

文章编号:1001-5078(2024)05-0787-09

· 光电技术与系统 ·

基于多模复合探测方法的无人艇目标识别研究

周昇辉, 武军安, 郭锐

(南京理工大学 智能弹药技术国防重点学科实验室, 江苏 南京 210094)

摘要:随着水面无人艇技术的不断发展和应用,其对于舰船的威胁程度也日益加剧。以末敏弹打击水面无人艇为背景,为了提升多元激光/红外/毫米波探测器对水面小型目标的识别性能,提出了一种基于多通道卷积神经网络(Multi-Channel Convolutional Neural Network, MCCNN)和极端梯度提升决策树(Extreme Gradient Boosting, XGBoost)的复合探测信号识别方法MCCNN-XGB,同时构建了单通道CNN识别网络与基于人工特征提取的XGBoost识别算法作为对照,最终通过水面目标无人艇探测试验数据对上述三种模型的目标识别性能进行评估与对比。测试结果表明,基于MCCNN-XGB的识别算法表现最佳,测试准确率达到97.26%。本文所提出的识别方法能够有效进行复合探测信号的特征提取,并且能够降低误识别率与漏识别率,具有较好的识别效果。

关键词:末敏弹;水面无人艇;复合探测;目标识别;卷积神经网络;机器学习

中图分类号:TN959.1;TP391.41 文献标识码:A DOI:10.3969/j.issn.1001-5078.2024.05.019

Study on target recognition of USV based on multi-mode composite detection method

ZHOU Sheng-hui, WU Jun-an, GUO Rui

(ZNDY Ministerial Key Laboratory, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: With the continuous development and application of USV technology, its threat to ships is increasing. In order to improve the recognition performance of multi-component laser/infrared/millimeter wave detector on small surface targets, a composite detection signal recognition method MCCNN-XGB based on multi-channel convolutional neural network (Multi-Channel Convolutional Neural Network, MCCNN) and extreme gradient lifting decision tree (Extreme Gradient Boosting, XGBoost) is proposed. At the same time, a single channel CNN recognition network and XGBoost recognition algorithm based on artificial feature extraction are constructed as a comparison. Then, the target recognition performance of the above three models is evaluated and compared through the test data of UAV mount USV target. The test results show that the recognition algorithm based on MCCNN-XGB performs the best, with a test accuracy of 97.26%. The recognition method proposed in this paper can effectively extract the features of the complex detection signal, and can reduce the false recognition rate and missing recognition rate, which has a good recognition effect.

Keywords: terminal sensitive projectile; USV; multiple detection; object identification; CNN; machine learning

基金项目:面向成像式灵巧弹药的DCNN轻量化研究项目;高动态导航技术北京市重点实验室开放课题任务书项目资助。

作者简介:周昇辉(1999-),男,硕士研究生,研究方向为末敏弹目标识别技术研究。E-mail:13365473001@139.com

通讯作者:武军安(1989-),男,博士,博士后,研究方向为弹药智能化技术研究。E-mail:574732664@qq.com

收稿日期:2023-07-17

1 引言

末敏弹是一种具有“经济性突出、命中概率高、毁伤效果好、打后不用管”等优点的灵巧弹药,在飞行至敌方目标上空后利用敏感器进行目标探测,发现目标后立即引爆 EFP 战斗部,从而能对地面集群装甲实施有效打击。水面无人艇主要是以集群编队方式出现^[1],这种编队行进方式恰好符合末敏弹打击集群目标的特点,因此末敏弹打击水面无人艇目标方案应时而生。

