

引用格式: LIU Yang, XU Can, ZHANG YaSheng, et al. GEO Satellite Status Analysis Method Based on Photometric Characteristics[J]. Acta Photonica Sinica, 2026, 55(8):0804003

刘洋,徐灿,张雅声,等. 基于光度特征的 GEO 卫星状态分析方法研究[J]. 光子学报, 2026, 55(8):0804003

基于光度特征的 GEO 卫星状态分析方法研究

刘洋,徐灿,张雅声,许棣欣

(航天工程大学, 北京 101416)

摘 要:在完成实测地球静止轨道目标光度序列处理和状态标记的基础上,对地球静止轨道目标光学散射特性进行分析,提出并建立以时域特征、频域特征和样本熵特征组合的光度序列特征集,并对传统机器学习方法和深度神经网络方法下各类特征的分类性能。采用多维度特征集后,随机森林、决策树、全连接神经网络、双向长短期记忆网络和支持向量机的分类准确率分别达到 94.16%、90.58%、89.71%、89.29% 和 82.31%。研究成果对于实际工程中有效发现地球静止轨道卫星姿态异常具有支撑作用。

关键词:空间目标光度学;卫星姿态异常识别;光度数据处理;机器学习;地球静止轨道卫星;频域特征

中图分类号:P171.3

文献标识码:A

doi:10.3788/gzxb20265508.0804003

0 引言

地球静止轨道(Geosynchronous Earth Orbit, GEO)卫星因具有相对地面静止的特点,在通信、气象监测和预警等领域有突出的应用价值。GEO 轨道资源的稀缺性与 GEO 卫星特殊的战略价值,使得观测 GEO 卫星运行状态成为太空目标监视的重要内容。

由于 GEO 目标距离远,雷达观测综合效费比低,光学观测成为主要手段^[1]。光学观测数据中,除定位信息外,还包括目标的光度信息。目前,基于光度数据的卫星状态识别研究已取得初步进展。例如,DAO P^[2]提出了一种基于隐马尔可夫模型的自动化算法,使用差分星等和颜色指数两种光度测量数据来检测三轴稳定 GEO 卫星的配置变化和身份误标问题;臧晴、邹润等^[3-4]通过分析两颗卫星在多帧关联图像中的相对光度变化,成功判断了其中一颗卫星的轨道是否变化,又通过光度数据的残差判断了卫星姿态是否变化,为利用光度信息进行状态诊断提供了可行途径;此外,SUKHOV P^[5]等提出了一种基于光度与天体测量信息联合求解反演问题的方法,通过构建 GEO 卫星的光度与动力学特征计算算法,成功分析了 4 颗真实 GEO 目标的在轨行为,为利用多源观测信息进行卫星状态描述提供了思路。然而,此类方法在非合作的单一 GEO 卫星场景下应用受限。近年来,机器学习方法开始展现潜力,如 LINARES R^[6]等提出一种基于卷积神经网络(Convolutional Neural Network, CNN)的深度学习方法,用物理模型生成光曲线数据对 CNN 进行训练,并结合少量真实光曲线数据以增强模型泛化能力,实现了对空间物体的光度曲线数据分类;LI Weixiao^[7]提出了一种基于时序注意力机制的长短期记忆网络(Temporal-Attention LSTM, TA-LSTM)异常检测方法,能够识别空间目标光变曲线中的异常事件,如快速姿态调整等行为,证明了深度学习在捕捉时序异常模式上的有效性;在特征工程层面,董吴卿与张绪国^[8]近期提出了一种基于“光度指纹”的特征提取方法,并结合 TabPFN 预训练模型实现了对 7 类卫星平台的高精度识别,该方法通过模型轻量化设计有效降低了推理算力需求与数据量门槛。然而,上述深度学习方法在决策过程的可解释性方面仍存在固有局限,其中基于 CNN 与 TA-LSTM 的方法对标注数据规模与计算资源的依赖程度依然较高。

第一作者:刘洋,615323632@qq.com

通讯作者:徐灿,452394317@qq.com

收稿日期:2026-03-23;录用日期:2026-07-03

<http://www.photon.ac.cn>

因此,针对现有研究在特征构建上较为单一、缺乏多域特征融合的不足,本文基于实测 GEO 卫星光度时序数据,在完成数据预处理与状态分组后,提取光度数据的时域、频域与样本熵特征,形成样本集;分别采用传统机器学习算法和深度学习算法进行卫星状态分类检验,获得工程可用的状态分类方法。在此基础上,本文通过特征有效性分析方法,对各类特征的有效性进行了定量对比分析,为后续开展广泛的实践应用提供支撑。

