



(12) 发明专利申请

(10) 申请公布号 CN 104899665 A

(43) 申请公布日 2015. 09. 09

(21) 申请号 201510342476. 8

(51) Int. Cl.

(22) 申请日 2015. 06. 19

G06Q 10/04(2012. 01)

G06Q 50/06(2012. 01)

(71) 申请人 国网四川省电力公司经济技术研究院

地址 610000 四川省成都市锦江区均隆街 3 号 4 楼

申请人 成都城电电力工程设计有限公司  
国家电网公司

(72) 发明人 肖猛 汪小明 王晞 尹笋  
苟旭丹 王波 杨楠 刘涤尘  
李松涛 严居斌 陶宇轩

(74) 专利代理机构 成都行之专利代理事务所  
(普通合伙) 51220

代理人 何筱茂

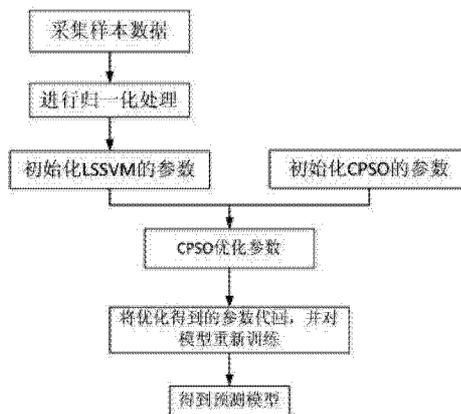
权利要求书3页 说明书8页 附图3页

(54) 发明名称

风电功率短期预测方法

(57) 摘要

本发明涉及风电预测技术领域,公开了一种风电功率短期预测方法,该方法以风速作为输入,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化。本发明将混沌运动特性引入到迭代过程中,在搜索过程中利用混沌运动的遍历性来提高算法的全局搜索能力,改善粒子群算法易陷入局部极值点、进化后期收敛慢且精度低的缺点,有效的解决粒子群算法的“早熟”问题,能够保证全局最优性,预测效果更好;运用最小二乘支持向量机进行预测,避免了求解二次规划的问题,并且将预测问题转化为求解线性方程组的过程,其求解过程大大简化;采用单一风速作为输入数据,预测模型更加简单。



1. 风电功率短期预测方法,其特征在于,以风速作为输入,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化。

2. 根据权利要求 1 所述的风电功率短期预测方法,其特征在于,所述的以风速作为输入,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化具体包括以下步骤:

步骤 1:获取数据,并对数据进行归一化处理作为训练样本;

步骤 2:初始化最小二乘支持向量机和混沌粒子群算法的参数;

步骤 3:以回归误差平方和最小为目标函数,采用混沌粒子群算法对最小二乘支持向量机的回归模型参数进行优化;

步骤 4:将优化的参数代回最小二乘支持向量机的回归模型中,重新进行训练;

步骤 5:使用训练好最小二乘支持向量机的回归模型对风电场的输出功率进行预测。

3. 根据权利要求 2 所述的风电功率短期预测方法,其特征在于,所述最小二乘支持向量机的回归模型构建方法包括以下步骤:

采用一个训练样本集  $(x_i, y_i)$ ,  $i = 1, 2, \dots, l$ ,  $x_i$  是风速,  $y_i$  是风电输出功率的实测值,  $l$  是训练样本集中数据点集的总数,利用一个非线性映射  $\varphi(x)$  将样本空间映射到特征空间,并在高维空间中构造最优决策函数:

$$f(x) = w\varphi(x) + b \quad (1);$$

利用结构风险最小化原则,最小二乘支持向量机的优化目标可表示为:

$$\min \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 \quad (2);$$

$$s.t. y_i = w\varphi(x) + b + \xi_i, i = 1, 2, \dots, l$$

其中:  $w$  为权值向量,  $\|w\|^2$  是模型的复杂度;  $C$  为边际系数,控制对误差的惩罚程度;  $\xi_i$  是误差向量;  $b$  是偏差量;

利用拉格朗日法求解式 (2), 可得:

$$L(w, b, \xi, \alpha) = \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i (w\varphi(x_i) + b + \xi_i - y_i) \quad (3);$$

式中:  $\alpha_i$  ( $i = 1, 2, \dots, l$ ) 为拉格朗日乘子;

由 KKT (Krush-Kuhn-Tucker) 条件可知:

$$\begin{cases} w = \sum_{i=1}^l \alpha_i \varphi(x_i) \\ \sum_{i=1}^l \alpha_i = 0 \end{cases} \quad (4);$$

