

弹底压力残缺信号的时频特征融合填充方法

胡晋刚¹, 原 玥^{2,3}, 赵永壮^{2,3}, 王 宇^{2,3}, 孙传猛^{2,3}, 武耀艳^{2,3}

(1. 山西省工业和信息化厅, 山西 太原 030032;

2. 中北大学 省部共建动态测试技术国家重点实验室, 山西 太原 030051;

3. 中北大学 电气与控制工程学院, 山西 太原 030051)

摘要: 针对火炮测试中因极端环境导致的弹底压力信号残缺问题, 提出基于长短时记忆网络(LSTM)与生成对抗插补网络(GAIN)的时频特征融合填充方法以提高信号填充的准确性。运用GAIN网络的对抗训练原理, 深入学习信号内部的复杂规律和潜在分布特征, 确保填充过程中保持信号全局结构与局部特征的一致性; 采用时频特征融合策略, 通过串并行双分支结构提取并融合弹底压力信号的时域与频域特征, 从而全面捕捉信号的关键特征信息; 引入具有时序处理能力的LSTM网络, 学习并捕捉信号中的时序模式和长期依赖关系, 确保填充信号在时序上的完整性和连贯性。试验结果表明: 重构后的信号与完整信号高度相似, 15 dB和30 dB信噪比情况下拟合优度达到0.973 6和0.996 8, 实现了对弹底压力信号的精准填充。

关键词: 弹底压力; 残缺信号填充; 时频特征融合; 长短时记忆网络; 生成对抗插补网络

中图分类号: TP206.3

文献标识码: A

doi: 10.62756/csjs.1671-7449.2025030

引用格式: 胡晋刚, 原玥, 赵永壮, 等. 弹底压力残缺信号的时频特征融合填充方法[J]. 测试技术学报, 2025, 39(2): 180-189.

HU Jingang, YUAN Yue, ZHAO Yongzhuang, et al. Fusion filling method of time-frequency characteristics for pressure-deficient signal at bottom of shell[J]. Journal of Test and Measurement Technology, 2025, 39(2): 180-189.

Fusion Filling Method of Time-Frequency Characteristics for Pressure-Deficient Signal at Bottom of Shell

HU Jingang¹, YUAN Yue^{2,3}, ZHAO Yongzhuang^{2,3}, WANG Yu^{2,3}, SUN Chuanmeng^{2,3}, WU Yaoyan^{2,3}

(1. Department of Industry and Information Technology of Shanxi Province, Taiyuan 030032, China;

2. State Key Laboratory of Dynamic Measurement Technology, North University of China, Taiyuan 030051, China;

3. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China)

Abstract: Missing projectile base pressure signals often occur due to extreme environments during artillery testing. To address this issue, a time-frequency feature fusion imputation method is proposed based on LSTM and GAIN to enhance the accuracy of signal reconstruction. The adversarial training principle of the GAIN network is utilized to learn the complex internal patterns and potential distributions of the signal and to ensure consistency between the global structure and local features during the imputation process. A time-frequency feature fusion strategy and a dual-branch parallel and serial structure are adopted to extract and integrate both time-domain and frequency-domain features of the base pressure signal. As a result, the critical signal information of the signal is comprehensively captured. LSTM networks with sequential processing capability is incorporated to learn and capture temporal patterns and long-term dependencies within the signal, as well as ensure the temporal completeness and coherence of the reconstructed signal. Experimental results show that

收稿日期: 2024-09-17

基金项目: 省部共建动态测试技术国家重点实验室基金资助项目(2023-SYSJJ-08); 山西省基础研究计划资助项目(202203021212129, 202203021221106)

作者简介: 胡晋刚(1977-), 男, 硕士, 主要从事恶劣环境下动态信息获取与校准技术研究。E-mail: 956628088@qq.com。

the reconstructed signals are highly similar to the complete signals. The goodness-of-fit reach 0.973 6 under a 15 dB signal-to-noise ratio(SNR)and 0.996 8 under a 30 dB SNR, respectively.

Key words: projectile base pressure; incomplete signal filling; time-frequency feature fusion; long-short term memory networks (LSTM); generative adversarial imputation nets(GAIN)

0 引 言

火炮内弹道测试成本高昂且耗时冗长，而弹底压力作为关键参数，对提升火炮的可靠性和安全性至关重要。因此，确保弹底压力信号的完整性和连续性对评估火炮的稳定性具有重要意义。然而，高温、高压和剧烈振动等恶劣环境常导致测压仪器损坏或失效，进而出现残缺信号。目前，对弹底压力信号的研究大多集中在测试系统^[1-5]的研制上，并已取得显著进展。然而，对于采集到的压力数据处理和分析仍然较为薄弱，尤其在弹底压力残缺信号的填充方面研究尚显不足，需进一步探索。

