Blind Separation Method for Degraded Signals in Fiber Optic Sensing Based on Deep Learning*

LU Xiaoya*, LI Haifang
(College of Information and Electronic Engineering, Shangqiu Institute of Technology, Shangqiu He'nan 476000, China)

Abstract: In distributed acoustic sensing (DAS) systems, the fiber core pumped Raman effect leads to quasi-static mode degradation, and its physical essence is the irreversible coupling of energy from the signal light fundamental mode to higher-order modes. This degradation reduces the separation accuracy of different source signals. To address this issue, a blind separation method for degraded signals in fiber optic sensing based on deep learning is proposed. Firstly, interference cancellation algorithms are used to eliminate strong interference, and then the number of sources is estimated by using the Gale circle theorem and Kullback criterion. Next, a stacked time domain convolutional network (Stacked TCN) model for independent component analysis is constructed. Time domain masks are generated through one-dimensional convolution, layer normalization, and stacked time domain convolutional network blocks to separate source signal features and restore source signal waveforms. The entire process optimizes the model using SISNR as the loss function to achieve precise blind separation. The experimental results show that the proposed method controls the signal amplitude within ±2 A.U. The similarity coefficient is higher than 0.85 and the SMSE is less than 0.025, effectively eliminating strong interference and maintaining high separation accuracy.

Key words: signal and communication engineering; blind signal separation; interference cancellation; Gale's circle theorem; estimation of the number of sources; deep learning
EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2025.11.012

基于深度学习的光纤传感退化信号盲分离方法*

路晓亚*, 李海芳
(商丘工学院信息与电子工程学院, 河南 商丘 476000)

摘 要: 在分布式声波传感(DAS)系统中, 纤芯泵浦拉曼效应导致准静态模式退化, 其物理本质是能量从信号光基模不可逆地耦合至高阶模。这种退化降低了不同信源信号的分离精度。为解决此问题, 提出基于深度学习的光纤传感退化信号盲分离方法。该方法首先用干扰抵消算法清除强干扰, 再利用盖尔圆定理与 Kullback 准则估计信源数。接着, 构建独立成分分析堆叠时域卷积网络(Stacked Time-Domain Convolutional Network, Stacked-TCN)模型, 通过一维卷积、层归一化和叠时域卷积网络块生成时域掩模, 分离源信号特征, 并恢复源信号波形。整个过程以 SISNR 为损失函数优化模型, 实现精确盲分离。实验结果表明, 所提方法将信号幅度控制在了±2A.U.之间, 相似系数高于 0.85, SMSE 小于 0.025, 有效消除强干扰并保持高分离精度。

关键词: 信号与通信工程; 信号盲分离; 干扰抵消; 盖尔圆定理; 信源数估计; 深度学习
中图分类号: TN911 **文献标识码**: A **文章编号**: 1004-1699(2025)11-2017-08

大模场光纤以其低非线性效应和高光束质量独特的光学特性, 成为实现高精度、长距离传感的关键元件。在分布式声波传感(DAS)系统中, 光纤不仅作为传输介质, 还作为传感元件, 能实时、连续地监测沿光纤长度分布的声波信号。然而, 随着传感系统的复杂化及应用场景的多样化, 光纤传感信号在传输过程中极易受到各种物理效应的影响, 其中受激拉曼散射效应尤为显著。这一效应, 特别是在纤芯泵浦拉曼效应的作用下, 会导致信号光能量发生单向且不可逆的耦合, 从基模向高阶模转移, 进而引发准静态模式的退化现象。由于光纤本身的老化、环境因素的变化、光纤连接损耗或光信号传输衰减[1]等原因, 导致光信号在传输过程中发生质量下降或特性改变的现象, 这种退化不仅降低了光纤传

项目来源: 河南省科技攻关项目(242102210111)
收稿日期: 2024-10-16 **修改日期**: 2024-11-08

感信号的质量,还使得不同信源产生的退化信号在传输过程中相互重叠,增加了信号分离的难度,对光纤传感系统的信号处理能力和数据质量构成了严峻挑战。

为了克服这些挑战,国际学术界开始积极探索将深度学习等先进机器学习技术应用于盲信号分离领域。Hassan 等[2]提出稀疏分量分析处理欠定情况。通过自适应时频阈值检测信号单源点,估计混合矩阵;通过层次聚类优化矩阵估计,并在第二阶段,应用最小二乘法恢复源信号,实现退化信号的盲分离。层次聚类优化矩阵估计的过程虽然可以提高矩阵估计的精度,但对于复杂信号其稳健性可能不足,导致信号幅度的控制范围受限。吴润发等[3]采用声表面波传感器收集信号,并设计信号的去噪与频谱分析处理流程;应用奇异谱分析与独立分量分析的信号盲源分离技术,剔除信号中的干扰,提升退化信号的分离精度与可靠性。奇异谱分析在信号幅度变化较大或噪声干扰较强的情况下,其分离效果可能受到影响。Zhao 等[4]提出基于改进小波包和变分模分解的单通道盲源分离(Single Channel Blind Source Separation,SCBSS)。通过改进小波包重建纯净的目标信号;与两级变分模分解本征模及原通道信号结合,构建虚拟多通道;利用特征矩阵的联合近似对角化算法处理虚拟信号,实现盲源分离。该算法涉及多个处理步骤和复杂的参数设置,可能会导致频谱混叠现象,进而影响信号幅度的准确估计。吴宸之等[5]提出小波包混合优化法。通过小波包变换扩展信号维数;利用贝叶斯准则估计信源数并结合鲸鱼优化算法和改进灰狼算法,与独立成分分析融合,实现信号重构分离,近似还原源信号。该方法涉及鲸鱼优化算法和改进灰狼算法,复杂度较高,无法完全避免频谱混叠现象,从而影响信号幅度的准确估计。

