

基于深度学习的 LDPC 码编码类型识别

李欣宇, 张轶凡

(北京邮电大学信息与通信工程学院, 北京 100000)

摘要: 随着通信技术的持续演进, 自适应编码调制 (AMC) 技术已成为提升通信效率的重要手段。在这一背景下, 信道编码识别技术的重要性日益凸显。特别是 LDPC 码, 因其出色的纠错能力和高效的传输性能, 在无线通信领域得到了广泛应用。然而, 要实现 LDPC 码的有效识别, 仍存在诸多挑战。当前, 尽管深度学习在信号特征自动提取方面展现出显著优势, 但关于 LDPC 码编码类型的深度学习识别研究仍相对匮乏, 且现有方法多采用单一神经网络结构, 识别精度和泛化能力有待进一步提高。因此, 探索更为精准、高效的 LDPC 码识别方法已成为当前研究的迫切需求。鉴于此, 本文提出了一种 BGRU-CNN 的 LDPC 码编码类型识别方法, 该方法融合了双向门控循环单元神经网络 (BGRU) 与卷积神经网络 (CNN) 的优势。该方法首先将接收到的信号输入到 BGRU 中进行初步处理, 随后利用 CNN 进行深层次特征提取与分类, 通过多个卷积层和池化层的堆叠, 进一步提取信号中的空间特征, 并对 LDPC 码的编码类型进行分类。实验结果表明, 该算法在性能上始终优于现有的深度学习算法, 如 textCNN 和 LSTM 等。

关键词: 信道编码; LDPC 码; 编码识别; 深度学习

中图分类号: TN91

Recognition of LDPC Code Encoding Types Based on Deep Learning

LI Xinyu, ZHANG Yifan

(Beijing University of Posts and Telecommunications, School of Information and Communication Engineering, Beijing 100000)

Abstract: As communication technologies advance, Adaptive Modulation and Coding (AMC) sees increasing application, and channel coding identification becomes ever more critical. In particular, Low-Density Parity-Check (LDPC) codes, known for their exceptional error correction and efficient transmission capabilities, have found broad usage in wireless communications. Yet, effective recognition of LDPC codes presents significant challenges. Although deep learning has shown substantial benefits in automatic feature extraction from signals, there is a scarcity of research on deep learning-based identification of LDPC code types, and existing methods, often reliant on single neural network architectures, need enhanced recognition accuracy. This article proposes a BGRU-CNN-based method for identifying LDPC code types, integrating the strengths of Bi-directional Gated Recurrent Unit (BGRU) and Convolutional Neural Networks (CNN). This method processes received signals with BGRU for initial treatment, then utilizes CNN for in-depth feature extraction and classification of LDPC code types. Experimental results demonstrate that this algorithm consistently outperforms existing deep learning algorithms, such as TextCNN and LSTM, in performance metrics.)

Key words: Channel coding; LDPC code; Code Recognition; Deep learning

0 引言

近年来, 随着无线通信技术的飞速发展, 自适应调制编码 (Adaptive Modulation and Coding, AMC) [1] 技术因其能够根据信道条件动态调整调制编码方式, 提高通信系统的传

作者简介: 李欣宇 (1999-), 女, 硕士研究生, 主要研究方向: 信道编码识别, 深度学习

通信联系人: 张轶凡, 男, 硕导, 主要研究方向: 宽带移动通信理论. E-mail: zhangyf@bupt.edu.cn

输效率,受到了广泛的关注。然而,传统的 AMC 技术通常依赖于控制信道来进行参数信息的传输,这不仅降低了整体的传输效率,还占用了一部分宝贵的频谱资源。为了解决这一问题,信道编码识别技术得到广泛关注,它能够通过分析接收到的信号特征,直接识别出所采用的信道编码方式,从而避免了额外的参数信息传输开销,将成为未来通信研究的一项关键技术。在众多信道编码中,低密度奇偶校验(Low Density Parity Check code, LDPC)^[2]码以其卓越的纠错性能和高效的解码算法而备受瞩目。因此,对 LDPC 码的编码识别具有重要意义。

