

## 多窗口谱图分析的低截获概率雷达信号识别\*

刘鲁涛<sup>1</sup>, 陈林军<sup>1</sup>, 李品<sup>2</sup>

(1. 哈尔滨工程大学信息与通信工程学院, 黑龙江哈尔滨 150001; 2. 南京电子技术研究所, 江苏南京 210000)

**摘要:**在当前复杂的战场环境中,低截获概率雷达信号因其具有大时宽带宽积、强干扰性能、高分辨率和低截获性特点得到了广泛应用,传统的雷达侦察手段很难对其进行有效识别。在低截获概率雷达典型调制分析的基础之上,研究基于人工智能的雷达信号分类识别方法。从低截获概率雷达信号时频特征入手,提出基于多窗口时频谱图分析方法。该算法采用 Hermite 函数作为谱图分析的窗函数,利用多个窗函数进行谱图分析,获得了聚集性更佳的有效信号,分散了噪声干扰,并且使信号调制特征的时频分析特征更加明显。在多窗口时频谱图基础上,采用迁移学习的思想,利用 ImageNet-VGG-f 神经网络完成信号的分类识别任务。实验结果表明,在低信噪比情况下,所提算法的性能优于传统的崔威廉姆斯分布和平滑伪维格纳分布方法。

**关键词:**低截获概率雷达;多窗口;迁移学习;信号识别

中图分类号:TN95 文献标志码:A 文章编号:1001-2486(2022)02-112-06

## Low probability of intercept radar signal recognition based on multi-window spectrogram analysis

LIU Lutao<sup>1</sup>, CHEN Linjun<sup>1</sup>, LI Pin<sup>2</sup>

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China;

2. Nanjing Research Institute of Electronic Technology, Nanjing 210000, China)

**Abstract:** In the current complex battlefield environment, low probability of intercept radar signal has been widely used due to their large time-bandwidth product, strong anti-jamming performance, high resolution and low interception. It is difficult to identify the low probability of intercept radar signal by traditional radar reconnaissance methods. Based on the analysis of typical modulation of low probability of intercept radar, a radar signal classification and recognition method based on artificial intelligence was studied. Starting from the time-frequency characteristics of low probability of intercepted radar signals, a multi-window spectrogram analysis method was proposed. In this algorithm, Hermite function was used as the window function of spectrum analysis, and multiple window functions were also used for spectrum analysis. The effective signal with better aggregation is obtained, the noise interference is dispersed, and the time-frequency analysis characteristics of signal modulation characteristics are more obvious through this algorithm. On the basis of multi-window spectrogram, the idea of transfer learning was adopted, and ImageNet-VGG-f neural network was used to complete the task of signal classification and recognition. Experimental results show that the performance of the proposed algorithm is better than the traditional Choi-William distribution and Smooth and Pseudo Wigner-Ville distribution methods at low signal-to-noise ratio.

**Keywords:** low probability of intercept radar; multi-window; transfer learning; signal recognition

自从雷达技术问世以来,由于其重要的检测应用,该技术取得了非凡的成就<sup>[1]</sup>。同时,雷达对抗技术也在逐渐发展,对抗系统能够在雷达发现目标之前截获信号并进行干扰。而低截获概率(Low Probability of Intercept, LPI)雷达具有良好的隐身效果,这对侦收到的雷达辐射源信号识别提出了巨大的挑战<sup>[2-3]</sup>。因此,在现代雷达电子对抗系统中,LPI 雷达信号识别已成为研究热点之一<sup>[4]</sup>。现有的文献中,有一些 LPI 雷达信号识

别技术首先对雷达信号进行特征提取,然后将提取的特征送入分类器中进行分类识别。

对于特征提取,一般采用时频分析将一维的雷达信号转换到时频域,得到时频图像,常见的时频分析算法有短时傅里叶变换(Short-Time Fourier Transform, STFT)、维格纳分布(Wigner-Ville Distribution, WVD)<sup>[5-6]</sup>,平滑伪维格纳分布(Smoothing Pseudo-Wigner-Ville Distribution, SPWVD)<sup>[7]</sup>和崔威廉姆斯分布(Choi-William