在以上研究的基础上,针对 DAS 传感器,本文提出了基于深度学习的光纤传感退化信号盲分离方法。以期通过构建高效的深度学习模型,实现对复杂、重叠的退化信号的有效分离,为 DAS 系统提供更加准确、可靠的信号支持。

1 光纤传感退化信号干扰抵消

光纤传感信号,特别是在分布式声波传感(DAS)系统中,容易受到包括光纤损耗、多径效应、端面反射、环境以及自然光等的干扰,导致信号退化。为从退化混合信号中分离源信号,采用盲信号分离技术结合干扰抵消,以提升信号质量,确保分离的有效性和准确性,这对后续处理和信息提取至关重要。

激拉曼散射是光纤中光与物质相互作用的一种形式,会导致光能量从泵浦光转移到光纤材料中的振动能级,产生斯托克斯和反斯托克斯散射光。当这种散射效应发生时,部分光能量会从信号光基模耦合到高阶模,导致信号光强度的衰减和波形失真。随着散射强度的增加,信号光的能量损失也会增加,从而加剧信号的退化。纤芯泵浦拉曼效应特指在光纤纤芯中发生的拉曼散射,与光纤的材料组成和泵浦光的波长有关。当泵浦光的能量与光纤材料中某个振动能级的能量差相匹配时,会发生强烈的拉曼散射,导致纤芯中的光能量重新分布。这种效应不仅会导致信号光的衰减,还引入额外的噪声和干扰,进一步降低信号质量。在 DAS 传感器系统中,接收到的信号常混有强干扰信号[6]和目标退化信号,直接盲源分离效果不佳。为提高信噪比和测量精度,在盲分离前采用干扰抵消算法有效抑制强干扰信号。光纤传感退化信号干扰抵消框架见图 1。

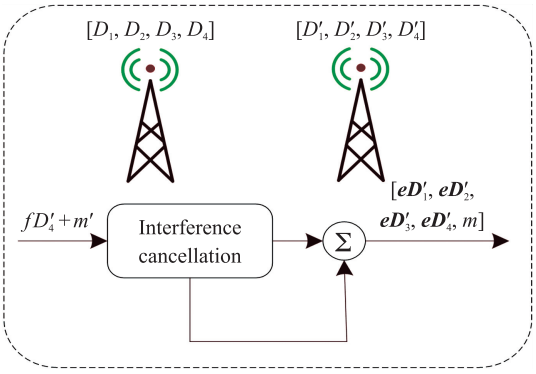

图 1 干扰抵消算法框架

图 1 中,fD'_4+m' 为强干扰信号 D_4 通过高斯信道[7]后得到的干扰估计信号,其中 $\boldsymbol{n}=[n_1,n_2,n_3,n_4]$ 为背景噪声,即每个接收天线接收到的噪声;$[\boldsymbol{eD}'_1,\boldsymbol{eD}'_2,\boldsymbol{eD}'_3,\boldsymbol{eD}'_4,m]$ 为消除强干扰后得到的目标退化混合信号和背景噪声。干扰估计信号的具体表达式为:

$$\begin{cases}\dfrac{|f_i|\times|D'_4|+|n'_i|}{|f_i|\times|D'_4|+|n'_j|}=\dfrac{\hat{f}_i}{\hat{f}_j}\approx\dfrac{|f_i|}{|f_j|},i,j=1,2,3,4\\ |f_i|\times|D'_4|\geqslant|n'|\end{cases}\tag{1}$$

由于强干扰信号是合作信号,其参数已知,此时通过已知的信道参数和干扰源参数来估计,假设每个信号通过高斯信道时都会受到一定的退化,采用减去估计强干扰信号的方式获取真实信号,计算公式如下:

$$\begin{cases} l_1-(l_1+l_2+l_3+l_4)\times\dfrac{\hat{f}_1}{\hat{f}_1+\hat{f}_2+\hat{f}_3+\hat{f}_4}\approx e_1D_1+f_1D_2+g_1D_3=\hat{L}_1 \\ l_2-(l_1+l_2+l_3+l_4)\times\dfrac{\hat{f}_2}{\hat{f}_1+\hat{f}_2+\hat{f}_3+\hat{f}_4}\approx e_2D_1+f_2D_2+g_2D_3=\hat{L}_2 \\ l_3-(l_1+l_2+l_3+l_4)\times\dfrac{\hat{f}_3}{\hat{f}_1+\hat{f}_2+\hat{f}_3+\hat{f}_4}\approx e_3D_1+f_3D_2+g_3D_3=\hat{L}_3 \\ l_4-(l_1+l_2+l_3+l_4)\times\dfrac{\hat{f}_4}{\hat{f}_1+\hat{f}_2+\hat{f}_3+\hat{f}_4}\approx e_4D_1+f_4D_2+g_4D_3=\hat{L}_4 \end{cases} \tag{2}$$

