

文章编号: 2095-4980(2021)04-0562-07

复杂电磁环境下基于信号时频图像的调制识别

李雨倩, 刘玉超, 郭兰图*

(中国电波传播研究所, 山东 青岛 266107)

摘要: 为解决调制识别研究中较少考虑到不同信号的特征之间联系性的问题, 搭建了卷积神经网络(CNN)来提取信号的彩色时频图对应的特征, 并利用时频变换的分析方法, 将一维信号处理成彩色时频图, 通过卷积神经网络架构提取图像特征; 同时为了提升算法在低信噪比下的分类识别准确率, 对时频图像的纹理特征进行了特征提取, 将提取到的纹理特征与卷积神经网络中提取到的特征进行特征融合。仿真实验结果表明, 采用的时频卷积神经网络(TF-CNN)和TF-Resnet网络框架能够达到高精度信号自动调制识别分类的目的。

关键词: 调制识别; 时频变换; 卷积神经网络; 特征提取及降维; 特征融合

中图分类号: TN911.23

文献标志码: A

doi: 10.11805/TKYDA2021195

Modulation recognition algorithm based on signal time-frequency images in complex electromagnetic environment

LI Yuqian, LIU Yuchao, GUO Lantu*

(China Research Institute of Radiowave Propagation, Qingdao Shandong 266107, China)

Abstract: In complex communication environment, the connection between the characteristics of different signals is seldom considered in modulation recognition. A Convolutional Neural Network(CNN) is built to extract the characteristics of the time-frequency images of signals. Time-frequency transform is employed to process the one-dimensional signal into images, and image features are extracted through CNN. In order to improve the classification and recognition accuracy of the algorithm under low SNR, the texture features are also extracted from the images, and they are fused with the features extracted from the CNN. The simulation results show that the Time-Frequency Convolution Neural Network(TF-CNN) and TF-Resnet framework can achieve signal automatic modulation recognition and classification.

Keywords: modulation recognition; time-frequency transform; Convolutional Neural Network; feature extraction and dimension reduction; feature fusion

针对现阶段复杂的电磁环境, 传统的信号调制识别方法不再能够有效地对信号进行分类识别, 信号识别的效果受人工特征提取的影响很大, 且这种人工提取特征的方法可操作性较差, 因此信号的分类识别效果不好^[1-4]。随着当前人类社会互联网等相关技术领域的飞速发展, 越来越多的无线通信设备得到广泛使用, 导致无线信道中各种噪声和干扰显著增多, 这对无线通信设备的使用产生严重的干扰^[5-6], 由此来看, 对于这种日益复杂的电磁环境, 信号的调制识别领域正面临着非常严峻的考验^[7-9]。

为提升复杂电磁环境中信号自动调制识别技术的分类精确度, 考虑到近年来卷积神经网络在图像处理领域的广泛应用及其优越表现, 本文将卷积神经网络架构用于时频图像的特征提取。将信号的传统特征与神经网络提取到的特征进行融合, 利用融合以后的特征进行信号的分类识别。首先通过仿真生成了用于后续信号处理的数据集, 将 I/Q 信号通过时频变换处理成时频图像, 然后经过图像处理降低噪声对信号时频图的影响。为保证特征的有效性和全面性, 提出了一种基于时频图像的时频卷积神经网络(TF-CNN)架构进行特征提取, 将提取到的图像特征与时频图的纹理特征进行特征融合, 因特征融合后维度过高, 不利于提升模型的性能, 因此对融合后的特征进行了主成分分析(Principal Component Analysis, PCA)降维处理。该方法在低信噪比下, 能够提高信号调

制识别的分类准确率，并能够广泛用于军用和民用场景中的信号分类识别。

1 复杂电磁环境下的信号时频变换

通过对信号进行时频变换的分析，能够将信号的时域和频域特性一一对应起来。基于此，可以用时间和频率的二维函数对信号进行表示，从而直观地将信号在时域和频域的关系联系起来。因此对于通信信号的调制识别，时频分析是一种十分有利的信号分析和处理工具^[10]。常见的时频分析有：短时傅里叶变换(Short Time Fourier Transform, STFT)^[11]、魏格纳威利算法及其改进算法^[12]等。

1.1 短时傅里叶变换

对平稳信号进行分析时，可以对信号进行傅里叶变换处理，通过对其进行傅里叶变换能够随时记录和观察信号，获得的结果是一个与时间无关的常数。将信号的短时傅里叶时频变换表示为：

$$STFT(t, f) = \int_{-\infty}^{+\infty} x(\tau)g(\tau-t)e^{-j2\pi f\tau}d\tau = \langle x(\tau), g_{t,f}(\tau) \rangle \quad (1)$$

