

doi: 10.7690/bgzdh.2022.04.013

# 基于深度学习的空中侦察取证目标分类

刘 克, 顾佼佼, 陈 健, 孟春英

(海军航空大学岸防兵学院, 山东 烟台 264001)

**摘要:** 为提高空中侦察取证的自动化、智能化水平, 提出基于深度学习与 FPGA 软硬件协同设计开展空中侦察取证自动目标分类。多渠道收集整理军机数据集, 利用深层神经网络模型开展自动识别, 验证自动目标分类可行性, 并部署至 FPGA 开发评估板进行准确率、吞吐量等性能验证。实验结果证明: 多种网络模型均可有效实现空中侦察取证目标的自动分类, 并具备较高的吞吐量与准确率, 时效性可满足战场实际需要。

**关键词:** 侦察取证; 深度学习; 梯度下降; 软硬件协同设计

**中图分类号:** TP391 **文献标志码:** A

## Target Classification for Aerial Reconnaissance and Forensics Based on Deep Learning

Liu Ke, Gu Jiaojiao, Chen Jian, Meng Chunying

(College of Shore Defense, Naval Aviation University, Yantai 264001, China)

**Abstract:** In order to improve the automation and intelligence level of aerial reconnaissance and forensics, this paper proposes an automatic target classification for aerial reconnaissance and forensics based on deep learning and FPGA software and hardware co-design. Multi-channel collection and collation of military aircraft data sets, using deep neural network model to carry out automatic recognition, verify the feasibility of automatic target classification, and deploy to the FPGA development evaluation board for accuracy, throughput and other performance verification. The experimental results show that various network models can effectively realize the automatic classification of aerial reconnaissance and forensics targets, and have high throughput and accuracy, and the timeliness can meet the actual needs of the battlefield.

**Keywords:** reconnaissance and forensics; deep learning; gradient descent; hardware and software co-design

### 0 引言

为提高侦察取证设备智能化水平, 减少飞行员取证操作负担<sup>[1-3]</sup>, 基于深度学习技术开展侦察取证目标的端侧自动分类识别研究, 在进行模型的硬件部署时要具备较高实时性<sup>[4-5]</sup>。对比验证多个典型模型的可行性, 并基于软硬件协同实现方式在 FPGA 开发评估板上验证准确率与执行速度, 笔者深度学习模型及其硬件实现具有较高的识别精度和执行速率, 可有效减少设备操控对飞行员操作带来的压力。

### 1 空中侦察取证对象分析

#### 1.1 侦察取证场景分析

在航空侦察取证时需尽早尽多地获取对方信息, 如机型、弦号、挂载装备等。取证场景中, 双方之间是一个逐渐靠近的过程。在实验中发现, 如图 1 所示, 双方距离较近时, 军机占据整个取证设备的视野, 其国别标志与舷号相对清晰; 在双方距离较远时目标飞机可能只占据少数像素, 这对识别

分类模型提出了较高要求<sup>[6-7]</sup>。



(a) 大尺度目标



(b) 小尺度目标

图 1 大、小尺度目标对比

在基于深度学习进行目标识别模型设计时, 需

收稿日期: 2021-12-22; 修回日期: 2022-01-28

作者简介: 刘 克(1984—), 男, 广西人, 硕士, 讲师, 从事人工智能与大数据应用、火力与指挥控制研究。E-mail: 13232394@qq.com。

同时考虑准确率与运行效率 2 方面指标，以便模型的硬件部署。基于软硬件协同设计的思路，在 FPGA 开发评估板验证深度学习模型的部署性能。

### 1.2 数据集构建

深度学习模型的高精度依赖于大数据集的支持，大批量数据集是保证基于深度学习识别模型性能的前提。收集整理军机数据集，共规整为如表 1 所示的 13 类。每个类别各取 5 000、1 000 张组合成训练数据集、测试数据集。

表 1 外军军机数据集分类

序号	机型	类别
1	舰载直升机	RGB 彩色图像
2	鹰巴迪	
3	P-8A	
4	P-8	
5	EP-3	
6	EP-3E	
7	OP-3	
8	AP-3	
9	P-3K	
10	猎鹰 200	
11	YS-11EB	
12	C-130	
13	CP-140	

表中，类别为采集图像的设备成像机制，主要有 RGB 与红外图像 2 大类，这里均使用彩色图像。

另外，部分类别的相似程度较高，如 P-8、P-8A，EP-3、EP-3E 均改自同一基础型号，机型相似度高，只有负载不同。这种信息是判断其侦察目的要素之一，在利用深度学习进行机型等智能化判读时需注意对细粒度特征进行提取<sup>[8]</sup>。

