

基于SE-Inception-v3的星系形态分类模型*

孔希阳^{1,2,3} 窦江培^{1,2†}

(1 中国科学院国家天文台南京天文光学技术研究所 南京 210042)

(2 中国科学院天文光学技术重点实验室(南京天文光学技术研究所) 南京 210042)

(3 中国科学院大学 北京 100049)

摘要 随着天文探测技术的快速发展,海量的星系图像数据不断产生,能够及时高效地对星系图像进行形态分类对研究星系的形成与演化至关重要.针对传统的星系形态分类模型特征选择困难、分类速度慢、准确率受限等难题,提出一种以Inception-v3神经网络为主干结构,融合压缩激励(Squeeze and Excitation Network, SE)通道注意力机制的星系形态分类模型.该模型在斯隆数字巡天(Sloan Digital Sky Survey, SDSS)样本的测试集准确率高达99.37%.旋涡星系、圆形星系、中间星系、雪茄状星系与侧向星系的F1值分别为99.33%、99.58%、99.33%、99.41%与99.16%.该模型与Inception-v3、MobileNet (Mobile Neural Network)和ResNet (Residual Neural Network)网络模型相比,SE-Inception-v3宽度和深度优势表现出更强的特征提取能力,可以高效识别不同形态的星系,为未来大型巡天计划的大规模星系形态分类问题提供了一种新方法.

关键词 星系: 普通, 方法: 数据分析, 技术: 图像处理

中图分类号: P157; 文献标识码: A

1 引言

星系作为宇宙的重要结构之一,是系外行星的主要聚集地.研究星系对理解宇宙的形成和演化及行星的生命历程有着重要的意义.星系形态是表征星系结构最直接的观测特征^[1-3],研究星系形态分类对于解答星系形态在宇宙不同时刻的演化过程至关重要^[4].在众多星系分类系统中^[5-10],目前最常用的星系形态分类系统为哈勃分类系统^[11],哈勃分类系统最早于1922年提出,发展至今逐步被补充而日趋完善^[12-14],是星系形态分类的重要参考依据.

随着天文观测技术与天文仪器的不断发展,大规模的巡天项目逐步实施,如MDS (Hubble Space

Telescope Medium Deep Survey)^[15]、GOODS (The Great Observatories Origins Deep Survey)^[16]、HUDF (Hubble Ultra Deep Field)^[17-18]、COSMOS (Cosmic Evolution Survey)^[19-21]、CANDELS (Cosmic Assembly Near-IR Deep Extragalactic Legacy Survey)^[22-24]、斯隆数字巡天(Sloan Digital Sky Survey, SDSS)^[25-26]等,海量的星系图像与数据不断涌入人们的视野,因此能够及时高效地对星系图像进行形态分类变得十分关键.一些从数学视角出发的星系形态分类方法应运而生,Lorenzo等^[27]采用分数三角形算法按照星系悬臂轨迹对椭圆星系与环状星系进行形态分类;Selim等^[28]采用非负矩阵分解算法识别星系

2022-11-22收到原稿, 2023-01-09收到修改稿

*国家自然科学基金项目(U2031210), 国家重大科研仪器研制项目(11827804), 中国载人航天工程巡天空间望远镜专项(CMS-CSST-2021-A11、CMS-CSST-2021-B04)资助

†jpdou@niaot.ac.cn

形态; Hosny等^[29]采用四元极性复指数变化与二元随机分形搜索算法对星系形态进行分类. 在人工智能与机器学习技术快速发展的大背景下, 越来越多的人工智能技术被广泛应用到系外行星搜寻、光谱分类、星系形态分类等领域^[30-34], 机器学习可以帮助天文工作者从不同维度提取特征信息并探索隐含层与高维复杂数据间的关联, 减少研究人员利用其领域知识进行人工特征设计的工作量. Huertas-Company等^[35]与Freed等^[36]都采用支持向量机(Support Vector Machine)的方法对来自SDSS的星系图片进行形态分类, Huertas-Company等^[35]给出了各类星系形态的概率估计, Freed等^[36]对椭圆星系与旋涡星系进行了二分类, Almeida等^[37]采用k均值聚类算法(k-means clustering algorithm)对SDSS星系光谱进行分类. 除此之外, 大量基于卷积神经网络(Convolutional Neural Network, CNN)的分类算法应用于星系形态分类, 如旋转不变(Rotation-invariant)卷积^[38]、ResNet (Residual Neural Network)卷积^[39]、随机森林(Random forest)^[40]、小样本学习(Few-shot learning)^[41]、卷积自编码与集成学习(Convolutional autoencoder and bagging-based multiclustering model)^[42]和EfficientNet网络^[43].

这些星系形态分类方法与不断增加的海量天文观测数据极大推动了星系形态分类领域的发展. 然而这些分类方法也存在不同星系形态样本数量失衡、特征选择困难等问题, 合理搭建星系形态网络模型以优化分类速度与分类准确率就显得至关重要, Inception-v3神经网络在解决图像分类任务方面有两个优点: (1)采用分解卷积增加卷积网络深度与宽度, 在增加了网络非线性表达能力的同时还加快了训练速度; (2)稀疏结构可以减轻计算量并减少过拟合. 压缩激励(Squeeze and Excitation Network, SE)^[44]通道注意力机制通过自学习的方式, 获取特征图每个通道的重要程度, 抑制对星系形态用处不大的特征通道, 让神经网络关注权重高的特征通道. 因此本文提出了一种以Inception-v3神经网络为主干结构, 融合SE通道注意力机制的星系形态分类模型. 该模型平衡了网络的宽度与深度, 避免特征描述瓶颈, 通过将低层次特征进行抽

象处理, 经过不同网络层的特征学习进而得到高维星系形态特征, 较好地解决了星系形态分类研究中准确率低的问题, 为未来从海量的星系图像中对不同星系进行精准分类提供快速高效的分类模型参考.

