

DOI: 10.19650/j.cnki.cjsi.J2413410

基于联合卷积变分自编码器和预测器的 UWB 定位算法*

古玉锋, 李 真, 高世椿, 黎程山

(长安大学道路施工技术与装备教育部重点实验室 西安 710064)

摘 要:某室内三线自动驾驶轨道交通系统使用了超宽带(UWB)定位系统,车辆的高精度定位是提高其运行可靠性和调度效率的关键技术。基于 UWB 定位精度的分析,提出了一种基于联合卷积变分自编码器和预测器(VAE-CNN)的非视距鉴别、测距误差补偿与神经网络定位误差补偿的三步 UWB 定位算法。首先,采集标签与基站的测距误差和信道脉冲响应(CIR)数据,训练 VAE-CNN 模型,根据原始 CIR 和重建 CIR 的可信度阈值剔除非视距测距值。其次,根据预测器的预测误差补偿原始测距值,使用最小二乘法计算坐标和该坐标相对于各个基站坐标的方向余弦,训练神经网络用于拟合定位误差与方向余弦的关系。在已公开的包含视距和非视距的 UWB 测距值和 CIR 数据集上,验证了 VAE-CNN 模型的非视距鉴别能力,评估了基于 VAE-CNN 模型的非视距鉴别和测距误差补偿对定位精度的提升效果;在不同测距方差下,基于车辆模拟运行轨迹,评估了定位误差补偿神经网络提高定位精度的效果。搭建了 UWB 定位系统,验证了动态定位中三步 UWB 定位算法的实际效果。结果表明,动态定位中,在完全视距环境中,算法的平均定位误差为 28.68 mm,均方根定位误差为 16.67 mm,最大定位误差为 76.68 mm;存在非视距的环境中,算法的平均定位误差为 38.73 mm,均方根定位误差为 20.61 mm,最大定位误差为 116.47 mm。由此可知,所提出的三步 UWB 定位算法具有精度高、成本低和稳定性好的优点,能满足所涉及的室内轨道交通的定位需求。

关键词: 三线室内轨道交通;UWB 定位;卷积变分自编码器;非视距鉴别;误差补偿

中图分类号: TH70 **文献标识码:** A **国家标准学科分类代码:** 460.40

UWB location algorithm based on joint convolutional variational auto-encoder and predictor

Gu Yufeng, Li Zhen, Gao Shichun, Li Chengshan

(Key Laboratory for Highway Construction Technology and Equipment of Ministry of Education, Chang'an University, Xi'an 710064, China)

Abstract: UWB positioning system was used in an indoor three-line autonomous driving rail transit system, where high-precision positioning of vehicles was a key technology to improve operational reliability and scheduling efficiency. A three-step UWB location algorithm including non-line-of-sight (NLOS) discrimination, ranging error compensation and neural network location error compensation was proposed using a joint convolutional variational auto-encoder and predictor (VAE-CNN), based on the analysis of UWB location accuracy. Firstly, the ranging error and channel impulse response (CIR) data between the tag and the base stations were collected and used to train the VAE-CNN model. The non-line-of-sight ranging values were eliminated according to the confidence threshold of the original and reconstructed CIR. Secondly, the original ranging values were compensated by the prediction errors of the predictor. The coordinates and the direction cosine of the coordinates with respect to the coordinates of each base station were calculated, which were used to train the neural network to fit the relationship between the localization error and the direction cosine. The NLOS discrimination capability of the VAE-CNN model was validated on a publicly available UWB ranging and CIR dataset, which includes both line-of-sight (LOS) and NLOS measurements. The effectiveness of NLOS discrimination and ranging error compensation based on the VAE-CNN model on improving positioning accuracy was also evaluated. The effect of positioning error compensation neural network on improving positioning accuracy was evaluated based on the simulated vehicle trajectories under different ranging variances. An UWB localization system was built to verify the practical performance of the three-step UWB localization algorithm in dynamic localization. The results

收稿日期: 2024-10-25 Received Date: 2024-10-25

* 基金项目: 国家自然科学基金(52205249)项目资助

show that in dynamic localization, in full line-of-sight environment, the algorithm achieved an average localization error of 28.68 mm, a root-mean-square localization error of 16.67 mm, and a maximum localization error of 76.68 mm. In the presence of non-line-of-sight environment, the average localization error is 38.73 mm, the root mean square localization error is 20.61 mm, and the maximum localization error is 116.47 mm. It can be seen that the three-step UWB location algorithm offers high accuracy, low cost, and excellent stability, meeting the positioning requirements of indoor rail transit systems.

