

基于闭集协议的非合作通信盲识别与解码技术研究

常雨涵, 李孝荣, 赵宏锋

(电信科学技术第四研究所有限公司, 西安 710061)

摘要: 非合作通信中, 编码方式的盲识别与后续解码环节通常被割裂研究, 且现有深度学习模型在多协议场景的低信噪比条件下鲁棒性不足。针对此问题, 本文提出一种时间卷积网络(Temporal convolutional network, TCN)-双向门控循环单元(Bidirectional gated recurrent unit, BiGRU)-attention深度学习混合模型, 构建了一体化盲解码框架。选取4类协议对应的5种编码方式构建实验数据集进行验证, 结果表明: 低信噪比条件下, 本文模型的编码识别准确率与抗噪鲁棒性显著优于现有对比模型; 基于识别结果进行的IEEE 802.16协议低密度奇偶校验(Low-density parity-check, LDPC)码解码实验, 进一步验证了一体化方案的有效性。

关键词: 信道编解码; 盲解码; 深度学习; 信息对抗; 非合作通信

中图分类号: TN92 **文献标志码:** A

引用格式: 常雨涵, 李孝荣, 赵宏锋. 基于闭集协议的非合作通信盲识别与解码技术研究[J]. 数据采集与处理, 2026, 41(4): 1089-1102. CHANG Yuhua, LI Xiaorong, ZHAO Hongfeng. Research on blind recognition and decoding technology for non-cooperative communications based on closed-set protocols[J]. Journal of Data Acquisition and Processing, 2026, 41(4): 1089-1102.

引言

在现代通信侦察系统中, 盲解码技术无先验信息的非合作通信场景中, 仅依赖接收序列分析出发端编码协议与参数, 旨在快速识别非合作方或未知通信系统的编码方式, 并根据其编码方式还原原始序列。该技术广泛应用于军事侦察、电子对抗等领域, 对破解未知通信协议、实现信息截获与还原至关重要, 可作为智能化通信对抗的关键支撑。

盲解码技术的核心是编码方式盲识别技术。经过几十年的发展, 盲识别技术从依赖人工定义规则与特征的传统方法, 向基于数据驱动自动学习的现代深度学习范式转变。传统的盲识别技术基于代数结构、统计特性进行生成矩阵的重构, 由于能够得到序列的生成矩阵, 这类研究通常构建识别与解码的一体化框架。黄丽^[1]基于代数理论及编码结构特性, 提出分阶段法、联合求取法、位置确定算法及沃尔什-哈达玛变换-分块矩阵(Walsh-Hadamard transform-block matrix, WHT-BM)算法, 实现了高误码率下的稳定参数估计。文献[2]提出一种开集识别算法, 基于符号级操作与伽罗华域上的高斯约当列消元算法, 通过内外部迭代流程融合解码与校验矩阵稀疏化。赵慧康^[3]提出改进秩准则法识别码长与码字起点、基于低列重求解对偶向量恢复线性约束关系、改进稀疏化算法重建校验矩阵的完整方案, 在无先验知识下提升高误码环境适应性, 实现了低密度奇偶校验(Low-density parity-check, LDPC)码有效识别。传统的盲识别方法虽然在构建了生成矩阵或校验矩阵后, 容易在此基础上进行解码处理, 但往往伴随识别种类少、计算复杂等问题。

随着深度学习的发展,基于深度学习的识别方法成为了研究的主要对象。文献[4]提出卷积神经网络(Convolutional neural network, CNN)-门控循环单元(Gate recurrent unit, GRU)混合深度学习模型,用于盲识别卷积码、Turbo码与LDPC码,在0~20 dB的信噪比(Signal-to-noise ratio, SNR)范围适配非协作通信场景,低SNR区域平均识别准确率达87%~90%, $\text{SNR} \geq 6$ dB时逼近90%。文献[5]提出一种基于深度学习的5G NR(New radio)极化编码物理下行控制信道高效盲检测方案,通过多层神经网络预测冻结比特位置并筛选候选者,在小幅降低检测精度的代价下显著减少解码延迟,可适配不同码长与下行控制信息(Downlink control information, DCI)长度,实现检测精度与延迟的灵活平衡。王宸^[6]针对非协作通信场景下的信道编码参数盲识别问题,提出改进CNN、长短时记忆网络(Long short-term memory, LSTM)、残差网络(Residual network, ResNet)及胶囊网络(Capsule network, CapsNet)等深度学习模型的识别方案,并结合小波变换、集合经验模态分解和奇异值分解降噪技术,提升高误码环境下的参数识别性能,为相关领域提供有效技术支撑。基于深度学习的盲识别算法是基于序列特征的识别,在识别过程中不构建生成矩阵,因此绝大多数研究以识别为主,没有构建整个盲解码框架。

综上所述,现有信道编码盲识别技术仍面临以下挑战:首先,现有基于深度学习的盲识别方法多聚焦于单一编码方式的识别算法改进^[7],鲜有研究从系统层面出发,构建完整的参数识别-编码方式盲识别-信道解码一体化的框架,编码识别与后续解码过程通常被割裂研究,缺乏将识别结果应用于解码过程的协同优化,导致实际系统效能受限;其次,LSTM、CNN等现有算法可识别的码型数量有限,大多仅支持3种或以下码型的盲识别,或是针对某种码型的识别——例如文献[5,8]仅针对低密度奇偶校验码或极化码一种码型进行识别,数据集比较简单;最后,传统算法识别率较低且对噪声极为敏感,尤其在小SNR环境下,误识别率高、鲁棒性不足的问题尤为突出,导致现有算法性能急剧下降,例如文献[9]指出CNN等简单模型难以满足实际复杂信道条件的需求。

