



(12)发明专利申请

(10)申请公布号 CN 110942205 A

(43)申请公布日 2020.03.31

(21)申请号 201911232794.3

(22)申请日 2019.12.05

(71)申请人 国网安徽省电力有限公司

地址 230061 安徽省合肥市黄山路9号

申请人 安徽大学

(72)发明人 马金辉 汪伟 王璨 陈实

李端超 王正风 王松 陶雪峰

潘文虎 陈璐 孔庆竹 张倩

马愿

(74)专利代理机构 武汉科皓知识产权代理事务

所(特殊普通合伙) 42222

代理人 鲁力

(51)Int.Cl.

G06Q 10/04(2012.01)

G06Q 50/06(2012.01)

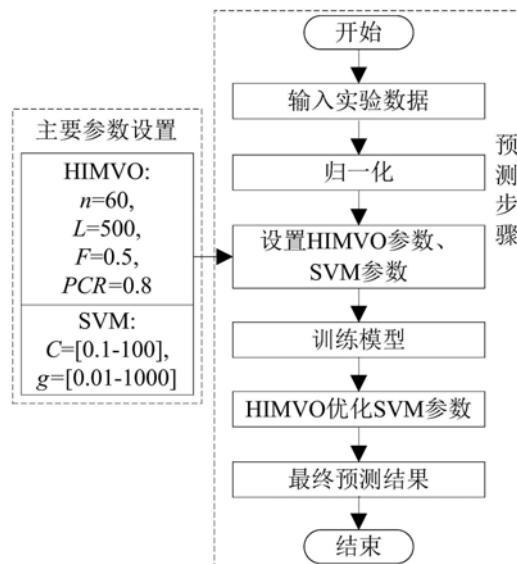
权利要求书2页 说明书9页 附图3页

(54)发明名称

一种基于HIMVO-SVM的短期光伏发电功率预测方法

(57)摘要

本发明提出了一种基于HIMVO-SVM的短期光伏发电功率预测方法。首先,为摆脱传统MVO算法易陷入局部优化的缺点,采用基于帐篷映射的混沌序列参与种群初始化;接着,在MVO算法的位置矢量更新中,引入了一种非线性惯性权值下降策略,并加入差分进化(DE)算法进行全局搜索,提出了HIMVO算法来寻优SVM参数;最后,采用所提方法在三种不同天气类型下进行仿真实验。预测结果与SVM、MVO-SVM方法对比,验证了HIMVO-SVM方法可有效提升短期光伏发电功率预测精度。



1. 一种基于HIMVO-SVM的短期光伏发电功率预测方法,其特征在于,包括
步骤1、采集数据,包括太阳辐射强度、相对湿度、大气温度和光伏功率;
步骤2、将采集的数据结合归一化,基于以下公式:

$X_i^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$, 其中, X_i 为原始数据序列, X_{\max} 和 X_{\min} 分别是原始数据中的最大值和最小

值, X_i^* 是归一化后的序列;

将归一化后的数据中选取训练集,剩下数据作为测试集;并定义 $\{(x_i, y_i) | i=1, 2, \dots, n, x_i \in R^n, y_i \in R^n\}$, x_i 和 y_i 分别是训练样本的输入和输出;

步骤3、设置HIMVO和SVM的参数;并基于SVM建模仿真,所述SVM建模模型基于以下公式:

线性回归函数见式(1)用于拟合 (x_i, y_i) ;

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

式中, w 是权重向量, b 是偏移量;

构造非线性函数 $\varphi(x)$, 将训练数据映射到高维空间, 并构造回归估计函数;表达式如下:

$$f(x) = w^T \varphi(x) + b \quad (2)$$

优化问题可以表示为:

$$\begin{aligned} & \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ & s.t. \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \end{aligned} \quad (3)$$

式中, C 是惩罚因子, ξ_i 、 ξ_i^* 是松弛变量, ε 是损失函数;

优化问题的拉格朗日函数可通过拉格朗日乘子 μ_i 、 μ_i^* 、 a_i 和 α_i^* 表示如下:

$$\begin{aligned} L = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \mu_i^* \xi_i^* \\ & + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^n \alpha_i^* (y_i - f(x_i) - \varepsilon - \xi_i^*) \end{aligned} \quad (4)$$

对式(4)的 w 求偏导且令其为0, 可得:

$$w = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i \quad (5)$$

式(5)带入式(1)可得回归函数:

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i^T x + b \quad (6)$$

步骤4、利用HIMVO算法搜索SVM模型参数的最佳值,具体包括:

步骤4.1, 初始化与MVO和DE算法相关的参数: 宇宙数 n 、最大迭代次数 L 、候选解维度 d 、决策变量矩阵大小 VS 、交叉概率 PCR 和比例因子 F ;

步骤4.2, 基于帐篷映射的混沌序列初始化宇宙群, 计算粒子的适应值以获得当前最优个体和全局最优个体位置;

步骤4.3, 根据式(7)进行迭代, 计算每个个体的适应度值, 更新每个个体的位置;

$$x_i^j = \begin{cases} w^* X_j + TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 < 0.5 \\ w^* X_j - TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 \geq 0.5 \\ x_i^j & r2 \geq WEP \end{cases} \quad (7)$$

