

6-1-2020

## Forecasting of Short-term Power Load of SecRPSO-SVM Based on Data-driven

Hairong Sun

*1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;;*

Bixia Xie

*1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;;2. Hebei Engineering Research Center of Simulation & Optimized Control for Power Generation, North China Electric Power University, Baoding 071003, China;*

Tian Yao

*1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;;2. Hebei Engineering Research Center of Simulation & Optimized Control for Power Generation, North China Electric Power University, Baoding 071003, China;*

Zhuoqun Li

*1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

## Forecasting of Short-term Power Load of SecRPSO-SVM Based on Data-driven

### Abstract

**Abstract:** For the parameter selection of support vector machine in modeling, a *particle swarm optimization algorithm based on second-order oscillation and repulsion factor* was proposed to optimize the parameter of SVM. The algorithm employed the nonlinear decreasing weight to balance the global and local search ability. Second-order oscillation factor could maintain the population diversity. The repulsion factor was introduced to make the swarm even distribution in search space, which could avoid local optimum. For the complex characteristics of nonlinearity, time-varying and multifactorial of electric power load, a support vector machine forecasting model based on data was proposed, and the influence of weather, time and historical load on the forecast results was considered. Simulation results show that the proposed method can be used to build an effective and high precision short-term power load forecasting model.

### Keywords

support vector machine, particle swarm optimization, second-order oscillation, repulsion factor, data analysis, short-term load forecasting

### Recommended Citation

Sun Hairong, Xie Bixia, Tian Yao, Li Zhuoqun. Forecasting of Short-term Power Load of SecRPSO-SVM Based on Data-driven[J]. Journal of System Simulation, 2017, 29(8): 1829-1836.

# 基于数据的 SecRPSO-SVM 短期电力负荷预测

孙海蓉<sup>1</sup>, 谢碧霞<sup>1,2</sup>, 田瑶<sup>1,2</sup>, 李卓群<sup>1</sup>

(1. 华北电力大学控制与计算机工程学院, 保定 071003;

2. 华北电力大学河北省发电过程仿真与优化控制工程技术研究中心, 保定 071003)

**摘要:** 针对支持向量机在建模中的参数选取问题, 提出一种二阶振荡和带斥力因子的粒子群优化算法优化支持向量机参数。采用非线性递减权重平衡算法的全局和局部搜索能力, 二阶振荡因子保持种群多样性, 提高全局搜索能力。斥力因子使粒子在搜索空间均匀分布, 避免陷入局部最优。针对电力负荷的非线性、时变性、受多因素影响的复杂特点, 提出一种基于数据的支持向量机预测模型, 综合考虑天气、时间因素、历史负荷对预测结果的影响。仿真表明该方法可以建立短期电力负荷的有效高精度预测模型。

**关键词:** 支持向量机; 粒子群算法; 二阶振荡; 斥力因子; 数据分析; 短期电力负荷

中图分类号: TP391

文献标识码: A

文章编号: 1004-731X (2017) 08-1829-08

DOI: 10.16182/j.issn1004731x.joss.201708025

## Forecasting of Short-term Power Load of SecRPSO-SVM Based on Data-driven

Sun Hairong<sup>1</sup>, Xie Bixia<sup>1,2</sup>, Tian Yao<sup>1,2</sup>, Li Zhuoqun<sup>1</sup>

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;

2. Hebei Engineering Research Center of Simulation & Optimized Control for Power Generation, North China Electric Power University, Baoding 071003, China)

**Abstract:** For the parameter selection of support vector machine in modeling, a *particle swarm optimization algorithm based on second-order oscillation and repulsion factor* was proposed to optimize the parameter of SVM. The algorithm employed the *nonlinear decreasing weight to balance the global and local search ability*. *Second-order oscillation factor could maintain the population diversity*. The *repulsion factor was introduced to make the swarm even distribution in search space, which could avoid local optimum*. For the complex characteristics of nonlinearity, time-varying and multifactorial of electric power load, a support vector machine forecasting model based on data was proposed, and the influence of weather, time and historical load on the forecast results was considered. Simulation results show that the proposed method can be used to build an effective and high precision short-term power load forecasting model.

**Keywords:** support vector machine; particle swarm optimization; second-order oscillation; repulsion factor; data analysis; short-term load forecasting

## 引言

短期电力负荷预测是电网能量管理的重要组



收稿日期: 2016-11-02 修回日期: 2016-12-18;  
基金项目: 中央高校基本科研业务费专项资金  
(2016MS143);

作者简介: 孙海蓉(1972-), 女, 北京, 博士, 副教授,  
研究方向为智能控制、系统建模、分析与综合; 谢碧霞  
(1992-), 女, 福建莆田, 硕士, 研究方向为智能算法  
和系统建模。

成部分, 要实现有计划地进行电力系统的营销、负荷经济调度分配等工作, 需要依赖精确的负荷预测数据。精确的预测源于海量的记录数据<sup>[1]</sup>, 合理有效利用大数据与短期负荷预测方法的预测结果, 对提高预测精度有重要意义。

