

DOI: 10.19650/j.cnki.cjsi.J2412420

基于辅助传感器阵列与 NECNN-BiLSTM 深度神经网络的磁场信号去噪方法研究*

胡书正¹, 王骁贤², 宋俊材³, 陆思良¹

(1. 安徽大学电气工程与自动化学院 合肥 230601; 2. 安徽大学电子信息工程学院 合肥 230601;
3. 安徽大学互联网学院 合肥 230601)

摘要:针对强噪声干扰下磁场信号精准去噪难题,提出一种结合中心-卫星架构辅助传感器阵列和深度噪声重建网络的磁场信号去噪新方法。首先,搭建磁场传感器阵列,通过有限元分析进行传感器阵列位置优化,分析中心和卫星传感器信号之间的信号特征。随后,构造一种结合噪声增强卷积神经网络(NECNN)和双向长短期记忆网络(BiLSTM)的深度神经网络模型,利用传感器阵列捕获的噪声信号对构造的网络模型进行训练,揭示中心传感器信号和卫星传感器信号之间的非线性映射关系。最后,在磁场检测过程中,利用卫星传感器阵列噪声重建出中心传感器的噪声分量,再将中心传感器捕获的含噪信号减去重建噪声,得到去噪后的待检测磁场信号。实验结果表明,本文提出方法在磁场去噪的最大误差与均方根误差指标上均优于常规方法,为磁场强干扰下信号动态去噪提供一种新手段,有望应用于电流检测、磁场成像、电池质量检测等领域。

关键词: 磁场传感器阵列; 磁场信号去噪; 噪声重建; 深度神经网络

中图分类号: TH7 **文献标识码:** A **国家标准学科分类代码:** 460

Magnetic field signal denoising based on auxiliary sensor array and NECNN-BiLSTM deep neural networks

Hu Shuzheng¹, Wang Xiaoxian², Song Juncai³, Lu Siliang¹

(1. College of Electrical Engineering and Automation, Anhui University, Hefei 230601, China; 2. College of Electronics and Information Engineering, Anhui University, Hefei 230601, China; 3. College of Internet, Anhui University, Hefei 230601, China)

Abstract: Aiming at the problem of accurate denoising of magnetic field signals under strong noise interference, a new method of denoising magnetic field signals combining the auxiliary sensor array of center-satellite architecture and the deep noise reconstruction network is proposed. First, the magnetic field sensor array is built, and finite element analysis is used to optimize the sensor array positions and analyze the signal characteristics between the center and satellite sensors. Subsequently, a deep neural network model combining noise-enhanced convolutional neural network (NECNN) and bi-directional long short-term memory (BiLSTM) is constructed. The model is trained using the noise signals captured by the sensor array to reveal the nonlinear mapping relationship between the center sensor signal and the satellite sensor signal. Finally, in the magnetic field detection process, the noise components of the center sensor are reconstructed using the noise of the satellite sensor array. The denoised magnetic field signal is obtained by subtracting the reconstructed noise from the noisy signal captured by the center sensor. The experimental results show that the proposed method outperforms the conventional method in terms of the maximum error and the root mean square error index of magnetic field denoising. This new approach provides a new means of dynamic denoising of signals under strong magnetic field interference, and is expected to be applied in the fields of current detection, magnetic field imaging, and battery quality detection.

Keywords: magnetic sensor array; magnetic signal denoising; noise reconstruction; deep neural network

0 引 言

磁场信号检测在机器和设备关键部件的质量检测、诊断和预测中起着重要作用^[1-5]。影响磁场测量精度的最主要因素是背景噪声干扰,如地磁场的干扰强度很大,在实际磁场测量中不可忽略^[6]。对于生产线上的目标设备磁场检测,电气和机械设备的磁场干扰更为显著,因此如何实现强干扰下的快速精确信号去噪是磁场测量的关键。

磁场信号去噪主要通过物理磁场屏蔽和背景噪声相消实现。对于物理磁场屏蔽方法,文献[7]提出一种磁共振成像技术,用于评估可充电锂离子电池的状态。该方法通过测量电池周围微小感应磁场和永久磁场的变化来实现。为了降低测试过程中的环境噪声干扰,电池被置于一个电磁屏蔽桶内。对于背景噪声消除方法,文献[8]设计了一个磁传感器阵列,用于对电池电流分布进行磁场空间高分辨测量。在测试过程中,通过将磁传感器的输出减去地磁场输出的方法,有效降低了背景噪声干扰。

除了前述两种广泛应用的磁场信号去噪方法之外,近年来随着深度学习的迅猛发展,一些学者已经探索了基于深度神经网络的信号去噪方法。文献[9]设计了一种用于磁共振图像去噪的卷积神经网络(convolutional neural network, CNN)。该网络采用了编码器-解码器结构,以确保在去除噪音的同时保留图像的显著特征,有效过滤掉不必要的细节。文献[10]构建了两个基于长短时记忆网络(long short-term memory network, LSTM)的循环神经网络,对大地电磁时域信号进行特征噪声的识别和提取,进而重构出去噪后的大地电磁信号。文献[11]为了解决冲击噪声下 LSTM 网络调制信号识别方法抗冲击噪声能力弱等问题,结合 CNN 去噪模型和演化 LSTM 模型提高信号识别的抗噪能力。文献[12]提出了一种基于神经网络的激光雷达信号去噪算法。该算法在 CNN 网络基础上融合了残差学习、注意力机制等方法,对噪声进行预测,实现了信号和噪声的有效分离。文献[13]为了解决天然电磁场源信号检测时易受电磁干扰的问题,提出了一种基于 LSTM 网络的大地电磁工频干扰压制方法。该方法通过神经网络学习含工频噪声信号与工频噪声之间的映射关系,重构含工频噪声信号中淹没的工频噪声分量,从而得到去噪后的真实信号。文献[14]针对磁场测量信号中存在的随机噪声信号,提出了一种基于 CEEMDAN 阈值滤波的算法。该方法采用小波软阈值方式提取含噪声分量信号中的有用信号,进行信号重构,对磁场信号进行有效去噪。

