文章编号:1671-4598(2026)01-0188-08　DOI:10.16526/j.cnki.11-4762/tp.2026.01.024　中图分类号:TP181;TN971　文献标识码:A

面向无人机信号检测与识别的自动标注方法

王燕楚[1]，张君毅[1,2]
(1. 中国电子科技集团公司 第五十四研究所，石家庄　050081；
2. 河北省电磁频谱认知与管控重点实验室，石家庄　050081)

摘要： 深度学习的性能高度依赖海量、高质量标注数据，但传统标注方式依赖人工面临效率低下、易出错等挑战，难以满足快速构建大规模精准数据集的需求；针对无人机射频信号检测与识别问题，为提高数据标注的效率，提出了一种基于轮廓检测的自动标注方法，该方法利用时频图中信号与背景的像素值差异，通过轮廓检测技术自动分离并定位信号区域坐标，并借助 K-Means 聚类算法精准区分不同目标信号并分配类别标签；实验表明，该自动标注方法在不同信噪比条件下均能取得优异的检测性能，信噪比达 8 dB 时检测率稳定接近 100%；将标注数据输入 YOLOv11 网络进行训练，最终由训练好的网络实现对无人机信号存在性及所属机型的高精度识别，结果显示对不同无人机信号分类准确率高；基于轮廓检测的自动标注方法的提出，有效提高了数据标注效率和准确性，对提升深度学习模型性能、解决实际工程问题具有重要意义。

关键词： 无人机信号检测与识别；时频图；自动标注；轮廓检测；YOLOv11

Automatic Labeling Method for UAV Signal Detection and Recognition

WANG Yanchu[1]，ZHANG Junyi[1,2]
(1. China Electronics Technology Group Corporation No. 54 Research Institute,
Shijiazhuang　050081, China;
2. Hebei Province Key Laboratory of Electromagnetic Spectrum Cognition and Control,
Shijiazhuang　050081, China)

Abstract: The performance of deep learning models is highly dependent on massive, high-quality annotated data. However, traditional manual annotation methods face challenges such as low efficiency and susceptibility to errors, making it difficult to meet the demand for rapidly constructing large-scale, precise datasets. To address the issue of drone RF signal detection and identification and improve data annotation efficiency, this paper proposes an automatic annotation method based on contour detection. This approach leverages the difference in pixel values between signals and the background in time-frequency spectrograms to automatically separate and locate signal region coordinates using contour detection techniques. Furthermore, it employs the K-Means clustering algorithm to accurately distinguish different target signals and assign category labels. Experimental results demonstrate that this automatic annotation method achieves excellent detection performance across various signal-to-noise ratio (SNR) conditions. When the SNR reaches 8 dB, the detection rate stably approaches 100%. The annotated data was input into a YOLOv11 network for training, and the trained network ultimately achieved high-precision identification of drone signal presence and corresponding aircraft type. The results show high classification accuracy for different drone signals. The proposal of this contour-detection-based automatic annotation method effectively enhances both the efficiency and accuracy of data annotation, holding significant importance for improving deep learning model performance and solving practical engineering problems.

Keywords: UAV signal detection and identification; time-frequency diagram; automatic annotation; contour detection; YOLOv11

收稿日期: 2025-07-13；　**修回日期:** 2025-08-25。
作者简介: 王燕楚(2001-),女,硕士研究生。
引用格式: 王燕楚,张君毅.面向无人机信号检测与识别的自动标注方法[J].计算机测量与控制,2026,34(1):188-195.

0　引言

近年来，无人机“黑飞”现象频繁发生，给社会带来了诸多严重问题[1]。在此背景下，各国纷纷开展针对无人机的检测、定位、分类、跟踪和反制的研究[2]。然而，现有技术各有局限：雷达低空监测成本高昂、存在盲区，易漏警；光学识别易被光照强度、云雾厚度、建筑遮挡干扰，夜间效果差；声纹识别距离短，不适用于嘈杂城市环境。相比之下，无人机射频检测技术因其成本低，不受光强、云雾、遮挡、无人机体积等因素影响，能够全天候、全地形工作，有效弥补了其他技术的不足，因此被采用[3-4]。

无人机射频检测技术的原理是无人机在与地面进行图片传输和飞行控制时会产生射频通信信号[5]，即图传信号和遥控信号。软件无线电设备接收这些信号，将接收到的信号与后台数据库比对，精准确定无人机类型，引导干扰机进行针对性反制。

现有的无人机射频检测技术分为射频指纹方法和深度学习方法[6]。射频指纹方法通常是通过传统方法提取信号特征对信号进行识别；深度学习技术能够自动从原始数据中学习到对任务有用的特征表示，而无需人工手动设计和提取特征。文献［7］基于包含三种无人机机型信号的 DroneRF 数据集，利用机器学习中的 XGBoost 算法构建了 3 种模型。这些模型分别用于检测无人机是否存在、识别类型以及判断其操作模式。文献［8］也基于 DroneRF 数据集，通过短时傅立叶变换从原始信号中提取包含时域和频域信息的二维特征，使用基于残差结构的卷积神经网络来实现多类分类。上述方法中包含的无人机型号少，不具有普适性。文献［9］基于时频图像的信号检测识别方法，借助图像处理技术和卷积神经网络模型实现无人机信号的检测与识别；文献［10］对六种无人机型号进行识别，利用短时傅里叶变换和小波变换将无人机的射频频谱信号进行时频分析获得频域图像，最后使用改进的 Yolov5-7.0 目标检测模型进行信号检测。此方法在检测速度和准确度上具有优势，但其是使用人工对所需学习的图像进行标注，这增加了前期准备的时间。