通过核函数将 (4) 转化为线性方程进行求解,选用在回归预测中效果较好的径向基核函数,定义核函数为  $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$ , 转化后的线性方程组为:

$$\begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{C} & \cdots & K(x_1, x_l) + \frac{1}{C} \\ \vdots & \vdots & & \vdots \\ 1 & K(x_l, x_1) + \frac{1}{C} & \cdots & K(x_l, x_l) + \frac{1}{C} \end{bmatrix} \times \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} b \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (5);$$

用最小二乘法求解上式,得到回归系数  $\alpha_i$ 和偏差  $b$ ,便能得到非线性的回归模型:

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (6);$$

式(6)中,径向基核函数  $K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right)$ ,式中  $\sigma$  为核宽度,  $\|x-x_i\|$  为二范数;

最小二乘支持向量机的回归模型为  $f(x) = \sum_{i=1}^l \alpha_i \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) + b$ ,该式中的  $\sigma$  和式

(2) 中的  $C$  采用混沌粒子群算法进行优化。

4. 根据权利要求 2 或 3 所述的风电功率短期预测方法,其特征在于,所述的步骤 3 具体包括以下步骤:

步骤 3.1:采用混沌系统  $z_{n+1} = \mu z_n(1-z_n)$  产生混沌序列对算法中粒子的速度和位置进行初始化,其中  $\mu$  为混沌控制参量,  $z_n$  是混沌变量,  $n$  为序列个数;

步骤 3.2:遍历搜索得到个体最优位置,并按公式(7)以回归误差平方和最小为适应度,计算并比较适应度值,迭代搜索出全局最优位置;

$$\min \sum_{i=1}^l (f(x_i) - y_i)^2 \quad (7);$$

式中:  $f(x_i)$  为第  $i$  时刻的预测值;  $x_i$  为最小二乘支持向量机的回归模型的输入值,  $y_i$  为第  $i$  时刻的实测值;

步骤 3.3:以全局最优位置为基础产生混沌序列,将产生的序列中最好的一个位置作为其中一个粒子的新位置;

步骤 3.4:按公式(8)更新其它粒子的速度,按公式(9)更新其他粒子的位置;

$$v_{ik}(t+1) = \omega v_{ik}(t) + c_1 \delta_1 (p_{ik}(t) - x_{ik}(t)) + c_2 \delta_2 (p_{gk}(t) - x_{ik}(t)) \quad (8)$$

$$x_{ik}(t+1) = x_{ik}(t) + v_{ik}(t+1) \quad (9);$$

式中:  $\omega$  为惯性权重;  $c_1$ 、 $c_2$  为学习因子;  $\delta_1$ 、 $\delta_2$  为介于 0 和 1 之间的随机数;此外,粒子的最大速度不应超过其最大速度  $V_{max}$ ,  $x_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的位置,  $x_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的位置;  $v_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的速度,  $v_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的速度,  $p_{ik}(t)$  是个体最优位置,  $p_{gk}(t)$  是全局最优位置;

步骤 3.5:判断是否满足迭代次数限制,是则结束优化并输出结果,否则返回步骤 3.2。

5. 根据权利要求 2 所述的风电功率短期预测方法,其特征在于,步骤 2 中,所述的初始化最小二乘支持向量机和混沌粒子群算法的参数包括以下步骤:

步骤 2.1、确定最小二乘支持向量机的惩罚参数  $C$  和核参数  $\sigma^2$  的范围,初始化最小二乘支持向量机的惯性权重  $\omega$  ;

步骤 2.2、确定混沌粒子群算法的学习因子  $c_1$ 、 $c_2$ ;混沌控制参量  $\mu$  和迭代次数。

## 风电功率短期预测方法

### 技术领域

[0001] 本发明涉及一种风电功率预测方法,具体地,涉及一种风电功率短期预测方法。

### 背景技术

[0002] 随着风力发电机组单机容量的提高和自动化技术的发展,风力发电系统也从原来的用户分布式能源向集中式大规模风电场发展。风电在电网中比例不断增大,大量并网的风电对电力系统的调度运行和安全稳定带来了严峻挑战。有效的风电功率预测可以减少电力系统备用容量、降低系统运行成本、减轻风力发电对电网造成的不利影响、提高风电在电力系统中的比例,因此对风电功率进行预测具有十分重要意义。