1 空间目标光度变化机理

空间目标的光度序列是探测器接收到空间目标辐射能量大小随时间变化的数值曲线^[9]。空间目标的光度主要来源于太阳直射光、地表反射太阳光、大气散射光、月球反射太阳光等,其中以太阳直射光为主^[10]。太阳光照射到空间目标表面后,一部分被目标表面吸收,另一部分被反射到空间中重新传播,光度信号即为空间目标反射太阳光至探测器入瞳处的光能量变化曲线。若此时探测器能够捕获到目标反射出的光能量,就可以稳定获得目标光度信号^[10-11]。地基空间目标光度信号观测示意图如图 1 所示。




图 1 空间目标光度信号观测示意图

Fig. 1 Schematic diagram of space target photometric signal observation

绝大多数空间目标自身并不会发光,因此它并不存在一个固有的“光度”属性,探测器所测的本质上是空间目标的亮度^[11]。通常情况下,空间目标的亮度用星等 m 表示,现假设有两个空间目标,根据波森公式,有

$$m_1 - m_2 = -2.5 \log \frac{E_1}{E_2} \quad (1)$$

式中, m_1 和 m_2 分别为目标 1 与目标 2 的星等, E_1 和 E_2 分别为目标 1 与目标 2 的辐射照度。为确定空间目标的星等,通常将其亮度与太阳相比较。在地球大气层外太阳视星等为 $m_{\odot} = -26.7$, 因此空间目标视星等计算公式可表示为

$$m = -26.7 - 2.5 \log \frac{E}{E_{\odot}} \quad (2)$$

式中, $E_{\odot}$ 为太阳的辐射照度, E 为空间目标的辐射照度。然而,目标的辐射照度 E 并非直接可测,它取决于目标表面对光的散射特性、几何形状以及观测几何。为此,引入了光学横截面 (Optical Cross Section, OCS) 这一物理量, OCS 定义为

$$\text{OCS} = \int_A f_r(\theta_i, \theta_j) \cos \theta_i \cos \theta_j dA \quad (3)$$

式中, f_r 为双向反射分布函数 (Bidirectional Reflectance Distribution Function, BRDF), θ_i 和 θ_j 分别为入射天顶角和反射天顶角, A 为有效面元面积,图 2 展示了各几何变量的定义。

那么目标在探测器入瞳处的辐射照度 E 可表示为

$$E = \frac{E_{\odot}}{R^2} \cdot \text{OCS} \quad (4)$$

式中, $E_{\odot}$ 为太阳的辐射照度, R 为目标到探测器入瞳处的距离。由式 (4) 可将式 (2) 转化为




图2 OCS各变量示意图

Fig. 2 Schematic diagram of OCS variables

$$\begin{aligned}
 m &= -26.74 - 2.5 \lg \left(\frac{\text{OCS}}{R^2} \right) \\
 &= -26.74 - 2.5 \lg \left(\frac{\int_A f_r(\theta_i, \theta_j) \cos \theta_i \cos \theta_j dA}{R^2} \right)
 \end{aligned} \quad (5)$$

根据式(5)可得知,光度数据受到空间目标运行轨道、光照和观测角度、运动状态、姿态变化、表面材质等诸多因素的共同影响。但对于高轨目标而言,由于其相对地球保持静止,观测角度是固定的,这为分析目标亮度提供了有利条件。通常,正常工作的高轨卫星,其光度变化主要是太阳的光照角变化引起的,由于太阳照射角度变化缓慢,其光度变化缓慢,光度曲线较为平滑^[12];而对于失效的高轨卫星,其姿态无法保持稳定进而出现异常的翻滚,其光学表现与正常运行卫星存在显著区别。从动力学角度看,失效卫星会绕其角动量轴做进动运动,且运动速度显著高于太阳入射角度的变化率,引起卫星表面不规则地反射太阳光;在光学观测上,这种不稳定的运动模式会表现为光度曲线剧烈且无规律波动,其亮度会出现幅值突变、周期混乱等情况。因此,由姿态失稳引发的光度曲线波动,是利用光度数据完成卫星异常状态诊断的关键物理判据。

2 GEO 卫星光度数据特征提取

光度曲线本质上是对目标反射太阳光通量随时间变化的记录,其中蕴含了目标的形状、材质、运动状态等多维信息。与低轨快速运动目标不同,GEO 卫星相对地面观测点几乎静止,引起其光度变化的主要原因是太阳-卫星-测站几何关系的连续缓慢变化以及自身姿态调整,而非轨道运动引起的快速周期性光变。因此,对 GEO 卫星而言,光度序列中的有效信息主要蕴含在姿态与光照几何的变化之中。从光度序列中提取有效的量化特征捕捉这些变化,是实现 GEO 卫星状态识别与异常检测的基础。本文从时域、频域以及非线性动力学三个角度出发,分别提取能够反映 GEO 卫星光度曲线变化规律的特征量。三类特征从不同侧面反映了卫星的姿态运动特性,共同构成用于后续分类器训练的特征集。

