

doi:10.3969/j.issn.1007-7545.2022.04.003

基于图像识别的铜转炉吹炼 造渣期渣含 Fe 预测模型研究

张冉¹, 李明周¹, 钟立桦², 童长仁¹, 何发友³, 黄金堤¹

(1. 江西理工大学 材料冶金化学学部, 江西 赣州 341000;

2. 赤峰金通铜业有限公司, 内蒙古 赤峰 024000;

3. 紫金铜业有限公司, 福建 上杭 361024)

摘要:铜转炉吹炼是火法炼铜的关键工序,其终点判断与炉寿、铜产率和直收率紧密相关,目前现有人工经验、仪器测定和物料平衡法等终点判断方法均存在一定的局限性。理论上铜转炉吹炼造渣期终点与渣含 Fe 是否达标有关,而不同 Fe 含量渣样呈现不同的图像特征,鉴于此,基于图形识别的特征向量提取原理,分别采用卷积神经网络(CNN)算法与支持向量机(SVM)算法,构建了铜转炉吹炼造渣期渣含 Fe 预测模型,为图像识别技术在铜转炉吹炼终点判断中的应用奠定数模基础。两种模型的实例分析表明,卷积神经网络的训练集预测准确率 98%,测试集预测准确率约 50%;支持向量机模型的训练集预测准确率 99%,测试集预测准确率 62%。

关键词:铜转炉吹炼;图像识别;卷积神经网络;支持向量机;终点判断

中图分类号:TF811

文献标志码:A

文章编号:1007-7545(2022)04-0021-10

Research on Prediction Model of Fe Content in Slag during Copper Converter Slag-Making Period Based on Image Recognition

ZHANG Ran¹, LI Ming-zhou¹, ZHONG Li-hua²,TONG Chang-ren¹, HE Fa-you³, HUANG Jin-di¹(1. Faculty of Materials Metallurgy and Chemistry, Jiangxi University of Science and
Technology, Ganzhou 341000, Jiangxi, China;

2. Chifeng Jintong Copper Industry Co., Ltd., Chifeng 024000, Inner Mongolia, China;

3. Zijin Copper Industry Co., Ltd., Shanghang 361024, Fujian, China)

Abstract: Copper converter blowing is the key process of pyrometallurgical copper smelting. Its end point judgment is closely related to furnace life, copper yield and direct yield. At present, the existing end point judgment methods such as manual experience, instrument measurement and material balance method have some limitations. Theoretically, the end point of copper converter slag blowing period is related to whether Fe content in the slag meets the standard, and the slag samples with different Fe content show different image features. In view of this, based on feature vector extraction principle of graphic recognition, the prediction model of Fe content in copper converter slag during slag blowing period is constructed by using convolution neural network (CNN) algorithm and support vector machine (SVM) algorithm respectively,

收稿日期:2021-11-14

基金项目:中国博士后科学基金项目(2019M662268);江西省博士后择优资助项目(2018KY15)

作者简介:张冉(1996-),女,硕士研究生;通信作者:李明周(1980-),男,博士,副教授

It lays a digital and analog foundation for application of image recognition technology in judgment of blowing end point of copper converter. The instance analysis of two models shows that the prediction accuracy of training set of convolutional neural network is 98%, and the prediction accuracy of test set is about 50%; the prediction accuracy of training set of support vector machine model is 99%, and the prediction accuracy of test set is 62%.

Key words: copper converter blowing; image recognition; convolutional neural network; support vector machine; end point judgment

铜转炉吹炼是火法炼铜的关键工序,目前近 50% 粗铜由 P-S 卧式转炉生产。铜转炉吹炼是周期性作业方式,包括造渣期和造铜期。造渣期欠吹,不仅会延长造铜期时间,还会降低粗铜质量和收率;造渣期过吹,会导致炉渣变黏、排渣困难、炉温升高、炉寿降低,同时会产生大量 SO_2 烟气,发生喷炉概率加大。因此,铜转炉吹炼造渣期终点判断的准确性,对铜转炉吹炼全过程至关重要。

目前,铜转炉吹炼周期性作业终点判断的方法主要有经验法^[1]、仪器测定法^[2]、物料平衡法^[3-4]等,这些方法大多存在判断准确性、滞后性、环境局限性和建模复杂性等不足之处。随着信息化智能化技术的发展,机器视觉^[5]、图像识别^[6]、智能算法等技术手段,已在烟化炉、烧结炉、炼钢转炉等冶金过程的终点判断中得到应用。

