

DOI: 10.19650/j.cnki.cjsi.J2614861

基于多尺度信息补全网络的高分辨率磁场数据 快速采集方法研究*

胡智勇¹, 陈文越¹, 宋俊材², 陆思良¹, 王骁贤³

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

摘 要: 二维高分辨率磁场数据在智能系统监测及故障诊断领域发挥重要作用,但存在的采集耗时及噪声干扰强等问题严重制约其工程应用。为此,提出了一种高分辨率磁场数据快速精准采集方法,仅需采集少量离散位置的磁场数据,即可高效重建完整的高分辨率磁场数据。该方法的核心在于设计了一种基于多尺度信息补全的高分辨率数据重建网络,通过将稀疏磁场数据映射至多个低分辨率尺度进行特征融合,充分挖掘邻近区域磁场数据间的空间关联性,在滤除干扰的同时有效补全缺失位置的磁场信息,进而恢复高分辨率磁场数据。此外,现有超分辨率重构网络训练需依赖稀疏-高分辨率磁场数据对,而所提网络仅需稀疏磁场数据作为训练样本,有效规避了对于高分辨率磁场数据的依赖,大幅降低了数据采集成本。仿真与实验结果表明,无论是稀疏采样还是均匀采样条件下,所提方法仅利用 625 点稀疏磁场数据,便可精准恢复 128×128 的高分辨率磁场数据,大幅缩短了采集时间。且相较于现有重构网络,所提方法在峰值信噪比和结构相似性指数两项核心指标上都取得了显著提升,充分验证了该方法的可行性和优越性,为高分辨率磁场数据的快速采集提供了一种切实可行的解决方案。

关键词: 磁场采集;超分辨率重构;磁场信号去噪;多尺度信息补全

中图分类号: TH763 文献标识码: A 国家标准学科分类代码: 520.20

Fast acquisition method for high-resolution magnetic field data based on multi-scale information completion network

Hu Zhiyong¹, Chen Wen Yue¹, Song Juncai², Lu Siliang¹, Wang Xiaoxian³

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

Abstract: High-resolution magnetic field data play a crucial role in intelligent system monitoring and fault diagnosis; however, time-consuming acquisition and strong noise interference limit their practical applications. To address this, this paper proposes a fast and accurate acquisition method capable of reconstructing complete high-resolution data from sparse measurements. The core contribution is a multi-scale information completion network that maps sparse data to multiple low-resolution scales for feature fusion. It fully exploits the spatial correlations among neighboring regions, the network filters noise and completes missing information. Unlike existing super-resolution networks that rely on paired sparse-high-resolution training data, the proposed network trains solely on sparse data, eliminating dependence on high-resolution ground truth and significantly reducing acquisition costs. Simulation and experimental results demonstrate that with only 625 sparse sampling points, the method accurately reconstruct 128×128 high-resolution data under both sparse and uniform sampling conditions, thereby significantly shortening acquisition time. Furthermore, compared to existing methods, it achieves substantial improvements in two key metrics: Peak signal-to-noise ratio and structural similarity index. These results fully verify the feasibility and superiority of the proposed method, offering a practical and effective solution for the rapid high-resolution magnetic field data acquisition.

Keywords: magnetic field acquisition; super-resolution reconstruction; magnetic field signal denoising; multi-scale information completion

0 引 言

磁场传感技术凭借非接触、高灵敏度的特性,已成为智能系统监测及故障诊断领域的关键技术支撑^[1-6]。近年来,通过磁传感器采集设备运行状态下的二维磁场数据,进而实现系统监测与故障诊断的技术方案,因成本低廉、设备结构简单、适用场景广泛等优势受到学界与工业界的广泛关注。在二维磁场数据中,高分辨率(high resolution, HR)磁场数据相比于低分辨率(low resolution, LR)磁场数据,在相同的采集区域内包含更密集的数据点,能够保留更丰富的设备状态信息,更适于应用在设备智能监测和故障诊断等领域。然而,在常用磁场检测手段中,大面积高分辨率磁场的采集过程往往效率偏低,难以满足设备状态监测对实时性的要求^[7]。即便采用成本较高的传感器阵列方案来提升采集速度,也会因传感器存在物理体积约束,无法满足高分辨率采集对传感器密布性的核心需求。

为突破这一瓶颈,一种可行策略是先采集低分辨率磁场数据,再借助神经网络对其进行超分辨率重构,从而恢复出高分辨率结果。由于网络推理过程耗时远低于物理采集过程,该方案的整体时间主要取决于低分辨率数据的采集阶段,因而有望实现高分辨率磁场数据的高效采集。

超分辨率成像作为机器视觉领域的前沿方向,已催生了多种先进的重构网络架构。例如,程德强等^[8]提出了一种多通道递归残差学习机制的超分辨率重建网络,其相比同类模型可以使用更短的时间获得更优的超分质量。熊巍等^[9]通过将通道注意力机制自适应地嵌入 Transformer 模型,在网络模型保持足够轻量化的同时,使图像超分辨率性能得到的有效提升。Chen 等^[10]提出了一种全新的双聚合 Transformer 模型,在连续的 Transformer 块中交替应用空间和通道自注意力机制,使网络能够捕获全局上下文并实现跨块特征聚合,实现了更优的超分效果。Li 等^[11]提出一种单图像超分辨率扩散概率模型,通过马尔可夫链,它可以通过逐步将高斯噪声转换为基于低分辨率图像输入的超分辨率图像,进而生成具有丰富细节的多样化超分辨率结果。Chen 等^[12]提出了一种新型混合注意力 Transformer,将常用于卷积网络结构的通道注意力机制添加进 Transformer 模型,并提出了一种基于窗口的自注意力机制,从而使得模型能够利用全局统计信息和强大的局部拟合能力的互补优势,有效利用更多的输入信息,激活更多输入像素,实现了更优的重建效果。