2 网络模型

2.1 Inception-v3主干网络

Inception-v3模型是由Google开发的以Inception网络结构构成的第3代CNN分类器, Inception模块的主要思想是用密集成分来近似最优的局部稀疏结构, 在传统卷积神经网络模型中引入了分解卷积, 示意图如图1所示. 分解卷积的主要目的是减少网络中的参数量, 主要方法有对称式分解和非对称式分解卷积. 对称式分解卷积如图1 (a)所示, 5×5 卷积使用两个 3×3 的卷积代替, 可以减少28%的参数量与计算量, 同时分解后增加了一个激活函数进而增加了非线性表达能力, 使得网络局部特征更加明显, 加快了网络训练速度. 非对称式分解卷积如图1 (b)所示, 3×3 的卷积采用 1×3 与 3×1 的卷积来代替, 可以减少33%的参数量与计算量, 这种非对称的卷积结构拆分能够处理更丰富的空间特征. Inception-v3网络结构如图2所示, 从输入端开始先后是3个卷积层、1个最大池化层、2个卷积层、1个最大池化层、11个混合模块、全局平均池化层、Dropout层、全连接层与Softmax层.




图1 分解卷积示意图, (a)为对称式分解卷积; (b)为非对称式分解卷积.

Fig. 1 Structure of decomposition convolution, (a) the symmetric decomposition convolution; (b) the asymmetric decomposition convolution.

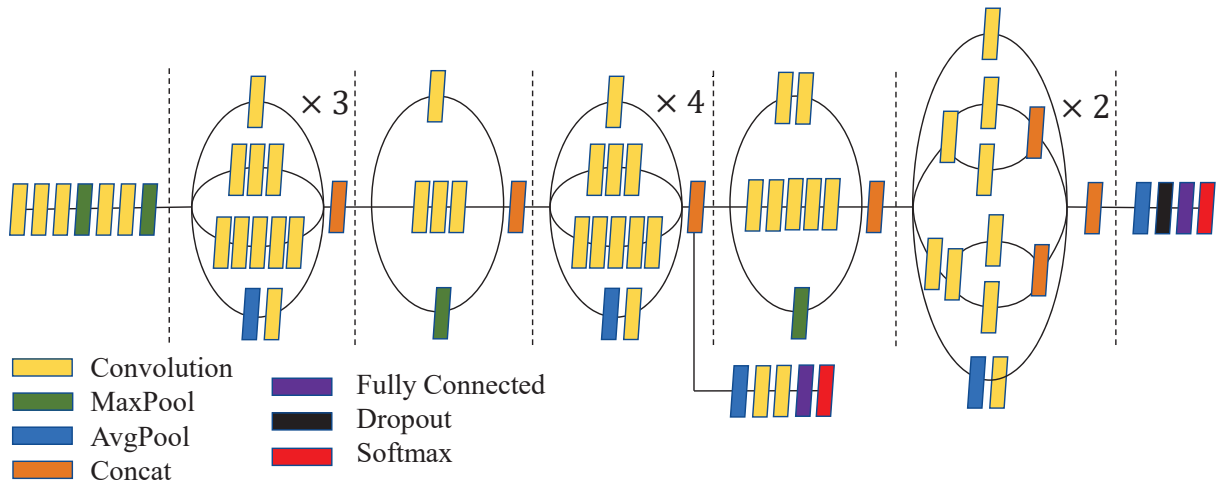


图 2 Inception-v3网络结构图

Fig. 2 Structure of Inception-v3 neural network

2.2 SE通道注意力机制

SE是一种即插即用的通道注意力模块, 通过压缩(Squeeze)、激励(Excitation)与Scale相乘特征

融合, 它能在不改变特征图大小的情况下对输入特征图进行通道特征加强, 其网络结构如图3所示, SE通道注意力机制主要包括以下4个步骤:




图 3 SE网络结构图

Fig. 3 Structure of squeeze and excitation (SE) network

(1) Transformation (F_{tr}): 给定一个输入特征图 X , 维度为 $H' \times W' \times C'$, 其中 H' 是高度(Height), W' 是宽度(Width), C' 是通道数(Channel). X 通过卷积算子映射为 U . 特征图 U 维度为 $H \times W \times C$, 其中 H 、 W 与 C 分别对应其高度、宽度与通道数.

(2) Squeeze (F_{sq}): Squeeze所做的就是把 $H \times W \times C$ 通过全局池化压缩为特征向量 Z , 即 $1 \times 1 \times C$, 相当于把 $H \times W$ 压缩成一维, 该一维参数获得了 $H \times W$ 全局视野. 如(1)式所示:

$$Z = F_{sq}(U) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U(a, b), \quad (1)$$

式中 a 与 b 分别表示特征图横纵坐标点的值.

(3) Excitation (F_{ex}): 将Squeeze操作得到的 Z 输入至2个全连接层 W 生成我们想要的通道权重 S , 两层全连接层之间存在一个超参数 R , 向量 Z 经过第1层全连接层 W_1 后维度由 $1 \times 1 \times C$ 变为 $1 \times 1 \times C/R$, 再经过第2层全连接层 W_2 , 维度由 $1 \times 1 \times C/R$ 变为 $1 \times 1 \times C$. 经过两层全连接层后得到

的 \mathbf{S} 中不同数值表示不同通道的权重信息. 如(2)式所示:

$$\mathbf{S} = \mathbf{F}_{\text{ex}}(\mathbf{Z}, \mathbf{W}) = \sigma(W_2 \delta(W_1 \mathbf{Z})), \quad (2)$$

其中 δ 代表第1层全连接层 W_1 的激活函数ReLU,

$$\text{ReLU} = f(x) = \max(0, x), \quad f'(x) = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0, \end{cases} \quad (3)$$

其中, x 与 f 分别表示横纵坐标的取值, σ 代表第2层全连接层 W_2 的激活函数Sigmoid,

$$\text{Sigmoid} = f(x) = \frac{1}{1 + e^{-x}}. \quad (4)$$

(4) Scale ($\mathbf{F}_{\text{scale}}$): 将Excitation操作生成的权重向量 \mathbf{S} 加权到原始输入特征图 \mathbf{U} 的每个通道上, 即特征图 \mathbf{U} 中每个通道的 $H \times W$ 个数值都乘 \mathbf{S} 中对应通道的权值, 便得到我们想要的特征图 \mathbf{X}' , 其尺寸大小与特征图 \mathbf{U} 完全一样, SE模块不改变特征图的大小. 如(5)式所示,

$$\mathbf{X}' = \mathbf{F}_{\text{scale}}(\mathbf{U}, \mathbf{S}) = \mathbf{S} \times \mathbf{U}. \quad (5)$$

2.3 SE-Inception-v3结构

本研究提出的SE-Inception-v3星系形态分类模型是基于迁移学习对模型参数进行微调, 以Inception-v3网络结构为基础, 添加SE通道注意力机制, 使模型选择性地关注星系图像重点目标区域, 模型框架如图4所示.

