

风电高渗透电网等效惯量概率预测方法

巴文岚¹,文云峰¹,叶希²,文明³,黄明增¹,张武其¹

(1. 湖南大学 电气与信息工程学院,湖南 长沙 410082;2. 国网四川省电力公司,四川 成都 610041;
3. 国网湖南省电力有限公司经济技术研究院,湖南 长沙 410118)

摘要:在虚拟惯量控制技术的驱动下,风电高渗透电网包含不同形式惯量资源,系统等效惯量呈现复杂的非线性时变波动特征。为更好地诠释系统等效惯量的不确定性,提出了一种考虑风机虚拟惯量的系统等效惯量概率预测方法。首先利用数据驱动方法构建系统等效惯量的点预测模型,预判等效惯量的变化趋势;然后采用非参数核密度估计建立各时段预测误差概率密度函数,得到一定置信水平下待预测时刻系统等效惯量可能发生波动的区间范围。基于改进的IEEE RTS-79系统进行算例分析,结果表明所提方法与传统参数估计方法相比可靠性更高,能够为新型电力系统在低惯量场景下运行方式安排提供有益的辅助决策信息。

关键词:双馈感应风机;系统等效惯量;惯量评估;惯量预测;不确定性

中图分类号:TM614

文献标志码:A

DOI:10.16081/j.epae.202209020

0 引言

构建以新能源为主体的新型电力系统是实现碳达峰、碳中和的主要举措之一。然而,风机大规模并网使得具有转动惯量的常规同步电源被不断替代。区别于同步电源,风机等非同步电源均通过电力电子换流器和电网接口,与系统频率解耦,有功功率扰动下不能为电网主动提供惯量支撑,导致系统惯量水平大幅降低、频率调节能力弱化^[1-2]。因此,低惯量电力系统的安全稳定运行将面临更大压力。

惯量评估已成为高比例新能源电力系统的热点研究问题,近年来,国内外学者在该领域开展了大量研究工作^[3-8]。文献[3]在瞬时输入扰动后,利用同步相量测量单元(phasor measurement unit, PMU)获取瞬态频率变化,基于频率变化率估计得到电网不同区域的惯量值,进而得到电力系统总惯量。文献[4]考虑频率和电压动态特性对系统功率变化的影响,基于摇摆方程建立电力系统振荡特征参数与惯量之间的数学表达式,从而实现系统惯量在线评估。文献[5-7]分别基于动态回归扩展与混合模型、带额外输入的自回归移动平均模型、马尔可夫切换模型等辨识方法对系统惯量进行在线估计,可在电网正常运行条件下给出连续的惯量估计值。欧洲一些电网运营商^[8]和我国部分区域电网调度中心研发了基于发电机出口断路器状态监测的电力系统惯量实时估计工具,主要用于估算系统中所有开机同步机组的整体惯量水平,尚未考虑虚拟惯量资源所能提供

的惯量贡献,不能真实反映多样化惯量资源并存下的系统惯量变化态势。

上述研究工作侧重于评估系统在当前运行时刻或扰动发生后的惯量水平,尚未探索未来时刻的系统惯量变化趋势预测问题。由于惯量响应迅速且短暂,对于规划和调度运行部门而言,可能因未提前预判系统惯量水平,致使系统在低惯量运行场景下频率失稳风险增大^[9]。对系统等效惯量进行预测有助于感知系统惯性水平的变化趋势,提前识别系统惯量小于临界水平的时间段,从而做好应对措施提高频率稳定性。因此,探索系统惯量水平的趋势预测方法具有重要研究意义。文献[10]提出一种基于人工神经网络的惯量预测方法,通过PMU得到的电力系统海量运行数据来预测系统惯量。然而,该方法仅对单独的样本点进行预测,并非时序预测。文献[11]基于各发电厂提交的未来时刻机组运行计划对系统惯量进行时序预测。文献[12]提出了一种基于最小方差谐波有限脉冲响应的惯量预测方法,关注可再生能源出力周期性导致的系统惯量时变特性。

现有的惯量预测方法所得结果都是确定的,只给出一个确定的预测数值。随着可再生能源渗透率的增加,可再生能源出力的间歇性和随机性将导致机组开机状态预测难度增大,依赖于机组运行计划的系统惯量点预测模型的准确性会降低。此外,上述研究仅考虑同步发电机转动惯量,未考虑风机提供的虚拟惯量。日益减少的火电机组逐渐难以独立承担不断增加的调频能力,电网在一定程度上要求风机提供一定的辅助调节能力^[13]。针对风电高渗透电网,有必要研究同步惯量与虚拟惯量并存下的系统等效惯量预测方法。由于风机出力受气象因素的影响具有强随机性和间歇性,使得系统运行方式复杂多变,系统等效惯量在时间尺度上将表现出较大

收稿日期:2022-01-17;修回日期:2022-04-01

在线出版日期:2022-09-21

基金项目:国家自然科学基金资助项目(52077066)

Project supported by the National Natural Science Foundation of China(52077066)

的波动特征,预测结果存在较高的不确定性。为此,亟需探索一种概率化的系统等效惯量预测表征方法,实现对惯量预测不确定性的量化。

本文提出了一种考虑风机虚拟惯量的系统等效惯量概率预测方法。利用数据驱动的CatBoost集成学习算法构建系统等效惯量点预测模型,并采用非参数核密度估计(kernel density estimation, KDE)建立各时段预测误差概率密度函数。所提方法可得到待预测时刻系统等效惯量的概率密度函数和一定置信水平下的预测区间,实现对惯量变化不确定性区间的动态估计,为电网运行方式人员提供更为全面的概率统计信息。