LDPC 码编码识别技术可大致分为两个研究方向:传统的 LDPC 码编码识别方法和基于深度学习的 LDPC 码编码识别方法。传统的 LDPC 码编码识别方法,主要是利用 LDPC 码的奇偶校验关系进行编码参数的识别^[3]。这类方法通常涉及对码长、码率等关键参数的分析,以此推断出 LDPC 码的编码参数类型。然而,在实际应用中,由于通信环境中存在多种具有不同编码结构的复杂 LDPC 码,这类传统方法无法准确识别出各种编码类型。因此具有很大的局限性。而深度学习方法可以通过训练对不同类型的 LDPC 码进行特征提取,从而很好的完成 LDPC 码的编码类型识别。

深度学习具有很强的特征提取能力,因此将深度学习引入到信道编码识别领域。文献^[4]构建了 RNN 识别器,通过捕捉码字序列中信息位于校验位的约束关系来完成信道编码的识别,文献^[5]引入了注意力机制来提高识别准确率,ResNet 网络^[6]也被应用于编码识别领域,此外,还有其他神经网络^[7],例如, text-CNN^{[8][9]}也被成功地应用于信道编码识别中,它通过将接收到的信号转换为类似于图像的形式,自动学习并提取出与信道编码相关的特征,从而实现准确的识别。另外, LeNet-5 也是一种常用于信道编码识别的深度神经网络模型,改进后的 LeNet-5^[10]通常包含多个卷积层、池化层和全连接层,能够有效地提取信号中的空间特征和层次结构信息,进而提升信道编码识别的性能。再此基础上,文献^[11]出基于 LSTM 的信道编码类型识别器,通过将原始编码序列作为神经网络的训练数据,利用训练后的神经网络完成对 polar 码、LDPC 码和卷积码的编码类型识别。

1 基于 BGRU-CNN 的 LDPC 码类型识别方法

1.1 数据处理

1.1.1 数据集构建

LDPC 码是现代通信系统中一种优秀的纠错码,具有良好的纠错性能,译码性能可以接近香农限。此外,LDPC 码的编译码算法简单,易于实现,在高速传输中具有较低的计算复杂度,因此应用广泛。本文旨在对不同类型的 LDPC 码进行识别,通过构建数据集完成 LDPC 码的编码类型识别。由于实际应用中,不同编码方式的 LDPC 码难以直接获取,因此本文利用 MATLAB 来生成不同种类的 LDPC 码,并把得到的 LDPC 码数据通过基本通信模型处理,最后将得到的接收序列作为样本数据放入数据集。

本文使用的 LDPC 码种类包括 IEEE802.11 协议、DVB-S2 协议、5G NR LDPC 码三种编码。具体的编码参数如表 1 所示:

表 1 数据集中各类型 LDPC 码编码参数

Tab. 1 Encoding parameters of various types of LDPC codes in the dataset

编码类型	Length N	Rate R
IEEE802.11 LDPC	648,1296,1944	1/2,2/3,3/4,4/5
DVB-S2 LDPC	16200,64800	1/4,1/3,1/2,3/5,2/3,3/4,4/5,5/6,8/9
5G NR LDPC	512,1024,2048,8192	1/2,1/3,2/5,1/5,2/3,3/4,5/6,8/9

本文利用 MATLAB 生成了 IEEE802.11, DVB-S2,5G NR LDPC 码各 20000 帧, 然后根据对应的校验矩阵 H 生成 LDPC 编码 $[c_1, c_2, \dots, c_n]$ 。将得到的 LDPC 编码数据通过 BPSK 调制器, 在加性高斯白噪声信道中进行传输, 信噪比范围为 dB, 将软判决解调后得到的信号作为样本保存到数据集中, 其中 60% 作为训练集, 20% 作为验证集, 20% 作为测试集。

1.1.2 数据预处理

由于数据集中的样本 LDPC 码编码结构不同, 并且在传输过程中会受到不同程度的噪声干扰, 因此直接对这些数据进行处理可能会引入不必要的偏差。为了解决这个问题, 我们需要通过特征数学标准化对数据进行预处理。通过标准化, 我们可以将数据集中的特征值转换为统一的尺度, 从而降低由于不同 LDPC 码编码结构和噪声干扰引起的差异。这可以使得后续的数据分析和机器学习模型的训练更加准确和可靠。因此, 在进行 LDPC 码的解码和性能评估之前, 对数据进行适当的预处理和标准化是至关重要的。

