5G多基站定位：分布式融合方案

Sharief Saleh，*IEEE*学生会员，Qamar Bader，*IEEE*学生会员Mohamed Elhabiby，*IEEE*会员
Aboelmagd Noureldin，*IEEE*高级会员

arXiv:2303.04192v2 [eess.SP] 3 May 2023

摘要—**预计第五代（5G）网络将利用毫米波信号，在城市和市中心区域提供高精度定位估计。在此类区域，5G基站将密集部署，从而使用户设备与多个基站之间能够同时进行视距通信。拥有丰富的测量源，就需要在基站之间进行最优融合，以获得准确、精确的定位解决方案。传统上，5G多基站融合通过扩展卡尔曼滤波器（EKF）实现，在集中式集成方案中直接利用距离与角度测量值。此类测量值与滤波器的定位状态之间存在非线性关系，从而产生线性化误差。与普遍看法相反，无迹卡尔曼滤波器（UKF）也无法彻底消除这类线性化误差。本文认为，5G基站之间采用分布式集成能够完全避免滤波器中的线性化误差，并显著提升定位性能。具体而言，该方法不直接融合距离与角度测量值，而是融合位置测量值；这种设计天然形成线性测量模型。所提出的分散式卡尔曼滤波方法在Siradel提供的准真实仿真环境中进行了评估，采用了多伦多市中心的一条真实轨迹。实验比较了分散式卡尔曼滤波融合与集中式扩展卡尔曼滤波器和无迹卡尔曼滤波融合方案的性能。结果表明，在多种场景下，所提出的方法均优于无迹卡尔曼滤波器和扩展卡尔曼滤波器实现，显著降低了均方根和最大二维定位误差，并在93.9% 的时间内达到了分米级精度。**

索引词—**5G；离开角 (AOD)；自动驾驶车辆 (AVs)；分散式传感器融合；卡尔曼滤波器 (KF)；定位；毫米波；定位；往返时间 (RTT)。**

I. 引言

PRECISE 近年来，随着对高度智能化物联网（IoT）应用、上下文感知服务和基于位置的服务（LBS）的研究不断深入，定位与导航解决方案变得日益重要。此外，自动驾驶汽车等安全关键应用需要精确的位置信息，这类应用要求更高水平的自主性。这些系统要求实现厘米级的绝对定位与相对定位精度、低延迟和高可靠性 [1]。几十年来，人们一直利用基于无线的定位，为精度要求较低的应用提供定位解决方案。这类技术利用基于时间、角度和功率的测量值，通过三边测量、三角定位和混合定位技术确定用户设备（UE）的位置 [2]。三边测量利用从三个或更多基站（BS）获取的距离来确定用户设备的位置。另一方面，三角定位则利用多个相对角度测量值来估算用户设备的位置。最后，混合定位方法同时利用距离与角度测量值来确定用户的位置，这可通过单个基站实现。例如，全球导航卫星系统（GNSS）在独立运行时可提供数米级精度；借助实时动态（RTK）技术后，精度可提高至厘米级[3]。然而，由于多径和信号阻塞，基于GNSS的定位解决方案在城市峡谷环境中的性能会下降。另一方面，WiFi和超宽带（UWB）能够实现亚米级精度，但这两种技术的工作距离较短，范围约为50米至200米 [4] [5], , 因此仅在室内环境中更具优势。相比之下，预计5G新空口（NR）小基站将为通信目的而在深度城区密集部署，基站间距为200至500米 [6]。这将提高与用户进行视距（LoS）通信的可能性，而这对基于视距的定位算法十分重要。此外，5G毫米波定位信号的带宽最高可达400 MHz，可实现对到达时间（TOA）、往返时间（RTT）和到达时间差（TDOA）等基于时间的测量值进行精确估算，并在时域中实现较高的多径（MP）分辨能力。此外，5G频段2（FR2）采用28 GHz至52 GHz的高频毫米波信号，从而推动大规模MIMO的发展。因此，5G接收器将配备大量天线，能够实现对到达角（AOA）和离开角（AOD）等基于角度的测量值进行精确测量，并在角度域中实现较高的多径分辨能力。

为了在考虑含噪距离与角度测量值的情况下优化用户设备的位置估计，需要使用最优状态估计器。最常用的滤波器是卡尔曼滤波器（KF） [7], 扩展卡尔曼滤波器（EKF） [8] 和无迹卡尔曼滤波器（UKF） [9]。KF 假设状态转移和观测模型均为线性，而其余所述滤波器则不要求这一条-

Sharief Saleh、Qamar Bader 和 Aboelmagd Noureldin 任职于加拿大安大略省金斯顿市女王大学电气与计算机工程系（邮编 K7L 3N6），并任职于加拿大皇家军事学院电气与计算机工程系导航与仪器（NavINST）实验室（加拿大安大略省金斯顿市，邮编 K7K 7B4）（电子邮箱：sharief.saleh@queensu.ca；qamar.bader@queensu.ca；nourelda@queensu.ca）。Mohamed Elhabiby 任职于 Micro Engineering Tech. Inc.，并兼任埃及开罗艾因·夏姆斯大学公共工程系职务（邮编 11566）（电子邮箱：mmelhabi@ucalgary.ca）。

件。此外，KF、EKF 和 UKF 要实现最优性能，都假设过程噪声和测量噪声服从正态分布。违反上述任一条件都会使滤波器失去最优性。上述滤波器可用于集中式或分布式状态估计方案，分别也称为紧耦合（TC）和松耦合（LC）集成方案。TC 和 LC 集成方案在全球导航卫星系统/惯性导航系统领域广为人知。集中式/TC 方案通过单级滤波器在测量层融合所有技术/基站。另一方面，分布式/LC 方案采用多级定位：每种技术/基站分别计算自身的位置估计，然后以级联方式在位置层进行融合。正如第二节将要介绍的，文献中提出的所有方法都采用集中式集成方案。在5G定位中，由于状态与测量值之间的关系是非线性的，这种方案本身会使滤波器失去最优性。集中式集成的不利影响将在第五节 B 部分通过仿真展示。随后将说明，多基站的分布式集成完全避免了线性化问题，因为它在设计上采用线性测量模型。因此，本文的贡献如下：

1) 我们对集中式/TC集成方案的缺点进行了全面分析。2) 我们提出了一种新颖的分布式/LC多基站5G定位方法，可避免集中式融合方案的缺点。3) 为了验证该方法，我们在准真实测试环境中评估了三种贝叶斯估计器，即 LC-KF、TC-EKF和TC-UKF。

本文其余部分安排如下：第二节介绍使用最优估计器进行5G定位的相关研究。第三节建立系统模型，第四节展示卡尔曼滤波器的各种实现方式。第五节深入分析集中式融合方案的误差，并提出将5G分布式集成作为有力的竞争方案。第六节详细介绍实验设置，并给出结果及讨论。最后，第七节对全文进行总结。

II. 文献综述

已有多项研究采用不同的估计技术，探讨视距条件下的5G定位。然而，贯穿现有文献的一个共同特点是采用集中式集成方案。值得注意的是，依赖三边测量或三角定位的方法本质上都属于集中式方法。文献 [10] 中的作者采用扩展卡尔曼滤波器，利用离开角和到达时间测量来估计用户设备的位置；由于观测模型高度非线性，产生了较大的线性化误差，但仍有75%的时间实现了亚米级精度。文献 [11], [12] 通过使用到达时间差三边测量，在90%的时间内实现了亚米级精度。然而，这一结果建立在用户设备始终同时连接三台基站的假设之上，而这一假设并不现实。文献 [13] 中的作者提出了一种基于到达时间差和到达角的混合定位方案，采用采用扩展卡尔曼滤波器，95% 的时间内精度达到 3 米以内。尽管如此，它仍面临以往研究中的相同局限。在 [13], 中，作者以集中式方式融合到达时间差和到达角测量值，95% 的时间内精度达到 3 米以内。 [14]中的研究通过采用非线性状态转移模型（NLSTM）替代匀速模型，缓解了其中一些局限。该模型利用车辆的前向速度和航向角来估计车辆位置。所提出的 NLSTM 优于以往研究，95% 的时间内精度达到 2.3 米以内。受 [14],启发， [15] 中的作者采用了相同的 NLSTM 模型，但改为集中式融合到达时间、到达角和航向测量值。车辆的航向测量值是通过组合到达角、离开角和到达时间测量值人工计算得出的。若未正确估计用户设备与基站之间的时钟偏差，则使用到达时间测量值并不实际。此外，所提出的方法使用了相关测量值，却未对测量协方差矩阵进行适当处理，导致扩展卡尔曼滤波器并非最优。该方法仅使用两个基站，95% 的时间内误差可达到 0.34 米。 [16]中的作者以集中式方式融合粗略的到达时间估计值，通过压缩感知方法直接确定用户设备的位置。所提出的方法约有 90% 的时间内精度达到亚米级。 [17]提出了一种基于三个离开角测量值的扩展卡尔曼滤波三角定位方案。该方法还会估计基站因安装误差产生的方位偏差。所提出的三角定位方法有 88% 的时间内精度达到亚米级。然而，假设能够获取三个与用户设备处于视距范围内的基站信号，通常并不现实。 [18]报告的研究提出了一种最小二乘法，直接融合来自多个基站的到达时间差和离开角测量值。此类方法至少需要两个视距基站，但用户设备通常无法获取这样的信号。此外，最小二乘法既不具备卡尔曼滤波器实现的最优加权能力，也不具备其跟踪能力。据报告，所提出的最小二乘法能够以亚米级精度估计位置，但研究未报告这一假设下的置信区间。[19] 中的作者提出了两种基于集中式扩展卡尔曼滤波器的三边定位方案，均使用到达时间差测量值。第一种方法对扩展卡尔曼滤波器进行了改进，在测量协方差矩阵和状态协方差矩阵中添加额外噪声，以应对非线性和噪声的非高斯分布。第二种方法提出了深度扩展卡尔曼滤波方案，利用神经网络（NN）取代改进型扩展卡尔曼滤波器的新息序列，以更好地捕捉非线性。结果表明，与传统扩展卡尔曼滤波器实现相比，所提出的方法明显改善了均方根误差，但未完整报告该方案的统计量。[20]中所述的研究通过高斯—牛顿最小二乘法直接融合到达时间差和到达角测量值，以估计用户设备的位置。所提出的方法还包括一种基于非视距检测和同步异常的基站排除机制。

