

基于深度卷积神经网络的数字调制方式识别

彭超然, 刁伟鹤, 杜振宇

(中国空间技术研究院 载人航天总体部, 北京 100094)

摘要: 针对非协作通信条件下信号调制方式识别问题, 提出了一种基于深度神经网络的调制方式自动识别新方法; 该方法对接收到的信号进行预处理, 生成星座图, 并将星座图形状作为深度卷积神经网络的输入, 根据训练好的网络模型对调制信号进行分类识别; 与以往的识别方法相比, 该方法利用卷积神经网络自动学习各种数字调制信号的星座图特征, 克服了特征提取困难, 通用性不强, 抗噪声性能差等缺点, 处理流程简单, 并对星座图的形变具有不敏感性; 针对 4 QAM、16 QAM 和 64 QAM 三种典型的数字调制方式, 进行了仿真实验, 当信噪比大于 4 时, 调制方式的识别正确率大于 95%, 实验结果表明, 基于深度卷积神经网络的信号调制方式识别方法是有效的。

关键词: 调制方式识别; 深度学习; 卷积神经网络; 星座图

Digital Modulation Recognition Based on Deep Convolutional Neural Network

Peng Chaoran, Diao Weihe, Du Zhenyu

(Institute of Manned Space System Engineering, China Academy of Space Technology, Beijing 100094, China)

Abstract: A novel method of automatic modulation recognition in non-cooperation communication systems, which is based on deep convolutional neural network, is proposed. Firstly, the received signal is preprocessed and generates the constellation diagram. Then, the shape of the constellation diagram is used as the input of the deep convolution neural network, which is trained to classify the modulated signal. The convolution neural network can automatically learn the constellation diagram features of various digital modulation signals, which can simplify the processing procedures and overcome the weaknesses of traditional techniques, such as the difficulty in extracting the features, the absence of universal property, and the poor anti-noise performance. In addition, the deformation of the constellation diagram is insensitive to the final classification performance by using convolution neural network. Three typical digital modulation schemes including 4 QAM, 16 QAM and 64 QAM are used in the simulation test, and the results show that when the SNR is greater than 4, the accuracy of modulation recognition is more than 95%, which confirmed that the proposed method is effective.

Keywords: modulation recognition; deep learning; convolutional neural networks; constellation diagram

0 引言

调制方式识别是指在未知调制信息内容的情况下对给定接收信号的调制方式进行判断的一种技术, 在无线电信号监测、电子对抗、智能通信等领域有着广泛的应用。真实环境下, 由于非协作通信以及背景噪声的干扰, 会使接收信号的某些特征产生模糊, 从而影响识别结果, 怎样在低信噪比情况下获得更高的调制方式识别正确率是一项重要的研究课题。星座图是数字调制信号分析的常用方法, 其形状反映了调制信号幅值和相位的分布情况, 由于任何一种数字幅相调制信号都可以用星座图唯一表示, 因此可以利用星座图将调制方式识别问题转换为模式识别问题, 避免了复杂的信号处理过程。Mobasser^[1]等最先提出了利

用信号星座图形状来进行调制方式识别。当前大多数基于星座图的调制方式识别研究都是利用聚类算法对星座图进行恢复, 再基于最大似然准则进行分类判别^[2-3]。星座图恢复中的常用算法有模糊 C-均值 (Fuzzy C-Means, FCM) 聚类算法^[4]和减法聚类方法^[5]等, 其中模糊 C-均值聚类算法需要预先给定聚类数目, 这在实际中是不可能预先得到的, 减法聚类方法在高阶 QAM 调制时难以达到理想的效果, 最大似然准则在信噪比低的情况下分类判别的准确度也大大降低。

随着人工智能技术的发展和硬件平台计算能力的提升, 神经网络迎来了新的发展阶段, 特别是 2006 年 Hinton^[6]等提出了逐层贪婪预训练的方法来高效训练神经网络, 有效地解决了一直以来多层深度网络难以训练的问题。当前深度学习已广泛应用在各个行业, 其中卷积神经网络具有强大的特征提取能力, 其分类模型在模式识别领域取得了很好的效果^[7-9], 在通信领域也逐渐受到重视, 陈敏华等^[10]对

