

文章编号: 2095-4980(2022)12-1311-07

基于 Transformer 的通信信号调制识别方法

李振星, 赵晓蕾*, 刘伟承, 王 杰

(中国电波传播研究所, 山东 青岛 266107)

摘 要: 提出一种基于 Transformer 模型的通信信号调制识别方法: 在数据准备阶段, 构建一个不同符号速率调制识别(DSRMR)数据集; 在数据预处理阶段, 提出 I/Q 数据增强方法, 用于满足模型训练在数量上和多样性的要求, 增强了模型泛化能力; 在模型构建阶段, 将切片序列化的方法引入调制识别 Transformer 模型中, 用于优化 Transformer 神经网络模型的输入问题。实验结果证明, 基于 Transformer 模型的通信信号调制识别方法能够获得较高的信号自动调制识别准确率。

关键词: 调制识别; 数据增强; Transformer 模型

中图分类号: TN911.234

文献标志码: A

doi: 10.11805/TKYDA2021392

A modulation recognition method of communication signal based on Transformer

LI Zhenxing, ZHAO Xiaolei*, LIU Weicheng, WANG Jie

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

Abstract: A communication signal modulation recognition method based on Transformer model is proposed. In the data preparation stage, a Different Symbol Rate Modulation Recognition(DSRMR) data set is constructed. In the data preprocessing stage, a method of I/Q data enhancement is proposed to meet the quantitative and diverse requirements of model training, and to enhance the generalization ability of the model. In the model construction stage, the method of slice serialization is introduced into the modulation recognition Transformer model, and it is employed to optimize the input problem of the Transformer neural network model. Experimental results prove that the communication signal modulation recognition method based on the Transformer model can obtain high-precision in signal automatic modulation recognition.

Keywords: modulation recognition; data enhancement; Transformer model

伴随着物联网技术、移动通信 5G 技术和数据超高速传输技术的迅猛发展, 如何精准高效地进行电磁频谱管理正遭受着严峻的挑战。在电磁频谱管理领域中, 一个至关重要的环节就是通信信号调制识别。通信信号调制识别技术经过很长一段时间的快速发展之后, 在理论方面已具有一定的完整性, 但面对现实的工程应用, 仍存在需要改进的方面^[1-2]。

自 20 世纪以来, 通信信号识别领域研究出现了一系列的调制识别算法, 大体划分为基于判决理论的调制识别算法、基于统计模式特征提取的调制识别算法和基于深度学习的调制识别算法^[3-4]。基于判决理论调制识别算法依赖于最大似然假设检验条件, 然而在非合作通信中, 很难精确估计调制信号的信道状态、采样率、均值、方差、协方差等诸多先验信息。基于统计模式特征提取的调制识别算法依赖于样本的统计属性特征, 一定程度上能够抑制噪声的干扰, 但信道衰落干扰对识别精确度影响很大, 低信噪比下信号识别率效果并不理想^[5-6]。

随着深度学习在自然语言处理、计算机视觉等领域取得显著成果^[7-8], 众多的研究者投身于基于深度学习调制识别算法中^[9-17]。文献[14]中, O'Shea 等使用开源无线电软件(GNU Radio)生成用于信号调制识别的公开数据集^[14], 该数据包括不同信噪比下 11 种调制信号, 可作为基于深度学习调制识别算法领域内的可靠基准。文献[15]中, Zhang 等使用二维 I/Q 数据结合提取的四阶累积量特征作为卷积神经网络输入, 调整神经网络不同的深

收稿日期: 2021-10-27; 修回日期: 2021-12-26

*通信作者: 赵晓蕾 email:zhaoxiaoleiqz@126.com

度、卷积核大小,取得了理想的识别精确度。文献[16]中,Zeng等采用时频变换对I/Q信号进行预处理,然后输入到设计的卷积神经网络中,验证了时频图包含丰富的信号特征。文献[17]中,将稀疏Transformer模型与卷积神经网络相结合,使原始基带I/Q样本对于某些信道效应保持不变,在低符号速率下,取得良好的识别效果。基于上述研究成果,本文提出一种基于Transformer的通信信号调制识别模型。