[0003] 目前风功率预测有物理方法和统计方法。物理方法主要考虑的是一些物理量,比如数值天气预报得到的天气数据(风速、风向、气压等),风电场周围的信息(等高线、粗糙度、障碍物等)以及风电机组的技术参数(轮毂高、穿透系数等)。其目的是找到风电机组轮毂高度出的风速最优估计值,然后用模型输出统计模块减小存在的误差,最后根据风电场的功率曲线计算得到风电场的输出功率。由于天气预报每天只更新几次,因此这种方法通常适用于相对较长的预测。

[0004] 统计预测方法一般需要大量的历史数据进行建模,统计方法对于提前几小时的风电功率预测结果是可以满足精度要求的,但对于提前更长时间的预测结果,精度是不够的。目前常用的统计学预测方法有卡尔曼滤波法、时间序列法、人工神经网络法、支持向量机法、灰色模型、小波分析等。这些方法随着风电技术的深入暴露了难以克服的缺陷,如预测精度差,收敛速度慢,有局限性等缺点。

### 发明内容

[0005] 本发明的目的就在于克服上述现有技术的缺点和不足,提供一种预测精度高、收敛速度快、计算简单的风电功率短期预测方法。

[0006] 本发明解决上述问题所采用的技术方案是:

风电功率短期预测方法,以风速作为输入,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化。

[0007] 作为本发明的进一步改进,所述的以风速作为输入,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化具体包括以下步骤:

步骤 1:获取数据,并对数据进行归一化处理后作为训练样本;

步骤 2:初始化最小二乘支持向量机和混沌粒子群算法的参数;

步骤 3:以回归误差平方和最小为目标函数,采用混沌粒子群算法对最小二乘支持向量机的回归模型参数进行优化;

步骤 4:将优化的参数代回最小二乘支持向量机的回归模型中,重新进行训练;

步骤 5:使用训练好最小二乘支持向量机的回归模型对风电场的输出功率进行预测。

[0008] 进一步,所述最小二乘支持向量机的回归模型构建方法包括以下步骤:

采用一个训练样本集  $(x_i, y_i)$ ,  $i = 1, 2, \dots, l$ ,  $x_i$  是风速,  $y_i$  是风电输出功率的实测值,  $l$  是训练样本集中数据点集的总数, 利用一个非线性映射  $\varphi(x)$  将样本空间映射到特征空间, 并在高维空间中构造最优决策函数:

$$f(x) = w\varphi(x) + b \quad (1);$$

利用结构风险最小化原则, 最小二乘支持向量机的优化目标可表示为:

$$\min \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 \quad (2);$$

$$s.t. y_i = w\varphi(x_i) + b + \xi_i, i = 1, 2, \dots, l$$

其中:  $w$  为权值向量,  $\|w\|^2$  是模型的复杂度;  $C$  为边际系数, 控制对误差的惩罚程度;  $\xi_i$  是误差向量;  $b$  是偏差量;

利用拉格朗日法求解式 (2), 可得:

$$L(w, b, \xi, \alpha) = \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i (w\varphi(x_i) + b + \xi_i - y_i) \quad (3);$$

式中:  $\alpha_i$  ( $i = 1, 2, \dots, l$ ) 为拉格朗日乘子;

由 KKT (Krush-Kuhn-Tucker) 条件可知:

$$\begin{cases} w = \sum_{i=1}^l \alpha_i \varphi(x_i) \\ \sum_{i=1}^l \alpha_i = 0 \end{cases} \quad (4);$$

通过核函数将 (4) 转化为线性方程进行求解, 选用在回归预测中效果较好的径向基核函数, 定义核函数为  $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$ , 转化后的线性方程组为:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{C} & \dots & K(x_1, x_l) + \frac{1}{C} \\ \vdots & \vdots & & \vdots \\ 1 & K(x_l, x_1) + \frac{1}{C} & \dots & K(x_l, x_l) + \frac{1}{C} \end{bmatrix} \times \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} b \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (5);$$

用最小二乘法求解上式, 得到回归系数  $\alpha_i$  和偏差  $b$ , 便能得到非线性的回归模型:

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (6);$$

式 (6) 中, 径向基核函数  $K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)$ , 式中  $\sigma$  为核宽度,  $\|x - x_i\|$  为二范

数;

最小二乘支持向量机的回归模型为  $f(x) = \sum_{i=1}^l \alpha_i \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) + b$ , 该式中的  $\sigma$  和式

(2) 中的  $C$  采用混沌粒子群算法进行优化。

[0009] 进一步, 步骤 3 具体包括以下步骤:

步骤 3.1: 采用混沌系统  $z_{n+1} = \mu z_n(1-z_n)$  产生混沌序列对算法中粒子的速度和位置进行初始化, 其中  $\mu$  为混沌控制参量,  $z_n$  是混沌变量,  $n$  为序列个数;

