

DOI: 10.19783/j.cnki.pspc.231088

基于 Koopman 算子与卡尔曼滤波的同步发电机动态状态估计

焦鹏悦¹, 杨德友², 蔡国伟¹

(1. 东北电力大学电气工程学院, 吉林 吉林 132012; 2. 哈尔滨理工大学电气与电子工程学院, 黑龙江 哈尔滨 150080)

摘要: 动态状态估计是监测同步发电机动态行为的重要手段, 准确的动态状态估计结果对于指导电力系统安全运行与高效控制具有重要意义。从数据驱动的角度出发, 提出了基于 Koopman 算子与卡尔曼滤波的同步发电机动态状态估计方法。该方法首先利用汉克尔动态模态分解算法从发电机动态响应数据中提取 Koopman 算子, 进而以提取的 Koopman 算子为基础构建同步发电机状态空间模型, 并利用卡尔曼滤波对同步发电机状态变量进行动态估计。该方法无须事先构建发电机模型及参数, 实现了完全数据驱动的动态状态估计。仿真实验结果表明, 在发电机模型及参数失配的情况下该方法估计精度明显高于传统以模型为基础的估计结果, 具有较好的自适应性和鲁棒性。

关键词: 动态状态估计; 模型; 数据驱动; Koopman 算子; 卡尔曼滤波; 汉克尔动态模态分解

Dynamic state estimation for a synchronous generator based on the Koopman operator and Kalman filter

JIAO Pengyue¹, YANG Deyou², CAI Guowei¹

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 2. School of Electrical and Electronic Engineering, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: Dynamic state estimation is an important means of monitoring the dynamic behavior of synchronous generators, and accurate results are important for guiding safe operation and efficient control of power systems. From a data-driven perspective, this paper proposes a method for estimating the dynamic state of synchronous generators based on the Koopman operator and Kalman filter. The method first extracts the Koopman operator from synchronous generator dynamic response data using the Hankel dynamic mode decomposition algorithm, and then constructs a state space model of the synchronous generators based on the extracted Koopman operator. The state variables of synchronous generators are dynamically estimated by Kalman filter. The algorithm does not require prior construction of generator models or parameters and achieves fully data-driven dynamic state estimation. Simulation results show that this algorithm has good adaptability and robustness and exhibits significantly higher accuracy than traditional model-based estimation results using mismatched generator models and parameters.

This work is supported by the Science and Technology Project of the Headquarters of State Grid Corporation of China (No. 5108-202299255A-1-0-ZB).

Key words: dynamic state estimation; model; data-driven; Koopman operator; Kalman filter; Hankel dynamic mode decomposition

0 引言

新型电力系统是新型能源供给体系的重要组成部分和实现“双碳”目标的核心载体。相比于同步发电机主导的传统电力系统, 新型电力系统惯量低、阻尼弱、抗扰能力差、调节特性弱、受扰后动态过程

复杂^[1-4], 对系统及元件动态轨迹跟踪能力提出了更高的要求。具有数据同步功能的相量测量单元(phasor measurement unit, PMU)已应用于电力系统状态估计^[5-7], 为快速准确地跟踪电力系统复杂动态过程(如同步发电机机电暂态)提供了可靠的数据平台。近年来, 以 PMU 为数据平台的同步发电机动态状态估计研究受到了国内外学者的广泛关注。动态状态估计亦称滤波, 本质是利用实际量测对系统模型的预测值进行修正, 因此, 同步发电机动态模型(含参数)和高性能滤波算法是实现同步发电机高精度

基金项目: 国家电网有限公司总部科技项目资助(5108-202299255A-1-0-ZB); 国家重点研发计划项目资助(2021YFB2400800)

动态状态估计的两个关键。目前基于物理模型的状态估计方法仍是主流^[8], 重点关注高性能滤波算法的应用以及量测数据噪声的处理^[9-10]。动态状态估计中常用的典型滤波算法主要有卡尔曼滤波(Kalman filtering, KF)、拓展卡尔曼滤波(extended Kalman filter, EKF)、无迹卡尔曼滤波(unscented Kalman filter, UKF)、容积卡尔曼滤波(cubage Kalman filter, CKF)以及粒子滤波(particle filter, PF)。

文献[11]针对 EKF 线性化精度不足的问题, 通过插值降低线性化过程的误差。UKF、CKF 常存在噪声协方差矩阵非正定导致的滤波失败问题, 文献[12-13]引入平方根滤波分别对其进行改进, 增强了数值稳定性。文献[14]在 UKF 中加入异常数据修正环节, 通过修正系数来降低异常数据的影响。文献[15]在 CKF 中采用隐式梯形积分雅克比矩阵重用策略辨识并修正不良数据, 提升了滤波鲁棒性。文献[16]采用 Sage-Husa 噪声统计估值器对系统噪声实时估计, 提出了一种自适应 UKF, 取得了较好的结果。针对测量中的异常值与非高斯噪声, 文献[17]基于广义最大似然估计改进 UKF, 提升了估计的精度与效率。文献[18]在测量存在异常数据时使用基于指数平滑的状态量预报代替状态方程的预测值, 以提升估计过程中 CKF 的鲁棒性。PF 以最大后验概率为准则, 能够直接处理非线性问题, 文献[19-20]提出了基于 PF 的同步发电机动态状态估计方法。此外, 基于渐消因子^[21]、 L_∞ ^[22]等理论的改进型滤波方法也已被用于同步发电机动态状态估计中。对高性能滤波算法的研究仍在不断进行。

准确的同步发电机模型及参数是对同步发电机进行动态状态估计的另一个关键问题。由于滤波算法自身无法处理发电机模型阶数不匹配及参数不精确的问题, 目前对于动态状态估计的研究多数是在默认发电机模型及其参数精确性满足要求的基础上开展的, 但研究表明, 特别是现有同步发电机模型参数精度仍有待提高。文献[23]利用从动态响应数据中提取的状态空间模型实现了同步发电机动态状态估计, 为基于数据驱动方法开展动态状态估计提供了新的思路。

