

# 铸造工艺数据驱动的工程机械 铸件缺陷预测

刘迎辉<sup>1</sup>, 余朋<sup>1</sup>, 潘徐政<sup>1</sup>, 朱守琴<sup>2</sup>, 计效园<sup>1</sup>,  
吴来发<sup>2</sup>, 殷亚军<sup>1</sup>, 沈旭<sup>1</sup>, 解明国<sup>2</sup>, 周建新<sup>1</sup>

(1. 华中科技大学材料成形与模具技术全国重点实验室, 湖北武汉 430074;  
2. 安徽合力股份有限公司合肥铸锻厂, 安徽合肥 230022)

**摘要:** 针对砂型铸造过程缺陷难以寻因、工艺数据类别不平衡问题, 提出了一种基于特征重分布与代价敏感学习的卷积神经网络缺陷预测方法。首先, 根据样本特征相关性, 对特征向量排列顺序进行了优化; 其次, 基于不平衡工艺数据样本设计了代价敏感正则项, 对模型损失函数进行了修正; 最后, 构建了缺陷预测模型 (FR-CS-CNN)。测试结果表明, 本研究构建的FR-CS-CNN在总体预测精度上达到了93.67%, 相比卷积神经网络提升了2.96%。

**关键词:** 砂型铸造; 缺陷预测; 代价敏感学习; 卷积神经网络

## 作者简介:

刘迎辉 (1997-), 硕士生, 研究方向为铸造数字化管理系统。E-mail: 350601200@qq.com

## 通讯作者:

计效园, 男, 副教授, 博士生导师。E-mail: jixiaoyuan@hust.edu.cn

中图分类号: TG245

文献标识码: A

文章编号: 1001-4977(2024)

09-1329-07

## 基金项目:

国家重点研发计划项目 (2020YFB1710100); 国家自然科学基金(52275337、52090042、51905188)。

## 收稿日期:

2023-07-16 收到初稿,

2023-10-18 收到修订稿。

在以信息化、智能化为标志的第四次工业革命背景下, 我国必须加快数字化产业转型<sup>[1]</sup>, 使得制造产业摆脱困境<sup>[2-3]</sup>、完成质量转型<sup>[4-5]</sup>。

砂型铸造是铸造的核心工艺方法之一, 其以型砂作为造型材料制作铸型, 通过金属液填充型腔, 而后冷却成形, 经热处理、机加工等环节得到最终产品, 具有生产周期长、工艺复杂、车间环境复杂等特点<sup>[6]</sup>。一方面, 传统的砂型铸造当中, 包含了造型、制芯、合型、金属熔炼、浇注、冷却等众多工序<sup>[7]</sup>, 涉及到的工艺参数与质量检测参数不胜枚举, 而参数间又存在着耦合作用的情况, 导致工艺与质量间的内禀关系难以探明<sup>[8]</sup>; 另一方面, 从企业获取到的数据大多为合格品数据, 缺陷类数据占比较低, 无法根据数学建模等数学分析方法充分挖掘缺陷数据的特征, 铸件质量演变规律无从分析。可见, 企业生产工艺需要与信息技术相结合, 从而跳出当前的工艺困境<sup>[9]</sup>。为此, 本研究提出了一种基于特征重分布与代价敏感学习的卷积神经网络缺陷预测方法, 为企业生产的工艺调整提供了新思路。

数据驱动的缺陷预测一直是国内外学者研究重点之一。英国A. S. Normanton等人<sup>[10]</sup>采用了多层感知机网络 (MLP) 技术, 经过统计算法的组合, 最终的质量预测系统得到了很大的提升; 印度S. Hore等人<sup>[11]</sup>为研究连铸过程中重要的加工参数对缺陷的影响, 采用人工神经网络对熔体成分、浇注速度、模具震荡频率等参数进行分析, 构建了两层前馈反向传播神经网络模型对各种缺陷的出现概率进行预测, 得到了震荡标记深度, 模具粉末消耗率与缺陷产生的内禀关系; 韩国Lee等人<sup>[12]</sup>在保证铸造缺陷预测准确率的前提下, 为改善预测误差带来的成本损失, 提出了误差加权深度神经网络模型, 均方根差降到了5.92%。国内, 豆义华<sup>[13]</sup>从砂芯强度、烘干温度、浇注温度等工艺因素入手, 建立了基于动量梯度下降算法的BP神经网络模型, 通过模型确定了断芯缺陷的主要影响因子; 张龙等人<sup>[14]</sup>提出了基于迁移学习的旋转机故障诊断方法, 把多传感器信号时频图融合输入进ResNet中, 简化了故障诊断的分类任务, 并在对应的数据集中进行了验证, 模型的平均识别准确率达到93.12%; 刘阳等人<sup>[15]</sup>基于长短时记忆循环神经网络建立了对轧机颤振能量值的智能预报, 获取到了最优的预测时间步长, 使得模型能够在预订的报警阈值内提前做出预测, 实现

