

一种光学卫星无控定位误差智能建模方法

陈昊¹, 乔凯¹, 刘伟玲²

(1. 北京跟踪与通信技术研究所, 北京 100094;

2. 武汉大学 测绘遥感信息工程国家重点实验室, 武汉 430000)

摘要: 光学卫星的无控定位精度是决定影像应用效果的重要因素; 研究表明, 影响光学卫星无控定位精度的主要因素包括姿态测量随机误差、时间同步误差、结构变形等引起的姿态低频误差等, 影响因素多, 难解耦, 传统通过控制点评估来建立无控定位误差模型的方法难以客观全面地揭示误差规律; 为了更准确地建立无控定位误差变化规律模型, 该文将卷积神经网络引入无控定位精度建模, 以卫星成像参数和业务系统全自动几何质检结果作为学习样本, 利用网络训练无控定位精度与成像参数的关系, 更全面揭示无控定位误差规律, 并通过预测定位误差来提升无控定位精度; 试验中选取了 10 019 景珞珈一号 01 星数据, 采用 7 514 景影像作为无控定位误差变化规律的训练样本集, 剩余的数据开展无控定位误差预测补偿精度验证; 结果表明, 模型预测精度小于 1 个像素, 验证了该方案的有效性和可行性。

关键词: 光学卫星; 几何定位; 姿态低频误差; 定位精度; 卷积神经网络

An Intelligent Modeling Method for Uncontrolled Positioning Error of Optical Satellite

CHEN Hao¹, QIAO Kai¹, LIU Wei Lin²

(1. Beijing Institute of Tracking and Communication Technology, Beijing 100094, China;

2. Wuhan University, Wuhan 430000, China)

Abstract: Uncontrolled positioning accuracy of optical satellite is an important factor to determine the effect of image application. The research shows that the main factors of image optical satellite uncontrolled positioning accuracy include attitude measurement random error, time synchronization error, attitude low-frequency error caused by structure deformation, etc. There are many image factors which is difficult to decouple. The traditional method of establishing uncontrolled positioning error model through control point evaluation is difficult to objectively and comprehensively reveal the error law. In order to establish the uncontrolled positioning error model of variety rule accurately. The convolutional neural network is introduced into the modeling of uncontrolled positioning accuracy. The satellite image parameters more comprehensively reveal the law of the uncontrolled positioning error, and improve the uncontrolled positioning accuracy by predicting positioning error. Finally, the effectiveness and feasibility of this method are verified by using the 10019 images data of Luo-Jia01 satellite. By using the 7514 scene images, the training sample set is taken as the uncontrolled positioning error, the compensation accuracy for the uncontrolled positioning error is verified through the remaining data. The results show that the prediction accuracy for the model is less than 1 pixel, the effectiveness and feasibility of this paper are verified.

Keywords: optical satellite; geometric positioning; attitude low frequency error; positioning accuracy; convolutional neural network

收稿日期: 2021-12-23; 修回日期: 2022-01-04。

作者简介: 陈昊(1982-), 男, 安徽铜陵人, 博士, 副研究员, 主要从事信号与信息处理方向的研究。

引用格式: 陈昊, 乔凯, 刘伟玲. 一种光学卫星无控定位误差智能建模方法[J]. 计算机测量与控制, 2022, 30(2): 269-275.

0 引言

长期以来,世界各国竞相发展航天遥感技术,陆续发射了系列对地观测光学卫星,如美国的 GeoEye、WorldView 系列卫星,法国的 SPOT、Pleiades 系列卫星等。国外依靠硬件优势,结合地面定标、误差建模等高精度处理技术,实现了光学卫星全球最高 3~5 m 的无控定位精度^[1-5]。“十二五”以来,我国在高分辨率对地观测卫星领域均取得重大成果,至“十三五”结束,我国高分专项卫星完成部署,民用领域光学卫星最高分辨率已可达 0.5 m 左右。虽然国内光学卫星影像分辨率日益趋近国外先进水平,但国内光学影像无控精度普遍在 10 米开外,与国外仍有较大差距。