1 基于卡尔曼滤波的动态状态估计

1.1 同步发电机状态空间模型

同步发电机状态空间模型是动态状态估计的基础。综合考虑模型的精细程度与计算复杂度, 选取同步发电机四阶状态方程建立状态空间模型。

同步发电机四阶状态方程如式(1)所示。

$$\begin{cases} \dot{\delta} = \frac{180}{\pi}(\omega - \omega_0) \\ \dot{\omega} = \frac{1}{T_j}(T_m - T_e - D(\omega - \omega_0)) \\ \dot{E}'_q = \frac{1}{T'_{d0}}[E_{fd} - E'_q - (X_d - X'_d)I_d] \\ \dot{E}'_d = \frac{1}{T'_{q0}}[-E'_d + (X_q - X'_q)I_q] \end{cases} \quad (1)$$

式中: δ 为功角, rad; ω 为转速, p.u., ω_0 为转速初值; T_m 、 T_e 分别为机械转矩和电磁转矩; D 为阻尼系数; T_j 为转子惯性时间常数, 且 $T_j = 2H$, 其中 H 为惯性常数; T'_{d0} 、 T'_{q0} 分别为 d 轴和 q 轴开路时间常数; X'_d 、 X'_q 分别为 d 轴和 q 轴暂态电抗; X_d 、 X_q 分别为 d 轴和 q 轴同步电抗; E_{fd} 为励磁电动势; E'_d 、 E'_q 分别为 d 轴和 q 轴暂态电动势; I_d 、 I_q 分别为定子 d 轴和 q 轴电流。

实践中, ω 的变化量很小, 标么值几乎保持为 1。因此对于机械功率 P_m 和电磁功率 P_e , 根据 $T_m = P_m / \omega$ 及 $T_e = P_e / \omega$, 取标么值时可以不区分转矩和功率。

根据式(1), 系统状态量为

$$\mathbf{x} = [\delta \ \omega \ E'_q \ E'_d]^T \quad (2)$$

控制量 \mathbf{u} 和量测量 \mathbf{y} 为

$$\begin{cases} \mathbf{u} = [E_{fd} \ P_m \ I_R \ I_L]^T \\ \mathbf{y} = [\delta \ \omega \ e_R \ e_L]^T \end{cases} \quad (3)$$

式中: I_R 、 I_L 分别为定子 R 轴和 L 轴电流; e_R 、 e_L 分别为定子 R 轴和 L 轴电动势。 I_d 、 I_q 可由 I_R 、 I_L 和状态量表示, e_R 、 e_L 可由状态量和常数表示。

基于上述分析, 可建立同步发电机的状态空间模型。考虑到系统实际测量的离散性与存在的噪声, 应取系统的离散型非线性状态空间模型如式(4)所示。

$$\begin{cases} \mathbf{x}_{k+1} = f_d(\mathbf{x}_k, \mathbf{u}_k, \mathbf{q}_k) \\ \mathbf{y}_{k+1} = h_d(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, \mathbf{r}_k) \end{cases} \quad (4)$$

式中: \mathbf{q}_k 代表过程噪声; \mathbf{r}_k 代表量测噪声; $f_d(\cdot)$ 、 $h_d(\cdot)$ 为差分方程。

1.2 基于卡尔曼滤波的动态状态估计流程

卡尔曼滤波及其拓展是动态状态估计中的常用方法, 其基本思想是利用数据的冗余度来提高所估计状态的精度, 即将不同的不精确数据进行最优结

合来获得更精确的数值。卡尔曼滤波首先利用上一时刻的状态值和状态方程获取当前时刻状态的预测值, 再根据量测方程和当前量测值修正预测值, 得到更精确的结果。这一过程可归纳为状态预测步和状态滤波步。

1) 状态预测步

利用 k 时刻的状态计算状态的一步预测值, 如式(5)所示。

$$\hat{\mathbf{x}}_{k+1|k} = \mathbf{F}\mathbf{x}_{k|k} + \mathbf{B}\mathbf{u}_{k+1} \quad (5)$$

式中: \mathbf{F} 为状态矩阵; \mathbf{B} 为控制矩阵。

同时按式(6)更新协方差阵 \mathbf{P} 。

$$\mathbf{P}_{k+1|k} = \mathbf{F}\mathbf{P}_{k|k}\mathbf{F}^T + \mathbf{Q}_{k+1} \quad (6)$$

式中, \mathbf{Q} 为过程噪声协方差矩阵。

式(5)、式(6)完成了状态在时间上的更新。

2) 状态滤波步

$\hat{\mathbf{x}}_{k+1|k}$ 并不是准确值, 接下来利用量测值对这一预测值进行修正, 得到滤波值, 即状态的最优估计。按式(7)计算卡尔曼增益。

$$\mathbf{S}_{k+1} = \mathbf{P}_{k+1|k}\mathbf{H}_k^T(\mathbf{H}_k\mathbf{P}_{k+1|k}\mathbf{H}_k^T + \mathbf{R}_{k+1})^{-1} \quad (7)$$

式中: \mathbf{S}_{k+1} 为卡尔曼增益矩阵; \mathbf{H} 为量测矩阵; \mathbf{R} 为量测噪声协方差矩阵。

按式(8)更新状态量。

$$\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + \mathbf{S}_{k+1}(\mathbf{y}_{k+1} - \mathbf{H}\hat{\mathbf{x}}_{k+1|k}) \quad (8)$$

按式(9)修正协方差矩阵。

$$\mathbf{P}_{k+1|k+1} = (\mathbf{I} - \mathbf{S}_{k+1}\mathbf{H}_{k+1})\mathbf{P}_{k+1|k} \quad (9)$$

式中, \mathbf{I} 为单位矩阵。

重复式(5)~式(9)就完成了卡尔曼滤波的一次迭代。上述计算流程需要获取系统的状态矩阵和量测矩阵, 只适用于线性系统。在同步发电机动态状态估计中, 通常以上述流程为基础对卡尔曼滤波进行改进, 使其能够处理式(4)所示的非线性状态空间模型, 如 EKF、UKF 等都是基于处理非线性而得到的改进方法。

卡尔曼滤波类算法进行动态状态估计时具有计算速度快、所需内存小等优点, 在噪声统计特性已知、建模准确无误的条件下能够取得较好的估计结果。

2 基于 Koopman 算子的同步发电机状态空间建模

同步发电机状态空间模型及参数的准确性直接影响动态状态估计结果。传统基于同步发电机物理特性的建模方法所构建的二阶、三阶、四阶、五阶及六阶模型在多机系统中的精度仍难以保证。同时, 精确的模型参数获取同样困难。数据驱动的状态空