尽管弹底压力残缺信号的填充研究相对较少，但是在其他领域，对残缺信号的填充技术已经得到广泛研究和应用。Wang等^[6]提出了一种用于粗糙表面接触的新型数值模型，并将其应用于正齿轮的磨损预测，使得填充数据的准确率较高，但插值节点选择不当会导致过拟合，从而影响模型的泛化能力。Nijman等^[7]提出缺失预测变量值的实时插补，改进了预测模型在日常实践中的应用，但填补模型适用于大量数据集构建，具有一定局限性。陈博等^[8]提出一种基于期望最大化算法的方法来估计含有缺失数据的滑动平均模型，但对数据序列长度和数据缺失比例不太敏感。Yesilbudak等^[9]提出了一种基于K-近邻法(K-Nearest Neighbor, KNN)分类器的新方法，能够减少风电功率预测的不确定性，但KNN算法对噪声和异常值较为敏感，会影响预测的准确性。Yang等^[10]通过构建多个决策树并将它们的结果进行汇总来做出最终的决策，提高了预测的准确性，但是预测速度较慢。Che等^[11]提出了一种基于门控循环单元(Gate Recurrent Unit, GRU)的新型深度学习模型，用于处理多变量时间序列数据中的缺失值问题，但模型依赖于与预测任务相关的缺失模式信息来提高预测性能。Cao等^[12]提出了一种生成对抗插补网络(Generative Adversarial Imputation Nets, GAIN)的新方法，用于填补缺失数据，但需要大量的计算资源。Zhao等^[13]提出一种结合改进型完全集经验模态分解方法和生成式对抗插值网络(Generative Adversarial Network, GAN)的风电数

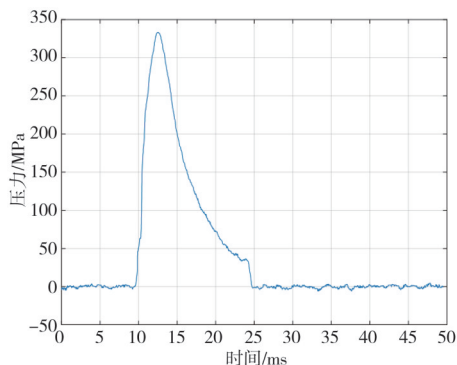
据缺失插值模型，但对时序复杂的残缺信号填充存在局限性。

上述方法都取得了显著性的效果，但都具有一定的局限性。因此，本文考虑将信号处理技术与深度学习相结合，以GAIN网络为主要框架，将融合了时频特征的串并行双分支结构与长短时记忆网络(Long Short-term Memory Networks, LSTM)加入生成器中，从不完整的信号中提取关键时频特征和长期依赖关系，进而生成更接近完整信号的填充数据，以此恢复弹底压力信号的完整数据。


1 机理分析

1.1 恶劣环境下弹底压力缺失信号分析

在某基地获取大量的火炮弹底压力数据，发现火炮发射过程的弹底压力^[14-16]曲线均如图1所示。



(a) 时域图



(b) 频域图

图 1 弹底压力信号

Fig. 1 Bottom pressure signal

在时域上，火炮发射过程中的弹底压力信号呈现出明显的三阶段特征，这些特征与发射过程具有

明确的物理关联性。第一阶段从点火开始至弹丸启动,火药燃烧产生的高温高压气体推动弹丸加速运动,导致弹底压力呈指数级快速上升。第二阶段始于弹丸运动直至出膛,随着火药持续燃烧和弹丸加速,炮膛容积减小,弹底压力在达到峰值后开始呈非线性下降,这一变化规律与火药燃烧动力学特性、弹丸质量惯性以及炮膛结构参数等物理因素存在确定性关系。第三阶段为弹丸完全出膛后,弹底压力信号归零。整个过程,弹底压力信号的时域特征表现为:初始阶段的急剧上升、中期的非线性下降以及末期的平稳归零,表明信号变化具有时序相关性。

在频域上,大部分信号的能量集中在低频部分,即主要信息在低频段,而高频部分能量迅速衰减,表明信号高频波动较弱,可能是由于噪声或次要物理过程引起的。时域中的急剧上升和缓慢下降阶段

对应于频域中的低频成分,而高频成分可能与压力变化的快速波动有关。

在弹底压力信号的采集与传输过程中,尽管采用了先进的技术和精密的设备,但仍难以完全避免数据缺失或损坏的风险。这主要是由于一系列复杂且不可控的因素所致,包括传感器故障、电路设计不完善以及存储介质的不稳定等。图2展示了3种实际测试过程中可能出现的信号缺失情况。弹底压力的时域特征与频域特征是由火炮发射过程的物理本质决定的,采集装置的失效仅会影响数据的获取,而不会影响弹底压力信号本身的时域特性与频域特性。根据万能逼近定理,深度学习通过学习数据分布生成无限逼近真实数据的插补值,能够更好地恢复信号的完整性。




图2 弹底压力信号缺失情况

Fig. 2 The missing of the pressure signal at the bottom of the bomb

根据上述分析可以构建GAIN网络,该模型在保留GAN网络框架的基础上,加入了掩码矩阵(Mask Matrix)和提示矩阵(Hinter Matrix),以生成更符合原始数据分布的样本数据。

GAIN通过学习数据的全局分布特征能够生成缺失数据,并保证生成的数据符合整体数据的分布特性,对于频谱上存在噪声的部分,GAIN可以有效生成符合数据分布的补充信号。

由于GAIN预测时序信号的能力较差,GAIN模型还融合LSTM。LSTM在时间序列数据中能够有效捕捉信号的时序关系,可以利用信号的上升与下降趋势来预测缺失的低频信号部分,使得模型能够捕获并记忆长时间范围内的依赖关系,从而在填充缺失值时能够全面考虑整个序列的上下文信息,实现最优数据填充的效果。具体方法框图如图3所示。

