

控制与决策

Control and Decision

基于WGRA-FCM样本相似性度量的转炉炼钢终点碳温软测量方法

刘辉, 曾鹏飞

引用本文:

刘辉, 曾鹏飞. 基于WGRA-FCM样本相似性度量的转炉炼钢终点碳温软测量方法[J]. *控制与决策*, 2021, 36(9): 2170-2178.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0128>

您可能感兴趣的其他文章

Articles you may be interested in

[基于聚类簇结构特性的自适应综合采样法在入侵检测中的应用](#)

Toward intrusion detection via cluster structure-based adaptive synthetic sampling approach

控制与决策. 2021, 36(8): 1920-1928 <https://doi.org/10.13195/j.kzyjc.2019.1672>

[基于混合邻域约束项的改进FCM算法](#)

Mixed neighborhood constraints based fuzzy C-means algorithm

控制与决策. 2021, 36(6): 1457-1464 <https://doi.org/10.13195/j.kzyjc.2019.1321>

[基于正态云模型的状态转移算法求解多目标柔性作业车间调度问题](#)

State transition algorithm based on normal cloud model for solving multi-objective flexible job shop scheduling problem

控制与决策. 2021, 36(5): 1181-1190 <https://doi.org/10.13195/j.kzyjc.2019.1233>

[基于相互邻近度的密度峰值聚类算法](#)

Density peaks clustering based on mutual neighbor degree

控制与决策. 2021, 36(3): 543-552 <https://doi.org/10.13195/j.kzyjc.2019.0795>

[考虑时间序列的动态大群体应急决策方法](#)

Dynamic large group emergency decision-making method considering time series

控制与决策. 2020, 35(11): 2609-2618 <https://doi.org/10.13195/j.kzyjc.2019.0088>

基于WGRA-FCM样本相似性度量的 转炉炼钢终点碳温软测量方法

刘 辉[†], 曾鹏飞

- (1. 昆明理工大学 信息工程与自动化学院, 昆明 650500;
2. 昆明理工大学 云南省人工智能重点实验室, 昆明 650500)

摘 要: 转炉炼钢过程中碳温连续实时预报是终点控制的关键, 针对过程数据波动影响炉次样本相似性度量进而造成建模困难、通用性差的问题, 同时考虑炼钢过程数据存在的时间序列特性, 提出一种自动聚类 and 计算待测样本后验概率的即时学习方法. 首先, 采用灰色关联度加权的模糊 C 聚类策略将历史库样本进行自动聚类; 然后, 利用混合高斯模型计算待测样本的后验概率确定关联度最大的样本集合; 最后, 度量出待测样本的最佳小样本子集, 进而采用 LSTM 网络预测终点碳温. 通过该方法对钢厂转炉炼钢生产过程数据进行验证, 实验结果表明, 按照炼钢的工艺要求, 温度预测误差在 $\pm 10^\circ\text{C}$ 的精确率为 93.3%, 碳含量预测误差在 ± 0.02 的精精确率为 90.0%.

关键词: 转炉炼钢; 灰色关联度; 模糊 C 聚类; 混合高斯模型; LSTM

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0128

开放科学(资源服务)标识码(OSID):



引用格式: 刘辉, 曾鹏飞. 基于 WGRA-FCM 样本相似性度量的转炉炼钢终点碳温软测量方法 [J]. 控制与决策, 2021, 36(9): 2170-2178.

End point carbon temperature measurement method based on WGRA-FCM for sample similarity measurement

LIU Hui[†], ZENG Peng-fei

- (1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Continuous real-time prediction of carbon and temperature is the key to the end point control in the process of converter steelmaking. Aiming at the problem that the fluctuation of process data affects the similarity measurement of furnace samples, which causes difficulties in modeling and poor generality, the time series characteristics of steelmaking process data are also considered, a real-time learning method of automatic clustering and calculating the posterior probability of samples to be tested is proposed. Firstly, the fuzzy C clustering strategy weighted by grey relational degree is adopted to automatically cluster the historical database samples. Then, the mixed Gaussian model is used to calculate the posterior probability of samples to be tested to determine the sample set with the largest correlation degree. Finally, the best small sample is measured out from a subset of the samples under test to predict end point carbon temperature with the LSTM network. Through the method of data verification, steel converter steelmaking experimental results show that, in accordance with requirements of the steelmaking process, the temperature prediction error on the accuracy of $\pm 10^\circ\text{C}$ is 93.33%, the accuracy of carbon content of the prediction error in $\pm 0.02\%$ is 90.0%.

Keywords: converter steelmaking; GRA; FCM; mixed Gaussian model; LSTM

0 引言

钢铁产业在国民经济生产中占有重要地位, 是实现工业化的基础条件. 转炉炼钢 (basic oxygen furnace, BOF) 以其高生产率和低成本的优势在世界

范围内得到广泛应用^[1]. 转炉炼钢的重要环节之一是实现吹炼终点的准确控制, 而终点控制的主要目标是使熔池中碳含量和温度达到出钢的工艺要求. 因此, 对熔池内碳温的快速、准确、实时预报是实现转

收稿日期: 2020-02-11; 修回日期: 2020-04-16.

基金项目: 国家自然科学基金项目 (61863018); 云南省科技厅应用基础研究项目 (202001AT070038).

责任编辑: 毛志忠.

[†]通讯作者. E-mail: liuhui621@126.com.

