

分类号: TM73  
密 级: 公开

学校代码: 10363  
学 号: 2220320167



安徽工程大学

Anhui Polytechnic University

# 硕士学位论文

题 目 基于PMU和SCADA数据融合的  
电力系统状态估计

|           |          |
|-----------|----------|
| 论 文 作 者   | 朱家明      |
| 校 内 导 师   | 高文根      |
| 校 外 导 师   | 许兴林      |
| 专业学位类别    | 电子信息     |
| 研究方向 (领域) | 多传感器信息融合 |

论文提交日期: 2025 年 5 月 13 日

---

分类号: TM73

单位代码: 10363

密 级: 公开

学 号: 2220320167

题 目 基于 PMU 和 SCADA 数据融合的电力系统状态估计

题 目 Power System State Estimation Based on PMU and  
SCADA Data Fusion

论文作者: 朱家明

校内导师: 高文根教授

校外导师: 许兴林

专 业: 电子信息

研究方向: 多传感器信息融合

论文答辩日期: 2025 年 4 月 29 日

---

## 安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：朱永明

日期：2025 年 4 月 29 日

## 安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 \_\_\_\_ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：朱永明 指导教师签名：高根根

日期：2025 年 4 月 29 日 日期：2025 年 4 月 29 日

# 基于 PMU 和 SCADA 数据融合的电力系统状态估计

## 摘要

状态估计作为智能电网实时分析与控制的核心环节，其主要作用在于提升量测数据的准确性，识别并监测异常数据，同时对电网状态进行估算和预测。随着相量量测单元(Phasor Measurement Unit, PMU)技术的快速发展，其在电网中的应用日益广泛。然而，由于经济成本高昂及技术改造复杂，短期内配电网难以实现 PMU 全面覆盖，因此，在未来可预测的时间内，配电网将依赖 PMU 与数据采集与监视控制系统(Supervisory Control and Data Acquisition, SCADA)的混合数据进行状态估计。与 SCADA 相比，PMU 具备更快的采样频率、更高的测量精度，因此，如何有效融合两者异质数据实现电网状态精准估计，成为了一个具有挑战性的问题。在此背景下，针对不同采样速率比约束，本文提出了两种数据融合状态估计方法，主要内容概述如下：

(1)构建电力系统状态估计模型。基于交流潮流方程建立电力系统状态估计的模型，并对传统加权最小二乘（Weighted Least Squares, WLS）方法与卡尔曼滤波(Kalman Filter, KF)方法进行了对比分析。针对电力系统固有非线性特性，选取了扩展卡尔曼滤波（Extended Kalman filter, EKF）建立电力系统状态估计模型，相比 WLS 方法依赖非线性迭代过程，EKF 更满足对 PMU 高频采样数据的处理需求。通过对多传感器数据融合模型的分析，将 PMU 与 SCADA 数据融合

等效为多传感器数据融合问题的一个特例，为后续算法设计提供了理论基础。

(2)针对 PMU 和 SCADA 量测数据采样速率比为整数的场景，提出了一种基于 Holt-EKF 数据融合的状态估计策略。首先，在假设 PMU 与 SCADA 采样速率比为正整数的条件下，根据 PMU 和 SCADA 的采样速率，定义一个固定窗口大小和移动步长的滑动窗口；其次，利用 Holt-EKF 方法对窗口内 SCADA 数据在非采样时刻的状态值进行估计，使其与窗口内 PMU 数据的状态值相匹配；最后，根据 MMSE(Minimum Mean Square Error, MMSE)准则对相同时刻的 PMU 和 SCADA 状态估计值进行加权融合，得到最优融合估计。在 IEEE-14 节点系统中进行仿真测试，结果证明了该算法的有效性。

(3)针对 PMU 和 SCADA 量测数据采样速率比为非整数的场景，提出了一种基于平均 KL 散度(Kullback Leibler Average, KLA)数据融合的状态估计方法。首先，利用电网电压、电流转换基本原理，建立 PMU 与 SCADA 的混合观测方程；其次，收集观测周期内的 PMU 和 SCADA 的混合数据，利用 KLA 算法近似混合数据的概率分布模型；最后，基于混合观测方程和近似概率分布模型，利用信息滤波器算法估计融合后的电网状态。在 IEEE-14 节点和 IEEE-30 节点系统中进行仿真测试，结果证明了该算法的有效性。

**关键词：**智能电网，多速率数据融合，平均 KL 散度，扩展卡尔曼滤波，状态估计

# Power System State Estimation Based on PMU and SCADA Data Fusion

## ABSTRACT

State estimation serves as a core component of real-time analysis and control in smart grids, primarily aimed at enhancing the accuracy of measurement data, identifying and monitoring abnormal data, and estimating and predicting grid states. With the rapid development of Phasor Measurement Unit (PMU) technology, its application in power grids has become increasingly widespread. However, due to high economic costs and complex technical modifications, achieving full PMU coverage in distribution networks remains challenging in the short term. Consequently, for the foreseeable future, state estimation in distribution networks will rely on hybrid data from PMU and Supervisory Control and Data Acquisition (SCADA) systems. Compared to SCADA, PMU offers a higher sampling frequency and greater measurement accuracy. Therefore, effectively integrating heterogeneous data from both systems to achieve accurate state estimation has become a significant challenge. Against this background, this paper proposes two data fusion-based state estimation methods under different sampling rate ratio constraints. The main research contents are summarized as follows:

- (1) Construction of a power system state estimation model. A state

estimation model for power systems is established based on the AC power flow equations. A comparative analysis of the traditional Weighted Least Squares (WLS) method and the Kalman Filter (KF) method is conducted. Given the inherent nonlinearity of power systems, this study selects the Extended Kalman Filter (EKF) method. Compared to the WLS method, which relies on a nonlinear iterative process, EKF is better suited for processing high-frequency PMU data. Through an analysis of multi-sensor data fusion models, it is determined that PMU and SCADA data fusion can be regarded as a special case of multi-sensor data fusion, providing a theoretical foundation for subsequent algorithm design..

(2) A state estimation strategy based on Holt-EKF data fusion is proposed for the scenario where the sampling rate ratio of PMU and SCADA measurement data is an integer multiple. Firstly, under the assumption that the PMU and SCADA sampling rates are positive integer multiples, a sliding window with a fixed window size and moving step is defined based on the PMU and SCADA sampling rates; secondly, the Holt-EKF method is utilized to predict the state values of the SCADA data in the window at the non-sampling moments to match the state values of the PMU data in the window; and finally. The PMU and SCADA state estimates at the same moments are weighted and fused according to the MMSE (Minimum Mean Square Error, MMSE) criterion to obtain the optimal fusion estimate. The effectiveness of the algorithm is finally

verified on an IEEE-14 bus system.

(3) State estimation strategy based on Kullback-Leibler Average (KLA) data fusion for non-integer multiple sampling rate ratios of PMU and SCADA. First, a hybrid observation equation for PMU and SCADA is established based on fundamental voltage and current transformation principles. Second, PMU and SCADA hybrid data within the observation period are collected, and the KLA algorithm is used to approximate the probability distribution model of the mixed data. Finally, based on the hybrid observation equation and the approximate probability distribution model, the information filter algorithm is employed to estimate the fused grid state. Simulation tests conducted on the IEEE-14 and IEEE-30 bus systems demonstrate the effectiveness of the proposed algorithm.

**KEY WORDS:** Smart grid, multi-rate data fusion, Kullback-Leibler Average, Extended Kalman Filter, state estimation

## 目录

|                                     |     |
|-------------------------------------|-----|
| 摘要.....                             | I   |
| ABSTRACT.....                       | III |
| 第 1 章 绪论.....                       | 1   |
| 1.1 课题研究背景及意义.....                  | 1   |
| 1.2 国内外研究现状.....                    | 3   |
| 1.2.1 状态估计研究现状 .....                | 3   |
| 1.2.2 多传感器融合算法研究现状 .....            | 5   |
| 1.2.3 混合量测状态估计研究现状 .....            | 7   |
| 1.3 主要研究内容及创新点.....                 | 8   |
| 第 2 章 电力系统状态估计理论基础和模型分析.....        | 11  |
| 2.1 引言.....                         | 11  |
| 2.2 电力系统状态估计数学模型.....               | 11  |
| 2.2.1 量测系统的数学模型 .....               | 11  |
| 2.2.2 电力网络的数学模型 .....               | 12  |
| 2.2.3 电力系统状态估计方法.....               | 13  |
| 2.3 多传感器数据融合的数学模型.....              | 19  |
| 2.4 本章小结.....                       | 23  |
| 第 3 章 面向整数倍采样速率比数据融合的状态估计 .....     | 24  |
| 3.1 引言.....                         | 24  |
| 3.2 PMU 布置策略的分析 .....               | 24  |
| 3.3 基于 Holt-EKF 数据融合的电力系统状态估计 ..... | 28  |
| 3.3.1 滑动窗口方法 .....                  | 28  |
| 3.3.2 基于 Holt-EKF 的电力系统状态估计 .....   | 30  |
| 3.3.3 基于 MMSE 的状态估计加权优化 .....       | 35  |
| 3.4 仿真实验与结果分析.....                  | 37  |
| 3.4.1 仿真系统 .....                    | 37  |

|                                 |    |
|---------------------------------|----|
| 3.4.2 仿真数值分析 .....              | 39 |
| 3.5 本章小结.....                   | 41 |
| 第 4 章 面向非整数倍采样速率比数据融合的状态估计..... | 42 |
| 4.1 引言.....                     | 42 |
| 4.2 传感器融合结构分析.....              | 42 |
| 4.2.1 集中式融合结构 .....             | 43 |
| 4.2.2 分布式融合结构 .....             | 43 |
| 4.2.3 混合式融合结构 .....             | 44 |
| 4.3 基于 KLA 数据融合的电力系统状态估计.....   | 46 |
| 4.3.1 PMU 和 SCADA 差异性研究.....    | 46 |
| 4.3.2 KLA 数据融合算法 .....          | 49 |
| 4.3.3 基于信息滤波的电力系统状态估计 .....     | 53 |
| 4.4 仿真实验和结果分析.....              | 57 |
| 4.4.1 仿真系统 .....                | 57 |
| 4.4.2 仿真数值分析 .....              | 57 |
| 4.5 本章小结.....                   | 63 |
| 第 5 章 总结与展望.....                | 64 |
| 5.1 总结.....                     | 64 |
| 5.2 展望.....                     | 65 |
| 参考文献.....                       | 66 |
| 攻读硕士期间取得的学术成果.....              | 73 |
| 致谢.....                         | 74 |

## 第 1 章 绪论

### 1.1 课题研究背景及意义

作为国民经济发展的核心要素，电力资源不仅是国家能源战略体系的关键组成部分，更是现代化社会运转的基础保障与核心驱动力承。电网运行的稳定性对经济稳健增长与社会和谐发展具有重要影响。值得关注的是，随着能源技术革新与产业转型升级，现代电网逐步形成多层级结构，分布式能源设备广泛布设，加上电动汽车等波动性负荷并网规模持续扩大，使得电网运行模式呈现高度异构化特征，系统安全稳定运行的潜在威胁因素显著增多。与此同时，由于多个区域电网的互联性提高，局部的故障可能波及整个电力系统的安全运行，严重的扰动甚至可能导致大范围停电或系统失去供电功能，这对电力系统的稳定性提出了极大的挑战<sup>[1-2]</sup>。

智能电网作为现代能源系统的关键载体，通过数字化升级实现电力网络智能化运行。其技术体系覆盖电力生产、传输、转换、分配及终端消费的全过程，并集成了现代信息通信、传感测量、智能调控与优化决策等核心技术。该系统旨在构建具备高可靠性、强安全性、经济运行、能效优化及低碳环保特征的智慧能源网络<sup>[3-5]</sup>。通过多源信息融合与协同控制，智能电网实现了能源从生产到消费的实时互动与协同优化，从而显著提升了能源系统的动态响应能力和运营效率。

为了确保智能电网的稳定运行，必须依赖更先进的技术及设备，这要求调度系统能够实时获取数据，优化电力市场配置，以适应市场竞争。智能电网不仅需要满足大型发电厂的电力需求，还需支持分布式小电源的接入。因此，能量管理系统(Energy Management System, EMS)必须实时、准确地获取系统运行状态，提前预测潜在的安全风险，并为系统提供精准的控制策略。作为 EMS 的核心技术之一，状态估计在实现数据滤波和动态监控中发挥着关键作用，其精度直接关系到数据质量与控制决策的有效性<sup>[6]</sup>。

构建电力系统的监控与分析体系是确保系统安全、经济运行的关键。这一

体系依赖于可靠的实时数据。获取实时数据主要有两种方式：一是通过增加测量点以提升测量精度和速度，二是在状态估计过程中执行新的优化算法对量测数据进行实时处理。状态估计是电力系统调度中心的核心功能之一，通过综合各类测量数据，精确估算当前系统运行状态，为 EMS 的高级应用提供全面、可靠且精准的数据支持<sup>[7-9]</sup>。作为电网的智能中枢，EMS 依托全域调控实现安全运行、供电质量保障以及经济环保等多重目标。在能源互联网建设与新型电力系统发展的背景下，状态估计作为数据处理核心技术，对实现全节点监测目标具有不可替代的支撑作用<sup>[10]</sup>。该技术体系既为 EMS 的智能化调度决策构建了精准的数据基底，又通过预防性态势推演与自适应控制优化形成多维数据闭环，为 EMS 各层级高级功能模块的稳健运行构筑了技术基石。

传统的状态估计方法依赖 SCADA 系统获取基础数据，借助计算机、控制、通信及网络技术，SCADA 系统能够实现对电网所有测量节点数据的实时采集和传输，其核心功能包括节点电压幅值监测、支路有功与无功功率计量、负荷功率追踪以及开关量状态识别，并通过通信网络将数据汇聚到 EMS 的中央监控平台<sup>[11-13]</sup>。随着全球卫星定位系统(Global Positioning System, GPS)与北斗导航系统的成熟应用，再加上计算机算法与数字通信技术获得突破性进展，使得 PMU 逐渐出现在配电网中。PMU 不仅具备高精度的同步量测能力，理论上仅需 PMU 数据即可构建完整的电网可观测模型并执行线性状态估计，而且具有快速采样频率，每秒可提供 30~60 个测量样本<sup>[14]</sup>。相比之下，电力系统中的传统测量系统，如基于(Remote Terminal Unit, RTU)的 SCADA 系统，每秒提供 1-2 个测量样本的速率要低得多<sup>[15]</sup>。随着 PMU 被公认为未来电网的关键组成部分，正在逐渐取代传统的 SCADA 系统。尽管 PMU 相对于 SCADA 系统具有一定的优势，但在短期内完全取代传统的 SCADA 系统仍面临巨大挑战。

这一问题主要源于大多数电力系统长期以来对 SCADA 系统的依赖，以及企业对 SCADA 基础设施进行了大量投资。此外，现有的 SCADA 系统在电力系统中运行稳定，没有重大问题或缺陷，因此全面更换将带来巨大的经济风险和损失。由此，短期内 PMU 和传统的 SCADA 系统将在电网内共存<sup>[16-17]</sup>，这就产生了一个复杂的场景：需要利用拥有着不同采样速率的 PMU 和 SCADA，共同

对电网状态进行实时监测和估计。

综上所述，电力系统混合状态估计策略的研究正逐渐成为热点。目前大多混合估计方法仅简单地将 PMU 数据嵌入 SCADA 框架，未能充分发挥 PMU 高频采样所带来的优势，导致实时性与精度受限。因此，如何在保证引入高精度 PMU 数据的同时，有效融合 PMU 与 SCADA 系统的数据，从而提高整体状态估计的准确性，对维持电力系统稳定性具有重要意义。

## 1.2 国内外研究现状

### 1.2.1 状态估计研究现状

电力系统状态估计(Power System State Estimation, PSSE)是现代电网智能化管理的关键技术之一。通过整合多元量测信息(如电压、电流、功率等)来估计电网的整体状态，以便于实时监控和优化电网运行。一方面，电网中的绝大部分在线分析功能，如调度员潮流计算、安全评估、电压自动调节等，均需以状态估计生成的动态潮流模型作为输入基准；另一方面，系统将周期性状态估计结果持久化存储于历史数据库，为离线稳定计算、机组组合优化、检修策略制定及调度方案验证等离线分析任务提供数据支撑<sup>[18-19]</sup>。由此可见，作为衔接电网底层量测数据与上层 EMS 高级功能的核心组件，状态估计构成了整个能量管理系统的运行基础。

静态状态估计(Static State Estimation, SSE)是电力系统状态估计的一种基本形式，主要用于估计电力系统在某一特定时刻的稳态工作条件。它的核心目标是提供一个快照，展示电网在静态条件下的电压幅值和相角分布。SSE 主要处理的是静态数据，如电压、电流、有功和无功功率等，在某一特定时刻的测量值。虽然处理的是静态数据，但这些数据通常需要实时收集，用于监控电网的当前状态<sup>[20-22]</sup>。随着社会的快速发展，人们对于电力资源的需求也越来越大，电力系统的规模逐渐扩大，发电机组增大，使得电力系统变得非常庞大，此时静态估计将消耗大量的资源和时间，于是便展开了对动态状态估计(Dynamic State Estimation, DSE)的研究<sup>[23]</sup>，电力系统动态估计主要是指在系统运行过程中，

利用实时采集的测量数据和动态模型，对系统内部状态(如发电机的转子角、转速、励磁状态等动态变量)进行实时估计的一种方法。该方法能够反映出系统在各种扰动下的动态响应，为系统的安全稳定运行提供实时支持，更适用于应对系统突发事件，如故障诊断、暂态稳定性分析及在线监测等场合，进行快速响应和调节。此外，静态估计一般采用功率流方程建立非线性代数方程模型，求解方法多为最小二乘法等数值算法；而动态估计需要建立描述系统动态行为的微分方程或差分方程模型(例如发电机动态模型、控制系统模型等)，多数情况下采用卡尔曼滤波及其它拓展形式进行估计<sup>[24]</sup>，具体静态估计和动态估计的区别如表 1-1 所示

表 1-1 动态估计与静态估计区别

| 类型   | 时间尺度   | 主要算法                | 响应速度              | 应用场景          |
|------|--------|---------------------|-------------------|---------------|
| 静态估计 | 长期稳定状态 | 最小二乘法、<br>牛顿-拉夫森    | 长期的系统状态<br>评估     | 常规调度、<br>稳态评估 |
| 动态估计 | 实时动态   | 扩展卡尔曼滤波、<br>无迹卡尔曼滤波 | 快速响应系统突<br>发事件和扰动 | 故障诊断、<br>在线监控 |

20 世纪 60 年代末，徐怀丕等人对于电力系统状态估计问题，提出了加权最小二乘法状态估计(Weighted Least Squares, WLS)，该方法是最基础的静态估计算法，通过构建残差加权平方和最小的目标函数，奠定了静态估计的数学基础<sup>[25-26]</sup>。尽管 WLS 方法在收敛性和精度方面表现优异，但其在大规模电网应用中面临雅可比矩阵重复计算带来的运算负荷问题。针对此瓶颈，文献[25]创新性地融合鲁棒估计理论，引入分段线性权重函数构建变权迭代机制。该改进方案通过残差反馈动态调整权重系数，在迭代过程中同步实现异常数据辨识与状态量修正，有效抑制了不良数据对估计过程的干扰影响。近年来，卡尔曼滤波的研究逐渐增多，其主要原因在于卡尔曼滤波能够实时提供状态估计结果。在标准卡尔曼滤波(Kalman Filter, KF)的基础上，许多改进算法相继提出，如扩展卡尔曼滤波(Extended Kalman Filter, EKF)和无迹卡尔曼滤波(Unscented Kalman Filter, UKF)，这些算法更适用于非线性系统。文献[27]针对 PMU 的电力系统状态估计问题，EKF 算法的工程适用性。研究通过构建电力系统仿真模型，评估了 EKF 在不同情况下的状态估计鲁棒性，证明了该算法在复杂条件下，误