1.2 基于LSTM与GAIN的时频特征融合填充方法

本文提出的填充方法主要以融合LSTM的

GAIN为主干结构,结合时频转换模块与串并行双分支网络。下面分别从改进后的生成器、判别器以及附加模块详细介绍网络结构。

1.2.1 改进后的生成器

生成器的任务是生成与真实数据尽可能相似的填充值以欺骗判别器,使其无法区分填充数据和真实数据。改进后生成器主要由3层LSTM、串并行双分支结构以及一个全连接层神经网络组成。这样的结构设计可以使生成器利用LSTM输出的隐藏状态来生成与真实数据分布更相近的假数据。

在相同网络参数训练条件下,对比生成器的损失函数值,如表1所示,3层LSTM结构的生成器展现出了最低的损失函数值,相比于1、2、4层LSTM结构具有显著优势。相较于4层LSTM网络,3层LSTM网络在保持一定模型复杂度的同时,避免了过多的计算成本和潜在的过拟合风险。因此,本文选择3层LSTM网络加入生成器,能够在保证模型性能的同时,维持较低的计算开销和泛化能力。

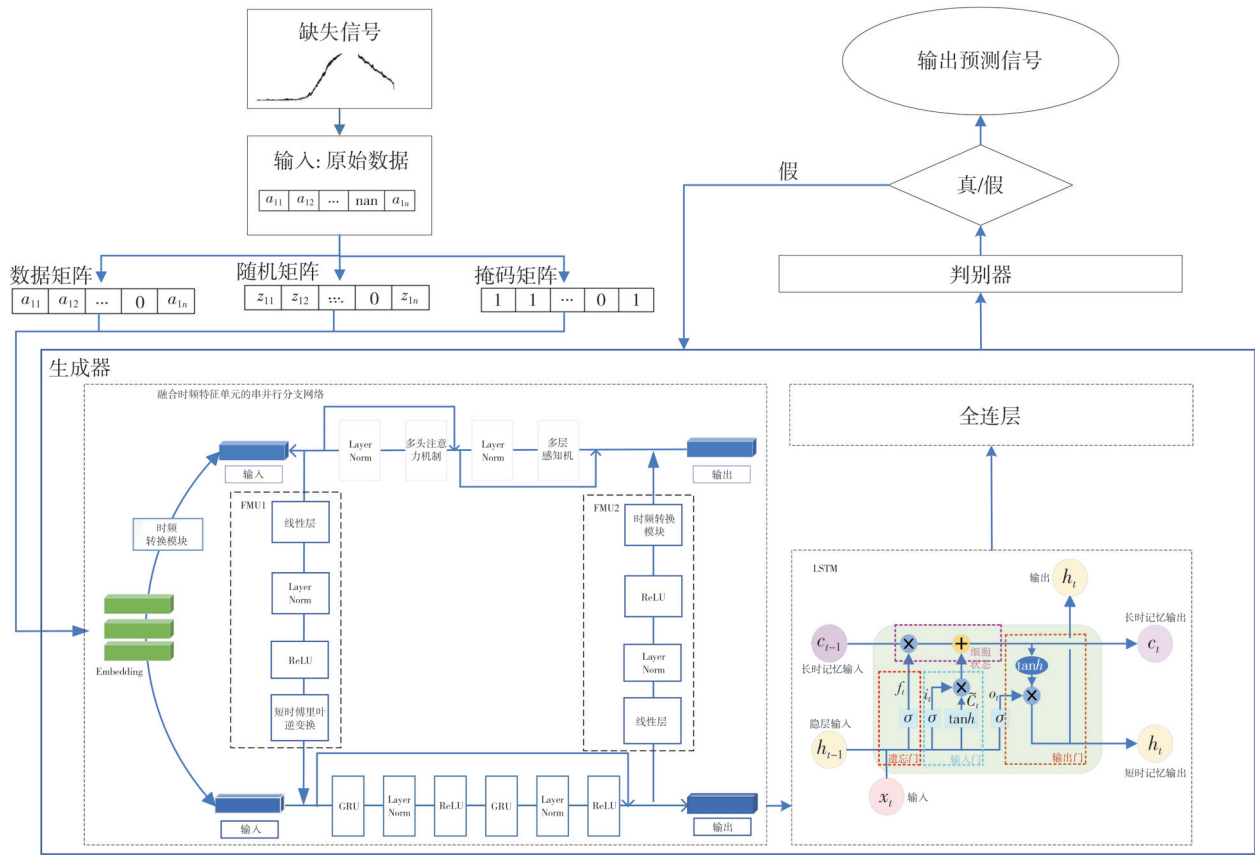


图3 基于LSTM与GAIN的时频特征融合填充方法框图

Fig. 3 Block diagram of the time-frequency feature fusion filling method based on LSTM and GAIN.

表1 4种LSTM结构损失函数数值对比

Tab. 1 Comparison of loss function values for 4 LSTM structures

LSTM层数	1	2	3	4
损失函数值	3×10^{-3}	7×10^{-6}	5×10^{-6}	9.9×10^{-5}

为了充分融合弹底压力信号中的时域与频域特征,采用基于GRU和Transformer模型的串并行双分支网络^[17],网络结构如图4所示,由Embedding层、双分支结构、用于耦合分支的特征融合单元(Feature Merging Unit, FMU)和用于输出的线性层所组成。双分支结构由Res-GRU和Transformer两个分支组成,形成了优势互补的特征提取机制。Res-GRU分支通过串行方式深入挖掘弹底压力信号的时序依赖关系,捕捉局部细微特征;而Transformer分支则以并行方式全局审视信号的频域特征,学习潜在的全局特征。在串并行双分支网络中,为了确保时域和频域特征的有效融合,从Res-GRU分支和Transformer分支的第二个模块开始,引入FMU来校准和融合两种不同类型的特征。为此,设计了两个方向的FMU:一个方向是将Res-GRU分支提取的局部时域特征通过时频转换模块转换为频域特征,以适配Transformer分支的处理;另一个方向则是将Transformer分支提取的频域特征通过短时傅里叶逆

