

# 城市轨道交通地下段列车辅助定位方法研究

魏然之<sup>1</sup> 吴杰<sup>1</sup> 王森<sup>2</sup>

(1. 上海地铁维护保障有限公司通号分公司, 200235, 上海;

2. 上海申通地铁集团有限公司技术中心, 201103, 上海//第一作者, 工程师)

**摘要** 城市轨道交通信号系统采用降级模式运行时, 列车定位信息的精确度将大幅下降, 这给行车安全带来了一定的安全隐患。利用民用通信 4G(第四代移动通信技术)/5G(第五代移动通信技术)网络的无线信号, 采用无线信号指纹定位算法, 建立了列车定位模型, 以辅助列车在地下线路区间进行精确定位。对上海轨道交通 9 号线列车及线路区间内的测速数据进行对比分析可知, 采用该算法可达到 200 m 或更高的列车定位精度, 基本能够满足列车降级运行下的辅助定位需求。

**关键词** 城市轨道交通; 地下区间; 无线通信; 列车辅助定位; 无线信号指纹定位算法

**中图分类号** U284.48<sup>+3</sup>

DOI:10.16037/j.1007-869x.2022.11.021

Shanghai, China

随着民用通信网络在国内城市轨道交通领域的大规模部署, 4G(第四代移动通信技术)/5G(第五代移动通信技术)无线信号实现了城市轨道交通线路地下区段的全覆盖。考虑到目前卫星定位技术在地下空间应用时具有局限性, 采用无线信号在地下线路区段为列车提供辅助的定位信息, 具有一定的可行性和应用空间。

城市轨道交通中的列车定位功能通常由信号系统负责, 通过安装在轨旁和列车上的定位设备把列车位置传送给 ATS(列车自动监控)系统。随着信号系统的更新迭代, 轨旁定位设备持续升级, 从传统的轨道电路到计轴, 再到目前基于无线的车地通信, 由此列车定位信息也越来越精确。但在信号系统发生故障、列车采用降级模式运行的情况下, 仅靠轨道电路或计轴只能将列车定位在某个轨道区段内, 其定位信息的精确度大幅下降。为此, 本文基于地下区间民用通信系统无线信号的应用实际, 提出了无线信号指纹定位算法, 建立了列车定位模型, 将该算法用于上海轨道交通 9 号线地下段现场测试, 并对测试结果进行分析验证。

## 1 建立列车辅助定位模型

本文针对地下线路场景下列车定位的研究从两个角度展开:

1) 建立列车辅助定位模型: 主要从数据采集、特征分析和 AI(人工智能)建模等环节逐步建立仿真模型, 通过 4G/5G 通信网络数据实现对列车所在位置的预测和输出。

2) 列车定位精度的分析: 基于所建模型对影响列车定位精度的主要因素进行细化, 并进行对比分析, 为提升列车定位精度提出有针对性的建议。

图 1 为列车辅助定位模型的数据流处置流程。

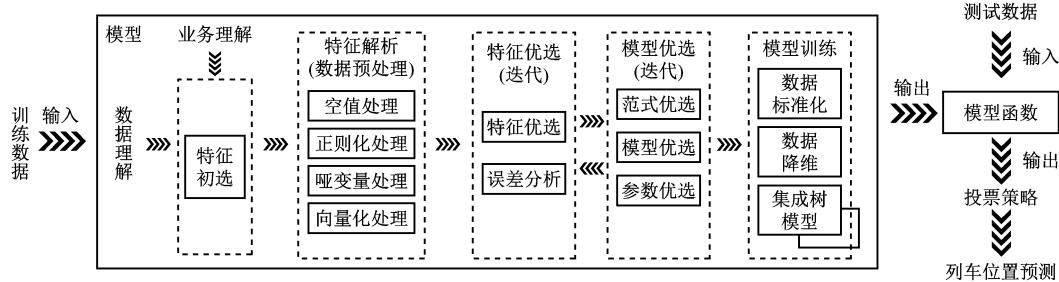


图1 列车辅助定位模型数据流示意图

Fig. 1 Schematic diagram of date flow for auxiliary train positioning model

## 1.1 明确模型的业务及数据

本研究采用无线信号指纹定位算法作为城市轨道交通列车辅助定位模型的核心算法,将信号系统中ATS的列车位置信息作为该算法的标签数据。

无线信号指纹定位算法拟通过AI模型学习方法,从数据中训练出一个从特征到标签的映射关系模型。如图2所示,信号指纹定位算法包括确定性的定位算法和基于概率的定位算法两部分,其计算过程可分两个阶段:列车位置数据库的建立阶段和列车位置的估计阶段。



图2 列车位置数据指纹法的相关算法

Fig. 2 Correlation algorithm of train position data fingerprint method

基于无线信号指纹定位算法建立列车辅助定位模型,其技术要点主要包括:①因ATS数据具有较高的精度,该算法将ATS数据作为标签;②指纹算法采用的特征数据为4G/5G的空口数据(包括但不限于通信时间、小区标识、小区电频强度等),通过算法结果预测列车的位置;③通过AI模型学习方法训练得到从特征到标签的映射关系模型。

