

基于关联信息对抗学习的综合能源系统运行状态分析方法

胡旭光¹ 马大中¹ 郑君¹ 张化光¹ 王睿¹

摘 要 综合能源系统 (Integrated energy system, IES) 运行状态分析常以广泛化信息技术应用提供的数据为支撑, 然而传感器故障、网络通信中断等信息异常导致的数据缺失会直接影响数据质量. 在考虑数据缺失的情况下, 本文提出了一种基于关联信息对抗学习的综合能源系统运行状态分析方法. 首先构建深度生成对抗网络 (Generative adversarial network, GAN) 对数据缺失部分进行可靠性补偿. 在设计生成器结构过程中, 通过引入系统拓扑邻接矩阵对生成器输入数据进行优化排序, 进而在训练过程中采用设计的多属性融合生成器损失函数, 促使生成器进一步得到高精度补偿数据. 接着将判别器提取的不同时刻完整能源数据的特征作为基础, 采用浅层特征分布及深层特征信息差异值融合判断, 从而实现系统运行状态分析. 最后对不同数据缺失补偿及不同类型节点改变情况进行仿真, 验证了本文所提方法的可行性与有效性.

关键词 综合能源系统, 数据补偿, 状态分析, 数据特征, 生成对抗网络

引用格式 胡旭光, 马大中, 郑君, 张化光, 王睿. 基于关联信息对抗学习的综合能源系统运行状态分析方法. 自动化学报, 2020, 46(9): 1783–1797

DOI 10.16383/j.aas.c200171



开放科学(资源服务)标识码(OSID):

An Operation State Analysis Method for Integrated Energy System Based on Correlation Information Adversarial Learning

HU Xu-Guang¹ MA Da-Zhong¹ ZHENG Jun¹ ZHANG Hua-Guang¹ WANG Rui¹

Abstract The operation state analysis of integrated energy system (IES) is based on data provided through information technology application. However, data missing caused by ubiquitous device failure, network interruption and so on, has direct influence on quality of data. Considering data missing, this paper proposes an operation state analysis method for integrated energy system based on correlation information adversarial learning. Firstly, deep generative adversarial network (GAN) is presented to complete the reliable data imputation process. In the designed generator structure, an adjacent matrix is presented to optimize the input data sorting, and then the multi-attribute fusion loss function in training process is utilized to drive generator for obtaining high precision completed data. Based on different time completed energy data features extracted by discriminator, difference values of shallow and deep features are considered as the judging index to realize operation state analysis. Finally, the feasibility and effectiveness of the proposed method are verified through the different data imputation situation and the changes of different types of nodes.

Key words Integrated energy system (IES), data imputation, state analysis, data feature, generative adversarial network (GAN)

Citation Hu Xu-Guang, Ma Da-Zhong, Zheng Jun, Zhang Hua-Guang, Wang Rui. An operation state analysis method for integrated energy system based on correlation information adversarial learning. *Acta Automatica Sinica*, 2020, 46(9): 1783–1797

在能源低碳高效化应用的驱动背景下, 电、气、

热等异质能源高度融合的综合能源系统 (Integrated energy system, IES) 被视为未来能源结构的理想化框架^[1-3]. 综合能源系统的主要目标是打破传统能源间相互独立的局面, 通过多种异质互联能源的广泛参与实现多主体用户的跨环节资源优化协调互动, 提高不同资源利用率. 随着系统结构日益复杂及运行规模不断扩大的前提下, 各能源子系统间的耦合程度存在着不同程度的增强. 近年来, 发生的美国西南部大停电^[4]、南加州电网故障^[5]及台湾大停电事故^[6]表明, 能源深度耦合进而使得单一能源变化会通过多种类型的耦合设备传递到其余能源连

收稿日期 2020-03-31 录用日期 2020-06-28

Manuscript received March 31, 2020; accepted June 28, 2020

国家重点研发计划 (2018YFA0702200), 国家自然科学基金 (61773109, 61627809, 61621004), 辽宁省“兴辽英才计划”项目 (XLYC1801005, XLYC1807009) 资助

Supported by National Key Research and Development Program of China (2018YFA0702200), National Natural Science Foundation of China (61773109, 61627809, 61621004), and Liaoning Revitalization Talents Program (XLYC1801005, XLYC1807009)

本文责任编辑 孙秋野

Recommended by Associate Editor SUN Qiu-Ye

1. 东北大学信息科学与工程学院 沈阳 110819

1. College of Information Science and Engineering, Northeastern University, Shenyang 110819

接系统,影响整个系统的安全运行.因此,保障系统安全运行的系统运行状态研究逐渐受到人们重视,并且国内外专家学者针对不同运行场景问题开展了一系列相关工作^[7-9].

针对系统运行状态问题的研究,以物理模型为主的状态估计方法通过合理假设和模型简化可以很好应对运行机理明确的系统.类比于电力系统状态,已有文献通过建立电-气耦合网络稳态量测模型,进而采用最小二乘方法实现了系统坏数据的辨识^[10-11].考虑到各个能源子系统间的数据隐私保护,文献^[12]提出了基于交替方向乘子法的分布式状态识别方法,在保证求解精度的同时提高了计算效率.文献^[13]提出了在能源枢纽参与情况下适用于实时运行风险预警的能量损失评价方法.虽然上述方法取得了一定效果,但是由于推演方法在能源强交织的综合能源系统中难以建立准确模型,模型不精确误差会通过参数传递累积最终使得结果难以保证.在信息智能技术高速发展完善阶段,以数据驱动为主的运行状态分析方法,由于其能够充分挖掘海量信息数据潜在特性并避免对机理模型的过度依赖,因而受到了广泛关注^[14-20].综合电力及气象系统数据,文献^[17]提出了一种基于自编码网络(Autoencoder, AE)的系统安全性估计方法.文献^[18]采用卷积神经网络(Convolutional neural network, CNN)研究了偏差、漂移及失效三种不同的区域供热系统故障.文献^[19]通过生成对抗网络(Generative adversarial network, GAN)解决了小样本故障数据问题,并通过支持向量机及决策树等机器学习方法证明了该方法的有效性.借助于双向生成对抗网络提取的特征,文献^[20]通过构建的近似标准正态分布实现了电力系统运行风险评价.然而由于综合能源系统包含不同类型的能源数据,数据差异性使得上述研究单一能源系统的方法无法满足综合能源系统运行状态分析与检测.

此外,上述数据驱动方法实现的关键前提是数据完整性.然而在现实情况中由于传感器失效、网络通信中断造成数据缺失不可用的情况时有发生,因此在进行系统运行状态分析时数据完整性是必须要考虑的问题.为了能够实现有效数据补偿恢复,期望最大化^[21]、回归分析^[22]及神经网络^[23]等方法逐步应用于该领域研究.文献^[24]提出了用去噪自编码网络(Denoising autoencoder, DAE)实现情绪预测领域的缺失数据生成.文献^[25]将原始交通数据转化为二维图像,并采用卷积神经网络实现了缺失数据部分的补偿. GAN 由于其在数据补偿过程中,可以通过深度神经网络强大的拟合能力对数据关联性进行研究分析,利用生成器和判别器的互相博弈

学习产生所需要的输出结果,从而避免复杂机理模型建立及参数不确定性带来的影响,因而得到广泛关注.文献^[26-27]对一维时间序列的量测数据进行了缺失值重建,保证了补偿数据具有与真实数据相似的时序特性.通过融合状态估计物理模型,文献^[28]采用 GAN 实现了电力系统测量值的恢复.文献^[29]对于风机数据的丢失问题,采用了条件生成对抗网络(Conditional GAN)用监督学习的方式实现了数据的有效补偿.尽管上述方法对时空关联性数据进行了研究,但是它们的数据均来源于同一系统,不存在数据量纲及变化幅值不统一的情况.对于综合能源系统来说,针对多时间尺度能源数据的补偿问题,仍需要结合耦合能量存在的潮流特性进行深入探究.