间建模方法有效避免了上述问题。

2.1 Koopman 理论

Koopman 理论能够利用数据分析非线性系统, 而不依赖任何模型信息, 为非线性系统的研究带来了新思路。

考虑某离散动力学系统, 如式(10)所示。

$$\mathbf{x}_t = \mathbf{g}(\mathbf{x}_{t-1}) \quad (10)$$

式中: \mathbf{x}_t 为动力系统在 t 时刻的 n 维状态向量, $\mathbf{x}_t \in M$, 其中 M 为状态空间, $M \in \mathbb{R}^n$; \mathbf{g} 为描述系统演化的非线性函数, 作用于系统状态。

设 Koopman 算子为 \mathcal{K} , 它是一个线性且高维(甚至无限维)的算子, 并直接作用于状态空间中的观测函数 \mathbf{z} , 其性质如下:

$$\mathcal{K}\mathbf{z}(\mathbf{x}_t) = \mathbf{z}(\mathbf{g}(\mathbf{x}_t)) \quad (11)$$

由于 \mathcal{K} 是一个线性算子, 通过其谱分解可以分析系统的特征。

$$\mathcal{K}\varphi_i(\mathbf{x}_t) = \lambda_i\varphi_i(\mathbf{x}_t), \quad i=1,2,\dots \quad (12)$$

式中: $\varphi_i(\cdot)$ 为 Koopman 本征函数(Koopman eigenfunction, KEF); λ_i 为 Koopman 本征值(Koopman eigenvalues, KE)。

在上述分析的基础上, 可基于 Koopman 理论将系统线性化, 函数 \mathbf{g} 可重构为

$$\mathbf{z}(\mathbf{x}_t) = \sum_{k=1}^{\infty} \mathbf{v}_k(\mathcal{K}^t\varphi_k)(\mathbf{x}_0) = \sum_{k=1}^{\infty} \mathbf{v}_k\lambda_k^t\varphi_k(\mathbf{x}_0) \quad (13)$$

式中: \mathbf{v}_k 为 Koopman 模态(Koopman mode, KM), 是一组在演化中保持不变的系数; \mathbf{x}_0 为 \mathbf{x} 的初值。

综上所述, 根据式(13), 系统的演化被转换为由 Koopman 模态控制的线性演化, 求出 \mathcal{K} 后就可以将非线性系统线性化, 并得出全局线性化的显式表达式。

2.2 数据驱动同步发电机状态空间模型

Koopman 算子理论的一大优越性在于其数据驱动特性, 在工程上可从数据中提取 Koopman 算子 \mathcal{K} 的有限维近似。动态模态分解(dynamic mode decomposition, DMD)算法是常用的从数据中提取 Koopman 算子近似的方法, 已经得到了广泛应用。然而, DMD 在系统动态较复杂或数据中噪声较大等场景的分析结果可能会出现较大的误差, 进而影响后续分析的准确度。

Hankel-DMD 是 DMD 的一种改进方法, 该方法在 DMD 的基础上利用 Koopman 算子和延时嵌入的关系来构造 Koopman 算子的近似, 将 Hankel 阵应用在 DMD 中, 从而能够更充分地捕获数据中的信息, 提高所求 Koopman 算子的精度^[24-25]。

假设系统进行了 m 次测量采样, 并构成数据序

列, 如式(14)所示。

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m] \quad (14)$$

可基于系统的测量构成 Hankel 矩阵^[26-27], 如式(15)和式(16)所示。

$$\mathbf{X}_1^p = \begin{bmatrix} \mathbf{x}_1 & \mathbf{x}_2 & \cdots & \mathbf{x}_{m-p} \\ \mathbf{x}_2 & \mathbf{x}_3 & \cdots & \mathbf{x}_{m-p+1} \\ \vdots & \vdots & & \vdots \\ \mathbf{x}_p & \mathbf{x}_{p+1} & \cdots & \mathbf{x}_{m-1} \end{bmatrix} \quad (15)$$

$$\mathbf{X}_2^p = \begin{bmatrix} \mathbf{x}_2 & \mathbf{x}_3 & \cdots & \mathbf{x}_{m-p+1} \\ \mathbf{x}_3 & \mathbf{x}_4 & \cdots & \mathbf{x}_{m-p+2} \\ \vdots & \vdots & & \vdots \\ \mathbf{x}_{p+1} & \mathbf{x}_{p+2} & \cdots & \mathbf{x}_m \end{bmatrix} \quad (16)$$

式中, $\mathbf{X}_1^p, \mathbf{X}_2^p \in \mathbb{R}^{np \times (m-p)}$ 。

基于构造的数据矩阵可进一步利用 DMD 求取 Koopman 算子的近似, 并将非线性系统重构为线性系统。

通过式(15)和式(16)可求 Koopman 算子的近似, 如式(17)所示。

$$\tilde{\mathbf{K}} = \mathbf{X}_2^p (\mathbf{X}_1^p)^\dagger \quad (17)$$

式中: $\tilde{\mathbf{K}}$ 为所求 Koopman 算子的近似; \dagger 表示摩尔-彭罗斯逆。

接下来对 $\tilde{\mathbf{K}}$ 进行特征值分解, 如式(18)所示。

$$\tilde{\mathbf{K}} \mathbf{w}_i(\mathbf{x}_i) = \mu_i \mathbf{w}_i(\mathbf{x}_i), i = 1, 2, \dots \quad (18)$$

式中: μ 为近似的 Koopman 本征值, μ_i 代表其第 i 个量; \mathbf{w} 为近似的 Koopman 模态, \mathbf{w}_i 代表其第 i 个量。

最后求 Koopman 本征函数的近似, 其表达式如式(19)所示。

$$\mathbf{d}(\mathbf{x}_k) = \mathbf{Z}^{-1} \mathbf{X}_k \quad (19)$$

式中: \mathbf{Z} 为 $\tilde{\mathbf{K}}$ 的特征矩阵; \mathbf{d} 为近似的 Koopman 本征函数; \mathbf{X}_k 为 \mathbf{X}_1^p 的第 k 列。

