



研究与开发

基于 DropBlock 双模态混合神经网络的无线通信调制识别

高岩¹, 石坚^{1,2}, 马圣雨^{1,2}, 马柏林³, 乐光学²

(1. 河南理工大学计算机科学与技术学院, 河南 焦作 454003;

2. 嘉兴学院信息科学与工程学院, 浙江 嘉兴 314000;

3. 嘉兴学院数据科学学院, 浙江 嘉兴 314000)

摘 要: 自动调制识别作为信号检测和解调的中间步骤, 在无线通信系统中起着至关重要的作用。针对现有自动调制识别方法识别精度低的问题, 提出了一种双模态混合神经网络 (bimodal hybrid neural network, BHNN), 该网络利用多个模态中包含的互补增益信息来丰富特征维度。将改进的残差网络与双向门控循环单元并行连接, 构建双模态混合神经网络模型, 分别提取信号的空间特征与时序特征。引入 DropBlock 正则化算法, 有效抑制网络训练过程中过拟合、梯度消失和梯度爆炸等对识别精度的影响。以双模态数据输入, 充分利用信号的空间与时序特征, 通过并行连接减少网络深度, 加速模型收敛, 提高调制信号的识别精度。为验证模型的有效性, 采用两种公开数据集对模型进行仿真实验, 结果表明, BHNN 在两种数据集上识别精度高、稳定性强, 在高信噪比下识别精度分别可达 89% 和 93.63%。

关键词: 调制识别; 双模态混合网络; DropBlock 正则化; ResNet; BiGRU

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2022099

DropBlock based bimodal hybrid neural network for wireless communication modulation recognition

GAO Yan¹, SHI Jian^{1,2}, MA Shengyu^{1,2}, MA Bolin³, YUE Guangxue²

1. College of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454003, China

2. College of Information Science and Engineering, Jiaxing University, Jiaxing 314000, China

3. College of Data Science, Jiaxing University, Jiaxing 314000, China

Abstract: As an intermediate step of signal detection and demodulation, automatic modulation recognition played a momentous role in wireless communication system. Aiming at the low recognition accuracy of existing automatic modulation recognition methods, a bimodal hybrid neural network (BHNN) was proposed, which utilized complementary gain information contained in multiple modes to enrich feature dimensions. The improved residual network was connected in parallel with the bidirectional gated loop unit to construct a bimodal hybrid neural network model, and the spatial and temporal features of the signal were extracted respectively. The DropBlock regularization algo-

收稿日期: 2021-11-16; 修回日期: 2022-05-15

通信作者: 乐光学, gxyue@zjxu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.U19B2015)

Foundation Item: The National Natural Science Foundation of China (No.U19B2015)



rithm was introduced to effectively suppress the influence of over fitting, gradient disappearance and gradient explosion on the recognition accuracy in the process of network training. Using bimodal data input, the spatial and temporal characteristics of signals were fully utilized, and the network depth was reduced through parallel connection. The model convergence was accelerated, and the recognition accuracy of modulated signals was improved. In order to verify the effectiveness of the model, two public datasets were used to simulate the model. The results show that BHNN has high recognition accuracy and strong stability on the two datasets, and the recognition accuracy can reach 89% and 93.63% respectively under high signal-to-noise ratio.

Key words: modulation recognition, bimodal hybrid neural network, DropBlock regularization, ResNet, BiGRU

0 引言

现代无线通信中的自动调制识别已被广泛应用于商业和军事领域^[1-4], 调制识别算法通常分为似然估计、特征估计和深度学习。基于似然估计的识别算法利用似然函数进行决策实现信号的分类^[5-6]; 基于特征估计的识别方法^[7-8]将调制特性与理论特征进行比较。这两种方法存在需要先验概率信息、对信噪比要求高^[9]、识别类型少以及鲁棒性差等缺点。随着人工智能技术的发展, 深度学习为无线通信信号调制识别提供了一种有效途径^[10], 深度神经网络通常在过度参数化、训练大量噪声和正则化时表现良好, 成为该领域的研究热点。文献[11]研究卷积神经网络应用于调制识别领域, 其调制识别类型达到 11 种, 实现低信噪比的高精度识别。文献[12]基于 ResNet 模型对 24 种调制信号进行识别, 精度有大幅提高。文献[13]提出了一种结构化 DropBlock, 通过全连接层正则化和卷积层中激活单元在空间上相关性, 抑制卷积层特征信息丢失问题, 实现对未被丢弃的特征图归一化和卷积层的正则化。

