

# 光学学报

## 基于深度学习的简化多信道并行光性能监测

李梦岩<sup>1</sup>, 吴锦涛<sup>1</sup>, 杨静宇<sup>2</sup>, 张力夫<sup>1</sup>, 谭勇<sup>2</sup>, 邱天<sup>2</sup>, 李岳彬<sup>1</sup>, 邓鹤鸣<sup>1</sup>, 罗风光<sup>2\*\*</sup>, 杨柳<sup>1,2\*</sup>

<sup>1</sup>湖北大学微电子学院, 湖北 武汉 430062;

<sup>2</sup>华中科技大学光学与电子信息学院下一代互联网接入系统国家工程研究中心, 湖北 武汉 430074

**摘要** 提出了一种基于信号光谱和多任务深度神经网络(MT-DNN)的多信道并行光性能监测(OPM)方案,采集多信道光谱图进行预处理来设计幅度直方图(Ahs),可实现波分复用(WDM)系统多信道调制格式识别(MFI)和光信噪比(OSNR)监测。在建立的3信道WDM相干光通信系统中,对由PDM-4QAM/16QAM/64QAM组合的10种调制格式的3信道信号实现了MFI准确率为100%、OSNR监测的平均绝对误差(MAE)为0.16 dB的精准监测。为进一步研究所提OPM方案的性能以应对复杂的传输环境,提出了迁移学习辅助的多任务深度神经网络(TL-MT-DNN)用于多信道MFI和OSNR并行监测。结果表明,所提方案可移植性较好,还可节省大量样本和训练周期,其MFI准确率仍可达100%,3信道OSNR监测的MAE分别为0.24 dB、0.20 dB和0.19 dB。

**关键词** 机器视觉; 光性能监测; 波分复用; 光信噪比; 调制格式识别; 迁移学习; 多任务深度神经网络

**中图分类号** TN929.11

**文献标志码** A

**DOI:** 10.3788/AOS222033

### 1 引言

随着新兴业务对互联网性能需求的急剧增加,大容量多信道的灵活光纤通信系统成为光纤通信的发展趋势,其数据传输也变得更加动态、灵活、复杂和透明。大容量多信道光通信系统中的链路损伤不仅会造成传输信号进一步劣化,还对保证光通信系统性能安全的关键技术——光性能监测(OPM)技术提出了更高的要求:OPM的监测参数和链路数量需要不断增加,不能仅仅局限在单线路监测上;在监测精度和动态范围上也有着更高的要求。因此,研究可用于多信道监测且具有可移植性、低复杂度和高精度的OPM方案是光通信OPM的发展要求。

传统的OPM方法主要是基于传输信号时域或频域特征的分析<sup>[1-5]</sup>来完成的,虽然这些方法可以获得很好的监测性能,但是其监测复杂度往往较高,且监测参数较单一。近年来,深度学习在光通信领域中的广泛应用促进了光纤通信智能系统的发展。与传统方法相比,深度学习算法具有强大的线性或非线形拟合和计算能力,故研究人员已提出了多种基于深度学习的多参数联合监测的OPM技术<sup>[6-16]</sup>,如基于多任务人工神经网络的OPM方案<sup>[6-7]</sup>、基于多任务卷积神经网络的OPM方案<sup>[8,12]</sup>和基于多任务深度神经网络的OPM方

案<sup>[13-14]</sup>等。目前,这些关于OPM技术的研究多数在接收端将(异步)幅度直方图<sup>[6,8,13-15]</sup>、异步延迟抽头采样绘制的二维散点图<sup>[12,15]</sup>、眼图<sup>[17-18]</sup>和星座图<sup>[19]</sup>等作为特征图来实现多参数监测,且监测机制以单信道监测为主,即使是多信道监测也是通过可调谐光学滤波器选择一个特定的信道进行顺序监测,但这种操作会引入测量延迟,尤其是在大量信道的波分复用(WDM)系统中<sup>[20]</sup>。在下一代动态可重构光网络中,接收端之外的中间节点同样要进行OPM,并且具有多种调制格式共存、超大容量传输等优点的WDM技术已被广泛应用在光网络中,故OPM技术也需具备同时监测多个信道的能力。

本文针对多信道监测方面存在的不足,提出了一种基于信号光谱和多任务深度神经网络(MT-DNN)的多信道并行OPM方案。该方案不需要单独处理每个信道,只需采集WDM系统中间节点或接收端的信号光谱,对光谱整体进行预处理,实现了多信道信号调制格式识别(MFI)准确率为100%和光信噪比(OSNR)监测的平均绝对误差(MAE)为0.16 dB。然后,对所提OPM方案的可移植性进行了验证,进一步提出了复杂传输环境下基于迁移学习(TL)辅助的多任务深度神经网络(TL-MT-DNN)的多信道信号MFI和OSNR并行监测方案,结果表明该方案在少量

收稿日期: 2022-11-22; 修回日期: 2022-12-17; 录用日期: 2023-01-07; 网络首发日期: 2023-02-07

基金项目: 国家自然科学基金(62001181)、国家重点研发计划(2022YFB2903000)、湖北省重点研发计划(2022BAA007)、武汉市知识创新专项-曙光计划(202201080102335)

通信作者: \*liuyang89@hust.edu.cn; \*\*fgluo@hust.edu.cn

样本的数据集上可以实现 MFI 准确率达到 100%，以及 3 信道 OSNR 监测的 MAE 分别达到 0.24 dB、0.20 dB 和 0.19 dB 的精准监测。

## 2 基本原理

### 2.1 基于信号光谱的幅度直方图

基于信号光谱生成的幅度直方图(Ahs)的原理如图 1 所示。采集的光谱数据经过预处理后生成 Ahs, 其具体过程为图 1 中虚线框所展示的部分。由于研究的是多信道 WDM 的并行监测, 故为了降低复杂度, 需要对信号进行预处理, 具体步骤为: 光谱经降采样、滤波处理、信号波形分离和功率进行归一化后, 统计每个功率值区间内的信号样本点数, 生成 Ahs。Ahs 反映了信号幅值的统计分布, Ahs 的纵轴表示每个幅值区间内数据出现的频率, Ahs 的横轴表示幅值的等分

数<sup>[13-14]</sup>。为清晰可见, 图 2 展示了调制格式类型为 64QAM-64QAM-64QAM、OSNR 为 25 dB 时, 光谱预处理的过程图。图 2(a)~(c) 依次为原始光谱、降采样后的光谱和滤波处理后的光谱。图 3 展示了基于图 1 描述的原理, 得到的在不同调制格式类型和 OSNR 值时信号的 Ahs, 其包含 60 个幅值区间, 这里仅展示了 4 个固定 OSNR 值信号的 Ahs。图 3(a)~(d) 所示的 Ahs 对应的调制格式类型分别为 64QAM-16QAM-4QAM、64QAM-64QAM-16QAM、4QAM-4QAM-64QAM 和 4QAM-4QAM-4QAM。可以发现: 不同调制格式类型的 Ahs 有着显著的区别; 对于一个固定调制格式类型的信号, 当其 OSNR 值发生变化时, 相应的 Ahs 会有微小的变化。这些 Ahs 的特征都将被 MT-DNN 自动学习, 从而实现多信道信号 MFI 和 OSNR 监测。

