

一个自注意力层和一个前馈神经网络。Transformer 模型的输入和输出均为一个特征向量序列,为了更好地考虑输入的特征向量位置信息,在输入第 1 层 Transformer 前,先对特征向量序列进行空间位置编码,然后和特征向量相加作为输入。Transformer 模型的输出同样为特征向量序列,并作为下一层 Transformer 的输入。




图 1 Transformer 基本结构

Fig.1 Basic structure of Transformer

1.1.1 空间位置编码

空间位置编码为每个特征向量输出一个维度与特征向量相同的空间位置向量,从而用空间位置向

量来描述特征向量的位置关系。本文采用如下的形式对特征向量进行位置编码,即

$$\begin{cases} PE(pos,2i) = \sin(\frac{pos}{10\,000^{2i/d_{model}}}) \\ PE(pos,2i+1) = \cos[\frac{pos}{10\,000^{(2i+1)/d_{model}}}] \end{cases}, \quad (1)$$

式中: PE 为位置编码; pos 为特征向量在整个序列中的位置; d_{model} 为特征向量的维度; i 为特征向量的位置。式(1)会在每个特征向量的偶数位置添加 $\sin$ 变量,奇数位置添加 $\cos$ 变量,以此来产生与原始特征向量维度相同的空间位置向量,然后与原始特征向量相加完成空间位置编码。

1.1.2 自注意力层

与卷积神经网络的训练参数卷积核不同,每层 Transformer 的训练参数包含 3 个矩阵 W^Q, W^K, W^V , 这 3 个矩阵分别与输入的向量序列相乘得到查询矩阵、键矩阵和值矩阵。自注意力机制的公式为:

$$Z = Attention(Q, K, V) = \text{softmax}(\frac{QK^T}{\sqrt{d_k}})V, \quad (2)$$

式中: Q, K, V 分别为查询矩阵、键矩阵和值矩阵; d_k 为输入的维度。为了提高模型的性能,采用多头注意力机制,即使用多个 W^Q, W^K, W^V 矩阵生成多个查询矩阵、键矩阵和值矩阵,再根据式(2)输出多个特征值,将多个特征值进行拼接再乘以一个矩阵参数输出最终特征。如图 2 所示, Z_1, Z_2, Z_3 分别是 3 个注意力头输出的特征矩阵(特征序列拼接成特征矩阵), 3 个特征矩阵拼接后形成矩阵 Z , 再与矩阵参数 W 相乘得到最终的输出特征,特征矩阵中每一行为一个特征向量。




图 2 多头注意力机制

Fig.2 Multi-head attention mechanism

为了提高模型的非线性,将自注意力层输出的特征向量序列再分别通过一个前馈神经网络,本文采用 2 层全连接层作为前馈神经网络。另外,在 Transformer 模型中的自注意力层和前馈神经网络层引入残差连接,以提高深度模型的训练效果。

1.2 本文网络模型

本文网络模型的整体结构如图 3 所示,

Conv2D, TRM 和 MLP 分别代表二维卷积层、Transformer 层和多层感知机。首先,利用主成分分析方法对高光谱数据立方体进行降维处理,并保留前 3 个主成分分量。为了充分利用高光谱影像中的空谱联合信息,选择中心像素周围 32 像素 $\times$ 32 像素大小的邻域作为输入样本。具体地,将输入样本沿空间方向划分为 16 个大小相等的图像块;然后,利用

卷积层将图像块映射为一维特征向量,至此一个输入样本被转换为 16 个一维特征向量;接着,将序列特征向量输入到包含 8 个 Transformer 层的深度网

络进行深度特征提取;最后,利用多层感知机输出分类结果。本文网络模型具有端到端的网络结构,以像素领域数据作为输入,以类别标记作为输出。




图 3 本文网络模型
Fig. 3 Proposed network model

2 数据集及参数设置

2.1 数据集

为了验证本文方法的有效性,采用 Salinas 和 Indian Pines 这 2 组高光谱数据集进行试验。Salinas 数据集由 AVIRIS 传感器于 1992 年获取,观测区域为美国加利福尼亚州某山谷,影像大小为 512 像素 × 217 像素,光谱覆盖范围为 0.40 ~ 2.50 μm,空间分辨率为 3.7 m。该数据集共包括野草、休耕地和莠苣等 16 个标注类别和 204 个波段,标注类别集中分布在影像的左侧和上侧,且均为条状和面状地物。Indian Pines 数据集由 AVIRIS 传感器于 2001 年获取,观测区域为美国印第安纳州西北部某处农田,影像大小为 145 像素 × 145 像素,光谱覆盖范围为 0.40 ~ 2.50 μm,空间分辨率为 20 m,共包括 200 个波段可用于分类。该数据集共包括玉米、大豆和树木等 16 个地物类别且在影像中均匀分布,但部分类别包含的标记样本过少。参照相关文献,本文仅选取了 9 个样本数量较多的类别进行实验。另外,2 个数据集均随机选取 200 个标记样本作为训练数据,剩余样本作为测试样本(2 个数据集分别包含 50 929 个和 7 434 个测试样本)。

2.2 参数设置

试验中,迭代训练次数设置为 600,学习率设置为 0.000 1,数据批量大小为 64,并利用 Adam 算法进行网络优化,以保证模型进行充分训练。卷积核数量设置为 128,因此每个图像块将被转换为长度为 128 的特征向量。多头注意力机制中头数设置为 8,使模型能够提取到更为丰富的特征。多层感知机中,全连接层的神经元个数分别设置为 128 和 K(K 为目标数据集中包含的类别数量)。另外,本文试验的硬件环境为 Intel(R) Xeon(R) Gold 6152 处理器和 Nvidia A100 PCIE 显卡。

3 结果与分析

为了验证本文方法的有效性,选择机器学习分类器 SVM、2 种经典的深度学习模型 SSDCNN^[15] 和 3D - CNN^[9] 以及深度三维残差网络 RES - 3D - CNN^[16] 作为对比算法。不同方法在 2 个数据集上的分类结果如图 4—5 所示。可以看到,本文方法的分类结果与真实地面标记最为接近,可以从视觉角度验证了本文方法在高光谱影像分类上的有效性。需要说明的是,图 4(e)中绿色地物区域出现了明显的噪点,但本文方法在其余区域的分类效果明显优




图 4 Salinas 数据集分类结果
Fig. 4 Classification of Salinas dataset




图 5 Indian Pines 数据集分类结果

Fig.5 Classification of Indian Pines dataset

于其他方法。本文方法能够通过提高难区分地物的分类精度来改善影像的整体分类效果,从而获得更为平滑的分类结果。

为了进一步对不同方法的分类性能进行定量评价,选择总体分类精度 (overall accuray, OA)、平均分类精度 (average accuracy, AA) 和 Kappa 系数作为评价指标。2 个数据集不同方法的分类结果如表 1—2 所示。从表中可以看到,传统的机器学习分类器 SVM 由于无法利用高光谱影像中的深层次特征,因

