

DOI: 10.13382/j.jemi.B2104897

面向 PDR 定位系统的多层感知机 IMU 阵列数据融合方法^{*}

廖亚桢 刘 昱 张立强 李 虎 宫霄霖
(天津大学微电子学院 天津 300072)

摘 要:为提高低成本惯性测量单元(intertial measurement unit,IMU)阵列的行人航位推算(pedestrian dead reckoning,PDR)定位精度,首次提出了采用多层感知机(multi-layer perceptron,MLP)实现低成本 IMU 阵列数据融合的算法,通过将自主设计的 IMU 阵列和高精度 IMU 同步运动来获得 IMU 阵列的测量数据(包括三轴加速度和三轴角速度)和高精度 IMU 的测量数据,以高精度 IMU 的测量数据作为标签,利用 MLP 将 IMU 阵列的测量数据融合,预测出物体的实际加速度和角速度,并用定位算法进行验证。在定位实验中,使用 MLP 融合后的预测数据的 PDR 定位精度比使用单个 IMU 测量数据的 PDR 定位精度提高了 33.9%;比使用简单平均处理的 IMU 阵列测量数据的 PDR 定位精度提高了 20.8%;比使用最小二乘法融合的 IMU 阵列测量数据的 PDR 定位精度提高了 11.6%,证明了本文所提出方法的可行性和有效性。

关键词: 惯性测量单元阵列;行人航位推算;多层感知机;数据融合

中图分类号: TP391;TN98 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Multi-layer sensor IMU array data fusion method for PDR positioning system

Liao Yazhen Liu Yu Zhang Liqiang Li Hu Gong Xiaolin
(School of Microelectronics, Tianjin University, Tianjin 300072, China)

Abstract:In order to improve the positioning accuracy of pedestrian dead reckoning (PDR) for low-cost inertial measurement unit (IMU) arrays, this paper proposes for the first time the use of multi-layer perceptron (MLP) to achieve algorithms for low-cost IMU array data fusion. The measurement data of the IMU array (including triaxial acceleration and triaxial angular velocity) and the measurement data of the high-precision IMU are obtained by synchronizing the motion of the self-designed IMU array and the high-precision IMU, and the measurement data of the high-precision IMU is used as a label. The MLP fuses the measurement data of the IMU array, predicts the actual acceleration and angular velocity of the object, and uses the positioning algorithm to verify it. In the localization experiment, the PDR localization accuracy using the prediction data fused by MLP is 33.9% higher than the PDR localization accuracy using a single IMU measurement data; it is 20.8% higher than the PDR localization accuracy using the simple average processing IMU array measurement data; it is 11.6% higher than the PDR localization accuracy using the IMU array measurement data fused by the least square method, which proves the feasibility and effectiveness of the method proposed in this paper.

Keywords: inertial measurement unit array; pedestrian dead reckoning; multi-layer perceptron; data fusion

0 引 言

位置服务(location based services,LBS)指的是向人们提供和位置相关的服务,例如:路线规划,位置查询等。近年来人们在衣食住行的各个方面都对位置服务的需求

越来越强烈,且对位置服务的精度和可靠性要求越来越高。而想要向人们提供位置服务,则首先需要进行行人定位,如今行人室外定位主要依赖于全球导航卫星系统(global navigation satellite system,GNSS),因为在开阔的室外环境中,GNSS 可以提供比较精确的位置信息。但是 GNSS 并不能够覆盖人类活动的全部区域,在一些隧道、

山洞以及室内环境下,由于墙体等物体对 GNSS 信号遮挡严重,信号会大幅衰减导致定位出现较大偏差。2013 年,国家发布的《室内外高精度定位导航白皮书》中指出,人们至少有 80% 的时间处于室内环境中,因此行人室内定位成为了位置服务的一个重要研究方向。在行人室内定位中,基于 WiFi 和磁场的定位已经被用于日常生活,但是仅使用 WiFi 或磁场的室内定位方法在实际应用中定位精度较低,所以目前大多数的室内定位还是基于惯性测量单元的惯性导航系统,通过消费级的超低成本的单一惯性测量单元(intertial measurement unit, IMU)采集的数据进行位置推算^[1]。超低成本 IMU 具有产量大、价格低和功耗小的优点,将其应用于行人位置推算具有重要的价值,但由于超低成本 IMU 存在稳定性不足的问题,无法独立实现长时间的行人跟踪。文献[2-3]提出了一种在单个印制电路板(printed circuit board, PCB)上组合多个 IMU 形成一个阵列的方法,通过对 IMU 阵列的测量数据进行数据处理以创建虚拟高性能传感器。使用 IMU 阵列不仅能够提高测量精度,还可以检测和隔离传感器故障,提高了操作的可靠性^[4-5],此外,IMU 阵列冗余的测量可用于估计测量误差的协方差,进而确定测量的可靠性^[6]。然而,使用 IMU 阵列时存在两个避不开的问题:1) 如何对 IMU 阵列的安装误差进行校准;2) 如何精确表示 IMU 阵列的测量数据和物体实际的加速度、角速度的关系并将 IMU 阵列的测量数据转换成物体实际的加速度、角速度。