由于使用厘米波，所提出的方法定位性能较差。关于将无迹卡尔曼滤波器用于 5G独立定位的研究有限。在 [21] 中，研究采用基于无迹卡尔曼滤波的估计器，通过集中式方案同时估计到达角、到达时间以及用户设备的位置，精度达到亚米级。然而，该研究假设基站每隔 50 米部署一个，这与 [22]所述城市区域小型小区的部署标准不符。值得注意的是，其他研究提出了联合定位与同步方案，例如 [23], [24],；另有研究提出联合估计用户设备位置和定位测量量，如 [25], [26]。此外，[21], [27] 中的研究提出联合估计用户设备位置、定位测量量以及用户设备与基站同步。联合估计定位测量量的研究通常采用多阶段滤波方法：先通过扩展卡尔曼滤波器／无迹卡尔曼滤波器估计定位测量量，再使用单独的滤波器进行定位。这类方案不能视为分布式方案，因为定位解决方案仍由单个集中式滤波器计算得出。与用户设备—基站同步相关的研究会在估计用户设备位置和方向的同时进行时钟偏差估计，并且同样采用集中式方式。总之，上述所有研究均采用集中式融合方案来融合基站的各种原始时间与角度测量值。这将对 5G 定位解决方案的精度造成不利影响。

III. 系统模型

5G新空口增强了 LTE 的下行链路（DL）定位参考信号（PRS）和上行链路（UL）探测参考信号（SRS），从而能够进行更精确的定位测量。借助这些信号，通过与配置的参考信号进行相关运算，可计算出 TOA、RTT 和 TDOA。此外，通过比较多个 PRS 信号的接收功率，可在波束成形训练序列中直接计算出 AOD。本文考虑在 UE 侧进行定位，因此使用 DL-PRS 和 UL-SRS 信号来计算 DL-AOD 和 RTT 测量值。随后，利用这些测量值计算 UE 与 BS (r) 之间的相对距离，以及方位角 (θ)，如式（1）和式（2）所示。

$$r = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2} \tag{1}$$

$$\theta = \arctan\left(\frac{\Delta y}{\Delta x}\right) \tag{2}$$

其中，$(\Delta x, \Delta y, \Delta z)$ 表示用户设备位置 (x, y, z) 与基站位置 (x_{BS}, y_{BS}, z_{BS}) 之间的差值。接下来，各个已连接基站提供的距离与角度测量值可以采用集中式或去中心化的方式进行融合。在集中式融合中，所有距离和角度都会在单个滤波器中融合，以计算用户设备的位置，如图 1 所示。另一方面，在去中心化融合中，用户设备首先通过单独的基站可测量量，采用开环、基于几何的方法进行计算，从而得到多个位置估计。随后，最优估计器将这些位置估计融合为单个位置估计，如图 2 所示。最后，为了探索 5G-NR 小小区密集化的真正潜力，自动驾驶场景设定在市中心区域，车辆周围环绕着城市峡谷和高层建筑。第六节-A 所示的仿真设置依据适用于深度城市环境的 3GPP第16版标准设计，这意味着基站之间的部署间隔为 $200 - 500$ 米 [28]。该场景设计表明，用户设备同时连接到最多三个基站的概率为 30%。研究还表明，用户设备有 46% 的时间可以连接到两个基站，另有 21% 的时间只能连接到一个基站。最后，所有基站均失去视距连接的情况较为罕见，发生概率为 3%。因此，将采用文献 [29],中提出的、基于往返时间与接收信号强度测量之间距离比较的非视距检测算法，以排除非视距基站。简而言之，该方法利用基于时间和基于功率的测量值之间的差异来检测非视距通信。具体做法是比较由到达时间和接收信号强度测量值计算出的距离差，并将其与预设阈值进行比较，如式（3）所示。

$$\text{LOS} = \begin{cases} \text{True}, & r_{TOA} - r_{RSS} \leq \varepsilon \\ \text{False}, & \text{otherwise.} \end{cases} \tag{3}$$

其中，r_{TOA} 和 r_{RSS} 分别为基于时间和基于功率的距离测量值，ε 为预设阈值，依据 [29]设定为80 m。

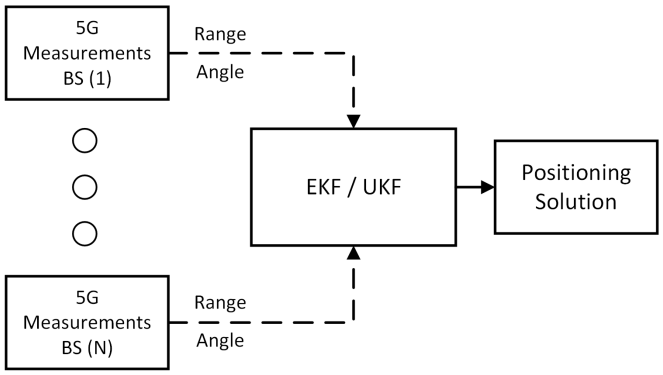

图 1. 集中式5G多基站集成框图。

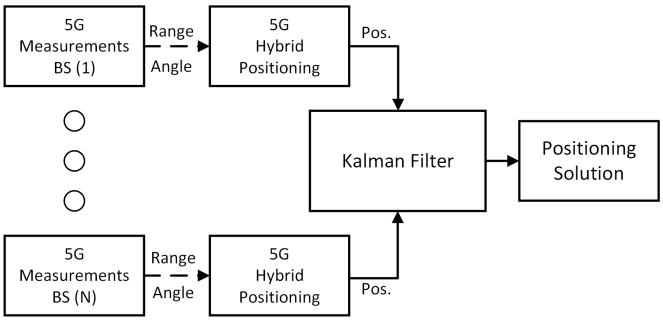

图 2. 分布式 5G 多基站融合框图。

IV. 卡尔曼滤波器实现

卡尔曼滤波器是一种针对含高斯噪声线性系统的最优迭代估计器，如算法1所示。在这两个假设下，卡尔曼滤波器只需跟踪状态的均值和协方差（分别由 $\boldsymbol{x}$ 和$\boldsymbol{P}$表示），即可传播、变换和处理状态的概率密度函数（PDF）。卡尔曼滤波器包含连续的两个阶段：状态预测和校正。在状态预测阶段，卡尔曼滤波器通过转移矩阵 $\boldsymbol{\Phi}=\boldsymbol{I}+\boldsymbol{F}$，将上一历元 $k-1$的后验状态估计$\boldsymbol{x}_{k-1}^{+}$ 和协方差矩阵 $\boldsymbol{P}_{k-1}^{+}$ 传播至当前历元 k。其中，$\boldsymbol{I}$ 为单位矩阵，$\boldsymbol{F}$ 为转移模型。变换的输出为先验状态估计$\boldsymbol{x}_{k}^{-}$ 和协方差矩阵$\boldsymbol{P}_{k}^{-}$ 。转移模型中由外部来源引起的噪声由过程协方差矩阵 $\boldsymbol{Q}$描述。借助噪声耦合矩阵$\boldsymbol{G}$，将过程噪声加入先验协方差矩阵。状态校正阶段利用测量向量$\boldsymbol{z}_k$ 和卡尔曼增益 $\boldsymbol{K}_k$ ，将先验状态和协方差估计更新为后验估计 $\boldsymbol{x}_{k}^{+}$ 和 $\boldsymbol{P}_{k}^{+}$。借助$\boldsymbol{P}_{k}^{-}$ 和测量协方差矩阵 $\boldsymbol{R}$计算卡尔曼增益 $\boldsymbol{K}_k$。此外，测量观测矩阵 $\boldsymbol{H}_k$ 用于将 $\boldsymbol{P}_{k}^{-}$ 和 $\boldsymbol{x}_{k}^{-}$ 从状态域变换至测量域，反之亦然。

