

doi:10.13756/j.gtxyj.2022.06.008

光通信系统与网络技术

迁移学习辅助基于机器学习的传输质量评估

王家馨

(南京邮电大学 电子与光学工程学院、柔性电子(未来技术)学院, 南京 210023)

摘要:当光纤链路的数据分布发生变化时,机器学习评估链路传输质量需要重新搜集数据并重新训练,这个过程是耗时的、复杂的。迁移学习直接将以前学到的知识应用到现在的任务,需要更少的数据。因此,文章提出在具有相关性的光通信系统中,使用两种迁移学习方式辅助基于机器学习的多分类器,仿真结果表明,迁移学习结合微调技术的机器学习多分类器比直接迁移的机器学习多分类器多分类指标分数提高 0.25 以上,减少了样本不均衡的影响,每个类别都具有高性能,证实迁移学习结合微调技术的机器学习多分类器能够减小数据集,降低了搜集数据集的成本,提高了光纤链路传输质量评估问题的效率。

关键词:光纤链路;传输质量;机器学习;迁移学习

中图分类号:TN929.11

文献标志码:A

文章编号:1005-8788(2022)06-0045-05

Transfer Learning Assisted Transmission Quality Evaluation based on Machine Learning

WANG Jia-xin

(College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology),
Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: When the data distribution of optical fiber link changes, machine learning can be used to evaluate the transmission quality of link, which needs to recollect data and retrain. This process is time-consuming and complex. Transfer learning directly applies the previously learned knowledge to the current task, which requires less data. Therefore, it is proposed to use two transfer learning methods to realize multi classifier based on machine learning in the correlated optical communication system. The simulation results show that the multi classifier of machine learning combined with transfer learning and fine-tuning technology improves the multi classification index score by more than 0.25 compared with the direct transfer machine learning multi classifier. It is also shown that the impact of sample imbalance is reduced, and each category has high performance. It is proved that the machine learning multi classifier combined with transfer learning and fine-tuning technology can reduce the size of data set, reduce the cost of collecting data set, and improve the efficiency of transmission quality evaluation process in optical fiber link.

Key words: fiber optical links; quality of transmission; machine learning; transfer learning

0 引 言

近年来,机器学习(Machine Learning, ML)评估方法在光通信领域拥有广泛的研究,迁移学习(Transfer Learning, TL)已被证明是一种有效的知识转移方法,但只有少数研究提出使用 TL 来预测与传输质量(Quality of Transmission, QoT)相关的各种指标(例如,误码率(Bit Error Ratio, BER)和 Q 因子)^[1]。在文献[2]中,采用一种基于人工神经网络(Artificial Neural Network, ANN)的 TL 框架来预测实时混合线路速率光学系统中的 Q 因子。结果表明,应用知识迁移来准确预测目标领域的 QoT,只需少量训练样本来微调权重。文献[3]提出基于卷积神经网络(Convolution Neural Network,

CNN)深度 TL 的多损伤诊断技术,减少了 95% 以上的训练时间且具有 99.88% 的准确率。文献[4]提出深度神经网络(Deep Neural Network, DNN)与 TL 相结合,对多域光网络进行 QoT 预测。结果表明,该方法可以显著降低估计精度新任务所需的训练数据量。

以上研究工作发现,神经网络是 TL 的研究热点,但神经网络性能不易解释,缺失利用传统 ML 算法方面的研究;其次,TL 在光纤链路 QoT 评估上的研究较少。因此,提出新的思路,使用直接 TL 与 TL 并微调参数两种方法在相关光通信系统中进行仿真分析并比较,验证 TL 并微调的基于 ML 的 QoT 多分类器在相关光纤通信系统的优势,其中 ML 算法使用传统 ML 和神经网络。

收稿日期:2022-04-07


作者简介:王家馨(1996—),女,江苏阜宁人。硕士,主要研究方向为机器学习在光通信中的应用。

通信作者:王家馨,硕士。E-mail: 1002054577@qq.com

1 模型构建及多分类器介绍

系统 A 采用的光纤通信系统模型:在网络线性拓扑中,假设使用 9 个信道、信道间隔为 50 GHz 的波分复用链路,码元速率为 32 GBaud,噪声带宽为 32 GHz 的偏振复用相干未补偿系统^[5]。拓扑采用色散无补偿的标准单模光纤(光纤损耗系数为 0.22 dB/km,非线性系数为 $1.3 \text{ 1}/(\text{W} \cdot \text{km})$),色散

