

射电望远镜天文台址云量监测方案研究

张海龙[†] 逯登荣[‡] 孙继先 李积斌 张旭国

(中国科学院紫金山天文台青海观测站 德令哈 817000)

摘要 在毫米波以及亚毫米波射电天文望远镜台址遴选过程中,为了能够充分地了解候选天文台址的云量信息,设计出应用于野外环境的全天相机系统很有必要.因此根据射电望远镜特点以及野外台址具体状况,方案中创新性地利用行星相机、嵌入式微控制器研制出全时段全天相机.其可在野外利用太阳能长期运行,而且最重要的特点是可实现无人值守、自主运行.在数据处理部分,也创新性地利用深度学习神经网络算法,提取数据特征值,建立机器学习模型库,全自动统计出台址的云量信息,比人工和一般图像处理算法统计效率更高,而且更简单.这些研究为更加全面地评估毫米和亚毫米波射电天文台址提供了重要的参考.

关键词 望远镜: 射电, 仪器: 探测器, 方法: 测量与评估, 技术: 图像处理, 选址

中图分类号: P111; **文献标识码**: A

1 引言

毫米波、亚毫米波射电天文望远镜对天文台址有着很高的要求,尤其是亚毫米波望远镜.其台址必须具备低温、低大气水汽含量、大范围电磁环境宁静区域等较高条件外,对其他如海拔、地形地貌、大气效应、云量等也有一定要求^[1].亚毫米波射电望远镜要求天文台址的云量少,因为云量能间接反映出台址大气水汽含量情况.所以云量对于毫米波射电望远镜优质数据产出有很大影响,甚至可降低望远镜观测效率,影响望远镜正常观测.

在天文台址数据监测中,利用全天相机拍摄云图来监测天空云量是最常用的方法之一^[2].为了能够了解野外候选台址的云量信息,在系统设计中借鉴了中国SONG (Stellar Observations Network Group)项目全天云量监测方案^[3]以及其他光学台址全天相机的研制方案^[4].为实现台址全自动监

测,方案中应用了振旺光电ASI224MC彩色行星相机,该相机像素 1280×960 ,像素大小 $3.75 \mu\text{m} \times 3.75 \mu\text{m}$,可提供极低的读取噪声和高灵敏度.该相机体积相比一般单反相机要小很多,方便集成,而且功耗很小(最大2.8 W),可使用USB接口直接供电和控制.为实现监测天空各个区域的云量情况,相机搭配了500万像素鱼镜头,焦距1.55 mm,相面尺寸 $(1/2)''$.后期为了对大量数据(每天至少几百张云图)进行快速处理,方案中使用python语言编写深度学习算法,通过大量样本进行机器学习训练,提取各种云图的特征值建立模型库,全自动统计出台址的天气状况.

2 全天相机监测系统

2.1 监测需求

在潜在的天文候选台址上进行监测,最基本要求就是无人值守,获取长期数据.特别是在遴选

2024-05-27收到原稿, 2024-09-25收到修改稿

[†] hlzhang@pmo.ac.cn

[‡] drlu@pmo.ac.cn

毫米波、亚毫米波射电望远镜台址时, 候选台址都在高海拔、缺氧的野外无人区, 没有任何保障支撑条件. 这就要求监测系统完全自动化, 如自动监测、根据光线自动调整相机参数、自动保存数据以及后期数据自动传输等.

全天相机监测系统必须对天空云量变化进行实时监测, 并本地保存数据. 在有网络连接的环境下, 系统支持远程登录显示云量数据. 云量数据也可按采样时间以图片格式本地保存, 方便后续数据处理. 采样时间可修改, 方案中根据图片大小, 存储空间以及云量变化时间综合分析, 选择5 min间隔保存一张云图. 由于长时间无人值守, 需要高

可靠性, 且候选台址环境最低温度可达 -35°C , 需要保证在低温环境下系统能正常运行. 监测控制系统需集成化、轻量化且具备低功耗特性以便能够适应野外安装、运行、维护.

