

基于稀疏学习的微电网负载建模

平作为¹ 何维² 李俊林¹ 杨涛³

摘要 微电网由负载、储能系统和分布式电源互联集成到能源系统中,微电网系统可以作为一个整体系统与电网并行运行或以孤岛模式运行.负载建模是微电网运行和管理中的一个基本问题.本文着重解决以下两个关键问题:1)协调负载模型结构的合理性和简洁性;2)负载模型参数的校准.与常规负载建模方法不同,本文提出了一类数据驱动建模方法以同时实现负载模型结构选择和参数校准.具体地,该方法从量测数据中稀疏学习静态负载模型和动态负载模型,其关键方法分别来自于稀疏贝叶斯学习方法和交替方向方法,即从一组备选非线性字典函数中稀疏学习最主要的非线性项以平衡数据拟合度并实现模型学习.所提出的方法将机器学习与稀疏表示相结合,旨在对负载模型从物理角度提供机理解释并向配电网系统操作员提供有关负载的动态信息.在孤岛微电网测试系统中验证并评估了所提出的算法.研究测例表明所提出算法从量测数据中实现负载稀疏学习的合理性和对于噪声的鲁棒性.

关键词 静态负载,动态负载,负载建模,微电网,机器学习,稀疏学习

引用格式 平作为,何维,李俊林,杨涛.基于稀疏学习的微电网负载建模.自动化学报,2020,46(9):1798-1808

DOI 10.16383/j.aas.c200154

Sparse Learning for Load Modeling in Microgrids

PING Zuo-Wei¹ HE Wei² LI Jun-Lin¹ YANG Tao³

Abstract The microgrid is integrated into the energy system by interconnected loads, energy storage systems and distributed energy sources, which can be operated in parallel with the grid as a whole system or run in island mode. Load modeling is a fundamental issue in the operation and control of the microgrid. This paper focuses on solving following two key problems, one is the coordination of the reasonability and conciseness of load model structure, the other is the parameters calibration of the load model. Different from conventional load modeling methods, this article proposes data-driven modeling methods to achieve structural selection and parameter calibration of load models simultaneously. Specifically, the key methodologies of sparse learning static load models and dynamic load models from measurement data draw from sparse Bayesian learning method and alternating direction method, and select the most dominant nonlinear terms from a pool of dictionary functions, which balance the data fitness and achieve model learning. The proposed methods combine the machine learning technique with sparse representation, aiming to provide physical interpretation for load model and offer insight to the distribution system operators about dynamics of load. We validate and evaluate the proposed algorithms on the islanded microgrid test system. Case studies demonstrate the effectiveness of proposed algorithms in achieving load modeling from measurement data in terms of reasonability and robustness against measurement noises.

Key words Static load, dynamic load, load modeling, microgrids, machine learning, sparse learning

Citation Ping Zuo-Wei, He Wei, Li Jun-Lin, Yang Tao. Sparse learning for load modeling in microgrids. *Acta Automatica Sinica*, 2020, 46(9): 1798-1808

收稿日期 2020-03-23 录用日期 2020-06-11

Manuscript received March 23, 2020; accepted June 11, 2020

国家自然科学基金委重大项目(61991403, 61991400)资助

Supported by Major Program of National Natural Science Foundation of China (61991403, 61991400)

本文责任编辑 孙秋野

Recommended by Associate Editor SUN Qiu-Ye

1. 华中科技大学人工智能与自动化学院 武汉 430074 2. 华中科技大学电气与电子工程学院 武汉 430074 3. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819

1. School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074 2. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074 3. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819

智能微电网(Microgrid, MG)是大型电力系统的现代化、小型化的一种形式,是多种能源发电设备和终端用户设备的智能优化和管理,能够提供更高的供电可靠性,更易满足用户增长的需求,最大可能地利用清洁能源并促进技术创新,在实现可持续发展目标的同时最大化投资效益^[1].智能微电网是指由分布式电源、储能装置、能量转换装置、相关负载和监控、保护装置汇集而成的小型配发电系统,是一个能够实现自我控制、保护和管理的自治系统,既可以与外部电网并网运行,也可以孤立运行^[2-4].通过配电线路,耦合微电网交换电力能够减轻可再

生能源造成的波动, 并通过聚集效应来平衡本地发电与消耗之间的不平衡^[5-6]. 微电网运行控制策略以及电压稳定性分析的研究主要依靠于对负载模型的充分了解. 负载建模, 即, 对负载模型表示, 是决定微电网管理的关键因素^[7]. 负载建模的不准确表示可能会导致整个电网激进或保守的运行. 在激进的结果中, 电网预防风险的能力明显减弱, 则会导致停电并威胁电网甚至公共安全; 在保守的结果中, 很难计算出电网功率传输的极限, 甚至可能导致输电受限. 因此, 负载建模是微电网系统运行及分析的关键问题, 且具有重要的理论和实际价值^[8].

