

低过采样数字调制信号的多尺度一维卷积神经网络解调器

陈显敏 符杰林*

(桂林电子科技大学认知无线电与信息处理教育部重点实验室 广西 桂林 541004)

摘要 针对应用深度学习对数字调制信号进行解调时过采样要求较高的问题,设计低过采样的多尺度一维卷积神经网络数字解调器。该解调器可以在与传统解调器相同的过采样条件下,对BPSK、4-QAM、8-QAM、16-QAM四种数字调制信号进行解调,并能保证传统解调方法相同的误码性能。仿真结果表明,在高斯和Rayleigh衰落信道下,给出的数字调制信号解调器可以在保证解调误码性能的同时,减少了对采样倍数的要求,降低了神经网络结构的复杂性。

关键词 低采样倍数 解调 多尺度一维卷积神经网络 BPSK和M-QAM

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.05.018

MULTI-SACLE 1D-CNN DEMODULATOR FOR LOW OVERSAMPLING DIGITAL MODULATION SIGNAL

Chen Xianmin Fu Jielin*

(Key Laboratory of Cognitive Radio & Information Processing of the Ministry of Education, Guilin University of Electronic Technology, Guilin 541004, Guangxi, China)

Abstract Aiming at the problem of high oversampling requirements when applying deep learning methods to demodulate of digital modulation signals, this paper designs a multi-scale one-dimensional convolutional neural network digital demodulator with low oversampling. It could demodulate the four digital modulation signals of BPSK, 4-QAM, 8-QAM, and 16-QAM under the same oversampling conditions as the traditional demodulator, and could ensure the same error performance of the traditional demodulation method. Simulation results show that under Gaussian and Rayleigh fading channels, the provided digital modulation signal demodulator can not only ensure the performance of demodulation error codes, but also reduce the requirement of sampling multiple, and also reduce the complexity of neural network structure.

Keywords Low sampling multiple Demodulation Multi-sacle 1D-CNN BPSK and M-QAM

0 引言

传统通信系统中,接收机在对多种数字调制信号进行解调时,需要设计实现不同的解调模块,使得需要设计的硬件电路变得十分复杂。机器学习为此提供了一种智能的解决方案,针对不同的调制方式,通过更换不同的网络参数,可以实现在一个解调模块下对多种调制信号进行解调。

基于机器学习方法在调制解调上的研究主要分为

两类:一类是基于人工神经网络(Artificial Neural Network, ANN)、概率神经网络(Probabilistic Neural Network, PNN)的浅层学习方法。基于人工神经网络, Li等^[1]设计了FSK信号解调器; Ahmed等^[2]实现了对16QAM信号的解调。基于概率神经网络, Amini等^[3]设计了一种高信噪比条件下的多信号解调器。基于浅层学习的神经网络解调器,与传统方法相比,无须对通信信号进行低通与匹配滤波,抽样判决处理,提高了通信系统的抗干扰能力,能直接将原始信号转化为比特流,但是受到计算单元的限制,对复杂函数的表达能力

收稿日期:2021-01-11。国家自然科学基金项目(61761014)。陈显敏,硕士,主研领域:机器学习,调制解调。符杰林,副教授。

有限,解调的误码性能并不理想。另一类是基于深度学习方法。吴乐南等^[4-5]提出一种深度置信网络(Deep Belief Network, DBN)解调器,实现了 BPSK 信号在短距离多径信道和瑞利衰落信道下的解调。Lin 等^[6]提出了一种深度卷积神经网络(DCNN)解调器,实现了对 BASK、BPSK 和 PFSK 三种二进制信号的解调。吴添等^[7]结合卷积神经网络提取局部特征和循环神经网络对时序序列建模的能力,提出了一种并联混合(SigNet)解调器,实现了 BPSK、BFSK、16QAM 信号在高斯和瑞利衰落信道下的解调。吴珍珍等^[8]提出了一种 K 近邻自适应增强(Adaptive Boosting, AdaBoost)解调器,针对实际接收平台接收的 BPSK 和 M-QAM 信号进行解调,在过采样倍数分别为 10、20、40、80 时进行实验,解调的误码率性能随着采样倍数的增加而逐渐提升。基于深度学习方法的神经网络解调器与浅层学习相比,误码率性能得到了极大的提升,能够逼近理论误码率曲线,针对不同调制信号的解调具有更强的泛化能力。

学者们应用深度学习在数字信号调制解调中做了许多工作,但是存在以下两个问题:一是为了有效果的提取信号的幅度、相位特征,往往需要几十甚至上百的过采样,对硬件设备和信号处理的能力提出了较大的需求;二是深度学习网络结构复杂,需要漫长的拟合时长,对网络的参数进行调整。

