



# 基于 GPS 的堆叠串行 LSTM 组合神经网络目标跟踪方法

金学波<sup>1,\*</sup>, 刘嵩政<sup>1</sup>

<sup>1</sup>北京工商大学, 计算机与人工智能学院, 北京 100048

学术编辑: 张伟民; 收稿日期: 2024-01-15; 录用日期: 2024-04-09; 发布日期: 2024-04-18

\*通讯作者: 金学波, [jinxuebo@btbu.edu.cn](mailto:jinxuebo@btbu.edu.cn)

## 文章引用

金学波, 刘嵩政. 基于 GPS 的堆叠串行 LSTM 组合神经网络目标跟踪方法. 人工智能前沿与应用, 2024, 1(1): 16–31.

## Citation

Jin, X., & Liu, S. (2024). Target Tracking Method Based on Stacked Serial LSTM Combinatorial Neural Network for GPS. *Frontiers and Applications of Artificial Intelligence*, 1(1), 16–31.

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

## 摘要

机动目标轨迹估计广泛应用于无人驾驶、拦截导弹等领域。由于机动目标的运动特性的不确定性、传感器精度低的问题, 轨迹估计一直是一个开放研究问题和一项有挑战性的工作。本文提出了目标运动特性不确情况下, 一种基于深度 LSTM 神经网络的轨迹估计方法。该网络有两个具有堆叠串行关系的 LSTM 网络组成, 其中一个 LSTM 网络用于预测运动状态, 另一个网络用于更新状态。与经典的基于机动模型的 Kalman 滤波器相比, 本文的方法基于网络学习、无需对运动特性和传感器特性进行建模。实验结果表明, 该方法可以在目标运动具有未知和不确定性的情况下, 有效提升轨迹的估计性能。

关键词: 轨迹估计, 循环神经网络, GPS, 滤波算法, LSTM, 堆叠串行结构

## Target Tracking Method Based on Stacked Serial LSTM Combinatorial Neural Network for GPS

Xuebo Jin<sup>1,\*</sup> and Songzheng Liu<sup>1</sup>

<sup>1</sup>School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

Academic Editor: Weimin Zhang; Submitted: 2024-01-15; Accepted: 2024-04-09; Published: 2024-04-18

\*Correspondence Author: Xuebo Jin, [jinxuebo@btbu.edu.cn](mailto:jinxuebo@btbu.edu.cn)

## Abstract

Maneuvering target tracking is widely used in unmanned vehicles, missile navigation, underwater ships, etc. Due to the uncertainty of the moving characteristics of maneuvering targets and the low sensor measurement accuracy, trajectory tracking has always been an open research problem and challenging work. This paper proposes a trajectory estimation method based on LSTM neural network for uncertain motion characteristics. The network consists of two LSTM networks with stacked serial relationships, one of which is used to predict the movement dynamics, and the other is used to update the track's state. Compared with the classical Kalman filter based on the maneuver model, the method proposed here does not need to model the motion characteristics and sensor characteristics. It can achieve high-performance tracking by learning historical data dynamics and sensor characteristics. Experimental results show that this method can effectively improve the trajectory estimation performance when the target motion is unknown and uncertain.

**Keywords:** Trajectory estimation, cyclic neural network, GPS, filtering algorithm, LSTM, stacked serial structure

## 1 序言

全球定位系统 (Global Positioning System, GPS) 是人造地球卫星为基础的高精度无线电导航的定位系统, 可以为运动目标提供实时位置和速度信息 [1]。然而 GPS 信号容易受到影响, 当运动目标所在位置信号强度不够或在遮蔽物下, 天气等因素也会干扰 GPS 信号。因此, GPS 测量值是带有不确定性和噪声。

在目标跟踪过程中, 基于带噪声测量中估计出真实的目标轨迹的方法主要是 Kalman 滤波器系列。经典的滤波方法包括卡尔曼滤波 (KF)[3]、扩展卡尔曼滤波 (EKF)[4]、无迹卡尔曼滤波 (UKF)[5-7]、容积卡尔曼滤波 (CKF)[8,9]、粒子滤波 (PF)[10] 等算法。其中卡尔曼滤波是离散状态空间模型下的线性最小方差估计, 系统的动态方程和量测方程都是线性高斯的; 在实际应用中, 动态过程和量测过程通常都是非线性的, 不能直接使用卡尔曼滤波, 一般使用扩展卡尔曼滤波、无迹卡尔曼滤波和容积卡尔曼滤波等。

运动目标在实际运动过程中会做运动模式变换, 使用准确的模型进行状态估计, 对机动目标的跟踪性能尤为关键。为了实现对机动目标的准确跟踪, 首要的是建立与目标运动真实状态相匹配的运动模型。目前的跟踪算法主要包括单模型 (Single Model, SM) 和多模型 (Multiple Model, MM) 算法。单模型算法包括匀速运动模型 (Constant Velocity, CV) [11]、匀加速运动模型 (Constant Acceleration, CA) [12]、Singer 模型 [13] 和“当前”统计 (Current Statistical, CS) 模型 [14] 等。CV 模型和 CA 模型分别将机动目标的加速度和加速度的导数视为零均值高斯噪声, 不能对目标的机动进行良好描述。Singer 模型将机动目标的加速度建模为指数自相关零均值有色噪声, 其零均值的假设对于真实情况下的机动目标运动状态的描述是不合理的。CS 模型在 Singer 模型的基础改进了自适应非零均值加速度, 并根据其均值的变化描述机动加速度的统计分布特性, 但由于其需要预先设置机动频率和加速度极限值, 不合理的设置将造成目标跟踪误差加大的情况。而且单模型算法中仅用一个模型来表示系统的运动模式, 因此只适用于目标运动形式单一、机动性不强的系统。随着目标机动性能的提升, 目标的复杂运动使得单一模型很难进行精确的描述, 为此多模型算法在很多领域得到了应用。多模型算法使用多个模型来覆盖目标的主要运动模式, 每个模型匹配一种运动模型, 将所有模型的输出按照不同的权重组合为目标的最终状态估计。交互式多模型 (Interacting Multiple Model, IMM) 算法 [15] 和自适应交互式多模型 (Adaptive Interacting Multiple Model, AIMM) 算法 [16] 等都是多模型算法的经典方法, 被广泛应用于智能制造和工业领域 [38-47]。

然而，多模型算法包含更多模型，会降低性能并增加计算量。

经典的卡尔曼滤波算法通过对运动特征就行动力学建模 [48-51]，引入观测数据对估计结果进行校正来提高跟踪精度。但是该类方法对模型的过度依赖成为其最大的缺陷。然而，由于机动目标运动的复杂性，使得准确建模非常具有挑战性。近年来，随着神经网络的发展 [52-61]，在图像识别、时序预测和自然语言处理等领域取得重大进展。与传统的基于模型的方法 [62-68] 不同，神经网络可以从大量的数据中学习数据中的重要特征。Chen 等人提出来的 IONet[17]，该方法预测行人在室内轨迹，模型的输入 IMU 和 GPS 数据，经过多层卷积神经网络 (CNN)，输出行人的极坐标。在图像识别方面，Bing Wang 等人提出的 AtLoc[18]，通过注意力机制让网络专注于具有几何鲁棒性的对象和特征，单个图像作为输入，该网络可以拒绝动态对象，从而提高运动目标姿态回归性能。