\* 收稿日期:2020-09-07

基金项目:国家自然科学基金资助项目(61801143);中央高校基本科研业务费专项资金资助项目(3072020CF0815)

作者简介:刘鲁涛(1977—),男,黑龙江哈尔滨人,副教授,博士,博士生导师,E-mail:liulutao@hrbeu.edu.cn

Distribution, CWD)<sup>[2-3]</sup>。另一方面,对于分类识别部分,由于卷积神经网络(Convolutional Neural Networks, CNN)在图像识别领域<sup>[8]</sup>内极高的识别准确率,不少学者将CNN与LPI雷达信号识别相结合:文献[9]将信号的脉宽、载频和脉冲重复间隔作为特征空间,形成三维图像,输入到CNN中实现58个独立辐射源的识别;文献[10]利用CWD时频变换和进化神经网络(Evolutionary Neural Networks, ENN)进行辐射源信号的识别,在信噪比-2 dB条件下,对8种辐射源信号的识别率达到94.7%;文献[11]将时频图像和图像形态学操作相结合,利用图像形态学操作消除时频图像中的部分噪声,并将时频图像送入CNN,实现了8种辐射源信号的识别。

针对低信噪比条件下多种类辐射源信号识别率低的问题,本文提出基于多窗口谱图(Multi Window SPectrogram, MWSP)分析与迁移学习ImageNet-VGG-f网络相结合的LPI雷达信号识别算法,即MWSP-ImageNet-VGG-f。多窗口谱图算法采用Hermite函数作为窗口函数进行谱图分析,通过不断改变Hermite多项式得到一系列窗函数,利用它们进行谱图分析,使得有效信号得到了好的聚集而分散了噪声的干扰聚集。该方法首先利用多窗口谱图变换对辐射源信号进行时频变换,转换为时频域的时频图像,再将时频图像送入VGG-f网络中进行分类识别。

## 1 LPI 雷达信号模型与识别流程

侦察接收机的截获作用范围小于雷达对目标的探测范围,这说明此时雷达能够探测目标但是侦察接收机无法作用于雷达,这种雷达辐射的信号称为“低截获概率雷达信号”。脉冲压缩技术能够使雷达信号满足低截获概率特性,常见的脉冲压缩方法有频率调制、相位调制等。

LPI雷达信号调制类型识别流程一般由时频变换和分类识别组成,首先将时域信号进行时频分析以得到时频域的图像,再将时频图像进行一系列预处理,最后送入分类网络中进行识别。

### 1.1 信号模型

雷达接收机接收到的信号由信号和噪声构成,它的数学模型为:

$$s(t) = x(t) + n(t) \quad (1)$$

$$x(t) = \text{Arec} \left[ \frac{t}{T} \right] \exp \left\{ j \left[ 2\pi f_c t + \phi(t) + \phi_0 \right] \right\} \quad (2)$$

其中: $s(t)$ 表示接收的雷达信号; $x(t)$ 表示调制信

号; $n(t)$ 表示高斯白噪声; $A$ 表示幅度,因为雷达信号一般不采用幅度调制, $A$ 是常数; $T, f_c$ 和 $\phi_0$ 分别是脉冲宽度、载频和初始相位; $\phi(t)$ 是相位调制函数。

高斯白噪声模型定义为 $X \sim N(0, \sigma_N^2)$ ,概率密度函数服从高斯分布,均值为零,方差为 $\sigma_N^2$ ,则信噪比数学表达式为:

$$\begin{aligned} SNR &= 10 \times \lg \left( \frac{E[s(t)s^*(t)]}{E[n(t)n^*(t)]} \right) \\ &= 10 \times \lg \left( \frac{E[s(t)s^*(t)]}{\sigma_N^2} \right) \end{aligned} \quad (3)$$