了冷轧过程中振动工艺的优化。

### 1 缺陷预测模型构建

针对工程机械当中使用QT450-10材质的转向桥、回转架以及桥壳铸件，开展典型缺陷的研究工作。在

生产以上三种类型的铸件时，会出现的常见缺陷包括砂眼、气孔、缩孔、冷隔，如图1所示。深入企业调研了解到，尽管生产工艺参数控制在正常范围内，但仍存在由多因素耦合作用导致的缺陷，产品质量管理陷入困境。

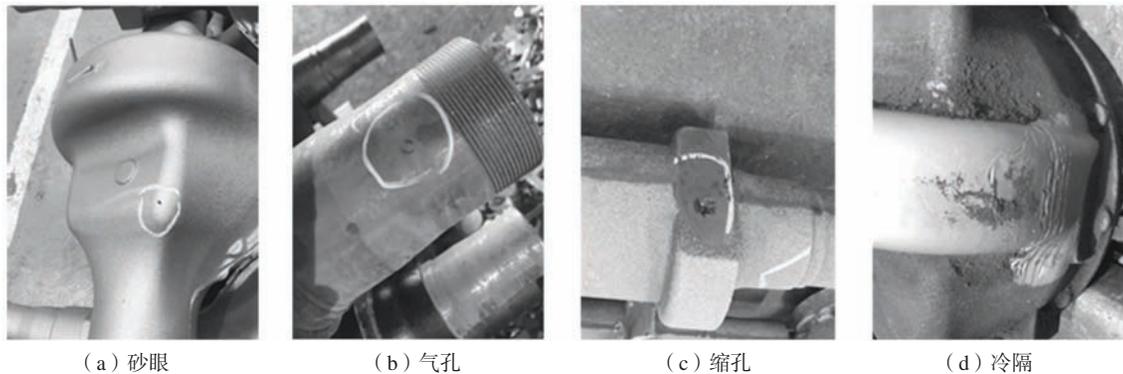


图1 四种典型缺陷  
Fig. 1 Four typical defects

对以上四种铸件缺陷，从某企业采集了转向桥、回转架、桥壳成形过程关键铸造工艺数据。具体涉及到混砂造型、金属熔炼、浇注过程工序的18个工艺参

数，经过数据清洗得到了用于模型训练的数据集，共计6 267条。表1分别展示了各项工艺参数范围变化。

表1 工艺参数变化范围统计  
Table 1 Process parameters variation range statistics

数值	紧实率/%	剪切强度/kPa	旧砂温度/℃	旧砂水分/%	膨润土/%	混配土/%	新砂/%	C/%	Si/%
下限值	35.07	2	33.4	1.38	19.9	9.8	0	3.61	2.6
上限值	48.82	6	48.8	2.38	33.2	19.7	40	3.85	2.92
数值	Mn/%	P/%	S/%	Mg/%	Al/%	浇注温度/℃	浇注重量/kg	浇注时间/s	孕育量/g
下限值	0.38	0.013	0.006	0.034	0.017	1 385	128	11.9	24
上限值	0.66	0.047	0.018	0.057	0.054	1 415	145	30.5	92

#### 1.1 特征重分布

采用一维卷积神经网络对砂型铸造缺陷预测问题进行建模分析。但事实上，上述采集的18个特征数据在不同的排列组合下，卷积核所能提取的信息是存在差异的。假设简单地对数据进行首尾连接，得到长度为18的特征向量，卷积核扫描邻近特征参数时，可能会将强相关特征组合做卷积运算，以此得到的数据信息在往下一层网络结构传递时并未得到丰富，反而丢失了对弱相关参数组合效果的分析，具体如图2所示。

因此，需要根据数据间的相关性对特征向量的一维空间排列进行重分布，确保模型充分挖掘弱相关参数的组合特征。重分布的思想为：让强相关特征在一维空间离散分布，弱相关特征在一维空间邻近组合。其具体实现步骤为：将18个工艺参数所对应的皮尔逊相关性系数矩阵转化成权重矩阵，相关系数越高，权重越小，相关系数越低，权重越大；然后，根据18个