式中:$(l_1+l_2+l_3+l_4)$为四个接收天线接收到的混合信号;$\hat{L}=\{\hat{L}_1,\hat{L}_2,\hat{L}_3,\hat{L}_4\}$为估计线性空间;$\hat{f}_1+\hat{f}_2+\hat{f}_3+\hat{f}_4$为从发射端到接收端的信道退化函数;$e$、$f$、$g$为信道退化相关系数,用于调整消除干扰后的信号强度。

通过消除干扰后的接收信号与相关系数矩阵相乘,得到最后消除强干扰后的目标退化混合信号 Y:

$$\boldsymbol{Y}=\begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix}=\begin{bmatrix} e_1 & f_1 & g_1 \\ e_2 & f_2 & g_2 \\ e_3 & f_3 & g_3 \end{bmatrix}\times[\hat{L}] \tag{3}$$

2　光纤传感退化信号盲分离

光纤传感信号,特别是 DAS 传感器接收的信号,面临复杂多变的非线性、不确定性干扰,传统抵消方法难以彻底去除,且干扰与有效信号频谱重叠,增加了难度。因此,需采用专门针对 DAS 传感器的光纤传感退化信号盲分离技术,该技术仅凭观测到的混合信号,运用统计学和信号处理手段分离源信号,恢复并提取退化信号,展现出更高的适应性和灵活性,有效应对复杂干扰,提升系统稳定性和可靠性。

2.1　信源数目估计

在复杂的 DAS 传感环境中,多个退化信号相互重叠,形成难以直接分离的混合信号。因此,准确估计信源数目是盲分离的前提。采用基于盖尔圆定理和 Kullback 准则的信源数目估计方法,该方法特别适用于 DAS 传感器系统,能准确判断混合信号中信源的数量,为后续的信号分离提供基础。通过计算协方差矩阵、构建酉变换矩阵、计算盖尔圆半径等步骤,最终确定信源数目。

①协方差矩阵计算

从消除强干扰后的目标退化混合信号 Y 中计算协方差矩阵[8-9] $\boldsymbol{R}_X$,反映信号中各分量之间的统计相关性:

$$\boldsymbol{R}_X=\boldsymbol{U}_dF[Y]\boldsymbol{U}_d^J=\begin{bmatrix} \boldsymbol{R}_1 & r \\ r^J & r_{MM} \end{bmatrix} \tag{4}$$

式中:$\boldsymbol{U}_d$ 为一个 $M\times M$ 维度的酉矩阵;$\boldsymbol{F}$ 为消除强干扰后的目标退化混合信号 Y 的特征值矩阵;$\boldsymbol{R}_1$ 为由 $\boldsymbol{R}_X$ 前 $M-1$ 行和列构成的相关子矩阵。

②酉变换[10]

构建一个新的酉变换矩阵 $\boldsymbol{U}$,将协方差矩阵 $\boldsymbol{R}_X$ 转换到一个更便于分析的形式,得到变换后的矩阵 $\boldsymbol{S}$:

$$\boldsymbol{S}=\boldsymbol{U}^J\boldsymbol{R}_X\boldsymbol{U} \tag{5}$$

③计算盖尔圆半径

计算变换后矩阵 $\boldsymbol{S}$ 的盖尔圆半径,如式(6)所示。在理想情况下,信号特征向量的盖尔圆半径远大于噪声特征向量的盖尔圆半径:

$$r_i=|u_i^JA_{M-1}-R_Sb_M^*|\leqslant k|u_i^JA_{M-1}|,\quad i=1,2,\cdots,M-1 \tag{6}$$

④应用盖尔圆准则

基于盖尔圆半径的差异,应用盖尔圆准则(Gerschgorin Disk Estimator,GDE)来估计光纤传感目标退化信号源数目,GDE 的基本思想是找到一个阈值,该阈值能够区分信号和噪声圆盘。通过累加信号圆盘的贡献,并与该阈值比较,来确定信源数目。公式为:

$$\mathrm{GDE}(k)=\boldsymbol{S}-\frac{D(L)}{M-1}\sum_{i=1}^{M-1}r_i>0 \tag{7}$$

式中:$D(L)$为调整因子,用于处理有限快拍数 L 的情况;通过调整信源数目 $k(1\sim M-1)$的值,找到使 $\mathrm{GDE}(k)$首次出现负值的 k_0,此时的 k 即为估计的信源数目,即:

$$N=\mathrm{GDE}(k_0)-1 \tag{8}$$

2.2　深度学习信号盲分离

在实际应用中,若假设的信源数与真实情况不符,许多阵列信号处理算法会失效,影响信源定位和信号处理。针对 DAS 传感器接收的复杂混合信号,引入深度学习信号盲分离技术。该技术能自动从复杂数据中提取特征,通过训练优化分离效果,无需先知道信源数量。因此,该技术能灵活应对信源数量变化,提升信号处理的适应性和准确性。

