

基于 CBAM-GRU 的通信信号自动调制识别

杨 宵, 姚爱琴, 孙运强, 石喜玲, 张婉婷
(中北大学 信息与通信学院 太原 030051)

摘要: 本文研究了一种基于卷积注意力机制模块 (CBAM) 与门控循环单元网络 (GRU) 结合的 CBAM-GRU 分类模型, 用于非合作通信系统中的自动调制识别技术。将信号预处理后的时域幅度值、相位值以及 I/Q 值合并, 转换为输入采样值矩阵, 进入网络进行信号分类识别。使用无线电数据集 RadioML2016.10a 进行仿真实验, 并将 CBAM-GRU 模型与卷积神经网络 (CNN)、长短期记忆网络 (LSTM)、GRU、卷积长短时深度神经网络 (CLDNN) 进行比较。实验结果表明: CBAM-GRU 模型的分类识别率达到 92.79%, 相较于对比模型分别提高了 8.52%、1.84%、1.75%、8.61%, 比传统的 CNN 或 LSTM 模型, 在处理信号时能够更有效地捕捉时空特征, 从而提高识别精度。

关键词: 自动调制识别; 非合作通信系统; 卷积注意力机制; 门控循环单元网络

中图分类号: TN911.3; TP391.4 **文献标志码:** A **文章编号:** 2095-1000(2024)05-0073-09

DOI: 10.12347/j.ycyk.20240606002

引用格式: 杨宵, 姚爱琴, 孙运强, 等. 基于 CBAM-GRU 的通信信号自动调制识别[J]. 遥测遥控, 2024, 45(5): 73-81.

Automatic Modulation and Recognition of Communication Signals Based on CBAM-GRU

YANG Xiao, YAO Aiqin, SUN Yunqiang, SHI Xiling, ZHANG Wanting
(School of Information and Communication, North University of China, Taiyuan 030051)

Abstract: A CBAM-GRU classification model based on the combination of Convolutional Attention Mechanism Module (CBAM) and Gated Recurrent Unit (GRU) network is investigated for automatic modulation identification in non-cooperative communication systems. The pre-processed time-domain amplitude, phase and I/Q values of the signal are combined and converted into a matrix of input sample values, which are entered into the network for signal classification and identification. Simulations are conducted using the RadioML2016.10a radio dataset, and the CBAM-GRU model are compared with the Convolutional Neural Network (CNN), Long Short-Term Memory network (LSTM), GRU, and Convolutional Long Deep Neural Network (CLDNN). The results indicates that the classification accuracy of the CBAM-GRU model reaches 92.79%, showing improvements of 8.52%, 1.84%, 1.75%, and 8.61% over the comparison models respectively. Compared to traditional CNN or LSTM models, the CBAM-GRU model is more effective in capturing spatio-temporal features of signals, thereby enhancing recognition accuracy.

Keywords: Automatic modulation recognition; Non-cooperative communication systems; Convolutional block attention mechanism; Gated recurrent unit network

Citation: YANG Xiao, YAO Aiqin, SUN Yunqiang, et al. Automatic Modulation and Recognition of Communication Signals Based on CBAM-GRU[J]. Journal of Telemetry, Tracking and Command, 2024, 45(5): 73-81.

0 引言

自动调制识别 (Automatic Modulation Recognition, AMR) 技术使接收机能够在非合作通信环境中自动识别信号的调制类型。该项技术在军事和民用领域得到了广泛应用, 如频谱干扰检测、频

谱感知和认知无线电 (Cognitive Radio, CR) 等。AMR 本质上是一个分类问题, 传统的 AMR 方法主要有基于似然比理论的方法^[1,2]和基于特征提取^[3]的方法。由于无线环境的日益复杂, 信号类型多样且同一信号特征之间存在显著差异, 传统的模式识别方法在特征提取方面需要大量人力成本, 且

信号分类的准确率有限。神经网络能够自动从大量信号样本中提取特征,有效解决了传统模式识别的缺点,并且可以联合多个网络进行识别,因此在AMR领域得到了越来越广泛的应用,神经网络已成为AMR研究的热点。

