

DOI:10.11784/tdxbz202405005

## 基于注意力机制的端到端轻量化星图识别算法研究

伊国胜<sup>1</sup>, 杨翰文<sup>1</sup>, 司文杰<sup>2</sup>, 李冰<sup>2</sup>, 王彦博<sup>1</sup>, 韩春晓<sup>3</sup>

(1. 天津大学电气自动化与信息工程学院, 天津 300072; 2. 北京航天自动控制研究所, 北京 100854;  
3. 天津职业技术师范大学自动化与电气工程学院, 天津 300222)

**摘要:** 星敏感器在航天任务中通过对恒星进行识别以实现姿态测量, 而星图识别算法作为其核心部分决定着星敏感器姿态定位的性能. 针对现有的基于神经网络的星图识别算法难以在保证识别准确率的同时限制计算成本的问题, 提出了一种基于注意力机制端到端轻量化网络 MobileCiT 的星图识别算法, 用于直接识别星敏感器中的含噪声星图. MobileCiT 在卷积神经网络的基础上采用深度可分离卷积和改进前置倒残差结构以实现星图识别算法的轻量化, 同时引入注意力机制以重点关注星点位置信息. 此外, 由于实拍星图的成本高, 噪声不可控, 采用基于小孔成像的坐标映射模型以生成含噪声的仿真星图训练集与测试集. 实验结果表明, MobileCiT 对含不同噪声星图的识别准确率为 99.850%, 高于现有的基于轻量化网络 MobileNet 和 MobileViT 的星图识别算法, 对位置噪声、星等噪声、假星和缺失星均具有良好的鲁棒性, 能够在无需背景去噪、连通域检测、星点质心提取等预处理操作的情况下实现高精度的星图识别. MobileCiT 在提升识别精度的同时具有较低的计算成本, 计算量仅为基于 MobileViT 网络算法的 1/3. 在此基础上, 将 MobileCiT 与基于子图同构的星图识别算法和基于模式识别的星图识别算法进行对比. 在相同的视场范围与噪声条件下, MobileCiT 依旧表现出了更高的识别准确率与更强的鲁棒性, 这进一步验证了 MobileCiT 相对于传统星图识别算法的先进性.

**关键词:** 星图识别; 注意力机制; 轻量化; 星图仿真; 卷积神经网络; 噪声鲁棒性

中图分类号: TP391.4

文献标志码: A

文章编号: 0493-2137(2025)03-0247-13

## End-to-End Lightweight Star-Map Identification Algorithm Based on Attention Mechanism

Yi Guosheng<sup>1</sup>, Yang Hanwen<sup>1</sup>, Si Wenjie<sup>2</sup>, Li Bing<sup>2</sup>, Wang Yanbo<sup>1</sup>, Han Chunxiao<sup>3</sup>

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;

2. Beijing Aerospace Automatic Control Institute, Beijing 100854, China;

3. School of Automation and Electrical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

**Abstract:** Star sensors measure attitude by identifying stars in space missions, and star-map identification algorithms, as the core part of the sensors, determine the accuracy of the star sensors' attitude measurement. To address concerns that existing neural network-based star-map identification algorithms hardly reduce computational costs while guaranteeing identification accuracy, this paper proposes an end-to-end lightweight network star-map identification algorithm (i.e., MobileCiT) based on an attention mechanism to directly identify noisy star-maps in star sensors. MobileCiT employs depthwise separable convolution and an improved pre-inverted residual structure based on a convolutional neural network. It also uses an attention mechanism to focus on the position information of star points. In addition, because of the high cost and uncontrollable noise of real star-maps, a coordinate mapping model based on small hole imaging is used to generate noisy simulated star-map training and test datasets. The experimental results

收稿日期: 2024-05-08; 修回日期: 2024-09-02.

作者简介: 伊国胜 (1986—), 男, 博士, 副教授, guoshengyi@tju.edu.cn.

通信作者: 韩春晓, cxhan@tju.edu.cn.

基金项目: 国家自然科学基金青年科学基金资助项目 (62103301).

Supported by the Youth Scientists Fund of the National Natural Science Foundation of China (No. 62103301).

show that the identification accuracy of MobileCiT for different noisy star-maps is 99.850%, which is higher than those of existing star-map identification algorithms based on the lightweight networks MobileNet and MobileViT. Moreover, it has good robustness to positional and magnitude noises, as well as false and missing stars. MobileCiT realizes high-accuracy star-map identification without the need for preprocessing operations, such as background denoising, connectivity domain detection, and star centroid extraction. MobileCiT improves the identification accuracy with low computational costs, and the computation load is one-third of the algorithm based on the MobileViT network. MobileCiT is compared with star-map identification algorithms based on subgraph isomorphism or pattern recognition. Under the same field of view and noise conditions, MobileCiT shows higher identification accuracy and robustness, further verifying its superiority over traditional star-map identification algorithms.

**Keywords:** star-map identification; attention mechanism; lightweight; star-map simulation; convolutional neural network (CNN); robustness to noise

大多数地球观测、天体导航等航天任务都需要航天器的姿态信息。作为姿态测量精度最高的自主式测量器件,星敏感器通过拍摄星空图像并对图像内星点进行识别以实现航天器姿态的测量<sup>[1]</sup>。星图识别算法是星敏感器的核心部分,决定着星敏感器姿态定位的性能<sup>[2]</sup>。然而,随着航天任务的多样性与复杂性不断提升,星图识别算法的识别准确率、噪声鲁棒性和计算成本等各项性能被提出了更高要求<sup>[3]</sup>。传统星图识别算法需要添加背景去噪、连通域检测、星点质心提取等预处理算法<sup>[4]</sup>,难以在保证对噪声鲁棒性的同时保持较高识别精度。为满足日益复杂的航天任务需求,需要一种抗噪声、高精度、轻量化的星图识别算法。

目前针对星图识别算法的研究大致可以分为基于子图同构的算法和基于模式识别的算法<sup>[5-6]</sup>,两种算法均需预先通过星图预处理操作提取星点质心坐标。子图同构算法通过计算星点之间的角距,并在特征库中搜寻相关的同构子图实现星图识别<sup>[5]</sup>。该类算法需要存储大量的导航星三角形或导航星对以构建数据库,但是较大的数据库通常会占用大量存储空间从而降低查询速度。一种典型的算法是金字塔算法,该算法利用 4 颗星点间的角距信息进行星图识别。但由于在高位置噪声条件下星点间角距信息误差增大,该算法难以维持较高的准确率<sup>[7]</sup>。基于模式的星图识别算法将星图识别视为一种模式识别任务,通过对每一颗恒星及其邻近恒星构建模式向量,根据向量的匹配结果实现星图识别。Padgett 等<sup>[6]</sup>提出的栅格算法是首个基于模式识别的算法,该算法将星图转换为特征矩阵进行匹配,识别精度更高、识别速度更快,但其识别准确率依赖于参考恒星和邻近恒星间的正确选择,易受星图中的星等噪声与假星影响<sup>[8-9]</sup>。2008 年,Zhang 等<sup>[10]</sup>提出了一种径向与循环算法,通过提取星图中的径向特征与循环特征实现星图识

别。但当参考星受到噪声干扰时,循环特征将严重失真。在此基础上,Wei 等<sup>[11]</sup>通过将动态循环模式与最大累积比较方法相结合,减少了假星和星等噪声对径向与循环算法的影响。2022 年,Du 等<sup>[12]</sup>提出了一种径向三角形矩阵算法。在该算法中,径向三角形参考星的两个相邻角距被当作笛卡尔坐标系  $x$  轴和  $y$  轴的索引值,而对边角距被作为特征值映射到矩阵中。该算法的星图特征构建方式类似于子图同构算法,避免了识别过程中对最近邻星的依赖,对各种噪声均具有良好的鲁棒性。随着人工智能发展,卷积神经网络(convolutional neural networks, CNN)被用于星图识别领域<sup>[13]</sup>。Wang 等<sup>[14]</sup>将深度卷积神经网络 VGG16 用于星图识别。相比于子图同构或模式识别算法,基于 CNN 的识别算法识别时间稳定,同时神经网络的模糊学习能力提高了算法对噪声的鲁棒性。但由于卷积层数的堆叠,该网络需要使用大量的存储空间存储网络参数,计算成本较高<sup>[14]</sup>。