系数为 $21 \text{ ps}^2/\text{km}$),构成等跨度的透明传输同质链路,每个跨度的损耗全部由光纤损耗组成,掺铒光纤放大器(Erbium-doped Fiber Amplifier, EDFA)以相同跨距均匀放在链路上。EDFA 完全弥补上一个跨度的损耗,噪声指数为 5 dB,EDFA 增益由光纤损耗系数决定。节点由具有波长选择开关(Wavelength Selection Switch, WSS)技术的可重构光分插复用器构成。光纤链路结构如图 1 所示。



注:Tx 为发送端; Rx 为接收端; MUX 为复用器; DMUX 为解复用器; PM-BPSK、PM-QPSK、16QAM 和 64QAM 分别为偏振复用二进制移相键控、偏振复用正交相移键控、16 进制正交幅度调制和 64 进制正交幅度调制。

图 1 光纤链路结构图

Figure 1 The structure diagram of optical fiber link

系统模型 B 与 A 不同的部分是信道间隔,信道带宽与码元速率相同,为 32 GHz(奈奎斯特一波分复用);系统模型 C 与 A 不同的部分是信道带宽为 64 GHz,选择大于系统 A 的带宽值^[6-7]。

1.1 链路系统参数设置

根据文献[5]、[6]和[8]设置链路参数,如表 1 所示。为系统相关,实现 TL,则 3 个系统链路参数的取值是相交的,有相同部分。

表 1 A、B 和 C 链路参数设置

Table 1 A, B and C link parameter settings

参数	A 参数范围	B 参数范围	C 参数范围
链路长度/km	80~7 500	90~7 500	50~7 000
跨度长度/km	80,100,120,150	90,110,130,150	50,80,110,140
调制格式	PM-BPSK, PM-QPSK, 16QAM,64QAM	PM-BPSK, PM-QPSK, 16QAM,64QAM	PM-BPSK, PM-QPSK, 16QAM,64QAM
数据速率 Gbit/s	40,50,100	40,50,100	50,100
信道发射功率/dBm	-10~5	-10~6	-15~0

1.2 获取数据

根据文献[4],确定数据集的特征为链路长度、跨度长度、调制格式、数据速率和信道发射功率, QoT 指标为 BER^[9],即数据集标签,并使用文献[5]和[10]中的 QoT 评估公式,在 Matlab2020a 软件平台构建 QoT 评估公式,获得初始数据集 A、B 和 C。

根据国际电信联盟电信标准分局(International Telecommunication Union-Telecommunication Sector, ITU-T) G. 975. 1 建议的前向纠错标准, BER 阈值设置为 4×10^{-3} 。对于多分类器而言,设置两个阈值,分别为 4×10^{-3} 和 4×10^{-5} 。 $BER = 4 \times 10^{-3}$ 时 QoT 及格,符合基本链路 QoT 要求; $BER = 4 \times 10^{-5}$ 时误码更少, QoT 精度更高。将 $BER < 4 \times 10^{-5}$ 、 $4 \times 10^{-5} < BER < 4 \times 10^{-3}$ 和 $BER > 4 \times 10^{-3}$ 分别对应 QoT 优良、合格和不合格。数据集中根据 BER 值设置标签。3 个数据集记录如表 2 所示,数据集的特征空间相同而分布不同,数据集相关。

表 2 数据集内容

Table 2 Dataset content

	总样本数量	类别 0 (优良)	类别 1 (合格)	类别 2 (不合格)
数据集 A	32 991	8 722	4 391	19 878
数据集 B	20 375	7 318	2 512	10 545
数据集 C	20 215	6 724	2 603	10 888

1.3 ML 多分类器介绍

1.3.1 ML 算法简介

(1) 传统 ML 算法

支持向量机(Support Vector Machine, SVM)是监督 ML 算法,通过一对多或一对一的策略实现多分类。SVM 的优点是泛化能力强,过拟合概率小,分类准确率高,中小型数据集使用其频率高^[11-12]。

随机森林是多个决策树的集成,是使用 bagging 方法的代表之一,能够执行分类和回归任务^[13-14]。在随机森林对陌生样本进行预测时,集成的所有决策树对其进行预测,会得到很多预测结果。分类时,对预测结果采用投票法,而回归时采用平均法。

(2) 神经网络

ANN 由一系列相互关联的人工神经元以拓扑结构的形式连接组成一个数学或计算模型,这些神经元有能力从经验数据中进行学习,以此模拟人类神经网络的功能和结构^[14-15]。

DNN 与 ANN 不一样的部分是隐藏层的数量,除了一层输出层,还包含两层以上的隐藏层,是一种典型的深度学习模型,能够实现逼近某个函数^[15]。

1.3.2 多分类器介绍

多分类器结构如图 2~3 所示。TL 选择基于参数的迁移方式,即源域 A 系统和目标域 B 和 C 系统共享模型参数。数据集 A、B 和 C 相关,则可进行微调技术。




