

基于深度学习网络融合的自动调制分类方法

黄杰 张顺生 陈爽

(电子科技大学电子科学技术研究院, 四川成都 611731)

摘要: 基于深度学习网络的自动调制分类(Automatic Modulation Classification, AMC)方法虽然对大多数通信调制信号能够取得满意的分类效果,但对 WBFM(Wide Band Frequency Modulation)信号和 MQAM(Multiple Quadrature Amplitude Modulation)信号的分类并不理想。针对 WBFM 信号误判的问题,使用判决法来筛选 WBFM 信号;考虑到信号样本不平衡的情况,引入数据增强方法扩充筛选后的 WBFM 信号。针对 MQAM 信号混淆的问题,利用分数阶傅里叶变换(Fractional Fourier Transform, FRFT)获取时频维度更多的特征信息。在此基础上,提出一种基于特征金字塔网络和长短时记忆网络并联的多通道特征融合网络(Multi-channel Feature Fusion, MFF)来提取信号的深层特征和浅层特征进行分类。实验结果表明:本文所提方法在一定程度上能够解决 WBFM 信号的误判问题和 MQAM 信号的混淆问题;与 CNN(Convolutional Neural Network)、ResNet(Residual Network)、LSTM(Long Short Term Memory)、CLDNN(Convolutional Long Short-term Deep Neural Network)网络相比,所提网络具有更高的分类准确率。

关键词: 自动调制分类; 判决法; 分数阶傅里叶变换; 多通道特征融合网络

中图分类号: TN91 文献标识码: A DOI: 10.16798/j.issn.1003-0530.2023.01.005

引用格式: 黄杰,张顺生,陈爽. 基于深度学习网络融合的自动调制分类方法[J]. 信号处理, 2023, 39(1): 42-50. DOI: 10.16798/j.issn.1003-0530.2023.01.005.

Reference format: HUANG Jie, ZHANG Shunsheng, CHEN Shuang. Automatic modulation classification method based on deep learning network fusion[J]. Journal of Signal Processing, 2023, 39(1): 42-50. DOI: 10.16798/j.issn.1003-0530.2023.01.005.

Automatic Modulation Classification Method Based on Deep Learning Network Fusion

HUANG Jie ZHANG Shunsheng CHEN Shuang

(Research Institute of Electronic Science and Technology, University of Electronic Science and Technology of China, Chengdu, Sichuan 611731, China)

Abstract: Although the automatic modulation classification (AMC) method based on deep learning network can achieve satisfactory classification results for most communication modulation signals, it is not ideal for the classification of WBFM signals and MQAM signals. Aiming at the problem of misjudgment of WBFM signal, the decision method is used to screen it. Considering the imbalance of signal samples, a data enhancement method is introduced to expand the screened WBFM signals. To solve the problem of confusion of MQAM signals, fractional Fourier transform (FRFT) is adopted to obtain more feature information of time-frequency dimension. On this basis, a multi-channel feature fusion network that is composed of feature pyramid network and long short-term memory network is proposed to extract deep and shallow features for classification. The experiment results show that the proposed method can solve the problem of misjudgment of WBFM sig-

nals and the confusion of MQAM signals to a certain extent. Compared with CNN, ResNet, LSTM and CLDNN networks, the proposed network has higher classification accuracy.

Key words: automatic modulation classification; decision method; fractional Fourier transform; multi-channel feature fusion network

1 引言

随着无线电通信技术的发展,信号的调制方式也日趋复杂多样。高精度调制识别方法对于无线电通信技术的研究是至关重要的。自动调制分类(Automatic Modulation Classification, AMC)是指针对非合作通信场景,自动对通信信号调制类型进行识别的过程。然而,产生调制信号的信道越发复杂多变,AMC需要解决信号噪声过大、信号混淆、数据量过大等问题。

AMC作为通信信号解调的关键环节,在通信侦察领域得到了广泛的应用。传统的AMC方法主要分为两类:基于最大似然(Likelihood-Based, LB)的识别方法和基于特征提取(Feature-Based, FB)的识别方法。LB方法给定一个概率分布,通过检测理论和决策准则来完成信号的分类任务。FB方法在贝叶斯估计上是最优的,但算法复杂度过高、过度依赖参数估计。FB方法能够对各种人工特征进行提取和分类,如高阶累积量^[1]、时频信息^[2]、星座形状^[3]、循环平稳^[4]等。FB方法相比LB方法降低了算法的复杂度,但比较依赖人工经验和信号自身条件。如何摆脱专家经验和先验信息的限制,有效提升调制类型识别效果成了众多学者的研究方向。

近年来,深度学习方法在图像处理^[5]、语音识别^[6]、自然语言处理^[7]等领域取得重大进展。Timothy J. O'Shea率先采用卷积神经网络^[8](Convolutional Neural Network, CNN)对通信信号的调制类型进行识别,为此他专门开发了用于通信信号调制类型识别的数据集 RML2016. 10a,当信噪比(Signal-to-Noise Ratio, SNR)为 10 dB时,识别准确率能达到 73%。

受 Timothy J. O'Shea 的启发,研究人员利用 RML2016. 10a 数据集尝试不同的深度学习方法开展 AMC 识别研究。文献[9]使用卷积长短期神经网络(Convolutional Long Short-term Deep Neural Network, CLDNN),在 10 dB 信噪比条件下对通信信号调制类型的平均识别率约为 85%。然而,由于受数据集 RML2016. 10a 本身采集的原因,导致这种方法难以有效区分 WBFM(Wide Band Frequency Modula-

tion)信号和 DSB-AM(Double Sideband Amplitude Modulation)信号以及 16QAM(Quadrature Amplitude Modulation)信号和 64QAM 信号。文献[10]将 WBFM 信号用专家特征方法单独进行识别,在网络输入端进行剔除;对于 16QAM 信号和 64QAM 信号,则将两种信号认为是 64QAM 信号。这样,原本 11 分类任务变为 9 分类任务,虽然提高了总体平均识别率,但并未解决信号混淆和误判问题。