迁移学习是指将一个在某领域完成学习任务的神经网络应用到新的领域进行学习训练. 通常已训练完毕神经网络模型的前几层学习到的是通用特征, 随着网络层数的增加, 更深层的网络更加偏重于学习特定的特征, 因此可将通用特征迁移到其他相关领域. 对于深度卷积神经网络来说, 经过预训练的网络模型可以实现网络结构与参数信息的分离, 在保证网络结构一致的前提下, 便可以采用预训练得到的权重参数来初始化新的神经网络, 这种参数迁移的方式极大缩短了神经网络训练时间.

如图4中的上图所示, 在获取基于ImageNet数据集预训练完毕的Inception-v3模型后, 用新网络模型的全连接层替换基于ImageNet数据集网络模型的全连接层, 采用ImageNet预训练得到的权重参数来初始化新模型, 在星系数据集上训练剩余参数, 直至新网络模型训练完毕. 基于ImageNet数据集训练完毕的神经网络模型泛化能力强, 通过迁移学习扩充了星系训练数据, 使得新网络模型具有更高的训练精度与更强的鲁棒性.

如图4中的下图所示, SE-Inception-v3星系形态分类模型主要分为Block1、Block2、Block3与SE共4个模组:

(1) Block1为Inception对称式分解卷积结构, 其4个分支上均有 1×1 卷积核, 相邻感受野的卷积是高度相关的, 使用 1×1 的卷积有利于保留相邻单元之间的相关性, 在降低约28%模型参数数量的同时又能增加模型的特征表达能力;

(2) Block2为Inception对称式分解卷积的拓展结构, 可用 $1 \times n$ 卷积拼接 $n \times 1$ 替换 $n \times n$ 以减少网络参数数量与计算量, 卷积核 n 常选用3、5、7等常数, 该模块适用于网络中层用以提取星系形态特征信息, 特征越多收敛越快, 输入的星系形态信息就会被分解得越彻底;

(3) Block3为Inception非对称式分解卷积结构, 该模块适用于网络后期以扩充通道数提取星系高维稀疏特征, Block3模块可降低约33%的网络参数量. 分解卷积在增加卷积神经网络的深度和宽度的同时, 又减少了参数数量和计算量, 避免模型陷入过拟合, 使得Inception-v3神经网络不仅具有密集矩阵的高计算性能, 又保持了滤波器级别的稀疏性. 此外, 多个卷积核共同作用相当于为模型增加了多个激活函数, 大大提升了模型的非线性表征能力;

(4) SE实现通道注意力机制最重要的两个地方分别是全连接层与相乘特征融合, 假设输入图像维度为 $H \times W \times C$, 通过全局池化(Global Pooling)与全连接层(Fully Connected)拉伸为 $1 \times 1 \times C$, 然后再和原图像相乘, 给每个通道赋予权重, 可以更好地拟合通道间复杂的相关性, 在提高网络运行时间的同时又减少了参数计算量.

