

基于 GAN 技术的自能源混合建模与参数辨识方法

孙秋野¹ 胡旌伟¹ 杨凌霄¹ 张化光¹

摘 要 自能源 (We-energy, WE) 作为能源互联网的子单元旨在实现能量间的双向传输及灵活转换. 由于自能源在不同工况下运行特性存在很大差异, 现有方法还不能对其参数精确地辨识. 为了解决上述问题, 本文根据自能源网络结构提出了一种基于 GAN 技术的数据-机理混合驱动方法对自能源模型参数辨识. 将 GAN (Generative adversarial networks) 模型中训练数据与专家经验结合进行模糊分类, 解决了自能源在不同运行工况下的模型切换问题. 通过应用含策略梯度反馈的改进 GAN 技术对模型进行训练, 解决了自能源中输出序列离散的问题. 仿真结果表明, 提出的模型具有较高的辨识精度和更好的推广性, 能有效地拟合系统不同工况下各节点的状态变化.

关键词 能源互联网, 自能源, 生成式对抗网络, 生成式模型, 对抗学习, 零和博弈

引用格式 孙秋野, 胡旌伟, 杨凌霄, 张化光. 基于 GAN 技术的自能源混合建模与参数辨识方法. 自动化学报, 2018, 44(5): 901–914

DOI 10.16383/j.aas.2018.c170487

We-energy Hybrid Modeling and Parameter Identification With GAN Technology

SUN Qiu-Ye¹ HU Jing-Wei¹ YANG Ling-Xiao¹ ZHANG Hua-Guang¹

Abstract As a sub-unit of the energy internet, we-energy (WE) aims at realizing bi-directional power transformation and flexible conversion between various types of energies. As the operating characteristics of WE have large difference under different working conditions, existing methods can not accurately identify its parameters. In order to solve this problem, a data-mechanism hybrid driving method based on generative adversarial networks (GAN) is proposed. In order to switch the WE model under different operating conditions, fuzzy theory is used to achieve fuzzy classification of training data of the GAN model by expertise. A modified GAN model containing policy gradient feedback is applied in training model, therefore solving the issue of discrete output sequence of WE. Simulation results validate that the proposed model is of high identification accuracy and has better generalization performance, and can effectively fit the state variation of each node of the whole system under different operation modes.

Key words Energy internet, we-energy (WE), generative adversarial networks (GAN), generative model, adversarial learning, zero-sum game

Citation 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

能源互联网是一个由电力网络、热力网络及天然气网络等能源网络集成交互形成的复杂网络, 以能源技术与先进控制技术、智能优化技术及信息处理技术等为实施手段的一种新型开放式能源生态系统, 可实现可再生能源的高效利用, 提高可再生能源在一次能源生产和消费中的占比^[1–2]. 自能源作为

能源互联网的子单元, 是由多种能源网络耦合而成的小型独立能源系统, 这些小型能源系统通过能源端口相互连接形成能源互联网^[3]. 随着能源互联网在世界各国的逐步推进, 能源互联网建模的准确性直接影响着能源系统运行的安全性、稳定性及经济性. 目前, 按照模型的驱动类型可把系统建模方法分为两类.

一类是基于机理驱动的系统建模方法, 在以往的研究中, 国内外学者已对电网、直供热管网及天然气的机理建模做出了大量工作. 在电力系统中, 由静态负荷及感应电动机负荷组成的混合负荷模型最受关注, Son 等提出了一种基于参数测量的负载建模优化方案^[4], 通过对混合负荷模型参数的敏感性分析, 减少了需要考虑的参数数量, 从而改进了参数优化性能. Kim 等利用识别参数敏感度相似性的

收稿日期 2017-08-31 录用日期 2018-03-07

Manuscript received August 31, 2017; accepted March 7, 2018
国家自然科学基金重点项目 (61433004), 国家自然科学基金 (61573094), 中央高校基础科研业务费 (N140402001) 资助

Supported by the Key Program of National Natural Science Foundation of China (61433004), National Natural Science Foundation of China (61573094), and The Central University Based Research Fees (N140402001)

本文责任编辑 谭莹

Recommended by Associate Editor TAN Ying

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

方法来估计混合负荷模型参数^[5], 由于一些参数的变化对模型的输出会产生相似的影响, 因此在优化过程中这些相似的参数可以同时被调整. 而在直供热管网中, 由于管网中状态变量(温度、压强、流速)不仅随管道距离变化而改变, 同时还是时间的函数, 供热系统的模型大多是根据质量守恒定律、动量守恒定律及能量守恒定律对管网中微元进行分析而建立的^[6], 因此这类模型并不能从宏观上表现出管道状态变量对模型输出的影响. 在天然气管网中, 由于气体可压缩的特点, 在建模过程中需要考虑理想气体状态方程. Behrooz 等根据质量、动量和能量平衡方程建立天然气管道非等温模型, 利用正交配置法对其动态方程进行求解^[7]. Pambour 等提出了一个集成的瞬态水力模型来描述天然气管网的动态特性^[8], 其模型中包括管道、增压站、减压站、储气站及终端用户.

另一类系统建模方法是基于数据驱动的, 主要分为统计综合法和总体辨识法. 统计综合法采用统计的方式形成系统综合模型, 由于能源网络中原始数据的冗余特性对模型的准确性产生影响, 为了解决这种问题, 聚类方法被采用对能源需求响应数据进行分析^[9-10], Sun 等通过寻找需求响应的内在特性和整合不同的特性来筛选数据冗余^[11]. 总体辨识法将系统作为总体建模拟合实测曲线, 其方法有最小二乘算法、逼近算法和极大似然等^[12-14], 这些传统算法在非线性或非高斯情形下效果并不理想. 近年来, 随着各类智能优化算法的提出, 一些适用于连续系统的新的辨识方法相继被提出, 杨刚等提出一种基于自适应量子粒子群优化的 RBF (Radial basis function) 神经网络结构优化设计方法来实现神经网络结构与参数的同步调整^[15], 钱富才等提出了一种以鲁棒二阶锥规划理论为基础的鲁棒最小二乘算法^[16]. 然而, 无论是统计综合法还是总体辨识法, 系统建模对历史数据的依赖性较大, 能源系统在稳态运行下拥有大量可测数据, 在异常工况下建模获得的数据却较少, 而异常工况下的能源系统模型对系统的运行至关重要. 系统在故障情况下对其检测不准确, 将影响系统运行的稳定性. 传统的建模方法已不能满足要求. 在以往的研究中, 综合预测被广泛应用于建模非线性动态系统的演化, 在线的多任务学习框架^[17]和半监督的多任务学习模型^[18]用来处理系统的综合预测和缺失的标签问题. 然而, 当系统的规模较大时其统计工作和总体辨识就变得过于繁重^[19-20]. 因此, 需要探讨一种更为有效的建模方法以解决模型数据不完备问题.

生成式对抗网络是由 2014 年 Goofellow 等提出的一种生成式模型^[21], 该技术不直接估计数据样本的分布特征, 而是通过模型训练来估测其潜在的

分布特征并产生与真实样本相同分布特性的新样本. 这种依据潜在分布产生“无限”新样本的生成式模型具有较强的可解释性^[22]. GAN (Generative adversarial networks) 技术在图像和视觉计算、语音和语言处理等众多领域建模中均有应用^[23-24], 同时平行智能与平行学习又为 GAN 进一步的发展提出了方向^[25]. 随着国内外学者对 GAN 技术的深入研究, 其结构模型也衍生出了多种变化, 基于不同的散度, GAN 技术可分为 JS-GAN^[21] (JS (Jensen-Shannon) 散度)、LS-GAN^[26] (LS (Loss sensitive) 散度)、W-GAN^[27] (Wasserstein 距离) 和 f-GAN^[28] (f 散度). Qi 提出了一种改进的 Loss-sensitive GAN, 该模型通过使用 Lipschitz 损失函数来限定 GAN 无限建模的能力, 拓展了训练的优化方法^[26]. Arjovsky 等^[27]提出的 Wasserstein GAN 利用 Wasserstein 距离产生的值函数, 在训练过程中不需要一直保持生成器与判别器严格的平衡, 可以通过训练判别器至最优来持续估计 Earth-mover 距离. Saito 等在仿真中对以上几种改进的 GAN 模型与 W-GAN 进行了比较^[29], 结果表明在提高合成语音质量方面 W-GAN 最小化 Earth-mover 距离效果较好. Chen 等提出的 InfoGAN 则在结构上进行了改进^[30], 通过将生成器的输入分为传统模型输入和隐码输入, 将潜在变量的小子集与观察结果之间的互信息最大化.