综上所述,在结合能源数据特性的前提下,本文以耦合能源数据为基础,通过生成对抗网络学习能源数据抽象特征,实现缺失数据情况下综合能源系统运行状态的分析.本文的创新点总结如下:

1) 提出一种基于关联信息对抗学习的综合能源系统运行状态分析方法.首先通过生成器对能源数据存在缺失的部分进行补偿,进而以完整数据为输入,通过判别器提取的特征差异性完成对系统运行状态的分析.

2) 针对系统缺失数据,采用以 U 型卷积神经网络为基础结构的生成器网络实现不同缺失数据情况的有效补偿.通过关联度进行输入数据优化排序及多属性融合的生成器损失函数设计,增强训练过程中生成器特征提取能力,从而提高数据补偿的精准性.

3) 采用差异化数据特征衡量方式完成对系统运行状态的分析.在判别器得到不同抽象特征的基础上,通过不同时刻浅层特征分布和深层特征信息差异性比较,判断出系统状态的改变,从而完成系统运行状态分析.

接下来,本文从以下 4 个方面进行阐述:第 1 节主要介绍系统结构及生成对抗网络基本内容;第 2 节介绍提出的基于对抗学习的数据补偿及系统运行状态分析方法;第 3 节通过综合能源系统仿真结果说明本文所提方法的有效性;最后,在第 4 节对本文所研究内容予以总结性描述.

1 预备知识

1.1 系统描述

综合能源系统是由电力、天然气及热力等不同能源子系统通过管道及耦合设备连接的大型网络.为了更好地对系统进行描述,本文根据图论将系统

表示为有向图 $\Psi = (V, L)$, 其中 $V = \{V_E, V_G, V_H\}$ 为 $\tilde{x}$ 个电力节点 v_i^E , $\tilde{y}$ 个天然气节点 v_j^G 及 $\tilde{z}$ 个热力节点 v_k^H 抽象而成的节点集合, 共有 $\tilde{w}$ 个系统节点. L 为能量传输线路集合. 在此基础上, 为了描述节点连接程度, 定义综合能源系统的邻接矩阵 $\tilde{A}^\Psi = [a_{ij}]_{\tilde{w} \times \tilde{w}}$, $\hat{i}$ 和 $\hat{j}$ 为系统节点并且定义元素 a_{ij} 为

$$a_{ij} = \begin{cases} -1, & \hat{j} \rightarrow \hat{i} \\ 1, & \hat{i} \rightarrow \hat{j} \\ 0, & \text{其余情况} \end{cases} \quad (1)$$

进一步, 假设系统 Ψ 中每个节点 $\hat{i}$ 均能够得到相应测量值, 也就是说系统内获取的测量变量均为已知可量测数据. 经过 l 个采样时刻后, 在采样时刻 t , 系统内第 $\hat{i}$ 个节点的测量值向量 $\mathbf{m}_i^t$ 表示为 $\mathbf{m}_i^t = (m_i^t(t-l+1), m_i^t(t-l+2), \dots, m_i^t(t))$. 将 $\tilde{w}$ 个节点测量值向量按照第 2.1.1 节得到的顺序排列得到测量矩阵 $M^t \in \mathbf{R}^{\tilde{f} \times l}$, $\tilde{f}$ 为系统测量值的总数量.

不同于单一能源系统, 综合能源系统内不同子系统有各自的测量变量, 会导致不同的量纲和变化幅值难以统一衡量, 能量变化差异度难以统一描述. 因此在不改变原始数据相关关系基础上, 本文进一步对测量矩阵 M^t 进行量纲归一化变换处理, 使其能够在同一衡量标准下进行分析, 变换后的矩阵 $\tilde{M}^t$ 为

$$\tilde{M}^t = [\tilde{h}(|\Delta M_E^t|), \tilde{h}(|\Delta M_G^t|), \tilde{h}(|\Delta M_H^t|)]^T \odot \tilde{h}(\lg |\Delta M^t| + r) \quad (2)$$

其中, ΔM_E^t , ΔM_G^t , ΔM_H^t 分别表示电力、天然气及热力子系统的差值测量子矩阵, 反映子系统内部不同节点量测数据变化, ΔM^t 为综合能源系统差值测量子矩阵, 实现各个子系统数据变化情况的统一体现, 此外其元素均为该时刻与上一时刻测量差值的绝对值, $\tilde{h}(\cdot)$ 为归一化函数, $\odot$ 为点乘运算符号. 作为 $\lg |\Delta M^t|$ 的补偿项, r 为实常数 r 构成的列向量.

接着, 对矩阵 $\tilde{M}^t$ 的每一行进行标准化变换, 得到如下所示的标准行向量 $\hat{\mathbf{m}}^t$

$$\hat{\mathbf{m}}^t = \frac{\tilde{\mathbf{m}}^t - \mu(\tilde{\mathbf{m}}^t)}{\sigma(\tilde{\mathbf{m}}^t)} \quad (3)$$

最后, 在融合矩阵 $\hat{M}^t$ 体现数据变化差异的基础上, 得到本文研究的数据矩阵 $\check{M}^t$ 为 $\check{M}^t = \hat{M}^t \odot \hat{M}^t$.

1.2 生成对抗网络

Goodfellow 等^[30] 于 2014 年正式提出了 GAN. 由于其能够在不依赖于任何先验假设情况下, 通过生成器 G 和判别器 D 零和博弈得到数据分布规律

并产生理想合成样本, 所以在众多领域取得了大量显著成果^[31-33]. 其中, Conditional GAN 作为原始 GAN 的一种改进网络结构, 在 G 和 D 的模型中均引入标签 c , 通过使用额外信息对模型增加条件, 指导数据生成过程^[34-35]. 此外针对缺失数据生成问题, 为了使 G 的输入数据与输出数据的维度一致, Conditional GAN 的生成器输入中并未增加条件变量 c .

因此针对 G , 为了使输出 $G(z)$ 尽可能近似于原始真实样本 x , 构造的生成器损失函数 L_G 为

$$L_G = E_{z \sim p_z} [1 - \ln D(G(z))] \quad (4)$$

其中, $E(\cdot)$ 为计算期望值, z 为输入样本并服从数据分布 p_z .

针对 D , 其输入为生成器生成样本 $G(z)$ 或者实际样本 x , 并且其训练目标为识别出输入样本来源, 所以 D 的输出结果为判别器输入样本是否为实际真实样本 x 的概率. 如果 D 的输入来自实际真实样本 x , 那么输出概率趋近于为 1, 否则为 0. 基于此, D 的损失函数表达为

$$L_D = -E_{x \sim p_x} [\ln D(x|c)] - E_{z \sim p_z} [1 - \ln D(G(z))] \quad (5)$$

其中, p_x 为实际真实样本 x 服从的数据分布.

