

# 基于成本敏感 CNN-BiLSTM 网络的目标可见性预测方法

廖希<sup>1</sup>, 蔺瑞甲<sup>1</sup>, 郑相全<sup>2</sup>, 文凯<sup>1</sup>

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 中国人民解放军 32008 部队, 北京 100141)

**摘要:** 针对传统 SGP4 模型预测目标可见性依赖于实时轨道参数, 导致在非完美星历信息条件下预测精度低、自主能力不足的问题, 立足特定区域的高动态目标, 提出基于成本敏感混合网络的目标可见性预测方法。该方法通过早期融合多源异质数据特征, 构建卷积双向长短期记忆神经网络 (CNN-BiLSTM) 架构, 全面提取高动态目标的空间域几何局部特征及时间域短时依赖特征, 引入成本敏感学习机制解决目标可见性的极端不平衡问题, 实现特定区域的可见窗口精准预测。结果表明, 当极端不平衡比为 1:357 时, 所提方法的精确率和召回率分别为 94.56% 和 97.78%, 优于现有方法, 为空地目标任务规划与防碰撞预警提供技术支撑。

**关键词:** 空天目标; 空间安全保障; 目标可见性预测; 深度学习

**中图分类号:** TN92

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2026061

## Target visibility prediction method based on cost-sensitive CNN-BiLSTM network

Liao Xi<sup>1</sup>, Lin Ruijia<sup>1</sup>, Zheng Xiangquan<sup>2</sup>, Wen Kai<sup>1</sup>

1. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. PLA Unit 32008, Beijing 100141, China

**Abstract:** To address the low accuracy and insufficient autonomy of the traditional SGP4 model in predicting target visibility under non-perfect ephemeris conditions, a cost-sensitive hybrid network-based method was proposed for predicting the visibility of high-dynamic targets in specific regions. This method employed an early fusion of multi-source heterogeneous data features and constructed a CNN-BiLSTM architecture to comprehensively extract spatial geometric local features and temporal short-term dependency features. A cost-sensitive learning mechanism was introduced to address the extreme imbalance in target visibility, enabling accurate prediction of visibility windows in specific regions. The results show that with an extreme imbalance ratio of 1:357, the proposed method achieves a precision of 94.56% and a recall of 97.78%, outperforming existing methods, and provides technical support for space mission planning and collision avoidance warning.

**Keywords:** aerospace target, space safety and security, target visibility prediction, deep learning

### 0 引言

随着在轨航天器与空间碎片数量激增, 空间目标感知与防碰撞预警对目标可见性预测技术提出前所未有的迫切需求, 包括决策支持的准确性、应对

星历不确定性的鲁棒性、多目标协调与资源调度的效率以及预警时效性的敏捷性等。

传统方法主要分为物理仿真法和几何分析快速法。物理仿真法以卫星工具包 (satellite tool kit,

收稿日期: 2026-01-12; 修回日期: 2026-02-14

通信作者: 廖希, liaoxi@cqupt.edu.cn

基金项目: 重庆市自然科学基金资助项目 (No.CSTB2025YITP-QCRC0045)

**Foundation Item:** Chongqing Natural Science Foundation (No.CSTB2025YITP-QCRC0045)

STK) 为代表, 在完美星历条件下具有预测精度高的优点, 但依赖高精度摄动力计算与数值积分计算繁复, 难以适用于大规模动态目标防碰撞预警场景<sup>[1]</sup>。几何分析快速法旨在通过简化空间几何关系提升计算效率。早期方法通过将目标轨迹近似为大圆弧, 基于球面三角学实现解析求解, 确立几何分析快速法基本范式<sup>[2]</sup>。随着研究深入, 方法逐步从纯几何解析向融合数值迭代与插值技术演进, 进一步提升了计算精度与适应范围<sup>[3-4]</sup>。近年来的研究进展则注重将可见性判定转化为函数优化问题, 通过模型简化、计算优化达到精度与效率的平衡<sup>[5-6]</sup>。几何分析快速法虽能显著提升单站可见性的计算效率, 但仅针对“目标-单端站”场景设计, 在面向多端站协同预测时, 未能有效处理多约束间的复杂时空耦合。两类传统方法均高度依赖完美星历信息, 鲁棒性不足, 且缺乏自主学习能力, 难以适应非理想条件下区域目标可见性预测需求。

近年来, 人工智能技术因强大的时序建模、自主学习能力, 为目标可见性预测提供了新的解决方案, 尤其在非完美星历条件下具有巨大潜力。目标可见性预测本质上是一个兼具多源异质特征融合、复杂时序依赖性以及极端类别不平衡性等挑战的任务。多源异质特征融合方面, 预测方法可分为早期融合方法、中期融合方法和基于知识嵌入的融合方法3类。早期融合方法通过在输入层将异质特征直接拼接为统一向量, 实现快速特征整合。中期融合方法为不同异质特征设计专用编码器, 通过注意力机制、门控融合与自适应加权等进行交互融合。基于知识嵌入的融合方法将领域知识与结构化表征相结合, 增强模型对物理约束的建模能力<sup>[7-8]</sup>。时序建模方面, 现有预测方法主要有以循环神经网络(recurrent neural network, RNN)及其改进变体长短期记忆网络(long short-term memory, LSTM)与门控循环单元(gated recurrent unit, GRU)、卷积神经网络(convolutional neural network, CNN)以及Transformer为代表的深度学习模型<sup>[9-12]</sup>。该类方法具有有效建模时间依赖、提取序列局部或全局特征等特点。现有融合方法与时序模型虽在通用任务中表现良好, 却未充分考虑可见性预测中蕴含的强时空几何约束与物理规律, 在极端不平衡条件下对关键可见事件的识别能力有限。不平衡时间序列分类(imbalanced time series classification, ITSC)方面,

该特性主要成因是目标需同时处于双站波束重叠区域, 导致空间约束极其严格, 同时低轨目标飞行速度较快导致飞越该区域的时间窗口极其短暂, 因此在连续时序采样中, “可见”正样本数量远少于“不可见”负样本, 形成高达1:357的极端不平衡比。现有应对方法可分为以下3类。1) 基于数据的方法通过调整样本分布以缓解类别不平衡, 如对多数类进行随机欠采样<sup>[13-14]</sup>。2) 基于算法的方法侧重于修正学习目标, 如成本敏感学习通过在损失函数中为少数类赋予更高的错分代价, 阈值移动通过后处理调整分类器的决策边界<sup>[15-17]</sup>。3) 基于深度学习的混合框架尝试将深度网络与不平衡学习机制融合, 方法演进主要沿着结构复合化与机制协同化两个维度展开: 在结构层面, 研究从早期基于CNN与GRU等单一架构的浅层融合, 逐步发展为LSTM与Transformer等序列模型的深度整合, 以兼顾长期依赖建模与全局上下文感知, 同时, 图神经网络等结构被引入, 以显式建模样本间的高阶关联进行不平衡分类; 在机制层面, 研究方法协同经典不平衡学习策略如成本敏感损失与阈值校准, 形成多层次、自适应的损失调度与决策优化体系<sup>[18-20]</sup>。综上, 尽管这些方法在ITSC任务中取得了进展, 但未充分考虑特定区域目标可见性预测中蕴含的强时空几何约束与物理耦合关系, 针对此类极端稀疏且具有明确物理意义的正样本识别问题, 泛化能力与精度仍有待提升。