深度学习中常见的预处理方法有数据归一化、标准化和白化等。数据归一化通常将特征值缩放到 $[0,1]$ 或 $[-1,1]$ 等特定范围内, 以消除量纲和数量级对模型的影响。标准化则是对数据进行线性变换, 使其转换为均值为 0, 标准差为 1 的标准整体分布。白化在标准化的基础上, 进一步消除特征间的相关性, 使得数据协方差矩阵为单位矩阵。这些方法能够调整数据的分布和尺度, 提升模型的训练效率和性能表现。

本文通过标准化的方法来对样本数据进行预处理, 标准化公式为:

$$x' = \frac{x - \text{mean}(x)}{\sigma(x)} \quad (1)$$

式 1 中, x 为数据集中的信号样本, $\text{mean}(x)$ 为样本数据平均值, $\sigma(x)$ 为样本数据的标准差。

1.2 BGRU-CNN 网络模型

1.2.1 BGRU 网络

门控循环神经网络单元(Gated Recurrent Unit, GRU)是 LSTM 网络的一种变体, 作为一种新型的循环网络单元, 它的出现主要是为了解决 LSTM 计算复杂度高以及模型参数多的问题。相比 LSTM 的复杂结构, GRU 仅用重置门和更新门两个门控单元来控制时间序列在网络上的流通状态, 从而使得 GRU 在保持了对长期依赖关系捕捉能力的同时, 降低了模型计算复杂度和输入参数数量, 提高了模型的训练速度。GRU 的具体结构如图 1 所示:

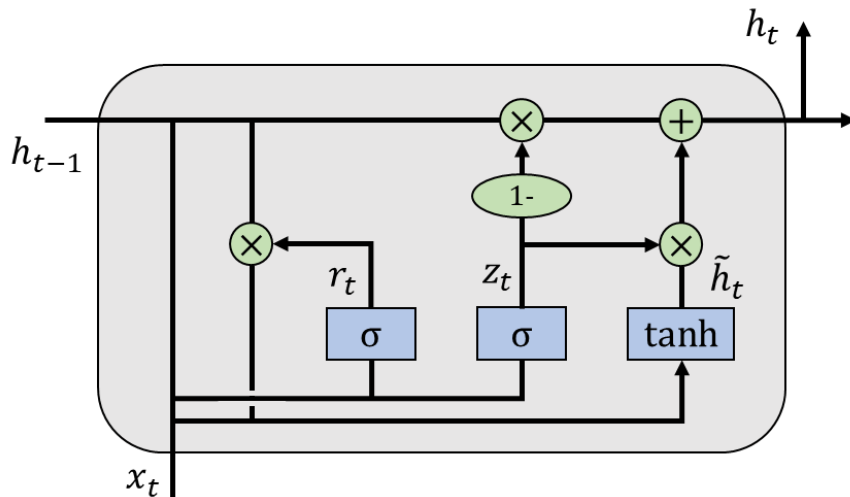


图1 GRU 基本神经单元

Fig. 1 Gru basic neural unit

图中 z_t 为更新门， r_t 为重置门。更新门用于提取当前状态的信息特征，更新门越小，说明提取的当前状态信息特征越少，说明当前网络模型更偏重于上一节点中包含的特征。重置门则用于提取前一时刻状态的信息特征，重置门越小，说明上一节点信息特征的占比越小，此时网络模型更偏重于当前节点中包含的信息特征。两个门控单元都与神经网络中上一个节点的隐藏层状态 h_{t-1} 和当前节点的输入 x_t 有关，具体公式为：

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (2)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3)$$

