



(12) 发明专利

(10) 授权公告号 CN 101498457 B

(45) 授权公告日 2010.08.25

(21) 申请号 200910096406.3

CN 101329582 A, 2008.12.24, 全文.

(22) 申请日 2009.03.02

吴智群等. 电站锅炉智能燃烧优化技术的应

(73) 专利权人 杭州电子科技大学

用研究.《热力发电》.2008, 第37卷(第9期), 23-
27.

地址 310018 浙江省杭州市江干区下沙高教
园区2号大街

审查员 李飞

(72) 发明人 王春林 薛安克 葛铭 王建中
张日东

(74) 专利代理机构 杭州求是专利事务所有限公
司 33200

代理人 杜军

(51) Int. Cl.

F23N 5/00 (2006.01)

G05B 19/418 (2006.01)

G05B 13/02 (2006.01)

(56) 对比文件

CN 101078526 A, 2007.11.28, 全文.

权利要求书 3 页 说明书 9 页

(54) 发明名称

一种锅炉燃烧优化的方法

(57) 摘要

本发明涉及一种锅炉燃烧优化的方法。目前锅炉的燃烧优化依靠调试人员进行实验，费时、费力，而且参数组合有限。本发明的具体步骤是：采集锅炉运行参数及相关的表征锅炉燃烧特征指标，建立实时数据库；在实际运行负荷小于锅炉设计负荷的60%情况下采用支持向量机集成建模方法建模，在实际运行负荷大于等于锅炉设计负荷的60%情况下采用径向基神经网络集成建模方法建模，建立不同指标的锅炉燃烧模型；利用粒子群优化算法结合所建模型，针对不同对锅炉燃烧指标或指标组合进行锅炉燃烧参数配置的优化。本发明方法提高了整体模型的预测能力，大大提高了模型的适应能力。本发明方法既可以在线优化也可以离线优化。

1. 一种锅炉燃烧优化的方法,其特征在于该方法的步骤包括:

步骤(1). 采集锅炉运行参数及表征锅炉燃烧特征指标,建立实时数据库;具体的锅炉运行参数通过锅炉实时运行数据库获取,或直接通过仪器设备测量采集;

所述的锅炉运行参数包括负荷、各层的一次风速、各层的二次风速、炉膛出口烟气含氧量、燃尽风速、给粉机给粉速度,燃煤工业分析指标;

所述的表征锅炉燃烧特征指标包括锅炉燃烧器边水冷壁的CO浓度、尾部烟气的NO浓度和锅炉效率;

步骤(2). 在实际运行负荷小于锅炉设计负荷的60%情况下采用支持向量机集成建模方法建模,在实际运行负荷大于等于锅炉设计负荷的60%情况下采用径向基神经网络集成建模方法建模,建立不同指标的锅炉燃烧模型;具体建模方法如下:

用于建模样本的输入参数及表征锅炉燃烧特征指标的输出参数表示为 $\{x_i, y_i\}_{i=1}^N$,其中 x_i 表示第*i*组作为输入数据的锅炉运行参数向量, y_i 表示第*i*组作为输出参数的表征锅炉燃烧特征指标的参数,*N*为样本数量,以实际运行数据为基础建立锅炉运行参数与锅炉各不同燃烧特征指标间的模型;

所述的支持向量机集成建模方法首先采用支持向量机方法建模,然后通过集成算法将模型集成;支持向量机核函数选为径向基函数

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

$\phi(x)$ 为映射函数,设所求的目标函数为: $f(x_i) = w \cdot \phi(x_i) + b$, $f(x_i)$ 为模型输出的锅炉燃烧特征指标预测值, w 为权重系数向量, b 为截距;

$$\text{根据 } \min R(w, \xi, \xi^*) = \frac{1}{2} w \cdot w + c \sum_{i=1}^k \xi_i + \xi^* \text{ 在约束条件}$$

$$\begin{cases} y_i - w \cdot \phi(x_i) - b \leq \varepsilon + \xi_i \\ w \cdot \phi(x_i) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0 \quad i = 1, \dots, N, \\ \xi_i^* \geq 0 \end{cases}$$

解得 w 、 b

其中常数 $c > 0$,为惩罚系数, ξ^* 和 ξ_i 为引入的松弛因子, $\xi_i^* \geq 0$ 和 $\xi_i \geq 0$, ε 为允许拟合误差;

