

·通信与信息工程·

基于稀疏滤波神经网络的智能调制识别

李润东^{1,2}, 李立忠¹, 李少谦^{1*}, 宋熙煜², 何 鹏²

(1. 电子科技大学通信抗干扰技术国家级重点实验室 成都 611731; 2. 西南电子电信技术研究所 成都 610041)

【摘要】针对传统调制识别中特征提取依赖人工经验的问题, 该文提出了一种基于抗噪预处理及稀疏滤波卷积神经网络的智能通信调制识别算法。该算法将调制信号的循环谱作为卷积神经网络的输入图像, 并引入低秩表示算法去除循环谱图中的噪声及干扰。在有监督训练卷积神经网络之前, 该文设计了一种新型的稀疏滤波准则对网络进行无监督的逐层预训练, 从而提升了泛化性能。仿真表明算法在信噪比为0 dB时仍可达94.2%的识别准确率, 优于传统方法及相关深度学习方法。

关 键 词 卷积神经网络; 深度学习; 低秩表示; 调制识别; 稀疏滤波

中图分类号 TN97

文献标志码 A

doi:10.3969/j.issn.1001-0548.2019.02.001

Intelligent Modulation Recognition Based on Neural Networks with Sparse Filtering

LI Run-dong^{1,2}, LI Li-zhong¹, LI Shao-qian^{1*}, SONG Xi-yu², and HE Peng²

(1. National Key Laboratory of Science and Technology on Communications,

University of Electronic Science and Technology of China Chengdu 611731;

2. Southwest Electronics and Telecommunication Technology Research Institute Chengdu 610041)

Abstract To overcome the disadvantage that the feature extraction in traditional automated modulation recognition is heavily dependent on manual experience, this paper proposes an intelligent modulation recognition algorithm for communication signals, which is based on antinoise processing and sparse filtering convolutional neural network (AN-SF-CNN). The cyclic spectra of modulated signals are calculated, then low-rank representation is performed on cyclic spectra to reduce noises and disturbances existed in signals. After that, before fine-tuning the convolutional neural network, we propose a sparse filtering criterion to conduct the unsupervised pre-train of the network layer-by-layer, so as to improve the generalization performance effectively. Simulation results demonstrate that the average correct classification rate of proposed method can even reach to 94.2% when the signal to noise ratio is 0 dB, it is superior to traditional methods and some popular deep learning methods.

Key words convolutional neural networks; deep learning; low-rank representation; modulation recognition; sparse filter

无线电信号调制识别, 在认知无线电频谱感知、战场信号截获等军民应用领域发挥着重要作用。调制识别总体上可分为基于最大似然函数及基于特征两大类方法^[1], 比较而言, 基于特征的方法更易于实现、应用更广泛, 因此本文主要讨论基于特征的方法。传统上, 提取的特征主要包括参量统计特征、高阶累积量特征和循环平稳特征3大类。在利用参量统计特征方面, 文献[2-3]计算出信号瞬时频率、幅度、相位等参量的标准差、峭度等特征后, 送入ANN(artificial neural network)开展调制识别; 文献[4]提取了信号的13个多重分形谱特征参数, 输入SVM(support vector machine)以识别不同调制。在利

用高阶累积量特征方面, 文献[5]提取了7种高阶累积量, 并利用遗传算法及KNN(K-nearest neighbor)混合优化来识别PSK(phase shift keying)及QAM(quadrature amplitude modulation)信号; 文献[6]通过对高阶累积量构建非线性方程组以及迭代求解等途径, 实现了多径信道下的调制识别。在利用循环平稳特征方面, 文献[7]提取了不同信号在特定循环累积量下的谱峰特征, 利用CAFR(constant false alarm rate)检测算法完成调制分类; 文献[8]从循环谱差分序列中生成一个图模型, 并从该图邻接矩阵中提取特征实现调制识别。此外, 文献[9]综合利用了高阶累积量和循环谱, 应用ANN对信号进行混识别。