为了解决上述两个问题,本文首次提出了采用多层感知机(multi-layer perceptron, MLP)实现 IMU 阵列数据融合的算法,并通过实验证明了此方法的可行性和有效性,主要贡献如下:

1) 设计了一套 IMU 阵列数据同步采集系统,由低成本 IMU 阵列板和高精度 IMU(MTw Awinda)组成;

2) 首次提出了用于 IMU 阵列测量数据融合的 MLP 模型,利用 MLP 模型学习 IMU 阵列的数据特征,预测出物体的实际加速度和角速度;

3) 制作了包含多人多状态的 IMU 阵列测量数据和高精度 IMU 测量数据的数据集,并将该数据集在 MLP 模型上训练、测试和验证,结果显示使用 MLP 融合后的预测数据的定位精度优于使用单个 IMU 测量数据的定位精度、使用简单平均处理的 IMU 阵列测量数据的定位精度和使用最小二乘法融合的 IMU 阵列测量数据的定位精度。

1 相关工作

在 2012 年,Perlmutter 等^[7]就证明可以用 9 个加速度计的组合来估计一个物体的比力和角加速度,在惯性

传感器阵列中放置多个空间分布的陀螺仪时,除了从冗余测量中获得的信息,不会获得额外的惯性信息。但是,通过冗余测量可以减小测量误差,例如文献[8]提出的 IMU 阵列的 Allan 方差分析。文献[9-10]中也描述了几种使用不同滤波框架和信号模型融合多个陀螺仪测量值的方法。

对于由多个 IMU 组成的惯性阵列,目前提出的信息融合方法主要是将 IMU 的原始测量数据进行融合,例如 Xue 等^[11]提出了 3 种使用滤波器对 IMU 测量数据进行处理的融合方法;Guerrier^[12]借助仿真证明了可以根据规范设计含有多个 IMU 的系统,从而更好地评估所采用的传感器数量与精度提高之间的关系;Skog 等^[13]提出了一种基于超低成本的 IMU 阵列提高脚装式惯性导航系统性能的方法,证明了通过计算 IMU 阵列数据的平均值测量组合惯性是可行的,但文章并未解释如何对测量值进行加权计算。Tarek 等^[14]使用自适应最小二乘法将 IMU 阵列的测量数据融合,并将其精度提升了 25% 以上。

近几年,不少文献将机器学习应用于 IMU 姿态识别和惯性导航领域,Brossard 等^[15]利用卷积神经网络(convolutional neural networks, CNN)对陀螺仪的测量数据进行降噪处理实现了精确的姿态估计;Vu 等^[16]使用多层感知机模型实现了手部姿态由 IMU 坐标系到相机坐标系的变换;Chen 等^[17]提出了一种神经网络结构直接从 IMU 原始数据中学习惯性里程计,效果优于传统的 PDR 算法。乔文超等^[18]使用反向传播(back propagation, BP)神经网络对精度较低的传感器进行误差补偿,补偿后精度远高于原始精度。本文首次将多层感知机应用于 IMU 阵列的测量数据融合,并利用多层感知机对 IMU 阵列的安装误差进行校准并提高 IMU 阵列测量数据融合后的定位精度。

2 提出的方案

本节将简要介绍低成本 IMU 阵列定位框架、数据同步采集系统和 MLP 模型的一些相关工作。

2.1 低成本 IMU 阵列定位框架

低成本 IMU 阵列框架分为训练过程和验证过程两个过程,如图 1 所示,在训练过程中,将数据同步采集系统采集到的数据进行预处理后分为标签和特征,再将其导入多层感知机模型进行训练并得到训练好的模型。在验证过程中,将用于验证的低成本 IMU 阵列采集到的数据导入训练好的模型生成预测数据,并用步长加航向定位算法验证预测数据的定位效果。