针对 WBFM 信号误判问题,本文使用判决法将误判信号剔除,并引入数据增强方法扩充筛选后的 WBFM 信号。针对 MQAM(Multiple Quadrature Amplitude Modulation)信号混淆问题,采用分数阶傅里叶变换提取时频维度的特征信息。进一步,提出一种基于特征金字塔网络和长短时记忆网络并联的多通道特征融合网络来提取信号的深层特征和浅层特征完成不同通信信号的自动调制分类。

2 问题分析

本文致力于解决模拟信号中 WBFM 信号误判为 DSB-AM 信号的问题、数字信号中 MQAM 类信号混淆的问题。利用 RML2016. 10a 数据集,我们首先分析下 WBFM 信号和 DSB-AM 信号误判以及 MQAM 类信号混淆的问题。

常见的模拟信号分为三种,调幅(Amplitude Modulation, AM)信号、调相(Phase Modulation, PM)信号、调频(Frequency Modulation, FM)信号。针对 RML2016. 10a 数据集中的模拟信号,重点分析 AM 信号和 FM 信号,两个模拟信号可以表示为:

$$S_{AM}(t) = A_c [1 + m(t)] \cos w_c t \quad (1)$$

$$S_{FM}(t) = A_c \cos [w_c t + K_f \int m(\tau) d\tau] \quad (2)$$

其中, A_c 为载波幅度, $m(t)$ 为基带信号, K_f 为 FM 的灵敏调频率。

DSB-AM 信号不含载波信号,可表示为:

$$S_{DSB}(t) = A_c m(t) \cos w_c t \quad (3)$$

而 WBFM 信号是一种特殊的 FM 信号,其瞬时相位偏移满足下式:

$$\left| K_f \int m(\tau) d\tau \right| > \frac{\pi}{6} \quad (4)$$

在 RML2016.10a 数据集中, DSB-AM 信号和 WBFM 信号都是通过模拟语音信号进行采集。在采集的过程中存在静音期, 静音期间数据样本仅有载波信息, 不包含信号的原始信息。图 1 展示了两个信号静音期的 I(In-phase) 路和 Q(Quadrature) 路波形, 两者的信号波形比较接近。文献[9]指出: 在 SNR=6 dB 以上时, 处在静音期的 WBFM 信号易误判为 DSB-AM 信号, 但 DSB-AM 的识别没有受到影响。因此, 需要筛选出处在静音期的 WBFM 信号样本, 剔除筛选后的样本再进行分类任务。

对于数字信号, 重点分析 16QAM 和 64QAM 信号。多进制正交幅度调制^[11](Multiple Quadrature Amplitude Modulation, MQAM)表达式为:

$$\begin{cases} S_{\text{MQAM}}(t) = A \sum_{k=1}^K \sqrt{S_k} e^{j(2\pi f_c t + \phi_k)} g(t - (k-1)T) \\ S_k = a_k^2 + b_k^2, \phi_k = \tan^{-1}\left(\frac{b_k}{a_k}\right) \bmod 2\pi \end{cases} \quad (5)$$

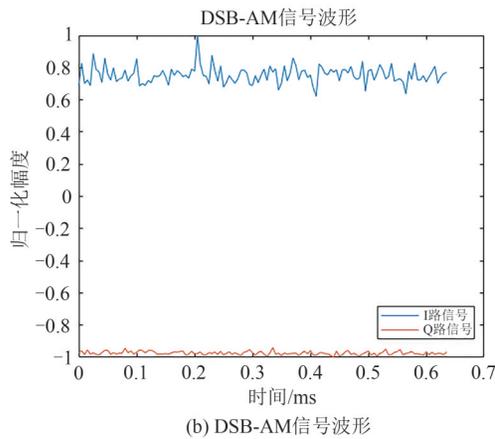
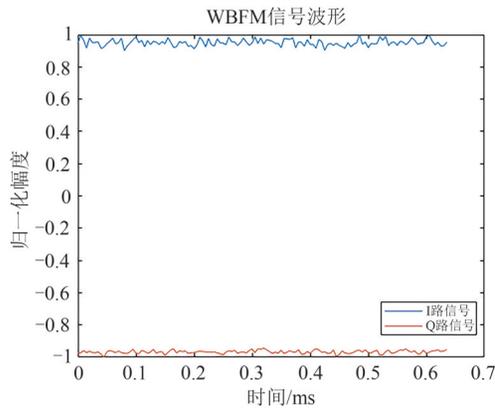


图 1 处在静音期的 WBFM 和 DSB-AM 信号波形
Fig. 1 WBFM and DSB-AM signal waveforms during silent period

其中 S_k 为第 k 个复符号, $g(t)$ 为单位冲击响应, T 为符号周期。

由上式可知, 16QAM 信号和 64QAM 信号的区别在于单个复符号携带的比特信息不同。16QAM 信号和 64QAM 信号的 I 路和 Q 路波形如图 2 所示。RML2016.10a 数据集信道环境较为复杂、噪声干扰严重, 每个样本采样点只有 128 个且每条信号符号数只有 8 个, 导致 16QAM 信号和 64QAM 信号混淆更加严重。因而, 通过信号的浅层特征信息是无法解决 16QAM 信号和 64QAM 信号的混淆问题, 需使用信号深层特征来改善这种混淆问题, 同时要确保获取的深层特征不会影响除这两类信号外其他信号的分类。