在上述提到的磁信号去噪方法中,使用物理屏蔽工具如屏蔽桶能够实现较好的去噪效果^[15-16],但其操作复


杂且设备昂贵。背景噪声相消更易操作^[17-18],但是只能在一定程度上确保精度。此外,目前的研究主要集中在相对理想和稳定的磁干扰环境下,对于实际复杂工况中的强干扰和高瞬态噪声的消除仍然是一个具有难度和挑战性的问题。

基于以上原因,本文提出了一种基于辅助传感器阵列和噪声增强卷积神经网络(noise-enhanced convolutional neural network, NECNN)、双向长短期记忆网络(bi-directional long short-term memory, BiLSTM)动态集成的深度噪声重建网络(NECNN-BiLSTM)的磁场信号去噪新方法。本文方法的具体实现如下:1)根据磁干扰噪声在空间中传播时不同位置的映射关系,设计辅助传感器阵列及其传感器信号采集电路;2)搭建磁信号去噪实验平台捕获各传感器处的噪声并进行信号分析,讨论分析磁场信号在中心与卫星传感器之间的相关性;3)引入 NECNN-BiLSTM 网络,将采集的卫星传感器磁场噪声作为所建立网络模型的输入,中心传感器磁场噪声作为输出,学习中心和卫星传感器之间的映射关系,利用重构噪声信号净化中心传感器的磁信号,实现强干扰下磁场信号精准去噪。

该方法为强磁场干扰下的电流信号检测易受干扰、磁场成像质量不稳定以及电池状态难以准确判断^[19]等问题提供了一种新的解决思路。

1 基于辅助传感器阵列与 NECNN-BiLSTM 网络的磁场信号去噪方法

为了实现磁场噪声重构和信号去噪,本文设计了一个基于辅助磁传感器阵列和相应的深度学习模型的系统。该系统首先在纯噪声干扰下通过中心-卫星式传感器阵列检测卫星与中心传感器处的磁场噪声,并将该信号输入到深度学习模型里去学习中心与卫星传感器之间噪声的映射关系,经过多轮训练,保存该训练好的模型,紧接着在信号与噪声同时存在的情况下,将各传感器检测到的数据输入到训练好的模型里,得到重构的噪声分量,最终利用加性噪声原理消去中心传感器的磁场噪声信号,得到理想纯净信号。该系统示意图如图 1 所示。






图 1 噪声重构与信号去噪示意图

Fig. 1 Noise reconstruction and signal denoising schematic

1.1 辅助传感器阵列设计

鉴于磁场信号在空间中传播,中心传感器与卫星传感器检测到的磁场信号具有相关性。本文设计的中心-卫星式传感器阵列,由隧道磁阻(tunneling magnetoresistance, TMR)传感器组成,其中待测磁信号由中心传感器下的通电直流导线产生,该导线仅在此传感器下裸露部分导线段,其余部分均用磁场屏蔽胶带包裹。

该传感器阵列示意图如图 2 所示。




图 2 卫星传感器阵列示意图

Fig. 2 Schematic of the satellite sensor array

1.2 NECNN-BiLSTM 网络深度学习模型搭建

本文采用的 NECNN-BiLSTM 网络由两个神经网络模块构成,其中噪声增强 CNN 模块通过向卷积神经网络注入条件噪声形成,数据集依次通过该模块及其后续的双向长短期记忆网络模块,最终输出目标预测值。本文的网络模型结构如图 3 所示。




图 3 NECNN-BiLSTM 网络示意图

Fig. 3 NECNN-BiLSTM network schematic

卷积神经网络利用卷积运算来提取局部特征,同时通过权值共享和池化等操作来减少参数数量和计算量,可以更好地提取数据的内部特征,减少网络的层间连接和过拟合的风险^[20]。条件噪声注入已经应用于 CNN 来增益其分类精度,本文使用的噪声增强 CNN 模块是通过向 CNN 中注入条件高斯噪声来提高 CNN 泛化能力和分类精度^[21],所注入的条件高斯噪声公式如式(1)所示。

$$n_{i,\theta} = \frac{1}{\lambda \sqrt{2\pi}} e^{-\frac{\omega_{i,\theta}^2}{2\lambda^2}} \quad (1)$$

式中: $\omega_{i,\theta}$ 为第 i 个神经元上的输入值, $n_{i,\theta}$ 为第 i 个神经元上添加的噪声, λ 为噪声参数,在本模型中将其设置为 0.8。

BiLSTM 由两个相反连接的 LSTM 组成,正向 LSTM 获取序列数据之前的信息,反向 LSTM 将数据反向,隐藏层合成前向和反向信息,以通过使用过去和未来的状态来增加网络的可用信息,负责对提取的特征进行预测。因此,BiLSTM 可以有效地增强网络的上下文理解能力,捕捉更长距离的依赖关系,提高序列建模的性能。两个相反连接的 LSTM 层主要由遗忘门、记忆门和输出门 3 部分组成^[22-23],如图 4 所示。