炉炼钢终点控制的关键,同时对提高炼钢生产效率、降低冶炼成本和节能减排有着重要的意义^[2]。

目前,BOF终点碳温测量方法主要有直接测量和间接测量两大类。其中,直接测量的方法检测熔池内钢水碳温时大多采用副枪检测^[3],但副枪在吹炼的全过程中只能间断性探测,不能实现连续实时测量,且副枪探头长期处于高温腐蚀环境中,使用和维护成本较高。随着工业智能化检测水平不断发展,间接测量终点碳温成为学者们的研究热点。温宏愿等^[4]利用炉口光谱辐射法实现对终点碳温的预报,但作者指出炼钢现场受钢包等其他高温物体的影响,获取到的光谱图片存在一定的干扰性造成终点碳温预测难度加大;李鹏举等^[5]采用炉口火焰动态形变特征预测终点碳温,但后续研究表明,随着火焰炉次样本的增加,不同碳温所对应的火焰图片相似性较大,导致提取的关键特征难以很好地区分,进而导致预测精度不理想。在BOF吹炼过程中,加入的石灰石、铁水、废钢、硅锰量等过程生产数据与终点碳含量和温度有着密切的非线性映射关系^[6],为基于过程生产数据驱动的终点碳温软测量方法提供了理论依据。谢书明等^[7]综合使用RBF(radial basis function)神经网络对转炉终点碳含量和温度进行预报;王心哲等^[8]使用变量选择的转炉炼钢终点预报模型;Cox等^[9]采用BP(back propagation)神经网络模型对BOF终点碳温进行预测;Zhou等^[10-11]依据BOF生产线上传感器测量的相关数据,结合多输出最小二乘支持向量回归(partial least squares, PLS)理论建立了非线性终点碳温预测模型。然而,转炉炼钢是一个复杂的物理化学过程,数据之间存在严重的非线性关系,且实际炼钢生产过程中,受炼钢原材料的品质不同以及检测仪表、变送器装置故障和人工操作失误的影响,采集的生产过程数据经常出现数据异常现象,导致预测模型不匹配实际工况,而建立的全局模型却很难在线更新,无法更好地预测出复杂工况下当前炉次的终点碳温,难以把握出钢的最佳时刻。

考虑到基于生产过程数据驱动的全局建模方法无法有效预测出实际工况下转炉炼钢终点时刻的碳温,常见方法是采用即时学习^[12](just in time learning, JITL)策略。已有文献表明,JITL策略的核心问题之一在于样本相似性度量问题。祁成等^[13]采用混合高斯模型加权马氏距离的方法度量样本之间的相似性;Chen等^[14]认为相似度准则仅仅与样本的输入信息有关,没有考虑到样本的输出信息,因此将输入和输出变量信息综合起来构建自适应加权距离作为相似性度量指标;Ge等^[15]将计算前后两个相邻测

试样本之间的相似度改进为计算当前时刻样本与上一更新初始时刻样本之间的相似度,预测精度有更好的提高。转炉炼钢实际生产中,工人会通过参照上一炉次的生产过程数据指导当前炉次的生产物料投放,进而更好地控制出钢时刻;此外,在连续生产过程中,前序炉次终点温度等数据也会影响后续炉次的生产数据。因此,从全局角度分析,历史库炉次样本间的数据具有较强的时间序列特性;同时因炼钢时矿石品质的不同和生产过程中检测的误差等问题造成炉次样本间的波动性较大导致无法有效地更好度量炉次样本间的相似性,使其待测样本的最佳训练子集达不到类间方差更大、类内方差更小的效果,进而影响终点碳温预测精度。已有文献综合采用灰色关联度算法(grey relational degree, GRA)进行样本相似性度量进而建立预测模型取得了较好的效果^[16-17],证明了GRA算法在度量具有时间序列特性样本相似性上具有一定的优势。

综上,本文从时间序列特性样本相似性度量准则出发,提出一种灰色关联度加权的模糊C聚类(ceighted grey relational analysis of fuzzy C-means algorithm, WGRA-FCM)和混合高斯模型(Gaussian mixture model, GMM)后验最大概率算法建立局部最优模型的终点碳温软测量方法。首先,通过构建WGRA度量策略实现对炉次样本的相似性度量,GRA准确有效地挖掘出丰富的时序信息;在GRA的基础上结合输入与输出间的贡献度信息实施加权策略有效平衡数据波动性大的问题;其次,采用WGRA度量样本相似性的自动模糊C聚类算法将历史库样本自动聚类,使得子集样本类间方差更大;随后,利用GMM模型计算出待测样本隶属于子集样本的最大概率,进而度量出类间方差最小的训练样本集;最后,采用具有反馈补偿机制的长短期记忆循环神经网络(long short term memory, LSTM)建立终点碳温预报回归模型,因训练样本具有很强的时间序列,更加利于模型对前序炉次样本信息的利用,增强模型的泛化能力。对转炉炼钢终点碳温预测进行仿真实验,结果表明本文所提方法能够有效融入时间序列特性且能够克服数据波动较大的相似性度量问题,提高了模型预测终点碳温的精度。

1 WGRA-FCM规则

1.1 传统即时学习相似性度量策略

JITL的思想是相似输入产生相似输出,而度量出待测样本的最佳子集是提高预测精度的关键。传统的相似性度量是从历史库样本 $X = [x_1, x_2, \dots, x_i]$ 中选择出与待测样本 x_q 相似度最高的一组训练

子集建立当前的最优局部模型,传统JITL度量准则描述如下:

$$S = \varphi \sqrt{\exp(d^2)} + (1 - \varphi) \cos \theta. \quad (1)$$

其中: S 表示待测样本 x_q 与训练样本 X 之间的相似度; φ 表示0到1之间的权重系数; d 表示两个样本之间的二范数; θ 表示两个样本之间的夹角,其中参数 d 与 θ 的计算公式如下:

$$d = \|x_q - x_i\|_2, \quad (2)$$

$$\theta = \cos^{-1} \frac{X_q^T \times x_i}{\|x_q\|_2 \times \|x_i\|_2}. \quad (3)$$

传统的相似性度量策略无法有效度量出具有时间序列特性且样本之间差异性很大的数据^[18],具体到本文特定的研究对象中时,待测的炉次样本无法度量出最佳的训练子集样本,造成转炉终点碳温的预测精度不高,影响吹炼终点的准确控制.

1.2 炉次样本WGRA度量策略

给定包含 n 炉次的历史样本库,终点碳温输入数据和输出数据集 H 表示如下:

$$H = \begin{bmatrix} h_{1,1} & \dots & h_{1,m} \\ \vdots & \ddots & \vdots \\ h_{n,1} & \dots & h_{n,m} \end{bmatrix}, \quad (4)$$

其中 $H = \{h_i \in R^m, i = 1, 2, \dots, n\}$, m 表示样本特征维数,第 $m-1, m$ 维表示终点碳含量和温度.

本文方法度量炉次样本相似性的流程为:首先通过重要贡献度 (important contribution degree, ICD) 衡量输入特征与输出终点碳温的ICD值,随后的关键步骤是将每个特征的重要贡献度值加权给灰色关联度,采用该相似度准则结合类间、类内评价函数使模糊 C 聚类自动分成最佳的样本子集,进而采用混合高斯模型后验概率确定待测样本隶属聚类子集样本的最大概率,最后度量出待测样本的最佳小样本集合,其思路流程如图1所示.

