

中图法分类号: V1; TP18 文献标识码: A 文章编号: 1006-8961(2025)09-2975-13

论文引用格式: Liu H Y, Zhang Y, Zhang C Q, Chen G and Yin J H. 2025. Initial orbit determination of high-earth-orbit objects combined with Kolmogorov-Arnold network. Journal of Image and Graphics, 30(9):2975-2987(刘宏宇, 张余, 张超群, 陈果, 尹继豪. 2025. 结合 Kolmogorov-Arnold 网络的高轨目标初轨确定. 中国图象图形学报, 30(9):2975-2987)[DOI:10.11834/jig.250147]

结合 Kolmogorov-Arnold 网络的高轨目标初轨确定

刘宏宇¹, 张余^{1,2*}, 张超群¹, 陈果¹, 尹继豪¹

1. 北京航空航天大学宇航学院, 北京 102206; 2. 天地往返高效运输技术全国重点实验室, 北京 102206

摘要: 目的 作为空间态势感知的关键环节, 高效且准确的初轨确定技术对于轨迹关联、卫星编目和异动感知等下游任务至关重要。传统方法通常依赖精确的动力学模型和充足的观测数据, 但在短弧段条件下, 物理约束不足易导致出现平凡解或方法不收敛的问题。尽管深度学习方法在数据拟合方面表现优异, 但其对轨道动力学内在物理规律的建模能力仍存在不足。针对以上问题, 提出一种基于 KAN(Kolmogorov-Arnold network)的天基光学观测高轨目标短弧初轨确定模型, 该模型兼具强大的物理规律捕捉能力和数学拟合能力, 能够获得稳定且高精度的定轨结果。**方法** 首先, 构建了面向初轨确定任务的专用 KAN 模型架构, 采用“先升维, 后降维”的策略增强物理特征提取能力, 并设计了融合运动状态约束的损失函数, 以针对性优化初轨确定性能。此外建立了一个大规模的天基光学观测短弧段数据集, 该数据集源自真实在轨卫星数据, 每个观测弧段时长 5 min, 包含 6 个观测点, 记录了目标卫星相对于观测卫星的方位角、俯仰角及其变化率。数据集涵盖多样化的目标卫星轨道, 为模型的训练与性能验证提供了可靠的数据支持。**结果** 与传统方法相比, 所提方法预测结果的位置和速度误差分别为 27.458 km 和 3.904 m/s, 仅为传统方法的 0.58% 和 1.14%。与基于多层感知机(multilayer perceptron, MLP)的深度学习方法相比, 所提方法预测结果的位置和速度误差分别为前者的 25.01% 和 19.58%, 显示出更优的性能。**结论** 提出的基于 KAN 的初轨确定模型有效解决了天基光学观测的高轨目标短弧初轨确定问题, 在定轨精度、计算效率和结果稳定性等方面均展现出显著优势, 为空间目标监测提供了新的技术手段。

关键词: 初轨确定; KAN; 短弧段; 天基光学观测; 高轨目标; 深度学习

Initial orbit determination of high-earth-orbit objects combined with Kolmogorov-Arnold network

Liu Hongyu¹, Zhang Yu^{1,2*}, Zhang Chaoqun¹, Chen Guo¹, Yin Jihao¹

1. School of Astronautics, Beihang University, Beijing 102206, China;

2. State Key Laboratory of High-Efficiency Reusable Aerospace Transportation Technology, Beijing 102206, China

Abstract: **Objective** Initial orbit determination (IOD) estimates a spacecraft's orbit by using a limited set of observations, providing rapid trajectory insights and essential initial estimates for subsequent orbit refinement. As a fundamental component of space situational awareness (SSA), an efficient and accurate IOD method is crucial for downstream tasks

收稿日期: 2025-03-31; 修回日期: 2025-05-28; 预印本日期: 2025-06-04

* 通信作者: 张余 uzeful@163.com

基金项目: “新一代人工智能”国家科技重大专项(2022ZD0117402); 国家自然科学基金项目(62132002); 中央高校基本科研业务费专项资金资助(501QYJC2024115010, 502GXXM2024115007)

Supported by: National Science and Technology Major Project (2022ZD0117402); National Natural Science Foundation of China (62132002); Fundamental Research Funds for the Central Universities (501QYJC2024115010, 502GXXM2024115007)

