

改进粒子群算法和最小二乘支持向量机的电力负荷预测

针对最小二乘支持向量机在电力负荷预测应用中的参数优化问题,将改进粒子群算法引入到最小二乘支持向量机参数中,建立一种新型的电力负荷预测模型(IPSO-LSSVM)。首先将最小二乘支持向量机参数编码为粒子初始位置向量;然后通过粒子个体之间的信息交流、协作找到最小二乘支持向量机的最优参数,并针对标准粒子群算法的不足进行相应改进;最后将其应用于电力负荷建模与预测,并通过仿真对比实验测试其性能。实验结果表明,IPSO-LSSVM可以获得较高准确度的电力负荷预测结果,大幅度减少了训练时间,满足电力负荷在线预测要求。

柴远斌/德州职业技术学院电气工程系

随着电力系统数据采集与监控技术的发展,采集的负荷数据越来越多,如何对这些数据包含的有效信息进行挖掘,提高电力负荷预测准确性,成为电力系统研究领域的热点问题之一。

当前电力负荷预测模型分成两类:线性模型和非线性模型。线性模型假设电力负荷是一种线性变化趋势,主要包括多元线性回归方法、时间序列分析法等,它们简单、易实现,预测结果解释性好,但是由于电力负荷具有非线性、时变性特点,线性模型无法准确跟踪电力负荷预测变化趋势,预测准确度较低。非线性模型主要包括神经网络、支持向量机等,具有良好的非线性拟合和预测能力,有效提高了电力负荷预测准确度,但是两种模型均存在各自的不足,如神经网络存在过拟合、收敛速度慢的缺陷;支持向量机泛化能力优异,

但学习速度慢、建模效率低。最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)是一种改进的支持向量机,不仅具有支持向量机的泛化性能,而且学习效率高,克服了神经网络的过拟合缺陷。在实际应用中, LSSVM预测性能与其核函数及参数直接相关,要建立基于LSSVM的电力负荷预测模型,首先要解决LSSVM参数选择问题,已有优化方法有许多算法对其参数进行优化,但它们同样存在一些缺陷,如网格搜索法寻优化时间长;遗传算法自身参数设置缺乏理论指导;粒子群算法易陷入局部最优和在后期阶段搜索速度慢,难以找到全局LSSVM最优参数。

为了提高电力负荷预测准确度,针对LSSVM参数优化的难题,提出一种改进粒子群(Improved Particle Swarm Optimization, IPSO)算法优化LSSVM的电力负荷混沌预测模型(IPSO-LSSVM),并通过仿真实验验证其有效性。

最小二乘支持向量机和改进粒子群算法

1. 最小二乘支持向量机

在支持向量机的基础上,最小二乘支持向量机对其进行了改进,降低了计算复杂度,给定训练样本集 $\{(x_i, y_i)\}$,通过非线性函数 $\phi(x)$ 将样本映射到高维空间,建立线性回归函数

$$f(x) = \omega^T \phi(x) + b \quad (1)$$

式中, ω 为权值向量; b 为偏置。

利用LSSVM进行回归时的优化目



柴远斌/副教授

关键词/Keywords

电力负荷 ·
粒子群优化算法 ·
混沌理论 ·
最小二乘支持向量机 ·

2013年山东省科研规划课题(2013zcyj134)。

标为

$$\begin{aligned} \min & \|\omega\|^2 + \frac{1}{2}\gamma \sum_{i=1}^n \xi_i^2 \\ \text{s. t.} & \\ & \begin{cases} y_i - \omega^T \phi(x) + b = e_i \\ i = 1, 2, \dots, n \end{cases} \end{aligned} \quad (2)$$

式中, γ 为正则化参数; e_i 为误差。

将式 (2) 转变为对偶优化问题, 即

$$\begin{aligned} L(\omega, b, \zeta, \alpha) = \min & \|\omega\|^2 + \frac{1}{2}\gamma \sum_{i=1}^n \xi_i^2 + \\ & \sum_{i=1}^n \alpha_i [\omega^T \phi(x) - b + e_i - y_i] \end{aligned} \quad (3)$$

式中, α_i 为拉格朗日乘子。

根据Mercer条件, 核函数定义为

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (4)$$

选择径向基核函数作为LSSVM核函数, 径向基核函数定义为

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (5)$$

式中, σ 为核函数宽度。

那么LSSVM的非线性回归方程为

$$f(x) = \sum_{i=1}^N \alpha_i \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) + b \quad (6)$$