1 考虑风机虚拟惯量的系统等效惯量特性分析

为了提升风机并网友好性,目前已有技术规程要求并网风机参与惯性支撑和辅助调频^[14]。双馈感应风机(doubly-fed induction generator, DFIG)因其优良的变速恒频运行特性和经济性,在并网风机中占有主导地位。根据实际风况的不同,并网风机输出最大功率曲线可分为启动区、最大功率点跟踪区、恒转速区和恒功率区,如图1所示。图中: $\omega_{\min}$ 和 $\omega_{\max}$ 分别为风机的最低并网转速和风机运行最大转速; ω 为风机转子转速; ω_s 为恒转速区风速下限; P 为风机输出功率; $P_{\max}$ 为输出功率最大值。




图1 最大功率曲线

Fig.1 Maximum power curve

根据贝茨理论,风机捕获的机械功率 P_w 可表示为:

$$\begin{cases} P_w = \frac{1}{2} \rho C_p(\lambda, \beta) A v^3 \\ C_p(\lambda, \beta) = 0.22 \left(\frac{116}{\lambda_i} - 0.45 \beta - 5 \right) e^{-\frac{12.5}{\lambda_i}} \\ \frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08 \beta} - \frac{0.035}{\beta^3 + 1} \\ \lambda = \frac{\omega R}{v} \end{cases} \quad (1)$$

式中: ρ 为空气密度; A 为风机扫风面积; v 为风速; $C_p(\lambda, \beta)$ 为风能利用系数,其为以叶尖速比 λ 和桨距角 β 为自变量的非线性函数; R 为叶轮半径。

文献[15]给出了反映风机有效储能的虚拟惯性时间常数的计算方法:当风机运行于启动区时,风机不具备惯量响应能力,无可惯量^[16];当 $\omega_{\min} \leq \omega \leq$

$\omega_{\max}$ 及 $\omega > \omega_{\max}$ 时,风机等效虚拟惯性时间常数分别如式(2)、(3)所示。当采用最大功率点跟踪控制时,风机的风速、转子转速与机组出力存在一一对应关系,因此,风机虚拟惯性时间常数可表示为风速、转子转速或机组出力的函数。

$$H_w = \frac{1}{S_{n,w}} \left\{ \frac{1}{2} J_w (\omega_0^2 - \omega_{\min}^2) - \int_{t_{on}}^{t_{off}} \left[\frac{1}{2} \rho \pi R^2 C_{pmax} v^3 - 0.11 \rho \pi R^2 v^3 \left[116 \left(\frac{v}{\omega R} - 0.035 \right) - 5 \right] \times e^{-12.5 \left(\frac{v}{\omega R} - 0.035 \right)} \right] dt \right\} \quad \omega_{\min} \leq \omega \leq \omega_{\max} \quad (2)$$

$$H_w = \frac{1}{S_{n,w}} \left\{ \frac{1}{2} J_w (\omega_{\max}^2 - \omega_{\min}^2) - \int_{t_{on}}^{t_{off}} 0.11 \rho \pi R^2 v^3 \times \left[116 \left(\frac{v}{\omega_{\max} R} - 0.035 \right) - 5 \right] e^{-12.5 \left(\frac{v}{\omega_{\max} R} - 0.035 \right)} - \left[116 \left(\frac{v}{\omega R} - 0.035 \right) - 5 \right] e^{-12.5 \left(\frac{v}{\omega R} - 0.035 \right)} \right\} dt \quad \omega > \omega_{\max} \quad (3)$$

式中: $S_{n,w}$ 为风机的额定容量; J_w 为单台风机包含发电机转子、叶轮等多种旋转结构的总转动惯量; ω_0 为机组初始转子转速; t_{on} 和 t_{off} 分别为机组调速初始时刻和结束时刻; C_{pmax} 为风能利用系数最大值。

为缓解高比例风机并网带来的惯量短缺问题,在控制技术的驱动下,已有大量研究和应用实践将频率变化率与频率偏差信号引入风机的控制系统中。通过风机的快速有功控制调节机组转子转速,进而释放/吸收转子动能来响应系统频率变化,起到一定的虚拟惯量支撑与辅助调频作用^[17]。在该应用场景下,风电高渗透电网等效惯量 H_{eq} 包含同步惯量和风机虚拟惯量,基于系统总动能和总额定容量,可求得系统等效惯量,如式(4)所示。在功率缺额条件下,与电网频率动态特性相关的3个重要指标(频率初始跌落速度、频率跌落最低点及发生时间)均与系统等效惯量密切相关,根据系统等效惯量可有效评估电网动态频率安全稳定^[18]。

$$H_{eq} = \frac{\sum_{i=1}^{n_G} H_{G,i} S_{G,i} + \sum_{j=1}^{n_w} H_{w,j} S_{w,j}}{\sum_{i=1}^{n_G} S_{G,i} + \sum_{j=1}^{n_w} S_{w,j}} \quad (4)$$

式中: n_G 为与电网直接相连的同步发电机数量; $H_{G,i}$ 和 $S_{G,i}$ 分别为同步发电机 i 的惯性时间常数和额定容量; n_w 为可参与系统惯量响应的风机数量; $H_{w,j}$ 和 $S_{w,j}$ 分别为风机 j 的虚拟惯性时间常数和额定容量。