已有研究表明,影响光学卫星无控定位精度的因素包括姿态测量精度、结构变形等引起的低频姿态误差。国内相关单位针对上述两方面开展了大量研究。针对姿态测量精度,2012 年发射的资源三号 01 星,姿态测量精度/频率可达到 3"/4 Hz^[6-8],2014 年发射的高分二号卫星姿态确定精度可达 3.6",2019 年发射的高分七号卫星姿态确定精度可达到 1",姿态测量误差得到很好的控制^[9];而针对低频姿态误差,熊凯等采用扩维卡尔曼滤波方法,将卫星成像姿态、低频误差参数作为变量进行同时估计,并在真实卫星遥感数据的基础上构建了仿真模型,利用仿真数据对所提方法开展验证,结果表明该方法在低频误差较大情况下的效果明显优于低频误差较小情况,其中当低频误差较小情况的姿态确定精度甚至不如传统的扩展卡尔曼滤波方法^[10];Lai Yuwang 等学者首先对 STE-CE(空间技术试验和气候探测)卫星两颗星敏间的夹角变化进行频谱分析,该研究认为星敏夹角变化可以侧面反映因外热流引起的结构变形,最终造成姿态低频误差。通过采用 Vondrak 滤波算法可以抑制该误差对姿态确定的影响,使滤波后的姿态低频误差峰值相交补偿前更小^[11-12]。

国内部分学者试图从地面处理的角度出发,直接建立无控定位精度随成像参数的变化规律,以求对定位误差进行预测补偿。王艳丽等学者认为姿态低频误差主要由外热流引起的结构变化造成,且该变化与太阳高度角相关,进而提出一种顾及太阳高度角变化的光学影像姿态低频误差标校与补偿方法,建立了姿态

低频误差的傅里叶级数展开模型,并利用地面控制求解模型参数,将海洋 1C 卫星无控定位精度从 3.8 像元提升到 1 个像元^[13];管志超等学者同样认为姿态低频误差与外热流引起的结构变形紧密相关,该变形可能与成像星下点经纬度存在关系,建立了无控定位误差与成像星下点经纬度的关系模型,并利用资源三号卫星正视相机开展了验证,建模精度可在 10 米以内^[14]。

但是,姿态低频误差的产生原因是多方面的,包括星敏/星相机内部随温度变化、外热流引起的结构变化等,因素多,难建模,传统通过地面控制点结合经验模型的建模补偿方法难以客观、全面的揭示姿态低频误差的特征规律。本文提出了一种光学卫星无控定位误差智能建模方法。首先,基于卷积神经网络对无控定位精度建模;其次,以卫星成像参数和业务系统全自动几何质检结果作为学习样本,利用网络训练无控定位精度与成像参数的关系,挖掘无控定位误差规律;最后,通过预测定位误差来提升无控定位精度。

1 算法原理

卫星在轨运行中,通常采用 GPS 设备测量其相位中心在 WGS84 坐标系下的位置及速度矢量;星敏及陀螺等定姿设备测量卫星成像姿态;当星敏参与定姿时,利用观测数据最终确定卫星本体相对于 J2000 坐标系的姿态;而当星敏不参与定姿时,则通常测量卫星本体相对于轨道坐标系的姿态。当前国内在轨的线阵推扫卫星均采用了星敏定姿,因此本文研究几何定位模型中仅考虑 J2000 坐标系下的姿态测量数据。

相机随着卫星的运动而推扫成像,各行影像符合中心投影原理。依据相关坐标系定义及转换,可构建线阵推扫光学卫星几何定位模型如下^[15-16]:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} X_s \\ Y_s \\ Z_s \end{bmatrix}_t + m(R_{J2000}^{WGS84} R_{body}^{J2000})_t \begin{bmatrix} Dx & dx \\ Dy + dy + R_{camera}^{body} \begin{bmatrix} x - x_0 - \Delta x \\ y - y_0 - \Delta y \\ f \end{bmatrix} \\ Dz & dz \end{bmatrix}$$

