

基于 GAN 的非侵入式自能源建模

孙秋野, 刘月, 胡旌伟, 胡旭光

(东北大学信息科学与工程学院, 辽宁省 沈阳市 110819)

Non-intrusive We-energy Modeling Based on GAN Technology

SUN Qiuye, LIU Yue, HU Jingwei, HU Xuguang

(School of Information Science and Engineering, Northeastern University, Shenyang 110819, Liaoning Province, China)

ABSTRACT: As the energy terminal of the Energy Internet, the model of we-energy is the basis for energy Internet optimization and dispatch. To solve the modeling problem of We-energy, this paper proposed a non-intrusive modeling method based on generative adversarial networks (GAN). First, considering the energy generation characteristics of wind turbines, photovoltaics, energy storages and coupling equipments, the non-intrusive monitoring for We-energy was realized by joint sliding and gradient separation. Furthermore, combined with the generation capacity and discrimination capacity of generation adversarial network, the improved GAN was used to deal with the time-asynchronous problem of electricity-gas-thermal data, and to classify and identify energy equipments. And a dispatching model for We-energy was established according to equipment classification. Finally, the effectiveness and accuracy of the proposed method were verified by the simulation of an energy region in the north.

KEY WORDS: we-energy; non-intrusive monitoring; generative adversarial network; modeling method; integrated energy

摘要: 自能源(we-energy)作为能源互联网的能源终端,其模型是能源互联网优化和调度的基础。该文针对自能源建模问题,提出一种基于生成式对抗网络(generative adversarial networks, GAN)的非侵入式建模方法。首先,考虑到自能源中风、光、储、耦合设备的产能特性,通过联合滑动与梯度分离实现自能源的非侵入式监测。进一步地,结合生成对抗网络的生成能力和判别能力,利用改进的GAN处理自能源中电-气-热数据时间异步问题,从而实现能源设备的分类和辨识,并在此基础上建立自能源的可调度模型。最后,以北方某能源区域作为算例进行仿真,验证所提方法的有效性和准确性。

基金项目: 国家重点研发计划项目(2018YFA0702200); 国家自然科学基金项目(62073065)。

National Key R&D Program of China (2018YFA0702200); Project Supported by National Natural Science Foundation of China (62073065).

关键词: 自能源; 非侵入式监测; 生成式对抗网络; 建模方法; 综合能源

0 引言

随着人类社会的进步和能源技术的发展,传统电力系统逐渐演化为智能电网。最近,第三次工业革命再次掀起能源领域改革的浪潮,能源互联网就此应运而生^[1]。以往研究表明,对一个复杂的大工业系统进行优化控制时,通常会将大系统分割成无数个小系统,通过对小系统进行优化控制实现大系统的优化控制,一如智能电网之于微网,能源互联网之于自能源^[2]。自能源作为一个包含电、热、气的能源自治区域,对其建模是实现自能源优化和控制的基础^[3]。

能源系统结构复杂、运行状态多样,具有较高的非线性和不确定性,对能源系统进行建模一直是国内外研究学者的研究重点^[4-7]。基于机理驱动的建模方法,通过研究能源网络和能源设备的物理表征建立模型^[4],这类侵入式建模方法需要已知自能源内部所有设备,不仅侵犯了用户的隐私,同时当用户增加设备时将影响建模的准确性。为解决机理建模带来的问题,本文采用基于数据-机理驱动的建模方法,通过对量测数据进行拟合^[7],结合机理模型的可解释性优势,建立自能源的输入-输出模型,属于非侵入式模型,相对于侵入式机理建模而言,该方法保护了用户隐私,降低了成本和部署难度,当用户设备增加时更能适应用户用能行为的改变。

目前,非侵入式建模技术仅用于家庭用电负荷,指导家庭用电^[8-9],文献[10]采用深度学习的框架,提出一种基于序列到序列和 Attention 机制的非侵入式模型。文献[11]提出一种新颖的非侵入式负

载建模方法，该方法结合设备使用模式，以提高主动负载识别和预测的性能。但是随着可再生能源的渗透^[12]，能源系统中不仅包括用电单元同时存在可再生能源和储能设备^[13]，在这种情况下，发电行为会对用电行为产生干扰和抵消，因此传统的非侵入式建模不再适用^[14-17]。同时，由于自能源端口能源监测装置对电、热、气三种能源进行数据采集时存在时间异步问题，导致无法精确对能源耦合设备进行识别，极大影响了自能源非侵入式建模的精度。

生成式对抗网络(generative adversarial networks, GAN)是 2014 年由 Goodfellow 提出的一种生成对抗模型^[18]，为了解决训练不稳定和不良竞争问题，文献[19]提出一种生成器和判别器逐层增长的训练方法，使图形由低分辨率逐步生成高清图。文献[20]应用 SAGANs 在 GAN 生成中加入 attention 机制，同时将光谱归一化应用到生成器中，提高了图形的识别精度。GAN 技术对实值、连续数据有较好的生成能力^[21-22]，而自能源采集的数据为离散序列，传统的 GAN 模型很难对其进行处理^[23]。为解决上述问题，本文将 GAN 与强化学习结合，将判别器的输出通过策略梯度直接训练策略，避免了传统 GAN 中离散数据的区分困难。使生成器具有较好的离散数据生成能力，可以对缺失数据进行填补^[24]，解决电、气、热数据时间异步问题。进一步地，本文将判别器最后一层变为全连接层^[25]，使其具有多分类功能。

基于上述分析，本文结合非侵入式建模的优势与改进的 GAN 方法，提出一种基于 GAN 的自能源非侵入式建模方法，主要创新点如下：

1) 针对含有风电、光伏、储能和耦合设备的能源自治区域，提出一种非侵入式建模方法，突破传统非侵入式建模无法识别产能行为的壁垒，实现了发-用-储-耦合设备一体化区域的非侵入式监测与建模。

2) 针对自能源端口电、气、热数据缺失以及不同步问题，提出一种改进的 GAN 方法，通过策略梯度训练生成器，并将判别器最后一层改为全连接层，实现了自能源设备的识别与分类。

3) 根据 GAN 输出结果，以经济性和用户舒适度为最优调度目标构建自能源可调度模型。

本文组织方式如下：第 1 节建立非侵入式建模流程，通过神经网络和滑动窗提取风电、光伏、储能和耦合设备特性；第 2 节提出改进的 GAN 方法

对自能源内部设备进行识别并建立自能源可调度模型；第 3 节对所提出方法进行仿真和验证；第 4 节得出结论。

1 自能源的非侵入式监测与识别

1.1 问题描述

自能源是集发-用-储-耦合设备于一体的能源自治区域^[3]，类似互联网中的自媒体，是能源互联网的能源终端，不同于综合能源系统，自能源具有全双工特性。该区域主要包括风力发电、光伏发电、电储能、电锅炉、微燃气轮机、用能设备等。其结构如图 1 所示。