such as track association, satellite cataloging, and anomaly detection. Optical observations are the primary means of acquiring space object data, but they lack direct range measurements, posing a major challenge for IOD. Traditional IOD methods typically rely on iterative range estimation to improve accuracy, leading to high computational costs and a strong dependence on precise dynamical models and sufficient observations. These challenges are exacerbated in short-arc scenarios, where limited physical constraints often result in trivial solutions or convergence failures. For high-earth-orbit objects, orbital dynamics are influenced by multiple perturbation factors, including the earth's non-spherical gravitational field, solar radiation pressure, and lunar gravitational effects, making orbit determination significantly more complex than in low-earth orbit. While deep learning has demonstrated strong nonlinear fitting capabilities, conventional neural networks function as black-box models and struggle to incorporate underlying physical laws governing orbital motion. In contrast, the Kolmogorov-Arnold network (KAN), inspired by the Kolmogorov-Arnold representation theorem, offers an interpretable alternative. Unlike traditional multilayer perceptron (MLP), KAN replaces fixed-weight parameters with learnable univariate functions, parameterized as splines, enabling adaptive activation functions and a more flexible topology. This design preserves strong fitting capabilities while improving interpretability. To overcome the limitations of traditional IOD techniques and conventional deep learning models in short-arc IOD tasks, we propose a novel IOD method of high-earth-orbit objects via short-arc observations using KAN. By leveraging short-arc space-based optical observations, our method integrates deep learning with orbital physics, enhancing accuracy and computational efficiency synergistically. **Method** In this study, we developed a model based on KAN for short-arc IOD tasks of high-earth-orbit objects. The model architecture consists of five interconnected KAN layers, employing a design strategy of dimensionality increase followed by dimensionality reduction. The model processes angular observation data of target objects acquired from space-based observers. Through its hierarchical structure, the network effectively extracts complex nonlinear relationships from the input data while focusing on the most critical features. Ultimately, the model outputs accurate predictions for the position vector and the velocity vector of the target object at the initial moment of the observation arc. Furthermore, we constructed a large-scale dataset of short-arc space-based optical observations for high-earth-orbit objects. This dataset is derived from real on-orbit satellite data provided by CelesTrak, selecting 581 high-orbit active satellites from its database as target objects. We further designed seven satellites to serve as space-based observers. We generated a total of 258 741 observation samples by simulation, which were split into training (70%), validation (15%), and test (15%) sets. Each observation arc spans 300 seconds with a sampling interval of 60 seconds, recording the observation angles and their rates of change of the target satellites relative to the observer. The selected dataset features a diverse range of orbits for the satellites, providing a reliable data foundation for model training and performance evaluation. Using this dataset, we trained our model. To address inconsistencies in parameter units and magnitudes, we first applied data normalization before feeding the data into the model as a preprocessing step. The model employs a composite loss function that incorporates both positional and velocity errors, regulated by a weighting coefficient λ to prevent over-optimization toward either metric. For training, we adopted the Adam optimizer with an initial learning rate of 0.001, supplemented by a dynamic learning rate scheduler; if the validation loss failed to decrease for 100 consecutive epochs, then the learning rate was halved. This approach ensures rapid and stable convergence while improving training efficiency considerably. With a batch size of 512 and training performed on an NVIDIA GeForce RTX 3090 GPU, the entire training process took approximately five hours to complete 2 000 training epochs. **Result** We evaluated our approach by comparing our model with four traditional IOD methods: the Laplace method, the Gauss method, the Double-R method, and the circle-orbit tracking method. The experiment was conducted on the dataset that we constructed. Quantitative evaluation metrics included the average position error (E_p), average velocity error (E_v), and speed evaluation metric arcs per second (APS). Experimental results demonstrate that our method outperforms all other methods across multiple performance dimensions. In terms of accuracy, our model's E_p is 27.458 km, which is only 0.24%, 0.58%, 0.49%, and 0.50% of those achieved by the four traditional IOD methods, respectively. Similarly, our model's E_v is 3.904 m/s, which is only 0.46%, 1.14%, 0.95%, and 0.98% of the E_v values of the corresponding methods. Moreover, with regard to processing speed, our method's APS is 154, 212, 822, and 132 times higher than that of the competing methods, demonstrating crucial advantages in both accuracy and efficiency. In addition, our approach exhibits outstanding stability. It produces no unsolvable cases and generates erroneous solutions at a rate less

than 0.08% of that observed with traditional IOD methods. Furthermore, when compared with the conventional deep learning method MLP, our method achieves E_p and E_e values that are only 25.01% and 19.58% of those of the MLP, respectively, highlighting KAN's superior nonlinear fitting capability over conventional deep learning methods. **Conclusion** In this study, we proposed a KAN-based model for short-arc IOD tasks of high-earth-orbit objects. Experiment results show that our model demonstrates superior accuracy and efficiency compared with several traditional IOD methods while also outperforming conventional deep learning approaches. It exhibits exceptional stability and effectively solves the problem of short-arc initial orbit determination.

Key words: initial orbit determination (IOD); Kolmogorov-Arnold network (KAN); short-arc; space-based optical observations; high-earth-orbit objects; deep learning

0 引言

随着航天技术的飞速发展,人类在太空领域的活动日益频繁,目标数量也呈现持续增长态势,随之而来的则是空间环境的逐步恶化。一方面,大量航天器的发射与运行,造成轨道资源日趋拥挤;另一方面,空间碎片数量不断增长,对正常运行的航天器构成了严重威胁。在此背景下,美、俄、欧等诸多国家和地区都已将大量资源投入到空间态势感知的研究中(王锋等,2024)。基于光学观测数据的初轨确定是空间态势感知的重要研究方向(汪璞等,2023)。该技术通过对光学相机拍摄到的图像中空间目标进行检测,从而计算出目标的相对测角信息。然而,光学观测本身无法直接获取目标到观测器的距离信息,因此需要设计专门的方法以实现目标的初轨确定。早在两百多年前,著名的数学家拉普拉斯和高斯就分别提出经典的 Laplace 法(Vallado, 2001)和 Gauss 法(Bate 等, 2020),这两种方法至今仍被广泛应用于初定轨计算。随后,学者们又陆续提出 Double-R 法(Escobal, 1965)、Gooding 法(Gooding, 1990, 1993, 1996)等多种代表性方法。然而,这些传统方法精度通常较低,且依赖于对距离信息的猜测和反复迭代,有时会因为观测数据的约束性不足而出现无解或得到错误解、平凡解等问题。

近年来,许多研究人员致力于改进传统方法。Der(2012)引入了笛卡儿的解析几何的思想,对 Laplace 法、Gauss 法和 Double-R 法均提出改进,避免了传统方法的距离猜测的问题;Kaushik(2016)则对比了 Gibbs 方法(Gibbs, 1889)和 Herrick-Gibbs 方法(Gibbs, 1889; Herrick, 1971)在传统方法中的应用,并对二者的初轨确定精度进行了全面的统计分析。

此外,也有学者提出新的方法。张晓祥等人(2003)提出的圆轨道跟踪法基于近圆轨道假设,首先假设目标轨道为圆轨道,而后在轨道平面中外推计算,有效规避了空间目标视运动不均匀性的影响;DeMars 等人(2012)结合角度观测值和角度变化率,提出一种基于多假设滤波(multiple hypothesis filter)的算法,以提高对空间目标轨道的估计精度;Lei 等人(2023)则设计了一种改进的距离搜索方法,增加观测组合,动态调整搜索步长,虽然提升了算法的精度,但也带来了计算量的增加。

伴随人工智能的迅猛发展,深度学习技术逐渐广泛应用到各领域实践中。深度学习模型擅长识别数据中的复杂规律,具备强大的数据拟合能力,广泛应用于各个领域(Goodfellow 等, 2016; 章毓晋, 2025)。传统初轨确定方法依赖复杂的物理模型和数学推导,而深度学习技术则可通过分析海量观测数据,快速识别其中的潜在规律和趋势。众多学者已尝试将深度学习技术应用于航天器轨道领域。例如 Gong 等人(2023)构建了一个基于多层感知机(multilayer perceptron, MLP)(Rosenblatt, 1958)的初轨确定模型,利用天基观测平台的观测数据,实现了对地球静止轨道(geostationary orbit, GEO)目标的初轨确定,并取得了较高的精度;Agostinelli 等人(2024)设计的基于 MLP 的初轨确定网络则结合了人工蜂群算法(Karaboga, 2005)搜索最优的轨道参数,有效避免了模型陷入局部最优解。

