

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2024 年 6 月 27 日 (27.06.2024)



(10) 国际公布号
WO 2024/130992 A1

(51) 国际专利分类号:

G16C 20/10 (2019.01)

(21) 国际申请号:

PCT/CN2023/101309

(22) 国际申请日:

2023 年 6 月 20 日 (20.06.2023)

(25) 申请语言:

中文

(26) 公布语言:

中文

(30) 优先权:

202211651114.3 2022 年 12 月 21 日 (21.12.2022) CN

(71) 申请人: 北京工业大学 (BEIJING UNIVERSITY OF TECHNOLOGY) [CN/CN]; 中国北京市朝阳区平乐园 100 号, Beijing 100124 (CN)。

(72) 发明人: 汤健 (TANG, Jian); 中国北京市朝阳区平乐园 100 号, Beijing 100124 (CN)。夏恒 (XIA, Heng); 中国北京市朝阳区平乐园 100 号, Beijing 100124 (CN)。张润雨 (ZHANG, Runyu); 中国北

京市朝阳区平乐园 100 号, Beijing 100124 (CN)。乔俊飞 (QIAO, Junfei); 中国北京市朝阳区平乐园 100 号, Beijing 100124 (CN)。

(74) 代理人: 北京思海天达知识产权代理有限公司 (BEIJING SIHAI TIANDA INTELLECTUAL PROPERTY AGENT LTD.); 中国北京市朝阳区百子湾西里 403 号楼 10 层 1011 室, Beijing 100124 (CN)。

(81) 指定国(除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CV, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IQ, IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, MG, MK, MN, MU, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD,

(54) Title: ONLINE SOFT MEASUREMENT METHOD FOR DIOXIN (DXN) EMISSION CONCENTRATION DURING MSWI PROCESS

(54) 发明名称: 一种MSWI过程二噁英排放浓度在线软测量方法

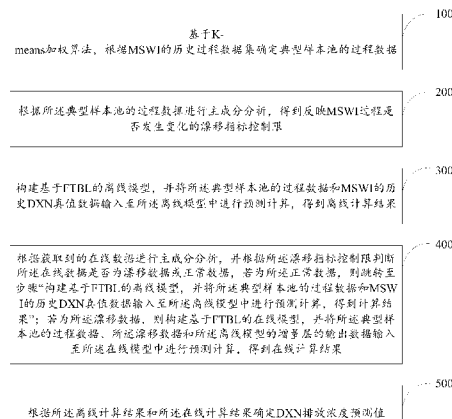


图 3

(57) Abstract: Provided in the present invention is an online soft measurement method for a dioxin (DXN) emission concentration during an MSWI process. The method comprises: determining process data according to a historical process data set of MSWI; performing principal component analysis according to the process data, so as to obtain a drift index control limit; constructing an FTBL-based offline model, and inputting the process data, and historical DXN true value data of MSWI into the offline model for prediction calculation; performing principal component analysis according to acquired online data, determining whether the online data is drift data or normal data according to the drift index control limit, and if the online data is normal data, skipping to the step of "constructing an FTBL-based offline model"; if the online data is drift data, constructing an FTBL-based online model, and inputting the process data of a typical sample pool, the drift data, and output data of an incremental layer of the offline model into the online model for prediction calculation; and determining a predicted DXN emission concentration value according to an offline calculation result and an online calculation result. The present invention can effectively improve the accuracy of the predicted DXN emission concentration value.

[见续页]

SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ,
UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW。

(84) 指定国(除另有指明, 要求每一种可提供的地区
保护): ARIPO (BW, CV, GH, GM, KE, LR, LS, MW, MZ,
NA, RW, SC, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚
(AM, AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE,
BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR,
HU, IE, IS, IT, LT, LU, LV, MC, ME, MK, MT, NL, NO,
PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF,
CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN,
TD, TG)。

本国际公布:
— 包括国际检索报告(条约第21条(3))。

(57) 摘要: 本发明提供了一种MSWI过程二噁英排放浓度在线软测量方法, 包括: 根据MSWI的历史过程数
据集确定过程数据; 根据过程数据进行主成分分析, 得到漂移指标控制限; 构建基于FTBL的离线模型, 并
将过程数据和MSWI的历史DXN真值数据输入至离线模型中进行预测计算; 根据获取到的在线数据进行主
成分分析, 并根据漂移指标控制限判断在线数据是否为漂移数据或正常数据, 若为正常数据, 则跳转至步
骤"构建基于FTBL的离线模型"; 若为漂移数据, 则构建基于FTBL的在线模型, 并将典型样本池的过程数
据、漂移数据和离线模型的增量层的输出数据输入至在线模型中进行预测计算; 根据离线计算结果和在线
计算结果确定DXN排放浓度预测值。本发明能够有效地提高DXN排放浓度预测值的准确性。

一种 MSWI 过程二噁英排放浓度在线软测量方法

技术领域

本发明涉及污染物监测技术领域，特别是涉及一种 MSWI 过程二噁英排放浓度在线软测量方法。

背景技术

二噁英(Dioxin, DXN)是城市固废焚烧(Municipal solid waste incineration, MSWI)过程中产生的持久性有机污染物,是需要通过优化控制实现最低排放的重要环境指标,但受限于检测技术、经济和人工成本等因素难以实时监测。

城市固废焚烧是实现废物发电的主要技术之一,已在世界范围内得到广泛应用。作为城市固废(Municipal solid waste, MSW)无害化、减量化和资源化处理的典型工业过程,虽然 MSWI 技术的优点大于缺点,但其排放气体中含的有毒有害物质一直是公众的焦点关注。二噁英是目前已知的对人体和环境毒性最大的持久性有机污染物,已成为制约 MSWI 技术发展的因素之一。由于 DXN 包含的化合物种类繁多且分析化验的步骤复杂、测量延迟大以及价格昂贵等原因,使得 DXN 排放浓度难以实时测量。DXN 是 MSWI 过程智能优化控制的重要环保指标。因此,应用软测量技术解决目前 DXN 离线检测的高经济和人工成本消耗问题的有效手段,也是实现 DXN 超低排放的基础。

目前软测量技术主要包括机理模型数据驱动模型两种策略。由于 DXN 的生成、吸附和排放机理尚不清晰,因此机理模型尚未出现。基于易于测量的过程变量的数据驱动模型因其高效、低成本和易于实现等优点而广泛应用。因此,本实施例研究基于 MSWI 过程数据构建面向 DXN 排放的软测量方法。

鉴于焚烧过程机理的复杂性、MSW 原料成分的波动性以及领域专家人工控制的随意性等原因,MSWI 过程的工况漂移现象频繁出现。此外,针对实际工程应用,建立可靠的 DXN 排放浓度软测量模型是很困难的。因此,DXN 排放的在线软测量需要解决以下问题:在 MSWI 过程中,温度、压力和流量等传感器数据所测量过程变量的波动是表征运行工况变化的主要依据,在软测量模型的在线应用阶段,如何根据过程数据识别运行状态的漂移变化以辅助实现准确检测和模型更新是当前面临的挑战之一;在线测量 DXN 排放浓度过程中如何保持对新数据(漂移数据)的持续快速学习能力,是软测量技术实现实际工程应用需要解决的关键问题;充分利用历史数据进行离线建模是实现在线软测量的第一步,如何选择历史数据构建具有低寻求你成本的离线模型并保持其最佳性能是 DXN 软测量建模需要解决的首要问题。

发明内容

为了克服现有技术的不足,本发明的目的是提供一种 MSWI 过程二噁英排放浓度在线软测量方法。

为实现上述目的,本发明提供了如下方案:

一种 MSWI 过程二噁英排放浓度在线软测量方法,包括:

基于 K-means 加权算法,根据 MSWI 的历史过程数据集确定典型样本池的过程数据;

根据所述典型样本池的过程数据进行主成分分析,得到反映 MSWI 过程

是否发生变化的漂移指标控制限；

构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到离线计算结果；所述离线模型包括特征映射层、增强层和增量层；

根据获取到的在线数据进行主成分分析，并根据所述漂移指标控制限判断所述在线数据是否为漂移数据或正常数据，若为所述正常数据，则跳转至步骤“构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到计算结果”；若为所述漂移数据，则构建基于 FTBL 的在线模型，并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算，得到在线计算结果；所述在线模型包括在线增量层；

根据所述离线计算结果和所述在线计算结果确定 DXN 排放浓度预测值。

优选地，所述基于 K-means 加权算法，根据 MSWI 的历史过程数据集确定典型样本池的过程数据包括：

获取 MSWI 的历史过程数据集 $\mathbf{X}^{\text{His}}$ ；

根据所述历史过程数据集 $\mathbf{X}^{\text{His}}$ 得到历史数据 $\mathbf{D}^{\text{His}} = \{\mathbf{x}_n, \mathbf{y}_n\}_n^N \in \mathbb{R}^{N \times (M+1)}$ ；其中， $\mathbf{x}_n$ 为第 n 个样本， $\mathbf{y}_n$ 为第 n 个样本对应的预测值； N 为 MSWI 的历史数据集的样本数， M 为 MSWI 的历史数据集的特征数；

随机选择 I 个实例作为初始质心 $\{C_i\}_{i=1}^I$ ，

根据样本与质心之间的加权欧氏距离，将所有样本列成 I 类：

$$C_i = C_i \cup \min\{d_n\}_{n=1}^N = C_i \cup \min\left\{\sqrt{[\mathbf{x}_n - C_i]^2 \mathbf{w}_{\text{TS}}^T}\right\}_{n=1}^N;$$

其中， C_i 表示第 i 个类； $\mathbf{w}_{\text{TS}}^T$ 表示过程变量的权重向量，其中， $w_{\text{TS}}^m = H(\mathbf{x}_m) - H(\mathbf{x}_m | \mathbf{y}) = \sum_{x_{n,m}} \sum_{y_n} p(x_{n,m}, y_n) \log_2 \frac{p(x_{n,m}, y_n)}{p(x_{n,m})p(y_n)}$ ；其中， $H(\cdot)$ 表示随机变

量的信息熵， $\mathbf{x}_m$ 为第 m 个特征向量， $\mathbf{y}$ 表示 DXN 浓度， $x_{n,m}$ 表示第 n 个样本的第 m 个特征值， $p(x_{n,m}) p(y_n)$ 表示边缘概率分布， $p(x_{n,m}, y_n)$ 为联合概率分布；

利用类间样本更新质心 C_i ：

$$C_i = \frac{1}{N_{C_i}} \sum_{x \in C_i} \mathbf{x}_n; \text{ 其中, } N_{C_i} \text{ 表示该第 } i \text{ 个聚类中的样本数量;}$$

对质心进行循环更新，并通过预设条件获得全部质心，所述预设条件表示为： $\{C_i\}_i^I \Leftarrow |R_{\text{iter}} - R_{\text{iter}-1}| \leq \delta^{\text{TS}}$ ；其中， δ^{TS} 为评价指标 R_{iter} 的阈值， iter 表示迭代次数，度量指标的计算公式为： $R_{\text{iter}} = \sum_{i=1}^I \sum_n^{N_{C_i}} [\mathbf{x}_n - C_i]^2 \mathbf{w}_{\text{TS}}^T$ ；

通过最小化聚类相似度建立 TSP，建立公式为：

$$R_{\text{DB}} = \min \left(\frac{1}{N} \sum_{n=1}^N (S_i + S_j) / M_{ij} \right); \text{ 其中, } R_{\text{DB}} \text{ 为聚类相似性度量指数; 其中, } S_i = \left((1/N_{C_i}) \sum |(\mathbf{x}_n - C_i) \mathbf{w}_{\text{TS}}^T|^a \right)^{1/a}, M_{ij} = \left\{ \sum |C_i - C_j|^b \right\}^{1/b}; \text{ 其中, } S_i \text{ 表示第 } i \text{ 类的距离之和,}$$

M_{ij} 表示闵可夫斯基度量准则。

优选地, 根据所述典型样本池的过程数据进行主成分分析, 得到反映 MSWI 过程是否发生变化的漂移指标控制限, 包括:

将 TSP 数据的相关系数矩阵 $D^{\text{TSP}} = \{x_n, y_n\}_n^{N_{\text{TSP}}} \in \mathbb{R}^{N_{\text{TSP}} \times (M+1)}$ 表示为 $R \approx \frac{1}{N_{\text{TSP}} - 1} [X^{\text{TSP}}]^T X^{\text{TSP}}$; 其中, N_{TSP} 为 TSP 数据 D^{TSP} 的个数; R 为 TSP 数据的相关系数矩阵;

对 R 进行奇异值分解, 并计算特征值; 计算公式为 $R = U^{M \times M} \Sigma^{M \times M} [V^{M \times M}]^T$; 其中, $U^{M \times M}$ 和 $V^{M \times M}$ 表示正交矩阵, $\Sigma^{M \times M}$ 是 M 维对角矩阵;

使用特征累计贡献率 η 和 PCA 贡献阈值 δ^{PCA} 进行降维:

$$\eta = \frac{\sum_{p_{\text{PCA}}=1}^{P_{\text{PCA}}} \sigma_{p_{\text{PCA}}}}{\sum_{m=1}^M \sigma_m}; \text{ 其中, } P_{\text{PCA}} \text{ 为所选主成分个数, } P_{\text{PCA}} \text{ 小于 } M;$$

$$\text{将计算公式重写为: } R = U^{M \times M} \Sigma^{M \times M} V^{M \times M} \approx U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} \Sigma_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T; \text{ 其中, } U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} \text{ 为负载}$$

