光电技术及应用

DOI：10.16818/j.issn1001－5868.20250105003

基于对抗生成网络的分布式光纤声波车辆传感信号高性能去噪方法

江　淦，胡天宇，熊彬博，彭　飞*

（四川大学 电气工程学院，成都 610000）

摘　要： 分布式光纤声波传感系统（DAS）已被证实能够实现被动、广覆盖且高空间分辨率的车辆检测与定位，其无需现场部署传感器设备的特点使其具备显著的成本优势。然而，基于DAS的车辆检测系统在实际应用中容易受到环境噪声和系统衰落的影响。针对该问题，提出一种多尺度上下文对抗生成式网络（MCGAN），该网络通过多尺度空洞卷积提取特征，有效整合不同尺度的层次化信息，从而显著提升模型的去噪性能。实验结果表明，MCGAN不仅能抑制环境噪声和衰落噪声，还能较好地保留车辆信号，尤其在低速小型车辆信号的检测中表现优异。

关键词： 分布式光纤声波传感技术；图像去噪；深度学习；对抗生成网络；空洞卷积

中图分类号： TN247；TP212　**文章编号：** 1001－5868（2025）01－0127－08

High-Performance Denoising Method for Distributed Fiber Optic Acoustic Vehicle Sensing Signals Based on Generative Adversarial Networks

JIANG Gan, HU Tianyu, XIONG Binbo, PENG Fei

（**College of Electrical Engineering, Sichuan University, Chengdu 610000, CHN**）

Abstract: Roadside vehicle detection system provides critical data support for intelligent transportation systems. However, traditional vehicle detection technologies still face challenges such as high maintenance and deployment costs. The Distributed Acoustic Sensing (DAS) system has been shown to offer passive, wide-range, and high spatial resolution vehicle detection and localization, without the need for on-site sensor installation, thus providing a significant advantage in terms of ultra-low deployment costs. However, DAS-based vehicle detection systems are susceptible to environmental noise and system fading. To address this issue, this paper proposes a Multi-Scale Context Generative Adversarial Network (MCGAN), which extracts features using multi-scale dilated convolutions and integrates hierarchical information across different scales to enhance the model's denoising performance. Experimental results demonstrate that MCGAN can effectively suppresses environmental and fading noise while preserving vehicle signals, particularly excelling in detecting low-speed and small vehicle signals.

Key words: distributed fiber acoustic sensing; image denoising; deep learning; generative adversarial networks; dilated convolution

收稿日期：2025－01－05.

基金项目：国家自然科学基金项目（62303335，52075349）；四川省科技计划项目（23NSFSC3797）.

*通信作者：彭　飞

0 引言

智能交通系统(ITS)通过协调车辆、交通设施和道路使用者的行为,提高交通安全、提升交通效率、减少环境影响并降低能源消耗,已成为现代交通运输中不可或缺的一部分[1]。ITS的许多功能依赖于准确且持续的数据输入,这些数据主要来源于各种检测技术。在众多交通检测技术中,路侧车辆检测技术因其高效性和准确性显得尤为关键[2]。该技术通过安装在路侧的传感器,监测通过车辆的速度、类型和数量,从而优化交通流量并提高事故检测与响应的效率[3]。常见的路侧感知技术包括环形检测器、地磁传感器、摄像头和雷达,但这些技术存在维护、部署成本高,以及数据碎片化等局限性。

近年来,光纤分布式声学传感(DAS)技术利用光纤中的瑞利散射,已实现了超长感测距离、高灵敏度和高空间分辨率的振动感知[4]。一些研究已将光纤埋设在道路下方,以获取高质量的车辆振动响应[5]。Linsey等发现,只要DAS性能足够优越,即使振动响应较弱,将DAS连接到路侧现有的"暗光纤"上,也能通过超低部署成本为ITS提供可靠的车辆数据[6]。此外,若DAS具备强大的超低频响应能力,通过提取由车辆产生的准静态应变信号,而非传统的表面波信号,可以显著提升车辆定位精度[7]。

基于准静态车辆信号,还可衍生出交通流量统计、车辆速度检测以及车辆类型识别等多种应用[7-8],展现出显著的应用潜力和成本优势。然而,基于DAS的车辆检测系统仍面临一些挑战。由于车辆与路侧光缆的距离、低速行驶及小吨位等因素,准静态应变信号本身较弱,且更易受到环境噪声和系统衰落噪声的影响。尤其是当车辆远离光缆时,DAS车辆信号成像质量较差,从而导致车辆检测的准确性显著降低。因此,消除环境噪声和系统衰落噪声对于实现高密度、精确的DAS车辆检测至关重要。