为此, 本文针对非完美星历条件下多源异质数据特征融合与极端不平衡对特定区域目标可见性预测带来的挑战, 提出一种基于成本敏感CNN-BiLSTM网络(cost-sensitive CNN-BiLSTM network, CSCLN)的目标可见性预测方法。该方法能够自主挖掘目标运动与双端站构成的特定区域之间的复杂时空约束关系, 为动态空天目标感知与防碰撞预警提供可靠的技术支撑。

本文主要贡献与创新点如下。

1) 提出一种面向极端类别不平衡场景的特定区域目标可见性自主预测新架构。通过融合高精度动力学模型与多源几何约束, 构建了具有显著极端类别不平衡特性的多源异质数据集, 设计了基于早期融合策略的CSCLN目标可见性预测方法。该方法综合利用CNN的空间局部提取能力与双向LSTM的时序依赖建模优势, 并集成重采样、成本

敏感学习及自适应阈值校准三重机制, 协同缓解极端类别不平衡问题, 实现对特定区域目标可见性的精准、高效预测。

2) 在极端不平衡条件下验证了所提方法的优异性能与强泛化能力。在可见性事件类别不平衡比达 1:357 的极端数据集中, 所提方法取得了精确率 94.56%、召回率 97.78%、F1 分数 0.961 4 的先进性能, 显著优于对比方法。在多种典型轨道构型下的结果表明, 所提方法性能保持稳定 (F1 分数均高于 0.93), 显示出良好的泛化性和鲁棒性。系统消融实验进一步证实了所提方法各核心组件的有效性和必要性。

### 1 目标可见性预测问题

目标可见性预测的核心任务是基于历史时序观测数据, 判定目标在未来时段是否处于特定空域范围内的可见状态。其中, 目标涵盖天基网络中的通信卫星、分布式星群等空间目标, 以及空基网络中的低空飞行器、直升机、无人机群等航空目标<sup>[21-22]</sup>。典型的预测结构可分为“目标-单端站”与“目标-双端站”协同两类, 分别如图 1(a)与图 1(b)所示。针对不同网络内的目标特性, 端站采取差异化的配置策略: 空基网络目标通常采用低功率发射与低仰角波束, 天基网络目标则采用高功率发射与高仰角波束, 以适应不同的雷达探测与通信需求。

由于目标飞过特定区域时的动态过程具有显著的时空耦合特性, 其可见性预测可被建模为一个时空序列分类问题。本文考虑由两个端站构成的协同感知网络  $G = \{G_A, G_B\}$  以及一个包含  $M$  个待观测空

天目标的集合  $\mathcal{T} = \{TG_1, TG_2, \dots, TG_M\}$ , 基于历史连续  $L$  个时间步的多维特征序列, 旨在对未来  $K$  个时间步内每个目标是否处于可见状态进行准确预测, 内在关系表示为

$$y_{ij}(t_k, t_{k+s}, \dots, t_{k+s(K-1)}) = F(\{\mathbf{E}_t^{TG}, \mathbf{E}_t^{G_j}\}_{t_{k-L}^{t_{k+s-1}}}) \in \{0, 1\}^K \quad (1)$$

其中,  $\{\mathbf{E}_t^{TG}, \mathbf{E}_t^{G_j}\}_{t_{k-L}^{t_{k+s-1}}}$  表示从时间  $t_{k-L}$  到  $t_{k+s-1}$  目标状态  $\mathbf{E}_t^{TG}$  以及端站观测约束  $\mathbf{E}_t^{G_j}$  的历史时序数据, 作为输入特征;  $y_{ij}(t_k, t_{k+s}, \dots, t_{k+s(K-1)})$  表示对未来  $K$  个时间步内目标可见性的预测序列。具体地,  $y_{ij}(t)$  表示目标  $TG_j$  在未来第  $t$  个时间步对端站  $G_j$  的可见性状态, 其中 1 表示可见, 0 表示不可见。建模过程中采用滑动窗口机制, 窗口长度固定为  $T$ , 滑动步长为  $s$ , 即每次取窗后, 起始时间  $t_k$  向后移动  $s$  步, 以生成连续且覆盖全时段的有效训练样本。

### 2 目标可见性预测方法

针对上述时空序列分类问题, 本节提出 CSCLN 目标可见性预测方法, 其网络模型主要包括输入层、CNN-BiLSTM 架构及输出层 3 个核心模块, 如图 2 所示。

#### 2.1 CNN-BiLSTM 预测架构

特定区域目标可见性预测的核心是准确建模目标轨迹与多观测端站波束覆盖之间复杂的动态时空耦合交互关系, 为此, 本文构建了一种 CNN-BiLSTM 融合预测架构。该架构利用 CNN 有效提取多