2.1 时域特征

采集形成的光度序列曲线在本质上是一种时间序列,即根据时间顺序得到的一系列观测值^[13]。因此,在时间序列分析中常用的特征或方法可以应用到光度曲线的分析中^[11]。根据对姿态异常卫星特点的分析,周期性起伏特征明显的卫星异常概率大,为此本文选择了 2 个常见的时域特征作为 GEO 卫星姿态异常的判据,分别是:标准差/方差、波动系数。

1) 标准差与方差

标准差(Standard Deviation)是描述一组数据离散程度的统计量,表示数据点与均值的平均偏离程度;方差(Variance)是数据点与均值偏离程度的平方的平均值,为标准差的平方,反映数据整体波动强度。在光度数据中,标准差与方差作为时域特征,其理论价值在于能够量化亮度的整体波动幅度。同时,由于不同卫星的大小、材质不同,其亮度会有差异,但一定时间内的标准差/方差却可以反映其亮度起伏程度。

2) 波动系数

波动系数(Coefficient of Variation),也叫变异系数,是用于衡量数据离散程度的相对指标,无量纲指标,能够消除量纲和绝对亮度的影响,衡量相对波动强度。其数学表达式定义为标准差与数据均值绝对值的比值

$$C_v = \frac{\sigma}{|\bar{X}|} \quad (6)$$

式中, σ 为数据标准差, $|\bar{X}|$ 为数据均值。波动系数作为无量纲特征,其优势在于能有效消除因卫星尺寸、距离等因素造成的绝对亮度差异,从而使得不同卫星光度数据间也有可比性。

2.2 频域特征

由于失效异常的卫星会失去姿态控制能力,在各类摄动力的影响下绕最大动量轴旋转,呈现出一定的周期性。频域特征则是能有效揭示信号在周期性谐振特性方面的状态信息,因此可作为光度数据分析的重要补充。本文选择提取频域特征以构建更全面的判别体系,选择了3个频域特征作为GEO卫星姿态异常的判据,分别为:频域平均幅值、中心频率与频率方差。

1) 频域平均幅值

频率域平均幅值(Average Amplitude)是用于量化信号在特定频带内周期性波动强度的频域特征。该特征通过分析信号功率在频域的分布,有效表征其周期性谐振特性。对于存在周期分量的信号而言,其频谱能量将偏离零频,进而引起频域平均幅值的变化。其计算遵循以下标准化流程:

首先,对原始光度时域信号 $x(t)$ 做快速傅里叶变换(Fast Fourier Transform, FFT),将其从时域投影至频域,得到信号的频谱 $X(f)$,其中 f 为频率分量, $|X(f)|$ 为其对应的幅值;再基于先验知识或频谱分析,确定能反映目标物理特性的关键频段 $[f_1, f_2]$;随后计算 $[f_1, f_2]$ 频段内所有离散频率点幅值的算术平均值,即为频率域平均幅值 A_{avg} ,其计算公式为

$$A_{\text{avg}} = \frac{1}{N} \sum_{f=f_1}^{f_2} |X(f)| \quad (7)$$

式中, N 为频段 $[f_1, f_2]$ 内的频率点数。

2) 功率谱密度与中心频率

功率谱密度(Power Spectral Density, PSD)是信号在频域中的能量分布函数,表征了不同频率成分所承载的能量大小,以下简称为PSD。其通过傅里叶变换将时域信号分解为频率成分,实现不同频点对信号总能量贡献的定量描述。

对于采样连续且采样率恒定的光度数据,可以使用离散傅里叶变换将离散采样的时域光度数据转换为曲线的功率谱,从而辨识出光度数据周期^[14]。设观测时刻数为 N , $x(n)$ 为有限长序列,即

$$x(n) = \begin{cases} x(n), & 0 \leq n \leq N-1 \\ 0, & \text{other} \end{cases} \quad (8)$$

则 $x(n)$ 的离散傅里叶变换为

$$X(k) = D_{\text{FT}}[x(n)] = \sum_{n=0}^{N-1} x(n) W_N^{nk}, 0 \leq k \leq N-1 \quad (9)$$

式中, D_{FT} 为离散傅里叶变换, W_N 为单位周期复指数序列, W_N 的表达式为

$$W_N = \exp\left(-j \frac{2\pi}{N}\right) \quad (10)$$

则对于离散时间序列 $X(k)$,其PSD可以通过周期图法计算,其表达式为

$$P_{\text{SD}}(f_k) = \frac{1}{N \cdot f_s} |X(k)|^2, k = 0, 1, \dots, \frac{N}{2} \quad (11)$$

