



自动化学报
ACTA AUTOMATICA SINICA

旋转导向钻井工具系统实时测量的智能粒子滤波方法

盛立 刘一凡 高明 周东华

Intelligent Particle Filter for Real-time Measurement of Rotary Steerable Drilling Tool System

SHENG Li, LIU Yi-Fan, GAO Ming, ZHOU Dong-Hua

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250136>

您可能感兴趣的其他文章

旋转导向钻井工具系统实时测量的智能粒子滤波方法

盛立¹ 刘一凡¹ 高明¹ 周东华²

摘要 针对旋转导向钻井工具系统中工具面角的实时测量问题, 提出一种基于深度学习的智能粒子滤波算法. 首先, 针对粒子滤波中的粒子短缺与退化问题, 建立条件生成对抗网络 (CGAN) 引导的粒子选择机制. 在该机制中, 生成器网络通过对抗训练优化采样分布, 生成高质量粒子集; 判别器则评估生成粒子在真实后验分布中的概率值, 指导粒子权重计算. 其次, 针对井下复杂工况中存在的噪声协方差矩阵未知且时变问题, 设计基于深度残差网络 (ResNet) 的协方差矩阵估计器. 该模块与 CGAN 引导的粒子滤波以端到端的方式集成, 形成闭环优化系统. ResNet 模块得益于粒子滤波算法中的模型信息, 并为粒子滤波提供协方差矩阵的估计. 最后, 在旋转导向钻井工具平台上进行实验. 结果表明所提算法能够有效解决工具面角的实时测量问题, 与已有算法相比具有更高的精度.

关键词 智能粒子滤波, 旋转导向钻井工具系统, 实时测量, 深度学习算法, 未知噪声协方差矩阵

引用格式 盛立, 刘一凡, 高明, 周东华. 旋转导向钻井工具系统实时测量的智能粒子滤波方法. 自动化学报, 2025, 51(10): 1-11

DOI 10.16383/j.aas.c250136 **CSTR** 32138.14.j.aas.c250136

Intelligent Particle Filter for Real-time Measurement of Rotary Steerable Drilling Tool System

SHENG Li¹ LIU Yi-Fan¹ GAO Ming¹ ZHOU Dong-Hua²

Abstract To address the real-time measurement challenge of Toolface in rotary steerable drilling tool system, this paper proposes an intelligent particle filtering algorithm based on deep learning. Initially, the particle selection mechanism guided by conditional generative adversarial network (CGAN) is established to tackle the issues of particle impoverishment and degeneracy in particle filtering. In this mechanism, the generator network optimizes the sampling distribution through adversarial training, producing a high-quality set of particles; The discriminator network evaluates the probability of the generated particles within the true posterior distribution, guiding the particle weight calculation. Subsequently, the covariance matrix estimator is designed based on a deep residual network (ResNet) to address the unknown but time-varying noise covariance matrices in complex downhole conditions. This module is integrated with the CGAN-guided particle filter in an end-to-end manner, forming a closed-loop optimization system. The ResNet module benefits from the model information in the particle filtering algorithm and provides the particle filter with estimates of the covariance matrices. Finally, experiments are conducted on the rotary steerable drilling tool platform. The results demonstrate that the proposed algorithm effectively addresses the real-time measurement issue of Toolface and exhibits higher accuracy compared with existing algorithms.

Key words Intelligent particle filter, rotary steerable drilling tool system, real-time measurement, deep learning algorithm, unknown noise covariance matrix

Citation Sheng Li, Liu Yi-Fan, Gao Ming, Zhou Dong-Hua. Intelligent particle filter for real-time measurement of rotary steerable drilling tool system. *Acta Automatica Sinica*, 2025, 51(10): 1-11

收稿日期 2025-04-02 录用日期 2025-07-13

Manuscript received April 2, 2025; accepted July 13, 2025

国家自然科学基金 (62473379, 62173343, 62033008), 山东省自然科学基金 (ZR2024MF072, ZR2022ZD34, ZR2025ZD02), 山东省泰山学者项目研究基金资助

Supported by National Natural Science Foundation of China (62473379, 62173343, 62033008), Natural Science Foundation of Shandong Province (ZR2024MF072, ZR2022ZD34, ZR2025ZD02), and Research Fund for the Taishan Scholar Project of Shandong Province of China

本文责任编辑 李忠奎

Recommended by Associate Editor LI Zhong-Kui

1. 中国石油大学 (华东) 控制科学与工程学院 青岛 266580 2. 东南大学自动化学院 南京 214135

旋转导向钻井工具系统 (Rotary steerable drilling tool system, RSDTS) 是油气勘探开发领域的重要设备, 主要负责驱动钻头沿着给定的工具面角钻进^[1]. 工具面角是表征钻头钻进方向的重要参数, 其测量精度决定 RSDTS 的整体性能. 传统方法主要采用加速度计等传感器静态测量工具面角^[2], 实时性不佳. 为此, 文献 [3] 建立 RSDTS 的数

1. College of Control Science and Engineering, China University of Petroleum (East China), Qingdao 266580 2. School of Automation, Southeast University, Nanjing 214135

学模型, 将工具面角的实时测量转化为非线性系统的滤波问题. 由于井下环境复杂多变, RSDTS 的滤波具有一定挑战性^[4], 主要难点集中于以下两方面: 1) 一般非线性滤波方法如扩展卡尔曼滤波 (Extended Kalman filter, EKF) 和无迹卡尔曼滤波 (Unscented Kalman filter, UKF) 在处理 RSDTS 模型中的非线性时存在固有局限性^[5]; 2) 实际钻井过程中 RSDTS 测量噪声和过程噪声的噪声协方差矩阵未知且时变.

粒子滤波 (Particle filter, PF) 是一种常用的非线性滤波算法^[6], 其核心思想在于通过融合重要性采样理论与基于离散随机测度的概率分布近似表征方法, 实现相关概率分布的递归计算. 然而, 传统粒子滤波算法存在粒子短缺与退化问题, 导致粒子难以描述真实分布. 该现象是由粒子状态选择不充分造成的, 其解决的关键在于设计合适的重要性采样分布. 早期的解决方案主要依赖于重采样策略^[7], 即通过舍弃低权重粒子并保留高权重粒子来优化粒子集. 文献 [8] 首次将遗传算法引入粒子滤波, 通过交叉操作引导低似然粒子向高似然区域迁移; 同时, 利用变异操作促使粒子随机向低似然区域探索, 以增加粒子多样性. 在基于启发式算法的改进粒子滤波中, 粒子的似然值被视为目标函数, 通过相应的寻优机制使粒子向高似然区域聚集^[9].

随着人工智能技术的发展, 深度学习模型被引入到滤波领域^[10], 其强大的学习能力有助于解决传统滤波算法的局限性^[11]. 文献 [12] 提出一种基于 Transformer 的卡尔曼滤波器, 通过捕捉数据的时序特征来实现时变信号的精准预测, 并采用最大期望 (Expectation-maximization, EM) 算法估计卡尔曼滤波的关键参数. 文献 [13] 提出一种深度粒子滤波算法, 在重采样前引入反向传播神经网络以增强粒子多样性, 并将其应用于滚动轴承的剩余使用寿命预测. 文献 [14] 利用条件变分自编码器 (Conditional variational autoencoder, CVAE) 生成模型引导粒子的状态选择, 学习数据的潜在分布, 并生成与分布相符的新数据. 在序贯采样策略框架下, 该方法能够从理论上最优的真实后验分布中采样. 然而, 生成模型本质上是一个黑箱模型, 难以直接从中获取真实的概率值, 这使得粒子权重的直接计算较为困难. 如何有效利用生成模型引导粒子滤波, 仍然是当前亟待解决的重要科学问题.