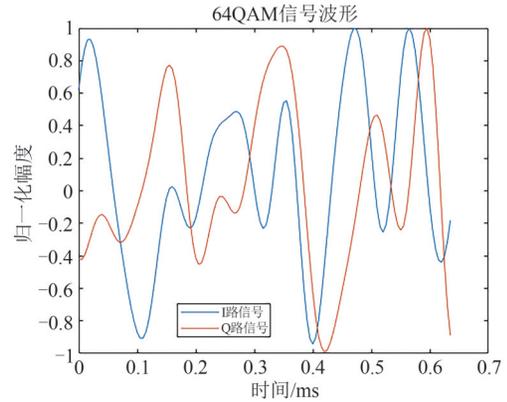
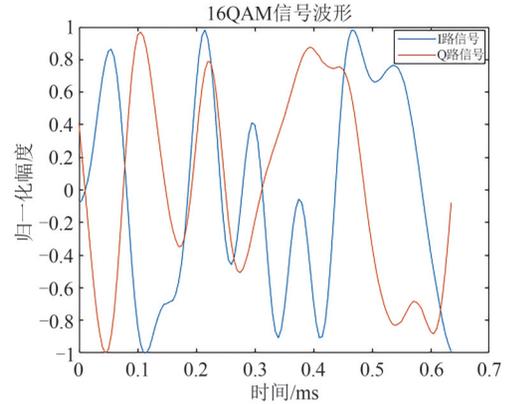


图 2 16QAM 和 64QAM 信号的 I 路和 Q 路波形
Fig. 2 I/Q waveforms of 16QAM and 64QAM signals

为了解决 16QAM 信号和 64QAM 信号的混淆问题, 我们将采用包含多尺度与多通道的深度学习网络模型。多尺度可以获得信号的不同尺度特征, 使得不同类别信号都具有较好的全局感受野, 能够区

分较为相似的类别信号。而多通道可用于提取信号层面的不同特征,通过不同特征的融合可以确保不同类别信号具有良好的区分效果。

3 基于多通道特征融合的自动调制分类方法

3.1 数据预处理

本文主要采用判决法进行数据预处理。判决法^[12]是根据信号的专家特征进行信号的分类判决。它的主要思想是对数字和模拟的混合调制类型进行自动识别,对模拟调制信号的识别主要从调制信号的专家特征,比如瞬时幅度和瞬时相位中提取。本文针对WBFM样本中处于静音期的样本,使用零中心归一化瞬时幅度谱密度的最大值 γ_{\max} ^[13]进行筛选, γ_{\max} 的表达式为:

$$\gamma_{\max} = \max \left| \text{fft} \left[\frac{N_s \cdot A(i)}{\sum_{i=1}^N A(i)} - 1 \right] \right|^2 \quad (6)$$

其中 $A(i)$ 是各个采样时刻的瞬时幅度值, N_s 是采样最大时刻。

设定一个适合的阈值 γ ,当 $\gamma_{\max} < \gamma$ 时判定信号为处于静音期WBFM信号,反之获取该样本信号。因此每种信噪比下的WBFM信号样本会少于1000个,而其他信号样本总数不变。为了避免数据不平衡导致的影响,需要对新的WBFM信号进行样本填充。RML2016.10a数据集的调制方式为I/Q调制,单个信号样本可表示为 $x_i = [I, Q]$ 。其中每个信噪比的样本维数为(1000, 2, 128),故此可用数据增强^[14]方法,比如翻转、旋转、滑动窗口对样本进行扩充。在数据增强后,把新获得不同信噪比的1000个WBFM信号样本进行打包生成新的数据集。

3.2 特征提取方法

本文主要采用幅度、相位、分数阶傅里叶变换的结果作为数据样本的特征信息。文献^[15]提出不同的调制方式在幅度和相位上有不同的体现。幅度和相位能直观表现信号在时间序列上的特征信息,并且提取非常简单便捷。RML2016.10a数据集采用I/Q调制方式,其每个信号的幅度和相位如式(7)~(8)所示:

$$A_i = \sqrt{I_i^2 + Q_i^2} \quad (7)$$

$$\varphi_i = \tan^{-1} \left(\frac{Q_i}{I_i} \right) \quad (8)$$

其中 I_i 表示样本中第 i 个数据的虚部, Q_i 表示样本中第 i 个数据和实部, A_i 表示第 i 个数据的幅度, φ_i 表示第 i 个数据的相位。

分数阶傅里叶变换^[16](Fractional Fourier Transform, FRFT)是一种特殊的傅里叶变换方式,本质是信号在时频面绕坐标原点旋转任意角度后所获得信号,是一种 n 阶的傅里叶变换。信号的FRFT的表达式为(9)~(10)。其中 F^p 为FRFT变换算子, $K_p(t, u)$ 为转换内核, α 为旋转角度。

$$X_p(u) = F^p[s(t)] = \int_{-\infty}^{+\infty} s(t) K_p(t, u) dt \quad (9)$$

$$K_p(t, u) = \begin{cases} \sqrt{1 - j \cot \alpha} e^{j\pi[(t^2 + u^2) \cot \alpha - 2tu \csc \alpha]}, & \alpha \neq n\pi \\ \delta(t - u), & \alpha = 2n\pi \\ \delta(t + u), & \alpha = (2n + 1)\pi \end{cases} \quad (10)$$