1 DSRMR数据集构建及预处理

1.1 通信信号模型

在无线通信中,假定基带信号 $S_b(t) = \text{Re}\{S_b(t)\} + j\text{Im}\{S_b(t)\}$ 以及载波频率 f_c ,则发射端信号为基带信号与载波频率的调制信号:

$$s(t) = \text{Re}\{S_b(t)e^{j2\pi f_c t}\} = \text{Re}\{S_b(t)\} \cos 2\pi f_c t - \text{Im}\{S_b(t)\} \sin 2\pi f_c t \quad (1)$$

到达接收端的信号 $r(t)$ 为通信信道和加性噪声的干扰,其表达式为:

$$r(t) = s(t) * h(t) + n(t) \quad (2)$$

式中: $h(t)$ 为信道衰落的影响; $n(t)$ 为加性噪声。

目前通信信号接收的大部分为I/Q信号数据,I/Q分量的计算如下:

$$I = A(t) \cos \phi(t) \quad (3)$$

$$Q = A(t) \sin \phi(t) \quad (4)$$

式中: $A(t)$ 为 $r(t)$ 的瞬时幅度值; $\phi(t)$ 为 $r(t)$ 的瞬时相位值。

1.2 DSRMR数据集构建

文献[14]中,作者构建了RadioML2016.10A数据集,其中包含:3种模拟调制方式:AM-DSB(Amplitude Modulation-Double Sideband),AM-SSB(Amplitude Modulation-Single Sideband),WBFM(Wideband Frequency Modulation);8种数字调制方式:相移键控8PSK(Phase-Shift Keying)、二进制相移键控(Binary Phase-Shift Keying, BPSK)、连续相位频移键控(Continuous Phase Frequency-Shift Keying, CPFSK)、高斯频移键控(Gaussian Frequency-Shift Keying, GFSK)、四电平脉冲幅度调制(Pulse Amplitude Modulation, PAM4)、正交幅度调制16QAM,64QAM(Quadrature Amplitude Modulation)、正交相移键控(Quadrature Phase-Shift Keying, QPSK)。采样率为200 kHz;每个符号8个采样点;信噪比范围为-20~18 dB,间隔为2 dB;每段采样点数为128;I/Q数据构成 2×18 的矩阵;每种调制在每一个信噪比下数据量为1 000条。在信噪比 $R_{SN}=18$ dB时,每种调制信号时域图(left)和星座图(right)如图1所示。

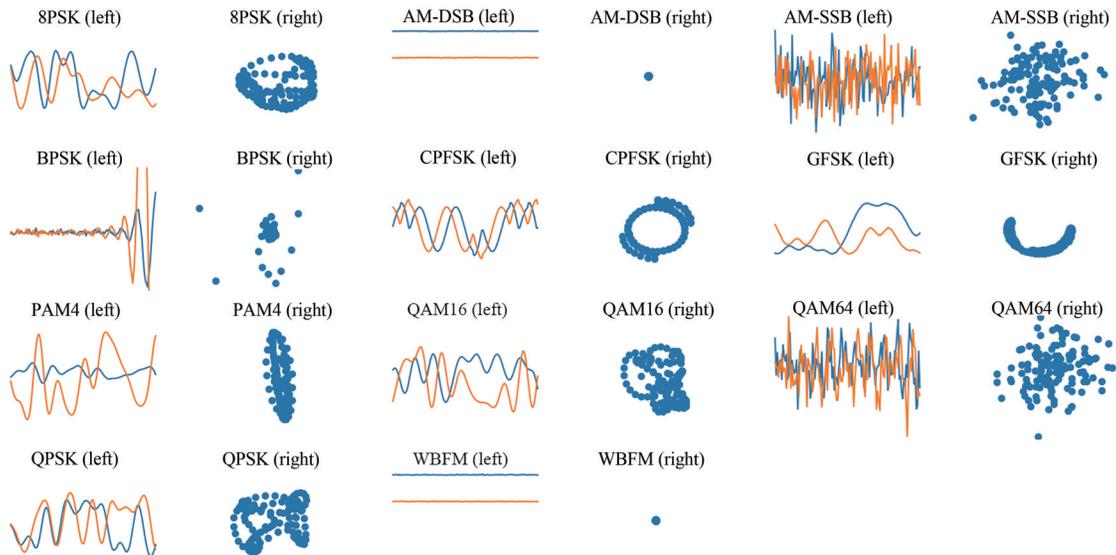


Fig.1 Time domain distribution (left) and constellation (right) of different modulated signals