为解决无线通信调制识别精度低的问题, 提出了一种改进的双模态混合神经网络 (bimodal hybrid neural network, BHNN) 模型, 该模型由残差网络 (residual network, ResNet) 和双向门控循环单元神经网络 (bidirectional gated recurrent unit, BiGRU) 构成。ResNet 因为网络层数多, 模型复杂度高, 训练时往往容

易出现梯度消失与梯度爆炸等问题, 因此本文在 BHNN 架构中引入 DropBlock 正则化, 希望通过正则化提高网络的泛化能力, 并允许对采集的信号进行轻微的干扰。

通过在公开数据集 RadioML2016.10a^[14]和 RadioML2016.10b^[11]上的仿真实验, 验证了所提出的基于 DropBlock 正则化的 BHNN 模型的自动调制识别方法。

1 模型设计

1.1 网络模型结构

1.1.1 ResNet 模型

BHNN 模型中第一个分支为 ResNet。残差网络可以构建更深层次的网络, 解决深度网络中精度下降的问题, 其中大量使用跳跃连接概念, 允许特征在网络的多个尺度和深度运行。残差单元 (Residual unit) 与残差块 (Residual stack) 结构如图 1 所示。




图 1 ResNet 中的残差单元与残差块结构

本文使用残差块提取特征，每个残差块包含一个卷积层、两个残差单元和一个最大池化层。残差单元中使用滤波器大小为 5 的一维卷积，ReLU 作为激活函数，并采用填充操作使得输入卷积层的张量大小与卷积后大小相同。每个卷积层后添加 DropBlock 正则化层以防止过拟合，再将残差单元的输入与最后一个 DropBlock 层的输出相加形成跳跃连接。ResNet 的模型结构见表 1。

表 1 ResNet 的模型结构


层	输出维度
输入	2×128
残差块	32×128
残差块	32×64
残差块	32×32
输出 1	512

1.1.2 BiGRU 模型

为使每个循环单元可以自适应地捕捉不同时间尺度的依赖性，文献[15]提出了由复位门和更新门组成的 GRU 模型，与长短期记忆（long short-term memory, LSTM）循环神经网络相比，结构简单，计算量少，更容易收敛。其中，更新门控制前一时刻隐藏层对当前隐藏层的影响程度，更新门值的大小正比影响当前隐藏状态；复位门控制先前隐藏层信息被忽略程度，复位门值越小，忽略的越多。GRU^[15]模型的更新方式如下：

$$r_j = \sigma([W_r x]_j + [U_r h_{(j-1)}]_j) \quad (1)$$

$$z_j = \sigma([W_z x]_j + [U_z h_{(j-1)}]_j) \quad (2)$$

图 2 BiGRU 模型网络结构^[15]

$$h_j^{(t)} = z_j h_j^{(t-1)} + (1 - z_j) \tilde{h}_j^{(t)} \quad (3)$$

$$\tilde{h}_j^{(t)} = \phi([Wx]_j + [U(r \otimes h_{(j-1)})]_j) \quad (4)$$

其中， r_j 和 z_j 分别表示 j 时刻的复位门和更新门， $\sigma(\cdot)$ 表示 sigmoid 函数， $[\cdot]_j$ 代表向量的第 j 个元素， x 是输入， W_r 和 U_r 为权重矩阵。 h_j 和 $\tilde{h}_j$ 分别代表 j 时刻的激活状态与候选激活状态。

隐藏单元通过单独的复位门和更新门学习捕获不同时间尺度上的依赖关系，学习捕捉长期与短期依赖关系的单元分别具有经常处于活动状态的更新门与复位门。

BHNN 中的另一个分支为 BiGRU 模型，BiGRU 模型网络结构如图 2 所示。BiGRU 利用了两个方向的信息流，其基本单元由一个前向传播的 GRU 单元与一个反向传播的 GRU 单元组成， n 个成对的 GRU 单元构成 BiGRU 模型。任一时刻的输出会同时提供两个方向相反的 GRU 单元，这两个单元共同决定了输出，这种设计有利于提取深层特征。BiGRU 模型结构见表 2。

