

多种深度学习组合应用于小样本空间目标分类研究

邓诗宇^{1,2}, 刘承志^{1,4*}, 谭勇^{3*}, 刘德龙¹, 张楠¹,
康喆¹, 李振伟¹, 范存波^{1,4}, 姜春旭³, 吕众³

1. 中国科学院国家天文台长春人造卫星观测站, 吉林 长春 130117
2. 中国科学院大学, 北京 100049
3. 长春理工大学理学院, 吉林 长春 130022
4. 中国科学院空间目标与碎片观测重点实验室, 江苏 南京 210008

摘要 随着近年来光谱探测仪器灵敏度、精确度和易用度的不断提升, 光谱技术已经深入到各行各业的物质成分的鉴定与分析中。对于空间目标的光谱观测是传统光学观测的重要拓展之一, 因其具有的非接触、无损伤等优点而备受关注, 然而由于观测条件所限, 空间目标的光谱数据量极小, 通过传统方法对其进行分类分析达不到较好效果, 必须探求提高分类精度的方法。首先, 通过 1.2 m 空间目标光学望远镜上搭载的光谱相机终端获取空间目标高光谱图像; 再通过天文学测光 IRAF 方法, 提取空间目标的一维光谱数据; 为对空间目标光谱进行分类, 提出一种结合多种深度学习解决方法小样本数据量的空间目标分类问题。该方法应用密度聚类方法将空间目标粗糙分类, 一维生成对抗网络方法增加空间目标数据, 一维卷积神经网络方法将空间目标精细分类, 三者组合进而达到较好的实验效果, 整体精度约为 79.1% (基于密度聚类、过采样、一维卷积神经网络方法组合、基于 K-means、一维生成对抗网络、一维卷积神经网络方法组合和基于 K-means、过采样、一维卷积神经网络方法组合的整体精度分别约为 78.4%, 77.9% 和 77.2%)。粗糙分类模型中, 密度聚类方法比 K-means 方法整体精度平均高出约为 0.67%; 数据增广模型中, 一维生成对抗网络方法比过采样方法整体精度平均高出约为 1.52%; 精细分类模型中, 一维卷积神经网络方法二层网络比三层网络整体精度平均仅高出约为 0.003%, 但是运算时间更长。四种组合方法精度均高于单一方法。实验结果表明本文提出的组合方法在小样本空间目标类别未知情况下, 可实现细分类且精度较高, 为实现空间目标极小数据量下的图谱一体化分析, 提供一定参考价值。

关键词 空间目标; 光谱数据; 密度聚类; 生成对抗网络; 卷积神经网络

中图分类号: TP29 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2022)02-0609-07

引言

近年来, 由于全球空间安全和环境监测的迫切需求, 空间目标的观测设备研制和数据分析已成为国防和科研领域的热点课题。光谱观测因其非接触、无损伤、准确快速等优点而受到关注。目前多种方法(如单狭缝光栅光谱仪、滤光片选通分时多色测光等)均能得到质量较好的数据, 但因观测条件所限, 光谱数据的样本通常极小。

深度学习随着人工智能领域的飞速发展, 已逐渐成为数据分析的热门领域。采用深度学习解决方法了大量人工

无法完成的工作, 例如极小样本(有限数量的样本)和高维度分析。本工作将多种深度学习(密度聚类、一维生成对抗网络、一维卷积神经网络)组合, 应用于小样本空间目标的光谱数据中, 有效地提高了观测数据的利用率, 扩展了数据的应用范围, 有利于对空间目标光谱数据进行深度挖掘。

1 国内外研究现状

Kim 等^[1]采用改进最远优先聚类算法对公开的真实结肠癌、乳腺癌、前列腺癌和淋巴瘤癌微阵列数据集进行元分类实验证实, 该方法优于单个个体分类器和其他替代方法。

