

一种模型驱动的 LDPC 码译码方法

王宝祥¹ 陈斌杰²

WANG Baoxiang CHEN Binjie

摘要

针对对数似然比置信传播 (log-likelihood ratio belief propagation, LLR BP) 译码算法对短码长的低密度奇偶校验 (low density parity check code, LDPC) 码译码性能差的问题, 提出了一种基于 LLR BP 译码算法的深度神经网络译码器。根据 Tanner 图构建深度神经网络模型, 利用深度学习优化边的权重来缓解短环造成的影响, 提升译码性能。此外, 网络采用了迁移学习的训练思想并添加批量归一化 (batch normalization, BN) 层来加快网络收敛。仿真结果表明, 所提出方法构建的深度神经网络收敛速度较快, 并且与传统 BP 译码算法相比, 对于短码长 LDPC 码译码性能有明显提升。

关键词

LDPC 码; 信道译码; 深度学习; 模型驱动; 迁移学习

doi: 10.3969/j.issn.1672-9528.2024.06.011

0 引言

低密度奇偶校验 (low density parity check code, LDPC) 码是一类具有稀疏校验矩阵的线性分组码, 其不仅有逼近香农极限的良好性能, 而且具有译码复杂度较低、结构灵活、低错误平层等优点, 被广泛应用于深空通信、光纤通信、卫星数字视频和音频广播等领域^[1-2]。在传统的 LDPC 码软判决迭代译码算法中, 随着码字长度的增加, 译码性能愈发优秀, 然而在中、短码长情景下, 译码性能不理想, 仍有可提升的空间^[3]。

近年来, 随着深度学习在各种任务中表现出优异的性能, 部分国内外学者将深度学习与信道编译码结合, 以期提升译码性能^[4-14]。其中, 神经网络构造思路大致有两种: 一种是直接利用经典 NN 结构构造网络, 也被称为基于数据驱动的神经网络; 另一种则是通过已有迭代算法加上可训练参数来构造网络, 一般称之为基于模型驱动的神经网络^[15]。后一种网络可以结合神经网络和传统译码算法的优势, 在保持原有算法结构的情况下, 利用神经网络的反向传播算法优化原有译码模型, 在数学层面的可解释性更好, 具有更高的稳定性。

文献 [4] 结合深度神经网络的自适应学习能力和 Tanner 图提供的迭代结构, 针对 BCH 码译码, 实现了比传统 BP 译码更好的误比特率。文献 [5] 将深度展开方法应用于改进 OMS 算法, 也得到了较好的效果。文献 [10] 基于文献 [4] 中提出的神经网络 BP 译码算法, 通过考虑 Tanner 图中权重的重要性, 裁剪掉网络中不重要的校验节点, 在降低译码复杂

度的同时实现了接近最大似然译码的译码性能。文献 [9] 针对脉冲信道下短码时 BP 算法译码性能差的问题, 通过构建深度前馈网络模型和循环神经网络模型, 对 Tanner 图中边的权重重新赋值来提高译码性能。本文提出了一种模型驱动的 LDPC 码译码方法, 以 Tanner 图中节点的连接构建深度神经网络模型, 通过迁移学习优化网络训练过程, 提高译码性能。

1 传统 LDPC 码译码算法

1.1 BP 译码算法

置信度传播 (belief propagation, BP) 译码算法是目前常用的 LDPC 码软判决译码算法之一。该算法是一种迭代算法, 其译码过程分为四个步骤: 初始化、校验节点更新、变量节点更新和译码硬判决, 可以用 Tanner 图表示信息在节点间的传递^[16]。初始化时, 将信道接收值作为译码的输入。校验节点更新时, 校验节点通过处理从相连的变量节点传递的信息来更新校验节点原有信息。变量节点更新时, 变量节点计算从相连的校验节点传递的信息来更新变量节点原有信息。当达到最大迭代次数或满足校验方程时, 迭代终止, 此时变量节点收集可利用的消息进行硬判决译码。

设编码后码长为 n 的码字为 $c = [c_1, c_2, \dots, c_n]$, 经 BPSK 调制后映射成双极性信号 $x = [x_1, x_2, \dots, x_n]$ 后, 经过信道后接收到的信号为 $y = [y_1, y_2, \dots, y_n]$, 其中 $y_i = x_i + n_i$, n_i 是均值为 0, 方差为 σ^2 的高斯白噪声。