本研究在上海轨道交通9号线的曹路站—杨高中路站区段(均为地下段)进行了现场测试。因信号指纹定位算法需要输入大量的测试数据,才能确保得到良好的列车定位精度,为此,本研究在测试列车上安装了带有天线的通信模组,通过ATS得到该区段起始点位置,通过业务-特征维度映射技术将位置信息映射为指纹算法的标签数据。测试数据(如表1所示)主要来自于UE(用户终端)和

eNodeB(基站)的物理层、RLC(无线控制层),以及在无线资源管理过程中计算产生的测试报告。

将ATS数据和测试数据进行筛选和拼接,在删除4个列次的测试数据后,最终共采集到ATS系统的23 442个样本数据及移动网络的14 275个样本数据。基于这些样本数据,建立列车辅助定位仿真模型。

## 1.2 特征的初选和解析

1) 特征初选:本研究基于对列车定位业务及其数据的理解,选择与特征维度(如时间、电信强度、基站和小区等)相关的字段作为特征值。

2) 特征解析:将不同特征字段数据分类,通过设计数据处理方法和代码等方法,使之成为统一的数据类型。

## 1.3 特征优化

应用大数据和AI模型学习技术进行数据挖掘时,往往通过试错的方式来反复迭代计算、优化挖掘结果,最终得到最优解。根据数据挖掘原理,本研究有以下3种特征优选方法可供选择:

1) 随机森林模型中所有决策树的平均不纯度衰减法:通过随机森林模型中所有决策树得到的平均不纯度衰减,用以度量各个变量的重要性,将重要性高的变量作为特征值。

2) 递归特征消除法:其主要思想是反复构建模型,将选出最好或最差的特征放到一边;然后在剩余的特征中重复这个过程,直到所有特征都遍历,并保留特定数量的特征。

3) 通过主成分分析实现特征降维:在主成分分析中将原始特征通过一系列的线性组合,形成低维的特征,以去除数据的相关性;降维后的数据应最大程度地保持原始高维数据的方差信息。

本研究选择随机森林模型中所有决策树的平均不纯度衰减法作为列车辅助定位模型的特征优选方法,并基于此方法进行了特征优选。

表 1 实际测试数据表

Tab. 1 Actual Test Data Sheet

测试日	起点站	起点时间戳	终点站	终点时间戳	车号	删除原因
第 1 天	曹路站	09:50:33	杨高中路站	10:14:03	9041	
	杨高中路站	10:15:15	曹路站	10:41:10	9002	中途换车
	曹路站	10:48:10	杨高中路站	11:10:49	9069	
	杨高中路站	11:11:52	曹路站	11:37:03	9016	
	曹路站	11:39:20	杨高中路站	12:02:01	9016	
	杨高中路站	12:03:09	曹路站	12:25:30	9062	
	曹路站	12:28:35	杨高中路站	12:51:41	9062	
	杨高中路站	12:53:03	曹路站	13:16:14	9041	
	曹路站	13:18:49	杨高中路站	13:41:20	9041	
	杨高中路站	14:42:08	曹路站	15:05:19	9102	
第 2 天	曹路站	15:07:37	杨高中路站	15:30:50	9102	
	杨高中路站	15:31:45	曹路站	15:54:57	9084	
	曹路站	09:33:34	杨高中路站	09:54:45	9018	数据采集异常
	杨高中路站	10:23:43	曹路站	10:46:35	9022	
	曹路站	10:48:12	杨高中路站	11:10:40	9022	
	杨高中路站	11:11:35	曹路站	11:37:06	9050	
	曹路站	11:38:58	杨高中路站	12:02:09	9050	
	杨高中路站	12:03:26	曹路站	12:31:22	9039	
	曹路站	12:33:54	杨高中路站	12:56:46	9039	中途换车
	杨高中路站	14:09:10	曹路站	14:32:44	9086	
	曹路站	14:34:15	杨高中路站	14:58:03	9086	
	杨高中路站	15:26:15	曹路站	15:49:30	9005	数据采集异常

## 1.4 选择列车辅助定位模型的范式及参数

### 1.4.1 选择模型范式

模型的范式主要包括监督学习范式、无监督学习范式及强化学习范式 3 种形式。根据列车定位模型的实际情况,需要给出列车具体位置的一系列样本和数据,供机器进行自学习。所以,本文优选有监督模型范式,即根据训练数据,通过基于无线信号指纹定位算法得到训练模型  $f(x)$ (一个  $x \rightarrow y$  的映射关系  $f$ )。在机器训练完成后,得到正式模型  $h(x)$ ,以便在输入新样本  $x$  后,可得到预测结果  $y$ ,其原理如图 3 所示。

