

磁定位中基于神经网络的生成模型数据增强方法

王振学¹ 杨其宇¹ 梁文虎¹

WANG Zhenxue YANG Qiyu LIANG Wenhui

摘要

磁定位技术在舌运动追踪、神经康复和精准医疗等领域具有广泛应用。但传统磁定位系统受限于数据采集成本高、空间数据分布稀疏、生成质量不足与缺乏区域适应性问题，导致训练模型性能受限。基于此，提出了一种基于空间区域感知的神经网络生成模型数据增强方法，通过空间划分与门控多层感知器（gMLP）神经网络相结合，生成高质量的磁场数据。首先，将磁场数据空间划分为若干子区域，并为每个子区域建立独立的gMLP生成子模型网络，用于学习该区域的磁场数据分布特征；其次，输入新的空间坐标到对应训练好的gMLP子模型网络中，生成高质量的磁场数据；最后，将生成数据填充到原始数据集中，形成扩充数据集。通过实验验证，所提方法有效提升了磁定位系统在复杂场景中的鲁棒性与定位精度，为舌运动追踪等磁定位应用提供了高效的数据增强方案。

关键词

磁定位；生成模型；数据增强；空间区域感知；gMLP

doi: 10.3969/j.issn.1672-9528.2025.06.032

0 引言

永磁体定位（permanent magnetic localization, PML）技术已广泛应用于无线运动检测、医学诊断与治疗中，如胶囊内窥镜^[1-3]与舌运动追踪^[4-6]等。尽管PML在实际应用中取得了良好效果，但面临数据采集成本高、空间数据分布稀疏、生成质量不足与缺乏区域适应性问题，严重制约了模型的训练性能与泛化能力。

传统数据增强主要包括随机噪声注入与线性插值方法。例如，随机噪声方法通过对原始磁场数据施加高斯噪声^[7]，提高数据集的多样性。然而，这种方法无法捕捉磁场数据的复杂非线性特征，易导致模型泛化性能下降。此外，线性插值方法^[8]在空间位置生成新样本，但生成数据的真实性较低，无法准确反映实际磁场分布的非线性变化。为提高神经网络模型的训练性能与泛化能力，Sebkhi等人^[9]在10 cm×10 cm×10 cm的体积内采集了170多万个样本，在很大程度上增加了数据采集成本。为减少真实数据采集的工作量，近年来，基于磁场物理模型的仿真数据生成方法逐渐兴起。例如，Qin等人^[10]利用磁偶极子模型生成模拟数据集，并使用这些数据进行神经网络预训练。但由于磁偶极子模型本身的简化假设，生成数据存在一定的模型偏差，导致与真实数据存在较大差异，影响了模型的泛化能力。此外，系统误差与标定误差的累积进一步降低了模拟数据的质量。

为了弥补模拟数据的缺陷，Fu等人^[11]提出了一种基于迁移学习的神经网络集合方法。结合模拟数据与真实数据（约20 000个样本）进行训练，通过迁移学习减少对大规模真实数据的依赖。然而，迁移学习方法依赖于模拟数据的精确性，而模拟数据的迭代优化仍然受到磁偶极模型近似误差的影响。

针对上述问题，本文提出了一种基于空间区域感知的神经网络生成模型数据增强方法，主要工作贡献如下：

（1）提出一种基于空间区域感知的方法，对独立的每个传感器，分别划分若干个空间子区域，并为每个子区域建立独立的gMLP生成子模型网络，精细建模每个独立传感器各个子区域内磁场数据的非线性分布。

（2）利用gMLP结构轻量化、计算高效的特点，在小规模真实数据的基础上生成高质量、分布均匀的磁场数据。

（3）将生成数据填充到原始数据集中，形成扩充数据集，显著提升磁定位模型的泛化性能与鲁棒性。

1 数据集

如图1所示，本文使用机器臂携带小磁铁（直径：6.02 mm，厚度：1.01 mm，重量：0.08 g，残留磁感应：18 500 Gs），在5 cm×7 cm×4 cm磁跟踪系统的工作空间内，沿立方体轨迹移动机器臂，收集磁铁方向变化时的数据，构成用于训练和评估磁定位系统中神经网络的数据集。本文总共收集了137条轨迹的磁铁的磁场数据和位置数据，记为：

$$S_i = \{\xi_i', x_i', y_i', z_i', \theta_i', \phi_i'\}_{i=1}^{137}, \quad i=1, 2, \dots, 137 \quad (1)$$

