

# 基于条件对抗生成网络数据增强的相敏光时域反射仪模式识别

张印<sup>1</sup>, 胡挺<sup>1</sup>, 李猷兴<sup>2</sup>, 王剑<sup>1</sup>, 苑立波<sup>1\*</sup>

<sup>1</sup>桂林电子科技大学光电工程学院, 广西 桂林 541004;

<sup>2</sup>哈尔滨工程大学物理与光电工程学院, 黑龙江 哈尔滨 150006

**摘要** 本文针对光纤传感技术中相敏光时域反射仪( $\Phi$ -OTDR)数据采集受限的问题,提出了一种基于条件对抗生成网络(CGAN)的数据增强方法,用于在少量数据基础上生成大量训练样本。实验中采用 $\Phi$ -OTDR完成数据采集,将采集到的真实数据作为CGAN的输入,网络通过自动提取信号特征,并在输入条件的帮助下生成逼真的信号数据。将生成数据和原始数据分别输入决策树、支持向量机、卷积神经网络等模型进行分类,实验结果显示,生成数据在各个分类器中的检测结果都得到了显著提升,有效提高了分类器模型的检测能力和性能,实现了 $\Phi$ -OTDR模式的目标识别,并解决了数据采集困难的问题。本文研究为小样本检测提供了新的思路和方法,对其他光纤传感技术的应用具有借鉴意义。

**关键词** 光纤传感; 相敏光时域反射仪; 数据增强; 深度学习; 条件对抗生成网络

中图分类号 O438

文献标志码 A

DOI: 10.3788/AOS231392

## 1 引言

光纤传感技术作为当前安全监测领域的研究热点,具有分辨率高、监测范围广、抗干扰能力强等优点<sup>[1]</sup>。其中,相敏光时域反射仪( $\Phi$ -OTDR)是一种非常重要的光纤传感器<sup>[2]</sup>,广泛应用于电力<sup>[3]</sup>、交通等领域的结构监测<sup>[4]</sup>、安全检测<sup>[5]</sup>、环境监测<sup>[6]</sup>等场景。

然而,入侵信号的特征通常是复杂的,难以通过传统的人工经验进行有效提取,可能导致漏检或误检的问题。近年来,人工智能在周界安全领域中的应用不断推进,成为模式识别的新兴手段<sup>[7]</sup>。在入侵检测中,研究人员通过使用机器学习模型对信号等进行分类识别,来实现对入侵信号的检测和预防。一些研究使用两级支持向量机(SVM)识别算法,对振动事件进行两级分类,实现对相似振动事件的精确识别<sup>[8]</sup>。另外,一些研究人员通过对干扰信号进行多特征提取,并在时空域进行相关性分析降维,使用SVM分类器对不同类别的入侵进行分类,取得了高准确率的结果<sup>[9]</sup>。此外,一些研究采用了经验模态分解(EMD)和极端梯度提升(XGBoost)的方法用于识别扰动事件<sup>[10]</sup>,能够有效地识别不同类型的干扰事件。还有一些研究使用了长短期记忆网络(LSTM)和卷积神经网络(CNN)结合边缘特征提取算法,实现了自动模式识别<sup>[11]</sup>。

虽然使用人工智能技术对 $\Phi$ -OTDR中的入侵信号进行检测和分类取得了良好的效果<sup>[12-14]</sup>,但该过程依赖大量高质量的数据进行模型学习。由于 $\Phi$ -OTDR的特殊性质,使得在实际的真实环境中,它的入侵信号采集确实存在一些困难<sup>[15]</sup>。首先,在现实中,光纤的物理特性和环境因素会影响反射信号的质量和精度,例如光纤长短、光纤弯曲、温度和压力等因素都会对反射信号产生影响。其次,由于环境的复杂性和多样性,使得入侵事件的发生场景多种多样,入侵行为的信号采集难度不小。此外,在 $\Phi$ -OTDR系统中,有时需要采集多个通道的反射信号,这增加了系统的复杂性和难度。因此,尽管 $\Phi$ -OTDR具有高灵敏度和高分辨率的特点,但在实际的真实环境中,其入侵信号采集困难,其应用受到限制。如何在有限数量的真实数据样本的基础上获取更多、更逼真的样本数据,成为亟待解决的问题。

针对上述问题,本文在实际工程环境中收集了车辆经过、环境噪声、挖掘破坏和行人经过四种真实信号,针对数据量过少的问题,使用数据增强进行数据的扩充。传统的数据增强方法包括几何变换(如旋转、平移、缩放)、图像处理(如裁剪、镜像、变形)、颜色处理(如色彩平衡、对比度、亮度和饱和度的变换)以及噪声处理(如高斯噪声、椒盐噪声等)。这些方法可以增加

收稿日期: 2023-08-11; 修回日期: 2023-10-08; 录用日期: 2023-10-21; 网络首发日期: 2023-10-31

基金项目: 国家自然科学基金(61827819, 62265004)、广西八桂学者资助专项(2019A38)

通信作者: \*lbyuan@vip.sina.com

数据的多样性,减少过拟合,并提高模型的鲁棒性<sup>[16]</sup>。但传统方法难以针对特定类型的数据进行定制化的增强。不同任务和领域的数据具有不同的特点和分布,通用的增强方法无法充分利用数据的特性进行有效的增强。其次,传统方法生成的样本可能无法真实地逼近真实数据。这是因为传统方法仅基于简单的变换操作,无法捕捉到数据的复杂结构和特征,生成的样本可能缺乏真实数据的细节和准确性。

本文以对抗生成网络(GAN)为基础,利用其生成模型来增强光纤传感数据的处理能力<sup>[17]</sup>。具体而言,使用条件对抗生成网络(CGAN)来对 $\Phi$ -OTDR系统中的真实数据进行学习以生成符合真实数据分布的人工数据,从而扩充数据集规模,使其更具代表性。使用CGAN可以在有限数量的真实数据基础上,获取更多、更为逼真的样本数据<sup>[18]</sup>,从而使得机器学习和深度学习训练所得的模型更加精准和可靠。实验结果表明,生成的数据在各个分类器模型中的检测能力都有了较大的提升,证明了该模型有很好的应用潜力。使用生成的数据能够提高分类器的性能,优化模型的检测能力。

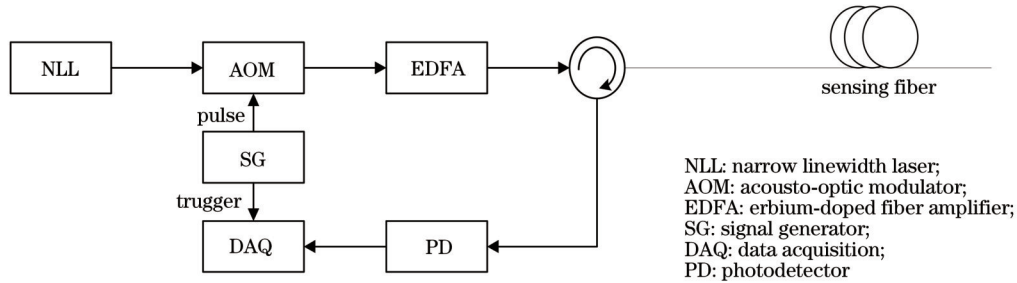


图1  $\Phi$ -OTDR系统进行信号收集  
Fig. 1 Signal collection in  $\Phi$ -OTDR system

## 2.2 数据增强方法

数据增强是一种常用的技术,用于通过对原始数据进行各种变换操作来生成更多的数据样本。在深度学习任务中,特别是在有限的数据集情况下,数据增强可以帮助提高模型的泛化能力和鲁棒性。