在 LSTM 层中,遗忘门的数学表达如式(2)所示。

$$S_t = \delta(W_s \cdot [H_{t-1}, x_t] + a_s) \quad (2)$$

式中: x_t 和 H_{t-1} 分别表示时刻 t 的输入和时刻 $t-1$ 的隐态, δ, W_s, a_s 分别表示遗忘门的激活函数、权重矩阵和偏置矩阵, S_t 表示取值范围是 0~1 的遗忘程度。




图4 LSTM层结构示意图

Fig. 4 Schematic diagram of LSTM layer structure

记忆门的数学表达如式(3)、(4)所示。式中, P_t 和 Z_t^0 分别表示 t 时刻的输出状态和暂存状态, W_p, a_p 和 W_z, a_z 分别是与之对应的权重矩阵和偏置矩阵。遗忘门和记忆门决定了当前神经网络层的状态信息, 数学表达如式(5)所示。

$$P_t = \delta(W_p \cdot [H_{t-1}, x_t] + a_p) \quad (3)$$

$$Z_t^0 = \tanh(W_z \cdot [H_{t-1}, x_t] + a_z) \quad (4)$$

$$Z_t = S_t * Z_{t-1} + P_t * Z_t^0 \quad (5)$$

输出门的数学表达如式(6)、(7)所示。式中, O_t 和 H_t 分别表示时刻 t 的输出和隐态, W_o, a_o 分别表示输出门的权重矩阵和偏置矩阵。

$$O_t = \delta(W_o \cdot [H_{t-1}, x_t] + a_o) \quad (6)$$

$$H_t = O_t * \tanh(Z_t) \quad (7)$$

2 实验装置设计与传感器布局优化

2.1 实验装置设计

为验证所提方法的可行性, 本文搭建了基于 TMR 传感器辅助阵列的磁场噪声去噪实验平台, 如图 5 所示。平台由以下部分组成: 可编程直流电源 DP800、数控直流电源 SPE3102、包含磁传感器的中心与卫星传感器模块、与限流电阻相连的导线、NI USB-6289 数据采集卡、计算机等。其中磁传感器选用的型号为 TMR2003, 传感器的灵敏度为 6 mV/GS , 线性量程为 $\pm 35 \text{ GS}$, 具有高灵敏度、宽动态范围、低功耗等优点。

中心传感器位于非磁性底座的中央, 各卫星传感器模块按照仿真所得最优布局分布在中心传感器周围, 均采用 TMR 传感器获取信号。考虑到 TMR 传感器检测信号与磁场方向有关, 各卫星传感器模块均包含两个垂直布置的 TMR 传感器用于采集磁场噪声的有效信息, 其中位于卫星传感器模块 1 处的是卫星传感器 1、5, 位于卫星传感器模块 2 处的是卫星传感器 2、6, 位于卫星传感器模块 3 处的是卫星传感器 3、7, 位于卫星传感器模块 4 处的




图5 基于辅助传感器阵列的磁场噪声去噪实验平台

Fig. 5 Experimental platform for magnetic noise denoising based on auxiliary sensor array

是卫星传感器 4、8。

此外, 在设计卫星传感器阵列采集电路时, 中心和卫星传感器采用图 6 所示的相同的电路模块。




图6 传感器采集电路示意图

Fig. 6 Schematic diagram of sensor acquisition circuit

该模块包括 1 个 TMR 磁传感器 (TMR2003)、1 个仪表放大器 (AD620)、1 个运算放大器 (LM741) 和 4 个电阻。电阻网络用于消除运放电路的零漂。满量程 $10 \text{ k}\Omega$ 的电阻 R_3 被调节至 AD620 的输出电压为零。消除零漂后, TMR 差分输出电压信号由 AD620 放大, 然后由数据采集系统 (NI) 采样。AD620 的增益计算公式如下:

$$G_A = \frac{49.4 \text{ k}\Omega}{R_A} + 1 \quad (8)$$

其中, 为 R_A 外部电阻, 在本采集电路中为 $1 \text{ k}\Omega$, 则得到放大器的增益 $G_A = 50.4$ 。

实验所设置的磁场噪声由位于卫星传感器模块 1 处的磁铁随机扰动产生,所设置的磁信号由位于中心传感器下的通电直流导线产生,导线内的电流由可编程电源提供,根据毕奥-萨伐尔定律得到可测磁信号^[24],如式(9)所示:

$$B = \frac{\mu_0 I_T}{2\pi r_T}$$

(9)

其中, μ_0 为真空磁导率, $\mu_0 = 4\pi \times 10^{-7} \text{ N/A}^2$, I_T 为通电直流导线内的电流, r_T 为实验中通电直流导线到中心传感器的距离,在本文实验中, r_T 设置为 18 mm。

2.2 传感器位置优化

为了确定磁噪声干扰下各卫星传感器的最优测量位置,考虑到实际传感器采集模块的尺寸,将实验中用以布置辅助传感器阵列的非磁性底座均匀划分网格并建立如图 2 所示的坐标系,中心传感器在该坐标系中的位置坐标为(4,4)。有限元仿真具有计算精度高、建模速度快等优点,本文采用计算机软件 ANSYS Maxwell 进行仿真计算,拟采取与中心传感器处磁场信号最相似的检测点来设计辅助传感器阵列,有限元仿真结果如图 7 所示,中心传感器所在位置为仿真模型的坐标原点,选取该处仿真信号作为中心传感器信号。本文根据图 2 所建立的坐标系确定位置坐标,考虑到实际实验时通电直流导线处不能放置卫星传感器,将 7×6 个测量位置的仿真信号作为卫星传感器信号并进行数据筛选。