收稿日期:2018-07-18; 修回日期:2018-07-29。

作者简介:彭超然(1984-),男,湖南邵东县人,硕士研究生,主要从事航天器测控通信系统设计方向的研究。

卷积神经网络在信道均衡中的应用开展了深入研究, 欧阳星辰等^[11]提出了一种基于卷积神经网络的解调器, 来解调扩展的二进制相移键控调制信号, 消除码间干扰。本文引入卷积神经网络用于解决信号调制方式识别问题, 利用经过训练的卷积神经网络模型, 同时实现特征提取和分类功能, 可直接对星座图进行分类识别, 简化了处理流程, 避免了需要根据不同星座图特征设计聚类算法的缺点, 并具有相位偏移不敏感性和良好的抗噪声性能。

本文首先分析了幅相数字调制信号模型, 根据信号模型列出了影响星座图生成的各种因素, 给出基于星座图进行调制方式识别的基本步骤, 然后提出一种基于深度卷积神经网络的星座图分类方法, 并详细描述了网络结构和模型训练方法, 最后利用 Matlab 产生不同信噪比下的 3 中典型 M-QAM 调制信号星座图进行仿真和卷积神经网络模型训练, 并对识别结果进行分析。

1 信号模型

幅相数字调制发射端信号可表示为:

$$s(n) = \sum_n R_n g(t - nT_b) \cdot \exp[j(2\pi f_c t + \theta_n + \varphi_c)] \quad (1)$$

其中: T_b 为符号周期, R_n 和 θ_n 分别为第 n 个符号的幅度和相位, f_c 和 φ_c 分别为载波频率和初始相位, $g(t)$ 为基带脉冲, $\theta_n \in \{2\pi i/M, i=0, 1, \dots, M-1\}$, M 为相位数。

调制信号通过加性高斯白噪声 (AWGN) 信道后, 接收端对信号进行正交采样得到采样信号, 此时接收信号可表示为:

$$r(k) = \sum_n R_n g(kT_s - nT_b - \epsilon T_b) \cdot \exp[j(2\pi(f_c + \Delta f_c)kT_s + \theta_n + \Delta \varphi_c)] + w(kT_s) \quad (2)$$

其中: T_s 为采样周期, ϵT_b 为采样定时误差, $-0.5 \leq \epsilon \leq 0.5$, Δf_c 和 $\Delta \varphi_c$ 分别为载波频偏和相偏, $w(kT_s)$ 为加性高斯白噪声。

由公式 (2) 可知, 为了获得接收信号星座图, 首先需要确定载波频率和符号周期。对于非协作通信系统, 由于存在采样定时误差, 导致码间干扰, 使得星座图产生扩散难以识别, 因此需要对定时误差进行估计, 获得最佳采样时刻。此外, 接收端恢复出的载波与发射端载波往往存在一定的频率偏移和相位偏移, 载波频偏和相偏也对星座图的形状存在影响。当存在载波频偏时, k 和 $k+1$ 时刻接收序列的绝对相位分别为:

$$\psi_k = 2\pi\Delta f_c kT_s + \theta_k + \varphi \quad (3)$$

$$\psi_{k+1} = 2\pi\Delta f_c (k+1)T_s + \theta_{k+1} + \varphi \quad (4)$$

由公式 (3) 和公式 (4) 可知, 相邻时刻采样点除了正常的符号相位变化外, 还存在一个相位偏移 $2\pi\Delta f_c T_s$, 相位偏移随采样点累加导致星座图呈现环状, 影响星座图识别。当存在载波相偏时, 固定相位偏移 $\Delta \varphi_c$ 将使得星座图整体旋转一个角度。通信信号通过信道传输, 还会引入噪

声, 加性高斯白噪声将导致星座图扩散, 信噪比低于一定程度时将导致星座图无法识别。

2 信号预处理

为了利用卷积神经网络进行调制方式识别, 需要先获得星座图。对于非协作通信系统, 公式 (2) 中的参数均未知, 为了在接收端生成星座图, 需要先进行信号预处理, 获得未知的调制参数, 包括载波频率、符号速率和带宽等, 并消除定时误差和载波频率偏移对星座图的影响, 提高星座图识别正确率。根据幅相调制信号模型以及卷积神经网络分类的特性, 设计基于星座图的调制方式识别预处理流程如图 1 所示。