无人艇表面材质大多采用玻璃纤维与不饱和聚酯树脂混合而成的玻璃钢复合材料^[2],相比于金属材料目标(陆地坦克、装甲车等),该材料在毫米波段具有一定的透波性,而透波率又取决于该复合材料的两种组成成分比例以及艇体厚度,此时无人艇的辐射能量为自身辐射能量与水面透射能量的叠加^[3],在无人艇艇壁厚度为 30 mm 时,3 mm 和 8 mm 波段的毫米波透射艇壁后的能量分别为透射前的 20.1% 和 47.6%,说明在 3 mm 波段下水面辐射能量对无人艇辐射能量的干扰更小,此时无人艇目标的辐射率为 0.31 以下,水面背景的辐射率为 0.63^[4],因而目标与背景在 3 mm 波段的毫米波辐射特性有明显差异。在红外辐射特性方面:首先,无人艇采用的主要动力系统是柴油机^[2],其正常工作温度为 75 °C ~ 95 °C,远超水面温度,二者在红外特性上差别很大;其次,太阳散射会使水面产生反射现象,因为太阳光在 3 ~ 5 μm 波段的辐射亮度比 8 ~ 12 μm 波段大两个量级^[5],所以长波段的水面反射亮温会远小于中波段;另外,在一天的不同时刻,长波段的水面亮温波动很小^[6],故选用 8 ~ 12 μm 波段的红外敏感器进行目标探测将会进一步减小背景的干扰性。在激光反射特性方面:平静水面和无人艇表面都较为光滑,具有良好的激光回波反射特性,而 905 nm 激光的大气透过率最高,衰减最小^[7],所以选用 905 nm 激光探测器进行测距更为精准。

基于人工特征提取的末敏弹传统目标识别方法,主要有三个步骤,分别是特征提取、特征选择和模型训练^[8]。首先选择峰值、脉宽、能量以及斜率等构成特征向量^[9];其次对所选特征集进行主成分分析(Principal Component Analysis, PCA)和特征判别分析等信号处理技术进一步选择敏感的特征以提升分类器的准确性^[8];最后将挑选的敏感特征输入

浅层机器学习模型进行训练,例如 BP 神经网络、支持向量机、梯度提升决策树 XGBoost 等^[10]。该类方法将目标识别问题划分为若干环节,并在每个环节获得局部最优解,识别准确率较高,但是需要大量的数据积累以及较为丰富的人工经验,倘若将工作环境改变,则先前经验可能会不再适用。

基于卷积神经网络(Convolutional Neural Network, CNN)的目标识别方法具有强大的自主提取特征能力,已经被应用于图像识别、语音识别等众多新领域。在末敏弹探测识别方面,以二维图像信号为识别样本的方案^[11-12]对扫描区域可进行更精细的成像式探测,能够对目标的细节特征进行描述,最终识别准确率较高,但存在以下几个问题:1) 处理速度慢,无法满足末敏弹实时性的要求;2) 硬件平台存在体积和功耗大的劣势。而以一维探测信号作为网络输入的方案^[9]数据处理速度极快,并且体积与功耗都大大降低,识别精度与成像式探测方案几乎相同,但该模型采用单通道 CNN,无法将多传感器所采数据视为一个整体来处理,不利于完整表达目标信息。上述两种方案还有一个共同的缺陷:所用分类器均为 CNN 中内置的 softmax。相比于 XGBoost 分类算法,softmax 分类器由指数函数组成,在数值计算过程中,很容易因为输出节点的值较大而发生数值溢出现象,其运算速度与准确度也都比较低,且类别数增加时,会影响 softmax 的拟合效果^[13]。

综上所述,为了实现末敏弹对水上目标的有效探测与识别,本文选用的探测体制为点元毫米波辐射计/6 元红外敏感器/6 元激光探测器,针对三模多元复合探测信号提出了一种结合多通道 CNN 和 XGBoost 的目标识别模型 MCCNN-XGB,并构建单通道 CNN 和基于人工特征提取的 XGBoost 识别算法作为对照,最终通过水面无人艇探测实验对本文所提方法进行实验分析和讨论。

2 CNN 与 XGBoost 基本原理

2.1 CNN

CNN 是一种有监督的深度学习模型,主要由卷积层、池化层以及全连接层堆叠组成。其中卷积层完成特征提取的工作;池化层可以对卷积层的特征进行筛选;最终的输出结果经过全连接层在分类器中实现目标分类功能。

在卷积层中,用卷积核对输入信号进行卷积运算,从信号起始处以固定步长滑动卷积核,对新的感受区域重复卷积运算,可得到输入信号特征。卷积运算过程如下:

$$x_l^i = f\left(\sum_r x_{l-1}^r * K_{l,r}^i + b_l^i\right) \quad (1)$$

其中, x_l^i 是第 l 层第 i 个输出特征图; x_{l-1}^r 是第 $l-1$ 层生成特征图的第 r 个卷积区域; $K_{l,r}^i$ 是第 l 层第 i 个卷积核的权重矩阵; b_l^i 是偏置值。通常每个卷积层后会增加一个池化层,可有效缩小参数矩阵尺寸,能起到加快计算速度和防止过拟合的作用。最大池化的表达式如下:

$$P_{i,m} = \max_{q_{i,k} \in R_m} q_{i,k} \quad (2)$$

其中, $P_{i,m}$ 表示池化区域的输出; R_m 表示一个池化区域。最后通过全连接层对提取的特征进行整合分类,并将其映射到样本标记空间,表达式如下:

$$\delta_k = f\left(\sum_{i=1}^n (w_{k,i} \cdot x_i) + b_k\right) \quad (3)$$

其中, δ_k 表示第 k 个神经元的输出; $w_{k,i}$ 是第 k 个神经元的第 i 个权重; b_k 是第 k 个神经元的偏置。

2.2 XGBoost

XGBoost 在原有的 GBDT 算法基础上进行了改进,成为了更高效的梯度提升决策树算法,核心思想是采用 boosting 方法,将多个弱学习器通过一定方法整合为一个强学习器进行共同决策。该模型支持交叉验证,可在设定的迭代次数之前停止树的生长,避免计算效率低下,同时还支持并行训练,可提高模型准确率以及预测速度。

在训练模型时首先定义一个目标函数,其中包含损失函数 L 和正则项 Ω ,损失函数是为了让预测值更加接近真实值,但过于接近可能会导致过拟合,因此增加一个正则性,用以控制基学习器的模型复杂度:

$$F_{obj}(\phi) = \sum_i L(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (4)$$

其中, y_i 是真实值; \hat{y}_i 是样本的估计值; K 表示树的数量。对于 CART 基学习器,正则项 Ω 包含了叶子数目 T 和权重向量 w ,为了使 CART 模型结构更为简单,二者都是越小越好:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (5)$$

假设现处于前向分布算法的第 t 步,则当前预

测结果可表示为:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (6)$$

将上式代入至损失函数 $L(y_i, \hat{y}_i)$ 中,并将其进行二阶泰勒展开,这样可有效减少模型参数,使目标函数更好地拟合非线性数据,同时运行速度更快,此时目标函数可改写为:

$$F_{obj}^{(t)} = \sum_{i=1}^n \left[L(y_i, \hat{y}_i^{(t-1)} + g f_t(x_i) + \frac{1}{2} h_t f_t^2(x_i)) \right] + \Omega(f_t) + \sum_{k=1}^{t-1} \Omega(f_k) \quad (7)$$

式中, $L(y_i, \hat{y}_i^{(t-1)})$ 是常数,可与最后的常数项合并化简,此时将正则项 Ω 代入上式,同时定义 G_j 为 j 号叶子节点上样本一阶导数和; H_j 为 j 号叶子节点上样本二阶导数和,则目标函数可转换为:

$$F_{obj}^{(t)} = \sum_{j=1}^n \left[G_j w_j + \frac{1}{2} (H_j + \lambda) w_j^2 \right] + \gamma T \quad (8)$$

由于求和公式中的每一项都是关于 w_j 的二次方程,因此令其导数为 0,可求出最优权重 $w_j^* = -\frac{G_j}{H_j + \lambda}$,此时目标函数最终为 $Obj^* = -\frac{1}{2}$.

$$\sum \frac{G_j^2}{H_j + \lambda} + \gamma T。$$

3 基于 MCCNN-XGB 的多模复合识别算法

3.1 数据预处理

本节采用下文水面无人艇多模探测试验部分数据构建训练样本,其中,红外信号表征目标与背景的温度差异,无人艇工作时,自身温度高于水面背景温度,故红外信号会先增强到一个峰值再逐渐减小,类似一个钟形;毫米波辐射计原理与其类似,也是被动探测目标的电磁波辐射强度,但在毫米波段,非金属目标相对于水面背景辐射亮温更低,因此输出波形是一个倒置的钟形;激光信号表征的是扫描点到末敏弹的距离,在扫描到目标时,距离变小,信号中会形成一个波谷,也是一个倒置的钟形。由于环境的复杂性以及仪器本身的特性,探测器采集得到的信号往往是非平稳、非光滑的,这为后续的数据处理会带来相当大的误差错误,因此需要对探测信号首先进行降噪处理。原始红外信号如图 1 所示,鉴于篇幅问题,其他两种原始信号不再展示。