后续仿真中出现的含噪信号是通过先计算信号的功率,然后根据信噪比来计算噪声功率以得到噪声后再与原始信号相加而得。

常见的LPI雷达信号调制方式包括频率调制和相位调制,例如,线性调频信号是一种频率调制信号,频率随时间线性变化,其信号表达式为:

$$x(t) = \text{Arec} \left[ \frac{t}{T} \right] \exp \left[ j(2\pi f_c t + \pi k t^2) \right] \quad (4)$$

非线性调频信号也是一种频率调制信号,频率随时间非线性变化,常见的非线性调频信号有正弦调频信号、三次调频信号和任意频率调频信号等。下面主要介绍正弦调频信号(Sinusoidal Frequency Modulation, SFM),其信号表达式为:

$$x(t) = \text{Arec} \left[ \frac{t}{T} \right] \exp \left\{ j \left[ 2\pi f_c t + \frac{k}{2f_0} \sin(2\pi f_0 t) \right] \right\} \quad (5)$$

上述信号和其他LPI雷达信号的参数设置在后续调制方式识别仿真研究过程中给出。

### 1.2 调制信号特征提取与识别流程

LPI雷达信号调制识别过程主要分为两个过程,首先通过时频分析算法产生时频图像;然后对时频分布图像进行预处理,如:二值化、调整图像大小等,调整图像使其满足分类网络的输入条件;最后将预处理过的时频图像送入分类网络进行调制方式识别。具体分类识别流程如图1所示。

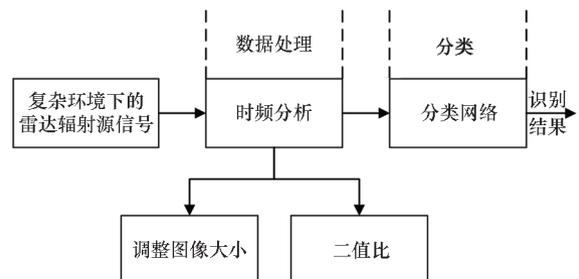


图1 LPI 雷达信号调制识别流程

Fig. 1 LPI radar signal modulation recognition process

## 2 MWSP 时频分析算法

时频分析是处理诸如雷达信号等非平稳信号的有效工具,时频图像的形状有助于显示不同类型的雷达信号之间的差异。常用的时频分析方法有 STFT、WVD、CWD 变换等。WVD 定义为:

$$W_x(t, \omega) = \int_{-\infty}^{+\infty} x\left(t + \frac{\tau}{2}\right)x^*\left(t - \frac{\tau}{2}\right)e^{-j\omega\tau} d\tau \quad (6)$$

WVD 虽然具有良好的时频分辨率,但是由于交叉项的存在,WVD 对噪声非常敏感。

STFT 是最常用的一种时频分析方法,该方法通过时间窗口内的截取信号来表示某一时刻的信号特征,定义为:

$$T_x(t, \omega) = \int_{-\infty}^{+\infty} x(\tau)g^*(\tau - t)e^{-j\omega\tau} d\tau \quad (7)$$

而谱图<sup>[12]</sup>是由 STFT 得到的,其定义式为:

$$S_x(t, \omega) = |T_x(t, \omega)|^2 = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} W_x(\tau, u)W_g^*(t - \tau, \omega - u) d\tau du \quad (8)$$

多窗口时频谱图算法是多窗口理论结合谱图的时频分析方法,多窗口思想首次由 Thomson 提出,利用多个正交窗口求各自的谱估计<sup>[13]</sup>,再综合在一起,用来增加谱估计的精度和减少谱估计的振荡,而 Bayram 等应用 Hermite 函数将 Thomson 提出的多窗口方法扩展到时间-频率平面<sup>[14]</sup>。

$$M_K(t, \omega) = \sum_{k=0}^{K-1} d_k S_x^{(h_k)}(t, \omega) = \sum_{k=0}^{K-1} d_k \left| \int_{-\infty}^{+\infty} x(\tau)h_k^*(\tau - t)e^{-j\omega\tau} d\tau \right|^2 \quad (9)$$