在传统电力系统中,同步发电机惯性时间常数通常是恒定的,系统整体惯量水平主要取决于开机状态,在运行方式变化不大时惯量值基本维持不变。在风机最大功率点跟踪控制过程中,不同运行工况

下转子转速不同,风机储备的动能不同。因此,风机进入调频阶段前的初始转速越大,能够表现出的虚拟惯量就越大。为此,高比例风机并网大量替代传统机组,系统等效惯量特性发生显著变化:

1) 由于风机出力具有随机性与间歇性,各时段风机出力渗透率有明显差异,使得系统运行方式复杂多变,日内同步机组启停更加频繁,系统等效惯量呈现出明显的时变波动特征;

2) 风电高渗透电网包含不同形式惯量(同步惯量+风机虚拟惯量),风机等效虚拟惯性时间常数表现为转子转速的分段函数形式,火电机组同步惯量主要与机组运行状态相关,不同形式惯量响应特性不同,使得系统等效惯量呈非线性特征;

3) 系统等效惯量受风机出力、负荷大小等诸多因素的影响,并且风机出力和用户用能行为均具有随机性,考虑风机输出功率以及用电负荷等不确定性因素对系统等效惯量带来的影响,系统等效惯量本身呈现较高的不确定性。

2 数据驱动的系统等效惯量点预测

由于风电高渗透电网等效惯量具有复杂的非线性时变特性、较大的波动特征和不确定性,对机组开停机状态预测难度较大,导致依赖于同步机组运行计划的系统惯量预测准确性将降低。本文联合数据驱动和非参数 KDE 得到待预测时刻系统等效惯量的概率密度函数和区间变化趋势,总体研究框架如图 2 所示。利用数据驱动方法挖掘系统等效惯量与相关变量间复杂的非线性关系,得到等效惯量点预测结果,研判等效惯量的变化趋势。




图2 系统等效惯量预测的研究框架

Fig.2 Research framework of system equivalent inertia prediction

2.1 CatBoost 算法

CatBoost 是一种改进的梯度提升决策树 (gradient boosting decision tree, GBDT) 算法,也是 Boosting 族算法的一种。Boosting 族算法具有参数较少、可支持类别型变量、可解决梯度偏差和预测偏移问题的优势,可减少过拟合现象的发生,进而提高计算准

确性和泛化能力^[19]。CatBoost 在 Boosting 族算法的基础上加入了梯度下降运算,即每次建立回归树都利用前者回归树的信息改变权值,向决策树梯度下降方向运算。整合多个弱学习器进而组成学习能力较强的学习器,其算法原理如附录 A 图 A1 所示。

2.2 数据驱动的等效惯量点预测模型的构建

将 CatBoost 算法应用于系统等效惯量预测,相较于传统深度神经网络算法, CatBoost 算法在数据预处理过程中无需进行数值强行代替标签步骤,同时在减小对超参数依赖的情况下,仍能得到较优的预测结果。

原始的 CatBoost 并未考虑时序信息。对电力系统等效惯量曲线进行分析可知,系统等效惯量预测场景实际是一个具有显著时序特征的场景,即未来某一时刻与历史对应(或相近)时刻的系统等效惯量具有较强的相关性。故可在预测模型中添加历史系统等效惯量值作为新的特征, CatBoost 可从中获取相关时序信息,为系统等效惯量预测提供参考。

为确保基于 CatBoost 的系统等效惯量点预测结果的准确性,应选取与系统等效惯量紧密相关的变量作为模型的输入数据。系统等效惯量包含同步惯量和风机虚拟惯量,随着同步发电机状态以及风机出力大小的变化而变化,主要受系统等效惯量历史信息、负荷、风机输出功率、日历规则等因素的综合影响。本文选取待预测时刻的负荷预测值、风机输出功率预测值、对应当日时刻 t 以及前两日对应时刻 $t-1$ 、 t 、 $t+1$ 的历史系统等效惯量值作为该模型的输入,输出为待预测时刻系统等效惯量值。基于所确定的输入-输出数据,通过离线迭代训练方式构建基于 CatBoost 的系统等效惯量预测模型,从而对系统等效惯量变化趋势进行预测。

3 系统等效惯量概率预测方法

确定性预测通常以未来某时刻的单点值作为输出,提供确定的预测值,预测信息较为有限,无法反映系统等效惯量变化可能的波动范围。随着新能源的大规模渗透,系统等效惯量预测受数据不确定性和预测模型不确定性的影响^[20],预测结果也存在较高的不确定性。一方面,由于每种预测模型都存在固有的缺点,导致预测结果存在一定的不确定性。另一方面,风机出力的随机性、波动性与不可控性导致较高的不确定性,因此无法对风机出力预测值进行精确建模,从而导致系统等效惯量预测结果的不确定性更为明显。基于点预测结果,概率预测方法可通过估计预测不确定性的概率分布,实现对预测不确定性的量化分析,进一步提供待预测时刻系统等效惯量较为完整的概率统计信息,从而为电网