其中 W 表示模型权重， σ 表示激活函数，这时候候选向量 \tilde{h}_t 可通过重置门 r_t 与上一节点隐藏状态 h_{t-1} 计算得到，式4中 \odot 表示点乘运算：

$$\tilde{h}_t = \tanh(W_x \cdot [r_t \odot h_{t-1}, x_t]) \quad (4)$$

最终可以得到 t 时刻GRU的输出 h_t 与 $t-1$ 时刻的输出 h_{t-1} 以及候选向量 \tilde{h}_t 的线性表示：

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (5)$$

式5中 $(1 - z_t) \odot h_{t-1}$ 表示对上一节点中的隐藏状态 h_{t-1} 的特征过滤， $z_t \odot \tilde{h}_t$ 表示对当前节点中的信息 \tilde{h}_t 特征提取。可以看出，在网络的前向传播中，GRU采用了一种联动的遗忘和更新机制，通过计算得到的更新门参数 z_t ，模型会选择性遗忘部分先前状态信息，遗忘比例由 $(1 - z_t)$ 决定，与此同时，为了保持信息的连续性，模型会利用当前输入生成的候选隐藏状态 \tilde{h}_t 中的权重 z_t 进行补偿。这种独特的门控单元设计可以防止梯度消失。在RNN网络中，由于每个节点隐藏层之间的权重是相互关联的，因此在反向传播过程中，会造成梯度消失的情况。而GRU的门控单元设计可以选择性的保留先前的记忆信息，大大降低了梯度在反向传播过程中的衰减速率。同时，这种机制确保了在处理序列数据的过程中，GRU能够有效的将历史信息与当前输入相结合，从而维持模型内部状态的稳定。因此，GRU能够在捕捉长期依赖关系的同时，实现更高效率和灵活的信息处理，在处理长序列数据中具有巨大优势。

但由于GRU是一个单向传播模型，只能根据先前的输入信息来更新处理当前输入，无法充分利用后序信息。而与语言模型不同，对于信道编码识别问题，输入的码字序列是完整的，因此考虑使用双向门控循环神经网络（Bi-direction Gated Recurrent Unit, BGru）模型可以完整的获取码字序列的上下文信息，从而有助于更好的区分不同编码方案，增强模型对噪声和干扰的鲁棒性。

BGRU 模型也是一种循环神经网络，结合了双向信息流和门控循环神经单元 GRU 的特性。它可以同时处理输入序列的前后向信息来捕获更丰富的上下文特征。BGRU 中包含有两个并行的 GRU 单元，一个前向 GRU，用于处理从序列起始到末端的信息流数据；一个反向 GRU，用于处理从序列末端到起始的信息流数据。两个 GRU 在每个时间步都会输出一个隐藏状态，分别代表该节点的前后向上下文信息，然后将这些隐藏状态合并起来，形成最终输出，此时得到的输出包含了序列中每个位置的双向信息。BGRU 模型如图 2 所示：

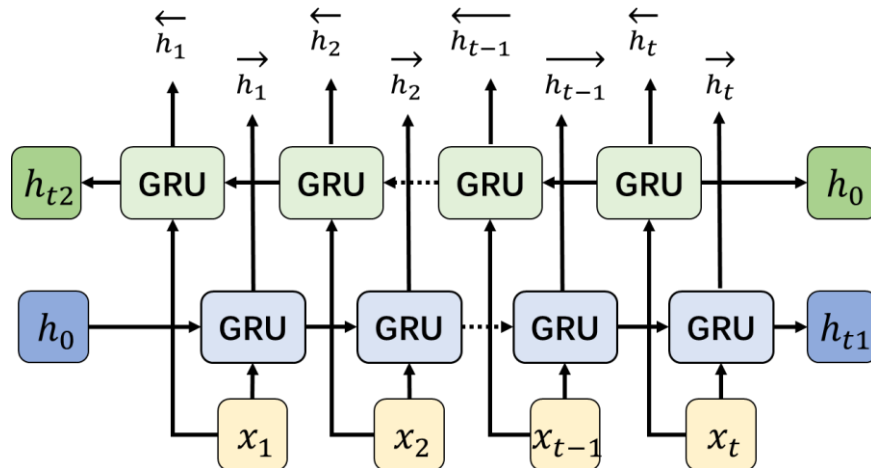


图 2 BGRU 网络结构图

Fig. 2 BGRU network diagram

从图上可以看出，前向 GRU 从前往后遍历序列信息，反向 GRU 从后向前遍历序列信息。对于任意节点 t ，最终得到的隐藏层状态 h_t 与两个门控循环单元的隐藏层状态都有关联，它们对应的计算公式为：