短期负荷预测方法分为经典预测方法和智能预测方法。经典方法主要包括回归分析<sup>[2]</sup>、时间序

列分析<sup>[3]</sup>等方法。电力系统具有混杂特性和大随机性的电力负荷历史数据,时间序列法是处理随机序列的有效方法,但时间序列法和非线性回归分析法的预测精度会随着生产、气象等因素的波动而大大降低。智能方法有模糊逻辑<sup>[4]</sup>、神经网络<sup>[5-6]</sup>、小波分析<sup>[6]</sup>、支持向量机<sup>[7-8]</sup>等方法。模糊理论有效解决了电力负荷的不确定性因素,但电力负荷系统的时变性特点使其预测精度并不十分理想。小波分析解决了电力负荷系统周期性波动的复杂情况,其不足是对温度、湿度等因素不敏感,难以解决气象因素对负荷预测的影响<sup>[6]</sup>。神经网络能对系统进行非线性无限的逼近和对输入信息各种复杂问题的有效处理,但其预测能力受初始连接权值、阈值等参数的影响较大<sup>[4]</sup>。支持向量机(Support Vector Machine, SVM)在解决非线性、高维数等问题中表现出结构简单、泛化能力强和全局最优等优势,取得了比神经网络和模糊模型更好的预测效果<sup>[7-8]</sup>,其核函数参数是影响 SVM 预测效果的关键因素。传统网格搜索的 SVM 核参数选择方法实现简单但计算量大且效率低。针对传统 SVM 核参数选取方法精度低的问题,引入了群智能算法,并取得较好的效果。粒子群(Particle Swarm Optimization, PSO)及其改进算法在 SVM 核参数优化领域应用最广<sup>[9-10]</sup>。在不同程度上,这些算法实现了优化 SVM 参数的目的,但本身也存在不足。

本文提出一种基于二阶振荡和带斥力因子的 PSO 算法(Second-order Oscillation and Repulsion Particle Swarm Optimization, SecRPSO)。针对种群寻优后期多样性下降而导致算法陷入停滞的问题<sup>[11]</sup>,采用二阶振荡因子,利用粒子位置变化和振荡的学习因子更新粒子速度,提高种群多样性,改善算法的全局收敛性。由于缺少变异因子,PSO 算法易发生“早熟”,陷入局部最优<sup>[12]</sup>,利用斥力因子改善粒子的分布格局,避免陷入局部最优,并采用非线性递减权重均衡算法的全局和局部搜索能力。将该算法应用于短期电力负荷预测建模,对 SVM 的学习参数在线优化,预处理实际生产过程的大量历史数据,全面考虑各影响因素,提高预测

精度。结果表明,SecRPSO 算法优化了 SVM 结构,基于数据分析的 SVM 预测模型改善了预测效果。

## 1 粒子群算法

### 1.1 基本粒子群算法

基本 PSO 算法将优化问题的潜在解用搜索空间中的粒子表示。首先在可解空间中初始化一群粒子,用位置、速度和适应度值三个指标来表达每个粒子的特征,其中速度决定粒子移动的方向和距离,即粒子的位置。粒子的速度是根据自身和其余粒子的位置进行动态调整,粒子具有记忆能力,依据比较新粒子的适应度值和当前个体极值、群体极值的适应度值来更新个体极值和群体极值的位置。

在  $D$  维目标搜索空间中随机生成一个由  $n$  个粒子组成的种群,用  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  表示第  $i$  个粒子的速度,在搜索空间中对应的位置表示为  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ,即问题的一个潜在解。根据目标函数计算出相对应的适应度值。分别用  $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 、 $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$  代表个体极值和群体极值。每次迭代过程中,粒子依靠个体极值和群体极值的变化来更新自己的速度和位置。

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (1)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (2)$$

式中:  $d = 1, 2, \dots, D$ ;  $i = 1, 2, \dots, n$ ;  $k$  表示当前的迭代次数;  $V_{id}$  表示粒子的速度;  $\omega$  表示惯性权重系数;  $c_1$ 、 $c_2$  表示加速度因子,均是非负的常数;  $r_1$ 、 $r_2$  表示分布在 0~1 之间的随机数。预先为位置和速度设置一个特定的区域,使得粒子在可解空间内有目的地搜索<sup>[13]</sup>。

### 1.2 改进粒子群算法

为避免算法过早陷入停滞和陷入局部最优,SecRPSO 算法引入二阶振荡学习因子和斥力因子的粒子速度更新策略来提高粒子群体多样性和改善粒子的分布特性。

#### 1.2.1 二阶振荡粒子

基本 PSO 算法中,速度更新公式分别由前一

时刻的速度信息、当前粒子对个体位置的认知和对群体位置的认知三部分组成。基本 PSO 算法的粒子飞行速度仅依靠粒子当前位置的信息进行更新, 而二阶粒子群算法中粒子飞行速度的变化与粒子位置的变化有关, 使粒子向着更优的位置运动。为了进一步增加粒子群体的多样性, 可在二阶粒子群算法中引入一个振荡环节<sup>[14]</sup>, 其速度更新方程为:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - (1 + \xi_1) X_{id}^k + \xi_1 X_{id}^{k-1}) + c_2 r_2 (P_{gd}^k - (1 + \xi_2) X_{id}^k + \xi_2 X_{id}^{k-1}) \quad (3)$$

