

DOI: 10.7667/PSPC160981

基于小波变异果蝇优化支持向量机短期负荷预测方法研究

熊军华, 牛珂, 张春歌, 李铎, 谢飞

(华北水利水电大学电力学院, 河南 郑州 450045)

摘要: 预测精度是电力负荷预测的重要指标。为增强预测精度, 提出基于小波变异果蝇优化的支持向量机预测模型(WFOAAM-LSSVM)。利用小波对负荷数据进行预处理, 分解成不同尺度的负荷曲线, 加强历史数据规律性和随机性。针对果蝇算法寻优精度不高和易陷入局部最优的不足, 利用群体适应度方差和当前最优解判断是否陷入局部最优, 再进行最优个体扰动和高斯变异操作, 对变异后的果蝇个体二次寻优, 使支持向量机预测模型精度得到明显增强。利用 WFOAAM-LSSVM 对 2015 年河南省某地区历史负荷数据对未来几日预测, 并与支持向量机模型以及粒子群优化的支持向量机模型预测结果对比。结果表明: 基于小波变异果蝇优化的支持向量机短期负荷预测精度高, 具有很好的实际应用意义。

关键词: 支持向量机; 粒子群算法; 变异果蝇算法; 小波分析; 短期负荷预测

LSSVM in short-term load forecasting based on wavelet transform and mutant fruit fly optimization algorithm

XIONG Junhua, NIU Ke, ZHANG Chungge, LI Duo, XIE Fei

(College of Electric Power, North China University of Water Resources and Electric Power, Zhengzhou 450045, China)

Abstract: Prediction accuracy is an important index of power load forecasting. In order to enhance the accuracy of prediction, this paper presents support vector machine prediction model based on wavelet transform and the mutant fruit fly parameter optimization algorithm (WFOAAM-LSSVM). The load data are pretreated by wavelet transform, and the load curves are decomposed into different scales, in order to strengthen the regularity and randomness of historical data. In order to overcome the problems of low convergence precision and easily relapsing into local extremum in basic fruit fly optimization algorithm (FOA), and on the condition of basic FOA's trapping in local extremum judging from the population's fitness variance and the current optimal, it carries out optimal individual disturbance and Gauss mutation operation and optimizes mutated replicates again to jump out of local extremism and continue to optimize. The accuracy of prediction model is obviously enhanced. The next few days of historical load data of a certain area of Henan Province in 2015 is predicted by using WFOAAM-LSSVM, and the prediction results of support vector machine model and the particle swarm optimization model of support vector machine model are compared. The results show that WFOAAM-LSSVM has high precision in short term load forecasting, and it has a very good practical significance.

Key words: support vector machine; particle swarm optimization algorithm; mutant fruit fly algorithm; wavelet analysis; short term load forecasting

0 引言

在北京召开的“2016年经济形势与电力发展分析预测会”提出电力行业不断迈上新台阶, 支撑经济社会发展能力显著增加, 但是地区性产能结构过剩问题逐渐显现。大数据时代^[1]的到来给电力系统预测带来新的方向, 通过各种能源和电力的联系,

对电力负荷进行预测已受到重视, 根据短期负荷预测高效控制电力系统中各机组的启停, 中长期负荷预测来进行区域规划, 是城市规划以及电网发展规划的依据。预测是一种概率问题, 在历史数据的基础上, 构建数学模型来外推。预测的准确性受数据质量以及所用何种预测方法搭建数学模型的影响。由于负荷需求受到多方面的影响, 如天气、假期、地区、季节、温度等非线性因素。建立数据模型完成负荷精确预测受到很大的挑战^[2]。应选择一种适应能力强的预测方法, 可以将多种因素综合考量,

基金项目: 国家电网公司 2016 年科技项目“输变电重大工程社会效益评价体系”

提高预测的准确性。其中文献[3]利用相似日法来搭建模型进行预测,文献[4]采用灰色系统进行模型预测,文献[5]利用支持向量机对短期气候进行预测,误差较小。近年来,由于支持向量机具有鲁棒性较好以及能有效避免维数灾难等优点,逐渐受到学者的重视,并提出了一系列提高支持向量机预测精度的理论。改进 SVM 模型有 LSSVM、VSVM 等。并加入智能算法、优化参数。文献[6-9]利用粒子群算法改进了支持向量机;文献[10-13]利用优选组合的预测方法。由于智能算法的加入,从而提高了 SVM 的预测精度。

