

文章编号: 1673-3193(2024)05-0687-08

## 基于深度学习的残缺冲击波信号构建方法

杨洋, 杜红棉, 郭晋杰, 王孺豪

(中北大学 电气与控制工程学院, 山西 太原 030051)

**摘要:** 爆炸冲击波参数是评估弹药威力的主要依据之一, 而在实际测试过程中, 测试系统可能受破片或其他因素影响而导致损坏, 从而无法捕获完整信号, 影响了后续的毁伤评估。本文针对该问题提出了一种基于双向长短时记忆网络(BiLSTM)融合多头自注意力模块的方法对残缺的冲击波信号进行完整性构建, 采用BiLSTM分析了冲击波信号的局部时序依赖关系, 以多头自注意力模块捕捉信号中的频率信息, 最终实现了时序信号与频率信息的融合, 从而得到完整的冲击波信号。在一次信息采集过程中, 所测得的信号数据通常只有数十组, 从而导致了小样本问题, 本文建立了以LSTM单元为生成器的GAN网络, 对完整的冲击波信号进行扩充, 增强了数据集容量。基于扩充数据集的构建实验结果表明, 本文所提方法构建的完整信号与原始信号之间的MSE和MAE分别为0.0068和0.1462, 优于LSTM、BiLSTM、CNN+BiLSTM等方法, 本文所提方法可以满足构建残缺冲击波信号的实际需求。

**关键词:** 信号构建; 冲击波; 深度学习; 双向长短时记忆网络; 多头自注意力

**中图分类号:** O384

**文献标识码:** A

**doi:** 10.3969/j.issn.1673-3193.2024.05.015

**引用格式:** 杨洋, 杜红棉, 郭晋杰, 等. 基于深度学习的残缺冲击波信号构建方法[J]. 中北大学学报(自然科学版), 2024, 45(5): 687-694.

YANG Yang, DU Hongmian, GUO Jinjie, et al. Reconstruction method of incomplete shock wave signals based on deep learning[J]. Journal of North University of China (Natural Science Edition), 2024, 45(5): 687-694.

## Reconstruction Method of Incomplete Shock Wave Signals Based on Deep Learning

YANG Yang, DU Hongmian, GUO Jinjie, WANG Ruhao

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

**Abstract:** The parameters of explosion shock waves are one of the main criteria for evaluating the power of ammunition. However, during the actual testing process, the testing system may be damaged by fragments or other factors, making it unable to capture the complete signal and thus affecting subsequent damage assessment. Therefore, this article proposed a method based on bidirectional long short-term memory network (BiLSTM) and multi head self-attention module fusion to construct the integrity of incomplete shockwave signals. BiLSTM was used to analyze the local temporal dependencies of shockwave signals, and the multi head self-attention module captured frequency information in the signal. Finally, the fusion of temporal signals and frequency information was achieved, resulting in a complete shockwave signal. In the process of information collection, the measured signal data is usually only dozens of sets, which leads

收稿日期: 2023-11-12

作者简介: 杨洋(1998-), 男, 硕士生, 主要从事冲击波测试方面的研究。

通信作者: 杜红棉(1977-), 女, 副教授, 博士, 主要从事冲击波测试方面的研究。E-mail: duhongmian@nuc.edu.cn。

to the problem of small sample size. This article established a GAN network with LSTM units as the generator to expand the complete shock wave signal and enhance the dataset capacity. The experimental results based on the expanded dataset show that the MSE and MAE between the complete signal constructed by the method proposed in this paper and the original signal are 0.006 8 and 0.146 2, respectively, which are superior to the LSTM, BiLSTM, and CNN+BiLSTM methods. The method proposed in this paper meets the practical requirements for constructing incomplete shock wave signals.