本文聚焦于卷积神经网络识别算法难以在识别准确率与计算成本之间取得平衡的问题,提出了基于注意力机制的端到端轻量化星图识别网络 MobileCiT,该网络在深度可分离卷积神经网络的基础上嵌入前置倒残差结构以降低网络计算量,引入通道注意力和 Transformer 自注意力以提高网络的识别准确率与鲁棒性。同时,端到端识别网络允许直接使用含噪声星图作为输入,避免了预处理算法对星图识别产生的干扰。在算法测试与验证方面,本文使用基于小孔成像的仿真算法生成星图以提供数据支持。通过训练与验证,发现相比于现有基于卷积的 MobileNet 网络<sup>[15]</sup>和基于注意力机制的 MobileViT 网络<sup>[16]</sup>,MobileCiT 在高噪声星图中保持了较高的识别精度,同时具有较低的网络计算成本。在此基础上,将 MobileCiT 与基于子图同构以及基于模式识别的算法进行比较。对比发现,在处于相同的视场范围与

噪声中, MobileCiT 相比于其他算法依然具有更高的星图识别性能。

## 1 仿真星图与星图识别算法的构建

本文采用基于小孔成像<sup>[17]</sup>的含噪声星图仿真模型为星图识别算法提供数据支持. 在获得含噪声星图后, 构建基于注意力机制的端到端轻量化星图识别算法 MobileCiT.

### 1.1 仿真星图的构建

为了给星图识别算法的研究提供数据支持, 需要大量星图数据. 实拍星图具有获取成本高、受自然条件影响大的缺点, 因此星图仿真算法成为星图识别算法研究和测试的重要辅助手段. 本文构建一个全天球含噪声星图仿真算法. 首先, 对 SAO 星表进行均匀化处理, 提取导航星库作为数据基础. 然后, 采用基于小孔成像的坐标映射模型<sup>[18]</sup>将恒星三维坐标映射到像平面二维坐标系中, 用于全天球自定义方向的星图仿真. 最后, 基于像平面星点质心坐标, 通过添加背景噪声和星点相关噪声实现含噪声的星图仿真.

#### 1.1.1 导航星库的建立与均匀化

真实的恒星数据是星图仿真和识别的基础. 为了研究星图仿真算法, 本文从 SAO 星表中获取恒星信息<sup>[19]</sup>. 然而星表中的恒星数量十分庞大, 需要对其进行筛选, 选择合适的恒星建立导航星库. 首先去除星表中数据记录不全和重复的恒星, 在此基础上筛选掉星等大于 6.0 的恒星. 对于星表中角距过小所导致的双星, 选择去除亮度较低的恒星. 对 SAO 星表中全部恒星按照上述条件过滤组成导航星库, 最终得到 4 908 颗恒星. 为使仿真星图中星点分布尽量均匀, 从而提高识别算法研究的可靠性, 采用随机矢量法<sup>[20]</sup>对导航星库进行均匀化处理, 最终得到 3 289 颗导航星.

#### 1.1.2 基于小孔成像的坐标映射模型

在获得均匀化的导航星库后, 需要建立恒星从天球赤道坐标系到像平面坐标系的坐标映射模型. 本文采用传统的小孔成像模型<sup>[18]</sup>模拟恒星的星光矢量通过星敏传感器映射到成像平面的过程, 该模型被广泛用于实现恒星三维坐标到像平面二维坐标的转换<sup>[18,21-22]</sup>, 具体如图 1 所示. 其中,  $O'$  是星敏传感器的镜头中心,  $O$  是像平面中心, 以光轴  $OO'$  为星敏传感器拍摄方向即视轴方向,  $f$  为星敏传感器的焦距. 恒星  $A$  发射的光线通过镜头到达像平面, 像平面感光元件得到的星点  $a$  与恒星实际位置相反, 电路元件将其反转

为位置正确的星点映射. 镜头坐标系的  $x'$  轴与  $y'$  轴分别平行于像平面坐标系的  $x$  轴与  $y$  轴, 其中  $y'$  轴为北天极方向, 星图中星点的位置用  $(x, y)$  表示.




图 1 小孔成像投影模型

Fig.1 Small hole imaging projection model

在此基础上, 为了将导航星库中的天球赤道坐标系恒星映射到像平面坐标系中, 本文采用恒星角距计算公式以建立恒星经纬度与角距之间的映射关系<sup>[23]</sup>. 将地球观测点到天球上两恒星连线间的夹角定义为恒星的真实角距, 记为恒星角距  $\theta$ . 将镜头到像平面上两个星点间连线的夹角定义为星图中的角距, 记为星点角距  $\theta'$ . 在小孔成像模型中,  $\theta = \theta'$ . 天球坐标系中, 根据球面三角形的余弦定理有

$$\begin{aligned} \cos \theta &= \cos\left(\frac{\pi}{2} - \delta_1\right) \cos\left(\frac{\pi}{2} - \delta_2\right) + \\ &\sin\left(\frac{\pi}{2} - \delta_1\right) \sin\left(\frac{\pi}{2} - \delta_2\right) \cos(\alpha_1 - \alpha_2) = \\ &\sin \delta_1 \sin \delta_2 + \cos \delta_1 \cos \delta_2 \cos(\alpha_1 - \alpha_2) \quad (1) \end{aligned}$$

式中  $(\alpha_1, \delta_1)$  和  $(\alpha_2, \delta_2)$  分别为两个恒星的赤经和赤纬. 将两个恒星改成第  $i$  颗恒星  $(\alpha_i, \delta_i)$  与视轴方向  $(\alpha_0, \delta_0)$  的经纬度, 得到第  $i$  颗恒星与拍摄视轴之间的恒星角距  $\theta_i$  满足

$$\cos \theta_i = \sin \delta_i \sin \delta_0 + \cos \delta_i \cos \delta_0 \cos(\alpha_i - \alpha_0) \quad (2)$$


为了确定第  $i$  颗恒星坐标映射后星点在星图中的位置, 需要角距和方向角两个参数. 角距信息  $\theta_i$  通过式 (2) 得到, 接下来计算第  $i$  颗恒星相对于视轴的方向角, 即图 2(a) 中恒星  $A$ 、视轴  $P$ 、北天极  $N$  的夹角  $p_i$ . 图 2(a) 中的  $\triangle APN$  同样构成球面三角形, 由球面三角形的正弦定理可得

$$\sin p_i = \frac{\cos \delta_i \sin(\alpha_i - \alpha_0)}{\sin \theta_i} \quad (3)$$

假设第  $i$  颗恒星  $A_i$  的恒星角距为  $\theta_i$ , 方向角为  $p_i$ , 根据小孔成像模型, 它的投影点  $a_i$  在星图中的位置如图 2(b) 所示,  $a_i$  的坐标  $(x, y)$  计算公式为

$$\begin{cases} x = -f \tan \theta_i \sin(p_i - \varphi) + x_0 \\ y = f \tan \theta_i \cos(p_i - \varphi) + y_0 \end{cases} \quad (4)$$

式中:  $x_0$  和  $y_0$  为像平面中心点对应的纵横坐标, 像素;  $\varphi$  为镜头自转的滚转角, 逆时针方向为正. 至此, 建立了基于小孔成像模型的恒星三维坐标到像平面二维坐标映射方法.