2.2 数据同步采集系统

数据同步采集系统包括两个部分,一部分是 IMU 阵




图 1 低成本 IMU 阵列定位框架

Fig. 1 Low-cost IMU array positioning framework




图 2 IMU 阵列工作原理

Fig. 2 Schematic diagram of IMU array

列板系统,另一部分是 MTw Awinda。将两部分沿着同轴向绑定并尽可能使它们的坐标中心重合,这样可以认为这两部分在同一个载体坐标系下,然后将两个设备的频率设置为 100 Hz,这样就近似认为数据采集系统可以同步接受 IMU 阵列和 MTw Awinda 的测量数据。

MTw Awinda 是 Xense 公司的一款高精度 IMU。IMU 阵列板主要包括由 4 个 MPU9250 组成的 2×2 的 IMU 阵列和 STM32F429 单片机,MPU9250 属于 INVENSENSE 公司的一种消费级的 9 轴传感器。其中 MTw Awinda 和 MPU9250 两款 IMU 的实测性能参数如表 1 所示。从表 1 中可知,MTw Awinda 在非线性、零偏不稳定性和噪声方面都要优于 MPU9250。

表 1 MTw Awinda 和 MPU9250 两款 IMU 的实测性能参数

Table 1 Measured performance parameters of two IMUs: MTw Awinda and MPU9250

参数	MTw Awinda	MTw Awinda	MPU9250	MPU9250
	加速度计	陀螺仪	加速度计	陀螺仪
量程	±160 m/s ²	±2 000 deg/s	±160 m/s ²	±2 000 deg/s
非线性	0.5% of FS	0.1% of FS	0.8% of FS	0.3% of FS
零偏	0.1 mg	10 deg/hour	40~60 mg	20 deg/hour
噪声	200 μg/√Hz	0.01 deg/s/√Hz	300 μg/√Hz	0.01 deg/s/√Hz

数据同步采集系统中 IMU 阵列板的工作原理如图 2 所示,IMU 阵列通过一组时钟同步的 I²C 和单片机相连,单片机通过 I²C 控制 IMU 阵列同时采集数据和上传数据,并将同一时间采集到的测量数据打包发送给电脑。相较于传统的单片机轮询发送指令并接收数据的方法,这种通信方式可以严格保证 IMU 阵列数据的同步性。

2.3 MLP 模型

本文需要根据 IMU 阵列的 24 维测量数据预测出新的 6 维预测数据,且用于训练的数据集较大,而 MLP 具有高度的非线性全局作用,非常强的自适应、自学习功能且适合处理数据量较大的数据集,因此使用 MLP 进行数据融合。

本文选用的模型是 4 层的感知机模型,如图 3 所示,模型层与层之间是全连接的,第 1 层是 24 个输入(4 个 IMU 的测量数据),中间有两个隐藏层,第 1 层隐藏层包含 128 个神经节点,第 2 层隐藏层包含 64 个神经节点,最后一层是 6 个输出(6 维惯性数据),隐藏层采用 sigmoid 函数作为激活函数,模型使用的损失函数是均方误差(mean-square error, MSE)损失函数,该网络模型的工作过程如下所示:

1) 设网络总层数为 L ,迭代步长为 α ,一共有 m 组训练数据,首先对各隐藏层与输出层的线性关系权重矩阵 W 和偏置向量 b 进行初始化。

2) 前向传播过程:设一组训练数据的输入为 x_i ,MLP 模型第 1 层(输入层)为:

$$a_i^1 = x_i \tag{1}$$

则从第 $l-1$ 层到第 l 层有:

$$a_i^l = \sigma(W^l a_i^{l-1} + b^l) \tag{2}$$

其中, σ 为激活函数 sigmoid, W^l 和 b^l 分别表示从 l 层到 $l+1$ 层的权重和偏置, a_i^l 表示第 l 层第 i 个神经元的激活值(激活函数的输出), a^l 表示第 l 层的激活值。由此可递推出输出层神经元的激活值 a^L 。




图 3 4 层感知机网络模型

Fig. 3 Four-layer perceptron network model diagram

3) 利用损失函数计算输出层误差 δ^l ; 损失函数为:

$$J(\mathbf{W}, \mathbf{b}, x, y) = \frac{1}{2} \|\mathbf{a}^l - y\|_2^2 \quad (3)$$

式中: y 为该组训练数据的标签数据, 设:

$$\mathbf{z}^l = \mathbf{W}^l \mathbf{a}^{l-1} + \mathbf{b}^l \quad (4)$$

则:

$$\delta^l = \frac{\partial J(\mathbf{W}, \mathbf{b}, x, y)}{\partial \mathbf{z}^l} = (\mathbf{a}^l - y) \odot \sigma'(\mathbf{z}^l) \quad (5)$$