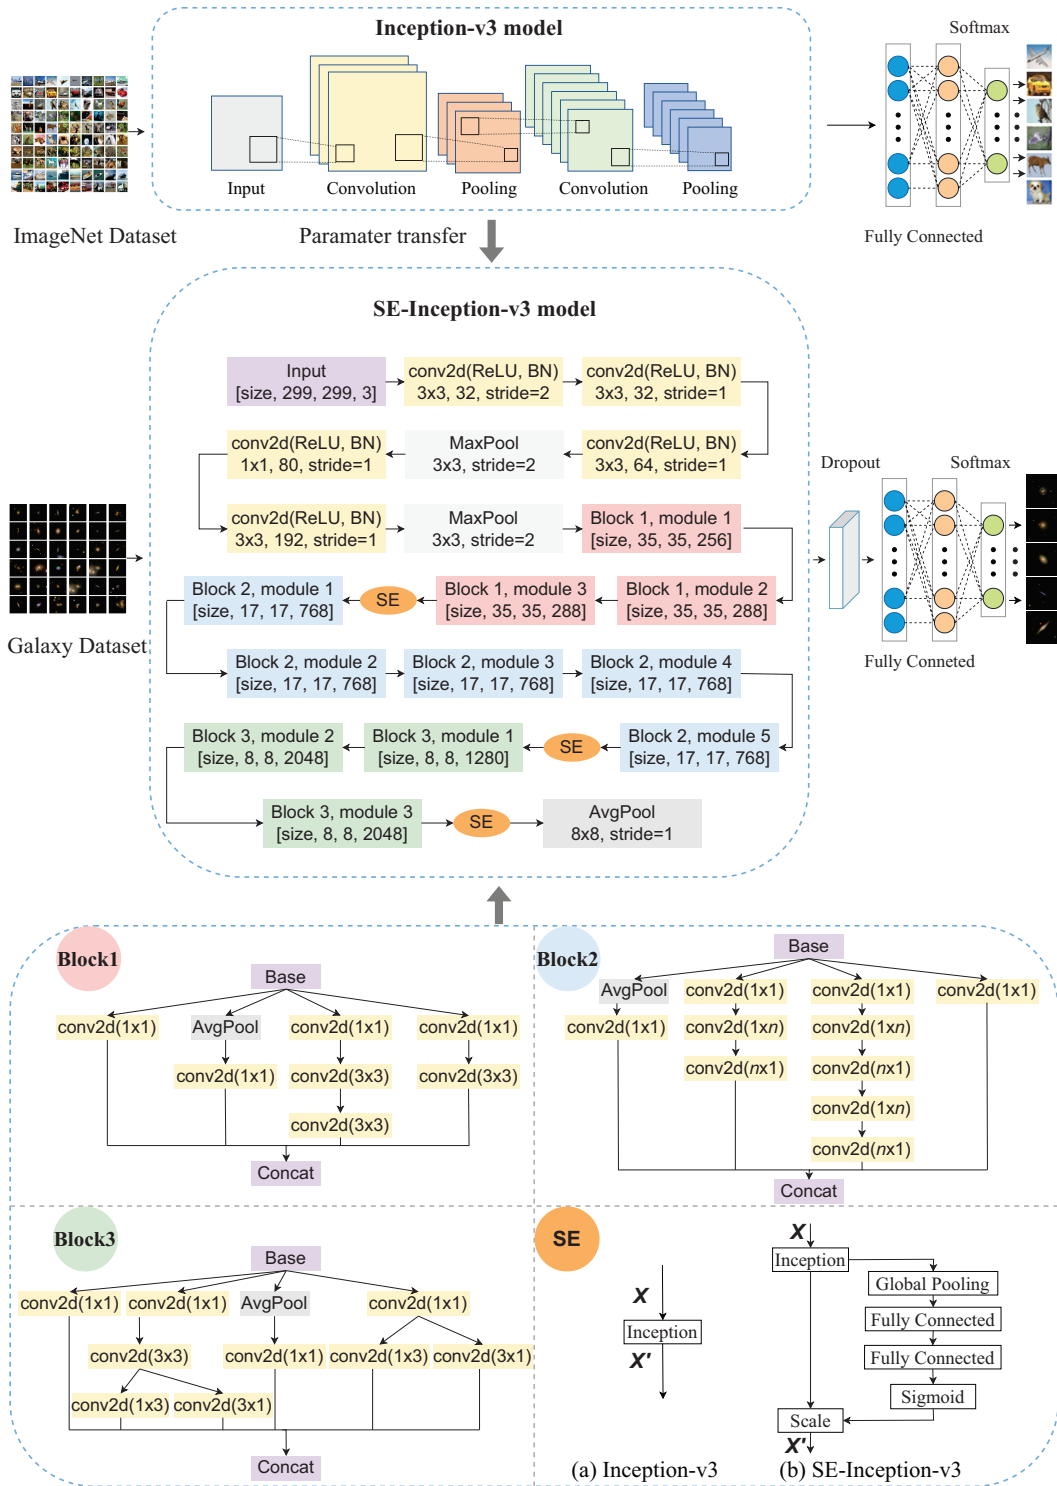


图 4 SE-Inception-v3星系形态分类模型

Fig. 4 Galaxy morphology classification model based on SE-Inception-v3

如图4中的中图所示, SE-Inception-v3星系形态分类模型流程为输入维度为 $299 \times 299 \times 3$ 的天文图像数据, 其后进入一个有32个 3×3 卷积核、步长(stride)为2的卷积层(conv2d), 经过ReLU 激活函数与批归一化(Batch Normalization, BN)处理后依次通过2个卷积层、1个最大池化层、2个卷积层、1个最大池化层、14个混合模块后进入一个大小为 8×8 、步长为1的平均池化层(AvgPool), 其后先进入Dropout层丢弃部分隐含层神经元, 使网络变得更为紧凑以避免过拟合, 然后依次进入全连接层与Softmax层, 最后输出星系形态分类结果. 其中, SE-Inception-v3模型在每个卷积层后加入的ReLU激活函数可以增加模型的非线性, 加入的批归一化可以减小网络内部协方差. SE-Inception-v3星系形态分类模型在网络前端避免了从输入到输出特征维度的严重压缩. 分解卷积将高维度信息在网络局部进行处理, 进而加快网络训练速度. 空间聚合通过低维嵌入, 在不降低网络表示能力的同时又加快学习速度. SE-Inception-v3模型4个模块的合理搭配较好地平衡网络每层滤波器的个数和网络层数, 并行增加网络宽度与深度使得网络性能最大化.

3 数据准备

大型巡天项目斯隆数字巡天(SDSS)¹被认为是诸多巡天项目中颇具影响力的一个, 它覆盖了约1/3的天区, 其中包括北天球的一半和少部分南天球天区. SDSS的CCD (Charge-Coupled Device) 测光系统利用6组CCD同时对天体的5个波段(u、g、r、i、z)进行测光, 获得了5亿多个天体的精确测光数据, 并对其中的300多万个恒星与星系进行了确认, 这些星系的能谱特征主要集中在g、r、i这3个波段, SDSS网站上提供这3个波段合成的伪彩色图片, 为用户研究各类星系形态分类模型提供了有力的数据支持.

本文采用的星系数据集来源于Kaggle²平台的Galaxy Zoo2, Galaxy Zoo2数据集采集自SDSS

DR7 (Data Release 7)的RGB (Red Green Blue)彩色图片, 用户可直接通过SQL (Structured Query Language)语句从SDSS的Skyserver平台获取星系图像数据. Galaxy Zoo2经过志愿者投票对星系图片给定类别标签值. 哈勃星系形态分类系统采用目视方法将星系分为旋涡(Spiral)星系、圆形(Completely round smooth)星系、中间(In-between smooth)星系、雪茄状(Cigar-shaped smooth)星系与侧向(Edge-on)星系等. 本文采用哈勃星系形态分类原则按照Willett等^[45]提供的星系形态分类细则从Galaxy Zoo2中挑选星系样本. 星系选择标准如表1所示, 其中T01-T11表示的是Galaxy Zoo2中的11个星系形态分类任务的类型, $f_{\text{features}/\text{disk}}$ 代表一张星系图片被分类为平滑且有盘状结构的概率; $f_{\text{edge-on,no}}$ 代表一张星系图片被分类为非侧向星系的概率; $f_{\text{spiral,yes}}$ 代表一张星系图片被分类为旋涡星系的概率; f_{smooth} 代表一张星系图片被分类为平滑星系的概率; $f_{\text{completelyround}}$ 代表图片被分类为圆形星系的概率; $f_{\text{in-between}}$ 代表一张星系图片被分类为处于圆和雪茄状之间的概率; $f_{\text{cigar-shaped}}$ 代表图片被分类为雪茄状的平滑星系的概率; N_{sample} 代表数据集选取的样本数.

本文从Galaxy Zoo2中分别挑选3400颗不同星系形态的图片作为星系形态分类模型的数据输入, 其中部分星系形态图片如图5所示, 将样本集按照11:3:3的标准随机分为训练集、验证集与测试集, 如表2所示, 其中每类星系样本中训练集为2200张星系图片, 验证集与测试集分别为600张.

4 实验设置

4.1 实验平台

- (1)操作系统: Windows 10;
- (2)图形处理器: NVIDIA GeForce GTX 950 M;
- (3)深度学习框架: TensorFlow 1.12;
- (4)编程语言: Python 3.6.5.