2.2 系统组成

全天相机监测系统由嵌入式微控制器(树莓派4B)、振旺光电公司所生产天文相机(ASI120MM-S)、加热控制模块、鱼镜头(FS15520FEMP)、亚克力半球、外壳以及直流电源(包含太阳能板、电池、充电控制器等)组成, 如图1所示.




图 1 全天相机系统框图

Fig. 1 All-sky camera system diagram

全天相机整个舱体由亚克力板包裹, 里面集成有嵌入式微控制器和行星相机. 嵌入式控制器采用树莓派微型控制器, 直流5 V供电, 最大功耗6–7 W, 搭载linux操作系统, 存储空间128 G. 行星相机由树莓派控制器USB端口供电和通讯, 最大功耗2.86 W.

考虑到相机以及镜头保护、透光性、加工安装、整体重量等因素, 全天相机壳体结构全部采用亚克力板材质(有机玻璃). 亚克力板透光率好(达92%以上), 其耐候性优良, 对自然环境适应性较强, 长时间在太阳光照射, 风吹雨淋下, 其性能

不会发生改变, 抗老化性能好. 加工方面既适合机械加工又易热成型, 裁剪也很方便. 亚克力半球和壳体均有现成产品不需要复杂加工, 其他支撑板可根据安装需求对亚克力板进行裁剪. 适用于野外安装运行的全天相机, 其结构设计原则是尽量做到小型化、集成化、轻量化, 全天相机3D模型如图2所示.

在冬季使用时, 亚克力壳体内外温度相差较大, 导致半球内壁可能出现结霜现象, 所以在半球安装时, 底部接触面留有缝隙, 并且四周开了通风孔, 方便平衡内外温度, 消除半球内壁结霜现象,

如图3所示.




图 2 全天相机3D模型
Fig. 2 All-sky camera 3D model




图 3 半球底部设计进气孔
Fig. 3 Air inlet designed at the bottom of the hemisphere

相机使用温度最低 $-5\text{ }^{\circ}\text{C}$, 考虑到野外台址冬季气温可达 $-35\text{ }^{\circ}\text{C}$, 所以给相机安装柔性聚酰亚胺 (Polyimide, PI)膜加热片, 以 12 V 直流电加热保温. 通过加热片加热以及树莓派控制器自身发热使相机温度保持在 $-5\text{ }^{\circ}\text{C}$ 以上, 温度控制使用简易的温度开关芯片控制, 安装于相机附近. 根据相机温度控制加热, $0\text{ }^{\circ}\text{C}$ 以下温度开关闭合, 加热片通电加热, $0\text{ }^{\circ}\text{C}$ 以上温度开关常开, 加热片断电停止加热, 如图4所示.




图 4 加热控制电路图
Fig. 4 Heating control circuit picture

为了提高保温效果, 整个亚克力外壳也用保温棉包裹, 减少热量流失. 实物如图5所示.




图 5 全天相机实物图
Fig. 5 All-sky camera actual picture

3 全天相机监测以及数据处理

3.1 全天相机安装监测

全天相机前期测试时间为2023年12月初至2024年2月中旬, 安装于中国科学院紫金山天文台青海观测站台址内. 2024年3月安装于紫金山天文台德令哈雪山牧场射电多波段候选台址进行长期监测, 如图6所示.



图 6 全天相机安装及监测现场
Fig. 6 All-sky camera installation and monitoring site

相机控制程序使用python语言进行编写, 调用了相机自带函数库, 可实现设定时间间隔的自动拍照并保存图片, 还可根据天空亮度变化实时控制相机曝光时间和增益两个参数. 常见的相机增益、曝光时间控制算法有: 平均亮度法、权重

均值法、亮度直方图等,其中最普遍的就是平均亮度法,方案中也应用了该方法,具体控制流程如图7所示.