LOWESS 滤波算法是一种局部加权光滑描点技术,该算法是在最小二乘法的基础上增加一个可滑动的窗口,在该窗口内,对其中的样本进行多项式拟

合,不断重复这个过程可得到在不同区间的加权回归曲线,最后将这些回归曲线的中心连在一起合成完整的回归曲线。经过多次实验比较,窗口大小选择为 64 时,处理后的数据既保持了一定的数据变化规律,又使得数据平滑,滤波效果最佳。滤波后的红外信号如图 2 所示。




图 1 原始红外信号图

Fig. 1 Original IR signal diagram




图 2 滤波红外信号图

Fig. 2 Filtered IR signal diagram

3.2 网络结构设计

3.2.1 基于 MCCNN-XGB 的多模信号特征提取

现有基于 CNN 模型的目标特征融合方案多采用多个单通道网络并行结构,这种结构会增加模型的复杂性和参数量,使得模型占用内存大,无法达到目标分类的实时性要求。针对上述问题,本节建立多输入通道 CNN 模型用来进行特征提取工作,将探测器采集信号构成 13 维信号集,在卷积神经网络的输入层构建 13 路输入通道,通道之间相互独立。该方法可以使目标的多种信息同时被当作一个整体对待,对于目标的状态信息表达更为完善,以达到降低虚警率和提高抗干扰性能的目的。该网络具体参数如表 1 所示。

表 1 MCCNN 模型参数配置

Tab. 1 MCCNN model parameter configuration

Network Layer	Parameter Configuration
Input layer	Channel 1, sample length: $1 \times M$
	Channel 2, sample length: $1 \times M$

	Channel 13, sample length: $1 \times M$
Conv L1	$in = 13 \times 800, n = 20, k = 1 \times 9, out = 20 \times 264$
Pool L2	$k = 1 \times 2, S = 2, out = 20 \times 132$
Conv L3	$in = 20 \times 132, n = 40, k = 1 \times 9, out = 40 \times 42$
Pool L4	$k = 1 \times 2, S = 2, out = 40 \times 21$
FC	840

注: Conv 为卷积层, Pool 为池化层, FC 为全连接层, in 表示输入尺寸, n 表示卷积核数量, k 表示卷积核尺寸, out 表示输出尺寸

具体参数设置:

1) 归一化: 归一化层不仅可以提高网络的泛化能力,还能够加快网络训练与收敛速度,提高网络训练效率,另外,卷积层的输出是一个对称非稀疏的分布,因此将归一化层放置于卷积层后会使得卷积层的分布变得更加稳定。本模型选用批标准化(BN)方法,由于该方法能够很好的控制权重值的更新幅度,因此可有效防止梯度消失与梯度爆炸, BN 层对样本数据标准化处理的方式如下:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (9)$$

其中, μ_B 为样本均值; σ_B^2 为样本方差,并添加了移动和缩放功能对 BN 层进行优化,引入了 γ 和 β 两个参数,可以使模型学习恢复出原始网络所要学习的特征分布:

$$y_i = \gamma \hat{x}_i + \beta \quad (10)$$

2) 激活函数: 激活函数层主要用来加入非线性因素以提高模型的表达能力,本实验选用 *Relu* 激活函数:

$$F_{Relu}(x) = \max\{0, x + N(0, \sigma(x))\} \quad (11)$$

相比于需要使用指数计算的 sigmoid 和 tanh 函数, Relu 的计算更为简单,能够在硬件实现,并且可以加速学习和简化模型。

3.2.2 基于 MCCNN-XGB 的多模信号特征分类

由于 XGBoost 分类模型可以在特征粒度上实现并行处理,相较于 softmax 分类器和线性分类器,其更能充分利用信号特征拟合数据。因此,我们可以

设计 XGB 模型对 MCCNN 网络提取的特征向量进行分类,以取得更好的结果。

XGB 模型诸多参数的调节对于模型的训练至关重要,其中,Booster 参数选择 gbtree,表示使用基于树的模型进行计算,符合本文提取的特征分类;由于 XGBoost 为了防止过拟合,采取了不完全信任每个弱学习器学到的残差值,因此需要给每个弱学习器拟合的残差值都乘上(0,1]的 eta;Max_depth 表示树的最大深度,合理设置可有效防止过拟合,一般取值 5~10 之间;random_state 是为了保证程序每次运行分割的训练集与测试集相同,有利于调整参数。subsample 是控制每棵树随机采样的比例,由于 CNN 所提取的特征数量多于人工提取的特征数量,所以该值不易设置过小,防止欠拟合。具体主要参数如表 2 所示。