FRFT可以获得信号时频面上的图像能量分布、幅度和相位信息,使获得的样本信号拥有更丰富的特征语义。

3.3 多通道特征融合网络

多通道特征融合(Multi-channel Feature Fusion, MFF)网络是特征金字塔网络^[17]和长短时记忆网络^[18]并联的深层网络结构,网络结构如图3所示。特征金字塔网络^[17](Feature Pyramid Networks, FPN)是基于Faster R-CNN(Faster Region-CNN)网络进行改进。该网络的主要思想是将输入数据送入卷积层,获得第一个分辨率的特征图。之后将第一个分辨率缩放两倍,再获取下一个分辨率的特征图并和第一个分辨率的特征图进行元素相加。通过这样的连接,每一层预测所用的特征图都融合了不同分辨率、不同语义强度的特征,融合的不同分辨率的特征图使其获得不同层级的信息。这样可以使分类目标中的小细节都有合适的使用,同时加强了各种信息的利用。长短时记忆网络^[18](Long Short Term Memory, LSTM)网络是一种改进的循环神经网络,通过一种被称为门的结构对细胞状态进行删除或者添加信息,利用门的结构来决定哪种特征信息能够进行学习。通过这种方式来更新网络整体获得的特征,从而提取到信号的全局语义信息。

MFF网络中的特征金字塔网络是通过三层卷积神经网络多尺度组成,将CNN网络中每一层的卷积输出与LSTM网络获取的特征在全连接层进行特

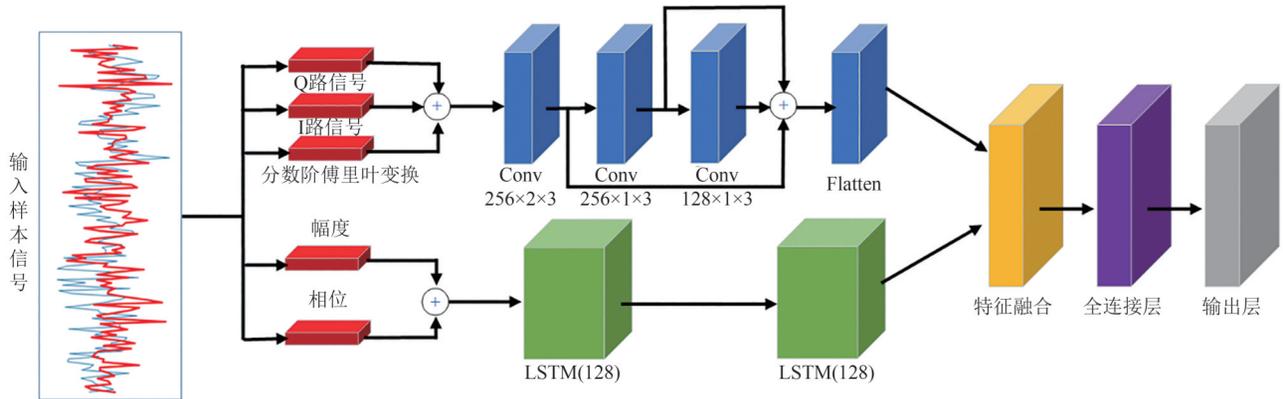


图3 MFF的网络结构

Fig. 3 The network structure of multi-channel feature fusion

征融合,用来降低梯度消失的情况,从而提高整体网络的分类准确率。CNN网络能够在对原始数据没有任何预处理的情况下完成分类任务,但是分类的准确率低、各种分类的混淆较大。其原因在于CNN网络的线性结构会把数据中重复的特征不断的提取,导致整体特征的语义不强。因此使用特征金字塔网络,将CNN网络进行多尺度连接,确保了浅层特征和深层特征的使用。LSTM网络拥有三种类型的门,通过这三种门的控制使得LSTM网络能够获取到数据的瞬时特征,从而弥补了CNN网络中无法获取的信号内部语义信息。

现在研究中,网络融合主要有三种方式:前端融合(数据级融合)、中间融合(特征级融合)和后端融合(决策级融合)^[19]。本文主要使用特征融合和决策层融合两种方式来提高信号的分类准确率。特征融合如图3所示,将分数阶傅里叶变换结果及原始I路和Q路信号以维度(N, 3, 128, 1)送入FPN网络的输入端,幅度和相位特征以维度(N, 128, 2)送入LSTM网络的输入端。决策层融合如图4所示,将FPN网络和LSTM网络的处理结果进行拼接,通过全连接层实现信号的分类。

4 实验与结果分析

4.1 数据集的选择

RML2016. 10a数据集中有3种模拟信号和8种数字信号,分别为DSB-AM、SSB-AM(Single Sideband Amplitude Modulation)、CPFSK(Continuous-Phase Frequency Shift Keying)、GFSK(Gauss Frequency Shift Keying)、4PAM(Pulse Amplitude Modulation)、16QAM、64QAM、QPSK(Quadrature Phase Shift Keying)、WBFM、8PSK。该数据集采用I/Q调制方式,采样频率200 kHz,包含128个采样点共8个符号。其中每类信号共有20种信噪比,且均匀分布在-20 dB到18 dB。每种信噪比下的样本数为1000个,样本总数为22万个。

众多研究表明RML2016. 10a数据集在信噪比低于-6 dB下,11类信号都会判为SSB-AM信号,因此判决法在-6 dB下筛选WBFM信号的性能较差。为此本文首先对RML2016. 10a数据集整体划分,获取-6 dB以上的信号,在此基础上使用判决法和数据增强方法获得的新数据集RML2022. HJ。将数据集RML2022. HJ中的样本信号按照6:2:2划分训练