变换转换回时域,以适配Res-GRU分支。

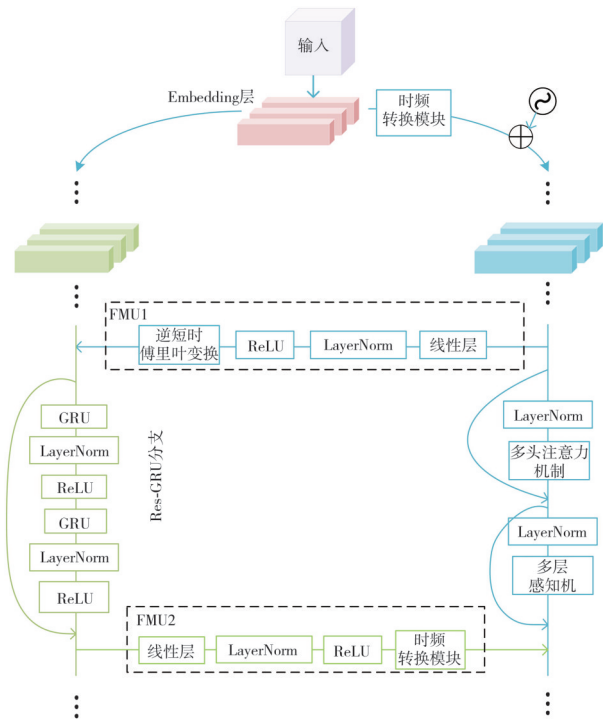


图4 串并行双分支网络结构

Fig. 4 Parallel and serial dual branches network structure

改进后生成器结构如图5所示。改进后生成器的生成过程表示为

$$\begin{aligned}\bar{X} &= G[LSTM(\tilde{X} \cdot M \cdot Z), M, (1 - M) \odot Z], \\ \hat{X} &= M \odot \tilde{X} + (1 - M) \odot \bar{X},\end{aligned}\quad (1)$$

式中: $LSTM(\tilde{X} \cdot M \cdot Z)$ 表示将融合特征、掩码和噪声在特征维度上进行拼接,作为LSTM网络的输入; \odot 表示Hadamard乘积运算; M 为与原始数据同形的掩码矩阵; \bar{X} 为生成器生成的填充数据; \hat{X} 为生成器最终输出的完整数据。




Fig. 5 Improved generator structure

1.2.2 判别器

判别器的架构由多层全连接神经网络构成,每层的神经元均与上下层全连接。为了增强模型处理非线性数据的能力,判别器在隐藏层中均采用LeakyReLU激活函数。相较于传统的ReLU,LeakyReLU在处理负输入信号时保留了微小的正梯度,这有助于缓解梯度消失问题。在判别器的输出层,使用sigmoid激活函数将输出值限制在0~1的范围内,这一输出值代表判别器对输入数据真实性的判断概率,结构如图6所示。




图6 判别器结构

Fig. 6 Discriminator structure

判别器的工作可被视作一个二分类任务,其损失函数通常采用二元交叉熵损失,如下所示

$$\mathcal{L}(a, b) = \sum_{i=1}^d [a_i \ln b_i + (1 - a_i) \ln (1 - b_i)], \quad (2)$$

式中: a_i 为 D 预测结果矩阵中的元素; b_i 为对应于 a_i 的 M 矩阵中的元素。

1.2.3 附加模块

GAIN网络通过引入掩码矩阵和提示矩阵,增强了模型在提取缺失值特征方面的能力。掩码矩阵用于标记缺失值的位置,而提示矩阵则帮助分析缺失值与周围值之间的关联。这使得网络能够更精确地定位和填补缺失值,从而大幅提升了缺失信号预测的质量和效率。

1.2.4 训练流程

基于LSTM与GAIN的时频特征融合填充网络的训练过程,通过最大化正确预测掩码矩阵 M 的概率,来训练生成器生成更接近原始数据的值,网络训练过程如图7所示。

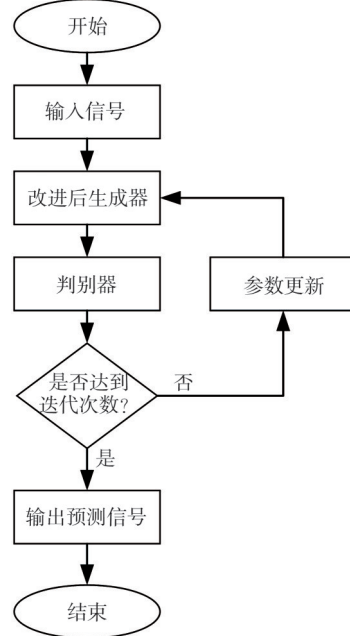


Fig. 7 Improved GAIN network training process

2 试验研究

2.1 试验方案

首先,建立弹底压力信号数据集。鉴于弹底压力信号数据的采集较为困难且具有保密性,因此,根据实验室模拟弹底压力测试信号的相关数据,拟合出200组具有相同形状特征的数据,每组数据都包含990个时间点。为丰富弹底压力信号特征,使得模拟信号更接近真实的弹底压力数据,分别加入信噪比为15 dB和30 dB的高斯白噪声,总共得到400组含噪的模拟弹底压力信号数据。模拟信号以及加噪后的模拟信号见图8所示。

