



结合注意力机制和 LSTM 的参数自适应无模型状态估计

陈伟¹, 金学波^{1,*}, 马慧鋆¹, 曹欣然²

¹北京工商大学, 计算机与人工智能学院, 北京 100048

²厦门大学, 航空航天学院, 厦门 361102

学术编辑: 张伟民; 收稿日期: 2024-04-11; 录用日期: 2024-06-03; 发布日期: 2024-06-15

*通讯作者: 金学波, jinxuebo@btbu.edu.cn

文章引用

陈伟, 金学波, 马慧鋆 & 曹欣然. 结合注意力机制和 LSTM 的参数自适应无模型状态估计. 智能机器人, 2024, 1(1): 55–72.

Citation

Chen, W., Jin, X., Ma, H., & Cao, X. (2024). Combination of Attention Mechanism and LSTM for Parameter Adaptive Model-Free State Estimation. *Journal of Intelligent Robots*, 1(1), 55–72.

© 2024 The Author(s). This work is licensed under a Creative Commons Attribution 4.0 License.

摘要

机动目标跟踪广泛地应用于无人车的自动驾驶跟踪领域。在实际应用中, 系统噪声协方差很难获得准确值。传统的 Kalman 滤波器在系统噪声的协方差未知情况下, 跟踪性能会下降。为了解决由于实际目标运动复杂、测量传感器噪声特性很难准确建模的困难, 本文提出了一种基于注意力参数学习模块的自适应 KF 算法的状态估计方法: 将 Transformer 的编码器和长短时记忆网络 (LSTM) 相结合, 本文设计了注意力学习模块。通过离线对测量数据进行学习, 获得了系统的运动特性, 无需进行系统动力学和测量特性建模。进而, 基于注意力学习模块的输出, 利用期望最大化 (EM) 算法在线估计系统模型参数, 并使用 Kalman 滤波器获得状态估计。本文使用 GPS 轨迹路径数据集进行验证, 实验结果证明了本文提出的无模型状态估计方法的估计精度优于其他模型, 为利用深度学习网络进行轨迹跟踪提供了一种有效方法。

关键词: 轨迹跟踪, 状态估计, Kalman 滤波, Transformer, 长短期记忆网络

Combination of Attention Mechanism and LSTM for Parameter Adaptive Model-Free State Estimation

Wei Chen¹, Xuebo Jin^{1,*}, Huijun Ma¹, Xinran Cao²

¹School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

²School of Aeronautics and Astronautics, Xiamen University, Xiamen 361102, China

Academic Editor:  Weimin Zhang; Submitted: 2024-04-11; Accepted: 2024-06-03; Published: 2024-06-15

*Correspondence Author:  Xuebo Jin, jinxuebo@btbu.edu.cn

Abstract

Mobile target tracking is widely used in the field of autonomous driving tracking for unmanned vehicles. In practical applications, it is difficult to obtain accurate values for the covariance of system noise. Traditional Kalman filters may experience a decrease in tracking performance when the covariance of system noise is unknown. In order to solve the difficulty of accurately modeling the noise characteristics of measurement sensors due to the complex motion of actual targets, this paper proposes a state estimation method based on an adaptive KF algorithm using an attention parameter learning module: combining the Transformer's encoder with a Long Short Term Memory Network (LSTM), this paper designs an attention learning module. By learning the measurement data offline, the motion characteristics of the system were obtained without the need for system dynamics and measurement characteristic modeling. Furthermore, based on the output of the attention learning module, the expectation maximization (EM) algorithm is used to estimate the system model parameters online, and a Kalman filter is used to obtain state estimation. This article uses GPS trajectory path dataset for verification, and the experimental results demonstrate that the proposed model free state estimation method has better estimation accuracy than other models, providing an effective method for using deep learning networks for trajectory tracking.

Keywords: Trajectory tracking, state estimation, kalman filter, transformer, long and short-term memory network

1 引言

状态估计是控制理论和机器学习中的一个重要研究方向,在运动机器人[1]、计算机视觉[2]、运动训练[3]和自动驾驶[4]和智慧工业[46–54]等领域有着广泛的应用。由于系统的状态和观测经常受到随机噪声的干扰,状态估计的目的是通过观测来估计实际状态,使估计更接近于实际状态。在状态估计的发展历程中, Rudolf Emil Kalman 基于观测值递推估计随机线性系统状态,提出了 Kalman 滤波(KF)[5]。他在随机估计理论中引入了状态空间,使用状态模型来描述状态和测量值之间的关系,并通过预测和更新来基于测量值估计状态。Kalman 滤波不需要存储所有的历史数据,而是根据前一时刻的状态估计和当前的测量信息,通过递归方法计算出新的估计,减少了计算机的存储和计算能力需求,提高了实时性。

由于 KF 基于线性随机差分方程,对于非线性系统模型[55–60]的信息估计有较大的偏差,Bucy 和 Sunahara 提出了扩展 Kalman 滤波器(EKF)[6]。EKF 首先将非线性系统线性化处理,然后再利用广义 Kalman 滤波器进行状态估计。EKF 在对系统模型线性化过程中舍弃了高阶导数分量,导致 EKF 在估计中存在估计精度不高的缺点。针对这一问题,Xiong K 等人提出了 UKF[7]。UKF 利用非线性系统函数的概率密度分布近似,引入无迹变换,无迹变换可以通过一定规律的权重以及采样,近似求得均值和方差。无迹变换所获得的结果近似精度较高,同时避免了高度非线性系统函数雅可比矩阵的复杂运算。但是当 UKF 的采样维数大于 3 时会损失掉部分 Sigma 点对非线性函数后验分布的统计特性,使得系统的估计精度下降。因此 Haykinz 等人提出了容积 Kalman 滤波器(CKF)[8],CKF 基于三阶球面径向容积准则,并使用一组容积点来逼近具有附加高斯噪声的非线性系统的状态均值和协方差,CKF 的滤波精度更高收敛性更好。CKF 算法对非线性系统估计时舍去了部

分近似化误差，会造成滤波不满足拟一致性，从而无法对状态真值进行准确估计。传统的滤波算法依赖于实际工程系统中噪声的先验统计信息 [17]。然而，由于外部环境的复杂性，噪声的统计特征是不确定的 [18]。由于噪声的统计特性未知，很难获得准确的估计。因此，传统的滤波算法的发展和应用受到限制。

虽然 Kalman 滤波及其扩展被广泛应用于状态估计，但 Kalman 滤波有两个不可忽视的缺点。

1) Kalman 滤波需要准确的运动目标及传感器模型参数。在实际应用中，由于目标机动特性复杂、以及传感器的测量存在不确定性，通过系统建模很难得到准确的模型参数。因此应用于 Kalman 滤波器的过程矩阵、测量矩阵等系统模型，以及过程和测量噪声特性往往依赖于设计者经验；

2) Kalman 滤波器要求系统参数已知，且系统噪声为高斯白噪声。这意味着，系统的状态符合马尔科夫过程，测量数据在状态已知的条件下相互独立，即所谓的“条件独立”。然而，这在实际系统中往往不满足，状态与测量数据之间存在更加复杂的动力学关系。为了解决第一个问题，Dempster 等人提出了期望最大化 (EM) 算法 [10]，用于在滤波之前进行参数估计。Shumway 和 Stoffer 首先提出了一种采用 EM 算法估计 Kalman 滤波参数的算法 [11]。在此基础上，Ghahramani 和 Hinton 提出了一种将 Kalman 滤波用于线性动态系统状态估计和 EM 算法用于参数估计的方法 [12]，称为 EM-KF 算法。

为了解决第二个问题，研究者们提出了基于数据驱动的深度学习状态估计方法，即基于大量的测量数据和与之对应的状态真实值来训练端到端的递归神经网络，进而，利用网络得到测量数据和状态之间的关系实现状态估计。并且，由于训练数据中复杂的有色噪声可以在网络中进行建模，该网络可以实现有色噪声的高性能状态估计。近年来，深度学习网络依靠其强大的建模能力和提取数据潜在特征的能力，在轨迹跟踪方面得到广泛的应用。