(a) 方向角三维示意 (b) 像平面示意

图 2 方向角示意

Fig.2 Schematic of direction angle

1.1.3 仿真星图的生成与噪声添加

在通过坐标映射模型得到像平面星点坐标后, 为了使星图识别算法更好地学习真实星图特征, 仿真星图应具有真实星图中的恒星光线与背景噪声分布. 为了生成含噪声的仿真星图, 需要确定像平面中星点分布的像素范围和灰度值大小. 恒星星等大小和像平面星点质心灰度值的转换关系如下<sup>[24]</sup>.

$$K = 255 / 2.51^{m-5} \tag{5}$$

式中:  $K$  为星点质心的灰度值;  $m$  为恒星的星等值. 恒星星等  $m$  越小, 星点质心的灰度值  $K$  越大. 光线传到感光平面上会有弥散效应, 即使不考虑背景噪声, 像平面的星点处也不会是一个点, 而是一个以星点质心为原点, 向四周高斯扩散的亮斑. 星点亮斑灰度值分布用高斯分布模拟<sup>[24]</sup>, 具体公式如下.

$$I(x, y) = K \exp \left[ \frac{-(x-x_0)^2 - (y-y_0)^2}{-2\sigma^2} \right] \tag{6}$$

式中:  $I(x, y)$  为平面  $(x, y)$  坐标处的灰度值;  $\sigma$  为模拟高斯分布的标准差.


在实际拍摄条件下, 由于宇宙杂光和成像器件本身噪声的干扰, 星图的背景灰度不会完全是 0. 这些干扰在星图上产生的杂光可统称为背景噪声, 一般使用高斯噪声进行模拟<sup>[24]</sup>. 在坐标映射模型生成的星图中添加均值为 0 且标准差为 0.005 的高斯噪声, 具体如图 3 所示. 在添加背景噪声后, 仿真星图中出现大量低亮度噪点, 一些在无噪声情况下可以明显观察到的低亮度星点在背景噪声中变得难以识别, 更加符合实际拍摄情境<sup>[25]</sup>.




(a) 无噪声星图



(b) 含背景噪声星图



(c) 无噪声星图灰度值



(d) 含噪声星图灰度值

图 3 含背景噪声星图的灰度值分布

Fig.3 Distribution of gray values for star-maps with background noise

此外, 实际拍摄的星图除背景噪声还会存在各种星点噪声. 与背景噪声不同, 这类有关星点本身的噪

声难以通过预处理算法去除,主要包括位置噪声、星等噪声、假星和缺失星<sup>[26-27]</sup>。星图的位置噪声是星图中实际星点位置与理论星点位置之间的偏差,本文通过对星图中星点横纵坐标添加高斯噪声实现模拟;星等噪声是星图中星点实际灰度值与恒星星等对应理论灰度值之间的亮度偏差,通过对视场内恒星星等添加高斯噪声以模拟星等噪声;缺失星是星图中低亮度星点不明显或直接消失的现象;假星是由某些背景射线或漂浮物在图像上形成的与星点相似的光斑,通过随机去除和添加星图中星点以模拟缺失星和假星。

为了观察不同噪声对星图的影响,对同一张标准星图添加不同类型的噪声,对标准星图部分星点进行标号,结果如图4所示。图4(b)添加了均值为0、标准差为4像素的位置噪声,其中方框标识的1号、2号星点有明显的位置偏移。图4(c)添加了均值为0、标准差为0.9像素的星等噪声,可以看出方框标识位置处的3号星点亮度有明显增加,1号星点亮度显著下降。图4(d)的缺失星数目设置为3,标准星图中4号、5号和6号星点消失。图4(e)的假星数目设置为3,图中方框处出现了3个亮度随机的虚假星点。

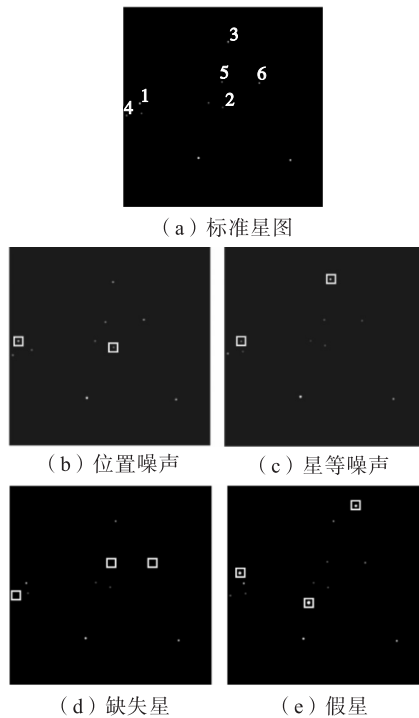


图4 不同噪声对星图的影响

Fig.4 Effect of different noises on star-map

## 1.2 星图识别算法的构建

在获得含噪声的仿真星图后,针对神经网络识别算法难以在识别准确率与计算成本之间取得平衡的问题,构建一个基于注意力机制的端到端轻量化星图识别算法 MobileCiT. 本文在 CNN 的基础上进行改

进,包括调整初步下采样、添加通道自注意力、改进前置倒残差结构、细化自注意力特征提取和完善网络结构,旨在提高识别效果的同时减少计算量。

### 1.2.1 调整初步下采样

神经网络通常在第1层使用初步下采样层对输入图片进行特征提取. 在传统 CNN 中,初步下采样层普遍由多个步距为2的2倍下采样卷积层和池化层共同组成. 然而, Liu 等<sup>[28]</sup>的研究结果表明在卷积网络中使用大卷积核进行初步下采样能够取得更好效果. 因此,本文使用一个卷积核大小为 $4 \times 4$ 、步距为4的卷积层实现初步下采样,以减少计算量。

### 1.2.2 添加通道注意力

星图识别网络主要学习星图中星点的相对位置,在低亮度背景噪声中学习高亮度星点特征是注意力机制的优势. 注意力机制包括通道注意力和自注意力等,在网络中添加通道注意力可以使识别算法在背景噪声中更好地学习星点信息. 压缩激发(squeeze-and-excitation, SE)模块<sup>[29]</sup>是经典的通道注意力结构,通过学习通道间关系提升网络的特征表达能力. 高效通道注意力(efficient channel attention, ECA)模块<sup>[30]</sup>是基于 SE 模块的改进,采用两层 $1 \times 1$ 卷积层替代 SE 模块中的全连接层,在保持原有功能不变的同时减少了模型参数,使整体结构更加轻量化. 因此, MobileCiT 使用 ECA 模块实现网络的通道注意力。

### 1.2.3 改进前置倒残差结构

为进一步提高网络的识别准确率,本文以倒残差结构为基础,通过调整其内部框架得到前置倒残差结构与改进的前置倒残差结构,具体如图5所示. 倒残差结构最先由 MobileNet 在残差结构和深度可分离卷积的基础上提出<sup>[15]</sup>. 在该结构中,第1层用 $1 \times 1$ 卷积升维,第2层用 $3 \times 3$ 深度可分离卷积提取特征,第3层用 $1 \times 1$ 卷积降维,有 $C_{temp} > C_{in}$ 和 $C_{temp} > C_{out}$ . 其中, $C_{in}$ 为输入特征图的通道数, $C_{out}$ 为输出特征图通道数, $C_{temp}$ 为卷积操作期间的临时通道数。

在倒残差结构基础上调整其内部构架,得到前置倒残差结构. 在 Transformer 编码器中<sup>[31]</sup>,首先通过多头自注意力(multi-headed self-attention, MSA)提取输入图的图像特征,后通过多层感知器(multilayer perceptron, MLP)模块进行先升维后降维操作,该计算过程与倒残差结构相似. 仿照 Transformer 编码器提取特征后升维降维的顺序,对倒残差结构进行改进. 将倒残差结构第2层的特征提取卷积层和第1层的升维卷积层调换位置,整体结构满足 $3 \times 3$ 深度卷积提取特征、 $1 \times 1$ 卷积升维和 $1 \times 1$ 卷积降维的功

能分布,形成前置倒残差结构.

