

DOI: 10.19783/j.cnki.pspc.231542

## 基于生成对抗网络与度量学习的数据驱动频率安全评估

李华瑞<sup>1</sup>, 李文博<sup>1</sup>, 李铮<sup>1</sup>, 贾宇乔<sup>1</sup>, 刘全<sup>1</sup>, 缪德炀<sup>1</sup>, 李雅然<sup>1</sup>, 王宝财<sup>2</sup>

(1. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211100; 2. 电网安全与节能国家重点实验室  
(中国电力科学研究院有限公司), 北京 100192)

**摘要:** 随着大容量远距离高压直流输电工程的建设 and 大规模可再生能源的接入, 电力系统的频率安全面临严峻挑战。为了对频率安全进行快速准确的在线评估, 提出一种基于度量学习与生成对抗网络技术的数据驱动频率安全评估模型。首先, 选取关键频率安全指标作为模型输出, 并构建输入特征集。然后, 使用改进的基于 Wasserstein 距离度量的生成对抗网络(Wasserstein generative adversarial network, WGAN)学习电力系统历史运行场景分布信息, 生成覆盖系统典型运行方式的运行场景以构建训练样本集。计及电力系统复杂运行方式下单个机器学习模型对频率安全评估的不适用性, 基于核回归度量学习(metric learning for kernel regression, MLKR)算法构建由多个子模型构成的频率安全组合评估模型。最后使用简化的山东电网算例, 验证了所提方法的有效性。

**关键词:** 频率安全; 机器学习; 数据驱动; 生成对抗网络; 度量学习

### Data-driven frequency security assessment based on generative adversarial networks and metric learning

LI Huarui<sup>1</sup>, LI Wenbo<sup>1</sup>, LI Zheng<sup>1</sup>, JIA Yuqiao<sup>1</sup>, LIU Quan<sup>1</sup>, MIAO Deyang<sup>1</sup>, LI Yaran<sup>1</sup>, WANG Baocai<sup>2</sup>

(1. State Grid Jiangsu Electric Power Co., Ltd. Electric Power Research Institute, Nanjing 211100, China; 2. State Key Laboratory of Power Grid Safety and Energy Conservation (China Electric Power Research Institute), Beijing 100192, China)

**Abstract:** With the construction of large-capacity long-distance high-voltage direct current transmission projects and the large-scale integration of renewable energy, frequency security of the power system is facing severe challenges. For fast and accurate online assessment of frequency security, a data-driven model based on a metric learning (ML) and generative adversarial network (GAN) is proposed. First, the key frequency security indicators are selected as the outputs of the model, and an input feature set is constructed. Then, the improved Wasserstein generative adversarial network (WGAN) based on the Wasserstein distance metric is used to learn the distribution information of historical operation scenarios of power systems. This generates operational scenarios covering typical modes to build the training sample set. Considering the inapplicability of a single machine learning model to frequency security assessment with complicated operational modes of power systems, a combined assessment model for assessment composed of multiple sub-models is constructed based on metric learning for a kernel regression (MLKR) method. Finally, a simplified Shandong power system example is used to verify the effectiveness of the proposed method.

This work is supported by the Natural Science Foundation of Jiangsu Provincial Basic Research Program (No. BK20230167).

**Key words:** frequency security; machine learning; data-driven; generative adversarial network; metric learning

## 0 引言

在高压直流输电和可再生能源发电技术发展的

**基金项目:** 江苏省基础研究计划自然科学基金项目资助 (BK20230167); 北京市自然科学基金青年基金项目资助 (3234063); 国网江苏省电力有限公司科技项目资助 (J2022016)

双重驱动下, 多直流馈入电网等效惯量降低、旋转备用容量减少, 电网大功率缺额事故风险增加<sup>[1-2]</sup>。直流闭锁等大功率缺额事故发生后, 直流馈入电网频率安全稳定面临巨大风险<sup>[3]</sup>, 亟需展开频率安全评估方法研究, 为后续频率安全控制决策提供研究基础, 增强电网频率安全性<sup>[4]</sup>。

全时域仿真基于电力系统详细模型分析系统频率动态, 是评估系统严重事故扰动后频率安全的重要

要手段。文献[5]计及锅炉热动态过程对机组输出功率的影响,对机组负荷调节系统详细建模以提高频率安全评估准确性。文献[6]对电力系统仿真软件PSS/E自定义模型进行了研究,结合自适应低频减载的基本原理建立了自适应、半自适应低频减载方案自定义时域仿真模型。文献[7]建立解列后大型火电机组频率动态详细时域仿真模型,以最低频率值和最低频率时刻作为待评估指标,分析解列后电网频率动态过程的重要影响因素。时域仿真法计及电力系统详细模型,能够全面反映系统频率动态<sup>[8]</sup>,但需要求解代数微分方程组以精确模拟有功扰动后频率响应过程,计算耗时长。现代电力系统源荷双侧不确定,需要进行大量未来可能运行场景下的频率安全在线评估,传统时域仿真方法难以适用<sup>[9]</sup>。

为了加快评估速度,一些简化模型被应用到频率安全评估中。文献[10]提出了忽略电压动态和网络影响的平均系统频率(average system frequency, ASF)模型。在ASF模型基础上进一步进行简化,即可得到系统频率响应(system frequency response, SFR)模型<sup>[11]</sup>。基于SFR模型可直接求得系统频率响应解析解,而不需要逐步积分。文献[12]忽略无功-电压变化对有功-频率动态的影响,提出一种新的基于直流潮流的电力系统频率响应分析方法。上述简化模型忽略网络影响和频率-电压动态的耦合关系,相对于时域仿真方法具有更快的计算速度。但是大规模电力系统中网络影响不可忽略,频率-电压动态紧密耦合。对于大规模电力系统,直流闭锁等严重有功扰动事件后,频率大范围偏移,上述简化模型评估精度较差。

近年来机器学习方法在频率安全在线评估领域得到了广泛应用。一旦离线训练完成,机器学习评估模型即可用于频率安全在线评估,不需要在线求解代数微分方程组。文献[13-14]使用传统支持向量回归(support vector regression, SVR)模型的改进模型——v-SVR模型对事故后最低频率进行预测。文献[15-16]应用极限学习机(extreme learning machine, ELM)和多层极限学习机(multi layer extreme learning machine, MLELM)实现频率安全的快速分析与预测。文献[17]提出一种基于随机森林(random forest, RF)的电网频率预测方法。文献[18]建立了物理-数据混合驱动的频率安全指标评估模型,保留系统基本物理因果关系的同时利用ELM模型对系统频率响应模型进行进一步拟合修正。

除了上述浅层机器学习模型外,还有文献提出将具有强大学习能力的深度学习模型应用于频率安全评估中。文献[19]利用堆栈降噪自动编码器的深

层构架挖掘极值频率、准稳态频率等频率指标信息。文献[20]对轻梯度提升机(light gradient boosting machine, LGBM)进行级联处理构成深度学习结构评估电力系统最大频率偏移,并在其损失函数中引入惩罚敏感机制。文献[21]采用“预训练—微调”的方式确定深度置信网络(deep belief networks, DBN)参数,进而训练得到用于预测扰动后电力系统频率曲线的深度网络。

一旦离线训练完成,机器学习模型即可用于频率安全在线评估,而不需要求解代数微分方程组。机器学习模型的评估精度取决于训练样本数据的充分性和模型结构的合理性<sup>[22]</sup>。目前,多数研究采用在一定范围内随机变化系统运行状态、以构造新运行场景生成训练样本的方式,训练样本难以覆盖待评估场景,频率安全评估模型对未来待评估场景泛化能力难以保障。同时对于不同运行场景,直流闭锁等严重功率扰动后的频率动态可能存在较大差异,待评估频率安全指标与输入特征之间的函数关系差异显著,单个机器学习模型可能产生较大评估误差。须构建合理的机器学习模型结构,研究计及强非线性、运行方式变化复杂的现代大规模电力系统不同场景下扰动后的频率动态差异,进而对频率安全进行快速、准确的评估。