步骤4.4,根据式(8)随机选择三个个体进行突变操作;

$$W_i(t+1) = X_{R1}(t) + F[X_{R2}(t) - X_{R3}(t)] \quad (8)$$

式中, $W_i(t+1)$ 是由突变操作产生的新个体,R1、R2、R3是彼此不等的随机数,F表示随机比例因子,值为0到1;

步骤4.5,根据式(9)进行交叉操作以获得新的突变个体,并计算其适应度值;交叉操作是在要变异的个体和新个体之间交换一些元素,以丰富个体的多样性;交叉方程式如下:

$$U_{i,j}(t+1) = \begin{cases} W_{i,j}(t+1) & \text{if } [0, 1] \leq PCR \text{ or } j = j_{sd} \\ X_{i,j}(t) & \text{otherwise} \end{cases} \quad (9)$$

式中,PCR表示交叉概率,SD表示随机维度;

步骤4.6,根据式(10)进行选择操作以获得最佳个体;适者生存的原则,选择方程如式如下:

$$X_i(t+1) = \begin{cases} U_i(t+1) & \text{if } f[U_i(t+1)] \leq f[X_i(t)] \\ X_i(t) & \text{otherwise} \end{cases} \quad (10)$$

步骤4.7,达到最大迭代次数,则结束算法,否则,返回步骤4.3;

步骤5、最后得到基于HIMVO-SVM短期光伏发电功率模型的预测结果,即三种天气状况下的预测光伏发电功率。

一种基于HIMVO-SVM的短期光伏发电功率预测方法

技术领域

[0001] 本发明涉及一种短期光伏发电功率预测方法,尤其是涉及一种基于HIMVO-SVM的短期光伏发电功率预测方法。

背景技术

[0002] 太阳能作为一种可再生能源,由于其储能丰富、分布广泛、绿色、清洁等特点,被公认为全球最佳的替代能源解决方案。光伏发电是太阳能发电的有效途径,随着光伏发电技术的不断完善,光伏并网规模日益扩大。而光伏发电的时变特性对并网带来了诸多问题,探索准确的预测方法仍是目前的重要工作。

[0003] 近年来,常用的短期光伏发电预测方法有神经网络法、支持向量机(Support Vector Machine,SVM)、时间序列法、回归分析法等。其中,SVM回归预测模型可以有效的克服常用方法预测值偏差过大、局部极值以及维数太高带来的计算问题。有现有技术利用小波阈值对光伏出力和辐照度去噪处理,结合多核SVM进行预测,极大的改善了光伏发电功率的预测精度。有现有技术还引入了集成学习的思想,利用Stacking算法改进SVM,将SVM分别作为Stacking算法的初、次级学习器分类预测,获得了良好的预测效果。有现有技术提出了加权马尔科夫链及修正的SVM预测方法,以均值-均方差对预测残差等级划分,权重定为残差序列标准化的自相关系数,残差未来的状态则使用马尔科夫链预测,最后将获得的SVM预测结果依据未来状态空间的阈值进行修正,仿真验证了该方法的有效性。

发明内容

[0004] 本发明的上述技术问题主要是通过下述技术方案得以解决的:

[0005] 一种基于HIMVO-SVM的短期光伏发电功率预测方法,其特征在于,包括

[0006] 步骤1、采集数据,包括太阳辐射强度、相对湿度、大气温度和光伏功率;

[0007] 步骤2、将采集的数据结合归一化,基于以下公式:

[0008] $X_i^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$, 其中, X_i 为原始数据序列, X_{\max} 和 X_{\min} 分别是原始数据中的最大值和最小值, X_i^* 是归一化后的序列;

[0009] 将归一化后的数据中选取训练集,剩下数据作为测试集;并定义 $\{(x_i, y_i) | i = 1, 2, \dots, n, x_i \in R^n, y_i \in R^n\}$, x_i 和 y_i 分别是训练样本的输入和输出;

[0010] 步骤3、设置HIMVO和SVM的参数;并基于SVM建模仿真,所述SVM建模模型基于以下公式:

[0011] 线性回归函数见式(1)用于拟合 (x_i, y_i) ;

[0012] $f(x) = w^T x + b \quad (1)$

[0013] 式中, w 是权重向量, b 是偏移量;

[0014] 构造非线性函数 $\varphi(x)$, 将训练数据映射到高维空间, 并构造回归估计函数;表达式如下:

[0015] $f(x) = w^T \varphi(x) + b \quad (2)$

[0016] 优化问题可以表示为：

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

[0017] $\begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (3)$

[0018] 式中，C是惩罚因子， ξ_i 、 ξ_i^* 是松弛变量， ε 是损失函数；

[0019] 优化问题的拉格朗日函数可通过拉格朗日乘子 μ_i 、 μ_i^* 、 α_i 和 α_i^* 表示如下：

$$\begin{aligned} L &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \mu_i^* \xi_i^* \\ [0020] &\quad + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^n \alpha_i^* (y_i - f(x_i) - \varepsilon - \xi_i^*) \end{aligned} \quad (4)$$

[0021] 对式(4)的w求偏导且令其为0,可得：

[0022] $w = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i \quad (5)$

[0023] 式(5)带入式(1)可得回归函数：

[0024] $f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i^T x + b \quad (6)$