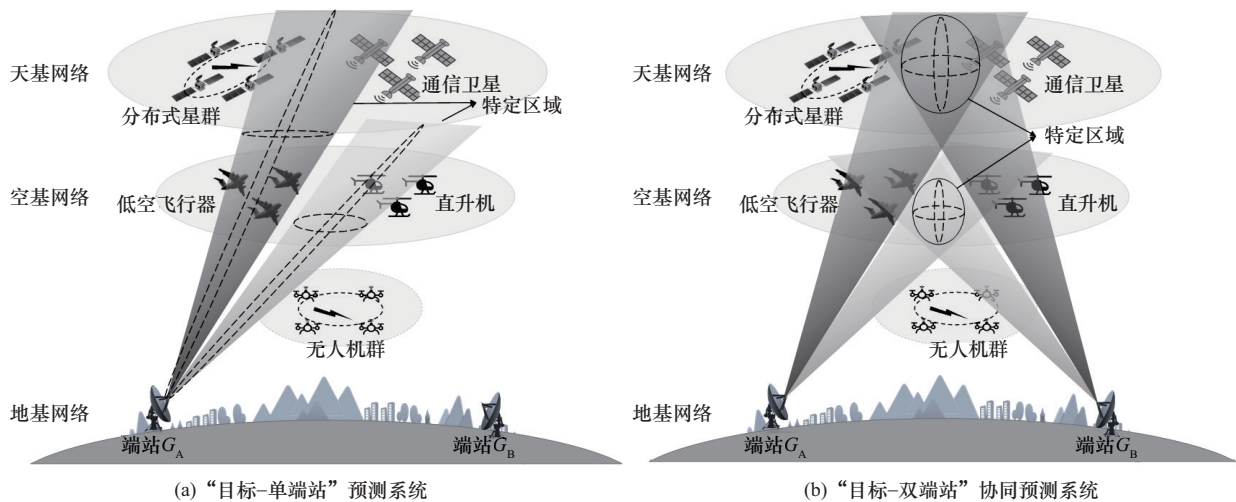


图 1 特定区域目标可见性预测系统示意

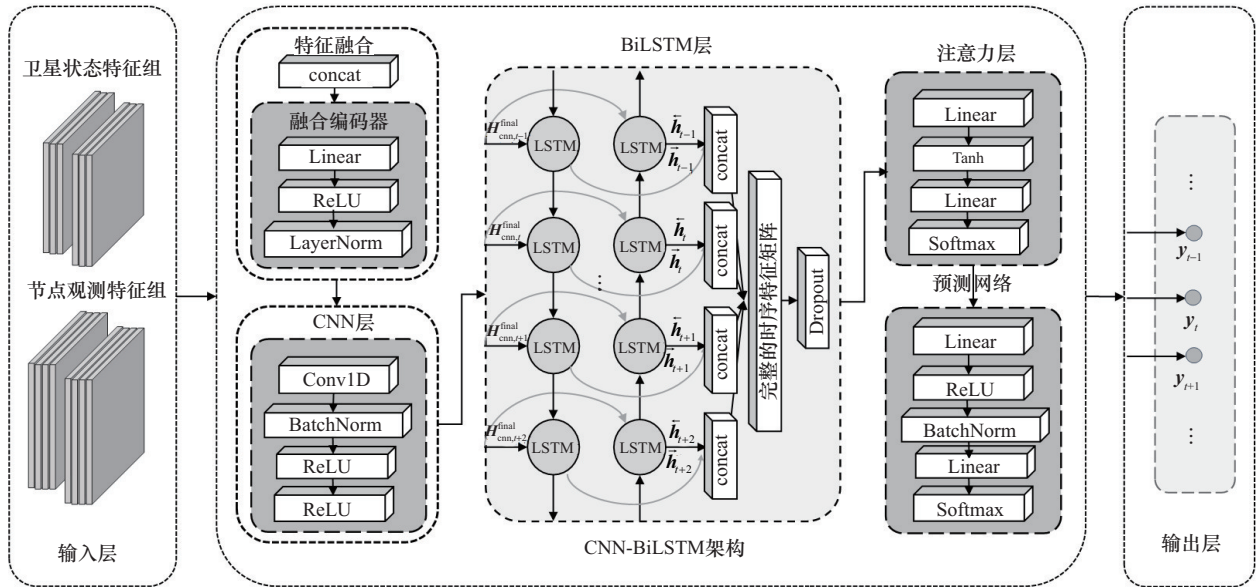


图2 特定区域目标可见性预测模型架构

端站几何约束下的空间局部特征，并借助 BiLSTM 捕捉目标状态演变的时序依赖关系，实现了对目标可见性中严格空间几何约束与快速时序演变规律的联合建模，克服了传统方法或单一网络模型在捕捉此类强时空耦合特性上的不足。

输入特征向量  $\mathbf{X}_t = [\mathbf{E}_t^{\text{TG}}, \mathbf{E}_t^{G_j}] \in \mathbb{R}^{14}$  包含两类信息，其中，目标状态特征组  $\mathbf{E}_t^{\text{TG}} = [x_{\text{ECI}}, y_{\text{ECI}}, z_{\text{ECI}}, i, e, n] \in \mathbb{R}^6$ ， $x_{\text{ECI}}, y_{\text{ECI}}, z_{\text{ECI}}$  为目标在地心惯性坐标系（earth centered inertial, ECI）下的位置， $i, e, n$  为目标轨道参数；端站观测特征组  $\mathbf{E}_t^{G_j} = [\theta_j, \varphi_j, d_j, \text{Beam}_j] \in \mathbb{R}^4$ ， $j \in \{A, B\}$ ， $\theta_j, \varphi_j, d_j, \text{Beam}_j$  分别为目标对  $G_j$  的俯仰角、方位角、链路距离及波束覆盖状态。本文假设各观测站时间已同步，在实际部署中，多观测站之间可通过高精度时间同步系统（如 GPS 授时）实现时间统一。

将 3 个特征组在特征维度上进行拼接，形成融合特征向量  $\mathbf{E}_t^{\text{fused}}$

$$\mathbf{E}_t^{\text{fused}} = \text{concat}(\mathbf{E}_t^{\text{TG}}, \mathbf{E}_t^{G_A}, \mathbf{E}_t^{G_B}) \in \mathbb{R}^{14} \quad (2)$$

通过融合编码器，整合多源信息

$$\mathbf{H}_t^{\text{fused}} = \text{LayerNorm}(\text{ReLU}(\mathbf{W}_{\text{fused}} \cdot \mathbf{E}_t^{\text{fused}} + \mathbf{b}_{\text{fused}})) \in \mathbb{R}^{64} \quad (3)$$

其中， $\mathbf{W}_{\text{fused}} \in \mathbb{R}^{64 \times 14}$ ， $\mathbf{b}_{\text{fused}} \in \mathbb{R}^{64}$ 。通过这种早期融合策略，将同一模态的多源异质特征在输入层进行整合，使模型能够在特征层面建立目标状态与双

端站观测之间的时空映射关系。

对于连续  $L$  个时间步，构建输入张量  $\mathbf{X}$

$$\mathbf{X} = [\mathbf{H}_1^{\text{fused}}, \mathbf{H}_2^{\text{fused}}, \dots, \mathbf{H}_L^{\text{fused}}] \in \mathbb{R}^{B \times L \times 64} \quad (4)$$

其次，模型通过一维卷积网络提取局部时空模式

$$\mathbf{H}_{\text{cnn}} = \text{Conv1D}(\mathbf{X}, \text{kernel} = 3, \text{channels} = 64, \text{padding} = 1, \text{stride} = 1) \in \mathbb{R}^{B \times L \times 64} \quad (5)$$

卷积层隐式学习目标轨道参数与双端站观测几何间的复杂关联，卷积操作后应用批归一化稳定训练过程

$$\mathbf{H}_{\text{cnn}}^{\text{norm}} = \text{BatchNorm}(\mathbf{H}_{\text{cnn}}) \quad (6)$$

通过 ReLU 激活函数引入非线性表达能力

$$\mathbf{H}_{\text{cnn}}^{\text{act}} = \text{ReLU}(\mathbf{H}_{\text{cnn}}^{\text{norm}}) \quad (7)$$

最后应用 Dropout 正则化防止过拟合，丢弃率为 0.4

$$\mathbf{H}_{\text{cnn}}^{\text{final}} = \text{Dropout}_{0.4}(\mathbf{H}_{\text{cnn}}^{\text{act}}) \in \mathbb{R}^{B \times L \times 64} \quad (8)$$

卷积特征  $\mathbf{H}_{\text{cnn}}^{\text{final}}$  经过维度调整后输入双向 LSTM 层，捕捉目标运动的长期演变规律。LSTM 网络采用双层双向结构

$$\vec{\mathbf{h}}_t = \text{LSTM}_{\text{Forward}}(\mathbf{H}_{\text{cnn},t}^{\text{final}}, \vec{\mathbf{h}}_{t-1}), t = 1, 2, \dots, L \quad (9)$$

$$\overleftarrow{\mathbf{h}}_t = \text{LSTM}_{\text{Backward}}(\mathbf{H}_{\text{cnn},t}^{\text{final}}, \overleftarrow{\mathbf{h}}_{t+1}), t = L, \dots, 2, 1 \quad (10)$$

其中， $\vec{\mathbf{h}}_t$  代表前向 LSTM， $\overleftarrow{\mathbf{h}}_t$  代表后向 LSTM。每个时间步的前向和后向隐藏状态拼接形成完整的时序  $\mathbf{H}_{\text{LSTM},t}$

$$\mathbf{H}_{\text{LSTM},t} = \text{concat}(\vec{\hat{\mathbf{h}}}_t, \vec{\hat{\mathbf{h}}}_t) \in \mathbb{R}^{256} \quad (11)$$

完整时序特征矩阵为  $\mathbf{H}_{\text{LSTM}}$

$$\mathbf{H}_{\text{LSTM}} = [\mathbf{H}_{\text{LSTM},1}, \mathbf{H}_{\text{LSTM},2}, \dots, \mathbf{H}_{\text{LSTM},L}] \in \mathbb{R}^{B \times L \times 256} \quad (12)$$