近期,Hu 等^[13]首次将超分辨率思想引入磁场数据采集领域,尝试通过深度学习从低分辨率磁场图中重建

高分辨率版本。然而,大多数现有超分辨率方法依赖大量成对的高低分辨率训练样本^[14-16],而高分辨率磁场数据的采集本身耗时、成本高,严重制约了此类模型的训练可行性与工程实用性。尽管部分研究尝试放宽对严格配对数据的需求,但仍无法完全摆脱对高分辨率数据的依赖^[17]。例如,Wang 等^[18]提出了一种基于循环卷积神经网络(cycle convolutional neural network, Cycle-CNN)的无监督网络,可以使用未完全配对的高低分辨率数据进行训练,降低了常规超分模型对训练数据的要求,并获得了较好的超分结果。总体而言,对高分辨率训练数据的高度依赖仍是当前基于深度学习的磁场超分辨率方法推广应用的主要障碍。

针对上述挑战,本文提出一种新型高效的高分辨率磁场数据采集方法:通过在空间上离散采样获得稀疏磁场数据,进而利用深度学习模型补全缺失区域,重建完整的高分辨率磁场分布。相比传统低分辨率采样,稀疏采样在相近采集成本下能够直接保留部分高分辨率信息,本文方法正是充分利用这一双重优势,实现高分辨率磁场数据的快速重建。

近年来,已有部分研究探索利用深度学习处理稀疏数据以重建完整场量。例如,Tang 等^[19]提出了一种基于残差 U 型神经网络(residual U-net, ResU-Net)架构的激发点-接收点-时间(shot-receiver-time, SRT)域重建方法,利用 SRT 域保留较高的信号连通性,使得模型可以有效学习稀疏采集的二维地震数据的特征,合理重建缺失的数据;Alejandro 等^[20]提出了一种基于超分辨率生成对抗网络的随机稀疏传感器场量的估计方法,能够从随机种子场中估计出高分辨率的流体场,进而加快高分辨率流体场数据的采集速度。

由于磁场数据在实际采集过程中不可避免地受到多种噪声源干扰^[21-23],如电路热噪声、半导体器件中的散粒噪声等。这些含噪数据将会显著劣化重建模型的性能,进而影响高分辨率磁场采集的精度与稳定性。本文提出一种基于多尺度信息补全的深度学习网络,仅利用稀疏的含噪数据便能实现高分辨率磁场的高精度快速重建。该网络通过将稀疏输入映射至多个特征尺度,充分挖掘相邻位置间磁场的空间相关性,在实现缺失数据补全的同时有效抑制噪声干扰,从而完成完整高分辨率磁场场图的精确重构。仿真与实测数据的实验结果表明,所提方法在不同噪声水平与稀疏程度下均能稳定高效地恢复完整高分辨率磁场分布,验证了其有效性与优越性。

1 基于稀疏磁场数据的高分辨率磁场重建方法

为了实现快速采集高分辨率磁场数据,同时解决现有方法中出现的神经网络模型训练数据获取成本高和噪

声导致完整磁场数据重建质量下降的问题,本文提出了一种基于多尺度信息补全网络的快速采集高分辨率磁场数据的方法。该方法主要通过稀疏分布的磁场传感器采集稀疏的磁场数据,通过本文所提出的神经网络模型,重建出空间连续的完整高分辨率磁场数据。和常见的超分

辨率方法相比,该神经网络模型无需成对的高低分辨率磁场数据进行训练,降低了训练数据的获取难度,如图 1 所示。与现有方法相比,本方法仅需少量稀疏观测即可完成高分辨率恢复,显著提升了系统的实用性与部署灵活性。




图 1 本文方法与现有方法对比

Fig. 1 Comparison between the proposed method and existing methods

本文所提出的神经网络模型主要基于生成对抗网络 (generative adversarial network, GAN) 的框架,主要由一

个生成器模块和一个判别器模块组成。模型的总体结构如图 2 所示。




图 2 基于多尺度信息补全的磁场重建模型架构

Fig. 2 Architecture of the magnetic field reconstruction model based on multi-scale information completion

1.1 生成器

生成器的主要任务是完成从稀疏磁场数据到完整磁场数据的重建工作,实现缺失信息的补全与空间特征的映射。

首先,生成器将稀疏数据输入3个并行的下采样分支模块,每个下采样分支模块由不同数量相同结构的多个下采样单元组成,每个单元包含一层卷积层和参数化整流线性单元(parametric rectified linear unit, PReLU)激活函数,从而将原始的稀疏数据点映射至3个不同尺度的低分辨率高维特征图。其中,PReLU激活函数的表达为:

$$\text{PReLU}(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad (1)$$

其中, a 是一个可学习的参数,在训练过程中进行优化,以增强网络的灵活性。

稀疏采样下磁场重建的核心在于高效利用有限观测点的信息,重构整个空间域上的完整磁场分布。本文基于磁场数据中邻近点在空间特征上的相关性,提出了一种多尺度信息补全模块。如图3所示,该模块首先将稀疏二维磁场数据映射至多个低分辨率尺度,在不同尺度上利用缺失点周围已知数据点的信息逐步补全缺失信息。各低分辨率特征图用于捕捉不同尺度下的磁场数据结构特征,既提升了重建质量,又通过引入更粗糙尺度的信息,增强网络的鲁棒性,有效避免了局部区域因完全无采样点而导致的区域重建失败问题。




图3 多尺度信息补全模块

Fig. 3 Multi-scale information completion module

随后,将3个不同尺度的低分辨率高维特征图进行特征融合,输入由16个残差块组成的深层特征提取序列中。每个残差块包含两个3×3卷积层和一个PReLU激活函数,并通过跳跃连接将其输入与输出相加。残差块中跳跃连接的设计有效促进了梯度在深层网络中的传播^[24],使模型能够学习从稀疏、带噪输入到完整、干净输出之间极其复杂的非线性映射。此外,本研究还使用了一个长距离跳跃连接将整个残差序列的输入与输出相加,进一步增强了特征提取的稳定性^[25]。

经深层特征提取后,特征图将进入上采样阶段,这一步采用两个串联的上采样模块,将特征图分辨率逐步恢复至目标分辨率。每个上采样模块包含一个卷积层、一个快速高效的PixelShuffle操作和一个PReLU激活函数。最后,通过一个9×9的等卷积层对多通道特征图进行最终的整合和映射,还原为单通道数据,输出最终的完整高分辨率磁场数据。