深度学习的训练过程高度依赖海量数据的支持。然而，原始数据往往存在未知性和冗余性，难以直接从中提取准确有效的信息。因此，在将数据用于模型训练之前，必须先对其进行多种形式的标注处理。数据标注是利用标注工具对未经处理的原始数据进行加工给予不同类型的标签，将其转换为机器能够理解的信息，使得机器能够学习输入特征与输出标签之间的映射关系，最终实现信号的检测与识别。数据标注技术的水平对深度学习模型的性能有着至关重要的影响。一般来说，标注的准确性越高、数据量越大，模型的性能就越出色。传统的数据标注方式主要依靠人工操作，标注人员需要通过识别信号，手动框选并为其分配类别标签。然而，这种方式在处理大规模数据集时面临着诸多挑战。一方面，人工标注效率低下，耗时巨大，难以满足快速构建高质量数据集的需求；另一方面，人为因素容易引入错误，干扰数据标注的准确性，进而影响模型的训练效果。

目前的自动标注技术主要依赖于深度学习，文献［11］提出一种半监督学习方法：先用已标注数据训练教师模型，对未标注数据预测生成高置信度伪标签，将其与原始标注数据合并，再训练学生模型，实现训练集扩充。文献［12］提出一种基于少量标记数据自动生成启发式标注规则的方法，用于弱监督下的未标记数据标注。文献［13］基于深度神经网络（DNN）提出了一种新的 MVSAE 模型，用于联合建立高层语义关键词与低层图像特征之间的相关性以实现自动图像标注。文献［14］通过种子数据集训练一个可粗略标注的模型，进而实现车辆部件的自动标注。上述方法都是基于深度学习技术的图像标注方法，这在一定程度上提高了传统图像标注的精度，但这些方法都依赖于一定数量的有标签数据，数据不足时模型性能下降，不适用于小样本的数据标注。

在小样本的前提下，本文基于轮廓检测实现了数据的自动标注，该方法通过时频图自动识别信号的坐标信息并分配类别标签，从而节约时间并提高准确性。首先利用时频分析算法将射频信号数据转换为图像形式，由于信号的带宽、持续时长和波形特征具有唯一性，这些特征表现在时频图像上为不同的长度和形状，为后续的检测和识别提供了直观的依据。在数据标注阶段，通过利用时频图中信号与背景的像素值差异，使用轮廓检测将信号从背景中分离出来，进而获得信号的坐标，根据信号特征差异采用 K-Means 聚类算法能够将不同目标信号进行区分，并为每个信号点分配准确的类别标签。最后利用 YOLOv11 实现对无人机信号类型的精准检测与识别。

1　信号预处理

民用无人机遥控信号常采用跳频扩频技术，由此产生的跳频信号是非平稳的，其频率会随时间快速变化。传统的傅里叶变换只能分析平稳信号，无法同时提供信号在时间和频率上的动态信息，因此不适用于这类非平稳信号的分析。为了克服这一限制，采用时频分析方法，能够同时展示信号在时间和频率上的变化，通过结合时间和频率信息，可以更全面地描述信号的特性。

时频分析方法主要分为线性和非线性两大类。线性

时频分析方法包括短时傅里叶变换和小波变换；非线性时频分析方法则包括维格纳—维尔分布和科恩类分布等。本文采用短时傅里叶变换，它比小波变换更简单、快速，能够克服传统傅里叶变换的不足，提供信号在时间和频率上的局部信息，同时避免了高次型非平稳分析方法中出现的交叉项干扰，并且能够获取完整的频谱信息[15]。

短时傅里叶变换的原理是将窗函数沿着时间轴滑动得到多个时间段的信号，对每个时间段内的信号进行傅里叶变换，得到该时间段内的频率分布信息，集合所有时间段的频率分布信息，即可获得反映信号频率随时间变化的时频分布。对于连续信号 $x(t)$，其短时傅里叶变换可以表示为：

$$S_x(\omega,t)=\int_{-\infty}^{\infty}x(\tau)\gamma^*(\tau-t)\,e^{-j\omega t}\mathrm{d}\tau \tag{1}$$

式中，$\gamma(t)$ 是一个实偶窗函数，t 是时间平移参数，ω 是信号的角频率。

设定一个窗口长度 N 为 2 048，选择汉明窗用于对信号进行加窗处理，设置窗函数重叠比例为 40%，以减少频谱泄漏，提高频谱分析的准确性。短时傅里叶变换的能量谱则定义为：

$$P_x(\omega,t)=\int_{-\infty}^{\infty}S_x(\omega,t)\times S_x^*(\omega,t)\mathrm{d}t=\int_{-\infty}^{\infty}|S_x(\omega,t)|^2\mathrm{d}t \tag{2}$$