通常, 获取电网负载的详细模型比对特定的电网系统组件建模更具复杂性. 因此, 电网运行中的负载模型必须能够反映负载的机理性质, 并能够用简单的低阶模型来表征. 特别地, 负载模型可以分为静态负载模型和动态负载模型, 其中, 静态负载模型包括 ZIP(恒定阻抗 (Z)、恒定电流 (I) 和恒定功率 (P)) 模型和指数模型, 它们揭示了功率与电压之间的关系^[9]. 获得简洁的负载模型并确保模型的合理性是负载建模的核心问题. 现已有许多研究提出方法致力于负载模型参数辨识. 静态负载的参数估计是相对简单的, 因为负载模型中不包含动态变量. 在这种情况下, 参数估计的任务实际上简化为曲线拟合. 文献 [10] 尝试使用改进 Broyden-Fletcher-Goldfarb-Shanno (BFGS) 算法和最小二乘方法来估计静态负载参数. 然而, 需要注意的是, 任何基于梯度的优化应用都可能会达到局部最优, 因此导致获得不准确的参数估计.

尽管静态负载模型已很好地应用于电压稳定性分析, 但是这些模型无法描述发生干扰时负载的动态响应^[11-12]. 动态负载模型是负载的时间敏感性行为, 是典型的 Hammerstein 系统^[13]. 传统意义上, 大多数基于量测的建模方法会考虑给定负载模型结构, 并使用不同的优化方法来估计相应的模型参数. 在这些优化方法中, 非线性最小二乘法^[14]、加权最小二乘^[15]、遗传算法^[16]、卡尔曼滤波方法^[17]和粒子群优化算法^[18]广泛用于负载建模. 然而, 由于给定负载模型无法准确描述负载可能的动态现象^[19], 研究人员对人工智能建模方法, 例如神经网络^[20-21]和模糊系统^[22], 表现出兴趣. 但是, 这些方法存在着某些缺点和局限性, 主要是收敛速度慢和算法对参数初始值的高敏感性, 以及由于局部最小值导致的训练失败^[19]. 此外, 相关的模型参数在不同的建模条件和电压扰动下变化很大. 因此, 参数更新过程可能变得非常耗时, 使得在实际应用中无法使用此类方法.

近年来, 有关上述基于量测的建模方法是否对静态负载和动态负载建模具有限制的研究引起了广泛的讨论. 对于给定模型结构^[23], 上述方法无法解决负载建模中广泛存在的模型结构不合理问题. 关于负载建模, 有两个方面需要考虑: 描述可能的负载结构特性和估计模型参数的方法^[24]. 这就是泛化能力, 即拟合新的量测数据的能力.

为了克服上述不足, 我们旨在提出一类数据驱动建模方法以同时实现负载模型结构的选择和负载模型参数的辨识. 就提升负载建模质量而言, 人工智能方法, 尤其是机器学习, 讨论构建负载动力学模型以寻找状态变量和负载输出之间的数量关系. 与现有的人工智能方法不同, 我们提出的稀疏学习建模方法不仅能同时实现负载模型结构的选择以及负载模型参数的辨识, 所获得的模型还具有物理可解释性, 可以为配电系统运营商提供负载的动态描述. 本文分别讨论了静态负载建模和动态负载建模. 本文的贡献主要有两个方面:

1) 将稀疏表示与机器学习相结合, 从量测数据中稀疏学习静态负载和动态负载, 其关键方法分别来自于稀疏贝叶斯学习方法和交替方向方法, 即从一组备选非线性字典函数中选择最主要非线性项以准确拟合数据, 从而平衡模型的复杂性以避免过拟合. 从理论上讲, 我们的工作基于存在备选非线性字典函数这一事实, 其线性组合可以表示静态负载模型和动态负载模型.

2) 所提出的数据驱动建模方法阐述了稀疏学习的一般框架, 在静态负载和动态负载建模过程中同时实现了负载动力学的合理模型结构选择和精确参数估计, 给予了模型物理性解释, 甚至在有噪声的情况下具有良好的鲁棒性和准确性.