差波动较小，且对采样频率变化不敏感，展现出较好的适应性。随着人工智能技术的快速发展，将人工智能技术融入电网的研究正在日益兴起，文献[28]提出了一种基于深度学习的对于相关性的分析，通过神经网络自动识别与其高度关联的量测数据，构建分区优化的分布式状态估计模型，显著提升了系统的容错性与实时性。

### 1.2.2 多传感器融合算法研究现状

为实现监测对象特征的有效辨识与感知，物联网系统依据分布式监测节点集构建数据采集网络，通过多传感器数据协同处理机制提升监测效能与评估准度。具体而言，由不同传感器构成的智能感知体系，通过时空协同观测获取目标多模态参数，经数据清洗、特征提取与信息关联等处理流程，最终形成具有更高置信度的综合研判结论<sup>[29-30]</sup>。值得关注的是，多源数据融合理论的发展可追溯至上世纪 70 年代军事传感技术创新，美国海军在水下声纳阵列协同定位研究中首次验证了分布式信号融合对潜艇轨迹追踪的有效性<sup>[31-33]</sup>。这一突破性进展促使传感器融合技术快速渗透至多个应用维度，不仅在战场态势感知(如战术制导优化、敌我识别强化、战略预警系统)中发挥关键作用，更在民用领域(包括智能交通监控、环境参数反演、工业过程诊断等方面)展现出显著的应用价值<sup>[34]</sup>。

多传感器数据融合技术作为现代状态估计领域的重要方法，采用多维度信息整合策略对异构传感器数据进行协同处理。相较于单传感器系统，该技术通过时空关联分析与特征互补机制，在提升数据置信度与信息完备性方面展现出显著优势<sup>[35-37]</sup>。具体而言，其技术价值主要体现在：增强对动态目标的连续追踪能力、降低观测不确定性、拓展系统时空感知维度，同时通过分布式计算架构优化通信资源消耗。研究证实，融合系统在估计精度、鲁棒性及可推理性等核心指标上均超越单一传感器性能极限，现已成为智能感知领域的关键技术<sup>[38-39]</sup>。当多个传感器同时监控同一随机系统的状态时，如何选择合适的融合架构用来处理观测信息，成为设计融合估计系统的关键问题。目前，融合理论主要提供两种方案：集中式融合和分布式融合，接下来将对这两种方法进行详

细阐述。




图 1-1 集中式融合状态估计示意图

在集中式融合结构中，传感器数据融合的节点在融合中心，融合中心将来自所有传感器的观测数据合并，得到一个扩维的观测向量，再结合系统模型的状态方程，对系统状态进行估计<sup>[40-43]</sup>。图 1-1 展示了集中式融合的结构。该方案的核心优势在于能够全面整合各传感器的监测信息，通过最大化数据完整性实现全局最优的测算精度。但是，该模式需要满足两个严格的条件：所有监测设备须持续保持稳定运行状态，同时大量观测数据的高速传输将显著消耗通信带宽，导致网络负载骤增与计算需求高度膨胀，这种理想化假设与实际工程场景存在适配性不足的问题<sup>[44]</sup>。




图 1-2 分布式融合状态估计示意图

在分布式融合结构中，各个传感器先在局部利用自身的观测信息进行滤波，得到局部的状态估计，然后根据一定的最优融合准则，在融合中心对局部估计

进行融合，以得到全局最优或次优的状态估计值<sup>[45]</sup>。分布式融合结构如图 1-2 所示，分布式融合结构将融合节点扩展成几个中间节点，并行的结构不仅提高了数据传输的速率，降低了融合中心对通信能力和存储空间的要求，也有利于传感器的故障监测和隔离，具有较高的可靠性和延续性<sup>[46]</sup>。不足之处在于，分布式融合的估计精度不如集中式融合结构的估计精度高<sup>[47]</sup>。

### 1.2.3 混合量测状态估计研究现状

状态估计技术作为电网运行监测的重要手段，能够准确呈现电网实时运行状态，既是智能电网管理系统的核心模块，也是保障电力系统稳定运行的关键支撑环节。传统估计策略主要依托 SCADA 系统采集的电力参数监测信息构建电网模型，在过去的很长一段时间中，SCADA 系统发展迅速，在电力行业中得到了广泛运用，几乎所有的 EMS 都集成了 SCADA 装置<sup>[48-51]</sup>，通过部署在远程的大量 RTU 装置收集各个总线的电压、注入功率和电流值，并将这些数据传输到中央终端单元进行状态估计，然而在 SCADA 系统中可用的数据采集往往表现的相对缓慢。

随着广域测量系统(Wide Area Measurement System, WAMS)的推广应用，基于卫星授时的 PMU 逐步实现规模化应用，为状态估计提供了新型数据支撑。分析发现，此类装置采集的数据与电网状态参数间存在直接线性关联，理论上可构建快速线性分析模型。然而实际应用中需解决两个难题：一是 PMU 和 SCADA 的数据差异性，从本质上看二者属于来自两个不同传感器的观测数据，在时间同步和成分上大有不同；二是 PMU 部署成本过高，需在监测覆盖范围与成本控制之间寻求平衡，因此部署在电网中的 PMU 具有一定的数量限制。

若在电力系统中部署足量的 PMU，这样一来，可以使整个电力系统处于仅由 PMU 可观测，电力系统的状态量可以直接获得，在运算速度和精度上都非常高效，这要求系统部署足量的 PMU，然而由于通信和经济限制，这种方法通常很难实现。当前的主流方案是通过精细化节点选择，在电网关键节点有限配置 PMU，目的是为了在尽可能降低成本的同时提升状态估计的准确性<sup>[52-54]</sup>。目前大多数的 SE 在估计的过程中引入 PMU 的高精度数据，这种 PMU 测量与传统的

SCADA 测量相结合的 SE，通常称为混合状态估计器(Hybrid SE, HSE)<sup>[55-56]</sup>。探索一种将 PMU 与 SCADA 数据融合的状态估计策略，对提升电网状态评估效能具有重要研究意义。

目前大多数的研究并未考虑到二者的采样频率的差异，如文献[57]与文献[58]中直接将 PMU 的测量值引入到 SCADA 的测量相量。这种融合算法与传统的 SE 相比，引入后的状态估计精度有所提高，这主要得益于 PMU 量测数据的高精度，从本质上讲这种方法的执行速度与传统状态估计算法相同，并未完全考虑到 PMU 高速采样的特性，也就是说，该策略只将高精度的数据加入测量向量对监测稳态条件有用。上述这些方法确实略提高了融合估计结果准确性，但其显著缺点是忽略了 PMU 和 SCADA 测量之间的采样率差异，本质上是在 SCADA 较慢的时间尺度上执行状态估计。为了实时地捕捉电力系统的状态，必须在更精细的时间尺度上进行估计。在文献[59-60]中采用的状态估计方法，旨在将 SCADA 量测值单独进行非线性状态估计，将上一步得到的状态估计结果与 PMU 量测数据结合，最后统一进行线性状态估计，这种方法忽略了实际电力系统中 PMU 和 SCADA 的采样率比为非整数的情况。


### 1.3 主要研究内容及创新点

综上所述，针对电力系统混合状态估计问题，本文提出在引用 PMU 的高精度的数据的同时，将 PMU 高速采样的特性集成到融合估计策略中，基于 PMU 的快速的时间尺度上执行状态估计，得到融合状态估计结果。本文主要框架如图 1-3 所示，内容和主要安排如下：

第 1 章：首先，详细论述了电力系统混合状态估计策略的必要性，以及 PMU 和 SCADA 两种监测装置的优缺点。接着，综述了状态估计和多传感器数据融合的研究现状，阐述了一些电力系统混合状态估计的相关研究方法，提出当前一些策略存在的不足及解决的难点。最后，介绍了本文的主要研究内容及创新点。

第 2 章：构建了电力系统状态估计模型。首先，根据潮流方程构建量测系统数学模型，并建立电力网络的数学模型。接着，对卡尔曼滤波和 WLS 的执行

过程进行了对比分析，建立本文电力系统状态估计的模型。最后，分析了多传感器数据融合算法的基本原理，发现可以将 PMU 和 SCADA 数据融合等效成多传感器数据融合的一个特例，建立了多传感器数据融合的数学模型。



第 3 章：对电力系统中 PMU 的部署策略进行了深入分析，以确保 PMU 与 SCADA 系统满足全局可观测性条件，在此条件下，针对 PMU 和 SCADA 采样

差异的问题，提出了一种基于 Holt-EKF 的电力系统状态估计方法，该方法首先在采样速率比为正整数的条件下，采用滑动窗口方法应用到 PMU 和 SCADA 采样速率差异问题中，然后，用 Holt-EKF 对窗口内 SCADA 数据在非采样时刻的状态值进行估计，使其与窗口内 PMU 的状态值一一对应。最后，利用 MMSE 进行数据融合，在融合过程中对高精度的 PMU 数据赋予更高权重，从而提升了融合状态估计的准确性。

第 4 章：针对 PMU 和 SCADA 采样速率比非整数的场景，提出了一种基于 KLA 数据融合的状态估计方法。该方法将一定时间内采集到的 PMU 与 SCADA 观测数据归纳为一个数据集合，并利用 KLA 方法确定一个最能反映该数据集合特征的概率分布。然后，依据该分布构建观测方程，其中观测向量由该分布的均值提供；最后，通过联立系统状态方程，在满足线性高斯条件下，采用信息滤波技术获得最终的融合状态估计值。

第 5 章：总结研究的主要内容与成果，剖析了现有研究中的局限性。此外，对未来可能的发展方向给出了前瞻性建议，并对相关课题进行了深入讨论。

本文主要创新点如下：

(1)在 PMU 与 SCADA 采样速率比为整数的条件下，提出了一种基于 Holt-EKF 数据融合的电力系统状态估计方法。该方法首先利用滑动窗口技术实现 SCADA 与 PMU 数据的时间对齐，随后，采用 Holt-EKF 对 SCADA 观测数据进行状态估计，从而获得非采样时刻的插值数据。在预测插值过程中，在传统 EKF 框架中引入 Holt 参数，实现自适应平滑参数调节，从而提高状态预测值的准确性。最后，采用 MMSE 方法对两种数据的状态估计结果进行加权融合，在融合过程中对高精度 PMU 数据赋予更高权重，从而有效提升了融合状态估计的精度。

(2)在 PMU 与 SCADA 采样速率比为非整数的条件下，提出了一种基于 KLA 数据融合的电力系统状态估计方法。对于某一时段内的 PMU 和 SCADA 观测数据进行收集，并利用 KLA 方法求得最能反映该数据集合特征的概率分布模型，依据该分布构建相应观测方程，将分布的均值作为观测向量，并根据 PMU 和 SCADA 的数据差异性构建建立观测矩阵，最后通过信息滤波算法对融合后的数据进行状态估计，得到最终的融合状态估计结果。

## 第2章 电力系统状态估计理论基础和模型分析

### 2.1 引言

电力系统状态估计作为保障电网安全、稳定运行的关键技术，其准确性和实时性直接影响到电力系统的运行调度和故障诊断。本章构建了电力系统状态估计模型并对不同的状态估计方法进行了对比分析。首先，基于潮流方程建立量测系统的数学模型，并建立电力网络的数学模型，为后续状态估计提供理论依据。其次，通过对卡尔曼滤波和 WLS 进行对比分析，揭示两种算法在数据处理、实时性及准确性方面的优缺点及适用条件。最后，本章研究了多传感器数据融合算法的基本原理及其在实际应用中的场景，并建立出多传感器数据融合的数学模型，为后续的研究工作打下理论基础。

### 2.2 电力系统状态估计数学模型

#### 2.2.1 量测系统的数学模型

在电力网络分析中，依据数学模型差异，潮流计算通常分为直流与交流两类。实际上，电力系统状态估计可以看作量测类型和数量上扩大了潮流计算。电力系统的状态估计方法主要可分为交流(Alternating Current, AC)状态估计和直流(Direct Current, DC)状态估计两种。在交流潮流状态估计中，由于潮流与电压幅值和相角之间存在非线性关系，交流电力系统的分支等效电路如图 2-1 所示。




图 2-1 电力系统交流支路等效电路

在交流状态估计中，通常利用交流潮流模型来描述电力系统，假设采样数

据中含有  $m$  个测量值和  $n$  个状态量，通常  $m > n$ ，从而可以得到一个非线性的量测方程，其具体表达形式为<sup>[25]</sup>：

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \mathbf{e} \quad (2.1)$$

其中， $\mathbf{z} = \mathbb{R}^{m \times 1}$  为测量向量(有功潮流和无功潮流、有功功率和无功功率注入、电压幅值和相角)； $\mathbf{x} = \mathbb{R}^{n \times 1}$  为状态向量，主要由节点电压幅值和相角构成； $\mathbf{e} = \mathbb{R}^{m \times 1}$  为测量误差向量，由传感器测量和数据传输过程中的误差组成，通常假定其服从均值为零、协方差矩阵为  $\mathbf{R}$  的高斯分布，即  $\mathbf{R} = \text{diag}(\sigma_1^2, \dots, \sigma_m^2)$ ； $\mathbf{h}(\mathbf{x})$  为描述状态变量与测量值之间非线性映射关系的函数。

根据基尔霍夫定律，状态向量与测量向量之间的非线性关系  $\mathbf{h}(\cdot)$  可由下面两组方程表示。

节点平衡功率方程：

$$P_i = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.2)$$

$$Q_i = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.3)$$

支路功率方程：

$$P_{ij} = V_i^2 (g_{si} + g_{ij}) - V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.4)$$

$$Q_{ij} = -V_i^2 (b_{si} + b_{ij}) - V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.5)$$

其中， $P_i$  和  $Q_i$  分别是节点  $i$  的有功功率和无功功率； $P_{ij}$  和  $Q_{ij}$  则代表支路  $i-j$  的有功功率和无功功率； $\theta_{ij} = \theta_i - \theta_j$  为节点  $i$  与  $j$  之间的相位角差； $G_{ij}, B_{ij}$  是节点  $i$  和  $j$  之间的线路导纳参数； $g_{ij} + jb_{ij}$  是节点  $i$  处的分流支路导纳； $V_i$ 、 $\theta_i$  分别对应节点  $i$  的电压幅值和相角。

### 2.2.2 电力网络的数学模型

在电力系统状态估计中，电力网络的数学建模主要依赖于对电力网络的网

络参数和网络接线状态。网络参数主要包括变压器参数和线路参数，变压器参数主要包括标称变比和等效电抗，线路参数主要为电阻、对地导纳等，这些参数一般是直接测量得到的，在系统中不会有变化，但是当参数因设备老化或环境变化产生偏差时，需进行修正，考虑参数不确定性，构建误差修正模型<sup>[41]</sup>：

$$\chi = \eta + v_p \quad (2.6)$$

其中， $\chi$  为参数量测值， $\eta$  为网络参数真实值， $v_p$  为量测误差，通常默认其遵循高斯分布。

网络接线状态  $s$  由开关或者断路器的状态决定，定义为二元向量：

$$s_{ij} = \begin{cases} 0 & \text{支路 } i-j \text{ 闭合} \\ 1 & \text{支路 } i-j \text{ 断开} \end{cases} \quad (2.7)$$

拓扑信息通过 SCADA 遥信或 PMU 同步量测获取。若存在遥信错误，网络接线状态修正为：

$$s = s_{meas} + \Delta s \quad (2.8)$$

其中， $s_{meas}$  为量测信息， $\Delta s$  表示开关状态的误判偏差。

### 2.2.3 电力系统状态估计方法

电力系统状态估计本质是最优估计理论在非线形动态系统中的工程实现，既继承了最小化估计误差的核心思想，又针对电力网络非线性、实时性强等特点进行了方法创新与约束增强，是支撑电网实时监控与安全分析的关键技术。

最优状态估计问题指的是当已知系统模型  $f(\mathbf{x})$ 、观测模型  $h(\mathbf{x})$ 、系统噪声和观测噪声的统计特性以及系统初始状态  $\mathbf{x}_0$ ，可以通过  $\mathbf{z}(k) = \{z_1, z_2, \dots, z_k\}$ ，选用最优状态估计准则，得到系统状态  $\mathbf{x}_k$  的最优状态估计值的问题。状态估计结构如图 2-2 所示，其中输入是含有噪声的观测值，滤波器是主要处理单元，输出是状态估计值  $\hat{\mathbf{x}}_k$ 。

根据状态估计框架，可以将最优估计问题的核心构成要素总结为以下要点：

- (1)观测数据集——反映系统输出的测量信息；
- (2)优化判据——确定最优估计准则；
- (3)数学描述——状态方程和观测方程；
- (4)不确定性来源——涵盖过程噪声、量测噪声及初始状态不确定性。




图 2-2 状态估计结构图

依据不同的划分维度，最优估计问题具有多种分类方式。从时域关系角度，可将其划分为三类：根据状态估计的时刻  $t_1$  与观测采样的时刻  $t$  之间的关系，可分为预测( $t_1 > t$ )、滤波( $t_1 = t$ )以及平滑( $t_1 < t$ )问题；根据动态系统模型的性质，可分为线性估计问题和非线性估计问题；基于时间连续性差异，则存在连续时间估计与离散时间估计两种。

为评估估计性能，需构建特定的优化判据函数，通过求极值实现最优状态推导。主要的判断体系包含以下四类：

#### (1)无偏估计准则

无偏估计准则要求状态估计误差的期望值为零，估计误差是指真实值  $\mathbf{x}$  和估计值  $\hat{\mathbf{x}}$  之间的差值，即要求估计误差满足：

$$E(\mathbf{x} - \hat{\mathbf{x}}) = 0 \quad (2.9)$$

#### (2)最小平方误差估计准则

最小平方误差估计目的是实现量测残差的二次型范数最小化：

$$J = \sum_{i=1}^n \mu_i^2 = \|\boldsymbol{\mu}\|_2^2 \quad (2.10)$$

其中， $\boldsymbol{\mu} = \mathbf{z} - \mathbf{H}\mathbf{x}$  表示观测向量  $\mathbf{z}$  与模型预测值  $\mathbf{H}\mathbf{x}$  之间的偏差。由此得到的估计值  $\hat{\mathbf{x}}$  为最小方差估计。当在系统方程难以构建或观测数据难以获取的情况下，可以采用最小二乘法解决。

### (3)最小方差估计准则

其主要目的是为了将估计误差的方差  $\mathbf{P}(\mathbf{x})$  做到最小，即对函数  $J$  求最小值：

$$\mathbf{J}(\hat{\mathbf{x}}) = \mathbf{P}(\mathbf{x}) = E[(\mathbf{x} - \hat{\mathbf{x}})(\mathbf{x} - \hat{\mathbf{x}})^T] \quad (2.11)$$

由此得到估计值  $\hat{\mathbf{x}}$ 。估计误差的方差反映了估计结果距真实值的集中程度，常用此来评价估计精度。计算估计误差方差时，被估状态值  $\mathbf{x}$  和观测值  $\mathbf{y}$  的条件概率密度  $p(\mathbf{x}|\mathbf{y})$  或  $p(\mathbf{y})$ ，以及它们的联合概率密度  $p(\mathbf{x}, \mathbf{y})$  需要提前已知。