$$h_t = \overrightarrow{h_t} \oplus \overleftarrow{h_t} \quad (6)$$

其中 $\overrightarrow{h_t}$ 表示前向 GRU 在 t 时刻的隐藏层状态， $\overleftarrow{h_t}$ 表示反向 GRU 在 t 时刻的隐藏层状态。从图示可以看出，两个门控单元之间是相互独立的，同一时刻得到的两个隐藏层状态之间不存在约束关系。

展开的双向循环神经网络训练步骤可以写成：

步骤一：前向传播

前向传播是神经网络中从输入层到输出层的数据传递过程。在双向网络中，这一过程涉及两个方向：正向和反向。

1. 正向状态传播

从时间步 $t = 1$ 开始，到 $t = r$ （这里的 r 可能是序列的中间点或某个特定时间点）。在这一阶段，正向的 GRU 单元会接收输入数据并产生正向的隐藏状态。

2. 反向状态传播

从时间步 $t = r$ 开始，到 $t = 1$ ，这里的反向不是指时间的倒流，而是从序列的末端开始处理数据。反向的 GRU 单元同样会接收输入数据，但产生的是反向的隐藏状态。

3. 输出层处理

正向和反向的隐藏状态通常会被结合起来（例如，通过拼接或平均），然后传递给输出层以产生预测输出。

步骤二：反向传播

后向传播（也称反向传播）是神经网络中用于计算误差梯度和更新权重的过程。在双向

网络中，后向传播同样需要考虑正向和反向两个方向。

1. 对传输层进行反向传递

首先计算输出层与目标函数之间的误差梯度。这通常涉及计算预测输出与实际目标之间的损失函数导数。

2. 正向状态的反向传递

时间步 $r = t$ 开始，反向传递到 $t = 1$ 。在这一阶段，计算正向 GRU 单元中每个时间步的权重和偏置的梯度。

3. 反向状态的反向传递

从时间步 $t=1$ 开始，正向传递到 （注意这里的描述可能有误，因为反向状态的反向传递通常也是从后往前进行，即从 到某个结束点，但这里为了与原文保持一致，保留了原表述）。计算反向 GRU 单元中每个时间步的权重和偏置的梯度。

步骤三：更新权重

在计算出所有必要的梯度之后，就需要对网络权重进行更新。这通常涉及使用优化算法（如梯度下降、Adam 等）来调整权重和偏置，以最小化损失函数。在双向网络中，需要同时更新正向和反向 GRU 单元的权重。

1.2.2 BGRU-CNN 网络模型

卷积神经网络（CNN）是一类包含卷积运算且有深度结构的前馈神经网络，它可以利用其卷积层的卷积操作，有效的提取样本中的局部特征，并通过多个卷积层的叠加，逐步提取出更加抽象、高层次的特征。因此本文将 BGRU 网络与 CNN 网络级联，构建出基于 BGRU-CNN 网络模型的 LDPC 码编码识别模型。

其中 BGRU 算法作为 RNN 算法的一种变体，在处理诸如 LDPC 码这样的序列数据上具有巨大优势，BGRU 可以通过其内部的隐藏状态来存储和处理信息，使得其能够对 LDPC 码的长期依赖关系进行跟踪。同时，由于 LDPC 码的码长普遍较长，因此特征关系在序列中距离可能较远，BGRU 的双向结构允许信息从两个方向传播，可以同时考虑前后序列中的信息，从而更全面的捕获 LDPC 码序列中的特征关系。而在经过 BGRU 全面获取码字序列的特征信息后，可以使用 CNN 网络来提取 LDPC 码的多层次特征，从而提高特征识别的精度。在 CNN 网络中，卷积层和池化层都能使得学到复杂抽象的特征表示，但当其数量过多时，会导致特征图的尺寸变小，导致全连接层的参数数量减少，从而影响模型的性能。经过实验得到最优网络结构如图 5 所示：




