

DOI:10.19651/j.cnki.emt.2209511

# 基于特征融合的调制识别增强与迁移演化<sup>\*</sup>

钱磊 吴昊 乔晓强 张涛 张江  
(国防科技大学第六十三研究所 南京 210007)

**摘要:** 针对调制识别中单一图像的特征信息不足,区分度不够高,识别范围受限的问题。本文提出了一种基于时频图和星座图特征融合的调制识别特征增强方法,利用深度学习神经网络提取信号图像的特征,构建特征空间,通过多维特征融合,挖掘和整合不同特征的优势,增强模型算法的鲁棒性。此外运用了模型迁移的方法,仅需对分类器进行训练,大幅节约了训练时间和资源,具有很强的实时性和实用性。仿真结果显示,在0 dB左右的条件下,相比于单一特征图像,采用特征融合增强的方法能将信号的平均识别率提高约25%,通过模型迁移,省去了卷积神经网络的训练,所需的训练时间约为迁移前的9.6%,消耗内存约为迁移前的7.3%,同时模型的识别率损失控制在了5%以内。

**关键词:** 调制识别;深度学习;图像特征;多维特征融合;迁移学习

中图分类号: TN911.7 文献标识码: A 国家标准学科分类代码: 510.40

## Modulation recognition enhancement and migration evolution based on feature fusion

Qian Lei Wu Hao Qiao Xiaoqiang Zhang Tao Zhang Jiang  
(The 63rd Research Institute of National University of Defense Technology, Nanjing 210007, China)

**Abstract:** In modulation recognition, the feature information of a single image is insufficient, the degree of discrimination is not high enough, and the recognition range is limited. In this paper, a modulation recognition feature enhancement method based on the feature fusion of time-frequency map and constellation map is proposed. The deep learning neural network is used to extract the features of signal image and construct the feature space. Through multidimensional feature fusion, the advantages of different features are mined and integrated to enhance the robustness of the model algorithm. In addition, the method of model migration is used, which only needs to train the classifier, which greatly saves the training time and resources, and has strong real-time and practicability. The simulation results show that under the condition of about 0 dB, compared with a single feature image, the average recognition rate of the signal can be improved by about 25% by using the feature fusion enhancement method. Through the model migration, the training of convolutional neural network is omitted, and the training time required is about 10% of that before migration, and the memory consumption is about 7.3% of that before migration. At the same time, the loss of recognition rate of the model is controlled within 5%..

**Keywords:** modulation recognition; deep learning; image features; multidimensional feature fusion; transfer learning

## 0 引言

在当前的复杂电磁环境下,各种信号交织,面对未知信号,需要确定其时域、频域、空域、调制域等方面的信息。在无线通信系统中,通常要将信号调制以提高信息传输的可靠性,通过调制识别技术可确定非协作通信中信号的调制样式。在民用领域,该技术可用于频谱监测与管理系统,以发现违法占用他人频带资源的行为,同时也可识别干扰信

号,确定干扰信号信息,保障通信的正常运行。在军用领域,战场电磁环境常常敌我混淆,敌方伺机对我方通信造成干扰,影响指令及时传达,同时妄图以电磁欺骗模拟战术终端的通信波形,获得接入网络的权利,从而窃取我方的军事意图。调制识别技术作为非协作通信中的关键技术,是频谱安全防护技术的重要一环,在电磁侦察、干扰信号调制识别、频谱监测等场景中都有着广泛的应用场景和巨大的发展潜力,在中低信噪比环境下进行增强调制识别的理论及

收稿日期:2022-04-05

\*基金项目:国家自然科学基金(61801496,61801497)、军委科技委基础加强计划技术领域基金(2019-JCJQ-JJ-221)项目资助

方法研究是一项很重要的课题。

调制识别可以看作是一类模式识别问题,其原理就是通过提取样本的特征进行分类识别。预处理、特征提取和分类识别等流程。其中提取不同的特征是将信号进行分类的前提和关键。文献[1]提取幅度、相位和频率三个维度的 5 个瞬时特征参数对六种调制信号进行识别。文献[2]提取高阶累积量特征实现了对 16PSK、QPSK、OQPSK 六种调相信号的识别。文献[3]提取信号瞬时自相关相位分区分布比率特征完成对 PSK 和 QAM 类特调制信号的识别。文献[4]利用连续小波变换(continuous wavelet transform, CWT)提取平均值、方差和中心矩等信号特征作为依据识别多种数字调制信号。文献[5]通过提取降维后的循环频谱向量特征,基于人工神经网络对调制样式进行分类。近年来,深度学习(deep learning, DL)快速发展,在图像、语音等领域的研究日趋深入,并广泛应用于识别、分类等工程实践。深度学习在计算机视觉领域的表现优于传统的机器学习技术,已成为图像分类的主流方法。而将调制识别问题转换为图像识别问题,是当前将深度学习与调制识别结合的常用方法。文献[6]通过短时傅里叶变换将信号表征为时频图像,实验表明,时频图包含更加丰富的信号特征信息。文献[7]生成基带信号的星座图并将其转化为灰度图像,对 8 类调制进行了识别。文献[8]生成数字调制信号的循环谱图并进行预处理,作为识别的特征输入。文献[9]波形优化的方法直接对信号滤波后,通过深度学习算法进行识别。然而目前单一的特征存在识别率和识别范围的局限性,如星座图无法对频率调制类信号进行识别,而基于中频信号的提取的时频图对幅度和相位方面的特征区分不强。