GAN在数据增强领域受到大家关注。GAN是一种基于博弈论的框架,由生成器和判别器组成。生成器负责生成逼真的数据样本,而判别器则负责区分生成的样本和真实样本,GAN的模型架构如图2所示。

在数据增强任务中,CGAN是GAN的一种扩展形式。CGAN通过引入条件源,使生成器能够生成具有特定条件的逼真数据样本。例如,在光纤传感技术中,条件源可以是入侵事件和非入侵事件的标签或类别,生成相应的逼真数据样本,从而增加数据样本的多样性和数量,提高入侵信号分类器的性能和准确率。与传统数据增强方式相比,CGAN能够更好地保持数据的真实性,同时实现更高效的数据增强。因此,本文

## 2 理论与方法

### 2.1 数据采集和预处理

在安全监测领域中, $\Phi$ -OTDR是一种被广泛采用的光纤传感技术。它可以通过向传感光缆发射测量光脉冲并接收后向瑞利散射曲线来对一定数量的瑞利散射曲线进行拼接,生成时空图。然而,实际应用中,一些非入侵性的行为也可能引起光缆的振动,这就需要对事件进行准确的分类判断,以使用户可以采取合理的应对措施。

在实验中,使用自研的 $\Phi$ -OTDR机箱进行光信号的产生和数据接收采集过程如图1所示。然而,通过 $\Phi$ -OTDR采集的数据存在数量少和质量低的问题,这就需要进行数据增强,增加样本多样性来提高模型的性能和鲁棒性,以便更好地利用机器学习的算法对数据进行处理。在进行数据增强之前,本文首先对原始数据进行了平滑处理和峰值去噪等操作,以减少噪声对数据的影响。这样的预处理过程有助于提高数据质量<sup>[19]</sup>,为后续数据增强提供更可靠的基础。通过数据增强,可以有效地增加样本的数量和多样性,从而改善模型的性能,并更好地应对复杂的实际应用场景。




图2 GAN的模型架构

Fig. 2 Model architecture of generative adversarial network (GAN)

采用CGAN完成对 $\Phi$ -OTDR数据的增强处理,以解决数据采集受限的问题。

### 2.3 CGAN进行数据增强

GAN是一类深度学习模型,由生成器和判别器两



部分组成。与传统的监督学习不同, GAN 是一种无监督学习方法, 其训练过程无需人工标注数据。在传统的 GAN 中, 生成器的输入是一个随机噪声向量, 需要通过学习生成逼真的数据分布来产生合成数据。原始的 GAN 只能生成随机的图片, 无法控制其输出的图片属性, 这使得 GAN 的应用受到限制。

为克服这些限制, CGAN 在原始 GAN 的基础上加入了条件信息, 这个条件信息可以是任何类型的辅助信息, 比如图像标签、文本描述或信号的频谱信息等属性。可以通过控制这些条件信息, 生成特定属性的数据<sup>[20-22]</sup>。与原始 GAN 不同, CGAN 强调有监督学习, 其生成器和判别器输入中都包含了条件信息。将条件信息作为输入, 使生成器可以根据给定的条件生成具有特定属性的合成数据, 从而提供了对生成数据的精细控制。这为数据生成和相关任务提供了更大的灵活性和控制性, 使得生成器能够根据信号的属性与标签生成具有所需属性的数据, 信号生成中根据波峰波谷等特性生成逼真信号。CGAN 可以更好地在研究人员掌控下进行学习, 从而更满足实际应用的需求, CGAN 的模型架构如图 3 所示。

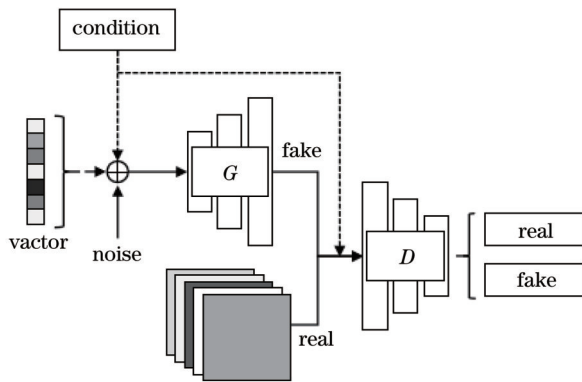


图 3 CGAN 的模型架构

Fig. 3 Model architecture of conditional generative adversarial network (CGAN)

在实际应用中,  $\Phi$ -OTDR 采集的入侵信号通常呈现为时序数据格式, 即一系列时序信号随时间变化而生成的数据序列。入侵信号的特点是信号强度和波形的变化在时间轴和强度轴上都有着明显的特征。因此, 在利用 CGAN 进行数据增强时, 需要注意保留数据的时间和强度两个维度的特征。本研究中, CGAN 通过对真实数据样本进行“噪声干扰”, 来产生更多、更为逼真的样本数据。这种噪声干扰可以是一些随机变化和模拟, 比如在真实数据的基础上加入一些随机扰动、扰动或者噪声等, 从而生成更多的样本数据。

## 2.4 实验

为验证 CGAN 的数据增强方法在光纤传感技术中  $\Phi$ -OTDR 数据采集的有效性, 进行了一系列充分的测试和验证实验。

首先, 在某厂区沿着厂区周界(采用 3 m 高的金属浸塑网围栏)开挖沟槽, 用于铺设光缆。沟槽平均深度为 0.2 m, 宽度为 1 m, 并使用夯机夯实沟槽底部, 以确保光缆铺设的稳固性。随后, 在沟槽上铺设土工栅格, 这将有助于保护光缆并增强光缆的强度。随后将 4 芯架空通信光缆以“S”形固定在土工栅格上, 采用绑扎带进行固定, 以确保光缆牢固地固定在位置上。然后, 在沟槽内倒入直径为 3~5 cm 的碎石子, 将光缆完全覆盖, 以提供光缆的保护和绝缘。在光缆埋设完成后, 光缆的一端通过穿井的方式引入监控室, 并连接到动态视觉传感器(DVS)设备。另一端剩余的约 20 m 光缆则被卷成盘后丢入光缆存放池中, 以备后续使用。在实验过程中, 模拟跳越围墙、行走等事件, 并采集各种噪声和事件数据, 这些数据样本构成了训练集和测试集, 用于训练和评估 CGAN 的生成器性能。光缆的总长度约为 13 km, DVS 的配置参数为: 光脉冲宽度为 100 ns, 光脉冲重复频率为 5 kHz, 数据采集速率为 100 M samples/s。在数据采集后, 对每个位置的时域数据进行有限脉冲响应(FIR)带通滤波, 滤波器相关参数为: 阶数为 20 阶, 通带频率为 125~750 Hz, 以提高数据的信噪比和准确度。实验场地的实际场景如图 4 所示。