信源等概率分布时, BP 译码步骤如下。

(1) 初始化: 计算初始概率, 并将其传递给变量节点。

$$q_{ij}(1) = P(c_i = 1 | y_i) = \frac{1}{1 + \exp(\frac{2y_i}{\sigma^2})} \quad (1)$$

1. 哈尔滨工程大学 黑龙江哈尔滨 150001

2. 北京遥感设备研究所 北京 100000

$$q_{ij}(0) = P(c_i = 0 | y_i) = \frac{1}{1 + \exp(\frac{-2y_i}{\sigma^2})} \quad (2)$$

式中： q_{ij} 表示变量节点*i*传递给校验节点*j*的外部概率信息。

(2) 校验节点更新

$$r_{ij}(0) = \frac{1}{2} + \frac{1}{2} \prod_{i' \in R_j \setminus i} (1 - 2q_{i'j}(1)) \quad (3)$$

$$r_{ij}(1) = \frac{1}{2} - \frac{1}{2} \prod_{i' \in R_j \setminus i} (1 - 2q_{i'j}(1)) \quad (4)$$

式中： r_{ij} 表示校验节点*j*传递给变量节点*i*的外部概率信息。

(3) 变量节点更新

$$q_{ij}(0) = K_{ij} P_i(0) \prod_{j' \in C_i \setminus j} r_{ji'}(0) \quad (5)$$

$$q_{ij}(1) = K_{ij} P_i(1) \prod_{j' \in C_i \setminus j} r_{ji'}(1) \quad (6)$$

式中： K_{ij} 是校正因子，使得 $q_{ij}(0) + q_{ij}(1) = 1$ 。

(4) 后验概率更新与判决

$$q_i(0) = K_i P_i(0) \prod_{j \in C_i} r_{ji}(0) \quad (7)$$

$$q_i(1) = K_i P_i(1) \prod_{j \in C_i} r_{ji}(1) \quad (8)$$

式中： K_i 是校正因子，使得 $q_i(0) + q_i(1) = 1$ 。若 $q_i(1) > q_i(0)$ ，则 $\hat{c}_i = 1$ ，否则 $\hat{c}_i = 0$ 。

(5) 迭代终止

达到迭代终止条件，迭代终止，否则继续从步骤(2)开始下一次迭代。

1.2 LLR BP 译码算法

对于二元 LDPC 码，将概率信息用对数似然比(log-likelihood ratio, LLR)表示，可以简化概率 BP 译码算法迭代过程中的大量乘法运算，降低复杂度，译码步骤如下。

(1) 信道初始消息

$$L(P_i) = \ln \frac{P_i(0)}{P_i(1)} = \ln \frac{P(x_i = 1 | y_i)}{P(x_i = -1 | y_i)} \quad (9)$$

(2) 校验节点传递给变量节点的消息

$$L(r_{ji}) = \ln \frac{r_{ji}(0)}{r_{ji}(1)} = 2 \tanh^{-1} \left(\prod_{i' \in R_j \setminus i} \tanh \left(\frac{1}{2} L(q_{i'j}) \right) \right) \quad (10)$$

(3) 变量节点传递给校验节点的消息

$$L(q_{ji}) = \ln \frac{q_{ji}(0)}{q_{ji}(1)} = L(P_i) + \sum_{j' \in C_i \setminus j} L(r_{ji'}) \quad (11)$$

(4) 变量节点收集到的消息

$$L(q_i) = \ln \frac{q_i(0)}{q_i(1)} = L(P_i) + \prod_{j \in C_i} L(r_{ji}) \quad (12)$$

若 $L(q_i) > 0$ ，则 $\hat{c}_i = 0$ ，否则 $\hat{c}_i = 1$ 。

(5) 迭代结束

达到最大迭代次数或 $H_c^T = 0$ ，迭代结束。

2 基于模型驱动的 LDPC 码译码算法

LDPC 短码的 Tanner 图中存在大量短环，在 BP 译码时破坏传递信息之间的独立性，导致译码性能恶化。基于模型驱动的 LDPC 码译码算法可以结合神经网络和传统译码算法的优势，以 Tanner 图为网络结构基础，将 BP 译码算法中的迭代过程表示为各网络层，通过对神经网络的训练，利用神经网络的反向传播算法优化原有译码模型，对 Tanner 图中传递的信息进行加权，以缓解译码性能恶化。