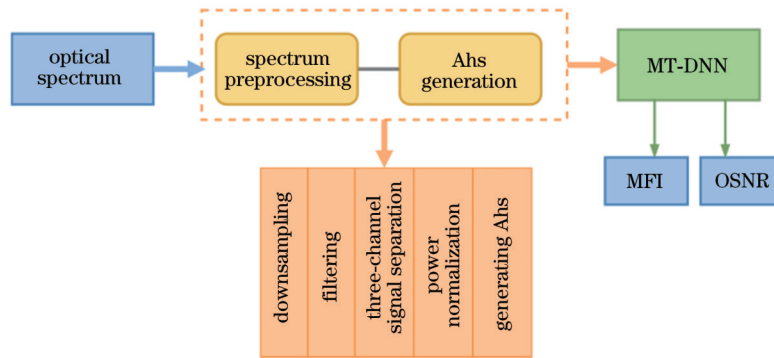


图 1 基于信号光谱的 Ahs 原理

Fig. 1 Principle of Ahs based on signal spectra




图 2 光谱预处理的过程图。(a)原始光谱;(b)降采样后的光谱;(c)滤波处理后的光谱

Fig. 2 Process of spectrum preprocessing. (a) Original spectrum; (b) spectrum after downsampling; (c) spectrum after filtering

### 2.2 MT-DNN 原理

本文采用的 MT-DNN 结构如图 4 所示, 该 MT-DNN 包含 1 个输入层、4 个隐藏层和 1 个输出层。将 Ahs 幅值的等分数作为 MT-DNN 的输入, 在输出层有 2 个任务, 将输出离散值 0 或 1 的 MFI 任务视为分类问题, 将输出连续值的 OSNR 监测任务视为回归问题。对于不同的任务, MT-DNN 的隐藏层共享相同的映射, 故将其称为共享隐藏层。输入层神经元仅接收输入, 不进行函数处理, 隐藏层与输出层之间包含功能神

经元<sup>[21]</sup>, 故在最后一个隐藏层与输出层之间, 对于两个不同的问题分别选取 Softmax 和 ReLU 作为激活函数, 其余层之间的激活函数均为 ReLU。同时, 定义任务 1 和任务 2 的损失函数分别为  $L_1$  和  $L_2$ , MT-DNN 的总损失函数为 2 个任务的损失函数的加权和  $L$ , 则  $L_1$ 、 $L_2$  和  $L$  可以表示为

$$L_1 = -\frac{1}{m} \left[ \sum_{i=1}^m y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i) \right], \quad (1)$$

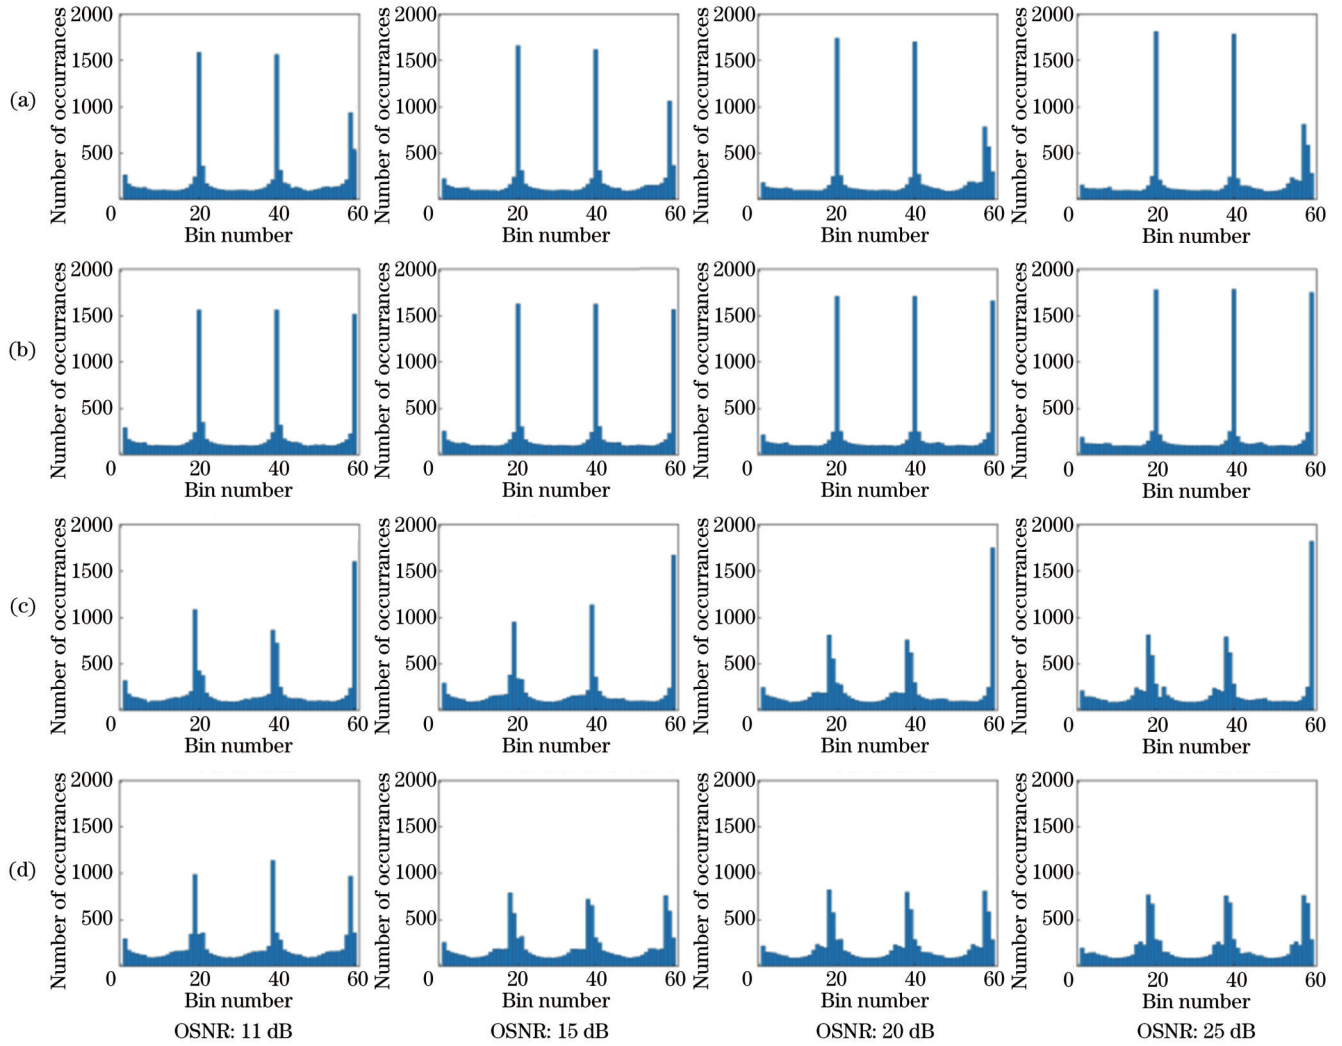


图 3 基于图 1 描述的原理得到的不同调制格式下的  $A_{hs}$ 。(a) 64QAM-16QAM-4QAM; (b) 64QAM-64QAM-16QAM; (c) 4QAM-4QAM-64QAM; (d) 4QAM-4QAM-4QAM