收稿日期: 2021-01-08, 修订日期: 2021-02-07

基金项目: 国家自然科学基金项目(U1731240, U2031129, 12003052)资助

作者简介: 邓诗宇, 1990 年生, 中国科学院国家天文台长春人造卫星观测站博士研究生 e-mail: dengsy@cho.ac.cn

* 通讯作者 e-mail: lcz@cho.ac.cn; laser95111@126.com

本刊 36 卷 5 期刊登了马啸等提出了在小样本数据集条件下道路沥青针入度的光谱定量分析新方法：由 Bootstrap 重抽样、噪声注入及 SVM 组成的 Bootstrap-SVM 模型算法。该方法预测精度相比 PLS、SVM 预测均方根误差小。38 卷 8 期报道了稀疏线性判别分析(SLDA)加入正则项的机器学习算法，同时完成分类器训练过程与变量选择过程，判断不同方向上载荷系数稀疏性，得出最优参数空间，增强了模型的可读性。将此方法应用到不同产地的秦艽样本中，对三种秦艽样本的傅里叶红外谱进行分析预测，其产地分类准确率达到 100%。39 卷 3 期有文章报道基于深度信念网络 Dropout 的随机丢弃策略对五代时期耀州窑古陶瓷进行断代分类。首先，采用两层受限玻尔兹曼机(RBM)进行降维，进而提取光谱数据高层特征，降低特征间的相关性；然后，对深度信念网络进行微调，进而提升网络训练的主动性；最后，在深度信念网络训练阶段，应用 Dropout 随机丢弃策略，减少网络训练过程中特征之间的依赖性。姚燕等^[2]提出遗传算法(GA)和支持向量机(SVM)相结合的全谱区范围内小样本数据的 BMP 快速预测方法，该方法具有良好的鲁棒性和全局搜索能力且方法简单，避开了传统过程中从归纳到演绎的时间浪费并剔除了样本中的大量冗余信息。

本工作将小样本空间目标光谱作为实验数据，首先，应用粗糙分类模型(密度聚类、K-means 方法)，分别将数据初次分类，找出数量最少一类；其次，应用数据增广模型(一维生成对抗网络、过采样方法)，分别扩充最少一类数量；最后，应用精细分类模型(一维卷积神经网络方法)，分别检验密度聚类和一维生成对抗网络、K-means 和一维生成对抗网络、密度聚类和过采样、K-means 和过采样，四种组合方法的整体分类精度，分别约为 79.1%，78.4%，77.9% 和 77.2%。实验结果显示密度聚类、一维生成对抗网络、一维卷积神经网络方法，在小样本空间目标光谱数据未知类别时，取得了较好的分类效果，可为空间目标高光谱图像和光谱数据一体化分析，提供一定的参考价值。

2 空间目标光谱数据探测方案

观测地点为吉林省吉林市大绥河镇，该地有较好的空间目标观测环境。利用 1.2 m 光学望远镜的卡塞格林焦点作为工作焦点，并配有独立的导星镜，如图 1(a)所示。终端设备为 sCMOS 相机、液晶可调滤光器(LCTF)、自制恒温器，如图 1(b)所示。经过 30 m 有源 Hub，将终端设备与控制室相连，以便随时监控望远镜状况。

选取高轨道目标作为观测对象，以便调整终端参数并实现多圈次的观测。选取相近天区，尽可能减少因观测环境、人为因素带来的影响。观测范围为可见光波段 400~720 nm，每间隔 5 nm 采集一次。光谱相机记录不同波段处空间目标的成像信息，某空间目标在 400, 435, 475, 515, 555, 595, 635, 675 和 720 nm 波长处的图像，如图 2 所示。

空间目标在 400~720 nm 波长范围的光谱，通过天文孔径测光方法 IRAF(image reduction and analysis facility)以及相关任务包，自动提取，并绘制成一维谱线，通过最大最小

值归一化方法 $x^* = \frac{x - x_{min}}{x_{max} - x_{min}}$ 进行处理得到目标反射率，

图 2 中目标亮度随波长变化曲线如图 3 所示。




图 1 (a) 光学望远镜示意图；(b) 终端盒示意图
Fig. 1 Schematic diagrams of optical telescope (a) and terminal box (b)