近年来，通过神经网络预测运动目标 GPS 的位置信息有很大的进展 [19-21]，这些基于神经网络的方法可以从高维原始数据中提取有用的信息，以端对端方法估计运动目标的位置，虽然这些模型在准确性和鲁棒性都有良好的性能，但是预测过程类似于“黑箱”，缺少解释性，而且不像卡尔曼算法可以做到一步预测和滚动优化。对于神经网络，给定测量值的真实值在轨迹估计中很重要，选择适当的神经网络能够处理运动目标的不确定性和噪声带来的影响。我们可以把运动目标的位置信息看作时序问题，在时序预测方面，循环神经网络 (RNN) 相比较其他网络性能较好，但 RNN 由于结构简单，随着时间的增加，RNN 会产生梯度消失或梯度爆炸，RNN 在处理运动目标不确定性的性能较差。LSTM 相比于 RNN 多了遗忘门，可以有效解决 RNN 的梯度消失和梯度爆炸的问题，还具有长时记忆功能。因此，本文提出一种基于 LSTM 的结构，它在时序数据中提取有效信息的性能优于其他方法，从测量值中估计轨迹的精度较高。本文主要的创新点如下：

1. 设计了堆叠 LSTM 结构，与卡尔曼算法相比，不需要对运动目标进行建模；与经典的神经网络相比，预测过程具有解释性。
2. 利用变分方法，修改经典的 LSTM 权重训练方式，让所提出来的网络能够适应 GPS 的有色粉红噪声，进一步提高跟踪性能。

## 2 相关工作

目前对于运动目标跟踪的研究，通过卡尔曼滤波器或改进的卡尔曼滤波器得出预测结果。Yiou Sun[22] 等人提出一种基于容积卡尔曼滤波器和 Sage-Husa 估计器的自适应卡尔曼滤波器。该算法在容积卡尔曼滤波算法中引入了 Sage-Husa 估计器，可以实时估计未知系统的统计参数和观测噪声，避免算法发散。该算法还可以降低未知噪声引起的跟踪误差，有效提高精度和数值稳定性。Nader Nagui[23] 等设计一种级联形式的扩展卡尔曼滤波器—线性卡尔曼滤波器，将 GPS 与 INS 耦合，GPS 原始数据与来自惯性测量单元读数的带噪欧拉角融合，以产生更一致和准确的实时位置信息。孙一欧 [24] 等人提出一种新的非线性卡尔曼滤波器算进行机动目标跟踪，边缘化卡尔曼滤波 (MKF) 算法将系统的非线性测量方程表示为 Hermite 多项式的加权和，然后将加权矩阵的先验分布建模为高斯过程。之后，计算加权矩阵的后验分布，并通过计算其积分去除加权矩阵的影响。因此，系统状态的封闭形式及其协方差是可用的。为了提高 MKF 算法的稳定性，通过在 MKF 算法中使用衰落因子，引入了 Strong Tracking Filter 的概念，它可以减少先前过滤步骤对当前步骤的影响。Yulong Huang[25] 等提出一种新的基于变分贝叶斯的自适应卡尔曼滤波器，通过选择逆 Wishart 先验矩阵，基于变分贝叶斯方法推断状态、预测误差和测量噪声协方差矩阵，该结构有更好的鲁棒性，能够抵抗过程和测量噪声协方差。上述基于滤波方法的研究一定程度上能够提升卡尔曼滤波器对非线性和非高斯白噪声的滤波效果，但是模型可能会根据目标的突然机动模型而失配，这种情况会导致滤波器发散。

近年来，随着深度学习的不断发展，一些研究结合深度学习提出新的目标跟踪方法，深度学习方法是目前应用

广泛的建模方法,包括循环神经网络 (Recurrent Neural Network, RNN)、编码器-解码器等多种结构,该方法结合海量训练数据和计算机的大规模运算能力优化模型内部参数,能够对复杂非线性数据进行拟合,在多个领域有广泛的应用 [26-28]。Jia 等 [29] 提出 DeepMTT 网络,主要使用双向 LSTM 搭建。通过使用自建的海量离线轨迹数据对模型进行预训练,可实现对机动目标的跟踪。张静等 [30] 设计一种结合长短期记忆 (LSTM) 的轨迹跟踪模型,将 LSTM 网络模型与 Unscented Kalman Filter (UKF) 相结合,利用 LSTM 网络的自主学习和记忆特性,为 UKF 算法提供观测值的预测值,仿真结果表明, LSTM-UKF 算法模型具有良好的跟踪效果。李思伟等 [31] 提出一种基于 LSTM 的轨迹识别方法和一种匹配 CS(current statistics) 模型参数的机动跟踪方法。该方法利用 LSTM 可以有效结合上述信息的特点,实现对目标运动状态的识别。然后通过聚类分析得到传统意义上各运动模式的最优滤波参数,并根据 LSTM 的识别结果进行滤波,与传统的机动跟踪模型相比,该方法可以在机动过程中保持稳定的滤波增益。崔亚奇等 [32] 在传统的神经网络架构中设计了一种新的滤波器,并专门使用前馈神经网络、递归神经网络和注意力机制构建。Vedula 等 [33] 将自编码器与 IMM 进行结合,使用自编码器对测量值执行非线性变换,帮助 IMM 更快地识别模式变化。在机动目标跟踪场景中验证了模型相较经典跟踪技术及 LSTM 深度学习模型的优越性。Giuliani 等 [34] 建立基于 Transformer 模型的运动轨迹跟踪模型。Transformer[35] 结合了编解码器和注意力机制,模型在 TrajNet 等多个轨迹预测基准上验证了性能。

James JQ[36] 等提出一种基于离散小波变换和深度学习技术最新发展的新型出行方式识别机制,所提出的机制皆在采用任意长度的 GPS 轨迹,可以准确识别出运动模式,采用离散小波变换进一步提出轨迹的时频特征,辅助神经网络分类和预测。刘嘉庚 [37] 等提出一种高斯混合模型和 Kullback-Leibler 的具有多个长短期记忆模块的深度学习框架来预测车辆位置的信息,将 IEKF 和多个 LSTM 组合在一起,以在多变的城市环境中 GPS 中断期间优化车辆定位精度。这些模型的应用使得跟踪性能提到了提升,证明了使用深度学习数据驱动的方法用于目标跟踪的可行性和有效性。目前这些方法都是直接使用深度的神经网络进行学习,将测量数据和参考待估计状态分别作为输入和输出网络,直接通过网络训练得到期望的状态输出。根据以上分析,本文结合深度学习的方法提出了基于贝叶斯思想的堆叠串行 LSTM 网络估计模型。该方法将传统滤波器的一步预测和滚动预测等优点与神经网络相结合,建立端对端的 GPS 位置估计,该方法可以充分提取运动数据的动力学特征,从而对有色噪声进行可靠建模,提升深度学习模型对复杂机动特性的精度。

### 3 堆叠 LSTM 跟踪模型

#### 3.1 贝叶斯估计与 Kalman 滤波器

轨迹估计本质是根据传感器测量值估计运动目标状态。在传统的基于模型估计方法中,假设运动目标和相应的测量值具有足够精度的已知数学模型表示,通常如下公式 (1) 表示:

$$X_{t+1} = f(X_t) + w_t \quad (1)$$

$X_t$  是运动目标第  $t$  个时间步的状态向量,  $w_t$  是过程噪声,  $f()$  为假设模型的状态转移函数。假设测量值依赖于模型,并通过以下公式 (2) 与真实相关:

$$Z_t = h_t(X_t) + q_t \quad (2)$$

$w_t$  是传感器的测量值,  $h_t$  是传感器确定的测量函数,  $q_t$  是传感器的测量噪声。

在目标运动过程中,利用实际运动目标的轨迹(状态方程)和传感器观测到的实际信息(观测方程)来估计目标的位置。在实际中,无论是状态还是观测都不可避免噪声,仅靠状态方程或观测方程来估计运动目标的轨迹,

