



(12)发明专利申请

(10)申请公布号 CN 106920006 A

(43)申请公布日 2017. 07. 04

(21)申请号 201710098913.5

(22)申请日 2017.02.23

(71)申请人 北京工业大学

地址 100124 北京市朝阳区平乐园100号

(72)发明人 王普 武翠霞 高学金 付龙晓

(74)专利代理机构 北京思海天达知识产权代理有限公司 11203

代理人 张慧

(51)Int. Cl.

G06Q 10/04(2012.01)

F24F 11/00(2006.01)


权利要求书3页 说明书9页 附图1页

(54)发明名称

一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法

(57)摘要

本发明公开一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法,包括:获取训练数据,将数据进行标准化,利用改进的人群搜索算法对最小二乘支持向量机进行参数寻优,建立预测模型;采集实时测量数据进行标准化,输入到预测模型进行预测,最后逆标准化输出预测能耗值。本发明实现了ISOA-LSSVM的地铁站空调系统能耗预测方法,其中改进的人群搜索算法采用高斯隶属函数表示搜索步长的模糊变量,减少了迭代次数,增加了模型预测精度;预动方向采用个体最优适应度值和当前个体的适应度值比较得出,可以很好的代表当前个体的预动行为,同时提高了迭代速度。



1. 一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法,其特征在于,包含以下步骤:

步骤(1):获取训练数据

采集地铁站空调系统运行中实时测得的能耗相关变量和下一时段的能耗变量形成训练数据,数据采样表示形式如下:

$$X = (x_1, x_2, \dots, x_n) \quad (1)$$

$$Y = (y_1) \quad (2)$$

其中, $x_1, x_2, \dots, x_n$ 表示系统运行过程中在线可实时测量的 n 个测量变量,包括当前的时刻、送风温度设定值、回风温度设定值、冷机出水温度、室外温度,当前时刻的送风温度、回风温度、当前一个确定时段的能耗; y_1 表示空调系统运行过程中下一时段所测量的能耗变量,经过多次采样形成建模数据集 $D = \{(X_{j,n}, Y_j)\}$, $j = 1, 2, L, p$,其中 p 表示样本个数; n 表示模型输入变量的维数;

步骤(2):归一标准化处理

将采集的输入数据集 $X_{p,n}$ 和输出数据集 Y_p 进行归一化,处理后的数据为 $X_{g,p,n} = (x_{g1}, x_{g2}, \dots, x_{gn})$ 和 $Y_{g,p} = (y_g)$;

$$x_{gi} = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (3)$$

$$y_g = \frac{y_1 - y_{\min}}{y_{\max} - y_{\min}} \quad (4)$$

式(3)-(4)中, $x_{i,\min}$ 和 $x_{i,\max}$ 分别为 X 中 x_i 的最小最大值, $y_{\min}$ 和 $y_{\max}$ 分别为 Y 中 y_1 的最小最大值, x_{gi}, x_i, y_g 为 p 维列向量, $i = 1, 2, \dots, n$;

步骤(3):初始化人群搜索算法SOA和最小二乘支持向量机LSSVM的参数;

步骤(4):根据上一步确定的种群寻优范围,随机产生SOA中的初始种群 $\text{Swarm}(i, :) = [\gamma_i, \sigma_i]$, $i = 1, 2, L, s$,根据式(5)-(7),每一个种群对应一个LSSVM模型,因此建立 s 个初始的LSSVM模型,每个模型建立方法如下:

$$\hat{Y}_{g,j} = \sum_{j=1}^p a_j K(X_{g,j^*n}, X_{g,n}^*) + b \quad (5)$$

$$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} K + \gamma^{-1}I & 1_{p \times 1} \\ 1_{p \times 1}^T & 0 \end{bmatrix}^{-1} \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (6)$$

$$K(X_{g,j^*n}, X_{g,n}^*) = \exp\left(-\frac{\|X_{g,j^*n} - X_{g,n}^*\|^2}{2\sigma^2}\right) \quad (7)$$

式(5)-(7)中, X_{g,j^*n} 为第 j 个样本的输入向量, $X_{g,n}^*$ 为建模输入数据集中每个测量点的均值组成的行向量, $K(X_{g,j^*n}, X_{g,n}^*)$ 为高斯核函数, σ 为高斯核参数, γ 为正则化参数, a_j 为LSSVM中的拉格朗日乘子, $a = [a_1, a_2, L, a_p]^T$, b 为一个偏置数, $y = [Y_{g,1}, Y_{g,2}, L, Y_{g,p}]^T$, $1_{p \times 1} = [1, 1, L, 1]^T$ 为 p 维列向量, I 为 $p \times p$ 的单位矩阵,

计算每一个模型的适应度值,适应度值由模型预测的平均相对误差来计算,计算公式为式(8):

$$F = \frac{1}{P} \sum_{j=1}^P \left| \frac{Y_{g,j} - \hat{Y}_{g,j}}{Y_{g,j}} \right| \times 100\% \quad (8)$$

式中, $Y_{g,j}$ 为第 j 个样本值; $\hat{Y}_{g,j}$ 为第 j 个样本的模型输出值, 由预测模型计算获得, 适应度函数 F 为 LSSVM 中正则化参数 γ 和核参数 σ 的函数,

步骤 (5): 利用改进的人群搜索算法 ISOA 进行迭代寻优, 建立新的 LSSVM 预测模型,

步骤 (6): 在线测量和处理数据, 具体步骤为:

步骤 (6.1): 在线采集新的测量数据 X_{new} ;

步骤 (6.2): 将采集到的新数据 X_{new} 进行标准化得到 X_{gnew} ;