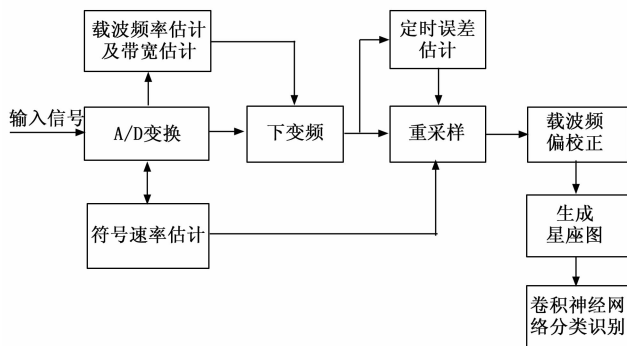


图 1 信号预处理流程

步骤 1: 对接收信号进行 A/D 采样, 通过快速傅里叶变换 (FFT) 将信号从时域变换到频域, 在频域对采样信号进行载波频率估计及带宽估计;

步骤 2: 按照估计得到的载波频率和带宽, 对信号进行下变频处理, 得到基带信号并进行匹配滤波;

步骤 3: 按照载波速率类似的方法进行符号速率估计, 并重新调整采样速率为符号速率的整数倍, 得到重采样信号;

步骤 4: 进行定时误差估计, 并按符号速率对重采样信号进行抽样, 根据定时误差, 获得最佳抽样时刻, 消除定时误差;

步骤 5: 进行载波频率偏移校正, 消除载波频偏对星座图的影响;

步骤 6: 对信号预处理后得到的星座图送入卷积神经网络进行分类识别。

载波频率估计时, 对采样后的信号进行四次方运算, 然后作快速傅里叶变换 (FFT) 得到其四次方谱, 由于四次方谱中含有 4 倍载波频率的谱线, 在频谱中搜索幅度最大值, 其对应频率的四分之一即为载波频率。由于信号包络的平方谱中含有符号速率的谱线分量, 可以按照载波频率类似的方法进行符号速率估计。

带宽估计用来对信号进行带通滤波, 因此对带宽的精度可以适当放宽要求, 可以直接在 FFT 变换后的频谱中粗

略估计得到。

为了获得基带数据的最佳采样时刻，防止星座图扩散，需要对定时误差进行估计。可以通过包络平方算法获得定时误差的估计值，如公式 (5) 所示，其中 N 为采样点数， f_b 为符号速率。

$$\epsilon = -\frac{1}{2\pi} \arg \left\{ \sum_{k=1}^N |r_k|^2 \exp(-j2\pi k f_b / f_s) \right\} \quad (5)$$

为了防止载波频率偏移导致采样点在星座图上的角度旋转累加，影响调制方式识别正确率，需要对载波频率偏移进行校正。在实际使用中，可以通过相位差分的方法进行校正。对每一个采样点根据公式 (3) 和公式 (4) 进行差分运算，重新构建接收信号序列 $r(k) = R(k) \exp(2\pi\Delta f_c T_s)$ ，重构后的序列相邻采样点相位变化固定，消除了载波频率偏移对星座图的影响。

3 分类识别

3.1 卷积神经网络

卷积神经网络 (Convolution Neural Network, CNN) 是一种带有前向反馈的多层神经网络，属于深度学习框架的一种，能够通过多层非线性变换，从数据中自动学习提取特征，具有很强的学习能力和表达能力，并降低了数据预处理的要求，非常适合用于模式识别领域。卷积神经网络一般由卷积层、下采样层、全连接层等组成。

卷积层使用卷积核对输入数据进行滤波后输出特征图，特征图的每个神经元与前一层的局部感受野相连，获得前一层的局部连接特征。卷积核是一个权值矩阵，多个卷积核可以提取多个不同的特征。卷积神经网络具有局部连接、权值共享的特点，可以极大地减少网络的训练参数，简化神经网络。

