基于TransUNet模型的铝合金压铸缺陷X射线检测研究

韩 伟[1] 柯世金[1] 杨 安[2] 黄凌森[1] 程得洋[2]
（1. 广州城市理工学院机械工程学院，广州 510800；2. 贵州蓝辉新材料有限公司，遵义 563000）

摘 要 针对铝合金压铸缺陷X射线图像传统人工阅片的低效和漏检等问题，基于改进的TransUNet模型定制开发X射线压铸缺陷图像自动快速检测系统。运用模型进行图像去噪、分割和缺陷特征提取，并嵌入Transformer注意力机制和多层感知序列，提高模型识别压铸件X射线图像中的气孔、缩松和偏析等缺陷的检测精度。通过Transformer对所有图像网格的各种权重值进行查询，对缺陷区域的孔隙率和缺陷面积进行精确计算，以及通过记录每个训练轮次的训练损失和缺陷预测概率，对模型的训练效果和进度进行监控，并运用类别平均像素准确率mPA和平均交并比MIou检查评价缺陷识别情况。以流水线快速通过方式检测全部压铸件的内部组织并同步进行缺陷检测标注，实现全面的压铸件内部凝固结晶质量数字化管控。

关键词 X射线图像；检测精度；孔隙率；缺陷面积；评价指标
中图分类号 TG244；TG249.2；TP311 **文献标志码** A DOI：10.15980/j.tzzz.T20250459

X-ray Detection of Aluminum Alloy Die-casting Defects Based on TransUNet Model

HAN Wei[1], KE Shijin[1], YANG An[2], HUANG Lingsen[1], CHENG Deyang[2]
(1. School of Mechanical Engineering, Guangzhou City University of Technology, Guangzhou 510800; 2. Guizhou Lanhui New Materials Co., Ltd., Zunyi 563000)

Abstract: In response to the inefficiency and missing detection associated with traditional manual review of X-ray images of aluminum alloy die-casting defects, an automated and rapid detection system for X-ray die-casting defect images was custom-developed based on an improved TransUNet model. The model was applied for image denoising, segmentation, and defect feature extraction, and Transformer attention mechanism as well as multi-layer perceptron sequences were integrated to enhance the detection accuracy of gas pores, shrinkage porosity, and segregation in die-casting X-ray images. Q, K, and V weight values were queried for all image grids via Transformer to accurately calculate the porosity and defect area in defect regions. Additionally, the training effect and progress of the model were monitored by recording the training loss and defect prediction probability for each training epoch. Moreover, mean pixel accuracy (mPA) and mean intersection over union (MIou) were utilized to evaluate defect recognition performance. The internal structure of all die-castings was examined by pipeline rapid throughput approach, and defect detection annotation was simultaneously carried out to achieve comprehensive digital management of internal solidification and crystallization quality of die-castings.

Key Words: **X-ray Images, Detection Accuracy, Porosity, Defect Area, Evaluation Metrics**

随着新能源汽车一体化压铸技术的发展，铝合金压铸件承担了更多受力或耐热功能，对压铸件内部凝固组织和力学性能指标的要求也越来越严苛[1]。随着数字化技术和图像识别技术的快速发展，采用数字化X射线技术对铸件内部进行无损检测已经得到广泛使用，高精度实时成像X射线检测能对铸件各个方向的内部断层进行扫描以获得清晰图像，实现对复杂金属零件内部缺陷和凝固质量的检测。但传统的压铸件X射线检测图像处理需要结合人工阅片，多数企业采用抽检铸件或者少数试样检测的方式，容易导致漏检、误检以及疲劳等人为因素产生错误判读等，因此不利于铸件内部质量的及时反馈和全面管控。近年来，深度学习在缺陷检测领域取得了显著进展。杜旺哲等[2]提出基于多任务分割的压铸件X射线图像检测方法，吴

收稿日期：2025-12-12；**修订日期**：2026-05-19
基金项目：广东省教育厅2025年创新团队建设资助项目（2025KCXTD059）；2024年广东省普通高校青年创新人才类资助项目（2024KQNCX100）
第一作者：韩伟，男，1963年出生，正高级实验师，E-mail：1786891960@qq.com
通信作者：柯世金，男，1989年出生，实验师，E-mail：375735074@qq.com
引用格式：韩伟，柯世金，杨安，等. 基于TransUNet模型的铝合金压铸缺陷X射线检测研究[J]. 特种铸造及有色合金，2026，46(11)：1 610-1 616.
HAN W，KE S J，YANG A，et al. X-ray detection of aluminum alloy die-casting defects based on TransUNet model[J]. Special Casting & Nonferrous Alloys，2026，46(11)：1 610-1 616.