双向 LSTM 能够同时考虑过去和未来的上下文信息, Dropout 层 (丢弃率为 0.4) 有效防止过拟合。

在 LSTM 输出的基础上, 引入时间注意力机制以自适应关注对预测至关重要的历史时间点。注意力机制通过全连接层和 Softmax 实现, 对所有时间步的 LSTM 输出计算统一的注意力权重分布  $\mathbf{A}_{\text{raw}}$

$$\mathbf{A}_{\text{raw}} = \text{FC}_2(\text{Tanh}(\text{FC}_1(\mathbf{H}_{\text{LSTM}}))) \in \mathbb{R}^{B \times K \times 1} \quad (13)$$

其中,  $\text{FC}_1: \mathbb{R}^{256} \rightarrow \mathbb{R}^{64}$ ,  $\text{FC}_2: \mathbb{R}^{64} \rightarrow \mathbb{R}^1$ 。随后在序列维度应用 Softmax 归一化

$$\mathbf{A} = \text{Softmax}(\mathbf{A}_{\text{raw}}, \text{dim} = 1) \in \mathbb{R}^{B \times K \times 1} \quad (14)$$

注意力加权后的上下文向量通过对所有时间步的 LSTM 特征进行加权平均得到

$$\mathbf{C}_t = \sum_{i=1}^{L_h} \mathbf{A}_i \cdot \mathbf{H}_{\text{LSTM},i} \in \mathbb{R}^{B \times 256} \quad (15)$$

该上下文向量  $\mathbf{C}_t$  综合了历史序列中最相关的信息, 作为后续多时间点预测的共享特征表示。

对于每个预测时间点  $t = 1, 2, \dots, K$ , 设计独立的预测网络

$$\hat{y}_t = \sigma(\text{FC}_2(\text{ReLU}(\text{FC}_1(\mathbf{C}_t)))) \in \mathbb{R}^{B \times 1} \quad (16)$$

其中,  $\text{FC}_1: \mathbb{R}^{256} \rightarrow \mathbb{R}^{64}$ ,  $\text{FC}_2: \mathbb{R}^{64} \rightarrow \mathbb{R}^1$ ,  $\sigma$  为 Sigmoid 激活函数。每个预测头包含 Dropout 正则化 (丢弃率为 0.4) 以防止过拟合。

所有预测头的输出在时间维度拼接形成完整的预测向量

$$\hat{\mathbf{Y}} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_K] \in \mathbb{R}^{B \times K} \quad (17)$$

该架构通过独立参数化每个时间点的预测过程, 能够捕捉不同时间点异常模式的差异性。

## 2.2 成本敏感损失函数与优化策略

针对特定区域目标可见性预测任务中存在的极端类别不平衡问题, 传统的二元交叉熵损失函数易导致模型过度偏向多数类 (即非可见窗口状态), 从而严重削弱对少数类 (可见窗口状态) 的识别能力。为此, 本文设计了一种时间级成本敏感损失函数, 并协同自适应阈值校准机制, 通过差异化的误差加权与动态决策边界优化, 显著提升模型对稀

疏可见事件的识别能力。

设训练集中非可见窗口时间点数量为  $N_n$ , 可见窗口时间点数量为  $N_r$ , 总时间点数为  $N = N_n + N_r$ 。基于类别频率的成本敏感权重定义为

$$\alpha = \min\left(\max\left(\frac{N}{2 \cdot N_r}, 1\right), 200\right) \quad (18)$$

$$\beta = \min\left(\max\left(\frac{N}{2 \cdot N_n}, 1\right), 1\right) \quad (19)$$

其中,  $\alpha$  为可见窗口样本的惩罚权重,  $\beta$  为非可见窗口样本的惩罚权重。这种权重设置使可见窗口样本在损失函数中获得显著更高的错分代价, 从而有效缓解类别不平衡带来的建模偏差。

对于批量大小为  $B$ 、预测长度为  $K$  的预测任务, 模型的预测输出为  $\hat{\mathbf{Y}} \in [0, 1]^{B \times K}$ , 真实标签为  $\mathbf{Y} \in \{0, 1\}^{B \times K}$ , 时间级成本敏感损失函数定义为

$$L_{\text{CS}} = -\frac{1}{B \cdot L_p} \sum_{i=1}^B \sum_{j=1}^K \left[ \alpha \cdot y_{ij}(t) \ln(\hat{y}_{ij}(t)) + \beta \cdot (1 - y_{ij}(t)) \ln(1 - \hat{y}_{ij}(t)) \right] \quad (20)$$

其中,  $y_{ij}(t)$  为真实标签,  $\hat{y}_{ij}(t)$  为对应的预测概率。该损失函数针对每个时间点独立计算分类损失, 从而实现了时间点级的精细化优化。

自适应阈值校准机制具体而言是一种基于时间级 F1 分数的阈值优化方法。在验证集上, 模型输出预测概率为  $\hat{\mathbf{Y}}_{\text{val}} \in [0, 1]^{N_{\text{val}} \times K}$ , 真实标签为  $\mathbf{Y}_{\text{val}} \in \{0, 1\}^{N_{\text{val}} \times K}$ 。将所有时间点的预测概率和真实标签展平为一维数组, 在阈值范围  $[0.05, 0.95]$  内以步长 0.005 搜索最优可见窗口判定阈值

$$\tau^* = \arg \max_{\tau \in [0.05, 0.95]} \text{F1}(\mathbf{Y}_{\text{val}}^{\text{flat}}, \mathbb{I}(\hat{\mathbf{Y}}_{\text{val}}^{\text{flat}} > \tau)) \quad (21)$$

其中,  $\hat{\mathbf{Y}}_{\text{val}}^{\text{flat}}$  和  $\mathbf{Y}_{\text{val}}^{\text{flat}}$  分别为验证集所有样本的预测概率和真实标签展平的一维向量,  $N_{\text{val}}$  为验证集样本数量,  $\mathbb{I}(\cdot)$  为指示函数,  $\text{F1}(\cdot)$  为 F1 分数计算函数, 最优阈值  $\tau^*$  用于测试阶段的可见窗口判定。

模型训练采用 AdamW 优化器, 结合权重衰减和梯度裁剪策略, 采用余弦退火学习率调度策略, 学习率变化式为

$$\eta_t = \eta_{\min} + \frac{1}{2}(\eta_{\max} - \eta_{\min}) \left(1 + \cos\left(\frac{T_{\text{cur}}}{\eta_{\max}} \pi\right)\right) \quad (22)$$

其中,  $\eta_{\max}$  和  $\eta_{\min}$  分别为最大和最小学习率,  $T_{\text{cur}}$  为当前训练步数,  $T_{\text{max}}$  为总训练步数。该策略使学习

率平滑下降,有助于模型收敛到更优解。

### 2.3 性能指标

针对极端类别不平衡问题,准确率(Accuracy)指标极易因模型偏向多数类而虚高,无法有效评估模型对关键少数类的捕捉能力。为了全面、客观地评估模型性能,本文使用精确率(Precision)、召回率(Recall)、F1分数(F1-Score)这3种指标评估预测性能,计算式分别为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (23)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (24)$$

$$\text{F1 - Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (25)$$

其中,真正例(TP)指模型正确预测为正例的数量,假正例(FP)指模型错误预测为正例的数量,真负例(TN)指模型正确预测为负例的数量,假负例(FN)指模型错误预测为负例的数量。

## 3 结果分析

本节首先介绍所用的数据集构建过程、数据预处理方法与关键参数配置,然后将本文所提模型与4种典型的基线模型进行对比实验以验证其整体性能优势,最后在不同轨道场景下测试模型的泛化能力,并通过消融实验验证模型中关键组件的有效性。

