

第3章 汽车定位技术

汽车定位是让自动驾驶汽车知道自身确切位置的技术,这是一个有趣且富有挑战的任务,在自动驾驶过程中担负着相当重要的职责。汽车自身定位信息获取的方式多样,涉及多种传感器类型和相关技术^[1],本章将从卫星定位、惯性导航定位、地图匹配定位及多传感器融合定位介绍自动驾驶汽车定位技术。

3.1 卫星定位技术

在任何驾驶条件下,自动驾驶汽车均依赖于精准的位姿信息,包括位置、速度和姿态等。收集这些信息需要整合多种复杂技术,其中 GNSS 功不可没。当下 GNSS 定位技术结合了多套卫星导航定位技术,能为自动驾驶汽车提供更精准的位置信息,如图 3-1 所示。本节将从卫星导航定位系统简介、GNSS 定位原理及 GNSS 误差分析等几个方面对卫星定位技术进行描述。

3.1.1 卫星导航定位系统简介

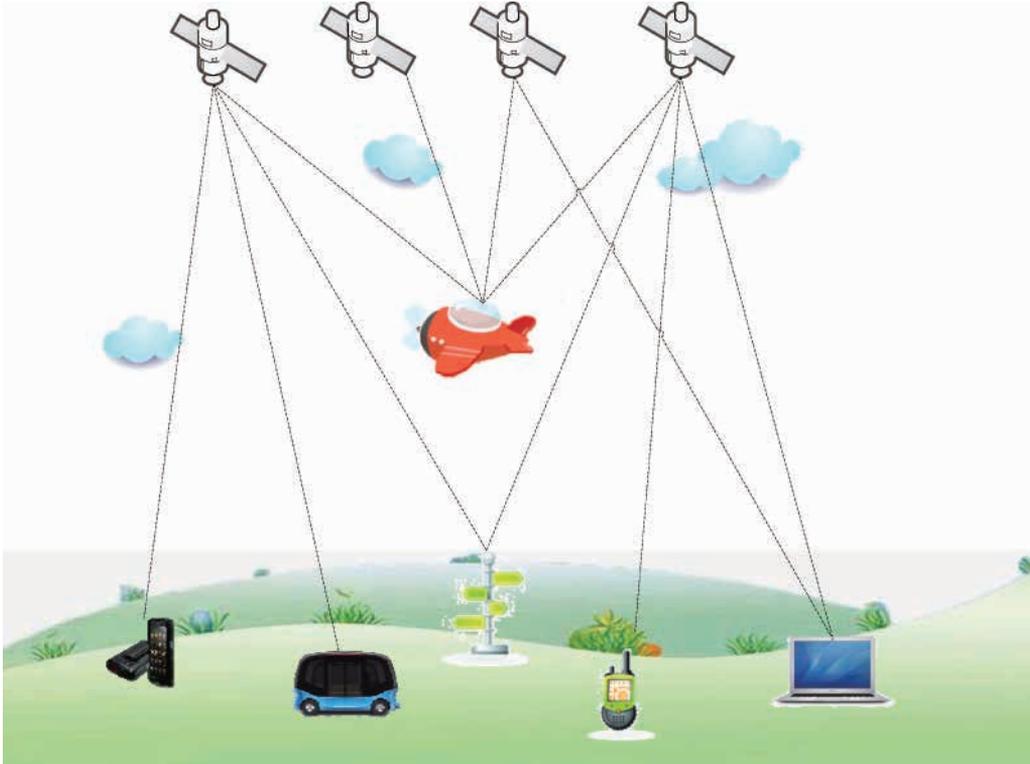
卫星导航定位系统是星基无线电导航系统,以人造地球卫星作为导航台,为全球海陆空的各类军民载体提供位置、速度和时间信息,这些信息都具有全天候且高精度等特征,因而又被称作天基定位、导航和授时系统。卫星导航定位系统包括全球 4 大导航卫星系统,还有区域系统和增强系统^[2]。

1. 全球 4 大导航卫星系统

美国的全球定位系统(Global Positioning System,GPS)、俄罗斯的格洛纳斯卫星导航系统(Global Navigation Satellite System, GLONASS)、中国的北斗卫星导航系统(Beidou Navigation Satellite System, BDS)与欧盟的伽利略卫星导航系统(Galileo Satellite Navigation System,GALILEO)并称为全球 4 大导航卫星系统^[3]。

1) GPS

GPS 提供具有全球覆盖、全天时、全天候、连续性等优点的三维导航



■ 图 3-1 卫星导航定位示意图

和定位能力,作为先进的测量、定位、导航和授时手段,除了在军事上起着举足轻重的作用,在国家安全、经济建设和民生发展的各个方面都扮演着重要的角色。

GPS 由 3 部分构成,即空间卫星部分、地面监控部分和用户接收部分。空间卫星部分又称为空间段,由 21 颗 GPS 工作卫星和 3 颗在轨备用卫星构成完整的 21+3 形式的 GPS 卫星工作星座。这种星座构型满足在地球上任意地点、任意时刻均能观测到至少 4 颗几何关系较好的卫星来用于定位。地面控制部分又称为地面段,由分布在全球的一个主控站、3 个注入站和若干个监测站组成。用户接收部分又称为用户段,主要接收导航、定位和授时服务,这些服务已广泛应用于各个领域。

2) GLONASS

GLONASS 是苏联时期建设的导航系统,同样能够为海陆空的民用和军用提供全球范围内的实时、全天候连续导航、定位和授时服务。GLONASS 也由空间段、地面段、用户段 3 大部分组成,但与 GPS 相比,各部分的具体技术有较大的差异。空间段由 24 颗卫星组成,其中有 21 颗正常工作卫星和 3 颗备份卫星。如果 GLONASS 星座完整,则可以满足在地球上任意地点、任意时刻都能收到来自至少 4 颗卫星的信号,从而获取可靠的导航定位信息^[4]。地面段包括系统控制中心的跟踪控制站网,这些跟踪控制站网分散在俄罗斯领土上。用户段接收卫星发射的导航信号,从而获取需要的位置、速度和时间信息。

3) BDS

BDS 是中国正在实施的自行研制的全球卫星导航系统,于 2012 年 12 月 27 日启动区域

性导航定位与授时服务^[5]。期间,由中国独立开发的北斗二号系统已向我国及周边地区在内的亚太大部分地区提供服务^[6]。目前,我国正在进行北斗三号系统卫星的发射与调试。

除了与上述导航系统提供的导航、定位、授时功能等相同的服务外,BDS还具有特殊的短报文通信功能。从组成结构来看,同样分为空间段、地面段和用户段。空间段由5颗地球静止轨道(Geostationary Orbit, GEO)卫星和30颗非地球静止轨道(Nongeostationary Orbit, NON-GEO)卫星组成。其中,由5颗GEO卫星、3颗倾斜地球同步轨道(Inclined Geosynchronous Orbit, IGSO)卫星和4颗中地球轨道(Medium Earth Orbit, MEO)导航卫星组成的星座方案被北斗二号区域导航系统采用。

“北斗三号”全球导航系统建设,将按照计划由5颗GEO卫星和30颗NON-GEO卫星组成全部35颗卫星。GEO+MEO+IGSO的星座构型是北斗卫星导航系统的完整布局,最大的优点则同样是保证了在地球上任意地点、任意时刻均能接收来自4颗及以上导航卫星发射的信号,观测条件良好的地区甚至可以接收到10余颗卫星的信号。地面段包括监测站、上行注入站、主控站。用户段组成及功能同前两者基本相同。

4) GALILEO

GALILEO也是一个正在建设中的全球卫星导航系统,其目的是使欧洲摆脱对美国GPS的依赖,打破其垄断地位。该系统的基本服务免费,但要使用高精度定位服务就需要付费。GALILEO也分为空间段、地面段、用户段3大部分。空间段是由分布在3个轨道上的30颗MEO卫星构成,其中27颗工作卫星、3颗备份卫星。地面段由2个地面操控站,29个伽利略传感器站以及5个S波段上行站和10个C波段上行站组成,传感器站及上行站均分布于全球。用户段则提供独立于其他卫星导航系统的5种基本服务。

2. 区域卫星导航系统

除了上文4个全球卫星导航系统外,还有一些其他已完成或正在建设的区域卫星导航系统,如日本的准天顶卫星系统(Quasi-Zenith Satellite System, QZSS)、印度的区域导航卫星系统(Indian Regional Navigation Satellite System, IRNSS)等^[7]。其中日本的QZSS的主要目标是作为GPS的补充、作为GNSS的增强和提供信息服务,范围覆盖了亚太地区,提升了灾害管理和有效维护国家安全的能力。随着系统卫星数量和密度的不断增加,QZSS从技术上可能升级为独立的卫星导航系统,提供完整的卫星导航功能。

3. 星基增强系统

星基增强系统(Satellite-Based Augmentation System, SBAS)是由美国实施选择可用性(Selective Availability, SA)政策而发展起来的。SBAS也主要由空间段、地面段和用户段构成。为了提升GPS的性能,满足不同用户对高精度、高完好性的需求,产生了相应的增强系统。例如,美国的WAAS(Wide Area Augmentation System)、俄罗斯的SDCM(System for Differential Corrections and Monitoring)、日本的MSAS(Multi-functional Satellite Augmentation System)、欧洲的EGNOS(European Geostationary Navigation Overlay Service)和印度的GAGAN(GPS Aided Geo Augmented Navigation)。这5个典型区域性星基增强系统被纳入GNSS中,可以提高单点卫星定位的稳定性和精度,从而实现1~3m甚至小于1m的定位精度。

4. 地基增强系统

地基增强系统(Ground-Based Augmentation Systems, GBAS)是卫星导航系统建设中

的一项重要内容,可以大大提升系统服务性能。GBAS 综合使用了各种不同效果的导航增强技术,主要包括精度增强技术、完好性增强技术、连续性和可用性增强技术,最终实现了其增强卫星导航服务性能的功能。

我国的地基增强系统主要是北斗地基增强系统,属于国家重大信息基础设施,用于增强北斗卫星导航系统的定位精度和完好性。该系统由框架网基准站和加强密度网基准站、通信网络、数据处理系统、运营平台、数据播发系统和用户终端组成,具备在全国范围内为用户提供广域实时米级、分米级、厘米级和后处理毫米级定位精度的能力,具有作用范围广、精度高、野外单机作业等优点。

3.1.2 GNSS 定位原理

根据后方交会定位原理,要实现 GNSS 定位,需要解决两个问题:一是观测瞬间卫星的空间位置;二是观测站点和卫星之间的距离,即卫星在某坐标系中的坐标。为此首先要建立适当的坐标系来表征卫星的参考位置^[8],而坐标又往往与时间联系在一起^[9],因此,GNSS 定位是基于坐标系统和时间系统进行的。

1. 坐标系统与时间系统

卫星导航系统中,坐标系用于描述与研究卫星在其轨道上的运动、表达地面观测站的位置以及处理定位观测数据。根据应用场合的不同,选用的坐标系也不相同。坐标系统大概分为以下几类:地理坐标系、惯性坐标系、地球坐标系、地心坐标系和参心坐标系。国内常用的坐标系统有:1954 年北京 54 坐标系(Beijing 54 Coordinate System,P54)、1980 年国家大地坐标系(National Geodetic Coordinate System 1980,C80)、1984 年世界大地坐标系系统(World Geodetic System-1984 Coordinate System,WGS-84)、2000 国家大地坐标系(China Geodetic Coordinate System 2000,CGCS2000)。

时间系统在卫星导航中是最重要、最基本的物理量之一。首先,高精度的原子钟控制卫星发送的所有信号。其次,在大多数卫星导航系统中,距离的测量都是通过精确测定信号传播的时间来实现的。时间系统主要包括世界时、历书时、力学时、原子时、协调世界时、儒略日、卫星导航时间系统。其中 GNSS 采用了一个独立的时间系统作为导航定位计算的依据,称为 GNSS 时间系统,简称 GNSST。GNSST 属于原子时系统,其秒长与原子时秒长相同。

2. 定位原理

GNSS 的设计思想是将空间的人造卫星作为参照点,确定一个物体的空间位置。根据几何学理论可以证明,通过精确测量地球上某个点到三颗人造卫星之间的距离,能对此点的位置进行三角形的测定,这就是 GNSS 最基本的设计思路及定位功能。

假设地面测得某点 P 到卫星 S_1 的距离为 r_1 ,那么从几何学可知, P 点所在的空间可能位置集缩到这样一个球面上,此球面的球心为卫星 S_1 ,半径为 r_1 。再假设测得 P 点到第二颗卫星 S_2 的距离为 r_2 ,同样意味着 P 点处于以第二颗卫星 S_2 为球心、半径为 r_2 的球面上。如果同时测得 P 点到第三颗卫星 S_3 的距离为 r_3 ,意味着 P 点也处于以第三颗卫星 S_3 为球心、半径为 r_3 的球面上,这样就可以确定 P 点的位置,也就是三个球面的交汇处,如

图 3-2 所示。

从 GNSS 进行定位的基本原理可以看出,GNSS 定位方法的实质,即测量学的空间后方交会。由于 GNSS 采用单程测距,且难以保证卫星钟与用户接收机钟的严格同步,因此观测站和卫星之间的距离均受两种时钟不同步的影响。卫星钟差可用导航电文中所给的有关钟差参数进行修正,而接收机的钟差大多难以精确确定,通常采用的优化做法是将其作为一个未知参数,与观测站的坐标一并求解,即一般在一个观测站上需求解 4 个未知参数(3 个点位坐标分量和一个钟差参数),因此至少需要 4 个同步伪距观测值,即需要同时观测 4 颗卫星。

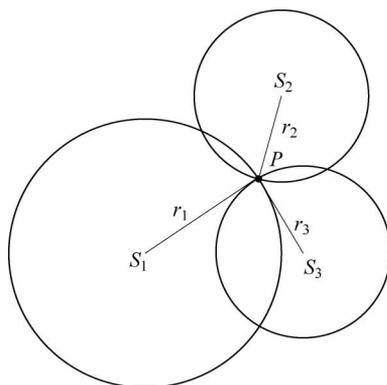


图 3-2 三球定位原理图

根据用户站的运动状态可将 GNSS 分为静态定位和动态定位。静态定位是将待定点固定不变,将接收机安置在待定点上进行大量的重复观测。动态定位是指待定点处于运动状态,测定待定点在各观测时刻运动中的点位坐标,以及运动载体的状态参数,如速度、时间和方位等。此外,还可以根据定位模式分为绝对定位和相对定位。绝对定位只用一台接收机来进行定位,又称作单点定位,它所确定的是接收机天线在坐标系统中的绝对位置。相对定位是指将两台接收机安置于两个固定不变的待定点上,或将一个点固定于已知点上,另一个点作为流动待定点,经过一段时间的同步观测,可以确定两个点之间的相对位置,从而获得高精度的位置坐标^[10]。

3.1.3 GNSS 数据误差

卫星导航系统的误差从来源上可以分为 4 类:与信号传播有关的误差、与卫星有关的误差、与接收机有关的误差以及与地球转动有关的误差^[11]。

与信号传播有关的误差包括电离层延迟误差、对流层延迟误差及多径效应误差。与卫星有关的误差包括卫星星历误差、卫星时钟误差、相对论效应等。与接收机有关的误差包括接收机时钟误差、(接收机天线相位中心相对于测站标识中心的)位置误差和天线相位中心位置的偏差。与地球转动有关的误差包括来自地球潮汐、地球自转的影响。误差分类如表 3-1 所示,下面列举几种常见误差进行说明。

表 3-1 卫星导航系统误差

误差来源		对测距的影响/m
与信号传播有关的误差	电离层延迟误差	1.5~15.0
	对流层延迟误差	
	多径效应误差	
与卫星有关的误差	卫星星历误差	1.5~15.0
	卫星时钟误差	
	相对论效应	

续表

误差来源		对测距的影响/m
与接收机有关的误差	接收机时钟误差	1.5~5.0
	位置误差	
	天线相位中心位置的偏差	
与地球转动有关的误差	地球潮汐	1
	地球自转的影响	

