

基于动态双组粒子群的短期负荷预测

王雪微, 程若发, 杨宏超, 吕彩艳

(南昌航空大学 信息工程学院, 南昌 330063)

摘要: 为提高电网短期负荷预测的精度, 提出一种有效的优化支持向量机参数的算法; 该算法首先将初始粒子群适应度排序, 然后根据适应度的大小将初始粒子群划分为两组, 并同时运用不同的权重进行全局搜索和局部搜索; 前期, 全局搜索的粒子群数量远多于局部搜索, 且使用全局搜索能力强的较大的惯性权重; 局部搜索的粒子群使用较小的惯性权重; 随着迭代次数的增加, 全局搜索的粒子群数量不断减少, 局部搜索不断增多, 两组粒子数量动态变化; 并且引入平均粒距和适应度方差解决粒子群容易陷入局部最优这一问题, 最后用改进的动态双组粒子群算法优化最小二乘支持向量机的参数用于短期负荷预测, 实验结果表明该方法预测精度更高, 可行且有效。

关键词: 短期负荷预测; 动态双组; 全局搜索; 局部搜索; 支持向量机

Short-term Load Forecasting Based on Dynamic Bi-group Particle Swarm

Wang Xuwei, Cheng Ruofa, Yang Hongchao, Lü Caiyan

(Information Engineering Institute, Nanchang Aviation University, Nanchang 330063, China)

Abstract: In order to improve the accuracy of short-term load forecasting, this paper presents an efficient algorithm for parameter optimization of Support Vector Machine. The algorithm first sorts the initial particle swarm fitness, and then divides the initial particle swarm into two groups according to the size of the fitness, and simultaneously uses the different weights for global search and local search. The number of global search particles is much larger than that of local search, and the larger global inertia weight is used. The local search particle group uses a smaller inertia weight. With the increase of the number of iterations, the number of global search particles is decreasing, the number of local search is increasing, the number of particles of two groups is dynamically changing. And the average particle size and fitness variance are introduced to solve the problem that the particle group is easy to fall into the local optimum. Finally, the improved dynamic two group particle swarm optimization algorithm is used to optimize the parameters of the least squares support vector machines for short-term load forecasting. The experimental results show that the proposed method has higher prediction accuracy and is feasible and effective.

Keywords: short-term load forecast; dynamic bi-group; global search; local search; support vector machine

0 引言

在 21 世纪的今天, 能源紧张和能源浪费的问题日益凸显, 开发新能源和高效利用现有能源必将成为未来的主题。短期负荷预测是节省能源的有效途径。负荷预测的精度越高电力系统运行就越可靠、供电质量越好, 能源利用率也就越高^[1-3]。面向非线性数据预测的方法与技术是当今负荷预测研究的热点, 近几年来一种新的学习机—支持向量机 (support vector machine, SVM) 模型得到了广泛的关注, 从已有的研究文献来看, 支持向量机能够比较好地解决小样本, 非线性, 和高纬度等问题, 其泛化能力要好于神经网络模型和模糊模型。文献 [4] 将回归支持向量机方法用于电力系统短期负荷预测, 文献 [5] 通过构造 (least squares support vector machines, LS-SVM) 模型, 将二次优化问题转化成为求解线性等式集的形式, 降低了计算的复杂性。因为支持向量机参数较多, 不等式约束具有

不确定因素, 所以本文也选取 LS-SVM 模型, 但是直到目前其参数确定还是多取决于经验, 因此找出有效方法确定其参数有待进一步研究。

本文针对 LS-SVM 存在的问题, 利用粒子群算法迭代搜索最优目标函数值的方法, 找到最优参数取值。鉴于粒子群自身具有鲁棒性强, 计算效率高, 易于实现的优点, 被应用于寻找 LS-SVM 的最优参数值, 考虑文献 [6] PSO 寻优过程中容易早熟收敛及陷入局部最优产生无效解的问题, 本文提出一种动态双组粒子群算法 (DBPSO), 将所有粒子分为两组, 每组使用不同的权重分别进行全局搜索和局部搜索, 搜索过程中适应度小的粒子进入局部搜索种群中, 两组种群数量实现动态变化, 全局搜索与局部搜索同步进行; 考虑到当种群收敛于若干个分散的局部极小点时, 对应的适应值相差并不大, 适应度方差很小, 种群的平均粒距却很大, 因此同时采用以上两个指标衡量种群的多样性。通过该算法能得到较优的支持向量机电量预测模型。实验结果表明基于改进后的粒子群与支持向量机的用电量预测具有很高的预测精度^[7-10]。