当噪声协方差矩阵未知时, 粒子滤波的应用面临显著挑战. 对于卡尔曼滤波器而言, 通过引入变分贝叶斯推断 (Variational Bayesian inference,

VB)、EM 等参数推断算法, 能够同时对状态和噪声协方差矩阵进行联合估计^[15-16]. 然而, 粒子滤波的实质是贝叶斯滤波的一种非参数实现, 上述参数化方法难以应用于粒子滤波框架. 在测量噪声协方差未知的情况下, 文献 [17] 将 VB 算法与 PF 算法结合, 并推导测量噪声协方差的更新公式. 由于粒子滤波依赖于采样过程, 该方法在处理粒子短缺与退化问题时容易出现较大偏差, 在理论上并非行之有效的解决方案. 当过程噪声协方差矩阵未知时, 粒子的状态确定本身十分困难, 而粒子的权重计算则更为复杂. 文献 [18] 提出将卷积神经网络 (Convolutional neural network, CNN) 与 UKF 结合, 利用 CNN 学习噪声协方差矩阵, 并以端到端的方式实现两者协同. 其中, CNN 受益于 UKF 提供的模型信息, 而 UKF 则借助 CNN 的学习能力提升估计性能. 类似地, 文献 [19] 提出一种基于深度学习的卡尔曼滤波器, 通过引入两个长短期记忆神经网络自适应调节测量噪声协方差, 实现车辆侧偏角的高精度估计. 针对过程噪声时变下的纯方位跟踪问题, 文献 [20] 提出基于 Swin Transformer 的自适应卡尔曼滤波器. 使用 Swin Transformer 模型来捕获过程噪声统计特性, 进而学习目标位移和速度间的统计关系. 需要指出的是, 尽管深度神经网络与粒子滤波的结合展现出巨大潜力, 但这一领域仍处于探索阶段, 许多关键问题尚未解决. 例如, 如何设计高效的网络结构以准确捕捉噪声特性, 以及如何将神经网络模型与粒子滤波进行集成, 都是当前研究的难点^[21].

综合上述分析, 本文提出一种 RSDTS 的智能滤波方法, 主要贡献包括:

1) 针对 RSDTS 工具面角的实时测量问题, 提出一种智能粒子滤波算法, 有效解决了系统中的强非线性及噪声协方差未知且时变的问题.

2) 提出条件生成对抗网络 (Conditional generative adversarial network, CGAN) 引导的粒子选择机制. 其中生成器拟合真实后验分布以实现粒子采样, 判别器指导粒子权重计算, 显著缓解了粒子短缺与退化问题, 提升了滤波性能.

3) 设计残差神经网络 (Residual network, ResNet) 与粒子滤波的融合算法, ResNet 利用粒子滤波的模型信息估计噪声协方差矩阵, 粒子滤波则借助 ResNet 的学习能力实现工具面角的测量, 有效应对了井下噪声协方差矩阵未知且时变的复杂工况.

本文提出的方法不仅为工具面角的实时测量提供新的解决方案, 还为粒子滤波与深度学习技术的结合探索了新的研究方向.

1 相关工作

1.1 RSDTS 模型

在钻井过程中, RSDTS 的工具面角决定了钻头的钻进方向, 通常由加速度计和陀螺仪进行测量^[5], 其测量方程为

$$\begin{cases} y_{1,k} = \bar{g}_k \sin(\phi_k) + v_{1,k} \\ y_{2,k} = -\bar{g}_k \cos(\phi_k) + v_{2,k} \\ y_{3,k} = \dot{\phi}_k + \bar{\omega}_{1,k} \end{cases}$$

其中, $y_{1,k}$ 和 $y_{2,k}$ 分别为加速度计的测量值, $y_{3,k}$ 为陀螺仪的测量值, $v_{1,k}$ 和 $v_{2,k}$ 和 $\bar{\omega}_{1,k}$ 为传感器的测量噪声, ϕ_k 为工具面角. \bar{g}_k 是重力加速度分量, 通常被建模为 $\bar{g}_{k+1} = \bar{g}_k + \omega_{2,k}$, $\omega_{2,k}$ 代表服从高斯分布噪声. 井下钻头钻进过程中的强振动使传感器的测量值受到强干扰影响, 为获得工具面角实时准确的测量值, 将此问题转化为动态系统的滤波问题.

为将 RSDTS 写成状态空间模型的形式, 首先对测量值进行离散化^[5]. 对于给定的采样间隔 m , 可以得到

$$\dot{\phi}_k \approx \frac{\phi_{k+1} - \phi_k}{m}$$

当采样间隔较小时, 可近似得到 $\phi_{k+1} = \phi_k + m\dot{\phi}_k + m\bar{\omega}_{1,k}$. 令状态变量 $x_{1,k}$ 表示工具面角, $x_{2,k}$ 表示重力加速度分量, 则有

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{x}_k + B u_k + \boldsymbol{\omega}_k \\ \mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{v}_k \end{cases} \quad (1)$$

其中,

$$\mathbf{x}_k = \begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix}, \quad B = \begin{bmatrix} m \\ 0 \end{bmatrix}, \quad u_k = y_{3,k}$$

$$\boldsymbol{\omega}_k = \begin{bmatrix} -m\bar{\omega}_{1,k} \\ \omega_{2,k} \end{bmatrix}, \quad \mathbf{y}_k = \begin{bmatrix} y_{1,k} \\ y_{2,k} \end{bmatrix}$$

$$\mathbf{v}_k = \begin{bmatrix} v_{1,k} \\ v_{2,k} \end{bmatrix}, \quad h(\mathbf{x}_k) = \begin{bmatrix} x_{2,k} \sin(x_{1,k}) \\ -x_{2,k} \cos(x_{1,k}) \end{bmatrix}$$

为描述井下噪声特性, 假设 $\boldsymbol{\omega}_k \sim N(\mathbf{0}, R_k)$ 且 $\mathbf{v}_k \sim N(\mathbf{0}, Q_k)$, 其中, $N(\boldsymbol{\mu}, \Sigma)$ 代表均值为 $\boldsymbol{\mu}$ 、协方差矩阵为 Σ 的高斯分布, R_k 和 Q_k 是未知的时变协方差矩阵参数. 本文的主要工作是提出一种新的智能粒子滤波算法, 用于解决 RSDTS 的滤波问题.

1.2 传统粒子滤波算法

本节首先介绍传统粒子滤波算法的框架^[6], 考虑如下一般形式的非线性随机系统:

$$\begin{cases} \mathbf{x}_{k+1} = g(\mathbf{x}_k) + B u_k + \boldsymbol{\omega}_k \\ \mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{v}_k \end{cases} \quad (2)$$

其中, $\mathbf{x}_k \in \mathbf{R}^{n_x}$ 为系统状态, $u_k \in \mathbf{R}^{n_u}$ 为系统输入, $\mathbf{y}_k \in \mathbf{R}^{n_y}$ 为系统输出, B 为已知适维矩阵, $g(\cdot)$ 代表状态函数, $h(\cdot)$ 代表测量函数, $\boldsymbol{\omega}_k \sim N(\mathbf{0}, R_k)$ 为系统的过程噪声, $\mathbf{v}_k \sim N(\mathbf{0}, Q_k)$ 为测量噪声.