随着时间得推移，估计的轨迹与运动目标的实际轨迹的误差会越来越大，贝叶斯滤波可以减小运动目标轨迹估计的不确定性。

运动目标的运动过程可以看作为随机过程，贝叶斯滤波通过带有噪声的前  $k$  个观测值  $y$  来估计隐状态的概率，即后验概率分布，贝叶斯滤波网络如图 1 所示：

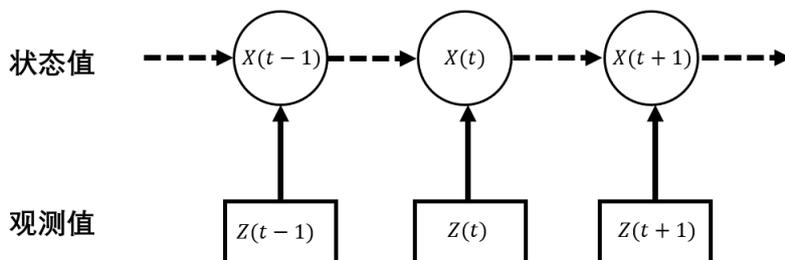


图 1. Bayesian filter networks

假设  $Z_t = (Z_1, Z_2, \dots, Z_t)$  为测量序列。轨迹估计的目标是确定计算  $p(X_t | Z_{t-1})$  和  $p(X_t | Z_t)$ ，分别对应的是预测过程和滤波过程，贝叶斯滤波中预测的公式 (3) 为：

$$p(X_t | Z_{1:t-1}) = \int p(X_t | Z_{t-1}) p(X_{t-1} | X_{1:t-1}) dX_{t-1} \tag{3}$$

预测的结果反应的是时间  $t$  测量之前状态的后验,滤波使用的是预测得到的后验概率  $p(X_t | Z_{1:t-1})$  计算  $p(X_t | Z_{1:t})$ ，滤波的公式 (4) 为：

$$p(X_t | Z_{1:t}) = \eta p(Z_t | X_t) p(X_t | Z_{1:t-1}) \tag{4}$$

其中,  $\eta$  为  $p(Z_t | X_t) p(X_t | Z_{1:t-1})$  归一化变量。运动目标的不确定性给轨迹估计带来了挑战，因为无法获得准确的动力学模型。

贝叶斯估计的实质是用已知的信息用系统的预测模型预测状态的先验概率密度，再用最新的观测数据进行修正，得到后验概率密度，卡尔曼滤波器是基于贝叶斯滤波的思想得到的一种算法。

卡尔曼滤波器是最优自回归数据处理算法，对于很多问题，卡尔曼滤波器都可以得到最优的估计结果。假设有线性离散系统的过程及测量模型如下公式 (5)：

$$\begin{aligned} X_{t+1} &= AX_t + w(t) \\ Z_t &= CX_t + v(t) \end{aligned} \tag{5}$$

其中， $X(k)$  是待估计量， $Z(k)$  是通过传感器得到的测量数据。公式 (7) 为该系统的过程模型，指的是系统中待估计状态随时间变化的规律， $A(k)$  为过程矩阵，前一时刻状态  $X(k)$ ，下一时刻状态即  $k + 1$  时刻会变成  $X(k + 1)$ ， $w(k)$  为过程噪声，表示  $X(k)$  到  $X(k + 1)$  过程中的不确定程度。 $Z(k)$  称为测量模型， $C(k)$  为测量矩阵， $v(k)$  为测量噪声。

卡尔曼滤波过程如下公式 (6)-(12)：

$$\hat{X}_{t|t-1} = A\hat{X}_{t-1|t-1} \tag{6}$$

$$\hat{X}_{t|t} = \hat{X}_{t|t-1} + K[Z_t - C\hat{X}_{t|t-1}] \tag{7}$$

$$K(t) = P_{t|t-1} C^T [C^T P_{t|t-1} C + R]^{-1} \quad (8)$$

$$P_{t|t-1} = A P_{t-1|t-1} A^T + Q \quad (9)$$

$$P_{t|t} = [I - KC] P_{t|t-1} \quad (10)$$

其中, 公式 (6) 为预测方程, 公式 (7) 为更新方程, 公式 (8) 为滤波增益方程, 为卡尔曼增益参数; 公式 (9) 为向前一步预测方程, 为的估计方差; 公式 (10) 为状态估计方程。公式 (6) 对应贝叶斯滤波公式 (3), 为预测方程; 公式 (7) 对应贝叶斯滤波公式 (4), 为更新方程。

在对运动目标估计的时候, 为了提高估计的精度, 首先根据运动目标的运动模式进行建模, 比如匀速运动、匀加速运动等, 但是在实际的运动中, 目标的运动模式都不是固定的, 对目标建模困难, 该方法不适用与实际的运动过程。但是经典滤波器的优点之一是一步预测, 充分利用数据, 并不断优化参数。

卡尔曼滤波是一种利用线性系统状态方程, 它最大的局限性是仅能对过程模型和测量模型进行精确的估计, 在实际中, 真正严格的线性方程几乎不存在, 几乎所有的系统都是非线性的。另一方面, 传统的机动模型, 例如, CV 模型、CA 模型、Singer 模型等, 主要针对机动特性进行先验假设, 由于先验知识的缺乏, 这些基于假设的模型一般很难得到较好的估计结果。

### 3.2 深度网络估计模型

神经网络具有很强的鲁棒性和容错性, 不仅可以自学习、自组织、自适应性, 使得网络处理不确定的系统, 还可以充分逼近任意复杂的非线性关系。因此本文选择神经网络代替传统的更新预测步骤。本文的方法与贝叶斯滤波和 kalman 滤波中一步预测, 一步更新的思想是相同的。该网络方法命名为堆叠长短期神经网络 (stack Long short-term Memory, SLSTM), 该网络结构如图 2 所示, 该网络由两个模块组成, 分别为预测模块和更新模块。输入为连续测量的轨迹信息, 通过网络的预测模块和更新模块, 输出估计的轨迹信息。SLSTM 的计算公式 (11) 如下:

$$\begin{aligned} C_{t-1}^p, h_{t-1}^p &= f_h^p(C_{t-1}, h_{t-1}, Z_{t-1}) \\ \hat{X}_{pre}^{(t|t-1)} &= f_o^p(h_{t-1}^p) \\ C_t, h_t &= f_h^f(C_{t-1}^p, h_{t-1}^p, \hat{X}_{pre}^{(t|t-1)}) \\ \hat{X}_{fil}^{(t)} &= f_o^f(h_t) \end{aligned} \quad (11)$$

其中  $\hat{X}_{pre}^{(t|t-1)}$  是时间  $t-1$  时刻所有到  $t-1$  测量值的预测值,  $\hat{X}_{fil}^{(t)}$  对应的是  $t$  时刻对应的更新值。  $f_h^p$  和  $f_h^f$  分别对应的是预测过程和更新过程的函数, 输入测量值  $Z_{t-1}$  进入滤波部分得到细胞状态  $C_{t-1}^p$  和滤波隐藏状态  $h_{t-1}^p$ , 隐藏状态作为输入进入更新部分, 得到更新后的状态,  $\hat{X}_{t-1|t-1}$  将预测后的状态作为输入给更新部分, 估计出  $t$  时刻的目标位置。

