

基于深度学习的车辆协同定位优化

姚桦林

西南民族大学, 四川成都, 610200;

摘要: 为了进一步提高车辆的定位准确性, 提出了一种基于卷积神经网络 (CNN) 和反向传播神经网络 (BPNN) 的车辆定位优化模型, 旨在通过融合车辆间距离信息和初始定位结果, 显著提升定位精度和鲁棒性。该模型利用 CNN 与 BPNN 的组合对 GNSS 估计位置进行优化, 输出最终的车辆坐标预测结果。通过 L2 损失和距离一致性损失的结合, 模型能够同时优化单个车辆的定位精度和车辆间的相对位置关系, 确保定位结果在复杂环境中的一致性。仿真实验结果表明, 该模型在静态和动态场景下均表现出优异的性能。

关键词: 车辆定位; 智能交通; 神经网络; 定位优化

DOI: 10. 69979/3060-8767. 25. 01. 041

引言

近年来, 为了实现道路环境的连通, 车载自组织网络 (VANET) 得到了快速发展^[1]。随着新的无线电技术, 特别是 5G 毫米波通信技术的显著进步, 车辆和路边单元 (RSU) 配备了大型天线阵列, 允许在车辆与车辆 (V2V) 和车辆与基础设施之间进行通信 (V2I) 方式^[2]。

全球卫星导航系统 (GNSS) 被广泛用于车辆定位和导航^[3]。一般认为, 在森林、城市峡谷或天空能见度有限的山脉等恶劣环境下, 无法保证可靠的 GNSS 定位。城市环境的建设导致 GNSS 性能下降。

随着深度学习技术的快速发展, 神经网络在定位优化中的应用逐渐受到关注^[4]。本文的研究重点是利用神经网络对 GNSS 的车辆估计位置进行优化, 特别是在 GNSS 信号受限的环境中, 通过融合多源传感器数据, 提升车辆定位的精度和鲁棒性。

1 模型建立

假设一个单项城市交通中的定位场景, 取长为 $L(m)$, 宽为 $W(m)$ 的道路段, 包括 $n(n>2)$ 辆车辆, 在路侧部署若干路测单元 (RSU), 其属于道路中的车辆与路侧所部署的 RSU 完全连接。

1.1 神经网络模型设计

提出的神经网络模型, 共由两部分组成, 分别是 CNN 和 BPNN 神经网络。其中, CNN 网络主要用于提取车辆与车辆之间的距离信息, 并分析其特征; 而 BPNN 网络部分, 主要用于将 GNSS 信号所估计的初始坐标, 与 CNN 所提取的距离特征进行综合分析并计算, 最终得到优化

后的车辆位置估计结果。

所截取道路为 $50m \times 20m$, 我们假设在此道路中最多容纳 30 辆车辆, 因此, 其距离矩阵的最大尺寸为 30×30 , 车辆的坐标向量的最大尺寸为 30×2 。基于此, 我们展开对所设计的神经网络模型的表述。

CNN 模型由四层卷积层和池化层构成, 用于从距离矩阵中提取特征信息。经过卷积和池化操作后, 模型通过全局平均池化层和全连接层生成一个 30 维的特征向量。该特征向量随后与 GNSS 所预测的车辆估计坐标信息相结合, 共同作为 BPNN 神经网络的输入。

CNN 的第一层输入通道和输出通道分别为 1 和 16, 第二层的输入与输出通道分别为 16 和 32, 第三层输入与输出通道分别为 32 和 64, 最后一层的输入与输出通道分别为 64 和 128, 在每一层卷积层后, 都接最大池化层, 将其步幅设置为 2。最后利用全局平均池化层对特征图进行降维, 连接全连接层将 128 维的特征向量映射到 30 维进行输出。

BPNN 全连接神经网络主要由两层隐藏层组成, 第一层全连接层为 90 维的输入维度, 输出维度维 128, 并使用 ReLU 激活函数激活; BPNN 的第二层全连接层输入维度为 128, 输出维度为 60, 其为对 GNSS 车辆位置估计的最终优化结果。

1.2 损失函数

对于损失函数的设计, 其包括两个部分, 第一个部分为车辆的最终估计位置与车辆真实位置的 L2 距离。该损失用于衡量模型输出的车辆坐标与真实坐标之间的误差, 优化单个车辆的定位精度。其形式如下公式表

示:

$$Loss_{L2} = \frac{1}{N} \sum_{i=1}^N \frac{1}{M_i} \sum_{j=1}^{M_i} |\hat{\mathbf{x}}_{ij} - \mathbf{x}_{ij}| \quad (1)$$

其中, N 为样本数量, M_i 为第 i 个样本中有效车辆的数量。

损失函数的第二部分为距离一致性损失, 用于确保模型预测的车辆位置之间的距离与真实距离矩阵的一致性。其计算公式如下:

$$Loss_D = \frac{1}{N} \sum_{i=1}^N \frac{1}{M_i^2} \sum_{j=1}^{M_i} \sum_{k=1}^{M_i} (\hat{d}_{jk} - d_{jk})^2 \quad (2)$$

其中, N 为样本数量, M_i 为第 i 个样本中有效车辆的数量。

总体损失函数将以上两部分的损失函数进行整合, 通过两者的加权之和作为整个模型在训练阶段的总体损失, 其形式如下所示:

$$Loss_{total} = Loss_{L2} + \omega \times Loss_D \quad (3)$$

其中, ω 是人工设置的权重系数, 其作用为平衡 $L2$ 损失和距离一致性损失的重要性。在此处, 我们取 $\omega = 0.5$ 。总损失函数通过双重优化目标, 不仅能够提高单个车辆的定位精度, 还能在复杂环境中保持车辆间相对位置的一致性。