将实验数据集中的数据随机组合成100个大小为 10×990 的矩阵。实验模拟传感器损坏导致测量数据缺失的情况,将第3、5、8、10列数据的260~990时间段做缺失处理,缺失值用nan表示,其余列为完整的信号数据。

其次,将实验数据集按照2:1的比例划分为训练集和测试集。利用训练集数据对填充模型进行训练,测试集数据对训练后的模型进行测试,验证模型的填充效果。搭建并训练深度学习网

络,利用测试集测试训练网络的性能。

最后,基于本文提出的填充方法对弹底压力信号进行填充试验,通过与原始 GAIN、结合 LSTM 的 GAN 预测填充方法(GAN-LSTM)以及 K 近邻法(KNN)进行对比,并设置不同的消融试验以验证本文方法的有效性和优越性。

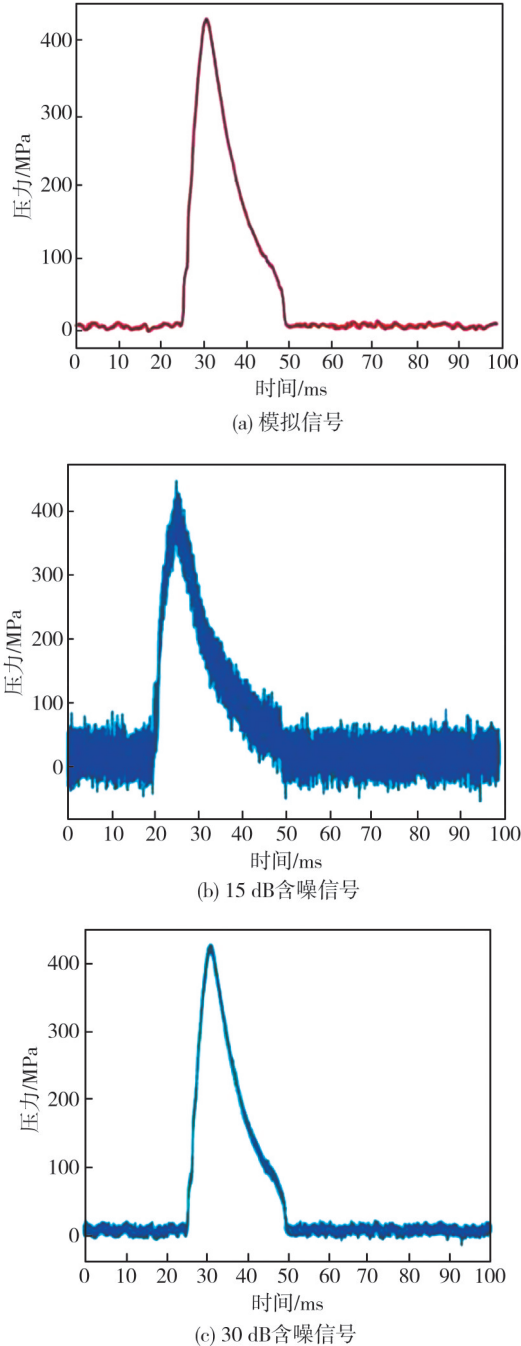


图 8 模拟信号、15 dB 含噪信号、30 dB 含噪信号
Fig. 8 Analog signals、15 dB noisy analog signals、30 dB noisy analog signals

2.2 评价指标

实验采用均方误差(Mean Squared Error,

MSE)、均方根误差(Root Mean Square Error, RMSE)和拟合优度(Goodness of Fit, GOF)对结果进行测评。

1) MSE 反应真实值与重构值之间差异平方的平均,

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2, \quad (3)$$

式中: y_i 与 \hat{y}_i 分别为原始数据和模型的预测值; m 为样本数量。MSE 值越小,表明模型的预测准确度越高,反之则越低。

2) RMSE 反应填充值与真实值之间的差异,

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}. \quad (4)$$

3) GOF 是衡量预测数据与实际数据之间匹配程度的关键指标,对于评估模型的预测效果和准确性至关重要。其中,可决系数(又称确定系数) R^2 是量化拟合优度的常用统计量。 R^2 的取值范围在 0~1 之间,其值越接近 1,表示模型的拟合效果越好,即模型能够更准确地捕捉数据中的变化。

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y}_i)^2}, \quad (5)$$

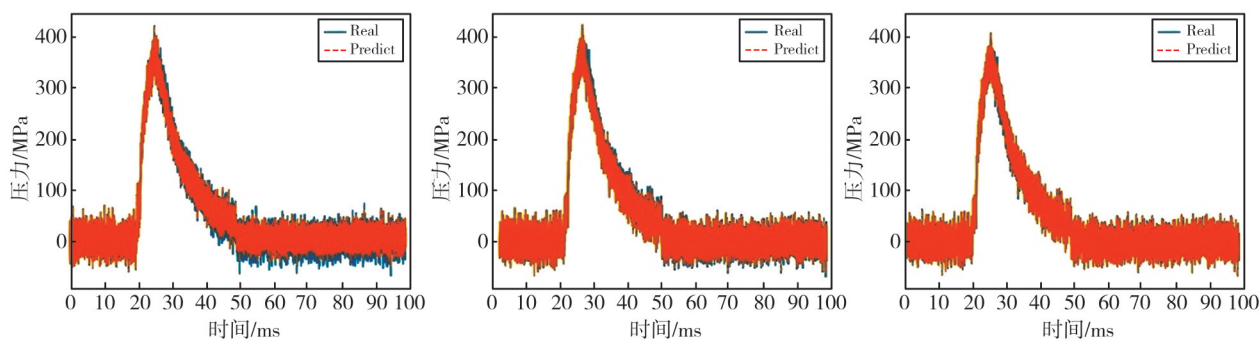
式中: y_i 和 \hat{y}_i 分别为原始数据与模型的预测值; \bar{y}_i 为信号在当前时间点与上一个时间点值的平均值。