### (4)线性最小方差估计准则

线性最小方差估计准则是一种在所有线性估计方法中寻求最优估计的准则，其目标是在满足线性估计形式的前提下，使得估计误差的方差（或误差协方差矩阵）达到最小。具体来说，该方法假设估计量是观测数据的线性组合，其一般形式为：

$$\hat{\mathbf{x}} = \mathbf{L}\mathbf{y} + \mathbf{b} \quad (2.12)$$

其中， $\mathbf{y}$  表示观测数据， $\mathbf{L}$  是待求的增益矩阵， $\mathbf{b}$  为偏置项。在无偏估计的条件下，通常要求  $\mathbf{b} = \mathbf{0}$ ，从而保证估计误差的期望值为零。即：

$$E[\hat{\mathbf{x}} - \mathbf{x}] = \mathbf{0} \quad (2.13)$$

线性最小方差估计的核心在于选取合适的  $\mathbf{L}$ ，使得估计误差的方差或协方差矩阵最小化，即求解下列最优化问题：

$$\min_{\mathbf{L}} \text{Var}(\hat{\mathbf{x}} - \mathbf{x}) \quad (2.14)$$

在实际应用中，此准则利用已知的观测数据和待估状态的一阶与二阶矩信息（如均值和协方差矩阵），而不需要完整的概率密度函数信息，因此具有较好的实用性。对于高斯噪声的情况，线性最小方差估计可以达到与最优估计相同

的性能，并且在动态系统中，也是卡尔曼滤波的理论基础，通过递归计算实现对状态的实时估计。

在众多估计方法中，WLS 作为最小平方误差估计准则的典型应用，其目标在于通过最小化测量值与预测值之间的加权残差平方和，对系统状态变量进行求解，从而实现对电网运行状态的实时监控。WLS 状态估计过程可以分为以下步骤：

(1)模型建立：依据电网的拓扑结构和线路参数，构造节点功率平衡方程和测量方程；

(2)数据采集：获取电力系统中诸如电压、电流、功率等实际测量数据；

(3)权值分配：根据各测量设备的精度，为不同测量数据赋予相应的权重，通常精度越高的设备所对应的权重也越大；

(4)迭代求解：利用加权最小二乘法，通过迭代计算逼近真实系统状态；

(5)结果评估：对估计结果进行检验，判断是否满足收敛条件，必要时对计算过程进行修正或重新估计。

状态估计的核心是求解量测模型中的状态向量，通常涉及各节点电压幅值与相角。为描述测量数据与理论值之间的偏差构建目标函数：

$$J(\mathbf{x}) = \sum_{i=1}^m \frac{[z_i - h_i(\mathbf{x})]^2}{\sigma_i^2} = [\mathbf{z} - \mathbf{h}(\mathbf{x})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x})] \quad (2.15)$$

其中， $m$  为测量数据的数量； $z_i$  和  $h_i(\mathbf{x})$  分别代表第  $i$  个观测值及其对应的理论预测值， $\sigma_i^2$  为该测量项的方差； $\mathbf{R}$  是根据  $\sigma_i^2$  的对角元素组成的误差方差矩阵。

通过最小化目标函数式(2.15)，可获得 WLS 状态估计的最优解，其表达式为<sup>[63]</sup>：

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} [\mathbf{z} - \mathbf{h}(\mathbf{x})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x})] \quad (2.16)$$

在求解过程中，牛顿法常被用来解决该优化问题。为求得目标函数的极值，需要对状态变量求偏导并令导数为零可以得到<sup>[25]</sup>：

$$\frac{\partial J(\mathbf{x})}{\partial \mathbf{x}^T} = -2\mathbf{H}(\mathbf{x})\mathbf{R}^{-1}[\mathbf{z} - \mathbf{h}(\mathbf{x})] = 0 \quad (2.17)$$

其中  $\mathbf{H}(\mathbf{x})$  是雅可比矩阵。为了简化求解过程通常在初始状态  $\mathbf{x}^{(0)}$  处对非线性函数  $\mathbf{h}(\mathbf{x})$  进行一阶泰勒展开：

$$\mathbf{h}(\mathbf{x}) \approx \mathbf{h}(\mathbf{x}^{(0)}) + \mathbf{H}(\mathbf{x}^{(0)})\Delta\mathbf{x} \quad (2.18)$$

相应地，目标函数可以重写为：

$$J(\mathbf{x}) = [\mathbf{z} - \mathbf{h}(\mathbf{x}^{(0)}) - \mathbf{H}(\mathbf{x}^{(0)})\Delta\mathbf{x}]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x}^{(0)}) - \mathbf{H}(\mathbf{x}^{(0)})\Delta\mathbf{x}] \quad (2.19)$$

令  $\Delta\mathbf{z} = \mathbf{z} - \mathbf{h}(\mathbf{x}^{(0)})$ ，进一步展开后得到式(2.11)的形式。为使目标函数达到最小值，需令式(2.19)中关于  $\Delta\mathbf{x}$  的二次项归零，从而得到：

$$\Delta\mathbf{x} = d(\mathbf{x}^{(0)})\mathbf{H}^T(\mathbf{x}^{(0)})\mathbf{R}^{-1}\Delta\mathbf{z} \quad (2.20)$$

其中， $d(\mathbf{x}^{(0)}) = [\mathbf{H}^T(\mathbf{x}^{(0)})\mathbf{R}^{-1}\mathbf{H}(\mathbf{x}^{(0)})]^{-1}$ ，由此，状态向量更新公式可表示为：

$$\hat{\mathbf{x}} = \mathbf{x}^{(0)} + \Delta\hat{\mathbf{x}} = \mathbf{x}^{(0)} + d(\mathbf{x}^{(0)})\mathbf{H}^T(\mathbf{x}^{(0)})\mathbf{R}^{-1}[\mathbf{z} - \mathbf{h}(\mathbf{x}^{(0)})] \quad (2.21)$$

将该更新过程通过迭代扩展，记第  $l$  次迭代更新为：

$$\Delta\hat{\mathbf{x}}^{(l)} = [\mathbf{H}^T(\hat{\mathbf{x}}^{(l)})\mathbf{R}^{-1}\mathbf{H}(\hat{\mathbf{x}}^{(l)})]^{-1} \mathbf{H}^T(\hat{\mathbf{x}}^{(l)})\mathbf{R}^{-1}\mathbf{H}^T(\hat{\mathbf{x}}^{(l)})\mathbf{R}^{-1}[\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}^{(l)})] \quad (2.22)$$

$$\hat{\mathbf{x}}^{(l+1)} = \hat{\mathbf{x}}^{(l)} + \Delta\hat{\mathbf{x}}^{(l)} \quad (2.23)$$

该迭代过程将持续进行，直至满足以下收敛准则之一：

$$\max_i |\Delta\hat{\mathbf{x}}_i^{(l)}| \leq \varepsilon_a \quad (2.24)$$

$$|J(\hat{\mathbf{x}}^{(l)}) - J(\hat{\mathbf{x}}^{(l-1)})| < \varepsilon_b \quad (2.25)$$

$$\|\Delta\hat{\mathbf{x}}^{(l)}\| \leq \varepsilon_c \quad (2.26)$$

其中， $i$  表示状态向量中各分量的索引，而  $\varepsilon_a$ 、 $\varepsilon_b$  和  $\varepsilon_c$  分别为不同的收敛容限。

面对动态系统的时间序列估计问题，卡尔曼滤波可视为 WLS 在递归框架下的扩展形式，卡尔曼滤波是主要用于在存在噪声干扰的情况下对系统状态进行最优估计。其执行过程可归纳为两个阶段，这两个阶段包括五个核心公式。每个计算周期内，算法依次执行预测与校准两个关键操作：预测阶段基于系统动态模型和上期最优结果进行预测，校准阶段则结合实时采集数据和测量模型进行结果优化。值得注意的是，校准结果实质上是预测结果与实际测量的动态平

衡，为此引入卡尔曼增益实现二者的配比，由此构成完整的预测和校正步骤。  
针对线性高斯系统，通过递推预测-更新机制实现最小方差无偏估计。

线性离散系统模型<sup>[36]</sup>：

$$\mathbf{x}_k = \Phi_{k-1} \mathbf{x}_{k-1} + \mathbf{B}_{k-1} \mathbf{w}_{k-1} \quad (2.27)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2.28)$$

其中， $\mathbf{x}_k \in \mathbb{R}^n$  表示系统在  $k$  时刻的  $n$  维状态向量， $\mathbf{B}_k \in \mathbb{R}^{n \times p}$  是噪声输入矩阵， $\mathbf{w}_k \sim \mathcal{N}(0, \mathbf{Q}_k)$  是系统噪声， $\Phi_{k|k-1} \in \mathbb{R}^{n \times n}$  表示系统状态转移矩阵， $\mathbf{z} \in \mathbb{R}^m$  为  $k$  时刻的  $m$  维观测向量， $\mathbf{H}_k \in \mathbb{R}^{m \times n}$  是观测矩阵， $\mathbf{v}_k \sim \mathcal{N}(0, \mathbf{R}_k)$  为服从零均值高斯分布的过程噪声量测噪声。 $\mathbf{Q}_k$  和  $\mathbf{R}_k$  分别为过程噪声和量测噪声的协方差矩阵。

卡尔曼滤波通过时间更新与量测更新两阶段递推实现最小方差无偏估计：

阶段 1：时间更新(预测)

基于  $k-1$  时刻后验估计  $\hat{\mathbf{x}}_{k-1}$  及其协方差矩阵  $\mathbf{P}_{k-1}$ ：

(1) 先验状态预测：

$$\hat{\mathbf{x}}_{k|k-1} = \Phi_{k-1} \hat{\mathbf{x}}_{k-1|k-1} \quad (2.29)$$

(2) 先验误差协方差预测：

$$\mathbf{P}_{k|k-1} = \Phi_{k-1} \mathbf{P}_{k-1|k-1} \Phi_{k-1}^T + \mathbf{B}_{k-1} \mathbf{Q}_{k-1} \mathbf{B}_{k-1}^T \quad (2.30)$$

阶段 2：量测更新(校正)

(1) 新息协方差计算：

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (2.31)$$

(2) 最优卡尔曼增益：

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (2.32)$$

(3) 后验状态估计更新：

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}) \quad (2.33)$$

(4) 后验误差协方差更新：

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (2.34)$$

因此，式(2.27)、式(2.28)和式(2.29)~式(2.34)构成线性离散时间系统的卡尔曼滤波基本方程框架。然而，实际电力系统是一个高度多维、非线性的动态系统，其强非线性特征会导致传统卡尔曼滤波器产生模型失配问题。因此，本文考虑使用 EKF 进行状态估计。该方法通过对非线性系统进行局部线性化近似，构建状态方程和观测方程：

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{G}_k \mathbf{w}_k \quad (2.35)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2.36)$$

其中， $\mathbf{F}_k = \partial \mathbf{f} / \partial \mathbf{x} |_{\mathbf{x}=\hat{\mathbf{x}}_k}$  是  $k$  时刻状态方程的雅可比矩阵； $\mathbf{G}_k$  表示为  $k$  时刻的输入矩阵； $\mathbf{H}_k = \partial \mathbf{h} / \partial \mathbf{x} |_{\mathbf{x}=\hat{\mathbf{x}}_k}$  是  $k$  时刻测量方程的雅可比矩阵。

## 2.3 多传感器数据融合的数学模型

多传感器数据融合方法通过综合不同位置采集到的监测信息，形成更准确的系统整体分析结果。相比单个设备，这种技术能够将不同采样速率、不同维度、不同层面的数据进行交叉比对与组合分析，既提高了数据的可靠性和实用性，又能拓展信息视角，发现数据之间的互补特性，从而在提升系统状态分析的精确度方面具有明显优势。

然而，在多传感器网络的实际部署中，采样速率的差异成为制约融合效果的关键瓶颈。这是由于各传感器节点因不同的硬件性能、通信协议及部署环境，往往具有非均匀的采样时序特性。为实现有效的时空数据融合，需建立统一的时序基准，其核心在于构建观测序列的时间对齐机制。典型方法包括滑动窗口插值法、状态预测补偿法以及基于李亚普诺夫指数的自适应同步策略，这些方法通过建立传感器间的时延补偿模型，将不同传感器的采样序列映射至统一的离散时间域。

假设有  $M$  个传感器，传感器  $i$  的采样周期为  $T_i$ ，其中  $i=1,2,\dots,M$ ，而传感器的数据观测值  $\mathbf{z}_i(t_i)$  表示在时刻  $t_i$  收集到的观测数据(其采样频率为  $1/T_i$ )。由于

不同传感器的采样频率不同，需要对其进行统一建模，使得能够在统一的时间尺度上进行融合。

数据融合的目标是根据来自多个传感器的不同观测数据，估计一个全局状态向量  $\mathbf{x}(t)$ ，即通过对不同速率数据的融合，得到关于系统状态的最佳估计。假设这  $M$  个传感器，分别提供来自系统状态  $\mathbf{x}(t)$  的观测  $\mathbf{z}_i(t)$ ，其观测值和系统状态之间的关系为<sup>[36]</sup>：

$$\mathbf{z}_i(t_i) = \mathbf{h}_i(\mathbf{x}(t_i)) + \mathbf{e}_i(t_i) \quad (2.37)$$

其中， $\mathbf{z}_i(t_i)$  是第  $i$  个传感器的观测函数，表示系统状态  $\mathbf{x}_i(t_i)$  到观测空间的映射。 $\mathbf{e}_i(t_i)$  为观测噪声，且  $\mathbf{e}_i(t_i) \sim \mathcal{N}(0, \mathbf{R}_i)$ ， $\mathbf{R}_i$  为第  $i$  个传感器的噪声协方差矩阵，通常假设不同传感器的  $\mathbf{R}_i$  互不相关。

由于传感器的采样速率不同，必须对不同传感器的观测值进行时间对齐和插值。假设一个统一的时间点  $T_{ref}$ ，并通过插值方法将不同速率的数据映射到这个统一时间点。例如，若  $\mathbf{z}_i(t_i)$  是第  $i$  个传感器在时刻  $t_i$  的观测数据，可以通过线性插值或样条插值方法，得到其在统一时间点  $t_{ref}$  的估计：

$$\mathbf{z}_i(T_{ref}) = \mathbf{F}_i(\mathbf{z}_i(t_i), T_{ref}) \quad (2.38)$$

其中， $\mathbf{F}_i(\cdot)$  表示插值函数，第  $i$  个传感器采用的插值函数，用于将本地时间  $t_i$  的观测值映射至  $T_{ref}$ 。插值后的数据将能够在统一的时间尺度上进行进一步的融合。

在上述多速率传感器系统中，假设各个传感器以不同的采样速率观测系统状态，传感器之间的采样速率关系为

$$S_i = \frac{S_1}{n_i} \quad (2.39)$$

其中， $S_1$  为传感器 1 的采样速率，其采样速率与系统同步， $S_i$  是传感器  $i$  的采样速率， $n_i$  为任意正整数，且  $n_i \geq 1$ 。由此可知，其中传感器 1 的采样速率为传感

器 $i$ 的 $n_i$ 倍。对上述系统提出以下假设<sup>[36]</sup>:

假设 2.1: 系统噪声 $w(t)$ 与观测噪声 $e_i(t_i)$ 都是高斯白噪声。

假设 2.2: 系统的初始状态向量 $\mathbf{x}(0)$ 的均值 $\mathbf{x}_0$ , 方差为 $P_0$ 。初始状态与系统噪声、观测噪声相互独立, 同时系统噪声与各个传感器的观测噪声互不相关。

根据假设 2.2, 在 $t$ 时刻融合中心得到的观测值为:

$$\mathbf{y}(t) = [\mathbf{y}_1(t) \cdots \mathbf{y}_i(t)] \quad (2.40)$$

将全部量测数据结合起来, 进行全局状态估计。可以通过卡尔曼滤波、粒子滤波或其他多传感器融合方法对状态进行估计, 最终目的是最小化由观测数据和状态估计之间的误差构成的成本函数。本文采用的方法是 EKF, 假设系统状态 $\mathbf{x}(t)$ 的模型为:

$$\mathbf{x}(t_i+1) = \mathbf{f}(\mathbf{x}(t_i), \mathbf{u}(t_i)) + \mathbf{w}(t_i) \quad (2.41)$$

其中,  $\mathbf{f}(\cdot)$ 为状态转移函数,  $\mathbf{u}(t_k)$ 是控制输入,  $\mathbf{w}(t_k)$ 是过程噪声。

多速率传感器系统的状态融合估计原理如图 2-3 所示。系统通过 $n$ 个不同速率的传感器对目标状态进行观测, 各节点将本地量测数据通过通信网络传输至融合中心基于式(2.37)和式(2.42)建立状态方程和观测方程, 融合中心利用最优估计理论构建融合准则, 通过分布式或集中式算法实现多源数据时空配准与数据关联, 最终输出融合状态估计值。

以三传感器系统为例(图 2-4), 其时空采样特性分析如下:

- (1)坐标定义: 横轴为统一时间基准( $t$ ), 纵轴表示各传感器的编号 $\{1, 2, 3\}$ ;
- (2)采样标记: 不同颜色的实心圆点表示各传感器的采样时刻;
- (3)采样周期: 传感器 1 至 3 满足整数倍速率比例约束, 采样间隔分别为 $T$ 、 $2T$ 和 $3T$ , 其中 $T=1s$ , 构成了典型整数倍多速率采样体系。




图 2-3 多速率融合估计示意图




图 2-4 采样时间示意图

需要注意的是，并非所有多传感器结构都满足采样速率为非整数比的情况，图 2-4 举例是采样速率满足整数比的情况，实际情况中也有速率比非整数倍的情况，本节只是进行举例说明。相比独立设备运作，多传感器数据融合方法能以更低的通信资源消耗获得更高精度的分析结果，并能完成单一设备无法实现的数据深度解析，因而成为提升监测系统性能的有效方案，在电力系统中，PMU 和 SCADA 作为两种主要的监测设备，各自具有不同的测量特性和数据精度。PMU 提供高采样率、高精度的相量数据，而 SCADA 则提供较低频率但范围更广的传统测量数据。将 PMU 和 SCADA 数据融合，正是多传感器数据融合在电力系统中的具体应用，通过整合两种数据源的信息，可以弥补单一监测手段的

不足，进而提高状态估计的准确性和实时性。

## 2.4 本章小结

本章研究了电力系统状态估计的数学描述及多传感器数据融合方法。首先介绍了直流潮流，并分析了两种常见的状态估计方法 WLS 和 Kalman 滤波，相比之下，Kalman 滤波更容易捕捉系统的实时状态。本章建立的电力系统状态估计模型，为后续章节实现数据融合和状态估计提供了关键理论工具。

## 第3章 面向整数倍采样速率比数据融合的状态估计

### 3.1 引言

电力系统状态估计是能源管理的核心功能，其准确性直接影响电网实时监控与控制的可靠性。传统状态估计主要依赖 SCADA 系统提供的量测数据，但其低采样率(0.1~5Hz)与异步特性导致动态跟踪能力不足，难以满足智能电网对实时性的需求。尽管 PMU 凭借高采样率(50~100Hz)与同步授时能力为状态估计提供了更精细的时间尺度，但短期内 PMU 难以完全替代 SCADA 系统。因此，如何有效融合 PMU 与 SCADA 的量测数据，成为提升状态估计性能的关键问题。

现有的混合估计方法多将 PMU 数据直接嵌入 SCADA 框架，未充分利用 PMU 的高采样速率特性，此类方法本质上仍以 SCADA 的慢时间尺度(秒级)进行估计，导致 PMU 的实时数据利用不足，无法捕捉电网实时动态变化。为了解决上述问题，本章在假设 PMU 和 SCADA 采样率成整数比的条件下，将 PMU 和 SCADA 的数据收集到一个窗口大小和移动步长固定的窗口，然后，采用 Holt-EKF 的方法对窗口内 SCADA 非采样时刻的状态值进行估计，实现 PMU 和 SCADA 状态值在时间尺度上的对齐，最后，将窗口内对齐的 PMU 和 SCADA 估计值，通过 MMSE 对得到的状态估计结果进行加权融合，得到最终的融合估计结果。在 IEEE-14 总线系统上进行仿真实验，验证了提出的算法的有效性。