在得出倒残差结构的功能层次分布后,调整其内部框架.仿照 Transformer 的大卷积构架,将深度可分离卷积层的卷积核大小由  $3 \times 3$  扩大到  $7 \times 7$ <sup>[28]</sup>,在去除激活函数 ReLU6 的同时使用 Transformer 中的

层标准化(layer normalization, LN)代替 CNN 常用的批标准化(batch normalization, BN)作为归一化层.在第 2 层去除归一化层,只保留激活函数.在前置倒残差结构的升维和降维卷积层之间加入 ECA 模块,以学习高亮星点和背景噪声之间的通道特征差异.

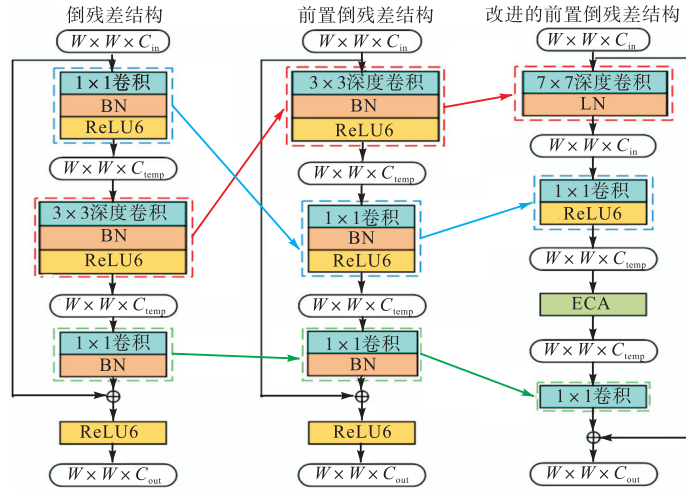


图 5 改进的前置倒残差结构

Fig.5 Improved pre-inverted residual structure

最终,在本文提出的星图识别网络 MobileCiT 使用改进的前置倒残差结构中,输入特征图首先通过  $7 \times 7$  的深度可分离卷积和 LN 归一化层学习图像特征,不改变图像大小.然后通过  $1 \times 1$  卷积层和 ReLU6 激活函数在不改变图像大小的情况下对特征通道进行升维.最后使用  $1 \times 1$  卷积层对通道数降维.整个过程只在第 2 层和第 4 层改变特征通道数.

1.2.4 细化 Transformer 特征提取

Transformer 自注意力可以有效提取数据的重要特征<sup>[31]</sup>,符合星图识别重点关注星点的任务需求. Transformer 编码器使用 MSA 编码特征,核心结构缩放点积注意力的输出 attention 计算公式如下.

$$\text{attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (7)$$

式中: softmax 为激活函数;  $\mathbf{Q}$ (查询向量)、 $\mathbf{K}$ (键向量)和  $\mathbf{V}$ (值向量)是计算自注意力的 3 个矩阵;  $d_k$  为矩阵  $\mathbf{K}$  的维数.  $\mathbf{Q}$  和  $\mathbf{K}^T$  的乘积构成了特征序列中每个元素与其他元素之间的注意力权重.在此基础上除以  $\sqrt{d_k}$  进行归一化,防止乘积过大导致的梯度消失.结合矩阵  $\mathbf{V}$  实现对全局特征的关注,以稳定训练过程.  $\mathbf{Q}$ 、 $\mathbf{K}$  和  $\mathbf{V}$  可通过输入序列计算得到,即

$$\begin{cases} \mathbf{Q} = \mathbf{X}\mathbf{W}_Q \\ \mathbf{K} = \mathbf{X}\mathbf{W}_K \\ \mathbf{V} = \mathbf{X}\mathbf{W}_V \end{cases} \quad (8)$$

式中:  $\mathbf{X}$  为输入特征序列;  $\mathbf{W}_Q$ 、 $\mathbf{W}_K$  和  $\mathbf{W}_V$  为可学习的参数矩阵. 并列  $n$  层缩放点积注意力,第  $i$  层对应的输入  $\mathbf{Q}_i$ 、 $\mathbf{K}_i$  和  $\mathbf{V}_i$  由总输入  $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$  映射得到,第  $i$  层的输出  $\text{head}_i$  为

$$\text{head}_i = \text{attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \quad (9)$$

$$\text{MSA}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n)\mathbf{W}_0 \quad (10)$$

最后将  $n$  个输出得到的结果进行 concat 拼接,乘以可学习的矩阵  $\mathbf{W}_0$  融合降维,得到输出结果 MSA.

基于 Transformer 自注意力的 ViT(vision transformer)网络可以直接学习输入图像的全局特征<sup>[32]</sup>,但该网络参数量大、计算速度慢的缺点与星图识别轻量化的需求背道而驰.随着对卷积与 Transformer 的研究不断深入,可以使用卷积代替 ViT 网络中的分类标签和位置编码以提取特征<sup>[16]</sup>.借鉴 MobileViT 模型中的特征提取方式降低自注意力计算成本,具体流程如图 6 所示.该特征提取过程呈现先升维后降维的倒残差结构,重点关注展平和折叠过程.在展平操作中,将特征图矩阵划分为大小相同的数个切片,如图 6 所示.其中每个切片占据  $2 \times 2$  像素所对应的特征矩阵中的 4 个矩阵元素,切片内每个矩阵元素用不同颜色表示.展平维度时,每个元素只和相同颜色的特征计算自注意力.相比于每个像素和所有像素对应的特征矩阵值一起计算特征,理论计算成本只有

原先的  $1/4^{[16]}$ . 折叠过程进行反向操作, 将结果恢复成输入特征的大小. 由于输入特征已经经过了卷积层的特征提取和局部建模, 相邻像素所对应的信息差异较少, 因此可以通过划分区块节省计算成本.




图6 Transformer特征提取

Fig.6 Transformer feature extraction

1.2.5 完善网络结构

上述操作都是对网络局部结构的改进, 接下来完善 MobileCiT 网络模型的宏观架构. 由于星图缺少局部特征, 星图识别网络不需要较深的卷积层数依次学

习局部纹理特征和全局特征. 本文提出的 MobileCiT 网络通过自注意力直接学习星图的全局特征.

对于网络整体结构, 首先是由卷积层组成的下采样部分, 对输入图像下采样, 提取图像不同位置的局部特征以用于后续计算. 然后是网络的核心部分, 选择不含 ECA 的改进前置倒残差结构作为基础模块, 组成 ECA 模块和 ViT 模块. ECA 模块由 1 层 2 倍下采样的基础模块、1 层添加 ECA 的基础模块和 1 层基础模块堆叠而成. ViT 模块由 1 层 2 倍下采样的基础模块和 1 层添加展平-编码-折叠结构的基础模块构成, 其中 MSA 采用 4 层缩放点积注意力. 网络中的非  $1 \times 1$  卷积层使用深度可分离卷积, 得到识别网络模型架构如图 7 所示. 依次是改进的初始下采样层、ECA 模块、ViT 模块、ECA 模块, 最后使用卷积层、池化层和归一化层得到分类结果. 本文研究表明, 相比于添加更多的 ViT 模块或使用更多 ECA 与 ViT 互换的结构, 该夹层结构能够在降低模型层数的同时达到更好效果.