江帆等^[7]、尤佳等^[8]、赵多祯^[9]基于转炉炼钢炉口火焰图像的动态变化与吹炼产物信息的关系,并采用纹理分析^[10]、神经网络^[11]、最小二乘支持向量机^[12-13]等方法,通过建立火焰表观特征与吹炼终点产物信息之间的关系模型,来判断转炉吹炼终点。张寿明^[14]通过提取烟化炉三次风口火焰的表观特征,采用神经网络识别技术,建立了火焰图像特征与冶炼过程间的映射关系,并采用多传感器数据融合^[15]方法,将在线检测物理量与图形识别结果协同,以实现冶炼终点判断。罗特^[16]通过建立改进的 Lenet-5 卷积神经网络来预测转炉终点渣的成分含量,并采用 BP 神经网络^[17-18]挖掘转炉终点火焰图像特征与成分含量的关联性。理论上铜转炉吹炼造渣期终点与渣含 Fe 是否达标有关,而不同 Fe 含量渣样呈现不同的图像特征,然而受吹炼过程高温、高腐蚀等环境限制,当前检测手段还难以实现高温熔体成分的在线实时检测,以上学者图像识别与智能算法相结合的研究方法为实现铜转炉吹炼造渣期终

点在线判断提供了良好方法借鉴。

鉴于此,本文基于图形识别的特征向量提取原理,首先对吹炼渣数据集图像进行数据增广;其次采用 python 与 matlab 等开发工具,分别基于卷积神经网络(CNN)算法与支持向量机(SVM)算法构建了吹炼渣含 Fe 预测模型,并对数据样本集进行训练学习;最后,通过对两种模型的实例分析,得出了两种模型训练集与测试集的预测准确率,以期对图像识别技术在铜转炉吹炼终点判断中实践应用奠定良好的模型基础。

1 试验数据

1.1 数据集采集与预处理

在铜转炉吹炼过程中,吹炼渣的颜色、纹理等表观特征与其成分间存在一定的映射关系^[19],具体量化关系见表 1。因此,可通过建立吹炼渣表观特征与其成分之间的关系数据库,根据图像识别吹炼渣的表观特征确定成分含量,从而间接判断造渣期终点是否达到。


表 1 吹炼渣的成分及其表观特征的映射关系
Table 1 Mapping relationship between blowing slag composition and its apparent characteristics

是否终点	Fe 含量/%	吹炼渣颜色	吹炼渣纹理
非终点	<44	灰白色或青灰色	粗糙
终点	44~52	油黑色	光滑

构建模型所需的吹炼渣图像样本及其成分信息采集于国内某铜冶炼企业转炉吹炼车间,通过从转炉炉体内取样,并采用 1 500 万像素的智能手机拍摄吹炼渣渣板样图像,共计 48 张,并采用 X-Ray 测定吹炼渣中 Fe、Cu、S 等成分含量,获得的吹炼渣样本信息如表 2 所示。由于拍摄条件限制,样本数据集过小,具有不平衡性,会影响识别准确率^[20],因此需要后续图像数据增广处理。

表 2 吹炼渣样本信息

Table 2 Sample information of converting slag

样本号	图像样本	主要成分含量/%			
		Fe	Cu	S	SiO ₂
1		47.68	3.04	0.26	20.32
2		44.70	2.31	0.27	22.75
3		46.85	2.53	0.22	21.87
4		50.23	2.04	0.30	22.79
⋮	⋮	⋮	⋮	⋮	⋮
45		50.51	2.01	0.32	23.53
46		49.92	2.19	0.23	23.17
47		49.81	1.87	0.25	23.06
48		50.14	2.14	0.30	22.86

1.2 图像数据增广

为解决因吹炼渣图像样本少可能产生的模型过拟合问题,在对 48 张采集图像样本进行适当裁剪基础上,采用去中心化、PCA 降维、旋转角度、水平与竖直平移、错切变换、随机缩放、水平与竖直翻转等图像处理方法,对采集样本进行了数据增强,将吹炼渣图像样本增加至 138 张,其中 108 张作为模型训练数据集,其余 30 张作为测试数据集。

2 试验原理与方法

2.1 基于 CNN 的吹炼渣含 Fe 预测模型原理

在铜转炉吹炼过程中,随着铜钨中 FeS 氧化造渣反应不断进行,吹炼渣 Fe 含量及其呈现的颜色、纹理、形状等图像表观特征不断变化。因此,可通过采集吹炼渣的颜色、纹理等图像特征,并采用某种智

能算法构建特征信息与 Fe 含量之间的对应关系,计算吹炼渣中 Fe 含量,从而判断铜转炉吹炼造渣期是否达到终点。传统人工神经网络算法虽然能进行图像特征提取,但参数需求量和计算量大,计算效率低。卷积神经网络(CNN)是目前图像识别领域的前沿核心算法之一^[21],也是深度学习的代表性算法之一,具有较好的表征学习能力,参数和计算量少,可在分类识别中用于提取图像的判别特征^[22]。卷积神经网络算法一般包含输入层、隐含层、输出层;隐含层主要为卷积层、池化层、全连接层。

本文拟采用卷积神经网络算法构建吹炼渣含 Fe 预测模型,模型网络结构见图 1,主要包含输入层、4 个卷积层、2 个池化层、归一化层、激励函数、全连接层和回归层,样本图像特征提取过程及 Fe 含量预测模型如图 2 所示。




