

# 基于 YOLOv11s 模型的地球磁层千米连续波识别

李萍<sup>1</sup> 张赛<sup>1\*</sup> 李德强<sup>1</sup> 王思琪<sup>2</sup> 王佳樊<sup>2</sup> 李东阳<sup>2</sup> 刘雅婧<sup>2</sup> 姚柳邑<sup>2</sup>

<sup>1</sup> (长沙理工大学物理与电子科学学院 长沙 410114)

<sup>2</sup> (长沙理工大学人工智能学院 长沙 410114)

**摘要** 千米连续波是地球磁层中广泛存在的一种电磁波，在磁层-电离层-大气层的耦合过程中起重要作用，从卫星的频谱数据中识别千米连续波是对其进行科学研究的基础。针对传统程序化识别方法存在抗干扰能力弱、识别精度低、扩展性差等问题，本文提出一种基于深度学习的磁层千米连续波自动识别方法。该方法以 YOLOv11s 为基础模型，结合卫星频谱图特征设计三通道预处理策略，将原始频谱强度、频率梯度和频率位置编码分别作为独立通道输入，为模型提供频域位置信息与边缘结构特征；采用频率平移和强度缩放的频谱增强技术扩充了训练集，提升模型对波形形态变化的鲁棒性；最后通过加权框融合集成三个独立训练模型的预测结果，抑制单个模型带来的决策偏差。在自制数据集上的实验结果表明，该方法的精确率和召回率调和平均值（F1 值）达到了 87.1%，较基线方法提升了 6.7 个百分点。消融实验显示，三通道处理与频域增强共同贡献了 4.9 个百分点，加权框融合进一步贡献了 1.8 个百分点。本文提出的方法能够有效减少千米连续波的误判和漏判，为自动识别千米连续波提供了可靠的技术支撑。

**关键词** 千米连续波; YOLOv11s; 三通道预处理; 频谱增强策略; 加权框融合  
中图分类号 P354

## Identification of Kilometric Continuum in the Magnetosphere Based on the YOLOv11s

LI Ping<sup>1</sup> ZHANG Sai<sup>1\*</sup> LI Deqiang<sup>1</sup> WANG Siqu<sup>2</sup> WANG Jiafan<sup>2</sup> LIU Yajing<sup>2</sup> YAO Liuyi<sup>2</sup>

<sup>1</sup>(School of Physics and Electronic Sciences, Changsha University of Science and Technology, Changsha, 410114)

<sup>2</sup>(School of Artificial Intelligence, Changsha University of Science and Technology, Changsha, 410114)

**Abstract** Kilometric Continuum (KC) is a type of electromagnetic wave widely present in Earth's magnetosphere and plays a significant role in the coupling of the magnetosphere, ionosphere, and atmosphere. Identifying KC from satellite spectrogram data is fundamental to scientific study. To address the limited accuracy, susceptibility to interference, and lack of scalability of traditional methods, this paper proposes a deep learning-based approach for identifying KC in the magnetosphere. The proposed method employs YOLOv11s as the base model and introduces

a three-channel preprocessing strategy tailored to the characteristics of satellite spectrograms, in which the raw spectral intensity, frequency gradient, and frequency positional encoding are fed as independent input channels to

国家自然科学基金重点项目资助（42230209）

2026-06-05 收到原稿，2026-08-07 收到修定稿

provide the model with frequency-domain positional information and edge structure features. A spectrum augmentation technique incorporating frequency shifting and intensity scaling is adopted to expand the training dataset, thereby enhancing the model's robustness against variations in waveform morphology. Furthermore, weighted box fusion (WBF) is applied to integrate the predictions from three independently trained models, thereby

mitigating decision biases associated with individual models. Experimental results on a self-constructed dataset demonstrate that the proposed method achieves an F1 score of 87.1%, representing an improvement of 6.7 percentage points over the baseline method. Ablation studies reveal that the three-channel processing combined with frequency-domain augmentation contributes 4.9 percentage points collectively, while weighted box fusion contributes an additional 1.8 percentage points. The proposed method can effectively reduce both false positives and missed detection rates of KC, providing reliable technical support for the automatic identification of KC.