上述方法由于算法的复杂性,影响建模速度,最终的 SVM 参数在迭代选择时难以取到全局最优。为了解决这些问题,提出基于小波变异果蝇优化的支持向量机预测模型(WFOAAM-LSSVM),利用小波^[14]对负荷数据进行预处理^[15],分解成不同尺度的负荷曲线,加强历史数据的规律性和随机性。针对果蝇算法寻优精度和易陷入局部最优的不足,利用群体适应度方差和当前最优解判断是否陷入局部最优,再进行最优个体扰动和高斯变异操作,对变异后的果蝇个体二次寻优,使支持向量机预测模型精度得到明显增强。以河南省某地区的历史数据仿真来验证,最终得到满意的结果。

1 离散小波负荷分解

电力系统中的负荷数据主要是离散数据,所以将信号 $x(t)$ 的连续小波变化定义为

$$WTx(a,t) = \frac{1}{a} \int x(\tau) \left(\frac{t-\tau}{a} \right) d\tau \quad (1)$$

式中, a 是尺度因子。

小波 ϕ 要求满足的条件为

$$\int_0^{\infty} \frac{|\hat{\phi}(w)|^2}{w} dw = \int_{-\infty}^0 \frac{|\hat{\phi}(w)|^2}{w} dw = C_{\phi} < +\infty \quad (2)$$

将信号还原,公式为

$$f(x) = \frac{1}{C_{\psi}} \int_0^{\infty} \int_{-\infty}^{\infty} WTx(a,t) \overline{\phi_a}(\tau-t) \frac{dad\tau}{a} \quad (3)$$

式中, $\overline{\phi_a}$ 为复共轭。

小波函数 $\psi(t)$ 经整数缩放和整点平移得到时间-频率函数族,构成离散小波。设 $f(t) \in L^2(R)$ 是采集的信号,标准正交基为 $\phi_{0,n} = \{\phi(t-n)\}$ 和 $\psi_{0,n} = \{\psi(t-n)\}$, 其中 $n \in Z$ 。

根据小波级数展开:

$$\begin{cases} f(t) \approx f_N(t) = f_J + \sum_{j=J}^{N-1} W_j \\ f_j \in V_j \subset V_N, w_j \in W_j, 0 \leq J \leq N-1 \end{cases} \quad (4)$$

从电力负荷历史数据可以发现有两点主要规律:第一,电力负荷处于缓慢增长的趋势;第二,电力负荷呈现出天、周、月、年的周期波动。除此之外还有一些非周期和随机波动,如天气、节假日等。利用小波将负荷分量投影到不同尺度,能加强历史数据变化的周期性。对采集的数据进行多尺度分解,得到高频和低频信号。其中低频信号包含了信号主体,主要是一些周期分量,高频信号主要是部分周期信号以及扰动和随机分量。可根据具体情况确定合适的分解层数。

2 最小二乘支持向量机

支持向量机(SVM)^[16-17]通过非线性映射,将样本空间映射到高维特征空间,原线性不可分问题转变成特征空间中的线性可分。由于升维度会增加计算难度甚至造成“维数灾难”,但 SVM 巧妙引入核函数来避免这种情况。映射显性表达式复杂难求,通过核函数展开定理,可以避免;为了尽量解决“维数灾难”问题,降低计算难度,在高维特征空间中建立线性学习机。

LSSVM 是在原有的 SVM 模型上改进。通过将 SVM 中的不等价约束条件转化成等价条件。

对非线性负荷预测模型

$$f(x) = (w, \phi(x)) + b \quad (5)$$

采集数据 $(x_i, y_i), i=1, 2, \dots, N, x_i \in R^d$ 是负荷预测紧密相连的影响因素, d 为输入变量维数, $y_i \in R$ 为预测的期望值, N 为已知采集到的数据点个数, $\phi(x)$ 是从输入样本到高维特征空间非线性映射, w 为权向量, b 为偏置量。

