分支识别：利用机器学习的无源光网络

Khouloud Abdelli[1,3], Carsten Tropschug[2], Helmut Grießer[1], Sander Jansen[1], 和 Stephan Pachnicke[3]
[1]ADVA Optical Networking SE，Fraunhoferstr. 9a，82152 慕尼黑/Martinsried，德国
[2] ADVA Optical Networking SE，Märzenquelle 1-3，98617 迈宁根，德国
[3] 基尔克里斯蒂安-阿尔布雷希特大学，Kaiserstr. 2，24143 基尔，德国
电子邮箱：*KAbdelli@adva.com*

摘要：本文提出并通过实验验证了一种机器学习方法，可改善具有近似等间距分支的无源光网络的监测效果。该方法的诊断准确率达到98.7%，事件定位误差为0.5米。© 2022年 作者。

1. 引言

无源光网络（PON）凭借高带宽、低成本、灵活性和可扩展性，已成为一种颇具前景的宽带光纤接入网解决方案。无源光网络系统主要部署于光纤到户（FTTH）网络，以提供种类丰富的通信和多媒体服务 [1]。由于省去了有源电子元件，运营支出得以降低，外线设施中的故障发生率也随之下降。在这些系统中实施和部署有效的监测方案，还能进一步显著节省运营支出。光时域反射测量（OTDR）是一种基于瑞利背向散射的技术，主要用于监测单条光纤段。然而，将OTDR用于监测无源光网络系统颇具挑战，因为各分支的背向散射信号会叠加在一起，难以区分各分支的后向信号 [2]。当分支末端间距相同或近似相同时，事件分析最为困难，因为长度相同的分支所产生的反射信号会相互重叠并叠加。此外，远端节点处光分路器的高损耗会导致背向散射信号显著衰减（例如，1:32分路器会使测得的功率损失15 dB [3]）。为应对上述挑战，一种解决方案是将可调谐光时域反射仪与波分复用器配合使用，为每个分支提供专用监测波长。然而，由于可调谐光时域反射仪网络设备成本高昂，该方案的费用相当高。另一种简单有效的方案是在每个分支末端使用光学参考反射器，通过检测参考反射器峰值是否出现及其高度变化，提高分支的可区分性。然而，如果各分支长度几乎相同，用于分析反射器数据的传统光时域反射仪事件检测方法往往表现不佳，因此难以应用于实际部署的、分支长度相近的网络。近期，有研究提出了一种基于机器学习（ML）的无源光网络故障诊断方法[4] ，但其重点是确定无源光网络系统中的故障类型，而非识别故障分支。

为克服上述不足，本文提出一种用于分支长度相近的PON系统事件监测的基于机器学习的方法。该方法利用安装在各分支末端的反射器所获取的监测数据，即使反射脉冲发生重叠，也能识别各分支。我们使用从一个PON系统获得的光时域反射仪实验数据验证了所提出的方法的效率，并使用来自另一个PON系统的此前未见过的实验数据评估了该机器学习方法的鲁棒性和泛化能力。

2. 所提出的方法

在我们的实现中，首先将从PON系统记录的光时域反射仪轨迹划分为固定长度的序列，然后将机器学习模型应用于每个序列，同时输出事件类型（C_0：无反射，C_1：一个反射，C_2：两个反射）及其位置。输入机器学习模型的序列长度经过专门选择，以确保对于光时域反射仪测量所用的脉冲宽度，该序列中出现两个以上反射的可能性极低。值得注意的是，训练和推理阶段所考虑的两种反射模式均包含重叠峰，其中一个反射部分或完全被遮挡，因此难以区分。

2.1 实验数据

图1所示的实验装置A用于记录在不同条件下包含各种反射模式的OTDR轨迹。通过级联分光比为1:32的光分路器，搭建出真实的无源光网络。每个分支末端均放置一个反射器或一个未插合的物理接触（PC）连接器，以产生反射。使用具有不同衰减设置的静态光衰减器调节各反射的高度，衰减范围为1至16 dB，以生成多种模式，包括代表故障分支状态的情形。相邻分支（第二和第三个分支）之间的长度差在1至3 m之间变化，以生成两个反射脉冲重叠的反射样本。将可变光衰减器（VOA）