式中, f_s 为采样频率, $f_k = \frac{k f_s}{N}$ 为频率分辨率。

中心频率(Central Frequency)是PSD的一阶统计矩,计算为频率基于PSD加权的平均值。中心频率不

关注能量的绝对大小,而是确定信号能量在频域的主要分布位置,从而反映信号的主要振荡模式。中心频率 f_c 的数学表达式为

$$f_c = \frac{\sum_{k=1}^M f_k \cdot P_{SD}(f_k)}{\sum_{k=1}^M P_{SD}(f_k)} \quad (12)$$

式中, f_k 为频率分辨率, $M = \frac{N}{2}$ 。

3) 频率方差

频率方差(Frequency Variance)是 PSD 中各频率成分相对于中心频率的离散程度的加权平均,表征了频谱能量围绕中心频率的离散程度。其数值反映了 PSD 分布的形状宽度:方差值越大,表示能量在频域上分布越分散;反之则表示能量越集中于中心频率附近。对于失效之初的卫星,尽管尚未形成周期分量,但其起伏也会明显加剧,引起频率方差的增大。频率方差 σ_f^2 的数学表达式为

$$\sigma_f^2 = \frac{\sum_{k=1}^M (f_k - f_c)^2 \cdot P_{SD}(f_k)}{\sum_{k=1}^M P_{SD}(f_k)} \quad (13)$$

式中, f_c 为中心频率, f_k 为频率分辨率, $M = \frac{N}{2}$ 。

频率方差能表征信号能量在频率范围内的分布集中程度,其物理意义在于:较低的频率方差说明信号能量高度集中,周期性规律显著;反之,较高的方差则表明能量广泛分散于多个频带,缺乏主导的周期性成分。正常 GEO 卫星因姿态稳定,其频谱能量集中于特征频率附近,频率方差普遍较低且分布集中;而当卫星姿态失控时,其运动状态混乱,频谱能量弥散,频率方差随之升高且分布范围更广。

2.3 样本熵特征

样本熵(Sample Entropy)是衡量时间序列复杂性的非线性指标,表示数据中新模式出现的概率。熵值越高,序列随机性越强,这与失效卫星光度曲线随机性增大的特征是一致的。现给定序列 $\{x_1, x_2, \dots, x_n\}$,设定嵌入维度 m 和容限 r ,构造 m 维向量 $X_i = [x_i, x_{i+1}, \dots, x_{i+m-1}]$,统计满足 $\|X_i - X_j\| < r (i \neq j)$ 的向量对数量 B_i^m ,则样本熵计算公式为

$$S_{\text{ampEn}}(m, r) = -\ln \left(\frac{\sum_{i=1}^{N-m} B_i^{m+1}}{\sum_{i=1}^{N-m} B_i^m} \right) \quad (14)$$

样本熵是无量纲的指标,用于量化时间序列复杂性与不规则性。理论上,其值越低表明信号越规则、越可预测;值越高则代表信号越复杂、越接近随机状态。熵特征已在雷达信号处理领域中被证实有效^[15],因此,本文将引入光度数据特征集,以验证其在卫星状态分类中的有效性。

3 数据特征有效性分析

本研究的实测数据来源于航天工程大学自研的“小型光电创新实践平台”。该观测系统核心为一台口径 150 mm、视场 $10^\circ \times 10^\circ$ 的光学望远镜,以及一台 QHY4040 科学级 CMOS 相机(分辨率 4096×4096),观测采用每秒一帧的曝光模式。基于此平台获取的原始图像经处理后得到用于分析的光度数据,数据集中采集于 2024 年 1 月至 12 月,共获得有效观测弧段 10080 圈次。原始光度数据按 50 秒为一个弧段进行截取(即每段 50 个采样点),经去噪、异常值剔除及归一化处理后,最终得到 73597 条光度序列样本。为完成对观测数据卫星状态的标记,根据卫星在轨年限及 Space-Track 网站公布信息进行初判,将在轨超过 15 年或网站宣布为失效的卫星判定为异常;随后由人工通过观察卫星亮度曲线的变化对初判结果进行复核确认,确定卫星状态。根据卫星状态,确定其中 44272 条数据来自正常运行的卫星,29325 条来自异常卫星。为评估模型

性能,本文采用保留集验证法,将数据集按7:3的比例随机划分为训练集和测试集。对于需要验证集进行早停的模型,再从训练集中随机划分出15%作为验证集,用于监控训练过程中的过拟合状态并触发早停。所有模型均在训练集或训练集+验证集上完成拟合后,在未曾使用过的测试集上进行预测,并将分类准确率作为核心性能指标。