### 3.1 数据集构建

为构建适用于可见性预测模型训练与评估的数据集,本文提出了一套基于轨道动力学与空间解析几何的目标可见性数据生成方法,如图3所示。




图3 基于轨道动力学与空间解析几何的特定区域目标可见性示意

ECI坐标系以地球质心为原点,不随地球自转。目标和端站 $G_j$ 在ECI坐标系中的位置向量分别为 $\mathbf{r}_{\text{TG}}$ 和 $\mathbf{r}_{G_j}$ ,目标相对于 $G_j$ 的位置向量为 $\boldsymbol{\rho}_j$ ,即

$$\mathbf{r}_{\text{TG}} = [x, y, z]^T \quad (26)$$

$$\mathbf{r}_{G_j} = (R_e + h_j) \begin{bmatrix} \cos\phi_j \cos\lambda_j \\ \cos\phi_j \sin\lambda_j \\ \sin\phi_j \end{bmatrix} \quad (27)$$

$$\boldsymbol{\rho}_j = \mathbf{r}_{\text{TG}} - \mathbf{r}_{G_j} = [\Delta x_j, \Delta y_j, \Delta z_j]^T \quad (28)$$

其中, $\mathbf{r}_{\text{TG}}$ 由空间轨道预报的标准模型SGP4计算得到,该模型在国际上被广泛用于基于两行轨道数据(two-line element set, TLE)的短期轨道预报与可见性分析任务; $\phi_j$ 、 $\lambda_j$ 、 $h_j$ 分别为端站 $G_j$ 的地理纬度、经度和海拔高度; $R_e = 6371 \text{ km}$ 为地球平均半径<sup>[23]</sup>。

对于每个端站,建立以站址为中心的站心坐标系(east-north-up, ENU),转换矩阵 $\mathbf{R}_j^{\text{ECI} \rightarrow \text{ENU}}$ 将ECI坐标转换为端站 $G_j$ 的ENU坐标

$$\begin{bmatrix} E_j \\ N_j \\ U_j \end{bmatrix} = \mathbf{R}_j^{\text{ECI} \rightarrow \text{ENU}}(t) \cdot \boldsymbol{\rho}_j \quad (29)$$

其中,转换矩阵 $\mathbf{R}_j^{\text{ECI} \rightarrow \text{ENU}} = \mathbf{R}_j^{\text{ECEF} \rightarrow \text{ENU}} \cdot \mathbf{R}_j^{\text{Z}(\text{GST})}$ 由两部分组成:绕Z轴旋转的ECI到地心地固坐标系(earth-centered, earth-fixed, ECEF)转换(考虑地球自转),以及从ECEF到ENU的坐标转换。

目标对端站 $j$ 的观测几何用3个参数描述,分别为方位角 $\phi_j$ 、俯仰角 $\theta_j$ 和斜距 $d_j$ 。ECI坐标系到端站坐标系的转换关系由式(30)~式(32)确定。

$$\phi_j = \arctan2(E_j, N_j) \quad (30)$$

$$\theta_j = \arctan\left(\frac{U^{(j)}}{\sqrt{(E_j)^2 + (N_j)^2}}\right) \quad (31)$$

$$d_j = \sqrt{(\Delta x_j)^2 + (\Delta y_j)^2 + (\Delta z_j)^2} \quad (32)$$

其中, $N_j$ 、 $E_j$ 和 $U_j$ 分别为北向、东向和天顶方向的分量。每个端站 $j$ 配置有固定指向的通信波束,中心方向由方位角 $\phi_{G_j}$ 和俯仰角 $\theta_{G_j}$ 定义,波束宽度为 $\theta_{\text{bw}}$ 。 $\theta_{\text{bw}}$ 设为 $90^\circ$ ,目的在于等效模拟相控阵天线

以窄波束进行空域扫描时实现的整体覆盖范围。

目标相对波束中心的角距离计算式为

$$\Delta\theta_j = \arccos \left[ \sin(\theta_{G_j}) \sin(\theta_j) + \cos(\theta_{G_j}) \cos(\theta_j) \cos(\varphi_{G_j} - \varphi_j) \right] \quad (33)$$

目标处于端站 $j$ 波束覆盖范围内的判定条件为

$$\Delta\theta_j \leq \frac{\theta_{bw}}{2} \quad (34)$$

$$\text{Beam}_j = \begin{cases} 1, \Delta\theta_j \leq \frac{\theta_{bw}}{2} \\ 0, \text{其他} \end{cases} \quad (35)$$

可见窗口指目标同时处于两个端站天线波束共同覆盖区域的几何可见状态，定义为二元变量

$$\text{Intersection} = \begin{cases} 1, (\text{Beam}_1 = 1) \cap (\text{Beam}_2 = 1) \\ 0, \text{其他} \end{cases} \quad (36)$$

目标的轨道参数是表征其空间运动特征的关键先验知识，对可见窗口预测具有重要意义。本文从两行轨道数据中提取 3 个核心轨道参数作为输入特征：轨道倾角 $i$ 、偏心率 $e$ 和平均运动 $n$ 。

为构建具有代表性的数据集，本文以星链星座作为预测对象，其公开的两行轨道数据来源于 Celestrak、Space-track 以及太空地图等权威平台<sup>[24-26]</sup>。仿真共选取 40 颗具有不同轨道倾角与运行方向的星链卫星，观测时段为北京时间 2025 年 6 月 1 日至 6 月 14 日（每日 8:00—12:00），共计 14 天。数据采样间隔固定 10 s，最终获得 7 200 个时序样本点。

为进一步验证本文构建的数据集生成方法的准确性，将生成的可见窗口与 STK（版本 11.6）仿真结果进行对比。实验中选取 8 颗涵盖不同轨道倾角与运行方向的卫星，在连续 14 天时段内共捕获

23 个有效可见窗口事件。这两类方法在窗口起止时间、持续时间等方面的对比结果如图 4 所示。

图 4 结果显示，本文方法在可见窗口的起止时间及持续时间与 STK 仿真结果达到毫秒级一致性：起始时间、结束时间和持续时间的平均绝对误差（mean absolute error, MAE）分别为 50.2 ms、45.6 ms 和 95.7 ms，均方根误差（root mean square error, RMSE）分别为 58.7 ms、57.1 ms 和 107.6 ms，且各项相关系数均大于 0.999。同时，持续时间误差约为起止时间误差之和，这主要源于两者仿真机制的差异：STK 采用连续仿真，可精确捕捉进出波束的临界瞬间；本文方法基于离散采样，导致窗口起始检测存在滞后、结束检测出现提前，两者相向偏移，从而使持续时间误差近似为起止时间误差之和。尽管存在毫秒级的固有偏差，但该误差水平在工程应用上完全可接受。更重要的是，本文方法突破 STK 依赖交互式分析的瓶颈，在保持与 STK 相当精度的前提下，实现了可见窗口预测数据的全自动、批量化生成，并能直接输出适用于模型训练的结构化时序特征，为后续模型训练奠定高效、可靠的数据基础。

### 3.2 数据预处理

为消除特征量纲差异对模型训练的影响，本节采用 Z-score 标准化方法对连续型特征进行归一化处理。需要进行标准化的 12 维连续特征包括  $x_{\text{ECI}}, y_{\text{ECI}}, z_{\text{ECI}}, \varphi_j, \theta_j, d_j, i, e, n$ ，排除标准化的 2 维二值特征为  $\text{Beam}_j$  和目标变量  $\text{Intersection}$ 。