1 最小二乘支持向量机模型

假设有训练样本集 $\{(x_1, y_1) \cdots (x_l, y_l)\}$, 其中 x_i 是输入向量, y_i 是输出, l 是样本个数。LS-SVM 回归理论的基本思想是寻找一个输入空间到输出空间的非线性映射 φ , 通过这个非线性映射, 将数据 x 映射到一个高维特征空间, 并

收稿日期: 2017-09-15; 修回日期: 2017-10-11。

基金项目: 国家基金项目 (51567019); 江西省教育厅项目 (JJ150757)。

作者简介: 王雪微 (1991-), 女, 硕士研究生, 主要从事微电网和电力系统负荷预测方向的研究。

程若发 (1969-), 男, 博士, 副教授, 硕士生导师, 主要从事微电网和电力电子方向的研究。

在特征空间中用下列估计函数进行线性回归：

$$f(x) = (\omega, \varphi(x)) + b \tag{1}$$

根据统计理论，LS-SVM 通过对以下目标数极小化确定回归函数：

$$J = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^l e_i^2 \tag{2}$$

$$s. t. \omega^T \varphi(x_i) + b + e_i = y_i$$

$$i = 1, \dots, l \tag{3}$$

式中， e_i 是误差， γ 为正则化参数，作为惩罚因子，控制对误差的惩罚程度，引入 Lagrange 乘子 λ ，上式转化为：

$$\min J = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \lambda_i (\omega^T \varphi(x_i) + b + e_i - y_i) \tag{4}$$

根据 KKT 条件：

$$\begin{cases} \frac{\partial J}{\partial \omega} = 0 \rightarrow \sum_{i=1}^l \lambda_i \varphi(x_i) \\ \frac{\partial J}{\partial b} = 0 \rightarrow \sum_{i=1}^l \lambda_i = 0 \\ \frac{\partial J}{\partial e_i} = 0 \rightarrow \lambda_i = \gamma e_i, i = 1, 2, \dots, l \\ \frac{\partial J}{\partial \lambda_i} = 0 \rightarrow \omega^T \varphi(x_i) + b + e_i - y_i = 0, i = 1, 2, \dots, l \end{cases} \tag{5}$$

消去 ω 和 e 后，最优问题转化为一个线性系统求解，可以通过求解线性方程求得 λ_i 和 b ，因此非线性预测模型的表达式为：

$$y = \sum_{i=1}^l \lambda_i K(x_i, x) + b \tag{6}$$

其中， $K(x_i, x)$ 表示从输入空间到高维特征空间的非线性映射，称为核函数。核函数取代高维特征空间中的点积运算，使计算得以简化，该核函数在使用过程中主要有线性核函数，多项式核函数，径向基 (radial basis function, RBF) 核函数，多层感知器 (multi-layer perception, MLP) 核函数，针对不同的情况选取不同的核函数，本文采用 RBF 核函数^[11-13]。

2 粒子群优化及其改进

2.1 PSO 算法

PSO 算法是一种基于群体的智能寻优算法，其基本思想源于对鸟类捕食行为的研究^[14-16]。PSO 初始化一群随机粒子 (随机解)，然后通过迭代寻找最优解。在每一次迭代中，粒子通过跟踪个体极值 pbest 和全局极值 gbest 来更新自己，个体极值 pbest 为粒子本身所找到的最优解；全局极值 gbest 是指整个种群目前找到的最优解。标准粒子群优化算法采用下列公式对粒子速度和位置进行更新：

$$v_{id} = \omega v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}) \tag{7}$$

$$x_{id} = x_{id} + v_{id} \tag{8}$$

其中： ω 为惯性权重系数， c_1 和 c_2 是两个非负常数，称为加速常数， r_1 和 r_2 是 $[0, 1]$ 之间的随机数。 p_{id} 为粒子本身最优位置， p_{gd} 是整个种群目前的最优位置。