式中: $\odot$ 为 Hadamard 乘积, 表示矩阵的对应位置元素相乘。

4) 反向传播过程: 已知:

$$\delta^l = \frac{\partial J(\mathbf{W}, \mathbf{b}, x, y)}{\partial \mathbf{z}^l} = (\mathbf{a}^l - y) \odot \sigma'(\mathbf{z}^l) \quad (6)$$

则从第 $l+1$ 层误差到第 l 层误差满足:

$$\delta^l = (\mathbf{W}^{l+1})^T \delta^{l+1} \odot \sigma'(\mathbf{z}^l) \quad (7)$$

5) 计算代价函数对权重和偏置的改变率:

$$\frac{\partial J}{\partial \mathbf{W}^l} = \frac{\partial J}{\partial \mathbf{z}^l} \frac{\partial \mathbf{z}^l}{\partial \mathbf{W}^l} = \delta^l (\mathbf{a}^{l-1})^T \quad (8)$$

$$\frac{\partial J}{\partial \mathbf{b}^l} = \frac{\partial J}{\partial \mathbf{z}^l} \frac{\partial \mathbf{z}^l}{\partial \mathbf{b}^l} = \delta^l \quad (9)$$

6) 将各组数据依次输入到 MLP 模型, 重复步骤 2) ~

5), 得到各组数据下代价函数对权重和偏置的改变率, 最后得到权重和偏置更新公式:

$$\mathbf{W}^l = \mathbf{W}^l - \alpha \sum_{j=1}^m \delta^{j,l} (\mathbf{a}^{j,l-1})^T \quad (10)$$

$$\mathbf{b}^l = \mathbf{b}^l - \alpha \sum_{j=1}^m \delta^{j,l} \quad (11)$$

式中: $\delta^{j,l}$ 表示第 j 组数据第 l 层的误差, $\mathbf{a}^{j,l-1}$ 表示第 j 组数据 $l-1$ 层的激活值。

重复步骤 2) ~ 6), 直到 $\mathbf{W}$ 、 $\mathbf{b}$ 的改变率都低于一个阈值时停止训练, 输出 $\mathbf{W}$ 和 $\mathbf{b}$ 。

3 实验与分析

3.1 PDR 定位算法

本实验使用的 PDR 定位算法为步长加航向定位方法^[19-20]。该定位算法利用 IMU 得到加速度、陀螺仪数据, 通过分析加速度信号实现步频探测和步长估计^[21], 利用 Mahony 算法进行姿态解算^[22-23], 以此来推算出行人的位置信息。

3.2 数据集制作

1) 数据采集

随机选取 10 个人 (5 位男生和 5 位女生) 作为实验人员, 将采集设备依次固定在其腰部 4 个不同位置 (前、后、左、右) 进行实验, 实验人员在室内分别以 3 种不同速度 (1、1.5、2 m/s) 进行 7 种不同运动 (向前进、向后退、向

左侧行、向右侧行、上楼、下楼、绕圈行走), 每一次运动持续 45 s, 每一种运动进行 3 次 (其中上楼、下楼和绕圈行走只以 1 m/s 速度运动), 最后一共采集到 270 万组实验数据, 其中每一组数据都包括 IMU 阵列的测量数据和 MTw Awinda 的测量数据。图 4 是某位同学进行数据采集的示例。



图 4 采集数据照片

Fig. 4 Data acquisition photo

2) 数据预处理

由于 IMU 阵列和 MTw Awinda 两个系统的时间系统不同, 无法完全实现同步采集, 且采集的原始数据单位也不同, 所以需要对采集到的数据进行预处理。数据预处理步骤如下:

(1) 对 MTw Awinda 和 IMU 阵列获得的测量数据进行单位换算 (加速度单位为 m/s^2 , 角速度为 rad/s)。

(2) 根据标志位对 IMU 阵列测量数据和 MTw Awinda 测量数据进行同步。实验人员在采集前先进行一个 90° 拐弯的运动, 测量数据的 Y 轴角速度产生一个明显的脉冲, 即标志位。后续将 IMU 阵列和 MTw Awinda 的测量数据依据标志位对齐, 标志位之后的数据可认为是同步的。图 5 是同步前和同步后的 IMU 阵列中第 1 个 IMU 和 MTw Awinda 的 Y 轴角速度数据对比, 从图 5 中可以看出, 两个系统的测量数据曲线在标志位之后基本是同步的。