步骤 3.2: 遍历搜索得到个体最优位置, 并按公式 (7) 以回归误差平方和最小为适应度, 计算并比较适应度值, 迭代搜索出全局最优位置;

$$\min \sum_{i=1}^l (f(x_i) - y_i)^2 \quad (7);$$

式中:  $f(x_i)$  为第  $i$  时刻的预测值;  $x_i$  为最小二乘支持向量机的回归模型的输入值,  $y_i$  为第  $i$  时刻的实测值;

步骤 3.3: 以全局最优位置为基础产生混沌序列, 将产生的序列中最好的一个位置作为其中一个粒子的新位置;

步骤 3.4: 按公式 (8) 更新其它粒子的速度, 按公式 (9) 更新其他粒子的位置;

$$v_{ik}(t+1) = \omega v_{ik}(t) + c_1 \delta_1 (p_{ik}(t) - x_{ik}(t)) + c_2 \delta_2 (p_{gk}(t) - x_{ik}(t)) \quad (8)$$

$$x_{ik}(t+1) = x_{ik}(t) + v_{ik}(t+1) \quad (9);$$

式中:  $\omega$  为惯性权重;  $c_1$ 、 $c_2$  为学习因子;  $\delta_1$ 、 $\delta_2$  为介于 0 和 1 之间的随机数; 此外, 粒子的最大速度不应超过其最大速度  $V_{max}$ ,  $x_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的位置,  $x_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的位置;  $v_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的速度,  $v_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的速度,  $p_{ik}(t)$  是个体最优位置,  $p_{gk}(t)$  是全局最优位置;

步骤 3.5: 判断是否满足迭代次数限制, 是则结束优化并输出结果, 否则返回步骤 3.2。

[0010] 进一步, 步骤 2 中, 所述的初始化最小二乘支持向量机和混沌粒子群算法的参数包括以下步骤:

步骤 2.1、确定最小二乘支持向量机的惩罚参数  $C$  和核参数  $\sigma^2$  的范围, 初始化最小二乘支持向量机的惯性权重  $\omega$ ;

步骤 2.2、确定混沌粒子群算法的学习因子  $c_1$ 、 $c_2$ ; 混沌控制参量和迭代次数。

[0011] 本发明的有益效果是:

1、本发明采用混沌粒子群算法对支持向量机的参数进行优化。粒子群算法是一种具有并行运算能力的智能优化算法, 但该算法也存在缺陷, 算法在迭代当中易落入局部最优点, 使得算法过早收敛而不能保证计算的精度。混沌粒子群算法是建立在混沌理论之上的, 混沌状态特点是遍历性、随机性和规律性, 混沌状态虽然是一种随机状态, 但是可以由确定的方程得到, 并且混沌运动能在一定范围内按照某一规律不重复地遍历所有状态。混沌粒子群算法将混沌运动特性引入到迭代过程当中, 在搜索过程中利用混沌运动的遍历性来提高算法的全局搜索能力, 改善了粒子群算法易陷入局部极值点、进化后期收敛慢且精度低的缺点, 有效的解决了粒子群算法的“早熟”问题, 能够保证全局最优性, 预测效果更好。

[0012] 2、本发明运用最小二乘支持向量机进行预测。在处理非线性复杂的回归问题时, 支持向量机将回归预测问题转化为一个求解二次规划的问题, 可以求得全局最优解。而最

小二乘支持向量机的预测模型则避免了求解二次规划的问题,并且将预测问题转化为求解线性方程组的过程,其求解过程大大简化。

[0013] 3、本发明采用单一风速作为输入数据,预测模型更加简单。

### 附图说明

[0014] 图 1 是本发明的风电功率短期预测流程;

[0015] 图 2 是混沌粒子群算法的计算流程;

[0016] 图 3 是实测值与最小二乘支持向量机的回归模型预测值对比图。

### 具体实施方式

[0017] 本发明针对风速间歇性和随机性的特点,采用一种基于混沌粒子群和最小二乘支持向量机(CPSO-LSSVM)的风电功率短期预测方法以风速作为输入,以风电场的输出功率为输出,采用最小二乘支持向量机的回归模型对风电场的输出功率进行预测,最小二乘支持向量机的回归模型参数采用混沌粒子群算法进行优化,克服传统方法计算方法陷入局部极小、训练时间长等缺点,有更好的泛化性能和精确性。