在二阶振荡粒子群算法中, 惯性权重系数非线性递减, 其表达形式为:

$$\omega = \omega_{ini} - (\omega_{ini} - \omega_{end})(k / k_{max})^2 \quad (4)$$

式中:  $\omega_{ini}$ 、 $\omega_{end}$  分别为惯性权重的初始值和终止值。

在算法前期取  $\xi_1 < \frac{2\sqrt{c_1}-1}{c_1}$ ,  $\xi_2 < \frac{2\sqrt{c_2}-1}{c_2}$ , 增强算法的全局搜索能力; 算法后期取  $\xi_1 \geq \frac{2\sqrt{c_1}-1}{c_1}$ ,  $\xi_2 \geq \frac{2\sqrt{c_2}-1}{c_2}$ , 使算法有较高的寻优能力, 并实现算法的细致搜索。

由上述混合粒子群算法的速度更新式(3)可看出, SecRPSO 算法中,  $k$  代粒子的个体位置和群体位置认知不仅依赖  $k$  代粒子位置信息, 还与  $k-1$  代粒子位置变化信息有关。SecRPSO 算法引入参数  $\xi$ , 依靠  $\xi$  的取值来调整算法在不同时期的搜索能力,  $\xi$  在其相应的取值范围内随机取值, 动态地调整搜索力度, 达到算法前期有较强的全局搜索能力和算法后期精细搜索的目的, 从而加快收敛速度。

### 1.2.2 斥力因子

在算法迭代初始阶段粒子可能会过度集中在某一搜索区域而陷入局部最优<sup>[15]</sup>。为了改善粒子在搜索空间分布特性, 使粒子尽可能均衡散布在整个搜索空间, 在粒子位置更新策略中引入了一个斥力因子。其主要原理是在每次迭代中粒子位置更新之后, 分别计算每个粒子在各个维度上与其他粒子对应维度的距离之和, 设  $\sum_{i \neq j, j=1}^n \|x_{id}^k - x_{jd}^k\|$  表示第  $i$

个粒子在  $d$  维上与其他粒子相应维的距离之和, 最后将其与粒子事先设定粒子间最小的允许距离  $\Delta l^k$  进行比较:

$$\text{当 } \sum_{i \neq j, j=1}^N \|x_{id}^k - x_{jd}^k\| < \Delta l^k \text{ 时:} \\ x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} + 2\Delta l^k \quad (5)$$

$$\text{当 } \sum_{i \neq j, j=1}^N \|x_{id}^k - x_{jd}^k\| \geq \Delta l^k \text{ 时:} \\ x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (6)$$

设置最小允许间距的取值随迭代次数的增加而逐渐减小, 实现算法在初始阶段在搜索空间快速粗糙寻优而在搜索后期小范围局部精细寻优,  $\Delta l^k$  变化规律表达形式为:

$$\Delta l^k = l_{ini} - (l_{ini} - l_{end})(k / k_{max})^2 \quad (7)$$

式中:  $l_{ini}$ 、 $l_{end}$  为粒子间最小的允许距离  $\Delta l^k$  的初始值和最终值。

## 2 支持向量机

### 2.1 支持向量机预测原理

支持向量机是将寻找最优超平面的算法转化为求解一个凸二次规划问题, 运用核函数的相关理论, 通过非线性映射把线性不可分的样本空间映射到一个线性可分的高维特征空间, 在特征空间中可以根据线性学习机的方法解决样本空间中的非线性分类和回归问题。

设训练样本集  $\{(x_i, y_i) | i=1, 2, \dots, N\}$ , 其中  $N$  为训练样本数,  $x_i \in R^N$  为第  $i$  个样本的输入,  $y_i \in R$  为对应输出, 式(8)表示映射后的预测模型:

$$f(x) = \omega^T \phi(x) + b \quad (8)$$

式中:  $\omega$  为权值;  $b$  为偏差;  $\phi(x)$  是从输入空间到高维特征空间的非线性映射。

依据结构风险最小化原理, SVM 优化目标可由式(9)表示:

$$\phi(\omega, \xi, \xi^*) = \frac{1}{2} \|\omega\|^2 + C \left( \sum_{i=1}^i \xi_i + \sum_{i=1}^i \xi_i^* \right) \quad (9)$$