考虑到上述问题,本文提出一种基于生成对抗网络与度量学习的数据驱动频率安全在线评估方法。首先选取相应频率安全指标,并构建模型输入特征;然后基于生成对抗网络技术,对数据驱动的频率安全机器学习评估模型训练样本生成方法展开研究;最后基于度量学习技术,对数据驱动的频率安全机器学习评估模型结构和学习过程展开研究,建立对未来待评估场景具有良好泛化能力的频率安全评估模型。基于简化的山东电网算例,验证本文所提基于生成对抗网络与度量学习的数据驱动频率安全评估模型可以对不同运行场景下直流闭锁严重功率扰动后的频率安全进行快速、准确的评估。

## 1 频率安全指标选取与输入特征构建

### 1.1 频率安全指标选取

本文所建立频率评估模型关注电力系统突然遭受有功功率扰动后的暂态频率安全,需要计及机组的惯性响应和一次调频影响。最大暂态频率偏移 $\Delta f_{\max}$ 、最大频率变化率 $f_{\max}^{\text{ROCOF}}$ 和准稳态频率偏差 $\Delta f_{\text{ss}}$ 是反映系统功率扰动后频率安全的重要指标<sup>[19-20]</sup>。 $\Delta f_{\max}$ 与功率扰动事件发生后机组惯性响应过程有关,用来决定系统相关保护的动作情况; $f_{\max}^{\text{ROCOF}}$ 与

功率扰动事件导致的功率扰动量以及系统本身惯性相关, 用于描述功率扰动事件发生后的频率变化速率;  $\Delta f_{ss}$  则可用于判断系统频率动态过程结束后的稳态频率是否满足相应要求。本文以  $\Delta f_{max}$ 、 $f_{max}^{ROCOF}$  和  $\Delta f_{ss}$  作为频率安全指标, 构建数据驱动的频率安全评估模型。

### 1.2 原始输入特征构建

反映系统运行方式信息的扰动前潮流特征和反映功率扰动后频率动态响应过程的系统动态特征均可作为频率安全评估模型的输入特征。但在线评估系统频率安全时获取扰动后的动态信息依赖时域仿真, 会影响模型评估速度。为满足评估快速性要求, 本文选择扰动前潮流特征构建频率安全评估模型输入特征, 以避免对时域仿真的依赖, 保证评估的快速性。

电力系统频率由机组惯性方程决定。

$$\frac{d\Delta f(t)}{dt} = \frac{1}{2H} \left( \sum_{i=1}^{N_G} \Delta P_G^i - \Delta P_d - D\Delta f(t) \right) \quad (1)$$

式中:  $\Delta f(t)$  表示系统频率  $f(t)$  的变化量;  $H$  表示系统惯性时间常数;  $N_G$  表示机组数量;  $\Delta P_G^i$  表示与原动机-调速器系统动态响应相关的机组有功调整量;  $\Delta P_d$  表示功率扰动量;  $D$  表示系统阻尼。

对于本文所选取反映扰动后频率动态的 3 个关键指标  $\Delta f_{max}$ 、 $f_{max}^{ROCOF}$  和  $\Delta f_{ss}$  而言,  $f_{max}^{ROCOF}$  与扰动量和系统惯性水平密切相关, 扰动量越大、系统惯性水平越低, 则频率变化率  $f_{max}^{ROCOF}$  越大;  $\Delta f_{max}$  的数值大小与系统惯性水平、备用容量及机组调节速率密切相关;  $\Delta f_{ss}$  则主要受相应事件导致的功率扰动规模以及电力系统本身旋转备用水平等因素影响。输入特征应尽可能包含电力系统运行信息和与频率动态相关的特征信息, 基于上述分析, 本文选取扰动前常规机组出力、旋转备用、机组容量、单位调节功率、惯性时间常数, 各新能源机组出力, 系统阻尼系数, 各负荷大小, 直流功率以及扰动量作为原始输入特征。

## 2 基于生成对抗网络的频率安全评估模型训练样本生成

直流闭锁等严重功率扰动事件在电力系统实际运行中发生的频次极低, 难以直接从电力系统历史运行数据中收集到足够数量的场景信息用于生成训练样本。需在离线阶段构建电力系统运行场景集进行功率扰动后的频率动态时域仿真, 得到相应场景下系统最大频率偏移等频率安全指标, 以生成训练样本用于频率安全评估模型的训练。目前通常是在

一定范围内随机变化负荷水平和新能源出力等系统运行状态, 从而生成批量运行场景以构建训练样本集<sup>[23]</sup>。这种训练样本的生成方法难以覆盖电力系统实际运行方式, 无法保证频率安全评估模型对未来待评估场景的泛化能力, 而且会产生大量远离系统实际运行情况的训练样本, 导致模型训练效率低。

生成对抗网络(generative adversarial network, GAN)<sup>[24]</sup>作为数据驱动的样本分布学习方法, 可以在不假设样本分布函数的情况下学习样本分布规律。本文基于电力系统历史运行方式信息, 使用改进的基于 Wasserstein 距离度量的生成对抗网络模型(Wasserstein generative adversarial network, WGAN)学习系统实际运行场景分布规律, 进而生成符合系统实际运行情况的批量场景进行时域仿真, 得到预想功率扰动事件后频率安全指标, 用于构建训练样本集。

### 2.1 基于传统 GAN 网络的运行场景生成

传统GAN是一种无监督的学习方法, 拥有一个生成器和一个判别器<sup>[24]</sup>。对于电力系统运行场景生成的GAN而言, 其生成器通过学习电力系统历史运行场景分布模拟生成尽可能接近电力系统实际运行规律的运行场景  $\mathbf{S}$ , 判别器则用于判别生成的运行场景是否接近电力系统真实场景分布规律。用  $P_{his}(\mathbf{S})$  表示电力系统运行场景的历史真实分布, 给定噪声分布  $P_{noise}(\mathbf{S})$ , GAN的目标是通过生成器和判别器的博弈过程映射  $P_{noise}(\mathbf{S})$  采样数据, 使其尽可能逼近  $P_{his}(\mathbf{S})$ 。

电力系统运行方式特征包括网络拓扑结构特征、发电负荷模式特征等。本文所提频率安全评估模型用于大量不同源荷场景对应运行方式下频率安全指标的评估, 因此在构建运行场景时主要考虑发电负荷模式信息的变化, 运行场景  $\mathbf{S}$  由风电功率、光伏出力、负荷和常规火电机组出力等构成潮流特征向量进行表征。

对于生成器  $G(\bullet; W^G)$ , 其输入是按  $P_{noise}(\mathbf{S})$  采样得到的噪声数据  $\mathbf{S}_{noise}$ , 输出是生成的模拟电力系统真实历史运行场景分布规律的数据样本  $G(\mathbf{S}_{noise}; W^G)$ 。生成器目标是使  $G(\mathbf{S}_{noise}; W^G)$  的分布  $P(G(\mathbf{S}_{noise}; W^G))$  尽可能接近电力系统真实历史运行场景分布  $P_{his}(\mathbf{S})$ , 其损失函数  $L_G$  可表示为

$$L_G = -E_{\mathbf{S}_{noise} \sim P_{noise}(\mathbf{S})} (D(G(\mathbf{S}_{noise}; W^G))) \quad (2)$$

式中:  $E_{\mathbf{S}_{noise} \sim P_{noise}(\mathbf{S})}(\cdot)$  表示期望;  $D(\cdot)$  表示判别器网络输出。

