

基于深度学习的皮肤器官芯片表皮模型图像的分类研究

徐成晓

东南大学生物科学与医学工程学院，江苏南京，210000；

摘要：本研究旨在利用深度学习技术实现皮肤器官芯片表皮模型图像的自动化分类，以解决人工标注成本高及小样本数据导致的过拟合问题。通过构建包含600张正常与异常样本的图像数据集，并采用多维度数据增强策略扩展至1200张样本缓解数据不足。选用改进型ResNeSt网络模型，结合Split-Attention机制与分组卷积优化特征表达，同时采用迁移学习策略和AdamW优化器进行模型训练。验证了其在皮肤器官芯片表皮模型图像分类中的优越性并为皮肤生物学研究与药物开发提供了高效的自动化分类工具。

关键词：深度学习；皮肤器官芯片；图像分类

DOI：10.69979/3029-2808.25.05.041

引言

皮肤作为人体最大的器官，发挥着至关重要的屏障、免疫调节以及感知等诸多功能^[3]。皮肤是人体天然的屏障，能够有效阻挡外界环境中的各种物理性、化学性以及生物性有害因素的侵袭^[4]。皮肤类器官为由诱导多能干细胞或多能干细胞分化的细胞在体外三维培养环境下诱导形成的皮肤类似物^[1]，皮肤器官芯片的构建可以通过将皮肤模型或皮肤类器官直接置于芯片中培养，也可以先置于Transwell培养支架中再放入芯片的腔室中，这些方式都能实现皮肤组织的气-液界面培养，有利于皮肤组织的分化和功能的表达^[5]。皮肤器官体外模型凭借其独特的模拟能力，在皮肤生物学基础研究、药物研发以及攻克皮肤疾病难题等方面都有着重要的意义^[2]。

对于传统的图像分类任务，机器学习算法如支持向量机（SVM）、决策树等依赖于人工精心挑选和设计的特征，通过训练分类器来实现不同类别图像的区分^[8]。然而，在面对海量、复杂且具有高度变异性的图像数据时，深度学习中的卷积神经网络（CNN）展现出了卓越的性能，像经典的AlexNet、VGG、ResNet等架构，通过大规模的图像数据训练，能够自动学习到图像中不同类别物体的特征差异，实现高精度的图像分类与识别^[9]。因此，在皮肤器官芯片图像分析这一特定领域中，由于皮肤器官芯片图像标注需结合病理知识，人工标注的成本比较高^[7]。同时受限于其制备过程周期以及制备环境，目前皮肤器官芯片表皮模型的图像数据比较少^[6]，在复杂的网络模型分类过程中会出现过拟合，这就需要利用小样本数据进行模型的轻量化设计。因此，利用深度

学习技术对皮肤器官芯片表皮模型的图像进行分类研究可以节约人工分类标注的时间、人力成本，实现图像的自动化分类。

1 研究方法

选用ResNeSt网络模型对构建的皮肤器官芯片表皮模型图像数据集进行自动化分类研究。

1.1 网络模型

ResNeSt是一种改进型卷积神经网络架构，在ResNet基础上引入Split-Attention机制，通过动态特征选择优化信息流动，在ImageNet等基准数据集上实现了很好的性能。

输入特征图的通道数为 c ，先将特征图按照通道分为 k 个组，每个组具有 c/k 个特征图通道。再将每个组的通道分为 r 个小组，每个小组通道数为 $c/k/r$ 。之后对每个小组的特征图通道映射为 c/k ，仍然有 r 个小组，每个小组的特征图输入splitAttention中计算，输出通道与单一输入的通道数相同，均为 c/k 。再最后将所有大组的特征图按照其面积进行拼接^[12]。

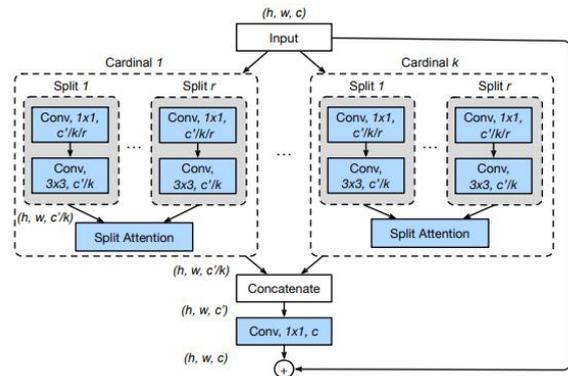


图1 ResNeSt的网络结构图

Split-Attention 的工作机制流程如下:

(1) 分组卷积: 将输入特征图沿通道维度划分为 g 个组 (通常 $g=32$), 每组独立进行 3×3 卷积。

(2) 注意力计算:

对分组卷积后的每个组的特征图执行全局平均池化。对于第 k 个组的特征图 x_k , 其大小为 $h \times w \times c / g$ (h 为特征图高度, w 为特征图宽度, c 为总通道数), 通过公式 $z_k = \frac{1}{h \cdot w} \sum_{i=1}^h \sum_{j=1}^w x_{k,i,j}$ 计算得到通道级统计量 $z \in \mathbb{R}^g$ ^[10]。

(3) 注意力分配: 将得到的通道级统计量 z 输入到两层全连接层 (FC) 中。第一层全连接层将 z 映射到一个低维空间, 降低维度以减少计算量和参数数量, 同时进行非线性变换, 增强网络对特征的表达能力的^[11]; 第二层全连接层再将低维特征映射回维空间, 输出注意力权重 $a \in \mathbb{R}^g$ 。

1.2 评价指标

研究采用多维度评价指标体系评估器官芯片图像分类模型的性能。通过准确率 (Accuracy, ACC)、精确率 (Precision)、召回率 (Recall) 及 F1 分数 (F1-Score) 进行量化。准确率定义为正确分类样本占比, 精确率则衡量正类预测的可靠性, 召回率则关注正类样本的检出能力, F1 分数作为精确率与召回率的调和平均^[13]。

2 实验设计

2.1 数据集预处理

实验构建了包含 600 张皮肤器官芯片表皮模型图像的数据集, 其中正常与异常样本各 300 例, 图像经明场显微镜采集并统一为 256×256 像素尺寸。针对小样本问题, 采用多维度数据增强策略让每张原始图像生成 4 种变体, 使有效样本量扩展至 1200 张。增强过程中随机组合 2-3 种变换以保证数据多样性, 数据集按 7:3 比例分层随机划分为训练集 (840 张, 正常/异常各 420 张) 与验证集 (360 张, 正常/异常各 180 张), 采用 Scikit-learn 的 train_test_split 函数并设置 stratify 参数确保类别分布一致性, 为模型评估提供可靠基准。

2.2 实验方案

实验采用 ResNeSt-50 作为核心分类模型, 基于 ImageNet 预训练权重实施迁移学习策略。首先冻结前 5 个卷积层以保留通用特征表示, 随后对剩余层进行微调。

优化过程采用 AdamW 优化器 ($\beta_1 = 0.9, \beta_2 = 0.999, weight_decay = 0.01$), 结合余弦退火学习率调度 (初始 $1e-4$, 每 10 个 epoch 衰减 50%)。训练阶段实施多维度数据增强, 包括实时随机旋转 ($\pm 15^\circ$)、水平翻转 ($p = 0.5$)、随机裁剪 (保留 80% 区域) 及 MixUp 增强 ($\alpha = 0.2$)。在全连接层前引入 Dropout ($p = 0.5$) 抑制参数共适应。训练配置为 batch_size=32、epoch=200, 使用 NVIDIA GeForce RTX 4090 GPU 进行分布式训练, 最终在验证集上实现最佳分类性能。对比实验模型分别为 ResNet-50、ResNeXt-50、SENet-154, 其目的分别为与基准模型比对、验证 ResNeSt 的 Split-Attention 与分组卷积在分支特征融合上的差异、验证 ResNeSt 的 Split-Attention 是否比单纯通道注意力更有效

3 结果与讨论

3.1 对比实验结果

实验结果如表 1 所示, ResNeSt 在各项指标上均展现出了相对优异的性能。

表 1 评价指标实验结果

模型	Accuracy	Precision	Recall	F1-Score
ResNeSt	0.90	0.88	0.92	0.90
ResNet-50	0.85	0.83	0.86	0.84
ResNeXt-50	0.87	0.85	0.88	0.86
SENet-154	0.84	0.82	0.85	0.83

具体而言, ResNeSt 模型取得了高达 0.90 的准确率, 相较于 ResNet-50 (准确率为 0.85)、ResNeXt-50 (准确率为 0.87) 以及 SENet-154 (准确率为 0.84), 有着明显的优势。这意味着 ResNeSt 在对正常与异常皮肤器官芯片表皮模型图像进行区分时, 整体的正确分类能力更为突出。从精确率指标来看, ResNeSt 的精确率达到了 0.88, 即在其预测为正例的样本中, 实际为正例的比例较高。与之相比, ResNet-50、ResNeXt-50 和 SENet-154 的精确率分别为 0.83、0.85 和 0.82, ResNeSt 在这一指标上同样表现出色, 反映出该模型在做出分类判断时具有较高的精准性, 能有效减少误判正例的情况。在召回率方面, ResNeSt 获得了 0.92 的成绩, 意味着实际为正例的样本中, 该模型能够正确召回的比例较高, 体现了其对正例样本较好的捕捉能力, 而 ResNet-50、ResNeXt-50 和 SENet-154 的召回率依次为 0.86、0.88 和 0.85, 进一步凸显了 ResNeSt 在召回正例样本上的优势。