图 3 BGRU-CNN 网络结构图

Fig. 3 BGRU-CNN network structure

其中第一层为输入层(Input)，在输入层中对数据集中每个序列样本进行信号处理，将序列数据处理为文本形式，从而降低识别的复杂度，设置采样数为 32，采样长度为 8，以码长

为 256bits 的信道码为例，将其分为 32 份，每份长度为 8bits。

第二层为双向门控循环单元神经网络层 BGRU，两个门控循环单元双向对数据进行处理，根据上下文对特征值进行过滤，并将最终得到的特征向量传播到下一层，BGRU 输出的 h_i 包含对应的样本序列 c_i 中所有码字间的信息。BGRU 层的输入尺寸设为 128，隐藏神经单元数目为 256，层数为 3 层。

BGRU 和 CNN 的每层输出都需要经过 dropout 层来降低其复杂度，防止过拟合问题出现。这里设置的概率值为 0.3，每次训练中它可以随机的将神经网络中的 30% 的神经元设置为 0，使得网络结构有所不同，从而减少了模型对训练数据中部分特征的依赖，增强了模型的鲁棒性。使用最大池化层(Max Pooling)来提取特征图最显著的特征，通过选择每个池化窗口中最大的值作为输出，减少了数据维度和计算复杂度，提高了网络表达能力。在卷积神经网络 CNN 部分，我们设置卷积核尺寸大小分别为 1×3 ， 1×4 ， 1×5 ，输出特征图参数均为 128。

本研究中使用 Adam 优化器来提高识别效率，使用常见的交叉熵函数作为损失函数。损失函数在深度学习网络的训练中有着至关重要的作用，它可以量化模型预测与真实标签之间的差异，为优化算法提供了方向和目标。通过最小化损失函数，我们能够不断调整模型参数，使得模型预测结果更为准确。交叉熵损失函数 \mathcal{L}_c 表示为：

$$\mathcal{L}_c = \frac{1}{m} \sum_{q=1}^m \ell_{ce}(P^{(q)}, \hat{p}^{(q)}) \quad (7)$$

式中 m 为 Batch-Size， $P^{(q)}$ 表示第 q 个数据样本的标签， $\hat{p}^{(q)}$ 表示第 q 个数据样本的预测概率向量。 $\ell_{ce}(P^{(q)}, \hat{p}^{(q)})$ 的计算公式为：

$$\ell_{ce}(P^{(q)}, \hat{p}^{(q)}) = - \sum_{k=1}^K p_k^{(q)} \log(P(H_k | c_i^{(q)})) \quad (8)$$

通过 SoftMax 函数，最后得到输入样本 c_i 与预测概率向量 $P = [P(H_1 | c_i), P(H_2 | c_i), \dots, P(H_K | c_i)]$ ，通过 SoftMax 函数计算得到：

$$P(H_k | c_i) = \frac{e^{x_k}}{\sum_{i=1}^K e^{x_i}} \quad (9)$$

其中 x_i 表示前一层得到的第 i 个激活函数输出结果。

1.3 训练过程

本次实验采用了 TensorFlow 深度学习框架，利用 GPU 加速训练，将生成的数据集按照 6: 2: 2 的比例划分为训练集，测试集和验证集，确保模型在训练过程中有足够的数据进行学习，同时保留一部分数据用于评估模型的性能。训练集是已知标签的数据集，这意味着每个数据样本都附带有一个或多个标签，用于指示该样本所属的类别或具有的特性。我们使用独热编码 (One-Hot Encoding) 来表示已知的 LDPC 码类型。它通过将每个类别映射为一个只包含一个“1”和多个“0”的向量，确保类别之间的距离计算更加合理。表示已知的 LDPC 码类型独热编码：

$$\hat{p}_i = (C_1, C_2, \dots, C_i, \dots, C_n) \quad (10)$$

n 表示有数据集中有 n 种编码类型，当 C_i 为发送端发送的编码类型时，此时其他 $C_j = 0, j \neq i$ 。在完成数据集构建和数据预处理后，开始进行 BGRU-CNN 网络的训练，具体训练流程如下：