表 2 Indian Pines 数据集分类结果

Tab.2 Classification results of Indian Pines dataset						
序号	类名称	SVM	SSDCNN	3D - CNN	RES - 3D - CNN	本文方法
1	免耕玉米	75.78	88.38	93.07	94.05	99.64
2	少耕玉米	71.12	94.34	96.27	99.04	97.42
3	草 - 牧场	89.10	97.52	98.55	98.96	100.00
4	草 - 树	96.15	99.86	97.12	99.59	97.73
5	堆积干草	99.79	100.00	100.00	100.00	100.00
6	免耕大豆	69.98	92.49	96.81	97.02	98.37
7	少耕大豆	89.22	87.17	91.85	91.28	99.59
8	大豆	79.79	99.33	97.47	99.33	97.85
9	树木	99.68	96.36	98.42	99.21	98.98
OA/%		84.57	92.81	95.41	96.12	98.96
AA/%		85.62	95.05	96.62	97.61	98.84
Kappa		0.820 9	0.915 9	0.946 3	0.954 7	0.987 8

表 1 Salinas 数据集分类结果

Tab.1 Classification results of Salinas dataset						
序号	类名称	SVM	SSDCNN	3D - CNN	RES - 3D - CNN	本文方法
1	椰菜_绿_野草_1	99.20	98.90	98.75	100	91.74
2	椰菜_绿_野草_2	99.62	89.43	99.25	98.12	100.00
3	休耕地	99.70	100	99.14	99.70	100.00
4	粗糙的休耕地	99.50	99.93	99.50	99.86	100.00
5	平滑的休耕地	96.75	96.56	99.74	99.81	99.81
6	残株	99.42	99.97	99.62	100	99.87
7	芹菜	99.36	97.18	98.21	99.55	100.00
8	未结果实的葡萄	84.75	77.61	89.57	88.24	100.00
9	正在开发的葡萄园土壤	99.10	99.11	99.98	99.50	99.98
10	开始衰老的玉米	93.29	99.69	95.01	98.66	99.82
11	长叶莴苣 (4 周)	97.85	99.91	95.78	100	100.00
12	长叶莴苣 (5 周)	99.84	100	99.79	99.95	99.95
13	长叶莴苣 (6 周)	98.58	99.89	100.00	99.45	99.89
14	长叶莴苣 (7 周)	95.79	99.53	97.99	100	100.00
15	未结果实的葡萄园	65.74	96.68	82.12	91.98	96.40
16	葡萄园小路	98.89	99.34	99.43	99.45	100.00
OA/%		91.20	93.61	94.67	96.12	99.13
AA/%		95.46	97.11	97.12	98.39	99.22
Kappa		0.902 0	0.929 1	0.940 7	0.956 9	0.990 3

此无法获得令人满意的分类结果。深度学习模型 SSDCNN 和 3D - CNN 分别利用二维卷积和三维卷积进行深度特征提取,分类精度有一定提高。RES - 3D - CNN 利用残差连接和三维卷积核构建了深度残差网络模型,具有更深层次的网络,能够利用深层次的空谱联合特征,因此具有更高的分类精度。在所有对比方法中,本文方法获得了更为优异的分类效果。在 Salinas 数据集上,其 OA,AA 和 Kappa 系数分别较第二名提高了 3.01 百分点,0.83 百分点和 0.033 4; 在 Indian Pines 数据集上,其 OA,AA 和 Kappa 系数分别较第二名提高了 2.84 百分点,1.23 百分点和 0.033 1。本文方法通过堆叠 Transformer 模型构建骨干网络,并利用注意力机制和残差连接保证模型能够有效利用到有益于分类任务的深层抽象特征,从而进一步提高分类精度。需要说明的是,本文方法虽然在个别地物上的分类精度略低于 RES - 3D - CNN 模型 (例如 Salinas 数据集中第 1 类,Indian Pines 数据集中第 2,4 和 8 类),但其能够明显提高其他方法难以区分的地物的分类精度 (例如 Salinas 数据集中第 8 类和第 15 类、Indian Pines 数据集中第 1 类和第 7 类)。这表明,本文方法能够有效提高可分性差的地物的分类精度,从而提升影像的整体分类效果。

另外,深度学习模型需要足够的标记样本进行网络优化和参数更新,然而,实际中获取高质量的标

记样本是十分费时费力的。因此,深度分类模型应对训练样本数量的变化具有良好的适应性。为了探究不同分类方法在训练样本逐渐减少时的分类性能,随机选取每类 100,120,140,160,180,200 个样本作为训练样本进行分类试验,结果如图 6 所示。从图 6 中可以看出,随着训练样本的减少,所有分类方法的分类准确率都逐渐下降。SVM 在 2 个数据

集上的分类曲线始终低于其他对比方法。SSDCNN,3D-CNN 和 RES-3D-CNN 这 3 种基于 CNN 的深度分类模型的总体分类精度曲线变化相对平稳,说明它们对训练样本数量的变化具有较好的适应性。本文方法的总体分类精度曲线始终高于其他方法,这表明当训练样本逐渐减少时,该方法具有最好的分类性能。




图 6 训练样本数量对分类精度的影响
Fig. 6 Influence of the number of training samples on classification accuracy

4 结论

为了进一步提高高光谱影像分类精度,基于 Transformer 模型设计了一种新颖的深度分类模型,并展开了相关高光谱影像分类试验,具体结论如下:

1)与基于卷积神经网络的深度学习模型相比,本文方法能够更好地对全局语义信息进行建模,从而获得更高的分类性能。在 Salinas 和 Indian Pines 这 2 个数据集上的试验结果表明,本文方法能够获得比现有卷积神经网络模型更为优异的分类性能。

2)从类一致性的角度看,本文方法的分类结果具有更好的视觉效果,更接近地面真实标记。

3)在逐渐减少训练样本的条件下,本文方法始终能够获得较为优异的分类效果,表明本文方法对训练样本数量具有较好的适应性。

与常规卷积神经网络相比,本文方法利用 Transformer 模型有效提高了高光谱影像分类精度。下一步的工作将结合半监督学习、元学习等方法进一步提高高光谱影像在训练样本受限条件下的分类精度。

参考文献 (References):

[1] He L, Li J, Liu C, et al. Recent advances on spectral - spatial hyperspectral image classification: An overview and new guidelines