对于判别器, 其输入是电力系统真实历史运行场景或者生成器生成的模拟历史运行场景, 输出是

相应场景为真实历史场景的概率，即判别器网络的目标是尽可能正确地判别输入运行场景的来源，其损失函数  $L_D$  表示为

$$L_D = -E_{S_{\text{his}} \sim P_{\text{his}}(S)}(D(S_{\text{his}})) + E_{S_{\text{noise}} \sim P_{\text{noise}}(S)}(D(G(S_{\text{noise}}))) \quad (3)$$

式中： $S_{\text{his}}$  表示历史运行场景； $G(S_{\text{noise}})$  表示输入为  $S_{\text{noise}}$  时生成器的输出。

为了建立生成器和判别器之间的博弈以使它们能同时训练，建立式(4)所示的博弈模型。

$$\min_G \max_D V(G,D) = E_{S_{\text{his}} \sim P_{\text{his}}(S)}(D(S_{\text{his}})) - E_{S_{\text{noise}} \sim P_{\text{noise}}(S)}(D(G(S_{\text{noise}}))) \quad (4)$$

通过生成器与判别器之间的博弈过程，最终得到模拟电力系统真实历史运行场景分布规律的生成器  $G(\bullet; W^G)$ 。

## 2.2 基于改进 WGAN 网络的运行场景生成

传统 GAN 模型存在梯度消失、模式坍塌等问题，本文进一步引入改进的 WGAN 网络模型<sup>[25]</sup>学习电力系统运行场景分布规律。 $P(G(S_{\text{noise}}; W^G))$  与  $P_{\text{his}}(S)$  之间的 Wasserstein 距离  $W(P(G(S_{\text{noise}}; W^G)), P_{\text{his}}(S))$  计算公式如式(5)所示。

$$W(P(G(S_{\text{noise}}; W^G)), P_{\text{his}}(S)) = \inf_{\gamma \sim \Pi(P(G(S_{\text{noise}}; W^G)), P_{\text{his}}(S))} E_{(u,v) \sim \gamma} [\|u - v\|] \quad (5)$$

式中： $\Pi(P(G(S_{\text{noise}}; W^G)), P_{\text{his}}(S))$  表示以  $P(G(S_{\text{noise}}; W^G))$  与  $P_{\text{his}}(S)$  为边缘分布的联合概率分布  $\gamma$  的集合； $u, v$  表示按联合概率分布  $\gamma$  进行采样得到的样本； $\inf$  表示下确界，即最大下界。

直接计算 Wasserstein 距离存在困难，本文采用 Kantorovich-Rubinstein 对偶形式衡量 Wasserstein 距离，如式(6)所示。

$$W(P(G(S_{\text{noise}}; W^G)), P_{\text{his}}(S)) = \sup_{\|D\|_L \leq 1} E_{S \sim P_{\text{his}}(S)}[D(S)] - E_{S \sim P_{\text{noise}}(S)}[D(G(S))] \quad (6)$$

式中： $D(S)$  表示输入为场景  $S$  时，判别器的输出； $G(S)$  表示输入为场景  $S$  时，生成器的输出； $\sup$  表示上确界，即最小上界； $\|D\|_L \leq 1$  表明判别器网络需要满足 1-Lipschitz 条件限制，即在训练时约束网络参数的变化幅度在一定范围内，以保证正常的梯度优化。

## 2.3 基于拒绝采样与重采样技术的生成场景调整

对基于改进 WGAN 生成的模拟电力系统运行场景进行直流闭锁等严重功率扰动后的频率动态详细时域仿真，得到最大频率偏移等相应频率安全指标，即可构建频率安全评估模型的训练样本集。部分待评估运行场景附近可能缺少运行方式与其相似

的训练样本，导致训练样本稀疏。在这种情况下，频率安全指标与潮流特征间复杂的函数映射关系难以被学习，从而导致频率安全评估模型的评估误差较大。提高这些运行场景附近的训练样本密度，是减小频率安全评估误差的关键。本文将这些评估误差较大的运行场景定义为关键场景，通过反复进行拒绝采样<sup>[26]</sup>与重采样<sup>[27]</sup>，提高关键场景附近训练样本密度，提高频率安全评估精度。

对于关键场景  $S_{\text{key},i}$ 、 $S_{\text{key},j}$  和  $S_{\text{key},k}$ ，其最大频率偏移等频率安全指标评估误差依次为  $e_i$ 、 $e_j$  和  $e_k$ ，有  $e_i \leq e_j \leq e_k$ 。按照新生成场景  $S_{\text{new}}$  应尽量接近评估误差较大的关键样本的原则，应有

$$d(S_{\text{new}}, S_{\text{key},i}) \geq d(S_{\text{new}}, S_{\text{key},j}) \geq d(S_{\text{new}}, S_{\text{key},k}) \quad (7)$$

式中， $d(\cdot)$  表示两场景之间距离。

关键场景的频率安全指标评估误差构成序列  $\{e_l, 1 \leq l \leq N_{\text{key}}\}$ ，其中  $e_l$  表示第  $l$  个场景的频率安全指标评估误差， $N_{\text{key}}$  表示关键场景数量。序列  $\{e_l, 1 \leq l \leq N_{\text{key}}\}$  与序列  $\{d(S_{\text{new}}, S_{\text{key},m}), 1 \leq m \leq N_{\text{key}}\}$  应具有较高的负相关性，以保证式(7)成立，从而尽量生成接近关键场景的训练样本。本文引入 Spearman 相关系数来衡量两序列的相关性，如式(8)所示。

$$\rho(\{e_l, 1 \leq l \leq N_{\text{key}}\}, \{d(S_{\text{new}}, S_{\text{key},m}), 1 \leq m \leq N_{\text{key}}\}) = \frac{\sum_{n=1}^{N_{\text{key}}} [R(e_n) - \bar{R}(e)] [R(d(S_{\text{new}}, S_{\text{key},n})) - \bar{R}(d)]}{\sqrt{\sum_{n=1}^{N_{\text{key}}} [R(e_n) - \bar{R}(e)]^2 \sum_{n=1}^{N_{\text{key}}} [R(d(S_{\text{new}}, S_{\text{key},n})) - \bar{R}(d)]^2}} \quad (8)$$

$$\bar{R}(e) = \frac{1}{N_{\text{key}}} \sum_{n=1}^{N_{\text{key}}} R(e_n)$$

$$\bar{R}(d) = \frac{1}{N_{\text{key}}} \sum_{n=1}^{N_{\text{key}}} R(d(S_{\text{new}}, S_{\text{key},n}))$$

式中： $\rho(\cdot)$  表示序列间相关系数； $R(e_n)$  和  $R(d(S_{\text{new}}, S_{\text{key},n}))$  分别表示序列  $\{e_l, 1 \leq l \leq N_{\text{key}}\}$  与序列  $\{d(S_{\text{new}}, S_{\text{key},m}), 1 \leq m \leq N_{\text{key}}\}$  中相应元素的秩次。

设定阈值  $\rho_{\text{th}}$ ，构造式(9)所示拒绝采样函数，筛除远离关键场景的训练样本。

$$h(S_{\text{new}}) = \begin{cases} 1, & \rho(\{e_l, 1 \leq l \leq N_{\text{key}}\}, \{d(S_{\text{new}}, S_{\text{key},m}), 1 \leq m \leq N_{\text{key}}\}) < \rho_{\text{th}} \\ 0, & \rho(\{e_l, 1 \leq l \leq N_{\text{key}}\}, \{d(S_{\text{new}}, S_{\text{key},m}), 1 \leq m \leq N_{\text{key}}\}) \geq \rho_{\text{th}} \end{cases} \quad (9)$$

每次基于生成器  $G(\bullet; W^G)$  新增模拟电力系统历史实际运行场景分布规律新场景后, 随机划分新场景分别用于生成训练样本与测试样本。将测试误差大于设定阈值的测试样本所对应场景定义为关键场景。基于 WGAN 生成器和式(9)中拒绝采样函数进行拒绝采样与重采样, 即可提高关键场景附近训练样本密度。