约束条件为:

$$\omega^T x_i + b - y_i \leq \xi_i^* + \varepsilon, i=1, 2, \dots, N \quad (10)$$

$$y_i - \omega^T x_i - b \leq \xi_i + \varepsilon, i=1, 2, \dots, N \quad (11)$$

$$\xi, \xi^* \geq 0, i=1, 2, \dots, N \quad (12)$$

式中:  $C$  为惩罚因子;  $\xi, \xi^*$  分别为松弛变量的上下限;  $\varepsilon$  为不敏感损失参数。

通过引入 Lagrange 函数, 利用拉格朗日乘子法将这个有约束的非线性规划问题转化为对偶问题, 求解得出相应的 Lagrange 参数, 最终得到非线性预测模型的表达式为:

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) K(x_i, x_j) + b \quad (13)$$

式中:  $a_i, a_i^* \geq 0$  为 Lagrange 乘子;  $K(x_i, x_j)$  为一个满足 Mercer 条件的核函数。

常用的核函数有多项式核函数、径向基(Radial Basis Function, RBF)核函数和 Sigmoid 核函数, 本文采用 RBF 核函数:

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right)$$

## 2.2 预测模型参数优化及评价标准

短期电力负荷预测建立的模型是非线性支持向量机回归模型, 核函数类型的选择对负荷预测精度的影响非常大, 需要事先设定核函数的类型并对一些参数进行寻优。根据以往的相关研究, 在缺乏样本数据的先验知识的情况下, 采用 RBF 核函数可获得比其他类型核函数更好的总体性能, 因此将采取 RBF 函数作为核函数。实验研究发现, 惩罚系数  $C$  和 RBF 核函数中的宽度系数  $\gamma$  对 SVM 的性能表现有十分重要的作用<sup>[16]</sup>, 其中惩罚系数  $C$  用来权衡损失和分类间隔的权重, 表示训练误差的大小和泛化能力的强弱; 宽度系数  $\gamma$  控制了函数的径向作用范围, 决定了训练样本数据的范围和分布特性。本文利用 SecRPSO 算法对 SVM 算法的这两个参数寻优。预测完成后, 为了验证所建模型的准确性, 进行模型预测精度评价。选取平均绝对百分误差(Mean Absolute Percent Error, MAPE)和相对误差(Relative Error, RE)作为 SVM 模型评判指标; 均方误差(Mean Square Error, MSE)作为适应度函数。其定义为:

1) 相对误差 RE;

$$RE = \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{|Y_i|} \times 100\%$$

2) 平均相对误差绝对值(平均绝对百分误差)MAPE;

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{|Y_i|} \times 100\%$$

3) 均方误差 MSE;

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \times 100\%$$

式中:  $Y_i$  和  $\hat{Y}_i$  分别是负荷的真实值和预测值;  $n$  为预测天数。

## 3 基于数据的 SVM 预测模型

本文选取某电力公司三年内的电力负荷记录<sup>[17]</sup>为研究对象, 包括三年内的电力负荷值、日均气温以及节假日时间表。电力负荷数据为每隔 0.5 h 采样的负荷值, 还包括日均负荷、日最大/小负荷值及其差值, 考虑了温度、工作日、节假日等影响因素对电力负荷造成的波动, 为建立更加精确的负荷预测模型提供依据。基于数据分析建立短期电力负荷的 SVM 预测模型, 并分别用 SecRPSO 算法、基本粒子群算法和网格寻优算法对惩罚系数  $C$  和核函数宽度系数  $\gamma$  寻优, 比较三者的预测精度。

### 3.1 样本特征的选择

短期电力负荷预测是多变量预测问题, 在建立预测模型时, 将其当作函数的回归问题。其函数的输出为预测负荷值  $y$ , 将影响负荷的因素如: 历史负荷、气温数据、时间信息等作为函数输入  $x$ 。称训练样本集  $\{(x_i, y_i)\}$  中输入向量  $x_i$  中的每一个元素为一种特征。

不同特征将会影响所建模型的有效性与准确性, 影响负荷的因素主要有历史负荷序列、气温因素、时间因素、社会经济因素等。支持向量机训练样本集中的特征对基于 SVM 的短期电力负荷预测的精度影响很大。在有关基于 SVM 的短期电力负

荷预测建模中特征确定的问题上,已经做了众多研究,利用不同方式确定样本的特征<sup>[18-19]</sup>。本文将样本的输入量确定为历史负荷、气温和日属性(节假日属性和周属性)。

### 3.2 数据预处理

为消去不同量纲数据对结果的影响,防止较大范围变化的数据覆盖较小范围变化的数据。对数据进行归一化处理。用如下公式对原始数据进行线性缩放处理,限制在一定的范围内:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

式中:  $x_{\max}$  和  $x_{\min}$  分别代表样本中历史负荷的最大值和最小值。最后对模型的输出按式(19)进行反归一化处理:

$$x = x_{\min} + (x_{\max} - x_{\min})x' \quad (15)$$

气温波动是影响短期负荷曲线变化的最大干扰因素<sup>[18]</sup>。为了提高 SVM 训练速度,消除温度的冗余信息,对温度进行模糊化处理,把温度的确切量用三个不同等级的模糊量表示,并利用隶属函数描述不同等级的模糊量。本文将每日的平均气温模糊划分为低温、中温、高温,按照隶属度最大原则确定日均气温所属的模糊集。式(16)~(18)分别是三个温度等级的隶属函数。