图 1 吹炼渣图像特征提取及其 Fe 含量预测 CNN 网络结构图

Fig. 1 CNN network structure diagram of converting slag image feature extraction and Fe content prediction




图2 基于CNN的吹炼渣图像特征提取及其Fe含量预测模型

Fig. 2 feature extraction of converting slag image based on CNN and its Fe content prediction model

1)输入层:主要用来定义输入样本图像的大小和类型,创建与输入图像大小相同的输入层,输入层的数据传递到卷积层;

2)卷积层:主要用来对输入图像样本进行特征提取,类似于图像处理中的滤波器,不同滤波器提取不同的特征,低级卷积层主要提取边缘、形状或斑块等基本信息,随着层次加深,提取的信息也越来越抽象。卷积层中包含多个卷积核,组成卷积核的每个元素都对应一个权重系数 w 和一个偏差量,类似于一个前馈神经网络的神经元,卷积运算将卷积核中每一个 w 与覆盖原图像对应像素 x 相乘,然后加权求和,得到特征数据图,由于进行卷积计算后参数增加,容易导致模型过拟合,因此卷积层后一般连接一个池化层;

3)激励函数:为进一步提高模型对吹炼渣样本图像特征提取的准确性,可将激励函数作为非线性因素引入到卷积层的权重系数调整运算,本文拟采用式(1)所示的Relu函数作为激励函数;

$$\text{ReLU}(t) = \max(0, t) \quad (1)$$

4)池化层:主要用来对卷积层输出参数进行信息过滤和特征选择,使特征图变小,参数变少,简化网络运算的复杂性。在提取吹炼渣图像主要特征时,本文选用平均池化,经过几次卷积池化处理后,传递到下一个卷积层;

5)归一化层:主要是在卷积计算的每一个迭代

周期上,对样本图像的数量 N 、高度 H 、通道数 C 等特征作归一化处理,使数据分布一致,防止模型过拟合。

6)全连接层与回归层:主要是将样本图像经归一化层处理后的特征信息经Dropout层,按20%的概率舍弃部分神经元后(神经元计算值置0,目的是减少中间特征数量,减少冗余,增加每层各个特征间的正交性)传递到全连接层,最后将特征图像以非线性组合形式的特征向量传递到回归层。由于预测模型只输出Fe含量,因此末尾全连接层的大小设置为1,输出吹炼渣中Fe含量值,最后将全连接层输出数据传递到回归层,用于采用均方误差方法计算损失值。吹炼渣Fe含量预测值和实测值之间的误差,采用式(2)所示的均方根误差(RMSE)公式来计算。

$$S = \{[(l_1 - l)^2 + (l_2 - l)^2 + \dots + (l_n - l)^2] / N\}^{\frac{1}{2}} \quad (2)$$

式中: l 为平均数; N 为样本个数。

2.2 基于SVM的吹炼渣含Fe预测模型原理

针对吹炼渣图像样本,分别采用Hu不变矩方法、颜色矩方法提取吹炼渣图像的形状特征和颜色特征,同时基于灰度差分统计特征(平均值,对比度,熵,角度方向)计算提取吹炼渣图像的纹理特征,并将获得的吹炼渣图像特征信息和对应Fe含量作为支持向量机预测模型的输入条件,构建基于SVM的吹炼渣Fe含量预测模型,如图3所示。




图3 吹炼渣图像特征提取与SVM预测渣含Fe模型

Fig. 3 Feature extraction of converting slag image and SVM prediction model of slag Fe content

2.2.1 样本图像特征提取算法

吹炼渣样本图像的表现特征信息主要包括形

状、颜色和纹理等,这些特征的提取步骤和算法如下。

1) 形状特征提取

采用式(3)~(5)实现对吹炼渣图像样本几何矩、中心矩和归一化中心矩等形状特征的提取计算。

几何矩计算公式

$$m_{ij} = \sum_x \sum_y x^i y^j f(x, y) \quad (3)$$

式中, $f(x, y)$ 表示样本图像的像素强度。

中心矩计算公式

$$u_{pq} = \sum_{x=1}^C \sum_{y=1}^R (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (4)$$

$$\begin{cases} M_1 = y_{20} + y_{02} \\ M_2 = (y_{20} - y_{02})^2 + 4y_{11}^2 \\ M_3 = (y_{30} - 3y_{12})^2 + (3y_{21} - y_{03})^2 \\ M_4 = (y_{30} + y_{12})^2 + (y_{21} + y_{03})^2 \\ M_5 = (y_{30} - 3y_{12})(y_{30} + y_{12})((y_{30} + y_{12})^2 - 3(y_{21} + y_{03})^2) + \\ \quad (3y_{21} - y_{03})(y_{21} + y_{03})(3(y_{30} + y_{12})^2 - (y_{21} + y_{03})^2) \\ M_6 = (y_{20} - y_{02})((y_{30} + y_{12})^2 - (y_{21} + y_{03})^2) + 4y_{11}(y_{30} + y_{12})(y_{21} + y_{03}) \\ M_7 = (3y_{21} - y_{03})(y_{30} + y_{12})((y_{30} + y_{12})^2 - 3(y_{21} + y_{03})^2) + \\ \quad (3y_{21} - y_{03})(y_{21} + y_{03})(3(y_{30} + y_{12})^2 - (y_{21} + y_{03})^2) \end{cases} \quad (6)$$