步骤 (7): 将 X_{gnew} 输入到已建立好的 LSSVM 模型中, 得到预测输出 Y_{gnew} ;

步骤 (8): 将 Y_{gnew} 进行逆标准化, 得到预测值 Y_{new} , 逆标准化的具体公式为式 (19):

$$Y_{\text{new}} = y_{\min} + Y_{\text{gnew}} \cdot (y_{\max} - y_{\min}) \quad (19)$$

步骤 (9): 若预测过程还需继续, 则重复步骤 (6) 至 (8)。

2. 如权利要求 1 所述的基于 ISOA-LSSVM 的地铁站空调系统能耗预测方法, 其特征在于, 步骤 (5) 为: 令迭代次数 $t=1$, 具体步骤为:

步骤 (5.1): 判断迭代的条件, 如果终止条件满足的话, 输出寻优结果, 进入步骤 (5.7); 否则进入下一步 (5.2), 设置终止迭代条件为: 迭代次数达到最大, 或者全局最优适应度值小于确定的最小适应度值;

步骤 (5.2): 确定搜索方向, 根据个体最佳和全局最佳确定出利己方向 $\vec{d}_{i,ego}(t)$ 、利他方向 $\vec{d}_{i,alt}(t)$ 和预动方向 $\vec{d}_{i,pro}(t)$, 计算如下式 (9) - (11):

$$\vec{d}_{i,ego}(t) = \vec{p}_{i,best}(t) - \vec{x}_i(t) \quad (9)$$

$$\vec{d}_{i,alt}(t) = \vec{g}_{i,best}(t) - \vec{x}_i(t) \quad (10)$$

$$\vec{d}_{i,pro}(t) = \begin{cases} \vec{d}_{ij}(t), & F_{p_{i,best}} < F_{x_i(t)} \\ -\vec{d}_{ij}(t), & F_{p_{i,best}} \geq F_{x_i(t)} \end{cases} \quad (11)$$

采用 3 个方向随机加权几何平均确定搜索方向 $\vec{d}_{ij}(t)$, 如下式 (12):

$$\vec{d}_{ij}(t) = \text{sign}(\omega \vec{d}_{i,pro}(t) + \varphi_1 \vec{d}_{i,ego}(t) + \varphi_2 \vec{d}_{i,alt}(t)) \quad (12)$$

$$\omega = W_{\max} - t \cdot \frac{W_{\max} - W_{\min}}{t_{\max}} \quad (13)$$

式 (9) - (13) 中 $\vec{x}_i(t)$ 为第 t 次迭代中第 i 个搜寻个体的位置; $\vec{p}_{i,best}(t)$ 为第 i 个搜寻个体到目前为止经历过的最佳位置; $\vec{g}_{i,best}(t)$ 为第 i 个搜寻个体所在领域的集体历史最佳位置; $F_{p_{i,best}}$ 为 $\vec{p}_{i,best}(t)$ 位置的适应度值; $F_{x_i(t)}$ 为 $\vec{x}_i(t)$ 位置的适应度值; $\text{sign}()$ 为符号函数; φ_1 和 φ_2 为 $[0, 1]$ 内符合均匀分布的随机常数; ω 为惯性权值, 随进化代数的增加从最大权值 $W_{\max}$

$=0.9$ 线性递减至最小权值 $w_{\min}=0.1$; t 和 $t_{\max}$ 分别为当前迭代次数和最大迭代次数; $\vec{d}_{ij}(t)$ 为第 t 次迭代中第 i 个搜寻个体的第 j 维搜索方向, 其中 $\vec{d}_{ij}(t) \in \{-1, 0, 1\}$ ($i=1, 2, L, s; j=1, 2, L, D$)。 $d_{ij}(t)=1$ 表示搜寻个体 i 沿着 j 维坐标的正方向前进; $d_{ij}(t)=-1$ 表示搜寻个体 i 沿着 j 维坐标的反方向前进; $d_{ij}(t)=0$ 表示搜寻个体 i 在第 j 维保持静止不动;

步骤(5.3): 确定搜索步长

采用如下式(14、15)的高斯隶属函数表示搜索步长的模糊变量可以很好的将第 i 个搜寻个体的适应度值非线性的模糊到 $[0.0111, 0.95]$ 之间,

$$u_i = \exp(-(fitness(i) - MinFit) / 2\delta_{ij}^2) \quad (14)$$

$$u_{ij} = u_i + \text{rand} \cdot (1 - u_i), j=1, L, D \quad (15)$$

其中, u_i 为第 i 个搜寻个体的步长模糊变量; $fitness(i)$ 为第 i 个搜寻个体的适应度值; $MinFit$ 为目标最小适应度值; u_{ij} 为由不确定性推理得出的第 i 个搜寻个体的第 j 维步长的模糊变量隶属度; D 为搜寻个体的维数; $\vec{\delta}_{ij}$ 为高斯隶属函数参数, 如下式(16):

$$\vec{\delta}_{ij} = \omega \cdot \left| \vec{x}_{\min} - \vec{x}_{\max} \right| \quad (16)$$

因此步长计算公式如下式(17):

$$\alpha_{ij} = \delta_{ij} \sqrt{-\ln(u_{ij})} \quad (17)$$

式(16)和(17)中, α_{ij} 为计算的搜索步长; $\vec{x}_{\min}$ 和 $\vec{x}_{\max}$ 分别为同一种群中的最小和最大适应度值的位置; ω 为惯性权值, 范围为 $[0.1, 0.9]$;