¹<https://www.sdss.org>

²<https://www.kaggle.com>

表 1 星系数据选择标准
Table 1 Galaxy data selection criteria

Class	Class-name	Tasks	Thresholds	N_{sample}
1	Spiral	T01	$f_{\text{features/disk}} \geq 0.43$	3400
		T02	$f_{\text{edge-on,no}} \geq 0.715$	
		T04	$f_{\text{spiral,yes}} \geq 0.619$	
2	Completely round smooth	T01	$f_{\text{smooth}} \geq 0.469$	3400
		T07	$f_{\text{completelyround}} \geq 0.5$	
3	In-between smooth	T01	$f_{\text{smooth}} \geq 0.469$	3400
		T07	$f_{\text{in-between}} \geq 0.5$	
4	Cigar-shaped smooth	T01	$f_{\text{smooth}} \geq 0.469$	3400
		T07	$f_{\text{cigar-shaped}} \geq 0.5$	
5	Edge-on	T01	$f_{\text{features/disk}} \geq 0.43$	3400
		T02	$f_{\text{edge-on,yes}} \geq 0.602$	

表 2 星系数据集构成
Table 2 The composition of galaxy dataset

Dataset	Training	Validation	Testing	Total
Spiral	2200	600	600	3400
Completely round smooth	2200	600	600	3400
In-between smooth	2200	600	600	3400
Cigar-shaped smooth	2200	600	600	3400
Edge-on	2200	600	600	3400
Total	11000	3000	3000	17000




图 5 采集自SDSS的星系形态图像样本

Fig. 5 Galaxy images from SDSS dataset

4.2 实验步骤

Galaxy Zoo2原始图像尺寸为424*424, 选用的图像尺寸过大则模型在进行运算处理时要求的配置越高, 选用的图像尺寸过小又会丢失部分特征信息. 在权衡整体样本集后, 本文将原始图像裁剪为299*299, 既最大化保留主体星系形态特征的同时又控制了计算量. 训练过程中, 每批次训练量(batch size)为16张, 学习率(learning rate)为0.01, 训练周期(epochs)为145次. 星系训练集图像分批次逐步进入SE-Inception-v3模型进行训练, 通过计算Softmax层的输出与给定星系形态类别标签值二者的误差, 采用如下交叉熵损失函数(cross entropy loss)调整权重参数,

$$H(y, y') = - \sum_x y(x) \lg(y'), \quad (6)$$

其中 y 为标签值, y' 为预测值, H 为交叉熵损失值. 交叉熵刻画的是两个概率分布的距离, 也就是说交叉熵值越小, 两个概率分布越接近. 训练每累计达100批次时, 验证集即对已训练好的模型进行分类准确率验证, 直到逐步调整权重参数达到预期准确率时训练过程结束, 保存星系形态分类模型的参

数权重, 最后用测试集对已训练好的星系形态分类模型进行准确率验证, 输出星系分类结果.

4.3 评价指标

本文选用训练准确率(Training Accuracy)、验证准确率(Validation Accuracy)、训练损失(Training Loss)、验证损失(Validation Loss)来评估基于SE-Inception-v3的星系形态分类模型的训练集与验证集性能; 选用混淆矩阵(Confusion Matrix)、准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1值(F1 score)来评估星系形态分类模型的测试集性能. 训练准确率如(7)式代表了星系形态分类模型的训练集的准确度, 其中 $X_{\text{train}}^{\text{actual}=\text{true}}$ 代表训练集实际为真的情况, $X_{\text{train}}^{\text{predict}=\text{true}}$ 代表训练集中预测值是真的情况.

$$\text{TrainingAccuracy} = \frac{\sum X_{\text{train}}^{\text{predict}=\text{true}}}{\sum X_{\text{train}}^{\text{actual}=\text{true}}}. \quad (7)$$

验证准确率如(8)式代表了星系形态分类模型的验证集的准确度, 其中 $X_{\text{val}}^{\text{actual}=\text{true}}$ 代表验证集中实际为真的情况, $X_{\text{val}}^{\text{predict}=\text{true}}$ 代表验证集中预测值

是真的情况.

$$\text{ValidationAccuracy} = \frac{\sum X_{\text{val}}^{\text{predict=true}}}{\sum X_{\text{val}}^{\text{actual=true}}}. \quad (8)$$

训练损失如(9)式代表了训练集的交叉熵损失值, 它表示的是模型实际输出和期望输出的偏差, 差值越小期望输出的准确率越高. 随着星系分类模型的收敛, 训练损失会逐步向0趋近, 其中, $t_{\text{train}}^{i,j}$ 代表训练集真实的第*i*个星系图像是*j*类的概率, $p_{\text{train}}^{i,j}$ 代表训练集第*i*个星系图像被预测为*j*类的概率.

$$\text{TrainingLoss} = - \sum \sum t_{\text{train}}^{i,j} \lg(p_{\text{train}}^{i,j}). \quad (9)$$

验证损失如(10)式代表了验证集的交叉熵损失值, 验证集损失越小, 则星系形态分类模型的分类效果越好, 其中, $t_{\text{val}}^{i,j}$ 代表验证集真实的第*i*个星系图像是*j*类的概率, $p_{\text{val}}^{i,j}$ 代表验证集第*i*个星系图像被预测为*j*类的概率.

$$\text{ValidationLoss} = - \sum \sum t_{\text{val}}^{i,j} \lg(p_{\text{val}}^{i,j}). \quad (10)$$

混淆矩阵如表3所示是对分类问题预测结果的总结, 用于比较分类结果和实际测试值, 结果共4类, 分别为TP (True Positive)、FN (False Negative)、FP (False Positive)及TN (True Negative). 测试集准确率是分类正确的样本占总样本个数的比例, 它是分类问题中最简单直观的评价指标, 表达式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}. \quad (11)$$

表 3 混淆矩阵
Table 3 Confusion matrix

Confusion Matrix		Predicted Class	
		Class=Yes	Class=No
Actual Class	Class=Yes	TP	FN
	Class=No	FP	TN

精确率指模型预测为正的样本中实际也为正的样本占被预测为正的样本的比例, 它体现了模型

对负样本的区分能力, 精确率越高, 模型对负样本的区分能力就越强, 计算公式为:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}. \quad (12)$$

召回率指实际为正的样本中被预测为正的样本所占实际为正的样本的比例, 召回率直观地说是分类器找到所有正样本的能力, 召回率越高, 模型对正样本的识别能力就越强, 表达式为:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}. \quad (13)$$

F1值可以解释为精确率和召回率的加权平均值, 精确率和召回率对F1值的贡献是相等的, 表达式为:

$$\text{F1} = \frac{2\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (14)$$

5 实验结果与分析

5.1 训练集与验证集实验结果

图6为基于SE-Inception-v3的星系形态分类模型在训练集与验证集上的准确率曲线. 从图中可知在模型初期的迭代训练中准确率会出现剧烈波动, 这是由于星系数据集较大, 在训练初期梯度下降可能会落入非最优解的局部最小值, 在约20个周期后模型逐步收敛, 训练集准确率与验证集准确率均趋于稳定, 训练集准确率最优达到100%, 验证集准确率最优达到99.39%.