图 2 某空间目标在不同波长处高光谱图像

Fig. 2 Hyperspectral images of a space object at different wavelengths

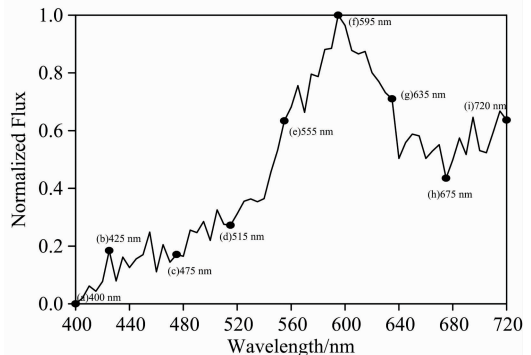


图 3 目标亮度随波长变化曲线

Fig. 3 The brightness of space object varying with wavelength

3 深度学习模型

3.1 粗糙分类模型

由于空间目标的光谱数据，没有专门的类型模板库，因此，需要粗分类方法进行初次区分，进而得到细分类模板。各种聚类算法中，密度聚类与 K-means 方法均有较好的效果^[3]，容易实现且结果较好。

密度聚类算法^[4] (density-based spatial clustering of applications with noise, DBSCAN)是将样本之间分布的紧密程度作为依据来构建框架，从密度层面的可连接性出发形成聚类族群，即计算点与点之间的欧式距离和点密度情况，来划分相似度较高的不同簇。例如空间目标 α 处于某域中，其领域半径为 Eps ，根据另一空间目标距 α 的欧氏距离 ($d_{1,2} = \sqrt{\sum_{k=1}^n (\alpha_{1,k} - \alpha_{2,k})^2}$) 和 Eps 的关系，判断其是否为 α 的近邻。若空间目标 α 领域内，近邻数大于等于 $MinPts$ ，视 α 为核心对象。以此可以根据核心对象确定聚类簇：密度直达 (t 与 v) 如图 4(a) 所示、密度可达 (t 与 p) 如图 4(a) 所示、密度 (t 与 v) 如图 4(b) 所示。




图 4 密度聚类算法基本架构图

Fig. 4 The basic architecture diagram of DBSCAN

将 183 个空间目标光谱随机排列，基于密度聚类方法进行粗分类，实验结果如表 1 所示。

表 1 基于密度聚类算法进行粗分类结果

Table 1 Rough classification results based on DBSCAN

类型	数量	精度/%
One	52	76.109 2
Two	9	75.880 9
Three	32	70.901 4
Four	42	75.910 1
Five	11	66.666 7
Six	37	—

K-means 算法^[5] 在给定 K 值和 K 个初始类簇中心点的情况下，把每个点(亦即数据记录)分离其最近的类簇中心点所代表的类簇中，所有点分配完毕之后，根据一个类簇内的所有点重新计算该类簇的中心点(取平均值)，然后再迭代更新分配点和类簇中心点，直至类簇中心点的变化很小，或者达到指定的迭代次数。

将 183 个空间目标光谱随机排列，采用基于 K-means 方法进行粗分类，实验结果如表 2 所示。

表 2 基于 K-means 算法进行粗分类结果

Table 2 Rough classification results based on K-means

类型	数量	精度/%
One	57	75.503 7
Two	10	75.900 9
Three	37	70.001 5
Four	45	74.999 9
Five	14	66.798 1
Six	17	—

3.2 数据增广模型

深度学习中，数据增广方法是应对不平衡训练集的常用方法^[6]。其中，生成对抗网络与过采样方法均有较好效果，容易实现且结果较好。

生成对抗网络^[7] (generative adversarial networks, GAN)是 2014 年提出的一种可微生成式网络模型方法。GAN 可通过梯度下降法学习，适用于零和博弈^[8]的网络场景即生成器(generator)网络与判别器(discriminator)网络处于一种竞争对手模式。生成器直接生成样本数据 $x = g(z; \theta^g)$ ；判别器将训练样本数据与生成器生成数据区分开，通过概率值 $d(x; \theta^d)$ ，判断 x 是真实样本数据而不是生成器生成样本数据。零和博弈是最简单的表示生成式对抗网络的形式化场景，判别器收益情况通过 $v(\theta^g, \theta^d)$ 确定，生成器收益情况通过 $-v(\theta^g, \theta^d)$ 确定。当生成器与判别器均达到各自最大化收益时，通过 $g^* = \arg \min_g \max_d (g, d)$ 函数判断两者收敛状态，其中， v 的选择方程为 $v(\theta^g, \theta^d) = E_{X \sim P_{data}} \log d(x) + E_{X \sim P_{model}} \log(1 - d(x))$ 。以上表明，迫使判别器学习将样本中真实的或是伪造的区分开，同样，生成器试图让判别器相信这就是真实的样本。当处于收敛的时候，生成器生成样本与真实样本无法区分开，即判别器输出 1/2 就被放弃。生成对抗网络基本流程如图 5(a) 所示。