Keywords: three-line indoor rail transit; UWB location; convolutional variational auto-encoder; non-line-of-sight identification; error compensation

0 引 言

高精度的位置服务对提高轨道交通系统的效率、安全性和运行管理水平具有重要意义。全球导航卫星系统(global navigation satellite system, GNSS)在室外环境提供了便捷和高精度的位置服务,但在室内环境中,由于遮挡物较多,卫星信号的接收受到严重干扰,GNSS 定位精度严重下降,无法满足室内定位的要求^[1-2]。近年来,基于车辆与路侧单元通信的定位方法广泛地应用于室内环境的定位服务^[3-5],其中,超宽带(ultra-wide band, UWB)技术具有优良的时间分辨能力,适合用于室内环境高精度定位^[4-6]的车载和路侧单元设备。UWB 定位一般采用双向测距方法测量标签与 3 个及以上基站的距离^[7],从而解算出标签的位置坐标。但由于硬件设备存在误差,定位基站的几何布局使得测距误差在不同方向上传递的程度不同,实际定位环境中存在的非视距误差和多径效应误差^[4,8-10]使得 UWB 的定位精度降低。因此,本研究提出一种能够减弱上述误差,提高定位精度的算法。

在 UWB 定位算法的研究中,曹立波等^[5]融合了 UWB、射频识别及视觉,实现了城市 GPS 定位效果不佳环境下的车道识别和车辆定位。吴鹏博等^[11]基于 GNSS、UWB 与惯性导航系统,提出了考虑非视距(non-line-of-sight, NLOS)与系统误差的 UWB 定位方法,提高了系统的定位精度。张少辉等^[12]在标签与基站距离信息的基础上,再测得多个标签之间的距离,作为冗余,提升了定位精度。Schmid 等^[10]将测距值、信道的标准噪声、最大噪声、接收功率和首径位置等特征输入神经网络,预测和补偿 UWB 的测距误差,提高了多路径环境下 UWB 的定位精度。从飞云等^[13]将复杂多径干扰的首径信号提取与分离,提出了一种基于 UWB 信道脉冲响应的消歧重构算法,减少了测距误差。Bregar 等^[14]将 UWB 信号的信道脉冲响应(channel impulse response, CIR)输入卷积神经网络以补偿 UWB 的测距误差和鉴别非视距测距值。曹波等^[15]将变分卡尔曼滤波、全质心定位算法和泰勒级数优化算法结合,提出了一种 UWB 混合定位算法,提高了农业设备的定位精度。Stahlke 等^[16]提出了一种基于变分自编码器(variational auto-encoders, VAE)的

非视距鉴别和 UWB 定位方差估计的算法,结合扩展卡尔曼滤波器,提高了 UWB 的定位精度。

由已有文献可知,多传感器融合的定位算法实现困难,计算量大,成本较高;通过冗余测量进行筛选的算法需要较高的定位频率和复杂的通信协议,对 UWB 设备的要求较高;传统深度学习方法所采用的特征难以较好地包含环境特征,定位精度提升有限;非视距鉴别中,采用 CIR 的监督式学习方法需要采集大量的非视距 CIR 数据,无监督学习方法仅需少量的非视距 CIR;在剔除非视距测距值后,多径效应误差和基站几何分布引起的误差放大效应仍会降低定位精度,已有文献关于这方面的研究还不深入。本研究所涉及的三线轨道交通系统中存在多个车辆同时运行,为保证车辆安全运行,需要 UWB 定位系统提供厘米级精度的定位服务,已有定位算法无法满足三线轨道车辆的定位需求。因此,提出了一种定位频率高、成本低且定位精度高的基于联合卷积变分自编码器和预测器(joint convolutional variational auto-encoder and predictor, VAE-CNN)的非视距鉴别、测距误差补偿与神经网络定位误差补偿的三步 UWB 定位算法。

1 定位方法和神经网络模型

1.1 UWB 定位原理

通信流程采用优化的双向双边测距(double-sided two way ranging, DS-TWR)算法,算法流程如图 1 所示。




图 1 优化的 DS-TWR 测距算法流程
Fig. 1 Process of optimized DS-TWR ranging algorithm

图1中, $poll_tx_ts$ 、 $poll_rx_ts$ 分别为 Poll 帧的发送、接收时间戳, $resp_tx_ts$ 、 $resp_rx_ts$ 分别为 Resp 帧的发送、接收时间戳, $final_tx_ts$ 、 $final_rx_ts$ 分别为 Final 帧的发送、接收时间戳。Final 消息帧中包含 Resp 有效性标记, Resp 有效性标记表示哪些基站的 Resp 帧被成功接收, 根据 Resp 有效性标记判断是否测距通信有效, 若有效, 则根据所获得的6个时间戳计算距离^[7], 计算步骤为:

$$T_{round1}^m = resp_rx_ts - poll_tx_ts \quad (1)$$

$$T_{round2}^m = final_rx_ts - resp_tx_ts \quad (2)$$

$$T_{reply1}^m = resp_tx_ts - poll_rx_ts \quad (3)$$

$$T_{reply2}^m = final_tx_ts - resp_rx_ts \quad (4)$$

$$\hat{T}_{prop}^m = \frac{T_{round1}^m \times T_{round2}^m - T_{reply1}^m \times T_{reply2}^m}{T_{round1}^m + T_{round2}^m + T_{reply1}^m + T_{reply2}^m} \quad (5)$$