深度学习在DAS车辆准静态信号的噪声抑制中展现出较高的应用价值。Feng等研究自监督网络已在背景高斯噪声的抑制中表现出色,但在处理复杂非平稳噪声时仍有局限性[9]。Martijn等基于Unet提出的自监督模型,提高DAS系统的时间分辨率,从而提高信号质量[7]。Yuan等提出一种基于空间域的DAE模型,该模型克服了因时间小波随速度变化而引起的空间小波失配问题,实现了更好的空间分辨率和去噪效果[10]。Liu等开发出一种空间域贝叶斯滤波与平滑算法,该算法减少了环境噪声对车辆轨迹提取的影响,并实现了对车辆的连续跟踪[11]。Min等设计了一系列预处理步骤来增强车辆信号,并基于增强后的信号创建高质量标签,训练了一个SVM模型,实现了DAS车辆准静态信号的噪声抑制[12]。上述研究中,针对DAS车辆准静态数据的去噪主要采用单网络模型。然而,由于DAS噪声特性在不同时间和位置上存在显著变化,单网络方法难以完全适应这些变化,从而影响噪声抑制与信号恢复的平衡。

对抗生成网络[13](GAN)与深度学习单一网络结构相比,引入了判别器来对生成的数据进行针对性特征的输出。基于DAS的车辆准静态信号在不同的通道中呈现较强的一致性和连续性。判别器可以利用这一特征,从环境噪声和系统衰落噪声中分离出车辆的准静态信号,从而实现分布式光纤声波车辆传感信号的去噪。但目前GAN网络的判别器对这种多个通道的一致性和连续性特征利用并不充足,导致模型在去噪后的车辆数据存在去噪不足和过度去噪的问题。

针对这一问题,本文提出一种利用GAN网络特性并结合多尺度结构的多尺度上下文对抗生成式网络(MCGAN)。该网络充分利用准静态车辆信号的时空连续性特征,通过多尺度空洞卷积结构提取不同尺度的特征信息。在抑制环境噪声和系统衰落噪声的同时,还能完整保留车辆信号,从而实现高质量的车辆成像。

1 数据采集

当车辆行驶时,车轮对地面施加的点载荷会导致地面产生形变,因此,移动车辆的准静态响应可以利用公路边原本用于通信的暗光纤作为传感媒介来检测。DAS通过激光器向暗光纤注入高相干的脉冲激光。随着脉冲激光在光纤中前行,不断产生瑞利散射光,在DAS的接收端可以在不同时刻接收到不同位置的瑞利散射光。当车辆经过与暗光纤平行的公路时,使公路以及暗光纤产生应变,进而改变瑞利散射光的相位,通过实时解调瑞利散射的相位,就可获得车辆产生的应变信号。基于DAS系统路端数据采集如图1所示。

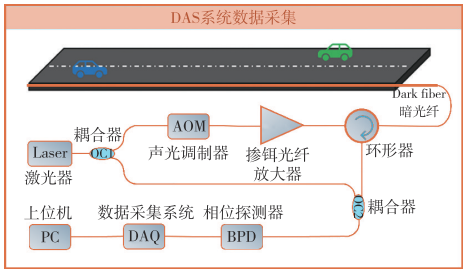

图1　基于DAS系统路端数据采集示意图

实验团队开发的DAS设备安装在通信室内，将DAS设备的时间采样率设置为250 Hz，空间采样间隔设置为3.2 m，量测长度也设置为3.2 m。实验中使用的通信电缆埋设在校园主干道旁的人行道下，深度为1.5～2 m，该电缆与主交通路线平行布置。需要注意的是，现有的通信光纤电缆被埋入混凝土管道中，而该管道最初并非为车辆感应应用设计。此设计中，电缆在管道内相对松散，会导致这种配置下的灵敏度显著降低。这些电缆的总长度为320 m，对应100个通道，如图1中车辆下方橙色线所示。信号训练所用的原始数据为2024年1月至4月份在城市里采集一段公路的交通数据。