图 7 磁噪声干扰下仿真结果示意图

Fig. 7 Schematic of simulation results under magnetic noise interference

弗朗明歇距离(Fréchet distance, Fd)^[25]和余弦相似度(cosine similarity, cos)^[26]广泛应用于计算一维信号之间的相似度,本文引入这两种方法对中心传感器信号和卫星传感器信号进行一维曲线相似度匹配,并采用模糊综合评价法(fuzzy comprehensive evaluation, FCE)选取匹配度最高的 4 个测量点,作为各卫星传感器的最佳测量位置,其计算结果如表 1 所示。

表 1 中心传感器信号与卫星传感器信号相似度匹配
Table 1 Similarity matching of center sensor signals to satellite sensor signals

序号	(x,y)	cos	Fd (GS)	FCE
1	(1,7)	0.572 0	79.291 3	0.809 2
2	(1,6)	0.841 8	81.554 9	0.727 4
3	(1,5)	0.985 2	73.871 3	0.607 4
4	(1,3)	0.861 2	29.881 7	0.274 6
5	(1,2)	0.392 7	15.033 0	0.322 5
6	(1,1)	0.562 5	18.646 5	0.289 9
7	(2,7)	0.608 9	35.864 0	0.420 9
8	(2,6)	0.840 9	34.873 1	0.325 3
9	(2,5)	0.973 1	30.430 8	0.237 3
10	(2,3)	0.902 2	12.386 3	0.108 4
11	(2,2)	0.482 7	9.484 3	0.240 9
12	(2,1)	0.378 3	13.907 5	0.318 2
13	(3,7)	0.618 4	17.438 0	0.258 5
14	(3,6)	0.828 9	15.107 0	0.159 4
15	(3,5)	0.960 1	11.668 3	0.080 5
16	(3,3)	0.913 3	4.350 0	0.034 9
17	(3,2)	0.472 5	7.404 6	0.226 7
18	(3,1)	0.285 2	11.354 3	0.331 1
19	(4,7)	0.611 0	9.423 5	0.192 2
20	(4,6)	0.809 0	6.733 9	0.094 6
21	(4,5)	0.946 3	3.562 4	0.015 7
22	(4,3)	0.901 4	3.725 4	0.034 0
23	(4,2)	0.402 9	7.190 2	0.251 0
24	(4,1)	0.251 3	9.941 6	0.331 7
25	(5,7)	0.595 5	6.668 2	0.174 2
26	(5,6)	0.784 3	4.834 6	0.087 5
27	(5,5)	0.931 8	3.430 0	0.020 0
28	(5,3)	0.867 2	5.423 0	0.061 4
29	(5,2)	0.302 1	7.430 1	0.290 9
30	(5,1)	0.247 0	9.125 8	0.326 2
31	(6,7)	0.577 6	6.371 9	0.178 4
32	(6,6)	0.757 8	5.603 3	0.104 1
33	(6,5)	0.917 0	5.278 2	0.041 5
34	(6,3)	0.810 3	6.543 3	0.092 5
35	(6,2)	0.198 2	7.635 8	0.331 7
36	(6,1)	0.255 0	8.612 5	0.318 8
37	(7,7)	0.561 7	6.774 8	0.187 8
38	(7,6)	0.733 9	6.512 1	0.120 9
39	(7,5)	0.903 1	6.468 7	0.057 0
40	(7,3)	0.741 7	7.173 9	0.123 7
41	(7,2)	0.115 8	7.737 3	0.363 5
42	(7,1)	0.264 5	8.255 1	0.312 1

$\cos$ 越大则两一维信号相似度越高; F_d 越小则两一维信号相似度越高; FCE 越小则该选择越好。

在表 1 中,第 16、21、22、27 组中心传感器信号与卫星传感器信号的 FCE 评判指标分别为 0.034 9、0.015 7、0.034 0、0.020 0,为 42 组测量位置中的 4 个最优选择。因此选取该 4 处检测点作为卫星传感器最佳测量位置,将该 4 处坐标作为卫星传感器阵列的安装位置,将该最优布局下的各卫星传感器采集到的信号作为 NECNN-BiLSTM 网络的输入,中心传感器采集到的信号作为 NECNN-BiLSTM 网络的输出。

3 方法有效性验证

为了验证本文方法的有效性,开展的实验过程如下:1)给采集电路供电,在无激励无磁场噪声干扰情况下通过调节采集电路模块的可调电阻进行调零操作,消除零漂;2)无激励有干扰阶段,停止可编程电源对于直流导线的电流输入,在卫星传感器模块 1、4 处用磁铁扰动,传感器阵列检测到磁场噪声,经由 NI USB-6289 数据采集卡(采集频率为 10 kHz)进行数据采集并发送至计算机,获得无激励有干扰情况下各传感器处的磁场噪声数据;3)有激励有干扰阶段,利用可编程电源向直流导线输入频率为 0.5 Hz,幅值为 3 A 的矩形电流,同时在卫星传感器模块 1、4 处仍用磁铁扰动,获得有激励有干扰情况下的卫星传感器处磁场噪声数据和中心传感器处含噪磁信号数据;4)将采集到的无激励有干扰数据中的卫星传感器处的数据作为输入,中心传感器处数据作为输出,通过 NECNN-BiLSTM 网络学习磁场噪声在中心与卫星传感器间的映射关系,保存训练好的模型参数,将有激励有干扰数据集输入该训练好的网络进行磁场噪声重建。

3.1 无电流激励条件下磁场传感器噪声特征分析

在获取训练数据集时,关闭可编程电源,不向导线注入电流,此时该导线不产生磁场,仅提供磁场噪声干扰,由采集卡获取的各传感器数据经中值滤波除去脉冲噪声后的磁场噪声波形如图 8 所示。

