

引用格式: 张尊帅, 刘昱含, 郎志远, 等. 基于图像处理的高熵合金图像定量分析技术[J]. 中国材料进展, 2025, 44(7): 622-628.
ZHANG Z S, LIU Y H, LANG Z Y, *et al.* Quantitative Analysis Techniques for High-Entropy Alloy Images Based on Image Processing[J]. Materials China, 2025, 44(7): 622-628.

基于图像处理的高熵合金图像定量分析技术

张尊帅¹, 刘昱含^{1,2}, 郎志远¹, 周生华¹, 杨炯¹

(1. 上海大学 材料基因组工程研究院, 上海 200444)

(2. 上海大学 钱伟长学院, 上海 200444)

摘要: 扫描电子显微镜(scanning electron microscope, SEM)在材料表征领域具有广泛的应用前景, 然而所获得的图像通常难以直接提取定量信息。针对一种共晶高熵合金的扫描电镜图像, 提出了一种基于机器学习和图像分割技术的自动化、定量分析方法, 该方法能够有效测量共晶高熵合金板条状区域的面积、长度、宽度、周长以及不同组分的占比。实验结果表明, 本研究所提出的方法在高熵合金图像上具有良好的鲁棒性和准确性, 为研究高熵合金材料的表面结构提供了重要的技术支持。

关键词: 机器学习; 扫描电子显微镜; 图像分割; 图像处理; 定量分析

中图分类号: TP181; TP391.41; TG139 文献标识码: A 文章编号: 1674-3962(2025)07-0622-07

Quantitative Analysis Techniques for High-Entropy Alloy Images Based on Image Processing

ZHANG Zunshuai¹, LIU Yuhan^{1,2}, LANG Zhiyuan¹, ZHOU Shenghua¹, YANG Jiong¹

(1. Materials Genome Institute, Shanghai University, Shanghai 200444, China)

(2. Qianweichang College, Shanghai University, Shanghai 200444, China)

Abstract: Scanning electron microscopes (SEM) hold broad application prospects in the field of material characterization. However, the images obtained are usually difficult to use for direct extraction of quantitative information. This paper proposes an automated and quantitative analysis method based on machine learning and image segmentation techniques for the scanning electron microscopy images of eutectic high-entropy alloys. The method effectively measures the area, length, width, circumference and proportion of different components in the lamellar regions of eutectic high-entropy alloys. Experimental results demonstrate that the proposed method in this study exhibits good robustness and accuracy on a large scale of high-entropy alloy images, providing significant technical support for studying the surface structures of high-entropy alloy materials.

Key words: machine learning; scanning electron microscope; image segmentation; image processing; quantitative analysis

1 前言

在材料科学研究中, 材料图像的定量分析是理解材料性能和特性的关键步骤。传统的定量分析方法往往面临着一些挑战和困难。首先, 传统手动标注的方法需要大量的人力和时间投入, 且结果往往受到操作者主观因

素的影响, 缺乏一致性和可重复性。其次, 对于一些复杂结构的材料, 如共晶高熵合金, 其微观结构通常非常复杂, 难以使用传统方法进行准确的定量分析。

随着深度学习和图像处理技术的进步, 基于计算机技术的自动化图像处理与分析方法广泛应用在各种类型的材料图像分析中。何春霞等^[1]基于一系列图像处理方法, 开发了一种纳米复合材料扫描电子显微镜(scanning electron microscope, SEM)图像分析系统, 可以对不同尺寸的纳米粒子进行识别和计数。刘亚径等^[2]基于机器学习方法实现了对耐火材料破损区域面积、周长、宽高比的计算。刘欢等^[3]基于滤波、边缘检测等方法提出了一种自动提取焊缝区域并提高焊缝区域对比度的方法。

收稿日期: 2024-04-17 修回日期: 2024-05-23

基金项目: 国家自然科学基金资助项目(52172216, 92163212)