因此本文提出一种基于时频图和星座图的多维特征融合方法,通过优势互补达到提高识别率,扩充识别范围的效果。具体地,将接收信号分为两路,一路进行平滑伪 Wigner-Ville 分布(SPWVD)变换得到特征图像,再将三维特征图像送入卷积神经网络(convolutional neural networks, CNN)得到提取的一维的时频图像特征向量,另一路变换到基带,得到星座特征图像,再将三维特征图像送入 CNN 得到提取的一维的星座图特征向量,两类特征向量首尾串联得到融合的特征,再将融合特征送入支持向量机进行分类。此外考虑到融合的双层卷积神经网络模型在训练时需消耗大量的运行时间和内存,运用了迁移学习理论,将预训练的单层 CNN 模型移植到本文的算法中,只通过对分类器进行训练,可达到节约资源和提升效率的目的。

## 1 特征图像获取

如图 1 所示,时频图对于不同调制信号间的频率和幅度差异区分明显,而星座图对于不同调制信号间的幅度和相位差异区分明显,从而利用时频图识别模拟调制信号和数字频率调制信号,利用星座图识别数字幅度和数字相位调制信号。因此综合考虑常见的调制类型以及所采用方法

的适用范围,选择 BPSK、QPSK、16QAM、32QAM、2ASK、4ASK、2FSK、4FSK、AM-SSB、FM 这十类信号进行识别。

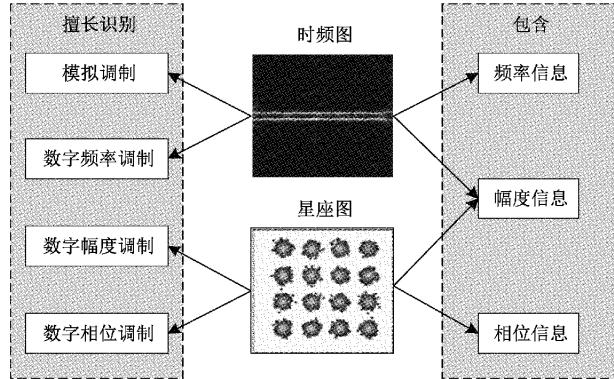


图 1 不同特征图像的特点

### 1.1 星座图获取

利用复平面对数字信号进行表示,这种表示方法就称为星座图<sup>[10]</sup>。星座图就是信号的矢量端点的位置分布,展现了信号的振幅和相位,有助于判断信号调制的方式。在接收端,将信号从中频变换到基带,通过画出信号点的分布得到星座图。如图 2 中所示的为不同调制信号的星座图。

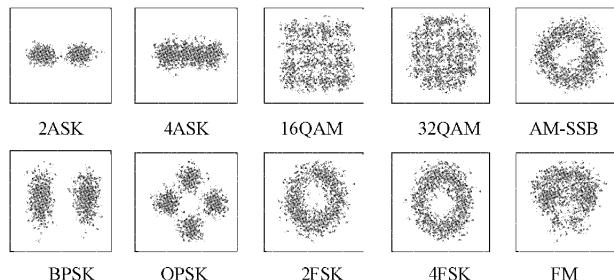


图 2 信号星座图

理想的星座图主要由不同位置和数量的点构成,然而由于噪声等不利因素的影响,星座图上的点会产生发散现象,经聚类处理后,可使得星座图的点更突出,特征更明显。其具体步骤如图 3 所示,首先确定搜索矩阵的大小,然后遍历星座图上的每一个点,计算以该点为中心的搜索矩阵内的点数量,从而得到该点范围内的密度,根据密度对该点上色,密度越大的点颜色越深。

如图 4 所示为聚类前后 QPSK 和 16QAM 信号的星座图对比。QPSK 在聚类前为集中在 4 个区域的发散点,经聚类处理后,可以在星座图中得到 4 个颜色较深的点。而 16QAM 信号的星座图在聚类前则更为发散,识别更加困难,经聚类处理后,使得集中点区域变得更清晰,聚类算法对于点越多的调制信号,提升效果越明显。

### 1.2 时频图获取

魏格纳威利分布<sup>[11]</sup>(Wigner-Ville, WVD),是一种双线性时频分布,在时频平面内分布信号的能量。由魏格纳(Wigner)提出,被威利(Ville)首次用于信号处理。若  $x(t)$