通过集成算法将模型集成的步骤如下:

a. 原始训练数据初始化权值为 $w_i^j = \frac{1}{N}, i = 1, 2, \dots, N, j$ 为权重更新次数,初始化权重时

$j = 1$,设定迭代次数 k ;

b. 调用以上支持向量机方法对训练样本建模,获得一个模型 M_j ,计算 M_j 的平均预测误

差的平方值 $\sigma_j: \sigma_j = \sum_{i=1}^N w_i^j (M_j(x_i) - y_i)^2$

c. 更新原始训练数据权重 w_i^{j+1} : $w_i^{j+1} = \frac{w_i^j(M_j(x_i) - y_i)^2}{\sigma_j}$

d. 根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为 :

$w_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 产生一个子支持向量机的训练集;

e. 重复步骤 b ~ d 获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成;

f. 将获得的 k 个子支持向量机模型进行集成, 模型权重为 : $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$, 最终获得的

集成模型为 : $M_{final} = \sum_{j=1}^k \alpha_j M_j$;

所述的径向基神经网络集成建模方法首先采用径向基神经网络建模方法建模, 对于 n 个隐节点的径向基神经网络其输出为 :

$y = \sum_{i=1}^n w_i \exp(-\frac{\|x - c_i\|^2}{2\rho_i^2})$, w_i 为权重系数, x 为 m 维输入向量, c_i 为第 i 个基函数的中心,

ρ_i 为函数的基宽度参数

w_i 、 x 、 c_i 、 ρ_i 由目标函数 $\min J = \sum_{i=1}^N (\tilde{y}_i - y_i)^2$ 确定, 其中 \tilde{y}_i 为 x_i 的神经网络输出值, y_i 为

x_i 对应的实际值; 定义粒子群算法初始群体 Z 向量的各维分量, 分别为隐节点个数、基函数中心、函数的基宽度和权重系数, 当 J 达到了最小、达到设定值或完成迭代次数时, 训练完成, 获得隐节点个数、基函数中心、函数的基宽度和权重系数, 从而获得径向基神经网络模型; 然后通过集成算法将模型集成, 具体步骤如下 :

g. 原始训练数据初始化权值为 $\lambda_i^j = \frac{1}{N}, i = 1, 2, \dots, N$, j 为权重更新次数, 初始化权重时

$j = 1$, 设定迭代次数 k;

h. 调用以上径向基神经网络建模方法对训练样本建模, 获得一个模型 M_j , 计算 M_j 的平

均预测误差的平方值 : $\sigma_j = \sum_{i=1}^N \lambda_i^j (M_j(x_i) - y_i)^2$

i. 更新原始训练数据权重 : $\lambda_i^{j+1} = \frac{\lambda_i^j (M_j(x_i) - y_i)^2}{\sigma_j}$

j. 根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为 :

$\lambda_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 产生一个子径向基神经网络的训练集;

k. 重复步骤 h ~ j 获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成;

l. 将获得的 k 个子径向基神经网络模型进行集成, 模型权重为 : $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$,

最终获得的集成模型为 : $M_{final} = \sum_{j=1}^k \alpha_j M_j$;

步骤 (3). 利用粒子群优化算法结合所建模型, 针对不同的锅炉燃烧特征指标或指标组合进行锅炉燃烧参数配置的优化, 具体步骤如下 :

- m. 定义粒子群位置向量 x 的各维分量分别为锅炉运行参数；
- n. 设定粒子群的搜索目标和迭代次数，搜索目标，包括单一目标：锅炉效率最高，NOx 排放最低或高温腐蚀最慢；复合目标：以上两个或三个燃烧指标的组合，组合方式是将各指标的变化折算为经济指标变化，再将经济指标变化求总合；
- o. 根据实际锅炉的设计和运行要求设定各参数的寻优范围，并初始化位置向量 x ，然后根据上一步设定的搜索目标，用粒子群算法进行迭代计算，搜索粒子群在参数向量空间内的最优位置；
- p. 当粒子群算法完成迭代次数或找到设定要求的最优时，停止计算获得相应最优的位置向量，即获得最优的锅炉运行可调操作参数组合。