O'Shea 等人^[4]在2016年创建了RML2016.10a数据集,并引入卷积神经网络(Convolutional Neural Network, CNN)到AMR领域,深度学习逐渐在无线电通信领域得到应用。文献[5]使用循环神经网络(Recurrent Neural Network, RNN),利用接收到的通信信号的时间序列特征,避免了手动提取信号特征。与基于CNN的方法相比,该方法表现出明显优势,并选择了双层门控循环单元(Gated Recurrent Unit, GRU)网络的更有效结构,进一步提高了识别效果。文献[6]使用长短期记忆网络(Long Short Term Memory, LSTM)处理I/Q数据,并将其转换为幅度和相位信息,相较于直接输入I/Q数据,这种数据预处理方法取得了更优异的效果,凸显了数据预处理在自动调制识别中的重要性。文献[7]使用卷积长短时深度神经网络(Convolutional Long Short-Term Deep Neural Networks, CLDNN)进行分类识别,该模型结合了CNN和LSTM,能够处理原始时域波形,实现更高效的调制识别。文献[8]改进了文献[4]的CNN作为训练模型,其结构包括4个卷积层和2个全连接层,表现出较低的算法复杂性和较短的训练时间。文献[9]引入了一种数据驱动的融合模型,通过将两个CNN通道的空间特征信息与LSTM的时序特征相互串联,实现了对调制信号的更精准分类。这种复合算法^[10,11]结合CNN和RNN的优势网络结构,不仅增强了网络的容量和特征提取能力,还有效解决了梯度消失的问题。然而,这也导致了网络参数量和运行时间的增加。

针对此问题,本文将卷积注意力机制模块(Convolutional Block Attention Module, CBAM)^[12,13]与门控循环单元相结合。CBAM模块的引入有助于有效降低无效目标的干扰,提升信号的分类识别性能。当CBAM与GRU网络相结合时,CBAM展现出对序列数据特征的优秀提取能力,有助于解决长期依赖问题。尽管已有研究利用深度学习进行自动调制识别取得了一定成果,但大多数方法未能有效结合空间和时间特征。本文通过引入卷积注意力机制,更好地提取了信号的时空特征,

从而显著提升了识别率。与现有方法相比,模型性能在高信噪比条件下表现尤为突出。

1 调制信号模型与预处理

通信系统中使用的AMR系统框架^[14]如图1所示,输入信号经过发射机调制成适合无线传输的射频信号,并通过通信信道传输。接收器捕获到信号后,将其解调为基带复数信号序列并进行预处理。




图1 AMR的系统框架

Fig.1 System framework of AMR

在接收端,已调信号模型见式(1),存在时变载波相位偏移。 $m(k)$ 代表发送的基带信号序列, $n(k)$ 表示加性白高斯噪声, $A \in [0, 1]$ 表示信道增益, $\phi(k)$ 表示相位偏移。

$$x(k) = Ae^{j\phi(k)}m(k) + n(k) \quad (1)$$

接收到的调制信号是IQ信号,包括同相分量 X_I ,正交分量 X_Q 。

$$x_k = X_I + jX_Q \quad (2)$$

原始信号可以通过其同相 X_I 与正交分量 X_Q 进行表示,同时也可以通过其幅度 X_A 和相位 X_p 来表示,元素可以由下式得到:

$$X_A = \sqrt{X_I^2 + X_Q^2} \quad (3)$$

$$X_p = \arctan\left(\frac{X_Q}{X_I}\right) \quad (4)$$

将采样点上的两个通道的值合并,使每个采样点信号值变为一个矩阵 $\begin{pmatrix} X_I & X_Q \\ X_A & X_p \end{pmatrix}$,此时信号的维度为 $k \times 4$ 。

2 算法结构设计

2.1 CBAM网络结构

CBAM是一种用于增强CNN网络性能的注意力机制模块,由Sanghyun Woo等人^[15]在2018年提出。这种机制模仿了人类视觉感知中的注意力机制,能够聚焦于有用信息、减少无效信息干扰,从而提高模型的效率和准确率^[16]。就像人类的视觉一样,CBAM经过训练自动调整其配置参数,实现最佳性能。在图2中可见,CBAM引入通道注意力和