式中, $(X \ Y \ Z)^T$ 为地物点坐标, $(X_s \ Y_s \ Z_s)_t^T$ 为 t 时刻 GPS 相位中心在 WGS84 坐标系下的位置矢量; $(R_{body}^{J2000})_t$ 为 t 时刻卫星本体坐标系与 J2000 坐标系的转换矩阵,由星上安装的星敏和陀螺联合处理获

取; $(R_{J2000}^{WGS84})_t$ 为 t 时刻 J2000 坐标系相对于 WGS84 坐标系的转换矩阵; R_{camera}^{body} 代表相机在卫星本体坐标系下的安装矩阵; 为 GPS 相位中心在卫星本体坐标系的坐标; $(dx \quad dy \quad dz)^T$ 为相机投影中心在卫星本体坐标系的坐标, m 为比例系数, (x, y) 为影像坐标, (x_0, y_0) 、 f 为相机主点、主距, $(\Delta x, \Delta y)$ 是由内方位元素误差 (如镜头畸变) 引起的像点偏移。

根据几何定位模型, 成像误差源梳理如表 1 所示。

表 1 误差源梳理

特性	误差源	误差项
系统误差	内方位元素误差	主点主距误差
		CCD 排列误差(尺寸误差、旋转误差)
		镜头畸变
	轨道系统误差	
	姿态误差	姿态系统误差
		姿态低漂
		星敏—相机安装误差
	时间误差	轨道时间系统误差
		姿态时间系统误差
	光行差	卫星运行速度和光信号
大气折射		
随机误差	姿态随机误差	
	时间误差	轨道时间随机误差
		姿态时间随机误差

表 1 中, “_” 标示误差通常可以通过常态化在轨几何定标进行消除, “=” 代表难以通过定标消除的在轨误差。可见, 影响无控定位精度的主要误差源来自于姿态低漂、姿态随机误差、时间随机误差。目前已有研究种, 部分学者认为姿态低漂主要由外热流引起的结构变形造成, 其可能与成像星下点经纬度或太阳高度角有关; 而姿态随机误差则认为主要由星点识别误差造成, 与星敏/星相机状态、成像空间等相关。由于误差产生机理复杂、误差源多且难以解耦, 传统方法难以建立无控几何定位精度的变化规律模型。因此, 为更为全面、客观地建立无控定位误差随姿态低频误差、测姿随机误差等的变化规律, 本文搭建深度学习框架, 以成像参数、无控定位误差作为训练对, 通过模型训练, 实现对给定成像参数的无控定