式(15)~式(19)从数据中提取了 Koopman 算子的有限维近似及其对应的本征值、本征函数及模态, 体现了数据驱动的特性, 其结果可用于对系统动态的进一步分析。

在利用 Hankel-DMD 完成对 Koopman 算子提取的基础上, 可基于 Koopman 理论构建同步发电机的线性状态空间方程。

根据式(13)给出的线性化方法, 同步发电机的状态量可按同样方法重构, 如式(20)所示。

$$\mathbf{x}_t = \sum_{k=1}^{q=np} \mathbf{w}_{1:n,k} (\tilde{\mathbf{K}}^t \mathbf{d}_k)(\mathbf{x}_0) = \sum_{k=1}^{q=np} \mathbf{w}_{1:n,k} \mu_k^t \mathbf{d}_k(\mathbf{x}_0) \quad (20)$$

式中: $\mathbf{w}_{1:n,k}$ 为 \mathbf{w}_k 的前 n 个元素; $\mathbf{d}_k(\mathbf{x}_0)$ 为 $\mathbf{d}(\mathbf{x}_0)$ 的

第 k 个元素; q 为重构维数, np 为其值; μ_k^t 代表 μ 的第 k 个量的乘方。

式(20)中系统演化为 μ 控制的线性演化。此表达式虽然为线性但还不能直接用于状态估计, 需将其转换为状态空间模型的形式。

经过推导与整理, 式(20)可转换为矩阵表示的线性形式:

$$\mathbf{D}(\mathbf{x}_{t+1}) = \underbrace{\begin{bmatrix} \mu_1 & & \\ & \ddots & \\ & & \mu_q \end{bmatrix}}_{\mathbf{U}} \underbrace{\begin{bmatrix} \mathbf{d}_1(\mathbf{x}_t) \\ \vdots \\ \mathbf{d}_q(\mathbf{x}_t) \end{bmatrix}}_{\mathbf{D}(\mathbf{x}_t)} \quad (21)$$

$$\mathbf{x}_{t+1} = \underbrace{\begin{bmatrix} \mathbf{w}_{1:n,1} & \cdots & \mathbf{w}_{1:n,q} \end{bmatrix}}_{\mathbf{W}} \mathbf{D}(\mathbf{x}_{t+1}) \quad (22)$$

式(21)和式(22)中的 \mathbf{D} 、 \mathbf{U} 及 \mathbf{W} 矩阵中的各元素均已求出, 且它们表述了系统的线性演化过程。

此时非线性系统的演化被转化为线性状态方程的形式, 得到了基于 Koopman 算子线性状态空间模型, 如式(23)所示。

$$\begin{cases} \mathbf{D}(\mathbf{x}_{t+1}) = \mathbf{U} \mathbf{D}(\mathbf{x}_t) \\ \mathbf{x}_{t+1} = \mathbf{W} \mathbf{D}(\mathbf{x}_{t+1}) \end{cases} \quad (23)$$

对于式(4)描述的非线性同步发电机状态空间模型, 将其转化为式(23)所描述的形式就实现了状态方程的线性化, 得到了动态状态估计中的线性状态空间模型, 并可以应用线性系统中卡尔曼滤波等相关方法完成动态状态估计。

本文基于 Koopman 理论的同步发电机动态状态估计流程如图 1 所示。

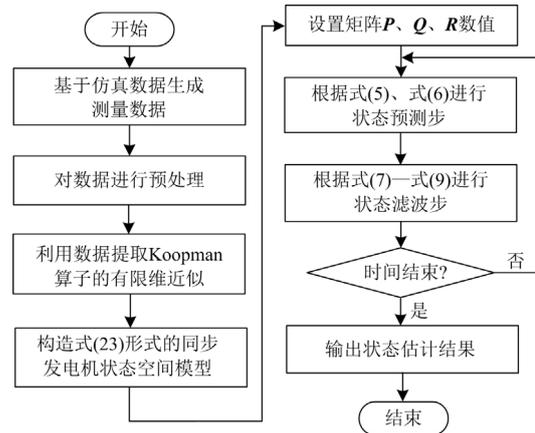


图 1 本文方法流程

Fig. 1 Flow chart of the proposed method

3 仿真计算与分析

为量化比较各算法在同步发电机动态状态估计中的性能差异, 引入均方根误差 (root mean squared error, RMSE) e_{RMSE} 作为性能指标, 其表达式如式(24)所示。

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{k=1}^N (x_k^i - \hat{x}_k^i)^2} \quad (24)$$

式中: N 为所估计的状态量采样点数; x_k^i 为真实值; \hat{x}_k^i 为估计值; i 表示状态量的第 i 个分量。

3.1 噪声协方差矩阵参数的选择

建立同步发电机的状态空间方程后, 需设置 Q 、 R 及 P 的取值以完成动态状态估计。

式(17)求出了 Koopman 算子的近似值, 并根据式(20)~式(22)将原系统转化为线性, 得到了式(23)所示的线性状态空间模型。但这一过程并不是绝对精确的, 从无限维到有限维近似必然会产生截断误差, 这些误差会在滤波中产生一定的影响。

在原始状态方程中, 根据文献[28], Q 的对角元素取状态量最大变化的 10% 的平方。

R 的取值与实际测量中的误差相关, 测量时 δ 的标准差取 2° , ω 的标准差取 10^{-3} [18], E'_d 、 E'_q 的标准差取 10^{-3} 。

则量测噪声协方差矩阵为

$$R = \begin{bmatrix} \left(\frac{2\pi}{180}\right)^2 & & & \\ & 10^{-6} & & \\ & & 10^{-6} & \\ & & & 10^{-6} \end{bmatrix} \quad (25)$$

而在式(23)中, Q 可视为一个调谐参数[29], 通过调整 Q 获得期望的渐近卡尔曼滤波器性能, Q 的对角元素取值为 10^{-6} 。对于 R , 由于引入截断误差, 在基于所建立的线性状态方程进行估计时, R 阵数据可取一个比原 R 阵更大的数值。