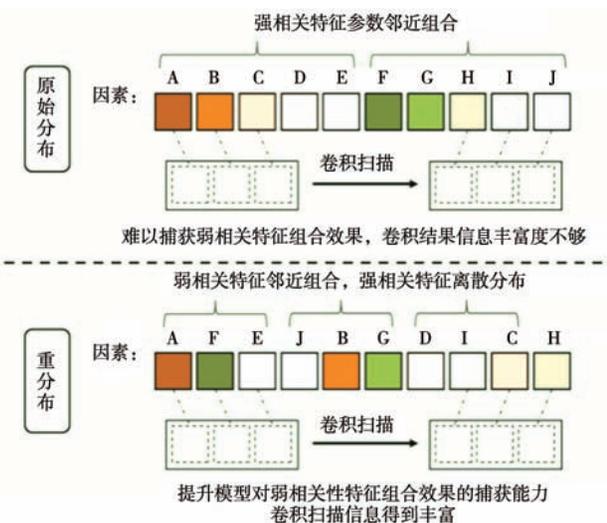


图2 原始分布与重分布的特征扫描过程对比  
Fig. 2 Comparison of feature scanning process between original distribution and redistribution

工艺参数生成两两组合的二元组集合，共计153个，按照二元组间权重系数大小对该集合进行由小到大的排序；最后，根据贪心算法的思想，每一步的特征组合必须是当前最优的二元组选择，即根据二元组权重系数大小依次调进组合中两个工艺参数的一维空间距离，进而得到全局的最优解，如图3所示。

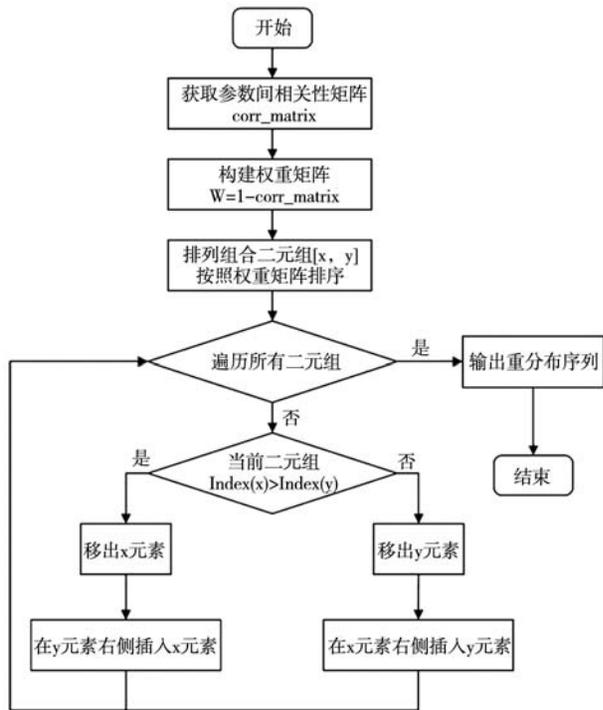


图3 数据重分布流程图  
Fig. 3 Data redistribution flowchart

### 1.2 代价敏感优化

在采集的6 267条工艺数据当中，合格品铸件5 111条，缩孔缺陷铸件144条，砂眼缺陷铸件350条，气孔缺陷铸件396条，冷隔缺陷铸件266条，类别存在严重的偏差，4种缺陷的少数类样本特征极容易被缺陷预测模型忽略。为此，引入代价敏感学习，为不同类别的判定赋予不同的预测代价，进而弥补样本不平衡所带来的性能损失。

代价敏感学习的具体实现方式为：根据样本比例对损失函数做出不同的调整。即给原有的损失函数添加含有代价矩阵的正则项，根据模型计算出的缺陷类型赋予其下次判别所要付出的代价，经过求和得到最终的损失函数。本模型具体的损失函数构建如公式(1)所示。

$$L_{\theta} = \frac{-1}{N} \sum_{i=1}^{Num} \sum_{c=1}^5 y_{ic} \log \hat{y}_{ic} + \frac{\lambda}{N} \sum M_{index_c} Softmax(y_{ic}) \quad (1)$$

式中：N代表样本数量，如果样本i的真实标签为c，则取1，反之取0； $\hat{y}_{ic}$ 代表样本i预测为c类的概率；λ代表

正则项系数，一般取为10； $M_{index_c}$ 代表预测为c类所需付出的代价值； $Softmax(y_{ic})$ 代表样本i经过网络计算后的不同标签分布概率。

在传统的五分类模型当中，会直接根据Softmax所计算的概率分布值挑选出最大值的下角标，其所代表的标签即为最终模型预测的缺陷类型。但引入代价敏感学习后，模型的判断依据不再是概率分布中的最大值，而是将Softmax计算的概率分布与真实类型在代价矩阵当中对应的代价向量进行矩阵乘积运算，进而得到改善损失函数的正则项。