将每个时间段内的频率分布信息绘制在二维平面上，横轴表示时间，纵轴表示频率，颜色表示幅度，由此可以观察到信号在不同时间点的频率分布情况[16]。

2 基于轮廓检测的自动标注

在人工标注过程中，通常使用 LabelImg 工具对时频图进行标注，通过在图像上创建矩形框并为其分配相应的标签，可以为图像中的目标物体提供确定的标注信息。YOLO 标注格式的文件以 TXT 格式保存，包含两部分关键信息：类别编号和矩形框坐标。类别编号从 0 开始，根据目标数量依次递增，不同的编号用于区分不同型号的无人机以及区分同一型号中的图传信号和遥控信号。矩形框坐标则采用归一化形式，包括矩形框中心点的相对坐标（x、y）、矩形框的相对宽度（w）和相对高度（h）[17]，标注文件的格式如表 1 所示。

表 1 标注样例

类别编号	中心点相对坐标 x	中心点相对坐标 y	标注框相对宽度 w	标注框相对高度 h
1	0.490 972 222	0.125	0.020 833 33	0.035 185 185
0	0.474 305 556	0.151 851 852	0.018 055 56	0.033 333 333

自动标注的目标是减少人工参与，提升标注的准确性和速度，最终生成符合指定格式的 TXT 文件。其核心在于为不同的信号分配正确的类别标签，并准确记录目标物体对应的矩形框坐标。标注工作完成后，可通过 LabelImg 工具验证标注结果的准确性。

为了实现这一目标，接下来将对时频图进行预处理步骤，包括滤波、二值化和形态学运算处理。这些处理的核心目的在于：优化信号质量、有效区分目标前景与背景、精炼目标物体的形状和边界，为后续环节检测目标位置并计算矩形框坐标和对信号类型分配标签奠定基础。

2.1 滤波

在时频图的处理中，采用高斯加权中值滤波（GWMF，gaussian weighted median filtering）去除噪声，使信号特征更加清晰。

高斯加权中值滤波是一种结合了高斯滤波和中值滤波优点的滤波方法。高斯滤波通过高斯函数对信号进行加权平均，能够有效地平滑信号，但可能会模糊信号的边缘特征。中值滤波则通过取局部区域的中值来去除噪声，对脉冲噪声具有很强的抑制能力，且能较好地保持信号的边缘信息。高斯加权中值滤波结合了高斯滤波的平滑特性和中值滤波的抗噪能力，其核心思想是为滤波窗口内的每个信号点分配高斯权重，然后根据这些权重选择加权后的中值作为滤波结果。滤波性能的关键在于参数选择：高斯函数的标准差 σ 决定了权重分布的宽度，影响平滑程度与边缘保持的权衡；滤波窗口的尺寸影响噪声去除效果和对细节的保护能力。

这种方法不仅能够去除背景噪声，还能在一定程度上保留信号的细节特征，这对于分析非平稳信号尤为重要，因为非平稳信号的频率成分会随时间变化，而噪声可能会掩盖这些变化。

2.2 二值化处理

对时频图进行二值化操作，根据最佳阈值将图像中的每个像素值分为两类：0 和 255，其中 0 表示背景，255 表示前景，这使得复杂的灰度信息简化为二值信息，从而突出信号的主要特征，减少噪声的影响，并提高处理效率。

通过使用 Otsu 算法来自动确定最佳阈值，基本思想是计算图像的灰度直方图，统计每个灰度值的像素分布概率，并遍历所有可能的阈值，将图像分为前景和背景两部分，分别计算这两部分的权重和平均灰度值。通过这些统计信息，算法进一步计算类间方差，该方差反映了前景与背景之间的分离程度。类间方差越大，说明前景和背景的区分越明显，分割效果越好，最后选择使类间方差最大的阈值作为最佳分割阈值，从而实现对图像的高效分割。类间方差的计算公式为：

$$\sigma_b^2 = \omega_0(T) \times \omega_1(T) \times [\mu_0(T) - \mu_1(T)] \quad (3)$$

式中，$\omega_0(T)$ 是背景像素的权重，表示背景像素在图像中所占的比例；$\omega_1(T)$ 是前景像素的权重，表示前景像素在图像中所占的比例；$\mu_0(T)$ 是背景像素的平均灰度值；$\mu_1(T)$ 是前景像素的平均灰度值。

2.3　形态学运算处理

形态学运算用于处理二值图像的形状特征，它通过定义结构元素与图像之间的操作，实现对图像的形状分析和处理。形态学运算的基本操作包括膨胀、腐蚀[18]。对于二值图像，膨胀是一种扩张图像的形态学操作，主要用于填充小孔、连接断裂的部分，或者扩大物体的边界。它通过将结构元素在图像上滑动，检查结构元素覆盖的区域是否与前景像素有交集。如果结构元素与前景像素有交集，则中心像素变为前景；否则保持为背景。

腐蚀是一种收缩图像的形态学操作，主要用于消除小物体、断开物体之间的连接，或者去除物体的边界。它通过将结构元素在图像上滑动，检查结构元素覆盖的区域是否完全被前景像素填充。如果结构元素完全被前景像素覆盖，则中心像素保持为前景；否则，中心像素变为背景。