1.2 判别器

判别器的主要任务是判断生成器所生成的完整磁场数据,经稀疏采样后,其相对真实稀疏磁场数据的拟真程度。判别器的输入为稀疏矩阵数据,通过一系列复杂的处理,最终输出一个单一的概率数值,其代表了判别器认为该输入数据为真实数据的可能性。判别器的整个任务可以划分为“特征提取”和“分类判断”两个步骤。

首先,判别器将稀疏磁场数据输入其特征提取模块,通过多层卷积网络,逐步提取出数据从浅层到深层的特征。如图4所示,稀疏磁场数据输入由8个3×3卷积层构成的深度网络主干,通过交替分布的步长为1和步长为2的卷积层进行特征提取。其中4个步长为1的卷积层负责增加特征图的深度,每一层都会使得特征图通道数翻倍,而4个步长为2的卷积层负责将特征图的空间尺寸逐级压缩,每一次压缩都会使得感受野显著扩大。在整个过程中,图像的空间尺寸不断缩小,而特征的维度不断增大。其中每个卷积层都使用了带漏整流线性单元(leaky rectified linear unit, LeakyReLU)激活函数,确保了信息流的稳定和梯度信号的有效传递。




图4 判别器特征提取模块

Fig. 4 Discriminator feature extraction module

然后,判别器将前一阶段提取出的高维特征图展平为一维特征向量,通过两层全连接层进行信息映射与整合。最终通过一个Sigmoid函数将输出值映射为一个介于0~1的概率值,完成最终的数据真实性判别任务。其中,Sigmoid函数的表达为:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

1.3 损失函数

生成器的损失函数分为两个部分,分别为像素损失和对抗损失,其具体的公式表达如式(3)所示。

$$\mathcal{L}_G = \lambda_{\text{pixel}} \cdot \mathcal{L}_{\text{pixel}} + \lambda_{\text{adv}} \cdot \mathcal{L}_{\text{adv}} \quad (3)$$

其中, $\mathcal{L}_{\text{pixel}}$ 为像素损失, $\mathcal{L}_{\text{adv}}$ 为对抗损失, λ_{pixel} 和 λ_{adv} 为各自的权重。

生成器的两部分损失函数分别确保了结果在采样点处的重建精度与重建图像整体内容的真实性, 两损失函数均只在采样点处进行计算。其中, 像素损失通过计算生成图像与真实图像在采样点处的像素值均方误差来衡量。其数学表达式为:

$$\mathcal{L}_{\text{pixel}} = \frac{1}{\sum_{i=1}^H \sum_{j=1}^W M_{i,j}} \sum_{i=1}^H \sum_{j=1}^W ((G(x))_{i,j} \cdot M_{i,j} - (x)_{i,j})^2 \quad (4)$$

其中, $M_{i,j}$ 为掩码矩阵在该点处的掩码值, 其为 0 或 1。每个稀疏采样数据均对应一个掩码矩阵, 用于描述该数据中的每个点是否为已有的采样点。 x 为输入生成器的稀疏采样数据, $G(x)_{i,j}$ 为生成器在该点处的输出值。该损失函数确保生成器在所有已知观测点上生成的结果尽可能接近真实值, 从而为重建任务奠定基础, 保证了生成结果的准确性。

对抗损失则负责保证数据的整体真实性, 其数学表达式为:

$$\mathcal{L}_{\text{adv}} = E_{x,\alpha} [-\alpha \log D(G(x) \odot M) - (1 - \alpha) \log(1 - D(G(x) \odot M))] \quad (5)$$

其中, M 为掩码矩阵, $G(x)$ 为生成器输出图像。 $D(G(x) \odot M)$ 为判别器对该输入样本的真实性评分。该损失函数的重点并非考量生成器在某个点处的还原是否准确, 而是迫使生成器去学习真实数据在不同点之间的内在联系与深层特征, 从而使其重建出的数据更加符合真实图像数据中隐藏的特征规律。

需要强调的是, 尽管像素损失与对抗损失均仅在采样点处计算, 且其输入完全相同, 但二者对于模型性能的提升都至关重要。像素损失确保了生成器在已知采样点处能够精确地重建出真实值, 而对抗损失则促使生成器学习更深层次的各个数据点之间的联系, 只有当生成器重建的数据在分布特征上与真实数据足够相似, 才能使判别器误判, 进而最小化该部分损失。这使得填充的区域更加合理, 而不是简单的使用数学平滑插值, 保证了在非采样点区域还原的真实性。

判别器的目标是准确区分输入数据的真伪, 即对输入的真实数据输出接近 1 的置信度, 而对生成器生成的磁场数据输出接近 0 的置信度。由于判别器需要对真实数据和生成器输出的重建数据进行判断, 因此其损失函数也相应地分为两个部分, 分别计算真实数据与“真实标签”、生成数据与“虚假标签”之间的二元交叉熵。

此处, “真实损失”和“虚假损失”的数学表达式分别为:

$$\mathcal{L}_{D_{\text{real}}} = E_{x,\alpha} [-\alpha \log D(x \odot M) - (1 - \alpha) \log(1 - D(x \odot M))] \quad (6)$$

$$\mathcal{L}_{D_{\text{fake}}} = E_{x,\beta} [-\beta \log D(G(x) \odot M) - (1 - \beta) \log(1 - D(G(x) \odot M))] \quad (7)$$

其中, 为了训练更加稳定, 避免判别器过早地收敛, 所提方法进一步对标签按照如下方式进行平滑处理, 即:

$$\begin{cases} \alpha \sim U(1 - \delta, 1) \\ \beta \sim U(0, \delta) \end{cases} \quad (8)$$

其中, δ 为标签平滑因子。

判别器的总损失为两部分损失的平均值, 其表达式为:

$$\mathcal{L}_D = \frac{1}{2} (\mathcal{L}_{D_{\text{real}}} + \mathcal{L}_{D_{\text{fake}}}) \quad (9)$$

