷入局部极值。文献[13]将支持向量机应用到风电机组状态评估, 文献[14]将支持向量机应用到光伏发电预测, 文献[15]利用支持向量机进行电网线损的估算。文献[16]针对SVR负荷模型的泛化能力进行了研究。

在非线性回归方法上, 除了SVR以外, 还有一些其他方法。比如文献[17]提出的人工神经网络预测模型; 文献[18]提出的极限学习机模型; 文献[19]提出的随机森林算法; 文献[20]提出的采用区间时间序列估计的方法。

本文将负荷特征学习转化为基于小时数、天数、负荷数3个维度的回归问题, 并提出相应的参数训练方法以及最优周期天数选取方法。

## 1 三维回归模型

SVR模型是一个基于支持向量机(Support Vector Machine, Vector) SVM理论建立的回归模型。在SVR框架下, 训练样本为二维向量 $\mathbf{x}$ , 分别对应天数(一个周期包含若干天)和小时数(一天包含24 h)。输出值 $y$ 是归一化后的用电负荷值。 $\mathbf{x}, y$ 共同构成了小时数、天数、负荷值三维空间中的坐标。向量 $\mathbf{x}^{[i]}$ 代表第 $i$ 组样本对应的 $\mathbf{x}$ , 三维回归模型(Three Dimensional Regression Model, TDRM)可以表述为:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{s. t. } |\mathbf{w} \cdot \mathbf{x}^{[i]} + b - y_i| \leq \varepsilon, i = 1, 2, \dots, N \quad (1)$$

其中, 令 $y^*$ 为学习后所得到的负荷计算值, 向量 $\mathbf{w}$ 与常量 $b$ 就是回归超平面 $y_i^* = \mathbf{w} \cdot \mathbf{x}^{[i]} + b$ 的参数;  $y_i$ 为真实的用电负荷值;  $\varepsilon$ 为不敏感参数;  $N$ 为样本数。向量 $\alpha$ 与 $\alpha^*$ 的各个分量分别为 $\alpha_i$ 与 $\alpha_i^*$ , 拉格朗日函数定义为:

$$L(\mathbf{w}, b, \alpha, \alpha^*) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i (y_i - \mathbf{w} \cdot \mathbf{x}^{[i]} - b - \varepsilon) - \sum_{i=1}^N \alpha_i^* (\mathbf{w} \cdot \mathbf{x}^{[i]} + b - y_i - \varepsilon) \quad (2)$$

利用核函数 $k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]})$ 将高维映射放在低维空间处理, 此时式(1)变为:

$$\argmin_{\alpha, \alpha^* \geq 0} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) + \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) - \sum_{i=1}^N (\alpha_i - \alpha_i^*) y_i \quad (3)$$

选用向量 $\gamma = \alpha - \alpha^*$ , 此时式(3)变为式(4) (证明过程见证明1):

$$\argmin_{\alpha, \alpha^* \geq 0} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \gamma_i \gamma_j k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) + \varepsilon \|\gamma\|_1 - \sum_{i=1}^N \gamma_i y_i \quad (4)$$

约束条件为:

$$\sum_{i=1}^N \gamma_i = 0 \quad (5)$$

**证明1** 式(3)与式(4)的等价性证明:

$$\forall k \in \{1, 2, \dots, N\}$$

令 $\beta_k = \alpha_k - \min\{\alpha_k, \alpha_k^*\}$ 且 $\beta_k^* = \alpha_k^* - \min\{\alpha_k, \alpha_k^*\}$ , 由于 $\min\{\alpha_k, \alpha_k^*\} \geq 0$ , 因此 $\beta_k \leq \alpha_k, \beta_k^* \leq \alpha_k^*$ , 且 $\beta_k \beta_k^* = 0$ 。由于 $\beta_k - \beta_k^* = \alpha_k - \alpha_k^*$ , 代入式(3)有:

$$\begin{aligned} L(\beta_k, \beta_k^*) &= \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) \\ &\quad + \varepsilon \sum_{i \neq k} (\alpha_i + \alpha_i^*) + (\beta_k + \beta_k^*) - \sum_{i=1}^N (\alpha_i - \alpha_i^*) y_i \\ &\leq \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) \\ &\quad + \varepsilon \sum_{i \neq k} (\alpha_i + \alpha_i^*) + (\alpha_k + \alpha_k^*) - \sum_{i=1}^N (\alpha_i - \alpha_i^*) y_i \\ &= L(\alpha_k, \alpha_k^*) \end{aligned}$$

