

引用本文: 梁坤, 刘战胜. 基于联合残差网络和 Bottleneck Transformer 的调制格式识别方法[J]. 光通信技术, 2024, 48(3): 13-17.

基于联合残差网络和 Bottleneck Transformer 的调制格式识别方法

梁坤, 刘战胜*

(江苏大学 计算机科学与通信工程学院, 江苏 镇江 212000)

摘要: 针对未来光网络链路中的传输需求, 提出一种基于联合残差网络(ResNet)和 Bottleneck Transformer(BT)的调制格式识别(MFI)方法。该方法结合 ResNet 和 BT 对 6 种不同调制格式的信号进行识别, 并应用 OptiSystem 和 TensorFlow 对其进行仿真。仿真结果表明: 在较宽的光信噪比(OSNR)范围内, 所提方法的准确率达到了 99.72%, 并且能够很好地应对传输损伤的影响; 与其它深度学习方法相比, 该方法性能显著提升。

关键词: 调制格式识别; 深度学习; 残差网络; 信号传输; 光信噪比

中图分类号: TN256 **文献标志码:** A **文章编号:** 1002-5561(2024)03-0013-05

DOI: 10.13921/j.cnki.issn1002-5561.2024.03.003

开放科学(资源服务)标识码(OSID):



Modulation format identification method based on joint residual network and Bottleneck Transformers

LIANG Kun, LIU Zhansheng*

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang Jiangsu 212000)

Abstract: A modulation format recognition(MFI) method based on joint residual network(ResNet) and Bottleneck Transformer(BT) is proposed to meet the transmission requirements in future optical network links. This method combines ResNet and BT to identify signals with six different modulation formats, and applies OptiSystem and TensorFlow to simulate them. The simulation results show that within a wide range of optical signal-to-noise ratio (OSNR), the proposed method achieves an accuracy of 99.72% and can effectively cope with the impact of transmission damage. Compared with other deep learning methods, this method significantly improves its performance.

Key words: modulation format identification, deep learning, residual network, signal transmission, optical signal-to-noise ratio

0 引言

光网络是未来智能城市、物联网、数据中心等新兴技术的关键驱动因素, 光网络容量的稳步增长带来了带宽和服务质量的挑战。随着终端用户对带宽需求的不断增加, 传统光网络固有的静态和固定网络结构的局限性逐渐凸显, 未来光网络体系结构将变得更加动态、复杂和透明^[1]。

在灵活的异构光网络中, 数据速率和调制格式可以根据终端用户的需求和信道条件而改变^[2]。采用高级调制格式, 如正交相移键控(QPSK)、正交幅度调制(QAM)和脉冲幅度调制(PAM), 能够有效提高光传输中的光谱效率。因此, 调制格式识别(MFI)是未来光网络中的一项重要任务。若在不需要来自发射端任何先验信息的情况下, 在接收端对调制格式进行自主分析和识别, 可以提高光网络的灵活性。文献[3]通过结合主成分分析和奇异值分解的方法, 实现了一种针对盲信号的 MFI。文献[4]提出了一种 K 近邻(KNN)方法对调制格式进行自动分类。文献[5]提出使用随机森林(RF)方法执行 MFI。上述 2 种方法在一定程度上满足了部分调制格式的识别。近年来, 深度学习以其鲁棒性和强大的特征提取能力受到越来越多研究者的关注。考虑到载波相位偏移, SHI J 等人^[6]提出了一种正

收稿日期: 2023-09-09。

基金项目: 江苏大学高级人才科研启动基金(16JDG023)资助。

作者简介: 梁坤(1998—), 男, 硕士研究生, 现就读于江苏大学计算机科学与通信工程学院电子信息专业, 研究方向为无线光通信, 主要从事光纤通信系统的仿真搭建和光学性能监测等方面的工作。

* 通信作者: 刘战胜(1975—), 男, 博士, 副教授, 主要研究方向为光纤通信。



梁坤,刘战胜:基于联合残差网络和 Bottleneck Transformer 的调制格式识别方法

交频分复用 (OFDM) 系统中的自动调制识别方法。ZENG Y 等人^[7]利用频谱图作为信号表示,提出了一种基于卷积神经网络(CNN)的通信系统无线电信号 MFI 框架。FAN X 等人^[8-10]采用基于 CNN 的多任务学习方法,通过 CNN 实现了光网络中 MFI 和光性能的同步监测。CHANG X 等人^[11]将长短期记忆(LSTM)网络用于相干光通信系统中的 MFI,其中使用了 4 种具有不同数据速率的调制格式。KUMAR Y 和 QI P^[12-13]提出了残差网络(ResNet)来对调制格式进行分类,通过引入 ResNet 模块,解决了大部分深度网络的退化问题。尽管上述方法在特定条件下能有效保证 MFI 的准确率,但在不增加计算复杂度的前提下,它难以涵盖更广泛的调制格式和信道损伤情况。这意味着 MFI 技术在这方面仍有待进一步优化。