空间注意力来增强CNN模型的感知能力，从而在不增加网络复杂性的情况下改善模型性能。通道注

意力有助于增强不同通道的特征表示，而空间注意力则有助于提取空间中不同位置的关键信息。




图2 CBAM模型结构

Fig.2 CBAM model structure

如上图，给定中间特征图 F ，其中 H 、 W 、 C 分别代表高度、宽度和维度， F 可以表示为 $F \in R^{C \times H \times W}$ 。对于通道注意力机制：首先， F 进行全局平均池化和全局最大池化操作，计算每个通道的平均值和最大值。其次，分别将输入特征通过多层感知机 (Multilayer Perceptron, MLP) 进行处理。在此过程中，为了减少参数数量，使用衰减率 $r=8$ 降低神经元的数量至 C/r (其中 C 为原始通道数)，激活函数选择 ReLU。最后，通过 Sigmoid 激活函数融合通道权重，得到最终的通道注意力特征图 $M_c(F)$ ，用于加权特征图中的每个通道；对于空间注意力机制： F' 同样进行全局平均池化和全局最大池化操作，将通道维度压缩为 1，并保留空间信息。随后，将这两个特征图进行拼接，并通过一个卷积层提取特征，最终经过 Sigmoid 激活，得到最终的空间注意力 $M_s(F')$ 。

CBAM 依次得到一个一维的通道注意力图 $M_c(F)$ 和一个二维的空间注意力图 $M_s(F')$ ，整个流程可以概括为：

$$F' = M_c(F) \otimes F \quad (5)$$

$$F'' = M_s(F') \otimes F' \quad (6)$$

其中， \otimes 表示对应元素相乘。通过对输入特征图

进行通道和空间的双重注意力加权，CBAM 能够更好地捕获信号中的关键信息，从而提升模型的特征能力和泛化性能。

2.2 GRU 网络结构

门控循环单元 (Gated Cycle Unit, GRU)，是传统 RNN 的变体^[7]，与 LSTM 结构相似，均具有门控机制，用来调节单元内部的信息流动。同时与 LSTM 相比，GRU 没有单独的存储单元，因此其结构和计算更为简洁，提高了运算效率，同时有效降低了训练过程中过拟合的风险。GRU 的核心结构包括更新门 (z_t) 和重置门 (r_t) 两个部分，如图 3 所示。GRU 网络状态更新过程如下：

① 更新门 (Update Gate):




图3 GRU网络结构

Fig.3 GRU network structure

更新门决定了前一时刻的隐藏状态(记忆)有多少需要传递到当前时刻。它的计算公式为:

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (7)$$

其中, x_t 是当前时刻的输入, h_{t-1} 是上一时刻的隐藏状态, W_z 是权重矩阵, σ 是 sigmoid 激活函数。

② 重置门(Reset Gate):

重置门决定了多少前一时刻的隐藏状态需要被重置, 从而计算当前时刻的候选隐藏状态。它的计算公式为:

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (8)$$

其中, W_r 是权重矩阵, 其他符号同上。

③ 候选隐藏状态(Candidate Hidden State):

利用重置门控制的上一时刻的隐藏状态来计算当前时刻的候选隐藏状态。计算公式为:

$$\tilde{h}_t = \tanh(W[h_{t-1} \odot r_t, x_t]) \quad (9)$$

其中, W 是权重矩阵, \odot 表示元素逐位相乘, \tanh 是双曲正切激活函数。

④ 隐藏状态更新:

最终的隐藏状态通过更新门来综合前一时刻的隐藏状态和当前时刻的候选隐藏状态。计算公式为:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (10)$$

其中, $(1 - z_t)$ 和 z_t 控制着保留前一时刻隐藏状态和采用候选隐藏状态的比例。

GRU 通过上述过程有效地控制信息在时间步上的流动, 能够在减少参数的同时保持对序列数据的强大建模能力, 相较于 LSTM 具有更高的计算效率。

2.3 CBAM-GRU 算法模型

用于调制分类的 CBAM-GRU 的模型结构如图 4 所示, 主要由 4 个 CNN 层、2 个 GRU 层、CBAM 层和 2 个全连接层组成。输入信号是由实部和虚部构成的实序列, 即 IQ 数据, 其格式为 $k \times 2$, 经过预处理后, 维度转变为 $k \times 4$ 的矩阵 $\begin{pmatrix} X_i & X_o \\ X_A & X_p \end{pmatrix}$ 。数据首先被输入至 CNN 模块, 该模块的前两层均使用 256 个卷积核, 后两层则使用 80 个卷积核, 所有卷积核的大小均为 3×3 , 激活函数均为 ReLU。提取空间特征信息后, 数据被传递到由 128 个单元组成的双层 GRU 模块。为了防止过拟合, 每个 GRU 层应用 30% 的 Dropout。随后, 使用两个密集全连接层进行进一步处理, 这两个全连接层的神经元数量分别为 128 和 11, 最终的激活函数为 Softmax, 用于多类别分类。损失函数采用分类交叉熵, 表示为:

$$loss = -\frac{1}{n} \sum_i y_i \ln a_i \quad (11)$$

式中, y_i 表示实际标签; a_i 表示预测输出; n 表示样本总数量。

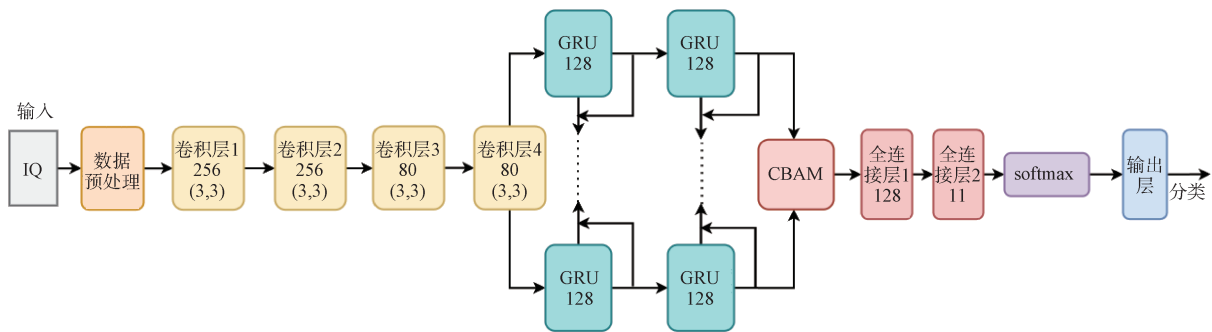


图 4 CBAM-GRU 模型结构
Fig.4 CBAM-GRU model structure

2.4 对比实验模型

在通信调制信号的识别研究中, CNN 的优势在于其能够有效地捕获局部特征, 具有平移不变性, 并且适用于二维数据的处理。LSTM 的优势在于其能够捕捉长期依赖关系, 适用于序列数据的建模和预测, 如自然语言处理任务。GRU 与 LSTM 相似, 但参数更少, 计算效率更高, 适用于需要考虑长期

依赖性的任务。卷积长短期记忆神经网络(Convolutional Long short term Deep Neural Networks, CLDNN)结合了 CNN 和 LSTM 的优点, 既能够提取空间特征, 又能够捕捉时间序列信息, 适用于复杂的音频和语音识别任务。因此, 本文选择了这几种常见的网络模型进行对比实验, 如 CNN^[8]、LSTM^[6]、GRU^[5]、CLDNN^[7]等, 全面评估不同模