规划和调度部门提供系统等效惯量波动风险预测信息。

3.1 系统等效惯量的概率预测模型

定义系统等效惯量预测误差 ε 为某一时刻系统等效惯量预测值 E_{pre} 与真实值 E_{real} 之间的偏差,即:

$$\varepsilon = E_{\text{pre}} - E_{\text{real}} \quad (5)$$

系统等效惯量受风机出力影响呈现随机性,且预测过程具有偶然性,使得系统等效惯量预测误差不一定符合特定的分布模式。不受分布假设约束的非参数模型直接根据误差数据拟合其概率分布,有助于提高对预测误差分布的表达精度。为此,本文采用非参数模型中的 KDE 来描述等效惯量预测误差的概率密度函数。KDE 是一种应用较广泛的非参数估计方法。利用 KDE 得到 CatBoost 预测误差分布的概率密度函数以及预测区间上、下限,无需对数据分布做出假设,仅基于预测数据构造区间,有较高的可靠性^[21]。选择高斯核函数对系统等效惯量预测误差进行估计,通过 KDE 构建的系统等效惯量预测误差概率密度函数^[22]为:

$$f(\varepsilon) = \frac{1}{nh} \sum_{i=1}^n K(\delta) \frac{\varepsilon - \varepsilon_i}{h} \quad (6)$$

$$K(\delta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{\delta^2}{2}} \quad (7)$$

式中: n 为系统等效惯量预测误差的样本数量; ε_i 为样本点 i 的系统等效惯量预测误差; h 为窗宽; $K(\delta)$ 为高斯核函数; δ 为高斯核函数自变量。

根据系统等效惯量预测误差概率密度函数 $f(\varepsilon)$, 对其积分得到预测误差累积分布函数 $F(\varepsilon)$ 。进而可求取满足置信度为 $1-\alpha$ 的置信区间 $[L_{i'}, U_{i'}]$:

$$[L_{i'}, U_{i'}] = [E_{\text{pre}} + \hat{f}(\alpha_1), E_{\text{pre}} + \hat{f}(\alpha_2)] \quad (8)$$

式中: $U_{i'}$ 和 $L_{i'}$ 分别为通过 KDE 方法得出的置信区间上限和下限; $\alpha_1 = \alpha/2$; $\alpha_2 = 1 - \alpha/2$; $\hat{f}(\cdot)$ 为 $F(\varepsilon)$ 的反函数。

3.2 系统等效惯量概率预测流程

基于前述介绍,本文提出的系统等效惯量概率预测方法的总体流程如附录 A 图 A2 所示,具体实施步骤如下。

步骤 1: 分析系统等效惯量特性及风机出力、负荷等影响因素,构建系统等效惯量数据集,将其划分为训练数据集和测试数据集两部分。

步骤 2: 根据前文所述 CatBoost 集成学习方法,利用训练数据集构建系统等效惯量预测模型。对测试数据集待预测时刻的系统等效惯量进行预测,得到点预测结果,反映系统等效惯量变化趋势。

步骤 3: 统计分析历史样本基于数据驱动点预测模型得到的预测误差,构建系统等效惯量预测误差数据库。采用非参数 KDE 方法,根据式(6)、(7)

得到系统等效惯量预测误差概率密度函数和累积分布函数。

步骤 4: 根据测试数据集构建待预测时刻对应的预测误差概率密度函数,结合点预测结果得到待预测时刻系统等效惯量的概率密度函数;在置信度 $1-\alpha$ 下,根据预测误差累积分布函数,利用式(8)计算得到以 $1-\alpha$ 的概率包含实际值,即系统等效惯量的预测区间上、下限,以获得系统等效惯量的波动区间。

3.3 惯量区间预测性能评价指标

对于惯量区间预测性能采用如下 2 个指标进行评估,即预测区间覆盖率(prediction interval coverage probability, PICP)与预测区间平均宽度(prediction interval normalized average width, PINAW)^[23]。

PICP 表征实际系统等效惯量会落在预测区间内的概率,是评估区间预测可靠性的关键指标,其值越大说明实际系统等效惯量落入预测区间上、下限之间的概率越大,区间越可靠。计算公式如下:

$$P_c = \frac{1}{n} \sum_{i=1}^n \varepsilon_{i'} \quad (9)$$

式中: P_c 为 PICP 值。如果目标值 $y_{i'}$ 处于预测区间的上限边界 $U_{i'}$ 与下限边界 $L_{i'}$ 之间,则 $\varepsilon_{i'} = 1$, 否则 $\varepsilon_{i'} = 0$, 其定义如下:

$$\varepsilon_{i'} = \begin{cases} 1 & y_{i'} \in [L_{i'}, U_{i'}] \\ 0 & y_{i'} \notin [L_{i'}, U_{i'}] \end{cases} \quad (10)$$

PINAW 表征预测区间的锐度,用于定量评估预测区间的宽度。在满足可靠性的同时,更窄的区间宽度能够提供更为精确的预测信息,区间过宽便失去了决策参考价值,其表达式为:

$$W_A = \frac{1}{nR'} \sum_{i=1}^n (U_{i'} - L_{i'}) \quad (11)$$

式中: W_A 为 PINAW 值; R' 为测试集中系统等效惯量最大值和最小值之差,可保证 W_A 归一化在 $[0, 1]$ 内。

理想的预测区间应具备较大的覆盖率和较小的宽度,但这两者是相互矛盾的。因此,需综合评估概率预测性能,避免评价的主观性与片面性。

4 算例分析

4.1 数据集构造及划分

本文采用 IEEE RTS-79 系统开展算例测试,验证所提方法的有效性。该系统包含 32 台发电机组、38 条输电线路以及 24 个节点。为模拟风电高渗透场景,在系统中共加入 14 座风电场,分别位于节点 1、2、7、8、13、15—23。同步机组总装机容量为 3 405 MW, 14 座风电场总装机容量为 2 638.5 MW (装机占比约为 44%), 各风电场参数见附录 A 表 A1。改进的 IEEE RTS-79 系统见附录 A 图 A3。