图1 不同调制信号时域分布图(left)和星座图(right)

本文参考文献[14]中数据集构建方法，利用 GNU Radio 软件仿真平台构建不同符号速率下的 I/Q 数据集。加入信道干扰、采样频率偏移、中心频率偏移、多径衰落和加性噪声多种干扰因素。自建 DSRMR 数据集包含 FM 和 AM 2 种模拟调制方式；13 种数字调制方式：8PSK, BPSK, MSK, 2FSK, 4FSK, 8QAM, 16QAM, 32QAM, 64QAM, 128QAM, QPSK, OQPSK 和 pi/4QPSK；符号采样点数在 2~8 之间。每段采样点数为 1 024，IQ 数据构成 2×1 024 的矩阵；每种调制在每一个信噪比下数据量为 20 000 条。

1.3 数据增强

Transformer 神经网络模型之所以具有强大的表达能力，其中一个极其重要的因素就是海量多样数据的支撑。实际应用中，并非所有数据集都满足数量上和多样性的要求。因此，有效的数据增强不仅可以增加数据集样本的数量，而且可以增加数据集样本的多样性，一方面可以有效提升 Transformer 神经网络模型的性能，另一方面可以有效避免模型训练过程中的过拟合现象。鉴此，本文设计了如下增强方法：时域信号随机局部放大、通信信号线性升降采样、随机平移和通信信号随机擦除。

1.4 数据归一化

参考文献[18]，对数据进行归一化处理：

$$ac(n) = a(n) - E(a(n)) \tag{5}$$

$$an(n) = ac(n) / \text{Max}(\text{abs}(ac(n))) \tag{6}$$

式中： $a(n)$ 表示 I/Q 数据序列； $E(*)$ 为求均值。

当相位值超越 $[0, 2\pi]$ ，如果按照 2π 范围计算相位序列 $\{\phi_i\}$ ，则会产生相位卷叠现象。因此本文以相位的相对位置为准，将相位值归一化到 $[-\pi, \pi]$ 。

本文利用 I/Q 数据、幅值和相位数据构建特征矩阵作为神经网络模型输入，其幅值 A 和相位计算如下：

$$A = \sqrt{I^2 + Q^2} ; \phi = \arctan(Q/I) \tag{7}$$

2 信号调制识别算法设计

2.1 Transformer 模型

经典 Transformer 模型包括编码器和解码器，编码器将输入的字符序列编码为连续的特征，解码器将连续的特征恢复为字符序列^[19]。如图 2 所示，编码器本质上由多层 Transformer 基础层堆叠排列而成，每一个基础层由 2 个子层组成，分别为多头自注意力(Multiheaded Self-Attention, MSA)机制层模块和多层感知器(Multi-Layer Perceptron, MLP)模块。MSA 和 MLP 模块分别将模块输入与模块输出相连接构建残差结构，用于增加模型基础层数量，提高表达能力和泛化性能，减少特征损失^[20]。该基础层计算公式为：

$$z'_l = \text{MSA}[LN(z_{l-1})] + z_{l-1}, \quad l = 1, 2, \dots, L \tag{8}$$

$$z_l = \text{MLP}[LN(z'_l)] + z'_l, \quad l = 1, 2, \dots, L \tag{9}$$

$$y = LN(z_l^0) \tag{10}$$

式中： z_{l-1} 为 MSA 模块输入； $LN()$ 表示层归一化； z'_l 为 MSA 模块残差结构输出和 MLP 模块输入； z_l 为 MSA 模块残差结构输出； z_l^0 为整个 Transformer 编码器的输出； L 为编码器层数。

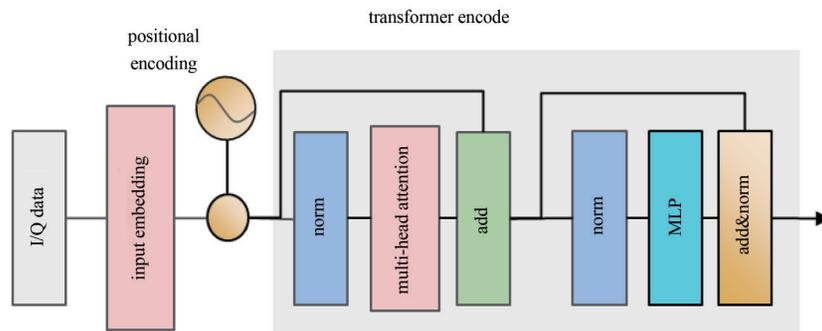


Fig.2 Structural diagram of Transformer model encoder
图 2 Transformer 模型编码器结构示意图

作为 MSA 模块的核心, 多头自注意力机制主要包含查询(Query, Q)、键(Key, K)和值(Value, V)。其中查询(Q)和一组键-值对(K-V)进行相乘后加权求和, 之后分配给每个值的权重由键-值查询计算得到。多头注意力机制模型在不同位置共同关注来自不同子空间的信息。多头自注意力机制的计算过程如下^[21]:

$$\text{MSA}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W^0 \quad (11)$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (12)$$

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (13)$$

式中: $W_i^Q \in \mathbf{R}^{d_{\text{model}} \times d_k}$; $W_i^K \in \mathbf{R}^{d_{\text{model}} \times d_k}$; $W_i^V \in \mathbf{R}^{d_{\text{model}} \times d_k}$; $W^0 \in \mathbf{R}^{d_{\text{model}} \times d_k}$; d_k 表示 query 的维度; h 表示多头的个数; Concat 函数表示将多头注意力机制计算结果连接为一个矩阵; softmax 函数计算值的权重。本文基于 I/Q 数据序列分类需求, 将 Transformer 模型编码器与分类层连接, 实现对调制样式分类。

2.2 基于 Transformer 模型的调制识别算法

由于 I/Q 数据序列具有一定的长度, 对 I/Q 序列按照时间维度做词嵌入编码时, 常常导致 Transformer 模型的输入层维度变大, 模型规模变大, 需要大量的显存, 且训练速度较慢。当 I/Q 数据序列较长时, 只能截取一部分数据进行编码输入至模型中。当 I/Q 数据每个符号采样点数较高时, 时间维度受限制的 I/Q 数据只包含很少符号数, 使分类准确率下降, 尤其在对 16QAM, 64QAM, QPSK 等调制分类时, 符号之间相似度较高, 分类效果不理想。综上, 本文引入文献[22]中的切片方法将 I/Q 数据切分为固定大小的数据块序列, 对于长度为 $[2, N]$ 的 I/Q 数据, 切分为大小为 $x_p \in \mathbf{R}^{M \times (2 \times W)}$ 的数据块序列, 其中 N 表示 I/Q 数据的长度, $(2 \times W)$ 表示数据块的大小, M 表示数据块的个数。Transformer 模型内部设计一个 D 维的固定尺寸向量, 因此将切片数据块通过线性映射转化为 D 维度的矩阵。

Transformer 编码器的输出表示不同调制 I/Q 数据的特征 y , 如式(11)所示。当加载预训练模型微调参数时, 将 MLP Head 分类头连接至 Transformer 编码器的输出。分类头由增加 Dropout 的两层全连接层构成。

利用一个可学习的一维向量作为位置编码, 添加到数据块映射后的矩阵中, 以保持数据块的位置信息。图 3 为基于 Transformer 的调制识别模型。

3 实验结果与分析

为了测试算法性能, 本文使用自建 DSRMR 数据集和 RadioML2016.10A 数据集。所有数据中 70% 作为训练集, 30% 作为测试集。实验环境包括: Intel(R) Core(TM) i9-7900 CPU、2 张 GeForce RTX 2080 Ti 显卡和 Ubn16.04 操作系统。选用改进 CNN^[23]、ResNet^[24]、CLDNN^[24]和 CNN-TF^[25]4 种算法进行对比实验。Transformer 模型参数选择数据块大小为 (4, 8); 模型层数为 16; 多头自注意力机制中 $head=12$, MLP 层大小为 3 072; 优化器选择 Adam, 其参数 $\beta_1=0.9, \beta_2=0.999, \text{weight decay}=0.01$; 训练批次大小为 128, 设 epoch=20, 训练集遍历 20 次; 学习率变化趋势采用余弦衰减策略, 初始学习率为 0.000 1, 峰值学习率为 0.001, 最终学习率为 0.000 01; 损失函数选用交叉熵。