型在调制信号识别中的性能。对应的四个模型结构分别如图5(a)、图5(b)、图5(c)、图5(d)所示。

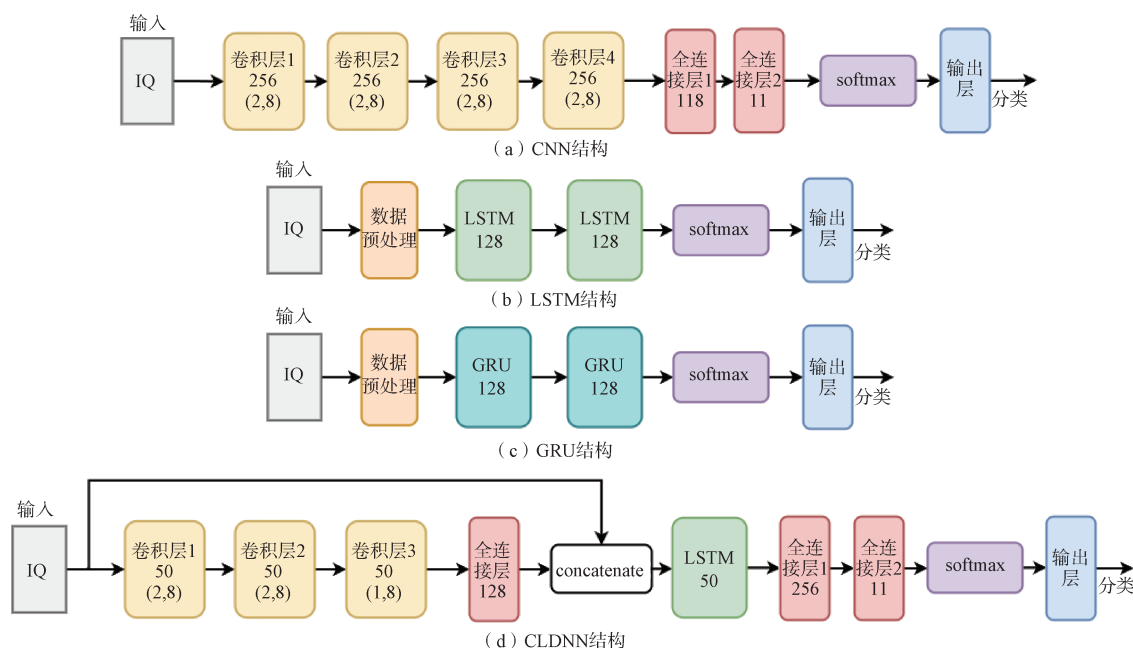


图5 对比实验模型结构

Fig.5 Comparative experimental models structure

3 实验结果与分析

3.1 数据集与实验环境

本文所有实验均使用GNU Radio生成的数据集RadioML2016.10a^[18]。该数据集包含22万个输入样本，每个样本对应特定信噪比(Signal to Noise Ratio, SNR)下的一种调制类型。数据集中包含了各种实际的信道缺陷，如采样率偏移、信道频率偏移、多径衰落和高斯白噪声。该数据集包括11种调制方式，SNR范围为-20 dB~18 dB，步长为2 dB。每个信号样本的长度为128，数据格式为[128, 2]，其中2代表IQ两个通道维度。具体细节如表1所示。

在本文实验中，以6:2:2的比例将数据集划分为训练集、测试集和验证集。

实验环境配置如下：中央处理器(CPU)为Intel (R) Core(TM) i7-14700KF 3.40 GHz，图形处理器(GPU)为NVIDIA GeForce RTX 4080；实验在TensorFlow框架下使用Keras 2.6.0进行开发，编程语言为Python 3.8.18。基于训练结果，设置超参数，并使用Adam优化器，将学习率设定为0.001，批量大小设为256，训练周期设置为100个。

表1 RML2016.10a数据集参数

Table 1 RML2016.10a dataset parameters

数据集	RML2016.10.a
调制类型	数字调制: BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK, PAM4, 模拟调制: WBFM, AM-SSB, AM-DSB
信号格式	同相和正交(IQ)[128, 2]
噪声设置	加性高斯白噪声, 信噪比范围 [-20 dB, -18 dB, ..., 18 dB]
信道环境	选择性衰落(莱斯+瑞利)、中心频率偏移、采样率偏移
总信号样本	220 000

3.2 消融实验分析

为了验证CBAM和GRU对模型性能的影响，本节进行了消融实验。实验分别使用了移除CBAM模块的CNN-GRU模型、移除GRU模块的CNN-CBAM模型以及同时添加了CBAM注意力模块和GRU网络的完整模型CBAM-GRU。表2展示了这三个网络模型在RadioML2016.10a数据集上的识别准确率。

实验结果表明，CBAM-GRU网络在低信噪比条件下的识别率为18.69%，在高信噪比条件下为91.74%，整体识别率为62.03%，显著优于消融

表 2 三种网络实验结果

Table 2 Comparison of the complexities of three types of networks

网络模型	Acc_low	Acc_high	Acc_all
CNN-GRU	17.74%	88.33%	60.95 %
CNN-CBAM	17.92%	88.92%	61.41%
CBAM-GRU	18.69%	91.74%	62.03%

CBAM 模块或消融 GRU 模块的模型。移除 CBAM 模块后, 整体识别率下降了 1.08%; 移除 GRU 模块后, 整体识别率下降了 0.62%。这些结果表明 CBAM 和 GRU 模块对模型性能的显著影响, 且二者结合能够有效提升信号分类的准确性。表 3 展示了三种模型的参数量和浮点计算量。

表 3 三种网络的复杂度对比

Table 3 Comparison of the complexities of three types of networks

网络模型	参数量	FLOPs/M
CNN-GRU	564 907	1 952.36
CNN-CBAM	937 131	2 045.05
CBAM-GRU	492 445	2 142.86