收稿日期: 2017-10-30; 修回日期: 2018-04-30

作者简介: 李润东(1984-), 男, 博士生, 主要从事通信信号处理及深度学习方面的研究。

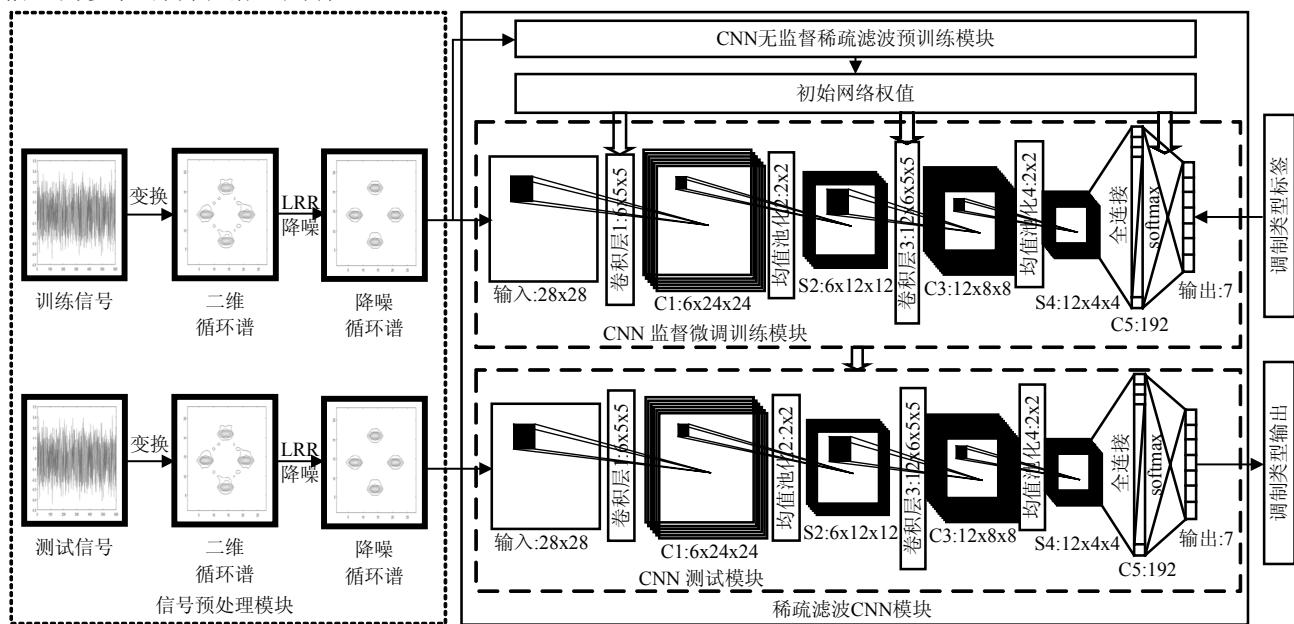
通信作者: 李少谦, 教授, E-mail: lsq@uestc.edu.cn

这3类方法在一定条件下取得了很好的效果，但由于特征需由专家设计，因此严重依赖于人工经验，耗时耗力且效果不稳定，需要研究更加智能的调制识别算法。近年来，深度学习^[10]已发展为人工智能的核心技术，其通过构建多隐层网络和海量训练数据来自动学习更有用的特征。因此，在调制识别应用中，利用深度学习将能有效提升效率。目前该类研究很少见，文献[11]将基带波形作为 2×128 图像，去训练一个卷积神经网络(convolutional neural networks, CNN)或深度神经网络(deep neural networks, DNN)来识别调制方式；文献[12]进一步用深度学习模型提取了信号的稀疏特征，据此半监督训练CNN来实现调制识别；文献[13]利用信号的异步延迟抽头图(asynchronous delay tap plots, ADTPs)来训练一个DNN，对调制方式及速率实现联合估计。这些工作较传统方法均取得了更好的成果，但仍待进一步改进。

本文基于CNN框架，提出了一种新型的、具有抗噪鲁棒性的智能调制识别算法。该算法利用调制信号变换后的循环谱图作为输入，降噪处理后训练CNN以实现识别。在监督训练之前，本文设计了一种新型的稀疏滤波准则对网络进行无监督预训练，有效增强了泛化能力，提升了识别精度且对噪声鲁棒。

1 系统模型及假设

如图1所示，调制识别在接收机中处于接收预处理与解调之间的关键位置，输入序列或波形经调制后变为 $s(t)$ ，经过信道响应 $h(\tau, t)$ 后成为 $g(t)$ ，假定信道为多径瑞利衰落，则有：



$$h(\tau, t) = \sum_i a_i(t) \delta[\tau - \tau_i(t)] \quad (1)$$

$$g(t) = s(t) * h(\tau, t) = \sum_i a_i(t) s[t - \tau_i(t)] \quad (2)$$

式中， $a_i(t), \tau_i(t)$ 分别是第 i 条径的衰减及延迟。 $g(t)$ 经过加性高斯白噪声信道 $n(t)$ 后，即可得到接收信号为 $r(t) = g(t) + n(t)$ 。接收机先对 $r(t)$ 进行滤波、变频、放大等预处理后，再开展调制识别，输出调制参数以引导解调过程。