值得注意的是，线性卡尔曼滤波器与扩展卡尔曼滤波器的主要区别在于，扩展卡尔曼滤波器处理非线性转移模型和非线性状态测量模型。若转移模型存在非线性，则使用 $f(\boldsymbol{x}_{k-1}^{+})$ 而非 $\boldsymbol{\Phi}\boldsymbol{x}_{k-1}^{+}$ 来转换状态，并通过求取 $f(\boldsymbol{x})$ 的雅可比矩阵来计算 $\boldsymbol{F}$ 。同样，若状态与测量值之间存在非线性，则使用 $h(\boldsymbol{x}_{k}^{-})$ 而非 $\boldsymbol{H}_k\boldsymbol{x}_{k}^{-}$ 将状态转换为测量值，并通过求取 $h(\boldsymbol{x})$ 的雅可比矩阵来计算 $\boldsymbol{H}_k$ 。值得注意的是，$\boldsymbol{\Phi}$和 $\boldsymbol{H}_k$ 仍分别用于转移和转换状态协方差矩阵 $\boldsymbol{P}$。

无迹卡尔曼滤波器通过非线性函数转换状态的概率密度函数，弥补了扩展卡尔曼滤波器在非线性近似方面的不足。无迹卡尔曼滤波器通过生成 $2N+1$ 个西格玛点 $\boldsymbol{\chi}_k$ 来转换概率密度函数，其中 N 是相连基站的数量。随后，无迹卡尔曼滤波器将各个 $\boldsymbol{\chi}_k$ 点通过非线性函数传播，最后计算传播后各点的均值和协方差，分别得到 $\boldsymbol{x}$ 和 $\boldsymbol{P}$。无迹卡尔曼滤波算法如算法2所示。

V. 5G 多基站传感器融合

本节将介绍传统的集中式集成方案和所提出的分布式融合方案。两种方案共用同一转移模型，因此将首先介绍该模型。接下来，将展示并详细讨论集中式方案的线性化误差。最后，将介绍所提出的分布式方案。

算法 1: 卡尔曼滤波器

初始化：$\boldsymbol{x}_0^+, \boldsymbol{P}_0^+, \boldsymbol{Q}, \boldsymbol{R}, k=0$

当 定位**时**

$$
\begin{aligned}
&k = k+1\\
&\boldsymbol{x}_k^- = \boldsymbol{\Phi}\boldsymbol{x}_{k-1}^+\\
&\boldsymbol{P}_k^- = \boldsymbol{\Phi}\boldsymbol{P}_{k-1}^+\boldsymbol{\Phi}^T + \boldsymbol{G}\boldsymbol{Q}\boldsymbol{G}^T\\
&\boldsymbol{K}_k = \boldsymbol{P}_k^-\boldsymbol{H}_k^T(\boldsymbol{H}_k\boldsymbol{P}_k^-\boldsymbol{H}_k^T + \boldsymbol{R})\\
&\boldsymbol{x}_k^+ = \boldsymbol{x}_k^- + \boldsymbol{K}_k(\boldsymbol{z}_k - \boldsymbol{H}_k\boldsymbol{x}_k^-)\\
&\boldsymbol{P}_k^+ = \boldsymbol{P}_k^- - \boldsymbol{K}_k\boldsymbol{H}_k\boldsymbol{P}_k^-
\end{aligned}
$$

end

算法 2: 无迹卡尔曼滤波器

initialization: $\boldsymbol{x}_0^+, \boldsymbol{P}_0^+, \boldsymbol{Q}, \boldsymbol{R}, W_m^i, \lambda, k=0$

while *positioning* **do**

$$
\begin{aligned}
&k = k+1\\
&\boldsymbol{\chi}_k^{-(i)} = \left[\hat{\boldsymbol{x}}_{k-1}^+ \pm \sqrt{\lambda+N}\left[\sqrt{\boldsymbol{P}_{k-1}^+}\right]\right]\\
&\boldsymbol{x}_k^{(i)} = f\left(\boldsymbol{\chi}_k^{-(i)}\right); i=0,1,\ldots,2N\\
&\hat{\boldsymbol{x}}_k^- = \sum_{i=0}^{2N} W_m^i \boldsymbol{x}_k^{(i)}\\
&\boldsymbol{P}_k^- = \sum_{i=0}^{2N} W_m^i \left(\boldsymbol{x}_k^{(i)} - \hat{\boldsymbol{x}}_k^-\right)\left(\boldsymbol{x}_k^{(i)} - \hat{\boldsymbol{x}}_k^-\right)^T + \boldsymbol{Q}\\
&\boldsymbol{z}_k^{(i)} = h\left(\boldsymbol{x}_k^{(i)}\right)\\
&\hat{\boldsymbol{z}}_k = \sum_{i=0}^{2N} W_m^i \boldsymbol{z}_k^{(i)}\\
&\boldsymbol{P}_z = \sum_{i=0}^{2N} W_m^i \left(\boldsymbol{z}_k^{(i)} - \hat{\boldsymbol{z}}_k^-\right)\left(\boldsymbol{z}_k^{(i)} - \hat{\boldsymbol{z}}_k^-\right)^T + \boldsymbol{R}\\
&\boldsymbol{P}_{xz} = \sum_{i=0}^{2N} W_m^i \left(\boldsymbol{x}_k^{(i)} - \hat{\boldsymbol{x}}_k^-\right)\left(\boldsymbol{z}_k^{(i)} - \hat{\boldsymbol{z}}_k^-\right)^T\\
&\boldsymbol{K}_k = \boldsymbol{P}_{xz}\boldsymbol{P}_z^{-1}\\
&\hat{\boldsymbol{x}}_k^+ = \boldsymbol{x}_k^- + \boldsymbol{K}_k\left(\boldsymbol{z}_k + \hat{\boldsymbol{z}}_k\right)\\
&\boldsymbol{P}_k^+ = \boldsymbol{P}_k^- + \boldsymbol{K}_k\boldsymbol{P}_k^-\boldsymbol{K}_k^T
\end{aligned}
$$

end

A. 状态与状态转移过程

本文介绍的所有方法中所考虑的导航状态均包括用户设备（UE）的估计二维位置和速度，即 $\boldsymbol{x}=[x, y, v_x, v_y]^T$。同样，本文所有卡尔曼滤波器实现中的状态转移过程均采用匀速模型，从而得到如式（4）所示的线性状态转移模型。

$$
\boldsymbol{\Phi} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{4}
$$

过程协方差矩阵 $\boldsymbol{Q}$ 包含因违反匀速模型而产生的误差，这些误差可能源于车辆方向改变或加速/减速。因此，$\boldsymbol{Q}$ 是通过经验计算市中心环境中行驶车辆速度方差的平均值来设定的。用于对 $\boldsymbol{Q}$ 进行此类经验调优的实验设置详见第六节。关于

另一方面， $\boldsymbol{R}$ 包含测量误差。对于集中式融合， $\boldsymbol{R}$ 包含距离与角度测量值的噪声方差，并通过经验调优分别设为 1 mm 和 0.1°。经验调优依据整个轨迹产生的定位均方根误差进行。然而，在分布式集成中， $\boldsymbol{R}$ 是各基站位置估计的噪声方差。因此，基于经验调优， $\boldsymbol{R}$ 对 x 和 y 测量值均设为 1 cm。

B. 集中式集成线性化误差

在集中式5G多基站传感器融合中，原始距离与角度测量值会在融合滤波器中直接融合，如图1所示。EKF和UKF集中式实现所使用的测量向量 $\boldsymbol{z}$ 如下：$\boldsymbol{z} = [r_1, \theta_1, \ldots, r_N, \theta_N]^T$。系统在EKF和UKF中的非线性测量模型表示为式（5）。此外，雅可比矩阵 $\boldsymbol{H}_k \in \mathbb{R}^{2N\times 4}$ 通过泰勒级数展开计算，如式（6）所示。值得注意的是， $\boldsymbol{H}_k$ 仅用于集中式EKF实现。

$$h(\boldsymbol{x}) = \begin{bmatrix} \sqrt{(\Delta x_k[n])^2 + (\Delta y_k[n])^2} \\ \arctan\left(\frac{\Delta y_k[n]}{\Delta x_k[n]}\right) \end{bmatrix} \tag{5}$$

$$\boldsymbol{H}_k = \begin{bmatrix} \frac{dx_1}{r_1} & \frac{dy_1}{r_1} & 0 & 0 \\ \frac{-dy_1}{r_1^2} & \frac{dx_1}{r_1^2} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ \frac{dx_N}{r_N} & \frac{dy_N}{r_N} & 0 & 0 \\ \frac{-dy_N}{r_N^2} & \frac{dx_N}{r_N^2} & 0 & 0 \end{bmatrix} \tag{6}$$