2 数据集构建与模型训练

2.1 磁场数据采集

为了验证所提方法的可行性, 本研究搭建了一个基于传感器阵列的磁场数据采集平台, 如图 5 所示。




图 5 基于传感器阵列的磁场采集平台

Fig. 5 Magnetic field acquisition platform based on sensor array

实验平台主要由以下部分组成: 可编程直流电源 DP800、数控直流电源 SPE3102、步进电机、8 通道磁传感器芯片、NI USB-6289 数据采集卡、计算机等。其中所选用的磁传感器的型号为 TMR2103, 线性量程为 ± 35 GS, 灵敏度为 6 mV/GS, 具有较宽的动态范围和较高的灵敏度。实验装置中进行扫描采样的磁场数据采集模块由两个 8 通道磁传感器芯片并排安装在非磁性基座构成, 可完成所需的稀疏磁场数据的采集。

在磁场数据测量过程中, 首先将待测电路固定在基座上, 通过步进电机沿 x 和 y 方向进行逐步的移动, 使得固定的磁场数据采集模块逐步扫描整个待测电路产生的磁场区域。步进电机带动待测电路沿着预定路径进行

分段移动,在每个待测点短暂停留,同时数据采集卡通过垂直对齐的双芯片通道实时记录磁场数据。收集的数据将自动按预设的模式进行保存,以便于后续的使用和分析。通过调整电机步长,可以灵活控制稀疏磁场数据的采样点数,进而满足不同使用需求。表 1 展示了该实验平台在均匀采集不同点数稀疏磁场数据的耗时情况。为确保磁场数据的精度,采集模块在每个采样位置停留 3 s,其中 2 s 用于磁场信号采集,剩余时间用于数据传输与记录,并且将采集到的磁场信号经滑动中值滤波处理,取其均值作为该点处的磁场幅值。

表 1 均匀稀疏磁场数据采集时长

Table 1 Duration of uniform sparse magnetic field data acquisition

采样点数/个	移动步长/mm	采集时间/min
256 × 256	0.625	411.2
160 × 160	1.000	161.0
80 × 80	2.000	40.2
64 × 64	2.500	25.7
32 × 32	5.000	6.6
16 × 16	10.000	1.7

基于该方法,不同布线图案的励磁电路板所采集的高分辨率磁场数据图像如图 6 所示。




图 6 励磁电路板与采集磁场信号图像

Fig. 6 Excitation circuit board and acquired magnetic field image

2.2 数据集构建

由于真实磁场数据采集需制作大量不同图案的电路板,耗时耗力,为此本研究采用仿真方法对数据集进行扩充。具体而言,首先基于毕奥-萨伐尔定律推导出磁场计算模型,进而利用特定的解析函数来生成不同分布的磁场数据^[13],从而快速灵活地扩充训练数据集。

毕奥-萨伐尔定律是描述电流产生磁场的物理定律,其定量给出了无限小电流元在空间某点产生的微分磁场,其公式表示为:

$$dB = \frac{\mu_0}{4\pi} \cdot \frac{Idl \times r}{r^3} \tag{10}$$

其中, dB 表示电流元在定点产生的微小磁场, μ_0 是真空磁导率或磁常数, I 是电流强度, dl 是电流元沿电流方向的微小长度矢量, r 是从电流元指向场点(观测点)的矢量, r 是该距离的大小, $\times$ 代表矢量叉乘,它决定了磁场的方向。

基于此原理,在 MATLAB 中搭建仿真模型生成数据集。首先使用函数解析式设定出不同的导线的形状,然后在直流导线上方设定一个 16 cm×16 cm 的正方形观测区域,根据不同的空间分辨率对该区域进行网格划分,最后利用毕奥-萨伐尔定律计算每个微小网格内的磁场强度并将其作为像素值,从而获得不同分辨率下的导线磁场分布图像。仿真数据集包含了不同复杂程度以及不同导线与传感器间距下的磁场数据,以充分保证数据的多样性,部分仿真磁场数据图像样本如图 7 所示。该方法不仅使网络模型能够学习到更具普适性的磁场特征,而且显著降低了模型对真实磁场数据的需求,为模型的灵活训练奠定了基础。




图 7 仿真磁场数据图像

Fig. 7 Simulated magnetic field data images

在后续的测试验证环节,本研究对仿真和采集的完整高分辨率磁场数据进行随机采样和均匀采样,生成稀疏磁场数据,以用于模型的训练与测试。具体而言,随机采样为对每个数据样本使用随机生成的目标采样点数的二值采样掩码(其采样点位置为 1 而非采样点位置为 0)与完整磁场数据进行逐元素相乘,进而得到随机采样稀疏数据。均匀采样为使用目标采样密度但起始采样点位置随机的二值采样掩码,与完整磁场数据逐元素相乘,得到均匀采样稀疏数据。此外,为确保稀疏数据样本的独立性与唯一性,所有样本在同一采样工况配置下均只进行一次稀疏采样。此外,由于采集磁场数据较少,所有的采集磁场数据样本均仅在测试阶段使用,以评估模型的重建能力。在训练阶段,所提模型仅利用采样得到的稀疏磁场数据进行训练。在测试阶段,模型以采样后的稀

疏磁场数据作为输入,并将该稀疏磁场数据对应的完整高分辨率磁场数据作为真实值,与模型重建结果对比,以量化计算各项重建指标。

2.3 模型训练方法

本文所提神经网络模型基于 pytorch 框架构建,其网络训练的设备、环境配置参数及网络超参数如表 2 所示。

表 2 模型训练环境及超参数配置

Table 2 Model training environment and hyperparameter configuration

项目	版本	超参数	值
CPU	AMD Ryzen 5 5600X	批大小	4
GPU	NVIDIA RTX4080s	训练轮次	150
Python	3.7.12	学习率	1×10^{-4}
CUDA	11.3	像素损失权重	1
框架	Pytorch 1.12.1	对抗损失权重	0.001
优化器	Adam	优化器动感参数	0.9