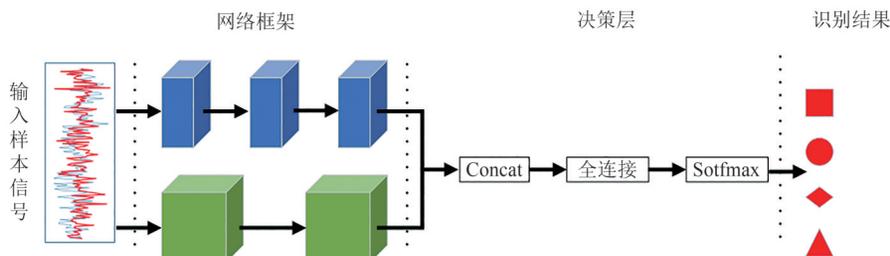


图4 决策层融合方式

Fig. 4 Fusion of decision-making layers

集、验证集和测试集。一次训练所选取的样本数为 256 个。使用动态学习率方案,初始学习率设置为 0.001。如果验证集的损失函数在训练 10 轮没有降低,则乘以系数 0.8 来提高训练效率。训练 80 轮内验证集的损失函数值未下降时,停止训练并保存模型。所有的训练、验证和测试都是基于 Nvidia GeForce RTX 2070 GPU 完成,使用 Pycharm 软件进行网络的搭建和调试。

4.2 实验与结果分析

首先使用传统 CNN 网络对数据集 RML2022. HJ 和数据集 RML2016. 10a 进行训练,得到的混淆矩阵分别如图 5 和图 6 所示。通过图 5、图 6 可知,使用判别法和数据增强方法可以大大减少 WBFM 信号误判为 DSB-AM 信号的概率。两种数据集对其他信号的分类效果差距不大,说明数据集 RML2022. HJ 并不会影响其他信号的分类。

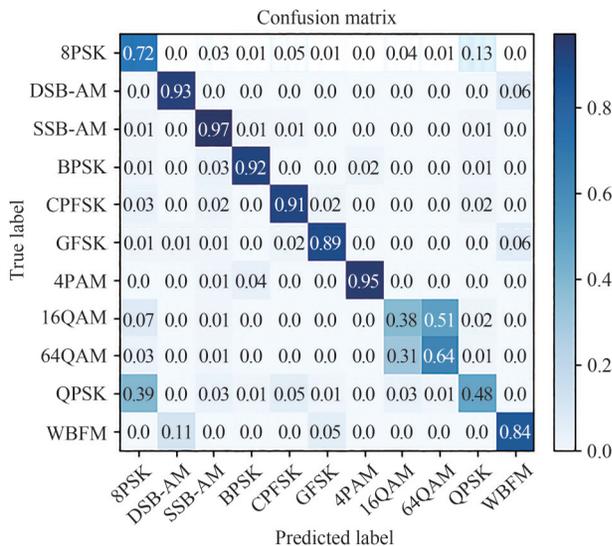


图 5 RML2022. HJ 的 CNN 混淆矩阵(SNR=16 dB)

Fig. 5 Convolutional neural network confusion matrix for RML2022. HJ(SNR=16 dB)

MFF 网络由三层卷积层、两层 LSTM 层、一层全连接层和一层输出层组成。每个卷积层都使用 ReLU 作为激活函数,采用 Adam 优化器。在训练过程中,为了避免过拟合设置丢弃因子为 0.5。MFF 网络是基于 FPN 网络和 LSTM 网络并联的网络结构,两个网络输入端均需要数据集预处理后的特征信息作为输入。

数据预处理的步骤如下:

(1)以数据集 RML2022. HJ 作为输入,用中值滤

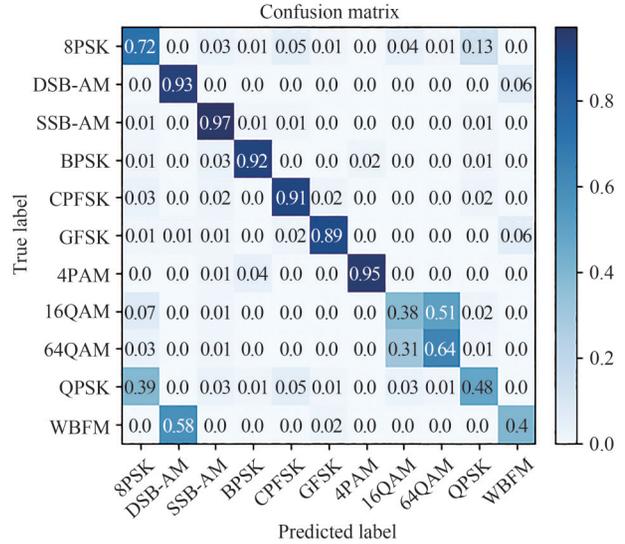


图 6 RML2016. 10a 的 CNN 混淆矩阵(SNR=16 dB)

Fig. 6 Convolutional neural network confusion matrix for RML2016. 10a(SNR=16 dB)

波方法进行降噪处理,获得信号 X_i 。

(2)将信号 X_i 通过 FRFT 获得 $FRFT(X_i)$, 计算信号 X_i 归一化后的幅度 A_i 和相位 ϕ_i 。

(3)将步骤(2)中的 $FRFT(X_i)$ 和原始 I/Q 信号进行拼接送入 FPN 网络,将步骤(2)中的幅度 A_i 和相位 ϕ_i 拼接送入 LSTM 网络。