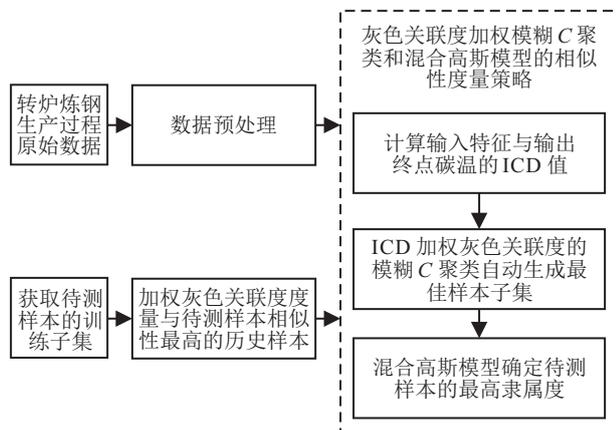


图1 相似性度量策略思路流程

1.2.1 灰色关联度加权的自动模糊 C 聚类

FCM算法是一种局部搜索算法,引入隶属度来表示每个数据点相对于每一类的约束性程度,其强弱度的程度根据式(1)计算每个样本点到其聚类中心的 S 值,但实验结果表明其聚类的子集样本的类间与类内方法达不到最佳,影响炉次待测样本的相似性度量,而文献[16]、文献[17]证明了传统GRA准则度量具有时间序列特性样本的有效性.同时考虑到炉次样本之间的波动性,本文在此基础上引入加权灰色关联度度量策略进行炉次样本的相似性度量,其WGRA度量策略如下:

$$D_{x_q, x_i} = \frac{1}{N} \sum_{k=1}^N \delta_{x_q, x_i}(k). \quad (5)$$

式(5)表示 D_{x_q, x_i} 待测样本 x_q 与历史库样本之间的加权灰色关联度值.

在给出具体计算过程之前,先给出如下定义.

定义1 (ICD算法的灰色关联度加权准则) 准则如下:

1) 采用皮尔逊相关系数 (Pearson correlation coefficient, PCCs) 计算输入特征与输出之间的相关系数 $P_{i,j}$ 如下所示:

$$P_{i,j} = \frac{\text{cov}(x_i, y_j)}{\sigma_{x_i} \times \sigma_{y_j}}, \quad i \in (1, m-2), j \in (1, 2). \quad (6)$$

2) 通过式(6)衡量出输入特征与终点碳温的相关性,进而得到每个输入特征对于输出的重要贡献度

$$\text{ICD} = \left| \frac{P_{i,j}}{\max(P_{i,j})} \right| \times 100\%. \quad (7)$$

其中: i 表示炉次样本的输入特征, j 表示终点碳温值.

3) 通过式(7)分别得到每个输入特征与终点碳含量和温度的ICD加权系数向量

$$\text{ICD}^C = [\text{ICD}_1^C, \text{ICD}_2^C, \dots, \text{ICD}_{m-2}^C]. \quad (8)$$

每个输入特征与终点温度的ICD值为

$$\text{ICD}^T = [\text{ICD}_1^T, \text{ICD}_2^T, \dots, \text{ICD}_{m-2}^T]. \quad (9)$$

step 1: 通过下式计算待测 x_q 与历史库样本 X 每一维度的绝对差值,构成差值矩阵

$$\Delta_{x_i, x_q}(k) = |X_q(k) - X_i(k)|, \quad (10)$$

差值矩阵表示如下:

$$\Delta_{x_i, x_q}(k) = \begin{bmatrix} \Delta_{x_1, x_q}(1) & \dots & \Delta_{x_1, x_q}(m) \\ \vdots & \ddots & \vdots \\ \Delta_{x_i, x_q}(1) & \dots & \Delta_{x_i, x_q}(m) \end{bmatrix}. \quad (11)$$

step 2: 通过式(11)获取两级极差的最大、最小值,计算公式如下所示:

$$\begin{cases} \Delta(\max) = \max(\Delta_{x_i, x_q}(k)), \\ \Delta(\min) = \min(\Delta_{x_i, x_q}(k)), \\ k \in (1, m). \end{cases} \quad (12)$$

step 3: 确定灰色关联度量炉次样本的加权系数. ICD 算法结合了输入和输出变量综合信息, 进而对灰色关联度进行加权能更好地度量炉次样本间的相似性, 使其更加利于终点碳温的预测.

step 4: 通过 ICD 加权灰色关联度准则得到输入特征加权灰色关联系数如下所示:

$$\delta_{x_q, x_j} = \frac{\Delta(\min) + \text{ICD} \times \Delta(\max)}{\Delta_{i,m}(k) + \text{ICD} \times \Delta(\max)}. \quad (13)$$

step 5: 通过式 (13) 获取待测样本 x_q 与历史库样本 X 之间每个特征的关联度系数如下:

$$\delta_{x_i, x_q} = \begin{bmatrix} \delta_{1,1} & \dots & \delta_{1,m} \\ \vdots & \ddots & \vdots \\ \delta_{i,1} & \dots & \delta_{i,m} \end{bmatrix}. \quad (14)$$

此时, 返回式 (5) 得到样本之间的加权灰色关联度值.

step 6: 采用灰色关联度加权度量准则的 FCM 算法将历史库的炉次样本进行聚类, 获取最佳的子集样本.

模糊 C 均值聚类时, 不同的聚类数会使得聚类的结果不同^[9], 进而影响待测样本的最佳子集样本选择. 通过定义一种衡量类间、类内离散程度的模型, 进而构造一种自适应评价函数判断聚类效果好坏以确定其最佳的聚类个数 C .