对于 P , 在线性状态方程中, 其初始值取值如式(26)所示。

$$P_0^h = (W)^\dagger P_0 (W^T)^\dagger \quad (26)$$

式中: P_0^h 为线性状态空间模型中 P 的初值; P_0 为原非线性系统 P 的初值。

值得注意的是, 本研究重点关注状态量 δ 的动态过程, 因此, 在利用 Hankel-DMD 提取发电机状态空间模型时所需要测量的状态量主要是发电机的功角 δ 和转速 ω 。

3.2 同步发电机模型参数异常环境下的性能验证

以 WSCC 3 机 9 节点系统为例测试所提方法的性能。系统节点图如图 2 所示。

选取同步发电机 G1、G2 为估计对象, G3 为参考机组, 仿真时所有同步发电机均采用二阶经典模型, 系统频率为 60 Hz。设仿真开始 0.1 s 后线路 5 与线路 7 所在的母线发生三相短路故障, 并分别在

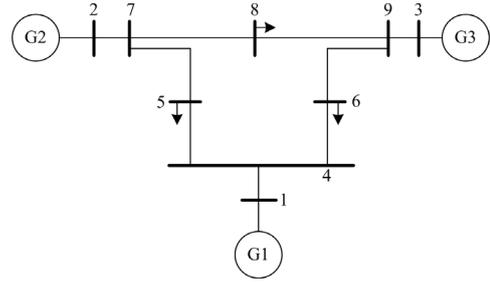


图 2 WSCC 3 机 9 节点系统

Fig. 2 WSCC 3-machine 9-bus system

0.05 s 和 0.1 s 后在近端和远端清除故障。利用电力系统工具箱(power system toolbox, PST)进行仿真, 以仿真值作为真实值, 并在仿真值的基础上叠加正态分布量测噪声作为测量值。在故障清除后进行动态状态估计, 共估计 409 个周波。

假设估计过程中同步发电机状态空间方程中参数 D 出现 +10% 误差, H 出现 -10% 的误差, 并在此发电机模型参数异常的条件下使用所提出的方法与平方根无迹卡尔曼滤波(square root unscented kalman filter, SRUKF)进行动态状态估计, 将结果进行对比, 分析性能的差异。

图 3、图 4 为估计过程中两台同步发电机功角的真实值、测量值、本文所提方法估计值和 SRUKF 估计值的对比图。

从图 3 和图 4 中可以看出, 在估计过程中, 随着估计的进行, 由于同步发电机参数的误差, SRUKF 的滤波曲线与真实值出现了偏离, 无法准确反映系统状态的变化。而本文所提方法通过测量数据构建系统状态空间方程, 避免了参数异常而引入的误差, 能够追踪系统状态的变化, 有效滤除测量值中的噪声。

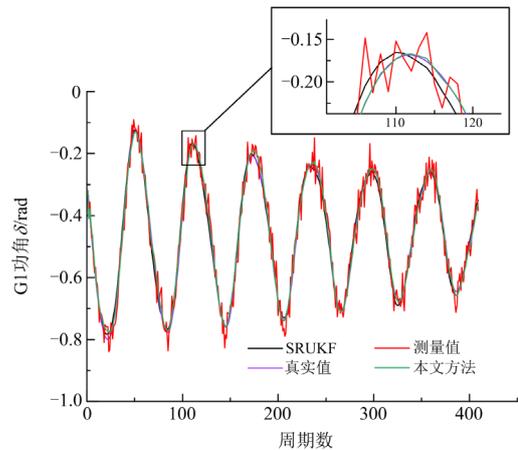


图 3 WSCC 3 机 9 节点系统 G1 功角

Fig. 3 Power angle of G1 in WSCC 3-machine 9-bus system

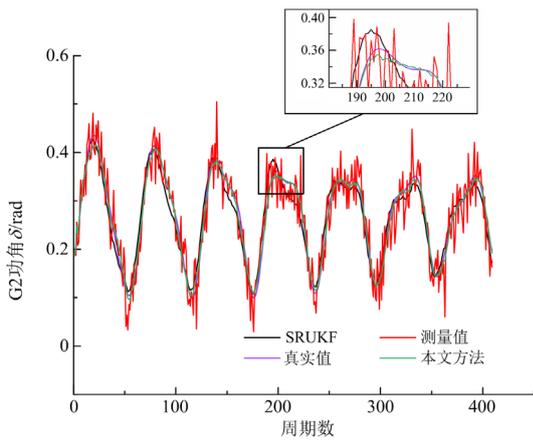


图 4 WSCC 3 机 9 节点系统 G2 功角

Fig. 4 Power angle of G2 in WSCC 3-machine 9-bus system

为了量化评估估计结果，表 1 给出了估计结果的 e_{RMSE} 指标。本文方法的 e_{RMSE} 值小于 SRUKF，进一步说明其优势。

表 1 WSCC 3 机 9 节点系统 e_{RMSE}

Table 1 The e_{RMSE} of WSCC 3-machine 9-bus system

状态量	算法	e_{RMSE}
G1 功角	本文方法	0.0097
	SRUKF	0.0148
G2 功角	本文方法	0.0088
	SRUKF	0.0203

为进一步量化本文方法的性能，对 G1 和 G2 的估计值与真实值的误差进行统计分析，如图 5 所示。通过分析估计误差的概率密度可知，本文提出方法的估计误差分布呈现明显的尖峰，且峰值在 0 附近，即误差集中于 0 附近，说明估计精度较高。而 SRUKF 的估计误差的分布尖峰不够明显，整体的分布也不对称，误差远离 0 处仍有大量分布，这再一次说明 SRUKF 的估计结果出现了显著偏差，本文所提方法具有更好的性能。

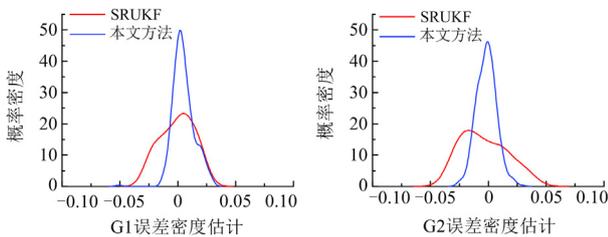


图 5 WSCC 3 机 9 节点系统 G1、G2 功角估计误差分析

Fig. 5 Power angle estimation error analysis of G1 and G2 in WSCC 3-machine 9-bus system