通过对三个模型比较, 可以发现, CNN-CBAM 模型拥有最多的参数, CBAM-GRU 模型则具有最少的参数。尽管 CBAM-GRU 模型参数较少, 但其 FLOPs/M 值却最高, 高达 2 142.86。这表明 CBAM-GRU 模型在相对较少的参数下实现了更高的计算效率, 充分利用了注意力机制和循环神经网络的优点, 既减少了模型复杂度, 又提升了计算效率。

图 6 展示了三种模型在 RadioML2016.10a 数据集上的识别准确率曲线。当信号的信噪比超过 8 dB 时, CBAM-GRU 网络的识别准确率稳定在 92% 以上。

3.3 对比实验分析

使用 CBAM-GRU 网络与如 CNN 网络、LSTM 网络、GRU 网络、CLDNN 网络进行对比实验。表 4 展示出 5 个网络的参数量和识别准确率。

实验结果显示, 文献[7]设计的 CLDNN 网络和文献[8]设计的 CNN 网络对信号的识别准确率明显低于其他网络, 这主要是由于这两个网络的卷积层较浅, 网络结构相对简单, 并且输入数据未进行预处理。相比之下, 文献[5]和文献[6]均将 I/Q 数据进行幅度和相位的转换, 并作为输入数据送入

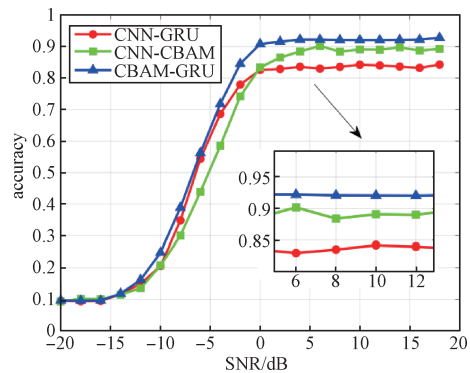


图 6 三种网络的识别曲线

Fig.6 Recognition curves of three types of networks

表 4 对比网络实验结果

Table 4 Compare network experimental results

网络模型	Acc_low	Acc_high	Acc_all	参数量
CNN	15.74%	83.50%	57.30%	858 123
GRU	16.95%	89.62%	60.63%	151 179
LSTM	17.24%	89.76%	60.54%	201 099
CLDNN	17.05%	83.00%	57.05%	164 433
CBAM-GRU	18.69%	91.74%	62.03%	492 445

网络模型, 显著提升了性能。在所有模型中, CBAM-GRU 在通信调制信号识别任务中表现出明显优势, 整体准确率达到 62.03%, 为最高。在高信噪比条件下, 其准确率高达 91.74%, 显著优于其他模型; 在低信噪比条件下, 其准确率也达到 18.69%, 同样表现最佳。尽管 CBAM-GRU 的参数量较大, 但其性能提升明显, 表明适当增加模型复杂度和引入注意力机制能够显著提升识别能力。

图 7 展示了本文算法以及对比模型在不同信噪比下的识别准确率曲线。当信噪比(SNR)高于 -4 dB 时, CBAM-GRU 模型显著优于其他模型。在 4 dB 的信噪比下, CBAM-GRU 的识别率超过 90%; 在 18 dB 时, 其最大识别率达到 92.79%。在 0~18 dB 的范围内, CBAM-GRU 的平均识别率为 91.35%, 相比其他方法提升了 1% 至 6%。随着信噪比增加, 5 种方法的识别性能均逐渐提升, 在 0 dB 时, 五种模型的识别准确率稳定在 80% 左右。CBAM-GRU 算法在高信噪比条件下表现尤为突出, 优于其他模型。

为了深入分析 CBAM-GRU 模型在分类任务中的表现, 图 8、图 9、图 10、图 11 和图 12 展示了五种模型在 6 dB 信噪比下的混淆矩阵。混淆矩阵是评估分类模型性能的重要工具, 每一列代表预测