本文的其余部分安排如下. 第 1 节阐述了微电网架构. 第 2 节介绍了微电网中不同类型的负载. 第 3 节提出了一类数据驱动负载稀疏建模算法. 第 4 节通过多个研究测例说明所提出算法的有效性, 即, 稀疏建模算法可以同时实现负载模型选择和参数校准.

1 微电网架构

在未来智能配电网系统中, 通过互联运行的微电网以实现适当的功率共享是至关重要的. 微电网的示意如图 1 所示, 其中每个分布式发电装置 (Distributed generation, DG) 与各自的本地负载相连.

1.1 分布式发电装置动力学模型

近来的研究中, 下垂控制是微电网中有效的功率共享问题解决方案^[25-27]. 受文献 [28-29] 启发, 相




图 1 微电网通过公共连接点连接主网

Fig. 1 A generic MG is connected to the main grid at the point of common coupling

角下垂控制使用相角而不是频率来表示功率不平衡. 考虑具有 N 个分布式发电装置的孤岛微电网. 在接口 $i \in \{1, \dots, N\}$ 处, 可以指定如下相角和电压下垂控制:

$$\begin{aligned} \tau_{P_i} \dot{\delta}_i &= -\delta_i + \delta_i^d - k_{P_i}(P_i - P_i^d) \\ \tau_{Q_i} \dot{V}_i &= -V_i + V_i^d - k_{Q_i}(Q_i - Q_i^d) \end{aligned} \quad (1)$$

其中, δ_i 和 V_i 分别表示相角和电压, δ_i^d 和 V_i^d 为设定参考值. τ_{P_i} 和 τ_{Q_i} 分别表示相角跟踪时间常数和电压跟踪时间常数, k_{P_i}, k_{Q_i} 分别为相角和电压下垂增益, 表示敏感度以指示有功功率和无功功率的不平衡. P_i 和 Q_i 分别是第 i 个分布式发电装置有功功率输出和无功功率输出, P_i^d 和 Q_i^d 分别是标称有功功率和标称无功功率.

1.2 潮流传输方程

对于微电网中第 i 个分布式发电装置, P_i 和 Q_i 不是本地确定的, 而是系统交互的结果, 可以视为来自网络的反馈. 标称有功和无功注入 P_i^d, Q_i^d 由电网调度决定, 并在调度期间保持恒定. 变量 δ_i 和 V_i 由本地网络反馈量测量 P_i, Q_i 以及参考设定值 $\delta_i^d, V_i^d, P_i^d, Q_i^d$ 调控. 注入的有功功率和无功功率由以下功角关系确定^[30]

$$\begin{aligned} \hat{P}_i &= \sum_{k=1, k \neq i}^N V_i V_k |B_{ik}| \sin(\delta_i - \delta_k) \\ \hat{Q}_i &= V_i^2 |B_{ii}| - \sum_{k=1, k \neq i}^N V_i V_k |B_{ik}| \sin(\delta_i - \delta_k) \end{aligned}$$

其中, B_{ik} 表示第 i 个分布式发电装置和第 k 个分布式发电装置之间的输电线路, $|B_{ik}|$ 是电纳 B_{ik} 的幅值.

第 i 个分布式发电装置的有功功率和无功功率

输出为

$$\begin{aligned} P_i &= P_{L,i} + \hat{P}_i \\ Q_i &= Q_{L,i} + \hat{Q}_i \end{aligned}$$

其中, $P_{L,i}$ 和 $Q_{L,i}$ 是负载的有功功率和无功功率需求, 负载类型可能是静态负载也可能是动态负载.

2 微电网中不同负载类型

在微电网的电压调节研究中, 负载类型对电压稳定性分析会产生影响. 具体地, 负载主要分为两种, 静态负载和动态负载. 静态负载模型, 包括 ZIP 负载模型和指数负载模型, 在任何时刻的有功功率和无功功率取决于节点电压幅度. 由于动态负载是对电压和时间的响应, 所以模型更加复杂.

2.1 静态负载

2.1.1 ZIP 模型

负载节点 i 上有功功率和无功功率需求 $P_{L,i}$ 和 $Q_{L,i}$ 关于电压是非线性的, 其模型为

$$P_{L,i} = P_{p,i} + I_{p,i} V_i + Z_{p,i} V_i^2 \quad (2)$$

$$Q_{L,i} = Q_{q,i} + I_{q,i} V_i + Z_{q,i} V_i^2 \quad (3)$$

此模型称为 ZIP 负载模型^[31], $i = 1, \dots, N$, 参数 $P_{p,i}, I_{p,i}, Z_{p,i}, Q_{q,i}, I_{q,i}, Z_{q,i}$ 为正. 特别地, ZIP 负载模型具有三种特殊的表达形式.