定义 2 (GRA 准则的类间方差) 通过确定总体样本的中心点 \bar{x} , 计算类类样本到中心点的灰色关联度方差值, 达到衡量类间方差的目的. \bar{x} 表示如下:

$$\bar{x} = \sum_{i=1}^C \sum_{k=1}^n u_{ik} x_k / n. \quad (15)$$

通过式 (15) 计算样本到中心点的灰色关联度值进而衡量样本类间距离, 当聚类效果最佳时, 类间方差最大, 衡量类间方差公式如下:

$$\sum_{i=1}^C \sum_{k=1}^N D_{x_q, x_i} \|\text{GRA}(x_i) - \text{GRA}(x_q)\|^2. \quad (16)$$

定义 3 (GRA 准则的类内方差) 通过类内中的样本点到聚类中心的灰色关联方差值衡量聚类效果, 类内方差越小, 聚类效果越佳. 通过下式计算类内样本点的距离:

$$\sum_{i=1}^C \left(\sum_{k=1}^N \|\text{GRA}(D_{x_i}) - \text{GRA}(\bar{C})\|^2 \right). \quad (17)$$

在每次聚类时, 通过定量分析类间、类内之间的方差, 确定最佳的 C 值. 为此, 在式 (16) 和 (17) 的基础上引入最佳参数 C 和最大的聚类数 N 构造确定最佳类别数的自适应评价函数如下所示:

$$P(C) = \frac{\sum_{i=1}^C \sum_{k=1}^N D_{x_q, x_i} \|x_i - x_q\|^2}{\sum_{i=1}^C \left(\sum_{k=1}^N \|D_{x_i} - \bar{C}\|^2 \right)}. \quad (18)$$

式 (18) 中分子表示类内之间的方差, 分母表示类间的方差, 当类内方差值越小、类间方差越大时, 聚类效果越佳, 表征出来的结果就是值越小, 因此找到合适的 C 值使自适应评价函数最小时即可确定最佳分类数, 通过不停的迭代进而找到最佳的 C 值. 模糊 C 均值聚类算法流程如图 2 所示.

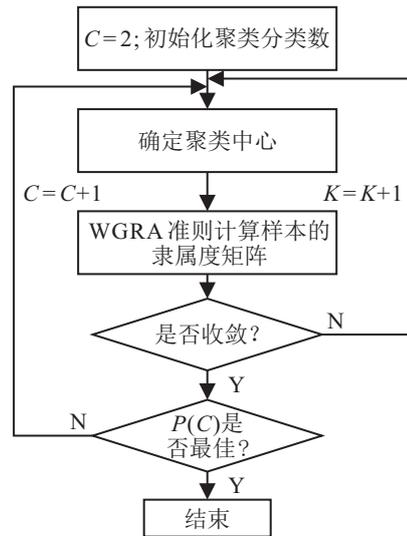


图 2 模糊 C 均值自动聚类算法流程

1.2.2 GMM 后验概率确定待测炉次样本的训练子集

对于任意的数据, 单高斯模型无法有效地拟合, 当高斯成分足够多时, GMM 能拟合任意的概率密度^[20], 因此通过 GMM 后验概率进而确定炉次待测样本的最佳样本子集.

设定历史库样本聚类的子集样本集合如下所示:

$$R = [r_1, r_2, \dots, r_n]. \quad (19)$$

聚类样本 L 概率密度函数可以表示为

$$L\left(\frac{R}{\theta_{\text{GMM}}}\right) = \prod_{i=1}^N \sum_{k=1}^k \pi_k N(x_i / u_k, \sigma_k^2), \quad (20)$$

其中混合高斯模型参数为

$$\theta_{\text{GMM}} = \{u_1, \dots, u_k, \sigma_1^2, \dots, \sigma_k^2, \pi_1, \dots, \pi_k\}. \quad (21)$$

u_k 、 σ_k^2 、 π_k 分别表示第 k 个高斯模型的均值、协方差和权重, 当混合高斯模型将 R 拟合后, 其模型的参数即可确定, 此时通过式 (21) 确定待测样本的最大概率

$$N(x_q | u_k, \sigma_k^2) = \frac{\exp\left\{-\frac{1}{2} \left(\frac{x_q}{u_k}\right)^2 (\sigma_k^2)^{-1} (x_q - u_k)\right\}}{(2\pi)^{\frac{m-2}{2}} |\sigma_k^2|^{\frac{1}{2}}}. \quad (22)$$

x_q 为待测样本, $m - 2$ 为输入的样本特征数. 通过式 (22) 计算其待测样本隶属 R 中的概率, 选择概率最大的样本子集 r_n . 随后, 利用 WGRA 准则度量子集 r_n 中与待测样本相似度最高的一组样本, 最佳子集样本如下所示:

$$H^* = \begin{bmatrix} h_{1,1}^* & \dots & h_{1,m}^* \\ \vdots & \ddots & \vdots \\ h_{e,1}^* & \dots & h_{e,m}^* \end{bmatrix}. \quad (23)$$

具有时间特性且样本之间差异度大的相似性度量策略算法图3所示.

