

微电网孤岛运行工况下DT模型自适应迁移方法

周亮

(国网上海市电力公司经济技术研究院,上海 200002)

摘要:微电网在孤岛运行工况变化情况下,会造成数字孪生(DT)模型迁移时无法准确匹配源域模型,从而导致迁移效率偏低等问题。为此,研究提出微电网孤岛运行工况变化场景下的数字孪生模型自适应迁移方法。通过分析微电网在孤岛运行工况下的运行特点,建立数字孪生模型,利用微电网孤岛运行工况的时变性,匹配计算源域模型,并通过缩小不同微电网孤岛运行工况下的源域数据分布差异,实现数字孪生模型的自适应迁移。实验结果表明,电流负载、实际电流等部分特征数据迁移效果较好,且具有较高迁移效率,验证了所提迁移方法可以适应不同微电网孤岛运行工况,具有较好的实用性。

关键词:微电网;孤岛运行;工况场景;变化状态;数字孪生模型;自适应迁移

中图分类号:TM727;TP399 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd24740

Adaptive Migration Method of DT Model Under Islanding Operation of Microgrid

ZHOU Liang

(State Grid Shanghai Electric Power Company Economic and Technical Research Institute,
Shanghai 200002, China)

Abstract: Under the change of island operation conditions, the microgrid will cause that the digital twin(DT) model cannot accurately match the source domain model when migrating, which will lead to low migration efficiency and other problems. For this reason, an adaptive migration method of digital twins model under the scenario of micro grid island operation condition changes was proposed. By analyzing the operation characteristics of the microgrid under the island operation condition, the digital twin model was established, and the time-varying operation condition of the microgrid island was used to match the calculation source domain model. The adaptive migration of the digital twin model was realized by reducing the distribution difference of the source domain data under different island operation conditions of the microgrid. The experimental results show that some characteristic data such as current load and actual current have high migration effect and high migration efficiency, which verifies that the proposed migration method can adapt to different micro grid island operation conditions, and has good practicability.

Key words: microgrid; island operation; working condition scenario; state of change; digital twin(DT) model; adaptive migration

数字孪生模型^[1]具有虚实交互、精确映射物理空间与信息空间的显著优势,采用数字孪生模型对实现微电网运行监测和优化具有重要意义。在现实的微电网系统中,其运行概况环境复杂多变,由于常规数字孪生模型无法适应孤岛工况的变化场景,极易导致其泛化能力下降,甚至产生错误判断,从而影响整个电网系统的安全稳定运行。因此,越来越多的学者对此提出运用数字孪生模型迁移方法。

沈慧等人^[2]基于特征数据分析结果,选择待迁移的源模型,利用迁移学习理论实现变工况下的数字孪生模型迁移,但是该方法忽略了源域数据之间具有序列关联性的影响,迁移效果不佳。史凯钰等人^[3]构建了基于长短期记忆网络的光伏发电功率预测数字孪生模型,该方法在计算数据匹配特征时,虽然考虑了数据序列的时间变化,但由于微电网孤岛运行时间以及运行状态的实时变化,其不能对模型的结构参数进行修正,从

基金项目:国家电网公司科技项目(521304170028)

作者简介:周亮(1980—),男,硕士,高级工程师,主要研究方向为输变电工程数字化设计管理与研究,Email:zllz1949@163.com

而导致迁移效率较低。高扬等人^[4]结合机器学习、通信网络、高性能分析计算及物联网的数字孪生技术,设计了考虑多通信协议交互的智慧微电网数字孪生和多智能体控制架构,对智慧微电网的全生命周期管理过程进行任务分解,构建系统的数字和物理孪生体,利用传感器采集的分布式元件和周围环境的各项孪生数据,构建出基于Opal-RT半实物仿真平台的智慧微电网测试模型。该方法利用用户通信数据协议(user datagram protocol, UDP)实时感知试验数据,在微电网并网和孤岛2种工作场景下验证了智慧微电网能够按照数字孪生优化后的试验方案在实际系统中执行。但由于执行情况与数字孪生系统在实时交互状态和不同工况变化环境下,还是难以自适应地在整个生命周期运行中提供保障。

为此,本文提出数字孪生模型自适应迁移策略,研究针对微电网在孤岛运行条件下的数字孪生模型迁移方法。通过在构建的迁移模型基础上计算源域模型的匹配数据,并缩减数据分布差异性,进而实现对数字孪生模型的自适应迁移。