将多窗口和谱图分析结合,采用 Hermite 函数作为窗口函数进行时频谱图分析,在低信噪比条件下,达到良好的抗噪性能。Hermite 函数具有正交性,在时间-频率平面具有良好的时频聚集性,图 2 是 Hermite 函数时域图(图中坐标无实际单位,仅表示关系)。

$k$  次 Hermite 函数<sup>[15]</sup>定义为:

$$h_k(t) = \frac{1}{\sqrt{\sqrt{\pi}2^k k!}} e^{-\frac{t^2}{2}} H_k(t) \quad k=0,1,2, \dots, K-1 \quad (10)$$

式中, $H_k(t)$  ( $k \in N$ ) 是  $k$  次 Hermite 多项式。

$$H_k(t) = (-1)^k e^{t^2} \frac{d^k}{dt^k} e^{-t^2} \quad k=0,1,2, \dots, K-1 \quad (11)$$

容易看出: $H_0(t) = 1, H_1(t) = 2t, H_2(t) = 4t^2 - 2, H_3(t) = 8t^2 - 12t, \dots$ 。

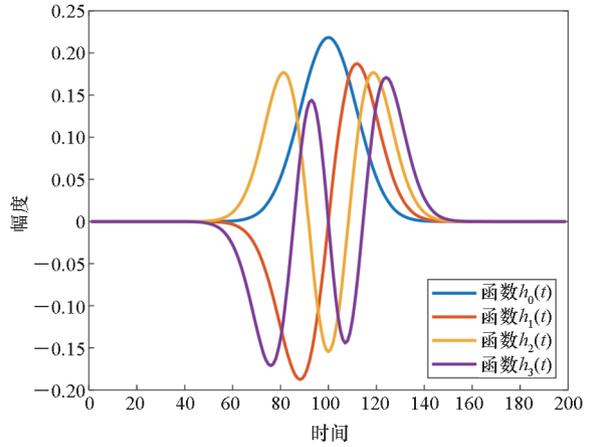


图 2 Hermite 函数时域图( $k=0,1,2,3$ )

Fig. 2 Hermite function time domain diagram ( $k=0,1,2,3$ )

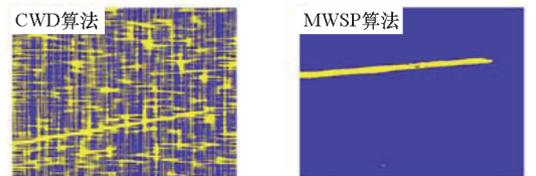
多窗口谱图算法定义如下:

$$M_K(t, \omega) = \sum_{k=0}^{K-1} d_k P_x^{(g_k)}(t, \omega) \quad k=0,1,2, \dots, K-1 \quad (12)$$

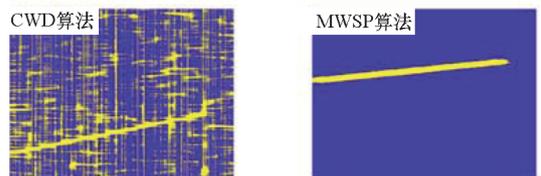
式中, $d_k$  是加权系数,且  $\sum d_k = 1$ 。

采用 MWSP 和 CWD 算法分别对典型的 LFM 信号进行信噪比对比仿真实验,信噪比范围设定为  $[-8, -2]$  dB,步进为 2 dB,对比 MWSP 算法、CWD 算法进行全局阈值二值化后的时频分布图像。仿真结果如图 3 所示。

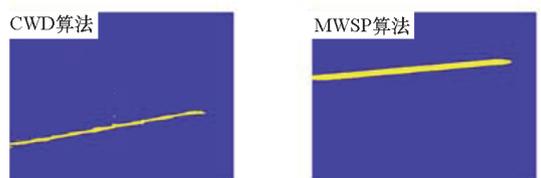
仿真结果表明:MWSP 算法对比 CWD 算法具有良好的抗噪性能,在信噪比低于  $-6$  dB 时,CWD 算法产生的时频分布图像已经完全被噪声