根据 SVM 的风险结构最小化原则, LSSVM 的优化目标为

$$\min \frac{1}{2} \|w\|^2 + \frac{r}{2} \sum_{i=1}^N \xi_i^2 \quad (6)$$

约束条件: $w^T \phi(x_i) + b + \xi = y_i, i=1, 2, \dots, N$ 。

式中: ξ 为误差向量; r 为惩罚参数,用来控制误差的惩罚程度。

将目标函数与拉格朗日函数约束条件相结合,得:

$$L(w, B, \xi, \alpha) = J(w, \xi) - \sum_{i=1}^N \alpha_i [w^T \phi(x_i) + b + \xi - y_i] \quad (7)$$

式中, α_i 为拉格朗日乘子。

由 KKT 条件可得线性方程组

$$\begin{bmatrix} 0 & q^T \\ q & pp^T + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ I \end{bmatrix} \quad (8)$$

式中: $\mathbf{P} = [\varphi(x_1)^T y_1, \varphi(x_2)^T y_2, \dots, \varphi(x_l)^T y_l]$; $\mathbf{I} = [1, 1, \dots, 1]^T$; $\mathbf{q} = [y_1, y_2, \dots, y_l]^T$; $\mathbf{a} = [a_1, a_2, \dots, a_l]^T$; \mathbf{I} 为单位矩阵。

根据 Mercer 条件, 核函数可以写成为

$$k(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (9)$$

因此可将非线性预测模型变换为

$$y = \sum_{i=1}^N \lambda_i k(x_i, x_j) + b \quad (10)$$

在进行负荷预测时, 径向基函数(RBF)为核函数:

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (11)$$

式中, $\sigma > 0$ 为核函数参数。

支持向量机的结构图如图 1 所示。

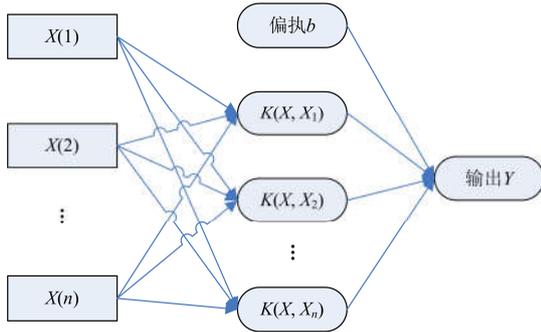


图 1 支持向量机模型

Fig. 1 Support vector machine model

3 变异果蝇优化算法(FOAAM)基本原理

果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)是台湾经济学教授潘文超博士在 2011 年提出, 从动物界受到启发而发明的优化算法。基于果蝇觅食行为的一种寻求全局优化的新方法。

针对果蝇算法的参数选取困难、易陷入局部最优的缺陷, 进行改进。具体优化步骤如下。

第一步: 确定种群规模 Sizepop, 最大迭代次数 Maxgen, 随机初始化果蝇群体位置 X_axis , Y_axis , 适应度(味道浓度)方差阈值 δ , 最优果蝇个体复制数 M , 变异概率 P 。

第二步: 在个体果蝇通过嗅觉寻觅食物过程中, 赋予随机方向和距离。

$$\begin{cases} X_i = X_axis + L_r \\ Y_i = Y_axis + L_r \end{cases}$$

式中, $L_r \in [-L, L]$ 为单个果蝇搜索步长。

第三步: 计算味道浓度。食物的详细位置未知, 先求与原点的距离 $Dist_i$, 然后求味道浓度判定值 s_i 。

$$\begin{cases} d_i = \sqrt{X_i^2 + Y_i^2} \\ s_i = \frac{1}{Dist_i} \end{cases}$$

第四步: 将计算出的味道浓度代入味道浓度判定函数, 以求得果蝇个体位置的味道浓度。

$$Smell_i = \text{function}(S_i)$$

第五步: 比较群体中味道浓度并存储浓度最大个体的坐标, 蝇群通过视觉飞往该地。寻优完成一次。

$$[\text{bestSmell bestindex}] = \min(Smell_i)$$

第六步: 记录并保留最佳浓度 bestSmell 与最优果蝇个体位置 X_axisb , Y_axisb 。

$$\begin{cases} Smell_{\text{best}} = \text{bestSmell} \\ X_axisb = X(\text{bestindex}) \\ Y_axisb = Y(\text{bestindex}) \end{cases}$$