用作磁干扰的扰动磁铁对各传感器采集到的信号影响很大,特别地由于人为给定的磁场噪声干扰靠近卫星传感器模块 1、4,位于这两处的卫星传感器 1 与卫星传感器 8 检测到的磁场噪声的幅值波动较大,其中卫星传感器 1 处信号幅值达到 3 GS 左右,卫星传感器 8 处的磁场噪声信号幅值波动达到 8 GS 左右,而相对远离干扰源的卫星传感器模块 2 和 3 处的检测到的磁场噪声幅值波动较小,这两处信号幅值波动最小值为 1 GS。

因为磁信号在空间中传播,各传感器检测到的信号应存在某种映射关系。本文通过有限元仿真与一维信号相似度匹配来确定各传感器的最佳位置,捕获各




图 8 无激励有干扰训练集:中心传感器信号与卫星传感器 1~8 处信号

Fig. 8 Training set without incentives and with interference: center sensor signals and satellite sensors at 1~8

传感器之间的映射关系。从图 8 中可以看出,实验所采集到的无电流激励条件下各卫星传感器处的磁场噪声信号与中心传感器处的磁场噪声信号之间存在某种联系,例如中心传感器处磁场噪声的幅值与相位波动与各卫星传感器信号变化均存在相似性,其中卫星传感器 1、8 处磁场噪声与中心传感器处磁场噪声的幅值与相位波动的相似性更为明显,这表明了利用一维信号相似度匹配来确定各传感器最佳位置方法的有效性,也使得利用深度学习学习中心与卫星传感器处磁场噪声间的映射关系,对中心传感器处的磁场噪声进行预测和重构成为可能。

3.2 NECNN-BiLSTM 模型训练

为了验证本文所提出方法的有效性,将实验所得无激励有干扰训练集输入所提出的 NECNN-BiLSTM 网络,用以学习中心信号与各卫星信号之间的映射关系,模型的训练平台配置如下:CPU i9-10900F, GPU RTX 3060, 操作系统为 WIN 10 64 位,模型框架为 PyTorch。NECNN-BiLSTM 模型的参数配置如表 2 所示。该模型的训练过程如图 9 所示。

表 2 NECNN-BiLSTM 模型参数

Table 2 NECNN-BiLSTM model parameters

层序号	层类别	层参数
1	输入层	维度 200×7×8
2	卷积层	输入通道数为 8 输出通道数为 32 卷积核大小为 3
3	最大池化层	核大小为 3,步长为 1
4	卷积层	输入通道数为 32 输出通道数为 32 卷积核大小为 1
5	最大池化层	核大小为 1,步长为 1
6	全连接层	输入特征数为 32 输出特征数为 32
7	噪声注入层	噪声参数 λ 的值为 0.8
8	BiLSTM 层	输入特征数为 32 隐含层特征数为 32 LSTM 层的层数为 2
9	输出层	输入特征数为 64 输出特征数为 1




图 9 NECNN-BiLSTM 模型训练过程

Fig. 9 Diagram of NECNN-BiLSTM model training process

NECNN-BiLSTM 模型的损失函数值和均方根误差 $RMSE$ (root mean square error) 值随着迭代次数的增加而减小。这两个指标在大约 30 次迭代后趋于稳定值,说明模型收敛速度较快。在经过多轮迭代后得到一个训练好的网络模型,该模型反映了中心传感器与卫星传感器之间明显的映射关系。

3.3 有电流激励条件下磁场传感器信号特征分析

在获取测试数据集阶段,开启可编程电源,在提供磁场噪声干扰的同时,向该导线注入输入频率为 0.5 Hz,幅值 3 A 的矩形电流,由式(9)中的毕奥-萨伐尔定律,中心传感器处应检测到一个矩形磁信号,然而由于磁场噪

声干扰的影响,其检测到的信号为纯净磁信号与干扰磁场噪声的组合信号,如图 10 中的最上方波形曲线所示。




图 10 有激励有干扰测试集:中心传感器处信号与卫星传感器 1~8 处信号

Fig. 10 Test set with excitation and interference; signal at center sensor and satellite sensors 1~8

由于磁场噪声的存在,中心传感器处矩形磁信号明显失真,但是中心传感器处信号的幅值与相位波动仍与各卫星传感器信号具有明显的相似性,如中心传感器信号的幅值与相位波动与卫星传感器 1 处信号变化相似,并且在其波形第 2~3 s、7~8 s、第 8~9 s 处产生明显畸变时,卫星传感器 1、8 处信号的波形幅值也在对应时刻达到极值,磁信号去噪的重点便是消除这些明显畸变。

3.4 磁场信号去噪实验验证

噪声重构与信号去噪结果如图 11 所示,含噪中心信号为被磁场噪声干扰的中心传感器信号,纯净信号为中心传感器未受干扰时的理想信号,重构中心噪声为采用本文方法重构的磁场噪声。降噪中心传感器信号由图 11 中的含噪中心信号,减去图 11 中的重构中心噪声得到,在图 11 中用紫色曲线表示。去噪后的中心传感器信号更接近于理想信号,具体来说,含噪中心传感器信号中用虚线圈出表示的 3 个明显扭曲的点已经被成功校正。