图 7 相机参数调整流程

Fig. 7 Camera parameter adjustment process

控制程序每次对相机捕获照片进行平均亮度计算,调用的函数为Python numpy库中的median函数.依据实测效果设定亮度范围,小于范围最小值则认为照片过暗,需增加曝光时间以及增益,反之大于范围最大值则认为照片过亮,需减小增益以及曝光时间.最后设置新的增益、曝光时间参数并获取调整后的图像,再次进行平均亮度计算以及判断.经过多次迭代直至照片平均亮度在设定范围内.

设定的亮度范围需结合台址实际情况确定,可采用天光亮度(Light)传感器、夜天光监测仪等一些仪器长期测量,然后利用仪器实测值来辅助计算设定参数.方案中依据特定情况,如有无太阳和月亮、晴天、阴天、多云等各种天气场景,通过多次调整参数,获取了最佳的经验亮度设定范围.确定亮度调整范围后进行拍摄,图8为白天有太阳、晴空、多云、阴天时拍摄的云图.图9为夜间有月亮、晴天、多云、阴天场景下拍摄的云图.




图 8 白天天空各类云图

Fig. 8 Various cloud maps of the daytime sky




图 9 夜晚天空各类云图

Fig. 9 Various cloud maps of the night sky

在测试阶段,发现太阳光直射时,会将相机底部影像反射到顶部半球上,如图8左上角照片显示,后期考虑将相机镜头底部平铺黑色消光布,以消除反射.

在传统的云图处理过程中,有时太阳和月亮区域的灰度值与云的特征很接近,数据处理算法很容易将太阳和月亮影响区域判断成云,造成误判,所以图片数据需要预处理.解决该方法为时间分割法和差分法^[5],其基本思路为在相邻两张照片内,太阳以及月亮位置变化小于云变化,可用差分法去除.时间分割法指在一段时间内,如多张连续帧内,认为太阳和月亮灰度值变化不大,可将其识别出轨迹变化,从而将其去除.这两种方法

可有效去除太阳和月亮影响, 但这样将使数据处理工作复杂化, 对于不需要准确分析云团大小、云团覆盖面的需求来说, 深度学习神经网络算法将更加有优势, 下面将重点介绍。

3.2 数据处理与统计分析

全天相机数据以图片格式保存, 而且数据量十分庞大, 需要高效率算法对图片进行处理并统计。对于云图分析较多的是人工统计^[5], 少量的用到了算法处理, 但算法建模一般都需要图片处理方面的专业知识, 而且用图像处理算法处理数据一般较为繁琐, 使得数据处理效率不是很理想。所以在本方案中, 创新性地用到了人工智能领域的图像识别技术。其基本思路是, 首先需要进行图像特征提取, 然后通过机器学习建立模型库, 最后在此基础上对目标图像进行分类和统计。传统的图像识别过程如图10所示。




图 10 传统的图像识别系统

Fig. 10 Traditional image recognition systems




图 11 经典神经网络结构示意图(A_i : 图像信息矩阵元素, W_i : 权重矩阵元素, K : 元素数量)

Fig. 11 Schematic diagram of the classic neural network structure (A_i : elements of image information matrix, W_i : elements of weight matrix, K : number of elements)

卷积神经网络的结构与传统神经网络类似, 也是根据大脑神经元而设计, 其本质就是将一个个简单的神经元连起来, 利用每个底层的神经元提取图像的信息, 然后将许多这样的神经元结合起来提取一个十分复杂的图像信息, 最终获得图像的高级语义特征^[6]。根据相关试验结果, 采用卷

随着AI人工智能技术发展, 图像识别技术成为人工智能的一个重要领域, 人们对图像识别的要求也更加严格, 使得传统图像识别展现出许多不足, 如自适应弱、易受噪声干扰、依赖于人工设计等^[6]。特别是在复杂的应用环境中, 例如自动驾驶领域, 需要计算机快速识别出各种物体。而深度学习十分适应这类应用场景, 通过大量样本和长时间训练, 使得图像识别准确率和效率大大提高。

