

激光与视觉融合的透视平面检测与深度预测研究

赵宇琦¹, 连晓峰¹, 王宇龙², 田梓薇¹, 徐晨星¹

(1. 北京工商大学 人工智能学院, 北京 100048;

2. 中国兵器工业信息中心, 北京 100089)

摘要: 针对单一的激光传感器或视觉传感器无法检测到透视三维平面的问题, 提出一种基于激光传感器与视觉传感器融合的透视平面检测与深度预测算法; 首先采用透视平面检测网络, 在二维彩色图像中对透视平面进行图像分割; 其次应用单一图像反射去除算法, 在分割得到的透视平面区域分离背景信息, 并使用 MegaDepth 算法进行深度预测, 得到相对深度图; 最后结合激光传感器的深度数据, 采用抽样一致性算法, 计算深度标尺, 并使用对透视平面进行深度赋值, 将相对深度图转化为绝对深度图, 进而完成对透视平面的深度预测; 实验结果表明该算法能成功检测并分割透视平面, 且能得到正确的透视平面绝对深度信息。

关键词: 视觉与激光融合; 数据融合; 平面检测; 深度估计; 随机抽样一致性

Research on Glass Plane Detection and Depth Prediction Based on Fusion of Laser and Camera

ZHAO Yuqi¹, LIAN Xiaofeng¹, WANG Yulong², TIAN Ziwei¹, XU Chenxing¹

(1. School of AI, Beijing Technology and Business University, Beijing 100048, China;

2. China Ordnance Industry Information Center, Beijing 100089, China)

Abstract: Aiming at the problem that a single laser sensor or vision sensor cannot detect the perspective three-dimensional plane, a perspective plane detection and depth prediction algorithm based on the fusion of laser sensor and vision sensor is proposed. Firstly, perspective plane detection network is used to segment the perspective plane in a two-dimensional color image; secondly, a single image reflection removal algorithm is applied to separate the background information in the segmented perspective plane area, and the MegaDepth algorithm is used for depth prediction to obtain a relative depth map; and finally combining the depth data of the laser sensor, the sampling consistency algorithm is used to calculate the depth scale, and the depth assignment to the perspective plane is used to convert the relative depth map into an absolute depth map, and then complete the depth prediction of the perspective plane. The experimental results show that the algorithm can successfully detect and segment the perspective plane, and can obtain the correct absolute depth information of the perspective plane.

Keywords: camera and laser fusion; data fusion; plane detection; depth estimation; random sample consensus (RANSAC)

0 引言

透视平面通常具有广泛的实用和装饰用途, 由于其透光无色的特性, 通常是一种非晶态的无定形的固体, 其透光无色的特性会对现有的计算机视觉系统与激光传感器系统造成严重的干扰 (如深度预测^[1]和激光测距^[2]): 视觉传感器及其算法无法分辨透视平面, 且由于视觉传感器提供的图像只有二维的信息, 所以通常会误判透视平面后的信息; 又由于透视平面通常为无色透光平面, 会对激光传感器测量的距离信息造成严重影响, 使其接收错误的深度信息。通过以上影响进一步干扰机器人导航和无人机跟踪等系统的运行。为了解决这一问题, 系统必须能够从输入的

数据中检测透视平面。

现有的方法通常采取语义分割应对这一问题, 语义分割旨在将给定图像分割并解析为不同语义类别的不同区域。近来, 受益于深度神经网络的进步, 在语义分割这一方面已经取得了较大的进展; 一些小型透视制品如杯子等, 由于拥有相对固定的形状可以用现有的方法很好的检测出来, 如 RCNN^[3] (Regions with CNN features)、YOLO^[4] (You only look once)、RetinaNet^[5]等算法。RCNN 通过生成类别独立的建议区域, 为感知器提供候选区域从而提高性能; YOLO 算法采用回归的方法, 对整张图进行预测, 学习更为通用的图像特征; RetinaNet 通过提出其改造后的损失函

收稿日期: 2021-03-17; 修回日期: 2021-05-06。

基金项目: 国家自然科学基金(61702020); 北京市自然科学基金(4172013); 北京市自然科学基金-海淀原始创新联合基金(L182007)。

作者简介: 赵宇琦 (1997-), 男, 北京人, 硕士生, 主要从事机器视觉, 三维重建方向的研究。

引用格式: 赵宇琦, 连晓峰, 王宇龙, 等. 激光与视觉融合的透视平面检测与深度预测研究[J]. 计算机测量与控制, 2021, 29(11): 29-34.