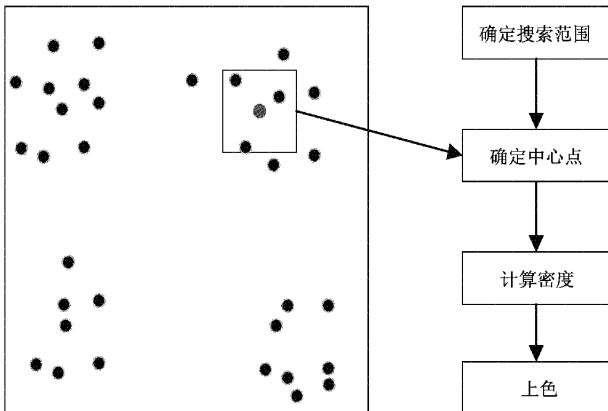


图 3 聚类的步骤

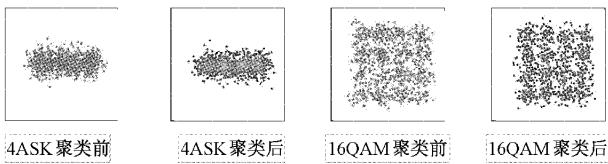


图 4 聚类前后对比

为确定性时间连续信号,其 WVD 定义为:

$$W_x(t, v) = \int_{-\infty}^{+\infty} x(t + \tau/2)x^*(t - \tau/2)e^{-j2\pi v\tau} d\tau \quad (1)$$

WVD 变换可以看作是把过去特定时刻的信号与未来特定时刻的信号相乘,并对时间差  $\tau$  求傅里叶变换。此类变换能有效地提取数字信号的幅度、频率等调制信息,可用于信号的调制识别。然而该变换具有严重的局限性,即会产生严重的交叉项干扰,并对信号的自项产生干扰,使原始特征遭到破坏。

为解决这个问题,提出了伪 Wigner-Ville 分布(pseudo WVD, PWVD),在 WVD 的基础上进行加窗处理,在有限范围内进行积分,其分布定义式为:

$$PW_x(t, v) = \int_{-\infty}^{+\infty} h(\tau)x(t + \tau/2)x^*(t - \tau/2)e^{-j2\pi v\tau} d\tau \quad (2)$$

其中,  $h(\tau)$  是常规窗口。加窗后对于多分量信号的交叉项有一定的压缩效果,同时也对 WVD 的某些边缘特性造成了破坏。为实现能量分布为正值,提出了把 WVD 与平滑函数进行卷积的方法得到平滑伪 Wigner-Ville 分布(smooth pseudo WVD, SPWVD),其分布定义式为:

$$SPW_x(t, v) = \int_{-\infty}^{+\infty} h(\tau) \int_{-\infty}^{+\infty} g(s-t)x(s + \tau/2)x^*(s - \tau/2)ds e^{-j2\pi v\tau} d\tau \quad (3)$$

SPWVD 分布消除交叉项的效果较好,并保持了良好的时频特征。因此在 Cohen 类时频分布中,是最为通用的分布之一。在频带较窄的情况下,选择 SPWVD 能获得较高的时频分辨率,优势十分明显。

本文采用 SPWVD 获取信号的时频图,不同信号的时频图如图 5 所示。

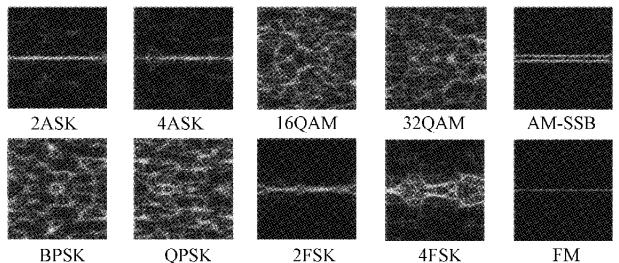


图 5 信号时频图

## 2 机器学习的算法结构

本文的调制识别算法综合运用了深度学习中的卷积神经网络与机器学习中的支持向量机算法,其中卷积神经网络在本文中用于信号时频图和星座图的特征提取,两类图像的特征提取采用相同的网络结构,支持向量机用于对融合后的特征进行分类,目的是防止模型过拟合。

### 2.1 图像特征提取网络设计

人工神经网络是本文信号特征提取与识别的主要工具。卷积神经网络擅长图片空间特性的提取,包含输入层、卷积层、池化层、全连接层和输出层。随着深度学习的热门,近年来基于深度学习的各种图像分类算法竞相涌现,为基于图像的信号的识别提供了良好的算法基础。CNN 模型的发展越来越多,越来越深入,这使得深度网络模型难以在移动设备上运行。

ShuffleNet<sup>[12]</sup>是探索一种能够满足有限条件的高效基础设施,可以在移动设备上运行。在该网络结构中,为了降低计算复杂度,提出了逐点组卷积的方法。在此基础上,为了解决信道间的信息流问题,提出了信道变换。2018 年提出的 ShuffleNetV2 网络<sup>[13]</sup>是 V1 的升级改进版本。如图 6 中为 ShuffleNetV2 的两个基本模块。

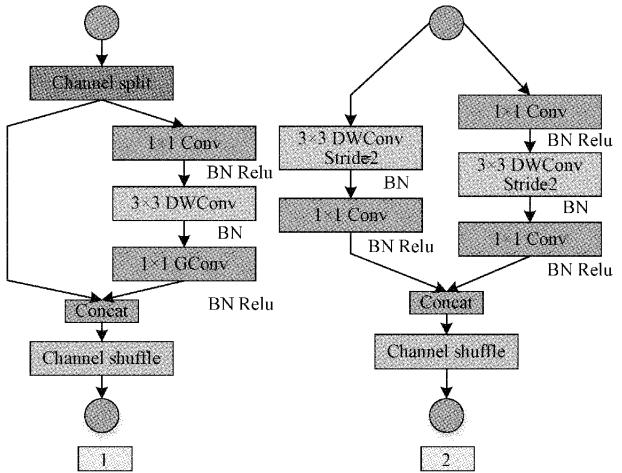


图 6 ShuffleNetV2 的基本模块

DWConv 代表深度卷积, GConv 代表组卷积。V2 版本从以下 4 个方面进行了改进。第一,引入了新运算: channel split。即在初始阶段将输入特征图分成两个通道