**Key words:** signal reconstruction; shock wave; deep learning; bidirectional long short-term memory network; multi head self-attention

## 0 引言

爆炸冲击波超压峰值、正压作用时间和比冲量是弹药毁伤评估的重要指标<sup>[1]</sup>。在弹药爆炸测试试验中,考虑试验成本及场地限制等因素,仅能在固定范围内布置有限数量的测试设备,因此每次试验所测量得到的信号数量较少。同时,由于测试系统易受爆炸碎片击中或高温环境影响,导致信号采集工作终止,会出现所测量冲击波信号缺失的问题,造成了有效数据的减少<sup>[2-3]</sup>。因此,深入研究残缺爆炸冲击波信号构建技术对武器威力评估具有重要意义。

残缺信号的完整性构建的方法主要有3种:1) 压缩感知算法<sup>[4-7]</sup>。采用该算法对残缺信号进行构建时,对信号数据的要求较为苛刻,信号必须具有稀疏特性且需人为选取合适的稀疏矩阵。2) 统计学方法<sup>[8-9]</sup>。该方法虽能将缺失值补充完整,但因缺少对其他维度统计信息的考虑,导致填充效果较差。3) 基于机器学习的方法<sup>[10-12]</sup>。该方法在样本量较多时对数值填充的效果比较明显,但在计算过程中易忽略数据在时间维度上的上下文依赖关系,从而造成填充数据与时序数据的隐含规律不符,导致填充效果较差。深度学习作为机器学习领域的一个重要分支,通过构建和训练深度神经网络,从大量输入数据中提取高级抽象特征,能够有效地进行模式识别和数据分析。尽管深度学习具有强大的特征学习能力,但在处理冲击波信号数据时,将面临小样本导致的特征学习能力受限的问题。

综上所述,本文在构建合适的深度学习算法对残缺冲击波信号进行完整性构建前,需解决模型训练时的小样本问题。目前,关于冲击波超压场重建的方法主要有3种:1) 利用传统的经验公

式法<sup>[13-14]</sup>进行重建,但对于不同的爆炸环境以及炸药类型,先验知识可能会失效;2) 利用插值法<sup>[15-17]</sup>重建的冲击波超压场,其重建精度严重依赖测试点数量;3) 射线追踪法<sup>[18-21]</sup>会受射线路径影响,降低了重建精度。

鉴于上述问题,本文首先构建了一种基于深度学习的冲击波超压场重建方法来解决残缺信号完整性构建所面临的小样本问题,利用深度学习中的生成对抗网络(GAN)对实际测量的冲击波信号进行数据扩充,以测量点与爆炸中心的距离为定向输入数据,以完整冲击波为指定输出数据。其次,构建了一种基于双向长短时记忆网络(BiLSTM)融合多头自注意力模块的神经网络用于实现残缺冲击波信号的完整性构建,该模型以BiLSTM单元学习信号时序特征,并设置多头自注意力机制对信号中的高频细节信息进行提取,消除信号中的噪声影响,最终将不同支路的高阶信息融合生成完整信号。最后,利用所提出的模型完成的扩充数据集对残缺冲击波构建模型展开实验研究,验证所提方法的有效性。

## 1 本文方法

### 1.1 数据扩充模型 GAN

GAN结构<sup>[22]</sup>如图1所示,构建独立的生成器网络G和判别器网络D,在训练过程中两者会不断进行二元极大极小博弈,使生成器生成的数据收敛于真实数据分布,同时完成两个网络的优化。其中,生成器主要以测点与爆炸中心距离作为输入条件完成假的冲击波信号构建,并尽可能提升假信号与真实信号的相似程度,即无限逼近真实信号分布,判别器主要区分真实信号和假信号,同时,判别器的输出结果会优化生成器自身参数,进而可以使生成器生成更加真实的信号。

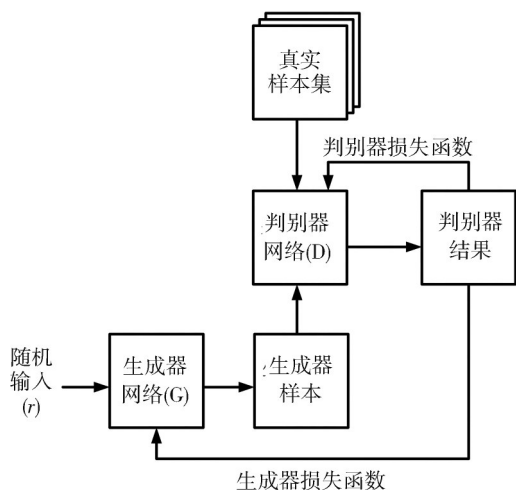


图 1 GAN 结构

Fig. 1 GAN structure

GAN 的损失函数如式(1)所示。判别器的损失计算包括对真实数据和生成器所生成的假数据进行真假判别,而生成器的损失计算包括判别假

数据和真实数据之间的误差。

$$L_{GAN}(G, D) = \min_G \left\{ \max_D \left[ E(\log D(r)) + E(\log(1 - D(G(r)))) \right] \right\} \quad (1)$$