2　数据预处理

根据频带可将车致应变分为0.01～1 Hz准静态应变信号和高于2 Hz的表面波信号。与表面波信号相比，准静态应变信号在空间上的扩散较小，具有更好的本地效应，更容易分离距离相近的车辆，因此本研究将准静态信号作为处理对象，所用的滤波器为带通的巴特沃斯滤波器[14]，通带范围为0.01～1 Hz。在DAS采集到的数据中，可将采集数据视为信号和噪声的叠加。因此，可以通过模型建立学习噪声数据中车辆振动信号的特征，然后利用这种特征复现出车辆信号。为此，需要制作干净的数据集。在进行巴特沃斯带通滤波之后，将采样频率从250 Hz降至25 Hz，此过程不影响准静态信号的特征，如图2中步骤①～④所示。如图2中步骤④所示，在降采样后的车辆数据中，依旧存在大量的非车辆信号的环境噪声和较多通道产生的衰落信号。为排除这些信号的干扰，通过手动标记车辆轨迹的区域，将标记的数据对应区域提取出来作为标签，如图2中步骤⑤所示。在模型训练过程中，模型没有学习到关于噪声的知识。当训练完成，模型接受到包含噪声的车辆信号数据时，对其中的车辆信号起作用，而对噪声则置0。因此，可以通过充足数据训练模型，实现对环境噪声和系统衰落噪声的滤除。