[0025] 步骤4、利用HIMVO算法搜索SVM模型参数的最佳值,具体包括：

[0026] 步骤4.1,初始化与MVO和DE算法相关的参数:宇宙数n、最大迭代次数L、候选解维数d、决策变量矩阵大小VS、交叉概率PCR和比例因子F；

[0027] 步骤4.2,基于帐篷映射的混沌序列初始化宇宙群,计算粒子的适应值以获得当前最优个体和全局最优个体位置；

[0028] 步骤4.3,根据式(7)进行迭代,计算每个个体的适应度值,更新每个个体的位置；

[0029] $x_i^j = \begin{cases} w^* X_j + TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 < 0.5 \\ w^* X_j - TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 \geq 0.5 \\ x_i^j & r2 \geq WEP \end{cases} \quad (7)$

[0030] 步骤4.4,根据式(8)随机选择三个个体进行突变操作；

[0031] $W_i(t+1) = X_{R1}(t) + F[X_{R2}(t) - X_{R3}(t)] \quad (8)$

[0032] 式中, $W_i(t+1)$ 是由突变操作产生的新个体,R1、R2、R3是彼此不等的随机数,F表示随机比例因子,值为0到1；

[0033] 步骤4.5,根据式(9)进行交叉操作以获得新的突变个体,并计算其适应度值;交叉操作是在要变异的个体和新个体之间交换一些元素,以丰富个体的多样性;交叉方程式如下：

[0034] $U_{i,j}(t+1) = \begin{cases} W_{i,j}(t+1) & \text{if } [0, 1] \leq PCR \text{ or } j = j_{sd} \\ X_{i,j}(t) & \text{otherwise} \end{cases} \quad (9)$

[0035] 式中,PCR表示交叉概率,SD表示随机维度；

[0036] 步骤4.6,根据式(10)进行选择操作以获得最佳个体;适者生存的原则,选择方程

如式如下：

$$[0037] \quad X_i(t+1) = \begin{cases} U_i(t+1) & \text{if } f[U_i(t+1)] \leq f[X_i(t)] \\ X_i(t) & \text{otherwise} \end{cases} \quad (10)$$

[0038] 步骤4.7, 达到最大迭代次数, 则结束算法, 否则, 返回步骤4.3;

[0039] 步骤5、最后得到基于HIMVO-SVM短期光伏发电功率模型的预测结果, 即三种天气状况下的预测光伏发电功率。

[0040] 因此, 本发明具有如下优点:1、采用帐篷映射的混沌序列参与种群初始化;2、引入了一种非线性惯性权值下降策略, 平衡算法的全局搜索和局部优化能力;iii) 加入差分进化(Differential Evolution, DE) 算法搜索全局最优解。将所提出的HIMVO算法用于选择SVM的惩罚因子和核函数参数中。分别在雨天、多云、晴天的天气状况下, 对安徽某地区光伏电站输出功率进行预测, 预测结果与SVM、MVO-SVM方法所得结果对比, 验证了该方法有更好的预测精度和稳定性。

附图说明

[0041] 附图1是本发明的方法流程示意图。

[0042] 附图2是本发明实施例中雨天预测结果(9月25日)。

[0043] 附图3是本发明实施例中多云天气预测结果(9月28日)。

[0044] 附图4是本发明实施例中晴天预测结果(9月29日)。

具体实施方式

[0045] 下面通过实施例, 并结合附图, 对本发明的技术方案作进一步具体的说明。

[0046] 实施例:

[0047] 一、首先介绍本发明涉及的几种方法原理。

[0048] (一) 多元宇宙优化算法

[0049] MVO算法是一种新的元启发式算法。该算法来源于多元宇宙理论中的黑洞、白洞和虫洞的概念^[10]。算法的具体操作如下:假设

$$[0050] \quad U = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (1)$$

[0051] 式中, d是变量数, n是宇宙数。

$$[0052] \quad x_i^j = \begin{cases} x_k^j & r1 < NI(U_i) \\ x_i^j & r1 > NI(U_i) \end{cases} \quad (2)$$

[0053] 式中, x_i^j 是第i个宇宙的第j个变量, x_k^j 是根据轮盘机制选择的第k个宇宙的j个变量。r1是0到1之间的随机数, U_i 是第i个宇宙的位置, $NI(U_i)$ 是第i个宇宙的标准化膨胀率。这是假设在每个宇宙和最优宇宙之间存在虫洞, 从而使每个宇宙中的局部变化能够通过虫洞来增加宇宙的膨胀率。这种机制用式(3)表示:

$$[0054] \quad x_i^j = \begin{cases} X_j + TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 < 0.5 \\ X_j - TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 \geq 0.5 \quad r2 < WEP \\ x_i^j & r2 \geq WEP \end{cases} \quad (3)$$

[0055] 式中, X_j 是当前的最优宇宙, ub_j 和 lb_j 是第 j 变量的上下限, $r2$ 、 $r3$ 、 $r4$ 是介于 0 和 1 之间的随机数。WEP 代表宇宙中虫洞的比例, 在迭代中数值线性增加。TDR 表示物体在最佳宇宙附近通过虫洞转换的距离。两者的方程式如下:

$$[0056] \quad WEP = WEP_{\min} + l * \left(\frac{WEP_{\max} - WEP_{\min}}{L} \right) \quad (4)$$

$$[0057] \quad TDR = 1 - \frac{l^p}{L^p} \quad (5)$$

[0058] 式中, WEP_{\max} 和 WEP_{\min} 分别是 WEP 值的上下限, $WEP_{\min} = 0.2$, $WEP_{\max} = 1.1$ 是当前迭代次数, L 是最大迭代次数, p 是迭代开发的准确性, 数值为 6。