图1展示了非合作通信的工作流程,虚线框中的流程是本文的主要内容,包含盲识别和解码。本文选取通信协议及其采用的编码方式为:IEEE802.11协议^[10]的LDPC码、IEEE 802.16协议的LDPC码、5G NR协议的Polar码,以及军用无线通信的Link 16下的RS(Reed-solomon)码和卷积码。本文采用时间卷积网络(Temporal convolutional network, TCN)-双向门控循环单元(Bidirectional gated recurrent unit, BiGRU)-attention的网络模型开展编码方式识别。该模型综合了TCN、BiGRU和注意力机制。由于每种编码方式需要搭建一个专用解码器,对5种编码方式均进行解码处理过于繁琐,故本文仅针对IEEE 802.16协议下的LDPC码进行解码处理。




图1 非合作通信流程图

Fig.1 Flowchart of non-cooperative communication

1 基于协议识别的盲解码一体化框架

本文首先通过参数识别获得编码方式盲识别前所需的编码参数,随后使用提出的新网络模型对信号进行识别,以解决低 SNR 环境下鲁棒性不足与识别率低的问题,最后进行解码处理,构建盲识别与解码的一体化框架。

1.1 参数识别

在编码方式识别和进行信道解码前,为了使用生成矩阵还原原序列,总码长与码率是必要的参数,因此需要通过参数识别的方法获得相关参数。本文使用了基于 GF(2)^[11]算法的参数识别模型,通过生成函数特征值与均方比的联合评估,实现对参数的高效识别。

对数似然比(Log-likelihood ratio, LLR)^[12]是衡量接收到的信号中比特为 0 或 1 的可能性的一个重要指标。它定义为接收到信号时,发送比特为 0 的概率与发送比特为 1 的概率之比的对数,即

$$\text{LLR} = \ln \frac{P(b=0|y)}{P(b=1|y)} \quad (1)$$

式中: $b=0$ 指发送比特为 0, $b=1$ 为发送比特为 1, y 为接收到的信号。根据贝叶斯定理可将对数似然比公式简化为

$$\text{LLR} = \frac{2y}{\sigma^2} \quad (2)$$

式中 σ^2 为噪声方差。LLR 的值大于 0 时,说明接收到的信号更可能对应发送比特 0; LLR 的值小于 0 时,说明接收到的信号更可能对应发送比特 1。

在得到对数似然比 LLR 后,通过双曲正切函数^[13]将其转换为生成函数基础值,即

$$g_{f_{\text{values}}} = \tanh\left(\frac{g_{\text{LLR}}}{2}\right) \quad (3)$$

双曲正切函数的取值范围是 $(-1, 1)$, 它将 LLR 的取值映射到一个有限的区间内。通过对 $g_{f_{\text{values}}}$ 与校验矩阵 H 的元素进行逐行相乘并累计得到生成函数特征值向量 $g_{f_{\text{features}}}$, 即

$$g_{f_{\text{features}_i}} = \prod_{j=1}^n (g_{f_{\text{values}_i}} \cdot H_{ij}) \quad \forall i \in [1, m] \quad (4)$$

式中: m 是校验矩阵的行数,生成函数特征值 $g_{f_{\text{features}_i}}$ 反映了第 i 个校验节点与所有相关变量节点之间的约束关系。当所有相关变量节点的 $g_{f_{\text{features}_i}}$ 与校验矩阵元素的乘积的累积结果较大时,说明这些变量节点满足该校验方程的可能性较大;反之,则说明不满足该校验方程的可能性较大。

均方比(Mean-square ratio, MSR)^[14]是本文参数盲识别算法中的一个关键评估指标,其定义为

$$\text{MSR} = \frac{\|g_{f_{\text{features}}}\|_2^2}{\text{Var}(g_{f_{\text{features}}}) + \epsilon} \quad (5)$$

式中: $\text{Var}(g_{f_{\text{features}}})$ 是生成函数特征值的方差, ϵ 是一个为防止除零错误而添加的小常数,通常取值为 10^{-8} 。

当校验矩阵与实际编码参数一致时,其代表的约束关系与信号编码结构匹配,生成函数特征值分布高度集中、方差小,此时分子大分母小,MSR 较大;反之,若二者不匹配,特征值分布分散、方差增大,MSR 相应减小。

本文通过上述参数识别算法获得码长、码率等关键参数,这些参数可为后续基于

TCN-BiGRU-attention的盲识别模型的训练与解码提供关键支撑。

1.2 TCN-BiGRU-attention模型的盲识别

参数识别环节的输出,为编码方式盲识别奠定了坚实的基础。所获得的码长、码率等参数,不仅限定了盲识别模型的分类空间,其本身亦可作为模型的特征输入,引导模型更精准地聚焦于与参数匹配的编码结构特征。为进一步提升在低 SNR 等复杂信道条件下的识别性能,本文构建了 TCN-BiGRU-attention 混合模型,该模型将利用已识别的参数,对接收序列的深层特征进行提取与分类,从而实现精确的盲识别。