矩阵;

根据得分矩阵 T 和负载矩阵 $U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}$, 将 x^{TSP} 表示为:

$$\begin{aligned} X^{\text{TSP}} &= X^{\text{TSP}} U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T + X^{\text{TSP}} (I^{P_{\text{PCA}} \times P_{\text{PCA}}} - U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T) \\ &= T [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T + \tilde{T} [\tilde{U}_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T; \\ &= \hat{X}^{\text{TSP}} + \tilde{X}^{\text{TSP}} \end{aligned}$$

其中, $\hat{X}^{\text{TSP}}$ 表示 x^{TSP} 在主成分空间上的投影, $\tilde{X}^{\text{TSP}}$ 表示 x^{TSP} 在残差空间上的投影; 所述 $\hat{X}^{\text{TSP}}$ 与 $\tilde{X}^{\text{TSP}}$ 满足正交关系;

此外, $\hat{X}^{\text{TSP}}$ 与 $\tilde{X}^{\text{TSP}}$ 满足正交关系, 证明如下:

$$\begin{aligned} [\hat{X}^{\text{TSP}}]^T \tilde{X}^{\text{TSP}} &= [X^{\text{TSP}} U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T]^T \cdot X^{\text{TSP}} (I^{P_{\text{PCA}} \times P_{\text{PCA}}} - U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T) \\ &= U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T [X^{\text{TSP}}]^T X^{\text{TSP}} (I^{P_{\text{PCA}} \times P_{\text{PCA}}} - U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T) \\ &= U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T [X^{\text{TSP}}]^T X^{\text{TSP}} I^{P_{\text{PCA}} \times P_{\text{PCA}}} - U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T [X^{\text{TSP}}]^T X^{\text{TSP}} U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T \\ \text{subject to } U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}} [U_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}]^T &= I^{P_{\text{PCA}} \times P_{\text{PCA}}} \\ &= [X^{\text{TSP}}]^T X^{\text{TSP}} - [X^{\text{TSP}}]^T X^{\text{TSP}} = 0 \end{aligned}$$

;

将所述漂移指标控制限表示为:

$$\begin{aligned} T_{\text{CL}}^2 &= \frac{P_{\text{PCA}}(N_{\text{TSP}} - 1)}{(N_{\text{TSP}} - P_{\text{PCA}})} F_{\alpha}(P_{\text{PCA}}, N_{\text{TSP}} - P_{\text{PCA}}); \\ SPE_{\text{CL}} &= \Theta_1 \left(\frac{c_{\alpha} \sqrt{2\Theta_2 h_0^2}}{\Theta_1} + 1 + \frac{\Theta_2 h_0 (h_0 - 1)}{\Theta_1^2} \right)^{1/h_0}; \end{aligned}$$

其中, T_{CL}^2 为 Hotelling's T^2 的控制限, SPE_{CL} 为 SPE 的控制限, P_{PCA} 为所选主成分个数 $F_{\alpha}(P_{\text{PCA}}, N_{\text{TSP}} - P_{\text{PCA}})$ 表示自由度为 P_{PCA} 和 $(N_{\text{TSP}} - P_{\text{PCA}})$ 的 F 分布; c_{α} 表示不超过 $(1-\alpha)$ 的正态偏差; Θ_1 、 Θ_2 和 h_0 的计算如下所示:

$$\begin{aligned} h_0 &= 1 - 2\Theta_1 \Theta_3 / 3\Theta_1^2; \\ \Theta_i &= \sum_{m=P_{\text{PCA}}+1}^M (\sigma_m)^i, \quad i=1, 2, 3; \end{aligned}$$

其中, h_0 、 Θ_1 和 Θ_2 均为 SPE 控制限计算的中间变量, σ_m 为奇异值分解的特征值。

优选地, 所述构建基于 FTBL 的离线模型, 并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算, 得到离线计算结果, 包括:

针对给定 TSP 数据 $\mathbf{D}^{\text{TSP}} = \{\mathbf{x}_n, \mathbf{y}_n\}_n^{N_{\text{TSP}}} \in \mathbb{R}^{N_{\text{TSP}} \times (M+1)}$, 在 $\mathbf{D}^{\text{TSP}}$ 中随机选择一个特征值 x 定义节点分裂函数 $\mu'_{\text{CS}}(x)$, 其表示为: $\mu'_{\text{CS}}(x) = \text{rand}(n, m)$, $n \in (1, N_{\text{TSP}})$ and $m \in (1, M)$; 其中, $\mu'_{\text{CS}}(x)$ 为符号函数, $\text{rand}(\cdot)$ 为随机数生成函数, n 和 m 不取最大值和最小值;

对 TS 模糊推理确定 K 个模糊规则, 其第 k 个规则可表示为:
 $R_k: \text{if } x_1^{\text{leaf}} \text{ is } \phi_1^k(x_1^{\text{leaf}}) \text{ and } \dots \text{ and } x_{M^{\text{leaf}}}^{\text{leaf}} \text{ is } \mu_{M^{\text{leaf}}}^k(x_{M^{\text{leaf}}}^{\text{leaf}})$; 其中, $\phi_m^k(x_m^{\text{leaf}}) = \exp\left[-(x_m^{\text{leaf}} - c_{k,m})^2 / \sigma_{k,m}^2\right]$;
 then $y^k = g^k(x_1, \dots, x_{M^{\text{leaf}}})$

其中, R_k 为第 k 条模糊规则, $c_{k,m}$ 和 $\sigma_{k,m}$ 分别表示高斯函数 $\phi_m^k(\cdot)$ 的中心和宽度, t_{leaf} 表示第 t_{leaf} 个叶节点; $\phi_m^k(\cdot)$ 为高斯函数;

根据上述 K 个模糊规则, FDT 的结果描述为:

$$\hat{y}_i = f(\mathbf{x}_i) = \sum_{k=1}^K \bar{o}^k g^k(\mathbf{x}_i) \quad ; \quad \text{其中}, \quad \bar{o}^k = \prod_{m=1}^{M^{\text{leaf}}} \phi_m^k(x_m^{\text{leaf}}) / \sum_{i=1}^K \left(\prod_{m=1}^{M^{\text{leaf}}} \phi_m^k(x_m^{\text{leaf}}) \right) ;$$

$g^k(\mathbf{x}_i^{\text{Lcaf}}) = \mathbf{x}_i^{\text{Lcaf}} \omega_{\text{TS}}^k$; 其中, $f(\cdot)$ 为 FDT 模型, $\bar{o}^k$ 和 $g^k(\cdot)$ 表示 TS 模糊推理的前件和后件部分, ω_{TS}^k 表示后件部分特征的权重;

应用梯度下降法更新 FDT 模型 $f(\cdot)$ 训练过程中的参数, 所述参数包括中心 c_k 、宽度 σ_k 和权重 ω_{TS}^k ; 所述特征映射层输出表示如下:

$\mathbf{Z}_{\text{FM}}^{\text{NFM}} = [\mathbf{z}_{\text{FM}}^1, \mathbf{z}_{\text{FM}}^2, \dots, \mathbf{z}_{\text{FM}}^{N_{\text{FM}}}] \in \mathbb{R}^{N_{\text{TSP}} \times N_{\text{FM}}}$; 其中, $\mathbf{z}_{\text{FM}}^n = f_{n_{\text{FM}}}^{\text{FM}}(\mathbf{X}^{\text{TSP}}) \in \mathbb{R}^{N_{\text{TSP}} \times 1}$; 其中, $\mathbf{z}_{\text{FM}}^n$ 是第 n_{FM} 个 FDT 模型通过输入 $\mathbf{X}^{\text{TSP}}$ 的输出。

增强层以 $\mathbf{z}_{\text{FM}}^{\text{NFM}}$ 作为输入, 所述增强层的输出表示为:

$\mathbf{Z}_{\text{En}}^{\text{NEn}} = [\mathbf{z}_{\text{En}}^1, \mathbf{z}_{\text{En}}^2, \dots, \mathbf{z}_{\text{En}}^{N_{\text{En}}}] \in \mathbb{R}^{N_{\text{TSP}} \times N_{\text{En}}}$; 所述特征映射层和所述增强层的输出为 $\mathbf{G}^{\text{NFM} + \text{NEn}} = [\mathbf{Z}_{\text{FM}}^{\text{NFM}} | \mathbf{Z}_{\text{En}}^{\text{NEn}}]$;

利用岭回归学习算法计算 $\mathbf{G}^{\text{NFM} + \text{NEn}}$ 与预测输出之间的权重 $\mathbf{W}^{\text{NFM} + \text{NEn}}$, 如下所示:

$$\mathbf{W}^{\text{NFM} + \text{NEn}} = (\lambda \mathbf{I} + \mathbf{G}^{\text{NFM} + \text{NEn}} (\mathbf{G}^{\text{NFM} + \text{NEn}})^{\text{T}})^{-1} (\mathbf{G}^{\text{NFM} + \text{NEn}})^{\text{T}} \mathbf{y}^{\text{TSP}} ; \text{其中}, (\mathbf{G}^{\text{NFM} + \text{NEn}})^* \text{ 为伪逆矩阵},$$

$$= (\mathbf{G}^{\text{NFM} + \text{NEn}})^* \mathbf{y}^{\text{TSP}}$$

λ 为正则化系数, $\mathbf{I}$ 为单位矩阵;

在增量层中增加 FDT 模型, 并动态更新伪逆矩阵, 以 $\mathbf{z}_{\text{En}}^{\text{NEn}}$ 作为输入, $\mathbf{G}^{\text{NFM} + \text{NEn} + 1} = [\mathbf{Z}_{\text{FM}}^{\text{NFM}} | \mathbf{Z}_{\text{En}}^{\text{NEn}} | \mathbf{z}_{\text{En}}^{\text{NEn}}]$ 作为输出; 增量过程的伪逆矩阵更新过程如下:

$$[\mathbf{G}^{\text{NFM} + \text{NEn} + 1}]^* = \begin{bmatrix} [\mathbf{G}^{\text{NFM} + \text{NEn}}]^{-1} & -\mathbf{D}\mathbf{B}^{\text{T}} \\ \mathbf{B}^{\text{T}} & \end{bmatrix} ; \text{其中}, \begin{cases} \mathbf{D} = [\mathbf{G}^{\text{NFM} + \text{NEn} + 1}]^* \mathbf{H}_{k+1} \\ \mathbf{B}^{\text{T}} = \begin{cases} [\mathbf{C}]^{\text{T}}, & \text{if } C \neq 0 \\ [1 + \mathbf{D}^{\text{T}} \mathbf{D}]^{-1} \mathbf{D}^{\text{T}} [\mathbf{G}^{\text{NFM} + \text{NEn} + 1}]^{\text{T}}, & \text{if } C = 0 \end{cases} ; \mathbf{D}, \mathbf{H}_{k+1}, \mathbf{B}^{\text{T}}, \\ \mathbf{C} = \mathbf{H}_{k+1} - \mathbf{G}^{\text{NFM} + \text{NEn} + 1} \mathbf{D} \end{cases}$$

$\mathbf{C}$ 均为伪逆矩阵更新过程的中间变量;

新的权重矩阵 $\mathbf{W}^{\text{NFM} + \text{NEn} + 1}$ 表示为:

$$\mathbf{W}^{N_{FM}+N_{En}+1} = \begin{bmatrix} \mathbf{W}^{N_{FM}+N_{En}} - \mathbf{D}\mathbf{B}^T \mathbf{y}^{TSP} \\ \mathbf{B}^T \mathbf{y}^{TSP} \end{bmatrix};$$

离线模型 FTBL 的预测计算过程如下:

$$\hat{\mathbf{y}} = \mathbf{G}^{N_{FM}+N_{En}+1} \mathbf{W}^{N_{FM}+N_{En}+1}.$$

优选地,所述根据获取到的在线数据进行主成分分析,并根据所述漂移指标控制限判断所述在线数据是否为漂移数据或正常数据,若为所述正常数据,则跳转至步骤“构建基于 FTBL 的离线模型,并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算,得到计算结果”;若为所述漂移数据,则构建基于 FTBL 的在线模型,并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算,得到在线计算结果,包括:

基于下式计算新窗口内的漂移值:

$$T_{O_i}^2 = \mathbf{x}_{O_i}^T \mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}} \Sigma_{N_{TSP}+1}^{-1} (\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}})^T \mathbf{x}_{O_i};$$

$SPE_{O_i} = \mathbf{x}_{O_i}^T \left(\mathbf{I} - \mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}} (\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}})^T \right) \mathbf{x}_{O_i}$; 其中, $T_{O_i}^2$ 和 SPE_{O_i} 是第 $(N_{TSP}+1)$ 个过程数据 $\mathbf{x}_{O_i}$ 的统计指标, $\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}}$ 表示新的负荷矩阵, $\Sigma_{N_{TSP}+1}^{-1}$ 表示新的对角矩阵;

通过判断公式确定样本为漂移样本或正常样本;所述判断公式为:

$$\begin{cases} \text{漂移,} & \text{if } T_{O_i}^2 > T_{CL}^2 \text{ and } SPE_{O_i} > SPE_{CL} \\ \text{正常,} & \text{其它} \end{cases};$$