### 3.2 PMU 布置策略的分析

SCADA 可观测性和 PMU 可观测性是实现估计融合策略的必要前提，这个条件对于计算单独的估计是至关重要的。SCADA 测量网络的可观测性假设是可行的，因为目前基于 SCADA 的状态估计技术采用的计量方案已设计成即使在复杂条件下也能确保系统可观测。然而，由于 PMU 在电网中的部署程度有限，PMU 可观测性的情况与 SCADA 有所不同，而且短期内预计这种情况不会有显著变化，因此，在进行融合估计之前，必须对 PMU 的部署情况进行详细研究，以确保融合策略的有效实施。

针对 PMU 可观测性问题, 文献[65]提出将 PMU 不可观测总线的先验信息作为伪测量数据。该方法虽解决了融合过程中 PMU 全局可观测性问题, 但增加了融合过程的计算量。为了更好地解决这一问题, 本文对 PMU 进行合理位置分配, 既最大限度地限制了 PMU 的数量以降低成本, 又使 PMU 在融合估计过程中具有全局可观察性。

在电力系统中, 各节点的电压和电流可以通过直接测量获得, 也可以通过计算方式间接推导。当进行间接测量时 PMU 的配置应遵循以下实施准则:

(1)直接量测拓展: 当某母线安装 PMU 装置时, 其电压矢量  $V_i$  及关联支路电流  $I_{ij}$  均由 PMU 直接采集到。

(2)电压传递特性: 若已知支路  $L_{ij}$  首端电压  $V_i$  及电流  $I_{ij}$  时, 可以通过阻抗矩阵计算其末端电压  $V_j$ :

$$V_j = V_i - I_{ij} Z_{ij} \quad (3.1)$$

(3)电流反演: 当支路两端电压  $V_i$ ,  $V_j$  均已知时, 支路电流可以由导纳参数推出:

$$I_{ij} = Y_{ij} (V_i - V_j) \quad (3.2)$$

(4)拓扑约束: 该方法根据基尔霍夫电流定理, 若某节点除单一支路外其余支路电流均已知, 则该未知支路电流可通过节点电流守恒方程求解。

针对零功率节点(净注入功率  $P_i + jQ_i = 0$ ), 采用以下准则:

(1)邻域观测传递: 设零功率节点具有  $N$  个相邻节点(含自身), 当任一邻接节点可观测时, 该节点自动满足可观测条件。

(2)拓扑合并优化: 对于零功率节点, 优先实施拓扑归并。若归并后仍无法满足全局可观测要求, 则保留关键节点单独配置 PMU。

PMU 优化配置的目的在于保证系统可观测性的前提下, 以最少的 PMU 数量实现系统的全局可观测性, 确定最优的 PMU 安装位置和最少的安装数量。该优化问题的目标函数:

$$\min \sum_{i \in N}^n x_i \quad (3.3)$$

式(3.3)中的  $x_i$  为决策变量，表示节点  $i$  是否安装 PMU ( $x_i=1$  代表安装， $x_i=0$  代表未安装)， $N$  为系统中所有节点的集合。该优化问题通常受到系统拓扑结构、电力网络可观测性约束以及可能的资源限制等条件的约束。

在满足 PMU 最小化部署约束条件下，当网络节点中配置同步相量测量装置的位置满足式(3.4)时，可确保电力系统实现全域可观测：

$$\mathbf{Y}\mathbf{X} > \mathbf{1} \quad (3.4)$$

式 3.4 表示向量间的元素级比较，即要求结果向量中每个元素均不小于 1；右侧的“1”为全 1 列向量，且维度与节点总数  $n$  相同，其物理意义为每个节点至少被 PMU 直接测量或通过拓扑规则间接推导一次，从而满足全局可观测性要求。基于最优配置准则构建的节点邻接矩阵  $\mathbf{Y} \in \mathbb{R}^{n \times n}$ ，其数学定义为：

$$\mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1n} \\ y_{21} & y_{22} & \cdots & y_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{nn} \end{bmatrix} \quad (3.5)$$

其中  $y_{ij}$  的取值由节点间的是否直接连接决定：

$$y_{ij} = \begin{cases} 1 & i \text{ 与 } j \text{ 连接} \\ 0 & i \text{ 与 } j \text{ 未连接} \end{cases} \quad (3.6)$$

其中， $n$  网络拓扑中包含的节点总数； $\mathbf{1}$  为所有元素都为 1 的列向量，表示网络连通性的基准条件。此定义表明，若在节点  $j$  安装 PMU，则可直接观测节点  $j$  及其所有相邻节点。

对于文献[63]中提出的安装策略，为确保在 PMU 部署后结合 SCADA 系统可以对电力系统实现全局可观，本文在 IEEE-14 系统中，将 PMU 部署在节点 2、6、7、9 的最优放置点。同时，节点 1、2、6、9、10、12、15、19、25、27 是 PMU 在 IEEE-30 总线系统中的最优部署位置。在图 3-1 和图 3-2 中，用红色标记了使用 PMU 部署的总线，而 SCADA 部署的总线则用黑色表示。该布局策略在

以最少的 PMU 数量实现全局可观性的同时，还具有较高的信息冗余度。本章以及第四章的仿真实验均基于上述布置策略进行。




图 3-1 IEEE-14 总线系统 PMU 部署位置




图 3-2 IEEE-30 总线系统 PMU 部署位置

### 3.3 基于 Holt-EKF 数据融合的电力系统状态估计

#### 3.3.1 滑动窗口方法

滑动窗口方法是一种在时间序列数据处理中常用的技术，其核心思想是在时间序列数据上提取固定大小的子序列，在固定长度的时间窗口内对数据进行插值处理，需要注意的是滑动窗口每次移动的步长是固定的<sup>[68-69]</sup>。具体而言，它通过在一个预设的、不断滑动的窗口内利用已知数据点，采用合适的插值算法（如线性插值、样条插值等）来估计窗口内或相邻时刻的缺失或不匹配的数据值，从而实现数据的平滑和对齐。该方法能够动态适应数据的局部变化，在处理如 PMU 和 SCADA 等采样频率不一致的数据时，能够有效提高数据的完整性和一致性。

在电力监测系统中 PMU 与 SCADA 在时间同步性上的差异会影响状态估计精度。两种系统在采样速率和数据传输时延方面的显著不同，如此一来，将导致控制中心接收的不同传感器的量测数据，难以保持严格的时间一致性。SCADA 量测系统的更新周期为 0.1~5 秒级，而 PMU 的更新周期可达到 10~20 毫秒级(即 50~100Hz)，这使得在这使得单位时间内相量测量装置采集的数据密度显著高于传统系统。图 3-3 为两种量测数据更新周期关系图，若仅以 SCADA 数据更新周期作为状态估计触发条件，那么在混合估计策略中高频 PMU 量测数据的利用效率将大幅降低，严重影响混合估计结果的准确性。




图 3-3 SCADA 与 PMU 测量周期示意图

$t$  为 SCADA 在相邻的量测时间间隔，从图 3-3 中可以看出 PMU 和 SCADA

的量测数据无法完全重叠，在多数电力系统混合状态估计策略中，通常仅将高精度的 PMU 测量值加入传统 SCADA 的测量向量中。相比传统状态估计方法，这种融合算法确实提升了估计精度，主要归功于在融合方程中引入了高精度的 PMU 数据。然而，该方法并未充分利用 PMU 的高频采样特性，其本质上仍在 SCADA 较慢的时间尺度上进行状态估计。为进一步提高估计精度并实时捕捉电力系统状态变化，必须在更细化的时间尺度上开展状态估计研究。在第二章对传感器数据融合进行分析研究发现，可以将 PMU 和 SCADA 看作两个具有不同速率的传感器，其中 PMU 的采样速率要远大于 SCADA 的采样速率。

为了确保实验的正常进行，假设 PMU 的采样速率  $k_p$  与 SCADA 的采样速率  $k_s$  的比值为一个正整数：

$$r = \frac{k_p}{k_s} \quad (3.7)$$

其中  $k_p$  表示 PMU 的采样速率， $k_s$  表示 SCADA 的采样速率， $r$  为任意正整数。PMU 和 SCADA 是两组独立的传感器，具有不同的时间尺度，每个传感器以不同的采样速率独立观察相同的目标状态，因此作出以下假设：

PMU 和 SCADA 进行均匀采样，PMU 的采样速率是 SCADA 的 4 倍(即 PMU 每秒采样 4 次，SCADA 每秒采样 1 次)，如图 3-4 所示，横坐标表示采样次数。两者的采样时间轴均从 0 时刻开始对齐，且 0 时刻二者都不进行采样。例如：当 SCADA 完成第 1 次采样时(对应时刻 1 秒)，PMU 已完成第 4 次采样(对应时刻 0.25 秒、0.5 秒、0.75 秒和 1 秒)，此时两者的采样时间点 1 秒处重合。




图 3-4 速率匹配示意图




图 3-5 SCADA 插值示意图

为了采用卡尔曼滤波方程，理想的做法是确保以相同的采样率获得测量结果。然而，PMU 和 SCADA 的采样率是不一样的，因此本章提出一种滑动窗口的方法对 PMU 和 SCADA 的采样速率进行匹配，如图 3-5 所示，本章采用滑动窗口的方法进行时间对齐，因为滑动窗口的宽度设置和移动步长设置必须是固定不变的，所以根据式(3.7)所建立的假设，将滑动窗口  $S$  的窗口大小设置为  $T = k_p + k_{p+3}$ ，移动步长  $s = k_p + k_{p+3}$ ，考虑窗口内的 PMU 的采样速率，根据窗口内的 SCADA 测量值进行状态估计得到 3 个插值用来匹配 PMU 的估计值，等待窗口内的采样速率匹配完毕后，滑动窗口按照指定的方向进行滑动，滑动距离为设定的滑动步长  $s$ ，然后对下一个窗口内的数据进行类似的处理。

### 3.3.2 基于 Holt-EKF 的电力系统状态估计

通过 Holt-EKF 对  $k_s$  时刻的 SCADA 观测值进行状态估计来获取图 3-5 中的插值，将获得的插值与 PMU 的估计值相对应，以此类推。通过 3.2 节的 PMU 部署策略，PMU 与 SCADA 已满足对电力系统的全局可观，在此条件下，假设 SCADA 和 PMU 采用同一状态变量， $x = [V, \theta]^T$ ，其状态方程为：

$$x(k+1) = Fx(k) + w(k) \quad (3.8)$$

其中,  $\mathbf{x} \in \mathbb{R}^{M \times 1}$  为  $k$  时刻的状态向量, 其中  $M=2N-1$ ,  $\mathbf{F} = \frac{\partial f}{\partial \mathbf{x}}|_{\mathbf{x}=\mathbf{x}_0}$  为  $M \times M$  维的状态转移矩阵,  $w \sim N(0, Q)$  表示高斯噪声, 其中  $Q \in \mathbb{R}^{M \times M}$ 。

电力系统是一个复杂且具有变化性的网络。每个时刻的状态转移矩阵很难确定, 为了方便构建状态方程的状态转移矩阵  $\mathbf{F}$ , 且减小在观测矩阵线性化过程中的误差影响, 本研究引入了一种自适应调节的 Holt 双参数指数平滑方法<sup>[64]</sup>。该方法通过两个时变平滑参数 (水平项参数  $\lambda_k$  和趋势项参数  $\gamma_k$ ), 对历史状态估计值  $\hat{\mathbf{x}}_k$  和预测值  $\tilde{\mathbf{x}}_k$  进行动态加权, 生成当前时刻预测值。采用这种方法, 可以将状态转移函数  $f(\cdot)$  表示为:

$$f(\mathbf{x}_k) = \tilde{\mathbf{x}}_{k+1} = \mathbf{c}_k + \mathbf{d}_k \quad (3.9)$$

其中,  $\tilde{\mathbf{x}}_{k+1}$  表示  $k+1$  时刻的预测状态向量;  $\mathbf{c}_k$  和  $\mathbf{d}_k$  分别为水平项和趋势项, 可以根据式(3.10)和式(3.11)获得:

$$\mathbf{d}_k = \gamma_k (\mathbf{c}_k - \mathbf{c}_{k-1}) + (1 - \gamma_k) \mathbf{c}_{k-1} \quad (3.10)$$

$$\mathbf{c}_k = \lambda_k \hat{\mathbf{x}}_k + (1 - \lambda_k) \tilde{\mathbf{x}}_k \quad (3.11)$$

其中,  $\hat{\mathbf{x}}_k$  表示  $k$  时刻的状态估计值。  $\gamma_k$  和  $\lambda_k$  是时变平滑参数。这两个时变平滑参数的具体确定方法如下所述。

(1)参数组合生成: 在时间  $k$  处选择一组中心值  $\lambda_0$  和  $\gamma_0$ , 根据预设定的偏移量  $\Delta\lambda$ 、 $\Delta\gamma$  生成以下五种参数组合:

$$\begin{cases} B^1(\lambda_0, \gamma_0) \\ B^2(\lambda_0 - \Delta\lambda, \gamma_0 - \Delta\gamma) \\ B^3(\lambda_0 + \Delta\lambda, \gamma_0 + \Delta\gamma) \\ B^4(\lambda_0 + \Delta\lambda, \gamma_0 - \Delta\gamma) \\ B^5(\lambda_0 - \Delta\lambda, \gamma_0 + \Delta\gamma) \end{cases} \quad (3.12)$$

(2)预测与误差评估: 利用式(3.12)中五种平滑参数组合, 生成对应的预测状态值  $\tilde{\mathbf{x}}_{k+1}^j$ , 其中  $j=1, \dots, 5$ , 每个预测状态值  $\tilde{\mathbf{x}}_{k+1}^j$  与状态估计值  $\hat{\mathbf{x}}_{k+1}^j$  的误差  $\phi_{k+1}^j(i)$ :

$$\varphi_{k+1}^j(i) = \hat{x}_{k+1}^j(i) - \tilde{x}_{k+1}^j(i) \quad (3.13)$$

(3)参数择优：利用式(3.14)计算预测状态值与状态估计值的均方误差  $\sigma_j$ ，并根据式(3.15)最小化  $\sigma_j$  得到预测估计误差最小的组合  $B^j$ ，从而确定其对应的  $\lambda$  和  $\gamma$  的值。

$$\sigma_j = \frac{1}{n} \sum_{i=1}^n (\varphi_{k+1}^j(i))^2 \quad (3.14)$$

$$\sigma_p = \min \{ \sigma_j \} \quad (3.15)$$

(4)状态转移建模：考虑系统噪声的影响本节采用以下状态方程：

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{U}_k + \mathbf{w}_k \quad (3.16)$$

将时变参数  $\lambda_k$  和  $\gamma_k$  代入 Holt 方程，通过式(3.10)~式(3.13)可以推导出状态转移矩阵  $\mathbf{F}_k$  和输入向量  $\mathbf{U}_k$ ：

$$\begin{cases} \mathbf{F}_k = \lambda_k (1 + \gamma_k) \mathbf{I} \\ \mathbf{U}_k = (1 + \gamma_k)(1 - \lambda_k) \tilde{\mathbf{x}}_k - \gamma_k \mathbf{c}_{k-1} + (1 - \gamma_k) \mathbf{d}_{k-1} \end{cases} \quad (3.17)$$

将该模型融入 EKF 的预测步骤中，通过式(3.17)将 Holt 双参数指数平滑生成的预测值  $\tilde{\mathbf{x}}_{k+1}$  作为 EKF 的先验状态估计，实现状态递推，通过预测误差的大小动态调整平滑参数  $\lambda_k$  和  $\gamma_k$ ，有效规避传统 EKF 中因模型失配导致的估计偏差。根据预测误差的大小实时调整平滑参数，维持预测估计值的准确性，最终进一步提高状态估计的精度。自适应调整平滑参数的具体实现流程如图 3-6 所示。




图 3-6 辅助预测状态估计流程图

在 EKF 算法过程中, 根据 EKF 量测更新后的状态估计值  $\hat{x}_k$  与预测值  $\tilde{x}_k$  的误差, 通过式(3.12)生成多组候选参数, 并利用式(3.13)~式(3.15)计算其均方误差, 最终选取最小误差对应的最优参数  $\lambda_k^p$  和  $\gamma_k^p$ 。此过程形成“预测-误差评估-参数优化”闭环, 确保平滑参数随系统运行状态自适应更新, 维持预测估计值的准确性, 具体实现步骤如图 3-6 所示。

假设 PMU 的测量向量为  $\mathbf{z}_p$ , 且  $\mathbf{z}_p = [v_{b1}, v_{b2}, \dots, v_{bn_p}, \theta_{b2}, \theta_{b3}, \dots, \theta_{bn_p}]^T$ , 其中  $b_{n_p}$  为 PMU 的在母线布置节点数,  $v_{bn_p}$  和  $\theta_{np}$  分别为部署了 PMU 的装置节点的电压幅值和相角, PMU 通过 GPS 同步技术直接测量节点电压和线路电流的相量形式

(幅值  $v$  和相角  $\theta$ )，电力系统状态估计的状态变量正是节点的电压幅值和相角。因此，PMU 量测与状态变量之间无需通过复杂的非线性物理方程转换，仅需线性映射即可表达，由此可以得到 PMU 的量测方程：

$$\mathbf{z}_p(k_p) = \mathbf{H}_p \mathbf{x}_p(k_p) + \mathbf{v}_p(k_p) \quad (3.18)$$

其中， $\mathbf{z}_p \in \mathbb{R}^{m_p \times 1}$  为  $k_p$  时刻的测量向量， $\mathbf{H}_p \in \mathbb{R}^{m_p \times n}$  为 PMU 的观测矩阵，因为直接测量节点的电压相量（幅值  $v_{b_{np}}$  和相角  $\theta_{b_{np}}$ ），且状态方程中的状态变量为节点的电压幅值与相角，所以本节中 PMU 的观测矩阵可以等效为单位矩阵  $\mathbf{I}$ ， $\mathbf{v}_p \sim \mathcal{N}(0, \mathbf{R}_p)$  为 PMU 测量噪声，且  $\mathbf{R}_p \in \mathbb{R}^{m_p \times N}$ ， $k_p$  为 PMU 的采样速率。

SCADA 的测量向量为  $\mathbf{z}_s = [P_{gen,1}, Q_{gen,1}, \dots, P_{gen,j}, Q_{gen,j} \dots]^T$ ，SCADA 的测量方程为：

$$\mathbf{z}_s(k_s) = \mathbf{h}_s(\mathbf{x}_s(k_s)) + \mathbf{v}_s(k_s) \quad (3.19)$$

其中， $\mathbf{z}_s(k_s) \in \mathbb{R}^{m_s \times 1}$  为  $k_s$  时刻的观测向量， $\mathbf{v}_s \sim \mathcal{N}(0, \mathbf{R}_s)$  为 SCADA 测量噪声， $\mathbf{h}_s(\cdot) \in \mathbb{R}^{m_s \times 1}$  为非线性函数，代表状态向量和观测向量之间的关系，可由支路潮流方程定义：

$$P_{ij} = V_i V_j [G_{ij} \cos(\theta_i - \theta_j) + B_{ij} \sin(\theta_i - \theta_j)] \quad (3.20)$$

$$Q_{ij} = V_i V_j [G_{ij} \sin(\theta_i - \theta_j) - B_{ij} \cos(\theta_i - \theta_j)] \quad (3.21)$$