与传统的五分类相比，引入了正则项后的模型在实现预测时，不再依靠数值大小进行判定，而是根据实际训练样本类别的分布情况做出相应的判断。该过程相当于为每一种标签结果的判定划分了各自的阈值，不再由模型输出的最大概率值对应的类别作为最终预测结果。除了损失函数的调整外，代价矩阵具体的cost值也是重点。

在本研究中，预测代价是样本不平衡引起的，则代价矩阵要围绕真实数据分布进行设计。现已获取的数据中，则代价矩阵可以设计成：

0	350	396	266	5 111
144	0	396	266	5 111
350	350	0	266	5 111
144	350	396	0	5 111
266	266	266	0	266
144	350	396	266	0
5 111	5 111	5 111	5 111	0

矩阵中的每一元素都是一个代价cost，而cost值的设计方式为：例如将原本的缩孔缺陷预测成砂眼缺陷，则相应的代价为，将原本的砂眼缺陷预测成缩孔缺陷，则代价为，以此类推便获得了代价矩阵的最终结果。

### 1.3 模型效果对比

根据以上特征重分布与代价敏感学习的优化，构建了针对工程机械复杂砂型铸件典型缺陷预测的模型（Feature Redistribution Cost Sensitive Convolutional Neural Network, FR-CS-CNN），模型具体网络结构如图4所示。

与传统的多层感知机全连接网络（Multilayer Perceptron, MLP）模型不同，本研究所构建的模型采用了一维卷积神经网络（1D-CNN），规避了特征全连接的耦合作用分析，凸显出弱相关特征组合的效果，