深度学习方面的研究可以追溯到1943年由美国心理学家McCulloch和数学家Pitts提出的M-P神经元模型, 是两位研究工作者在探讨人工神经网络时所提出^[7]。深度学习主要包括以下算法: 深度置信网络(Deep Belief Network, DBN)^[8-10]、递归神经网络(Recurrent Neural Network, RNN)^[11]和卷积神经网络(Convolution Neural Network, CNN)^[12-15]等。一个典型的神经网络结构如图11所示, 包括输入层、若干个隐层(Hidden Layer)、输出层。隐层中包含众多神经元以及相应权重链接和激励函数(Activation function)。神经元和隐层数目标志着网络的复杂程度, 数目越多的神经网络适应能力越强, 非线性效应越显著。

积神经网络设计的训练模型, 对数据集识别的准确率可达到96%^[6], 为更好地发展图像识别技术提供基础支持。

数据处理流程如图12所示, 方案中首先利用卷积神经网络生成机器学习模型库, 将大量样本云图划分为4组样本(分别用数字表示, 0: 阴天; 1:

多云; 2: 晴天; 3: 雪). 数据处理程序将所有云图转成灰度图, 获取像素矩阵后利用深度学习卷积神经网络工具进行特征提取, 分别得到阴、晴、多云、雪4组样本下的特征矩阵 W . 经过大样本多次迭代训练, 最终得到训练模型库(Training model parameter library). 云图识别过程也是将云图转

换成灰度图, 然后调用训练模型库, 通过卷积神经网络提取云图特征值, 最后依据特征值归类到提前划分好的4组集合, 从而判别天气状况.

卷积神经网络特征提取是训练模型库和云图识别过程中都要参与的重要环节, 是图像识别的核心, 其基本结构如图13所示.




图 12 使用神经网络处理云图流程

Fig. 12 Using neural networks to process cloud images




图 13 卷积神经网络图片特征提取结构(W : 模型库特征矩阵)

Fig. 13 Convolutional neural network image feature extraction (W : the characteristic matrix of model library)

图13中,在卷积神经网络图像特征提取中用到了卷积层(Convolution)、最大池化层(Max pooling)、激活层ReLU (Rectified Linear Unit)、全连接层(Fully connected layers)多个经典网络层.卷积层的功能是提取图像特征,是卷积神经网络

的核心.图片的像素矩阵数据(Pixel matrix)与包含权重参数的卷积核(Convolutional Kernel)进行卷积运算,在像素矩阵中从左到右、自上而下,按照公式(1)进行卷积运算,得到图片特征矩阵,如图14所示.




图 14 特征值的卷积运算

Fig. 14 Convolution of eigenvalues

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} * \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix} = a_{11} \times 1 + a_{12} \times 0 + a_{13} \times 1 + a_{21} \times 0 + a_{22} \times 1 + a_{23} \times 0 + a_{31} \times 1 + a_{32} \times 0 + a_{33} \times 1 \quad (1)$$

(1)式中最左侧的矩阵为图片像素矩阵,记为 $\mathbf{a}$,卷积核的权重值是图像识别所要得到的最终结果,即模型库.初始值为随机量,经过训练迭代后最终得到机器学习模型库.

池化层(Pooling)的主要作用是对于卷积层提取的特征进行挑选,挑选不受位置干扰的图像信息.其次是对特征进行降维,减小特征变量个数,从而减少计算量.常见的池化操作有最大池化和均值池化.图15中按粗线方框将提取的特征矩阵进行划分,再对每个划分区域提取最大值,将这些最大值组成新的特征矩阵,这就是最大池化运算.