一种锅炉燃烧优化的方法

技术领域

[0001] 本发明属于信息与控制技术领域,涉及到自动化技术,特别是涉及一种锅炉燃烧优化方法。

背景技术

[0002] 锅炉的燃烧优化是节能减排的重要技术手段,其目标是在一定的锅炉负荷条件下,通过调整锅炉配风、给煤等运行参数而获得高效率、低污染排放及更安全的运行状态。锅炉的配风、给煤等运行参数的搭配对锅炉燃烧状态有直接的影响,不同的配风、给煤及氧量等操作参数的配置会直接导致不同的锅炉效率、污染气体的排放量及高温腐蚀的情况。对于给定的锅炉,在一定的负荷条件下,针对不同的燃烧指标,存在一种最优的操作参数配置方案,能够使相应燃烧指标最优化,但是,锅炉的操作参数间有着非常复杂的耦合关系,要找到最优的操作参数的配置不容易。随着科学技术的不断进步,锅炉运行自动化程度不断提高,但是锅炉燃烧优化问题一直没有很好的得到解决。

[0003] 实际中锅炉的燃烧优化主要是靠调试人员进行不同工况的实验,针对具体的锅炉和煤种情况通过大量的实验来寻找好的运行参数配置,以提供给运行人员作参照,此种方法费时、费力而且能够实验的参数组合有限,因此通过调试实验找到的最优参数配置还存在较大的提升空间,而且这种方法还不能实现根据锅炉的实时变化情况进行在线的优化。

[0004] 通过数据挖掘,在大量不同的运行参数组合中,应用机器学习的方法,挖掘出运行参数与锅炉燃烧指标间的关系模型,再结合优化算法对进行锅炉的燃烧优化是非常有潜力的方法。如何使该方法真正达到锅炉生产实际的要求,是困扰工程技术人员的难题,主要难题包括,如何提高模型的预测和泛化能力,如何提高模型的增量学习能力,如何丰富锅炉燃烧优化的目标,使之达到兼顾各项指标的更全面的优化的目的。

发明内容

[0005] 本发明的目标是针对锅炉燃烧优化中的一些难题,提出一种具有较强增量学习能力锅炉燃烧优化方法,优化内容兼顾了经济性、环保性和设备安全和损耗特性。

[0006] 本发明的技术方案是通过锅炉的数据采集,针对相互影响的不同锅炉燃烧指标建立基于集成技术的模型,应用并行的优化算法寻优等手段,确立了一种锅炉燃烧优化的方法,利用该方法可有效提高锅炉燃烧优化的效率和全面性,既可以实施离线优化也可以进行在线实时燃烧优化。

[0007] 本发明的具体步骤是:

[0008] 步骤(1)采集锅炉运行参数及相关的表征锅炉燃烧特征指标,建立实时数据库;具体的锅炉运行参数通过锅炉实时运行数据库获取,或直接通过仪器设备测量采集。

[0009] 所述的实时锅炉运行参数数据包括负荷、各层的一次风速、各层的二次风速、炉膛出口烟气含氧量、燃尽风速、给粉机给粉速度,燃煤工业分析指标;所述的表征锅炉燃烧特征指标的数据包括锅炉燃烧器边水冷壁的CO浓度、尾部烟气的NO浓度和锅炉效率,其获得

的方法为成熟技术。

[0010] 这个过程是积累数据的阶段,只有积累了相当的数据后才可能进行后边的数据挖掘建模。

[0011] 步骤 (2) 由于极低负荷下锅炉参数变化对锅炉燃烧的影响情况与其它负荷段不同,而且实际运行中极低负荷段下的运行数据相对于其它负荷段又少很多,因此根据极低负荷段(实际运行负荷小于锅炉设计负荷的 60%) 的特点采用适于小样本且泛化能力强的支持向量机集成建模方法建模;对于数据量充分的其它负荷段(实际运行负荷大于等于锅炉设计负荷的 60%) 采用径向基神经网络集成建模方法建模,对数据库中的数据进行挖掘,建立不同指标的锅炉燃烧模型。需要调用所建模型预测时,根据实际的锅炉运行负荷情况选用相应负荷段下的模型进行预测计算。具体建模方法如下:

[0012] 用于建模样本的输入参数及表征锅炉燃烧状态的输出参数可以表示为 $\{x_i, y_i\}_{i=1}^N$,其中 x_i 表示第 i 组作为输入数据的锅炉运行参数向量, y_i 表示第 i 组作为输出参数的表征锅炉燃烧状态的参数, N 为样本数量,以实际运行数据为基础建立锅炉运行参数与锅炉各不同燃烧特征指标间的模型。