**Key words** Kilometric Continuum; YOLOv11s; three-channel preprocessing; a spectrogram enhancement; weighted box fusion

## 0 引言

千米连续波（Kilometric Continuum，简称 KC）是 Hashimoto 等人在 1999 年命名的一种绝热连续辐射，其频率范围在 10~800 kHz，属于窄带电磁波，持续时间可达数小时，甚至是更久，中心频率变化相对较小，波动较为稳定<sup>[1]-[2]</sup>。在同样的高频范围内，还存在另一种电磁波：极光千米波（Auroral Kilometric Radiation，简称 AKR），它是一种宽带电磁波，持续时间不定，是一种间歇性辐射，中心频率会随时间随机变化<sup>[3]-[9]</sup>。前人研究表明 KC 可以传播到高纬度地区，并与能量电子相互作用导致电子沉降，从而产生 X 射线，因此正确区分这两种高频电磁波成为关键工作。传统方法主要是人工或利用波形特征编写的自动计算程序进行筛选，这种方法存在易受背景干扰、识别不准确和扩展性不高等问题。

高频电磁波的数据主要来源于卫星，比如 IMAGE、GEOTAIL、范艾伦探测器等<sup>[10]</sup><sup>[11]</sup>。其中，范艾伦探测器（又称 RBSP）于 2012 年 8 月 30 日发射，由配置相同、轨道相近的两颗卫星（RBSP-A 和 RBSP-B）组成，近地点高度约为 600 公里，远地点高度约为 31,000 公里，轨道倾角为 10°。RBSP 搭载的 EMFISIS 仪器中高频接收器采集了丰富的电场功率谱密度数据，频率覆盖范围为 10 kHz 至 500 kHz<sup>[12]-[13]</sup>。RBSP 的观测数据记录了各种类型的电磁波，例如：AKR、KC、太阳 III 型辐射等。目前传统的数据处理方法效率较低，随着深度学习的快速发展，为高效识别不同类型电磁波提供了新的技术手段，其应用已经覆盖了很多前沿领域<sup>[14]-[22]</sup>。例如，Chen 等人基于 TIEGCM 模型和神经网络，为实现实时监测电离层-热层系统中多尺度动态变化的关键参数提供了可扩展的方法<sup>[23]</sup>；Cristian Omat 等人基于 YOLOv12 模型对全天相机图像中的空间目标进行自动检测与分类<sup>[24]</sup>；Haiying Zhang 等人提出基于 YOLOv8s 改进的目标检测模型（YOLO-Dynamic），用于南极天文观测站拍摄的空间动态目标（如近地小行星、空间碎片）的实时检测<sup>[25]</sup>；Qian Wang 等人基于 Mask R-CNN 模型提出一种弱监督目标检测方法，用于自动检测全天空极光图像中极光涡旋结构<sup>[26]</sup>；夏凯等人提出基于迁移学习和 EfficientNetB2 网络用于自动识别太空台风<sup>[27]</sup>；王鹤野等人基于 VGG16 和自注意力机制实现对 AKR 存在性的二分类判断<sup>[28]</sup>；宋小健等人开发了一种全自动模型来识别日下点附近的磁层顶穿越事件<sup>[29]</sup>；蒋家楠等人采用深度学习方法，提出了一种基于 CBAM 注意力的 EfficientNet 来识别极光亚暴爆发时点<sup>[30]</sup>；Chen 等

人利用深度学习模型重建了高能电子沉降的全球动态演化过程<sup>[31]</sup>。

现有深度学习方法在空间物理目标检测领域取得了良好效果，但频谱图具有频率轴、时间轴和强度分布等独特特性，现有的方法未针对这些特性进行专门设计，且没有针对磁层中 KC 的识别研究。为此，本文提出一种基于 YOLOv11s 的 KC 自动识别方法，通过设计预处理、数据增强策略和加权框融合方法，实现对磁层中 KC 的准确识别，为磁层中的高频电磁波研究提供了有力的技术支撑。

## 1 数据集来源

本文采用 RBSP 所搭载的 EMFISIS 仪器中高频接收器的数据，该仪器在 2012 年至 2019 年期间探测了丰富的电场功率谱密度（Power Spectral Density, PSD）数据。对原始卫星数据进行初步的处理，仅去除低于上混杂频率（黑色实线）的功率谱密度数据以及功率谱密度低于  $10^{-16} \text{ V}^2/\text{m}^2/\text{Hz}$  的数据。生成频谱图前经过了以 10 为底的对数变换，即图像像素值直接表示  $\log_{10}(\text{PSD})$ 。图 1 展示了卫星原始数据绘制的频谱图（a）和经过处理后的频谱图（b）。图中横坐标是时间，纵坐标是频率，颜色代表功率谱密度大小。每一张频谱图对应同一天内同一卫星轨道的连续观测，因此不同频谱图之间不存在同日期或相邻轨道的重叠。




图 1 (a)卫星数据绘制的原始频谱图；(b)处理后的频谱图

Fig.1 (a)Original spectrogram generated from satellite data; (b) Processed spectrogram