通过上述步骤进行 MFF 网络的训练并得到 MFF 网络每种信噪比下的混淆矩阵,其中 MFF 网络最优的混淆矩阵如图 7 所示。观察图 7 可知,

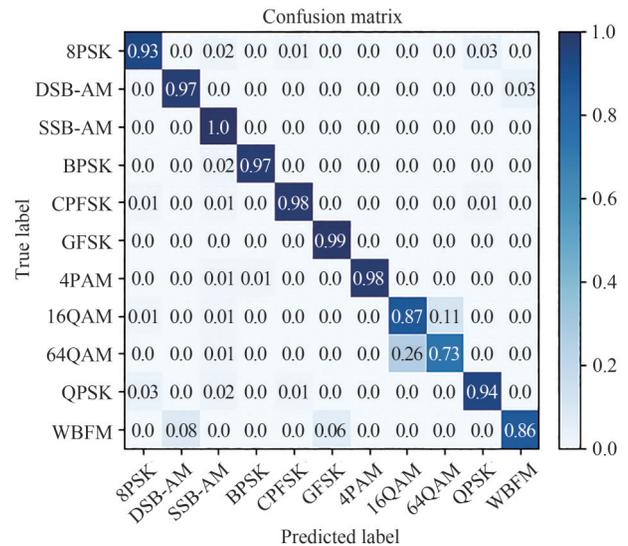


图 7 MFF 混淆矩阵(SNR=16 dB)

Fig. 7 Multi-channel feature fusion confusion matrix (SNR=16 dB)

16QAM信号和64QAM信号的分类准确率上升。通过MFF网络的混淆矩阵和CNN网络的混淆矩阵可以看出,WBFM信号分类准确率基本一致。这是由于判别法和数据增强方法改善了WBFM信号样本,即使是轻量CNN网络也依然能很好的进行识别。判别法阈值的局限性导致了仍有部分处于静音期的样本,即使提高了网络复杂度和数据的特征语义依然无法将处于静音期的WBFM信号样本识别为WBFM标签。但其他8种信号的识别率均为92%,说明MFF网络有良好的分类效果。

将MFF网络与CNN^[8], ResNet(Residual Network)^[20], LSTM^[17]和CLDNN(Convolutional Long Short-

term Deep Neural Network)^[9]网络进行对比实验。不同网络模型的混淆矩阵如图8所示。不同网络模型的信号分类准确率如图9所示。

由图8可知,CNN、ResNet、CLDNN和LSTM四种网络模型对解决WBFM信号误判为DSB-AM信号的问题均有较好的效果,说明采取的数据预处理方法具有普适性。但四种网络模型对解决MQAM信号混淆问题效果差,这是因为四种网络模型获取的特征语义不足以区分MQAM信号。对比图7可知,CNN网络中8PSK信号和GFSK信号的分类识别率较低,并会将QPSK信号误判为8PSK信号; ResNet网络会将8PSK信号误判为QPSK信号;