1) 负载节点 i 上有功功率和无功功率需求 $P_{L,i}$ 和 $Q_{L,i}$ 与电压平方成正比, 其模型为

$$\begin{aligned} P_{L,i} &= Z_{p,i} V_i^2 \\ Q_{L,i} &= Z_{q,i} V_i^2 \end{aligned} \quad (4)$$

此模型称为恒定阻抗负载模型, $i = 1, \dots, N$.

2) 负载节点 i 上有功功率和无功功率需求 $P_{L,i}$ 和 $Q_{L,i}$ 与电压成正比, 其模型为

$$\begin{aligned} P_{L,i} &= I_{p,i} V_i \\ Q_{L,i} &= I_{q,i} V_i \end{aligned} \quad (5)$$

此模型称为恒定电流负载模型, $i = 1, \dots, N$.

3) 负载节点 i 上有功功率和无功功率需求 $P_{L,i}$ 和 $Q_{L,i}$ 与电压无关, 其模型为

$$\begin{aligned} P_{L,i} &= P_{p,i} \\ Q_{L,i} &= Q_{q,i} \end{aligned} \quad (6)$$

此模型称为恒定功率负载模型, $i = 1, \dots, N$.

2.1.2 指数负载模型

静态负载也可以表示为指数形式^[32-33]

$$\begin{aligned} P_{L,i} &= P_0 V_i^{n_p} \\ Q_{L,i} &= Q_0 V_i^{n_q} \end{aligned} \quad (7)$$

其中, $i = 1, \dots, N$. 此模型的参数为指数 n_p, n_q 和系数 P_0, Q_0 . 针对不同负载元件, 模型的指数常数信息如表 1 所示.

表 1 不同负载元件指数值 n_p 和 n_q [34]
Table 1 Values of the exponents n_p and n_q for different load components [34]

负载元件/指数值	n_p	n_q
空调	0.50	2.50
电阻加热器	2.00	0.00
灯	1.00	3.00
泵机	0.08	1.60
大型工业电机	0.05	0.50
小型工业电机	0.10	0.60

2.2 动态负载

为了进一步研究, 假定动态负载模型表示为一组非线性微分方程. 这里我们假定负载消耗的有功功率具有如下非线性形式 [35]

$$T_{p,i} \frac{dP_{L,i}}{dt} + P_{L,i} = \alpha_{1,i} + \alpha_{2,i}V_i + \alpha_{3,i}V_i^2 \quad (8)$$

其中, $i = 1, \dots, N$. 类似的方程对于无功功率也同样有效. 与无功功率有关的方程式如下

$$T_{q,i} \frac{dQ_{L,i}}{dt} + Q_{L,i} = \beta_{1,i} + \beta_{2,i}V_i + \beta_{3,i}V_i^2 \quad (9)$$

其中, $i = 1, \dots, N$.

式 (8) 和式 (9) 是典型的 Hammerstein 模型结构. 我们可以考虑更高阶和更通用的非线性动力学模型结构. 给定 m 个非线性函数 $f_1(V_i), \dots, f_m(V_i)$, 与有功功率相关的 n 阶 Hammerstein 系统可以表示为

$$\frac{d^n P_{L,i}}{dt^n} + a_{1,i} \frac{d^{n-1} P_{L,i}}{dt^{n-1}} + \dots + a_{n,i} P_{L,i} = c_{1,i} f_1(V_i) + \dots + c_{m,i} f_m(V_i) \quad (10)$$

其中, $a_{1,i}, \dots, a_{n,i}, c_{1,i}, \dots, c_{m,i}$ 为未知参数. 给定 m 个非线性函数 $g_1(V_i), \dots, g_m(V_i)$, 与无功功率相关的 n 阶 Hammerstein 系统可以表示为

$$\frac{d^n Q_{L,i}}{dt^n} + b_{1,i} \frac{d^{n-1} Q_{L,i}}{dt^{n-1}} + \dots + b_{n,i} Q_{L,i} = d_{1,i} g_1(V_i) + \dots + d_{m,i} g_m(V_i) \quad (11)$$

其中, $b_{1,i}, \dots, b_{n,i}$ 和 $d_{1,i}, \dots, d_{m,i}$ 为未知参数.