最后, 截取标志位以后的数据作为数据集, 该数据集包括 250 万行 $\times$ 30 列的数据 (IMU 阵列的测量数据和 MTw Awinda 的测量数据), 其中 MTw Awinda 的测量数据是标签, IMU 阵列的测量数据是特征。

3.3 网络训练和测试

将数据集中 80% 的部分作为训练集, 20% 的部分作为测试集, 即 200 万样本作为训练集, 50 万样本作为测试集, 再在公共可用的 PyTorch 框架上搭建本文模型, 将




图 5 IMU 阵列第 1 个 IMU 和 MTw Awinda 的 Y 轴角速度对齐前后对比

Fig. 5 The first IMU and MTw Awinda are aligned before and after the Y-axis angular velocity comparison

训练集放在 NVIDIA GeForce RTX 3070 GPU 上进行训练。在训练期间,使用了 Adam 优化器^[24]($\beta_1 = 0.9, \beta_2 = 0.99$)来优化损失函数,学习率 α 为 0.01。训练在 50 次迭代后收敛。

将 MTw Awinda 的测量数据作为真实值,测试集中 IMU 阵列的单个 IMU 的测量数据、IMU 阵列测量数据的平均值、最小二乘法 (least square, LS) 融合 IMU 阵列测量数据后的数据、卡尔曼滤波 (Kalman filtering, KF) 融合 IMU 阵列测量数据后的数据、BP 神经网络的预测数据作为参考数据,分别统计了不同隐藏层结构下的 MLP 的预测数据与真实值之间的 MSE 以及参考数据和真实值之间的 MSE 如表 2 所示。

表 2 预测值以及参考数据和真实值之间的 MSE

Table 2 MSE between predicted, reference data and true values						
	X 轴加	Y 轴加	Z 轴加	X 轴角	Y 轴角	Z 轴角
方案	速度	速度	速度	速度	速度	速度
1 号	0.902 4	2.387 7	1.623 2	0.008 1	0.006 4	0.005 7
2 号	1.027 0	2.662 2	2.217 9	0.021 8	0.011 5	0.007 4
3 号	0.991 0	2.609 1	1.659 1	0.020 7	0.010 9	0.006 6
4 号	0.990 0	2.702 2	1.759 5	0.021 5	0.012 2	0.007 5
平均	0.894 6	2.433 3	1.640 0	0.011 9	0.007 1	0.005 9
KF	0.838 3	2.234 8	1.349 0	0.010 0	0.006 9	0.004 8
LS	0.753 5	2.006 7	1.186 5	0.007 7	0.006 5	0.004 2
BP	0.797 5	1.978 4	1.208 5	0.010 7	0.005 9	0.004 1
MLP1	0.702 0	1.673 2	0.746 3	0.009 2	0.005 7	0.003 2
MLP2	0.631 0	1.460 3	0.595 2	0.008 0	0.004 3	0.001 4
MLP3	0.594 8	1.405 2	0.554 3	0.007 2	0.004 0	0.001 6
MLP4	0.532 4	1.203 2	0.473 2	0.005 0	0.003 8	0.001 2

其中,1、2、3、4 号代表 IMU 阵列的 4 个单个的 IMU; BP 表示隐藏层具有 64 个神经元的 BP 神经网络;MLP1

表示第 1 层隐藏层具有 64 个神经元,第 2 层隐藏层具有 128 个神经元的 MLP 模型;MLP2 表示第 1 层隐藏层具有 128 个神经元,第 2 层隐藏层具有 64 个神经元的 MLP 模型;MLP3 表示第 1 层隐藏层具有 64 个神经元,第 2 层隐藏层具有 128 个神经元,第 3 层隐藏层具有 64 个神经元的 MLP 模型;MLP4 表示第 1 层隐藏层具有 256 个神经元,第 2 层隐藏层具有 128 个神经元,第 3 层隐藏层具有 64 个神经元的 MLP 模型;从表 2 可知在传统融合方法(平均融合、最小二乘法融合、卡尔曼滤波融合)中,平均融合的效果最差,最小二乘法融合的效果最好,而 MLP 模型预测的加速度、角速度数据比传统融合方法得到的加速度、角速度数据更加贴近真实值,同时 MLP 模型预测的准确性要高于 BP 神经网络预测的准确性,且随着 MLP 模型的隐藏层数、神经元的增加,MLP 模型预测的准确性也越来越高,考虑到后续可能需要将该 MLP 移植到单片机内并进行实时定位,所以该 MLP 模型的结构不能过于复杂,综合考虑了 MLP 模型精度和复杂度以后,选择了 MLP2,也就是第 1 层隐藏层含有 128 个神经元,第 2 层神经元含有 64 个神经元。该 MLP 预测的 6 维惯性数据与真实值之间的 MSE,相比于单个 IMU 测量数据和真实值之间的 MSE 减小了 25%~70%。

