

DOI: 10.19650/j.cnki.cjsi.J2311259

基于多源异构信息自适应融合的镁砂熔炼过程运行状态评价*

刘炎¹, 熊雨露¹, 褚菲², 王福利¹

(1. 东北大学信息科学与工程学院 沈阳 110819; 2. 中国矿业大学信息与控制工程学院 徐州 221116)

摘要:本文针对镁砂熔炼过程中的电流、声音和图像信息,提出了一种基于多源异构信息自适应加权融合的过程运行状态评价方法。首先,针对镁砂熔炼过程中的多源异构信息进行数据预处理,采用深度学习方法建立基于不同信息的运行状态评价子模型;其次,利用注意力机制建立各子模型决策层自适应融合网络,以综合分析不同熔炼状态下的多源异构信息对评价结果的影响;最后,将融合结果输入 SoftMax 分类器,建立镁砂熔炼过程运行状态评价模型。仿真结果显示,相比于仅依赖单一类型信息建立的评价模型以及现有的深度学习多源异构信息评价模型,本文所提方法综合考虑多源异构信息的共同作用,基于仿真平台数据与实际生产数据的评价准确率分别达 99.5% 与 98.44%, 优于其他被比较的方法,验证了所提方法的有效性和优越性。

关键词: 镁砂熔炼过程;多源异构信息;过程运行状态评价;评价子模型;注意力机制

中图分类号: TP13 TH17 **文献标识码:** A **国家标准学科分类代码:** 510.80

Process operating performance assessment for magnesium melting process based on adaptive fusion of multi-source heterogeneous information

Liu Yan¹, Xiong Yulu¹, Chu Fei², Wang Fuli¹

(1. College of Information Science & Engineering, Northeastern University, Shenyang 110819, China;

2. School of Information and Control Engineering, University of Mining and Technology, Xuzhou 221116, China)

Abstract: In this article, a new operating performance assessment method based on adaptive fusion of multi-source heterogeneous information (AFMSHI) is proposed for magnesium melting process. First, the data pre-processing is performed for the multi-source heterogeneous information (MSHI) in the process of magnesium melting, and deep learning methods are used to formulate performance assessment sub-models based on different types of information. Secondly, to fully consider the impacts of MSHI on the assessment results under different melting states, the attention mechanism is used to establish an adaptive fusion network for the assessment results of each sub-model. Finally, the fused assessment results are input into a SoftMax classifier, and the magnesium melting process assessment model is formulated. The simulation results show that, comparing with the assessment model established by a single type of information or the existing deep learning MSHI assessment methods, the assessment accuracy of AFMSHI based on simulation platform data and actual production data reached 99.5% and 98.44%, respectively, which is higher than the compared methods by comprehensively considering the roles of MSHI. The effectiveness and the superiority of the proposed method are verified.

Keywords: magnesium melting process; multi-source heterogeneous information; process operating performance assessment; assessment sub-models; attention mechanism

0 引言

镁砂是一种重要的耐火材料,被广泛用于航空航天、冶金、化工等行业^[1]。我国虽然是世界上镁矿资源雄厚的国家之一,但原材料通常存在矿石品位低、组成成分复

杂且变化较大等问题,因此通常采用敞口型三相电熔镁炉来生产高品质的镁砂。在镁砂熔炼过程中,通过调整三相电极的位置来改变电弧的长度,以控制电流的大小,从而控制整个生产过程的运行^[1-2]。然而熔炼现场环境复杂,受高温、高粉尘、高电磁干扰等影响,熔炼过程难以安全稳定的运行,这吸引了很多研究人员对其展开相关

研究,在建模^[3]、控制与优化^[4-5]、故障诊断^[6]、质量预测^[7]、异常工况识别^[8]及自愈控制^[9]等方面都取得了一定研究成果。为了获得更高质量的产品和更大的经济效益,针对镁砂熔炼过程运行状态的在线评价具有重要意义。

镁砂熔炼过程包含起炉、加料与熔炼等多个生产工序。通过调控三相电极位置,可使控制系统跟踪不同的电流设定值,精确操控整个过程。然而,复杂的现场环境使现有的控制手段难以确保高效的过程控制,容易导致半融化、过加热与排气异常等非优状态的产生。镁砂熔炼过程中可实时采集电弧电流、电弧声音以及炉体图像等多源异构信息,而非优的运行状态可通过这些多源异构信息反映。例如,半融化状态下电流值低于设定值,局部高温使炉壁薄处熔化出现局部亮斑。在过加热状态下,电流值高于设定值,熔浆液面快速上升,炉体表面亮度区域变化,且电弧声音异常尖锐。排气异常状态出现时,由于炉内气压过高造成高温溶液飞溅,此时的电流值剧烈变化且电弧声音沉闷。可见,镁砂熔炼过程运行状态的改变能够反映于不同种类信息,且每种非优状态所呈现的多源异构信息的特点也各有不同。仅分析电流数据的变化趋势,难以区分4种状态;仅分析电弧声音,可以区分出产生尖锐声音的过加热状态以及声音沉闷的排气异常状态,而其余状态难以区分;仅分析炉体图像信息,可以区分出炉体产生亮斑的半融化状态以及炉口火焰明亮且造成溶液飞溅的排气异常状态,而难以区分其余状态。因此,应充分利用多源异构信息,多角度、全方位实现镁砂熔炼过程运行状态的精准评价。

近年来,面向复杂工业生产过程的运行状态评价受到越来越多研究学者的关注。考虑到实际工业数据中蕴含大量反映综合经济指标的有用信息,Chang等^[10]提出了基于规范相关性分析的过程运行状态评价方法,提取过程变量与评价指标之间的最大相关性,建立了有效的评价策略。Zou等^[11]提出改进的基于动态因果图的评价模型,增强模型可解释性的同时建立了有效的运行状态评价策略。然而,上述方法适用于过程数据呈高斯分布的工业过程,具有一定的局限性。针对非高斯分布数据,Liu等^[12]结合高斯混合模型和高斯过程回归技术,实现非高斯多模态过程的运行状态评价,并提出非优原因追溯方法。此外,针对非线性过程,Chu等^[13]提出一种改进的全鲁棒核潜结构投影算法,有效解决过程变量间呈非线性相关的工业过程运行状态评价问题。上述方法在一些复杂工业过程中取得了较好的效果。但由于它们在建模时只进行一次特征提取,均属于浅层模型结构,对变量间复杂相关关系的表示能力有限且评价模型的泛化能力较差,面对不同运行状态下数据差异度小的情况,难以提取生产数据中的深层本质特征,影响评价结果的准确性。

深度学习是机器学习领域中一个重要分支,近年来受到研究学者的广泛关注。深度学习模型一般具有多隐层结构,用于学习输入信息的内在规律和表示层次,在特征提取过程中无须具备关于研究对象的特定先验知识。数据特征提取的目的是在降低维度和去除冗余信息的同时,利用深层特征最大程度地表示原始输入数据的本质特性。堆叠自编码器(stacked auto-encoder, SAE)及其衍生模型因具有较强的非线性处理能力和揭示高维数据低维结构的良好性能,常被用于数据的特征提取。Bu等^[14]提出了一种基于堆叠稀疏降噪自编码器的过程运行状态评价方法。Yuan等^[15]提出一种可变加权堆叠自编码器,用于逐层分层输出相关的特征表示,相比于传统方法具有更好的预测性能。研究学者早期提出了循环神经网络(recurrent neural networks, RNN)^[16],实现了神经网络学习时序信息前后特征的能力。门控循环单元(gate recurrent unit, GRU)的提出在简化模型结构的同时,解决了RNN的长期依赖性问题。Pan等^[17]提出了一种基于门控循环单元的高光谱微小模型,通过学习图像邻域空间信息来提高分类精度。Liu等^[18]利用双向门控循环单元和注意力机制来识别网络加密流量,进一步提高分类的准确性。图像信息通常具有高维度、高复杂度的特点,而卷积神经网络(convolutional neural networks, CNN)^[19]具有较强的特征学习能力,在降低图像维度的同时能够从复杂的图像中提取关键特征。褚洁等^[20]提出一种多阶通道响应对称双线性卷积神经网络来提高图像分类精度。Wang等^[21]提出一种具有渐进优化的级联CNN算法进行参数优化,提高了故障诊断的性能。对于在实际问题中产生的多源异构信息,Bu等^[22]提出了一种多源异构信息深度特征融合方法(multi-source heterogeneous information deep feature fusion, MSHIDFF),并采用带注意力机制的SoftMax回归来训练神经网络分类器,以匹配不同性能等级的融合深度特征,获得了较好的评估精度。

镁砂熔炼过程中产生的电流、电弧声音以及炉体图像等多源异构信息,能够从不同的角度反映熔炼过程的运行状态。而现有的深度学习方法为提取不同种类异构信息中的深层特征提供了重要的理论支撑。本文充分利用熔炼过程中的多源异构信息,提出一种新的面向镁砂熔炼过程的运行状态评价方法。首先,通过镁砂熔炼过程的半实物仿真平台获取不同运行状态下的多源异构信息,并根据每种异构信息的特点,采用合适的方法,对原始数据进行预处理。其次,利用不同的深层神经网络并结合SoftMax分类器,分别学习和提取每种异构信息的深层特征,构建基于每类信息的评价子模型。再次,基于各个评价子模型的评价结果,通过引入注意力机制,建立一种基于多源异构信息自适应融合(adaptive fusion of multi-

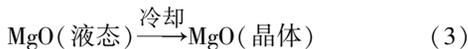
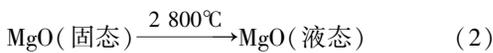
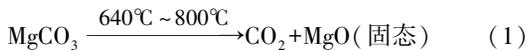
source heterogeneous information, AFMSHI) 的评价模型, 以综合考虑不同运行状态下多源异构信息对于评价结果的影响, 避免因为单一使用某类信息造成的评价结果片面且不准确的问题。最后, 基于镁砂熔炼过程设计对比实验, 验证所提方法的有效性和优越性。

本文的主要贡献包括: 1) 充分利用多源异构信息来综合且全面地评价熔炼过程的运行状态, 避免因为单一使用某类信息造成的评价结果片面且不准确的问题; 2) 引入注意力机制为基于每类异构信息获得的评价结果自动地赋予合适的权重, 自适应地衡量每类异构信息在描述不同运行状态时所起的作用, 提升评价模型的准确性和可靠性。