本文采用 Labelme 图像标注工具对选取的频谱图进行人工标注，以矩形边界框来标记目标的位置，标注内容包括 KC 及其他频谱事件（AKR）。KC 事件的判别依据为：窄带信号，持续时间较长，功率谱密度随频率变化缓慢，形态上较为稳定。AKR 事件的判别依据为：宽带信号，持续时间不定，功率谱密度随频率变化较大，形态上较为杂乱。两者均由人工根据功率谱密度的形态特征进行矩形框标注。本文从 2012 年-2015 年的频谱图中随机挑选了 700 张频谱图来构建数据集，划分为训练集 600 张和验证集 100 张。700 张频谱图均包含至少一个标注目标，无纯背景样本。其中训练集（600 张）中仅含 KC 的样本 210 张、仅含 AKR 的样本 95 张、同时含 KC 和 AKR 的样本 295 张，共包含标注实例 5736 个（KC：2355 个、AKR：3381 个）；验证集（100 张）中仅含 KC 的样本 25 张、仅含 AKR 的样本 4 张、同时含 KC 和 AKR 的样本 71 张，共包含标注实例 425 个（KC：139 个、AKR：286 个）。图 2 显示了不同情况的标注示例，图 2a-图 2c 分别为仅含 KC、仅含 AKR 和 AKR 与 KC 并存的情况。本文主要关注 KC 的检测结果，AKR 作为辅助类别用于验证模型对不同类型电磁波的泛化能力。




图 2 数据集标注示例图。(a)KC 的标注图；(b)AKR 的标注图；(c)KC 和 AKR 同时存在的标注图

Fig.2 Examples of dataset annotation. (a) Annotation of KC; (b) Annotation of AKR; (c) Annotation of coexisting KC and AKR

## 2 方法

本文提出的 KC 自动识别方法流程图如图 3 所示。首先对原始频谱图进行三通道预处理，主要包括频谱强度、频率梯度和频率位置编码的三通道输入图像；然后通过离线数据增强的方法扩充训练集，主要使用频率方向平移和强度缩放的手段来做数据增强；将处理后的数据集输入到 YOLOv11s 模型，使用三个不同超参数配置训练模型；最后使用加权框融合（Weighted Box Fusion, WBF）结合三个模型的预测结果。各模块的具体实现将在后续详细阐述。




图 3 自动识别方法流程图

Fig.3 Flowchart of the proposed automatic identification method

### 2.1 YOLOv11s 模型

YOLOv11 是 Ultralytics 公司发布的实时目标检测模型，在继承前代 YOLO 系列优势的基础上，对网络架构与训练策略进行了优化。图 4 展示了 YOLOv11 的网络结构图，该模型以 CSPDarknet 网络为设计基础，主干网络由基础卷积模块（Conv）、核心特征提取模块（C3K2）、下采样模块（SPPF）和空间注意力机制（C2PSA）构成，通过层级化堆叠形成多阶段特征金字塔，实现多尺度特征提取来捕捉不同尺度的目标。该架构采用跨阶段部分连接策略，在减少了冗余计算的同时保持了高效的特征提取能力。YOLOv11 支持图像分类、目标检测、实例分割、旋转框检测和姿态关键点估计等多种视觉任务，并提供 x、l、m、s 和 n 五种不同规模的模型。本文选用的就是 YOLOv11s 模型来做基线模型，以平衡检测精度与计算效率。



$$I_2 = |I_1 * K_y| \quad (3)$$

$$K_y = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (4)$$

其中  $K_y$  为 Sobel 算子的垂直方向卷积核，\* 表示卷积运算。该算子沿频率方向计算差分，能够有效检测信号强度在频率方向上的变化，突出 KC 的边界特征。

### 2.2.3 通道 3：频率位置编码

采用基于整图高度的线性频率位置编码。对于高度为  $H$  的频谱图，第  $i$  行像素位置编码为：

$$I_3(i, j) = \frac{i}{H-1} \times 255, i \in [0, H-1] \quad (5)$$

编码值从图像顶部（0）到底部（255）线性渐变，而在原始频谱图上，高频率在图像的上面，低频率反之。因此较小的编码值对应较高频率区域，较大的编码值对应较低频率区域。该通道为模型提供了功率谱密度在频率轴上的相对位置，有助于模型区分高频和低频区域。

### 2.2.4 三通道合成

本文将上述三个通道预处理的结果作为独立通道，合并为三通道特征图  $I=[I_1, I_2, I_3]$ ，对应了能量分布、边界特征和频率位置。该方法与传统的 RGB 三通道或者单通道灰度图相比，为模型提供更明确的物理可解释性，从而避免网络从数据中隐式学习频域特征。合并后的三通道特征图作为 YOLOv11s 的网络输入，替代了原来的 RGB 三通道输入。图 5 展示了三通道预处理的效果示例，其中图 5a-图 5d 分别为原始 RGB 彩色频谱图、能量分布通道（通道 1）、边界特征通道（通道 2）和频率位置编码通道（通道 3）。