2.3 结果与讨论


2.3.1 对比试验

利用 GAIN、GAN-LSTM 以及 KNN 对同组数据进行预测填充缺失值,结果如图 9、图 10 和表 2 所示。


实验过程中,使用训练完成的模型对测试集数据进行测试,并将预测结果与实验结果对比显示,经过本文方法的填充处理,两种含噪模拟信号的重构曲线与原始信号曲线紧密贴合,呈现出高度的一致性。相比之下,传统 GAIN 网络在填充过程中出现了较大的偏差,说明其对复杂时序信号特征和变化规律的捕捉能力有限。利用 GAN-LSTM 网络填充的信号在后半部分出现大量偏移现象,这是因为 GAN 网络在训练时容易出现模式崩溃,导致模型生成的数据缺乏多样性。由于 KNN 算法的复杂度无法满足弹底压力信号在上升沿部分的复杂特征变化,导致填充的信号明显与实际信号特征偏差较大。




(a) 基于LSTM与GAN的时频特征融合填充方法



(b) GAIN



(c) GAN-LSTM



(d) KNN

图9 15 dB含噪模拟信号实验结果

Fig. 9 15 dB noise-containing analog signal experimental results

根据表2中的数据对比,可以观察到本文所提填充方法在信噪比为15 dB时, MSE为 1.56×10^{-5} 、RMSE为0.003 9,拟合优度为0.973 6;信噪比为30 dB时, MSE为 2.50×10^{-5} 、RMSE为0.004 9,拟合优度为0.996 8。