低温的隶属函数为:

$$u_1 = \begin{cases} 0, & t > 5 \\ \frac{5-t}{15}, & -10 < t < 5 \\ 1, & t < -10 \end{cases} \quad (16)$$

中温的隶属函数为:

$$u_1 = \begin{cases} 0, & t < 0 \text{ 或 } t > 20 \\ \frac{t}{10}, & 0 \leq t \leq 10 \\ \frac{20-t}{10}, & 10 < t \leq 20 \end{cases} \quad (17)$$

高温的隶属函数为:

$$u_1 = \begin{cases} 0, & t < 15 \\ \frac{t-15}{10}, & 15 < t < 25 \\ 1, & t > 25 \end{cases} \quad (18)$$

同时,对输入样本特征编码,最后得到的输入样本分别是:

1) 预测日前 7 天每日的日平均负荷数据  $A = \{a_1, a_2, a_3, a_4, a_5, a_6, a_7\}$ ;

2) 预测日的日平均气温  $T = (-1, 0, 1)$ , 三个元素分别对应模糊集低温、中温和高温;

3) 预测日的周属性  $W = \{1, 2, 3, 4, 5, 6, 7\}$ , 其中的数值对应于周一到周日;

4) 预测日的节日属性  $F = (1, 0)$ , 值为 1 代表预测日是重大节假日,值为 0 则代表预测日为非重大节假日;

由此可得基于数据的 SVM 算法输入样本为 10 维向量  $\{a_1, a_2, a_3, a_4, a_5, a_6, a_7, T, W\}$ , 输出样本为 1 维向量  $R$ , 是预测日的日平均负荷。

### 3.3 建立预测模型步骤

本文选用滚动预测的方式进行短期电力负荷预测建模,其步骤如下:

1) 预处理输入样本中的数据,得到训练数据集;

2) 用训练数据集建立次日的日均负荷 SVM 模型;

3) 采用 SecRPSO 算法对惩罚因子  $C$ 、核函数宽度系数  $\gamma$  进行寻优;

4) 将次日预测出的数据当成已知数据,加入到训练数据集中;

5) 重复 2)~4)直到得出所有待预测日的日均负荷预测结果;

6) 对所建模型进行预测效果评判。

## 4 模型验证

本文主要研究的短期电力负荷预测模型是基于数据分析的 SecRPSO 寻优算法的 SVM 预测模型,为了检验这种模型是否具有较高的准确性,本文建立了基于基本 PSO 算法和网格寻优算法的 SVM 预测模型与之对比。本文选用上一年度半年间的每日日均负荷数据、日均温度、节日属性和周

属性数据形成训练样本预测次年 1 月的日均负荷。

#### 4.1 实验仿真

##### 1) 网格寻优算法的 SVM 建模

网格寻优法中运用的验证原理是交叉验证 (CV: Cross Validation), 本文选用常用的  $k$  折交叉验证 ( $k$ -CV), 在寻优过程中对每得到一组新的参数数据, 利用交叉验证去验证。首先将原始数据进行随机平分成  $k$  组子集, 每个子集数据依次做一次验证集, 其余的  $k-1$  组子集数据作为训练集, 分别将验证集数据带入用训练集建立的模型计算出均方差, 此参数下  $k$  个均方差的平均值作为模型精度的评判指标, 值越小表明模型具有更高的预测精度。

相关参数设置为: 数据归一化范围为  $[-1, 1]$ , 参数  $C$  的变化空间为  $[-3.4:0.2:3.4]$ , 参数  $\gamma$  的变化区间为  $[-3.4:0.2:3.4]$ ,  $k=5$ , 不敏感函数  $\varepsilon=0.01$ 。模型预测结果如图 1 所示。

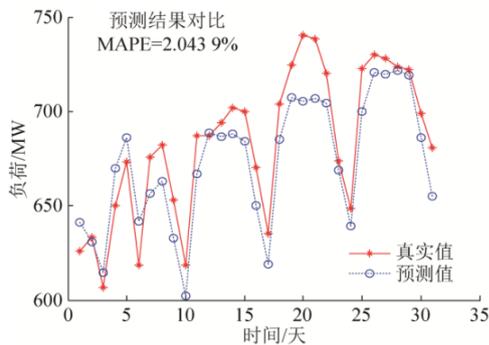


图 1 网格寻优算法的 SVM 预测模型结果  
Fig. 1 SVM prediction model results of grid algorithm

##### 2) 基本 PSO 寻优算法的 SVM 建模

相关参数设置为: 数据归一化范围为  $[-1, 1]$ , 加速度因子  $c_1, c_2=2$ , 种群规模设置为  $n=20$ , 最大进化代数  $G_{\max}=100$ , 不敏感函数  $\varepsilon=0.01$ , 参数  $C$  及参数  $\gamma$  的搜索范围和搜索速度分别为  $[0.1, 10]$  和  $[-6, 6]$ 。模型预测结果如图 2 所示。

