

基于机器学习的大视场星敏感器畸变在轨标定技术

刘 源, 谢睿达, 赵 琳, 郝 勇

(哈尔滨工程大学 自动化学院, 黑龙江 哈尔滨 150001)

摘 要: 随着遥感卫星在轨任务复杂性的不断提升, 对卫星定姿精度的要求也不断提高。星敏感器是星上精度最高的姿态敏感器, 因而其在轨标定是提高定姿精度的有效手段。由于大视场星敏感器的镜头畸变复杂, 目前广泛采用的基于星对角距的最小二乘法存在一定局限性。因此提出一种基于机器学习的星敏感器在轨标定算法, 该方法结合机器学习预测建模思想, 通过构造特征建立镜头畸变模型, 并结合主成分分析方法进行冗余特征的消除, 最后从星角距和模型泛化能力两方面对标定效果进行评价。仿真结果表明: 算法对镜头畸变程度较大的星敏感器有良好的校正效果, 标定精度始终能保持在 $0.8''$ 内, 与目前几种主流算法相比, 具有精度高, 鲁棒性好等优点。

关键词: 标定; 星敏感器; 光学系统; 畸变; 机器学习; 主成分分析

中图分类号: V241.62⁺³ **文献标志码:** A **文章编号:** 10.3788/IRLA201645.1217004

Machine learning based on-orbit distortion calibration technique for large field-of-view star tracker

Liu Yuan, Xie Ruida, Zhao Lin, Hao Yong

(College of Automation, Harbin Engineering University, Harbin 150001, China)

Abstract: As on-orbit missions of satellites are increasingly complicated, the demand for satellites' attitude determination accuracy is becoming higher. Star sensor is the most accurate attitude sensor on the satellite, so calibration of the star sensor is critical to further improvements of satellites' attitude determination. However, conventional on-orbit method which take advantage of inter-star cosine angle to solve the calibration problem of large field-of-view (FOV) star sensor was not sufficient due to the complexity of lens distortions. Motivated by this observation, a novel technique for the large FOV star sensor's calibration based on machine learning theory was presented. The technique used the created features to build complex distortion models. These created features were redundant, so Principal Components Analysis (PCA) was employed to reduce the useless features. Moreover, two methods were employed to judge the efficiency and the effectiveness of the calibration algorithms. The results show that machine-learning based on-orbit calibration method can achieve remarkable improvement when the distortion of the large FOV star sensor is relatively huge. The calibration error is less than $0.8''$ under the working condition in the paper. Compared with current algorithms, this algorithm can achieve a higher accuracy and is more robust.

Key words: calibration; star sensor; optical system; distortion; machine learning; principal components analysis

收稿日期: 2016-04-05; 修订日期: 2016-05-15

基金项目: 黑龙江省博士后科研启动金(LBH-Q14054); 中央高校基本科研业务费专项资金(HEUCFD1503)

作者简介: 刘源(1984-), 男, 讲师, 博士, 主要从事飞行器总体设计方面的研究。Email: undertwilight@foxmail.com

通讯作者: 谢睿达(1991-), 男, 硕士, 主要从事卫星姿态确定系统智能算法方面的研究。Email: xieruida_paper@163.com

算如公式(3)所示:

$$\begin{cases} \delta_{ur} = u_s (k_1 r_s^2 + k_2 r_s^4) \\ \delta_{vr} = v_s (k_1 r_s^2 + k_2 r_s^4) \end{cases} \quad (3)$$

式中: $r_s^2 = u_s^2 + v_s^2$, u_s 、 v_s 为存在主点偏移的星点坐标; k_1 、 k_2 为径向畸变系数。

1.2 主流星敏感器标定方法

取星光矢量夹角的方向余弦, 对于恒星单位矢量的测量与对应的星历表中的惯性参考矢量有如下联系:

$$\cos \theta_{ij} = \vec{W}_{i1}^T \vec{W}_{j1} = \vec{W}_{si}^T \vec{W}_{sj} \quad (4)$$

图 2 所示为测量星对角距与惯性系下星对角距示意图, 测量星角距与星表中的星角距不相等, 星敏感器光学误差就包含在星角距残差中。通过计算多个星矢, 利用最小二乘法和卡尔曼滤波法进行计算误差参数。




图 2 测量星对角距与惯性系下星对角距示意图

Fig.2 Measured inter-star cosine angle and the inter-star cosine angles between the corresponding cataloged stars