表 2 XGBoost 模型参数配置

Tab.2 XGBoost model parameter configuration

Parameter	Value
Booster	gbtree
Num_class	2
Max_depth	7
Gamma	0.1
Subsample	0.6
Eta	0.025
Objective	softmax

综上所述,MCCNN-XGB 模型整体结构如图 3 所示,识别流程图如图 4 所示




图 3 MCCNN 模型结构图

Fig.3 MCCNN model structure diagram

4 试验结果与分析

4.1 试验过程与样本构建

探测试验以我国南方某水域为水面背景,无人艇目标全长 8 m,最大宽度 2.5 m,其位置与岸边垂直距离为 200 m;无人机挂载三模多元探测器飞行至目标上空垂直距离 150 m、水平距离 50 m 处。试验进行时,无人机以 10 m/s 的速度水平飞行,探测

器以 30°探测角、4 r/s 转速、5 k 采样率的条件进行工作。图 5 为无人机挂载探测器,图 6 为目标场景。

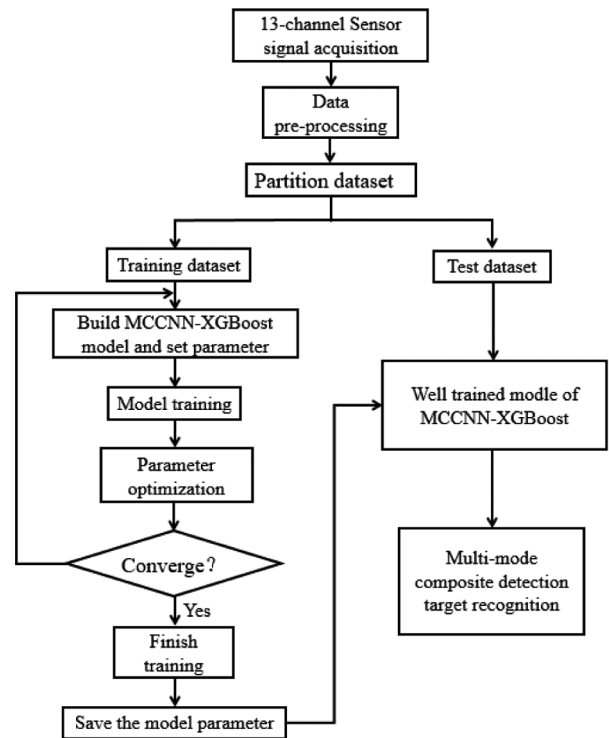


图 4 识别流程图

Fig.4 Recognition flow diagram



图 5 无人机挂载探测器

Fig.5 UAV mount detector




图 6 目标场景

Fig.6 Target scene

多模复合信号数据集来自上述水面无人艇探测试验数据,包含红外敏感器、激光探测器和毫米波辐射计三种探测信号。根据采样率与无人机飞行速

度,为了充分捕捉有目标的时段,采用了长度为 800 的滑动窗口对信号进行截取,同时为了确保正样本与负样本的数量大致相等,采用截取窗口变滑动步长策略,即有目标区域采用小步长,无目标区域采用大步长,最终获得总样本 5930 个,其中正样本(有目标)2955 个,负样本(无目标)2975 个,并按照 3:1 的比例将数据集划分为训练集、测试集。三模敏感器的正样本示例如图 7,从左至右分别为红外信号,毫米波信号以及激光信号。




图 7 三模敏感器正样本示例

Fig. 7 Three mode sensor positive sample example

4.2 对比试验设计

本节分别设计单通道 CNN 模型和 XGBoost 模型,并与本文所提出的 MCCNN-XGB 识别模型在同

样的信号数据下进行目标识别测试,以此验证本文所提模型性能优越性。

4.2.1 单通道 CNN

该网络是在输入层之后产生多个分支,每个分支连接一个单通道网络,网络各自独立并且仅对一路信号进行单独卷积以此提取其特征,然后在全连接层以叠加方式完成特征融合,最后将融合特征输入分类器进行分类。单通道 CNN 模型结构如图 8 所示,单个网络主要参数如表 3。