递归神经网络 (RNN) 常被用于分析时序数据 [13]，而长短时记忆网络 (Long Short-Term Memory, LSTM) 是 Hochreiter 等人 [14] 在 1997 年发表的 RNN 网络的优秀变体。LSTM 通过增加一个隐状态单元用于存储序列前面位置的重要信息，设计了三个门控单元进行神经元输入信息重要程度的判断。三个门采用不同的激活函数和计算方式，有效地克服了 RNN 梯度爆炸导致网络瘫痪等问题，在长时间跨度的序列建模中发挥了优势。Chang-hao Chen[24] 等人根据线速度和角速度回归速度矢量的方法，提出了 IONet 研究通过限制 IMU 的固定位置来估计人体运动。该方法基于 Bi-LSTM 模型实现轨迹跟踪，对比传统的行人航位推算 (Pedestrian Dead Reckoning, PDR) 算法在廉价 imu 的数据上有更准确的跟踪效果。Won-Yeol Kim 等人提出的扩展的九轴 IONet[25]，通过补偿六轴 IONet 的漂移问题来提高轨迹跟踪的准确性。除了现有的 6 轴 IONet 的输入结构外，9 轴 IONet 还使用了 IMU 的重力加速度和地磁数据。因此，通过减少数据对 6 轴 IONet 原始输入的依赖，提高了对于位姿变化的估计精度。Rui-peng Gao[26] 等人为了解决汽车 GPS 信号不可用时实时跟踪车辆的问题，提出了通过时间卷积网络 (TCN) 从手机中 imu 的历史数据推断车辆的运动的方法。

深度学习方法有较好的学习能力，但是在大数据时代，神经网络往往需要接收大量的输入信息。这些信息中往往包含许多无用或者用处不大的数据，使得神经网络学习起来很困难，降低深度学习方法的学习效率并且也有可能陷入过拟合现象，对复杂机动目标跟踪问题仍然是一个挑战。

注意机制 [15] 的引入有效地解决了该问题。注意机制可以看作是对人类注意力的模拟，即人类可以注意有用的信息，而忽略无用的信息。近年来，Transformer 一种基于自注意力 Seq2seq 模型，[16] 作为一种全新的注意力机制架构被提出。Transformer 在序列数据处理方面表现出了强大的能力，如自然语言处理 [16]，音频处理 [27]，甚至计算机视觉 [28]。与 RNN 不同，Transformer 允许模型访问历史的任何部分，而不考虑距离，这使得它可能更适合于掌握具有长期依赖关系的重复模式，防止过拟合。自然语言处理实验表明，Transformer 能够较好地解决 LSTM 中的长期依赖问题，从而能够更好地对复杂非线性、有色噪声进行建模。目前，使用该框架应用于无模型跟踪的研究已经引起了研究者们的广泛关注。

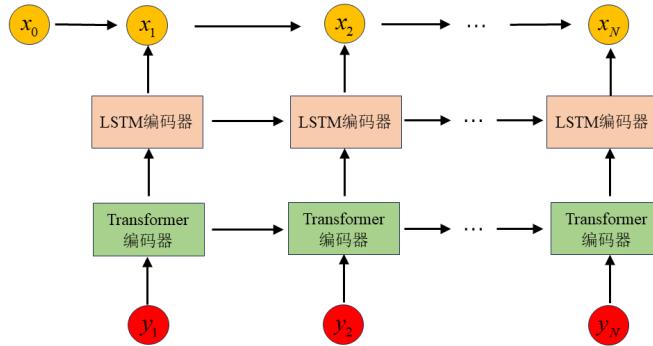


图 1. 系统模型学习器

为了更好的估计机动目标的轨迹，本文提出了一种新的算法 TL-EF，解决在实际中估计方法所面临的问题：利用包含 Transformer 多头自注意力机制和长短时记忆网络 (LSTM) 对学习系统状态及测量的复杂关系，获得其复杂运动的统计特性；同时，基于网络的输出、利用 EM 方法估计 Kalman 滤波器提供更为准确的模型参数。

2 TL-KF 估计

2.1 离线训练系统模型—TL 学习器

现有的基于滤波器模型的轨迹跟踪方法，模型需要和状态估计的方法互相配合工作。根据传感器观测到的测量信息，结合跟踪目标的先验知识对当前跟踪目标运动状态进行估计。为了对机动目标当前状态和测量传感器进行准确的描述，需要建立机动目标的运动过程模型和测量模型。

通常，线性系统模型如下：

$$\begin{aligned}
 x_k &= Ax_{k-1} + \omega_k \\
 y_k &= Cx_k + \nu_k \\
 \omega_k &\sim \mathcal{N}(0, Q), \nu_k \sim \mathcal{N}(0, R) \\
 x_0 &\sim \mathcal{N}(m_0, P_0), k = 1, 2, \dots, N
 \end{aligned} \tag{1}$$

式中， x_k 为状态， y_k 为测量数据， A 为状态转移矩阵， ω_k 为状态噪声， Q 为状态噪声协方差， C 为测量矩阵公式， ν_k 为测量噪声， R 为测量噪声协方差， m_0 和 P_0 分别为初始状态的均值和协方差。通常情况下，可以根据历史知识或系统机理对上述参数进行建模，本文中将其称为初始参数。

本文提出的模型结构主要由离线训练及在线估计两个步骤组成。离线训练是结合系统的初始参数离线训练基于注意力和 LSTM 的系统模型学习器（如图1所示）。使用 Transformer 的编码器结构和 LSTM 结合，对观测数据学习，无需对系统动力学和测量特性建模，仅通过神经网络的训练学习可以学习系统的运动特性。

Transformer 之所以能够捕获长期依赖，是因为它集成了多头自注意力和残差连接，提升了模型的训练深度，不容易过拟合。将 LSTM 与 Transformer 编码器相结合，可以增强 Transformer 编码器的结构优势和序列建模能力。由于 Transformer 可以捕捉到 LSTM 不能捕捉到的显著性，两者结合则可以更好地刻画运动序列。该模型可以充分利用系统的机理模型的已知信息，同时通过训练网络模型从历史测量数据中获得系统的复杂依赖关系。与仅有机理模型相比，该模型能够更好地描述实际系统的动力学与测量关系。

借鉴人类的认知注意力机制 [31]，多头自注意力 [16] 即在网络中产生多个注意力分别平行地作用于特征，其模块的输入为观测数据 $y_{1:N} = [y_1, y_2, \dots, y_N]$ ，注意力任务相关的查询向量表示为 $Query$ ，输入的特征等信息

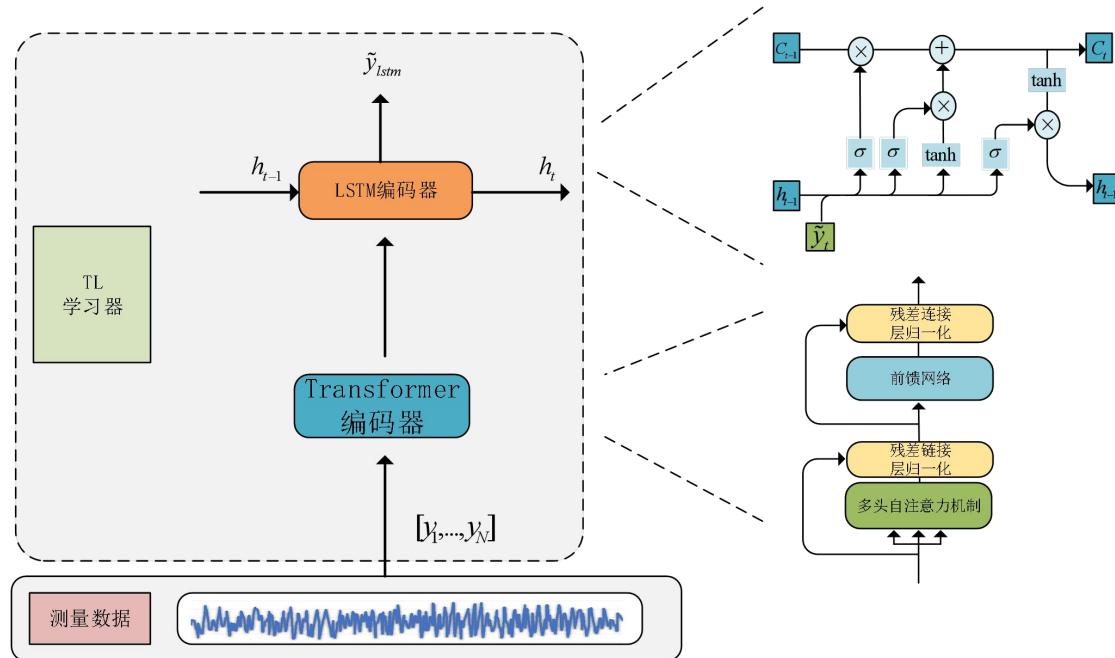


图 2. 基于注意力和 LSTM 的系统模型学习器

以键值对的形式分别表示为 Key 和 $Value$ 。 $Query$ 、 Key 和 $Value$ 分别通过输入的观测数据 $y_{1:N}$ 线性变换得到，则注意力作用的过程可表示为

$$Query = W_Q y_{1:N} \quad (2)$$

$$Key = W_K y_{1:N} \quad (3)$$

$$Value = W_V y_{1:N} \quad (4)$$

$$\text{Attention}(Query, Key, Value) = \text{softmax}\left(\frac{Query \cdot Key^T}{\sqrt{d_k}}\right) Value \quad (5)$$