##### 3) SecRPSO 寻优算法的 SVM 建模

惯性权重  $\omega_{ini}=0.9$ ,  $\omega_{end}=0.4$ , 最小允许间距  $l_{ini}=30$ ,  $l_{end}=5$ ; , 设定  $\xi_1, \xi_2$  在算法前期 ( $i < G_{\max}/2$ ) 在  $(0, \frac{2\sqrt{c_1}-1}{c_1})$  和  $(0, \frac{2\sqrt{c_2}-1}{c_2})$  内均匀

分布, 在算法后期 ( $i \geq G_{\max}/2$ ),  $\xi_1, \xi_2$  在  $(\frac{2\sqrt{c_1}-1}{c_1}, \frac{3(2\sqrt{c_1}-1)}{2c_1})$  和  $(\frac{2\sqrt{c_2}-1}{c_2}, \frac{3(2\sqrt{c_2}-1)}{2c_2})$  内均匀分布, 其余参数与基本 PSO 算法一致。模型预测结果如图 3 所示。

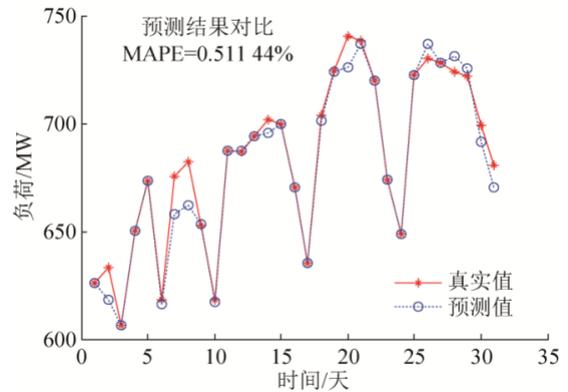


图 2 基本 PSO 寻优算法的 SVM 预测模型结果  
Fig. 2 SVM prediction model results of basic PSO algorithm

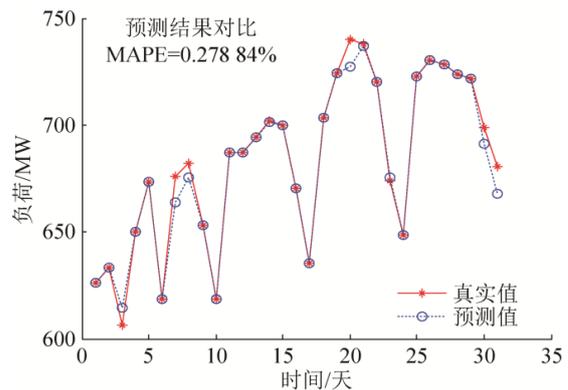


图 3 SecRPSO 寻优算法的 SVM 预测模型结果  
Fig. 3 SVM prediction model results of SecRPSO algorithm

#### 4.2 预测结果分析

从图 1 可以看出, 基于网格寻优算法建立的 SVM 预测模型与真实负荷值曲线出入较大, 不能很好地跟随真实值的变化而变化。基于基本 PSO 寻优和 SecRPSO 寻优算法建立的 SVM 预测模型与真实负荷值曲线的拟合度较好, 而基于 SecRPSO 寻优算法建立的 SVM 预测模型的预测准确度更高且相对平稳。表 1 是基于 SecRPSO 寻优算法建立的 SVM 预测模型的预测结果; 表 2 是将基于三种算法建立的 SVM 预测模型在不同评判标准下 (ME 和 MAPE) 作对比。

表 1 基于 SecRPSO 算法 SVM 模型的预测结果

Tab. 1 Prediction results of SVM model based on SecRPSO algorithm

预测日期(1月)	实际负荷/MW	预测/MW	RE (%)
1	626.041 7	626.041 9	3.56E-5
2	633.354 2	633.355 7	0.000 2
3	606.479 2	614.336 6	1.061 3
4	650.250 0	650.250 4	5.19E-5
5	673.375 0	673.374 2	0.000 1
6	618.416 7	618.416 0	8.57E-5
7	675.770 8	663.724 4	1.027 2
8	682.208 3	675.355 8	0.625 6
9	652.979 2	652.941 6	0.000 5
10	618.416 7	618.416 7	1.08E-6
11	687.312 5	687.313 5	0.000 1
12	687.000 0	686.891 1	0.014 7
13	694.229 2	694.227 6	0.000 2
14	701.979 2	701.26	0.097 1
15	699.812 5	699.812 9	5.15E-5
16	670.312 5	670.312 2	4.47E-5
17	635.375 0	635.373 9	0.000 1
18	703.645 8	703.644 9	0.000 1
19	724.520 8	724.520 8	8.12E-7
20	740.291 7	727.145 7	1.775 7
21	738.291 7	736.886 5	0.189 8
22	720.083 3	720.083 7	4.91E-5
23	673.833 3	675.329 4	0.202 0
24	648.583 3	648.799 9	0.029 2
25	722.562 5	722.563 1	7.89E-5
26	730.229 2	730.229 1	6.51E-6
27	728.166 7	728.149 3	0.002 3
28	723.729 2	723.880 6	0.020 4
29	722.000 0	721.999 7	4.37E-5
30	699.104 2	691.331 3	1.049 9
31	680.750 0	667.182 7	1.032 6