表 2 BiGRU 模型结构^[15]

层	输出维度
输入	128×2
BiGRU	128×256
输出 2	32768

1.1.3 双模态混合神经网络

采用多模态融合的方式关联数据特征，其特征表示比单一模态表示更具鉴别性，且有助于提



高模型的鲁棒性,使模型在某些模态缺失时仍能有效工作,已成为调制识别的有效方法之一。文献[16]使用信号的3种模态,分别输入 ResNet 模型中,使得不同模态数据包含的丰富信息可以相互补充^[16],但是 ResNet 忽略了信息在序列中的传递,会导致较早时间步长信息的丢失。为解决这一问题,将同相和正交(in-phase and quadrature, IQ)分量与信号的极坐标形式两种模态并行输入所构建的 BHNN 模型,通过 ResNet 与 BiGRU 分别提取信号的空间特征和时序特征,使得较早时间步长的信息传递下去。BHNN 模型总体框架如图3所示。

ResNet 模型可以避免梯度消失和梯度爆炸, BiGRU 模型能够减少过拟合的发生。文献[17]中提出,在循环神经网络结构中使用极坐标形式表示的输入数据可以为 QAM 调制类型带来更优异的分类性能,因此 BiGRU 以极坐标形式接收输入样本,而非 ResNet 结构所使用的矩形形式。

文献[18]对 IQ 数据表示为:

$$M = \begin{cases} I = A \cos \varphi \\ Q = A \sin \varphi \end{cases} \quad (5)$$

其中, A 表示幅值, φ 表示相位。极坐标形式^[18]通过计算输入 IQ 采样在每个时间步长的幅值和相位获得,表示为:

$$P = (\rho, \theta) = \begin{cases} \rho = \sqrt{I^2 + Q^2} \\ \theta = A \tan 2(I, Q) \end{cases} \quad (6)$$

数据输入 ResNet 与 BiGRU 模型提取特征后,通过 Flatten 操作分别将空间特征和时序特征转换为一维特征, Concatenate 操作将一维特征拼接融合。最后以全连接层作为网络的结束,全连接层的结果输入 Softmax 分类器中,将提取的特征分类。选用 Adam 优化算法使网络更易于训练,初始学习率设置为 0.001,使用交叉熵函数计算网络训练的损失,并采用 Early Stopping 策略,当验证损失在 15 个 epoch 内没有改善时,停止训练并保存模型。BHNN 模型隐藏层详细参数见表 3。

1.2 DropBlock 正则化

基于文献[13]提出的 DropBlock 正则化方法,为使其适应无线信号分类任务,将特征图的分块调整为矩形,改善卷积层正则化效果不理想的问题。DropBlock 从图层的特征映射中删除连续的区域,主要参数为 block_size 和 keep_prob,其中 block_size 控制删除块的大小,keep_prob 控制删除的激活单元数量。

DropBlock 算法中不考虑特征映射的分辨率,为所有特征映射设置了一个常量 block_size。当 block_size=1 时,DropBlock 与 Dropout^[19]相似;当 block_size 覆盖整个特征图时,DropBlock 与 SpatialDropout^[20]相似。