1. 广东工业大学 广东广州 511400

式中: T_i 是轨迹 i 中的样本数量, 每个轨迹约有 1 200 个样本; x'_i 、 y'_i 和 z'_i 是轨迹 i 中第 t 个样本的三维位置; θ'_i 和 ϕ'_i 是俯仰角和偏航角; $\xi'_i \in R^{96}$ 是传感器数据。




图 1 数据采集与校准系统

在收集的 137 组数据中, 有 77 组数据用于训练和验证的数据集, 覆盖范围偏航角为 $\pm 50^\circ$, 步长为 10° , 俯仰角为 $\pm 90^\circ$, 步长为 30° , 记为:

$$D_{tr} = \{S_j\} \begin{cases} \theta_j \in [-90^\circ, 30^\circ, 90^\circ] \\ \phi_j \in [-50^\circ, 10^\circ, 50^\circ] \end{cases}, \quad j = 1, 2, \dots, 77 \quad (2)$$

为确保训练和验证数据包含所有角度的信息并避免对训练集过拟合, 将 D_{tr} 的 80% 随机分割为训练集, 剩下 20% 作为验证集。

剩余 60 组数据则是用来作为测试集, 覆盖范围偏航角为 $\pm 45^\circ$, 步长为 10° , 俯仰角为 $\pm 75^\circ$, 步长为 30° , 记为:

$$D_{ts} = \{S_k\} \begin{cases} \theta_k \in [-75^\circ, 30^\circ, 75^\circ] \\ \phi_k \in [-45^\circ, 10^\circ, 45^\circ] \end{cases}, \quad k = 1, 2, \dots, 60 \quad (3)$$

式中: D_{tr} 和 D_{ts} 位置没有重叠。

2 方法

2.1 空间区域划分

因磁铁产生的磁场在空间的不同区域具有不一致的效果, 当磁铁离传感器太远或太近时, 传感器收集的磁场强度数据与磁铁的位置之间的关系无法准确地用欧拉方程描述。为提高生成训练样本集质量与区域适应性, 本文提出一种基于空间区域感知的方法。如图 2 所示, 将空间区域划分为 8 个子区域, 每个子区域的体积为 $2.5 \text{ cm} \times 3.5 \text{ cm} \times 2.0 \text{ cm}$ 。使用 32 个磁传感器布置于磁场检测空间, 覆盖目标区域。每个传感器的检测空间被均匀划分为 8 个子区域, 从而总计形成 256 个空间子区域。




图 2 空间区域划分示意图

2.2 空间子区域建立局部模型

256 个空间子区域, 每个空间子区域内建立独立的 gMLP 生成子网络, 用于学习磁场数据分布特征。

如图 3 所示, 本文中的神经网络主要基于门控多层感知器构建。该模型由 N ($N=3$) 个具有相同结构和大小的堆栈块组成。所有投影操作均为线性, “ $\times$ ” 表示元素逐个乘法。




图 3 门控多层感知器架构图

层指的是层规范化。在第一个线性层中, 五维的磁铁位置数据被映射到一个高维潜在特征空间。将得到的高维特征空间分为多个通道和维度。这种分组策略降低了每个通道内的计算复杂性, 从而降低了模型的整体计算成本, 并在模型复杂性和计算效率之间取得了平衡。在每个门控多层感知器中, 每个通道都经过两个线性映射 (通道投影), 使得不同通道之间的信息可以交互和融合。随后, 特征通过空间门控单元进行组间交互。门控操作生成一个门特征掩码, 控制信息的流动和融合, 从而抑制噪声和冗余。空间门控单元通过对每个通道的特征应用一维卷积操作来引入组间交互, 然后通过与门特征的元素逐个乘法进行特征融合。一维卷积的输入通道和输出通道相同, 步幅为 2, 核大小为 5。这些交互机制使模型能够捕获多个维度的信息, 从而增强其表达能力。