楚澔等[3]研究了基于特征提取算法的铝铸件X射线探伤图像缺陷评级系统。LIN J H等[4]较早将深度卷积神经网络应用于铸件缺陷检测，验证了CNN在缺陷分类任务中的有效性。HAI C等[5]针对铝铸件X射线图像低对比度和噪声问题，提出了增益自适应多尺度Retinex（GAMSR）增强算法，并将特征金字塔网络（FPN）与卷积块注意力模块（CBAM）相结合，同时采用加权感兴趣区域池化（W-RoI池化）消除区域错位，显著提升了小气孔缺陷的检测精度。针对X射线图像中缺陷与背景对比度低、缺陷空间位置随机、形状和纵横比不规则等挑战，CHENG J D等[6]提出了自适应全局动态检测Transformer（AGD-DETR）框架，通过多注意力金字塔特征细化模块融合多尺度缺陷特征，并设计全局动态感受野融合Transformer实现复杂缺陷的全局感知与动态特征提取。WANG S等[7]进一步针对铸件射线检测中缺陷边界模糊、图像可见度低及缺陷尺度不规则等问题，提出了空间交叉双注意力金字塔视觉Transformer检测器（SDA-PVTDet），通过差分窗口级联多头自注意力和全局感知多头自注意力模块建模长短程空间交互，并利用特征回流金字塔网络实现随机缺陷分布下的多尺度特征融合。

尽管上述研究取得了积极进展，但仍存在以下问题：第一，现有方法多聚焦于缺陷的分类或定位，对缺陷区域的孔隙率和缺陷面积等定量指标的计算能力不足，难以实现压铸件内部质量的数字化定量管控；第二，压铸缺陷图像中缺陷尺度差异大、微小缺陷易丢失的问题仍未得到有效解决，尤其是在低对比度X射线图像中，传统卷积神经网络及部分Transformer模型对微小缺陷的特征响应仍不够敏感。

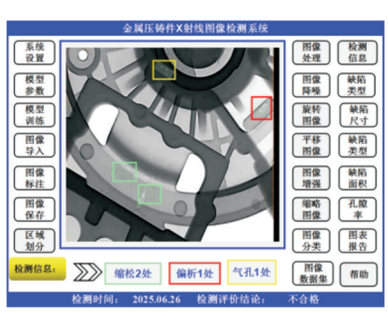
针对压铸件缺陷图像中缺陷尺度差异大、微小缺陷易丢失等问题，以及需要对缺陷区域的孔隙率和缺陷面积进行精确计算，以实现压铸件内部质量的数字化定量管控，仍是当前研究的薄弱环节。因此，某公司在建立多样化的金属压铸件X射线缺陷图像数据集的基础上，采用U-Net架构为骨干网络并引入Transformer结构，提出运用Transformer多头注意力机制对压铸缺陷特征进行权重编码的计算模型，再通过softmax分类函数遍历所有X射线图像网格，查询每个网格图像的不同权重值，精确计算缺陷区域的孔隙率和缺陷面积。同时，设计流水线快速通过方式检测全部压铸件的X射线图像内部组织，同步进行缺陷检测、分类识别和标注[2]。模型经过试用和调整，已经在企业进入压铸件逐个检测和缺陷标注的使用阶段，并达到了85%以上的平均精度，实现对铝合金压铸件内部质量的数字化全面管控。

1　通过式X射线图像检测系统组成及流程

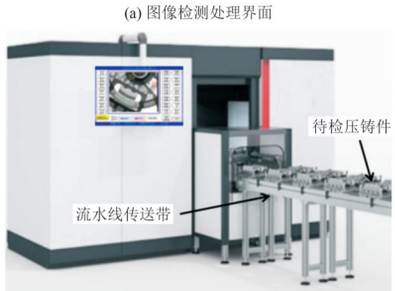
铝合金压铸过程中由于模具设计不合适、浇排系统布局不合理或工艺参数设计不当等影响，造成铝合金压铸件内部产生气孔、缩孔、偏析和缩松等缺陷。随着企业对产品质量要求的不断提高，需要对全部压铸件内部组织进行X射线扫描检测，避免不合格铸件在机加工之后才发现内部缺陷造成的成本浪费和质量问题。

1.1　通过式X射线图像检测系统组成

使用传统的X射线图像灰度阈值和边缘检测方式对压铸件内部进行检测时，需要通过图像增强、二值化和阈值分割等技术，耗费较长的检测判断工作流程时间。常常要增加人工阅片进行判别分析，而人工阅片对于压铸件内部模糊缺陷判断能力有限，无法对铸件内部缺陷的孔隙率和缺陷面积等进行计算，容易造成错误判别和漏检且效率低下。另外，传统的抽检方式只能对部分铸件进行内部检测，不利于铸件内部成形质量的全面管控[3]。随着人工智能的快速发展和推广应用，采用网络模型进行铸件内部缺陷自动检测得到重视。因此研究根据压铸行业质量提升目标，尤其针对新能源汽车铝合金压铸件大批量生产的快速通过式检测需要，基于TransUNet算法模型定制设计了X射线图像智能检测系统，见图1。该系统由X射线图像检测设备、传送装置和基于TransUNet模型的API控制系统组成。铸件按照一定的时间节拍逐次通过X射线