基于此真实数据集,分别采用支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)、决策树(Decision Tree, DT)三种传统空间目标光度信号分类识别算法,与双向长短期记忆网络(Bi-Directional Long Short-Term Memory, Bi-LSTM)、全连接神经网络(Fully Connected Neural Network, FCNN)两种深度神经网络识别算法进行处理,通过分类准确率评估各数据特征的优劣,并分析其背后原因。

首先,现对本实验Bi-LSTM与FCNN网络的具体配置进行说明:Bi-LSTM网络包含一个输入维度可根据数据特征数进行调整的序列输入层、一个包含128个隐藏单元的单层双向LSTM,以及用于二分类的全连接与softmax输出层。训练采用Adam优化器,初始学习率为0.001,设置训练周期为30,批大小为32,并设置梯度裁剪阈值为1来稳定训练过程。网络在双向LSTM层后加入了丢弃率为0.5的Dropout层,用于随机丢弃部分神经元输出以增强模型泛化能力;FCNN采用简单的多层感知机结构:一个可根据数据特征数进行调整的特征输入层,一个包含50个神经元的隐藏层,后接ReLU激活函数,最后连接至2维输出层及Softmax分类层。训练设置如下:使用Adam优化器,初始学习率为0.001,最大训练周期为20,批大小为32,设置梯度裁剪阈值为1。两种网络均进行了验证集监控,从训练集中随机划分15%作为验证集,在每个训练周期结束后计算验证损失与准确率,实时监控过拟合情况;并设置了早停机制,当验证损失连续5个训练周期未改善时,自动终止训练,并保留验证损失最低时的模型参数,防止过拟合。

为探究各特征的独立判别能力,将计算每个特征在各算法下的平均分类准确率。平均分类准确率能反映每个特征在独立使用时对卫星状态分类的整体贡献度,所以表1将基于此对特征的有效性进行排序。

表1 各特征平均分类准确率
Table 1 Average classification accuracy of different features

Feature	SVM	DT	RF	Bi-LSTM	FCNN	Average accuracy
Average amplitude	79.67%	78.22%	80.72%	79.54%	80.15%	79.46%
Central frequency	60.31%	75.33%	75.97%	75.07%	76.71%	69.74%
Frequency variance	60.19%	74.96%	75.60%	74.59%	75.98%	69.36%
Standard deviation & variance	60.13%	67.08%	72.58%	63.77%	62.92%	64.59%
Coefficient of variation	59.85%	65.54%	71.50%	62.65%	59.40%	63.22%
Sample entropy	59.67%	60.67%	60.63%	60.40%	60.02%	60.25%

基于表1的结果可以分析出以下结论:

1)平均幅值是本研究设置下单特征判别的最优解。其平均准确率接近80%,显著高于其他特征,表明特定频段综合能量的强度是对卫星状态变化最敏感稳定的指标;

2)样本熵在本任务中表现不佳,其平均分类准确率为所有特征中最低,显著低于时域与频域特征。深入分析其原因有三:

首先,样本熵对数据长度和参数选取较为敏感,实测光度序列在状态分组后长度有限,影响熵值估计的稳定性;

其次,样本熵是对整个时间序列复杂度的全局度量,其将整段时序压缩为单一数值的过程会丢失其中的动态演化信息。对于正常卫星而言,由于光照角度的差异性引起的光度曲线复杂度差异较大,导致正常类别内部的熵值分布范围较宽,与异常类别的熵值分布产生重叠,从而削弱了样本熵对正常与异常状态的区分能力;

最后,实测光度数据在采集过程中不可避免存在测量噪声,这会额外增加时间序列的随机性,使得正常卫星的样本熵值被抬高,进一步加剧了与异常卫星的混淆。上述因素共同制约了样本熵作为单一特征时的判别能力。

3)频域特征在判别效力上占据绝对主导地位,平均准确率排名前三的特征均为频域特征,而两种时域特征及熵特征的分类准确率则明显偏低。

现为进一步验证“频域特征在判别效力上占据绝对主导地位”的结论,在排除分类效力不佳的样本熵特征后,计算各算法在仅使用时域特征与仅使用频域特征时的分类准确率,继续深入分析时域与频域特征在此分类任务中的有效性。表2展示了各算法分别使用时域特征与频域特征的分类准确率。

表2 时域特征与频域特征分类准确率
Table 2 Classification accuracy of time-domain features and frequency-domain features

Algorithm	Time-domain	Frequency-domain
RF	73.40%	90.03%
DT	67.83%	84.82%
FCNN	65.39%	86.04%
Bi-LSTM	64.76%	84.41%
SVM	63.82%	79.60%

表2的实验结果表明,频域特征相较于时域特征对本研究中的卫星状态分类任务具有显著更高的判别效力。这一结论在不同算法中均表现一致,频域特征的分类准确率普遍高出时域特征约16个百分点。现对导致这一差异的原因进行分析。