步骤一，根据图 5 所示结构图完成 BGRU-CNN 网络模型的搭建。

步骤二，将划分好的训练集输入网络中进行训练，采用 Adam 优化器来更新参数，学习率为 10^{-3} ，批处理大小 Batch-Size 为 64，Epoch 为 100。

步骤三，保存网络训练中的最优网络模型，选择在验证集上性能最好的模型作为最优模型进行保存。

为了更直观地展示模型在训练过程中的性能变化，我们将每个 epoch 的准确率和损失函数值分别绘制成曲线图 6, 7。曲线图的横轴表示训练的 epoch 数，纵轴分别表示准确率和损失函数值。通过观察这些曲线图，我们可以清晰地看到模型在每个 epoch 上的性能表现，以及随着训练的进行，模型的性能是如何逐渐提升的。




图 4 BGRU-CNN 网络训练准确率

Fig. 4 BGRU-CNN network training accuracy




图 5 BGRU-CNN 网络训练 loss 值

Fig. 5 BGRU-CNN network training loss value

在图 4, 5 中，我们观察到了网络在训练过程中的识别准确率和损失函数值的变化曲线。首先，从准确率曲线图 4 中可以看出，随着训练轮次的增加，训练集和验证集的准确率都呈现出了稳步上升的趋势。这表明模型在不断地学习并优化其内部参数，以更好地提取输入数据的特征。最终，训练集和验证集的准确率均达到了 98.7%。

其次，我们注意到准确率曲线在训练过程中并没有出现明显的波动或下降，这意味着模型在训练过程中是稳定的，没有出现严重的过拟合或欠拟合现象。随着训练的进行，损失函数值逐渐减小并也趋于稳定。

2 实验仿真和分析

2.1 LDPC 码编码类型识别情况

首先,为了全面评估算法对 LDPC 码的识别能力,我们从数据集中选取了三种不同类型的 LDPC 码,每种类型各取 4000 个样本作为数据集。这些样本涵盖了不同的码长、码率和信噪比,旨在模拟实际通信环境中可能遇到的各种 LDPC 码场景。我们将通过算法对这些样本进行识别,以验证其对不同类型 LDPC 码的准确性和可靠性。




图 6 BGRU-CNN 编码类型识别情况

Fig. 6 BGRU-CNN code type identification

图 6 为单个样本长度为 4000 时,三种不同编码类型的 LDPC 码识别精度在-4~6dB 范围内的变化曲线。从图中可以看到,随着信噪比的增加,所有三种 LDPC 码的识别精度都在提高。这是因为信噪比的提高意味着接收信号中的噪声水平降低,从而使得解码器更容易准确地识别和解析码字。

在比较三种不同编码类型的 LDPC 码时,我们可以发现 DVB-S2 协议中的 LDPC 码表现出最佳的识别精度。这主要是由于 DVB-S2 协议中使用的 LDPC 码具有最长的码长。在长码长的情况下,BGRU-CNN 网络在训练过程中能够捕获更多的序列信息。这些信息不仅包括码字本身的结构特征,还包括隐藏在长序列中的复杂依赖关系和时间模式。因此,BGRU-CNN 在处理长码长 LDPC 码时具有更高的识别精度。相比之下,IEEE802.11 标准中的 LDPC 码具有最短的码长,因此在相同的信噪比条件下,其识别精度相对较低。这主要是因为短码长提供的序列信息较少,使得 BGRU-CNN 网络在训练过程中难以提取到足够的特征来进行准确的识别。

2.2 不同模型 LDPC 码编码类型识别对比

将本文提出算法与常见的基于深度学习的编码类型识别算法模型进行比较,包括 text-CNN^[9],LSTM^[11],Res-Net^[6],并根据对应文献来进行参数设置。