(a) 图像检测处理界面



(b) 流水线通过式X射线检测设备

图1　流水线通过式X射线检测设备及系统界面

Fig.1　X-ray inspection equipment by pipeline rapid throughput approach and system display

检测产生图像，由API控制系统自动阅片并生成检测结果。对全部压铸件进行流水线通过式X射线检测，设备及系统界面能快速准确地发现压铸件内部的气孔、缩松、缩孔和偏析等缺陷。

1.2　图像检测系统设计流程

运用TransUNet神经网络模型进行X射线检测的开发过程，首先运用Label Studio图像标注软件工具构建各类金属压铸件X射线图像的数据集，广泛收集、定义和标注各种压铸件X射线缺陷图像样本，再在Label Studio自动标注软件中进行图像编辑、裁剪和标注等操作。其中包括各种形状的压铸件内部缩松、气孔和偏析等缺陷图像，并将图像分成训练集和测试集。同时根据压铸件内部缺陷的典型类型和图像检测精度要求，运用Pytorch构建U-Net模型网络架构，并嵌入Transformer构成改进的TransUNet模型架构，定制设计图像快速检测和自动标识缺陷的模型，然后将模型进行训练、测试和调整，提高模型的检测精度和速度，具体设计流程见图2。

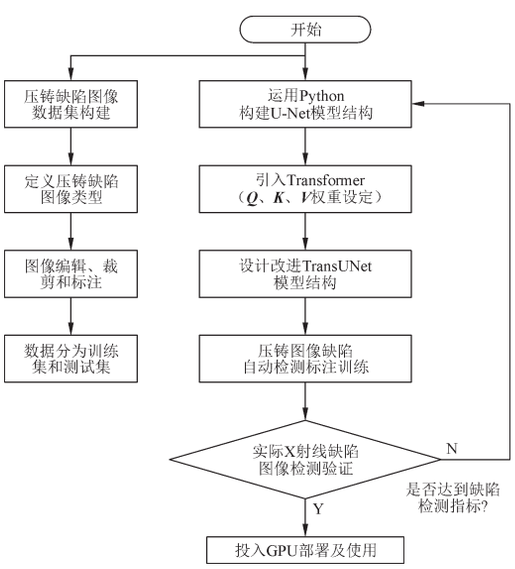


图2　基于TransUNet模型定制X射线图像检测系统设计流程

Fig.2　Design workflow of customized X-ray image inspection system based on TransUNet model

2　压铸件内部缺陷分析及模型架构设计

经过改进的TransUNet模型通过端到端的连续跳跃编码和解码，在进行图像降噪的基础上，通过Transformer注意力机制对所有图像网格的$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$权重值高精度遍历检索，能够快速准确识别图像的微小缺陷，并对缺陷区域的孔隙率和缺陷面积进行精确计算，从而实现压铸件内部缺陷图像的数字化精确分割识别。

2.1　压铸内部缺陷分析及数据集构建

在铝合金压铸充型及凝固成形过程中，注入模具型腔的金属液如未能及时获得足够的补充，则会在壁厚不均匀局部形成不规则立体细小缩孔，相互连接后成为内壁粗糙并带有树枝状晶粒的疏松组织。这些缩孔或缩松缺陷往往出现在铸件最后凝固的部位，其X射线图像呈现黑色带状、云雾状及海绵团状。其次，压铸时金属液高速进入型腔过程中会卷入部分气体，如果浇排系统布局不合理以致未能及时排出气体，剩余气体会残留于凝固零件中形成气孔[8]，其X射线图像为具有一定尺寸的圆形或椭圆形黑点，呈现单个或链状分布。还有较少出现的偏析和冷隔等缺陷，偏析缺陷是金属液成分不均匀而导致的局部结晶析出，其图像一般表现为较模糊的云雾状或棉花状白色团簇状图像。图3为典型铝合金压铸件内部缺陷部分图像数据，包括铝合金压铸的气孔、缩孔和偏析的分类识别标注。这些位于压铸件内部的缺陷容易对铸件结构功能造成损害，因此需要在压铸成形后及时检测内部是否存在缺陷[9]。