结合生成式对抗网络所具有的建模能力, 本文提出自能源模型的 GAN 参数辨识方法, 而电、气、热网络的采样周期不同, 生成器所生成的数据为离散序列, 若采用传统建模方法 GAN 技术, 其判别器无法实现对生成器序列的梯度更新. 因此, 本文根据 Yu 等所提 Seq-GAN 模型^[31]解决生成器输出离散的问题, 该模型将 GAN 技术与策略梯度相结合, 把判别器的输出结果作为策略梯度的奖励对生成器进行反馈训练.

本文建立了考虑能源耦合以及双向流动特性的自能源模型. 针对其结构复杂且状态变量采样周期不同所造成的信息不完备等特点, 设计了基于 GAN 技术的参数辨识算法, 结合模糊算法对真实数据进行分类, 实现对自能源不同工况的拟合, 同时, 应用含策略梯度的反馈改进模型, 实现了自能源生成器生成模型离散的问题, 进而通过训练得出自能源模型的网络参数, 最后进行了考虑自能源不同工况的仿真实验, 结果表明提出的方法是有效的.

1 自能源

受互联网中信息传递单元“自媒体”这一概念启发, 我们将能源互联网中具有能源交换能力的区域定义为“自能源”. 在互联网中“自媒体”承担着

信息传递的作用, 包括博客、微博、微信、百度官方贴吧、论坛/BBS 等网络社区, 具有私人化、平民化、普泛化、自主化的特性. 而在能源互联网中, 自能源也有类似的特性, 自能源同样是来自草根阶层并且不再是单一的能源接收者, 同时还是能源的供应者, 具有互补性、开放性和区域性. 自能源中, 能源载体形式各种各样, 包括电能、热能、天然气和交通, 自能源的规模大小可以是拥有分布式发电、储能、冷热电联产等能源生产、转换和存储设备的个人、别墅、企业或社区, 也可以是具有能源质量调节能力的电厂、供热站等. 与传统能源系统(微网、直供热网、直供气网)相比, 自能源强耦合性和互补性使得自能源具有将不同种类能源转换成自己所需能源的能力.

在以往的研究中, Energy cell 和 Prosumer 分别被提出用来刻画能源互联网子单元特性, “Energy cell” 被定义为由本地发电单元、存储设备和可控负荷组成的个体消费者或一组实体, “Prosumer” 顾名思义, 是指一类生产消费一体化的能量单元, 然而两者所建模型均为能源互联网电能交易市场框架下的经济模型, 体现不出多能源耦合在能源互联网中起到的优化作用. 本文所建自能源模型为多能源载体耦合交互模型, 与 “Prosumer” 相比, 自能源采用分布式协调控制, 使能源互联网内各自能源进行协同合作, 实现能源互联网的故障诊断、故障恢复、状态监控, 保证能源互联网安全、稳定运行; 与 “Energy cell” 相比, 自能源体现出多种能源交易的同步性, 在同一时刻, 不同种类的能源流动方向可能不同, 因此, 能源互联网中自能源同时担任买家和卖家两种角色.

在能源互联网中, 自能源根据自身能源供求情况及能源互联网中能源价格来制定能源转换量, 从而平衡全网能源和最大化自身利益. 自能源间通过能源端口与其他自能源交换能量. 图 1 为涵盖电能、热能、天然气的自能源结构, 负荷(电负荷、热负荷和天然气负荷)由本地能量生产单元供能, 多余能源

不仅可以通过能量存储设备进行储能, 还可以通过能源端口进行能量交换.

2 自能源机理模型

2.1 电力子系统模型

根据图 1 所示自能源结构, 其中电力子系统模型包括分布式电源、储能设备、负荷及能量转换单元. 其中, 储能设备充放电过程带有一定的计划性, 因此可以联合分布式电源统一被视为电力子网中的 PQ 节点, 将分布式电源联储模块等效成输出功率可控的微电源, 经过逆变器向本地负荷和能源互联网输送功率. 负荷单元是由网络中众多用电设备和用户组成的综合对象, 具有非线性 and 异构性, 根据负荷特性可以分为静态负荷和动态负荷. 本文中涉及的电能转换单元主要包括电锅炉、水泵、天然气压缩机, 这些转换单元的能量输入波动会影响耦合网络的能源输出, 因此其模型不能视为常规负荷或电源来看, 其等效模电路如图 2 所示.

从自能源能源端口来看, 分布式电源联储模块可以描述为

$$\tilde{S}_{DG} = -(P_{DG} + jQ_{DG}) \quad (1)$$

式中, $\tilde{S}_{DG}$ 为分布式电源联储模块输出的复功率, P_{DG} 为有功功率, Q_{DG} 为无功功率. 为了更好地协调自能源系统中的有功和无功功率分配, 系统的逆变器输出功率采用下垂控制方法进行调节^[32]:

$$\begin{aligned} P_{DG} &= P_{DG,0} - \frac{1}{m}(f - f_0) \\ Q_{DG} &= Q_{DG,0} - \frac{1}{n}(U_{DG} - U_0) \end{aligned} \quad (2)$$

式中, m 为频率下垂系数, n 为频率下垂系数, f_0 和 f 分别为逆变器额定频率和输出频率, U_0 和 U 分别为额定电压和输出电压, $P_{DG,0}$ 和 $Q_{DG,0}$ 分别为逆变器的有功和无功额定容量.

在自能源中, 微燃气轮机通过燃烧天然气产生热能, 其中具有较高压力和温度的高品味热能转换为电能, 低品味热能通过热交换器供给热负荷, 其单位时间内所产生的电能与进气量的关系为

$$P_{E,MT} = \eta_{g2e} H_u m_g \quad (3)$$

式中, $P_{E,MT}$ 为微燃气轮机的输出电功率, η_{g2e} 为微燃气轮机发电效率, H_u 为天然气燃烧低位发热值, m_g 为单位时间天然气的进气量.

自能源中电力系统的静态负荷按特性为恒定阻抗(Z)、恒定电流(I)和恒定功率(P)三种负载按一定比例的组合, 可以表示为电压的二次函数, 即:

$$\tilde{S}_{L0} = P_{L0} + jQ_{L0} \quad (4)$$




图 1 自能源结构

Fig. 1 Structure of we-energy




图2 电力子系统模型

Fig. 2 Power subsystem model for we-energy

自能源中电力系统的动态负荷主要由感应电动机组成, 根据感应电动机机械暂态过程, 其模型可以描述为

$$\tilde{S}_L = \frac{R_L}{R_L^2 + X_L^2} U^2 + j \frac{X_L}{R_L^2 + X_L^2} U^2 \quad (5)$$

式中, $Z_L = R_L + jX_L$ 为感应电动机的等值阻抗。

自能源中的电锅炉可以将电能转化为热能为热力管网提供热量, 其电功率 $P_{E,EB}$ 表达如下:

$$P_{E,EB} = UI_{EB} \quad (6)$$

式中, $P_{E,EB}$ 为电锅炉输入功率, I_{EB} 为电锅炉的电流。

自能源中的水泵和空气压缩机将电能转换为机械能从而增加热力管网和天然气管网对介质的输送能力, 其耗电功率可以表示为

$$\begin{aligned} P_{E,pump} &= UI_{pump} \\ P_{E,comp} &= UI_{comp} \end{aligned} \quad (7)$$

式中, $P_{E,pump}$ 和 $P_{E,comp}$ 分别为水泵和压缩机的输入功率, I_{pump} 和 I_{comp} 分别为水泵和压缩机电锅炉的电流。

根据系统结构, 电力子系统中线路损耗 $\Delta \tilde{S}_l = \Delta P_l + j\Delta Q_l$ 可表示为

$$\begin{aligned} \Delta P_l &= \frac{r_l}{r_l^2 + x_l^2} (U_{EI} - U)^2 \\ \Delta Q_l &= \frac{x_l}{r_l^2 + x_l^2} (U_{EI} - U)^2 \end{aligned} \quad (8)$$

式中, ΔP_l 为有功功率损耗, ΔQ_l 为无功功率损耗, $r_l + jx_l$ 为自能源端口到负荷的线路阻抗。

由于系统中电能转换设备的输入功率会影响耦合网络的状态变量, 同时天然气网络中输入至微燃气轮机的天然气质量流率也会影响其电功率的输出, 因此, 在电力子系统中这些耦合变量需要单独考虑, 根据本文所建立的电力子系统结构, 自能源电力子

系统的输出功率为

$$\begin{aligned} P_E &= P_{L0} + P_L + P_{E,EB} + P_{pump} + \\ &\quad P_{comp} + \Delta P_l - P_{DG} - P_{E,MT} \quad (9) \\ Q_E &= Q_L + Q_{L0} + \Delta Q_l - Q_{DG} \end{aligned}$$