图7为基于SE-Inception-v3的星系形态分类模型在训练集与验证集上的损失函数曲线. 在模型训练初期, 由于模型处于欠拟合状态, 验证集损失较高, 随着迭代次数的增加, 训练集损失不断下降, 验证集损失偶尔出现波动, 在约20个周期后, 训练集与验证集的参数基本收敛, 交叉熵损失趋于稳定.

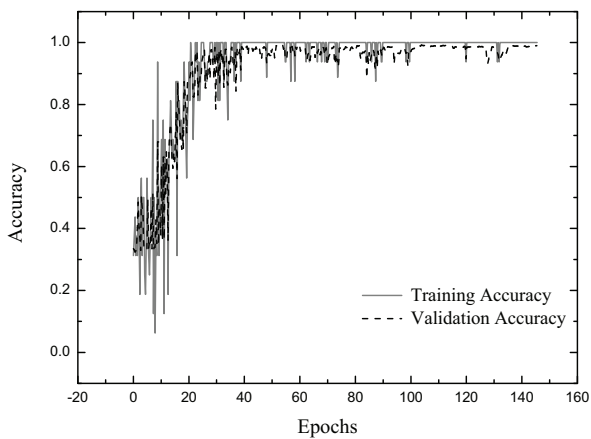


图 6 基于SE-Inception-v3的星系形态分类模型准确率

Fig. 6 Accuracy of galaxy morphology classification model based on SE-Inception-v3

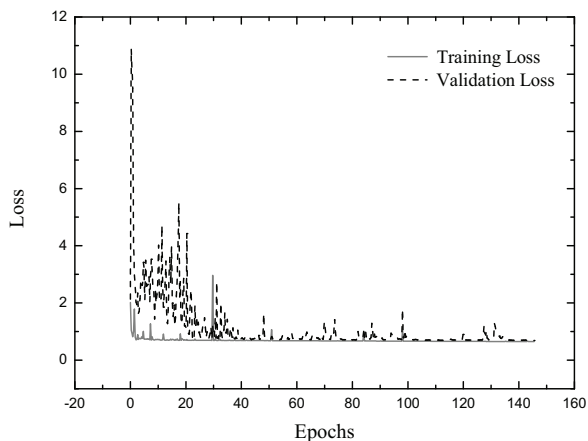


图 7 基于SE-Inception-v3的星系形态分类模型交叉熵损失

Fig. 7 Cross entropy loss of galaxy classification model based on SE-Inception-v3

5.2 测试集实验结果

本文对在SDSS数据集上训练好的SE-Inception-v3的星系形态分类模型进行了测试集检测. 测试集共包含3000张星系图片, 其中旋涡星系(Class 1)、圆形星系(Class 2)、中间星系(Class 3)、雪茄状星系(Class 4)与侧向星系(Class 5)各600张, 星系形态分类模型在测试集上的混淆矩阵如图8所示.

SE-Inception-v3星系形态分类模型在测试集上的分类准确率、精确率、召回率、F1值等实

验结果如表4所示. 测试集中星系整体准确率为99.37%; 5类星系的精确率均在99.00%以上, 说明该星系形态分类模型对负样本的区分能力极强; 5类星系的召回率均在99.17%以上, 体现了该模型对正样本具有高效的识别能力; F1值均在99.16%以上, 表明该模型具有极强的稳定性.

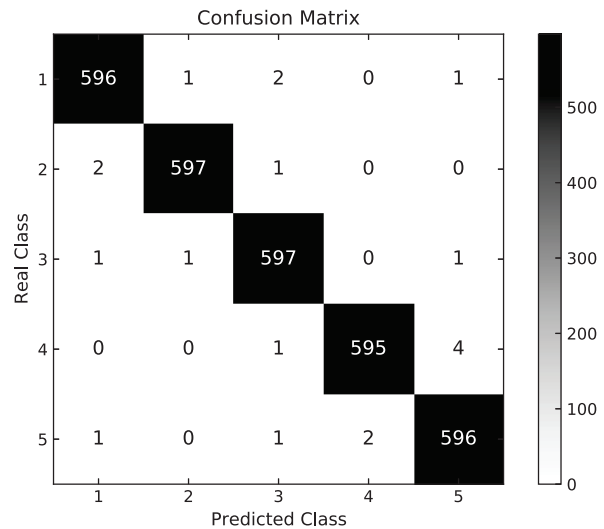


图 8 星系形态分类测试集混淆矩阵

Fig. 8 Confusion matrix for galaxy morphology classification on testing dataset

5.3 学习率合理性验证

为检验SE-Inception-v3星系形态分类模型中的学习率选择的合理性, 本文进行了不同学习率的对比实验, 在保证模型训练时除学习率外其余各参数不变的前提下, 进行了学习率分别为0.1、0.01与0.001的对比实验. 实验结果如图9所示, 随着学习率的不断减小, 模型收敛速度也不断减小, 当学习率为0.1时模型收敛速度较快, 但是振荡剧烈, 模型稳定性较差. 当学习率为0.001时, 收敛速度较慢, 由于参数更新过慢, 模型在经过20个周期训练进入收敛状态后依然有明显振荡. 而学习率为0.01时, 既保证了模型的收敛速度与稳定性又达到了极高的准确率且不容易发生过拟合现象, 该实验结果验证了本文选择的0.01学习率的合理性.