2.3 数据生成和数据集增强

使用原始数据集 D_{tr} , 对 256 个 gMLP 子模型网络进行独立训练, 使每个子模型网络精准建模对应子区域的磁场分布; 对原始数据集 D_{tr} 进行线性插值合成新的位置数据, 记为:

$$P = \left\{ \frac{1}{2}(x'_i + x'_{i+1}), \frac{1}{2}(y'_i + y'_{i+1}), \frac{1}{2}(z'_i + z'_{i+1}), \right. \\ \left. \frac{1}{2}(\theta'_i + \theta'_{i+1}), \frac{1}{2}(\phi'_i + \phi'_{i+1}) \right\} \quad (4)$$

式中: $P = \{x, y, z, \theta, \phi\}$ 是合成的新位置数据。

将合成新的位置数据输入到对应训练好的 gMLP 子模型网络中, 从而生成高质量的磁场数据 D_{tr}' ; 最后将生成的磁场数据与原始数据集 D_{tr} 合并, 形成扩充数据集, 记为:

$$D_{tr}'' = D_{tr} + D_{tr}' \quad (5)$$

D_{tr} 在空间覆盖率和数据多样性上优于原始数据集 D_{tr} , 能够有效解决数据稀缺与分布不均的问题。

3 实验与结果分析

3.1 生成模型数据增强

在实际应用的数据采集过程中, 为降低数据采集的时间成本, 通常采用数据生成策略。基于实际采集的稀疏原始数据集, 利用生成模型来生成数据, 填充稀疏原始数据集, 以评估在采样不足的情况下生成模型对神经网络性能的影响。

本文提出的基于空间区域感知的神经网络生成模型数据增强方法具体过程如下:

步骤 1: 32 个传感器, 对独立的每个传感器, 分别划分 8 个空间子区域建立生成子模型, 共计 256 个磁场数据生成子模型。

步骤 2: 256 个磁场数据生成子模型均采用 gMLP 作为神经网络训练模型, 使用原始数据集 D_{tr} 训练各个磁场数据生成子模型, 神经网络的构建和训练基于 PyTorch, 使用 Adam 作为优化器, 学习率为 0.001, 迭代次数为 200, 输入是 5 维位置数据, 输出是三维磁场强度数据, 损失函数为均方根误差 (root mean square error, RMSE), 记为:

$$L_1(w_s) = \frac{1}{N_s} \sum_{i=1}^{N_s} \|F(y'_i; w_s) - \xi'_i\|^2, \quad i=1, 2, \dots, 32 \quad (6)$$

式中: N_s 表示位于子区域 s 的样本数量; $F(\cdot)$ 表示 gMLP 网络; w_s 表示待训练的可学习参数; $y'_i \in R^5$ 表示传感器 i 中第 t 个样本的磁示踪剂的位置和角度; $\xi'_i \in R^3$ 表示传感器 i 中第 t 个样本对应的磁场强度数据。

步骤 3: 由原始数据集 D_{tr} 做线性插值合成新的位置数据 P , 将合成的新位置数据输入到训练好的磁场数据生成子模型中, 生成相对应的磁场数据, 得到生成的数据集 D_{tr}' 。

步骤 4: 将生成的磁场数据集 D_{tr}' 填充到原始数据集 D_{tr} 中, 得到扩充后的训练数据集 D_{tr}'' 。

3.2 定位性能评估

为评估本文提出的基于空间区域感知的神经网络生成模型数据增强方法的有效性, 通过磁铁的定位误差来衡量模型在测试集上的预测精度, 这里使用磁铁的预测位置数据和实际位置数据的均方根误差 RMSE 作为定位精度评估, 记为:

$$L_2(w_s) = \frac{1}{N_s} \sum_{i=1}^{N_s} \|F(\xi_i; w_s) - y_i\|^2 \quad (7)$$