真实数据与生成数据相似度，采用数据欧式距离进行判断，选择 Six 类中某空间目标原始与生成图谱，如图 5(b) 所示，其相似度较高。

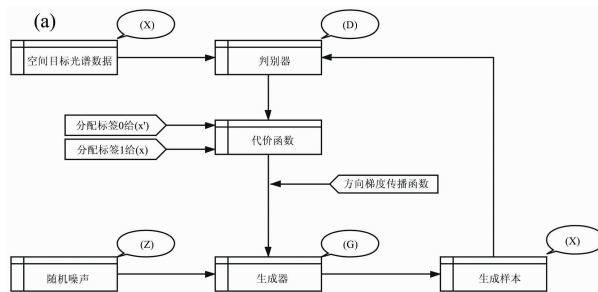


图 5(a) 生成对抗网络基本流程图

Fig. 5(a) The basic flow chart of generative adversarial network




图 5(b) 某空间目标原始光谱与生成光谱
Fig. 5(b) The original and generated spectra of a space object

过采样(Over-sampling)^[9]是一种平衡训练集的简单方法,这意味着要反复采样训练集中比例相对较低的少数群体,因此过采样不能有效避免训练的过度拟合。

3.3 精细分类模型

经典的 CNN 主要由卷积层、最大池化层和全连接层组成,其中,LeNet 更为经典^[10]。本工作应用的一维(1D)卷积神经网络(CNN)^[11]类似 LeNet 作为光谱分类器。为了适应




图 6 一维卷积神经网络基本流程图

Fig. 6 The basic flow chart of one dimensional CNN

1D 光谱数据的特殊性,我们使用了不同的网络层数,两层和三层进行实验比较。1D CNN 基本流程图,如图 6 所示。

输入层为 1×320 个核执行卷积运算以生成 m 个特征,见式(1)

$$h^{(m)} = \sigma \left(\sum_{i=0}^4 \sum_{j=0}^4 x_{i,j} \omega_{i,j}^{(m)} + b^{(m)} \right) \quad (1)$$

式(1)中,权重矩阵为 $\omega^{(m)}$,偏差向量为 $b^{(m)}$, $\sigma(\cdot)$ 为 Relu 激活函数,其式为 $O_{i,j} = \max(0, x)$ 。选择 Relu 作为激活函数,主要是因为它具有良好的非线性和不饱和度,可以有效降低网络的计算复杂度,能更好地收敛网络。在卷积层中,通过滑动窗口对特征进行采样。使用最大池化层可以实现特征压缩,降低计算复杂度

$$O_{i,j} = \max\{h_{q,r}^{(m)}\} \quad (2)$$

式(2)中, $q, r \in (2i, 2j), (2i+1, 2j), (2i, 2j+1), (2i+1, 2j+1)$ 。

在两个卷积和两个最大池化层之后,所有特征被重新整形为一维向量 f ,并被传输到 MLP 全连接网络,见式(3)

$$y_c = \phi \left(\sum_{j=0}^{f-1} f_j \omega_{j,c} + b_c \right) \quad (3)$$

式(3)中,失调为 b_c ,权重矩阵为 ω 。然后利用 SoftMax 函数计算频谱的分类概率,见式(4)

$$\phi(h_c) = \frac{e^{h_c}}{\sum_{j=1}^P e^{h_j}} \quad (4)$$

输出的是一维向量,表示空间目标的光谱类别,分别为 One, Two, Three, Four, Five 和 Six。

4 结果与讨论

实验数据为通过光谱相机采集到的 183 个空间目标光谱数据,随机排序整合为 χ ;首先,通过密度聚类 and K-means 将 χ 粗分为 6 类;其次,通过一维生成对抗网络和过采样增加最少一类的数据量;最后,通过一维卷积神经网络将 χ 细分类为 6 类,判断其精准度。实验算法基本流程如图 7 所示。