本文方法的MSE及RMSE相比于其他3种方法均达到了最低值,而拟合优度更加接近于1,表明本文方法填充的数据更接近真实数据,拟合效果也更接近完整信号。

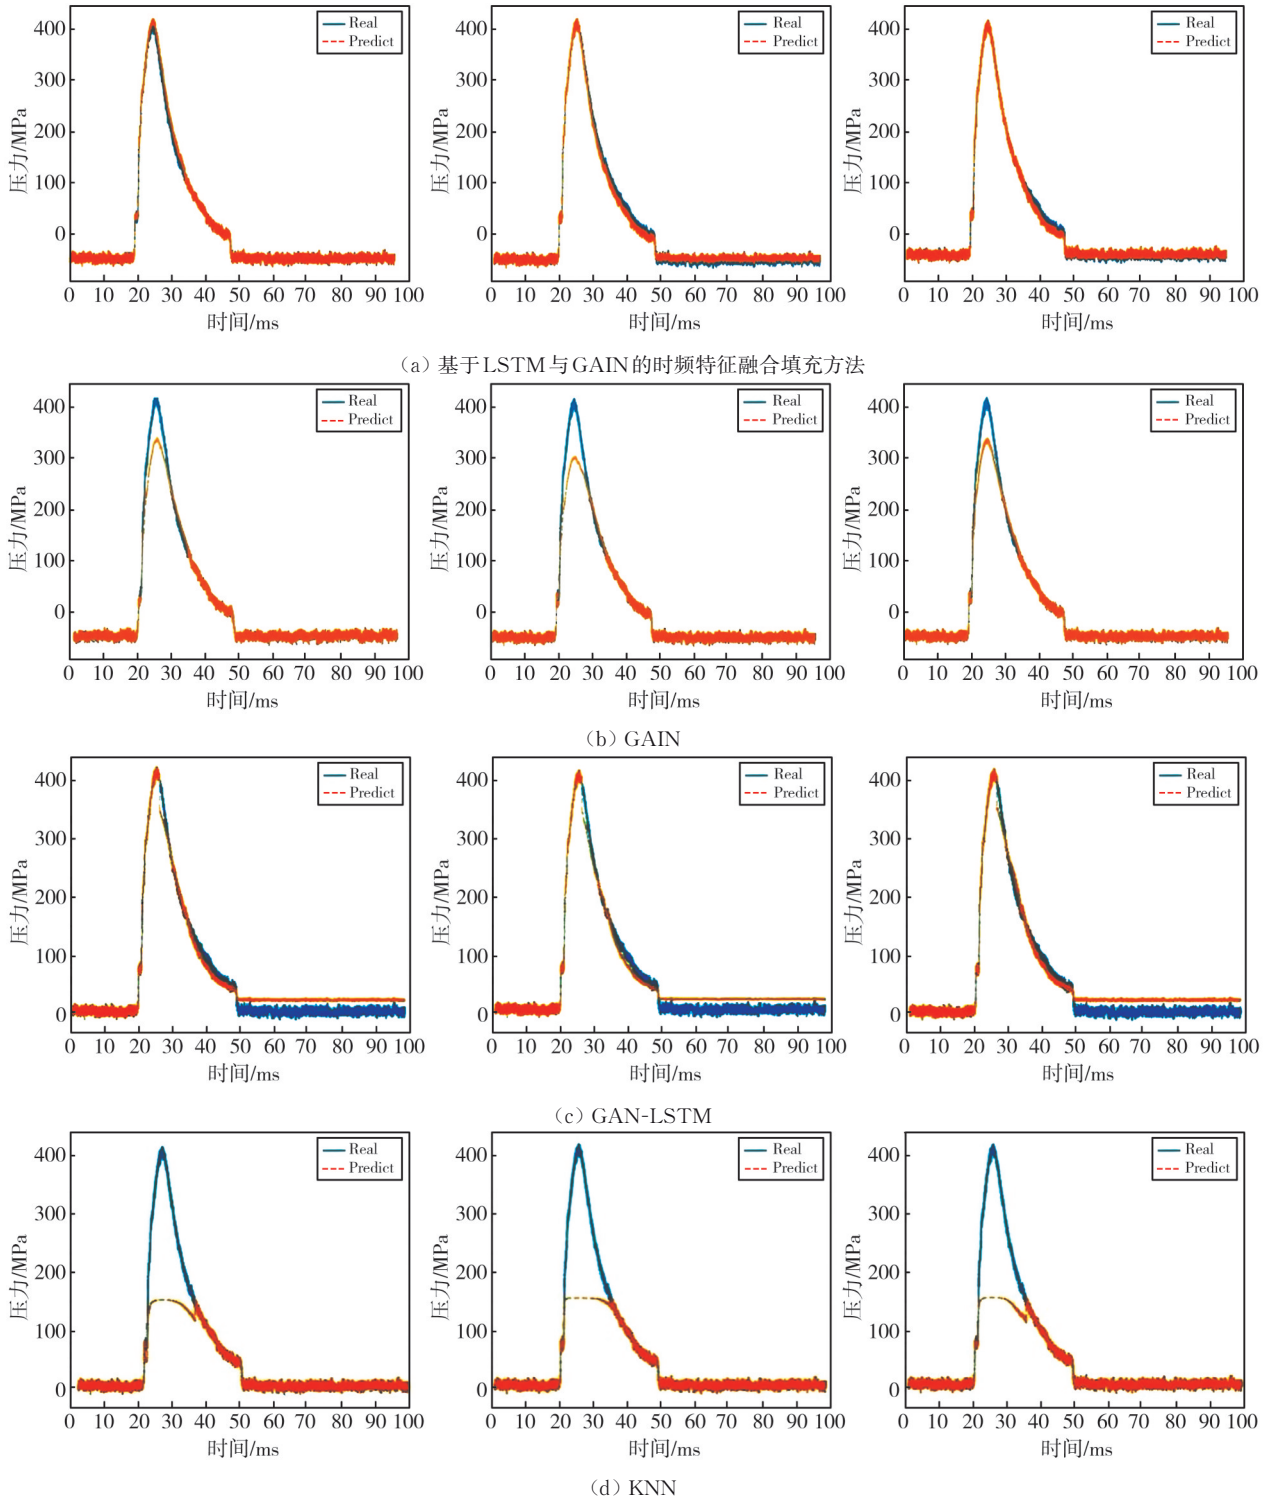


图 10 30 dB 含噪模拟信号实验结果

Fig. 10 30 dB noise-containing analog signal experimental results

2.3.2 消融试验

通过消融实验对本文所提填充方法的每一部分进行有效性验证,实验采用含有 15 dB 信噪比的高斯白噪声弹底压力信号模拟数据进行实验,对时间点 260~990 做缺失处理,实验结果如表 3 所示。

信号填充方法以 GAIN 为网络框架,结合表中数据可以观察到,实验组 1 在 GAIN 网络中加入 LSTM 结构,填充后信号的拟合优度为 0.906 6, RMSE 为 0.014 0,表现良好。实验组 2 在填充网络中加入串并行双分支结构,填充后信号的拟合优度为 0.938 3, RMSE 为 0.010 4,提高了信号拟

合的准确性。实验3为本文提出的填充方法,填充后信号的拟合优度为0.973 6,更加接近于1, RMSE为0.002 36,达到了更精准的预测填充,表明该方法能够更好地填充弹底压力缺失信号。

表 2 试验对比

Tab 2 Experimental comparison data

信噪比	方法	MSE	RMSE	R ²
15 dB	本文方法	1.56×10^{-5}	0.003 9	0.973 6
	GAIN	0.014 2	0.119 2	0.874 5
	GAN-LSTM	0.012 8	0.113 1	0.841 7
	KNN	0.015 1	0.122 8	0.785 4
30 dB	本文方法	2.50×10^{-5}	0.004 9	0.996 8
	GAIN	0.000 3	0.017 3	0.906 5
	GAN-LSTM	0.013 5	0.119 2	0.869 3
	KNN	0.016 4	0.128 1	0.810 1

表 3 消融实验结果对比

Tab. 3 Comparison of ablation experimental results

		1	2	3
填充	LSTM	✓		✓
	串并行双分支		✓	✓
	R ²	0.906 6	0.938 3	0.973 6
	RMSE	0.014 0	0.010 4	2.36×10^{-3}

3 结 论

1) 对由极端测试条件(如高温、高压、强冲击等)以及传感器故障和电路设计缺陷所引发的弹底压力信号缺失问题,本文提出基于LSTM与GAIN的时频特征融合填充方法,引入时频特征融合单元的串并行分支网络,有效改进了GAIN处理时序能力差的问题。

2) 实验结果表明,对含有15 dB信噪比的弹底压力缺失信号进行填充,拟合优度达到0.973 6;对含有30 dB信噪比的弹底压力缺失信号进行填充,拟合优度达到0.996 8,填充完的信号与完整信号高度相似,表明该方法能准确填充缺失信号。

参考文献:

[1] 祖静, 马铁华, 裴东兴, 等. 新概念动态测试[M]. 北京: 国防工业出版社, 2016.