针对上诉问题,本文提出一种适用于低过采样数字调制信号的多尺度一维卷积神经网络解调器。该解调器将 IQ 两路信号串联拼接成一维时序序列,利用一维卷积神经网络对时序序列的检测能力,提取出低维序列中的幅度相位特征,降低了对采样倍数的要求;同时应用多尺度卷积神经网络结构,在计算量不显著提升的前提下增加了神经网络的宽度,增强了网络提取映射特征的能力,最终通过全连接层将学到的特征映射到对应的样本空间,实现了在低过采样条件下对 BPSK 和 M-QAM 信号的解调。

1 神经网络解调器模型

图 1 为神经网络解调模型。该解调模型中的解调系统由预训练参数选择模块和数字信号解调器模块两部分组成。其中,预训练参数选择模块针对不同调制信号解调的参数在离线时通过不同信号数据训练而成。在实时通信时,预训练参数选择模块根据调制信号识别模块的输出,将相应调制方式的参数载入至数字信号解调器,解调器在载入参数后对输入信号进行实时解调输出。如上所述,本方案实现了在一个解调

模块下对多种调制信号进行解调。




图 1 神经网络解调模型

2 适用于低过采样下解调的多尺度一维卷积神经网络

本文利用一维卷积神经网络对时序序列检测分析的能力,借鉴 Inception^[9]架构对提取特征增强的能力,建立了适用于低过采样倍速的多尺度一维卷积神经网络。网络如图 2 所示,由两部分组成:第一部分为并联卷积层,第二部分为全连接层和分类器。

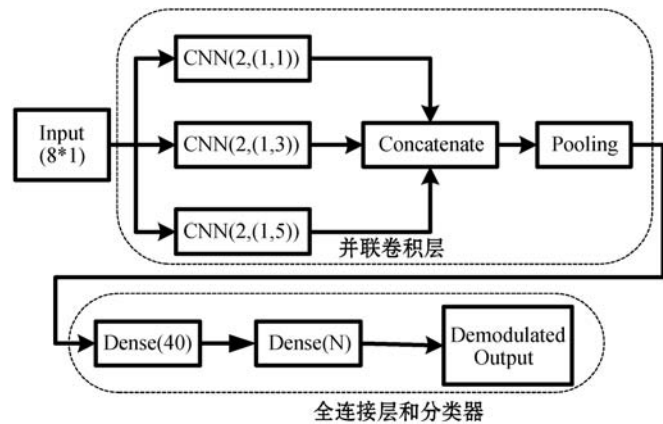


图 2 多尺度一维卷积神经网络

本文网络的输入层为 IQ 两路时域信号的原始数据, 8×1 代表每一个样本的数据矩形,由每个符号采样 4 个采样点串联转化而成。首先将数据填 0 对齐后输入到并联卷积层。并联卷积层由并联一维卷积层和池化层组成。并联一维卷积层模型由图 3 所示,由三层不同卷积核尺寸的一维卷积神经网络并联拼接而成。数据输入至并联一维卷积层,分别由 2 个尺寸为 1×1 、 1×3 、 1×5 的卷积核与输入进行卷积,充分提取出信号的时序特征。采用不同尺寸的卷积核并联的目的是为了让不同尺寸的感受野获取更为丰富的特征映射,拼接的目的是为了使不同尺度的特征融合。

并联一维卷积层借鉴了 Inception 架构的思想,试图使用一个密集组件来代替最佳局部稀疏矩阵。当前版本的 Inception 架构仅限于在二维神经网络中使用。本文输入的数据为一维时序序列,将 Inception 架构中的二维卷积神经网络改为与之相匹配的一维卷积网络,将 1×1 、 3×3 和 5×5 的滤波器更改为将 1×1 、 1×3

和 1×5 的滤波器进行拼接并剪去了并联的池化层。




图 3 并联一维卷积层模型

在一维卷积神经网络中,使用一维数组作为卷积核。在向前传播的过程中,调整维度与卷积和相匹配。当前卷积层 l 输出表示为:

$$x_j^l = f\left[\sum_{i \in M} (x_i^{l-1} k_{ij}^l) + b_j^l\right] \quad (1)$$

式中: x_j^l 表示为当前层(l 层)的第 j 个神经元的输出特征映射; x_i^{l-1} 表示上一层的输出特征映射; $\sum_{i \in M}$ 表示遍历输入特征映射; k_{ij}^l 表示第 $l-1$ 层的第 i 个神经元到第 l 层的第 j 个神经元的卷积核; b_j^l 表示第 j 层的标准偏差; f 为激活函数。