TCN是一种擅长建模时间序列的网络结构,TCN模型以CNN模型^[15]为基础,并进行了两种改进:(1)适用序列模型:因果卷积(Causal convolution);(2)记忆历史:空洞卷积/膨胀卷积(Dilated convolution),残差模块(Residual block)。

膨胀卷积是TCN模型的核心,模型的感受野常受限于卷积核尺寸,传统CNN通常通过堆叠多层或引入池化层来扩大感受野,但池化操作可能导致信息丢失。膨胀卷积通过引入超参数膨胀率实现这一目标,该参数指的是卷积核元素之间的间隔数,可迅速扩大感受野,且无需依赖池化层,从而避免了信息丢失。

如图2,3所示,通过引入膨胀率超参数,卷积核的有效感受野得以指数级扩大。得益于这种机制,卷积网络仅需少量层级即可获得极大的感受野。然而,在深层网络中,若为追求更大感受野而持续叠加卷积层,则易引发梯度消失或梯度爆炸问题(尤其是梯度消失)。为此,本文引入了残差卷积模块,该结构允许梯度直接跨层传播,从而有效缓解了深层网络的训练难题。

BiGRU是GRU的改进结构,GRU是针对循环神经网络(Recurrent neural network, RNN)梯度消失和梯度爆炸问题的改进方案^[16],BiGRU由两个独立的GRU组成,通过同时对序列进行正向和反向处理,能够捕捉到更丰富的序列特征信息,在诸多任务中均表现出卓越性能。

训练过程中通过注入自适应高斯噪声提高模型的鲁棒性

$$\tilde{r}_t = r_t + \sqrt{\frac{E[r_t^2]}{10^{(\alpha - U(-5, 10))/10}}} \cdot n_t \quad (6)$$

式中: $\tilde{r}_t$ 为加噪声后的信号, r_t 为原始信号, n_t 来自标准高斯分布(均值为0,方差为1)的随机噪声, $E[r_t^2]$ 为原始信号 r_t 的平均能量,用于对噪声进行功率归一化^[17], α 为一个基准SNR值,用于在训练开始时对噪声功率进行归一化校准, $U(-5, 10)$ 为一个在区间 $(-5, 10)$ 内均匀分布的随机变量,用于在训练过程中动态调整SNR。

模型训练过程中,为了检索保存最优模型,需要计算损失函数,这里使用分类交叉熵




图2 传统CNN卷积与膨胀卷积
Fig.2 Traditional CNN convolution and dilated convolution




图3 CNN卷积与变间隔膨胀卷积卷积层的区别

Fig.3 Difference between of convolutional layers the CNN convolution and the variable-interval dilated convolution

(Categorical crossentropy)损失函数,引导模型优化,其数学定义为

$$L(y, \hat{y}) = - \sum_{i=1}^C y_i \lg(\hat{y}_i) \quad (7)$$

式中: y_i 为真实标签的 one-hot 编码向量(如类别 2 对应 $[0, 1, 0]$), $\hat{y}_i$ 为是模型输出的 softmax 概率分布(如 $[0.1, 0.8, 0.1]$), C 为类别总数(本文中为 3 类协议分类)。该函数衡量模型预测概率分布与真实分布的差异:当预测概率 $\hat{y}_i$ 接近真实标签 y_i 时,损失值趋近于 0;反之则惩罚增大(如预测错误时,负对数项导致损失骤增)。

注意力机制^[18]是一种常用的数据信息处理方法,常用在语音处理、图像识别等领域。注意力机制通常通过加权的方法对关键信息进行提取,其中权重的提取依赖 Query(查询)、Key(键)、Value(值)这 3 个核心。

本文实验使用了简化后的注意力机制,由于实验需要提高小 SNR 下的识别率,信号中掺杂的噪声较多,因此仅使用 Query 和 Value 两个核心,使用类“自注意力”的方式以消弱噪声对权重的干扰。其中,Query 为目前需要关注的目标,例如本文实验需要关注的是信号特征,则 Query 为信号特征;直接使用原始输入 inputs 作为 Value 序列,通过注意力权重加权求和得到上下文向量。

首先,使用线性变换与非线性激活生成中间特征,公式为

$$F_{\text{hidden}_1} = \tanh(F_{\text{inputs}} \times W_1 + b_1) \quad (8)$$

$$F_{\text{hidden}_2} = \tanh(F_{\text{hidden}_1} \times W_2 + b_2) \quad (9)$$

式中: F_{hidden_i} 指中间特征, F_{inputs} 指输入信号序列, W_i 指用以学习的权重矩阵, b_i 为偏置项,作用是能为线性变换提供“平移调整”的自由度。实验采用两次线性变换与非线性激活,使模型能够更精准地捕捉时序信号中的关键特征(如符号切换与载波跳变)。

随后需要计算注意力分数,以衡量每个时序位置的重要性,公式为

$$F_{\text{attention_scores}} = F_{\text{hidden}_2} \times W_V + b_V \quad (10)$$

式(10)中的 W_V 、 b_V 作用同式(8,9)中的权重矩阵和偏置项,矩阵乘法后,维度从 $B \times T \times U$ 压缩为 $B \times T \times 1$,每个时序位置 T 对应一个分数,表示该位置在当前任务中的重要性。