### 3 频率安全组合评估模型结构与学习过程

#### 3.1 频率安全组合评估模型结构

频率安全机器学习评估模型基于历史训练样本学习频率安全指标  $y$  与输入特征  $\mathbf{x}$  之间的函数关系  $y = F(\mathbf{x})$ , 从而基于  $y = F(\mathbf{x})$  在不求解微分代数方程组的情况下直接获得待评估场景频率安全指标。其中,  $y$  可取  $\Delta f_{\max}$ 、 $f_{\max}^{\text{ROCOF}}$  或  $\Delta f_{\text{ss}}$ ,  $\mathbf{x}$  为由常规机组出力、负荷水平等原始潮流特征经过特征降维之后形成的模型输入特征。不同运行场景下电力系统惯性水平、旋转备用水平、闭锁直流等可能相差较大, 导致不同场景下扰动后系统频率动态过程具有显著差异。在这种情况下, 描述不同场景下频率安全指标与输入特征关系的函数表达式  $y = F(\mathbf{x})$  可能具有明显差异, 难以使用单个机器学习模型对其进行学习。本文提出由多个子模型构成的频率安全组合评估模型, 用于评估系统直流闭锁等严重扰动后的频率安全。

频率安全组合评估模型建立过程中, 基于尽量将频率安全指标与输入特征间函数映射关系相似样本分至同簇的原则进行样本聚类, 进而针对各簇分别建立对应子模型。传统聚类算法通常基于样本间距离, 根据“同簇样本间距离尽量小, 不同簇样本间距离尽量大”的原则进行样本分簇。而频率安全指标与输入特征间函数映射关系相似性难以直接用常用的距离进行度量。因此, 本文引入度量学习<sup>[28]</sup> (metric learning, ML) 方法对原始距离度量进行调整, 使调整后的距离能够反映不同样本的频率安全指标与输入特征间函数映射关系的相似性, 进而使用传统基于距离的聚类算法将相似样本分至同簇。

频率安全组合评估模型建立过程可以分为 3 步: 首先, 以反映不同样本频率安全指标与输入特征间函数映射关系相似性为目标, 对原始距离度量进行调整, 即度量学习过程; 然后, 使用聚类方法将相似样本分至同簇; 最后, 分别针对各簇建立频率安全评估子模型。整个过程如图 1 所示, 其中相同形状的点表示函数映射关系相似样本,  $F_1$ 、 $F_2$  和  $F_3$  表示针对各簇样本建立的频率安全评估子模型。

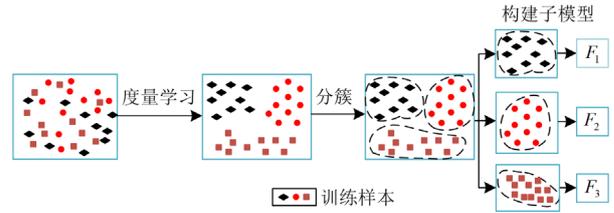


图 1 频率安全组合评估模型建立过程

Fig. 1 Establishment process of the combined assessment model for frequency security assessment

#### 3.2 基于 MLKR 算法的样本距离调整

度量学习对原始距离度量进行调整, 调整后距离度量可反映不同样本频率安全指标与输入特征间函数映射关系相似性, 越相似的样本距离越接近。从而可根据调整后的距离度量对样本进行分簇, 将相似样本分至同簇。

本文引入马氏距离 (Mahalanobis distance)<sup>[28]</sup> 度量不同样本间的距离, 样本  $\mathbf{x}_i$  和  $\mathbf{x}_j$  间的马氏距离  $d_{\text{mah}}(\mathbf{x}_i, \mathbf{x}_j)$  的计算公式如式(10)所示。

$$d_{\text{mah}}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{M} (\mathbf{x}_i - \mathbf{x}_j)} = \sqrt{\|\mathbf{x}_i - \mathbf{x}_j\|_{\mathbf{M}}^2} \quad (10)$$

式中,  $\mathbf{M}$  为可以通过度量学习进行调整的半正定变换矩阵, 即马氏矩阵。

度量学习过程即矩阵  $\mathbf{M}$  的调整过程。在度量学习过程中首先需要选择  $F(\cdot)$  的形式, 即选择适当的机器学习方法内嵌入度量学习过程之中, 从而在学习过程中根据函数映射关系相似样本尽量接近的原则对  $\mathbf{M}$  进行调整。懒惰式机器学习 (lazy learning, LL) 不需要显式训练过程<sup>[29]</sup>, 相较于急切式机器学习 (eager learning, EL) 更适合嵌入度量学习过程中。本文选择经典懒惰学习算法核回归 (kernel regression, KR) 算法内嵌入度量学习, 度量学习过程即为核回归度量学习 (metric learning for kernel regression, MLKR)<sup>[29]</sup>。

本文选择高斯核函数<sup>[29]</sup> 作为 KR 核函数, 并设定其半径为 1, 得到待评估场景基于 KR 方法的频率安全评估指标评估值  $\hat{y}_i$ , 如式(11)所示。

$$\hat{y}_i = \frac{\sum_{j=1}^{N_{\text{tra}}} y_j e^{-d_{\text{mah}}(\mathbf{x}_i, \mathbf{x}_j)}}{\sum_{j=1}^{N_{\text{tra}}} e^{-d_{\text{mah}}(\mathbf{x}_i, \mathbf{x}_j)}} \quad (11)$$

式中:  $y_j$  表示第  $j$  个历史训练样本的频率安全指标真实值;  $N_{\text{tra}}$  表示训练样本个数。

基于函数映射关系相似样本尽量接近的学习目标, MLKR 学习过程的损失函数  $L$  如式(12)所示,

MLKR 学习过程即为调整矩阵  $M$  以最小化损失函数的优化问题求解过程。

$$\min L = \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (12)$$

将半正定矩阵  $M$  分解为如式(13)的形式。

$$M = A^T A \quad (13)$$

马氏距离重新定义为如式(14)所示的形式, MLKR 学习过程即以式(12)中损失函数最小化为目标求解矩阵  $A$  的过程。

$$d_{\text{mah}}(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sqrt{(\mathbf{x}_i - \mathbf{x}_j)^T A^T A (\mathbf{x}_i - \mathbf{x}_j)}}{\sqrt{\|A(\mathbf{x}_i - \mathbf{x}_j)\|^2}} \quad (14)$$

本文使用批量梯度下降(batch gradient descent, BGD)方法<sup>[30]</sup>求解  $A$ , MLKR 学习过程中  $A$  的每次迭代修正量  $\Delta A$  计算方法如式(15)和式(16)所示。

$$\frac{\partial L}{\partial A} = 4A \sum_i (\hat{y}_i - y_i) \sum_j (\hat{y}_j - y_j) k_{ij} \mathbf{x}_i \mathbf{x}_j^T \quad (15)$$

$$\Delta A = -\varepsilon \frac{\partial L}{\partial A} \quad (16)$$

式中:  $k_{ij}$  表示基于样本  $\mathbf{x}_i$  和  $\mathbf{x}_j$  所得到的的高斯核;  $\varepsilon$  表示步长。

### 3.3 样本聚类与子模型构建

通过 MLKR 学习对样本间距离进行调整后, 对于不同样本, 若频率安全指标与输入特征间函数映射关系相似, 则样本间距离接近。需要进一步使用聚类算法将相似样本分至同簇, 从而针对各簇建立频率安全子评估模型。本文使用经典的模糊 k-means 聚类<sup>[31]</sup>对样本进行分簇。在模糊 k-means 聚类中, 首先从样本中随机选取初始簇中心点  $c_j (j = 1, 2, \dots, K)$ , 其中  $K$  为聚类簇数。然后计算样本  $\mathbf{x}_i$  对第  $q$  个样本簇的隶属度  $u(\mathbf{x}_i, q)$ , 如式(17)所示。

$$u(\mathbf{x}_i, q) = \left( \sum_{j=1}^K \left( \frac{d_{\text{mah}}(\mathbf{x}_i, \mathbf{c}_q)}{d_{\text{mah}}(\mathbf{x}_i, \mathbf{c}_j)} \right)^{\frac{1}{\beta-1}} \right)^{-1} \quad (17)$$