由于 SCADA 观测方程为非线性，为了方便后续的状态更新进行，在此对  $\mathbf{h}_s(\mathbf{x}_s)$  进行线性化，得到为 SCADA 测量向量的雅可比矩阵  $\mathbf{H}_s = \frac{\partial \mathbf{h}}{\partial \mathbf{x}}|_{\mathbf{x}=\mathbf{x}_0}$ ，是由交流潮流方程  $\mathbf{h}(\cdot)$  线性化得来的。

系统状态方程和观测方程总结如下：

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{U}_k + \mathbf{w}_k \quad (3.22)$$

$$\mathbf{z}_s(k_s) = \mathbf{H}_s \mathbf{x}_s(k_s) + \mathbf{v}_s(k_s) \quad (3.23)$$

$$\mathbf{z}_p(k_p) = \mathbf{H}_p \mathbf{x}_p(k_p) + \mathbf{v}_p(k_p) \quad (3.24)$$

其中,  $v_s(k_s)$  和  $v_p(k_p)$  分别为  $k_s$  时刻和  $k_p$  时刻的 SCADA 和 PMU 的测量噪声, 两者相互独立且遵循高斯分布。由于已经基于 Holt 参数法对状态方程进行了线性化处理以及预测, 可直接执行如下步骤(以 SCADA 的插值获取为例):

预测步骤:

$$\begin{aligned}\tilde{\mathbf{x}}_s(k_s) &= \mathbf{F}_s(k_s-1)\hat{\mathbf{x}}_s(k_s-1) + \mathbf{U}_s(k_s-1) + \mathbf{w}_s(k_s-1) \\ \tilde{\mathbf{P}}_s(k_s) &= \mathbf{F}_s(k_s-1)\mathbf{P}_s(k_s-1)\mathbf{F}_s^T(k_s-1) + \mathbf{Q}_s(k_s-1)\end{aligned}\quad (3.25)$$

修正步骤:

$$\mathbf{K}_s(k_s) = \tilde{\mathbf{P}}_s(k_s)\mathbf{H}_s^T(k_s) \left[ \mathbf{H}_s(k_s)\tilde{\mathbf{P}}_s(k_s)\mathbf{H}_s^T(k_s) + \mathbf{R}_s(k_s) \right]^{-1} \quad (3.26)$$

$$\hat{\mathbf{x}}_s(k_s) = \tilde{\mathbf{x}}_s(k_s) + \mathbf{K}_s \left[ \mathbf{z}_s(k_s) - \mathbf{h}_s(\hat{\mathbf{x}}_s(k_s)) \right] \quad (3.27)$$

$$\mathbf{P}_s(k_s) = (\mathbf{I} - \mathbf{K}_s(k_s)\mathbf{H}_s(k_s))\tilde{\mathbf{P}}_s(k_s) \quad (3.28)$$

其中,  $\tilde{\mathbf{P}}_s(k_s-1)$  为  $k_s-1$  时刻的先验估计误差协方差矩阵,  $\mathbf{P}_s(k_s)$  则表示在  $k_s$  时刻的后验估计误差的协方差矩阵;  $\mathbf{K}_s(k_s)$  表示  $k_s$  时刻的卡尔曼增益。假设初始状态值为  $\mathbf{x}_s(0)=0$ , 估计误差协方差矩阵的初始值为  $\mathbf{P}_s(0)=\mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵。

本节主要展示了如何通过 Holt-EKF 方法获取非 SCADA 采样时刻的状态估计。需要指出的是, 为了获得最优的状态估计结果, 还必须将 PMU 与 SCADA 在原始采样时刻获得的状态估计结果进行融合。因此, 在 PMU 和 SCADA 各自原始采样时刻, 同样需要进行状态估计, 其步骤与式(3.25)~式(3.28)中的方法类似。

### 3.3.3 基于 MMSE 的状态估计加权优化

在经过 3.3.2 的状态估计后, 可以得到在相同采样速率下 PMU 和 SCADA 的状态估计值, 为了得到最优的融合估计结果, 需要对 PMU 和 SCADA 的估计值进行加权融合, 本节利用 MMSE 对估计结果进行加权融合, MMSE 是贝叶斯估计理论中的核心方法, 其目标是通过最小化估计误差的均方值, 获得对随机参数的最优估计。利用 MMSE 将插值后的 SCADA 状态估计与 PMU 数据进行融

合，上一节已经得到了同一时刻 PMU 和 SCADA 的估计值  $\hat{\mathbf{x}}_p \in \mathbb{R}^n$  和  $\hat{\mathbf{x}}_s \in \mathbb{R}^n$  [60]，并且 PMU 和 SCADA 的估计误差协方差矩阵均遵循高斯分布：

$$\hat{\mathbf{x}}_p \sim \mathcal{N}(\mathbf{x}, \mathbf{P}_p), \hat{\mathbf{x}}_s \sim \mathcal{N}(\mathbf{x}, \mathbf{P}_s) \quad (3.29)$$

其中  $\mathbf{x}$  为真实状态，噪声独立且  $E[(\hat{\mathbf{x}}_p - \mathbf{x})(\hat{\mathbf{x}}_s - \mathbf{x})]^T = 0$ 。定义融合估计为线性组合：

$$\hat{\mathbf{x}}_f = \mathbf{W}_1 \hat{\mathbf{x}}_s + \mathbf{W}_2 \hat{\mathbf{x}}_p \quad (3.30)$$

其中  $\mathbf{W}_1, \mathbf{W}_2$  为权重矩阵，需满足无偏约束： $\mathbf{W}_1 + \mathbf{W}_2 = \mathbf{I}$ ，可以通过最小化均方误差确立权重矩阵，即： $E[\|\mathbf{x} - \hat{\mathbf{x}}_f\|^2]$ ，将其展开可以得到：

$$\begin{aligned} & E[(\mathbf{x} - \hat{\mathbf{x}}_f)^T (\mathbf{x} - \hat{\mathbf{x}}_f)] \\ &= E\left[\text{Trace}\left((\mathbf{x} - \hat{\mathbf{x}}_f)(\mathbf{x} - \hat{\mathbf{x}}_f)^T\right)\right] \\ &= \text{Trace}(\mathbf{P}_f) \end{aligned} \quad (3.31)$$

通过拉格朗日乘数法进行求解，引入拉格朗日乘子矩阵  $\mathbf{A} \in \mathbb{R}^{n \times n}$ ，构造目标函数  $\mathbf{L}$ ：

$$\mathbf{L} = \text{Trace}(\mathbf{P}_f) + \text{Trace}(\mathbf{A}^T (\mathbf{W}_1 + \mathbf{W}_2 - \mathbf{I})) \quad (3.32)$$

求解融合后的误差协方差矩阵  $\mathbf{P}_f$ ：

$$\begin{aligned} \mathbf{P}_f &= E\left[(\mathbf{x} - \mathbf{W}_1 \hat{\mathbf{x}}_s - \mathbf{W}_2 \hat{\mathbf{x}}_p)(\mathbf{x} - \mathbf{W}_1 \hat{\mathbf{x}}_s - \mathbf{W}_2 \hat{\mathbf{x}}_p)^T\right] \\ &= \mathbf{W}_1 \mathbf{P}_s \mathbf{W}_1^T + \mathbf{W}_2 \mathbf{P}_p \mathbf{W}_2^T \end{aligned} \quad (3.33)$$

对  $\mathbf{W}_1$  和  $\mathbf{W}_2$  求导并置零：

$$\frac{\partial \mathbf{L}}{\partial \mathbf{W}_1} = 2\mathbf{W}_1 \mathbf{P}_s + \mathbf{A} = 0 \quad (3.34)$$

$$\frac{\partial \mathbf{L}}{\partial \mathbf{W}_2} = 2\mathbf{W}_2 \mathbf{P}_p + \mathbf{A} = 0 \quad (3.35)$$

联立  $\mathbf{W}_1$  和  $\mathbf{W}_2$  可得：

$$W_1 = P_p (P_s + P_p)^{-1}, W_2 = P_s (P_s + P_p)^{-1} \quad (3.36)$$

通过矩阵求逆引理 (Sherman-Morrison-Woodbury), 式(3.36)可重写为:

$$\begin{aligned} \hat{x}_f &= (P_s^{-1} + P_p^{-1})^{-1} (P_s^{-1} \hat{x}_s + P_p^{-1} \hat{x}_p) \\ P_f &= (P_s^{-1} + P_p^{-1})^{-1} \end{aligned} \quad (3.37)$$

由于 PMU 的数据精度要高于 SCADA 的数据精度, 且在估计过程中  $P_s > P_p$ , 从式(3.37)中可以看出, 在融合估计结果的构成中, 精度较低的 SCADA 估计值被赋予了较小的权重比, 而 PMU 的估计值被赋予较大权重, 因此提高了融合估计的可靠性。

### 3.4 仿真实验与结果分析

#### 3.4.1 仿真系统

Matpower 是一个开源的 Matlab 工具箱, 主要针对电力系统稳态分析而设计。该软件旨在解决电网稳态运行中遇到的问题, 如潮流计算、最优潮流(Optimal Power Flow, OPF)求解、可行性评估以及市场分析等<sup>[61]</sup>。在其内置的标准节点电力系统中, 每个测试系统通常包含节点(或母线)数据、线路信息、发电机参数和负荷需求等基本数据, 这些数据构成了电力系统分析的必要输入<sup>[61-63]</sup>。通过提供不同规模和复杂程度的电网模型, Matpower 为研究人员和工程师在统一、受控的环境中验证新方法和算法提供了便利。

本文利用 Matpower 7.1 工具箱执行连续最优潮流, 以获得系统中状态和测量的真实值。同时, 通过在真实测量值中添加平均值为 0、标准差为 0.015 的高斯噪声来模拟真实量测值。大部分电力系统状态估计的研究都是在 IEEE 标准节点系统中进行仿真验证的, 本次仿真采用的 IEEE-14 标准节点系统如图 3-7 所示, 采用 IEEE-14 标准测试系统作为基础, 其拓扑结构包含 14 个节点 (节点 1 设置为平衡节点)、20 条输电支路、5 台同步发电机及 11 个负荷节点。系统量测配置共包含 41 个观测值, IEEE-14 标准节点系统中的节点和支路功率如表 3-1 和表 3-2<sup>[64]</sup>, 其中 PMU 的部署位置为 3.2 节所示。




图 3-7 IEEE-14 标准节点系统图

表 3-1 IEEE-14 节点系统注入功率

| 量测数 | 节点 <i>i</i> | 有功功率 $P_i$ | 无功功率 $Q_i$ |
|-----|-------------|------------|------------|
| 1   | 2           | 0.1830     | 0.3086     |
| 2   | 3           | -0.9420    | 0.0608     |
| 3   | 7           | 0.00       | 0.00       |
| 4   | 8           | 0.00       | 0.1762     |
| 5   | 10          | -0.0900    | -0.0580    |
| 6   | 11          | -0.0350    | -0.0180    |
| 7   | 12          | -0.0610    | -0.0160    |
| 8   | 14          | -0.1490    | -0.0500    |

表 3-2 IEEE-14 节点系统支路功率

| 量测数 | 起始节点 <i>i</i> | 终止节点 <i>j</i> | 有功功率 $P_{ij}$ | 无功功率 $Q_{ij}$ |
|-----|---------------|---------------|---------------|---------------|
| 1   | 1             | 2             | 1.5688        | -0.2040       |
| 2   | 2             | 3             | 0.7324        | 0.0356        |
| 3   | 4             | 2             | -0.5445       | 0.0302        |
| 4   | 4             | 7             | 0.2807        | -0.2107       |
| 5   | 4             | 9             | 0.1608        | -0.0658       |
| 6   | 5             | 2             | -0.4061       | -0.0210       |
| 7   | 5             | 4             | 0.6167        | -0.1420       |

续表 3-2IEEE-14 节点系统支路功率

|    |    |    |         |         |
|----|----|----|---------|---------|
| 8  | 5  | 6  | 0.4409  | -0.1982 |
| 9  | 6  | 13 | 0.1775  | 0.0722  |
| 10 | 7  | 9  | 0.2807  | 0.0578  |
| 11 | 11 | 6  | -0.0730 | -0.0344 |
| 12 | 12 | 13 | 0.0161  | 0.0075  |

3.4.2 仿真数值分析

为全面评估本章算法的性能优势，本节从动态时域特性和静态节点精度两个维度，在 SCADA 的时间尺度上进行状态估计算法(传统 SE)与本章提出的基于 Holt 状态估计算法(融合 SE)进行了对比，本文中仿真实验的。如图 3-8 所示，在  $T=80s$  的时间段内，融合 SE 的电压幅值估计结果较传统 SE 更贴近真实值；从静态节点的维度进行分析，图 3-9 和

图 3-10 分别表示不同估计器在同一时刻内各个节点的幅值和相角的估计结果。在节点电压幅值估计方面(图 3-9)，融合 SE 的平均绝对误差为 0.008p.u.，较传统 SE 的 0.023p.u.降低了约 60%，并且在电压相角估计方面（图 3-10），融合 SE 在 14 个节点上的相角误差标准差为 0.82°，显著优于传统 SE 的 2.35°。




图 3-8 IEEE-14 系统电压幅值估计结果




图 3-9 IEEE-14 节点某一时刻各个节点幅值




图 3-10 IEEE-14 节点某一时刻各个节点电压相角

如图 3-11 所示，本节使用均方根误差(Root Mean Square Error, RMSE)来比较不同估计器之间的性能差距。RMSE 通过使用预测估计值与实际值之间的差异来计算两个估计器的估计误差。将单个估计器估计的电压值与节点的真实电压值进行比较。RMSE 的公式定义为：

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{\mathbf{x}}_j - \mathbf{x}_j)^2} \quad (3.38)$$

其中， $N$  代表节点的数量； $\hat{\mathbf{x}}_j$  是第  $j$  个节点的电压估计值； $\mathbf{x}_j$  表示第  $j$  个节点的真实值，均方根误差越小则表明估计值与真实值的偏离程度越小。




图 3-11 不同估计器 RMSE 对比结果

### 3.5 本章小结

本章提出了一种解决 PMU 和 SCADA 采样率比为整数倍条件下数据匹配的方法，通过滑动窗口插值结合 Holt-EKF 预测的方法，对慢频的 SCADA 观测值进行预测，从而与 PMU 的测量值对齐，与传统的单一数据估计方法相比，采用混合状态估计器在精度和计算效率方面表现出了更优的性能。融合估计器不仅能够有效提升系统状态估计的精度，还在处理大规模数据和复杂电力网络时，展现出更高的计算效率和鲁棒性，具有更强的适应性和实际应用价值。

## 第4章 面向非整数倍采样速率比数据融合的状态估计

### 4.1 引言

在实际电力系统中，PMU 与 SCADA 的采样率之比往往并非严格成整数，滑动窗口的大小和移动步长是固定的，这导致第三章中提出的插值方法在部分应用场景下可能难以适用。为解决这一问题，本章提出了一种基于 KLA 的数据融合算法。首先，将选定时间段内的 PMU 与 SCADA 观测数据整合为一个数据集，并利用 KLA 方法寻找最接近该集合分布的概率模型；其次，基于所得到的分布构建新的观测方程，其观测向量采用 KLA 方法计算得到的均值向量，并结合 PMU 与 SCADA 数据的差异性构造观测矩阵，通过信息滤波对融合后的数据进行状态估计。最后，在 IEEE-14 节点和 IEEE-30 节点标准电力系统进行仿真测试，以此来验证所提方法的有效性。

### 4.2 传感器融合结构分析

考虑一个含有  $N$  个传感器的多传感器系统，其系统的第  $i$  个传感器 ( $i=1,2,\dots,N$ ) 的状态方程和量测方程如下：

$$\mathbf{x}_{k+1}^i = \mathbf{F}_k^i \mathbf{x}_k^i + \mathbf{U}_k^i + \mathbf{w}_k^i \quad (4.1)$$

$$\mathbf{z}_k^i = \mathbf{H}_k^i \mathbf{x}_k^i + \mathbf{v}_k^i \quad (4.2)$$

其中， $\mathbf{x}_k^i \in \mathbb{R}^n$  是传感器  $i$  在  $k$  时刻的状态向量， $\mathbf{w}_k^i \in \mathbb{R}^p$  为过程噪声； $\mathbf{z}_k^i \in \mathbb{R}^m$  为  $k$  时刻的第  $i$  个传感器的量测向量， $\mathbf{F}_k^i \in \mathbb{R}^{n \times n}$  为状态转移矩阵， $\mathbf{H}_k^i \in \mathbb{R}^{m \times n}$  是观测矩阵，而  $\mathbf{v}_k^i \in \mathbb{R}^q$  是量测噪声。

假设过程噪声  $\mathbf{w}_k^i$  和量测噪声  $\mathbf{v}_k^i$  均为独立同分布的高斯白噪声序列，且满足：

$$\mathbf{w}_k^i \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k^i), \quad \mathbf{v}_k^i \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k^i) \quad (4.3)$$

若系统初始状态  $\mathbf{x}_0^i$  服从高斯分布，即  $\mathbf{x}_0^i \sim \mathcal{N}(\bar{\mathbf{x}}_0^i, \mathbf{P}_0^i)$ ，且与噪声过程统计

独立。

基于上述独立性假设，对于任意两个传感器  $i, j$  在时刻  $k, l$ ，其联合统计特性满足：

$$E\left[\mathbf{w}_k^i \left(\mathbf{w}_l^j\right)^T\right]=0, \quad E\left[\mathbf{v}_k^i \left(\mathbf{v}_l^j\right)^T\right]=0, \quad \forall k, l \quad (4.4)$$

由上述描述可知，多传感器数据融合旨在通过融合异构数据集  $\{\mathbf{z}_k^1, \dots, \mathbf{z}_k^N\}$  实现系统状态  $\mathbf{x}_k$  的最优估计。现有融合算法的性能与传感器网络拓扑结构密切相关，根据信息处理层级差异，主要可分为以下三类架构。

#### 4.2.1 集中式融合结构

集中式架构通过通信线路汇总所有传感器的原始量测至中央处理节点(见图 4-1)，由中心处理器执行全局状态估计。在集中式的融合结构中，处理中心可以从所有传感器中获得原始量测数据，其中包括最完整的目标信息。由于集中式结构中信息损失最少、数据量最大，所以所获得的融合结果是最优的。因为集中式结果的最优估计性能，可以将其作为分布式结构以及混合式结构的基准性能比较<sup>[36]</sup>。

#### 4.2.2 分布式融合结构

如图 4-2 所示，在分布式融合结构中，各个传感器节点均具有独立的局部处理中心，可以在当前阶段执行量测数据的处理。每个传感器可利用自身的处理中心对获得对目标的局部估计结果，或是与其他传感器进行信息交互，进而获得对准确的估计。在实际应用中，由于分布式结构对于传感器通信能力要求并不高，而且对于系统拓扑结构依赖性不强，因此在工程 and 实际实践中得到了广泛的应用。

根据不同的通信方式，分布式融合系统又可以被划分为<sup>[37]</sup>：

(1) 无反馈分布式融合结构(见图 4-2)，各传感器基于局部观测数据独立执行状态估计，并通过通信网络将局部估计结果传送至融合中心进行全局优化；

(2)反馈式分布式融合结构(见图 4-3)，除了上传局部估计结果外，各节点还可以接收全局融合结果作为反馈，对原有局部估计进行校正，从而进一步提高整体系统的容错性。例如，在卡尔曼滤波或贝叶斯融合框架下，全局估计结果可用来修正先验，从而有效降低各节点估计误差累积的风险。




图 4-1 集中式融合示意图




图 4-2 无反馈分布式融合示意图

### 4.2.3 混合式融合结构

混合式融合结构是集中式和分布式结构的有机结合，既包含中央处理节点，又包含各传感器节点的局部处理单元（见图 4-4）。在这种结构中，中央节点不仅能直接接收原始量测数据，还可以获取局部处理中心处理后的初步状态估计结果。典型的工作流程如下：