该网络第一部分为预测部分, 利用 LSTM 对输入数据  $Z(t-1)$  进行一步预测, 将预测的值  $X(t-1|t-1)$  作为输入到第二部分 LSTM 进行更新, 得到一步估计的值  $X(t|t-1)$ 。该网络的算法第一步与贝叶斯滤波公式 (3) 和卡尔曼滤波器公式 (6) 均为预测方程, 该网络算法第二步与贝叶斯滤波公式 (4) 和卡尔曼滤波器公式 (7) 均为更新方程, 因此此方法与贝叶斯滤波和卡尔曼算法的预测方程和更新方程的思想是一样的。

### 3.3 基于贝叶斯变分的训练方法

由于代价函数是非凸函数, 并且整个训练数据集的梯度计算量是非常大的, 因此使用基于贝叶斯变分的训练方法来训练网络以获得参数。图 3 展示了 SLSTM 网络的训练结构。LSTM 需要大量的数据来避免过拟合。对输入的数据做最大最小归一化处理, 把数据映射到 0 1 范围之内处理, 加快训练网络的收敛性。

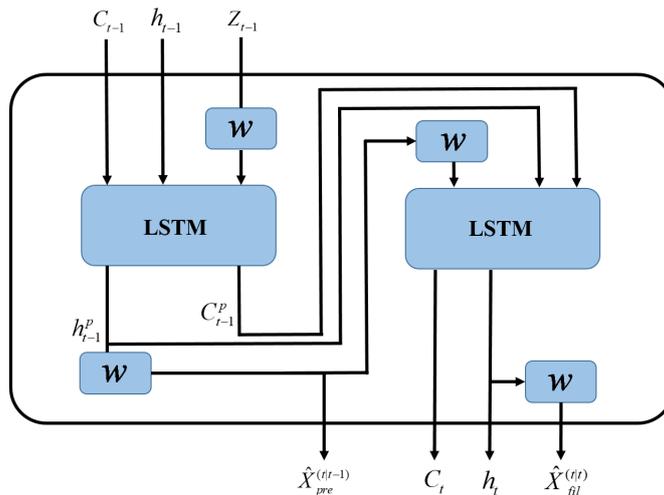


图 2. SLSTM 结构

在训练网络的时候减少神经网络过拟合的一种方法是使用 dropout，该方法为正则化方法，在每一个的进程中，通过设定某个概率暂时丢弃一部分隐藏层神经元来简化网络，从而达到防止过拟合的目的，还可以提高网络的泛化能力。经过多次实验当 dropout 设置为 0.2 时该网络的效果最好。

经过网络的训练后，将网络输出的结果进行反归一化操作，得到模型的输出值，通过代价函数对网络中的参数优化。代价函数是非凸的，并且整个训练数据集的计算量非常大，因此使用最小梯度下降算法训练网络以获得参数，该网络的成本函数为公式 (12)：

$$J(\theta) = \frac{1}{N} \sum_{t=1}^N [(x_{fil}^{(t)} - \hat{x}_{fil}^{(t)})^2 + \epsilon(x_{pre}^{(t|t-1)} - \hat{x}_{pre}^{(t|t-1)})^2] \quad (12)$$

上标  $n$  表示训练数据集中的第  $n$  个序列，该序列总共包括  $n$  个序列， $L_n$  是其长度，加权系数  $\epsilon$  是超参数，用于平衡滤波或估计的误差。如果传感器的精度更高，可以设置为大于 1 的值。

**Algorithm 1** 堆叠 LSTM 网络优化过程

1. 输入 GPS 信息，对每一条轨迹信息做最大最小归一化数据预处理，设置网络的参数，dropout=0.2, hidden\_dim=32。
2. 给定每个 batch 共  $m$  个样本：  $D(Z_t - 1, X)$ ，其中  $Z$  表示网络输入数据， $x_{fil}^{(t)}$  表示网络的期望输出，网络输出为  $x_{fil}^{(t)}$ 。
3. 使用变分推断对网络权重和偏置进行  $n$  次采样，并计算平均损失：

$$J(\theta) = \frac{1}{N} \sum_{t=1}^N [(x_{fil}^{(t)} - \hat{x}_{fil}^{(t)})^2 + \epsilon(x_{pre}^{(t|t-1)} - \hat{x}_{pre}^{(t|t-1)})^2]$$

4. 根据 Loss 使用 Adam 优化器，更新权重和参数： $\theta$ 。
5. 重复第二步至第四步直到网络收敛，即 Loss 不再下降。
6. 使用测试集评估训练好的网络模型。

我们的网络成本由两部分组成，一部分是通过 SLSTM 从输入序列计算出来的结果，一部分是 GPS 真实值。我们的目标是学习一个能估计接近真实轨迹的真实轨迹网络，为此，我们最小化了滤波状态和预测状态以及真实

状态之间的均方误差。训练 SLSTM 以获取其参数的流程图如图 3 所示。为此，代价函数是非凸的，我们采用梯度下降算法来优化 SLSTM 的参数，即。为了克服在计算梯度时由大型训练数据集引起的计算大的问题，只需向网络输入一小批训练样本来更新每个时间步长的参数。在对整个训练数据集迭代一段时间直到代价函数收敛后，获得 SLSTM 的参数。此外，可以通过随机启动参数来执行优化，以避免局部极小值，并以更高的概率找到全局极小值。该网络是一步预测，充分利用 GPS 数据，通过网络训练出来预测值，与真实值计算成本函数，并不断优化参数  $\theta$ 。

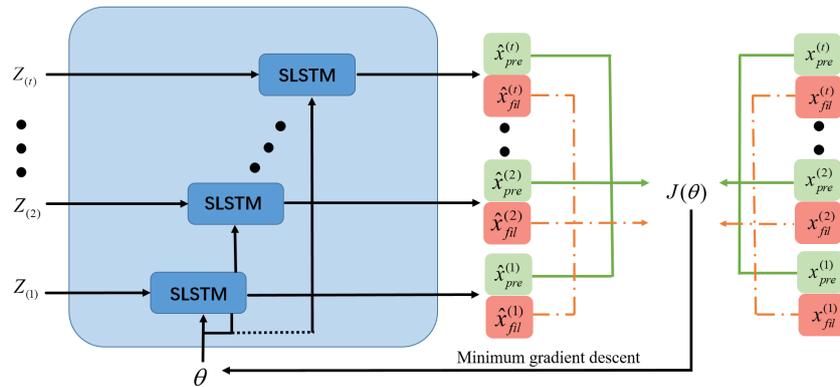


图 3. SLSTM 训练

## 4 实验

### 4.1 数据集

在本文中，我们的数据集是通过仿真运动模式不确定目标的轨迹数据，每条轨迹加粉红噪声作为传感器的测量值，共包含 4200 条轨迹，每条轨迹包含 201 个点的位置信息，每个位置信息都有 x 和 y 的坐标值，x 和 y 的坐标值为解耦数据我们将该数据 80% 的数据作为模型的训练集，20% 的数据作为测试集。

### 4.2 实验流程及评价指标

设计如下实验对本文所提模型的性能进行验证。

与经典目标跟踪算法的性能对比。本文所提模型主要应用于目标轨迹估计，尝试采用数据驱动的方法对机动目标的运动数据进行拟合。而目前应用广泛的是经典目标跟踪算法，例如 CV、Singer 模型等。因此，第一个实验将本文所提模型与 CV、CA、Singer、当前统计模型和自适应模型共五种经典模型进行对比，验证模型对含有色噪声的运动数据的拟合效果。