式中,  $\beta$  为所设定的隶属度参数。

簇中心  $\mathbf{c}_q$  使用第  $q$  簇样本隶属度平均值对其进行更新, 如式(18)所示。

$$\mathbf{c}_q = \frac{\sum_{i=1}^{N_q} (u(\mathbf{x}_i, q))^\beta \mathbf{x}_i}{\sum_{i=1}^{N_q} (u(\mathbf{x}_i, q))^\beta} \quad (18)$$

式中,  $N_q$  为第  $q$  个样本簇中的样本个数。

不断重复分簇迭代过程, 直至样本簇中心不再改变, 即可得到最终的簇中心。将待评估场景对各

簇的隶属度定义为其归属于各簇的置信度, 将相应场景分至置信度最高的样本簇中。

相较于懒惰式机器学习方法, 急切式机器学习方法通过离线学习, 构建最大频率偏移等频率安全指标与输入特征之间的显式函数关系表达式, 频率安全的在线评估直接基于所构建的表达式进行, 评估过程迅速, 不需要进行懒惰式机器学习中待评估场景与训练样本间的距离计算。因此, 在完成度量学习和样本分簇后, 本文最终选择经典的急切学习方法 SVR 方法<sup>[14]</sup>构建各样本簇对应的子评估模型。基于 SVR 方法的子评估模型频率安全指标与输入特征间的表达式如式(19)所示。

$$F(\mathbf{x}_i) = \mathbf{w}^T \varphi(A\mathbf{x}_i) + b \quad (19)$$

式中:  $\mathbf{w}$  为系数向量;  $b$  为偏置量;  $\varphi$  为与核函数所对应的函数映射, 本文中 SVR 模型核函数取为高斯核函数。

## 4 算例分析

### 4.1 算例电网介绍

以图 2 所示简化的山东电网作为算例, 验证本文所提频率安全机器学习评估方法的有效性。该算例电网基准运行方式下总负荷为 58 GW, 共有 3 条直流馈入, 总直流馈入为 20 GW, 其中直流#1 和直流#2 线路容量均为 8 GW, 直流#3 线路容量为 4 GW。在算例系统中节点 170、178、187、322 分别接入 1 号风电场、2 号风电场、3 号风电场和 4 号风电场。

### 4.2 样本集构建

以 15 min 作为时间间隔, 基于系统 1 个月共 2976 个时间断面下的风电功率与负荷数据, 以网损最小为目标进行潮流计算, 得到 2976 个系统运行场景。以直流#2 闭锁作为预想事故, 取 2976 个场景中的 976 个场景作为历史运行场景, 进行时域仿真得到预想事故下  $\Delta f_{\text{max}}$ 、 $f_{\text{max}}^{\text{ROCOF}}$  和  $\Delta f_{\text{ss}}$  作为所要进行评估的频率安全指标, 构建原始训练样本集。基于其余 2000 个场景进行预想事故下的时域仿真, 构建测试样本集。

本文对以  $\Delta f_{\text{max}}$  作为模型评估指标输出的模型详细学习过程进行展示, 以  $f_{\text{max}}^{\text{ROCOF}}$  和  $\Delta f_{\text{ss}}$  作为评估指标输出的模型学习过程类似。在 4.6 节, 统一给出基于所提方法建立的频率安全评估模型对各频率安全指标的最终评估精度情况。

### 4.3 新增训练样本生成

基于 976 个初始训练样本进行 MLKR 学习, MLKR 学习过程收敛后  $\Delta f_{\text{max}}$  评估误差收敛于较大值 0.137 Hz 左右。使用本文所提方法生成新场景以

生成新的训练样本用于模型训练, 以提高频率安全评估模型精度。基于 WGAN 生成符合历史场景分布规律的新运行场景集, 将其与文献[23]中使用的在一定范围内随机变化负荷水平和新能源出力等系统运行状态、进而生成批量运行场景以构建训练样本集的方法进行比较。为可视化比较结果, 使用

t-SNE 方法<sup>[32]</sup>对场景进行降维处理, 降为  $x_1$  和  $x_2$  二维特征表示的形式, 如图 3 所示。从图 3 可以看出, 使用本文所提基于 WGAN 的新场景生成方法可以生成遵循系统历史真实运行方式分布规律的场景, 更好地覆盖历史实际运行方式。

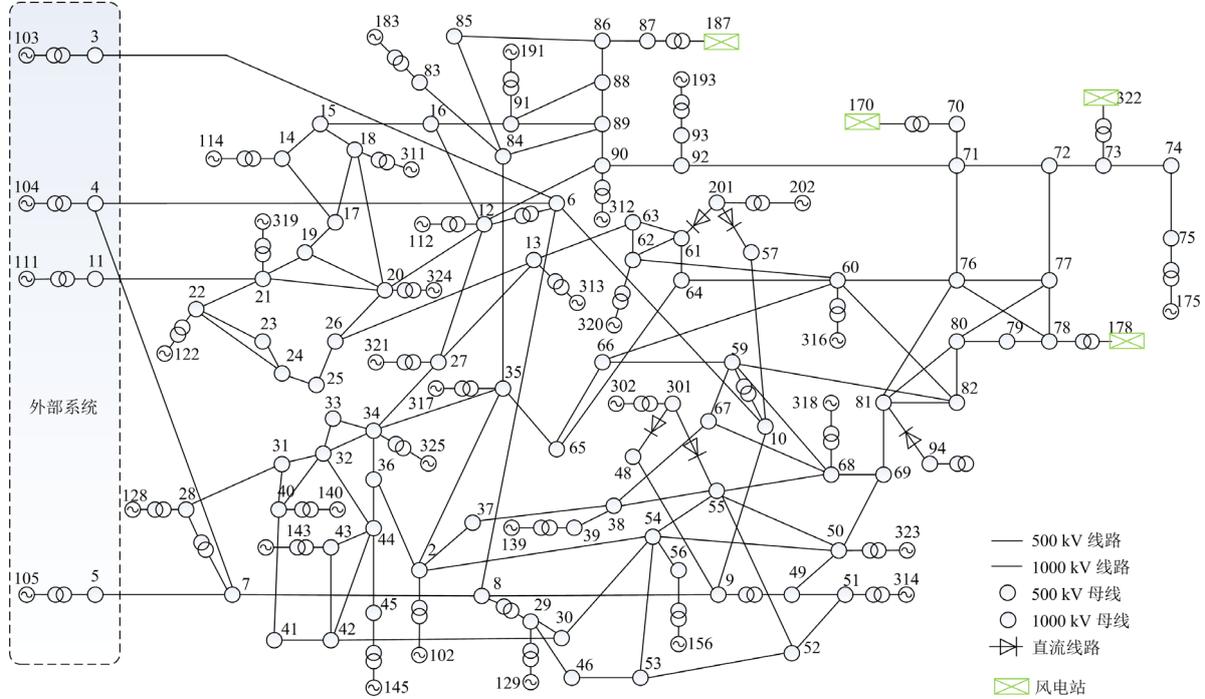


图 2 简化的山东电网单线图

Fig. 2 Single line diagram of simplified Shandong power grid

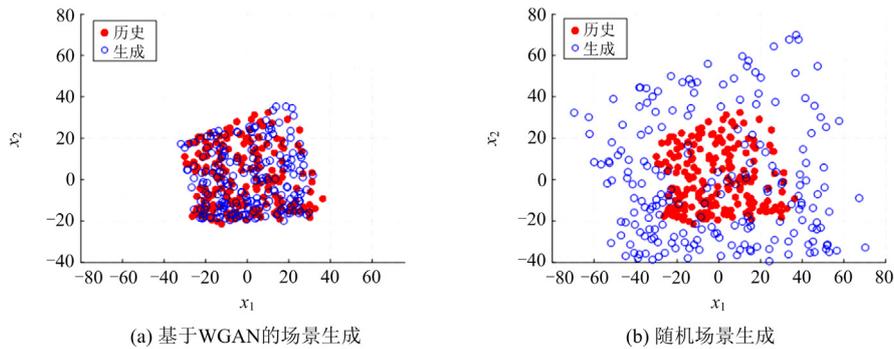


图 3 不同场景生成方式下场景分布对比

Fig. 3 Comparison of scenario distribution with different scenario generation methods