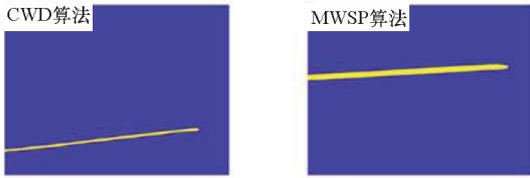
(a) SNR = -8 dB



(b) SNR = -6 dB



(c) SNR = -4 dB



(d) SNR = -2 dB

图 3 LFM 的 CWD 和 MWSP 算法对比

Fig. 3 Comparison of LFM's CWD and MWSP algorithms

淹没,无法正常分辨;而 MWSP 算法产生的时频分布图像具有良好的抗噪性能。

### 3 ImageNet-VGG-f 网络

深度卷积神经网络模型具有良好的分类效果,但需要经过上百万个参数的训练,所以 Deep-CNN 在训练的时候需要大量的有标签样本和时间才能够得到具有良好泛化能力的模型。在训练样本不足、训练时间有限的条件下,可以利用预训练好的模型来迁移到新的数据中,将训练数据送入预训练的网络中进行训练,在短时间内达到良好的分类识别的效果。

预训练 ImageNet-VGG-f 网络通过 ImageNet 数据集完成训练<sup>[16]</sup>,ImageNet 任务包含 1 000 类图像的分类与定位。VGG 网络模型采用 3 × 3 的卷积核,2 × 2 的池化核,用 2 个 3 × 3 的卷积核堆叠等同 5 × 5 的感受野,用 3 个 3 × 3 的卷积核堆叠等同 7 × 7 的感受野。虽然采用的是小卷积核,在相同步长情况下,产生的特征图跟大卷积核相差不多,但是计算量小了很多。VGG 网络结构虽深但比较简单,因为只有 CNN 足够深,才能够更好地表达图像特征。

采用 ImageNet-VGG-f 网络模型进行调制类型识别<sup>[17]</sup>,对于该网络结构的研究可以对 Deep-CNN 网络迁移到调制识别的有效性进行深入了解,为进一步识别分类奠定理论基础。ImageNet-VGG-f 网络结构如表 1 所示。

表 1 ImageNet-VGG-f 网络结构

Tab. 1 ImageNet-VGG-f network structure

层	Conv1	Conv2	Conv3	Conv4
网络结构	64 × 11 × 11	256 × 5 × 5	256 × 3 × 3	256 × 3 × 3
	st. 4, pad 0,	st. 1, pad 2,	st. 1, pad 1	st. 1, pad 1
	LRN, × 2pool	LRN, × 2pool		
层	Conv5	full6	full7	full8
网络结构	256 × 3 × 3	4 096	4 096	1 000
	st. 1, pad 1, × 2pool	dropout	dropout	softmax

ImageNet-VGG-f 网络调制识别步骤如下。  
**步骤 1:** 根据仿真参数产生 LPI 雷达信号集;  
**步骤 2:** 利用 MWSP、CWD、SPWVD 算法对雷达信号进行时频变换,产生时频图像,并对时频图像进行预处理,产生 224 × 224 × 3 大小的 RGB 图像集;  
**步骤 3:** 构建迁移网络模型,保持预训练的 ImageNet-VGG-f 网络参数和网络结构不变,组成 VGG-f 迁移网络模型;  
**步骤 4:** 将步骤 2 的图像集送入 VGG-f 迁移网络模型,经过特征提取后,full8 层得到的特征图大小为 1 × 1 000;  
**步骤 5:** 利用 softmax 对时频图像的数据集进行分类,并验证 SPWVD、CWD 和 MWSP 算法产生的时频图像的识别率。