针对正常样本,重用所述 FTBL 的离线模型进行 DXN 浓度软测量,可表示为:

$$\begin{aligned} \hat{\mathbf{y}}_{O_i} &= \mathbf{G}^{k+N_{In}} \mathbf{W}^{k+N_{In}} \\ &= [\mathbf{Z}_{FM}^{N_{FM}} | \mathbf{Z}_{En}^{N_{En}} | \mathbf{Z}_{In}^{N_{In}}] \mathbf{W}^{k+N_{In}} \\ &= [f_1^{FM}(\mathbf{x}_{O_i}), \dots, f_{N_{FM}}^{FM}(\mathbf{x}_{O_i}) | f_1^{En}(\mathbf{x}_{O_i}), \dots, f_{N_{En}}^{En}(\mathbf{x}_{O_i}) | f_1^{In}(\mathbf{x}_{O_i}), \dots, f_{N_{In}}^{In}(\mathbf{x}_{O_i})] \mathbf{W}^{k+N_{In}}; \end{aligned}$$

针对漂移样本,软测量值计算方式为:

$$\hat{\mathbf{y}}_{O_i} = \mathbf{G}^{k+N_{In}} \mathbf{W}^{k+N_{In}} + \varepsilon_{Offset}; \text{ 其中, } \varepsilon_{Offset} \text{ 为离线 FTBL 预测输出的偏移值, 如下:}$$

$$\varepsilon_{Offset} = \begin{cases} +\frac{1}{N_t} \sum (\hat{\mathbf{y}}_t - E(\hat{\mathbf{y}})), & \text{if } x_{IncTem} < E(x_{IncTem}) \\ -\frac{1}{N_t} \sum (\hat{\mathbf{y}}_t - E(\hat{\mathbf{y}})), & \text{if } x_{IncTem} \geq E(x_{IncTem}) \end{cases}; \text{ 其中, } N_t \text{ 表示到达 } t \text{ 时刻的全部数}$$

据量, $\hat{\mathbf{y}}$ 表示到达 t 时刻的所有预测值, $E(\hat{\mathbf{y}})$ 表示向量 $\hat{\mathbf{y}}$ 的数学期望, x_{IncTem} 表示 t 时刻的焚烧炉温度。

当检测真值存在时,将 TSP 数据、漂移数据和增量层的输出输入至所述在线模型中;所述在线模型的预测值为:

$$\hat{\mathbf{y}}_{O_i} = \mathbf{G}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \mathbf{W}^{N_{FM}+N_{En}+N_{In}+N_{OI}}; \text{ 其中, } \mathbf{W}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \text{ 表示权重矩阵, } \mathbf{G}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \text{ 是 } N_{FM}+N_{En}+N_{In}+N_{OI} \text{ FDT 的输出矩阵。}$$

根据本发明提供的具体实施例,本发明公开了以下技术效果:

本发明提供了一种 MSWI 过程二噁英排放浓度在线软测量方法,其特征

在于，包括：基于 K-means 加权算法，根据 MSWI 的历史过程数据集确定典型样本池的过程数据；根据所述典型样本池的过程数据进行主成分分析，得到反映 MSWI 过程是否发生变化的漂移指标控制限；构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到离线计算结果；所述离线模型包括特征映射层、增强层和增量层；根据获取到的在线数据进行主成分分析，并根据所述漂移指标控制限判断所述在线数据是否为漂移数据或正常数据，若为所述正常数据，则跳转至步骤“构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到计算结果”；若为所述漂移数据，则构建基于 FTBL 的在线模型，并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算，得到在线计算结果；所述在线模型包括在线增量层；根据所述离线计算结果和所述在线计算结果确定 DXN 排放浓度预测值。本发明能够有效地提高 DXN 排放浓度预测值的准确性。

附图说明

为了更清楚地说明本发明实施例或现有技术中的技术方案，下面将对实施例中所需要使用的附图作简单地介绍，显而易见地，下面描述中的附图仅仅是本发明的一些实施例，对于本领域普通技术人员来讲，在不付出创造性劳动性的前提下，还可以根据这些附图获得其他的附图。

图 1 为本发明实施例提供的 MSWI 过程和 DXN 排放示意图；

图 2 为本发明实施例提供的 DXN 浓度测量过程示意图；

图 3 为本发明实施例提供的方法流程图；

图 4 为本发明实施例提供的 DXN 浓度软测量策略示意图；

图 5 为本发明实施例提供的模糊决策树示意图；

图 6 为本发明实施例提供的 DXN 数据的第一示意图；

图 7 为本发明实施例提供的 DXN 数据的第二示意图；

图 8 为本发明实施例提供的不同方法的训练数据拟合曲线示意图；

图 9 为本发明实施例提供的不同方法的测试数据拟合曲线示意图；

图 10 为本发明实施例提供的典型样本的三维曲线示意图；

图 11 为本发明实施例提供的典型样本的二维曲线示意图；

图 12 为本发明实施例提供的删除冗余样本的典型样本的三维曲线示意图；

图 13 为本发明实施例提供的 T^2 曲线示意图；

图 14 为本发明实施例提供的 SPE 曲线示意图；

图 15 为本发明实施例提供的离线阶段预测结果示意图

图 16 为本发明实施例提供的在线阶段预测结果示意图

图 17 为本发明实施例提供的实验室仿真应用测试示意图；

图 18 为本发明实施例提供的工业现场在线应用测试示意图。

具体实施方式

下面将结合本发明实施例中的附图，对本发明实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例仅仅是本发明一部分实施例，而不是

全部的实施例。基于本发明中的实施例，本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例，都属于本发明保护的范围。

在本实施例中提及“实施例”意味着，结合实施例描述的特定特征、结构或特性可以包含在本申请的至少一个实施例中。在说明书中的各个位置出现该短语并不一定均是指相同的实施例，也不是与其它实施例互斥的独立的或备选的实施例。本领域技术人员显式地和隐式地理解的是，本实施例所描述的实施例可以与其它实施例相结合。

本申请的说明书和权利要求书及所述附图中的术语“第一”、“第二”、“第三”和“第四”等是用于区别不同对象，而不是用于描述特定顺序。此外，术语“包括”和“具有”以及它们任何变形，意图在于覆盖不排他的包含。例如包含了一系列步骤、过程、方法等没有限定于已列出的步骤，而是可选地还包括没有列出的步骤，或可选地还包括对于这些过程、方法、产品或设备固有的其它步骤元。

本发明的目的是提供一种 MSWI 过程二噁英排放浓度在线软测量方法，能够有效地提高 DXN 排放浓度预测值的准确性。

为使本发明的上述目的、特征和优点能够更加明显易懂，下面结合附图和具体实施方式对本发明作进一步的说明。

如图 1 所示，本实施例将 MSWI 过程分为五个阶段，依次为：

(1)MSW 通过机械抓斗送入料斗，然后通过移动炉排输送到焚烧炉；

(2)在 850℃以上的高温环境中，MSW 在炉排上经过干燥、热解和气化等阶段形成灰渣；

(3)高温烟气的热能通过水冷壁、过热器、蒸发器、省煤器、汽包等热交换装置转化为高温高压蒸汽，然后利用蒸汽驱动汽轮发电机，实现废物转化为能源；

(4)采用选择性非催化还原(SNCR)系统脱硝、活性炭吸附、半干脱酸、袋式除尘器等对 MSWI 过程产生的有毒有害物质(如 CO、HCl、SO₂、NO_x、颗粒物、DXN)进行烟气净化；

(5)符合污染物控制排放标准(GB18485-2014) 的烟气，通过 80 米高的烟囱排放到大气中。

研究表明，原生 MSW 中含有微量的 DXN。DXN 在 MSW 的燃烧和净化过程中依次经过高温分解、低温从头合成、活性炭吸附和布袋除尘后，剩余微量 DXN 被排放到大气中。此外，由于飞灰在 MSWI 设备中的累积作用，导致 DXN 具有显著的“记忆效应”。因此，应用软测量方法检测 DXN 排放浓度是一项具有挑战性的任务。通常，MSWI 过程的 DXN 排放浓度检测位置位于烟囱入口处(即图 1 中烟气与烟囱相交处的圆点标记的位置)。

迄今为止，DXN 排放浓度的检测主要依靠人工现场采样和实验室分析。检测过程如图 2 所示。

在图 2 中，第一阶段是现场工程师手动现场取样，需要使用恒速采样装置两小时连续采集管道中的实时烟气，得到石英滤筒(固相)、树脂筒(气相)和凝析液(液相)，然后将其包装后被送往实验室分析；第二阶段是样品分析，这些

样品需要进行预处理、提取和索氏提取，然后放入指定的试剂瓶中，然后使用高分辨率气相色谱-高分辨率质谱(HRGC/HRMS)设备对样品进行分析；第三阶段为分析计算 HRGC/HRMS 数据，获得包含 17 种化合物的 DXN 浓度报告。

DXN 浓度检测存在耗时长、人工和材料成本高的缺点，无法连续、及时地反映焚烧炉的 DXN 排放情况，同时导致基于上述实验获取的 DXN 建模数据具有样本量小、维数高的特点。此外，由于 DXN 机理不清，检测环节人为干扰因素较多，基于实际 DXN 数据的软测量技术很难达到令人满意的检测精度。因此，研究具有稳定高性能的 DXN 排放浓度软测量模型是一项巨大的挑战。

图 3 为本实施例提供的一种 MSWI 过程二噁英排放浓度在线软测量方法，包括：

步骤 100：基于 K-means 加权算法，根据 MSWI 的历史过程数据集确定典型样本池的过程数据；

步骤 200：根据所述典型样本池的过程数据进行主成分分析，得到反映 MSWI 过程是否发生变化的漂移指标控制限；

步骤 300：构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到离线计算结果；所述离线模型包括特征映射层、增强层和增量层；

步骤 400：根据获取到的在线数据进行主成分分析，并根据所述漂移指标控制限判断所述在线数据是否为漂移数据或正常数据，若为所述正常数据，则跳转至步骤“构建基于 FTBL 的离线模型，并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算，得到计算结果”；若为所述漂移数据，则构建基于 FTBL 的在线模型，并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算，得到在线计算结果；所述在线模型包括在线增量层；

步骤 500：根据所述离线计算结果和所述在线计算结果确定 DXN 排放浓度预测值。

本实施例所提 DXN 排放浓度软测量结构如图 4 所示，包括离线和在线两个阶段。在离线阶段，采用 TSP、FTBL 算法和 PCA 分析获得基于历史过程数据的离线模型和漂移指标控制限。在在线阶段，采用滑动窗口递归 PCA 自适应监视过程实现漂移检测、在线测量以及 FTBL 动态学习。图 4 中，不同符号的含义如下表 1 所示。

表 1

序号	符号	含义
1	H_N	第 N 条 MSWI 的历史过程数据
2	O_T	第 T 时刻 MSWI 的在线过程数据
3	X^{His}	MSWI 的历史过程数据集
4	N	MSWI 的历史数据集的样本数
5	M	MSWI 的历史数据集的特征数

6	$\mathbf{X}^{\text{TSP}}$	典型样本池的过程数据
7	N^{TSP}	典型样本池的样本数
8	$\mathbf{y}^{\text{His}}$	MSWI 的历史 DXN 真值数据
9	$f_i^{\text{FM}}(\cdot), i=1 \cdots n$	特征映射层中的 FDT 模型
10	$\mathbf{Z}_{\text{FM}}^n$	特征映射层的输出矩阵
11	$f_1^{\text{En}}(\cdot), i=1 \cdots k$	增强层中的 FDT 模型
12	$\mathbf{Z}_{\text{En}}^k$	增强层的输出矩阵
13	$f_1^{\text{In}}(\cdot), i=1 \cdots p$	增量层中的 FDT 模型
14	$\mathbf{Z}_{\text{In}}^p$	增量层的输出矩阵
15	$\mathbf{X}^{\text{DS}}$	在线窗口中的漂移样本集
16	$f_1^{\text{OI}}(\cdot), i=1 \cdots Q$	FDT 模型在在线增量层的函数
17	$\mathbf{Z}_{\text{OI}}^p$	在线增量层的输出矩阵
18	$\mathbf{W}^{n+k+p}$	权重矩阵
19	$\hat{\mathbf{y}}$	DXN 排放浓度预测
20	$\mathbf{D}^{\text{His}}$	历史数据
21	C_i	第 i 个质心
22	$\mathbf{x}_n$	第 n 个样本
23	$\mathbf{w}_{\text{TS}}^{\text{T}}$	过程变量的权重
24	d_n	加权欧氏距离
25	$H(\cdot)$	随机变量的熵
26	$\mathbf{x}_m$	第 m 个特征向量
27	$x_{n,m}$	第 n 个样本的第 m 个特征值
28	$p(\cdot)$	边缘概率分布
29	$p(\cdot, \cdot)$	联合概率分布
30	N_{C_i}	聚类中第 i 个样本数量
31	R_{iter}	聚类样本与质心之间的欧氏距离之和
32	δ^{TS}	评价指标 R_{iter} 的阈值
33	R_{DB}	聚类相似性度量指数
34	S_i	第 i 类的距离之和
35	M_{ij}	表示闵可夫斯基度量准则
36	$\mathbf{D}^{\text{TSP}}$	典型样本池数据
37	N_{TSP}	$\mathbf{D}^{\text{TSP}}$ 的样本数量
38	R	TSP 数据的相关系数矩阵
39	$\mathbf{U}^{M \times M}$	奇异值分解的正交矩阵
40	$\mathbf{V}^{M \times M}$	奇异值分解的正交矩阵
41	σ_m	奇异值分解的特征值
42	η	特征累计贡献率
43	δ^{PCA}	PCA 贡献阈值
44	P_{PCA}	所选主成分个数
45	$\mathbf{T}$	得分矩阵
46	$\mathbf{U}_{\text{Key}}^{P_{\text{PCA}} \times P_{\text{PCA}}}$	负载矩阵