将基于 KR 方法的  $\Delta f_{\max}$  评估误差大于 0.1 Hz 的样本所对应运行场景定义为关键场景, 使用拒绝采样与重采样方法对新生成场景进行调整。通过拒绝采样与重采样, 提高关键场景附近的训练样本密度, 直至全部待评估场景的评估误差均小于 0.1 Hz, 最终得到增加训练样本后的训练样本集, 共 2507 个训

练样本。

#### 4.4 频率安全组合评估模型学习过程

基于训练样本集进行 MLKR 学习, 并使用测试集测试学习效果。在 MLKR 学习前,  $\Delta f_{\max}$  指标最大训练误差为 0.187 Hz, 最大测试误差为 0.169 Hz。MLKR 学习后, 最大训练误差减小为 0.0404 Hz, 最

大测试误差减小为 0.0468 Hz。MLKR 学习过程中, 训练误差和测试误差的变化如图 4 所示, 其中  $e_{\max}$  表示各次迭代中所有样本的最大评估误差。随着 MLKR 学习迭代次数的增加, 评估误差逐渐收敛。

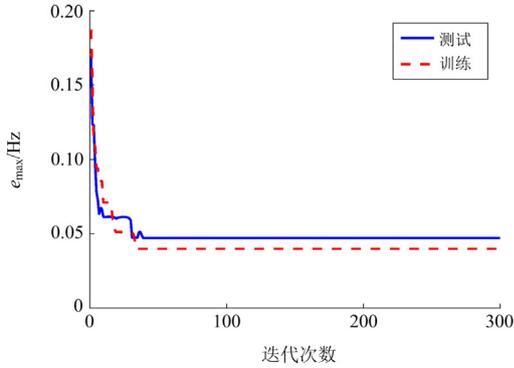


图 4 在 MLKR 学习过程中评估误差的变化  
Fig. 4 Variation of the assessment error in the process of MLKR learning

在 MLKR 学习之后, 采用模糊 k-means 聚类对样本进行分簇, 并分别使用 KR 方法和 SVR 方法建立各簇对应子评估模型。在 MLKR 学习前后, 不同  $K$  值下 KR 和 SVR 评估误差如图 5 所示。

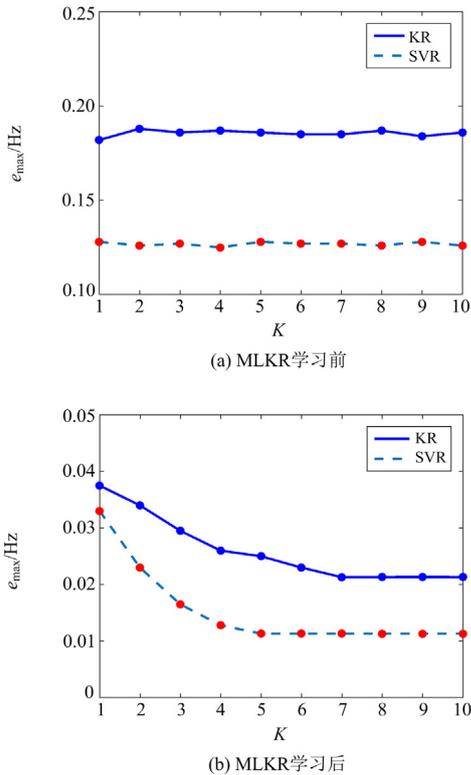


图 5 MLKR 学习前后不同  $K$  值下 KR 与 SVR 子模型误差  
Fig. 5 Error of the KR and SVR sub-models with different  $K$  before and after MLKR learning

在 MLKR 学习前, 距离接近的样本其频率动态并不一定相似, 基于原始距离度量进行聚类无法保证将频率安全指标与输入特征函数映射关系相似的样本分至同簇, 随着  $K$  值的增加, 频率安全评估误差基本无变化。经 MLKR 学习后, 样本间距离与样本间频率动态相似性相关, 频率安全指标与输入特征函数映射关系相似样本接近。随着  $K$  值的增加, 同簇样本频率动态相似性增加, 各簇样本使用 KR 与 SVR 进行评估, 评估误差均随着  $K$  值的增加而逐渐减小, 模型评估精度提高, 如图 5 所示。相较于 KR 方法, SVR 评估模型具有更好的函数拟合能力, 因此具有更高的频率安全指标评估精度。随着  $K$  值的增加, 当  $K > 6$  时, 模型评估误差不再明显减小, 故本文最终取  $K = 6$ 。

#### 4.5 与其他方法的对比

对比基于人工神经网络(artificial neural network, ANN)、函数链神经网络(functional link neural network, FLNN)、 $\nu$ -支持向量回归( $\nu$ -support vector regression,  $\nu$ -SVR)、极限学习机(extreme learning machine, ELM)以及文献[23]中度量学习(metric learning, ML)机器学习方法的频率安全评估模型和本文频率安全组合评估模型, 训练样本生成方法分别采用本文方法和在一定范围内随机变化负荷水平等系统运行状态的方法, 不同方法测试误差如图 6 所示。随机生成训练样本方法中, 基于历史运行方式下各负荷及新能源机组出力取值范围, 随机生成相应负荷水平和新能源机组出力。对负荷水平与新能源机组出力进行组合, 按照最优潮流原则计算各常规机组出力, 分别生成 2000 个、4000 个、8000 个训练样本, 将基于上述训练样本集进行模型训练所得模型测试误差与采用本文方法生成的 2507 个训练样本进行训练所得模型测试误差进行对比, 结果如图 6 所示。

如图 6 所示, 本文所提频率安全组合评估模型具有较好的泛化能力, 在各种训练样本集上均取得相较于其他方法更低的频率安全指标测试误差。当随机生成训练样本时, 所生成训练样本集难以覆盖系统实际运行场景分布, 模型训练效率较低, 基于 2000 个随机训练样本进行训练所得到的频率安全组合评估模型测试误差高达 0.102 Hz。随着训练样本数增加, 频率安全组合评估模型测试误差缓慢减小。直至随机训练样本数增加至 8000 个, 频率安全组合评估模型测试误差降为 0.053 Hz。