式中： $\langle \cdot \rangle$ 为内积； t 和 τ 为时间因子； f 为频率因子；窗函数满足 $\|g(t)\|=1$ ， $\|g_{t,f}(\tau)\|=1$ ，能够沿着时间轴的滑动而不断滑动。研究人员可以通过窗函数来观察信号的局部频率特性，从而得到一组与之对应的傅里叶变换结果。但窗函数的类型对时频变换的结果有直接影响：首先是窗函数的类型，一定要选择合适的窗函数，在正常情况下窗函数的选择并不困难，但是当处理重叠信号时，选择合适的窗函数类型是十分困难的；同时需要注意的是，窗口大小的选择对于信号分析也很重要。在分析快信号时，应提高时间分辨率，而在分析慢信号时，应提高频率分辨率。

以二进制相移键控(Binary Phase Shift Keying, BPSK)信号为例，图 1 是该信号经过 STFT 变换以后的时频图，从中能够发现，选择不同类型的窗函数和对窗函数的尺寸进行调整，都会在一定程度上对时频分析的结果产生不同的影响。

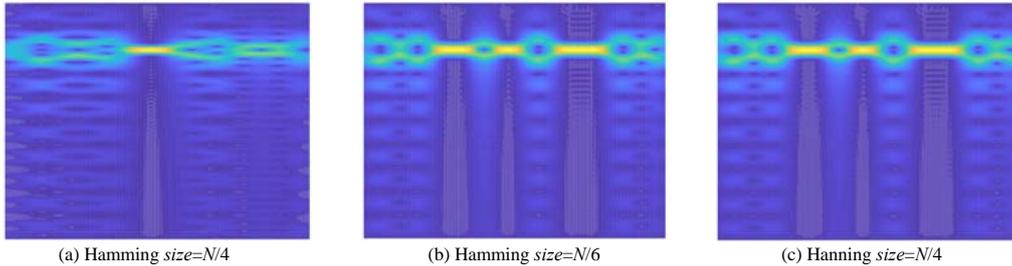


Fig.1 Time-frequency images of BPSK signal after STFT
图 1 BPSK 信号 STFT 变换时频图

1.2 魏格纳时频变换

魏格纳-威利分布(Wigner-Villy Distribution, WVD)时频变换方法使用信号本身作为窗函数进行时频变换，使窗函数能够对信号进行自适应性的调整，将信号 $s(t)$ 的WVD定义为：

$$W(t, f) = \int_{-\infty}^{+\infty} s\left(t + \frac{\tau}{2}\right)s^*\left(t - \frac{\tau}{2}\right)e^{-j2\pi f\tau}d\tau \quad (2)$$

使用信号本身作为窗函数进行 STFT 时频变换，可以改进 STFT 变换存在的问题，这样一来窗函数就能够对信号进行自适应性的调整，但 WVD 不利于叠加信号 $x(t) = x_1(t) + x_2(t)$ 的时频变换分析，它的 WVD 表达式为：

$$WVD_x(t, f) = WVD_{x_1}(t, f) + WVD_{x_2}(t, f) + WVD_{x_1, x_2}(t, f) + WVD_{x_2, x_1}(t, f) \quad (3)$$

式中 $WVD_{x_1, x_2}(t, f) = \int_{-\infty}^{+\infty} x_1\left(t + \frac{\tau}{2}\right)x_2^*\left(t - \frac{\tau}{2}\right)e^{-j2\pi f\tau}d\tau$ 。

1.3 平滑伪魏格纳时频变换

为解决 WVD 的双线性问题，将 WVD 在频域中进行平滑处理操作，表示为：

$$PWVD_s(t, \omega) = \int_{-\infty}^{+\infty} h(\tau)s\left(t + \frac{\tau}{2}\right)s^*\left(t - \frac{\tau}{2}\right)e^{-j\omega\tau}d\tau \quad (4)$$

式中：窗函数被定义为 $h(\tau)$ ； $s^*(t)$ 为 $s(t)$ 的共轭变换； $\omega=2\pi f$ 。将 BPSK 信号经过 WVD 时频变换以后对应的时频图通过仿真绘制出来，如图 2 所示。由此来看，WVD 时频变换方法虽能够在一定程度上抑制交叉干扰项的影响，但抑制效果不明显，需要对该种时频变换方法进一步改进。