在使用原始距离和角度测量值对 5G 基站进行集中式融合时，不可避免地会出现线性化误差。这主要是由于对 $h(\boldsymbol{x})$ 进行线性化时舍弃了高阶项所致。在卡尔曼滤波器实现中，如算法1所示，线性化后的 $\boldsymbol{H}$ 会在多个环节中使用。因此，研究每次使用这种线性化版本的测量观测矩阵所带来的负面影响十分重要。值得指出的是，文献中实现扩展卡尔曼滤波器时常见的一种错误，是在新息序列中使用 $\boldsymbol{H}$而非 $h(\boldsymbol{x})$，也就是说，使用$\boldsymbol{z}-\boldsymbol{H}\boldsymbol{x}$ 而非 $\boldsymbol{z}-h(\boldsymbol{x})$。这种错误会使原本无偏的滤波器产生偏差，导致不必要的额外误差。尽管如此，在扩展卡尔曼滤波器实现中，观测矩阵仅用于计算卡尔曼增益 $\boldsymbol{K}$，而卡尔曼增益在校正过程中有两个作用。首先，它对新息序列中的各个测量误差进行最优加权。其次，它将新息序列从测量域转换到状态域。观测矩阵 $\boldsymbol{H}$ 在这两项功能中都发挥作用。首先，利用 $\boldsymbol{H}$ 计算新息协方差矩阵（$\boldsymbol{H}\boldsymbol{P}^-\boldsymbol{H}^T + \boldsymbol{R}$）。新息协方差矩阵对于扩展卡尔曼滤波器的加权过程至关重要。因此， $\boldsymbol{H}$ 中的线性化误差会导致滤波器对新息序列过度自信或信心不足。值得注意的是，无迹卡尔曼滤波器实现不会出现此类误差，因为它使用西格玛点计算新息协方差矩阵。这将带来更准确的测量值加权效果。观测矩阵的第二个作用是帮助将新息残差误差从测量域转换到状态域。这通过使用 $\boldsymbol{H}^T$ 来实现。也就是说，状态与测量值之间的非线性关系被简化为 $\boldsymbol{H}^T$与 $\boldsymbol{z}-h(\boldsymbol{x})$ 之间的线性乘法。这种对非线性关系的简化会在集中式扩展卡尔曼滤波器实现中造成较大的定位误差。值得注意的是，尽管使用西格玛点计算卡尔曼增益，无迹卡尔曼滤波器的集中式实现仍会受到此类变换误差的影响。这是因为无迹卡尔曼滤波器仍使用 $\boldsymbol{K}$ 与 $\boldsymbol{z} - h(\boldsymbol{x})$ 之间的线性乘法来执行非线性变换。因此，与普遍看法相反，无迹卡尔曼滤波器并不能完全避免线性化误差。事实上，作者认为，由于卡尔曼滤波器的内在基本设计，所有卡尔曼滤波器实现及其变体在某种程度上都会受到线性化误差的影响。

为进一步研究上述线性化误差，我们进行了多次理论仿真。仿真分别考察了距离与角度测量值的加权误差和变换误差。为模拟加权误差，我们使用随机数生成器生成一组均值和方差给定的正态分布用户设备位置，并形成点云。随后，将该点云分别通过非线性测量模型 $h(\boldsymbol{x})$和线性化测量模型 $\boldsymbol{H}\boldsymbol{x}$处理一次。最后，展示变换后概率密度函数，以供比较。非线性变换得到的概率密度函数作为真实值，代表理想情况下分布的形态。当然，与线性变换后的分布不同，非线性变换后的分布不一定呈高斯分布。不过，仍希望线性变换后的分布尽可能接近非线性变换后的分布，从而实现公平的测量值加权。图3和图4分别展示了近距离和远距离下距离测量值的概率密度函数变换仿真结果。可以看到，在近距离下，线性变换后的概率密度函数无法模拟非线性变换后的概率密度函数，这与 [30]的预期一致。更重要的是，线性变换后的概率密度函数方差高于非线性变换的实际方差，这意味着滤波器会低估校正更新量。另一方面，在远距离下，两种概率密度函数几乎完全相同，因此能够对测量值进行恰当加权。

图 5 和图 6 分别展示了近距离和远距离角度测量的概率密度函数（PDF）变换仿真结果。可以看出，与非线性变换后的概率密度函数相比，线性变换后的概率密度函数在这两种情况下都过度自信。测量值的这种过度自信在现实导航中十分危险，尤其是在变换误差也可能导致更新存在偏差的情况下。

为了模拟变换误差，创建了一个用户设备位置网格，并通过非线性测量模型 $h(\boldsymbol{x})$ 计算距离和角度，以及

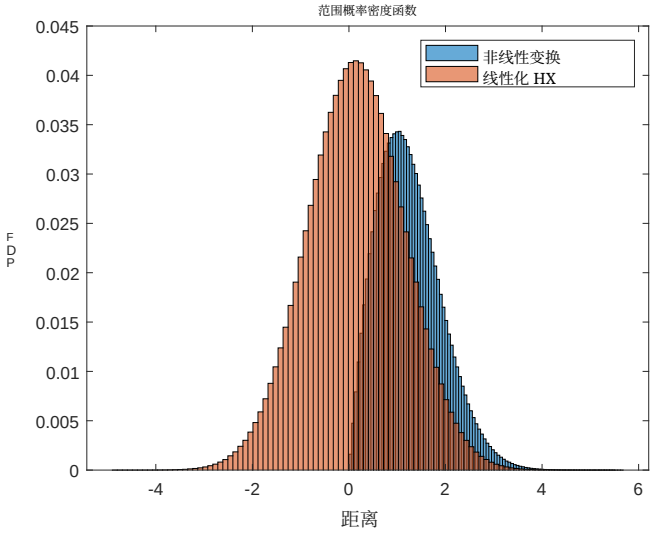

图 3. 基站-用户设备距离较近时（$\Delta x = \Delta y = 0.1$ m），位置概率密度函数向范围概率密度函数的变换。

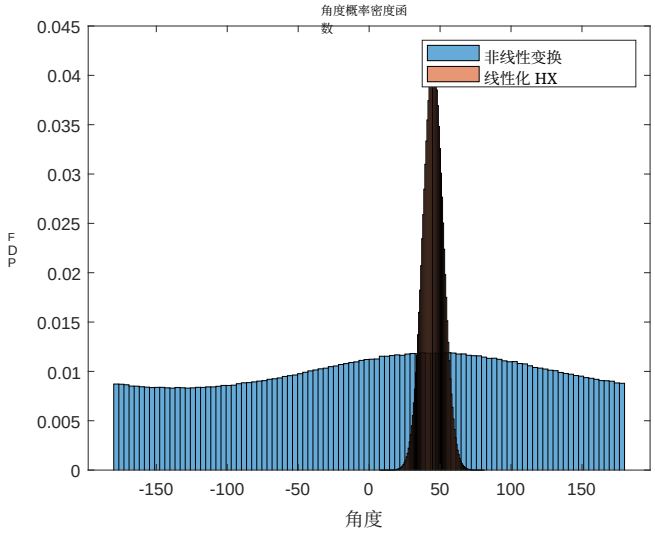

图 5. 基站-用户设备距离较近（$\Delta x = \Delta y = 0.1$ m）时，位置概率密度函数向角度概率密度函数的转换。

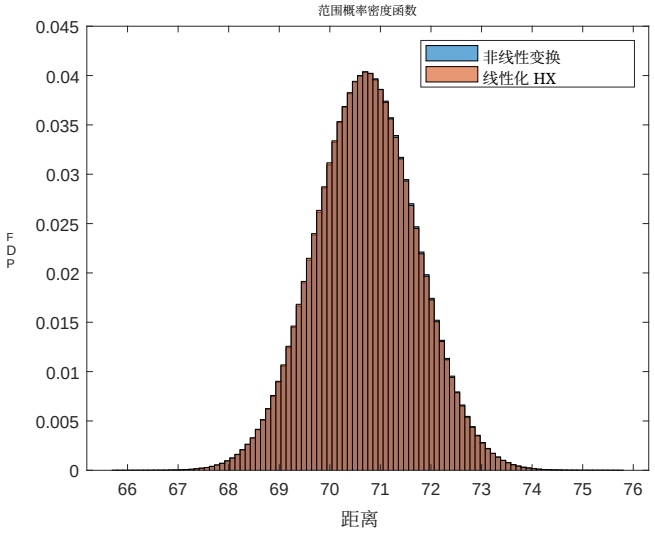

图 4. 基站-用户设备距离较远时（$\Delta x = \Delta y = 50$ m），位置概率密度函数向范围概率密度函数的变换。

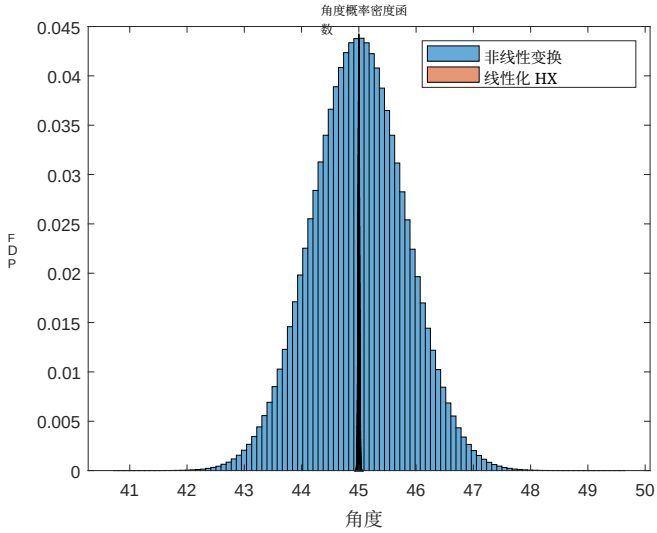

图 6. 基站-用户设备距离较远（$\Delta x = \Delta y = 50$ m）时，位置概率密度函数向角度概率密度函数的转换。

通过线性化测量模型 $\boldsymbol{Hx}$ 进行计算。随后给出了这两种变换之间的差异，这直接反映了泰勒级数近似所产生的线性化误差。图 7 和图 8 分别展示了基站与用户设备距离较近和较远时的距离测量线性化误差。显然，随着用户设备越来越靠近基站，线性化变换造成的线性化误差会增大。有关误差的更多分析见 [30]。图 9 展示了以 θ =45° 为中心进行线性化时的角度变换误差。该图揭示了几点。首先，通过泰勒级数近似对反正切函数进行线性化会导致相当大的误差，最高可达 240°。其次，可以看出线性化