图 15 最大池化运算

Fig. 15 MaxPooling operation

在神经元中,输入Input经过一系列加权求和

后作用于另一个函数,这个函数被称为激励函数.类似于人类大脑中基于神经元的模型,激励函数最终决定了是否要传递信号以及要传递给下一个神经元的内容.常见的激励函数有Sigmoid函数、Tanh函数、ReLU函数.前两个在运算过程中易出现过拟合,所以一般用ReLU函数,形式如下:

$$g(x) = \max(0, x) \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

全连接层在神经网络模型中起到分类作用,是最后一层.在训练模型库时,通过优化参数可使训练效率提高,如神经网络卷积层层数(Layer)、卷积核个数、是否做填充(Padding)操作、神经网络模型的正则化Dropout随机失活比例以及数据遍历次数Epochs等参数,其中卷积层数和遍历次数影响较大.

图16为神经网络卷积层数对训练效果影响,Train_loss以及Train_acc分别为神经网络损失函数值和准确率,可以看出在同样样本数据量下,卷积层数越多,损失函数出现跳变和过拟合风险也越大.图17所示为Epochs分别为10次、30次、60次、100次时,达到的训练效果,可以看出在数据遍历30次时,准确率已经达到90%以上.遍历次数过大,损失函数值不再平滑,有过拟合风险,而且计算机处理时间也越长.




图 16 卷积层数对训练效果影响(a: 3层, b: 4层)

Fig. 16 The influence of convolution layers on training effect (a: 3 layers, b: 4 layers)




图 17 Epochs参数对训练效果影响


Fig. 17 The influence of different epochs on training effect

2024年3月4日至17日, 在候选台址测得4089组数据, 通过训练模型, 获得天气统计情况. 图18和图19分别为模型训练和天气数据统计.

得到训练模型后, 为了评估模型的优劣, 在样

本数据中抽取4组真实的样本集合(金标), 包括阴天、多云、晴天、雪, 然后将这些真实集合代入到模型中进行分析. 这里用到了由Python语言编写的开源人工神经网络库keras, 使用keras自带模

型评估函数Evaluate和评估分类算法中普遍用到 的混淆矩阵.




```

选定 Anaconda Powershell Prompt (Anaconda3)
5/15 [=====] - 1s 95ms/step - loss: 0.1171 - accuracy: 0.9546
epoch 12/30
5/15 [=====] - 1s 91ms/step - loss: 0.1083 - accuracy: 0.9719
epoch 13/30
5/15 [=====] - 1s 92ms/step - loss: 0.0756 - accuracy: 0.9762
epoch 14/30
5/15 [=====] - 1s 91ms/step - loss: 0.0474 - accuracy: 0.9849
epoch 15/30
5/15 [=====] - 1s 92ms/step - loss: 0.0358 - accuracy: 0.9978
epoch 16/30
5/15 [=====] - 1s 91ms/step - loss: 0.0431 - accuracy: 0.9870
epoch 17/30
5/15 [=====] - 1s 91ms/step - loss: 0.0518 - accuracy: 0.9806
epoch 18/30
5/15 [=====] - 1s 91ms/step - loss: 0.0543 - accuracy: 0.9784
epoch 19/30
5/15 [=====] - 1s 91ms/step - loss: 0.2711 - accuracy: 0.9071
epoch 20/30
5/15 [=====] - 1s 91ms/step - loss: 0.1641 - accuracy: 0.9460
epoch 21/30
5/15 [=====] - 1s 91ms/step - loss: 0.1359 - accuracy: 0.9546
epoch 22/30
5/15 [=====] - 1s 92ms/step - loss: 0.0507 - accuracy: 0.9892
epoch 23/30
5/15 [=====] - 1s 91ms/step - loss: 0.0216 - accuracy: 0.9957
epoch 24/30
5/15 [=====] - 1s 92ms/step - loss: 0.0507 - accuracy: 0.9849
epoch 25/30
5/15 [=====] - 1s 92ms/step - loss: 0.0572 - accuracy: 0.9892
epoch 26/30
5/15 [=====] - 1s 92ms/step - loss: 0.0289 - accuracy: 0.9935
epoch 27/30
5/15 [=====] - 1s 91ms/step - loss: 0.0209 - accuracy: 1.0000
epoch 28/30
5/15 [=====] - 1s 91ms/step - loss: 0.0134 - accuracy: 0.9978
epoch 29/30
5/15 [=====] - 1s 91ms/step - loss: 0.0151 - accuracy: 0.9978
epoch 30/30
5/15 [=====] - 1s 91ms/step - loss: 0.0156 - accuracy: 0.9957
loss: [1.1312826871871948, 0.8016170859336853, 0.6977229714393616, 0.571111202239902, 0.391853