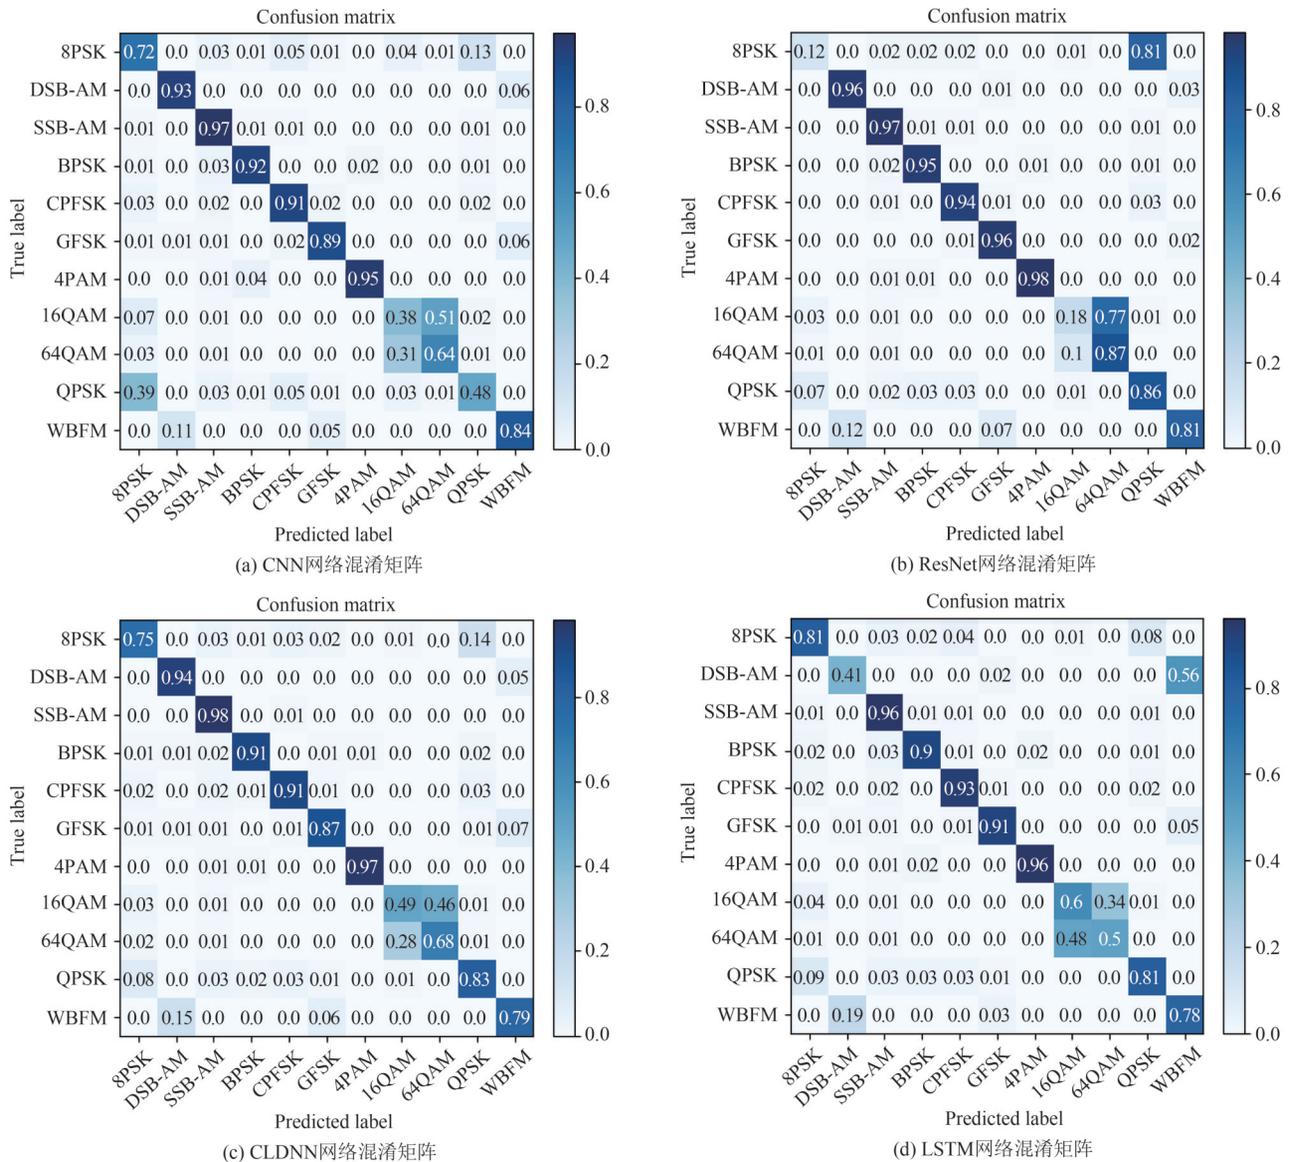


图8 不同网络模型混淆矩阵

Fig. 8 Confusion matrix of different network models

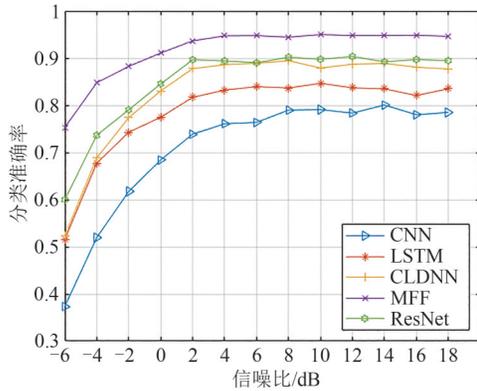


图9 不同网络模型分类性能比较

Fig. 9 Comparison of classification performance of different network models

CLDNN 网络中 8PSK 信号、GFSK 信号和 QPSK 信号的分类识别率较低; LSTM 网络中 8PSK 信号和 QPSK 信号的分类识别率较低,同时会将 DSB-AM 信号误判为 WBFM 信号。

由图 9 可知, CNN 网络在处理时间信号数据时表现不佳, 平均分类准确率仅有 78%。ResNet 和 CLDNN 网络对特征信息重复利用, 但特征信息利用不够充分, 平均分类准确率分别为 90%, 88%。MFF 网络平均分类准确率可达 94%, 这是因为网络充分提取样本信号的时间、空间、深层和浅层特征, 从而解决 16QAM 信号和 64QAM 信号混淆问题, 使平均分类准确率上升。

对比表 1 中不同网络的训练时间可以看出, MFF 网络训练时间相对其他网络较长, 这是因为获取的特征信息更多、网络结构复杂导致了时间复杂度上升。实验表明, MFF 网络在平均分类准确率方面优于其他网络模型。

表 1 不同网络模型的训练时间对比

Tab. 1 Comparison of training time of different network models

网络模型	每 step 训练时间/ms
MFF	64
CNN	6
LSTM	29
CLDNN	39
ResNet	21

5 结论

针对传统网络在信噪比大于 6 dB 条件下仍将

WBFM 信号误判为 DSB-AM 信号的问题, 本文首先使用判决法和数据增强方法对数据进行清洗来获取新的数据集, 使用 CNN 网络测试新数据集的可行性, 解决了数据集 RML2016. 10a 中处于静音期的 WBFM 信号误判问题。其次, 本文用 FRFT、幅度相位对数据样本进行特征提取, 获得新的特征参数加强数据样本的语义信息。最后, 提出了一种基于 FPN 网络和 LSTM 网络决策端融合的网络模型, 解决了 16QAM 和 64QAM 混淆的问题, 并使整体平均分类准确率有所提升。实验结果表明, 所提网络模型提高了对多种通信调制信号的平均分类准确率, 降低了 16QAM 信号与 64QAM 的混淆问题。