- (1)各传感器节点采集原始数据，并将其传输至对应的局部处理中心；

(2)局部处理中心对所采集的数据进行初步融合与状态估计，生成局部估计结果；

(3)各局部节点将融合结果及相应的协方差矩阵传输至中央节点；

(4)中央节点对各局部估计结果进行全局融合，采用卡尔曼滤波、粒子滤波或信息滤波等方法生成全局最优状态估计，并将结果反馈至局部节点以便改进后续估计或执行控制操作。




图 4-3 反馈式分布式融合示意图




图 4-4 混合式融合结构示意图

这种多级融合结构在平衡计算复杂性与通信负担的同时，提高了多传感器数据融合系统的估计精度和鲁棒性。表4-1总结了三种不同融合滤波方法的优缺点及适用场景，对比三种方法可以发现，尽管集中式融合方法的计算复杂度较高，但其状态估计精度明显优于其他方法。考虑到电力系统状态估计的精度直

接影响到电网的安全、经济和可靠运行<sup>[13]</sup>，因此本章采用集中式融合结构进行数据融合。

表 4-1 不同融合滤波的比较

| 融合滤波类型 | 工作方法               | 优点           | 缺点           | 应用场景       |
|--------|--------------------|--------------|--------------|------------|
| 集中式    | 中央节点统一处理所有数据       | 数据较完整，估计精度高， | 通信负担重，计算复杂度高 | 小型网络       |
| 分布式    | 各个节点独立处理数据         | 灵活性高，适应性强    | 无法全局优化，精度受限  | 大规模网络      |
| 混合式    | 部分节点数据融合后传中央节点全局融合 | 较为灵活，可进行全局优化 | 结构复杂，成本较高    | 有资源限制的大型网络 |

4.3 基于 KLA 数据融合的电力系统状态估计

4.3.1 PMU 和 SCADA 差异性研究

电力系统混合状态估计主要是在传统的状态估计方法中引入 PMU 的高精度量测，有效提升传统方法的估计精度与可靠性，但是需要注意 PMU 和 SCADA 两者得到数据具有差异性(如表 4-2 所示)，SCADA 采用分钟级采样而 PMU 实现毫秒级测量，两类数据存在时标差异；SCADA 量测具有高冗余特性但精度有限，PMU 量测精度高但覆盖范围不足，因此无法进行有效融合。在第三章提出的假设条件下，PMU 和 SCADA 分别进行状态估计后，对状态估计结果进行融合，估计结果的类型均为电压幅值和相角，所以只需考虑二者的采样速率的差异，对估计结果进行插值补齐，无需在开始阶段对数据进行预处理，但是本章要解决的问题为采样速率比为非整数的情况，无法直接进行插值，因此需要考虑 PMU 和 SCADA 的数据成分差异对于数据融合的影响。

PMU 与 SCADA 数据的差异主要有以下区别：(1)采样频率：PMU 数据的采样频率通常很高，一般可达到 30 至 60 次/秒甚至更高，而 SCADA 系统的数据采样间隔较长，通常为几秒一次；(2)时钟同步性：PMU 利用 GPS 技术实现精确的全网时间同步，从而保证不同设备之间数据时间戳的一致性；(3)数据精度与内容：PMU 不仅能提供高精度的电压幅值和相位角，还能输出频率及其变化率

等动态信息，这对于实时监控和动态分析至关重要。SCADA 系统则主要采集基本的监控信息，如潮流、电压、电流和功率等，精度相对较低；(4)实时性：由于采样频率高且时钟同步精度好，PMU 数据具备更低的延迟，能够支持实时控制与快速故障诊断；而 SCADA 系统的数据传输和处理延时较大，更适用于常规监控和调度管理。因此，若要解决 PMU 和 SCADA 的数据差异性问题需要同时关注到两者数据的成分差异以及结构差异。

表 4-2 PMU 和 SCADA 数据对比

| 量测数据类型 | 采样间隔 | 数据同步性 | 量测配置 | 可观测性  |
|--------|------|-------|------|-------|
| SCADA  | 长    | 较差    | 全    | 可观测   |
| PMU    | 短    | 较好    | 不全   | 局部可观测 |

SCADA 系统主要采集节点电压幅值、电流幅值(不包含相位信息)、支路有功功率和无功功率等常规电气参数，而 PMU 可直接获取支路电流相量与节点电压相量的同步量测数据。需特别注意的是，PMU 电压相量可直接用于状态估计，但需用部署的 PMU 的节点的电压扩展整个系统的可观测性从而覆盖非 PMU 节点，而 PMU 的电流相量包含相位信息，PMU 电流相量需经数学变换方可融入状态估计框架，目前主流处理方法包括：

(1)基于 PMU 节点与非 PMU 节点间电压转换：在一些节点未配置 PMU 的情况下，可利用相邻配置 PMU 节点的电压及支路电流量测数据，通过电路网络模型计算非 PMU 节点的电压。设节点  $i$  为已配置 PMU 的参考节点，节点  $j$  为非 PMU 节点，则依据支路电流平衡和导纳关系得到：

$$V_j = [I_{ij} - (\xi_{ij} + \xi_{i0})V_i] / -\xi_{ij} \quad (4.5)$$

其中， $V_i = |V_i|e^{j\theta_i}$  是配置 PMU 的节点  $i$  处直接测得的电压相量， $V_j$  为待计算的非 PMU 节点  $j$  的电压相量， $\xi_{ij}$  表示支路导纳矩阵(一般写为  $g + jb$ ，其中  $g$  为电导， $b$  为电纳)， $\xi_{i0}$  为节点  $i$  对地导纳。

(2)支路潮流等效转换：其核心是将 PMU 直接测量的支路电流相量  $I_{ij}$  和节点电压相量  $V_i$ ，通过复功率定义转换为等效的有功功率  $P_{ij}$  和无功功率  $Q_{ij}$ ，从而

实现统一 SCADA 与 PMU 数据的物理意义，将 PMU 直接测得的支路电流相量转换为与 SCADA 系统中常见的功率数据相对应的等效支路潮流。利用复功率定义为：

$$\tilde{S}_{ij} = V_i \cdot (I_{ij})^* = P_{ij}^{PMU} + jQ_{ij}^{PMU} \quad (4.6)$$

其中  $V_i$  为节点  $i$  的电压相量， $I_{ij} = |I_{ij}|e^{j\omega_{ij}}$  为支路  $ij$  的电流相量， $\omega_{ij}$  为支路  $ij$  的电流相位角， $(\cdot)^*$  表示共轭运算， $P_{ij}^{PMU}$  与  $Q_{ij}^{PMU}$  分别表示 PMU 的等效有功功率和无功功率，对于式(4.6)进行展开可以得到：

$$\tilde{S}_{ij} = \underbrace{|V_i||I_{ij}|\cos(\theta_i - \omega_{ij})}_{P_{ij}^{PMU}} + j \underbrace{|V_i||I_{ij}|\sin(\theta_i - \omega_{ij})}_{Q_{ij}^{PMU}} \quad (4.7)$$

在进行电力系统状态估计时，通常以节点电压幅值和相角为状态变量，上述的转换也是在此条件下进行的，无论转换目标是电压还是功率，在对其雅可比矩阵求偏导的时候，其方程均指向电压幅值  $V_j$  和相角  $\theta_j$ ，且二者经过转化后的数据，在量测方程中的线性化一致，节点电压转化后量测方程  $V_j = f(V_i, I_{ij}, \xi_{ij})$ ，进行线性化后可以得到：

$$\Delta V_j = \frac{\partial V_j}{\partial |V_i|} \Delta |V_i| + \frac{\partial V_j}{\partial \theta_i} \Delta \theta_i \quad (4.8)$$

支路潮流转换后量测方程  $P_{ij}^{PMU} + jQ_{ij}^{PMU} = V_i I_{ij}^*$  进行线性化，有：

$$\Delta P_{ij}^{PMU} = \frac{\partial P_{ij}^{PMU}}{\partial |V_i|} \Delta |V_i| + \frac{\partial P_{ij}^{PMU}}{\partial \theta_i} \Delta \theta_i \quad (4.9)$$

由式(4.8)和式(4.9)可以看出，两种转换方法通过线性化后，其偏导数均围绕相同的状态变量  $|V|$  和  $\theta$  展开。若将 PMU 节点设为参考节点 ( $\theta_{ref} = 0$ )，非 PMU 节点的相角偏差仅依赖于 PMU 量测，则两种转换方法均通过固定参考节点，消除了相角自由度的冗余，使得雅可比矩阵中相角相关的偏导数结构一致。因此通过上述两种转换方式可以得到相同形式的雅克比矩阵：

$$\mathbf{H}_f = \begin{bmatrix} \mathbf{H}_{SCADA}^P \\ \mathbf{H}_{SCADA}^Q \\ \mathbf{H}_{PMU}^P \\ \mathbf{H}_{PMU}^Q \\ \mathbf{H}_{SCADA}^V \\ \mathbf{H}_{SCADA}^\theta \end{bmatrix} \quad (4.10)$$

其中 SCADA 和 PMU 的观测矩阵分别为式(4.11)和式(4.12)所示。

$$\begin{aligned} \mathbf{H}_{SCADA}^P &= \begin{bmatrix} \frac{\partial P_i}{\partial V_j} \\ \frac{\partial P_i}{\partial \theta_j} \end{bmatrix} & \mathbf{H}_{SCADA}^Q &= \begin{bmatrix} \frac{\partial Q_i}{\partial V_j} \\ \frac{\partial Q_i}{\partial \theta_j} \end{bmatrix} \\ \mathbf{H}_{PMU}^V &= \frac{\partial |V_i|}{\partial |V_j|} & \mathbf{H}_{PMU}^\theta &= \frac{\partial \theta_i}{\partial \theta_j} \\ \mathbf{H}_{PMU}^P &= \begin{bmatrix} \frac{\partial P_{ij}^{PMU}}{\partial |V_i|} \\ \frac{\partial P_{ij}^{PMU}}{\partial |V_j|} \end{bmatrix} & \mathbf{H}_{PMU}^Q &= \begin{bmatrix} \frac{\partial Q_{ij}^{PMU}}{\partial \theta_i} \\ \frac{\partial Q_{ij}^{PMU}}{\partial \theta_j} \end{bmatrix} \end{aligned} \quad (4.11)$$

式(4.11)中  $\mathbf{H}_{SCADA}^P$  和  $\mathbf{H}_{SCADA}^Q$  对应 SCADA 系统采集的有功功率和无功功率测量，通过非线性函数  $h(x)$  映射到状态变量； $\mathbf{H}_{PMU}^V$  和  $\mathbf{H}_{PMU}^\theta$  则对应 PMU 直接测量的电压幅值与相角，由于其直接量测的关系，其偏导数项为单位值或零； $\mathbf{H}_{PMU}^P$  和  $\mathbf{H}_{PMU}^Q$  为根据支路潮流求得的等效有功功率和无功功率。

通过引入上述经过数学转换后的 PMU 量测(包括利用式(4.5)计算的节点电压以及式(4.6)转换的支路功率)，可构造一个融合 PMU 与 SCADA 数据的混合状态估计模型。该模型既利用 SCADA 的稳态经济调度数据，又充分发挥 PMU 在动态监测中的高采样率和同步特性，从而提升整体状态估计的精度和鲁棒性。

#### 4.3.2 KLA 数据融合算法

KL 散度是一种衡量两个概率分布之间差异的非对称度量。它广泛应用于信息论、机器学习、统计学等领域，用于量化两个分布的差异或“信息丧失”在电

力系统中，KL 散度可以用来衡量预测状态估计值与实际测量值之间的差异，尤其是在故障诊断和数据融合中。例如，当合并来自不同传感器的数据时，可以使用 KL 散度来量化模型预测与实际观测之间的差异，从而优化状态估计过程。

给定两个连续概率分布  $P$  和  $Q$ ，KL 散度的定义为：

$$D_{KL}(P \parallel Q) = \int_{-\infty}^{\infty} P(x) \log \frac{P(x)}{Q(x)} dx \quad (4.12)$$

其中  $P(x)$  和  $Q(x)$  分别表示在事件  $x$  下的概率分布  $P$  和  $Q$  的概率， $D_{KL}(P \parallel Q)$  衡量的是分布  $P$  和  $Q$  之间的差异。




图 4-5 测量数据选取示意图

在电力系统中 PMU 和 SCADA 系统在无共同干扰源时其采集的数据相互独立，且在稳态条件下遵循高斯分布。如图 4-5 所示，假设在  $T$  时刻内 PMU 收集到  $M$  个数据，即  $\mathbf{z}_p = [\mathbf{z}_p^1, \mathbf{z}_p^2, \dots, \mathbf{z}_p^M]$ ，且  $\mathbf{z}_p \sim \mathcal{N}(\mu_p, \Sigma_p)$ ，SCADA 收集到  $W$  个数据  $\mathbf{z}_s = [\mathbf{z}_s^1, \mathbf{z}_s^2, \dots, \mathbf{z}_s^W]$ ，且  $\mathbf{z}_s \sim \mathcal{N}(\mu_s, \Sigma_s)$ ，其中  $M \gg W$  (因 PMU 采样率更高)，将其整合为联合数据集：

$$\mathbf{z}_t^N = \{\mathbf{z}_p^1, \dots, \mathbf{z}_p^1, \dots, \mathbf{z}_p^M, \dots, \mathbf{z}_s^W\} \quad (4.13)$$

假设  $\mathbf{z}_t^N$  对应  $N = M + W$  个分布  $\{q^1, \dots, q^N\}$ ，每个  $q^i$  为数据集中单一测量数据的高斯分布，其中  $i = 1, \dots, N$ ，为了融合 PMU 和 SCADA 的测量数据，需构建

一个最优的概率密度函数  $\bar{p}$ ，使其与联合数据集的平均差异最小，可以通过最小化平均 KL 散度求解融合概率密度为：

$$\bar{p} = \arg \inf \sum_{i=1}^N \frac{1}{N} D_{KL}(p \parallel q^i) \quad (4.14)$$

式(4.14)中的 KL 散度的定义为：

$$D_{KL}(f \parallel g) = \int f(x) \log \frac{f(x)}{g(x)} dx \quad (4.15)$$

其中  $f(x)$  为候选融合近似分布  $p$ ， $g(x)$  为观测数据集中的真实分布  $q^i$ ，根据 KL 散度的定义式(4.14)可以转换成：

$$\sum_{i=1}^N \frac{1}{N} D_{KL}(p \parallel q^i) = \sum_{i=1}^N \frac{1}{N} \int p \log \frac{p}{q^i} dx \quad (4.16)$$

对式(4.16)进行简化：

$$\begin{aligned} \sum_{i=1}^N \frac{1}{N} D_{KL}(p \parallel q^i) &= \sum_{i=1}^N \frac{1}{N} \int p [\log p - q^i] dx \\ &= \int p \left[ \log p \cdot \frac{1}{N} \sum_{i=1}^N 1 - \frac{1}{N} \sum_{i=1}^N \log q^i \right] dx \\ &= \int p \left[ \log p - \frac{1}{N} \sum_{i=1}^N \log q^i \right] dx \\ &= \int p \log \frac{p}{\prod_{i=1}^N q^{\frac{1}{N}}} dx \end{aligned} \quad (4.17)$$

式(4.14)中  $\inf$  为下确界，代表实数集合中的最小值，且 KL 散度具有非负性：

$D_{KL}(P \parallel Q) \geq 0$ 。且当  $p = \prod_{i=1}^N q^i$  时， $D_{KL}(P \parallel Q) = 0$ ，应用到式(4.17)中可以得到：

$$p^N = \prod_{i=1}^N q^i \quad (4.18)$$

PMU 和 SCADA 的观测数据均遵循高斯分布，所以上式中的概率密度函数 (PDF) 服从高斯分布。高斯分布的向量形式通常指多元高斯分布，其中  $(x_1, x_2, \dots, x_n)^T$  表示一个  $n$  维向量，多元高斯分布的概率密度函数表达式为：

$$p(x) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{|\Sigma|}} \exp \left[ -\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right] \quad (4.19)$$

其中， $\mu$  是均值向量， $\Sigma$  是协方差矩阵， $|\Sigma|$  表示协方差矩阵的行列式， $\Sigma^{-1}$  是协方差矩阵的逆矩阵，此外，高斯分布的概率密度函数（PDF）还可以采用另一种表示形式，即标准形式：

$$p(x) = \exp \left( \zeta + \eta^T x - \frac{1}{2} x^T \Lambda x \right) \quad (4.20)$$

$\zeta$  是一个与归一化常数相关的标量， $\eta$  是一个线性系数向量， $\Lambda$  是正定矩阵，表示精度矩阵(协方差矩阵的逆，即  $\Lambda = \Sigma^{-1}$ )，其中  $\eta = \Sigma^{-1} \mu$ ， $\zeta = -\frac{1}{2} (d \log 2\pi - \log |\Lambda| + \eta^T \Lambda^{-1} \eta)$ 。这种标准形式在统计推断和优化任务中非常实用，简化了线性和二次项的计算，在多元高斯模型的应用中拥有着较高的计算效率。

对于式（4.18），将  $N$  个相同的概率密度函数的乘积进行简化：

$$\begin{aligned} p(x)^N &= \exp \sum_{i=1}^N \left[ \zeta + \eta^T x - \frac{1}{2} x^T \Lambda x \right] \\ &= \exp \left[ N\zeta + (N\eta)^T x - \frac{1}{2} x^T N\Lambda x \right] \end{aligned} \quad (4.21)$$

对于  $N$  个高斯 PDF 的乘积进行转化，其中  $i=1 \dots n$ ：

$$\prod_{i=1}^N q^i(x) = \exp \left[ \zeta_{i=1 \dots n} + \left( \sum_{i=1}^N \eta_i \right)^T x - \frac{1}{2} x^T \left( \sum_{i=1}^N \Lambda_i \right) x \right] \quad (4.22)$$

将  $\zeta$  单独提取出来可以得到式（4.23）：

$$\begin{aligned} \zeta_{i=1 \dots n} &= \sum_{i=1}^N \zeta_i \\ &= -\frac{1}{2} \left( nd \log 2\pi - \sum_{i=1}^N \log |\Lambda_i| + \sum_{i=1}^N \eta_i^T \Lambda_i^{-1} \eta_i \right) \end{aligned} \quad (4.23)$$

将式(4.23)代入到式(4.22)中可以得到：

$$\begin{aligned} \prod_{i=1}^N q^i(x) &= \exp \left[ \zeta_{i=1\dots N} + \zeta_N - \zeta_N + \left( \sum_{i=1}^N \boldsymbol{\eta}_i \right)^T x - \frac{1}{2} x^T \left( \sum_{i=1}^N \mathbf{A}_i \right) x \right] \\ &= \exp(\zeta_{i=1\dots N} - \zeta_N) \exp \left( \zeta_N + \boldsymbol{\eta}_N^T x - \frac{1}{2} x^T \mathbf{A}_N x \right) \end{aligned} \quad (4.24)$$

其中

$$\mathbf{A}_N = \sum_{i=1}^N \mathbf{A}_i, \boldsymbol{\eta}_N = \sum_{i=1}^N \boldsymbol{\eta}_i \quad (4.25)$$

$$\zeta_n = -\frac{1}{2} \left( Nd \log 2\pi - \log |\mathbf{A}_N| + \boldsymbol{\eta}_N^T \mathbf{A}_N^{-1} \boldsymbol{\eta}_N \right) \quad (4.26)$$