与随机生成训练样本相比, 基于本文训练样本生成方法所得到的训练样本可以较好地覆盖系统实际运行场景分布。通过使用拒绝采样与重采样技术,

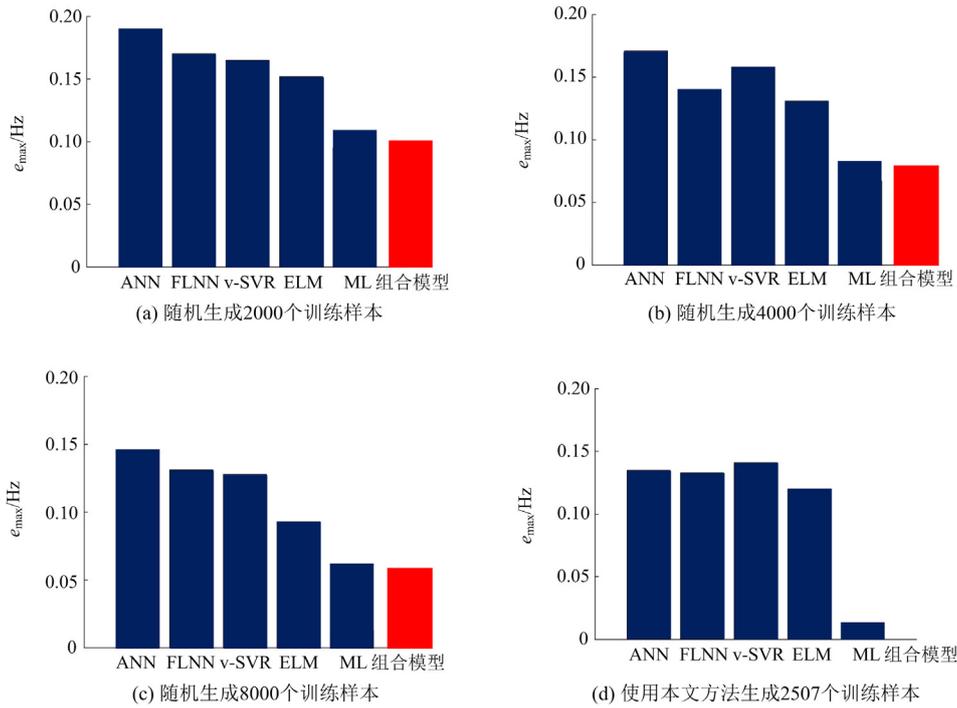


图 6 不同训练样本集下不同评估模型测试误差

Fig. 6 Test errors of different models with different training sample sets

提高了在评估误差较大的关键场景附近的训练样本密度, 模型训练效率得到提高。使用本文所提训练样本生成方法, 仅需 2507 个训练样本即可使模型测试误差减小至 0.0113 Hz。与随机生成训练样本相比, 在训练样本数量不到其三分之一的情况下, 训练得到精度比其更高的评估模型, 证明了本文所提训练样本生成方法有效性。

#### 4.6 各频率安全指标评估精度

上述算例分析对以  $\Delta f_{\max}$  作为模型输出的模型学习过程以及与其他方法的对比进行了详细展示, 以  $f_{\max}^{\text{ROCOF}}$  和  $\Delta f_{\text{ss}}$  作为模型输出的模型学习过程类似, 本文未加详叙。此处统一给出基于本文所提频率安全组合评估模型得到的各频率安全指标  $\Delta f_{\max}$ 、 $f_{\max}^{\text{ROCOF}}$  和  $\Delta f_{\text{ss}}$  评估误差的最大值与平均值, 如表 1 所示。

表 1 各频率安全指标评估误差最大值与平均值

Table 1 Maximum and average values of the assessment errors of each frequency security indicator

频率安全指标	$\Delta f_{\max}/\text{Hz}$	$f_{\max}^{\text{ROCOF}}/(\text{Hz/s})$	$\Delta f_{\text{ss}}/\text{Hz}$
评估误差最大值	0.0113	0.0098	0.0092
评估误差平均值	0.0093	0.0067	0.0071

如表 1 所示, 使用本文方法所建立频率安全组合评估模型对各频率安全指标均有较高的评估精

度, 各频率安全指标评估误差较小。其中,  $\Delta f_{\max}$  评估误差在 0.0113 Hz 内,  $f_{\max}^{\text{ROCOF}}$  评估误差在 0.0098 Hz/s 内,  $\Delta f_{\text{ss}}$  评估误差在 0.0092 Hz 内。基于本文所提方法, 可以对直流闭锁严重功率扰动后的频率安全指标进行快速准确的评估。

## 5 结论

本文提出了基于生成对抗网络与度量学习方法的数据驱动频率安全评估模型, 用于大量不确定运行场景的频率安全快速评估。在频率安全指标选取与输入特征构建方面, 选取反映扰动后频率动态过程的关键指标进行评估, 并选择扰动前潮流特征构建频率安全评估模型输入特征, 以避免对时域仿真的依赖, 保证评估的快速性。在频率安全评估模型训练样本生成方面, 提出了基于生成对抗网络的训练样本生成方法, 并使用拒绝采样和重采样技术提高关键场景附近样本密度, 提高频率安全评估模型对未来待评估场景的泛化能力。在频率安全评估模型结构与学习算法方面, 构建了由多个子模型构成的频率安全组合评估模型, 充分计及系统不同场景下扰动事件后频率动态差异较大、频率安全指标与输入特征间函数映射关系差异较大导致单个评估模型评估精度不足的问题, 提高频率安全评估的准确性。通过简化的山东电网算例, 验证了本文所提方

法可以对大量不同运行场景下的多直流馈入受端电网遭受直流闭锁严重功率扰动后的频率安全进行快速准确的评估。在未来的工作中,获取电力系统实际运行数据以构造待评估场景和训练评估模型,可进一步将本文所提方法应用到实际电网频率安全在线评估中。

### 参考文献

- [1] 胡加伟,王彤,王增平. 直流闭锁后系统暂态稳定紧急协同控制策略研究[J]. 电力系统保护与控制, 2023, 51(4): 43-52.  
HU Jiawei, WANG Tong, WANG Zengping. Collaborative emergency control strategy of system transient stability after DC blocking[J]. Power System Protection and Control, 2023, 51(4): 43-52.
- [2] 李世春,田冰杰,李惠子,等. 基于频率安全约束与临界惯量计算的分时段限制风电出力方法[J]. 电力系统保护与控制, 2022, 50(15): 60-71.  
LI Shichun, TIAN Bingjie, LI Huizi, et al. Method for limiting wind power output in time periods based on frequency safety constraints and a critical inertia calculation[J]. Power System Protection and Control, 2022, 50(15): 60-71.
- [3] 相禹维,王彤,李聪聪,等. 面向大容量直流闭锁的暂态稳定紧急切机控制策略研究[J]. 电力系统保护与控制, 2021, 49(15): 84-92.  
XIANG Yuwei, WANG Tong, LI Congcong, et al. Strategy of emergency generator tripping control for transient stability after a large capacity HVDC blocking fault[J]. Power System Protection and Control, 2021, 49(15): 84-92.
- [4] 韩泽雷,鞠平,秦川,等. 面向新型电力系统的频率安全研究综述与展望[J]. 电力自动化设备, 2023, 43(9): 112-124.  
HAN Zelei, JU Ping, QIN Chuan, et al. Review and prospect of research on frequency security of new power system[J]. Electric Power Automation Equipment, 2023, 43(9): 112-124.
- [5] 施翔,刘洪波,徐兴伟,等. 电力系统频率动态过程仿真中锅炉动态特性影响研究[J]. 电力自动化设备, 2007, 27(5): 69-72.  
SHI Xiang, LIU Hongbo, XU Xingwei, et al. Study of impact of boiler's dynamic characteristics on dynamic frequency process in power system[J]. Electric Power Automation Equipment, 2007, 27(5): 69-72.
- [6] 谢大鹏,王晓茹,张薇. 利用PSS/E实现电力系统低频减载控制仿真[J]. 电力系统保护与控制, 2009, 37(1): 71-75.  
XIE Dapeng, WANG Xiaoru, ZHANG Wei. Realization of power system under-frequency load shedding control simulation with PSS/E[J]. Power System Protection and Control, 2009, 37(1): 71-75.
- [7] 王一振,马世英,王青,等. 大型火电机组动态频率响应特性[J]. 电网技术, 2013, 37(1): 106-111.  
WANG Yizhen, MA Shiyong, WANG Qing, et al. Dynamic frequency response characteristics of large thermal power generation units[J]. Power System Technology, 2013, 37(1): 106-111.
- [8] BEVRANI H, GHOSH A, LEDWICH G. Renewable energy sources and frequency regulation: survey and new perspectives[J]. IET Renewable Power Generation, 2010, 4(5): 438-457.
- [9] MOGHADDAM S Z. Generation and transmission expansion planning with high penetration of wind farms considering spatial distribution of wind speed[J]. International Journal of Electrical Power & Energy Systems, 2019, 106(3): 232-241.
- [10] CHAN M L, DUNLOP R D, SCHWEPP F. Dynamic equivalents for average system frequency behavior following major disturbances[J]. IEEE Transactions on Power Apparatus and Systems, 1972, 91(4): 1637-1642.
- [11] ANDERSON P M, MIRHEYDAR M. A low-order system frequency response model[J]. IEEE Transactions on Power Systems, 1990, 5(3): 720-729.
- [12] 李常刚,刘玉田,张恒旭,等. 基于直流潮流的电力系统频率响应分析方法[J]. 中国电机工程学报, 2009, 29(34): 36-41.  
LI Changgang, LIU Yutian, ZHANG Hengxu, et al. Power system frequency response analysis based on the direct current loadflow[J]. Proceedings of the CSEE, 2009, 29(34): 36-41.
- [13] ALIZADEH M, AMRAEE T. Adaptive scheme for local prediction of post-contingency power system frequency[J]. Electric Power Systems Research, 2014, 107(5): 240-249.
- [14] 薄其滨,王晓茹,刘克天. 基于v-SVR的电力系统扰动后最低频率预测[J]. 电力自动化设备, 2015, 35(7): 83-88.  
BO Qibin, WANG Xiaoru, LIU Ketian. Minimum frequency prediction based on v-SVR for post-disturbance power system[J]. Electric Power Automation Equipment, 2015, 35(7): 83-88.
- [15] XU Y, DAI Y Y, DONG Z Y, et al. Extreme learning machine-based predictor for real-time frequency stability assessment of electric power systems[J]. Neural Computing and Applications, 2013, 22(1): 501-508.
- [16] 文云峰,赵荣臻,肖友强,等. 基于多层极限学习机的电力系统频率安全评估方法[J]. 电力系统自动化, 2019, 43(1): 133-140.  
WEN Yunfeng, ZHAO Rongzhen, XIAO Youqiang, et al.