[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(3): 1579 - 1597.
[2] Ghamisi P, Plaza J, Chen Y, et al. Advanced spectral classifiers for hyperspectral images: A review[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8 - 32.
[3] Tao C, Pan H, Li Y, et al. Unsupervised spectral - spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(12): 2438 - 2442.
[4] Li T, Zhang J, Zhang Y. Classification of hyperspectral image based on deep belief networks[C]// Proceedings of the 2014 IEEE International Conference on Image Processing (ICIP), 2014.
[5] Zhang X R, Sun Y J, Jiang K, et al. Spatial sequential recurrent neural network for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(11): 4141 - 4155.
[6] Xu Q, Xiao Y, Wang D, et al. CSA - MSO3DCNN: Multiscale octave 3D CNN with channel and spatial attention for hyperspectral image classification[J]. Remote Sensing, 2020, 12(1): 188.
[7] Gao K, Guo W, Yu X, et al. Deep induction network for small samples classification of hyperspectral images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 3462 - 3477.
[8] 高奎亮, 张鹏强, 余旭初, 等. 基于 Network In Network 网络结构的高光谱影像分类方法[J]. 测绘科学技术学报, 2019, 36(5): 500 - 504, 510.
Gao K L, Zhang P Q, Yu X C, et al. Classification method of hyperspectral image based on Network In Network structure[J]. Journal of Geomatics Science and Technology, 2019, 36(5): 500 - 504,

510.

[9]

Li Y,Zhang H,Shen Q. Spectral – spatial classification of hyperspectral imagery with 3D convolutional neural network[J]. Remote Sensing,2017,9(1):67.

[10]

Xu X,Li J,Li S. Multiview intensity – based active learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing,2018,56(2):669 – 680.

[11]

He X,Chen Y. Transferring CNN ensemble for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2021,18(5):876 – 880.

[12]

Mou L,Ghamisi P,Zhu X X. Unsupervised spectral – spatial feature learning via deep residual Conv – Deconv network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing,2018,56(1):391 – 406.

[13]

Vaswani A,Shazeer N,Parmer N,et al. Attention is all you need [C]// Thirty – first Conference on Neural Information Processing Systems,2017.

[14]

Dosovitskiy A,Beyer L,Kolesnikov A,et al. An image is worth 16 × 16[Z]. Transformers for Image Recognition at Scale,2020.

[15]

Yue J,Zhao W,Mao S,et al. Spectral – spatial classification of hyperspectral images using deep convolutional neural networks[J]. Remote Sensing Letters,2015,6(4 – 6):468 – 477.

[16]

刘 冰,余旭初,张鹏强,等. 联合空 – 谱信息的高光谱影像深度三维卷积网络分类[J]. 测绘学报,2019,48(1):53 – 63.

Liu B,Yu X C,Zhang P Q,et al. Deep 3D convolutional network combined with spatial – spectral features for hyperspectral image classification[J]. Acta Geodaetica et Cartographica Sinica,2019, 48(1):53 – 63.

Classification of hyperspectral images based on deep Transformer network combined with spatial – spectral information

ZHANG Pengqiang, GAO Kuiliang, LIU Bing, TAN Xiong
(Information Engineering University, Zhengzhou 450001, China)

Abstract: The local convolution operation in convolutional neural networks cannot fully learn the global semantic information in hyperspectral images. Given this, this study designed a novel deep network model based on Transformer in order to further improve the classification precision of hyperspectral images. Firstly, this study reduced the dimensionality of hyperspectral images using the principal component analysis method and selected the neighborhood data around pixels as input samples to fully utilize the spatial – spectral information in the images. Secondly, the convolutional layer was used to transform the input samples into sequential characteristic vectors. Finally, image classification was conducted using the designed deep Transformer network. The multi – head attention mechanism in the Transformer model can make full use of the rich discriminative information. Experimental results show that the method proposed in this study can achieve better classification performance than the existing convolutional neural network model.

Keywords: hyperspectral image classification; Transformer; deep learning; self – attention mechanism
(责任编辑: 陈 理)

doi: 10. 6046/zrzyyg. 2021259

引用格式: 鄢俊洁,郭雪星,瞿建华,等. 基于朴素贝叶斯方法的 FY-4A/AGRI 云检测模型[J]. 自然资源遥感,2022,34(3):33-42. (Yan J J,Guo X X,Qu J H,et al. An FY-4A/AGRI cloud detection model based on the naive Bayes algorithm[J]. Remote Sensing for Natural Resources,2022,34(3):33-42.)

基于朴素贝叶斯方法的 FY-4A/AGRI 云检测模型

鄢俊洁, 郭雪星, 瞿建华, 韩 旻

(北京华云星地通科技有限公司,北京 100081)

摘要: 针对风云四号 A 星(FY-4A)中多通道扫描成像辐射计(advanced geosynchronous radiation imager, AGRI)云检测问题,提出了一种基于朴素贝叶斯算法的全自动云检测方法。使用朴素贝叶斯算法作为核心结构,基于光学载荷基本云检测原理选择合适的红外通道作为特性分类器参数,可保证日夜云检测一致性,同时针对不同的地表类型和不同月份分别分类训练构建,最终得到基于朴素贝叶斯算法的云检测模型。针对 FY-4A/AGRI 数据生成了 7 种经典的云检测特征和 1 种基于红外合成图像特征的贝叶斯分类器,经过 2019 年国家卫星气象中心业务云检测产品的学习测试验证,在陆地、沙漠、浅水和深海的召回率(probability of detection, POD)达到 98% 以上,积雪 POD 达到 80%,南北极 POD 达到 80% 以上。将检测结果与国家卫星气象中心业务系统云检测结果进行比较,全年月度平均 POD 均高于 98%,误判率(false alarm ratio, FAR)低于 5%,Kuipers 评分(Kuiper's skill score, KSS)均高于 90%。

关键词: FY-4A/AGRI; 朴素贝叶斯; 云检测; POD

中图法分类号: TP 79 **文献标志码:** A **文章编号:** 2097-034X(2022)03-0033-10

0 引言

云在地球大气系统的辐射收支平衡中的作用是由云的光学性质决定的^[1]。云层的遮挡会导致卫星影像出现噪音,从而使遥感反演的参数出现误差,干扰后续的图像分类或目标识别。因此,对云的准确检测是遥感产品精准反演的前提。

传统的云检测方法主要利用云的高反射率和云顶的低温等特点^[2],结合物理阈值法^[3]或同态滤波去云法^[4]等进行检测。物理阈值法包括国际卫星云气候计划(international satellite cloud climatology project, ISCCP)云检测方法^[5-8]、高级甚高分辨率辐射计云、陆、海处理方案(AVHRR processing scheme over cloud, land and ocean, APOLLO)检测算法^[9-11]、美国国家海洋和大气管理局云高级甚高分辨率辐射计(the NOAA cloud advanced very high resolution radiometer, CLAVR)云检测算法^[12-13]和二氧化碳(CO₂)薄片法^[14-15]。ISCCP 法基于可见光和红外窗区波段的数据,把每一个像元的观测辐射值与晴空辐射值比较,若两者的差大于晴空辐射值本身的变化时,判定该像元点是云点; APOLLO 法利