### 4 实验结果与分析

#### 4.1 MWSP 算法仿真分析

采用 MWSP 算法对常见的 LPI 雷达信号进行时频分析,观察各个信号的时频图像。

**实验 1** 通过 AWGN 信道,信噪比 SNR = 0 dB, MWSP 算法对 LFM、QFM、Costas、SFM、EQFM、T1 这 6 种常见的 LPI 雷达信号进行时频变换,如图 4 所示。可以看出,在低信噪比 0 dB 条

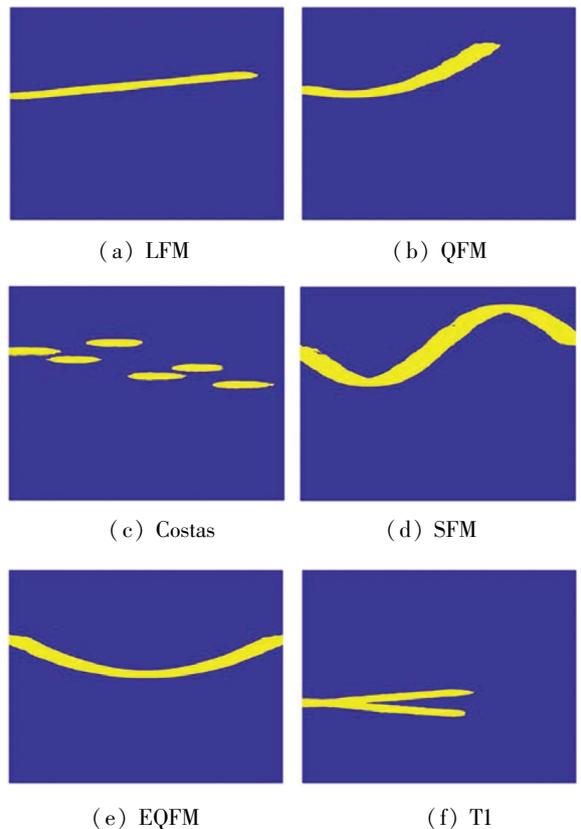


图 4 SNR = 0 dB 时 MWSP 算法产生的时频图像  
 Fig. 4 Time-frequency image produced by MWSP algorithm when SNR = 0 dB

件下,采用 MWSP 算法产生的六种时频图像依旧有良好的可分辨性。

### 4.2 调制识别仿真分析

采用 MATLAB 仿真环境产生 7 种常见的 LPI 雷达信号进行调制识别仿真实验,进一步验证 MWSP 算法对识别性能的影响。这 7 种 LPI 雷达信号分别为 LFM、QFM、Costas、EQFM、SFM、T1 和 ANYFM。

仿真参数设置:为了在时频分析中使用快速傅里叶变换(Fast Fourier Transform, FFT),将信号时域采样点数目统一为 1 024。在实际情况中,存在不同载频的信号,接收机接收到的信号也是不同载频的,对信号参数设置载频范围,调整时频图像的位置,具体的参数设置如表 2 所示。每种信号随机产生 500 个作为训练数据,共 3 500 个训练信号,加入不同信噪比的高斯白噪声,分别利用 MWSP 算法、CWD 算法和 SPWVD 算法产生每种信号 100 个作为测试信号。

根据表 2 的仿真参数,对测试信号进行随机添加噪声,信噪比范围从 -8 dB 到 8 dB,利用 SPWVD、CWD 和 MWSP 算法产生时频图像,经过时频变换后产生的是 1 024 × 1 024 大小的时频矩阵,然后经过全局阈值二值化处理得到二值图像。在测试部分,一共设置 9 个测试集,他们的信噪比分别是 -8 dB、-6 dB、-4 dB、-2 dB、0 dB、2 dB、4 dB、6 dB 和 8 dB,每个测试集包含 700 个测试样本,随机产生不同参数的信号,参数范围如表 2 所示。