将并联一维卷积层输出输入至池化层。池化层作为子采样层,在特征进行压缩的同时,可以保证映射不变性。为了避免局部特征对分类结果造成偏差,选择使用均值池化(average-pooling)作为池化方式。均值池化可以表示为:

$$y_i^l = \text{average-pooling}(x_i^{l-1}, s_{\text{scale}}, s_{\text{stride}}) \quad (2)$$

式中: y_i^l 为当前层 l 的第 i 个神经元的输出;average-pooling(\cdot)为下采样函数,取上一层在一定范围内输出的均值; s_{scale} 为池化的尺寸; s_{stride} 表示池化的步长。

第二部分,将并联卷积层部分学到的特征映射输出至全连接层和输出层。全连接层的作用是将学到的分布式特征表示映射到对应的样本空间。全连接层第一层的节点数是 50,第二层的节点数定义为 N 。 N 随分类调制信号的不同做相应改变。当解调信号为 4QAM 时, N 为 4;当解调信号为 8QAM 时, N 为 8;即采用 one-hot 编码^[10],需要保证最后一层的节点数和分类的种类保持一致。分类器选择 Adma 作为优化算法,以降低函数为目标进行训练。使用 Softmax 作为分类器,在概率向量中索引最大的熵值作为分类结果。

3 仿真与性能分析

3.1 高斯信道下解调性能分析

针对 BPSK、4QAM、8QAM、16QAM 四种调制信号在高斯白噪声信道下解调进行性能分析。仿真设置 E_b/N_0 为 $-6 \text{ dB} \sim 10 \text{ dB}$,每次增加 1 dB ,在每个 E_b/N_0

下随机产生 1×10^6 个符号,利用矩形脉冲成形进行 4 倍的过采样。每一种调制方式有 $17 \times 10^6 \times 4 = 68 \text{ Mbits}$ 数据。在接收机噪声建模中,采用加性高斯白噪声(AWGN),并将噪声加到整个信号中。数据集随机分为两部分,其中一半用于训练和验证,另一半用于测试。图 4 显示了多尺度一维卷积解调器与最佳接收机对四种不同调制信号在高斯白噪声信道下解调的误码性能。

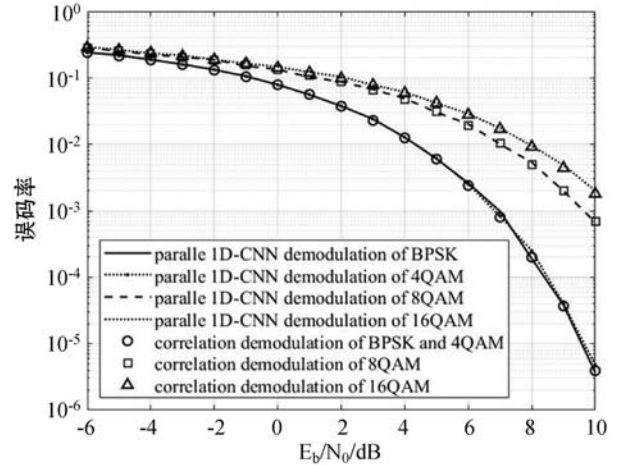


图 4 四种调制信号在高斯白噪声信道下的误码性能

测试结果表明,所提出的多尺度一维卷积神经网络解调器对四种调制信号的解调误码性能均逼近最佳接收机,该解调器针对不同调制方案具有较强的泛化能力。

3.2 瑞利衰落信道下解调性能分析

针对 BPSK、4QAM、8QAM、16QAM 四种调制信号在瑞利衰落信道下解调进行性能分析。在信道模型中,采用 3 条多径延迟的瑞利衰落信道模型,最大多普勒频移频率为 100 Hz 。在接收端获得的数据经过理想的信道估计,此外数据的生成方式与 AWGN 信道相同。图 5 显示了多尺度一维卷积神经网络解调器与最佳接收机对四种不同调制信号在瑞利衰落信道下解调的误码性能。