表 4 基于SE-Inception-v3星系形态分类模型的测试集实验结果

Table 4 The results of SE-Inception-v3 galaxy morphology classification model on testing dataset

Accuracy=99.37%	Precision	Recall	F1 score
Spiral	99.33%	99.33%	99.33%
Completely round smooth	99.67%	99.50%	99.58%
In-between smooth	99.17%	99.50%	99.33%
Cigar-shaped smooth	99.66%	99.17%	99.41%
Edge-on	99.00%	99.33%	99.16%

5.4 不同模型对比与分析

为验证基于SE-Inception-v3的星系形态分类模型的优良性能, 本文将SE-Inception-v3星系形态分类模型与Inception-v3星系形态模型进行对比, 同时还采用相同的数据集将该模型与广泛应用于目标检测、目标分类、人脸识别等领域的MobileNet模型和ResNet模型进行对比分析。

4种神经网络的星系形态分类模型在验证集上的准确率对比情况如图10所示。由图可知, MobileNet (Mobile Neural Network)网络模型振荡小但收敛速度较慢, 它是一个轻量级的卷积神经网络, 该网络进行卷积的参数比标准卷积要少很多, 因此在收敛速度上相对较慢。MobileNet使用DW (Depth-wise)卷积提取特征, DW和标准卷积不同, 标准卷积的卷积核是用在所有的输入通道上, 而DW针对每个输入通道采用不同的卷积核, 一个卷积核对应一个输入通道, 因此该模型在训练过程中不易产生振荡。ResNet网络引入了残差结构, 残差结构的引入增加了神经网络的深度, 网络越深, 模型获取的信息越多, 提取的特征就会越丰富, 因此在收敛速度上会优于MobileNet。SE-Inception-v3星系形态分类模型在准确率与稳定性方面显著优于Inception-v3模型。SE-Inception-v3增大了神经网络的感受视野, 运用不同类型卷积核对张量进行运算, 从星系图像中提取大量有效特征, 并在参数更新过程中引入批归一化, 减少了梯度消失对训练过程的影响, 使得星系分类性能大幅度提高。

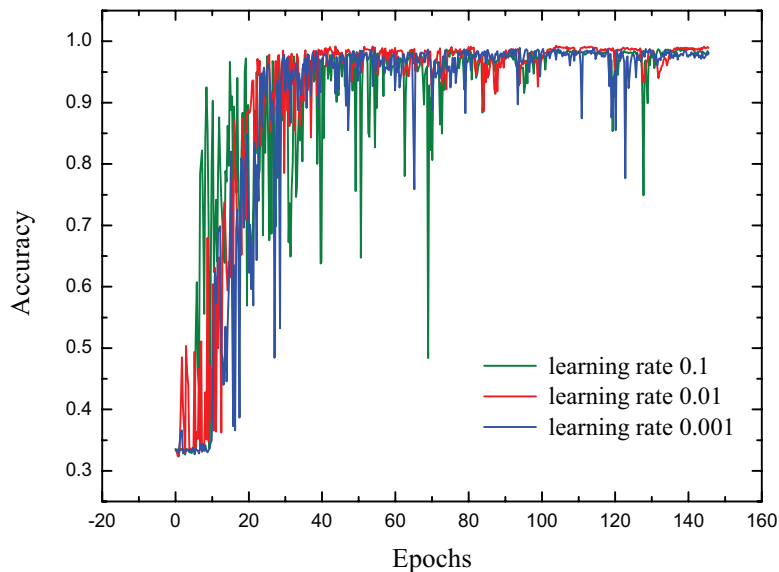


图 9 SE-Inception-v3星系形态分类模型不同学习率的验证集准确率对比

Fig. 9 Validation accuracy comparison of SE-Inception-v3 galaxy morphology classification models with different learning rates




图 10 4种星系形态分类模型验证集准确率对比

Fig. 10 Contrast of 4 kinds of galaxy morphology classification models on validation dataset

表5为SE-Inception-v3模型与Inception-v3模型、MobileNet模型和ResNet模型的性能比较. SE-Inception-v3模型验证集最优准确率达到99.27%, 远高于其他3个网络. SE-Inception-v3、Inception-v3、MobileNet与ResNet网络模型验证集准确率达到85%时所对应的训练周期分别为16、21、45与29, 对应消耗的时长分别为2.72 h、3.09 h、5.18 h与4.82 h. 由此可见SE-Inception-v3模型在收敛速度和运算时间方面都显著优于Inception-v3、MobileNet与ResNet模型, 充分验证了本文提出的基于SE-Inception-v3神经网络的星系形态分类模型的高性能.

表 5 4种星系形态分类模型在验证集上的性能比较

Table 5 Performance contrast of 4 kinds of galaxy classification models on validation dataset

CNN model	Optimal accuracy	Accuracy =85% epochs	Accuracy=85% time consuming /h
SE-Inception-v3	99.27%	16	2.72
Inception-v3	93.99%	21	3.09
MobileNet	90.46%	45	5.18
ResNet	93.22%	29	4.82

6 结语

天文望远镜与天文观测技术的不断进步推动了海量星系数据的产生, 针对传统星系形态分类模型特征选择困难、分类速度和准确率受限等问题, 本文提出了一种融合SE通道注意力机制的Inception-v3星系形态分类模型. 针对图像背景噪音等无关信息对星系形态识别的干扰问题, 在模型中引入SE通道注意力模块增强有用特征通道权重, 降低无关特征通道对神经网络性能的影响. 将Inception-v3神经网络与SE通道注意力机制相融合, 能够较好地平衡精度与抗噪性, SE-Inception-v3模型宽度与深度的优良设计在避免特征表示瓶颈的同时又最大化了网络性能, 高效地实现了自动化星系形态的分类识别. 通过对SDSS星系数据集进行实验验证, 最终在测试集上的星系分类准确率高达99.37%, 旋涡星系、圆形星系、中间星系、雪茄状星系与侧向星系5种星系分类F1值均在99.16%以上. 本文模型与Inception-v3、MobileNet、ResNet等模型相比具有更快的收敛速度和更高的准确率. 该模型弥补了现有模型在分类精度和效率的不足, 可为星系形态分类提供有力支撑.