数,提高了算法的速度与精度。然而由于透视平面不具有固定的形状,任何场景都有可能出现在透视平面的区域内,并且这些场景通常与透视平面周围的场景具有一定的相似性,这使得对透视平面的检测与深度预测从根本上不同于其他常见物体。现有的物体检测方法不适用于透视平面检测,因为不是所有透视区域都具有明确可识别的边界这使得如 HED^[6] (Holistically-nested edge detection)、RCF^[7] (Richer convolutional features)、Basnet^[8] (Boundary-aware salient network) 等算法不能很好的得到应用。此外,有些镜像分割方法通过检测镜像边界处的内容不连续性来分割镜像,如 Mask RCNN^[9], R3Net^[10] (Recurrent residual refinement network)、Picanet^[11] (Pixel-wise contextual attention network) 等。然而这并不适用于透视检测,因为透视后面的场景是真实场景的一部分,这使得透视边界处的不连续性非常微弱,同时也加大了透视平面检测的难度。深度预测算法旨在从二维的图像中得到深度信息,而基于单目视觉传感器的深度预测算法难以得到准确的深度信息(如 Monodepth^[12]等算法),基于多个传感器的深度预测算法也会忽视透视平面的存在(如 SFM^[13] (Structure from motion)、Depth-VO-Feat^[14]等算法),这说明预测透视平面本身的深度是一个被忽视的问题,同时也证明了问题的难度。

为了解决透视平面的检测与深度预测这一问题,首先采用透视平面检测网络^[15]独有的广域上下文特征融合模块,同时提取高级特征与低级特征,从而达到模仿人类对透视平面的辨别方式,进而检测图像输入中的透视平面,其次采用 MegaDepth^[16]方法进行相对深度预测, MegaDepth 算法通过叠加多个沙漏模块,不断地对图像进行卷积提取高阶特征,然后结合单一图像反射去除^[17] (single image reflection removal—SIRR) 算法,分离透视平面的背景,屏蔽背景信息对深度预测的干扰,进而对图像进行相对深度预测,最后结合激光传感器提供的深度信息,记录多个像素点在相对深度预测图中的灰度及深度信息,并以灰度值为横轴深度值为纵轴,应用随机抽样一致性算法^[18] (random sample consensus—RANSAC) 对所得点集进行直线拟合,得到“灰度-深度”的标尺,并通过标尺完成对透视平面深度信息的预测。

1 透视平面检测网络

透视平面检测网络是一种专门针对检测透视平面的人物设计的深度神经网络,这种网络通过模仿人类对高级语义特征(例如,不同对象之间的关系)与颜色纹理等低级特征(例如,透视平面内部和外部之间的色差,反射导致的模糊、斑点、重影等)的辨识设计了广域上下文特征融合模块,以检测不同尺寸的透视平面,这种模块可以从较大的范围内,提取丰富的上下文特征以进行上下文推理和透视平面的定位。广域上下文特征融合模块基础结构图如

图 1 所示。




图 1 广域上下文特征融合模块基础结构图

其中:BN (batch normalization) 代表归一化,ReLU (rectified linear unit) 为线性整流函数,conv 为卷积运算。广域上下文特征融合模块旨在提取大量广域特征信息,以进行上下文推断和定位透视平面。该模块使用空间可分离卷积来实现此目标:

$$F_c = \mathcal{N}(\text{conv}_h(\text{conv}_v(F))) \quad (1)$$

F 代表输入特征, \mathcal{N} 为 BN 与 ReLU 运算, F_c 代表输出的广域特征, conv_h 与 conv_v 分别为大小为 $k \times 1$ 垂直卷积核与 $1 \times k$ 的水平卷积核。由于透视区域内的内容通常很复杂,因此从两个平行路径中互补的提取广域上下文特征在经由 3×3 的卷积核融合后输出特征。则整个广域上下文特征融合模块可以表示为:

$$F_c = \mathcal{N}(\text{conv}_v(\text{concat}(\mathcal{N}(\text{conv}_v(\text{conv}_h(F_1))), \mathcal{N}(\text{conv}_h(\text{conv}_v(F_1)))))) \quad (2)$$