图 4 为 Transformer 模型调制识别算法在 RadioML2016.10A 数据集上训练过程损失值变化曲线图。图 5 为本文模

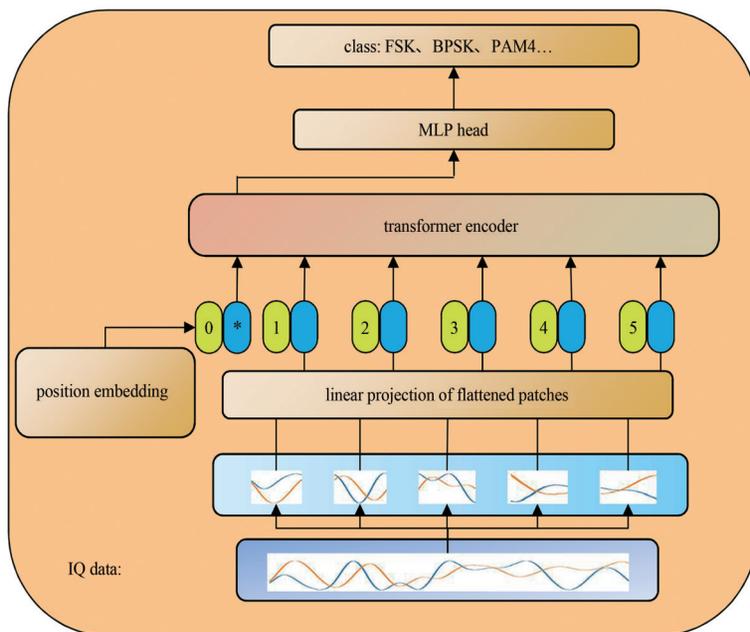


Fig.3 Modulation recognition model based on Transformer
图3 基于 Transformer 的调制识别模型

型在信噪比 $R_{SN}=14$ dB 时 11 种调制识别的自相关矩阵，各调制平均识别率为 93.27%。表 1 为不同信噪比下各种调制方式的识别率。从表 1 中可以看出，随着信噪比的不断增加，各调制识别率也在增加；当信噪比大于 0 时，平均识别率为 91.67%。

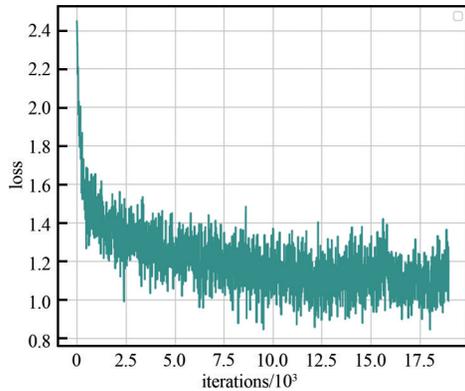


Fig.4 Training loss curve of Transformer model
图4 Transformer模型训练损失变化曲线

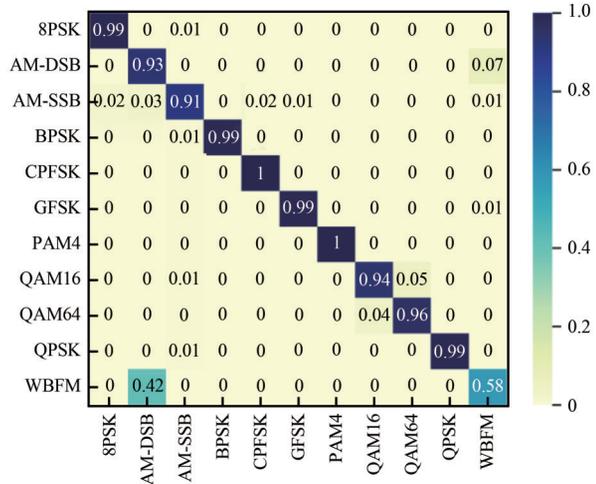


Fig.5 Recognition rate confusion matrix of this mode at 14 dB
图5 本文模型在 14 dB 下识别率混淆矩阵