表 2 SVM 模型基于不同参数寻优算法的实验结果对比  
Tab. 2 Comparison of experimental results of SVM model based on different parameter optimization algorithms

寻优方法	参数 $c$ 值	参数 $\gamma$ 值	ME (MW)	MAPE (%)
SecRPSO	9.225 4	0.559 1	1.567 3	0.278 84
基本 PSO	10.000 0	1.168 5	14.481 1	0.511 44
网格搜索	4.000 0	0.125 0	35.098 3	2.043 9

从表 1 可以看出, 基于 SecRPSO 寻优算法建立的 SVM 预测模型的相对误差 RE 普遍较小, 预测值能够跟踪实际值的变化, 误差在工程应用范围之内波动。因此, SecRPSO 优化算法建立短期电力

负荷 SVM 预测模型是一种可行有效的方法。

本文采取的是滚动预测方式, 每预测一天建立一个新的模型, 表 2 中的参数  $c$  取值和参数  $\gamma$  取值均取自 1 月 31 日的模型参数。从表 2 可以看出, 网格优化算法建立的预测模型最大误差为 35.098 3 MW, 平均绝对百分误差是 2.043 9%, 远高于 PSO 寻优算法建立的 SVM 预测模型的最大误差和平均绝对百分误差。SecRPSO 算法的位置修正策略通过维持种群多样性, 提高了全局搜索能力, 斥力因子的引入保证了粒子均匀分散于搜索空间, 避免陷入局部最优, 所以基于 SecRPSO 算法建立的预测模型比基于基本 PSO 算法建立的模型误差更小、拟合精度更高。由此可见, 基于 SecRPSO 寻优算法相比于基本 PSO 寻优算法更适用于短期电力负荷 SVM 预测模型的建立, 它的优势在于能够有效提升短期电力负荷的预测精度。

## 5 结论

本文选取短期电力负荷为研究对象, 采用支持向量机建立其预测模型, 在对海量数据的负荷记录的特性分析研究的基础上, 充分考虑主要影响因素对负荷预测性能的影响, 基于模糊理论对训练样本进行有效的约简, 提高训练速度。同时, 提出一种基于二阶振荡及斥力因子粒子群算法优化 SVM 参数, 改善了基本 PSO 算法早熟收敛的不足, 提高了粒子群体的多样性, 增强全局寻优能力。与基于网格寻优和基本 PSO 寻优算法所建立的 SVM 预测模型在多种预测精度评判指标下进行对比, 利用图表等方式直观表示出所建模型的准确性。仿真结果表明将 PSO 寻优算法和 SVM 方法结合可以建立出短期电力负荷的有效预测模型, 基于 SecRPSO 寻优算法建立的短期电力负荷 SVM 预测模型比基于基本 PSO 寻优算法建立的预测模型具有更好的稳定性和更高的预测精度。同时, 该方法可以应用到风速预测建模、软测量和故障诊断等方面。

## 参考文献:

- [1] 沈伟民, 黄蕾, 张晓闽. 大数据让负荷预测更精准 [J].