2.1 系统模型

采用模型驱动的神经网络 LDPC 译码器总体框架如图 1 所示。编码部分将 k 位信息位编码成码长为 n 的码字，并对其 BPSK 调制，信道传输部分对信号添加加性高斯白噪声来模拟实际信道传输过程，然后计算信道 LLR 值，将计算后的结果输入到神经网络译码器中。




图 1 系统模型

以码长为 8、码率 3/4 的 LDPC 码为例，图 2 是其对应的 Tanner 图。将 BP 译码过程展开，以一个神经元代表 Tanner 图中的一条边，组成为各个网络层，网络结构如图 3 所示。




图 2 (8, 6) LDPC 码 Tanner 图




图 3 (8, 6) LDPC 码网络结构

图 3 中,以神经元替代原有译码算法中变量节点、校验节点的迭代计算,其中隐藏层 1、隐藏层 3 作为校验层,表示 Tanner 图中校验节点的更新,隐藏层 2、隐藏层 4 作为变量层,表示 Tanner 图中变量节点的更新。相邻的两层隐藏层表示信息从校验节点传递到变量节点,再从变量节点传递到校验节点,即 BP 译码算法中的一次迭代。

2.2 优化神经网络模型

在一定条件下,译码算法迭代次数的增加能有效提高译码性能、降低误码率,但随着神经网络对应迭代次数的增加,神经网络的深度也逐渐增加,深度的增加使得网络收敛难度大大增加。为了降低网络模型的训练难度,采用了迁移学习的思想进行训练,并为加快网络收敛,在网络中添加批量归一化(batch normalization, BN)层。

首先,构建一个仅由一层校验层、一层变量层构成的浅层神经网络模型并进行训练,由于网络规模较小,收敛速度显著提高。

然后,将训练好的模型参数保留,通过设置冻结防止在后续训练过程中被更新。在训练好的浅层网络模型的基础上,增加更多的网络层,以深度神经网络实现更多次的译码迭代,并进行训练。训练过程如图 4 所示。




图 4 网络训练过程

最后,为网络添加 BN 层。BN 层是深度神经网络中一种广泛应用的层类型,它通过对每一层神经网络的输入信号进行标准化处理,来解决深层神经网络在训练过程中内部协变量变化导致的问题,从而加快网络收敛,大幅提升深层网络的训练效率和性能。在以模型驱动的神经网络 LDPC 码译码模型中,由于神经元数量与 Tanner 图中的连线数、选定的迭代次数有关,当码长较长时,网络规模将比较庞大,网络训练困难。因此,在译码模型中添加 BN 层加快网络收敛。对应的网络结构如图 5 所示。



图 5 优化神经网络模型

BN 层通常被放置在线性激活函数之前,这样能够确保激活函数接收到的输入具有更稳定的均值和方差,因此将

BN 层放置在每次迭代即每个偶数隐藏层之后,既能使下一隐藏层即下一次迭代译码的输入更稳定,避免内部协变量偏移问题,又能够保持类似 Tanner 图的译码结构。

3 仿真结果与分析

本文中的基于模型驱动的 LDPC 码译码器基于 PyTorch 框架构建,程序使用 Python 语言编写,使用了英伟达公司的 A5000 系列 GPU 来加快训练速度。网络参数设置如表 1 所示。

表 1 网络参数

网络模型	网络层	优化算法	损失函数	学习率	Batch size
BP Net	输入层、5 层校验层、5 层变量层、输出层	Adam	MSE Loss	0.001	400
优化的 BP Net	输入层、5 层校验层、5 层变量层、5 层 BN 层、输出层	Adam	MSE Loss	0.001	400

3.1 数据集生成

本数据集以模拟 AWGN 信道下译码器接收到的码字作为训练和测试数据集。生成方法如下:使用伪随机数生成器生成信息比特序列,对比特序列采用高斯消元法进行编码,得到训练集的标签值,将编码后的码字进行映射,将其转换为双极性码,模拟通信系统中的 BPSK 调制步骤,按照预设的信噪比区间加入高斯白噪声,并计算对数似然比,得到网络输入。

3.2 译码性能分析

使用 LLR BP 译码算法和神经网络译码模型,分别对 $R=1/2$ 的 LDPC 码进行译码,仿真结果如图 6 所示。




图 6 (16, 8) LDPC 码误码率曲线

使用误比特率 (bit error rate, BER) 作为纵坐标进行分析比较。在负数信噪比的条件下,对比其误比特率,优化的 BN Net 模型与 BP Net 模型性能接近,对比 LLR BP 译码算