式中， W_Q 、 W_K 、 W_V 均为可训练的参数投影矩阵， d_k 为 Key 的特征维度。根据输入数据 $Query$ 和 Key ，可以得到点积；然后可以根据 softmax 函数得到输入数据 $Value$ 中各元素对应的权重。 d_k 则是对点积起到缩放作用，防止得到的点积过大，有利于学习的快速进行。

多头自注意力机制的实质是多个注意力计算结果拼接之后的线性变换，该机制可以使模型使用在不同位置得到的不同特征信息，从而增加特征的多样性。多头自注意力的计算方式如下所示：

$$\text{MHA}(Query, Key, Value) = \text{Concat}(\text{head}_1, \dots, \text{head}_t) W^O \quad (6)$$

$$\text{head}_i = \text{softmax}\left(\frac{\text{Query}_i \cdot \text{Key}_i^T}{\sqrt{d_k}}\right) \text{Value}_i \quad (7)$$

式中， t 表示总的头数， W^O 为权重矩阵用于确保符合目标维度， Concat 表示向量的拼接操作， head_i 表示第 i 头的特征。

本文采用了 Transformer 的编码器结构用于对观测数据的潜在动力学特性进行编码学习，利用多头注意力机制，构建了更高维度、多通道的注意力信息，发掘丰富的信息。基于注意力的学习模块将观测数据输入 Transformer 编码器模块，编码器中对观测数据进行位置编码，将编码后的数据输入多头自注意力层。为了防止网络退化和加速收敛，编码器的结构还有残差连接、层归一化层和前馈神经网络。我们通过 Transformer 编码器模块输出潜在编码特征：

$$\tilde{y}_{\text{transformerEncoder}} = \text{TransformerEncoder}(y_{1:N}) \quad (8)$$

在 Transformer 之后，我们使用 LSTM 学习测量数据之间更长的依赖关系：

$$\tilde{y}_{\text{lstm}} = \text{LSTM}(\tilde{y}_{\text{TransformerEncoder}}, h_{t-1}) \quad (9)$$

式中， h_{t-1} 表示前一时刻的隐藏状态。

该系统模型学习器（如图2所示）通过离线训练实现系统动力学关系学习，输入输出关系对是观测数据及系统的参考状态，基于多头自注意力的 Transformer 编码器结构和长短时记忆网络（LSTM）可以来学习数据的潜在特征，实现了无需进行系统动力学和测量特性建模。

2.2 基于 EM 算法的在线估计

经过离线训练的网络模型仍然与实际系统存在偏差，在估计过程中，在线估计部分是使用 EM 算法实时更新模型参数。具体来讲，将测量数据输入已经训练好的注意力 LSTM 学习模块，得到准确刻画运动序列的动力学特性数据，再通过 Kalman 滤波进行在线的递归估计。进而，使用 EM 算法更新当前的状态转移矩阵、测量矩阵、状态噪声和测量噪声方差等参数（如图3所示）。

期望最大化（EM）算法是在概率分布函数（PDF）存在潜在变量时迭代计算参数的最大似然估计（MLE）。根据 Jensen's 不等式：

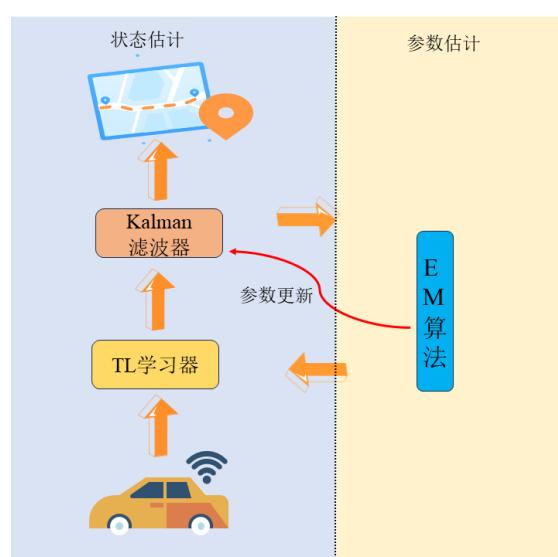


图 3. 基于 EM 算法的在线估计示意图

$$\begin{aligned}\log p(y_{1:N} | \theta) &= \log \left(\int q(z_{0:N}) \frac{p(z_{0:N}, y_{1:N} | \theta)}{q(z_{0:N})} dz_{0:N} \right) \\ &\geq \int q(z_{0:N}) \log \frac{p(z_{0:N}, y_{1:N} | \theta)}{q(z_{0:N})} dz_{0:N}\end{aligned}\quad (10)$$

式中, $z_{0:N}$ 为隐变量, θ 为需要估计的未知参数, $\theta^{(n)}$ 表示第 n 次迭代时的参数。

$$q(z_{0:N}) = p(z_{0:N} | y_{1:N}, \theta^{(n)}) \quad (11)$$

将公式 (11) 代入公式 (10) 得:

$$\begin{aligned}&\int p(z_{0:N} | y_{1:N}, \theta^{(n)}) \log \frac{p(z_{0:N}, y_{1:N} | \theta)}{p(z_{0:N} | y_{1:N}, \theta^{(n)})} dz_{0:N} \\ &= \int p(z_{0:N} | y_{1:N}, \theta^{(n)}) \log p(z_{0:N}, y_{1:N} | \theta) dz_{0:N} \\ &- \int p(z_{0:N} | y_{1:N}, \theta^{(n)}) \log p(z_{0:N} | y_{1:N}, \theta^{(n)}) dz_{0:N}\end{aligned}\quad (12)$$

可知, 上式的后项与 θ 无关, 可以省略。对于状态估计, 最大化观测 $\log p(z_{0:N}, y_{1:N} | \theta)$ 的 PDF 的对数似然, 等价于最大化 Q 。

$$Q(\theta, \theta^{(n)}) = E \left[\log p(z_{0:N}, y_{1:N} | \theta) \mid y_{1:N}, \theta^{(n)} \right] \quad (13)$$

EM 算法从初始估计开始, 然后迭代算法的 E 步和 M 步 (表 1 给出了 EM 算法的伪代码)。

Algorithm 1 EM algorithm

Require: Initial estimation of parameters $\theta^{(0)}$, error ε , maximum iteration number n_m

Ensure: θ^*

- 1: **repeat**
 - 2: **E-step:** compute $Q(\theta, \theta^{(n)})$
 - 3: **M-step:** $\theta^{(n+1)} \leftarrow \arg \max_{\theta} Q(\theta, \theta^{(n)})$
 - 4: **until** $|\theta^{(n+1)} - \theta^{(n)}| < \varepsilon$ **or** iteration number is up to n_m
 - 5: **return** $\theta^* \leftarrow \theta^{(n+1)}$
-

设系统的待估计状态为 x_k , 测量值为 y_k , 其概率分布为:

$$\begin{aligned}p(x_k | x_{k-1}) &= \mathcal{N}(x_k | Ax_{k-1}, Q) \\ P(y_k | x_k) &= \mathcal{N}(y_k | Cx_{k-1}, R) \\ p(x_0) &= \mathcal{N}(m_0, P_0)\end{aligned}\quad (14)$$

因此,

$$p(x_k | x_{k-1}) = \exp \left\{ -\frac{1}{2} [x_k - Ax_{k-1}]^T Q^{-1} [x_k - Ax_{k-1}] \right\} (2\pi)^{-u/2} |Q|^{-1/2} \quad (15)$$

$$p(y_k | x_k) = \exp \left\{ -\frac{1}{2} [y_k - Cx_k]^T R^{-1} [y_k - Cx_k] \right\} (2\pi)^{-v/2} |R|^{-1/2} \quad (16)$$

$$p(x_0) = \exp \left\{ -\frac{1}{2} [x_0 - m_0]^T P_0^{-1} [x_0 - m_0] \right\} (2\pi)^{-u/2} |P_0|^{-1/2} \quad (17)$$

式中, u 、 v 分别为状态转移矩阵和观测矩阵的维数。

在状态的马尔可夫性质和观测的条件独立性的假设下, 我们可以得到:

$$p(x_{0:N} | y_{1:N}) = p(x_0) \prod_{k=1}^N p(x_k | x_{k-1}) \prod_{k=1}^N p(y_k | x_k) \quad (18)$$

因此,

$$\begin{aligned} \ln p(x_{0:N} | y_{1:N}) &= -\sum_{k=1}^N \left(\frac{1}{2} [y_k - Cx_k]^T R^{-1} [y_k - Cx_k] \right) - \frac{N}{2} \ln |2\pi R| \\ &\quad - \sum_{k=1}^N \left(\frac{1}{2} [x_k - Ax_{k-1}]^T Q^{-1} [x_k - Ax_{k-1}] \right) - \frac{N}{2} \ln |2\pi Q| \\ &\quad - \frac{1}{2} [x_0 - m_0]^T P_0^{-1} [x_0 - m_0] - \frac{1}{2} \ln |2\pi P_0| \end{aligned} \quad (19)$$