本研究聚焦高轨目标初轨确定问题,针对其轨道周期长(约 24 h)、观测弧段短(5 min, 不足轨道周期 1%)导致的数据约束不足、传统方法收敛困难等技术瓶颈,采用了深度学习方法进行突破。本文引入了 KAN(Kolmogorov-Arnold network)(Liu 等, 2025)用于空间目标初轨确定。这是一种新型的深

度学习网络架构,该网络将激活函数从网络的节点移动到了连接节点的边(edge)上。与传统的MLP相比,KAN能够在数学拟合、偏微分方程求解等任务中表现出更好的准确性,且具有更强的可解释性。由于观测数据和空间目标的轨道参数之间存在着特定的物理和数学规律,KAN的特性使其成为解决初轨确定问题的理想方案。

具体而言,本文研究的主要贡献包括以下3个方面:1)构建了一个针对高轨目标的大规模天基光学观测短弧段数据集,为高轨目标初轨确定研究提供了重要的基准测试平台;2)创新性地提出基于KAN的高轨目标短弧初轨确定方法,并在构建的数据集上进行了测试;3)通过系统的对比实验验证了所提方法在高轨目标短弧初定轨任务上的优越性。实验结果表明,与传统初轨确定方法相比,基于KAN的定轨方法在稳定性上体现出了极大的优势,且具有更快的推理速度和更高的精度,能够同时兼顾效率与准确率;与MLP相比,KAN能够体现出更强的数学拟合能力,取得比MLP更加优秀的结果。

1 相关工作

1.1 基于天基光学观测的初轨确定

天基光学观测数据特点为观测时间短,且仅有角度观测信息。首先要确定所采用的坐标系。天基观测平台和空间目标的速度矢量及位置矢量均采用一种地心惯性坐标系(earth-centered inertial frame, ECI)进行表示,本文选择J2000坐标系。该坐标系的原点位于地心, XOY 平面即为J2000平赤道面, X 轴指向J2000平春分点, Z 轴沿着地球自转轴指向北方,整个坐标系为右手系(黄城和刘林,2015)。在地惯系下,物体的运动状态可由其位置矢量和速度矢量共同描述,具体为

$$\mathbf{X} = [\mathbf{r}^T, \mathbf{v}^T]^T = [x, y, z, v_x, v_y, v_z]^T \quad (1)$$

式中, $\mathbf{r} = [x, y, z]^T$ 表示物体的位置矢量, $\mathbf{v} = [v_x, v_y, v_z]^T$ 表示物体的速度矢量。

观测坐标系采用VVLH(vehicle velocity local horizontal)坐标系。坐标系的原点位于平台观测器的中心, Z 轴指向地心, X 轴位于轨道平面上,与 Z 轴垂直且指向观测卫星前进的一侧, Y 轴沿着轨道的负法向,可通过右手定则确定。当天基平台轨道为

圆时, X 轴方向与速度方向一致(王国华等,2023; 黄海兵和张进,2014)。图1为所采用的坐标系的示意图。图中左侧为天基平台的观测坐标系(VVLH坐标系),右侧则为采用的地惯系(J2000坐标系)。

在数据构建的过程中,观测值通常以方位角(azimuth angle)和俯仰角(elevation angle)的形式呈现。如图2所示,在观测坐标系中,方位角 φ 为目标的位置矢量在 XoY 平面上的投影与 X 轴的夹角,其正向为从 X 轴向 Y 轴旋转的方向;俯仰角 θ 为目标的位置矢量与 XoY 平面的夹角,方向以 Z 轴的反方向为正。方位角 φ 的取值范围为 $[0^\circ, 360^\circ]$,俯仰角 θ 的取值范围为 $[-90^\circ, 90^\circ]$ 。




图1 VVLH坐标系与J2000坐标系示意图

Fig. 1 Diagram of VVLH frame and J2000 frame




图2 目标卫星相对于天基观测平台的方位角和俯仰角

Fig. 2 The azimuth angle and elevation angle of the target satellite relative to the space-based observer

假设空间目标在观测坐标系下的位置矢量为 $\mathbf{r}_i^o = [x_i^o, y_i^o, z_i^o]^T$,则目标的方位角和俯仰角分别满足

$$\begin{cases} x_i^o = \rho \cos(\theta) \cos(\varphi) \\ y_i^o = \rho \cos(\theta) \sin(\varphi) \\ z_i^o = -\rho \sin(\theta) \end{cases} \quad (2)$$

式中, $\rho = \|\mathbf{r}_i^o\|$ 为目标与平台之间的距离。根据角度的取值范围和等式条件的共同约束下, 给定位置矢量 $\mathbf{r}_i^o$, 可以唯一确定 θ 和 φ 的值; 反之, 若已知 θ, φ 和 ρ , 也可计算得到空间目标在观测坐标系下的坐标。然后通过坐标系的转换, 将 $\mathbf{r}_i^o$ 由观测坐标系转换到地惯系下。二者可通过旋转与平移变换得到, 假设观测坐标系到地惯系之间的旋转变换矩阵为 $\mathbf{T}_{e,o}$, 平台和目标在地惯系下的坐标分别为 $\mathbf{r}_o^e$ 和 $\mathbf{r}_i^e$, 则有

$$\mathbf{r}_i^e = \mathbf{T}_{e,o} \mathbf{r}_i^o + \mathbf{r}_o^e \quad (3)$$

因此, 一旦确定了目标在观测坐标系下的位置 $\mathbf{r}_i^o$, 即可通过坐标系变换得到目标在地惯系下的坐标 $\mathbf{r}_i^e$, 进而推导目标的轨道参数。然而, 距离 ρ 无法通过光学观测直接测得, 所以需要设计专门的初轨确定方法来推导目标的轨道参数。

传统的初轨确定方法 (如 Laplace 法、Gauss 法、Double-R 法等) 往往需要先对数值作出假设, 并反复迭代求解。这不仅导致计算量庞大且结果精度受限, 而且在迭代过程中若方向选择出现偏差, 可能会导致无解或产生错误解。相比之下, 深度学习方法仅在训练阶段需要通过反复迭代从大量数据中学习规律, 而在推理阶段无需进行复杂的迭代计算, 不存在无解的问题。此外, 深度学习方法能够对数据进行批量处理, 显著提高计算效率。