下采样层也称为池化层，实现对输入的采样，可缩减数据规模，避免过拟合，并保证新的特征层表示不敏感于前一层元素在位置和表现上的变化，对平移、缩放、倾斜或其他形式的变形具有高度不变性，特别适用于本文中因载波相位偏移等导致星座图形变的场景。采样方式一般有最大值采样、平均值采样和随机采样等。

最后一个下采样层或卷积层连到一个或多个全连接层，全连接层的每个神经元与上一层的每个神经元相连，全连接层在整个卷积神经网络中起到分类器的作用，将学到的特征映射到样本标记空间。

1) 若第 l 层为卷积层，则第 j 个特征图为：

$$x_j^l = f \left(\sum_{x_i^{l-1} \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (6)$$

其中： M_j 表示 $l-1$ 层中与第 j 个映射图相连的映射图集合， f 为非线性激活函数， k_{ij}^l 为连接 $l-1$ 层中第 i 个映射图和第 l 层中第 j 个映射图的卷积核； b_j^l 为偏置。

2) 若第 l 层为下采样层，则第 j 个特征图为：

$$x_j^l = f(\omega_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (7)$$

其中： down 为下采样函数， ω_j^l 为权值， b_j^l 为偏置。

3) 若第 l 层为全连接层，则输出特征图为：

$$x^l = f(\beta^l \cdot v + b^l) \quad (8)$$

其中： v 为 $l-1$ 层的下采样层或卷积层的特征图转换成的向量或全连接层输出的向量； β^l 为权值， b^l 为偏置量。

网络中的卷积层和全连接层的权值和偏置量等参数需要通过训练来确定，通过反向传播算法，不断迭代更新网络参数，使得损失函数收敛于全局最小值。训练时使用梯度下降法更新参数：

$$\vec{\omega}_{k+1} = \vec{\omega}_k - \alpha \cdot \nabla L(\vec{\omega}) \Big|_{\omega=\omega_k} \quad (9)$$

其中： ω 表示可训练的参数， k 表示第 k 次迭代， α 为学习率， $\nabla L(\vec{\omega})$ 为损失函数的梯度。计算时每层先计算该层输出节点的误差梯度，即所有来自后一层输入节点的误差梯度的加权和，之后使用链式法则将误差梯度传递至该层输入节点。输出单元的误差梯度通过对损失函数求导得到。为了快速寻找全局最优解，防止陷入局部极值点，需要采取合适的梯度下降优化算法，通常采用的梯度下降优化算法有 Momentum、Nesterov Accelerated Gradient、Adagrad、Adadelta、RMSprop 和 Adam 等。

3.2 VGG-19 网络模型

一般网络结构越深，提取特征的能力越强，且在时间复杂度大致相同时，网络深度比卷积核大小更重要。VGG 网络是一种在 LeNet 以及 AlexNet 的基础上提出来的卷积神经网络，选用小型卷积核串联卷积层来构建更深的网络结构，以此提升网络性能。和大卷积核相比，VGG 网络拥有同样的感受野，却有着更少的参数，更强的非线性能力，因此有着更强的特征提取能力。此外，VGG 网络只需要很少的迭代次数就能收敛。

本文使用 VGG-19 网络进行星座图识别，其结构如图 2 所示，包含 16 个卷积层 (conv)，5 个下采样层 (maxpool) 和 3 个全连接层 (FC)。卷积层均使用 33 的卷积核。下采样层使用最大值采样，窗口大小为 22，步长固定为 2。为了防止梯度消失现象，非线性激活函数使用 ReLU，与 Sigmoid 和 Tanh 等传统非线性激活函数相比，ReLU 具有更快的收敛速度，且只需要一个阈值就可以得到激活值，避免了复杂的运算。最后一个全连接层的结果送到一个输出层，采用 Softmax 逻辑回归进行分类。同时输出层定义一个损失函数来训练整个网络模型，损失函数用于衡量在训练集上训练结果的好坏程度。损失函数通过前向传播计算，同时也是反向传播的起点。VGG-19 网络的损失函数使用 Softmax 计算交叉熵得到。此外为了防止过拟合，在训练时，使用 Dropout 技术让每个神经元以 $p=0.5$ 的概率随机保持其原来的状态 (激活或者抑制)，当神经元被抑制时，这些节点不参加前向传播，也不参加反向