1 预备知识

1.1 镁砂熔炼过程及半实物仿真平台简介

镁砂熔炼过程是将菱镁矿石原料在三相交流电熔镁炉中通过电弧放电加热熔炼, 使原料在炉中经过熔融、结晶、晶体成长、冷却等一系列物理和化学过程后得到高纯度的镁砂。镁砂熔炼设备主要由供电系统、信号检测系统、电极位置控制系统 3 部分构成^[23]。其熔炼过程包含 3 个熔炼状态: 加热熔炼、加料和排气。现场操作人员通常根据经验为不同的熔炼状态设定不同的电流值。熔炼过程中, 控制系统通过控制电机的正反转来调节熔池表面与电极之间的距离, 使电极的电流值追踪系统电流设定值, 确保熔炼过程平稳运行。熔炼过程中的物理和化学反应过程如下:



菱镁矿石的主要成分为 MgCO_3 , 但也含有熔点较低的杂质如 CaO 、 Fe_2O_3 、 SiO_2 和 Al_2O_3 等。在镁砂熔炼过程中, 随着电弧放电加热, 熔点低的杂质成分先被融化, 且向外层析出。当温度达到 $640^\circ\text{C} \sim 800^\circ\text{C}$ 时, 菱镁矿石分解为 CO_2 气体和固态 MgO , 此时需要及时移动电极追踪电流设定值, 将气体排出以保持炉内外的气压平衡, 否则可能发生排气异常。继续加热, 当温度达到 $2\ 800^\circ\text{C}$ 时, 固态 MgO 熔化成液态, 且由于杂质熔点较低, 会首先熔化成液态, 并与固体分离析出。在上述的加热过程中极易产生半融化和过加热两种非优运行状态。当原料的熔点升高时, 若保持原始电流设定值不变, 部分原材料无法完全融化, 产生大量气体, 造成炉内气压过高, 且高温熔液与炉壁接触, 形成亮斑, 发生半熔化非优状态。当原料的熔点降低时, 保持原始设定值造成原材料快速融化,

熔池液面上升, 发生过加热非优状态。这些非优运行状态不仅会导致产品纯度下降, 还带来生产安全隐患, 严重影响企业的综合经济收益。

为了验证本文所提方法的有效性, 利用课题组搭建的镁砂熔炼过程半实物仿真平台获取仿真数据, 该仿真平台基于机理分析和实际数据模拟电熔镁炉的熔炼过程。平台中包括完成各种功能的计算机、嵌入式控制系统、数据库、传感设备及传输设备。传感设备包括电流检测装置、声音检测装置和图像检测装置。通过传输装置将信号传送到本地服务器中, 获得实验所需要的仿真数据^[24]。仿真平台如图 1 所示。

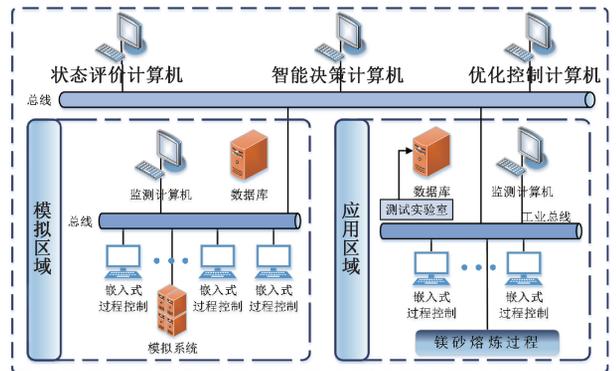


图 1 镁砂熔炼过程仿真平台

Fig. 1 Simulation platform of magnesite melting process

1.2 电流数据预处理

根据镁砂熔炼过程的工艺机理可知, 电流数据是反映熔炼过程运行状态的重要信息, 分析电流数据, 挖掘其不同运行状态下的本质特征, 将有助于精准评价熔炼过程的运行状态。为了提高神经网络挖掘电流数据深层特征的效率、同时去除冗余信息、降低噪声干扰, 需要对电流数据进行预处理。

通过镁砂熔炼过程的半实物仿真平台采集不同运行状态下的三相电极电流值及三相电极距离液面的距离信息。以一段时间内电流的均值、方差、三相电极到液面距离的均值及方差作为电流信息的预处理结果, 并以此建立基于电流的评价子模型。以 A 相电极电流数据预处理为例进行阐明。用 C_a^A 与 C_v^A 分别表示 A 相电极电流值的均值和方差, D_a^A 与 D_v^A 分别表示 A 相电极到液面距离的均值和方差, 则有: $C_a^A = \frac{1}{G} \sum_{g=1}^G C_g^A$, $C_v^A = \frac{1}{G} \sum_{g=1}^G (C_g^A - C_a^A)^2$, $D_a^A = \frac{1}{G} \sum_{g=1}^G D_g^A$, $D_v^A = \frac{1}{G} \sum_{g=1}^G (D_g^A - D_a^A)^2$, 其中, G 表示一段时间内包含的样本个数, C_g^A 为第 g 个样本, $g = 1, 2, \dots, G$ 。以上述同样的方式计算 B、C 相的电流变量值, 共获得 12 个电流变量, 如表 1 所示。

表 1 电流变量表
Table 1 Current variable

序号	参数描述	单位
1	A 相电极到液面距离均值	mm
2	B 相电极到液面距离均值	mm
3	C 相电极到液面距离均值	mm
4	A 相电极到液面距离方差	-
5	B 相电极到液面距离方差	-
6	C 相电极到液面距离方差	-
7	A 相电极电流值均值	A
8	B 相电极电流值均值	A
9	C 相电极电流值均值	A
10	A 相电极电流值方差	-
11	B 相电极电流值方差	-
12	C 相电极电流值方差	-

原始的 A 相电流值以及经过处理过后的 A 相电极电流均值的变化趋势如图 2 所示。从图 2 中可以看出,不同运行状态下的电流均值差异不大,且在一些采样点下,通过分析电流数据的浅层特征易混淆 4 种运行状态。因此,利用深度神经网络提取与电流数据相关的深层特征,将有助于更好地区分不同运行状态。

1.3 电弧声音预处理

熔炼过程中,若电弧发出极其尖锐刺耳的声音,预示着过程可能发生过加热;若电弧声音比较沉闷,表示可能发生排气异常。因此,电弧声音可以在一定程度上反映出熔炼过程的运行状态。由于电弧声音是一种模拟信号,声音的时域波形只代表声压随时间变化的关系,不能很好的代表声音的特征,因此,必须将声音波形转换为声学特征向量。由于人耳对不同频率的声波有不同的听觉敏感度,常利用梅尔频率倒谱系数(mel frequency cepstral coefficients, MFCC)来提取出与人类非线性的听觉系统

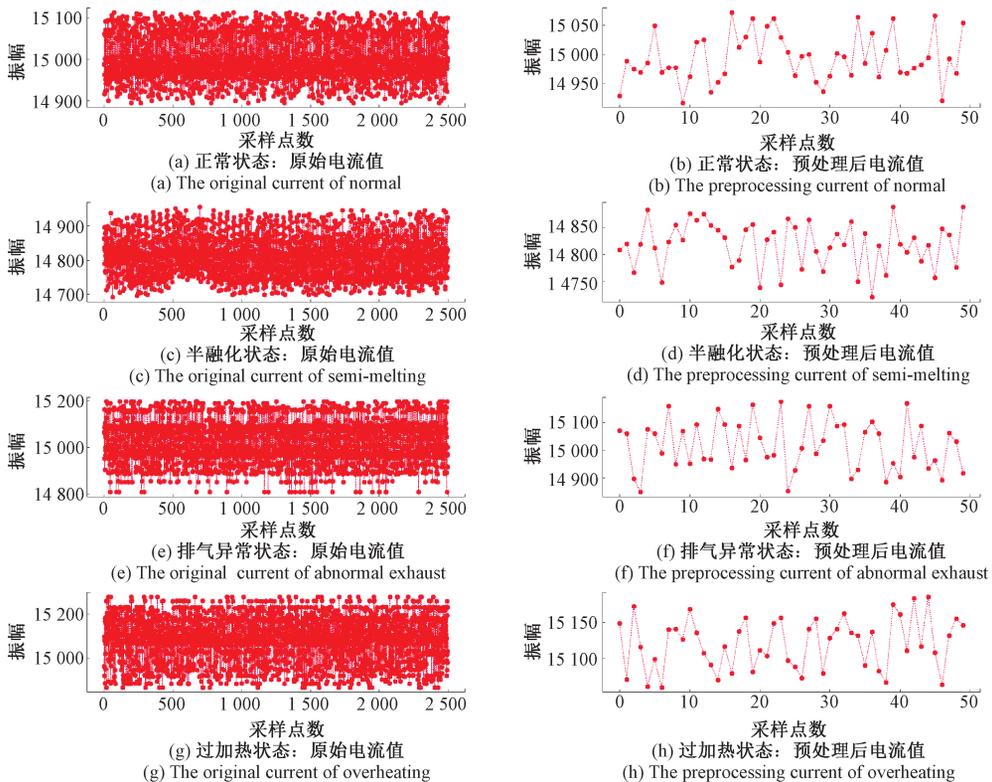


图 2 4 种运行状态下 A 相电极电流值预处理前后对比

Fig. 2 Comparison of A-phase electrode current values before and after preprocessing in four operating performances

更为接近的特征参数。MFCC 具有很好的鲁棒性,符合人耳的听觉特性,而且当信噪比降低时仍然具有较好的识别性能^[25]。本文采用 MFCC 来对电弧声音信号进行预处理。

MFCC 主要由预加重、分帧、加窗、快速傅里叶变换

(fast Fourier transform, FFT)、梅尔滤波器组、离散余弦变换(discrete cosine transform, DCT)等几部分组成,其中 FFT 与梅尔滤波器组是 MFCC 最重要的两个部分。一个完整的 MFCC 算法包括如下 4 个步骤^[26]:1)FFT;2)梅尔频率尺度转换;3)配置三角形滤波器组并计算每一个三角