我们基于开源 Pytorch 深度学习框架构建深度学习模型，所有实验均在 CPU:AMD Ryzen 7 5800H CPU 的 PC 上运行在多次实验结果，选择最优的超参数，在滤波部分，我们使用一层 LSTM，其隐含的神经元个数为 32；在预测部分，我们使用一层 LSTM，其隐藏神经元个数为 32；该深度学习模型使用 Adam 优化算法进行优化，优化的学习率为 0.01；输入网络的数据大小为 32 条轨迹所有位置信息，每次迭代为 300 次。

为了验证所提方法的有效性，对特征匹配方法 [10] 和本文所提方法进行比较，两种方法的实验均在同一组数据上比较了处理时间和平移误差，所用到的实验设备是在联想 thinkPad E470 电脑，实验中使用的电脑配置为 i5-7200U, 2.50GHz CPU, 8GB 内存, Ubuntu16.04 操作系统, ROS 操作系统的版本为 Kinetic。该实验在一组车载数据上进行，该数据是在北京市朝阳区观塘小区采集，车速在 0km/h-30km/h。

本实验采用四种评价指标对实验结果进行评价，分别是：均方根误差 RMSE、平均绝对误差 MAE、均方误差 MSE 和皮尔逊相关系数 R2。四种评价指标均可以衡量模型给出的估计值与实际值之间的差距，对模型的性能

进行评价。其中 RMSE、MAE 和 MSE 三种评价指标的值越小，代表模型给出的估计值与真实值之间的差越小，而 R 的数值越大，则代表模型的拟合能力越好。四种评价指标的计算公式 (14)-(17) 所示：

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (x_{fil}^{(t)} - \hat{x}_{fil}^{(t)})^2} \tag{13}$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |(x_{fil}^{(t)} - \hat{x}_{fil}^{(t)})| \tag{14}$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (x_{fil}^{(t)} - \hat{x}_{fil}^{(t)})^2 \tag{15}$$

$$R^2 = \frac{\sum_{t=1}^N (x_{fil}^{(t)} - \bar{x}_{fil}^{(t)})(\hat{x}_{fil}^{(t)} - \bar{\hat{x}}_{fil}^{(t)})}{\sqrt{\sum_{t=1}^N (x_{fil}^{(t)} - \bar{x}_{fil}^{(t)})^2} \sqrt{\sum_{t=1}^N (\hat{x}_{fil}^{(t)} - \bar{\hat{x}}_{fil}^{(t)})^2}} \tag{16}$$

### 4.3 实验结果

本文对比五种经典路径估计模型，包括 CV[11]、CA[12]、Singer[13]、当前统计模型 [14] 和自适应模型。本次实验用的数据集为仿真目标轨迹带有粉红噪声数据集，本论文对解耦数据进行估计，其中，将 CA 模型和 CV 模型运动过程中的噪声方差设为 200，将 Singer 模型噪声方差和机动频率分别设置为 200 和 1，当前统计模型对设置参数比较敏感，因此设置了多组机动频率，分别为  $\alpha=1/10$ 、 $\alpha=1/20$  和  $\alpha=1/50$ 。实现方法：每次将 32 条轨迹的时刻观察值输入网络，真实值作为标签，训练该网络的参数矩阵，输出为时刻不含噪声的数据。解耦数据对比实验结果如下表 1 所示。

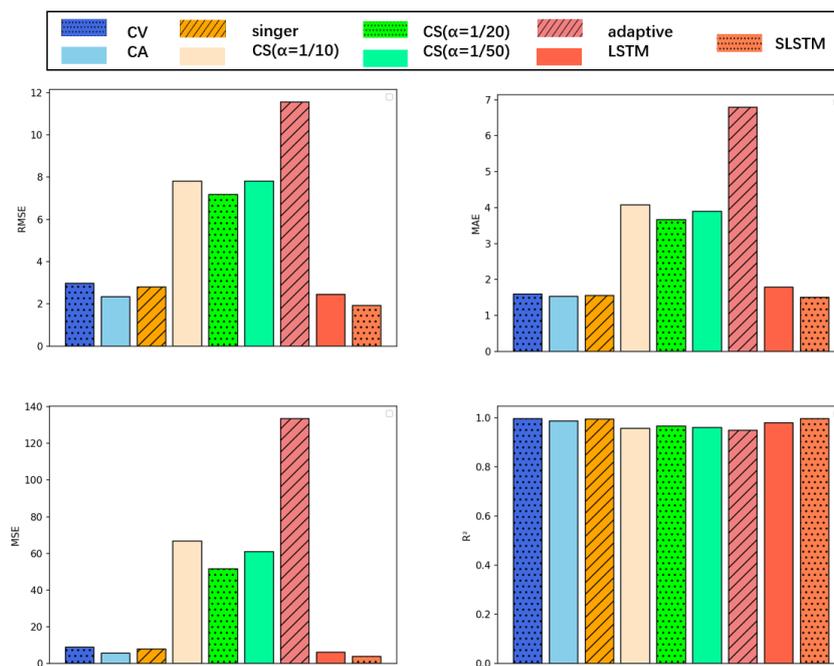


图 4. x 坐标的拟合效果对比

表 1. Effect comparison with the classical model

Model	direction	RMSE	MAE	MSE	R
CV <sup>[11]</sup>	X	2.982	1.586	8.893	0.996
	Y	2.449	1.499	5.998	0.996
CA <sup>[12]</sup>	X	2.348	1.531	5.515	0.986
	Y	2.072	1.474	4.294	0.991
singer <sup>[13]</sup>	X	2.788	1.556	7.776	0.994
	Y	2.326	1.479	5.411	0.995
CS <sup>[14]</sup>	X	7.799	4.077	66.799	0.957
$\alpha=1/10$	Y	6.683	4.128	48.954	0.964
CS <sup>[15]</sup>	X	7.171	3.659	51.433	0.966
$\alpha=1/20$	Y	6.139	3.653	37.694	0.971
CS <sup>[16]</sup>	X	7.803	3.891	60.891	0.961
$\alpha=1/50$	Y	6.695	3.957	44.831	0.966
Adaptive <sup>[43]</sup>	X	11.556	6.790	133.563	0.949
	Y	5.866	4.054	34.413	0.975
LSTM <sup>[16]</sup>	X	2.452	1.786	6.016	0.978
	Y	2.246	1.697	5.048	0.983
SLSTM	X	1.916	1.499	3.673	0.997
	Y	1.716	1.316	2.946	0.998