图3 BHNN 模型总体框架

表3 BHNN 模型隐藏层详细参数

隐藏层名称	类型	输出维度
Input1	Featureinput	(None,2,128)
Conv	Conv1D,kernel size:1	(None,32,128)
Norm	Batch Normalization	(None,32,128)
Conv1	Conv1D,kernel size:5	(None,32,128)
DropBlock	DropBlock	(None,32,128)
Conv2	Conv1D,kernel size:5	(None,32,128)
DropBlock1	DropBlock	(None,32,128)
Add	Addition[Norm,DropBlock]	(None,32,128)
Conv3	Conv1D,kernel size:5	(None,32,128)
DropBlock2	DropBlock	(None,32,128)
Conv4	Conv1D,kernel size:5	(None,32,128)
DropBlock3	DropBlock	(None,32,128)
Add1	Addition[Add,DropBlock3]	(None,32,128)
Maxpooling	MaxPooling1D	(None,32,64)
Conv5	Conv1D,kernel size:1	(None,32,64)
Norm1	Batch Normalization	(None,32,64)
Conv6	Conv1D,kernel size:5	(None,32,64)
DropBlock4	DropBlock	(None,32,64)
Conv7	Conv1D,kernel size:5	(None,32,64)
DropBlock5	DropBlock	(None,32,64)
Add2	Addition[Norm,DropBlock5]	(None,32,64)
Conv8	Conv1D,kernel size:5	(None,32,64)
DropBlock6	DropBlock	(None,32,64)
Conv9	Conv1D,kernel size:5	(None,32,64)
DropBlock7	DropBlock	(None,32,64)
Add3	Addition[Add2,DropBlock7]	(None,32,64)
Maxpooling1	MaxPooling1D	(None,32,32)
Conv10	Conv1D,kernel size:1	(None,32,32)
Norm2	Batch Normalization	(None,32,32)
Conv11	Conv1D,kernel size:5	(None,32,32)
DropBlock8	DropBlock	(None,32,32)
Conv12	Conv1D,kernel size:5	(None,32,32)
DropBlock9	DropBlock	(None,32,32)
Add4	Addition[Norm2,DropBlock9]	(None,32,32)
Conv13	Conv1D,kernel size:5	(None,32,32)
DropBlock10	DropBlock	(None,32,32)
Conv14	Conv1D,kernel size:5	(None,32,32)
DropBlock11	DropBlock	(None,32,32)
Add5	Addition[Add4,DropBlock11]	(None,32,32)
Maxpooling2	MaxPooling1D	(None,32,16)
Flatten1	Flatten	(None,512)
Input2	Featureinput	(None,128,2)
Bidirectional	BiGRU	(None,128,256)
Flatten2	Flatten	(None,32768)
Concatenate	Concatenate [Flatten1, Flatten2]	(None, 33280)
Dense	Dense,activation:softmax	(None,10)
Reshape	Reshape	(None,10)
Output	Regression output	Regression output

keep_prob 的设置随着参数改变。DropBlock 掩码中每个零条目均由 block_size^2 展开,块完全包含在特征映射中,无法使用平均值为 $1-\text{keep_prob}$ 的伯努利分布对二进制掩码采样,需相应地调整 keep_prob。

文献[13]关于 keep_prob 的计算式为:

$$\gamma = \frac{1 - \text{keep_prob}}{\text{block_size}^2} \frac{\text{feat_size}^2}{(\text{feat_size} - \text{block_size} + 1)^2} \quad (7)$$

其中, $(\text{feat_size} - \text{block_size} + 1)^2$ 为有效种子区域的大小, feat_size 代表特征图的大小, $\text{feat_size} = w_size \times h_size$, w_size 为特征图的长, h_size 为特征图的宽。DropBlock 的主要误差在于丢弃的块中会有一些重叠,因此式(7)只是一个近似值。

DropBlock 伪代码如算法1所示。

算法1 DropBlock

输入: output activations of a layer (A),
block_size, γ , mode

if mode==Inference then

返回 A

end if

随机抽样掩码 M : $M_{ij} \sim \text{Bernoulli}(\gamma)$

对于每个零位 M_{ij} , 创建一个以 M_{ij} 为中心、宽度为 w_size 、高度为 h_size 的空间矩形,并将矩形中 M 的所有值设置为零。

置入掩码: $A = A \times M$

对特征正则化: $A = A \times \text{count}(M) / \text{count_ones}(M)$

2 实验与性能分析

2.1 数据集与实验环境

为验证 BHNN 结构的有效性,实验分别采用文献[14]与文献[11]中的公开数据集 RadioML 2016.10a 和 RadioML2016.10b 测试。

RadioML2016.10a 数据集有 22 万个样本、11 种调制方式,其中包括 8 种数字调制方式和 3 种模拟调制方式。每种调制类型包括 20 种不同的信噪比,范



围从-20 dB 到 18 dB 步长为 2 dB。3 种模拟调制包括 AM-DSB、AM-SSB 和 WBFM, 8 种数字调制方式包括 GFSK、CPFSK、PAM4、BPSK、QPSK、8PSK、16QAM 和 64QAM。RadioML2016.10a 数据集详细参数见表 4。为模拟真实的信道环境, 数据集中添加了由采样率偏移、中心频率偏移、选择性衰落和加性高斯白噪声组成的信道模块^[21]。数据集中的每个样本由 128 个采样点组成, 2×128 个向量输入模型, 其中实部和虚部分别代表 I 信号和 Q 信号。数据集的标签由信噪比和调制类型组成。