[0059] (二) 混合改进的多元宇宙优化算法

[0060] 传统的启发式智能算法通常通过随机生成方法初始化粒子。当搜索空间维数较高或搜索种群数较小时, 随机生成方法生成的初始种群分布均匀性较差, 不能满足有效空间搜索。混沌是一种非线性现象, 对初始条件敏感, 其自身运动具有随机性, 规则性和非重复遍历性的特点。这些特征使粒子能够实现更好的空间分布, 摆脱局部优化, 并加速算法的收敛速度。因此采用基于帐篷映射的混沌序列参与种群初始化, 其表达式如式 (6) 所示。

$$[0061] \quad f(x) = \begin{cases} 2x & 0 \leq x \leq 0.5 \\ 2(1-x) & 0.5 < x \leq 1 \end{cases} \quad (6)$$

[0062] 伯努利变换后帐篷映射的表达式如下^[10]:

$$[0063] \quad f(x) = \begin{cases} 2x & 0 \leq x \leq 0.5 \\ 2x - 1 & 0.5 < x \leq 1 \end{cases} \quad (7)$$

[0064] 在 MVO 算法迭代开始时, 当前的最优宇宙个体通常远离全局最优解, 因此需要进行全局搜索。在迭代结束时, 宇宙群体中代际信息遗传的累积效应使得当前宇宙逐渐接近全局最优解。此时, 需要充分利用算法的局部挖掘能力。文 [11] 在正弦余弦算法的位置矢量更新中引入了线性降权, 结果表明, 该策略能够有效地平衡算法的全局搜索和局部优化能力。在 MVO 算法的位置矢量更新中, 引入了一种非线性惯性权值下降策略。改进公式如下:

$$[0065] \quad x_i^j = \begin{cases} w * X_j + TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 < 0.5 \\ w * X_j - TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 \geq 0.5 \quad r2 < WEP \\ x_i^j & r2 \geq WEP \end{cases} \quad (8)$$

[0066] 式中, 惯性权重 w 表示如下:

$$[0067] \quad w = w_{\min} + (w_{\max} - w_{\min}) \sin\left(\frac{\pi l}{(2L)} + \pi\right) + 1 \quad (9)$$

[0068] 式中, w_{\max} 和 w_{\min} 分别为惯性权重的最大值和最小值。根据正弦函数在 π 到 1.5π 区间内非线性递减的性质, w 随着迭代次数的增加而逐渐减小。经过多次测试, 当 $w_{\max} = 0.7$ 和 $w_{\min} = 0.2$ 时, 算法的优化效果最佳。通过分析式 (8)、(9) 可知, 为了保证算法早期的全局搜索能力, 惯性权重值较大。随着迭代的进行, 惯性权重逐渐减小, 算法快速收敛到全局最优解, 搜

索范围逐渐缩小,有利于当前最优解充分搜索全局最优解,提高算法的局部优化能力。

[0069] DE算法是一种模拟生物进化的启发式全局搜索方法,用于搜索全局最优解。该算法主要由变异,交叉和选择组成。

[0070] (1)通过在群体中的任何两个载体之间产生载体差异,然后与第三个个体求和以产生新变体来进行突变操作。变异方程式如下:

$$W_i(t+1) = X_{R1}(t) + F [X_{R2}(t) - X_{R3}(t)] \quad (10)$$

[0072] 式中, $W_i(t+1)$ 是由突变操作产生的新个体,R1、R2、R3是彼此不等的随机数,F表示随机比例因子,值为0到1。

[0073] (2)交叉操作是在要变异的个体和新个体之间交换一些元素,以丰富个体的多样性。交叉方程式如下:

$$U_{i,j}(t+1) = \begin{cases} W_{i,j}(t+1) & \text{if } [0, 1] \leq PCR \text{ or } j = j_{sd} \\ X_{i,j}(t) & \text{otherwise} \end{cases} \quad (11)$$

[0075] 式中,PCR表示交叉概率,SD表示随机维度。

[0076] (3)适者生存的原则,选择方程如式如下:

$$X_i(t+1) = \begin{cases} U_i(t+1) & \text{if } f[U_i(t+1)] \leq f[X_i(t)] \\ X_i(t) & \text{otherwise} \end{cases} \quad (12)$$

[0078] HIMVO算法的流程如下:

[0079] 步骤1,初始化与MVO和DE算法相关的参数:宇宙数n、最大迭代次数L、候选解维度d、决策变量矩阵大小VS、交叉概率PCR和比例因子F。

[0080] 步骤2,基于帐篷映射的混沌序列初始化宇宙群,计算粒子的适应值以获得当前最优个体和全局最优个体位置。

[0081] 步骤3,根据式(8)进行迭代,计算每个个体的适应度值,更新每个个体的位置。

[0082] 步骤4,根据式(10)随机选择三个个体进行突变操作。

[0083] 步骤5,根据式(11)进行交叉操作以获得新的突变个体,并计算其适应度值。

[0084] 步骤6,根据式(12)进行选择操作以获得最佳个体。

[0085] 步骤7,达到最大迭代次数,则结束算法,否则,返回步骤3。

[0086] (三)支持向量机

[0087] SVM是一种基于统计量和结构风险最小化理论相结合的监督学习算法。它是模式识别和回归领域的一个重要工具用于解决高维、非线性和小样本问题的预测。SVM模型的原理如下:

[0088] 给定数据集: $\{(x_i, y_i) | i=1, 2, \dots, n, x_i \in \mathbb{R}^n, y_i \in \mathbb{R}\}$, x_i 和 y_i 分别是训练样本的输入和输出。线性回归函数见式(13)用于拟合 (x_i, y_i) 。

$$f(x) = w^T x + b \quad (13)$$

[0090] 式中,w是权重向量,b是偏移量。

[0091] 构造非线性函数 $\varphi(x)$,将训练数据映射到高维空间,并构造回归估计函数。表达式如下:

$$f(x) = w^T \varphi(x) + b \quad (14)$$

[0093] 优化问题可以表示为:

$$\begin{aligned} & \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ [0094] \quad & s.t. \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (15) \end{aligned}$$

[0095] 式中,C是惩罚因子, ξ_i 、 ξ_i^* 是松弛变量, ε 是损失函数。

[0096] 优化问题的拉格朗日函数可通过拉格朗日乘子 μ_i 、 μ_i^* 、 α_i 和 α_i^* 表示如下:

$$\begin{aligned} [0097] \quad L = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \mu_i^* \xi_i^* \\ & + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^n \alpha_i^* (y_i - f(x_i) - \varepsilon - \xi_i^*) \end{aligned} \quad (16)$$

[0098] 对式(16)的w求偏导且令其为0,可得:

$$[0099] \quad w = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i \quad (17)$$

[0100] 式(17)带入式(13)可得回归函数:

$$[0101] \quad f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i^T x + b \quad (18)$$

[0102] SVM模型的回归性能很大程度上依赖于惩罚因子C和核函数参数g的选择,这将极大地改变SVM的预测性能。因此,本文采用HIMVO算法来选择SVM参数,SVM的核函数选取应用最广泛的径向基函数。

[0103] 二、下面介绍本发明基于HIMVO算法优化SVM的短期光伏发电功率预测方法的具体步骤,包括:

[0104] 步骤1、采集数据,包括太阳辐射强度、相对湿度、大气温度和光伏功率;

[0105] 步骤2、将采集的数据结合归一化,基于以下公式:

[0106] $X_i^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$, 其中, X_i 为原始数据序列, X_{\max} 和 X_{\min} 分别是原始数据中的最大值和最小值, X_i^* 是归一化后的序列;

[0107] 将归一化后的数据中训练集,剩下数据作为测试集(具体是:测试集是选取晴天、多云和雨天三种天气类型各一天,即为预测日,预测日当日的太阳辐射强度、相对湿度、大气温度和光伏功率构成测试集;训练样本则按照预测日的类型分别选取相近的若干天,这里的相似日是指相似的天气类型,即预测日的三种天气类型,最接近是指每种天气类型与预测日的日期最接近的。比如说预测日的晴天是8月25号,而这个月8月25号以前有6个晴天,选择最接近8月25号的5个晴天作为预测日晴天类型的训练样本);并定义 $\{(x_i, y_i) | i = 1, 2, \dots, n, x_i \in \mathbb{R}^n, y_i \in \mathbb{R}^n\}$, x_i 和 y_i 分别是训练样本的输入和输出;

[0108] 步骤3、设置HIMVO和SVM的参数;并基于SVM建模仿真,所述SVM建模模型基于以下公式:

[0109] 线性回归函数见式(1)用于拟合 (x_i, y_i) ;

$$[0110] \quad f(x) = w^T x + b \quad (1)$$

[0111] 式中,w是权重向量,b是偏移量;

[0112] 构造非线性函数 $\varphi(x)$,将训练数据映射到高维空间,并构造回归估计函数;表达式如下:

[0113] $f(x) = w^T \varphi(x) + b \quad (2)$

[0114] 优化问题可以表示为:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

[0115]
$$\begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (3)$$

[0116] 式中,C是惩罚因子, ξ_i 、 ξ_i^* 是松弛变量, ε 是损失函数;

[0117] 优化问题的拉格朗日函数可通过拉格朗日乘子 μ_i 、 μ_i^* 、 a_i 和 α_i^* 表示如下:

[0118]
$$\begin{aligned} L = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \mu_i^* \xi_i^* \\ & + \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^n \alpha_i^* (y_i - f(x_i) - \varepsilon - \xi_i^*) \end{aligned} \quad (4)$$

[0119] 对式(4)的w求偏导且令其为0,可得:

[0120] $w = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i \quad (5)$

[0121] 式(5)带入式(1)可得回归函数:

[0122] $f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i^T x + b \quad (6)$

[0123] 步骤4、利用HIMVO算法搜索SVM模型参数的最佳值,具体包括:

[0124] 步骤4.1,初始化与MVO和DE算法相关的参数:宇宙数n、最大迭代次数L、候选解维度d、决策变量矩阵大小VS、交叉概率PCR和比例因子F;

[0125] 步骤4.2,基于帐篷映射的混沌序列初始化宇宙群,计算粒子的适应值以获得当前最优个体和全局最优个体位置;

[0126] 步骤4.3,根据式(7)进行迭代,计算每个个体的适应度值,更新每个个体的位置;