用高级甚高分辨率辐射计(advanced very high resolution radiometer, AVHRR)5 个全分辨率探测通道资料,包括 5 个阈值检测因子; CLAVR 法关注的是极区,利用光谱及空间变化特征检测云的存在; CO₂薄片法主要针对全球高云覆盖,包括薄卷云,利用对 CO₂敏感的红外光谱辐射,把穿透性云从不透明的云和晴空中区分出来。阈值法简单易行,但是对阈值的敏感性高,而阈值的选择具有一定的主观性,同时阈值法以像元为主要处理单元,没有考虑遥感影像的结构信息^[16]。同态滤波去云法将频率过滤与灰度变化结合起来,分离云与背景地物,最终从影像中去除云的影响。这种方法由于涉及到滤波器以及截止频率的选择,在滤波过程中有时会导致一些有用信息的损失。随着模式识别理论的发展应用,正演模式被引入到云检测研究,如大气辐射传输模式^[17],考虑了大气温湿和云微物理状况,能够正演模拟云顶亮温^[18]。传统的云检测算法需要大量的先验知识,经过大量的人工判读和调整,才能实现全球范围的云判识。针对这一问题,机器学习方法被逐渐引入到云检测研究中^[19-20]。机器学习方法利用训练样本进行特征训练,将先验知识和人工判识的经验提供给计算机,由计算机来综合相关制约因

收稿日期: 2021-08-19; 修订日期: 2021-12-03

基金项目: 国家自然科学基金面上项目“基于深对流云和月球高低端目标的长序列气象卫星辐射定标研究”(编号: 41675036)资助。

第一作者: 鄢俊洁(1980-),女,硕士,高级工程师,研究方向为气象卫星数据处理与应用。Email: yanjj@ema.gov.cn。

通信作者: 郭雪星(1983-),男,硕士,高级工程师,研究方向为人工智能和数据挖掘。Email: guoquexing@cnhyc.com。

素,完成回归学习过程,同时使算法的适应性增强^[21]。利用机器学习进行云检测时,检测效果通常取决于选取的特征描述能力的强弱,因此需要寻找一种好的描述特征^[20]。

以往气象卫星光学载荷的云检测主要还是采用与美国地球观测系统/中分辨率成像光谱仪(earth observing satellites/moderate resolution imaging spectro-radiometer, EOS/MODIS)载荷类似的方法,通过多光谱在云上的反射和辐射特性进行云的识别,需要大量人为干预。据此,本文基于风云四号 A 星(FY-4A)多通道扫描成像辐射计(advanced geosynchronous radiation imager, AGRI)数据,提出了一种基于朴素贝叶

斯方法的全自动云检测模型,使用朴素贝叶斯算法作为核心结构,基于光学载荷基本云检测原理选择合适的红外通道作为特性分类器参数,同时针对不同的地表类型和不同月份分别分类训练构建,最终得到基于朴素贝叶斯算法的全自动云检测模型,实现光学载荷影像云像元的高效、精准识别。

1 云检测方法流程

基于朴素贝叶斯的云检测方法从类别上分属于统计模型,因而整体上分为模型训练和产品推断 2 个阶段(图 1)。




图 1 朴素贝叶斯云检测方法流程

Fig.1 Methodology of naive bayes cloud detection algorithm

模型训练阶段的目标是生成云检测特征概率的查找表,具体步骤如下:①先执行预处理,主要内容包括初始化准备工作,按照文件时间确定模型的月度标志,读取 L1b 数据,按照下垫面归集云和晴空像元的位置;②基于第一步归集到各类下垫面的云和非云的像元,计算用于与云检测相关的特征,在本研究中使用了 6 类特征,分别为 T_{11} , T_{std} , $Emiss4$, $T_{max} - T$, $T_{D_{11-85}}$ 和 $GeoColor$,3.3 节对各类特征进行了详细介绍。

产品推断阶段的目标是基于时次观测的 L1b 产品文件推断其云检测产品。与模型训练阶段相同,推断阶段同样执行了预处理操作,与之不同的是推断阶段依赖训练阶段的云检测特征查找表来判识当前观测的云像元,对每个像元的 6 种云属特征,查找与特征值对应的机率,按照条件概率公式推断云属概率值,并按照下垫面不同云属阈值得到最终的云产品。

2 创建数据集

FY-4 气象卫星是新一代静止轨道定量遥感气象卫星,其载荷 AGRI 通道数由风云二号气象卫星的 5 个增加为 14 个(表 1),覆盖了可见光、近红外、短波红外、中波红外和长波红外等波段。星上辐射定标精度为 0.5 K、灵敏度为 0.2 K、可见光空间分

辨率为 0.5 km,能实现云、气溶胶、水汽、陆地表面特性、海洋水色等大气、陆地、海洋参量的高精度定量反演^[22]。

表 1 FY-4A AGRI 载荷通道^[23]
Tab.1 Channel setting of FY-4A AGRI

通道序号	中心波长/ μm	特性描述
1	0.47	白天云、沙尘和气溶胶
2	0.65	白天云、沙尘、积雪等
3	0.825	白天云、气溶胶、植被、海洋特性检测
4	1.375	卷云
5	1.61	低云/雪、水云/冰云
6	2.25	卷云、气溶胶
7	3.75H	火点高温
8	3.75L	低云/雾
9	6.25	高层云
10	7.1	中层云
11	8.5	云、沙尘
12	10.7	地球表面和云
13	12.0	云
14	13.5	中低层云

3 朴素贝叶斯云检测算法

3.1 算法原理

朴素贝叶斯是基于贝叶斯定理与特征条件独立假设的分类方法。对于给定的训练数据集,首先基于特征条件独立假设学习输入输出的联合概率分

布。然后基于此模型对给定的输入利用贝叶斯定理求出后验概率最大的输出。

具体地,设云特征为 n 维向量集合 $X = \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n\}$, 输出为云类别标记 $Y = \{0, 1\}$ 。则云

$$P(Y = 1 | X) = \frac{P(Y = 1) \prod_{i=1}^n P(X^{(i)} = \mathbf{x}_i | Y = 1)}{P(X)}, \tag{2}$$