2.2 动态双组粒子群

本文中针对 PSO 算法的早熟收敛问题，引用了一种以

PSO 算法为基础的，通过多样性度量指标控制种群特征的改进粒子群优化算法。PSO 算法易陷入早熟收敛这个问题一直困扰着广大学者，很多学者都在研究如何在确保 PSO 算法多样性的同时，而不会改变算法收敛速度及避免早熟收敛的问题。A. Siva 等 (2003) 提出了一种捕食—掠夺模型来保持种群的多样性以避免早熟收敛的目的^[17]。T. Hendtlass 等 (2003) 提出了一种生存密度模型来保持 PSO 算法中的多样性^[18]。W. J. Zhang 等在 PSO 算法中引入差分进化操作保持种群的多样性提高 PSO 的性能^[19]。余炳辉等通过对种群中的最差粒子重新进行初始化来保持种群的多样性以避免陷入局部最优解。

本节提出动态双组粒子群方法解决该问题。为了提高 PSO 的搜索能力，实现前期侧重全局搜索，后期集中于局部搜索的整体搜索方案，将初始粒子群按适应度大小分为两个大小不同的子群 S_1 和 S_2 ^[13-14]， S_1 使用全局搜索能力强的较大权重， S_2 则使用局部搜索能力强的较小权重。由于算法早期迭代强调前者的整体搜索能力，所以 S_1 的数量远大于 S_2 ；而后期强调后者的局部搜索能力，需要提高 S_2 的数量，所以随着迭代次数的增加动态改变两个子群的数量。每次迭代后， S_1 中适应度小的粒子进入 S_2 进行局部搜索，通过 S_1 和 S_2 子群的重组，实现信息的交换与合并，经过多次迭代，可以找到很好的解。为避免粒子早熟收敛为平均粒距和适应度方差设定阈值，每次迭代后判断是否粒子距离大于阈值，适应度方差小于阈值，若是重新分配其在解空间的位置。粒子群最初分组按照下式进行：

$$N = \frac{1}{10} S \tag{9}$$

$$S_2 = N \tag{10}$$

$$S_1 = S - S_2 \tag{11}$$

式中， S 是粒子总数。

DBPSO 算法基本步骤与流程如下：

1) 初始化各类参数，包括种群规模 S ，惯性权重 ω_1, ω_2 学习因子 c_1, c_2 ，多样性阈值 $[d_{low}, d_{high}]$ ，最大迭代次数 T_{max} ，速度范围 $[v_{min}, v_{max}]$ ，位置范围，随机的初始位置和速度等；

2) 设置开始迭代次数 $t=0$ ，对所有粒子进行迭代更新，并对初始粒子的适应值排序，按适应度大小 9: 1 的比例分为 S_1 和 S_2 ，同时设置局部搜索 S_2 的上限，超出上限则重新分组；

3) S_1 组在权重 ω_1 作用下进行全局大规模搜索迭代， S_2 在权重 ω_2 作用下进行局部精确搜索；

4) 每次迭代后， S_1 中适应度小于 S_2 的粒子进入 S_2 ，没有符合条件的就继续迭代，并记录各粒子的最优位置 pbest，和全局最优位置 gbest；判断平均粒距是否大于阈值，适应度方差是否小于阈值，当这两个条件同时满足时返回 2)；