光纤传感信号混合包含复杂的非线性关系,而 Stacked-TCN 模型通过堆叠多个时域卷积网络块,能深入提取信号的深层特征,有效处理这种非线性混合问题。在实际应用中,信源数量发生变化,而 Stacked-TCN 模型[11-12]无需先知道信源数量,能自动从复杂数据中提取特征,通过训练优化分离效果。

此外,Stacked-TCN 模型采用递增膨胀率的空洞卷积和深度可分离卷积,减少冗余参数,提高计算效率,同时保持模型对复杂信号的解析能力。因此,在信源数目估计后,采用基于独立成分分析堆叠时域卷积网络(Stacked Time-Domain Convolutional Network, Stacked-TCN)的全卷积时域分离网络(Convolutional Time-domain audio separation Network, Conv-TasNet)分离框架,实现目标光纤传感目标退化信号的盲分离。通过堆叠多个 TCN 块,模型能深入提取信号的深层特征,生成高质量的源信号掩模,从而实现高精度的信号分离。其次,Stacked-TCN 模型在训练过程中,通过优化损失函数,能增强模型对噪声的鲁棒性,提高在复杂环境下的信号分离性能。此外,模型引入层归一化步骤,提升跨数据集时的泛化能力,使得模型能适应于不同场景下的信号分离任务,网络结构见图 2。

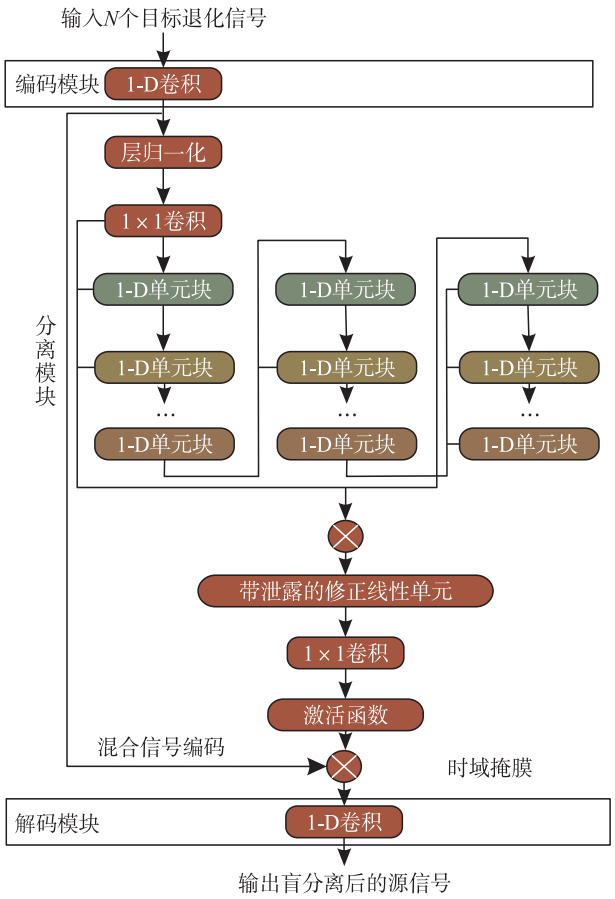

图 2 分离模块网络结构

具体步骤如下:

步骤 1 退化信号编码特征表示

明确给定信源数量 N 的情况下,采用一维卷积技术提取目标光纤传感的退化源信号 x 的线性编码特征。该过程部署 512 组卷积核,以生成这些信号的多维度、编码化特征表示,并用作后续信号分离网络模型的输入。操作核心采用卷积运算 $p_{\text{encoder}}(\cdot)$,包含卷积核的权重与偏置项 w_1、b_1,用于捕捉信号中的关键信息,具体公式为:

$$x_{\text{encoder}}=p_{\text{encoder}}(x)=w_1\times Nx+b_1 \tag{9}$$

步骤 2 源信号掩模生成

①为缓解内部协变量偏移的影响,引入层归一化步骤,提升模型跨数据集时的泛化能力。同时在瓶颈层引入 1×1 卷积减少特征通道的数量,进而简化后续的数据处理流程,使模型更加高效。

②特征被送入由多个堆叠块组成的时域卷积网络(Temporal Convolutional Network, TCN)[13] 中,每个堆叠块含四 TCN 层,均采用递增膨胀率的空洞卷积,并在各层加入深度可分离卷积以提升效率,减少冗余参数。此外,堆叠块间实施三次重复连接,深入提取信号深层特征,增强模型对复杂信号的解析能力。