[0013] 对于数据量少的极低负荷段,采用适合于小样本学习的支持向量机集成算法建模,支持向量机核函数选为径向基函数:

$$[0014] K(x_i, x_j) = \phi(x_i) \bullet \phi(x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right)$$

[0015] $\phi(x)$ 为映射函数,设所求的目标函数为: $f(x_i) = w \cdot \phi(x_i) + b$, $f(x_i)$ 为模型输出的锅炉燃烧指标预测值, w 为权重系数向量, b 为截距。引入松弛因子 $\xi_i^* \geq 0$ 和 $\xi_i \geq 0$ 和允许拟合误差 ϵ ,模型可以通过在约束:

$$[0016] \begin{cases} y_i - w \cdot \phi(x_i) - b \leq \epsilon + \xi_i \\ w \cdot \phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i \geq 0 \\ \xi_i^* \geq 0 \end{cases} \quad i = 1, \dots, N, \text{条件下,最小化:}$$

$$[0017] \min R(w, \xi, \xi^*) = \frac{1}{2} w \cdot w + c \sum_{i=1}^k \xi_i + \xi_i^*$$

[0018] 获得,其中常数 $c > 0$ 为惩罚系数。该最小化问题为一个凸二次规划问题,引入拉格朗日函数:

$$[0019] L(w, b, \xi, \xi^*, \alpha, \alpha^*, \gamma, \gamma^*) = \frac{1}{2} w \cdot w + C \sum_{i=1}^N (\xi_i + \xi_i^*) - \sum_{i=1}^N \alpha_i [y_i - (\xi_i + \epsilon + f(x_i))]$$

$$[0020] - \sum_{i=1}^N \alpha_i^* [\xi_i^* + \epsilon + f(x_i) - y_i] - \sum_{i=1}^N (\gamma_i \xi_i + \gamma_i^* \xi_i^*)$$

[0021] 其中: $\alpha_i, \alpha_i^* \geq 0, \gamma_i, \gamma_i^* \geq 0$,为拉格朗日乘数。

[0022] 在鞍点处,函数 L 是关于 w, b, ξ_1, ξ_1^* 的极小点,也是 $\alpha_1, \alpha_1^*, \gamma_1, \gamma_1^*$ 极大点,最小化问题转化为求其对偶问题的最大化问题。

[0023] 拉格朗日函数 L 在鞍点处是关于 w, b, ξ_1, ξ_1^* 极小点,得:

$$\begin{aligned} [0024] \quad & \left\{ \begin{array}{l} \frac{\partial}{\partial w} L = 0 \rightarrow w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i) \\ \frac{\partial}{\partial b} L = 0 \rightarrow \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ \frac{\partial}{\partial \xi_i} L = 0 \rightarrow C - \alpha_i - \gamma_i = 0 \\ \frac{\partial}{\partial \xi_i^*} L = 0 \rightarrow C - \alpha_i^* - \gamma_i^* = 0 \end{array} \right. \end{aligned}$$

[0025] 可得拉格朗日函数的对偶函数：

[0026]

$$\varpi(\alpha, \alpha^*)_{w, b, \xi, \xi^*} = -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j)$$

[0027]

$$-\sum_{i=1}^N (\alpha_i + \alpha_i^*) \varepsilon + \sum_{i=1}^N (\alpha_i + \alpha_i^*) y_i$$

[0028] 此时，

$$[0029] \quad w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i)$$

$$[0030] \quad f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b$$

[0031] 按照库恩 - 塔克 (KKT) 条件定理，在鞍点有下式成立：

$$[0032] \quad \begin{cases} \alpha_i [\varepsilon + \xi_i - y_i + f(x_i)] = 0 & i = 1, \dots, N \\ \alpha_i^* [\varepsilon + \xi_i + y_i - f(x_i)] = 0 \end{cases}$$

[0033] 由上式可见, $\alpha_i \cdot \alpha_i^* = 0$, α_i 和 α_i^* 都不会同时为非零, 可得：

$$[0034] \quad \begin{cases} \xi_i \gamma_i = 0 & i = 1, \dots, N \\ \xi_i^* \gamma_i^* = 0 \end{cases}$$