图 8 单通道 CNN 模型结构图

Fig. 8 Single-channel CNN model structure diagram

表 3 单通道 CNN 模型参数配置

Tab. 3 Single-channel CNN model parameter configuration

Network Layer	Parameter Configuration
Conv L1	$in = 1 \times 800, n = 1, k = 1 \times 9, out = 260$
Pool L2	$k = 1 \times 2, S = 2, out = 130$
Conv L3	$in = 1 \times 130, n = 1, k = 1 \times 9, out = 40$
Pool L4	$k = 1 \times 2, S = 2, out = 20$
FC	20×13

注:Conv 为卷积层,Pool 为池化层,FC 为全连接层, in 表示输入尺寸, n 表示卷积核数量, k 表示卷积核尺寸, out 表示输出尺寸

本模型分类器选用 softmax 分类器,其原理如下:

$$F_{\text{softmax}}(x_i) = \frac{e^{x_i}}{\sum_{c=1}^C e^{x_c}} \quad (12)$$

其中, x_i 为第 i 个节点的输出值; C 为输出节点的个数。经过指数形式的 softmax 可以将差距更快拉大,加快梯度下降过程。损失函数选用 BCEWithLogitsLoss 函数,该函数可防止由于节点输出值较大而发生的溢出现象,原理如下:

$$F_{\text{loss}} = - [y_n \cdot \log(\sigma(x_n)) + (1 - y_n) \cdot \log(1 - \sigma(x_n))] \quad (13)$$

其中, x_n 为经过 sigmoid 函数处理的第 n 个样本对应的模型输出; y_n 为第 n 个样本对应的类别。

4.2.2 人工特征 XGBoost

在该模型中,特征选择与提取是最关键的一步,传统方式是将三种信号的峰值(谷值)、斜率、脉宽以及面积四个特征作为特征向量。现随机选取 300 组正样本和负样本,分别对所取样本中三种探测信号进行上述四个特征的提取,并计算每个特征在正样本和负样本中的平均值。正负样本特征均值如下图,图 9、10、11 分别代表红外、毫米波和激光信号。

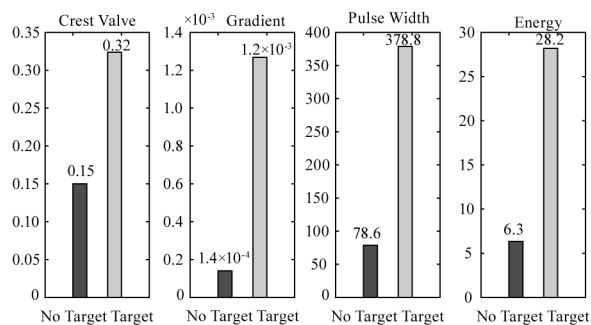


图 9 红外信号特征均值

Fig. 9 IR signal average feature value




图 10 毫米波信号特征均值

Fig. 10 MMW signal average feature value

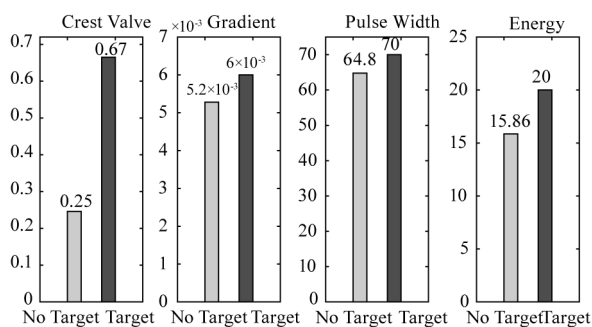


图 11 激光信号特征均值

Fig. 11 Laser signal average feature value

通过观察正负样本特征值对比图可发现,毫米波信号脉宽特征对比不明显,而激光信号只有峰值特征对比最为明显。因此在进行特征提取操作时,对于红外信号,选择其峰值、斜率、脉宽和能量特征;对于毫米波信号,选择其峰值、斜率和能量特征;而

对于激光信号,只选择其峰值特征。现将 13 路探测信号按照上述选择进行特征提取,并将所提取特征依次排列构成 33 维的向量矩阵,作为人工特征 XGBoost 模型的输入。

根据所选特征对模型的参数进行设置与调整,最终参数如表 4 所示。

表 4 人工特征 XGBoost 模型参数配置

Tab. 4 Manual feature XGBoost model

parameters configuration	
Parameter	Value
Booster	gbtree
Num_class	2
Max_depth	15
Min_child_weight	3
Gamma	0.5
Subsample	0.8
Eta	0.025
Objective	softmax