```

图 18 生成神经网络训练模型

Fig. 18 The generated neural network training model



```

Anaconda Powershell Prompt (Anaconda3)
预测结果为: 多云 E:\sky\20240303\camer20240317231003.jpg
1/1 [=====] - 0s 21ms/step
预测结果为: 多云 E:\sky\20240303\camer20240317231504.jpg
1/1 [=====] - 0s 21ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317232005.jpg
1/1 [=====] - 0s 19ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317232506.jpg
1/1 [=====] - 0s 20ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317233007.jpg
1/1 [=====] - 0s 19ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317233508.jpg
1/1 [=====] - 0s 19ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317234009.jpg
1/1 [=====] - 0s 19ms/step
预测结果为: 阴天 E:\sky\20240303\camer20240317234509.jpg
1/1 [=====] - 0s 20ms/step
预测结果为: 多云 E:\sky\20240303\camer20240317235000.jpg
1/1 [=====] - 0s 19ms/step
预测结果为: 晴天 E:\sky\20240303\camer20240317235501.jpg

++++++统计结果++++++
多云:431 晴:2417 阴:1241 雪:0
多云:10
阴:30
晴:59
雪:0
++++++统计结果++++++
(base) PS E:\sky>
微软拼音 半 :04:34.175354: I tensorflow/core/util/port.cc:113] oneDNN cust

```

图 19 利用神经网络训练模型对云图像进行分类

Fig. 19 Using the neural network training model to classify the cloud images

分析结果显示: 自带评估函数evaluate评估模型准确率为94%, 混淆矩阵评估每个分类集合的准确率为93.7%, 如图20所示.

图21为人工统计和神经网络算法统计结果对比, 最大差别在于多云和阴天之间的差别, 主要原因为模型训练时样本较少, 每个样本集合小于100组数据. 但在处理时间上, 机器学习算法效率比人工处理高很多, 以上述处理4089组数据为例, 算法可在1 min左右完成统计, 而人工将花费至少1 h以上. 可见在大数据批处理上, 机器学习算法更加高效.

与其他算法比较, 例如灰度值聚集类算法^[5], 在特定场合下(不需精确计算云量), 卷积神经网络在复杂程度、效率以及准确率上也有所优势, 对比结果如表1所示. 当然在需要精确计算云量的应用场景下, 神经网络则还需更加精细的分类以及庞大的训练样本, 甚至需要复杂的图像处理算法才能满足要求. 而在射电望远镜天文选址方面, 不需要得到云量精确数据, 只需得到一个能够反映

台址上空大气概况的长期统计数据, 以便与其他环境数据来共同反映出台址的天气情况, 正是这一原因, 卷积神经网络算法才有较大的优势.




图 20 使用混淆矩阵评估训练模型

Fig. 20 Using confusion matrix to evaluate the training model




图 21 人工统计和神经网络模型统计结果对比

Fig. 21 Comparison of statistical results between manual statistics and neural network models

表 1 灰度值聚集类算法与卷积神经网络对比
Table 1 Comparison between grayscale value aggregation algorithms and convolutional neural networks

Algorithm	Characteristic			
	Image preprocessed	Complexity	Result accuracy	Efficiency
Grayscale value aggregation	Yes	Complex	76.67%	180 Groups @ 2.1 Minutes
Convolutional neural network	No	Simple	More than 90%	4089 Groups @ 1 Minutes