其中: F_c 表示集成的广域上下文特征, conv_v 表示大小为 3×3 的卷积核, F_1 为:

$$F_1 = \mathcal{N}(\text{conv}_1(F_{in})) \quad (3)$$

F_{in} 代表广域上下文特征融合模块的输入特征。将 4 个该基础模块并联,并将 4 个基础模块输出的特征进行串联融合,即可构成完整的广域上下文特征融合模块。透视平面检测网络的流程如图 2 所示。

对于单个 RGB 图像,首先用经过预训练的 ResNeXt101^[19] 网络对图像提取特征,以得到不同级别的特征,然后将这些特征的最后 3 个特征层分别输入到一个广域上下文特征融合模块,并将输出融合生成高级广域上下文特征,剩下的特征层导入另一个广域上下文特征融合模块中提取出低级特征,这些低级特征将引导算法把注意力^[20]放在更多的集中在图像中的透视平面上,从而进行图像分割。

2 相对深度预测

现有的深度预测算法大多数基于双目视觉得到的视差图计算深度,或由同一个视觉传感器前后帧的时间关系以及像素点的匹配关系进行估算,而深度学习算法使用的训

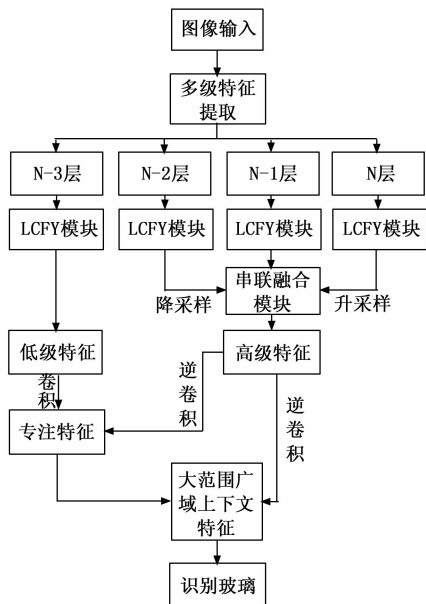


图 2 透视平面检测网络算法框图

练集也都没有特意针对透视平面进行标注,这使得深度预测的算法在直接对含有透视平面的图像进行深度预测时,算法会将透视平面后的背景当做实景进行预测,导致预测结果错误。这种错误对于机器人、无人机等移动平台来说是致命的。



图 3 错误的深度预测

为了解决这一问题,采用 MegaDepth 算法对图像进行深度估计。首先加入单一图像反射去除算法,用于该算法采用全卷积神经网络,经过训练后能可将透视平面后的实景与透视平面中的镜像分离,并屏蔽镜像,防止其对深度预测造成影响。但该算法直接应用在包含透视平面的图像中时,透视平面以外区域的特征信息可能会遭到抹除或模糊。

如图 4 所示,左图为未经 SIRR 算法处理的原图,可以看到,表示区域中的纹理信息是完好的,右图是经过 SIRR 算法整图运算后的算法,可以看到标识区域内的纹理信息在应用 SIRR 算法后,地板及墙面的纹理信息被模糊甚至抹

除。所以首先对图像进行透视平面检测,得出透视平面所在区域,然后只对透视平面检测网络分割出的透视平面区域应用 SIRR 算法并屏蔽镜像。这样做可以避免纹理信息错误导致的特征提取信息的错误影响预测结果的问题。然后应用 MegaDepth 算法对处理后的图像进行深度预测。相对深度预测算法网络结构如图 5 所示。




图 4 应用算法后部分纹理信息被模糊

如图 6 所示, Conv 代表卷积层, Res 代表残差块, Max pool 是降采样模块。由于较低的分辨率更能提取出图像的高阶特征,便于网络进行预测,所以将输入图像经由 7×7 的卷积层运算后,再经过一个残差块与降采样层使图像分辨率下降,使网络能更好的提取图像的特征,然后经过 7 个沙漏模块运算输出预测的相对深度结果。沙漏模块的结构如图 6 所示。