分支,解决了网络碎片化问题。第二,通道左边分支做同等映射,右边的分支包含 3 个连续的卷积,保证输入输出的通道数相同,解决最小化内存访问的问题。第三,V2 两个  $1 \times 1$  卷积不再是组卷积,解决了数据包过多和 MAC 增加的问题。第四,两个分支的输出不再采用 Add,而是通过合并减少元素级运算。ShuffleNetV2 的整体结构如表 1 所示。其中模块 1 到模块 3 都是由图 6 中所示的小模块组成,小模块的数量对应表中的重复列。

表 1 ShuffleNetV2 的网络结构

网络层	输出	卷积核	步长	重复	通道
图片	$224 \times 224$				3
卷积层 1	$112 \times 112$	$3 \times 3$	3	1	24
池化层	$56 \times 56$	$3 \times 3$	3		
模块 1	$28 \times 28$		2	1	116
	$14 \times 14$		1	3	
模块 2	$7 \times 7$		2	1	232
	$7 \times 7$		1	7	
模块 3	$7 \times 7$		2	1	464
	$7 \times 7$		1	3	
卷积层 5	$1 \times 1$	$1 \times 1$	1	1	1024

## 2.2 分类器设计

支持向量机<sup>[14]</sup>(support vector machine, SVM)是一种基于结构风险最小化原则的分类技术,具有较高的泛化能力。它能有效地解决用有限样本构建高维数据模型的问题。同时,该算法具有全局最优收敛性和维数不敏感等优点。SVM 的样本集具有一定的鲁棒性。采用图像融合的方法,特征融合后特征数量较多,易产生过拟合的现象,因此,选择 SVM 作为分类器是较好的选择。

SVM 可分为线性 SVM 与非线性 SVM。非线性支持向量机利用非线性变换,高维特征空间中将非线性问题转换成线性问题。

SVM 划分超平面的模型可表示为:

$$f(x) = \omega^T \phi(x) + b \quad (4)$$

其中,  $\omega$  表示垂直于超平面的向量,  $b$  为权值。通过对偶变换和核函数代替内积,可得到最终的非线性 SVM 的分类决策函数模型:

$$f(x) = \text{sign}(\sum_{i=1}^m \alpha_i y_i k(x_i, x_j) + b) \quad (5)$$

其中,  $k(x_i, x_j)$  表示核函数,  $y_i$  表示类标记,  $\alpha$  由对偶问题计算而来。根据 mercer 定理,任何半正定的函数都可作为核函数。在本算法中由于特征长度较长,而样本数量较少,因此采用泛化能力更强的线性核函数 LINEAR:

$$k(x_i, x_j) = x_i^T x_j \quad (6)$$

该函数的优点是参数少、速度快,且对于线性可分数据的分类效果较好。

## 3 特征融合与模型训练

### 3.1 特征融合的算法模型

本文设计的特征融合与识别的算法流程如图 7 所示。

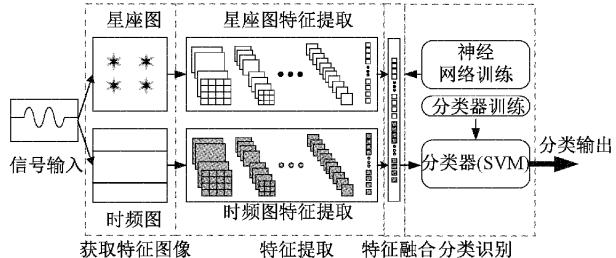


图 7 特征融合与识别算法流程

其具体操作为:

- 1) 对接收信号作时频变换和星座图变换;
- 2) 构建并联神经网络模型,两个模型的输出在全连接层串联融合;
- 3) 对融合的神经网络模型进行训练;
- 4) 将神经网络模型全连接层融合后的特征输出,送入支持向量机分类器并进行训练;
- 5) 将训练好的 CNN 和 SVM 在特征融合后串联,验证识别效果;

### 3.2 网络模型的训练

本文算法在训练神经网络模型时,是将并联的神经网络看作是一个整体,通过全连接层重构将两个神经网络模型相联。两个  $1024 \times 1$  的全连接层组合成为一个  $2048 \times 1$  的全连接层,之后再与 softmax 层相连计算损失函数。

本算法在计算损失时采用了交叉熵函数,交叉熵代表了两个概率分布间的差异性,在深度学习中,交叉熵表示真实预测概率与期望预测概率的差距。其数学表达式为:

$$H(p, q) = - \sum_{i=1}^n p(x_i) \log(q(x_i)) \quad (7)$$

其中,  $p(x)$  表示真实概率分布,  $q(x)$  表示预测概率分布,其值越小,代表模型预测准确率越高。在分类时域 softmax 搭配使用,使多分类的预测值和为 1。