图 5 三通道预处理效果图。(a)原始频谱图；(b)通道 1：灰度图；(c)通道 2：频率梯度图；(d)通道 3：频率位置编码图

Fig.5 Visualization of the three-channel preprocessing. (a) Original spectrogram; (b) Channel 1: Grayscale image; (c) Channel 2: Frequency gradient image; (d) Channel 3: Frequency position

## 2.3 数据增强策略

由于训练样本数量有限，直接训练模型容易过拟合，为此本文设计了两种频域专业数据增强策略，对训练集进行扩展<sup>[34][35]</sup>。

(1) 强度缩放：卫星在不同轨道位置的观测距离及仪器增益变化，可能会导致接收到的信号强度有所不同。为模拟这种情况，将频谱图像素值乘以 0.8~1.2 的随机缩放系数，让模型可以适应不同强度的频谱信号。

(2) 频率平移：将频谱图沿频率轴方向随机循环平移，平移量在图像高度的 $\pm 10\%$ 范围内均匀取值，同时同步调整标注框坐标。经实测，频谱图有效数据区距上边界 52 像素、距下边界 44 像素， $\pm 10\%$ 的平移量（约 $\pm 59$  像素）仅将数据区边缘推入坐标轴空白区域，不会导致生成现实观测中不存在的频谱结构。同时，三通道输入中的频率位置编码通道始终为模型提供绝对频率位置参照，确保模型不会因图像内容平移而混淆 KC 和 AKR 的类别判定。

以上两种操作分别以 50% 的概率随机应用在每张训练图像上，每张原始图像会随机生成 2 个增强版本，增强后的图像与原图构成扩展训练集，训练样本从 600 张扩充到 1800 张。

## 2.4 WBF 集成方法

在推理阶段，本文采用加权框融合（Weighted Box Fusion, WBF）方法对多个训练模型的检测结果进行融合，充分利用多个模型在不同初始化条件和超参数设置下学到的互补特征<sup>[36]</sup>。WBF 与传统的非极大值抑制（Non-Maximum Suppression, NMS）不同，NMS 仅保留得分最高的框而丢弃其余重叠框，而 WBF 则收集多个模型所有的预测框，按照类别分组预测框，将 IOU 超过阈值的预测框归为同一融合组，对组内所有框的坐标按置信度加权平均，生成融合后的最终预测框。对于融合组  $F$  内  $n$  个预测框  $(B_1, B_2, \dots, B_n)$ ，其坐标计算方式如下：

$$F_{coord} = \frac{\sum_{k=1}^n w_k \cdot s_k \cdot B_{k,coord}}{\sum_{k=1}^n w_k \cdot s_k} \quad (6)$$

其中  $coord \in \{x1, y1, x2, y2\}$ ， $w_k$  是第  $k$  个预测框所属模型的权重， $s_k$  为该框的置信度分数。融合框置信度取组内各框置信度的均值，融合框类别取组内数量占优的类别。而置信度低于阈值的融合框会被丢弃。

## 3 实验过程与结果分析

### 3.1 实验设置

实验采用 Windows11 操作系统，搭载 Intel Core i7-10875H 中央处理器和 NVIDIA GeForce RTX3060 独立显卡。软件环境采用 Python 作为编程语言解释器，搭配 Pytorch 2.2.0 深度学习框架，并基于 CUDA 11.8 并行计算架构进行加速。目标检测框架选用 YOLOv11s 作为基础网络。基线模型初始学习率 0.01，训练 150 个 epoch，输入尺寸为 640\*640，批量大小为 8，在线数据增强包括剪切变换、尺度缩放、垂直翻转、Mosaic 拼接和 Mixup 混合，其余参数采用 Ultralytics 默认值，在基线模型基础上，依次引入三通道预处理、离线数据增强和多模型 WBF 基础策略。

### 3.2 评价指标

为了评估模型的性能，本文选择精确率（Precision，P）、召回率（Recall，R）、F1分数和平均精度值（mean average precision，mAP）指标作为评价指标。各指标计算公式如下：

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (9)$$

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP(i) \quad (11)$$

式中， $TP$ 为模型正确检测的目标数量； $FP$ 为模型将背景或者其他类别错误检测为目标的数量， $FN$ 为模型未能检测到的真实目标数量， $P$ 是衡量模型检测结果中正确检测所占比例， $R$ 是衡量所有真实目标中被正确检测出的比例， $F1$ 分数是精确率和召回率的调和平均值，综合衡量精确率与召回率的平衡性； $AP$ （Average Precision）指的是单类别PR曲线下的面积，其取值依赖于IoU（Intersection over Union）阈值对正负样本的判定。为综合评估所有类别性能，取各类别AP的均值，即mAP（mean Average Precision）。其中，mAP@0.5固定IoU阈值为0.5；mAP@0.5:0.95则计算IoU从0.5至0.95（步长0.05）共10个阈值下的mAP平均值。由于本文重点关注KC的识别结果，实验分析以KC的评价指标为主。