在实验执行阶段, 使用 CGAN 进行数据增强。通过将真实的挖掘信号与随机噪声向量结合, 生成逼真的虚假挖掘信号。同样地, 通过结合真实的行走信号和背景噪声与随机噪声向量, 生成逼真的虚假行走信号和背景噪声。这样, 获得了丰富多样的数据样本, 用于更好地训练分类器模型。将生成的虚假信号和原始真实信号分别输入到支持向量机、分类树和逻辑回归模型中进行分类。通过对比生成数据和原始数据在不同分类器中的检测结果, 进行数据增强方法的性能和效果的评估。

通过以上实验设计和设置, 旨在验证 CGAN 的数据增强方法对光纤传感技术中  $\Phi$ -OTDR 数据采集的有效性, 以提高数据的质量和可靠性, 为光纤传感技术的应用提供更准确的数据支持和增强技术手段。

## 3 实验设计

### 3.1 构造 CGAN

本文使用 tens flow 框架搭建 CGAN 模型, 包含生成器和判别器两部分。其中生成器模型使用 CNN 来提取信号的特征, 鉴别器则是一个 GAN。CGAN 通过生成器和判别器相互协作来生成逼真的  $\Phi$ -OTDR 数据, 本文的生成器网络结构设计和关键组成部分如图 5 所示。

在生成器网络中, 首先采用输入层接收 100 维度的噪声信号, 经过全连接层转换为 128×375 维度的张量。为了确保网络输出与  $\Phi$ -OTDR 信号匹配, 使用重塑层将张量重塑为三维张量。接下来, 采用一个一维

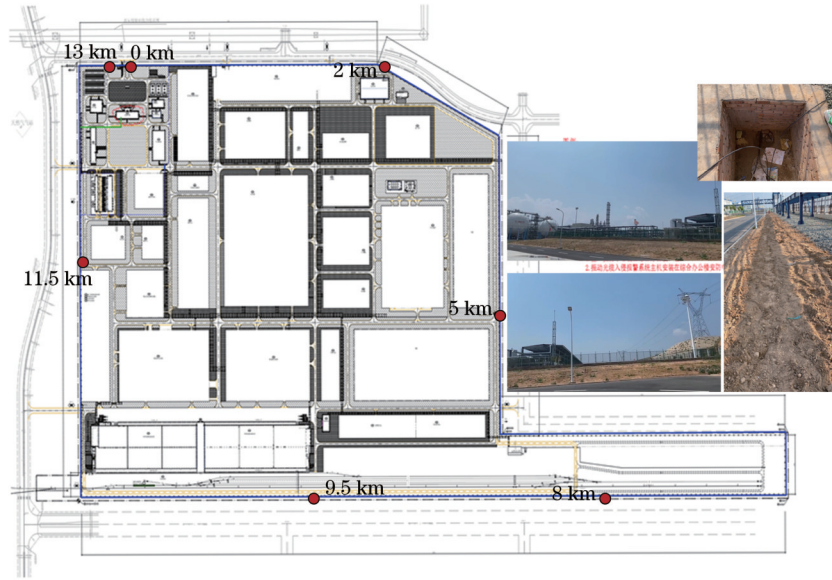


图 4 实验厂地实景图

Fig. 4 Realistic view of experimental plant site




图 5 生成器网络构造图

Fig. 5 Network architecture of generator

卷积层,其中包含 5 个大小为 64 的卷积核,进行卷积操作,使用零填充方式保持维度不变。在卷积操作后,应用批归一化技术加速训练过程,并采用 LeakyReLU 作为激活函数,提升网络性能。通过上采样层将特征图的长度扩大一倍,将维度变为原来的 2 倍。经过多次上采样操作后,最后一个卷积层使用 1 个大小为 5 的卷积核,并选择零填充方式,输出层的激活函数为 tanh。这样,整个生成器网络的输出形状为一个三维张量,维度为 (6000, 1)。生成器的损失函数包括生成器生成的信号被判别器判定为真实信号的概率。

判别器同样使用了多层全连接神经网络,接收生成器生成的信号和相应的标签作为输入,目标是区分生成的信号和真实的  $\Phi$ -OTDR 信号。判别器将接收生成器生成的信号和相应的标签作为输入,目标是区分生成的信号和真实的  $\Phi$ -OTDR 信号。判别器网络包含卷积层、LeakyReLU 激活函数以及全连接层,用

于提取输入信号的特征和进行分类判别。判别器网络的结构设计和关键组成部分如图 6 所示。

输入信号通过一维卷积层,采用 5 个大小为 64 的卷积核进行特征提取。随后,LeakyReLU 激活函数进行非线性处理,增强网络表达能力。接着再次应用一维卷积层,采用 5 个大小为 128 的卷积核,并使用步长为 2 进行卷积操作,进一步提取信号特征。通过展宽层将卷积操作得到的特征图转换为一维向量,为全连接层的输入做准备。最后,通过全连接层输出一个维度为 1 的标量值,并经过 sigmoid 激活函数处理,代表输入信号被判别为真实信号的概率。整个判别器网络可视为一个二元分类器,在训练过程中,通过优化参数,判别器不断提高对输入信号的判别准确度,以区分真实信号和虚假数据,从而促进生成器网络生成更逼真的信号。




图 6 判别器网络构造图

Fig. 6 Network architecture of discriminator

### 3.2 CGAN 训练

CGAN 的训练过程中,生成器和判别器通过损失函数进行优化。生成器的目标是生成逼真的信号,以欺骗判别器,使其将虚假信号误判为真实信号。生成器的损失函数旨在最小化虚假信号被判别器判定为真实信号的概率,提升生成器的生成能力。生成器损失函数可表示为

$$J_{\text{GCGAN}} = -\frac{1}{m} \log \left\{ D \left\{ G \left[ z^{(i)} | c^{(i)} \right] \right\} \right\}. \quad (1)$$

判别器的目标是区分真实信号和虚假信号。判别器的损失函数包括真实信号被判别为真实信号的概率和生成器生成的信号被判别为假信号的概率。判别器的目标是最大化对真实数据的正确判别和对虚假数据的正确判别。判别器损失函数为

$$J_{\text{DCGAN}} = -\frac{1}{m} \sum_{i=1}^m \left\{ \log \left\{ D \left[ x^{(i)} z^{(i)} | c^{(i)} \right] \right\} + \log \left\{ 1 - D \left\{ G \left[ z^{(i)} z^{(i)} | c^{(i)} \right] \right\} \right\} \right\}, \quad (2)$$