式中:  $r$  为输入数据。

本文采用 LSTM 搭建网络的生成器和判别器, LSTM<sup>[23]</sup> 是基于 RNN 模型改进的循环单元, 其结构如图 2 所示。该网络使用输入门  $i_t$ 、遗忘门  $f_t$  和输出门  $o_t$  以动态方式控制信息串行传递。遗忘门选择上一时刻状态  $c_{t-1}$  的部分信息, 输入门决定当前时刻状态  $c_t$  需要保存的信息, 而输出门则决定当前时刻状态的输出。3 个门的计算公式为

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (2)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (3)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o). \quad (4)$$

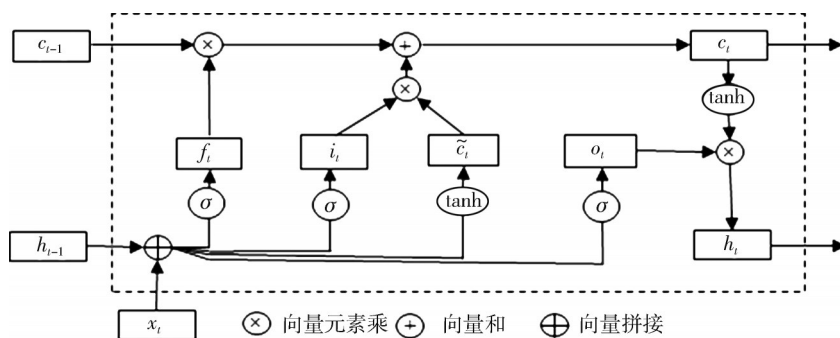


图 2 LSTM 结构

Fig. 2 LSTM structure

LSTM 网络借助循环结构可以捕捉冲击波信号从起始到结束这一较长时序的依赖关系。相比传统 RNN 方法, LSTM 能够解决长序列数据训练过程的梯度消失问题, 进而适用于具有长时间距离的冲击波信号特征的分析。

### 1.2 残缺信号构建模型

对于真实测量的冲击波信号, 一定是由于在连续介质中传播的阶跃扰动所形成的, 理想冲击波信号融合了噪声、介质反射信号等误差因素从而形成了真实的冲击波信号。因此, 对于深度学习模型必定可学习到完整冲击波信号存在的时序特征关系, 进而逐渐抽象与概念化其高阶特征。由于采集系统的采集频率较高, 所收集的信号具有较长时序长度, 如何利用残缺数据的局部特征, 分析数据变化的长时序依赖关系, 构建完整

信号的全局分布, 是目前研究的难点。

冲击波信号可视为融合全局信息与局部特征的数据, 全局信息是由测点位置与爆炸中心点距离所确定的整体分布信息, 而局部信息则指在冲击波传递过程中融合了反射信号或干扰因素所造成的局部突变信息, 因此需同时基于两种信息的关注来构建模型。

#### 1.2.1 BiLSTM 模型

BiLSTM<sup>[24]</sup> 是复制单向 LSTM, 使其具有并排结构, 将输入序列的正向顺序输入第一层, 而将反向顺序输入第二层, 该过程能够克服常规 LSTM 的局限性, 使用时序中过去和未来所有可用信息进行训练, 该结构如图 3 所示。冲击波信号是以时间序列采集得到的信号, 通过从不同方向捕捉信号数据中的前后关联信息, 可提升模型对数据特征分析的有效性, 增强对冲击波信号中

的峰值、上升沿、下降沿等关键信息的提取。




图3 BiLSTM结构

Fig. 3 Bidirectional LSTM structure

### 1.2.2 多头自注意力模块

多头自注意力模块(Multi-head Self-attention)由多个自注意力模块构成,通过并行计算进行融合。自注意力计算采用QKV过程,计算过程如图4所示。