传统方法应用在大视场星敏感器的标定问题中存在以下局限性: 首先, 在轨运行的星敏感器受温度、重力、引力变化影响, 用固定的数学模型无法准确地描述各个误差; 其次, 各个误差互相耦合, 当考虑的误差项增多时, 难以将各类误差准确分离, 因此当进行补偿时, 有可能误将其他误差补偿至影响因素较大的参数项中, 导致补偿结果不可靠。

2 基于机器学习的大视场星敏感器在轨标定算法

2.1 星敏感器误差分析

目前, 星敏感器标定中, 对星敏感器的误差分析较为简单, 以下, 借助相机标定领域的一些经验^[9], 对星敏感器误差进行建模分析。

理想星光成像点经历以下映射变换到 CCD 平面的实际星点:

$$\begin{aligned} u_i &\Rightarrow u_s \Rightarrow u_d \\ v_i &\Rightarrow v_s \Rightarrow v_d \end{aligned}$$

式中: u_i 为理想星点坐标; u_s 为镜头光轴偏移后的星点坐标; u_d 为偏移后的星点坐标因镜头畸变产生的偏移; v 坐标与此类似。因此, 星敏感器总偏差可由以下等式表示:

$$\begin{cases} u_d = u_s + \delta_u(u_s, v_s) = u_i + u_0 + \delta_u(u_s, v_s) \\ v_d = v_s + \delta_v(u_s, v_s) = v_i + v_0 + \delta_v(u_s, v_s) \end{cases} \quad (5)$$

式中: u_i 、 v_i 为理想星点坐标; u_0 、 v_0 为星点在轴向的偏移; $\delta_u(u_s, v_s)$ 、 $\delta_v(u_s, v_s)$ 为畸变项。对于大视场星敏感器, 镜头畸变不能按照近似噪声项来考虑。

镜头径向畸变可由以下等式表示:

$$\begin{cases} \delta_{ur}(u_s, v_s) = u_s (k_1 \cdot r_s^2 + k_2 \cdot r_s^4 + \dots) \\ \delta_{vr}(u_s, v_s) = v_s (k_1 \cdot r_s^2 + k_2 \cdot r_s^4 + \dots) \end{cases} \quad (6)$$

式中: k_1 、 k_2 、 k_3 为径向畸变系数; r_s 为偏移后的星点距离理想像平面坐标原点的距离, 即其距离主轴的距离。在实际应用中, 往往只考虑前两项, 文中为精确建模, 将级数取至 4 阶。

镜头偏心畸变是由于光学系统的多个镜头不完全共线导致的, 其也可以分为径向分量和切向分量, 可由以下方程表示:

$$\begin{cases} \delta_{ud}(u_s, v_s) = p_1 (3u_s^2 + v_s^2) + 2p_2 \cdot u_s \cdot v_s \\ \delta_{vd}(u_s, v_s) = p_2 (3v_s^2 + u_s^2) + 2p_1 \cdot u_s \cdot v_s \end{cases} \quad (7)$$

式中: p_1 、 p_2 为偏心畸变系数。

薄棱镜畸变主要由光学镜头制造误差和成像敏感器阵列制造误差引起的图像畸变, 也可按照径向分量和切向分量组成, 可有以下等式表示:

$$\begin{cases} \delta_{uip}(u_s, v_s) = s_1 (u_s^2 + v_s^2) \\ \delta_{vip}(u_s, v_s) = s_2 (u_s^2 + v_s^2) \end{cases} \quad (8)$$

式中: s_1 、 s_2 为薄棱镜畸变系数。

因此, 星敏感器光学系统的总畸变量可由以上畸变线性叠加, 表示为:

$$\begin{cases} \delta_u(u_s, v_s) = \delta_{ur}(u_s, v_s) + \delta_{ud}(u_s, v_s) + \delta_{uip}(u_s, v_s) \\ \delta_v(u_s, v_s) = \delta_{vr}(u_s, v_s) + \delta_{vd}(u_s, v_s) + \delta_{vip}(u_s, v_s) \end{cases} \quad (9)$$


经整理, 上述方程可表述为:

$$\begin{cases} u_d = u_i + u_0 + \sum_{i=1}^n u_s \cdot k_i \cdot (u_s^2 + v_s^2)^i + q_1 (u_s^2 + v_s^2) + 2 \cdot u_s (p_1 \cdot u_s + p_2 \cdot v_s) \\ v_d = v_i + v_0 + \sum_{i=1}^n v_s \cdot k_i \cdot (u_s^2 + v_s^2)^i + q_2 (u_s^2 + v_s^2) + 2 \cdot v_s (p_1 \cdot u_s + p_2 \cdot v_s) \end{cases} \quad (10)$$