[0018] 下面结合实施例及附图,对本发明作进一步地的详细说明,但本发明的实施方式不限于此。

[0019] 如图 1 所示,风电功率短期预测方法包括以下步骤:

步骤 1:数据的获取和归一化处理。本实施例中采用某一时刻的风速数据  $x_i$  作为输入数据进行训练,用于预测下一时刻的风速,获取到风速数据后首先按公式 10 进行归一化处理,然后作为训练样本 T:

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中: $\bar{x}_i$  是训练样本 T 中的某个风速数据归一化后的结果; $x_{\max}$  和  $x_{\min}$  分别是训练样本 T 中该组变量数据的最大值和最小值。本步骤中数据的获取可以直接从电力系统的 SCADA 系统中提取,也可以通过其他方式采集。

步骤 2:初始化最小二乘支持向量机(LSSVM)和混沌粒子群算法(CPSO)的各参数。本步骤中,初始化最小二乘支持向量机和混沌粒子群算法的各参数具体包括:

步骤 2.1、确定 LSSVM 的惩罚参数 C 和核参数  $\sigma^2$  的范围,初始化 LSSVM 的惯性权重  $\omega$ ;

步骤 2.2、确定 CPSO 的相关参数,例如但不限于算法参数、迭代次数;算法参数包括学习因子  $c_1$ 、 $c_2$ ;混沌控制参量  $\mu$ ;

步骤 2.3、在 LSSVM 的惩罚参数 C 和核参数  $\sigma^2$  的范围内随机初始化粒子群。

步骤 3:以回归误差平方和最小为目标函数,采用混沌粒子群算法对最小二乘支持向量机的参数进行优化。

步骤 4:将优化的参数代回最小二乘支持向量机的回归模型中,得到预测模型,并对预测模型重新进行训练;

步骤 5:根据得到的风速数据,使用训练好最小二乘支持向量机的回归模型作为预测模型对风电场的输出功率进行预测。

[0020] 其中,上述 LSSVM 的回归模型的构建方法为:

对于事先获得的训练样本集  $(x_i, y_i)$ ,  $x_i$  是风速,  $y_i$  是风电输出功率的实测值,  $l$  是训练样本集中数据点集的总数, 利用一个非线性映射  $\varphi(x)$  将样本空间映射到特征空间, 并在高维空间中构造最优决策函数:

$$f(x) = w\varphi(x) + b \quad (1)$$

利用结构风险最小化原则, 最小二乘支持向量机的优化目标可表示为:

$$\begin{aligned} \min \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 \\ \text{s.t. } y_i = w\varphi(x_i) + b + \xi_i, i = 1, 2, \dots, l \end{aligned} \quad (2)$$

其中:  $w$  为权值向量, 用于控制前面风速对当前风速的影响,  $\|w\|^2$  是模型的复杂度;  $C$  为边际系数, 控制对误差的惩罚程度;  $\xi_i$  是误差向量;  $b$  是偏差量。

[0021] 利用拉格朗日法求解式 (2), 可得:

$$L(w, b, \xi, \alpha) = \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i (w\varphi(x_i) + b + \xi_i - y_i) \quad (3)$$

式中:  $\alpha_i$  ( $i = 1, 2, \dots, l$ ) 为拉格朗日乘子。

[0022] 由 KKT (Krush-Kuhn-Tucker) 条件:  $\frac{\partial L}{\partial w} = 0$ ,  $\frac{\partial L}{\partial b} = 0$ ,  $\frac{\partial L}{\partial \xi} = 0$ ,  $\frac{\partial L}{\partial \alpha} = 0$  可得:

$$w = \sum_{i=1}^l \alpha_i \varphi(x_i), \quad \sum_{i=1}^l \alpha_i = 0, \quad \alpha_i = C \xi_i, \quad w \cdot \varphi(x_i) + b + \xi_i - y_i = 0$$

即得到公式:

$$\begin{cases} w = \sum_{i=1}^l \alpha_i \varphi(x_i) \\ \sum_{i=1}^l \alpha_i = 0 \end{cases} \quad (4)$$

[0023] 最后, 只须通过核函数, 将上述的优化过程转化为线性方程, 再进行求解即可。本实施例中, 选用在回归预测中效果较好的径向基核函数, 定义核函数为  $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$ , 转化后的线性方程组为:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{C} & \dots & K(x_1, x_l) + \frac{1}{C} \\ \vdots & \vdots & & \vdots \\ 1 & K(x_l, x_1) + \frac{1}{C} & \dots & K(x_l, x_l) + \frac{1}{C} \end{bmatrix} \times \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} b \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (5)$$