表 4 RadioML2016.10a 数据集详细参数

参数	说明
调制类型	数字调制: BPSK、QPSK、8PSK、16QAM、64QAM、CPFSK、PAM4、GFSK 模拟调制: AM-DSB、WBFM、AM-SSB
数据格式	IQ
数据维度	2×128
采样频率	1 MHz
信噪比范围	[-20 dB, -18 dB, ..., 16 dB, 18 dB]
总样本量	220 000
训练集样本量	154 000
测试集样本量	66 000

与 RadioML2016.10a 相比, RadioML2016.10b 缺少模拟调制方法中的 AM-SSB, 并且数据量有所扩充, 数据样本量为 120 万。RadioML2016.10b 数据集详细参数见表 5。

表 5 RadioML2016.10b 数据集详细参数

参数	说明
调制类型	数字调制: BPSK、QPSK、8PSK、16QAM、64QAM、CPFSK、PAM4、GFSK 模拟调制: AM-DSB、WBFM
数据格式	IQ
数据维度	2×128
采样频率	1 MHz
信噪比范围	[-20 dB, -18 dB, ..., 16 dB, 18 dB]
总样本量	1 200 000
训练集样本量	840 000
测试集样本量	360 000

实验硬件配备 Intel Xeon Gold 6230 CPU、NVIDIA Quadro RTX 8000 显卡, 所有网络模型均在单一 GPU 环境中训练。使用 Keras 和 Tensorflow 作为后端, Python3.8 进行编译。在数据预处理部分, 对数据集进行均匀分布分割, 将 70% 的数据分配给训练集, 30% 的数据分配给测试集。

2.2 不同激活函数下模型的识别精度分析

为评价 BHNN 模型对激活函数的适应性, 以 GeLU、ReLU、Linear、LeakyReLU、Softmax、ELU 6 种激活函数测试, BHNN 在不同激活函数下分类精度对比如图 4 所示, 即其在 RadioML2016.10a 和 RadioML2016.10b 数据集上的测试结果。




图 4 BHNN 在不同激活函数下分类精度对比

(1) RadioML2016.10a 数据集测试, ReLU 函数的分类性能明显优于其他激活函数, 信噪比为 0 dB 时分类准确率达到 80% 以上, 其他激活函数均未达 80%。信噪比大于 4 dB 时分类性能趋于稳定, ReLU 函数分类准确率最高为 89%; ReLU、

GeLU、LeakyReLU 以及 ELU 函数分类准确率稳定在 80%~85%；Softmax 和 Linear 函数分类效果较差，准确率低于 75%。

(2) RadioML2016.10b 数据集测试，高信噪比下 ReLU、GeLU、SeLU、LeakyReLU 以及 ELU 5 种激活函数分类性能相似；当信噪比大于 -8 dB 且小于 4 dB 时，SeLU 函数的分类效果明显低于其他 4 种激活函数。与小数据集情况相似，Softmax 和 Linear 函数在大数据集分类效果最差，高信噪比下分类准确率低于 85%。

经对比分析，ReLU 在两数据集的分类效果均较好，因此最终在模型中选用 ReLU 激活函数。

2.3 不同 DropBlock 参数下模型的识别精度分析

keep_prob 和 block_size 是 DropBlock 正则

化中的两个重要参数，两者的改变影响着 DropBlock 的效果，为使 DropBlock 对 BHNN 模型正则化效果达到最佳，使用 RadioML 2016.10a 和 RadioML2016.10b 数据集分别测试两个参数。

据文献[12]假设 keep_prob=0.7 为最佳值，对比不同的 block_size 值。DropBlock 在不同 block_size 值下的分类精度如图 5 所示，基于 RadioML2016.10a 和 RadioML2016.10b 数据集测试时，随着 block_size 值的减小，分类效果逐渐提高，当 block_size=2 时，模型的分类性能最优异。

将 block_size 值设为 2，比较不同的 keep_prob 值。DropBlock 在不同 keep_prob 值下的分类精度如图 6 所示，随着 keep_prob 值的增大，分类精




图5 DropBlock 在不同 block_size 值下的分类精度




图6 DropBlock 在不同 keep_prob 值下的分类精度



度逐渐升高, keep_prob=0.7 时性能最佳, 继续增大后性能反而下降, 基于 RadioML 2016.10a 测试时, keep_prob=0.4 时模型丧失分类能力, 分类精度稳定在 10%。