同时为了优化网络模型的目标函数,使损失值达到最小,常采用各种优化算法,在每轮训练中计算损失函数的梯度并更新模型的参数。在本文的网络训练中采用了 Adam (adaptive moment estimation) 优化算法<sup>[15]</sup>,该算法利用梯度的一阶矩和二阶矩估计调整参数的学习率,其更新算法可表示为:

$$\begin{aligned} g_t &= \nabla_{\theta} f_t(\theta_{t-1}) \\ m_t &= \beta_1 * m_{t-1} + (1 - \beta_1) * g_t \\ n_t &= \beta_2 * n_{t-1} + (1 - \beta_2) * g_t^2 \\ \hat{m}_t &= m_t / (1 - \beta_1') \\ \hat{n}_t &= n_t / (1 - \beta_2') \\ \theta_t &= \theta_{t-1} - \alpha * \hat{m}_t / (\sqrt{\hat{n}_t} + \epsilon) \end{aligned} \quad (8)$$

其中,  $g_t$  为时间步为  $t$  时的梯度,  $\theta$  为要更新的参数,  $f(\theta)$  随机目标函数,  $\beta_1, \beta_2$  分别为一阶矩和二阶矩的指数衰减率,  $m_t$  为梯度的一阶矩估计,  $n_t$  为梯度的二阶矩估计,  $\hat{m}_t, \hat{n}_t$  为校准后的参数,  $\alpha$  学习率,  $\epsilon$  是为保持数值稳定性添加的常数。该算法的运用优势在于经偏置校正后, 每一次迭代时通过限制学习率的范围, 保证参数的平稳性。此外, 并联的神经网络模型在更新参数时会对同步更新两个神经网络模型的权值与阈值。

### 3.3 分类器的训练

在对神经网络训练后会出现训练集的损失值很低而测试集的损失值很高的情况, 如图 8 所示, 其中横坐标代表训练次数, 纵坐标代表平均损失值。可以看到训练值的平均损失接近于 0, 而测试集的损失值则大于 0.6, 这是由于模型并联后, 全连接层的特征过长造成的过拟合现象。因此不再采用 softmax 作为分类器, 而是选择泛化能力更强的 SVM, 同时选择线性核函数, 用于处理特征数量长而样本数量少的情况。

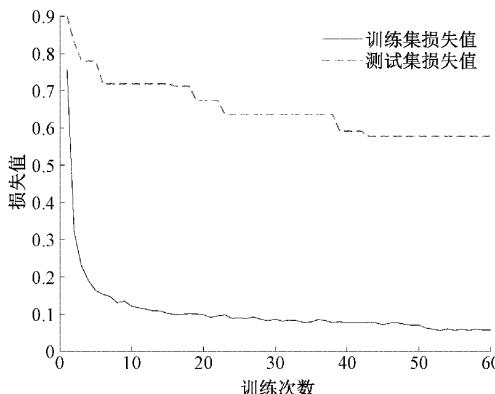


图 8 训练集与测试集的损失值

在训练支持向量机时, 首先将特征图像输入卷积神经网络, 得到全连接层的特征向量作为支持向量机的训练和测试数据。SVM<sup>[16]</sup>训练的目标函数为:

$$\begin{aligned} L_{\min} &= \frac{1}{2} \sum_{i=0}^{l-1} \sum_{j=0}^{l-1} \alpha_i \alpha_j y_i y_j k(x_i, x_j) - \sum_{i=0}^{l-1} \alpha_i \\ 0 \leq \alpha_i \leq C, \quad S.t. \sum_{i=0}^{l-1} \alpha_i y_i &= 0 \end{aligned} \quad (9)$$

其中,  $y$  表示类标记, 也就是真实输出,  $\alpha$  是通过对偶问题求得,  $C$  为惩罚参数,  $C$  越小分类越细, 但容易出现过拟合现象,  $C$  越大, 模型泛化能力越好, 但容易准确率会降低。如下是 SVM 收敛的条件:

$$y_i \left( \sum_{j=0}^{l-1} \alpha_j y_j k(x_i, x_j) + b \right) \begin{cases} \geq 1, & \alpha_i = 0 \\ = 1, & 0 < \alpha_i < C \\ \leq 1, & \alpha_i = C \end{cases} \quad (10)$$

当  $0 < \alpha_i < C$  时表示模型在分割平面上, 为支持向量, 此时, 训练停止。同时采用序列最小优化算法对参数进行优化更新, 该算法每次选取两个参数作为优化对象, 其他视

作常数。求得最终的  $\alpha^*$  后, 再计算  $w, b$  的值:

$$\begin{aligned} w^* &= \sum_{i=1}^N \alpha_i^* y_i x_i \\ b^* &= y_j - \sum_{i=1}^N \alpha_i^* y_i (x_i * x_j) \end{aligned} \quad (11)$$