5) 如果当前的迭代次数达到了预先设定的最大次数，则停止迭代，输出最优解，否则 $t=t+1$ ，转到步骤 3)；

3 短期负荷预测模型

建模首要工作需要构造输入向量，选取对短期负荷有影响的各类因素，并对这些样本数据进行预处理。因为短期负荷与

季节、日期类型、天气等因素密切相关, 所以, 本文在建立预测模型时, 充分考虑了日类型、温度, 湿度对短期负荷的影响。为降低问题求解规模, 一天中每隔一小时取一个预测点分别建立预测模型。选用预测点前一个月的负荷及其相关数据形成训练样本。本文训练样本中的输入数据包括温度, 湿度, 24 小时的负荷值和星期类型, 输出为用电量。由于特性指标的量纲和数量级不尽相同, 为了消除特性指标单位的差别和特性指标数量级不同的影响, 对负荷数据采取对数处理方式, 其它变量全部进行归一化, 线性转化为 [0-1] 之间的值, 最后在进行反归一化。

由前面分析的 LS-SVM 基本算法可知, 选取合适的核函数对支持向量机的预测结果有很大影响, 基于径向基函数有如下优点: ①表示形式简单, 即使对于多变量输入也不增加太多的复杂性; ②径向对称, 光滑性好, 任意阶导数均存在; ③由于该函数表示简单且解析性好, 因而便于进行理论分析本文采用径向基函数作为回归模型中的核函数:

$$K(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (12)$$

x 是输入向量, x_i 是第 i 个径向基函数的中心, 与 x 具有相同维数, σ 是标准化参数, 数, 决定了该函数围绕中心点的宽度, $\|x - x_i\|$ 是向量 $x - x_i$ 的范数, 表示 x 与 x_i 之间的距离。

对于 LS-SVM 来说, 核函数中的参数 σ 和惩罚因子 C 对模型精确度有重要影响。这些参数通过 DBPSO 算法训练得到, 作为 LS-SVM 模型的输入数据, 然后进行负荷预测; 最后输出模型预测结果。基于 DBPSO 算法的 LS-SVM 预测流程如图 1 所示。

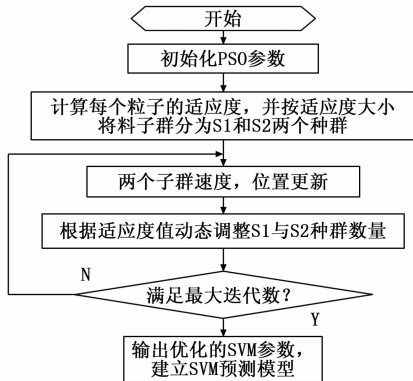


图 1 基于 PSO 的 LS-SVM 算法流程图

4 实例分析

以下结合实际数据讨论在上述方法下建立的支持向量机预测模型的预测效果, 本文选取浙江台州 2010 年 2 月~3 月的用电量数据, 以及对负荷影响较大的相关气象因素, 星期类型等, 作为本文的实验数据。部分数据如表 1 所示。

为了消除量纲不同的影响, 对用电量数据和各影响因素进行归一化处理, 构建训练样本, 建立 DBPSO-SVM 用电量预测模型, 并与 PSO-SVM 模型的预测结果进行对比。仿真环境为 MATLAB2010b, 对于 DBPSO 算法的各个参数为: 粒子数 m 取 30, 最大迭代次数取 50, 全局搜索惯性权重系数 ω 取值范围为 0.9, 局部搜索惯性权重系数取 0.4; 加速常数和均

取 2。平均粒距阈值取 1。

表 1 浙江台州 2010 年 2 月~3 月的用电量数据

日期	最高温度/°C	最低温度/°C	平均温度/°C	相对湿度	星期类型	每日 0 时负荷 kW/h
2010-02-13	26.2	16.7	20.8	0.7	0.8	157.3
2010-02-14	21.2	10.9	12.5	0.8	0.4	161.9
2010-02-15	13.5	10.8	11.5	0.77	0.3	163.7
2010-02-16	11.2	6.4	8.6	0.79	0.7	172.8
2010-02-17	8.4	6.1	7.1	0.84	0.8	178.6
2010-02-18	8.6	6.9	7.8	0.93	0.8	181.4
2010-02-19	15.7	8.4	11.4	0.91	0.8	175.1
2010-02-20	14.2	8	10.6	0.58	0.8	177.3
2010-02-21	14.2	4.9	9.6	0.72	0.4	179.8
2010-02-22	22.8	10.7	15.3	0.77	0.3	146