1. 电离层延迟误差

电离层是处于地球上空 50~1000km 高度的大气层。该大气层中的中性分子受太阳辐射的影响发生电离,产生大量的正离子与电子。在电离层中,电磁波的传输速率与电子密度有关。因此直接将真空中电磁波的传播速度乘以信号的传播时间得到的距离,很大可能与卫星至接收机间的真实几何距离不相等,这两种距离上的偏差叫电离层延迟误差。电离层延迟误差是影响卫星定位的主要误差源之一,它引起的距离误差较大,一般在白天可以达到 15m 的误差,在夜晚则可以达到 3m 的误差;并且在天顶方向引起的误差最大可达 50m,水平方向引起的误差最大可达 150m。针对电离层延迟误差的改进措施通常包括利用双频观测、利用电离层模型辅以修正和利用同步观测值求差。

2. 多径效应误差

接收机接收信号时,如果接收机周围物体所反射的信号也进入天线,并且与来自卫星的信号通过不同路径传播且于不同时间到达接收端,反射信号和来自卫星的直达信号相互叠加干扰,使原本的信号失真或者产生错误,造成衰落^[12]。这种由于多径信号传播所引起的衰落被称作多径效应,也称多路径效应。多径效应误差是卫星导航系统中一种主要的误差源,可造成卫星定位精确度的损害,严重时还将引起信号的失锁。改进措施通常包括将接收机天线安置在远离强发射面的环境、选择抗多径天线、适当延长观测时间、降低周期性影响、改进接收机的电路设计、改进抗多径信号处理和自适应抵消技术。

3. 卫星星历误差

由星历所给出的卫星位置与卫星实际位置之差称为卫星星历误差。卫星星历误差主要由钟差、频偏、频漂等产生。针对卫星在运动中受到的多种摄动力的综合影响,对于目前的技术来说,要求地面监测站实现准确、可靠地测出这些作用力,并掌握其作用规律是比较困难的,因此卫星星历误差的估计和处理尤为关键。改进措施通常包括忽略轨道误差、通过轨道改进法处理观测数据、采用精密星历和同步观测值求差。

3.1.4 差分 GNSS 定位技术

减少甚至消除 3.1.3 节所提到的误差是提高定位精度的措施之一,而差分 GNSS 可有效利用已知位置的基准站将公共误差估算出来,通过相关的补偿算法削弱或消除部分误差,从而提高定位精度。

差分 GNSS 的基本原理主要是在一定地域范围内设置一台或多台接收机,将一台已知精密坐标的接收机作为差分基准站,基准站连续接收 GNSS 信号,与基准站已知的位置和

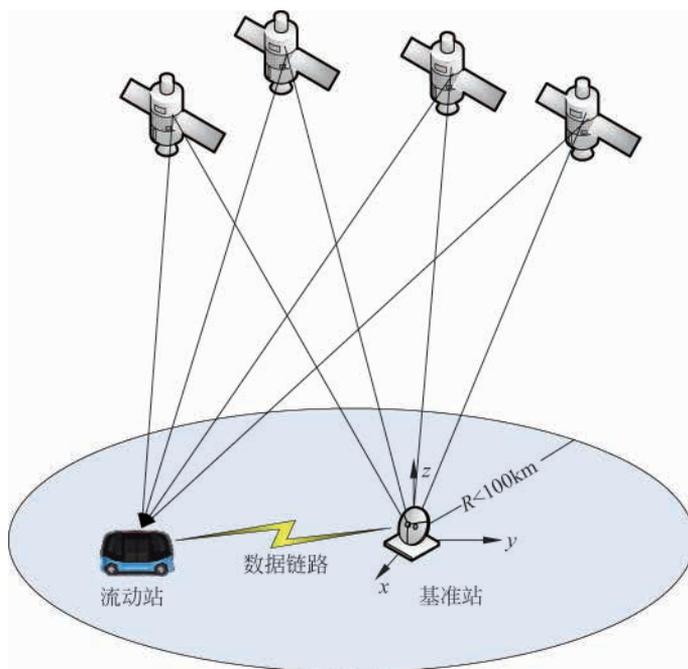
距离数据进行比较,从而计算出差分校正量。然后,基准站就会将此差分校正量发送到其范围内的流动站进行数据修正,从而减少甚至消除卫星时钟、卫星星历、电离层延迟与对流层延迟所引起的误差,提高定位精度。

流动站与差分基准站的距离直接影响差分 GNSS 的效果,流动站与差分基准站的距离越近,两站点之间测量误差的相关性就越强,差分 GNSS 系统性能就越好。

根据差分校正的目标参量的不同,差分 GNSS 主要分为位置差分、伪距差分和载波相位差分。下面将简要介绍位置差分、伪距差分、载波相位差分。

1. 位置差分

位置差分系统如图 3-3 所示。通过在已知坐标点的基准站上安装 GNSS 接收机来对 4 颗或 4 颗以上的卫星进行实时观测,便可以进行定位,得出当前基准站的坐标测量值。实际上由于误差的存在,通过 GNSS 接收机接收的消息解算(Solve)出来的坐标与基准站的已知坐标是不同的。然后将坐标测量值与基准站实际坐标值的差值作为差分校正量。基准站利用数据链将所得的差分校正量发送给流动站,流动站利用接收到的差分校正量与自身 GNSS 接收机接收到的测量值进行坐标修改。位置差分是一种最简单的差分方法,其传输的差分改正数少,计算简单,并且任何一种 GNSS 接收机均可改装和组成这种差分系统。但由于流动站与基准站必须观测同一组卫星,因此位置差分法的应用范围受到距离上的限制,通常流动站与基准站间距离不超过 100km。



■ 图 3-3 位置差分系统

2. 伪距差分

如图 3-4 所示,伪距差分技术是在一定范围的定位区域内,设置一个或多个安装 GNSS 接收机的已知点作为基准站,连续跟踪、观测所有在信号接收范围内的 GNSS 卫星伪距,通

过在基准站上利用已知坐标求出卫星到基准站的真实几何距离,并将其与观测所得的伪距比较,然后通过滤波器对此差值进行滤波并获得其伪距修正值。接下来,基准站将所有的伪距修正值发送给流动站,流动站利用这些误差值来改正 GNSS 卫星传输测量伪距。最后,用户利用修正后的伪距进行定位。伪距差分的基准站与流动站的测量误差与距离存在很强的相关性,故在一定区域范围内,流动站与基准站的距离越小,其使用 GNSS 差分得到的定位精度就会越高。

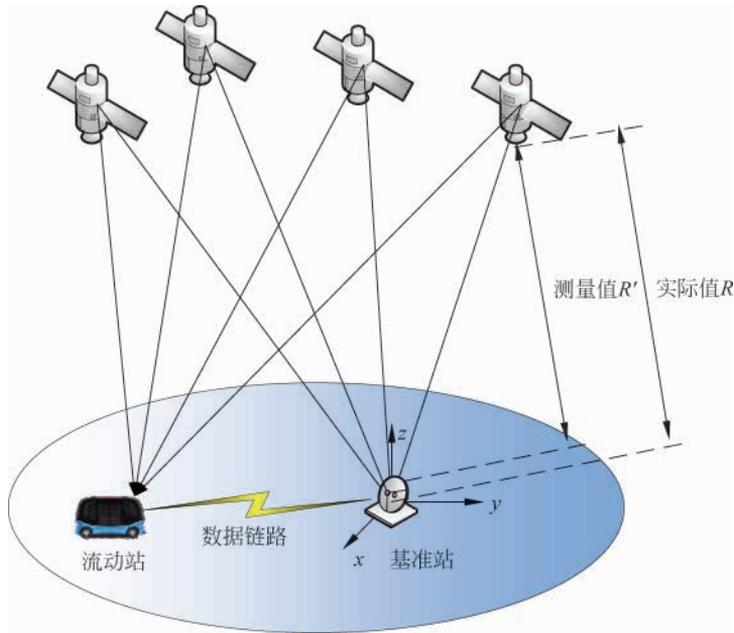


图 3-4 伪距差分系统

3. 载波相位差分

GNSS 位置差分技术与伪距差分技术都能基本满足定位导航等的定位精度需求^[13],但应用在自动驾驶中还远远不够,因此需要更加精准的 GNSS 差分技术,即载波相位差分技术。载波相位实现差分的方法有修正法和差分法。修正法与伪距差分类似,由基准站将载波相位修正量发送给流动站,以改正其载波相位观测值,然后得到自身的坐标。差分法是将基准站观测的载波相位测量值发送给流动站,使其自身求出差分修正量,从而实现差分定位。

载波差分技术的根本是实时处理两个测站的载波相位。与其他差分技术相比,载波相位差分技术中基准站不直接传输关于 GNSS 测量的差分校正量,而是发送 GNSS 的测量原始值。流动站收到基准站的数据后,与自身观测卫星的数据组成相位差分观测值,利用组合后的测量值求出基线向量完成相对定位,进而推算出测量点的坐标。

然而,在使用载波差分法进行相位测量时,每一个相位的观测值都包含有无法直接观测载波的未知整周期数,称为相位整周模糊度。如何正确确定相位整周模糊度是载波相位测量求解中最重要,也是最棘手的问题。求解相位整周模糊度分为有初始化方法和无初始化方法。前者要求具有初始化过程,即对流动站进行一定时间的固定观测,一般需要 15min,利用静态相对测量软件进行求解,得到每颗卫星的相位整周模糊度并固定此值,便于在以后

的动态测量中将此相位整周模糊度作为已知量进行求解。后者虽然称作无初始化,但实际上仍需要时间较短的初始化过程,一般只需 3~5min,随后快速求解相位整周模糊度。因此两种求解相位整周模糊度的方法都需要具备初始化过程,并且在初始化后必须保持卫星信号不失锁,否则,就要回到起算点重新进行捕捉和锁定。

RTK 是一种利用接收机实时观测卫星信号载波相位的技术,结合了数据通信技术与卫星定位技术,采用实时解算和数据处理的方式,能够实现为流动站提供在指定坐标系中的实时三维坐标点,在极短的时间内实现高精度的位置定位。常用的 RTK 定位技术分为常规 RTK 和网络 RTK。

1) 常规 RTK

常规 RTK 定位技术是一种基于 GNSS 高精度载波相位观测值的实时动态差分定位技术,也可用于快速静态定位。采用常规 RTK 进行定位工作时,除需配备基准站接收机和流动站接收机外,还需要数据通信设备,基准站通过数据链路将自己所获得的载波相位观测值及站坐标实时播发给在其周围工作的动态用户。流动站数据处理模块则通过动态差分定位的方式,确定流动站相对于基准站的位置,并根据基准站的坐标得到自身的瞬时绝对位置。常规 RTK 系统如图 3-5 所示。

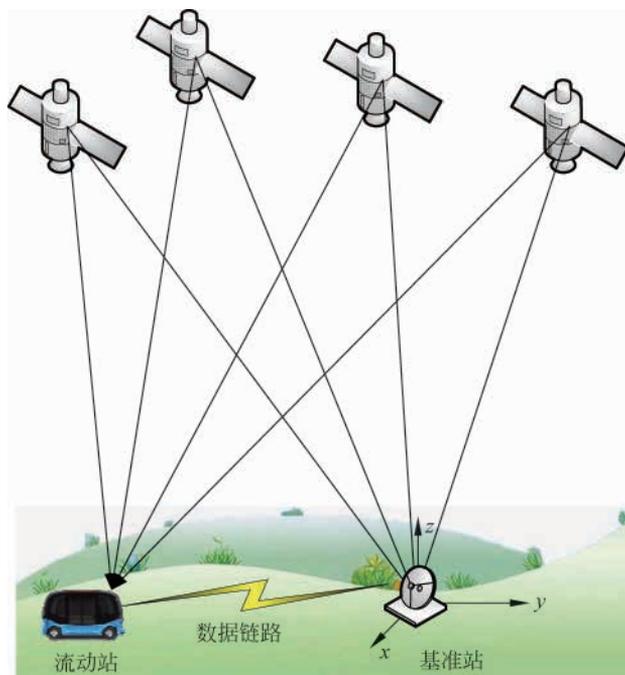


图 3-5 常规 RTK 系统

显然,常规 RTK 定位技术虽然可以满足很多应用的要求,但流动站与基准站的距离不能过远,当距离大于 50km 时,常规 RTK 一般只能达到分米级的定位精度。因此,常规 RTK 并不能完全满足自动驾驶系统对汽车、车道及障碍物的厘米级定位需求。

2) 网络 RTK

(1) 网络 RTK 原理。

网络 RTK 也称多基准站 RTK。网络 RTK 属于实时载波相位双差定位,是近年来一

种基于常规 RTK 和差分 GNSS 技术等发展起来的实时动态定位新技术。网络 RTK 是指在某一区域内由若干个固定的、连续运行的 GNSS 基准站形成一个基准站网络,对区域内全方位覆盖,并以这些基准站中的一个或多个为基准,为该区域内的 GNSS 用户实现实时、高精度定位提供 GNSS 误差改正信息。网络 RTK 技术与常规 RTK 技术相比,覆盖范围更广,作业成本更低,定位精度更高,用户定位的初始化时间更短。

(2) 网络 RTK 系统。

网络 RTK 系统如图 3-6 所示。它是网络 RTK 技术的应用实例,主要包括固定的基准站网、负责数据处理的控制中心部分、数据播发中心、数据链路和用户站。其中基准站网由若干个基准站组成,每个基准站都配备有双频全波长 GNSS 接收机、数据通信设备和气象仪器等。通过长时间 GNSS 静态相对定位等方法可以精确得到基准站的坐标,基准站 GNSS 接收机按一定采样率进行连续观测,通过数据链路将观测数据实时传送给数据处理中心,数据处理中心首先对各个站的数据进行预处理和质量分析,然后对整个基准站网的数据进行统一解算,实时估计出网内的各种系统误差的改正项(电离层、对流层和轨道误差),并建立误差模型。

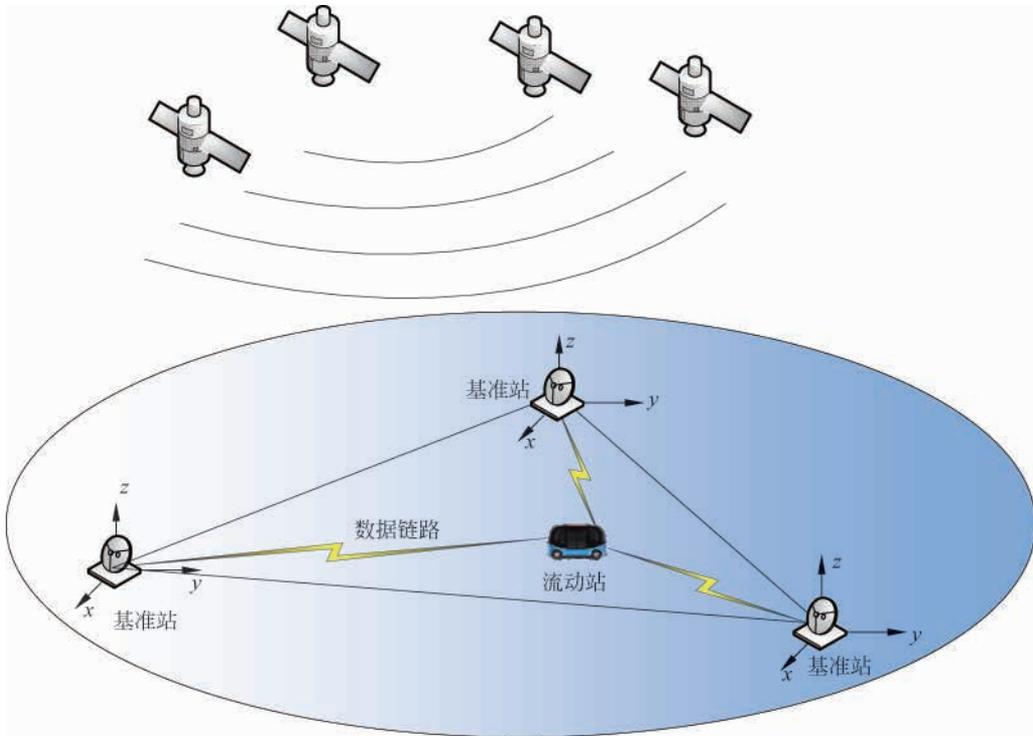


图 3-6 网络 RTK 系统

根据通信方式的不同,可将网络 RTK 系统分为单向数据通信和双向数据通信。在单向数据通信中,数据处理中心直接通过数据播发设备把误差参数广播出去,用户收到这些误差改正参数后,根据自己的坐标和相应的误差改正模型计算出误差改正数,从而进行高精度定位。在双向数据通信中,数据处理中心对流动站的服务请求进行实时侦听,并接收来自流动站的近似坐标,根据流动站的近似坐标和误差模型,求出流动站处的误差后,直接将改正