位误差预测, 进而提升无控定位精度。本文技术流程如图 1 所示。

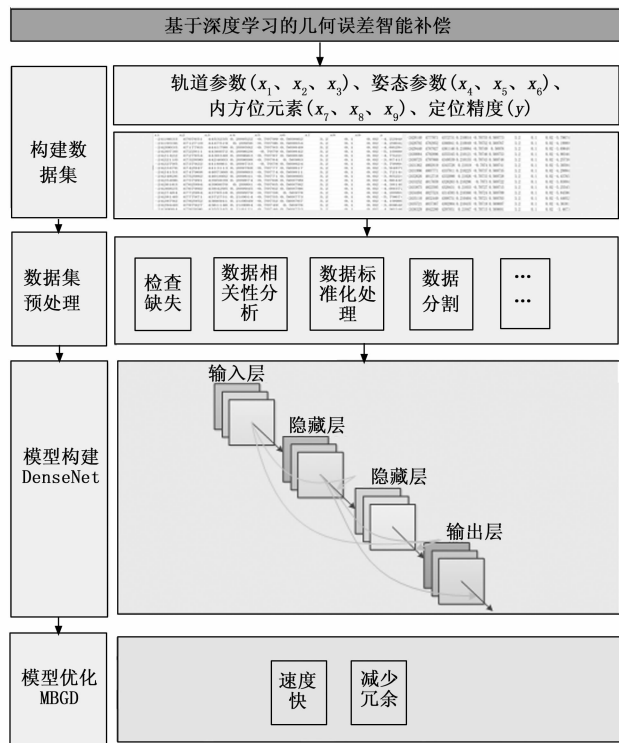


图 1 光学卫星无控定位误差智能建模处理流程

1.1 构建光学无控定位误差模型数据集

无控定位误差本质上是由测姿随机误差、低频误差等引起。而测姿随机误差主要与星敏/星相机状态 (如因温度变化造成的焦面变化)、成像空间 (即观测恒星的星等、数量等情况) 相关, 而低频误差与外热流等相关, 而无论温度变化、成像空间变化或者外热流等, 均可包含在卫星成像的相关参数种, 例如星下点经纬度、成像姿态。因此, 可以利用无控定位误差与成像参数作为训练对来搭建样本集。

当前卫星业务处理系统均包含自动几何质检模块, 可以利用国内外公开的较高精度几何基准数据开展几何质检, 评估得到每景影像的无控定位误差。为了进行无控定位误差智能建模, 文中对影响卫星定位精度的核心要素进行筛选, 例如可选取影响卫星定位精度的星下点位置、成像姿态等作为模型回归拟合的自变量, 相应的定位误差作为回归拟合的因变量^[18-19]:

$$Y = f \odot (X_{roll}, X_{pitch}, X_{yaw}, X_{lat}, X_{lon}) \quad (1)$$

式中, x_{roll} , x_{pitch} , x_{yaw} 分别为影像拍摄时的成像角度,

x_{lat} 和 x_{lon} 分别为星下点经纬度, \odot 为神经网络运算。

1.2 数据预处理

卫星成像数据传输过程, 可能存在误码等现象, 造成少量影像数据无控定位异常, 该部分数据不应加入样本集进行训练。因此, 在构建数据集中, 我们首先需要对本样本进行预处理, 以提高模型预测精度。

1) 我们利用 Pandas 库提供的 drop 函数接口和 isna 函数接口, 对初始样本集种的所有样本进行数值探测, 剔除数值过大或者过小的异常值, 避免影响模型拟合精度。

2) 采用 Pandas 库提供的 corrwith 函数, 对选择的自变量和因变量进行相关性分析, 若因变量与自变量相关性强, 则说明该自变量因素是引起无控定位误差变化的主要因素, 若相关性弱, 则该自变量因素可能与无控定位误差变化无关。设定 corrwith 函数阈值为 0.000 1, 剔除相关性小于 0.000 1 的自变量因素。

3) 由于数据在数量级上存在较大差距, 易造成模型陷入局部最优状态, 我们采用标准化方法对本样本集进行处理。在文中总共采用了 3 个函数进行标准化处理, 分别是 MinMaxScaler、Normalizer、StandardScaler。经过反复验证和调整参数, 最终采用的标准话函数是 MinMaxScaler。最终获取文中数据集。

1.3 DenseNet 模型构建

深度学习可以通过构建具有多隐藏层的神经元节点来构建机器学习模型, 并从海量的数据中学习隐藏的特征, 以实现数据的高准确性预测。深度学习之所以称之为深度学习是因为它相较于浅层神经网络模型具有更多的层, 并且它的优势是可以实现特征的自动学习, 与传统方法相比, 它能挖掘更深层次的数据特征。

卷积神经网络 (CNN, convolutional neural networks) 模型是深度学习中最具代表性的模型之一, 在计算机视觉领域有着广泛的应用, 但随着应用领域的不断扩展, CNN 模型在随着网络层数不断加深时, 神经网络层的梯度消失问题逐渐显现, 这一问题也导致了 CNN 个学者对该问题的改进。DenseNet 通过将所有层直接相互连接, 在实验过程中也验证了该操作可以有效减轻梯度消失的问题。文中也借鉴了 DenseNet 网络的优势^[15], 构建适用于珞珈数据的神