图4 QKV计算过程

Fig. 4 QKV calculation process

QKV矩阵首先采用线性层对输入数据进行映射,分别得到 $Q, K, V$ 矩阵

$$\begin{cases} Q = W^Q X, \\ K = W^K X, \\ V = W^V X, \end{cases} \quad (5)$$

式中: $W^Q, W^K$ 和 $W^V$ 分别为线性映射的参数矩阵。

其次通过矩阵计算获得数据中的重要程度

$$Score = \frac{(Q \cdot K^T)}{\sqrt{d_k}}, \quad (6)$$

式中: $d_k$ 为 $K$ 的维度。

使用缩放点积方法获得最终的输出值

$$Z = Softmax(Score) \cdot V. \quad (7)$$

多头自注意力模块是同时使用多组不同的 $Q, K, V$ 矩阵分别计算各自对应的输出 $Z$ ,并将结果进行融合,如图5所示。通过增加注意力模块的维数,能够对信号中的关键信息进行不同程度的关注,进而增强了对完整信号中细节信息的分析。

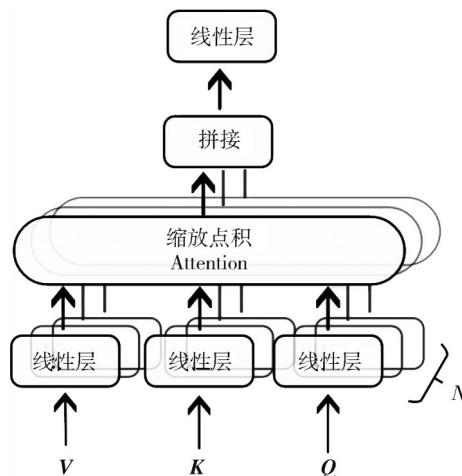


图5 多头自注意力机制

Fig. 5 Multi head self-attention mechanism

### 1.2.3 残缺爆炸冲击波信号构建模型

本文以时序关系构建基于BiLSTM融合多头自注意力模块的构建模型,自动学习信号的特征和频率信息,捕捉信号的长时序依赖关系,构建其具有的频率特征。BiLSTM模型不仅具有串行处理数据的特点,且可以对数据从不同方向同时探究其隐含特征,进而加强了前后数据的关联性,使模型能够适应数据的变化规律。

然而,残缺数据变化复杂,峰值特征多样,单一的BiLSTM难以提取上升沿与峰值点周围的关键特征,因而本文采用多头自注意力机制加强对信号中高频细节信息的学习,将输入信号转换为具有更高层次的特征表示。在自注意力模块中,通过计算输入信号中不同位置之间的相关性,能够生成完整的注意力特征,重新标定特征的重要程度。对于变化较快(高频)的局部数据,该模块自动计算其重要程度,从而赋予更高的权重,从而能够更好地捕捉信号中的动态信息。同时,对于信号中的噪声影响,该模块能够通过降低其权重来减弱噪声干扰,进而突出原始信号的关键局部特征。BiLSTM模块融合多头自注意力模块模型如图6所示。

