

基于相位变换和 GhostNet-门控循环单元的 自动调制识别方法

陈 昊, 郭文普*, 康 凯
(火箭军工程大学, 陕西 西安 710025)

摘 要: 针对信号调制方式低信噪比条件下识别准确率不高的问题, 提出了一种由相位变换、GhostNet、压缩与激励网络 (Squeeze and Excitation Network, SENet)、门控循环单元 (Gated Recurrent Unit, GRU) 和深度神经网络组成的模型, 用于自动调制识别接收信号。首先, 采用基准数据集 RML2016.10a 和 RML2016.10b 同相正交数据作为模型输入; 其次, 构建识别模型, 其中, 相位变换用于降低相位偏移对调制识别的影响, GhostNet 和 GRU 分别用于提取调制信号的空间特征和时间特征, SENet 用于对特征图权重进行调整; 而后, 通过深度神经网络进行分类; 最后, 对所提模型进行了训练及测试。实验结果表明: 与现有模型 CGDNet、CLDNN、IC-AMCNet、MCLDNN 和 LSTM 相比, 所提出模型显著降低了参数量, 有效提升了低信噪比条件下的识别准确率, 平均识别准确率分别达到 62.30% 和 64.45%。

关键词: 自动调制识别; 深度学习; 相位变换; GhostNet; 门控循环单元

中图分类号: TN911.3

文献标志码: A

文章编号: 2097-2741(2024)04-086-007

Automatic Modulation Recognition Method Based on Phase Transformation and GhostNet-GRU

CHEN Hao, GUO Wenpu*, KANG Kai

(Rocket Force University of Engineering, Xi'an 710025, Shaanxi)

ABSTRACT: To address the problem of low recognition accuracy under low signal-to-noise ratio (SNR), a model consisting of phase transformation, GhostNet, Squeeze and Excitation network (SENet), gated recurrent unit (GRU), and deep neural network was proposed, by which received modulated signals could be automatically recognized. Firstly, the benchmark datasets RML2016.10a and RML2016.10b, as well as in-phase quadrature (I/Q) data were used as input for the model. Secondly, a recognition model was constructed, where phase transformation was used to reduce the impact of phase shift on modulation recognition, GhostNet and GRU were used to extract spatial and temporal features of modulation signals and SENet was used to adjust weights of feature maps. Then, deep neural networks were used to classify the processed signal. Finally, the proposed model was trained and tested. Experimental results showed that compared

收稿日期: 2024-04-30

第一作者: 陈昊 (1997—), 男, 硕士研究生, 主要从事通信信号调制识别研究。E-mail: 1337109163@qq.com

***通信作者:** 郭文普 (1976—), 男, 副教授, 主要从事通信网络安全和通信系统运用研究。E-mail: gwp_403@163.com

引用格式: 陈昊, 郭文普, 康凯, 等. 基于相位变换和 GhostNet-门控循环单元的自动调制识别方法[J]. 火箭军工程大学学报, 2024, 38 (4): 86-92.

with existing models CGDNet, CLDNN, IC-AMCNet, MCLDNN and LSTM, the proposed model significantly reduces the number of parameters and effectively improves the recognition accuracy under low SNR, with average recognition accuracies of 62.30% and 64.45%, respectively.

KEYWORDS: automatic modulation recognition; deep learning; phase transformation; GhostNet; gate recurrent unit

自动调制识别 (Automatic Modulation Recognition, AMR) 可用于在非合作场景下识别接收信号的调制样式。作为信号检测和解调的关键环节, AMR 在多个领域得到了广泛应用^[1], 如频谱检测、频谱感知、认知无线电等^[2]。相比传统的基于最大似然的方法和基于特征的方法, 基于深度学习 (Deep Learning, DL) 的自动调制识别方法在识别精度和计算复杂度方面更具优势。