考虑到行人行走时腰部和胸部的惯性特征不同,所以实验人员可以将采集设备固定在胸部位置进行数据采集,以此来验证网络的鲁棒性。实验人员将采集设备固定在胸部位置后行走 5 min 后,分别统计了单个的 IMU 数据和真实值之间的 MSE,该 MLP 模型的预测数据和真实值之间的 MSE 如表 3 所示。从表 3 可以得知即便数据的采集方式不同,该 MLP 模型仍然可以有效的进行数据融合。

表 3 预测值以及单个 IMU 数据和真实值之间的 MSE

Table 3 MSE between predicted value, single IMU data and true value						
	X 轴加	Y 轴加	Z 轴加	X 轴角	Y 轴角	Z 轴角
方案	速度	速度	速度	速度	速度	速度
1 号	0.623 0	1.569 8	1.408 5	0.008 6	0.006 6	0.005 2
2 号	0.734 8	1.986 3	1.867 8	0.009 5	0.011 5	0.004 8
3 号	0.805 6	1.789 4	1.790 4	0.010 4	0.007 8	0.004 2
4 号	0.776 4	2.074 7	1.567 0	0.007 8	0.008 4	0.006 3
MLP2	0.484 0	1.1631	0.644 2	0.006 9	0.004 6	0.001 8

3.4 PDR 定位实验

将进行实验并利用 PDR 定位算法来比较 MLP 融合后的预测数据、单个 IMU 测量数据、简单平均处理的 IMU 阵列测量数据、最小二乘法融合 IMU 阵列测量数据后得到的数据在实际场景的定位精度。

1) 实验步骤

共进行了 20 次实验(将采集设备固定到腰前、腰后

各 10 次), 每一次实验中, 实验人员在一个 $49.2\text{ m} \times 31.2\text{ m}$ 的矩形边上行走, 先将得到的 IMU 阵列测量数据导入训练好的 MLP 模型得到新的预测数据, 然后对 IMU 阵列测量数据进行简单平均得到新的数据, 最后使用最小二乘法将 IMU 阵列测量数据融合得到新的数据。

2) 实验精度对比方法

将 MLP 模型的预测数据、单个 IMU 测量数据、简单平均处理的 IMU 阵列测量数据和最小二乘法融合 IMU 阵列测量数据后得到的数据分别作为原始数据进行定位解算, 解算出的位置信息同真实位置之间的距离作为参考标准, 对比各原始数据的定位精度, 并分析融合算法的适用性。选取了 3 个具有代表性的指标为精度分析标准: (1) 平均总行走距离 (total travelled distance, TTD) 误差, 20 次实验终点误差与行走总路线长度比值的平均值; (2) 矩形顶点的误差平均值和方差, 20 次实验中各顶点位置的误差的平均值和方差; (3) 矩形顶点的 MSE, 20 次实验中各顶点位置和真实位置之间的 MSE。

3) 实验结果和分析

将使用 MLP 模型的预测数据作为原始数据进行定位的方案称为方案 1, 将使用单个 IMU 测量数据作为原始数据进行定位的方案称为方案 2, 将使用简单平均处理的 IMU 阵列测量数据作为原始数据进行定位的方案称为方案 3, 将使用最小二乘法融合 IMU 阵列测量数据后得到的数据作为原始数据进行定位的方案称为方案 4, 20 次实验中各方案的终点的平均 TTD 误差和各顶点的 MSE 如表 4 所示, 20 次实验中各顶点的误差平均值、标准差如图 6 所示, 某一次实验中各方案的轨迹对比图如图 7 所示。

表 4 各方案的终点的平均 TTD 误差和各顶点的 MSE
(d_1, d_2, d_3, d_4 代表矩形 4 个顶点)

Table 4 Average TTD error at the end of each scheme and MSE of each vertex (d_1, d_2, d_3 and d_4 represent four rectangular vertices)