形滤波器对信号幅度谱滤波后的输出;4)对所有滤波器的输出做对数运算,再进一步做DCT,即可得到MFCC。

图3中展示了声音的原始波形变化以及通过MFCC处理后得到的4种不同运行状态下电弧声音的梅尔语谱

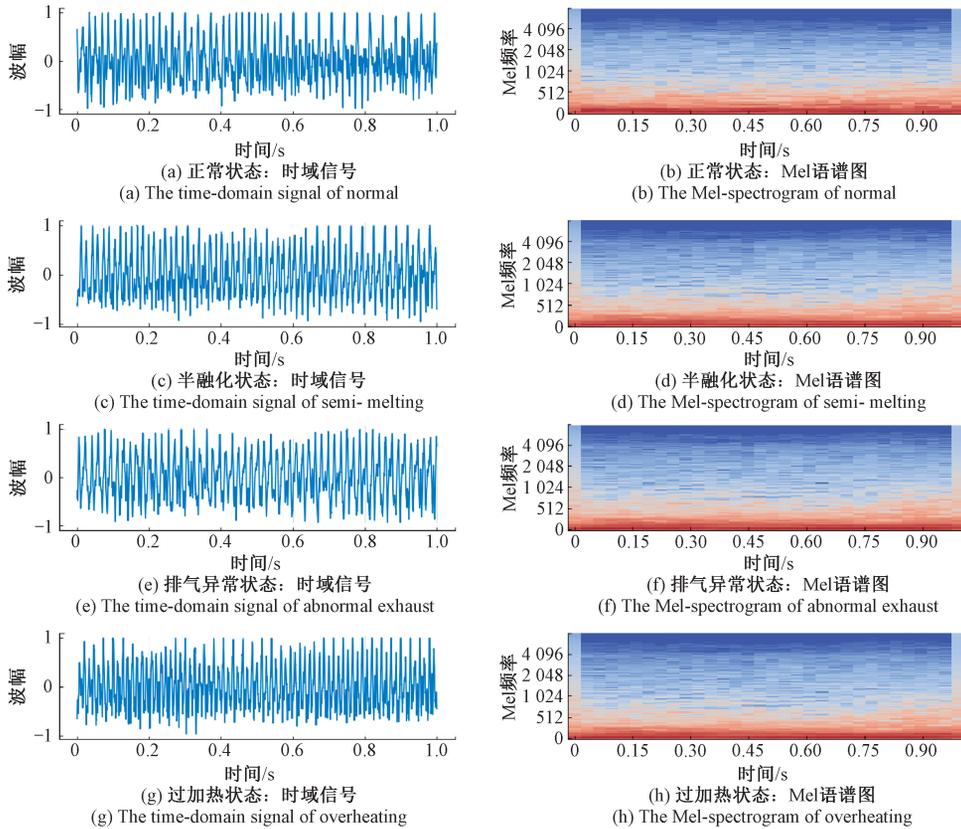


图3 4种运行状态下电弧声音的原始波形图及梅尔语谱图

Fig.3 Original waveform and Mel-spectrogram of arc sound in four operating performances

1.4 炉体图像预处理

图像信息具有维度高、复杂度高等特点,手动特征选择需要大量的专业知识,影响特征提取的准确性。在镁砂熔炼过程中,有经验的现场操作人员会根据炉体的图像信息来判断生产过程的运行状态,并做出相应的调整。炉体图像信息包括:炉体表面是否出现亮斑、炉体外是否存在飞溅的熔炼液体、炉口的火焰形态、明暗程度以及照亮周边的程度。为了过滤浓烟与周围雾气对分析炉口火焰形态的干扰,克服视频监控在高动态背景下的曝光异常问题,同时为了降低神经网络提取图片深层特征的负荷,本文对炉体图像进行全局阈值二值化预处理。原始炉体图像及经过预处理后的图像如图4所示。

从图4可以看出,预处理后的过加热状态的炉体图像与正常熔炼状态的炉体图像仍然非常相似。因此需要进一步利用深度神经网络来学习其深层次本质特征,以准确的评价生产过程的运行状态。

图。虽然预处理后的信息可以在一定程度上提高对声音特征表征能力,但仍然较难区分正常熔炼状态和半融化状态。因此,利用具有处理时序相关性数据的深度神经网络,将有助于更好地地区分不同运行状态。

2 基于各类异构信息的评价子模型

2.1 基于堆叠自编码器的电流评价子模型

SAE是由Bengio等^[27]在贪婪训练基础上首次提出的,它由多个基础自编码器(auto-encoder, AE)单元堆叠而成,其中AE是一个3层无监督神经网络,包含输入层、隐藏层和输出层。AE的基本原理是:首先通过编码过程(encoder)提取输入数据特征,再通过解码过程(decoder)利用隐藏层提取出的特征来重构输入,然后通过最小化重构数据与输入数据之间的均方误差损失函数优化网络参数,从而获得原始输入数据最优的特征表达。将电流数据记为 $\mathbf{x}^c = [x_1^c, x_2^c, \dots, x_j^c]^T \in \mathbb{R}^l$,设置隐藏层节点数为 M ,其编码过程如下:

$$\mathbf{h}^c = f(\mathbf{W}^c \mathbf{x}^c + \mathbf{b}^c) \quad (4)$$

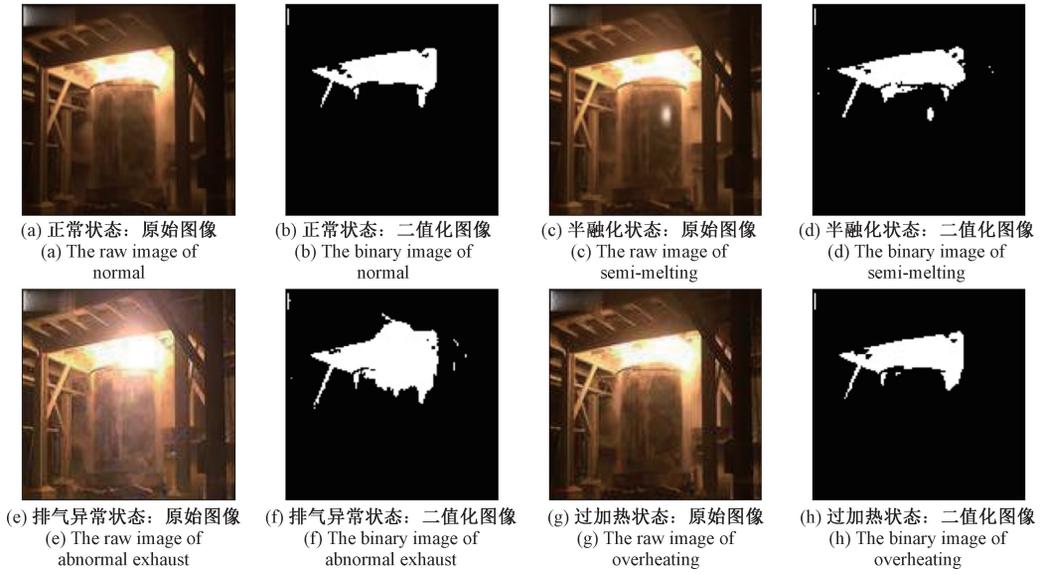


图 4 4 种运行状态下的原始炉体图像及二值化预处理

Fig. 4 Raw furnace images and binarized preprocessed images in four operating performances

其中, $\mathbf{W}^C \in \mathbb{R}^{M \times J}$ 和 $\mathbf{b}^C \in \mathbb{R}^{M \times 1}$ 分别为编码过程的权重矩阵与偏置向量, $f(\cdot)$ 为 sigmoid 激活函数。

隐藏层特征 $\mathbf{h}^C = [h_1^C, h_2^C, \dots, h_M^C]^T \in \mathbb{R}^M$ 通过解码过程对输入数据进行重构, 即:

$$\tilde{\mathbf{x}}^C = g(\tilde{\mathbf{W}}^C \mathbf{h}^C + \tilde{\mathbf{b}}^C) \quad (5)$$

其中, $g(\cdot)$ 为 sigmoid 激活函数, $\tilde{\mathbf{W}}^C \in \mathbb{R}^{J \times M}$ 和 $\tilde{\mathbf{b}}^C \in \mathbb{R}^{J \times 1}$ 分别为解码过程的权重矩阵与偏置向量, $\tilde{\mathbf{x}}^C = [\tilde{x}_1^C, \tilde{x}_2^C, \dots, \tilde{x}_J^C]^T \in \mathbb{R}^J$ 是原始数据的重构向量。

假设共有 N 个样本, 计算重构数据与输入数据间的重构误差, 通过最小化重构损失函数, 使重构输出近似等于原始输入, 即:

$$L_{AE} = \sum_{n=1}^N (\mathbf{x}_n^C - \tilde{\mathbf{x}}_n^C)^2 / 2N \quad (6)$$

其中, \mathbf{x}_n^C 为第 n 个样本, $\tilde{\mathbf{x}}_n^C$ 为 \mathbf{x}_n^C 的重构向量, $n = 1, 2, \dots, N$ 。利用反向传播算法更新网络参数。

SAE 是在预训练好的 AE 基础上, 将每一层 AE 的编码部分保存下来, 作为 SAE 的初始参数, 再对整个网络进行有监督的反向微调。结合 SoftMax 分类器即可搭建基于 SAE 的电流评价子模型。

将 SAE 的网络深度记为 L , 第 l 层 AE 的预训练过程如下:

$$AE - l(\text{编码}): \mathbf{h}_l^C = f(\mathbf{W}_l^C \mathbf{h}_{l-1}^C + \mathbf{b}_l^C) \quad (7)$$

$$AE - l(\text{解码}): \tilde{\mathbf{h}}_{l-1}^C = g(\tilde{\mathbf{W}}_l^C \mathbf{h}_l^C + \tilde{\mathbf{b}}_l^C) \quad (8)$$

其中, $l = 1, 2, \dots, L$, \mathbf{h}_l^C 是第 l 层 AE 训练得到的隐层特征向量, \mathbf{h}_{l-1}^C 是第 $l-1$ 层 AE 训练得到的隐层特征向量并作为 l 层 AE 的输入, $\tilde{\mathbf{h}}_{l-1}^C$ 为 \mathbf{h}_{l-1}^C 的重构输出。

利用式 (6) 对每一层 AE 进行优化, 采用反向传播算法对其参数进行更新。将每一层预训练好的隐层特征作为下一层的输入, 逐步完成全部 SAE 的训练过程。最后, 以最后一层隐含特征 $\mathbf{h}_{n,L}^C$ 做为输入, 利用 SoftMax 回归算法, 计算原始输入数据 \mathbf{x}_n^C 属于每种运行状态的后验概率 $\tilde{\mathbf{y}}_n^C = [\tilde{y}_{n,1}^C, \tilde{y}_{n,2}^C, \dots, \tilde{y}_{n,K}^C] \in \mathbb{R}^{1 \times K}$, 即:

$$\tilde{y}_{n,k}^C = g_{sm}(y_{n,k}^C = 1 | \mathbf{h}_{n,L}^C; \Theta_k^C) = \frac{\exp(\Theta_k^C \mathbf{h}_{n,L}^C)}{\sum_{k=1}^K \exp(\Theta_k^C \mathbf{h}_{n,L}^C)} \quad (9)$$

其中, K 为运行状态的种类数, $k = 1, 2, \dots, K$ 。 $\tilde{y}_{n,k}^C$ 表示第 n 个样本 \mathbf{x}_n^C 属于第 k 种运行状态的后验概率, $\mathbf{y}_n^C = [y_{n,1}^C, y_{n,2}^C, \dots, y_{n,K}^C]$ 为 \mathbf{x}_n^C 对应的真实运行状态标签, 采用 one-hot 编码。 $\mathbf{h}_{n,L}^C$ 为 \mathbf{x}_n^C 经 SAE 提取出的最后一层隐含特征, 且 $\sum_{k=1}^K g_{sm}(y_n^C = k | \mathbf{h}_n^C; \Theta_k^C) = 1$, $\Theta^C = \{\Theta_1^C, \Theta_2^C, \dots, \Theta_K^C\}$ 为 SoftMax 分类器的参数集。