第一作者: 张尊帅, 男, 1995年生, 硕士研究生

通讯作者: 杨炯, 男, 1981年生, 教授, 博士生导师,

Email: jiongy@t.shu.edu.cn

DOI: 10.7502/j.issn.1674-3962.202404021

本研究基于深度学习和图像处理技术提出一种针对共晶高熵合金^[4]电镜图像的分析方法，实现了对不同组分占比以及板条状区域面积、长度、宽度、周长的自动化计算。本研究所提方法具有以下几个显著优点：① 自动化，本方法可以自动处理大量的共晶高熵合金图像，无需人工干预，大大提高了分析的效率和速度；② 准确性，本方法基于深度学习，通过学习和识别复杂的共晶高熵合金图像特征，提高了分析的准确度和可靠性；③ 可重复性，由于方法的自动化特性，分析结果具有较高的一致性和可重复性，不受操作者主观因素的影响；④ 普适性，虽然本方法目前主要针对 AlCoCrFeNi_{2.1} 共晶高熵合金的扫描电镜图像，但也为其他复杂材料结构的定量分析提供了有益的思路和参考，具有一定的可拓展性和适用性^[5,6]。通过本文提出的方法，研究人员可以更加方便地进行共晶高熵合金及其它类型材料扫描电镜图像的定量分析，从而深入探索其微观结构与性能之间的关系。

2 分析方法

本研究所用数据来自于前期论文^[7]，通过场发射扫描电镜(型号 G300, Carl Zeiss, Germany)对 AlCoCrFeNi_{2.1}

样品进行表征。如图 1 所示，蓝色线条包围的部分为板条状区域，板条状区域具有轮廓复杂且长短、面积大小不一的特点。板条状区域的面积、长度、宽度和周长是其特征指标。另外，图 1 中深色区域为 BCC 相，浅色区域为 FCC 相。数据分为用于模型训练的图像(共 65 张，训练集 50 张，验证集 15 张)和用于结果分析的图像(共 242 张)。根据图像的形貌特征，整体处理流程如图 2 所示。




图 1 AlCoCrFeNi_{2.1} 共晶高熵合金扫描电镜图像

Fig. 1 SEM images of AlCoCrFeNi_{2.1} eutectic high-entropy alloy

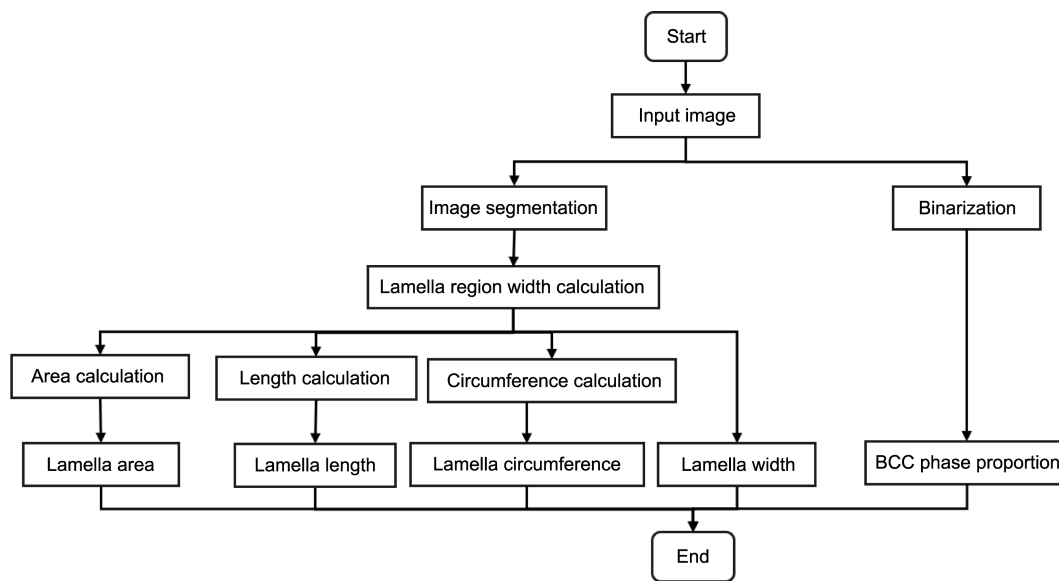


图 2 定量分析计算流程

Fig. 2 Quantitative analysis computational workflow

2.1 图像分割

本研究采用 U-Net 网络进行高熵合金板条状区域的分割。U-Net 是一种用于图像分割的深度学习网络，最初由 Ronneberger 等^[8]于 2015 年提出，现广泛应用在图像分割领域^[9-12]。

2.1.1 模型结构

U-Net 的主要特点是将传统的编码-解码结构与跳跃连接相结合，在保留高分辨率信息的同时提高了语义特征的表达能力。编码器部分，由多个卷积层和池化层组成，用于提取图像的语义特征并逐步降低空间分辨率。