经对比分析, DropBlock 正则化中最终选用 block_size=2、keep_prob=0.7 的参数组合。

为避免网络出现梯度消失和过拟合等问题, 在 BHNN 模型中引入 DropBlock 正则化, BHNN 加与不加 DropBlock 的分类精度对比如图 7 所示。




图7 BHNN 加与不加 DropBlock 的分类精度对比

(1) RadioML2016.10a 数据集测试, 信噪比小于-5 dB 时, 加入 DropBlock 的模型分类效果较好; 在-5~-1 dB 区间内, 两模型分类效果相似; 信噪比大于-1 dB 时, 加入 DropBlock 的模型分类效果较好, 分类准确率最高为 89%。

(2) RadioML2016.10b 数据集测试, 当信噪比低于-10 dB, 不加入 DropBlock 的模型效果较

好; 信噪比高于-10 dB 时, 加入 DropBlock 的模型分类效果明显优于不加 DropBlock, 并在 0 dB 时分类准确率达到 90%。高信噪比下分类精度最高可达 93.6%。

正则化能够防止过拟合, 在模型中添加正则化可以限制模型的复杂度, 为验证 DropBlock 正则化对模型的适应性, 以 L1、L2、L1L2、L1_L2 正则化对比测试, 以上 4 种正则化均从 Tensorflow 库中直接调用, 不同正则化方法的参数设置见表 6。

表6 不同正则化方法的参数设置

算法	正则化因子	正则化惩罚项
L1	$l1=0.01$	$loss = l1 \times \text{reduce_sum}(\text{abs}(x))$
L2	$l2=0.01$	$loss = l2 \times \text{reduce_sum}(\text{square}(x))$
L1L2	$l1=0.01$	$loss = l1 \times \text{reduce_sum}(\text{abs}(x))$
	$l2=0.01$	$loss = l2 \times \text{reduce_sum}(\text{square}(x))$
L1_L2	$l1=0.01$	$loss = l1 \times \text{reduce_sum}(\text{abs}(x))$
	$l2=0.01$	$loss = l2 \times \text{reduce_sum}(\text{square}(x))$

模型在不同正则化下的分类精度如图 8 所示, 即不同正则化在 RadioML2016.10a 和 RadioML2016.10b 数据集上的测试结果。

(1) RadioML2016.10a 数据集测试, 在低信噪比下 5 种正则化分类准确率大致相同, 因为低信噪比下, 大量干扰信息淹没了大部分信号特征, 导致大多调制方式的识别精度较低, 从而降低了整体识别精度; 当信噪比大于-6 dB 时, DropBlock 的分类效果明显高于其他 4 种正则化。

(2) RadioML2016.10b 数据集测试, 当信噪比大于-8 dB 且小于 2 dB 时, DropBlock 分类效果明显高于其他 4 种正则化; 当信噪比小于-8 dB 和大于 2 dB 时, 5 种正则化的分类精度相似。

实验结果表明, 加入 DropBlock 正则化后模型避免了过拟合等问题, 分类效果在两个数据集上均有明显提升, 且 DropBlock 正则化更适用于卷积层的正则化, 其对模型过拟合问题的抑制能力优于其他正则化方法。




图8 模型在不同正则化下的分类精度

2.4 不同神经网络的识别精度对比分析

混淆矩阵是分类问题的一个衡量指标。样例根据真实情况与预测类别的组合被划分为4种情形,显然可得真正例数+假正例数+真反例数+假反例数=样例总数,分类结果的混淆矩阵见表7。

表7 分类结果混淆矩阵

真实情况	预测结果	
	正例	反例
正例	TP (真正例)	FN (假反例)
反例	FP (假正例)	TN (真反例)

混淆矩阵也称误差矩阵,能够直观反映识别结果的分布情况,对于多分类问题通常使用 $M \times M$ 的矩阵,其中对角线的分类是正确的,对角线之外均为错误的。BHNN 在 RadioML 2016.10a 数据集上的混淆矩阵如图9所示, BHNN 在 RadioML2016.10b 数据集上的混淆矩阵如图10所示,即 BHNN 模型对信号分类后的混淆矩阵,