进一步, 为了能够描述 G 与 D 的博弈训练过程, 通过对式 (4) 和式 (5) 组合得到极小极大化博弈评价函数 $\hat{V}(G, D)$ 为

$$\min_G \max_D \hat{V}(D, G) = \min_G \max_D E_{x \sim p_x} [\ln D(x|c)] + E_{z \sim p_z} [\ln(1 - D(G(z)))] \quad (6)$$

在生成对抗网络训练初期, 生成器生成的样本 $G(z)$ 由于与实际真实样本 x 存在很大差异, 所以判别器 D 可以很明显地将两者进行区别并得到很高的准确率, 此时 L_G 和 L_D 的值都很大; 随着训练迭代过程的不断进行, 生成器网络通过误差反向传播方式调整每一层网络权值参数使得 $G(z)$ 相似于 x , 与此同时 D 也通过相同方式提高了对不同样本来源的判别能力. 当训练过程进行到 D 再也无法明确区分不同样本来源时, 那么就可以认为 GAN 已经训练完毕.

2 运行状态分析

2.1 缺失数据补偿

2.1.1 输入数据排列

对于 GAN 实现数据补偿来说, 生成器输入数据的构建是极为关键的^[29]. 针对综合能源系统缺失数据补偿问题, 由于其涉及到电、气、热等多种类型

的能量运行数据, 所以必须充分考虑能源数据潮流特性带来的变化关联度. 通过将变化相似的数据放在一起进行数据特征提取可以使特征相似性最大化, 从而提高后续数据补偿精度. 因此为全面考虑不同系统间的能量交互程度, 本文以邻接矩阵 $\tilde{A}^\Psi$ 为基础, 系统多能流计算的统一雅可比矩阵 J^Ψ [36] 为依据进行数据关联度分析. 将电力系统节点有功功率 (P)、无功功率 (Q)、天然气系统的节点流量 (f) 平衡方程以及热力系统的热力-水力平衡方程 (供水温度 T^s , 回水温度 T^r), 在稳态运行点进行 Taylor 级数展开, 略去二次项及以上高次项, 通过线性化多能流修正方程即可得到统一雅可比矩阵 J^Ψ [36], 如下所示:

$$J^\Psi = \begin{bmatrix} J_{P\theta} & J_{Pv} & J_{P\Pi} & J_{Pm} & 0 & J_{PT^r} \\ J_{Q\theta} & J_{Qv} & 0 & 0 & 0 & 0 \\ J_{f\theta} & J_{fv} & J_{f\Pi} & J_{fm} & 0 & J_{fT^r} \\ J_{[\phi,\sigma]\theta} & J_{[\phi,\sigma]v} & 0 & J_{[\phi,\sigma]m} & J_{[\phi,\sigma]T^s} & 0 \\ 0 & 0 & 0 & 0 & J_{T^sT^s} & 0 \\ 0 & 0 & 0 & 0 & 0 & J_{T^rT^r} \end{bmatrix} \quad (7)$$

其中, θ 为电压相角, v 为电压幅值, Π 为天然气节点压力, m 为热力质量流.

由第 1.1 节可知, 邻接矩阵 $\tilde{A}^\Psi$ 是描述节点连接程度的矩阵, 从网络拓扑角度直接反映出节点关

联度. 同时由矩阵 J^Ψ 可知, 矩阵内元素的物理含义为不同异构能源变量间的相互耦合, 体现节点对其余系统节点的能量变化程度影响, 通过隐含着的系统节点间连接关系, 进而间接体现了数据能源方面的关联度. 因此, 定义节点 $\hat{i}$ 的关联度要素 φ_i 为

$$\varphi_i = \sum_{\varsigma=1}^{\kappa} \chi \times a_{i\varsigma} \times j_{i\varsigma} + \sum_{\tilde{\varsigma}=1}^{\tilde{\kappa}} a_{i\tilde{\varsigma}} \times j_{i\tilde{\varsigma}} \quad (8)$$

其中, κ 和 $\tilde{\kappa}$ 分别为节点 $\hat{i}$ 流向其他节点和其他节点流向节点 $\hat{i}$ 的数量, χ 为节点连接关联度权重, $j_{i(\cdot)}$ 为矩阵 J^Ψ 的元素.

进一步通过关联度要素 φ_i 的值即可确定数据间关联度关系, 最终实现输入数据的优化排序.

2.1.2 网络结构

在确定输入数据排列顺序的基础上, 网络结构是 GAN 实现数据补偿的另一个重要环节. 相较于全连接神经元构建的 GAN, 由卷积核搭建的 GAN 能够通过卷积操作对局部数据信息进行关注, 并且相同情况下运行效率更高. 进一步考虑到在调整输入数据的基础上, 卷积网络可以更好地对具有强烈时序特性变化的关联数据挖掘时空特性, 更好地完成数据补偿. 因此本文均采用卷积神经网络对 GAN 实现 G 和 D 的网络结构构建, 结构示意图如图 1 所示.




图 1 GAN 结构示意图

Fig. 1 Diagram of GAN structure

在数据补偿问题中, G 的输入样本 z 可以看作是在真实样本 x 的基础上修改得到的. 因此生成器网络是通过特征提取处理高维数据到高维数据的映射关系. 由于 G 的输入为高维数据矩阵 $\tilde{M}^t$, 无法直接对其进行操作, 因此需要通过低维特征的联合共享及逐层反卷积实现缺失数据的补偿. 基于此, 本文采用 U 型卷积神经网络^[37] 作为生成器结构. 如图 1 所示, 相较于普通自编码网络, U 型卷积神经网络中编码器第 i 层与解码器第 $n-i$ 层神经网络的结构相同, 通过加入跳跃连接, 可以将第 i 层网络拼接到第 $n-i$ 层中实现不同网络层的特征传递, 形成对应特征强化关系, 便于实现高维数据的生成.

D 的功能是对 x 和 $G(z)$ 进行特征提取并实现样本来源的判断, 因此如图 1 所示, 采用只包含卷积层的卷积神经网络进行训练并输出对应数据的差异性. 考虑到 D 提取的特征包含更多能源数据潜在特征并且后续用于运行状态分析, 因此在判别器中不添加全连接层, 而是通过不同卷积层提取的特征来区分 x 和 $G(z)$ 的差异性并通过第 2.1.3 节构造的损失函数完成 GAN 的训练.

2.1.3 损失函数

在 GAN 中, G 的作用是尽可能使缺失数据类似于原始真实数据. 因为综合能源系统数据具有实际物理意义, 所以为了得到更加精准的数据补偿结果, 需要同时考虑数据及物理两方面属性对生成器损失函数 L_G 进行设计.