表 1 不同信噪比下各调制识别率

Table1 Recognition rate of each modulation under different SNRs

R_{SN}/dB	8PSK	AM-DSB	AM-SSB	BPSK	CPFSK	GFSK	PAM4	16QAM	64QAM	QPSK	WBFM
-6	0.210 0	0.633 0	0.900	0.393 0	0.456	0.567 0	0.806	0.413 0	0.780	0.106 0	0.216 0
-4	0.343 0	0.776 0	0.896	0.723 0	0.653	0.816 0	0.980	0.660 0	0.880	0.186 0	0.270 0
-2	0.570 0	0.823 0	0.920	0.926 0	0.820	0.930 0	0.986	0.760 0	0.930	0.613 0	0.306 0
0	0.770 0	0.906 0	0.916	0.966 0	0.970	0.963 0	0.983	0.873 0	0.940	0.910 0	0.343 0
2	0.960 0	0.930 0	0.896	0.970 0	0.990	0.956 0	0.983	0.910 0	0.950	0.986 0	0.406 0
4	0.983 0	0.916 0	0.893	0.990 0	0.990	0.976 6	0.980	0.956 0	0.950	0.990 0	0.443 0
6	0.983 0	0.926 0	0.913	0.993 0	1.000	0.963 0	0.986	0.936 0	0.953	0.986 0	0.413 0
8	0.980 0	0.933 3	0.893	0.980 0	1.000	0.993 0	0.983	0.933 0	0.956	0.983 0	0.446 0
10	0.990 0	0.933 0	0.890	0.993 3	1.000	0.983 0	0.986	0.956 0	0.956	0.993 0	0.483 3
12	0.993 0	0.946 0	0.903	0.993 0	1.000	0.993 0	0.990	0.933 3	0.923	0.996 0	0.580 0
14	0.986 0	0.930 0	0.906	0.993 0	1.000	0.990 0	0.996	0.936 0	0.956	0.986 0	0.576 0
16	0.993 3	0.900 0	0.920	0.993 3	1.000	0.996 0	0.996	0.933 0	0.936	0.983 3	0.596 0
18	0.983 0	0.810 0	0.890	0.993 0	1.000	1.000 0	0.997	0.916 0	0.936	0.983 0	0.670 0

图 6 为不同信噪比下，5 种识别算法在 RadioML2016.10A 数据集上的识别率。从图中能够看出，信噪比 $R_{SN} < -2$ dB 时，本文算法识别率低于其他 4 种参考文献的方法。主要原因是信噪比过低时，噪声对调制识别干扰非常严重。信噪比 $R_{SN} > -2$ dB 时，本文算法识别率开始领先参考文献的方法，平均识别率提升 8.33%；特别地，信噪比 R_{SN} 16 dB 时，识别率提升达到 10%。

图 7(b) 为本文算法在 DSRMR 数据集上的调制识别准确率。从图中可以看出，本文模型优于参考文献[26]模型(图 7(a))的识别准确率，在 PI4QPSK, OQPSK 和 8PSK 略微低于参考文献[26]模型；但在 16QAM, 32QAM, 64QAM, 128QAM 调制下识别率显著优于参考文献[26]模型，充分证明本文算法的有效性。