结合公式 (19) 和公式 (13) 得:

$$\begin{aligned} Q(\theta, \theta^{(n)}) &= -\frac{1}{2} \ln |2\pi P_0| - \frac{N}{2} \ln |2\pi Q| - \frac{N}{2} \ln |2\pi R| \\ &\quad - \frac{1}{2} \text{tr} \{ P_0^{-1} [P_0|N + (m_0|N - m_0)(m_0|N - m_0)^T] \} \\ &\quad - \frac{1}{2} \sum_{k=1}^N \text{tr} \{ Q^{-1} E [(x_k - Ax_{k-1})(x_k - Ax_{k-1})^T | y_{1:N}] \} \\ &\quad - \frac{1}{2} \sum_{k=1}^N \text{tr} \{ R^{-1} E [(y_k - Cx_k)(y_k - Cx_k)^T | y_{1:N}] \} \end{aligned} \quad (20)$$

然后解方程, 最大化 Q :

$$\frac{\partial Q(\theta, \theta^{(n)})}{\partial \theta^{(n)}} = 0 \quad (21)$$

对于模型的参数估计, 我们将原始测量数据 $y_{[1,N]}$ 通过离线训练好的注意力学习模块估计的数据 \tilde{y}_{lstm} 用于 EM 算法, 经过多头自注意力和长短期记忆网络能够捕捉到数据之间的长时间的依赖和数据之间的潜在关联, 能更好的估计滤波器模型的参数。

对于系统参数 A, C 则有:

$$A = \left(\sum_{k=1}^{N-1} E [\hat{x}_{k|k} \hat{x}_{k-1|k-1}^T | y_{1:k}] \right) \left(\sum_{k=1}^{N-1} E [\hat{x}_{k-1|k-1} \hat{x}_{k-1|k-1}^T] \right)^{-1} \quad (22)$$

$$C = \left(\sum_{k=0}^{N-1} y_{\text{lstm},k} E [\hat{x}_{k|k}^T] \right) \left(\sum_{k=0}^{N-1} E [\hat{x}_{k|k} \hat{x}_{k|k}^T] \right)^{-1} \quad (23)$$

式中, $\hat{x}_{k|k}$ 表示滤波器在第 k 步的估计。

然后根据 A, C 更新 Q, R :

$$\begin{aligned} Q = & \frac{1}{N-1} \sum_{k=0}^{N-2} (E[\hat{x}_{k+1|k+1}] - AE[\hat{x}_{k|k}]) (E[\hat{x}_{k+1|k+1}] - AE[\hat{x}_{k|k}])^T \\ & + A\text{Var}[\hat{x}_{k|k}]A^T + \text{Var}[\hat{x}_{k+1|k+1}] \\ & - \text{Cov}(\hat{x}_{k+1|k+1}, \hat{x}_{k|k})A^T - A\text{Cov}(\hat{x}_{k+1|k+1}, \hat{x}_{k|k}) \end{aligned} \quad (24)$$

$$R = \frac{1}{N} \sum_{k=0}^{N-1} [y_{\text{lstm},k} - CE[\hat{x}_{k|k}]] [z_k - CE[\hat{x}_{k|k}]]^T + C\text{Var}[\hat{x}_{k|k}]C^T \quad (25)$$

通过 Kalman 滤波递归的输出状态 $\hat{x}_{k|k}$, 得到估计轨迹。在使用 Kalman 滤波器时, A 为状态转移矩阵由公式 (22) 计算得到, ω_k 为状态噪声, Q 为状态噪声协方差由公式 (24) 计算得到, C 为测量矩阵公式 (23) 计算得到, ν_k 为测量噪声, R 为测量噪声协方差由公式 (25) 计算得到。

3 实验与分析

3.1 数据集

在本研究中, 我们使用的数据集为网上公开的轨迹路径数据集 (<https://github.com/btbuIntelliSense>), 其中仿真数据集共包含 4200 条轨迹路径, 每条路径包含 201 个数据点。模拟的数据范围是在一个从 0 到 100 的二维平面上, 并加入了粉红噪声信号。所含有色噪声是由 MATLAB 信号处理工具箱 ColoredNoise 函数生成。

3.2 实验设立及评价指标

本文基于开源深度学习库 Pytorch 深度学习框架来搭建网络模型, 所有实验均在 Intel Core i5-7300HQ @2.50 GHz CPU 处理器, 8GB 内存的 PC 机上进行。实验设计的神经网络模型, 通过 Pytorch 中的默认参数来进行神经网络的初始化 (如确定性深度学习网络的权值初始化), 所有实验设置计算机固定的随机数种子。

通过对不同的滤波器参数和不同的神经网络模型。我们进行了以下实验:

1) Case 1: 基于公开轨迹数据集的对比;

2) Case 2: 基于北京车辆 GPS 轨迹数据集的对比。

为了评价不同模型预测性能的优劣, 本研究使用四个评价指标来综合评估不同模型的预测性能, 包括均方根误差 (RMSE)、平均绝对误差 (MAE)、对称平均绝对百分比误差 (SMAPE)、皮尔逊相关系数 (R)。这四个评价指标的计算公式如公式 (26) ~ (29) 所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{x}_{k|k} - x_{k|k})^2} \quad (26)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |\hat{x}_{k|k} - x_{k|k}| \quad (27)$$

$$SMAPE = \frac{100\%}{n} \sum_{k=1}^n \frac{|(\hat{x}_{k|k} - x_{k|k})|^2}{(|\hat{x}_{k|k}| + |x_{k|k}|)^2 / 2} \quad (28)$$

$$R = \frac{\sum_{i=1}^n (x_{i|k} - \bar{x}_{i|k}) (\hat{x}_{i|k} - \bar{\hat{x}}_{i|k})}{\sqrt{\sum_{i=1}^n (x_{i|k} - \bar{x}_{i|k})^2 \sum_{i=1}^n (\hat{x}_{i|k} - \bar{\hat{x}}_{i|k})^2}} \quad (29)$$

其中 n 为数据集中的样本总数, $x_{k|k}$ 为参考轨迹的第 k 个真值, $\bar{x}_{k|k}$ 为参考轨迹真值的平均值, $\hat{x}_{k|k}$ 为模型得出的估计轨迹的第 k 个估计值, $\bar{\hat{x}}_{k|k}$ 为模型得出的估计轨迹的平均值。其中, 四个评价指标中的前三个评价指标的意义为: 结果值越小, 模型估计精度就越准确。评价指标 R 所代表的意义是: 结果值越大, 参考轨迹与估计轨迹的拟合效果越好。

3.3 结果和讨论

3.3.1 基于公开轨迹数据集的对比

在这种情况下, 所提出的估计方法与传统的 Kalman 滤波器 [5] 过程模型 CA[38]、CV[39]、Singer[40]、Current Statistical[41] 和 EM-Kalman 滤波器 [12] 进行了比较。传统的 Kalman 滤波器主要是为线性系统设计的, 假设系统和测量噪声遵循高斯模型。CV 和 CA 模型将操纵目标的加速度及其导数视为零平均高斯噪声, 而 Singer 模型将操纵目标和加速度视为指数相关的零平均彩色噪声。然而, 假设为零均值并不适合描述实际机动目标的运动状态。目前的统计模型假设目标运动遵循一个恒定的速度过程, 而观测是状态变量的线性组合, 可以通过最小均方估计进行有效的状态估计。另一方面, EM-Kalman 滤波结合了期望最大化 (EM) 算法来迭代更新系统模型参数和估计隐藏状态变量。当底层系统模型不准确或不确定时, EM-Kalman 滤波可以取得比传统 Kalman 滤波更好的性能, 因此它在实践中成为一种流行的方法。通过将我们提出的估计方法与这些广泛使用的方法进行比较, 我们旨在证明其在跟踪高机动性目标方面的卓越性能。

我们比较了不同滤波器模型的轨迹跟踪性能的优劣, 结果见表1和图4。可以看出, 所提出的模型在各误差评价指标上的结果最低, 最高的 R 值、RMSE、MAE、SMAPE 和 R 分别为 1.71、1.35、4.36 和 0.99。与其他五个滤波器模型相比, 我们提出的模型不需要复杂的手动参数调整过程, 而手动参数调整通常需要大量的专业知识, 而且难以优化。我们提出的 TL-EF 模型与其他六个模型相比, RMSE 的估计精度分别降低了 78.2%、20.9%、34.9%、30.9%、70.4%、62.9% 和 0.72%, MAE 分别降低了 66.5%、10.7%、12.4%、11.3%、60.1% 和 61.1%。此外, 我们的模型使 SMAPE 分别提高了 79.6%、80.4%、82.2%、81.4%、91.5% 和 57.8%。从 R 的指数来看,