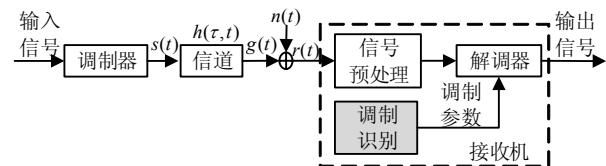


图1 系统原理模型

2 算法模型

算法结构见图2所示，总体上包括信号预处理及稀疏滤波CNN两大模块。在信号预处理环节，基于不同调制信号其循环特性也不相同这一原理，首先对原始信号进行循环谱变换作为识别的源图像，然后利用低秩表示算法(low rank representation, LRR)优良的去噪性能对谱图进行降噪预处理；在稀疏滤波CNN环节，利用降噪循环谱图训练一个CNN网络以实现调制识别，关键是设计了一组新型的无监督稀疏滤波算法对CNN进行逐层预训练，利用预训练得到的权值初始化网络，再进行有监督微调训练；最终，利用两级训练得到的CNN，对未知调制信号的降噪循环谱图开展识别分类，详细算法如下所述。

图2 算法原理结构框图

2.1 循环谱变换

大部分调制信号均可建模为循环平稳随机过程 $x(t)$, 设其循环周期为 T_0 , 则循环谱^[14]定义如下:

$$S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-j2\pi f\tau} d\tau \quad (3)$$

式中, $R_x^\alpha(\tau)$ 是 $x(t)$ 的循环自相关函数^[14], $\alpha = m/T_0$, $m \in \mathbb{Z}$, $R_x^\alpha(\tau) \neq 0$ 称为循环频率。不同调制信号的二维循环谱各不相同, 图3列举出了几类, 因此可从中提取特征来识别调制方式。

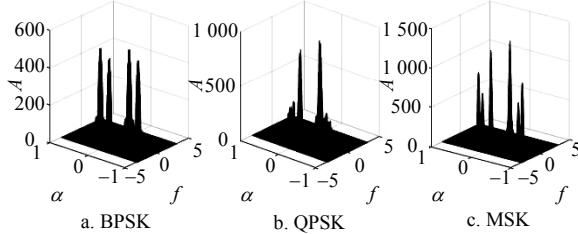


图3 3种不同调制信号的循环谱图

2.2 低秩表示降噪

信号中存在的噪声及干扰会导致循环谱图质量退化, 因此有必要开展降噪处理。文献[15]证明, LRR算法可有效处理被噪声严重污染的数据, 因此本文选用LRR算法对循环谱进行降噪处理。

二维循环谱图经归一化及矢量化后, 可组成数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{D \times N}$, 其中 D 为每样本像素个数, N 为样本数目。LRR算法等效于求解如下约束优化问题:

$$\begin{aligned} & \min_{\mathbf{Z}, \mathbf{E}, \mathbf{J}} \|\mathbf{J}\|_* + \lambda \|\mathbf{E}\|_{2,1} \\ \text{s.t. } & \mathbf{X} = \mathbf{XZ} + \mathbf{E}, \mathbf{Z} = \mathbf{J} \end{aligned} \quad (4)$$

式中, $\|\mathbf{E}\|_{2,1} = \sum_{j=1}^N \sqrt{\sum_{i=1}^D (\mathbf{E}_{ij})^2}$ 称为 $\ell_{2,1}$ 范数。求秩运算用核范数($\|\cdot\|_*$)代替, 得到的最低秩表示矩阵 \mathbf{Z} 即可表征样本之间的联系并且能有效滤除噪声 \mathbf{E} 。式(4)可通过不精确增广拉格朗日算法^[16]求解, 最终 $\hat{\mathbf{X}}_1 = \mathbf{X} - \mathbf{E}$ 为去噪的循环谱图像集。

2.3 稀疏滤波CNN

相较于传统DNN, CNN采用了局部感受视野、权值共享、池化时空降采样等关键技术, 适用于图像识别等处理, 本文选用CNN开展调制识别。此外, 理论及试验表明, 在深度学习中采用“无监督预训练+监督训练微调”的两级训练机制, 有助于学习算法向全局极小值收敛, 从而提升泛化性能^[17]。同时, 循环谱图像是稀疏信号, 提取其稀疏特征更能反映数据的内在结构, 对于不同类别的区分度更高。本文设计了一个稀疏滤波算法对网络进行无监督预训

练, 在此基础上再开展有监督的微调训练。

如图2所示, 假设CNN包含[卷积层C-1、池化层S-2]、[卷积层C-3、池化层S-4]、…[卷积层C-2m-1、池化层S-2m]共 m 组($2m$ 层)卷积及池化层, 并在 S-2m 层后全连接一个 softmax 回归输出层, 因此网络共有 $2m+1$ 层。各卷积层 C-2k-1 ($k=1, 2, \dots, m$) 分别包含 N_k 个特征图, 对应特征滤波器尺寸为 $T_k \times d_k \times d_k$, 其中 T_k 为输入图像通道数(对于循环谱之类的灰度图像, $T_1=1$, $T_k=N_{k-1}$, $k=1, 2, \dots, m$), 卷积层非线性激活函数均为 $f(\cdot)$ (通常为 relu 或 sigmoid 函数)。各池化层 S-2k ($k=1, 2, \dots, m$) 的池化区域尺寸为 $w_k \times w_k$ (池化是将原图像中 $w_k \times w_k$ 的像素块通过求最大值或加权平均的方式映射为单个像素点的过程)。在此条件下, “稀疏滤波无监督预训练+有监督微调训练”的两级网络训练算法如下所述。