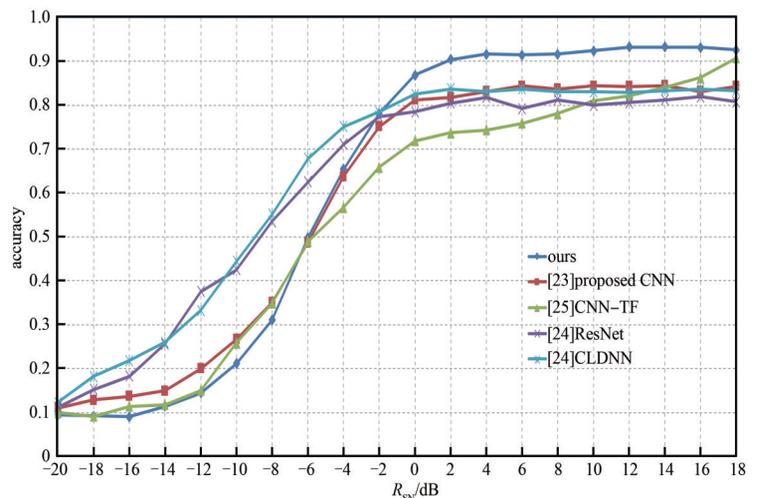


Fig.6 Recognition rate of each model under different SNRs

图6 不同信噪比下各模型识别率

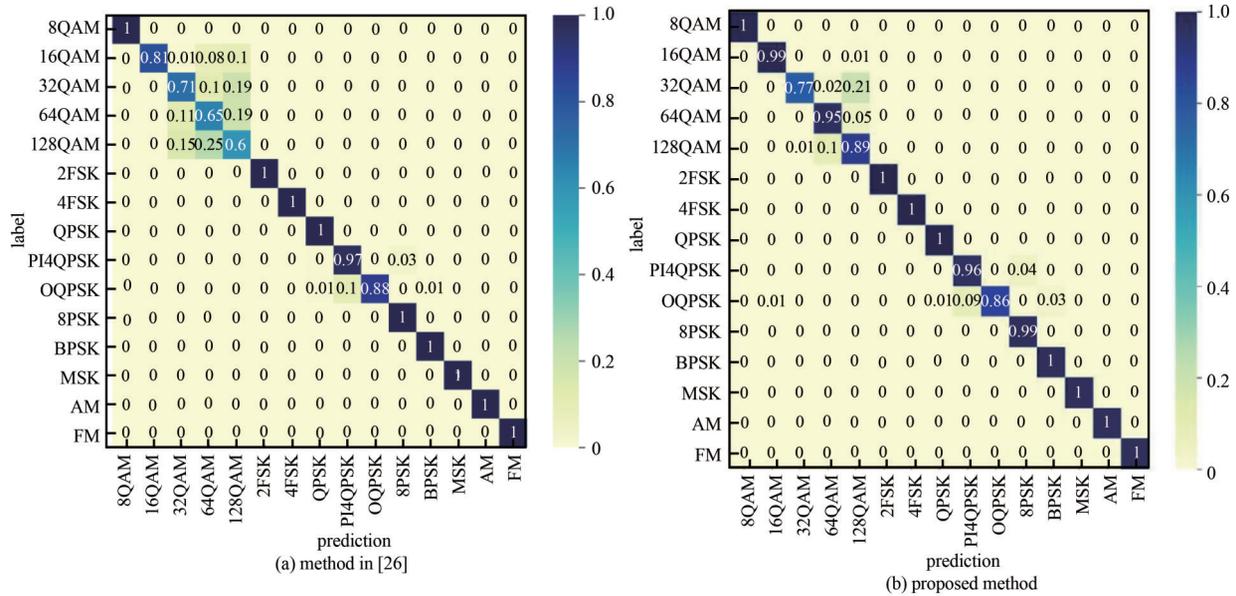


Fig.7 Recognition rate confusion matrix under DSRMR dataset
图7 在DSRMR数据集下识别率混淆矩阵

4 结论

本文研究了一种基于Transformer模型的信号调制识别算法。将本文提出的Transformer模型与现有文献中模型进行对比,结果表明,在信噪比 $R_{SN} > -2$ dB时,平均识别率达到了91.67%,相对于现有文献中的模型,平均识别率提升了8.3%。虽然本文算法在RadioML2016.10A数据集和自建的DSRMR数据集上取得了满意的识别率,但仍有许多需要完善的空间,如:在非合作通信模式下,能够采集到信号样本数量会受到极大限制,有监督的深度学习方法受到信号数据量的限制,易过拟合,因此研究在小样本场景下信号调制识别的意义重大。在频谱管理领域,对通信信号识别提出了更高的要求,对信号协议层识别的需求越来越迫切。在以后的研究中,将进一步探索如何解决上述问题,继续提高信号识别性能,为频谱管理业务提供更精确的信号识别方法。

参考文献:

- [1] 鲍庆龙,王森,潘嘉蒙,等. 非合作雷达辐射源目标探测系统关键技术分析[J]. 电波科学学报, 2020,35(4):496-503. (BAO Qinglong, WANG Sen, PAN Jiameng, et al. Key technology analysis of target detection system based on non-cooperative radar illuminator[J]. Chinese Journal of Radio Science, 2020,35(4):496-503.)
- [2] 黄宇涛,普运伟,吴海潇,等. 基于栈式自编码器和模糊函数主脊的雷达辐射源信号识别[J]. 电波科学学报, 2020,35(5):689-698. (HUANG Yutao, PU Yunwei, WU Haixiao, et al. Radar emitter signal recognition based on stacked auto-encoder and ambiguity function main ridge[J]. Chinese Journal of Radio Science, 2020,35(5):689-698.)
- [3] HUAN C Y, POLYDOROS A. Likelihood methods for MPSK modulation classification[J]. IEEE Transactions on Communications, 1995,43(2-4):1493-1504.
- [4] FREUND Y, SCHAPIRE R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997,55(1):119-139.
- [5] 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 Xiongwen, GUO Chunxia, LI Jingchun. 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.)
- [6] WANG L, GUO S, JIA C. Recognition of digital modulation signals based on wavelet amplitude difference[C]// IEEE International Conference on Software Engineering & Service Science. Beijing:IEEE, 2017:627-630.
- [7] ZHOU S, DONG L, XU S, et al. Syllable-based sequence-to-sequence speech recognition with the transformer in mandarin Chinese[C]// International Conference on Neural Information Processing. 2018:210-220.
- [8] SHI X, HUANG H, JIAN P, et al. Case-sensitive neural machine translation[C]// Pacific-Asia Conference on knowledge discovery and data mining. Singapore:Springer, 2020:662-674.