式中: $X^{(i)}$ 为向量集合 X 中的第 i 维; $\mathbf{x}_i$ 为 X 中第 i 维的取值。

本文利用极大似然估计计算学习联合概率分布 $P(X, Y)$ 。假定训练样本集合容量为 J , 云属先验概率的极大似然估计为:

$$P(Y = 1) = \frac{\sum_{j=1}^J I(y = 1)}{J} \tag{3}$$

特征条件概率分布的极大似然估计为:

$$P(X^{(i)} = a_{jk} | Y = 1) = \frac{\sum_{j=1}^J I(\mathbf{x}_j^{(i)} = a_{jk}, y = 1)}{\sum_{j=1}^J I(Y = 1)}, \tag{4}$$

式中 a_{jk} 为第 j 个样本的第 k 个可能取值。

由此,对给定像元的云属特征 x ,通过学习到的模型计算其后验概率分布,根据后验概率最大化准则判别其云属类型。另外应云检测产品的要求,本文对检测结果按照概率阈值划分了可能云和可能晴空 2 种中间类别。

3.2 地表覆盖分类

由于云在不同下垫面类型上的特征差异显著,本文将地球表面分为 7 类型(深海、浅水、陆地、积雪、北极、南极、沙漠)。对不同地表类型进行分类的目的是为了得到对晴空条件认识存在的系统性偏差,这种偏差因地表类型的不同而有很大差异。分类的输入数据来自 FY-4 气象卫星导航文件,图 2 显示了 2019 年 1 月和 6 月 FY-4A 全圆盘中下垫

检测问题描述为:

$$P(Y = 1 | X) = \frac{P(Y = 1)P(X | Y = 1)}{P(X)} \tag{1}$$

基于特征条件独立假设,上式转化为:

面类型的分布。




图 2 全球地表覆盖分类

Fig. 2 Classification of global land cover

从图 2 中可以看出,地表类型变化中最大的驱动因素是积雪的变化,本文中的积雪覆盖使用近实时积雪覆盖产品(near-real-time ice and snow extent, NISE),积雪覆盖产品包括由微波成像仪(SSM/I)生成的北半球和南半球海冰、积雪覆盖范围。积雪覆盖产品以南、北半球 2 个 25 km 方位角、等面积投影(EASE grid)方式提供。首先,将 EASE grid 投影转换为全球等经纬度投影,然后根据经纬度信息与 FY-4A 全圆盘 4 km 网格数据进行匹配,得到全圆盘范围的积雪覆盖信息。图 3 显示了 2019 年具体各月份积雪和海冰的空间覆盖变化,从图中可以看出,积雪和海冰的空间覆盖度随季节变化差异显著。




图 3-1 2019 年全球各月积雪覆盖

Fig. 3-1 Global monthly snow cover in 2019




图 3-2 2019 年全球各月积雪覆盖
Fig. 3-2 Global monthly snow cover in 2019

3.3 云检测分类器

提取良好的云属特征是构建云检测分类模型的关键步骤。本文在调研现有云检测算法的基础上，针对 FY-4A 卫星 AGRI 载荷的观测特性选取了 6 种云相关特征：

1) T_{11} ：11 μm 亮温是经由 AGRI 载荷观测到的 11 μm 谱段辐亮度计算得到的亮度温度 $x_{bt,11}$ 。因中、高层云在 11 μm 谱段的亮温相较于地面低很多，因此可以直接使用该特征检测云^[24]。

2) T_{std} ：11 μm 亮温局地标准差是为以目标像元为中心，局部窗口范围内的所有像元亮温的标准差。使用该特征能够较为准确地区分中、高层云的边缘，薄云和晴空背景。

3) $T_{max} - T$ ：11 μm 亮温局地最大值差被定义为

以目标像元为中心局部窗口范围内亮温最大值与目标像元亮温的差。与 T_{std} 类似，中、高层云边缘处的该特征值显著高于晴空。

4) $T_{D_{11}-85}$ ：11 μm 与 8.5 μm 亮温差定义为目标像元 11 μm 亮温与 8.5 μm 亮温之差。由于冰和水的吸收峰值位于在窗区通道不同的波长^[25]，有云像元处该特征值一般为正值，而晴空像元处该特征值则普遍小于 0。

5) E_{miss4} ：伪 4 μm 发射率定义为：

$$E_{miss4} = \frac{\frac{c_2}{e^{4x_{bt,11}-1}}}{\frac{c_2}{e^{4x_{bt,4}-1}}}, \tag{5}$$

式中：e 为自然对数； c_2 为常数； $x_{bt,11}$ 为 11 μm 亮温； $x_{bt,4}$ 为 4 μm 亮温。图 4 表现了 FY-4A 卫星




图 4 伪 4 μm 发射率随太阳天顶角的变化
Fig. 4 Variation of pseudo 4 μm emissivity with solar zenith Angle

AGRI 载荷 2020 年 1 月 1 日昼夜时刻云与晴空发射率随太阳天顶角的关系。分析图 4 可以发现,云的伪 4 μm 发射率随昼夜变化十分明显。当太阳天顶角小于 85° 时(图 4(a)),云的伪 4 μm 发射率多数大于 1.8,晴空则集中于 1 附近,可能云、可能晴空存在于两者的过渡区间。而当太阳天顶角大于 85° 时(图 4(b)),云的伪 4 μm 发射率的下界降低到 1 以下,与晴空分布存在较大的重叠。因此,本研究选择计算伪 4 μm 发射率 2 种特征 Emiss4_Day 和 Emiss4_Night,分别在太阳天顶角小于 85° 和大于 85° 时参与后验概率计算。

6) GeoColor: GeoColor 是一种由 AGRI 载荷多通道观测值合成的 3 通道彩色图像,具有良好的视觉表现力^[26]。图 5 是一幅彩色合成示例图,其制作方法为:在太阳天顶角小于 90° 时,采用 0.46 μm 、0.64 μm 和 0.86 μm 反射率经过拉伸、变换得到白昼图像;当太阳天顶角大于 90° 时,采用 3.9 μm 和 10.4 μm 亮温经由拉伸、组合、变换得到夜间图像;




图 5 2020 年 1 月 1 日 10 时 UTC FY-4A/AGRI GeoColor 彩色合成图
Fig.5 Color composite image of FY-4A/AGRI GeoColor at 10:00 UTC January 1, 2020

按照太阳天顶角计算晨昏线位置处的渐变掩模,合并昼夜图像得到最终的彩色合成图。云和晴空在 GeoColor 合成图中具有较为明显的视觉差别,具体地,云表现为白色,晴空则表现为下垫面的色彩。由于云在 GeoColor 中的色彩是 RGB 通道共同决定的结果,且昼夜较为均匀,本研究决定在最大估计时学习通道值特征的联合概率分布,并将其引入到朴素贝叶斯的框架中作为一种新的独立特征。

3.4 模型构建

研究使用 2019 年 12 个月的 FY-4A 卫星 AGRI 载荷 L1 产品,定位(Geolocation, GEO)产品和云检测(cloud mask, CLM)产品。其中,L1 记录谱段观测值,GEO 提供时间和地理相关信息,CLM 作为云检测的真实标记。每个月选取 20% 的时次构成训练集,80% 的时次构成测试集合,图 6 是带有集合时次数量的数据划分统计情况。