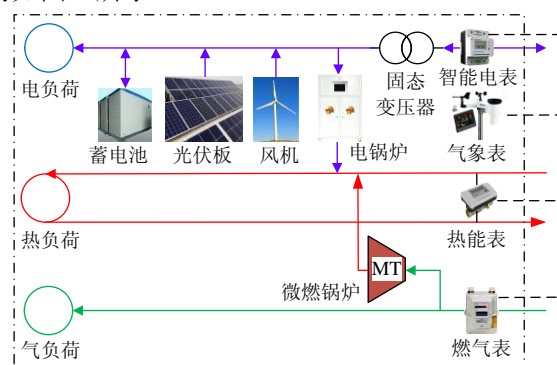


图 1 自能源结构图形

Fig. 1 We-energy structure graphic

能源互联网中，能源管理者通过制定能源价格、市场机制和控制方法等措施对网络中所有的自能源进行能量管理，确保供需平衡、能源质量符合标准，自能源作为能源互联网中的能源终端，对内表现为根据能源市场机制自主控制和优化，对外表现为自能源端口涉及所有能源设备运行情况的叠加。为了精准的对自能源进行管理和控制，需要采集其内部设备数据，根据数据对其进行特性分析和建模。自能源内部设备众多，通过大量的安装智能仪表来收集设备数据、分析设备数据会耗费大量的人力物力，因此采用非侵入式的方式对自能源系统进行数据采集和设备监测。

考虑到自能源中可再生能源和储能设备均具有发电特性，其发电行为会抵消部分负荷的用电行为，同时，可再生能源的随机波动会对其他设备的识别精度造成影响，因此，本文主要采用梯度分离的方式对自能源系统进行非侵入式建模，如图 2 所示。步骤如下：

1) 数据采集：通过智能仪表采集电端口功率数据 P_E 、热端口功率数据 P_H 、气端口功率数据 P_Q 、风速 v 、辐照幅度 M 、温度 T ；

2) 数据处理：对采集到的数据进行去噪和归

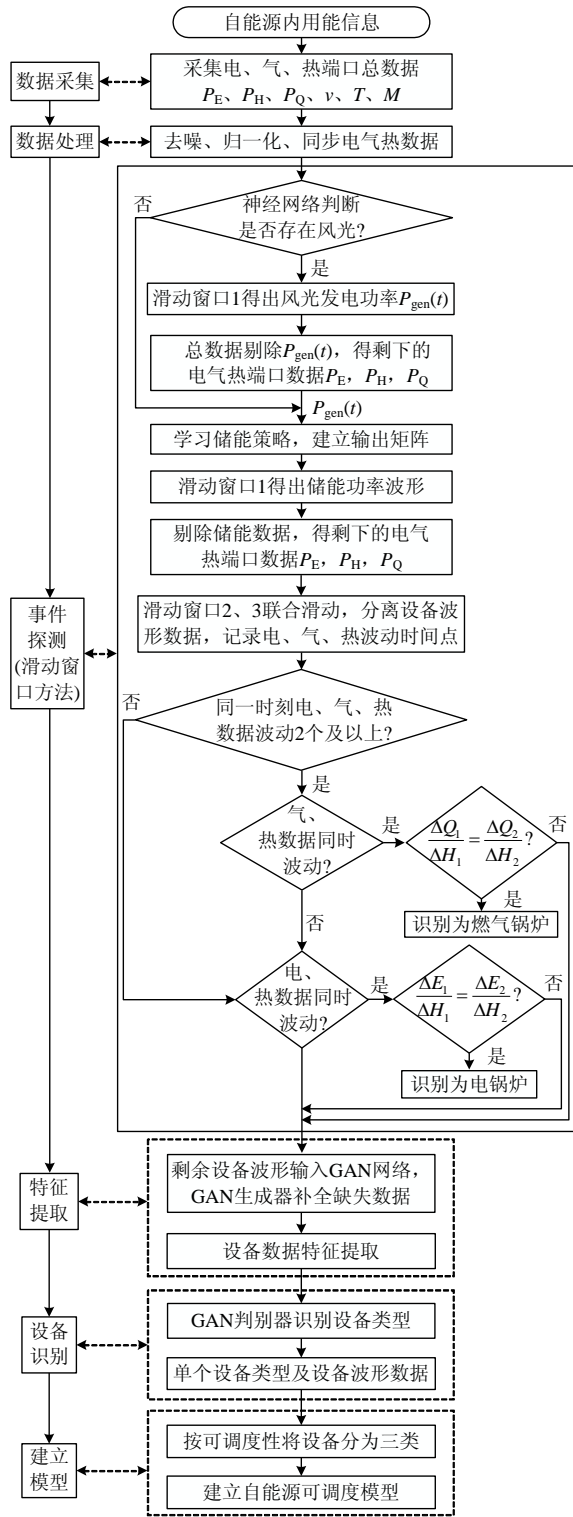


图2 非侵入式建模流程图

Fig. 2 Non-intrusive modeling flowchart

一化处理,进一步地,利用第2节改进的GAN对数据进行同步;

3) 事件探测: 利用神经网络和联合滑动方法对风电、光伏、储能、耦合设备的模型进行识别;

3) 特性提取: 将分离的数据输入GAN网络,训练生成器生成更多的数据,进行设备特征提取;

4) 设备识别: 将生成的完备的数据输入改进

的判别器中进行设备识别。最终识别自能源系统中的电、气、热的所有设备。

5) 建立模型: 按可调度性将设备进行分类,建立自能源调度模型。

1.2 联合滑动方法

为了准确识别自能源中的产能行为,本文提出一种联合滑动的方法分离风电、光伏、储能和耦合设备。如图3所示,窗口1对气象数据、电端口输出功率和电价数据进行滑动,用于识别风电、光伏和储能设备,窗口2对气热数据进行联合滑动,用于识别燃气锅炉,窗口3对电热数据进行联合滑动,用于识别电锅炉,窗口长度 m 取值为5,时间窗口提取的信息在时刻 t 算法所提取的功率序列表示为

$$\begin{cases} P_E(t) = \{P_E(t-m), p \cdot t, E_{PB} + t(-m) \\ P_H(t) = \{P_H(t-m), p \cdot t, H_{PB} + t(-m) \\ P_Q(t) = \{P_Q(t-m), q \cdot t, Q_{PB} + t(-m) \end{cases} \quad (1)$$

式中: $P_E(t)$ 为电端口功率时间序列; $P_H(t)$ 为热端口功率时间序列; $P_Q(t)$ 为气端口时间功率序列; $k=1,2,\dots,n$, n 为数据集中数据点的总个数。通过时间窗口按采样间隔 T 向后滑动,可以将数据转化为若干时间功率序列。

在窗口滑动过程中,提取窗口内功率序列的最大值和最小值,若两者差值超过设定阈值则判定此时有设备切入/切出,并提取该时刻差值作为该设备运行功率。为避免人工设定阈值的片面性,本文采




图3 联合滑动窗口示意图形

Fig. 3 Schematic diagram of linked sliding window

用长短时记忆网络来训练神经网络的参数，从而获得最优阈值。

1.3 可再生能源发电识别

可再生能源发电受天气影响，具有较强的随机性和波动性，在自能源中其发电行为与用电行为相互抵消，造成其它设备识别难度大、精度低等问题，因此需研究风光发电特性以对风光进行精确识别，风电和光伏特性分析和识别步骤如下：