4 总结

全天相机监测系统在云量信息的实时监测上

发挥着重要作用, 是光学望远镜以及射电望远镜天文台址监测系统的重要组成部分. 本系统旨在

针对毫米波、亚毫米波射电望远镜选址的主要特点,如候选台址基本在高海拔、恶劣环境、无任何保障条件的野外无人区,设计方案需满足供电简单(太阳能电池供电)、安装简单、可无人值守自动运行的全天相机监测系统,后续可利用北斗系统进行短报文通讯直接实现远程监测.围绕这些特殊需求,在系统硬件方面创新地选用性价比比较好的行星相机来获取天空图像.通过利用低功耗、小型化的嵌入式控制器,根据实际天光亮度进行相机自动调参,实现监测系统无人值守运行.在数据处理方面,开创性地引入深度学习卷积神经网络算法,基于python语言编写深度学习算法软件,通过大量样本进行机器训练,提取各种云图的特征值,可对庞大数据(上万量级)进行有效处理,实现数据批量处理并全自动统计出台址的天气状况.

在后续的数据处理算法研究中,可进行的主要研究内容包括:对图像前期处理、消除太阳、月亮区域的误判、消除反射;研究卷积神经网络算法下的全天空云量的定义和计算;增加神经网

络模型训练样本数据,使得模型更可靠;进行远程数据传输实验,对处理过后的数据结果通过北斗短报文方式传输,实现对野外台址天气状况远程监测等.

参考文献

- [1] 张海龙,姚骑均,孙继先,等. 青海科技, 2023, 3: 23
- [2] 彭焕文,辛玉新,和寿圣. 天文研究与技术, 2015, 12: 89
- [3] 田健峰,邓李才,闫正洲. 天文学报, 2016, 57: 366
- [4] 樊亮,雷成明. 天文学报, 2016, 57: 461
- [5] 魏诗雅,邱波,曹子皇. 天文研究与技术, 2019, 16: 85
- [6] 张玉红,白初祥,孟凡军. 新技术新工艺, 2021, 1: 52
- [7] 周飞燕,金林鹏,董军. 计算机学报, 2017, 40: 1229
- [8] 郭丽丽,丁世飞. 计算机科学, 2015, 42: 28
- [9] 刘方园,王水花,张煜东. 计算机工程与应用, 2018, 54: 11
- [10] 郑胤,陈权崎,章毓晋. 中国图象图形学报, 2014, 19: 175
- [11] 丛爽,戴谊. 计算机应用, 2004, 24: 18
- [12] 张荣磊,田爱奎,谭浩. 山东理工大学学报(自然科学版), 2018, 32: 48
- [13] 罗嘉杰,施佳林. 科技创新导报, 2019, 24: 130
- [14] 许锋,卢建刚,孙优贤. 信息与控制, 2003, 32: 344
- [15] 常亮,邓小明,周明全. 自动化学报, 2016, 42: 1300

Research on Cloud Monitoring Scheme for Radio Telescope Observatory Site

ZHANG Hai-long LU Deng-rong SUN Ji-xian LI Ji-bin ZHANG Xu-guo

(Qinghai Station of Purple Mountain Observatory, Chinese Academy of Sciences, Delingha 817000)

ABSTRACT In the process of selecting millimeter/submillimeter wave radio astronomical telescope sites, it is necessary to design an all-sky camera system for use in the field environment in order to fully understand the cloud amount information of candidate observatory sites. Therefore, according to the characteristics of submillimeter wave radio telescopes and the specific conditions of the field sites, this scheme innovatively use the planetary camera and embedded microcontroller to develop a full-time all-sky camera, which can operate in the field for a long time using solar energy, and the most important feature is that it can achieve unmanned and autonomous operation. In the data processing part, the deep learning neural network algorithm is also innovatively used to extract data feature values, establish machine learning model library, and automatically count cloud information of the site, which is more efficient and simpler than manual and general image processing algorithms. These studies provide important references for more comprehensive evaluation of millimeter/submillimeter wave radio observatory sites.

Key words telescopes: radio, instrumentation: detectors, methods: measurement and evaluation, techniques: image processing, site testing