2.2 热力网子系统模型

在供热系统中, 由能源互联网提供带有一定温度和质量流率的水, 经过水泵、电锅炉和热交换器等设备加压升温后向自能源中的热负荷提供热量, 最后在由回水管流回能源互联网。目前, 集中供热系统的经济收益大多来自采暖用户每年固定缴纳的采暖费, 而非用户有关实时采暖热量的价格函数。因此, 本文从供热子系统功率平衡的角度出发对自能源建模, 通过调整设备输入功率控制系统中的各状态变量, 从而达到控制自能源热网系统, 同时根据本文所建模型可对供热系统进行实时经济性分析, 其系统结构如图3所示。在图3所示热力子系统中, 无能源耦合设备时测得进水后流体状态变量为 $T_{w,i}$ 、 $p_{w,i}$ 和 $v_{w,i}$ 。由于管道中的水带有流动性, 为方便计算热网热功率对流体温度变化的影响, 本文从热力学角度对热功率作出如下定义:




图3 热力子系统模型

Fig. 3 Heating subsystem model for we-energy

定义 1. 在理想情况下, 管道的热功率是指单位时间内管道中流体通过某一截面时流体所具有的热量, 单位 W , 热功率表征管道输送热量的快慢, 其计算公式为

$$P_Q = c_w \dot{m}_w T_w \quad (10)$$

式中, c_w 为比热容 ($J/kg \cdot K$), $\dot{m}_w = \rho_w v_w S_w$ 为流体的质量流率 (kg/s), T_w 为流体的温度 (K), 其中 ρ_w 为流体密度, v_w 为速度, S_w 为管道横截面积。

电锅炉作为热力管网中的升温设备, 可以将电能转化为热能为热力管网提供热量, 当接入输入电

功率为 $P_{E,EB}$ 的电锅炉时, 其热功率 $P_{Q,EB}$ 表达如下:

$$P_{Q,EB} = \eta_{EB} P_{E,EB} \quad (11)$$

式中, $P_{E,EB}$ 为电锅炉输入功率, η_{EB} 为电锅炉热效率.

在自能源中, 微燃气轮机在向电力子系统提供电能的同时也向热力子系统提供热能, 其单位时间内所产生的热能与微燃气轮机进气量的关系为

$$P_{Q,MT} = \eta_{g2h} H_u \dot{m}_g \quad (12)$$

式中, $P_{Q,MT}$ 为微燃气轮机的输出热功率, η_{g2h} 为微燃气轮机产热效率, H_u 为天然气低热值, $\dot{m}_g$ 为微燃气轮机进气质量流量.

在热力管网中, 水泵的输入功率 P_{pump} 与泵的转速 ω 的立方成正比, 而泵转速的变换会直接影响热力管网中流体的流速与压强:

$$P_{\text{pump}} = \frac{\dot{m}_w H_w}{1000 \eta_{\text{pump}}} \quad (13)$$

式中, H_w 为水泵扬程, η_{pump} 为水泵效率.

假设水泵进水口与出水口高度相等, $h_1 = h_2$, 若水泵的输入功率为 P_{pump} , 由于进水管管径不变, 管道内流体流速不突变, 因此水泵扬程瞬间转化为流体压强, 由式 (13) 及带有机能输入的伯努利方程可得到加压后水泵出水后压强 p_w 为

$$p_w = p_{w,i} + \frac{1000 \eta_{\text{pump}} \rho_w g P_{\text{pump}}}{\dot{m}_{w,1}} \quad (14)$$

式中, $\dot{m}_{w,1}$ 为水泵加压之前流体质量流量.

对整个热力管网, 假设出水后压强 $p_{w,o}$ 不变, 则根据式 (14), 管道中流体流速经水泵加压后变为

$$v_w^2 = v_{w,1}^2 + \frac{2000 \eta_{\text{pump}} g P_{\text{pump}}}{\rho_w S_{w,\text{pipe}} v_{w,1}} + \frac{2p_{w,i} - 2p_{w,o}}{\rho_w} \quad (15)$$

基于以上分析, 当管道中加入功率为 P_{pump} 的水泵时, 其输出热功率为

$$P_{Q,\text{pump}} = c_w \rho_w S_{w,\text{pipe}} (v_w - v_{w,1}) T_w \quad (16)$$

在实际工程中, 由于建筑的能耗与室内室外温度、建筑结构等多方面因素有关, 采暖用户的热负荷很难得到一个精准的模型. 本文采用热力学中较为通用的单位面积指标法对热负荷进行建模, 由于供热系统中的燃煤锅炉和热储能设备具有一定的计划性, 对其控制可等效为控制建筑采暖面积, 因此锅炉用

户储能联合模型可表示为

$$P_{Q,L} = \chi_{Q,L} F_{Q,L} \quad (17)$$

$$F_{Q,L} \in \left(F_{Q,L}^{\min} - \frac{P_{Q,B}^{\max} + P_{Q,HS}^{\max}}{\chi_{Q,L}}, F_{Q,L}^{\max} + \frac{P_{Q,HS}^{\max}}{\chi_{Q,L}} \right)$$

式中, $P_{Q,L}$ 为建筑物采暖热负荷, $\chi_{Q,L}$ 建筑单位面积耗热指标, $F_{Q,L}$ 为可控建筑面积, $P_{Q,B}^{\max}$ 和 $P_{Q,HS}^{\max}$ 分别为燃煤锅炉最大热功率和热储能最大存储 (释放) 功率.

由于流体在运动时存在黏性, 在管道中流动会产生摩擦力, 将使流体一部分机械能转化为热能, 因此管道中流体虽然由于摩擦阻力减小了流速, 但温度却增加了, 从功率平衡角度来看, 流体的热功率损失非常小, 可忽略不计.

根据本文所建立的热力子系统结构, 自能源热力子系统的输出功率为

$$P_{Q,o} = P_{Q,i} + P_{Q,EB} + P_{Q,MT} + \Delta P_{Q,\text{pump}} - P_{Q,L} \quad (18)$$

2.3 天然气管网子系统模型

在天然气管网中, 天然气气井联合储气罐作为一个可控气源输出具有一定 $v_{g,1}$ 、 $p_{g,1}$ 和 $\rho_{g,1}$ 的天然气, 经过空气压缩机升压后与天然气管网汇流, 与电网中功率流动规律类似, 经压缩机升压后天然气压力大于能源互联网端压强时, 自能源向能源互联网输出天然气, 反之能源互联网向自能源输入, 自能源内天然气子系统具体结构如图 4 所示, 其中, $v_{g,1}$ 、 $p_{g,1}$ 和 $\rho_{g,1}$ 为自能源端口天然气状态变量, $\dot{m}_{g,L}$ 为天然气负荷.




图4 天然气管网子系统模型

Fig. 4 Natural gas pipeline model for we-energy

本文根据天然气管网中总能量守恒和气体状态变量转化规律研究天然气的流量变化. 其中, 天然气压缩机的输入功率与电力网络耦合, 其工作原理与水泵类似, 但由于天然气是可压缩的, 加压后天然气的密度和流速等都会发生改变, 因此, 压缩机输入功率对天然气管网的影响与热力管网不同. 假设压缩机的输入功率为 P_{comp} , 由于气体流速、密度不能瞬变, 其功率变化全部转化为 H_g . 由伯努利方程可得

到天然气压力瞬时变化量 $\Delta p_{g,1}$ 为

$$\Delta p_{g,1} = \rho_{g,1} g H_g \quad (19)$$

引理 1. 在理性气体中, 管道中压缩机输入功率 P_{comp} 与管道中气体流速变化量 Δv_g 、气体压强变化量 Δp_g 的关系为

$$p_{g,1} \Delta v_g + v_{g,1} \Delta p_g + \Delta p_g \Delta v_g = \gamma_1 P_{\text{comp}} \quad (20)$$

式中, $\gamma_1 = \frac{1000g\eta_{\text{comp}}}{1+c/RZ}$, η_{comp} 为压缩机效率.

证明. 在不考虑气体对外热损失的条件下, 根据能量守恒方程, 压缩机对气体所做的功一部分以机械能形式传给气体的理论能头, 另一部分以热能形式传给气体, 因此, 管道中气体的总功率 $P_{g,\text{tot}}$ 为

$$P_{g,\text{tot}} = P_M + P_Q \quad (21)$$

式中, P_M 为气体的机械功率.

当压缩机功率为 P_{comp} 时, 根据式 (21), 气体总功率变化为

$$\Delta P_{g,\text{tot}} = \Delta p_{g,1} \cdot S_{g,\text{pipe}} \cdot v_{g,1} \quad (22)$$

由式 (19)、(21) 可得压缩机的输入功率为 P_{comp} 时管道中气体的功率平衡方程:

$$\begin{aligned} (p_{g,1} + \Delta p_{g,1}) v_{g,1} S_{g,\text{pipe}} + c \dot{m}_{g,1} T_{g,1} = \\ p_{g,2} v_{g,2} S_{g,\text{pipe}} + c \dot{m}_{g,2} T_{g,2} \end{aligned} \quad (23)$$

根据理想气体状态方程可得:

$$\rho_g T_g = \frac{M}{R} p_g \quad (24)$$

式中, M 为气体的摩尔质量, R 为气体常数.