图 6 数据划分统计
Fig.6 Data partition statistical chart



(a) T_{11} 在海洋下垫面云和非云的特征概率分布 (b) T_{11} 在海洋下垫面的云属概率曲线修正图
图 7 特征分布与云属概率曲线修正图

Fig.7 Modified graph of characteristic distribution and probability curve of cloud genus

响,更加准确地建立其云属关系,本文以月度作为模型求取的最小时间尺度。研究求取云检测单一特征月度模型的步骤描述如下:

1) 在收集数据集中随机选取 20% 的时次作为样本集,按云属和非云属统计每个时次各下垫面上特征的频数直方图,如图 7(a)。

2) 根据步骤 1) 得到频数直方图计算特征的云属和非云属条件概率分布,随后按公式(4)求取特征的贝叶斯模型参数。

3) 在统计样本特征的分布时,区间边缘的样本总数较小,晴空与云的比例易受噪声的干扰,云属概率值有时会表现异常。因此需要对步骤 2) 得到的模型参数进行手动的修正,图 7(b) 展示了修正后 11 μm 亮温特征对应的云属概率曲线。

3.5 云检测类别划分

在根据求解得到的模型检测产品时,首先需要判断像元的下垫面类型,然后计算算法定义的 6 类特征值,最后照式(2)融合多个特征的条件概率分布系数,由此可以得到该像元的云属概率值。

现有主流的云检测算法提供的是 4 类检测结果,晴空、可能晴空、可能云和云,如 EOS/MODIS, FY3D/MERSI 和 NOAA/AVHRR 云检测产品。为了生成类别产品,本研究选定 0.5 作为云与非云的概率阈值。为了得到较为准确的云和晴空类别,设定 0.1 的阈值划分晴空和可能晴空,0.9 的阈值划分为可能云和云。

4 结果验证分析

4.1 FY-4A/AGRI 数据云检测结果

以 FY-4A 业务 CLM 产品作为参照,本文采用分别针对云和晴空的召回率(probability of detection, POD)、误判率(false alarm ratio, FAR)并综合 Kuipers 评分(Kuiper's skill score, KSS)来从多个角度反映算法的精度。假设参照为云的像元且实际被判别为云的像元数量为 a ,参照为云的像元但实际被判别为晴空的像元数量为 b ,参照为晴空的像元但实际被判别为云的像元数量为 c ,参照为晴空的像元且实际被判别为晴空的像元数量为 d ,算法对云判识的 POD 反映的是本文算法判别出的云占实际的云的比例,云的 POD 公式为:

$$POD_{\text{cld}} = \frac{a}{a + b} \text{。}$$

(6)

云的 FAR 反映的是本文算法判别出的错误的云占判出的云的比例,公式为:

$$FAR_{\text{cld}} = \frac{c}{a + c} \text{。}$$

(7)

晴空的 POD 反映的是本文算法判别出的晴空占实际的云的比例,公式为:

$$POD_{\text{clr}} = \frac{d}{c + d} \text{。}$$

(8)

晴空的 FAR 反映的是本文算法判别出的错误的晴空占实际的晴空的比例,公式为:

$$FAR_{\text{clr}} = \frac{b}{b + d} \text{。}$$

(9)

KSS 是一种对错误分类敏感的补充性综合指标,常用于算法传统指标相近时更严格的评价,计算公式为:

$$KSS = \frac{ad - cb}{(a + b)(c + d)} \text{。}$$

(10)

2019 年 12 个月测试集验证统计结果如表 2。从表中可以看出,本文方法云检测的 POD 最高为 6 月份的 98.9%,最低为 9 月份的 90.4%。总体上,在 2019 年全年验证集中,云的平均 POD 为 97%,平均 FAR 为 6.3%,晴空的平均 POD 为 89.0%,平均 FAR 为 2.9%,方法的平均 KSS 为 87.4%。

表 2 2019 年 12 个月朴素贝叶斯以业务 CLM 为真值的交叉比对结果

Tab.2 Cross comparison results of naive Bayes in different months with business CLM as truth value in 2019 (%)

月份	云		晴空		KSS
	POD	FAR	POD	FAR	
1	98.2	5.6	89.4	3.5	87.6
2	98.1	7.4	88.5	3.1	86.6
3	97.8	6.9	87.2	4.2	85.0
4	90.5	6.3	88.7	2.8	87.3
5	98.5	6.4	90.3	2.3	88.9
6	98.9	4.8	89.2	2.7	88.1
7	98.7	5.0	90.3	2.6	89.0
8	98.8	5.2	89.0	2.6	87.8
9	90.4	7.0	88.0	2.8	86.4
10	98.4	7.8	87.6	2.6	86.0
11	98.0	6.7	90.1	3.0	88.1
12	98.2	6.8	89.4	2.9	87.6
均值	97.0	6.3	89.0	2.9	87.4

图 8 展示了测试集 1 月 1 日 10 时的云检测结果。整体而言,贝叶斯云检测算法与业务算法的结果大体一致。对比同时次的彩色合成图(图 5),细节上,贝叶斯算法在白天部分判断出的晴空多于业务算法,可能晴空少于业务算法,与合成图观察到的结果更一致。在耀斑区,贝叶斯算法出现了部分中间状态,业务算法表现更好。在澳大利亚中部,业务算法出现了错判,而贝叶斯算法表现更好。在夜晚

部分,业务算法在中国南海海域判云较多,而贝叶斯算法可能云较多,更符合实际云图分布。




图 8 2020 年 1 月 1 日 10 时
UTC 云检测结果对比

Fig. 8 Comparison of UTC cloud detection results at 10:00 UTC on January 1, 2020

4.2 模型分析

利用统计手段计算模型连续的参数值是本文算法区别于经典云检测方法的最大不同之处。根据不同的特征量和下垫面信息从模型中获得对应的有云概率值,并将不同特征量的概率值归一化到 0~1 之间获得云属概率并根据分类阈值获得云检测结果。




图 9 1 月和 6 月各下垫面 T_{11} 特征概率曲线

Fig. 9 T_{11} characteristic probability curve of each underlying surface in January and June

观察图 10 左侧上部的耀斑区,可以发现本文算法与 FY-4A CLM 产品表现接近一致,都检测到了成片的云区。但本文算法在亮度反应较为强烈的海洋上会产生一定程度地误判,其原因是 GeoColor 合成图中耀斑处。观察左侧中部的薄云区,可以发现本文算法在薄云边缘处的判识精度仍有待提升。观察右侧中下部的海陆边界处,可以发现 FY-4A CLM 产品沿着边界线出现了较为明显的误判,而本