从数据属性来看, 如果 GAN 能达到理想效果, 也就是说生成样本 $G(z)$ 能完全复原真实样本 x , 那么经过相同神经网络提取的数据特征也完全相同. 生成样本 $G(z)$ 属于高维数据范畴, 以卷积神经网络为结构的 D 可以在不同的卷积层提取到一系列不同维度特征, 因此为了进一步强化生成器能力, 使得 G 不仅要关注于高度抽象特征, 更要关注到不同卷积层提取的数据特征, 进而放大数据间的差异性, D 不同层提取的数据特征以 L1 正则化形式添加到 L_G , 其具体公式定义为

$$L_G^1 = \sum_{\varsigma=1}^d \mathbb{E}_{x \sim p_x, z \sim p_z} \|D_{\varsigma}^{\vartheta}(x|z) - D_{\varsigma}^{\vartheta}(G(z))\|_1 \quad (9)$$

其中, ϑ 表示参与到损失函数中的具体判别器卷积层编号. 选择具体卷积层时, 既要考虑数据特征差异性, 又要尽量使得提取的特征包含更多隐含信息, 尽可能从高维和低维两个不同角度对数据属性进行差异性分析.

对于物理属性来说, 最为直观的体现就是系统的整体潮流特性并且该特性可以用数据的统计量进

行表示. 本文选取反映系统整体变化趋势的样本协方差矩阵谱分布来分析生成样本 $G(z)$ 的物理属性, 并利用 JS 散度描述与真实样本 x 差距, 其表达式为

$$L_G^2 = \frac{1}{2} \sum \frac{2\tilde{p}_x \ln \tilde{p}_x}{\tilde{p}_x + \tilde{p}_z} + \frac{1}{2} \sum \frac{2\tilde{p}_z \ln \tilde{p}_z}{\tilde{p}_x + \tilde{p}_z} \quad (10)$$

其中, $\tilde{p}_z$ 和 $\tilde{p}_x$ 分别为生成样本 $G(z)$ 和真实样本 x 的样本协方差矩阵谱分布.

综上, 本文提出多属性融合的生成器损失函数 L_G 为

$$L_G = \mathbb{E}_{z \sim p_z} [1 - \ln D(G(z))] + \lambda_1 \times L_G^1 + \lambda_2 \times L_G^2 \quad (11)$$

其中, λ_1 和 λ_2 为损失函数权重, 用于控制不同属性在损失函数中的作用.

针对 D 的损失函数依然采用如式 (5) 所示的形式, 其中标签 c 为生成器的输入样本 z . 并且 D 的输入为 $x+z$ 和 $G(z)+z$ 的组合形式, 直接将对应数据按照通道拼接在一起进行分析.

2.2 系统状态判断

GAN 大多数研究都集中于对生成器 G 的改进和应用扩展, 然而作为 GAN 的另一组成部分的判别器 D 同样值得关注. 根据 D 的功能及相关卷积神经网络结构可知, D 能够通过提取的特征判断出不同样本来源. 此外, 根据卷积原理可知, 初始卷积层得到的数据特征能够体现数据整体性变化, 随着卷积层的不断深入, 数据的特征趋于高度抽象化, 反映出数据内在的隐含数据特征. 因此为了从数据特征不同层面考虑能源数据发生的变化, 在不丢失数据变化趋势信息基础上, 选取 D 首层卷积层提取的特征作为浅层特征; 此外, 充分考虑提取的特征需要体现数据不同部分变化情况, 因此将 D 倒数第二层卷积层提取的特征作为深层特征, 通过将浅层特征和深层特征进行融合判断, 实现系统运行状态分析. 基于特征融合判断的系统状态判断方法如图 2 所示.

如图 2 所示, 针对浅层特征, 由于其能够反映数据整体性变化, 所以采用 JS 散度对其进行变化判断, 其具体过程为: 首先选取 ζ 个能够描述数据不同部分的浅层特征 P_i , $i = 1, 2, \dots, \zeta$; 接着将 P_i 按照列顺序依次排列特征元素 p , 使其形成一维行向量 $\hat{p}_i$; 然后通过拟合得到 $\hat{p}_i$ 的拟合曲线 $\phi(\hat{p}_i)$ 并将其作为特征分布; 最后通过对不同时刻的特征分布 $\phi(\hat{p}_i^t)$ 和 $\phi(\hat{p}_i^{\bar{t}})$ 采用 JS 散度进行分布差异性的判断并满足预先设定的阈值 θ , 即满足下式时, 表明 $\bar{t}$ 时刻的浅层特征 P_i 存在差异性.

$$\Xi_i^1 = \text{JS}(\phi(\hat{p}_i^t) \parallel \phi(\hat{p}_i^{\bar{t}})) \geq \theta \quad (12)$$




图2 系统状态判断方法

Fig.2 Operation state judgement method

针对深层特征, 由于其小尺寸维度内包含着高度抽象化信息, 所以采用欧几里得距离进行分析, 其过程描述为: 首先等间距选取 ϖ 个深层特征 Q_j , $j = 1, 2, \dots, \varpi$; 接着将 Q_j 按照列顺序依次排列特征元素 q , 使其形成一维行向量 $\hat{p}_j$; 然后通过对不同时刻的 $\hat{p}_j^t$ 和 $\hat{p}_j^{\check{t}}$ 采用欧几里得距离得到数据间的差异性; 最后当满足预先设定的阈值 σ , 即满足下式时, 表明 $\check{t}$ 时刻的深层特征 Q_i 存在差异性.

$$\Xi_j^2 = \text{Euclidean}(\hat{q}_j^t, \hat{q}_j^{\check{t}}) \geq \sigma \quad (13)$$

综上, 当浅层和深层特征同时满足式 (14) 时, 即超过阈值的特征数量大于设定的数目时, 则认为

$\check{t}$ 时刻系统运行状态发生了变化.

$$\begin{cases} \sum_{i=1}^{\varsigma} \Xi_i^1 > [\rho \times \zeta] \\ \sum_{i=1}^{\varpi} \Xi_i^2 > [\rho \times \varpi] \end{cases} \quad (14)$$

其中, $\rho \in (0, 1]$, $[\cdot]$ 为向上取整符号.

2.3 状态分析流程

综上所述, 本文提出的方法流程如图3所示. 在训练阶段, 首先通过综合能源系统获取海量数据, 然后在 G 补偿缺失数据的基础上, 通过输入生成数据及完备数据到 D 中得到对应补偿情况评价, 接着将评价结果进一步返回到 G , 促使其生成更好的结果, 从而实现一次完整的训练过程. 经过一系列上述零和博弈的训练过程后, 最终得到训练好的 GAN. 在分析阶段, 首先判断获取的异构能源数据缺失情况, 如果数据存在缺失则将输入数据送入到训练好的 G 中实现数据补偿过程, 进而得到完备能源数据; 在保证数据完整性基础上, 将所得的数据通过 D 提取到不同时刻的能源数据特征, 再经过相应分析过程得到最终系统运行状态分析结果.

3 仿真研究与分析

3.1 仿真设置

在本文中, 为了证明本文所提方法的有效性, 采用 IEEE33 节点、天然气 20 节点及热力 32 节点




图3 状态分析方法流程图

Fig.3 Flowchart of operation state analysis method

构建的综合能源系统进行仿真, 其网络拓扑结构及耦合设备连接如图 4 所示, 同时选取电力系统节点电压 v 、天然气系统节点气压 Π 及热力系统管道质量流 m 为相应系统测量值进行研究, 从而使得系统节点与测量变量间形成一一对应的关系. 并且本节方法的仿真运行环境为 Intel Xeon(R) E5-2 640 2.4 GHz CPU, 运行内存为 160 GB, 采用 NVIDIA 的 GPU 显卡 Titan X(Pascal) 对 tensorflow 程序进行深度加速训练.