为保证模型广泛学习各类压铸内部缺陷特征，开发前期收集了1 000份铝合金压铸件的X射线图像，将

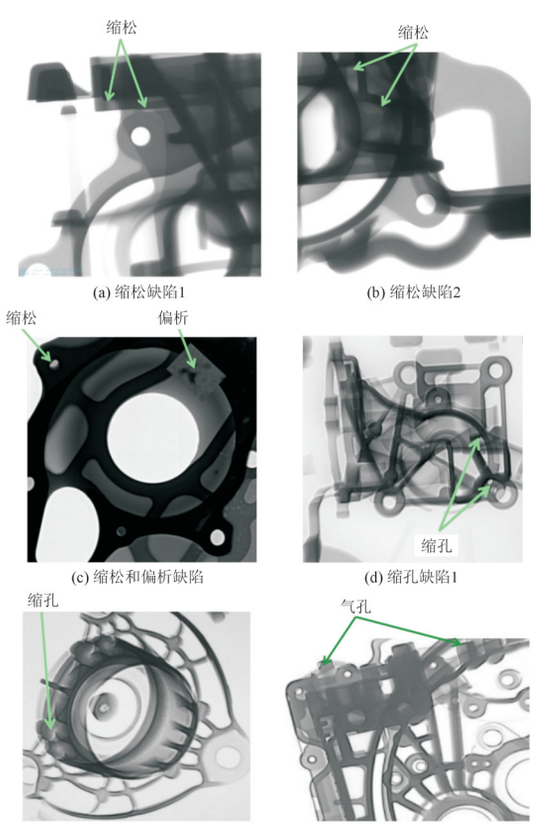


图3　压铸缺陷样本数据集的预处理标注

Fig.3　Preprocessing annotation of die-casting defect sample dataset

图像处理转换为640×640像素，再对训练集图像典型缺陷进行人工标注，按照6∶3∶1将压铸缺陷图像划分为训练集、测试集、验证集[10]。其中，气孔样本为280张，缩松样本为260张，缩孔样本为230张，偏析样本为230张，各类缺陷样本分布涵盖不同尺寸、形状和位置，确保模型训练的多样性和泛化能力。然后对图像进行旋转、翻转、缩放和添加噪声等处理操作，得到不同视角和大小各异的缺陷图像，使模型能够检测不同金属材料压铸缺陷类型，提高模型的准确性和适应各种压铸件的泛化能力。最后将文件转为JPEG格式方便TransUNet模型读取，并创建对应类型数据集的存放目录[11]。

2.2　基于TransUNet的图像处理模型构建

作为卷积神经网络图像分割网络的一种，传统的U-Net具有较强的局部图像细节特征提取和空间定位能力，但同时存在卷积运算的局限性，对压铸件的X射线大尺度图像全局信息建模不足。因此在传统U-Net模型的U形基础上，将CNN和Transformer结合起来组成TransUNet，引入混合编码器进行压铸件X射线图像缺陷检测任务定制化试验，见图4。底层编码器由左边连续的3×3卷积层组成，使用U-Net的CNN提取压铸缺陷的局部细节特征。高层编码器使用Transformer的SW-MSA模块滑动窗口功能将输入图像划分为一系列的局部窗口，SW-MSA模块对输入的图像进行滑动窗口操作并提取全局所有空间特征。与此同时嵌入Transformer多层感知MLP模块，注意力机制x_p^1, x_p^2, …, x_p^n多层感知序列矩阵，将捕捉到的信息进行非线性变换和处理，其中X、H、W分别为特征序列、卷积块高度和宽度[12]。计算每个窗口内部位置的图像单元权重编码，实现复杂语义理解和区分是否为缺陷的逻辑推理判定。并由多层感知MLP模块将窗口内的特征进行全连接层线性变换，通过ReLU激活函数增加网络非线性表达能力，然后经过U-Net模型右边连续的3×3卷积层解码器进一步提取和分割缺陷特征，逐步恢复空间分辨率，将压铸缺陷特征以更高精度凸显出来并生成分割图像，输出对比度清晰的全局信息图像[13]。