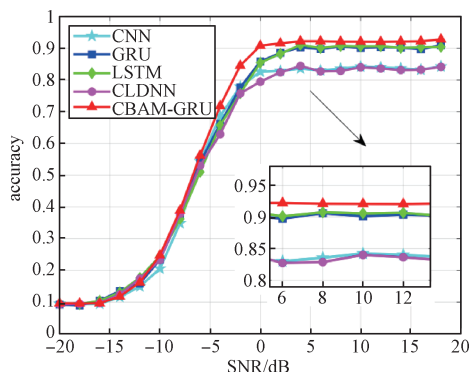


图7 不同模型准确率曲线

Fig.7 Different models' accuracy curves

类别，每一行代表实际类别。它展示了分类模型在每个类别中的正确分类和错误分类数量，帮助更好地理解模型的准确率等指标，从而优化模型性能。

从图8~图12可以看出，CBAM-GRU模型在对角线上的识别精度优于其他模型，且对角线外的杂块较少。相比之下，CLDNN的杂块明显更多，识别能力较低。

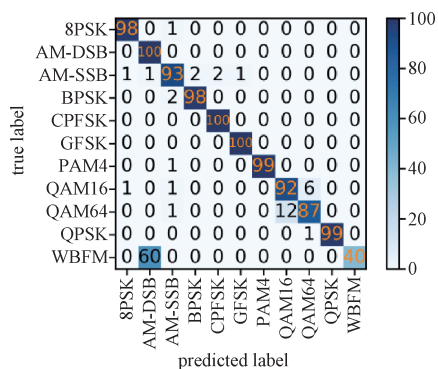


图8 CBAM-GRU 混淆矩阵

Fig.8 Confusion matrix of CBAM-GRU




图9 LSTM 混淆矩阵

Fig.9 Confusion matrix of LSTM




图10 GRU 混淆矩阵

Fig.10 Confusion matrix of GRU

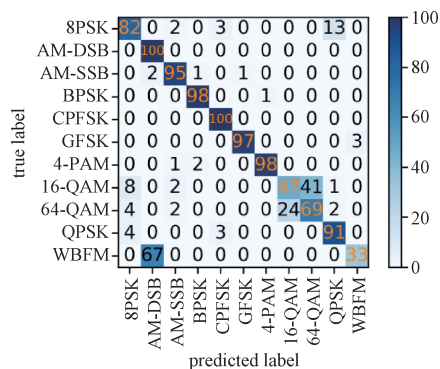


图11 CLDNN 混淆矩阵

Fig.11 Confusion matrix of CLDNN

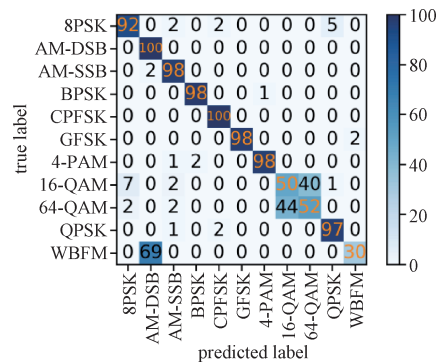


图12 CNN 混淆矩阵

Fig.12 Confusion matrix of CNN

通过对比不同算法在信号识别中的表现，得出以下结论：首先，在高信噪比数据集上训练后，CBAM-GRU模型对64QAM信号的识别率相对较高，而其他四种算法则表现出明显的混淆现象；其次，超过一半的WBFM信号被错误归类为AM-DSB信号。这是因为WBFM和AM-DSB信号都属于连续调制，其在复数平面上的特征相似，导致算法无法准确区分。

CBAM-GRU模型相较于其他对比模型具有显

著优势。这是由于引入了CBAM模块和双向GRU网络, CBAM能够有效学习信号的空间和通道信息, 而GRU结构则能够有效捕获序列数据中的长期依赖关系, 使得模型能够更好地分辨不同调制信号之间的细微差异。此外, CBAM-GRU模型的网络结构经过精心设计和调优, 通过增加适当的复杂度和注意力机制, 提高了模型的泛化能力和识别准确率。尽管参数量较大, 但性能明显提升, 特别是在高信噪比条件下, 其识别准确率显著优于其他模型, 展现了其在复杂信号环境中的卓越能力和鲁棒性。

4 结束语

本文研究了一种结合CBAM和GRU的时域联合AMR模型, 旨在有效识别常见的无线通信调制信号。该模型利用采样数据的幅度和相位信息作为输入, 通过深度学习网络对11种通信信号进行分类。实验结果表明: 相较于传统的CNN、LSTM、GRU和CLDNN等网络模型, 该模型在高信噪比环境下实现了卓越的信号识别性能。

随着电磁环境复杂度的不断增加, 基于深度学习的自动调制识别方法受到了广泛关注。本文使用的数据集是RML 2016.10a, 该数据集在调制类别数量上有所限制。因此, 进一步研究可以考虑采用RML 2018.01a^[9]和HisarMod 2019.1^[8]数据集, 这些数据集涵盖更多类别的信号, 特别设计用于开发相应的联合识别网络。此外, 未来研究中如何运用机器学习技术提升无线通信系统数据处理的安全性, 是一项具有挑战性的课题。