将式 (19)、(24) 及 $p_{g,2} = p_{g,1} + \Delta p_g$ 代入式 (23) 即可得出 P_{comp} 与 Δv_g 、 Δp_g 的关系. $\square$

根据式 (20), 当天然气管网接入输入功率为 P_{comp} 的压缩机时, 当系统稳定, 管道中天然气压强变化量与速度变化量的乘积可以表示为

$$\Delta p_g \Delta v_g = \gamma_1 P_{\text{comp}} + 2p_{g,1} v_{g,1} - p_{g,1} v_g - v_{g,1} p_g \quad (25)$$

在天然气管网中, 微燃气轮机和天然气负荷出气口均有测速装置, 其输出天然气量可控, 假设微燃气轮机和天然气负荷出气口压强均为标准大气压, 则微燃气轮机和天然气负荷的气流量可以表示为

$$\begin{aligned} V_{g,MT} &= S_{g,MT} v_{g,MT} \\ V_{g,L} &= S_{g,L} v_{g,L} \end{aligned} \quad (26)$$

假设经压缩机升压后的气体状态变量 $v_{g,s}$ 、 $p_{g,s}$ 和 $\rho_{g,s}$, 天然气管网水平放置, 根据图 4 所示天然气管

网沿程流量变化可列出天然气总流的伯努利方程:

$$\begin{aligned} \dot{m}_{g,2} \left(\frac{p_{g,2}}{\rho_{g,2}g} + \frac{v_{g,2}^2}{2g} \right) = \dot{m}_{g,s} \left(\frac{p_{g,s}}{\rho_{g,s}g} + \frac{v_{g,s}^2}{2g} \right) - \\ \dot{m}_{g,MT} \left(\frac{p_{g,MT}}{\rho_{g,MT}g} + \frac{v_{g,MT}^2}{2g} \right) - \\ \dot{m}_{g,L} \left(\frac{p_{g,L}}{\rho_{g,L}g} + \frac{v_{g,L}^2}{2g} \right) - \dot{m}_{g,L} \Delta H_{g,l} \end{aligned} \quad (27)$$

式中, $\dot{m}_{g,s} > 0$ 代表压缩机向自能源端口输气, 反之为储气罐储气; $\dot{m}_{g,2} > 0$ 代表能源互联网向自能源输气, 反之为自能源向能源互联网输气.

天然气管道中, 天然气流动会产生摩擦力使其流速减小, 但因此增大了管道压强, 因此本文忽略天然气黏性对管道状态变量的影响. 同时, 在实际工程中, 天然气的压力势能远远大于其动能, 因此可假设天然气在稳定时各节点流速相等. 基于以上假设, 式 (31) 可以简化为

$$p_{g,2} \dot{V}_{g,2} = p_{g,s} \dot{V}_{g,s} - p_{g,MT} \dot{V}_{g,MT} - p_{g,L} \dot{V}_{g,L} \quad (28)$$

式中, $\dot{V}_g = v_g S_g$ 为天然气的体积流率.

这里, 类比电力学中的电功率为电压与电流的乘积, 在能源互联网中我们将天然气管网中天然气压力与体积流率的乘积做出如下定义:

定义 2. 在标准大气压下, 气体的容压是指单位时间内管道某一截面处通过气体体积的多少, 单位为 $\text{bar} \cdot \text{m}^3/\text{s}$, 容压表征管道输送气体的能力, 其计算公式为

$$Z_g = \frac{p_g \dot{V}_g}{1 \times 10^5} \quad (29)$$

根据本文所建天然气管网结构, 自能源天然气子系统模型可以表示为

$$Z_{g,2} = Z_{g,1} - Z_{g,MT} - Z_{g,L} + \Delta Z_{g,\text{comp}} \quad (30)$$

2.4 自能源整体模型

根据对自能源各个子网络中的电功率平衡方程、热功率平衡方程及容压平衡方程进行整理, 可得到自能源的整体机理模型:

$$\begin{aligned} P_E &= \theta_{11} U^2 + \theta_{12} U + \theta_{13} f - \theta_{14} v_{g,MT} + \theta_{15} \\ Q_E &= \theta_{21} U^2 + \theta_{22} U + \theta_{23} U_{DG} + \theta_{24} \\ P_Q &= \theta_{31} v_w T_w - \theta_{32} T_w + \theta_{33} v_{g,MT} - \\ &\quad \theta_{34} F_{Q,L} + \theta_{35} + \eta_{EB} P_{EB} \\ Z_g &= \theta_{41} v_g + \theta_{42} p_g + \theta_{43} v_{g,MT} + \\ &\quad \theta_{44} v_{g,L} + \theta_{45} P_{\text{comp}} + \theta_{46} \end{aligned} \quad (31)$$

式中, θ 为自能源系统模型待估参数, 其中有功功率参数具体形式为: $\theta_{11} = R_L / (R_L^2 + X_L^2) + P_0 P_Z / U_0^2 +$

$r_l/(r_l^2 + x_l^2)$, $\theta_{12} = P_0 P_I / U_0 - 2r_l U_{EI} / (r_l^2 + x_l^2)$, $\theta_{13} = 1/m$, $\theta_{14} = \eta_{g2e} H_u \rho_{g,MT} S_{g,MT}$, $\theta_{15} = P_0 P_P + P_{EB} + P_{pump} + P_{comp} + 2r_l U_{EI}^2 / (r_l^2 + x_l^2) - f_0/m - P_{DG,0}$; 无功功率参数具体形式为: $\theta_{21} = X_L / (R_L^2 + X_L^2) + Q_0 Q_Z / U_0^2 + x_l / (r_l^2 + x_l^2)$, $\theta_{22} = Q_0 Q_I / U_0 - 2x_l U_{EI} / (r_l^2 + x_l^2)$, $\theta_{23} = 1/n$, $\theta_{24} = Q_0 Q_P + 2x_l U_{EI}^2 / (r_l^2 + x_l^2) - U_0/m - Q_{DG,0}$; 热功率方程参数具体形式为: $\theta_{31} = c_w \rho_w S_{w,pipe}$, $\theta_{32} = c_w \rho_w S_{w,pipe} v_{w,i}$, $\theta_{33} = \eta_{g2h} H_u \rho_{g,MT} S_{g,MT}$, $\theta_{34} = \chi_{Q,L}$, $\theta_{35} = \rho_w v_{w,i} S_{w,1} T_{w,i}$; 天然气气压方程参数具体形式为: $\theta_{41} = -S_{g,pipe} p_{g,1}$, $\theta_{42} = -S_{g,pipe} v_{g,1}$, $\theta_{43} = p_{g,0} S_{g,MT}$, $\theta_{44} = p_{g,0} S_{g,L}$, $\theta_{45} = \gamma_1 S_{g,pipe}$, $\theta_{46} = p_{g,1} v_{g,1} S_{g,pipe} + 2S_{g,pipe} p_{g,1} v_{g,1}$.

3 自能源模型参数辨识的 GAN 算法实现

生成式对抗网络由生成器和判别器组成, 其中, 生成器的主要作用是通过对采样的随机变量进行加工产生与真实数据相似的值, 模拟现实环境; 而判别器的主要目标旨在尽量正确地判别输入数据的来源, 训练生成器模拟数据分布的能力, 由此两者通过二人零和博弈实现学习优化过程, 最终达到一个纳什均衡. 本文将式 (31) 所建立的自能源机理模型作为待辨识的生成器, 自能源系统根据真实数据类别选择状态变量的采样区间, 并将该区间的随机变量输入生成器产生模拟数据, 其中, z 采样于先验分布, 本文假设其服从高斯噪声分布^[21]. 根据图 5 所示结构, 首先, 生成器 G 根据模糊分类的输入改变式 (31) 对应的自能源机理模型; 随后, 一组服从高斯噪声分布的随机序列 z 经生成器 G 后输出一组离散的模拟数据 $G(z)$; 最后, 判别器对模拟数据 $G(z)$ 与真实数据 x 进行判别训练, 并将其判别准确率作为奖励值通过策略梯度法反馈回生成器, 从而对生成器进行更新. 由于自能源在不同的运行工况下其模型不同, 本文通过对输入数据的模糊分类可计算出能反映自能源不同运行工况的隶属度, 根据自能源控制策略可提前对机理模型进行修正, 使模型精确地逼近于输入数据.