在粒子滤波框架中, 状态的后验分布由一组粒子及相应的权重描述. 令 $\boldsymbol{\nu}_{0:k} = [\boldsymbol{\nu}_0^T, \dots, \boldsymbol{\nu}_k^T]^T$, 其中 $\boldsymbol{\nu}$ 代表任意向量. 那么, 对于 k 时刻状态的后验分布 $p(\mathbf{x}_{0:k} | \mathbf{y}_{0:k})$, 其可以表示成

$$p(\mathbf{x}_{0:k} | \mathbf{y}_{0:k}) \approx \sum_{i=1}^{N_s} w_k^i \delta(\mathbf{x}_{0:k} - \mathbf{x}_{0:k}^i) \quad (3)$$

其中, $\mathbf{x}_{0:k}^i$ 是粒子状态, w_k^i 是粒子权重, N_s 为粒子数量, $\delta(\cdot)$ 是狄拉克 delta 函数. 在更新阶段, 通过引入预设的采样分布生成新粒子, 并基于重要性采样理论推导粒子权重. 从贝叶斯滤波框架出发, 后验概率密度可分解为如下递推形式:

$$p(\mathbf{x}_{0:k} | \mathbf{y}_{0:k}) = \frac{p(\mathbf{y}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{x}_{k-1})}{p(\mathbf{y}_k | \mathbf{y}_{0:k-1})} p(\mathbf{x}_{0:k-1} | \mathbf{y}_{0:k-1})$$

为确保粒子滤波算法的递推性并降低计算复杂度, 通常假设新粒子状态的采样分布与历史分布无关. 据此构造如下可分解形式的分布:

$$q(\mathbf{x}_{0:k} | \mathbf{y}_{0:k}) = q(\mathbf{x}_{0:k-1} | \mathbf{y}_{0:k-1}) q(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{0:k})$$

基于上述分解形式, 通过重要性采样原理可推导出权重递推式:

$$w_k^i = w_{k-1}^i \frac{p(\mathbf{y}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{y}_{0:k})} \quad (4)$$

在基于序贯重要性采样的传统粒子滤波方法中, 采样分布 $q(\mathbf{x}_k | \mathbf{x}_{0:k-1}^i, \mathbf{y}_{0:k})$ 被选取为 $p(\mathbf{x}_k | \mathbf{x}_{k-1}^i)$, 从而粒子权重的更新式简化为

$$w_k^i = w_{k-1}^i p(\mathbf{y}_k | \mathbf{x}_k^i)$$

1.3 条件生成对抗网络 (CGAN)

生成对抗网络 (Generative adversarial network, GAN) 是基于对抗训练的深度学习模型, 旨在生成逼近于真实数据分布的合成数据^[22]. 其核心架构由生成器 (Generator) 和判别器 (Discriminator) 两个相互对抗的神经网络组成, 通过二者间的动态博弈实现数据生成任务. 具体而言, 生成器以

随机噪声作为输入,生成与真实数据分布相似的合成样本. 判别器则作为一个二元分类器,判别真实数据和生成数据的真实性.

CGAN 是 GAN 的一种扩展形式. 基于生成器-判别器的框架,CGAN 引入条件信息,为判别器和生成器的输入端附加标签^[23]. $D(\cdot)$ 是判别分数,衡量样本与真实分布的差异. 分数越高,代表样本越接近真实分布. $G(\mathbf{z}, \mathbf{y})$ 代表给定标签 \mathbf{y} 下基于随机噪声 \mathbf{z} 生成的样本. 通过生成器 G 和判别器 D 的交替优化训练,生成器逐渐学习生成能够欺骗判别器的样本,而判别器则不断提升其判别能力. 当训练达到纳什均衡时,生成器 G 将能够生成与真实数据分布高度相似的样本^[24],即

$$G(\mathbf{z}, \mathbf{y}) \sim p(\mathbf{x}|\mathbf{y})$$

此时生成器已经达到理想性能,其生成的样本与 $p(\mathbf{x}|\mathbf{y})$ 在统计意义下趋于一致.

2 基于 CGAN 的粒子滤波 (CGAN-PF)

RSDTS 中存在的强非线性会导致传统粒子滤波并不适用. 具体而言, RSDTS 中正余弦形式的输出函数导致状态后验分布难以近似,进而引发严重的粒子短缺与退化问题. 为解决这一难题,本节提出一种基于 CGAN 的粒子滤波 (Particle filter based on CGAN, CGAN-PF) 算法.

首先考虑粒子状态的选择问题. 优秀的采样函数既能充分利用观测信息,又能保持计算效率与估计精度的平衡,这成为改进粒子滤波性能的关键研究方向. 已有学者明确指出,最优的采样分布为如下条件后验分布

$$q(\mathbf{x}_k|\mathbf{x}_{0:k-1}^i, \mathbf{y}_{0:k}) = p(\mathbf{x}_k|\mathbf{x}_{k-1}^i, \mathbf{y}_k) \quad (5)$$

根据该策略采样的粒子能够准确描述状态的后验分布,从而解决粒子短缺与退化问题.

受 RSDTS 强非线性的影响,上述后验分布难以精确获得. 能够注意到,粒子演进过程只需要从重要性分布中进行采样,而无需精确获知该后验分布的具体解析形式. 类似地,作为黑箱模型,CGAN 能够生成服从特定分布的样本. 该过程与采样是等价的,因而本文考虑将粒子采样环节交由生成器来完成,以取代传统采样方法. 为使粒子的分布最优,需要令生成器 G 学习到式 (5) 中给出的最优后验分布. 具体而言,考虑一个训练完备的 CGAN,其生成器 G 能够在给定标签 \mathbf{x}_{k-1} 和 \mathbf{y}_k 的情况下从分布 $p(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{y}_k)$ 中生成样本. 这样,生成器 $G(\mathbf{z}, \mathbf{x}_{k-1}, \mathbf{y}_k)$ 的输出数据近似服从如下分布:

$$G(\mathbf{z}, \mathbf{x}_{k-1}, \mathbf{y}_k) \sim p(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{y}_k)$$

如果将生成器的输出作为新的粒子状态,即令

$$\mathbf{x}_k^i = G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k) \quad (6)$$

那么 \mathbf{x}_k^i 可以看作是从分布 $p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 中采样得到的样本. 对于粒子集合 $\{\mathbf{x}_{k-1}^i\}_{i=1}^{N_s}$,将粒子状态与当前观测值组合形成输入特征 $\{\mathbf{x}_{k-1}^i, \mathbf{y}_k\}$,并将其作为 CGAN 中生成器 G 的输入. 这样, G 生成的粒子服从分布

$$\mathbf{x}_k^i \sim p(\mathbf{x}_k|\mathbf{x}_{k-1}^i, \mathbf{y}_k)$$

通过式 (6) 所示的粒子更新机制,实现粒子的采样步骤,其采样分布能够逼近理论上的最优后验分布. 得益于生成对抗网络的强大生成能力,这种采样策略能够有效克服传统粒子滤波中采样分布与真实后验分布偏差较大的问题,为复杂非线性系统的状态估计提供一种新的解决方案.

接下来,考虑上述粒子的权重更新问题. 根据式 (4) 和式 (5),CGAN-PF 算法的粒子权重可以通过下式进行计算:

$$w_k^i = w_{k-1}^i \frac{p(\mathbf{y}_k|\mathbf{x}_k^i)p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i)}{p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i, \mathbf{y}_k)}$$

在已知噪声协方差矩阵的条件下,上式中的概率密度函数可以表示为高斯分布的形式,即

$$p(\mathbf{y}_k|\mathbf{x}_k^i) = \mathbf{N}(\mathbf{y}_k - h(\mathbf{x}_k^i); \mathbf{0}, Q_k)$$

$$p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i) = \mathbf{N}(\mathbf{x}_k^i - g(\mathbf{x}_{k-1}^i) - B\mathbf{u}_{k-1}; \mathbf{0}, R_k)$$

其中, $\mathbf{N}(\mathbf{x}; \boldsymbol{\mu}, \Sigma)$ 代表随机变量 \mathbf{x} 的概率密度函数,其服从均值为 $\boldsymbol{\mu}$ 、协方差矩阵为 Σ 的高斯分布. 注意到,条件概率 $p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 涉及到复杂的积分运算:

$$p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i, \mathbf{y}_k) = \frac{p(\mathbf{y}_k|\mathbf{x}_k^i)p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i)}{p(\mathbf{y}_k|\mathbf{x}_{k-1}^i)} = \frac{p(\mathbf{y}_k|\mathbf{x}_k^i)p(\mathbf{x}_k^i|\mathbf{x}_{k-1}^i)}{\int_{\mathbf{x}_k} p(\mathbf{y}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{x}_{k-1}^i)d\mathbf{x}_k}$$

这使得 CGAN-PF 算法的粒子权重难以直接解析获得. 经过深入的文献调研,目前学术界尚未提出针对该问题的有效可行方法,因此,基于生成器模型的粒子权重计算仍然是一个亟待解决的开放性科学问题.