式中: T_{round1}^m 是标签发送 Poll 帧至接收到基站 A_m Resp 帧的时间间隔; T_{round2}^m 是基站 A_m 发送 Resp 帧至接收到标签 Final 消息帧的时间间隔; T_{reply1}^m 是基站 A_m 接收到 Poll 帧至发送 Resp 帧的时间间隔; T_{reply2}^m 是标签接收到基站 A_m 的 Resp 帧至发送 Final 帧的时间间隔; $\hat{T}_{prop}^m$ 是标签到基站 A_m 间的估计飞行时间。由此可得, 标签与基站 A_m 的距离为:

$$\hat{d}_m = \hat{T}_{prop}^m \times c \quad (6)$$

式中: $\hat{d}_m$ 是标签与基站 A_m 的测量距离; c 为光速, $c = 2.997\,924\,58 \times 10^8$ m/s。

标签与3个及以上数目基站的测距通信完成后, 即可计算位置。标签的真实坐标 (x, y) 与第 i 个基站的坐标 (x_i, y_i) 满足:

$$x^2 + y^2 - 2x_i x - 2y_i y = d_i^2 - x_i^2 - y_i^2 \quad (7)$$

当标签测得与 n 个基站的距离后, 可获得1个方程组, 使用最小二乘法求解:

$$\mathbf{X} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (8)$$

式中:

$$\mathbf{X} = (x \quad y \quad x^2 + y^2)^T; \mathbf{A} = \begin{pmatrix} -2x_0 & -2y_0 & 1 \\ -2x_1 & -2y_1 & 1 \\ \vdots & \vdots & \vdots \\ -2x_n & -2y_n & 1 \end{pmatrix}$$

1.2 定位精度分析

标签与多个基站测距实现定位, 定位精度受到标签与基站相对几何分布的影响, 测距误差在不同方向具有不同程度的传递, 使得定位精度下降。设 $(\hat{x}, \hat{y})$ 为最小二乘法得出的位置, 对应其实际位置 (x, y) 。

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} \hat{x} \\ \hat{y} \end{pmatrix} + \begin{pmatrix} \Delta x \\ \Delta y \end{pmatrix} \quad (9)$$

由此, 可得到其真实距离与测量距离和定位误差的关系。

$$d_i = \sqrt{(x - x_i)^2 + (y - y_i)^2} = \sqrt{(\hat{x} + \Delta x - x_i)^2 + (\hat{y} + \Delta y - y_i)^2} \quad (10)$$

式中: d_i 为标签与第 i 个基站间的真实距离; (x_i, y_i) 为第 i 个基站的坐标; 对式 (10) 在 $(\hat{x}, \hat{y})$ 处进行一阶泰勒展开得到:

$$d_i = \hat{d}_i - \frac{\hat{x} - x_i}{\hat{d}_i} \Delta x - \frac{\hat{y} - y_i}{\hat{d}_i} \Delta y \quad (11)$$

式中: $\hat{d}_i$ 为标签与基站 i 间的测量距离。 Δd_i 为测距误差。令 $d_i = \hat{d}_i + \Delta d_i$, $\alpha_i = \frac{x_i - \hat{x}}{\hat{d}_i}$, $\beta_i = \frac{y_i - \hat{y}}{\hat{d}_i}$, 可得:

$$\begin{pmatrix} \Delta d_1 \\ \Delta d_2 \\ \vdots \\ \Delta d_n \end{pmatrix} = \begin{pmatrix} \alpha_1 & \beta_1 \\ \alpha_2 & \beta_2 \\ \vdots & \vdots \\ \alpha_n & \beta_n \end{pmatrix} \begin{pmatrix} \Delta x \\ \Delta y \end{pmatrix} \quad (12)$$

令 $\mathbf{H}$ 为最小二乘法所得坐标相对各个基站坐标的方向余弦矩阵, 其矩阵形式为:

$$\mathbf{E}_d = \mathbf{H} \mathbf{E}_p \quad (13)$$

所采用的 EVK1000 模块在其通信速率为 120 Kbps 时的 CIR 数据包含 1 016 个样本, 图2所示为 UWB 测距信号的部分 CIR 数据, 用于 VAE-CNN 模型训练的 CIR 数据是以 UWB 射频芯片报告的信号首达路径为基准, 包括首达路径前 50 个 CIR 数据和首达路径后的 150 个 CIR 数据。首达路径附近的 CIR 数据包含了 UWB 测距信号中的多径信号和信道噪声等信息, 因此可作为 UWB 测距环境误差减弱的依据。




图2 UWB 信号的部分 CIR 数据

Fig.2 Partial CIR data of UWB signal

1.3 定位系统和 VAE-CNN 模型

定位系统的结构如图3所示, UWB 标签与基站定位通信完成后, 基站通过传输控制协议 (transmission control protocol, TCP) 将测距信息和 CIR 发送至定位服务器, 计算出标签的实时坐标, 再通过 TCP 协议发送至轨道车辆的集中控制中心。UWB 设备如图4所示, 由 EVK1000

评估板和 STM32F103ZET6 主控板组成,主控板通过串行外围接口(serial peripheral interface, SPI)控制 EVK1000 实现定位通信,并通过 TCP 协议将数据传输到定位服务器。相较于标签,基站可以更便捷地采集和传输数据,同时为使 UWB 通信的时间尽量短,仅在基站端采集 Final 消息帧的 CIR 数据。




图 3 UWB 定位系统的结构

Fig. 3 The structure of UWB positioning system



图 4 UWB 设备

Fig. 4 UWB device

变分自编码器是一种生成式的神经网络模型,通过学习输入样本的概率分布特征并从中抽样生成重建样本,具有较强的特征学习能力^[16-19]。为了实现 UWB 测距误差补偿和非视距鉴别,提出了一种 VAE-CNN 模型,其结构如图 5 所示。