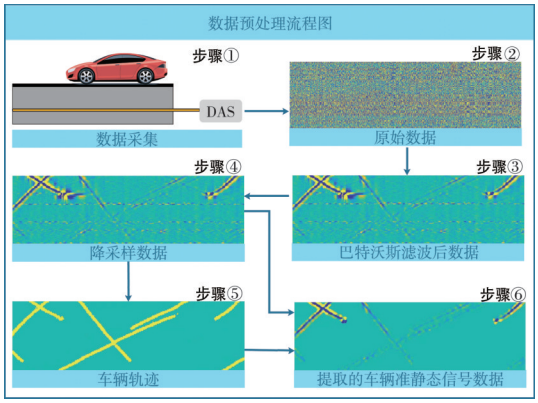

图2　DAS车辆准静态数据预处理流程图

3　MCGAN网络架构

目前GAN网络的判别器对这种多个通道的DAS车辆准静态信号的一致性和连续性特征利用并不充足，导致模型在去噪性后的车辆数据存在欠去噪和过去噪的问题。

针对这些挑战，提出了一种基于多尺度策略的MCGAN模型框架，以适应DAS数据中的复杂噪声环境和弱信号特性。总体框架如图3所示。

为了解决DAS准静态车辆信号中的复杂噪声并增强弱信号，设计该模型为实现以下功能：

1）多尺度特征提取：在MCGAN模型中引入了多尺度空洞卷积机制。在每个尺度上，利用不同的感受野尺寸提取多样化的特征，从而捕获更多细节信息。

2）层次化特征融合：通过整合来自不同尺度的层次化特征提取结果，模型能够更准确地重建与车辆信号相关的关键信息，并有效抑制背景噪声。

3）针对弱信号的去噪优化：MCGAN能通过多层次权重调整来平衡噪声去除与信号保留的能力，特别是提高对弱信号区域的还原效果。

MCGAN通过在不同尺度上提取特征并计算损失，提升了生成图像的质量和准确性。多尺度提取过程分为两步：

1）多尺度上下文提取：为了从特征图中提取多尺度上下文特征，使用第N层$M_i(i=1,2,\cdots,N)$，其中M_i的计算方式为：

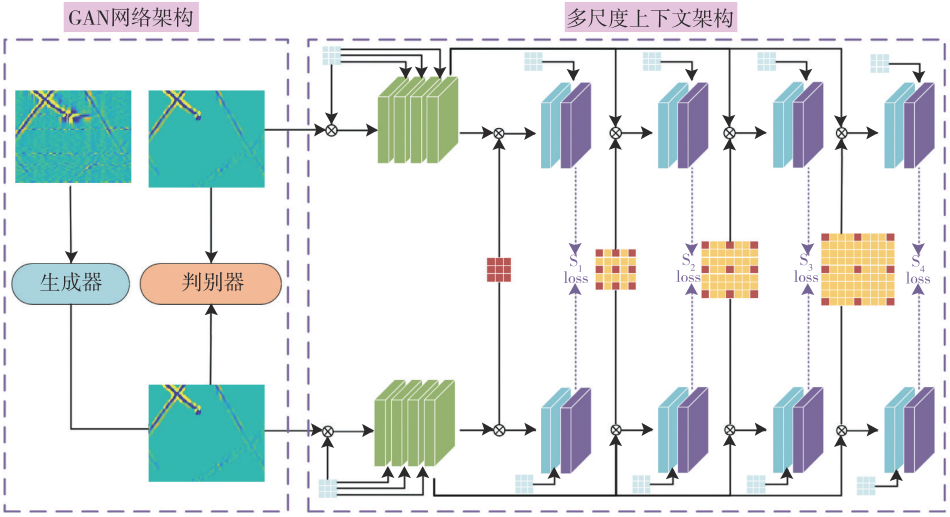

图3 MCGAN模型架构图

$$y=\mathrm{Conv}_{1\times1}\left\{\mathrm{Concat}\left(F_c,F_{d1},F_{d2},\cdots,F_{d(i-1)}\right)\right\}$$
$$\left\{F_c=\mathrm{Conv}_{3\times3}(x),F_{d1}=\mathrm{dc}_{(3\times3,r=1)}(x)\right. \quad (1)$$
$$\left.F_{d2}=\mathrm{dc}_{(3\times3,r=2)},\cdots,F_{dn}=\mathrm{dc}_{(3\times3,r=N-1)}(x)\right\}$$

式中，y为M_i的输出，x为M_i的输入，$\mathrm{Conv}_{3\times3}(\cdot)$表示卷积核为3的卷积操作，$\mathrm{dc}_{(3\times3,\,r=1,\,2,\,\ldots,\,N-1)}(\cdot)$表示具有核大小为3和膨胀率$r$分别为$1,2,\cdots,N-1$的膨胀卷积操作。随着膨胀卷积层的膨胀率$r$增加，卷积层的感受野逐渐增大，最终生成具有相同分辨率的多尺度特征图。

2）高斯滤波：在获得每个尺度的特征图后，使用高斯滤波器对每个尺度的特征图进行平滑处理。使用每一层经过高斯滤波后的图像来计算每个尺度的损失s_i，其表达式为：

$$S_i=E_{x,y,z}\left[\left\|M_i\left(F_G(y)\right)-M_i\left(F_G(G(x,z))\right)\right\|_1\right] \quad (2)$$

式中，x是输入，y是真实值，z是随机噪声，M_i，F_G和G分别表示多尺度卷积层、高斯滤波器和生成器。因此，总的多尺度损失为：

$$L_{\mathrm{MC}}=\sum_i\lambda_i S_i \quad (3)$$

式中，λ_i表示尺度权重，其中$i=1,2,\cdots,N$。实验中的对抗损失为交叉熵损失，计算式为：

$$L_{c\mathrm{GAN}}(G,D)=E_{x,y}[\log D(x,y)]+E_{x,z}[\log(1-D(x,G(x,z)))] \quad (4)$$

其中，生成器G试图最小化对抗损失，而判别器D则试图最大化对抗损失。使用L_1损失来对原始分辨率施加约束，确保生成的图像在细节上尽可能与车辆轨迹图像匹配。这里L_1损失表示为：

$$L_1=E_{x,y,z}\left[\|y-G(x,z)\|_1\right] \quad (5)$$

最后模型将多尺度损失、对抗损失和L_1损失结合，优化生成器G和判别器D，得到整体目标函数：

$$G^*=arg\min_G\max_D L_{c\mathrm{GAN}}(G,D)+\alpha L_1+L_{\mathrm{MC}} \quad (6)$$

通过整合这些损失，模型增强了生成高质量且准确的车辆轨迹图像的能力。多尺度损失捕捉了数据的层次结构，确保了图像去噪效果。

4 实验和结果

4.1 实验方法

使用所提出的算法对DAS数据进行实验。实验中使用基于ResUnet的生成器结构，判别器结构采用常用的PatchGAN。校园环境的特点是行人流量密度大，车辆种类繁多，通常行驶速度较低，速度阈值为20 km/h。尽管一些车辆超过了这一限制，但其速度很少超过40 km/h。因此，所收集到的许多DAS车辆信号较弱。DAS数据经过预处理，以获得准静态信号和相应的标签。每个时空窗口被分割，得到一个1 000时间通道×64空间通道的图像（即1 000×64像素的图像），最终生成1 956张图像作为训练集，635张图像未参与训练，作为测试集。实验在NVIDIA 32GB GPU 4070Ti上进行。