下面针对 T_{11} ($11\text{ }\mu\text{m}$ 亮温)特征参数模型进行分析。

图 9 为 1 月和 6 月 7 类下垫面类型所构建模型的 T_{11} 特征概率曲线。其中,横坐标 AGRI 载荷在 $11\text{ }\mu\text{m}$ 谱段的观测亮温,纵坐标为经由式(2)计算得出的后验云属概率。 $11\text{ }\mu\text{m}$ 通道为长波红外通道,对于此通道,大气组成成分对辐射的影响可以忽略,水汽只有微弱的吸收和再发射作用,卫星接收到的辐射主要是云和下垫面的发射辐射。根据普朗克定律,通常情况下高云比低云温度低,低云比下垫面温度低。但是由图 9 可知,不同下垫面和季节,云的 T_{11} 特征概率差别很大,在使用单一阈值进行区别时就需要特别注意。当下垫面为南极、北极和积雪时,云和下垫面差别较小,温度很低的高厚云才容易被识别;在不同季节,当下垫面为深海和浅海时,云与晴空的曲线变化十分陡峭,说明云的区分明显, T_{11} 在此下垫面比较适用;由于沙漠和积雪的下垫面主要分布在北半球,在不同季节时,沙漠和积雪的云属概率差异很明显,在 1 月时出现明显的逆温现象,这是因为此时沙漠和积雪的温度有可能比云低。另外,综合不同季节的模型和检验结果,在南极下垫面的有效情况样本点过少,此下垫面的模型正确性待确认。

文算法表现良好。同时,由于 FY-4A CLM 产品使用了 $12\text{ }\mu\text{m}$ 亮温,所以当谱段观测出现缺失时会形成明显的条带。本文算法使用的谱段较少,且基于概率的条件独立假设在信息缺失条件下仍能够得出后验云属概率,因而可以有效避免条纹现象。另外,本文对 12 个月份分别构建模型,因而需要评估不同月度模型之间的差异对云检测精度的影响。




图 10 2019 年 9 月 26 日 5 时 UTC 云检测局地结果对比

Fig. 10 Comparison of results of cloud mask locally at UTC at 5:00 September 26, 2019

图 11 直观展示了不同月度模型对云检测精度的影响。在图像的上部,6 月份模型检测结果出现了大量的错判晴空。这主要是不同月度模型的下垫面划分不同,出现晴空错判的下垫面是积雪,而 6 月份积雪下垫面上云的特征与 1 月份有较大不同。2 个模型在其他区域上的表现接近一致。




图 11 不同月度模型检测差异

Fig. 11 Model detection difference for different months

为了研究模型的月度差异,研究在 1 月的测试数据上定量对比基于 1 月和 6 月标记数据得到的 2 组模型,得到如表 3 的百分比混淆矩阵。分析表格

表 3 不同月度模型云检测混淆矩阵统计

Tab. 3 Model cloud detection confusion matrix statistics for different months (%)

模型月份	类别	云	可能云	可能晴空	晴空	总计
1 月	云	50.73	3.75	3.51	1.64	59.63
	可能云	1.95	0.51	0.55	0.91	3.92
	可能晴空	1.55	0.56	0.47	1.58	4.16
	晴空	3.14	1.96	2.65	24.54	32.29
6 月	云	46.89	3.83	3.3	8.55	62.57
	可能云	1.73	0.35	0.35	1.23	3.66
	可能晴空	1.59	0.35	0.34	1.35	3.63
	晴空	7.16	2.25	3.19	17.54	30.14
总计		57.37	6.78	7.18	28.67	100

可以发现,1 月模型的云判识结果要高出 6 月模型 3.84 百分点,晴空甚至高出 7 百分点;而明显错判的比例也明显较低,例如把云判为晴空的比例低 6.91 百分点,把晴空判为云的比例低 4.02 百分点。说明使用同期月度模型推断的云属类别会更加准确。

5 结论

本文针对 FY-4A/AGRI 云检测问题,提出了一种基于朴素贝叶斯算法的全自动云检测模型,实现了 FY-4A/AGRI 影像云像元的高效、精准识别。与已有的云检测方法相比,该模型引入了朴素贝叶斯理论,将云检测的阈值判断转化为概率评价,即不局限于是否有云,而是以云出现的概率做评价,评价结果更加合理。同时,新算法中涉及的数据只有红外通道,较好地解决了传统算法同时使用红外通道和可见光数据造成的晨昏区云检测分割线的问题。此外,该模型还引入了新的合成图特征,学习联合概率,取得了较好的云检测效果。

总体而言,基于朴素贝叶斯算法的全自动云检测模型展现出良好的识别光学载荷影像云像元的潜力,具有一定的理论意义和应用价值。不足之处在于使用的训练集真值来自 FY-4 业务产品,模型精度依赖于产品数据的精度,因此未来可以引入测云卫星 CALIPSO 的数据作为真值进行模型学习训练。另外,现有方法没有考虑到特征随太阳高度角和耀斑角的变化,未来可以加入 M 估计的方法,以改善分类评价效果。我们还计划将该模型应用于风云三号 E 星光学载荷的云检测,为解决气象卫星晨昏轨道云检测提供新的方法。

参考文献 (References) :

[1] 林 晔. 大气探测学教程[M]. 北京:气象出版社,1995.

Lin Y. Course of atmospheric exploration[M]. Beijing: China Meteorological Press, 1995.

[2] 杨亦萍,董晓刚,戴聪明,等. 利用MODIS数据对北极夏季卷云特性的研究[J]. 红外与激光工程, 2016, 45(4): 30-37.

Yang Y P, Dong X G, Dai C M, et al. Cirrus clouds properties in the arctic in summer based on MODIS data[J]. Infrared and Laser Engineering, 2016, 45(4): 30-37.

[3] 秦永,付仲良,周凡,等. 一种利用TM影像自动检测云层的方法[J]. 武汉大学学报(信息科学版), 2014, 39(2): 234-238.

Qin Y, Fu Z L, Zhou F, et al. A method of automatic cloud detection using TM image[J]. Geomatics and Information Science of Wuhan University, 2014, 39(2): 234-238.

[4] 赵忠明,朱重光. 遥感图象中薄云的去除方法[J]. 环境遥感, 1996, 11(3): 195-199.

Zhao Z M, Zhu C G. Approach to removing cloud cover from satellite imagery[J]. Remote Sensing of Environment, 1996, 11(3): 195-199.

[5] Rossow W B, Schiffer R A. ISCCP cloud data products[J]. Bulletin of the American Meteorological Society, 1991, 72(1): 2-20.