图9 BHNN 在 RadioML2016.10a 数据集上的混淆矩阵




图 10 BHNN 在 RadioML2016.10b 数据集上的混淆矩阵

对角线上的单元格表示预测与真实标签一致，颜色越深，预测精度越高。

由于 RadioML2016.10a 数据样本量小，模型泛化能力较差，在该数据集上对信号分类识别时效果并不理想。识别的误差主要发生在 16QAM 与 64QAM 之间，WBFM 主要预测为 AM-DSB，两者都属于连续调制，它们之间的变化在复杂信道下受到限制，并且采样的模拟信号包含沉默间隔，加剧了 WBFM 与 AM-DSB 之间的混淆。

RadioML2016.10b 数据样本量更大，分类效果相对较好，在该数据集上对信号分类识别时改善了 16QAM 与 64QAM 间的混淆，误差主要发生在 WBFM 与 AM-DSB 间。

为验证 BHNN 模型的有效性，本节基于 RadioML2016.10a 与 RadioML2016.10b 数据集进行对比实验，将 CNN^[11]、ResNet^[11]、LSTM、BiGRU 与 BHNN 模型对比，结果如图 11 所示。




图 11 各模型分类精度对比

(1) RadioML2016.10a 数据集测试, 当信噪比小于-4 dB 时, 5 种网络模型分类效果相似; 随着信噪比的增大, 模型性能趋于稳定, 在高信噪比下, BHNN 模型分类准确率可达 88.5%; ResNet、BiGRU 和 LSTM 模型分类性能相似, 分类精度稳定在 82% 左右; CNN 模型分类性能较差, 分类准确率低于 75%。

(2) RadioML2016.10b 数据集测试, 当信噪比小于-6 dB 时, 5 种网络模型分类效果相似; 当信噪比大于-6 dB 时, CNN 模型分类性能明显低于其他 4 种模型, 分类准确率最高为 81.1%; BHNN 模型与 ResNet、BiGRU 和 LSTM 网络模型相比分类性能差距较小, 略微领先于另外 3 个模型, 最高分类准确率为 93.63%。

为进一步研究 DropBlock 正则化对提高模型精度的有效性, 分别在 CNN^[11]、ResNet^[11]、LSTM、BiGRU 模型中加入 DropBlock 正则化, 并与 BHNN 模型对比, 各模型加 DropBlock 后的分类精度对比如图 12 所示。




图 12 各模型加 DropBlock 后的分类精度对比

(1) RadioML2016.10a 数据集测试, 除 ResNet 模型外, BHNN 的分类准确率明显优于其他 3 个模型; 当信噪比大于 3 dB 时, BHNN 模型分类准确率超过 85%, 在 3~18 dB 范围内的平均分类准确率比其他 3 种模型高 6%~9%; 但在低信噪比情况下, 所有模型分类准确率基本一致。

(2) RadioML2016.10b 数据集测试, 除 CNN 模型外, 信噪比大于-5 dB 且小于 0 dB 情况下, BHNN 的分类准确率略优于除 CNN 外的其他 3 种模型; 在信噪比大于 0 dB 时, BHNN 与 3 种模型分类准确率基本相同, 因为数据集样本量越大, 模型训练充足, 泛化能力强。

仿真结果表明, BHNN 模型在 RadioML2016.10b 数据集上分类性能优于 RadioML2016.10a 数据集, 说明数据样本量越大, 模型训练越充足, 泛化能力越强; 模型加入 DropBlock 后分类效果均有提升, 说明 DropBlock 能够有效防止模型产生过拟合。下一步工作将聚焦于优化模型在小数据集上的分类性能。

3 结束语

深度神经网络在提高无线电信号识别的准确性和灵敏度方面展示出巨大的潜力。本文提出了一种双模态混合神经网络模型, 该模型结合 ResNet 模型可以避免梯度消失或梯度爆炸, BiGRU 模型能减少过拟合的优点。仿真结果表明, 基于 RadioML2016.10a 测试时, BHNN 的最高分类准确率为 89%; 基于 RadioML2016.10b 测试时, BHNN 的最高分类准确率为 93.63%, 相同仿真条件下分类性能均优于 CNN、LSTM、BiGRU 和 ResNet 模型。为避免模型训练时出现过拟合现象, 模型中引入 DropBlock 正则化, 并与 L1、L2、L1L2、L1_L2 4 种正则化方法对比, 仿真结果表明, BHNN 模型引入 DropBlock 正则化后分类效果有明显提升。