图 5 VAE-CNN 模型结构

Fig. 5 VAE-CNN model structure

VAE-CNN 由卷积变分自编码器和误差预测器组成。卷积变分自编码器由编码器和解码器组成,编码器由 3 个卷积层和 2 个输出层组成,用于从 CIR 中推理出低维特征变量的概率分布参数。输入原始 CIR 样本后,第 1 层卷积核大小选择为 3×3 ,步幅为 2,目的是压缩特征图的长度,同时提取局部时序特征。16 个通道的设计,能够捕获多种特征模式,且不会过多增加计算复杂度,第 2、3 层卷积核大小为 3×3 ,步幅仍为 2,逐步增大的通道

数有助于提高特征表达能力,适合捕获更高层次的特征,展平层将卷积特征图展平,为后续全连接层准备。2 个输出层分别输出特征变量的均值和方差,选取 64 维的潜在空间,能够较好地平衡 CIR 样本的压缩能力和生成能力。解码器的目标是逐层还原编码器中压缩的特征,使其接近原始输入的 CIR 样本。解码器由输入层和 3 层转置卷积和卷积输出层组成,解码器中的通道数逐层减少,遵循编码器的对称设计原则,有助于生成的特征与输入样本在分

布上的适配。为了提高训练效率,对编码器和解码器的各卷积层和转置卷积层的输入数据进行了批量标准化。误差预测器由2个卷积层、1个池化层和全连接层组成,由于测距误差的回归任务相对简单,预测器采用较少的卷积层和通道数,避免过度拟合。池化层采用最大池化操作,增强关键特征的表达。误差预测器与解码器共同连接到特征变量层。同时,为了模型具有良好的性能,VAE-CNN模型中各层间采用了线性整流函数(rectified linear unit, ReLU),帮助模型学习更复杂的特征映射和空间结构。VAE的编码器从原始CIR样本 $\mathbf{X} = (x_1, x_2, \dots, x_n)$ 推理得出特征变量 z 所服从的概率分布 $q_\phi(z|x)N(\mu_i, \sigma_i^2)$,从中采样获得特征变量 z' ,解码器根据特征变量 z' 推理得到重建的CIR样本,预测器根据特征变量 z' 估计测距误差 e'_i 。因此,VAE-CNN模型的损失函数包括VAE损失 L_{VAE} 和预测器损失 L_{PRE} 。令:

$$f(\mu_i^{(j)}, \sigma_i^{(j)}) = \mu_i^{(j)^2} + \sigma_i^{(j)^2} - 2\log\sigma_i^{(j)} - 1 \quad (14)$$

则:

$$L_{VAE} = \frac{1}{n} \sum_{i=1}^n \|x_i - x'_i\|^2 + \frac{1}{2n} \sum_{i=1}^n \sum_{j=1}^n (f(\mu_i^{(j)}, \sigma_i^{(j)})) \quad (15)$$

式中: x_i 代表原始CIR数据; x'_i 为重建CIR数据; $\mu_i^{(i)}$ 和 $\sigma_i^{(j)}$ 为由第 i 条数据推理得到的第 j 个高斯分布的均值与标准差。预测器的损失函数为:

$$L_{PRE} = \frac{1}{n} \sum_{i=1}^n (e_i - e'_i)^2 \quad (16)$$

式中: e_i 为真实误差; e'_i 为预测误差。为了平衡VAE和预测器的训练损失,需要在两者之间施加不同的权重。因此,VAE-CNN模型的损失函数为:

$$L_{VAE-CNN} = \sqrt{\omega_1^2 L_{VAE}^2 + \omega_2^2 L_{PRE}^2} \quad (17)$$

式中: L_{VAE} 为VAE的损失函数; L_{PRE} 为预测器的损失函数; ω_1 为VAE损失权重; ω_2 为预测器损失权重,本研究训练中采用的权重 $\omega_1 = 1, \omega_2 = 1000$ 。

2 三步UWB定位算法

三步UWB定位算法的定位流程包含模型建立和实时定位两个阶段,如图6所示,模型建立阶段包括VAE-CNN模型和定位误差补偿神经网络的建立,实时定位阶段包含非视距鉴别、测距误差补偿和定位误差补偿三步。




图6 三步UWB定位算法流程

Fig. 6 Three-step UWB positioning algorithm process

在模型建立阶段,使用视距环境下的UWB标签和基站采集标签与基站的测距误差和CIR数据,训练VAE-CNN模型。根据VAE-CNN补偿后的误差,使用最小二乘法计算位置坐标和该坐标相对于各个基站坐标的方向余弦矩阵,训练定位误差补偿神经网络以拟合方向余弦矩阵和最小二乘法定位误差的关系。使用视距和非视距信号的CIR与VAE重建的CIR计算重建可信度,从

而划定阈值实现非视距鉴别,本研究通过输入视距CIR和非视距CIR,使用编码器拟合特征分布变量建立CIR特征分布,对CIR特征分布进行 n 次采样并使用解码器重建CIR,计算 n 次的平均重建可信度。对于本研究采用的200个样本的CIR数据,重建可信度 P_r 为:

$$P_r = \frac{1}{200n} \sum_{i=1}^n \sum_{j=1}^{200} (x_j - x'_j)^2 \quad (18)$$

式中： n 为采样次数； x_j 为原始 CIR 数据的第 j 个幅值； x'_j 为重建 CIR 数据的第 j 个幅值。在训练集数据的重建可信度的区间范围内，选择使得视距与非视距鉴别准确率最高的阈值为非视距鉴别阈值。