当 Δx 和 Δy 相等时，误差最小，这符合预期，因为线性化是在 45° 附近进行的。第三，反正切函数的线性化对新息序列中的任何误差都非常敏感，因为当新息序列误差不再非常接近零时，线性化误差会大幅增加。因此，如果存在其他可行的替代方案，则不建议对这类函数进行线性化；分布式融合方案便是这种情况。

C. 提出的分布式集成

作者认为，多个基站的分布式集成是 5G-NR 的主要优势之一。过去，基于全球导航卫星系统的系统无法采用分布式集成方案，因为单颗卫星无法仅凭一次距离测量估算用户设备的位置。因此，全球导航卫星系统不得不采用集中式融合方案，并承受其不可避免的线性化误差。

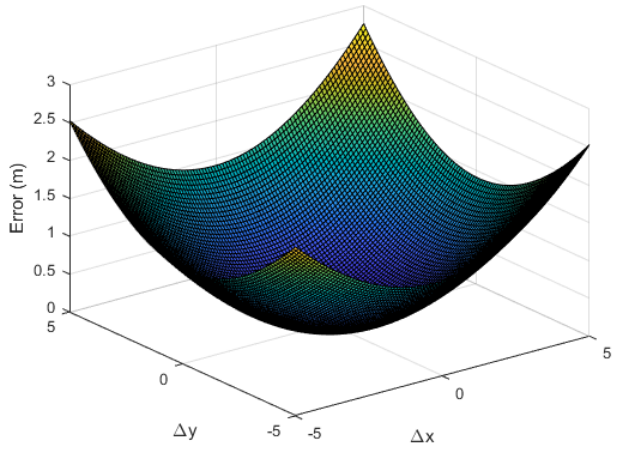

图7. 基站-用户设备距离较近时的距离线性化误差（$\Delta x = \Delta y = 1$ 米）。

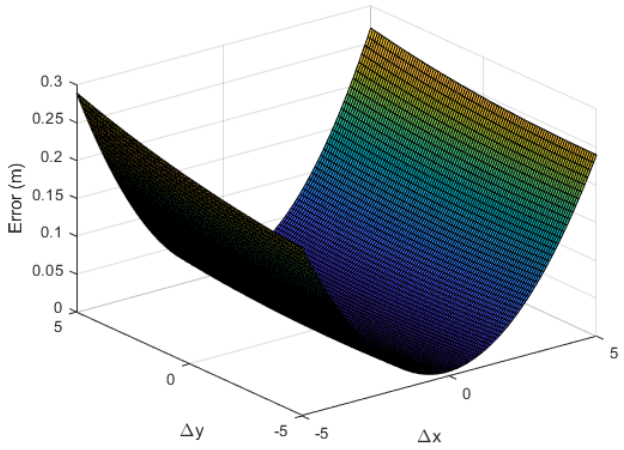

图8. 基站-用户设备距离较远时的距离线性化误差（$\Delta x = 1m$，$\Delta y = 50$ 米）。

相反，单个 5G 基站能够独立估算用户设备的位置，从而实现基站的分布式集成，此时状态与测量值之间呈线性关系。如下所示，若要利用单个基站进行去中心化融合，计算车辆的三维位置，则需要距离、方位角和仰角：

$$\begin{aligned} x &= r \cdot \sin(\theta)\cos(\phi) + x_{BS} \\ y &= r \cdot \cos(\theta)\cos(\phi) + y_{BS} \\ z &= r \cdot \sin(\phi) + z_{BS}, \end{aligned} \tag{7}$$

其中，ϕ 为仰角。为了测量仰角以及离开角的方位角，需要使用由天线组成的二维均匀矩形阵列（URA）。或者，如果已知车辆高度保持不变，则可以降低对仰角信息的要求。因此，只需使用一维均匀线性阵列（ULA）即可。对于陆地车辆而言，这一假设通常成立，因为其在 z 轴方向上的变化通常很小。因此，车辆的位置可以计算如下：

$$\begin{aligned} x &= r_{2D} \cdot \sin(\theta) + x_{BS} \\ y &= r_{2D} \cdot \cos(\theta) + y_{BS} \\ r_{2D} &= \sqrt{r^2 - \Delta z^2}, \end{aligned} \tag{8}$$

其中，r_{2D} 为基站与用户设备之间的二维距离，Δz 为基站与用户设备之间已知的高度差。可以看出，式（8）中的计算仍会使用非线性模型。不过，这些非线性模型是在卡尔曼滤波器实现之外使用的。因此，无需进行线性化。

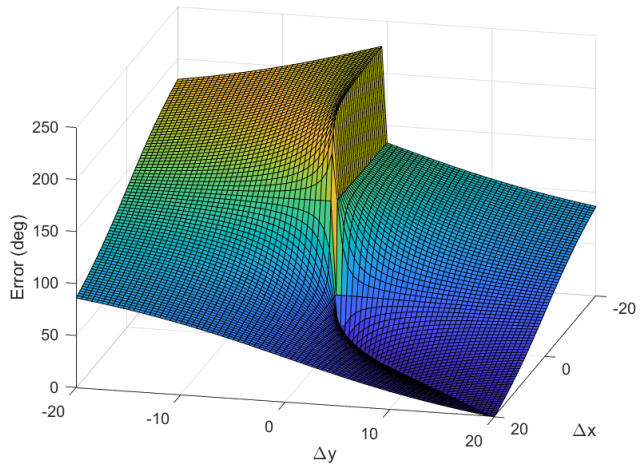

图9. 45°方向上的角度线性化误差。

在所提出的 5G 多基站去中心化传感器融合方案中，测量向量 $\boldsymbol{z}$ 如下所示：$\boldsymbol{z} = [x_1, y_1, \ldots, x_N, y_N]^T$。可以看出，状态与测量值之间的线性关系确实是线性的。因此，式（9）中给出的用于 5G 基站去中心化融合的 $\boldsymbol{H}_k$ 矩阵，能够完整描述状态向量 $\boldsymbol{x}$ 与测量向量 $\boldsymbol{z}$之间的关系，同时不会产生任何线性化误差。

$$\boldsymbol{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \tag{9}$$

值得注意的是，尽管所提出的方法设计简单而优雅，5G定位文献中却尚未提出过此类方案。因此，本文

提出在5G多基站定位中采用分布式融合方案，因为该方案能够消除线性化误差，同时不会带来任何不利影响。

VI. 实验设置与结果

A. 实验设置

为了验证分散式/LC集成相较于集中式/TC集成的优越性，我们使用了由 Siradel 提供的准真实5G仿真设置。Siradel 5G信道包含多伦多、纽约和巴黎等城市市中心区域内建筑物、植被和水体的基于激光雷达的地图，如图10所示。该仿真工具需要用户设备和与其虚拟连接的基站的位置，并利用射线追踪功能和传播模型计算所需的定位测量量，例如接收信号强度、到达时间、到达角和离开角。为了模拟真实的城市导航场景，一辆车辆配备了 NovAtel 提供的高端定位解决方案，其中包括 KVH 1700、一台战术级惯性测量单元，以及 NovAtel 的战术级全球导航卫星系统接收机，并在多伦多市中心行驶。车辆行驶了1小时13分钟，轨迹长9公里，如图11所示。该轨迹采集于交通高峰时段，因此遇到了许多车辆突然停车和加速的动态情况。此外，轨迹包含许多转弯和具有挑战性的操控动态。随后，我们编写了一段代码，按照第三代合作伙伴计划第16版指南 [28]，沿着行驶轨迹每隔250米布设基站。最后，将生成的基站位置和 NovAtel 的参考解决方案导入 Siradel，以生成所需的5G测量量。Siradel 被配置为使用载波频率约为28 GHz、带宽为400 MHz的毫米波信号。基站配备了 8×1 均匀线性阵列，而用户设备则配备了全向天线。