图 5 基于模糊分类的 GAN 模型

Fig. 5 GAN structure based on fuzzy classification

3.1 自能源的模糊分类

在图 1 所示自能源结构中, 由于自能源中电、

热、气三网根据其各自网络状态变量波动均涉及系统运行状态变化, 当网络状态变量偏离各自允许范围时, 式 (31) 所建自能源模型亦发生相应变化. 值得注意的是, 由于本文采用的是基于机理-数据混合驱动的建模方法, 在优化过程中, 通过对输入数据的模糊分类可计算出能反映自能源不同运行工况的隶属度, 根据其对应的控制策略可提前对机理模型进行修正, 从而使模型精确地逼近于训练数据, 从而很大程度上避免了陷入局部最优. 在自能源系统中, 影响电力网络中运行工况的状态变量主要有电压、频率, 影响热力管网和天然气管网运行工况的状态变量主要为管道压强. 根据专家经验, 电网中的电压 U (V) 和频率 f Hz 隶属函数分别可设计为

$$\mu_{E,U}(U) = \begin{cases} \frac{U - U_{\max}^{ur}}{U_{\max}^{nor} - U_{\max}^{ur}}, & U_{\max}^{nor} \leq U \leq U_{\max}^{ur} \\ 1, & U_{\min}^{nor} \leq U \leq U_{\max}^{nor} \\ \frac{U - U_{\min}^{ur}}{U_{\min}^{nor} - U_{\min}^{ur}}, & U_{\min}^{ur} \leq U \leq U_{\min}^{nor} \end{cases} \quad (32)$$

$$\mu_{E,f}(f) = \begin{cases} \frac{f - f_{\max}^{ur}}{f_{\max}^{nor} - f_{\max}^{ur}}, & f_{\max}^{nor} \leq f \leq f_{\max}^{ur} \\ 1, & f_{\min}^{nor} \leq f \leq f_{\max}^{nor} \\ \frac{f - f_{\min}^{ur}}{f_{\min}^{nor} - f_{\min}^{ur}}, & f_{\min}^{ur} \leq f \leq f_{\min}^{nor} \end{cases} \quad (33)$$

式中, $\mu_{E,U}$ 为对电压的隶属度, $\mu_{E,f}$ 为对频率的隶属度.

在电网中出现电压、频率波动时, 根据式 (32)、(33) 即可求出电网的运行工况:

$$\mu_E = \mu_{E \cup f} = \min \{ \mu_{E,U}, \mu_{E,f} \} \quad (34)$$

式中, μ_E 为电网稳定隶属度.

在自能源中, 当 $\mu_E = 1$ 时, 自能源电力子系统以常规模式运营. 当 $\mu_E^{ur} \leq \mu_E < 1$ 时, 电力子系统处于临界模式, 此时自能源若处于对外输出电功率, 则须将分布式电源切除; 自能源若处于吸收电功率模式, 则须切除动态负荷以保证系统回稳. 当 $0 \leq \mu_E < \mu_E^{ur}$ 时, 电力子系统处于紧急模式, 此时自能源若处于对外输出电功率模式, 则须切除分布式电源及微燃气轮机的输出; 自能源若处于吸收电功率模式, 则须切除自能源中静态负荷及动态负荷.

热力子系统中, 流体管道的压强 p_w (atm) 隶属

函数可设计为

$$\mu_{H,p}(p_w) = \begin{cases} \frac{p_w - p_{w,\max}^{ur}}{p_{w,\max}^{nor} - p_{w,\max}^{ur}}, & p_{w,\max}^{nor} \leq p_w \leq p_{w,\max}^{ur} \\ 1, & p_{w,\min}^{nor} \leq p_w \leq p_{w,\max}^{nor} \\ \frac{p_w - p_{w,\min}^{ur}}{p_{w,\min}^{nor} - p_{w,\min}^{ur}}, & p_{w,\min}^{ur} \leq p_w \leq p_{w,\min}^{nor} \end{cases} \quad (35)$$

式中, $\mu_{H,p}$ 为低压供热管网稳定隶属度。

在自能源中, 当 $\mu_{H,p}=1$ 时, 自能源供热子系统以常规模式运营. 当 $\mu_H^{ur} \leq \mu_{H,p} < 1$ 时, 供热子系统处于临界模式, 此时自能源若处于对外输出热功率, 则须将水泵切除; 自能源若处于吸收热功率模式, 则须切除热储能以保证系统回稳. 当 $0 \leq \mu_{H,p} < \mu_H^{ur}$ 时, 系统处于紧急模式, 此时自能源若处于对外输出热功率模式, 则开启热储能并切除水泵的输出; 自能源若处于吸收热功率模式, 则切除自能源中热负荷及微燃气轮机热输出.

天然气子系统中, 天然气管道的压强 p_g (Kpa) 隶属函数可设计为

$$\mu_{G,p}(p_g) = \begin{cases} \frac{p_g - p_{g,\max}^{ur}}{p_{g,\max}^{nor} - p_{g,\max}^{ur}}, & p_{g,\max}^{nor} \leq p_g \leq p_{g,\max}^{ur} \\ 1, & p_{g,\min}^{nor} \leq p_g \leq p_{g,\max}^{nor} \\ \frac{p_g - p_{g,\min}^{ur}}{p_{g,\min}^{nor} - p_{g,\min}^{ur}}, & p_{g,\min}^{ur} \leq p_g \leq p_{g,\min}^{nor} \end{cases} \quad (36)$$

式中, $\mu_{G,p}$ 为天然气低压管网稳定隶属度。

在自能源中, 当 $\mu_{G,p} = 1$ 时, 自能源天然气子系统以常规模式运营. 当 $\mu_G^{ur} \leq \mu_{G,p} < 1$ 时, 天然气子系统处于临界模式, 此时自能源若处于对外输出容压, 则须将压缩机切除; 自能源若处于吸收天然气模式, 则须切除微燃气轮机以保证系统回稳. 当 $0 \leq \mu_E < \mu_G^{ur}$ 时, 系统处于紧急模式, 此时自能源若处于对外输出天然气模式, 则须切除天然气源及压缩机的输出; 自能源若处于吸收电功率模式, 则须切除自能源中天然气负荷及微燃气轮机.

3.2 基于自能源的生成对抗网络

在能源互联网中, 自能源在不同运行条件下运行状态不同, 系统中各设备所处工况亦不相同, 故根据自能源的真实数据将自能源的各子网系统运行状态分为常规运行模式、临界运行模式和紧急运行模式. 生成器的输入状态变量的采样区间可根据系统运行分为常规运行区间、临界运行区间和紧急运行区间. 生成器根据真实数据所反映的系统运行状态

选择其采样区间.

生成器的模型即根据式 (31) 所建立的基于自能源能量传输特征的可微分方程组, 生成器在初始化阶段, 由于缺少判别器的训练, 本文选用极大似然估计法预训练生成器模型, 从而初始化自能源系统参数. 在判别器对其进行训练时, 生成器根据判别器的奖励函数对其系统参数策略调参, 使自身损失函数 $Obj^G(\theta_G)$ 最大化.

为了获取更为精准的能源分布信息, 判别器需要对生成器所生成的数据分布与真实数据分布进行判别. 判别器 D 作为一个二分类器, 以真实数据 x 和生成器 G 输出的模拟数据 $G(z)$ 作为输入, 通过最小化判别器的损失函数优化自身判别能力, 输出一个对当前输入是真实数据还是模拟数据的判别概率. 当数据来自真实数据 x 时, D 的目标是使得输出概率值 $D(x)$ 趋近于 1, 而当数据由 G 生成时, D 的目标是正确判断数据来源, 使得 $D(G(z))$ 趋近于 0. 通过自能源的当前结构, 可采样获得自能源与网络接口的能量信息, 包括各个时段的 P_E, Q_E, P_Q, Z_g , 即能源序列 $x_1; x_2; \dots; x_T$; 而生成器 G 即根据考虑多种工况的随机样本以及初始参数生成目标自能源端口的能源信息 $y_1; y_2; \dots; y_T$. 在给定生成器的情况下, 通过最小化交叉熵以优化判别器 D . 基于判别器的二分类判别特征, 其模型采用深度神经网络结构. RNN (Recurrent neural network) 和 CNN (Convolutional neural network) 针对复杂的序列分类具有较好的训练特性, 其中, RNN 允许网络信息的持久化, 但当 RNN 的输出与相关信息间隔较远时 RNN 将丧失学习较远的信息的能力, LSTM (Long-short term memory) 可以学习长期依赖信息, 记住长期的信息在实践中是 LSTM 的默认行为, 较 RNN 更能处理好长期依赖问题^[33-34]. 在自能源中, 输出能源的状态变量只与上一时刻状态变量有关, 这种短期依赖问题在生成器建模过程中可以根据爬坡约束进行限制, 而 CNN 最突出的特点之一就是局部感知能力, 在训练过程中 CNN 可以通过减少隐藏单元与输入单元的连接来降低权重计算复杂度, 因此本文选用 CNN 构建判别器模型^[35], 通过最小化判别器损失函数以得到最优解:

$$\min Obj^D(\theta_D, \theta_G) = -E_{Y \in P_{data}} [\log D(X, Y)] - E_{Y \in G_\theta} [\log (1 - D(X, Y))] \quad (37)$$

式中, $Y \in P_{data}$ 表示数据来自真实数据样本分布, $Y \in G$ 则表示数据来自生成器模拟样本分布.