参考文献

- [1] CHEN W, XIE Z, MA L, et al. A faster maximum-likelihood modulation classification in flat fading non Gaussian channels[J]. IEEE Communications Letters, 2019, 23(3): 454-457.
- [2] ZHANG J, WANG F, ZHONG Z, et al. Continuous phase modulation classification via Baum-Welch algorithm[J]. IEEE Communications Letters, 2018, 22(7): 1390-1393.
- [3] XIE X, NI Y, PENG S, et al. Deep learning based automatic modulation classification for varying SNR environment[C]//Proceedings of the 2019 28th Wireless and Optical Communications Conference (WOCC). 2019: 1-5.
- [4] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]// Proceedings IEEE Int. Conf. Eng. Appl. Neural Netw., 2016: 213-226.
- [5] HONG D, ZHANG Z, XU X. Automatic modulation classification using recurrent neural networks[C]//2017 3rd IEEE International Conference on Computer and Communications (ICCC). 2017: 695-700.
- [6] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[C]// IEEE Transactions on Cognitive Communications and Networking. 2018, (4)3: 433-445.
- [7] WEST N E, SHEA T O. Deep architectures for modulation recognition[C]//2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). 2017: 1-6.
- [8] TEKBYK K, EKTI A R, GÖRÇİN A, et al. Robust and fast automatic modulation classification with CNN under multipath fading channels[C]//2020 IEEE 91st Vehicular Technology Conference(VTC2020-Spring). 2020: 1-6.
- [9] 葛战, 孙磊, 李兵, 等. 数据驱动的双通道CNN-LSTM调制分类算法[J]. 无线电工程, 2023, 53(1): 73-79.
- [10] 向建, 高勇. 基于GRU-CNN并联神经网络的自动调制识别[J]. 电讯技术, 2021, 61(11): 1339-1343.
XIANG Jian, GAO Yong. Automatic modulation recognition based on GRU-CNN parallel neural network[J]. 2021, 61(11): 1339-1343.
- [11] ZHANG Z, LUO H, WANG C, et al. Automatic modulation classification using CNN-LSTM based dual-stream structure[J]. IEEE Transactions on Vehicular Technology, 2020, 69(11): 13521-13531.
- [12] 付国栋, 黄进, 杨涛, 等. 改进CBAM的轻量级注意力模型[J]. 计算机工程与应用, 2021, 57(20): 150-156.
FU Guodong, HUANG Jin, YANG Tao, et al. Improved lightweight attention model based on CBAM[J]. Computer Engineering and Applications, 2021, 57(20): 150-156.
- [13] 高振斌, 张毅, 宿绍莹. 基于CBAM-CNN-BiGR的Morse信号智能识别译码算法研究[J]. 无线电工程, 2022, 52(9): 1519-1524.
- [14] ZHOU C, SHI F, LIU Q. Research on parameters estima-

- tion and suppression for C&I jamming[C]// Proceedings of the 2016 CIE International Conference on Radar (RADAR). 2016: 1-4.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//ECCV 2018, Lecture Notes in Computer Science, 2018: 11211.
- [16] 石磊, 王毅, 成颖, 等. 自然语言处理中的注意力机制研究综述[J]. 数据分析与知识发现, 2020, 4(5): 1-14.
SHI Lei, WANG Yi, CHENG Ying, et al. Review of attention mechanism in natural language[J]. Data Analysis and Knowledge Discovery, 2020, 4(5): 1-14.
- [17] 陈榕, 任崇广, 王智远, 等. 基于注意力机制的CRNN文本分类算法[J]. 计算机工程与设计, 2019, 40(11): 3151-3157.
- [18] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[C]//Proceedings of the GNU Radio Conference. 2016: 1358-1365.
- [19] 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.

[作者简介]

- 杨宵 1999年生, 硕士, 研究员。
姚爱琴 1969年生, 副教授, 研究生导师。
孙运强 1963年生, 教授, 博士生导师。
石喜玲 1980年生, 副教授, 研究生导师。
张婉婷 1999年生, 硕士, 研究员。

(本文编辑: 杨秀丽)

(英文编辑: 赵尹默)