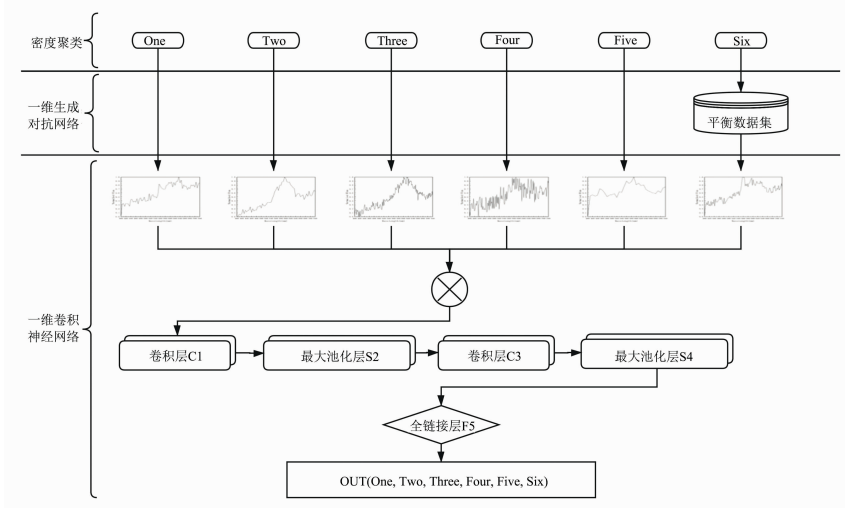


图 7 实验算法基本流程图

Fig. 7 The basic flow chart of experimental algorithm

实验一为密度聚类、一维生成对抗网络、一维卷积神经网络三种方法组合 (DBGANCNN)；实验二为 K-means、一维生成对抗网络、一维卷积神经网络三种方法组合 (KM-GANCNN)；实验三为密度聚类、过采样、一维卷积神经网络三种方法组合 (DBOSCNN)；实验四为 K-means、过采样、一维卷积神经网络三种方法组合 (KMOSCNN)。四种实验方法 6 类分类精度结果，如表 3 所示。

表 3 多种方法组合实验 6 类分类精度 (%)

Table 3 Classification accuracies (%) of six categories by using multiple methods combination

类型	方法			
	DBGANCNN	KMGANCNN	DBOSCNN	KMOSCNN
One	81.276 1	79.910 4	80.673 9	79.102 3
Two	80.890 1	80.125 6	80.110 1	79.912 2
Three	75.692 4	75.001 9	75.515 2	74.999 9
Four	80.902 9	80.511 1	80.190 7	80.111 3
Five	70.834 2	67.335 3	69.244 0	65.338 2
Six	85.000 1	84.600 9	84.859 3	83.981 5

上述各个算法比较，在同一类模型 (如粗糙或精细分类模型) 中，固定数据增广模型，分析不同方法对精度的影响；在数据增广模型中，固定粗分类模型，分析不同方法对精度的影响。影响精度值非常相近，说明两两对比效果显著，有助于实验对比，得出最后结果。各种方法平均运算时间与精度比较，如图 8 所示。




图 8 各种方法运算时间与精度比较

Fig. 8 Comparisons of average operation time and accuracy among various methods

两个卷积和两个最大池化层、三个卷积和三个最大池化层相比精度相差较小，但计算时间更长，所以 1D-CNN 选择两层结构式，四种组合方法运算时间与精度，如图 9 所示。

由以上实验结果可以看出，DBGANCNN 方法在 6 类以及整体分类精度均高于其他方法，为 0.667 1%~1.85%，且四种组合方法中 DBGANCNN 方法的运算时间比其他方法大约少 6~15 s；DBGANCNN 方法精度比 DBOSCNN 高