47	$\hat{\mathbf{X}}^{\text{TSP}}$	$\mathbf{x}^{\text{TSP}}$ 在主成分空间上的投影
48	$\tilde{\mathbf{X}}^{\text{TSP}}$	$\mathbf{x}^{\text{TSP}}$ 在残差空间上的投影
49	T_{CL}^2	Hotelling's T^2 的控制限
50	SPE_{CL}	SPE 的控制限
51	$F_{\alpha}(P_{\text{PCA}}, N_{\text{TSP}} - P_{\text{PCA}})$	自由度为 P_{PCA} 和 $(N_{\text{TSP}} - P_{\text{PCA}})$ 的 F 分布
52	c_{α}	不超过 $(1-\alpha)$ 的正态偏差
53	Θ_1	SPE 控制限计算的中间变量
54	Θ_2	SPE 控制限计算的中间变量
55	h_0	SPE 控制限计算的中间变量
56	$\mu_{\text{CS}}^i(x)$	节点分裂函数 (符号函数)
57	$\text{rand}(\cdot)$	随机数生成函数
58	$\mathbf{D}^{\text{Leaf}}$	叶节点样本集
59	$\mathbf{x}_i^{\text{Leaf}}$	节点中样本集中的过程数据
60	R_k	第 k 条模糊规则
61	$\phi_n^k(\cdot)$	高斯函数
62	$c_{k,m}$	高斯函数 $\phi_n^k(\cdot)$ 的中心
63	$\sigma_{k,m}$	高斯函数 $\phi_n^k(\cdot)$ 的宽度
64	t_{leaf}	第 t_{leaf} 个叶节点
65	$\bar{o}^k$	TS 模糊推理的前件部分
66	$g^k(\cdot)$	TS 模糊推理的后件部分
67	ω_{TS}^k	TS 模糊推理后件部分各特征的权重
68	$\mathbf{Z}_{\text{FM}}^{N_{\text{FM}}}$	特征映射层输出
69	$\mathbf{z}_{\text{FM}}^{n_{\text{FM}}}$	第 n_{FM} 个 FDT 模型的输出
70	$\mathbf{Z}_{\text{En}}^{N_{\text{En}}}$	增强层的输出
71	$\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}}$	特征映射层和增强层的输出
72	$\mathbf{W}^{N_{\text{FM}}+N_{\text{En}}}$	$\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}}$ 与预测输出之间的权重
73	λ	岭回归的正则化系数
74	$(\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}})^*$	伪逆矩阵
75	$\mathbf{I}$	单位矩阵
76	$\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}+1}$	特征映射层、增强层和增量层的输出
77	$\mathbf{W}^{N_{\text{FM}}+N_{\text{En}}+1}$	$\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}+1}$ 与预测输出之间的权重
78	$[\mathbf{G}^{N_{\text{FM}}+N_{\text{En}}+1}]^*$	伪逆矩阵
79	$\mathbf{D}$	伪逆矩阵更新过程的中间变量
80	$\mathbf{H}_{k+1}$	伪逆矩阵更新过程的中间变量
81	$\mathbf{B}^T$	伪逆矩阵更新过程的中间变量
82	$\mathbf{C}$	伪逆矩阵更新过程的中间变量
83	$T_{\text{O}_i}^2$	第 $(N_{\text{TSP}} + 1)$ 个过程数据 (x_{O_i}) 的 T2 统计指标
84	SPE_{O_i}	第 $(N_{\text{TSP}} + 1)$ 个过程数据 (x_{O_i}) 的 SPE 统计指标
85	$\mathbf{U}_{N_{\text{TSP}}+1}^{P_{\text{PCA}} \times P_{\text{PCA}}}$	新的负荷矩阵
86	$\Sigma_{N_{\text{TSP}}+1}^{-1}$	对角矩阵 (即 $\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_{P_{\text{PCA}}})$)
87	$\hat{y}_{\text{O}_i}$	第 t 时刻 MSWI 过程数据的预测值

88	$\varepsilon_{\text{Offset}}$	离线 FTBL 预测输出的偏移值
89	N_t	到达 t 时刻的全部数据量
90	$\hat{y}$	到达 t 时刻的所有预测值
91	$E(\hat{y})$	向量 $\hat{y}$ 的数学期望
92	x_{IncTem}	t 时刻的焚烧炉温度
93	X^{Dri}	漂移数据
94	$Z_{\text{In}}^{N_{\text{In}}}$	增量层的输出
95	$W^{N_{\text{FM}}+N_{\text{FS}}+N_{\text{In}}+N_{\text{Out}}}$	$G^{N_{\text{FM}}+N_{\text{FS}}+N_{\text{In}}+N_{\text{Out}}}$ 与预测输出之间的权重

本实施例首先构建基于 k-means 的典型样品池获取模块, 通常, 从复杂工业过程采集的历史数据具有高维数、强相关性和高冗余度等特点, 导致建模数据和有价值信息之间存在不对称问题。因此, 本实施例提出加权 k-means 构建典型样品池(TSP)的方法。理论上, 基于 TSP 可获得与原始数据集具有相同(或更高)的建模性能。

根据历史数据 $D^{\text{His}} = \{x_n, y_n\}_n^N \in \mathbb{R}^{N \times (M+1)}$, 首先随机选择 I 个实例作为初始质心 $\{C_i\}_{i=1}^I$, 然后根据样本与质心之间的加权欧氏距离, 将所有样本列成 I 类:

$$\begin{aligned} C_i &= C_i \cup \min\{d_n\}_{n=1}^N \\ &= C_i \cup \min\left\{\sqrt{[x_n - C_i]^2 w_{\text{TS}}^T}\right\}_{n=1}^N \end{aligned} \quad (1)$$

其中, C_i 表示第 i 个类; x_n 代表第 n 个样本; w_{TS}^T 表示过程变量的权重向量, 其由过程变量与 DXN 浓度之间的信息值确定, 如下所示:

$$\begin{aligned} w_{\text{TS}}^m &= H(x_m) - H(x_m | y) \\ &= \sum_{x_{n,m}} \sum_{y_n} p(x_{n,m}, y_n) \log_2 \frac{p(x_{n,m}, y_n)}{p(x_{n,m}) p(y_n)} \end{aligned} \quad (2)$$

其中, $H(\cdot)$ 表示随机变量的信息熵, x_m 为第 m 个特征向量, y 表示 DXN 浓度, $x_{n,m}$ 表示第 n 个样本的第 m 个特征值, $p(x_{n,m}) p(y_n)$ 表示边缘概率分布, $p(x_{n,m}, y_n)$ 为联合概率分布。

利用类间样本更新质心 C_i :

$$C_i = \frac{1}{N_{C_i}} \sum_{x \in C_i} x_n \quad (3)$$

其中, N_{C_i} 表示该第 i 个聚类中的样本数量。

利用式(1)-(3)对质心进行循环更新, 最终通过以下条件获得全部质心, 可表示为:

$$\{C_i\}_i^I \Leftarrow |R_{\text{iter}} - R_{\text{iter}-1}| \leq \delta^{\text{TS}} \quad (4)$$

其中, δ^{TS} 为评价指标 R_{iter} 的阈值, iter 表示迭代次数, 度量指标的计算如下:

$$R_{\text{iter}} = \sum_{i=1}^I \sum_n [x_n - C_i]^2 w_{\text{TS}}^T \quad (5)$$

由上式可知, 其表示聚类样本与质心之间的欧氏距离之和。

然后, 通过最小化聚类相似度建立 TSP, 可表示为:

$$R_{\text{DB}} = \min \left(\frac{1}{N} \sum_{n=1}^N (S_i + S_j) / M_{ij} \right) \quad (6)$$

其中, R_{DB} 为聚类相似性度量(CSM)指数。

$$S_i = \left\{ (1/N_{C_i}) \sum \left| (x_n - C_i) w_{TS}^T \right|^a \right\}^{1/a} \quad (7)$$

$$M_{ij} = \left\{ \sum |C_i - C_j|^b \right\}^{1/b} \quad (8)$$

其中, S_i 表示第 i 类的距离之和, M_{ij} 表示闵可夫斯基度量准则。

其次, 本实施例构建有基于 PCA 的漂移指标计算模块, 针对高维过程变量, 本实施例采用主成分分析(PCA)模型计算用于确定 MSWI 过程是否发生变化的漂移指标控制限。

首先, 将 TSP 数据的相关系数矩阵 $D^{TSP} = \{x_n, y_n\}_n^{N_{TSP}} \in \mathbb{R}^{N_{TSP} \times (M+1)}$ 表示如下:

$$R \approx \frac{1}{N_{TSP} - 1} [X^{TSP}]^T X^{TSP} \quad (9)$$

其中, N_{TSP} 为 TSP 数据 D^{TSP} 的个数。

为了获得能够表征原始高维过程变量的潜在变量即主成分, 本实施例对 R 进行奇异值分解(SVD), 并计算特征值:

$$R = U^{M \times M} \Sigma^{M \times M} [V^{M \times M}]^T \quad (10)$$

其中, $U^{M \times M}$ 和 $V^{M \times M}$ 表示正交矩阵($V^{M \times M} = [U^{M \times M}]^T$), $\Sigma^{M \times M}$ 是 M 维对角矩阵(即 $\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_M)$), σ_m 是对角线上的特征值。

本实施例使用特征累计贡献率 η 和 PCA 贡献阈值 δ^{PCA} 进行降维:

$$\eta = \frac{\sum_{p_{PCA}=1}^{P_{PCA}} \sigma_{p_{PCA}}}{\sum_{m=1}^M \sigma_m} \quad (11)$$

其中, P_{PCA} 为所选主成分个数, P_{PCA} 小于 M 。

据此, 通过 P_{PCA} 确定用于监测工况是否发生变化的漂移控制限。

进一步, 将式(10)重写为:

$$R = U^{M \times M} \Sigma^{M \times M} V^{M \times M} \approx U_{Key}^{P_{PCA} \times P_{PCA}} \Sigma_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T \quad (12)$$

根据得分矩阵 T 和负载矩阵 $U_{Key}^{P_{PCA} \times P_{PCA}}$, 将 x^{TSP} 表示为:

$$\begin{aligned} x^{TSP} &= X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T + X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= T [U_{Key}^{P_{PCA} \times P_{PCA}}]^T + \tilde{T} [\tilde{U}_{Key}^{P_{PCA} \times P_{PCA}}]^T \\ &= \hat{x}^{TSP} + \tilde{x}^{TSP} \end{aligned} \quad (13)$$

其中, $\hat{x}^{TSP}$ 表示 x^{TSP} 在主成分空间上的投影, $\tilde{x}^{TSP}$ 表示 x^{TSP} 在残差空间上的投影。

此外, $\hat{x}^{TSP}$ 与 $\tilde{x}^{TSP}$ 满足正交关系, 证明如下:

$$\begin{aligned} [\hat{x}^{TSP}]^T \tilde{x}^{TSP} &= [X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T]^T \cdot X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T \\ \text{subject to } U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T &= I^{P_{PCA} \times P_{PCA}} \\ &= [X^{TSP}]^T X^{TSP} - [X^{TSP}]^T X^{TSP} = 0 \end{aligned}$$

(14)

因此, 使用 $\hat{x}^{TSP}$ 和 $\tilde{x}^{TSP}$ 进行过程监视的优势在于两部分相互独立 (即统计信息互不干扰)。

本实施例采用根据 TSP 计算所得到的 Hotelling's T2 和 SPE 统计指标作为进行工况漂移识别的控制限。上述 2 个统计指标可表示为:

$$T_{CL}^2 = \frac{P_{PCA}(N_{TSP}-1)}{(N_{TSP}-P_{PCA})} F_{\alpha}(P_{PCA}, N_{TSP}-P_{PCA}) \quad (15)$$

$$SPE_{CL} = \Theta_1 \left(\frac{c_{\alpha} \sqrt{2\Theta_2 h_0^2}}{\Theta_1} + 1 + \frac{\Theta_2 h_0 (h_0 - 1)}{\Theta_1^2} \right)^{1/h_0} \quad (16)$$

其中, $F_{\alpha}(P_{PCA}, N_{TSP}-P_{PCA})$ 表示自由度为 P_{PCA} 和 $(N_{TSP}-P_{PCA})$ 的 F 分布; c_{α} 表示不超过 $(1-\alpha)$ 的正态偏差; Θ_1 、 Θ_2 和 h_0 的计算如下所示:

$$h_0 = 1 - 2\Theta_1\Theta_3/3\Theta_1^2 \quad (17)$$

$$\Theta_i = \sum_{n=P_{PCA}+1}^M (\sigma_n)^i, \quad i=1,2,3 \quad (18)$$

再次, 本实施例构建有基于 FTBL 的离线模型构建模块, FTBL 离线建模方法由特征映射层、增强层和增量层组成(图 5)。相比于传统 DT, 其每层的基本单元均由 FDT 替代神经元, FDT 的结构如图 5 所示。FDT 是二叉树的一类, 结构包括非叶节点和叶节点, 其中: 前者用于特征选择, 后者用于 TS 模糊推理系统。