为增强模型具备抗干扰能力,本研究采用了一种主动降噪训练策略对所提出的模型进行训练^[26]。具体而言,在训练阶段,向输入生成器的稀疏数据注入标准差范围为 0.05~0.15 的高斯噪声,以模拟磁场数据采集过程中常见的随机噪声干扰,其数学表达式为:

$$x'_{i,j} = x_{i,j} + \varepsilon_{i,j} \odot M_{i,j} \quad (11)$$

其中, $\varepsilon_{i,j} \sim N(0, \sigma^2)$, ε 是一个与输入数据尺寸相同的噪声张量。 σ 是随机噪声的标准差,用于衡量所添加噪声的强度。而对于输入判别器的稀疏数据则未做处理,仍输入纯净的稀疏磁场数据。通过这种训练方式,所提出的神经网络模型不仅能够学习从稀疏磁场数据到完整磁场数据的映射关系,还能同时学习从含噪磁场数据到无噪磁场数据的映射关系,从而在网络训练过程中实现主动降噪。

2.4 评估指标

为量化评估稀疏磁场数据的重建效果,本文选择峰值信噪比 (peak signal to noise ratio, PSNR) 与结构相似性指数 (structural similarity index measure, SSIM) 作为指标,以客观评估所提方法的有效性。

PSNR 是衡量图像重建质量的常用指标,PSNR 值越高,说明图像重建的质量越好,其公式为:

$$PSNR(X, Y) = 20 \times \lg \left(\frac{MAX}{\sqrt{MSE(X, Y)}} \right) \quad (12)$$

其中, $MSE(X, Y)$ 表示两张图像对应像素的均方误差。 X, Y 代表两张图像的图像矩阵。 MAX 一般表示信号的动态范围,在本研究中,其为每个完整高分辨率磁场图像中最大值与最小值的差值。

SSIM 是一种基于图像的对比度、亮度与结构 3 个方面来衡量两个图像数据相似度的方法。SSIM 值的范围为 $[0, 1]$, 其数值越大,表示重建图像数据的失真程度越小,与目标图像数据整体更相似。其公式表达为:

$$SSIM(X, Y) = L(X, Y) \times C(X, Y) \times S(X, Y) \quad (13)$$

其中, $L(X, Y)$ 为亮度分量, $C(X, Y)$ 为对比度分量, $S(X, Y)$ 为结构分量,其各表达式为:

$$L(X, Y) = \frac{2\mu_X \mu_Y}{\mu_X^2 + \mu_Y^2} \quad (14)$$

$$C(X, Y) = \frac{2\sigma_X \sigma_Y}{\sigma_X^2 + \sigma_Y^2} \quad (15)$$

$$S(X, Y) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \quad (16)$$

其中, μ_X 和 μ_Y 分别为 X 和 Y 图像的像素平均值。 σ_X 和 σ_Y 分别为 X 和 Y 图像的像素标准差, σ_{XY} 为 X 和 Y 图像的协方差。


3 结果与分析

为验证所提出的高分辨率磁场数据快速采集方法的有效性和可行性,本章分别采用随机采样和均匀采样策略构建稀疏磁场数据,并对比各类方法的磁场重建效果。同时,为更加全面、客观地评估本文模型与对比模型的重建结果,本文中所有的模型均使用了五折交叉验证方法。具体而言,本文将完整数据集中的样本进行随机打乱,并等分为 5 个规模一致的子数据集。在此基础上,依次选取其中的 4 个子数据集的并集作为训练集进行模型的训练,而将剩余的子数据集作为验证集,用于计算重建指标。最终,对所有样本的验证重建结果计算统计指标,以更加全面、客观地反映各个模型的重建性能。

3.1 随机采样条件下高分辨率磁场重建性能分析


本节利用随机采样稀疏磁场数据对所提方法的重建性能进行验证,并引入随机种子超分辨率生成对抗网络 (randomly-seeded super-resolution generative adversarial network, RsGAN)^[20] 和 U 型神经网络 (U-Net)^[27] 两种基于稀疏数据的重建网络作为对比模型。为确保对比的严谨性,所有模型执行相同的主动降噪训练策略 (详见 2.3 节),且仅使用稀疏磁场数据进行模型训练及测试。为进一步评估各方法在不同条件下的鲁棒性,实验设计涵盖多种采样点数的稀疏磁场数据,并且测试阶段引入比训练阶段标准差范围更广的高斯噪声 (0~0.25),以模拟实际应用中遇到的更复杂环境干扰。

为更直观的进行不同方法间重建指标的对比,各类方法在不同采样点数下的重建结果指标展示于图 8 中。随着噪声强度的增加和采样点数的减少,所有方法的重



(a) 不同方法的PSNR

(a) PSNR of different methods



(b) 不同方法的SSIM


(b) SSIM of different methods

图 8 基于随机稀疏采样磁场数据的重建结果

Fig. 8 Reconstruction metrics of randomly sampled sparse magnetic field data


建性能均出现不同程度的降低。然而,在各种条件下,所提方法始终优于 RsGAN 和 U-Net 两种对比模型。此外,在反映全局结构保真度的 SSIM 指标(图 8(b))中,尽管所提方法的性能也随噪声增强而有所降低,尤其在采样点数较少的情况下更为明显,但其性能下降幅度最小。值得注意的是,标准差为 0.20 和 0.25 的高斯噪声并未出现在训练数据中,而所提方法仍能保持良好表现,充分验证了其优异的泛化能力与对复杂噪声环境的适应性。

为更直观地展示不同方法的重建效果,图 9 展示了在仿真测试数据和实测励磁电路板数据上的重建结果。需要说明的是,由于 U-Net 依赖成对的“稀疏-稠密”数据进行训练,而本文对所有方法均仅使用稀疏数据进行训练,导致其训练不稳定且重建质量较差。




(a) 仿真数据重建结果

(a) Reconstruction results on simulation data



(b) 1号励磁电路板磁场重建结果

(b) Reconstruction results of excitation circuit board 1



(c) 2号励磁电路板磁场重建结果

(c) Reconstruction results of excitation circuit board 2

图9 基于随机稀疏采样数据的高分辨率磁场重建图像

Fig. 9 Reconstructed images of randomly sampled sparse magnetic field data

因此,图9中并未展示 U-Net 重建结果,而是重点关注与 RsGAN 的对比。仿真与实测数据的结果均表明,尽

管在无监督训练条件下,两种方法均不可避免地出现了局部细节失真,但本文方法基于多尺度信息补全模块能够更有效地推断并补全采样点之间的缺失信息,在边缘连续性和平滑度上表现更优,显著提升了重建质量。