式中： $q_i = s_i + p_i, i=1,2$ 。

在实际中,径向畸变、切向畸变、薄棱镜畸变往往是相互耦合的。一些学者提出了很多算法,试图通过参数估计来补偿这些误差。然而,不仅畸变之间是不相互独立的,星点偏移和畸变之间也相互影响,某一参数估计的不准确将导致拟合精度的整体下降。


图 3 所示为星敏传感器像平面径向畸变、薄棱镜畸变以及偏心畸变和薄棱镜畸变综合引起的畸变




(a) 星敏传感器像平面阶径向畸变分布
(a) First order radial distortion distribution of star trackers imaging plane



(b) 星敏传感器像平面偏心畸变分布
(b) Decentering distortion distribution of star trackers imaging plane



(c) 星敏传感器想平面薄棱镜畸变分布
(c) Thin prism distortion distribution of star trackers imaging plane



(d) 星敏传感器像平面畸变误差综合分布
(d) Total distortion distribution of star trackers imaging plane

图 3 大视场星敏传感器畸变误差分布

Fig.3 Error distribution of the large FOV star sensor

误差分布图。图中,径向畸变分布是以光轴所在坐标为中心,圆环状分布。偏心畸变分布则根据畸变系数不同菱形分布,星敏传感器薄棱镜畸变实际上与径向畸变类似,因此容易与径向畸变耦合。当考虑各种畸变时,误差分布如图 3(d)所示,由于像平面的偏移,像平面边缘的畸变量是不同的,其中主点偏移方向的畸变量较大。对于一般的标定算法,采用过多的或过少的畸变参数会导致估计的不准确。

除畸变之外,星敏传感器焦距也是主要误差源之一,如图 4 所示为焦距误差,焦距值对星敏传感器精度的影响。

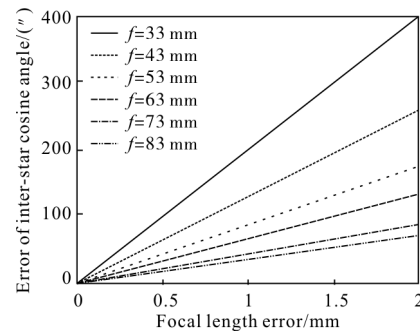


图 4 焦距误差对星敏传感器精度影响

Fig.4 Impact of star sensors' focal length error

设定星敏传感器焦距为 33~83 mm,误差量一般在 2%以内,即 $|\Delta f| \leq 0.02f$,焦距误差对星敏传感器精度的

影响以星对角距统计偏差评价,如图所示焦距越小,单位焦距误差(0.1 mm)对星传感器精度影响越大,反之,大焦距条件下,星传感器精度对焦距误差的敏感程度则会变低。

2.2 理论星点的获取

当在轨姿态确定精度有限或由于其他原因不能够获取理想的星点位置时,可通过地面事后处理的高精度数据对理想星点在星传感器像平面上的位置进行估计^[12-15]。

由前文所述,星传感器理想模型可由小孔成像模型来表示。某一导航星在惯性系下的星光矢量到星传感器系下的坐标可由一系列矩阵映射组成,可由以下方程表示:

$$W_s = C_{si} W_I \quad (11)$$

式中: C_{si} 为星传感器测量坐标系向惯性坐标系的转移矩阵; W_I 为星光矢量在赤经赤纬惯性坐标系中的方向矢量; W_s 为星光矢量在测量坐标系中的单位矢量。

通过星图识别、星表获得惯性系下的星矢 W_I 。由星传感器视轴在测量坐标系中的矢量方向,以及多个矩阵之间的转换关系,得到视轴在惯性坐标系中的矢量表示:

$$C_{si} = A_{sb} A_{bc} A_{oi} \quad (12)$$

式中: A_{sb} 为测量坐标系向卫星本体坐标系的转换矩阵,即星传感器的安装矩阵。

2.3 基于机器学习的星传感器标定方法

将机器学习应用于标定主要分为数据处理、误差模型建立和参数求解三大部分组成。算法流程图如图 5 所示。

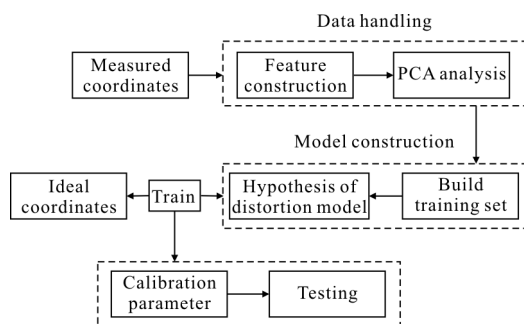


图 5 基于主成分分析的机器学习算法数据流程图

Fig.5 Calibration method based on PCA

数据处理利用星点坐标构建高阶特征以描述复

杂的畸变模型,同时利用主成分分析法(PCA)进行相似特征的筛选以提高效率;误差模型建立即采用线性模型描述误差;参数求解则利用共轭梯度下降方法求解出模型参数。

2.3.1 特征重组

星传感器镜头畸变可以用阶次不定的多项式来拟合,为便于对实际星象点进行校正,此处使用测量星点对理想星点进行拟合:

$$\begin{cases} u_{ideal} = u_{real} + \sum_{j=1}^{k_x} \sum_{i=0}^j \theta_x^{(i+1)} u_{real}^i v_{real}^{j-i} \\ v_{ideal} = v_{real} + \sum_{j=1}^{k_y} \sum_{i=0}^j \theta_y^{(i+1)} u_{real}^i v_{real}^{j-i} \end{cases} \quad (13)$$

式中: (u_{ideal}, v_{ideal}) 为理想星点坐标; (u_{deal}, v_{deal}) 为测量星点坐标; $\theta_x^{(i)}, \theta_y^{(i)}$ 为拟合参数; $\{u_{real}^p v_{real}^q\}$ 为重组的特征集合,可表示为 $\{u^p v^q\} = \{u, v, u^2, v^2, uv, \dots, u^p v^q\}$,这些重组的特征必定存在冗余,冗余特征项的系数较小。因而必须有相应的筛选机制,选择有效特征表达星传感器校正模型。选择 60%的数据作为训练集,20%的数据作为交叉验证集,20%的数据作为测试集。

2.3.2 重组特征缩放

由于重组后的特征存在高阶项,不同特征数量级差距较大,对算法收敛性造成极大影响,因而需要进行特征缩放,有如下替换方程:

$$\text{令 } X_{m \times n} = \begin{bmatrix} X_1^{(1)} & X_2^{(1)} & \dots & X_n^{(1)} \\ X_1^{(2)} & \ddots & & \vdots \\ \vdots & & \ddots & X_n^{(m-1)} \\ X_1^{(m)} & \dots & X_{n-1}^{(m)} & X_n^{(m)} \end{bmatrix}, \text{ 其中 } X^{(i)} \text{ 代表第 } i \text{ 个样}$$

本的所有特征, X_j 代表所有样本的第 j 个特征,则:

$$X_j^{(i)} = \frac{(X_j^{(i)} - \text{mean}(\{X_j\}))}{\text{std}(\{X_j\})} \quad (14)$$

2.3.3 建立弹性网模型

$\{X\}$ 为重组后的特征值,其中包含高阶项,经过 PCA 处理后,线性化为以下猜想模型:

$$\begin{cases} h_\theta(u) = \theta_u^{(0)} + \theta_u^{(1)} X_1 + \dots + \theta_u^{(n_u)} X_{n_u} \\ h_\theta(v) = \theta_v^{(0)} + \theta_v^{(1)} X_1 + \dots + \theta_v^{(n_v)} X_{n_v} \end{cases} \quad (15)$$

为防止过度拟合,考虑正则化项和,两个方向的校正,则建立联合代价函数:

$$\begin{cases} J(\Theta)_u = \frac{1}{2m} \sum_{i=1}^m (h_\theta(X^{(i)}) - u_{ideal}^{(i)})^2 + \frac{\lambda_{u1}}{2r} \sum_{j=1}^r (\theta_u^{(j)})^2 + \frac{\lambda_{u2}}{2r} \sum_{j=1}^r |\theta_u^{(j)}| \\ J(\Theta)_v = \frac{1}{2m} \sum_{i=1}^m (h_\theta(X^{(i)}) - v_{ideal}^{(i)})^2 + \frac{\lambda_{v1}}{2s} \sum_{j=1}^s (\theta_v^{(j)})^2 + \frac{\lambda_{v2}}{2s} \sum_{j=1}^s |\theta_v^{(j)}| \end{cases} \quad (16)$$

式中： m 为训练集数量。

2.3.4 特征选取策略

特征选取策略考虑两种方法，一种是基于学习曲线的特征选取策略，即提高拟合多项式阶数，用交叉验证集绘制学习曲线、训练曲线，选取学习曲线代价最小值点所对应的拟合参数，同时绘制训练曲线还可获得训练参数是否过拟合等信息。然而该方法训练量巨大，尤其是当扩展到高阶多项式时，特征数量众多，矩阵维数高，因此采用主成分分析法。