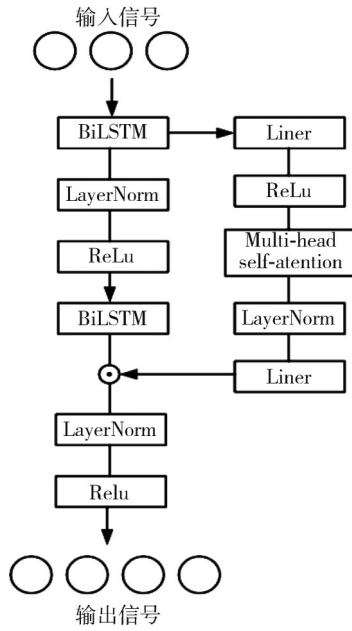


图 6 BiLSTM融合多头自注意力模块

Fig. 6 BiLSTM fusion multi head self-attention module

## 2 实验设置

### 2.1 实验方案

首先, 本文将同一爆炸实验中所测量的真实数据进行整理, 删除不可用信号, 共保留 20 条时序长度为 8 000  $\mu\text{s}$  的信号, 并保存测点与爆炸中心位置距离的信息。首先, 使用 GAN 学习 20 条数据特征, 以距离值为输入, 将数据扩充至 200 条。其次, 将所扩充信号以 8:2 划分为训练集和测试集, 并将所有信号数据拆解成输入数据和对应标签, 输入数据长度为 700  $\mu\text{s}$ , 输出数据长度为 7 300  $\mu\text{s}$ 。根据本文所提残缺冲击波信号构建模型, 利用训练集完成模型对信号特征的学习, 并利用测试集检验模型性能。最后, 将所提模型与 LSTM、BiLSTM 和 CNN-BiLSTM 等方法进行对比, 以验证本文方法的有效性。

### 2.2 实验环境及超参数设置

本文实验的硬件环境: Intel I7-10400H CPU, 16GB 内存, Nvidia RTX 2060 GPU 6GB。软件环境: 操作系统为 64 位的 Window10, 开发环境是 Pycharm 2021, 开发语言为 Python3.6.0 + PyTorch1.8。

在构建实验中, 采用 SGD 优化器, 设置初始学习率为 0.01, 共训练 50 个 Epochs, 分别在第

20 个和第 40 个 Epochs 处将学习率乘以 0.1 的衰减因子。采用均方误差 (MSE) 和平均绝对误差 (MAE) 损失函数监督模型的优化。

### 2.3 评价指标

数据扩充实验中利用输出的完整冲击波信号对原始数据集进行扩充, 因此本文将冲击波信号的超压峰值、正压作用时间、比冲量误差作为数据扩充实验的评价指标。由于残缺信号构建实验中仅补充部分正压区间内数据, 因此以预测数据  $\hat{y}$  和原始数据  $y$  之间的 MSE、MAE 作为构建模型的评价指标。

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|. \quad (9)$$

平均峰值误差 ( $E_p$ ) 用于反映真实信号  $y$  与扩充信号  $\hat{y}$  之间峰值的相对误差均值。

$$E_p = \frac{1}{n} \sum_{i=1}^n \frac{|\max(\hat{y}_i) - \max(y_i)|}{\max(y_i)}. \quad (10)$$

平均正压时间误差 ( $E_T$ ) 用于反映真实信号与扩充信号之间正压时间的相对误差平均值。

$$E_T = \frac{1}{n} \sum_{i=1}^n \left| \frac{(X_{\hat{y}, \text{MAX}} - X_{\hat{y}, \text{MIN}}) - (X_{y, \text{MAX}} - X_{y, \text{MIN}})}{X_{y, \text{MAX}} - X_{y, \text{MIN}}} \right|, \quad (11)$$

式中:  $X_y$  为信号  $y$  的正压区间对应的横坐标;  $X_{\text{MAX}}$  为信号最大值所对应的时间点;  $X_{\text{MIN}}$  为出现最大值后信号首次出现负值的时间点。

平均比冲量误差 ( $E_s$ ) 用于反映真实信号与扩充信号之间比冲量的相对误差平均值。

$$S = \sum_{m=1}^{M-1} \frac{1}{2} (X_m \cdot f(X_m) + X_{m+1} \cdot f(X_{m+1})), \quad (12)$$

$$E_s = \frac{1}{n} \sum_{i=1}^n \left( \frac{S_{\hat{y}_i} - S_{y_i}}{S_{y_i}} \right), \quad (13)$$

式中:  $M$  为冲击波信号正压区间的长度;  $S$  为冲击波信号的比冲量;  $f(\bullet)$  为冲击波信号。

## 3 结果与讨论

### 3.1 扩充数据实验的结果与分析

针对所测量的真实爆炸冲击波信号数据不足所造成的小样本训练问题, 采用 GAN 对信号进行

扩充,以爆炸点与实际测量点之间的输入距离作为随机输入,以真实测量所得冲击波为标签值。设置循环迭代次数为200个Epochs,其结果如图7所示(爆距分别为3.482, 5.105, 6.013 m),图中绿色曲线为原始冲击波信号,蓝色曲线为所生成的扩充冲击波信号。根据2.3节所述评价标准,GAN所扩充信号的平均MSE为0.053, MAE