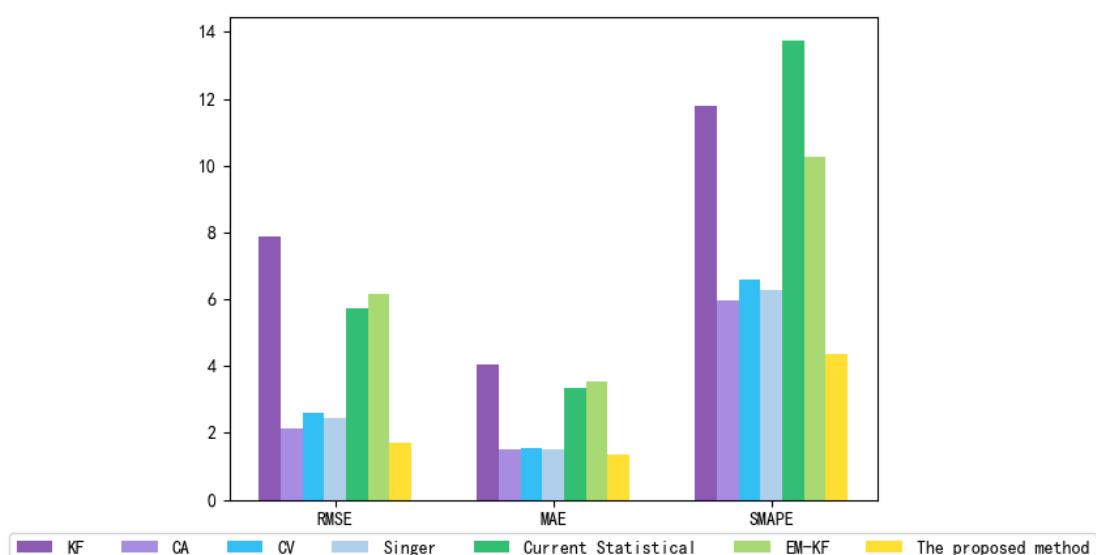


图 4. 不同滤波器模型评价指标的结果直方图

表 1. 不同滤波器模型的估计结果

模型	模型参数	RMSE	MAE	SMAPE	R
KF[5]		7.88	4.04	11.79	0.97
CA[38]	T=0.5 R=400 Qq=100	2.83	1.64	7.13	0.98
	T=1 R=1600 Qq=200	2.15	1.50	5.98	0.99
CV[39]	T=0.5 R=400 Qq=100	3.18	1.62	7.00	0.97
	T=1 R=1600 Qq=200	2.61	1.53	6.57	0.98
Singer [40]	T=0.5 R=400 Qq=100 A=2	3.24	1.64	7.10	0.98
	T=1 R=1600 Qq=200 A=1	2.46	1.51	6.29	0.98
Current Statistical[41]	T=0.2 R=50 a=0.5 xamax=50	5.76	4.30	15.00	0.93
	T=0.1 R=25 a=0.2 xamax=30	5.74	3.36	13.76	0.93
EM-KF [12]		6.14	3.55	10.28	0.98
TL-EF (本文提出的方法)		1.71	1.35	4.36	0.99

所提出的模型的最大 R 值代表估计值和真实值之间的最佳拟合。对上述实验数据的分析表明，我们提出的模型在估计精度和结果拟合方面优于其他滤波器模型。事实证明，使用基于注意力和 LSTM 的学习器可以通过改善 EM 算法的估计参数来提高所提模型的性能，进一步证明了其在轨迹跟踪领域的适用性。

3.3.2 基于北京车辆 GPS 轨迹数据集的对比

在这种情况下，我们利用了 Geolife 北京车辆 GPS 轨迹数据集 (<https://www.gpsvisualizer.com/>)，其中包含 13987 个 GPS 坐标。其中，80% 被选为模型的训练集，其余 20% 为测试集。图6是该数据集中一个轨迹实例。神经网络模型在估计应用中具有很大的优势，特别是在处理复杂的非线性问题和海量数据时 [61]。然而，不同类型的神经网络模型在估计精度、计算效率和模型参数方面存在明显差异。因此，我们将 TL-EF 模型应用于北京车辆轨迹数据集，并与 LSTM[14]、GRU[42]、CNN-LSTM[43]、ConvLSTM[44] 和 PFVAE[45] 等五个模型进行了对比实验。对于每个比较模型，我们都设置了相应的参数。以 GRU 为例，我们采用了 50 个隐藏的神经单元，0.0001 的学习率，1000 次迭代，以及 30 个批次大小。它由两个网络层组成，每个网络层包含 50 个隐藏单元。对于比较模型的滑动窗口策略，我们采用了与滤波器模型相同的递归估计策略。表 3 显示了实验中使用的六个模型的估计结果。

在表2中，与 LSTM、GRU、CNN-LSTM、ConvLSTM 和 PFVAE 模型相比，我们提出的 TL-EF 模型的 RMSE 性能分别提高了 52.6%、73.8%、69.2%、68.4% 和 27.7%，MAE 则提高了 66.7%、76.1%、70.5%、71.8% 和 32.9%。SMAPE 的改善率分别为 74.1%、77.3%、74.9%、69.2% 和 48.9%。此外，TL-EF 模型获得的 R 指标与 LSTM、GRU、CNN-LSTM、ConvLSTM 和 PFVAE 模型相当。