置于1000 m光纤之后，用于模拟较长馈线光纤或较高分光比的影响。VOA 衰减范围为0至12 dB。OTDR配置参数，即脉冲宽度以及

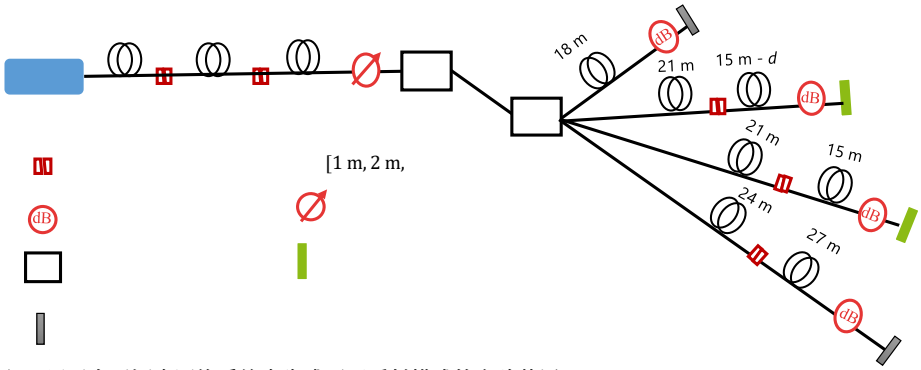

图1：用于在无源光网络系统中生成不同反射模式的实验装置A。

波长设为 ns，an 用于采集和平均 OTDR 轨迹的平均时间范围为 2 ms 至 2 s。总计记录并归一化了 0~8,159 条 OTDR 轨迹。对于每条生成的OTDR轨迹和所研究的事件类型，随机提取4个长度为50的序列，其中包括该事件的模式。请注意，通过改变OTDR轨迹分割的起始点，所研究事件类型（即一个或两个反射）在所得序列中的位置会发生变化，从而提高机器学习模型在实际应用中的预测能力；在实际应用中，机器学习模型会应用于任意分割的OTDR序列，而这些序列中感兴趣的事件类型可能位于不同位置。对于每个所得序列，都会标注事件类型（（$C_i\ \forall i \in \{0 \dots 2\}$））以及该事件在序列中的事件位置索引。最终构建了一个由97,902个样本组成的数据集（每种所研究事件类型包含~32,634个样本），并将其划分为训练集（60%）、验证集（20%）和测试集（20%）。。

2. 模型架构

所提出的机器学习方法的结构 如图 2 所示。该机器学习模型以长度为 50 的光时域反射仪（OTDR）序列 of 为输入，并输出事件类型及其位置。首先将输入馈入具有 64 个单元的门控循环单元（GRU）[5] 层，以提取相关的序列特征 [h_1, h_2,...h_{50}]。注意力层随后为每个提取的特征 h_i 分配一个权重（即注意力分数）α_i [6]。之后，将计算得到的不同权重 α_i 聚合，生成加权特征向量（即注意力上下文向量） c，计算方式为 $\sum_i \alpha_i h_i$，该向量捕获相关的信息 to提高.....的性能模型。随后，c 被传递至两个任务专用层，每层包含 16 个神经元，利用基于注意力的 GRU 共享层提取的知识，分别完成反射类型分类（T_1） 和事件定位（T_2）任务。机器学习模型的总损失由两个任务各自损失的加权和计算得出，其中，交叉熵损失和回归损失（均方误差）分别为 T_1 和 T_2的损失。

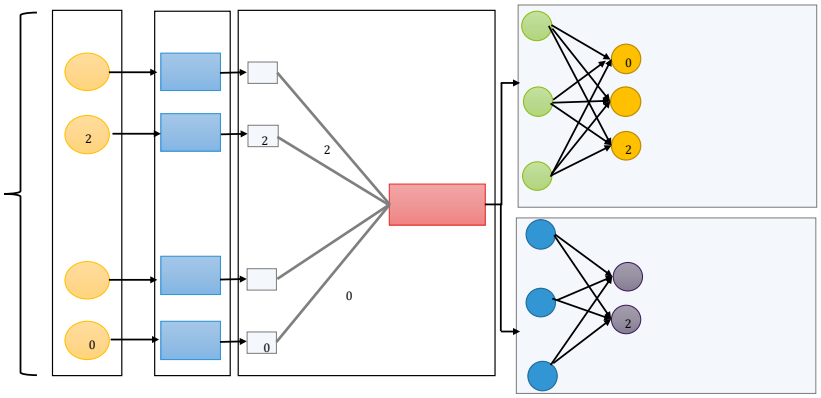

图 2：所提出的方法的机器学习模型架构。

3. 结果与讨论

首先使用未见测试数据集评估机器学习方法的性能。图 3 (a) 所示的混淆矩阵表明，该方法对不同类别（即事件类型）的分类效果良好，平均诊断准确率达到 98.7%。在极少数情况下，类别 C_1 和 C_2 可能会被误分类，尤其是对于类别 C_2 的样本，其中一个反射完全消失。图 3 (b) 表明，该方法的预测误差非常小（即所研究事件类型的预测位置与实际位置之间的差值），平均值为 0.05 m，标准差为 0.6，证明机器学习模型能够准确定位事件。图 3 (c) 显示了增加 VOA 衰减（其效果与