开运算是先腐蚀后膨胀的组合操作，用于去除前景区域中的细小结构；闭运算是先膨胀后腐蚀的组合操作，用于填充前景区域中的细小结构。通过膨胀和腐蚀的组合操作可以提取图像的边缘信息，如图 1 所示即为经过形态学处理后的二值化图的变化情况。

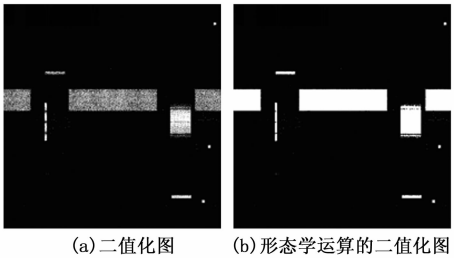

(a) 二值化图　　(b) 形态学运算的二值化图

图 1　形态学运算变换图

2.4　轮廓检测

在对时频图进行二值化处理后，图像中的像素点仅包含 0 和 255 两种值。基于这一特性，可以通过检测信号轮廓来提取关键信息。其原理是：从图像的左上角开始，逐像素进行扫描，寻找第一个非零像素点，即信号的边界点。一旦找到这样一个边界点，算法便沿着边界移动，并记录下边界点的坐标。在移动过程中，算法通过检查当前点周围 8 个方向的像素（包括上下、左右以及对角线方向）来确定移动的方向，这种 8-连通性方法使得算法能够沿着轮廓的边界逐步移动，从而完整地追踪出轮廓的形状。当算法再次回到起始点时，表明已经完成了一个轮廓的检测。随后，算法继续扫描图像，寻找下一个尚未被访问的非零像素点，并重复上述过程，直到图像中所有非零像素点都被访问完毕。

在完成轮廓检测后，进一步为每个轮廓计算其最小外接矩形，并返回该矩形的坐标信息。具体方法是：遍历轮廓中的所有点，找到这些点的最小和最大 x 坐标，以及最小和最大 y 坐标。这四个坐标值共同定义了一个矩形的左上角和右下角，从而确定了能够完全包含该轮廓的最小外接矩形。最终返回一个元组 (x,y,w,h)，其中 (x,y) 表示矩形左上角的坐标，w 是矩形的宽度，h 是矩形的高度。

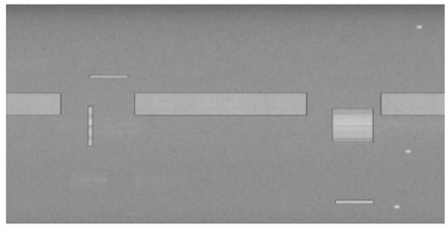

图 2　时频图的轮廓识别结果

2.5　分配聚类标签

通过分析发现，二值化图中的图传信号和遥控信号的主要区别在于信号的长宽不同，根据这个特征使用 K-means 聚类算法，通过合理设置聚类数量，算法能够依据信号的长宽特征将其归类到相应的类别中，从而实现图传信号、遥控信号以及噪声的有效区分。

但在经过滤波和形态学运算处理后，部分功率较低的噪声被去除，或者是遥控信号未被接收到，在这种情况下，无法直接用一个固定的值确定聚类数量，因此可以通过计算不同聚类数量下的轮廓系数（Silhouette Score）来选择最优聚类数量，值越大聚类效果越好，从而选择最优的值作为聚类数量。轮廓系数基于每个数据点的轮廓值（Silhouette Value）计算得到，是一种用于评估聚类效果的指标。对于一个数据点 i，其轮廓值 $s(i)$ 定义为：

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (4)$$

式中，$a(i)$ 是数据点 i 与其所在聚类中其他点的平均距离，$b(i)$ 是数据点 i 与最近的其他聚类中所有点的平均距离。计算得到的值范围在 $[-1,1]$ 之间，如果 $s(i) \approx 1$，表示数据点 i 明显属于其所在的聚类，并且与其他聚类明显分离；如果 $s(i) \approx 0$，表示数据点 i 位于两个聚类的边界上，难以判断其归属；如果 $s(i) \approx 1$，表示数据点 i 可能被错误地分配到了其他聚类中。

由于 K-Means 聚类算法的输出标签（即聚类结果的标签分配）具有随机性。这种随机性主要来源于算法的初始聚类中心的选择是随机选取的，因此每次运行算法时，可能会得到不同的聚类结果。为了实现每一种信

号分配的标签是确定的，根据信号的特征一般是遥控信号的宽度小于图传信号，因此根据聚类中心的宽度从小到大对聚类结果进行排序，赋予新的标签。可用 LabelImg 验证标注结果的准确性，如图 3 所示。