主成分分析法是一种降维的统计方法，它借助于一个正交变换，将其分量相关的原随机向量转化成其分量不相关的新随机向量，将高维矩阵以一个较高的精度转换成低维变量系统。但主成分分析法所构造的特征理解性差。对于星敏标定来说，星敏感器标定采用的扩展特征本身不具备可理解性，且各特征之间高度冗余，因此适合结合 PCA 进行计算。

协方差阵可由如下公式表示：

$$\Sigma = \frac{1}{m} \sum_{i=1}^m (X^{(i)}) \cdot (X^{(i)})^T \quad (17)$$

对矩阵进行奇异值分解：

$$\Sigma = U \cdot S \cdot V^* \quad (18)$$

则取 U 阵中的 k 列：

$$U^{(n)} \Rightarrow U^{(k)}, Y^{(i)} = (U_{n \times k}^{(k)})^T \cdot X_{n \times 1}^{(i)} \quad (19)$$

由此得到的 $Y^{(i)}$ 即为经过 PCA 映射得到的“主成分”。

想要得到有效的映射，需确定 k 值。从信息论的角度来看， k 越大，系统熵越大，认为样本保留了大部分的差异性，所获得的映射不会导致数据失真。反之， k 较小时，则降维后的特征不能很好的描述数据。

k 值选取标准如下所示：

$$P(k) = 1 - \frac{P_1}{P_2} = 1 - \frac{\frac{1}{m} \sum_{i=1}^k \left\| X^{(i)} - X_{approx}^{(i)} \right\|^2}{\frac{1}{m} \sum_{i=1}^m \left\| X^{(i)} \right\|^2} \geq q \quad (20)$$

$$\text{Delta} = \frac{1}{\sqrt{m}} \cdot \sqrt{\frac{2}{m(m+1)} \sum_{i=1}^{m-1} \left[\sum_{j=i+1}^m (\arccos \langle \vec{W}_{Ti}, \vec{W}_{Tj} \rangle - \arccos \langle \vec{W}_{Si}, \vec{W}_{Sj} \rangle)^2 \right]} \quad (22)$$

式中： $X_{approx}^{(i)} = U_{reduce} \cdot Y^{(i)}$ ，为重构数据集； P_1 为平均平方映射误差； P_2 为数据的总变差； $q = 85\%, 90\%, 95\%, 99\%, \dots$

P 在实际求解时，利用 S 阵中的奇异值（奇异值由大到小排列），计算如公式(21)所示：

$$P(k) = \frac{\sum_{i=1}^k S(i,i)}{\sum_{i=1}^m S(i,i)} \geq q \quad (21)$$

如图 6 所示为 PCA 算法中 q 值(x 轴)与计算时间(z 轴)、机器学习效果(y 轴)之间的关系，显而易见， q 值越大，计算效果越好，然而当 $q \geq 99\%$ 时，计算时间明显增大，同时学习效果并没有因此而增强，反而略有降低，因此另为 $q \in \{0.95 \leq q \leq 0.99\}$ 最佳。

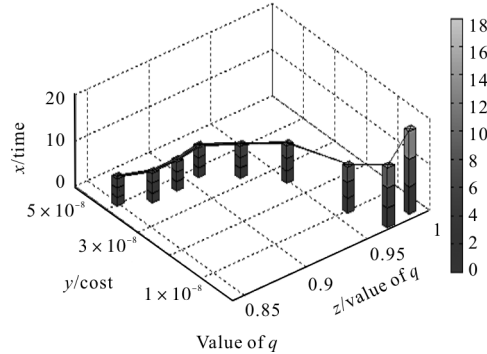


图 6 计算误差、 q 值选择与计算时间的关系

Fig.6 Relationship between computational error, the value of q and runtime of the algorithm

2.3.5 标定结果评价标准

为了对校正效果进行有效描述，文中从星对角距误差统计结果和机器学习角度进行评价。星对角距统计偏差统计评价标准计算了数据集中任意两星在惯性系下的星角距与校正后的像平面上的两星星角距之间偏差的平方和，其表达式如公式(22)所示：

式中： m 星点个数；Deta 单位为（"）。

(1) 传统评价标准

传统方法中采用星对角距的残差进行统计。

(2) 机器学习评价标准

从机器学习角度评价，采用对测试集拟合的计算代价进行评价，表现机器学习算法或经典算法的泛化能力：

$$\begin{cases} J_{test}(\Theta)_u = \frac{1}{2m_{test}} \sum_{i=1}^{m_{test}} \left(h_{\theta} \left(X_{test}^{(i)} \right) - u_{ideal}^{(i)} \right)^2 \\ J_{test}(\Theta)_v = \frac{1}{2m_{test}} \sum_{j=1}^{m_{test}} \left(h_{\theta} \left(X_{test}^{(j)} \right) - v_{ideal}^{(j)} \right)^2 \end{cases} \quad (23)$$