### 3.3 单个模型实验

本文在相同数据集上训练了6个YOLOv11s模型。模型1到模型5采用相同的超参数配置（初始学习率为0.01），随机种子分别是0、42、123、492和681，模型6则将初始学习率降低为0.005，边界框损失权重增大到10，分类损失权重增大到0.8。

表1展示了六个训练模型在验证集上的检测结果，从表中可以看出，模型1到模型5的KC的F1值在83.0%~85.3%之间，尽管不同随机种子之间存在一定波动（标准差1个百分点），但是所有实验结果都优于基线模型。这表明所提方法的性能提升并非源于随机种子的偶然性，而是方法本身的有效性。本文选择模型1、模型2和模型6来进行WBF融合，模型1的F1值最高，因此在WBF融合时设置为2倍权重，模型2和模型6的权重各为1。

表1 单个模型结果

Table1 Individual models results

| 模型  | P/%(KC) | R/%(KC) | F1/%(KC) | mAP@0.5/<br>%(KC) | mAP@0.5:0<br>.95/%(KC) | F1/%(AKR) |
|-----|---------|---------|----------|-------------------|------------------------|-----------|
| 模型1 | 88.0    | 82.7    | 85.3     | 87.2              | 51.2                   | 75.3      |
| 模型2 | 86.2    | 81.3    | 83.7     | 86.1              | 54.3                   | 76.9      |
| 模型3 | 85.6    | 81.3    | 83.4     | 88.2              | 55.2                   | 78.1      |
| 模型4 | 87.3    | 79.1    | 83       | 85.2              | 54.9                   | 78.3      |
| 模型5 | 89.1    | 78.4    | 83.4     | 85.1              | 54.0                   | 78.0      |
| 模型6 | 85.3    | 81.3    | 83.2     | 86.3              | 54.1                   | 76.0      |

3.4 消融实验

为了验证每个模块的有效性，本文在统一验证集上进行消融试验，实验结果如表 2 所示，表中“√”表示在基线网络 YOLOv11s 的基础上使用了此模块。

表 2 消融实验结果  
Table2 Ablation experiments results

| 模型   | 预处理 | 数据增强 | WB<br>F | P/%<br>(KC) | R/%<br>(KC) | F1/%<br>(KC) | mAP@0<br>.5/%<br>(KC) | mAP@0<br>.5:0.95/<br>%(KC) | F1/%<br>(AKR) |
|------|-----|------|---------|-------------|-------------|--------------|-----------------------|----------------------------|---------------|
| 模型 A | ×   | ×    | ×       | 82.0        | 78.8        | 80.4         | 84.6                  | 52.4                       | 75.3          |
| 模型 B | √   | ×    | ×       | 75.1        | 81.3        | 78.1         | 82.7                  | 53.6                       | 76.7          |
| 模型 C | √   | √    | ×       | 88.0        | 82.7        | 85.3         | 87.2                  | 51.2                       | 75.3          |
| 模型 D | √   | √    | √       | 89.4        | 84.9        | 87.1         | 84.9                  | 51.2                       | 82.2          |

从表 2 可以看出，数据经过三通道预处理后（模型 B），KC 的 F1 值低于基线（模型 A）。其中，R 从 78.8% 提升至 81.3%，表明频率梯度通道和频率位置编码通道有助于减少 KC 的漏检，但 P 从 82.0% 下降到 75.1%，虚警明显增加。定位精度方面，mAP@0.5 由 84.6% 降至 82.7%，而 mAP@0.5:0.95 由 52.4% 升至 53.6%（四组最优）。AKR 的 F1 值变化不大。结果表明，在训练样本有限的条件下，三通道预处理虽然提供了更丰富的频域信息但是模型难以充分学习，出现了过拟合，但提升了预测框的定位精细度。

在三通道预处理基础上加入数据增强后（模型 C），KC 的 F1 值从 78.1% 提升至 85.3%。其中 P 从 75.1% 提升至 88.0%，R 从 81.3% 提升至 82.7%。mAP@0.5 由 82.7% 升至 87.2%（四组最优），但 mAP@0.5:0.95 由 53.6% 降至 51.2%（四组最差）。数据增强扩充了训练集，模型可以充分利用三通道输入提供的频域结构。这一结果表明三通道预处理与数据增强之间存在协同关系：预处理提供频域特征，数据增强提供足够的训练样本。但增强策略并未同步改善模型的边界回归精度，甚至可能因随机变换引入了定位偏差，导致预测框在严格 IoU 阈值下难以达到匹配标准。