增加馈线光纤长度或分光比）对诊断准确率的影响。即使馈线光纤更长（最长达 62.5 km）或分光比更高，诊断准确率仍然很高（高于 96.5%）。

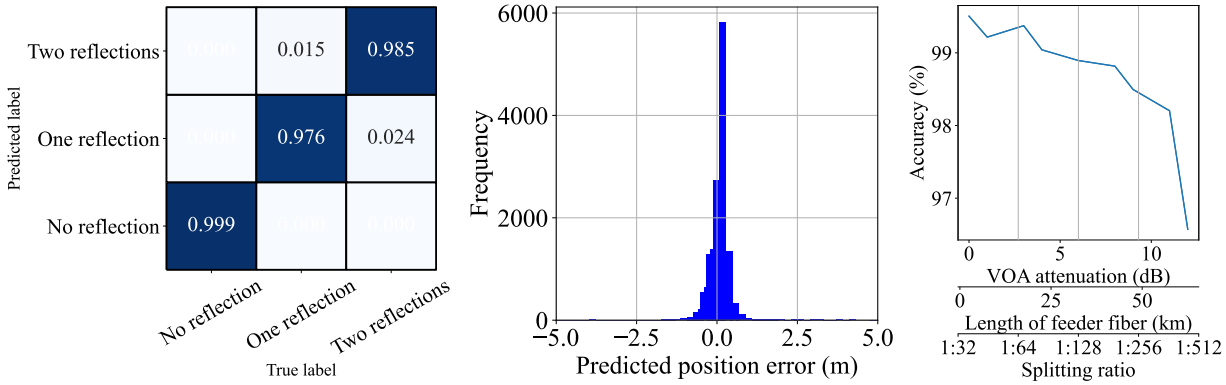

(a) (b) (c)

图 3：(a) 混淆矩阵，(b) 事件位置预测误差的直方图，以及 (c) VOA 衰减对准确率的影响。我们从诊断准确率和均方根误差（RMSE）两方面，将所提出的机器学习方法与当前最先进的机器学习技术进行比较，包括多层感知机（MLP）、卷积神经网络（CNN）、长短期记忆网络（LSTM）和 GRU。如表 1 所示，所提出的方法优于其他机器学习算法；得益于注意力机制与 GRU 的结合，该方法能够更好地捕捉数据中的相关模式，因此取得了最高的准确率和最低的 RMSE。

随后，使用来自图 4 所示的另一种实验装置B的未见测试数据评估机器学习模型的性能，以检验所提出方法的鲁棒性。我们将该机器学习方法与一种传统方法——基于阈值的系统——进行比较。在该系统中，针对测试集优化用于检测反射的阈值，以提高检测能力并降低误报率。图 5 所示结果表明，首先，所提出的模型具有良好的泛化能力（在此前未见过的数据上测试时仍能取得较高的准确率）；其次，我们的方法显著优于传统方法。传统方法的表现较差，是因为在衰减设置较高时，它无法识别重叠反射，而第二个反射会完全或部分消失。表 1. 不同机器学习方法的比较

方法	准确率（%）	均方根误差 (m)
MLP	77.3	2.3
CNN	86.9	2.04
LSTM	96.2	1.1
GRU	97.9	0.74
所提出的方法	**98.6**	**0.5**

方法

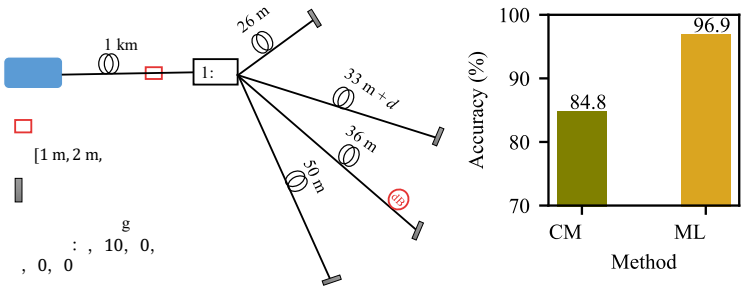

图4：用于生成测试数据的实验装置B。图5：不同方法的比较。

4. 结论

我们提出并通过实验验证了一种基于机器学习的方法，用于增强具有近似等间距分支的PON系统中的光纤分支监测。实验结果证明，所提出的模型优于其他先进的机器学习技术，也优于传统采用的方法。未来，我们计划将机器学习模型推广到能够识别一个序列中的两个以上反射（即分支）。本研究在CELTIC-NEXT项目AI-NET PROTECT（项目编号C2019/3-4）框架内开展，部分由德国联邦教育与研究部资助（资助编号FKZ16KIS1279K）。

5. 参考文献

[1] ,. “ bgsw k :.w, ” J w k m, 016。[2] M. A. Esmail 等，“TDM无源光网络物理层监测技术：综述”，IEEE Comm. Surv. & Tut.，第15卷，第2期，第943-958页，2013年。[3] M.-M. Rad, .，“w k m g: h g m”，EEE Comm. Mag.，第49卷，第2期，第S45-S52页（2011年）。[4] K.Abdelli 等，“基于门控循环单元的自编码器：用于无源光网络中的光链路故障诊断”，ECOC 2021。[5] K. Cho, .，“g h g E -Decod S M h”，EMNLP，2014。[6] K. Abdelli 等，“用于光通信半导体激光器预测性维护的基于机器学习的框架”，IEEE J. of Lightw. Technol.，第40卷，第14期，第4698-4708页，2022年