一般来说，泛化能力越好，校正模型精度越高，但由于星对角距残差统计结果受到星点分布影响，因此二者关系并不绝对。

3 仿真分析

文中对三种算法进行了仿真对比，分别为 Samaan 的标定算法，谢俊峰的算法以及文中提出的基于机器学习的标定算法。基于星角距不变的算法，所需星点数量最低只要大于待求解参数数量即可，但因其采用最小二乘法，因而星点数量多，标定效果越好。基于机器学习理论的算法则是基于数据的算法，对模型的依赖度较低，对星点数没有具体的需求，但随着星图样本数量的增多，标定效果会逐渐增强。

星传感器参数如表 1 所示。文中共搭建了以下三种成像模型，Model1 为简单成像模型，符合小孔成像规律，不存在畸变，只考虑星点偏移等线性误差，Model2 只考虑了镜头径向畸变带来的影响，较为接近实际星传感器模型。Model3 则为考虑多种畸

表 1 大视场星敏传感器参数

Tab.1 Parameters of large FOV star sensor

Parameter	Value
Pixel resolution	1 024×1 024
Pixel size/μm	15×15
Image center/pixel	(512,512)
Focal length/mm	43.3000
FOV / (°)	25×25
Sensitivity of star magnitude/Mv	6
PSF/pixel	1

变耦合的大视场星敏传感器模型。相关模型参数如表 2 所示，其中 x_{rand}, y_{rand} 表示星敏传感器电路或图像探测器芯片引入的电路噪声造成的星点位置的随机偏差， k 为径向畸变，下角标表示畸变阶数。

表 3 为基于星对角距不变原理的最小二乘法参数标定结果，下角标 m 表示标校值；表 4 为该方法的标定效果。表 5 为基于机器学习的星敏传感器标定算法结果。仿真环境参数：Intel i3 CPU, 3.4 GHz, RAM: 4 GB, 软件：Matlab2012a。

表 2 不同畸变程度的星敏传感器模型

Tab.2 Different distortion star sensor models

Model1	Model2	Model3
	$u_0=0.5 \text{ mm}$	$u_0=0.5 \text{ mm}$
	$v_0=-0.6 \text{ mm}$	$v_0=-0.6 \text{ mm}$
$u_0=0.5 \text{ mm}$	$f_0=0.2 \text{ mm}$	$f_0=0.2 \text{ mm}$
$v_0=-0.6 \text{ mm}$	$k_1=1 \times 10^{-6}$	$k_2=1 \times 10^{-10}$
$f_0=0.2 \text{ mm}$	$k_2=1 \times 10^{-10}$	$k_4=1 \times 10^{-18}$
$x_{rand}=0.3 \text{ pixel}$	$k_3=1 \times 10^{-14}$	$p_2=-3 \times 10^{-4}$
$y_{rand}=0.3 \text{ pixel}$	$x_{rand}=0.3 \text{ pixel}$	$q_2=-3 \times 10^{-4}$
	$y_{rand}=0.3 \text{ pixel}$	$x_{rand}=0.3 \text{ pixel}$
		$y_{rand}=0.3 \text{ pixel}$

表 3 中，使用 Samman 算法对 Model1 进行标定

表 3 基于成像模型分析的常规方法的标定参数

Tab.3 Calibrated parameters of conventional methods based on imaging model analysis

	Samaan's method			Junfeng Xie's method		
	Model1	Model2	Model3	Model1	Model2	Model3
u_m	0.491 9	0.349 4	2.207 1	0.471 0	0.489 5	1.394 0
v_m	-0.612 6	-0.681 4	-0.894 7	-0.552 5	-0.581 8	-0.574 8
f_m	43.307	43.313	43.205 4	43.304	43.296	42.876 8
k_1	-	-	-	1.30×10^{-06}	-9.47×10^{-07}	-3.14×10^{-04}
k_2	-	-	-	-6.09×10^{-08}	-6.67×10^{-11}	2.67×10^{-06}
$ (u_m - u_0) / u_0 $	1.62 %	30.12 %	341.42 %	5.80 %	2.10 %	178.81 %
$ (v_m - v_0) / v_0 $	2.10 %	13.57 %	49.12 %	7.92 %	3.03 %	4.19 %
$ (f_m - f_0) / f_0 $	0.02 %	0.03 %	0.22 %	0.01 %	0.01 %	1.00 %