Max pool 代表下采样, Res 代表残差块, Up sample 代表上采样模块。沙漏模块的上中两路都包含残差模块,能逐步提取更深层的图像特征。整个相对深度预测网络中堆叠了很多沙漏模块,这使得网络可以不断地重复的进行高阶特征的提取与预测,从而得到更精确的预测图。在得到相对深度预测图后,加入透视平面检测网络所得的分割结果,对透视平面区域进行处理,由透视平面的边界值对整个透视平面进行平面拟合得到透视平面的相对深度值。

3 透视平面深度预测

目前由深度学习算法对单目图像进行深度预测的算法中,均需要带有深度图的标定后的数据集作为训练样本,才能获得测试图像的深度图,且在包含透视平面的图像中,对深度的预测结果均不准确。MegaDepth 算法的不同之处在于,其大部分图像来自互联网,泛用性很强,且对于这部分数据集的构建只需要标出图像中最近和最远的两点即可进行训练和预测,获得相对深度图。再结合深度标尺就可以完成对于透视平面的深度获取任务。

MegaDepth 算法对于物体边缘的深度值估计准确程度不高,所以尽可能选取位于物体平面上的点进行深度赋值获取深度信息。在相对深度图中,随机抽选 n 个像素点,




图 5 相对深度预测网络示意图

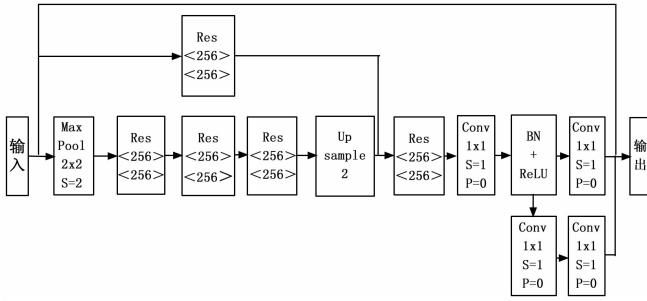


图 6 沙漏模块

记录其灰度值，并结合激光传感器所提供的深度信息获取像素点对应的深度值。像素点深度值的获取方法为，以像素点为中心， l 像素为边长框选邻域，计算所框选邻域中所有深度信息的平均值，所得值即为当前像素点的深度值，对于深度值丢失的像素点不计入平均值总数中，同时默认透视平面中的所有像素点深度值均有误差，不计入平均值样本中。其计算方法如式 (4) 所示。

$$D(p) = \frac{\sum_{i=-\frac{l}{2}}^{\frac{l}{2}} \sum_{j=-\frac{l}{2}}^{\frac{l}{2}} D(p^*(x+i, y+j))}{\alpha} \quad (4)$$

其中： D 代表深度值， p 为随机选取的像素点， p^* 代表 p 点邻域内的像素点， x, y 为 p 点坐标， α 为邻域内拥有深度信息的像素点数量。

位于物体边界处的像素点，计算后会得到错误的深度信息，因为以边界处像素点为中心框选的邻域内，通常会包含非该像素点所在平面的其他深度信息，在求取平均值后会得出错误的深度信息。所以为了避免这种情况，引入 ORB (Oriented FAST and rotated BRIEF) 特征提取^[21] 算法中的 FAST 角点检测算法^[22]，FAST 算法可以通过像素点周围距离为 3 的 16 个像素快速判断待测点是否为角点或边界点，通过对比待测点与周围点的灰度差值来进行分类，若连续有 9 个点为同一类型，则确定该像素点位于物体边界处，并将此点删除。

利用 FAST 算法排除上述选取的 n 个像素点中的边界像素点，从而提高预测精度。判断方法如式 (5) 所示。

$$F_{pn} = \begin{cases} F & \|I_n - I_p\| \geq t \\ T & \|I_n - I_p\| < t \end{cases} \quad n = 1, 2, 3, \dots, 16 \quad (5)$$

I_n 为 p 点周围点的灰度值， I_p 为 p 点的灰度值， t 为判断阈值。当 F_{pn} 为 F 时，排除该像素点。

然后再从激光传感器提供的深度信息中，随机选取 m 个像素点 (像素点同样不位于透视平面上)，记录像素点本身提供的深度信息与对应的相对深度图中像素块的灰度值。将所记录的 $m+n$ 个像素点的数据平铺于以灰度值为 x 轴，深度值为 y 轴平面坐标系中。并应用 RANSAC 算法对所得坐标点集进行直线拟合，RANSAC 算法通过对离散的点集进行迭代估计其数学模型，并且能排除误差点的干扰，适