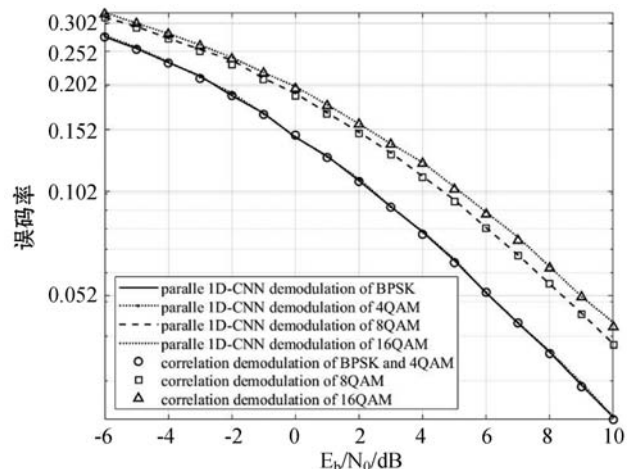


图 5 四种调制信号在瑞利衰落信道下的误码性能

测试结果表明,所提出的多尺度一维卷积神经网络解调器方案在瑞利衰落通道下,仍然能逼近理论的误码率曲线,该解调器针对不同的信道模型具有较强的泛化能力。

3.3 模型结构与参数分析

在这一部分中,分析模型参数对解调性能的影响。实验采用 16QAM 作为调制信号,在高斯白噪声中进行实验,本结论同样适用于其他调制方案。

本文借鉴 Inception 网络,使用不同卷积核尺寸的一维卷积神经网络并联提取更丰富的特征,而经典卷积神经网络结构是由两组交替的卷积层和池化层串联构成。为讨论不同卷积神经网络网络结构对解调性能的影响,固定滤波器数量为 2,保持全连接层节点数不变,在不同的网络结构和卷积核参数设置下进行实验,实验的网络结构和参数设置如表 1 所示。实验结果由图 6 可知,按照经典卷积神经网络搭建的串联模型和单层神经网络搭建的单层模型解调的误码率并不理想,并联结构的神经网络模型具有更有的性能,随着并联层数的增加性能逐渐提升,增加到三层时误码性能最佳。

表 1 卷积神经网络网络结构及卷积核参数设置

模型编号	网络结构	卷积核大小
1	单层	1×1
2	串联	$1 \times 1, 1 \times 3$
3	并联	$1 \times 1, 1 \times 3$
4	并联	$1 \times 1, 1 \times 3, 1 \times 5$
5	并联	$1 \times 1, 1 \times 3, 1 \times 5, 1 \times 7$




图 6 不同网络结构的一维卷积神经网络解调器的误码性能

在卷积神经网络中,卷积核数量的增加能提取更多的映射特征,但当超过某个临界指后则只会徒劳的增加模型的复杂程度。为分析滤波器数量对解调性能的影响,固定多尺度一维卷积神经网络解调器中其他网络

结构,在 2~30 之间改变卷积核的数量,在实验环境相同的条件下进行模型的训练和测试。图 7 显示了卷积核数量对多尺度一维卷积神经网络解调器解调性能的影响。




图 7 滤波器数量对多尺度一维卷积神经网络解调器解调性能的影响

实验结果表明,随着卷积核数量的增加,解调模型性能保持在相对持平的水平,这意味着多尺度一维卷积神经网络解调网络不需要太多的滤波器来提取足够的特征,在训练的过程的不需要对过多的参数进行调整。

3.4 不同神经网络解调器解调性能对比分析

本文所提出的多尺度一维卷积神经网络解调器与已有文献[6]和文献[7]两种神经网络解调器进行复杂度和误码率性能比较。仿真采用 BPSK 调制信号,在高斯信道下对几种神经网络的参数及解调性能进行了对比分析。

表 2 三种深度神经网络复杂度与误码性能比较

网络模型		mult-scale 1D-CNN	DCNN	SigNet
参数数量		2 505	107 026	2 058 845
过采样倍数		4	20	100
不同信噪比下误码率 /dB	$E_b/N_0 = 0$	0.078 80	0.079 20	0.078 60
	$E_b/N_0 = 5$	0.006 20	0.006 40	0.006 10
	$E_b/N_0 = 8$	0.000 82	0.000 83	0.000 81

由表 2 可知,本文方法与另外 2 种神经网络解调器在不同信噪比环境的 E_b/N_0 上误码性能基本保持一致,在此基础上,极大地降低了网络的复杂度,减少了对过采样倍数的要求。这是由于一维卷积网络卷积核为一维数,而二维卷积网络卷积核为矩阵,使得参数数量有所减少;其次本文所需要的滤波器数量和全连接层节点数远少于另外二种神经网络解调器;另外本文