数或者虚拟观测值播发给用户。基准站与数据处理中心间的数据通信可采用无线通信等方法进行。流动站和数据处理中心间的双向数据通信则可通过 V2X 等车联网通信技术实现, 相关技术详见本书第 4 章内容。

3.2 惯性导航定位技术

惯性是所有质量体本身的基本属性。建立在牛顿定律基础上的惯性导航系统不与外界发生任何光电联系, 仅靠系统本身就能对汽车进行连续的三维定位和三维定向。由于惯性导航系统这种能自主地、隐蔽地获取汽车完备运动信息的优势是诸如 GNSS 等其他定位系统无法比拟的, 所以惯性导航系统一直是自动驾驶中获取汽车位姿数据的重要手段。

惯性导航定位是一门跨多学科的技术, 涉及近代数学、物理学、力学、光学、材料学、微电子和计算机等诸多领域, 内容较为丰富^[14]。本节将从系统简介、工作原理、误差分析等方面对惯性导航定位系统进行介绍。

3.2.1 惯性导航定位系统简介

惯性导航系统是一种不依赖于外部信息, 也不向外部辐射能量的自主式导航系统^[15]。其主要由惯性测量单元、信号预处理和机械力学编排 3 个模块组成, 如图 3-7 所示。



图 3-7 惯性导航系统的主要模块

一个惯性测量单元包括 3 个相互正交的单轴加速度计 (Accelerometer) 和 3 个相互正交的单轴陀螺仪 (Gyroscopes)。惯性测量单元结构如图 3-8 所示。信号预处理部分对惯性测量单元输出信号进行信号调理、误差补偿并检查输出量范围等, 以确保惯性测量单元正常工作。

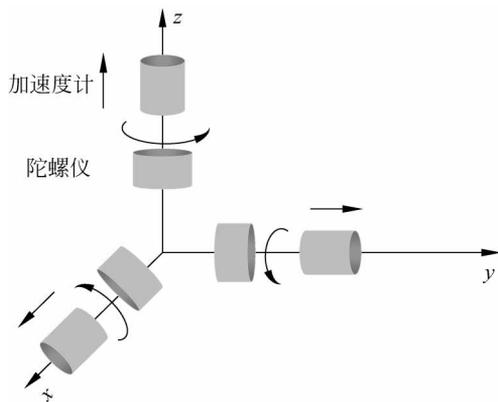
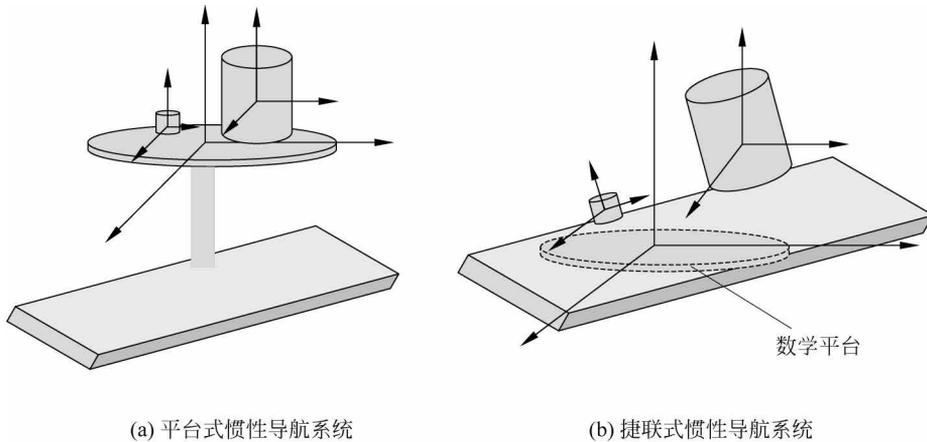


图 3-8 惯性测量单元结构

惯性导航系统根据机械力学编排形式的不同,可分为平台式惯性导航系统(Gimbaled Inertial Navigation System,GINS)和捷联式惯性导航系统(Strap-down Inertial Navigation System,SINS),这两种系统的组成如图 3-9 所示。图 3-9 中的数学平台是为了建立导航坐标系,计算导航数据所虚构的平台。



(a) 平台式惯性导航系统

(b) 捷联式惯性导航系统

■ 图 3-9 平台式惯性导航系统和捷联式惯性导航系统的组成

平台式惯性导航系统是将陀螺仪和加速度计等惯性测量单元通过支架平台与载体固连的惯性导航系统。惯性测量单元固定在平台台体上,系统的敏感轴能直接模拟导航坐标系,这就保证了敏感轴的准确指向,并且隔离了载体的角运动,给惯性测量单元提供了较好的工作环境,使得系统的精度较高,但平台台体也直接导致了系统结构复杂、体积大、制造成本高等不足。捷联式惯性导航系统是把惯性测量单元直接固连在载体上,用计算机来完成导航平台功能的惯性导航系统,载体转动时系统的敏感轴也跟随转动,通过计算载体的姿态角就能确定出惯性测量单元敏感轴的指向,然后将惯性测量单元测量得到的载体运动信息变换到导航坐标系上即可进行航迹递推。基于成本控制考虑,当前自动驾驶领域常用捷联式惯性导航系统。

3.2.2 惯性导航定位系统工作原理

惯性导航系统是一种以陀螺仪和加速度计为感知元件的导航参数解算系统,应用航迹递推算法提供位置、速度和姿态等信息^[16]。汽车行驶数据的采集由以陀螺仪和加速度计组成的惯性测量单元来完成。通常说“用加速度计测量载体的运动加速度”,实际上这个说法并不确切,因为加速度计测量的不是载体的运动加速度,而是载体相对惯性空间的绝对加速度和重力加速度之和,称作“比力”。从加速度计的工作原理可知,加速度计可以输出沿敏感轴方向的比力,其中含有载体绝对加速度。同样地,陀螺仪可以输出车体相对于惯性坐标系的角加速度信号。以上两个惯性传感器组的敏感轴是相互平行的,共享惯性传感器组的原点和敏感轴。因此,如果在汽车上能得到互相正交的 3 个敏感轴上的加速度计和陀螺仪输出,同时又已知敏感轴的准确指向,就可以掌握汽车在三维空间内的运动加速度和角速度。

惯性导航系统工作原理基于牛顿第二运动定律,其说明了加速度的大小与作用力成正

比,方向与作用力的方向相同^[17],数学表达式为:

$$F = ma \quad (3-1)$$

惯性导航系统利用载体先前的位置、惯性测量单元测量的加速度和角速度来确定其当前位置。其中,速度 v 和偏移量 s 都可以通过对加速度 a 的积分得到。如式(3-2)、式(3-3)所示,加速度 a 经过积分得到速度 v ,经过二重积分得到偏移量 s 。相反,速度和加速度也可以通过对位移的微分而估算得到。

$$\begin{cases} v = \int a dt \\ s = \int v dt = \iint a dt dt \end{cases} \quad (3-2)$$

$$v = \frac{ds}{dt}, \quad a = \frac{dv}{dt} = \frac{d^2s}{dt^2} \quad (3-3)$$

类似地,汽车的俯仰、偏航、翻滚等姿态信息都可以通过对角加速度的积分得到。利用姿态信息可以把导航参数从惯性坐标系变换到导航坐标系中^[18]。

综上,惯性导航系统可以说是一个由惯性测量单元和积分器组成的积分系统。该系统通过陀螺仪测量载体旋转信息求解得到载体的姿态信息,再将加速度计测量得到的载体比力信息转换到导航坐标系进行加速度信息的积分运算,就能推算出汽车的位置和姿态信息。

从一个已知的坐标位置开始,根据载体在该点的航向、航速和航行时间,推算下一时刻该坐标位置的导航过程称为航迹递推^[19]。航迹递推是一种非常原始的定位技术,最早是海上船只根据罗经和计程仪所指示的航向、航程以及船舶操纵要素与风流要素等,在不借助外界导航物标的条件下求取航迹和船位,逐渐演化成如今自动驾驶汽车定位技术中最常用的方法。

正如前面所提到的,惯性导航定位基于一个简单的原理,那就是位置的差异可以由一个加速度的双重积分得到,可以被描述为在一个稳定坐标系下并且被明确定义的与时间相关的函数,可表述为:

$$\Delta s = s_t - s_0 = \int_0^t \int_0^t a_t dt dt \quad (3-4)$$

式中, s_0 为初始位置, a_t 是在 s_t 规定的坐标系中的惯性测量单元测量得到的沿运动方向的加速度。

接下来介绍一维航迹递推和二维航迹递推的导航例子,然后,简要叙述三维航迹递推的基本思路。

1. 一维航迹递推

对于一维航迹递推,考虑在如图 3-10 所示的汽车直线(即在一个固定的方向)上移动的场景。要在这种情况下进行航迹递推,只需要将一个加速度计安装在汽车上,并使加速度计的敏感轴方向与汽车运动方向一致,即可得到速度和位置。

已知汽车的初始位置 s_0 、初始速度 v_0 ,通过对加速度 a 进行积分即可得到汽车在 t 时刻的速度 v_t ,即

$$v_t = \int a dt = at + v_0 \quad (3-5)$$

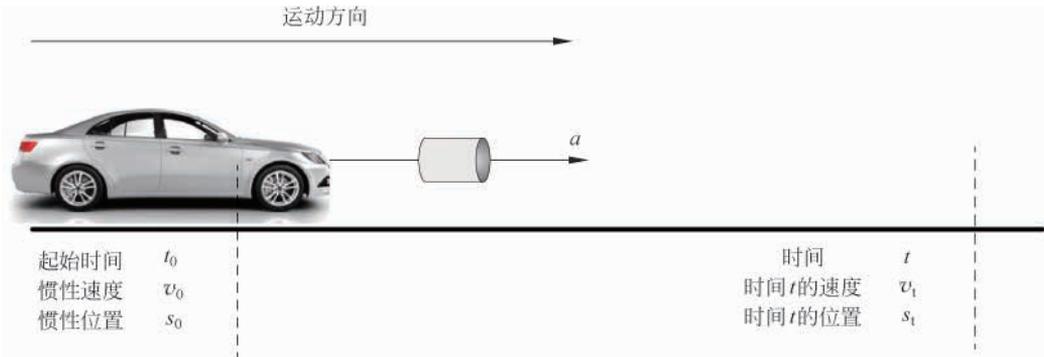


图 3-10 一维惯性导航

对速度 v_t 进行积分得到汽车在 t 时刻的位置 s_t ：

$$\begin{aligned}
 s_t &= \int v_t dt \\
 &= \int (at + v_0) dt \\
 &= \frac{1}{2}at^2 + v_0t + s_0
 \end{aligned} \tag{3-6}$$

2. 二维航迹递推

航迹递推从一维拓展到二维的难点主要在于需要将惯性坐标系(坐标轴为 x, y , x 轴与汽车航向保持一致)下的加速度变换到一个与地球固连的坐标系下,常用的是地理坐标系,也称为导航坐标系(坐标轴为 E, N , N 轴与地理北向保持一致)。

在二维航迹递推中,将汽车看作是在二维平面(x, y)上的运动,需要已知汽车的起始点(x_0, y_0)和起始航向角 A_0 。通过实时检测汽车在 x, y 两个方向上的行驶距离和航向角的变化,即可实时推算汽车的二维位置。

图 3-11 是将曲线运动近似为直线运动的捷联式惯性导航二维航迹递推示意图,其中黑色圆点表示汽车位置, θ 表示汽车与北向间的夹角,圆柱体表示加速度计与陀螺仪,陀螺仪敏感轴垂直于纸面向外。在进行类似一维航迹递推中的积分运算前,需要将惯性测量单元的输出转换到导航坐标系中。汽车转弯将使陀螺仪产生一个相对于导航坐标系方向角变化的角速度 ω ,结合初始航向角 A_0 ,对陀螺仪测量得到的角速度进行积分可以得到航向角 A_t 。

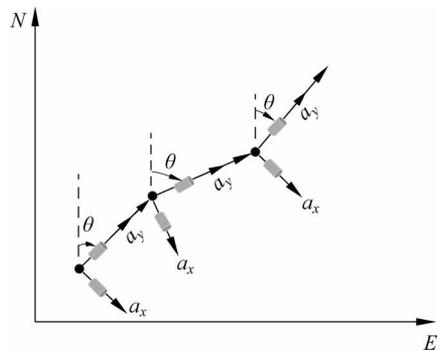


图 3-11 捷联式惯性导航二维航迹递推示意图

$$A_t = \int \omega dt + A_0 \tag{3-7}$$

汽车速度变化将产生 IMU 坐标系下的加速度 a_y ,但是推算需要在导航坐标系中的加速度 a_N ,使用航向角 A_t 可以将惯性测量单元的测量信息转换到导航坐标系中。坐标系的转换如图 3-12 所示。

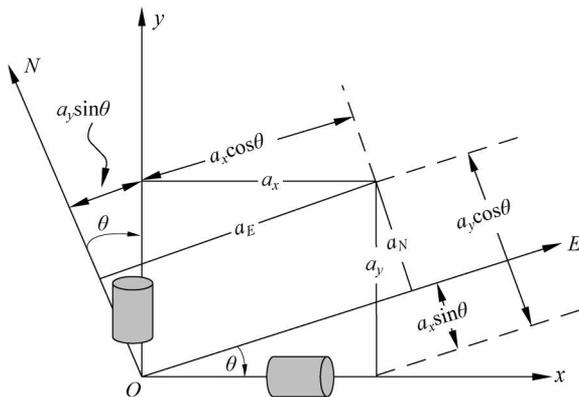


图 3-12 惯性坐标系到导航坐标系的转换

IMU 坐标轴 x 、 y 与导航坐标轴 E 、 N 存在夹角 θ , 因此加速度 a_E 和加速度 a_N 可以写为

$$a_E = a_y \sin\theta + a_x \cos\theta \quad (3-8)$$

$$a_N = a_y \cos\theta - a_x \sin\theta \quad (3-9)$$

矩阵形式为

$$\begin{pmatrix} a_E \\ a_N \end{pmatrix} = \begin{pmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{pmatrix} \begin{pmatrix} a_x \\ a_y \end{pmatrix} \quad (3-10)$$

其中, $\begin{pmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{pmatrix}$ 为坐标转换的二维旋转矩阵。

得到导航坐标系中的加速度, 即可对其积分得到速度:

$$\begin{cases} v_E = \int (a_y \sin\theta + a_x \cos\theta) dt \\ v_N = \int (a_y \cos\theta - a_x \sin\theta) dt \end{cases} \quad (3-11)$$

再进行积分, 得到导航坐标系中的位置:

$$\begin{cases} x_E = \iint (a_y \sin\theta + a_x \cos\theta) dt dt \\ x_N = \iint (a_y \cos\theta - a_x \sin\theta) dt dt \end{cases} \quad (3-12)$$

矩阵形式为

$$\begin{pmatrix} x_E \\ x_N \end{pmatrix} = \iint \begin{pmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{pmatrix} \begin{pmatrix} a_x \\ a_y \end{pmatrix} dt dt \quad (3-13)$$

3. 三维航迹递推

三维航迹递推需要 3 个陀螺仪来测量载体相对于惯性空间的旋转角速率, 需要 3 个加速度计来测量载体相对惯性空间受到的比力。如图 3-13 所示, 载体的合加速度是重力加速度和其他外力产生的加速度的合成。为了消除重力加速度分量, 须知道加速度计相对于重力方向的角度, 这个可以由解算的姿态矩阵给出。与二维航迹递推类似, 对陀螺仪测量的角