在实时定位阶段，对于 n 个标签的定位数据，包含 $4n$ 条测距和 CIR 数据，首先，将 $4n$ 条 CIR 作为一个批次输入编码器获得各自特征分布参数，并从该特征分布中进行 m 次采样获得重建 CIR 并计算平均重建可信度，将平均重建可信度大于重建可信度阈值的测距值鉴别为非视距测距。其次，根据编码器输出的特征分布参数，进行 m 次采样输入预测器并计算预测误差的均值，剔除非视距测距，对于视距测距值，补偿方法为从原始测距值中减去预测误差均值。最后，为减弱基站几何分布对定位精度的影响，将最小二乘法和 VAE-CNN 筛选补偿后的位置及对应的方向余弦矩阵作为输入，使用定位误差补偿神经网络预测和补偿定位误差。定位误差补偿神经网络的结构如图 7 所示，其中输入层有 8 个神经元，两个隐藏层分别由 120 和 8 个神经元组成，输出层的神经元数量为 2，各层之间采用 ReLU 激活函数。




图 7 定位误差补偿神经网络的结构

Fig. 7 Structure of positioning error compensation neural network

3 模型验证和仿真测试

3.1 VAE-CNN 模型验证

为了验证所提出的 VAE-CNN 模型的性能，在已公开的视距和非视距 UWB 测距和 CIR 的数据集^[14]上对模型进行测试。训练集上的 CIR 重建可信度分布如图 8 所示，视距重建可信度分布较为集中，非视距重建可信度分布较为分散，以一定步长在重建可信度的上下界区间内选择待评估阈值，为了保留视距测距的同时尽可能地剔除更多的非视距测距，需要计算每个待评估阈值的非视距识别准确率，选择非视距识别准确率最高的待评估阈

值作为非视距识别阈值，阈值的选择属于模型建立阶段，计算的复杂度并不影响定位算法的实时性，通过对每一个待评估阈值的计算，可以精确地得到识别准确率最高的阈值，将该阈值作为视距信号判断的上界，在此训练集上的最佳阈值为 9.234 8，非视距鉴别准确率为 89.04%，漏检率为 7.5%，虚警率为 14%。




图 8 重建可信度分布

Fig. 8 Reconstruct credibility distribution

将所提出的 VAE-CNN 算法与多层感知机 (multilayer perceptron, MLP)、支持向量机 (support vector machine, SVM) 以及 CNN 算法在准确率、虚警率和漏检率方面进行了对比，其中 SVM 分别使用了线性核函数 (linear kernel, LK) 和径向基函数 (radial basis function, RBF)，对比结果如表 1 所示。

表 1 不同非视距识别算法对比

Table 1 Comparison of different NLOS recognition algorithms (%)

算法	准确率	虚警率	漏检率
MLP	82.9	28.2	5.9
SVM(LK)	82.5	31.9	2.9
SVM(RBF)	82.6	32.2	2.5
CNN	87.4	14.7	10.6
VAE-CNN	89.0	14.0	7.5

由表 1 可知，与其他非视距检测算法相比，本研究提出的 VAE-CNN 算法性能较好。VAE-CNN 算法具有更高的准确率，在虚警率与漏检率之间实现了更好的平衡。

将实际位置与算法计算位置间的欧氏距离作为定位误差，由式 (19) 计算。

$$e_i = \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \tag{19}$$

式中: e_i 为第 i 个位置的定位误差; (x_i, y_i) 为标签的真实位置; $(\hat{x}_i, \hat{y}_i)$ 为算法计算得到的位置。

在测试集上,分别计算使用 3 基站和 4 基站时,最小二乘法、仅视距时测距误差补偿、存在非视距时测距误差补偿、非视距鉴别和同时校正测距误差与非视距鉴别 5 种情况的定位误差,结果如表 2 和 3 所示。

表 2 采用 3 基站定位时的定位精度

Table 2 Positioning accuracy when using 3 base stations (mm)		
算法	平均误差	均方根误差
最小二乘法	1 726.28	3 239.36
仅视距测距时测距误差补偿	360.38	446.84
存在非视距时测距误差补偿	1 526.79	2 142.08
非视距鉴别	384.10	528.83
非视距鉴别和测距误差补偿	218.61	284.16

表 3 采用 4 基站定位时的定位精度

Table 3 Positioning accuracy when using 4 base stations (mm)		
算法	平均误差	均方根误差
最小二乘法	1 366.63	2 462.90
仅视距测距时测距误差补偿	291.11	351.32
存在非视距时测距误差补偿	1 319.02	1 740.29
非视距鉴别	309.21	404.89
非视距鉴别和测距误差补偿	174.69	230.08

由表 2 可知,3 基站定位时,非视距鉴别和测距误差补偿与最小二乘法相比,平均误差下降了 87.3%,均方根误差下降了 91.2%。由表 3 可知,4 基站定位时,非视距鉴别和测距误差补偿与最小二乘法相比,平均误差下降了 87.2%,均方根误差下降了 90.7%。相较于 3 基站定位,4 基站定位时非视距鉴别和测距误差补偿的平均误差下降了 20.1%,均方根误差下降了 19.0%。