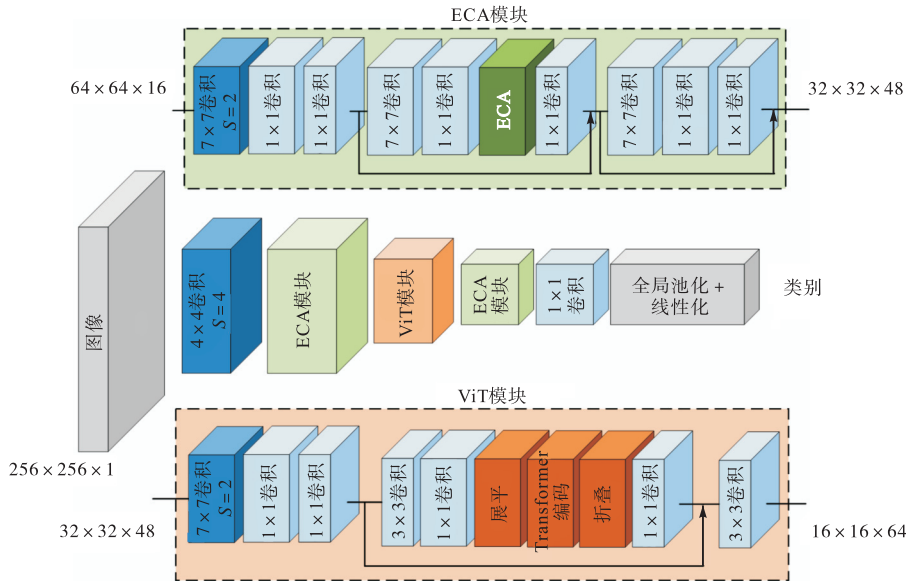


图7 本文识别网络的整体结构

Fig.7 Overall structure of the proposed identification network

2 算法实验测试及性能分析

神经网络星图识别算法需要训练集学习导航星的模式特征, 也需要测试集测试识别网络的性能. 选择识别准确率和计算量作为识别算法的评价指标, 量化网络架构改进和 Transformer 划分区块过程中每一步操作对性能的影响. 选择基于卷积的 MobileNet 网络和基于注意力机制的 MobileViT 网络作为神经网络架构的比较对象, 验证本文 MobileCiT 算法的网络架构在识别含噪声星图方面的性能. 在此基础上选

取金字塔算法<sup>[7]</sup>、改进栅格算法<sup>[8]</sup>、径向与动态循环算法<sup>[11]</sup>和径向三角形矩阵算法<sup>[12]</sup>与本文的 MobileCiT 算法进行比较, 进一步评价 MobileCiT 的先进性.

2.1 训练集与测试集

采用第 1.2 节的星图仿真算法, 对导航星库中 3 289 颗导航星进行仿真以制作训练集和测试集. 选择每颗导航星方向为视轴方向, 视场大小取  $12^\circ$ , 生成含标准差 0.005 背景噪声的 256 像素  $\times$  256 像素的仿真星图, 训练集总容量为 986 700. 由于镜头存在

自旋角度,网络的泛化能力需考虑旋转不变性,要求当拍摄设备滚转角变化时,仍然能够正确识别主星编号.因此,在网络训练时在 90°范围内随机旋转输入图像,以学习图像旋转特征.相应地,生成测试集用于对星图识别算法的效果进行验证,分别构建总测试集和分类测试集.总测试集包含的噪声强度与训练集相同,仅减少星图数量,用于测试算法对含噪声星图的整体识别效果.分类测试集在每个噪声类别中添加未训练过的更高强度噪声,用于细分算法对不同噪声的鲁棒性.

### 2.2 识别算法评价指标

对于星图识别网络,采用的主要评价标准是星图主星的识别准确率、识别速度和对各类噪声的抗干扰能力.本文选择识别准确率、Kappa 系数、网络计算量和网络参数量作为星图识别网络的评价指标.识别准确率是评价星图识别算法最常用的指标之一,对于输入的含噪声星图,网络输出的主星编号与主星对应的导航星编号相同则认为识别成功,否则认为识别失败.定义网络的识别准确率为网络识别成功的星图数目与输入星图总数之比.考虑到星图具有旋转不变性,为验证星图识别网络是否能够正确识别对旋转后的星图,本文分别将测试星图旋转 0°、15°、45°和 75°,记录上述 4 种情况下的星图识别准确率,取平均值作为最终准确率.Kappa 系数是用于衡量多分类神经网络性能的指标,范围为[0, 1].Kappa 系数越高,代表网络的分类准确度越高.网络计算量指每秒浮点运算次数(floating-point operations per second, FLOPs),每一次加减乘除操作的 FLOPs 都为 1, FLOPs 越大,网络识别星图需要的计算量越大,网络的时间复杂度越高.网络参数量是网络本身的大小,参数量越大,就需要更多内存空间储存该网络,网络空间复杂度越高.

### 2.3 实验结果分析

本次星图识别算法测试中的所有网络基于 Pytorch 框架构建,所有网络在 NVIDIA GeForce GTX750Ti 硬件环境中运行.计算机处理器为 Intel(R) Core(TM) i5-7400CPU@3.00 GHz,内存 16.0 GB.使用本文训练集训练识别网络参数,不添加预训练权重.网络的输入图像大小调整为 256 像素×256 像素,计算训练集星图中的所有像素,得出其平均值为 0.033,标准差为 0.039.为了方便训练时星图识别算法的网络函数迭代,对输入星图进行归一化处理.归一化后所有输入特征图像像素的均值为 0,标准差为 1.为了增加网络对星图旋转的鲁棒性,训练时对输入星图随机旋转.训练的批次大小设置为 16,使用

AdamW 优化器优化识别网络参数,设置学习率为 0.000 2,使用交叉熵作为损失函数.

#### 2.3.1 网络改进过程分析

为了量化网络架构改进过程中每一步操作对性能的影响,本文使用训练集训练识别网络并记录改进过程中每个网络对总测试集的识别准确率和 FLOPs,汇总结果绘制于图 8.结果显示,以 MobileViT 网络为基准,首先使用大小为 4×4、步距为 4 的卷积层替换原有的初步下采样结构,准确率降低 0.300%,FLOPs 从 264.48×10<sup>6</sup>下降到 200.24×10<sup>6</sup>.将倒残差结构中的卷积层上移形成前置倒残差结构,准确率提高到 99.750%,FLOPs 降低到 193.81×10<sup>6</sup>.然后,将 3×3 卷积核替换为 7×7 卷积核,减少归一化层和激活函数的数量,在前置倒残差结构的基础上添加 ECA,形成改进前置倒残差结构.这些操作使得准确率提高到 99.775%,而 FLOPs 保持在 194.59×10<sup>6</sup>.最后,在改进前置倒残差结构的基础上减少 ECA 的使用频率并嵌入展平-编码-折叠结构,形成 ECA 模块与 ViT 模块.对其按顺序进行排列,构成如图 7 所示的星图识别网络.精简宏观构架后,识别网络的准确率提升到 99.850%,FLOPs 降低到 85.74×10<sup>6</sup>,为基准 MobileViT 网络的 1/3.