卫星的正常运行状态表现为非周期性运动,常用姿态为对地定向,其光度变化没有明显的周期性成分,反映在频域上即为能量集中在零频区域附近;而异常状态表现为运动失稳,引入了周期性引发频率域能量分布的扩散。频域分析能将复杂信号解耦为不同频率的成分,从而量化卫星周期性运动模式的变化:平均幅值可直接反映特定频段的振动强度,中心频率可捕捉主振荡模式的变化,频率方差则可度量能量分布的离散程度。这些特征是具有明确物理意义的判别依据。相比之下,时域特征仅能描述信号的整体能量起伏与幅值统计特性,无法揭示当卫星姿态异常时在频率结构的变化。这种只能反映信号宏观整体表现,无法捕捉信号微观内在成分变化的特性,使得时域特征在区分正常起伏波动与异常周期性波动时敏感性不足。

综上所述,频域特征因与卫星动力学物理机理直接关联,能够揭示信号的频率结构特性,在卫星状态分类任务中展现出显著优势,其中平均幅值表现尤为突出。这一发现为今后类似的空间目标状态监测研究提供了重要的特征选择指导。

现为进一步验证多维度光度序列特征集的有效性,将时域特征、频域特征及样本熵特征进行组合构建多维度特征集,并采用相同的五种算法进行分类实验。表3展示了各算法在多维度特征集下的分类准确率。

表3 多维度特征集分类准确率
Table 3 Classification accuracy of multi-dimensional feature sets

Algorithm	Classification accuracy
RF	94.16%
DT	90.58%
FCNN	89.71%
Bi-LSTM	89.29%
SVM	82.31%

对比表2与表3的结果可以发现,多维度特征集在所有算法上均取得了较单独使用时域或频域特征更高的分类准确率。以随机森林为例,其准确率从频域特征的90.03%提升至94.16%,提升了约4个百分点;决策树从84.82%提升至90.58%,提升近6个百分点;支持向量机从79.60%提升至82.31%;两种深度学习算法的准确率也有所提升,Bi-LSTM从78.21%提升至80.43%,FCNN从86.04%提升至89.71%。

在前期分析中发现样本熵的单一分类能力有限,为考察样本熵是否仍有必要加入多维度特征集,本文在剔除样本熵后,仅保留时域与频域特征构建对比特征集,采用相同算法进行分类实验,结果如表4所示。

表4 有无样本熵的特征集分类准确率对比
Table 4 Comparison of classification accuracy with and without sample entropy

Algorithm	Time—frequency features (w/o sample entropy)	Time—frequency features with sample entropy (multi—dimensional set)	Improvement
RF	92.72%	94.16%	+1.44%
DT	89.32%	90.58%	+1.26%
FCNN	88.54%	89.71%	+1.17%
Bi—LSTM	88.06%	89.29%	+1.23%
SVM	80.64%	82.31%	+1.67%

实验结果表明,加入样本熵后各分类模型的准确率均获得了提升。这说明,尽管样本熵作为单一特征判别能力有限,但分类器仍能利用高维特征空间中的交互作用,将样本熵的微弱信号与其他特征协同利用,从而提升整体分类性能。因此,本文在多维度特征集中保留样本熵,以构建更完备的特征体系。

时域特征反映光度的整体统计特性,频域特征捕捉周期性运动的变化,样本熵则度量信号的复杂性。三者互为补充,共同提升模型对卫星正常与异常状态的区分能力。因此,在本研究构建的多维度光度序列特征集下,分类性能显著优于单一类型特征,验证了多维度特征融合的有效性,为后续实际应用提供了借鉴。

4 结论

本文针对 GEO 卫星状态分析的实际需求,系统性地探索了基于光度数据的机器学习解决方案。通过对实验结果的分析与讨论,得出以下结论:

首先,在特征工程层面,本文揭示了频域特征对于捕捉卫星姿态异常的重要价值。这与陈世超等^[15]在雷达目标检测中成功应用熵特征形成对比,凸显了数据模态对特征有效性的影响。控制变量实验表明,频域特征(平均幅值、中心频率、频率方差)的判别效力全面优于时域特征,其中平均幅值以 79.54% 的高平均准确率成为单特征判别的最优解。这一发现说明频域特征能够直接解耦信号频率成分,灵敏地诊断出卫星从有序周期运动到无序状态的转变,而时域特征仅提供宏观的、模糊的波动信息。

其次,在特征组合层面,本文构建了融合时域、频域及样本熵的多维度特征集,并进一步验证了特征融合的有效性。实验结果表明,多维度特征集在所有算法上的分类准确率均显著高于单独使用时域或频域特征。以随机森林为例,其准确率从频域特征的 90.03% 提升至 94.16%;全连接神经网络从 86.04% 提升至 89.71%。这说明不同维度的特征具有互补性,三者结合能够更全面地刻画卫星状态,为基于光度数据的卫星在轨状态诊断提供了更可靠的特征依据。