文献[3]首次利用卷积神经网络进行调制识别, 相较于基于专家特征的分类器性能更好。文献[4]借鉴残差网络 (Residual Networks, ResNet) 和密集连接网络 (Densely Connected Networks, DenseNet) 在图像分类领域的良好性能, 建立了对应的调制识别模型, 通过残差连接来加强层与层之间的特征传播, 并同时引入了一种卷积长短期深度神经网络 (Convolutional Long Short-term Deep Neural Network, CLDNN) 模型。上述网络模型都是将原始同相正交 (In-phase Quadrature, I/Q) 数据作为输入, 从而无法有效利用相关专家特征, 如高阶累积量、频谱图、星座图等。针对此问题, 文献[5]利用短时离散傅里叶变换将一维无线电信号转换为频谱图像, 并使用高斯滤波器来减弱噪声影响。文献[6]将无线电信号转化为星座图, 利用卷积神经网络的图像处理能力, 由 AlexNet 模型和 GoogLeNet 模型进行特征提取和样式分类。虽然识别准确率得到了一定提升, 但在实际应用中, 获取多种形式的信号是一种复杂的任务, 且由于不同类型的输入会导致网络结构较为复杂, 模型尺寸变大, 计算时间变长, 性能受到影响。

为了满足 5G 对低延迟通信的需求, 文献[7]通过结合卷积层、池化层和高斯噪声层改进网络结构, 并在其中加入 Dropout 算法进行正则化处理。文献[8]借鉴长短期记忆网络 (Long Short-term Memory, LSTM) 对时间序列处理的有效性, 对原始 I/Q 数据首先进行预处理得到振幅和相位信息, 再经过双层 LSTM 进行特征提取。随着 6G 实时通信的快速发展, 需要在有限的可用资

源下提高通信性能, 所以, 高效的调制识别模型对于计算资源和存储资源有限的 IoT 设备至关重要^[9]。文献[2]在处理数据前进行相位变换, 从而减少相位偏移带来的不良影响。文献[10]提出用于鲁棒自动调制识别的高效混合深度学习模型, 加速了特征提取过程。文献[11]基于 LSTM 去噪自动编码器设计了调制识别模型, 模型得以有效简化。但上述文献所提出的网络模型均有一个不足: 低信噪比条件下的识别准确度不高, 有待进一步提升。

文献[12]考虑到卷积神经网络中特征的冗余性, 结合内在特征通道之间具有相似性的特点, 首先通过常规卷积产生内在特征, 而后对内在特征通过计算量代价更小的线性变换产生更多特征。文献[13]对门控循环单元 (Gated Recurrent Unit, GRU) 在序列建模中的可行性进行验证, 实验表明 GRU 在时间收敛、参数更新及泛化方面均优于 LSTM。在模型识别准确率上, 文献[8]实验表明双层 LSTM 优于单层 LSTM, 文献[14]实验表明双层 GRU 优于单层 GRU。文献[15]关注特征通道之间的依赖关系, 提出新的架构单元——压缩与激励网络 (Squeeze and Excitation Network, SENet), 通过显式建模通道之间的依赖关系, 自适应重新校准通道方向的特征响应, 使用全局信息来选择性强调重要特征, 抑制不太有用的特征。

为解决低信噪比条件下识别准确率不高的问题, 本文提出了一种结合相位变换、GhostNet、SENet、GRU 和深度神经网络组成的模型, 通过较少的参数量有效提取信号调制特征, 提升识别准确率。

1 信号模型

在单输入单输出通信系统中, 接收端的信号可以表示为

$$y[l] = A[l] e^{j(\omega l + \varphi)} x[l] + n[l], \quad l = 1, 2, \dots, L \quad (1)$$

式中: $x[l]$ 为发射机发出的调制信号; $n[l]$ 为复

数加性高斯噪声; $A[l]$ 为信道增益; w 和 φ 分别为频率偏移和相位偏移; $y[l]$ 为接收信号。

接收到的信号通常以 I/Q 的形式存储, 可表示为

$$y = [\Re\{y[1]\}, \dots, \Re\{y[L]\}; \Im\{y[1]\}, \dots, \Im\{y[L]\}]$$

式中: $\Re\{\}$ 和 $\Im\{\}$ 分别表示实部和虚部; L 为单个样本信号采样数。

2 识别模型

本文提出的 AMR 模型的结构如图 1 所示, 模型由相位变换、GhostNet、SENet、GRU 和深度神经网络组成, 详细参数如表 1 所示。




图 1 所建 AMR 模型结构

Fig. 1 Structure of proposed AMR model

2.1 相位变换

信号在传输中易受到信道噪声和硬件设计的影响, 导致接收信号发生时延、线性混合、反转等后果。根据经典信号理论, 这些不良影响可以通过相位变换来解决。相位变换前后, 信号产生的相位偏移如图 2 所示。