传播, 降低了神经元之间相互适应的复杂性, 使学习得到的特征更具鲁棒性。

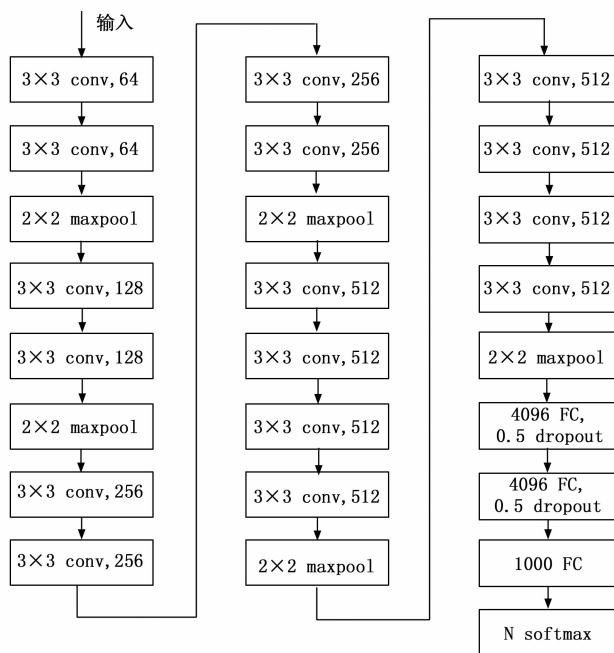


图 2 VGG-19 网络结构

4 仿真结果与分析

4.1 数据集准备

为了获得卷积神经网络模型, 需要大量训练样本进行有监督的训练, 为了验证网络模型的准确性, 需要用测试样本进行测试验证。星座图识别模型中, 训练样本和测试样本为不同调制方式不同信噪比环境下经过标注的星座图。本文利用 Matlab 生成随机二进制序列, 进行 3 中典型的幅相数字方式调制: 4 QAM、16 QAM 和 64 QAM, 并将信号叠加加性高斯白噪声, 模拟信号预处理后的星座图, 得到训练集和测试集。生成的归一化后的星座图如图 3 中 (a)、(b)、(c) 所示。仿真时模拟了各种噪声环境下的信号, 选择信噪比的变化范围为 2~20 dB, 每 1 dB 步进生成 100 个星座图, 每种调制方式共 1900 个星座图作为训练集, 并通过旋转、缩放、平移等方式增广训练集, 其中模拟相偏下的星座图如图 4 所示。在各个调制方式的训练集中每 1 dB 步进选择 50 个星座图作为测试集。

4.2 模型训练与识别

卷积神经网络的具体实现上, 本文使用 Caffe 来构建 VGG-19 网络。Caffe 是一种 C++ 编写的深度学习框架, 具有简单、高效、开源等优点和较强的可扩展性及可移植性, 支持 CPU 和 GPU 运算, 支持 Matlab 和 Python 接口。Caffe 提供了一个完整的工具包, 用于训练、测试、微调和部署模型, 允许用户对新的数据格式、网络层和损失函数进行拓展。VGG-19 网络的具体结构在 Caffe 中的 prototxt