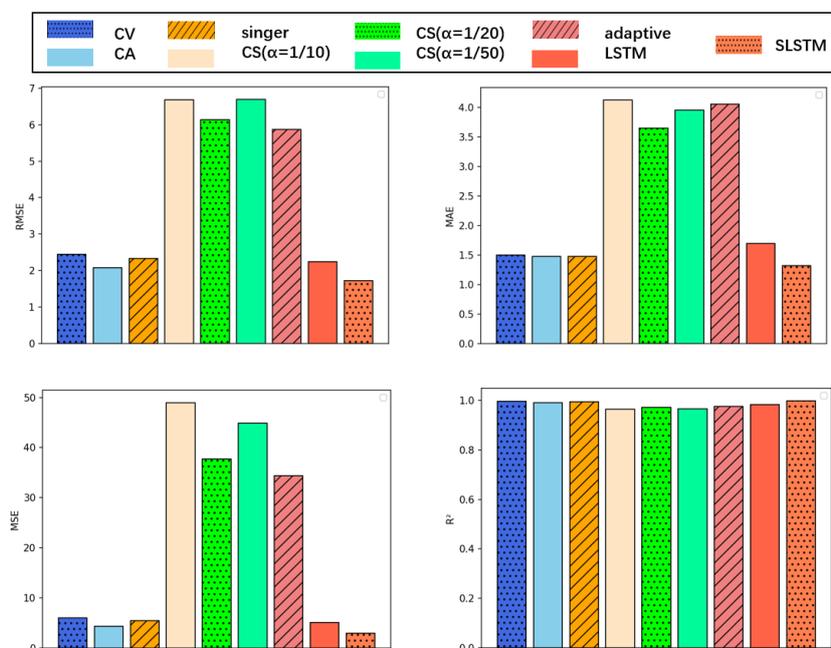


图 5. y 坐标的拟合效果对比

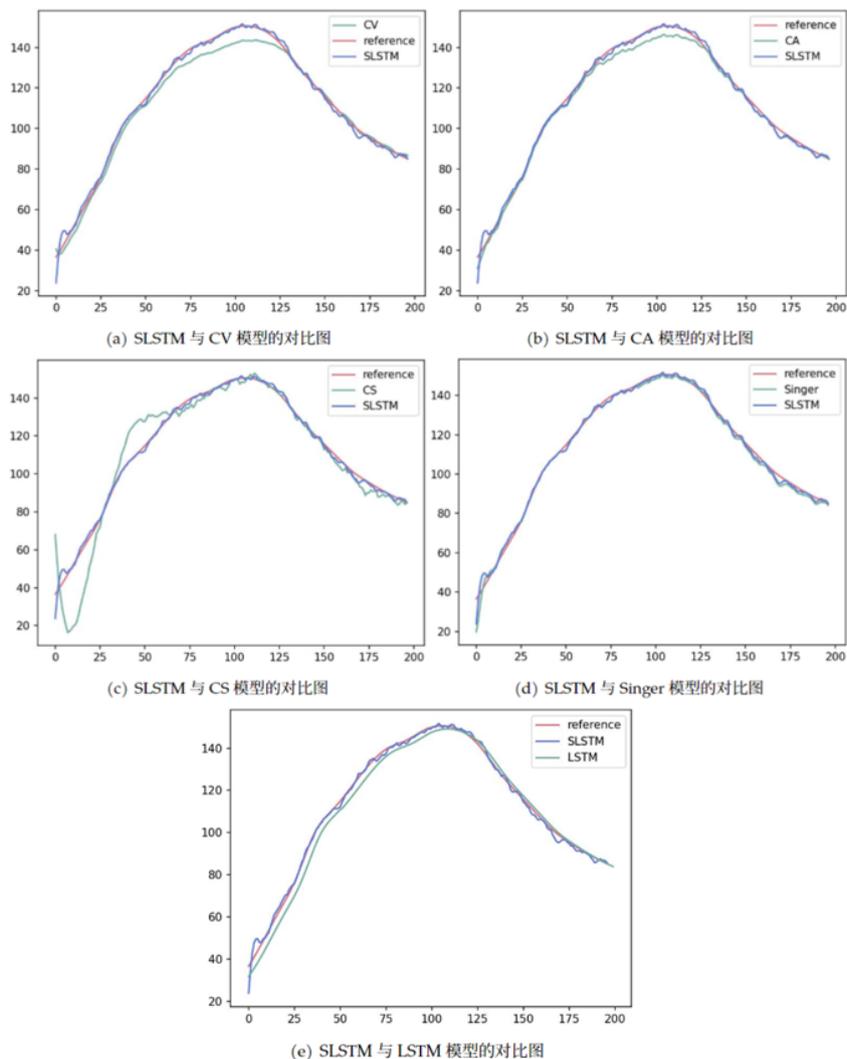


图 6. (a)-(e) 代表 SLSTM 分别将估计与 CV、CA、CS、Singer 模型和 LSTM 网络进行比较

## 5 结论

从表 1 和图 4,5,6 中对比结果可以看出，本文所提出的方法相比较经典估计方法与深度学习方法在估计精度上有提升。其中，解耦 X 坐标的估计结果相比较经典估计方法中结果最优的模型 CA，精度提高了 18.3%，与 LSTM 模型相比精度提高了 21.86%；解耦 Y 坐标的估计结果相比较经典模型中结果最优的模型 CA，精度提高了 17.19%，与 LSTM 模型相比精度提高了 23.38%。kalman 算法主要针对线性系统，要求系统和测量噪声为高斯模型；UKF、EKF、CKF 可以对非线性系统进行估计，也仍要求噪声为高斯噪声；CV 和 CA 模型将机动目标的加速度和加速度的导数视为零均值高斯噪声，Singer 模型将机动目标和加速度建模为指数自相关零均值有色噪声，零均值的假设对于真实情况下的机动目标运动状态的描述是不合理的。本数据集加有粉红噪声更符合实际的工程，神经网络能够对复杂非线性数据进行拟合，在训练数据中的复杂粉红噪声可以在网络中进行建模，可以实现对带有粉红噪声数据的估计。图 6 给出了基于 CV、CA、CS 和 Singer 机动模型的估计结果（见图 6(a), (b), (c), (d)，以及基于 LSTM 的数据驱动估计方法。从图中可以看出，本文提出的 SLSTM 网络拟合运动目标真实位置效果最好。这是由于 SLSTM 有两层递归结构，通过学习参考轨迹的动力学特性，可以将模型信息嵌入深度学习网络之中。而且，与 LSTM 网络模型相比，本文所提出的堆叠串行双 LSTM 结构，可以获取复杂的不确定运动模式的特征，能够更好表达测量值与目标真实值之间的映射，从而获得更好的轨迹估计性能。我们的实验结果表明，当运动目标不确定时，SLSTM 可以拟合不同的运动轨迹，这比基于机动模型和

LSTM 估计的卡尔曼估计结果更准确。

针对经典估计方法中有色噪声建模困难，目标运动模型与经典估计方法难以匹配，本文提出一种基于贝叶斯滤波思想的长短期神经网络，提出一种数据驱动的端对端状态估计方法，本文的主要贡献如下：设计出堆叠长短期神经网络，通过递归模块来估计目标的轨迹，SLSTM 从带有噪声的观测数据中估计运动目标状态，充分利用运动目标的 GPS 数据，实现一步预测，通过神经网络训练出不同轨迹的非线性关系，可以克服传统的轨迹估计方法估计精度的局限性。对比解耦数据 X 坐标，该方法与经典估计方法相比，精度提高 18.3%，对比 LSTM，精度提高 21.86%；对比解耦数据 Y 坐标，该方法与经典估计方法相比，精度提高 17.19% 该方法对比 LSTM，精度提高 23.38%。通过实验结果可以看出，该方法优于经典估计方法，优于经典的神经网络方法。在未来的工作中，我们不仅考虑 GPS 信息，还要考虑 IMU 信息，进一步提高模型预测的精度。

## 创新说明

本文研究的问题属于运动目标轨迹估计问题。该问题是在运动目标运动过程中，通常使用预测方程和更新方程对运动目标的状态进行建模，对每一时刻的运动目标的位置信息收集，并通过模型方程进行位置估计，从而估计运动目标的轨迹信息。

目前国际上针对这个问题已经提出了一些目标跟踪方法，其中包括经典估计方法和神经网络估计方法。这些方法在一定程度上解决了运动目标运动状态确定的目标跟踪问题，但是对于复杂的运动方式，其模型处理结果准确率较差。

本文提出一种基于 GPS 的堆叠串行 LSTM 组合网络目标跟踪方法，该网络模型基于贝叶斯滤波思想，一个 LSTM 网络用于预测运动状态，一个 LSTM 网络用于更新状态。该方法基于神经网络模型，无需对运动特性和传感器特性进行建模，有效提高目标的跟踪性能。