进一步地, 建立基于 SAE 的电流评价子模型, 在对网络进行整体微调时使用交叉熵损失函数, 即:

$$L_{SAE-sm} = - \sum_{n=1}^N \mathbf{y}_n^C \log \tilde{\mathbf{y}}_n^C / N = - \sum_{n=1}^N \sum_{k=1}^K y_{n,k}^C \log \tilde{y}_{n,k}^C / N \quad (10)$$

通过最小化损失函数来优化更新网络参数。

2.2 基于门控循环单元的声音评价子模型

为了解决 RNN 中的梯度消失的问题, Hochreiter 等^[28] 提出了长短时记忆神经网络 (long short-term memory networks, LSTM), 通过 3 个门控单元实现了对长时序信号特征信息的记忆。但 LSTM 内部结构复杂, 需要花费大量的时间进行训练, 为了简化其内部结构同时

保留网络处理时序信息的能力,Cho等^[29]首次提出了门控循环单元(gate recurrent unit, GRU)框架。GRU将LSTM的遗忘门与输入门参数合并为更新门(update gate),用于控制上一时刻信息传递与当前时刻隐藏信息的计算,并利用重置门(reset gate)控制要遗忘多少过去的信息。GRU在减少网络参数、降低计算时间成本、防止欠拟合的同时与LSTM性能相当。

将经过MFCC处理后的第 n 个采样时刻的声音样本记为 $\mathbf{x}_n^S, \mathbf{h}_{n-1}^S$ 表示该样本在上一时刻的外部状态。以第 l 层的GRU为例,其更新门 $\mathbf{Z}_{n,l}$ 、重置门 $\mathbf{R}_{n,l}$ 以及候选单元状态 $\tilde{\mathbf{h}}_{n,l}^S$ 的表达式如下:

$$\mathbf{Z}_{n,l} = f(\mathbf{W}_l^{zx} \mathbf{x}_{n,l-1}^S + \mathbf{W}_l^{zh} \mathbf{h}_{n-1,l}^S + \mathbf{b}_l^z) \quad (11)$$

$$\mathbf{R}_{n,l} = f(\mathbf{W}_l^{rx} \mathbf{x}_{n,l-1}^S + \mathbf{W}_l^{rh} \mathbf{h}_{n-1,l}^S + \mathbf{b}_l^r) \quad (12)$$

$$\tilde{\mathbf{h}}_{n,l}^S = \tanh(\mathbf{W}_l^{hx} \mathbf{x}_{n,l-1}^S + \mathbf{W}_l^{hh} (\mathbf{R}_{n,l} \odot \mathbf{h}_{n-1,l}^S) + \mathbf{b}_l^h) \quad (13)$$

其中, $f(\cdot)$ 表示sigmoid激活函数, $\tanh(\cdot)$ 为双曲正切激活函数, $\mathbf{W}_l^x, \mathbf{W}_l^h$ 和 \mathbf{b}_l^z 分别表示更新门的权重矩阵和偏置向量, $\mathbf{W}_l^x, \mathbf{W}_l^h$ 和 \mathbf{b}_l^r 分别为重置门的权重矩阵及偏置向量, $\mathbf{W}_l^h, \mathbf{W}_l^h$ 和 \mathbf{b}_l^h 分别表示候选单元状态的权重矩阵和偏置向量, \odot 为向量元素点乘运算。

结合两个门控单元,GRU网络的更新方式如下:

$$\mathbf{h}_{n,l}^S = \mathbf{Z}_{n,l} \odot \mathbf{h}_{n-1,l}^S + (1 - \mathbf{Z}_{n,l}) \odot \tilde{\mathbf{h}}_{n,l}^S \quad (14)$$

利用GRU提取电弧声音的深层特征 $\mathbf{h}_{n,L}^S$ 后,采用SoftMax分类器计算声音样本 \mathbf{x}_n^S 属于每种运行状态的后验概率 $\tilde{\mathbf{y}}_n^S = [\tilde{y}_{n,1}^S, \tilde{y}_{n,2}^S, \dots, \tilde{y}_{n,K}^S] \in \mathbb{R}^{1 \times K}$,即:

$$\tilde{y}_{n,k}^S = g_{sm}(\mathbf{y}_{n,k}^S = 1 | \mathbf{h}_{n,L}^S; \Theta_k^S) = \frac{\exp(\Theta_k^S \mathbf{h}_{n,L}^S)}{\sum_{k=1}^K \exp(\Theta_k^S \mathbf{h}_{n,L}^S)} \quad (15)$$

其中, $\tilde{y}_{n,k}^S$ 表示 \mathbf{x}_n^S 属于第 k 种运行状态的后验概率,且 $\sum_{k=1}^K g_{sm}(\mathbf{y}_n^S = k | \mathbf{h}_{n,L}^S; \Theta_k^S) = 1, \Theta^S = \{\Theta_1^S, \Theta_2^S, \dots, \Theta_K^S\}$ 是声音特征SoftMax分类器的参数集, $\mathbf{y}_n^S = [y_{n,1}^S, y_{n,2}^S, \dots, y_{n,K}^S]$ 为 \mathbf{x}_n^S 的真实运行状态标签。

建立基于GRU的声音评价子模型,其损失函数为:

$$L_{GRU} = - \sum_{n=1}^N \mathbf{y}_n^S \log \tilde{\mathbf{y}}_n^S / N = - \sum_{n=1}^N \sum_{k=1}^K y_{n,k}^S \log \tilde{y}_{n,k}^S / N \quad (16)$$

2.3 基于卷积神经网络的图像评价子模型

CNN通过局部感测区域和共享权重解决了传统前馈网络参数过多的问题。其主要由卷积层、池化层和全连接层交叉堆叠构成,在图像处理领域有明显的优势^[30]。由于镁砂熔炼过程中的图像信息受周围环境的影响,常伴有强噪声干扰,传统方法很难对其进行精确有效的分析。因此,采用CNN来提取图像的深层特征对镁砂熔炼过程运行状态的精准评价十分重要。

卷积层类似于一个滑动窗口,在整个输入图像中按特定的步骤滑动,提取图像的局部特征。卷积层的特征图子区域在点积运算后通过激活函数运算,可得到对应的特征映射。将图像记为 $\mathbf{x}^l \in \mathbb{R}^{H \times H \times Q}, H \times H'$ 表示输入图像的大小, Q 为其输入深度。若输入为彩色图像,则有RGB 3个颜色通道的特征映射,即 $Q = 3$;若输入为灰度图像,则只有一个特征映射,此时 $Q = 1$ 。卷积层运算的数学表达式为:

$$\mathbf{F}_{p,l}^l = f\left(\sum_{q=1}^Q \mathbf{W}_{p,q,l}^l \otimes \tilde{\mathbf{F}}_{q,l-1}^l + \mathbf{b}_{p,l}^l\right) \quad (17)$$

其中,激活函数 $f(\cdot)$ 选用ReLU非线性激活函数, $\mathbf{F}_{p,l}^l$ 是第 l 层的第 p 个特征映射的输出, $\tilde{\mathbf{F}}_{q,l-1}^l$ 是第 $l-1$ 层的 q 个通道特征映射输出并作为第 l 层的输入, $\mathbf{W}_{p,q,l}^l$ 是第 l 层所有神经元的共享权重, $\mathbf{b}_{p,l}^l$ 为第 l 层卷积层的第 p 个偏置向量, \otimes 为卷积算子。

虽然卷积层可以显著减低网络中节点数量,但特征映射组中神经元的数量并没有显著降低,因此,引入池化层来解决这个问题,进一步降低特征维数,避免过拟合。本文采用最大池化操作,即选择这个区域内所有神经元的最大值作为这个区域的表示。此外,在每个池化层后增加一个比例为0.1的Dropout层,使网络对局部形态的改变保持不变性,拥有更大的感受野。

全连接层通常置于多个连续的卷积池化操作之后,整合经过多次卷积后高度抽象化的特征并将学到的“分布式特征表示”映射到样本标记空间。

最后,将CNN提取到的深层特征输入SoftMax分类器,计算图像样本 \mathbf{x}_n^l 属于每种运行状态的后验概率 $\tilde{\mathbf{y}}_n^l = [\tilde{y}_{n,1}^l, \tilde{y}_{n,2}^l, \dots, \tilde{y}_{n,K}^l]$,即:

$$\tilde{y}_{n,k}^l = g_{sm}(\mathbf{y}_{n,k}^l = 1 | \mathbf{h}_{n,L}^l; \Theta_k^l) = \frac{\exp(\Theta_k^l \mathbf{h}_{n,L}^l)}{\sum_{k=1}^K \exp(\Theta_k^l \mathbf{h}_{n,L}^l)} \quad (18)$$

其中, $\tilde{y}_{n,k}^l$ 表示 \mathbf{x}_n^l 属于第 k 种运行状态的后验概率,且 $\sum_{k=1}^K g_{sm}(\mathbf{y}_n^l = k | \mathbf{h}_{n,L}^l; \Theta_k^l) = 1, \Theta^l = \{\Theta_1^l, \Theta_2^l, \dots, \Theta_K^l\}$ 为图像特征SoftMax分类器的参数集, $\mathbf{y}_n^l = [y_{n,1}^l, y_{n,2}^l, \dots, y_{n,K}^l]$ 为 \mathbf{x}_n^l 的真实运行状态标签。

进一步地,建立基于CNN的图像评价子模型,最小化损失函数来优化更新网络参数。其损失函数为:

$$L_{CNN} = - \sum_{n=1}^N \mathbf{y}_n^l \log \tilde{\mathbf{y}}_n^l / N = - \sum_{n=1}^N \sum_{k=1}^K y_{n,k}^l \log \tilde{y}_{n,k}^l / N \quad (19)$$

3 基于AFMSHI的镁砂熔炼过程运行状态评价

通过分析电熔镁炉的生产工艺可知,熔炼过程中的电流、声音和图像能够从不同的角度反映过程的运行状

态,仅片面地分析其中某一种信息容易造成信息遗漏,难以对熔炼过程的运行状态进行全面和准确地评价。因此,如何高效利用镁砂熔炼过程中的多源异构信息,成为提升评价结果准确性和可靠性的关键。

在深度学习中,特征层融合是在特征提取层对不同模型的中间特征进行融合,随后输入到评价层。策层融合是对不同模型的评价结果进行融合,得出最终的评价结果。特征层融合包含更多的参数,模型复杂度高,训练难度更大且训练时间更长;决策层融合简单高效且模型独立,不仅能降低训练难度,在减少网络过拟合可能性的同时含有较少的网络参数^[31]。鉴于此,本文在深度学习的背景下,基于各个评价子模型的评价结果,引入注意力机制,提出一种基于 AFMSHI 的镁砂熔炼过程运行状态评价方法,以综合考虑不同熔炼状态下多源异构信息对于过程运行状态的影响。