2) 颜色特征提取算法

采用颜色矩^[24]算法提取吹炼渣图像的颜色特征,由于人眼对颜色的主观认识符合 HSV 颜色空间的色

调、饱和度、明度,而图像颜色信息通常存在于 RGB 颜色空间,故需要先将 RGB 颜色空间转换为 HSV 颜色空间,RGB→HSV 的转换公式如式(7)~(9)所示。

归一化中心矩计算公式

$$y_{pq} = \frac{u_{pq}}{u_{00}^r} \quad (r = \frac{p+q}{2} + 1) \quad (5)$$

采用式(3)计算得到吹炼渣样本图像的重心 $(\bar{x}, \bar{y})$, 并代入到式(4)中计算得到样本图像的中心矩 u_{pq} , 将 u_{pq} 代入式(5)得到二阶 ($p+q=2$) 与三阶 ($p+q=3$) 归一化中心矩 y_{pq} , 采用 y_{pq} 计算结果构造式(6)所示的 7 个 Hu 不变矩^[23], 用于提取样本图像的形状特征。

$$h = \begin{cases} 0^\circ & \text{if max=min} \\ 60^\circ \times \frac{g-b}{\max-\min} + 0^\circ & \text{if max=r and } g \geq b \\ 60^\circ \times \frac{g-b}{\max-\min} + 360^\circ & \text{if max=r and } g < b \\ 60^\circ \times \frac{b-r}{\max-\min} + 120^\circ & \text{if max=g} \\ 60^\circ \times \frac{r-g}{\max-\min} + 24^\circ & \text{if max=b} \end{cases} \quad (7)$$

$$s = \begin{cases} 0 & \text{if max=0} \\ \frac{\max-\min}{\max} = 1 - \frac{\min}{\max} & \text{otherwise} \end{cases} \quad (8)$$

$$v = \max \quad (9)$$

式中, max 为 r, g, b 中的最大者; min 为 r, g, b 中的最小者

HSV 颜色空间一般有 H、S、V 三个颜色分量, 每个分量需计算三个颜色低阶矩, 因此图像的颜色矩共 9 个。颜色低阶矩计算公式如式(10)~(12)所示。

$$\text{一阶矩(均值)} \quad \mu_i = \frac{1}{N} \sum_{j=1}^N P_{i,j} \quad (10)$$

$$\text{二阶矩(标准差)} \quad \sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (P_{i,j} - \mu_i)^2} \quad (11)$$

$$\text{三阶矩(斜度)} \quad S_i = \sqrt[3]{\frac{1}{N} \sum_{j=1}^N (P_{i,j} - \mu_i)^3} \quad (12)$$

式中, $P_{i,j}$ 表示彩色图像第 i 个颜色通道分量中灰度为 j 的像素出现的概率; N 表示图像中的像

素个数。

3) 纹理特征提取算法

采用灰度共生矩阵算法^[25]描述吹炼渣图像的纹理特征,灰度共生矩阵常用的能量、对比度、相关度和熵4个特征分别采用式(13)~(16)来计算。

$$ASM = \sum_i \sum_j i^2 j^2 P(i, j) \quad (13)$$

$$CON = \sum_i \sum_j |i - j| P(i, j) \quad (14)$$

$$CORRLN = [\sum_i \sum_j i j P(i, j) - \mu_x \mu_y] / \sigma_x \sigma_y \quad (15)$$

$$ENT = - \sum_i \sum_j P(i, j) \log P(i, j) \quad (16)$$

式中, $P(i, j)$ 表示归一后的灰度共生矩阵, i, j 为两个灰度值, (i, j) 的值表示一个灰度为 i , 另一个灰度为 j 的两个相距 d 的像素对在对角的方向上出现的次数。

2.2.2 SVM 含量预测算法

支持向量机算法(SVM)主要用于分类与回归,在图像识别、文本分类等模式识别问题中应用广泛^[26-27]。与传统人工神经网络算法相比,SVM 算法具有算法简单、鲁棒性好等优点,尤其在解决小样本、非线性图像处理中优势更为明显^[28]。