然而,本文也存在一定局限性。一方面,所使用数据集中异常状态的样本数量和多样性仍有不足,可能限制了模型,尤其是深度学习模型潜力的充分发挥;另一方面,样本熵在本任务中表现不佳,平均准确率仅 60.25%。因其在雷达目标检测等其他领域被证明有效,或许是受具体应用场景的限制,后续还需继续开发其应用价值。

参考文献

- [1] HU Yunpeng, LI Kebo, LIANG Yan'gang, et al. Review on strategies of space-based optical space situational awareness [J]. Journal of Systems Engineering and Electronics, 2021, 32(5): 1152-1166.
- [2] DAO P. Automated algorithm to detect changes in geostationary satellite's configuration and cross-tagging[C]. Proceedings of the 2015 Advanced Maui Optical and Space Surveillance Technologies Conference (AMOS), September 15-18, 2015, Maui, HI, USA. 2015: 377.
- [3] 臧晴, 邹润, 侯进永, 等. 一种判断卫星姿态变化的数据处理方法及装置: CN118982736A[P]. 2024-11-19.
- [4] 邹润, 臧晴, 侯进永, 等. 一种分析高轨卫星轨道变化方法及装置: CN118965227A[P]. 2024-11-15.
- [5] SUKHOV P, YEPISHEV V P, MOTRUNICH I I, et al. Using photometric data to describe the behaviour of objects in geostationary orbit[J]. International Journal of Aerospace System Science and Engineering, 2025, 1(2): 157-171.
- [6] LINARES R, FURFARO R, REDDY V. Space objects classification via light-curve measurements using deep convolutional neural networks[J]. The Journal of the Astronautical Sciences, 2020, 67: 1063-1091.

- [7] LI Weixiao, ZHANG Yu, WANG Jianfeng, et al. Detecting anomalies in space-object light curves using temporal-attention LSTM[J]. Space Habitation, 2025, 1(2): 100007.
- [8] DONG Haoqing, ZHANG Xuguo. Intelligent recognition method for space target based on photometric fingerprint features [J]. Spacecraft Recovery & Remote Sensing, 2025, 46(6): 123-135.
董昊卿, 张绪国. 基于光度指纹特征的空间目标智能识别方法[J]. 航天返回与遥感, 2025, 46(6): 123-135.
- [9] MA R. Research on key feature inversion method of space objects based on photometric data from ground observatory[D]. Harbin: Harbin Institute of Technology, 2020: 26-27.
马若. 基于地基光度信号的空间目标关键特征反演方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020: 8-9.
- [10] DU Xiaoping, GENG Wendong, ZHAO Jiguang, et al. Space situational awareness fundamentals[M]. Beijing: National Defense Industry Press, 2017: 97-123.
杜小平, 耿文东, 赵继广, 等. 空间态势感知基础[M]. 北京: 国防工业出版社, 2017: 97-123.
- [11] DU Junju. Photometric data acquisition and analysis of space debris[D]. Shandong: Shandong University, 2022: 26-27.
杜俊举. 空间碎片光度数据的获取与分析[D]. 山东: 山东大学, 2022: 26-27.
- [12] LI Zhi, XU Can, HUO Yurong, et al. Space target optical characteristics: principles and applications[M]. Beijing: Tsinghua University Press, 2024: 107-110.
李智, 徐灿, 霍俞蓉, 等. 空间目标光学特性原理与应用[M]. 北京: 清华大学出版社, 2024: 107-110.
- [13] BOX G E P, JENKINS G M, REINSEL G C. Time series analysis: forecasting and control[M]. WANG Chengzhang, YOU Meifang, HAO Yang, et al., transl. 4th ed. Beijing: China Machine Press, 2011: 328-352.
乔治·博克斯, 格威利姆·詹金斯, 格雷戈里·莱因泽尔. 时间序列分析: 预测与控制[M]. 王成璋, 尤梅芳, 郝杨, 等, 译. 4版. 北京: 机械工业出版社, 2011: 328-352.
- [14] WANG Yang, HU Min, DU Xiaoping, et al. Method for function determination of GEO spin stabilized objects by ground-based photometric data[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 113-119.
王阳, 胡敏, 杜小平, 等. 地基光度数据判定 GEO 自旋稳定目标功能方法[J]. 北京航空航天大学学报, 2025, 51(1): 113-119.
- [15] CHEN Shichao, LUO Feng, HU Chong, et al. Small target detection in sea clutter background based on tsallis entropy of doppler spectrum[J]. Journal of Radars, 2019, 8(3): 344-354.
陈世超, 罗丰, 胡冲, 等. 基于多普勒谱非广延熵的海面目标检测方法[J]. 雷达学报, 2019, 8(3): 344-354.