1) 特征映射层

针对给定 TSP 数据 $D^{TSP} = \{x_n, y_n\}_n \in \mathbb{R}^{N_{TSP} \times (M+1)}$, 本实施例在 D^{TSP} 中随机选择一个特征值 x 定义节点分裂函数 $\mu'_{CS}(x)$, 其可表示为:

$$\mu'_{CS}(x) = rand(n, m), \quad n \in (1, N_{TSP}) \text{ and } m \in (1, M) \quad (19)$$

其中, $\mu'_{CS}(x)$ 为符号函数, $rand(\cdot)$ 为随机数生成函数(n 和 m 不取最大值和最小值)。

本实施例可得到 $T/2-1$ 个非叶节点(即 $\{\mu'_{CS}(x)\}_{i=1}^{T/2-1}$)和采用式(20)构建 FDT 的 $T/2$ 个叶节点。由于从根节点到叶节点的路径不一样, 每个叶节点输入数据 ($D^{Lcaf} = \{x_n^{Lcaf}, y_n\}_n \in \mathbb{R}^{N_{TSP}^{Lcaf} \times (M^{Lcaf}+1)}$) 是不同的。因此, 基于 D^{Lcaf} 的 TS 模糊推理过程如下所示。

对 TS 模糊推理确定 K 个模糊规则, 其第 k 个规则可表示为:

$$\begin{aligned} R_k: & \text{if } x_1^{Lcaf} \text{ is } \phi_1^k(x_1^{Lcaf}) \text{ and } \dots \text{ and } x_{M^{Lcaf}}^{Lcaf} \text{ is } \phi_{M^{Lcaf}}^k(x_{M^{Lcaf}}^{Lcaf}) \\ & \text{then } y^k = g^k(x_1, \dots, x_{M^{Lcaf}}) \end{aligned} \quad (20)$$

其中,

$$\phi_m^k(x_m^{Lcaf}) = \exp \left[- \left(x_m^{Lcaf} - c_{k,m} \right)^2 / \sigma_{k,m}^2 \right] \quad (21)$$

其中, $c_{k,m}$ 和 $\sigma_{k,m}$ 分别表示高斯函数 $\phi_m^k(\cdot)$ 的中心和宽度, l_{leaf} 表示第 l_{leaf} 个叶节点。根据上述 K 个模糊规则, FDT 的结果可描述为:

$$\hat{y}_i = f(x_i) = \sum_{k=1}^K \bar{\sigma}^k g^k(x_i) \quad (22)$$

其中,

$$\bar{\sigma}^k = \prod_{m=1}^{M^{Lcaf}} \phi_m^k(x_m^{Lcaf}) / \sum_{j=1}^K \left(\prod_{m=1}^{M^{Lcaf}} \phi_m^j(x_m^{Lcaf}) \right) \quad (23)$$

$$g^k(x_i^{Lcaf}) = x_i^{Lcaf} \omega_{TS}^k \quad (24)$$

其中, $f(\cdot)$ 为 FDT 模型, $\bar{\sigma}^k$ 和 $g^k(\cdot)$ 表示 TS 模糊推理的前件和后件部分, ω_{TS}^k 表示后件部分特征的权重。

本实施例应用梯度下降法更新 FDT 模型 $f(\cdot)$ 训练过程中的参数, 包括中心 c_k 、宽度 σ_k 和权重 ω_{ts}^k 。

因此, 特征映射层输出表示如下:

$$\mathbf{Z}_{FM}^{N_{FM}} = [\mathbf{z}_{FM}^1, \mathbf{z}_{FM}^2, \dots, \mathbf{z}_{FM}^{N_{FM}}] \in \mathbb{R}^{N_{TSP} \times N_{FM}} \quad (25)$$

其中,

$$\mathbf{z}_{FM}^{n_{FM}} = f_{FM}^{FM}(\mathbf{X}^{TSP}) \in \mathbb{R}^{N_{TSP} \times 1} \quad (26)$$

其中, $\mathbf{z}_{FM}^{n_{FM}}$ 是第 n_{FM} 个 FDT 模型通过输入 $\mathbf{X}^{TSP}$ 的输出。

2) 增强层

增强层以 $\mathbf{Z}_{FM}^{N_{FM}}$ 作为输入, 其输出可表示为:

$$\mathbf{Z}_{En}^{N_{En}} = [\mathbf{z}_{En}^1, \mathbf{z}_{En}^2, \dots, \mathbf{z}_{En}^{N_{En}}] \in \mathbb{R}^{N_{TSP} \times N_{En}} \quad (27)$$

因此, 特征映射层和增强层的输出为 $\mathbf{G}^{N_{FM}+N_{En}} = [\mathbf{Z}_{FM}^{N_{FM}} | \mathbf{Z}_{En}^{N_{En}}]$ 。利用岭回归学习算法计算 $\mathbf{G}^{N_{FM}+N_{En}}$ 与预测输出之间的权重 $\mathbf{W}^{N_{FM}+N_{En}}$, 如下所示:

$$\begin{aligned} \mathbf{W}^{N_{FM}+N_{En}} &= (\lambda \mathbf{I} + \mathbf{G}^{N_{FM}+N_{En}} (\mathbf{G}^{N_{FM}+N_{En}})^T)^{-1} (\mathbf{G}^{N_{FM}+N_{En}})^T \mathbf{y}^{TSP} \\ &= (\mathbf{G}^{N_{FM}+N_{En}})^* \mathbf{y}^{TSP} \end{aligned} \quad (28)$$

其中, $(\mathbf{G}^{N_{FM}+N_{En}})^*$ 为伪逆矩阵, λ 为正则化系数, $\mathbf{I}$ 为单位矩阵。

3) 增量层

为了获得足够好的性能, 进一步在增量层中增加 FDT 模型, 并动态更新伪逆矩阵。

以 $\mathbf{Z}_{En}^{N_{En}}$ 作为输入, $\mathbf{G}^{N_{FM}+N_{En}+1} = [\mathbf{Z}_{FM}^{N_{FM}} | \mathbf{Z}_{En}^{N_{En}} | \mathbf{z}_{in}^1]$ 作为输出。增量过程的伪逆矩阵更新过程如下:

$$[\mathbf{G}^{N_{FM}+N_{En}+1}]^* = \begin{bmatrix} [\mathbf{G}^{N_{FM}+N_{En}}]^* - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} \quad (29)$$

其中,

$$\begin{cases} \mathbf{D} = [\mathbf{G}^{N_{FM}+N_{En}+1}]^* \mathbf{H}_{k+1} \\ \mathbf{B}^T = \begin{cases} [\mathbf{C}]^T, & \text{if } \mathbf{C} \neq 0 \\ [(\mathbf{I} + \mathbf{D}^T \mathbf{D})^{-1} \mathbf{D}^T [\mathbf{G}^{N_{FM}+N_{En}}]^*]^T, & \text{if } \mathbf{C} = 0 \end{cases} \\ \mathbf{C} = \mathbf{H}_{k+1} - \mathbf{G}^{N_{FM}+N_{En}+1} \mathbf{D} \end{cases} \quad (30)$$

因此, 新的权重矩阵 $\mathbf{W}^{N_{FM}+N_{En}+1}$ 可表示为:

$$\mathbf{W}^{N_{FM}+N_{En}+1} = \begin{bmatrix} \mathbf{W}^{N_{FM}+N_{En}} - \mathbf{D}\mathbf{B}^T \mathbf{y}^{TSP} \\ \mathbf{B}^T \mathbf{y}^{TSP} \end{bmatrix} \quad (31)$$

离线模型 FTBL 的预测计算过程如下:

$$\hat{\mathbf{y}} = \mathbf{G}^{N_{FM}+N_{En}+1} \mathbf{W}^{N_{FM}+N_{En}+1} \quad (32)$$

再次, 本实施例还构建有在线漂移识别与软测量模块, 该部分基于上述建立的 PCA 模型和漂移指标控制限进行 MSWI 过程的实时监视, 并基于漂移识别结果进行相应的软测量输出。本实施例采用固定的窗口尺寸获取过程数据, 当数据填满窗时启动漂移识别和软测量。

基于下式计算新窗口内的漂移值:

$$\mathbf{T}_{O_1}^2 = \mathbf{x}_{O_1}^T \mathbf{U}^{P_{PCA} \times P_{PCA}} \Sigma^{-1} (\mathbf{U}^{P_{PCA} \times P_{PCA}})^T \mathbf{x}_{O_1} \quad (33)$$

$$SPE_{O_1} = \mathbf{x}_{O_1}^T \left(\mathbf{I} - \mathbf{U}^{P_{PCA} \times P_{PCA}} (\mathbf{U}^{P_{PCA} \times P_{PCA}})^T \right) \mathbf{x}_{O_1} \quad (34)$$

其中, $T_{o_i}^2$ 和 SPE_{o_i} 是第 $(N_{TSP}+1)$ 个过程数据(x_{o_i})的统计指标, $U_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}}$ 表示新的负荷矩阵, $\Sigma_{N_{TSP}+1}^{-1}$ 表示新的对角矩阵(即 $diag(\sigma_1, \sigma_2, \dots, \sigma_{P_{PCA}})$)。

窗口内样本被定义为漂移和正常样本, 通过以下条件, :

$$\begin{cases} \text{漂移,} & \text{if } T_{o_i}^2 > T_{CL}^2 \text{ and } SPE_{o_i} > SPE_{CL} \\ \text{正常,} & \text{其它} \end{cases} \quad (35)$$

针对正常样本, 重用 FTBL 离线模型进行 DXN 浓度软测量, 可表示为:

$$\begin{aligned} \hat{y}_{o_i} &= G^{k+N_{in}} W^{k+N_{in}} \\ &= [Z_{FM}^{N_{FM}} | Z_{En}^{N_{En}} | Z_{In}^{N_{In}}] W^{k+N_{in}} \\ &= [f_1^{FM}(x_{o_i}), \dots, f_{N_{FM}}^{FM}(x_{o_i}) | f_1^{En}(x_{o_i}), \dots, f_{N_{En}}^{En}(x_{o_i}) | f_1^{In}(x_{o_i}), \dots, f_{N_{In}}^{In}(x_{o_i})] W^{k+N_{in}} \end{aligned} \quad (36)$$

针对漂移样本, 考虑到实际工程中 DXN 排放的真值检测耗时长, 难以实时获取 DXN 真值数据, 此处除能提示需要进行检测外, 给出如下的软测量值计算方式:

$$\hat{y}_{o_i} = G^{k+N_{in}} W^{k+N_{in}} + \varepsilon_{Offset} \quad (37)$$

其中, ε_{Offset} 为离线 FTBL 预测输出的偏移值, 如下:

$$\varepsilon_{Offset} = \begin{cases} +\frac{1}{N_i} \sum (\hat{y}_i - E(\hat{y})), & \text{if } x_{IncTem} < E(x_{IncTem}) \\ -\frac{1}{N_i} \sum (\hat{y}_i - E(\hat{y})), & \text{if } x_{IncTem} \geq E(x_{IncTem}) \end{cases} \quad (38)$$

其中, N_i 表示到达 i 时刻的全部数据量, $\hat{y}$ 表示到达 i 时刻的所有预测值, $E(\hat{y})$ 表示向量 $\hat{y}$ 的数学期望, x_{IncTem} 表示 i 时刻的焚烧炉温度。

此外, 当检测真值存在时, 采用下述方法进行 FTBL 的更新。

最后, 本实施例还构建有 FTBL 模型在线动态更新模块, 针对漂移数据, 本实施例增加在线增量层 $\{f_{n_{oi}}^{OI}(\cdot)\}_{n_{oi}=1}^{N_{OI}}$ 以快速学习漂移数据的特征。在在线增量过程中, 离线 FTBL 被描述为一个独立的模型, 通过扩展原模型宽度的概念以增强模型在线测量精度。此时, 输入数据包括 TSP 数据(X^{TSP})、漂移数据(X^{Dri})和增量层的输出($Z_{In}^{N_{In}}$)。新 FTBL 模型的预测值记为:

$$\hat{y}_{o_i} = G^{N_{FM}+N_{En}+N_{In}+N_{OI}} W^{N_{FM}+N_{En}+N_{In}+N_{OI}} \quad (39)$$

其中, $W^{N_{FM}+N_{En}+N_{In}+N_{OI}}$ 表示权重矩阵, $G^{N_{FM}+N_{En}+N_{In}+N_{OI}}$ 是 $N_{FM} + N_{En} + N_{In} + N_{OI}$ FDT 的输出矩阵, 其动态更新过程与式(29)~(31)一致。

在完成在线学习和预测后, 还需要更新 TSP 及 T_{CL}^2 和 SPE_{CL} 控制限, 以适应下一个窗口的在线测量。

如图 6 和图 7 所示, 本实施例采用北京某大型 MSWI 电厂 2009 - 2020 年的 DXN 数据。图 6 和图 7 左侧为 DXN 的实际浓度值。

由图 6 和图 7 可知, MSWI 电厂自投产以来 DXN 浓度未超过 0.1 TEQ ng/m^3 , 满足污染物控制排放标准(GB18485-2014)要求。考虑到难以获取 DXN 真值, 仅能在历史数据驱动下建立离线模型进行软测量。因此, 历史数据取 2009 - 2016 年的真值样本, 测试数据取 2016 - 2020 年的真值样本。DXN 浓度真值取 MSWI 过程在 2 小时内的平均排放浓度。同时, 在离散控制系统(DCS)中, 温度、压力、流量等过程变量数秒内生成, 需平均采样时间内过程数据获得 DXN 真值所对应样本。本实施例对 DXN 数据的划分如表 2 所示。