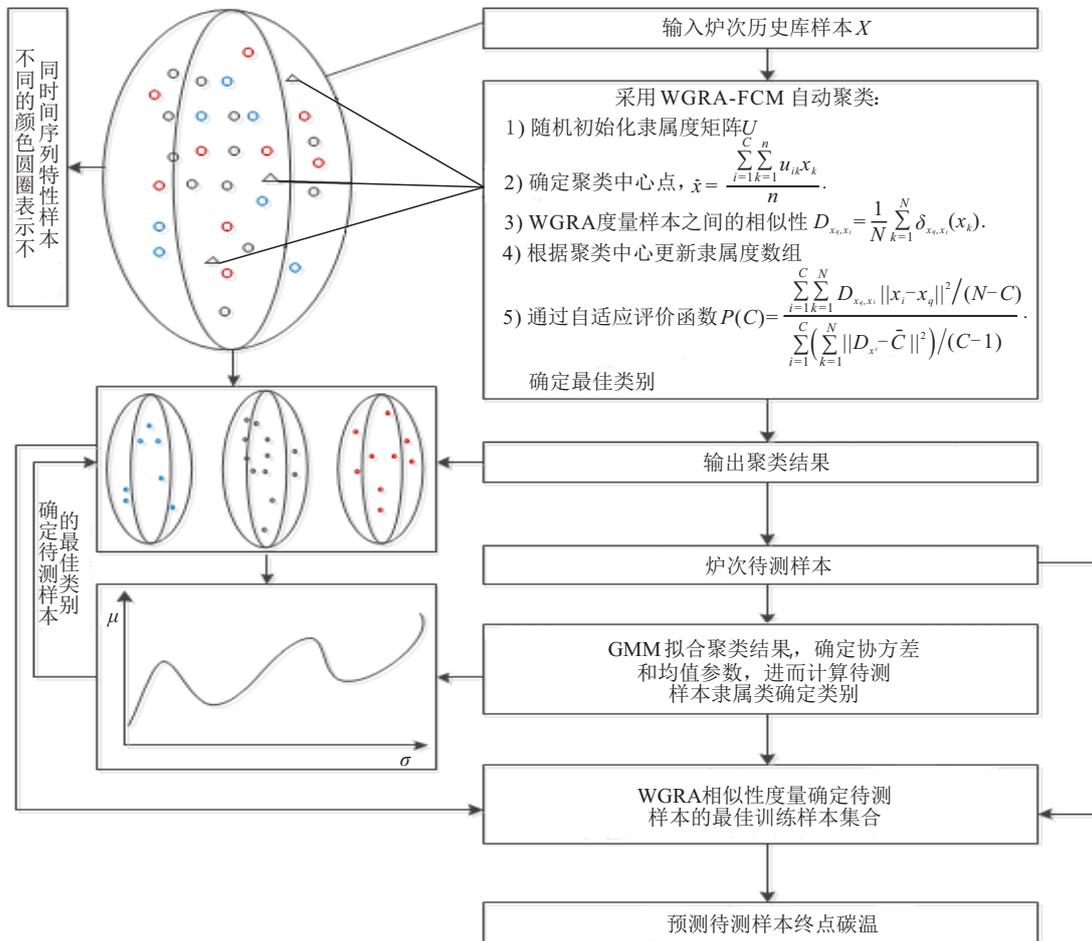


图3 炉次样本相似性度量算法原理

本算法从具有时间特性的炉次样本度量策略角度出发, 采用灰色关联度准则不仅兼顾了距离和角度的信息, 且挖掘出了炉次样本的时间信息, 通过结合输入与输出的信息加权给 GRA 度量准则, 有效地将样本间的类内差距变小, 类间差距变大. 采用模糊 C 自动聚类有效地节约了炉次待测样本预测出终点碳温的时间, 同时即时学习思想有效克服了数据波动大导致预测精度不高的问题.

2 转炉炼钢终点碳温预测模型

递归神经网络 (recurrent neural network, RNN) 属于深度神经网络, 其主要解决的问题是处理具有时间序列特性的数据^[21], 使上一时刻的输入数据对当前数据产生影响, 在炉次样本数据缺失或错误的情况下也有较强的鲁棒性, 但网络层数的增加会导致“梯度

消失”问题, 不利于终点碳温的准确预测, 因此 LSTM 在其基础上增加记忆模块、输入门、遗忘门、输出门, 能够克服 RNN 的不足. LSTM 不仅克服了“梯度消失”问题, 同时反馈层的加入融入了炉次样本时间序列特征, 使得数据在残缺的情况下充分利用前一炉次的信息. 实验证明, 在数据有残缺和不合理的情况下, 大部分数据的预测精度误差在允许范围内. LSTM 网络神经元的运行机理如图4所示.

LSTM 网络能够预测具有时间序列特性的炉次样本信息, 能够有效克服炉次样本间因生产工况的复杂性导致样本数据丢失和错误等情况, 循环神经网络不仅可以提取层次间的特征, 而且反馈层的加入又融合了炉次样本间序列特征, 因此在数据残缺的情况下充分利用 $t - 1$ 时刻的炉次样本信息, 从而使预测精度达到最优.

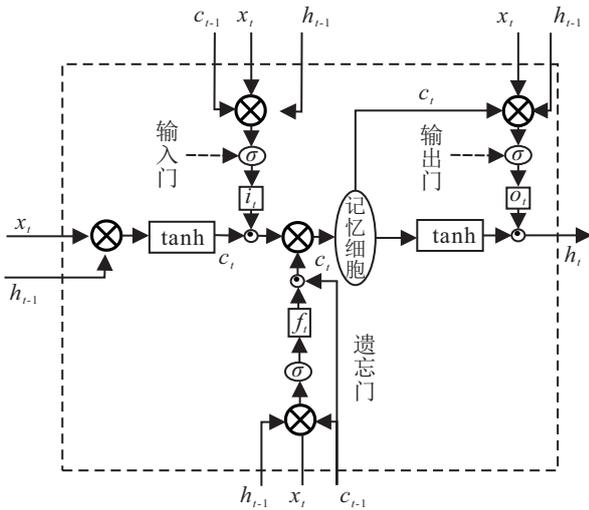


图4 LSTM网络记忆模块结构

3 仿真实验

按照上述方法,建立转炉炼钢终点碳温预报模型,使用30组数据对上述方法进行验证实验,纵向对比文献[22]中的传统即时学习度量策略方法和文献[23]中的GRA度量策略,证明灰色关联度量具有时间序列特性样本的可行性及加权策略对炉次样本相似性度量的有效性;同时,增加了文献[12]、文献[13]的横向对比实验,以及干扰数据情况下的对比实验,以此证明本文所提方法预测终点碳温的有效性。

3.1 实验原始数据及样本特征

实验数据来源于实际钢厂转炉炼钢生产数据,其过程数据包括装入铁水量、装入生铁量、装入废钢量、铁水C、铁水SI、铝铁时间、1吹氧量、枪位16、氧压28等120维数据,历史库样本2万炉次。原始部分实验数据列举如表1所示。

表1 转炉炼钢生产过程原始数据

炉次	装入铁水量	装入生铁量	装入废钢量	铁水C	氧压28	...	温度	C
1	120	7.39	10.41	4.15	0.87	...	1632	0.22
2	118	7.1	8.99	4.19	0.84	...	1640	0.25
3	124	8.18	8.08	4.21	0.89	...	1642	0.24
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20000	112.8	9.16	12.09	4.36	0.81	...	1597	0.09

通过特征选择,选出终点碳温与生产过程数据联系最密切的特征。终点温度预测的输入特征包括氧压31、兑铁时长、兑铁结束到开氧时间、铁水温度、枪位36、装入废钢量;终点碳含量预测的输入特征包括装入生铁量、铁水P、枪位22、氧压29、氧压11、枪位16,其中部分特征名称中所含数字表示不同时刻点传感器对该特征进行测量的次数。