针对极端类别不平衡问题，本节设计了序列级动态平衡采样策略，在保持时间序列连续性的前提下缓解类别不平衡问题。首先定义序列级标签，表示预测窗口内是否包含至少一个可见窗口时间点。




图 4 本文方法与 STK 仿真结果的对比验证

$$l_t = \begin{cases} 1, & \sum_{k=1}^K y_{ij}(t) > 0 \\ 0, & \text{其他} \end{cases} \quad (37)$$

基于序列级标签,将训练样本划分为可见窗口序列集  $\mathcal{R} = \mathbf{X}_i | l_i = 1$  和非可见窗口序列集  $\mathcal{N} = \mathbf{X}_i | l_i = 0$ 。为解决正负样本比例失衡问题,采用渐近式平衡采样策略。设初始平衡比为  $r_{\text{init}}$ , 最终平衡比为  $r_{\text{final}}$ , 当前训练轮次为  $e$ , 总训练轮次为  $E$ , 则当前轮次的目标平衡比为

$$r_e = r_{\text{init}} \cdot \left(1 - \frac{e}{E}\right) + r_{\text{final}} \cdot \frac{e}{E} \quad (38)$$

在每个训练轮次  $e$  中,从负样本集中采样  $|\mathcal{R}| \times r_e$  个样本,与所有正样本合并构成该轮次的训练集。这种策略在训练初期使模型专注于学习可见窗口模式,逐步增加非可见窗口样本数量以提升泛化能力。

### 3.3 方法验证

本文基于 Anaconda 科学计算平台搭建预测模型,采用 Python 3.8.8 作为编程语言,并依托 PyTorch 1.10 深度学习框架完成模型实现。实验硬件平台配置为 Intel(R) Xeon(R) Gold 6133 CPU @ 2.50 GHz。模型关键参数配置如下:输入特征维度为 14 维,历史序列长度为 36 个时间步,预测未来 12 个时间步的可见性状态。为了兼顾特征表达能力与计算效率,CNN 采用单层一维卷积结构,卷积核大小为 3,输出通道为 64。为了同时融合前向与后向的时序上下文信息,LSTM 网络采用双向结构,隐藏层维度设为 128。CNN-BiLSTM 混合模型训练采用 AdamW 优化器,初始学习率为 0.000 5,权重衰减为  $1 \times 10^{-4}$ ,批次大小为 32,训练 80 轮并辅以早停机制。为缓解极端类别不平衡问题,损失函数采用时间点级成本敏感损失,其权重根据类别频率自动计算;同时,引入序列级平衡采样器,在训练过程中将采样比例从 1:15 逐步调整为 1:80,使模型渐近适应真实数据分布。验证集保持原始不平衡比,确保评估结果客观可靠。训练集与验证集的划分比例为 7:3。

为全面验证 CSCLN 模型在非完美星历与极端不平衡条件下的有效性与泛化能力,本文选取了 4 种代表性深度学习模型作为对比基准,包括 LSTM-GRU、GRU-CNN、CNN-Transformer 及 LSTM-Transformer<sup>[27-30]</sup>。这些模型均为当前时序预测研究中常用架构,并且能够从不同角度建模时空依赖关系。所有对比实验均在相同环境下进行,采用统一

的评价指标与参数配置原则,其核心超参数配置如表 1 所示。

表 1 预测模型的主要参数配置

模型	激活函数	核函数	Dropout 系数
LSTM-GRU	ReLU	—	0.4
GRU-CNN	ReLU	5	0.35
CNN-Transformer	ReLU+Tanh	3	0.4
LSTM-Transformer	ReLU	—	0.1
CSCLN	ReLU+Tanh	3	0.4

测试集采用与训练集同源的原始不平衡数据集,观测时段为 2025 年 6 月 18 日 8:00—16:00,共计 8 h 连续数据,包含 115 240 个时间点样本,覆盖 40 颗不同轨道特性的星链卫星。其中,正样本(可见)仅 326 个,类别不平衡比达 1:357。数据集划分、特征处理与标准化流程均与训练阶段保持一致,最终生成 113 360 条完整时序样本用于测试。各模型在该测试集上的性能对比如表 2 所示。

表 2 预测模型的结果对比

模型	Precision	Recall	F1-Score	运行效率/ (样本·秒 <sup>-1</sup> )
LSTM-GRU	79.69%	86.17%	0.828 1	<b>109.89</b>
GRU-CNN	79.69%	93.10%	0.858 8	58.39
CNN-Transformer	89.90%	95.76%	0.927 3	46.88
LSTM-Transformer	80.27%	<b>98.06%</b>	0.882 8	12.36
CSCLN	<b>94.56%</b>	97.78%	<b>0.961 4</b>	68.30

由表 2 可知,本文所提 CSCLN 模型在极端不平衡条件下达到了 94.56% 的精确率与 97.78% 的召回率, F1 分数为 0.961 4,体现了模型在控制漏报与误报方面的均衡能力。LSTM-GRU 模型在运行效率上最高(109.89 样本/秒),但 F1 分数仅为 0.828 1。结构复杂的 LSTM-Transformer 虽然召回率较高,但精确率偏低且效率显著下降(12.36 样本/秒)。相比之下,CSCLN 以 68.30 样本/秒的推理速度,在性能与效率之间取得了更优的平衡,验证了所提模型的有效性。

图 5 展示了各模型在测试集上的混淆矩阵。图 6 给出了不同模型的精确率-召回率(precision-recall, PR)曲线,评估了模型在极端不平衡场景下的分类性能。由图 6 可知,CSCLN 的 PR 曲线最贴