③采用 Leaky ReLU 激活,避免负值致神经元失活。利用 1×1 卷积瓶颈层恢复特征通道数,并通过 Sigmoid 激活生成两个源信号的时域掩模 s_{mask},具体公式为:

$$s_{\text{mask}}=h_{\text{mask}}^{\text{stacked-TCN}}(x_{\text{encoder}}) \tag{10}$$

式中:$h_{\text{mask}}^{\text{stacked-TCN}}$ 为含 Stacked-TCN 的分离模块。

④利用 1×1 卷积瓶颈层恢复特征通道数,并通过 Sigmoid 激活生成源信号的时域掩模[14]。即 $s_{\text{sep}}=x_{\text{encoder}}\cdot s_{\text{mask}}$ 这一过程通过执行 Hadamard 乘积(·)实现,确保了源信号特征的有效分离与提取。

步骤 3 源信号波形恢复

将分离后的源信号特征实施编码处理,利用一维(1-D)卷积反变换技术,将这些高维(512 维)特征实施解码展开,以恢复或重构出原始信号的特性,公式为 $s^*=p_{\text{decoder}}(x_{\text{sep}})$,其中,$p_{\text{decoder}}$ 为解码器。

步骤 4 网络训练

在网络训练时,将 SISNR 作为损失函数,具体目标函数项为:

$$\min_{\theta}\ell_{\text{SISNR}}(s,s^*)=-10\times\lg\left[\frac{(a_{\text{aim}})^2}{s_{\text{mask}}(s^*-s_{\text{aim}})^2}\right] \tag{11}$$

式中:s_{aim} 为标准化后的源信号。

通过反向传播梯度下降算法[15]展开参数更新,公式如下:

$$\begin{cases}\theta_{\text{encoder}}\leftarrow\theta_{\text{encoder}}-\eta\dfrac{\partial\ell_{\text{SISNR}}}{\partial\theta_{\text{encoder}}}\\ \theta_{\text{mask}}\leftarrow\theta_{\text{mask}}-\eta\dfrac{\partial\ell_{\text{SISNR}}}{\partial\theta_{\text{mask}}}\\ \theta_{\text{decoder}}\leftarrow\theta_{\text{decoder}}-\eta\dfrac{\partial\ell_{\text{SISNR}}}{\partial\theta_{\text{decoder}}}\end{cases} \tag{12}$$

式中：$\boldsymbol{\theta}=\{\theta_{\text{encoder}},\theta_{\text{mask}},\theta_{\text{decoder}}\}$ 为模型参数集；η 为学习率。

至此，在式(12)的约束下，基于独立成分分析堆叠时域卷积网络的退化信号盲分离模型，特征提取、时域掩模生成、信号恢复和优化策略，处理了光纤传感退化信号中的非线性混合问题，实现了目标退化信号的精确盲分离。

本文提出的光纤传感退化信号盲分离方法，通过干扰抵消算法有效抑制了强干扰信号，提高了系统的信噪比。在此基础上，利用基于深度学习的全卷积时域分离网络框架，实现了对目标退化信号的精确盲分离。该方法不仅解决了传统盲分离方法在复杂环境下的精度低、效率低等问题，还为光纤传感系统的实际应用提供了有力支持。通过特征提取、时域掩模生成、信号恢复和网络训练等步骤，该方法准确分离出混合信号中的各个源信号，为光纤传感技术的发展注入了新的活力。

3　实验与分析

为了验证基于深度学习的光纤传感退化信号盲分离方法的整体有效性，需要对其展开测试。

3.1　信号采集环境

①地点选择：实验选址于某企业具有代表性的生产区域，该区域具有典型的温度变化、机械振动、电磁干扰等工业环境特征，这些因素均可能对光纤传感信号产生退化影响。

②DAS 系统部署：在该区域内，部署了高精度的 DAS 系统，利用预先铺设的埋地电缆作为探针光纤，以捕获光纤传感信号。埋地电缆指的是被埋设在地下，用于传输电话、网络等电力或信号的电缆。这些电缆具有坚固的外壳和保护层，以应对地下的复杂环境，包括湿度、温度变化、土壤压力等。在光纤传感技术中，探针光纤是指用于感知温度、压力、振动等外界环境变化并将其转换为光信号进行传输的光纤。探针光纤具有较高的灵敏度，能捕捉到微小的环境变化。在某些情况下，为了监测管道、隧道等地下结构的状态或地下环境的变化，会利用已经铺设好的埋地电缆作为传感元件。这是由于埋地电缆本身就是一个很好的物理结构，可承受地下环境的各种挑战，并且其内部的光纤可作为传感元件来捕获信号。然而，并不是所有的埋地电缆都包含光纤，因此在实际应用中需要特别定制或改造电缆以满足光纤传感的需求。当外界环境发生变化时，探针光纤会感知到这些变化并将其转换为光信号进行传输。这些光信号随后被光纤传感系统接收并进行处理，从而实现对环境变化的监测和测量。该系统具有高灵敏度和宽动态范围，能够准确记录光纤传感过程中的微小变化，如图 3 所示。