用最小二乘法求解上式, 得到回归系数  $\alpha_i$  和偏差  $b$ , 便能得到非线性的回归模型:

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (6)$$

式 (6) 中, 径向基核函数  $K(x, x_i) = \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right)$ , 式中  $\sigma$  为核宽度,  $\|x-x_i\|$  为二范数;

最小二乘支持向量机的回归模型为  $f(x) = \sum_{i=1}^l \alpha_i \exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) + b$ , 该式中的  $\sigma$  和式

(2) 中的  $C$  采用混沌粒子群算法进行优化。

[0024] 混沌粒子群主要利用混沌运动的遍历性以当前整个粒子群搜索到的最优位置为基础产生混沌序列, 再把产生的混沌序列中的最优位置粒子随机代替当前粒子群中的一个粒子位置, 改善了粒子群算法易陷入局部极值点、进化后期收敛慢精度低的缺点。

[0025] 具体地, 步骤 3 中, 以回归误差平方和最小为目标函数, 采用混沌粒子群算法对最小二乘支持向量机的回归模型参数进行优化的具体算法流程如图 2 所示, 步骤如下:

[0026] 步骤 3.1: 采用混沌系统  $z_{n+1} = \mu z_n(1-z_n)$  产生混沌序列对算法中粒子的速度和位置进行初始化, 其中  $\mu$  为混沌控制参量,  $z_n$  是混沌变量,  $n$  为序列个数;

[0027] 步骤 3.2: 根据混沌运动的遍历性, 遍历搜索得到个体最优位置  $p_{ik}(t)$ , 并以回归误差平方和最小为适应度如式 (7), 计算并比较适应度值, 迭代搜索出全局最优位置  $p_{gk}(t)$ ,

$$\min \sum_{i=1}^I (f(x_i) - y_i)^2 \quad (7)$$

式中:  $f(x_i)$  为第  $i$  时刻的预测值;  $x_i$  为最小二乘支持向量机的回归模型的输入值,  $y_i$  为第  $i$  时刻的实测值。

[0028] 步骤 3.3: 以全局最优位置为基础产生混沌序列, 将产生的序列中最好的一个作为其中任一个粒子的新位置。

[0029] 步骤 3.4: 按公式 (3) 更新其它粒子的速度, 按公式 (4) 更新其他粒子的位置;

$$v_{ik}(t+1) = \omega v_{ik}(t) + c_1 \delta_1 (p_{ik}(t) - x_{ik}(t)) + c_2 \delta_2 (p_{gk}(t) - x_{ik}(t)) \quad (3)$$

$$x_{ik}(t+1) = x_{ik}(t) + v_{ik}(t+1) \quad (4)$$

式中:  $\omega$  为惯性权重;  $c_1$ 、 $c_2$  为学习因子;  $\delta_1$ 、 $\delta_2$  为介于 0 和 1 之间的随机数; 此外, 粒子的最大速度不应超过其最大速度  $v_{max}$ ,  $x_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的位置,  $x_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的位置;  $v_{ik}(t)$  是  $i$  时刻第  $k$  个粒子的速度,  $v_{ik}(t+1)$  是  $i+1$  时刻第  $k$  个粒子的速度, 并更新粒子种群中全局最优和个体最优位置。

[0030] 步骤 3.5: 判断是否满足迭代次数限制, 是则结束优化并输出结果即输出优化后的回归模型参数: 惩罚参数  $C$  和核宽度  $\sigma$ , 否则返回步骤 3.2, 例如达到了设定的迭代次数则结束并输出结果, 否则返回步骤 3.2 继续迭代优化。

[0031] 本发明采用混沌粒子群算法对支持向量机的参数进行优化。粒子群算法是一种具有并行运算能力的智能优化算法, 但该算法也存在缺陷, 算法在迭代当中易落入局部最优, 使得算法过早收敛而不能保证计算的精度。混沌粒子群算法是建立在混沌理论之上的, 混沌状态特点是遍历性, 随机性和规律性, 混沌状态虽然是一种随机状态, 但是可以由确定的方程得到, 并且混沌运动能在一定范围内按照某一规律不重复地遍历所有状态。混沌粒

子群算法将混沌运动特性引入到迭代过程当中,在搜索过程中利用混沌运动的遍历性来提高算法的全局搜索能力,有效的解决了粒子群算法的“早熟”问题。

[0032] 本发明运用最小二乘支持向量机进行预测。在处理非线性复杂的回归问题时,支持向量机将回归预测问题转化为一个求解二次规划的问题,可以求得全局最优解。而最小二乘支持向量机的预测模型则避免了求解二次规划的问题,并且将预测问题转化为求解线性方程组的过程,其求解过程大大简化。