表 2 DXN 数据划分

	数据	训练集	测试集
样本	141	71	70
特征	116	116	116
时间	2009s~2020s	2009s~2016s	2016s~2020s

从图 7 可看出历史数据与测试数据的分布存在显著差异, 这将导致基于经典建模法难以准确检测 DXN 排放浓度。

采用随机森林(RF)、反向传播神经网络(BPNN)、深度森林回归(DFR)、支持向量回归(SVR)、模糊神经网络(FNN)和宽度学习系统(BLS)等经典和流行的方法, 与所提 FTBL 方法进行比较。

所采用的指标为均方根误差(RMSE)和可解释方差(EV), 计算如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y} - y_n)^2} \quad (40)$$

$$EV = 1 - \frac{\sum_{n=1}^N ((\hat{y} - y_n) - E(\hat{y} - y))^2}{\sum_{n=1}^N (y_n - E(y))^2} \quad (41)$$

实验数据及拟合曲线如表 3 和图 8 以及图 9 所示。

表 3 不同方法的比较结果

方法	训练集 (2009s~2016s)		测试集 (2016s~2020s)	
	RMSE	EV	RMSE	EV
RF	1.3248E-02	7.9134E-01	2.7447E-02	-1.9795E-01
BP	9.2128E-04	9.9899E-01	5.7262E-02	-1.6648E+01
SVR	6.7068E-03	7.7486E-01	2.0233E-02	-6.8958E+00
FNN	2.2107E-03	9.9419E-01	1.1513E-01	-8.4589E+01
DFR	1.5410E-02	7.1763E-01	2.8644E-02	-1.4681E-01
BLS	1.0074E-02	8.7950E-01	2.6993E-02	-2.4269E+00
离线 FTBL	7.1257E-03	9.3979E-01	2.3639E-02	-1.9953E+00

从表 3 和图 8 以及图 9 可知, 上述方法的建模性能均良好, 具体而言:

(1)在训练数据中, BPNN、FNN 和 FTBL 的 RMSE 和 EV 优于 RF、DFR、SVR 和 BLS, 这表明 BPNN、FNN 和 FTBL 对训练数据具有较好的拟合性能;

(2)在测试数据中, 由于数据分布的差异, 预测性能存在显著差异, 导致所有方法都难以有效拟合测试数据的分布;

(3) SVR 的 RMSE 最低(2.0233E-02), RF 的 EV 最低(-1.9795E-01), 而 SVR、RF 和 DFR 方法的预测曲线趋近于一条直线, 这意味着 RF、SVR 和 DFR 方法对测试数据的响应能力较差; 此外, 针对其余方法如 BP、FNN、BLS 和 FTBL, 其对在线数据的响应则更为敏感。这表明, 这些方法的预测趋势随在线工艺的变化而波动。本实施例提出的 FTBL 方法在建模精度和模型灵敏度方面均具有较高优势。

上述实验结果表明, 所提出的离线建模法比 RF 和 DFR 法具有更高的建模精度和灵敏度; 此外, 与 BP、FNN、SVR 和 BLS 方法相比, FTBL 具有相同的建模精度和更稳定的敏感度。

本实施例使用加权 k-means 聚类训练数据，使用 CSM 指标构建 TSP 数据 D^{TSP} 。聚类结果以历史数据的前三个维度 x_1 、 x_2 、 x_3 为例，结果如图 10 和图 11 所示。

图 10 和图 11 表明加权 k-means 聚类在三维空间的有效性，聚类之间存在清晰的空间距离。在迭代过程中，聚类间总距离 R_{iter} 逐渐减小，直至收敛（图 11）。然后，根据 CSM 指标删除冗余样本。结果见图 12 和表 4。对比图 10 和图 12 的结果可看出，类内间样本向质心周边靠近，类类间的距离得到了扩大。此外，从 CSM 指标的统计结果来看，典型样本的聚类相似度更低。

表 4 典型样本的 CSM		
	CSM 指标	样本
旧	3.0452E+01	71
新	2.7603E+01	64

本实施例采用贡献阈值 $\delta^{PCA}=0.9$ 确定主成分，由此选择了 19 个主成分进行统计分析。根据式(15)、(16)和 19 个主成分，进一步得出历史数据的两条 T_{cl}^2 和 SPE_{cl} 控制限，分别为 13.2270 和 19.3475，置信水平为 95%。

固定在线监视的移动窗口尺寸为 5，基于上一节所建立的离线模型，在线漂移识别和软测量结果如图 13、图 14 以及表 5 所示。

表 5 在线测量过程的结果					
窗口	尺寸	漂移	在线增量层	RMSE	更新时间(秒)
W1	5	5	5	2.8219E-03	7.0182E-01
W2	5	5	5	2.2935E-03	4.5206E-01
W3	5	5	5	2.8391E-03	6.0348E-01
W4	5	5	5	1.5100E-03	6.0865E-01
W5	5	5	5	3.2899E-03	6.0067E-01
W6	5	5	5	1.9852E-03	7.1308E-01
W7	5	5	5	2.2766E-03	7.0608E-01
W8	5	5	5	1.9585E-03	6.9887E-01
W9	5	5	5	1.6349E-03	5.9082E-01
W10	5	5	5	4.0845E-03	5.8389E-01
W11	5	5	5	4.2041E-03	7.2849E-01
W12	5	5	5	1.6638E-03	6.2889E-01
W13	5	5	5	1.6363E-03	5.4703E-01
W14	5	5	5	1.8561E-03	5.8797E-01

实验结果表明，在线阶段的过程数据与历史数据存在显著差异。根据数据统计指标控制限可知，所有过程数据均为漂移样本。在线增量更新层中的 FDT 数量设置为 5 有效控制了软测量的时间成本。表 5 中的结果表明，FTBL 在线更新过程拟合精度高，更新时间短，其对应的实验结果如图 15 和图 16 所示。

如表 6 所示,历史数据的 RMSE 和 EV 分别为 $9.9065\text{E-}03$ 和 $8.9321\text{E-}01$,测试数据的 RMSE 和 EV 分别为 $2.1595\text{E-}02$ 和 $9.5089\text{E-}01$ 。从以下几个方面考虑: 1)离线 FTBL 模型使用 TSP,其建模精度虽略有下降,但建模时间成本和在线更新过程的计算成本有所降低; 2)与离线建模部分相比,测试监测阶段实现对数据的较好拟合和较高建模精度。结果表明,本实施例所提离线建模和在线测量策略是充分的。

表 6 离线、在线阶段预测指标统计

阶段	RMSE	EV
Train	$9.9065\text{E-}03$	$8.9321\text{E-}01$
Test	$2.1595\text{E-}02$	$9.5089\text{E-}01$

针对工况漂移,此处结合实际工程应用实现所提策略。本实施例基于 C# 编程语言开发了 DXN 浓度排放在线检测系统,分别在实验室半实物仿真平台和 MSWI 工业现场进行了实验测试,相应的硬件结构和软件界面如图 17 和图 18 所示。

图 12(b)和图 13(a)分别表示基于半实物仿真实验室平台和工业现场应用的在线软测量系统界面,通过“启动”按钮启动运行后,软件界面实时显示在线预测的 DXN 排放浓度。图 12 的软件界面上方为半实物仿真平台的硬件结构,图 13 主要为 MSWI 流程示意和控制系统结构以及用于支撑 DXN 在线软测量的单向物理隔离数据采集系统和现场实时工艺数据与 DXN 排放浓度实时测量曲线。通过在半实物仿真平台上对软测量系统进行测试的结果验证了软件系统的有效性,表明本实施例所提方法能够工程应用,为实际工程提供有力支撑。

本发明的有益效果如下:

针对 MSWI 过程 DXN 排放浓度的软测量问题,本实施例提出一种基于模糊树宽度学习的软测量策略,主要贡献体现在:提出新的 FTBL 算法用于构建离线 DXN 排放模型,提出在线工况漂移识别与相应的软测量策略,提出 FTBL 模型的在线动态更新方法,基于实际过程数据在实验室仿真实验平台验证所提策略的有效性后,在实际工业过程验证了所提方法。

本说明书中各个实施例采用递进的方式描述,每个实施例重点说明的都是与其他实施例的不同之处,各个实施例之间相同相似部分互相参见即可。

本实施例中应用了具体个例对本发明的原理及实施方式进行了阐述,以上实施例的说明只是用于帮助理解本发明的方法及其核心思想;同时,对于本领域的一般技术人员,依据本发明的思想,在具体实施方式及应用范围上均会有改变之处。综上所述,本说明书内容不应理解为对本发明的限制。

1、一种 MSWI 过程二噁英排放浓度在线软测量方法,其特征在于,包括:
基于 K-means 加权算法,根据 MSWI 的历史过程数据集确定典型样本池的过程数据;

根据所述典型样本池的过程数据进行主成分分析,得到反映 MSWI 过程是否发生变化的漂移指标控制限;

构建基于 FTBL 的离线模型,并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算,得到离线计算结果;所述离线模型包括特征映射层、增强层和增量层;

根据获取到的在线数据进行主成分分析,并根据所述漂移指标控制限判断所述在线数据是否为漂移数据或正常数据,若为所述正常数据,则跳转至步骤“构建基于 FTBL 的离线模型,并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算,得到计算结果”;若为所述漂移数据,则构建基于 FTBL 的在线模型,并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算,得到在线计算结果;所述在线模型包括在线增量层;

根据所述离线计算结果和所述在线计算结果确定 DXN 排放浓度预测值。

2、根据权利要求 1 所述的 MSWI 过程二噁英排放浓度在线软测量方法,其特征在于,所述基于 K-means 加权算法,根据 MSWI 的历史过程数据集确定典型样本池的过程数据包括:

获取 MSWI 的历史过程数据集 $\mathbf{X}^{\text{His}}$;

根据所述历史过程数据集 $\mathbf{X}^{\text{His}}$ 得到历史数据 $\mathbf{D}^{\text{His}} = \{\mathbf{x}_n, \mathbf{y}_n\}_{n=1}^N \in \mathbb{R}^{N \times (M+1)}$; 其中, $\mathbf{x}_n$ 为第 n 个样本, $\mathbf{y}_n$ 为第 n 个样本对应的预测值; N 为 MSWI 的历史数据集的样本数, M 为 MSWI 的历史数据集的特征数;

随机选择 I 个实例作为初始质心 $\{C_i\}_{i=1}^I$,

根据样本与质心之间的加权欧氏距离,将所有样本列成 I 类:

$$C_i = C_i \cup \min\{d_n\}_{n=1}^N = C_i \cup \min\left\{\sqrt{[\mathbf{x}_n - C_i]^2 \mathbf{w}_{\text{TS}}^T}\right\}_{n=1}^N;$$

其中, C_i 表示第 i 个类; $\mathbf{w}_{\text{TS}}^T$ 表示过程变量的权重向量, 其中,

$$\mathbf{w}_{\text{TS}}^m = H(\mathbf{x}_m) - H(\mathbf{x}_m | \mathbf{y}) = \sum_{x_{n,m}} \sum_{y_n} p(x_{n,m}, y_n) \log_2 \frac{p(x_{n,m}, y_n)}{p(x_{n,m}) p(y_n)}; \text{ 其中, } H(\cdot) \text{ 表示随机变}$$

量的信息熵, $\mathbf{x}_m$ 为第 m 个特征向量, $\mathbf{y}$ 表示 DXN 浓度, $x_{n,m}$ 表示第 n 个样本的第 m 个特征值, $p(x_{n,m}) p(y_n)$ 表示边缘概率分布, $p(x_{n,m}, y_n)$ 为联合概率分布;

利用类间样本更新质心 C_i :

$$C_i = \frac{1}{N_{C_i}} \sum_{x \in C_i} \mathbf{x}_n; \text{ 其中, } N_{C_i} \text{ 表示该第 } i \text{ 个聚类中的样本数量};$$

对质心进行循环更新,并通过预设条件获得全部质心,所述预设条件表示为: $\{C_i\}_i^I \Leftarrow |R_{\text{iter}} - R_{\text{iter}-1}| \leq \delta^{\text{TS}}$; 其中, δ^{TS} 为评价指标 R_{iter} 的阈值, iter 表示迭代次数, 度量指标的计算公式为: $R_{\text{iter}} = \sum_{i=1}^I \sum_n^{N_{C_i}} [\mathbf{x}_n - C_i]^2 \mathbf{w}_{\text{TS}}^T$;

通过最小化聚类相似度建立 TSP, 建立公式为:

$$R_{\text{DB}} = \min \left(\frac{1}{N} \sum_{n=1}^N (S_i + S_j) / M_{ij} \right); \text{ 其中, } R_{\text{DB}} \text{ 为聚类相似性度量指数; 其中,}$$

$$S_i = \left\{ (1/N_{C_i}) \sum |(\mathbf{x}_n - C_i) \mathbf{w}_{\text{TS}}^T|^a \right\}^{1/a}, \quad M_{ij} = \left\{ \sum |C_i - C_j|^b \right\}^{1/b}; \text{ 其中, } S_i \text{ 表示第 } i \text{ 类的距离之和,}$$

权 利 要 求 书

M_{ij} 表示闵可夫斯基度量准则。

3、根据权利要求 2 所述的 MSWI 过程二噁英排放浓度在线软测量方法，其特征在于，根据所述典型样本池的过程数据进行主成分分析，得到反映 MSWI 过程是否发生变化的漂移指标控制限，包括：