最后,通过归一化将分数转化为概率分布后,通过计算上下文向量加权聚合关键特征,计算公式为

$$F_{\text{context_vector}} = \sum_{t=1}^T (F_{\text{attention_weights}_t} \times F_{\text{inputs}_t}) \quad (11)$$

式中: $F_{\text{attention_weights}_t}$ 为第 t 个时间步的注意力分数归一化后的权重概率, F_{inputs_t} 指第 t 个时间步的序列特征,通过相乘对应的权重后逐元素相加得到最终特征。注意力机制通过“特征变换→分数计算→权重归一化→加权聚合”的数学流程,实现了对通信信号中有效信息的自动聚焦,为后续分类器提供更鲁棒的输入。

完整模型的详细流程图如图 4 所示。综上所述,本文构建的 TCN-BiGRU-attention 混合模型,通过 TCN 的强大时序特征提取与膨胀卷积所带来的宽广感受野、BiGRU 的双向上下文依赖捕捉以及 Attention 机制对关键信息的自适应加权,形成了一种协同增效的架构;统计特征经全连接层完成高阶映射与维度适配,与时序特征向量拼接融合,最终通过分类器完成特征降维、筛选与归一化处理,输出编码方式的识别概率。该模型能够从复杂的接收信号中鲁棒地提取深层特征,有效克服了低 SNR 环境下的识别挑战,为后续准确的信道解码奠定了坚实基础。

1.3 基于盲识别结果的解码验证

编码识别完成后,对接收序列进行信道解码。本文使用 IEEE 802.16 协议下的 LDPC 码,并重点研究最小和置信传播(Min-sum belief propagation, Min-Sum BP)解码算法^[19]。该算法是标准 BP 的简化

版,通过近似校验节点更新来降低复杂度,同时保留了核心的解码流程。

Min-Sum BP算法是BP算法的一种简化版本,它通过近似计算校验节点更新公式,减少了计算复杂度。Min-Sum BP算法的核心逻辑与BP算法相同,仅在校验节点更新时使用了近似计算。

变量节点更新:变量节点 j 发送给校验节点 i 的消息 $V_{i,j}$ 可以表示为

$$V_{i,j} = L_j + \sum_{k \in N(j) \setminus i} C_{k,j} \quad (12)$$

式中: $V_{i,j}$ 指变量节点 j 发送给校验节点 i 的消息; L_j 指变量节点 j 的初始LLR,反映接收到的比特是0或1的置信度; $N(j)$ 为与变量节点 j 相连的所有校验节点的集合。

校验节点更新:校验节点 i 发送给变量节点 j 的消息 $C_{i,j}$ 可以表示为

$$C_{i,j} = \text{Sign} \left(\prod_{k \in N(i) \setminus j} V_{i,k} \right) \min_{k \in N(i) \setminus j} |V_{i,k}| \quad (13)$$

式中: $C_{i,j}$ 指校验节点 i 发送给变量节点 j 的消息, $N(i)$ 是与校验节点 i 相连的所有变量节点的集合,

$\min_{k \in N(i) \setminus j} |V_{i,k}|$ 为这些消息的绝对值中的最小值。

在盲识别后,已经知悉编码后序列使用的标准协议与编码参数,在已知生成矩阵的情况下,解码过程即可依下述步骤展开。

在消息传递中,首先需要进行初始化输入,解码器以接收信号的LLR作为初始输入,LLR反映了每个接收比特为0或1的概率对数差^[20],基本计算公式如式(1)。

根据节点进行校验节点更新(符号与幅值分离处理),每个校验节点根据相连变量节点的消息,计算并发送更新后的消息至变量节点,核心步骤为:(1)符号乘积:计算除当前变量节点外所有输入消息的符号乘积($\text{prod}(\text{Sign}(V_{i,k}))$),反映校验方程的整体符号一致性;(2)最小绝对值:提取除当前变量节点外输入消息的最小绝对值($\min(|V_{i,k}|)$),近似校验方程的约束强度;(3)缩放因子:对结果乘以0.5(代码中显式设置),用于调整消息幅值,增强迭代稳定性,避免数值溢出。

最后,需要对迭代后的信息进行判决,通过硬判决($\text{sum}(V^{\text{new}}) < 0? 0 : 1$)生成候选码字,并通过校验子(Syndrome)检查^[21],即

$$S = H \cdot X \pmod{2} \quad (14)$$

式中: S 为校验子, H 为校验矩阵, $X \pmod{2}$ 指信号序列的模二形式。

若校验子全为0,则提前终止迭代(early_term=True),否则继续迭代直至达到最大次数(默认100次)。

综上所述,采用Min-Sum BP算法进行信道解码,在保持接近标准BP算法性能的同时,显著降低了计算复杂度,具备良好的工程可实现性。作为本文盲解码框架的最终执行环节,它有效地利用了前级盲识别所提供的协议与参数信息,将盲识别的结果转化为最终可用的解码数据,从而完整实现了“参数




图4 TCN-BiGRU-attention模型流程图

Fig.4 Flowchart of the TCN-BiGRU-attention model

识别-盲识别-信道解码”的一体化方案构想。

2 实验验证及结果分析

2.1 实验环境与实验数据集

2.1.1 实验环境

本实验所使用的硬件平台为计算机,具体配置如下:CPU为12th Gen Intel(R) Core(TM) i5-12450H (2.00 GHz)处理器;GPU为NVIDIA GeForce RTX 4060显卡,显存为16 GB。操作系统基于Windows 11使用Tensorflow构建算法框架,并通过Python编写代码。