[0033] 本发明还选取实测风力发电机数据中较完整的一组作为训练样本数据进行预测,以某一时刻的风速数据作为输入数据,预测下一时刻的风速,进行了试验。

[0034] 选取的机组的工作时长为 96 小时,采样间隔为 10 分钟,采集到的该机组共 576 组风速和温度数据,以及 576 组发电机输出功率数据。

[0035] 采用混沌粒子群算法对惩罚参数  $C$  和核宽度  $\sigma$  进行优化,初始化惯性权重  $\omega$  为 0.4;学习因子  $c_1 = c_2 = 0.2$ ;混沌控制参量  $\mu = 4$ ;迭代次数为 200 次。优化结果  $C = 75.5839$ ,  $\sigma^2 = 0.1267$ 。应用训练后的模型对下一时刻的风速进行预测,并与实测值进行对比,结果如图 3。

[0036] 由图 3 可知,预测值与实测值变化趋于一致,说明采用本发明的方法预测可靠性较高。

[0037] 同时,本发明还用以下几种方法进行了误差分析:

(1) 预测误差平方和 (SSE)

$$e_{SSE} = \sum_{i=1}^N (A_i - P_i)^2 \quad (11)$$

(2) 均方误差 (MSE)

$$e_{MSE} = \frac{1}{N} \sqrt{\sum_{i=1}^N (A_i - P_i)^2} \quad (12)$$

(3) 平均绝对百分比误差 (MAPE)

$$e_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{A_i - P_i}{A_i} \right| \quad (13)$$

(4) 均方百分比误差 (MSPE)

$$e_{MSPE} = \frac{1}{N} \sqrt{\sum_{i=1}^N ((A_i - P_i) / A_i)^2} \quad (14)$$

在上述各式中: $A_i$ 为预测点的实测值, $P_i$ 为预测点的预测值, $N$ 为预测点的个数。

[0038] 误差分析计算结果如表 1 所示。

表 1 CPSO-LSSVM 分析指标

预测模型	SEE	MSE	MAPE	MSPE
CPSO-LSSVM	62.4669	0.0659	0.1178	0.0544

由表可知,本发明提出 CPSO-LSSVM 预测模型具有较好的预测精度和适应性。

[0039] 以上仅是本发明的优选实施方式,本发明的保护范围并不仅限于上述实施例,凡属于本发明思路下的技术方案均属于本发明的保护范围。应当指出,对于本技术领域的普通技术人员来说,在不脱离本发明原理前提下的若干改进和润饰,应视为本发明的保护范围。