图 8 网络改进过程

Fig.8 Network improvement process

在此基础上,为了继续减少自注意力计算成本,本文探究了将 Transformer 模块内的输入特征划分为大小不同的区块对网络识别效果产生的影响,得到网络识别准确率和 FLOPs,结果如表 1 所示.当分区中的元素个数从 1×1 提升到 2×2,即从不分区到分区,准确率有所上升,继续增大分区中的元素个数,准确率开始下降.这可能是因为星图中每颗星点信息本就只占据 3 像素×3 像素到 5 像素×5 像素,即使经过卷积特征提取,有效信息仍旧较为集中.分区中的元素个数过大会导致神经网络学习不到重要特征,造成算法识别准确率下降.测试结果表明,在 Transformer 模块中将输入特征划分成大小为 2×2

的区块能够达到最好的效果。

### 2.3.2 网络宏观架构分析

在确定本文网络 ECA-ViT-ECA 层次的宏观架构后,为验证自注意力结构中模块数目和位置对网络识别效果的影响,添加 ViT 模块数目并改变其排列顺序.将本文网络与 ECA-ViT-ViT-ECA 结构和 ViT-ECA-ViT 结构进行对比,以评价 3 种结构识别准确率和计算速度的优劣.记录不同网络对总测试集的识别结果,具体如表 2 所示.测试结果显示单纯添加 ViT 模块数目不会提高网络准确率,但会增加 FLOPs.而将 ECA 模块和 ViT 模块位置调换后,网络准确率下降,FLOPs 明显提高.这是因为输入图片在经过每一个 ECA 模块或 ViT 模块时,内部第 1 层改进前置残差结构都会对图片大小进行 2 倍下采样.而 ViT 的自注意力主要计算图像中各特征间的相关性,图像越大,需要计算的信息就越多.考虑到图像识别网络需要在更高的准确率和更少的计算量之间达到平衡,ECA-ViT-ECA 结构的效果更优.

表 1 不同区块划分大小下的识别结果

Tab.1 Identification results for different block sizes

| 区块划分大小 | 准确率/%  | FLOPs/10 <sup>6</sup> |
|--------|--------|-----------------------|
| 1×1    | 99.800 | 86.03                 |
| 2×2    | 99.850 | 85.74                 |
| 4×4    | 99.750 | 85.66                 |
| 8×8    | 99.750 | 85.64                 |

表 2 网络结构对比结果

Tab.2 Comparative results of network structures

| 网络类别            | 准确率/%  | FLOPs/10 <sup>6</sup> |
|-----------------|--------|-----------------------|
| ECA-ViT-ECA     | 99.850 | 85.74                 |
| ECA-ViT-ViT-ECA | 99.850 | 99.11                 |
| ViT-ECA-ViT     | 99.780 | 146.00                |

### 2.3.3 网络对比

本文研究一个基于神经网络注意力机制的端到端轻量化星图识别算法 MobileCiT,结合了卷积网络和 Transformer 网络的优点.为验证该网络的识别效果,将其与基于卷积的 MobileNet 网络和基于注意力机制的 MobileViT 网络进行比较.它们对于 12°视场下总测试集的准确率、Kappa 系数、FLOPs 和参数量如表 3 所示.结果显示,MobileCiT 的识别准确率和 Kappa 系数大于上述两种网络,计算量约为 MobileViT 的 1/3,与纯卷积的 MobileNet 相似.卷积网络使用深度堆叠提取全局特征,虽然计算量低,但是层层堆叠会增加网络参数量. Transformer 参数较少,但要付出更多计算成本.本文提出的 MobileCiT 的参数量小于上述两种网络.测试结果表明,本文通过缩减模型整体堆叠深度,获得了占用空间更少、计

算速度较快、识别准确率更高的 MobileCiT 星图识别网络.

表 3 MobileCiT、MobileNet、MobileViT 识别结果比较  
Tab.3 Comparison of identification results among MobileCiT, MobileNet and MobileViT

| 识别网络      | 准确率/%  | Kappa 系数 | FLOPs/10 <sup>6</sup> | 参数量/10 <sup>6</sup> |
|-----------|--------|----------|-----------------------|---------------------|
| MobileCiT | 99.850 | 0.998 4  | 85.74                 | 0.66                |
| MobileNet | 98.350 | 0.986 1  | 80.59                 | 2.54                |
| MobileViT | 99.200 | 0.992 0  | 264.48                | 0.98                |

上述分析是基于总测试集的结果,接下来使用细分 4 种噪声的测试集验证 MobileCiT 对强噪声的鲁棒性.上述 3 种网络在位置噪声、星等噪声、假星、缺失星 4 种星点噪声类型下的识别准确率如图 9 所示.可以看出,本文 MobileCiT 网络在标准差 6 像素的位置噪声强度下仍然能够达到 95.350% 的识别准确率,比 MobileNet 的 91.775% 高出 3.575%.在标准差 1.05 像素的星等噪声下,MobileCiT 能够达到 98.325% 的准确率,比 MobileViT 的 92.975% 提高 5.350%.在假星噪声中,选择 7 颗假星为噪声强度上限,此时 MobileCiT 的识别准确率为 95.100%,比 MobileViT 的 84.400% 高出 10.700%.对于缺失星,由于部分星图中只有 5 个星点,因此缺失星个数最多只能取到 5.对于常见的 3 颗以内的缺失星,MobileCiT 可以保持准确率高于 99.000%,对于最大缺失星强度,准确率达到 75.350%,比 MobileViT 的 52.725% 高出 22.625%.在测试集中,有 19.37% 的星图在缺失星个数为 4 时剩余星点数小于 4,但 MobileCiT 识别准确率仍然达到 94.250%.这意味着 MobileCiT 成功识别了一些星点数量小于 4 的星图,这是使用星点三角形进行角距匹配的子图同构算法难以实现的任务.

实验结果表明,随着 4 种星点噪声强度逐渐增加,不同网络的识别准确率都有所下降,但 MobileCiT 在任意噪声强度的准确率都显著高于另外两种网络.在星等噪声、假星和缺失星 3 种星点噪声中,MobileViT 的准确率在任意噪声强度下均高于 MobileNet 的准确率;而 MobileViT 的准确率在低位置噪声下略高于 MobileNet 的准确率,高位置噪声下相反.这是因为星等噪声、假星和缺失星都没有改变星图中存在星点之间的相对位置分布,自注意力机制的全局特征学习能力可以更好地提取星图全局特征.然而,位置噪声改变了图像中星点之间的位置关系.尽管 Transformer 的全局特征编码能力在低位置噪声时有较好的识别效果,但对高位置噪声的鲁棒性

较低,在这方面卷积层堆叠有更好的效果.卷积结构不仅在运行速度方面优于 Transformer,在对位置噪声鲁棒性上也有一定作用.而自注意力机制在星等噪声、假星、缺失星方面鲁棒性更好,整体识别准确率更高.相比于基于卷积的 MobileNet 网络和基于注意力机制的 MobileViT 网络,MobileCiT 网络在保证了对噪声鲁棒性的同时,提高了识别精度并减少了网络计算成本.