2.1.2 数据集

由于缺少公开并受到广泛认可的数据集,本文在实验前自制了数据集,数据集通过Matlab R 2023b与Python 3.8生成。

数据集选取每种编码方式各11 000个样本,其中包含10 000个训练集和1 000个测试集,共55 000个样本。训练时通过添加动态噪声模拟不同SNR环境,SNR覆盖范围为-10~10 dB。具体的数据集参数如表1所示。

表1 数据集参数表
Table 1 Parameter table of dataset

协议类型	编码方式	码长	码率	调制方式
IEEE 802.11	LDPC	648, 1 296, 1 944	1/2, 2/3, 3/4, 5/6	二进制相移键控 (Binary phase shift keying, BPSK)
IEEE 802.16	LDPC	576, 2 304		
5G NR	Polar	256	可变	
Link16	RS	620	15/31	
	卷积码	600	1/2	

2.2 实验结果分析

2.2.1 对比实验与消融实验

通过训练与参数调优,获得了CNN、GRU、CNN-LSTM、BiGRU-CNN、TCN-BiGRU与TCN-BiGRU-attention这6种模型的最优权重参数,使用上述6种模型对测试集进行识别,得到了图5所示的多种模型在不同SNR下的识别准确率。由图5可以看出,本文提出的TCN-BiGRU-attention网络模型解决了低SNR下鲁棒性差、识别率低的问题,在0 dB时准确率即可近似达到100%,同时在SNR低于-5 dB时,该模型的识别准确率仍能保持在80%以上,识别性能显著优于其余5种对比模型。

在6种对比模型中,纯GRU与CNN-LSTM表现最差,均未充分拟合,识别准确率远低于其他模型,且未达100%。核心原因是结构缺陷与训练适配不足的双重影响:纯GRU为单向时序建模,丢失编码信号关键的反向约束特征;CNN-LSTM虽结合CNN与LSTM优势,但单向LSTM门控复杂,处理超长序列易梯度衰减,无法捕捉长距离时序关联。加之二者未针对小SNR、大噪声场景充分调优,抗




图5 多种模型在不同SNR下的准确率对比

Fig.5 Comparison of accuracy rates of various models under different SNRs

噪鲁棒性弱,难以从强噪声中剥离有效编码特征,最终无法收敛至最优状态。

本文通过消融实验逐步增加网络模型的复杂度,从加入 BiGRU 双向门控网络,到引入 TCN 时间卷积网络,最后融入注意力机制,并在每次模型深化后完成训练与验证。实验结果表明,在加入 BiGRU 双向门控网络后,模型的识别准确率实现小幅提升,这是由于模型深度的增加进一步强化了特征提取能力,可更充分地捕捉编码信号的双向时序关联特征^[22];在引入 TCN 时间卷积网络后,模型在小 SNR 区间的识别准确率得到明显改善,但随着训练推进,过拟合现象逐渐凸显,表现为训练集准确率快速趋近 100%,但验证集准确率在 $\text{SNR} < -5 \text{ dB}$ 区间波动幅度达 10% 以上,高 SNR 下验证集准确率比训练集低 5%~8%。

过拟合的具体原因在于:本实验输入信号为拟解调后的数字信号,其有效特征仅包含有限的码元时序、电平跳变等简单模式,而 TCN 采用 3 层因果卷积叠加残差连接的结构,参数规模远超信号特征的复杂度;当模型拟合完所有有效信号特征后,会被迫学习训练数据中随机噪声的分布,最终出现拟合噪声而非信号的过拟合问题。

为解决这一问题,本文首先对 TCN 进行轻量化优化:将原 3 层 64 通道的卷积核调整为 3 层 32 通道,削减 25% 的参数规模;同时在 TCN 每层后增加 Dropout 层、引入 L_2 正则化,并采用早停策略,从参数规模、训练约束层面抑制过拟合风险。在此基础上,进一步融入注意力机制,通过对编码信号的码元跳变、时序周期等关键特征分配高权重,对冗余噪声特征分配低权重,既避免模型过度学习噪声,又强化了有效特征的表征能力,最终彻底消除过拟合现象,得到在小 SNR 下能够保持高识别准确率的最优 TCN-BiGRU-attention 模型。

模型鲁棒性的优化逻辑在于结构协同与特征聚焦的双重增强:TCN 的因果卷积负责捕捉信号的局部时序跳变特征,BiGRU 的双向门控负责建模全局时序关联,二者结合可完整提取信号的有效时序模式,减少对噪声的依赖;注意力机制则在强噪声场景下优先聚焦有效特征,进一步削弱噪声干扰;叠加轻量化、正则化等过拟合优化措施后,模型的泛化能力显著提升,最终实现低 SNR 下 80% 以上的稳定准确率,抗噪鲁棒性大幅优于其他对比模型。