在图7中，我们可以看到每个模型轨迹的估计值和真实值所呈现的散点图。这些估计值的直线与相应散点的真实经度和纬度值非常接近，比较准确地反映了模型的估计结果。

上述分析表明，TL-EF 模型在估计 GPS 轨迹方面具有较高的精度和稳定性，优于其他传统模型和深度学习模

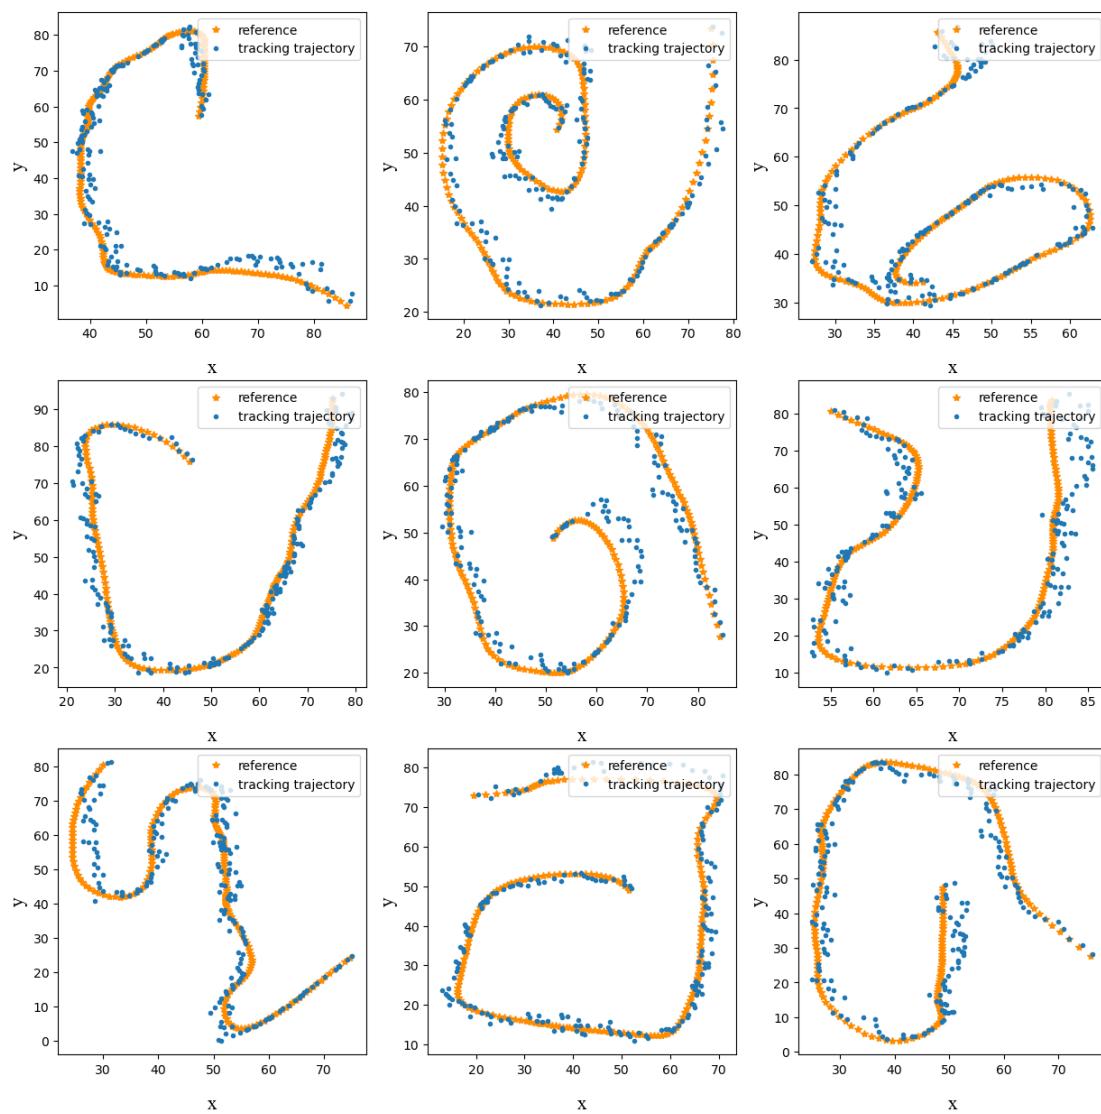


图 5. 估计模拟数据轨迹的结果实例

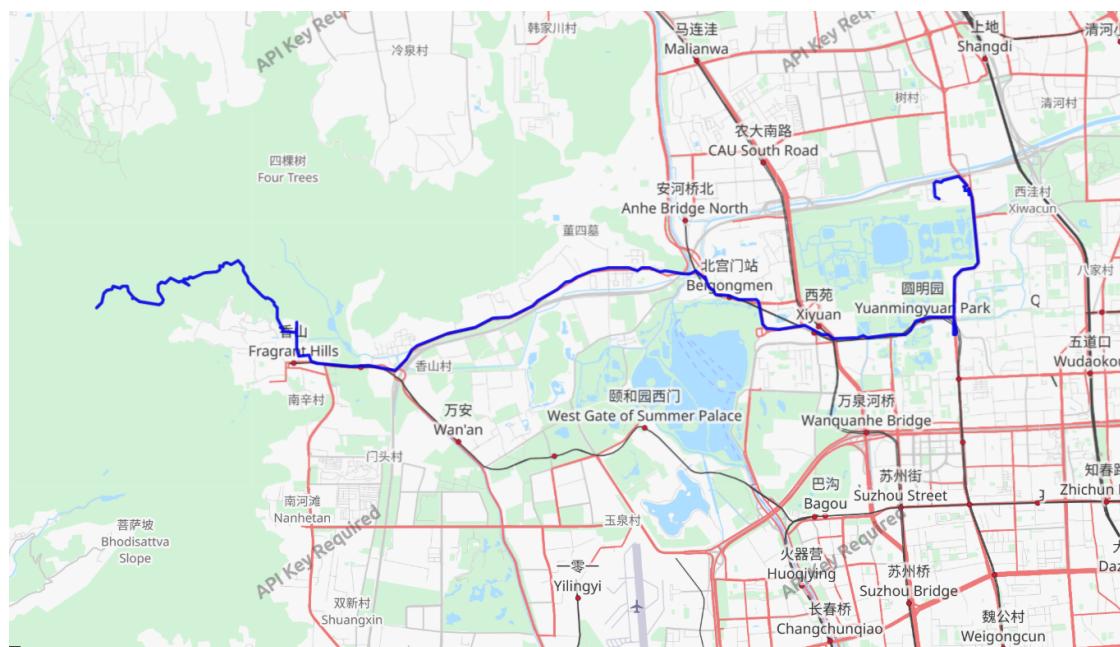
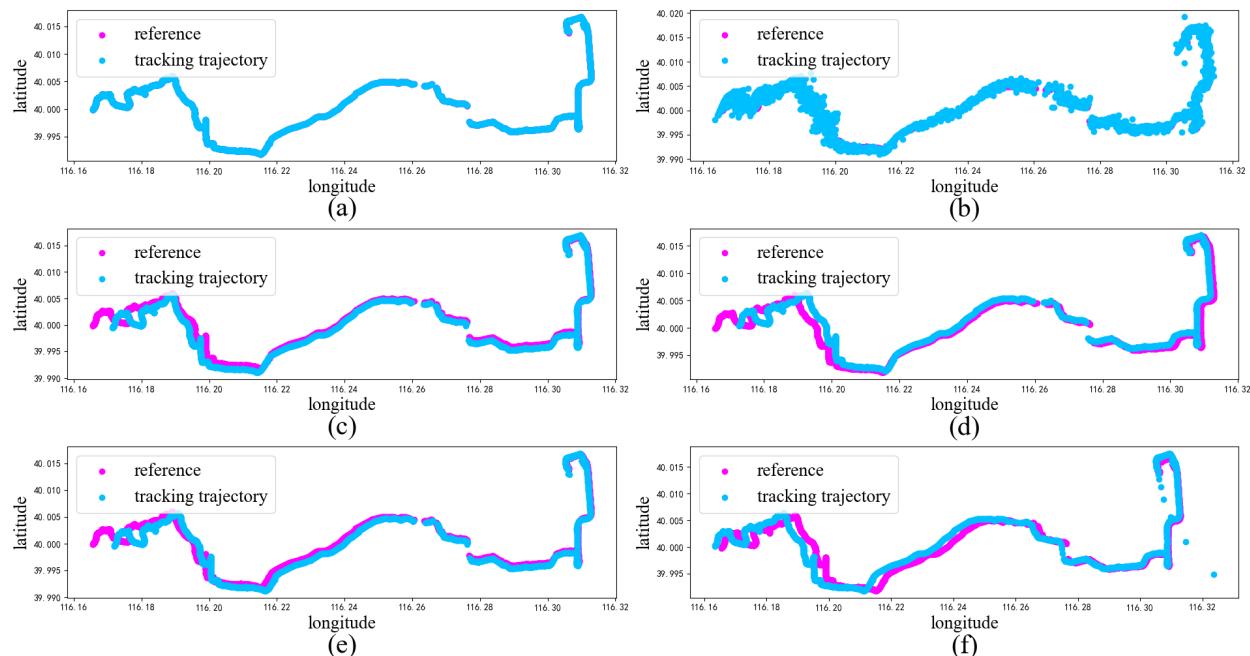


图 6. 估计模拟数据轨迹的结果实例

表 2. 各模型对北京车辆 GPS 运动轨迹数据的估计性能评价结果

Model	RMSE	MAE	SMAPE	R
LSTM[14]	3.84	3.97	3.75	0.99
GRU[42]	6.83	5.52	4.29	0.99
CNN-LSTM[43]	5.92	4.47	3.87	0.99
ConvLSTM[44]	5.76	4.69	3.15	0.99
PFVAE[45]	2.52	1.97	1.90	0.99
TL-EF	1.82	1.32	0.97	0.99

**图 7.** 不同模型估计的北京地区车辆 GPS 运动轨迹的比较。 (a) 使用 TL-EF 估计的轨迹, (b) 使用 PFVAE 估计的轨迹, (c) 使用 LSTM 估计的轨迹, (d) 使用 GRU 估计的轨迹, (e) 使用 CNN-LSTM 估计的轨迹, (f) 使用 ConvLSTM 的轨迹

型, 使其有效地应用于轨迹跟踪领域。该模型的提出对状态估计方法具有重要意义, 为进一步研究提供了可靠的技术支持。

4 结论

状态估计是一个重要的研究领域, 有许多应用, 从自主系统的导航和控制到国防系统的跟踪目标和环境监测。尽管有广泛的应用, 但状态估计仍面临许多挑战, 特别是在处理高度机动的目标或含有彩色噪声的复杂系统时。例如, 在特殊的 GPS 应用环境中, 用户终端收到的 GPS 导航信号要么由于高动态多普勒频移而过大, 要么由于遮挡、多径、闪烁等原因而过弱。因此, 迫切需要开发新颖有效的估计算法来应对这种挑战, 提高状态估计的准确性。

为了应对这一挑战, 本文提出了一种用于状态估计的自适应 Kalman 算法, 该算法利用了基于 Transformer 和 LSTM 的学习模块。通过将 Transformer 编码器结构与 LSTM 相结合, 设计了一个神经网络参数学习模块来学习离线状态下的测量数据, 以获得系统的运动特性, 而无需对系统动力学和测量特性进行建模。随后, 根据神

经网络参数学习模块的输出，利用 EM 算法获得适合估计 Kalman 滤波估计的模型参数，并利用 Kalman 滤波状态估计，适合参数化位置系统的精确状态估计。然而，该模型仍有一些局限性，如对于具有复杂非线性噪声的测量数据，可能会影响模型的性能。此外，该模型的计算复杂度也高于传统的 Kalman 滤波器，这限制了实时性能。