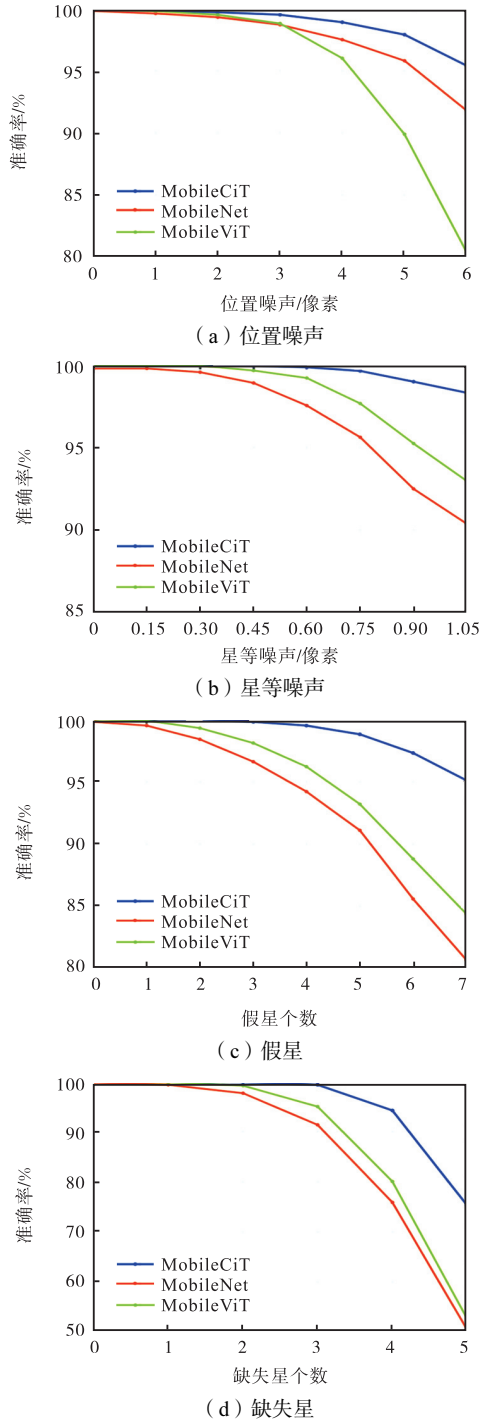


图 9 不同噪声强度下的模型准确率

Fig.9 Model accuracy at different noise intensities

### 2.3.4 不同类型的星图识别算法对比

前文测试结果说明了 MobileCiT 网络相比于现有的基于卷积的 MobileNet 网络和基于注意力机制的 MobileViT 网络具有更高的性能.为了评价星图识别算法 MobileCiT 网络的先进性,本节选取了金字塔算法、改进栅格算法、径向与动态循环算法和径向三角形矩阵算法作为比较对象,将上述算法在位置噪声、假星和星等噪声条件下的识别准确率作为评价标准以评估算法间的性能差异.上述算法的预处理过程采用了相同的背景去噪<sup>[4]</sup>、连通域检测<sup>[24]</sup>与星点质心提取<sup>[4]</sup>算法,而本文基于神经网络的端到端算法不需要该过程.MobileCiT 网络在噪声中的识别准确率已在前文给出,本节在算法测试中所使用的测试集与在前文中测试 MobileCiT 网络性能所采用的测试集相同,在 MATLAB 2023 平台上对上述算法进行测试,结果如图 10 所示.

位置噪声会改变星点间相对位置,这对依赖于通过星点间角距进行匹配的金字塔算法的影响较大.在图 10(a)中,当位置噪声标准差为 0.5 时,5 种算法都能保持较高的识别准确率.但随着噪声强度不断提高,除 MobileCiT 以外的 4 种算法的识别准确率迅速下降.当位置噪声标准差为 3 时,金字塔算法、改进栅格算法、径向与动态循环算法和径向三角形矩阵算法的识别准确率分别降至 22.102%、50.955%、54.711% 和 60.369%,远低于 MobileCiT 的 99.450%.假星会使星图中出现额外星点,干扰星图的全局特征.星图中假星数目的增加会导致星图识别算法的准确率下降.在图 10(b)中,当假星个数为 4 时,金字塔算法、改进栅格算法、径向与动态循环算法和径向三角形矩阵算法的识别准确率分别为 89.308%、83.891%、89.376% 和 93.812%,低于本文提出算法的 99.450%.星等噪声会随机提高或降低星图中星点亮度,导致星点提取过程中出现伪星或恒星缺失.随着星等噪声强度的提高,星图识别算法的识别准确率会逐渐下降.图 10(c)中,当星等噪声的标准差为 0.90 时,MobileCiT 依旧能够达到 99.000% 的准确率.此时,金字塔算法的准确率只有 82.120%,改进栅格算法的准确率为 81.288%,径向与动态循环算法的准确率为 84.195%,径向三角形矩阵算法的准确率为 93.837%,均低于 MobileCiT 的准确率.

需要说明的是,传统的子图同构与模式识别算法需要使用星图预处理算法提取星点坐标,但是本文提出的端到端识别网络 MobileCiT 允许直接使用含噪声星图作为输入,不需要星图预处理算法进行星点坐

标提取. 这在一定程度上规避了由星图预处理算法所带来的识别误差.

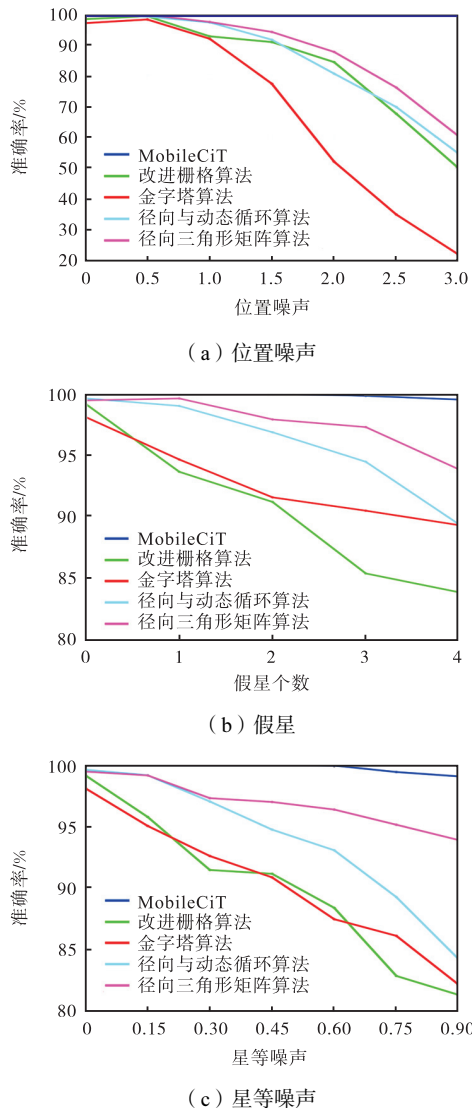


图 10 5种星图识别算法在不同噪声下的识别准确率

Fig.10 Identification accuracy of five star-map identification algorithms with different noises

### 3 结 语

针对神经网络识别算法难以在识别准确率与计算成本之间取得平衡的问题, 本文研究一种基于注意力机制的端到端轻量化星图识别算法. 首先, 采用基于小孔成像的含噪声星图仿真算法, 实现具有相应噪声特征的像平面星图训练集与测试集生成, 在此基础上进行星图识别算法的研究. 之后, 通过调整初步下采样、添加通道注意力、改进前置倒残差结构、细化自注意力特征提取部分并完善网络宏观结构, 得到更加适合星图识别任务的基于注意力机制的端到端轻量化星图识别网络 MobileCiT. 最后, 使用训练集训

练 MobileCiT 网络参数, 在此基础上利用测试集进行了一系列实验与分析. 主要包括网络改进过程分析, 网络宏观架构分析, MobileCiT 网络与现有轻量化网络 MobileNet 和 MobileViT 的性能比较, 与金字塔算法、改进栅格算法、径向与动态循环算法和径向三角形矩阵算法的噪声鲁棒性比较. 试验结果表明, 通过在 MobileViT 网络的基础上进行改进并使用 ECA-ViT-ECA 宏观架构, MobileCiT 网络对含噪声星图的识别准确率和 Kappa 系数提升至 99.850%、0.9984, 优于 MobileNet 网络与 MobileViT 网络. MobileCiT 网络的 FLOPs 为  $85.74 \times 10^6$ , 低于 MobileViT 网络的 FLOPs, 但略高于 MobileNet 网络的 FLOPs; 参数量为  $0.66 \times 10^6$ , 均低于上述两种网络. 相比于基于子图同构与基于模式识别的星图识别算法, MobileCiT 网络具有更高的噪声鲁棒性与识别准确率. 综上所述, 在 CNN 普遍具有对星图中噪声鲁棒性的基础上, 本文提出的 MobileCiT 网络在提升识别精度的同时具有较低的时空复杂度, 结合了卷积和自注意力机制的优势, 能够在无需预处理的情况下实现高精度的星图识别, 具有更高的识别准确率.