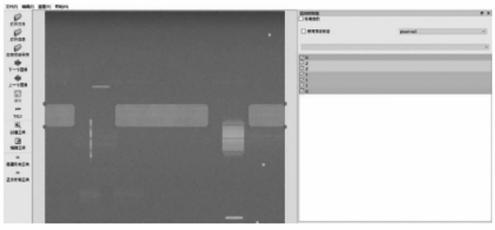

图 3 LabelImg 标注结果

将得到的聚类标签和坐标信息按照表 1 的格式进行排序、归一化等操作，输出 txt 文件，即实现信号的自动标注。

在信号识别中，当信号受到不同强度的背景噪声干扰时，其检测性能会显著变化，衡量这种性能的核心指标是检测率和虚警率。检测率是指在目标信号实际存在时，正确判定有信号的概率；虚警率是指在没有目标信号存在的情况下，错误地判定为有信号的概率。如图 4 所示给出了在不同信噪比的条件下，自动标注的检测率和虚警率。

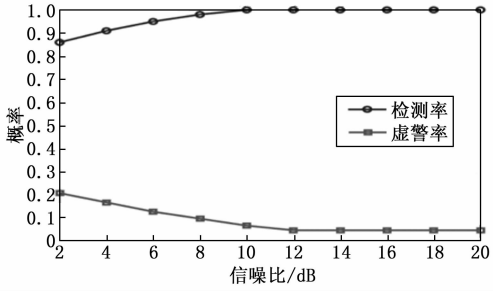

图 4 不同信噪比的条件下的检测率和虚警率

随着信噪比的增加，检测率显著提高。在信噪比低于 8 dB 的低信噪比区域，检测率迅速上升，提升幅度最大。当信噪比达到 8 dB 后，检测率趋近于并稳定在接近 100%的理想水平，表明此时系统能够非常可靠地检测到目标信号。与此同时，虚警率随信噪比增加而明显下降。在低信噪比区域，虚警率较高，但随着信噪比提升迅速降低。当信噪比达到 10 dB 左右时，虚警率下降趋缓并最终进入一个相对稳定的阶段，但不会降为零，这是由于部分噪声和目标信号具有类似的长宽特征造成识别错误，这就需要后续的数据清洗工作。

2.6 数据清洗

尽管自动标注方法能够显著提高数据标注的效率和准确性，但在实际应用中，自动标注生成的数据中仍可能包含噪声信号。这些噪声信号可能来源于标注算法的误判、数据采集过程中的干扰或数据本身的复杂性，噪声信号的存在对后续的模型训练和应用具有显著的负面影响。噪声信号会干扰模型对真实信号特征的学习，导致模型泛化能力下降。以及噪声信号可能引入错误的标签信息，影响模型的预测精度。因此，对自动标注后的数据进行噪声信号清洗是确保数据质量的关键步骤。

在自动标注过程中，噪声也被分配了标签。通过删除这些噪声对应的标签，可有效去除大部分噪声。然而，基于边缘检测的自动标注方法主要依赖信号的轮廓特征进行区分。当噪声信号的几何尺寸与目标信号高度相似时，仅凭轮廓特征难以有效辨别两者，极易将噪声误判为目标信号并赋予对应标签。此时需标注人员通过观察信号的波形特征判断其是否为噪声，一旦确认是噪声信号，则删除对应的数据记录。

2.7 数据集设置

本文实验数据来自开源数据集 DroneRFa[19]，对其中的 12 种无人机信号转换为时频图并对其进行自动标注，得到的无人机样本个数如表 2 所示。

表 2 数据集

信号类型	样本个数
DJI Phantom 3	1 037
DJI Phantom 4 Pro	770
DJI MATRICE 200	1 141
DJI MATRICE 100	1 558
DJI Air 2S	996
DJI Mini 3 Pro	900
DJI Mini 2	913
DJI Phantom 4 Pro RTK	727
DJI MATRICE 30T	748
DJI MATRICE 600 Pro	692
RadioLink AT9S 飞控器	727
Futaba T14SG 飞控器	755

3 基于 YOLOv11 的无人机射频信号检测与识别

3.1 YOLOv11 结构

YOLO（You Only Look Once）是单阶段目标检测算法的代表之一，其核心思想是将目标检测问题转化为一个回归问题。它直接从输入图像中预测目标的类别和边界框，而不需要依赖于额外的候选区域生成步骤，实现了到端学习。YOLOv11 是 YOLO 系列目标检测算法的最新版本，由 Ultralytics 开发，继承了 YOLOv8 的代码库并进行了多项改进。其网络结构主要由主干网络（Backbone）、颈部网络（Neck）、头部网络（Head）3 个部分组成。其结构图如图 5 所示。