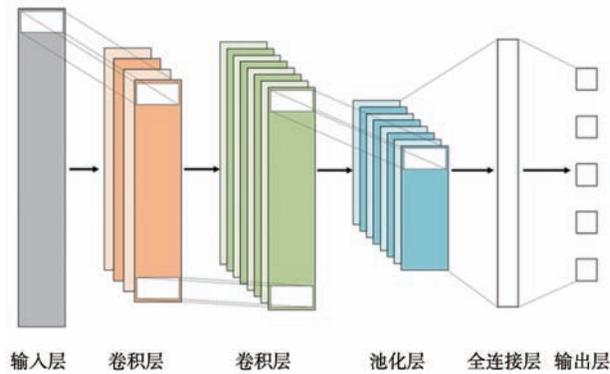


图4 网络模型结构

Fig. 4 Network model structure

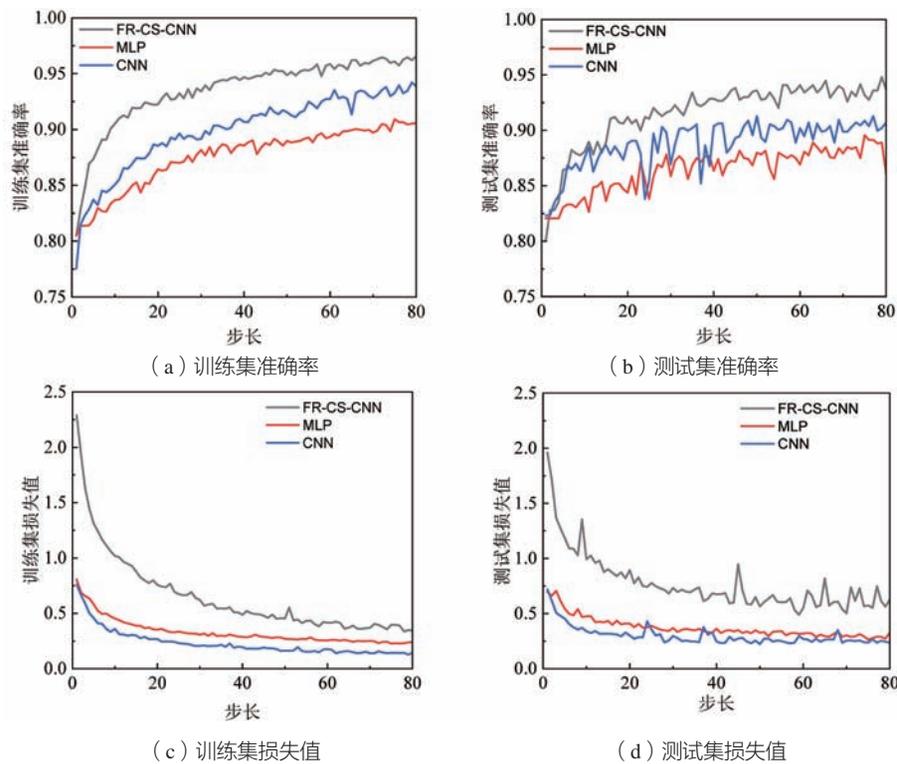


图5 FR-CS-CNN、CNN及MLP模型训练效果

Fig. 5 Training effects of FR-CS-CNN, CNN, and MLP models

93.67%。该结果表明，通过特征重分布与代价敏感学习的优化，FR-CS-CNN对不同类型的缺陷有了更强的预测能力，并且FR-CS-CNN在损失值上的降幅要明显大于CNN和MLP，这也进一步证明了FR-CS-CNN模型在尽可能地减小缺陷预测的风险，至于其最终的损失值高于前两者，是因为FR-CS-CNN在损失函数中添加了代价敏感正则项，数值上会偏高。

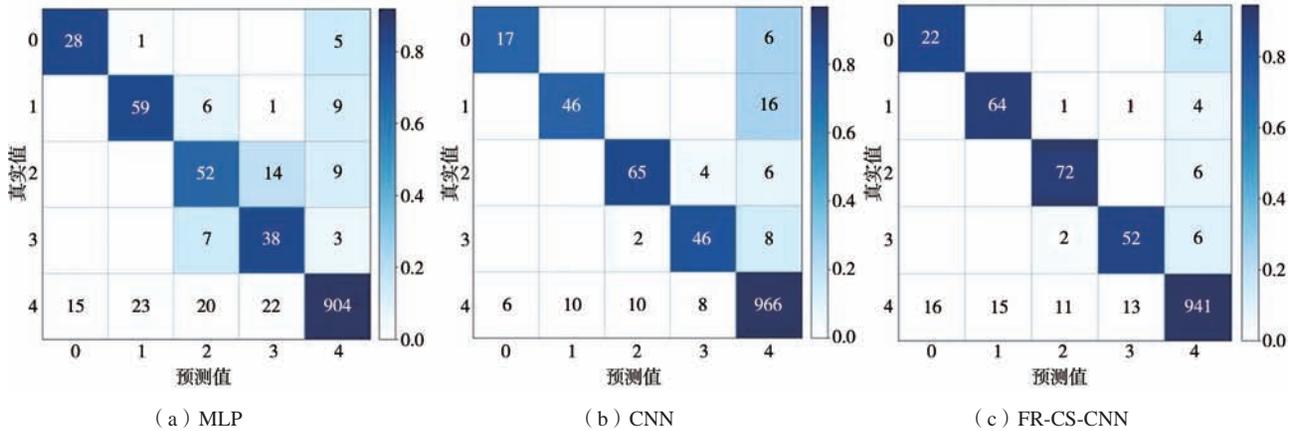
模型的总体准确率以及损失值并不能完全反映模型的优劣，还需要从最终的预测分类混淆矩阵、精准率、召回率和F1分数来进行分析说明，下面分别展示了不同模型的混淆矩阵如图6所示，以及评估结果如表2所示。

确保了模型对特征融合的高效学习。此外，在CNN的基础上，引入代价敏感学习对交叉熵损失函数进行调整，改善了样本不均衡带来的风险，并得到了基于特征重分布与代价敏感学习的卷积神经网络（FR-CS-CNN）模型。本研究对MLP、CNN、FR-CS-CNN三种模型进行了训练对比，效果如图5所示。

MLP在训练集和测试集上的缺陷预测准确率分别达到了90.56%和86.10%，CNN在训练集和测试集上的准确率分别为93.89%和90.71%，可见基于卷积核局部特征的融合分析方法要优于特征全连接分析方法，这也间接证明了特征重分布的必要性；FR-CS-CNN在训练集以及测试集的效果分别达到了96.53%和

在混淆矩阵当中，方格的颜色越深，代表对应的预测数量越多，理想的多分类模型当中预测的点应该全部落在斜对角线上。MLP中除了合格品外，只有缩孔缺陷的预测精度较高，其他三种缺陷的精度过低，CNN中气孔和合格品的精度较为准确，而在FR-CS-CNN当中，四种缺陷的预测准确率相较于前二者来说都有一定的提升，并且其预测错误的点大多都是落在合格品类的FN区域，影响程度较低。

表2也印证了上述特点，除了FR-CS-CNN在缩孔类的精准率较低进而影响了F1分数外，FR-CS-CNN在其他类别上的F1分数要明显优于CNN与MLP，并且结合实际生产情况，宁可增加繁琐的检测步骤，也不要放



(\*注: 图中0表示冷隔、1表示气孔、2表示砂眼、3表示缩孔、4表示合格品)