Fig. 3 Obtained  $A_{hs}$  under different modulation formats based on principle described in Fig. 1. (a) 64QAM-16QAM-4QAM; (b) 64QAM-64QAM-16QAM; (c) 4QAM-4QAM-64QAM; (d) 4QAM-4QAM-4QAM

$$L_2 = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2, \quad (2)$$

$$L = \sigma_1 L_1 + \sigma_2 L_2, \quad (3)$$

式中:  $L_1$  为交叉熵损失函数;  $L_2$  为均方误差 (MSE) 函数;  $y_i$  为真实输出;  $\hat{y}_i$  为 MT-DNN 的预测输出;  $m$  为样本总数;  $L$  为 MT-DNN 的总损失函数;  $\sigma_1$  和  $\sigma_2$  分别为 MFI 和 OSNR 监测的权重因子,  $\sigma_1$  和  $\sigma_2$  的大小直接影响 MT-DNN 的监测结果。另外, 在 MT-DNN 的训练阶段和测试阶段, 对于任务 1 选用精确度作为评估标准, 对于任务 2 选用 MAE 作为评估标准, MAE 的表达式为

$$E_{MA} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|. \quad (4)$$

### 2.3 迁移学习原理

TL 就是建立源域  $D_s$  到目标域  $D_T$  的映射关系<sup>[22]</sup>, 它可以从根据以前的任务预先训练的模型中提取知识, 并将其应用到相似或相关联的目标任务中<sup>[14, 18-19]</sup>。

采用的基于参数的 TL<sup>[23]</sup> 如图 5 所示, 将源域  $D_s$  的 MT-DNN 模型除输出层以外的参数共享给目标域  $D_T$  的 TL-MT-DNN 模型以代替网络参数的随机初始化, 对 TL-MT-DNN 模型中输出层的参数进行随机初始化, 再使用 TL 中常用的参数调整方法 (微调) 来调整 TL-MT-DNN 模型的参数以达到更好的监测性能。仅改变图 5 实线框内所示的 TL-MT-DNN 模型的输出层结构, 由于 TL-MT-DNN 要完成 3 信道信号的 MFI 和 OSNR 并行监测, 故 TL-MT-DNN 的输出层有 4 个任务。同样, MFI 任务的损失函数采用交叉熵损失函数, 3 个 OSNR 监测任务的损失函数均采用 MSE 函数, 定义 TL-MT-DNN 的总损失函数为  $L_{TL}$ , 其表达式为

$$L_{TL} = \sigma_1 L_1 + \sigma_2 L_2 + \sigma_3 L_3 + \sigma_4 L_4, \quad (5)$$

式中:  $L_3$  和  $L_4$  为 MSE 函数;  $\sigma_1$ 、 $\sigma_2$ 、 $\sigma_3$  和  $\sigma_4$  为 4 个任务的权重因子, 其大小同样直接影响 TL-MT-DNN 的监测性能, 这里的  $\sigma_1$  和  $\sigma_2$  的取值与 MT-DNN 中经优化后的

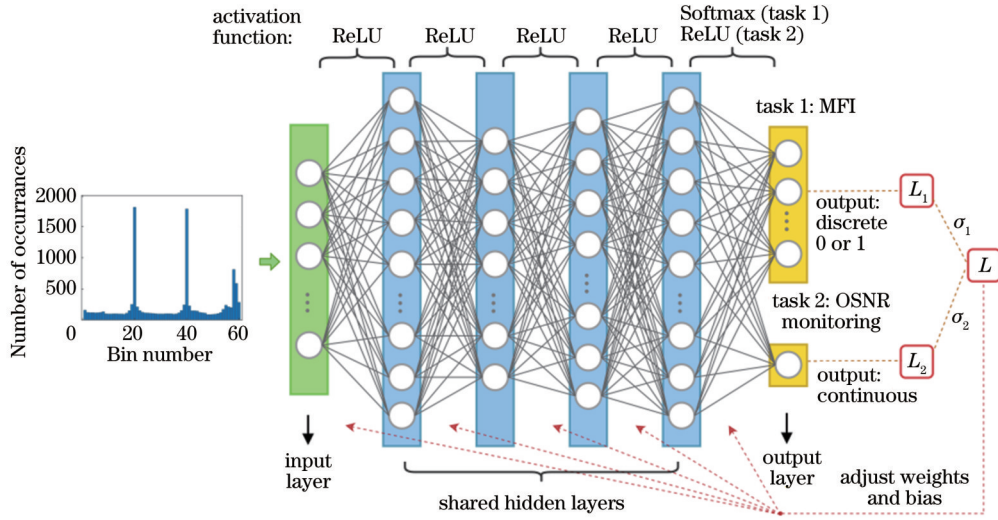


图 4 MT-DNN 结构图

Fig. 4 Structural diagram of MT-DNN

$\sigma_1$  和  $\sigma_2$  的取值相同。由于任务 2、任务 3 和任务 4 均是 OSNR 监测任务,故取  $\sigma_3$  和  $\sigma_4$  与  $\sigma_2$  的值相同以使每个

信道的 OSNR 监测占有同样的权重。

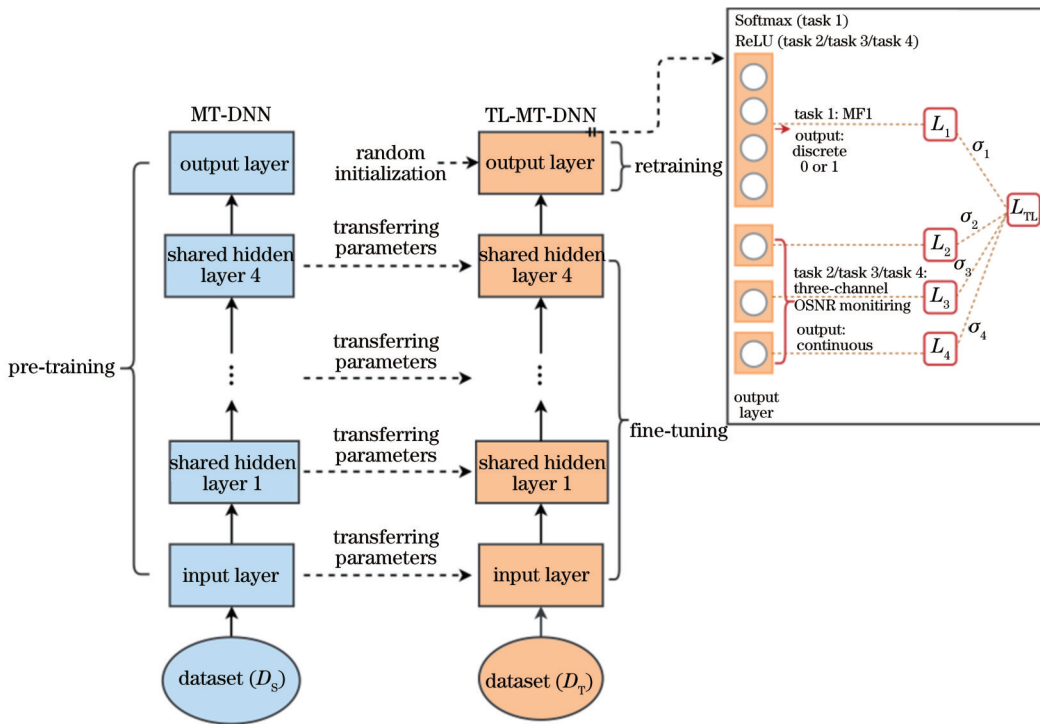


图 5 基于参数的 TL 原理

Fig. 5 Principle of parameter-based TL

### 3 系统建立

基于 VPItransmissionMaker 9.9 和 MATLAB 建立的 3 信道 WDM 相干光通信系统如图 6 所示,其中  $M_1$ 、 $M_2$  和  $M_3$  的取值均为 4 或 16 或 64, TX 为光发送机模块。系统的主要参数已在表 1 中展示。将一个长度为  $2^{15} - 1$  的伪随机二进制序列 (PRBS) 调制成 3 种广泛应用的光信号 PDM-4QAM、PDM-16QAM 和