YOLOv11 相较于 YOLOv8 改进主要包括：在主干网络中采用了对传统 C3 模块进行改进与优化的 C3K2

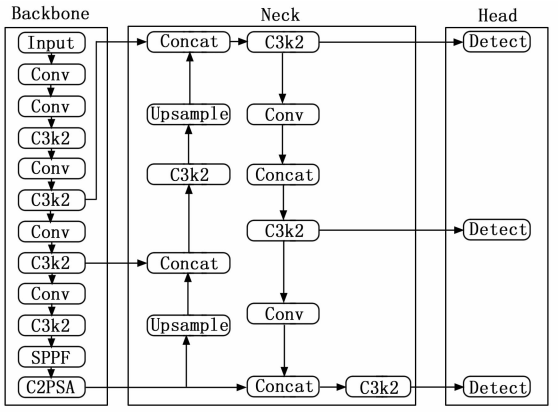

图 5　YOLOv11 结构图

模块，通过并行卷积层的设计，将输入特征图分为两部分处理：一部分通过卷积直接传递，保留浅层特征；另一部分则需要进行判断，当 C3K＝True 时，启用 C3K 模块，使用可变卷积核进行深层次特征挖掘，通过改变 K 的大小而改变卷积核的大小，当 C3K＝False 时，则使用传统的 Bottleneck 结构。C2PSA（Cross Stage Partial with Spatial Attention）模块是 YOLOv11 新增的核心模块之一，该模块基于 CSP（Cross Stage Partial）结构，将输入的特征图分为两部分，一部分保持原始特征，直接传递到后续的拼接操作，另一部分则进入 PSA（Pyramid Squeeze Attention）注意力模块进行处理。在 PSA 模块中通过使用不同尺度的卷积核实现并行提取特征，生成多尺度的特征图，使用 SE（Squeeze-and-Excitation）机制对对这些特征图的通道进行动态加权，进一步增强重要通道的响应。最后将这两部分的输出进行拼接，这样使得模型既能保留原始特征又能关注经过注意力增强的特征，增强了模型更加关注目标细节能力。C3K2 和 C2PSA 的结构图如图 6 所示。

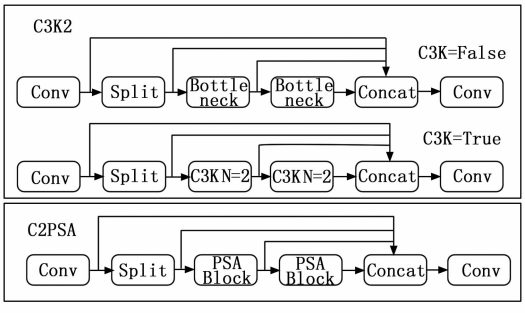

图 6　C3K2 和 C2PSA 的结构图

3.2　实验流程

基于 YOLOv11 的无人机射频信号检测与识别方法的实现过程如图 7 所示。

综上所述，基于 YOLOv11 的无人机射频信号检测与识别的流程如下：

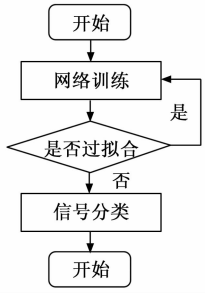

图 7　基于 YOLOv11 的无人机射频信号检测与识别的流程图

1）初始化模型参数，将数据集按 70%、15%、15%划分为训练集、验证集和测试集。

2）使用训练集训练 YOLOv11 模型。

3）每轮训练结束后，将验证集输入当前模型，计算本轮的平均识别准确率；若验证集准确率连续多轮下降则判定为过拟合，提前终止训练；否则继续训练直至收敛。

4）选取验证集准确率最高的模型参数作为最优模型。最后在测试集上计算识别准确率，实现无人机射频信号的检测与识别。

3.3　实验环境与参数配置

硬件平台基于 64 位 Windows 10 操作系统，搭载 11th Gen Intel（R）Core（TM）i7-1180H @2.3 GHz 处理器与 NVIDIA GeForce RTX 3070 Laptop GPU 显卡（显存 4 GB），配备 32 GB 内存；软件环境依托 PyTorch 1.12.0 深度学习框架，协同 CUDA 11.4 加速库及 Python 3.10.16 编程环境构建。

在开始训练前将将图片像素大小压缩至 640×640 像素，设置批次大小（batch size）为 12，训练次数（epoch）为 80 轮，设置 SGD 为神经网络的优化器，优化器的动量参数为 0.937，初始学习率为 0.01。

3.4　评价指标

本文使用精确率（P，precision）、召回率（R，recall）、平均精度均值（mAP，mean Average Precision）、F_1 分数（F_1 Score）作为模型的评价指标。

精确率反映预测正样本的真实准确性，如式（5）所示。召回率反映实际正样本的识别覆盖率，式（6）所示：

$$P = \frac{TP}{TP + FP} \tag{5}$$

$$R = \frac{TP}{TP + FN} \tag{6}$$

式中，TP（True Positive）表示实际为正类且预测也为正类；TN（True Negative）表示实际为负类且预测也为负类；FP（False Positive）表示实际为负类但预测为

正类；FN（False Negative）表示实际为正类但预测为负类[20]。

mAP 是一个用于评估目标检测模型准确性的综合指标，其计算方法是取所有类别的平均精度（AP，average precision），然后对这些 *AP* 分数进行平均。*AP* 是针对单个类别计算的，它表示该类别的精度－召回率曲线下的面积，表达式如式（7）所示：