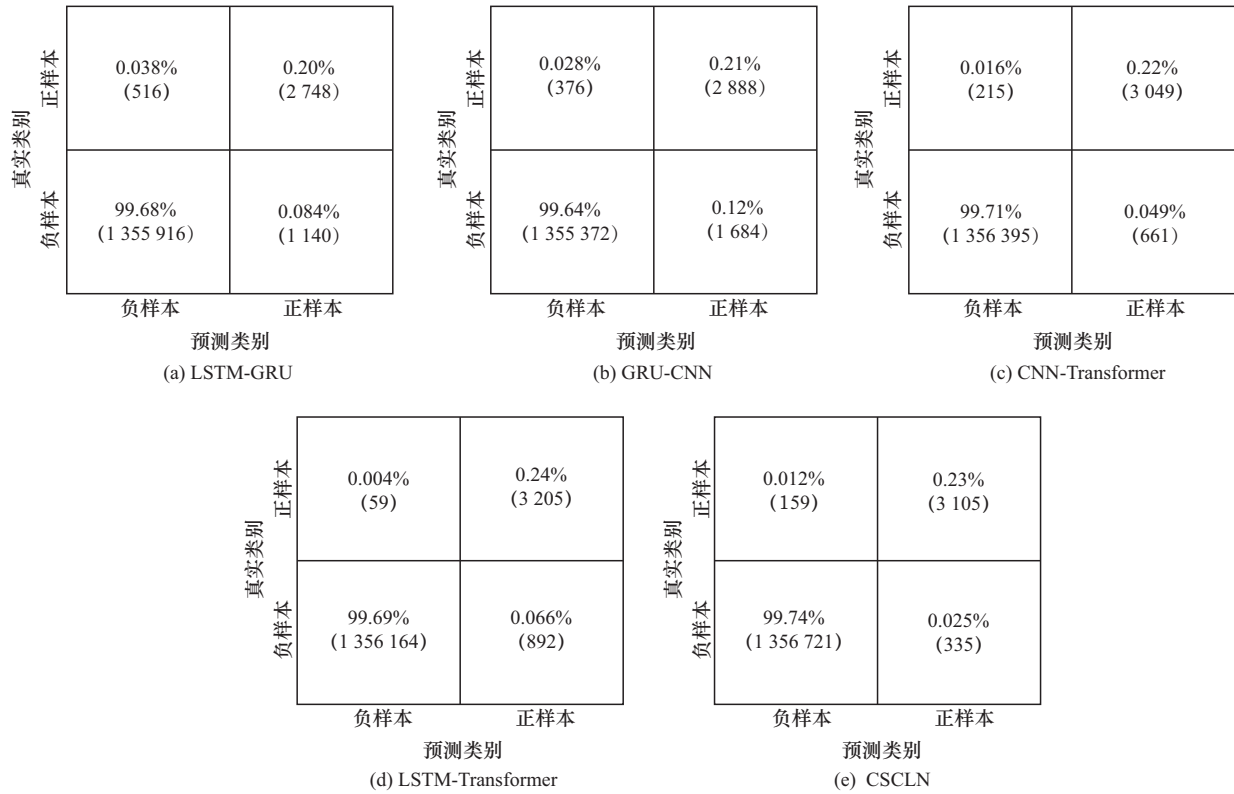


图5 各模型混淆矩阵结果

近右上角，其曲线下面积（average precision, AP）明显高于其他模型。

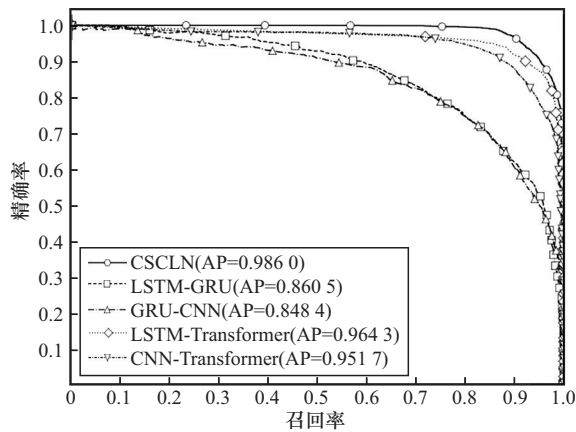


图6 不同模型的PR曲线

为评估所提模型的泛化性能，表3和表4分别给出了不同轨道倾角和不同运行方向下预测模型的泛化性能，其中轨道倾角包括43°、53°、70°、97.6°，运行方向包括西北-东南（简称NW-SE）、西南-东北（简称SW-NE）、东北-西南（简称NE-SW）、东南-西北（简称SE-NW）。

在多样化轨道条件下，CSCLN表现出最优的泛化性能，各场景F1分数始终高于0.93，且波动范围最小（标准差仅为0.013~0.015），优于其他模型。尤其在70°高倾角场景中，CSCLN仍保持97.27%的精确率与0.9493的F1分数，LSTM-GRU、GRU-CNN模型的精确率均低于50%，呈现严重的性能塌陷。

表3 不同轨道倾角下预测模型的泛化性能

模型	Precision				Recall				F1-Score			
	43°	53°	70°	97.6°	43°	53°	70°	97.6°	43°	53°	70°	97.6°
LSTM-GRU	89.81%	69.02%	46.32%	85.44%	82.52%	79.04%	91.67%	92.24%	0.860 1	0.736 9	0.615 4	0.887 1
GRU-CNN	81.17%	82.99%	35.74%	89.66%	95.06%	81.94%	92.71%	97.07%	0.875 7	0.824 7	0.515 9	0.932 2
CNN-Transformer	91.95%	88.76%	65.50%	91.49%	96.90%	93.06%	88.02%	97.07%	0.943 6	0.919 0	0.751 1	0.942 0
LSTM-Transformer	79.77%	69.96%	74.51%	88.20%	<b>98.30%</b>	<b>98.48%</b>	<b>98.96%</b>	97.52%	0.880 7	0.818 0	0.850 1	0.926 3
CSCLN	<b>95.12%</b>	<b>89.07%</b>	<b>97.27%</b>	<b>96.75%</b>	97.71%	97.73%	92.71%	<b>98.47%</b>	<b>0.964 0</b>	<b>0.932 0</b>	<b>0.949 3</b>	<b>0.976 0</b>

表4 不同运行方向预测模型的泛化性能

模型	Precision				Recall				F1-Score			
	NW-SE	SW-NE	NE-SW	SE-NW	NW-SE	SW-NE	NE-SW	SE-NW	NW-SE	SW-NE	NE-SW	SE-NW
LSTM-GRU	87.15%	81.35%	83.66%	87.29%	86.20%	80.08%	92.56%	91.92%	0.866 8	0.807 1	0.878 9	0.895 4
GRU-CNN	76.07%	77.26%	91.91%	87.53%	92.08%	91.67%	97.56%	96.59%	0.833 1	0.838 5	0.946 5	0.918 4
CNN-Transformer	86.15%	91.01%	91.47%	91.51%	96.86%	92.94%	97.56%	96.59%	0.911 9	0.919 6	0.944 2	0.939 8
LSTM-Transformer	84.61%	75.52%	88.89%	87.51%	<b>98.36%</b>	<b>96.75%</b>	<b>99.49%</b>	95.58%	0.909 7	0.848 3	0.938 9	0.913 7
CSCLN	<b>94.99%</b>	<b>92.82%</b>	<b>96.87%</b>	<b>96.63%</b>	<b>98.36%</b>	<b>96.75%</b>	99.10%	<b>97.85%</b>	<b>0.966 4</b>	<b>0.947 4</b>	<b>0.979 7</b>	<b>0.972 4</b>

### 3.4 消融实验

为明确CSCLN模型中CNN层、LSTM层及成本敏感损失函数对目标可见性预测的贡献,表5给出了所提模型的消融实验结果,其中方案1为去除CNN层,方案2为去除LSTM层,方案3为去除成本敏感损失函数。

表5 消融实验结果

模型	Precision	Recall	F1-Score	运行效率/ (样本·秒 <sup>-1</sup> )
方案1	86.33%	94.48%	0.902 2	67.01
方案2	77.49%	98.14%	0.866 0	141.11
方案3	96.17%	92.48%	0.942 9	65.37
本文方法	94.56%	97.78%	0.961 4	65.55

由表5可知,方案1的精确率下降至86.33%,F1分数下降至0.902 2,验证了CNN在局部时空特征提取中的重要作用;方案2虽将运行效率提升至141.11样本/秒,但精确率下降至77.49%,F1分数下降至0.866 0,验证了LSTM在建模时序依赖性方面的关键作用;方案3虽使精确率提升至96.17%,但召回率下降至92.48%,F1分数下降至0.942 9,验证了成本敏感学习机制在极端类别不平衡情况下对少数类识别的重要性。本文方法在保持运行效率(65.55样本/秒)的同时,实现了94.56%的精确率、97.78%的召回率以及0.961 4的F1分数,取得了最优的均衡性能,充分证明了该模型架构设计的有效性及各组件间的互补增强效应。

## 4 结束语

针对非完美星历条件下特定区域高动态目标可见性预测难题,本文提出了一种基于成本敏感CNN-BiLSTM网络的自主预测方法。该方法通过融合空间域局部几何特征与时间域短时依赖特征,