PDM-64QAM。3 信道信号经波分复用器汇合在一起,然后经过一个由偏振分束器 (PBS)、光纤延迟线和偏振合束器 (PBC) 组成的偏振复用模块,由 OSNR 设置模块来调整信号 OSNR 的变化范围,最后送到光纤链路中进行传输。当所有光开关 OS 置于 B 时,系统传输环境为源域  $D_s$ ,多信道 MFI 和 OSNR 监测作为源任务  $T_s$ 。考虑到在实际的传输环境中,不同的调制格式对 OSNR 的要求不同,为应对复杂传输环境,对不

同的信道进行差异化 OSNR 设置。当所有光开关 OS 都置于 A 时,系统传输环境为目标域  $D_T$ ,多信道 MFI 和 OSNR 并行监测作为目标任务  $T_T$ 。图 6 虚线框部分展示了所提监测方案,此 OPM 方案可用于光纤链路任意节点或接收端。使用光谱仪采集数据,根据图 1 描述的原理对采集的数据进行处理后生成 Ahs。针对源域  $D_S$ ,对于固定的调制格式类型,收集了不同 OSNR 下的 50 个 Ahs。针对目标域  $D_T$ ,仅考虑 4 种调制格式类型,在固定的调制格式类型和 OSNR 值时收集 20 个 Ahs。因此,源域  $D_S$  的原始数据集包含 7500

(50×15×10) 个 Ahs,目标域  $D_T$  的原始数据集包含 400(20×5×4) 个 Ahs,将原始数据集按 8:2 随机划分为训练集和测试集。使用的 6 层 MT-DNN 的各层神经元节点数分别为 60、120、90、100、120、11(10/1),6 层 TL-MT-DNN 的各层神经元节点数分别为 60、120、90、100、120、7(4/1/1/1)。基于 MT-DNN 的 MFI 和 OSNR 监测任务的权重因子  $\sigma_1$  和  $\sigma_2$  将在 4.1.1 节中进行优化调整。使用 Keras 库结合 TensorFlow 深度学习框架(2.0 版本)来构建 MT-DNN 模型<sup>[24]</sup>。

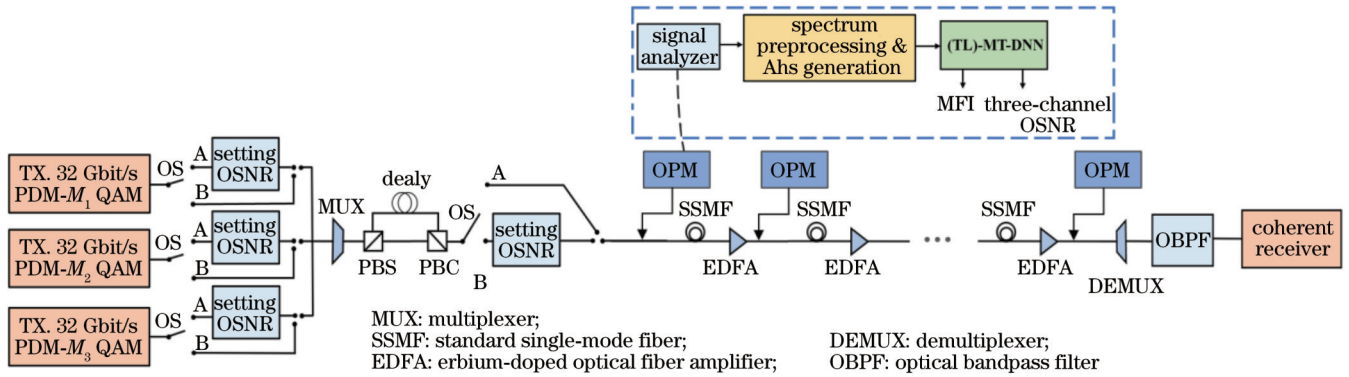


图 6 3 信道 WDM 相干光通信系统图

Fig. 6 Schematic diagram of three-channel WDM coherent optical communication system

表 1 3 信道 WDM 相干光通信系统的主要参数

Table 1 Key parameters of three-channel WDM coherent optical communication system

Parameter	Description
Modulation format	PDM-4QAM/16QAM/64QAM (ten types of modulation formats)
Bit rate	32 Gbit/s
OSNR range (with step of 1 dB) for multiplexed-channel signals ( $D_S$ )	11 dB-25 dB
OSNR range (with step of 1 dB) for single-channel 4QAM signal ( $D_T$ )	11 dB-15 dB
OSNR range (with step of 1 dB) for single-channel 16QAM signal ( $D_T$ )	16 dB-20 dB
OSNR range (with step of 1 dB) for single-channel 64QAM signal ( $D_T$ )	21 dB-25 dB
Middle channel reference frequency	193.1 THz
Channel spacing	50 GHz
Pulse shape	Root-raised-cosine
Roll-off factor	0.3
Laser power	0 dBm
Laser linewidth	0

## 4 结果与分析

### 4.1 基于 MT-DNN 的光性能监测结果分析

#### 4.1.1 MT-DNN 的超参数对其监测性能的影响

首先,研究 MFI 任务和 OSNR 监测任务的权重因

子  $\sigma_1$  和  $\sigma_2$  对 MT-DNN 性能的影响。由于每个任务所占的权重都会影响 MT-DNN 的性能,故寻找最优的  $\sigma_1$  和  $\sigma_2$  值以获得最佳的监测结果。将 MFI 和 OSNR 监测两个任务的权重之和设置为 1 ( $\sigma_1 + \sigma_2 = 1$ ), MFI 准确率和 OSNR 监测的 MAE 相对于  $\sigma_1$  的变化如图 7 所

示。可以发现:随着 $\sigma_1$ 的变化,MFI准确率一直保持在99.95%以上,这可以解释为不同调制格式的信号的Ahs有明显的特性,故MFI相对简单,准确率可以达到100.00%;随着 $\sigma_1$ 的增长,OSNR监测的MAE在上下波动,存在一个最优值 $\sigma_1$ 使得OSNR监测的误差最小。因此,经过优化之后,最终选取两个任务的权重分别为0.4和0.6。

其次,对比了不同优化器情况下MT-DNN的监

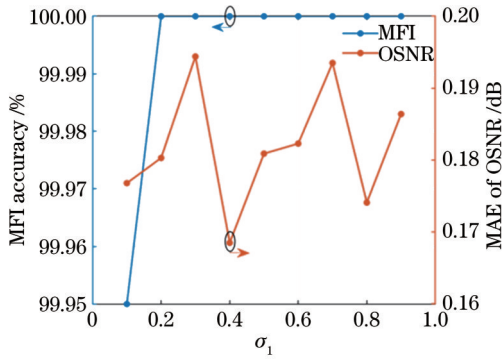


图7 MFI准确率和OSNR监测的MAE相对于 $\sigma_1$ 的变化曲线  
Fig. 7 MFI accuracy and MAE of OSNR monitoring varying with  $\sigma_1$