式中: $y_i \in R^5$ 表示样本 i 的磁示踪剂的位置和角度; $\xi_i \in R^3$ 表示样本 i 对应的磁场强度数据。

本文使用基于区域感知的空间-角度集成 (spatial-angular ensemble, SAE) [8] 和多层感知器 (multi-layer perception, MLP) [9] 两种磁定位算法进行定位性能评估实验, 分别使用

原始数据集 D_{tr} 和本文提出的基于空间区域感知的神经网络生成模型数据增强方法扩充后的数据集 D_{tr}'' 进行模型训练, 然后在测试集上进行测试, 验证本文提出的数据增强方法对 PML 系统性能的提升效果。

两种神经网络定位算法 MLP 和 SAE 的构建和训练均基于 PyTorch, 使用 Adam 作为优化器, 学习率为 0.001, 迭代次数为 200, 损失函数为均方根误差 RMSE。

3.3 实验结果与分析

基于数据集 D_{tr} 和 D_{tr}'' 的不同网络的磁铁位置 P 和姿态角 (θ, ϕ) 均方根误差定位性能比较如表 1 所示, 其定位性能在位置和角度上的均方根误差 RMSE, 记为:

$$E_p = \frac{1}{K} \sum_{k=1}^K \sqrt{\frac{1}{n_k} \sum_{i=1}^{n_k} \|\tilde{p}_k^i - p_k^i\|^2} \quad (8)$$

$$E_\theta = \frac{1}{K} \sum_{k=1}^K \sqrt{\frac{1}{n_k} \sum_{i=1}^{n_k} (\tilde{\theta}_k^i - \theta_k^i)^2} \quad (9)$$

$$E_\phi = \frac{1}{K} \sum_{k=1}^K \sqrt{\frac{1}{n_k} \sum_{i=1}^{n_k} (\tilde{\phi}_k^i - \phi_k^i)^2} \quad (10)$$

式中: $\tilde{p}_k^i$ 、 $\tilde{\theta}_k^i$ 和 $\tilde{\phi}_k^i$ 分别是在轨迹 k 中样本 i 输入磁场强度数据到模型中, 输出预测的磁铁位置和角度值; p_k^i 、 θ_k^i 和 ϕ_k^i 则是实际值; n_k 是轨迹 k 的样本数量; K 是轨迹数量。





从表 1 可看出, 本文提出的基于空间区域感知的神经网络生成模型数据增强方法进行数据扩展被证明在提高模型的定位和定位精度方面非常有益。例如, 基于数据集 D_{tr}'' 与基于数据集 D_{tr} 的 MLP 定位算法相比, 基于数据集 D_{tr}'' 的 MLP 对位置、俯仰角和偏航角的预测精度分别提高了 34.42%、17.72% 和 32.42%, 而对于 SAE 定位算法来说, 基于数据集 D_{tr}'' 的 SAE 对位置、俯仰角和偏航角的预测精度分别显著提高了 29.30%、25.48% 和 39.90%。生成模型的应用进一步放大了各模型的优势, 显著提高了定位和定位精度。

表 1 基于数据集 D_{tr} 和 D_{tr}'' 不同算法定位精度

	E_p/mm	$E_\theta/^\circ$	$E_\phi/^\circ$
MLP (D_{tr})	4.59	3.95	8.76
MLP (D_{tr}'')	3.01	3.25	5.92
SAE (D_{tr})	1.57	2.59	6.14
SAE (D_{tr}'')	1.11	1.93	3.69

如表 2 所示, 展示了不同算法分别基于数据集 D_{tr} 和 D_{tr}'' 在特定角度条件下 ($\theta = -45^\circ$, $\phi = -5^\circ$) 对轨迹预测的结果, 其中实际轨迹是立方体轨迹。从表 2 可以直观地看出, 相较于基于数据集 D_{tr} 的 MLP 和 SAE 两种定位算法网络定位结果预测轨迹, 基于数据集 D_{tr}'' 定位结果预测轨迹均与实际轨迹更加接近。