4.2 性能指标

抑制衰减噪声的本质是在尽可能保留信号完整性的同时降低噪声。选用峰值信噪比（PSNR）和结构相似性（SSIM）来分别评估上述两个标准的实现程度。PSNR用于评估去噪后图像的质量，其定义式为：

$$PSNR=10\times\log_{10}\left(\frac{MAX^2}{MSE}\right) \quad (7)$$

式中，MAX是图像中最大像素值，MSE表示均方误差，其定义为：

$$MSE=\frac{1}{m\times n}\sum_{a=1}^{m}\|I(a,b)-K(a,b)\|^2 \quad (8)$$

式中，I表示去噪后的图像，K表示原始图像，图像大小为$m\times n$。PSNR是基于两幅图像对应像素之间的误差，是使用最广泛的客观评价指标，PSNR值越高表明去噪性能越好。然而，PSNR的评价结果可能不足以反映图像结构上的去噪效果。因此，实验还使用SSIM来衡量DAS信号在去噪前后结构信息的保留程度，其定义式为：

$$SSIM(a,b)=\frac{(2\mu_a\mu_b+C_1)(2\sigma_{ab}+C_2)}{(\mu_a^2+\mu_b^2+C_1)(\sigma_a^2+\sigma_b^2+C_2)} \quad (9)$$

式中，μ_a和σ_a分别表示原始信号的均值和标准差，μ_b和σ_b分别表示去噪信号的均值和标准差，σ_{ab}表示原始信号和去噪信号之间的协方差，C_1和C_2为常数。较大的SSIM值表示振动信号的失真程度较低，表明去噪后信号与预处理信号的相似性更高。因此，高SSIM值意味着所采用的去噪技术在保留原始数据完整性方面表现出色，在后续分析和解读中更加可靠。