将 TSP 数据的相关系数矩阵 $D^{TSP} = \{x_n, y_n\}_n^{N_{TSP}} \in \mathbb{R}^{N_{TSP} \times (M+1)}$ 表示为 $R \approx \frac{1}{N_{TSP}-1} [X^{TSP}]^T X^{TSP}$ ；其中， N_{TSP} 为 TSP 数据 D^{TSP} 的个数； R 为 TSP 数据的相关系数矩阵；

对 R 进行奇异值分解，并计算特征值；计算公式为 $R = U^{M \times M} \Sigma^{M \times M} [V^{M \times M}]^T$ ；其中， $U^{M \times M}$ 和 $V^{M \times M}$ 表示正交矩阵， $\Sigma^{M \times M}$ 是 M 维对角矩阵；

使用特征累计贡献率 η 和 PCA 贡献阈值 δ^{PCA} 进行降维：

$$\eta = \frac{\sum_{m=1}^{P_{PCA}} \sigma_{P_{PCA}}}{\sum_{m=1}^M \sigma_m} ; \text{ 其中， } P_{PCA} \text{ 为所选主成分个数， } P_{PCA} \text{ 小于 } M ;$$

将计算公式重写为： $R = U^{M \times M} \Sigma^{M \times M} V^{M \times M}$
 $\approx U_{Key}^{P_{PCA} \times P_{PCA}} \Sigma_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T$ ；其中， $U_{Key}^{P_{PCA} \times P_{PCA}}$ 为负载

矩阵；

根据得分矩阵 T 和负载矩阵 $U_{Key}^{P_{PCA} \times P_{PCA}}$ ，将 x^{TSP} 表示为：

$$\begin{aligned} X^{TSP} &= X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T + X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= T [U_{Key}^{P_{PCA} \times P_{PCA}}]^T + \tilde{T} [\tilde{U}_{Key}^{P_{PCA} \times P_{PCA}}]^T \\ &= \hat{X}^{TSP} + \tilde{X}^{TSP} \end{aligned}$$

其中， $\hat{X}^{TSP}$ 表示 x^{TSP} 在主成分空间上的投影， $\tilde{X}^{TSP}$ 表示 x^{TSP} 在残差空间上的投影；所述 $\hat{X}^{TSP}$ 与 $\tilde{X}^{TSP}$ 满足正交关系；

此外， $\hat{X}^{TSP}$ 与 $\tilde{X}^{TSP}$ 满足正交关系，证明如下：

$$\begin{aligned} [\hat{X}^{TSP}]^T \tilde{X}^{TSP} &= [X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T]^T \cdot X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} (I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T) \\ &= U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} I^{P_{PCA} \times P_{PCA}} - U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T [X^{TSP}]^T X^{TSP} U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T ; \end{aligned}$$

$$\begin{aligned} \text{subject to } U_{Key}^{P_{PCA} \times P_{PCA}} [U_{Key}^{P_{PCA} \times P_{PCA}}]^T &= I^{P_{PCA} \times P_{PCA}} \\ &= [X^{TSP}]^T X^{TSP} - [X^{TSP}]^T X^{TSP} = 0 \end{aligned}$$

将所述漂移指标控制限表示为：

$$T_{CL}^2 = \frac{P_{PCA}(N_{TSP}-1)}{(N_{TSP}-P_{PCA})} F_{\alpha}(P_{PCA}, N_{TSP}-P_{PCA}) ;$$

$$SPE_{CL} = \Theta_1 \left(\frac{c_{\alpha} \sqrt{2\Theta_2 h_0}}{\Theta_1} + 1 + \frac{\Theta_2 h_0 (h_0 - 1)}{\Theta_1^2} \right)^{1/h_0} ;$$

其中， T_{CL}^2 为 Hotelling's T^2 的控制限， SPE_{CL} 为 SPE 的控制限， P_{PCA} 为所选主成分个数 $F_{\alpha}(P_{PCA}, N_{TSP}-P_{PCA})$ 表示自由度为 P_{PCA} 和 $(N_{TSP}-P_{PCA})$ 的 F 分布； c_{α} 表示不超过 $(1-\alpha)$ 的正态偏差； Θ_1 、 Θ_2 和 h_0 的计算如下所示：

$$h_0 = 1 - 2\Theta_1 \Theta_3 / 3\Theta_1^2 ;$$

$$\Theta_i = \sum_{m=P_{PCA}+1}^M (\sigma_m)^i, \quad i=1,2,3 ;$$

其中， h_0 、 Θ_1 和 Θ_2 均为 SPE 控制限计算的中间变量， σ_m 为奇异值分解的

特征值。

4、根据权利要求3所述的MSWI过程二噁英排放浓度在线软测量方法，其特征在于，所述构建基于FTBL的离线模型，并将所述典型样本池的过程数据和MSWI的历史DXN真值数据输入至所述离线模型中进行预测计算，得到离线计算结果，包括：

针对给定TSP数据 $\mathbf{D}^{\text{TSP}} = \{\mathbf{x}_n, \mathbf{y}_n\}_n^{N_{\text{TSP}}} \in \mathbb{R}^{N_{\text{TSP}} \times (M+1)}$ ，在 $\mathbf{D}^{\text{TSP}}$ 中随机选择一个特征值 x 定义节点分裂函数 $\mu'_{\text{CS}}(x)$ ，其表示为： $\mu'_{\text{CS}}(x) = \text{rand}(n, m)$ ， $n \in (1, N_{\text{TSP}})$ and $m \in (1, M)$ ；其中， $\mu'_{\text{CS}}(x)$ 为符号函数， $\text{rand}(\cdot)$ 为随机数生成函数， n 和 m 不取最大值和最小值；

对TS模糊推理确定 K 个模糊规则，其第 k 个规则可表示为：
 $R_k: \text{if } x_1^{\text{leaf}} \text{ is } \phi_1^k(x_1^{\text{leaf}}) \text{ and } \dots \text{ and } x_{M^{\text{leaf}}}^{\text{leaf}} \text{ is } \mu_{M^{\text{leaf}}}^k(x_{M^{\text{leaf}}}^{\text{leaf}})$; 其中， $\phi_m^k(x_m^{\text{leaf}}) = \exp\left[-(x_m^{\text{leaf}} - c_{k,m})^2 / \sigma_{k,m}^2\right]$;
 $\text{then } y^k = g^k(x_1, \dots, x_{M^{\text{leaf}}})$

其中， R_k 为第 k 条模糊规则， $c_{k,m}$ 和 $\sigma_{k,m}$ 分别表示高斯函数 $\phi_m^k(\cdot)$ 的中心和宽度， t_{leaf} 表示第 t_{leaf} 个叶节点； $\phi_m^k(\cdot)$ 为高斯函数；

根据上述 K 个模糊规则，FDT的结果描述为：

$$\hat{y}_i = f(\mathbf{x}_i) = \sum_{k=1}^K \bar{o}^k g^k(\mathbf{x}_i) \quad ; \quad \text{其中} \quad , \quad \bar{o}^k = \prod_{m=1}^{M^{\text{leaf}}} \phi_m^k(x_m^{\text{leaf}}) / \sum_{i=1}^K \left(\prod_{m=1}^{M^{\text{leaf}}} \phi_m^k(x_m^{\text{leaf}}) \right) \quad ;$$

$g^k(\mathbf{x}_i^{\text{leaf}}) = \mathbf{x}_i^{\text{leaf}} \omega_{\text{TS}}^k$ ；其中， $f(\cdot)$ 为FDT模型， $\bar{o}^k$ 和 $g^k(\cdot)$ 表示TS模糊推理的前件和后件部分， ω_{TS}^k 表示后件部分特征的权重；

应用梯度下降法更新FDT模型 $f(\cdot)$ 训练过程中的参数，所述参数包括中心 c_k 、宽度 σ_k 和权重 ω_{TS}^k ；所述特征映射层输出表示如下：

$\mathbf{Z}_{\text{FM}}^{N_{\text{FM}}} = [\mathbf{z}_{\text{FM}}^1, \mathbf{z}_{\text{FM}}^2, \dots, \mathbf{z}_{\text{FM}}^{N_{\text{FM}}}] \in \mathbb{R}^{N_{\text{TSP}} \times N_{\text{FM}}}$ ；其中， $\mathbf{z}_{\text{FM}}^{n_{\text{FM}}} = f_{n_{\text{FM}}}^{\text{FM}}(\mathbf{X}^{\text{TSP}}) \in \mathbb{R}^{N_{\text{TSP}} \times 1}$ ；其中， $\mathbf{z}_{\text{FM}}^{n_{\text{FM}}}$ 是第 n_{FM} 个FDT模型通过输入 $\mathbf{X}^{\text{TSP}}$ 的输出。

增强层以 $\mathbf{Z}_{\text{FM}}^{N_{\text{FM}}}$ 作为输入，所述增强层的输出表示为：

$\mathbf{Z}_{\text{En}}^{N_{\text{En}}} = [\mathbf{z}_{\text{En}}^1, \mathbf{z}_{\text{En}}^2, \dots, \mathbf{z}_{\text{En}}^{N_{\text{En}}}] \in \mathbb{R}^{N_{\text{TSP}} \times N_{\text{En}}}$ ；所述特征映射层和所述增强层的输出为 $\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}} = [\mathbf{Z}_{\text{FM}}^{N_{\text{FM}}} | \mathbf{Z}_{\text{En}}^{N_{\text{En}}}]$ ；

利用岭回归学习算法计算 $\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}}$ 与预测输出之间的权重 $\mathbf{W}^{N_{\text{FM}} + N_{\text{En}}}$ ，如下所示：

$$\mathbf{W}^{N_{\text{FM}} + N_{\text{En}}} = (\lambda \mathbf{I} + \mathbf{G}^{N_{\text{FM}} + N_{\text{En}}} (\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}})^T)^{-1} (\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}})^T \mathbf{y}^{\text{TSP}} \quad ; \quad \text{其中，} (\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}})^* \text{ 为伪逆矩阵，} \\ = (\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}})^* \mathbf{y}^{\text{TSP}}$$

λ 为正则化系数， $\mathbf{I}$ 为单位矩阵；

在增量层中增加FDT模型，并动态更新伪逆矩阵，以 $\mathbf{z}_{\text{En}}^{N_{\text{En}}}$ 作为输入， $\mathbf{G}^{N_{\text{FM}} + N_{\text{En}} + 1} = [\mathbf{Z}_{\text{FM}}^{N_{\text{FM}}} | \mathbf{Z}_{\text{En}}^{N_{\text{En}}} | \mathbf{z}_{\text{En}}]$ 作为输出；增量过程的伪逆矩阵更新过程如下：

$$[\mathbf{G}^{N_{\text{FM}} + N_{\text{En}} + 1}]^* = \begin{bmatrix} [\mathbf{G}^{N_{\text{FM}} + N_{\text{En}}}]^* - \mathbf{D} \mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} ; \quad \text{其中，} \begin{cases} \mathbf{D} = [\mathbf{G}^{N_{\text{FM}} + N_{\text{En}} + 1}]^* \mathbf{H}_{k+1} \\ \mathbf{B}^T = \begin{cases} [\mathbf{C}]^T, & \text{if } C \neq 0 \\ [1 + \mathbf{D}^T \mathbf{D}]^{-1} \mathbf{D}^T [\mathbf{G}^{N_{\text{FM}} + N_{\text{En}} + 1}]^T, & \text{if } C = 0 \end{cases} ; \mathbf{D}、\mathbf{H}_{k+1}、\mathbf{B}^T、 \\ \mathbf{C} = \mathbf{H}_{k+1} - \mathbf{G}^{N_{\text{FM}} + N_{\text{En}} + 1} \mathbf{D} \end{cases}$$

$\mathbf{C}$ 均为伪逆矩阵更新过程的中间变量；

新的权重矩阵 $\mathbf{W}^{N_{\text{FM}} + N_{\text{En}} + 1}$ 表示为：

$$\mathbf{W}^{N_{FM}+N_{En}+1} = \begin{bmatrix} \mathbf{W}^{N_{FM}+N_{En}} - \mathbf{D}\mathbf{B}^T \mathbf{y}^{TSP} \\ \mathbf{B}^T \mathbf{y}^{TSP} \end{bmatrix};$$

离线模型 FTBL 的预测计算过程如下:

$$\hat{\mathbf{y}} = \mathbf{G}^{N_{FM}+N_{En}+1} \mathbf{W}^{N_{FM}+N_{En}+1}.$$

5、根据权利要求 4 所述的 MSWI 过程二噁英排放浓度在线软测量方法, 其特征在于, 所述根据获取到的在线数据进行主成分分析, 并根据所述漂移标识控制限判断所述在线数据是否为漂移数据或正常数据, 若为所述正常数据, 则跳转至步骤“构建基于 FTBL 的离线模型, 并将所述典型样本池的过程数据和 MSWI 的历史 DXN 真值数据输入至所述离线模型中进行预测计算, 得到计算结果”; 若为所述漂移数据, 则构建基于 FTBL 的在线模型, 并将所述典型样本池的过程数据、所述漂移数据和所述离线模型的增量层的输出数据输入至所述在线模型中进行预测计算, 得到在线计算结果, 包括:

基于下式计算新窗口内的漂移值:

$$T_{O_i}^2 = \mathbf{x}_{O_i}^T \mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}} \Sigma_{N_{TSP}+1}^{-1} (\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}})^T \mathbf{x}_{O_i};$$