2.3.1 稀疏滤波无监督预训练

1) 抽取C-1层预训练数据集。从降噪循环谱集合 $\hat{\mathbf{X}}_1$ 中随机抽取 L 个大小为 $T_1 \times d_1 \times d_1$ (即C-1层滤波器尺寸)的数据块, 将其向量化组成预训练数据集 $\mathbf{X}_1 = \{\mathbf{x}_1^{(1)}, \mathbf{x}_1^{(2)}, \dots, \mathbf{x}_1^{(L)}\} \in \mathbb{R}^{(T_1 \times d_1^2) \times L}$ 。

2) 预训练C-1层稀疏滤波器。设C-1层滤波器组权值(或称字典)为 \mathbf{W}_1 , 偏置值为 \mathbf{b}_1 , 则 $\mathbf{W}_1 \in \mathbb{R}^{N_1 \times (T_1 \times d_1^2)}$, $\mathbf{b}_1 \in \mathbb{R}^{N_1 \times 1}$, 那么卷积及平滑后的特征矩阵为 $\mathbf{F} = \sqrt{[f(\mathbf{W}_1 \mathbf{X}_1 + \text{repmat}(\mathbf{b}_1, 1, L))]^2 + \varepsilon} \in \mathbb{R}^{N_1 \times L}$ (ε 控制平滑程度)。稀疏滤波要达到两个目标: ① \mathbf{F} 中每个特征分量稀疏化并符合统一激活分布, 即 \mathbf{F} 各行的分布应该具有相似统计特性, 没有一行具有比其他行更显著的非零“激活”, 满足归一化行稀疏; ② \mathbf{F} 中每个样本的特征稀疏化, 即满足归一化列稀疏。为实现目标1), 使每一特征能够同等的被激活, 就需要对 \mathbf{F} 的各行向量 $\mathbf{l}_i \in \mathbb{R}^{1 \times L}$ ($i=1, 2, \dots, N_1$) 进行二范数归一化, 即 $\tilde{\mathbf{l}}_i = \mathbf{l}_i / \|\mathbf{l}_i\|_2$, 得到归一化特征矩阵 $\tilde{\mathbf{F}} = [\tilde{\mathbf{l}}_1, \tilde{\mathbf{l}}_2, \dots, \tilde{\mathbf{l}}_{N_1}]^T$ 。为实现目标2), 先对1)中得到的矩阵 $\tilde{\mathbf{F}}$ 的各列向量 $\tilde{\mathbf{c}}_j \in \mathbb{R}^{N_1 \times 1}$ ($j=1, 2, \dots, L$) 进行二范数归一化, 即 $\hat{\mathbf{c}}_j = \tilde{\mathbf{c}}_j / \|\tilde{\mathbf{c}}_j\|_2$, 得到位于单位 ℓ_2 范数球上的归一化特征矩阵 $\hat{\mathbf{F}} = [\hat{\mathbf{c}}_1, \hat{\mathbf{c}}_2, \dots, \hat{\mathbf{c}}_L]$ 后, 再对其利用 ℓ_1 范数惩罚进行稀疏优化。同时, 为防止权值 \mathbf{W}_1 过大, 添加正则化约束, 稀疏滤波等效于求解式(5)所示优化问题, 式中, $\text{norm_r}(\cdot)$, $\text{norm_c}(\cdot)$ 为上述行、列二范数归一化运算, 求解式(5)可得到 C-1 层的最优稀疏滤波器权值 $\hat{\mathbf{W}}_1$ 及偏置值 $\hat{\mathbf{b}}_1$ 。

$$\begin{aligned} & \min_{\hat{\mathbf{F}}, b_1} \|\hat{\mathbf{F}}\|_1 + \lambda \|\mathbf{W}_1\|_2^2 \\ \text{s.t. } & \mathbf{F} = \sqrt{[f(\mathbf{W}_1 \mathbf{X}_1 + \text{repmat}(\mathbf{b}_1, 1, L))]^2 + \varepsilon} \quad (5) \\ & \hat{\mathbf{F}} = \text{norm_c}[\text{norm_r}(\mathbf{F})] \end{aligned}$$