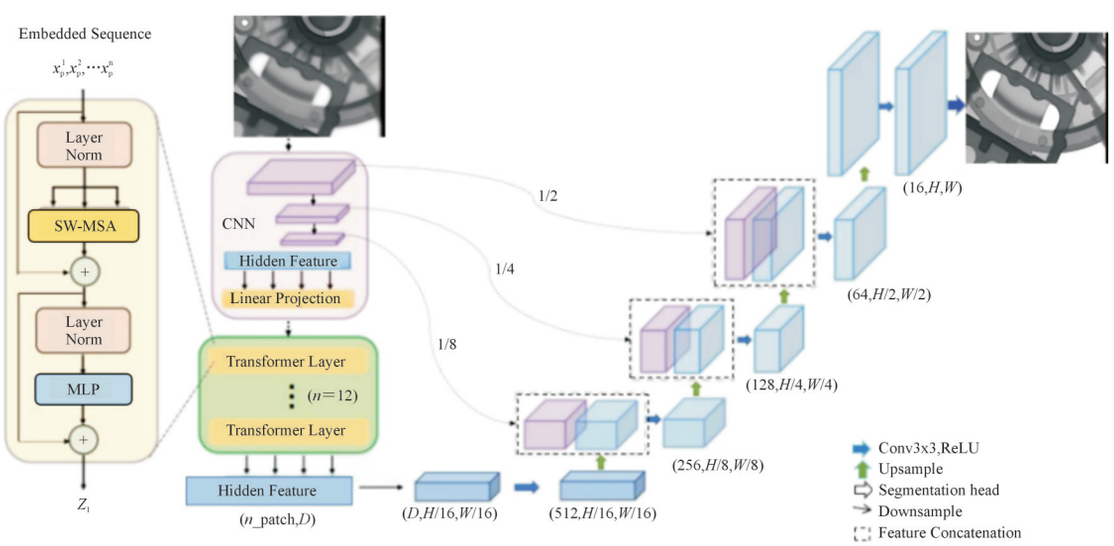


图4　改进的TransUNet的X射线图像处理模型架构

Fig.4　Architecture of improved TransUNet model for X-ray image processing

检测时由Transformer通过给定的特征向量$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$权重区分每个像素网格位置的语义分割图像信息，通过注意力计算表达的对缺陷特征向量$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$权重关系式为：

$$A_{\text{ttention}}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=S_{\text{oftmax}}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^T}{\sqrt{d}}\right)\boldsymbol{V} \tag{1}$$

式中，$\boldsymbol{Q}$（Query）特征向量描述在图像数据序列中需要关注的缺陷内容；$\boldsymbol{K}$和$\boldsymbol{V}$则分别是缺陷特征的键矩阵（Keys）和值（Values）。设计时通过Pytorch进行模型创建和TransUNet函数定义，在导入torch库及所有的层之后，进行卷积嵌入和缺陷特征卷积映射设计[14]。设定输入特征图大小为$C\times H\times W$的基础卷积块结构，再平铺成$(H\times W)\times C$大小的张量并进行归一化操作。然后进行卷积映射操作，对特征图分别进行3个深度可分离卷积，输入改进后的多头注意力Multi-Headed Attention模块，然后将$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$向量分别切分为h组进行计算为：

$$\boldsymbol{q}_i=\boldsymbol{q}w_i^q,\boldsymbol{k}_i=\boldsymbol{k}w_i^k,\boldsymbol{v}_i=\boldsymbol{v}w_i^v,i=1,\cdots,h \tag{2}$$

式中，x_i^q,x_i^k,x_i^v为卷积变换时的感知序列矩阵，对每组

$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$向量进行相似度计算得到权重。在此过程加入压铸缺陷特征和相对位置信息，将每种缺陷图像特征像素的注意力分解，分别添加位置编码进行分类头的预测概率定义，其计算公式为：

$$y = S_{\text{oftmax}}(Wx + b) \tag{3}$$

式中，W为分类头的权重矩阵；b为偏置项；y为分类结果。通过softmax分类函数对压铸缺陷类型进行3个维度方向的矩阵乘法运算和区分重塑，得到各种缺陷类别对应的预测分布数据，通过颜色框自动区分标注缺陷的类型，运用多头注意力机制Mutli-Headed Attention模块的检测结果标识输出见图5。