本文的创新点和意义在于：首先，设计了堆叠 LSTM 结构，与卡尔曼算法相比，不需要对运动目标进行建模；与神经网络算法相比，预测过程具有解释性。最后，利用变分方法，修改经典 LSTM 权重训练方式，让所提出来的网络能够适应 GPS 的有色噪声，进一步提高跟踪性能。这一创新技术有望在军事、机器人技术、自动驾驶等领域具有重要的应用前景。

## 参考文献

- [1] K. Mathiassen, L. Hanssen and O. Hallingstad, A low cost navigation unit for positioning of personnel after loss of GPS position, 2010 International Conference on Indoor Positioning and Indoor Navigation, Zurich, Switzerland, 1-10, 2010.
- [2] Huang, Z., Zhang, P., Liu, R., & Li, D. (2023). An Improved YOLOv3-Based Method for Immature Apple Detection. *IECE Transactions on Internet of Things*, 1(1), 9-14.
- [3] B. S Y, X. R. Li, T. Kirubarajan, Estimation with applications to tracking and navigation: theory algorithms and software. New York: Wiley-Interscience, 2001.
- [4] Julier, J. Simon, K. U. Jeffrey, New extension of the Kalman filter to nonlinear systems, *Signal processing, sensor fusion, and target recognition*, 3068: 182-193, 1997.
- [5] S. Julier, J. Uhlmann, H. F. Durrant-Whyte, A new method for the nonlinear transformation of means and covariances in filters and estimators, *IEEE Transactions on automatic control*, 45(3): 477-482, 2000.
- [6] S. J. Julier, J. K. Uhlmann, Unscented filtering and nonlinear estimation, *Proceedings of the IEEE*, 92(3): 401-422, 2004.
- [7] I. Arasaratnam, S. Haykin, Cubature kalman filters, *IEEE Transactions on automatic control*, 54(6): 1254-1269, 2009.

- [8] P. Li, J. Yu, M. Wan, J. Huang, The augmented form of cubature Kalman filter and quadrature Kalman filter for additive noise, In 2009 IEEE Youth Conference on Information, Computing and Telecommunication, 2009: 295-298.
- [9] Y. Chen, X. Xie, B. Yu, Multitarget vehicle tracking and motion state estimation using a novel driving environment perception system of intelligent vehicles, *Journal of advanced transportation*, 2021: 1-16, 2021.
- [10] M. Eltoukhy, M. O. Ahmad, M. N. S. Swamy, An adaptive turn rate estimation for tracking a maneuvering target, *IEEE Access*, 8: 94176-94189, 2020.
- [11] L. Wang, G. Zhou, Pseudo-spectrum based track-before-detect for weak maneuvering targets in range-Doppler plane, *IEEE Transactions on Vehicular Technology*, 70(4), 3043-3058, 2021.
- [12] S. Jia, Y. Zhang, G. Wang, Highly maneuvering target tracking using multi-parameter fusion Singer model, *Journal of Systems Engineering and Electronics*, 28(5): 841-850, 2017
- [13] Zhenkai, Xiong, F. Li, L. Zhang, Study on Maneuvering Target On-axis Tracking Algorithm of Modified Current Statistical Model, *MATEC Web of Conferences*, 160, 02008, 2018.
- [14] B. S. Y, *Multitarget-Multisensor Tracking: Applications and Advances*. 1992, chapter 2.
- [15] H. Jyh, L. Aiid, D. P. Atherton, Investigation of IMM Tracking Algorithm for The Maneuvering Target Tracking, *First IEEE Regional Conf. on Aerospace Control System*, 53: 113-117, 1993.
- [16] H. Sepp, S. Jürgen, Long Short-Term Memory, *Neural Comput*, 9(8): 1735-1780, 1997.
- [17] C. Chen, P. Zhao, C. X. Lu, W. Wang, A. Markham, N. Trigoni, Deep-learning-based pedestrian inertial navigation: Methods, data set, and on-device inference, *IEEE Internet Things J*, 7(5): 4431-4441, 2020.
- [18] B. Wang, C. Chen, C. X. Lu, AtLoc: Attention Guided Camera Localization, *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(6): 10393-10401, 2020.
- [19] S. Wang, R. Clark, H. Wen, N. Trigoni, DeepVO : Towards End-to-End Visual Odometry with Deep Recurrent Convolutional Neural Networks, in *IEEE International Conference on Robotics and Automation (ICRA)*, 2017: 2043-2050.
- [20] R. Clark, S. Wang, A. Markham, N. Trigoni, H. Wen, VidLoc: A Deep Spatio-Temporal Model for 6-DoF Video-Clip Relocalization, in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 6856-6864.
- [21] T. Zhou, M. Brown, N. Snavely, Unsupervised Learning of Depth and Ego-Motion from Video, in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 1851-1858.
- [22] Y. Sun, J. Xie, J. Guo, A new maneuvering target tracking method using adaptive cubature Kalman filter, in 2014 *IEEE International Conference on Control Science and Systems Engineering*, 2014: 40-44.
- [23] N. Nagui, O. Attallah, M. S. Zaghoul, Improved GPS/IMU loosely coupled integration scheme using two kalman filter-based cascaded stages, *Arabian Journal for Science and Engineering*, 46: 1345-1367, 2021.
- [24] Y. Sun, J. Xie, J. Guo, H. Wang, Y. Zhao, A modified marginalized Kalman filter for maneuvering target tracking, in *Proceedings of 2nd International Conference on Information Technology and Electronic Commerce*, 2014: 107-111.
- [25] Y. Huang, Y. Zhang, P. Shi and J. Chambers, Variational Adaptive Kalman Filter With Gaussian-Inverse-Wishart Mixture Distribution, in *IEEE Transactions on Automatic Control*, 66(4): 1786-1793, 2021.
- [26] Y. Chang, Y. Wang, Y. Shen, A new fuzzy strong tracking cubature Kalman filter for INS/GNSS, *GPS Solutions*, 25(3): 120, 2021.
- [27] S. S. Xiong, Z. Y. Zhou, Neural filtering of colored noise based on Kalman filter structure, *IEEE Transactions on Instrumentation and Measurement*, 52(3): 742-747, 2003.
- [28] Morales, F. Eduardo, A survey on deep learning and deep reinforcement learning in robotics with a tutorial on deep reinforcement learning, *Intelligent Service Robotics*, 14(5): 773-805, 2021.