基于西北某地区 2018、2019 年的 14 座风电场实际输出功率、预测功率,考虑系统负荷、安全等约束条件,以 1 h 为时间间隔,利用 GAMS 软件编程,通过运行模拟得到各时刻同步机组的运行状态和出力大小。假设各风电场均采用同一型号风机,且各风机均能参与系统惯量响应,型号参数如附录 A 表 A2 所示。根据西北某地区 14 座风电场 2018、2019 年输出功率真实值以及负荷数据,通过机组组合得到系统中同步发电机运行状态,进而求取各时刻系统等效惯量训练值,从而构建惯量预测数据集。

为检验本文概率预测方法的正确性和有效性,选取 2018 年 1 月 1 日至 2019 年 12 月 29 日的系统等效惯量数据集进行短期系统等效惯量概率预测,每小时采样 1 次,有效数据共计 17 472 组。其中 2018 年 1 月 1 日至 2019 年 12 月 22 日共 17 304 个样本用于训练,综合考虑风机出力、负荷大小、历史时刻系统等效惯量等影响因素,构建基于 CatBoost 的系统等效惯量预测模型;同时利用训练样本训练值及其预测值统计分析预测误差,构建预测误差数据库。系统等效惯量的提前预测时间与负荷、风机输出功率的提前预测时间相对应。由于目前所获得的风机输出功率预测数据为提前一天的预测值,因此,预测目标为未来一天的系统等效惯量情况,2019 年 12 月 23 日至 2019 年 12 月 29 日共 168 个样本作为测试数据,对系统等效惯量进行概率预测。

4.2 系统等效惯量点预测结果

基于训练数据,通过离线迭代训练构建基于 CatBoost 的电力系统等效惯量预测模型。利用所构建的预测模型对测试数据集 2019 年 12 月 23 日至 2019 年 12 月 29 日连续 7 天共 168 个样本的系统等效惯量进行预测,结果如图 3 所示。




图 3 系统惯量预测曲线

Fig.3 Prediction curves of system inertia

可以看出,系统等效惯量呈现一定的日循环规律:白天风机出力较小、用电负荷较大使系统等效惯量值较高;而傍晚至清晨系统等效惯量值较低。系统等效惯量在一天内变化范围较为明显,预测结果较好地刻画了这一趋势。目前电力系统运行中通常根据全年预期的最坏情况来确定系统频率响应储备需求,由于系统等效惯量在一年内大幅变化,要求固定数额的频率响应储备不具备经济性,并且系统低

惯量场景和频率响应储备不足可能对电网的可靠性和安全性造成威胁。根据数据驱动的点预测结果可初步了解系统等效惯量变化趋势,动态确定所需频率响应储备需求,识别系统何时可能面临惯量薄弱风险,提前规划并做好紧急应对措施,避免在扰动发生时触发继电保护装置动作。但由于白天风速较小,风机处于是否具有惯量响应的临界状态,风机可用惯量具有间歇性,风机出力预测误差相对较大,系统等效惯量预测误差受风机可用惯量不确定性影响呈现时段相关性。

在 168 个测试样本中,存在风机出力占比较大和风机出力占比较小 2 种特殊运行场景。表 1 给出了 2 种运行场景各 3 个测试样本的预测结果,预测准确率均在 95 % 以上,说明即使在特殊场景下,所提方法依旧能对系统等效惯量进行较为精确的预测。

表 1 不同运行场景系统等效惯量预测结果

Table 1 Prediction results of system inertia in different operation scenarios

特殊运行场景	采样时间	风机出力占比 / %	H_{eq} 训练值 / s	H_{eq} 预测值 / s	预测准确率 / %
风机出力占比较大	2019 年 12 月 24 日 24:00	58.137	2.062	1.994	96.726
	2019 年 12 月 28 日 05:00	56.677	2.025	1.943	95.984
	2019 年 12 月 29 日 03:00	55.929	1.958	1.899	96.978
风机出力占比较小	2019 年 12 月 23 日 11:00	2.284	5.210	5.436	95.654
	2019 年 12 月 24 日 09:00	2.923	5.545	5.347	96.417
	2019 年 12 月 25 日 13:00	2.302	5.386	5.463	98.564

4.3 系统等效惯量概率预测结果

根据确定性点预测结果可知,预测值能较好地追踪训练值的变化趋势,但系统等效惯量预测误差受风机可用惯量不确定性影响呈现时段相关性。整体性误差建模或单一性的不确定性建模均难以在各个时刻都展现较高的可靠性和适应性。因此,对历史样本的预测误差进行统计分析,依次计算日内各时刻对应的系统等效惯量预测误差概率密度函数,了解预测误差概率分布情况,对预测误差的不确定性进行量化。进一步,结合点预测结果,给定置信水平,利用不同时刻预测误差的概率密度分布依次对待预测样本的系统等效惯量进行概率预测,使得系统运行的不确定性信息描述更为细致。