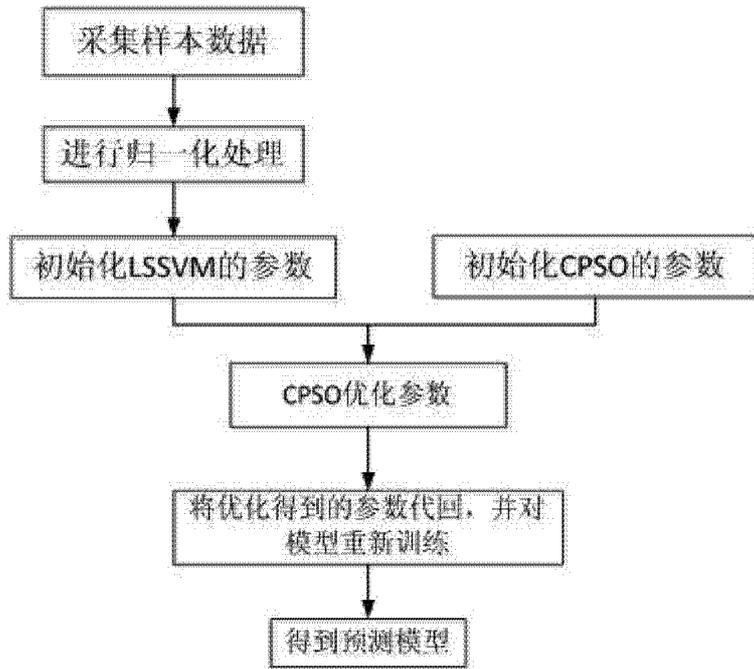


图 1

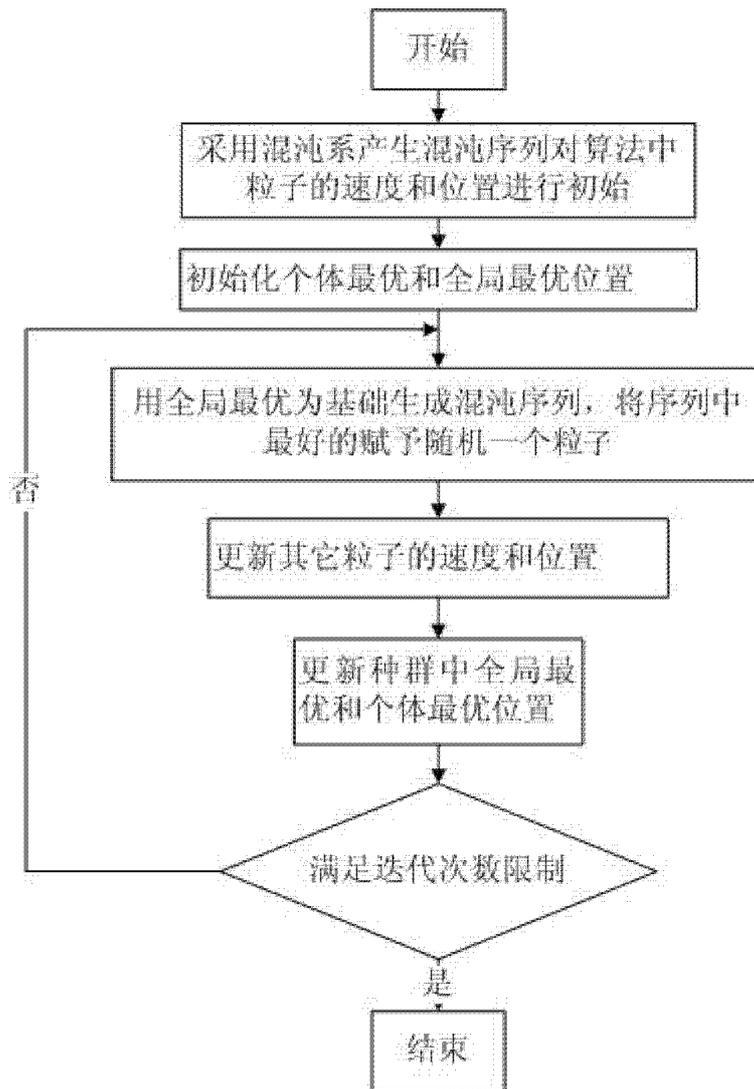


图 2

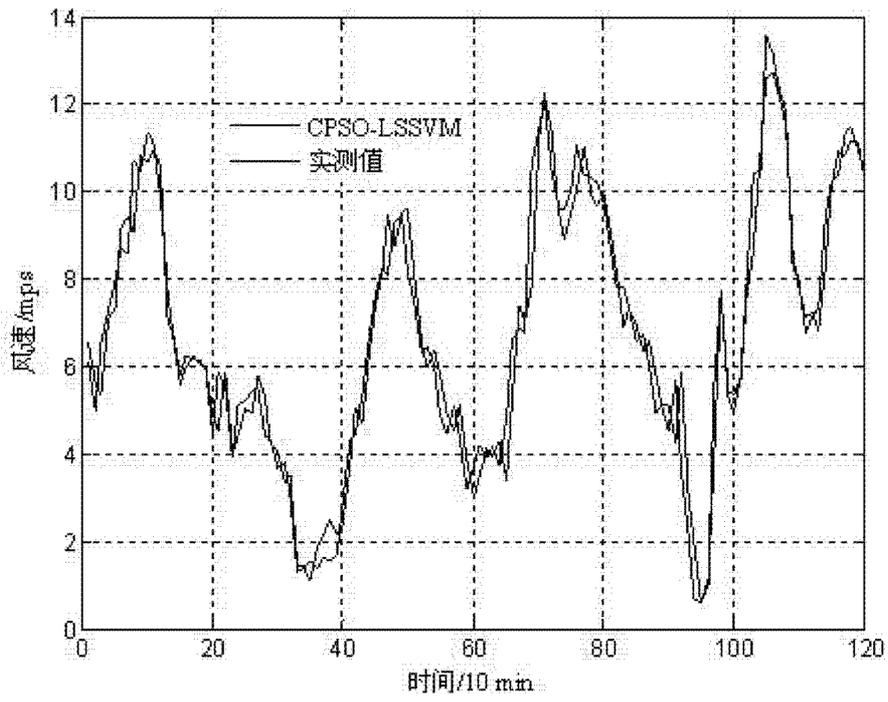


图 3