1) 风光存在识别：将风速 v 、光照幅度 M 、温度 T 、总功率 P_i 数据输入神经网络中进行训练，输出为矩阵 $[c_1 c_2 c_3 c_4]$ ，矩阵由 0 和 1 组成。输出矩阵中 $c_1=1$ 时数据中存在光伏不存在风电， $c_2=1$ 时数据中存在风电不存在光伏， $c_3=1$ 时数据中不存在光伏和风电， $c_4=1$ 时数据中存在光伏和风电；

2) 确定风电和光伏的发电功率，风力发电和光伏发电模型^[26]如下：

$$P_{WT}(t) = k_4 v^3 \quad (2)$$

$$P_{PV}(t) = k_1 G^2(t) + k_2 T(t)G(t) + k_3 G(t) \quad (3)$$

式中： P_{WT} 为风电出力； P_{PV} 为光伏出力； v 为风速； G 为太阳光辐照强度； T 为温度； k_1 、 k_2 、 k_3 、 k_4 为比例系数。

将窗口 1 记录风速变化 Δv 和总功率数据变化 ΔP 代入式(2)，计算 k_4 ，计算结果概率最大的数值为 k_4 的唯一解。将 k_4 代回式(2)计算风力发电的发电功率。光伏发电的参数计算方法与风力发电类似，将幅度变化 ΔM 、温度变化 ΔT 、总功率变化 ΔP 代入式(3)求出 k_1 、 k_2 、 k_3 的唯一解。

3) 建立发电设备功率模型，建立总发电功率与风速、光伏的关系：

$$P_{gen}(t) = k_1 G^2(t) + k_2 T(t)G(t) + k_3 G(t) + k_4 v^3 \quad (4)$$

1.4 储能识别

自能源中蓄电池兼具用电和发电特性，其充放电行为由可再生能源的发电量 $P_{gen}(t)$ 、端口输出功率 $x(t)$ 和电价 $p(t)$ 决定。同时各自能源不同的储能策略会造成不同的充放电行为，导致无法通过一个统一储能策略对所有自能源进行储能识别。因此，本文采用神经网络学习自能源的储能策略，从而实现储能行为的识别。储能设备识别过程如下：

1) 学习储能策略：将储能行为按充放电功率大小分为 k 类， $P_{gen}(t)$ 在 $[0, \max(P_{gen}(t))]$ 区间分为 n 类， $x(t)$ 在 $[x_{\min}, x_{\max}]$ 区间分为 m 类， $p(t)$ 在 $[\min(p(t)), \max(p(t))]$ 区间分为 l 类，上述分类满足 $k \leq n \times m \times l$ ，

将 $n \times m \times l$ 种情况作为储能设备的决策变量输入 BP 神经网络进行训练；

2) 建立输出矩阵：输出矩阵 $[c_1 c_2 c_3]$ 由 0 和 1 组成，其中 $c_1=1$ 时储能充电， $c_2=1$ 时储能放电， $c_3=1$ 时储能不工作；

3) 分离储能波形：窗口 1 记录输出矩阵变化时刻 $[t_1, t_2, \dots, t_n]$ ，并计算这些时刻端口输出功率差值作为储能波形。

1.5 耦合设备识别

自能源中耦合设备主要包括电锅炉和燃气锅炉，电锅炉消耗电能产生热能，其工作时会引起电热数据波动，燃气锅炉消耗气能产生热能，其工作时会引起气热数据波动。单一窗口滑动不能精准的识别耦合设备，为解决识别精度问题，本文采用多窗口联合滑动的方法对耦合设备进行识别。根据窗口数据同时发生波动的类型来判断耦合设备的种类。

自能源中，燃气锅炉通过消耗气能产生热能其单位时间内所产生的热能与进气量的关系为：

$$P_{H,MT} = \eta_{g2h} H_u \dot{m}_g \quad (5)$$

式中： $P_{H,MT}$ 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 为天然气热值； \dot{m}_g 为进气量。

电锅炉消耗电能产生热能，输入电功率为 $P_{E,EB}$ 时，其热功率 $P_{Q,EB}$ 表达式如下：

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

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

电转热、气转热实质上均为通过消耗电能、天然气对锅炉内炉水加热的过程，水温升高到一定温度会消耗一定的时间，即能源转换设备在运行过程中存在一定的延时。根据热量公式可知：

$$\tau = Cm\Delta t / \eta P_H \quad (7)$$

式中： τ 为延时时间； C 为比热容； m 为电锅炉内筒炉水质量； Δt 为温差； η 为热效率； P_H 为热功率。

窗口 2 和窗口 3 对 P_E 的波动时间点进行记录，形成时间矩阵 $T_E=[te_1, te_2, \dots, te_x]$ ，对 P_Q 的波动时间点进行记录形成时间矩阵 $T_Q=[tq_1, tq_2, \dots, tq_n]$ ，对 P_H 的波动时间点进行记录形成时间矩阵 $T_H=[th_1-\tau, th_2-\tau, \dots, th_m-\tau]$ 。耦合设备分类判定：

$$\begin{cases} T_Q = T_H \cap \frac{\Delta Q_1}{\Delta H_1} = \frac{\Delta Q_2}{\Delta H_2}, & t \text{时刻为燃气锅炉} \\ T_E = T_H \cap \frac{\Delta E_1}{\Delta H_1} = \frac{\Delta E_2}{\Delta H_2}, & t \text{时刻为电锅炉} \end{cases} \quad (8)$$

当 $T_Q=T_H$ 并且前一时刻 ΔQ (气值变化)与 ΔH (热值变化)的比值与此刻气热数据波动的比值相等时判定为燃气锅炉波动,对波动时间点进行记录形成时间矩阵 $T_W=[t_1,t_2,\dots,t_c]$, 根据 T_W 将燃气锅炉在气热中的波形变化分离并识别出来。当 $T_E=T_Q$ 时并且前一时刻 ΔE (电值变化)与 ΔH (热值变化)与此刻电热数据波动的比值相等时判定为电锅炉数据波动,对波动时间点进行记录形成时间矩阵 $T_{EH}=[t_1,t_2,\dots,t_x]$, 根据 T_{EH} 将电锅炉在电气热中的波形变化分离并识别出来。

2 识别及建模方法

2.1 生成式对抗网络

自能源存在电、气、热 3 种形式能源, 由于 3 种能源采集频率不同, 电端口采样周期为 9s/个, 热端口为 3min/个, 气端口为 5min/个, 而公共数据集数据采样周期为 3s/个, 在进行联合扫描时由于采集数据不同步将直接影响非侵入式识别精度和建模的准确度。

GAN 主要由生成器 G(generator)和判别器 D(discriminator)组成, 生成器用于生成数据, 判别器用于判断生成的数据是否真实。

本文利用 GAN 的数据生成能力对电、气、热数据进行填补和同步, 如图 4 所示, 将分离的各个设备数据输入 GAN 网络, 通过生成器对数据缺失部分进行补全, 判别器对补全的设备数据进行分类