神经网络模型。DenseNet 网络通过将每一层中的神经元以前馈的方式与其他层均进连接, 每一层的输出都是前面所有层的输入经过激活函数计算得到的, 此外, 网络中每一层都与输入层连接, 经过实验验证发现, 该连接方式有效减轻了梯度消失的问题, 并加强了数据特征的传输, 有效缓解了数据集上过拟合的问题, 使得数据隐藏特征被充分挖掘, 有效的提高了网络预测精度。与残差网络 (ResNet), 由于 DenseNet 网络的每一层都有自己的权重, 整个模型参数数量巨大。但 DenseNet 的不同之处在于, 它没有一味的通过加深网络层数来构建网络架构, 这种机制有效提高了参数的利用率, 故在反向传播过程中网络需要更新的参数数量较少, 模型也更加易于收敛, 我们将 DenseNet 网络结构引入了回归拟合中, 激活函数采用了 RELU 函数^[21]。

1.4 模型优化

MBGD 是深度学习中应用较为广泛的优化模型, 它可以在梯度下降的方向上以很小的步幅来实现更新神经网络中每一层的权重和偏置等参数^[16-17]。

MBGD 算法流程:

输入: 样本集的训练集 X_{train} 和测试集 X_{test} , 迭代次数 T , 学习率 α

初始参数 θ

for t to T

从 X_{train} 中选取 k 个样本 $\{x_{ig}\}, i=1, \dots, k, g=1, 2, 3$
 $g=0$

for $i=1$ to k do

$g \leftarrow \frac{1}{k} \nabla_{\theta_{i-1}} \sum_i L(h(y_i; \theta_{i-1}), h_i)$

end for

$\theta_i \leftarrow \theta_{i-1} - \eta g_i$

end for

输出 θ 。

2 智能建模试验

2.1 实验数据

珞珈一号 01 星是首颗兼具遥感和导航功能的一星多用低轨微纳科学试验卫星, 2015 年由武汉大学立项研制, 2018 年 6 月 2 日发射入轨, 其主载荷为夜光成像相机和星基导航增强载荷, 主要用于社会经济参数估算、重大事件评估、国家安全等领域, 以及开展低轨星基导航信号增强试验。珞珈一号 01 星的

夜光遥感分辨率 130 m, 可清晰识别道路和街区, 优于美国的 DMSP/ OLS 2.7 km 和 NPP/VIIRS 740 m, 目前该星已向 22 个国家和地区 (包括美德法英等) 3 千多用户分发了 18 万多景夜光影像, 为全球不同行业各类用户提供免费数据服务, 在社会经济参数估算、国家安全等领域发挥了重要作用^[20]。

试验中共选取 10 019 景珞珈一号 01 星数据开展实验。为了获取试验数据的无控定位误差, 考虑珞珈一号影像分辨率仅为 130 m, 我们采用 google 的 15 m 高分辨率影像作为几何基准, 采用全自动匹配的方法将珞珈一号 01 星影像与 google 底图进行匹配获取检查点并计算影像的无控定位误差。

2.2 影响无控定位精度的自变量筛选及数据集确定

试验中搭建的神经网络的输入层是: 成像姿态参数 (三轴向: X_{roll} 是翻滚角, X_{pitch} 是俯仰角、 X_{yaw} 是偏航角)、星下点经纬度 (X_{lat} 为星下点精度、 X_{lon} 为星下点纬度)。珞珈一号 01 星采用双星敏定姿, 因此其成像姿态采用四元数表示, 但四元数不利用模型建立。因此, 实验前, 我们采用四元数与欧拉角的转换公式, 将四元数转换成成像三轴欧拉角。数据集的构建具体如下。