为0.103,平均峰值误差( $E_P$ )为11.01%,平均正压时间误差( $E_T$ )为12.36%,平均比冲量误差( $E_S$ )为13.83%。结果表明,通过构建基于LSTM的GAN网络,可有效扩充真实测量的冲击波信号数据,一定程度上解决后续对残缺冲击波信号构建的小样本问题。




图7 不同爆距下GAN所生成的扩充数据与真实数据的对比

Fig. 7 Comparison between fake data generated by GAN and real data at different burst distances

### 3.2 残缺冲击波信号构建实验的结果与分析

使用真实的残缺冲击波信号以及GAN扩充所得的混合训练数据对BiLSTM融合多头自注意力模型进行训练,将测试数据输入至训练完成的构建模型中,对残缺信号的后半部分进行构建以期获得完整的超压信号分布。在构建实验中,输入数据包含了原始信号中的峰值特征和部分正压作用区间,这一部分作为关键特征被多头注意力

模块所捕捉,因此能够使模型实现残缺信号的完整性构建。模型最终的实验结果如图8(第一行爆距为3.562 m,第二行爆距为4 m,第三行爆距为5.787 m)和表1所示。可以看出,在相同的实验设置下本文所提方法相对其他方法达到最优,测试数据集的平均MSE为0.006 8,平均MAE为0.146 2。而基于BiLSTM的方法,仅能从不同方向分析数据特征,缺少对关键信息的显著关注,其MSE为0.010 3, MAE为0.198 7。

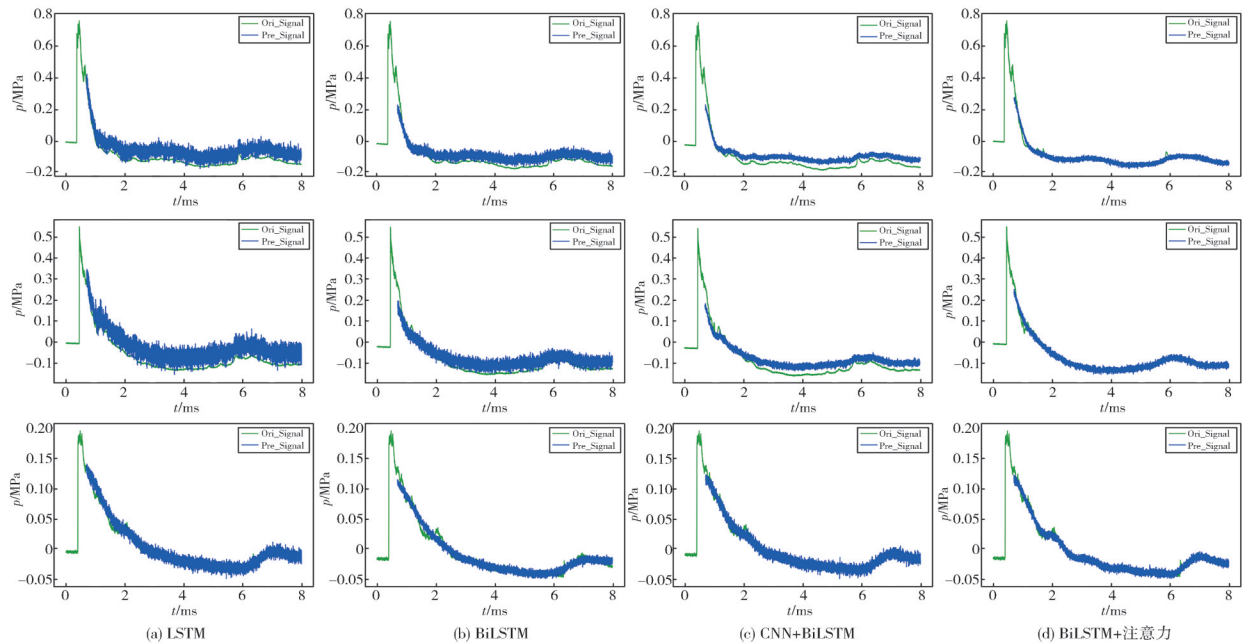


图8 各方法在扩充数据集上的实验结果对比

Fig. 8 Comparative experimental results of different methods on expanded datasets