式中:  $z^{(i)}$  表示噪声向量;  $x^{(i)}$  表示实际数据;  $G \left[ z^{(i)} \right]$  表示生成器生成的数据;  $D \left[ x^{(i)} \right]$  表示判别器对实际数据

的输出;  $D \left\{ G \left[ z^{(i)} \right] \right\}$  表示鉴别器对生成数据的输出;  $c^{(i)}$  表示 CGAN 的条件标签。

整个训练过程旨在使生成器和判别器达到相对平衡的状态。生成器生成的虚假信号难以被判别器区分,同时判别器能更准确地区分真实和虚假信号。生成器和判别器在相互竞争和协作中逐渐优化,最终达到一种相对稳定的状态,实现数据增强的目标。训练中选择了一部分数据作为训练集,并对信号进行归一化处理,以确保数据处于相同的尺度范围内。采用 Adam 优化器来优化生成器和判别器的参数,其学习率设定为  $10^{-4}$ 。训练过程中,使用生成器损失值相对于其参数的梯度来更新生成器参数,以生成更好的信号。生成器更新的表达式为

$$\theta_{\text{Gnew}} = \theta_{\text{Gold}} - \alpha \cdot \nabla_{\theta_{\text{G}}} J_{\text{G}}. \quad (3)$$

使用鉴别器损失相对于其参数的梯度来更新鉴别器参数。鉴别器更新的表达式为

$$\theta_{\text{Dnew}} = \theta_{\text{Dold}} - \alpha \cdot \nabla_{\theta_{\text{D}}} J_{\text{D}}, \quad (4)$$

式中:  $\theta_{\text{G}}$  和  $\theta_{\text{D}}$  分别是生成器和鉴别器的参数;  $\alpha$  是用于优化的学习率。整个训练过程的流程图如图 7 所示。

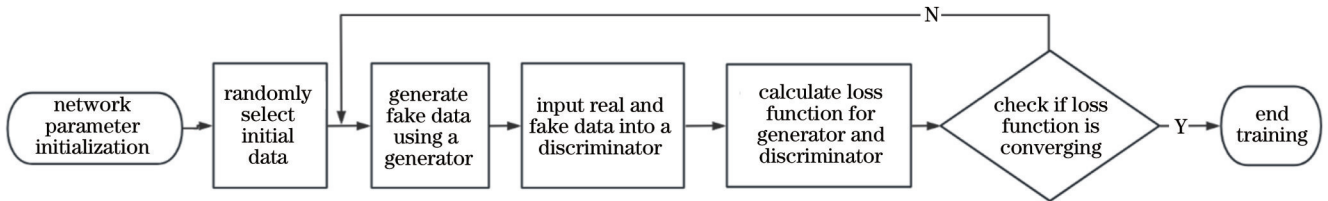


图 7 CGAN 训练流程图

Fig. 7 Flow chart of CGAN training

在训练过程中,通过随机采样生成噪声向量,并从训练集中随机选择一些真实信号和相应的标签。然后使用生成器生成一批假信号,并将真实信号和假信号输入判别器进行训练。通过交替训练生成器和判别器,逐渐提高生成器生成逼真信号的能力,并使判别器能够更好地区分真实信号和生成信号。生成器的目标是欺骗判别器,使其将虚假数据误判为真实数据。训

练过程中生成器和判别器的损失函数变化如图 8 所示。

由图 8 可见,初始阶段判别器的损失较高,约为 35 bit。这是由于生成器刚开始训练时,生成的虚假数据可能与真实数据差异较大,因此判别器很容易区分真假数据。随着训练的进行,生成器逐渐改进生成的虚假数据,导致判别器越来越难以区分真假,从而判别



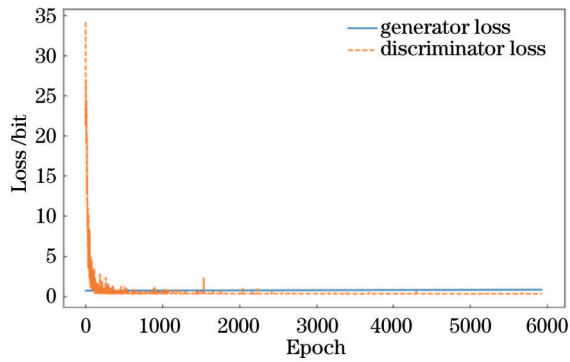


图 8 生成器和判别器的损失值变化图

Fig. 8 Loss diagrams of generators and discriminators

器的损失逐渐降低。经过约 500 轮训练后,判别器的损失趋于稳定,在约 0.43 bit 的水平上波动,这表明生成器生成的虚假数据已经足够逼真,以至于判别器难以区分。在整个训练过程中,生成器的损失维持在约 0.71 bit 左右。随着训练的进行,生成器学习生成更逼真的虚假数据,同时判别器也在学习更好地区分真假数据。因此,生成器和判别器之间的竞争和协作导致生成器损失相对稳定在一个较低的水平。虽然生成器

损失(G-loss)在整个训练过程中略微有增长,但这是由于生成器要欺骗越来越强大的判别器变得更加困难导致的。从变化趋势来看,判别器损失(D-loss)趋于稳定在 0.43 bit 左右的水平,G-loss 也在相对稳定的水平约 0.71 bit 左右波动。这表明 CGAN 在一定程度上已经达到了一种相对平衡的状态,生成器生成的虚假数据已经较为逼真。

综合分析可知,本文的 CGAN 训练结果较好,并证实了在光纤传感技术中应用 CGAN 进行数据增强的有效性和成功性。D-loss 的下降和 G-loss 的相对稳定表明生成器生成的虚假数据已经足够逼真,同时判别器也在尽可能地准确区分真假数据。

### 3.3 CGAN 网络生成信号

输入噪声向量和相应的标签到生成器中,生成器将生成一个与标签相匹配的假信号。生成的假信号经过反归一化处理后,即可得到生成的  $\Phi$ -OTDR 数据。训练过程中,每经过 200 轮迭代,记录生成器生成的信号,并对其进行了详细分析。生成信号的变化情况如图 9 所示。从图 9 中可以观察到,随着训练的进行,生成器生成的信号逐渐变得更加逼真和精细,与真实信号之间的相似度也不断提高。




图 9 生成信号展示(200 轮一次)

Fig. 9 Display of generating a signal (200 rounds at a time)

使用训练好的 CGAN 网络,根据给定的标签生成不同类型的  $\Phi$ -OTDR 数据。将原始数据和生成数据进行绘图展示对比,如图 10 所示。

图 10 展示了生成的信号与真实信号之间的对比情况,从上往下分别是车辆经过、环境噪声、行人经过、人为破坏。车辆经过的信号峰值较高,一般在 10000 以上,能具有轻微的高度变化。环境噪声信号的信号强度较低,信号趋于平稳,没有过多明显的高低变化。