因此, 当式(3)取得最小值时必有:

$$\alpha_k \alpha_k^* = 0, \forall k \in \{1, 2, \dots, N\}$$

由于 $\gamma_k = \alpha_k - \alpha_k^*$ , 因此 $|\gamma_k| = |\alpha_k| + |\alpha_k^*| = \alpha_k + \alpha_k^* (\alpha_k, \alpha_k^* \geq 0)$ , 因为 $\|\gamma\|_1 = \sum_{i=1}^N |\gamma_i|$ , 所以式(3)与式(4)等价性得证。

由于 $\forall i$ , 训练样本向量 $\mathbf{x}_i$ 是确定的, 因此 $k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]})$ 是定值, 可以利用矩阵 $\mathbf{K}$ 存储 $k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]})$ 的信息。给定矩阵 $\mathbf{K}$ 满足:

$$\mathbf{K}_{ij} = k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) \quad (6)$$

令向量 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_N)$ , 并且给定向量 $y = (y_1, y_2, \dots, y_N)$ , 式(4)可以变为:

$$\argmin_{\alpha, \alpha^* \geq 0} \frac{1}{2} \gamma \cdot \mathbf{K} \cdot \gamma^T + \varepsilon \|\gamma\|_1 - \gamma \cdot y \quad (7)$$

最终只需要对式(7)进行优化即可解决原问题。在求解过程中, 为了衡量参数 $\gamma$ 的训练结果, 本文引入了偏差的平方和:

$$err = \sum_{i=1}^N (y_i^* - y_i)^2 \quad (8)$$

其中,  $y_i$ 为第 $i$ 个样本的真实值;  $y_i^*$ 为第 $i$ 个样本的回归值, 且 $y_i^*$ 为:

$$y_i^* = \sum_{j=1}^N \gamma_j k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]}) + b \quad (9)$$

其中,  $b$ 通过如下方式求得:

$$b = \frac{\sum_i [y_i^* - \sum_{j=1}^N \gamma_j k(\mathbf{x}^{[i]}, \mathbf{x}^{[j]})]}{N} \quad (10)$$

为了便于计算, 令向量:

$$\mathbf{B} = b \cdot (1, 1, \dots, 1) \quad (11)$$

在式(7)中已经利用了核函数矩阵 $\mathbf{K}$ , 因此, 式(8)也可以变为:

$$err = (\mathbf{K} \gamma^T + \mathbf{B} - y)^T \cdot (\mathbf{K} \gamma^T + \mathbf{B} - y) \quad (12)$$

最终可利用式(12)衡量训练误差, 误差越小, 训练效果越好。

## 2 模型参数训练算法

参数向量  $\gamma$  训练的步骤:

**步骤 1** 随机生成  $\gamma$  初始值  $\gamma_0$ , 训练次数设为 0。

**步骤 2** 随机生成  $(i, j)$ , s. t.  $i, j \in 1, 2, \dots, N$ ,  $i \neq j$ 。

**步骤 3** 改变  $\gamma_i$  和  $\gamma_j$  的值, 分别得到  $\gamma_i^*$  与  $\gamma_j^*$ , 根据约束条件式(5), 可得:

$$\gamma_i^* + \gamma_j^* = \gamma_i + \gamma_j \quad (13)$$

因此, 令  $\gamma_i^* = \gamma_i + \Delta$ ,  $\gamma_j^* = \gamma_j - \Delta$ , 其中, 增量  $\Delta$  决定训练精度。

**步骤 4** 若  $L(\gamma^*) < L(\gamma)$ , 则令  $\gamma = \gamma^*$ , 其中,  $L(\gamma)$  通过式(7)计算得。

**步骤 5** 训练次数加 1, 若训练次数达到上限值, 结束, 否则回到步骤 2。

本文采用的训练算法, 对初始值  $\gamma_0$  敏感, 需要重复多次进行训练步骤, 从不同初始值  $\gamma_0$  开始搜索最优解。最终  $\gamma$  的取值为:

$$\gamma = \arg \min_{\gamma} \{ err^{(1)}, err^{(2)}, err^{(3)}, \dots, err^{(num)} \} \quad (14)$$