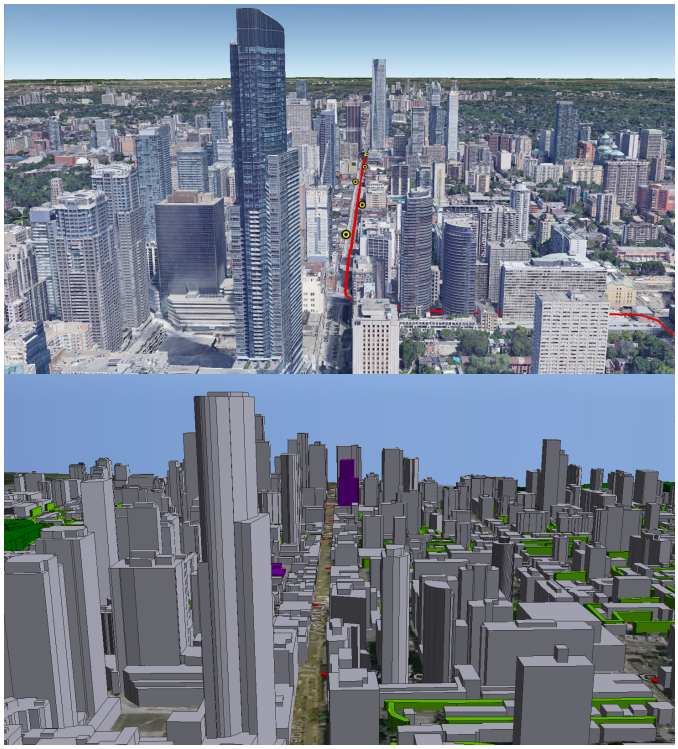

图10. 谷歌地球中的多伦多市中心，安大略省（上）与 Siradel 仿真工具（下）。

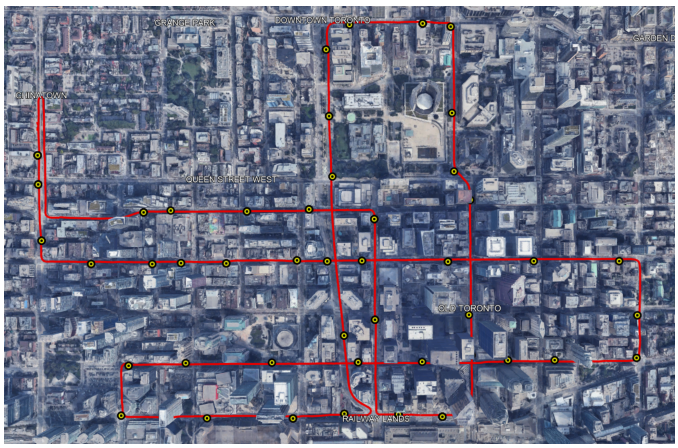

图11. 多伦多市中心轨迹（红色）及5个基站（黄色圆圈）。

B. 结果与讨论

本节将比较采用扩展卡尔曼滤波器和无迹卡尔曼滤波器的集中式方案，与采用卡尔曼滤波器的所提分布式方案的性能。比较将在三种场景下进行。首先，为所有滤波器提供理想的距离与角度测量值。该测试中产生的位置误差将完全归因于线性化误差。第二种测试场景将采用 Siradel 仿真得到的准实测数据，并允许进行非视距通信，但不启用非视距检测功能。该测试将表明，非视距检测能力是实现车道级定位的必要条件。最后，第三种测试场景将采用准实测数据以及[29]中讨论的非视距检测能力。该场景将作为准确的基准，用于评估所比较的滤波器和积分方案的预期性能。对于所有测试场景，还将针对扩展卡尔曼滤波器和无迹卡尔曼滤波器方案给出一种三边测量变体解，分别称为 EKF-R 和 UKF-R，以评估在集中式融合中加入角度测量的优缺点。

图12描绘了采用理想测量值时所有已实现的滤波器和积分方案的累积分布函数（CDF）。显然，分布式卡尔曼滤波器该实现优于所有其他方案，表现几乎完美。另一方面，可以看出，扩展卡尔曼滤波器混合实现的性能最低，甚至不及其三边测量对应方案。这证明，对基于角度的测量进行线性化会阻碍滤波器的性能，因为它带来的额外误差多于额外信息。此外，两种无迹卡尔曼滤波器实现的性能几乎相同，这意味着在集中式融合方案中加入角度测量并未带来额外价值。而且，显然，与其扩展卡尔曼滤波器对应方案相比，无迹卡尔曼滤波器在分米级误差方面的误差更多，但它能够抑制超过 0.5 m 的误差。为了更深入地了解

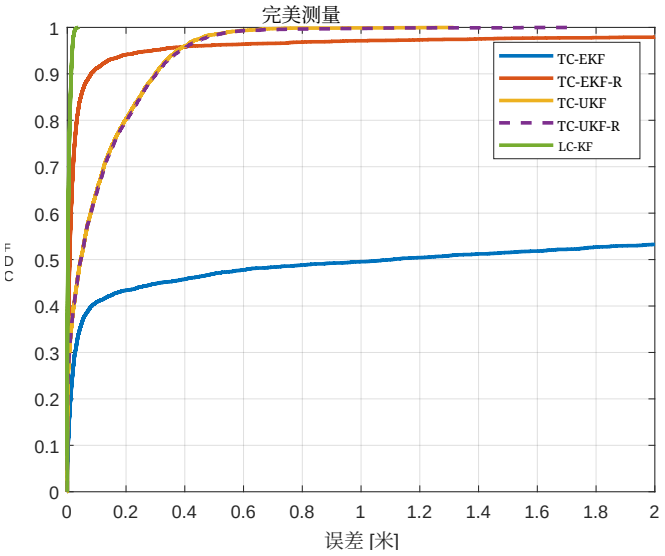

图12. 使用完美的距离和角度测量值时二维定位误差的累积分布函数。

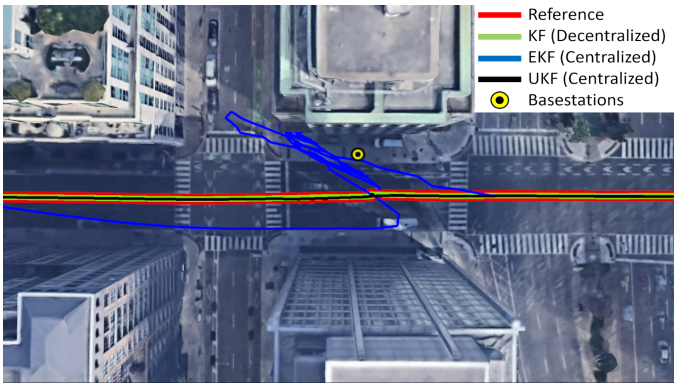

图13. 驾驶经过基站附近时展示滤波器性能的第一个特写，使用完美测量

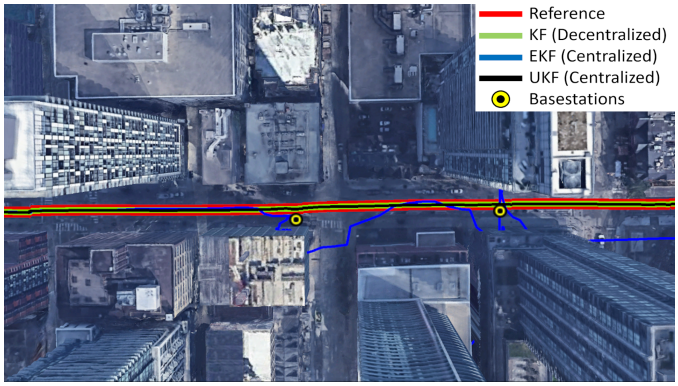

图14. 驾驶经过基站附近时展示滤波器性能的第二个特写，使用完美测量值。

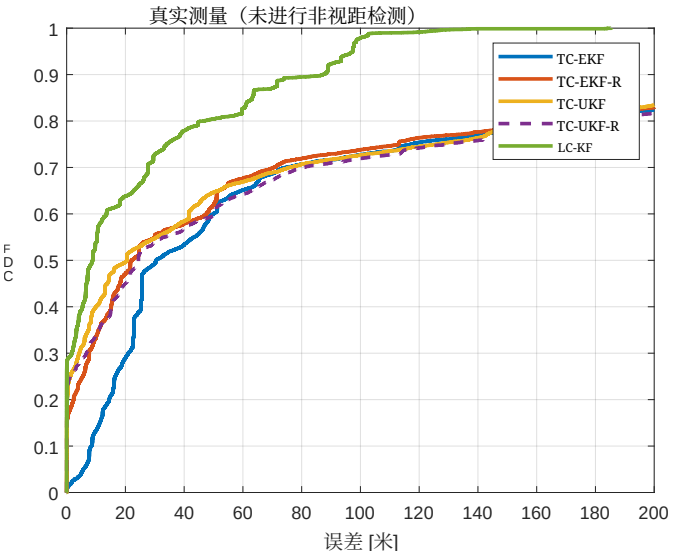

图 15. 未进行非视距检测时，利用近似真实的 Siradel 距离和角度测量值所得二维定位误差的累积分布函数。

线性化误差如何影响测量值，图 13 和图 14 展示了两个局部放大的测试样本，其中用户设备行驶至靠近基站的位置。可以看出，分布式卡尔曼滤波器和集中式无迹卡尔曼滤波器在经过附近基站时都没有维持较大的误差。相反，由于线性化误差，集中式扩展卡尔曼滤波器实现产生了持续且显著的定位误差。

图 15 展示了使用来自 Siradel 的真实距离与角度测量值、且不具备非视距检测能力时，所有已实现滤波器和积分方案的累积分布函数。显然，所提出的分布式卡尔曼滤波器实现以显著优势超越了所有其他方案。然而，这种性能仍不足以达到车道级精度，因为它无法抑制较大的误差。同时，所有其他实现都未能提供可用的估计结果，其精度低于 2 米的时间占比不到 26%。这一结果符合预期，因为当新息序列的残差误差数值较大时，线性化误差的影响更大，而非视距测量值正是如此。这一发现凸显了开发非视距检测算法的重要性，而学界对此关注不足。此外，这也证明了所提出的分布式方法具有优越性，尤其是在非视距检测器未能检测出非视距通信链路的情况下。