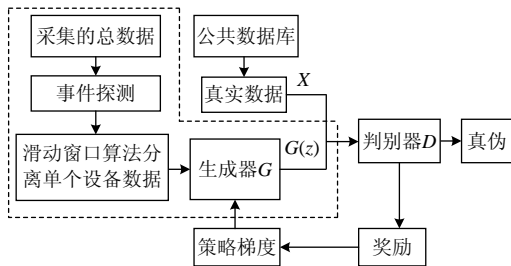


图 4 GAN 网络模型

Fig. 4 GAN network model

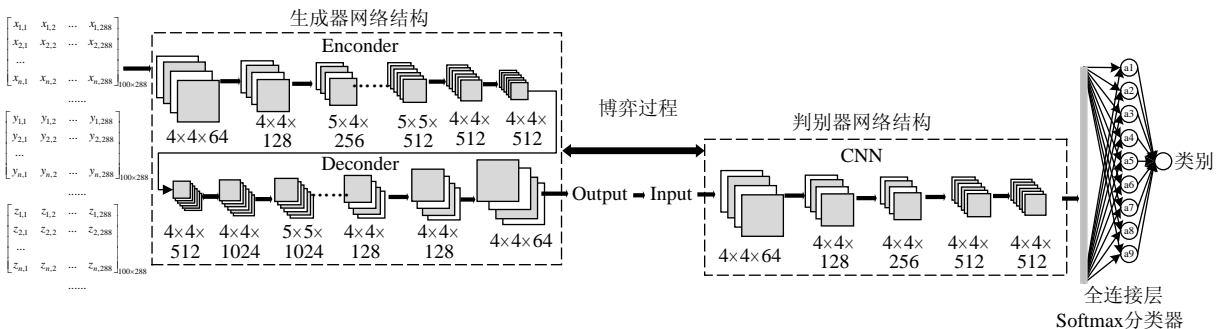


图 5 GAN 生成识别网络层数设置

Fig. 5 GAN generation recognition network layer setting

处理, 从而提高设备识别精度和模型建立准确度。

传统的 GAN 将随机变量作为生成器的输入值, 对设备数据缺失部分进行补全, 这种方法准确度不高、生成速度慢。本文将滑动窗口算法分离的各个设备的数据作为为了生成器的输入, 通过内部网络生成数据, 从而提高了数据生成速度和识别精度。同时, 本文将判别器最后一层改为 softmax 全连接层, 用于实现负荷识别。GAN 生成识别网络层数设置如图 5 所示。

生成对抗网络表达式如下:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (9)$$

式中: 在 $E_{x \sim P_{data}(x)} [\log D(x)]$ 中, x 表示设备的真实样本, $D(x)$ 表示 x 通过判别网络判断其为真实样本的概率; $E_{z \sim P_z(z)} [\log(1 - D(G(z)))]$ 中, z 表示输入生成器的随机样本, $G(z)$ 表示生成网络由随机样本 z 生成的样本, $D(G(z))$ 表示生成样本通过判别网络后, 判断其为真实样本的概率。

GAN 只能给出整个连续序列的得分/损失, 而本文数据为离散数据, 其不能评估当前生成的数据的好坏和对后面生成的影响, 强化学习恰好能解决 GAN 存在的问题^[27], 因此本文采用强化学习与 GAN 结合的方法来训练模型, 生成模型被视为强化学习的媒介, 其状态是到目前为止已生成的序列, 而动作是要生成的下一个序列。根据工作要求的特定任务的序列得分来给予不同的奖励, 采用了判别器来评估序列并反馈评估以指导学习生成模型。为了解决输出离散时梯度不能返回到生成模型的问题, 将生成模型视为一种随机参数化策略。在策略梯度中, 采用蒙特卡洛(Monte Carlo, MC)搜索来近似状态作用值。通过策略梯度直接训练策略(生成模型), 避免了传统 GAN 中离散数据的区分困难。

Softmax 回归代价函数：

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=0}^n \theta_{ij}^2 \quad (10)$$

式中： $1\{\cdot\}$ 为示性函数，运算法则： $1\{\text{表达式的值为真}\}=1$ ， $1\{\text{表达式的值为假}\}=0$ ， $\frac{e^{\theta_j^T x^{(i)}}}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}}$ 为在

Softmax 回归中将样本 x 分类为类别 j 的概率， $\frac{\lambda}{2} \sum_{i=1}^m \sum_{j=0}^n \theta_{ij}^2$ 代价函数中增加一个衰减项，其会对过大的参数进行惩罚。

代价函数越小，模型训练精度越高，此代价函数为凸函数，为防止优化过程陷入局部收敛，可以得到最优解，代价函数梯度公式：

$$\nabla_{\theta_j} J(\theta) = -\frac{1}{m} \sum_{i=1}^m [x^{(i)} (1\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta))] + \lambda \theta_j \quad (11)$$

通过最小化代价函数 $J(\theta)$ ，可以实现 softmax 回归分类模型。

2.2 自能源系统可调度模型

GAN 识别出的设备中存在大量可控设备，如空调、电暖气、电热水器、电冰箱、耦合设备、储能设备等，这些设备工作方式灵活可控、分布空间广泛，具有较大的可调度潜力。同时，在以激励为基础的能源互联网调度中，对自能源中一些允许运营商直接控制的设备进行合理调度，可以达到优化负荷波形、消峰平谷等目的。本文在对自能源进行非侵入式监测的基础上，建立了自能源调度模型，相比传统的能源系统模型，可以更精准地识别、调控自能源中可控设备。通过分析自能源用能规律和设备特征，发现一部分设备用能行为无规律，具有随机性，属于不可控设备，而一部分设备用能行为规律，可以根据能源价格、奖励激励和供需关系进行适当平移和调节。设备按可调度性可分为以下 3 类：

1) 不可调度设备：主要包括不可平移和不可调节的负荷设备。例如风力发电、光伏发电、电视、夜间照明灯等。

2) 可平移设备：在一天中，可平移电负荷总用电量不变，只是改变设备的用电时间段，例如洗碗机、消毒柜等。

3) 可调节设备：在用户设定的可调节程度范围内，可调节设备可以被动调节功率大小。例如耦合设备(电锅炉、燃气锅炉)、储能设备、空调等。

在自能源运行过程中，自能源的经济性、用户舒适度、可再生能源的利用率等均为可调度影响因素，本文考虑经济性和用户舒适度对自能源设备运行的影响，建立自能源可调度模型：

$$P_{WE}(t) = (1 - \lambda_1) \underbrace{\begin{bmatrix} -P_{\text{gen}}(t) + \Sigma P_{\text{load}}^{\text{un,e}}(t) \\ \Sigma P_{\text{load}}^{\text{un,h}}(t) \\ \Sigma P_{\text{load}}^{\text{un,g}}(t) \end{bmatrix}}_{\text{unadjustable and uncuttable}} + \underbrace{\begin{bmatrix} \lambda_{\text{pan}}^e \Phi_{\text{pan}}^e P_{\text{load}}^{\text{pan,e}}(t) \\ \lambda_{\text{pan}}^h \Phi_{\text{pan}}^h P_{\text{load}}^{\text{pan,h}}(t) \\ \lambda_{\text{pan}}^g \Phi_{\text{pan}}^g P_{\text{load}}^{\text{pan,g}}(t) \end{bmatrix}}_{\text{Panable}} + \underbrace{\begin{bmatrix} \lambda_{\text{adj}}^e \Phi_{\text{adj}}^e (P_{\text{es}}(t) + P_{\text{load}}^{\text{adj,e}}(t)) \\ \lambda_{\text{adj}}^h \Phi_{\text{adj}}^h P_{\text{load}}^{\text{adj,h}}(t) \\ \lambda_{\text{adj}}^g \Phi_{\text{adj}}^g P_{\text{load}}^{\text{adj,g}}(t) \end{bmatrix}}_{\text{adjustable}} \quad (12)$$