图6 不同模型在测试集上的混淆矩阵

Fig. 6 Confusion matrices of different models on test set

表2 不同模型的评估结果  
Table 2 Evaluation results of different models

项目	MLP精准率	MLP召回率	MLP F1分数	CNN精准率	CNN召回率	CNN F1分数	CS-CNN精准率	CS-CNN召回率	CS-CNN F1分数
缩孔	0.651 2	0.823 5	0.727 3	0.739 1	0.739 1	0.739 1	0.578 9	0.846 2	0.687 5
砂眼	0.710 8	0.786 7	0.746 8	0.821 4	0.741 9	0.779 6	0.782 6	0.9	0.837 2
气孔	0.611 8	0.693 3	0.65	0.844 2	0.866 7	0.855 3	0.837 2	0.923 1	0.878 1
冷隔	0.506 7	0.791 7	0.617 9	0.793 1	0.821 4	0.807	0.787 9	0.866 7	0.825 4
合格品	0.972	0.918 7	0.944 6	0.964 1	0.966	0.965	0.979 2	0.944 8	0.961 7

过出现缺陷的潜在风险,所以说类别的召回率是研究的侧重点,在FR-CS-CNN当中,对实际缺陷铸件的合格“误判”概率较低,这与模型有着较高的召回率有关。由此可见,本研究构建的FR-CS-CNN模型能够融合生产工艺参数与铸件的三维特征,更加精准地预测铸件缺陷,具备实际的应用价值。

## 2 缺陷演变规律分析

基于构建的FR-CS-CNN模型,本节分别从混砂造型、金属熔炼以及浇注三个工序中选取了剪切强度、C

含量、浇注温度进行了如图7的单因素分析。

由于FR-CS-CNN模型最终的输出是经过Softmax函数处理的,得到的结果是五类别的概率值,图中展现的是随着工艺因素变化,四种缺陷的产生概率的波动规律。在剪切强度的影响下,砂眼在较低的剪切强度下有较大的出现概率,而另外几种缺陷的变化程度较小,可以粗略认为剪切强度只对砂眼的产生有影响,单因素的分析角度下,剪切强度在实际生产中需要尽量控制在2.7 kPa以上;在C含量的影响下,冷隔在较高C含量的情况下出现概率有所提升,但并未占据主导地

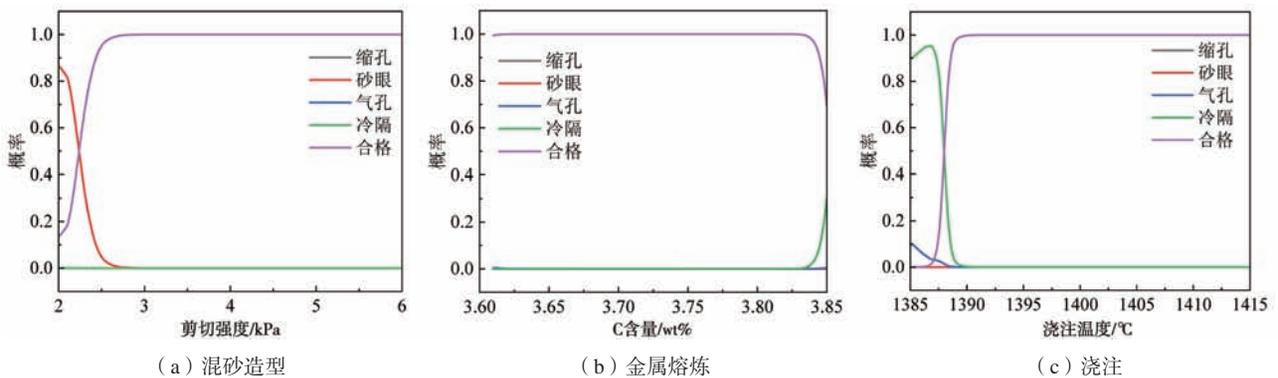


图7 单因素工序工艺对缺陷规律的分析

Fig. 7 Analysis of defect rule in single factor process

位, 存在30%的概率, 而另外几种缺陷的变化程度较小, 忽略不计, 因此在实际生产中C含量尽量控制在3.83%以下较为安全; 而在浇注温度的单独影响下, 冷隔与气孔在1 390 ℃以下容易形成, 故浇注温度不能太低, 或是球化处理完后需要尽快完成浇注, 否则较低温度的铁水流动性不够, 极易冷凝。

除此之外, 本研究还分别对剪切强度(SS)-紧实率(JS)、C含量-Mg含量、浇注温度(PT)-孕育剂量(PV)双因素进行了分析, 五种类别的概率以曲面的形式呈现出来。