适应度方差阈值取 0.001。将本文方法与遗传算法, 神经网络算法进行对比, 采用 EUNITE 竞赛的评判标准对预测结果进行分析, 主要是: 平均绝对误差 (MAPE) 和最大误差 (ME)。3 种模型负荷预测曲线都能达到不错的效果, 但预测精度存在差异:




图 2 适应度对比图




图 3 绝对值对比图

表 2 不同模型的误差对比

方法	MAPE/%	ME/MW
DBPSO-LSSVM	1.09	8.4359
GA-LSSVM	1.17	11.4759
BP-LSSVM	1.56	13.6565

由图 2 可知改进后的粒子群 (DBPSO) 兼顾全局与局部搜索二者之间的平衡, 在动态搜索的过程中逐步搜索到全局最优, 比遗传算法和神经网络算法的预测结果更加精确, 误差更小。由图 3 可以看出改进后的粒子群收敛更快, 效果更好; 图 4 中 DBPSO 模型的绝对误差虽然并不是每个时刻的负荷都比 GA 算法精确但是整体趋势明显更好, 说明本文算法可行。由

表 2 可以看出本文方法预测结果平均绝对误差为 1.09%，最大误差为 8.4 359 MW，预测精度比另外两种模型更优，并且本文算法的泛化能力较好，也可以应用到其他的领域。

5 实验结果与分析

本文提出基于动态双组粒子群优化支持向量机参数的短期负荷预测新方法，改进后的粒子群在不同权重的引导下对全局和局部都进行了很好的搜索，提高了计算精度及全局寻优能力。通过实例验证，本文提出的改进算法性能优于遗传算法与神经网络，用于支持向量机负荷预测模型的精度更高，稳定性也比较好。且本文所提出的混合算法泛化能力强，相信不仅能在电力系统中应用，其他领域同样适用^[20]。

参考文献:

- [1] 吴景龙, 杨淑霞, 刘承水, 等. 基于遗传算法优化参数的支持向量机短期负荷预测方法 [J]. 中南大学学报, 2009, 40 (1): 180-184.
- [2] 洪杨欢, 基于智能计算的变权重组合优化短期负荷预测研究 [D]. 广州: 广东工业大学, 2013.
- [3] 王惠中, 周 佳, 刘 珂. 电力系统短期负荷预测方法研究综述 [J]. 电气自动化, 2015, 37 (1): 1-4.
- [4] 梁妮晓. 基于改进果蝇算法优化支持向量机的短期负荷预测 [D]. 广西大学, 2014.
- [5] Lopez M, Valero S, Senabre C, et al. Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study [J]. Electric Power Systems Research, 2012, 91: 18-27.
- [6] 谢 宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化 [J]. 中国电机工程学报, 2006, 26 (25): 17-22.
- [7] 龙金莲, 张玉分, 卢家暄. 基于改进粒子群优化 LSSVM 的短期电力负荷预测 [J]. 机电信息, 2016, 36: 25-27.
- [8] 王海斌, 刘维亭, 徐 卉. 基于迭代局部搜索和自适应粒子群优化的 SVM 短期负荷预测 [J]. 船舶工程, 2013, 35 (1): 57-60.

(上接第 129 页)

该函数。需要注意的是，由于我们这次省去了文件更新替换的过程。

4 结束语

本文从当前常规在轨航天器软件重构角度出发，分析传统星载软件重构方式，并从模块加载的角度验证了一种新型在轨航天器软件重构方案，还从实例的角度验证了这一方案可行性和可操作性。

基于该架构的星载软件会使航天器的软件在轨更新变得更加可靠、简便、安全，也能极大程度地减小对系统的影响，减小了系统在轨维护难度，对于其他嵌入式系统的软件在线更新也有一定的借鉴意义。

参考文献:

- [1] 刘 贇, 左小川. 嵌入式软件在线升级系统的设计与实现 [J]. 计算机测量与控制, 2015, 23 (04): 1425-1427.
- [2] 王 鹏, 张友根, 李永刚. 一种改进的 VxWorks 模块卸载方法研究 [J]. 装备指挥技术学院学报, 2010, 21 (5): 83-87.