本文结合 ResNet 和 Bottleneck Transformers (BT) 进行 MFI,提出一种基于 ResNet 和 BT 的 MFI 方法。

1 基于 ResNet 和 BT 的 MFI 方法

ResNet 和 BT 模型的结构图如图 1 所示。图 1(a) 中,ResNet 模型的结构通过 1×1 卷积,有效减少了计算量,同时确保了信息的丰富性,其中 s, p 分别表示卷积层中的步幅和填充状态。ResNet 网络层的批量归一

化(BN)层中执行归一化和去中心化,数据服从均值为零、方差为 1 的分布,这种预处理可以加快网络的收敛速度。经过预处理后,数据被送入一个称为校正线性单元(ReLU)的激活函数,同时在剩余网络的主路输出端加入跳跃连接,将输入与输出直接进行相加,并且补充卷积过程中损失的特征信息。

图 1(b)中,BT 是一种图像分类模型,它结合了计算机视觉识别的自我注意机制。为了提高图像分类的基线,减少参数,文献[14]采用全局自注意机制代替 CNN 中的空间卷积。BT 模型的出现可以解决特征提取过于复杂和繁琐的难题,以及训练效率低下的问题。BT 模型结构包括 3 个基本压缩层、2 个自注意力机制层和 2 个扩展层。在压缩层,对图像进行下采样压缩,提取特征;在自注意力机制层,从大的图像中学习抽象和低层次的特征;在扩展层,利用卷积操作对特征映射中的信息进行深度处理和聚合,随后通过上采样恢复图像的细节。在 BT 模型中存在一个跳跃连接,它在有效处理大图像的同时还可以最小化延迟并减少参数^[14]。

图 1(c)为本文提出的基于 ResNet 和 BT 的 MFI 方法的模型结构(下文简称 ResNet-BT 模型)。首先,将眼图数据送入第一卷积层和最大池化层,通过 1 个




图 1 ResNet和 BT 模型的结构图

ResNet 网络层后将信息以跳跃连接的方式重新激活;然后,经历 3 个由向下采样的 ResNet 模块和 ResNet 网络层,处理不同信息的特征。随后,数据进入到 BT 模块中,处理和聚合更有效的特征信息。经过平均池化层进行压缩降维,优化降低网络复杂度,最终通过全连接层和 Softmax 函数进行输出。

2 仿真分析

2.1 仿真设置

本文使用 OptiSystem 15 软件建立仿真链路收集所提模型的眼图数据,其仿真设置示意图如图 2 所示。采用分布反馈激光发射器作为光源生成伪随机二进制序列(PRBS),将其分别映射到二电平脉冲幅度调制(PAM2)、四电平脉冲幅度调制(PAM4)、八电平脉冲幅度调制(PAM8)、十六电平脉冲幅度调制(PAM16)、二进制移相键控(BPSK)和正交相移键控(QPSK)这 6 种调制格式中。PRBS 的数据速率设置为 20 Gb/s,通过马赫-曾德尔调制器(MZM)将电数据调制成光载波。采用一组光信噪比(OSNR)分量将定义的噪声下限电平加载到光信号,OSNR 从 8 dB 变为 30 dB,步长为 2 dB;采用 25 km 的单模光纤(SMF),其色散(CD)和偏振模色散(PMD)系数分别设置为 16.75 ps/(nm·km)和 0.5 ps/(nm·km)(在本研究中未改变)。在光电二极管后采集不同调制方式的眼图。通过离线数字信号处理(DSP)预处理得到 224×224 的灰度图像,并利用集成编译环境(PyCharm IDE)和深度学习框架(TensorFlow)库实现联合 ResNet-BT 模型。

在不同的 OSNR 下,总共采集 10 800 幅不同调制格式的眼图图像。整个图像数据集被随机分成训练集(80%)和测试集(20%),即一共有 8640 幅图像用于训练,2160 幅图像用于测试。为了标记不同的格式,使用具有 6 个元素的向量,其中只有 1 个非零元素表示调制格式。例如,PAM2(100000)、PAM4(010000)、PAM8(001000)、PAM16(000100)、BPSK(000010)、QPSK(000001)。在训练

过程中,本文首先运用自适应矩估计方法在 ResNet-BT 模型中提取和共享特征,以减小模型输出值与实际值之间的误差,最后通过测试集来评估模型训练后的准确性。

2.2 结果与讨论

2.2.1 MFI 结果

为验证 ResNet-BT 模型的 MFI 性能,本文对其训练集和测试集的损失值进行测试,结果如图 3 所示。其中,损失函数用于评估模型的收敛性。可以看出,训练集和测试集的损失值随着历元次数的增加而显著减少,模型收敛性非常平稳。在经 80 次历元后,训练集和测试集的损失值分别为 0.087 8 和 0.372 5,损失值较低说明模型鲁棒性较好。