为解决粒子权重的更新问题,重新考虑 CGAN-PF 算法中的判别器和生成器结构. 生成器 $G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 生成的样本所得到的判别分数 $D(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k))$ 表征其通过判别的置信度. 具体而言,判别器的输入端接收真实数据和生成数据,输出端给出相应的判别器分数,其值在区间 $[0, 1]$ 内. 判别

器分数较高表明数据更可能来自真实分布, 判别器分数较低表明数据更可能来自生成器 G . 当判别器 D 经过充分训练的情况下, 该分数能够有效反映生成数据的真实程度. 具体而言, 当判别器分数 $D(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k))$ 较高时, 意味着生成数据与真实数据较难区分, 此时 $G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 位于条件分布 $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 的高似然区域. 事实上, 判别器分数 $D(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k))$ 和概率值 $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$ 之间必然存在着单调的正相关关系. 根据上述分析, 本研究作出如下合理假设:

$$p(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k) | \mathbf{x}_{k-1}^i, \mathbf{y}_k) \propto D(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k))$$

即生成器生成数据的似然值与判别器给出的判别分数成正比. 定义伪权重

$$\tilde{w}_k^i = w_{k-1}^i \frac{p(\mathbf{y}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{D(G(\mathbf{z}, \mathbf{x}_{k-1}^i, \mathbf{y}_k))}$$

可以得到 CGAN-PF 算法的粒子权重 w_k^i 与 \tilde{w}_k^i 成正比, 因而粒子权重可以通过下式进行计算:

$$w_k^i = \frac{\tilde{w}_k^i}{\sum_{j=1}^{N_s} \tilde{w}_k^j} \quad (7)$$

至此, 用判别器分数来作为粒子后验概率值的有效代理, 解决了粒子权重的更新问题. 需要说明的是, 尽管在实际应用中判别器评分与似然值之间并不完全呈现线性正比例关系, 其误差在工程应用中被认为是可接受的. 此外, 由于判别器分数的计算仅需通过判别器的前向传播即可完成, 该方法在计算效率方面具有显著优势.

粒子权重值确定后, 系统在 k 时刻状态估计值可通过所有粒子的加权求和来获得, 其数学表达式为

$$\hat{\mathbf{x}}_k = \sum_{i=1}^{N_s} w_k^i \mathbf{x}_k^i$$

这样, 通过引入 CGAN 中的生成器-判别器架构, 实现粒子滤波中粒子采样和权重更新过程的优化. 这种基于深度学习的改进方法能够解决 RSDTS 中非线性导致的粒子短缺与退化问题, 提高工具面角的实时测量精度.

3 改进 CGAN-PF 算法 (ResCGAN-PF)

当系统过程噪声和测量噪声的协方差矩阵已知时, CGAN-PF 算法能够有效测量工具面角. 然而, 受井下复杂工况 (如强振动、强干扰) 的影响, RSDTS 的噪声协方差矩阵往往难以精确获得. 此外, 实际

应用中 RSDTS 的噪声协方差矩阵通常具有时变特性, 进一步增加了算法设计的挑战性. 从技术的角度来讲, 上述问题将使得权重更新部分的 $p(\mathbf{y}_k | \mathbf{x}_k^i)$ 和 $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)$ 无法直接计算, 从而导致 CGAN-PF 算法的实际滤波精度较差.

尽管学术界对噪声协方差矩阵未知的问题已有初步研究, 但在粒子滤波框架下, 这一问题尚未得到有效解决. 其主要难点在于, 传统粒子滤波算法中粒子的状态更新步骤严重依赖于过程噪声协方差矩阵的已知性. 只有在已知过程噪声协方差矩阵的情况下, 才能确定采样分布并生成粒子状态. 而当粒子状态无法确定时, 噪声协方差矩阵的估计也几乎不可行. 这种相互依赖性形成一个技术闭环. 幸运的是, CGAN-PF 算法提供了新的解决思路. 得益于生成器强大的学习能力, CGAN-PF 算法能够在噪声协方差矩阵完全未知的情况下, 直接生成符合系统动态特性的粒子状态. 这使得粒子滤波框架下的状态与噪声协方差的联合估计成为可能.

基于上述分析, 本节提出一种数据驱动和基于模型的混合算法, 该方法能够同时利用神经网络的学习能力及系统中包含的模型信息. 首先, 对同时刻的粒子集进行网格化处理, 将其转化为二维的图像数据. 通过对粒子分布进行可视化, 其密度可以反映在图像的像素值上. 进而可以通过图片学习到后验分布的形状, 并对其进行特征提取. 网格化的粒子图像被输入到残差神经网络, 进而通过三层堆叠的残差块, 对噪声协方差矩阵参数进行估计. 考虑到时序反向传播算法中可能出现的梯度爆炸和梯度消失问题, 残差神经网络能够增强训练的鲁棒性. 所提 ResCGAN-PF 的流程如图 1 所示. 具体而言, 将残差神经网络与粒子滤波以端到端的方式连接. 残差神经网络的输入端包括粒子状态 $\{\mathbf{x}_{k-1}^i\}_{i=1}^{N_s}$ 的网格化图像和系统测量值 \mathbf{y}_k , 输出端为粒子滤波算法提供点估计 U_{k-1} 和 V_k . 在前向传播中, 残差神经网络向粒子滤波传递噪声协方差矩阵; 在反向传播中, 残差网络利用滤波结果和真实值的误差来进行训练. 由于滤波结果充分利用了系统的状态空间模型, 因而该方法可以视为模型信息引导的神经网络. 为保证协方差矩阵的正定性, 粒子滤波中的参数选为

$$R_{k-1} = U_{k-1} U_{k-1}^T, \quad Q_k = V_k V_k^T$$

在训练阶段, 考虑到粒子滤波的时序性, 残差网络是在预定义的时间段 T 上进行训练的. 采用文献 [18] 中提出的时序反向传播算法进行优化, 损失函数由粒子滤波结果和真实状态的均方误差来定义