3) 预训练后续各卷积层及 softmax 分类器。针对后续各卷积层,逐层递归地重复步骤1)~2)中列出数据抽取及稀疏滤波过程,即可得到各卷积层最优稀疏滤波权值 $\hat{\mathbf{W}}_k$ 及偏置值 $\hat{\mathbf{b}}_k$, $k=2, 3, \dots, m$, 并计算出 $S-2m$ 层的输出特征集 $\hat{\mathbf{X}}_m \in R^{D_m \times N}$ (D_m 为特征维度)。然后,将 $\hat{\mathbf{X}}_m$ 全连接至 softmax 分类器,并进行预训练得到最优的 softmax 权重 $\hat{\mathbf{W}}_s$ 。

至此,通过逐层的稀疏卷积滤波及 softmax 预训练,就得到了能够提取循环谱图稀疏特征的网络参数初值,包括卷积滤波器权重及偏置 $\hat{\mathbf{W}}_k, \hat{\mathbf{b}}_k, k=1, 2, \dots, m$ 和 softmax 权重参数 $\hat{\mathbf{W}}_s$ 。

2.3.2 有监督微调训练

将预训练得到的滤波器参数 $\hat{\mathbf{W}}_k, \hat{\mathbf{b}}_k, k=1, 2, \dots, m$ 及 softmax 权重 $\hat{\mathbf{W}}_s$ 设为网络参数初值,基于循环谱数据集 $\hat{\mathbf{X}}_1$ 及其类别标签 \mathbf{Y} ,以多分类交叉熵误差作为代价函数,利用反向传播(back propagation, BP)及随机梯度下降(stochastic gradient descent, SGD)算法对网络重新进行训练,更新网络参数。最后,应用两级训练后的CNN即可对调制信号进行识别。

3 仿真分析

3.1 仿真模型及参数

仿真模型如图4所示,据此产生了超短波频段常见的7种调制信号(BPSK、QPSK、2FSK、4FSK、MSK、AM、FM)样本并进行测试验证,参数设置如下:

1) 对于数字调制,调制速率 f_d 为 1 MBd,对于模拟调制,基带带宽 b_d 为 1 MHz,采样率 f_s 为信号带宽或速率的 10 倍,即 $10 \text{ MS}\cdot\text{s}^{-1}$;

2) 信号经滚降系数 α 为 0.35 的根升余弦滤波器进行成型滤波,之后通过一个 3 径瑞利衰落信道,并添加加性高斯白噪声 $n(t)$ 。其中瑞利信道 3 条径的增益 $G_i (i=1, 2, 3)$ 在 $-5 \sim 0$ dB 之间随机选取,路径延迟 $\tau_i = \alpha_i \times f_d$ (对于数字调制) 或 $\tau_i = \alpha_i \times b_d$ (对于模拟调制),其中 α_i 为 $0 \sim 0.5$ 之间的随机数,同时信道的最大多普勒频移设置为 200 Hz;

3) 每类调制方式各产生了 10 000 个训练样本及 1 000 个测试样本,每样本包含 600 个采样点。为覆盖全面,训练信号信噪比在 $0 \sim 30$ dB 之间随机选取;为仿真方便,测试信噪比按照 2 dB 步进覆盖 $0 \sim 20$ dB;

4) 采用的 5 层 CNN 网络结构如图 2 所示,各层参数见表 1 所示,执行稀疏滤波预训练时,相关参数设置为: $L = 10\,000$, $\lambda = 0.0001$, $\varepsilon = 0.001$, 微调训练执行 SGD 算法时,块大小为 50, 执行 3 次迭代。

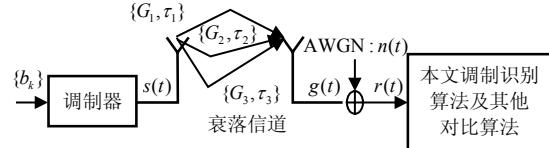


图4 仿真模型框图

表1 CNN结构参数

层名称	输入大小	结构参数	激活函数
卷积层1	28×28	6个特征图, 5×5 卷积核	Sigmoid
池化层2	$6 \times 24 \times 24$	均值池化, 尺寸 2×2	无
卷积层3	$6 \times 12 \times 12$	12个特征图, 5×5 卷积核	Sigmoid
池化层4	$12 \times 8 \times 8$	均值池化, 尺寸 2×2	无
全连接层5	192×1	7个输出单元	Softmax

3.2 识别精度分析

3.2.1 本文算法及其简化版本的对比分析

为验证本文算法效能,仿真比较了以下 3 种 CNN 算法的平均识别准确率:即简单 CNN 算法(未采用 LRR 降噪及稀疏滤波预训练的原始 CNN 算法)、抗噪 CNN 算法(采用降噪但未进行预训练的 CNN 算法)、抗噪稀疏滤波 CNN 算法(采用了 LRR 降噪及稀疏滤波预训练的改进型 CNN 算法,即本文所提完整算法),其结果见图 5 所示。可以看出,简单 CNN 算法的准确率相对较低,特别是信噪比较低(小于 5 dB)时,最低降到了 84.3%,这主要是由于没有考虑噪声影响,导致学习到的调制信号特征有一定干扰。当采用了 LRR 抗噪算法后,识别性能就得到了一定改善;在此基础上,当开展稀疏滤波 CNN 预训练后,识别准确率得到了进一步明显提升,甚至于当信噪比降至 0 dB 时,仍可达到 94.2%,表现出很好的鲁棒性。