表 4 基于成像模型分析的星敏器常规方法的标定算法

Tab.4 Star sensor calibration results of conventional methods based on imaging model analysis

	Samaan's method			Junfeng Xie's method		
	Model1	Model2	Model3	Model1	Model2	Model3
Run time	3.2 s	3.2 s	3.2 s	3.1 s	3.2 s	3.1 s
Generalization ability	<i>u</i> direction	4.37×10^{-07}	1.16×10^{-02}	1.49	2.91×10^{-07}	3.62×10^{-08}
	<i>v</i> direction	1.04×10^{-06}	3.49×10^{-08}	4.13×10^{-02}	6.52×10^{-07}	1.15×10^{-07}
Error of inter-star cosine	0.290 5	1.168 7	5.144 5	0.418 7	0.528 5	2.801 8

时,标定精度很高,对星点偏移、焦距估计准确,在相同工况下,谢的模型所计算出的校正参数校正效果略低于 Samaan 算法,但结果都在 0.5"内。随着模型复杂度的升高,将 Samaan 算法应用于 Model2 和 Model3 时显示出局限性,参数估计明显偏差过大,星对角距统计偏差分别达到 1.1687"和 5.1445"。将谢俊峰算法用于 Model2 时,显示出良好的校正效果,校正精度保持在(0.5±0.1)"内,且从 *u*、*v* 方向计算代价可以看出,对于 Model2,谢俊峰算法模型泛化能力较强,但对于大视场星敏器的复杂误差(Model3)进行校正时,其星对角距统计偏差明显增大,光学参数估计偏差较大。由上表可发现,造成误差较大的原因主要为光学参数估计不准确造成的,由 3.1 节所述,误差相互作用,相互影响,因而造成参数估计的不准确,进而影响最终校正结果。

表 5 基于机器学习的星敏器标定算法

Tab.5 Star sensor calibration results of machine learning based algorithm

Index	Model1	Model2	Model3
Order of polynomial	-	60	-
Number of constructed features	-	1 890	-
Numbers of the selected features	<i>u</i> direction	8	17
	<i>v</i> direction	4	21
Run time	6.2 s	8.7 s	10.1s
Generalization ability	<i>u</i> direction	9.34×10^{-07}	8.19×10^{-07}
	<i>v</i> direction	8.26×10^{-07}	8.69×10^{-07}
f_m	43.307	43.297	43.322
$ f_m - f_0 / f_0$	0.02%	0.01%	0.05%
Error of inter-star cosine angle	0.505 6	0.489 8	0.738 7

由以上分析可知,Samaan 算法和谢俊峰算法对于满足其光学模型假设的星敏器校正精度高,但对于误差模型更为复杂的大视场星敏器校正精度低。

表 5 为基于机器学习的星敏器标定结果。结合表 3、4、5,所有算法的标定精度都随着模型复杂程度的上升而下降,但是几种算法表现却各有不同。表 5 为拟合复杂性不断提升的误差模型,构造出的特征阶数最高为 60,特征数量多达 1890 个,但是即使针对最复杂的大视场星敏器模型,经过 PCA 压缩也仅保留 54 个特征数据,在保证精度的同时,极大的减少了计算量。随着模型复杂程度的加深,*u*、*v* 两方向所选取的特征数量也逐渐增多,以构建更复杂的光学误差模型。

由表 5 分析可得,基于机器学习的星敏器标定算法,对不同复杂程度的模型来说,都能始终保持较高的校正精度,由于星点校正精度的提升,在复杂模型下,焦距标定准确性提升明显。从星角距偏差的统计指标来看,在文中所提供的工况中,其精度始终可以保持在以内,但在无畸变或畸变可忽略的情况下,精度略低于 Samaan 算法。从机器学习评价指标来看,*u*、*v* 两个方向的计算代价始终保持在 10^{-7} 量级,因此算法具有良好的泛化能力,对于新的星点有良好的校正效果。针对 Model3,其星角距统计偏差为 0.738 7",因此对于畸变程度较大的大视场星敏器,校正效果明显提升。

从运行时间上看,机器学习算法运行时间明显多于常规算法,这是因为值选择过程中,存在大量重复运算,因此具体到工程上可以采用 FPGA 并行计算来解决,FPGA 并行加速是国内外星上高速计算的一个常规技术手段。