本文仿真参数为: $\hat{w} = \tilde{w} = \tilde{f} = 85, l = 180, \chi = 2$. 并且设置 $r = 50$, 使得归一化过程中的 $\lg |\Delta M^t|$ 内的元素在已有基础上整体增加 50. 为了均衡数据及物理属性对生成器损失函数的影响, 设置 $\lambda_1 = \lambda_2 = 10$, 并且根据实验结果设置 $\theta = 0.1, \varpi = 1, \rho = 0.7$. 针对 GAN, G 的步长均为 2, 采用 5 个卷积层和相应的反卷积层, 其中卷积核大小依次为 $3 \times 4, 3 \times 3, 4 \times 3, 3 \times 3$ 及 4×4 , 激活函数采用 ReLu 函数, 最后采用卷积核为 4×4 , 激活函数为 tanh 函数实现样本生成; 根据生成器卷积核参数可知, 生成器编码过程的维度变化情况是: $43 \times 90, 22 \times 45, 11 \times 23, 6 \times 12$ 以及 3×6 , 其对应的解码过程数据维度变化为: $6 \times 12, 11 \times 23, 22 \times 45, 43 \times 90$ 及 85×180 . 判别器 D 采用 6 层卷积神经网络构建, 卷积核为 $10 \times 20, 4 \times 5, 3 \times 5, 4 \times 4, 4 \times 4$ 及 4×4 , 除最后一层采用 sigmoid 函数以外, 其余均采用 Leaky

ReLU 函数, 同时只有第 1 层的步长为 1, 其余卷积核的步长为 2. 根据第 2.1.3 节所述判别器卷积层选取原则, 第 2 层和第 4 层卷积层兼顾了数据特征差异性和隐含信息两方面, 因此 $\vartheta = \{2, 4\}$. 批次大小为 1, 采用 Adam 优化器进行 GAN 网络参数训练, 初始学习率为 0.0002, $\beta_1 = 0.5$, 最大迭代次数为 12000 次.

在构建样本集的过程中, 首先通过调整节点需求变化, 生成不同情况下的系统数据, 从而得到 4600 个不同数据样本作为数据来源; 为了能够更好地比较补偿效果, 体现补偿数据与真实数据间的差距并且考虑到不同节点、不同缺失数量的情况, 接着对得到的 4600 个数据样本的不同节点数据进行随机性删除, 并且将该部分数据设置为 0, 也就是说将节点缺失数据用 0 替换保持数据维度不变, 并且替换的长度在 20~50 之间; 经过处理后, 存在数值为 0 的节点数据即可认为是运行过程中出现的缺失数据. 将原始仿真得到的系统数据和修改后的数据一一对应构成数据对, 相应的 4600 个数据样本对即为构建的样本集, 从而用于所提方法的训练和验证, 其中随机选取 3680 个不同类型样本作为训练样本, 其余样本为测试样本.

3.2 数据补偿结果

为了衡量数据补偿效果, 本文采用平均绝对误




图 4 综合能源系统结构图
Fig. 4 Integrated energy system structure

差 (Mean absolute error, MAE)、均方误差 (Mean squared error, MSE) 及平均百分比误差 (Mean percentage error, MPE) 三个不同的指标进行分析. 其中, MAE 反映了补偿值误差的实际情况, MSE 体现了数据的变化程度, MPE 则表明补偿值与真实值间的偏离程度. 同时本节从缺失数据补偿有效性、多节点数据缺失补偿及与不同方法比较三个方面进行了分析, 结果表明所提方法实现缺失补偿的有效性.

首先, 假设电节点 15 网络通信传输存在问题, 在电力系统节点 17 负荷变化下通过相邻数据对缺失数据进行补偿, 并以此对所提方法有效性进行分析. 如图 5 所示, 图 5(a) 和 (c) 分别展示了电节点 15 电压幅值间断缺失及持续缺失两种不同的情况, 纵坐标为电压幅值, 图 5(b) 和 (d) 为相应数据补偿结果及原始真实数据. 并且从输入输出关系出发, 图 5(a) 和 (b) 分别为电节点 15 数据间断缺失情况及通过本文所提方法得到的数据补偿情况. 从直观

上看, 补偿数据和原始数据有很高的相似度并且部分数据可以基本实现重合. 从统计指标上看, 图 5(b) 补偿结果的 MAE、MSE 及 MPE 分别为 1.4819×10^{-5} , 1.4881×10^{-5} 及 1.4016×10^{-5} ; 图 5(d) 补偿结果的 MAE、MSE 及 MPE 分别为 1.5338×10^{-5} , 1.6544×10^{-5} 及 1.4600×10^{-5} . 综合上述曲线展示及统计指标可知, 对于不同情况的单一节点数据缺失情况, 提出的方法均能够较好地实现缺失数据补偿.

接着, 针对于在缺失数据的个数、缺失数据数量及缺失时刻方面, 与单一节点缺失补偿不同的多节点数据补偿问题进行分析. 假设在含电转气设备的节点 8 发生变化过程中, 如图 6(a), (c), (e) 所示, 电节点 9、12 及气节点 7 三个两种类型的节点数据在采样时刻 41 ~ 70 及 111 ~ 130 存在缺失情况. 经过训练好的生成器 G 得到的对应节点缺失数据补偿的结果呈现在图 6(b), (d), (f) 中. 从图中可以看到, 对于数据突变处, 补偿数据均能够较好地得到




图 5 电节点 15 数据缺失补偿曲线

Fig.5 Data imputation curves of electricity node 15




图6 多节点数据缺失补偿曲线

Fig.6 Multi-node data imputation curves

与原始数据相似的变化情况,当数据变化趋于稳定即数据变为随机变化时,不同节点的补偿效果存在一定的误差.三个节点的统计指标结果如表1所示.通过表1可知,三个节点的补偿效果没有明显的差异性,不会因为节点类型的差异而导致补偿效果存在差别.同时与图5所得结果相比较可得,多节点数据

补偿效果与单节点基本相同,所提方法的补偿效果不会因为多节点的缺失情况而影响补偿效果.通过上述单/多节点数据补偿结果可知,在缺失数据与前后部分数据变化接近时,可以采用前后数据加权平均后加少量噪声的方法对缺失数据进行补偿.但是当发生如图6所示数据突变或数据变化情况未知

表 1 多节点数据缺失补偿结果 ($\times 10^{-5}$)
Table 1 Multi-node data imputation results ($\times 10^{-5}$)

补偿节点	MAE	MSE	MPE
电节点9	1.4852	1.4948	1.4136
电节点12	1.5093	1.5188	1.4418
气节点7	1.5250	1.5362	2.1993

时,通过直接数据拟合方法无法实现数据补偿.于此方法不同的是,本文所提方法采用生成对抗网络实现,通过大量数据训练后可以根据数据间变化关联性进行数据补偿,在避免建立复杂数学模型的同时完成缺失数据的补偿.

进一步为了讨论本文所提方法对于不同节点数量缺失情况的补偿效果,选取节点数量缺失情况分别为 1, 3, 5, 7, 9 的五种情况进行研究,具体结果如表 2 所示.