$SPE_{O_i} = \mathbf{x}_{N_{TSP}+1}^T \left(\mathbf{I} - \mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}} (\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}})^T \right) \mathbf{x}_{N_{TSP}+1}$; 其中, $T_{O_i}^2$ 和 SPE_{O_i} 是第 $(N_{TSP}+1)$ 个过程数据 $\mathbf{x}_{O_i}$ 的统计指标, $\mathbf{U}_{N_{TSP}+1}^{P_{PCA} \times P_{PCA}}$ 表示新的负荷矩阵, $\Sigma_{N_{TSP}+1}^{-1}$ 表示新的对角矩阵;

通过判断公式确定样本为漂移样本或正常样本; 所述判断公式为:

$$\begin{cases} \text{漂移,} & \text{if } T_{O_i}^2 > T_{CL}^2 \text{ and } SPE_{O_i} > SPE_{CL} \\ \text{正常,} & \text{其它} \end{cases};$$

针对正常样本, 重用所述 FTBL 的离线模型进行 DXN 浓度软测量, 可表示为:

$$\begin{aligned} \hat{\mathbf{y}}_{O_i} &= \mathbf{G}^{k+N_{In}} \mathbf{W}^{k+N_{In}} \\ &= [\mathbf{Z}_{FM}^{N_{FM}} | \mathbf{Z}_{En}^{N_{En}} | \mathbf{Z}_{In}^{N_{In}}] \mathbf{W}^{k+N_{In}} \\ &= [f_1^{FM}(\mathbf{x}_{O_i}), \dots, f_{N_{FM}}^{FM}(\mathbf{x}_{O_i}) | f_1^{En}(\mathbf{x}_{O_i}), \dots, f_{N_{En}}^{En}(\mathbf{x}_{O_i}) | f_1^{In}(\mathbf{x}_{O_i}), \dots, f_{N_{In}}^{In}(\mathbf{x}_{O_i})] \mathbf{W}^{k+N_{In}}; \end{aligned}$$

针对漂移样本, 软测量值计算方式为:

$$\hat{\mathbf{y}}_{O_i} = \mathbf{G}^{k+N_{In}} \mathbf{W}^{k+N_{In}} + \varepsilon_{Offset}; \text{ 其中, } \varepsilon_{Offset} \text{ 为离线 FTBL 预测输出的偏移值, 如下:}$$

$$\varepsilon_{Offset} = \begin{cases} +\frac{1}{N_t} \sum (\hat{\mathbf{y}}_i - E(\hat{\mathbf{y}})), & \text{if } x_{IncTem} < E(x_{IncTem}) \\ -\frac{1}{N_t} \sum (\hat{\mathbf{y}}_i - E(\hat{\mathbf{y}})), & \text{if } x_{IncTem} \geq E(x_{IncTem}) \end{cases}; \text{ 其中, } N_t \text{ 表示到达 } t \text{ 时刻的全部数}$$

据量, $\hat{\mathbf{y}}$ 表示到达 t 时刻的所有预测值, $E(\hat{\mathbf{y}})$ 表示向量 $\hat{\mathbf{y}}$ 的数学期望, x_{IncTem} 表示 t 时刻的焚烧炉温度。

当检测真值存在时, 将 TSP 数据、漂移数据和增量层的输出输入至所述在线模型中; 所述在线模型的预测值为:

$$\hat{\mathbf{y}}_{O_i} = \mathbf{G}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \mathbf{W}^{N_{FM}+N_{En}+N_{In}+N_{OI}}; \text{ 其中, } \mathbf{W}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \text{ 表示权重矩阵, } \mathbf{G}^{N_{FM}+N_{En}+N_{In}+N_{OI}} \text{ 是 } N_{FM}+N_{En}+N_{In}+N_{OI} \text{ FDT 的输出矩阵。}$$




图 1




图 2

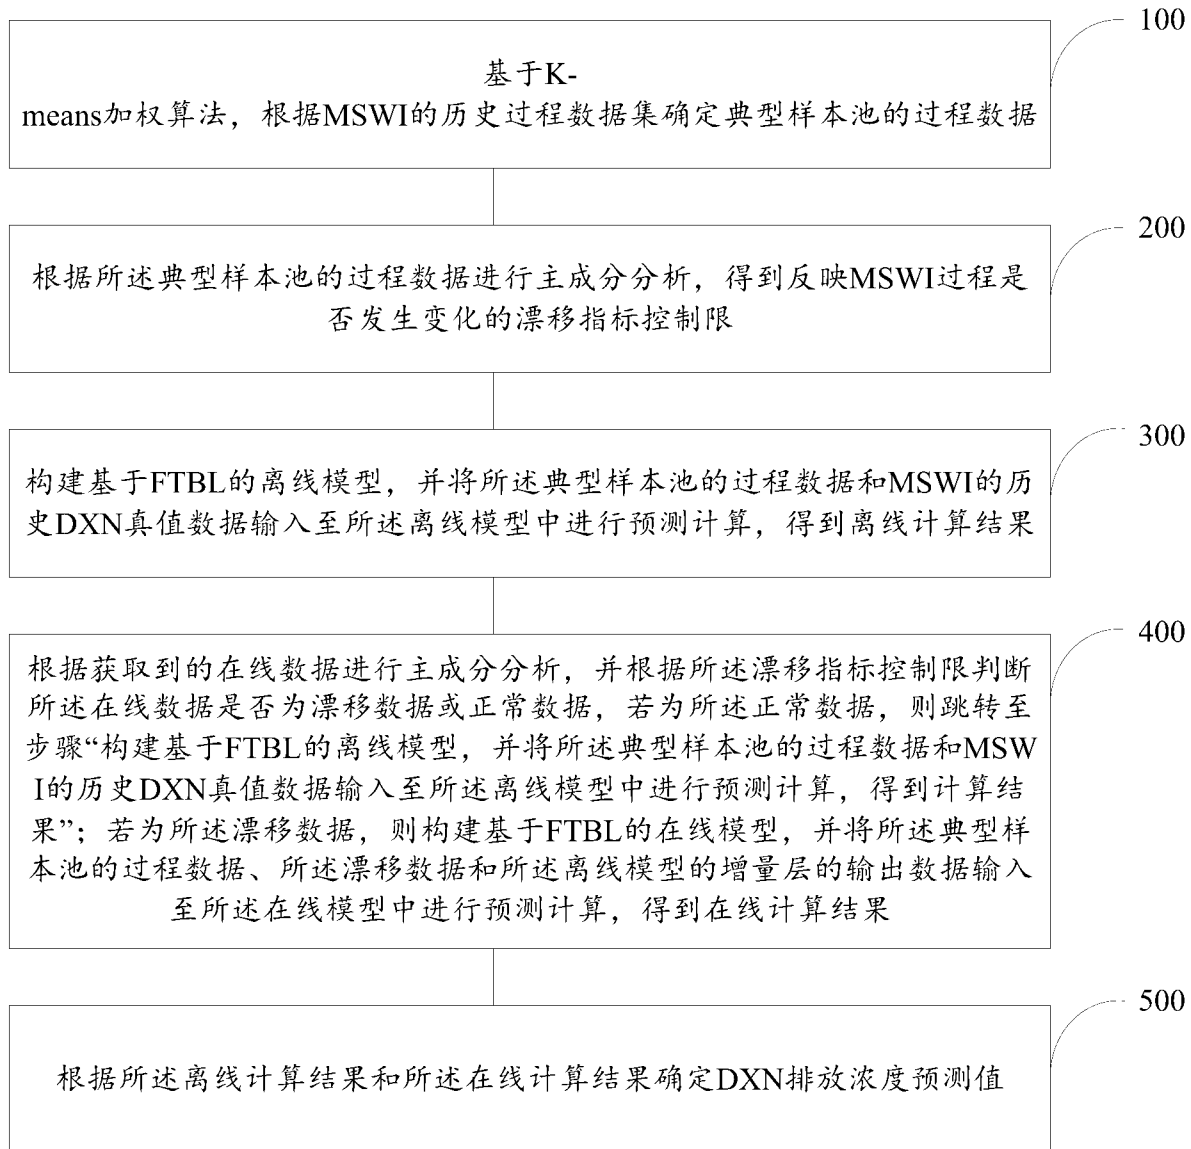


图 3




图 4




图 5




图 6





图 7






图 9




图 10




图 11




图 12




图 13




图 14




图 15





图 16

(a)



(b)




图 17




图 18

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2023/101309

A. CLASSIFICATION OF SUBJECT MATTER

G16C 20/10(2019.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

IPC: G16C

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

VEN, CNABS, CNTXT, WOTXT, EPTXT, USTXT, CNKI, IEEE: 二噁英, 排放, 浓度, 软测量, 固废焚烧, 样本, 离线, 在线, 预测, 增量, DXN, dioxin, emission, concentration, soft, measurement, MSWI, sample, offline, online, prediction, incremental

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
PX	CN 116110506 A (BEIJING UNIVERSITY OF TECHNOLOGY) 12 May 2023 (2023-05-12) claims 1-5	1-5
A	CN 114330845 A (BEIJING UNIVERSITY OF TECHNOLOGY) 12 April 2022 (2022-04-12) claim 1, and description, paragraphs [0003]-[0010] and [0150]	1-5
A	CN 114398836 A (BEIJING UNIVERSITY OF TECHNOLOGY) 26 April 2022 (2022-04-26) entire document	1-5
A	CN 109960873 A (BEIJING UNIVERSITY OF TECHNOLOGY) 02 July 2019 (2019-07-02) entire document	1-5
A	WO 2020228215 A1 (BEIJING UNIVERSITY OF TECHNOLOGY) 19 November 2020 (2020-11-19) entire document	1-5
A	WO 2022252960 A1 (JINGDONG CITY (BEIJING) DIGITAL TECHNOLOGY CO., LTD.) 08 December 2022 (2022-12-08) entire document	1-5



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“D” document cited by the applicant in the international application

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

16 August 2023

Date of mailing of the international search report

23 August 2023

Name and mailing address of the ISA/CN

China National Intellectual Property Administration (ISA/
CN)
China No. 6, Xitucheng Road, Jimenqiao, Haidian District,
Beijing 100088

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2023/101309

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
CN	116110506	A	12 May 2023	None			
CN	114330845	A	12 April 2022	None			
CN	114398836	A	26 April 2022	None			
CN	109960873	A	02 July 2019	WO	2020192166	A1	01 October 2020
				US	2021233039	A1	29 July 2021
WO	2020228215	A1	19 November 2020	US	2021033282	A1	04 February 2021
				CN	110135057	A	16 August 2019
WO	2022252960	A1	08 December 2022	CN	113344196	A	03 September 2021

A. 主题的分类

G16C 20/10 (2019.01) i

按照国际专利分类 (IPC) 或者同时按照国家分类和 IPC 两种分类

B. 检索领域

检索的最低限度文献 (标明分类系统和分类号)

IPC: G16C

包含在检索领域中的除最低限度文献以外的检索文献

在国际检索时查阅的电子数据库 (数据库的名称, 和使用的检索词 (如使用))

VEN, CNABS, CNTXT, WOTXT, EPTXT, USTXT, CNKI, IEEE: 二噁英, 排放, 浓度, 软测量, 固废焚烧, 样本, 离线, 在线, 预测, 增量, DXN, dioxin, emission, concentration, soft, measurement, MSWI, sample, offline, online, prediction, incremental

C. 相关文件

类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
PX	CN 116110506 A (北京工业大学) 2023年5月12日 (2023 - 05 - 12) 权利要求1-5	1-5
A	CN 114330845 A (北京工业大学) 2022年4月12日 (2022 - 04 - 12) 权利要求1, 说明书第[0003]-[0010], [0150]段	1-5
A	CN 114398836 A (北京工业大学) 2022年4月26日 (2022 - 04 - 26) 全文	1-5
A	CN 109960873 A (北京工业大学) 2019年7月2日 (2019 - 07 - 02) 全文	1-5
A	W0 2020228215 A1 (北京工业大学) 2020年11月19日 (2020 - 11 - 19) 全文	1-5
A	W0 2022252960 A1 (京东城市 (北京) 数字科技有限公司) 2022年12月8日 (2022 - 12 - 08) 全文	1-5

☐ 其余文件在C栏的续页中列出。

☒ 见同族专利附件。

* 引用文件的具体类型:

“A” 认为不特别相关的表示了现有技术一般状态的文件

“D” 申请人在国际申请中引证的文件

“E” 在国际申请日的当天或之后公布的在先申请或专利

“L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件 (如具体说明的)

“O” 涉及口头公开、使用、展览或其他方式公开的文件

“P” 公布日先于国际申请日但迟于所要求的优先权日的文件

“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件

“X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性

“Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性

“&” 同族专利的文件

国际检索实际完成的日期

2023年8月16日

国际检索报告邮寄日期

2023年8月23日

ISA/CN的名称和邮寄地址

中国国家知识产权局
中国北京市海淀区蓟门桥西土城路6号 100088

授权官员

王莹

电话号码 (+86) 010-53961411

PCT/ISA/210 表(第2页) (2022年7月)

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2023/101309

检索报告引用的专利文件			公布日 (年/月/日)	同族专利			公布日 (年/月/日)
CN	116110506	A	2023年5月12日	无			
CN	114330845	A	2022年4月12日	无			
CN	114398836	A	2022年4月26日	无			
CN	109960873	A	2019年7月2日	WO	2020192166	A1	2020年10月1日
				US	2021233039	A1	2021年7月29日
WO	2020228215	A1	2020年11月19日	US	2021033282	A1	2021年2月4日
				CN	110135057	A	2019年8月16日
WO	2022252960	A1	2022年12月8日	CN	113344196	A	2021年9月3日