图 2 迁移+微调分类器结构图

Figure 2 The structure diagram of migration and fine-tuning classifier




图 3 直接迁移分类器结构图

Figure 3 The structure diagram of direct migration classifier

微调技术将训练集 B 和 C 输入由训练集 A 训练好的 ML 多分类器中,在预先训练好的多分类器的模型参数基础上,由于系统相关,更快获得拟合系统 B 和 C 的模型参数。SVM 模型对决策函数的权重和偏置进行微调,随机森林对节点特征和特征阈值进行微调,神经网络对神经元的权重和偏置进行微调。直接 TL 将训练集 A 训练好的 ML 多分类器,直接用于系统 B 和 C,输入测试集 B 和 C 对模

型进行评估。

2 仿真结果分析

以 A 系统为源域,B 和 C 系统为目标域。算法进行超参数调优,使用系统 A 数据集以最优超参数的算法训练得到多分类器,使用 B 和 C 系统的数据测试评估并比较直接 TL 和 TL 并微调两种方式下的多分类器分类性能。

2.1 未微调的多分类器性能分析

多分类器在系统 B 中的多分类性能指标分数总结如表 3 所示,ANN 和 DNN 均运行 30 次取均值。Kappa 为统计学中评估一致性的一种方法,可用于衡量分类精度;F1_macro 为 F1 分数的宏平均计算方式,取值范围为 0~1,是评估多分类性能的指标^[16]。

表 3 系统 B 的多分类性能指标分数

Table 3	Multi-classification performances of system B			
	Kappa	海明距离	准确率	F1_macro
SVM	0.885 5	0.067 6	0.932 3	0.879 0
随机森林	0.824 4	0.103 6	0.896 4	0.812 6
ANN	0.880 5	0.070 5	0.929 5	0.872 7
DNN	0.881 1	0.070 1	0.929 8	0.873 5

表 3 记录了系统 B 中的多分类性能指标分数,SVM、ANN 和 DNN 准确率在 0.92 以上,Kappa 和 F1_macro 关注样本较少的类别,分数在 0.87 以上。随机森林三者分数均最低,分别为 0.896 4、0.812 6 和 0.824 4。海明距离,分数越低性能越好,SVM、ANN 和 DNN 值相近。随机森林比前 3 种分类器分数大一个精度。

综上,4 种性能指标分数,基于训练集 A 的 ML 多分类器整体对系统 B 的 QoT 分类精度较高,但 4 种分类器的准确率都比 F1_macro 和 Kappa 高,所以没有经过微调的多分类器对数据集 B 中样本数量较少的类别分类能力一般,其中 SVM 性能最好。

多分类器在系统 C 中的多分类性能指标分数总结如表 4 所示,ANN 和 DNN 均运行 30 次取均值。

表 4 系统 C 的多分类性能指标分数

Table 4	Multi-classification performances of system C			
	Kappa	海明距离	准确率	F1_macro
SVM	0.810 3	0.111 5	0.888 5	0.831 4
随机森林	0.632 7	0.209 1	0.790 9	0.675 9
ANN	0.842 2	0.092 0	0.908 0	0.851 6
DNN	0.840 2	0.093 6	0.907 4	0.850 2

表 4 记录了系统 C 中的多分类性能指标分数,SVM、ANN 和 DNN 的准确率均在 0.88 以上,F1_

macro 和 Kappa 系数的分数皆在 0.80 以上,其中 ANN 和 DNN 分数相近。随机森林三者分数均最低,分别为 0.790 9、0.675 9 和 0.632 7。ANN 和 DNN 的海明距离分数差距为 0.001 6。随机森林和 SVM 比 ANN 和 DNN 分数大一个精度。结合 4 个指标来分析,ANN 和 DNN 在系统 C 中的 QoT 分类能力与 SVM 相比较强,分类精度较高。SVM 的分类精度中等,随机森林对系统 C 的分类能力较差。

比较 4 种分类器的准确率、F1_macro 和 Kappa 系数,SVM、ANN 和 DNN 的准确率比 F1_macro 和 Kappa 系数高 0.05~0.06,随机森林的准确率比 F1_macro 和 Kappa 系数高 0.12~0.16。结果表明,没有经过微调的多分类器对数据集 C 中样本数量较少的类别分类能力一般。