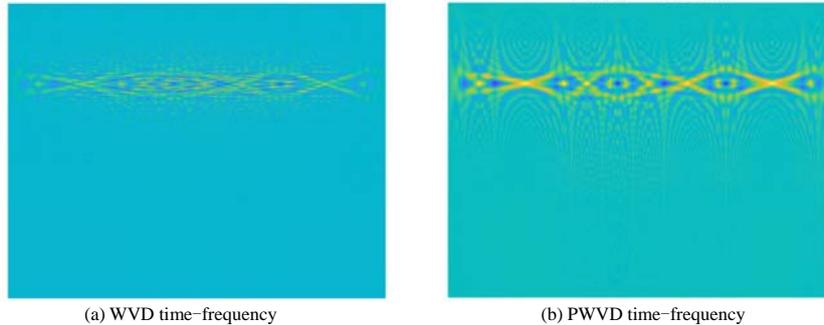


Fig.2 Time-frequency images of BPSK signal after WVD and PWVD transforms
图 2 BPSK 信号 WVD 和 PWVD 变换时频图

将窗函数从 t 和 τ 的 2 个变化方向展开，能够去除 2 个方向的交叉项，从而得到信号的平滑伪魏格纳威利分布 (Smooth Pseudo Wigner-Ville Distribution, SPWVD) 变换。WVD 具有较高的时间和频率分辨力，但它在信号项的中间存在一个交叉项，给信号分析带来麻烦，基于以上分析，本文最终选择对信号进行 SPWVD 时频变换处理。

$$SPWVD_s(t, \omega) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(u) h(\tau) s\left(t - u + \frac{\tau}{2}\right) s^*\left(t - u - \frac{\tau}{2}\right) e^{-j\omega\tau} du d\tau \quad (5)$$

式中： $g(\bullet)$ 为平滑时间窗函数； $h(\bullet)$ 为频率时间窗函数，2 个窗函数分别在时间和频率 2 个维度上压制交叉项。

2 信号时频图像的特征提取方法

为能够有效地对信号进行区分，本文对 10 种数字信号进行时频变换：幅移键控 2ASK(Amplitude-Shift Keying), 4ASK, 8ASK；频移键控 2FSK(Frequency-Shift Keying), 4FSK；正交幅度调制 16QAM(Quadrature Amplitude Modulation), 32QAM, 64QAM；BPSK 和正交相移键控(Quadrature Phase-Shift Keying, QPSK)，信号的采样频率为 40 kHz，载波频率为 4~16 kHz，采样点数为 500，相应的每种调制类型信号在每个信噪比下的信号数量为 200。将本文算法记为 TF-CNN 算法，图 3 是对应的 TF-CNN 算法框图。