参考文献

- [1] Bershadsky M A. *PASP*, 1993, 105: 1028
- [2] Naim A, Ratnatunga K U, Griffiths R E. *ApJS*, 1997, 111: 357
- [3] Wu Y Z. *AJ*, 2021, 168: 28
- [4] Berch S V D. *AJ*, 2001, 122: 621
- [5] Kelly B C, Makay T A. *AJ*, 2004, 127: 625
- [6] Kelly B C, Makay T A. *AJ*, 2005, 129: 1287
- [7] Park C, Choi Y Y. *ApJ*, 2005, 635: L29
- [8] Deng X F. *RAA*, 2013, 13: 651
- [9] Xu Z Y, Hu T, Peng Z Q. The 2020 International Seminar on Artificial Intelligence, Networking and Information Technology. Shanghai: Journal of Physics: Conference Series, 2020, 1684: 012032
- [10] Bódi A, Hajdu T. *ApJS*, 2021, 255: 1
- [11] Hubble E P. *ApJ*, 1926, 64: 321
- [12] de Vaucouleurs G. *ApJS*, 1961, 5: 233
- [13] Sandage A. *PASP*, 1975, 87: 853
- [14] Lahav O, Naim A, Buta R J, et al. *Science*, 1995, 267: 859
- [15] Ratnatunga K U, Griffiths R E, Ostrander E J. *AJ*, 1999, 118: 86
- [16] Giavalisco M, Ferguson H C, Koekemoer A M, et al. *ApJ*, 2004, 600: L93
- [17] Beckwith S V W, Stiavelli M, Koekemoer A M, et al. *AJ*, 2006, 132: 1729
- [18] Illingworth G D, Magee D, Oesch P A, et al. *ApJS*, 2013, 209: 6
- [19] Scoville N, Abraham R G, Aussel H, et al. *ApJS*, 2007, 172: 38
- [20] Leauthaud A, Massey R, Kneib J P, et al. *ApJS*, 2007, 172: 219
- [21] Capak P, Aussel H, Ajiki M, et al. *ApJS*, 2007, 172: 99
- [22] Grogin N A, Kocevski D D, Faber S M, et al. *ApJS*, 2011, 197: 35
- [23] Koekemoer A M, Faber S M, Ferguson H C, et al. *ApJS*, 2011, 197: 36
- [24] Guo Y, Ferguson H C, Giavalisco M, et al. *ApJS*, 2013, 207: 24
- [25] Lupton R, Gunn J E, Ivezić Z, et al. *ASPC*, 2001, 238: 269
- [26] York D G, Adelman J, Anderson J E, et al. *AJ*, 2000, 120: 1579
- [27] Lorenzo C F, Hartley T T. Proceedings of the ASME 2015 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference. Boston: ASME, 2015, 46279
- [28] Selim I M, Abd El Aziz M. *ExA*, 2017, 43: 131
- [29] Hosny K M, Elaziz M A, Selim I M et al. *A&C*, 2020, 31: 100383
- [30] Kim E J, Brunner R J. *MNRAS*, 2017, 464: 4463
- [31] Cheng T Y, Huertas-Company M, Conselice C J, et al. *MNRAS*, 2021, 503: 4446
- [32] Perez-Carrasco M, Cabrera-Vives G, Martinez-Marin M, et al. *PASP*, 2019, 131: 108002
- [33] Ghosh A, Urry C M, Wang Z, et al. *ApJ*, 2020, 895: 112
- [34] Chen J W. 2020 International Conference on Environment Science and Advanced Energy Technologies. Chongqing: Journal of Physics: Conference Series, 2020, 1549: 042033
- [35] Huertas-Company M, Aguerri J A L, Bernardi M, et al. *A&A*, 2011, 525: A157
- [36] Freed M, Lee J. 2013 International Conference on Computational and Information Sciences. IEEE, 2013: 322
- [37] Almeida J S, Aguerri J A L, Muñoz-Tuñón C, et al. *ApJ*, 2010, 714: 487
- [38] Dieleman S, Willett K W, Dambre J. *MNRAS*, 2015, 450: 1441
- [39] Zhu X P, Dai J M, Bian C J, et al. *Ap&SS*, 2019, 364: 55
- [40] Baldeschi A, Miller A, Stroh M, et al. *ApJ*, 2020, 902: 60
- [41] Zhang Z R, Zou Z Q, Li N, et al. *RAA*, 2022, 22: 055002
- [42] Zhou C C, Gu Y Z, Fang G W, et al. *AJ*, 2022, 163: 86
- [43] 艾霖嫻, 徐权峰, 杜利婷, 等. *天文学报*, 2022, 63: 42
- [44] Jie H, Li S, Cang S, et al. *ITPAM*, 2020, 42: 2011
- [45] Willett K W, Lintott C J, Bamford S P, et al. *MNRAS*, 2013, 435: 2835

Galaxy Morphology Classification Model Based on SE-Inception-v3

KONG Xi-yang^{1,2,3} DOU Jiang-pei^{1,2}

(1 National Astronomical Observatories/Nanjing Institute of Astronomical Optics & Technology, Chinese Academy of Sciences, Nanjing 210042)

(2 CAS Key Laboratory of Astronomical Optics & Technology, Nanjing Institute of Astronomical Optics & Technology, Nanjing 210042)

(3 University of Chinese Academy of Sciences, Beijing 100049)

ABSTRACT With the rapid development of astronomical detection technology, there will be a huge torrent of incoming galaxy images in the coming years, making the automatic galaxy morphology classification a challenging task. To solve the problem of feature selection, the low speed and low accuracy of traditional galaxy morphology classification models, a galaxy morphology classification model based on Inception-v3 neural network with SE (Squeeze and Excitation Network) channel attention mechanism is introduced. We select galaxy images from Sloan Digital Sky Survey (SDSS) for the SE-Inception-v3 model. The test results show that the accuracy of SE-Inception-v3 model is as high as 99.37%, and the F1 scores of spiral galaxy, completely round smooth galaxy, in-between smooth galaxy, cigar-shaped smooth galaxy and edge-on galaxy are 99.33%, 99.58%, 99.33%, 99.41% and 99.16%, respectively. Compared with the MobileNet (Mobile Neural Network) and ResNet (Residual Neural Network) models, the width and depth advantages of SE-Inception-v3 make the classification model have stronger feature extraction capabilities, which provides a new galaxy morphology classification approach for future large-scale sky survey programs.

Key words galaxies: general, methods: data analysis, techniques: image processing