表 2 数据集构建

参数	姿态参数/rad		星下点经纬度/(°)		定位精度/m
	X_{roll}	X_{pitch}	X_{yaw}	X_{lat}	X_{lon}
Y					

在数据集预处理过程中, 我们对变量 X_n ($n = roll, pitch, \dots, lon$) 和 Y 进行了相关性分析, 其中 X_{yaw} 与 Y 的相关性为 0.000 1, 按照统计学的观点, 该参数对定位精度的影响可忽略不计。实际上, 由于偏航角误差引起的像点偏移表现为像面旋转, 其与卫星飞行高度无关, 对无控定位精度的影响最小, 故在实验进程中, 我们将该数据做了删除处理。

在模型构建阶段, 数据集划分比例对模型精度产生了一定的影响, 在比例为 0.6: 0.4, 0.65: 0.35, 0.7: 0.3, 0.75: 0.25, 0.8: 0.2, 0.85: 0.15 下, 模型的精度在 0.08 ~ 0.3 中波动, 其中在 0.75: 0.25 的比例下, 模型得到的预测精度最高, 故将所有数据集按照此比例进行划分。划分采用 Tensorflow 框架提供的 train_test_split 函数实现。

2.3 智能建模精度验证

文中基于 DenseNet 结构设计了网络模型, 具体各层参数图 2 所示。

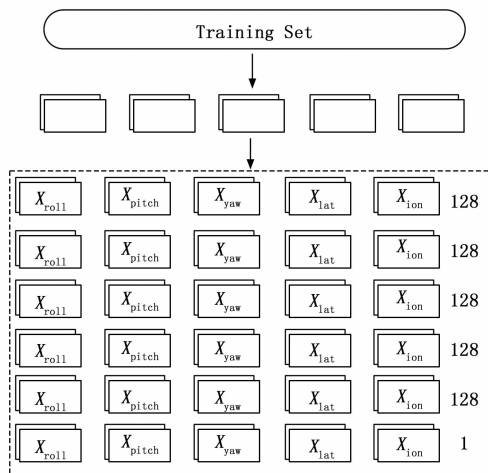


图 2 光学卫星无控定位误差智能模型

通过对网络模型的不断调试, 最终选择采用包含 6 层的网络模型, 其中 1~5 层的神经元个数为 128 个, 最终输出层神经元个数为 1。实验中, 各隐藏层的损失函数如表 3 所示。

表 3 模型各层损失函数

1	2	3	4	5
0.734 0	0.353 6	0.094 2	-0.347 6	-0.846 5

由表 3 可知, 最终模型整体评分为 0.846 5, 通过对数据集的进一步清理筛选, 可以逐步提高模型的稳定性和预测精度。

选取了珞珈一号 01 星 10 019 景数据进行实验, 数据数量达到 3 T, 训练集包含参数 7 514 景数据。模型训练结果如表 4 所示。

如表 4 所示, 由于珞珈一号 01 星作为微纳卫星, 平台小、搭载的星敏等硬件测量精度较低, 其无控定位误差变化较大, 试验数据定位误差范围处于 41~1 432 m 之间, 该部分误差主要由于姿态低频误差、姿态测量随机误差等造成。但是, 由于引起姿态低频误差、测量随机误差的因素众多, 难以建立较为准确的规律模型并通过传统方法求解模型参数, 因此较难进行补偿。而文中利用深度学习框架, 通过搭建深度学习网络对无控定位误差与星下点经纬度、成像姿态的关系进行训练。利用试验数据中的 7 514 景影像进行无控定位误差的智能建模, 训练得到的模型可以非常