图 2 中, 点 A 的坐标为 (m, n) , 与原点的距离为 R , 与横轴之间的角度为 α , 点 A 顺时针旋转角度 θ 到点 B, 其坐标为 (m_1, n_1) 。点 A、点 B 的坐标分别可以表示为

$$\begin{cases} m = R \cos \alpha \\ n = R \sin \alpha \end{cases} \quad (2)$$

$$\begin{cases} m_1 = R \cos(\alpha - \theta) = R \cos \alpha \cos \theta + R \sin \alpha \sin \theta \\ n_1 = R \sin(\alpha - \theta) = R \sin \alpha \cos \theta - R \cos \alpha \sin \theta \end{cases} \quad (3)$$

表 1 所建 AMR 模型的结构参数

Tab. 1 Structure parameters of proposed AMR model

层类型	层设计	层输出
输入层	128×2	$128 \times 2 \times 1$
拉平层	—	256
全连接层	1	1
参数变换层	—	$128 \times 2 \times 1$
GhostNet	普通卷积 38, (8×2) 深度可分离卷积 38, (2×2)	$121 \times 1 \times 76$
SENet	—	$121 \times 1 \times 76$
GhostNet	普通卷积 13, (5×1) 深度可分离卷积 13, (2×2)	$117 \times 1 \times 26$
SENet	—	$117 \times 1 \times 26$
GRU	50	117×50
Dropout	0.6	—
GRU	50	50
Dropout	0.6	—
softmax	11(RML2016.10 a) 10(RML2016.10 b)	11 10




图 2 相位偏移

Fig. 2 Phase shift

将式 (2) 带入式 (3), 可得

$$\begin{cases} m_1 = m \cos \theta + n \sin \theta \\ n_1 = n \cos \theta - m \sin \theta \end{cases} \quad (4)$$

由式 (4) 可知, 通过相位偏移参数即可将点 A 和点 B 联系起来。

相位变换主要由参数估计器和参数转换器两部分组成, 其作用原理如图 3 所示。参数估计器可

以通过与后续模型的协同训练估计出一个相位偏移参数, 通过拉平层和全连接层输出相位偏移参数 φ , 参数转换器将参数 φ 和输入 I/Q 数据作为输入, 利用式 (5) 变换补偿信号中的相位偏移, 从而对输入 I/Q 信号进行校正。

$$\mathbf{y}' = e^{-j\varphi} \mathbf{y} = \begin{bmatrix} \Re\{\mathbf{y}\} \cos \varphi + \Im\{\mathbf{y}\} \sin \varphi \\ \Im\{\mathbf{y}\} \cos \varphi - \Re\{\mathbf{y}\} \sin \varphi \end{bmatrix} \quad (5)$$

式中: $\mathbf{y}$ 为输入的原始 I/Q 数据; $\mathbf{y}'$ 为被校正后的信号。




图3 相位变换原理

Fig. 3 Mechanism of phase transformation

2.2 GhostNet

以往大部分调制识别模型都使用常规卷积, 但卷积神经网络通常包含大量的卷积计算, 从而导致模型随着卷积核维度和组数的增大, 其参数数量和计算时间急剧增大。考虑到常规卷积特征存在冗余性, 特征图之间具有一定相似性, GhostNet模块的卷积操作主要分为两部分: 第一部分和常规卷积相同, 利用给定维度的卷积核对输入数据进行卷积操作, 但其卷积核组数一般为常规卷积的一半; 第二部分主要是对第一部分卷积所得特征图进行深度可分离卷积, 由于深度可分离卷积较常规卷积而言参数量更少, 计算效率更高, 从而在保证网络模型效用的同时模型参数量更少。其作用机理如图4所示。

本文使用 GhostNet 卷积模块提取接收信号的空间特征, 有效利用卷积特征图之间的冗余性,

在保持特征提取能力的同时减少模型参数量。




图4 GhostNet作用原理

Fig. 4 Mechanism of GhostNet

2.3 SENet

SENet通过显式建模卷积特征通道之间的权重关系, 从而提高网络产生特征的表示质量, 其作用机理如图5所示。




图5 SENet模块作用机理

Fig. 5 Mechanism of SENet module

SENet的作用机理是: 输入为 C 个卷积特征图, 维度为 $H \times W$, 首先进行全局平均池化, 各特征图分别对应一个权值, 对权值整体降维同时通过 Relu 函数处理, 再升维并通过 sigmoid 函数归一化到 $[0, 1]$ 之间, 将更新后的权值与原特征图进行相乘, 通过学习全局信息来选择性强调有用的信息特征, 抑制不太有用的特征。