解码器部分,由多个反卷积层和上采样操作组成,用于将编码器产生的低分辨率特征图恢复到原始输入图像的分辨率。跳跃连接部分,解码器的每一级都与编码器对应级别的特征图连接,通过编码器中更低级别的细节信息来帮助解码器更好地还原细节。这种跳跃连接有助于缓解因编码过程中的信息损失而导致的分割结果模糊或不准确的问题。由于编码器负责提取语义特征以及降低空间分辨率,对模型效果影响较大,本研究中对使用不同编码器结构^[13-16]的 U-Net 网络进行了评估,以探索其在高熵合金板条状区域分割任务中的性能表现,并使用性能最好的网络模型用于后续任务。

2.1.2 数据增强

由于原始训练集样本较少,本文通过数据增强操作对其进行扩充。数据增强是深度学习中常用的一种技术,旨在通过对原始数据的变换和扩充,增加模型的泛化能力和鲁棒性。本研究设计了一系列数据增强操作,包括水平翻转、随机平移、缩放和旋转、填充和随机裁剪。最终用于训练的数据集包括两部分,一部分是原始训练数据集 50 张,另一部分是使用数据增强得到的数据集 450 张,共计 500 张。

2.2 宽度计算

对于输入图片(图 3a),宽度计算基于分割模型的输出结果(图 3b)。首先对分割出的板条状区域进行轮廓检测,然后提取板条状区域的骨架并估算出骨架线的法向

量,最后根据轮廓检测的结果、骨架线和法向量计算板条状区域的宽度。

2.2.1 骨架化

本研究使用快速并行细化算法^[17]对图像分割得到的板条状区域进行骨架化处理。该算法能够将板条状区域转换为一系列连接的线条,线条宽度仅为一像素,如图 3d 红色线条所示。

2.2.2 轮廓检测

根据图像分割的结果,本研究使用 Suzuki85 算法^[18]检测板条状区域的轮廓,如图 3e 所示。该算法能够将图像中的连续像素边界转换为一系列坐标点,以描述轮廓的形状和位置。

2.2.3 计算宽度

为了从给定的骨架线点集中、准确地估计法向量,本研究采用基于 KD-Tree^[19]和奇异值分解的方法。首先,将骨架化得到的骨架线点集构建成为 KD-Tree,以便高效地进行空间搜索。对于骨架线点集中的每一个点,使用构建的 KD-Tree 查找其邻域内的 3 个点。接下来,根据这些点,应用奇异值分解,估计出骨架线上点的法向量,图 3f 为每隔 20 个点采样一次的法向量可视化结果。法向量估计的计算流程如下:①输入邻近点集 $\{x_1, x_2, x_3\}$;②计算点集的质心,将每个点减去质心,得到点集矩阵 A ;③ $A = A^T$;④应用奇异值分解, $A = U\Sigma V^T$;⑤ U 的最后一列对应的向量表示数据点变化最小的方向,即法




图 3 指标计算过程示意图: (a)输入图像, (b)分割模型输出, (c)二值化, (d)骨架化, (e)轮廓检测, (f)法向量估计, (g)宽度计算
Fig. 3 Schematic diagram of the metric calculation process: (a) input image, (b) segmentation model output, (c) binarization, (d) skeletonization, (e) contour detection, (f) normal vector estimation, (g) width calculation

向量的估计 normal ; ⑥ 将 normal 的长度归一化为 1。最后, 基于骨架线、法向量和轮廓信息来计算板条状区域的宽度。通过计算骨架线上各点的法向量与板条状区域轮廓的交点之间的距离, 可以得到板条状区域每一点的宽度, 然后进一步计算板条状区域的平均宽度, 完成对整个板条状区域宽度的测量, 图 3g 为每隔 20 个点采样一次的宽度可视化结果。

2.3 二值化

二值化的处理流程为: 首先通过颜色空间转换将原始图像转换为灰度图, 然后使用 3×3 的高斯滤波器对图像进行平滑处理, 以减少噪声的影响, 最后使用全局阈值法进行二值化处理, 将图像转换为黑白二值图像, 阈值设置为图像本身的平均值。如图 3c 所示, 黑色部分即为 BCC 相。

2.4 其他指标计算

基于 2.2.2 节中轮廓检测的结果完成其他指标的计算。面积计算, 利用 OpenCV 中的 $\text{contourArea}()$ 方法对板条状区域的面积进行计算。该方法能够准确地测量板条状区域内部的像素数量, 从而反映出其实际的面积。长度计算, 针对板条状区域的长度, 首先利用 $\text{minAreaRect}()$ 方法计算其最小外接矩形, 矩形较长边的长度即为板条状区域长度。周长计算, 利用 OpenCV 中的 $\text{arclength}()$ 方法对板条状区域的面积进行计算。