3.1 基于 AFMSHI 的离线评价模型建立

注意力机制将有限的注意力集中在重点信息上,从而快速获得最有效的信息表达。在建立 AFMSHI 模型过程中,通过网络训练,自适应地衡量不同的运行状态下,每种异构信息在表征相应运行状态本质特征时所占的比例,实现对不同运行状态的精准描述,为获得准确的评价结果奠定基础。基于注意力机制的多源异构信息决策层自适应融合过程如图 5 所示。

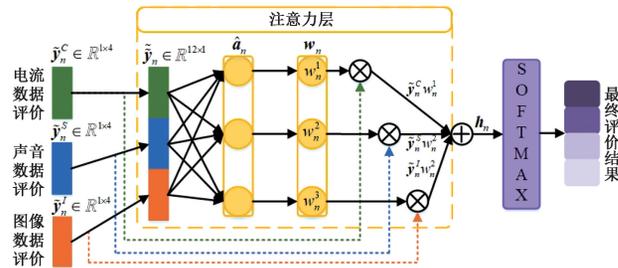


图 5 基于注意力机制的自适应融合模型

Fig. 5 Adaptive fusion model based on attention mechanism

首先,将基于 SAE、GRU 和 CNN 的评价子模型得到的各类信息属于每种运行状态的后验概率 $\tilde{y}_n^c, \tilde{y}_n^s$ 和 \tilde{y}_n^l 串行拼接得到 $\tilde{\mathbf{y}}_n = [(\tilde{y}_n^c)^T (\tilde{y}_n^s)^T (\tilde{y}_n^l)^T]^T \in \mathbb{R}^{12 \times 1}$ 。随后,将 $\tilde{\mathbf{y}}_n$ 送入注意力层,计算注意力权重,即:

$$\hat{\mathbf{a}}_n = \tanh(\hat{\mathbf{W}} \tilde{\mathbf{y}}_n + \hat{\mathbf{b}}) \quad (20)$$

其中, $\hat{\mathbf{a}}_n = [\hat{a}_n^1, \hat{a}_n^2, \hat{a}_n^3]^T$ 为注意力机制的隐藏层输出, $\hat{\mathbf{W}} \in \mathbb{R}^{3 \times 12}$ 与 $\hat{\mathbf{b}} \in \mathbb{R}^{3 \times 1}$ 分别为该层的权重矩阵与偏置向量。将权值 $\hat{\mathbf{a}}_n$ 送入 SoftMax 分类器进行归一化,得到自适应权重 $\mathbf{w}_n = [w_n^1, w_n^2, w_n^3]^T$:

$$w_n^e = \text{SoftMax}(\hat{a}_n^e) = \frac{\exp(\hat{a}_n^e)}{\sum_{e=1}^3 \exp(\hat{a}_n^e)} \quad (21)$$

其中, w_n^1, w_n^2, w_n^3 分别为 $\tilde{\mathbf{y}}_n^c, \tilde{\mathbf{y}}_n^s$ 和 $\tilde{\mathbf{y}}_n^l$ 的权重。加权后的综合特征为:

$$\mathbf{h}_n = w_n^1 \times \tilde{\mathbf{y}}_n^c + w_n^2 \times \tilde{\mathbf{y}}_n^s + w_n^3 \times \tilde{\mathbf{y}}_n^l \quad (22)$$

进一步地,将综合特征 \mathbf{h}_n 输入 SoftMax 分类器,得到其属于各个运行状态的后验概率为:

$$\tilde{y}_{n,k} = g_{sm}(y_{n,k} = 1 | \mathbf{h}_n; \Theta_k) = \frac{\exp(\Theta_k \mathbf{h}_n)}{\sum_{k=1}^K \exp(\Theta_k \mathbf{h}_n)} \quad (23)$$

其中, $\Theta = \{\Theta_1, \Theta_2, \dots, \Theta_K\}$ 为 AFMSHI 综合评价模型的 SoftMax 分类器的参数集。

基于 AFMSHI 运行状态评价模型的损失函数为:

$$L_{AFMSHI} = - \sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n / N = - \sum_{n=1}^N \sum_{k=1}^K y_{n,k} \log \tilde{y}_{n,k} / N \quad (24)$$

在此基础上,利用反向传播算法对 AFMSHI 的所有参数进行有监督的微调,优化网络参数,从而完成基于 AFMSHI 的过程运行状态评价模型的构建。

3.2 基于 AFMSHI 的运行状态在线评价

对于在线数据 $\mathbf{x}_{on} = [\mathbf{x}_{on}^c, \mathbf{x}_{on}^s, \mathbf{x}_{on}^l]$, 首先将预处理后的电流 \mathbf{x}_{on}^c 、声音 \mathbf{x}_{on}^s 以及图像 \mathbf{x}_{on}^l 分别输入到基于 SAE、GRU 和 CNN 的评价子模型,得属于不同运行状态的后验概率为:

$$\tilde{y}_{on,k}^c = g_{sm}(y_{on}^c = k | \mathbf{h}_{on,L^c}^c; \Theta^c), k = 1, 2, \dots, K \quad (25)$$

$$\tilde{y}_{on,k}^s = g_{sm}(y_{on}^s = k | \mathbf{h}_{on,L^s}^s; \Theta^s) \quad (26)$$

$$\tilde{y}_{on,k}^l = g_{sm}(y_{on}^l = k | \mathbf{h}_{on,L^l}^l; \Theta^l) \quad (27)$$

其中, $\mathbf{h}_{on,L^c}^c, \mathbf{h}_{on,L^s}^s$ 与 \mathbf{h}_{on,L^l}^l 分别是由 SAE、GRU 和 CNN 从 $\mathbf{x}_{on}^c, \mathbf{x}_{on}^s$ 与 \mathbf{x}_{on}^l 中提取的最深层特征, L^c, L^s 和 L^l 分别是评价子模型的网络层数。

随后,将 $\tilde{y}_{on,k}^c, \tilde{y}_{on,k}^s$ 和 $\tilde{y}_{on,k}^l$ 串联拼接得到的 $\tilde{\mathbf{y}}_{on} = [\tilde{y}_{on}^c, \tilde{y}_{on}^s, \tilde{y}_{on}^l]$ 输入到基于注意力机制的自适应融合模型,即按照式 (20) ~ (22) 计算,可得到加权后的综合特征 \mathbf{h}_{on} , 最后输入 SoftMax 分类器得到基于 AFMSHI 的综合评价结果,即:

$$\tilde{y}_{on,k} = g_{sm}(y_{on} = k | \mathbf{h}_{on}; \Theta_k) = \frac{\exp(\Theta_k \mathbf{h}_{on})}{\sum_{k=1}^K \exp(\Theta_k \mathbf{h}_{on})} \quad (28)$$

其中, $\tilde{\mathbf{y}}_{on} = [\tilde{y}_{on,1}, \tilde{y}_{on,2}, \dots, \tilde{y}_{on,K}]$ 为在线数据 \mathbf{x}_{on} 属于各种运行状态的后验概率,而最大后验概率对应的索引即为当前过程所处的运行状态,即:

$$\hat{k} = \text{argmax}\{k | \tilde{y}_{on,k}, k = 1, 2, \dots, K\} \quad (29)$$

3.3 离线建模及在线评价步骤

基于 AFMSHI 的镁砂熔炼过程运行状态离线建模及在线评价流程如图 6 所示,其包含离线建模及在线评价两个步骤,具体流程如下:

离线建模步骤:1) 数据采集:通过半实物仿真平台生成镁砂熔炼过程仿真数据,同时采集实际生产数据,获得

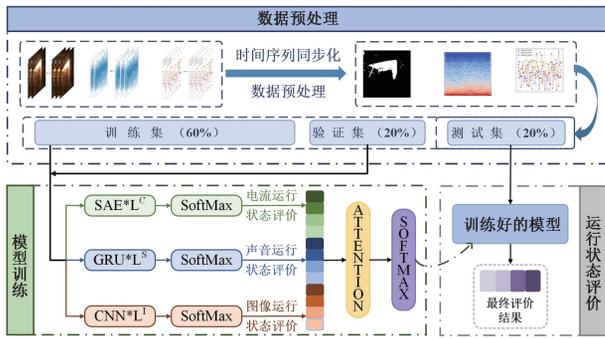


图6 基于 AFMSHI 的镁砂熔炼过程运行状态离线建模及在线评价流程

Fig. 6 The process of offline modeling and online assessment of magnesia smelting process based on AFMSHI

各个状态的多源异构信息。2) 数据预处理: 对采集数据进行预处理及时序对应, 随后按 3:1:1 随机划分训练集、验证集和测试集。3) AFMSHI 评价模型的训练: 将训练集与验证集输入 AFMSHI, 通过式 (24) 不断迭代优化, 实现 AFMSHI 的离线建模。

在线评价步骤: 1) 数据预处理: 根据物理过程和异构信息特征, 对在线数据进行预处理及时序对应; 2) 在线评价: 将预处理后的在线数据输入 AFMSHI 模型, 获得在线评价结果。

4 镁砂熔炼过程运行状态评价验证

4.1 基于半实物仿真平台数据的验证

1) 数据采集

根据镁砂熔炼过程的工艺特点, 本文主要考虑如下 4 种运行状态: 正常状态、半融化状态、排气异常状态和过加热状态, 并用 1、2、3、4 分别标记。由于实际生产过程中传感器的采样频率不同, 采集电流、声音以及图像的频率分别为 50、48 000 和 25 Hz。因此, 需要将采集到的数据进行时间序列同步化处理。对于电流数据, 用每分钟采集的 50 个样本计算表 1 变量构成一个电流样本; 一个表征声音样本的 MFCC 可由每分钟采集的 48 000 个声音数据计算得到; 一个图像样本可由每分钟采集的 25 张图像取均值得到, 然后再采用全局阈值二值化方法对每个图像样本进行预处理。

经过数据预处理后, 共得到 4 000 个样本, 其中属于每种运行状态的样本各有 1 000 个。将数据集中各个运行状态的样本按比例随机划分为 60%、20%、20%, 分别作为训练集、验证集和测试集。利用训练集搭建 AFMSHI 模型。利用验证集对不同超参数下的模型性能进行度量, 并选择在验证集上使误差最小的一组超参数, 作为网络训练的超参数。测试数据中, 运行状态依次经历 1、2、3、4, 且每种状态含 200 个样本。