第七步: 计算群体的平均味道浓度 $Smell_{\text{avg}}$ 以及适应度方差 σ^2 。

$$\begin{cases} Smell = \sum_{i=1}^{\text{Sizepop}} Smell_i / \text{Sizepop} \\ \sigma^2 = \sum_{i=1}^{\text{Sizepop}} (Smell_i - Smell_{\text{avg}})^2 \end{cases}$$

第八步: 如果 $\sigma^2 \leq \delta$ 且 $Smell_{\text{best}} >$ 理论最优解或目标精度且分布于 $[0, 1]$ 之间随机数小于 P 。需要克隆 M 个最优果蝇位置 X_axisb_j , Y_axisb_j ($j = 1, 2, \dots, M$); 再对克隆的果蝇进行高斯变异, 更新位置。

克隆

$$\begin{cases} X_axisb_j = X_axisb \quad j = 1, 2, \dots, M \\ Y_axisb_j = Y_axisb \quad j = 1, 2, \dots, M \end{cases}$$

高斯变异

$$\begin{cases} X_axisb'_j = X_axisb_j \times (1 + 0.5 \times \text{normrnd}(0, 1, [1, \text{dim}]))) \\ Y_axisb'_j = Y_axisb_j \times (1 + 0.5 \times \text{normrnd}(0, 1, [1, \text{dim}]))) \\ j = 1, 2, \dots, M \end{cases}$$

第九步: 计算新位置的味道浓度判定值 S'_j , $j = 1, 2, \dots, M$ 。

$$\begin{cases} Dist'_j = \sqrt{X_axisb_j'^2 + Y_axisb_j'^2} \\ S'_j = \frac{1}{Dist'_j} \end{cases}$$

第十步：由计算得到的判定值 S'_j 代入味道浓度判定函数，计算味道浓度 $Smell'_j$ ， $j=1,2,\dots,M$ 。

$$Smell'_j = \text{function}(S'_j)$$

第十一步：判断是否本次最优的味道浓度。若 $Smell'_j < Smell_{best}$ 则 $Smell_{best} = Smell'_j$ ， $X_axis = X_axisb'_j$ ， $Y_axis = Y_axisb'_j$ ($j=1,2,\dots,M$)。

第十二步：迭代寻优，重复执行第二步到第十一步。以等于最大迭代次数或达到目标精度为止。

4 小波变异果蝇优化的 LSSVM 模型建立

利用小波变化可以将负荷投影到不同尺度上。也就是将数据在不同尺度上分解，得到规律性被强化的几组数据。再将这些数据作为 LSSVM 的输入量。根据 LSSVM 的基本原理，LSSVM 的预测模型受到惩罚因子以及核函数参数的影响，即参数 γ, σ 。其中参数 γ 主要权衡最大间隔和分类误差；参数 σ 主要影响映射到高维特征空间的复杂程度。所以为了选择最佳的参数 γ, σ ，采用变异果蝇算法 FOAAM 与 LSSVM 相结合。参数优化流程如图 2 所示。