挖掘破坏信号具有撞击地面等明显的动作,信号表现为跳跃度较大的特点。行人经过的信号强度较低,类似于环境噪声,具有高低强度变换,与行人抬脚和踩下的动作有关。这些特点为不同类型的信号提供了辨识的依据,尤其是在挖掘破坏信号中的撞击动作和行人经过信号中的高低强度变换等特征。这些特点为信号分类和分析提供了重要的信息。生成的信号与真实信号在形态和特征上非常相似,具有很高的 consistency。这

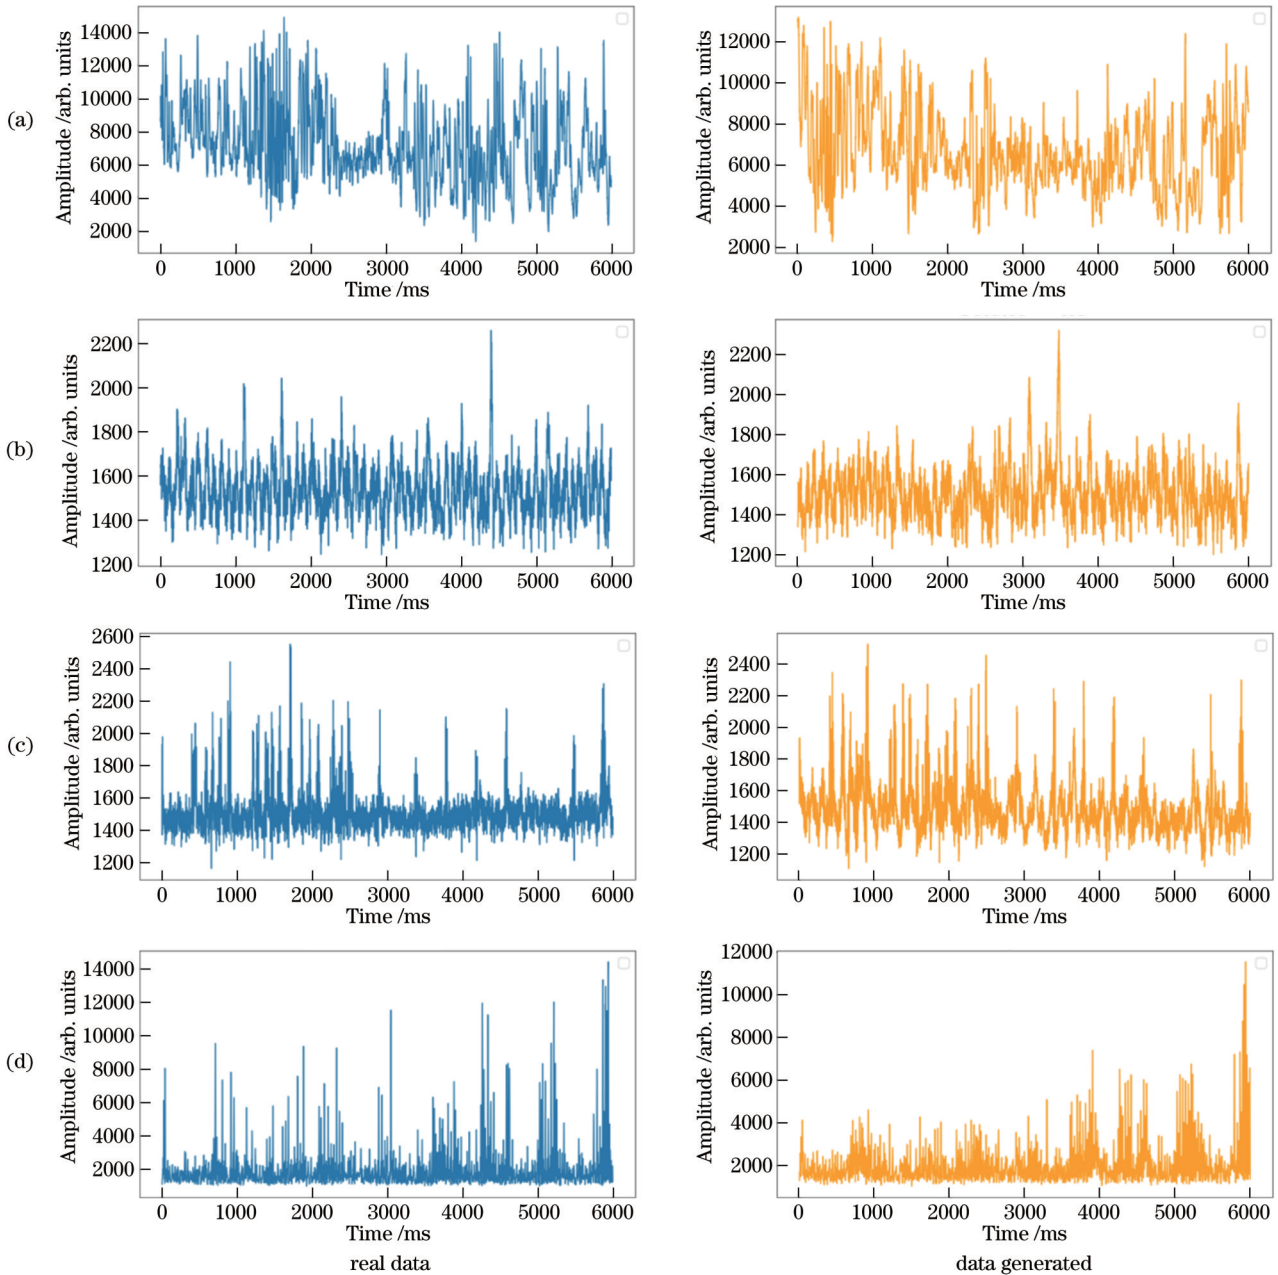


图 10 生成信号和真实信号对比图。(a)车辆经过;(b)环境噪声;(c)行人经过;(d)人为破坏

Fig. 10 Comparison of generated and real signals. (a) Vehicles passing by; (b) ambient noise; (c) pedestrians passing by; (d) artificial destruction

验证了CGAN在生成信号方面的有效性和准确性。

#### 4 结果分析

本文使用CGAN模型,对 $\Phi$ -OTDR数据进行增强处理,获得大量逼真的信号样本。直方图是一种常用的数据可视化方法,可以反映数据的分布特征和一些统计信息。为验证生成数据与原始数据的相似性,采用直方图进行对比分析,对比结果如图11所示。

图11中显示,生成数据的直方图与原始数据的直方图非常接近,呈现出相似的分布特征,表明生成数据与原始数据在数据分布上具有高度一致性。然而,增强后的数据直方图的y轴较高,这是由于数据增强引