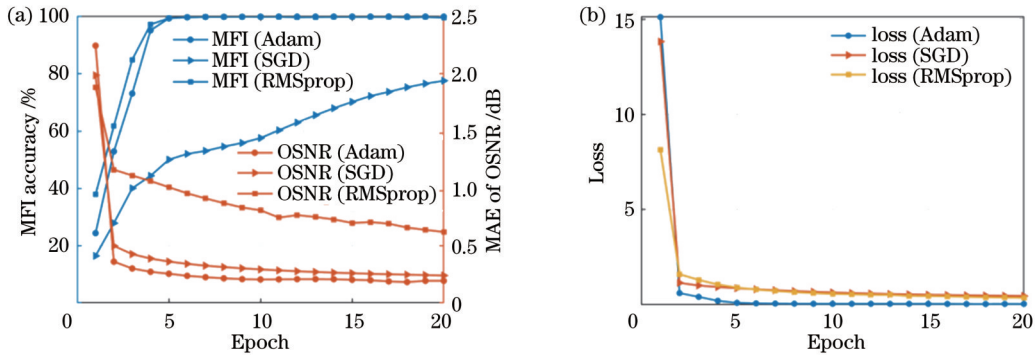


图8 不同优化器情况下MT-DNN的监测结果。(a) MFI准确率和OSNR监测的MAE;(b) MFI和OSNR监测的损失  
Fig. 8 Monitoring results of MT-DNN with different optimizers. (a) MFI accuracy and MAE of OSNR monitoring; (b) loss of MFI and OSNR monitoring

此外,为研究基于MT-DNN的MFI和OSNR监测的限制因素,改变训练集的大小,并绘制出不同epoch时MFI准确率和OSNR监测的MAE,如图9所示。设置训练集在原始数据集中的占比分别为80%(6000 Ahs)、60%(4500 Ahs)、40%(3000 Ahs)和20%(1500 Ahs)。显然,当epoch相同时,训练集越小,MT-DNN监测的性能越差。然而,随着epoch的增加,对于所有大小不同的训练集,MFI精确度最终均可提高至约100%,OSNR监测的MAE均在0.30 dB以下。即使非常小的训练集,也可以通过不断增加epoch来实现接近于零误差的监测结果,这是因为不同调制格式和OSNR信号的Ahs具有较为显著的特性,便于MT-DNN进行学习,同时表明了所提MT-DNN

测结果。在深度学习领域中,选择优化神经网络的算法是最重要的步骤之一<sup>[21]</sup>,在所提监测方案中,选取合适的优化器以使损失函数最小化。选取深度学习中最广泛应用的三种优化算法<sup>[25]</sup>,即Adam优化器、随机梯度下降(SGD)算法和RMSprop算法,其初始学习率均设置为0.001,相应的MFI和OSNR监测的结果如图8(a)所示。显然,对于在MT-DNN中加入Adam优化器和RMSprop算法的情况:当epoch小于5时,MFI准确率随着epoch的增长而迅速升高,OSNR监测的MAE随着epoch的增长而迅速减小;当epoch达到6之后,MFI准确率均保持在100%,OSNR监测的MAE均在1 dB以下,但加入Adam优化器的MT-DNN的OSNR监测的MAE始终明显小于加入RMSprop算法的情况。当在MT-DNN中加入SGD算法时,随着epoch的增长,OSNR监测的MAE具有明显的下降趋势,虽然MFI准确率一直处于上升状态,但是其最大值仅在78%左右。图8(b)展示的是在MT-DNN中加入不同优化器时,MFI和OSNR监测的总损失值随着epoch的变化曲线。很容易发现,加入Adam优化器的MT-DNN的MFI和OSNR监测的总损失值最小,几乎接近0。因此,选择在MT-DNN中加入Adam优化器以达到最佳的监测结果。

模型的泛化性能较好。下文中训练集在原始数据集中的占比均为80%。

#### 4.1.2 基于MT-DNN的多信道信号MFI和OSNR监测结果分析

为展示基于所提OPM方案训练完成的MT-DNN在测试数据中的性能,绘制了混淆矩阵,如图10所示,色条颜色的深浅表示MFI准确率,颜色越深表示准确率越高,如数值1表示MFI准确率为100%,数值0表示MFI准确率为0。为了清晰可见,信号的调制格式类型 64QAM-16QAM-4QAM、64QAM-64QAM-16QAM、64QAM-64QAM-4QAM、16QAM-16QAM-4QAM、16QAM-16QAM-64QAM、4QAM-4QAM-16QAM、4QAM-4QAM-64QAM、64QAM-64QAM-

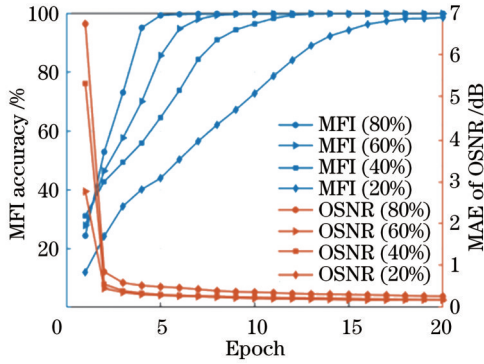


图 9 不同训练集大小下的 MFI 和 OSNR 监测的结果

Fig. 9 Results of MFI and OSNR monitoring under different training set sizes

64QAM、16QAM-16QAM-16QAM、4QAM-4QAM-4QAM 分别被命名为 format 0、format 1、format 2、format 3、format 4、format 5、format 6、format 7、format 8、format 9。对于该混淆矩阵,实际的调制格式类型出现在矩阵的每一行,识别的调制格式类型出现在矩阵的每一列,混淆矩阵的方块中下面较小的数字表示该类被正确识别的样本数,上面较大的数字表示该类被正确识别的样本数与测试集中该类的总样本数的比值。从该混淆矩阵可以看出,对于具有这 10 类调制格式的信号,其 MFI 识别准确率均为 100%。

图 11 展示了基于训练完成的 MT-DNN,在测试阶段 10 类调制格式的信号 OSNR 监测的平均 MAE 和测试集中所有信号的 OSNR 监测误差。从图 11(a) 可以看出,不同调制格式信号的 OSNR 监测的平均

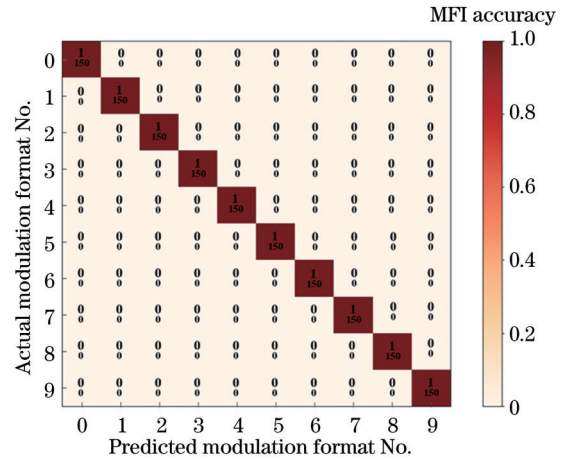


图 10 MFI 准确率的混淆矩阵

Fig. 10 Confusion matrix of MFI accuracy

MAE 大多数在 0.250 dB 以内。对于调制格式为 format 6 即 4QAM-4QAM-16QAM 的信号,OSNR 监测的平均 MAE 最大(达到了 0.263 dB),但这个误差仍然在误差容限之内。图 11(b) 展示的是整个测试集中所有信号的 OSNR 的估计值相对于 OSNR 的实际值的分布。经计算,对于所有调制格式的信号,OSNR 监测的 MAE 为 0.160 dB,此误差仍然在 0.250 dB 以内。因此,所提 OPM 方案即使在 OSNR 很小时也可以使 MFI 准确率达到 100%,且 OSNR 监测的 MAE 可达到 0.160 dB。为进一步验证所提 OPM 方案的性能,设置了更复杂的传输环境,根据图 5 描述的原理将 MT-DNN 的参数迁移至 TL-MT-DNN 中以实现多信道信号 MFI 和 OSNR 并行监测。