在紧实率与剪切强度双因素的影响下缺陷形成概率的情况如图8所示, 可以看到在双区间紧实率(45.2, 48), 剪切强度(2, 3.1)以及紧实率(39.3, 42.9), 剪切强度(2.8, 4.6)内, 气孔的出现概率大幅度提升, 实际生产中需要尽量将紧实率与剪切强度范围控制在上述范围以外。

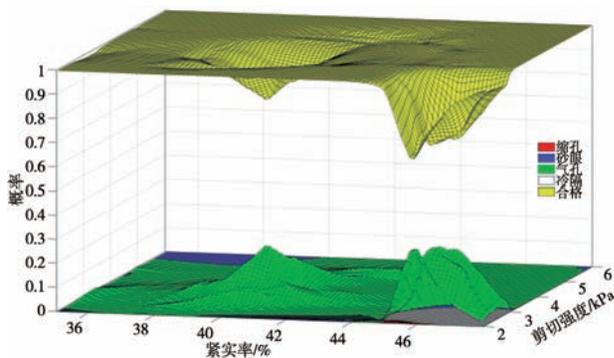


图8 双因素(剪切强度-紧实率)对缺陷规律的分析

Fig. 8 Analysis of defect rule by two factors (shear strength and compaction rate)

C含量与Mg含量耦合影响下的缺陷形成概率如图9所示, 其中冷隔缺陷在较高的C含量下会有较大的概率出现, 这与前述的单因素分析是吻合的, Mg含量在此情况下基本没有可以优化的空间, 而Mg含量在大于0.05%的范围内也会增大缩孔缺陷出现的概率, 以上两种缺陷的出现基本都属于单因素作用下的结果, C含量和Mg含量的耦合作用效果可以忽略不计。

浇注温度与孕育量耦合影响下的缺陷形成概率如图10所示, 当孕育量的范围在(20, 70), 并且浇注温度在1 390 ℃以上时, 铸件成形质量没有问题, 但越过该范围后, 会集中出现气孔和冷隔缺陷, 当温度低

于1 390 ℃时主要以冷隔缺陷为主, 而当孕育剂过量时, 主要以气孔缺陷为主。

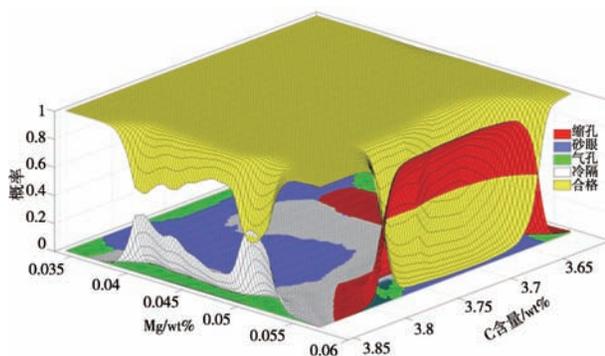


图9 双因素(C-Mg)对缺陷规律的分析

Fig. 9 Two-factor (C-Mg) analysis of defect rule

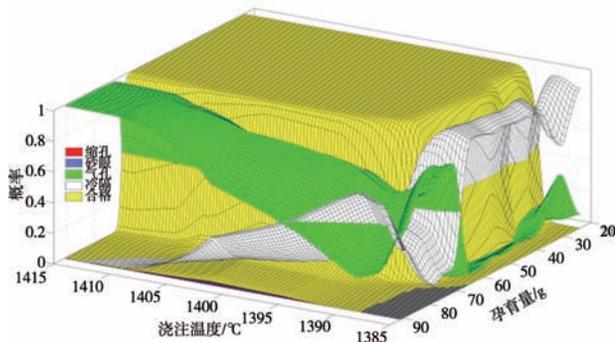


图10 双因素(浇注温度-孕育量)对缺陷规律的分析

Fig. 10 Analysis of defect rule by two factors (pouring temperature - inoculation amount)

### 3 结语

针对砂型铸造过程中缺陷预测困难、工艺质量数据类别不平衡等问题, 提出了一种基于特征重分布与代价敏感学习的卷积神经网络缺陷预测方法; 采用特征重分布对特征向量进行重新排列, 提升了模型对弱相关特征组合效果的捕获能力; 根据样本类别的分布比例为模型的损失函数附加了代价敏感正则项, 减轻了模型对多数类的“偏袒”; 经测试证明, 所构建的FR-CS-CNN模型的缺陷预测精度达到了93.67%, 相比全连接神经网络模型提升了7.57%, 相比卷积神经网络模型提升了2.96%; 最终基于已有模型总结分析了基于FR-CS-CNN模型重要工艺参数对缺陷演变规律的影响。