3 负载稀疏建模方法

本节关注以下两个关键问题, 一个是负载模型结构合理性和简洁性的协调; 另一个是负载模型参

数的校准. 在本节中, 我们结合机器学习和稀疏表示去选择负载动力学中最主要的项来拟合数据, 以学习具有物理解释的负载模型. 对于静态负载和动态负载, 我们分别提出稀疏贝叶斯学习方法 [36] 和交替方向法 (Alternating direction method, ADM) [37] 进行稀疏建模, 在算法 1 和算法 2 中分别进行了阐明.

3.1 静态负载稀疏建模

这里, 我们针对单个负载进行建模. 令 $\mathbf{y}(t) = P_L(t)$ 或 $\mathbf{y}(t) = Q_L(t)$ 为关于电压的负载功率输出. 表示动力学的函数 Ξ 具有一般形式

$$\mathbf{y}(t) = \Xi(V(t)) = \sum_{r=1}^K \phi_r(V(t)) \theta_r \quad (12)$$

其中, 每个基函数 ϕ_r 代表一个备选字典函数, 例如单项式和指数函数, 同时系数 θ_r 是基函数 ϕ_r 的线性参数. 所有 ϕ_r 组成一个大的字典函数矩阵 $\Phi = [\phi_1, \phi_2, \dots, \phi_K]$, 其中 K 为基函数的总数.

要稀疏学习静态负载模型, 首先以适当的采样率收集时间序列 $\{\mathbf{y}(t_h) : h = 1, 2, \dots, l\}$. 输出量测向量表示为

$$\mathbf{Y} = [\mathbf{y}(t_1) \ \mathbf{y}(t_2) \ \dots \ \mathbf{y}(t_l)]^T \in \mathbf{R}^{l \times 1} \quad (13)$$

现可通过以下方式将量测向量 \mathbf{Y} 与字典函数矩阵 $\Phi(V)$ 相关联

$$\mathbf{Y} = \Phi(V) \boldsymbol{\theta} \quad (14)$$

其中, 字典函数矩阵 Φ 是在 $\{t_h, h = 1, 2, \dots, l\}$ 时刻进行估算, 同时, $\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_K]$ 是未知权重向量. 当系统存在观测噪声时, 负载的动力学可以表示为

$$\mathbf{Y} = \Phi \boldsymbol{\theta} + \boldsymbol{\xi} \quad (15)$$

其中, $\boldsymbol{\xi}$ 的分量是方差为 λ 、期望为零的独立同分布 (i.i.d) 高斯随机变量, 即 $\boldsymbol{\xi} \sim \mathbf{N}(0, \lambda \mathbf{I})$.

对于式 (15), 为对静态负载稀疏建模, 采用稀疏贝叶斯学习方法来寻找非零稀疏向量 $\boldsymbol{\theta}$.

步骤 1. 利用稀疏诱导先验使得边际似然最大化. 在贝叶斯学习的框架中, 所有未知参数通常被视为具有一定概率分布的随机变量, 可以基于 \mathbf{Y} 提取 $\boldsymbol{\theta}$ 的统计信息, 即为后验概率密度函数 $p(\boldsymbol{\theta}|\mathbf{Y})$. 这样, 在给定参数 $\boldsymbol{\theta}$ 的情况下, 量测向量 \mathbf{Y} 的似然函数定义为

$$p(\mathbf{Y}|\boldsymbol{\theta}) = \mathbf{N}(\mathbf{Y}|\Phi\boldsymbol{\theta}, \lambda \mathbf{I}) \propto \exp \left[-\frac{1}{2\lambda} \|\mathbf{Y} - \Phi\boldsymbol{\theta}\|_2^2 \right]$$

根据贝叶斯法则, 后验概率密度函数为

$$p(\theta|\mathbf{Y}) = \frac{p(\mathbf{Y}|\theta)p(\theta)}{p(\mathbf{Y})}$$

式中, 定义一个先验分布 $p(\theta) = \prod_j p(\theta_j)$.

在这里, 基于 \mathbf{Y} 提取 θ 的统计信息, 即后验均值 $\mathbb{E}(\theta|\mathbf{Y})$ 是主要问题. 然而, 由于后验 $p(\theta|\mathbf{Y})$ 是非高斯的, 很难进行积分, 因此引入超高斯先验来解决此问题^[38]. 更具体地说, 引入超参数向量 $\gamma = [\gamma_1, \dots, \gamma_K]^T \in \mathbf{R}_+^K$, 松弛先验概率为以下形式

$$p(\theta) = \prod_{j=1} p(\theta_j)$$

$$p(\theta_j) = \max_{\gamma_j > 0} N(\theta_j|0, \gamma_j)\eta(\gamma_j)$$

其中, $\eta(\gamma_j)$ 表示非负函数.