4.3　基准测试结果

通过测试集展示了不同模型对DAS车辆准静态数据集去噪后的瀑布图效果，如图4所示，红色虚线框表示环境噪声，紫色虚线框表示过去噪，橙色虚线框表示欠去噪。

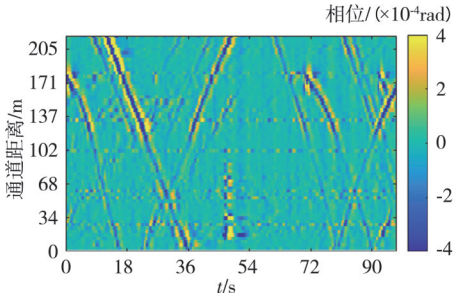

（a）Input

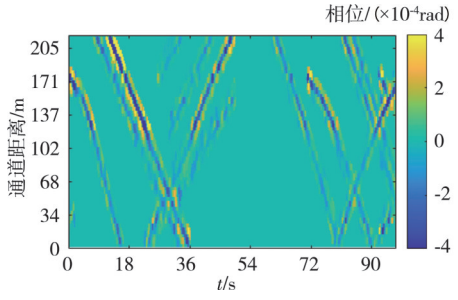

（b）Real Vehicle Trajectory

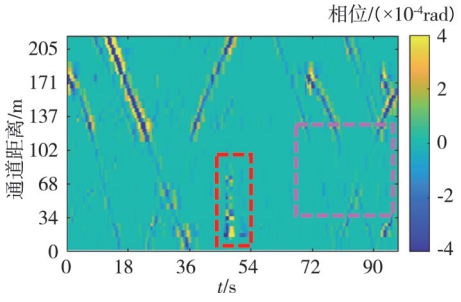

（c）Wavelet-2D

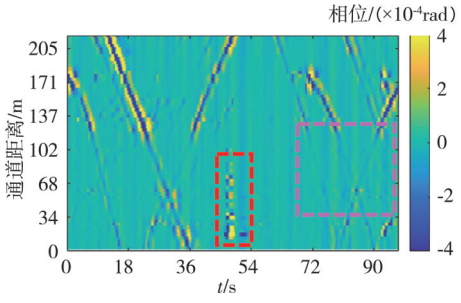

（d）NLM

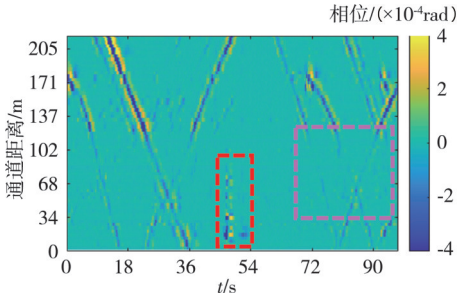

（e）Unet

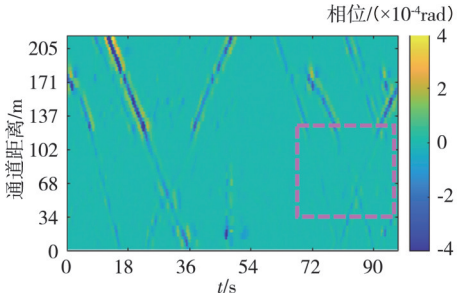

（f）ResUnet

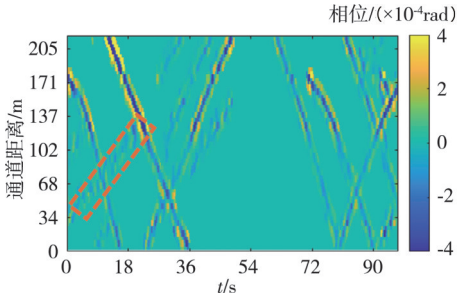

（g）GAN

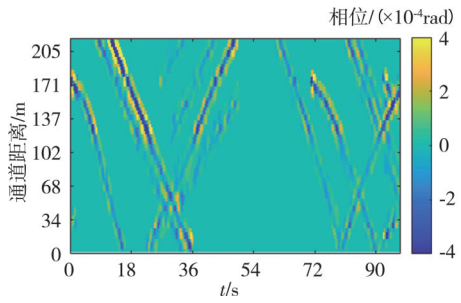

（h）MCGAN

图4 DAS准静态车辆数据集上不同方法的去噪效果比较

从图4(c)和(d)可以看出，二维小波去噪[15]和非局部均值滤波[16-17]环境噪声引起的振动信号识别能力较弱，尤其是当面对超低频多通道的振动信号时，传统算法难以有效滤除这类噪声。相比之下，基于深度学习的Unet和ResUnet网络能够识别DAS车辆的准静态信号，并实现一定程度的去噪。如图4(e)和(f)所示，Unet和ResUnet均能抑制DAS非车辆振动信号，但无法完全消除噪声，且ResUnet的抑制效果明显优于Unet。然而，无论是传统图像去噪方法，还是深度学习的单网络结构去噪，都难以解决车辆信号较弱区域的过度去噪问题，导致这些区域的信号被过度平滑。为解决此问题，以ResUnet为生成器，引入判别器PatchGAN，构建了对抗生成网络，以针对弱信号区域进行去噪，从而减少模型的过度去噪现象。然而，从图4(g)可以看出由于GAN网络中判别器的加入，在抑制生成器过度去噪的同时，也削弱了模型对车辆准静态信号的识别能力，导致噪声去除不足，残留了部分与车辆准静态信号相似的噪声。

为进一步增强模型对车辆准静态信号的识别能力，同时避免过度平滑车辆弱信号，提出MCGAN网络。从图4(h)可以看出，该网络利用多尺度空洞卷积提取上下文信息，有效平衡了车辆信号保留与噪声去除之间的权重，显著提升了模型的综合性能。

为验证模型在衰落通道上的去噪效果，将不同方法处理后的去噪信号与原始信号进行对比，如图5所示。具体而言，从图5(a)的瀑布图中提取衰落通道（红色箭头指向的通道）的数据作为原始信号，不同方法滤波后的结果分别展示在图5(b)～(g)中。可以观察到，二维小波去噪和非局部均值滤波对被衰落信号覆盖的车辆信号识别能力较弱，难以有效提取目标信号。相比之下，Unet和ResUnet能从衰落信号中提取出车辆信号，并在一定程度上抑制衰落信号。而GAN和MCGAN在抑制衰落信号方面表现更为出色，能够更准确地还原车辆信号，有效提升信号的质量和完整性。