3.3 训练策略

基于自能源模型的参数识别, 需通过生成器 G

产生基于能源数据源的目标能源数据分布, 并根据判别器判别数据分布来自真实能源数据或者生成器生成数据. 由于电、气、热网络状态变量的采样周期不同, 在训练生成器时需要将同一时刻数据输入, 因此文中的训练数据是离散的. 为此, 本文所建立模型将 GAN 技术与策略梯度相结合, 策略梯度法作为强化学习中一种基于策略的直接逼近算法, 可以处理离散数据, 将判别器的输出作为策略梯度的奖励函数对生成器直接进行反馈训练, 从而避免离散数据难以进行微分计算的问题. 因此, 生成器的目标函数可以表示为

$$\max \text{Obj}^G(\theta_G) = \sum_{Y_{1:T-1}} G_\theta(Y_{1:T-1} | S) \cdot Q_{D_\phi}^{G_\theta}(Y_{1:T-1}, S) \quad (38)$$

式中, $Y_{1:T-1} = y_1, \dots, y_T$ 表示生成器所产生的目标序列, $Q_{D_\phi}^{G_\theta}$ 为动作值函数, 即判别器在状态 $(Y_{1:T-1}, S)$ 时, 依照策略 G_θ , 采取动作 y_T 所产生的积累奖励. 为了估算动作值函数, 将判别器所判别正确的概率作为奖励值:

$$Q_{D_\phi}^{G_\theta}((Y_{1:T-1}, X), y_T) = D(X, Y_{1:T}) - b(X, Y_{1:T}) \quad (39)$$

式中, $b(S, Y_{1:T})$ 表示用于减少奖励值方差的基准值. 通常将其设为常量. 由于判别器仅能得出一个完整序列的奖励值, 在不完全序列中, $D(S, Y_{1:T})$ 无法获得. 为了能够估算中间状态的动作值函数, 采用基于策略 G 的蒙特卡洛搜索策略采样剩余未知的序列, 从而近似动作值函数. 则 N 次蒙特卡洛搜索策略可以表示为

$$\{Y_{1:T_1}^1, \dots, Y_{1:T_N}^1\} = MC^{G_\theta}((Y_{1:t}, X), N) \quad (40)$$

式中, $(Y_{1:t}, X) = (y_1, \dots, y_t, X)$ 为当前状态; $Y_{t+1:T_N}^N$ 为基于策略 G 取样的序列长度; T_i 为蒙特卡洛搜索的序列样本长度; 由此, 判别器将依据所采样的 N 个序列得出 N 个奖励值. 因此, 对于中间状态的最终奖励值为 N 个奖励值的平均值. 则可将动作值函数分为两种情况表示如下:

$$Q_{D_\phi}^{G_\theta}((Y_{1:T-1}, X), y_T) = \begin{cases} \frac{1}{N} \sum_{n=1}^N D(X, Y_{1:T_n}^n) - b(X, Y_{1:T_n}^n), & t < T \\ D(X, Y_{1:t}^n) - b(X, Y_{1:t}^n), & t = T \end{cases} \quad (41)$$

根据上述将判别器作为奖励函数的形式, 可以通过动态地更新判别器来提高生成器的性能. 依据生成器的数据序列, 也可进一步修正判别器. 在更新判别器后, 交替更新生成器, 依据生成器的目标函

数, 对其进行梯度求解则可计算出生成器的参数, 即式 (42).

$$\begin{aligned} \nabla J(\theta_G) &= \frac{1}{T} \sum_{t=1}^T \sum_{y_t} Q_{D_\phi}^{G_\theta}((Y_{1:t-1}, X), y_t) \times \\ &\quad \nabla_\theta (G_\theta(y_t | Y_{1:t-1}, X)) = \\ &\quad \frac{1}{T} \sum_{t=1}^T E_{y_t \in G_\theta} \left[Q_{D_\phi}^{G_\theta}((Y_{1:t-1}, X), y_t) \times \right. \\ &\quad \left. \nabla_\theta \log p(y_t | Y_{1:t-1}, X) \right] \end{aligned} \quad (42)$$

3.4 自能源参数的辨识算法

生成式对抗网络的训练方式包含生成器和判别器, 在训练过程中需要保持两者的训练一致性. 综合上述分析, 得到适用于自能源建模的生成式对抗网络参数辨识算法:

步骤 1. 收集自能源的能源分布的观测序列, 得到需辨识的数据序列 $X = \{X_{1:T}\}$.

步骤 2. 初始化生成器模型 G_θ 和判别器模型 D_ϕ .

步骤 3. 基于数据序列 S , 用极大似然估计法预训练生成器模型 G_θ .

步骤 4. 根据当前生成器模型产生可用于训练的反馈.

步骤 5. 基于给定的生成器, 以最小化损失函数预训练判别器.

步骤 6. 进入生成器训练过程.

步骤 6.1. 生成生成器序列 $Y_{1:T} = (y_1, \dots, y_T)$;

步骤 6.2. 计算 t 从 1 到 T 阶段的奖励函数 $Q(a = y_t; s = Y_{1:t-1})$;

步骤 6.3. 通过策略梯度算法更新生成器的参数 θ .

步骤 7. 进入判别器训练过程. 用当前的生成器模型产生模拟数据与所给的真实样本结合起来训练判别器模型. 输出判别器参数 ϕ .

步骤 8. 重复步骤 6, 步骤 7 对生成器和判别器进行交替训练, 直至收敛.

4 算例分析

本文根据式 (31) 所建立的自能源模型作为对抗式生成网络参数辨识的算例, 以某大学搭建的校园狭义能源互联网^[36]的运行数据为参照, 不同来源的数据经过标么值换算后可以用于自能源整体的参数辨识. 本文根据数据的不同额定值分别对电、热、气

数据进行标么值换算, 将微燃气轮机输出的电、热功率标么值叠加到电、热子系统中的电、热功率输出, 将气网中压缩机消耗的电功率标么值叠加到电力子系统中的电负荷, 从而达到数据的融合. 截取各系统连续运行的 100 天中运行状态信息, 其中包括电力子系统 PCC (Point of common coupling) 的电压、频率、有功功率和无功功率, 热力子系统暖气管道进出口流体温度和压强, 天然气管道体积流量和压强. 由于电、气、热三个子系统的采样周期不同, 本文根据采样周期最长的热力管网为标准对电、热、气三种网络采样数据进行提取以达到不同时段数据的统一, 取一天 24 h 整点数据作为训练数据, 即共 2400 组数据. 在自能源中, 电网视在功率的基准值取 100 kVA, 电压的基准值取 1 kV, 其取值区间为 $[0.8, 1.2]$, 常规运行区间为 $[0.95, 1.05]$, 频率的基准值取 50 Hz, 其取值区间为 $[0.9, 1.1]$, 常规运行区间为 $[0.98, 1.02]$, 直供热管道流体压强基准值取 5 bar, 其取值区间为 $[0.8, 1.2]$, 常规运行区间为 $[0.96, 1.04]$, 热功率的基准值取 100 kW, 流体温度基准值取 400 K, 天然气管道天然气压强基准值取 3 bar, 其取值区间为 $[0.7, 1.3]$, 常规运行区间为 $[0.9, 1.1]$, 容压的基准值取 $10 \text{ bar} \cdot \text{m}^3/\text{s}$, 天然气温度基准值取 400 K. 自能源中各设备参数如表 1 所示.

表 1 自能源系统设备参数

Table 1 Parameter of equipment in WE system

自能源系统	容量 (kW)	功率下限 (kW)	功率上限 (kW)
光伏发电	40	0	12
风力发电	1×3	0	30
电储能	5×3	-10	10
微燃气轮机	80	20	80
燃气锅炉	40×2	20	80
电锅炉	5×4	0	20
热储能	5×2	-10	10
水泵	0.5×4	0.4	0.6
压缩机	0.3×2	0.25	0.35

4.1 自能源常规模式运行下系统参数识别

由于自能源在实际中还不存在实体, 很难获得一个较为真实的自能源状态变量运行数据, 本文以微电网、热电联产、直供热管网及天然气管网实际运行数据作为参考, 在常规运行模式下, 某一天自能源电力子系统、热力子系统和天然气子系统运行状态如图 6~8 所示.