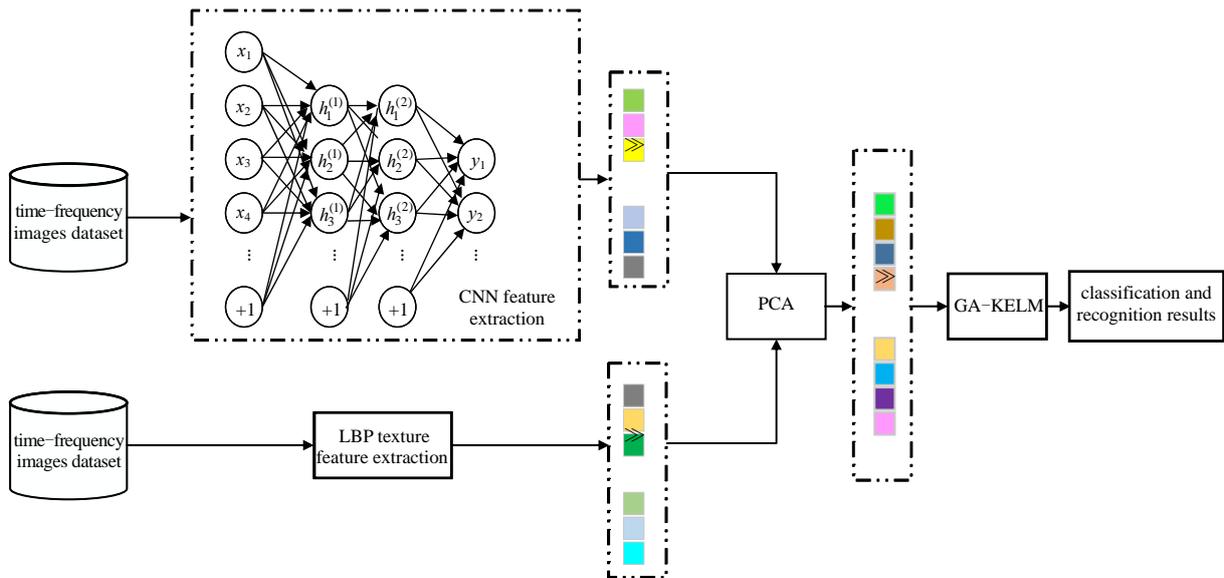


Fig.3 Block diagram of TF-CNN algorithm
图 3 TF-CNN 算法框图

2.1 基于 TF-CNN 的时频图像特征提取

搭建的 TF-CNN 网络架构共有 37 层，其中涵盖有 8 个卷积层、3 个池化层、3 个全连接层和 1 个 softmax 层，

图 4 为相应的 TF-CNN 网络架构图。该网络架构的输入均为大小为 80×80 的灰度时频图像，本文中的时频图像数据集中共有 14 000 张灰度时频图(10 种信号在 7 种信噪比下，每种信噪比对应 200 张时频图像，共计 $200 \times 7 \times 10 = 14\ 000$ 张图像)，将该数据集作为 CNN 架构模型的输入，通过 CNN 网络架构提取相应的时频图像特征。将通过 TF-CNN 网络架构提取到的特征，与信号彩色时频图像的局部二值模式(Local Binary Patterns, LBP)纹理特征进行特征融合，经过 TF-CNN 提取到的特征维度为 512×1 ，通过信号时频图像提取到的纹理特征维度为 $1 \times 2\ 891$ 。对 TF-CNN 提取到的特征进行转置，将其维度变为 1×512 以后，与 LBP 的纹理特征进行特征拼接成为 $1 \times 3\ 403$ 的特征。由于本文的 10 种信号在每一信噪比下具有 2 000 条信号信息，则此时的联合特征维度为 $2\ 000 \times 3\ 403$ 。

2.2 对高维图像特征采用 PCA 方法进行降维

本文采用 PCA 方法降维，接下来对 PCA 算法的原理展开介绍。假设样本数量为 m 个，每个样本具有 n 个特征，将样本表示为 $\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(m)}$ ，将每个样本的特征表示为 $\mathbf{X}^{(i)} = [x_1^{(i)}, x_2^{(i)}, x_3^{(i)}, \dots, x_n^{(i)}]^T$ 。由于在样本映射的过程中存在误差，需要计算每次映射的误差大小，用式(6)表示：

$$e = \frac{1}{m} \sum_{i=1}^m \left\| \mathbf{X}^{(i)} - \mathbf{X}_{\text{approx}}^{(i)} \right\|^2 \quad (6)$$

式中 $\mathbf{X}_{\text{approx}}^{(i)}$ 为样本经过映射处理以后的新坐标，该坐标的维度与样本的维度是一致的。

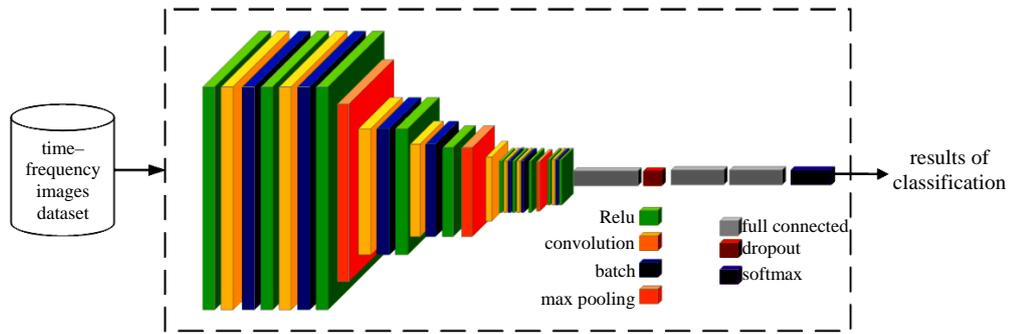


Fig.4 Diagram of TF-CNN network architecture

图 4 TF-CNN 网络架构图

PCA 算法的计算过程为：

1) 特征归一化：对训练样本的特征进行归一化处理操作，归一化操作计算的参数只能由训练样本得到，然后利用得到的样本对测试样本的参数进行归一化处理。

2) 计算降维矩阵：首先计算样本特征的协方差矩阵，若是每个样本单独计算，则使用式(7)计算相应的特征协方差：

$$\text{Cov} = \frac{1}{m} \sum_{i=1}^n (\mathbf{X}^{(i)}) \cdot (\mathbf{X}^{(i)})^T \quad (7)$$