合对上述记录的可能存在误差点的点集进行直线拟合得到合理的预测线。将其预测的直线作为灰度值与深度值对应的“灰度-深度”标尺，以此深度标尺对透视平面进行深度赋值，来完成对透视平面的深度预测。


4 实验结果与分析

实验平台 CPU 为 i7-6700HQ，内存为 8 GB，实验数据集为 TUM 数据集^[23]。首先在数据集中挑选包含透视平面的图像，并确认图像分辨率并进行透视平面的标定，然后将所得数据的 70% 进行训练 30% 进行测试。先进行透视平面的分割实验，并与对比算法进行比较。其次分别进行改进 MegaDepth 与原算法的实验，并进行对比。最后计算深度标尺，完成透视平面深度预测实验。

4.1 透视平面分割实验

实验采用可对镜子进行分割的 MirrorNet^[24] 与经典的 Mask RCNN 算法进行对比，将输入图像分别使用 3 种算法进行图像分割。

由图 7 可看出，由 Mask RCNN 算法对透视平面进行预测时，不能完成对透视平面的图像分割，其基本没有识别到透视平面。由于 MirrorNet 算法是用于对镜子平面进行目标平面检测的算法，与对透视平面进行分割具有一定的相似度，因此 MirrorNet 在对透视平面的平面检测上仍能有一定的精确度基本覆盖了透视平面所在区域，但仍然有未被识别的区域，效果远不如透视平面检测网络。透视平面检测网络通过大范围的学习上下文高级特征与低级纹理特征成功的检测到了整个透视平面，远优于其他两个算法。



(a) 输入图像

(b) Mask RCNN

(c) MirrorNet

(d) 透视平面检测网络

图 7 不同算法对透视平面检测的结果

4.2 相对深度预测实验

在相对深度预测的实验中，将改进算法与原 MegaDepth 算法进行对比，以证明改进的有效性。原算法直接对输入图像进行预测，改进算法在对透视平面区域进行背景分割并屏蔽后，再进行深度预测。结果如图 8 所示。

从图 8 (b) 可以明显的看出，原算法忽略了透视平面，




图 8 相对深度预测结果

对透视平面的背景进行了深度预测, 而加入了 SIRR 算法及透视平面检测网络后的改进 MegaDepth 算法修正了这个错误, 对透视平面本身进行相对深度预测, 得到了图像相对深度图。

相对深度图中只个像素的相对深度值, 不能得到各像素点的绝对深度值, 所以还需要使用深度标尺对相对深度图进行赋值。

4.3 透视平面深度预测实验

在该组实验中, 首先统计对改进 MegaDepth 算法所得预测图进行深度赋值并与激光传感器提供的深度图进行比较, 随机抽选像素点个数 n 和 m 均为 300, 邻域边长 l 为 20 个像素, FAST 算法判断阈值 t 为 7。首先随机选取像素点, 并记录深度值与相对深度图上的灰度值, 然后将像素点平铺于横轴为灰度值, 纵轴为深度值的在坐标系内, 使用 RANSAC 算法进行直线拟合, 得到深度标尺, 并使用深度标尺复原透视平面的深度值。实验结果如图 9 所示。




图 9 透视平面深度预测结果

(其中 (a) 为输入图像 (b) 为激光传感器提供的深度图 (c) 为对改进 MegaDepth 赋值结果)

可以明显的看出, 在输入图像 (图 9 (a)) 显示的透视平面所在区域, 激光传感器获得了错误的深度信息, 这是由于透视平面的折射使得传感器不能正确接收信息, 其所获得的部分深度信息为透视平面背景的深度信息。使用深度标尺对相对深度图赋值后, 成功的修正了这一点 (图 9 (c) 所示), 成功获得了整个透视平面的深度信息。