步骤(5.4): 位置更新

在确定出的搜索方向和步长后, 即可对每一个搜寻个体进行位置更新, 公式如下式(18):

$$\begin{cases} \Delta x_{ij}(t+1) = \alpha_{ij}(t) d_{ij}(t) \\ x_{ij}(t+1) = x_{ij}(t) + \Delta x_{ij}(t+1) \end{cases} \quad (18)$$

其中, $\Delta x_{ij}(t+1)$ 为第 $t+1$ 次搜寻个体相对于第 t 次的位置增量, $x_{ij}(t+1)$ 为搜寻个体的第 $t+1$ 次位置, $x_{ij}(t)$ 为搜寻个体的第 t 次位置, $\alpha_{ij}(t)$ 为搜索步长, $d_{ij}(t)$ 为搜索方向;

步骤(5.5): 由式(5)-(7)更新LSSVM模型, 由式(8)计算适应度值, 通过比较, 进行个体最优更新和群体最优更新;

步骤(5.6): 令 $t=t+1$, 返回步骤(5.1);

步骤(5.7): 根据寻优结果, 建立新的LSSVM预测模型, 迭代结束。

3. 如权利要求1所述的基于ISOA-LSSVM的地铁站空调系统能耗预测方法, 其特征在于, 所述人群搜索算法的参数包括: 种群规模 s , 最大迭代次数 $iter_{\max}$, 最小适应度值 $MinFit$, 初始的利己方向 $\vec{d}_{i,ego}$ 、利他方向 $\vec{d}_{i,alt}$ 和预动方向 $\vec{d}_{i,pro}$, 初始的搜索方向 $\vec{d}_{ij}(t)$ 、搜索步长 α_{ij} 、高斯隶属参数 δ_{ij} ; 最小二乘支持向量机需要初始的参数包括: 正则化参数 γ 和核参数 σ 的寻优范围分别为 $[\gamma_{\min}, \gamma_{\max}]$ 和 $[\sigma_{\min}, \sigma_{\max}]$ 。

一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法

技术领域

[0001] 本发明属于暖通空调能耗建模领域,尤其涉及在地铁站空调系统中应用基于ISOA-LSSVM的地铁站空调系统能耗预测方法,用于预测短时间段内的能耗值。

背景技术

[0002] 地铁站通风空调系统是整个地铁系统的能耗大户,占比为30%-50%。因此,目前空调系统的运行要在温度、湿度等各项指标达到控制要求的同时降低系统的运行能耗。然而,由于空调系统中影响能耗的因素众多,并且各因素之间的关系复杂,系统呈现大滞后性,能耗模型很难建立准确,因此对地铁站空调系统,建立出精确的能耗预测模型是节能运行和优化控制的基础和前提。

[0003] 目前对于空调能耗常用的预测算法有时间序列算法、人工神经网络和支持向量回归机算法等。比如,何厚建等利用神经网络方法辨识中央空调系统的静态模型。赵廷法等人用回归的方法对VAV中央空调建能耗模型;Ioan等人利用最小二乘回归的方法,建立控制变量(冷却水温度、室内温度)和非控制变量(太阳热辐射、室外温度)跟能耗的表达式。Hyun等人利用改进的实数编码的遗传算法(GA)算法优化的最小二乘支持向量机(LSSVM)对建筑的能耗进行预测,但是计算速度偏慢。以上的研究虽然都取得了一定的成果,但是大多针对中央空调的研究,而地铁站空调系统有其独有的特点,因此迫切需要对地铁站空调系统的能耗模型研究。

[0004] LSSVM算法相对于神经网络来说,需要确定的参数较少,模型的泛化能力强,不宜陷入局部最小值。近些年一些智能优化算法应用到LSSVM中,为了解决传统LSSVM中的网格搜索算法速度慢的问题,其中人群搜索算法是相对较优的一种新型智能算法,但是其在迭代计算过程中还是会存在一定的改进空间,使得计算速度更快,因此建立一种基于ISOA-LSSVM算法并考虑地铁的独有特性建立的能耗预测模型,对研究地铁站空调系统的节能优化控制的理论研究具有重要的意义。

发明内容

[0005] 本发明针对地铁站空调系统的多变量耦合、大滞后性和能耗模型难以建立的问题,提出一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法,解决了传统网格搜索LSSVM的计算量大问题,提高了模型的预测速度和精度。

[0006] 为实现上述目的,本发明采用如下的技术方案

[0007] 一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法包含以下步骤:

[0008] 步骤(1):获取训练数据

[0009] 采集地铁站空调系统运行中实时测得的能耗相关变量和下一时段的能耗变量形成训练数据,数据采样表示形式如下:

[0010] $X = (x_1, x_2, \dots, x_n)$ (1)

[0011] $Y = (y_1)$ (2)

[0012] 其中, $x_1, x_2, \dots, x_n$ 表示系统运行过程中在线可实时测量的 n 个测量变量, 包括当前的时刻、送风温度设定值、回风温度设定值、冷机出水温度、室外温度, 当前时刻的送风温度、回风温度、当前一个确定时段的能耗; y_1 表示空调系统运行过程中下一时段所测量的能耗变量, 经过多次采样形成建模数据集 $D = \{(X_{jn}, Y_j)\}$, $j = 1, 2, L, p$, 其中 p 表示样本个数; n 表示模型输入变量的维数;