图 3　测试现场

③信号特征：采集的信号需展现出显著的光纤传感退化特征，包括但不限于光强衰减、波形失真、信噪比下降等，以全面反映实际应用中可能遇到的各种退化情况。

首先，在测试现场部署高精度的 DAS 系统。这包括将预先铺设的埋地电缆作为探针光纤，用于捕获光纤传感信号。确保 DAS 系统与探针光纤正确连接，并处于正常工作状态。将数据采集设备连接到 DAS 系统的输出端，用于实时采集光纤传感信号。确保数据采集设备与 DAS 系统之间的信号传输稳定可靠。其次，启动 DAS 系统，开始采集光纤传感信号。确保采集到的信号具有显著的光纤传感退化特征，包括光强衰减、波形失真、信噪比下降等。对采集到的信号进行预处理，包括去噪、滤波等步骤，以提高信号质量。预处理后的信号将作为深度学习模型的输入。随后，根据提出的基于深度学习的光纤传感退化信号盲分离方法，构建相应的深度学习模型。这包括干扰抵消算法、盖尔圆定理与 Kullback 准则的信源数估计、基于独立成分分析堆叠时域卷积网络(Stacked-TCN)的退化信号盲分离模型等。使用预处理后的信号数据对深度学习模型进行训练。训练过程中，以 SISNR 为损失函数，通过反向传播优化模型参数，实现对目标退化信号的精确盲分离。将训练好的深度学习模型接入到数据采集设备的后端处理系统中。确保模型能够实时接收预处理后的信号数据，并输出分离后的源信号波形。在实际应用中，需要选择具有高灵敏度和稳定性的探针光纤。在测试现场，将探针光纤(即埋地电缆中的光纤)正确部署在需要监测的区域，并确保其与 DAS 系统正确连接。为了确保实验的实时性，需要选择高速数据采集设备和高效的数据处理算法。同时，对采集到的信号进行实时预处理，以提高信号质量和后续分析的准确性。在模型训练过程中，需要不断调整模型参数和优化算法，以提高模型

的盲分离精度和泛化能力。同时,在测试现场对模型进行实际验证,确保其在不同退化程度下的稳定性和可靠性。

综上所述,通过将提出的基于深度学习的光纤传感退化信号盲分离方法接入到测试现场的 DAS 系统中,并经过系统部署与连接、信号采集与预处理、深度学习模型接入以及实验结果分析等步骤,实现对光纤传感退化信号的精确盲分离。这一过程不仅提高了信号分离的精度和稳定性,还为光纤传感技术在工业环境监测中的应用提供了有力的支持。

3.2 方法初始参数设计及所提方法性能验证

①干扰抵消算法:接收天线数量为 4;步长因子为 0.01;迭代次数为 50 次;②信源数目估计:盖尔圆半径阈值为 0.5,调整因子为初始 1.0;噪声阈值为信号功率的 1/10;③深度学习信号盲分离:卷积核数量为 512,堆叠块数量初始为 3,TCN 层数初始为 4,学习率初始为 0.001,优化器:选用 Adam 优化器;批量大小为 64;正则化参数为 0.000 1;训练轮数为 100 轮。

验证所提方法设计的基于盖尔圆定理与 Kullback 准则相结合的方法,在光纤传感信号中估计退化目标混合信源数的能力。使用实验平台生成 8PSK、16QAM、64QAM 四种调制方式的光纤传感信号(编号为 1~3),随机混合成源信号数目为 2 至 4 的混合信号,添加信噪比(Signal-to-Noise Ratio, SNR)分别为 10 dB 和 20 dB 的高斯白噪声到原始的采集信号中,产生不同的信号退化效果。随机展开信源数估计,使用混淆矩阵(Confusion Matrix)展示不同信噪比下所提方法对信源数的估计结果(图 4),并与实际信源数进行对比。

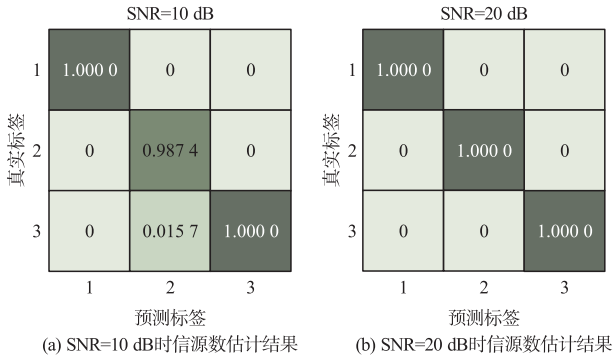

(a) SNR=10 dB时信源数估计结果 (b) SNR=20 dB时信源数估计结果

图 4 不同信噪比下信源数估计结果

验证结果显示,所提方法在光纤传感信号中能有效估计退化目标混合信源数。在不同信噪比(10 dB 和 12 dB)下,均展现出较高的估计准确率,特别是在较高信噪比时更为显著,验证了其在复杂光纤传感环境中的鲁棒性和实用性,也为后续退化信号的盲分离提供了良好的计算环境。