[0035] 从上式可求出 b, 获得模型。

[0036] 支持向量机集成建模方法的步骤如下：

[0037] a. 原始训练数据初始化权值为 $w_i^j = \frac{1}{N}, i = 1, 2, \dots, N$, j 为权重更新次数, 初始化权重时 $j = 1$, 设定迭代次数 k。

[0038] b. 调用以上支持向量机算法对训练样本建模, 获得一个模型 M_j , 计算 M_j 的平均预测误差的平方值 : $\sigma_j = \sum_{i=1}^N w_i^j (M_j(x_i) - y_i)^2$

[0039] c. 更新原始训练数据权重 : $w_i^{j+1} = \frac{w_i^j (M_j(x_i) - y_i)^2}{\sigma_j}$

[0040] d. 根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为 :

[0041] $w_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 产生一个子支持向量机的训练集。

[0042] e. 重复步骤 b ~ d 获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成。

[0043] f. 将获得的 k 个子支持向量机模型进行集成, 模型权重为: $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$, 最终获得的集成模型为: $M_{final} = \sum_{j=1}^k \alpha_j M_j$

[0044] 对于数据量丰富的负荷段, 采用用学习能力和函数逼近能力强的径向基神经网络建模:

[0045] 对于 n 个隐节点的径向基神经网络其输出为:

[0046] $y = \sum_{i=1}^n w_i \exp\left(-\frac{\|x - c_i\|^2}{2\rho_i^2}\right)$, w_i 为权重系数, x 为 m 维输入向量, c_i 为第 i 个基函数的中心, ρ_i 为函数的基宽度参数。建立径向基神经网络模型的关键在于确定基函数的中心 c_i , 基宽度 ρ_i 及权重系数 w_i 。采用粒子群算法迭代训练径向基神经网络, 定义粒子群算法初始群体 Z 向量的各维分量, 分别为隐节点个、数基函数中心、函数的基宽度和权重系数, 目标函数为: $\min J = \sum_{i=1}^N (\tilde{y}_i - y_i)^2$, 其中 \tilde{y}_i 为第 i 个样本的神经网络输出值, y_i 为第 i 个样本的实际值。当 J 达到了最小、达到设定值或完成迭代次数时, 训练完成, 获得隐节点个数、基函数中心、函数的基宽度和权重系数, 从而获得径向基神经网络模型。

[0047] 径向基神经网络集成建模方法的步骤如下:

[0048] g. 原始训练数据初始化权值为 $\lambda_i^j = \frac{1}{N}, i = 1, 2, \dots, N$, j 为权重更新次数, 初始化权重时 $j = 1$, 设定迭代次数 k。

[0049] h. 调用以上径向基神经网络集成建模方法对训练样本建模, 获得一个模型 M_j , 计算 M_j 的平均预测误差的平方值: $\sigma_j = \sum_{i=1}^N \lambda_i^j (M_j(x_i) - y_i)^2$

[0050] i. 更新原始训练数据权重: $\lambda_i^{j+1} = \frac{\lambda_i^j (M_j(x_i) - y_i)^2}{\sigma_j}$

[0051] j. 根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为:

[0052] $\lambda_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 产生一个子径向基神经网络的训练集。

[0053] k. 重复步骤 h ~ j 获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成。

[0054] l. 将获得的 k 个子径向基神经网络模型进行集成, 模型权重为: $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$,

[0055] 最终获得的集成模型为: $M_{final} = \sum_{j=1}^k \alpha_j M_j$

[0056] 集成技术具有较强的增量学习特点, 适合于适应锅炉燃烧中出现的新情况和变化。

[0057] 步骤 (3) 利用粒子群优化算法结合所建模型, 针对不同对锅炉燃烧指标或指标组合进行锅炉燃烧参数配置的优化, 具体步骤如下:

[0058] m. 定义粒子群位置向量 x 的各维分量, 分别为锅炉可调操作参数, 包括: 各层一次

风速,各层二次风速,燃尽风速,炉膛出口氧量。

[0059] n. 设定粒子群的搜索目标和迭代次数,搜索目标可以根据具体的锅炉运行情况为单一目标,包括锅炉效率最高, NOx 排放最低或高温腐蚀最慢;也可以是复合目标,即以上两个或三个燃烧指标的组合,组合方式为,将各指标的变化折算为经济指标变化,再将经济指标变化求总合,以求达到综合最优。锅炉效率,NOx 排放和高温腐蚀情况分别由上文所建的各自相应模型预测获得。