对于给定的 $\gamma = [\gamma_1, \dots, \gamma_K]^T$, $p(\theta|\mathbf{Y}, \gamma)$ 可以用来近似 $p(\theta|\mathbf{Y})$ 以获得后验信息. 假定松弛先验为

$$p(\theta; \gamma) = \prod_j N(\theta_j|0, \gamma_j)\eta(\gamma_j) = p(\theta|\gamma)p(\gamma) \leq p(\theta)$$

其中, $p(\theta|\gamma) = \prod_j N(\theta_j|0, \gamma_j)$ 和 $p(\gamma) = \prod_j \eta(\gamma_j)$. 由于似然函数 $p(\mathbf{Y}|\theta)$ 为高斯函数, 因此

$$p(\theta|\mathbf{Y}, \gamma) = \frac{p(\mathbf{Y}|\theta)p(\theta; \gamma)}{\int p(\mathbf{Y}|\theta)p(\theta; \gamma)d\theta} = N(M_\theta, \Sigma_\theta)$$

其中, M_θ 和 Σ_θ 分别是后验期望和后验协方差矩阵. 全后验概率可表示为

$$p(\theta, \gamma|\mathbf{Y}) \propto p(\theta|\mathbf{Y}, \gamma)p(\gamma|\mathbf{Y}) = N(M_\theta, \Sigma_\theta) \times \frac{p(\mathbf{Y}|\gamma)p(\gamma)}{p(\mathbf{Y})}$$

由于 $p(\mathbf{Y})$ 独立于 γ ,

$$p(\mathbf{Y}|\gamma)p(\gamma) = \int p(\mathbf{Y}|\theta)p(\theta|\gamma)p(\gamma)d\theta$$

其主要目标是估计超参数

$$(\hat{\gamma}, \hat{\lambda}) = \arg \min_{\gamma, \lambda \geq 0} \int p(\mathbf{Y}|\theta) |p(\theta) - p(\theta; \gamma)| d\theta = \arg \min_{\gamma, \lambda \geq 0} -2 \ln \int p(\mathbf{Y}|\theta)p(\theta; \gamma)d\theta = \arg \min_{\gamma, \lambda \geq 0} -2 \ln p(\mathbf{Y}; \gamma, \lambda) \quad (16)$$

一旦得到这些值, 即可以选择未知参数 θ 为 M_θ .

步骤 2. 求解 (γ, λ) 等价于最小化 $-\ln p(\mathbf{Y}; \gamma, \lambda)$. 期望最大化 (Expectation-maximum, EM) 方法^[38] 通过将 θ 作为隐藏变量, 最大化

$$E_{\theta|\mathbf{Y}; \gamma, \lambda} [p(\mathbf{Y}, \theta; \gamma, \lambda)] \quad (17)$$

从而更新 (γ, λ) 以最大化 $p(\mathbf{Y}; \gamma, \lambda)$. 根据期望最大化 (EM) 的更新方法, 所提出的稀疏辨识算法如算法 1 所示.

算法 1. 通过期望最大化方法稀疏学习静态负载输入. 采集量测数据 \mathbf{Y} 和构建冗余字典矩阵 Φ ;

输出. 后验期望 θ ;

1: 初始化 γ^0, λ^0 ;

2: **for** $k = 1 : Max$, **do**;

3: E 步: 确定条件期望

$$E_{\theta|\mathbf{Y}, \gamma^k, \lambda} [\theta_j^2] = (\Sigma_\theta)_{j,j} + M_{\theta,j}^2;$$

4: M 步: 关于 (γ^k, λ^k) , 更新

$$\gamma_j^{k+1} = \arg \min_{\gamma_j \geq 0} E_{\theta|\mathbf{Y}; \gamma^k, \lambda} [p(\mathbf{Y}, \theta; \gamma, \lambda)] =$$

$$E_{\theta|\mathbf{Y}; \gamma^k, \lambda} [\theta_j^2]$$

$$\lambda^{k+1} = \frac{\|\mathbf{Y} - \Phi M_\theta\|^2 + \lambda^k \sum_{j=1}^K [1 - (\gamma_j^k)^{-1} (\Sigma_\theta)_{j,j}]}{l}$$