## 2 基于深度学习的侦察目标分类模型构建

### 2.1 特征提取网络

如表 2 所示，综合对比 VGG16、VGG19<sup>[9]</sup>、ResNet-18、ResNet-34、ResNet-34-Res、ResNet-50-Res<sup>[10]</sup>、Inception-V1<sup>[11]</sup>等骨干网络模型的参数量、FLOPs，网络结构需选用参数量适中且准确率较高的模型。对这些网络结构均进行实现并实验分析，仅展示后文采用的 ResNet-18 网络结构。网络结构可视化如图 2 所示。

表 2 骨干网络模型体量对比

骨干网络	参数量(10 <sup>3</sup> )	FLOPs(10 <sup>6</sup> )
VGG16	138 344	15 470
VGG19	143 652	19 632
Inception-V1	6 826	1 583
ResNet-18	11 600	1 820
ResNet-34	21 608	3 644
ResNet-34-Res	21 780	3 664
ResNet-50-Res	23 967	3 856

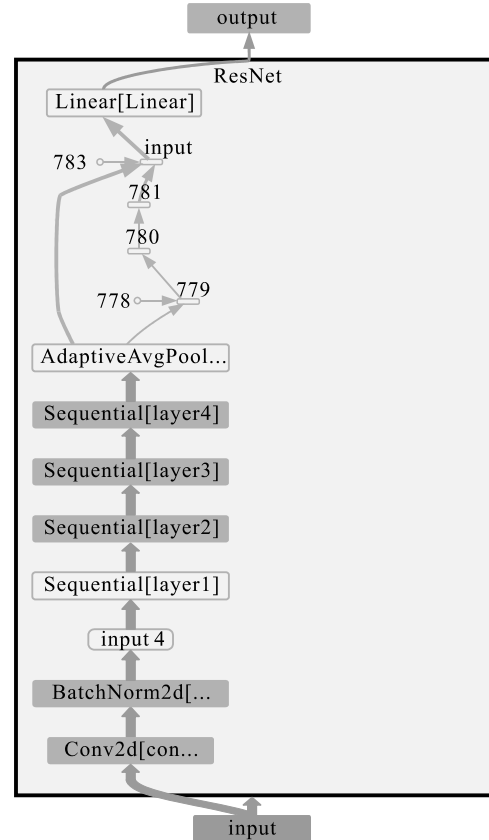


图 2 TensorBoard 中 ResNet18 网络结构可视化

### 2.2 模型训练设置

训练集 6.5 万张，测试集 1.3 万张，采用随机梯度下降法 SGD，用交叉熵损失函数如式(1)，设置参数如表 3 所示。

$$L(\omega) = \sum_{i=1}^N \sum_{c=1}^{1000} -y_{ic} \log f_c(x_i) + \varepsilon \|\omega\|_2^2 \quad (1)$$

表 3 训练参数配置

参数	设置
Batch size	128
SGD Momentum	0.9
学习率	0.01
L2 Weight decay	0.000 5
激活函数	ReLU
Dropout	0.5

权重衰减对于模型学习很重要，减少了模型的训练误差。权重  $w$  的更新规则为：

$$v_{i+1} = 0.9 \cdot v_i - 0.000 5 \cdot \varepsilon \cdot \omega_i - \varepsilon \cdot \left\langle \left( \frac{\partial L}{\partial \omega} \right) \Big|_{\omega_i} \right\rangle_{D_i};$$

$$\omega_{i+1} = \omega_i + v_{i+1} \quad (2)$$

其中： $i$  为迭代次数； $v$  为动力 Momentum 变量； $\varepsilon$  为学习率； $\left\langle \left( \frac{\partial L}{\partial \omega} \right) \Big|_{\omega_i} \right\rangle_{D_i}$  为在  $w_i$  处评估目标相对于  $w$  的导数在第  $i$  批样本  $D_i$  的平均值。

以高斯分布(0, 0.01)的方式初始化了每一层的权重，神经元偏置初始化为 1，使早期 ReLU 激活

函数获得正向的输入，能加快学习进程。其余层的神经元偏置初始化为常数 0。学习率初始化为 0.01。在整个训练过程中手动调整，所有层使用相同的学习率。当验证误差率在当前学习率下不再提高时，将学习率除以 10，在终止前降低 3 次。

### 3 实验及分析

考虑到侦察目标模型最终需要部署到嵌入式系统(FPGA 芯片)，需综合对比提取特征的骨干网络的准确率与运行效率。用于部署验证深层神经网络模型的是 ZCU-104 开发评估板，有可编程逻辑架构的 Zynq UltraScale+™MPSoC 器件，配备 FPGA 可编程逻辑器件芯片 XCZU7EV-2FFVC1156<sup>[12]</sup>。