CNN 结合 BiLSTM 的方法通过引入一维卷积关注局部特征, 其  $MSE$  为 0.009 3,  $MAE$  为 0.175 5。显然引入多头自注意力模块能够分析全局特征, 提取数据中的长距离依赖关系, 实现了最低的构建误差。同时, 相比原始数据集, 构建结果得到显著提升。结果表明通过 GAN 对数据集扩充, 且与原始数据集进行融合, 能够缓解真实采集数据引起的小样本问题, 增强了模型的可学习能力和泛化能力, 扩充模型 GAN 与本文提出的构建模型相结合能够较好地完成对残缺冲击波信号的构建, 满足实际需求。

表 1 残缺冲击波信号构建的实验结果

Tab. 1 Experimental results of reconstruction of incomplete shock wave signals

数据集	模型	$MSE$	$MAE$
扩充数据集	LSTM	0.012 7	0.263 2
	BiLSTM	0.010 3	0.198 7
	CNN+BiLSTM	0.009 3	0.175 5
	BiLSTM+注意力	0.006 8	0.146 2
原始数据集	LSTM	0.099 5	0.423 7
	BiLSTM	0.103 9	0.368 0
	CNN+BiLSTM	0.118 5	0.354 4
	BiLSTM+注意力	0.105 6	0.364 0

## 4 结 论

本文提出了一种基于 BiLSTM 融合多头自注意力机制的残缺冲击波信号构建方法, 通过分析冲击波信号的局部时序依赖关系, 提取残缺信号中的关键特征, 最终融合信息完成对残缺信号的构建。同时, 依靠以 LSTM 单元为生成器的 GAN 网络来解决小样本难题, 通过扩充原始数据集, 提升了模型的泛化能力。最终结果表明, 所提方法能够有效地对残缺部分进行构建, 且相对误差较小, 对实际应用具有重要意义。

### 参考文献:

[ 1 ] 李瑞, 李孝臣, 汪泉, 等. 低温和低压环境下炸药爆炸冲击波的传播特性[J]. 爆炸与冲击, 2023, 43(2): 18-28.  
 LI Rui, LI Xiaochen, WANG Quan, et al. Propagation characteristics of blast wave in diminished ambient temperature and pressure environments[J]. Explosion and Shock Waves, 2023, 43(2): 18-28. (in Chinese)  
 [ 2 ] 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.  
 [ 3 ] 刘慧慧. 战斗部爆炸冲击波超压测试与数据处理技术

研究[D]. 太原: 中北大学, 2019.  
 [ 4 ] 张帅, 杨润海, 高尔根. 基于压缩感知的信号重建方法及在气枪震源信号处理中的应用[J]. 地震工程学报, 2021, 43(2): 322-330.  
 ZHANG Shuai, YANG Runhai, GAO Ergen. Signal reconstruction method based on compressive sensing and its application in signal processing of air-gun sources [J]. China Earthquake Engineering Journal, 2021, 43(2): 322-330. (in Chinese)  
 [ 5 ] 曹春红. 压缩感知信号重建的相关理论及应用研究 [D]. 湘潭: 湘潭大学, 2017.  
 [ 6 ] 蒙彬钧. 基于压缩感知的数字全息聚焦重建方法研究 [D]. 西安: 西安工业大学, 2023.  
 [ 7 ] PENG Y Y, QIAO W, QU L Y. Compressive sensing-based missing-data-tolerant fault detection for remote condition monitoring of wind turbines[J]. IEEE Transactions on Industrial Electronics, 2022, 69(2): 1937-1947.  
 [ 8 ] AMIRI M, JENSEN R. Missing data imputation using fuzzy-rough methods [J]. Neurocomputing, 2016, 205: 152-164.  
 [ 9 ] PURWAR A, SINGH S K. Hybrid prediction model with missing value imputation for medical data [J]. Expert Systems with Applications, 2015, 42(13): 5621-5631.  
 [10] 冯宪凯, 黄树成. 基于 DBSCAN 的缺失值填充算法研究[J]. 计算机与数字工程, 2020, 48(7): 1572-1575.  
 FENG Xiankai, HUANG Shucheng. Research on missing value filling algorithm based on DBSCAN[J]. Computer and Digital Engineering, 2020, 48(7): 1572-1575. (in Chinese)  
 [11] HIRON K, TEMPM M, FIZMOSER P. Imputation of missing values for compositional data using classical and robust methods [J]. Computational Statistics & Data Analysis, 2010, 54(12): 3095-3107.  
 [12] HAN H, KIM B, KIM K, et al. Machine learning approach for the estimation of missing precipitation data: A case study of South Korea[J]. Water Science and Technology, 2023, 88(3): 556-571.  
 [13] 李翼祺, 马素贞. 爆炸力学[M]. 北京: 科学出版社, 1992.  
 [14] YANG F, XU L X, ZHAI H B, et al. Numerical simulations of air shock wave overpressure propagation in shallow-buried explosion [J]. Journal of Physics: Conference Series, 2023, 2470(1): 012022.  
 [15] 杨志, 张志杰, 夏永乐. 基于 B 样条插值拟合的冲击波超压场重建[J]. 科学技术与工程, 2016, 16(7):