4.3 评估指标

本文具体采用准确率、精确率、召回率和 F1 值四个评价指标对本文提出的 MCCNN - XGB 模型与所设计对比试验模型的识别效果进行衡量,通过混淆矩阵对四个评价指标进行计算,TP 和 TN 分别表示预测正确的正样本数量和预测正确的负样本数量,FP 和 FN 分别表示预测错误的正样本数量和预测错误的负样本数量。

准确率表示预测正确的样本数量占总样本数量的比例,公式为:

$$R_{acc} = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

精确率表示预测正确的正样本数量占预测为正样本数量的比例,公式为:

$$R_{pre} = \frac{TP}{TP + FP} \quad (15)$$

召回率表示预测正确的正样本数量占实际正样本数量的比例,公式为:

$$R_{recall} = \frac{TP}{TP + FN} \quad (16)$$

通常情况下,精确率的提升可降低误识别的概率,但可能导致漏识别概率上升;而召回率的提升可降低漏识别概率,但会导致误识别概率上升,二者存

在矛盾性。为了综合评判模型的识别能力,则使用 F1 评价指标, F1 是精确率和召回率乘积的两倍再除以两者之和,该值越大,说明模型的识别能力越强,公式如下:

$$F1 = \frac{2 \times R_{pre} \times R_{recall}}{R_{pre} + R_{recall}} \quad (17)$$

4.4 实验结果与分析

为了表明三模多元复合探测的优势,以三模点源探测信号作为对照组,并基于本文提出的 MCCNN-XGB 模型及其对比模型进行训练,最终在测试集上所得各项指标如表 5 所示。

表 5 各模型性能对比

Tab. 5 Performance comparison of each model

Model	R_{acc}	R_{pre}	R_{recall}	$F1$
Single-channel CNN (uni-sample)	0.9066	0.9368	0.9137	0.9251
Single-channel CNN (multi-sample)	0.9353	0.9475	0.9549	0.9512
Manual feature XGBoost (uni-sample)	0.9133	0.8775	0.9449	0.9099
Manual feature XGBoost (multi-sample)	0.9339	0.9272	0.9359	0.9305
MCCNN-XGB (uni-sample)	0.9237	0.9160	0.9348	0.9253
MCCNN-XGB (multi-sample)	0.9726	0.9717	0.9734	0.9725

根据表 5 可以看出:

(1) 所有模型的准确率均在 90% 以上,并采用相同的识别模型时,三模多元信号能够比三模点元信号提供更丰富的信息,获得更好的识别效果。

(2) 对于相同的样本, MCCNN-XGB 模型表现最佳,相较于其他两个网络,该模型不仅提升了准确率,还尽可能的降低了对非目标的误识别率和对目标的漏识别率。这说明 MCCNN 所提取的更高维度特征比人工提取的特征表现出了更多隐藏信息,使得准确率大幅提升;而将 XGBoost 分类器是在特征粒度上并行迭代运算,能够快速的对特征值进行重要性排序实现高效数据拟合,使得精确率和召回率二者可以最大限度达到平衡。

5 结论

本文对于末敏弹的水面目标探测识别问题,利

用卷积神经网络与 XGBoost 相结合的网络模型,提出了基于 MCCNN-XGB 的末敏弹三模多元复合识别方法,取得了较好的识别效果。实验表明,三模多元复合信号相比于三模点源信号能够提供更丰富的信息,获得更高的识别准确率;对于多元复合信号, CNN 所提取的特征相比于人工提取的特征维度更高,能够挖掘出更深层的隐藏信息,并且基于 XGBoost 的分类算法能够在保证准确率的同时,平衡误识别率和漏识别率。

但本文对于网络的超参数设置仍需手动调参,有一定的局限性,对于模型参数的智能化选取还可以进一步研究;另外,该模型的训练需要标签数据进行全监督式学习,耗费时间与人力,因此将网络与无监督算法相结合是未来的研究方向。

总体上,本文所提识别方法能够避免单种网络的弊端,获得出色的识别效果,相比于传统方法,可以为末敏弹进行水面目标探测识别方案提供参考。

参考文献:

- [1] Wang Shi, Zhang Jianqiang, Yang Shuhui, et al. Research on development status and combat applications of USVs in worldwide[J]. Fire Control & Command Control, 2019, 44(2): 11-15. (in Chinese)
王石, 张建强, 杨舒卉, 等. 国内外无人艇发展现状及典型作战应用研究[J]. 火力与指挥控制, 2019, 44(2): 11-15.
- [2] Shen Yunlei, Gao Xiaopeng. Research status and progress of unmanned surface vehicle[J]. Marine Electric & Electronic Technology, 2018, 38(9): 7-10. (in Chinese)
申云磊, 高霄鹏. 无人艇的研究现状与进展[J]. 船电技术, 2018, 38(9): 7-10.
- [3] Sun Baohua, Wang Xinghua, Gao Yu. Study on the factors affecting the transmitting property of magnetic wave through glass/unsaturated polyester resin composites[J]. Fiber Composites, 2002(2): 13-16. (in Chinese)
孙宝华, 王兴华, 高禹. 影响玻璃纤维/不饱和聚酯树脂复合材料透波性能因素的研究[J]. 纤维复合材料, 2002(2): 13-16.
- [4] Yan Guangli. Research on multi-mode composite detection signal recognition of terminal sensitive projectiles based on deep learning[D]. Nanjing: Nanjing University of Science and Technology, 2021. (in Chinese)
闫广利. 基于深度学习的末敏弹多模复合探测信号识

- 别研究[D]. 南京:南京理工大学,2021.
- [5] Chen Bin. Research on infrared radiation characteristics of naval vessel target in the sea background [D]. Harbin: Harbin Institute of Technology,2015. (in Chinese)
陈彬. 海面背景下舰船目标红外辐射特性研究[D]. 哈尔滨:哈尔滨工业大学,2015.
- [6] Shi Jiabao. Research on radiation scattering of sea-sky background environment [D]. Xi'an: Xidian University, 2009. (in Chinese)
施加宝. 海天背景的红外辐射散射特性研究[D]. 西安:西安电子科技大学,2009.
- [7] Shi Mingsen. Laser pulse scattering characteristic of target above complex background and its application [D]. Xi'an: Xidian University,2021. (in Chinese)
史铭森. 复杂背景下目标的激光脉冲波束散射特性及其应用[D]. 西安:西安电子科技大学,2021.
- [8] Li Hongmei. Research about intelligent fault diagnosis method based on convolutional neural network [D]. Taiyuan: North University of China,2021. (in Chinese)
李红梅. 基于卷积神经网络的智能故障诊断方法研究[D]. 太原:中北大学,2021.
- [9] Yan Guangli, Guo Rui, Liu Rongzong, et al. Recognition method of compound detection signal of terminal sensitive sub-ammunition based on convolutional neural network [J]. Laser & Infrared,2022,52(4):564-570. (in Chinese)
闫广利,郭锐,刘荣忠,等. 基于卷积神经网络的末敏弹复合探测信号识别方法[J]. 激光与红外,2022,52(4):564-570.
- [10] Jiang Zhangtao. Research on terminal sensitive composite detector technology and detection probability [D]. Nanjing: Nanjing University of Science and Technology,2016. (in Chinese)
蒋张涛. 末敏复合探测器技术与探测概率研究[D]. 南京:南京理工大学,2016.
- [11] Wu Junan, Guo Rongzong, Liu Rongzong, et al. A light-weight convolutional neural network target recognition method for missile-borne fuse linear array infrared and lidar-scanning image [J]. Journal of Ballistics, 2021, 33(3):89-96. (in Chinese)
武军安,郭锐,刘荣忠,等. 用于弹载线阵红外与激光扫描成像引信的轻量化卷积神经网络目标识别方法[J]. 弹道学报,2021,33(3):89-96.
- [12] Hou Yuwei. Study on compression and acceleration of convolutional neural networks for missile-borne target recognition systems [D]. Nanjing: Nanjing University of Science and Technology,2022. (in Chinese)
侯宇威. 面向弹载目标识别系统的卷积神经网络压缩与加速研究[D]. 南京:南京理工大学,2022.
- [13] Tang Ruonan. A clutter recognition algorithm for complex scenes base on machine learning [D]. Chendu: Sichuan University,2021. (in Chinese)
唐若男. 基于机器学习的复杂场景杂波识别算法[D]. 成都:四川大学,2021.