图 11 噪声重构与信号去噪结果图




图 12 模型指标对比
Fig. 12 Comparison of model indicators

取特征能力强和 LSTM 网络可以按序列扩张^[27]等优点, 还通过条件高斯噪声的注入增强了模型的泛化能力和预测精度。

4 方法鲁棒性验证

4.1 传感器数量对去噪效果的影响

本文探究了传感器数量对于磁场信号去噪实验结果的影响,以本文采用的 NECNN-BiLSTM 网络为例,不同传感器数量下磁场信号去噪结果如表 4 所示。从表 4 可以看出,磁场信号去噪结果在整体趋势上随传感器数量的增加而变好。此外,当传感器数量减少到一定程度时,本文所提方法的去噪效果开始明显变差,例如在传感器数量为 5 时,降噪后的中心传感器信号开始出现明显畸变,如图 13 所示。

表 4 不同传感器数量下 NECNN-BiLSTM 网络磁场信号去噪结果对比

Table 4 Comparison of denoising results of magnetic field signals in NECNN-BiLSTM networks with different number of sensors

传感器数量	E_m (GS)	$RMSE$ (GS)
8	0.108 0	0.216 1
7	0.134 1	0.216 9
6	0.154 1	0.218 3
5	0.568 6	0.236 5
4	0.495 4	0.234 6
3	0.246 9	0.236 6
2	0.672 8	0.284 1
1	0.655 2	0.269 7

4.2 稳态噪声对去噪效果的影响

为了进一步论证本文使用的回归预测模型的鲁棒性,分别将 50 dB 和 40 dB 的高斯噪声引入实验采集的有

此外,为了进一步对比验证 NECNN-BiLSTM 网络性能的优越性,引入 4 种常见的回归预测模型(back propagation neural network, BPNN)、CNN、LSTM、CNN-LSTM 进行对比,同时引入最大误差 E_m (Max Error) 与均方根误差以证明本文使用的 NECNN-BiLSTM 网络的优越性,其中,用 $s_cen[i]$ 表示降噪中心信号的所有采样点, $true[i]$ 表示纯净信号的所有采样点, E_m 定义为考虑所有采样点的 $s_cen[i]$ 和 $true[i]$ 的最大绝对幅值差,如下所示:

$$E_m = \text{Max}(|s_cen[i] - true[i]|) \tag{10}$$

$RMSE$ 用于描述这两个信号之间的差异,其定义如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_cen[i] - true[i])^2} \tag{11}$$

式中: N 为采样信号的点数。

由表 3 和图 12 可知,本文所用 NECNN-BiLSTM 模型的最大误差和均方根误差分别为 0.108 0 GS 和 0.216 1 GS,相比于其他网络预测精确度更高,定量分析证明了模型的优越性。NECNN-BiLSTM 网络精度更高的原因是与对比的网络相比,所提的方法不仅综合了 CNN 网络提

表 3 各模型预测精度对比

Table 3 Comparison of prediction accuracy of models

模型	E_m (GS)	$RMSE$ (GS)
本文方法	0.108 0	0.216 1
BPNN	0.138 7	0.218 2
CNN	0.499 0	0.228 7
LSTM	0.206 1	0.217 3
CNN-LSTM	0.110 4	0.217 1




图 13 传感器数量为 5 时磁场信号去噪结果图
Fig. 13 De-noising result of magnetic field signal with 5 sensors

激励有干扰数据集作为新的测试集,将其输入到训练好的网络,以验证 NECNN-BiLSTM 网络相较于其他模型的抗噪能力和鲁棒性。由图 14 可知在加入高斯噪声后,所提出的 NECNN-BiLSTM 模型在不同噪声环境下仍能准确地从卫星传感器信号重构淹没在中心传感器信号内的干扰分量,降噪后的中心传感器信号与纯净信号基本重合。




图 14 不同噪声环境 NECNN-BiLSTM 网络信号去噪结果图
Fig. 14 Graphs of signal denoising results for NECNN-BiLSTM networks in different noise environments

由表 5 与图 15 可知,不同模型在面对 50 dB 与 40 dB 噪声时,预测准确度均出现了不同程度的下降。例如,在 40 dB 噪声环境下,本文方法的信号去噪结果的最大误差增加到了 0.115 7 GS,但是在相同的噪声环境下,本文提出的模型仍然优于其他模型,其抗噪能力和鲁棒性更好,性能更加优越。

4.3 交变磁场干扰对去噪效果的影响

考虑到实际生产应用中影响磁场信号检测的外部干扰源多为交变磁场,本文将永磁体置于旋转电机轴上,通过电机的轴向旋转而引起的永磁体磁极相对于辅助传感器阵列的变化来获取交变磁场干扰。将该交变磁场干扰

表 5 不同噪声环境下的各模型预测准确度对比 Table 5 Comparison of the prediction accuracy of each model in different noise environments			
SNR/dB	模型	E_m (GS)	$RMSE$ (GS)
50	本文方法	0.115 7	0.216 1
	BPNN	0.141 8	0.218 4
	CNN	0.498 2	0.228 7
	LSTM	0.202 3	0.217 2
	CNN-LSTM	0.124 2	0.217 1
40	本文方法	0.115 7	0.215 3
	BPNN	0.142 5	0.218 2
	CNN	0.494 9	0.227 6
	LSTM	0.206 1	0.216 8
	CNN-LSTM	0.125 7	0.217 3




图 15 不同噪声环境下的各模型指标对比
Fig. 15 Comparison of model metrics in different noise environments

源替换掉上文实验中的永磁铁干扰源,重复上文实验操作,进行信号采集、模型训练、噪声重构与信号去噪。交变磁场干扰下采集到的磁场噪声信号去噪训练集与测试集的波形如图 16、17 所示。