1 数字孪生模型自适应迁移

1.1 建立可迁移的数字孪生模型

当微电网在孤岛工况状态下运行时,其电压、电流以及母线频率均由上级电网提供,其内部各单元系统无需参与调压和调频。因此,在建立可迁移的数字孪生模型时,忽略电网单一储能与故障,仅研究在可变工况下实现自适应迁移更新。

在数字孪生模型自适应迁移过程中会涉及两个重要参数,即源域数据和目标域数据。源域指的是包括所有标记样本的学习域输入数据;目标域指的是源域模型的各参数。可迁移数字孪生模型如图1所示。

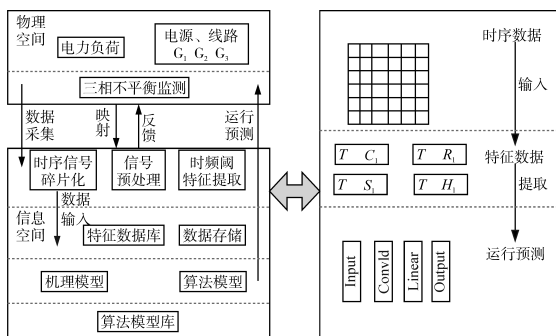


图1 微电网可迁移数字孪生模型

Fig.1 Microgrid migratable digital twin model

如图1所示, G_1, G_2, G_3 分别为孤岛工况下的

不同场景; T 为系统运行总时间; C_1 为在场景1下的运行状态属性; R_1 为功率属性; S_1 为频率属性; H_1 为电压属性。物理空间中包括电力负荷、独立电源、双回线路、单回线路和三相不平衡监测设备,根据系统运行状态,采用不同设备对特定的线路进行监测;信息空间与物理空间利用映射原理^[5]对系统运行数据进行低维映射。在算法模型库中,包括机理模型和预测模型,机理模型主要对提取的特征进行二次处理,以获得更加精细化的特征数据;预测模型利用自适应学习方式对数据之间的序列相关性进行深度挖掘,获取用于预测运行状态的结构参数。当系统在同一工况的不同场景下运行时,通过运算特征匹配数据从机理模型中找出对应的源域模型以实现更新域自适应迁移,迁移后的新模型产生的数据可在特征数据库中存储,以作为后续模型迁移的参考数据。

1.2 模型匹配

针对微电网源域模型(原始数字孪生模型)的时变性,从建立的可迁移数字孪生模型中匹配获得最佳待重用的源模型和源域数据,是实现后续决策模型迁移更新的基础。

在孤岛运行工况下产生的特征数据相似度过高,表明数据可重用的概率越大。基于建立的可迁移数字孪生模型,因微电网孤岛运行工况的变化和模型自身的时变性,造成其模型参数也具有可更新性,基于这一原理进行模型匹配,原理如图2所示。




图2 源模型和源域数据匹配原理

Fig.2 Matching principle of source model and source domain data

在源域模型匹配计算前,首先对孤岛运行工况下的特征数据组成的领域空间进行形式化表述,如下式:

$$\bar{D} = \{fea_spa, lab_spa, Mar_pro, Con_pro\} \quad (1)$$

式中: fea_spa 为当前工况下产生的数据分布的特征空间; lab_spa 为当前工况下产生的数据的标签空间; Mar_pro 为当前工况下产生的数据的边缘概率分布; Con_pro 为当前工况下产生的数据的条件概率分布。

由于特征数据是无标签数据,且不同工况决策模型是针对同一运行质量指标进行预测分析,因此数据条件概率 Con_pro 和标签种类 lab_spa 可以忽略不计。由此,上述特征数据领域空间^[6]可表示为

$$\bar{D} = \{ \chi | p(x) \} \quad (2)$$

领域数据集表示为

$$\bar{D}' = \{ x^i \}_{i=1}^N \quad (3)$$

式中: χ 为领域特征空间; $p(x)$ 为领域实例所服从的边缘概率分布; x^i 为 \bar{D}' 中的第 i 个实例, $x^i \in \chi$; N 为领域数据集的实例个数,各领域数据集实例数量相同。