- 236-240.
- YANG Zhi, ZHANG Zhijie, XIA Yongle. Reconstruction of shock wave overpressure field based on B-spline interpolation[J]. *Science Technology and Engineering*, 2016, 16(7): 236-240. (in Chinese)
- [16] 赵化彬, 张志杰. 基于非均匀有理B样条“蛛网”插值的冲击波压力场重建方法[J]. *科学技术与工程*, 2017, 17(18): 258-264.
- ZHAO Huabin, ZHANG Zhijie. SReconstruction method of blast wave pressure field based non-uniform rational B-splines “cobweb” interpolation[J]. *Science Technology and Engineering*, 2017, 17(18): 258-264. (in Chinese)
- [17] GENG W, CAI L, LIU D M, et al. Seismic data interpolation beyond continuous missing data using high-order streaming prediction filter[J]. *Acta Geophysica Sinica*, 2023, 66(3): 1220 - 1231.
- [18] 郭亚丽, 韩焱, 王黎明. 基于广义逆算法的冲击波超压场重建方法[J]. *爆炸与冲击*, 2014, 34(6): 764-768.
- GUO Yali, HAN Yan, WANG Liming. Overpressure reconstruction of shock wave based on generalized inverse theory [J]. *Explosion and Shock Waves*, 2014, 34(6): 764-768. (in Chinese)
- [19] 李同宇, 张建中. 地震射线追踪的线性走时扰动插值法[J]. *石油地球物理勘探*, 2018, 53(6): 1165-1174.
- LI Tongyu, ZHANG Jianzhong. A linear travelttime perturbation interpolation method for seismic ray tracing [J]. *Oil Geophysical Prospecting*, 2018, 53(6): 1165-1174. (in Chinese)
- [20] 尧礼辉. 广义逆矩阵计算及在矩阵方程中应用的研究[D]. 郑州: 解放军信息工程大学, 2008.
- [21] WANG H, CHEN Y F, OBOUÉ Y A S I, et al. Simultaneous reconstruction and denoising of extremely sparse 5-D seismic data by a simple and effective method [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5909212.
- [22] 任晓琪. 基于自适应上下文生成对抗网络模型的RSS缺失值预测的方法[D]. 天津: 天津大学, 2019.
- [23] 张琴琴, 刘文强, 陈之鸿, 等. 基于LSTM-SVM模型的河流流量预测[J]. *天津师范大学学报(自然科学版)*, 2023, 43(6): 45-52.
- ZHANG Qinqin, LIU Wenqiang, CHEN Zhihong, et al. Forecasting of river flow based on LSTM-SVM model[J]. *Journal of Tianjin Normal University(Natural Science Edition)*, 2023, 43(6): 45-52. (in Chinese)
- [24] 章志晃, 徐启峰, 林穿. 基于SSA-BiLSTM-AM的短期风电功率预测[J]. *国外电子测量技术*, 2023, 42(3): 46-51.
- ZHANG Zhihuang, XU Qifeng, LIN Chuan. Short-term wind power prediction based on SSA-BiLSTM-AM [J]. *Foreign Electronic Measurement Technology*, 2023, 42(3): 46-51. (in Chinese)