### 3.4 迁移学习

深度神经网络在训练时需要消耗大量的时间和内存, 而调制识别算法不仅要追求高的识别率, 也追求强的实时性。由此, 产生了迁移学习<sup>[17]</sup>的概念。迁移学习就是将其他任务中已经学习的知识, 应用到不同但相关的任务。采用迁移学习的方法, 可以节约大量的训练时间和计算资源。根据迁移内容的不同, 一般可分为样本迁移、特征迁移和模型迁移等。

本文采用了模型迁移的方法, 即将预训练的神经网络模型, 迁移到新任务的新模型中。模型的迁移也包含不同的方法, 一种是冻结所有卷积层, 只训练新的全连接层, 一种是冻结部分卷积层, 训练剩下的卷积层和全连接层。本文选择将已有模型的卷积层和池化层的权重参数冻结, 获取其全连接层的输出, 将不同模型获取的多维图像特征在全连接层融合后, 利用融合特征对分类器进行训练。迁移的流程如图 9 所示。其中预训练的模型通过单特征图像识别的任务中获取。

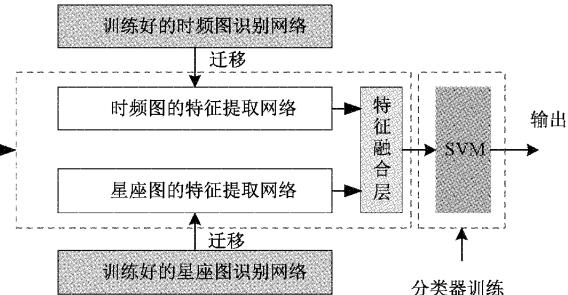


图 9 模型的迁移演化

## 4 验证分析

本文所采用的信号数据集均由 matlab2016a 生成, 信号的频率为 10 kHz, 采样率 40 kHz, 信号长度为 512。信号种类包括 BPSK、QPSK、16QAM、32QAM、2ASK、4ASK、2FSK、4FSK、AM-SSB、FM, 信噪比范围为 -4 ~ 10 dB。

### 4.1 基于单一图像特征的识别验证

为了测试本文算法是否有提高识别率的效果。首先采用单一特征的星座图和时频图识别算法分别对信号识别的效果进行测试。如图 10 和 11 所示。

从图中看出单一特征的方法各有局限性, 时频图对 QAM 和 PSK 信号识别效果较差, 几乎都在 70% 以下, 且 16QAM 的识别率几乎为 0。而星座图特征对 FSK 信号以及 AM 和 FM 信号识别较差, 高信噪比下也仅有 80%。同

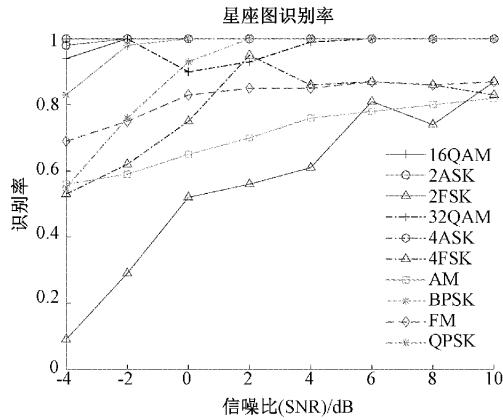


图 10 星座图的识别率

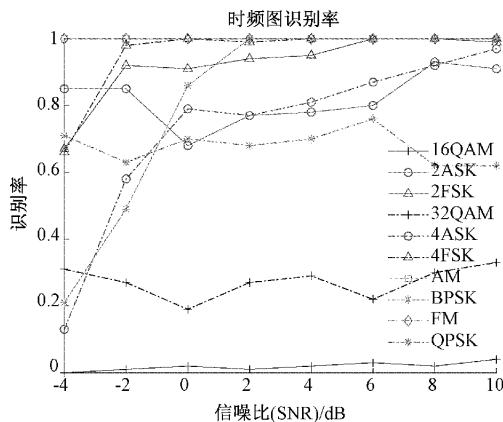


图 11 时频图的识别率

时也能发现二者的优势可以互补,比如时频图对 QAM 识别差,然而星座图对 QAM 的识别率相当高,这为本文开展两类特征融合的研究提供了指导。

#### 4.2 基于融合图像特征的识别验证

采用本文算法对其进行特征融合后再识别的效果如图 12 所示。图中展示了融合前后的平均识别率,相比于单一图像特征,进行特征融合后,相同信噪比下识别率提高了约 10%~30%。证明了特征融合算法的有效性,即使在-4 dB 的条件下,本文的算法也有约 86% 的识别准确率。

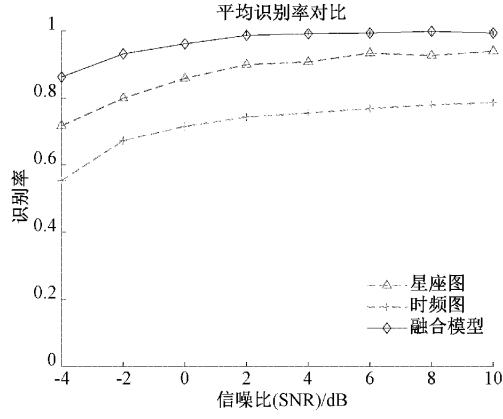


图 12 平均识别率对比

为提高测试集的识别率,需要进一步提高模型的泛化能力,因此,在训练时对特征图像进行随机切片、随机水平旋转等形态学处理后再输入模型。如图 13 分别为将图片进行随机切片,随机水平旋转以及两种方式同步应用后与原图的对比。