采用 WBF（模型 D）集成三个单一模型的预测结果，可以发现 KC 的 F1 值从基线的 80.4% 提升至 87.1%，P 从 82.0% 提升至 89.4%，R 从 78.8% 提升至 84.9%。mAP@0.5 由 84.6% 提升至 84.9%，mAP@0.5:0.95 从 52.4% 降至 51.2%。mAP 的下降主要源于 WBF 对多个预测框的坐标进行加权平均时，融合框与真值框的精确重合度相比单模型略有下降，在 IoU 阈值更严格的 mAP@0.5:0.95 指标上影响明显，但是 P 和 R 都超过了任一模型，表明 WBF 在减少漏检和误检方面的增益远大于定位精度的微小损失。WBF 通过融合多个模型的互补信息，减少了漏检和误检。

3.4 对比实验

为了验证本文方法的有效性，将本文算法和 YOLO 系列的其他算法进行对比分析，为确保实验的严格性，数据集和训练参数保持一致，结果如表 3 所示。

从表 3 可以看出，本文方法在 KC 检测上的取得了最好的 F1 分数（87.1%），优于

YOLOv5（82.8%）、YOLOv8（82.9%）、YOLOv9（83.1%）、YOLOv10（74.1%）和YOLOv11（80.4%）。其中准确率和召回率在所有模型中为最高，表明三通道预处理、频谱增强与 WBF 集成的组合策略在减少漏检和误检方面均取得了显著效果。YOLOv10s 表现最差（F1=74.1%），可能与其 anchor-free 设计在频谱图数据上的适应性不足有关。在 AKR 检测方面，本文方法的 F1 分数为 82.2%，高于其他对比模型（74.1%-78.6%），进一步验证了方法的有效性。

表3 不同 YOLO 模型的结果  
Table3 Results of different YOLO models

| 模型      | P/%<br>(KC) | R/%(KC) | F1/%(KC) | mAP@0.5/<br>%(KC) | mAP@0.5:0<br>.95/%(KC) | F1/%(AKR) |
|---------|-------------|---------|----------|-------------------|------------------------|-----------|
| YOLOv5  | 87.7        | 72.7    | 82.8     | 78.6              | 53.9                   | 75.6      |
| YOLOv8  | 83.3        | 82.6    | 82.9     | 85.8              | 57.2                   | 74.9      |
| YOLOv9  | 86.5        | 79.9    | 83.1     | 86.7              | 58.7                   | 78.6      |
| YOLOv10 | 75.5        | 72.7    | 74.1     | 78.6              | 53.9                   | 74.1      |
| YOLOv11 | 82.0        | 78.8    | 80.4     | 84.6              | 52.4                   | 75.3      |
| 本文      | 89.4        | 84.9    | 87.1     | 84.9              | 51.2                   | 82.2      |

### 3.5 检测结果可视化

图 6 为 6 种模型的目标检测效果对比图，图 6a-图 6g 分别是标注图、模型 1、模型 2、模型 3、模型 B（预处理）、模型 D（WBF）和模型 A（基线），图中标签显示类别名称和置信度，置信度表示该检测框为目标类别的预测概率。可以看出，所有模型均正确检测到了 2 个 KC 事件，基线模型对 KC 的检测置信度较低（平均 0.805），三通道预处理后提升至 0.885，三通道结合数据增强后置置信度最高（平均 0.935）。WBF 集成后的平均置信度为 0.91，高于基线和三通道预处理的结果。这表明所提出的方法显著提升了预测置信度，具有优异的检测性能，为 KC 的自动识别提供了可靠的技术支撑。




图 6 6 种模型检测结果对比图。(a)标注图；(b)模型 1 的检测结果图；(c)模型 2 的检测结果图；(d)模型 3 的检测结果图；(e)模型 B 的检测结果图；(f)模型 D 的检测结果图；(g)模型 A 的检测结果图

Fig.6 Comparison of detection results of the six models. (a) Ground truth; (b) Detection result of

Model 1; (c) Detection result of Model 2; (d) Detection result of Model 3; (e) Detection result of Model B; (f) Detection result of Model D; (g) Detection result of Model A