2) 离线建模

表 2 中展示了 AFMSHI 评价模型的超参数设置情况。如表 2 所示, 离线建模时, 设置 SAE、GRU 和 CNN 的网络深度为: $L^c = 3, L^s = 4, L^l = 12$; $32@3 \times 3$ 是指一个卷积层中包含 32 个大小为 3×3 的卷积滤波器; 池化层中的参数 2×2 是指执行大小为 2×2 的最大池化操作, 融合网络反向微调时学习率为 0.001 2。

表 2 AFMSHI 模型参数-仿真平台数据

Table 2 Parameters of the AFMSHI-simulation platform data

网络名称	参数描述	参数
SAE	输入层节点数	12
	第 1 个隐层节点数	10
	第 2 个隐层节点数	8
	第 3 个隐层节点数	6
	输出层节点数	4
	预训练学习率	0.008 5
	微调学习率	0.001
GRU	输入层节点数	48 000
	第 1 个隐层节点数	1 200
	第 2 个隐层节点数	400
	第 3 个隐层节点数	20
	Dropout 层参数设置	0.1
	输出层节点数	4
CNN	学习率	0.000 1
	输入层节点数	128×128
	第 1 层卷积层参数	32@3×3
	第 1 层池化层参数	2×2
	第 1 层 Dropout 层参数设置	0.1
	第 2 层卷积层参数	64@3×3
	第 2 层池化层参数	2×2
	第 2 层 Dropout 层参数设置	0.1
	第 3 层卷积层参数	128@3×3
	第 3 层池化层参数	2×2
	第 3 层 Dropout 层参数设置	0.1
融合模型	第 1 层全连接层	1 024
	第 4 层 Dropout 层参数设置	0.2
	第 2 层全连接层	512
	输出层节点数	4
	学习率	0.001
注意力机制	注意力层输入	12
融合模型	注意力层输出	4

仿真实验环境如下:软件平台:PyCharm 2021.1.2, Python3.8.8;硬件平台:CPU: Intel i5-11300H (3.10 GHz)、RAM:16.0 GB。

将 2 400 个训练数据输入到 AFMSHI 模型中,通过计算 AFMSHI 的交叉熵损失函数,即式(24),优化更新网络参数,建立基于 AFMSHI 的镁砂熔炼过程运行状态评价模型。训练过程如图 7 所示。从中可以看出,经过 25 轮训练后,模型趋于稳定,模型在训练集和验证集上的精度都接近于 100%,损失接近于 0。

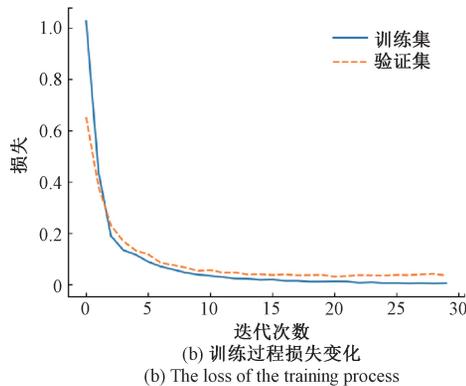
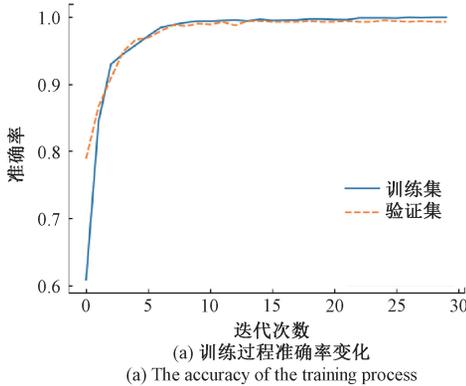


图 7 AFMSHI 的训练结果

Fig. 7 Comprehensive training results of AFMSHI

为了说明 AFMSHI 模型具有更强的特征提取能力,通过 t-SNE 对微调后的各个评价子模型及 AFMSHI 评价模型的最深层特征进行非线性降维可视化。降维后的可视化散点图如图 8 所示。可以看出,单独利用某一类信息建立评价子模型时,4 种不同运行状态下每类特征均没有实现完全分离,但将多源异构信息经自适应融合后,可以较好地地区分不同运行状态,说明同时利用多种信息可以更加准确地描述不同运行状态的本质特征,展现了更强的特征提取能力。

3) 在线评价

将在线数据输入到离线训练好的 AFMSHI 模型中,得到各时刻样本属于不同运行状态的后验概率,将概率最大值对应的运行状态作为评价结果,实现基于 AFMSHI 的镁砂熔炼过程运行状态在线评价。运行状态

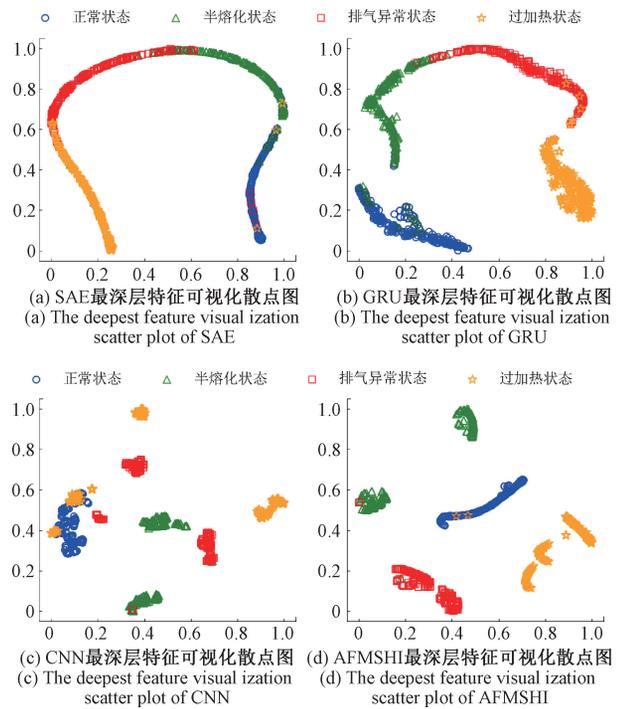


图 8 深层特征的 t-SNE 可视化结果

Fig. 8 The t-SNE visualization of deep features

在线评价结果如图 9 所示。图 9(f)为基于 AFMSHI 评价模型的在线评价结果,其评价准确率高达 99.50%,评价结果与实际情况相符,说明本文所提方法可以为熔炼过程的运行状态提供可靠的评价结果。

为了进一步说明本文所提方法的优越性,采用了其他两类方法进行仿真对比实验。第 1 类是仅利用由单一信息建立的模型,即基于 SAE 的电流评价子模型、基于 GRU 的声音评价子模型和基于 CNN 的图像评价子模型,它们的评价准确率分别为 91.25%、92.63%和 92%。第 2 类是利用多源异构信息所建的评价模型,其中一种是文献[22]中所用的基于多源异构信息深层特征融合的评价模型,该模型与本文方法的区别在于,它是一种特征层融合模型,其评价准确率为 99.12%。另一种是基于本文所提方法,消融注意力融合层,将各子模型决策层串行融合,随后将融合后的特征作为分类器的输入进行评价,将该模型简称为 FMSHI,其评价准确率为 98.75%。图 9(a)~(e)中分别展示了基于上述方法的在线评价结果。此外,为了确保实验的公平性,所有搭建的模型均在同一数据集下进行 10 次训练以及测试,并取 10 次的平均值作为最终的评价结果。各模型在训练过程中达到收敛的平均训练时间如表 3 所示。

通过图 9 和表 3(注:除 MSHIDFF 模型,其余评价模型训练时间均包含数据预处理的时间)可知,仅利用某单一某种信息对于镁砂熔炼过程进行评价存在诸多缺陷。虽然对于结构简单的信息,如电流和声音,评价模型的训练时间相对较少,但其评价的准确率低,说明

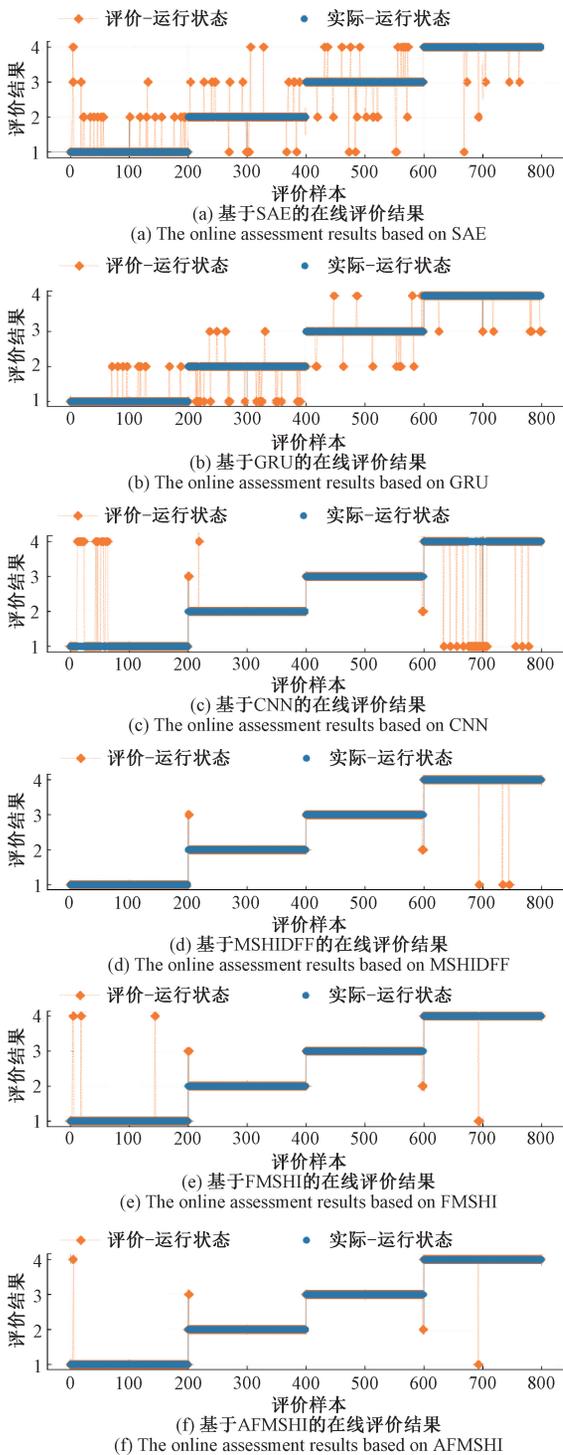


图9 基于仿真平台数据的各模型在线评价结果对比
Fig. 9 Comparison of online assessment results of each model based on simulation platform data

基于单一信息建立的评价模型并不能准确判断熔炼过程的真实运行状态。另外,由于模型的离线训练过程只需消耗一次资源成本,用相对较长但在实际生产可接受范围内的时间成本训练一个更为精准的评价模型是非常有必要的。