综上,基于训练集 A 的 ML 分类器对系统 C 的分类能力总体尚优,其中 ANN 和 DNN 总体性能好。随机森林对系统 C 的分类能力较差,不适合用于系统 C。与系统 B 性能相比,系统 C 的性能分数均低。4 种分类器对系统 B 的分类能力明显好于系统 C,这说明系统 B 与系统 A 的相关性更强。

2.2 微调的多分类器性能分析

多分类器在系统 B 中的多分类性能指标分数总结如表 5 所示,ANN 和 DNN 均运行 30 次取均值。

表 5 系统 B 的多分类性能指标分数

	Kappa	海明距离	准确率	F1_macro
SVM	0.956 6	0.025 6	0.974 3	0.954 7
随机森林	0.886 9	0.066 3	0.933 7	0.880 6
ANN	0.963 0	0.021 8	0.978 2	0.962 2
DNN	0.970 1	0.017 6	0.982 4	0.968 4

表 5 记录了系统 B 中的多分类性能指标分数,SVM、ANN 和 DNN 的准确率、F1_macro 和 Kappa 系数三者分数皆在 0.95 以上。随机森林三者分数均最低,分别为 0.933 7、0.880 6 和 0.886 9,分数也均在 0.88 以上。所有分类器的海明距离精度级别都在 0.01。结合 4 个指标分析,经过微调后的 ANN 和 DNN 在系统 B 中的 QoT 分类能力较 SVM 强,分类精度很高。SVM 的分类精度也很高,随机森林对系统 C 的分类能力也高。

测试集的大小对性能影响可忽略不计,与表 3 数据相比,经过微调的 4 种分类器分类质量明显提高,表 3 中,SVM、ANN 和 DNN 的 F1_macro 和

Kappa 系数的数值都处于 0.88 左右,随机森林在 0.82 左右。经过微调,表 4 中 SVM、ANN 和 DNN 的 F1_macro 和 Kappa 系数数值都处于 0.95 以上,提升了 0.07 分,进步显著。随机森林在 0.88 左右,提高了 0.06 分,提高了随机森林对系统 B 的分类能力。

综上,得到经过微调的基于 ML 多分类器对系统 B 的分类能力提高甚多,分类精度高。DNN 的性能最好,性能分数最佳。

多分类器在系统 C 中的多分类性能指标分数总结如表 6 所示,ANN 和 DNN 均运行 30 次取均值。

表 6 系统 C 的多分类性能指标分数

	Kappa	海明距离	准确率	F1_macro
SVM	0.953 0	0.027 5	0.972 5	0.954 2
随机森林	0.916 2	0.048 4	0.951 6	0.917 4
ANN	0.961 9	0.022 2	0.977 8	0.961 7
DNN	0.968 2	0.018 5	0.981 5	0.968 3

表 6 记录了系统 C 中的多分类性能指标分数,SVM、ANN 和 DNN 的准确率、F1_macro 和 Kappa 系数三者分数皆在 0.95 以上。随机森林分数三者均最低,分别为 0.951 6、0.917 4 和 0.916 2,分数也均在 0.91 以上。ANN 的分数与 DNN 相近。ANN 和 SVM 的海明距离分数差距微小,为 0.006 左右,DNN 最小,随机森林分数最大,所有分类器的海明距离都在 0.01 级别的精度。结合 4 个指标来分析,经过微调后 4 种分类器对系统 C 的 QoT 分类能力增强,分类精度显著变高。

同样,与表 4 相比,微调后的 4 种分类器性能指标分数大幅度提高。表 4 中,SVM、ANN 和 DNN 的 F1_macro 和 Kappa 系数的数值都处于 0.84 左右,随机森林分数在 0.66 左右。经过微调,表 6 中 SVM、ANN 和 DNN 的 F1_macro 和 Kappa 系数的数值都处于 0.95 以上,提升 0.11 分。随机森林分数在 0.91 左右,提高了 0.25 分,数量较少的样本分类能力明显提高。

综上,得到微调后的分类器性能都比未微调的分类器性能提高很多,提升了系统 C 的分类精度,减少了样本不均衡影响。随机森林的变化非常大,这是由于随机森林依赖数据以进行特征和特征阈值的选择,若是不进行微调,则需要目标域与源域的系统相关性强,生成的随机森林相关性也强,否则直接迁移不能实现较好的分类,微调后所有指标分数都得到改善。

2.3 比较结果

比较系统 B 和系统 C 在直接 TL 和 TL 并微调的两种方式下得到的多分类性能分数,得出结论,TL 结合微调能够极大改善分类器的性能,减少对系统间相关性的依赖。传统 ML 分类器的分类质量不逊于神经网络,且其算法复杂度较低,性能原因更容易解释分析。因此,传统 ML 对于 TL 是一个有效选择。