3.2 均匀采样条件下高分辨率磁场重建性能分析

在实际磁场监测应用中,均匀排布的阵列磁传感器是一种更为常见的方式。为验证所提方法在该常见采样模式下的适用性,本节首先使用所提方法对均匀采样的多种采样密度进行了初步实验测试,使用含标准差为 0.1 的高斯噪声的稀疏磁场进行推理验证与指标计算,所提出模型在不同均匀采样密度下的重建数据 PSNR 指标变化趋势如图 10 所示。




图10 不同均匀采样密度下重建指标变化趋势

Fig. 10 Variation trend of reconstruction metrics under different uniform sampling densities

如图 10 所示,在初步测试中,随着采样点数的增加,模型的重建结果指标逐渐趋于“饱和”。在满足高分辨率磁场重建的需求的前提下,进一步采集更密集的均匀稀疏磁场数据时,其采样时间会大幅度上升,而重建指标则上升速度缓慢,逐步进入瓶颈。这一现象与稀疏数据重建领域中普遍存在的边际效益递减规律相符^[28]。在空间场重建任务中,当采样密度越过特定阈值后,继续增加观测点所带来的精度收益将远低于其付出的时间或硬件成本^[29]。而当均匀采样点逐步变得稀疏,在接近 10×10 采样密度时,模型的重建指标也出现了明显的下降。在接近 10×10 均匀采样及更为稀疏的均匀采样方式时,模型的稀疏数据重建结果不满足重建需求,本文所提出的磁场重建方法不再适用。

综合上述实验结果与现有研究的权衡准则^[30],均匀采样密度为 25×25 的采样方式在有着较高的重建精度的前提下,总体采样点数适中,是本方法重建精度与采集时效的综合平衡点。因此,本节使用 25×25 的均匀采样数据作为典型案例,以评估对比各类方法的重建性能。此外,除了上节选用的 RsGAN 和 U-Net 两类基于稀疏数据的重建网络外,本节进一步引入超分辨率卷积神经网络(super-resolution convolutional neural network, SRCNN)作

为额外对比基准。其中,3类基于稀疏数据的重建方法(包括所提方法)均仅使用稀疏磁场数据输入进行训练,而SRCNN则用了成对的高低分辨率磁场数据进行训练。各模型在测试集上的重建指标统计值如图11所示。




图11 基于均匀稀疏采样磁场数据的重建结果

Fig. 11 Reconstruction metrics of uniformly sampled sparse magnetic field data

由于数据集中包含多种复杂程度的数据,所有方法的测试标准差均偏高,但本文所提方法在所有噪声条件下均有最优的重建质量。尽管SRCNN在训练阶段利用了成对的高分辨率图像作为额外监督信息,但其模型整体重建能力较弱,对于复杂数据下的高倍率的超分效果有限。相比之下,本文所提方法在所有测试噪声水平下均展现出最优的重建性能,各项指标始终显著高于其他对比方法。尤其是在高噪声环境下,所提方法仍能保持较高的重建质量,且其性能衰减趋势较为平缓,展现出较强的鲁棒性与实际应用潜力。

图12展示了均匀采样条件下,各种方法对于仿真测试数据和实测励磁电路板数据的重建结果,噪声标准差设为0.1。

由图12可知,SRCNN在该噪声水平下无法有效分离背景噪声与有效信号,导致磁场的轮廓发生显著畸




图12 基于均匀稀疏采样数据的高分辨率磁场重建图像

Fig. 12 Reconstructed images of uniformly sampled sparse magnetic field data

变。U-Net在无监督训练条件下,仅能恢复磁场的整体分布趋势,细节信息严重缺失,重建质量有限。RsGAN相比前两种方法在去噪性能上有所提升,但仍难以合理补全采样缺失区域的信息,在磁场边缘处存在不连续的断裂现象。相比之下,所提方法不仅实现了对背景噪声的有效抑制,而且在磁场边界处恢复出平滑、连贯的结构细节,显著优于对比方法,达到了最佳的重建效果。

3.3 采集效率分析

本文提出的基于多尺度信息补全网络的高分辨率磁场数据快速采集方法,其采集效率相较于传统的直接采集方法有显著提升。以从 25×25 均匀稀疏采样重建 128×128 高分辨率磁场数据为例进行说明。根据表1中不同采样点数对应的采集时间,直接采集 128×128 高分辨率磁场数据耗时达103.34 min,而采集 25×25 稀疏磁场数据的理论耗时为4.06 min,采集时间缩短至原方法的3.9%,效率提升超过25倍。此外,模型单次重建一张高分辨率图像的时间通常仅为数十至数百毫秒,相对于采集过程可忽略不计。因此,通过“稀疏采集+深度学习重建”的策略,本方法以不足4%的数据采集量可获得高分辨率磁场分布,不仅大幅压缩了数据获取时间,也降低了数据存储与传输负担,为高精度、高效率的实时磁场监测提供了可行路径。

3.4 讨论

本文针对稀疏磁场数据的重建问题,在借鉴现有“降采样预处理结合超分辨率重建”分阶段处理稀疏数据的思路,深入剖析并克服了传统方法的局限性。现有方法(如RsGAN^[20])在降采样阶段多采用物理池化,这种机械的“有损映射”极易抹除原始采样点的高频特征。同时,该机制面对均匀分布或极稀疏的采样点时,极易产生“信息空洞”,导致后续重建缺失引导信息。为此,本文提出了多尺度信息补全模块,通过将稀疏数据映射至多个低分辨率尺度进行特征融合,从根本上保留了原始采样数据的空间结构信息。此外,相比于局限于随机采样的传统方法,本文方法更贴合实际工程中磁场传感器规则网格布置的场景,有效提升了网络在处理规则、均匀稀疏磁场数据时的鲁棒性与实用价值。

然而,本研究目前仍存在一定的局限性,本文采用的无监督学习框架虽摆脱了网络训练对完整高分辨率真实数据的依赖,但也导致模型缺乏对复杂数据纹理细节的直接学习,针对复杂数据的重建结果仍存在部分细节特征丢失的现象。因此,未来的研究工作将重点聚焦于进一步提升稀疏数据重建网络对复杂细节的恢复能力,以期在保持不依赖完整高分辨率数据这一优势的前提下,突破极端稀疏条件与复杂纹理细节的重建瓶颈。