入了更多多样性的样本,使得生成的数据在原始数据的分布范围内具有更多的数据点,从而使直方图的y轴整体上升,表现出增强数据的丰富多样性。

在CGAN模型中,生成器的目标是通过反复调整参数以最大化生成数据与原始数据的相似性。在此过程中,生成器会引入一些噪声或变异,导致生成的数据在某些取值范围内具有更高的频率或分布,进而使直方图的y轴值整体上升,体现了生成数据的多样性。生成器在生成数据时会尽可能地引入一些变化和差异,增加数据的多样性。同时,训练生成对抗网络时,生成器和判别器之间的竞争和协作也会影响生成数据的分布。生成器不断优化参数以生成更逼真的数据,

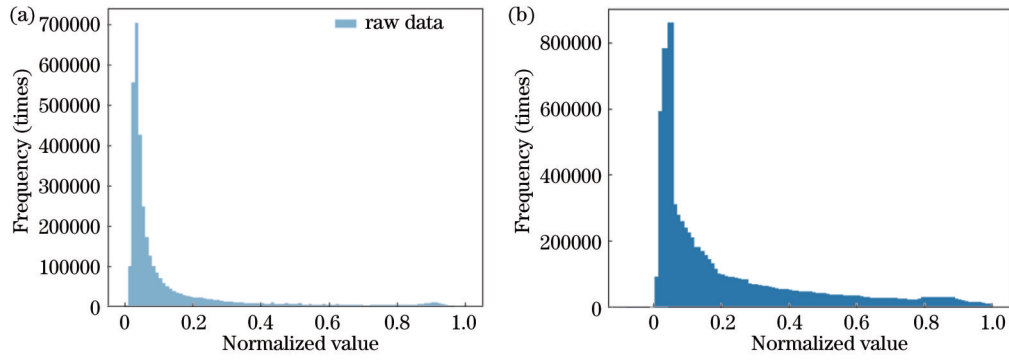


图 11 生成数据和原始数据的直方图对比。(a)原始数据;(b)生成数据

Fig. 11 Comparison of histograms of raw and generated data. (a) Raw data; (b) generated data

而判别器则努力准确区分真假数据。这种竞争和协作导致生成的数据在某些值范围内具有更高的分布,进而使直方图的y轴值整体上升。

为验证数据增强的可行性和效果,本文使用了不同分类器对原始数据和增强后的数据进行分类。将原始数据和生成数据分别输入决策树、支持向量机、卷积神经网络等不同分类器模型进行分类。为了评估分类器的性能,本文选用精准率作为判定标准。精准率是指分类器在所有预测为正类的样本中,实际为正类的比例。通过计算分类器的精准率,可以衡量分类器在正确预测正类样本方面的准确度。具体地,精准率的计算公式为

$$P = \frac{S_{TP}}{S_{TP} + S_{FN}} \times 100\%, \quad (5)$$

式中:真阳性( $S_{TP}$ )是指分类器将正类样本正确地预测为正类的数量;假阳性( $S_{FN}$ )是指分类器将负类样本错误地预测为正类的数量。检测结果如图 12 所示。

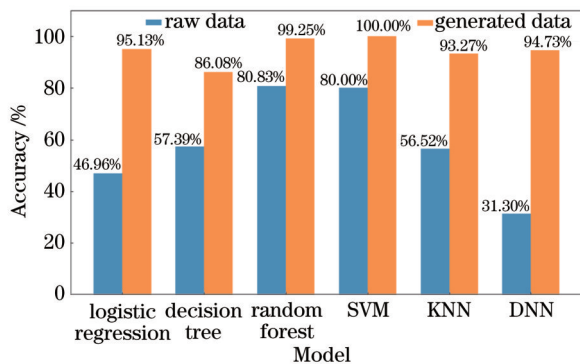


图 12 原始数据和生成数据的检测结果对比

Fig. 12 Comparison of detection results between raw and generated data

从实验结果可以看出,对于大多数分类器模型,增强后的数据在检测结果上都得到了显著提升,有效提高了分类器模型的检测能力和性能。特别是在支持向量机(SVM)和逻辑回归(DNN)模型中,增强后的数据表现出更高的准确性,分别为 100% 和 95.13%,相

较于原始数据的 80% 和 46.96%,提升明显。

混淆矩阵图是对分类器性能更细致的评估,它可以展示分类器在不同类别上的分类情况。混淆矩阵能够直观地展示分类器在不同类别上的分类情况,进而计算出分类器的准确率、召回率、F1 值等性能指标,有助于全面了解分类器的表现。为了更好地观测对原始数据和增强后数据的分类状况,选取 DNN 模型、随机森林模型及 SVM 模型进行混淆矩阵图的对比,对比结果如图 13 所示。

对  $\Phi$ -OTDR 收集到的原始数据和经过数据增强处理后的数据进行分类,并绘制混淆矩阵图进行对比分析。原始数据的混淆矩阵图显示,由于原始数据的样本量较少且数据分布不均衡,导致分类器的性能较差,出现了较多的误分类情况。与此相对比,经过数据增强后的第二个混淆矩阵图显示出较好的分类性能。这表明数据增强通过增加更多多样性的数据样本,使分类器能够更好地学习和泛化数据的特征,从而提高了分类性能。

数据增强的目标是引入更多的数据样本和多样性,使生成的数据与原始数据在数据分布上更加一致。经过数据增强处理后的数据在  $\Phi$ -OTDR 数据分类任务中表现更好,有效提高了分类器模型的检测能力和性能。这证实了数据增强在解决数据采集困难问题上的有效性,并为  $\Phi$ -OTDR 模式识别的实现提供了有力支持。通过 CGAN 模型进行数据增强后的数据在分类器模型中具有更好的分类性能和检测准确性,增强后的数据能够更好地支持  $\Phi$ -OTDR 模式的识别。由于数据增强能够有效增加数据样本的多样性和数量,为分类器模型提供更多的训练样本,从而改善了分类器模型的泛化能力和性能。

在研究中,为了防止模型的过拟合,提高对真实实验数据的准确性判断,采集未在 CGAN 训练中使用过的真实实验数据,并将其输入基于 CGAN 生成数据训练的机器学习模型中。通过模型对全新数据的检测,评估其在真实数据上的性能,以验证模型的训练效果,实验结果如图 14 所示。