3.2 讨论分析

为了更直观地展现 ResNeSt 在验证集上的分类效果优势,我们引入了混淆矩阵进行可视化分析,如图 2 所示,在本次针对皮肤器官芯片表皮图像分类的验证集中,该模型对于正常样本预测为正常以及异常样本预测为异常的准确率较高。正常样本中被正确预测为正常的数量达到了 162 个,异常样本中被正确预测为异常的数量达到了 172 个,而误分类的情况相对较少,这充分体现了 ResNeSt 在实际分类过程中的准确性和可靠性,与前文所提到的较高的评价指标相互印证,进一步证明了其在处理此类图像分类任务时的优越性能。

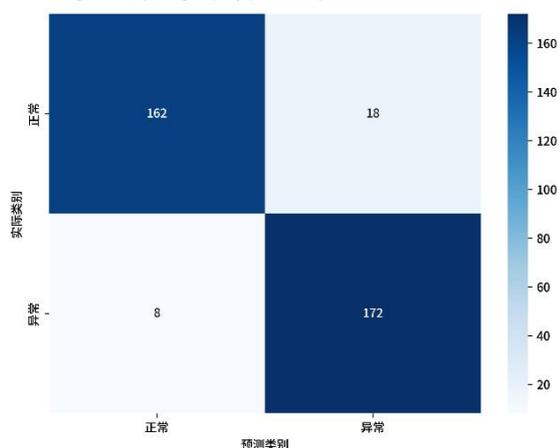


图 2 验证集的可视化混淆矩阵

参考文献

[1] Hong Z X, Zhu S T, Li H, et al. Bioengineered skin organoids: from development to applications [J]. *Military Medical Research*, 2023, 10(1): 40.

[2] Lee J, Van Der Valk W H, Serdy S A, Deakin C, Kim J, Le A P, Koehler K R. Generation and characterization of hair-bearing skin organoids from human pluripotent stem cells [J]. *Nature protocols*, 2022, 17(5): 1266-1305.

[3] Ebner-Peking P, Krisch L, Wolf M, et al. Self-assembly of differentiated progenitor cells facilitates spheroid human skin organoid formation and planar skin regeneration [J]. *Theranostics*, 2021, 11(17): 8430.

[4] Ramovs V, Janssen H, Fuentes I, et al. Characterization of the epidermal-dermal junction in hiPSC-derived skin organoids [J]. *Stem Cell Reports*, 2022, 17(6): 1279-1288.

[5] Sutterby E, Thurgood P, Baratchi S, et al. Microfluidic skin-on-a-chip models: Toward biomimetic artificial skin [J]. *Small*, 2020, 16(39): 2002515.

[6] Ismayilzada N, Tarar C, Dabbagh S R, et al. Skin-on-a-chip technologies towards clinical translation and commercialization [J]. *Biofabrication*, 2024, 16(4): 042001.

[7] Michielon E, Boninsegna M, Waaijman T, et al. Environmentally Controlled Microfluidic System Enabling Immune Cell Flow and Activation in an Endothelialised Skin-On-Chip [J]. *Advanced Healthcare Materials*, 2024, 13(29): 2400750.

[8] 陈健, 王珍妮, 夏开建, 等. 基于深度学习的结肠息肉内镜图像分割和分类方法比较 [J]. *上海交通大学学报(医学版)*, 2024, 44(6): 762.

[9] Alharith R, Ibrahim A O, Wahid N, et al. Comparative Analysis of ResNet Models for Skin Cancer Diagnosis: Performance Evaluation and Insights [C] // *International Conference on Soft Computing and Data Mining*. Cham: Springer Nature Switzerland, 2024: 370-378.

[10] Indumathi C P, Santhoshsivan V, Selvakumar R. ResNet and ResNeSt-Based Deep-Learning [C] // *Digital Geography: Proceedings of the International Conference on Internet and Modern Society (IMS 2023)*. Springer Nature, 2024: 215.

[11] 夏平, 张光一, 雷帮军, 等. 多尺度 ResNeSt-50 聚合网络与置信度传播的息肉图像分割 [J]. *光学精密工程*, 2023, 31(18): 2765-2780.

[12] Zhang H, Wu C, Zhang Z, et al. Resnest: Split-attention networks [C] // *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2022: 2736-2746.

[13] Jia Y, Wan G, Liu L, et al. Split-attention networks with self-calibrated convolution for moon impact crater detection from multi-source data [J]. *Remote Sensing*, 2021, 13(16): 3193.

作者简介: 徐成晓 (1999 年), 女, 汉族, 安徽省滁州市, 在读硕士, 研究方向: 皮肤器官芯片表皮模型图像分析