[0013] 步骤(2): 归一标准化处理

[0014] 将采集的输入数据集 X_{pn} 和输出数据集 Y_p 进行归一化, 处理后的数据为 $X_{g,pn} = (x_{g1}, x_{g2}, \dots, x_{gn})$ 和 $Y_{g,p} = (y_g)$;

$$[0015] \quad x_{gi} = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (3)$$

$$[0016] \quad y_g = \frac{y_1 - y_{\min}}{y_{\max} - y_{\min}} \quad (4)$$

[0017] 式(3)-(4)中, $x_{i,\min}$ 和 $x_{i,\max}$ 分别为 X 中 x_i 的最小最大值, $y_{\min}$ 和 $y_{\max}$ 分别为 Y 中 y_1 的最小最大值, x_{gi}, x_i, y_g 为 p 维列向量, $i = 1, 2, \dots, n$ 。

[0018] 步骤(3): 初始化人群搜索算法 SOA 和最小二乘支持向量机 LSSVM 的参数;

[0019] 步骤(4): 根据上一步确定的种群寻优范围, 随机产生 SOA 中的初始种群 $Swarm(i, :) = [\gamma_i, \sigma_i]$, $i = 1, 2, L, s$, 根据式(5)-(7), 每一个种群对应一个 LSSVM 模型, 因此建立 s 个初始的 LSSVM 模型, 每个模型建立方法如下:

$$[0020] \quad \hat{Y}_{g,j} = \sum_{j=1}^p a_j K(X_{g,j*n}, X_{g,n}^*) + b \quad (5)$$

$$[0021] \quad \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} K + \gamma^{-1} I & \mathbf{1}_{p*1} \\ \mathbf{1}_{p*1}^T & 0 \end{bmatrix}^{-1} \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (6)$$

$$[0022] \quad K(X_{g,j*n}, X_{g,n}^*) = \exp\left(-\frac{\|X_{g,j*n} - X_{g,n}^*\|^2}{2\sigma^2}\right) \quad (7)$$

[0023] 式(5)-(7)中, $X_{g,j*n}$ 为第 j 个样本的输入向量, $X_{g,n}^*$ 为建模输入数据集中每个测量点的均值组成的行向量, $K(X_{g,j*n}, X_{g,n}^*)$ 为高斯核函数, σ 为高斯核参数, γ 为正则化参数, a_j 为 LSSVM 中的拉格朗日乘子, $a = [a_1, a_2, L, a_p]^T$, b 为一个偏置数, $y = [Y_{g,1}, Y_{g,2}, L, Y_{g,p}]^T$, $\mathbf{1}_{p*1} = [1, 1, L, 1]^T$ 为 p 维列向量, I 为 $p \times p$ 的单位矩阵,

[0024] 计算每一个模型的适应度值, 适应度值由模型预测的平均相对误差来计算, 计算公式为式(8):

$$[0025] \quad F = \frac{1}{p} \sum_{j=1}^p \left| \frac{Y_{g,j} - \hat{Y}_{g,j}}{Y_{g,j}} \right| \times 100\% \quad (8)$$

[0026] 式中, $Y_{g,j}$ 为第 j 个样本值; $\hat{Y}_{g,j}$ 为第 j 个样本的模型输出值, 由预测模型计算获得, 适应度函数 F 就是 LSSVM 中正则化参数 γ 和核参数 σ 的函数, 最后, 通过比较得出个体最优和群体最优,

[0027] 步骤(5): 利用改进的人群搜索算法 ISOA 进行迭代寻优, 建立新的 LSSVM 预测模型,

[0028] 步骤(6):在线测量和处理数据,具体步骤为:

[0029] 步骤(6.1):在线采集新的测量数据 X_{new} ,其数据格式与公式(1)中的 X 相同;

[0030] 步骤(6.2):将采集到的新数据 X_{new} 按照公式(3)进行标准化得到 X_{gnew} ;

[0031] 步骤(7):将 X_{gnew} 输入到已建立好的LSSVM模型中,得到预测输出 Y_{gnew} ;

[0032] 步骤(8):将 Y_{gnew} 进行逆标准化,得到预测值 Y_{new} ,逆标准化的具体公式为式(19):

$$[0033] \quad Y_{\text{new}} = y_{\min} + Y_{\text{gnew}} \cdot (y_{\max} - y_{\min}) \quad (19)$$

[0034] 步骤(9):若预测过程还需继续,则重复步骤(6)至(8)。

[0035] 作为优选,步骤(5)为:令迭代次数 $t=1$,具体步骤为:

[0036] 步骤(5.1):判断迭代的条件,如果终止条件满足的话,输出寻优结果,进入步骤(5.7);否则进入下一步(5.2),设置终止迭代条件为:迭代次数达到最大,或者全局最优适应度值小于确定的最小适应度值。

[0037] 步骤(5.2):确定搜索方向,为了使新一代在进化中的位置更新,需要确定三个搜索方向,根据个体最佳和全局最佳确定出利己方向 $\vec{d}_{i,ego}(t)$ 、利他方向 $\vec{d}_{i,alt}(t)$ 和预动方向 $\vec{d}_{i,pro}(t)$,计算如下式(9)-(11):

$$[0038] \quad \vec{d}_{i,ego}(t) = \vec{p}_{i,best}(t) - \vec{x}_i(t) \quad (9)$$

$$[0039] \quad \vec{d}_{i,alt}(t) = \vec{g}_{i,best}(t) - \vec{x}_i(t) \quad (10)$$

$$[0040] \quad \vec{d}_{i,pro}(t) = \begin{cases} \vec{d}_{ij}(t), & F_{p_{i,best}} < F_{x_i(t)} \\ -\vec{d}_{ij}(t), & F_{p_{i,best}} \geq F_{x_i(t)} \end{cases} \quad (11)$$