## 4 结论

针对传统识别 KC 方法存在易受背景干扰、识别不准确和扩展性不高等问题, 本文提出了一种基于 YOLOv11s 的 KC 自动识别方法。该方法以 YOLOv11s 为基础网络, 根据卫星频谱图的特点, 设计三通道预处理策略, 将原始频谱图重构为功率谱密度强度、频率梯度和频率位置编码三个通道, 为卷积神经网络显式注入频域物理先验信息; 利用数据增强的办法缓解小样本问题, 并采用 WBF 对多个独立训练模型进行集成, 进一步优化检测结果。实验结果表明, 三通道预处理与数据增强之间存在协同效应, 两者联合使用使单模型 KC 的 F1 分数达到 85.3%, WBF 集成后进一步提升至 87.1%, 相比基线模型提升 6.7 个百分点。与五种 YOLO 基线模型的对比实验验证了所提方法的有效性。相比于人工判别, 该方法不仅提高了识别精度, 还提升了识别效率。将训练好的模型应用于 2012 年-2019 年 RBSP 双星的全部频谱图, 共识别出 1517 张含 KC 事件的频谱图, 这为后续研究 KC 的时空分布及其产生机制提供了数据支撑。此外, 本文方法目前仅在 RBSP 双星数据上进行了验证, 跨仪器平台和更广泛空间环境下的推广有待进一步研究。未来工作将致力于在更多卫星数据 (如 Arase、IMAGE 等) 上测试方法的泛化能力。

## 参考文献:

- [1] HASHIMOTO K, CALVERT W, MATSUMOTO H. Kilometric continuum observed with Geotail[J]. *Advances in Space Research*, 1999, **24**(1): 63-66
- [2] MENIETTI J D, ANDERSON R R, PICKETT J S, *et al.* Near-source and remote observations of kilometric continuum radiation from multispacecraft observations[J]. *Journal of Geophysical Research Space Physics*, 2003, **108**(A11): 1393
- [3] DENG Z K, XIAO F L, ZHOU Q H, *et al.* A direct evidence for kilometric continuum generation through mode conversion[J]. *Earth and Planetary Physics*, 2025, **9**(4): 995-1000
- [4] XIAO F L, TANG J W, ZHANG S, *et al.* Asymmetric distributions of auroral kilometric radiation in earth's northern and southern hemispheres observed by the Arase satellite[J]. *Geophysical Research Letters*, 2022, **49**(13): e2022GL099571
- [5] ZHANG S, LIU S, LI W T, *et al.* A concise empirical formula for the field-aligned distribution of auroral kilometric radiation based on Arase satellite and van Allen probes[J]. *Geophysical Research Letters*, 2021, **48**(8): e2021GL092805
- [6] ZHANG S, SHANG X J, HE Y H, *et al.* Dominant roles of high harmonics on interactions between AKR and radiation belt relativistic electrons[J]. *Geophysical Research Letters*, 2020, **47**(16): e2020GL088421
- [7] ZHANG S, YIN Q P, YANG H M, *et al.* Direct observation of L-X mode of auroral kilometric radiation in the Lower latitude magnetosphere by the Arase satellite[J]. *Geophysical Research Letters*, 2024, **51**(5): e2023GL105694
- [8] LI P, ZHANG S, XIAO F L, *et al.* Annual and seasonal occurrence pattern of auroral kilometric radiation associated with the interplanetary magnetic field[J]. *The Astrophysical Journal Letters*, 2024, **966**(2): L26
- [9] FOGG A R, JACKMAN C M, WATERS J E, *et al.* Wind/WAVES observations of auroral kilometric radiation: automated burst detection and terrestrial solar wind-magnetosphere coupling effects[J]. *Journal of Geophysical Research: Space Physics*, 2022, **127**(5):