3.3 同步发电机模型阶数不匹配环境下性能验证

如前文所述，根据考虑的物理量的不同，同步

发电机的模型可分为二阶、四阶模型以及更复杂的高阶模型。但随着模型复杂程度的增加，模型中所包含的各种参数也随之增加，数学上的求解也更为困难，采用更高阶的模型未必能取得更高的精度。下面以 IEEE10 机 39 节点系统为例(如图 6 所示)，论证估计时所取模型阶数不匹配场景下所提方法的优势。

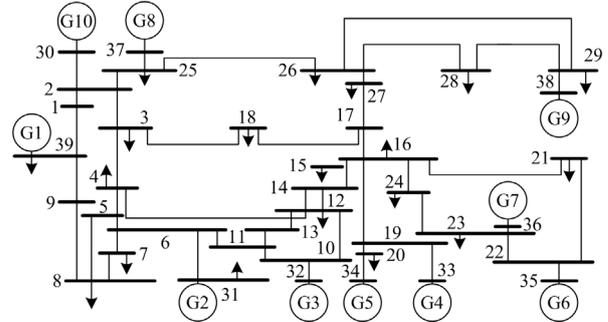


图 6 IEEE10 机 39 节点系统

Fig. 6 IEEE10-machine 39-bus system

采用 PST 进行仿真，仿真开始 0.1 s 后线路 3 与线路 4 所在的母线发生三相短路故障，并分别在 0.05 s 和 0.1 s 后在近端和远端清除故障。同步发电机 G10 为参考机组，G1—G9 为估计对象。仿真时所有同步发电机均采用四阶模型，系统频率、真实值及测量值的定义与选取等与 3.2 节相同。

为验证模型阶数不匹配场景下所提出方法的性能，在 IEEE10 机 39 节点系统中使用同步发电机二阶状态空间模型，采用 SRUKF 进行动态状态估计，并将估计结果与本文方法进行比较。图 7、图 8 展示了部分所估计同步发电机功角的真实值、测量值、本文方法估计值和 SRUKF 估计值的对比。

由于 SRUKF 方法采用同步发电机二阶模型进行估计，完全忽略同步发电机绕组磁链方程对 δ 的影响，估计过程中结果出现了较大的误差。

图 7、图 8 结果显示，在估计过程中，滤波的整体波形与真实值之间偏离明显，并且这种偏离在估计的过程中有增大的趋势，进一步说明此时 SRUKF 已经不能准确追踪系统状态的变化，难以对同步发电机功角进行准确的估计。而所提方法基于 Koopman 理论从测量数据中提取系统的动态信息，建立基于数据的状态空间模型，能够避免模型不准确引入的误差，精度相比基于模型的 SRUKF 方法有很大的改善，能够显著降低测量值中的噪声，反映系统真实状态。

计算估计结果的 e_{RMSE} 指标，结果如表 2 所示。可知所有同步发电机功角的 e_{RMSE} 值均有显著下降，平均下降幅度为 62.8%。基于 e_{RMSE} 的量化分析结果

证明了所提方法的有效性。

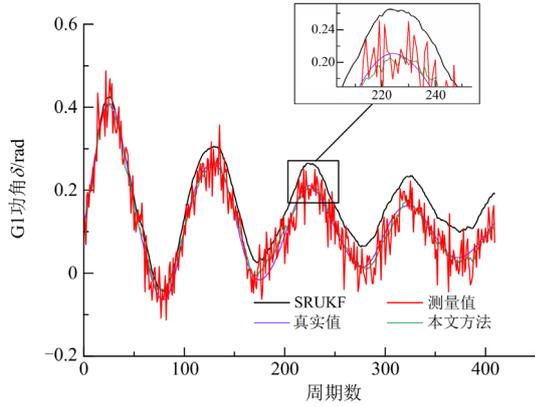


图 7 IEEE10 机 39 节点系统 G1 功角

Fig. 7 Power angle of G1 in IEEE10-machine 39-bus system

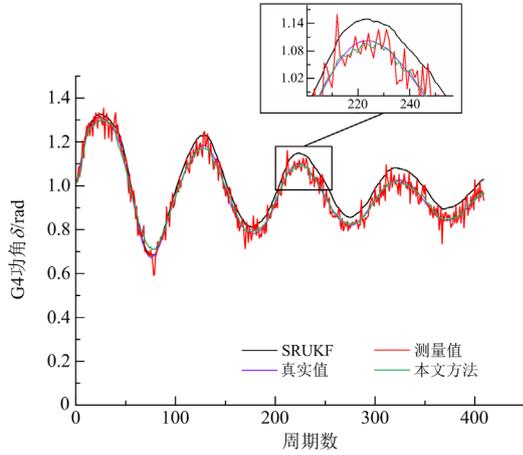


图 8 IEEE10 机 39 节点系统 G4 功角

Fig. 8 Power angle of G4 in IEEE10-machine 39-bus system

表 2 IEEE10 机 39 节点系统 e_{RMSE}

Table 2 The e_{RMSE} of IEEE10-machine 39-bus system

状态量	算法	e_{RMSE}
G1 功角	本文方法	0.0130
	SRUKF	0.0487
G2 功角	本文方法	0.0160
	SRUKF	0.0287
G3 功角	本文方法	0.0131
	SRUKF	0.0169
G4 功角	本文方法	0.0125
	SRUKF	0.0435
G5 功角	本文方法	0.0173
	SRUKF	0.0361
G6 功角	本文方法	0.0109
	SRUKF	0.0256
G7 功角	本文方法	0.0135
	SRUKF	0.0454
G8 功角	本文方法	0.0131
	SRUKF	0.0238
G9 功角	本文方法	0.0138
	SRUKF	0.0628

同样对估计误差的分布进行统计分析。由图 9 可知, 此时 SRUKF 的估计误差的分布出现了峰值不在 0 附近的尖峰, 而本文所提方法的估计误差呈现尖峰薄尾状态。这说明此时 SRUKF 的估计是有偏估计且偏离的程度较大, 而本文所提方法仍具有较高精度。对估计误差的分析更加充分地证明了本文方法的有效性。