图3 训练集与测试集的损失值

训练集和测试集的 MFI 混淆矩阵如图 4 所示。每种调制格式有 1 440 个训练图像和 360 个测试图像,通过行列间的数据可得出识别正确和错误的实例个数。可以看出,使用训练集输出的所有调制格式的 MFI 分类准确率均达到 100%。使用测试集输出的调制格式中,只有 BPSK、QPSK 和 PAM2 的 MFI 分类准确率才能达到 100%。而更高级别的调制格式 PAM4、PAM8 和 PAM16 则发生了错误分类。例如,对于使用 PAM8 的 360 幅图像,2 个实例被错误识别为 PAM16,1 个实例被错误识别为 PAM4。PAM4、PAM8 和 PAM16 的分




图2 仿真设置示意图

梁坤,刘战胜:基于联合残差网络和 Bottleneck Transformer 的调制格式识别方法

目标调制格式	QPSK	0	0	0	0	0	1 440
	BPSK	0	0	0	0	1 440	0
	PAM16	0	0	0	1 440	0	0
	PAM8	0	0	1 440	0	0	0
	PAM4	0	1 440	0	0	0	0
	PAM2	1 440	0	0	0	0	0
		PAM2	PAM4	PAM8	PAM16	BPSK	QPSK

实际输出的调制格式

(a) 训练集输出调制格式

目标调制格式	QPSK	0	0	0	0	0	360
	BPSK	0	0	0	0	360	0
	PAM16	0	0	2	358	0	0
	PAM8	0	1	357	2	0	0
	PAM4	0	359	1	0	0	0
	PAM2	360	0	0	0	0	0
		PAM2	PAM4	PAM8	PAM16	BPSK	QPSK

实际输出的调制格式

(b) 训练集输出调制格式

图4 训练集与测试集的 MFI 混淆矩阵

类准确率分别为 99.72%、99.17%和 99.44%，其 MFI 错误原因是由于相近格式中的特征复用,但出现的概率极小,即在 6 种光信号格式识别中,MFI 已实现了优异的性能。


2.2.2 不同因素对 MFI 的影响

为验证所提模型在不同历元次数、传输距离和 OSNR 条件的性能,本文对所有调制类型的总体准确率进行测试。


首先,研究模型的 MFI 性能随历元次数的变化。其中,一次历元是将整个训练数据集提供给 ResNet-BT 模型进行参数调整。当历元次数过小时,数据集中的有效特征没有得到充分提取或在训练阶段参数调整不当,会导致在较少的时间段内无法实现较高的准确率。总体趋势是随着历元次数的增加,模型参数中的权重和偏置被进一步优化,提取更多的特征以实现性能的逐步提高。不同历元次数下模型的 MFI 的准确率如图5(a)所示。可以看出,在 80 和 100 次历元时,准确率达到100%。当进一步增加历元次数时,模型对噪声的记忆能力过强及训练集信息间产生相互干扰,从而产生过拟合现象,导致整体性能略有下降。在设置的历元范围内,MFI 的准确率达到较好的水平,证明

了在历元因素下该模型具有较强的鲁棒性。


其次,本文以背靠背传输为基准,通过调整 SMF 来改变光信号的传输距离,并研究在不同传输距离下 ResNet-BT 模型的性能,得到不同传输距离对 MFI 的影响如图 5(b)所示。可以看出,当传输距离小于或等于 40 km 时,MFI 的准确率不受影响,但在传输距离为 50 km 时,准确率开始略有下降,这说明传输距离对信号的损伤确实会对模型的 MFI 产生显著影响。在 0~100 km 的测试范围内,MFI 的准确率可以保持在 98.76% 以上。光纤的色散和非线性则需要采用相应的 DSP 算法进行补偿。



(a) 不同历元次数下模型的 MFI 精度



(b) 不同传输距离对 MFI 的影响



(c) 不同 OSNR 对 MFI 的影响

图5 不同因素对 MFI 的影响

最后,研究了不同 OSNR 对 MFI 的影响,结果如图 5(c)所示,OSNR 从 8 dB 变化到 30 dB,步长为 2 dB。可以看出,当 OSNR 在 14~22 dB 之间变化时,MFI 的准确率可以保持在 100%。在 OSNR 偏低和偏大时,MFI 的准确率均会受到影响。其中,当 OSNR 为 8 dB 时,MFI 的准确率为 99.16%;OSNR 为 30 dB 时,其准确率为 99.3%。主要原因是当 OSNR 过小时,噪声的影响会使信号眼图部分或局部失真;而当 OSNR 过大时,信号可能导致光纤器件处于非线性区,从而受到线性传输损伤。这 2 个种情况都会影响模型提取信号特征。从影响程度来看,ResNet-BT 模型能很好地处理受损伤的信号下的数据,并在不同因素的影响下仍能很好地对不同调制格式的信号进行识别,其 MFI 的准确率超过 99%。