[0060] o. 根据实际锅炉的设计和运行要求设定各参数的寻优范围,并初始化位置向量 x ,然后根据上一步设定的搜索目标,用粒子群算法进行迭代计算,搜索粒子群在参数向量空间内的最优位置。

[0061] p. 当粒子群算法完成迭代次数或找到设定要求的最优时,停止计算获得相应最优的位置向量,即获得最优的锅炉运行可调操作参数组合,根据所获得的最优可调操作参数组合对锅炉实际燃烧进行调整,达到燃烧优化的目的。

[0062] 锅炉在降低 NOx 排放时,会造成燃烧器附近水冷壁高温腐蚀比较严重,实际工程中的燃烧优化只注重了 NOx 排放和效率方面的指标,对因降低 NOx 排放而导致高温腐蚀没有考虑在内,而且在模型预测能力和模型更新方面也存在严重不足。本发明方法具体是采集锅炉实时数据并利用基于集成技术的挖掘算法,针对锅炉的效率、NOx 排放特性及燃烧器附近水冷壁的高温腐蚀情况进行建模,结合寻优算法对锅炉的运行进行优化,以达到高效、低污染和高安全抵损耗的目标。

[0063] 本发明中的方法将近燃烧器水冷壁边的高温腐蚀情况也作为燃烧优化的目标之一,使燃烧优化更加完善,克服了仅优化 NOx 排放和锅炉效率给锅炉运行带来的负面影响;而且该方法在建模时将数据量少的极低负荷段单独建模,提高了整体模型的预测能力;模型更新方面采用了有较强增量学习能力的基于集成技术的建模方法,大大提高了模型的适应能力。本发明方法既可以在线优化也可以离线优化。

具体实施方式

[0064] 一种锅炉燃烧优化的方法,具体是以下步骤:

[0065] (1) 根据实际锅炉燃烧优化的要求建立实时数据库,采集锅炉运行参数及相关的表征锅炉燃烧特征指标。具体的锅炉运行参数可以通过锅炉实时运行数据库获取,或直接通过仪器设备测量采集。

[0066] 所述的实时锅炉运行参数数据包括负荷、各层的一次风速、各层的二次风速、炉膛出口烟气含氧量、燃尽风速、给粉机给粉速度,燃煤工业分析指标;所述的表征锅炉燃烧特征指标的数据包括表征锅炉水冷壁高温腐蚀情况的近燃烧器水冷壁边的 CO 浓度、尾部烟气的 NO 浓度和锅炉效率,其获得的方法为成熟技术。

[0067] (2) 由于极低负荷下锅炉参数变化对锅炉燃烧的影响情况与其它负荷段不同,而且实际运行中极低负荷段下的运行数据相对于其它负荷段又少很多,因此根据极低负荷段的特点采用适于小样本且泛化能力强的支持向量机集成建模方法;对于数据量充分的其它负荷段采用径向基神经网络集成建模方法,对数据库中的数据进行挖掘,建立不同指标的锅炉燃烧模型。需要调用所建模型预测时,根据实际的锅炉运行负荷情况选用相应负荷段下的模型进行预测计算。具体建模方法如下:

[0068] 用于建模样本的输入参数及表征锅炉燃烧状态的输出参数可以表示为 $\{x_i, y_i\}_{i=1}^N$, 其中 x_i 表示第 i 组作为输入数据的锅炉运行参数向量, y_i 表示第 i 组作为输出参数的表征锅炉燃烧状态的参数, N 为样本数量, 以实际运行数据为基础建立锅炉运行参数与锅炉燃烧特征指标间的模型。

[0069] 对于数据量少的极低负荷段, 在此作为示例, 将 60% 负荷以下的负荷段定为极低负荷段, 采用适合于小样本学习的支持向量机集成算法建模, 支持向量机核函数选为径向基函数:

$$[0070] K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right)$$

[0071] $\phi(x)$ 为映射函数, 设所求的目标函数为: $f(x_i) = w \cdot \phi(x_i) + b$, $f(x_i)$ 为模型输出的锅炉燃烧指标预测值, w 为权重系数向量, b 为截距。引入松弛因子 $\xi_i^* \geq 0$ 和 $\xi_i \geq 0$ 和允许拟合误差 ϵ , 模型可以通过在约束:

$$[0072] \begin{cases} y_i - w \cdot \phi(x_i) - b \leq \epsilon + \xi_i \\ w \cdot \phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i \geq 0 \\ \xi_i^* \geq 0 \end{cases} \quad i = 1, \dots, N, \text{条件下, 最小化:}$$

$$[0073] \min R(w, \xi, \xi^*) = \frac{1}{2} w \cdot w + c \sum_{i=1}^k \xi_i + \xi_i^*$$