其中,  $err^{(k)}$  代表第  $k$  次训练误差, 可通过式(12)求得; 而  $num$  为重复训练的次数。本文参数训练算法可保证在满足约束条件的前提下, 从多路径逐步逼近最优解, 避免了过早收敛与局部极值。

## 3 核函数权重自适应选择机制

用 4 个核函数的线性组合构成全新的核函数  $k_p(x^{[i]}, x^{[j]})$ , 其中,  $p$  代表该核函数形式对应的编号, 分别对应:

$$\begin{aligned} k_1(x^{[i]}, x^{[j]}) &= x^{[i]} \cdot x^{[j]} + d_1 \\ k_2(x^{[i]}, x^{[j]}) &= (x^{[i]} \cdot x^{[j]} + d_2)^2 \\ k_3(x^{[i]}, x^{[j]}) &= (x^{[i]} \cdot x^{[j]} + d_3)^3 \\ k_4(x^{[i]}, x^{[j]}) &= \exp\{-\sigma(x^{[i]} - x^{[j]}) \cdot (x^{[i]} - x^{[j]})^T\} \end{aligned} \quad (15)$$

因此, 核函数的线性组合构成核函数:

$$k(x^{[i]}, x^{[j]}) = \sum_{p=1}^4 \beta_p k_p(x^{[i]}, x^{[j]}) \quad (16)$$

其中,  $\beta_p$  代表第  $p$  种核函数的权重, 通过权值的调整, 构成合适的核函数。每个原始数据  $(x, y)$  都可以得到在  $p$  种核函数下的训练结果  $(x^*, y^*)_p$ , 将其存入矩阵  $M$  对应的  $M_{ip}$  位置, 其中,  $i$  是点的编号;  $p$  是 4 种核函数对应编号。训练结果与期望值之间的偏差用距离  $\delta$  衡量:

$$\delta = \|(x, y) - (x^*, y^*)\| \quad (17)$$

总的训练误差  $err$ , 可以用距离平方和表示:

$$err = \sum_{i=1}^N \delta^2 = \sum_{i=1}^N \|(x^{[i]}, y_i) - (x^{*[i]}, y_i^*)\|^2 \quad (18)$$

核函数  $k(x^{[i]}, x^{[j]})$  对应的样本偏差为:

$$\delta = \|(x, y) - \sum_{p=1}^4 \beta_p (x^*, y^*)_p\| \quad (19)$$

最小误差对应的系数向量  $\beta = (\beta_1, \beta_2, \beta_3, \beta_4)^T$  表示为列向量形式, 若没有误差, 可以直接列出方程组  $M\beta = y$ , 根据所求得  $\beta$  得到  $k(x^{[i]}, x^{[j]})$ 。对照式(19), 式(18)中误差可以表示为:

$$\begin{aligned} err &= \sum_{i=1}^N \|(x^{[i]}, y_i) - \sum_{p=1}^4 \beta_p (x^{*[i]}, y_i^*)_p\|^2 \\ &= \|y - M\beta\|^2 \end{aligned} \quad (20)$$

利用最小二乘法, 对  $\beta$  求导得到  $M^T y = M^T M \beta$ , 此时只有  $\beta$  是未知量, 可直接解出:

$$\beta = (M^T M)^{-1} M^T y \quad (21)$$

## 4 数据选取与预处理

本文采用文献[17]所提供网站的发布数据, 即 PJM 电力市场逐时负荷数据。

现有的每日数据可构成 24 个元素的向量, 多组向量可构成一个矩阵  $L_{\tau \times 24}$ 。其中,  $\tau$  为一个周期的天数。每个周期构成矩阵  $L^{[1]}, L^{[2]}, \dots, L^{[\tau_{\max}]}$ , 其中,  $\tau_{\max}$  为最大天数, 而  $\tau = 1$  得到的是不分周期逐日回归的效果。为了确定周期  $\tau$  的最优值, 引入均方差矩阵  $A$ , 满足:

$$A_{ij} = \frac{1}{\tau} \cdot \|L^{[i]} - L^{[j]}\|_F^2 \quad (22)$$

根据式(22), 对角线上数据全为 0, 且  $A_{ij} = A_{ji}$ 。不同周期  $\tau$  对应不同的矩阵  $A^{[\tau]}$ 。求解  $\tau$  的最优值可根据目标函数:

$$\min \frac{1}{2\tau(\tau-1)} \|A^{[\tau]}\|_F \quad (23)$$

对每个周期内的每日用电数据进行归一化处理, 使每日的负荷值经过处理后位于区间  $[0, 1]$ :

$$l^* = \frac{l}{\max l} \quad (24)$$

其中,  $l$  为一个周期内的每日负荷向量;  $\max l$  表示一个周期内用电负荷量最大值;  $l^*$  为每日处理后负荷向量。表 1 对不同周期  $\tau$  分别计算目标函数式(23)的值。