式中 $\mathbf{X}^{(i)} = [x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)}]^T$ 。若 $\mathbf{X} = \begin{bmatrix} (\mathbf{X}^{(1)})^T \\ \vdots \\ (\mathbf{X}^{(m)})^T \end{bmatrix} = \begin{bmatrix} x_1^{(1)} & x_2^{(1)} & \dots & x_n^{(1)} \\ x_1^{(2)} & x_2^{(2)} & \dots & x_n^{(2)} \\ \vdots & \vdots & \vdots & \vdots \\ x_1^{(m)} & x_2^{(m)} & \dots & x_n^{(m)} \end{bmatrix}$ ，则使用式(8)计算特征协方差：

$$e = \frac{1}{m} \mathbf{X}^T \times \mathbf{X} \quad (8)$$

利用奇异值分解方法计算协方差矩阵的特征值和特征向量：

$$[\mathbf{U}, \mathbf{S}, \mathbf{V}] = \text{SVD}(\text{Cov}) \quad (9)$$

式中 \mathbf{U} 为通过计算得到的协方差矩阵对应的所有特征向量，其中特征向量与特征值的大小是对应的。将 \mathbf{U} 的维度表示为 $n \times n$ ，其被称为降维矩阵，利用该矩阵能够对样本进行降维处理，并且在其中包含协方差矩阵的所有特征向量，如需将样本降到 k 维，则可以选取 \mathbf{U} 矩阵的前 k 列。

3) 降维计算：得到降维矩阵后，利用降维矩阵将样本映射到低维空间中：

a) 当样本为 $\mathbf{X}^{(i)} = [\mathbf{X}_1^{(i)}, \mathbf{X}_2^{(i)}, \dots, \mathbf{X}_n^{(i)}]^T$ 时, 降维为:

$$\mathbf{Z} = \mathbf{U}_k^T \cdot \mathbf{X}^{(i)} \tag{10}$$

式中: \mathbf{U}_k 的维度为 $n \times k$; \mathbf{X} 的维度为 $n \times 1$, 则降维以后的 \mathbf{Z} 矩阵维度为 $k \times 1$ 。

b) 当样本为 $\mathbf{X} = \begin{bmatrix} (\mathbf{X}^{(1)})^T \\ \vdots \\ (\mathbf{X}^{(m)})^T \end{bmatrix}$, 降维为:

$$\mathbf{Z} = \mathbf{X} \cdot \mathbf{U}_k \tag{11}$$

式中: \mathbf{X} 的维度为 $m \times n$; \mathbf{U}_k 的维度为 $n \times k$, 则降维操作以后的 \mathbf{Z} 矩阵的维度为 $m \times k$ 。

2.3 基于 TF-Resnet 的时频图像特征提取

为了能够在低信噪比下获得更高的分类识别效果, 本文还搭建了一种基于 Resnet 的网络框架用于特征提取和分类识别, 并将其称为 TF-Resnet 网络架构, 图 5 为 TF-Resnet 的网络框架图。将通过 TF-Resnet 网络架构提取到的特征, 与信号彩色时频图像的 LBP 纹理特征进行特征融合, 得到特征维度为 1×512 的特征, 由于本文的 10 种信号在每一信噪比下具有 2 000 条信号信息, 则此时的联合特征维度为 $2\,000 \times 512$ 。

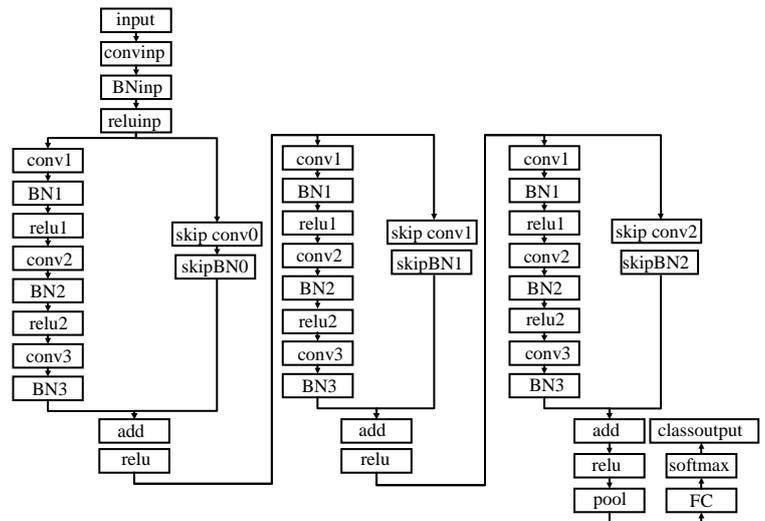


Fig.5 Network architecture of TF-Resnet
图 5 TF-Resnet 网络架构图

3 仿真分析

对这 2 种网络框架的仿真结果进行对比分析。仿真实验的硬件环境采用 AMD Ryzen 5 2600X Six-Core Processor 3.60 GHz 的计算机处理器。图 6 为基于 TF-CNN 网络架构的信号调制识别算法的训练代价变化曲线图, 图 7 为使用 TF-CNN 网络架构在低信噪比 ($R_{SN}=0\text{ dB}$) 下的信号分类识别结果, 平均识别率能够达到 80.64% 的分类效果。