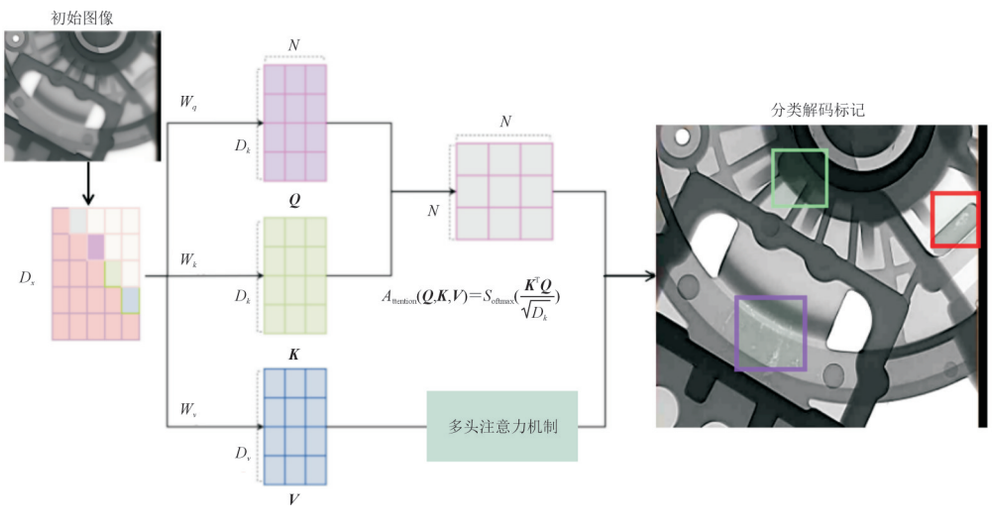


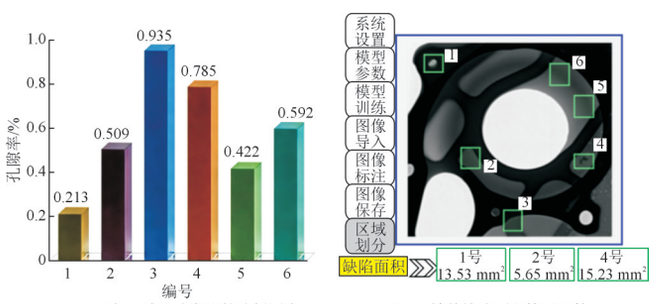
图5　多头注意力模块区分标注缺陷示意图

Fig.5　Schematic diagram of defect discrimination via multi-head attention module

模型通过遍历每个网格图像的$\boldsymbol{Q}$、$\boldsymbol{K}$和$\boldsymbol{V}$权重值查询方法后，将所有检测的网格自动区分为缺陷部分与正常压铸凝固组织，对X射线图像进行高精度的孔隙率计算。孔隙率(P)为铸件内部组织中孔隙体积占检测区域总体积的比例，是衡量压铸凝固组织致密度的重要指标，其计算公式为：

$$P = \frac{V_0 - V}{V_0} \times 100\% = (1 - \frac{\rho_0}{\rho}) \times 100\% \tag{4}$$

式中，V_0为材料在自然状态下的体积，mm^3；ρ_0为材料表观密度，g/cm^3；V为材料的绝对密实体积，mm^3；ρ为材料密度，g/cm^3。根据式(4)，在模型检测时同步进行各区域的网格检测计算，并根据检测需要生成选定区域的孔隙率直方图对比表，以及缺陷面积大小的计算标注，见图6。图6a中，运用套索工具对1号、2号、4号3个缺陷进行面积计算，以及图6b中的6个重点检测区域进行孔隙率计算。通过对各区域孔隙率的可视化数据分布比较和缺陷面积数值，能更详细了解压铸过程金属液充型凝固情况，为压铸模具结构、温度和压力控制等工艺优化提供数字化依据[14]。



(a) 1～6各区域孔隙率比较分析图表　(b) 压铸件缺陷面积检测计算

图6　局部区域孔隙率分析及缺陷面积计算

Fig.6　Localized porosity analysis and defect area calculation

3　模型的训练和评价

针对铝合金压铸件缺陷类型较多的特点，在完成TransUNet模型的定制设计后，需要使用Python分别进行缺陷的图像分类处理训练，才能使系统建立从局部到图像全局的缺陷特征分类、标识和判断输出。同时为确保图像分割识别的效果可靠，采用平均像素准确率mPA和平均交并比MIou检查评价缺陷识别效果。

3.1　模型的训练及超参数优化

训练过程在64 GB内存的Intel i5处理器的GPU单元中进行，使用Python 3.8版本。为验证超参数设置的合理性，首先进行了超参数寻优试验。以验证集上的平均像素精度(mPA)和平均交并比(MIou)为指标，分别考察不同学习率、batch size和迭代轮次的影响。

（1）学习率　对比0.1、0.01、0.001三个数量级。0.1导致损失震荡不收敛；0.001收敛速度过慢，200轮时mPA仅为84.8%；0.01在收敛速度与最终性能上取得最佳平衡，200轮达到86.1% mPA。

（2）Batch size　测试4、8、16。batch size为4时训练不稳定，损失波动较大；16时模型泛化能力下降（验证集mPA为85.3%）；8时训练过程最稳定，验证集与训练集性能差距最小。

（3）迭代轮次　训练至300轮观察，200轮后损失曲线趋于平缓，继续增加轮次带来的提升小于0.3% MIou，故选择200轮以兼顾性能与效率。

最终采用Adam优化器，初始学习率设定为0.01，权重衰减为0.000 5，损失函数采用交叉熵损失与Dice损失的组合，以平衡类别不平衡问题。Batch size设为8，迭代轮次为200轮，每10轮保存一次模型[15]。数据增强方式包括随机旋转（−30°至30°）、水平翻转、垂直翻转、随机缩放（0.8～1.2倍）、添加高斯噪声等。根据气孔、缩松、缩孔和偏析等各种缺陷图像的不同特征样本图像，用Mask模块进行多通道初始化掩码，每种缺陷设置一个通道分别加载对应的掩码，以便于进行Sigmoid激活函数的多标签分割训练[16]，其中部分训练过程见图7。