当干扰源换做交变磁场时,用作磁干扰的交变磁场对各传感器采集到的信号影响很大,但是通过一维信号相似度匹配得到的辅助传感器最优布局依旧可以捕获各传感器之间的映射关系。例如,中心传感器处磁场噪




图 16 交变磁场干扰下磁场噪声信号去噪训练集

Fig. 16 Training set for denoising magnetic field noise signals under alternating magnetic field interference




图 17 交变磁场干扰下磁场噪声信号去噪测试集

Fig. 17 Test set for denoising magnetic field noise signals under alternating magnetic field interference

声的幅值与相位波动与卫星传感器 1、2 处信号变化仍然存在明显的相似性。

交变磁场干扰下噪声重构与信号去噪结果如图 18 所示,去噪后的中心传感器信号接近于理想信号,其 $E_m=0.114\ 3\ \text{GS}$, $RMSE=0.227\ 6\ \text{GS}$,这表明本文所提方法能够有效地消除交变磁场干扰下淹没在中心传感器信号内的干扰分量,实现精准去噪。




图 18 交变磁场干扰下噪声重构与信号去噪结果图

Fig. 18 Noise reconstruction and signal denoising result plots under alternating magnetic field interference

5 结 论


本文提出了一种基于辅助传感器阵列和 NECNN-BiLSTM 网络的磁场信号去噪新方法。根据磁干扰噪声在空间中传播时不同位置的映射关系,通过有限元分析进行传感器阵列位置优化,设计采集电路和辅助传感器阵列捕获不同位置的噪声。提出 NECNN-BiLSTM 网络探索噪声在卫星传感器与中心传感器的非线性映射关系,从卫星传感器噪声重构出中心传感器的噪声分量,根据加性噪声原理,实现中心传感器磁场信号的高精度去噪。磁场去噪实验和鲁棒性实验结果表明,该方法可以有效实现强噪声干扰下的中心传感器信号的高精度去噪,其 $E_m=0.108\ 0\ \text{GS}$, $RMSE=0.216\ 1\ \text{GS}$,表明该方法具有较高的准确性,对于强噪声干扰下的精确磁场信号去噪研究具有一定的实用价值,为强磁场干扰下的电流信号检测易受干扰、磁场成像质量不稳定以及电池状态难以准确判断等实际应用问题提供了一种新的解决思路。

参考文献

- [1] 刘金海, 赵贺, 神祥凯, 等. 基于漏磁内检测的自监督缺陷检测方法[J]. 仪器仪表学报, 2020, 41(9): 180-187.
LIU J H, ZHAO H, SHEN X K, et al. Self-supervised defect detection method based on magnetic flux leakage internal detection [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 180-187.
- [2] 鲁文帅, 尤睿, 周扬, 等. 基于单片 TMR 磁传感器的非侵入电流监测微系统[J]. 仪器仪表学报, 2020, 41(6): 1-9.
LU W SH, YOU R, ZHOU Y, et al. Non-invasive current monitoring microsystem based on a single TMR sensor [J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 1-9.
- [3] 张娜, 彭磊, 吴瑶, 等. 高分辨率 TMR 传感器阵列磁场成像涡流检测探头[J]. 仪器仪表学报, 2020, 41(7): 45-53.
ZHANG N, PENG L, WU Y, et al. ECT probe based on magnetic field imaging with a high resolution TMR sensor array [J]. Chinese Journal of Scientific Instrument, 2020, 41(7): 45-53.
- [4] 闫梁, 万本例, 胡斌, 等. 基于双轴 TMR 电磁传感器的裂纹检测方法研究[J]. 仪器仪表学报, 2021, 42(9): 106-114.
YAN L, WAN B L, HU B, et al. Research on crack detection method based on double axis TMR electromagnetic sensor[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 106-114.
- [5] 姜春, 汪圣涵, 唐健, 等. 基于双层排线探头的轧辊表面微裂纹检测方法[J]. 仪器仪表学报, 2023, 44(6): 188-196.
JIANG CH, WANG SH H, TANG J, et al. Micro-crack detection method on roll surface based on double-layer parallel cables probe [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 188-196.
- [6] 周媛媛, 常莹, 陈浩, 等. 基于参考台的盲源分离法在抑制地磁场近场噪音中的应用研究[J]. 地球物理学报, 2019, 62(2): 572-586.
ZHOU Y Y, CHANG Y, CHEN H, et al. Application of reference-based blind source separation method in the reduction of near-field noise of geomagnetic measurements [J]. Chinese Journal of Geophysics, 2019, 62(2): 572-586.
- [7] ILOTT A J, MOHAMMADI M, SCHAUERMAN C M, et al. Rechargeable lithium-ion cell state of charge and defect detection by in-situ inside-out magnetic resonance imaging [J]. Nature Communications, 2018, 9(1): 1776.
- [8] GREEN J E, STONE D A, FOSTER M P, et al. Spatially resolved measurements of magnetic fields applied to current distribution problems in batteries [J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(4): 951-958.
- [9] TRIPATHI P C, BAG S. CNN-DMRI: A convolutional neural network for denoising of magnetic resonance images [J]. Pattern Recognition Letters, 2020, 135: 57-63.
- [10] 韩盈, 安志国, 底青云, 等. 基于循环神经网络的大地电磁信号噪声压制研究[J]. 地球物理学报, 2023, 66(10): 4317-4331.
HAN Y, AN ZH G, DI Q Y, et al. Research on noise suppression of magnetotelluric signal based on recurrent neural network [J]. Chinese Journal of Geophysics, 2023, 66(10): 4317-4331.
- [11] 高洪元, 王世豪, 程建华, 等. 冲击噪声下基于演化长短时记忆神经网络的调制信号识别[J]. 智能系统学报, 2023, 18(4): 676-687.
GAO H Y, WANG SH H, CHENG J H, et al. Modulation signal recognition based on evolutionary long short-term memory neural network under impulse noise [J]. CAAI Transactions on Intelligent Systems, 2023, 18(4): 676-687.
- [12] 马愈昭, 张岩峰, 冯帅. 基于神经网络的侧向激光雷达信号去噪算法[J]. 光电工程, 2023, 50(6): 46-57.
MA Y ZH, ZHANG Y F, FENG SH. A denoising algorithm based on neural network for side-scatter lidar signal [J]. Opto-Electronic Engineering, 2023, 50(6): 46-57.
- [13] 许滔滔, 王中兴, 肖卓伟, 等. 基于 LSTM 循环神经网络的大地电磁工频干扰压制[J]. 地球物理学进展, 2020, 35(5): 2016-2022.
XU T T, WANG ZH X, XIAO ZH W, et al. Magnetotelluric power frequency interference suppression based on LSTM recurrent neural network [J]. Progress in Geophysics, 2020, 35(5): 2016-2022.
- [14] 董晓芬, 陈国光, 田晓丽, 等. 基于 CEEMDAN 阈值滤波的磁场信号去噪模型[J]. 传感技术学报, 2021, 34(7): 919-925.
DONG X F, CHEN G G, TIAN X L, et al. Denoising model of magnetic field signal based on CEEMDAN threshold filtering [J]. Chinese Journal of Sensors and Actuators, 2021, 34(7): 919-925.
- [15] WANG H, DAI L, MAO L, et al. In situ detection of lithium-ion battery pack capacity inconsistency using