图 11 测试阶段中 10 类不同调制格式的信号 OSNR 监测的 MAE 和所有信号的 OSNR 监测误差;(a) OSNR 监测的 MAE; (b) OSNR 监测误差

Fig. 11 MAE of OSNR monitoring for ten different modulation formats and OSNR monitoring error for all signals in testing phase. (a) MAE of OSNR monitoring; (b) OSNR monitoring error

### 4.2 基于 TL-MT-DNN 的监测性能研究

图 12 展示了基于 TL-MT-DNN 和不使用 TL 的多任务深度神经网络(w/o TL-MT-DNN)的监测结果。由于目标域  $D_T$  数据集比源域  $D_S$  数据集小,故在目标域  $D_T$  数据集上基于式(5)训练 TL-MT-DNN 和 w/o TL-MT-DNN,可能会导致过拟合现象的出现。

因此,在训练过程中加入 Adam 优化器<sup>[25]</sup>,并使用 Dropout 和  $L_2$  正则化防止过拟合现象的出现。Dropout 在每次训练过程中都随机选择一部分节点不进行学习,即使一部分节点随机断开连接。本文在 TL-MT-DNN 的前两层中加入 Dropout,均使其中 20% 的神经元节点断开连接。 $L_2$  正则化则是在神经网络计算损失

的过程中,在损失项后面加上正则项。因此,重新定义 TL-MT-DNN 的损失函数为  $J$ ,其表达式为

$$J = L_{\text{TL}} + \frac{\lambda}{2m} \|\mathbf{w}\|_2^2, \quad (6)$$

式中: $m$ 为训练样本数; $\mathbf{w}$ 为 TL-MT-DNN 各层的权值; $\lambda$ 为正则化系数,经优化调整后设置为 $\lambda=0.1$ 。从图 12(a)可以清晰地看出:基于式(6)训练的 TL-MT-DNN 收敛速度较快,当 epoch 低于 10 时,随着 epoch 的增大,TL-MT-DNN 的 MFI 准确率迅速上升;当 epoch 达到 10 以上时,基于式(6)训练的 TL-MT-DNN 的 MFI 准确率达到 100% 并保持不变;当 epoch 达到 18 时,基于式(5)训练的 TL-MT-DNN 的 MFI 准确率才达到 100%;对于基于式(6)训练的 w/o TL-MT-DNN 的 MFI 准确率,从整体来看,随着 epoch 的增大,其大致有逐渐上升的趋势,直到 epoch 为 30 时才达到 100%。从图 12(b)可以看出,基于 TL-MT-DNN 和 w/o TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 随着 epoch 的增大均有逐渐减小的趋势,且 TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 均小于 w/o TL-MT-DNN 情况。同时,从图 12(b)的子图中

可以清晰地看出:对于基于式(6)训练的 TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 的收敛速度较快,当 epoch 达到 10 时,其 MAE 均已降至 0.4 dB 以下;当 epoch 达到 15 时,基于式(6)训练的 TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 均已降至 0.3 dB 以下,然后随着 epoch 的逐渐增大,其 MAE 均达到收敛;当 epoch 达到 15 时,基于式(5)训练的 TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 均降至 0.4 dB 以下,然后随着 epoch 的逐渐增大逐渐达到收敛,但其 MAE 整体上大于基于式(6)训练的 TL-MT-DNN 的 MAE;当 epoch 接近 30 时,w/o TL-MT-DNN 的 3 信道 OSNR 并行监测的 MAE 才降至 0.4 dB 以下。由此得出,在仅有少量样本的  $D_T$  数据集上,基于式(6)训练的 TL-MT-DNN 可以获得很好的监测性能,而 w/o TL-MT-DNN 的监测性能没有达到收敛,虽然可以通过增加训练周期或扩充  $D_T$  数据集来获得更佳的监测性能,但是这会增加训练成本。如果以 3 信道 OSNR 并行监测的 MAE 达到 0.4 dB 作为评估标准,基于式(6)训练的 TL-MT-DNN 相较 w/o TL-MT-DNN 约节省了约 66.67% 的训练成本。

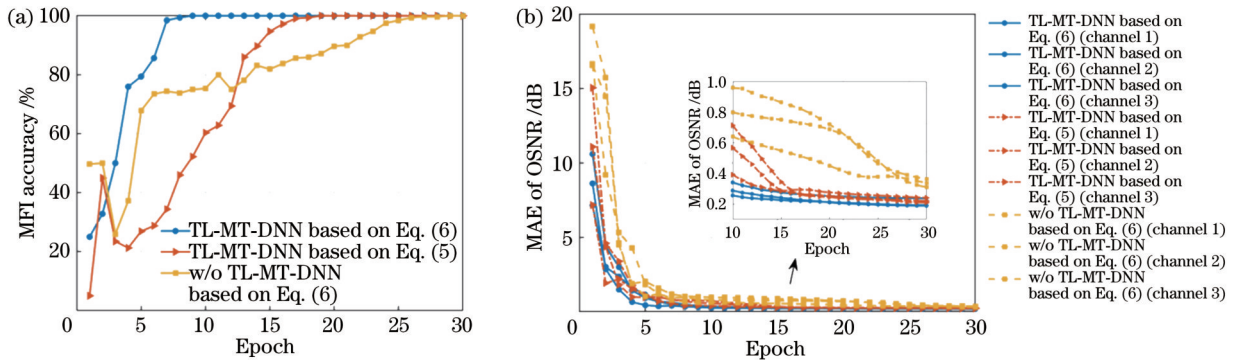


图 12 训练阶段中 TL-MT-DNN 和 w/o TL-MT-DNN 的 MFI 精确度和 3 信道 OSNR 并行监测的 MAE 相对于 epoch 的变化曲线。  
(a) MFI 精确度; (b) 3 信道 OSNR 并行监测的 MAE

Fig. 12 MFI accuracies and MAEs of three-channel OSNR parallel monitoring of TL-MT-DNN and w/o TL-MT-DNN varying with epoch in training phase. (a) MFI accuracy; (b) MAE of three-channel OSNR parallel monitoring

图 13(a)展示了测试阶段中基于式(6)训练完成的 TL-MT-DNN 的 MFI 识别准确率的混淆矩阵,对于 format 0、format 1、format 3 和 format 6 这 4 种调制格式类型的信号,其 MFI 准确率均为 100%。图 13(b)~(d)分别展示了 3 信道 OSNR 并行监测的监测误差,经计算 3 信道 OSNR 监测的 MAE 分别为 0.24 dB、0.20 dB 和 0.19 dB。同时,计算出了基于式(6)训练完成的 w/o TL-MT-DNN 的 MFI 准确率为 97.25%,3 信道 OSNR 监测的 MAE 分别为 0.37 dB、0.30 dB 和 0.31 dB。显然,TL-MT-DNN 的监测精度高于 w/o TL-MT-DNN。因此,所提 OPM 方案在复杂传输环境下也可以达到很好的监测性能,具有较好的可移植性。