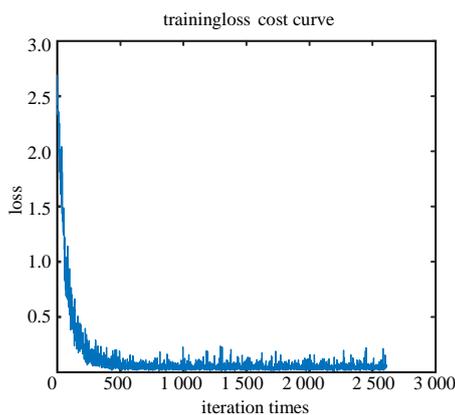


Fig.6 Training cost curve of TF-CNN
图 6 TF-CNN 网络框架的训练代价变化曲线图

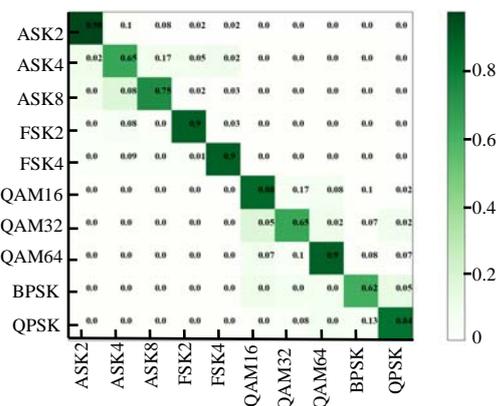


Fig.7 Results of TF-CNN at 0 dB
图 7 TF-CNN 在 0 dB 下的分类识别效果

图 8 是基于 TF-Resnet 网络架构的信号调制识别算法的训练代价变化曲线图, 图 9 是使用 TF-Resnet 网络架构在 $R_{SN}=0\text{ dB}$ 下的信号分类结果, 平均识别率能够达到 84.50% 左右。表 1 是将 TF-CNN 和 TF-Resnet 在 0 dB 时, 对应本文中 10 种数字通信信号的分类识别准确率进行了对比。本文将文献[13]中的 CNN 特征提取框架复现出来, 将输入层的信号眼图图像替换为本文的 10 种数字信号的时频图像, 图 10 是将该方法复现以后获得的训练代价变化曲线图。从图中能够发现, 该网络框架在迭代更新了 1 400 次左右后, 达到了较为理想的收敛效果。图 11 是使用文献[13]网络架构在低信噪比 $R_{SN}=0\text{ dB}$ 下的信号分类结果, 平均识别率在 76.67% 左右。

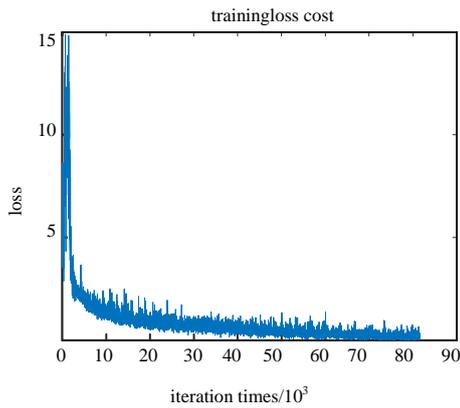


Fig.8 Training cost curve of TF-Resnet
图 8 TF-Resnet 的训练代价变化曲线

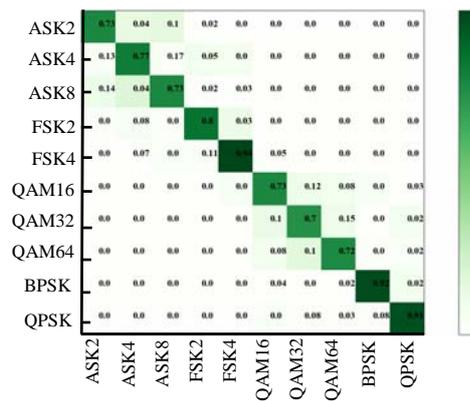


Fig.9 Results of TF-Resnet at 0 dB
图 9 TF-Resnet 在 0 dB 下的分类识别效果

表 1 TF-CNN 和 TF-Resnet 调制识别方法的分类结果

Table1 Classification results of TF-CNN and TF-Resnet

signal type	2ASK	4ASK	8ASK	2FSK	4FSK	16QAM	32QAM	64QAM	BPSK	QPSK
TF-CNN accuracy/%	97.62	65.00	75.00	90.00	89.52	88.81	64.29	90.00	61.67	84.52
TF-Resnet accuracy/%	73.33	77.00	73.00	80.00	93.78	72.50	70.67	71.67	92.35	91.67