[0041] 预动方向采用个体最优适应度值和当前个体的适应度值比较得出,可以很好的代表当前个体的预动行为,同时减小了计算量,提高了计算速度,

[0042] 综合以上3个因素,采用3个方向随机加权几何平均确定搜索方向 $\vec{d}_{ij}(t)$,如下式(12):

$$[0043] \quad \vec{d}_{ij}(t) = \text{sign}(\omega \vec{d}_{i,pro}(t) + \phi_1 \vec{d}_{i,ego}(t) + \phi_2 \vec{d}_{i,alt}(t)) \quad (12)$$

$$[0044] \quad \omega = W_{\max} - t \cdot \frac{W_{\max} - W_{\min}}{t_{\max}} \quad (13)$$

[0045] 式(9)-(13)中 $\vec{x}_i(t)$ 为第 t 次迭代中第 i 个搜寻个体的位置; $\vec{p}_{i,best}(t)$ 为第 i 个搜寻个体到目前为止经历过的最佳位置; $\vec{g}_{i,best}(t)$ 为第 i 个搜寻个体所在领域的集体历史最佳位置; $F_{p_{i,best}}$ 为 $\vec{p}_{i,best}(t)$ 位置的适应度值; $F_{x_i(t)}$ 为 $\vec{x}_i(t)$ 位置的适应度值; $\text{sign}()$ 为符号函数; ϕ_1 和 ϕ_2 为 $[0,1]$ 内符合均匀分布的随机常数; ω 为惯性权值,随进化代数的增加从最大权值 $W_{\max}=0.9$ 线性递减至最小权值 $W_{\min}=0.1$; t 和 $t_{\max}$ 分别为当前迭代次数和最大迭代次数; $\vec{d}_{ij}(t)$ 为第 t 次迭代中第 i 个搜寻个体的第 j 维搜索方向,其中 $\vec{d}_{ij}(t) \in \{-1, 0, 1\} (i=1, 2, L, s; j=1, 2, L, D)$ 。 $d_{ij}(t)=1$ 表示搜寻个体 i 沿着 j 维坐标的正方向前进; $d_{ij}(t)=-1$ 表示搜寻个体 i 沿着 j 维坐标的反方向前进; $d_{ij}(t)=0$ 表示搜寻个体 i 在第 j 维保持静止不动。

[0046] 步骤(5.3):确定搜索步长

[0047] 相比于线性隶属函数来说,采用如下式(14、15)的高斯隶属函数表示搜索步长的模糊变量可以很好的将第*i*个搜寻个体的适应度值非线性的模糊到[0.0111,0.95]之间,避免了由线性隶属函数模糊的步长不准确性,可以快速收敛,并且可以减小计算量。

$$[0048] \quad u_i = \exp(-(fitness(i) - MinFit) / 2\delta_{ij}^2) \quad (14)$$

$$[0049] \quad u_{ij} = u_i + rand \cdot (1 - u_i), j = 1, L, D \quad (15)$$

[0050] 其中, u_i 为第*i*个搜寻个体的步长模糊变量; $fitness(i)$ 为第*i*个搜寻个体的适应度值; $MinFit$ 为目标最小适应度值; u_{ij} 为由不确定性推理得出的第*i*个搜寻个体的第*j*维步长的模糊变量隶属度; D 为搜寻个体的维数; $\vec{\delta}_{ij}$ 为高斯隶属函数参数,如下式(16):

$$[0051] \quad \vec{\delta}_{ij} = \omega \cdot \left| \vec{x}_{\min} - \vec{x}_{\max} \right| \quad (16)$$

[0052] 因此步长计算公式如下式(17):

$$[0053] \quad \alpha_{ij} = \vec{\delta}_{ij} \sqrt{-\ln(u_{ij})} \quad (17)$$

[0054] 式(16)和(17)中, α_{ij} 为计算的搜索步长; $\vec{x}_{\min}$ 和 $\vec{x}_{\max}$ 分别为同一种群中的最小和最大适应度值的位置; ω 为惯性权值,范围为[0.1,0.9]。

[0055] 步骤(5.4):位置更新

[0056] 在确定出的搜索方向和步长后,即可对每一个搜寻个体进行位置更新,公式如下式(18):

$$[0057] \quad \begin{cases} \Delta x_{ij}(t+1) = \alpha_{ij}(t) d_{ij}(t) \\ x_{ij}(t+1) = x_{ij}(t) + \Delta x_{ij}(t+1) \end{cases} \quad (18)$$

[0058] 其中, $\Delta x_{ij}(t+1)$ 为第*t*+1次搜寻个体相对于第*t*次的位置增量, $x_{ij}(t+1)$ 为搜寻个体的第*t*+1次位置, $x_{ij}(t)$ 为搜寻个体的第*t*次位置, $\alpha_{ij}(t)$ 为搜索步长, $d_{ij}(t)$ 为搜索方向。

[0059] 步骤(5.5):由式(5)-(7)更新LSSVM模型,由式(8)计算适应度值,通过比较,进行个体最优更新和群体最优更新。

[0060] 步骤(5.6):令*t*=*t*+1,返回步骤(5.1)。

[0061] 步骤(5.7):根据寻优结果,建立新的LSSVM预测模型,迭代结束。

[0062] 作为优选,所述人群搜索算法的参数包括:种群规模*s*,最大迭代次数 $iter_{\max}$,最小适应度值 $MinFit$,初始的利己方向 $\vec{d}_{i,ego}$ 、利他方向 $\vec{d}_{i,alt}$ 和预动方向 $\vec{d}_{i,pro}$,初始的搜索方向 $\vec{d}_{ij}(t)$ 、搜索步长 α_{ij} 、高斯隶属参数 δ_{ij} ;最小二乘支持向量机需要初始的参数包括:正则化参数 γ 和核参数 σ 的寻优范围分别为 $[\gamma_{\min}, \gamma_{\max}]$ 和 $[\sigma_{\min}, \sigma_{\max}]$ 。