0.667 1%，原因在于过采样方法导致过拟合状态，同理 KMGANCNN 方法精度高于 KMOSCNN 方法 0.673 3%；DBGANCNN 方法精度高于 KMGANCNN 方法 1.85%，原因在于 K-means 方法相比 DBSCAN 方法在粗分类上，需要提前设定类数，同理 DBOSCNN 方法精度高于 KMOSCNN 方法 1.191 3%；四种组合方法的分类精度均高于单一方法，但是平均运算时间均低于单一方法；1D CNN 方法网络层数对分类精度影响较小，2 层网络与 3 层网络精度差距极小，但平均运算时间更长。

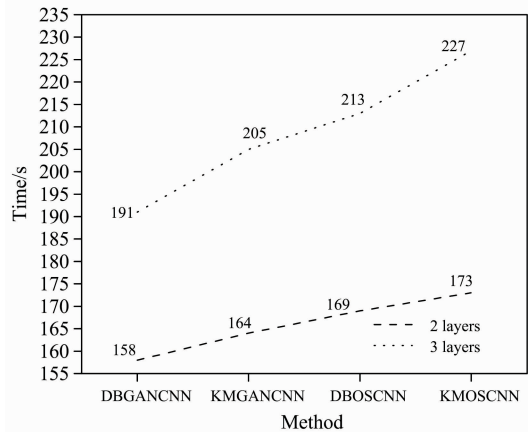


图 9(a) 四种组合方法运算时间

Fig. 9(a) Average operation time of four combination methods

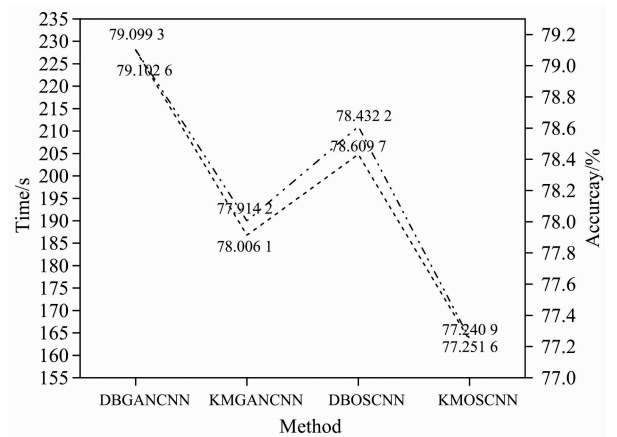


图 9(b) 四种组合方法精度

Fig. 9(b) Accuracies of four combination methods

5 结论

空间目标光谱数据包含丰富的信息，但由于其数据量较小无法详细分析。基于小样本空间目标光谱数据，应用粗糙分类模型，密度聚类方法粗分 6 类获得数据类型模板；应用数据增广模型，一维生成对抗网络方法增加最少一类数据平衡数据集；应用精细分类模型，一维卷积神经网络方法实现比较准确分类。通过光谱数据将空间目标进行分类，应用所研究密度聚类、一维生成对抗网络、一维卷积神经网络组合方法分类精度较高，进而实现未来高光谱图像与光谱数据联合分析。

References

- [1] Kim K J, Cho S. *Pattern Analysis & Applications*, 2015, (18): 553.
- [2] YAO Yan, SHEN Xiao-min, QIU Qian, et al(姚 燕, 沈晓敏, 邱 倩, 等). *Spectroscopy and Spectral Analysis(光谱学与光谱分析)*, 2020, 40(6): 1857.
- [3] Mohiuddin A, Raihan S, Syed M S I. *Electronics*, 2020, 9(8): 1295.
- [4] Rodriguez, Alex, Laio, et al. *Science*, 2014, 344(6191): 1492.
- [5] Rudolf S, Kristian S. *Advances in Data Analysis and Classification*, 2020, 15(1): 83.
- [6] LI Yan-xia, CHAI Yi, HU You-qiang, et al(李艳霞, 柴 毅, 胡友强, 等). *Control and Decision(控制与决策)*, 2019, 34(4): 673.
- [7] Ghahramani Z, Welling M, Cortes C. *NIPS*, 2014, (2): 2672.
- [8] Wang Z, She Q, Ward T E. *Generative Adversarial Networks: A Survey and Taxonomy*, 2019, arXiv: 1906.01529[CS.LG].
- [9] Koziarski M, Krawczyk B, Wozniak M. *Neurocomputing*, 2019, (343): 19.
- [10] LeCun Y, Bottou L, Bengio Y, et al. *Proceedings of the IEEE*, 1998, (86): 2278.
- [11] Zheng Z P, Qiu B, Luo A L, et al. *Publications of the Astronomical Society of the Pacific*, 2020, 132(1008): 024504.