图7 BGRU-CNN 编码类型识别情况

Fig. 7 BGRU-CNN code type identification

图7呈现了本章所提BGRU-CNN算法与现有深度学习算法在LDPC(低密度奇偶校验)码编码类型识别性能上的比较结果。从图中可以清晰地观察到,在各种信噪比条件下,BGRU-CNN算法的性能始终优于现有算法,其最高识别率达到了约97.8%,显示出显著的优越性和鲁棒性。同时,该图也揭示了不同算法在不同信噪比条件下的性能差异和变化趋势。当信噪比较低时,LSTM的识别效果相对较好,优于text-CNN。这是因为在低信噪比条件下,噪声对信号的影响较大,使得信号的局部特征受到严重干扰。由于CNN类网络主要通过卷积操作提取局部特征,因此在这种情况下难以有效提取出有用的特征信息。而RNN类算法(如LSTM)通过捕捉序列前后的依赖关系来处理信号,能够在一定程度上抑制噪声的影响,因此在低信噪比条件下表现出更好的识别效果。

然而,当信噪比较高时,text-CNN的识别效果要优于LSTM。这是因为在高信噪比条件下,噪声对信号的影响相对较小,此时信号的局部特征变得更为清晰和突出。CNN类网络由于其强大的局部特征提取能力,能够更准确地捕捉到这些特征信息,并进行有效的分类和识别。而RNN类算法虽然也能处理序列数据,但在高信噪比条件下其性能优势不再明显。

而本文提出的BGRU-CNN算法综合了CNN类算法和RNN类算法的优势,从而提升了识别性能。BGRU-CNN算法通过结合双向门控循环单元(BGRU)和卷积神经网络(CNN)的结构特点,既能够捕捉到序列数据中的长期依赖关系,又能够有效地提取局部特征信息。这使得BGRU-CNN算法在处理LDPC码编码类型识别任务时,无论是在低信噪比还是高信噪比条件下,都能够表现出良好性能。

3 总结

本文提出了一种基于深度学习的LDPC码编码类型识别技术,即BGRU-CNN网络,用于完成对LDPC码的编码类型识别。BGRU-CNN算法将RNN和CNN的优势相结合,既能够捕捉到LDPC码字序列中的长期依赖关系,又能够准确地提取出局部特征信息。这种综合性的识别能力使得BGRU-CNN算法在处理LDPC码编码类型识别任务时表现出色。为了验证BGRU-CNN算法的有效性,本文还进行了大量的实验对比。实验结果表明,与其他深度学习的类型识别方法相比,BGRU-CNN算法在分类精度上取得了显著的优势。无论是在不同的信噪比条件下,还是在面对各种复杂的编码类型时,BGRU-CNN算法都能够准确地识

别出 LDPC 码的编码类型，为通信系统的解码和信号处理提供了有力的支持。

[参考文献] (References)

- 320 [1] 解辉, 黄知涛, 王丰华. 信道编码盲识别技术研究进展[J]. 电子学报, 2013
- [2] Gallager R G. Low-Density Parity-Check Codes. Cambridge, MA: MIT Press, 1963
- [3] Xia T, Wu H C. Novel blind identification of LDPC codes using average LLR of syndrome a posteriori probability [C] // 2012 12th International Conference on ITS Tele-communications, Taipei, IEEE. 2012:12-16
- 325 [4] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016.
- [5] Z. Yang, D. Yang, C. Dyer, X. He, A. Smola, and E. Hovy, "Hierarchical attention networks for document classification," in Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016, pp. 1480-1489.
- 330 [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR'16), June 2016.
- [7] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436-444, May 2015.
- [8] X. Qin, S. Peng, X. Yang and Y. -D. Yao, "Deep Learning based Channel Code Recognition using TextCNN," 2019 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN), 2019, pp. 1-5.
- 335 [9] Y. Ni, S. Peng, L. Zhou and X. Yang, "Blind Identification of LDPC Code Based on Deep Learning," 2019 6th International Conference on Dependable Systems and Their Applications (DSA), 2020, pp. 460-464.
- [10] Xia T, Wu H C. Joint blind frame synchronization and en-coder identification for low-density parity-check codes [J]. IEEE Communications Letters, 2014, 18(2):352-355.
- [11] B. Shen, H. Wu and C. Huang, "Blind Recognition of Channel Codes via Deep Learning," 2019 IEEE Global Conference on Signal and Information Processing (GlobalSIP), Ottawa, ON, Canada, 2019, pp. 1-5.