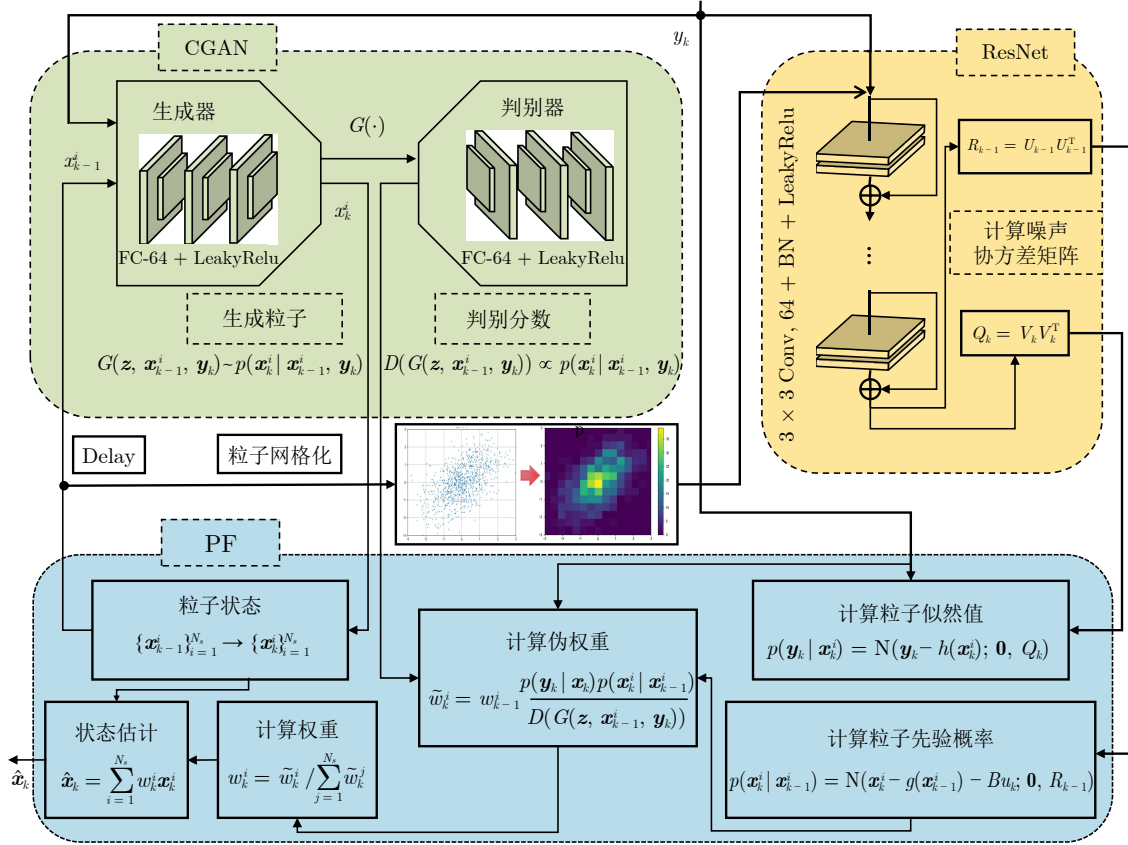


图1 ResCGAN-PF 算法图示

Fig.1 The diagram of the ResCGAN-PF algorithm

$$L = \frac{1}{T} \sum_{t=1}^T \|\mathbf{x}_t - \hat{\mathbf{x}}_t\|^2$$

令 $\mathbf{s}_t = [w_t^1, \dots, w_t^{N_s}]$ 代表权重的集合, 由于协方差矩阵参数只影响粒子的权重, 且粒子已经从 CGAN 算法中采样, 系统状态 \mathbf{x}_t 的分布实际上是由 \mathbf{s}_t 表征的. 由于矩阵参数的存储是连续的一维数组, 定义 $\text{vec}(A_{m \times n}) = [A_1^T, \dots, A_n^T]^T$, 其中 A_1, \dots, A_n 是矩阵 A 的列. 令 $\mathbf{z}_t = [\text{vec}^T(U_{t-1}) \text{vec}^T(V_t)]^T$ 代表神经网络的输出端, \mathbf{o}_t 代表输入端, 那么 $\mathbf{z}_t = f_{\theta}(\mathbf{o}_t)$, 其中 θ 为待训练的参数. 在本文中, 向量求导采用分子布局. 根据文献 [18], 损失函数相对于神经网络的梯度可以通过下式计算:

$$\frac{dL}{d\theta} = \sum_{t=1}^T \frac{dL}{ds_t} \frac{ds_t}{dz_t} \frac{dz_t}{d\theta}$$

其中, $\frac{dL}{ds_t}$ 可以通过递归计算得到. 考虑损失函数对于 \mathbf{s}_{t-1} 的梯度, 根据链式法则可以得到

$$\frac{dL}{ds_{t-1}} = \frac{1}{T} \left(\frac{d\|\hat{\mathbf{x}}_{t-1} - \mathbf{x}_{t-1}\|^2}{ds_{t-1}} + \frac{dL}{ds_t} \frac{ds_t}{ds_{t-1}} \right)$$

$\frac{ds_t}{ds_{t-1}}$ 为 t 时刻关于 $t-1$ 时刻粒子权重的梯

度, 即

$$\frac{ds_t}{ds_{t-1}} = \begin{bmatrix} \frac{dw_t^1}{dw_{t-1}^1} & \dots & \frac{dw_t^1}{dw_{t-1}^{N_s}} \\ \vdots & \ddots & \vdots \\ \frac{dw_t^{N_s}}{dw_{t-1}^1} & \dots & \frac{dw_t^{N_s}}{dw_{t-1}^{N_s}} \end{bmatrix} \quad (8)$$

$\frac{ds_t}{dz_t}$ 为神经网络输出 U_{t-1} 和 V_t 对粒子权重的梯度作用, 可以表示为

$$\frac{ds_t}{dz_t} = \begin{bmatrix} \frac{dw_t^1}{d\text{vec}(U_{t-1})} & \frac{dw_t^1}{d\text{vec}(V_t)} \\ \vdots & \vdots \\ \frac{dw_t^{N_s}}{d\text{vec}(U_{t-1})} & \frac{dw_t^{N_s}}{d\text{vec}(V_t)} \end{bmatrix}$$

对于 $i \in [1, N_s]$, 有

$$\frac{dw_t^i}{d\text{vec}(U_{t-1})} = \frac{dw_t^i}{d\text{vec}(R_{t-1})} \frac{d\text{vec}(R_{t-1})}{d\text{vec}(U_{t-1})}$$

$$\frac{dw_t^i}{d\text{vec}(V_{t-1})} = \frac{dw_t^i}{d\text{vec}(Q_t)} \frac{d\text{vec}(Q_t)}{d\text{vec}(V_t)}$$

其中, $\frac{dw_t^i}{d\text{vec}(R_{t-1})}$ 和 $\frac{dw_t^i}{d\text{vec}(Q_t)}$ 的计算涉及高斯概率密

度函数 $p(\mathbf{x}_t^i | \mathbf{x}_{t-1}^i)$ 和 $p(\mathbf{y}_t | \mathbf{x}_t^i)$ 对协方差矩阵的微分. $\frac{dz_t}{d\theta} = \frac{dz_t}{d\theta}$ 是神经网络输出对输入的梯度.

通过上述设计, 本文构建了一种 ResNet 驱动的滤波方法, 将粒子滤波的模型信息与残差神经网络的学习能力相结合, 实现端到端的联合优化. 该方法增加了粒子滤波算法在噪声协方差未知下的应用场景, 为动态系统的滤波提供了新的技术路径.

4 实验结果

4.1 实验平台

为验证所提算法的有效性, 搭建如图 2 所示的旋转导向钻井工具系统实验平台, 并进行实验验证. 该实验平台主要由永磁同步电机、振动平台、集成芯片等组成. 电机为工具面角提供旋转动力, 驱动工具面角进行旋转. 振动平台则通过模拟井下振动环境为钻井工具提供振动信号激励. 工具面角的测量通过陀螺仪和加速度计协同实现, 采用 WT9011G4K 型号的高精度 IMU (Inertial measurement unit) 传感器进行数据采集. 该传感器具备实时测量工具面角转速、角度、钻头三轴加速度及温度信号的功能, 其技术参数详见表 1. 采样频率设定为 100 Hz, 训练阶段采集的数据均通过上位机进行进一步分析和可视化. 为模拟井下工况, 振动平台以 30 Hz 的频率进行垂直方向的振动. 该实验平台的设计充分考虑井下实际工况的复杂性和多样性, 能够对旋转导向钻井工具的性能进行全面验证.