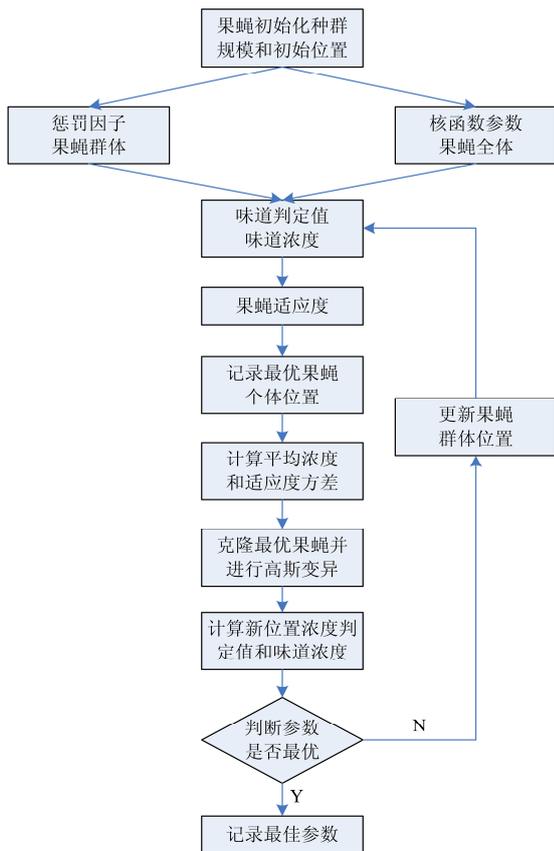


图 2 LSSVM 参数优化流程图

Fig. 2 Flow chart of LSSVM parameter optimization

该模型利用电网搜集到的负荷数据为依托，利用小波分解将负荷数据分解成细节分量以及趋势分量，即 D1, D2, D3 以及 A3。分别进行 LSSVM 的建模，以实时更新数据为参数优化提供训练集，搜索 D1, D2, D3 以及 A3 的 LSSVM 模型中最优的惩罚因子以及核函数参数，确保预测精度，最后采用叠加可得到未来一段时间的预测值。建模流程如图 3 所示。

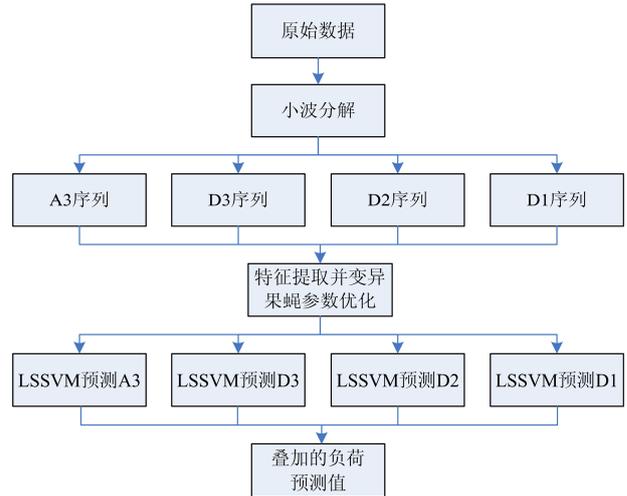


图 3 建模流程图

Fig. 3 Flow chart of modeling

5 实例分析

为了验证 WFOAAM-LSSVM 预测方法的普适性和预测精度。利用 2015 年河南省某地区负荷数据库为训练样本，采用不同预测模型对比预测，并将预测日类型分为工作日和节假日分别进行预测，将预测结果与预测日的实际负荷数据作对比，采用平均绝对值的误差计算方法和多样本预测，减少偶然误差的影响。

工作日预测结果如图 4 所示。

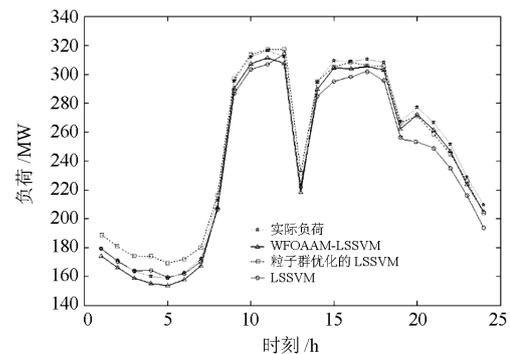


图 4 工作日负荷预测曲线和实际负荷曲线对比图

Fig. 4 Comparison of the working day load forecasting curve and the actual load curve

记录多样本数据结果, 如表 1。

表 1 工作日多个样本的预测结果

Table 1 Prediction results of working day multiple samples

时间/天	误差/% 以及参数(c, theta)		
	LSSVM	粒子群优化 LSSVM	WFOAAM-LSSVM
1	2.73	1.17	1.05
	(30, 2)	(0.1, 1.7863)	(0.1, 0.7102)
2	2.76	1.26	1.12
	(30, 2)	(15.8828, 0.3243)	(150, 0.1728)
3	3.18	1.69	1.49
	(30, 2)	(2.5933, 9.3116)	(2.6225, 8.5543)
4	3.08	1.43	1.12
	(30, 2)	(150, 0.5574)	(110.6786, 0.6184)
平均误差	2.9375	1.3875	1.1950