3.2 仿真测试

为了验证所提出的定位误差补偿神经网络在不同的测距精度的性能,在 32 m×10 m 的范围内,依据轨道车辆的平移进出站、变道、直线行驶及曲线行驶等实际运行情况,模拟生成了一组轨迹并计算得到轨迹上的实际距离,4 个基站的坐标分别为 (0, 0)、(0, 10)、(32, 0) 和 (32, 10),并在实际距离上分别施加方差为 $\sigma^2 = 0.1^2$ 、 $\sigma^2 = 0.2^2$ 和 $\sigma^2 = 0.3^2$ 的高斯噪声,将生成的轨迹分别采用最小二乘法、卡尔曼滤波算法和定位误差补偿进行对比,结果如表 4 ~ 6 所示,测距方差 $\sigma^2 = 0.3^2$ 时的轨迹如图 9 所示。

表 4 $\sigma^2 = 0.1^2$ 时的定位误差

Table 4 Position error when $\sigma^2 = 0.1^2$ (mm)		
算法	平均误差	均方根误差
最小二乘法	173.54	115.28
卡尔曼滤波	120.95	81.82
定位误差补偿	51.68	37.64

表 5 $\sigma^2 = 0.2^2$ 时的定位误差

Table 5 Position error when $\sigma^2 = 0.2^2$ (mm)		
算法	平均误差	均方根误差
最小二乘法	333.81	221.43
卡尔曼滤波	219.99	143.08
定位误差补偿	103.55	75.24

表 6 $\sigma^2 = 0.3^2$ 时的定位误差

Table 6 Position error when $\sigma^2 = 0.3^2$ (mm)		
算法	平均误差	均方根误差
最小二乘法	522.28	353.05
卡尔曼滤波	355.26	240.16
定位误差补偿	161.54	119.46




图 9 $\sigma^2 = 0.3^2$ 时不同算法的轨迹

Fig. 9 Trajectory of different algorithms when $\sigma^2 = 0.3^2$

由表 4~6 可知,测距方差 $\sigma^2 = 0.1^2$ 时,相较于最小二乘法和卡尔曼滤波算法,定位误差补偿算法的平均误差分别下降了 70.2% 和 57.3%,均方根误差分别下降了 67.3% 和 54.0%;测距方差 $\sigma^2 = 0.2^2$ 时,相较于最小二乘法和卡尔曼滤波算法,定位误差补偿算法的平均误差分别下降了 69.0% 和 52.9%,均方根误差分别下降了 66.1% 和 47.4%;测距方差 $\sigma^2 = 0.3^2$ 时,相较于最小二乘法和卡尔曼滤波算法,定位误差补偿算法的平均误差分别下降了 69.1% 和 54.5%,均方根误差分别下降了 66.2% 和 50.3%。

由以上结果可知,非视距误差是造成较大定位误差的主要因素,在剔除非视距误差后,多径效应误差成为定位误差增大的主要因素。当基站数量由 3 个增加到 4 个时,定位误差有一定程度的下降。VAE-CNN 模型可用于

非视距鉴别和误差补偿,可在存在非视距和多径影响的条件下提高 UWB 定位。同时,所提出的定位误差补偿算法提高了不同方差下的定位精度。因此,将 VAE-CNN 非视距鉴别、误差补偿和定位误差补偿算法相结合可进一步提高定位精度。

在实时定位过程中,有效的定位算法能够显著降低测距误差,但算法的计算时间也会影响测距精度。因此对三步 UWB 定位算法的复杂度进行分析,以验证算法的实时性。同时输入 $4n$ (确定一个定位需要 4 条测距信息) 条测距信息,根据编码器输出的特征分布参数,进行 m 次采样,对算法流程进行分析,所得的复杂度的主要增长项结果如表 7 所示。

表 7 算法主要流程复杂度

算法流程	时间复杂度	空间复杂度
非视距鉴别	$O(n \cdot m)$	$O(n \cdot m)$
测距误差补偿	$O(n \cdot m)$	$O(n)$
定位误差补偿	$O(n^2)$	$O(n)$
算法总流程	$O(n^2 + n \cdot m)$	$O(n^2 + n \cdot m)$

本研究算法采用 $m = 10$,由表 7 可知,当 m 确定,影响算法复杂度的因素主要为输入测距信息的数量,系统仅进行一次定位时,计算所用时间为微秒级,能够满足需求。实际中,三线自动驾驶轨道交通系统在大范围、运行车辆多的时刻有很多测距值同时上报,因此利用 GPU 并行计算能力实现批量顺序计算,以保证计算速度,确保实时性不会大幅度降低。输入当前时刻接收的所有 CIR、基站坐标及原始测距,经过张量并行计算剔除非视距测距,通过本文算法对测距值进行补偿。三线轨道系统分为低速道、中速道及高速道,对不同车道车辆进行不同测距频率分配,以保障车辆实时性定位的要求,减少测距计算量以及显存占用。

4 实验验证

为了进一步验证所提出的基于 VAE-CNN 的非视距鉴别、测距误差补偿与神经网络定位误差补偿的三步 UWB 定位算法,搭建了定位系统,进行实验验证。定位服务器的界面如图 10 所示。服务器显示了标签的实际运行轨迹和坐标信息,同时记录数据。实验中,在标签的运行轨迹上均匀地选取了 72 个测试点,分别在完全视距和部分基站非视距两种情况下,记录标签经过测试点时本研究算法的定位坐标和实际坐标。