通过碳温预测实验结果说明本文相似性度量策

略的有效性,实验结果如下所示。图5~图10为终点温度预测实验结果,图11~图16为终点碳含量预测结果,预测精度如表2和表3所示。

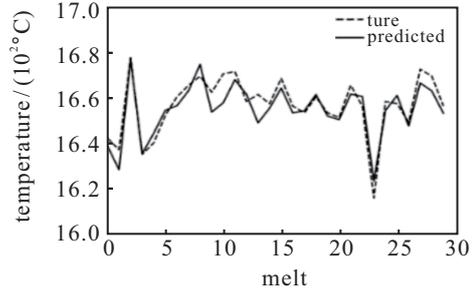


图5 本文方法终点温度预测

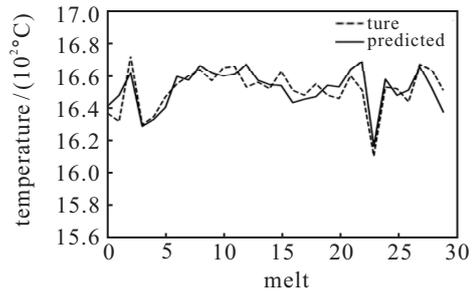


图6 数据扰动+本文方法终点温度预测

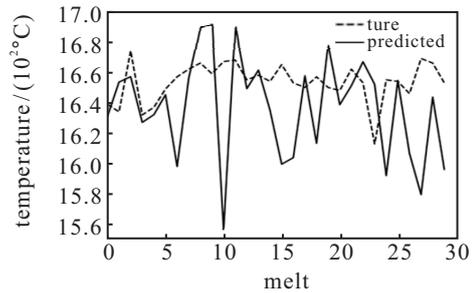


图7 文献[22]传统即时学习度量策略终点温度预测

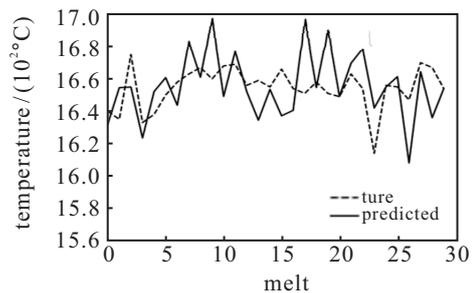


图8 文献[23]GRA度量策略终点温度预测

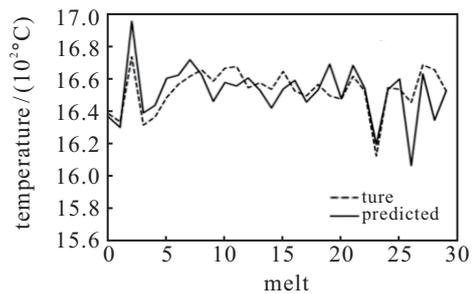


图9 文献[12]二阶相似性度量策略终点温度预测

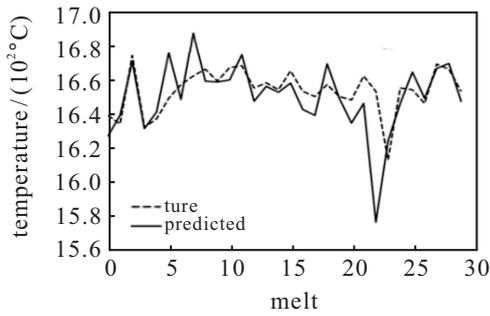


图10 文献[13]BGMM策略终点温度预测

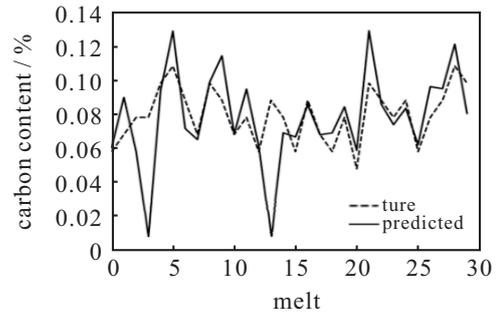


图15 文献[12]二阶相似性度量策略终点碳含量预测

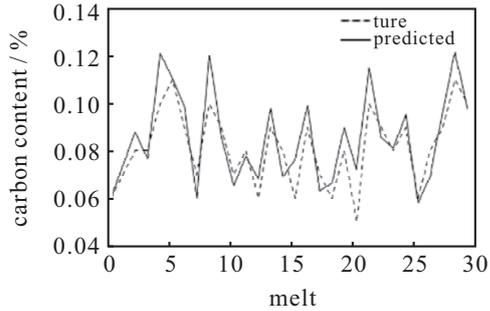


图11 本文方法终点碳含量预测

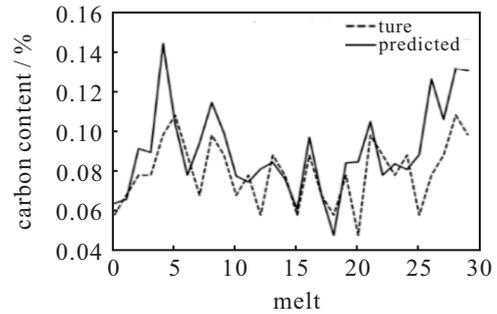


图16 文献[13]BGMM策略终点碳含量预测

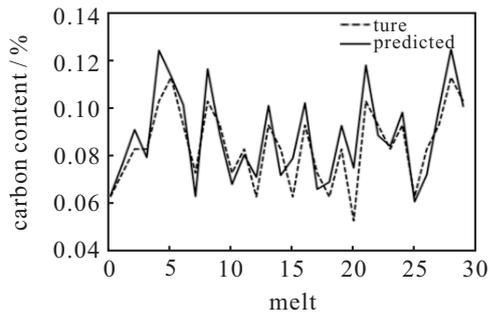


图12 数据扰动+本文方法终点碳含量预测

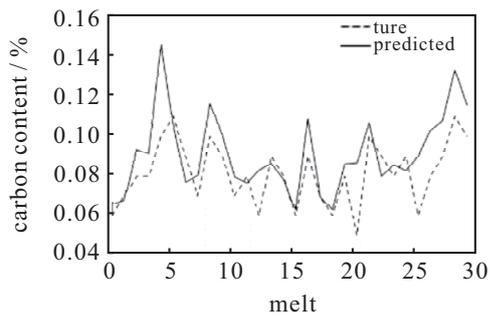


图13 文献[22]传统即时学习度量策略终点碳含量预测

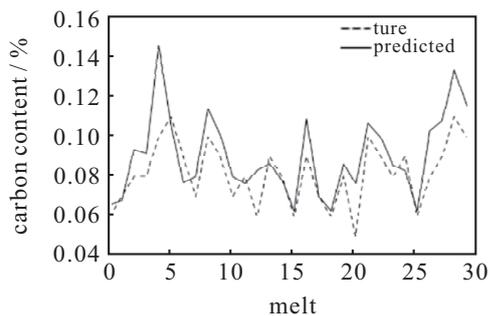


图14 文献[23]GRA度量策略终点碳含量预测

表2 转炉炼钢终点温度预测结果 %

	终点温度预测 误差 ± 5°C	终点温度预测 误差 ± 10°C
文献[12]二阶相似性度量策略	33.3	66.7
文献[13]BGMM策略	26.7	56.7
文献[20]传统即时学习度量策略	16.7	33.3
文献[21]GRA度量策略	20.0	43.3
本文方法	73.3	93.3
数据扰动+本文方法	67.7	86.7