## 5 结 论

针对大容量多信道光网络的多参数并行监测问题,提出了一种在 WDM 系统的中间节点基于信号光谱和 MT-DNN 的多信道信号的 OPM 技术。该方法不需单独处理每个信道,只需对采集的多信道光谱整体进行预处理来设计 Ahs,并建立 MT-DNN。首先,分析了 MT-DNN 的超参数(各任务的权重因子、优化器和训练集大小)对 MT-DNN 监测性能的影响。然后,对 MT-DNN 的监测结果进行分析,实现了多信道信号的精准监测。最后,设置复杂传输环境以验证此 OPM 方案的可移植性,提出了 TL-MT-DNN 模型,在仅有少量样本的数据集上实现了低训练成本和低实现复杂度的多信道 MFI 和 OSNR 并行监测。所提 OPM



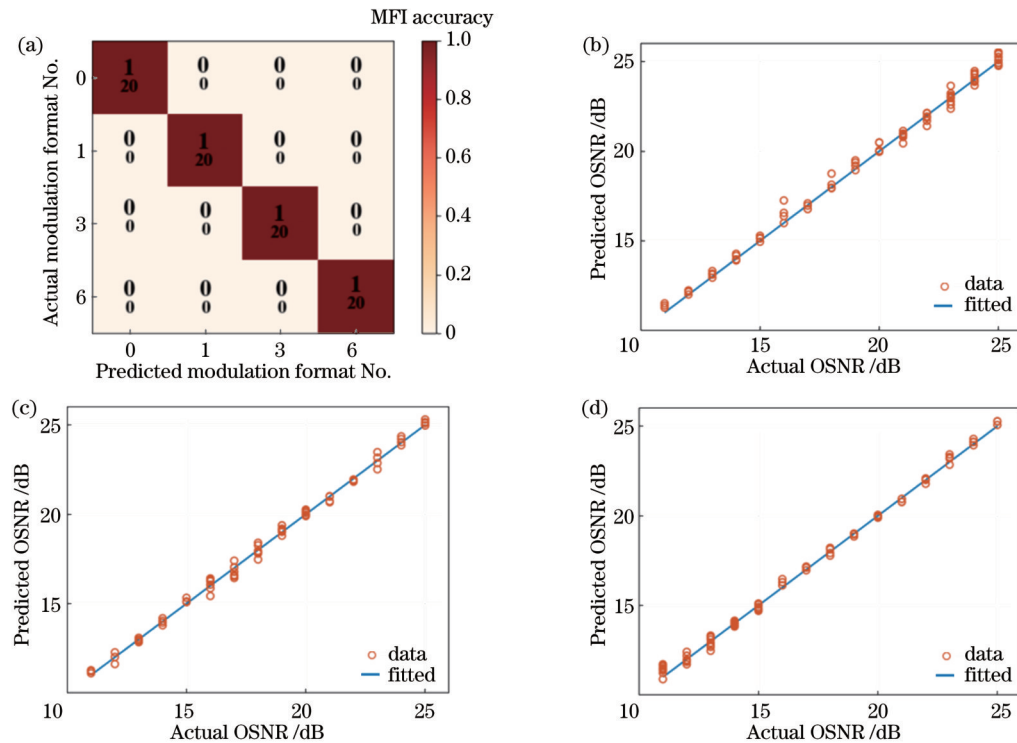


图 13 测试阶段中基于式(6)训练完成的 TL-MT-DNN 的 MFI 准确率的混淆矩阵和三个信道的 OSNR 监测误差。(a) MFI 准确率的混淆矩阵;(b)信道 1 的 OSNR 监测误差;(c)信道 2 的 OSNR 监测误差;(d)信道 3 的 OSNR 监测误差

Fig. 13 Confusion matrix of MFI accuracy and OSNR monitoring errors of three channels for trained TL-MT-DNN based on Eq. (6) in testing phase. (a) Confusion matrix of MFI accuracy; (b) OSNR monitoring error of channel 1; (c) OSNR monitoring error of channel 2; (d) OSNR monitoring error of channel 3

方案仅需要 1 个光谱仪和单个 MT-DNN 就可以实现精准的多信道监测,可以扩展到光纤链路的任意节点或接收端处实现精准的监测,为未来动态灵活光网络 OPM 提供了一种理想选择。

#### 参 考 文 献

- [1] Amrani A, Junyent G, Prat J, et al. Performance monitor for all-optical networks based on homodyne spectroscopy[J]. IEEE Photonics Technology Letters, 2000, 12(11): 1564-1566.
- [2] Tian X Q, Su Y, Hu W S, et al. Precise in-band OSNR and spectrum monitoring using high-resolution swept coherent detection[J]. IEEE Photonics Technology Letters, 2006, 18(1): 145-147.
- [3] Dorrer C. Monitoring of optical signals from constellation diagrams measured with linear optical sampling[J]. Journal of Lightwave Technology, 2006, 24(1): 313-321.
- [4] Wang Z H, Yang A Y, Guo P, et al. Nonlinearity-tolerant OSNR estimation method based on correlation function and statistical moments[J]. Optical Fiber Technology, 2017, 39: 5-11.
- [5] Wang W L, Yang A Y, Guo P, et al. Joint OSNR and interchannel nonlinearity estimation method based on fractional Fourier transform[J]. Journal of Lightwave Technology, 2017, 35(20): 4497-4506.
- [6] Wan Z Q, Yu Z M, Shu L, et al. Intelligent optical performance monitor using multi-task learning based artificial neural network [J]. Optics Express, 2019, 27(8): 11281-11291.
- [7] Yang S L, Yang L, Luo F G, et al. Joint fiber nonlinear noise estimation, OSNR estimation and modulation format identification based on asynchronous complex histograms and deep learning for digital coherent receivers[J]. Sensors, 2021, 21(2): 380.
- [8] Lü H J, Zhou X, Huo J H, et al. Joint OSNR monitoring and modulation format identification on signal amplitude histograms using convolutional neural network[J]. Optical Fiber Technology, 2021, 61: 102455.
- [9] Khan F N, Zhong K P, Zhou X, et al. Joint OSNR monitoring and modulation format identification in digital coherent receivers using deep neural networks[J]. Optics Express, 2017, 25(15): 17767-17776.
- [10] Wang C X, Fu S N, Xiao Z P, et al. Long short-term memory neural network (LSTM-NN) enabled accurate optical signal-to-noise ratio (OSNR) monitoring[J]. Journal of Lightwave Technology, 2019, 37(16): 4140-4146.
- [11] 鞠京泽, 刘庆添, 李宏钊, 等. 基于卷积神经网络的多任务光性能监测[J]. 光学学报, 2022, 42(22): 2206002.
- [12] Ju J Z, Liu Q T, Li H Z, et al. Multi-task optical performance monitoring based on convolutional neural network[J]. Acta Optica Sinica, 2022, 42(22): 2206002.
- [13] Fan X J, Xie Y L, 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.
- [14] Cheng Y J, Fu S N, Tang M, et al. Multi-task deep neural network (MT-DNN) enabled optical performance monitoring from directly detected PDM-QAM signals[J]. Optics Express, 2019, 27(13): 19062-19074.
- [15] Cheng Y J, Zhang W K, Fu S N, et al. Transfer learning simplified multi-task deep neural network for PDM-64QAM optical performance monitoring[J]. Optics Express, 2020, 28(5): 7607-7617.
- [16] Luo H J, Huang Z L, Wu X, et al. Cost-effective multi-