[0063] 本发明的基于ISOA-LSSVM的地铁站空调系统能耗预测方法,针对地铁站空调系统的多变量耦合、大滞后性和能耗模型难以建立的问题,使地铁站空调系统可提前调节被控参数,建立一种短时能耗预测模型是非常有必要的。具体步骤包括:获取训练数据,将数据进行标准化,利用改进的人群搜索算法对最小二乘支持向量机进行参数寻优,建立预测模型;采集实时测量数据进行标准化,输入到预测模型进行预测,最后逆标准化输出预测能耗

值。本发明实现了ISOA-LSSVM的地铁站空调系统能耗预测方法,其中改进的人群搜索算法采用高斯隶属函数表示搜索步长的模糊变量,减少了迭代次数,增加了模型预测精度;预动方向采用个体最优适应度值和当前个体的适应度值比较得出,可以很好的代表当前个体的预动行为,同时提高了迭代速度。对实现地铁站空调系统的优化控制有重要意义。

[0064] 有益效果

[0065] 与其他现有技术相比,本发明实现了ISOA-LSSVM的地铁站空调系统能耗预测方法,其中改进的人群搜索算法采用高斯隶属函数表示搜索步长的模糊变量,减少了迭代次数,增加了模型预测精度;预动方向采用个体最优适应度值和当前个体的适应度值比较得出,可以很好的代表当前个体的预动行为,同时提高了迭代速度。

附图说明

[0066] 图1本发明地铁站空调系统能耗预测方法流程图。

具体实施方式

[0067] 结合本发明的内容提供如下实施例:

[0068] 由于影响空调系统能耗的因素众多,并且各因素之间关系复杂,系统呈现大滞后性,能耗模型很难建立准确,因此对地铁站空调系统,建立出精确的能耗预测模型是节能运行和优化控制的基础和前提。

[0069] 本实验利用北京某高校地铁实训平台的实际数据,验证本发明方法的准确性。地铁实训平台由两个子系统组成,分别为通风系统和水系统。通风系统的主要设备包括组合式空调机组两台,组合式空调机组内包含风机1台,额定功率3kW,8排表冷器1个,板式初效过滤器1个,风阀1个。水系统主要设备包括冷水机组2台,一用一备,额定功率8.81kW;冷冻水水泵3台,一用两备,额定功率3kW;冷却水水泵2台,一用一备,额定功率5kW;冷却塔1台,额定功率1.5kW。系统的控制方式:风系统采用变频变风量控制回风温度,即随着站内热湿负荷的变化,通过变频调节空气处理机组(AHU)风机的转速改变送风量;水系统采用冷冻水泵变频变流量控制送风温度,以满足站内送风温度的要求。

[0070] 试验过程中送风温度和回风温度的设定值采用排列组合的方式进行交叉变化,同时实验过程中会监控18个变量值,最后选出8个能耗相关变量最为建模数据的输入,下一时间段的能耗值作为预测输出,输入与输出之间相差的时间段由经验取值为0.5h,具体的模型输入变量为:当前的时刻,送风温度设定值,回风温度设定值,冷机出水温度,室外温度,当前时刻的送风温度、回风温度,和当前0.5h内的能耗值。实验收集数据为夏季两个月的时间,组成样本数为2910,将这些数据的5/6的数据,即2425个样本,作为建模数据;1/6的数据,即485个样本,作为测试数据。

[0071] 如图1所示,本发明提供一种基于ISOA-LSSVM的地铁站空调系统能耗预测方法,包括如下步骤:

[0072] 步骤(1):获取训练数据。

[0073] 采集地铁站空调系统运行中实时测得的能耗相关变量和下一时段的能耗变量形成训练数据,具体的一次数据采样表示形式如下:

[0074] $X = (x_1, x_2, \dots, x_8)$ (1)

[0075] $Y = (y_1)$ (2)

[0076] 其中, $x_1, x_2, \dots, x_8$ 分别表示当前的时刻、送风温度设定值、回风温度设定值、冷机出水温度、室外温度、当前时刻的送风温度、回风温度, 和当前 0.5h 的能耗; y_1 表示空调系统下 0.5h 时段所测量的能耗变量。

[0077] 步骤 (2): 归一标准化处理。将采集的输入数据集 X_{pn} 和输出数据集 Y_p 进行归一化, 处理后的数据为 $X_{g,pn} = (x_{g1}, x_{g2}, \dots, x_{gn})$ 和 $Y_{g,p} = (y_g)$;

[0078]
$$x_{gi} = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (3)$$

[0079]
$$y_g = \frac{y_1 - y_{\min}}{y_{\max} - y_{\min}} \quad (4)$$

[0080] 式 (3) - (4) 中, $x_{i,\min}$ 和 $x_{i,\max}$ 分别为 X 中 x_i 的最小最大值, $y_{\min}$ 和 $y_{\max}$ 分别为 Y 中 y_1 的最小最大值, x_{gi}, x_i, y_g 为 p 维列向量, $i = 1, 2, \dots, n$ 。