表3 转炉炼钢终点碳含量预测结果 %

	终点温度预测 误差 ± 0.01 %	终点温度预测 误差 ± 10 %
文献[12]二阶相似性度量策略	53.3	76.7
文献[13]BGMM策略	56.7	56.7
文献[20]传统即时学习度量策略	50	80
文献[21]GRA度量策略	53.3	83.34
本文方法	80.0	90.0
数据扰动+本文方法	73.3	90

3.2 实验分析

1) 传统即时学习相似性度量策略和 GRA 度量策略选择的最佳子样本预测终点碳温时,温度误差在 ±10°C 内的精度分别为 33.4% 和 43.4%, 碳含量预测误差在 ±0.02% 内的精度分别为 80.0% 和 83.34%, GRA 度量策略使得温度预测精度和碳含量精度提高了 10% 和 3%, 说明 GRA 策略在度量具有时间序列炉次样本时有一定的优势.

2) 在数据有干扰情况下, 预测温度在 ±10°C 的精度为 86.7%; 在 ±5°C 的预测精度是 67.7%, 相比于无干扰的情况分别下降了 6.6% 和 5.6%. 在误差

允许范围内,碳含量预测中, $\pm 0.02\%$ 的预测精度为93.3%, $\pm 0.01\%$ 的误差预测精度为80.0%,相比于无干扰情况下,误差在 $\pm 0.02\%$ 时降低了3.3%,误差在 $\pm 0.01\%$ 时下降了6.9%,该组对比实验表明了本文所提方法具有一定的抗干扰能力.因其加权灰色关联度使选择的局部样本时间序列信息更强,且LSTM网络有效地融合了邻近序列样本的信息,在数据异常时可以有效忽略其干扰,增强模型的鲁棒性.

3) 本文所提方法相比于文献[12],预测温度在 $\pm 10^\circ\text{C}$ 的精度从66.7%提高到93.3%,碳含量预测误差在 $\pm 0.02\%$ 内的精度从76.7%提高到93.3%.相比于文献[13],预测温度在 $\pm 10^\circ\text{C}$ 的精度从56.7%提高到93.3%,碳含量预测误差在 $\pm 0.02\%$ 内的精度从73.3%提高到93.3%.原因在于灰色关联度准则适用于度量具有时间序列特性的炉次样本,而ICD加权准则平衡了样本间的特征波动性大的问题,进而采用自动模糊C聚类时能够更好地将不同时间序列样本分开,更加有利于待测样本选择最佳训练子集;同时,采用LSTM网络建模时,训练子集具有很强的时间序列性,利于模型更好地挖掘出样本的规律,使得预测终点碳温的精度更高.

4 结论

转炉炼钢过程中,终点碳温准确预报是出钢的关键.本文针对转炉炼钢过程数据具有时间序列特性炉次样本且样本间数据波动较大的问题,建立WGRA-FCM准则和GMM后验概率方法确定待测样本的最佳训练样本,进而采用具有时间序列特征分析的LSTM网络模型进行终点碳温预测.具体内容如下:

1) 采用WGRA准则有效地挖掘出炉次样本间的时间特性,加权准则充分利用了输出终点碳温与输入特征的相关性,能更好地度量具有时间序列样本特点的相似性.

2) 构造模糊C聚类确定类别数的自适应评价函数,让历史库样本的聚类效果更加合理,使得待测样本度量出的相似样本类内方差更小,利于终点碳温的准确预测.

3) LSTM网络使得隐含层和输出层特征利用更加合理,隐含层的循环可以提取层次间的特征,反馈层的加入又融合了炉次样本间序列特征,使得在数据残缺的情况下充分利用上一炉次的信息,以保证其预测精度的最优化.本文所提终点碳温预报模型具有一定的实际应用价值,为实现转炉炼钢计算机自动控制任务打下良好的基础.

参考文献(References)

- [1] 邵艳明, 陈延如, 赵琦, 等. 基于炉口火焰辐射测温的转炉终温预测研究[J]. 光谱学与光谱分析, 2015, 35(11): 3023-3027.
(Shao Y M, Chen Y R, Zhao Q, et al. Endpoint temperature prediction of the basic oxygen furnace based on the flame temperature measurement at the converter mouth[J]. Spectroscopy and Spectral Analysis, 2015, 35(11): 3023-3027.)
- [2] Shao Y M, Zhou M C, Chen Y R, et al. BOF endpoint prediction based on the flame radiation by hybrid SVC and SVR modeling[J]. Optik, 2014, 125(11): 2491-2496.
- [3] 王忠刚, 任科社, 刘忠建. 副枪技术在莱钢120t转炉上的应用[J]. 中国冶金, 2009, 19(11): 30-32.
(Wang Z G, Ren K S, Liu Z J. Sublance technology application of 120t converter at Laiwu steelmaking plant[J]. China Metallurgy, 2009, 19(11): 30-32.)
- [4] 温宏愿, 赵琦, 陈延如, 等. 基于炉口辐射和改进神经网络的转炉终点预测模型[J]. 光学学报, 2008, 28(11): 2131-2135.
(Wen H Y, Zhao Q, Chen Y R, et al. Basic-oxygen-furnace endpoint forecasting model based on radiation and modified neural network[J]. Acta Optica Sinica, 2008, 28(11): 2131-2135.)
- [5] 李鹏举, 刘辉, 王彬, 等. 基于火焰动态形变特征的转炉炼钢终点判定[J]. 仪器仪表学报, 2015, 36(11): 2625-2633.
(Li P J, Liu H, Wang B, et al. Endpoint determination of the basic oxygen furnace based on flame dynamic deformation characteristics[J]. Chinese Journal of Scientific Instrument, 2015, 36(11): 2625-2633.)
- [6] 韩敏, 张瑞全, 许美玲. 一种基于改进灰色关联分析的变量选择算法[J]. 控制与决策, 2017, 32(9): 1647-1652.
(Han M, Zhang R Q, Xu M L. A variable selection algorithm based on improved grey relational analysis[J]. Control and Decision, 2017, 32(9): 1647-1652.)
- [7] 谢书明, 陶钧, 柴天佑. 基于神经网络的转炉炼钢终点控制[J]. 控制理论与应用, 2003, 20(6): 903-907.
(Xie S M, Tao J, Chai T Y. BOF steelmaking endpoint control based on neural network[J]. Control Theory & Applications, 2003, 20(6): 903-907.)
- [8] 王心哲, 韩敏. 基于变量选择的转炉炼钢终点预报模型[J]. 控制与决策, 2010, 25(10): 1589-1592.
(Wang X Z, Han M. Variable selection based BOF endpoint prediction model[J]. Control and Decision, 2010, 25(10): 1589-1592.)
- [9] Cox I J, Lewis R W, Ransing R S, et al. Application of neural computing in basic oxygen steelmaking[J]. Journal of Materials Processing Technology, 2002, 120(1/2/3):