由此可以得到：

$$\prod_{i=1}^N q^i(x) = \exp \left( \zeta_N + \boldsymbol{\eta}_N^T x - \frac{1}{2} x^T \mathbf{A}_N x \right) \quad (4.27)$$

若要使式(4.18)成立，且满足 KL 散度的非负性，则需要式(4.21)和式(4.27)中的系数相等，由此可以得到：

$$\begin{cases} N\mathbf{A} = \mathbf{A}_N \\ N\boldsymbol{\eta} = \boldsymbol{\eta}_N \end{cases} \quad (4.28)$$

将其代入到高斯概率密度函数的标准形式中，可以得到：

$$\begin{cases} \bar{\boldsymbol{\Sigma}}^{-1} = \frac{1}{N} \sum_{i=1}^N \boldsymbol{\Sigma}_i^{-1} \\ \bar{\boldsymbol{\Sigma}}^{-1} \bar{\boldsymbol{\mu}} = \frac{1}{N} \sum_{i=1}^N \boldsymbol{\Sigma}_i^{-1} \boldsymbol{\mu}_i \end{cases} \quad (4.29)$$

式(4.29)中包含了融合后数据的矩阵和方差，为状态更新的过程提供了必要条件，因此可以结合式(4.29)建立信息矩阵和信息向量。

#### 4.3.3 基于信息滤波的电力系统状态估计

根据第三章中式(3.20)建立状态方程， $\mathbf{f}(\cdot)$  经过线性化后可以得到状态方程：

$$\mathbf{x}_f(k+1) = \mathbf{F}\mathbf{x}_f(k) + \mathbf{U}_f(k) + \mathbf{w}_f(k) \quad (4.30)$$

依据式(4.2)建立虚拟观测方程：

$$\mathbf{z}_f = \mathbf{H}_f \mathbf{x}_f + \mathbf{v}_f \quad (4.31)$$

其中,  $\mathbf{z}_f = \bar{\boldsymbol{\mu}}$  为虚拟观测值, 表示 PMU 和 SCADA 融合后的等效量测,  $\mathbf{v}_f$  为测量噪声, 且  $\mathbf{v}_f \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_f)$ ,  $\mathbf{R}_f = \bar{\boldsymbol{\Sigma}}$  为虚拟观测噪声协方差,  $\mathbf{H}_f$  为由式(4.10)得到的观测矩阵, 用来描述虚拟观测与状态值之间的映射关系。

信息滤波作为卡尔曼滤波的一种数学等价形式, 通过信息矩阵(逆协方差矩阵)和信息向量表示状态估计, 这种形式在多传感器数据融合中具有独特的优势。为了初始化算法, 本节提出以下假设<sup>[67]</sup>: 初始状态值为  $\lambda_0(\mathbf{x}) = \mathcal{D}(\mathbf{x}; \hat{\mathbf{x}}_0; \mathbf{P}_0)$ ,  $\hat{\mathbf{x}}_0$  是初始状态的先验估计,  $\mathbf{P}_0$  为初始方差; 初始过程噪声为  $\lambda_v(\mathbf{v}) = \mathcal{D}(\mathbf{v}; \mathbf{0}; \mathbf{R}_f)$ , 初始测量噪声为  $\lambda_w(\mathbf{w}) = \mathcal{D}(\mathbf{w}; \mathbf{0}; \mathbf{Q}_f)$ , 其中  $\mathcal{D}$  表示参数化高斯分布, 即  $\mathcal{D}(\mathbf{x}; \hat{\mathbf{x}}, \mathbf{P}) \triangleq \mathcal{N}(\mathbf{x}; \hat{\mathbf{x}}, \mathbf{P})$ ,  $\hat{\mathbf{x}}_0$  和  $\mathbf{P}_0$  是已知量,  $\mathbf{R}_f, \mathbf{Q}_f$  为已知的正定矩阵, 在这种情况下, 可以得到以下贝叶斯滤波递归方程:

1. 预测步骤: 基于上一时刻状态估计, 通过系统动态模型预测当前时刻的先验状态分布。

$$\lambda_{k+1}(x) = \int \lambda_w[x - f(\xi)] \lambda_k(\xi) d\xi \quad (4.32)$$

其中,  $\lambda_k(\xi)$  为  $k$  时刻的后验信息向量,  $f(\xi)$  为非线性状态转移函数,  $\lambda_w(\cdot)$  为过程噪声的概率分布, 参数化可转为  $\mathcal{D}(\mathbf{v}; \mathbf{0}; \mathbf{R}_f)$ 。

2. 更新步骤: 融合当前时刻的观测数据  $\mathbf{z}_k$ , 修正先验估计以获取更精确的后验分布。

$$\lambda_k(\mathbf{x}) = \frac{\lambda_v[\mathbf{z}_k - \mathbf{H}(\mathbf{x})] \lambda_k(x)}{\int \lambda_v[\mathbf{z}_k - \mathbf{H}(\xi)] \lambda_k(\xi) d\xi} \quad (4.33)$$

其中,  $\lambda_k(\xi)$  为  $\mathbf{x}_k$  的概率密度函数, 此时, 贝叶斯滤波递推公式存在闭合解, 在满足线性高斯系统假设条件下, 贝叶斯滤波递推方程可显式解析求解(即存在闭合形式解)。具体约束条件为:

- (1) 系统线性性: 状态转移矩阵与观测矩阵均为线性算子;
- (2) 噪声高斯性: 过程噪声与观测噪声均服从高斯分布;

(3) 模型线性化：式(4.30)与式(4.31)中的状态转移矩阵与观测矩阵已完成线性化处理。

由于式(4.30)和式(4.31)过程矩阵和观测矩阵均经过线性化操作，因此在此条件下，贝叶斯滤波递推过程可解析表述为以下高斯分布参数更新形式：

后验分布（更新阶段）：

$$\lambda_k(\mathbf{x}) = \mathcal{D}(\mathbf{x}; \hat{\mathbf{x}}_k, \mathbf{P}_k) \quad (4.34)$$

预测分布（传播阶段）：

$$\lambda_{k+1}(\mathbf{x}) = \mathcal{D}(\mathbf{x}; \hat{\mathbf{x}}_{k+1}, \mathbf{P}_{k+1}) \quad (4.35)$$

其中，后验概率密度函数  $\lambda_k(\mathbf{x})$  和预测概率密度函数  $\lambda_{k+1}(\mathbf{x})$  均保持高斯特性，均值向量  $\hat{\mathbf{x}}_k$ 、 $\hat{\mathbf{x}}_{k+1}$ ，以及协方差矩阵  $\mathbf{P}_{k+1}$ 、 $\mathbf{P}_k$  可以通过卡尔曼滤波递推公式(第二章中式(2.30)-式(2.35))得到<sup>[66]</sup>，为了将高斯分布参数从协方差空间映射至信息空间，结合式(4.29)定义以下信息矩阵  $\mathbf{A}_k$  和信息向量  $\boldsymbol{\delta}_k$ ：

$$\begin{aligned} \mathbf{A}_k &= (\mathbf{P}_k)^{-1} & \mathbf{A}_{k+1} &= (\mathbf{P}_{k+1})^{-1} \\ \boldsymbol{\delta}_k &= \mathbf{A}_k \hat{\mathbf{x}}_k & \boldsymbol{\delta}_{k+1} &= \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k+1} \end{aligned} \quad (4.36)$$

测量更新阶段：融合当前时刻观测值  $z_k$ ，修正先验信息参数以获取后验估计，信息向量更新：

$$\boldsymbol{\delta}_k = \boldsymbol{\delta}_{k-1} + (\mathbf{H})^T (\mathbf{R})^{-1} z_k \quad (4.37)$$

其中， $\boldsymbol{\delta}_{k-1}$  为  $k-1$  时刻的后验信息向量， $\mathbf{H}$  为线性观测矩阵， $\mathbf{R}$  为观测噪声协方差矩阵，观测数据  $z_k$  通过加权(权重为  $\mathbf{H}^T \mathbf{R}^{-1}$ )直接叠加至先验信息向量，体现观测数据对状态估计的修正作用，信息矩阵更新：

$$\mathbf{A}_k = \mathbf{A}_{k-1} + (\mathbf{H})^T (\mathbf{R})^{-1} \mathbf{H} \quad (4.38)$$

其中， $\mathbf{A}_{k-1}$  为  $k-1$  时刻的后验信息矩阵，观测信息  $\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$  以线性方式累积至信息矩阵，反映融合新数据后估计不确定性的降低。

假设系统矩阵  $F$  可逆，对于信息向量和信息矩阵的预测步骤可以总结如下：

预测信息向量:

$$\delta_{k+1} = F^{-T} \left[ I - A_k (A_k + F^T Q^{-1} F) \right] \delta_k \quad (4.39)$$

通过状态转移矩阵  $F$  的逆传播历史信息，并引入过程噪声  $Q$  的抑制作用，调整信息权重分布。预测信息矩阵:

$$A_{k+1} = F^{-T} A_{k+1} F^{-1} - F^{-T} A_k (A_k + F^T Q^{-1} F)^{-1} A_k F^{-1} \quad (4.40)$$

为确保式(4.40)与式(4.41)的数学有效性， $F$  需满足系统矩阵可逆性的约束条件。在采样数据系统中，该矩阵通常通过连续时间系统矩阵的离散化方法（如零阶保持器、双线性变换等）获得。当系统矩阵不可逆时（例如因离散化引入的秩缺失或病态条件数），可以采用广义平方根滤波器规避矩阵求逆操作<sup>[66]</sup>。利用式(4.37)-式(4.40)定义的信息滤波器，基于信息滤波形式，进行状态估计输出融合估计值，具体步骤如下：

(1)本地测量更新：采集观测值  $z_k$ ，通过式(4.38)-式(4.39)计算初始后验信息对：  $(A_{k,[0]}, \delta_{k,[0]})$ 。

(2)在 KLA 的基础上执行  $L$  步共识迭代，  $(\varsigma = 0, 1, \dots, L-1)$ ：

$$A_{k,[\varsigma+1]} = \sum_{\sigma \in N} \pi^\sigma A_{k,[\varsigma]}^\sigma \quad (4.41)$$

$$\delta_{k,[\varsigma+1]} = \sum_{\sigma \in N} \pi^\sigma \delta_{k,[\varsigma]}^\sigma \quad (4.42)$$

其中  $\pi^\sigma$  为信息矩阵  $A_k$  和  $\delta_k$  信息向量的融合权重，在融合结束后可以得到融合后信息对：

$$(\delta_k, A_k) := (\delta_{k,[L]}, A_{k,[L]}) \quad (4.43)$$

(3)将融合后信息对转换为状态估计的均值与协方差矩阵：

$$\hat{x}_k = (A_k)^{-1} \delta_k, P_k = (A_k)^{-1} \quad (4.44)$$

输出当前时刻  $k$  的状态估计结果  $\hat{x}_k$  及协方差  $P_k$ 。

(4)基于融合后信息对  $(\delta_k, A_k)$ ，通过式(4.43)和式(4.44)算下一时刻先验信息对  $(\delta_{k+1}, A_{k+1})$ 。

## 4.4 仿真实验和结果分析

### 4.4.1 仿真系统

本次仿真使用 MATLAB R2018b 进行仿真，为了为获取测量数据，本研究采用 MATLAB 中的 MatPower7.1 工具箱执行高斯-牛顿潮流计算，用于更新整个系统的电压幅值潮流计算的结果，特别是电压幅值和相角，表示系统的真实状态变量。此外，为了对系统状态进行长期观察，仿真总时间  $T$  定为 80s。此外，为更接近实际运行条件，在 PMU 和 SCADA 的观测数据中加入高斯噪声，其方差分别为  $\sigma_s = 0.02$ ， $\sigma_p = 0.01$ 。

### 4.4.2 仿真数值分析

在电力系统中，电压幅值和相角是描述电力系统状态的重要参数。通过对电压幅值和相角状态的估计，该方法能够及时发现并处理电力系统中的异常情况，提升电力系统的稳定性和可靠性。其次，它还可以用于电力系统的故障诊断和故障定位。通过对电压幅值和相角状态的估计，可以判断电力系统中故障的类型和位置，为故障处理提供指导。

为了避免偶然性对仿真实验的影响，实验分别在两个电力系统中进行，以更好地确定仿真实验的准确性。对在 SCADA 的时间尺度上进行状态估计算法(传统 SE)与本章提出的基于 KLA 数据融合状态估计算法(融合 SE)进行了对比，图 4-5 和图 4-6 分别显示了在 IEEE-14 总线系统中的节点 8 和 IEEE-30 总线系统中的节点 28 上，传统估计器和融合估计器在单一节点上的状态估计结果图，重点展示了估计器在迭代计算过程中的每一时刻的状态估计结果。

根据潮流计算，IEEE-14 系统中 8 号节点的真实电压幅值应为 1.610p.u.。在迭代过程中，该值作为基准来比较传统估计器和融合估计器的性能。从图 4-5 可以看出，在 80 秒仿真周期内，传统估计器的电压幅值的估计值波动较大，而基于 KLA 数据融合的融合估计器的波动则明显小于传统的状态估计器。在  $t = 25s$  时，传统 SE 偏离真实值最大，误差达到  $\Delta V_{pmu} = 0.045p.u.$ ，而融合估计器的同

期误差仅为 $\Delta V_{\text{Fusion}} = 0.012\text{p.u.}$ 。图 4-6 显示，在 IEEE-30 节点系统中，传统 SE 在  $t=10\text{s}$  至  $t=30\text{s}$  期间，因 SCADA 噪声干扰出现周期性波动(峰值误差 $\Delta V_{\text{PMU}} = 0.062\text{p.u.}$ )，而融合估计器通过 KL 散度动态调整权重，将同期误差限制在 $\Delta V_{\text{Fusion}} = 0.018\text{p.u.}$ 以内。




图 4-5 IEEE-14 总线系统 8 号节点融合前后电压幅值




图 4-6 IEEE-30 总线 28 号节点融合前后电压幅值




图 4-7 同一时刻 IEEE-14 总线各个节点电压幅值状态估计结果




图 4-8 同一时刻 IEEE-30 总线各个节点的电压幅值状态估计结果

本次仿真的时间周期为  $T = 80s$ ，且 14 节点系统和 30 节点系统的节点数过多，在仿真的过程中随机选择节点数进行展示。这样做是为了展示在滤波过程中，融合估计器在不同时间段内的性能优于单个估计器，因此节点的选择并不具有任何特定意义。在 IEEE-14 系统中，选择 1 到 14 号节点中的任何一个。然而，在 IEEE-30 系统中，为了更好地区别于 IEEE-14 节点系统，本章从 15 到 30 号节点中进行了随机选择，当然其他节点也表现出类似的良好性能，如图 4-7 和

图 4-8 所示。




图 4-9 同一时刻 IEEE-14 总线各个节点电压相角状态估计结果

同时，为了更好的突出融合估计器的性能优势，对同一时刻内的电压相角进行了比对(如图 4-9 和图 4-10 所示)，可以明显看出，在 KLA 算法加成下，在同一时刻内，融合估计器对于各个节点的相角估计精度要优于传统估计器。




图 4-10 同一时刻 IEEE-30 总线的各个节点电压相角状态估计结果




图 4-11 IEEE-14 系统均方根误差 (RMSE)




图 4-12 IEEE-30 系统均方根误差 (RMSE)

RMSE 是一种常用的性能评估指标，用于衡量估计值与实际值之间的偏差。在本节中，RMSE 代表了估计电压状态与实际值之间的差异，通过计算预测值与真实值之间平方差的平均值的平方根来得出。该指标衡量了预测值与实际值之间的偏离程度，特别对数据集中的异常值敏感，较小的 RMSE 值表示估计器的性能更好，因为它意味着估计值与实际值之间的差距较小：

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{x}_i - x_i)^2} \quad (4.45)$$

其中， $m$  表示总的母线数。仿真中使用了 IEEE-14 和 IEEE-30 母线系统，因此  $m=14$  或  $m=30$ 。 $i$  表示母线编号，即  $i \in 1 \dots m$ 。 $\hat{x}_i$  和  $x_i$  分别表示电压的估计值和实际值。需要注意的是，此处计算的 RMSE 与所有节点的幅度相关，并展示了在 80 秒仿真期间的变化情况。

图 4-11 和图 4-12 分别展示了传统状态估计器和融合估计器在 IEEE-14 和 IEEE-30 节点系统中的均方根误差值。从图中可以观察到，无论是在 14 节点系统还是 30 节点系统中，融合估计器的整体均方根误差始终小于传统估计。这表明，在状态估计过程中，提出的融合估计器所得到的状态估计结果与真实值之间的偏差较小。

表 4-3 IEEE-14 系统各个节点的电压幅值估计误差平均值

| 节点 | SE-SCADA              | 传统 SE                 | 融合 SE                 |
|----|-----------------------|-----------------------|-----------------------|
| 1  | $7.60 \times 10^{-2}$ | $5.33 \times 10^{-3}$ | $3.31 \times 10^{-3}$ |
| 2  | $7.83 \times 10^{-2}$ | $4.00 \times 10^{-3}$ | $2.7 \times 10^{-3}$  |
| 3  | $0.49 \times 10^{-2}$ | $3.2 \times 10^{-3}$  | $0.58 \times 10^{-3}$ |
| 4  | $1.32 \times 10^{-2}$ | $5.9 \times 10^{-3}$  | $0.51 \times 10^{-3}$ |
| 5  | $0.79 \times 10^{-2}$ | $5.3 \times 10^{-3}$  | $1.38 \times 10^{-3}$ |
| 6  | $5.59 \times 10^{-2}$ | $1.12 \times 10^{-3}$ | $0.35 \times 10^{-3}$ |
| 7  | $4.00 \times 10^{-2}$ | $5.10 \times 10^{-3}$ | $3.8 \times 10^{-3}$  |
| 8  | $3.86 \times 10^{-2}$ | $9.1 \times 10^{-3}$  | $5.7 \times 10^{-3}$  |
| 9  | $3.55 \times 10^{-2}$ | $1.13 \times 10^{-2}$ | $3.5 \times 10^{-3}$  |
| 10 | $8.67 \times 10^{-2}$ | $1.35 \times 10^{-2}$ | $4.35 \times 10^{-3}$ |
| 11 | $6.81 \times 10^{-2}$ | $5.14 \times 10^{-3}$ | $2.05 \times 10^{-3}$ |
| 12 | $5.08 \times 10^{-2}$ | $1.51 \times 10^{-3}$ | $1.1 \times 10^{-3}$  |
| 13 | $1.10 \times 10^{-2}$ | $1.85 \times 10^{-3}$ | $1.2 \times 10^{-3}$  |
| 14 | $2.28 \times 10^{-2}$ | $8.6 \times 10^{-3}$  | $1.89 \times 10^{-3}$ |

表 4-4 不同节点系统中算法的平均计算时间(秒)

| 算法    | IEEE-14 节点            | IEEE-30 节点            |
|-------|-----------------------|-----------------------|
| 传统 SE | $1.86 \times 10^{-2}$ | $4.87 \times 10^{-2}$ |
| 融合 SE | $3.72 \times 10^{-2}$ | $8.13 \times 10^{-2}$ |

表 4-4 表示了本章算法和传统状态估计算法在 IEEE-14 节点系统和 IEEE-30 节点系统中的平均计算时间，相比较传统状态估计算法，本章提出的算法虽然在计算时间上略有增加，但是本章算法的到状态值相比于传统状态估计算法拥有着更高的精度，这对电网的稳定运行是十分关键的，因此证明了本章算法具有一定的有效性。

#### 4.5 本章小结

本章针对 PMU 和 SCADA 采样速率比不成整数的情况下，通过集中收取某一时刻内的全部 SCADA 和 PMU 测量值，利用 KLA 散度求得的新分布建立观测方程，然后通过信息滤波的方式求得融合状态估计值，解决了第三章算法在部分场景下无法应用的问题，并通过仿真实验验证了算法的有效性。