领域概念符号含义如表1所示。

表1 数据领域符号含义

Tab.1 Symbol meaning of data domain

分类	数学符号	含义描述
当前工况特征 数据领域	$\bar{D}_{k(j)}$	第 j 个待选择源领域空间
	$\chi_{k(j)}$	待选择源领域特征空间
	$p_{k(j)}(x_{k(j)})$	待选择源领域边缘概率分布
	$\bar{D}'_{k(j)}$	待选择源领域数据集
	$x_{k(j)}$	待选择源领域数据实例
	$\bar{D}_{K(n)}$	已选择源领域特征数据集(D)
	\bar{D}_x	目标领域数据集
	$\bar{D}_{k(j)}$	其他各工况待选择源领域数据集
	D_K	全部待选择源领域数据集
	源领域	d_k
$x_{k(n)}$		源域数据实例

由于特定工况下特征提取种类固定,各工况特征数据领域的特征空间保持不变。因此,目标域数据和待选择源领域数据间的相似性度量主要针对其边缘概率分布的相似性计算^[7]。利用多级相似度量方法度量 GK_i 目标领域数据和待选择源领域数据分布差异。相似度量方法的原理示意图如图3所示。




图3 度量源域数据分布差异原理

Fig.3 Principle of measuring source domain data distribution difference

如图3所示,当工况场景变化时,待选择源域数据集和目标领域数据集中的部分样本数据也随之发生相应的变化。此时产生变化的数据通过映射函数将各场景下的数据映射^[8]到新的映射空间中,并重新生成新的样本数据,且当前数据是下次映射的初始数据。因此,利用上述方法度量 GK_i 目标领域数据和待选择源领域数据分布差异。原始数据空间的计算公式如下:

$$MMD(\bar{D}_x, \bar{D}_{k(j)}) = \sum_{i=1}^N \frac{\Phi(\bar{D}_x)}{N} - \sum_{i=1}^N \frac{\Phi(\bar{D}_{k(j)})}{N} \quad (4)$$

式中: $\Phi(\cdot)$ 为从目标领域与待选择源领域空间到信息空间的一个映射函数。

计算初始源域模型中的样本与邻域之间的线性相关性,如下式所示:

$$Q = \min \sum_{i=1}^N z_i - w_{ji} z_{ji} \quad (5)$$

式中: z_i 为目标域的第 i 个样本; z_{ji} 为样本 z_i 的第 j 个最近邻; w_{ji} 为样本 z_i 的第 j 个最近邻的权重。

将式(5)用核函数进行改写,得到下式:

$$MMD[\bar{D}_x, \bar{D}_{k(j)}] = Q \{ [\sum_{a,b=1}^N k(x_x^a, x_x^b)] / N^2 - [2 \sum_{a,b=1}^N k(x_x^a, x_{k(j)}^b) + k(x_{k(j)}^a, x_{k(j)}^b)] / N \} \quad (6)$$

式中: $k(\cdot)$ 为核函数; $(x_x^a, x_x^b), (x_{k(j)}^a, x_{k(j)}^b)$ 分别为 $\bar{D}_x, \bar{D}_{k(j)}$ 的实例样本。

依次计算 GK_i 中目标领域数据集 \bar{D}_x 和 D_K 中其他各工况待选择源领域数据集 $\bar{D}_{k(j)}$ 的 MMD 值,根据计算结果获得 MMD 最小值 m 及其对应源领域^[9]工况信息 GK_n 。

基于 GK_n ,从 D_K 和 d_k 中索引获得对应存储的决策模型和带标签的加工数据,该决策模型即为待重用的源模型 M ,带标签运行数据为待重用的源域数据 d ,至此完成源域模型的匹配计算,为后续实现模型自适应迁移奠定了重要基础。

1.3 实现变工况数字孪生模型自适应迁移

在微电网孤岛运行过程中,输电量的改变造成电流负载均值变化,从而导致工况发生动态变化。为提高数字孪生模型在变工况下的自适应能力,保证微电网孤岛运行稳定性,利用所提方法进行数字孪生模型自适应迁移。

为使模型迁移具有可移植性,本文采用深度网络自适应(deep domain confusion, DDC)方法实现微电网数字孪生模型自适应迁移。将前文匹配计算出的待重用源数据和源模型作为自适应迁移网络的输入样本,同时考虑系统初期 D_k 中存储的决策模型较少,导致新工况目标域数据和匹配获得的源域数据间仍存在较大差异。若直接利用新工况目标域数据 D_i 对源模型网络参数进行微调,其效果往往不佳,甚至会导致负迁移^[10]。因此,有必要在决策模型迁移方法中进一步缩减两种工况数据分布差异以保证源模型迁移更新效果。