- magnetic field scanning imaging [J]. *Small Methods*, 2022, 6(3): e2101358.
- [16] WANG H, YU K, MAO L, et al. Evaluation of lithium-ion battery pack capacity consistency using one-dimensional magnetic field scanning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3507610.
- [17] CHEN R, JIAO J, CHEN Z Y, et al. Power batteries health monitoring: A magnetic imaging method based on magnetoelectric sensors[J]. 2022, 15(5): 15051980.
- [18] BERGHOLZ T, NUÑEZ T, WACKERL J, et al. Magnetography: A novel characterization tool for li-ion-batteries[J]. *In-situ Characterization Methods in Energy Materials Research*, 2013;28-33.
- [19] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述[J]. *仪器仪表学报*, 2020, 41(11): 1-18.
LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(11): 1-18.
- [20] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. *仪器仪表学报*, 2023, 44(4): 19-27.
WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(4): 19-27.
- [21] CHEN L, AN K, HUANG D, et al. Noise-boosted convolutional neural network for edge-based motor fault diagnosis with limited samples[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(9): 9491-9502.
- [22] 陈思佳, 罗志增. 基于长短时记忆和卷积神经网络的手势肌电识别研究 [J]. *仪器仪表学报*, 2021, 42(2): 162-170.
CHEN S J, LUO ZH Z. Research on gesture EMG recognition based on long short-term memory and convolutional neural network [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(2): 162-170.
- [23] 董静怡, 庞景月, 彭宇, 等. 集成 LSTM 的航天器遥测数据异常检测方法 [J]. *仪器仪表学报*, 2019, 40(7): 22-29.
DONG J Y, PANG J Y, PENG Y, et al. Spacecraft telemetry data anomaly detection method based on ensemble LSTM [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(7): 22-29.
- [24] HUANG G W, JENG J T. Implementation of 16-channel amr sensor array for quantitative mapping of two-dimension current distribution[J]. *IEEE Transactions on Magnetism*, 2018, 54(11): 6500605.
- [25] BUCHIN M, KILGUS B. Fréchet distance between two point sets [J]. *Computational Geometry*, 2022, 102: 101842.
- [26] LIU D, CHEN X, PENG D. Some cosine similarity measures and distance measures between q-rung orthopair fuzzy sets [J]. *International Journal of Intelligent Systems*, 2019, 34(7): 1572-1587.
- [27] 李锋, 陈勇, 向往, 等. 基于量子加权长短时记忆神经网络的状态退化趋势预测 [J]. *仪器仪表学报*, 2018, 39(7): 217-225.
LI F, CHEN Y, XIANG W, et al. State degradation trend prediction based on quantum weighted long short-term memory neural network [J]. *Chinese Journal of Scientific Instrument*, 2018, 39(7): 217-225.

作者简介



胡书正, 2021 年于合肥工业大学获得学士学位, 现为安徽大学电气工程与自动化学院硕士研究生, 主要研究方向为信号处理与动态测试。

E-mail: Z22301114@stu.ahu.edu.cn

Hu Shuzheng, received his B.Sc. degree from Hefei University of Technology in 2021. He is currently pursuing his master degree in the School of Electrical Engineering and Automation, Anhui University. His main research interests are signal processing and dynamic testing.



陆思良 (通信作者), 分别于 2010 年和 2015 年获得中国科学技术大学机械工程学士和博士学位。现为安徽大学电气工程与自动化学院教授, 主要研究方向为机电系统的状态监测和故障诊断、信号处理、物联网和边缘计算。

E-mail: silianglu@ahu.edu.cn

Lu Siliang (Corresponding author), received the B.Sc. and Ph.D. degrees in mechanical engineering from the University of Science and Technology of China, in 2010 and 2015, respectively. He is currently a professor at the School of Electrical Engineering and Automation, Anhui University. His research interests include condition monitoring and fault diagnosis of electromechanical systems, signal processing, internet of things and edge computing.