5: **if** 终止条件满足 **then**

6: 终止

7: **end if**

8: **end for**

3.2 动态负载稀疏建模

本小节仍针对单个负载进行建模. 在适当的采样间隔 τ 下, 动态负载模型 (10) 可以离散化, 从而形成离散时间系统并提取 M 个数据点 $y(s) = P_L(s)$ 或 $y(s) = Q_L(s)$ 和 M 个数据点 $V(s)$, 其中 $s = 1, \dots, M$. 在图 2 中, Hammerstein 系统包括静态非线性部分和线性动态子系统. $A(z)$ 是度为 n_a 的后退转移运算符 $z^{-1}(z^{-1}y(s) = y(s-1))$, 其中

$$A(z) = a_0 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{n_a} z^{-n_a} \quad (18)$$




图 2 广义 Hammerstein 模型表示负载功率关系
Fig.2 A general Hammerstein model representation for load power

Hammerstein 系统可以表示为

$$A(z)y(s) = f(V(s)) \quad (19)$$

假设非线性项 $f(V(s))$ 是一个高次多项式, 由备选非线性基函数向量 $\mathbf{f} = (f_1, f_2, \dots, f_{n_c})$ 和未知权重向量 \mathbf{c} 的线性组合来表示:

$$f(V(s)) = c_1 f_1(V(s)) + c_2 f_2(V(s)) + \dots + c_{n_c} f_{n_c}(V(s)) = \mathbf{f}(V(s))\mathbf{c}$$

线性子系统的参数向量 \mathbf{a} 和非线性部分的参数向量 \mathbf{c} 分别为

$$\begin{aligned} \mathbf{a} &= [a_0, a_1, a_2, \dots, a_{n_a}]^T \in \mathbf{R}^{n_a+1} \\ \mathbf{c} &= [c_1, c_2, \dots, c_{n_c}]^T \in \mathbf{R}^{n_c} \end{aligned}$$

定义系统输出向量 $\varphi(s) \in \mathbf{R}^{n_a+1}$ 为

$$\varphi(s) = [-y(s), -y(s-1), \dots, -y(s-n_a)]^T$$

因此, Hammerstein 系统的辨识模型可以表示为

$$0 = \varphi^T(s)\mathbf{a} + \mathbf{f}(s)\mathbf{c}$$

或者, 令 $D = n_a + n_c + 1$,

$$\begin{aligned} \psi_s^T \mathbf{x} &= 0, \quad \psi_s = [\varphi^T(s)\mathbf{f}(s)]^T \in \mathbf{R}^D \\ \mathbf{x} &= \begin{bmatrix} \mathbf{a} \\ \mathbf{c} \end{bmatrix} \in \mathbf{R}^D \end{aligned}$$

假设 1. $\|\mathbf{c}\|_2 = 1$, 并且 \mathbf{c} 的第 1 个非零元素为正, 也就是说, 基函数向量 $\mathbf{f}(\cdot)$ 中元素对应的第 1 个非零系数为正.

定义 $\Psi_M = [\psi_1, \dots, \psi_M]^T$ 为稀疏建模动态负载, 给定矩阵 Ψ_M , 在这里采用交替方向法 (ADM) 方法来寻找非零稀疏向量 \mathbf{x}

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0, \quad \text{s.t. } \Psi_M^T \mathbf{x} = 0, \quad \mathbf{x} \neq 0 \quad (20)$$

或者

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0, \quad \text{s.t. } \mathbf{x} \in \mathcal{S} \setminus \{0\} \quad (21)$$

其中, 子空间 $\mathcal{S} = \text{Null}(\Psi_M) \subseteq \mathbf{R}^D, \dim(\mathcal{S}) = w$. 以上可以松弛为^[39]

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1, \quad \text{s.t. } \mathbf{x} \in \mathcal{S}, \quad \|\mathbf{x}\|_2 = 1 \quad (22)$$

或等价于

$$\min_{\mathbf{x}, \mathbf{q}} \|\mathbf{x}\|_1, \quad \text{s.t. } U\mathbf{q} = \mathbf{x}, \quad \|\mathbf{q}\|_2 = 1 \quad (23)$$

其中, $U \in \mathbf{R}^{D \times w}$ 对于 \mathcal{S} 是一个正交基矩阵, 即 $U^T U = I_w$. 式 (23) 的增强拉格朗日函数为

$$L(\mathbf{x}, \mathbf{q}, \boldsymbol{\mu}) = \|\mathbf{x}\|_1 - \boldsymbol{\mu}^T (U\mathbf{q} - \mathbf{x}) + \frac{\beta}{2} \|U\mathbf{q} - \mathbf{x}\|_2^2$$