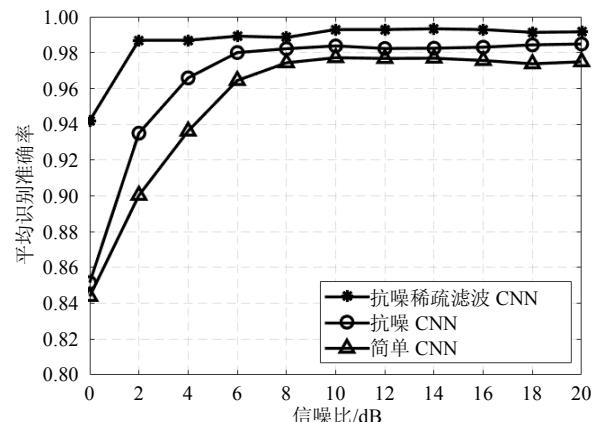


图5 本文算法及其简化版本识别精度对比图

3.2.2 样本规模对识别精度的影响分析

为分析训练样本规模对于算法性能的影响, 在保持其他参数不变的情况下, 将每类调制信号的训练样本数量从10 000降至4 000及1 000时, 利用抗噪稀疏滤波CNN算法及未采用稀疏滤波的抗噪CNN算法分别训练网络, 并对测试样本进行识别, 得到的结果对比见图6。

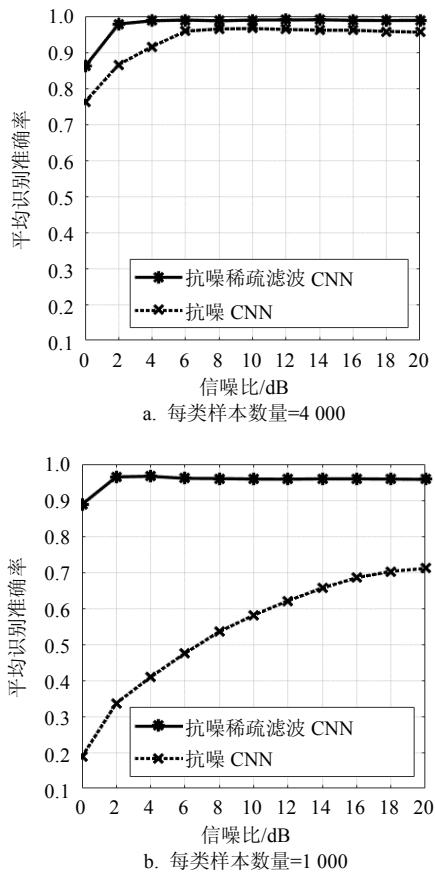


图6 样本数量降低时的识别精度对比图

从图6可看出, 当每类训练样本数量降至4 000时, 两种算法的性能与样本数量为10 000时相比, 都发生了轻微的退化, 但不明显。但是当每类训练样本数量降至1 000时, 普通抗噪CNN的识别准确率发生了严重恶化, 最差时仅达到18.8%, 最好时也只有70%左右, 而此时抗噪稀疏滤波CNN的性能最差也能达到88.8%, 且波动不大, 对噪声仍然鲁棒。这主要是由于未开展预训练的普通CNN发生了过拟合导致的, 即当每类训练样本数量降至1 000时, 即总的样本数降至 $7 \times 1 000 = 7 000$ 时, 其数量已小于网络参数总数量的5倍(即 $5 \times \{6 \times (5 \times 5 + 1) + 12 \times (5 \times 5 + 1) + 192 \times 7\} = 9 060$), 按照机器学习理论^[18], 此时会发生严重过拟合, 即训练误差很小但测试误差很大。而稀疏滤波预训练可等效为对神经元激活

施加稀疏约束, 本质上是一种对抗过拟合的正则化策略, 因此取得了明显的改善效果。以上结果表明, 抗噪稀疏滤波CNN算法在小样本量的条件下, 效果明显优于简单的CNN算法。