取置信度为 90 %,以测试样本 2019 年 12 月 27 日 23:00 为例进行系统等效惯量概率预测。对预测误差进行统计分析,图 4 给出了该系统历史样本在 2019 年 12 月 27 日 23:00 时的系统等效惯量概率分布,其中直方图为误差频率分布直方图,曲线为应用

非参数KDE方法得到的预测误差概率密度曲线。




图4 23:00时预测误差概率密度曲线

Fig.4 Prediction error probability density curve at 23:00

利用数据驱动预测模型得到2019年12月27日23:00系统等效惯量确定性预测结果为2.496 s,对23:00时的预测误差概率密度函数进行积分并结合确定性预测结果可得到满足置信度为90%的置信区间为[2.054, 2.916] s,该样本系统等效惯量训练值为2.566 s,能够被该预测区间所包含。图5为2019年12月27日23:00时系统等效惯量概率密度曲线。由图可知,利用待预测时刻的系统等效惯量概率分布曲线,可计算该时刻低于最低系统等效惯量需求的概率,使系统运行人员了解未来时刻系统面临惯量缺额风险的概率,有针对性地采取惯量补偿措施,通过提前规划并做好紧急应对措施避免大功率冲击下触发低频减载、高频切机、系统解列等严重后果。




图5 系统等效惯量概率密度曲线

Fig.5 Curve of system equivalent inertia probability density

按同样的方法,遍历所有待预测时刻,得到各待预测时刻的系统等效惯量概率密度曲线。将所有置信度为90%的预测区间上、下限分别联结,形成上、下2条包络线,置信区间大小随着置信度的取值不同而变化。附录A图A4给出了置信度为90%和80%下的系统等效惯量区间预测结果,描绘了不同置信水平下系统等效惯量预测可能发生的波动区间与实际系统等效惯量之间的关系。由图可知:虽然实际系统等效惯量波动频繁,但输出的预测区间基本上能够在全局范围内完全包络系统等效惯量的实际波动;且预测区间宽度根据所处时刻进行动态调整,有利于了解未来系统等效惯量的变化波动范围。系统等效惯量概率预测在既定的置信度下,获得高质量的预测区间及预测范围边界,即使在系统等效

惯量剧烈变化时段,更大限度地包含风机出力占比的极端情况,进一步提供系统等效惯量波动风险预测信息,使调度部门能够提前根据系统等效惯量的变化波动范围修正各火电机组的发电计划,并降低风机大规模并网给系统带来的运行风险。

在一定置信水平上,区间上、下限值可以分别作为系统等效惯量预测值的保守估计值和乐观估计值。当区间置信度满足实际工程需要时,在风机出力占比较大的运行场景下,可利用区间下限值估算系统等效惯量大小。如果系统等效惯量预测值低于临界水平,调度员需安排更多的同步机组开机,以增加系统等效惯量;在风机出力占比较小的运行场景下,可利用区间上限值估算系统等效惯量大小,以保障运行经济性、提高新能源利用效率。因此,相较点预测结果,惯量概率预测可提供更为全面的信息。

为了验证非参数KDE方法的优越性,选取常用的参数型方法,如Logistic分布和Stable分布进行对比分析,结果如表2所示。由表可知:相比于其他方法,基于KDE进行区间预测具有最佳的可靠性;当置信度分别为90%和80%时,所得区间覆盖率比Logistic分布提高2.38%和3.57%,比Stable分布高了1.78%和2.38%;此外,Logistic分布和Stable分布所得区间覆盖率均低于给定的置信度。这表明参数型估计方法难以保证预测可靠性要求,不适用于系统等效惯量概率预测。

表2 参数型和非参数型估计方法性能指标

Table 2 Performance indexes under parameter type method and non-parameter type estimation method

方法	$P_c / \%$		$W_A / \%$	
	置信度为90%	置信度为80%	置信度为90%	置信度为80%
KDE	91.07	82.14	21.70	16.66
Logistic 分布	88.69	78.57	88.69	15.78
Stable 分布	89.29	79.76	89.29	15.99

5 结论

在虚拟惯量控制技术的驱动下,风电高渗透电网包含不同形式惯量资源,系统等效惯量呈现复杂的非线性时变特征。本文考虑风机可提供的虚拟惯量,提出了一种联合数据驱动和KDE的系统等效惯量概率预测方法,主要结论如下:

1) 利用数据驱动方法挖掘系统等效惯量与相关变量间复杂的非线性关系,可得到等效惯量预测结果,初步判断等效惯量的变化趋势;

2) 由于风机可用惯量具有不确定性,系统等效惯量在时间尺度表现出较大的波动特征,系统等效惯量预测误差受到风机出力的影响,呈时段相关性,有必要建立各对应时刻惯量预测误差的概率密度函数;