- [10] GREEN J L, SANDEL B R, FUNG S F, *et al.* On the origin of kilometric continuum[J]. *Journal of Geophysical Research: Space Physics*, 2002, **107**(A7): SMP 12-1-SMP 12-10
- [11] GREEN J L, BOARDSEN S, FUNG S F, *et al.* Association of kilometric continuum radiation with plasmaspheric structures[J]. *Journal of Geophysical Research: Space Physics*, 2004, **109**(A3): A03203
- [12] KLETZING C A, KURTH W S, ACUNA M, *et al.* The electric and magnetic field instrument suite and integrated science (EMFISIS) on RBSP[J]. *Space Science Reviews*, 2013, **179**(1/2/3/4): 127-181
- [13] KESSEL R L, FOX N J, WEISS M. The radiation belt storm probes (RBSP) and space weather[J]. *Space Science Reviews*, 2013, **179**(1/2/3/4): 531-543
- [14] GIRSHICK R. Fast R-CNN[C]//Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015: 1440-1448
- [15] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 580-587
- [16] REN S Q, HE K M, GIRSHICK R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, **39**(6): 1137-1149
- [17] REDMON J, DIVVALA S, GIRSHICK R, *et al.* You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 779-788
- [18] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 6517-6525
- [19] REDMON J, FARHADI A. YOLOv3: an incremental improvement[OL]. arXiv preprint arXiv: 1804.02767, 2018
- [20] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot MultiBox detector[C]//14th European Conference Computer Vision – ECCV 2016. Amsterdam: Springer, 2016: 21-37
- [21] LIU B Y, LU W L, SUN T R, *et al.* RUPDA: an unsupervised method for magnetopause tangent direction detection with multiviewpoints in low SNR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, **62**: 5930024
- [22] SCULLY J, FLYNN R, CARLEY E, *et al.* Type III solar radio burst detection: a deep learning approach[C]//2021 32nd Irish Signals and Systems Conference (ISSC). Athlone: IEEE, 2021: 1-6
- [23] CHEN Z, ZHANG J L, WANG J S, *et al.* A TIEGCM-based inversion model for ionosphere-thermosphere parameters driven by three-dimensional electron density[J]. *Science Advances*, 2026, **12**(16): eaea2406
- [24] OMAT C, BIRLAN M, NEDELCO D A. An Automatically approach of space objects detection[C]//Proceedings of the 9th European Conference on Space Debris. Bonn: ESA Space Debris Office, 2025: 1-5
- [25] ZHANG H Y, LI Z Y, WANG C Y. YOLO-dynamic: a detection algorithm for spaceborne dynamic objects[J]. *Sensors*, 2024, **24**(23): 7684
- [26] WANG Q, LIU J C, YANG Y W. Weakly supervised object detection for auroral vortex structure in all-sky image[C]//Proceedings of the 2021 4th International Conference on

Artificial Intelligence and Pattern Recognition. Xiamen: Association for Computing Machinery, 2022: 42-49

- [27] XIA Kai, XING Zanyang, ZHANG Qinghe, *et al.* Automatic identification of space hurricane based on transfer learning[J]. *Chinese Journal of Space Science*, 2023, **43**(2): 231-240 (夏凯, 邢赞扬, 张清和, 等. 基于迁移学习的太空台风自动识别[J]. 空间科学学报, 2023, **43**(2): 231-240)
- [28] WANG Heye, GUO Xuedou, ZHANG Sai, *et al.* Recognition method of auroral kilometric radiation based on fusion of VGG16 and self-attention mechanism[J]. *Chinese Journal of Space Science*, 2025, **45**(3): 677-688 (王鹤野, 郭雪豆, 张赛, 等. 基于 VGG16 与自注意力机制融合的极光千米波识别[J]. 空间科学学报, 2025, **45**(3): 677-688)
- [29] SONG Xiaojian, ZUO Pingbing, ZHOU Zilu. Automatic identification of magnetopause crossing events[J]. *Chinese Journal of Space Science*, 2021, **41**(3): 375-383 (宋小健, 左平兵, 周梓露. 磁层顶穿越事件自动识别算法[J]. 空间科学学报, 2021, **41**(3): 375-383)
- [30] JIANG Jianan, ZOU Ziming, LU Yang. Machine identification method of auroral substorm onset time[J]. *Chinese Journal of Space Science*, 2025, **45**(3): 662-676 (蒋家楠, 邹自明, 陆阳. 极光亚暴爆发时点机器识别方法[J]. 空间科学学报, 2025, **45**(3): 662-676)
- [31] CHEN Z, TIAN H, LI H M, *et al.* The study on the global evolution of energetic electron precipitation during geomagnetic storm based on deep learning algorithm[J]. *Journal of Geophysical Research: Space Physics*, 2023, **128**(3): e2022JA030974
- [32] ALLEN J. Short term spectral analysis, synthesis, and modification by discrete Fourier transform[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1977, **25**(3): 235-238
- [33] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778
- [34] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. *Journal of Big Data*, 2019, **6**(1): 60
- [35] PARK D S, CHAN W, ZHANG Y, *et al.* SpecAugment: a simple data augmentation method for automatic speech recognition[C]//20th Annual Conference of the International Speech Communication Association. Graz: ISCA, 2019
- [36] SOLOVYEV R, WANG W M, GABRUSEVA T. Weighted boxes fusion: ensembling boxes from different object detection models[J]. *Image and Vision Computing*, 2021, **107**: 104117

## 作者简介

李萍 女, 1994 年 4 月出生于湖南省永州市, 现为长沙理工大学物理与电子科学学院博士研究生, 主要研究方向为地球内磁层等离子体波动和人工智能应用。

E-mail: [pingli410@foxmail.com](mailto:pingli410@foxmail.com)



张赛 (通讯作者) 男, 1986 年 10 月出生于山西省运城市, 现为长沙理工大学物理与电子

科学学院副教授，博士生导师，主要研究方向为空间等离子体物理和人工智能应用。

E-mail: [saizh@126.com](mailto:saizh@126.com)



最新录用