- 310-315.
- [10] Zhou P, Guo D W, Wang H, et al. Data-driven robust M-LS-SVR-based NARX modeling for estimation and control of molten iron quality indices in blast furnace ironmaking[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(9): 4007-4021.
- [11] 易诚明, 周平, 柴天佑. 基于即时学习的高炉炼铁过程数据驱动自适应预测控制[J]. *控制理论与应用*, 2020, 37(2): 295-306.
(Yi C M, Zhou P, Chai T Y. Data-driven just-in-time learning based adaptive predictive control for blast furnace ironmaking[J]. *Control Theory & Applications*, 2020, 37(2): 295-306.)
- [12] 祁成, 史旭东, 熊伟丽. 基于二阶相似度的即时学习软测量建模方法[J]. *智能系统学报*, 2020, 15(5): 910-918.
(Qi C, Shi X D, Xiong W L. A just-in-time learning soft sensor modeling method based on the second-order similarity[J]. *CAAI Transactions on Intelligent Systems*, 2020, 15(5): 910-918.)
- [13] 祁成, 熊伟丽. 基于BGMM的即时学习软测量建模方法[J]. *系统仿真学报*, 2019, 31(8): 1555-1561.
(Qi C, Xiong W L. A just-in-time learning soft sensing modeling method based on Bayesian Gaussian mixture model[J]. *Journal of System Simulation*, 2019, 31(8): 1555-1561.)
- [14] Chen K, Liu Y. Adaptive weighting just-in-time-learning quality prediction model for an industrial blast furnace[J]. *ISIJ International*, 2017, 57(1): 107-113.
- [15] Ge Z Q, Song Z H. A comparative study of just-in-time-learning based methods for online soft sensor modeling[J]. *Chemometrics and Intelligent Laboratory Systems*, 2010, 104(2): 306-317.
- [16] 湛社霞, 匡耀求, 阮柱. 基于灰色关联度的粤港澳大湾区空气质量影响因素分析[J]. *清华大学学报: 自然科学版*, 2018, 58(8): 761-767.
(Zhan S X, Kuang Y Q, Ruan Z. Factors impacting the regional air quality in the Guangdong-Hong Kong-Macao Greater Bay Area: A study based on grey relational analysis[J]. *Journal of Tsinghua University: Science and Technology*, 2018, 58(8): 761-767.)
- [17] 赵怀鑫, 孙星星, 徐倩倩, 等. 基于灰熵法的公路货运量和货物周转量关联因素分析[J]. *交通运输工程学报*, 2018, 18(4): 160-170.
(Zhao H X, Sun X X, Xu Q Q, et al. Analysis of relevant factors for highway freight volume and freight turnover based on grey entropy method[J]. *Journal of Traffic and Transportation Engineering*, 2018, 18(4): 160-170.)
- [18] 韩敏, 马俊珠, 任伟杰, 等. 基于核自适应滤波器的时间序列在线预测研究综述[J]. *自动化学报*, DOI: 10.16383/j.aas.c190051.
(Han M, Ma J Z, Ren W J, et al. A review of online prediction of time series based on kernel adaptive filter[J]. *Acta Automatica Sinica*, DOI: 10.16383/j.aas.c190051.)
- [19] 张丽艳, 陈映月, 韩正庆. 基于改进聚类方式的牵引负荷分类方法[J]. *西南交通大学学报*, 2020, 55(1): 27-33.
(Zhang L Y, Chen Y Y, Han Z Q. Traction load classification method based on improved clustering method[J]. *Journal of Southwest Jiaotong University*, 2020, 55(1): 27-33.)
- [20] 肖进胜, 刘婷婷, 张亚琪, 等. 一种基于历史背景的混合高斯背景建模算法[J]. *湖南大学学报: 自然科学版*, 2015, 42(10): 127-132.
(Xiao J S, Liu T T, Zhang Y Q, et al. A history background-based Gaussian mixture background modeling algorithm[J]. *Journal of Hunan University: Natural Sciences*, 2015, 42(10): 127-132.)
- [21] 虞浩跃, 沈韬, 朱艳, 等. 基于双向长短期记忆网络的太赫兹光谱识别[J]. *光谱学与光谱分析*, 2019, 39(12): 3737-3742.
(Yu H Y, Shen T, Zhu Y, et al. Terahertz spectral recognition based on bidirectional long short-term memory recurrent neural network[J]. *Spectroscopy and Spectral Analysis*, 2019, 39(12): 3737-3742.)
- [22] 朱明鹤. 基于即时学习的接收灵敏度测量方法[J]. *电子设计工程*, 2018, 26(8): 102-105.
(Zhu M H. Receiver sensitivity measurement method based on lazy learning[J]. *Electronic Design Engineering*, 2018, 26(8): 102-105.)
- [23] 赵静, 王选仓, 丁龙亭, 等. 基于灰色关联度分析和支持向量机回归的沥青路面使用性能预测[J]. *重庆大学学报*, 2019, 42(4): 72-81.
(Zhao J, Wang X C, Ding L T, et al. Performance prediction of asphalt pavement based on grey relational analysis and support vector machine regression[J]. *Journal of Chongqing University*, 2019, 42(4): 72-81.)

作者简介

刘辉(1984—), 男, 副教授, 博士, 从事图像处理、软测量等研究, E-mail: liuhui621@126.com;

曾鹏飞(1992—), 男, 硕士生, 从事图像处理、软测量的研究, E-mail: 1431919050@qq.com.

(责任编辑: 齐 霖)