3) 概率预测方法能够完整地描述系统等效惯量的不确定性及波动性, 根据不同调度需求灵活选择置信水平, 可以得到系统等效惯量预测区间包络线以及系统等效惯量概率分布, 实现预测不确定性的有效量化, 为系统等效惯量预测提供更多有用信息, 可对电网运行方式安排和发电调度提供决策支持。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] FANG J, LI H, TANG Y, et al. On the inertia of future more-electronics power systems[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2019, 7(4): 2130-2146.
- [2] 文云峰, 杨伟峰, 林晓煌. 低惯量电力系统频率稳定分析与控制研究综述及展望[J]. 电力自动化设备, 2020, 40(9): 211-222.
WEN Yunfeng, YANG Weifeng, LIN Xiaohuang. Review and prospect of frequency stability analysis and control of low-inertia power systems[J]. Electric Power Automation Equipment, 2020, 40(9): 211-222.
- [3] ASHTON P M, SAUNDERS C S, TAYLOR G A, et al. Inertia estimation of the GB power system using synchrophasor measurements[J]. IEEE Transactions on Power Systems, 2015, 30(2): 701-709.
- [4] ZOGRAFOS D, CHANDHARI M, ERIKSSON R. Power system inertia estimation: utilization of frequency and voltage response after a disturbance[J]. Electric Power Systems Research, 2018, 161: 52-60.
- [5] SCHIFFER J, ARISTIDOU P, ORTEGA R. Online estimation of power system inertia using dynamic regressor extension and mixing[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4993-5001.
- [6] LUGNANI L, DOTTA D, LACKNER C, et al. ARMAX-based method for inertial constant estimation of generation units using synchrophasors[J]. Electric Power Systems Research, 2020, 180: 1-9.
- [7] CAO X, STEPHEN B, ABDULHADI I F, et al. Switching Markov Gaussian models for dynamic power system inertia estimation[J]. IEEE Transactions on Power Systems, 2016, 31(5): 3394-3403.
- [8] ØRUM E, KUIVANIEMI M, LAASONEN M, et al. Future system inertia[R]. Brussels, Belgium: ENTSOE, 2015.
- [9] 张武其, 文云峰, 迟方德, 等. 电力系统惯量评估研究框架与展望[J]. 中国电机工程学报, 2021, 41(20): 6842-6856.
ZHANG Wuqi, WEN Yunfeng, CHI Fangde, et al. Research framework and prospect on power system inertia estimation[J]. Proceedings of the CSEE, 2021, 41(20): 6842-6856.
- [10] TUTTELBERG K, KILTER J, WILSON D, et al. Estimation of power system inertia from ambient wide area measurements[J]. IEEE Transactions on Power Systems, 2018, 33(6): 7249-7257.
- [11] DU P, MATEVOSYAN J. Forecast system inertia condition and its impact to integrate more renewables[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1531-1533.
- [12] CARLINI E M, DEL P F, GIANNUZZI G M, et al. Online analysis and prediction of the inertia in power systems with renewable power generation based on a minimum variance harmonic finite impulse response filter[J]. International Journal of Electrical Power & Energy Systems, 2021, 131: 107042.
- [13] 刘洪波, 彭晓宇, 张崇, 等. 风电参与电力系统调频控制策略综述[J]. 电力自动化设备, 2021, 41(11): 81-92.
- LIU Hongbo, PENG Xiaoyu, ZHANG Chong, et al. Overview of wind power participating in frequency regulation control strategy for power system[J]. Electric Power Automation Equipment, 2021, 41(11): 81-92.
- [14] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 风电场接入电力系统技术规定: GB/T 19963—2011[S]. 北京: 中国标准出版社, 2011.
- [15] 田新首, 王伟胜, 迟永宁, 等. 基于双馈风电机组有效储能的变参数虚拟惯量控制[J]. 电力系统自动化, 2015, 39(5): 20-26, 33.
TIAN Xinshou, WANG Weisheng, CHI Yongning, et al. Variable parameter virtual inertia control based on effective energy storage of DFIG-based wind turbines[J]. Automation of Electric Power Systems, 2015, 39(5): 20-26, 33.
- [16] 韩帅, 张峰, 丁磊, 等. 基于混合 Copula 函数的风电场可用惯量评估方法[J]. 电力自动化设备, 2021, 41(3): 189-195, 210.
HAN Shuai, ZHANG Feng, DING Lei, et al. Available inertia evaluation method of wind farm based on mixed Copula function[J]. Electric Power Automation Equipment, 2021, 41(3): 189-195, 210.
- [17] 刘中建, 周明, 李昭辉, 等. 高比例新能源电力系统的惯量控制技术与惯量需求评估综述[J]. 电力自动化设备, 2021, 41(12): 1-11, 53.
LIU Zhongjian, ZHOU Ming, LI Zhaohui, et al. Review of inertia control technology and requirement evaluation in renewable-dominant power system[J]. Electric Power Automation Equipment, 2021, 41(12): 1-11, 53.
- [18] ANDERSON P M, MIRHEYDAR M. A low-order system frequency response model[J]. IEEE Transactions on Power Systems, 1990, 5(3): 720-729.
- [19] PROKHORENKOVA L, GUSEV G, VOROBEEV A, et al. CatBoost: unbiased boosting with categorical features[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York, USA: ACM, 2018: 6639-6649.
- [20] 万灿, 崔文康, 宋永华. 新能源电力系统概率预测: 基本概念与数学原理[J]. 中国电机工程学报, 2021, 41(19): 6493-6509.
WAN Can, CUI Wenkang, SONG Yonghua. Probabilistic forecasting for power systems with renewable energy sources: basic concepts and mathematical principles[J]. Proceedings of the CSEE, 2021, 41(19): 6493-6509.
- [21] EPANECHNIKOV V A. Non-parametric estimation of a multivariate probability density[J]. Theory of Probability & Its Applications, 1969, 14(1): 153-158.
- [22] SILVERMAN B W. Density estimation for statistics and data analysis[M]. London, UK: Chapman and Hall, 1986: 8-21.
- [23] KHOSRAVI A, NAHAVANDI S, CREIGHTON D, et al. Lower upper bound estimation method for construction of neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks, 2011, 22(3): 337-346.