3 结果与讨论

3.1 评价指标

为了评估使用不同编码器结构的 U-Net 网络在高熵合金板条状区域分割任务中的性能, 本研究采用以下常用指标进行评估。

(1) 交并比(intersection over union, IoU Score)用于衡量预测结果与真实标签之间的重叠程度, 计算方法是预测区域与真实区域的交集面积除以它们的并集面积, 见式(1):

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (1)$$

(2) 精确度(Precision)用于衡量模型预测为正样本的准确性, 即模型预测为正样本的样本中真实为正样本的比例。计算见式(2):

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

(3) 召回率(Recall)用于衡量模型对正样本的识别能力, 即真实为正样本的样本中, 被模型正确识别为正样本的比例。计算见式(3):

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

(4) F1 值(F1-score)用于综合评价模型的准确性和全面性, 见式(4):

$$F_1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

(5) 准确度(Accuracy)用于衡量模型在整个数据集上的分类准确率, 即正确分类的样本数占总样本数的比例。计算见式(5):

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (5)$$

其中, TP 代表真正例(true positive), 表示模型正确地将正样本预测为正样本的数量。FP 代表假正例(false positive), 表示模型错误地将负样本预测为正样本的数量。FN 代表假负例(false negative), 表示模型错误地将正样本预测为负样本的数量。TN 代表真负例(true negative), 表示模型正确地将负样本预测为负样本的数量。

3.2 分割结果

本研究基于深度学习框架 Pytorch 进行实验, 模型训练和预测在 Windows 10 系统上完成, 具体软硬件配置如表 1 所示。为保持一致, 训练过程中除编码器结构不同外, 所有实验参数均保持相同。批处理大小设置为 8, 训练周期设置为 40, 损失函数为 Dice Loss^[20], 采用 Adam 优化器优化网络模型。

表 2 给出了使用不同编码器的评价指标结果, 综合考虑这些评价指标, 最终选择编码器为 vision_transformer_b2 的 U-Net 网络用于板条状区域分割。

表 1 模型训练软硬件配置环境

Table 1 Model training software and hardware configuration environment

Name	Hardware configuration	Name	Version
Processor	AMD Ryzen 7 3700X CPU	Python	3.8
Graphics card	NVIDIA GeForce GTX 1080Ti 11 GB	Pytorch	1.9
Memory (RAM)	32 GB	CUDA	12.2

3.3 定量计算结果

本研究使用 242 张图像进行分析。对于每张图像, 板条状区域面积和 BCC 相面积通过在图像中所占百分比表示, 宽度、长度与周长均为平均值, 即图像中总的数值除以图像中板条状区域的数量, 指标分布如图 4a~4e 所示。图 4f 展示了测试图像中不同面积的板条状区域的数量分布。为测试准确度, 本文从上述数据中随机选择 6 张图像与使用 Image J 手动标注计算进行比较。在宽度的计算中, 尽管本方法可以沿着骨架线给出每一点处的宽度, 但是这对于手动标注是难以实现的, 因此对于宽

表 2 不同编码器结构在 15 张验证集图像上的实验结果

Table 2 Experimental results of different encoder structures on the verification set (15 images)

No.	Encoder structure	IoU score/%	Precision/%	Recall/%	F1-score/%	Accuracy/%	Model size/MB
1	vgg13	77.1	94.3	80.9	87	80.7	70
2	vgg16	78.8	94.6	82.5	88.1	82.1	91
3	resnet34	84.5	93.3	89.9	91.6	86.7	93
4	resnet50	85.6	92.3	92.3	92.3	87.6	124
5	vision_transformer_b0	77.9	95.9	80.6	87.6	81.6	21
6	vision_transformer_b2	85.7	92.5	92.1	92.3	87.7	105
7	efficientnet-b0	72.9	79.9	89.2	84.3	73.3	24
8	efficientnet-b5	76.7	92.4	81.8	86.8	80	120

度, 每张图随机选择了 10 个点进行标注, 如图 5 所示。为准确反映定量计算的准确度, 手动标注也以分割模型的输出结果为基础。由表 3 至表 7 可知, 本方法与人工