图 16 展示了使用真实 Siradel 距离和角度测量值以及 [29] 中的非视距检测能力时，所有上述方案的定位误差累积分布函数。显然，所提出的分布式卡尔曼滤波器实现，在分米级精度和米级精度统计方面均优于其他实现。所提出的方法在约 91% 的时间内实现了亚米级精度。两种无迹卡尔曼滤波器实现均能在约 82% 的时间内保持低于 1 米的精度。还可以看到，基于三边测量的无迹卡尔曼滤波器略优于其混合型对应方法，这是因为它避免了角度测量值带来的额外线性化误差。最后，毫无疑问，两种扩展卡尔曼滤波器实现都不适用于

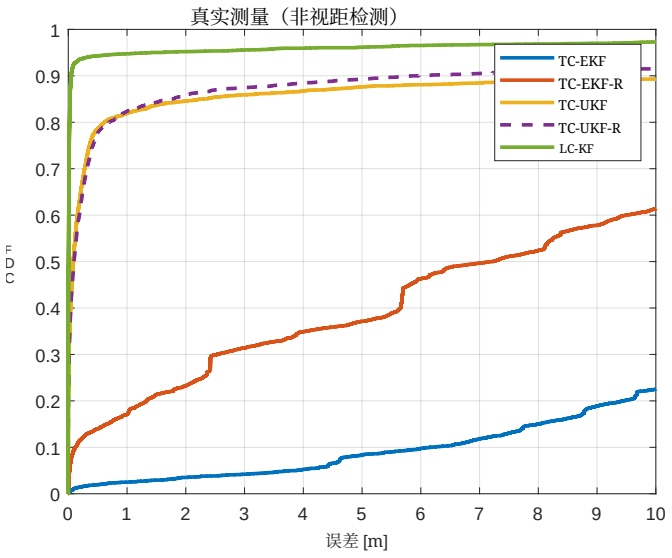

图 16. 使用准真实 Siradel 距离和角度测量并进行非视距检测时的二维定位误差累积分布函数。

车道级定位，尽管基于三边测量的版本因上述原因表现显著更好。

图 17 至图 19 展示了三种不同场景下分布式卡尔曼滤波器和集中式无迹卡尔曼滤波器定位解决方案的局部放大样例。第一个场景如图 17 所示，描述了滤波器在靠近某个基站、同时连接多个基站时的性能。可以看出，所提出的分散式卡尔曼滤波方法没有持续产生误差，而集中式无迹卡尔曼滤波器实现由于线性化误差，在靠近该基站的位置附近短时间内产生了车道级误差。第二个场景如图 18 所示，描述了滤波器连接单个基站时的性能。所提出方法相较于集中式无迹卡尔曼滤波器的优越性十分明显：由于缺少提供支持的基站，无迹卡尔曼滤波器实现持续产生定位误差的时间更长。最后，第三个场景如图 19 所示，展示了用户设备与附近所有基站均处于完全非视距通信状态时的性能。可以看出，两种实现都持续产生了大量误差。在使用 5G独立定位时，这种结果预计会不时出现。因此，作者认为，亟需将 5G 与其他车载运动传感器进行集成，以弥补此类间断。未来的工作将研究 5G 与其他传感器之间的新型集成方法。表 I 汇总了所有算法和方案的性能统计数据。

表 I 二维定位误差统计摘要

统计量	LC-KF	TC-UKF	TC-UKF-R	TC-EKF	TC-EKF-R
RMS	9 m	47.7 米	12.8 米	881.2 米	115.7 米
Max	89.3 米	885.7 米	145.3 米	5.8e4 米	2.3e3 米
< 2 米	95.2%	84.5%	85.7%	3.5%	23.3%
< 1 米	94.7%	81.9%	82.4%	2.5%	17.1%
< 30 厘米	93.9%	71.4%	68.9%	1.7%	12.7%

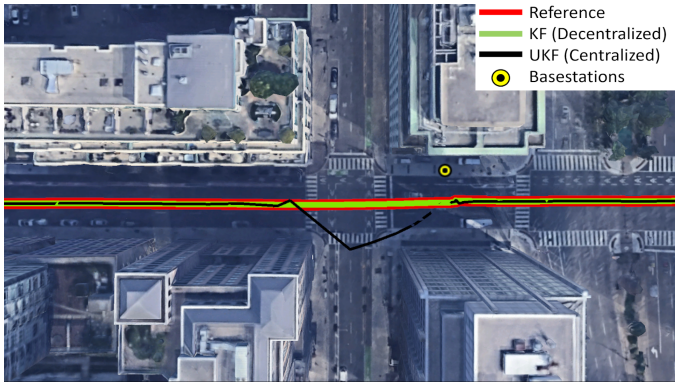

图 17. 首个局部放大图，展示车辆在靠近一个基站行驶时，连接多个基站并使用准真实测量数据的情况下滤波器的性能。

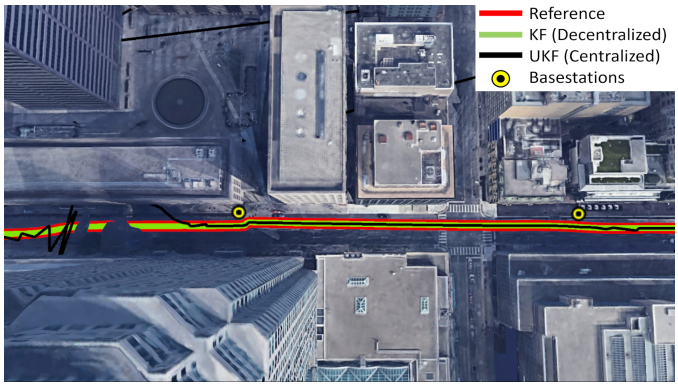

图 18. 第二个局部放大图：展示连接单个基站并使用准实测数据时，车辆驶近基站过程中滤波器的性能。

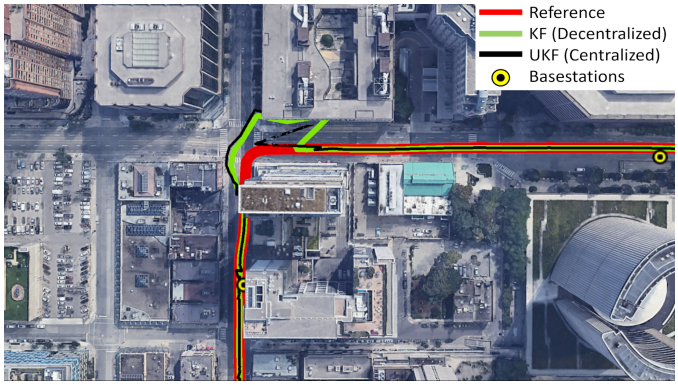

图 19. 第三个局部放大图：展示连接非视距基站并使用准实测数据时，车辆驶近基站过程中滤波器的性能。

VII. 结论

总之，研究表明，文献中用于定位的 5G 多基站集成方案深受全球导航卫星系统三边测量集中式方案的启发。研究证明，由于直接使用距离与角度测量值，此类方案会产生线性化误差。这类

误差对于基于全球导航卫星系统的算法而言不可避免，因为其状态与测量值之间不存在一一对应关系，且算法仅依赖距离测量。然而，研究表明，在 5G 中，借助基于角度的测量，可以实现状态与测量值之间的一一对应，从而使在位置层而非测量层进行集成成为可能。因此，研究提出采用基于分布式卡尔曼滤波器的集成方案，以彻底消除线性化误差。为测试所提出的集成方案，研究使用准实测仿真系统，模拟在多伦多市中心运行的 5G 网络，并采用一条时长为 1 小时 13 分钟的真实轨迹。测试分别在完美测量场景，以及具备／不具备非视距检测能力的真实测量场景中进行。结果表明，在所有场景下，分布式定位方案的表现均显著优于采用基于扩展卡尔曼滤波器和基于无迹卡尔曼滤波器的滤波器的集中式对应方案。