[2] 徐浩, 芮筱亭, 冯宾宾, 等. 基于PVDF压电薄膜的大口径火炮弹底发射装药挤压应力测试方法[J]. 振动与冲击, 2012, 31(22): 20-23.

XU Hao, RUI Xiaoting, FENG Binbin, et al. Measuring method for big area projectile base compression stress of propellant charge based PVDF piezoelectric film[J]. Journal of Vibration and Shock, 2012, 31(22): 20-23. (in Chinese)

[3] 杨会, 沈大伟, 祖静. 弹底压力测试中压力传感器的加速度效应及其校准方法[J]. 传感技术学报, 2011, 24(9): 1256-1259.

YANG Hui, SHEN Dawei, ZU Jing. The acceleration effect and calibration method of pressure sensors in the test of pressure on the bottom of the projectile[J]. Chinese Journal of Sensors and Actuators, 2011, 24(9): 1256-1259. (in Chinese)

[4] 裴东兴, 沈大伟, 张瑜, 等. 弹底压力测试技术研究[J]. 弹箭与制导学报, 2012, 32(5): 196-198.

PEI Dongxing, SHEN Dawei, ZHANG Yu, et al. The research of projectile bottom pressure measuring technology[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2012, 32(5): 196-198. (in Chinese)

[5] 尤文斌, 丁永红, 马铁华, 等. 弹底压力测试技术[J]. 火炮发射与控制学报, 2012, 33(3): 64-67.

YOU Wenbin, DING Yonghong, MA Tiehua, et al. Testing technology of projectile base pressure[J]. Journal of Gun Launch & Control, 2012, 33(3): 64-67. (in Chinese)

[6] WANG H, ZHOU C, WANG H, et al. A novel contact model for rough surfaces using piecewise linear interpolation and its application in gear wear[J]. Wear, 2021, 476: 203685.

[7] NIJMAN S W J, GROENHOF T K J, HOOGLAND J, et al. Real-time imputation of missing predictor values improved the application of prediction models in daily practice[J]. Journal of Clinical Epidemiology, 2021, 134: 22-34.

[8] 陈博, 何幼桦. 缺失数据下滑动平均模型的估计方法[J]. 上海大学学报(自然科学版), 2020, 26(2): 181-188.

CHEN Bo, HE Youhua. Estimation method of moving average model with missing data[J]. Journal of Shanghai University (Natural Science Edition), 2020, 26(2): 181-188. (in Chinese)

[9] YESILBUDAK M, SAGIROGLU S, COLAK I. A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction[J]. Energy Conversion and Management, 2017, 135: 434-444.

[10] YANG D X, KHERA R, CHANG E, et al. Comparison of machine learning approaches for missing data imputation among non-small cell lung cancer patients[J]. International Journal of Radiation Oncology Biology Physics, 2021, 111(3): 115.

[11] CHE Z, PURUSHOTHAM S, CHO K, et al. Recurrent neural networks for multivariate time series with

- missing values [J]. *Scientific Reports*, 2018, 8(1): 6085.
- [12] CAO W, ZHANG H, HE W, et al. Autoencoder in autoencoder network based on low-rank embedding for anomaly detection in hyperspectral images [C]//2022 IEEE International Geoscience and Remote Sensing Symposium, 2022: 3263-3266.
- [13] ZHAO L Y, WANG Z Y, CHEN T X, et al. Missing interpolation model for wind power data based on the improved CEEMDAN method and generative adversarial interpolation network [J]. *Global Energy Interconnection*, 2023, 6(5): 517-529.
- [14] 郭俊行, 李艳利. 某大口径火炮发射弹丸启动压力研究[J]. *弹道学报*, 2022, 34(2): 80-85.
GUO Junhang, LI Yanli. A study on initial pressure of projectile engraving process for large caliber gun [J]. *Journal of Ballistics*, 2022, 34 (2) : 80-85. (in Chinese)
- [15] 周梦笛, 曹从咏, 钱林方. 火炮后效期内弹底压力预估理论模型研究[J]. *兵工学报*, 2019, 40(6): 1304-1309.
ZHOU Mengdi, CAO Congyong, QIAN Linfang. Research on prediction theoretical model of projectile base pressure during aftereffect period [J]. *Acta Armamentarii*, 2019, 40(6): 1304-1309. (in Chinese)
- [16] 于情波, 杨国来, 葛建立, 等. 基于火药燃气压力空间变化的火炮发射动力学研究[J]. *振动与冲击*, 2018, 37(17): 141-147.
YU Qingbo, YANG Guolai, GE Jianli, et al. Artillery firing dynamics based on spatial variation of propellant gases pressure [J]. *Journal of Vibration and Shock*, 2018, 37(17): 141-147. (in Chinese)
- [17] 孙传猛, 陈嘉欣, 原玥, 等. 基于串并行双分支网络的冲击波信号重构方法[J]. *振动与冲击*, 2024, 43(6): 38-49.
SUN Chuanmeng, CHEN Jiaxin, YUAN Yue, et al. Shockwave signal reconstruction method based on a serial-parallel double branch network [J]. *Journal of Vibration and Shock*, 2024, 43 (6) : 38-49. (in Chinese)