表 2 仿真雷达信号参数

Tab.2 Simulation radar signal parameter

调制方式	参数	变化范围
LFM&QFM	载频 $f_c$ /MHz	0.01 ~ 0.45
	带宽 $\Delta f$ /MHz	0.05 ~ 0.4
SFM	最小频率 $f_{min}$ /MHz	0.05 ~ 0.15
	带宽 $\Delta f$ /MHz	0.05 ~ 0.35
Costas	最小频率 $f_{min}$ /MHz	0.1 ~ 0.4
EQFM	最小频率 $f_{min}$ /MHz	0.1 ~ 0.4
	带宽 $\Delta f$ /MHz	0.05 ~ 0.3
T1	载频 $f_c$ /MHz	0.1 ~ 0.4
	码序列段数 $k$	{4,5,6}
	相位状态数 $n$	2
ANYFM	线性频率长度 $l_1$	200 ~ 512
	正弦频率长度 $l_2$	1024 - $l_1$

ImageNet-VGG-f 预训练网络模型输入要求为 224 × 224 × 3 的 RGB 图像,在送入网络训练和测试之前,采用图像处理中的双三次插值算法将时频图像的维度压缩至 224 × 224,并且通过拼接将二值图像拼接成三维图像,满足网络输入要求。

**实验 2** 高斯白噪声环境下,信噪比为 0 dB,对 MWSP 算法产生的测试集进行仿真实验,观察每种信号的识别率。

当 SNR = 0 dB 时,对于本文生成的 7 种 LPI 雷达信号都能够正确识别,平均识别正确率达到 99%,T1 信号识别正确率为 94%,且 LFM、QFM、Costas、ANYFM、SFM、EQFM 信号识别正确率均为 100%。可以得到结论,MWSP 算法产生的时频图像具有良好的抗噪性能,在低信噪比条件下依旧有很好的表现,为低信噪比情况下的 LPI 雷达信号调制识别研究提供了新思路。

**实验 3** 对三种算法产生的 9 种测试集进行对比实验,信噪比从 -8 dB 到 8 dB,步进为 2 dB,实验过程中,分别对三种算法产生的时频图像进行训练和测试。

三种算法在不同信噪比条件下的平均识别正确率如图 5 所示,从图中可以看出,在 SNR < 0 dB 时,MWSP 算法明显优于另外两种算法,CWD 和 SPWVD 时频分析方法受噪声干扰严重,无法对 LPI 雷达信号进行有效的分析,识别正确率低;随着信噪比逐渐增加,大于 0 dB 之后三种算法的识别正确率趋于平滑,基本保持很高的正确率。仿真结果证明了 MWSP 算法良好的抗噪性能,为低信噪比环境下的 LPI 雷达信号调制识别提供了可行性。

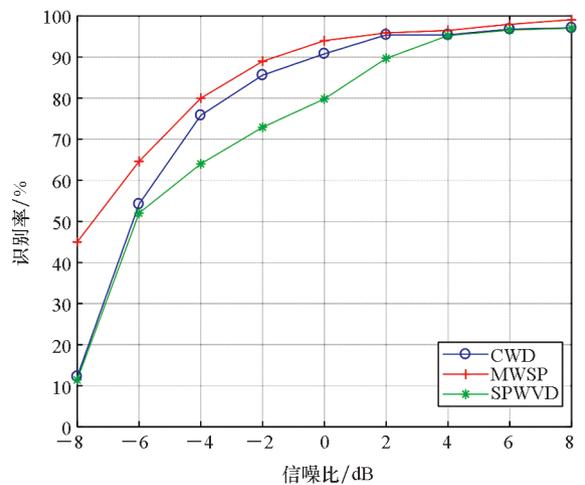


图 5 三种算法识别准确率对比

Fig.5 Comparison of recognition accuracy of three algorithms

## 5 结论

本文针对 LPI 雷达信号常规时频分析方法产生的时频图像受噪声干扰严重的问题,使用 MWSP 算法产生时频分布图像,有效地降低噪声干扰,在低信噪比条件下,使不同 LPI 雷达信号的时频图像具有良好的可辨识度。产生时频图像之后,经过全局阈值二值化、双三次插值压缩和拼接,利用 ImageNet-VGG-f 迁移神经网络完成了 LPI 雷达信号分类识别。仿真条件相同时,将 MWSP 算法与传统的 CWD 和 SPWVD 算法进行对比实验,将三种时频分析方法产生的图像分别送入 ImageNet-VGG-f 迁移神经网络中进行识别,实验结果表明 MWSP 算法具有更佳的抗噪性能,产生的时频图像噪声干扰少,在低信噪比情况下, MWSP 算法的 LPI 雷达信号识别正确率明显高于另外两种算法。