采用DDC方法进行源模型 M 迁移更新的原理架构如图4所示,该方法以采用卷积神经网络^[11]搭建的决策模型为前提。决策模型架构由特征提取层和全连接层组成,通过特征提取层中多个卷积块对某工况特征数据进行层层卷积池化计算,并经过全连接层的线性拟合,最终完成数字孪生模型的自适应迁移。

DDC迁移方法是在源模型网络的基础上添加一层自适应度量,训练工况 GK_n 下带标签的源

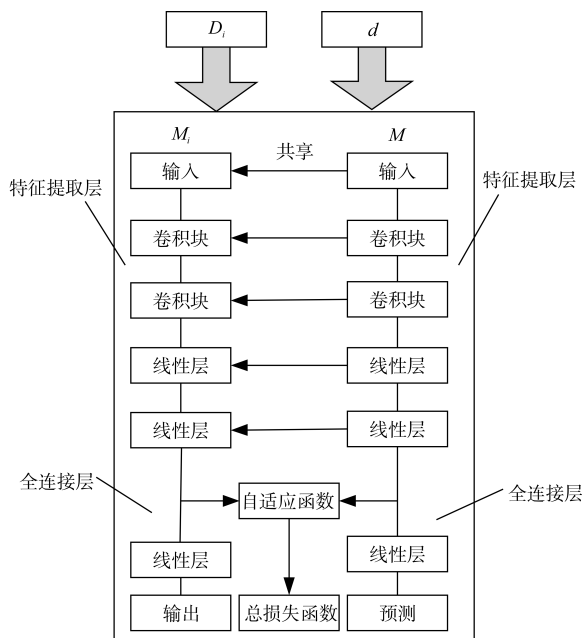


图4 模型自适应迁移示意图

Fig.4 Schematic diagram of model adaptive migration

域数据 d 和新工况 GK_i 下的目标域数据 D_i 数字孪生模型双输入数据。数字孪生模型中,首先基于特征提取层分别提取领域数据 d 和 D_i 的深层特征,并在自适应层基于源域模型匹配计算两深层特征间的分布距离,最后经全连接层拟合输出源域数据 d 对应的模型预测值^[12]。

模型训练的总损失函数为下式:

$$l = l_c(d, y) + \lambda l_A(d, D_i) M \quad (7)$$

式中: l 为数字孪生模型的总损失函数; y 为源域数据标签集; l_c 为源域数据 d 的预测损失函数; l_A 为自适应损失函数; λ 为自适应损失函数权重参数。

现建立稀疏矩阵 W :

$$W = \begin{cases} w_{ji} & z_j \in l \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

$$\sum_{i=1}^N w_{ji} z_{ji} = IZ'W \quad (9)$$

式中: I 为单位矩阵; Z' 为映射后的目标域数据。利用稀疏矩阵式(8)与式(9)结合,训练数字孪生模型。

更新训练完成后,将具有新网络结构参数的模型 M_i 作为新工况 GK_i 的决策模型并存储在 d_k 中。在实际生产应用中,通过实时采集处理 GK_i 下的特征数据并输入至决策模型 M_i 中进行微电网模型迁移与结果反馈^[13]。至此,完成了微电网孤岛运行工况变化场景下的数字孪生模型自适应迁移。

2 实验与结果分析

2.1 实验准备

选取某地区24节点微电网作为测试对象,根据微电网内部各组成单元利用Matlab软件搭建仿真模型,如图5所示。

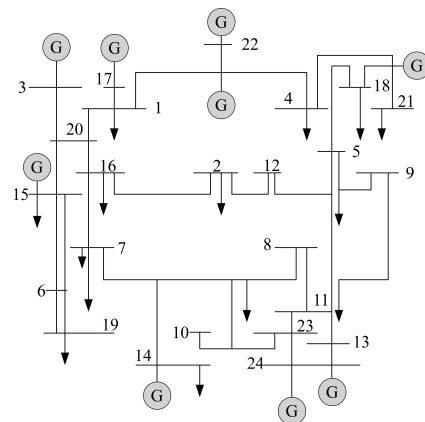


图5 实验微电网拓扑结构

Fig.5 Experimental microgrid topology

图5中,G为光伏电站。测试操作过程中,对该微电网孤岛运行工况进行12 s的测试。在1 s时断开开关,此时应用电池储能单元充当微电网主电源;在9 s时,接入200 kW的冲击性负荷,运行3 s后退出。