1.2 KAN 相关原理

KAN (Liu 等, 2025) 是一种创新的神经网络模型, 它对传统多层感知机 (MLP) (Rosenblatt, 1958) 的设计进行了革新, 被视为一种全新的替代方案。在此之前, MLP 一直是深度学习领域中最为基础和重要的模型架构之一, 广泛应用于各种复杂的神经网络设计中。MLP 的核心优势之一在于其通用逼近定理 (universal approximation theorem) (Cybenko, 1989; Hornik 等, 1989)。该定理表明, 只要网络的规模足够大, MLP 理论上能够以任意精度逼近任何连续函数, 从而实现复杂的输入输出之间的映射。这一特性使得 MLP 成为解决非线性问题的有力工具, 无论是分类、回归还是更复杂的函数映射任务, MLP 都能胜任。然而, MLP 存在着参数量庞大、参数效率低下且缺乏可解释性的问题, 这些缺点制约了其进

一步发展。

为了克服这些挑战, 研究人员不断探索新的网络架构。KAN 同样采用了全连接结构, 但其设计理念与 MLP 存在显著差异。MLP 在每个神经元节点上使用预定义的激活函数, 其训练参数主要包括线性权重和偏置; 而 KAN 则不再将权重视为单一的实数, 而是用一种可学习的单变量函数进行替代。通过构建多层单变量函数的组合来实现对复杂函数的逼近, KAN 具有更强的数学拟合能力与可解释性。

KAN 的思路来源于 Kolmogorov-Arnold 表示定理 (Kolmogorov, 1957, 2009; Arnold, 1959)。该定理指出, 如果 f 为有界定义域上的多元连续函数, 则 f 可以表示为单变量连续函数与二元加法的有限组合。图 3 以一个二元函数 $f(x_1, x_2)$ 为例, 直观地展示了该定理。由一元函数组成的层称为 KAN 层, 它用于连接相邻的节点层。定理指出, 对于 n 元函数, 只需两层 KAN 层连接在 $n, 2n+1, 1$ 个节点的节点层中, 即可实现对任意函数的拟合。然而在实际应用中, 这种过于简单的网络结构难以实现各种复杂的任务。KAN 拓展了网络的大小与深度, 每层节点数可根据实际问题灵活设计, 从而增强了网络的非线性拟合能力。




图3 Kolmogorov-Arnold 表示定理示意图

Fig. 3 Diagram of the Kolmogorov-Arnold representation theorem

KAN 选用样条插值的方式拟合不同类型的激活函数, 较低的阶数即可实现较好的拟合效果, 从而避免高阶多项式插值方法导致的剧烈振荡问题 (龙格现象 (Runge's phenomenon))。图 4 展示了样条函数 $spline(x)$ 与 B 样条 (B-spline, basic spline) 的示意

图,样条函数被参数化为B样条的线性组合。此外,引入SiLU函数作为基函数 $b(x)$,以起到残差连接的效果。最终的激活函数是基函数和样条函数的加权,相关公式为

$$\phi(x) = w_b b(x) + w_s \text{spline}(x) \quad (4)$$

$$b(x) = \text{SiLU}(x) = \frac{x}{1 + e^{-x}} \quad (5)$$

$$\text{spline}(x) = \sum_i c_i B_i(x) \quad (6)$$

式中,权重值 c_i 、 w_b 和 w_s 都是可训练的参数。通过这种方式将函数参数化,使得KAN成为了一个可学习的网络。




图4 样条函数与B样条示意图

Fig. 4 Diagram of spline function and B-splines

相较于传统的神经网络,KAN在非线性拟合能力和可解释性方面具有显著优势。MLP在节点上使用固定的激活函数,而连接节点的边上仅采用简单的线性权重,这种结构难以灵活适应不同任务的需求。相比之下,KAN将可学习的样条函数置于网络的边上,能够根据问题特性自适应地调整激活函数,从而大幅提升网络的灵活性及非线性拟合能力;此外,KAN的样条函数支持可视化,能够直观展示每个连接的非线性变换过程。同时KAN的结构可以通过剪枝(去除影响较小的激活函数)或符号化(用近似数学表达式替换复杂函数)进一步简化,这使得模型更具可解释性,有助于揭示数据中的潜在规律。

以上特性使KAN在初轨确定领域展现出独特优势。从动力学角度看,轨道作为微分方程的解,其空间构型完全由动力学方程决定。初轨确定本质上是一个逆问题,即通过有限的观测数据反演出系统初始状态,这对动力学模型的非线性表达能力提出严苛要求。KAN凭借其独特的网络结构和强大的

函数逼近能力,可以直接构建从观测数据到轨道参数的端到端映射,避免了传统方法中复杂的摄动力建模过程。由此可见,KAN在初轨确定任务中展现出显著的应用潜力。

2 基于KAN的高轨目标短弧初轨确定

针对高轨目标短弧初轨确定问题,本文提出一种基于KAN的初轨确定方法。该方法以短弧段的天基光学测角数据为输入,预测目标在观测弧段初始时刻的运动状态。模型设计中引入了结合运动状态约束的损失函数,以提升预测精度。

2.1 网络结构

本文模型由输入层、隐藏层和输出层组成,节点间由5层KAN层连接,模型的具体架构如图5所示。输入数据源自天基光学观测的高轨目标短弧段轨迹,每个弧段的时长为300 s,采样间隔为60 s,共6个观测点。每个观测点的数据包含目标的方位角 θ 、俯仰角 φ 、观测角度变化率,以及天基平台在地惯系中的位置矢量 $\mathbf{r}_e^o$ 和速度矢量 $\mathbf{v}_e^o$,共计10个维度。因此,每组输入数据构成一个 6×10 的矩阵,经过展平后转化为包含60个元素的一维向量,作为模型输入层的输入。

图5展示了每层节点的数量。模型采用了“先升维、后降维”的设计策略。在模型的前几层,通过增加节点数逐步提升特征维度,有助于提取更复杂的特征,捕捉数据中更多的细节与内在关系,从而增强特征表达能力。随着网络层数的加深,模型逐渐降低特征的维度。这一过程旨在限制模型的复杂度,有效防止模型的过拟合,进而更好地提升模型的泛化能力。同时,逐步降低特征维度也有助于模型逐步聚焦于最重要的特征,最终得到准确且可靠的输出结果。