图 10 定位服务器软件界面

Fig. 10 Positioning server software interface

实验布局 and 运动轨迹如图 11 所示,使用了 4 个定位基站,车辆从站点 A 出站移动至低速轨道,低速道运行一段距离后变道至中速道,在中速道运行一段距离后再次变道至高速道,随后经过 2 次变道再次回到低速道,最后平移进入站点 B。



图 11 实验布局 and 运动轨迹

Fig. 11 Experimental layout and motion trajectory

完全视距时的定位轨迹如图 12 所示,其定位误差如表 8 所示。




图 12 完全视距时的定位轨迹

Fig. 12 Positioning trajectory at full line of sight

表 8 完全视距时定位误差对比

Table 8 Comparison of positioning errors at full line of sight (mm)			
算法	平均误差	均方根误差	最大误差
最小二乘法	246.77	128.64	471.48
定位误差补偿	199.86	105.05	390.23
测距误差补偿	75.37	46.96	209.17
测距和定位误差补偿	28.68	16.67	76.68

由表 8 可知,完全视距时,测距误差补偿和定位误差补偿与最小二乘法相比,平均定位误差下降了 88.4%,均方根误差下降了 87.0%,最大误差下降了 83.7%。

存在非视距时的定位误差如表 9 所示,根据所采集的训练数据,确定非视距鉴别阈值为 4.222 9,在此阈值下,漏检率为 0.12%,虚警率为 0.11%,重建可信度如图 13 所示。

表 9 存在非视距时的定位误差对比

Table 9 Comparison of positioning errors in the presence of non line of sight (mm)

算法	平均误差	均方根误差	最大误差
最小二乘法	286.53	267.17	2 103.20
非视距鉴别	227.89	126.55	481.00
定位误差补偿	265.55	320.16	2 585.00
定位误差补偿和非视距鉴别	182.27	104.18	403.38
测距误差补偿	151.36	249.12	1 946.25
测距误差补偿和非视距鉴别	90.70	52.23	240.58
测距和定位误差补偿	136.27	327.36	2 495.48
测距和定位误差补偿及非视距鉴别	38.73	20.61	116.47




图 13 实验数据的重建可信度

Fig. 13 Reliability of experimental data reconstruction

与实验集相比,公开集采集的环境在传输路径上存在较多的障碍物和干扰,非视距和多径反射造成的误差比实验集更严重,因此,此处算法的准确率比公开集高。不同的环境对视距与非视距重建可信度分布影响较大,

三线自动驾驶轨道交通系统运行范围很广,在实际运行前需要将车辆运行区域分为多个子区,对不同的子区确定出当前环境下视距鉴别准确率最高的阈值,以提高测距精度。

由表 9 可知,存在非视距时,测距和定位误差补偿及非视距鉴别与最小二乘法相比,平均误差下降了 86.5%,均方根误差下降了 92.3%,最大误差下降了 94.5%。

由实验结果可知,基于 VAE-CNN 的非视距鉴别、测距误差补偿与神经网络定位误差补偿的三步 UWB 定位算法,减弱了非视距引起的较大误差,补偿了多径效应误差,减弱了由于基站几何分布引起的误差放大效应,且具有实时性好、定位精度高和稳定性强的优点。

5 结 论

针对已有定位算法无法满足三线轨道车辆定位需求的问题,提出了基于联合卷积变分自编码器和预测器的非视距鉴别、测距误差补偿与神经网络定位误差补偿的三步 UWB 定位算法。将信道脉冲响应数据作为输入,以鉴别非视距并预测和补偿测距误差。基于方向余弦的定位误差补偿神经网络,以最小二乘法估计位置和各基站的方向余弦矩阵作为输入,定位误差作为输出,使用神经网络拟合两者关系以补偿定位误差。

实验结果表明,在完全视距环境下与最小二乘法相比,平均定位误差下降了 88.4%,均方根误差下降了 87.0%,最大误差下降了 83.7%。在存在非视距环境下与最小二乘法相比,平均误差下降了 86.5%,均方根误差下降了 92.3%,最大误差下降了 94.5%,达到了厘米级的定位精度,满足了所涉及的三线轨道交通系统的定位要求。

在未来的研究中,可采用边缘计算设备搭建分布式定位系统,并进一步优化本文算法以符合边缘设备的计算性能,以保证大规模 UWB 定位系统的可靠性。

参考文献

[1] 黄琴,兰小机,夏益强,等. Chan-IDW 算法在信号干扰下的 UWB 精确定位研究[J]. 电子测量技术, 2023, 46(9): 1-7.
HUANG Q, LAN X J, XIA Y Q, et al. UWB of Chan-IDW algorithm under signal interference research on