5 结束语

为了检测透视平面并获取透视平面本身的绝对深度信息, 提出了一种融合激光传感器与视觉传感器信息的算法, 算法能成功对图像中的透视平面进行平面检测, 并在 MegaDepth 算法的基础上加入 SIRR 算法, 结合透视平面检测

网络成功的预测了透视平面本身的相对深度信息, 最后应用 ORB 特征提取算法与 RANSAC 算法建立了深度标尺, 成功获取了透视平面本身的绝对深度信息。并在大量含有透视平面场景的 TUM 数据集进行试验验证。实验结果表明, 激光与视觉融合的平面检测与深度预测算法, 能成功检测到透视平面并能获取其绝对深度信息, 对实际问题具有一定的应用价值。

参考文献:

- [1] 周大可, 田 径, 杨 欣. 结合局部平面参数预测的无监督单目图像深度估计 [J]. 中国图象图形学报, 2021, 26 (1): 165-175.
- [2] 杜蒙蒙, 刘颖超, 姬江涛, 等. 基于无人机与激光测距技术的农田地形测绘 [J]. 农业工程学报, 2020, 36 (22): 60-67.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] //Proceedings of the IEEE conference on computer vision and pattern recognition. 2014: 580-587.
- [4] ZHU Q, ZHENG H, WANG Y, et al. Study on the Evaluation Method of Sound Phase Cloud Maps Based on an Improved YOLOv4 Algorithm [J]. Sensors, 2020, 20 (15): 4314.
- [5] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] //Proceedings of the IEEE international conference on computer vision. 2017: 2980-2988.
- [6] XIE S, TU Z. Holistically-nested edge detection [C] //Proceedings of the IEEE international conference on computer vision. 2015: 1395-1403.
- [7] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection [C] //Proceedings of the IEEE conference on computer vision and pattern recognition, 2017: 3000-3009.
- [8] QIN X, ZHANG Z, HUANG C, et al. Basnet: Boundary-aware salient object detection [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 7479-7489.
- [9] HE K, Gkioxari G, Dollár P, et al. Mask R-CNN [C] //Proceedings of the IEEE international conference on computer vision. 2017: 2961-2969.
- [10] DENG Z, HU X, ZHU L, et al. R3net: Recurrent residual refinement network for saliency detection [C] //Proceedings of the 27th International Joint Conference on Artificial Intelligence. AAAI Press, 2018: 684-690.
- [11] LIU N, HAN J, YANG M H. Picanet: Learning pixel-wise contextual attention for saliency detection [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 3089-3098.
- [12] GODARD C, MAC AODHA O, BROSTOW G J. Unsupervised monocular depth estimation with left-right consistency [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 270-279.
- [13] ZHOU T, BROWN M, SNAVELY N, et al. Unsupervised learning of depth and ego-motion from video [C] //Proceed-

ings of the IEEE conference on computer vision and pattern recognition. 2017; 1851 - 1858.

[14] ZHAN H, GARG R, WEERASEKERA C S, et al. Unsupervised learning of monocular depth estimation and visual odometry with deep feature reconstruction [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018; 340 - 349.

[15] MEI H, YANG X, WANG Y, et al. Don't hit me! glass detection in real - world scenes [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020; 3687 - 3696.

[16] LI Z, SNAVELY N. Megadepth: Learning single-view depth prediction from internet photos [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018; 2041 - 2050.

[17] YANG J, GONG D, LIU L, et al. Seeing deeply and bidirectionally: A deep learning approach for single image reflection removal [C] //Proceedings of the European Conference on Computer Vision (ECCV). 2018; 654 - 669.

[18] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography [J]. Communications of the ACM,

1981, 24 (6): 381 - 395.

[19] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks [C] //Proceedings of the IEEE conference on computer vision and pattern recognition. 2017; 1492 - 1500.

[20] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C] //Proceedings of the European conference on computer vision (ECCV). 2018; 3 - 19.

[21] 宋超群, 许四祥, 杨宇, 等. 一种基于改进 ORB 算法的双目视觉测距方法 [J]. 光电子·激光, 2021, 32 (2): 122 - 129.

[22] VISWANATHAN D G. Features from accelerated segment test (fast) [C] //Proceedings of the 10th workshop on Image Analysis for Multimedia Interactive Services, London, UK. 2009; 6 - 8.