- [9] 张思成,林云,涂涯,等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. 通信学报, 2020,41(11):12–21. (ZHANG Sicheng, LIN Yun, TU Ya, et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network[J]. Journal of Communications, 2020,41(11):12–21.)
- [10] WANG M, LIN Y, TIAN Q, et al. Transfer learning promotes 6G wireless communications: recent advances and future challenges[J]. IEEE Transactions on Reliability, 2021,70(2):790–807.
- [11] LIN Y, TU Y, DOU Z, et al. Contour stella image and deep learning for signal recognition in the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2020,7(1):34–46.
- [12] LIN Y, TU Y, DOU Z. An improved neural network pruning technology for automatic modulation classification in edge devices[J]. IEEE Transactions on Vehicular Technology, 2020,69(5):5703–5706.
- [13] TU Y, LIN Y, HOU C, et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020,69(9):10085–10089.
- [14] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[C]// Proceedings of the GNU Radio Conference. Boulder, CO: [s.n.], 2016:11–16.
- [15] ZHANG M, ZENG Y, HAN Z, et al. Automatic modulation recognition using deep learning architectures[C]// 2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Kalamata, Greece: IEEE, 2018: 1–5.
- [16] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2019,8(3):929–932.
- [17] MIRMOHAMMADSADEGHI M, HANNA S S, CABRIC D. Modulation classification using convolutional neural networks and spatial transformer networks[C]// 2017 51st Asilomar Conference on Signals, Systems, and Computers. Pacific Grove, CA, USA: IEEE, 2017:936–939.
- [18] 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.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017(30):6000–6015.
- [20] HE K M, ZHANG X Y, REN A Q, et al. Deep residual learning for image recognition[C]// The IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016:770–778.
- [21] 邱大伟, 刘子辰, 周一青, 等. 基于 Transformer 神经网络的滚动轴承故障类型识别[J]. 高技术通信, 2021,31(1):1–11. (QIU Dawei, LIU Zichen, ZHOU Yiqing, et al. A novel fault type detection method of rolling bearing using transformer neural networks[J]. Chinese High Technology Letters, 2021,31(1):1–11.)
- [22] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: transformers for image recognition at scale[J/OL]. arXiv.org, 2021.
- [23] WEST N E, O'SHEA T. Deep architectures for modulation recognition[C]// 2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Baltimore, USA: IEEE, 2017:1–6.
- [24] 余文星. 基于深度学习的数字信号自动调制识别方法研究[D]. 西安:西安电子科技大学, 2019. (YU Wenxing. Research on digital signal automatic modulation recognition method based on deep learning[D]. Xi'an, Shaanxi, China: Xidian University, 2019.)
- [25] 石彦坤. 基于深度学习的信号调制识别研究[D]. 哈尔滨:哈尔滨工业大学, 2020. (SHI Yankun. Research on signal modulation recognition based on deep learning[D]. Harbin, Heilongjiang, China: Harbin Institute of Technology, 2020.)
- [26] SHANG X, HU H, LI X, et al. Dive into deep learning based automatic modulation classification: a disentangled approach[J]. IEEE Access, 2020(8):113271–113284.

作者简介:

李振星(1985–), 男, 硕士, 高级工程师, 主要研究方向为电磁环境大数据、电磁频谱管理. email: lizx@crip.ac.cn.

刘伟承(1988–), 男, 学士, 助理工程师, 主要研究方向为信号处理、机器学习.

赵晓蕾(1992–), 男, 硕士, 工程师, 主要研究方向为智能信号处理、深度学习.

王杰(1990–), 女, 硕士, 工程师, 主要研究方向为智能信号处理、深度学习.