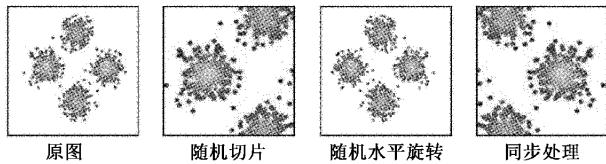


图 13 图片形态学处理

其测试识别效果如图 14 所示。从图中可以看出,经过处理后,在低信噪比的识别率又提高了约 5%,在-4 dB 时平均识别率达到了 90%, -2 dB 时约为 98%。

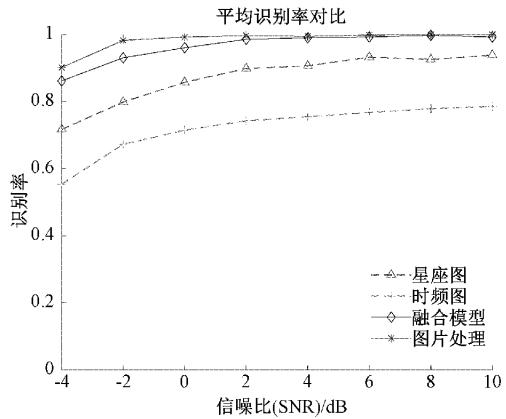


图 14 图片处理后的模型平均识别率

同时,经过图片处理后的不同调制的识别率如图 15 所示,从图中可以看出,优化后的模型,在一2 dB 时对所有调制类型的识别率均在 95% 以上,在-4 dB 时,最差也有接近 80% 的识别率。

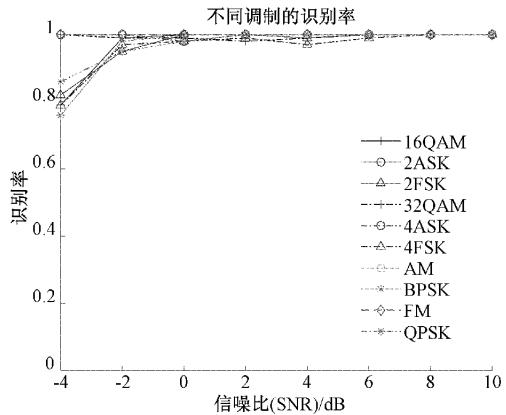


图 15 图片处理后不同调制的识别率

#### 4.3 基于迁移演化的识别验证

在本节中,采用了模型迁移的方法,将识别单一图像的两个单模型移植入融合模型,神经网络迁移演化后,仅对支

持向量机进行训练。本文的时频特征图和星座特征图分别设置了24 000个训练样本。如图16为在本模型中,对于卷积神经网络模型和支持向量机训练时间与消耗内存对比。

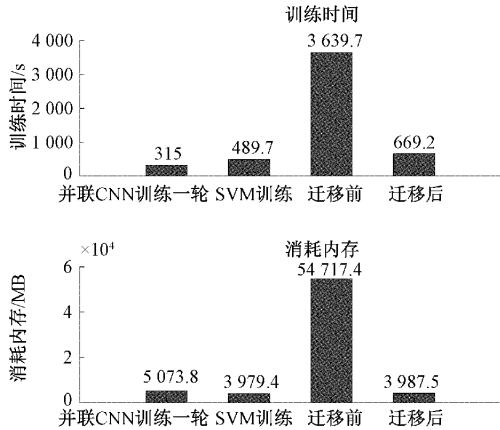


图16 模型训练时间与消耗内存

通常情况下本算法中的并联模型训练10次后接近收敛,假设训练一轮的平均用时为 $t_1$ ,分类器只需训练一次,用时为 $t_2$ 。因此迁移前总的训练时间为 $t = t_1 \times 10 + t_2$ ,消耗内存的计算同理。根据图中数据可知迁移后的训练时间约为迁移前9.6%,消耗内存约为迁移前的7.3%。

如图17为模型迁移演化算法与其他算法的识别率对比,从图中可以看出,基于模型迁移的算法,其性能比优化后的模型略低,在-2 dB和0 dB时仅降低了约5%,且在信噪比较高时,识别率几乎没有损失。这足以证明采用模型迁移的算法,在大幅降低训练时间,提高实时性的同时,又能保持较高的识别率,具有很强的实用意义。

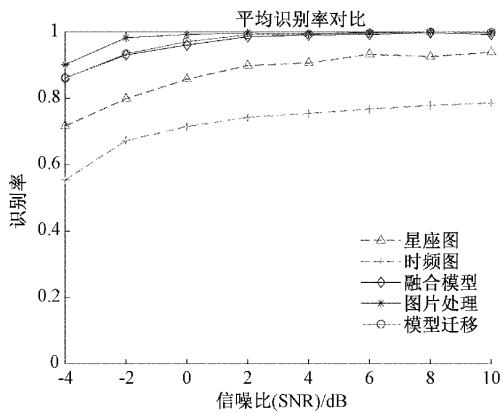


图17 迁移模型的识别率

#### 4.4 与其他算法的识别率对比

为进一步验证本算法的先进性,特将本算法与其他特征提取调制识别算法的识别率进行比较,如图18所示。基于文献[18],提取5个高阶累积量特征参数,并利用BP神经网络进行分类,可完成对2ASK、4ASK、BPSK、QPSK、2FSK、4FSK六种数字调制信号的识别。