式中： $P_{\text{load}}^{\text{un,e}}(t)$ 、 $P_{\text{load}}^{\text{un,h}}(t)$ 、 $P_{\text{load}}^{\text{un,g}}(t)$ 为不可调度电、气、热负荷； $P_{\text{load}}^{\text{adj,e}}(t)$ 、 $P_{\text{load}}^{\text{adj,h}}(t)$ 、 $P_{\text{load}}^{\text{adj,g}}(t)$ 为可调节电、气、热负荷； $P_{\text{load}}^{\text{pan,e}}(t)$ 、 $P_{\text{load}}^{\text{pan,h}}(t)$ 、 $P_{\text{load}}^{\text{pan,g}}(t)$ 为可平移电负荷、气负荷、热负荷； $\Phi_{\text{adj}} \lambda_{\text{adj}} = [\Phi_{\text{adj}}^1, \Phi_{\text{adj}}^2, \dots]$ $[\lambda_{\text{adj}}^1, \lambda_{\text{adj}}^2, \dots]$ 为可调节系数矩阵； $\Phi_{\text{pan}} \lambda_{\text{pan}} = [\Phi_{\text{pan}}^1, \Phi_{\text{pan}}^2, \dots]$ $[\lambda_{\text{pan}}^1, \lambda_{\text{pan}}^2, \dots]$ 为可平移系数矩阵。矩阵中元素 Φ_{adj} 、 $\Phi_{\text{pan}} \in [0, 1]$ ， λ_{adj} 、 $\lambda_{\text{pan}} \in [0, 1]$ ， λ_1 为 0。

根据式(12)建立基于用户满意度的目标函数为：

$$\max F = \min_{\lambda} \max_{\Phi} \sum_{t=1}^{24} P_{\text{pan}}(t)(p(t)\phi_{\text{pan}} + \lambda_{\text{pan}}) + P_{\text{adj}}(t)(p(t)\phi_{\text{adj}} + \lambda_{\text{adj}}) \quad (13)$$

式中：总满意度 F 是指综合考虑用电舒适度和经济度，可利用用电舒适度和经济度的乘积表示； $P_{\text{pan}}(t)$ 为可平移负荷总量； $P_{\text{adj}}(t)$ 为可调节负荷总量； Φ 对应由能源价格(经济性)为目标的调度参数矩阵； λ 对应由舒适度为目标的调度参数矩阵。

3 算例分析

为了验证本文方法在自能源系统设备非侵入式识别与建模中的应用效果，本文选取了中国北方一别墅区进行训练和测试，选取 90 家别墅的电、气、热数据作为训练集，选取另外 10 家别墅作为测试集，训练集别墅包括风机、光伏、电储能、冰箱、空调、洗碗机、洗衣机、供水暖气、电锅炉、燃气灶、燃气锅炉等设备。测试别墅分解得到各个设备在每个时刻的功率(或者热量)选取别墅 91 进行仿真展示。