3 结束语

本文提出直接 TL 和 TL 并微调两种方法去解决 ML 光纤链路 QoT 评估器训练复杂的问题,构造的 4 种 ML 链路 QoT 多分类器的直接迁移指标分数在 0.63 以上,TL 并微调在 0.88 以上,与其他研究结果相比,从新的思路验证了 TL 辅助并进行微调的多分类器实现少样本高精度评估相关通信系统的链路 QoT,传统 ML 多分类性能优秀且易解释,对光纤链路 QoT 评估具有很好的实现意义。未来可以引入更多 TL 和 ML 相关的技术,进一步提升评估光纤链路的效率。

参考文献:

- [1] Rottondi C, Marino R D, Nava M, et al. On the Benefits of Domain Adaptation Techniques for Quality of Transmission Estimation in Optical Networks [J]. *Journal of Optical Communications and Networking*, 2021, 13(1):A34—A43.
- [2] Yu J, Mo W, Huang Y K, et al. Model Transfer of QoT Prediction in Optical Networks based on Artificial Neural Networks[J]. *Journal of Optical Communications and Networking*, 2019, 11(10):C48—C57.
- [3] Xu Y L, Wang D S, Zhang M, et al. Deep Transfer Learning based Multi-Impairment Diagnosis for PAM-4 Optical Communication Systems[C]//2019 18th International Conference on Optical Communications and Networks (ICOON). Huangshan, China: IEEE, 2019:1—3.
- [4] Liu Y L, Chen X L, Proietti R, et al. Evol-TL: Evolutionary Transfer Learning for QoT Estimation in Multi-domain Networks[C] //Optical Fiber Communications Conference and Exhibition (OFC). San Diego, USA: IEEE, 2020:1—3.
- [5] Aladin S, Tremblay C. Cognitive Tool for Estimating the QoT of New Lightpaths[C]//Optical Fiber Communication Conference and Exposition (OFC). San Diego, USA: IEEE, 2018:1—3.

- [6] Carena A. Modeling of the Impact of Nonlinear Propagation Effects in Uncompensated Optical Coherent Transmission Links[J]. *Journal of Lightwave Technology*, 2012, 30(10):1524—1539.
- [7] Tremblay C, Allogba S, Aladin S. Machine Learning Techniques for Estimating Quality of Transmission Estimation of Lightpaths[C]//2018 IEEE Photonics Society Summer Topical Meeting Series (SUM). Hilton Waikoloa Village, USA: IEEE, 2018.
- [8] Tremblay C, Allogba S, Aladin S. Quality of Transmission Estimation and Performance Prediction of Lightpaths Using Machine Learning[C]//45th European Conference on Optical Communication (ECOC 2019). Dublin, Ireland: IEEE, 2019:1—3.
- [9] Pointurier Y. Design of Low-margin Optical Networks [J]. *Journal of Optical Communications and Networking*, 2017, 9(1):A9—A17.
- [10] Poggiolini P, Bosco G, Carena A, et al. The GN-model of Fiber Non-linear Propagation and Its Applications [J]. *Journal of Lightwave Technology*, 2014, 32(4):694—721.
- [11] Aurélien Geron(奥雷利安·杰龙). 机器学习实战:基于机器 Scikit_Learn, Keras 和 Tensorflow[M]. 宋能辉, 李炯, 译. 北京:机械工业出版社, 2020.
Aurélien Geron. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, Second Edition[M]. BO'Reilly Media, Inc., 2020.
- [12] Morais R M, Pedro J. Machine Learning Models for Estimating Quality of Transmission in DWDM Networks[J]. *Journal of Optical Communications and Networking*, 2018, 10(10):D84—D99.
- [13] Khan I, Bilal M, Curri V. Assessment of Cross-train Machine Learning Techniques for QoT-estimation in Agnostic Optical Networks [J]. *OSA Continuum*, 2020, 3(10):2690—2706.
- [14] Khan F N, Fan Q, Lu C, et al. An Optical Communication's Perspective on Machine Learning and Its Applications[J]. *Journal of Lightwave Technology*, 2019, 37(2):493—516.
- [15] 周志华. 机器学习[M]. 北京:清华大学出版社, 2018.
Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2018.
- [16] Albon C(克里斯阿尔本). Python 机器学习手册:从数据预处理到深度学习[M]. 韩慧昌, 林然, 徐江, 译. 北京:电子工业出版社, 2018.
Chris Albon. Python: Machine Learning with Python Cookbook[M]. BO'Reilly Media, Inc., 2018.