从LSSVM的工作原理看, 能够发现核函数宽度 σ 及正则参数 γ 对LSSVM模型的准确度有重要影响。在本文中, 这些参数通过改进粒子群优化算法进行选择。

2. 改进粒子群算法

(1) 标准粒子群算法

设 $z_i = (z_{i1}, z_{i2}, \dots, z_{id})$ 、 $v_i = (v_{i1}, v_{i2}, \dots, v_{id})$ 分别为第 i 个粒子的位置和速度; $p_i = (p_{i1}, p_{i2}, \dots, p_{id})$ 为粒子搜索到的最优位置; $p_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 为种群搜索到的最优位置。在每次迭代中, 粒子更新速度和位置

$$\begin{cases} v_{id}^{k+1} = \omega v_{id} + c_1 r_1 (p_{id} - z_{id}^k) + c_2 r_2 (p_{gd} - z_{id}^k) \\ z_{id}^{k+1} = z_{id}^k + v_{id}^{k+1} \end{cases} \quad (7)$$

式中, k 为迭代次数; c_1 、 c_2 为学习因子; r_1 、 r_2 为随机数。

(2) 惯性权重的自适应调整

为了使全局和局部搜索能力达到平衡, 本文

引入一种自适应调整的惯性权重方法, 将其设为随迭代次数线性改变的变量, 表达式为

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}} & f < f_{\text{avg}} \\ \omega_{\max} & f \geq f_{\text{avg}} \end{cases} \quad (8)$$

式中, $\omega_{\min}$ 、 $\omega_{\max}$ 分别为 ω 的最小值和最大值; f 为当前的个体适应度; f_{avg} 和 $f_{\min}$ 分别为平均适应值和最小适应值。

(3) 异步变化的学习因子

为了加快种群的搜索速度, 提高找到全局最优解的效率, 采用异步变化的学习因子, 即

$$\begin{cases} c_1 = c_{1\text{ini}} - (c_{1\text{ini}} - c_{1\text{fin}}) \frac{t}{T_{\max}} \\ c_2 = c_{2\text{ini}} + (c_{2\text{fin}} - c_{2\text{ini}}) \frac{t}{T_{\max}} \end{cases} \quad (9)$$

式中, $c_{1\text{ini}}$ 、 $c_{2\text{ini}}$ 为 c_1 、 c_2 的初始值; $c_{1\text{fin}}$ 、 $c_{2\text{fin}}$ 为 c_1 、 c_2 的终值; t 和 $T_{\max}$ 分别为当前和最大迭代次数。

IPSO-LSSVM的电力负荷预测模型

电力负荷中的LSSVM参数优化目标是为了提高预测准确度, 降低预测误差, 因此LSSVM参数优化目标函数如下

$$\begin{aligned} \min & f(\gamma, \sigma) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ \text{s. t.} & \\ & \begin{cases} \gamma \in [\gamma_{\min}, \gamma_{\max}] \\ \sigma \in [\sigma_{\min}, \sigma_{\max}] \end{cases} \end{aligned} \quad (10)$$

式中, y_i 和 $\hat{y}_i$ 分别为第 i 个样本的输出值和模型预测值。

LSSVM 参数优化是找到一组参数 (γ, σ) 使式 (10) 的值达到最小, 本文采用改进粒子群算法优化LSSVM的参数, IPSO-LSSVM的电力负荷预测工作步骤如下:

1) 收集电力负荷数据, 并通过混沌理论对其进行重构, 得到LSSVM的学习样本。

2) 将学习样本划分成训练集和测试集, 根据模型的预测误差计算每一个粒子的适应度函数值。

3) 设置IPSO参数的初始值, 包括种群规模 m 、最大迭代次数 k 等; 设置LSSVM参数 γ 和 σ 的初

始值。

4) 计算每个粒子的适应度, 根据适应度值的大小更新 p_i 和 p_g , 并更新粒子的速度和位置、惯性权重 ω 和学习因子 c_1 、 c_2 , 形成新的粒子群。

5) 判断终止条件, 如果不满足, 则返回步骤4); 如果满足, 则结束参数寻优。

6) 将全局最优粒子映射为LSSVM的参数 γ 和 σ , 对训练样本进行训练, 建立电力负荷预测模型。

IPSO-LSSVM在电力负荷中的应用实例

1. 数据来源

选择某地区电力负荷数据进行仿真测试, 共收集到200个样本, 其中前150个样本作为训练集, 后50个样本作为测试集, 数据如图1所示。




图1 电力负荷数据

电力负荷具有随机性, 数据值变化幅度大, 这给LSSVM学习过程带来不利影响, 为此, 在建模之前对电力负荷数据进行归一化处理, 具体为

$$x'(i) = \frac{x(i) - \max[x(i)]}{1.5\max[x(i)] - \min[x(i)]} \quad (11)$$

式中, $x(i)$ 和 $x'(i)$ 分别为原始和归一化后的电力负荷值; $\max()$ 和 $\min()$ 分别为样本中的最大值和最小值。

2. 电力负荷学习样本的相空间重构

电力负荷具有混沌特性, 因此需要选择延迟时间 τ 和嵌入维数 m 重构LSSVM的学习样本, 挖掘样本之间的相互关系, 发现其中隐藏的规律。本文采用自相关法和假近邻法分别计算电力负荷的延迟时间 τ 和嵌入维数 m , 其结果分别如图2和图3所示。由图2和图3可知, 最佳延迟时间 $\tau=5$, 最佳嵌入维数 $m=5$ 。