借鉴 Inception 架构造了多尺度卷积神经网络结构在计算量不显著提升的前提下增加了神经网络的宽度,减少了对神经网络深度的要求。

4 结 语

本文在低过采样下对多种数字调制信号在一个解调模型下解调进行研究。本文利用了多尺度网络结构构建并联合一维卷积层提取低维时序序列中的幅度相位特征,全连接层处理提取出来的特征,设计了适应于低过采样倍数的数字信号解调器,并验证了解调器对 BPSK、4QAM、8QAM、16QAM 四种数字调制信号在高频和瑞利衰落信道下解调的误码性能。相较于已有深度学习解调方法,本文方法在保证解调性能同时,降低了网络的复杂度,减少了对采样倍数的要求。另外本文方法所需过采样倍数与传统解调器相同,理论上能直接嵌入到现代通信系统当中,具有一定的实际应用价值。

参 考 文 献

- [1] Li M, Zhong H, Li M. Neural network demodulator for frequency shift keying[C]//International Conference on Computer Science and Software Engineering, 2008.
- [2] Amini M, Balarastaghi E. Universal neural network demodulator for software defined radio[J]. International Journal of Machine Learning and Computing, 2011, 1(3):305 - 310.
- [3] Ahmed N, Aziz M. Neural network demodulator for quadrature amplitude modulation[J]. International Journal of Advanced studies in Computers, Science and Engineering, 2016, 5:10 - 14.
- [4] Meng F, Wu L. Demodulator based on deep belief networks in communication system[C]//International Conference on Communication, Control, Computing and Electronics Engineering (ICCCCEE). IEEE, 2017.
- [5] Fang L, Wu L. Deep learning detection method for signal demodulation in short range multipath channel[C]//International Conference on Communication, Control, Computing and Electronics Engineering (ICCCCEE), IEEE, 2017.
- [6] Lin X, Liu R, Hu W, et al. A deep convolutional network demodulator for mixed signals with different modulation types [C]//2017 IEEE 15th International Conference on Dependable, Autonomic and Secure Computing (DASC). IEEE, 2017.
- [7] Wu T. CNN and RNN-based deep learning methods for digital signal demodulation[C]//Proceedings of the 2019 International Conference on Image, Video and Signal Processing (IVSP). IEEE, 2019.
- [8] Wang H. Deep learning for signal demodulation in physical layer wireless communications: Prototype platform, open dataset, and analytics[J]. IEEE Access, 2019, 7:30792 - 30801.
- [9] Szegedy C. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2015.
- [10] 弗朗索瓦·肖莱. Python 深度学习[M]. 张亮译. 北京:人民邮电出版社, 2018.
- ~~~~~
- (上接第 95 页)
- [3] 喻伟,冯根福,张文珺. 机动车辆保险欺诈检测系统及团伙识别研究[J]. 保险研究, 2017(2):63 - 73.
- [4] Palshikar G K, Apte M. Collusion set detection using graph clustering[J]. Data Mining Knowledge Discovery, 2008, 16:135 - 164.
- [5] 杨烁. 基于图的车险欺诈可视化分析系统的设计与实现[D]. 北京:北京邮电大学, 2019.
- [6] 范倬瑜. 基于图数据库 Neo4j 的信用卡反欺诈系统的设计与实现[D]. 杭州:浙江工业大学, 2020.
- [7] 孙权,汤韬,郑建宾,等. 金融交易数据驱动的图谱网络智能化欺诈侦测[J]. 应用科学学报, 2020, 38(5):713 - 723.
- [8] Liang C, Liu Z Q, Liu B, et al. Uncovering insurance fraud conspiracy with network learning[EB]. arXiv:2002.12789, 2020.
- [9] 刘峤,李杨,段宏,等. 知识图谱构建技术综述[J]. 计算机研究与发展, 2016, 53(3):582 - 600.
- [10] Knyazev B, Lin X, Amer M R, et al. Image classification with hierarchical multigraph networks [EB]. arXiv:1907.09000, 2019.
- [11] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[C]//International Conference on Learning Representations, 2017:2197 - 2208.
- [12] Li G H, Muller M, Thabet A, et al. DeepGCNs: Can GCNs go as deep as CNNs? [C]//IEEE International Conference on Computer Vision, 2019:9267 - 9276.
- [13] Yang Y, Xu Y H, Wang C P, et al. Understanding default behavior in online lending [C]//28th ACM International Conference on Information and Knowledge Management, 2019:2043 - 2052.
- [14] 凡友荣,杨涛,孔华锋,等. 基于知识图谱的电信欺诈团伙特征挖掘方法[J]. 计算机应用与软件, 2019, 36(11):182 - 187.
- [15] 周志涛,鲍灵佳. 社会网络分析在团伙诈骗犯罪侦查中的应用[J]. 江西警察学院学报, 2014(3):39 - 44.