- [29] K. Yeo, K. IMelny, Deep learning algorithm for data-driven simulation of noisy dynamical system, *Journal of Computational Physics*, 376: 1212-1231, 2018.
- [30] J. Liu, Z. Wang, M. Xu, DeepMTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network, *Information Fusion*, 53: 289-304, 2020.
- [31] J. Zhang, Y. Wu, S. Jiao, Research on Trajectory Tracking Algorithm Based on LSTM-UKF, in 2021 7th IEEE International Conference on Network Intelligence and Digital Content (IC-NIDC), 2021: 61-65.
- [32] S. Li, C. Hu, R. Wang, C. Zhou, J. Yang, A maneuvering tracking method based on LSTM and CS model, in 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP), 2019: 1-4.
- [33] Y. Cui, A new target tracking filter based on deep learning, *Chinese Journal of Aeronautics*, 35(5): 11-24, 2022.
- [34] K. Vedula, M. L. Weiss, R. C. Paffenroth, J. R. Uzarski, D. Richard. Brown, Maneuvering Target Tracking using the Autoencoder-Interacting Multiple Model Filter, in 2020 54th Asilomar Conference on Signals, Systems, and Computers, 2020: 1512-1517.
- [35] F. Giuliari, I. Hasan, M. Cristani, Transformer Networks for Trajectory Forecasting, in 2020 25th International Conference on Pattern Recognition (ICPR), 2021: 10335-10342.
- [36] H. Bo, Trajnet: A trajectory-based deep learning model for traffic prediction, in Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 716-724.
- [37] J. J. Q, Travel Mode Identification With GPS Trajectories Using Wavelet Transform and Deep Learning, *IEEE Transactions on Intelligent Transportation Systems*, 22(2): 1093-1103, 2021.
- [38] 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.
- [39] 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.
- [40] 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.
- [41] 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.
- [42] Fang, F., & Xiong, Y. (2014). Event-driven-based water level control for nuclear steam generators. *IEEE Transactions on Industrial electronics*, 61(10), 5480-5489.
- [43] 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.
- [44] 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.
- [45] 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.
- [46] Wei, L., & Fang, F. (2016).  $H_\infty$ -LQR-Based Coordinated Control for Large Coal-Fired Boiler-Turbine Generation Units. *IEEE Transactions on Industrial Electronics*, 64(6), 5212-5221.
- [47] 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.
- [48] 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.
- [49] 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.
- [50] 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.
- [51] 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.
- [52] Xu, D., Zhu, Z., Liu, C., Wang, Y., Zhao, S., Zhang, L., ... & Cheng, K. T. (2021). Reliability evaluation and analysis of FPGA-based neural network acceleration system. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 29(3), 472-484.
- [53] Li, W., Wang, Y., Li, H., & Li, X. (2019, January). P3M: a PIM-based neural network model protection scheme for deep learning accelerator. In *Proceedings of the 24th Asia and South Pacific Design Automation Conference* (pp. 633-638).
- [54] Wang, Y., Deng, J., Fang, Y., Li, H., & Li, X. (2017). Resilience-aware frequency tuning for neural-network-based approximate computing chips. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 25(10), 2736-2748.
- [55] Qu, S., Li, B., Wang, Y., Xu, D., Zhao, X., & Zhang, L. (2020, July). RaQu: An automatic high-utilization CNN quantization and mapping framework for general-purpose RRAM accelerator. In *2020 57th ACM/IEEE Design Automation Conference (DAC)* (pp. 1-6). IEEE.
- [56] Liu, B., Chen, X., Wang, Y., Han, Y., Li, J., Xu, H., & Li, X. (2019, January). Addressing the issue of processing element under-utilization in general-purpose systolic deep learning accelerators. In *Proceedings of the 24th Asia and South Pacific Design Automation Conference* (pp. 733-738).
- [57] Wang, C., Wang, Y., Han, Y., Song, L., Quan, Z., Li, J., & Li, X. (2017, January). CNN-based object detection solutions for embedded heterogeneous multicore SoCs. In *2017 22nd Asia and South Pacific design automation conference (ASP-DAC)* (pp. 105-110). IEEE.
- [58] Xu, D., Chu, C., Wang, Q., Liu, C., Wang, Y., Zhang, L., ... & Cheng, K. T. (2020, October). A hybrid computing architecture for fault-tolerant deep learning accelerators. In *2020 IEEE 38th International Conference on Computer Design (ICCD)* (pp. 478-485). IEEE.
- [59] Liu, C., Chu, C., Xu, D., Wang, Y., Wang, Q., Li, H., ... & Cheng, K. T. (2021). HyCA: A hybrid computing architecture for fault-tolerant deep learning. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 41(10), 3400-3413.
- [60] Wang, Y., Li, H., & Li, X. (2017). A case of on-chip memory subsystem design for low-power CNN accelerators. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 37(10), 1971-1984.
- [61] Li, J., Chen, Z., Cheng, L., & Liu, X. (2022). Energy data generation with wasserstein deep convolutional generative adversarial networks. *Energy*, 257, 124694.
- [62] Lian, S., Han, Y., Chen, X., Wang, Y., & Xiao, H. (2018, June). Dadu-p: A scalable accelerator for robot motion planning in a dynamic environment. In *Proceedings of the 55th Annual Design Automation Conference* (pp. 1-6).
- [63] Chang, K., Wang, Y., Ren, H., Wang, M., Liang, S., Han, Y., ... & Li, X. (2023). Chipgpt: How far are we from natural language hardware design. *arXiv preprint arXiv:2305.14019*.
- [64] Wang, Y., Han, Y., Zhang, L., Li, H., & Li, X. (2015, June). ProPRAM: Exploiting the transparent logic resources in non-volatile memory for near data computing. In *Proceedings of the 52nd Annual Design Automation Conference* (pp. 1-6).
- [65] Li, C., Wang, Y., Liu, C., Liang, S., Li, H., & Li, X. (2021). GLIST: Towards in-storage graph learning. In *2021 USENIX Annual Technical Conference (USENIX ATC 21)* (pp. 225-238).

- [66] Han, Y., Wang, Y., Li, H., & Li, X. (2014, November). Data-aware DRAM refresh to squeeze the margin of retention time in hybrid memory cube. In 2014 IEEE/ACM International Conference on Computer-Aided Design (ICCAD) (pp. 295-300). IEEE.
- [67] Zhao, X., Wang, Y., Liu, C., Shi, C., Tu, K., & Zhang, L. (2020, July). BitPruner: Network pruning for bit-serial accelerators. In 2020 57th ACM/IEEE Design Automation Conference (DAC) (pp. 1-6). IEEE.
- [68] Wu, B., Wang, C., Wang, Z., Wang, Y., Zhang, D., Liu, D., ... & Hu, X. S. (2020). Field-free 3T2SOT MRAM for non-volatile cache memories. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 67(12), 4660-4669.
- [69] Ma, X., Wang, Y., Wang, Y., Cai, X., & Han, Y. (2022). Survey on chiplets: interface, interconnect and integration methodology. *CCF Transactions on High Performance Computing*, 4(1), 43-52.
- [70] Hamdioui, S., Pouyan, P., Li, H., Wang, Y., Raychowdhur, A., & Yoon, I. (2017, November). Test and reliability of emerging non-volatile memories. In 2017 IEEE 26th Asian Test Symposium (ATS) (pp. 175-183). IEEE.
- [71] Chen, W., Wang, Y., Yang, S., Liu, C., & Zhang, L. (2020, March). You only search once: A fast automation framework for single-stage dnn/accelerator co-design. In 2020 Design, Automation & Test in Europe Conference & Exhibition (DATE) (pp. 1283-1286). IEEE.
- [72] Liu, Q., Cheng, L., Alves, R., Ozcelebi, T., Kuipers, F., Xu, G., ... & Chen, S. (2021). Cluster-based flow control in hybrid software-defined wireless sensor networks. *Computer Networks*, 187, 107788.
- [73] Liu, Q., Cheng, L., Ozcelebi, T., Murphy, J., & Lukkien, J. (2019, May). Deep reinforcement learning for IoT network dynamic clustering in edge computing. In 2019 19th IEEE/ACM international symposium on cluster, Cloud and Grid Computing (CCGRID) (pp. 600-603). IEEE.



**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项国家自然科学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, Changchun, China, in 1994 and 1997, and the Ph.D. degree in control theory and control engineering from the University of Zhe-

jiang, 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.



**刘嵩政** 2024年毕业于北京工商大学电子信息专业，获硕士学位。研究方向为模式识别与信息融合、卡尔曼滤波、目标跟踪、深度学习等。

Songzheng Liu, graduated from Beijing University of Technology and Business in 2019 with a master's degree in Detection Technology and Automation Devices. His research focuses on pattern recognition and information fusion, unmanned vehicles, machine learning, and other related fields.