速度进行积分可以得到 3 个姿态角,去掉重力加速度的同时通过三维旋转矩阵将加速度计测量值投影到导航坐标系中。下面给出基础三维旋转矩阵,其中 γ 、 α 、 β 角分别对应 3 个姿态角翻滚角、俯仰角、航向角,式(3-14)~式(3-16)分别表示绕 x 、 y 、 z 轴旋转 γ 、 α 、 β 角的旋转矩阵。

$$\mathbf{R}_x(\gamma) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos\gamma & \sin\gamma \\ 0 & -\sin\gamma & \cos\gamma \end{pmatrix} \quad (3-14)$$

$$\mathbf{R}_y(\alpha) = \begin{pmatrix} \cos\alpha & 0 & -\sin\alpha \\ 0 & 1 & 0 \\ \sin\alpha & 0 & \cos\alpha \end{pmatrix} \quad (3-15)$$

$$\mathbf{R}_z(\beta) = \begin{pmatrix} \cos\beta & \sin\beta & 0 \\ -\sin\beta & \cos\beta & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (3-16)$$

对于上述 3 个基础旋转矩阵,其旋转次序不可忽略,旋转次序也称顺规,顺规可以自由组合。对于 γ 、 β 、 α 角在不同的顺规中有不同的复合旋转矩阵结果,例如先绕 x 轴旋转 γ ,或者先绕 y 轴旋转 β ,最后会得出不同的复合旋转矩阵。一般情况下不同顺规完成的旋转效果相同,但当 y 轴旋转 90° 时,会导致 x 轴和 z 轴重合而失去 x 轴的自由度,即万向节死锁(Gimbal Lock)。下面举例说明复合旋转矩阵的计算, zyx 顺规下的复合旋转矩阵为:

$$\begin{aligned} & R(\gamma, \alpha, \beta) \\ &= R_x(\gamma)R_y(\alpha)R_z(\beta) \\ &= \begin{pmatrix} \cos(\alpha)\cos(\beta) & \cos(\alpha)\sin(\beta) & -\sin(\alpha) \\ -\cos(\gamma)\sin(\beta) + \sin(\gamma)\sin(\alpha)\cos(\beta) & \cos(\gamma)\cos(\beta) + \sin(\gamma)\sin(\alpha)\sin(\beta) & \sin(\gamma)\cos(\alpha) \\ \sin(\gamma)\sin(\beta) + \cos(\gamma)\sin(\alpha)\cos(\beta) & -\sin(\gamma)\cos(\beta) + \cos(\gamma)\sin(\alpha)\sin(\beta) & \cos(\gamma)\cos(\alpha) \end{pmatrix} \end{aligned} \quad (3-17)$$

结合初始航向角,对这 3 个加速度做一次积分可得到三维的速度信息,通过两次积分运算可得到三维的位置信息。

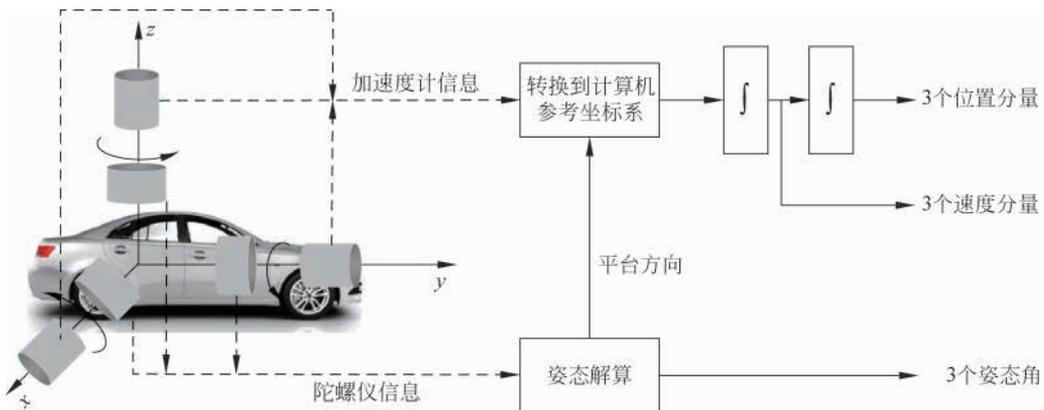


图 3-13 三维航迹递推

3.2.3 惯性导航定位系统误差分析

前面提到,惯性导航系统不与外界发生任何光电联系,仅靠系统本身就能对汽车进行连续三维定位和定向,其通过在内部所感知到的情况来推断外面的情况,使得惯性导航被称为“在盒子里导航”或“黑盒导航”。如图 3-14 所示,惯性导航系统中既有电子设备,又有机械结构,在外部冲击、振动等力学环境中,除了需要的加速度和角速度之外,还有很多误差源^[20]。本节介绍随机误差和固定误差。

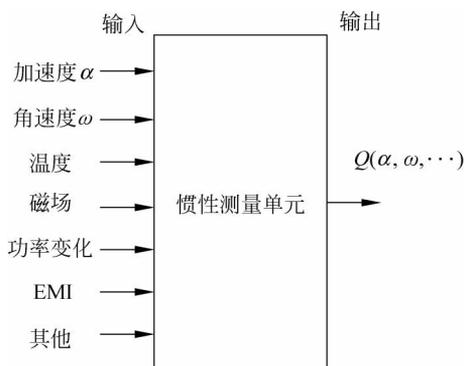


图 3-14 惯性测量单元黑盒模型

1. 随机误差

(1) 传感器白噪声误差。该噪声通常与电子噪声合在一起,可能是来自电源、半导体设备内部的噪声或数字化过程中的量化误差。

(2) 变温误差。传感器偏差的变温误差类似时变的加性噪声源,是由外部环境温度变化或内部热分布变化引起的。

(3) 传感器随机游动误差。在惯性测量单元中,对随机游动噪声有具体要求,但大多数都针对其输出的积分,而不是输出本身。例如,来自速率陀螺仪的“角度随机游走”等同于角速度输出白噪声的积分。类似地,加速度计的“速度随机游走”等同于加速度计输出白噪声的积分。随机游动误差随着时间线性增大,其功率谱密度也随之下降。

(4) 谐波误差。由于热量传输延迟,所以温度控制方法(如通风与空调系统)经常引入循环误差,这些都可在传感器输出中引入谐波误差,谐波周期取决于设备的尺寸大小。同样,主载体的悬挂和结构共振也引入了谐波加速度,它会对传感器中的加速度敏感误差源产生影响。

(5) 闪烁噪声误差。闪烁噪声是陀螺仪零偏随时间漂移的主要因素。多数电子设备中都存在这种噪声,该噪声通常模型化为白噪声和随机游动的组合。

2. 固定误差

与随机误差不同,固定误差是可重复的传感器输出误差。常见的传感器误差模型如图 3-15 所示,包括:偏差,即输入为零时传感器的任何非零的输出;尺度因子误差,常来自标定偏差;非线性,不同程度地存在于多种传感器中;尺度因子符号不对称性,来自不匹配的推挽式的放大器;死区误差,通常由机械静摩擦力或死锁引起;量化误差,这在所

有数字系统中是固有的。由于它可能存在于标准化环境中,当输入不变时它可能不是零均值的。

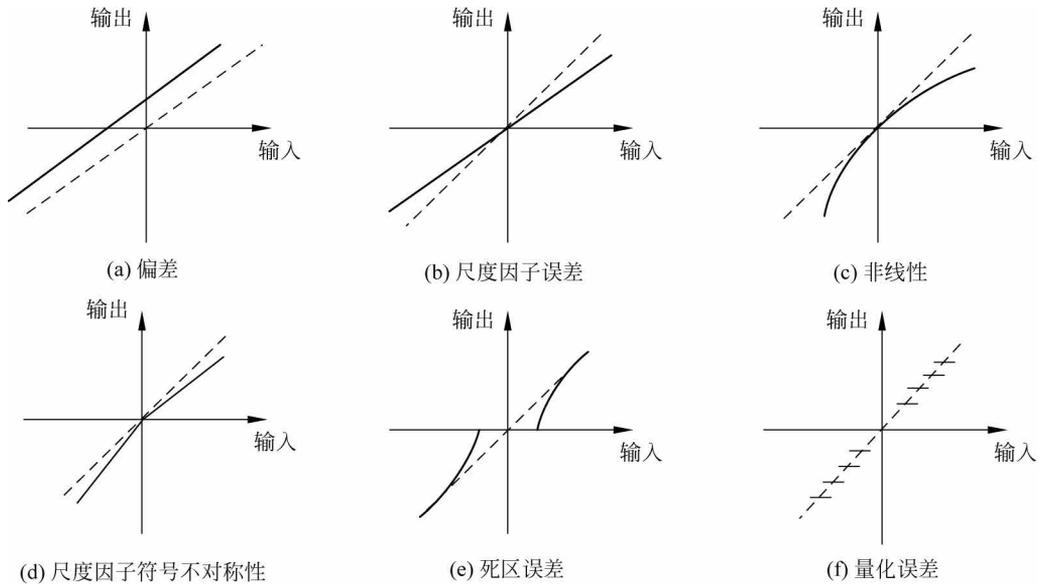


图 3-15 常见的传感器误差模型

3.3 地图匹配定位技术

地图匹配定位利用实时道路物理信息与预制高精度地图进行匹配来实现汽车定位的技术。在卫星定位、惯性导航系统出现明显误差时,即可利用地图匹配定位技术为自动驾驶汽车提供定位修正信息。本节将从地图匹配定位技术的简介、原理、误差分析以及地图匹配常用算法等方面进行介绍。

3.3.1 地图匹配定位技术简介

无论是 GNSS 定位还是惯性导航定位,自动驾驶汽车定位系统的误差都是不可避免的,定位结果通常偏离实际位置。引入地图匹配可以有效消除系统随机误差,校正传感器参数,弥补在城市高楼区、林荫道、立交桥、隧道中长时间 GNSS 定位失效而惯性导航系统误差急剧增大时的定位真空期。

地图匹配定位技术是指将自动驾驶汽车行驶轨迹的经纬度采样序列与高精度地图路网匹配的过程。地图匹配定位技术将汽车定位信息与高精度地图提供的道路位置信息进行比较,并采用适当的算法确定汽车当前的行驶路段以及在路段中的准确位置,校正定位误差^[21],并为自动驾驶汽车实现路径规划提供可靠依据。

如图 3-16 所示,由于各种原因导致自动驾驶汽车定位信息存在误差,尽管汽车行驶在中间车道上,但定位结果与实际情况存在偏差,利用地图匹配定位技术可将汽车定位信息纠正回正确车道,提高定位精度。

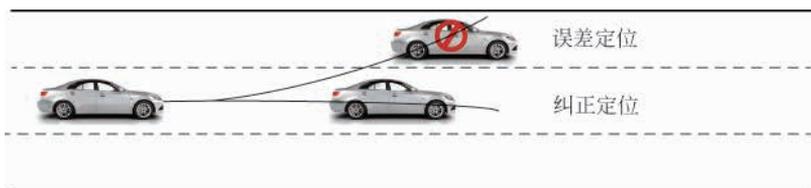


图 3-16 地图匹配定位效果示意图

3.3.2 地图匹配定位技术原理

地图匹配定位是在已知汽车的位姿信息的条件下进行高精度地图局部搜索的过程。首先,利用汽车装载的 GNSS 和 INS 做出初始位置判断,确定高精度地图局部搜索范围。然后,将激光雷达实时数据与预先制作好的高精度地图数据变换到同一个坐标系内进行匹配,匹配成功后即可确认汽车定位信息。地图匹配定位流程图如图 3-17 所示。

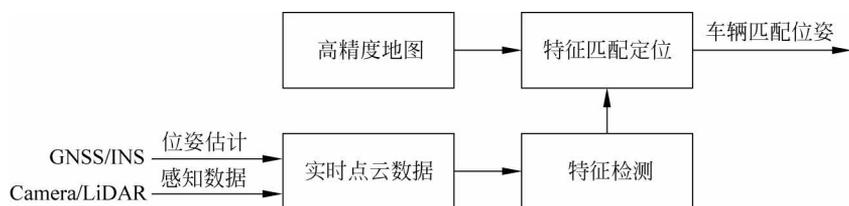


图 3-17 地图匹配定位流程图

高精度地图的预制是地图匹配的基础,需包含特征明显的结构化语义特征和具有统计意义的信息。高精度地图中常用于地图匹配的特征主要包含车道线、停止线、导流线、路灯、电线杆等特征明显的物体,同时,还包括平均反射值、方差及平均高度值等具有统计意义的信息。下面将以示意图的方式说明地图匹配定位技术原理。

在自动驾驶过程中,位姿信息可能存在较大误差,不能满足自动驾驶定位精度要求^[22],仅能确定其在道路上的大致位置,如图 3-18 所示。



图 3-18 误差定位位姿图

图 3-18 中带有“不执行”符号的汽车表示不可用的、带有误差的 GNSS 或惯性导航系统定位位姿。根据实时感知数据进行环境特征的检测,主要检测对象是地面上的车道线与杆状物,并从高精度地图对应位置范围内提取对应的元素。实际匹配过程中,系统将检测出的车道线、护栏等道路特征与高精度地图提供的道路特征进行对比,修正汽车的横纵向定位,如图 3-19 和图 3-20 所示。图中不带有“不执行”符号的汽车为修正后的汽车定位位姿。



图 3-19 修正横向位姿示意图

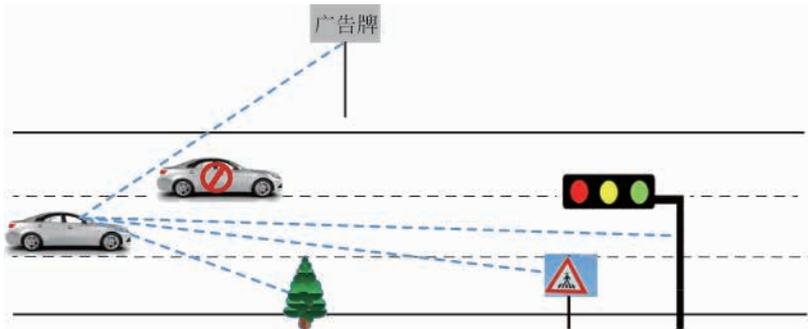


图 3-20 修正纵向位姿示意图

如图 3-19 所示,GNSS 将汽车定位在前进方向的左侧车道,自动驾驶汽车利用传感器检测到的车道线信息与高精度地图数据进行匹配后,确定汽车位于前进方向中间车道,与 GNSS 的定位结果存在差异,进而修正横向的位姿误差。如图 3-20 所示,纵向上修正主要提取传感器所检测到的广告牌、红绿灯、交通标志灯等道路元素与高精度地图进行匹配,可以修正汽车的纵向误差。

3.3.3 地图匹配定位误差分析

地图匹配定位误差主要由局部搜索范围正确性问题引起。局部搜索范围正确性即道路选择的正确性,是地图匹配中极大的影响因素之一,在选择道路正确的情况下,才能继续之后的地图匹配过程。造成道路选择错误的原因主要包括路况引起的误差、传感器误差、高精度地图误差及算法误差等方面。

1. 路况引起的误差

真实道路的情况复杂而多变,无法保证汽车在各种复杂路况上都能够正确地提取特征,并实现正确定位。车速变化将会影响传感器采集数据的质量,车速越快,质量越低,甚至产生运动模糊、失真等情况。在没有 INS 的定位系统中,各种路况下造成的汽车轮胎的漂移及地面颠簸等情况都可能使激光点云数据存在畸变、抖动和运动模糊等问题。与此同时,实际行驶情况中汽车有时会离开道路,这将导致道路匹配错误并引起误差。

2. 传感器误差

进行地图匹配需要利用传感器的量测信息(如激光雷达、摄像头),这些数据存在误差将直接影响定位速度与成功率。

3. 高精度地图误差

在实际使用中,一般默认高精度地图的精度比传感器获得的数据精度高,但实际上,高精度地图同样有可能存在较大误差。在地图数据本身存在误差时,即使在正确选择道路的情况下也会引入误差。