4 结论

本文提出了一种高分辨率磁场数据快速采集方法,基于可快速采集的稀疏磁场数据重建出完整高分辨率磁场数据,显著提升了磁场数据采集效率,并兼具良好的去噪性能。该方法摆脱了对成对高低分辨率训练样本的依

赖,仅利用易于采集的稀疏磁场数据即可完成模型训练与高精度重建,从根本上解决了传统超分辨率方法训练数据获取成本高、周期长的难题。

模型通过多尺度信息补全模块,将稀疏磁场数据映射至多个低分辨率尺度进行特征融合,充分挖掘邻近区域磁场数据间的空间关联性,在滤除干扰的同时有效补全缺失位置的磁场信息,实现了高分辨率磁场数据的高精度重建。在随机稀疏采样与均匀稀疏采样两种典型场景下,本文利用仿真与实测数据对所提方法与现有稀疏重建网络(如RsGAN、U-Net)及超分辨率模型(如SRCNN)进行了系统对比。实验结果表明,本方法在不同采样点数及噪声程度下均表现出更优的重建性能,充分验证了其有效性、鲁棒性以及实际应用潜力。

在未来的研究中,首先将致力于本方法的进一步重建性能改进,尝试引入更精细的物理信息局部特征约束机制,以突破极端稀疏条件与复杂纹理细节的重建瓶颈。其次,尝试将本方法与现有基于磁场的故障诊断技术的深度融合与适配。一方面,探索本方法与磁场故障监测算法的协同机制,构建基于稀疏传感输入的高精度诊断新范式,进一步降低系统成本;另一方面,推进算法的轻量化设计与边缘部署,提升其在边缘计算设备上的实时处理能力,以适应更广泛、复杂的工业现场动态监测需求。

参考文献

- [1] 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.
- [2] 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.
- [3] 廉正,刘斌,刘桐,等.基于双磁场管道复合型缺陷应力信号提取方法研究[J].仪器仪表学报,2023,44(3):107-118.
LIAN ZH, LIU B, LIU T, et al. Research on the stress signal extraction method of pipeline composite defect

- based on dual magnetic field[J]. Chinese Journal of Scientific Instrument, 2023, 44(3): 107-118.
- [4] 刘斌, 罗宁, 武梓涵, 等. 基于双磁场的管道非体积损伤检测研究[J]. 仪器仪表学报, 2024, 45(8): 77-91.
- LIU B, LUO N, WU Z H, et al. Research on non-volume damage of pipeline based on dual magnetic field detection[J]. Chinese Journal of Scientific Instrument, 2024, 45(8): 77-91.
- [5] SONG J C, WU X H, QIAN L, et al. PMSLM eccentricity fault diagnosis based on deep feature fusion of stray magnetic field signals[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 73: 3506012.
- [6] LIU ZH Y, SUN Y N, MAO L, et al. Efficient fault diagnosis of proton exchange membrane fuel cell using external magnetic field measurement[J]. Energy Conversion and Management, 2022, 266: 115809.
- [7] LE H, VAN LUONG S, LE M. Development of magnetic image super-resolution model for nondestructive testing[J]. Measurement Science and Technology, 2023, 34(12): 125907.
- [8] 程德强, 郭昕, 陈亮亮, 等. 多通道递归残差网络的图像超分辨率重建[J]. 中国图象图形学报, 2021, 26(3): 605-618.
- CHENG D Q, GUO X, CHEN L L, et al. Image super-resolution reconstruction from multi-channel recursive residual network[J]. Journal of Image and Graphics, 2021, 26(3): 605-618.
- [9] 熊巍, 熊承义, 高志荣, 等. 通道注意力嵌入的Transformer 图像超分辨率重构[J]. 中国图象图形学报, 2023, 28(12): 3744-3757.
- XIONG W, XIONG CH Y, GAO ZH R, et al. Image super-resolution with channel-attention-embedded Transformer[J]. Journal of Image and Graphics, 2023, 28(12): 3744-3757.
- [10] CHEN ZH, ZHANG Y L, GU J J, et al. Dual aggregation transformer for image super-resolution[C]. 2023 IEEE/CVF International Conference on Computer Vision, 2023: 12278-12287.
- [11] LI H Y, YANG Y F, CHANG M, et al. Srdiff: Single image super-resolution with diffusion probabilistic models[J]. Neurocomputing, 2022, 479: 47-59.
- [12] CHEN X Y, WANG X T, ZHOU J T, et al. Activating more pixels in image super-resolution transformer[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 22367-22377.
- [13] HU ZH Y, LIANG H Y, XU J W, et al. Network-assisted super-resolution imaging of magnetic fields under noisy conditions[J]. IEEE Sensors Journal, 2025, 25(17): 33620-33632.
- [14] 邹承权, 黄江成, 孙正宝, 等. 遥感图像超分辨率重建方法: 综述与实验[J]. 遥感技术与应用, 2025, 40(4): 969-989.
- ZOU CH Q, HUANG J CH, SUN ZH B, et al. Super-resolution reconstruction methods for remote sensing images: A review and experiments[J]. Remote Sensing Technology and Application, 2025, 40(4): 969-989.
- [15] 田苗苗, 支力佳, 张少敏, 等. 医学CT影像超分辨率深度学习方法综述[J]. 计算机工程与应用, 2024, 60(3): 44-60.
- TIAN M M, ZHI L J, ZHANG SH M, et al. Review of deep learning methods applied to medical CT super-resolution[J]. Computer Engineering and Applications, 2024, 60(3): 44-60.
- [16] 唐艳秋, 潘泓, 朱亚平, 等. 图像超分辨率重建研究综述[J]. 电子学报, 2020, 48(7): 1407-1420.
- TANG Y Q, PAN H, ZHU Y P, et al. A survey of image super-resolution reconstruction[J]. Acta Electronica Sinica, 2020, 48(7): 1407-1420.
- [17] WANG X, YI J L, GUO J, et al. A review of image super-resolution approaches based on deep learning and applications in remote sensing[J]. Remote Sensing, 2022, 14(21): 5423.
- [18] WANG P R, ZHANG H P, ZHOU F, et al. Unsupervised remote sensing image super-resolution using cycle CNN[C]. 2019 IEEE International Geoscience and Remote Sensing Symposium, 2019: 3117-3120.
- [19] TANG SH H, DING Y SH, ZHOU H W, et al. Reconstruction of sparsely sampled seismic data via residual U-Net[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 19: 1-5.
- [20] ALEJANDRO G, CARLOS S V, STEFANO D. Super-resolution generative adversarial networks of randomly-seeded fields[J]. Nature Machine Intelligence, 2022, 4(12): 1165-1173.
- [21] 赵鑫宇, 张宁. 受空间天气影响的地磁导航装置磁场