图2 最优延迟时间的确定




图3 最优嵌入维数的确定

3. LSSVM的参数优化

LSSVM参数 γ 的范围为 $(0.1, 10\ 000)$, σ 的范围为 $(0, 10)$ 。IPSO算法的参数设置如下: 粒子群规模 $m=30$, 粒子空间维度 $d=2$, $c_1=c_2=2$, $\omega_{\min}=0.3$, $\omega_{\max}=0.9$, 最大迭代次数 $k=200$; 通过 $\tau=5$ 和 $m=5$ 对电力负荷数据进行重构后, IPSO算法得到最优参数 γ 和 σ 如表1所示。

表1 IPSO算法选择的LSSVM参数 (γ 和 σ)

预测步长	γ	σ
单步	115.170	1.625
四步	275.955	1.902

4. 结果与分析

(1) 单步预测结果分析

IPSO-LSSVM的单步电力负荷预测结果如图4所示。从图4可以看出, 预测值与电力负荷实际




图4 IPSO-LSSVM的单步预测结果

值的误差较小，实验结果表明，IPSO-LSSVM可以准确拟合电力负荷变化趋势，获得比较理想的电力负荷预测结果，是一种有效、可行的电力负荷预测模型。

(2) 多步预测结果分析

在电力负荷的实际应用中，预测时间需要一定的提前量，单步预测结果没有太多的实际应用价值，为此，采用滚动方式得到IPSO-LSSVM提前四步预测结果，具体如图5所示。从图5可知，相对于单步预测结果，IPSO-LSSVM的多步电力负荷预测误差增大，但仍然能够描述电力负荷的整体变化趋势，而且预测误差控制在电力负荷预测的实际应用需求范围内，预测结果可以为电力部门管理人员提供有价值的参考意见。




图5 IPSO-LSSVM的多步预测结果

(3) 与其他模型的性能对比

为了测试IPSO-LSSVM的优越性，选择标准粒子群算法优化LSSVM（PSO-LSSVM）、遗传算法优化LSSVM（GA-LSSVM）作为对比模型，选择方均根误差 e_{RMSE} 和相对平均误差 e_{MAPE} 对预测结果优劣进行评价，具体如下

$$e_{RMSE} = \frac{1}{\max(y_i)} \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \times 100\% \tag{12}$$

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{13}$$

式中， y_i 和 $\hat{y}_i$ 分别为实际值和预测值； n 为测试样本点。

所有模型的电力负荷预测结果评价指标如表2所示。从表2可知，相对于对比模型，IPSO-LSSVM预测误差更小，有效提高了电力负荷的预

测准确度，尤其对于电力负荷的多步预测，预测结果的优势更加明显。

表2 所有模型的电力负荷预测结果综合性能对比

模型	单步		四步	
	e_{RMSE} (%)	e_{MAPE} (%)	e_{RMSE} (%)	e_{MAPE} (%)
GA-LSSVM	2.22	2.21	9.15	9.11
PSO-LSSVM	1.90	1.86	8.95	8.82
IPSO-LSSVM	1.32	1.43	7.89	7.45

(4) 训练时间对比

模型的训练时间也是电力负荷预测模型性能评价的重要指标之一，所有模型的训练时间如图6所示。从图6可知，相比于电力负荷预测模型，IPSO-LSSVM的训练时间相对减少，而且随着预测步长的增加，优势更加明显，主要是由于IPSO算法加快了LSSVM参数寻优的速度，减少了计算的复杂度，同时加快了电力负荷训练速度，更适合于电力负荷的在线预测，拓宽了实际应用范围。




图6 不同电力负荷模型的训练时间对比

结束语

电力负荷受到多种因素影响，具有复杂性和不确定性的特点，提出IPSO和LSSVM相融合的电力负荷预测模型，克服了LSSVM参数选择的盲目性，并与当前一些电力负荷预测模型进行了对比实验，以测试IPSO-LSSVM的有效性和优越性。实验结果表明，IPSO-LSSVM可以准确描述电力负荷的变化趋势，提高了电力负荷预测准确度，在训练时间上有明显的优势，在电力负荷预测中具有广泛的应用前景。

(收稿日期：2015-01-15) EA