[0127]
$$x_i^j = \begin{cases} w^* X_j + TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 < 0.5 \\ w^* X_j - TDR * ((ub_j - lb_j) * r4 + lb_j) & r3 \geq 0.5 \\ x_i^j & r2 \geq WEP \end{cases} \quad (7)$$

[0128] 步骤4.4,根据式(8)随机选择三个个体进行突变操作;

[0129] $W_i(t+1) = X_{R1}(t) + F[X_{R2}(t) - X_{R3}(t)] \quad (8)$

[0130] 式中, $W_i(t+1)$ 是由突变操作产生的新个体,R1、R2、R3是彼此不等的随机数,F表示随机比例因子,值为0到1;

[0131] 步骤4.5,根据式(9)进行交叉操作以获得新的突变个体,并计算其适应度值;交叉操作是在要变异的个体和新个体之间交换一些元素,以丰富个体的多样性;交叉方程式如下:

[0132]
$$U_{i,j}(t+1) = \begin{cases} W_{i,j}(t+1) & \text{if } [0, 1] \leq PCR \text{ or } j = j_{sd} \\ X_{i,j}(t) & \text{otherwise} \end{cases} \quad (9)$$

[0133] 式中,PCR表示交叉概率,sd表示随机维度;

[0134] 步骤4.6,根据式(10)进行选择操作以获得最佳个体;适者生存的原则,选择方程如式如下:

$$[0135] X_i(t+1) = \begin{cases} U_i(t+1) & \text{if } f[U_i(t+1)] \leq f[X_i(t)] \\ X_i(t) & \text{otherwise} \end{cases} \quad (10)$$

[0136] 步骤4.7,达到最大迭代次数,则结束算法,否则,返回步骤4.3;

[0137] 步骤5、最后得到基于HIMVO-SVM短期光伏发电功率模型的预测结果,即三种天气状况下的预测光伏发电功率。

[0138] 三、以下是采用上述方法的具体实施例。

[0139] 在三种天气类型下:晴天、多云、雨天,采用上节所提模型对光伏功率进行预测,预测结果与MVO-SVM、SVM方法的预测结果对比。数据为安徽省某地市2018年8-9月份之间数据,采样间隔为15min,采样点时段为6:30-17:30,即每天45个时间点,选取预测日为:9月25日(雨天),9月28日(多云),9月29日(晴天)。训练样本则按照预测日的类型分别选取相近的5天。按照上述三种方法对各种天气类型分别进行预测获得的预测结果见图2-图4。

[0140] 雨天太阳能电池板上的光强较弱、大气温度较低、相对湿度较高,光伏系统的发电效率较低,各种气象因素变化较快,导致光伏发电量波动较大,难以精准预测。图2中可以看出本文所提HIMVO-SVM预测模型的预测曲线更符合实际负荷变化曲线。

[0141] 在多云天气下,天空中的云量变化较快,太阳电池板上的光强变化较大,导致输出功率曲线的规律性较弱,波动较大。图3中可以看出三种模型预测轨迹大致相同,但是从图中输出功率较高的点可以看出,HIMVO-SVM预测曲线与实际输出功率曲线更加接近晴天光伏输出功率波动较小,从图4中可以看出,三种模型在上午和下午时段的预测效果都很好,但在早上、中午、晚上SVM模型和MVO-SVM模型的预测误差明显大于HIMVO-SVM。

[0142] 计算上述三种模型在三种天气类型下的平均绝对百分误差(Mean Absolute Percentage Error,MAPE),误差统计结果如下表1:

[0143] 表1三种模型误差计算结果

	天气 类型	MAPE/%		
		SVM	MVO-SVM	HIMVO-SVM
[0144]	雨天	17.75	14.75	10.30
	多云	11.79	9.35	6.69
	晴天	10.71	8.84	5.30

[0145] 在表1中,在三种天气类型中,HIMVO-SVM模型具有最小的MAPE值。HIMVO-SVM模型在三种天气类型下的MAPE值分别为10.30%、6.69%和5.30%。与其它三种模型相比,MAPE值分别降低至少0.0026、0.0030和0.0012,MAPE值分别降低至少4.45%、2.66%和3.54%,这表明,在不同天气类型下,HIMVO-SVM模型具有较高的预测精度和稳定性。

[0146] 本发明针对SVM参数的选取问题,提出了一种基于HIMVO-SVM的短期光伏发电功率预测模型。针对传统MVO算法的不足,提出HIMVO算法提升其局部优化能力,并用于SVM的惩罚因子和核函数参数的选取。在不同天气类型下进行仿真实验,与SVM、MVO-SVM方法预测结

果对比，突显了本文方法优越的预测性能和稳定性，为研究光伏发电功率预测提供一定的参考意义。

[0147] 本文中所描述的具体实施例仅仅是对本发明精神作举例说明。本发明所属技术领域的技术人员可以对所描述的具体实施例做各种各样的修改或补充或采用类似的方式替代，但并不会偏离本发明的精神或者超越所附权利要求书所定义的范围。