表 2 不同数量的缺失数据补偿结果 ($\times 10^{-5}$)
Table 2 Imputation results of different numbers of missing data ($\times 10^{-5}$)

缺失数量	MAE	MSE	MPE
1	1.5022	1.4926	1.5008
3	1.5190	1.5205	1.5063
5	1.5183	1.5194	1.5253
7	1.5852	1.5933	1.5757
9	1.6232	1.6201	1.6193

根据表 2 可知,当系统内节点数量缺失少于 5 时,生成器对于缺失数据的补偿效果基本相同,但是随着缺失数量的增加,输入数据的缺失部分也越来越多,使得输入到生成器中的完整测量变量的数量也越来越少,神经网络无法提取到充足的数据特征,因此相应的性能指标也随之变差.但是从整体效果来看,所提方法仍然能够对缺失数据进行相应地补偿.

最后,为了进一步表明所提方法在数据补偿方面的有效性,本文采用五种不同的深度学习方法进行比较,并且相应的结构为: 1) 作为回归模型, CNN 采用 6 层卷积自编码基本结构实现数据补偿; 2) DAE 方法与 CNN 具有相同的结构,但不同的是将自编码网络结构分为 2-2-2 的形式,采用分层更新迭代-微调训练的方式进行,最后通过训练好的编码网络完成数据补偿; 3) DCGAN 采用不含跳跃连接的编码器-解码器结构的生成器,并且判别器中添加一层全连接层实现特征拼接; 4) DCGAN-L1 在 DCGAN 的基础上,增加 L1 正则化损失函数到原有生成器损失函数中; 5) Pix2Pix 方法除了损

失函数以外,网络结构与本文所提方法相同.在相同训练环境下,不同方法的补偿结果如表 3 所示.

表 3 不同方法补偿结果对比 ($\times 10^{-5}$)
Table 3 Comparison of different data imputation methods ($\times 10^{-5}$)

补偿方法	MAE	MSE	MPE
CNN	2.3248	2.3003	2.2741
DAE	2.2428	2.1892	2.1505
DCGAN	1.9255	1.8864	1.8469
DCGAN-L1	1.8421	1.7605	1.7844
Pix2Pix	1.7274	1.6148	1.6303
本文方法	1.5934	1.4835	1.4492

从表 3 中可以看出,本文所提方法均优于其余五种不同类型的方法.由于 CNN 与 DAE 采用相同的结构,所以对应结果差别不大,但是由于 DAE 采用逐层训练及反复微调网络参数的方式,比 CNN 参数调整更为精细,因此效果比 CNN 好.其余四种数据补偿方法由于判别器的加入,可以更好地捕捉到数据间的差异性并且促使生成器进行参数调整,进一步提高了数据补偿能力.与 DCGAN 所得结果相比较可知,在相同结构情况下, L1 正则化损失函数能够使得生成对抗网络的数据补偿结果更接近于真实值.相较于 DCGAN、DCGAN-L1 及 Pix2Pix 方法来说,本文所提方法进行了生成器输入数据的优化排序改进,使得变化相似的数据放在一起进行数据特征提取,数据特征相似性最大化;另外,生成器损失函数方面,除原始损失函数以外,增加了以判别器提取的不同卷积层数据特征为核心的 L1 正则化形式的损失函数表征数据属性,并且根据数据本身存在的物理属性,通过样本协方差矩阵谱分布进一步描述生成样本与真实样本间的差距,因此更为适应于能源缺失数据变化特点,使得补偿效果优于其他数据补偿方法.

3.3 状态判断结果

为了表明第 2.2 节提出方法对状态判断的有效性,本节从电节点及热节点两个不同类型的能源变化为例进行研究.通过对判别器提取的特征进行统一性分析,依照浅层特征反映整体性变化趋势要求,选取第 1, 23, 46 及 59 个判别器首层提取的特征作为系统状态判断所需的浅层特征,此外第 1, 101, 331 及 481 个判别器倒数第二层卷积层提取的特征作为深层特征.需要说明的是数据特征的数字为相应卷积层根据卷积核提取的数据特征进行顺序编号得到的,并且所选取的数据特征不具有普遍代表性,数据特征的选取可以根据具体情况进行适当调整.

针对电节点变化情况, 选取电节点 21 的有功功率负荷增加 6.16% 为相应未知功率变化事件进行分析^[16]. 如图 7 所示为判别器 D 的输入数据及选取的特征可视化展示结果, 通过对图 7(a) 和图 7(b) 的比较可知, 判别器 D 第 1 层卷积核提取的特征与输入数据存在极高的相似性, 但是随着对特征不断的抽象卷积提取, 到第五层卷积核提取到的特征呈现出高度抽象化情况, 即图 7(c) 所示的深层特征, 并且对图 7(d), (e), (f) 变化情况分析可以得到类似的结果.

接着根据第 2.2 节判断过程, 从数据分布整体性变化趋势的角度出发, 将图 7(b), (e) 所示的浅层特征构建为一维行向量并得到如图 8 所示结果. 进一步, 为避免转化为一维行向量的浅层特征数据变化波动性影响分析结果, 进而采用拟合方法得到相应浅层特征的拟合曲线, 并通过 JS 散度实现浅层特征差异性的表达, 相应浅层特征的 JS 散度依次为 0.1486, 0.1245, 0.1441, 0.1129, 超过了设定的阈




图 7 电节点 21 变化前后系统数据及特征

Fig.7 IES data and features change of electricity node 21




图 8 电节点 21 变化前后系统浅层特征分布曲线

Fig.8 Data distribution change of shallow features for electricity node 21

值 0.1, 对于图 7(c), (f) 所示的深层特征进行欧几里得距离的分析, 并得到相应结果为 1.9766, 0.9795, 2.3763, 2.6861, 最后通过式 (12) ~ (14) 的判断得到系统运行状态发生变化。

类似地, 对热节点 18 增加其对应的热需求至原有需求的 104.2%, 并得到图 9 所示的系统数据及对应的浅层、深层特征。进一步, 对浅层特征进行维度变换、拟合及特征分布计算等操作得到如图 10 所示的对应结果, 进一步得到 JS 散度为 0.1092, 0.1085, 0.1110, 0.1034。根据第 3.1 节设定的 θ 参数可知, 选取的浅层特征分布均满足式 (12), 即浅层特征存在差异性。通过对变化前后系统深层特征计算欧几里得距离并与设定的阈值 1 相比较可知, 选取的深层特征的欧几里得距离 (2.0742, 1.3195, 2.4701, 2.1099) 均大于阈值 1, 符合式 (13) 的要求。综合浅层特征、深层特征差异性并通过式 (14) 判断, 最终得到系统运行状态发生改变。

为了进一步研究第 2.2 节所提方法对不同电、




图 9 热节点 18 变化前后系统数据及特征

Fig.9 IES data and features change of heat node 18




图 10 热节点 18 变化前后系统浅层特征分布曲线

Fig.10 Data distribution change of shallow features for heat node 18

热节点需求变化情况的判断, 在增加电节点 17 及热节点 30 进行分析的基础上, 选取节点需求变化范围为 (0, 5%), 并且将其分为 5 等份, 在不同节点需求变化范围内, 选取 10 个不同需求变化情况进行判断, 得到的状态判断结果如表 4 所示。

表 4 不同节点的状态判断结果 (%)

Table 4 State judgment results of different nodes (%)

变化节点	(0, 1%)	(1%, 2%)	(2%, 3%)	(3%, 4%)	(4%, 5%)
电节点17	0	60	100	100	100
电节点21	0	70	100	100	100
热节点18	0	70	100	100	100
热节点30	0	70	100	100	100