表 2 预测轨迹图示例

模型	轨迹 (D_{tr})	E_p/mm
MLP		3.29
SAE		1.11
模型	轨迹 (D_{tr}'')	E_p/mm
MLP		2.57
SAE		0.75

4 结语

本文提出的基于空间区域感知的神经网络生成模型数据增强方法生成的磁场数据在空间一致性和质量方面都得到了显著提高，为稀疏的训练数据集增强了多样性，有效提升了磁定位系统的精度。通过区域划分与局部建模，模型能够精细捕捉不同区域内磁场数据的变化，避免了传统方法中的全局建模所带来的过拟合问题。

尽管本方法在定位精度和模型鲁棒性上表现出色，但在实际应用中仍面临一些挑战。例如，数据集规模与模型训练时间之间的平衡问题，以及如何进一步优化生成模型的计算效率，仍然是未来研究的关键方向。

参考文献:

[1] WANG X N, MENG M Q H, HU C. A localization method using 3-axis magnetoresistive sensors for tracking of capsule endoscope[C/OL]//2006 International Conference of the IEEE Engineering in Medicine and Biology Society. Piscataway:IEEE, 2006[2024-09-12].<https://ieeexplore.ieee.org/document/4462308>. DOI:10.1109/IEMBS.2006.260711.

[2] SHAO G L, TANG Y C, TANG L,et al. A novel passive magnetic localization wearable system for wireless capsule endoscopy[J].IEEE sensors journal, 2019,19(9):3462-3472.

[3] HU C, MENG M Q H M, MANDAL M. Efficient magnetic localization and orientation technique for capsule endoscopy[C/OL]//2005 IEEE/RSJ International Conference on Intelligent Robots and Systems.Piscataway:IEEE,2005[2024-03-19].<https://ieeexplore.ieee.org/document/1545490>.DOI:10.1109/IROS.2005.1545490.

[4] SEBKHI N, BHAVSAR A, ANDERSON D V,et al.Inertial measurements for tongue motion tracking based on magnetic localization with orientation compensation[J].IEEE sensors journal, 2021,21(6):7964-7971.

[5] LU J, YANG Z T, OKKELBERG K Z,et al.Joint magnetic calibration and localization based on expectation maximization for tongue tracking[J].IEEE transactions on biomedical engineering,2018,65(1):52-63.

[6] HUO X L, WANG J, GHOVANLOO M.A magneto-inductive sensor based wireless tongue-computer interface[J].IEEE transactions on neural systems and rehabilitation engineering, 2008,16(5):497-504.

[7] ZHANG H Y, CISSE M, DAUPHIN Y N, et al.Mixup: beyond empirical risk minimization[EB/OL].(2018-04-27) [2024-06-11].<https://doi.org/10.48550/arXiv.1710.09412>.

[8] LU J, ZHENG F, ZHANG S H, et al.Regional perceptrons ensemble for permanent magnetic localization[J]. IEEE sensors journal, 2024,24(17): 28056-28067.

[9] SEBKHI N, SAHADAT N, HERSEK S,et al.A deep neural network-based permanent magnet localization for tongue tracking[J].IEEE sensors journal, 2018,19(20):9324-9331.

[10] QIN Y D, LÜ B, DAI H D, et al.An hFFNN-LM based real-time and high precision magnet localization method[J]. IEEE transactions on instrumentation and measurement, 2022,71: 1-9.

[11] FU Y M, GUO Y X.Guideline on initial point finding and search bounds setting for biomedical magnetic localization[J]. IEEE sensors journal, 2022,22(16):16492-16504.

【作者简介】

王振学（1998—），男，广东湛江人，硕士，研究方向：电磁系统建模和优化、生物信号处理。

杨其宇（1977—），男，广东湛江人，博士，副教授，研究方向：智能控制与数字信号处理。

梁文虎（1998—），男，广东茂名，人，硕士，研究方向：模式识别、生物信号处理。

（收稿日期：2024-12-23 修回日期：2025-04-29）