在工作日负荷预测中, WFOAAM-LSSVM 预测精度与传统的 LSSVM 相比提高约 1.8%, 和粒子群优化 LSSVM 相比精度提高约 0.2%。

节假日预测结果如图 5 所示。

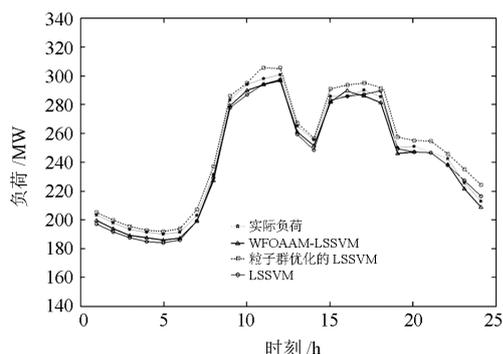


图 5 节假日负荷预测曲线和实际负荷曲线对比图

Fig. 5 Comparison of the holiday load forecasting curve and the real one

记录多样本数据结果, 如表 2。

表 2 节假日多个样本的预测结果

Table 2 Prediction results of holiday multiple samples

时间/天	误差/% 以及参数(c, theta)		
	LSSVM	粒子群优化 LSSVM	WFOAAM-LSSVM
1	2.74	3.98	1.25
	(30, 2)	(0.21, 1.8563)	(0.12, 0.8102)
2	2.92	3.23	1.32
	(30, 2)	(110.676, 0.6184)	(150, 0.5574)
3	3.22	3.11	1.51
	(30, 2)	(150, 0.1728)	(2.6225, 8.5543)
4	2.88	2.11	1.22
	(30, 2)	(150, 0.5574)	(106.6786, 0.6184)
平均误差	2.9400	3.1075	1.3250

在节假日负荷预测中, WFOAAM-LSSVM 预测精度比传统的 LSSVM 和粒子群优化 LSSVM 提高约 1.7%。甚至传统的 LSSVM 的平均预测精度都高于粒子群优化 LSSVM 约 0.15%。

这是由于节假日负荷随机量更多, 粒子群算法对于离散的优化问题处理不佳, 容易陷入局部最优, 使预测结果误差较大。WFOAAM-LSSVM 预测普适性更加优越, 工作日以及节假日预测都比较稳定, 且误差较小, 可以用于短期负荷预测。

对果蝇优化方法的改进使预测模型具有更强的寻优能力和搜索精度。果蝇个体寻优参数位置以及迭代代数如图 6、图 7 所示。

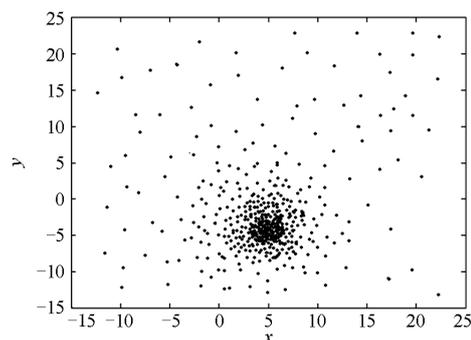


图 6 果蝇个体寻优参数位置

Fig. 6 Location of the optimal parameters of drosophila

从图 6 看出, 在 $[-25;20; -25;20]$ 直角坐标系范围内, 果蝇的搜索能力很强, 通过对食物味道的感知, 会趋向于种群中离食物最近的个体。

对于变异果蝇算法和粒子群算法收敛速度的比较, 主要通过群体中个体位置与最优解的距离。而适应值与最优解的距离直接有关。因此在预测模型进行预测时, 记录并绘制图 7 和图 8, 比较收敛速度。