表3 各个模型训练时间

网络名称	耗时/s	网络名称	耗时/s
SAE	25.19	MSHIDFF	1 576.02
GRU	200.74	FMSHI	1 407.93
CNN	1 404.17	AFMSHI	1 429.40

对比 MSHIDFF、FMSHI 和 AFMSHI 可以看出,多源异构信息的综合利用有助于挖掘各个运行状态的数据特征,通过多种信息之间的相互补充,可以有效降低片面分析带来的不良影响,有助于提高评价结果的准确率。虽然 MSHIDFF、FMSHI 和 AFMSHI 均获得较高的评价准确率,但引入注意力机制的 MSHIDFF 和 AFMSHI 的评价准确率仍高于不含注意力机制的 FMSHI,这是因为注意力机制可以将有限的计算资源用来处理更重要的信息,通过赋予关键信息更高的权重,抑制其他无用的信息,从而提高评价准确率。而本文所提的 AFMSHI 与 MSHIDFF 的区别体现在 3 个方面: 1) AFMSHI 在建模之前对多源异构信息进行预处理,在去除原始异构信息中噪声数据的同时降低数据维度,不仅减小网络训练的压力还使得神经网络能够从中更有效识别并提取多源异构信息的深层特征; 2) MSHIDFF 中采用双向 LSTM 处理声音数据,而 AFMSHI 使用了结构更为简单的 GRU,可以在更短的训练时间内达到同样效果; 3) 相比于 MSHIDFF 中的特征层融合(参数量:538),AFMSHI 在决策层融合(参数量:12)多源异构信息,使得融合网络具有更少的训练参数和更高的实时性,且其抗干扰能力与纠错能力很强,可消除单个评价子模型造成的决策误差,获得更精确的评价结果,因此针对镁砂熔炼过程,采用决策层融合更为合适。

为了说明模型中引入注意力机制的必要性,提取注意力机制模块中每种异构信息在不同运行状态下的注意力权重,如图 10 所示。前 400 个样本分别是正常状态和半融化状态,由于半融化状态下,炉体呈现的亮斑与其他状态有明显区别,因此网络自动为图像信息分配了更高的权重。第 401~600 个样本对应于排气异常状态,此时电流发生剧烈波动,电弧声音沉闷,且电熔镁炉的炉口呈现明亮的火焰,说明该状态的特性可从电流、声音与图像三方信息中体现出来,因此网络为 3 种信息赋予了相当的权重。第 601~800 个样本属于过加热状态,该状态亦可由电流、声音和图像信息共同呈现,但由于此时电流数据易与其它状态混淆,因此电流的权重较低,而图像与声音的权重相当。通过上述仿真分析可知,3 种异构信息在描述不同运行状态的本

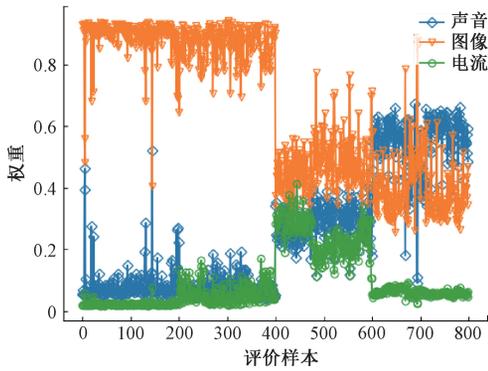


图 10 仿真平台中多源异构信息的注意力权重

Fig. 10 Attention weights of MSHI based on simulation

表 4 基于仿真平台数据的各个评价方法的准确率、精确率、召回率和 F1 分数

Table 4 Accuracy, precision, recall and F1 score for various assessment methods based on simulation platform data %

评价方法	评价指标	运行状态 1	运行状态 2	运行状态 3	运行状态 4	平均值
SAE, 准确率:91.25%	精确率	94.21	86.60	90.77	93.69	91.32
	召回率	89.50	90.50	88.50	96.50	91.25
	F1 分数	91.79	88.51	89.62	95.07	91.25
GRU, 准确率:92.63%	精确率	89.15	89.64	94.42	97.47	92.67
	召回率	94.50	86.50	93.00	96.50	92.63
	F1 分数	91.75	88.04	93.70	96.98	92.62
CNN, 准确率:92.00%	精确率	83.41	98.99	99.00	86.84	92.06
	召回率	88.00	98.50	99.00	82.50	92.00
	F1 分数	85.64	98.75	99.00	84.62	92.00
MSHIDFF ^[22] , 准确率:99.12%	精确率	98.52	99.00	99.00	100	99.13
	召回率	100	99.00	99.00	98.50	99.12
	F1 分数	99.26	99.00	99.00	99.24	99.12
FMSHI, 准确率:98.75%	精确率	98.99	99.00	99.00	98.02	98.75
	召回率	98.00	99.00	99.00	99.00	98.75
	F1 分数	98.49	99.00	99.00	98.51	98.75
AFMSHI, 准确率:99.50%	精确率	99.50	99.50	99.00	99.50	99.50
	召回率	99.50	99.50	99.00	100	99.50
	F1 分数	99.75	99.25	99.25	99.75	99.50

在镁砂熔炼过程中产生的多源异构信息不是单一存在的,它们具有一定的互补性,因此在评价时,不应忽略任何信息对熔炼过程评价结果的影响,否则难以准确地描述不同运行状态的本质特征,影响评价结果的准确性和可靠性。应该利用深度学习充分挖掘多源异构信息中的深层特征,并引入注意力机制以增强模型对特征的代表能力,提高过程运行状态评价的准确性。

质特征时,所起的作用不尽相同,自适应地为不同信息赋予不同的权重可以有效提高评价模型的特征表示和提取能力,避免因为单一使用某类信息造成的评价结果片面且不准确的问题,为获得准确的评价结果奠定基础。

除准确率外,本文还采用精确率、召回率、F1 分数等广泛用于分类领域的评价指标对上述评价方法进行对比,并汇总于表 4 中。

由表 4 的对比结果可知,利用镁砂熔炼过程中的单一信息进行评价,难以全面准确的评价熔炼过程,且导致某些状态的误评价。基于 AFMSHI 的评价模型能够更准确实现镁砂熔炼过程的运行状态评价。这是因为

4.2 基于实际生产数据的验证

1) 数据采集

针对实际镁砂熔炼过程,本文进一步采用辽宁某镁砂熔炼厂的实际生产数据验证所提方法的有效性。结合专家知识及现场传感设备的采样频率,从历史生产数据库中采集正常状态(1)、半融化状态(2)、排气异常状态(3)和过加热状态(4)各 800 个数据。

将数据集中各个运行状态的样本按比例随机划分为 60%、20%、20%,分别作为训练集、验证集和测试集。测

试数据中,每种状态含 160 个样本。

2) 离线建模

基于实际生产数据建立的网络结构与模型参数如表 5 所示,其中 SAE 网络的学习率为微调时的学习率。

表 5 AFMSHI 模型参数-实际生产数据

Table 5 Parameters of the AFMSHI-actual production data

网络名称	参数描述	学习率	网络名称	参数描述	学习率
SAE	$L_r^C = 3$	0.001 5	CNN	$L_r^I = 12$	0.001
GRU	$L_r^S = 4$	0.000 2	融合网络	$L_r^{AM} = 2$	0.001

3) 在线评价

将实际过程数据中的测试数据输入到离线训练好的 AFMSHI 模型中。由图 11 可知,针对实际生产过程数据,AFMSHI 对于多源异构信息在不同运行状态下的注意力权重分配与仿真平台数据得到的权重分配大致相当,验证了所提模型的有效性。

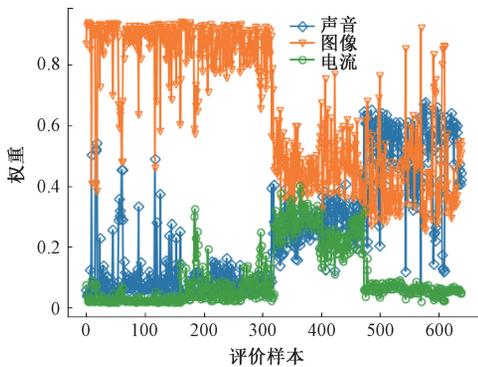


图 11 实际生产中多源异构信息的注意力权重

Fig. 11 Attention weights of MSHI based on actual production

此外,基于实际生产数据的各个评价模型的准确率以及在线评价结果,分别如表 6 及图 12 所示。

表 6 基于实际生产数据的各个评价方法的准确率

Table 6 Accuracy for various assessment methods based on actual production data

名称	SAE	GRU	CNN	MSHIDFF ^[22]	FMSHI	AFMSHI
准确率	80.50	83.25	85.47	96.88	95.47	98.44

针对实际镁砂熔炼数据,由各个评价模型的评价准确率及在线评价结果对比可知,本文提出的 AFMSHI 模型能有效提高镁砂熔炼过程的评价准确率,同时验证了利用多源异构信息能更准确的对镁砂

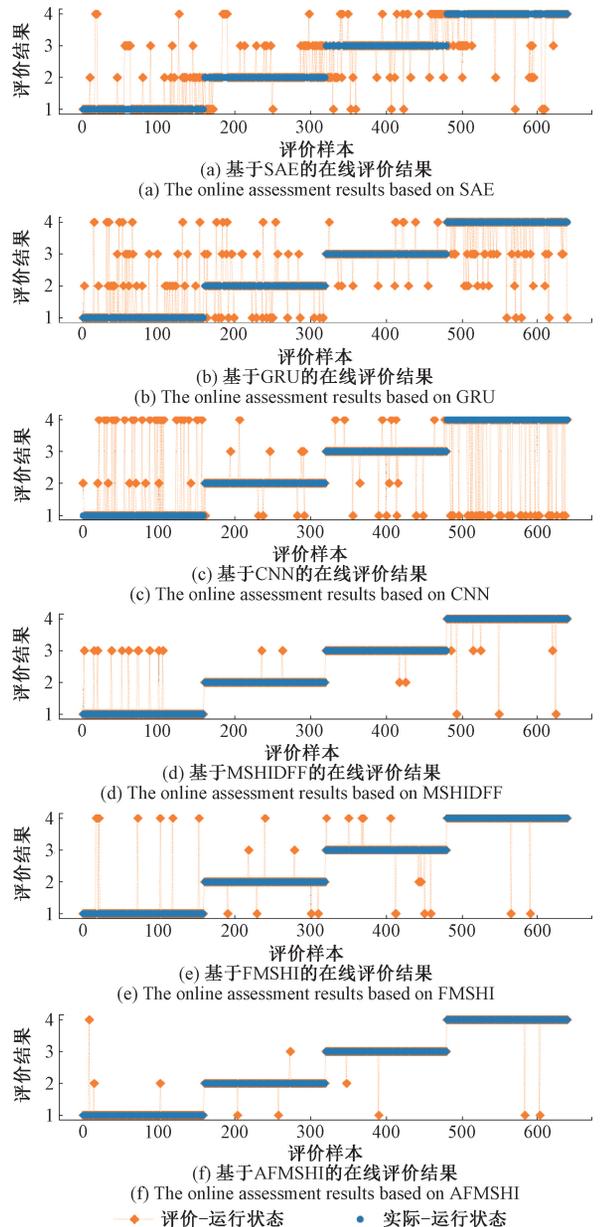


图 12 基于实际生产数据的各模型在线评价结果对比

Fig. 12 Comparison of online assessment results of each model based on actual production data