模型的输出数据应能够充分表示轨道信息。通常,轨道会用6个基本参数(半长轴、离心率、轨道倾角、升交点赤经、近地点辐角以及真近点角),即轨道六根数来描述。然而,由于这些参数之间单位不同、尺度差异较大,不利于模型的收敛,因此,本文选择输出目标在观测弧段初始时刻的运动状态,即位置矢量 $\mathbf{r}_i^o$ 和速度矢量 $\mathbf{v}_i^o$,而这些运动状态参数可以通过相关公式与轨道六根数相互转换(刘林和汤靖师,




图5 基于KAN的初轨确定网络结构

Fig. 5 Architecture of the orbit determination network based on KAN

2015)。为确保输出数据的尺度统一且大小限制在合理范围内,以便于模型收敛,这里输出的位置矢量的单位设定为 10^6 m,速度矢量的单位设定为 km/s。

2.2 损失函数

针对轨道确定问题设计了一种优化的损失函数,而非直接采用传统的均方误差(mean squared error, MSE)。为了提高轨道估计的准确性,引入了融合运动状态约束的损失函数,该函数综合考虑了位置预测误差和速度预测误差,以更全面地衡量模型的预测性能。其数学表达为

$$Loss = \frac{1}{N} \sum_{i=1}^N (\|r_i - \hat{r}_i\| + \lambda \|v_i - \hat{v}_i\|) \quad (7)$$

式中, r 和 v 分别表示目标的真实位置矢量和速度矢量, $\hat{r}$ 和 $\hat{v}$ 为模型预测值。从物理意义上分析, $\|r_i - \hat{r}_i\|$ 表示目标真实位置与预测位置之间的欧氏距离(直线距离), $\|v_i - \hat{v}_i\|$ 则表示目标真实速度矢量 v 与预测速度矢量 $\hat{v}$ 之间差值的二范数,用于表征速度估计的矢量误差模。 λ 用于调节位置误差与速度误差的权重比例,本文设定 $\lambda = 10$ 。该损失函数没有对输出的各参数统一处理,而是依据位置和速度在物理意义及量纲上的差异,分别计算两部分误差并通过权重进行组合,从而更好地综合考虑各物理量造成的影响,避免模型在优化过程中过度偏向某一误差指标。

2.3 实现细节

2.3.1 数据预处理

模型输入数据包括角度、角度变化率、观测平台的位置速度等,不同特征尺度不同。神经网络旨在学习数据的分布与关联特征,如果数据的尺度彼此之间差异过大,则会使得模型难以收敛。数据归一化是一种将数据缩放到统一尺度的方法,将各个特征缩放到相近的范围,使得模型更加稳定,能够更快达到最优解。

与图像像素均为正数不同,在轨道领域中,考虑到各种数据有正有负,这里选择采用下式将数据的各个特征归一化到 $[-1, 1]$ 的区间,具体为

$$x' = 2 \frac{x - \min(x)}{\max(x) - \min(x)} - 1 \quad (8)$$

式中, x 和 x' 分别表示特征在归一化前和归一化后的值, $\max(x)$ 和 $\min(x)$ 分别表示该类特征的最大值和最小值。模型需要记录训练集数据中 10 类特征的最大值和最小值,后续使用新的观测数据进行初轨确定时,也要将输入数据采用同样的变换,式中最大值和最小值则采用模型记录的值。

2.3.2 训练方法

设计一个合理的模型训练方法也是不可或缺的环节。本文采用了广泛使用的 Adam (Kingma 和 Ba, 2017) 优化器,该优化器具有良好的自适应性,能够使模型快速收敛到最优解,显著提升训练效率。

在模型训练中,学习率作为至关重要的超参数,

控制着参数更新时梯度下降的步长。选择合适的学习率直接影响着模型的收敛速度和最终性能。如果学习率过高,模型参数可能会因为梯度下降步长过大而跳过最优解;如果学习率过小,则可能导致参数更新缓慢,甚至陷入局部最优解。为此,本文采用动态调整学习率的方法,在训练初期使用较大的学习率使得模型参数快速收敛,随后逐步减小学习率以稳定地找到最优解。训练时初始学习率设定为0.001,同时监测验证集损失的变化。如果验证集损失在连续100轮内未下降,则将学习率减半。

最后,本文实验在Intel Xeon Gold 5218 CPU和NVIDIA GeForce RTX 3090 GPU硬件平台上进行, batchsize 设置为512。

3 高轨目标的天基光学观测短弧段数据集构建

由于深度学习方法高度依赖大规模高质量数据支持,本文基于CelesTrak开源卫星数据库(Kelso,

1985)构建了一个针对高轨目标的大规模天基光学观测短弧段数据集。该数据库采用国际通用的两行轨道数据(two-line orbital element, TLE)格式,完整记录了卫星观测历元、轨道倾角和偏心率等关键参数(示例见表1)。本研究筛选了581颗具有轨道多样性的高轨卫星作为目标,其参数分布如表2所示:多数卫星位于地球静止轨道(GEO),具有近圆形轨道和小倾角特征;同时包含部分大倾角卫星,确保了数据集的代表性。该数据集既为模型训练提供了可靠支撑,也为性能验证建立了基准。

除目标卫星外,本研究还设计了7颗高轨卫星作为天基观测平台,其轨道参数详见表3。通过差异化配置轨道六根数,实现了轨道的多样化设计,从而增强数据集的覆盖范围,避免因样本单一导致的局限性。图6展示了目标卫星与观测平台卫星的仿真轨道,直观地展示了这种多样性的设计。需要说明的是,多个观测平台的设计旨在丰富数据集,但在实际定轨应用中,仅需采用一个平台的观测数据即可完成目标的高精度初定轨任务。

表 1 TLE数据示例
Table 1 An example of TLE

行号	TLE数据
0	ABS-6
1	25924U 99053A 25065.67345108 -.00000130 00000+0 00000+0 0 9993
2	25924 0.0455 260.2029 0003105 59.0997 246.7824 1.00273316 93151

表 2 轨道各参数的指定分布比例对应区间
Table 2 The intervals corresponding to the specific distribution ratios of classical orbital elements

分布比例/%	半长轴/km	离心率	轨道倾角/(°)
0~20	39 780~42 159	8E-6~1.24E-4	0.029~0.138
20~40	42 159~42 163	1.24E-4~2.27E-4	0.138~0.190
40~60	42 163~42 167	2.27E-4~3.07E-4	0.190~0.268
60~80	42 167~42 172	3.07E-4~4.76E-4	0.268~3.663
80~100	42 172~43 620	4.76E-4~7.52E-2	3.663~61.742