- parameter optical performance monitoring using multi-task deep learning with adaptive ADTP and AAH[J]. *Journal of Lightwave Technology*, 2021, 39(6): 1733-1741.
- [16] Zhang J, Li Y J, Hu S H, et al. Joint modulation format identification and OSNR monitoring using cascaded neural network with transfer learning[J]. *IEEE Photonics Journal*, 2021, 13(1): 7200910.
- [17] Wang D S, Xu Y L, Li J Q, et al. Comprehensive eye diagram analysis: a transfer learning approach[J]. *IEEE Photonics Journal*, 2019, 11(6): 7205019.
- [18] Jha D K, Mishra J K. Transfer learning approach toward joint monitoring of bit rate and modulation format[J]. *Applied Optics*, 2022, 61(13): 3695-3701.
- [19] Zhu X R, Liu B, Zhu X, et al. Transfer learning assisted convolutional neural networks for modulation format recognition in few-mode fibers[J]. *Optics Express*, 2021, 29(22): 36953-36963.
- [20] Dong Z H, Khan F N, Sui Q, et al. Optical performance monitoring: a review of current and future technologies[J]. *Journal of Lightwave Technology*, 2016, 34(2): 525-543.
- [21] Zhou Z H. *Machine learning*[M]. Beijing: Tsinghua University Press, 2016: 97-107.
- [22] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [23] Zhuang F Z, Qi Z Y, Duan K Y, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2021, 109(1): 43-76.
- [24] Abadi M, Barham P, Chen J, et al. TensorFlow: a system for large-scale machine learning[C]//*Proceedings of the 12th USENIX conference on Operating Systems Design and Implementation (OSDI'16)*, November 2-4, 2016, Savannah, GA, USA. New York: Association for Computing Machinery, 2016: 265-283.
- [25] Soydaner D. A comparison of optimization algorithms for deep learning[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2020, 34(13): 2052013.

## Simplified Multi-Channel Parallel Optical Performance Monitoring Based on Deep Learning

Li Mengyan<sup>1</sup>, Wu Jintao<sup>1</sup>, Yang Jingyu<sup>2</sup>, Zhang Lifu<sup>1</sup>, Tan Yong<sup>2</sup>, Qiu Tian<sup>2</sup>, Li Yuebin<sup>1</sup>,  
Deng Heming<sup>1</sup>, Luo Fengguang<sup>2\*\*</sup>, Yang Liu<sup>1,2\*</sup>

<sup>1</sup>*School of Microelectronics, Hubei University, Wuhan 430062, Hubei, China;*

<sup>2</sup>*National Engineering Research Center of Next Generation Internet Access-System, School of Optical and Electronic Information, Huazhong University of Science and Technology, Wuhan 430074, Hubei, China*

### Abstract

**Objective** As emerging services have a higher demand for internet performance, high-capacity, multi-channel, and flexible fiber optic communication systems have become the trend of optical communications with the advantages of dynamic, high-capacity, and transparent transmission. Complex link impairments in large-capacity and multi-channel optical communication systems put forward higher requirements for optical performance monitoring (OPM) technology. The number of monitoring parameters and links of OPM needs to be increased continuously with a higher monitoring accuracy and a larger dynamic range. In the previous papers, existing monitoring mechanisms for optical fiber communications focus on OPM performance and are still dominated by single-channel monitoring schemes. The so-called multi-channel monitoring schemes are operated sequentially by selecting specific channels through tunable optical filters, which may introduce measurement delays for multi-channel systems such as wavelength division multiplexing (WDM) systems. Besides, in next-generation dynamically reconfigurable optical networks, OPM is also conducted on intermediate nodes except for the receiver. Obviously, there are few studies on this flexible OPM. In order to meet these demands for future OPM schemes, it is necessary to develop OPM that can be used for multi-channel monitoring with portability, low complexity, and high accuracy. Therefore, a simplified multi-channel parallel OPM scheme is proposed based on deep learning to overcome the shortcomings in multi-channel monitoring.

**Methods** In this paper, a multi-channel parallel OPM scheme based on signal spectrum and multi-task deep neural network (MT-DNN) is proposed to deal with the shortcomings of the multi-channel OPM. This scheme processes the collected multi-channel spectrum from the fiber link by downsampling, filtering, signal waveform separation, and power normalization. Then, the number of signal sample points is counted based on each power value interval to generate amplitude histograms (Ahs). The Keras library in the TensorFlow deep learning framework (version 2.0) is used to build an MT-DNN model. Since Ahs reflect the statistical distribution of signal amplitude, the bin number vector of Ahs is used as the input of MT-DNN for training, which can realize the multi-channel modulation format identification (MFI) and optical signal-to-noise ratio (OSNR) monitoring of a WDM system. In order to further investigate the performance of this

OPM scheme and cope with the complex transmission environment, a transfer learning-assisted multi-task deep neural network (TL-MT-DNN) is proposed for parallel monitoring of multi-channel MFI and OSNR. This paper shares the parameters of the MT-DNN model in the source domain ( $D_s$ ) except for the output layer to the TL-MT-DNN model in the target domain ( $D_T$ ) to replace random initialization of the network parameters. The parameters of the output layer of the TL-MT-DNN model are randomly initialized. The parameters of the TL-MT-DNN model are tuned for better monitoring performance by using Fine-Tuning, a parameter-tuning method commonly used in transfer learning.

**Results and Discussions** The proposed MT-DNN model for multi-channel parallel MFI and OSNR monitoring is demonstrated in this paper. In the established three-channel WDM coherent optical communication system, an accurate monitoring with MFI accuracy of 100% and mean absolute error (MAE) of 0.16 dB for OSNR monitoring is achieved for three-channel signals with ten modulation formats combined by PDM-4QAM/16QAM/64QAM (Fig. 10 and Fig. 11). In order to deal with a more complex transmission environment, the paper transfers the parameters of MT-DNN to TL-MT-DNN to achieve parallel monitoring of multi-channel MFI and OSNR according to the principle described in Fig. 5. This scheme has better portability and saves a large number of samples and training epochs (Fig. 12). The MFI accuracy can reach 100%, and the MAE of three-channel OSNR monitoring is 0.24 dB, 0.20 dB, and 0.19 dB, respectively (Fig. 13). The results show that the simplified multi-channel parallel OPM scheme based on deep learning proposed in this paper can monitor the multi-channel optical system without processing each channel individually and requiring additional filtering equipment. The scheme can be extended to any node of the fiber optic link or receiver side to achieve multi-channel monitoring, which is suitable for future high-capacity and elastic optical transmission systems.

**Conclusions** This paper proposes a multi-channel OPM technique based on signal spectrum and MT-DNN at the intermediate node of the WDM system for multi-parameter parallel monitoring of high-capacity multi-channel optical networks. The method can monitor multi-channel OPM without processing each channel individually. The performance of this scheme is demonstrated, and the scheme can accurately monitor multi-channel signals. The influence of hyperparameters of MT-DNN (weighting factor of each task, optimizer, and training set size) on its monitoring performance is studied. In order to verify the portability of this OPM scheme for complex transmission environments, a TL-MT-DNN model is proposed and demonstrated with a low training cost and low implementation complexity. The results show that the proposed intelligent OPM scheme requiring only one spectrometer and a single MT-DNN can achieve accurate multi-channel monitoring, which can be extended to any node of the fiber optic link or receiver side to achieve accurate monitoring. Due to these advantages, this method provides a certain research reference for future flexible and high-capacity optical network performance monitoring.

**Key words** machine vision; optical performance monitoring; wavelength division multiplexing; optical signal-to-noise ratio; modulation format identification; transfer learning; multi-task deep neural network