- precise positioning[J]. *Electronic Measurement Technology*, 2023, 46(9): 1-7.
- [2] 张福斌, 王凯, 廖伟飞, 等. 激光雷达/MEMS IMU/里程计紧组合导航算法[J]. *仪器仪表学报*, 2022, 43(7): 139-148.
- ZHANG F B, WANG K, LIAO W F, et al. LiDAR/MEMS IMU/Odometer integrated tightly navigation algorithm[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(7): 139-148.
- [3] ANG C W. Vehicle positioning using WIFI fingerprinting in urban environment[C]. 2018 IEEE 4th World Forum on Internet of Things (WF-IoT). IEEE, 2018: 652-657.
- [4] LANDOLSI M A, ALMUTAIRI A F, KOURAHL M A. LOS/NLOS channel identification for improved localization in wireless ultra-wideband networks[J]. *Telecommunication Systems*, 2019, 72(3): 441-456.
- [5] 曹立波, 陈峥, 颜凌波, 等. 基于 RFID、视觉和 UWB 的车辆定位系统[J]. *汽车工程*, 2017, 39(2): 225-231.
- CAO L B, CHEN ZH, YAN L B, et al. Vehicle positioning system based on RFID, vision and UWB[J]. *Automotive Engineering*, 2017, 39(2): 225-231.
- [6] 宁恒, 刘冉, 郭林, 等. 基于 UWB 方位的机器人间相对定位[J]. *电子测量与仪器学报*, 2024, 38(6): 58-66.
- NING H, LIU R, GUO L, et al. Relative localization between robots based on UWB bearing[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(6): 58-66.
- [7] LAADUNG T, ULP S, ALAM M, et al. Novel active-passive two-way ranging protocols for UWB positioning systems[J]. *IEEE Sensors Journal*, 2022, 22(6): 5223-5237.
- [8] 杨承志, 张晓明, 张鸽. 基于 WLS-KF 的 UWB 室内定位滤波算法研究[J]. *电子测量与仪器学报*, 2024, 38(1): 25-33.
- YANG CH ZH, ZHANG X M, ZHANG G. Research on UWB indoor localization filtering algorithm based on WLS-KF[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(1): 25-33.
- [9] TSAREGORODTSEV D V, KULIKOV R S, BROVKO T A, et al. Systematic error due to receive power level in UWB systems[C]. 2022 IEEE 23rd International Conference of Young Professionals in Electron Devices and Materials (EDM). IEEE, 2022: 266-270.
- [10] SCHMID L, SALODO-MONZU D, WIESER A. Accuracy assessment and learned error mitigation of UWB ToF ranging[C]. 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN). IEEE, 2019: 1-8.
- [11] 吴鹏博, 潘树国, 高旺, 等. 顾及非视距与系统误差的 UWB 质量控制及其与 GNSS/INS 的组合定位[J]. *仪器仪表学报*, 2024, 45(5): 51-60.
- WU P B, PAN SH G, GAO W, et al. UWB quality control and its integrated positioning with GNSS/INS considering NLOS and system errors[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(5): 51-60.
- [12] 张少辉, 亓玉浩, 翟方文, 等. 基于冗余距离筛选的 UWB 定位优化方法[J]. *清华大学学报(自然科学版)*, 2022, 62(5): 934-942.
- ZHANG SH H, QI Y H, ZHAI F W, et al. UWB positioning optimization method based on redundant distance screening[J]. *Journal of Tsinghua University (Science and Technology)*, 2022, 62(5): 934-942.
- [13] 从飞云, 洪纵横, 汤子安, 等. 基于脉冲响应消歧重构的 UWB 测距优化方法[J]. *仪器仪表学报*, 2022, 43(10): 13-21.
- CONG F Y, HONG Z H, TANG Z AN, et al. An optimization method of UWB ranging based on pulse response disambiguation and reconstruction[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(10): 13-21.
- [14] BREGAR K, MOHORCIC M. Improving indoor localization using convolutional neural networks on computationally restricted devices[J]. *IEEE Access*, 2018, 6: 17429-17441.
- [15] 曹波, 朱万洁, 姜春霞, 等. 基于 VBKF-CPA-TSA 算法的 UWB 定位技术[J]. *仪器仪表学报*, 2023, 44(10): 120-129.
- CAO B, ZHU W J, JIANG CH X, et al. A UWB localization technique based on the VBKF-CPA-TSA algorithm[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(10): 120-129.
- [16] STAHLKE M, KRAM S, OTT F, et al. Estimating TOA reliability with variational autoencoders[J]. *IEEE Sensors Journal*, 2022, 22(6): 5133-5140.
- [17] CAO Y J, CHEN CH, ST-ONGE D, et al. Distributed

TDMA for mobile UWB network localization [J]. IEEE Internet of Things Journal, 2021, 8(17) : 13449-13464.

[18] JANSSEN M, BUSBOOM A, SCHOON U, et al. A mobile open infrastructure network protocol (MOIN) for localization and data communication in UWB based wireless sensor networks [C]. 2014 IEEE International Conference on Ultra-WideBand (ICUWB). IEEE, 2014: 409-414.

[19] WONG C I, JAWARD M H, BASKARAN V M, et al. Joint channel estimation and signal detection using latent space representations in VAE [C]. 2022 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS). IEEE, 2022: 1-4.

作者简介



古玉锋 (通信作者), 2001 年于太原理工大学获得学士学位, 2005 年于西北工业大学获得硕士学位, 2010 年于西北工业大学获得博士学位, 现为长安大学副教授, 主要研究方向为自动驾驶。

E-mail: guyufeng@chd.edu.cn

Gu Yufeng (Corresponding author) received his B.Sc. degree from Taiyuan University of Technology in 2001, M. Sc. degree from Northwestern Polytechnical University in 2005, and Ph.D. degree from Northwestern Polytechnical University in 2010. Now he is an associate professor at Chang'an University. His main research interest is autonomous driving technology.