本研究通过仿真获取了天基观测平台的卫星观测数据,包含了目标相对于天基平台的方位角 φ 和俯仰角 θ ,以及观测角度的变化率。考虑到实际中光学传感器的物理限制,这里设定观测相机的视场角为45°,仅当目标位于视场内时才可被有效观测。每个观测弧段长300 s,采样间隔为60 s,共包含6个

观测点。最终得到了258 741组数据,按照70%、15%、15%的比例划分为训练集、验证集和测试集。其中,训练集用于模型参数优化,验证集用于训练超参数调优以及防止发生过拟合,而测试集用于最终模型性能评估。为提升数据真实性,本研究模拟实际观测中的噪声,在仿真得到的观测角度中添加了

表 3 观测平台卫星的轨道参数
Table 3 Classical orbital elements of space-based observers

编号	半长轴/km	离心率	倾角/(°)	升交点赤经/(°)	近地点幅角/(°)	真近点角/(°)
1	42 164.2	0.000 1	28.5	100	0	0
2	42 164.2	0.000 1	38.5	130	0	100
3	42 364.2	0.000 1	12.5	60	30	40
4	42 464.2	0.000 1	27.3	327	103	65
5	42 304.2	0.000 1	5.5	10	32	189
6	42 164.2	0.000 1	13.5	343	12	276
7	42 164.2	0.000 1	3.5	166	83	170

服从均值为 0° ,标准差为 1° 的正态分布的随机误差,并通过边界约束确保所有数据保持在合理的取值范围内。

相较于 Gong 等人(2023)采用的长达 20 min 的观测弧段和较为单一的轨道参数,本文的数据集注重短弧段与多样化的轨道参数的结合,极大地提升

了数据集的挑战性。短弧段观测要求设计的方法在有限数据条件下实现较高的精度,而多样化的轨道则需要模型具备良好的泛化能力,以适应不同的轨道状态。正因如此,该数据集既能更真实地反映实际任务中的复杂情况,也能更充分地展示所提出方法在初轨确定任务中的优越性能。




图 6 目标卫星与天基观测平台的仿真轨道
Fig. 6 Simulated orbits of target satellites and space-based observers ((a) simulated orbits of target satellites;
(b) simulated orbits of space-based observers)

4 实验结果与分析

为验证所提出方法的性能,本文在构建的数据集上进行了系统实验,并与经典定轨方法及基于 MLP 的定轨方法进行了全面对比,以评估 KAN 在初轨确定任务中的有效性。下文将从对比方法与评价指标和结果对比与分析两方面展开。

4.1 对比方法与评价指标

本文选取 3 种传统初轨确定方法(Laplace 法、Gauss 法和 Double-R 法),以及圆轨道跟踪法(张晓祥

等,2003)作为对比基准,以系统评估深度学习方法在短弧段初轨确定问题中的有效性。Laplace 法和 Gauss 法都是初轨确定领域典型的代表方法,前者通过确定某一定轨历元时刻运动天体的位置矢量和速度矢量进行初轨确定,后者则是依据二体问题的基本关系确定两个时刻运动天体的位置矢量。Double-R 法与 Gauss 法类似,首先要初步推测两个位置矢量的大小,然后借助轨道动力学的约束不断修正位置矢量。为适应短弧段问题并提升传统方法的性能,实验中 3 种传统方法均结合了 Herrick-Gibbs 方法(Kaushik, 2016),通过二体问题与幂级

数展开相结合的方法提高估计精度。此外,圆轨道跟踪法基于近圆轨道假设,通过在轨道平面中外推计算有效规避了空间目标视运动不均匀性的影响,是近年来应用较广泛的新型定轨方法。

除传统方法外,本文还与 MLP 进行了对比,以验证 KAN 相较于 MLP 在初轨确定任务中的性能优势。为了确保网络架构层面的公平比较,本文搭建了具有相同网络结构的 MLP,具体网络结构如图 7 所示。这里 MLP 的激活函数采用 ReLU(rectified linear unit)函数。

实验选择的评价指标包括精度指标和效率指标。精度评价指标定义为平均位置误差 E_p 和平均速度误差 E_v ,二者的表达式分别为

$$E_p = \frac{1}{N} \sum_{i=1}^N \|r_i - \hat{r}_i\| = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 + (z_i - \hat{z}_i)^2} \quad (9)$$

$$E_v = \frac{1}{N} \sum_{i=1}^N \|v_i - \hat{v}_i\| = \frac{1}{N} \sum_{i=1}^N \sqrt{(v_{x,i} - \hat{v}_{x,i})^2 + (v_{y,i} - \hat{v}_{y,i})^2 + (v_{z,i} - \hat{v}_{z,i})^2} \quad (10)$$

式中, x, y, z 分别为目标位置矢量的分量, v_x, v_y, v_z 分别为目标速度矢量的分量。 E_p 和 E_v 分别表示模型预测的目标位置和速度与真实值的差异,误差越低,表明方法的精度越高。速度评价指标为方法的推理速度,单位定义为 APS(arcs per second),表示单位时间内能够完成初轨确定的弧段数量,数值越大,表明方法的效率越高。




图 7 MLP 网络结构

Fig. 7 Architecture of MLP

4.2 结果对比与分析

在相同测试集上对各种方法进行定量评估,比较不同方法的精度指标和效率指标,结果如表 4 所示。由表 4 可见,深度学习方法在各项性能上均优于传统方法。在精度方面,相较于传统方法中表现最好的 Gauss 法,本文方法的 E_p 和 E_v 分别仅为前者的 0.58% 和 1.14%。这是由于观测弧段过短(仅为 5 min),观测数据量少且数据变化量小,导致物理约束不足,传统方法的精度难以保证。同时,传统算法

容易出现平凡解、错误解等问题,大幅拉高了平均的误差结果。在效率方面,本文方法的 APS 达到了传统方法的 132 倍以上。这是由于传统方法需要反复迭代以逼近正确解,计算量大,而深度学习方法在推理时无需进行迭代,且能够进行批量运算,既具有更高的运算效率,也避免了因迭代不收敛而导致的无解问题,具有更强的稳定性。这体现了深度学习方法强大的泛化能力和鲁棒性,能够更好地适应各种条件下的初轨确定问题。