- Frequency safety assessment of power system based on multi-layer extreme learning machine[J]. *Automation of Electric Power Systems*, 2019, 43(1): 133-140.
- [17] 李冠争, 李斌, 王帅, 等. 基于特征选择和随机森林的电力系统受扰后动态频率预测[J]. *电网技术*, 2021, 45(7): 2492-2502.
- LI Guanzheng, LI Bin, WANG Shuai, et al. Dynamic frequency prediction of power system post-disturbance based on feature selection and random forest[J]. *Power System Technology*, 2021, 45(7): 2492-2502.
- [18] WANG Q, LI F, TANG Y, et al. Integrating model-driven and data-driven methods for power system frequency stability assessment and control[J]. *IEEE Transactions on Power Systems*, 2019, 34(6): 4557-4568.
- [19] 赵荣臻, 文云峰, 叶希, 等. 基于改进堆栈降噪自动编码器的预想事故频率指标评估方法研究[J]. *中国电机工程学报*, 2019, 39(14): 4081-4093.
- ZHAO Rongzhen, WEN Yunfeng, YE Xi, et al. Research on frequency indicators evaluation of disturbance events based on improved stacked denoising autoencoders[J]. *Proceedings of the CSEE*, 2019, 39(14): 4081-4093.
- [20] 黄明增, 文云峰, 苟竞, 等. 计及频率偏移分布与惩罚代价的最大频率偏移预测方法[J]. *电力系统自动化*, 2021, 45(23): 51-59.
- HUANG Mingzeng, WEN Yunfeng, GOU Jing, et al. Maximum frequency deviation prediction method considering frequency deviation distribution and penalty cost[J]. *Automation of Electric Power Systems*, 2021, 45(23): 51-59.
- [21] 仇怡超, 闻达, 王晓茹, 等. 基于深度置信网络的电力系统扰动后频率曲线预测[J]. *中国电机工程学报*, 2019, 39(17): 5095-5104.
- ZHANG Yichao, WEN Da, WANG Xiaoru, et al. A method of frequency curve prediction based on deep belief network of post-disturbance power system[J]. *Proceedings of the CSEE*, 2019, 39(17): 5095-5104.
- [22] 周志华. *机器学习*[M]. 北京: 清华大学出版社, 2015.
- [23] LI H R, LI C G, LIU Y T, Maximum frequency deviation assessment with clustering based on metric learning[J]. *International Journal of Electrical Power & Energy Systems*, 2020, 120.
- [24] 贾梦瑶, 王玉玮, 宋明浩. 基于时间生成对抗网络的风电随机场景预测[J]. *智慧电力*, 2023, 51(8): 59-66.
- JIA Mengyao, WANG Yuwei, SONG Minghao. Stochastic scenario prediction of wind power based on time generative adversarial networks[J]. *Smart Power*, 2023, 51(8): 59-66.
- [25] 程卓, 许仪勋, 李泽霜. 基于改进生成对抗网络生成风光场景的微电网多时间尺度优化调度策略研究[J/OL]. *现代电力*: 1-10[2023-12-06]. <https://doi.org/10.19725/j.cnki.1007-2322.2022.0309>.
- CHENG Zhuo, XU Yixun, LI Zeshuang. Research on multi-time scale optimization scheduling strategy of microgrid based on improved generative adversarial network for wind and PV power scenario generation[J/OL]. *Modern Electric Power*: 1-10[2023-12-06]. <https://doi.org/10.19725/j.cnki.1007-2322.2022.0309>.
- [26] YORINO N, ABDILLAH M, SASAKI Y. Robust power system security assessment under uncertainties using bi-level optimization[J]. *IEEE Transactions on Power Systems*, 2018, 33(1): 352-362.
- [27] BIEIMAN L. Bagging predictors[J]. *Machine Learning*, 1996, 26(2): 123-140.
- [28] BELLET A, HABRARD A, SEBBAN M. A survey on metric learning for feature vectors and structured data [EB/OL]. [2023-12-06]. <https://arxiv.org/abs/1306.6709>.
- [29] WEINBERGER K Q, TESAURO G. Metric learning for kernel regression[J]. *Journal of Machine Learning Research*, 2007, 2(5): 612-619.
- [30] 杨龔亮, 王秀云, 曾淑珍, 等. 基于改进梯度粒子群算法的无功优化[J]. *现代电力*, 2010, 27(4): 17-21.
- YANG Yanliang, WANG Xiuyun, ZENG Shuzhen, et al. Reactive power optimization based on improved gradient particle swarm optimization algorithm[J]. *Modern Electric Power*, 2010, 27(4): 17-21.
- [31] 赵明宇, 徐石明, 高辉, 等. 基于模糊 K-means 算法的电动汽车应急供电策略[J]. *电力系统自动化*, 2016, 40(5): 91-95, 108.
- ZHAO Mingyu, XU Shiming, GAO Hui, et al. Strategy of electric vehicle emergency power supply based on fuzzy K-means algorithm[J]. *Automation of Electric Power Systems*, 2016, 40(5): 91-95, 108.
- [32] 齐胜, 单海鸥, 罗林, 等. 融合格拉姆角场的深度特征学习在痕量气体浓度识别中的应用研究[J]. *电力系统保护与控制*, 2023, 51(15): 55-65.
- QI Sheng, SHAN Haiou, LUO Lin, et al. Application of deep feature learning with Gram's angle field for trace gas concentration identification[J]. *Power System Protection and Control*, 2023, 51(15): 55-65.

收稿日期: 2023-12-27; 修回日期: 2024-03-15

作者简介:

李华瑞(1994—), 男, 通信作者, 博士, 工程师, 研究方向为电力系统频率安全评估与控制。E-mail: lihuarui\_sdu@163.com

(编辑 周金梅)