表 1 不同周期对应的目标函数式(23)的值

| $\tau$ | 目标函数值/ $10^{-3}$ | $\tau$ | 目标函数值/ $10^{-3}$ |
|--------|------------------|--------|------------------|
| 1      | 1.679 1          | 9      | 1.387 1          |
| 2      | 1.434 2          | 10     | 1.379 9          |
| 3      | 1.453 5          | 11     | 1.505 7          |
| 4      | 1.365 4          | 12     | 1.362 5          |
| 5      | 1.414 3          | 13     | 1.530 1          |
| 6      | 1.369 2          | 14     | 1.118 3          |
| 7      | 1.096 9          | 15     | 1.749 1          |
| 8      | 1.361 0          |        |                  |

本文选取了 2015-01-01 01:00—2015-03-15 24:00 的 PJME 数据, 进行上述步骤。可以发现, 当周期天数为 7 d 时(即一周时), 式(23)取得最小目标函数值, 其次是周期天数为 14 d(7 的倍数)时, 进而可以确定周期天数为 7 d。

5 仿真模拟

核函数参数  $\sigma = 1, d_1 = 0, d_2 = 0, d_3 = 0$ 。参数  $\varepsilon$  分别取  $\varepsilon = 0.01$  和  $\varepsilon = 0.02$ , 经测试对最终结果影响不大。核函数组合权重根据自适应选取机制确定。

在得到每个  $\mathbf{x}$  对应的回归值  $y^*$  后, 用  $y$  和  $y^*$  计算平均绝对误差 (MAPE)。为了验证本文提出算法的性能, 本文采用 3 层人工神经网络 (文献[17]用其预测 PJM 和 ISO 逐时负荷) 以及最小二乘非线性拟合 (经典方法) 的曲面回归方法进行对照。

在 3 层神经网络中, 各节点的计算过程可表示为  $output = input \cdot weight^T + \theta$ , 为了方便计算, 向量维数设置为 3, 第 1 层输入与样本维数有关, 第 3 层为多输入单输出, 共 7 个节点。节点权值调整采用启发式搜索方法, 通过输出结果与真实值的平均绝对误差作为目标函数, 以增量为 0.001 调整相应权值增大或减小。与第 2 节提出的方法类似, 初始值随机生成, 各节点训练顺序为从后往前。并且重复训练 (或并行) 一定次数取最优结果, 避免陷入局部极值的情况。

最小二乘法进行非线性拟合, 需要将原始数据  $\mathbf{x}$  进行映射, 得到高维向量  $\mathbf{x}^*$ , 最终通过  $\mathbf{x}^*$  得到  $y^*$ , 设置映射的最高次幂为 3。

模型参数训练算法的搜索深度均设为 10 000 步, 并行次数为 50 次。3 种回归模型的效果如图 1 所示。




图 1 三维回归的二维效果

图 1 中将一个周期 (7 d, 总共 168 h) 的三维回归结果按照时间序列展开成为二维曲线的结果, 不同方法的平均绝对百分误差见表 2。

表 2 不同方法的 MAPE 对比

| 样本种类   | TDRM | 三层神经网络 | 最小二乘拟合 |
|--------|------|--------|--------|
| 训练样本   | 5.92 | 6.30   | 5.41   |
| 预测检验样本 | 5.46 | 5.62   | 5.54   |

表 2 给出了 3 种方法进行回归得到的平均绝对百分误差 (MAPE), 其中, 样本分为训练样本和预测检验样本 (2015-03-19—2015-03-25)。训练样本共有 10 组, 平均绝对百分偏差为 3.36%, 预测样本只有一组, 无样本偏差, 因此, 训练样本的误差高于较预测检验样本。根据表 2 可知, 3 种方法在回归和预测方面都有较低误差, 说明本文提出的 TDRM 模型具有较好的用电负荷特征学习性能和预测性能。