## 第 5 章 总结与展望

### 5.1 总结

作为智能电网实时监控体系的核心组件，状态估计技术通过多数据融合与建模，实现了电网运行状态的高精度动态感知。该技术不仅是能量管理系统的智能化核心模块，更是构建新型电力系统安全防御体系的关键技术支撑。随着广域测量技术的突破性进展，PMU 依托北斗/GNSS 授时技术实现精确同步精度，为状态估计提供高精度的数据。虽然完全依赖 PMU 数据可以实现线性状态估计并显著缩短计算时间，但在若短期内全面实现这一转变仍面临较大挑战。这一挑战在于大多数电力系统对 SCADA 系统的长期依赖，企业对 SCADA 基础设施进行了大量投资，现有的 SCADA 系统在电力系统中运行稳定，没有重大问题或缺陷。因此，全面更换将导致严重的经济损失。PMU 和传统的 SCADA 系统将在电网内共存。这就产生了一个复杂的场景，需要通过不同采样率的传感器阵列来监测系统状态。本文针对电力系统混合状态估计问题，详细介绍了电力系统状态估计的原理和多传感器数据融合的结构，对于二者采样速率的差异，本文提出两种不同情况下的电力系统状态估计方法，主要研究内容如下：

(1) 阐述了电力系统状态估计的基本理论，包括交流模型的详细讨论。同时，分别介绍了多传感器数据融合的三种方法，以及每一种方法适应的场景。接着，文中深入探讨了 PMU 和 SCADA 二者的数据差异性，分别对它们的成分差异、采样频率差异进行了介绍。

(2) 提出了一种基于 Holt-EKF 的状态估计方法。在假设 PMU 和 SCADA 采样率比为正整数的情况下，利用滑动窗口的方法实现了 PMU 数据与 SCADA 数据在时间尺度上的对齐，在传统扩展卡尔曼滤波框架中引入自适应 Holt 平滑参数，从而提高了状态预测的精度，并利用改进后的扩展卡尔曼滤波对窗口内 SCADA 非采样时刻的状态值进行预测。最后，采用最小均方误差（MMSE）加权融合方法，对窗口内已经实现时间对齐的状态估计数据进行加权融合，得到最终的融合估计结果。

(3) 针对采样率比非整数的情况，本文进一步提出了基于 KLA 数据融合的

状态估计方法。该方法通过在一定时间段内对 PMU 与 SCADA 观测数据进行归纳, 利用 KLA 求得最能反映数据集合特征的概率分布, 并基于该分布构建相应的观测方程, 再通过信息滤波技术实现数据融合, 最终获得融合后的状态估计值。仿真实验结果表明, 所提出的两种数据融合方法在不同采样条件下均能有效缓解数据采样不匹配问题, 提高电力系统状态估计的精度和鲁棒性。

## 5.2 展望

本文针对电力系统混合状态估计的问题, 提出一种基于 PMU 量测和 SCADA 量测数据融合的策略, 重点解决数据融合中两种不同量测数据的差异性问题。尽管已获得一定成果, 但仍存在不足, 有待进一步改进, 如:

(1) 本文中的研究假设 PMU 和 SCADA 的噪声服从高斯分布, 但是在实际作业过程中, 电网里可能存在非高斯噪声(如脉冲干扰、重尾分布噪声等), 在这种非高斯分布的噪声环境下, 传统卡尔曼滤波的线性化方法可能失效。若在非高斯噪声的环境进行状态估计, 针对上述问题, 可以研究基于  $H_\infty$  滤波或者容积卡尔曼滤波(CKF)的非线性估计方法, 提升算法对非高斯噪声的鲁棒性, 并且结合自适应阈值策略, 对异常噪声进行动态检测与抑制。

(2) 本文是在 IEEE 标准节点系统中进行的, 然而随着可再生能源渗透率提高, 电力系统的动态特性更加复杂, 诸如太阳能和风能的广泛部署, 迫切需要深入探究如何更有效地将这些可再生能源资源整合到智能电网中。这一探究需解决新能源出力强随机性与传统模型刚性之间的矛盾, 可以构建风光储联合模型, 结合深度学习算法研究数据-物理融合驱动方法, 解决新能源随机性对状态估计的影响。

(3) 本文的研究基于仿真环境, 后续条件允许的情况下需通过硬件实验验证算法的工程适用性, 可以根据 RT-LAB 等平台构建硬件在环测试系统, 模拟实际 PMU/SCADA 通信链路, 验证算法在数据丢包、时钟不同步等非理想场景下的鲁棒性, 结合实际电网试点应用, 可以选择在微电网系统或者工业园区中部署融合估计系统, 收集运行数据并迭代优化算法, 开发可视化监控界面, 辅助调度人员实时决策。

## 参考文献

- [1] 于尔铿, 刘广一, 周京阳, 等. 能量管理系统[M]. 北京, 科学出版社, 1998.
- [2] Yu L, Kumar A S, Junbo Z, et al. Dynamic state estimation for power system control and protection IEEE task force on power system dynamic state and parameter estimation[J]. IEEE Transactions On Power Systems, 2021, 36(6): 5909-5921.
- [3] 陈建民, 周健, 蔡霖. 面向智能电网愿景的变电站二次技术需求分析[J]. 华东电力, 2008, 36(11): 37-39.
- [4] Rana M M, Li L, Su S W, et al. Consensus-based smart grid state estimation algorithm[J]. IEEE Transactions on Industrial Informatics, 2017, 14(8): 3368-3375.
- [5] 格桑曲珍. 智能电网中的电力电子技术分析[J]. 电子技术, 2024, 53(05): 168-169.
- [6] 于尔铿. 电力系统状态估计[M]. 北京:水利电力出版社, 1985.
- [7] 韩茂岳, 尹忠东, 沈子伦, 等. 基于相量测量单元优化配置的配电网谐波状态估计研究[J]. 科学技术与工程, 2024, 24(08): 3243-3250.
- [8] Pei C, Xiao Y, Liang W, et al. A deviation-based detection method against false data injection attacks in smart grid[J]. IEEE Access, 2021, 9: 15499-15509.
- [9] Li Y, Wang Y, Hu S. Online generative adversary network based measurement recovery in false data injection attacks: A cyber-physical approach[J]. IEEE Transactions on Industrial Informatics, 2020, 16(3): 2031-2043.
- [10] Wang H, Wen X, Xu Y, et al. Operating state reconstruction in cyber physical smart grid for automatic attack filtering[J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 2909-2922.
- [11] Hossan M S, Chowdhury B, Schoene J, et al, Advanced distribution management system: implementation, assessment, and challenges[C]// 2018 IEEE Power & Energy Society General Meeting (PESGM), Portland, USA, 2018:1-5.

- [12]Latheef A A , Negnevitsky M. Estimation of power system voltage with limited measurement[C]//2009 Australasian Universities Power Engineering Conference (AUPEC), Adelaide, Australia, 2009: 1-5.
- [13]Zhao J, Gómez-Expósito A, Netto M, et al. Power system dynamic state estimation: Motivations, definitions, methodologies, and future work[J]. IEEE Transactions on Power Systems, 2019, 34(4): 3188-3198.
- [14]Zhou N, Meng D, Huang Z, et al. Dynamic state estimation of a synchronous machine using PMU data: A comparative study[J]. IEEE Transactions on Smart grid, 2014, 6(1): 450-460.
- [15]Costa A S, Albuquerque A, Bez D. An estimation fusion method for including phasor measurements into power system real-time modeling[J]. IEEE Transactions on Power Systems, 2013, 28(2): 1910-1920.
- [16]Du J, Ma S, Wu Y C, et al. Distributed hybrid power state estimation under PMU sampling phase errors[J]. IEEE Transactions on Signal Processing, 2014, 62(16): 4052-4063.
- [17]魏新迟, 徐琴, 柳劲松等. 基于同步相量测量的配电网状态估计方法[J]. 电力系统及其自动化学报, 2023, 35(09): 30-39.
- [18]Gomez-Quiles C, de la Villa Jaen A, Gomez-Exposito A. A factorized approach to WLS state estimation[J]. IEEE Transactions on Power Systems, 2011, 26(3): 1724-1732.
- [19]肖润龙, 王刚, 郝晓亮, 等. 静态状态估计中权重矩阵确定的方法研究[J]. 计算机仿真, 2018, 35(09): 391-396.
- [20]陈艳波, 高瑜珑, 赵俊博, 等. 综合能源系统状态估计研究综述[J]. 高电压技术, 2021, 47(07): 2281-2292.
- [21]王海涛, 白建伟, 刘文等. 基于改进两阶段鲁棒优化的电力系统状态估计方法[J]. 电网与清洁能源, 2022, 38(09): 55-64.
- [22]SSheweppe F C. Power system static-state estimation, part I-III[J]. IEEE Trans. Power Apparatus System, 1970, 89(1): 120-135.

- [23]Benedito R A S, Alberto L F C, Bretas N G, et al. Power system state estimation: Undetectable bad data[J]. International Transactions on Electrical Energy Systems, 2014, 24(1): 91-107.
- [24]Chughtai A H, Akram U, Tahir M, et al. Dynamic state estimation in the presence of sensor outliers using MAP-based EKF[J]. IEEE Sensors Letters, 2020, 4(4): 1-4.
- [25]Zhang Y J, Liu J, Li Y G, et al. A method of state estimation with variable weights iteration based on piecewise linear weight function[C]//2016 China International Conference on Electricity Distribution(CICED), Xi'an, China, 2016: 1-4.
- [26]Kundu S, Alam M, Roy B K S, et al. Power systems state estimation using complex synchronized pmu measurements: two novel non-iterative approaches[J]. Arabian Journal for Science and Engineering, 2023, 48(5): 5935-5951.
- [27]Huang Z, Schneider K, Nieplocha J. Feasibility studies of applying Kalman filter techniques to power system dynamic state estimation[C]// 2007 International Power Engineering Conference (IPEC), Singapore, 2007: 376–382.
- [28]俞文帅, 张晓华, 卫志农等. 基于深度神经网络的电力系统快速状态估计[J]. 电网技术, 2021, 45(7): 2551-2561.
- [29]Li X, Xu S. Multi-sensor complex network data fusion under the condition of uncertainty of coupling occurrence probability[J]. IEEE Sensors Journal, 2021, 21(22): 24933-24940.
- [30]王俊娜, 雷静. 多传感器信息融合及其应用综述[J]. 信息记录材料, 2016, (5): 78-79.
- [31]Deng F, Huang Y, Lu S, et al. A multi-sensor data fusion system for laser welding process monitoring[J]. IEEE Access, 2020, 8: 147349-147357.
- [32]陈建平, 胡占强, 苏晓东. 智能化断路器机械特性在线监测关键技术设计[J]. 高压电器, 2014, 50(04): 108-112+119.
- [33]Hu G, Xu L, Gao B, et al. Robust unscented Kalman filter-based decentralized

- multisensor information fusion for INS/GNSS/CNS integration in hypersonic vehicle navigation[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [34] 闫莉萍. 多速率传感器状态融合估计及多分辨率图像融合算法研究[D]. 北京: 清华大学, 2006.
- [35] Khaleghi B, Khamis A A, Karray F O, et al. Multisensor data fusion: A review of the state-of the-art[J]. Information Fusion, 2013, 14(1): 28-44.
- [36] 罗潘. 多速率传感器系统的状态融合估计算法研究[D]. 电子科技大学, 2021.
- [37] You W, Li F, Liao L, et al. Data fusion of UWB and IMU based on unscented Kalman filter for indoor localization of quadrotor UAV[J]. Ieee Access, 2020, 8: 64971-64981.
- [38] Kong L, Peng X, Chen Y, et al. Multi-sensor measurement and data fusion technology for manufacturing process monitoring: a literature review[J]. International journal of extreme manufacturing, 2020, 2(2): 022001.
- [39] Xing C, Huang J, Wang Z, et al. A multi-system weighted fusion method to improve measurement accuracy of structured light 3D profilometry[J]. Measurement Science and Technology, 2022, 33(5): 055401.
- [40] Khodarahmi M, Maihami V. A review on Kalman filter models[J]. Archives of Computational Methods in Engineering, 2023, 30(1): 727-747.
- [41] 刘津硕. 基于 PMU 的电力系统状态估计研究[D]. 吉林大学, 2019.
- [42] Geng H, Liu H, Ma L, et al. Multi-sensor filtering fusion meets censored measurements under a constrained network environment: advances, challenges and prospects[J]. International Journal of Systems Science, 2021, 52(16): 3410-3436.
- [43] Liang Y, Chen T W, Pan Q. Multi-rate optimal state estimation[J]. International Journal of Control, 2009, 82(11): 2059-2076.
- [44] 陶平平, 冯肖亮. 二维卡尔曼滤波的多源信息集中式融合去噪方法[J]. 科技创新与应用, 2018, (20): 33-34.

- [45]Gandhi A, Adhvaryu K, Poria S, et al. Multimodal sentiment analysis: A systematic review of history, datasets, multimodal fusion methods, applications, challenges and future directions[J]. Information Fusion, 2023, 91: 424-444.
- [46]C.Federico. A review of data fusion techniques[J]. The Scientific world journal, 2013, 704504.
- [47]邓自立. 信息融合估计理论及其应用[M]. 北京: 科学出版社, 2012.
- [48]Dobakhshari A S, Azizi S, Paolone M, et al. Ultra fast linear state estimation utilizing SCADA measurements[J]. IEEE Transactions on Power Systems, 2019, 34(4): 2622-2631.
- [49]Musleh A S, Chen G, Dong Z Y. A survey on the detection algorithms for false data injection attacks in smart grids[J]. IEEE Transactions on Smart Grid, 2019, 11(3): 2218-2234.
- [50]Wang X, Shi D, Wang J, et al. Online identification and data recovery for PMU data manipulation attack[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 5889-5898.
- [51]Ruan J, Liang G, Zhao J, et al. An inertia-based data recovery scheme for false data injection attack[J]. IEEE Transactions on Industrial Informatics, 2022, 18(11): 7814-7823.
- [52]De Oliveira-De Jesus P M, Rodriguez N A, Celeita D F, et al. PMU-based system state estimation for multi-grounded distribution systems[J]. IEEE Transactions on Power Systems, 2020, 36(2): 1071-1081.
- [53]Battistelli G, Chisci L, Morrocchi S, et al. An information-theoretic approach to distributed state estimation[J]. IFAC Proceedings Volumes, 2011, 44(1): 12477-12482.
- [54]Kashyap N, Werner S, Huang Y F, et al. Power system state estimation under incomplete PMU observability—A reduced-order approach[J]. IEEE Journal of Selected Topics in Signal Processing, 2014, 8(6): 1051-10624.
- [55]Asprou M, Kyriakides E. Enhancement of hybrid state estimation using pseudo

- flow measurements[C]//2011 IEEE Power and Energy Society General Meeting, MI, USA, 2011:1-7.
- [56]曲正伟,董一兵,王云静,等.用于电力系统动态状态估计的改进鲁棒无迹卡尔曼滤波算法[J].电力系统自动化,2018,42(10): 87-92.
- [57]Zhao J, Gómez-Expósito A, Netto M, et al.. Power system dynamic state estimation: Motivations, definitions, methodologies, and future work[J]. IEEE Transactions on Power Systems, 2019, 34(4): 3188-3198.
- [58]Soni S, Bhil S D, Wagh S. Linear state estimation model using phasor measurement unit (PMU) technology[C]//2012 9th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE), Mexico, Mexico, 2012: 1-6.
- [59]Kotha S K, Rajpathak B. Power system state estimation using non-iterative weighted least square method based on wide area measurements with maximum redundancy[J]. Electric power systems research, 2022, 206: 107794..
- [60]Ghosal M, Rao V. Fusion of multi-rate measurements for nonlinear dynamic state estimation of the power systems[J]. IEEE Transactions on Smart Grid, 2017, 10(1): 216-226.
- [61]Zimmerman R D, Murillo-Sánchez C E, Thomas R J. MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education[J]. IEEE Transactions on power systems, 2010, 26(1): 12-19.
- [62]Wang Y, Sun Y, Dinavahi V. Robust forecasting-aided state estimation for power system against uncertainties[J]. IEEE Transactions on Power Systems, 2019, 35(1): 691-702.
- [63]Kusljevic M D K, Poljak P D. Simultaneous reactive-power and frequency estimations using simple recursive WLS algorithm and adaptive filtering[J]. IEEE Transactions on Instrumentation and Measurement, 2011, 60(12): 3860-3867.
- [64]Hu P F, Gao W G, Li Y F, et al. Anomaly detection and state correction in smart

- grid using EKF and data compensation techniques[J]. IEEE Sensors Journal, 2024, 24(8): 12995-13009.
- [65] Kiio M N, Wekesa C W, Kamau S I. Evaluating Performance of a Linear Hybrid State Estimator Utilizing Measurements From RTUs and Optimally Placed PMUs, IEEE Access,2022, 10:63113-63131.
- [66]Mutambara A G O. Decentralized estimation and control for multisensor systems[M]. Routledge, 2019.
- [67]Alriksson P, Rantzer A. Distributed Kalman filtering using weighted averaging[C]//17th International Symposium on Mathematical Theory of Networks and Systems, 2006.
- [68]Braverman V, Ostrovsky R, Zaniolo C. Optimal sampling from sliding windows[C]//Proceedings of the twenty-eighth ACM SIGMOD-SIGACT-SIGART symposium on Principles of database systems. 2009: 147-156.
- [69]杜万里, 周家成, 张建国, 等. 基于滑动窗口算法的镜面反射率标定软件系统设计[J]. 仪表技术, 2025, (01): 1-4+16.

## 攻读硕士期间取得的学术成果

- [1] Zhu J, Gao W, Li Y, et al. Power System State Estimation Based on Fusion of PMU and SCADA Data[J]. Energies, 2024, 17(11): 2609.
- [2] Zhu J, Gao W. Multi-rate measurement fusion for power system state estimation. 2024 International Symposium on New Energy Technologies and Power Systems, NanJing, China, 2024, 2814(1): 012034.

## 致谢

星霜浮沉处，砚边春秋已悄然流转。当暮色浸染最后一页书稿，回首求学路上的云月长河，万千感怀如檐下雨珠，点滴浸润心田。在此，我要向所有陪伴我、支持我、指导我走过这段旅程的人表达衷心的感谢。

首先，衷心感谢我的导师高文根教授。您严谨的治学态度和精益求精的科研精神，如同灯塔始终指引着我的学术航向。从选题方向的把握到论文框架的搭建，从实验设计的优化到学术规范的打磨，每个环节都凝结着您的智慧与心血。您不仅教会我如何用科学思维破解难题，更以身作则诠释了科研工作者应有的责任与担当。

其次，我要感谢李云飞老师在论文写作中给予的指导。您总能在组会上精准捕捉论证漏洞，用清晰的逻辑梳理帮我跳出思维困局。从文献综述的结构调整到数据分析的方法优化，您细致的批注建议让论文逐渐褪去青涩。尤其记得您在出差途中仍逐句修改文稿，使我能够顺利完成这篇论文，并在学术研究中取得了长足的进步。

此外，我要感谢实验室的同门和师弟师妹们，他们在学术和生活上给予了我很多启发和帮助。我们共同探讨问题、分享经验，一起度过了许多难忘的时光。你们的陪伴使我的研究生生涯充满了欢笑与温暖、使我在学术研究的道路上不再孤单。

今当别离，惟愿将此番山水相逢的暖意，酿作他日重逢时的桂花陈酿。学术长路虽漫漫，幸有诸君赠我满天星斗，纵使独行亦不惧夜寒。

尚德敏学 唯实惟新