标注相差不大, 面积计算准确度误差在 2% 以内, 平均长度误差在 5% 以内, 平均宽度误差在 8% 以内, 平均周长误差在 4% 以内, BCC 相占比误差在 4% 以内。

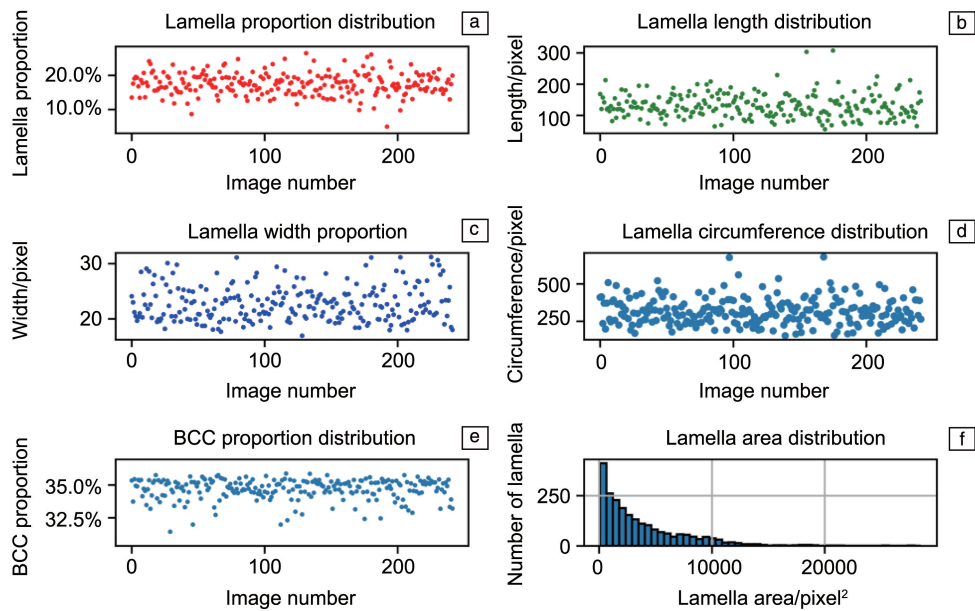


图 4 242 张图像不同指标的分布

Fig. 4 Distribution of different indicators in 242 images




图 5 计算结果示意图(黄色线条为轮廓检测的结果, 红色数字为两个蓝色点处的板条状区域宽度), 右图为左图的局部区域放大图
Fig. 5 Schematic diagram of calculation results(yellow lines represent the results of contour detection, and red numbers indicate the width of the lamellar region between two blue points), the right image is an enlarged view of a local area in the left image

表 3 板条状区域面积计算结果

Table 3 Lamellar region area calculation results

No.	Actual measurement/%	Compute/%	Relative error/%
1	17.85	17.88	0.17
2	15.70	15.74	0.25
3	19.18	19.32	0.73
4	16.11	15.94	1.06
5	14.37	14.42	0.35
6	12.83	13.00	1.33

表 4 长度计算结果

Table 4 Length calculation results

No.	Actual measurement/pixel	Compute/pixel	Relative error/%
1	191	199	4.19
2	299	303	1.34
3	190	197	3.68
4	150	149	0.67
5	134	136	1.49
6	175	171	2.29

表 5 宽度计算结果

Table 5 Width calculation results

No.	Actual measurement/pixel	Compute/pixel	Relative error/%
1	21	21	0
2	24	23	4.17
3	23	22	4.35
4	19	18	5.26
5	29	27	6.90
6	26	24	7.69

表 6 周长计算结果

Table 6 Circumference calculation results

No.	Actual measurement/pixel	Compute/pixel	Relative error/%
1	439	449	2.28
2	650	676	4.00
3	506	489	3.36
4	395	398	0.76
5	380	372	2.11
6	412	422	2.43

表 7 BCC 相区域面积计算结果

Table 7 BCC phase area calculation results

No.	Actual measurement/%	Compute/%	Relative error/%
1	33.27	34.42	3.46
2	33.31	34.41	3.30
3	34.21	35.27	3.10
4	35.44	35.46	0.06
5	33.44	33.96	1.56
6	33.30	33.33	0.09

4 结 论

(1) 本研究评估了 vgg13、resnet34、vision_transformer_b0 等不同编码器结构的 U-Net 网络模型在共晶高熵合金板条状分割中的表现，为材料量化分析提供了有效的深度学习方法支撑，有助于共晶高熵合金材料构效关系的研究。