图 2 RSDTS 实验平台

Fig.2 RSDTS experimental platform

表 1 WT9011G4K 芯片参数

Table 1 Parameters of chip WT9011G4K

参数	加速度计	陀螺仪
测量范围	16 g	$\pm 4\ 000^\circ/\text{s}$
误差	0.0005 g	0.061 $^\circ/\text{s}$
温漂	+0.00015 g/ $^\circ\text{C}$	0.005($^\circ/\text{s})/^\circ\text{C}$
采样频率	5 ~ 256 Hz	5 ~ 256 Hz

旋转导向钻井工具系统原始数据集包括 100 s 内共 10 000 个数据样本, 如图 3 所示. $y_{1,k}$ 和 $y_{2,k}$ 分别表示加速度计在 y 轴和 z 轴上的测量值, 即动态系统 (2) 的输出变量; $x_{1,k}$ 代表工具面角, $x_{2,k}$ 为重力加速度分量, 它们共同构成动态系统 (2) 的状态变量. 状态 $x_{1,k}$ 的真实值由 IMU 测量得到. 由于实验中钻井工具水平放置且与地面相对静止, $x_{2,k}$ 的真实值为一个重力加速度. 输入矩阵和角速度分别为 $B = \begin{bmatrix} 0.01 \\ 0 \end{bmatrix}$, $u_k = 0.2\pi$. 首先对原始数据进行初步分析, 定义预测输出为

$$\hat{\mathbf{y}}_k = \begin{bmatrix} x_{2,k} \sin(x_{1,k}) \\ -x_{2,k} \cos(x_{1,k}) \end{bmatrix}$$

图 4 给出预测输出和实际输出的误差图像, 该图像反映了加速度计的噪声信号. 分析结果表明, RSDTS 的噪声均值为 0, 而其协方差矩阵呈现时变特性. 事实上, 不同方向的加速度计噪声协方差是与状态相关的, 并呈现出周期性的变化规律. 具体




图 3 RSDTS 数据集

Fig.3 RSDTS dataset




图 4 RSDTS 测量噪声

Fig.4 RSDTS measurement noise

而言, 当 y 轴加速度计的噪声协方差变小时, z 轴加速度计的噪声协方差会变大; 当 y 轴加速度计的噪声协方差变大时, z 轴加速度计的噪声协方差会随之变小.

训练集和测试集按照 4:1 的比例进行划分, 前 8 000 个样本被用来训练 CGAN 和 ResNet, 后 2 000 个样本用来进行测试. CGAN 的生成器输入由以下三部分组成: 服从多元高斯分布的随机变量 z , 系统输出 y_k 和前一时刻粒子状态 x_{k-1}^i , 输出为当前粒子状态 x_k^i . 生成器网络包括三个全连接层, 每层具有 64 个神经元, 且均集成批归一化层和 LeakyReLU 激活函数. 相应地, 判别器也采用三层全连接层的网络结构, 各层神经元数量与生成器一致, 并同样配备批归一化层和 LeakyReLU 激活函数. CGAN 的目标是从后验分布 $p(x_k^i | x_{k-1}^i, y_k)$ 中采样得到 x_k^i 作为下一时刻的粒子状态. ResNet 模块由 3 个相同的残差块拼接组成, 其卷积层的通道数均为 64, 且每个卷积层使用大小为 3×3 的卷积核和 LeakyReLU 激活函数. ResNet 的输入端包括 k 时刻的加速度计测量值 y_k , 粒子 $\{x_{k-1}^i\}_{i=1}^{N_s}$ 的网格化图像, 输出为协方差矩阵参数 U_{k-1} 和 V_k . 受到时序反向传播算法的影响, 每个批次的训练均在大小为 64 个时刻的连续时间段上进行, 其反向传播的梯度由式 (8) 给出. CGAN 和 ResNet 的训练批次大小都被设置为 64, 优化器使用 Adam 算法, 初始学习率设置为 0.1. 算法实现基于 pytorch 平台, 所有训练及测试均在一台配备 2.30 GHz 11th Gen Intel(R) Core(TM) i7-11800H CPU 和 RTX 3060 Laptop GPU 的计算机上完成. 由于高精度 IMU 造价昂贵且维修成本较高, 在实际应用中通常使用数字信号处理器 (Digital signal processing, DSP) 进行信号处理. 在 ResCGAN-PF 算法中, 高精度 IMU 仅用于训练神经网络模型, 而在井下环境中, 训练好的模型将利用 DSP 的测量值完成滤波任务.

4.2 实验结果

在本节中, 首先验证 ResCGAN-PF 算法相较于传统 PF 算法在粒子选择方面的显著优势. 如第 2 节所述, 通过引入生成模型, ResCGAN-PF 算法能够从近似真实的后验分布中进行粒子采样, 而传统粒子滤波算法仅依赖于先验分布采样, 这使得 CGAN-PF 算法的粒子分布更接近于真实的粒子后验分布. 为直观展示这一现象, 在包含 2 000 个数据点的测试集上进行粒子滤波实验, 对不同算法所得到的粒子分布结果进行对比.

图 5 展示了不同算法在 2 000 个采样点上的

粒子分布情况, 图 5(a) 是工具面角, 图 5(b) 是重力加速度分量. 图 6 进一步对比 4 个特定时刻 ($k = 75, 250, 500, 750$) 的粒子状态. 蓝色点集代表传统 PF 算法的粒子状态, 黄色点集代表 ResCGAN-PF 算法的粒子状态, 红色点集代表真实状态. 所有算法的粒子数都设置为 64. 实验结果表明, 传统 PF 算法中大部分粒子距离真实状态较远, 这意味着粒子选择效果欠佳. 由于传统 PF 算法并未充分利用测量的后验信息, 导致大量粒子集中于低似然区域, 出现粒子短缺现象. 接着, 由于大量粒子的权重相对较小, 这会造成计算资源的浪费, 出现粒子




图 5 粒子分布随时间变化图

Fig. 5 Particle distributions over time

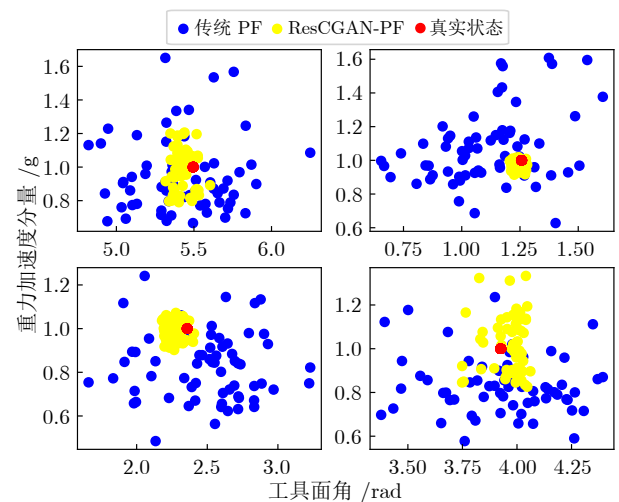


图 6 四个时刻粒子分布图

Fig. 6 Particle distributions at four time instances

退化现象. 相比之下, ResCGAN-PF 算法中粒子状态与真实状态更为接近, 粒子能够提供有效的信息. ResCGAN-PF 通过 CGAN 引导粒子集中于高似然区域, 从而能够精确描述当前状态的后验分布. 这一机制能够解决粒子退化和粒子短缺问题, 提升滤波精度.