$$AP = \int_0^1 P(t)\,\mathrm{d}t \tag{7}$$

mAP 是所有类别 *AP* 的平均值，表示如式（8）所示：

$$mAP = \frac{\sum_{n=1}^{N} AP_n}{N} \tag{8}$$

式中，N 是类别的总数，AP_n 是第 n 个类别的平均精度。

F_1 分数是精确率和召回率的调和平均数，用于衡量模型的准确性和完整性。F_1 分数在 0 到 1 之间，值越高表示模型的性能越好，表示如式（9）所示：

$$F_1 = 2 \times \frac{P \times R}{P + R} \tag{9}$$

混淆矩阵是评估分类模型性能的重要工具，它通过一个矩阵形式直观地展示了模型对各个类别的预测情况[21]。

3.5 实验结果与分析

将测试集输入最优模型进行信号检测与识别，得到的归一化混淆矩阵如图 8 所示。图中所有无人机信号类别名称的后缀 _0 表示遥控信号，_1 表示图传信号。通过分析，可以观察到大多数类别的预测准确率均接近或超过 0.95。DJI Phantom3 和 DJI MATRICE200 图传信号的识别准确率较低，易被识别成 Futaba T14SG 飞控器的信号，这一现象的出现，主要是因为这些信号在有限的时频分辨率下生成的时频图中具有较高的相似性，从而导致混淆，在这种情况下分类准确率仍能达到约 85%。

图 9 精度－召回率（P-R，precision-recall）曲线显示，在交并比（IoU）阈值设为 0.5 的标准下，模型对所有类别的 *mAP*@0.5 达到了 0.969。这表明模型在目标检测任务中，对于待检测的各类目标在定位和识别方面整体表现非常出色。平均曲线始终维持在较高位置，反映出模型在绝大多数召回率水平下都能保持很高的精度。

图 10 F_1-置信度曲线整体趋势显示，在置信度是 0.462 时，所有类别平均 F_1 分数 0.96，这表示模型在中等置信度水平上取得了接近最优的识别效果，证明了模型在高度准确的识别上具有优越的泛化能力和实用性。

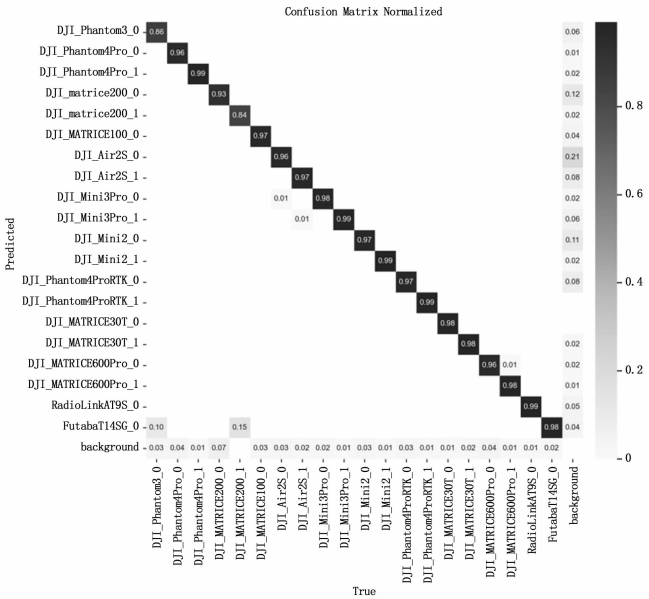

图 8 归一化的混淆矩阵

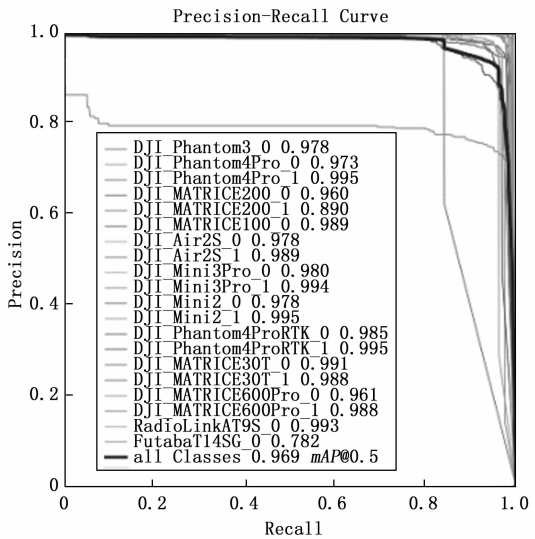

图 9 P-R 曲线

4 结束语

在无人机信号检测与识别领域，时频图作为一种关键的信号表达方式，其形状与纹理特征因不同无人机信号而异，本研究采用深度学习的方法从时频图中提取特征实现无人机射频信号的检测与识别。为提升时频图信号标注的效率和精度，本文提出了基于轮廓检测的自动标注方法，通过利用时频图中信号与背景的像素值差异，轮廓检测有效分离信号区域并定位其坐标，进一步针对信号特征的差异性，运用 K-Means 聚类算法实现了对不同目标信号的区分，并为各信号点精确分配类别标签。经实验验证，在不同信噪比条件下，本方法均展现出卓越的检测性能，当信噪比达到 8 dB 时，检测率便稳定在接近 100%的理想水平，且虚警率始终保持在