6 结束语

本文针对负荷的周期性特点, 提出基于 SVR 的三维回归模型 TDRM。仿真结果表明, 该模型在用电负荷的回归、预测方面均有较好的表现。在掌握了用户的用电特征与用电习惯以后, 如何将其应用在引导用户进行错峰用电, 将是下一步的研究方向。

参考文献

[1] HERNANDEZ L, BALADRON C, AGUIAR J M, et al. A Survey on Electric Power Demand Forecasting: Future Trends in Smart Grids, Microgrids and Smart Buildings[J]. IEEE Communications Surveys & Tutorials, 2014, 16(3): 1460-1495.

[2] 肖建, 于龙, 白裔峰. 支持向量回归中核函数和超参数选择方法综述[J]. 西南交通大学学报, 2008, 43(3): 297-303.

[3] HU Wenbin, YAN Liping, LIU Kaizeng, et al. PSO-SVR: A Hybrid Short-term Traffic Flow Forecasting Method[C]// Proceedings of the 21st IEEE International Conference on Parallel and Distributed Systems. Washington D. C., USA: IEEE Press, 2015: 14-17.

[4] LI Yan, LONG Yuening. Application of Improved SVR Model in Ecological Economy Prediction [C]// Proceedings of the 6th International Conference on Intelligent Systems Design and Engineering Applications. Washington D. C., USA: IEEE Conference Publications, 2015: 155-158.

[5] XIE Qiyue, FU Huilin, WANG Xiaoli, et al. SVR Based Prediction Modeling for Carbon Content of Pulverized Coal in Primary Air Pipe of Thermal Power Plant Boiler[C]// Proceedings of the 35th Chinese Control Conference. Washington D. C., USA: IEEE Conference Publications, 2016: 2235-2240.

[6] EL-ATTAR E E, GOULERMAS J Y, WU Q H. Forecasting Electric Daily Peak Load Based on Local Prediction[C]// Proceedings of Power and Energy Society General Meeting. Washington D. C., USA: IEEE Conference Publications, 2009: 1-6.

## 5 结束语

本文提出一种 PCL 环境下粒子滤波目标跟踪算法。给出 KLD 自适应粒子滤波算法中参数设置的方法, 指出了参数设置的正确顺序和规律。实验结果表明, 该算法具有较高的跟踪精度和跟踪效率。由于只实现单目标跟踪, 根据课题要求, 今后将在这些参数设置规律的基础上, 实现多目标跟踪。