展望未来，未来的研究可以探索使用不同的深度学习网络或调整估计精度和计算复杂性之间的权衡，以进一步提高状态估计系统的实用性。通过解决这些挑战，我们可以为在一系列应用中开发和部署先进的状态估计系统开辟新的可能性。

参考文献

- [1] Baatar, G., Eichhorn, M., & Ament, C. (2014). Precise indoor localization of multiple mobile robots with adaptive sensor fusion using odometry and vision data. *IFAC Proceedings Volumes*, 47(3), 7182-7189. [CrossRef]
- [2] Wang, J., Wang, S., & Leng, W. (2021). Vision Positioning-Based Estimation Method and Its Simulation Studies on State of Underwater Manipulator. *Mathematical Problems in Engineering*, 2021(1), 6656928. [CrossRef]
- [3] Zhang, B., Lyu, M., Zhang, L., & Wu, Y. (2021). Artificial Intelligence-Based Joint Movement Estimation Method for Football Players in Sports Training. *Mobile Information Systems*, 2021(1), 9956482. [CrossRef]
- [4] Gao, J., Sun, C., Zhao, H., Shen, Y., Anguelov, D., Li, C., & Schmid, C. (2020). Vectornet: Encoding hd maps and agent dynamics from vectorized representation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11525-11533). [CrossRef]
- [5] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. [CrossRef]
- [6] Kalman, R. E., & Bucy, R. S. (1961). New results in linear filtering and prediction theory. [CrossRef]
- [7] Julier, S. J., Uhlmann, J. K., & Durrant-Whyte, H. F. (1995, June). A new approach for filtering nonlinear systems. In *Proceedings of 1995 American Control Conference-ACC'95* (Vol. 3, pp. 1628-1632). IEEE. [CrossRef]
- [8] Arasaratnam, I., & Haykin, S. (2011). Cubature kalman smoothers. *Automatica*, 47(10), 2245-2250. [CrossRef]
- [9] Gordon, N. J., Salmond, D. J., & Smith, A. F. (1993, April). Novel approach to nonlinear/non-Gaussian Bayesian state estimation. In *IEE proceedings F (radar and signal processing)* (Vol. 140, No. 2, pp. 107-113). IET Digital Library. [CrossRef]
- [10] Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society: series B (methodological)*, 39(1), 1-22. [CrossRef]
- [11] Shumway, R. H., & Stoffer, D. S. (1982). An approach to time series smoothing and forecasting using the EM algorithm. *Journal of time series analysis*, 3(4), 253-264. [CrossRef]
- [12] Ghahramani, Z., & Hinton, G. E. (1996). Parameter estimation for linear dynamical systems. [CrossRef]
- [13] Connor, J. T., Martin, R. D., & Atlas, L. E. (1994). Recurrent neural networks and robust time series prediction. *IEEE transactions on neural networks*, 5(2), 240-254. [CrossRef]
- [14] Choi, H. M., Kim, M. K., & Yang, H. (2021). Abnormally high water temperature prediction using LSTM deep learning model. *Journal of Intelligent & Fuzzy Systems*, 40(4), 8013-8020. [CrossRef]
- [15] Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*. [CrossRef]
- [16] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30. [CrossRef]
- [17] Tong, Y., Zheng, Z., Fan, W., & Liu, Z. (2022). Improved unscented Kalman filter for state of charge estimation of lithium-ion battery with one-step randomly measurement loss and inaccurate noise covariance matrices. *Digital*

- Signal Processing, 131, 103780. [[CrossRef](#)]
- [18] Greenberg, I., Yannay, N., & Mannor, S. (2021). Noise estimation is not optimal: How to use kalman filter the right way. arXiv preprint arXiv2104, 2372.
- [19] Sage, A. P., & Husa, G. W. (1969, November). Algorithms for sequential adaptive estimation of prior statistics. In 1969 IEEE Symposium on Adaptive Processes (8th) Decision and Control (pp. 61-61). IEEE. [[CrossRef](#)]
- [20] Tamura, K., Peterson, D., Peterson, N., Stecher, G., Nei, M., & Kumar, S. (2011). MEGA5: molecular evolutionary genetics analysis using maximum likelihood, evolutionary distance, and maximum parsimony methods. Molecular biology and evolution, 28(10), 2731-2739. [[CrossRef](#)]
- [21] Zia, A., Kirubarajan, T., Reilly, J. P., Yee, D., Punithakumar, K., & Shirani, S. (2008). An EM algorithm for nonlinear state estimation with model uncertainties. IEEE Transactions on Signal Processing, 56(3), 921-936. [[CrossRef](#)]
- [22] Menon, V., Yarahmadian, S., & Rezania, V. (2018). Novel EM based ML Kalman estimation framework for super-resolution of stochastic three-states microtubule signal. BMC Systems Biology, 12, 117-128. [[CrossRef](#)]
- [23] Wang, X., Song, B., Liang, Y., & Pan, Q. (2017). EM-based adaptive divided difference filter for nonlinear system with multiplicative parameter. International Journal of Robust and Nonlinear Control, 27(13), 2167-2197. [[CrossRef](#)]
- [24] Chen, C., Lu, X., Markham, A., & Trigoni, N. (2018, April). Ionet: Learning to cure the curse of drift in inertial odometry. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 32, No. 1). [[CrossRef](#)]
- [25] Kim, W. Y., Seo, H. I., & Seo, D. H. (2021). Nine-Axis IMU-based Extended inertial odometry neural network. Expert Systems with Applications, 178, 115075. [[CrossRef](#)]
- [26] Gao, R., Xiao, X., Zhu, S., Xing, W., Li, C., Liu, L., ... & Chai, H. (2021). Glow in the dark: Smartphone inertial odometry for vehicle tracking in GPS blocked environments. IEEE Internet of Things Journal, 8(16), 12955-12967. [[CrossRef](#)]
- [27] Akbari, H., Yuan, L., Qian, R., Chuang, W. H., Chang, S. F., Cui, Y., & Gong, B. (2021). Vatt: Transformers for multimodal self-supervised learning from raw video, audio and text. Advances in Neural Information Processing Systems, 34, 24206-24221. [[CrossRef](#)]
- [28] Liu, Y., He, G., Wang, Z., Li, W., & Huang, H. (2022). NRT-YOLO: Improved YOLOv5 based on nested residual transformer for tiny remote sensing object detection. Sensors, 22(13), 4953. [[CrossRef](#)]
- [29] Yunus, A. P., Shirai, N. C., Morita, K., & Wakabayashi, T. (2022, August). Comparison of RNN-LSTM and kalman filter based time series human motion prediction. In Journal of Physics: Conference Series (Vol. 2319, No. 1, p. 012034). IOP Publishing. [[CrossRef](#)]
- [30] Song, F., Li, Y., Cheng, W., Dong, L., Li, M., & Li, J. (2022). An Improved Kalman Filter Based on Long Short-Memory Recurrent Neural Network for Nonlinear Radar Target Tracking. Wireless Communications and Mobile Computing, 2022(1), 8280428. [[CrossRef](#)]
- [31] Liu, Y., Wang, X., Chen, L., Liu, S., Han, J., Shi, H., & Zhong, F. (2022). Driver' s visual attention characteristics and their emotional influencing mechanism under different cognitive tasks. International journal of environmental research and public health, 19(9), 5059. [[CrossRef](#)]
- [32] Zha, Y., Liu, X., Ma, F., & Liu, C. C. (2022). Vehicle state estimation based on extended Kalman filter and radial basis function neural networks. International Journal of Distributed Sensor Networks, 18(6), 15501329221102730. [[CrossRef](#)]
- [33] Arjas, A., Alles, E. J., Maneas, E., Arridge, S., Desjardins, A., Sillanpää, M. J., & Hauptmann, A. (2022). Neural network kalman filtering for 3-d object tracking from linear array ultrasound data. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 69(5), 1691-1702. [[CrossRef](#)]