方案	d_1	d_2	d_3	d_4	TTD 误差/%
方案 1	0.703 2	1.485 2	1.103 5	1.930 4	0.76
方案 2	2.123 3	5.321 0	3.805 4	3.648 5	1.15
方案 3	1.923 3	4.582 0	1.928 6	2.790 2	0.96
方案 4	0.902 3	2.469 8	1.520 9	2.231 6	0.86

表 4 和图 6 显示, 方案 1 的平均 TTD 误差只有 0.76%, 和方案 2、3、4 相比分别降低了 33.9%、20.8%、11.6%; 同时方案 1 各顶点位置的误差平均值相比于方案 2、3、4 也分别减少了 32.4%~53.4%、21.5%~47%、13.2%~33.7%, 且方案 1 各顶点位置的标准差都保持在较低水平, 而另外 3 种方案第 2 个顶点的标准差都偏大一些, 说明使用方案 1 的整体定位精度效果优于另外 3 种方案, 而方案 1 各顶点的 MSE 比方案 2 各顶点的 MSE




图 6 各方案的顶点的误差平均值和标准差

Fig. 6 Mean error and standard deviation of vertices of each scheme




图 7 某次实验 4 种方案的轨迹对比

Fig. 7 Trajectory comparison of schemes in an experiment

减小了 47.1%~72.1%, 比方案 3 各顶点的 MSE 减小了 30.8%~67.6%, 比方案 4 各顶点的 MSE 减小了 13.5%~39.9%, 说明方案 1 相比于另外 3 种方案更加稳定。同时, 从图 7 也可以直观看出 4 种方案的优劣, 从整个轨迹来看, 特别是在图示拐角区域, 方案 1 的轨迹曲线比另外 3 种方案更加贴近真实轨迹。

实验结果表明, 通过 MLP 融合模型得到的预测数据不仅在数值上更加接近于真实数据, 并且在定位精度上优于单个 IMU 测量数据、简单平均处理的 IMU 阵列测量数据和最小二乘法融合的 IMU 阵列测量数据, 证明了利用神经网络对 IMU 阵列的数据进行融合是有效的。

4 结 论

本文提出了一种使用 MLP 对 IMU 阵列数据进行融合的新算法, 利用自主设计的数据采集装置制作了包含多人多状态的 IMU 阵列测量数据和高精度 IMU 测量数

据的数据集,将该数据集在 MLP 模型上训练、测试,并重新进行了定位实验进行验证,在 20 次 160 m 的运动实验中,经过 MLP 融合后的预测数据的整体平均定位精度比使用单个 IMU 测量数据的整体平均定位精度提高了 33.9%,比使用简单平均处理的 IMU 阵列测量数据整体平均定位精度提高了 20.8%,比使用最小二乘法融合的 IMU 阵列测量数据的整体平均定位精度提高了 11.6%,证明了本文所提出方法的可行性和有效性。

未来工作如下:1) 换用其他的深度学习网络来融合 IMU 阵列的测量数据以提高定位精度;2) 将基于 IMU 阵列的惯性定位和 WiFi 指纹定位结合进一步提高定位精度。