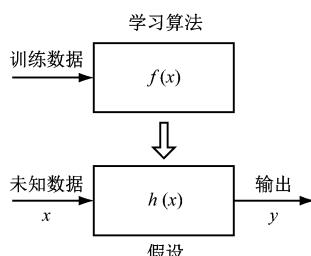


图 3 机器有监督学习模型示意图

Fig. 3 Model diagram of AI supervised learning

### 1.4.2 选择学习模型

可在集成学习、传统机器学习及神经网络等模型中优选所需的学习模型。综合考虑列车辅助定位模型的实际情况,通过大量的迭代计算,本研究采用集成学习模型进行建模。

集成学习模型是一种从错误中进行学习的技术,可以较好地应用到数字预测模型中。该模型可以训练程序做出某一决定。程序将收到的无线信号指纹输入分配到集成算法的个体学习器中,并搜集各个体学习器产生的列车位置预测结果,通过投票法、平均法等结合算法,选出最优的预测结果并输出。

### 1.4.3 选择评估参数

在机器学习过程中,可以得到查准率  $P$  与查全率  $R$  这两个数据。 $P$  的  $R$  的计算式为:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (1)$$

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (2)$$

式中:

$P$ ——查准率,指被机器学习认为是正确的样本数与样本总数之比;

$T_p$ ——被机器学习认为正确且实际也是正确的样本;

$F_p$ ——被机器学习认为正确但实际是错误的样本;

$R$ ——查全率,指被机器学习认为是正确的样本数与应当被机器学习认为是正确的样本数之比;

$F_n$ ——未被机器学习认为正确但实际是正确的样本。

在训练机器学习模型过程中,往往希望能够兼顾查准率和查全率,并使用一个统一的单值评价指标来评价机器学习模型的训练效果。因此,通过计算得到查准率与查全率的调和平均数  $f_1$ , $f_1$  是一个可以综合评估查全率和查准率的指标。

$$f_1 = \frac{2}{\frac{1}{P} + \frac{1}{R}} = \frac{2PR}{P + R} \quad (3)$$

$f_1 = 1$  时,说明查准率和查全率指标都是 100%,即没有漏检和误检。此时列车定位预测模型越接近理论最优模型,能准确输出列车行驶过程中所有的真实位置。

## 2 对列车辅助定位模型预测结果的评估

根据采集到的样本数据(即测试的开行列次),将列车定位精度分别划分 50 m、100 m、150 m 和 200 m 栅格。对这 4 种栅格尺寸下样本进行统计,可得到不同栅格尺寸下的样本数量的平均值和最小值,如表 2 所示。

表 2 不同栅格尺寸下的样本数据分布

Tab. 2 Sample data distribution under different grid sizes

栅格尺寸/m	样本数量平均值/个	样本数量最小值/个
50	25.87	1
100	50.13	0
150	74.80	31
200	99.01	37

根据样本数量的分布情况,通过大量的迭代测试和优化,本次采用 200 m 栅格建立列车辅助定位模型,此时模型输出较为均衡的定位精度为 200 m 栅格。在大量的迭代测试和优化中,模型的输出有微小的变化,其评估指标  $f_1$  也略有不同。 $f_1 =$

0.763 540 191 是迭代过程中出现的最高值。

## 3 仿真结果分析

综上分析,得到如下结论:①列车辅助定位模型可以稳定运行并输出列车的位置数据;②列车辅助定位模型可输出较为均衡的位置数据,当定位精度为 200 m 栅格时, $f_1 = 0.763 540 191$ ;③如表 3 所示,对栅格尺寸、样本数量平均值和  $f_1$  三者的关系进行对比分析可知,样本数据与栅格尺寸存在较强的正相关性,栅格尺寸每增加 50 m,样本数据约增加 25 个,样本数量和  $f_1$  也存在较强的正相关性。

表 3 栅格尺寸、样本数量及  $f_1$  关联度列表

Tab. 3 List of grid size, sample number and  $f_1$  correlation degree

栅格尺寸/m	样本数量/个	$f_1$
50	26	0.344 652 302
100	50	0.589 738 842
150	75	0.674 407 686
200	99	0.763 540 191

从实际测试的效果看,200 m 栅格的定位精度基本可以满足列车降级运行下的定位需求。从建模评估数据看,在保持  $f_1$  不明显下降的前提下,若需增加 10 个开行列次的测试数据,列车的定位精度预计需在 150 m 左右;若增加 50 个开行列次的测试数据,列车的定位精度预计应在 50 m 以内。

## 4 结语

本文采用信号指纹定位算法,利用民用通信 4G/5G 网络的无线信号,实现了列车在地下线路区间的定位。经测试,该算法可以至少实现 200 m 的定位精度,基本能够满足列车降级运行下的辅助定位需求。此外,该算法还可以为其他应用提供服务,如内燃机车等工程车辆在正线施工时的定位、不同信号制式线路间列车转线时的定位等。在下一阶段的工作中,应进一步扩大标记数据样本的来源和数量,以探索不同场景下基于无线信号的列车定位性能的极限。

## 参考文献

- [1] 李志明,邓建芳.基于 5G 基站地铁列车定位仿真研究[J].电子测试,2020(20):47.

(下转第 102 页)