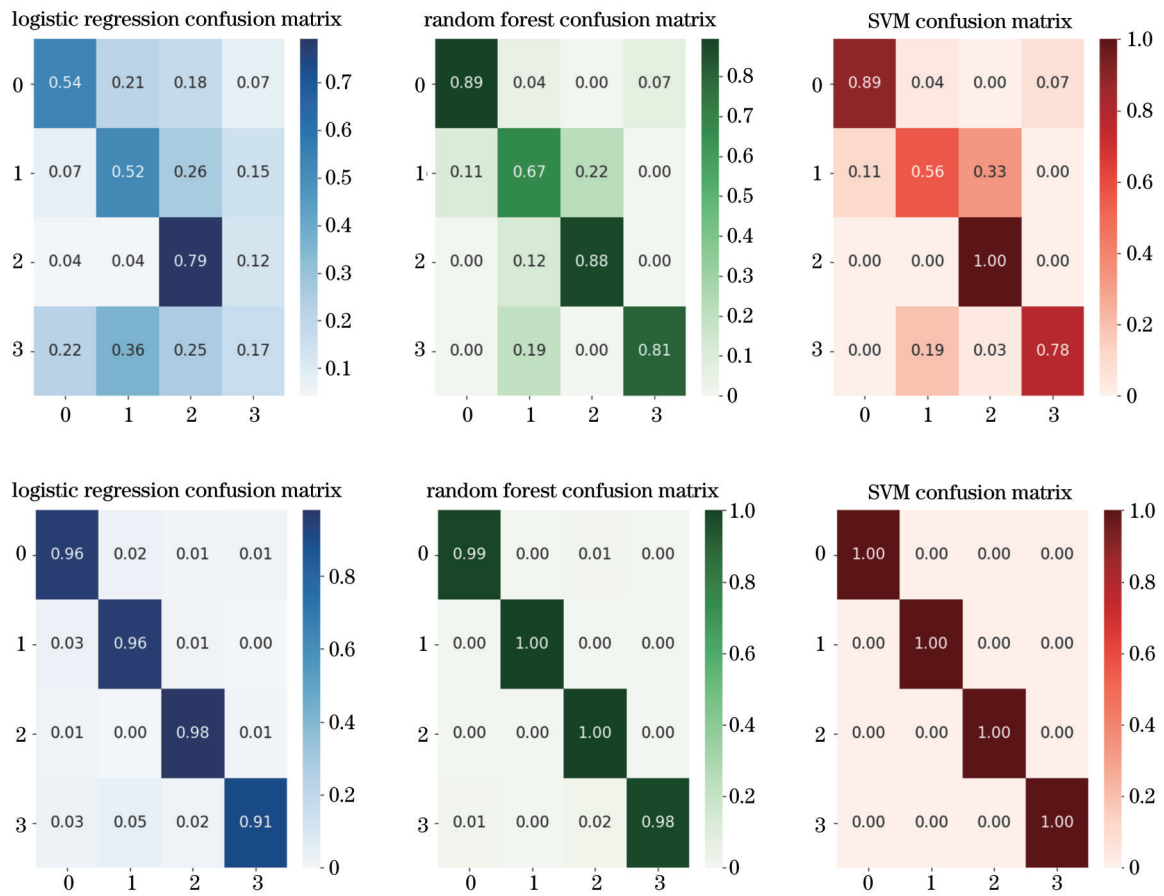


图 13 原始数据和生成数据的混淆矩阵图的对比

Fig. 13 Comparison of confusion matrix plots between raw and generated data

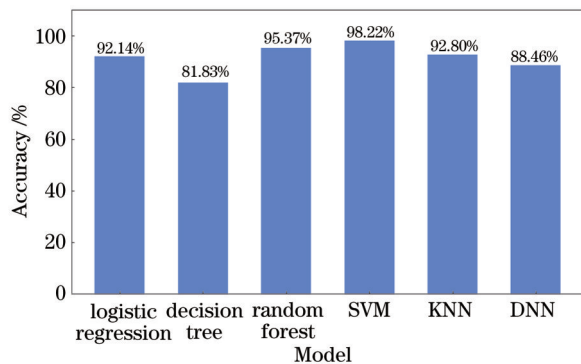


图 14 真实数据检测结果

Fig. 14 Test results of real data

为验证本文方法的性能,与其他三种不同的检测方法进行对比,结果如表 1 所示。

表 1 不同方法检测结果对比

Table 1 Comparison of detection results of different methods

Method	Accuracy / %
Ref. [8]	92.43
Refs. [23,24]	94.43
Ref. [25]	96.10
Proposed method	98.22

在对比中,本文所提出的方法表现出最高的检测率,突显了其在目标检测领域的优越性。这一结果彰显了本文方法在实验中的卓越表现,还为该方法在实际应用中的潜在价值提供了有力支持。

## 5 结 论

本文提出了改进 CGAN 模型,应用于  $\Phi$ -OTDR 数据增强。通过生成数据,将原始数据集的样本量进行扩充,优化了分类器的性能和模型的检测能力。实验结果表明,生成的数据在工程应用中表现出色。同时,该方法成功解决了数据采集和处理的限制问题,扩大了数据集规模,进一步优化了模型的检测能力和性能。本文研究为分布式光纤传感技术在安全监测领域的应用提供了新的思路和方法,并为光纤传感技术的发展做出了有益的探索和实践。

## 参 考 文 献

[1] 吴慧娟,刘欣雨,饶云江. 基于  $\Phi$ -OTDR 的光纤分布式传感信号处理及应用[J]. 激光与光电子学进展, 2021, 58(13): 1306003.  
Wu H J, Liu X Y, Rao Y J. Processing and application of fiber optic distributed sensing signal based on  $\Phi$ -OTDR[J]. Laser & Optoelectronics Progress, 2021, 58(13): 1306003.