- 国家电网, 2016, 11(7): 64-65. (Shen Weimin, Huang Lei, Zhang Xiaomin. Big data makes load forecasting more accurate [J]. National Grid, 2016, 11(7): 64-65.)
- [2] 袁诚斌, 张涛, 朱建良. 基于 MRA 与回归分析法的短期电力负荷预测 [J]. 信息技术, 2007, 46(10): 88-90. (Yuan Chengbin, Zhang Tao, Zhu Jianliang. Short term power load forecasting based on MRA and regression analysis [J]. Information Technology, 2007 (10): 88-90.)
- [3] 李玲玲, 朱博. 基于混沌时间序列的短期电力负荷预测 [J]. 信息技术, 2009, 33(3): 44-46. (Li Lingling, Zhu Bo. Short term power load forecasting based on chaotic time series [J]. Information Technology, 2009(3): 44-46.)
- [4] 周虎, 江岳春, 陈旭, 等. 模糊聚类分析和代数算法结合的短期负荷预测 [J]. 电力系统及其自动化学报, 2011, 23(3): 101-105. (Zhou Hu, Jiang Yue Chun, Chen Xu, et al. Combining fuzzy clustering analysis and algebraic algorithm for short-term load forecasting [J]. Power System And Automation, 2011, 23(3): 101-105.)
- [5] 吴桂峰, 王轩, 陈东雷. 基于优化神经网络的短期电力负荷预测 [J]. 计算机仿真, 2013, 30(11): 95-99, 111. (Wu Guifeng, Wang Xuan, Chen Donglei. Short term power load forecasting based on optimized neural network [J]. Computer Simulation, 2013, 30(11): 95-99, 111.)
- [6] 王玉龙, 崔玉, 李鹏, 等. 基于小波分析改进的神经网络模型电力系统负荷预测 [J]. 电网与清洁能源, 2015, 31(2): 16-20, 27. (Wang Yulong, Cui Yu, Li Peng, et al. Improved neural network model based on wavelet analysis, power system load forecasting [J]. Power Grid And Clean Energy, 2015, 31(2): 16-20, 27.)
- [7] 段其昌, 曾勇, 黄大伟, 等. 基于扩展记忆粒子群-支持向量回归的短期电力负荷预测 [J]. 电力系统保护与控制, 2012, 40(2): 40-44. (Duan Qichang, Zeng Yong, Huang Dawei, et al. Short-term power load forecast based on particle swarm optimization with extended memory and support vector regression [J]. Power System Protection and Control, 2012, 40(2): 40-44.)
- [8] 王义军, 李殿文, 高超, 等. 基于改进的 PSO-SVM 的短期电力负荷预测 [J]. 电测与仪表, 2015, 52(3): 22-25. (Wang Yijun, Li Dianwen, Gao Chao, et al. Short term power load forecasting based on improved [J]. PSO-SVM Electrical Measurement and Instrumentation, 2015, 52(3): 22-25.)
- [9] 高春能, 张彪, 纪志成. 基于自适应动态搜索粒子群的 SVM 参数优化研究 [J]. 系统仿真学报, 2015, 27(12): 2958-2964, 2972. (Gao Chuneng, Zhang Biao, Ji Zhicheng. Research on Optimization of SVM parameters based on adaptive dynamic search particle swarm [J]. Journal of System Simulation (S1004-731X), 2015, 27(12): 2958-2964, 2972.)
- [10] 祝晓燕, 张金会, 付士鹏, 等. 基于改进 PSO 的 SVM 参数优化及其在风速预测中的应用 [J]. 中国电力, 2013, 46(11): 105-108. (Zhu Xiaoyan, Zhang Jinhui, Fu Shipeng, et al. Optimization of SVM parameters based on improved PSO and its application in wind speed prediction [J]. China Electric Power, 2013, 46(11): 105-108.)
- [11] 方伟, 孙俊, 须文波. 一种多样性控制的粒子群优化算法 [J]. 控制与决策, 2008, 23(8): 863-868. (Fang Wei, Sun Jun, Xu Wenbo. A particle swarm optimization algorithm with diversity control [J]. Control And Decision, 2008, 23(8): 863-868.)
- [12] 高立群, 吴沛锋, 邹德旋. 基于变异策略的粒子群算法 [J]. 东北大学学报(自然科学版), 2010, 31(11): 1530-1533. (Gao Liqun, Wu Peifeng, Zou Dexuan. Particle swarm optimization algorithm based on mutation strategy [J]. Journal of Northeastern University (Natural Science edition), 2010, 31(11): 1530-1533.)
- [13] 李丽, 牛奔. 粒子群优化算法 [M]. 北京: 冶金工业出版社, 2009. (Li Li, Niu Ben. Particle swarm optimization algorithm [M]. Beijing, China: Metallurgical Industry Press, 2009.)
- [14] 胡建秀, 曾建潮. 二阶振荡微粒群算法 [J]. 系统仿真学报, 2007, 19(5): 997-999. (Hu Jianxiu, Zeng Jianchao. Two order oscillating particle swarm algorithm [J]. Journal of System Simulation (S1004-731X), 2007, 19(5): 997-999.)
- [15] 张成兴. 时变压缩因子粒子群算法 [J]. 计算机工程与应用, 2015, 51(23): 59-64. (Zhang Chengxing. Time varying compression factor particle swarm optimization [J]. Computer Engineering and Applications, 2015, 51(23): 59-64.)
- [16] 魏俊, 周步祥, 林楠, 等. 基于蚁群支持向量机的短期负荷预测 [J]. 电力系统保护与控制, 2009, 37(4): 36-40. (Wei Jun, Zhou Buxiang, Lin Nan, et al. Short term load forecasting based on ant colony support vector machines [J]. Power System Protection and Control, 2009, 37(4): 36-40.)
- [17] Eunite. World-wide European intelligence technology network competition load forecast sample data [DB/OL]. (2001-08-01) [2016-10-01]. <http://neuron.tuke.sk/competition/index.php>
- [18] 康重庆, 周安石, 王鹏, 等. 短期负荷预测中实时气象因素的影响分析及其处理策略 [J]. 电网技术, 2006, 30(7): 5-10. (Kang Chongqing, Zhou Anshi, Wang Peng, et al. Analysis of the influence of real-time meteorological factors in short-term load forecasting and its treatment strategy [J]. Power System Technology, 2006, 30(7): 5-10.)
- [19] Hinojosa V H, Hoese A. Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms [J]. IEEE Transaction on Power Systems (S0885-8950), 2010, 25(1): 565-574.