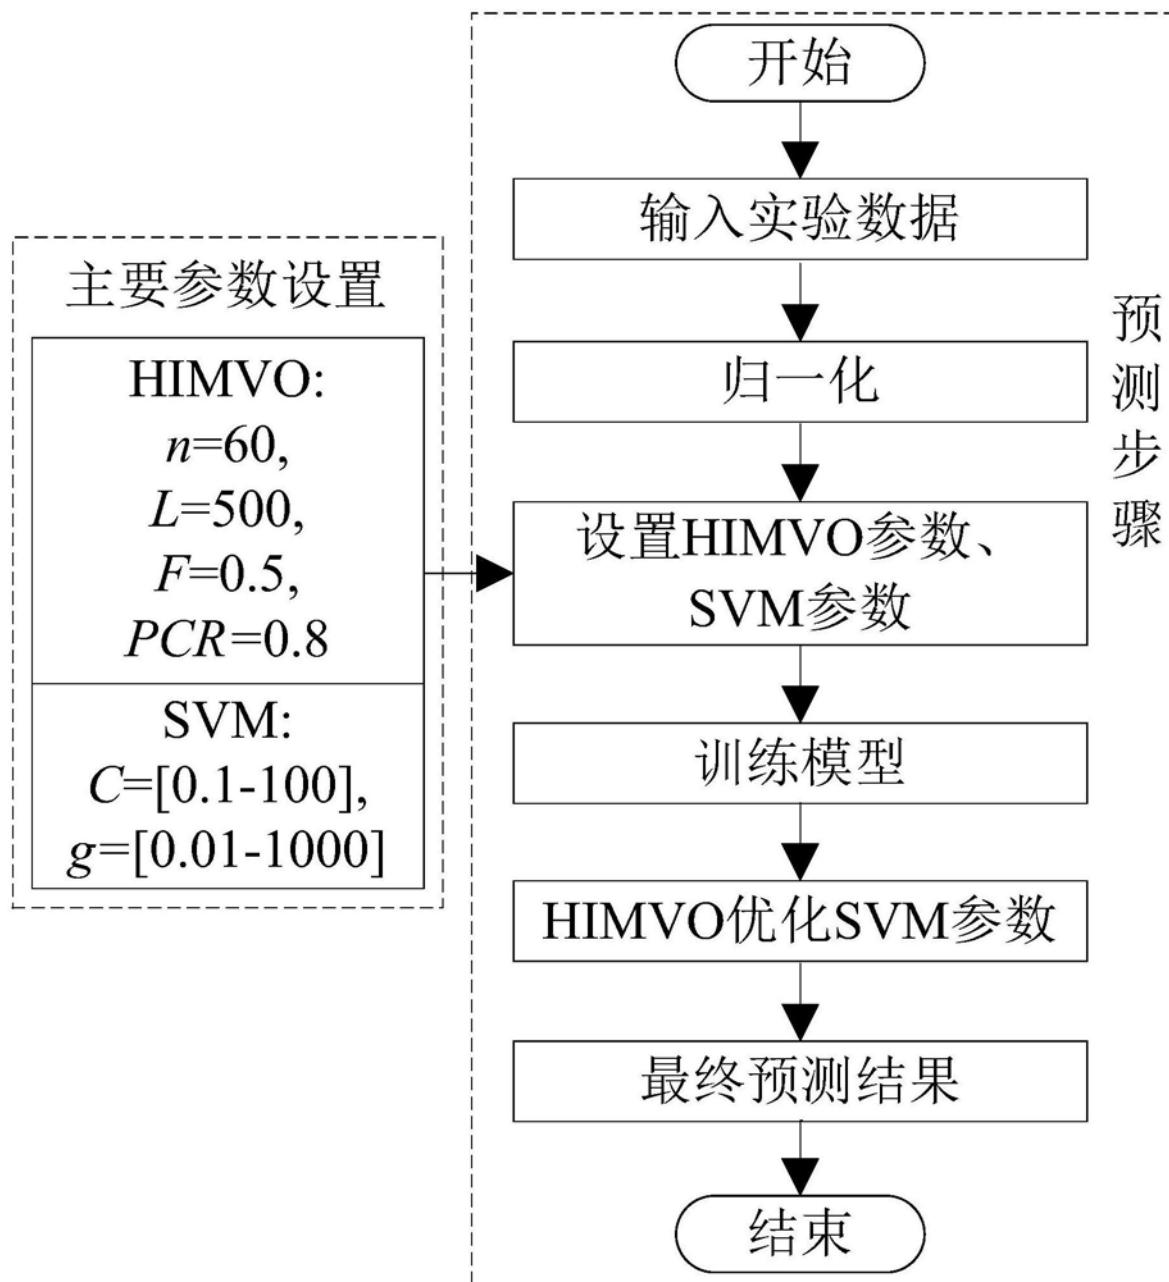


图1

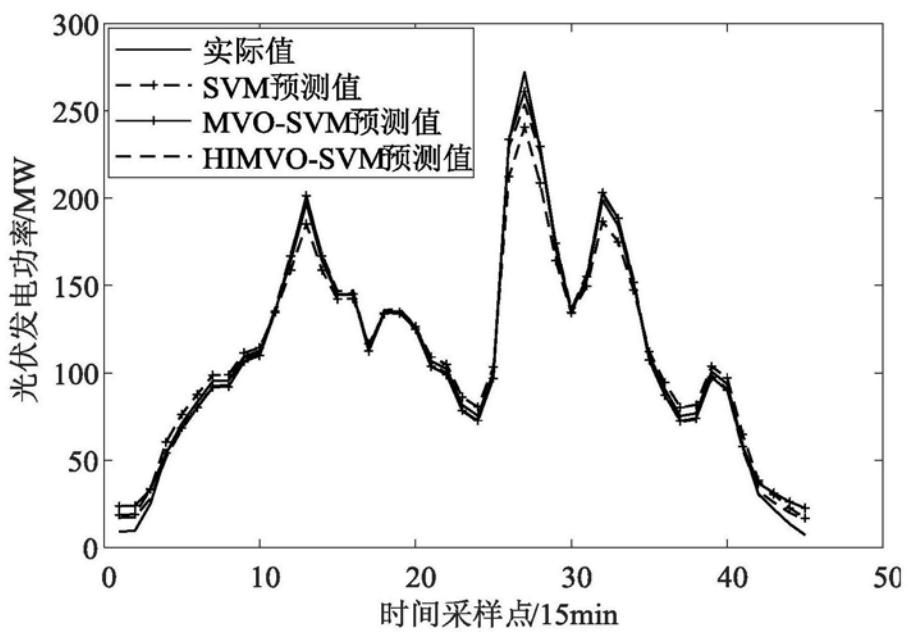


图2