表 4 基于珞珈一号真实数据影像定位精度预测结果, Y_{pred} 为预测结果

X_{roll}	X_{pitch}	X_{yaw}	X_{lat}	X_{lon}	Y	Y_{pred}
10.429 26	0.729 463	-1.185 12	34.065 1	-115.562	309	390.089 3
-16.864 839	-0.850 897	-1.23059	27.573 3	75.344 1	619	610.724
10.437 537	0.725 03	-1.179 27	33.943 6	-115.529	798	792.631 9
-0.877 449	1.113 25	-1.238 21	43.446 4	29.094 8	1432	1425.052 3
-15.000 407	-0.690 081	-1.471 18	28.474 9	113.122	592	585.300 6
7.966 382	0.518 732	-1.549 33	45.388 5	34.9424	776	760.453 2
0.487 94	0.155 157	-2.324 9	49.985 3	124.807	840	835.392 6
-14.781 373	-0.139 197	-0.808 25	36.155	117.595	404	399.381 2
18.024 89	1.011 732	0.261 914	35.071	130.382	222	212.479
-12.931 398	-0.631 942	-0.310 8	47.857	-1.720 85	473	466.470 6
9.037 477	0.414 941	-0.091 18	43.670 6	42.633	461	455.323 8
-0.015 842	0.003 365	-0.195 38	41.224 2	19.041 1	219	212.440 2
0.047 013	-0.000 92	-0.494 33	46.950 8	17.063 8	219	222.889 2
15.025 702	0.765 262	0.059 239	40.005 2	7.508 66	269	258.705 5
14.968 153	0.775 816	-0.138 73	44.292 2	6.104 54	269	253.795 4
14.997 673	0.561 658	-0.560 36	52.396 7	2.905 46	269	232.789 6
7.504 619	0.614 653	-1.479 63	37.172 6	-74.453 2	286	279.080 9
33.363 471	-60.391 219	56.022 46	33.169 8	30.787 6	212	206.912 8
0.369 048	0.289 798	-1.811 81	40.883 2	-122.634	340	330.150 7
-1.529 766	0.069 815	-1.635 12	29.025 4	114.451	695	589.109 3
20.393 143	1.399 065	-1.311 29	34.988 8	76.571 1	267	259.787 9
0.483 728	0.252 701	-1.826 28	45.914 4	140.358	79	80.988 5
0.552 699	0.193 361	-2.012 41	46.910 5	-79.5785	388	385.210 9
0.458 6	0.278 078	-1.284 67	-33.818 8	147.652	290	287.896 1
12.510 803	0.979 729	-1.793 75	26.385 4	109.749	452	448.510 803
-7.505 738	-0.195 279	-1.632 49	28.831 6	85.937 4	237	228.505 738
1.5439 28	0.325 679	-1.438 91	5.281 31	103.733	373	367.543 928
-16.528 533	-0.739 147	-1.408 89	28.871 2	-84.252 8	321	319.528 533
0.508 946	0.248 634	-1.977 77	49.480 3	0.938 676	41	43.508 946
0.510 666	0.250 096	-1.739	30.816 7	98.522 1	421	418.510 666
2.352 027	0.446 929	-1.907 73	32.816 4	116.441	390	380.352 027
-11.559 243	-0.537 757	-1.150 07	-3.105 77	118.58	170	167.559 243
0.467 388	0.222 369	-1.598 26	31.057 3	86.559 4	181	173.467 388

准确地预测其余 2 505 景影像地无控定位误差。表中结果表明,训练网络预测的无控定位误差与真实评估得到的无控定位误差仅仅相差 10 m 以内,即训练网络可以根据影像成像地星下点经纬度和姿态来准确预测无控定位误差,从而实现定位误差补偿,提升定位精度,如图 3 所示。

3 结束语

无控定位精度是影响光学卫星影像应用的重要




图 3 训练网络预测值与真实值偏差

因素。文中从地面处理的角度出发,将卷积神经网络

络引入定位误差建模, 选取卫星成像星下点位置、成像姿态等作为可选变量, 利用系统全自动质检获取的无控定位误差与可选变量组成学习样本对, 基于深度学习框架, 通过 DenseNet 网络和 MDGB 优化模型构建了无控定位误差模型。利用珞珈一号真实在轨数据开展试验, 试验结果表明, 通过对模型进行训练以及验证, 模型得到了较高的预测精度, 并可根据该模型进行影像定位精度预测, 模型预测精度小于 1 个像素。

参考文献:

- [1] 李国元, 胡 芬, 张重阳, 等. WorldView-3 卫星成像模式介绍及数据质量初步评价 [J]. 测绘通报, 2015 (s2): 11-16.
- [2] GRESLOU D, DE LUSSY F, DELVIT J M, et al. Pleiades-Hr innovative techniques for geometric image quality commissioning [J]. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, XXXIX - B1 (1): 51-56.
- [3] BOUILLON A, BRETON E, LUSSY F D, et al. SPOT5 geometric image quality [C] //IEEE International Geoscience & Remote Sensing Symposium, IEEE, 2003.
- [4] DIAL G, GRODECKI J. Ikonos accuracy without ground control [C] //Proc. of ISPRS Commission I, Mid-Term Symposium, 2012: 10-15.
- [5] FRASER C S, RAVANBAKHS M. Georeferencing performance of geoeye-1 [J]. Photogrammetric Engineering & Remote Sensing, 2009, 75 (6): 634-638.
- [6] 李德仁. 我国第一颗民用三线阵立体测图卫星—资源三号测绘卫星 [J]. 测绘学报, 2012, 41 (3): 317-322.
- [7] 唐新明, 张 过, 祝小勇, 等. 资源三号测绘卫星三线阵成像几何模型构建与精度初步验证 [J]. 测绘学报, 2012, 41 (2): 191-198.
- [8] 蒋永华, 张 过, 唐新明, 等. 资源三号测绘卫星三线阵影像高精度几何检校 [J]. 测绘学报, 2013, 42 (4): 523-553.
- [9] 余成武, 隋 杰, 陈 超, 等. 高分七号卫星多探头甚高精度星敏传感器热设计与验证 [J]. 航天器工程, 2020, 29 (3): 144-150.
- [10] 熊 凯, 汤 亮, 刘一武, 等. 基于地标信息的星敏传感器低频误差标定方法 [J]. 空间控制技术与应用, 2012, 38 (3): 11-15.
- [11] LAI Y, GU D, LIU J, et al. Low-frequency error extraction and compensation for attitude measurements from STECE star tracker [J]. Sensors, 2016, 16 (10): 1-6.
- [12] LAI Y, LIU J, DING Y, et al. In-flight quality evaluation of attitude measurements from STECE APS-01 star tracker [J]. ACTA Astronautica, 2014, 102: 207-216.
- [13] 王艳丽, 王 密. 顾及太阳高度角变化的海洋 1C 卫星姿态低频误差建模与补偿方法 [C] //第六届高分辨率对地观测学术年会论文集 (上). 成都, 2019: 19.
- [14] 张 过, 管志超. 卫星成像质量可靠性研究初探 [J]. 武汉大学学报 (信息科学版), 2018, 43 (12): 1954-1961.
- [15] TOUTIN T, et al. Geometric processing of remote sensing images: models, algorithms and methods [J]. International Journal of Remote Sensing, 2004, 25 (10): 1893-1924.
- [16] POLI D. Review of developments in geometric modeling for high resolution satellite pushbroom sensors [J]. The Photogrammetric Record, 2012, 137 (27): 58-73.
- [17] 徐德荣, 陈秀宏, 田 进. 稀疏自编码和 Softmax 回归的快速高效特征学习 [J]. 传感器与微系统, 2017, 36 (5): 55-58.
- [18] 杨 冰, 徐 丹, 张豪远, 等. 基于改进的 DenseNet-BC 对少数民族服饰的识别 [J]. 浙江大学学报 (理学版), 2021, 48 (6): 676-683.
- [19] 奚 琦, 张正道, 彭 力. 基于改进密集网络与二次回归的小目标检测算法 [J]. 计算机工程, 2021, 47 (4): 241-247.
- [20] ZHANG G, WANG J, JIANG Y, et al. On-orbit geometric calibration and validation of LuoJia 1-01 night-light satellite [J]. Remote Sens, 2019 (11): 1-19.
- [21] 吴仁彪, 赵 婷, 屈景怡. 基于深度 SE-DenseNet 的航班延误预测模型 [J]. 电子与信息学报, 2019, 41 (6): 1510-1517.