[2] 王一凡,刘庆文,李赫,等. 基于瑞利图形相关的光纤分布式

- 动态应变传感器[J]. 中国激光, 2021, 48(11): 1110002.
- Wang Y F, Liu Q W, Li H, et al. Distributed fiber-optic dynamic strain sensor based on spectra correlation of Rayleigh backscattering[J]. Chinese Journal of Lasers, 2021, 48(11): 1110002.
- [3] Ding Z W, Zhang X P, Zou N M, et al. Phi-OTDR based on-line monitoring of overhead power transmission line[J]. Journal of Lightwave Technology, 2021, 39(15): 5163-5169.
- [4] 罗天林, 王砾苑, 施羿. 基于 1D-CNN 的  $\Phi$ -OTDR 地理光纤振动事件分类方法[J]. 光电子·激光, 2020, 31(9): 955-964.
- Luo T L, Wang L Y, Shi Y. Buried fiber vibration event classification method based on 1D-CNN for  $\Phi$ -OTDR[J]. Journal of Optoelectronics·Laser, 2020, 31(9): 955-964.
- [5] 杨震, 封皓. 基于深度学习的  $\Phi$ -OTDR 输油管道入侵监测研究[J]. 激光与光电子学进展, 2022, 59(8): 0806001.
- Yang Z, Feng H. Oil pipeline intrusion monitoring based on deep learning of  $\Phi$ -OTDR[J]. Laser & Optoelectronics Progress, 2022, 59(8): 0806001.
- [6] Lu B, Wu B Y, Gu J F, et al. Distributed optical fiber hydrophone based on  $\Phi$ -OTDR and its field test[J]. Optics Express, 2021, 29(3): 3147-3162.
- [7] 赵丽娟, 魏迎健, 徐志钮. 基于  $\Phi$ -OTDR 的振动事件识别分类器研究进展[J]. 光通信技术, 2023, 47(2): 1-5.
- Zhao L J, Wei Y J, Xu Z N. Research progress of vibration event recognition classifier based on  $\Phi$ -OTDR[J]. Optical Communication Technology, 2023, 47(2): 1-5.
- [8] 朱海强, 张志利, 高慧敏, 等. 基于两级 SVM 的  $\Phi$ -OTDR 系统振动事件识别算法[J]. 电子器件, 2023, 46(3): 783-789.
- Zhu H Q, Zhang Z L, Gao H M, et al. Vibration event recognition algorithm of  $\Phi$ -OTDR system based on two-level support vector machine[J]. Chinese Journal of Electron Devices, 2023, 46(3): 783-789.
- [9] Wang Y, Wang P F, Ding K, et al. Pattern recognition using relevant vector machine in optical fiber vibration sensing system[J]. IEEE Access, 2019, 7: 5886-5895.
- [10] Wang Z D, Lou S Q, Liang S, et al. Multi-class disturbance events recognition based on EMD and XGBoost in  $\Phi$ -OTDR[J]. IEEE Access, 2020, 8: 63551-63558.
- [11] 张旭苹, 陈晓红, 梁蕾, 等. 长距离海缆在线监测改进型 C-OTDR 系统[J]. 光学学报, 2021, 41(13): 1306001.
- Zhang X P, Chen X H, Liang L, et al. Enhanced C-OTDR-based online monitoring scheme for long-distance submarine cables[J]. Acta Optica Sinica, 2021, 41(13): 1306001.
- [12] Yang X, Li S, Xu Y, et al. Multi-event location denoising scheme for  $\Phi$ -OTDR based on FFDNet network[J]. Photonics, 2023, 10(10): 1114.
- [13] Kayan C E, Aldogan K Y, Gumus A. Intensity and phase stacked analysis of a  $\Phi$ -OTDR system using deep transfer learning and recurrent neural networks[J]. Applied Optics, 2023, 62(7): 1753-1764.
- [14] 吴华芹. 基于机器学习的光纤故障数据信息快速排除方法[J]. 激光杂志, 2018, 39(12): 160-165.
- Wu H Q. Quickly elimination for data faults of optical fiber faults based on machine learning[J]. Laser Journal, 2018, 39(12): 160-165.
- [15] 田曼伶, 刘东辉, 曹晓敏, 等. 相位敏感光时域反射仪的信号处理方法综述[J]. 光学精密工程, 2021, 29(9): 2189-2209.
- Tian M L, Liu D H, Cao X M, et al. Signal processing methods of phase sensitive optical time domain reflectometer: a review[J]. Optics and Precision Engineering, 2021, 29(9): 2189-2209.
- [16] Feng S Y, Gangal V, Wei J, et al. A survey of data augmentation approaches for NLP[EB/OL]. (2021-05-07)[2023-06-05]. <https://arxiv.org/abs/2105.03075>.
- [17] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: an overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [18] Mirza M, Osindero S. Conditional generative adversarial nets [EB/OL]. (2014-11-06)[2023-05-04]. <https://arxiv.org/abs/1411.1784>.
- [19] 唱友义, 孙赫阳, 顾泰宇, 等. 采用历史数据扩充方法的风力发电量月度预测[J]. 电网技术, 2021, 45(3): 1059-1068.
- Chang Y Y, Sun H Y, Gu T Y, et al. Monthly forecast of wind power generation using historical data expansion method[J]. Power System Technology, 2021, 45(3): 1059-1068.
- [20] Ma J Y, Xu H, Jiang J J, et al. DDCGAN: a dual-discriminator conditional generative adversarial network for multi-resolution image fusion[J]. IEEE Transactions on Image Processing, 2020, 29: 4980-4995.
- [21] Zhang H, Sindagi V, Patel V M. Image de-raining using a conditional generative adversarial network[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(11): 3943-3956.
- [22] Huang X Q, Li Q, Tai Y H, et al. Time series forecasting for hourly photovoltaic power using conditional generative adversarial network and Bi-LSTM[J]. Energy, 2022, 246: 123403.
- [23] 王鸣, 沙洲, 封皓, 等. 基于 LSTM-CNN 的  $\Phi$ -OTDR 模式识别[J]. 光学学报, 2023, 43(5): 0506001.
- Wang M, Sha Z, Feng H, et al.  $\Phi$ -OTDR pattern recognition based on LSTM-CNN[J]. Acta Optica Sinica, 2023, 43(5): 0506001.
- [24] 李笑, 高毅, 吴昊, 等. 基于混合输入神经网络的  $\Phi$ -OTDR 系统模式识别方法[J]. 中国激光, 2023, 50(11): 1106003.
- Li X, Gao Y, Wu H, et al. Mode recognition method of  $\Phi$ -OTDR system based on mixed input neural network[J]. Chinese Journal of Lasers, 2023, 50(11): 1106003.

# Pattern Recognition of Phase-Sensitive Optical Time-Domain Reflectometer Based on Conditional Generative Adversarial Network Data Augmentation

Zhang Yin<sup>1</sup>, Hu Ting<sup>1</sup>, Li Youxing<sup>2</sup>, Wang Jian<sup>1</sup>, Yuan Libo<sup>1\*</sup>

<sup>1</sup>*School of Optoelectronic Engineering, Guilin University of Electronic Technology, Guilin 541004, Guangxi, China;*

<sup>2</sup>*College of Physics and Optoelectronic Engineering, Harbin Engineering University, Harbin 150006, Heilongjiang, China*

## Abstract

**Objective** We aim to address limited data acquisition in fiber optic sensing technology, especially in phase-sensitive optical time-domain reflectometry. A data augmentation method based on conditional generative adversarial networks (GANs) is proposed to generate a large number of training samples and improve the detection capability and performance of the classifier model.

**Methods** The experimental data collection is conducted using a phase-sensitive optical time-domain reflectometer ( $\Phi$ -OTDR). First, the collected real data are adopted as input to the conditional GAN. The GAN model automatically extracts signal features and generates realistic signal data with the assistance of input conditions, with the specific experimental flow shown in Fig. 7. Second, the generated data and original data are separately fed into classifiers such as decision trees, support vector machines, and convolutional neural networks for classification. By comparing the detection results of the generated and raw data across different classifiers, the effectiveness of the data augmentation method is evaluated, and the specific comparison results are shown in Fig. 12. This comprehensive approach can assess the influence of the generated data on the classifier performance to address limited data acquisition in fiber optic sensing technology.

**Results and Discussions** The experimental results demonstrate that the detection results of the generated data significantly improve across decision trees, support vector machines, and convolutional neural networks. The generated data enhance the detection capability and performance of the classifier models, achieving the target identification in  $\Phi$ -OTDR. Furthermore, improvements in the conditional GAN can generate more realistic signal data, further enhancing the model performance.

**Conclusions** We successfully address the data acquisition limitations in  $\Phi$ -OTDR by a data augmentation method based on conditional GAN. The generated data improve the detection capability and performance of the classifier models. The research findings provide new insights and methods for small-sample detection, and also valuable references for the applications of other fiber optic sensing technologies.

**Key words** optical fiber sensing; phase-sensitive optical time-domain reflectometer; data augmentation; deep learning; conditional generative adversarial network