[23] SCHUBETT D, GOLL T, DEMMEL N, et al. The TUM VI benchmark for evaluating visual - inertial odometry [C] // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018; 1680 - 1687.

[24] YANG X, MEI H, XU K, et al. Where is my mirror? [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019; 8809 - 8818.

差

差的组成, 仿真计算确定和、差通道物理路径长度差值与相位差之间关系。由于对塔校相数据是处于静态条件下获取的相位值, 准确性较高, 因此在剔除近场效应的影响后, 基于测控系统各设备组合的对塔校相数据进行校相参数计算, 获取相关参数后得出相位差计算公式。在此基础上归纳总结出海上相位修正及标校方法和基带不同工作模式之间相位修正方法, 通过编写相应的功能软件准确快速计算任一点频的相位值及修正, 实现测量船 S 频段测控系统全频段海上相位标校工作。

参考文献:

[1] 房新兵, 毛南平, 刘向前, 等. 船载测控雷达无塔角度标校新方法 [J]. 电讯技术, 2010, 50 (12): 116 - 120.

[2] 杨稳竞, 吴昊, 杨国. 锚泊状态下船载测控系统对塔相位标校研究 [J]. 计算机测量与控制, 2017, 25 (9): 1 - 4.

[3] 董建伟, 高长生, 熊伟, 等. 脉冲测量雷达无塔标校系统设计 [J]. 计算机测量与控制, 2013, 21 (3): 685 - 686.

[4] 毛南平, 徐昌庆, 张忠华. 船载测控雷达海上无塔校相技术 [J]. 电讯技术, 2004, (1): 38 - 43.

[5] 刘童岭, 邵长宝, 周成刚. 船载雷达无塔动态相位标校方法研究 [J]. 科学技术与工程, 2011, 11 (24): 5989 - 5993.

[6] 王健, 姚学露, 夏利利. 航天测量船海上相位快速修正方法 [J]. 火力与指挥控制, 2011, 36 (7): 82 - 84

[7] 王健, 夏莉莉, 张清, 等. 船载数字跟踪接收机自动校相新算法研究 [J]. 遥测遥控, 2010, 31 (5): 67 - 71.

[8] 宋海军, 丁求启, 苏龔. 船载单脉冲雷达快速标校系统设计

与实现 [J]. 计算机测量与控制, 2017, 25 (9): 95 - 98.

[9] 仇三山. 双通道单脉冲跟踪快速校相改进算法 [J]. 四川兵工学报, 2013, 34 (5): 96 - 98.

[10] 汪晓燕. 单通道单脉冲角跟踪系统的研究 [J]. 电讯技术, 2005, 45 (3): 117 - 120.

[11] 庄传刚, 刘莉, 李彬. 车载测控系统标校过程中校相新方法研究 [J]. 计算机测量与控制, 2014, 22 (7): 2234 - 2236.

[12] 刘冰, 陆人佳. 统一测控系统跟踪在轨目标自动校相方法研究 [J]. 遥测遥控, 2010, 31 (1): 37 - 40.

[13] 瞿元新. 船载微波统一测控系统概论 [M]. 北京: 国防工业出版社, 2015.

[14] 仇三山, 汪远玲, 杨洪军. 深空测控系统跟踪接收机射电星校相的可行性分析 [J]. 电讯技术, 2010, 50 (8): 22 - 25.

[15] 习靖. 双通道角跟踪设备的近场相位校准研究 [J]. 无线电工程, 2013, 43 (5): 32 - 34.

[16] 毛南平, 丛波. 近场效应对一种 C 频段统一测控雷达角度标校数据的影响分析 [J]. 电讯技术, 2004, 48 (4): 65 - 68.

[17] 唐海. 天线测量 [M]. 北京: 国防工业出版社. 2000

[18] 徐荣, 陈步康, 刘童岭. 近场虚拟目标在船载测控设备无塔校相中的应用研究 [J]. 飞行器测控学报, 2010, 29 (6): 34 - 38

[19] 蔡瑾曜, 陈晓阳. 近场效应对船载双通道雷达相位标校影响及应对方法研究 [J]. 国外电子测量技术, 2017, 36 (7): 27 - 30.

[20] 林昌禄. 天线工程手册 [M]. 北京: 电子工业出版社, 2002.