A Combination of Multiple Deep Learning Methods Applied to Small-Sample Space Objects Classification

DENG Shi-yu^{1, 2}, LIU Cheng-zhi^{1, 4*}, TAN Yong^{3*}, LIU De-long¹, ZHANG Nan¹, KANG Zhe¹, LI Zhen-wei¹,
FAN Cun-bo^{1, 4}, JIANG Chun-xu³, LÜ Zhong³

1. Changchun Observatory of National Astronomical Observators, Chinese Academy of Sciences, Changchun 130117, China
2. University of Chinese Academy of Sciences, Beijing 100049, China
3. School of Science, Changchun University of Science and Technology, Changchun 130022, China
4. Key Laboratory of Space Object & Debris Observation, PMO, CAS, Nanjing 210008, China

Abstract With the continuous improvement of the sensitivity, accuracy and easy use of spectral detection instruments in recent years, spectral technology has penetrated the identification and analysis of material components in all walks of life. Spectral observation of space targets is one of the important extensions of traditional optical observations. It has attracted much attention due to its non-contact and damage-free advantages. However, due to the limited observation conditions, the amount of spectral data of space targets is minimal. Traditional methods cannot achieve better results in classification analysis. In this paper, Firstly, the hyperspectral image of the space target is obtained through the spectroscopic camera terminal mounted on the 1.2 m space target optical telescope; Secondly, the one-dimensional spectral data of the space target is extracted through the astronomical photometric IRAF method; Finally, the combination of multiple deep learning methods, classify the spectral data of space targets. Accordingly, this paper proposes a combination of multiple deep learning methods to solve small sample data's spatial object classification problem. This method uses Density Clustering method to roughly classify spatial targets, one-dimensional Generative Adversarial Network method to generate spatial target data, one-dimensional Convolutional Neural Network method to finely classify spatial targets, the combination of three methods can achieve relatively good experimental results and overall accuracy is about 79.1% (Based on the combination of Density Clustering, Oversampling, one-dimensional Convolutional Neural Network methods; Based on the combination of K-means, one-dimensional Generative Adversarial Network, one-dimensional Convolutional Neural Network methods; Based on the combination of K-means, Oversampling, One-dimensional Convolutional Neural Network methods, the overall accuracy is about 78.4%, 77.9%, 77.2%). In the rough classification model, the overall accuracy of the Density Clustering method is about 0.67% higher than the K-means method; In the data augmentation model, the overall accuracy of the one-dimensional Generative Adversarial Network method is about 1.52% higher than the Oversampling method; In the fine classification model, the two-layer network of the one-dimensional Convolutional Neural Network method has an average accuracy of only about 0.003% higher than the three-layer network, but the calculation time is longer. The accuracy of the four combined methods are higher than the single method. The experimental results show that the combination method proposed in this paper can achieve fine classification and high accuracy when the small sample space target category is unknown. It provides a certain reference value for realizing the integrated analysis of the map

under the minimal data volume of the space target.

Keywords Space targets; Spectral data; Density based spatial clustering of applications with noise; Generative adversarial networks; Convolutional neural networks

(Received Jan. 8, 2021; accepted Feb. 7, 2021)

* Corresponding authors

敬告读者——《光谱学与光谱分析》已全文上网

从 2008 年第 7 期开始在《光谱学与光谱分析》网站(www.gpxygpx.com)“在线期刊”栏内发布《光谱学与光谱分析》期刊全文, 读者可方便地免费下载摘要和 PDF 全文, 欢迎浏览、检索本刊当期的全部内容; 并陆续刊出自 2004 年以后出版的各期摘要和 PDF 全文内容。2009 年起《光谱学与光谱分析》每期出版日期改为每月 1 日。

《光谱学与光谱分析》期刊社