本文使用 SENet 模块对 GhostNet 卷积所得特征进行权重调整, 从而在保证卷积参数量降低的同时, 使卷积特征得到有效增强。

3 仿真实验

分别使用基准数据集 RML2016.10a 和 RML2016.10b, 将本文提出的模型与 CLDNN^[4]、IC-AMCNet^[7] (Improved Convolutional Neural Network-based Automatic Modulation Classification Network)、MCLDNN (Multi-channel CLDNN)^[11]、LSTM^[8]、CGDNet (Conv2D-GRU-DNN)^[10] 在识别准确率和模型复杂度上进行比较。

RML2016.10a 数据集含有 WBFM、AM-DSB、AM-SSB、BPSK、CPFSK、GFSK、4PAM、16QAM、64QAM、QPSK 和 8PSK 共 11

种常用调制信号, 每种调制信号对应 20 种信噪比 ($-20 \sim 18$ dB), 间隔 2 dB, 单个信噪比含有 1 000 个样本, 共有 220 000 个调制信号, 该数据集在模拟恶劣的传播环境中产生, 如高斯白噪声、多路径衰落、采样率偏移、中心频率偏移等。RML2016.10b 数据集和 RML2016.10a 数据集不同的是缺少 AM-SSB 调制信号, 共 10 种调制信号, 每间隔 2 dB 生成 6 000 个样本, 共生成 1 200 000 个调制信号。

实验中将数据集内信号以 6 : 2 : 2 比例随机分为训练集、验证集和测试集。批量处理大小为 400, 使用 Adam 优化器, 以交叉熵损失为损失函数。如果验证损失在 10 个时期内没有改善, 则利用回调函数减半学习率; 如果验证损失在 50 个时期内没有改善, 则利用回调函数停止训练。所有实验在单个 NVIDIA GeForce GTX1050Ti GPU 上运行。

4 结果与讨论

4.1 识别准确率

4.1.1 不同信噪比时的识别准确率

在相同基准数据集 RML2016.10a 训练下, 信噪比变化时不同模型的识别准确率如图 6 所示。




图 6 不同模型准确率对比 (RML2016.10a)

Fig. 6 Comparison of accuracies of different models (RML2016.10a)

由图 6 可知: 在信噪比大于 -12 dB 后, 本文提出的模型除在少数信噪比下 (-6 , -2 , 8 , 18 dB) 与模型 MCLDNN 的识别准确率不相上下之外, 其在大部分信噪比下的识别准确率基本优于其他模型, 平均识别准确率达到 62.30%; 在信噪比为 10 dB 时识别准确率最高, 达到 93.05%, 明显高于其他模型。

4.1.2 低信噪比时的识别准确率

选取信噪比为 -4 dB 条件下的各模型识别混淆矩阵, 如图 7 所示。混淆矩阵表示不同调制样式的




图 7 不同模型在 -4 dB 信噪比时的混淆矩阵

Fig. 7 Confusion matrixes of different models at -4 dB SNR

分类效果, 分类效果越好, 对角线上的结果越高, 对应颜色越深。

从混淆矩阵图中可以发现, 识别错误主要出现在 16QAM 与 64QAM 之间和 AM-DSB 与 WB-FM 之间。原因可能是: 16QAM 和 64QAM 因在数字域存在大量重叠星座点而引起混淆, AM-DSB 和 WBFM 均为连续调制, 均通过模拟音频信号产生, 二者特征在复平面上趋于一致。

4.1.3 大数据集下的识别准确率

将上述模型在更大的基准数据集 RML 2016.10b 下进行训练验证, 不同模型的识别准确率如图 8 所示。




图 8 不同模型准确率对比 (RML2016.10b)
Fig. 8 Comparison of accuracies of different models (RML2016.10b)