## 参考文献:

- [1] 赵岩. 立足新时代新型工业化发展 构建“十四五”新一代信息技术与制造业融合标准体系 [J]. 新型工业化, 2023, 13 (Z1): 18-22.
- [2] 周建新, 计效园, 殷亚军, 等. 精铸企业数字化智能化铸造技术研究与应用 [C]//全国各省区市机械工程学会, 云南省机械工程学会. 2015年第五届全国地方机械工程学会学术年会暨中国制造2025发展论坛论文集. 2015: 734-746.
- [3] 周建新. 数字化智能化铸造技术及应用 [C]//中国机械工程学会, 铸造行业生产力促进中心. 2018中国铸造活动周论文集. 2018: 602.
- [4] 王辉, 王季叶, 张梅涛, 等. 铸造行业数字化转型打造数字孪生工厂 [J]. 铸造设备与工艺, 2021 (6): 37-40.
- [5] 张立波. 中国特色铸造产业集群(园区)之路 [C]//中国铸造协会. 中国铸造行业第七届高层论坛论文(摘要集). 2015: 281.
- [6] 谷振宇, 何仪, 李东洋. 基于数字孪生的铸造工艺过程环境影响评价方法 [J/OL]. 中国机械工程: 1-13 [2023-04-20].
- [7] 张明珠, 计效园, 周建新, 等. 砂型铸造企业熔炼批量计划与调度模型及求解方法 [J]. 铸造, 2018, 67 (5): 414-419.
- [8] 豆义华, 计效园, 周建新, 等. 基于层次分析法与数据挖掘的砂铸工艺自评价模型及应用 [J]. 铸造, 2017, 66 (12): 1299-1303.
- [9] 周建新, 殷亚军, 计效园, 等. 熔模铸造数字化智能化大数据工业软件平台的构建及应用 [J]. 铸造, 2021, 70 (2): 160-174.
- [10] NORMANTON A S, BARBER B, BELL A, et al. Developments in online surface and internal quality forecasting of continuously cast semis [J]. Ironmaking & Steelmaking, 2004, 31 (5): 376-382.
- [11] HORE S, DAS S K, HUMANE M M, et al. Neural network modelling to characterize steel continuous casting process parameters and prediction of casting defects [J]. Transactions of the Indian Institute of Metals, 2019, 72 (12): 3015-3025.
- [12] KIM J, LEE J Y. Development of a cost analysis-based defect-prediction system with a type error-weighted deep neural network algorithm [J]. Journal of Computational Design and Engineering, 2022, 9 (2): 380-392.
- [13] 豆义华. 基于BP神经网络的发动机铸铁件断芯诊断模型及应用 [D]. 武汉: 华中科技大学, 2018.
- [14] 张龙, 胡燕青, 赵丽娟, 等. 多通道信息融合与深度迁移学习的旋转机械故障诊断 [J/OL]. 中国机械工程: 1-12.
- [15] 刘阳, 郜志英, 周晓敏, 等. 工业数据驱动下薄板冷轧颤振的LSTM智能预报 [J]. 机械工程学报, 2020, 56 (11): 121-131.

## Casting Process Data-Driven Defect Prediction for Construction Machinery Castings

LIU Ying-hui<sup>1</sup>, YU Peng<sup>1</sup>, PAN Xu-zheng<sup>1</sup>, ZHU Shou-qin<sup>2</sup>, JI Xiao-yuan<sup>1</sup>, WU Lai-fa<sup>2</sup>, YIN Ya-jun<sup>1</sup>, SHEN Xu<sup>1</sup>, XIE Ming-guo<sup>2</sup>, ZHOU Jian-xin<sup>1</sup>

(1. State Key Laboratory of Material Processing and Die & Mould Technology, Huazhong University of Science and Technology, Wuhan 430074, Hubei, China; 2. Hefei Casting and Forging Factory, Anhui Heli Co., Ltd., Hefei 230022, Anhui, China)

### Abstract:

Directing at the problems of difficult to find defect cause, and category imbalance of technical data during sand casting process, a convolutional neural network defect prediction method based on feature redistribution and cost sensitive learning was proposed to solve the defects in sand casting process. Firstly, according to the feature correlation of samples, the sequence of feature vectors is optimized. Secondly, the cost sensitive regular term is designed based on the unbalanced process data sample, and the model loss function is modified. Finally, a defect prediction model (FR-CS-CNN) is constructed. The test results show that the overall prediction accuracy of FR-CS-CNN constructed in this study reaches 93.67%, which is 2.96% higher than that of convolutional neural network.

### Key words:

sand casting; defect prediction; cost-sensitive learning; convolutional neural networks