GEO Satellite Status Analysis Method Based on Photometric Characteristics

LIU Yang, XU Can, ZHANG YaSheng, XU Dixin
(Space Engineering University, Beijing 101416, China)

Abstract: This study aims to develop a robust method for analyzing the attitude status of Geostationary Earth Orbit (GEO) satellites based on photometric data. Due to their high orbital altitude, ground-based telescopes cannot resolve imagery of GEO satellites, making photometric analysis a crucial technique for attitude monitoring. Existing methods primarily rely on time-series analysis but often lack comprehensive multi-dimensional feature extraction and validation. To address this gap, we propose constructing a photometric feature set that integrates time-domain, frequency-domain, and sample entropy characteristics. Furthermore, this study evaluates the classification performance of these features using both traditional machine learning algorithms and deep neural networks. The primary objective is to establish an effective and interpretable feature system that can reliably detect satellite attitude anomalies, thereby providing technical support for practical space situational awareness applications. To achieve this, the research methodology consists of four main components. First, we collected and preprocessed measured photometric data of GEO targets, performing state labeling to create a validated dataset containing both normal and anomalous satellite states. Second, we analyzed the optical scattering characteristics of high Earth orbit space targets to establish a theoretical foundation for feature selection. Based on this analysis, we constructed a multi-dimensional feature set comprising: (1) time-domain features (standard deviation/variance and fluctuation coefficient), which capture statistical characteristics and overall variability of light curves; (2) frequency-domain features (average amplitude, center frequency, and frequency variance),

derived from power spectral density analysis to quantify periodic components and energy distribution patterns; and (3) sample entropy, a nonlinear metric that measures time series complexity and randomness. Third, we implemented five classification algorithms: three traditional machine learning methods (Support Vector Machine, Random Forest, and Decision Tree) and two deep neural network approaches (Bidirectional Long Short-Term Memory and Fully Connected Neural Network). Finally, we conducted controlled experiments to evaluate feature effectiveness through average classification accuracy, comparing single-feature performance, time-domain versus frequency-domain features, and the complete multi-dimensional feature set. Experimental results revealed several key findings regarding feature effectiveness. Frequency-domain features demonstrated superior discriminative power, with average amplitude achieving the highest single-feature classification accuracy of approximately 79.54%, significantly outperforming other individual features. The top three performing features were all frequency-domain characteristics, whereas time-domain features and sample entropy showed notably lower accuracy. Sample entropy performed poorly in this task with average accuracy around 60.25%, approaching random classification levels, likely due to measurement noise in normal satellite data increasing entropy values and obscuring distinctions. When comparing feature categories, frequency-domain features consistently outperformed time-domain features across all algorithms, with accuracy advantages of approximately 16 percentage points: Random Forest achieved 90.03% with frequency-domain features versus 73.40% with time-domain features; FCNN reached 86.04% versus 65.39%. Most importantly, the multi-dimensional feature set integrating time-domain, frequency-domain, and sample entropy characteristics achieved the highest classification performance across all algorithms: Random Forest reached 94.16%, Decision Tree achieved 90.58%, FCNN attained 89.71%, SVM reached 82.31%, and Bi-LSTM achieved 80.43%. This represents improvements of 4–6 percentage points over frequency-domain features alone, demonstrating the complementary nature of multi-dimensional features. These findings demonstrate that frequency-domain characteristics serve as the most reliable indicators for detecting GEO satellite attitude anomalies, with average amplitude identified as the optimal single-feature discriminator. The superior performance of frequency-domain features stems from their direct physical connection to satellite dynamics: normal attitude-stabilized satellites exhibit energy concentrated near zero frequency, while anomalous tumbling motion introduces periodic components that disperse spectral energy—a phenomenon that time-domain statistics cannot adequately capture. Multi-dimensional feature fusion significantly enhances classification performance by integrating complementary information: time-domain features capture overall statistical fluctuations, frequency-domain features quantify periodic structural changes, and nonlinear entropy measures signal complexity. These findings provide practical guidance for space object monitoring: prioritizing frequency-domain features while incorporating complementary dimensions offers the most effective approach for photometric-based satellite state diagnosis. Future work should focus on expanding anomalous state sample diversity and exploring alternative complexity metrics better suited to photometric data characteristics.

Key words: Space object photometry; Satellite attitude anomaly recognition; Photometric data processing; Machine learning; Geostationary earth orbit satellite; Frequency domain features

OCIS Codes: 120.5240; 280.4991; 070.6020

CSTR: 32255.14.gzxb20265508.0804003