1.3 模型的训练

1.3.1 数据集的生成

数据集的生成过程旨在模拟实际场景中的车辆分布和信号噪声, 为神经网络模型的训练和验证提供高质量的数据支持。数据集的核心内容包括带噪声的距离矩阵、虚假坐标和真实坐标信息。

首先, 数据集初始化时, 定义了样本数量, 并创建用于存储真实位置、虚假位置 (GNSS 的初始估计位置)、真实距离矩阵和带噪声距离矩阵的张量。每个样本中, 随机生成一个车辆数量 (3 到 30 辆), 并为每辆车生成随机的真实坐标 (x 和 y 坐标范围分别为 0 到 50 和 0 到 20)。为了模拟实际环境中的测量误差, 在真实坐标的基础上添加了高斯噪声, 生成虚假坐标。

接着, 计算每对车辆之间的真实距离矩阵。并将结果存储在 30×30 的矩阵中。对于无效车辆 (坐标为 -10 的车辆), 其与其他车辆之间的距离设置为 999, 表示无效距离。同时, 在真实距离矩阵的基础上, 对每个元素添加高斯噪声, 生成带噪声的距离矩阵。

最后, 数据集通过随机划分, 将 80% 的数据划分为训练集, 20% 的数据划分为验证集。训练集在每次迭代时进行随机打乱, 验证集保持固定顺序。

1.3.2 模型的训练

模型的训练过程结合了前向传播、损失计算、反向传播和参数更新等步骤, 同时通过验证集评估模型的泛化能力。

在每个训练周期 (epoch) 中, 模型切换到训练模式, 依次处理训练集中的每个批次数据。对于每个批次, 模型首先执行前向传播操作, 随后计算损失值, 并通过反向传播算法计算损失函数对模型参数的梯度。最后, 使用 Adam 优化器根据梯度信息更新模型参数。

在每个训练周期结束后, 模型进入验证模式, 并在验证集上进行评估。验证过程与训练过程类似, 但不进行参数更新。模型遍历验证集中的每个批次, 计算验证损失, 并根据验证损失调整学习率。在此基础上引入早停机制, 以避免过拟合。

训练完成后, 模型的参数被保存到指定路径, 以便后续使用和部署。图 1 展示了模型的训练过程。




图 1 损失函数随训练次数的变化趋势

2 仿真实验

2.1 实验设置

实验环境基于 Python 3.8 和 PyTorch 框架, 硬件配置为 Intel Core i7-9750H CPU 和 NVIDIA GeForce RTX 3050 GPU。数据集通过模拟生成, 包含带噪声的距离矩阵、虚假坐标和真实坐标信息。数据集被随机划分为训练集和验证集, 其中 80% 用于训练, 20% 用于验证。

2.2 定位优化实验

在静态场景中, 我们模拟了一个固定车辆分布的环境, 车辆数量在 3 到 30 辆之间随机生成。每辆车的真实坐标在 $50\text{m} \times 20\text{m}$ 的道路区域内随机分布, 并在真实坐标的基础上添加高斯噪声生成虚假坐标。距离矩阵

通过计算车辆间的欧几里得距离生成，并添加高斯噪声以模拟实际环境中的测距误差。

为了评估模型的定位精度，我们计算了模型预测的车辆坐标与真实坐标之间的均方根误差（RMSE）。其结果如图 2 和图 3 所示。




图 2 RMSE_x随车辆间距离测量噪声水平的变化趋势




图 3 RMSE_y随车辆间距离测量噪声水平的变化趋势

实验表明，所提出的模型结构可以有效提高 GNSS 的初步估计精确度，与传统的 GNSS 定位方法方法相比，模型在定位误差和一致性方面均有显著提升。

3 结语

总而言之，将深度学习技术引入车辆定位优化中，

不仅显著提升了定位精度和鲁棒性，还为智能交通系统和自动驾驶技术的发展提供了强有力的技术支持。在此过程中，所设计的 CNN-BPNN 模型通过融合多源传感器数据和神经网络模型，能够有效应对复杂环境下的定位挑战，确保车辆定位的准确性和一致性。未来，随着技术的不断进步和应用场景的拓展，车辆定位优化模型将在智能交通和自动驾驶领域发挥更加重要的作用，推动整个行业的持续发展。

参考文献

- [1]E. Ahmed and H. Gharavi, "Cooperative vehicular networking:A survey," IEEE Trans. Intell. Transp. Syst., vol. 19, no. 3, pp. 996 - 1014, Mar. 2018
- [2]H. Kim, S. H. Lee, and S. Kim, "Cooperative localization with constraint satisfaction problem in 5G vehicular networks," IEEE Trans. Intell. Transp. Syst., vol. 23, no. 4, pp. 3180 - 3189, Apr. 2022
- [3]X. Qu, T. Liu, F. Li and W. Tan, "Cooperative Localization With the Fusion of GNSS and Relative Range Information in Vehicular Ad-Hoc Networks," in IEEE Transactions on Intelligent Transportation Systems, vol. 24, no. 11, pp. 11864-11877, Nov. 2023
- [4]Njima W, Ahriz I, Zayani R, et al. Deep CNN for indoor localization in IoT-sensor systems[J]. Sensors, 2019, 19(14): 3127.

作者简介:姚桦林,男,汉族,河南平顶山人,硕士研究生,软件工程,研究方向为车联网、车辆定位、信息融合。