3.1 生成与分解结果

图 6 为不可调度设备数据库数据和识别数据的对比曲线，识别值和数据库值基本吻合，说明算法分离识别的精确度高。

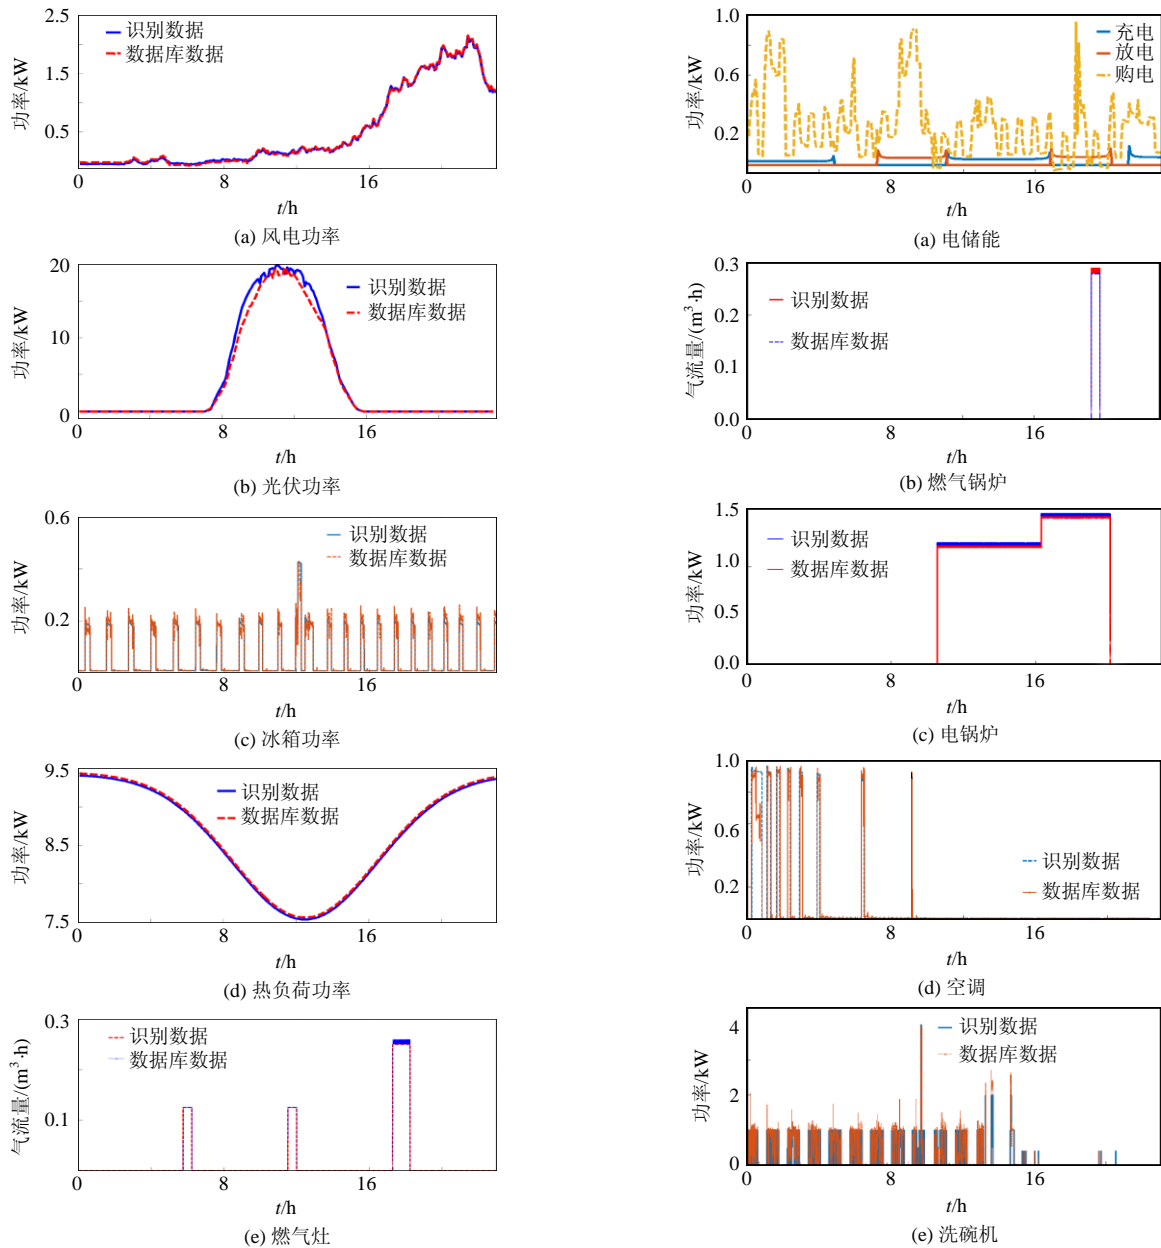


图6 不可调度设备真实与识别数值对比图形
 Fig. 6 Non-schedulable device real and recognition value comparison graph

图7为可调度设备的数据库数据和识别数据的对比曲线,图(a)为运用储能设备的决策变量进行储能行为的识别的电储能的充放电功率。购电量较大时,蓄能电池放电,购电量较低时,蓄能电池充电。

图8为生成器和判别器的损失函数随训练次数增加而变化的情况。从图8可以看出生成器和判别器的损失函数随着训练次数的增加,2个图都呈现下降的趋势,训练中都出现大幅度振荡,这是生成器和判别器进行对抗的结果。

3.2 评价指标

为了对分解算法进行全面的评价,本文选取了4个参数作为评价算法的指标,分别为准确度、召




图7 可调度设备真实与识别数值对比图形
 Fig. 7 Dispatch equipment real and identification value comparison

回率、F1分数、平均绝对误差,其具体计算方法如下所示:

$$P_{RE} = \frac{T_P}{T_P + F_P} \quad (14)$$

$$R_{EC} = \frac{T_P}{T_P + F_N} \quad (15)$$




图 8 GAN 网络损失函数图形

Fig. 8 GAN network loss function graph

$$F1 = 2 \times \frac{P_{RE} \times R_{EC}}{P_{RE} + R_{EC}} \quad (16)$$

表 1 别墅 1 设备识别的不同辨识算法评价指标

Tab. 1 Algorithm evaluation index of different identification algorithms for villa 91 equipment identification

可调度性		不可调度设备					可调度设备					
指标	方法	风电	光伏	冰箱	供水暖气	燃气灶	电储能	燃气锅炉	电锅炉	空调	洗衣机	洗碗机
PRE	GAN	0.998	0.967	0.999	0.991	0.998	0.985	0.996	0.993	0.784	0.926	0.991
	CNN	0.975	0.941	0.998	0.952	0.954	0.953	0.954	0.934	0.767	0.921	0.990
	LSTM	0.952	0.215	0.978	0.932	0.634	0.964	0.931	0.967	0.775	0.919	0.865
REC	GAN	0.971	0.984	0.972	0.987	0.985	0.995	0.993	0.995	0.766	0.768	0.833
	CNN	0.820	0.925	0.850	0.921	0.629	0.932	0.931	0.958	0.605	0.608	0.701
F1 分数	LSTM	0.850	0.821	0.862	0.852	0.537	0.964	0.914	0.931	0.612	0.634	0.739
	GAN	0.993	0.995	0.994	0.998	0.982	0.995	0.994	0.997	0.796	0.826	0.859
	CNN	0.981	0.982	0.989	0.993	0.837	0.925	0.947	0.951	0.790	0.739	0.789
MAE	LSTM	0.921	0.959	0.951	0.924	0.764	0.936	0.836	0.834	0.786	0.810	0.762
	GAN	0.960	0.931	0.964	0.951	0.962	0.963	0.937	0.934	3.001	2.236	2.012
	CNN	1.012	1.825	1.954	1.257	1.653	1.687	1.365	1.258	5.324	2.312	2.659
LSTM	0.022	1.523	1.966	1.349	1.954	1.364	1.347	1.147	4.365	2.358	2.719	

由表 1 可知，本文提出的 GAN 分解识别方法在各种设备上都取得了很好的判别效果，4 个判别精确度指标 P_{RE} 、 R_{EC} 、 $F1$ 分数、 M_{AE} 明显优于其他 2 种分类识别算法。

为验证本文建立模型的准确性，本文对别墅 91~别墅 100 进行了仿真验证的测试，表 2 列举了别墅 91、别墅 95、别墅 100 的验证结果，结果证明模型精确度均在 90% 以上，验证了模型的准确性。

本文对别墅 91 根据电价、热价、气价的变化进行了调度，用户设定可调节设备的舒适度矩阵 $\lambda=[\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6]=[0.8, 0.6, 0.5, 0.2, 1, 1]$ ，调度前后对比数据曲线如图 9 所示。

由图 9 可以看出：电网络设备调度时段在

$$M_{AE} = \frac{1}{T_1 - T_0} \sum_{t=T_0}^{T_1} \text{abs}(y_{t_2} - y_t) \quad (17)$$

式中： P_{RE} 为精确度； P_{EC} 为召回率； $F1$ 代表 $F1$ 分数，也叫平衡分数； T_P 表示设备实际处于工作状态且算法分解结果也为工作状态的序列总点数； F_P 表示设备实际处于工作状态但是算法分解结果为非工作状态的序列总点数； F_N 表示用电器实际未工作但算法分解结果为在工作状态的序列点总数 y_t 为 t 时刻设备的真实功率； y_{t_2} 为 t 适合模型分解的设备功率； M_{AE} 为时间段 T_0 到 T_1 内功率分解值的平均绝对误差。

P_{RE} 、 P_{EC} 、 $F1$ 分数反映算法判断设备处于工作状态的准确度， M_{AE} 反映模型分解功率值的准确性。

以别墅 91 为例，将提出的 GAN 算法和传统的 CNN、LSTM 设备分类识别方法进行比较。如表 1 所示。

表 2 3 个别墅验证模型准确度评价指标

Tab. 2 Evaluation index of accuracy of three villa verification models

房屋	可调整性	数据库功率/W	模型功率/W	精确度
别墅 91	可调节	1600	1562	0.9763
	可削减	900	834	0.9267
	可平移	500	501	0.9980
	不可调整	12200	11000	0.9527
别墅 95	可调节	1586	1511	0.9527
	可削减	862	854	0.9907
	可平移	532	500	0.9398
	不可调整	12040	12127	0.9928
别墅 100	可调节	1482	1500	0.9880
	可削减	763	759	0.9947
	可平移	552	513	0.9293
	不可调整	13024	13651	0.9541