干扰噪声研究[J]. 长春理工大学学报(自然科学版), 2023, 46(3): 78-86.

ZHAO X Y, ZHANG N. Study of magnetic field interference noise in geomagnetic navigation devices affected by space weather [J]. Journal of Changchun University of Science and Technology, 2023, 46(3): 78-86.

[22] 胡书正, 王骁贤, 宋俊材, 等. 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[J]. 仪器仪表学报, 2024, 45(7): 227-238.

HU SH ZH, WANG X X, SONG J C, et al. Magnetic field signal denoising based on auxiliary sensor array and NECNN-BiLSTM deep neural networks [J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 227-238.

[23] 刘斌, 谢明玲, 员朝鑫, 等. 隧穿磁电阻效应磁场传感器中的噪声分析及降低噪声的方法[J]. 甘肃科技, 2024, 40(3): 1-4,9.

LIU B, XIE M L, YUAN CH X, et al. Analysis of noise in TMR magnetic sensor and methods to reduce the noise[J]. Gansu Science and Technology, 2024, 40(3): 1-4,9.

[24] 郭玥秀, 杨伟, 刘琦, 等. 残差网络研究综述[J]. 计算机应用研究, 2020, 37(5): 1292-1297.

GUO Y X, YANG W, LIU Q, et al. Survey of residual network[J]. Application Research of Computers, 2020, 37(5): 1292-1297.

[25] ZHANG K, SUN M, HAN T X, et al. Residual networks of residual networks: Multilevel residual networks [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 28(6): 1303-1314.

[26] SHRIVASTAVA A, PFISTER T, TUZEL O, et al. Learning from simulated and unsupervised images through adversarial training [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2242-2251.

[27] HAN Y, YE J C. Framing U-Net via deep convolutional framelets: Application to sparse-view CT [J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1418-1429.

[28] MANOHAR K, BRUNTON B W, KUTZ J N, et al. Data-driven sparse sensor placement for reconstruction: Demonstrating the benefits of exploiting known pat-

erns[J]. IEEE Control Systems, 2018, 38(3): 63-86.

[29] FUKAMI K, MAULIK R, RAMACHANDRA N, et al. Global field reconstruction from sparse sensors with Voronoi tessellation-assisted deep learning [J]. Nature Machine Intelligence, 2021, 3(11): 945-951.

[30] ZOU Y Q, CHEN W X, LIANG T X, et al. Efficiency evaluation of sampling density for indoor building LiDAR point-cloud segmentation[J]. Sensors, 2025, 25(20): 6398.

作者简介



胡智勇, 2011 年于安徽工业大学获得学士学位, 2016 年于中国科学技术大学获得硕士学位, 2021 年于美国德克萨斯理工大学获得博士学位。现为安徽大学电气工程与自动化学院讲师, 主要研究方向为复杂系统监测、分析与控制中的多流数据分析统计建模。

E-mail: hzyllwen@ahu.edu.cn

Hu Zhiyong received his B. Sc. degree from Anhui University of Technology in 2011, his M. Sc. degree from the University of Science and Technology of China in 2016, and his Ph. D. degree from Texas Tech University, USA, in 2021. He is currently a lecturer in the School of Electrical Engineering and Automation at Anhui University. His main research interests include multistream data analysis and statistical modeling in complex system monitoring, analysis, and control.



陈文越, 2024 年于华侨大学获得学士学位, 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状态监测。

E-mail: z24301163@stu.ahu.edu.cn

Chen Wenyue received his B. Sc. degree in 2024 from Huaqiao University. He is currently a master's student in the School of Electrical Engineering and Automation at Anhui University. His main research interests include signal processing and condition monitoring.



宋俊材, 分别于 2014、2017、2020 年获得安徽大学学士、硕士、博士学位, 现为安徽大学互联网学院副教授, 主要研究方向为电机故障诊断、直线电机设计优化、电能质量扰动识别。

E-mail: songjuncai@ahu.edu.cn

Song Juncai received his B. Sc., M. Sc., and Ph. D. degrees all from Anhui University in 2014, 2017, and 2020, respectively. He is currently an associate professor in the School of Internet at Anhui University. His main research interests include motor fault diagnosis, design optimization of linear

motors, and power quality disturbance recognition.



陆思良, 分别于 2010 年、2015 年获得中国科学技术大学学士、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 received his B. Sc. and Ph. D. degrees both from the University of Science and Technology of China in 2010 and 2015, respectively. He is currently a professor in the School of Electrical Engineering and Automation at Anhui University. His main research interests include condition monitoring and fault diagnosis of electromechanical systems, signal processing, Internet of Things, and edge computing.



王晓贤 (通信作者), 2010 年于山东科技大学获得学士学位, 分别于 2013 年、2024 年获得中国科学技术大学硕士、博士学位。现为安徽大学电子信息工程学院副教授, 主要研究方向为信息处理、深度学习、机器人、工业自动化。

E-mail: xiaoxian@ahu.edu.cn

Wang Xiaoxian (Corresponding author) received her B. Sc. degree from Shandong University of Science and Technology in 2010, and her M. Sc. and Ph. D. degrees both from the University of Science and Technology of China in 2013 and 2024, respectively. She is currently an associate professor in the School of Electronic Information Engineering at Anhui University. Her main research interests include information processing, deep learning, robotics, and industrial automation.