[6] Seze G, Rossow W B. Time-cumulated visible and infrared radiance histograms used as descriptors of surface and cloud variations[J]. International Journal of Remote Sensing, 1991, 12(5): 877-920.

[7] Rossow W B, Garder L C. Cloud detection using satellite measurements of infrared and visible radiances for ISCCP[J]. Journal of Climate, 1993, 6(12): 2341-2369.

[8] 刘健. FY-2云检测中动态阈值提取技术改进方法研究[J]. 红外与毫米波学报, 2010, 29(4): 288-292.

Liu J. Improvement of dynamic threshold value extraction technic in FY-2 cloud detection[J]. Journal of Infrared and Millimeter Waves, 2010, 29(4): 288-292.

[9] Saunders R W, Kriebel K T. An improved method for detecting clear sky and cloudy radiances from AVHRR data[J]. International Journal of Remote Sensing, 1988, 9(1): 123-150.

[10] Kriebel K T, Saunders R W, Gesell G. Optical properties of clouds derived from fully cloudy AVHRR pixels[J]. Beiträge zur Physik der freien Atmosphäre, 1989, 62: 165-171.

[11] Gesell G. An algorithm for snow and ice detection using AVHRR data an extension to the APOLLO software package[J]. International Journal of Remote Sensing, 1989, 10: 4-5, 897-905.

[12] Stowe L L, McClain E P, Carey R, et al. Global distribution of cloud cover derived from NOAA/AVHRR operational satellite data[J]. Advances in Space Research, 1991, 11(3): 51-54.

[13] Stowe L L, Vemury S K, Rao A V. AVHRR clear sky radiation data sets at NOAA/NESDIS[J]. Advance in Space Research, 1994, 14(1): 113-116.

[14] Menzel W P, Wylie D P, Strabala K I. Seasonal and diurnal changes in cirrus clouds as seen in four years of observations with the VAS[J]. Journal of Applied Meteorology, 1992, 31(4): 370-385.

[15] Wylie D P, Menzel W P, Woolf H M, et al. Four years of global cirrus cloud statistics using HIRS[J]. Journal of Climate, 1994, 7(12): 1972-1986.

[16] Shan N, Zheng T Y, Wang Z S. High-speed and high-accuracy algorithm for cloud detection and its application[J]. Journal of Remote Sensing, 2009, 13(6): 1138-1146.

[17] Goodman A H, Henderson-Sellers A. Cloud detection and analysis: A review of recent progress[J]. Atmospheric Research, 1988, 21(3-4): 203-228.

[18] 韩成鸣,李耀东,史小康. 云分析预报方法研究进展[J]. 地球科学进展, 2015, 30(4): 505-516.

Han C M, Li Y D, Shi X K. Overview of researches on cloud analysis and prediction methods[J]. Advances in Earth Science, 2015, 30(4): 505-516.

[19] 孙汝星,范荣双. 基于支持向量机的多特征融合影像云检测[J]. 测绘与空间地理信息, 2018, 41(6): 153-156, 160.

Sun R X, Fan R S. Multi-feature fusion image cloud detection based on SVM[J]. Geomatics and Spatial Information Technology, 2018, 41(6): 153-156, 160.

[20] 关峥嵘,谭毅华,田金文. 一种快速的遥感卫星图像云检测算法. 计算机与数字工程, 2019, 47(11): 2808-2811.

Guan Z R, Tan Y H, Tian J W. A fast cloud detection method in remote sensing satellite images[J]. Computer and Digital Engineering, 2019, 47(11): 2808-2811.

[21] 瞿建华,鄢俊洁,薛娟,等. 基于深度学习的FY3D/MERSI和EOS/MODIS云检测模型研究[J]. 气象与环境学报, 2019, 35(3): 87-93.

Qu J H, Yan J J, Xue J, et al. Research on the cloud detection model of FY3D/MERSI and EOS/MODIS based on deep learning[J]. Journal of Meteorology and Environment, 2019, 35(3): 87-93.

[22] 董瑶海. 风云四号气象卫星及其应用展望[J]. 上海航天, 2016, 33(2): 1-8.

Dong Y H. FY-4 meteorological satellite and its application prospect[J]. Aerospace Shanghai, 2016, 33(2): 1-8.

[23] 陆风,张晓虎,陈博洋,等. 风云四号气象卫星成像特性及其应用前景[J]. 海洋气象学报, 2017, 37(2): 1-12.

Lu F, Zhang X H, Chen B Y, et al. FY-4 geostationary meteorological satellite imaging characteristics and its application prospects[J]. Journal of Marine Meteorology, 2017, 37(2): 1-12.

[24] 杨军. 气象卫星及其应用[M]. 北京: 气象出版社, 2012.

Yang J. Meteorological satellites and their applications[M]. Beijing: China Meteorological Press, 2012.

[25] Ackerman S A, Smith W L, Revercomb H E, et al. The 27-28 October 1986 FIRE IFO cirrus case study: Spectral properties of cirrus clouds in the 8-12μm[J]. Monthly Weather Review, 1990, 118(11): 2377-2388.

[26] Miller S D, Lindsey D T, Seaman C J, et al. GeoColor: A blending technique for satellite imagery[J]. Journal of Atmospheric and Oceanic Technology, 2020, 37(3): 429-448.

An FY –4A/AGRI cloud detection model based on the naive Bayes algorithm

YAN Junjie, GUO Xuexing, QU Jianhua, HAN Min

(Beijing Huayun Shinetek Science and Technology Co. , Ltd. , Beijing 100081, China)

Abstract: This study developed an automatic cloud detection method based on the naive Bayes algorithm for the cloud detection of the advanced geosynchronous radiation imager (AGRI) aboard the FY –4A satellite. In this method, the naive Bayes algorithm serves as the core structure, and appropriate infrared channels are selected as the parameters of the characteristic classifier according to the basic cloud detection principle of optical payload to ensure the consistency of cloud detection between day and night. After the classified training and construction for different surface types and different months, a cloud detection model based on the naive Bayes algorithm was finally established. Moreover, the classifier for FY –4A/AGRI data used in the method was established considering seven typical cloud detection characteristics and one characteristic based on the infrared composite images. As indicated by the learning tests and verification using the business cloud detection product of the National Satellite Meteorological Center (NSMC) in 2019, the classifier yielded a probability of detection (POD) greater than 98% for land, desert, shallow water, and deep sea, greater than 80% for snow cover, and greater than 80% for North and South poles. The comparison between the cloud detection results of this study and those obtained using the NSMC business system showed that the cloud detection results of this study had an average monthly POD of the whole year greater than 98% , a false alarm ratio (FAR) less than 5% , and all Kuiper’ s skill scores (KSSs) greater than 90% .

Keywords: FY –4A/AGRI; Naive Bayes Algorithm; cloud detection; POD

(责任编辑: 张 仙)