作者简介:



巴文岚

巴文岚(1998—), 女, 硕士研究生, 主要研究方向为高比例新能源电力系统惯量预测和灵活性评估(E-mail: wenlan3637@163.com);

文云峰(1986—), 男, 副教授, 博士研究生导师, 通信作者, 主要研究方向为低惯量电力系统规划、运行与控制(E-mail: yunfeng.8681@163.com)。

(编辑 王欣竹)

(下转第165页 continued on page 165)

学报,2021,41(1):135-146,404.

ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM[J]. Proceedings of the CSEE, 2021, 41(1):135-146, 404.

- [20] 邓带雨,李坚,张真源,等. 基于EEMD-GRU-MLR的短期电力负荷预测[J]. 电网技术, 2020, 44(2):593-602.

DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2):593-602.

作者简介:



肖 白

肖 白(1973—),男,教授,博士,通信作者,主要研究方向为电力系统规划、空间电力负荷预测、多能源互补协调发电、电能质量综合治理等(E-mail:xbxiaobai@126.com);

高文瑞(1996—),男,硕士研究生,研究方向为空间负荷预测(E-mail:974282332@qq.com)。

(编辑 王锦秀)

Spatial load forecasting method based on 3σ -CEEMDAN-LSTM

XIAO Bai¹, GAO Wenrui¹, LI Daoming¹, QI Xuesong², KAN Zhongfeng²

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;

2. Jilin Power Supply Company of State Grid Jilin Electric Power Company Co., Ltd., Jilin 132001, China)

Abstract: In order to effectively use the massive data collected from distribution network and improve the forecasting effect of spatial load, a spatial load forecasting method based on 3σ rule, complementary ensemble empirical mode decomposition with adaptive noise(CEEMDAN) and long-short term memory neural network(LSTM) is proposed. Based on 3σ rule, the singular value detection and disposition for measured load data of each Class I cell are carried out. CEEMDAN technology is applied to decompose the processed load data of Class I cells into several intrinsic mode functions(IMFs) with different frequencies and amplitudes. LSTM model is built for each IMF component for forecasting. The spatial load forecasting based on Class I cells at the target year is obtained by linearly superimposed of the forecasting results of all the IMF components, on this basis, the spatial power load grid technology is used to obtain the spatial load forecasting results based on Class II cells. The correctness and effectiveness of the proposed method are verified by case analysis results.

Key words: spatial load forecasting; cell; geographic information system; CEEMDAN; LSTM

(上接第130页 continued from page 130)

Probability prediction method of equivalent inertia for high wind power penetration grid

BA Wenlan¹, WEN Yunfeng¹, YE Xi², WEN Ming³, HUANG Mingzeng¹, ZHANG Wuqi¹

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

2. State Grid Sichuan Electric Power Company, Chengdu 610041, China;

3. Economic & Technology Research Institute of State Grid Hunan Electric Power Co., Ltd., Changsha 410118, China)

Abstract: Driven by virtual inertia control technology, high wind power penetration grid contains different forms of inertia resources, and the system equivalent inertia presents the characteristic of complex nonlinear, time-varying and fluctuation. In order to better explain the uncertainty of system equivalent inertia, a probability prediction method of the system equivalent inertia considering the virtual inertia of wind turbine is proposed. Firstly, the point prediction model of system equivalent inertia is established through data-driven method, and the change trend of the equivalent inertia is predicted. Then, the non-parameter kernel density estimation is used to establish the probability density function of the prediction error for each time period, and the interval in which the system equivalent inertia may fluctuate under a certain confidence level at the prediction moment is obtained. An example is analyzed based on the modified IEEE RTS-79 system, and the results show that the proposed method is more reliable than the traditional parameter estimation method, it can provide useful decision-making information for new power system operation mode arrangement under low inertia scenarios.

Key words: doubly-fed induction generator; system equivalent inertia; inertia estimation; inertia forecasting; uncertainty

附录 A




图 A1 CatBoost 算法示意图
Fig.A1 Schematic diagram of CatBoost algorithm




图 A2 系统等效惯量概率预测流程
Fig.A2 Process of system inertia probability prediction

表 A1 风电场参数

Table A1 Parameters of wind farm

风电场 编号	风机数 量/台	总装机容量 /MW	风电场 编号	风机数 量/台	总装机容量 /MW
W1	135	202.5	W8	166	249
W2	133	199.5	W9	129	193.5
W3	67	100.5	W10	66	99
W4	97	145.5	W11	134	201
W5	99	148.5	W12	133	199.5
W6	66	99	W13	200	300
W7	200	300	W14	134	201





图 A3 改进的 RTS-79 系统
Fig.A3 Modified RTS-79 system

表 A2 风机参数
Table A2 Parameters of wind turbine

参数	取值	参数	取值
额定功率/kW	1 500	转动惯量/kg m ²	6
叶轮直径/m	82.76	叶轮转速/rpm	9.7~19.5
切入风速/m s ⁻¹	3	最优叶尖速比	8.5
额定风速/m s ⁻¹	10.8	齿轮箱传动比率	100.746
切出风速/m s ⁻¹	25	发电机额定转速/rpm	1 750



图A4 系统等效惯量区间预测结果
Fig.A4 Interval prediction results of system inertia