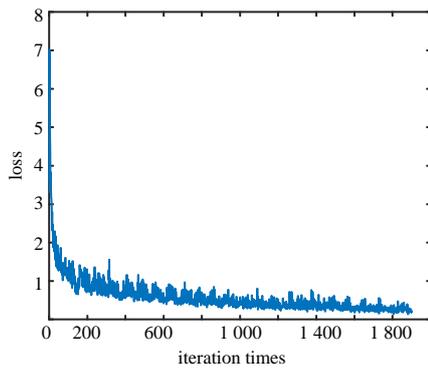


Fig.10 Training cost of [Wang]
图 10 文献[Wang]的训练代价变化曲线图

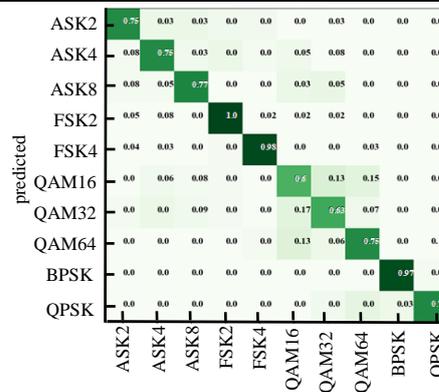


Fig.11 Results of [Wang] at 0 dB
图 11 文献[Wang]在 0 dB 下的分类识别混淆矩阵

图 12 为不同信噪比下，采用 5 种方法的信号调制识别分类的准确率折线图。从仿真结果图中能够发现，TF-Resnet 架构在低信噪比下仍能够取得很好的分类识别效果。为了进一步分析本文调制识别方法的计算复杂度，比较了不同方法的运行时间，并记录了在 -2 dB 下不同算法的分类识别准确率，结果如表 2 所示。

从分类识别的准确率均值来看，TF-Resnet 架构算法在低信噪比下能够获得最好的分类效果；从算法的运行时间上分析，文献[13]算法的运行时间最短，但分类识别的准确率最低。综合，本文提出的信号调制识别算法和其他的信号调制识别方法对比，得到的性价比更高。通过仿真实验结果的分析能够发现，在 -2 dB 低信噪比情况下，TF-Resnet 方法能够获得最好的信号分类结果为 83.67%，相比于已有的文献[13]算法、GoogleNet 网络架构和 AlexNet 网络架构，本文所提出的方法能够有 15%左右的提升空间，但同时本文算法的运行时间相比于文献[13]算法多了 398 s，主要是由于网络层数的增加，会在一定程度上降低算法的效率，延长算法的运行时间。

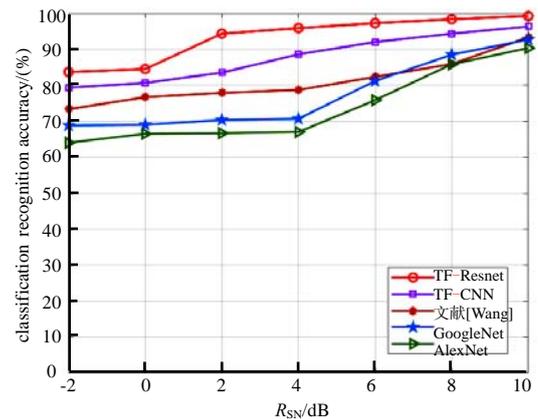


Fig.12 Comparison of classification results of different CNN architectures under different SNRs

图 12 不同 R_{SN} 下不同 CNN 架构的分类结果对比

表 2 在 -2 dB 下不同分类算法分类识别性能对比

Table2 Performance comparison of different classification algorithms at -2 dB

algorithm	average of classification accuracy/(%)	average running time/s
reference[13]	73.35	1 002
Googlenet	68.83	1 893
AlexNet	64.00	923
TF-CNN algorithm	79.33	1 376
TF-Resnet algorithm	83.67	1 400