### 参考文献

- [1] 侯志强, 韩崇昭. 视觉跟踪技术综述[J]. 自动化学报, 2006, 32(4): 603-617.
  - [2] 张雪华, 刘华平, 孙富春, 等. 采用 Kinect 的移动机器人目标跟踪[J]. 智能系统学报, 2014, 9(1): 34-39.
  - [3] 朱德海. 点云库 PCL 学习教程[M]. 北京: 北京航空航天大学出版社, 2012.
  - [4] COMANICIU D, RAMESH V, MEER P. Kernel-based Object Tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(5): 564-577.
  - [5] ZIMMERMANN K, MATAS J, SVOBODA T. Tracking by an Optimal Sequence of Linear Predictors[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(4): 677-692.
  - [6] FOX D. KLD-sampling: Adaptive Particle Filters[C]//Proceedings of Advances in Neural Information Processing Systems. Seattle, USA: MIT Press, 2002: 713-720.
  - [7] SRTAKA O, IMANDL M. Adaptive Particle Filter with Fixed Empirical Density Quality [C]//Proceedings of the 17th Teiennial World Congress of International Federation of Automatic Control. Seoul, Korea: French Automatic Control Community, 2008: 6484-6489.
  - [8] 常发亮, 马 丽, 刘增晓, 等. 复杂环境下基于自适应粒子滤波器的目标跟踪[J]. 电子学报, 2006, 34(12): 2150-2153.
  - [9] 查宇飞, 毕笃彦. 一种基于粒子滤波的自适应运动目标跟踪方法[J]. 电子与信息学报, 2007, 29(1): 92-95.
  - [10] CHEN Feng, WANG Qing, WANG Song, et al. Object Tracking via Appearance Modeling and Sparse Representation[J]. Image and Vision Computing, 2011, 29(11): 787-796.
  - [11] PATI Y C, REZAIIFAR R, KRISHNAPRASAD P S. Orthogonal Matching Pursuit: Recursive Function Approximation with Applications to Wavelet Decomposition[C]//Proceedings of the 27th Asilomar Conference on Signals, Systems and Computers. Washington D. C., USA: IEEE Press, 1993: 40-44.
  - [12] 文志强, 朱艳辉, 彭召意. 粒子滤波目标跟踪中的有效粒子数控制方法[J]. 控制与决策, 2013, 28(9): 1349-1354.
  - [13] 李晓捷, 李光旭. 基于粒子滤波器算法的特征标记点匹配[J]. 计算机工程, 2016, 42(2): 249-253, 265.
  - [14] RICHTSFELD A, MÖRWALD T, PRANKL J, et al. Segmentation of Unknown Objects in Indoor Environments [C]//Proceedings of IEEE/RSJ International Conference on Intelligent Robots & Systems. Vilamoura, Portugal: Intelligent Robots and Systems, 2012: 4791-4796.
  - [15] ROYHEI U. TRACKING OBJECT in Real Time[EB/OL]. (2010-11-21). <http://pointclouds.org/documentation/tutorials/Tracking.php>.
- 编辑 刘 冰
- 
- (上接第 303 页)
- [7] HONG Wei-chiang, LAI Chien-yuan, HUNG Wei-mou, et al. Electric Load Forecasting by SVR with Chaotic Ant Swarm Optimization [C]//Proceedings of Cybernetics and Intelligent Systems. Washington D. C., USA: IEEE Conference Publications, 2010: 102-107.
  - [8] ZHENG Xiaoxia. Electric Load Forecasting Using Bayesian Least Squares Support Vector Machine[C]//Proceedings of the 6th International Conference on Natural Computation. Washington D. C., USA: IEEE Conference Publications, 2010: 880-883.
  - [9] LI Han, HAN Xueshan, HUA Jian, et al. A Hybrid Approach of Ultra-short Term Multinodeload Forecasting[C]//Proceedings of International Power Engineering Conference. Washington D. C., USA: IEEE Conference Publications, 2007: 1321-1326.
  - [10] 谭艳峰, 贾振红, 覃锡忠, 等. SA-SVR 在移动通信话务量预测中的应用[J]. 计算机工程, 2010, 36(22): 195-196.
  - [11] 韩 锐, 贾振红, 覃锡忠, 等. 基于 SVR 与微分进化策略的话务量预测[J]. 计算机工程, 2011, 37(2): 178-182.
  - [12] 王 琳, 张 赟, 彭文辉, 等. 基于人工蜂群优化的支持向量回归预测方法[J]. 系统工程与电子技术, 2014, 36(2): 326-330.
  - [13] 梁 颖, 方瑞明. 基于 SCADA 和支持向量回归的风电机组状态在线评估方法[J]. 电力系统自动化, 2013, 37(14): 7-12.
  - [14] 黄 磊, 舒 杰, 姜桂秀, 等. 基于多维时间序列局部支持向量回归的微网光伏发电预测[J]. 电力系统自动化, 2014, 38(5): 19-23.
  - [15] 彭建春, 李春晖, 祁学红, 等. 基于快速独立成分分析和支持向量回归的混合馈线线损估算[J]. 电力系统保护与控制, 2012, 40(3): 51-55.
  - [16] 马 进, 贺仁睦, 周彦军. 负荷模型泛化能力的研究[J]. 中国电机工程学报, 2006, 26(21): 29-35.
  - [17] SAHAY K B, TRIPATHI M M. Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Network [C]//Proceedings of Innovative Smart Grid Technologies Conference. Washington D. C., USA: IEEE Conference Publications, 2013: 1-5.
  - [18] 王保义, 赵 硕, 张少敏. 基于云计算和极限学习机的分布式电力负荷预测算法[J]. 电网技术, 2014, 38(2): 526-531.
  - [19] 王德文, 孙志伟. 电力用户侧大数据分析并行负荷预测[J]. 中国电机工程学报, 2015, 35(3): 527-537.
  - [20] 万 昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012, 36(11): 77-81.
- 编辑 刘 冰