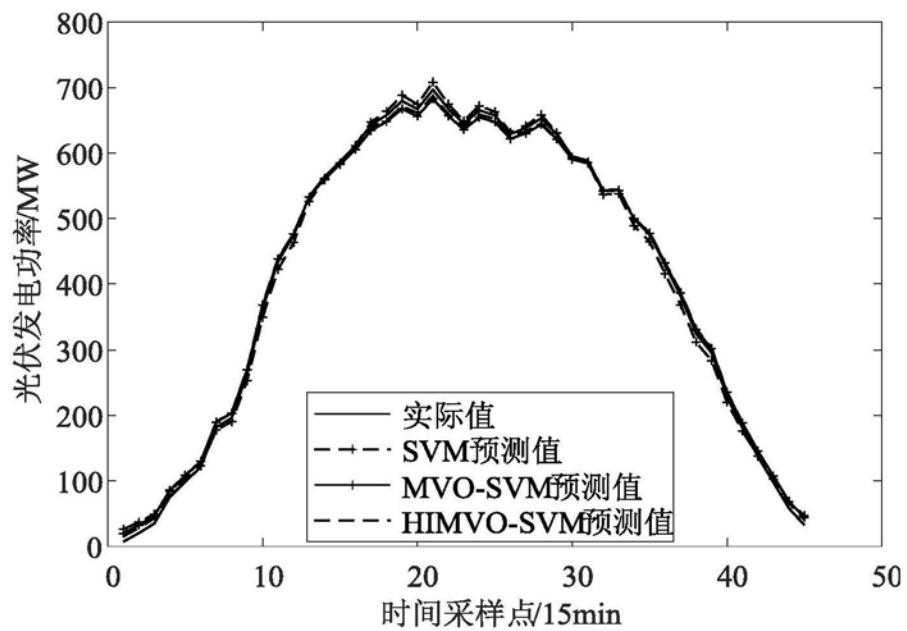


图3

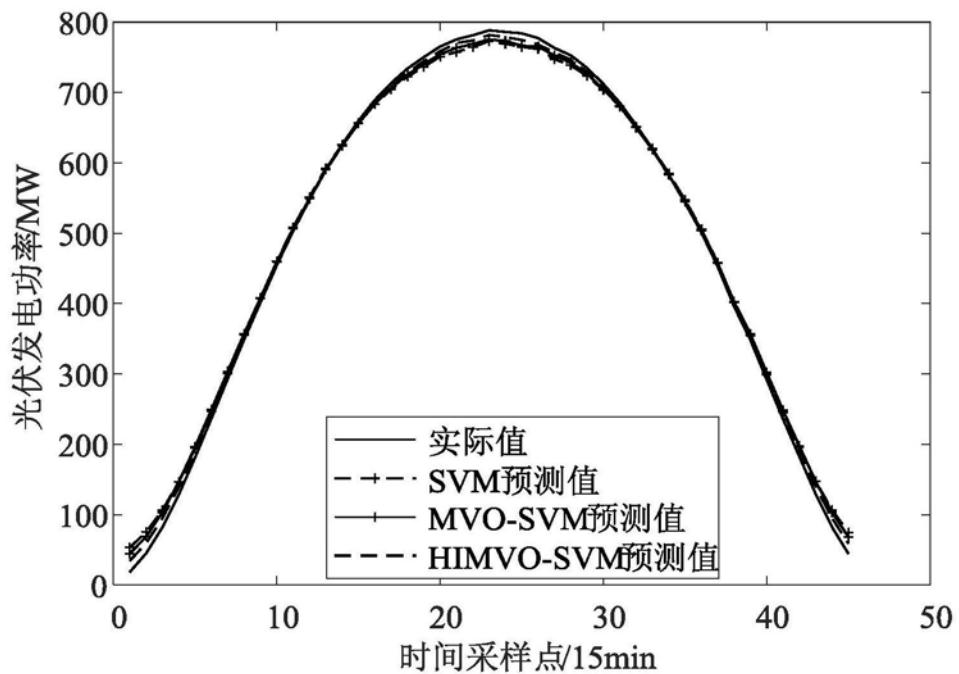


图4