4. 算法误差

在地图匹配过程中不可避免地因算法存在的缺点导致发生错误匹配,发生错误匹配会对之后的地图匹配定位结果产生恶劣的影响。

3.3.4 地图匹配常用算法

任何一种地图匹配算法都涉及两个根本的问题:①当前汽车在哪一条道路上;②当前汽车在对应道路的哪一个位置。因此,地图匹配算法几乎都可以用式(3-18)进行形式化描述:

$$\hat{X}_n = f((X_0, X_1, X_2, \dots, X_n)^T, G(R, N)) \quad (3-18)$$

式中, X_n 表示 n 时刻汽车的原始状态信息,如定位数据、速度、行驶方向等; G 表示道路网络,由道路路段集 R 以及道路节点集 N 构成。根据不同的地图匹配特点,将地图匹配算法分为几何匹配算法、概率统计算法和其他高级算法。

1. 几何匹配算法

几何匹配算法包括点到点、点到弧和弧到弧的地图匹配算法^[23]。

1) 点到点的地图匹配算法

点到点的地图匹配算法的原理即搜索汽车定位点与高精度地图中位置点之间几何距离最近的点作为匹配结果。该算法匹配精度取决于位置点集的数量,随着位置点集数量的增大,匹配精度更高,但占用的硬件资源也更多。点到点的地图匹配算法得到的匹配结果很可能与实际不符,如在一条笔直道路上,待匹配 GNSS 点都会错误地匹配到道路两端的节点上,这样得到的匹配精度显然不符合实际使用要求。

2) 点到弧的地图匹配算法

通过寻找与汽车定位点几何距离最近的路段作为匹配线段,将汽车定位点投影到该线段上作为匹配结果。对于曲线则做线性化处理后进行投影,该算法只利用了部分数据,当两条曲线距离较小或相同时极易造成误匹配,在路网密度大时匹配的结果的精度就会锐减,此时的算法缺乏稳定性。

3) 弧到弧的地图匹配算法

将连续的汽车定位点组成一条轨迹曲线,寻找与这条曲线最近的匹配弧线作为匹配线段。由于最近路段的寻找方法是基于匹配路段与定位点的最小距离,所以,若某定位点与非正确匹配线段非常近,将导致严重误差。

2. 概率统计算法

概率统计算法通过在汽车导航定位系统中获得的历史轨迹,建立置信区域来与高精度地图进行匹配。置信区域参考 GNSS 误差、汽车航迹、汽车速度及道路信息等进行选取,与高精度地图匹配后采取最近距离原则来确定匹配线段。

一个完整的基于概率统计的地图匹配算法包括三个主要的处理过程,即确定误差区域、选取候选路段和计算匹配位置。基于概率统计算法地图匹配的一般过程如图 3-21 所示。

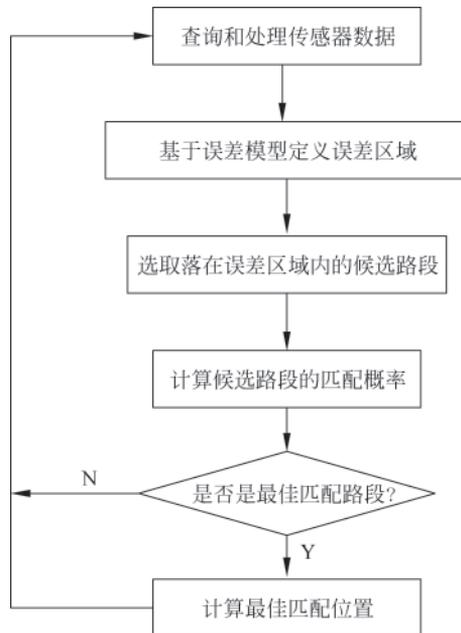


图 3-21 基于概率统计算法地图匹配的一般过程

误差区域是指可能包含汽车真实位置的区域范围,它应根据传感器定位结果和误差情况确定。在误差区域内的道路称为候选路段,地图匹配算法认为其中包含了汽车的真实位置。匹配路段的选取方法是从候选路段中挑选最有可能的是汽车行驶路段,挑选原则依据具体的算法设计而不同,通常,挑选参考量是高精度地图中的道路形状与汽车轨迹的相似程度。确定匹配路段后,计算汽车在该路段中最可能的位置,并用匹配结果修正原有的定位信息并输出。

3. 其他高级算法

除了上述两种地图匹配算法外,还有非参数滤波算法和参数滤波算法等。非参数滤波算法包括了直方图滤波(Histogram Filter, HF)和粒子滤波(Particle Filter, PF)等。参数滤波算法包括卡尔曼滤波、扩展卡尔曼滤波(Extended Kalman Filter, EKF)、信息滤波(Information Filter, IF)、扩展信息滤波(Extended Information Filter, EIF)等。这些算法在固定场景下有很高的匹配准确率,但需要大量的数据进行参数的前期学习和总结,对系统的要求较高。

3.4 多传感器融合定位技术

由于 GNSS 定位信息更新频率低,不能满足自动驾驶中实时性的要求,且定位信号会因隧道、建筑群等障碍物的遮挡而中断。而 INS 中配备高频传感器,一定时间内可以提供

连续的较高精度的汽车位置、速度和航向信息,但其定位误差会随着系统运行时间累积而剧增。将 GNSS 与 INS 相结合,可以利用 GNSS 提供的不随时间增加的高精度定位来纠正 INS 的累积定位误差^[24]。同时,INS 可以解决 GNSS 特定场景易受影响的问题^[25]。通过结合这两种系统的优点,就能得到实时和精准的定位。如果再与地图匹配技术相结合,利用高精度地图提供的信息,可进一步提高定位精度^[26]。

要实现多个定位系统融合,提高定位精度,设计一种融合多个传感器数据的系统尤为重要。本节将从多传感器融合系统简介、系统原理、误差分析以及融合算法等方面对多传感器融合定位系统进行介绍。

3.4.1 多传感器融合系统简介

多传感器数据融合是 20 世纪 80 年代出现的一门新兴学科,它是将不同传感器对某一目标或环境特征描述的信息融合成统一的特征表达信息及其处理的过程。在多传感器系统中,各种传感器提供的信息可能具有不同的特征,如模糊的与确定的、时变的与非时变的、实时的与非实时的等。多传感器数据融合实际上是模拟人脑综合处理复杂问题的过程^[27],通过对各种传感器及其观测信息的合理支配与使用,将各种传感器在空间和时间上的互补与冗余信息,依据某种优化准则加以组合,产生对观测环境或对象的一致性解释和描述,实现多个传感器共同或联合操作,提高整个传感器系统的有效性。数据融合的目标是利用各种传感器的独立观测信息,对数据进行多级别、多方位和多层次的处理,产生新的有意义的信息,这种信息是最佳协同作用的结果,是任何单一传感器无法获得的。

自动驾驶汽车定位的主要模式有 DR、GNSS、GNSS/DR 组合定位模式。在系统精度要求不高的前提下可以单独使用这 3 种定位模式。为了进一步提高定位系统的精度,保障自动驾驶的安全,在上述 3 种定位模式中引入了地图匹配,可组合产生出新的 3 种定位模式: DR/MM、GNSS/MM、GNSS/DR/MM。多传感器融合定位系统可在 6 种模式中自动切换以提高整个系统的定位精度和可靠性。接下来对多传感器融合系统体系结构以及系统分层进行介绍。

1. 多传感器融合系统体系结构

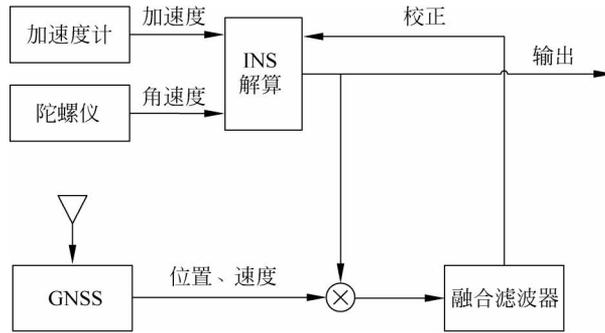
多传感器融合系统体系结构主要包括松耦合(Loosely Coupled)、紧耦合(Tightly Coupled)以及深耦合(Deep Coupling)等组合结构^[28-29]。

1) 松耦合

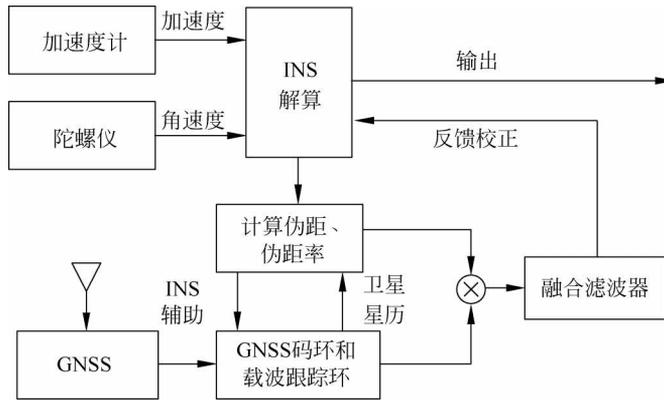
在松耦合系统里,GNSS 给 INS 提供位置信息,二者硬件上相互独立且可随时断开连接,分别输出定位信息与速度信息到融合滤波器,融合滤波器进行优化处理后将结果反馈给惯性导航系统对其修正后进行输出。GNSS/INS 松耦合系统原理图如图 3-22 所示。

2) 紧耦合

紧耦合系统是将由 GNSS 码环与载波跟踪环解算得到的伪距、伪距率与由惯性导航系统结合自身信息和卫星星历进行计算得到的伪距、伪距率做差,得到伪距与伪距率的测量残差,将其作为融合滤波器的输入观测量,得到惯性导航系统计算误差以及传感器偏差以完成对惯性导航系统的校正并获得位置与速度的最优估计值。GNSS/INS 紧耦合系统原理图如图 3-23 所示。



■ 图 3-22 GNSS/INS 松耦合系统原理图



■ 图 3-23 GNSS/INS 紧耦合系统原理图

3) 深耦合

深耦合系统相对于紧耦合系统,增加了INS单元对GNSS接收机的辅助。利用INS单元结合星历信息可以对伪距与载波的多普勒频移进行估计,利用估计结果辅助接收机的捕获与跟踪环路,可以有效地提高GNSS接收机跟踪环路的动态性与灵敏度。

2. 多传感器融合系统分层

如图 3-24 所示,按照信息处理的流程,可将多传感器融合系统划分为数据层融合、特征层融合和决策层融合^[30]。



■ 图 3-24 多传感器数据融合的 3 个层次

1) 数据层融合

数据层融合也称像素级融合,首先将传感器的观测数据融合,然后从融合的数据中提取特征向量,并进行判断识别。数据层融合需要传感器是同质的(传感器观测的是同一物理量),如果多个传感器是异质的(传感器观测的不是同一个物理量),那么数据只能在特征层或决策层进行融合。数据层融合不存在数据丢失的问题,得到的结果也是最准确的,但计算

量大,且对系统通信带宽的要求很高。

2) 特征层融合

特征层融合属于中间层次,先从每种传感器提供的观测数据中提取有代表性的特征,这些特征融合成单一的特征向量,然后运用模式识别的方法进行处理。这种方法的计算量及对通信带宽的要求相对较低,但部分数据的舍弃使其准确性有所下降。

3) 决策层融合

决策层融合指在每个传感器对目标做出识别后,再将多个传感器的识别结果进行融合,属于高层次的融合。决策层融合由于对可能包含误差的传感器数据进行再处理,产生的结果相对而言最不准确,但其计算量及对通信带宽的要求最低。

3.4.2 多传感器融合定位系统原理

多传感器数据融合定位系统的输入主要来自 GNSS-RTK、惯性导航系统和地图匹配定位系统。融合定位系统对其数据进行预处理、数据配准和数据融合等处理后,可输出汽车自身的速度、位置和姿态信息。图 3-25 所示为多传感器数据融合定位流程示意图。

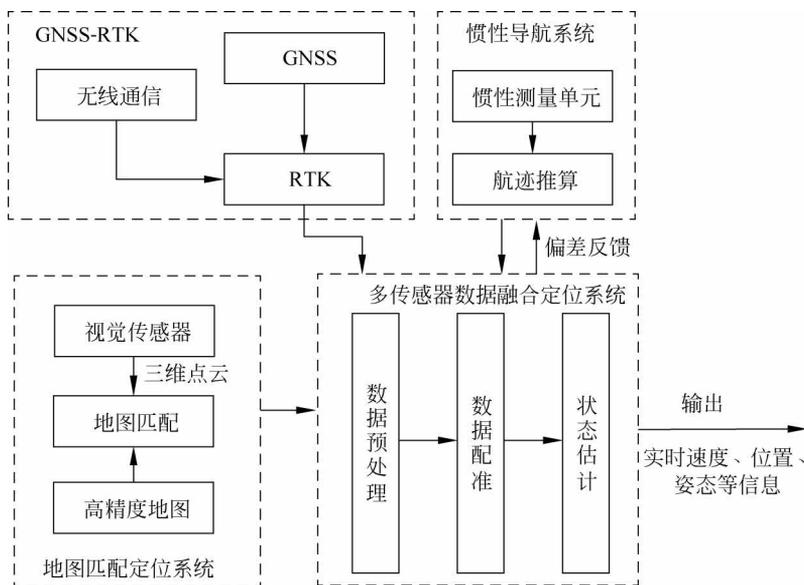


图 3-25 多传感器数据融合定位流程示意图

数据预处理可以考虑为传感器初始化及校准,传感器初始化相对于系统坐标独立地校准每一个传感器。一旦完成了传感器初始化,就可以利用各传感器对共同目标采集得到的数据进行数据配准。所谓数据配准,就是把来自一个或多个传感器的观测或点迹数据与已知或已经确认的事件归并到一起,保证每个事件集合所包含的观测与点迹数据来自同一个实体的概率较大。具体地说,就是要把每批目标的观测或点迹数据与事件集合中各自的数据配对^[31]。在传感器配准过程中,收集足够的点迹数据来计算系统偏差,计算得到的系统偏差用来调整随后得到的传感器数据。其中,传感器的配准主要包括时间配准和空间配准两个方面^[32]。

1. 时间配准

时间配准,就是将关于同一目标的各传感器不同步的量测信息同步到同一时刻。由于各传感器对目标的量测是相互独立进行的,且采样周期(如惯性测量单元和激光雷达的采样周期)往往不同,所以它们向数据处理中心报告的时刻往往也是不同的。另外,由于通信网络的不同延迟,各传感器和融合处理中心之间传送信息所需的时间也各不相同,因此,各传感器上数据的发送时间有可能存在时间差,所以融合处理前需将不同步的信息配准到相同的时刻。

时间配准的一般做法是将各传感器数据统一到扫描周期较长的一个传感器数据上^[33],目前,常用的方法包括最小二乘法(Least Squares, LS)和内插外推法^[34]。这两种方法都对目标的运动模型做了匀速运动的假设,对于做变加速运动的目标,配准效果往往很差。下面仅对基于最小二乘法的时间配准法做简单介绍^[35]。

假设有两类传感器,分别表示为传感器 1 和传感器 2,其采样周期分别为 τ 和 T ,且两者之比为 $\tau:T=n$,如果第一类传感器 1 对目标状态的最近一次更新时刻为 t_{k-1} ,下一次更新时刻为 $t_k=t_{k-1}+nT$,这就意味着在传感器 1 连续两次目标状态更新之间传感器 2 有 n 次量测值。因此可采用最小二乘法,将传感器 2 的 n 次量测值进行融合,就可以消除由于时间偏差而引起的对目标状态量测的不同步,从而消除时间偏差对多传感器数据融合造成的影响。