法都有显著提高。在低信噪比的条件下,优化的 BN Net 模型较 LLR BP 译码算法性能有显著提升,最大提升约 2 dB,对比 BN Net 模型也有近 0.5 dB 的提升。在较高信噪比条件下,优化的 BN Net 模型译码性能相比 LLR BP 译码算法有近 1 dB 的提高。

图 7 展示了两种网络模型收敛速度对比,可以看到,优化的 BP Net 模型收敛速度显著提高。




图 7 模型收敛速度曲线

4 结语

本文研究了基于模型驱动的 LDPC 码译码算法,针对短码时传统 BP 译码算法性能差的问题,基于 LLR BP 译码算法构建了基于模型驱动的神经网络模型,利用神经网络的反向传播算法优化 Tanner 图中边的权重,缓解了短码时译码算法性能恶化问题,并针对深度神经网络不容易收敛的问题,优化了神经网络结构,加快了网络收敛,降低了训练难度。仿真实验表明,在短码时,基于模型驱动的神经网络模型相较于传统 BP 译码算法性能有显著提升,优化的神经网络模型在译码性能上有所提高的同时,网络收敛速度大大加快。

参考文献:

- [1]VATTA F, SORANZO A, COMISSO M, et al.A survey on old and new approximations to the function $\phi(x)$ involved in LDPC codes density evolution analysis using a gaussian approximation[J].Information,2021,12(5):212.
- [2]LI F, ZHANG C, PENG K, et al.Review on 5G NR LDPC code:recommendations for DTTB system[J].IEEE access, 2021, 9: 155413-155424.
- [3]梁冠强.基于深度学习的短码长 LDPC 译码研究[D].广州:华南理工大学,2019.
- [4]NACHMANI E, BE'ERY Y, BURSHTEN D. Learning to decode linear codes using deep learning[C]//2016 54th

- Annual Allerton Conference on Communication,Control,and Computing,[v.1].Piscataway:IEEE,2016:341-346.
- [5]LUGOSCH L, WARREN J G.Neural offset min-sum decoding[C]//2017 IEEE International Symposium on Information Theory,[v.1].Piscataway:IEEE,2017:1361-1365.
- [6]NACHMANI E, MARCIANO E, LUGOSCH L, et al.Deep learning methods for improved decoding of linear codes[C]//IEEE Journal of Selected Topics in Signal Processing(Volume: 12,Issue:1,February 2018).Piscataway:IEEE,2018:119-131.
- [7]LUGOSCH L.Learning algorithms for error correction[EB/OL].(2018-01-04)[2024-02-23].<https://www.semanticscholar.org/paper/Learning-Algorithms-for-Error-Correction-Lugosch/7a9b11c7e8936f17c14f5a5dbd890f1a695d3a28>.
- [8]LEWANDOWSKY J, BAUCH G.Information-optimum LDPC decoders based on the information bottleneck method[J].IEEE access, 2018,6:4054-4071.
- [9]潘睿,袁磊.脉冲信道下基于深度学习的 BP 译码方法[J].系统工程与电子技术,2020,42(9):2116-2122.
- [10]BUCHBERGER A, HAGER C, PFISTER H D, et al.Pruning neural belief propagation decoders[EB/OL].(2020-01-21)[2024-02-23].<https://doi.org/10.48550/arXiv.2001.07464>.
- [11]冯俊鹏.LDPC 码神经网络译码模型研究[D].成都:西南交通大学,2021.
- [12]张丽.基于深度学习的信道译码技术研究[D].西安:西安电子科技大学,2021.
- [13]CHU L, HE H, PEI L, et al. NOLD: a neural-network optimized low-resolution decoder for LDPC codes[J].Journal of communications and networks, 2021,23(3):159-170.
- [14]万飞,白宝明,朱敏.多元 LDPC 编码调制系统 CNN 辅助迭代检测译码算法[J].无线电通信技术,2022, 48(4): 673-679.
- [15]黄启圣.基于深度学习的信道译码算法研究[D].南京:东南大学,2021.
- [16]康婧.星地高速数传 LDPC 码编译码算法及高效实现技术研究[D].北京:中国科学院大学,2021.

【作者简介】

王宝祥(1999—),男,山东临沂人,硕士研究生,研究方向:信道译码。

陈斌杰(1981—),男,浙江宁波人,硕士,高级工程师,研究方向:电子信息。

(收稿日期:2024-03-18)