在上述微电网中进行测试,测试过程中,在对源域数据进行降噪和标准化处理的基础上,按照系统运行时间划分源信号时序,并根据时频域特征提取当前微电网孤岛运行工况下的源模型 M 、当前工况下目标域数据 D 、源域数据 d 以及决策模型 M_i 超参数特征数据,并以此作为待迁移模型的输入数据。根据上述过程,汇总部分特征数据,如表2所示。

表2 部分特征数据
Tab.2 Partial characteristic data

样本编号	电流负载均值/A	实际电流均方差/A	z向振动信号均方差/dB	z向振动信号重心频率/Hz
01	1.06E+00	1.48E+00	1.29E-01	-1.22E+00
02	4.66E-01	3.16E-01	6.25E-01	1.40E+00
03	1.16E-01	6.46E-02	-1.71E+00	4.53E-01
04	-8.99E-01	5.88E-01	2.35E+00	-5.46E-01
05	1.58E+00	-1.71E+00	1.65E+00	7.63E-01
06	-7.69E-01	6.86E-01	-3.69E-02	1.51E+00

以表2获取的微电网初始工况下的电流负载均值、实际电流均方差等数据为基础,进行实验分析。

2.2 实验结果分析

通过所提方法采集孤岛工况下的微电网运行数据作为处理时的初始数据,利用四轴力传感器监测微电网在正常运行状态下的力信号,并利用传感器组采集电信号和振动信号。预处理后的微电网时频域变化图像如图6所示。图6中, a 为信号加速度, t 为监测时间, f 为运行频率, A 为信号幅值。

为验证本文设计的迁移方法的迁移性能,对其迁移时间进行测试。在相同实验环境下,设定微电网在孤岛运行下的不同工况场景,即改变母线运行频率。以微电网母线频率为30 Hz,40 Hz,50 Hz,60 Hz和70 Hz进行数字孪生模型自适应迁移对比实验,分别统计不同迁移方法的迁移时间,比较分析迁移效率,对比结果如图7所示。同时给出本文方法在迁移数据时的输出幅值结果,如图8所示。




图6 初始工况振动信号时域、频域图像

Fig.6 Time domain and frequency domain image of vibration signal under initial working condition




图7 不同迁移方法的总迁移时间对比结果

Fig.7 Comparison results of total migration time of different migration methods




图8 迁移输出幅值

Fig.8 Migration output amplitude

图7中,方法1为本文提出的微电网孤岛运行工况变化场景下的数字孪生模型自适应迁移方法,方法2为面向加工领域的数字孪生模型自适应迁移方法,方法3为基于LSTM与迁移学习的光伏发电功率预测数字孪生模型。由图7可

知,随着微电网运行过程中母线频率的增加,方法2与方法3的总迁移时间也不断增加,迁移效率较低。而本文设计的迁移方法在不同工况变化条件下,其总迁移时间的整体波动程度不大,主要是由于实际方法在其他工况环境中的部分网络参数不同,使得模型同时学习到了孤岛运行工况不同变化场景下的数据特征,从而提高了迁移效率。

图8显示,所提方法在微电网孤岛运行工况变化场景下的数字孪生模型输出平衡较好,干扰滤波性能较好。

3 结论

对于微电网孤岛运行工况变化场景下的数字孪生模型自适应迁移,为提高其迁移效率,本文提出了一种新的迁移方法。通过构建数字孪生模型的基础上对微电网孤岛运行变工况的时变性匹配源域数据,实现了对数字孪生模型的自适应迁移。实验结果表明,该方法可有效缩短迁移时间,大大提高了迁移效率。