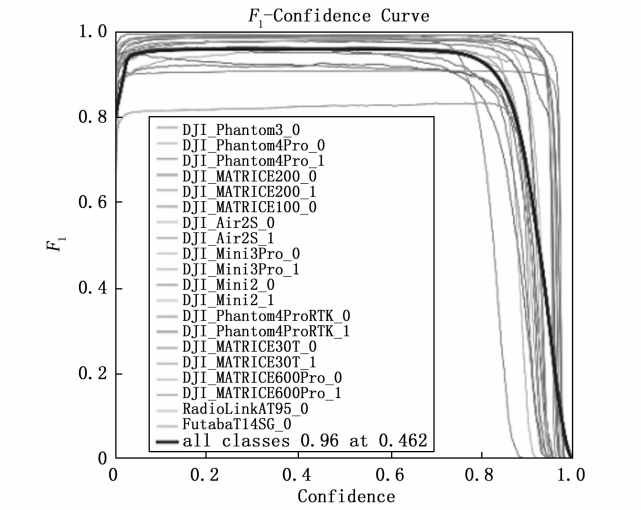

图 10　F_1-置信度曲线

较低水平。利用自动标注数据训练的 YOLOv11 网络也展现了优异的无人机信号分类能力。当前研究的主要限制在于不同无人机信号在有限时频分辨率下的时频图具有一定相似性，导致少量分类混淆。因此，未来研究将重点探索引入除时频图以外的补充特征，构建多维度融合识别框架，以期在复杂环境下实现更高精度的无人机信号快速识别，更好地服务于实际工程应用场景的需求。

参考文献：

[1] WANG Z，CAO Z，XIE J W. RF-Based drone detection enhancement via a generalized denoising and interference-removal framework [J]. IEEE Signal Processing Letters，2024，31：929－933.

[2] TAN Z，KARAKÖSE M. Survey and comparative study for drone detection using deep learning [C] //2022 International Conference on Data Analytics for Business and Industry (ICDABI)，Bahrain：IEEE，2022：234－238.

[3] 秦　浪. 基于深度学习的无人机检测方法研究 [D]. 成都：西南交通大学，2017.

[4] MANDAL S，SATIJA U. Time-Frequency multiscale convolutional neural network for RF-Based drone detection and identification [J]. IEEE Sensors Letters，2023，7 (7)：1－4.

[5] JURN Y N，IBAAHEEM Z T，ZAKI N D，et al. A review of RF based drone detection，direction of arrival and identification techniques [C] //2024 IEEE 14th International Conference on Control System，Computing and Engineering (ICCSCE)，Penang：IEEE，2024：162－167.

[6] 杨小伟，王泽跃，杨鹤猛，等. 基于残差神经网络的无人机射频信号识别 [J]. 电讯技术，2023，63 (1)：101－106.

[7] MEDAIYESE O O，SYED A，LAUF A P. Machine learning framework for RF-Based drone detection and identification system [C] // 2021 2nd International Conference On Smart Cities，Automation & Intelligent Computing Systems (ICON-SONICS). Tangerang，Indonesia：IEEE，2021：58－64.

[8] ZHAO Z，DU Q，YAO X，et al. A two-dimensional deep network for RF-based drone detection and identification towards secure coverage extension [C] // 2023 IEEE 98th Vehicular Technology Conference (VTC2023-Fall)，Hong Kong，China：IEEE，2023：1－5.

[9] 程晓静，牛慧莹. 基于时频图像的无人机信号检测识别算法研究 [J]. 信息技术，2022，4：170－174.

[10] LI M，HAO D，WANG J，et al. Intelligent identification and classification of small UAV remote control signals based on improved Yolov5-7.0 [J]. IEEE Access，2024，12：41688－41703.

[11] 黄　睿，赵　昶，李汉清，等. 基于视觉大模型的智能驾驶数据自动标注方法 [C] //中国汽车工程学会，北京：机械工业出版社，2024：263－270.

[12] VARMA P，RÉC. Snuba：Automating weak supervision to label training data [J]. Proceedings of the VLDB Endowment，2018，12 (3)：223－236.

[13] YANG Y，ZHANG W，XIE Y. Image automatic annotation via multiview deep representation [J]. Journal of Visual Communication and Image Representation，2015，33：368－377.

[14] 邵延富，谢大为. 基于深度学习的车辆部件半自动标注研究 [J]. 科技创新与应用，2025，15 (13)：14－19.

[15] 孙　震. 无人机信号的检测与识别方法研究 [D]. 武汉：中国舰船研究院，2021.

[16] 吴佳潞. 低信噪比下无人机通信信号检测与识别方法 [D]. 长沙：国防科技大学，2021.

[17] 郑琳欣，朱大智，吉承文. 人工智能数据标注格式转换方法 [J]. 数字技术与应用，2023，41 (6)：164－166.

[18] 韩　萌. 基于时频分析的无人机信号检测算法研究 [D]. 哈尔滨：哈尔滨工程大学，2023.

[19] 俞宁宁，毛盛健，周成伟，等. DroneRFa：用于侦测低空无人机的大规模无人机射频信号数据集 [J]. 电子与信息学报，2024，46 (4)：1147－1156.

[20] RAHMAN M H，AZIZ M A，TABASSUM R，et al. Improved drone classification and detection using RF：a cascaded deep learning approach [C] //2024 15th International Conference on Information and Communication Technology Convergence (ICTC)，Jeju Island，Republic of Korea：IEEE，2024：1869－1872.

[21] 葛嘉鑫，李晋徽，晋晓曦，等. 复杂环境下高扩展性无人机信号检测识别方法 [J]. 通信技术，2023，56 (8)：929－936.