为分析各模型复杂度与鲁棒性,本文对训练完成的 6 种模型进行参数量与计算复杂度分析,结果如图 6 所示。由图 6 可以看出,以 CNN 为基准,各模型的参数量、计算复杂度、识别精准度与鲁棒性存在显著差异:GRU 参数量更低但计算复杂度偏高,抗噪声鲁棒性最差,低 SNR 场景下识别精度衰减严重;CNN-LSTM、BiGRU-CNN 参数量与 CNN 持平,计算复杂度小幅上升,强噪声环境下鲁棒性改善有限;TCN-BiGRU 参数量、计算复杂度有所增加,低 SNR 下精度衰减趋势放缓。

TCN-BiGRU-attention 展现出最优综合性能:其参数量与计算复杂度增幅完全可控,却凭借 TCN、BiGRU 与注意力层的协同作用,实现了精准度与鲁棒性的双重突破。该模型在全 SNR 区间识别精度稳居首位,尤其在 -10 dB 等高噪声场景下,抗干扰鲁棒性极强。整体而言,该模型以可控的复杂度提升,达成了识别精准度与噪声鲁棒性的同步优化,实现了模型效率、性能与环境适应性的最佳平衡。

综上所述,针对覆盖大 SNR 范围、包含多种编码方式且样本量充足的数据集,结构更为复杂的模型对编码信号的深层特征提取具备显著优势;而针对覆盖小 SNR 范围、样本量较少的数据集,过度复杂的模型易对噪声特征进行过度提取,进而引发过拟合现象。纯 GRU 与 CNN-LSTM 这类结构存在先天局限、对训练配置敏感度较高的模型,在未完成充分参数调优与结构适配的情况下,难以适配小 SNR、大噪声范围的编码盲识别场景。因此,模型的选型、结构设计与参数调优工作必须紧密结合具体实验环境与数据特征,通过多模型对比验证与反复调试优化,才能获得适配目标场景的最优模型。





图6 各模型可训练参数量与计算复杂度对比图

Fig.6 Comparison of trainable parameters and computational complexity across models

2.2.2 各模型准确率分析

为分析实验中各网络模型的识别准确率,将识别准确率可视化,生成SNR为0 dB的实验背景下的所有模型的盲识别混淆矩阵,如图7所示。

根据各种模型在SNR为0 dB的实验背景下的混淆矩阵可以看出:首先,对于特征存在部分相似性的IEEE 802.11与IEEE 802.16协议,多数模型存在小幅度误识别,CNN模型中802.11误判为802.16共






图7 各模型在SNR为0 dB时的盲识别混淆矩阵

Fig.7 Confusion matrix of blind recognition of each model at 0 dB SNR

9个,BiGRU-CNN有21个802.11误判为802.16、1个802.16误判为802.11,CNN_LSTM有11个802.11误判为802.16、1个802.16误判为802.11,而GRU的误识别幅度最明显;其次,针对Link 16协议下特征相近的RS与Conv编码方式,所有模型均存在误识别,但差异显著:TCN-BiGRU的误识别最严重,CNN-LSTM与GRU的误识别幅度也较大,而CNN、BiGRU-CNN的误识别相对轻微,TCN-BiGRU-attention的误识别最少。

综上,本文提出的TCN-BiGRU-attention模型,既在SNR低于0 dB的低噪声场景下保持了较高识别率,又在0 dB这类较高SNR场景中,相比其余5种模型仍具备微弱但稳定的识别优势。

2.2.3 注意力机制可视化分析

根据上文消融实验结果可知,注意力机制对准确率提高有明显作用,为了分析注意力机制作用的位置与权重大小,实验中采样了部分序列,并将该序列下的注意力权重可视化,如图8,9所示。




图8 IEEE 802.16协议下样本的注意力权重分布

Fig.8 Attention weight distribution of samples under IEEE 802.16 protocol




图9 Polar协议下样本的注意力权重分布

Fig.9 Attention weight distribution of samples under Polar protocol

根据图中信息分析,注意力机制权重在有信号时明显提高,并在信号某些位置有大幅提升,该现象表明在有信号序列出现时注意力机制能够捕捉信号特征,并根据特征重要性加权处理。在每次信号结束后同样有权重大幅度提升的现象,这表明注意力机制在提取信号时序特征。综上所述,注意力机制对主要特征加权处理,减少了模型训练时的过拟合风险,有效优化了模型质量。

2.2.4 信道解码

经过编码方式盲识别后,使用获得的编码参数与协议信息进行解码处理,本文对 IEEE 802.16 协议下的 LDPC 码进行解码处理,采用 Min-Sum BP(最小和置信传播)算法,在不同 SNR 条件下进行仿真,得到其误码率性能,如图 10 所示。从图 10 可以看出,2.5 dB 处为误码率拐点,本质是算法的缩放因子与迭代终止策略协同作用的结果。Min-Sum BP 引入缩放因子补偿消息幅值高估问题,在 2.5 dB 前,噪声导致 LLR 偏差较大,缩放因子的补偿效果有限;当 SNR 超过 2.5 dB 后,LLR 置信度足够高,缩放因子可精准修正校验节点消息,同时“校验子全 0 终止”策略减少无效迭代,避免消息传递中的累积误差,最终使误码率稳定在极低水平达到 1×10^{-3} 以下,能够满足解码需求。