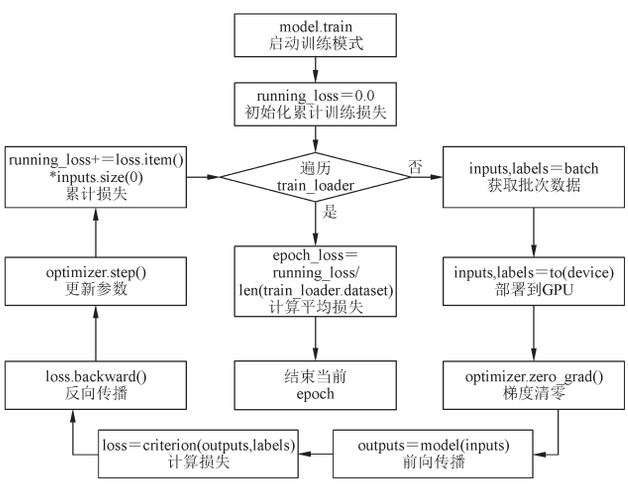
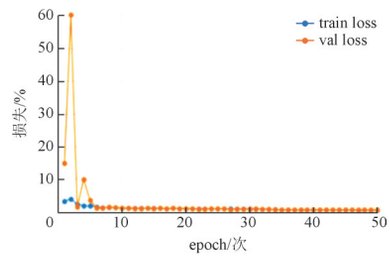


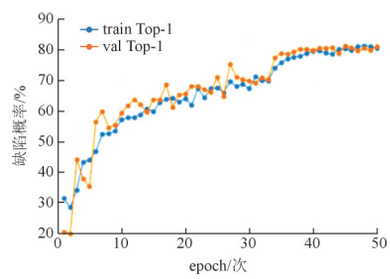
图7　模型训练过程

Fig.7　Model training process

图7中epoch为模型在训练过程遍历全部压铸缺陷样本数据集一次的过程，loss则为训练损失。通过记录每个epoch的训练损失和缺陷预测概率，可以监控模型的训练效果和进度[17]，持续进行模型性能优化，见图8。图8a的训练损失loss持续下降，说明训练过程epoch是有效的。图8b的Top-1是指最多缺陷类型准确率，表明经过训练过程对概率最高的缺陷类别正确程度不断提高[18]。



(a) 训练损失loss持续下降图表



(b) Top-1缺陷准确率图表

图8　训练损失loss图表和Top-1缺陷预测概率图表

Fig.8　Training loss and Top1 defect prediction probability curves

3.2　消融试验

为验证各改进模块的有效性及其协同增益效果，设计了消融试验与模块组合试验，分别组合以下3个模块：多头注意力优化（MA）、多尺度特征融合（MS）、损失加权策略（LW）。评价指标采用mPA（平均像素精度）和MIou（平均交并比），后者是图像分割领域的核心评价指标，结果见表1。可以看出，完整改进型的性能最优，mPA较原生TransUNet提升了2.5%，MIou提升了3.15%。此外，与其他图像检测模型如YOLOv或VGG16等相比，改进型TransUNet模型具有更高的精度及灵活性等优点，方便在GPU进行FPGA并行流水线的协同加速部署。还可以使用Class-Balanced Weights类平衡权重，以及在损失函数中使用defect weights缺陷权重调整进行优化，从而拓宽模型适应其他类型金属压铸内部缺陷检测的分类辨识精度能力。

表1　消融试验及模块试验结果

Tab.1　Results of ablation and module experiments

序号	模型配置	mPA/%	MIou/%
1	原生TransUNet	84.3	82.6
2	＋多头注意力优化	85.2	83.9
3	＋多尺度特征融合	84.8	83.3
4	＋损失加权策略	85.0	83.7
5	＋多头注意力优化＋多尺度特征融合	85.6	84.4
6	＋多头注意力优化＋损失加权策略	85.9	84.8
7	＋多尺度特征融合＋损失加权策略	85.5	84.2
8	完整改进模型	86.1	85.2

设计过程通过对新能源汽车电动机壳压铸件的X射线检测图像标注精度进行验证，TransUNet定制模型达到mPA为86.1%和平均交并比MIou为85.2%的精

度。为进一步验证模型性能，在相同数据集下将改进 TransUNet 与原生 TransUNet、U-Net、SegNet、DeepLabV3＋等主流分割模型进行对比，结果见表 2。

表 2　不同模型在压铸缺陷检测任务上的性能对比

Tab.2　Performance comparison of different models on die-casting defect detection task

序号	模型	mPA/%	MIou/%	推理时间/(ms·帧$^{-1}$)
1	U-Net	81.2	79.5	72
2	SegNet	79.8	77.3	68
3	DeepLabV3＋	83.5	81.7	95
4	原生 TransUNet	84.3	82.6	88
5	改进 TransUNet	86.1	85.2	86