### 参考文献:

- [1] Wang B D, Wang H, Jin Z H. An efficient and robust star identification algorithm based on neural networks[J]. Sensors, 2021, 21(22): 7686-7698.
- [2] 徐彬, 郑勇, 陈张雷, 等. 星光导航星点目标区域提取算法改进[J]. 测绘学报, 2023, 52(5): 760-768.
- [3] Xu Bin, Zheng Yong, Chen Zhanglei, et al. The improvement of star target region extraction algorithm for star centroid[J]. Acta Geodaetica et Cartographica Sinica, 2023, 52(5): 760-768(in Chinese).
- [4] 梁斌, 朱海龙, 张涛, 等. 星敏传感器技术研究现状及发展趋势[J]. 中国光学, 2016, 9(1): 16-29.
- [5] Liang Bin, Zhu Hailong, Zhang Tao, et al. Research status and development tendency of star tracker technique[J]. Chinese Optics, 2016, 9(1): 16-29(in Chinese).
- [6] Xu W, Li Q, Feng H J, et al. A novel star image thresholding method for effective segmentation and centroid statistics[J]. Optik, 2013, 124: 4673-4677.
- [7] Spratling B B, Mortari D. A survey on star identification

- algorithms[J]. Algorithms, 2009, 2(1): 93-107.
- [6] Padgett C, Kreutz-Delgado K. A grid algorithm for autonomous star identification[J]. IEEE Transactions on Aerospace and Electronic Systems, 1997, 33(1): 202-213.
- [7] Mortari D, Samaan M A, Bruccoleri C. The pyramid star identification technique[J]. Journal of the Institute of Navigation, 2004, 51(3): 171-184.
- [8] Na M, Zheng D N, Jia P F. Modified grid algorithm for noisy all-sky autonomous star identification[J]. IEEE Transactions on Aerospace and Electronic Systems, 2009, 45(2): 516-522.
- [9] Aghaei M, Moghaddam H. Grid star identification improvement using optimization approaches[J]. IEEE Transactions on Aerospace and Electronic Systems, 2016, 52(5): 2080-2090.
- [10] Zhang G J, Wei X G, Jiang J. Full-sky autonomous star identification based on radial and cyclic features of star pattern[J]. Image & Vision Computing, 2008, 26(7): 891-897.
- [11] Wei X, Wen D S, Song Z X, et al. A star identification algorithm based on radial and dynamic cyclic features of star pattern[J]. Advance in Space Research, 2019, 63(7): 2245-2259.
- [12] Du J Y, Wei X G, Li J, et al. Star identification based on radial triangle mapping matrix[J]. IEEE Sensors Journal, 2022, 22(9): 8795-8807.
- [13] 马涛, 孙红辉, 肖松, 等. 基于 BP 神经网络的小样本星图识别方法[J]. 应用光学, 2009, 30(2): 252-256.
- Ma Tao, Sun Honghui, Xiao Song, et al. Recognition algorithm for star pattern of little swatch based on BP neural network[J]. Journal of Applied Optics, 2009, 30(2): 252-256 (in Chinese).
- [14] Wang H, Wang Z Y, Wang B D, et al. An artificial intelligence enhanced star identification algorithm[J]. Frontiers of Information Technology & Electronic Engineering, 2020, 21: 1661-1670.
- [15] Howard A G, Zhu M L, Chen B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[EB/OL]. <https://arxiv.org/abs/1704.04861>, 2017-04-17.
- [16] Sachin M, Mohammad R. MobileViT: Light-weight, general-purpose, and mobile-friendly vision transformer[EB/OL]. <https://arxiv.org/abs/2110.02178>, 2022-03-04.
- [17] 凌翔, 郑宏亮, 何元驹. 数字星图生成算法的设计与仿真[J]. 实验室研究与探索, 2018, 37(2): 120-123.
- Ling Xiang, Zheng Hongliang, He Yuanju. Design and simulation of digital star map generation algorithm[J]. Research and Exploration in Laboratory, 2018, 37(2): 120-123 (in Chinese).
- [18] Quan W, Xu L, Fang J C. A new star identification algorithm based on improved Hausdorff distance for star sensors[J]. IEEE Transactions on Aerospace and Electronic Systems, 2013, 49(3): 2101-2109.
- [19] 陈雪芬, 康国华. 基于 ITSI 优选算法的星敏感器导航星库建立[J]. 传感技术学报, 2015, 28(3): 381-386.
- Chen Xuefen, Kang Guohua. Guide star database creation for the star sensor based on ITSI selection algorithm[J]. Chinese Journal of Sensors and Actuators, 2015, 28(3): 381-386 (in Chinese).
- [20] 王海涌, 徐皓. 一种星敏感器导航星筛选算法[J]. 激光与光电子学进展, 2021, 58(1): 343-349.
- Wang Haiyong, Xu Hao. Algorithm for screening navigation stars on star sensors[J]. Laser & Optoelectronics Progress, 2021, 58(1): 343-349 (in Chinese).
- [21] Van Bezooijen R W H. A star pattern recognition algorithm for autonomous attitude determination[J]. IFAC Proceedings Volumes, 1989, 22(7): 51-58.
- [22] 卫昕. 高精度星敏感器星图识别算法研究[D]. 西安: 中国科学院大学(中国科学院西安光学精密机械研究所), 2022.
- Wei Xin. Study on Star Centroid Extraction and Star Identification Method Based on Star Sensor[D]. Xi'an: University of Chinese Academy of Sciences (Xi'an Institute of Optics and Precision Mechanics of Chinese Academy of Sciences), 2022 (in Chinese).
- [23] 孙龙, 蔡佳楠. 一种折射星图的模拟方法[J]. 电子科技, 2018, 31(3): 21-23, 31.
- Sun Long, Cai Jianan. A simulative method of refraction star map[J]. Electronic Science and Technology,

- 2018, 31(3): 21-23, 31 (in Chinese).
- [24] 王海涌, 周文睿, 林浩宇, 等. 静态像点高斯灰度扩散模型参数估计方法[J]. 光学学报, 2012, 32(3): 275-280.  
Wang Haiyong, Zhou Wenrui, Lin Haoyu, et al. Parameter estimation of Gaussian gray diffusion model of static image spot[J]. Acta Optica Sinica, 2012, 32(3): 275-280 (in Chinese).
- [25] 支帅, 张刘, 李欣璐. 带噪声模拟仿真星图的实现[J]. 中国光学, 2014, 7(4): 581-587.  
Zhi Shuai, Zhang Liu, Li Xinlu. Realization of simulated star map with noise[J]. Chinese Optics, 2014, 7(4): 581-587 (in Chinese).
- [26] 胡坤, 陈嘉鸿, 谢元平. 一种基于旋转不变特征的星图识别算法[J]. 光电工程, 2015, 42(6): 20-26.  
Hu Kun, Chen Jiahong, Xie Yuanping. A novel star pattern identification algorithm based on rotation-invariant[J]. Opto-Electronic Engineering, 2015, 42(6): 20-26 (in Chinese).
- [27] 张广军, 魏新国, 江洁. 一种改进的三角形星图识别方法[J]. 航空学报, 2006, 27(6): 1150-1154.  
Zhang Guangjun, Wei Xinguo, Jiang Jie. Star map identification based on a modified triangle algorithm[J]. Acta Aeronautica et Astronautica Sinica, 2006, 27(6): 1150-1154 (in Chinese).
- [28] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]// 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, Canada, 2021: 9992-10002.
- [29] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018: 7132-7141.
- [30] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[EB/OL]. <https://arxiv.org/abs/1910.03151>, 2022-04-07.
- [31] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA, 2017: 6000-6010.
- [32] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16 × 16 words: Transformers for image recognition at scale[EB/OL]. <https://arxiv.org/abs/2010.11929>, 2021-06-03.

(责任编辑: 孙立华)