[0081] 步骤 (3): 初始化人群搜索算法 SOA 和最小二乘支持向量机 LSSVM 的参数。人群搜索算法的参数包括: 种群规模 $s = 20$, 最大迭代次数 $t_{\max} = 80$, 最小适应度值 $\text{MinFit} = 0.0085$, 初始的利己方向 $\vec{d}_{i,ego} = 0$ 、利他方向 $\vec{d}_{i,alt} = 0$ 和预动方向 $\vec{d}_{i,pro} = 0$, 初始的搜索方向 $\vec{d}_{ij}(t) = 1$ 、搜索步长 $\alpha_{ij} = 0$ 、高斯隶属参数 $\delta_{ij} = 0$ 。最小二乘支持向量机需要初始的参数包括: 正则化参数 γ 和核参数 σ 的寻优范围分别为 $[0.1, 10^6]$ 和 $[0.1, 10]$;

[0082] 步骤 (4): 根据种群寻优范围, 随机产生初始种群 $\text{Swarm}(i, :) = [\gamma_i, \sigma_i]$, $i = 1, 2, \dots, L, 20$, 根据式 (5) - (7), 每一个种群对应一个初始 LSSVM 模型, 因此建立 s 个初始的 LSSVM 模型, 每个模型建立方法如下:

[0083]
$$\hat{Y}_{g,j} = \sum_{j=1}^p a_j K(X_{g,j*}, X_{g,n}^*) + b \quad (5)$$

[0084]
$$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} K + \gamma^{-1} I & 1_{p*1} \\ 1_{p*1}^T & 0 \end{bmatrix}^{-1} \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (6)$$

[0085]
$$K(X_{g,j*}, X_{g,n}^*) = \exp\left(-\frac{\|X_{g,j*} - X_{g,n}^*\|^2}{2\sigma^2}\right) \quad (7)$$

[0086] 式 (5) - (7) 中, $X_{g,j*}$ 为第 j 个样本的输入向量, $X_{g,n}^*$ 为建模输入数据集中每个测量点的均值组成的行向量, $K(X_{g,j*}, X_{g,n}^*)$ 为高斯核函数, σ 为高斯核参数, γ 为正则化参数, a_j 为 LSSVM 中的拉格朗日乘子, $a = [a_1, a_2, \dots, a_{2425}]^T$, b 偏置数, $y = [Y_{g,1}, Y_{g,2}, \dots, Y_{g,2425}]^T$, $1_{p*1} = [1, 1, \dots, 1]^T$ 为 p 维列向量, I 为 2425×2425 的单位矩阵。

[0087] 计算每一个模型的适应度值, 计算公式为式 (8):

[0088]
$$F = \frac{1}{p} \sum_{j=1}^p \left| \frac{Y_{g,j} - \hat{Y}_{g,j}}{Y_{g,j}} \right| \times 100\% \quad (8)$$

[0089] 式中, $Y_{g,j}$ 为第 j 个样本值; $\hat{Y}_{g,j}$ 为第 j 个样本的模型输出值, 由预测模型计算获得。因此, 适应度函数 F 就是 LSSVM 中正则化参数 γ 和核参数 σ 的函数。最后, 通过比较得出个体

最优和群体最优。

[0090] 步骤(5):利用改进的人群搜索算法ISOA进行迭代寻优,令迭代次数 $t=1$,具体步骤为:

[0091] 步骤(5.1):判断迭代的条件,如果终止条件满足的话,输出寻优结果,进入步骤(5.7);否则进入下一步(5.2)。设置终止迭代条件为:迭代次数达到最大,或者全局最优适应度值小于确定的最小适应度值。

[0092] 步骤(5.2):确定搜索方向。为了使新一代在进化中的位置更新,需要确定三个搜索方向。根据个体最佳和全局最佳确定出利己方向 $\vec{d}_{i,ego}(t)$ 、利他方向 $\vec{d}_{i,alt}(t)$ 和预动方向 $\vec{d}_{i,pro}(t)$,计算如下式(9)-(11):

$$[0093] \quad \vec{d}_{i,ego}(t) = \vec{p}_{i,best}(t) - \vec{x}_i(t) \quad (9)$$

$$[0094] \quad \vec{d}_{i,alt}(t) = \vec{g}_{i,best}(t) - \vec{x}_i(t) \quad (10)$$

$$[0095] \quad \vec{d}_{i,pro}(t) = \begin{cases} \vec{d}_{ij}(t), & F_{p_{i,best}} < F_{x_i(t)} \\ -\vec{d}_{ij}(t), & F_{p_{i,best}} \geq F_{x_i(t)} \end{cases} \quad (11)$$

[0096] 预动方向采用个体最优适应度值和当前个体的适应度值比较得出,可以很好的代表当前个体的预动行为,同时减小了计算量,提高了计算速度。

[0097] 综合以上3个因素,采用3个方向随机加权几何平均确定搜索方向 $\vec{d}_{ij}(t)$,如下式(12):

$$[0098] \quad \vec{d}_{ij}(t) = \text{sign}(\omega \vec{d}_{i,pro}(t) + \varphi_1 \vec{d}_{i,ego}(t) + \varphi_2 \vec{d}_{i,alt}(t)) \quad (12)$$

$$[0099] \quad \omega = W_{\max} - t \cdot \frac{W_{\max} - W_{\min}}{t_{\max}} \quad (13)$$