在图像识别中,支持向量机算法通常基于图4所示的原理,采用式(17)所示的非线性函数来处理训练样本。

$$f(x) = w^T \varphi(x) + B = \sum_{i=1}^m a_i y_i k(x_i, x_j) + B \quad (17)$$

式中, $k(x_i, x_j)$ 表示映射至高维特征空间之后的内积; a_i 为拉格朗日乘子, $a_i > 0$; B 表示偏置量; w 为加权向量。




图4 支持向量机算法原理图

Fig. 4 Schematic diagram of support vector machine algorithm

由于 $k(x_i, x_j)$ 的内积计算比较复杂,故需要引入核函数对向量内积空间进行扩展,使得非线性回归问题得到近线性化处理;本文采用的核函数为式(18)所示高斯核函数。

$$k(x_i, x_j) = \exp \left(- \frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \quad (18)$$

式中, σ 为径向基核函数参数, $\sigma > 0$ 为高斯核的宽带。

高斯核函数自带一个参数 g , 其计算公式如式(19)所示:

$$g = \frac{1}{2\sigma^2} \quad (19)$$

由式(18)和式(19)可知,最优核函数取决于 σ 的最优解,而 σ 的最优解又取决于 g 的最优解。因此,本文采用式(20)和式(21)所示的粒子群优化算法^[13]对 g 进行优化求解。

$$v_i = v_i + c_1 \times \text{rand}() \times (pbest_i - x_i) + c_2 \times \text{rand}() \times (gbest_i - x_i) \quad (20)$$

$$k_i = k_i + v_i \quad (21)$$

式中, $pbest_i$ 和 $gbest_i$ 表示两个极值; $\text{rand}()$ 是介于(0,1)的随机数; c_1 、 c_2 是学习因子; v_i 是粒子的速度; k_i 是当前粒子的位置。

3 试验与结果分析

3.1 基于 CNN 的预测模型试验过程

针对现场采集并经过图像数据增广处理后的样本,基于所构建的吹炼渣 Fe 含量 CNN 预测模型,采用如下步骤开展训练和预测试验。

1) 样本信息处理:将增广处理后的样本图像大小统一处理为 28×28 pixel,保存到文件夹,并建立吹炼渣图像信息与吹炼渣成分含量的关系表,表中包含吹炼渣图像文件存储位置和该图像对应吹炼渣 Fe 含量等信息;

2) 训练样本获取:将关系表转换为包含吹炼渣图像及吹炼渣 Fe 含量的数据集,作为 CNN 预测模型的训练学习样本;

3) 参数设置:在对样本数据集进行训练学习时,采用的“Adam”作为优化器,设置初始训练学习率为 0.001,每次训练迭代最小批次为 50,训练最大轮数 300;

4) 训练学习:学习率为 0.001,且每个时期训练数据被重排;验证数据指定为前期处理过的 Xvalidation, Yvalidation,并在训练期间实时显示如图5所示的训练学习结果;

5) 预测测试: 以所构建的 CNN 预测模型和测试数据集(Xvalidation)作为参数, 采用 predict 函数计算中吹炼渣测试样本的 Fe 含量。采用训练集、测试集样本的实测值与预测值之间的平方相关系数 R^2 来评估 CNN 模型的预测准确率, R^2 计算表达式如式(22)所示。

$$R^2 = \left(\frac{\sum_{i=1}^n (d_i - \bar{d})(z_i - \bar{z})}{\sqrt{\sum_{i=1}^n (d_i - \bar{d})^2} \sqrt{\sum_{i=1}^n (z_i - \bar{z})^2}} \right)^2 \quad (22)$$

式中, $\bar{d}$ 和 $\bar{z}$ 分别表示实测值的平均值与预测值的平均值。

3.2 基于 SVM 的预测模型试验过程

针对现场采集并经过图像数据增广处理后的样本, 基于所构建的吹炼渣 Fe 含量 SVM 预测模型, 采用如下步骤开展训练和预测试验。

1) 样本信息处理: 将增广处理后的样本图像放入文件夹中, 利用图像特征提取代码对文件夹中的图像提取特征, 将提取的特征信息与吹炼渣成分含量形成对应的映射关系;

2) 训练样本获取: 将映射关系表转换为 mat 文件, 并按照 3 : 1 的比例将数据分为训练集与测试集, 并将训练集与测试集数据进行归一化处理作为支持向量机模型的输入样本;

3) 参数设置: svm 的类型设置为 3, 选用 e-SVR

类型, 核函数选用 RBF, 核函数中参数 g 与支持向量机中参数 c 的最佳值利用粒子群优化方法寻得, 损失函数设置为 0.01;

4) 训练学习: 将归一化后训练集数据、对应归一化处理后的 Fe 含量数据和创建好的 SVM 模型作为 libsvmtrain 函数的参数用于对样本信息的训练学习;

5) 模型预测: 将训练集与测试集数据、训练完成的 SVM 模型作为 libsvmpredict 函数的参数, 对测试样本进行预测计算, 得到吹炼渣 Fe 含量预测值与相对误差, 显示训练集与测试集实际值与预测值对比图, 并采用式(22)评估 SVM 模型的预测准确率。