- [34] Havangi, R. (2020). Intelligent adaptive unscented particle filter with application in target tracking. *Signal, Image and Video Processing*, 14(7), 1487-1495. [\[CrossRef\]](#)
- [35] Lichota, P. (2023). Wavelet transform-based aircraft system identification. *Journal of Guidance, Control, and Dynamics*, 46(2), 350-361. [\[CrossRef\]](#)
- [36] Goswami, D., & Paley, D. A. (2021). Non-gaussian estimation and dynamic output feedback using the gaussian mixture kalman filter. *Journal of Guidance, Control, and Dynamics*, 44(1), 15-24. [\[CrossRef\]](#)
- [37] Goff, G. M., Showalter, D., Black, J. T., & Beck, J. A. (2015). Parameter requirements for noncooperative satellite maneuver reconstruction using adaptive filters. *Journal of Guidance, Control, and Dynamics*, 38(3), 361-374. [\[CrossRef\]](#)
- [38] Wang, L., & Zhou, G. (2021). Pseudo-spectrum based track-before-detect for weak maneuvering targets in range-Doppler plane. *IEEE Transactions on Vehicular Technology*, 70(4), 3043-3058. [\[CrossRef\]](#)
- [39] Eltoukhy, M., Ahmad, M. O., & Swamy, M. N. S. (2020). An adaptive turn rate estimation for tracking a maneuvering target. *IEEE Access*, 8, 94176-94189. [\[CrossRef\]](#)
- [40] Ye, X., Zhang, O., Li, X., & Qiu, Y. (2019, February). Tracking algorithm for cruise missile based on IMM-singer model. In *AIP Conference Proceedings* (Vol. 2073, No. 1). AIP Publishing. [\[CrossRef\]](#)
- [41] Zhenkai, X., Fanying, L., & Lei, Z. (2018). Study on Maneuvering Target On-axis Tracking Algorithm of Modified Current Statistical Model. In *MATEC Web of Conferences* (Vol. 160, p. 02008). EDP Sciences. [\[CrossRef\]](#)
- [42] Ansari, M. S., Bartoš, V., & Lee, B. (2022). GRU-based deep learning approach for network intrusion alert prediction. *Future Generation Computer Systems*, 128, 235-247. [\[CrossRef\]](#)
- [43] Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., & Xu, Y. (2022). Forecasting monthly gas field production based on the CNN-LSTM model. *Energy*, 260, 124889. [\[CrossRef\]](#)
- [44] Huang, H., Zeng, Z., Yao, D., Pei, X., & Zhang, Y. (2021). Spatial-temporal ConvLSTM for vehicle driving intention prediction. *Tsinghua Science and Technology*, 27(3), 599-609. [\[CrossRef\]](#)
- [45] Jin, X. B., Gong, W. T., Kong, J. L., Bai, Y. T., & Su, T. L. (2022). PFVAE: a planar flow-based variational auto-encoder prediction model for time series data. *Mathematics*, 10(4), 610. [\[CrossRef\]](#)
- [46] Wang, N., Fang, F., & Feng, M. (2014, May). Multi-objective optimal analysis of comfort and energy management for intelligent buildings. In *The 26th Chinese control and decision conference (2014 CCDC)* (pp. 2783-2788). IEEE. [\[CrossRef\]](#)
- [47] Liu, J., Wang, Q., Song, Z., & Fang, F. (2021). Bottlenecks and countermeasures of high-penetration renewable energy development in China. *Engineering*, 7(11), 1611-1622. [\[CrossRef\]](#)
- [48] Zhang, J., Feng, J., Zhou, Y., Fang, F., & Yue, H. (2012). Linear active disturbance rejection control of waste heat recovery systems with organic Rankine cycles. *Energies*, 5(12), 5111-5125. [\[CrossRef\]](#)
- [49] Wei, L., & Fang, F. (2016). H_∞ -LQR-Based Coordinated Control for Large Coal-Fired Boiler-Turbine Generation Units. *IEEE Transactions on Industrial Electronics*, 64(6), 5212-5221. [\[CrossRef\]](#)
- [50] Wang, W., Liu, J., Zeng, D., Fang, F., & Niu, Y. (2020). Modeling and flexible load control of combined heat and power units. *Applied Thermal Engineering*, 166, 114624. [\[CrossRef\]](#)
- [51] Liu, J., Song, D., Li, Q., Yang, J., Hu, Y., Fang, F., & Joo, Y. H. (2023). Life cycle cost modelling and economic analysis of wind power: A state of art review. *Energy Conversion and Management*, 277, 116628. [\[CrossRef\]](#)
- [52] Liu, J., Zeng, D., Tian, L., Gao, M., Wang, W., Niu, Y., & Fang, F. (2015). Control strategy for operating flexibility of coal-fired power plants in alternate electrical power systems. *Proceedings of the CSEE*, 35(21), 5385-5394.
- [53] Fang, F., & Xiong, Y. (2014). Event-driven-based water level control for nuclear steam generators. *IEEE Transactions on Industrial electronics*, 61(10), 5480-5489. [\[CrossRef\]](#)

- [54] Fang, F. A. N. G., Tan, W., & Liu, J. Z. (2005). Tuning of coordinated controllers for boiler-turbine units. *Acta Automatica Sinica*, 31(2), 291-296.
- [55] Liu, Y., Fang, F., & Park, J. H. (2018). Decentralized dissipative filtering for delayed nonlinear interconnected systems based on T-S fuzzy model. *IEEE Transactions on Fuzzy Systems*, 27(4), 790-801. [CrossRef]
- [56] Lv, Y., Fang, F. A. N. G., Yang, T., & Romero, C. E. (2020). An early fault detection method for induced draft fans based on MSET with informative memory matrix selection. *ISA transactions*, 102, 325-334. [CrossRef]
- [57] Fang, F., Zhu, Z., Jin, S., & Hu, S. (2020). Two-layer game theoretic microgrid capacity optimization considering uncertainty of renewable energy. *IEEE Systems Journal*, 15(3), 4260-4271. [CrossRef]
- [58] Fang, F., Jizhen, L., & Wen, T. (2004). Nonlinear internal model control for the boiler-turbine coordinate systems of power unit. *PROCEEDINGS-CHINESE SOCIETY OF ELECTRICAL ENGINEERING*, 24(4), 195-199.
- [59] Zhang, X., Fang, F., & Liu, J. (2019). Weather-classification-MARS-based photovoltaic power forecasting for energy imbalance market. *IEEE Transactions on Industrial Electronics*, 66(11), 8692-8702. [CrossRef]
- [60] Lv, Y., Lv, X., Fang, F., Yang, T., & Romero, C. E. (2020). Adaptive selective catalytic reduction model development using typical operating data in coal-fired power plants. *Energy*, 192, 116589. [CrossRef]
- [61] Fang, F., & Wu, X. (2020). A win-win mode: The complementary and coexistence of 5G networks and edge computing. *IEEE Internet of Things Journal*, 8(6), 3983-4003. [CrossRef]



陈伟 2024 年毕业于北京工商大学控制工程专业，获硕士学位。研究方向为模式识别与信息融合、无人车、机器学习等。

Wei Chen, graduated from Beijing University of Technology and Business in 2024 with a master's degree in Control engineering. His research focuses on pattern recognition and information fusion, unmanned vehicles, machine learning, and other related fields.

Changchun, China, in 1994 and 1997, and the Ph.D. degree in control theory and control engineering from the University of Zhejiang, Zhejiang, China, in 2004. She was a Senior Visiting Scholar with the University of Illinois at Chicago, Chicago, IL, USA, in 2007. From 2009 to 2012, she was an Assistant Professor with Zhejiang Sci-tech University. Since 2012, she has been a Professor with Beijing Technology and Business University, Beijing, China. Her research includes a variety of areas in information fusion, big data analysis, condition estimation, and video tracking.



金学波 教授，博士生导师。1994 年毕业于吉林大学（原吉林工业大学）获学士学位，1997 年毕业于吉林大学（原吉林工业大学）获硕士学位，2004 年获得浙江大学控制科学与工程博士学位，导师为孙优贤院士。研究方向为信息融合、模式识别与预测、大数据分析、深度学习等。近年来在相关领域主持了 1 项国家科技支撑计划课题、4 项国家自然基金面上项目等多项研究课题。获 2021 年度中国粮油学会科学技术奖一等奖。在时序信号模式识别、图像目标检测与识别等研究领域，已发表 SCI、EI 收录等高水平学术论文 159 篇，其中 7 篇为 ESI 高被引论文（前 1%）、3 篇 ESI 热点论文（前 0.1%），已授权国家发明专利 20 余项，出版关于传感器信号识别与状态估计、多传感器信息融合的学术专著 3 部。担任 SCI 收录期刊 Sensors 编委，为 IEEE/CAA Journal of Automatica Sinica、Knowledge-Based Systems 等中科院一区 SCI 期刊审稿人。

Xuebo Jin (Fellow, ASP) received the B.S. and M.S. degrees in control theory and control engineering from Jilin University,



马慧鋆 2010 年毕业于长春光机学院原子与分子物理专业，获硕士学位，目前为北京工商大学系统科学专业在职博士生。研究方向为复杂系统建模、模式识别与信息融合、机器学习等。

Huijun Ma graduated from Changchun Institute of Optics and Mechanics with a master's degree in atomic and molecular physics in 2010. She is currently an on-the-job doctoral student in systems science at Beijing Technology and Business University. Research directions include complex system modeling, pattern recognition and information fusion, machine learning, etc.



曹欣然 就读于厦门大学航空航天学院，研究方向为人工智能、电子信息等。

Xinran Cao is studying at the School of Aeronautics and Astronautics of Xiamen Uni-

versity, and his research interests include artificial intelligence and electronic information.