并引入三重不平衡学习机制,有效应对了极端类别不平衡带来的挑战。结果表明,当样本不平衡比高达1:357时,所提方法取得了精确率94.56%、召回率97.78%、F1分数0.961 4的优异性能,显著优于现有对比模型。在多轨道场景测试中,所提模型表现出良好的泛化性与稳定性,消融实验进一步验证了各核心组件的有效性及其协同作用。需要指出的是,本文工作主要针对无显著物理遮挡的空天目标,未来研究将围绕模型轻量化部署、多目标协同预测、动态星历实时更新、面向实际传感器数据的鲁棒性增强,以及面向低空遮挡环境的多站协同与地理信息融合等方向展开,为空天态势感知与防碰撞预警提供更高效可靠的解决方案。

### 参考文献:

- [1] 徐川,张汝凤,何熊文,等.卫星编队流调度的门控对齐策略研究[J].通信学报,2024,45(8):51-61.  
Xu C, Zhang R F, He X W, et al. Research on gating alignment strategy for flow scheduling in satellite formation[J]. Journal on Communications, 2024, 45(8): 51-61.
- [2] Ali I, Al-Dhahir N, Hershey J E. Predicting the visibility of LEO satellites[J]. IEEE Transactions on Aerospace and Electronic Systems, 1999, 35(4): 1183-1190.
- [3] Tang R F, Yi D Y, Zhu J B, et al. TAIC algorithm for the visibility of the elliptical orbits' satellites[C]//Proceedings of the 2007 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2007: 781-785.
- [4] Gu Y, Han C, Wang X W. A Kriging based framework for rapid satellite-to-site visibility determination[C]//Proceedings of the 2019 IEEE 10th International Conference on Mechanical and Aerospace Engineering (ICMAE). Piscataway: IEEE Press, 2019: 262-267.
- [5] Ortigueira R, Montejo-Sánchez S, Henn S, et al. Satellite visibility prediction for constrained devices in direct-to-satellite IoT systems[J]. IEEE Sensors Journal, 2024, 24(16): 26630-26644.
- [6] Feng B H, Wang X Y, Meng K, et al. Rapid satellite-ground station visibility determination for LEO constellation networks[J]. IEEE Wireless Communications Letters, 2025, 14(10): 3289-3293.
- [7] Pereira L M, Salazar A, Vergara L. A comparative analysis of early and

- late fusion for the multimodal two-class problem[J]. IEEE Access, 2023, 11: 84283-84300.
- [8] Liu J, Du H, Guo R, et al. MMGK: multimodality multiview graph representations and knowledge embedding for mild cognitive impairment diagnosis[J]. IEEE Transactions on Computational Social Systems, 2024, 11(1): 389-398.
- [9] Yadav H, Thakkar A. NOA-LSTM: an efficient LSTM cell architecture for time series forecasting[J]. Expert Systems with Applications, 2024, 238: 122333.
- [10] Duduku H V, Taskiran M, Cam Taskiran Z G, et al. Temporal Convolutional Networks with RNN approach for chaotic time series prediction[J]. Applied Soft Computing, 2023, 133: 109945.
- [11] Kong X J, Chen Z H, Liu W Y, et al. Deep learning for time series forecasting: a survey[J]. International Journal of Machine Learning and Cybernetics, 2025, 16(7/8): 5079-5112.
- [12] Li W X, Eddie Law K L. Deep learning models for time series forecasting: a review[J]. IEEE Access, 2024, 12: 92306-92327.
- [13] Saripuddin M, Suliman A, Syarmila Sameon S, et al. Random undersampling on imbalance time series data for anomaly detection[C]//Proceedings of the 2021 The 4th International Conference on Machine Learning and Machine Intelligence. New York: ACM Press, 2021: 151-156.
- [14] Zhu H H, Zhou M C, Liu G J, et al. NUS: noisy-sample-removed undersampling scheme for imbalanced classification and application to credit card fraud detection[J]. IEEE Transactions on Computational Social Systems, 2024, 11(2): 1793-1804.
- [15] Hu Z H, Wu W, Yang Z Q, et al. A cost-sensitive small vessel detection method for maritime remote sensing imagery[J]. Remote Sensing, 2025, 17(14): 2471-2494.
- [16] Zhang C, Tan K C, Li H Z, et al. A cost-sensitive deep belief network for imbalanced classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(1): 109-122.
- [17] Seng Z A, Kareem S A, Varathan K D. A neighborhood undersampling stacked ensemble (NUS-SE) in imbalanced classification[J]. Expert Systems with Applications, 2021, 168: 114246.
- [18] Wang X F, Zhang Y, Bai N N, et al. Class-imbalanced time series anomaly detection method based on cost-sensitive hybrid network[J]. Expert Systems with Applications, 2024, 238: 122192.
- [19] Liu C, Guan D H, Yuan W W, et al. ITS2Graph: Graph-based generative adversarial learning for imbalanced time series classification[J]. Neural Networks, 2025, 191: 107770.
- [20] Modé P, Demartino C, Georgakis C T, et al. Short-term extreme wind speed forecasting using dual-output LSTM-based regression and classification model[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2025, 259: 106035.
- [21] Yan B B, Wei Y X, Liu S X, et al. A review of current studies on the unmanned aerial vehicle-based moving target tracking methods[J]. Defence Technology, 2025, 51: 201-219.
- [22] Mohamed E M, Ahmed Alnakhli M, Fouda M M. Joint UAV trajectory planning and LEO-sat selection in SAGIN[J]. IEEE Open Journal of the Communications Society, 2024, 5: 1624-1638.
- [23] Kelso T S. Validation of SGP4 and IS-GPS-200D against GPS precision ephemerides[R]. Colorado Springs: Center for Space Standards & Innovation, 2007.
- [24] CelesTrak. NORAD two-line element sets homepage [EB]. [2025-01-31].
- [25] Space-track. The source for space situational awareness data [EB]. [2026-01-31].
- [26] SpaceMapper. 数据格式与轨道类型支持说明 [EB]. [2026-01-31]. SpaceMapper. Data format and orbit type support documentation [EB]. [2026-01-31].
- [27] Liu X L, Lin Z, Feng Z M. Short-term offshore wind speed forecast by seasonal ARIMA - A comparison against GRU and LSTM[J]. Energy, 2021, 227: 120492.
- [28] Zhang L Z, Li J T, Tang Z J, et al. A gate recurrent unit based convolutional neural network approach for pharmacokinetic parameter reconstruction[C]//Proceedings of the 2025 IEEE 22nd International Symposium on Biomedical Imaging (ISBI). Piscataway: IEEE Press, 2025: 1-4.
- [29] Izadi M A, Hajizadeh E. Time series prediction for cryptocurrency markets with transformer and parallel convolutional neural networks[J]. Applied Soft Computing, 2025, 177: 113229.
- [30] Kabir M R, Bhadra D, Ridoy M, et al. LSTM-transformer-based robust hybrid deep learning model for financial time series forecasting[J]. Sci, 2025, 7(1): 7.

## [作者简介]



廖希 (1988-), 女, 四川绵阳人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为面向 6G 新场景新频段的电波传播与信道建模、广域无线通信、散射反射通信。



藺瑞甲 (2003-), 女, 甘肃庆阳人, 重庆邮电大学硕士生, 主要研究方向为无线通信。



郑相全 (1972-), 男, 四川内江人, 博士, 中国人民解放军 32008 部队高级工程师, 主要研究方向为无线通信。



文凯 (1972-), 男, 重庆人, 博士, 重庆邮电大学正高级工程师、硕士生导师, 主要研究方向为无线移动通信网络、图像视觉、电波传播。