参考文献:

- [1] WOUTERS J, PATRINOS P, KLOOSTERMAN F, et al. Multi-pattern recognition through maximization of signal-to-peak-



- interference ratio with application to neural spike sorting[J]. IEEE Transactions on Signal Processing, 2020(68): 6240-6254.
- [2] LIU F, ZHOU Y, LIU Y A. A deep neural network method for automatic modulation recognition in OFDM with index modulation[C]//Proceedings of 2019 IEEE 89th Vehicular Technology Conference. Piscataway: IEEE Press, 2019: 1-5.
- [3] 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.
- [4] TUNZE G B, HUYNH-THE T, LEE J M, et al. Sparsely connected CNN for efficient automatic modulation recognition[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15557-15568.
- [5] LIN C, YAN W J, ZHANG L M, et al. A real-time modulation recognition system based on software-defined radio and multi-skip residual neural network[J]. IEEE Access, 2020(8): 221235-221245.
- [6] CHEN S Y, ZHANG Y, HE Z W, et al. A novel attention cooperative framework for automatic modulation recognition[J]. IEEE Access, 2020(8): 15673-15686.
- [7] PIJACKOVA K, GOTTHANS T. Radio modulation classification using deep learning architectures[C]//Proceedings of 2021 31st International Conference Radioelektronika (RADIOELEKTRONIKA). Piscataway: IEEE Press, 2021: 1-5.
- [8] ZHAO X D, ZHOU X H, XIONG J, et al. Automatic modulation recognition based on multi-dimensional feature extraction[C]//Proceedings of 2020 International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2020: 823-828.
- [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 X W, GUO C X, LI J C. 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] 孙姝君, 彭盛亮, 姚育东, 等. 基于深度学习的调制识别综述[J]. 电信科学, 2021, 37(5): 82-90.
- SUN S J, PENG S L, YAO Y D, et al. A survey of deep learning based modulation recognition[J]. Telecommunications Science, 2021, 37(5): 82-90.
- [11] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[M]//Engineering Applications of Neural Networks. Cham: Springer International Publishing, 2016: 213-226.
- [12] O'SHEA T J, ROY T, CLANCY T C. Over-the-air deep learning based radio signal classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 168-179.
- [13] GHIASI G, LIN T Y, QUOC V. DropBlock: a regularization method for convolutional networks[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems (NIPS'18). New York: ACM Press, 2018:10750-10760.
- [14] O'SHEA T J, WEST N. Radio machine learning dataset generation with gnu radio[C]//Proceedings of the GNU Radio Conference. 2016:1-6.
- [15] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. Computer Science, arXiv: 1406.1078v3, 2014.
- [16] QI P H, ZHOU X Y, ZHENG S L, et al. Automatic modulation classification based on deep residual networks with multimodal information[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 21-33.
- [17] RAMJEE S, JU S, YANG D, et al. Fast deep learning for automatic modulation classification[J]. arXiv:1901.05850, 2019.
- [18] YANG H G, ZHAO L Z, YUE G X, et al. IRLNet: a short-time and robust architecture for automatic modulation recognition[J]. IEEE Access, 2021, 9(10): 143661-143676.
- [19] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [20] TOMPSON J, GOROSHIN R, JAIN A, et al. Efficient object localization using Convolutional Networks[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015: 648-656.
- [21] LU M, PENG T J, YUE G X, et al. Dual-channel hybrid neural network for modulation recognition[J]. IEEE Access, 2021(9): 76260-76269.

[作者简介]



高岩 (1963—), 男, 博士, 河南理工大学计算机科学与技术学院教授, 主要研究方向为智能信息处理与智能控制等。

石坚 (1996—), 男, 河南理工大学硕士生, 主要研究方向为深度学习与智能通信。

马圣雨 (1997—), 女, 河南理工大学硕士生, 主要研究方向为深度学习与智能通信。

马柏林 (1961—), 男, 博士, 嘉兴学院数据科学学院教授, 主要研究方向为调和分析和小波分析、智能计算。

乐光学 (1963—), 男, 博士, 嘉兴学院信息科学与工程学院教授, 主要研究方向为多云融合与协同服务、边缘计算与一体化通信网络、深度学习与智能通信。