表 4 不同方法的精度指标和效率指标结果对比
Table 4 Comparison of accuracy and efficiency metrics for different methods

方法	E_p /km	E_v /(m/s)	APS	不收敛弧段比例
Laplace 法 (Kaushik, 2016)	11 603.533	844.984	72.335	222 / 38 812
Gauss 法 (Kaushik, 2016)	4 736.358	343.958	52.533	<u>166 / 38 812</u>
Double-R 法 (Kaushik, 2016)	5 578.645	411.019	13.580	20 105 / 38 812
圆轨道跟踪法 (张晓祥 等, 2003)	5 516.569	399.351	84.388	20 192 / 38 812
MLP	<u>109.774</u>	<u>19.940</u>	73 707.998	0 / 38 812
本文	27.458	3.904	<u>11 166.727</u>	0 / 38 812

注:加粗、下划线字体分别表示各列最优和次优结果。

对比 KAN 和 MLP 的定轨结果可见, KAN 模型的 E_p 和 E_v 分别为 MLP 的 25.01% 和 19.58%。这体现了 KAN 强大的数学拟合能力, 在空间目标轨道确定这一高度依赖物理知识的问题上, KAN 能够表现出更为优异的性能。然而, 在推理速度上, KAN 的效率稍逊于 MLP, 这是因为 KAN 将简单的边缘权重修改为样条函数, 导致模型参数量和计算量增加, 从而降低了计算效率。即便如此, KAN 的计算效率依然远远优于传统方法, 在实际应用中可以保证计算的实时性。

5 结 论

针对高轨目标短弧初轨确定的技术挑战, 本文提出一种基于 KAN 的新型轨道确定模型。相较于低轨目标以大气阻力为主导摄动源, 高轨目标的轨道动力学受地球非球形引力、太阳光压及月球引力等多源摄动耦合作用, 其非线性特性导致传统方法在短弧段条件下存在结果稳定性差、计算效率低等局限。实验表明, 该方法在降低计算复杂度的同时, 显著提升了短弧段定轨精度, 为解决高轨目标监测难题提供了新方案。

为了系统验证模型性能, 本研究构建了一个针对高轨目标的大规模天基光学观测短弧段数据集。该数据集基于 CelesTrak 实测卫星轨道数据, 涵盖地球静止轨道 (GEO)、大椭圆轨道 (highly elliptical orbit, HEO) 等典型轨道类型, 严格遵循天基观测平台的动力学特性。数据集设计兼顾两方面的科学价值: 一是通过轨道多样性增强模型对复杂摄动环境的适应能力; 二是利用短弧段数据模拟实际观测约

束, 验证方法在有限信息条件下的泛化性能。

与传统定轨方法的对比实验充分展示了本文提出的基于 KAN 模型的优越性。在精度方面, 传统方法中表现最佳的是 Gauss 法, 而本文方法的位置误差 E_p 和速度误差 E_v 分别仅为 Gauss 法的 0.58% 和 1.14%。同时, 本文方法获得错误解的数量远低于传统方法, 在定轨任务上展现出极高的稳定性。在效率方面, 传统方法中运行速度最快的为圆轨道跟踪法, 能够达到每秒处理 84.388 组数据, 而本文方法的推理速度达到了圆轨道跟踪法的 132 倍, 实现了精度与效率的双重优化。

尽管本文方法在高轨目标短弧初轨确定任务中取得了显著成效, 但仍存在两个关键改进方向值得深入研究。首先, 当前模型的性能仍依赖于预设的观测条件参数 (包括观测频率和弧段时长), 当实际观测条件超出预设范围时需重新训练模型。未来工作将重点突破动态自适应技术, 使模型能够自主适应不同观测条件的变化。其次, 虽然模型已初步融合轨道动力学约束, 但物理机理的嵌入深度和方式仍有优化空间, 通过引入高阶摄动模型等更精确的物理先验, 有望实现性能的进一步提升。

从应用前景来看, 本文方法不仅为当前高轨目标监测提供了有效解决方案, 更具有广阔的拓展空间: 一方面可向更高轨道的三体问题领域延伸, 验证深度学习方法在地月转移轨道等复杂摄动环境下的适用性; 另一方面可向智能化方向发展, 与自主导航系统深度融合, 为未来深空探测任务提供实时轨道确定支持。这些拓展研究将有力推动空间态势感知技术向更智能、更精准的方向发展。

致谢: 本文为第 27 届中国科协年会学术论文,

感谢中国科学技术协会的支持。

参考文献(References)