3.3 结果分析

3.3.1 基于 CNN 的预测模型试验结果与分析

基于构建的 CNN 吹炼渣含 Fe 预测模型, 采用增广处理后的 108 张作为模型训练数据集, 进行样本训练学习, 训练结果如图 5a 所示; 采用训练学习后的预测模型, 将另外 30 张吹炼渣图像作为测试样本进行 Fe 含量预测计算, 测试结果如图 5b 所示, 模型预测值、实测值及二者相对误差见表 3。由图 5 和表 3 结果可知, 采用 CNN 的预测模型对吹炼渣样本进行训练学习时, 训练集的预测准确率达 98%; 测试集的预测准确率约 50%, 相对误差低于 11%, 平均相对误差 4.09%, 相对误差小于 5% 的测试样本比例接近 65%。




图 5 基于 CNN 的预测模型试验结果

Fig. 5 Prediction results of convolutional neural network

表 3 基于 CNN 的预测模型渣含 Fe 计算结果

Table 3 Comparison between predicted value and actual value of convolution neural network model

样本号	Fe 含量实测值/%	Fe 含量预测值/%	相对误差/%	样本号	Fe 含量实测值/%	Fe 含量预测值/%	相对误差/%
1	48.37	48.20	0.35	16	50.56	48.27	4.53
2	49.78	49.48	0.60	17	50.14	46.63	7.00
3	49.81	49.54	0.55	18	49.19	45.84	6.81
4	50.56	48.89	3.31	19	44.63	49.18	10.20
5	50.14	49.27	1.74	20	48.9	50.31	2.87
6	49.19	44.88	8.77	21	46.74	48.60	3.97
7	44.63	47.05	5.41	22	45.85	49.93	8.91
8	48.90	48.70	0.41	23	47.33	44.92	5.10
9	46.74	49.06	4.96	24	47.58	48.87	2.70
10	45.85	50.75	10.6	25	48.37	46.35	4.18
11	47.33	46.02	2.78	26	49.78	49.73	0.10
12	47.58	49.95	4.97	27	49.81	48.38	2.86
13	48.37	48.33	0.08	28	50.56	47.34	6.37
14	49.78	49.26	1.05	29	50.14	47.53	5.21
15	49.81	49.52	0.58	30	49.19	46.40	5.66

3.3.2 基于 SVM 的预测模型试验结果与分析

基于构建的 SVM 吹炼渣含 Fe 预测模型,对 108 张吹炼渣样本训练学习的结果如图 6a 所示;采集 30 张吹炼渣测试样本的预测结果如图 6b 所示,模型预测值、实测值及二者相对误差见表 4。由图 6 和表 4

结果可知,采用 SVM 的预测模型对吹炼渣样本进行训练学习时,训练集的预测准确率达 99%,均方误差为 8.95×10^{-5} ;测试集的预测准确率为 62%,均方误差为 0.06,相对误差低于 5.14%,平均相对误差 1.35%,相对误差小于 5%的比例约 97%。




图 6 基于 SVM 的预测模型试验结果

Fig. 6 Experimental results of SVM based prediction mode

表 4 基于 SVM 的预测模型渣含 Fe 计算结果

Table 4 Comparison between predicted value and actual value of Fe content of support vector machine/%

样本号	Fe 含量 实测值/%	Fe 含量 预测值/%	相对 误差/%	样本号	Fe 含量 实测值/%	Fe 含量 预测值/%	相对 误差/%
1	47.37	48.15	1.65	16	49.78	49.31	0.94
2	48.25	48.49	0.50	17	49.99	49.71	0.56
3	47.33	47.59	0.55	18	49.84	49.17	1.35
4	46.85	47.83	2.08	19	49.81	49.49	0.64
5	46.5	46.73	0.49	20	49.93	49.32	1.22
6	47.58	47.87	0.62	21	49.89	48.80	2.18
7	48.44	48.37	0.15	22	49.19	49.65	0.93
8	50.31	49.74	1.13	23	49.47	48.89	1.17
9	51.29	48.65	5.14	24	49.82	49.33	0.99
10	50.89	49.93	1.88	25	48.87	48.90	0.06
11	48.83	48.89	0.12	26	49.81	48.99	1.65
12	48.37	48.71	0.71	27	49.81	48.73	2.17
13	48.51	48.36	0.31	28	49.37	48.72	1.31
14	49.85	48.05	3.61	29	50.56	49.00	3.09
15	49.61	48.92	1.38	30	50.14	49.10	2.07

4 结论

铜转炉吹炼造渣期的终点判断是影响粗铜质量和回收率的重要问题,在整个火法炼铜中有着重要的意义。采用卷积神经网络和支持向量机算法,基于图像特征数据与吹炼渣中 Fe 含量数据,通过建立预测模型,对造渣期吹炼渣中 Fe 含量进行预测,为图像识别技术在铜转炉吹炼终点判断中的应用奠定数模基础。实例测试结果表明,两种预测模型的预测准确率均低于 65%,后续将提高吹炼渣图像样本数和样本图像分辨率,优化模型参数,进一步提高模型对吹炼渣含 Fe 预测的准确率。