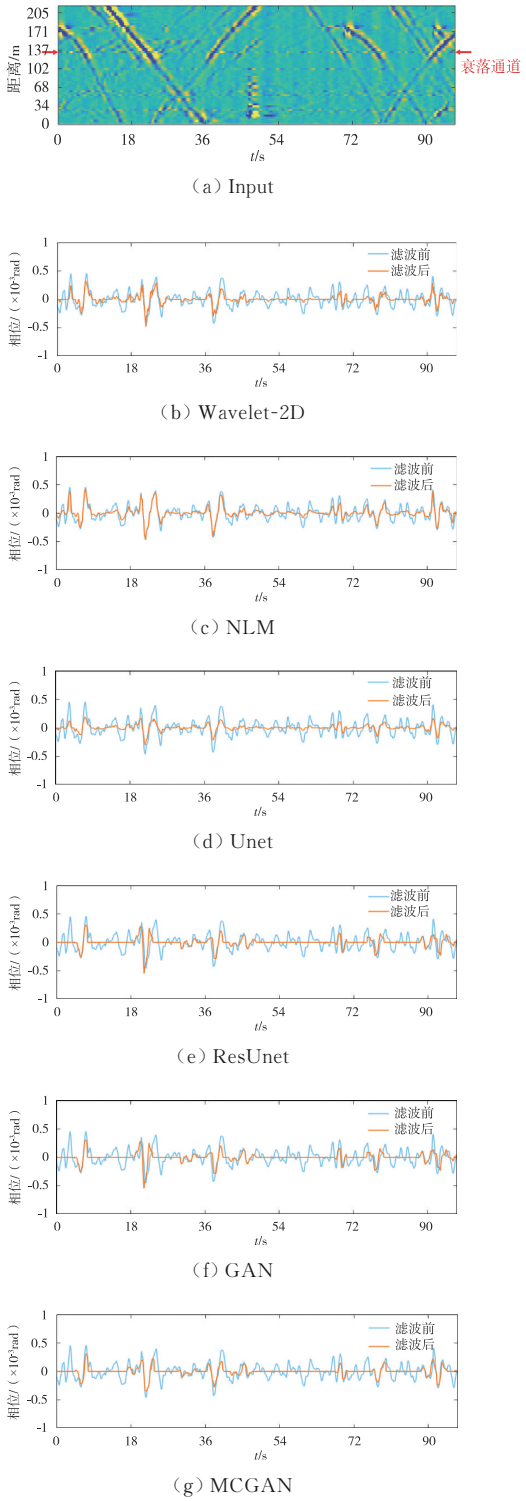

（a）Input

（b）Wavelet-2D

（c）NLM

（d）Unet

（e）ResUnet

（f）GAN

（g）MCGAN

图5 DAS衰落通道上不同方法的去噪效果比较

由表1可以看出Wavelet-2D，NLMUnet在车辆信号的PSNR和SSIM比较低，信号去噪效果较差。ResUnet和GAN的PSNR差距不大，但SSIM从0.724 60提升到0.839 06进一步验证了加入判别器后，模型对弱信号区域的信号还原效果显著增强。

表1　DAS准静态车辆数据上不同方法的对比

方法	*PSNR*/dB	*SSIM*
Wavelet-2D	82.467 8	0.684 22
NLM	80.797 5	0.445 62
Unet	85.578 5	0.660 75
ResUnet	88.141 8	0.724 60
GAN	89.109 3	0.839 06
MCGAN	**90.895 7**	**0.936 02**

实验结果表明，MCGAN模型不仅在准静态车辆信号识别任务中表现出优异的性能，还能在衰落存在情况下，更好地提取出被系统衰落淹没的车辆信号，并较为完整保留车辆信号，实现高质量的车辆成像。

4.4　多尺度分析

MCGAN网络通过引入多尺度上下文特征提取模块，有效提升了对低频噪声和弱信号区域的处理能力，其多尺度分析如表2所示。其中，MCGAN-S3在空洞卷积设计上优化了特征提取，表现出最佳的信号保留与噪声去除平衡能力，体现为最高的PSNR和SSIM值。虽然MCGAN-S4性能接近MCGAN-S3，但因提取尺度的过度增加，导致了轻微的过度平滑。相比之下，GAN对弱信号处理不足，性能显著低于其他改进模型。

表2　MCGAN的多尺度分析

尺度	*PSNR*/dB	*SSIM*
MCGAN-S1	**88.665 6**	0.908 40
MCGAN-S2	89.178 4	0.914 35
MCGAN-S3	**90.895 7**	**0.936 02**
MCGAN-S4	90.510 1	0.931 79
GAN	89.109 3	**0.839 06**