熔炼过程做出评价,为系统的控制或操作人员实时调整提供依据。

5 结 论

针对镁砂熔炼过程的工艺特点,本文提出了一种基于 AFMSHI 的镁砂熔炼过程运行状态评价方法。采用合适的的数据预处理手段对熔炼过程中产生的多源异构信息进行预处理,以去除原始数据中的噪声和冗余

信息,并作为深度学习模型的输入。通过SAE、GRU、CNN对各类信息进行深层特征提取,建立基于各类信息的评价子模型,并利用注意力机制对各个子模型的评价结果加权融合,以综合考虑不同种类信息对评价结果的影响,从而建立镁砂熔炼过程运行状态评价模型。实验对比结果表明,相比于仅依赖单一信息的SAE、GRU、CNN评价模型以及考虑多源异构信息的MSHIDFF和FMSHI评价模型,本文提出的AFMSHI评价方法的准确率最高,且比MSHIDFF和FMSHI模型训练时间更短,说明了本文所提方法在镁砂熔炼过程中的有效性和优势。

参考文献

- [1] 李鸿儒,王奕文,邓靖川. 基于信息融合的电熔镁炉熔炼异常工况等级识别[J]. 东北大学学报:自然科学版, 2020, 41(2): 153-157.
- LI H R, WANG Y W, DENG J CH. Information fusion based abnormal condition levels recognition of smelting in fused magnesium furnace [J]. Journal of Northeastern University Natural Science, 2020, 41(2): 153-157.
- [2] BU K Q, LIU Y, WANG F L. Process operation performance assessment based on multisource heterogeneous information with semisupervised transfer generative adversarial network for electrofused magnesium furnace[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 6785-6793.
- [3] 吴志伟,柴天佑,吴永建. 电熔镁砂产品单吨能耗混合预报模型[J]. 自动化学报, 2013, 39(12): 2002-2011.
- WU ZH W, CHAI T Y, WU Y J. A hybrid prediction model of energy consumption per ton for fused magnesia[J]. Acta Automatica Sinica, 2013, 39(12): 2002-2011.
- [4] 吴志伟,方正,柴天佑,等. 电熔镁炉嵌入式专用控制器及其控制方法研究[J]. 仪器仪表学报, 2012, 33(6): 1261-1267.
- WU ZH W, FANG ZH, CHAI T Y, et al. Research on special embedded controller and its control method for fused magnesium furnace [J]. Chinese Journal of Scientific Instrument, 2012, 33(6): 1261-1267.
- [5] WU Z W, LIU T F, JIANG Z P, et al. Nonlinear control tools for fused magnesium furnaces: Design and implementation [J]. IEEE Transactions on Industrial Electronics, 2018, 65(9): 7248-7257.
- [6] DU W Y, ZHOU W. An intelligent fault diagnosis architecture for electrical fused magnesia furnace using sound spectrum submanifold analysis [J]. IEEE Transactions on Instrumentation & Measurement, 2018, 67(9): 2014-2023.
- [7] LI M Y, ZHANG J W, CHAI T Y. Deep learning assisted online multi-step demand forecasting of fused magnesia smelting processes[C]. Proceedings of the 4th International Conference on Industrial Artificial Intelligence (IAI) in Shenyang of China, 2022: 1-8.
- [8] YUAN P, SUN Y F, LI H. Abnormal condition identification modeling method based on Bayesian network parameters transfer learning for the electro-fused magnesia smelting process [J]. IEEE Access, 2019, 7: 149764-149775.
- [9] 李荟,王福利,李鸿儒. 电熔镁炉熔炼过程异常工况识别及自愈控制方法[J]. 自动化学报, 2020, 46(7): 1411-1419.
- LI H, WANG F L, LI H R. Abnormal condition identification and self-healing control scheme for the electro-fused magnesia smelting process [J]. Acta Automatica Sinica, 2020, 46(7): 1411-1419.
- [10] CHANG Y Q, NIU D P, ZOU X Y. Canonical correlation analysis based process operating performance assessment and its application to a gold hydrometallurgy process [C]. Proceedings of the Chinese Automation Congress (CAC) in Jinan of China, 2017: 1584-1587.
- [11] ZOU X Y, WANG F L, CHANG Y Q, et al. Process operating performance optimality assessment and non-optimal cause identification under uncertainties [J]. Chemical Engineering Research and Design, 2017, 120: 348-359.
- [12] LIU Y, WANG F L, CHANG Y Q, et al. Operating optimality assessment and nonoptimal cause identification for non-Gaussian multimode processes with transitions[J]. Chemical Engineering Science, 2015, 137: 106-118.
- [13] CHU F, DAI W, SHEN J, et al. Online complex nonlinear industrial process operating optimality assessment using modified robust total kernel partial M-regression[J]. Chinese Journal of Chemical Engineering,

- 2018, 26(4): 775-785.
- [14] BU K Q, WANG F L, LIU Y. Operating performance assessment based on stacked sparse denoising auto-encoder for gold hydrometallurgy processes [C]. Proceedings of the 39th Chinese Control Conference, 2020: 2904-2909.
- [15] YUAN X F, HUANG B, WANG Y L, et al. Deep learning-based feature representation and its application for soft sensor modeling with variable-wise weighted SAE[J]. IEEE Transactions on Industrial Informatics, 2018, 14(7): 3235-3243.
- [16] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization [J]. Proceedings of International Conference on Learning Representations 2015: 1-8.
- [17] PAN E T, MEI X G, WANG Q D, et al. Spectral-spatial classification for hyperspectral image based on a single GRU[J]. Neurocomputing, 2020, 387: 150-160.
- [18] LIU X, YOU J L, WU Y L, et al. Attention-based bidirectional GRU networks for efficient HTTPS traffic classification [J]. Information Sciences, 2020, 541: 297-315.
- [19] BOUVRIE J. Notes on convolutional neural networks[J]. Computer Science, 2006, 22(November): 5869.
- [20] 褚洁, 蔡觉平, 李龙, 等. 基于多阶通道响应对称双线性卷积神经网络的分布式压力识别[J]. 仪器仪表学报, 2022, 43(6): 92-100.
- CHU J, CAI J P, LI L, et al. Hybrid-order channel response symmetric bilinear convolutional neural network for distributed pressure recognition[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 92-100.
- [21] WANG F, LIU R N, HU Q H, et al. Cascade convolutional neural network with progressive optimization for motor fault diagnosis under nonstationary conditions [J]. IEEE Transactions on Industrial Informatics, 2021, 17(4): 2511-2521.
- [22] BU K Q, LIU Y, WANG F L. Operating performance assessment based on multi-source heterogeneous information with deep learning for smelting process of electro-fused magnesium furnace[J]. ISA Transactions, 2022, 128: 357-371.
- [23] BU K Q, LIU Y, WANG F L. Process operation performance assessment based on semi-supervised fine-grained generative adversarial network for EFMF [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-9.
- [24] 闫浩, 王福利, 孙钰洋, 等. 基于贝叶斯网络参数迁移学习的电熔镁炉异常工况识别[J]. 自动化学报, 2021, 47(1): 197-208.
- YAN H, WANG F L, SUN Y F, et al. Abnormal condition identification based on bayesian network parameter transferlearning for the electro-fused magnesia [J]. Acta Automatica Sinica, 2021, 47(1): 197-208.
- [25] JIN S P, WANG X F, DU L L, et al. Evaluation and modeling of automotive transmission whine noise quality based on MFCC and CNN[J]. Applied Acoustics, 2021, 172.
- [26] AZIM N M, SARATH R. Combined classification models for bearing fault diagnosis with improved ICA and MFCC feature set [J]. Advances in Engineering Software, 2022, 173.
- [27] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks [J]. Advances in Neural Information Processing Systems, 2007 (1): 153-160.
- [28] HOCHREITER S, SCHNIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [29] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. Computer Science, 2014: 1724-1734.
- [30] 周露珊, 赵磊, 李恒, 等. 基于轻量级密集残差网络的水下图像增强[J]. 电子测量与仪器学报, 2023, 37(1): 70-77.
- ZHOU L SH, ZHAO L, LI H, et al. Underwater image enhancement based on lightweight dense residual network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 70-77.
- [31] WEI Z Q, ZHANG F K, CHANG S, et al. MmWave

radar and vision fusion for object detection in autonomous driving: A review[J]. *Sensors*, 2022; 22(7):2542.

作者简介



刘炎 (通信作者), 2016年于东北大学获得博士学位, 现为东北大学副教授, 博士研究生导师, 主要研究方向为复杂工业过程运行状态评价、过程监测等。

E-mail: liuyan@ise.neu.edu.cn

Liu Yan (Corresponding author) received her Ph. D. degree from Northeastern University in 2016. She is currently an associate professor and a Ph. D. advisor at Northeastern University. Her main research interests include process operating performance assessment, process monitoring, etc.



熊雨露, 2021年于青岛理工大学获得学士学位, 现为东北大学硕士研究生, 主要研究方向为深度学习、复杂工业过程运行状态评价等。

E-mail: 2170833@stu.neu.edu.cn

Xiong Yulu received her B. Sc. degree from Qingdao University of Technology in 2021. She is currently a master student at Northeastern University. Her main research interests include deep learning, process operating performance assessment, etc.



褚菲, 2014年于东北大学获得博士学位, 现为中国矿业大学教授, 博士研究生导师, 主要研究方向为复杂工业过程建模、控制与优化、机器学习及运行状态评价等。

E-mail: chufeizhufei@sina.com

Chu Fei received his Ph. D. degree from Northeastern University in 2014. He is currently a professor and a Ph. D. advisor at China University of Mining and Technology. His main research interest include modeling, control and optimization of complex industrial process, statistical process monitoring and operating performance assessment, etc.



王福利, 1988年于东北大学获得博士学位, 现为东北大学教授, 博士研究生导师, 主要研究方向为复杂工业系统的建模、控制与优化, 过程监测和故障诊断等。

E-mail: wangfuli@ise.neu.edu.cn

Wang Fuli received his Ph. D. degree from Northeastern University in 1988. He is currently a professor and a Ph. D. advisor at Northeastern University. His main research interest covers modeling, control and optimization of complex industrial process, process monitoring and fault diagnosis, etc.