根据表 4 可知, 当热电需求变化不剧烈时, 会导致测量数据的幅值变化也会减小, 从而导致 D 提取的深层特征和浅层特征的差异性不大; 在节点需求变化处于 (0, 1%) 时, 不能满足预先设定的系统状态变化的判断条件, 因此无法识别出系统状态的改变情况; 随着热电需求变化的逐渐增加, 数据的变化程度也越来越剧烈, 因此当节点需求变化大于 2% 时, 通过式 (14) 对浅层和深层特征的融合判断, 可以准确得到系统状态变化的结果。

综合上述两个不同类型节点变化分析过程可知, 在提取特征并融合不同特征变化情况下, 本文提出的方法可以在热电需求变化剧烈时准确地判断出状态改变情况。

4 结论


针对综合能源系统存在的节点变化引起的状态改变检测问题, 本文提出了一种基于关联信息对抗学习的运行状态分析方法。首先采用构建的深度生成对抗网络的生成器实现缺失数据的补偿, 通过系统邻接矩阵实现输入数据按照关联度排序, 增强相邻输入数据间相似程度; 再通过设计的多属性融合生成器损失函数, 进一步提高了数据补偿的精度。接着采用判别器网络复用的方式, 通过训练好的判别器提取能源数据的抽象特征, 然后采用 JS 散度及欧几里得距离衡量不同时刻能源数据特征的差异性并以此为依据得到系统运行状态。最后通过对电-气-热综合能源系统不同类型节点的变化情况进行仿真分析, 结果表明与其他补偿算法相比, 本文提出的方法能够更好地反映和补偿数据缺失部分, 并且采用判别器提取的特征可以有效地检测出节点变化, 最终得到系统运行状态。在接下来研究中, 将进一步针对输入数据存在未知量下的缺失数据补偿

进行分析, 同时找寻出能够准确表征节点微弱需求变化的特征及相应指标, 从而完成热电需求变化不剧烈下的系统状态判断并实现在线应用。

References

- 1 Sun Qiu-Ye, Teng Fei, Zhang Hua-Guang. Energy internet and its key control issues. *Acta Automatica Sinica*, 2017, **42**(2): 176-194
(孙秋野, 滕菲, 张化光. 能源互联网及其关键控制问题. *自动化学报*, 2017, **42**(2): 176-194)
- 2 Heinen S, Burke D, O'Malley M. Electricity, gas, heat integration via residential hybrid heating technologies — an investment model assessment. *Energy*, 2016, **109**: 906-919
- 3 Sun H B, Guo Q L, Zhang B M, Wu W C, Wang B, Shen X W, Wang J H. Integrated energy management system: concept, design, and demonstration in China. *IEEE Electrification Magazine*, 2018, **6**(2): 42-40
- 4 Hibbard P J, Schatzki T. The interdependence of electricity and natural gas: Current factors and future prospects. *Electricity Journal*, 2012, **25**(4): 6-17
- 5 Fairley P. The troubled link between gas and electricity grids. *IEEE Spectrum*, 2016, **53**(6): 11-12
- 6 Wang Ping, Wang Yao. Taiwan power failure “pot” who will carry. *Cross-Strait Relations*, 2017, (9): 30-30
(王平, 王尧. 台湾大停电的“锅”谁来背. 两岸关系, 2017, (9): 30-30)
- 7 Augutis J, Krikštolaitis R, Martišauskas L, Pečiulytė S, Zutaaitė I. Integrated energy security assessment. *Energy*, 2017, **109**: 890-901
- 8 Wang D, Liu L, Jia H J, Wang W L, Zhi Y Q, Meng Z J, Zhou B Y. Review of key problems related to integrated energy distribution systems. *CSEE Journal of Power and Energy Systems*, 2018, **4**(2): 130-145
- 9 Chen Sheng, Wei Zhi-Nong, Sun Guo-Qing, Wang Dan, Zang Hai-Yang. Review on security analysis and optimal control of electricity-gas integrated energy system. *Electric Power Automation Equipment*, 2019, **39**(8): 3-11
(陈胜, 卫志农, 孙国强, 王丹, 臧海祥. 电-气互联综合能源系统安全分析与优化控制研究综述. *电力自动化设备*, 2019, **39**(8): 3-11)
- 10 Dong Jin-Ni, Sun Hong-Bin, Guo Qing-Lai, Sheng Tong-Tian, Qiao Zheng. State estimation of combined electric-gas networks for energy internet. *Power System Technology*, 2018, **42**(2): 400-408
(董今妮, 孙宏斌, 郭庆来, 盛同天, 乔铮. 面向能源互联网的电-气耦合网络状态估计技术. *电网技术*, 2018, **42**(2): 400-408)
- 11 Chen Yan-Bo, Zheng Shun-Lin, Yang Ning, Yang Xiao-Nan, Liu Kai-Cheng. Robust state estimation of electric-gas integrated energy system based on weighted least absolute value. *Automation of Electric Power Systems*, 2019, **43**(13): 61-74
(陈艳波, 郑顺林, 杨宁, 杨晓楠, 刘铠诚. 基于加权最小绝对值的电-气综合能源系统抗差状态估计. *电力系统自动化*, 2019, **43**(13): 61-74)
- 12 Du Y X, Zhang W, Zhang T T. ADMM-based distributed state estimation for integrated energy system. *CSEE Journal of Power and Energy Systems*, 2019, **5**(2): 275-283
- 13 Liu Y B, Su Y C, Xiang Y, Liu J Y, Wang L F, Xu W T. Operational reliability assessment for gas-electric integrated distribu-