根据本文所提出的 GAN 方法对自能源系统进行辨识, 基于 CNN 的判别器对于自能源模型生成的




图 6 自能源电力子系统运行状态

Fig. 6 Operating state of power subsystem in WE




图 7 自能源热力子系统运行状态

Fig. 7 Operating state of heating network in WE




图 8 自能源天然气子系统运行状态

Fig. 8 Operating state of natural gas network in WE

输出数据具有较好的训练效果, 其参数设置如下: Embedding 层的维度 64, 有 12 种卷积核, filter sizes = $[1 \ 2 \ 3 \ 4 \ 5 \ 6 \ 7 \ 8 \ 9 \ 10 \ 15 \ 20]$, 每种卷积核的个数 = $[100 \ 200 \ 200 \ 200 \ 200 \ 100 \ 100 \ 100 \ 100 \ 100 \ 160 \ 160]$, 任何一个给定单元的留存率 batch size = 0.85, 正则参数 lambda = 0.2, 每一次参数更新的训练样本数 batch size = 64, 序列长度 = 20. 本文以所提

方法与传统最小二乘法^[12]以及粒子群算法辨识方法^[15]作比较,将基于以上三种参数辨识方法的系统模型输出的模拟数据与训练数据产生的相对误差做均值处理,其计算公式为

$$\varepsilon = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - x_i|}{x_i} \quad (43)$$

其中, x_i 为训练数据, y_i 为模拟数据, N 为训练数据量. 比较结果如图 9 所示,通过比较看出,采用本文方法训练数据最小,误差在收敛后较为平坦,传统最小二乘法误差和收敛所需数据较大.

图 10 为自能源模型对实际输出数据的拟合,展示了自能源的动态特性,其模型对应参数如表 2 所示.




图 9 三种参数辨识方法的比较结果

Fig. 9 Comparison results of three parameter identification methods




图 10 自能源输出拟合曲线

Fig. 10 Output fitting curves of we-energy

4.2 自能源不同工况下系统参数识别

根据自能源在常规模式下运行时所辨识结果,假设在某一时刻能源互联网电力负荷增加 15%,自能源根据系统状态变量的模糊分类对模型参数进行调整,其参数辨识结果如表 3 所示.

从表 3 和图 11 我们可以看出,当能源互联网电力负荷增加时,自能源 PCC 点电压下降,根据文中

所提模糊策略,需要增加有功和无功功率输出支撑电压降,系统切除部分电加热设备及动态负载并增加微燃气轮机的进气量,因此其有关动态负载状态变量的参数变小,输出热功率和容压存在下降趋势,当电压恢复时,热功率和容压也逐渐恢复常规状态.

表 2 自能源常规运行时模型参数辨识结果

Table 2 Parameter identification results in regular

参数	估值	参数	估值	参数	估值
θ_{11}	0.035	θ_{23}	0.213	θ_{41}	-0.106
θ_{12}	0.136	θ_{24}	-0.622	θ_{42}	-0.127
θ_{13}	0.078	θ_{31}	0.296	θ_{43}	0.312
θ_{14}	-0.235	θ_{32}	0.065	θ_{44}	0.225
θ_{15}	0.438	θ_{33}	0.386	θ_{45}	0.064
θ_{21}	0.164	θ_{34}	0.176	θ_{46}	0.133
θ_{22}	0.153	θ_{35}	0.217		

表 3 自能源在电压异常时模型参数辨识结果

Table 3 Parameter identification results of WE model in abnormal voltage

参数	估值	参数	估值	参数	估值
θ_{11}	0.014	θ_{23}	0.178	θ_{41}	-0.157
θ_{12}	0.123	θ_{24}	-0.534	θ_{42}	-0.134
θ_{13}	0.081	θ_{31}	0.237	θ_{43}	0.247
θ_{14}	-0.211	θ_{32}	0.049	θ_{44}	0.265
θ_{15}	0.369	θ_{33}	0.276	θ_{45}	0.067
θ_{21}	0.145	θ_{34}	0.198	θ_{46}	0.233
θ_{22}	0.147	θ_{35}	0.234		




图 11 电压异常时自能源输出曲线

Fig. 11 Output curves of we-energy in abnormal voltage

根据自能源在常规模式下运行时所辨识结果,假设在某一时刻能源互联网热负荷增加 10% 时,自能源根据系统状态变量的模糊分类对模型参数进行调整,其参数辨识结果如表 4 所示.

从表 4 和图 12 我们可以看出,当能源互联网热力负荷减少时,由于热力管网液压突增,自能源 PCC 点液压逐渐增加,自能源需要减少热功率输出,系统根据自身策略切除部分电加热设备并减少

水泵的输入功率及微燃气轮机的进气量, 这将导致电网子系统负荷减小, 从而自能源关于电压参数变大. 表 4 为自能源在某一时刻天然气管网压强突然降低 20% 时模型参数辨识结果.

表 4 自能源在液压异常时模型参数辨识结果
Table 4 Parameter identification results of WE model in abnormal fluid pressure




图 12 液压异常时自能源输出曲线
Fig. 12 Output curves of WE in abnormal fluid pressure

从表 5 和图 13 我们可以看出, 当时能源互联网天然气负荷增加时, 自能源 PCC 点气压下降, 需要增加自能源容压输出, 系统根据策略减少微燃气轮机的进气量, 影响电力子系统和热力子系统的功率输出, 因此其有关电压和温度的参数变小于天然气管网压强下降.

表 5 自能源在气压异常时模型参数辨识结果
Table 5 Parameter identification results of WE model in abnormal gas pressure

参数	估值	参数	估值	参数	估值
θ_{11}	0.045	θ_{23}	0.157	θ_{41}	-0.095
θ_{12}	0.246	θ_{24}	-0.576	θ_{42}	-0.108
θ_{13}	0.069	θ_{31}	0.146	θ_{43}	0.289
θ_{14}	-0.246	θ_{32}	0.068	θ_{44}	0.227
θ_{15}	0.398	θ_{33}	0.356	θ_{45}	0.074
θ_{21}	0.148	θ_{34}	0.269	θ_{46}	0.145
θ_{22}	0.169	θ_{35}	0.235		

5 结论

本文提出一种基于 GAN 技术的自能源混合建模方法, 该方法由自能源网络结构的机理模型和基于 GAN 技术的参数辨识方法组成. 1) 针对自能源网络结构特点进行机理建模, 适用于具有能源双向传输的特点以及能源耦合等复杂特征的混合能源系统; 2) 针对自能源模型的数据不完备, 结构复杂等特点, 设计了基于 GAN 技术的数据、机理混合驱动方法, 应用含策略梯度反馈的 GAN 改进模型进行参数辨识, 解决了自能源模型中输出序列离散的问题; 3) 将模糊理论应用于 GAN 模型中真实数据分类, 根据自能源不同的运行工况对自能源模型进行调整, 保证了生成器产生的模型符合能源变化规律.




图 13 气压异常时自能源输出曲线
Fig. 13 Output curves of WE in abnormal gas pressure

References

- 1 Sun Qiu-Ye, Teng Fei, Zhang Hua-Guang, Ma Da-Zhong. Construction of dynamic coordinated optimization control system for energy internet. *Proceedings of the CSEE*, 2015, **35**(14): 3667–3677 (孙秋野, 滕菲, 张化光, 马大中. 能源互联网动态协调优化控制体系构建. *中国电机工程学报*, 2015, **35**(14): 3667–3677)
- 2 Sun Qiu-Ye, Teng Fei, Zhang Hua-Guang. Energy internet and its key control issues. *Acta Automatica Sinica*, 2017, **43**(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, **43**(2): 176–194)
- 3 Hu J W, Sun Q Y, Teng F. A game-theoretic pricing model for energy internet in day-ahead trading market considering distributed generations uncertainty. In: *Proceedings of the 2016 IEEE Symposium Series on Computational Intelligence (SSCI)*. Athens, Greece: IEEE, 2016. 1–7
- 4 Son S E, Lee S H, Choi D H, Song K B, Park J D, Kwon Y H, et al. Improvement of composite load modeling based on parameter sensitivity and dependency analyses. *IEEE Transactions on Power Systems*, 2014, **29**(1): 242–250
- 5 Kim J K, An K, Ma J, Shin J, Song K B, Park J D, et al. Fast and reliable estimation of composite load model parameters using analytical similarity of parameter sensitivity. *IEEE Transactions on Power Systems*, 2016, **31**(1): 663–671