3.3 对比结果分析

引入文献[2]最小二乘法和文献[4]基于改进小波包和变分模态分解的 SCBSS 盲分离算法作为所提方法的对比方法,以此衡量所提方法针对光纤传感退化信号的盲分离效果。选取一段光纤传感信号作为测试信号,采用上述三种方法展开退化信号盲分离,得到的信号波形图分别如图 5(a)~图 5(d)所示。

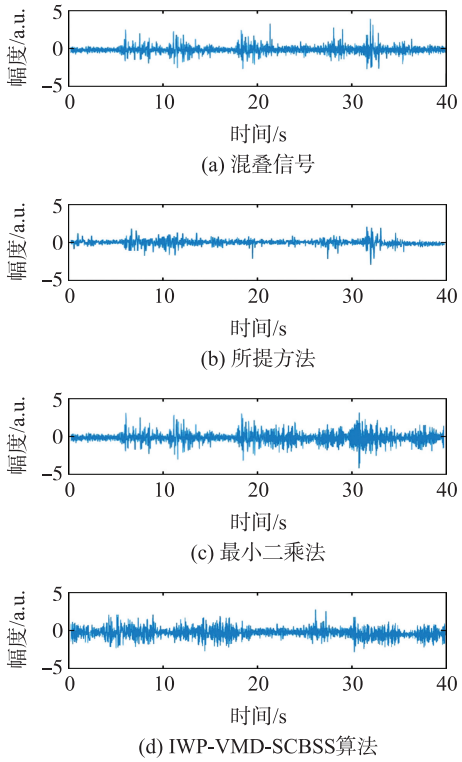

(a) 混叠信号
(b) 所提方法
(c) 最小二乘法
(d) IWP-VMD-SCBSS算法

图 5 各方法信号盲分离结果

图 5 表明,所提方法相较于传统的最小二乘法和 SCBSS 盲分离算法展现出了更为优越的性能。具体而言,所提方法不仅成功将信号幅度控制在 ±2 A.U. 范围内,更有效地恢复了源信号的波形特征,减少了噪声和干扰的影响。这主要是由于所提方法在处理复杂且退化的光纤传感信号时,更精确地识别并分离出各个源信号,同时保持信号的细节信息。此外,该方法在算法设计上融入了更高效的特征提取方法,从而实现了在细节保留和分离精度上的双重提升。相比之下,最小二乘法虽然实现简单,但在处理复杂且退化的光纤传感信号时,其分离效果较为有限,引入了额外的失真或误差;SCBSS 盲分离算法的分离效果也在细节保留和噪声抑制方面有所不足。因此,所提方法在处理光纤传感退化信号时,不仅具有更高的分离精度和更强的噪声抑制能力,还在保持信号细节的同时,实现更准确的源信号恢复。

采用相似系数 ζ_{ij} 和 SMSE 两个指标直观地评估所提方法的有效性和分离性能[16],指标计算公式分别为:

$$\begin{cases}\zeta_{ij}=\zeta(d_i,d_i)= \\ \quad\left|\sum_{t=1}^{Z_d}\hat{d}_i(t)d_i(t)\right|\Big/\sqrt{\sum_{t=1}^{Z_d}\hat{d}_i^2(t)\sum_{t=1}^{Z_d}d_i^2(t)} \\ \text{SMSE}=N^{-1}\sum_{k=1}^{N}E\{|\tilde{d}_k-\tilde{\hat{d}}_k|^2\}\end{cases} \tag{12}$$

式中:$d_i(t)$ 和 $\hat{d}_i(t)$ 为原始信号中第 i 个分量和盲分离后估计信号的第 i 个分量;Z_d 为参与信号长度;$E\{|\tilde{d}_k-\tilde{\hat{d}}_k|^2\}$ 为盲分离信号与源信号之间各分量的差值。盲分离效果佳则相似度 ζ_{ij} 接近于 1,若 SMSE 低则分离效果更优(理论上接近 0 为最佳)。为了量化受激拉曼散射效应和纤芯泵浦拉曼效应对光纤传感信号退化的影响,采用五等分法将光纤传感退化信号分为几乎无损、轻微退化、中度退化、重度退化、极端退化五种程度,分别采集包含这五种退化程度的信号展开测试,得到的结果如表 1 所示。

表 1　各方法盲分离性能对比

退化程度	评估指标	所提方法	最小二乘法	SCBSS 盲分离算法
几乎无损	相似系数	0.990	0.950	0.970
	SMSE	0.001	0.005	0.003
轻微退化	相似系数	0.980	0.900	0.940
	SMSE	0.003	0.010	0.006
中度退化	相似系数	0.950	0.850	0.900
	SMSE	0.008	0.020	0.012
重度退化	相似系数	0.900	0.750	0.800
	SMSE	0.015	0.035	0.025
极端退化	相似系数	0.850	0.650	0.700
	SMSE	0.025	0.050	0.040