用 $\mathbf{Z}_n=[z_1, z_2, \dots, z_n]^T$ 表示传感器 2 在 $t_{k-1} \sim t_k$ 时刻的 n 个位置量测构成的测量矩阵, z_n 和传感器 1 在 t_k 时刻的量测值同步,若用 $\mathbf{U}=[z, \dot{z}]^T$ 表示 z_1, z_2, \dots, z_n 融合以后的量测值及其导数构成的列向量,则传感器 2 的量测值 z_i 可以表示为

$$z_i = z + (i - n)T\dot{z} + v_i, \quad i = 1, 2, \dots, n \quad (3-19)$$

式中, v_i 表示量测噪声。将上式改写为向量形式:

$$\mathbf{Z}_n = \mathbf{W}_n \mathbf{U} + \mathbf{V}_n \quad (3-20)$$

其中 $\mathbf{V}_n=[v_1, v_2, \dots, v_n]^T$,其均值为零,协方差阵为

$$\text{cov}(\mathbf{V}_n) = \text{diag}\{\sigma_r^2, \sigma_r^2, \dots, \sigma_r^2\} \quad (3-21)$$

其中, σ_r^2 为融合以前的位置量测噪声方差,同时有

$$\mathbf{W}_n = \begin{bmatrix} 1 & 1 & \dots & 1 \\ (1-n)T & (2-n)T & \dots & (n-n)T \end{bmatrix}^T \quad (3-22)$$

根据最小二乘准则得到目标函数:

$$J = \mathbf{V}_n^T \mathbf{V}_n = [\mathbf{Z}_n - \mathbf{W}_n \hat{\mathbf{U}}]^T [\mathbf{Z}_n - \mathbf{W}_n \hat{\mathbf{U}}] \quad (3-23)$$

要使 J 为最小,在 J 两边对 $\hat{\mathbf{U}}$ 求偏导数并令其等于零:

$$\frac{\partial J}{\partial \hat{\mathbf{U}}} = -2(\mathbf{W}_n^T \mathbf{Z}_n - \mathbf{W}_n^T \mathbf{W}_n \hat{\mathbf{U}}) = 0 \quad (3-24)$$

从而有

$$\hat{\mathbf{U}} = [\hat{z}, \hat{\dot{z}}] = (\mathbf{W}_n^T \mathbf{W}_n)^{-1} \mathbf{W}_n^T \mathbf{Z}_n \quad (3-25)$$

相应的误差协方差阵为

$$\mathbf{R}_{\hat{\mathbf{U}}} = (\mathbf{W}_n^T \mathbf{W}_n)^{-1} \sigma_r^2 \quad (3-26)$$

对传感器 2 的 n 个测量值进行融合得 t_k 时刻的量测值及量测噪声方差分别为

$$\hat{z}_{i_k} = c_1 \sum_{i=1}^n z_i + c_2 \sum_{i=1}^n i \cdot z_i \quad (3-27)$$

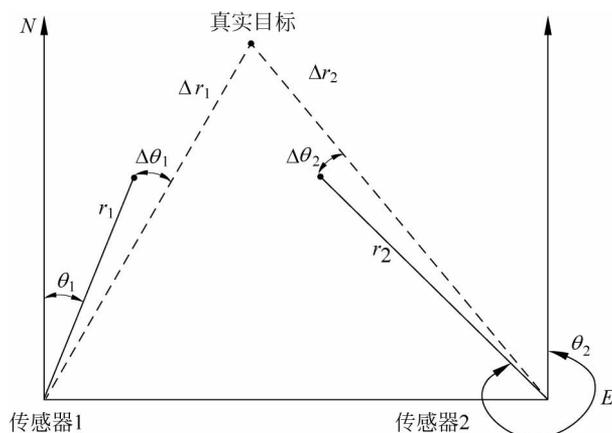
$$\text{var}[\hat{z}_{i_k}] = \frac{2\sigma_r^2(2n+1)}{n(n+1)} \quad (3-28)$$

式中 $c_1 = -2/n$, $c_2 = 6/[n(n+1)]$ 。

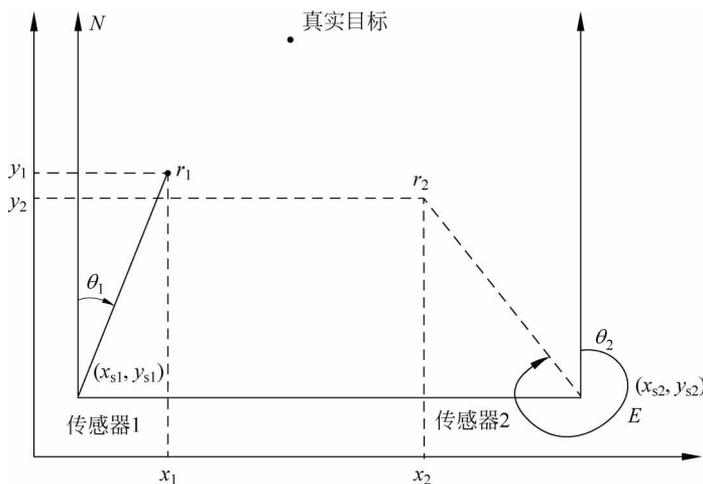
2. 空间配准

空间配准,就是借助于多传感器对空间共同目标的量测结果对传感器的偏差进行估计和补偿。对于同一系统内采用不同坐标系的各传感器的量测,定位时必须将它们转换成同一坐标系中的数据,对于多个不同子系统,各子系统采用的坐标系是不同的,所以在融合处理各子系统间信息前,也需要将它们转换到同一量测坐标系中,而处理后还需将结果转换成各子系统坐标系的数据,再传送给各个子系统^[36]。

如图 3-26 所示,由于传感器 1(传感器 2)存在斜距和方位角偏差 Δr_1 、 $\Delta\theta_1$ (Δr_2 、 $\Delta\theta_2$),导致在系统平面上出现两个目标,而实际上只有一个真实目标,所以需要进行空间配准^[37]。配准过程如图 3-27 所示。



■ 图 3-26 目标误差



■ 图 3-27 在系统平面上的偏差估计配置

图 3-27 中, r_1, θ_1 分别表示传感器 1 的斜距和方位角量测值; r_2, θ_2 分别表示传感器 2 的斜距和方位角量测值; (x_{s1}, y_{s1}) 表示传感器 1 在导航坐标平面上的位置; (x_{s2}, y_{s2}) 表示传感器 2 在导航坐标平面上的位置; (x_1, y_1) 表示传感器 1 在导航坐标系上的测量值; (x_2, y_2) 表示传感器 2 在导航坐标系上的测量值。从图 3-27 可以推导出如下基本方程:

$$\begin{cases} x_1 = x_{s1} + r_1 \sin\theta_1 \\ y_1 = y_{s1} + r_1 \cos\theta_1 \\ x_2 = x_{s2} + r_2 \sin\theta_2 \\ y_2 = y_{s2} + r_2 \cos\theta_2 \end{cases} \quad (3-29)$$

如果忽略噪声, 则有

$$\begin{cases} r_1 = r'_1 + \Delta r_1 \\ \theta_1 = \theta'_1 + \Delta\theta_1 \\ r_2 = r'_2 + \Delta r_2 \\ \theta_2 = \theta'_2 + \Delta\theta_2 \end{cases} \quad (3-30)$$

其中, r'_1, θ'_1 分别表示目标相对于传感器 1 的真实斜距和方位角; r'_2, θ'_2 分别表示目标相对于传感器 2 的真实斜距和方位角; $\Delta r_1, \Delta\theta_1$ 表示传感器 1 的斜距和方位角偏差; $\Delta r_2, \Delta\theta_2$ 表示传感器 2 的斜距和方位角偏差。将式(3-30)代入式(3-29), 并且将所得到的方程相对于 $\Delta r_1, \Delta\theta_1$ 和 $\Delta r_2, \Delta\theta_2$ 进行一阶泰勒级数展开, 可得

$$\begin{cases} x_1 - x_2 \approx \sin\theta_1 \Delta r_1 - \sin\theta_2 \Delta r_2 + r_1 \cos\theta_1 \Delta\theta_1 - r_2 \cos\theta_2 \Delta\theta_2 \\ y_1 - y_2 \approx \cos\theta_1 \Delta r_1 - \cos\theta_2 \Delta r_2 - r_1 \sin\theta_1 \Delta\theta_1 + r_2 \sin\theta_2 \Delta\theta_2 \end{cases} \quad (3-31)$$

式(3-31)对与目标运动航迹无关的偏差估计方法提供了基础。

常用的与目标运动航迹无关的偏差估计方法主要有实时质量控制法(Real Time Quality Control, RTQC)、最小二乘法、极大似然法(Maximum Likelihood, ML)和基于卡尔曼滤波器的空间配准算法等。在给出的几种算法中, 实时质量控制法和最小二乘法完全忽略了传感器量测噪声的影响, 认为公共坐标系中的误差来源于传感器配准误差(传感器偏差)。广义最小二乘法(Generalized Least Square, GLS)和基于卡尔曼滤波器的方法虽然考虑了传感器量测噪声的影响, 但只有在量测噪声相对小时, 才会产生好的性能。为了克服前两种局限性, 提出了精确极大似然(Exact Maximum Likelihood, EML)空间配准算法。

尽管前面已经介绍了多种不同的配准算法, 但它们都是基于立体投影在一个二维区域平面上实现的。更确切地说, 首先通过立体投影技术把传感器量测投影到与地球正切的局部传感器坐标上, 然后变换到区域平面, 并利用不同传感器量测之间的差异来估计传感器偏差。虽然立体投影能够减轻单个配准算法的计算复杂度, 但这一方法还有一些缺点。首先, 立体投影给局部传感器和区域平面的量测都引入了误差。尽管更高阶的近似可以将变换的精度保证到几米, 但由于地球本身是一个椭圆形球而不是一个圆柱, 因此地球非正圆球体造成的误差仍然存在。其次, 立体投影扭曲了数据, 值得注意的是立体投影的保角性只能保留方位角, 而不能保留斜距。由此可以断定系统偏差将会依赖于量测, 而不再是时不变的。这样, 在区域平面上的二维配准模型就不能正确地表示实际的传感器模型。这时, 一种直接在三维空间中对传感器偏差进行估计的基于地心坐标系的空间配准(Earth Centered Earth Fixed, ECEF)算法被提出以解决上述问题。若读者想深入了解可参考其他相关资料。

3.4.3 多传感器融合误差分析

在多传感器融合系统中,来自多个传感器的数据通常要变换到相同的时空参照系中^[38]。但由于存在量测误差,直接进行变换很难保证精度来发挥多传感器的优越性,因此在对多传感器数据进行处理时需要寻求一些传感器的配准算法,但配准误差也随之而来。

多传感器配准误差的主要来源有^[39]:

- (1) 传感器的误差,也就是传感器本身因制造误差带来的偏差。
- (2) 各传感器参考坐标中量测的方位角、高低角和斜距偏差。通常是因量测系统解算传感器数据时造成的误差。
- (3) 相对于公共坐标系的传感器的位置误差和计时误差。位置误差通常由传感器导航系统的偏差引起,而计时误差由传感器的时钟偏差所致。
- (4) 各传感器采用的定位算法不同,从而引起单系统内局部定位误差。
- (5) 各传感器本身的位置不确定,为融合处理而进行坐标转换时产生偏差。
- (6) 坐标转换的精度不够,为了减少系统的计算负担而在投影变换时采用了一些近似方法(如将地球视为标准的球体等)所导致的误差。

由于以上原因,同一个目标由不同传感器定位产生的航迹就有一定的偏差。这种偏差不同于单传感器定位时对目标的随机量测误差,它是一种固定的偏差(至少在较长时间内不会改变)。对于单传感器来说,目标航迹的固定偏差对各个目标来说都是一样的,只是产生一个固定的偏移,并不会影响整个系统的定位性能。而对于多传感器系统来说,本来是同一个目标的航迹,却由于相互偏差较大而被认为是不同的目标,从而给航迹关联和融合带来了模糊和困难,使融合处理得到的系统航迹的定位精度下降,丧失了多传感器处理本身应有的优点。

3.4.4 多传感器融合算法

实现多传感器融合定位的算法有很多种^[40],下面首先简要介绍一下各种数据融合算法及其优缺点。其中,卡尔曼滤波算法作为一种经典算法,由于其实时性强、融合精度高等优点,在自动驾驶领域中被广泛使用,下面将重点介绍卡尔曼滤波技术。

1. 数据融合算法概述

目前,融合算法可概括为随机类和人工智能类。随机类多传感器数据融合算法主要有综合估计法、贝叶斯估计法、D-S 证据推理、最大似然估计、贝叶斯估计、最优估计、卡尔曼滤波算法及鲁棒估计等。人工智能类多传感器数据融合算法主要有模糊逻辑法、神经网络算法以及专家系统等。下面简介上述算法^[41]。

用某种适当的模型来描述一个实际的物理系统,对分析、研究该物理系统是非常重要的。在导航、信号处理、通信、雷达、声呐等许多实际工程应用中,经常采用动态空间模型来描述其中的许多问题^[42]。动态空间模型是一个很重要的统计分析工具,如卡尔曼滤波器采用的高斯-马尔可夫线性模型就是一个很好的例子,它用状态方程(动力学方程)来描述状态随时间演变的过程,而用观测方程来描述与状态有关的噪声变量^[43]。同样地,只要将高斯-马尔可夫线性模型写成一般的数学映射,就可以用这两个方程来描述更一般的动态系统了:

$$\text{状态方程: } X_k = f(X_{k-1}, W_k) \quad (3-32)$$

$$\text{观测方程: } L_k = h(X_k, V_k) \quad (3-33)$$

式(3-32)和式(3-33)被称为动态空间模型。其中, $X_k \in \mathbf{R}^{k_x}$ 为系统在 k 时刻的状态, $L_k \in \mathbf{R}^{k_x}$ 为系统状态 X_k 的观测值; W_k 、 V_k 分别为过程和观测噪声。

(1) 综合平均法。该算法是把来自多个传感器的众多数据进行综合平均。它适用于用同样的传感器检测同一个目标的情况。如果对一个检测目标进行了 k 次检测, 其平均值

$$\bar{S} = \sum_{i=1}^k W_i S_i / \sum_{i=1}^k W_i, W_i \text{ 为分配给第 } i \text{ 次检测的权值。}$$

(2) 贝叶斯估计法。贝叶斯估计理论是较经典的统计估计理论, 具有更大的优势, 逐渐成为科学界推理的一个重要工具, 提供了一种与传统算法不同的概率分布形式的估计。贝叶斯推理技术主要用来进行决策层融合。贝叶斯估计法通过先验信息和样本信息合成为后验分布, 对检测目标做出推断。因此贝叶斯估计是一个不断预测和更新的过程。这样就包括了观测值和先验知识在内的所有可以利用的信息, 得到的估计误差自然较小。

(3) D-S 证据推理。D-S 证据推理是目前数据融合技术中比较常用的一种算法, 该算法通常用来对检测目标的大小、位置以及存在与否进行推断, 采用概率区间和不确定区间决定多证据下假设的似然函数来进行推理^[44]。提取的特征参数构成了该理论中的证据, 利用这些证据构造相应的基本概率分布函数, 对于所有的命题赋予一个信任度。基本概率分布函数及其相应的分辨框合称为一个证据体。因此, 每个传感器就相当于一个证据体。而多个传感器数据融合, 实质上就是在同一分辨框下, 利用 Dempster 合并规则将各个证据体合并成一个新的证据体, 产生新证据体的过程就是 D-S 证据推理数据融合。

(4) 卡尔曼滤波算法。卡尔曼滤波在控制领域得到广泛应用以后, 也逐渐成为多传感器数据融合系统的主要技术手段之一。联合卡尔曼滤波器的设计思想是先分散处理、再全局融合, 即在诸多非相似子系统中选择一个信息全面、输出速率高、可靠性绝对保证的子系统作为公共参考系统, 与其他子系统两两结合, 形成若干子滤波器。各子滤波器并行运行, 获得建立在子滤波器局部观测基础上的局部最优估计, 这些局部最优估计在主滤波器内按融合算法合成, 从而获得建立在所有观测基础上的全局估计。

(5) 模糊逻辑法。针对数据融合中所检测的目标特征具有某种模糊性的现象, 利用模糊逻辑算法来对检测目标进行识别和分类。建立标准检测目标和待识别检测目标的模糊子集是此算法的研究基础。