[0074] 获得, 其中常数 $c > 0$ 为惩罚系数。该最小化问题为一个凸二次规划问题, 引入拉格朗日函数:

$$[0075] L(w, b, \xi, \xi^*, \alpha, \alpha^*, \gamma, \gamma^*) = \frac{1}{2} w \cdot w + C \sum_{i=1}^N (\xi_i + \xi_i^*) - \sum_{i=1}^N \alpha_i [y_i - (\xi_i + \epsilon + f(x_i))]$$

$$[0076] - \sum_{i=1}^N \alpha_i^* [\xi_i^* + \epsilon + f(x_i) - y_i] - \sum_{i=1}^N (\gamma_i \xi_i + \gamma_i^* \xi_i^*)$$

[0077] 其中: $\alpha_i, \alpha_i^* \geq 0, \gamma_i, \gamma_i^* \geq 0$, 为拉格朗日乘数。

[0078] 在鞍点处, 函数 L 是关于 w, b, ξ_i, ξ_i^* 的极小点, 也是 $\alpha_i, \alpha_i^*, \gamma_i, \gamma_i^*$ 极大点, 最小化问题转化为求其对偶问题的最大化问题。

[0079] 拉格朗日函数 L 在鞍点处是关于 w, b, ξ_i, ξ_i^* 极小点, 得:

$$[0080] \begin{cases} \frac{\partial}{\partial w} L = 0 \rightarrow w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i) \\ \frac{\partial}{\partial b} L = 0 \rightarrow \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ \frac{\partial}{\partial \xi_i} L = 0 \rightarrow C - \alpha_i - \gamma_i = 0 \\ \frac{\partial}{\partial \xi_i^*} L = 0 \rightarrow C - \alpha_i^* - \gamma_i^* = 0 \end{cases}$$

[0081] 可得拉格朗日函数的对偶函数:

[0082]

$$\varpi(\alpha, \alpha^*)_{w,b,\xi,\xi^*} = -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j)$$

[0083]

$$-\sum_{i=1}^N (\alpha_i + \alpha_i^*) \varepsilon + \sum_{i=1}^N (\alpha_i + \alpha_i^*) y_i$$

[0084] 此时,

$$[0085] w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i)$$

$$[0086] f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b$$

[0087] 按照库恩 - 塔克 (KKT) 条件定理, 在鞍点有下式成立:

$$[0088] \begin{cases} \alpha_i [\varepsilon + \xi_i - y_i + f(x_i)] = 0 \\ \alpha_i^* [\varepsilon + \xi_i + y_i - f(x_i)] = 0 \end{cases} i = 1, \dots, N$$

[0089] 由上式可见, $\alpha_i \cdot \alpha_i^* = 0$, α_i 和 α_i^* 都不会同时为非零, 可得:

$$[0090] \begin{cases} \xi_i \gamma_i = 0 \\ \xi_i^* \gamma_i^* = 0 \end{cases} i = 1, \dots, N$$

[0091] 从上式可求出 b , 获得模型。

[0092] 集成技术与支持向量机相结合的步骤如下:

[0093] ①原始训练数据初始化权值为 $w_i^j = \frac{1}{N}$, $i = 1, 2, \dots, N$, j 为权重更新次数, 初始化权重时 $j = 1$, 设定迭代次数 k 。

[0094] ②调用以上支持向量机算法对训练样本建模, 获得一个模型 M_j , 计算 M_j 的平均预测误差的平方值: $\sigma_j = \sum_{i=1}^N w_i^j (M_j(x_i) - y_i)^2$

[0095] ③更新原始训练数据权重: $w_i^{j+1} = \frac{w_i^j (M_j(x_i) - y_i)^2}{\sigma_j}$

[0096] ④根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为:

[0097] $w_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 作为示例此处取 $\beta = \frac{1}{N}$, 产生一个子支持向量机的训练集。

[0098] ⑤重复步骤②~④获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成。

[0099] ⑥将获得的 k 个子支持向量机模型进行集成, 模型权重为: $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$, 最终获得