- 6 Duquette J, Rowe A, Wild P. Thermal performance of a steady state physical pipe model for simulating district heating grids with variable flow. *Applied Energy*, 2016, **178**: 383–393
- 7 Behrooz H A, Boozarjomehry R B. Modeling and state estimation for gas transmission networks. *Journal of Natural Gas Science and Engineering*, 2015, **22**: 551–570
- 8 Pambour K A, Bolado-Lavin R, Dijkema G P J. An integrated transient model for simulating the operation of natural gas transport systems. *Journal of Natural Gas Science and Engineering*, 2016, **28**: 672–690
- 9 Haben S, Singleton C, Grindrod P. Analysis and clustering of residential customers energy behavioral demand using smart meter data. *IEEE Transactions on Smart Grid*, 2016, **7**(1): 136–144
- 10 Fernandes M P, Viegas J L, Vieira S M, Sousa J M. Analysis of residential natural gas consumers using fuzzy c-means clustering. In: Proceedings of the 2016 IEEE International Conference on Fuzzy Systems. Vancouver, Canada: IEEE, 2016. 1484–1491
- 11 Sun G, Cong Y, Hou D D, Fan H J, Xu X W, Yu H B. Joint household characteristic prediction via smart meter data. *IEEE Transactions on Smart Grid*, DOI: 10.1109/TSG.2017.2778428
- 12 Sun Ming-Xuan, Bi Hong-Bo. Learning identification: least squares algorithms and their repetitive consistency. *Acta Automatica Sinica*, 2012, **38**(5): 698–706
(孙明轩, 毕宏博. 学习辨识: 最小二乘算法及其重复一致性. 自动化学报, 2012, **38**(5): 698–706)
- 13 Gu Cheng-Kui, Wang Zheng-Ou. A practical method for identification nonlinear time-varying systems using basis sequences. *Systems Engineering*, 2001, **19**(4): 22–26
(顾成奎, 王正欧. 利用基序列逼近的一类非线性时变系统辨识的实用方法. 系统工程, 2001, **19**(4): 22–26)
- 14 Wang Le-Yi, Zhao Wen-Xiao. System identification: new paradigms, challenges, and opportunities. *Acta Automatica Sinica*, 2013, **39**(7): 933–942
(王乐一, 赵文斌. 系统辨识: 新的模式、挑战及机遇. 自动化学报, 2013, **39**(7): 933–942)
- 15 Yang Gang, Wang Le, Dai Li-Zhen, Yang Hui, Lu Rong-Xiu. AQPSO-based self-organization learning of RBF neural network. *Control and Decision*, DOI: 10.13195/j.kzyjc.2017.0595
(杨刚, 王乐, 戴丽珍, 杨辉, 陆荣秀. 基于 AQPSO 的 RBF 神经网络自组织学习. 控制与决策, DOI: 10.13195/j.kzyjc.2017.0595)
- 16 Qian Fu-Cai, Huang Jiao-Ru, Qin Xin-Qiang. Research on algorithm for system identification based on robust optimization. *Acta Automatica Sinica*, 2014, **40**(5): 988–993
(钱富才, 黄姣茹, 秦新强. 基于鲁棒优化的系统辨识算法研究. 自动化学报, 2014, **40**(5): 988–993)
- 17 Xu J P, Tan P N, Zhou J Y, Luo L F. Online multi-task learning framework for ensemble forecasting. *IEEE Transactions on Knowledge and Data Engineering*, 2017, **29**(6): 1268–1280
- 18 Cong Y, Sun G, Liu J, Yu H B, Luo J B. User attribute discovery with missing labels. *Pattern Recognition*, 2018, **73**: 33–46
- 19 Tang Yong. *Mathematical Model and Modeling Technology of Power Load*. Beijing: Science Press, 2012. 30–32
(汤涌. 电力负荷的数学模型与建模技术. 北京: 科学出版社, 2012. 30–32)
- 20 Zhu Jian-Quan, Li Ying, Tan Wei. Characteristic fusion based on electric load modeling. *Power System Technology*, 2015, **39**(5): 1358–1364
(朱建全, 李颖, 谭伟. 基于特性融合的电力负荷建模. 电网技术, 2015, **39**(5): 1358–1364)
- 21 Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial nets. In: Proceedings of the 2014 Conference on Advances in Neural Information Processing Systems 27. Montreal, Canada: Curran Associates, Inc., 2014. 2672–2680
- 22 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)
- 23 Zhang H, Xu T, Li H S, Zhang S T, Huang X L, Wang X G, et al. StackGAN: text to photo-realistic image synthesis with stacked generative adversarial networks. arXiv preprint arXiv: 1612.03242, 2016
- 24 Santana E, Hotz G. Learning a driving simulator. arXiv preprint arXiv: 1608.01230, 2016
- 25 Wang Fei-Yue. Software-defined systems and knowledge automation: a parallel paradigm shift from Newton to Merton. *Acta Automatica Sinica*, 2015, **41**(1): 1–8
(王飞跃. 软件定义的系统与知识自动化: 从牛顿到默顿的平行升华. 自动化学报, 2015, **41**(1): 1–8)
- 26 Qi G J. Loss-sensitive generative adversarial networks on Lipschitz densities. arXiv preprint arXiv: 1701.06264, 2017
- 27 Arjovsky M, Chintala S, Bottou L. Wasserstein GAN. arXiv preprint arXiv: 1701.07875, 2017
- 28 Nowozin S, Cseke B, Tomioka R. F-GAN: training generative neural samplers using variational divergence minimization. In: Proceedings of the 2016 Neural Information Processing Systems. Barcelona, Spain: Curran Associates, Inc., 2016. 271–279
- 29 Saito Y, Takamichi S, Saruwatari H. Statistical parametric speech synthesis incorporating generative adversarial networks. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2018, **26**(1): 84–96
- 30 Chen X, Duan Y, Houthoofd R, Schulman J, Sutskever I, Abbeel P. InfoGAN: interpretable representation learning by information maximizing generative adversarial nets. In: Proceedings of the 2016 Neural Information Processing Systems. Barcelona, Spain: Curran Associates, Inc., 2016. 2172–2180

- 31 Yu L T, Zhang W N, Wang J, Yu Y. SeqGAN: sequence generative adversarial nets with policy gradient. In: Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco, California, USA: AAAI, 2017. 2852–2858
- 32 Sun Q Y, Zhou J G, Guerrero J M, Zhang H G. Hybrid three-phase/single-phase microgrid architecture with power management capabilities. *IEEE Transactions on Power Electronics*, 2015, **30**(10): 5964–5977
- 33 Zhao Z, Chen W H, Wu X M, Chen P C Y, Liu J M. LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 2017, **11**(2): 68–75
- 34 Palangi H, Deng L, Shen Y L, Gao J F, He X D, Chen J S, et al. Deep sentence embedding using long short-term memory networks: analysis and application to information retrieval. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2016, **24**(4): 694–707
- 35 Kim Y. Convolutional neural networks for sentence classification. In: Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha, Qatar: ACL, 2014. 1746–1751
- 36 Sun Qiu-Ye, Wang Bing-Yu, Huang Bo-Nan, Ma Da-Zhong. The optimization control and implementation for the special energy internet. *Proceedings of the CSEE*, 2015, **35**(18): 4571–4580
(孙秋野, 王冰玉, 黄博南, 马大中. 狭义能源互联网优化控制框架及实现. *中国电机工程学报*, 2015, **35**(18): 4571–4580)




孙秋野 东北大学信息科学与工程学院教授. 主要研究方向为网络控制技术, 分布式控制技术, 分布式优化分析及其在能源互联网, 微网, 配电网等领域相关应用. 本文通信作者.

E-mail: sunqiuye@mail.neu.edu.cn

(**SUN Qiu-Ye** Professor at the School of Information Science and Engineering, Northeastern University. His research interest covers network control technology, distributed control technology, distributed optimization analysis and various ap-

plications in energy internet, microgrid, power distribution network. Corresponding author of this paper.)



胡旌伟 东北大学信息科学与工程学院博士研究生. 主要研究方向为博弈论及其在能源互联网, 微网, 配电网等领域相关应用.

E-mail: hjw_neu@outlook.com

(**HU Jing-Wei** Ph.D. candidate at the School of Information Science and Engineering, Northeastern University.

His research interest covers game theory and its various applications in energy internet, microgrid, power distribution network.)



杨凌霄 东北大学信息科学与工程学院博士研究生. 主要研究方向为机器学习及其在能源互联网, 微网, 配电网等领域相关应用.

E-mail: ylxiao66@163.com

(**YANG Ling-Xiao** Ph.D. candidate at the School of Information Science and Engineering, Northeastern University. Her research interest covers machine learning and its various applications in energy internet, microgrid, power distribution network.)



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: zhanghuaguang@mail.neu.edu.cn

(**ZHANG Hua-Guang** Professor at the School of Information Science and Engineering, Northeastern University. His research interest covers adaptive dynamic programming, fuzzy control, network control, and chaos control.)