图9 电气热网络调度前后用能情况对比

Fig. 9 Comparison of energy consumption before and after electrical thermal network dispatching

08:00—11:30、17:00—20:00、20:00—5:00(次日)、3个时段,3个时段中第一调度时段电价为0.3838元/kWh、第二和第三调度时段电价为1.3963元/kWh,未调度时段电价依次为5:00—08:00、11:30—17:00,电价为0.8775元/kWh。别墅91的24h调度前电费合计为17.813元,调度后电费合计为12.174元。花费减少了31.7%。

热网设备调度时段在08:00—12:00、17:00—20:30、20:30—5:00(次日)3个时段,3个时段中第一调度时段热价为0.3元/kWh、第二和第三调度时段热价为0.2元/kWh,热价未调度时段依次为5:00—8:00、12:00—17:00,热价为0.25元/kWh。别墅91的24h调度前热费合计为38.65元,调度后热费合计为36.55元。花费减少了5.4%。

气网设备调度时段在17:00—20:30、20:30—5:30(次日),2个时段中第一调度时段气价为2.63元/m³、第二调度时段气价为0.3元/m³,气价未调度时段为5:30—17:00,气价为2.85元/m³。别墅91的24h调度前气费合计为1.204元,调度后气费合计为1.198元。花费减少了0.5%。

电网络在20:00电价低,热价高,此时电锅炉投入使用,将电能转化为热能,为用户供暖需要,由于电转热过程存在延时故热数据在20:27产生波动。气网络在20:30气价低,热价高,此时微燃气轮机投入使用,将气能转化为热能,气转热过程存在延时故热数据在21:08产生波动。

4 结论

本文针对含有风电、光伏、储能、耦合设备的能源自治区域—自能源进行非侵入式建模,提出一种基于GAN的非侵入建模方法,相比于传统的非侵入式负荷建模,该方法通过神经网络对自能源中风电、光伏、储能、耦合设备进行特性分析、特征提取,联合滑动窗口方法进行梯度分离,实现了自能源非侵入式监测。进一步地,利用GAN生成器生成更多数据,解决了电-气-热数据时间异步问题,利用判别器对生成数据进行分类识别,提高了设备的识别精度。在此基础上,将自能源系统设备分为了不可调度、可平移、可调节3种类型,建立了自能源的可调度模型。最后,本文以北方某能源区域作为算例进行仿真,验证了所提方法和所建模型的有效性和准确性,并与基于CNN和LSTM的监测方法进行对比,结果表明本文所提方法在精确度、召回率、F1分数和MAE方面具有明显优势。

参考文献

- [1] Lin Chuncheng, Deng D J, Kuo C C, et al. Optimal charging control of energy storage and electric vehicle of an individual in the internet of energy with energy trading[J]. IEEE Transactions on Industrial Informatics, 2018, 14(6): 2570-2578.
- [2] Sun Qiuye, Fan Ruyi, Li Yushuai, et al. A distributed double-consensus algorithm for residential we-energy [J]. IEEE Transactions on Industrial Informatics, 2019, 15(8): 4830-4842.
- [3] 孙秋野, 胡旌伟, 张化光. 能源互联网中自能源的建模与应用[J]. 中国科学: 信息科学, 2018, 48(10): 1409-1429.
Sun Qiuye, Hu Jingwei, Zhang Huaguang. Modeling and application of we-energy in energy Internet[J]. Scientia Sinica Informationis, 2018, 48(10): 1409-1429(in Chinese).
- [4] Duquette J, Rowe A, Wild P. Thermal performance of a steady state physical pipe model for simulating district heating grids with variable flow[J]. Applied Energy, 2016, 178: 383-393.
- [5] Son S E, Lee S H, Choi D H, et al. Improvement of composite load modeling based on parameter sensitivity and dependency analyses[J]. IEEE Transactions on Power Systems, 2014, 29(1): 242-250.
- [6] Tahir M F, Chen Haoyong, Mehmood K, et al. Integrated energy system modeling of China for 2020 by incorporating demand response, heat pump and thermal storage[J]. IEEE Access, 2019, 7: 40095-40108.
- [7] Gu Zhifeng, Xu Bin, Li Juanzi. Service data correlation modeling and its application in data-driven service

- composition[J]. IEEE Transactions on Services Computing, 2010, 3(4): 279-291.
- [8] Hannan M A, Faisal M, Ker P J, et al. A review of internet of energy based building energy management systems: issues and recommendations[J]. IEEE Access, 2018, 6: 38997-39014.
- [9] Han J, Choi C S, Park W K, et al. Smart home energy management system including renewable energy based on ZigBee and PLC[J]. IEEE Transactions on Consumer Electronics, 2014, 60(2): 198-202.
- [10] 王轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解[J]. 中国电机工程学报, 2019, 39(1): 75-83.
Wang Ke, Zhong Haiwang, Yu Nanpeng, et al. Nonintrusive load monitoring based on Sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE, 2019, 39(1): 75-83(in Chinese).
- [11] Welikala S, Dinesh C, Ekanayake M P B, et al. Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 448-461.
- [12] Fletscher L A, Suárez L A, Grace D, et al. Energy-aware resource management in heterogeneous cellular networks with hybrid energy sources[J]. IEEE Transactions on Network and Service Management, 2019, 16(1): 279-293.
- [13] Zhang Huaguang, Li Yushuai, Gao D W, et al. Distributed optimal energy management for energy internet[J]. IEEE Transactions on Industrial Informatics, 2017, 13(6): 3081-3097.
- [14] Dong Ming, Meira P C M, Xu W, et al. Non-intrusive signature extraction for major residential loads[J]. IEEE Transactions on Smart Grid, 2013, 4(3): 1421-1430.
- [15] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.
Cheng Xiang, Li Linzhi, Wu Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117(in Chinese).
- [16] 王轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解[J]. 中国电机工程学报, 2019, 39(1): 75-83.
Wang Ke, Zhong Haiwang, Yu Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE, 2019, 39(1): 75-83(in Chinese).
- [17] Welikala S, Dinesh C, Ekanayake M P B, et al. Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 448-461.
- [18] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Proceedings of the 2014 Conference on Advances in Neural Information Processing Systems 27. Montreal, Canada: Curran Associates, Inc., 2014: 2672-2680.
- [19] Guo Xiaopeng, Nie Rencan, Cao Jinde, et al. FuseGAN: learning to fuse multi-focus image via conditional generative adversarial network[J]. IEEE Transactions on Multimedia, 2019, 21(8): 1982-1996.
- [20] Wang Xiangyang, Cao Zhongzheng, Wang Rui, et al. Improving human pose estimation with self-attention generative adversarial networks[J]. IEEE Access, 2019, 7: 119668-119680.
- [21] Zhang Han, Xu Tao, Li Hongsheng, et al. StackGAN: Text to photo-realistic image synthesis with stacked generative adversarial networks[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2016.
- [22] Santana E, Hotz G. Learning a driving simulator[J]. arXiv preprint arXiv: 1608. 01230, 2016.
- [23] 王守相, 陈海文, 潘志新, 等. 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[J]. 中国电机工程学报, 2019, 39(1): 56-64.
Wang Shouxiang, Chen Haiwen, Pan Zhixin, et al. A reconstruction method for missing data in power system measurement using an improved generative adversarial network[J]. Proceedings of the CSEE, 2019, 39(1): 56-64(in Chinese).
- [24] Pan Zhaoqing, Yu Weijie, Yi Xiaokai, et al. Recent progress on generative adversarial networks(GANs): a survey[J]. IEEE Access, 2019, 7: 36322-36333.
- [25] 唐贤伦, 杜一铭, 刘雨微, 等. 基于条件深度卷积生成对抗网络的图像识别方法[J]. 自动化学报, 2018, 44(5): 855-864.
Tang Xianlun, Du Yiming, Liu Yuwei, et al. Image recognition with conditional deep convolutional generative adversarial networks[J]. Acta Automatica Sinica, 2018, 44(5): 855-864(in Chinese).
- [26] Mahmoud Y, El-Saadany E. Accuracy improvement of the ideal PV model[J]. IEEE Transactions on Sustainable Energy, 2015, 6(3): 909-911.
- [27] Ye Dayong, Zhang Minjie, Sutanto D. A hybrid multiagent framework with Q-learning for power grid systems restoration[J]. IEEE Transactions on Power Systems, 2011, 26(4): 2434-2441.