图 7 展示了 ResCGAN-PF 算法的滤波性能. 实验结果表明, 工具面角和重力加速度分量的估计值均围绕真实值波动, 且波动幅度较小 (在可接受范围内), 验证了该算法在噪声协方差矩阵时变且未知条件下的鲁棒估计能力. 为系统评估算法性能, 本研究设计两组对比实验: 第 1 组通过与传统粒子滤波 (PF), 遗传粒子滤波 (Genetic PF, GPF) 和变分自编码器粒子滤波 (CVAE-PF) 进行对比, 验证改进粒子选择策略的有效性; 第 2 组通过与变分贝叶斯粒子滤波 (VB-PF) 和期望最大化扩展卡尔曼滤波 (EM-EKF) 的对比分析, 重点评估所提方法在处理时变噪声协方差矩阵方面的显著优势. 对比算法的简单介绍如表 2 所示.

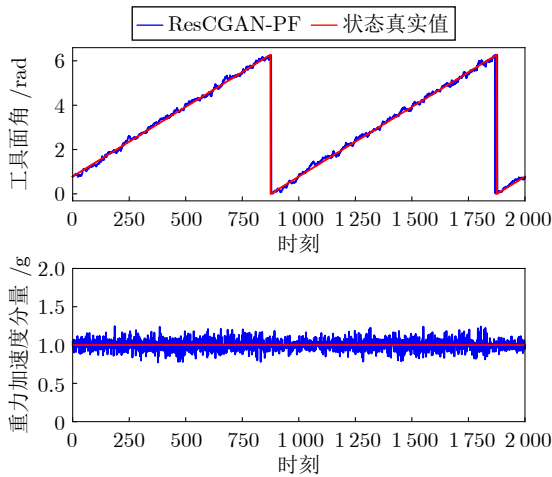


图 7 ResCGAN-PF 估计结果

Fig.7 Estimation results of ResCGAN-PF

表 2 各种粒子滤波算法对比

Table 2 Comparison of particle filtering algorithms

算法名称	算法特点
PF ^[6]	使用重采样技术来缓解粒子退化问题, 是粒子滤波领域的基础方法
GPF ^[8]	引入交叉和变异操作来动态调节粒子状态分布, 以解决粒子短缺问题
CVAE-PF ^[14]	将条件变分自编码器引入粒子滤波框架, 利用其生成能力引导粒子状态分布
VB-PF ^[17]	假设过程噪声协方差矩阵已知, 利用 VB 算法对测量噪声协方差矩阵进行自适应估计
EM-EKF ^[15]	对系统进行线性化处理, 使用 EM 算法对过程和测量噪声协方差进行联合估计

由于第 1 组算法未能处理噪声协方差矩阵时变未知的情形, 将算法中的过程噪声设置为 $R_k = 0.1\mathbf{I}$, $Q_k = \mathbf{I}$, \mathbf{I} 为单位矩阵. GPF 中的变异参数设置为 0.1, CVAE-PF 中 CVAE 的网络设计与文献 [13] 保持一致. 图 8 给出不同算法的估计误差, 其计算式为

$$e_k = \|\mathbf{x}_k - \hat{\mathbf{x}}_k\|^2$$

从实验结果可以看出, 在所有对比的算法中, 所提 ResCGAN-PF 算法具有最小的估计误差. 由于角度值限制在 $[0, 2\pi]$ 的范围内, 因此工具面角每转一周时, 估计误差会产生周期性突变. 受取模运算的影响, 工具面角在 2π 附近时估计误差会失真, 精度高的算法会短暂出现较大的估计误差. 其他时刻的估计误差能够反映算法的真实精度. 在第 1 组实验中, CVAE-PF 算法与 ResCGAN-PF 算法均通过生成模型改进粒子选择策略. 然而, CVAE 结构仅能优化粒子分布, 无法直接参与粒子权重的计算, 而 CGAN 框架中的判别器可以为粒子权重的更新提供有效信息, 这使得 ResCGAN-PF 算法与粒子滤波框架具有更好的适配性. 与传统 PF 算法相比, GPF 算法通过遗传操作改善粒子多样性, 因此具有更低的估计误差. 但由于遗传算法缺乏可靠的理论基础, 且未能从根本上改变粒子状态的采样分布, 其估计效果劣于基于生成模型的智能算法.

图 9 给出了 ResCGAN-PF 算法和现有自适应滤波算法的估计误差. VB-PF 算法中的过程噪声协方差矩阵设定为 $0.1\mathbf{I}$, 测量噪声协方差矩阵初始值为 \mathbf{I} 并基于变分贝叶斯算法进行迭代更新. 然而, VB-PF 算法未包含对过程噪声协方差矩阵的自适应更新机制, 且未能充分考虑噪声协方差矩阵的时变特性. 这些缺陷导致 VB-PF 算法在处理 RSDTS 的滤波问题时性能次于所提 ResCGAN-PF 算法. 对于 EM-EKF 算法, 其噪声协方差矩阵的更新依




图 8 不同算法的估计误差 (第 1 组)

Fig.8 Estimation errors of different algorithms in Group 1

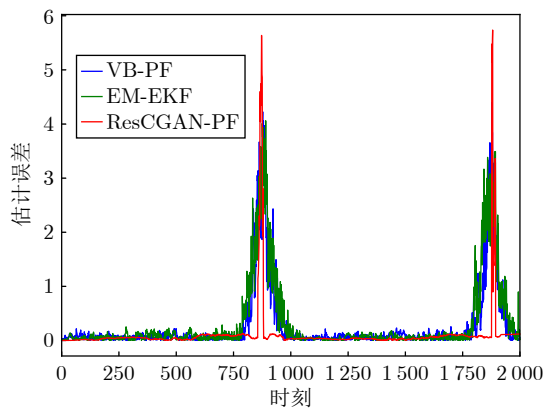


图 9 不同算法的估计误差 (第 2 组)

Fig.9 Estimation errors of different algorithms in Group 2

赖于对系统非线性函数的一阶线性化近似。对于具有强非线性的系统, EM 算法对于噪声协方差矩阵的估计精度较低。而 RSDTS 的输出函数包含正弦和余弦函数, 从而导致 EM-EKF 的滤波性能较差。相比之下, ResCGAN-PF 算法得益于粒子滤波对于非线性的拟合优势, 能够克服线性化方法的局限性。经过上述分析, ResCGAN-PF 算法使用生成模型引导的粒子选择策略, 并且对噪声协方差矩阵具有动态估计能力。上述技术优势能够较好地解决复杂工况下 RSDTS 的工具面角测量问题。


5 结束语

针对旋转导向钻井工具系统的工具面角实时测量难题, 本文提出基于深度学习的智能粒子滤波算法。通过构建条件生成对抗网络引导的粒子选择机制和深度残差网络协方差矩阵估计器, 形成端到端的闭环优化系统, 有效解决了粒子退化和噪声协方差时变等关键科学问题。实验结果表明, 所提算法在粒子状态选择和工具面角估计方面均展现出显著优势, 相比同类算法具有更高的估计精度。本文下一步工作将研究奇异系统的智能粒子滤波算法, 进而解决 RSDTS 中的故障检测与估计等问题。