- [9] 孙 薇, 刘默涵. 基于改进最小二乘支持向量机的短期负荷预测 [J]. 电力科学与工程, 2015, 35 (12): 17-33.
- [10] 王 岗, 姜 杰, 唐昆明, 等. 基于自适应双向加权最小二乘支持向量机的超短期负荷预测 [J]. 电力系统保护与控制, 2010, 38 (19): 142-146.
- [11] 李 洪, 江刘栋. 基于交叉验证支持向量机的短期负荷预测 [J]. 云南电力技术, 2016, 44 (3): 1-3, 13.
- [12] 孟凡喜, 屈 鸿, 侯孟书. 基于 GA 和 SVM 的电力负荷预测方法研究 [J]. 计算机科学, 2014, 41 (6A): 91-93.
- [13] 谢 宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化方法 [J]. 中国电机工程学报, 2006, 26 (22): 17-22.
- [14] 张少迪. 基于 PSO-BP 神经网络的短期负荷预测算法 [J]. 现代电子技术, 2013, 12: 155-158, 162.
- [15] 张 红, 金 月, 郭彦春. 改进 RBF 神经网络在短期负荷预测中的应用 [J]. 科技资讯, 2014, 29: 89.
- [16] 孙 林, 杨世元, 吴德会. 基于隶属度模糊最小二乘支持向量机的工序能力预测 [J]. 中国机械工程, 2008, 19 (13): 1561-1564.
- [17] Li X B, Zhang J, Zhang G Y, et al. Short-term load forecasting for similar days based on support vector machine and dempster-shafer theory [J]. Power System Technology, 2010, 34 (7): 143-147.
- [18] Demirel O, Kakilli A, Tektas M. Electric energy load forecasting using ANFIS and arma methods [J]. Journal of the Faculty of Engineering and Architecture of Gazi University, 2010, 25 (3): 601-610.
- [19] Chen D G, York M. Neural network based very short term load prediction [A]. transmission and distribution conference and exposition [C]. Latin (America), 2008: 1-9.
- [20] Platt J. Fast training of support vector machines using sequential minimum optimization [A]. Advance in Kernel Methods—support Vector Learning [C]. Cambridge: 1999: 185-208.

- [3] 朱海江. 星载软件模块化设计方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2007.
- [4] 石 炜, 邓 伟. 基于 VxWorks 的星载控制计算机动态可重构研究 [J]. 电子设计工程, 2013, 21 (6): 30-33.
- [5] 廖崇琦, 文 臣, 邓 文, 等. 一种基于 VxWorks 的可重构软件框架设计 [J]. 电子技术应用, 2013, 39 (12): 22-24.
- [6] 于 康, 宁 洪, 邓胜兰, 等. 基于 VxWorks 的模块自动加载机制 [J]. 计算机工程, 2010, 36 (18): 264-266.
- [7] 宁 涛. 面向嵌入式应用的动态加载机制研究 [D]. 重庆: 重庆大学, 2008.
- [8] 于 康. 基于动态加载机制的星载计算机可靠性增强技术研究 [D]. 长沙: 国防科学技术大学, 2009.
- [9] Wind River, Kernel Programmer's Guide: Local File Systems [Z]. Wind River, 2009.
- [10] Wind River, Vxworks Application Programmers Guide [Z]. Wind River, 2009.
- [11] 王晋东, 黄 海, 王 坤, 等. 基于 VxWorks 的 dosFs 文件系统分析与实现 [J]. 微计算机信息, 2008: 85-87.
- [12] 龙芯中科技术有限公司, 龙芯 1E1F 开发手册 [R]. 北京: 龙芯中科技术有限公司, 2017.