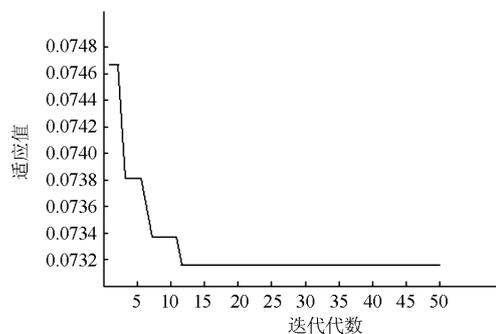


图 7 变异果蝇迭代代数

Fig. 7 Iterative algebra of mutant fruit flies

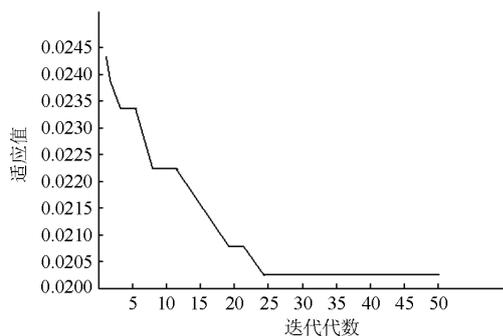


图 8 粒子群优化迭代代数

Fig. 8 Iterative algebra of particle swarm optimization

图 7 为变异果蝇的优化迭代代数,从图中看出,收敛速度较快,大概在 12 代就能达到理想精度。为了与粒子群优化对比,都采用相同大小的种群规模,实验结果如图 7 显示,粒子群优化大概需要迭代到 25 代左右,才能收敛达到所需精度。明显看出变异果蝇优化的迭代速度更快。

6 结语

通过小波分解加强周期性,通过变异果蝇优化原理挑选最佳的惩罚参数以及核函数参数,建立小波变异果蝇优化的 LSSVM 预测模型。克服了传统 SVM 在参数选择上的盲目性。并与传统支持向量机模型以及粒子群优化的支持向量机模型预测结果对比。基于小波变异果蝇优化的支持向量机预测模型在工作日以及节假日的短期预测中,预测精度都很高,并且收敛速度快,不宜陷入局部最优,具有很好的普适性。

参考文献

- [1] 林顺富, 郝朝, 汤晓栋, 等. 基于数据挖掘的楼宇短期负荷预测方法研究[J]. 电力系统保护与控制, 2016, 44(7): 83-89.
LIN Shunfu, HAO Chao, TANG Xiaodong, et al. Study of short-term load forecasting method based on data mining for buildings[J]. Power System Protection and Control, 2016, 44(7): 83-89.
- [2] 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. Impact analysis of hourly weather factors in short-term load forecasting and its processing strategy[J]. Power System Technology, 2006, 30(7): 5-10.
- [3] 黎灿兵, 李晓辉, 赵瑞, 等. 电力短期负荷预测相似日

选取算法[J]. 电力系统自动化, 2008, 32(9): 69-73.

- LI Canbing, LI Xiaohui, ZHAO Rui, et al. A similar day selection algorithm for short term load forecasting of electric power[J]. Automation of Electric Power Systems, 2008, 32(9): 69-73.
- [4] 刘思捷, 张海鹏, 林舜江, 等. 夏季日最大降温负荷的估算和预测方法[J]. 电力系统保护与控制, 2016, 44(5): 75-81.
LIU Sijie, ZHANG Haipeng, LIN Shunjiang, et al. An estimating and forecasting method for daily maximum cooling load in summer[J]. Power System Protection and Control, 2016, 44(5): 75-81.
- [5] 李智才, 马文瑞, 李素敏, 等. 支持向量机在短期气候预测中的应用[J]. 气象, 2006, 32(5): 57-61.
LI Zhicai, MA Wenrui, LI Sumin, et al. Application of support vector machine to short-term climate forecast[J]. Meteorological Monthly, 2006, 32(5): 57-61.
- [6] 陆宁, 武本令, 刘颖. 基于自适应粒子群优化的 SVM 模型在负荷预测中的应用[J]. 电力系统保护与控制, 2011, 39(15): 43-46, 51.
LU Ning, WU Benling, LIU Ying. Application of support vector machine model in load forecasting based on adaptive particle swarm optimization[J]. Power System Protection and Control, 2011, 39(15): 43-46, 51.
- [7] 金翠云, 崔瑶, 王颖. 粒子群优化的 SVM 算法在气体分析中的应用[J]. 电子测量与仪器学报, 2012, 26(7): 635-639.
JIN Cuiyun, CUI Yao, WANG Ying. Application of SVM algorithm for particle swarm optimization in quantitative analysis of gas[J]. Journal of Electronic Measurement and Instrument, 2012, 26(7): 635-639.
- [8] 孙斌, 姚海涛. 基于 PSO 优化 LSSVM 的短期风速预测[J]. 电力系统保护与控制, 2012, 40(5): 85-89.
SUN Bin, YAO Haitao. The short-term wind speed forecast analysis based on the PSO-LSSVM predict model[J]. Power System Protection and Control, 2012, 40(5): 85-89.
- [9] 何轩, 王永庆, 温步瀛, 等. 基于粒子群算法优化支持向量机的专用工程费用量化研究[J]. 电网与清洁能源, 2015, 31(12): 27-30.
HE Xuan, WANG Yongqing, WEN Buying, et al. Quantization research on special power transmission project cost based on particle swarm optimization and support vector machine[J]. Power System and Clean Energy, 2015, 31(12): 27-30.