的集成模型为: $M_{final} = \sum_{j=1}^k \alpha_j M_j$

[0100] 对于数据量丰富的负荷段, 采用学习能力和函数逼近能力强的径向基神经网络建模:

[0101] 对于 n 个隐节点的径向基神经网络其输出为:

[0102] $y = \sum_{i=1}^n w_i \exp\left(-\frac{\|x - c_i\|^2}{2\rho_i^2}\right)$, w_i 为权重系数, x 为 m 维输入向量, c_i 为第 i 个基函数的中心, ρ_i 为函数的基宽度参数。建立径向基神经网络模型的关键在于确定基函数的中心 c_i , 基宽度 ρ_i 及权重系数 w_i 。采用粒子群算法迭代训练径向基神经网络, 定义粒子群算法初始群体 Z 向量的各维分量, 分别为隐节点个数、数基函数中心、函数的基宽度和权重系数, 目标函数为: $\min J = \sum_{i=1}^N (\tilde{y}_i - y_i)^2$, 其中 \tilde{y}_i 为第 i 个样本的神经网络输出值, y_i 为第 i 个样本的实际值。当 J 达到了最小、达到设定值或完成迭代次数时, 训练完成, 获得隐节点个数、基函数中心、函数的基宽度和权重系数, 从而获得径向基神经网络模型。

[0103] 集成技术与径向基神经网络相结合的步骤如下:

[0104] ①原始训练数据初始化权值为 $\lambda_i^j = \frac{1}{N}$, $i = 1, 2, \dots, N$, j 为权重更新次数, 初始化权重时 $j = 1$, 设定迭代次数 k 。

[0105] ②调用以上径向基神经网络集成建模方法对训练样本建模, 获得一个模型 M_j , 计算 M_j 的平均预测误差的平方值: $\sigma_j = \sum_{i=1}^N \lambda_i^j (M_j(x_i) - y_i)^2$

[0106] ③更新原始训练数据权重: $\lambda_i^{j+1} = \frac{\lambda_i^j (M_j(x_i) - y_i)^2}{\sigma_j}$

[0107] ④根据原始训练数据的新权值分布, 在原训练集进行采样, 采样条件为: $\lambda_i^{j+1} \geq \beta$, β 为设定的权重采样阀值, 作为示例此处取 $\beta = \frac{1}{N}$, 产生一个子径向基神经网络的训练集。

[0108] ⑤重复步骤②~④获得新的模型 M_{j+1} 和新的子训练集, 直到 k 次迭代完成。

[0109] ⑥将获得的 k 个子径向基神经网络模型进行集成, 模型权重为: $\alpha_i = \frac{1}{\sigma_i \sum_{i=1}^k \frac{1}{\sigma_i}}$, 最终

获得的集成模型为: $M_{final} = \sum_{j=1}^k \alpha_j M_j$

[0110] 集成技术具有较强的增量学习特点, 适合于适应锅炉燃烧中出现的新情况和变化。

[0111] (3) 利用粒子群优化算法结合所建模型, 针对不同对锅炉燃烧指标或指标组合进行锅炉燃烧参数配置的优化具体步骤如下:

[0112] ①定义粒子群位置向量 x 的各维分量, 分别为锅炉可调操作参数, 包括: 各层一次风速, 各层二次风速, 燃尽风速, 炉膛出口氧量。

[0113] ②设定粒子群的搜索目标和迭代次数, 搜索目标可以根据具体的锅炉运行情况为单一目标, 包括锅炉效率最高, NOx 排放最低或高温腐蚀最慢; 也可以是复合目标, 即以上两个或三个燃烧指标的组合, 组合方式为, 将各指标的变化折算为经济指标变化, 再将经济指标变化求总合, 以求达到综合最优。锅炉效率, NOx 排放和高温腐蚀情况分别由上文所建的各自相应模型预测获得。

[0114] ③根据实际锅炉的设计和运行要求设定个参数的寻优范围, 并初始化位置向量 x ,

然后根据上一步设定的搜索目标,用粒子群算法进行迭代计算,搜索粒子群在参数向量空间内的最优位置。

[0115] ④当粒子群算法完成迭代次数或找到设定要求的最优时,停止计算获得相应最优的位置向量,即获得最优的锅炉运行可调操作参数组合,根据所获得的最优可调操作参数组合对锅炉实际燃烧进行调整,达到燃烧优化的目的。