2.2.3 与不同方法的对比

为了进一步验证 ResNet-BT 模型的性能,本文将其与 RF、KNN、支持向量机(SVM)、CNN、VGG(优化的深度网络)和 ResNet 共 6 种机器学习或深度学习方法进行了比较,仿真条件均一致,对比结果如图 6 所示。可以看出,RF 方法的 MFI 准确率仅为 68.96%,KNN、SVM、CNN、VGG 的 MFI 准确率分别为 76.95%、87.36%、92.64%、98.29%,ResNet 模型的 MFI 准确率达到 99.26%,ResNet-BT 模型的 MFI 准确率则达到了 99.72%,比 ResNet 模型和 RF 方法分别略高 0.46% 和 30.76%。




图 6 不同方法的对比结果

3 结束语

本文提出了一种 ResNet-BT 模型,并对光网络中的 6 种调制格式进行了识别。该网络结构是一种新颖的神经网络结构,具有先进的特征提取功能。每个 ResNet 网络层通过适当地结合结构中的自注意力机制和跳跃连接来细化不同的功能。仿真结果表明:与其它方法相比,ResNet-BT 模型计算复杂度低且准确率高,准确率达到 99.72%,展示了其未来在多种调

制格式与宽范围下 MFI 应用的前景。在未来的工作中,考虑到 CD 和 PMD 的影响,可以对网络结构进行扩展和优化,以适应更多类型的调制格式和实现对光性能的更有效监测。

参考文献:

- [1] SAIF W S, ESMAIL M A, RAGHEB A R, et al. Machine learning techniques for optical performance monitoring and modulation format identification: a survey [J]. IEEE Communications Surveys & Tutorials, 2020, 2(4): 525–543.
- [2] NAG A, TORNATORE M, MUKHERJEE B. Optical network design with mixed line rates and multiple modulation formats[J]. Journal of Light-wave Technology, 2010, 28(4): 466–475.
- [3] JIANG J, ZHANG Q, XIN X, et al. Blind modulation format identification based on principal component analysis and singular value decomposition[J]. Electronics, 2022, 11(4): 612–627.
- [4] ASLAM M W, ZHU Z, NANDI A K. Automatic modulation classification using combination of genetic programming and KNN[J]. IEEE Transactions on Wireless Communications, 2012, 11(8): 2742–2750.
- [5] ZHAO Y, SHI C, WANG D, et al. Modulation format identification using random forest[J]. IEEE Photonics Technology Letters, 2019, 31(11): 853–856.
- [6] SHI J, HONG S, CAI C, et al. Deep learning-based automatic modulation recognition method in the presence of phase offset [J]. IEEE Access, 2020, 8: 42841–42847.
- [7] ZENG Y, ZHANG M, HAN F, et al. Spectrum analysis and convolutional neural network for automatic modulation recognition [J]. IEEE Wireless Communications Letters, 2019, 8(3): 929–932.
- [8] FAN X, XIE Y, REN F, et al. Joint optical performance monitoring and modulation format/bit-rate identification by CNN-based multi-task learning [J]. IEEE Photonics Journal, 2018, 10(5): 7906712–1–7906712–12.
- [9] FAN Z, WANG L, REN F, et al. Feature fusion-based multi-task ConvNet for simultaneous optical performance monitoring and bit-rate/modulation format identification[J]. IEEE Access, 2019, 7: 126709–126719.
- [10] ZHANG W, CUI D, LOU S. Training images generation for CNN based automatic modulation classification[J]. IEEE Access, 2021, 9: 62916–62925.
- [11] CHANG X, LI Z, ZHANG Q, et al. Modulation format identification for coherent optical communication systems based on long short-term memory networks [C]//IEEE. Proceeding of International Conference on Optical Communications and Networks(ICOCN). Shenzhen: IEEE, 2022: 1–3
- [12] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic modulation classification based on constellation density using deep learning[J]. IEEE Communications Letters, 2020, 24(6): 1275–1278.
- [13] QI P, ZHOU X, ZHENG S, et al. Automatic modulation classification based on deep residual networks with multimodal information[J]. IEEE Transactions on Cognitive Communications & Networking, 2020, 7(1): 21–33.
- [14] SRINIVAS A, LIN T Y, PARMAR N, et al. Bottleneck transformers for visual recognition [C]//IEEE/CVF. IEEE Conference on Computer Vision and Pattern Recognition, IEEE/CVF, 2021: 16514–16524.