参考文献

[1] T. G. Reid、S. E. Houts、R. Cammarata、G. Mills、S. Agarwal、A. Vora 和 G. Pandey，《自动驾驶车辆的定位需求》，*SAE*国际网联与自动驾驶车辆期刊，第2卷，第3期，2019年9月。 [在线]。可访问：https: // doi.org/ 10 4271 2 12 02 03 0012 。% F - - - F. Mogyorosi、P. Revisnyei、A. Pa˘sic、Z. Papp、I. T¨or¨os、P. Varga 和 A. Pa˘si´c，《5G和6G网络中的定位——综述》，*Sensors*，第22卷，第13期，2022年。[2] [3] P. Nair 和 A. S. Sarif，《全球定位系统在建筑业中的应用综述》，工程应用与技术进展，第3卷，第1期，第249–259页，2022年6月。[4] F. Mazhar、M. G. Khan 和 B. S¨allberg，《利用超宽带实现精准室内定位：方法、算法与实现综述》，无线个人通信，第97卷，第3期，第4467–4491页，2017年。[5] F. Liu、J. Liu、Y. Yin、W. Wang、D. Hu、P. Chen 和 Q. Niu，《基于WiFi的室内定位技术综述》，*IET*通信，第14卷，第9期，第1372–1383页，2020年。[6] S. Dwivedi、R. Shreevastav、F. Munier、J. Nygren、I. Siomina、Y. Lyazidi、D. Shrestha、G. Lindmark、P. Ernstr¨om、E. Stare、S. M. Razavi、S. Mu- ruganathan、G. Masini、 。A. Busin 和 F. Gunnarsson，《5G网络中的定位》，*IEEE*通信杂志，第59卷，44，2021年11月，38第期，第–页。[7] R. E. K´alm´an，《线性滤波与预测问题的新方法》，基础工程学杂志，第82卷，45，1960年3月，1第期，第–页。[8] H. W. Sorenson 和 A. R. Stubberud，《通过近似后验概率密度进行非线性滤波》，国际控制杂志，第8卷，第1期，第33–51页，1968年。[9] S. Julier 和 J. Uhlmann，《无迹滤波与非线性估计》，*IEEE*会议录，第92卷，第3期，第401–422页，2004年。[10] J. Talvitie、T. Levanen、M. Koivisto、K. Pajukoski、M. Renfors 和 M. Valkama，《利用5G新空口同步信号对高速列车进行定位》，载于*IEEE*无线通信与网络会议（*WCNC*），2018年，第1–6页。[11] J. Talvitie、T. Levanen、M. Koivisto、T. Ihalainen、K. Pajukoski、M. Renfors 和 M. Valkama，《5G NR网络中高速列车的定位与基于位置的波束成形》，载于*IEEE*全球通信大会研讨会（*GC Wkshps*），2018年，第1–7页。[12] J. Talvitie、T. Levanen、M. Koivisto、T. Ihalainen、K. Pajukoski 和 M. Valkama，《采用5G新空口实现现代铁路的定位与位置感知通信》，*IEEE*通信杂志，第57卷，第9期，第24–30页，2019年。[13] J. Talvitie、M. Koivisto、T. Levanen、T. Ihalainen、K. Pajukoski 和 M. Valkama，《5G NR网络中高速移动设备的无线电定位与跟踪：系统概念与性能》，载于欧洲信号处理会议（*EUSIPCO*），2019年，第1–5页。[14] J. Talvitie、T. Levanen、M. Koivisto 和 M. Valkama，《利用非线性状态模型在5G及后续系统中对高速列车进行定位与跟踪》，载于国际无线通信系统研讨会（*ISWCS*），2019年，第309–314页。

[15] M. A. Trivedi 和 J. H. van Wyk，《基于压缩感知的5G定位算法在高速列车定位与跟踪中的应用》，载于*IEEE*国际信息融合会议（*FUSION*），2021年11月，第1–8页。[16] N. Garcia、H. Wymeersch、E. G. Larsson、A. M. Haimovich 和 M. Coulon，《大规模MIMO的直接定位》，*IEEE*信号处理汇刊，第65卷，第10期，第2475–2487页，2017年。[17] E. Rastorgueva-Foi、M. Costa、M. Koivisto、J. Talvitie、K. Leppaneny 和 M. Valkama，《方向不确定性条件下毫米波 5G 系统中的基于波束的设备定位》，载于*Asilomar*信号、系统与计算机会议。美国加利福尼亚州太平洋格罗夫：IEEE，2018年10月，第3–7页。 [在线]。网址：https://ieeexplore.ieee.org/ document/8645340/[18] P. Gertzell、J. Landelius、H. Nyqvist、A. Fascista、A. Coluccia、G. Seco-Granados、N. Garcia 和 H. Wymeersch，《单天线接收机的5G多基站定位》，载于*IEEE*个人、室内和移动无线电通信国际年会（*PIMRC*），2020年8月，第1–5页，ISSN：2166-9589。[19] K. Ko、I. Byun、W. Ahn 和 W. Shin，《使用深度卡尔曼滤波器和5G NR信号进行高速列车定位》，*IEEE*智能交通系统汇刊，第23卷，第9期，第15 993–16 004页，2022年9月，会议名称：IEEE智能交通系统汇刊。[20] A. Xhafa、J. A. del Peral-Rosado、J. A. L´ opez-Salcedo 和 G. Seco-Granados，《基于UTDoA、到达角和基站选择性排除的5G定位性能评估》，*Sensors*，第22卷，第1期，第101页，2022年1月，期号：1，出版商：多学科数字出版研究所。 [在线]。网址：https://www.mdpi.com/ 1424 8220 22 1 101 - / / / [21] M. Koivisto、M. Costa、A. Hakkarainen、K. Leppanen 和 M. Valkama，《在5G超密集网络中使用UKF和EKF进行联合三维定位与网络同步》，载于*IEEE*全球通信大会研讨会（*GC Wkshps*），2016年，第1–7页。[22] 5G Americas，《5G时代的蜂窝通信》，5G Americas，技术报告，2022年1月。[23] J. Werner、M. Costa、A. Hakkarainen、K. Leppanen 和 M. Valkama，《5G超密集网络中的联合用户节点定位与时钟偏移估计》，载于*IEEE*全球通信会议（*GLOBE-COM*），2015年，第1–7页。[24] L. Bai、C. Sun、H. Zhao、J. W. Cheong、A. G. Dempster 和 W. Feng，《采用MIMO天线的5G网络TOA-AOA混合定位方法》，载于中国卫星导航大会（*CSNC*），《电气工程讲义》丛书，C. Yang 和 J. Xie 编。新加坡：Springer，2021年，第285–295页。[25] E. Rastorgueva-Foi、M. Koivisto、M. Valkama、M. Costa 和 K. Leppanen，《利用基于波束的DoD测量值在毫米波无线电网络中进行定位与跟踪》，载于国际定位与*GNSS*会议（*ICL-GNSS*）。吉马良斯：IEEE，2018年6月，第1–6页。 [在线]。网址：https://ieeexplore.ieee.org/document/8440914/ [26] A. Shahmansoori、B. Uguen、G. Destino、G. Seco-Granados 和 H. Wymeersch，《通过5G系统中的毫米波透镜MIMO跟踪位置与方向》，*IEEE*信号处理快报，第26卷，第8期，第1222–1226页，2019年8月，会议名称：IEEE信号处理快报。[27] M. Koivisto、M. Costa、J. Werner、K. Heiska、J. Talvitie、K. Lepp¨anen、V. Koivunen 和 M. Valkama，《5G超密集网络中的联合设备定位与时钟同步》，*IEEE*无线通信汇刊，第16卷，第5期，第2866–2881页，2017年。[28] J. Levine，《5G小蜂窝部署基础》，载于*IEEE*通信学会培训课程，2020年。[29] Q. Bader、S. Saleh、M. Elhabiby 和 A. Noureldin，《面向车辆物联网应用的毫米波5G定位增强型非视距检测》，载于*2022*年*IEEE*全球通信会议，2022年。[30] S. Saleh、S. Sorour 和 A. Noureldin，《使用动态调谐协方差矩阵的毫米波TDOA车辆定位》，载于*IEEE*全球通信大会研讨会（*GC Wkshps*），2021年，第1–6页。



Sharief Saleh （IEEE研究生会员）于2016年和2018年分别获得卡塔尔多哈卡塔尔大学电气工程理学学士和理学硕士学位，目前正在加拿大女王大学攻读电气工程博士学位。硕士学习期间，他获聘为卡塔尔大学研究生助理，随后受聘为卡塔尔多哈卡塔尔大学研究助理。目前，他是加拿大皇家军事学院导航与仪器研究实验室（NavINST）的成员。

他目前的研究兴趣包括5G定位与导航、传感器融合、传感器与仪器、估计理论和强化学习。



Qamar Bader （IEEE研究生会员）于2016年获得卡塔尔多哈卡塔尔大学电气工程理学学士学位，目前正在加拿大女王大学攻读电气工程理学硕士学位。她目前是加拿大皇家军事学院导航与仪器（NavINST）研究实验室的成员。她目前的研究兴趣包括5G定位与导航、传感器融合、深度学习、计算机视觉和环境建图。



Mohamed Elhabiby 于2008年至2014年担任加拿大地球物理联合会大地测量分会的财务主管。他目前是埃及开罗艾因·夏姆斯大学工程学院的副教授，同时也是Micro Engineering Tech Inc.的执行副总裁和联合创始人。该公司位于加拿大艾伯塔省卡尔加里，是一家专注于高精度工程与仪器、移动测绘、激光扫描、变形监测以及GPS/INS集成的高科技国际公司。他是一个考古任务的负责人

位于开罗大金字塔地区。他曾获Astech奖。《Avenue》杂志将他评为“40位40岁以下杰出人士”之一。他担任工作组4.1.4：成像技术、第4.1分委员会：GNSS替代方案与备用方案的主席。2008年至2012年，他主持了加拿大地球物理联合会年会上的地理计算与网络基础设施口头报告专题。



Aboelmagd Noureldin （IEEE高级会员）于1993年和1997年分别获得埃及开罗大学电气工程学士学位和工程物理硕士学位，并于2002年获得加拿大艾伯塔省卡尔加里大学电气与计算机工程博士学位。他现任加拿大皇家军事学院（RMCC）电气与计算机工程系教授，并兼任计算机学院及电气与计算机

女王大学工程学院。他还是加拿大皇家军事学院导航与仪器研究实验室（NavINST）的创始人兼主任。他已出版两本书、四个书籍章节，并在期刊、杂志和会议论文集中发表了 270 多篇论文。他的研究兴趣包括全球导航卫星系统、无线定位与导航、室内定位和多传感器融合，研究应用面向自主系统、智能交通、道路信息服务、人群管理和车联网。他的研究工作促成了 13 项专利，并推动多项定位与导航系统领域的技术获得产业许可。