参考文献

- [1] HARLE R. A survey of indoor inertial positioning systems for pedestrians [J]. IEEE Communications Surveys & Tutorials, 2013, 15(3):1281-1293.
- [2] TANENHAUS M, CARHOUN D, GEIS T, et al. Miniature IMU/INS with optimally fused low drift MEMS gyro and accelerometers for applications in GPS-denied environments[J]. Fiber Optic Sensors & Systems, 2012: 259-264.
- [3] MARTIN H, GROVES P D, NEWMAN M, et al. A new approach to better low-cost MEMS IMU performance using sensor arrays [C]. Proceedings of the 26th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2013), 2013: 2125-2142.
- [4] BITTNER D, CHRISTIAN J, BISHOP R, et al. Fault detection, isolation, and recovery techniques for large clusters of inertial measurement units [C]. IEEE/ION Position, Location and Navigation Symposium - PLANS. IEEE, 2014.
- [5] SONG J W, PARK C G. Optimal configuration of redundant inertial sensors considering lever arm effect [J]. IEEE Sensors Journal, 2016, 16(9):3171-3180.
- [6] WAEGLI A, SKALOUD J, GUERRIER S, et al. Noise reduction and estimation in multiple micro-electro-mechanical inertial systems[J]. Measurement Ence and Technology, 2010, 21(6):156-158.
- [7] PERLMUTTER M, ROBIN L. High-performance, low cost inertial MEMS: A market in motion! [C]. Proceedings of the 2012 IEEE/ION Position, Location and Navigation Symposium. IEEE, 2012: 225-229.
- [8] SKOG I, NILSSON J O, HÄNDEL P. An open-source multi inertial measurement unit (MIMU) platform[C]. 2014 International Symposium on Inertial Sensors and Systems (ISISS). IEEE, 2014: 1-4.
- [9] JIANG C Y, XUE L, CHANG H L, et al. Signal processing of MEMS gyroscope arrays to improve accuracy using a 1st order markov for rate signal modeling [J]. Sensors, 2012, 12(2):1720-1737.
- [10] YUKSEL Y, EL-SHEIMY N. An optimal sensor fusion method for skew-redundant inertial measurement units[J]. Journal of Applied Geodesy, 2011, 5(2):99-115.
- [11] XUE L, JIANG C Y, CHANG H L, et al. A novel Kalman filter for combining outputs of MEMS gyroscope array[J]. Measurement, 2012, 45(4):745-754.
- [12] GUERRIER S. Improving accuracy with multiple sensors: Study of redundant MEMS-IMU/GPS configurations [C]. Proceedings of the 22nd International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS 2009), 2009: 3114-3121.
- [13] SKOG I, NILSSON J, HANDEL P. Pedestrian tracking using an IMU array [C]. IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT). IEEE, 2014:1-4.
- [14] TAREK M, ZAHARAN S. Enhanced IMU sensors fusion based on adaptive least square windowing technique [C]. 2021 International Telecommunications Conference (ITC-Egypt), 2021.
- [15] BROSSARD M, BONNABEL S, BARRAU A. Denoising IMU gyroscopes with deep learning for open-loop attitude estimation [J]. IEEE Robotics and Automation Letters, 2020, 5(3):4796-4803.
- [16] VU L C, YOU B J. Hand pose detection in hmd environments by sensor fusion using multi-layer perceptron [C]. 2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC). IEEE, 2019: 218-223.
- [17] CHEN C, LU X, MARKHAM A, et al. Ionet: Learning to cure the curse of drift in inertial odometry [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018.
- [18] 乔文超,王红雨,王鸿东. 基于 BP 神经网络的无人机 IMU 多传感器冗余的补偿算法 [J]. 电子测量与仪器学报, 2020, 34(12): 19-28.
- [19] QIAO W CH, WANG H Y, WANG H D. Compensation algorithm for UAV IMU multi-sensor redundancy based on BP neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 39-46.
- [19] PRATAMA A, HIDAYAT R. Smartphone-based pedestrian dead reckoning as an indoor positioning system [C]. International Conference on System Engineering and Technology (ICSET), 2012:1-6.

- [20] KANG W, HAN Y. SmartPDR: Smartphone-based pedestrian dead reckoning for indoor localization [J]. IEEE Sensors Journal, 2015, 15(5):2906-2916.
- [21] VEZOCNIK M, JURIC M. Average step length estimation models' evaluation using inertial sensors: A review [J]. IEEE Sensors Journal, 2019, 19(2): 396-403.
- [22] 储开斌, 赵爽, 冯成涛. 基于 Mahony-EKF 的无人机姿态解算算法 [J]. 电子测量与仪器学报, 2020, 32(12):12-18.
CHU K B, ZHAO S, FENG C T. UAV attitude calculation algorithm based on Mahony-EKF [J]. Journal of Electronic Measurement and Instrumentation, 2020, 32(12):12-18.
- [23] LUDWIG S A, BURNHAM K D. Comparison of Euler estimate using extended Kalman filter, Madgwick and Mahony on quadcopter flight data [C]. 2018 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2018: 1236-1241.
- [24] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. ArXiv Preprint, 2014, arXiv:1412.6980.

作者简介



廖亚桢, 2019 年于天津大学获得学士学位。现为天津大学硕士研究生, 主要研究方向为室内定位。

E-mail: 15122051228@163.com

Liao Yazhen received his B. Sc. degree from Tianjin University in 2019. Now he is a M. Sc. candidate at Tianjin University. His main research interest includes indoor positioning.



宫霄霖 (通信作者), 分别于 2002 年、2005 年及 2010 年于天津大学获得学士学位、硕士学位和博士学位, 现为天津大学讲师, 主要研究方向为无线定位和智能图像处理。

E-mail: gxl@tju.edu.cn

Gong Xiaolin (Corresponding author) received the B. Sc. degree, the M. Sc. degree and the Ph. D. degree from Tianjin University in 2002, 2005 and 2010, respectively. She is now working in School of Microelectronics, Tianjin University. Her main research interests include wireless localization and intelligent image processing.