图 10 不同 SNR 下的解码误码率

Fig.10 Decoding bit error rate under different SNRs

3 结束语

本文针对 IEEE 802.11、IEEE 802.16、5G NR 及 Link 16 这 4 类协议对应的 5 种编码方式,开展了基于深度学习的盲识别与解码一体化研究。在模型层面,TCN-BiGRU-attention 网络通过时间卷积提取局部时序跳变特征、双向门控网络建模全局上下文依赖、注意力机制自适应抑制噪声干扰,三者的层级化协同使得模型在 $-10 \sim 0$ dB 的低 SNR 区间仍保持 80% 以上的识别准确率,较 CNN、GRU 等对比模型提升约 20%。消融实验进一步表明,注意力机制对过拟合的抑制效果最为显著,是模型在强噪声条件下保持稳定泛化能力的关键环节。在解码层面,基于盲识别所获参数,采用 Min-Sum BP 算法对 IEEE 802.16 LDPC 码进行解码,在 $\text{SNR} > 2.5$ dB 时误码率降至 1×10^{-3} 以下,验证了前级识别结果对解码环节的有效支撑^[23-24]。

本文所提框架贯通了“参数识别-编码盲识别-信道解码”的全链路处理流程,其系统级设计思路与实验结论可为非合作通信侦察及通信对抗领域的工程实践提供参考。后续研究将拓展至更多协议类型及非闭集识别场景,并探索模型轻量化部署方案。

参考文献:

- [1] 黄丽. 基于代数结构的交织器与卷积码的盲识别研究[D]. 合肥: 中国科学技术大学, 2016.
HUANG Li. Blind recognition of interleavers and convolutional codes based on algebraic structures[D]. Hefei: University of Science and Technology of China, 2016.
- [2] JIANG M, HUANG D, LIU S, et al. Open-set blind recognition of non-binary LDPC codes[J]. *Digital Communications and Networks*, 2025, DOI:10.1016/j.dcan.2025.10.004.
- [3] 赵慧康. 基于非协作通信场景下的LDPC码识别研究[D]. 西安: 西安电子科技大学, 2019.
ZHAO Huikang. Research on LDPC code identification in non-cooperative communication scenarios[D]. Xi'an: Xidian University, 2019.
- [4] SINGH B. Deep learning-based blind identification of channel coding schemes[C]//*Proceedings of the 3rd International Conference on Device Intelligence, Computing and Communication Technologies (DICCT)*. [S.l.]: IEEE, 2025: 598-602.
- [5] TALHA M, ELSAYED K M F. Efficient blind detection for 5G NR polar-coded physical downlink control channels using deep learning[C]//*Proceedings of the 6th Novel Intelligent and Leading Emerging Sciences Conference (NILES)*. [S.l.]: IEEE, 2024: 423-426.
- [6] 王宸. 非协作通信下的信道编码参数盲识别[D]. 南京: 东南大学, 2021.
WANG Chen. Blind identification of channel coding parameters under non-cooperative communication[D]. Nanjing: Southeast University, 2021.
- [7] 战权海, 张雄伟, 宋磊, 等. 基于改进Transformer的自动调制识别方法[J]. *数据采集与处理*, 2024, 39(6): 1410-1419.
ZHAN Quanhai, ZHANG Xongwei, SONG Lei, et al. An automatic modulation recognition method based on improved Transformer[J]. *Journal of Data Acquisition and Processing*, 2024, 39(6): 1410-1419.
- [8] 李欣宇. LDPC码编码盲识别技术研究[D]. 北京: 北京邮电大学, 2024.
LI Xinyu. Research on blind recognition technology of LDPC codes encoding [D]. Beijing: Beijing University of Posts and Telecommunications, 2024.
- [9] 杨壮. LDPC码信号盲识别算法研究[D]. 武汉: 华中科技大学, 2024.
YANG Zhuang. Research on blind recognition algorithm for LDPC code signals[D]. Wuhan: Huazhong University of Science and Technology, 2024.
- [10] CHOI B, JUNG D, LIM H. Interframe spacing adaptation method for IEEE 802.11 WLANs coexisting with IEEE 802.16 networks[C]//*Proceedings of 2011 IEEE 36th Conference on Local Computer Networks*. [S.l.]: IEEE, 2011: 299-302.
- [11] 黄裕青, 李华锋, 原铭, 等. 基于卷积神经网络梯度和纹理补偿的单幅图像超分辨率重建[J]. *数据采集与处理*, 2023, 38(5): 1112-1124.
HUANG Yuqing, LI Huafeng, YUAN Ming, et al. Single-image super-resolution reconstruction based on convolutional neural network gradients and texture compensation [J]. *Journal of Data Acquisition and Processing*, 2023, 38(5): 1112-1124.
- [12] 郑仁乐, 李东阳, 刘文学, 等. LDPC码的分层自适应最小和译码算法[J]. *系统工程与电子技术*, 2024, 46(12): 4231-4237.
ZHENG Renle, LI Dongyang, LIU Wenxue, et al. The hierarchical adaptive minimum sum decoding algorithm for LDPC codes [J]. *Systems Engineering and Electronics*, 2024, 46(12): 4231-4237.
- [13] 陈逸凡. LDPC编码盲识别技术研究[D]. 西安: 西安电子科技大学, 2021.
CHEN Yifan. Research on blind recognition technology of LDPC coding [D]. Xi'an: Xidian University, 2021.
- [14] JOUNG J, JUNG B C. Machine learning based blind decoding for space-time line code (STLC) systems[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(5): 5154-5158.
- [15] 姜科宇. 基于深度学习的非协作通信信道编码识别[D]. 成都: 电子科技大学, 2023.
JIANG Keyu. Channel coding recognition for non-cooperative communication based on deep learning[D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [16] YU P, PENG H, LI J. On blind recognition of channel codes within a candidate set[J]. *IEEE Communications Letters*, 2016, 20(4): 736-739.
- [17] UPADHYAY S, YADAV G, TRIGUNE R, et al. Attention based encoding and decoding for convolutional neural networks