3.2.3 本文算法与其他算法的对比分析

为了与传统专家特征方法及其他深度学习识别算法进行对比, 一方面本文综合提取了文献[4-6]设计的10种专家特征, 并采用单隐层ANN及KNN算法分别作为分类器进行调制识别测试(称其为专家特征ANN算法及专家特征KNN算法); 另一方面, 本文对文献[8]所提的基于原始波形及CNN的深度学习识别算法(称其为原始波形CNN算法)进行了仿真测试。图7是对比结果, 本文算法达到了最高的准确率。由图可见, 当信号信噪比较低时(大于10 dB), 专家特征ANN算法的识别精度与本文算法相比, 虽有一定差距但不很明显, 然而当信噪比较低时(小于10 dB), 其性能迅速恶化, 最低时仅达到了67.5%的准确率, 而本文算法此时仍可达94.2%。这主要是由于其采用由专家设计的各类统计特征, 当信号经过多径衰落及信噪比较低时, 这类特征的分布将明显偏离理想分布, 从而导致识别性能恶化。此外, 原始波形CNN算法的识别精度虽然波动不大, 但由于其直接采用常规CNN及原始含噪波形进行训练, 因而提取出的特征区分度不够, 所以整体准确率并不是很高。总体上讲, 本文所提的抗噪稀疏滤波算法可自动学习信号特征以实现有效的调制识别, 同时对于噪声不敏感。

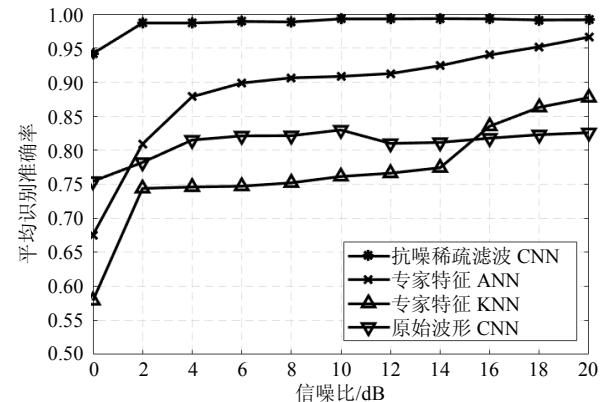


图7 本文算法及其他算法识别精度对比图

3.3 算法复杂度及速度分析

首先对本文算法及专家特征ANN、专家特征KNN和原始波形CNN3类算法进行复杂度分析。

1) 本文算法: 分为循环谱变换、LRR降噪和稀疏滤波CNN训练3个环节。设循环谱图像的尺寸为

$n \times n$, 循环谱计算窗长为 m , 则循环谱计算涉及 $n/2 \times n/2 = n^2/4$ (仅计算1/4频率平面即可)次复杂度为 m 的乘加运算; LRR降噪的运算量主要体现在 SVD(singular value decomposition)分解, 待分解矩阵大小为 $n^2 \times N$ (N 为样本数量); 稀疏滤波CNN的参数规模为1 812; 总复杂度为 $O(n^2/4 \times m)$ 次乘加运算 + $O(n^2 \times N)$ 次SVD分解+参数量为1 812的CNN训练、测试过程。

2) 专家特征ANN、专家特征KNN: 分为提取10种专家特征及ANN、KNN分类器两个环节, 提取专家特征的运算量基本与样本长度 L 相当, 即为 $10 \times O(L)$ 次乘加运算; 采用的3层ANN网络参数共277个, 采用KNN分类器时, 涉及 $O(N)$ 次距离运算;

3) 原始波形CNN: 该算法主要涉及大规模CNN训练及测试过程, 文献[8]中采用的CNN网络参数为2 665 045个参数, 是本文算法CNN网络规模的1 470倍, 训练及测试运算量巨大。

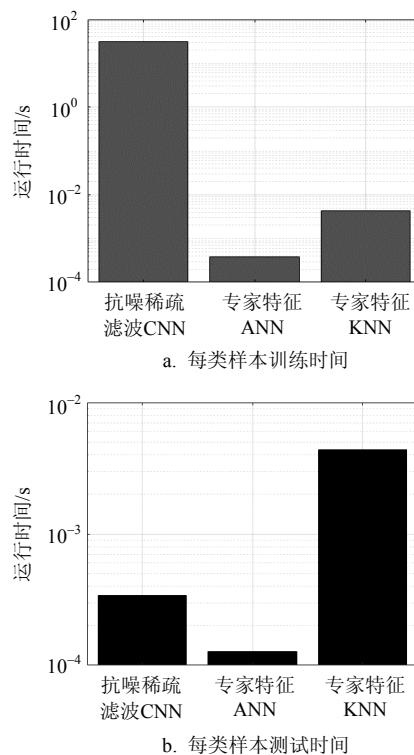


图8 算法运行速度对比图

通过上述分析, 本文算法的主要运算量消耗在循环谱计算及LRR降噪中的SVD分解运算, 会比专家特征ANN及KNN算法速度慢, 但是依然会快于规模巨大的原始波形CNN算法。为验证此分析, 本文在Intel i7-3770 8核CPU上, 利用matlab进行了对比分析。由于原始波形CNN算法网络规模很大, 训练耗时难以容忍, 因此不予对比。本文算法、专家特征