(2) 针对共晶高熵合金的扫描电镜图像，本研究基于图像处理技术提出了一套自动高效的定量指标计算方法，该方法能够准确地测量板条状区域的面积、长度、宽度、周长以及 BCC 相占比，与实际测量值相比，相对误差控制在 8% 以内。

(3) 当前方法在分割精度和计算效率方面仍有一定的提升空间，后续工作将重点优化模型结构和算法，进一步提高分割准确度。

(4) 本研究所提出的自动化计算方法为共晶高熵合金的微观组织定量分析提供了可靠的技术手段，对材料性能研究具有重要应用价值。

致谢 本研究得到了“上海大学上海市科学与工程计算专业技术服务平台”的支持。

参考文献 References

- [1] 何春霞, 肖声明, 陆德荣, 等. 武汉科技大学学报[J], 2011, 34(1): 23-27+61.
HE C X, XIAO S M, LU D R, *et al.* Journal of Wuhan University of Science and Technology[J], 2011, 34(1): 23-27+61.
- [2] 刘亚径, 王兴东, 朱青友, 等. 武汉科技大学学报[J], 2022, 45(1): 37-45.
LIU Y J, WANG X D, ZHU Q Y, *et al.* Journal of Wuhan University of Science and Technology[J], 2022, 45(1): 37-45.
- [3] 刘欢, 刘晓佳, 赵耀邦, 等. 中国材料进展[J], 2024, 43(2): 175-180.
LIU H, LIU X J, ZHAO Y B, *et al.* Materials China[J], 2024, 43(2): 175-180.
- [4] GAO X, LU Y, ZHANG B, *et al.* Acta Materialia[J], 2017, 141:

- 59-66.
- [5] ZHAO F Y, YE Y C, ZHANG Z R, *et al.* Rare Metal Materials and Engineering[J], 2023, 52(4): 1192-1200.
- [6] 陈凯旋, 熊志平. 稀有金属材料与工程[J], 2024, 53(7): 2083-2093.
CHEN K X, XIONG Z P. Rare Metal Materials and Engineering[J], 2024, 53(7): 2083-2093.
- [7] LANG Z, ZHANG Z, WANG L, *et al.* Microstructures[J], 2025, 5: 2025004.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015[C]. Cham: Springer International Publishing, 2015: 234-241.
- [9] 张利欣, 车世界, 徐正光, 等. 科学技术与工程[J], 2020, 20(1): 246-251.
ZHANG L X, CHE S J, XU Z G, *et al.* Science Technology and Engineering[J], 2020, 20(1): 246-251.
- [10] 文喆皓, 周敏. 兵器材料科学与工程[J], 2020, 43(6): 106-112.
WEN Z H, ZHOU M. Ordnance Material Science and Engineering [J], 2020, 43(6): 106-112.
- [11] 姜军强, 张旭辉, 徐奎奎, 等. 西安科技大学学报[J], 2023, 43(1): 201-208.
JIANG J Q, ZHANG X H, XU K K, *et al.* Journal of Xi'an University of Science and Technology[J], 2023, 43(1): 201-208.
- [12] 魏惠姗, 韩越兴, 王冰, 等. 计算机应用研究[J], 2022, 39(10): 3196-3200.
WEI H S, HAN Y X, WANG B, *et al.* Application Research of Computers[J], 2022, 39(10): 3196-3200.
- [13] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, *et al.* An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale[J/OL]. (2021-06-03) [2025-06-26]. <https://arxiv.org/abs/2010.11929>
- [14] HE K, ZHANG X, REN S, *et al.* Deep Residual Learning for Image Recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016.
- [15] TAN M, LE Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks[C]//CHAUDHURI K, SALAKHUTDINOV R. Proceedings of the 36th International Conference on Machine Learning [C]. New York: ACM, 2019, 97: 6105-6114.
- [16] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J/OL]. (2015-04-10) [2025-06-26]. <https://arxiv.org/abs/1409.1556>
- [17] ZHANG T Y, SUEN C Y. Communications of the ACM[J], 1984, 27(3): 236-239.
- [18] SUZUKI S. Computer Vision, Graphics, and Image Processing[J], 1985, 30(1): 32-46.
- [19] BENTLEY J L. Communications of the ACM[J], 1975, 18(9): 509-517.
- [20] EELBODE T, BERTELS J, BERMAN M, *et al.* IEEE Transactions on Medical Imaging[J], 2020, 39(11): 3679-3690.