从表 1 数据可以看出,相比传统最小二乘法,所提方法在几乎无损、轻微退化、中度退化、重度退化、极端退化五种程度下,相似系数均高于 0.85,且 SMSE 值均小于 0.025,这表明该方法在不同退化程度下更有效地保持信号的相似性和减少误差(SMSE)。这主要是由于该方法采用了光纤传感退化信号盲分离方法,更精确地识别并分离出各个源信号,即使在信号严重退化的情况下也能保持较高的分离精度。其次,所提方法在算法设计上融入了堆叠时域卷积网络的特征提取策略,从而有效减少了噪声和干扰对信号的影响,提高了信号的恢复质量。最后,该方法还具备更强的鲁棒性和适应性,应对各种复杂多变的退化情况,确保在不同退化程度下均能稳定地输出高质量的分离结果。而 SCBSS 盲分离算法虽然性能尚可,但在极端条件下其分离精度和稳定性略显不足;最小二乘法整体性能均差一些。综上,所提方法在复杂光纤传感退化信号处理上具有更优的分离效果和鲁棒性。

4　结论

所提方法结合干扰抵消算法、盖氏圆盘理论信源数目估计以及深度学习技术,形成了一个完整的处理流程来处理光纤传感退化信号的盲分离问题。实验结果证实了所提方法在多种退化程度下均能保持优异的分离性能,不仅有效控制了信号幅度波动,还实现了高相似系数和低均方误差。这一成果不仅显著提升了光纤传感系统的信号处理能力和数据质量,还为光纤传感领域中的退化信号处理和盲源分离问题提供了新的解决思路和技术手段。

参考文献:

[1] 文虎,刘盛铠,郑学召,等. 基于钻孔救援的 UWB 雷达波传输衰减研究及展望[J]. 工矿自动化,2023,49(4):42-49.

[2] Hassan N,Ramli D A. Sparse Component Analysis(SCA) Based on Adaptive Time—Frequency Thresholding for Underdetermined Blind Source Separation(UBSS)[J]. Sensors,2023,23(4):2060.

[3] 吴润发,鄂振伟,付东,等. 基于声表面波技术的变压器无线温度传感器信号处理方法[J]. 压电与声光,2023,45(1):82-88.

[4] Zhao W,Fu W. A Single-Channel Blind Source Separation Algorithm Based on Improved Wavelet Packet and Variational Mode Decomposition[J]. Telecommunication Systems,2024,86(1):127-142.

[5] 吴宸之,李炜,房琪,等. 基于小波包混合优化的欠定盲源分离方法[J]. 电子测量与仪器学报,2023,37(9):213-224.

[6] Sleewaegen J M,Montenbruck O,Steigenberger P. Pseudorange Bias from Inter-Signal Interference:The QZSS L5-L5S Case[J]. GPS Solutions,2023,27(3):150.

[7] 马康宁,徐寅飞,邵硕,等. 衰落高斯 MIMO 窃听信道下安全发送方案及其优化问题[J]. 中国科学:信息科学,2022,52(2):239-252.

[8] 张光普,刘恺忻,付进,等. 无误差阵列协方差矩阵分离的阵列自校正方法[J]. 声学学报,2024,49(2):298-307.

[9] Jackson D,Viechtbauer W,Aert R C M. Multistep Estimators of the Between-Study Covariance Matrix under the Multivariate Random-Effects Model for Meta-Analysis[J]. Statistics in medicine,2024,43(4):756-773.

[10] 金彦亮,闾儒坤,汪小勇,等. 基于酉重构子空间的一

维 DOA 估计[J]. 应用科学学报, 2023, 41(6): 926-939.
[11] 曹磊,王珺瑶,朱俊杰,等. 基于深度学习和高分辨率遥感图像的车流量统计[J]. 江苏大学学报(自然科学版),2023,44(5):570-576.
[12] 王玉芳,朱琛,陈江萍. 基于深度学习 Transformer 网络的皮革表面瑕疵自动检测研究[J]. 中国皮革,2024,53(6):28-31,36.
[13] 董卫宇,李海涛,王瑞敏,等. 基于堆叠卷积注意力的网络流量异常检测模型[J]. 计算机工程,2022,48(9):12-19.
[14] 包涵,张涌. 三维掩模光刻成像快速计算模型[J]. 光学学报,2023,43(13):252-260.
[15] 秦利娟,冯乃勤. 基于深度学习反向传播的稀疏数据特征提取[J]. 计算机仿真,2022,39(5):333-336,469.
[16] 吴慧娟,王新蕾,廖海贝,等. 全智能化分布式光纤声波传感器的信号处理方法[J]. 光学学报,2024,44(1):180-200.

路晓亚(1983—),女,汉族,河南省商丘市人,硕士,副教授,研究方向:计算机技术。长期从事一线教学工作,主讲课程有《操作系统》《面向对象编程与设计》等,教学特色为启发思维,互动高效;主持、参与完成各级课题 18 项,发表论文 20 余篇,主编、参编出版教材 4 部。