#### 3.1 模型性能

在测试集上验证单模型的 Top-1 准确率如表 4 所示。ResNet 和 Inception 各有优点，ResNet 的网络结构规整简单，Inception 更复杂，一个更深，一个更宽。结合表 2 分析可知，VGG 系列的模型规模较大，准确率与 ResNet-34 相当，但 ResNet 系列的参数体量明显要少很多。Inception-V1 与 ResNet-18、ResNet-34 准确率相当，参数量少很多，FLOPs 也有一定差异<sup>[13]</sup>。

表 4 各网络模型准确率 %

骨干网络	准确率
VGG16	93.33
VGG19	94.89
Inception-V1	92.16
ResNet-18	93.54
ResNet-34	92.76
ResNet-34-Res	97.31
ResNet-50-Res	99.79

以 ResNet-18 为例，图 3 为训练时损失值变化，横轴为迭代次数，纵轴为损失函数值；图 4 为各个类别的 PR 曲线<sup>[14]</sup>，其中：P 为 precision(精准率)，R 为 recall(召回率)，代表精准率与召回率的关系。从其平衡点来看，基本都具备较好的识别性能。







图 3 训练时损失函数




(a) AP-3




(b) C-130



(c) CP-140



(d) EP-3



(e) EP-3E

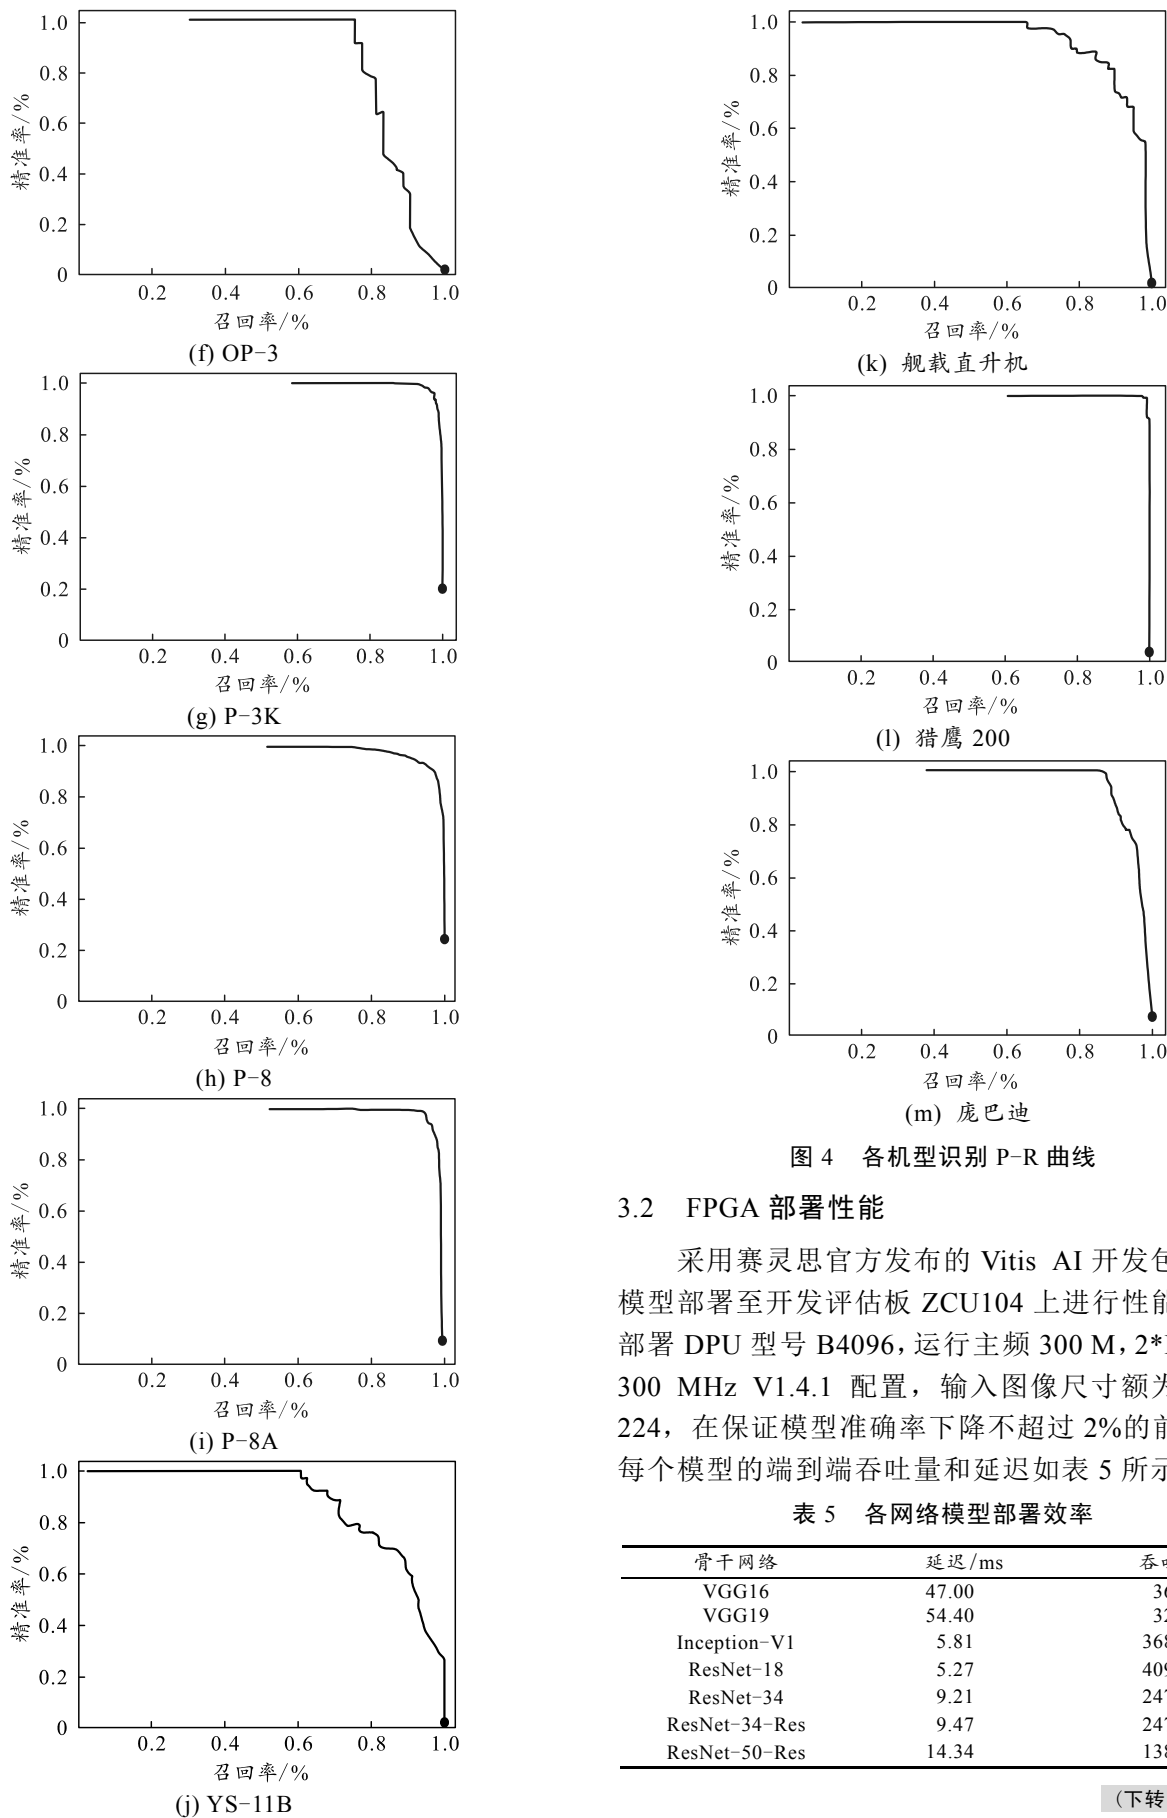


图 4 各机型识别 P-R 曲线

### 3.2 FPGA 部署性能

采用赛灵思官方发布的 Vitis AI 开发包将 6 个模型部署至开发评估板 ZCU104 上进行性能验证，部署 DPU 型号 B4096，运行主频 300 M，2\*B4096@300 MHz V1.4.1 配置，输入图像尺寸额为 224×224，在保证模型准确率下降不超过 2%的前提下，每个模型的端到端吞吐量和延迟如表 5 所示。

表 5 各网络模型部署效率

骨干网络	延迟/ms	吞吐量
VGG16	47.00	36.8
VGG19	54.40	32.4
Inception-V1	5.81	368.0
ResNet-18	5.27	409.7
ResNet-34	9.21	247.0
ResNet-34-Res	9.47	247.0
ResNet-50-Res	14.34	138.0