[0100] 式(9)-(13)中 $\vec{x}_i(t)$ 为第 t 次迭代中第 i 个搜寻个体的位置; $\vec{p}_{i,best}(t)$ 为第 i 个搜寻个体到目前为止经历过的最佳位置; $\vec{g}_{i,best}(t)$ 为第 i 个搜寻个体所在领域的集体历史最佳位置; $F_{p_{i,best}}$ 为 $\vec{p}_{i,best}(t)$ 位置的适应度值; $F_{x_i(t)}$ 为 $\vec{x}_i(t)$ 位置的适应度值; $\text{sign}()$ 为符号函数; φ_1 和 φ_2 为 $[0,1]$ 内符合均匀分布的随机常数; ω 为惯性权值,随进化代数的增加从最大权值 $W_{\max}=0.9$ 线性递减至最小权值 $W_{\min}=0.1$; t 和 $t_{\max}$ 分别为当前迭代次数和最大迭代次数; $\vec{d}_{ij}(t)$ 为第 t 次迭代中第 i 个搜寻个体的第 j 维搜索方向,其中 $\vec{d}_{ij}(t) \in \{-1,0,1\} (i=1,2,L,20; j=1,2)$ 。

[0101] 步骤(5.3):确定搜索步长。

[0102] 采用如下式(11)的高斯隶属函数表示搜索步长的模糊变量将第 i 个搜寻个体的适应度值非线性的模糊到 $[0.0111,0.95]$ 之间。

$$[0103] \quad u_i = \exp(-(fitness(i) - \text{MinFit}) / 2\delta_{ij}^2) \quad (14)$$

$$[0104] \quad u_{ij} = u_i + \text{rand} \cdot (1 - u_i), j=1,L,D \quad (15)$$

[0105] 其中, $i=1,2,L,20$; u_i 为第 i 个搜寻个体的步长模糊变量; $fitness(i)$ 为第 i 个搜

寻个体的适应度值； u_{ij} 为由不确定性推理得出的第*i*个搜寻个体的第*j*维步长的模糊变量隶属度； $\vec{\delta}_{ij}$ 为高斯隶属函数参数，如下式 (16)：

$$[0106] \quad \vec{\delta}_{ij} = \omega \cdot \left| \vec{x}_{\min} - \vec{x}_{\max} \right| \quad (16)$$

[0107] 因此步长计算公式如下式 (17)：

$$[0108] \quad \alpha_{ij} = \vec{\delta}_{ij} \sqrt{-\ln(u_{ij})} \quad (17)$$

[0109] 式 (15) 和 (16) 中， α_{ij} 为计算的搜索步长； $\vec{x}_{\min}$ 和 $\vec{x}_{\max}$ 分别为同一种群中的最小和最大适应度值的位置； ω 为惯性权值，范围为 [0.1, 0.9]。

[0110] 步骤 (5.4)：位置更新。在确定出的搜索方向和步长后，即可对每一个搜寻个体进行位置更新，公式如下式 (18)：

$$[0111] \quad \begin{cases} \Delta x_{ij}(t+1) = \alpha_{ij}(t) d_{ij}(t) \\ x_{ij}(t+1) = x_{ij}(t) + \Delta x_{ij}(t+1) \end{cases} \quad (18)$$

[0112] 其中， $\Delta x_{ij}(t+1)$ 为第*t*+1次搜寻个体相对于第*t*次的位置增量， $x_{ij}(t+1)$ 为搜寻个体的第*t*+1次位置， $x_{ij}(t)$ 为搜寻个体的第*t*次位置， $\alpha_{ij}(t)$ 为搜索步长， $d_{ij}(t)$ 为搜索方向。

[0113] 步骤 (5.5)：由式 (5) - (7) 更新LSSVM模型，由式 (8) 计算适应度值，通过比较，进行个体最优更新和群体最优更新。

[0114] 步骤 (5.6)：令 $t = t + 1$ ，返回步骤 (5.1)。

[0115] 步骤 (5.7)：根据寻优结果，建立新的LSSVM预测模型，迭代结束。

[0116] 步骤 (6)：在线测量和处理数据，具体步骤为：

[0117] 步骤 (6.1)：在线采集新的测量数据 X_{new} ，其数据格式与公式 (1) 中的 X 相同；

[0118] 步骤 (6.2)：将采集到的新数据 X_{new} 按照公式 (3) 进行标准化得到 X_{gnew} 。

[0119] 步骤 (7)：将 X_{gnew} 输入到已建立好的LSSVM模型中，得到预测输出 Y_{gnew} 。

[0120] 步骤 (8)：将 Y_{gnew} 进行逆标准化，得到预测值 Y_{new} ，逆标准化的具体公式为式 (19)：

$$[0121] \quad Y_{\text{new}} = y_{\min} + Y_{\text{gnew}} \cdot (y_{\max} - y_{\min}) \quad (19)$$

[0122] 步骤 (9)：若预测过程还需继续，则重复步骤 (6) 至 (8)。

[0123] 按照以上步骤在计算机上用MATLAB程序实现，则所建立五种方法的模型预测平均相对误差MAPE、均方根误差MSE、建模预测时间、收敛迭代次数和参数输出值如表1所示，即本发明 (ISOA-LSSVM)、使用高斯隶属函数的SOA优化最小二乘支持向量机 (GSOA-LSSVM)、SOA优化最小二乘支持向量机 (SOA-LSSVM)、粒子群优化最小二乘支持向量机 (PSO-LSSVM) 和传统的网格搜索优化LSSVM：

[0124] 表1

[0125]

算法 指标	ISOA-LSSVM	GSOA-LSSVM	SOA-LSSVM	PSO-LSSVM	LSSVM
MAPE	0.832%	0.84%	0.855%	0.93%	1.06%
MSE	0.0963	0.0960	0.1004	0.1157	0.1298
时间/s	33.53	89.99	273.518	275.99	296.77
迭代 次数	4	4	10	27	/
γ	33039.12	22179	27018	34047	61747
σ	0.1	0.1	0.1	0.1	4.0224




图1