(6) 神经网络算法。神经网络是一种试图仿效生物神经系统处理信息方式的新型计算模型。一个神经网络由多层处理单元或节点组成, 可以用各种方法互联。在指挥和控制多传感器数据融合的系统中, 神经网络的输入可能是与一个目标有关的测量参数集, 输出可能是目标身份, 也可能是推荐的响应或行动。基于神经网络的融合优于传统的聚类算法, 尤其是当输入数据中带有噪声和数据不完整时。然而, 要使神经网络算法在实际的融合系统中得到应用, 无论在网络结构设计或是算法规则方面, 还有许多基础工作要做, 如网络模型、网络的层次和每层的节点数、网络学习策略、神经网络算法与传统分类算法的关系和综合应用等。

(7) 专家系统。专家系统是一组计算机程序, 它获取专家们在某个特定领域内的知识, 然后根据专家的知识或经验导出一组规则, 由计算机做出本应由专家做出的结论。目前, 专

家系统已在军用和民用领域得到了广泛应用。

此外,其他数据融合算法还有品质因数、模板算法、聚合分析、统计决策理论等。各种融合算法的特点比较如表 3-2 所示。

表 3-2 各种融合算法的特点比较

融合算法	运行环境	信息类型	信息表示	不确定性	融合技术	适用范围
综合平均法	动态	冗余	原始读数值	—	加权平均	低层融合
贝叶斯估计法	静态	冗余	概率分布	高斯噪声	贝叶斯估计	高层融合
D-S 证据推理	静态	冗余互补	命题	—	逻辑推理	高层融合
卡尔曼滤波	动态	冗余	概率分布	高斯噪声	系统模型滤波	低层融合
模糊逻辑法	静态	冗余互补	命题	隶属度	逻辑推理	高层融合
神经网络算法	动、静态	冗余互补	神经元输入	学习误差	神经网络	低/高层融合
专家系统	静态	冗余互补	命题	置信因子	逻辑推理	高层融合

2. 卡尔曼滤波算法

鉴于卡尔曼滤波算法在多传感器融合系统中使用的普遍性,本节将单独就卡尔曼滤波算法及自动驾驶中常用的改进卡尔曼滤波算法进行详细介绍^[45]。首先介绍卡尔曼滤波的基本方法,接着介绍针对非线性系统改进的扩展卡尔曼滤波,最后介绍卡尔曼滤波在自动驾驶中常用的联邦卡尔曼滤波。

1960年,卡尔曼第一次发表了介绍卡尔曼滤波算法的论文^[46]。而卡尔曼滤波算法的第一次实际应用则是将惯性导航器与 C5A 军用飞机上的机载雷达集成在一起^[47]。卡尔曼滤波算法被称为“导航组合的驮马”^[48],因为其已经成了现代导航系统的必要部分,特别是对于像 GNSS 和 INS 这样完全不同的系统进行组合导航的系统。卡尔曼滤波可分为线性卡尔曼滤波^[49]、扩展卡尔曼滤波^[50]、级联式和联邦式卡尔曼滤波^[51]、无迹卡尔曼滤波^[52]等,下面将详细阐述卡尔曼滤波的原理。

1) 最小方差估计

最小方差估计是指以均方误差最小作为估计准则的估计,即满足式(3-34):

$$E\{[\mathbf{X} - \hat{\mathbf{X}}(\mathbf{Z})][\mathbf{X} - \hat{\mathbf{X}}(\mathbf{Z})]^T\} \leq E\{[\mathbf{X} - \mathbf{r}(\mathbf{Z})][\mathbf{X} - \mathbf{r}(\mathbf{Z})]^T\} \quad (3-34)$$

式中, \mathbf{X} 为 m 维系统状态变量矢量; \mathbf{Z} 为 n 维观测矢量; $\hat{\mathbf{X}}(\mathbf{Z})$ 为用观测矢量 \mathbf{Z} 计算得出的关于 \mathbf{X} 的最小方差估计; $E\{\cdot\}$ 表示取均值; $\mathbf{r}(\mathbf{Z})$ 表示由其他方法得到的 \mathbf{X} 的估计值。容易证明,最小方差估计是无偏的,即残差的均值为 0,满足式(3-35)。

$$E\{\tilde{\mathbf{X}}\} = E\{\mathbf{X} - \hat{\mathbf{X}}(\mathbf{Z})\} = 0 \quad (3-35)$$

同样容易证明,最小方差估计的均方误差就是估计误差的方差,即

$$E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\} = E\{[\tilde{\mathbf{X}} - E(\tilde{\mathbf{X}})][\tilde{\mathbf{X}} - E(\tilde{\mathbf{X}})]^T\} \quad (3-36)$$

为了求得 \mathbf{X} 的最小方差估计,必须首先得到 \mathbf{X} 的条件概率密度,对于工程中的实际应用而言,系统状态的各种条件概率密度是很不容易得到的,因此这种估计方法的应用受到一定的限制^[53]。

2) 卡尔曼滤波的估计

如果将估计值 $\hat{\mathbf{X}}(\mathbf{Z})$ 规定为观测矢量 \mathbf{Z} 的线性函数,即

$$\hat{\mathbf{X}}(\mathbf{Z}) = \mathbf{AZ} + \mathbf{b} \quad (3-37)$$

式中, \mathbf{A} 和 \mathbf{b} 分别是 $m \times n$ 阶的矩阵和 n 维矢量。 \mathbf{A} 值和 \mathbf{b} 值仍旧按照最小方差估计来选择, 则这样的估计被称为线性最小方差估计^[54]。可以证明, 这种估计只需要知道被估计值 \mathbf{X} 和观测值的一、二阶统计特性, 所以它比最小方差估计更加实用, 尽管它的估计精度一般小于最小方差估计。

对于动态系统, 工程上常常要求由 t 时刻的量测值 $Z(t)$ 计算出该时刻状态 $X(t)$ 的估计 \tilde{X} , 由于 $X(t)$ 是历史时刻的状态按照系统转移规律发展过来的, 与历史时刻的状态有关联, 所以, 利用 t 时刻和历史时刻的所有观测值对 $X(t)$ 进行估计, 将有助于提高估计精度。但是对于最小方差估计和线性最小方差估计而言, 由于计算方法的限制, 同时处理不同时刻的观测值而得到 t 时刻估计值的计算量太大。因此, 这两种估计方法不适合估计动态系统的状态。

卡尔曼滤波是一种递推线性最小方差估计, 它的估计准则仍是方差最小估计技术。在工程技术中, 为了解工程对象(系统)的各个物理量(状态), 或者为了达到控制工程对象的目的, 必须采用测量手段对系统的各个状态进行测量, 由于观测值可能是系统的部分状态或其线性组合, 且包含随机误差(也称观测噪声), 最优的估计能将仅与部分相关的观测值进行处理, 从而得到统计意义上估计误差最小的更多状态的估计。因此, 卡尔曼滤波是一种递推线性最小方差估计, 它的估计值是观测值的线性函数, 满足式(3-36)。并且, 只要包含初始估计值在内的滤波算法初值选择正确, 它的估计也是无偏的。在计算方法上, 卡尔曼滤波采用了递推模型, 即在历史估计值的基础上, 根据 t 时刻的观测值, 递推得到 t 时刻的状态估计 $\hat{\mathbf{X}}(t)$ 。由于历史时刻中每一时刻的估计值又是根据其历史时刻的观测值得到, 所以, 这种递推算法的估计值可以说是综合利用了 t 时刻和 t 时刻以前的所有观测信息得到, 并且一次仅处理一个时刻的观测值, 使计算量大为减少。因为卡尔曼滤波是用状态方程和观测方程来描述系统和观测值的, 所以它主要适用于线性动态系统。

3) 卡尔曼滤波方程

虽然工程对象一般都是连续系统, 但是卡尔曼滤波常常采用离散化模型来描述系统, 以便于计算机进行处理。离散系统就是用离散化后的差分方程来描述连续系统。假设离散化后的系统状态方程和观测方程为

$$\begin{cases} \mathbf{X}_k = \Phi_{k,k-1} \mathbf{X}_{k-1} + \Gamma_{k-1} \mathbf{W}_{k-1} \\ \mathbf{Z}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{V}_k \end{cases} \quad (3-38)$$

式中, \mathbf{X}_k 为 k 时刻的 n 维状态矢量, 也是被估计矢量; \mathbf{Z}_k 为 k 时刻的 m 维观测矢量; $\Phi_{k,k-1}$ 为 $k-1$ 时刻到 k 时刻的系统一步转移矩阵($n \times n$); \mathbf{W}_{k-1} 为 $k-1$ 时刻的系统噪声(r 维), Γ_{k-1} 为系统噪声矩阵($n \times r$), 它表征由 $k-1$ 时刻到 k 时刻的各个系统噪声分别影响各个状态的程度; \mathbf{H}_k 为 k 时刻的观测矩阵($m \times n$); \mathbf{V}_k 为 k 时刻的 m 维观测噪声。卡尔曼滤波要求 $\{\mathbf{W}_k\}$ 和 $\{\mathbf{V}_k\}$ 是互不相关的零均值的高斯白噪声序列, 有

$$\begin{cases} E\{\mathbf{W}_k \mathbf{W}_j^T\} = \mathbf{Q}_k \delta_{kj} \\ E\{\mathbf{V}_k \mathbf{V}_j^T\} = \mathbf{R}_k \delta_{kj} \end{cases} \quad (3-39)$$

式中, \mathbf{Q}_k 和 \mathbf{R}_k 分别为系统噪声和观测噪声的方差矩阵, 在卡尔曼滤波中要求它们分别是已

知值的非负定阵和正定阵； δ_{kj} 是狄利克雷函数，即

$$\delta_{kj} = \begin{cases} 0, & k \neq j \\ 1, & k = j \end{cases} \quad (3-40)$$

初始状态的一、二阶统计特性为

$$\begin{cases} E\{\mathbf{X}_0\} = m_{x_0} \\ \text{var}\{\mathbf{X}_0\} = C_{x_0} \end{cases} \quad (3-41)$$

式中， $\text{var}\{\cdot\}$ 表示求方差，卡尔曼滤波要求 m_{x_0} 和 C_{x_0} 为已知量，且要求 \mathbf{X}_0 与 $\{\mathbf{W}_k\}$ 以及 $\{\mathbf{V}_k\}$ 都互不相关。

4) 离散卡尔曼滤波的计算流程

由递推的观点看，假如在 $k-1$ 时刻已经获得了对 \mathbf{X}_{k-1} 的最优估计值 $\hat{\mathbf{X}}_{k-1}$ ，并且在 k 时刻又观测到 \mathbf{Z}_k ，则当前时刻 k 的最优估计 $\hat{\mathbf{X}}_k$ 可以用两者的线性组合表示^[55]，即

$$\hat{\mathbf{X}}_k = \mathbf{A}\hat{\mathbf{X}}_{k-1} + \mathbf{B}\mathbf{Z}_k \quad (3-42)$$

式中， \mathbf{A} 、 \mathbf{B} 待定但需保证不同维，满足

$$\begin{aligned} & E((\mathbf{X}_k - (\mathbf{A}\hat{\mathbf{X}}_{k-1} + \mathbf{B}\mathbf{Z}_k))(\mathbf{X}_k - (\mathbf{A}\hat{\mathbf{X}}_{k-1} + \mathbf{B}\mathbf{Z}_k))^T) \\ & \leq E((\mathbf{X}_k - (\tilde{\mathbf{A}}\hat{\mathbf{X}}_{k-1} + \tilde{\mathbf{B}}\mathbf{Z}_k))(\mathbf{X}_k - (\tilde{\mathbf{A}}\hat{\mathbf{X}}_{k-1} + \tilde{\mathbf{B}}\mathbf{Z}_k))^T) \end{aligned} \quad (3-43)$$

式中， $\tilde{\mathbf{A}}$ 、 $\tilde{\mathbf{B}}$ 分别为与 \mathbf{A} 、 \mathbf{B} 同维的任意矩阵。最终卡尔曼滤波可以按照如下流程进行计算。

状态一步预测方程为

$$\hat{\mathbf{X}}_{k|k-1} = \Phi_{k,k-1}\hat{\mathbf{X}}_{k-1} \quad (3-44)$$

状态估计计算方程为

$$\hat{\mathbf{X}}_k = \hat{\mathbf{X}}_{k|k-1} + \mathbf{K}_k(\mathbf{Z}_k - \mathbf{H}_k\hat{\mathbf{X}}_{k|k-1}) \quad (3-45)$$

其中， \mathbf{K}_k 为卡尔曼滤波增益。滤波增益方程为

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}\mathbf{H}_k^T(\mathbf{H}_k\mathbf{P}_{k|k-1}\mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (3-46)$$

一步预测均方误差方程为

$$\mathbf{P}_{k|k-1} = \Phi_{k,k-1}\mathbf{P}_{k-1}\Phi_{k,k-1}^T + \Gamma_{k-1}\mathbf{Q}_{k-1}\Gamma_{k-1}^T \quad (3-47)$$

估计均方误差方程为

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H}_k)\mathbf{P}_{k|k-1}(\mathbf{I} - \mathbf{K}_k\mathbf{H}_k)^T + \mathbf{K}_k\mathbf{R}_k\mathbf{K}_k^T \quad (3-48)$$

5) 扩展卡尔曼滤波

传统卡尔曼滤波要求系统的状态方程和观测方程均是线性条件，然而现实中，许多工程系统往往不能简单地用线性系统来描述，如参数估计引入增广状态方程的非线性、结构关系带来的非线性和观测信号的非线性，因此，十分有必要对非线性滤波进行深入的讨论。一般情况是将非线性方程线性化，而后利用线性卡尔曼滤波基本方程处理线性问题^[56]。

当式(3-38)是非线性的，则系统状态方程和观测方程为^[57]

$$\begin{cases} \mathbf{X}_k = f(\mathbf{X}_{k-1}) + \mathbf{W}_k \\ \mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{V}_k \end{cases} \quad (3-49)$$

状态一步预测方程为

$$\hat{\mathbf{X}}_{k|k-1} = f(\hat{\mathbf{X}}_{k-1}) + \mathbf{W}_k \quad (3-50)$$

其中, \mathbf{W}_k 为过程噪声。扩展卡尔曼滤波算法就是将非线性方程线性化的滤波算法, 是解决非线性滤波问题常用的一种方法。其时间递推公式和卡尔曼滤波相似, 与卡尔曼滤波算法不同的是式(3-44)中的状态一步预测方程中的参数要用非线性函数的一阶偏导数来计算, 不具有像线性滤波那样可以实现离线计算增益和协方差的优点。

6) 联邦卡尔曼滤波

联邦卡尔曼滤波框图如图 3-28 所示。联邦卡尔曼滤波一般分为两步滤波, 即先基于局部传感器进行滤波, 然后再进行主滤波。先假设状态向量从 $k-1$ 时刻的 \mathbf{X}_{k-1} 转移到 k 时刻的 \mathbf{X}_k , 其动力学模型为

$$\mathbf{X}_k = \Phi_{k,k-1} \mathbf{X}_{k-1} + \mathbf{W}_k \quad (3-51)$$

式中 $\Phi_{k,k-1}$ 为时间 $k-1$ 到 k 的状态转移矩阵, \mathbf{W}_k 为动力学模型误差, \mathbf{W}_k 与 \mathbf{W}_{k-1} 不相关。