4 结论

通过对目前主流算法以及文中提出的基于机器

学习的标定算法的仿真对比分析,得出在畸变程度较大的工况下,基于 PCA 特征选择的机器学习的大视场星敏感器在轨标定算法可以有效地、高精度的对星敏感器误差进行标定和补偿。该方法的优势在于在不必求取具体模型和光学参数的情况下,对星点进行补偿,因而该方法可避免由于建模不准带来的误差。以星对角距补偿残差作为评价指标,相比较于主流方法,提高了标定精度。从机器学习的视角考察算法,可以认为算法具有不断“学习”的特点—随着星敏感器光学系统参数的缓慢变化,不断获得新数据并不断重组特征,并选择最优参数进行补偿,以提高标定效果;同时算法计算代价小,因而适合长期在轨运行的卫星进行大视场星敏感器标定。

参考文献:

[1] Liebe C C. Star trackers for attitude determination [J]. *IEEE Aerospace and Electronic Systems Magazine*, 1995, 10(6): 10-16.

[2] Cheng Y, Crassidis J L, Markley F L. Attitude estimation for large field-of-view sensors [J]. *The Journal of the Astronautical Sciences*, 2006, 54(3-4): 433-448.

[3] Sun Gaofei, Zhang Guoyu, Zheng Ru, et al. Star sensor calibration research and development [J]. *Journal of Changchun University of Science and Technology*, 2010 (4): 8-14. (in Chinese)
孙高飞, 张国玉, 郑茹, 等. 星敏感器标定方法的研究现状与发展趋势[J]. 长春理工大学学报, 2010 (4): 8-14.

[4] Samaan M A, Griffith T, Singla P, et al. Autonomous on-orbit calibration of star trackers [C]//Core Technologies for Space Systems Conference (Communication and Navigation Session), 2001: 1-8.

[5] Xie J, Tang H, Dou X, et al. On-orbit calibration of domestic APS star tracker [C]//Earth Observation and Remote Sensing Applications, 2014 3rd International Workshop on, 2014: 239-242.

[6] Zhou F, Ye T, Chai X, et al. Novel autonomous on-orbit calibration method for star sensors[J]. *Optics and Lasers in Engineering*, 2015, 67: 135-144.

[7] Pal M, Bhat M S. Autonomous star camera calibration and

spacecraft attitude determination [J]. *Journal of Intelligent & Robotic Systems*, 2014: 1-21.

[8] Pal M, Bhat M S. Star sensor based spacecraft angular rate estimation independent of attitude determination [C]//Control Applications, 2013 IEEE International Conference on, 2013: 580-585.

[9] Prescott B, Mclean G F. Line-based correction of radial lens distortion [J]. *Graphical Models & Image Processing*, 1997, 59(1): 39-47.

[10] Tang Jun, Li Wei, Xu Xuanbin. New method of star sensor's calibration and leading building [J]. *Infrared and Laser Engineering*, 2015, 44(5): 1610-1615. (in Chinese)
唐君, 李伟, 徐轩彬. 一种星敏感器光学系统标定与引建的新方法[J]. 红外与激光工程, 2015, 44(5): 1610-1615.

[11] Guo Yanchi, Xu Xiping, Qiao Yang, et al. Optical system design of star sensor with wide field of view and wide spectra range [J]. *Infrared and Laser Engineering*, 2014, 43 (12): 3969-3972. (in Chinese)
郭彦池, 徐熙平, 乔杨, 等. 大视场宽谱段星敏感器光学系统设计[J]. 红外与激光工程, 2014, 43(12): 3969-3972.

[12] Lian Wenhao, Wang Yongjie, Yang Xialong, et al. Prediction and interference of navigation star [J]. *Optics and Precision Engineering*, 2015, 23(10z): 814-823. (in Chinese)
连文浩, 王永杰, 杨小龙, 等. 导航星光的预测及干扰[J]. 光学精密工程, 2015, 23(10z): 814-823.

[13] Yin Hang, Song Xin, Yan Ye. Performance on sparse representation of star images [J]. *Optics and Precision Engineering*, 2015, 23(2): 573-581.
尹航, 宋新, 闫野. 星图的稀疏表示性能 [J]. 光学精密工程, 2015, 23(2): 573-581.

[14] Zhi Shuai, Zhang Liu, Li Xinlu. Realization of simulated star map with noise[J]. *Chinese Optics*, 2014, 7(4): 581-587. (in Chinese)
支帅, 张刘, 李欣璐. 带噪声模拟仿真星图的实现 [J]. 中国光学, 2014, 7(4): 581-587.

[15] Li Jie, Guo Pan, Wang Chunzhe. Application of shearlet transform in the star extraction[J]. *Chinese Optics*, 2015, 8 (3): 386-393. (in Chinese)
李杰, 郭盼, 王春哲. 剪切波变换在星点提取中的应用[J]. 中国光学, 2015, 8(3): 386-393.