改进的 TransUNet 模型明显优于其他对比模型，系统的单帧推理延时达到 86 ms，能够在 3 min 之内完成铝合金电动机壳等压铸件的快速 X 射线检测，并在不同结构尺寸、不同壁厚的其他铝合金压铸件上开展了泛化性能测试，都得到了与上述数据相似的指标结果，证明改进的 TransUNet 模型能满足对常见铝合金压铸件进行流水线通过式内部检测的需求。

4　结　论

（1）采用智能算法模型对所有压铸件进行流水线通过式 X 射线图像检测，才能避免传统抽检方式的漏检和错检现象，满足压铸行业不断提升的质量目标。

（2）基于 TransUNet 算法强大的特征提取和图像分割能力。可以快速进行压铸件内部 X 射线图像的缺陷识别及分类标识，并对压铸件各区域的孔隙率和缺陷面积进行精确计算。

（3）通过监控模型训练过程的每个 epoch 的训练损失和缺陷预测概率，可以持续提升优化对缺陷类型的分割识别能力。

参　考　文　献

[1] 陈晓斌，韩伟，颜建，等．低压铸造水冷机壳 X 射线检测图像技术分析与应用[J]．特种铸造及有色合金，2023，43(1)：119-121.

[2] 杜旺哲，刘元铭，牛小淼，等．铝合金压铸件 X 射线图像多任务分割方法研究[J]．特种铸造及有色合金，2025，45(1)：15-22.

[3] 吴楚澔，侯明君，李蒙，等．基于特征提取的铝铸件 X 射线探伤图像缺陷评级技术[J]．特种铸造及有色合金，2024，44(5)：605-613.

[4] LIN J H，YAO Y，MA L，et al.Detection of a casting defect tracked by deep convolution neural network[J]．The International Journal of Advanced Manufacturing Technology，2018，97(1-4)：573-581.

[5] HAI C，WU Y P，ZHANG H，et al.Approach for automatic defect detection in aluminum casting X-ray images using deep learning and gain-adaptive multi-scale retinex [J]．Journal of Nondestructive Evaluation，2024，43(1)：29.

[6] CHENG J D，WANG S，ZHANG B H，et al.A novel framework for low-contrast and random multi-scale blade casting defect detection by an adaptive global dynamic detection transformer[J]．Computers in Industry，2024，162：104 138.

[7] WANG S，CHENG D J，FANG X F，et al.SDA-PVTDet：A spatial-cross dual attention pyramid vision transformer detector for casting defect detection in radiography images[J]．Expert Systems With Applications，2025，269：126 385.

[8] 高东璇，刘占峰，李艳丽，等．汽车无损检测 X 射线源钼铼合金零件加工技术研究[J]．现代制造工程，2019(4)：46-49.

[9] 龚律凯，彭伊丽，陈绪兵，等．基于改进 U-Net 算法的焊缝特征识别研究[J]．现代制造工程，2024(11)：18-25.

[10] 韩伟，廖志青，刘建光，等．视觉控制在低压铸造机器人下芯中的探索应用[J]．现代制造工程，2021(8)：119-124.

[11] 施皓然，孙静宇．基于混合深度学习网络的边缘感知黑色素瘤分割方法[J]．计算机工程与设计，2025，46(6)：1 796-1 802.

[12] 李丽芬，黄如．引入 Transformer 的道路小目标检测[J]．计算机工程与设计，2024，45(1)：95-101.

[13] 李雪梅，郭义华，张鑫，等．基于改进 U-Net 网络的激光条纹提取方法[J]．应用激光，2024，44(9)：133-146.

[14] 陈逢军，吕继阳，胡天，等．基于 U-Net 网络的柱面透镜视觉定位策略[J]．中国机械工程，2023，34(5)：505-514.

[15] 常颖，常大俊．改进型卷积神经网络焊点缺陷识别算法研究[J]．激光技术．2020，44(6)：779-783.

[16] 彭晏飞，孟欣，李泳欣，等．结合坐标注意力与生成式对抗网络的图像超分辨率重建[J]．计算机工程与科学，2024，46(1)：122-131.

[17] 杨崎，张卓然，何嘉．基于改进 U-Net 的卫星图像分割算法[J]．计算机工程与设计，2023，44(6)：1 714-1 720.

[18] 周林，何理，王宸，等．基于改进 U-Net 的小型机械零件识别与定位方法研究[J]．制造技术与机床，2024(2)：91-98.

（编辑：张正贺）

欢迎关注《特种铸造及有色合金》微信公众号矩阵，文章信息、行业研究动态与资讯信息早知道！

特种铸造
（关注铸造及有色合金领域重要研究成果）

压铸界
（压铸领域最新动态及研究）

青稞讲堂
（金属领域青年科学家最新研究成果）

特种铸造及有色合金杂志
（文章动态时刻关注）