孙秋野

在线出版日期: 2020-10-10。

收稿日期: 2020-06-17。

作者简介:

孙秋野(1977), 男, 博士, 教授, 主要研究方向为能源互联网的建模与优化运行、多能源综合互补优化、分布式发电系统的网络控制等, sunqiuyue@mail.neu.edu.cn;

刘月(1994), 女, 硕士研究生, 主要研究方向为机器学习, 系统建模, 1851276121@qq.com。

(责任编辑 邱丽萍)

Non-Intrusive We-energy Modeling Based on GAN Technology

SUN Qiuye, LIU Yue, HU Jingwei, HU Xuguang
(Northeastern University)

KEY WORDS: we-energy; non-intrusive monitoring; generative adversarial network; modeling method; integrated energy

To solve the modeling problem of We-energy, this paper proposes a non-intrusive modeling method based on generative adversarial networks (GAN). First, considering the energy generation characteristics of wind turbines, photovoltaics, energy storages and coupling equipments, the non-intrusive monitoring for We-Energy is realized by joint sliding and gradient separation. Furthermore, combined with the generation capacity and discrimination capacity of generation adversarial network, the improved GAN is used to deal with the time-asynchronous problem of electricity-gas-thermal data, and to classify and identify energy equipments. And a dispatching model for we-energy is established according to equipment classification. Finally, the effectiveness and accuracy of the proposed method are verified by the simulation of an energy region in the north.

As shown in Fig.1, input the separated device data into the GAN network, complete the missing part of the data through the generator, and classify the completed device data by the discriminator, thereby improving the accuracy of device identification and model establishment.

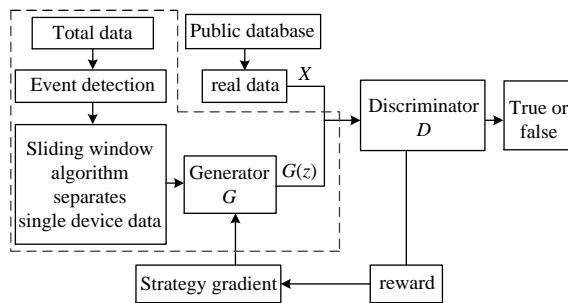


Fig.1 GAN network model

The expression of the generated adversarial network is as follows:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

The smaller the cost function, the higher the model training accuracy. This cost function is convex. In order to prevent the optimization process from falling into local convergence, the optimal solution can be obtained. The cost function gradient formula is as follows:

$$\nabla_{\theta_j} J(\theta) = -\frac{1}{m} \sum_{i=1}^m [x^{(i)}(1\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta))] + \lambda \theta_j \quad (2)$$

Fig.2 shows the GAN generation and recognition network layer number setting. The generator part generates the data, and the last layer of the discriminator is the fully connected layer, which can realize the multi-classification function of the device. When dispatching according to the function, Fig.3 shows the dispatching of electricity, gas and heat equipment.

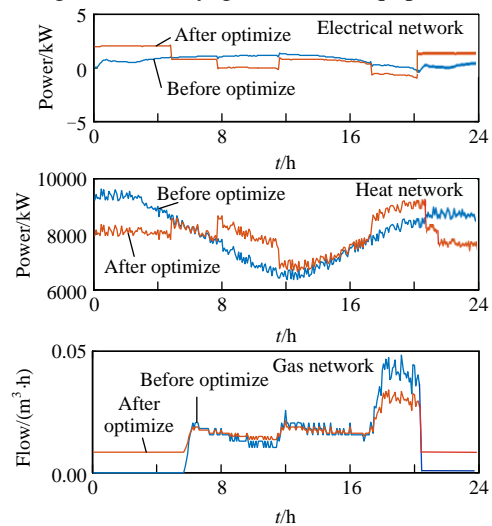


Fig.3 Comparison of energy consumption before and after electrical thermal network dispatching

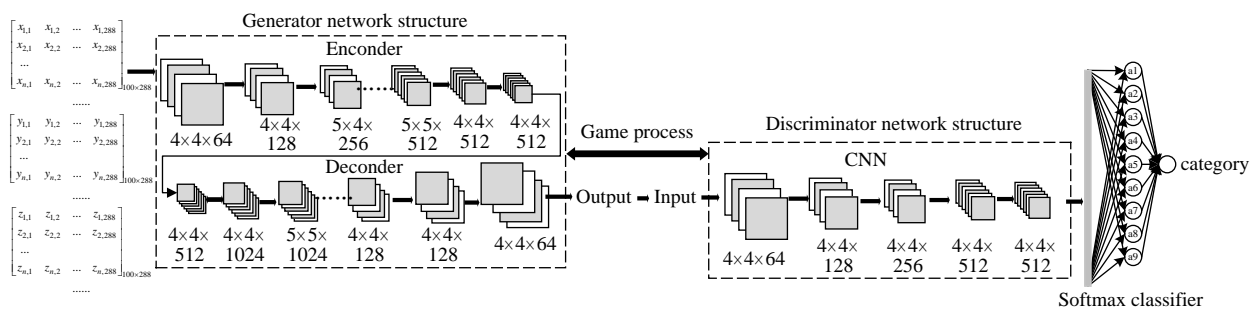


Fig.2 GAN generation recognition network layer setting