参考文献

- [1] 薛立华. 铜钼 P-S 转炉吹炼终点复合式预报系统的开发与应用[D]. 长沙:中南大学,2003.
XUE L H. Development and application of compound forecast system for copper matte P-S converter end point[D]. Changsha: Central South University, 2003.
- [2] 范进军,何建平,刘奇,等. 铜终点在线监测系统对转炉吹炼终点判断的应用[J]. 有色金属(冶炼部分), 2018(8):8-11.
FAN J J, HE J P, LIU Q, et al. Application of copper end point on-line monitoring system to judge end point of converter blowing[J]. Nonferrous Metals (Extractive Metallurgy), 2018(8):8-11.
- [3] 张云生,金以诚,刘瑞敏. 应用信息集成的铜吹炼转炉终点控制[J]. 冶金自动化,2000(3):14-17.
ZHANG Y S, JIN Y C, LIU R M. Terminal point control by use of information integration in copper smelt process[J]. Metallurgical Industry Automation, 2000(3):14-17.
- [4] 胡志坤,桂卫华,阳春华,等. 铜转炉吹炼过程熔剂加入量的模糊操作模式挖掘方法[J]. 控制与决策,2010, 25(11):1689-1692.
HU Z K, GUI W H, YANG C H, et al. A mining method for fuzzy operational patterns of the amount of flux in the process of copper converter[J]. Control and Decision, 2010, 25(11):1689-1692.
- [5] 熊向敏. 基于机器视觉的漏钢检测方法:评《连铸漏钢计算机视觉检测方法》[J]. 有色金属(冶炼部分), 2020(12):126.
XIONG X M. Breakout detection method based on machine vision: Comment on “Computer vision detection method for continuous casting breakout”[J]. Nonferrous Metals (Extractive Metallurgy), 2020(12):126.
- [6] 罗宗山. 基于图像识别的二次仿真及在氧化铝回转窑上的应用[J]. 有色金属(冶炼部分), 2011(11):30-33.
LUO Z S. Image recognition based on secondary simulation and its application on alumina rotary kiln[J]. Nonferrous Metals (Extractive Metallurgy), 2011(11):30-33.
- [7] 江帆,刘辉,王彬,等. 基于火焰图像 CNN 的转炉炼钢吹炼终点判断方法[J]. 计算机工程,2016,42(10): 277-282.
JIANG F, LIU H, WANG B, et al. Basic oxygen furnace blowing endpoint judgment method based on flame image convolution neural network[J]. Computer Engineering, 2016, 42(10):277-282.
- [8] 尤佳,王绍纯,李希胜,等. 通过转炉炉口火焰纹理分析判断氧气顶吹转炉吹炼终点[J]. 北京科技大学学报, 2000,22(6):524-528.
YOU J, WANG Z C, LI X S, et al. Estimate blowing final point by analyzing texture features of top-blowing BOF vessel mouth flame[J]. Journal of University of Science and Technology Beijing, 2000, 22(6):524-528.
- [9] 赵多祯. 基于图像处理的转炉终点预测研究[D]. 内蒙古包头:内蒙古科技大学,2020.
ZHAO D Z. Research on end point prediction of converter based on image processing[D]. Baotou: Inner Mongolia University of Science & Technology, 2020.
- [10] CHAKI J, DEY N. Texture feature extraction techniques for image recognition [M/OL]. Springer, Singapore, 2020. <https://link.springer.com/book/10.1007/978-981-15-0853-0>.
- [11] 汪金良,曾青云,汪仁良. 应用神经网络技术建立铜闪速熔炼温度模型[J]. 有色金属(冶炼部分), 2002(1): 12-14.
WANG J L, ZENG Q Y, WANG R L. Study on the temperature model for copper flash smelting based on neural network [J]. Nonferrous Metals (Extractive Metallurgy), 2002(1):12-14.
- [12] SUYKENS J A K, VAN G T, DE BRABANTER J, et al. Least squares support vector machines [M]. Republic of Singapore: World Scientific Publishing Company, 2003.
- [13] 刘飞飞,罗贤平,古帅奇,等. 碱煮过程浸出率预测与优化研究[J]. 有色金属(冶炼部分), 2016(5):29-32.
LIU F F, LUO X P, GU S Q, et al. Prediction and optimization of leaching rate during alkali boiling process[J]. Nonferrous Metals (Extractive Metallurgy), 2016(5):29-32.
- [14] 张寿明. 基于冶炼过程及终点判断技术的烟化炉智能控制系统研究[D]. 昆明:昆明理工大学,2009.
ZHANG S M. Research on intelligent control system of