基于文献[19]提取5个瞬时特征参数,同样通过BP神经网络分类,可识别2ASK、4ASK、BPSK、QPSK、2FSK、4FSK六种数字调制信号。实验证明本文提出的图像特征融合算法兼具识别范围广,识别率高的优点,在低信噪比下有明显优势。

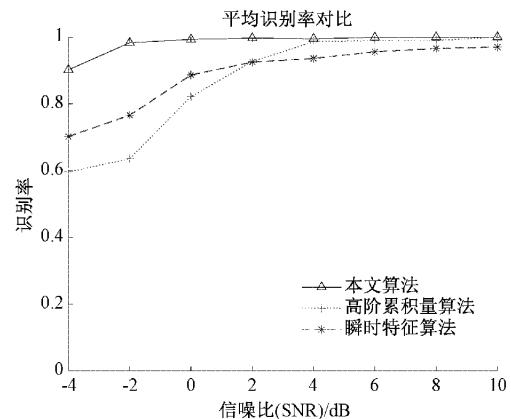


图18 不同算法的识别率对比

## 5 结论

本文对接收数字信号基于星座图和时频分布提取了两类图像特征,采用轻量化的ShuffleNetV2网络对图像特征进行提取,对不同的图像进行多维特征融合,并利用SVM进行分类。基于这两类特征的融合实现了对10种调制信号的识别。实验结果表明,与仅使用单一时频图或星座图进行分类的算法对比,本文提出的融合算法在不同信噪比下可提高10%~30%的识别率,-2 dB时对所有调制类型的识别率可达到95%以上。同时采用了模型迁移的算法,将训练好的单网络模型移植到融合模型中,仅对支持向量机进行训练。训练时间约为迁移前的9.6%,消耗内存约为迁移前的7.3%,同时识别率下降保持在了5%以内。

## 参考文献

- [1] 海滨,周正,李炳荣,解传军.基于数字通信信号瞬时特性的调制方式识别方法[J].现代电子技术,2019,42(16): 22-25.
- [2] 赵知劲,强芳芳,陈颖.利用高阶累积量的数字调相信号识别[J].杭州电子科技大学学报(自然),2016,36(3):1-5,DOI:10.13954/j.cnki.hdu.2016.03.001.
- [3] 汪浩,吴云树.融合神经网络与瞬时自相关分区特征的自动调制分类方法研究[J].国外电子测量技术,2019,38(11): 52-56.
- [4] WALENCZYKOWSKA M, KAWALEC A. Type of modulation identification using wavelet transform and neural network[J]. Bulletin of the Polish Academy of Sciences: Technical Sciences, 2016, 64(2):257-261.
- [5] WANG H, GUO L L. A new method of automatic

- modulation recognition based on dimension reduction[C]. 2017 Forum on Cooperative Positioning and Service (CPGPS), IEEE, 2017: 316-320.
- [6] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2019, 8(3): 929-932.
- [7] PENG S. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 3(30):718-727.
- [8] 郭蕴欣,张越,马宏.基于CNN的数字信号调制识别研究[J].电子测量技术,2019,42(14):112-116.
- [9] 杨小洪,余春泉.基于波形优化的深度调制识别方法[J].电子测量与仪器学报,2020,34(10): 186-193.
- [10] WANG Y, LIU M, YANG J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 4074-4077.
- [11] 尚东东,张劲东,杜盈,等.基于SPWVD和改进AlexNet的复合干扰识别[J].数据采集与处理,2021, 36(3): 577-586.
- [12] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [13] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design [J]. European Conference on Computer Vision, 2018.
- [14] ZHANG X L, CHEN J, SUN Z G. Modulation recognition of communication signals based on SCHKS-SSVM[J]. Journal of Systems Engineering and Electronics, 2017, 28(4): 627-633.
- [15] 李敏,李红娇,陈杰.差分隐私保护下的Adam优化算法研究[J].计算机应用与软件,2020,37(6): 253-258,296.
- [16] 陈桂林,熊刚.一种基于新型特征与支持向量机的调制识别方法[J].通信技术,2018,51(4):763-767.
- [17] 申良喜,吴璇,张巍巍.基于多尺度迁移学习的雷达辐射源信号识别算法[J].信息化研究,2021,47(6): 6-10.
- [18] 张利,李青.基于高阶累积量的调制识别算法的研究[J].信息工程大学学报,2017,18(4): 403-408.
- [19] 李佩,王龙龙,陶丽伟,等.基于瞬时特征和BP神经网络的数字调制信号自动识别及实现[J].通信技术, 2020,53(11):2635-2640.

### 作者简介

钱磊,硕士研究生,主要研究方向为调制识别技术。  
E-mail:1206290801@qq.com