ANN、专家特征KNN 3种算法对应的训练及测试时间见图8所示(说明: 实际上KNN算法没有训练过程, 此处把算法总耗时均摊到每个训练及测试样本上)。可以看出, 本文算法在训练时间上没有优势, 比最快算法慢了大约5个数量级, 但是测试时间仅为0.000 34 s, 并没有显著差别。

4 结束语

本文基于深度学习提出了一种新型的通信信号智能调制识别算法, 训练CNN从降噪循环谱图中自动学习特征并实现调制分类。在有监督训练CNN之前, 设计了一种新型的稀疏滤波准则对网络进行逐层预训练, 从而有效利用了循环谱的稀疏性, 提高了泛化性能。最后通过实验验证了算法效能, 与传统专家特征方法及其他深度学习方法相比, 不仅识别准确率更高, 且对噪声鲁棒。下一步一方面需继续研究复杂度更低的降噪算法, 另一方面要研究如何将算法向雷达等电子信号识别领域转化。

参 考 文 献

- [1] DOBRE O A, ABDI A, BAR-NESS Y, et al. Survey of automatic modulation classification techniques: Classical approaches and new trends [J]. IET Communications, 2007, 1(2): 137-156.
- [2] AZZOUZ E E, NANDI A K. Automatic identification of digital modulation types[J]. Signal Processing, 1995, 47(1): 55-69.
- [3] NANDI A K, AZZOUZ E E. Algorithms for automatic modulation recognition of communication signals[J]. IEEE Transactions on Communications, 1998, 46(4): 431-436.
- [4] 陈红, 蔡晓霞, 徐云, 等. 基于多重分形特征的通信调制方式识别研究[J]. 电子与信息学报, 2016, 38(4): 863-869.
CHEN Hong, CAI Xiao-xia, XU Yun, et al. Communication modulation recognition based on multi-fractal dimension characteristics[J]. Journal of Electronics & Information Technology, 2016, 38(4): 863-869.
- [5] ASLAM M W, ZHU Zhe-che, NANDI A K. Automatic modulation classification using combination of genetic programming and knn[J]. IEEE Transactions on Wireless Communications, 2012, 11(8): 2742-2750.
- [6] 董鑫, 欧阳喜, 袁强. 多径信道下基于高阶累积量的通信信号调制识别算法[J]. 信息工程大学学报, 2015, 16(1): 73-78.
DONG Xin, OUYANG Xi, YUAN Qiang. Automatic modulation classification using cumulant features for communications via multipath channels[J]. Journal of Information Engineering University, 2015, 16(1): 73-78.
- [7] 王辉, 王斌. 多径衰落信道下基于循环累积量的调制分类算法[J]. 信号处理, 2016, 32(10): 1194-1201.
WANG Hui, WANG Bin. The identification classification

- algorithm based on cyclic statistics in multipath fading Channel[J]. Journal of Signal Processing, 2016, 32(10): 1194-1201.
- [8] YAN X, FENG G, WU H C, et al. Innovative robust modulation classification using graph-based cyclic-spectrum analysis[J]. IEEE Communications Letters, 2017, 21(1): 16-19.
- [9] 赵雄文, 郭春霞, 李景春. 基于高阶累积量和循环谱的信号调制方式混合识别算法[J]. 电子与信息学报, 2016, 38(3): 674-680.
- ZHAO Xiong-wen, GUO Chun-xia, LI Jing-chun. Mixed recognition algorithm for signal modulation schemes by high-order cumulants and cyclic spectrum[J]. Journal of Electronics & Information Technology, 2016, 38(3): 674-680.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.
- [11] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//International Conference on Engineering Applications of Neural Networks. Cham: Springer, 2016: 213-226.
- [12] O'SHEA T J, WEST N, VONDAL M, et al. Semi-supervised radio signal identification[C]// International Conference on Advanced Communication Technology. Bongpyeong: IEEE, 2017: 33-38.
- [13] KHAN F N, LU C, LAU A P T. Joint modulation format/bit-rate classification and signal-to-noise ratio estimation in multipath fading channels using deep machine learning[J]. Electronics Letters, 2016, 52(14): 1272-1274.
- [14] GARDNER W A, SPOONER C M. Signal interception: Performance advantages of cyclic-feature detectors[J]. IEEE Transactions on Communications, 1992, 40 (1): 149-159.
- [15] LIU G, LIN Z, YU Y. Robust subspace segmentation by low-rank representation[C]//International Conference on Machine Learning. Haifa: DBLP, 2010: 663-670.
- [16] CHEN M, LIN Z, MA Y, et al. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[J]. Eprint Arxiv, 2010, 11:1-23.
- [17] ERHAN D, BENGIO Y, COURVILLE A, et al. Why does unsupervised pre-training help deep learning? [J]. Journal of Machine Learning Research, 2010, 11(3): 625-660.

编 辑 刘飞阳