5　结论

分布式声波传感具有长期连续监测、高监测密度和成本效益等优势，因此在智能交通系统中的交通流量检测、车辆类型识别和车辆行为分析方面具有很高的适用性。DAS技术可直接利用现有的光缆，而无需重新铺设，从而显著降低部署成本。然而，这也导致所检测到的车辆信号微弱且存在大量的环境噪声和系统噪声，限制了DAS在交通应用中的广泛采用。为解决这些问题，本文提出MCGAN模型，该模型在搭建对抗生成网络的基础上，引入多尺度空洞卷积和改进的损失函数，从而整合来自不同尺度的层次化特征提取结果，这使得该模型能更准确地重建与车辆信号相关的关键信息，并有效抑制背景噪声。该模型在处理弱信号区域的还原效果显著提升，避免了过度去噪和去噪不足的问题。这为包括高速公路和低速小道在内的各种场景下的车辆检测提供了一种精确且高度实用的解决方案。

参考文献：

[1] Barth M, Boriboonsomsin K. Environmentally beneficial intelligent transportation systems [J]. IFAC Proceedings Volumes, 2009, 42(15): 342-345.

[2] d'Orey P M, Ferreira M. ITS for sustainable mobility: A survey on applications and impact assessment tools[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(2): 477-493.

[3] Wang Q, Zheng J, Xu H, et al. Roadside magnetic sensor system for vehicle detection in urban environments[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(5): 1365-1374.

[4] Ip E, Huang Y K, Huang M F, et al. DAS over 1, 007-km hybrid link with 10-Tb/s DP-16QAM co-propagation using frequency-diverse chirped pulses [J]. Journal of Lightwave Technology, 2023, 41(4): 1077-1086.

[5] Wang P, Zhang H, Chen J, et al. Ultra-long range distributed acoustic sensor using poly-phase coding approach[J]. Journal of Lightwave Technology, 2023, 42(7): 2595-2603.

[6] Lindsey N J, Rademacher H, Ajo-Franklin J B. On the broadband instrument response of fiber-optic DAS arrays[J]. Journal of Geophysical Research: Solid Earth, 2020, 125(2): e2019JB018145.

[7] van den Ende M, Ferrari A, Sladen A, et al. Deep deconvolution for traffic analysis with distributed acoustic sensing data [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(3): 2947-2962.

[8] Mohine S, Bansod B S, Bhalla R, et al. Acoustic modality based hybrid deep 1D CNN-BiLSTM algorithm for moving vehicle classification [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 16206-16216.

[9] Feng Q, Wang S, Li Y. Analysis of DAS seismic noise generation and elimination process based on mean-SDE diffusion model [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5905613.

[10] Yuan S, van den Ende M, Liu J, et al. Spatial deep deconvolution U-Net for traffic analyses with distributed

acoustic sensing [J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(2): 1913-1924.

[11] Liu J, Yuan S, Dong Y, et al. TelecomTM[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2023, 7(2): 1-24.

[12] Min R, Chen Y, Wang H, et al. DAS vehicle signal extraction using machine learning in urban traffic monitoring [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5908510.

[13] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 63 (11): 139-144.

[14] Isken M P, Vasyura-Bathke H, Dahm T, et al. De-noising distributed acoustic sensing data using an adaptive frequency-wavenumber filter [J]. Geophysical Journal International, 2022, 231(2): 944-949.

[15] Sun W, Zheng J, Shen S, et al. Denoising method of the ϕ-OTDR system based on wavelet-subspace joint filtering[J]. IEEE Sensors Journal, 2024, 24(16): 26070-26080.

[16] Li T, Zhang F, Lin J, et al. Fading noise suppression method of Φ-OTDR system based on non-local means filtering [J]. Optical Fiber Technology, 2023, 81: 103572.

[17] Su J, Qin Y, Zheng H, et al. Noise suppression for phase-sensitive optical time-domain reflectometer based on non-local means filtering [J]. Optical Fiber Technology, 2022, 74: 103119.

作者简介：

江　淦(1999—),男,湖北省黄冈市人,硕士研究生,主要研究方向为人工智能在分布式光纤传感器技术应用以及信号处理;

彭　飞(1986—),男,四川省成都市人,副教授,硕士生导师,主要研究方向为解决分布式光纤传感器的光学信号的解调与处理、人工智能、传感参数到事件的精确对应。