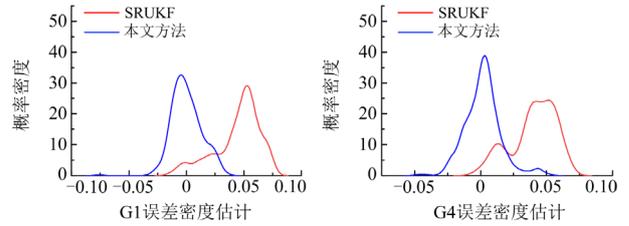


图 9 IEEE10 机 39 节点系统 G1、G4 功角估计误差分析

Fig. 9 Power angle estimation error analysis of G1 and G4 in IEEE10-machine 39-bus system

4 结论

针对动态状态估计过程可能出现的同步发电机模型阶数不匹配及参数不精确的问题, 本文提出了基于 Koopman 算子与卡尔曼滤波相结合的数据驱动型动态状态估计方法, 有效解决了同步发电机模型阶数不匹配及参数不精确导致的动态状态估计结果误差大的问题。仿真与测试结果表明:

- 1) Hankel-DMD 方法能够从有限数据中准确提取 Koopman 算子, 且对量测噪声具有很强的鲁棒性;
- 2) 基于 Koopman 算子构造的同步发电机状态空间模型能够正确反映同步发电机的动态特性, 具有集稳定预测与控制于一体的系统性框架潜能;
- 3) 本文提出的方法可以在同步发电机模型参数不精确及模型阶数不匹配的情况下完成动态状态估计。

本文在滤波估计过程中采用的是传统卡尔曼滤波算法, 如何结合更先进的滤波估计方法是下一步亟需开展的工作。

参考文献

- [1] 齐金山, 姚良忠, 廖思阳, 等. 高比例新能源电力系统静态电压稳定裕度在线概率评估[J]. 电力系统保护与控制, 2023, 51(5): 47-57.
QI Jinshan, YAO Liangzhong, LIAO Siyang, et al. Online probabilistic assessment of static voltage stability margin for power systems with a high proportion of renewable energy[J]. Power System Protection and Control, 2023, 51(5): 47-57.
- [2] 王中, 黎丽丽, 李振华, 等. 考虑新能源渗透的电网频率

- 概率分布研究[J]. 电力系统保护与控制, 2021, 49(20): 65-73.
- WANG Zhong, LI Lili, LI Zhenhua, et al. The evolution characteristics of power grid frequency probability distribution[J]. Power System Protection and Control, 2021, 49(20): 65-73.
- [3] 马也, 史丽萍, 李衡, 等. 基于 VSG 控制的微网逆变器工频振荡现象研究[J]. 电力系统保护与控制, 2022, 50(1): 107-115.
- MA Ye, SHI Liping, LI Heng, et al. Power frequency oscillation of a microgrid inverter based on VSG control[J]. Power System Protection and Control, 2022, 50(1): 107-115.
- [4] 苏鹏, 陈璐, 吴坚, 等. 新型电力系统多能源能量惯性动态优化控制模型[J]. 电力建设, 2022, 43(9): 87-93.
- SU Peng, CHEN Lu, WU Jian, et al. Dynamic optimal control model of multi-energy inertia in new power system[J]. Electric Power Construction, 2022, 43(9): 87-93.
- [5] 宋雨露, 樊艳芳, 刘牧阳, 等. 基于 SC-DNN 和多源数据融合的新能源电力系统状态估计方法[J]. 电力系统保护与控制, 2023, 51(9): 177-187.
- SONG Yulu, FAN Yanfang, LIU Muyang, et al. State estimation method of a new energy power system based on SC-DNN and multi-source data fusion[J]. Power System Protection and Control, 2023, 51(9): 177-187.
- [6] 魏新迟, 秦龙宇, 方陈, 等. 配电网同步相量测量技术与应用综述[J]. 电力建设, 2023, 44(5): 13-22.
- WEI Xinchu, QIN Longyu, FANG Chen, et al. Review of the synchronous measurement technology and its application in distribution networks[J]. Electric Power Construction, 2023, 44(5): 13-22.
- [7] 曹鹏, 刘敏, 杭鲁庆. 基于改进磷虾群算法的配电网 PMU 优化配置研究[J]. 电网与清洁能源, 2022, 38(4): 61-67.
- CAO Peng, LIU Min, HANG Luqing. Research on PMU optimal configuration of distribution networks based on improved krill herd algorithm[J]. Power System and Clean Energy, 2022, 38(4): 61-67.
- [8] 巨云涛, 黄炎. 适应非光滑特性的交直流混合电力系统状态估计[J]. 电力系统保护与控制, 2023, 51(2): 141-150.
- JU Yuntao, HUANG Yan. State estimation for an AC/DC hybrid power system adapted to non-smooth characteristics[J]. Power System Protection and Control, 2023, 51(2): 141-150.
- [9] 符杨, 张语涵, 田书欣, 等. 抵御多点虚假数据攻击的主动配电网状态估计方法[J]. 智慧电力, 2023, 51(4): 69-76, 83.
- FU Yang, ZHANG Yuhuan, TIAN Shuxin, et al. Active distribution network state estimation method against multi-point false data injection attacks[J]. Smart Power, 2023, 51(4): 69-76, 83.
- [10] 田钧祥, 陈铁, 陈彬. 基于改进自适应 UKF 算法的中压配电网鲁棒动态状态估计方法[J]. 中国电力, 2023, 56(11): 128-133.
- TIAN Junxiang, CHEN Tie, CHEN Bin. Robust dynamic state estimation method for medium voltage distribution networks based on improved adaptive UKF algorithm[J]. Electric Power, 2023, 56(11): 128-133.
- [11] 艾蔓桐, 孙永辉, 王义, 等. 基于插值 H^∞ 扩展卡尔曼滤波的发电机动态状态估计[J]. 中国电机工程学报, 2018, 38(19): 5846-5853, 5942.
- AI Mantong, SUN Yonghui, WANG Yi, et al. Dynamic state estimation for synchronous machines based on interpolation H^∞ extended Kalman filter[J]. Proceedings of the CSEE, 2018, 38(19): 5846-5853, 5942.
- [12] 安军, 杨振瑞, 周毅博, 等. 基于平方根容积卡尔曼滤波的发电机动态状态估计[J]. 电工技术学报, 2017, 32(12): 234-240.
- AN Jun, YANG Zhenrui, ZHOU Yibo, et al. Dynamic state estimator for synchronous-machines based on square root cubature Kalman filter[J]. Transactions of China Electrotechnical Society, 2017, 32(12): 234-240.
- [13] 卫志农, 孙国强, 庞博. 无迹卡尔曼滤波及其平方根形式在电力系统动态状态估计中的应用[J]. 中国电机工程学报, 2011, 31(16): 74-80.
- WEI Zhinong, SUN Guoqiang, PANG Bo. Application of UKF and SRUKF to power system dynamic state estimation[J]. Proceedings of the CSEE, 2011, 31(16): 74-80.
- [14] 张明, 徐诗露, 陆东亮, 等. 基于自适应 SRUKF 算法的电力系统动态谐波状态估计[J]. 电力系统保护与控制, 2023, 51(2): 102-111.
- ZHANG Ming, XU Shilu, LU Dongliang, et al. Dynamic harmonic state estimation of a power system based on adaptive SRUKF[J]. Power System Protection and Control, 2023, 51(2): 102-111.
- [15] 刘朋成, 项中明, 江全元, 等. 基于鲁棒容积卡尔曼滤波的同步发电机实时动态状态估计方法[J]. 电网技术, 2019, 43(8): 2860-2868.
- LIU Pengcheng, XIANG Zhongmin, JIANG Quanyuan, et al. Real-time dynamic state estimation method of synchronous generator based on Robust volumetric Kalman filter[J]. Power System Technology, 2019, 43(8): 2860-2868.
- [16] 赵洪山, 田甜. 基于自适应无迹卡尔曼滤波的电力系统动态状态估计[J]. 电网技术, 2014, 38(1): 3790-3794.