由图 8 可知, 在更大基准数据集 RML 2016.10b 下, 各网络模型都能得到更好的训练, 从而识别准确率都有了较好的提升。对比各模型准确率性能可以发现: 本文提出的模型除在少数几个信噪比下的识别准确率略差于模型 MCLDNN 之外, 在大部分信噪比下的识别准确率基本优于其他模型, 平均识别准确率达到 64.45%; 当信噪比为 10 dB 时, 本文模型的识别准确率最高, 可达 93.91%, 优于其他网络模型。

4.2 模型复杂度

表 2 给出了在基准数据集 RML2016.10a 训练下各模型的参数量、每周训练时长和平均识别准确率。

由表 2 可知, 本文提出的模型在参数量有效减少的情况下, 平均识别准确率得到了不同程度的提升, 除单周期训练时间多于模型 IC-AMCNet 之外, 较其他模型训练效率更高。模型 IC-AMCNet 之所以训练时间短, 是因为其只利用卷积神经网络

进行空间特征提取, 而没有利用循环神经网络模块进行时间特征提取。

表 2 模型复杂度对比

Tab. 2 Comparison of model complexities

模型	总参数量	训练时间 秒/周期	平均识别 准确率/%
CGDNet	124 933	22	56.63
IC-AMCNet	1 264 011	19	56.97
MCLDNN	406 199	51	61.92
LSTM	201 099	30	60.04
CLDNN	516 743	64	56.85
本文模型	33 672	20	62.30

5 结论

为了解决现有调制识别模型低信噪比条件下识别准确率的问题, 提出了一种由相位变换、GhostNet、SENet、GRU 和深度神经网络组成的模型。该模型通过相位变换对原始 I/Q 信号进行校正, 然后使用 GhostNet 对卷积层进行优化, 确保参数量减少的情况下实现高效卷积操作, 结合 SENet 对卷积特征进行权重调整, 利用 GRU 提取时序特征, 最后由深度神经网络结合提取特征进行分类。在基准数据集下的实验结果表明, 本文提出的模型较其他模型在低信噪比条件下的识别准确率有了不同程度的提升。后期计划在现有模型的基础上融合其他特征, 并进行模块优化, 从而进一步提升模型在低信噪比条件下的调制样式分类能力。

参考文献:

[1] XU J L, LUO C B, PARR G, et al. A spatio-temporal multi-channel learning framework for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1629-1632.

[2] ZHANG F X, LUO C B, XU J L, et al. An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation[J]. IEEE Communications Letters, 2021, 25(10): 3287-3290.

[3] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C]//17th International Conference on Engineering

- Applications of Neural Networks. Aberdeen, United Kingdom: Springer Verlag, 2016: 213-226.
- [4] LIU X Y, YANG D Y, GAMAL A E. Deep neural network architectures for modulation classification[C]//51st Asilomar Conference on Signals, Systems, and Computers. Piscataway, NJ, USA: IEEE, 2017: 915-919.
- [5] 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.
- [6] PENG S L, JIANG H Y, WANG H X, et al. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(3): 718-727.
- [7] HERMAWAN A P, GINANJAR R R, KIM D S, et al. CNN-based automatic modulation classification for beyond 5G communications[J]. IEEE Communications Letters, 2020, 24(5): 1038-1041.
- [8] 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.
- [9] 邵凯, 朱苗苗. 一种信号调制识别网络的轻量化设计[J]. 电讯技术, 2023, 63(5): 626-632.
- SHAO K, ZHU M M. Lightweight design of a signal modulation identification neural network[J]. Telecommunication Engineering, 2023, 63(5): 626-632.
- [10] NJOKU J N, MOROCHO-CAYAMCELA M E, LIM W. CGDNet: Efficient hybrid deep learning model for robust automatic modulation recognition[J]. IEEE Networking Letters, 2021, 3(2): 47-51.
- [11] KE Z Q, VIKALO H. Real-time radio technology and modulation classification via an LSTM auto-encoder[J]. IEEE Transactions on Wireless Communications, 2022, 21(1): 370-382.
- [12] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2020: 1577-1586.
- [13] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [EB/OL]. 2014 (2024-03-28). <http://doi.org/10.48550/arXiv.142.3555>.
- [14] HONG D H, ZHANG Z L, XU X D. Automatic modulation classification using recurrent neural networks[C]//2017 3rd IEEE International Conference on Computer and Communications (ICCC). Piscataway, NJ, USA: IEEE, 2017: 695-700.
- [15] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.