## 参考文献 (References)

- [1] 张国柱. 雷达辐射源识别技术研究[D]. 长沙: 国防科技大学, 2005.  
ZHANG G Z. Research on emitter identification [D]. Changsha: National University of Defense Technology, 2005. (in Chinese)
- [2] LUNDÉN J, KOIVUNEN V. Automatic radar waveform recognition[J]. IEEE Journal of Selected Topics in Signal Processing, 2007, 1(1): 124-136.
- [3] ZHANG M, LIU L T, DIAO M. LPI radar waveform recognition based on time-frequency distribution[J]. Sensors, 2016, 16: 1682.
- [4] 周志文, 黄高明, 陈海洋, 等. 雷达辐射源识别算法综述[J]. 电讯技术, 2017, 57(8): 973-980.  
ZHOU Z W, HUANG G M, CHEN H Y, et al. An overview of radar emitter recognition algorithms [J]. Telecommunication Engineering, 2017, 57(8): 973-980. (in Chinese)
- [5] WANG C, WANG J, ZHANG X D. Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network [C]//Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing, 2017: 2437-2441.
- [6] KISHORE R T, RAO K D. Automatic intrapulse modulation classification of advanced LPI radar waveforms [J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 53(2): 901-914.
- [7] 郭立民, 陈鑫, 陈涛. 基于 AlexNet 模型的雷达信号调制类型识别[J]. 吉林大学学报(工学版), 2019, 49(3): 1000-1008.  
GUO L M, CHEN X, CHEN T. Radar signal modulation type recognition based on AlexNet model [J]. Journal of Jilin University (Engineering and Technology Edition), 2019, 49(3): 1000-1008. (in Chinese)
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [9] CAIN L, CLARK J, PAULS E, et al. Convolutional neural networks for radar emitter classification [C]//Proceedings of IEEE 8th Annual Computing and Communication Workshop and Conference, 2018: 79-83.
- [10] ZHANG M, DIAO M, GAO L P, et al. Neural networks for radar waveform recognition [J]. Symmetry, 2017, 9: 75.
- [11] ZHANG M, DIAO M, GUO L M. Convolutional neural networks for automatic cognitive radio waveform recognition [J]. IEEE Access, 2017, 5: 11074-11082.
- [12] 葛哲学, 陈仲生. MATLAB 时频分析技术及其应用[M]. 北京: 人民邮电出版社, 2006.  
GE Z X, CHEN Z S. MATLAB time-frequency analysis technology and its application [M]. Beijing: Posts & Telecom Press, 2006. (in Chinese)
- [13] THOMSON D J. Spectrum estimation and harmonic analysis [J]. Proceedings of the IEEE, 1982, 70(9): 1055-1096.
- [14] BAYRAM M, BARANIUK R G. Multiple window time-frequency analysis [C]//Proceedings of 3rd International Symposium on Time-Frequency and Time-Scale Analysis, 1996: 173-176.
- [15] 丁夏畦, 丁毅. Hermite 展开与广义函数[M]. 武汉: 华中师范大学出版社, 2005.  
DING X Q, DING Y. Hermite expansions and generalized functions [M]. Wuhan: Central China Normal University Press, 2005. (in Chinese)
- [16] CHATFIELD K, SIMONYAN K, VEDALDI A, et al. Return of the devil in the details: delving deep into convolutional nets [DB/OL]. (2014-11-05) [2020-09-01]. <https://arxiv.org/abs/1405.3531v4>.
- [17] JIANG Q Y, LI W J. Deep cross-modal hashing [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3270-3278.