- Agostinelli I, Goracci G and Curti F. 2024. Initial orbit determination via artificial intelligence for too-short arcs. *Acta Astronautica*, 222: 609-624 [DOI: 10.1016/j.actaastro.2024.06.006]
- Arnol'd V I. 1959. On the representation of continuous functions of three variables by superpositions of continuous functions of two variables. *Matematicheskii Sbornik. Novaya Seriya*, 48(90): 3-74
- Bate R R, Mueller D D, White J E and Saylor W W. 2020. *Fundamentals of Astrodynamics*. 2nd ed. New York, USA: Dover Publications
- Cybenko G. 1989. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 2(4): 303-314 [DOI: 10.1007/BF02551274]
- DeMars K J, Jah M K and Schumacher P W. 2012. Initial orbit determination using short-arc angle and angle rate data. *IEEE Transactions on Aerospace and Electronic Systems*, 48(3): 2628-2637 [DOI: 10.1109/TAES.2012.6237613]
- Der G J. 2012. New angles-only algorithms for initial orbit determination//*Proceedings of 2012 Advanced Maui Optical and Space Surveillance Technologies Conference (AMOS 2012)*. Maui, USA: Maui Economic Development Board: 412-427
- Escobal P R. 1965. *Methods of Orbit Determination*. Malabar, USA: John Wiley & Sons, Inc
- Gibbs J W. 1889. *On the Determination of Elliptic Orbits from Three Complete Observations*. USA: *Memoires National Academy of Science*
- Gong B C, Ma Y Q, Zhang W F, Li S and Li X Q. 2023. Deep-neural-network-based angles-only relative orbit determination for space non-cooperative target. *Acta Astronautica*, 204: 552-567 [DOI: 10.1016/j.actaastro.2022.09.024]
- Goodfellow I, Bengio Y and Courville A. 2016. *Deep Learning*. Cambridge, USA: The MIT Press
- Gooding R H. 1990. A procedure for the solution of Lambert's orbital boundary-value problem. *Celestial Mechanics and Dynamical Astronomy*, 48(2): 145-165 [DOI: 10.1007/BF00049511]
- Gooding R H. 1993. A new procedure for orbit determination based on three lines of sight: angles only. *NASA STI/Recon Technical Report N*, 94: #21224
- Gooding R H. 1996. A new procedure for the solution of the classical problem of minimal orbit determination from three lines of sight. *Celestial Mechanics and Dynamical Astronomy*, 66(4): 387-423 [DOI: 10.1007/BF00049379]
- Herrick S. 1971. *Astrodynamics: Orbit Determination, Space Navigation*. *Celestial Mechanics, Volume 1*. London: Van Nostrand Reinhold Co.: 90-93
- Hornik K, Stinchcombe M and White H. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5): 359-366 [DOI: 10.1016/0893-6080(89)90020-8]
- Huang C and Liu L. 2015. *Reference Coordinate System and Aerospace Applications*. Beijing: Publishing House of Electronics Industry (黄斌, 刘林. 2015. 参考坐标系及航天应用. 北京: 电子工业出版社)
- Huang H B and Zhang J. 2014. A nonlinear covariance analysis method for space station rendezvous phasing based on unscented transformation. *Journal of National University of Defense Technology*, 36(2): 18-23 (黄海兵, 张进. 2014. 基于U变换的空间站交会调相非线性协方差分析方法. 国防科技大学学报, 36(2): 18-23) [DOI: 10.11887/j.cn.201402004]
- Karaboga D. 2005. *An Idea Based on Honey Bee Swarm for Numerical Optimization*. Technical Report-TR06. Erciyes University
- Kaushik A S. 2016. *A Statistical Comparison between Gibbs and Herrick-Gibbs Orbit Determination Methods*. College Station, USA: Texas A&M University
- Kelso T S. 1985. *Celestrak* [EB/OL]. [2025-03-31]. <https://celestrak.org/>
- Kingma D P and Ba J L. 2017. Adam: a method for stochastic optimization [EB/OL]. [2025-03-31]. <https://arxiv.org/pdf/1412.6980.pdf>
- Kolmogorov A N. 2009. On the representation of continuous functions of several variables as superpositions of continuous functions of a smaller number of variables//*Vladimir I. Arnold - Collected Works*. Berlin, Germany: Springer: 25-46 [DOI: 10.1007/978-3-642-01742-1_5]
- Kolmogorov A N. 1957. On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition. *Doklady Akademii Nauk*, 114(5): 953-956
- Lei X X, Xia S F, Liu H K, Wang X Z, Li Z W, Han B M, Sang J Z, Zhao Y and Luo H. 2023. An improved range-searching initial orbit-determination method and correlation of optical observations for space debris. *Applied Sciences*, 13(24): #13224 [DOI: 10.3390/app132413224]
- Liu L and Tang J S. 2015. *Theory and Applications of Orbit*. Beijing: Publishing House of Electronics Industry (刘林, 汤靖师. 2015. 卫星轨道理论与应用. 北京: 电子工业出版社)
- Liu Z M, Wang Y X, Vaidya S, Ruehle F, Halverson J, Soljačić M, Hou T Y and Tegmark M. 2025. KAN: Kolmogorov-Arnold networks [EB/OL]. [2025-03-31]. <https://arxiv.org/pdf/2404.19756.pdf>
- Rosenblatt F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6): 386-408 [DOI: 10.1037/h0042519]
- Vallado D A. 2001. *Fundamentals of Astrodynamics and Applications*. 2nd ed. Segundo, USA: Microcosm Press
- Wang F, Zhang Z, Ye H and Zhang G P. 2024. Development status and trends of foreign space situation awareness ability (invited). *Laser and Optoelectronics Progress*, 61(20): #2011006 (王锋, 张哲,

- 叶昊, 张高鹏. 2024. 国外空间态势感知能力分析与发展趋势 (特邀). 激光与光电子学进展, 61(20): #2011006 [DOI: 10.3788/LOP240882]
- Wang G H, Chang L, Wu H Y, Tang T and Wang M L. 2023. Satellite autonomous mission planning based on orbit solar vector. Transactions of Beijing Institute of Technology, 43(6): 609-615 (王国华, 常亮, 吴会英, 唐涛, 王明亮. 2023. 基于轨道系太阳矢量的卫星自主任务规划设计. 北京理工大学学报, 43(6): 609-615) [DOI: 10.15918/j.tbit1001-0645.2022.152]
- Wang P, An W, Sheng W D and Yan T Y. 2023. Observability analysis of initial orbit determination with bearings-only measurements from single satellite. Acta Aeronautica et Astronautica Sinica, 44(15): 359-370 (汪璞, 安玮, 盛卫东, 闫天羽. 2023. 基于单星光学测角的初轨确定可观测性分析. 航空学报, 44(15): 359-370) [DOI: 10.7527/S1000-6893.2023.28798]
- Zhang X X, Wu L D and Xiong J N. 2003. Circle-orbit tracking method of space object. Acta Astronomica Sinica, 44(4): 405-415 (张晓祥, 吴连大, 熊建宁. 2003. 空间目标的圆轨道跟踪法. 天文学报, 44(4): 405-415) [DOI: 10.3321/j.issn:0001-5245.2003.04.010]
- Zhang Y J. 2025. Image engineering in China; 2024. Journal of Image and Graphics, 30(5): 1346-1363 (章毓晋. 2025. 中国图像工程: 2024. 中国图象图形学报, 30(5): 1346-1363) [DOI: 10.11834/jig.250116]

作者简介

刘宏宇, 男, 博士研究生, 主要研究方向为机器学习、轨道确定和空间态势感知。E-mail: liuhongyu2415@buaa.edu.cn

张余, 通信作者, 男, 副教授, 主要研究方向为计算机视觉、机器学习、空间态势感知和外科手术规划。
E-mail: uzeful@163.com

张超群, 男, 本科生, 主要研究方向为机器学习、图像处理和空间态势感知。E-mail: zhangchaoqun@buaa.edu.cn

陈果, 男, 博士研究生, 主要研究方向为图像处理、目标检测、多模态大模型和空间态势感知。
E-mail: chenguo777@buaa.edu.cn

尹继豪, 男, 教授, 主要研究方向为人工智能、深空探测、计算机视觉和空间态势感知。E-mail: jihaoyin@buaa.edu.cn