- smoked furnace based on smelting process and end point judgment technology [D]. Kunming: Kunming University of Science and Technology, 2009.
- [15] RAOL J R. Multi-sensor data fusion with MATLAB[M]. Taylor and Francis: CRC Press, 2010.
- [16] 罗特. 基于卷积神经网络火焰图像识别的转炉炼钢终点碳温实时预报[D]. 昆明: 昆明理工大学, 2019.
- LUO T. Real-time prediction of final carbon temperature of converter steelmaking based on flame image recognition of convolutional neural network[D]. Kunming: Kunming University of Science and Technology, 2019.
- [17] 时章明, 薛立华, 周安梁, 等. BP神经网络在铜铈吹炼终点预报中的应用[J]. 有色金属(冶炼部分), 2002(5): 24-27.
- SHI Z M, XUE L H, ZHOU A L, et al. Application of BP neural network model in predicting the endpoint in matte-converting [J]. Nonferrous Metals (Extractive Metallurgy), 2002(5): 24-27.
- [18] 胡志坤, 彭小奇, 姚俊峰, 等. 炼铜转炉吹炼终点预报研究[J]. 有色金属(冶炼部分), 2000(6): 7-9.
- HU Z X, PENG X Q, YAO J F, et al. Research on endpoint forecast of copper smelting converter [J]. Nonferrous Metals (Extractive Metallurgy), 2000(6): 7-9.
- [19] 杨文栋, 谢文仕, 冯秋艳. 浅析转炉吹炼终点的判断方法[J]. 有色矿冶, 2006(6): 30-33.
- YANG W D, XIE W S, FENG Q Y. Simply analyzing of termial judgment during the blowing refinement of the matte [J]. Non-Ferrous Mining and Metallurgy, 2006(6): 7-9.
- [20] 王李管, 陈斯佳, 贾明滔, 等. 基于深度学习的黑钨矿图像识别选矿方法[J]. 中国有色金属学报, 2020, 30(5): 1192-1201.
- WANG L G, CHEN S J, JIA M T, et al. Beneficiation method of wolframite image recognition based on deep learning [J]. The Chinese Journal of Nonferrous Metals, 2020, 30(5): 1192-1201.
- [21] 罗特, 刘辉, 巫乔顺, 等. 基于卷积神经网络的转炉炼钢终点碳含量预测方法[J]. 信息技术, 2018, 42(12): 142-147.
- LUO T, LIU H, WU Q S, et al. Prediction method of carbon content in BOF endpoint based on convolutional neural network [J]. Information Technology, 2018, 42(12): 142-147.
- [22] 孙洁, 丁笑君, 杜磊, 等. 基于卷积神经网络的织物图像特征提取与检索研究进展[J]. 纺织学报, 2019, 40(12): 146-151.
- SUN J, DING X J, DU L, et al. Research progress of fabric image feature extraction and retrieval based on convolutional neural network [J]. Journal of Textile Research, 2019, 40(12): 146-151.
- [23] 江波, 徐小力, 吴国新, 等. 轮廓 Hu 不变矩的工件图像匹配与识别[J]. 组合机床与自动化加工技术, 2020(9): 104-107, 111.
- JIANG B, XU X L, WU G X, et al. Workpiece recognition and matching based on Hu invariant moment of workpiece contour [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(9): 104-107, 111.
- [24] 王业琴, 赵志国. 基于直方图和颜色矩方法的木材表面颜色特征的表达[J]. 林业科技, 2006(5): 56-58.
- WANG Y Q, ZHAO Z G. Expression on the basis of the timber surface color characteristic of the histogram and color moment method [J]. Forestry Science & Technology, 2006(5): 56-58.
- [25] 赵爽, 李延军, 马志庆, 等. 基于灰度共生矩阵的乳腺病理图像纹理特征分析[J]. 中国医学装备, 2018, 15(8): 5-8.
- ZHAO S, LI Y J, MA Z Q, et al. An analysis of texture features of breast pathology image based on gray scale co-occurrence matrix [J]. China Medical Equipment, 2018, 15(8): 5-8.
- [26] 卢超猛, 马泽众, 韩阳, 等. 基于支持向量回归的房价数据分析[J]. 华北理工大学学报(自然科学版), 2021, 43(4): 76-82.
- LU C M, MA Z Z, HAN Y, et al. Analysis of house price data based on support vector regression [J]. Journal of Hebei United University (Natural Science Edition), 2021, 43(4): 76-82.
- [27] 刘飞飞, 祝恩宇, 徐鹏, 等. 碱煮工艺过程的智能集成建模研究[J]. 有色金属(冶炼部分), 2015(6): 63-66.
- LIU F F, ZHU E Y, XU P, et al. Intelligent integrated modeling for tungsten alkali leaching process [J]. Nonferrous Metals (Extractive Metallurgy), 2015(6): 63-66.
- [28] 周志聪, 祁广云. 基于支持向量机对稻米淀粉含量的回归预测研究[J]. 黑龙江八一农垦大学学报, 2014, 26(6): 88-92.
- ZHOU Z C, QI G Y. Study of regression prediction based on support vector machine to rice starch content [J]. Journal of Heilongjiang August First Land Reclamation University, 2014, 26(6): 88-92.