参考文献

- [1] 杜晓东,曾四鸣,刘科研,等.基于云模型的配电网运行画像数字孪生构建方法[J].电力系统保护与控制,2022,50(10):104-113.
DU Xiaodong, ZENG Siming, LIU Keyan, et al. Construction of portraits for a distribution network with digital twins based on a cloud model[J]. Power System Protection and Control, 2022, 50(10):104-113.
- [2] 沈慧,刘世民,许敏俊,等.面向加工领域的数字孪生模型自适应迁移方法[J].上海交通大学学报,2022,56(1):70-80.
SHEN Hui, LIU Shimin, XU Minjun, et al. Adaptive transferring method of digital twin model for machining domain[J]. Journal of Shanghai Jiaotong University, 2022, 56(1):70-80.
- [3] 史凯钰,张东霞,韩肖清,等.基于LSTM与迁移学习的光伏发电功率预测数字孪生模型[J].电网技术,2022,46(4):1363-1372.
SHI Kaiyu, ZHANG Dongxia, HAN Xiaoqing, et al. Digital twin model of PV power prediction based on LSTM and migration learning[J]. Power Grid Technology, 2022, 46(4):1363-1372.
- [4] 高扬,贺兴,艾芊.基于数字孪生驱动的智慧微电网多智能体协调优化控制策略[J].电网技术,2021,45(7):2483-2491.
GAO Yang, HE Xing, AI Qian. Multi agent coordinated optimal control strategy of smart microgrid based on digital twin drive [J]. Power Grid Technology, 2021, 45(7):2483-2491.
- [5] 王晓霞,郑大钊.基于GSA算法的WVN资源映射数学模型[J].计算机仿真,2022,39(4):398-402.
WANG Xiaoxia, ZHENG Dazhao. Mathematical model of wireless virtual network resource mapping based on GSA algorithm [J]. Computer Simulation, 2022, 39(4):398-402.
- [6] 沈飞,陈超,徐佳文,等.数据领域选择与空间迁移在齿轮箱故障诊断中的应用[J].振动工程学报,2021,34(2):389-401.
SHEN Fei, CHEN Chao, XU Jiawen, et al. Application of data domain selection and spatial migration in gearbox fault diagnosis[J]. Journal of Vibration Engineering, 2021, 34(2):389-401.
- [7] DEEPA Karuppaiah, DURAI RAJ VINCENT P M. Hybrid approach for semantic similarity calculation between tamil words [J]. International Journal of Innovative Computing and Applications, 2021, 12(1):13-23.
- [8] EFTHYMIOS Chondrogiannis, EFSTATHIOS Karanastasis, VASSILIKI Andronikou, et al. Bridging the gap among cohort data using mapping scenarios[J]. Journal of Advances in Information Technology, 2021, 12(3):179-188.
- [9] 李佳芮,刘健,陈钰枫,等.一种多源领域自适应命名实体识别方法[J].厦门大学学报(自然科学版),2022,61(4):617-623.
LI Jiarui, LIU Jian, CHEN Yufeng, et al. A multi-source domain adaptation approach in named entity recognition[J]. Journal of Xiamen University (Natural Science Edition), 2022, 61(4):617-623.
- [10] 唐焕玲,郑涵,刘艳红,等.Tr-SLDA:一种面向交叉领域的迁移主题模型[J].电子学报,2021,49(3):605-613.
TANG Huanling, ZHENG Han, LIU Yanhong, et al. Tr-SLDA: a transfer topic model for cross-domains[J]. Journal of Electronics, 2021, 49(3):605-613.
- [11] 孙淑娥,姚柳,赵怡.基于卷积神经网络的时间序列数据融合算法[J].西安石油大学学报(自然科学版),2021,36(5):136-142.
SUN Shue, YAO Liu, ZHAO Yi. Time series data fusion algorithm based on convolutional neural network[J]. Journal of Xi'an Petroleum University (Natural Science Edition), 2021, 36(5):136-142.
- [12] 袁晓磊,岳晓峰,方博,等.基于点对特征及分层全连接聚类的三维目标识别方法[J].计算机科学,2021,48(z1):127-131.
YUAN Xiaolei, YUE Xiaofeng, FANG Bo, et al. Three-dimensional target recognition method based on pair point feature and hierarchical complete-linkage clustering[J]. Computer Science, 2021, 48(z1):127-131.
- [13] 李晓庆,孟德智,杨家强.基于单位矩阵的电动汽车永磁同步电机制动电流解耦技术研究[J].大电机技术,2021(4):19-23,34.
LI Xiaoping, MENG Dezhi, YANG Jiaqiang. Research on decoupling technology of permanent magnet synchronous motor braking current of electric vehicle based on unit matrix[J]. Large Motor Technology, 2021(4):19-23,34.

收稿日期:2022-10-29

修改稿日期:2022-12-13