References

- Sheng Li, Niu Yi-Chun, Liu Shi-Yang, Wang Wei-Liang, Gao Ming, Zhou Dong-Hua. Incipient fault detection of rotary steerable drilling tool equipment. *Scientia Sinica Informationis*, 2022, **52**(11): 2106–2120 (盛立, 牛艺春, 刘诗洋, 王伟亮, 高明, 周东华. 旋转导向钻井工具装备的微小故障检测. *中国科学: 信息科学*, 2022, **52**(11): 2106–2120)
- Xue Q L, Wang R H, Sun F, Huang L L, Han L J. Continuous measurement-while-drilling utilizing strap-down multi-model surveying system. *IEEE Transactions on Instrumentation and Measurement*, 2014, **63**(3): 650–657
- Sheng L, Niu Y, Wang W L, Gao M, Geng Y F, Zhou D H. Estimation of Toolface for dynamic point-the-bit rotary steerable systems via nonlinear polynomial filtering. *IEEE Transactions on Industrial Electronics*, 2022, **69**(7): 7192–7201
- Niu Y, Sheng L, Gao M, Wang Y C, Zhou D H. Variational Bayesian-based moving horizon estimation of Toolface for rotary steerable drilling tool systems. *IEEE Transactions on Industrial Electronics*, 2023, **70**(1): 813–823
- Sheng L, Niu Y C, Gao M, Geng Y F, Zhou D H. Particle filter-based fault detection for Toolface measurement of rotary steerable systems. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3519511
- Arulampala M S, Maskell S, Gordon N, Clapp T. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. *IEEE Transactions on Signal Processing*, 2002, **50**(2): 174–188
- Liu J S, Chen R. Sequential Monte Carlo methods for dynamic systems. *Journal of the American Statistical Association*, 1998, **93**(443): 1032–1044
- Yin S, Zhu X P. Intelligent particle filter and its application to fault detection of nonlinear system. *IEEE Transactions on Industrial Electronics*, 2015, **62**(6): 3852–3861
- Tian Meng-Chu, Bo Yu-Ming, Chen Zhi-Min, Wu Pan-Long, Zhao Gao-Peng. Firefly algorithm intelligence optimized particle filter. *Acta Automatica Sinica*, 2016, **42**(1): 89–97 (田梦楚, 薄煜明, 陈志敏, 吴盘龙, 赵高鹏. 萤火虫算法智能优化粒子滤波. *自动化学报*, 2016, **42**(1): 89–97)
- Li T C, Sun S D, Sattar T P, Corchado J M. Fight sample degeneracy and impoverishment in particle filters: A review of intelligent approaches. *Expert Systems With Applications*, 2014, **41**(8): 3944–3954
- Zhang Wen-An, Lin An-Di, Yang Xu-Sheng, Yu Li, Yang Xiao-Niu. A survey on Bayesian filtering with deep learning. *Acta Automatica Sinica*, 2024, **50**(8): 1502–1516 (张文安, 林安迪, 杨旭升, 俞立, 杨小牛. 融合深度学习的贝叶斯滤波综述. *自动化学报*, 2024, **50**(8): 1502–1516)
- Ma M, Fu L, Zhai Z, Sun R B. Transformer based Kalman filter with EM algorithm for time series prediction and anomaly detection of complex systems. *Measurement*, 2024, **229**: Article No. 114378
- Qian Y N, Yan R Q. Remaining useful life prediction of rolling bearings using an enhanced particle filter. *IEEE Transactions on Instrumentation and Measurement*, 2015, **64**(10): 2696–2707
- Jiao R H, Peng K X, Dong J. Remaining useful life prediction of lithium-ton batteries based on conditional variational autoencoders-particle filter. *IEEE Transactions on Instrumentation and Measurement*, 2020, **69**(11): 8831–8843
- Huang Y, Zhang Y, Xu B, Wu Z, Chambers A. A new adaptive extended Kalman filter for cooperative localization. *IEEE Transactions on Aerospace and Electronic Systems*, 2018, **54**(1): 353–368
- Niu Y, Sheng L, Gao M, Zhou D H. Moving horizon estimation for stochastic descriptor systems with inaccurate noise covariance matrices. *IEEE Transactions on Industrial Electronics*, 2024, **71**(8): 9530–9540
- Li K, Zhao S Y, Liu F. Joint state estimation for nonlinear state-space model with unknown time-variant noise statistics. *International Journal of Adaptive Control and Signal Processing*, 2021, **35**(4): 498–512
- Bertipaglia A, Alirezaei M, Happee R, Shyrokau B. An unscented Kalman filter-informed neural network for vehicle sideslip angle estimation. *IEEE Transactions on Vehicular Technology*, 2024, **73**(9): 12731–12746
- Zhang Y P, Huang Y F, Deng K, Shi B F, Wang X Y, Li L, et al. Vehicle dynamics estimator utilizing LSTM-ensembled adaptive Kalman filter. *IEEE Transactions on Industrial Electronics*, 2025, **72**(5): 5429–5439
- Zeng G X, Wu H, Chen S X, Yang M B. Modified Swin Transformer-based continuous-discrete extended Kalman filtering for bearings-only tracking with unknown noise statistics. *IEEE Sensors Journal*, 2025, **25**(3): 9842–9852
- Ahwiadi M, Wang W. An adaptive particle filter technique for system state estimation and prognosis. *IEEE Transactions on Instrumentation and Measurement*, 2020, **69**(9): 6756–6765


- 22 Wang Kun-Feng, Gou Chao, Duan Yan-Jie, Lin Yi-Lun, Zheng Xin-Hu, Wang Fei-Yue. Generative adversarial networks: The state of the art and beyond. *Acta Automatica Sinica*, 2017, **43**(3): 321-332
(王坤峰, 苟超, 段艳杰, 林懿伦, 郑心湖, 王飞跃. 生成式对抗网络 GAN 的研究进展与展望. 自动化学报, 2017, **43**(3): 321-332)
- 23 Liu Jian-Wei, Xie Hao-Jie, Luo Xiong-Lin. Research progress on application of generative adversarial networks in various fields. *Acta Automatica Sinica*, 2020, **46**(12): 2500-2536
(刘建伟, 谢浩杰, 罗雄麟. 生成对抗网络在各领域应用研究进展. 自动化学报, 2020, **46**(12): 2500-2536)
- 24 Hu Ming-Fei, Zuo Xin, Liu Jian-Wei. Survey on deep generative model. *Acta Automatica Sinica*, 2022, **48**(1): 40-74
(胡铭菲, 左信, 刘建伟. 深度生成模型综述. 自动化学报, 2022, **48**(1): 40-74)



盛立 中国石油大学(华东)控制科学与工程学院教授. 2010年获得江南大学博士学位. 主要研究方向为随机控制与滤波, 网络化控制系统以及现代系统的故障检测与诊断.

E-mail: shengli@upc.edu.cn

(**SHENG Li** Professor at the College of Control Science and Engineering, China University of Petroleum (East China). He received his Ph.D. degree from Jiangnan University in 2010. His research interest covers stochastic control and filtering, networked control systems, and fault detection and diagnosis for modern systems.)



刘一凡 中国石油大学(华东)控制科学与工程学院博士研究生. 主要研究方向为随机系统的滤波与故障诊断.

E-mail: b24050007@s.upc.edu.cn

(**LIU Yi-Fan** Ph.D. candidate at the College of Control Science and

Engineering, China University of Petroleum (East China). His research interest covers filtering and fault diagnosis for stochastic systems.)



高明 中国石油大学(华东)控制科学与工程学院教授. 2009年获得江南大学博士学位. 主要研究方向为网络化控制系统的鲁棒控制与故障诊断. E-mail: gaoming@upc.edu.cn

(**GAO Ming** Professor at the College of Control Science and Engineering, China University of Petroleum (East China). She received her Ph.D. degree from Jiangnan University in 2009. Her research interest covers robust control and fault diagnosis for networked control systems.)



周东华 东南大学自动化学院教授. 1990年获得上海交通大学博士学位. 主要研究方向为动态系统的故障诊断与容错控制, 故障预测与最优维护技术. 本文通信作者.

E-mail: zdh@tsinghua.edu.cn

(**ZHOU Dong-Hua** Professor at the School of Automation, Southeast University. He received his Ph.D. degree from Shanghai Jiao Tong University in 1990. His research interest covers fault diagnosis, fault-tolerant control, fault prediction, and optimal maintenance for dynamic systems. Corresponding author of this paper.)