4 结论

本文研究了基于传统特征提取的信号调制识别方法,对仿真生成的白噪声条件下的10种数字通信信号进行了特征提取。通过将本文所提出的方法与其他文献中已有的方法进行比较,发现在低信噪比下,如: $R_{SN}=-2$ dB时,本文算法相比于文献[13],信号识别准确率有10.32%的提升;相比于已有的AlexNet和GoogleNet网络架构,分别有19.67%和14.84%的提升。尽管本文方法取得了较好的信号分类性能,但仍有很多方面值得进一步改善,如:在实际通信环境中,存在很多信号混叠的情况,因此,研究混叠信号的分类识别是具有重大实际应用意义的课题方向;本文研究的信号调制识别方法主要基于监督学习,需要大量时间对数据进行训练和标注,但在实际的通信过程中,很难提前获取到已被标签化处理的数据,因此,无监督学习算法具有十分重要的研究意义。在后续的学习和研究中,可以对上述研究方向进一步展开实验分析,从而提高信号在实际生产生活中的分类识别效果。

参考文献:

- [1] 张天骐,范聪聪,葛宛莹,等. 基于ICA和特征提取的MIMO信号调制识别算法[J]. 电子与信息学报, 2020,42(9):2208-2215. (ZHANG Tianqi, FAN Congcong, GE Wanying, et al. MIMO signal modulation recognition algorithm based on ICA and feature extraction[J]. Journal of Electronics & Information Technology, 2020,42(9):2208-2215.)
- [2] HAZZA A, SHOAI B M, ALSHEBEILI S A. An overview of feature-based methods for digital modulation classification[C]// International Conference on Communications, Signal Processing, and their Applications (ICCSPA). Sharjah, United Arab Emirates: IEEE, 2013:1-6.
- [3] PENG S, JIANG H, WANG H. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018,30(3):718-727.
- [4] RAYMUNDO A A, AKHTAR M Z, FELIPE S J. Feature pooling of modulation spectrum features for improved speech emotion recognition in the wild[J]. IEEE Transactions on Affective Computing, 2018,12(1):177-188.
- [5] 周鑫,何晓新,郑昌文. 基于图像深度学习的无线电信号识别[J]. 通信学报, 2019,40(7):114-125. (ZHOU Xin, HE Xiaoxin, ZHENG Changwen. Radio signal recognition based on image deep learning[J]. Journal on Communications, 2019,40(7):114-125.)
- [6] LI X, DONG F, ZHANG S, et al. A survey on deep learning techniques in wireless signal recognition[J]. Wireless Communications and Mobile Computing, 2019(179):1-12.
- [7] 刘明骞,李建英,李兵兵,等. 认知无线电Underlay模式下MQAM信号的调制识别[J]. 西安交通大学学报, 2018,52(2):52-57. (LIU Mingqian, LI Jianying, LI Bingbing, et al. Modulation identification of MQAM signals in Underlay cognitive radios[J]. Journal of Xi'an Jiaotong University, 2018,52(2):52-57.)
- [8] 查雄,彭华,秦鑫,等. 基于多端卷积神经网络的调制识别方法[J]. 通信学报, 2019,40(11):30-37. (ZHA Xiong, PENG Hua, QIN Xin, et al. Modulation recognition method based on multi-inputs convolution neural network[J]. Journal on Communications, 2019,40(11):30-37.)
- [9] MANSOURI M, BAKLOUTI R, HARKAT M F, et al. Kernel generalized likelihood ratio test for fault detection of biological systems[J]. IEEE Transactions on Nanobioscience, 2018,17(4):498-506.
- [10] 郭立民,寇韵涵,陈涛. 基于栈式稀疏自编码器的低信噪比下低截获概率雷达信号调制类型识别[J]. 电子与信息学报, 2018,40(4):875-881. (GUO Limin, KOU Yunhan, CHEN Tao. Low probability of intercept radar signal recognition based on stacked sparse auto-encoder[J]. Journal of Electronics & Information Technology, 2018,40(4):875-881.)
- [11] KANEKO T, TAKAKI S, KAMEOKA H, et al. Generative adversarial network-based postfilter for STFT spectrograms[C]// IEEE International Conference on Acoustics. Stockholm, Sweden: IEEE, 2017:3389-3393.
- [12] WANG G, CHEN S, HUANG J, et al. Radar signal sorting and recognition based on transferred deep learning[J]. Computer Science and Application, 2019,9(9):1761-1778.
- [13] WANG D, ZHANG M, LI Z, et al. Modulation format recognition and OSNR estimation using CNN-based deep learning[J]. IEEE Photonics Technology Letters, 2017,29(19):1667-1670.

作者简介:

李雨倩(1995-),女,硕士,助理工程师,主要研究方向为信号处理、调制识别、模式识别与机器学习. email: liyuqian1025@foxmail.com.

刘玉超(1984-),男,硕士,高级工程师,主要研究方向为电磁频谱管理和复杂电磁环境建模领域技术.

郭兰图(1982-),男,硕士,研究员,主要研究方向为频谱管理、复杂电磁环境建模等.