- ZHAO Hongshan, TIAN Tian. Dynamic state estimation for power system based on an adaptive unscented Kalman filter[J]. Power System Technology, 2014, 38(1): 3790-3794.
- [17] ZHAO Junbo, MILI L. A robust generalized-maximum likelihood unscented Kalman filter for power system dynamic state estimation[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(4): 578-592.
- [18] 朱茂林, 刘灏, 毕天姝, 等. 考虑输入量不良数据的发电机动态状态估计方法[J]. 电力系统自动化, 2022, 46(7): 94-103.
- ZHU Maolin, LIU Hao, BI Tianshu, et al. Dynamic state estimation method for generators considering bad data in input[J]. Automation of Electric Power Systems, 2022, 46(7): 94-103.
- [19] 蔡国伟, 郑存龙, 杨德友, 等. 基于粒子滤波算法的发电机机电暂态过程动态状态估计[J]. 电力系统自动化, 2016, 40(2): 49-54.
- CAI Guowei, ZHENG Cunlong, YANG Deyou, et al. Dynamic state estimation of electromechanical transient for generators based on particle filter algorithm[J]. Automation of Electric Power Systems, 2016, 40(2): 49-54.
- [20] 孙国强, 王晗雯, 卫志农, 等. 基于无迹粒子滤波理论的发电机动态状态估计方法[J]. 电力系统自动化, 2017, 41(14): 133-139.
- SUN Guoqiang, WANG Hanwen, WEI Zhinong, et al. Dynamic state estimation for generators based on unscented particle filtering algorithm[J]. Automation of Electric Power Systems, 2017, 41(14): 133-139.
- [21] 陈思未. 基于渐消因子的自适应发电机动态状态估计[J]. 水电能源科学, 2023, 41(3): 198-201.
- CHEN Siwei. Fading factor based adaptive dynamic state estimator for generators[J]. Water Resources and Power, 2023, 41(3): 198-201.
- [22] NUGROHO S A, TAHA A F, QI Junjian. Robust dynamic state estimation of synchronous machines with asymptotic state estimation error performance guarantees[J]. IEEE Transactions on Power Systems, 2020, 35(3): 1923-1935.
- [23] NETTO M, MILI L. A robust data-driven Koopman Kalman filter for power systems dynamic state estimation[J]. IEEE Transactions on Power Systems, 2018, 33(6): 7228-7237.
- [24] BRUNTON S L, BRUNTUN B W, PROCTOR J L, et al. Chaos as an intermittently forced linear system[J]. Nature Communications, 2017, 8(1): 19.
- [25] CHAMPION K P, BRUNTUN S L, KUTZ J N. Discovery of nonlinear multiscale systems: sampling strategies and embeddings[J]. SIAM Journal on Applied Dynamical Systems, 2019, 18(1): 312-333.
- [26] FILHO V E, SANTOS P L D. A dynamic mode decomposition approach with Hankel blocks to forecast multi-channel temporal series[J]. IEEE Control Systems Letters, 2019, 3(3): 739-744.
- [27] 庄旭, 戈宝军, 陶大军. 基于分块 Hankel 矩阵的抽水蓄能电机扩展卡尔曼滤波模型子空间循环辨识[J]. 中国电机工程学报, 2017, 37(24): 7328-7337, 7447.
- ZHUANG Xu, GE Baojun, TAO Dajun. Sub space cycle identification of pumped storage motor extended Kalman filter model based on block Hankel matrix[J]. Proceedings of the CSEE, 2017, 37(24): 7328-7337, 7447.
- [28] QI Junjian, SUN Kai, WANG Jianhui, et al. Dynamic state estimation for multi-machine power system by unscented Kalman filter with enhanced numerical stability[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1184-1196.
- [29] SURANA A. Koopman operator framework for time series modeling and analysis[J]. Journal of Nonlinear Science, 2018, 30(5): 1973-2006.
-
- 收稿日期: 2023-08-23; 修回日期: 2024-01-26
- 作者简介:
- 焦鹏悦(1998—), 男, 硕士研究生, 研究方向为电力系统状态估计; E-mail: 847310368@qq.com
- 杨德友(1983—), 男, 通信作者, 博士, 教授, 研究方向为电力系统稳定分析与控制; E-mail: dy0101232@163.com
- 蔡国伟(1968—), 男, 博士, 教授, 研究方向为电力系统稳定分析与控制。E-mail: caigw@mail.nedu.edu.cn
- (编辑 魏小丽)