- tion feeders. *IEEE Transactions on Smart Grid*, 2019, **10**(1): 1091–1100
- 14 Zhou K L, Fu C, Yang S L. Big data driven smart energy management: from big data to big insights. *Renewable and Sustainable Energy Reviews*, 2016, **56**: 215–225
 - 15 Sun Qiu-Ye, Yang Ling-Xiao, Zhang Hua-Guang. Smart energy-applications and prospects of artificial intelligence technology in power system. *Control and Decision*, 2018, **33**(5): 938–949 (孙秋野, 杨凌霄, 张化光. 智慧能源—人工智能技术在电力系统中的应用与展望. *控制与决策*, 2018, **33**(5): 938–949)
 - 16 He X, Qiu R C, Chu L, Ai Q, Ling Z N, Zhang J. Invisible units detection and estimation based on random matrix theory. *IEEE Transactions on Power Systems*, 2020, **35**(3): 1846–1855
 - 17 Huang T E, Guo Q L, Sun H B, Tan C W, Hu T Y. A deep spatial-temporal data-driven approach considering microclimates for power system security assessment. *Applied Energy*, 2019, **237**: 36–48
 - 18 Li M S, Deng W M, Xiahou K S, Ji T Y, Wu Q H. A data-driven method for fault detection and isolation of the integrated energy-based district heating system. *IEEE Access*, 2020, **8**: 23787–23801
 - 19 Liu J H, Qu F M, Hong X W, Zhang H G. A small-sample wind turbine fault detection method with synthetic fault data using generative adversarial nets. *IEEE Transactions on Industrial Informatics*, 2019, **15**(7): 3877–3888
 - 20 Shi X, Qiu R, Mi T B, He X, Zhu Y L. Adversarial feature learning of online monitoring data for operational risk assessment in distribution networks. *IEEE Transactions on Power Systems*, 2020, **35**(2): 975–985
 - 21 Ghahramani Z. Supervised learning from incomplete data via an EM approach. *Advances in Neural Information Processing Systems*, 1984, **6**: 120–127
 - 22 Xie K, Wang X, Liu X L, Wen J G, Cao J N. Interference-aware cooperative communication in multi-radio multi-channel wireless networks. *IEEE Transactions on Computers*, 2016, **65**(5): 1528–1542
 - 23 Chen H B, Grant-Muller S, Mussone L, Montgomery F. A study of hybrid neural network approaches and the effects of missing data on traffic forecasting. *Neural Computing and Applications*, 2001, **10**(3): 277–286
 - 24 Jaques N, Taylor S, Sano A, Picard R. Multimodal autoencoder: a deep learning approach to filling in missing sensor data and enabling better mood prediction. In: *Proceedings of the 2017 International Conference on Affective Computing and Intelligent Interaction*, San Antonio, TX, USA: IEEE, 2017. 202–208
 - 25 Zhuang Y F, Ke R M, Wang Y H. Innovative method for traffic data imputation based on convolutional neural network. *IET Intelligent Transport Systems*, 2019, **13**(4): 605–613
 - 26 Wang Shou-Xiang, Chen Hai-Wen, Pan Zhi-Xin, Wang Jian-Ming. A reconstruction method for missing data in power system measurement using an improved generative adversarial network. *Proceedings of the CSEE*, 2019, **39**(1): 56–64 (王守相, 陈海文, 潘志新, 王健明. 采用改进生成式对抗网络的电力系统量测缺失数据重建方法. *中国电机工程学报*, 2019, **39**(1): 56–64)
 - 27 Ren C, Xu Y. A fully data-driven method based on generative adversarial networks for power system dynamic security assessment with missing data. *IEEE Transactions on Power Systems*, 2019, **34**(6): 5044–5052
 - 28 Li Y C, Wang Y Y, Hu S Y. Online generative adversary network based measurement recovery in false data injection attacks: A cyber-physical approach. *IEEE Transactions on Industrial Informatics*, 2020, **16**(3): 2031–2043
 - 29 Qu F M, Liu J H, Ma Y J, Zang D, Fu M R. A novel wind turbine data imputation method with multiple optimizations based on GANs. *Mechanical Systems and Signal Processing*, 2020, **139**: Article 106610
 - 30 Goodfellow I J, Pougetabadi J, Mirza M. Generative adversarial networks. *Advances in Neural Information Processing Systems*, 2014, **3**: 2672–2680
 - 31 Wang Kun-Feng, Gou Chao, Duan Yan-Jie, Lin Yi-Lun, Zheng Xin-Hu, Wang Fei-Yue. Generative adversarial networks: The state of the art and beyond. *Acta Automatica Sinica*, 2017, **43**(3): 321–332 (王坤峰, 苟超, 段艳杰, 林懿伦, 郑心湖, 王飞跃. 生成式对抗网络 GAN 的研究进展与展望. *自动化学报*, 2017, **43**(3): 321–332)
 - 32 Liu Jian-Wei, Xie Hao-Jie, Luo Xiong-Lin. Research progress on application of generative adversarial networks in various fields. *Acta Automatica Sinica*, 2020, DOI: [10.16383/j.aas.c180831](https://doi.org/10.16383/j.aas.c180831) (刘建伟, 谢浩杰, 罗雄麟. 生成对抗网络在各领域应用研究进展. *自动化学报*, 2020, DOI: [10.16383/j.aas.c180831](https://doi.org/10.16383/j.aas.c180831))
 - 33 Sun Qiu-Ye, Hu Jing-Wei, Yang Ling-Xiao, Zhang Hua-Guang. We-energy hybrid modeling and parameter identification with GAN technology. *Acta Automatica Sinica*, 2018, **44**(5): 901–914 (孙秋野, 胡旌伟, 杨凌霄, 张化光. 基于 GAN 技术的自能混建建模与参数辨识方法. *自动化学报*, 2018, **44**(5): 901–914)
 - 34 Mirza M, Osindero S. Conditional generative adversarial nets. arXiv preprint arXiv: 1411.1784, 2014.
 - 35 Isola P, Zhu J Y, Zhou T H, Efros A A. Image-to-image translation with conditional adversarial networks. In: *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*, 2017. 1125–1134
 - 36 Huang Yu-Jia, Sun Qiu-Ye, Wang Rui, Huang Bo-Nan. Static voltage stability analysis for integrated energy system. *Proceedings of the CSEE*, 2019, **39**(s): 44–53 (黄雨佳, 孙秋野, 王睿, 黄博南. 面向综合能源系统的静态电压稳定性分析. *中国电机工程学报*, 2019, **39**(s): 44–53)
 - 37 Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In: *Proceedings of the 2015 International Conference on Medical Image Computing and Computer-assisted Intervention*. Springer, Cham, 2015. 234–241



胡旭光 东北大学信息科学与工程学院博士研究生. 主要研究方向为基于数据驱动的故障诊断, 信息物理系统的建模及优化控制.

E-mail: 1710252@stu.neu.edu.cn

(**HU Xu-Guang** Ph.D. candidate at the College of Information Science and Engineering, Northeastern University. His research interest covers fault diagnosis based on data-driven, modeling and optimal control of cyber-physical system.)




马大中 东北大学信息科学与工程学院副教授. 主要研究方向为故障诊断, 容错控制, 能源管理系统以及分布式发电系统、微网和能源互联网的优化与控制. 本文通信作者.

E-mail: madazhong@ise.neu.edu.cn

(**MA Da-Zhong** Associate professor

at the College of Information Science and Engineering, Northeastern University. His research interest covers fault diagnosis, fault-tolerant control, energy management systems, and control and optimization of distributed generation systems, microgrids and energy internet. Corresponding author of this paper.)



郑 君 东北大学信息科学与工程学院硕士研究生. 主要研究方向为基于机器学习的综合能源系统故障检测与诊断.

E-mail: zj623928036@163.com

(**ZHENG Jun** Master student at the College of Information Science

and Engineering, Northeastern University. His research interest covers fault detection and diagnosis of integrated energy system based on machine learning.)



张化光 东北大学信息科学与工程学院教授. 主要研究方向为自适应动态规划, 模糊控制, 网络控制, 混沌控制. E-mail: hgzhang@ieee.org

(**ZHANG Hua-Guang** Professor at the College of Information Science and Engineering, Northeastern Uni-

versity. His research interest covers adaptive dynamic programming, fuzzy control, network control, and chaos control.)



王 睿 东北大学信息科学与工程学院博士研究生. 2016 年于东北大学获得电气工程及其自动化专业学士学位. 主要研究方向为能源互联网中分布式电源的协同优化及其电磁时间尺度稳定性分析.

E-mail: 1610232@stu.neu.edu.cn

(**WANG Rui** Ph.D. candidate at the College of Information Science and Engineering, Northeastern University. He received his B.S. degree in electrical engineering and automation from Northeastern University in 2016. His research interest covers collaborative optimization of distributed generation and its stability analysis of electromagnetic timescale in energy internet.)