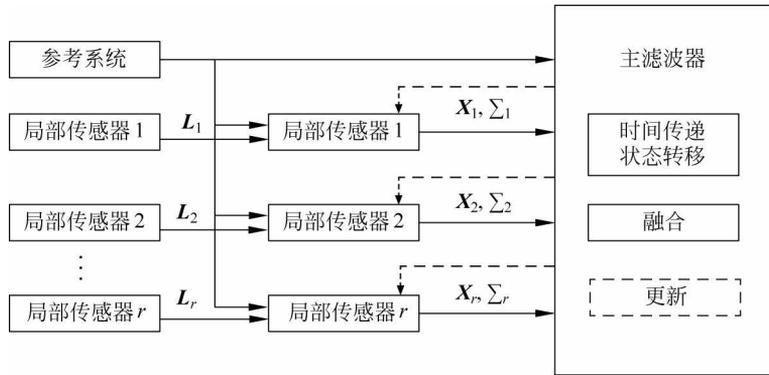


图 3-28 联邦卡尔曼滤波框图

设在 k 时刻有 r 个传感器, 各传感器相应的观测方程为

$$\mathbf{L}_{ik} = \mathbf{A}_{ik} \mathbf{X}_k + \Delta_{ik} \quad (3-52)$$

式中, \mathbf{A}_{ik} 为传感器 i 的观测方程设计矩阵, \mathbf{L}_{ik} 和 Δ_{ik} 为传感器 i 的观测向量和误差向量。假设各传感器观测误差与动态模型误差不相关, 各传感器观测误差互不相关。

$$E(\mathbf{W}_k) = 0, \quad E(\Delta_{ik}) = 0 \quad (3-53)$$

$$E[\Delta_{ik} \Delta_{ik}^T] = \sum_{ik} = \mathbf{P}_{ik}^{-1}, \quad E[\Delta_{ik} \Delta_{jk}^T] = 0 \quad (i \neq j) \quad (3-54)$$

$$E(\mathbf{W}_k \mathbf{W}_{k-1}^T) = 0, \quad E(\mathbf{W}_k \mathbf{W}_k^T) = \sum_{\mathbf{W}_k} \quad (3-55)$$

由各传感器得到局部滤波解为

$$\hat{\mathbf{X}}_{ik} = [\mathbf{I} - \mathbf{K}_{ik} \mathbf{A}_{ik}] \bar{\mathbf{X}}_k + \mathbf{K}_{ik} \mathbf{L}_{ik} \quad (3-56)$$

式中

$$\mathbf{K}_{ik} = \sum_{\bar{\mathbf{X}}_k} \mathbf{A}_{ik}^T \left(\mathbf{A}_{ik} \sum_{\bar{\mathbf{X}}_k} \mathbf{A}_{ik}^T + \sum_{ik} \right) \quad (3-57)$$

$$\sum_{\bar{\mathbf{X}}_k} = \Phi_{k,k-1} \sum_{\hat{\mathbf{X}}_{k-1}} \Phi_{k,k-1}^T + \sum_{\mathbf{W}_k} \quad (3-58)$$

$$\sum_{\hat{\mathbf{x}}_{ik}} = (\mathbf{I} - \mathbf{K}_{ik}\mathbf{A}_{ik}) \sum_{\mathbf{x}_k} \quad (3-59)$$

设主传感器(参考传感器)的观测向量为 \mathbf{L}_{mk} , 则主滤波(MF)解为

$$\hat{\mathbf{X}}_{mk} = [\mathbf{I} - \mathbf{K}_{mk}\mathbf{A}_{mk}] \bar{\mathbf{X}}_k + \mathbf{K}_{mk}\mathbf{L}_{mk} \quad (3-60)$$

式中, \mathbf{K}_{mk} 和 \mathbf{A}_{mk} 分别与 \mathbf{K}_{ik} 和 \mathbf{A}_{ik} 类似。

由联邦卡尔曼滤波算法信息分享原理^[37], 可得最终融合滤波解 $\hat{\mathbf{X}}_{fk}$ 及相应的权矩阵 $\mathbf{P}_{\hat{\mathbf{x}}_{fk}}$ 为

$$\mathbf{P}_{\hat{\mathbf{x}}_{fk}} = \mathbf{P}_{\hat{\mathbf{x}}_{1k}} + \mathbf{P}_{\hat{\mathbf{x}}_{2k}} + \cdots + \mathbf{P}_{\hat{\mathbf{x}}_{rk}} + \mathbf{P}_{\hat{\mathbf{x}}_{mk}} \quad (3-61)$$

$$\mathbf{P}_{\hat{\mathbf{x}}_{fk}} \hat{\mathbf{X}}_{fk} = \mathbf{P}_{\hat{\mathbf{x}}_{1k}} \hat{\mathbf{X}}_{1k} + \mathbf{P}_{\hat{\mathbf{x}}_{2k}} \hat{\mathbf{X}}_{2k} + \cdots + \mathbf{P}_{\hat{\mathbf{x}}_{rk}} \hat{\mathbf{X}}_{rk} + \mathbf{P}_{\hat{\mathbf{x}}_{mk}} \hat{\mathbf{X}}_{mk} \quad (3-62)$$

式中 $\mathbf{P}_{\hat{\mathbf{x}}_{1k}}, \mathbf{P}_{\hat{\mathbf{x}}_{2k}}, \cdots, \mathbf{P}_{\hat{\mathbf{x}}_{rk}}, \mathbf{P}_{\hat{\mathbf{x}}_{mk}}$ 分别为局部传感器滤波输出的状态估计向量的权矩阵, $\mathbf{P}_{\hat{\mathbf{x}}_{fk}}$ 为联邦滤波算法输出的状态向量的权矩阵(或称信息矩阵), 它们是相应协方差矩阵的逆矩阵。

$$\mathbf{P}_{\hat{\mathbf{x}}_{ik}} = \sum_{\hat{\mathbf{x}}_{ik}}^{-1}, \quad \mathbf{P}_{\hat{\mathbf{x}}_{mk}} = \sum_{\hat{\mathbf{x}}_{mk}}^{-1} \quad (3-63)$$

由(3-62)得

$$\hat{\mathbf{X}}_{fk} = \mathbf{P}_{\mathbf{x}_{fk}}^{-1} (\mathbf{P}_{\hat{\mathbf{x}}_{1k}} \hat{\mathbf{X}}_{1k} + \mathbf{P}_{\hat{\mathbf{x}}_{2k}} \hat{\mathbf{X}}_{2k} + \cdots + \mathbf{P}_{\hat{\mathbf{x}}_{rk}} \hat{\mathbf{X}}_{rk} + \mathbf{P}_{\hat{\mathbf{x}}_{mk}} \hat{\mathbf{X}}_{mk}) \quad (3-64)$$

3.5 本章小结

本章从汽车定位的四种系统出发, 具体涉及 GNSS、航迹递推系统、地图匹配定位系统和多传感器融合定位系统, 阐述了应用于汽车定位的各系统的原理、方法和误差分析。本章着重介绍了利用 RTK 改进 GNSS 实现自动驾驶汽车定位的原理和相应的系统, 讲解了航迹递推的基本原理、地图匹配算法和融合算法, 最后重点阐述了卡尔曼滤波技术。

参考文献

- [1] QUAN Y, LAU L, ROBERTS G W, et al. Measurement signal quality assessment on all available and new signals of multi-GNSS (GPS, GLONASS, Galileo, BDS, and QZSS) with real data[J]. The Journal of Navigation, 2016, 69(2): 313-334.
- [2] LI P, ZHANG X. Integrating GPS and GLONASS to accelerate convergence and initialization times of precise point positioning[J]. GPS solutions, 2014, 18(3): 461-471.
- [3] 刘俊伟. 移动智能终端北斗导航技术展望[J]. 信息通信技术, 2017, 11(05): 29-34.
- [4] DING W, TAN B, CHEN Y, et al. Evaluation of a regional real-time precise positioning system based on GPS/BeiDou observations in Australia[J]. Advances in Space Research, 2018, 61(3): 951-961.
- [5] SIEBLER B, DE PONTE MÜLLER F, HEIRICH O, et al. Algorithms for relative train localization with GNSS and track map: Evaluation and comparison [C]//2017 International Conference on

- Localization and GNSS (ICL-GNSS). IEEE, 2017: 1-7.
- [6] 杨元喜,陆明泉,韩春好. GNSS 互操作若干问题[J]. 测绘学报,2016,45(03):253-259.
- [7] 王泉. 从车联网到自动驾驶[M]. 北京:人民邮电出版社,2018.
- [8] DRAWIL N M, AMAR H M, BASIR O A. GPS localization accuracy classification: A context-based approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(1): 262-273.
- [9] 李川,刘星,石明旺,等. GPS 多路径误差特性分析及削弱方法[J]. 导航定位学报,2017,5(01): 103-107.
- [10] CHEN H, JIANG W, GE M, et al. Efficient high-rate satellite clock estimation for PPP ambiguity resolution using carrier-ranges[J]. Sensors, 2014, 14(12): 22300-22312.
- [11] MOHINDER S G. GNSS 惯性导航组合[M]. 北京:电子工业出版社,2016.
- [12] 张月新,王立辉,汤新华. 汽车动力学模型辅助的惯性导航系统[J]. 中国惯性技术学报,2017,25(05):576-580.
- [13] 百度百科. 惯性导航系统[EB/OL]. (2016-11-21)[2019-05-03]. <https://baike.baidu.com/item/惯性导航系统/2286423?fr=Aladdin>.
- [14] 维基百科. 惯性导航系统[EB/OL]. (2019-01-21)[2019-05-03]. <https://zh.wikipedia.org/wiki/%E6%83%AF%E6%80%A7%E5%AF%BC%E8%88%AA%E7%B3%BB%E7%BB%9F>.
- [15] PLASTINO A R, MUZZIO J C. On the use and abuse of Newton's second law for variable mass problems[J]. Celestial Mechanics and Dynamical Astronomy, 1992, 53(3): 227-232.
- [16] 李翔. 矢量道路数据辅助惯性导航定位的技术与方法研究[J]. 测绘学报,2018,47(05):692.
- [17] COTTER D, TATHAM M C. Dead reckoning—a primitive and efficient self-routing protocol for ultrafast mesh networks[J]. IEE Proceedings-Communications, 1997, 144(3): 135-142.
- [18] METZNER A, WICKRAMARATHNE T. On Multi-Sensor Radar Configurations for Vehicle Tracking in Autonomous Driving Environments [C]//2018 21st International Conference on Information Fusion (FUSION). IEEE, 2018: 1-8.
- [19] KIM J, HAN D S, SENOUCI B. Radar and vision sensor fusion for object detection in autonomous vehicle surroundings[C]//2018 Tenth International Conference on Ubiquitous and Future Networks (ICUFN). IEEE, 2018: 76-78.
- [20] 黄卫权. 惯性导航、卫星定位及其组合的基本原理[M]. 北京:国防工业出版社,2017.
- [21] 周俊,王琳,徐永强,等. 惯性导航与卫星导航组合定位精度分析及仿真[J]. 无线电工程,2018,48(12):1086-1090.
- [22] 王宝树,李芳社. 基于数据融合技术的多目标跟踪算法研究[J]. 西安电子科技大学学报(自然科学版)1998,25(3):269-272.
- [23] 富立. 汽车定位导航系统[M]. 北京:中国铁道出版社,2004.
- [24] WAN G, YANG X, CAI R, et al. Robust and precise vehicle localization based on multi-sensor fusion in diverse city scenes[C]//2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018: 4670-4677.
- [25] ZHU X, TIAN W, LI G Z, et al. Research on Localization Vehicle Based on Multiple Sensors Fusion System [C]//2017 International Conference on Computer Network, Electronic and Automation (ICCNEA). IEEE, 2017: 491-494.
- [26] ZHANG M, ZHANG Z, DAI Y, et al. Design of a multi-threaded positioning system software architecture for ground mobile robots[C]//2018 5th International Conference on Information Science and Control Engineering (ICISCE). IEEE, 2018: 699-703.
- [27] WANG Z. Robot Obstacle Avoidance and Navigation Control Algorithm Research Based on Multi-Sensor Information Fusion [C]//2018 11th International Conference on Intelligent Computation Technology and Automation (ICICTA). IEEE, 2018: 351-354.

- [28] LIU S, SHEN-TU H, CHEN H, et al. Asynchronous Multi-Sensor Fusion Multi-Target Tracking Method[C]//2018 IEEE 14th International Conference on Control and Automation (ICCA). IEEE, 2018: 459-463.
- [29] 何伟. GNSS/INS 深耦合系统关键技术研究[D]. 西安: 西北工业大学, 2016.
- [30] 董保根. 机载 LiDAR 点云与遥感影像融合的地物分类技术研究[D]. 郑州: 解放军信息工程大学, 2013.
- [31] 百度百科. 地图匹配[EB/OL]. (2016-01-30)[2019-05-03]. <https://baike.baidu.com/item/地图匹配/799321>.
- [32] 陈玉坤. 多模复合制导信息融合理论与技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2007.
- [33] 丁小, 肖兵, 金宏斌. 传感器误差配准问题研究[J]. 湖南工业大学学报, 2008(05): 86-89.
- [34] 李教. 多平台多传感器多源信息融合系统时空配准及性能评估研究[D]. 西安: 西北工业大学, 2003.
- [35] BIEZAD D J. Integrated navigation and guidance systems[M]. Detroit: American Institute of Aeronautics and Astronautics, 1999.
- [36] 李教. 多平台多传感器多源信息融合系统时空配准及性能评估研究[D]. 西安: 西北工业大学, 2003.
- [37] 李鹏. 卡尔曼滤波在信息融合理论中的应用[D]. 西安: 西安电子科技大学, 2008.
- [38] 穆加艳. 雷达数据与 AIS 数据融合的应用研究[D]. 南京: 南京理工大学, 2011.
- [39] 刘铮. 自适应颜色直方图的粒子滤波算法[D]. 武汉: 武汉理工大学, 2012.
- [40] AWOGBAMI G, AGANA N, NAZMI S, et al. An Evidence Theory Based Multi Sensor Data Fusion for Multiclass Classification[C]//2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2018: 1755-1760.
- [41] MCGEE L A, SCHMIDT S F. Discovery of the Kalman Filter as a Practical Tool for Aerospace and Industry[J]. National Aeronautics and Space Administration, Ames Research, 1985.
- [42] YOUSUF S, KADRI M B. Robot Localization in Indoor and Outdoor Environments by Multi-sensor Fusion[C]//2018 14th International Conference on Emerging Technologies (ICET). IEEE, 2018: 1-6.
- [43] LEVY L J. The Kalman filter: Navigation's integration workhorse[J]. GPS World, 1997, 8(9): 65-71.
- [44] HUANG Y, JING Y, SHI Y. Multi-sensor node fusion localization using unscented Kalman filter in rough environments[C]//2018 Chinese Control And Decision Conference (CCDC). IEEE, 2018: 5476-5481.
- [45] 高怡. 组合导航滤波算法[M]. 北京: 电子工业出版社, 2017.
- [46] KE Z, YING S. Steady-state Kalman Fusion Filter Based on Improved Multi-innovation Least Squares Algorithm[C]//2018 37th Chinese Control Conference (CCC). IEEE, 2018: 4434-4437.
- [47] JANISZEWSKI D, KIELCZEWSKI M. Kalman filter sensor fusion for multi-head position encoder [C]//2017 19th European Conference on Power Electronics and Applications (EPE'17 ECCE Europe). IEEE, 2017: 1-7.
- [48] 朱晓娟. 飞行控制系统多传感器信息融合技术研究[D]. 南京: 南京航空航天大学, 2008.
- [49] 杨元喜. 多源传感器动、静态滤波融合导航[J]. 武汉大学学报(信息科学版), 2003(04): 386-388+396.
- [50] 王庆. 汽车组合定位与导航系统[M]. 北京: 科学出版社, 2016.
- [51] WANG M, YAN G, SUN X. Distributed fusion incremental Kalman filter[C]//2018 Chinese Control And Decision Conference (CCDC). IEEE, 2018: 686-688.
- [52] VOGEL S, ALKHATIB H, NEUMANN I. Iterated Extended Kalman Filter with Implicit

- Measurement Equation and Nonlinear Constraints for Information-Based Georeferencing[C]//2018 21st International Conference on Information Fusion (FUSION). IEEE, 2018: 1209-1216.
- [53] TONGYUE G, KAIDA H, JIA Y, et al. An Altitude Location System for Vehicle Based on Federated Kalman Filter [C]//2018 5th International Conference on Systems and Informatics (ICSAI). IEEE, 2018: 1235-1239.
- [54] 付梦印, 邓志红. Kalman 滤波理论及其在导航系统中的应用[M]. 北京: 科学出版社, 2003.
- [55] 丁小, 肖兵, 金宏斌. 传感器误差配准问题研究[J]. 湖南工业大学学报, 2008(05): 86-89.
- [56] MOHINDER S G. 卡尔曼滤波理论与实践(MATLAB 版)[M]. 北京: 电子工业出版社, 2017.
- [57] 刘铮. 自适应颜色直方图的粒子滤波算法[D]. 武汉: 武汉理工大学, 2012.