- [C]//Proceedings of 2019 International Conference on Smart Systems and Inventive Technology (ICSSIT). [S.l.]: IEEE, 2019: 600-604.
- [18] 王登天,周华,钱荷玥. LDPC 自适应最小和译码算法及其FPGA实现[J]. 计算机科学, 2021, 48(S1): 608-612.
WANG Dengtian, ZHOU Hua, QIAN Heyue. LDPC adaptive minimum sum decoding algorithm and its FPGA implementation [J]. Computer Science, 2021, 48(S1): 608-612.
- [19] AMIRZADE F, SADEGHI M R, PANARIO D. Construction of protograph-based LDPC codes with chordless short cycles [J]. IEEE Transactions on Information Theory, 2023, 70(1): 51-74.
- [20] 胡国翔. WiFi6 系统中 QC-LDPC 编解码器设计与验证[D]. 西安: 西安电子科技大学, 2023.
HU Guoxiang. Design and verification of QC-LDPC encoder/decoder in WiFi6 system[D]. Xi'an: Xidian University, 2023.
- [21] ZHANG Y, SONG G, LI Y, et al. Signal scrambling based joint blind channel estimation, activity detection, and decoding for massive random access[J]. IEEE Transactions on Wireless Communications, 2024, 23(8): 9629-9642.
- [22] 李峰,杨岳松,李生权. 基于分数阶滤波器和BiGRU神经网络的Wiener非线性系统建模与辨识[J]. 控制理论与应用, 2025, 42(6):1181-1190.
LI Feng, YANG Yuesong, LI Shengquan. Modeling and identification of Wiener nonlinear systems based on fractional-order filters and BiGRU neural networks [J]. Control Theory & Applications, 2025, 42(6): 1181-1190.
- [23] USMAN S, MANSOUR M M, CHEHAB A. A multi-Gbps fully pipelined layered decoder for IEEE 802.11 n/ac/ax LDPC codes[C]//Proceedings of 2017 IEEE Computer Society Annual Symposium on VLSI (ISVLSI). [S.l.]: IEEE, 2017: 194-199.
- [24] 丁卓. 基于FPGA的LDPC编译码器的设计与实现[D]. 北京: 北京邮电大学, 2023.
DING Zhuo. Design and implementation of LDPC encoder and decoder based on FPGA[D]. Beijing: Beijing University of Posts and Telecommunications, 2023.

作者简介:



常雨涵(2000-),男,硕士研究生,研究方向:电磁场与微波技术,E-mail:s308614542@163.com。



李孝荣(1982-),男,高级工程师,研究方向:微波通信、信号处理等,E-mail:324014251@qq.com。



赵宏锋(1970-),通信作者,男,正高级工程师,博士,研究方向:通信对抗、微波专用无线通信等,E-mail:2563914009@qq.com。

(编辑:陈瑒)

Research on Blind Recognition and Decoding Technology for Non-cooperative Communications Based on Closed-Set Protocols

CHANG Yuhan, LI Xiaorong, ZHAO Hongfeng*

(The Fourth Institute of Telecommunications Science and Technology Co., Ltd, Xi'an 710061, China)

Abstract: Blind decoding is the core technique to recover the original data sequence without any prior information in non-cooperative communication scenarios. However, the absence of prior information poses severe challenges to blind decoding, making the integrated implementation of blind recognition of channel coding scheme and blind decoding a critical and urgent problem to be solved in this field. In current wireless communication systems, limited and fixed standard protocols are widely adopted, and specific protocols have a strong binding relationship with their corresponding channel coding schemes. Therefore, the coding scheme adopted by the communication system can be inferred through the blind recognition of the communication protocol. To address the above challenges, this paper proposes a novel hybrid deep learning network model, and constructs an integrated solution for blind recognition of channel coding and blind decoding. Numerical experimental results demonstrate that, under low signal-to-noise ratio regimes, the proposed model achieves higher recognition accuracy of channel coding and stronger anti-noise robustness compared with conventional schemes. This work provides a new technical approach for the research of blind decoding technology, and also supplies theoretical and experimental support for engineering applications in the field of information countermeasures.

Highlights:

1. This paper proposes an integrated framework for blind recognition and decoding that unifies parameter estimation, coding scheme identification and channel decoding, addressing the problem of information loss and procedural disconnection in non-cooperative communications.
2. A novel TCN-BiGRU-attention hybrid deep learning model is constructed, which enhances coding scheme identification accuracy and noise robustness under low signal-to-noise ratio conditions by effectively capturing temporal features and focusing on key information.
3. The proposed framework successfully performs blind recognition of coding schemes for multiple closed-set protocols, including IEEE 802.11/802.16, 5G NR, and Link16, and validates the feasibility of integrated decoding based on recognition results.

Key words: channel encoding and decoding; blind decoding; deep learning; information countermeasures; non-cooperative communications