- [10] RAZA M Q, BAHARUDIN Z. A review on short term load forecasting using hybrid neural network techniques[C] // IEEE International Conference on Power and Energy: IEEE, 2013: 846-851.
- [11] FAN S, HYNDMAN R J. Forecast short-term electricity demand using semi-parametric additive model[C] // Universities Power Engineering Conference: IEEE, 2010: 1-6.
- [12] KOO B G, KIM M S, KIM K H, et al. Short-term electric load forecasting using data mining technique[C] // International Conference on Intelligent Systems and Control: IEEE, 2013: 153-157.
- [13] 陈毅波, 郑玲, 姚建刚. 基于粗糙集理论与D-S证据理论改进的多元回归负荷预测方法研究[J]. 电力系统保护与控制, 2016, 44(6): 62-67.
CHEN Yibo, ZHENG Ling, YAO Jiangang. Improved multiple regression load forecasting method based on rough set theory[J]. Power System Protection and Control, 2016, 44(6): 62-67.
- [14] 鲁军, 李侠, 王重马, 等. 基于小波分析的MSMA振动传感器信号处理与故障检测[J]. 电工技术学报, 2015, 30(10): 354-360.
LU Jun, LI Xia, WANG Chongma, et al. Signal Process and fault detection of MSMA vibration sensor based on wavelet analysis[J]. Transactions of China Electrotechnical Society, 2015, 30(10): 354-360.
- [15] 郭凤仪, 李坤, 陈昌晔, 等. 基于小波近似熵的串联电弧故障识别方法[J]. 电工技术学报, 2016, 31(24): 164-172.
- GUO Fengyi, LI Kun, CHEN Changken, et al. Series arc fault identification method based on wavelet approximate entropy[J]. Transactions of China Electrotechnical Society, 2016, 31(24): 164-172.
- [16] 王东, 史晓霞, 尹交英. 不同核函数的支持向量机用于空调负荷预测的对比研究[J]. 电工技术学报, 2015, 30(增刊 1): 531-535.
WANG Dong, SHI Xiaoxia, YIN Jiaoying. Prediction on hourly load of air conditioning by RBF support vector machine[J]. Transactions of China Electrotechnical Society, 2015, 30(S1): 531-535.
- [17] 张琳, 马宏忠, 王涛云, 等. 基于振动-SVM的变压器绕组缺陷诊断方法[J]. 陕西电力, 2016, 44(11): 14-18.
ZHANG Lin, MA Hongzhong, WANG Taoyun, et al. Defect diagnosis for transformer winding based on vibration-SVM[J]. Shaanxi Electric Power, 2016, 44(11): 14-18.

收稿日期: 2016-06-30; 修回日期: 2016-09-26

作者简介:

熊军华(1973—), 女, 博士, 副教授, 主要从事电气自动化、电力电子、机械设计及理论方面的研究; E-mail: xjh2004@ncwu.edu.cn

牛珂(1991—), 男, 硕士研究生, 研究方向为电力系统安全运行与运行规划。E-mail: nkniuke@126.com

(编辑 魏小丽)