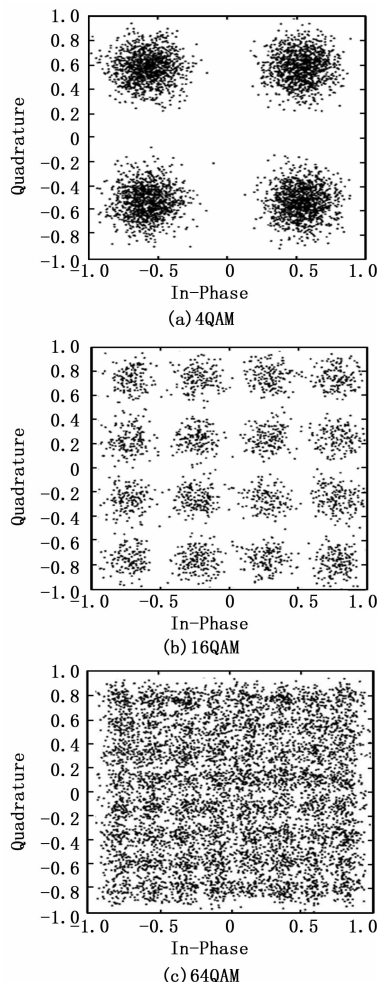


图 3 星座图仿真, 信噪比为 10





图 4 存在相位偏移的 16QAM 星座图


文件中定义。

使用准备好的星座图训练集对 VGG-19 网络进行训练, 初始学习率 α 设为 0.01, 梯度下降优化算法选用 RM-Sprop, 训练结果如图 5 所示, 可以看到随着训练次数的增加, 训练损失快速下降, 正确率迅速上升, 经过约 20 次训

练迭代，可以实现训练曲线的收敛。



(a) 损失函数随迭代次数的变化



(b) 正确率随迭代次数的变化

图 5 网络模型训练曲线

对训练好的 VGG-19 网络模型使用测试集进行验证，不同信噪比下调制信号分类识别的结果如图 6 所示。




图 6 不同信噪比下的识别正确率

分析识别结果可以发现：同等低信噪比条件下，随着 QAM 调制阶数的增加，识别准确率下降。随着信噪比的升高，3 中调制方式的识别正确率均显著提高。在信噪比大于 4 的情况下，3 中调制方式的识别正确率都在 95% 以上，且对于存在载波相位偏移的接收信号星座图，依然具有很高的分类识别正确率。

5 结束语

本文研究了基于星座图的幅相调制方式识别方法，给

出了在信号接收端生成星座图的基本处理流程，根据调制方式与星座图一一对应的关系，将调制方式识别问题转换成星座图模式匹配问题。通过信号模型分析了影响星座图识别准确度的主要因素和处理方法，并利用卷积神经网络的特性，将 VGG-19 深度卷积神经网络用于星座图识别，并给出了 VGG-19 网络模型和训练方法。卷积神经网络通过训练可以自动学习各种调制方式下的星座图特征，避免了在低信噪比环境下人工分析和提取特征的复杂性，此外，由于卷积神经网络对平移、缩放、倾斜或其他形式的变形具有高度不敏感性，简化了信号预处理中对载波相位偏移的处理过程。通过仿真实验，证明了基于深度卷积神经网络的数字调制识别方法的有效性。

参考文献:

- [1] Mobasseri B G. Digital modulation classification using constellation shape [J]. *Signal Processing*, 2000, 80 (2): 251-277.
- [2] 程汉文, 吴乐南. 基于星座图和相似性度量的调制方式识别 [J]. *应用科学学报*, 2008, 26 (2): 111-116.
- [3] 王建新, 宋 辉, 基于星座图的数字调制方式识别 [J]. *通信学报*, 2004, 25 (6): 166-173.
- [4] Schreyogg C, Reichert J. Modulation classification of QAM schemes using the DFT of phase histogram combined with modulus information. *Proceedings of the 21st Century Military Communications Conference [C]*. California, USA, 1997: 1372-1376.
- [5] Boiteau D, Martret C L. A general maximum likelihood framework for modulation classification [A]. *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing [C]*. Washington State, USA, 1998: 2165-2168.
- [6] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313 (5786): 504-7.
- [7] Swietojanski P, Ghoshal A, Renals S. Convolutional neural networks for distant speech recognition. *IEEE Signal Processing Letters [J]*. 2014, 21 (9): 1120-1124.
- [8] Cao K, Jain A K. Latent orientation field estimation via convolutional neural network [A]. *Proceedings of the 2015 International Conference on Biometrics [C]*. Phuket, Thailand, 2015: 349-356.
- [9] 周 敏, 史振威, 丁火平. 遥感图像飞机目标分类的卷积神经网络方法 [J]. *中国图象图形学报*, 2017, 22 (5): 702-708.
- [10] 陈敏华, 李 杨, 张武雄. 基于卷积神经网络的信道均衡算法 [J]. *计算机应用与软件*, 2017, 34 (9): 257-261.
- [11] 欧阳星辰, 吴乐南. 基于 CNN 解调器的超奈奎斯特速率通信 [J]. *东南大学学报 (英文版)*, 2016, 32 (1): 6-10.