参考文献

- [1] CAI Tian, WANG Cheng, CUI Gaofeng, et al. Constellation-wavelet transform automatic modulation identifier for M-ary QAM signals[C]//2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications. Hong Kong, China. IEEE, 2015: 212-216.
- [2] ZHANG Haijian, YU Lei, XIA Guisong. Iterative time-frequency filtering of sinusoidal signals with updated frequency estimation [J]. IEEE Signal Processing Letters, 2016, 23(1): 139-143.
- [3] LIU Xueyuan, SHANG Jing, LEONG P H W, et al. Modulation recognition using an FPGA-based convolutional neural network [C]//2019 22nd International Conference on Electrical Machines and Systems (ICEMS). Harbin, China. IEEE, 2019: 1-6.
- [4] FEHSKE A, GAEDDERT J, REED J H. A new approach to signal classification using spectral correlation and neural networks[C]//First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. Baltimore, MD, USA. IEEE, 2005: 144-150.
- [5] POSTADJIAN T, BRIS A L, MALLET C, et al. Super-pixel partitioning of very high resolution satellite images for large-scale classification perspectives with deep convolutional neural networks [C]//IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain. IEEE, 2018: 1328-1331.
- [6] 张文字, 刘畅. 卷积神经网络算法在语音识别中的应用[J]. 信息技术, 2018, 42(10): 147-152. ZHANG Wenyu, LIU Chang. Application of convolutional neural network algorithm in speech recognition[J]. Information Technology, 2018, 42(10): 147-152. (in Chinese)

- [7] CHUNG J S, SENIOR A, VINYALS O, et al. Lip reading sentences in the wild [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA. IEEE, 2017: 3444-3453.
- [8] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C]//Engineering Applications of Neural Networks, 2016: 213-226.
- [9] LIU Xiaoyu, YANG Diyu, GAMAL A E. Deep neural network architectures for modulation classification [C]//2017 51st Asilomar Conference on Signals, Systems, and Computers. Pacific Grove, CA, USA. IEEE, 2017: 915-919.
- [10] YAO Tianyao, CHAI Yuan, WANG Shuai, et al. Radio signal automatic modulation classification based on deep learning and expert features [C]//2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference. Chongqing, China. IEEE, 2020, 1: 1225-1230.
- [11] CHAITHANYA V, REDDY V U. Blind modulation classification in the presence of carrier frequency offset [C]//2010 International Conference on Signal Processing and Communications (SPCOM). Bangalore, India. IEEE, 2010: 1-5.
- [12] 孙伟豹, 孙虎, 王军. 判决法对数字和模拟信号的自动识别及验证 [J]. 计算机科学, 2012, 39(S3): 88-89, 107.
SUN Weibao, SUN Hu, WANG Jun. Automatic recognition of digital and analog communication signals based on decision laws [J]. Computer Science, 2012, 39(S3): 88-89, 107. (in Chinese)
- [13] 梁艳, 梁昔明, 廖力清. 模拟信号调制方式自动识别仿真 [J]. 计算机测量与控制, 2006, 14(1): 117-119, 127.
LIANG Yan, LIANG Ximing, LIAO Liqing. Simulation of automatic recognition of analogue modulated signals [J]. Computer Measurement & Control, 2006, 14(1): 117-119, 127. (in Chinese)
- [14] 甘俊英, 翟懿奎, 黄聿, 等. 基于双激活层深度卷积特征的人脸美丽预测研究 [J]. 电子学报, 2019, 47(3): 636-642.
GAN Junying, ZHAI Yikui, HUANG Yu, et al. Research of facial beauty prediction based on deep convolutional features using double activation layer [J]. Acta Electronica Sinica, 2019, 47(3): 636-642. (in Chinese)
- [15] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors [J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 433-445.
- [16] 张忠民, 刘刚, 刘鲁涛. 基于分数阶傅里叶变换和循环谱的雷达信号调制方式识别 [J]. 应用科技, 2020, 47(3): 30-36.
ZHANG Zhongmin, LIU Gang, LIU Lutao. Radar signal modulation recognition based on fractional Fourier transform and cyclic spectrum [J]. Applied Science and Technology, 2020, 47(3): 30-36. (in Chinese)
- [17] WEST N E, O'SHEA T. Deep architectures for modulation recognition [C]//2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Baltimore, MD, USA. IEEE, 2017: 1-6.
- [18] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA. IEEE, 2017: 936-944.
- [19] EROL B, LEE D S, HULL J. Multimodal summarization of meeting recordings [C]//2003 International Conference on Multimedia and Expo. ICME '03. Proceedings (Cat. No.03TH8698). Baltimore, MD, USA. IEEE, 2003: III-25.
- [20] HONG Dehua, ZHANG Zilong, XU Xiaodong. Automatic modulation classification using recurrent neural networks [C]//2017 3rd IEEE International Conference on Computer and Communications. Chengdu, China. IEEE, 2017: 695-700.

作者简介



黄杰男, 1997年生, 湖北人。电子科技大学电子科学技术研究院硕士研究生, 研究方向为通信信号调制类型识别。
E-mail: 2434782527@qq.com



张顺生男, 1980年生, 安徽人。博士, 研究员/博士生导师, 综合电子技术教育部重点实验室副主任。2007年9月毕业于北京理工大学信号与信息处理专业, 获工学博士学位。2007年10月至今, 在电子科技大学从事科研和教学工作, 研究方向涉及新体制雷达探测、新体制雷达成像、人工智能技术在雷达及电子战中的应用等。
E-mail: zhangss@uestc.edu.cn



陈爽女, 1998年生, 吉林人。电子科技大学电子科学技术研究院硕士研究生, 研究方向为雷达有源欺骗干扰的检测与识别。
E-mail: 13604352096t@gmail.com