其中, $\boldsymbol{\mu} \in \mathbf{R}^D$ 是拉格朗日乘数, 且 $\beta > 0$ 为惩罚参数. 对于合适的 $\boldsymbol{\mu} \in \mathbf{R}^D$, 式 (23) 的全局优化值可以通过最小化增强拉格朗日函数来求解:

$$\min_{\mathbf{x} \in \mathbf{R}^D, \mathbf{q} \in \mathbf{S}^{w-1}} L(\mathbf{x}, \mathbf{q}, \boldsymbol{\mu}) \quad (24)$$

其中, \mathbf{S}^{w-1} 是 \mathbf{R}^w 中的单位超球面. 给定初始值 $\mathbf{q}^0 \in \mathbf{R}^w, \boldsymbol{\mu}^0 \in \mathbf{R}^D$, 关于 \mathbf{x}, \mathbf{q} 的交替优化为

$$\mathbf{q}^{k+1} = \arg \min_{\mathbf{q} \in \mathbf{S}^{w-1}} L(\mathbf{x}^k, \mathbf{q}, \boldsymbol{\mu}^k)$$

$$\mathbf{x}^{k+1} = \arg \min_{\mathbf{x} \in \mathbf{R}^D} L(\mathbf{x}, \mathbf{q}^{k+1}, \boldsymbol{\mu}^k)$$

$$\boldsymbol{\mu}^{k+1} = \boldsymbol{\mu}^k - \beta(U\mathbf{q}^{k+1} - \mathbf{x}^{k+1})$$

$L(\mathbf{x}^k, \mathbf{q}, \boldsymbol{\mu}^k)$ 关于 \mathbf{q} 的梯度并置零为

$$\nabla_{\mathbf{q}} L(\mathbf{x}^k, \mathbf{q}, \boldsymbol{\mu}^k) = -U^T \boldsymbol{\mu}^k + \beta(\mathbf{q} - U^T \mathbf{x}^k) = 0$$

对于所有 k 和 $\boldsymbol{\mu}^k$. 令 $\mathcal{P}_{\mathbf{S}^{w-1}}$ 表示正交映射, 可将 \mathbf{R}^w 中的元素投影到单位球面 \mathbf{S}^{w-1} , 同时 ϵ 为足够小正数. 按照该过程, 在算法 2 中阐述了所提出的稀疏学习算法.

算法 2. 通过交替方向法 (ADM) 学习动态负载模型

输入. 给定一个正交基矩阵 $U \in \mathbf{R}^{D \times w}$ 和一个初始向量 $\mathbf{x}^0 \in \mathbf{R}^D, \boldsymbol{\mu}^0 \in \mathbf{R}^D$;

输出. 稀疏向量估计 $\hat{\mathbf{x}}$;

1: 令 $k = 0$;

2: **while** 不收敛 **do**

3: $\mathbf{q}^{k+1} = \mathcal{P}_{\mathbf{S}^{w-1}}(U^T \mathbf{x}^k + \frac{1}{\beta} U^T \boldsymbol{\mu}^k)$;

4: $\mathbf{x}^{k+1} = \mathbf{H}_{\beta}(\mathbf{x}^k - (1 - \epsilon)\boldsymbol{\alpha}^k)$, 其中, $\boldsymbol{\alpha}^k = \mathbf{x}^k - (U\mathbf{q}^{k+1} - \frac{1}{\beta}\boldsymbol{\mu}^k)$, $\mathbf{H}_{\beta}(\mathbf{x}) = \max\{|\mathbf{x}| - \frac{1 - \epsilon}{\beta}, 0\} \text{sgn}(\mathbf{x})$;

5: $\boldsymbol{\mu}^{k+1} = \boldsymbol{\mu}^k - \beta(U\mathbf{q}^{k+1} - \mathbf{x}^{k+1})$;

6: $k = k + 1$;

7: **end while**

4 结果验证

本节通过在孤岛微电网测试系统^[40]中进行仿真验证以说明负载稀疏建模算法的有效性. 需要说明的是文献 [40] 着重研究微电网频率和电压稳定控制器设计. 如图 3 所示, 孤岛微电网测试系统中有四个分布式发电装置, 四个局部负载和三条输电线路. 表 2 和表 3 分别列出了输电线路参数和孤岛微电网系统参数. 孤岛微电网通过公共连接点连接

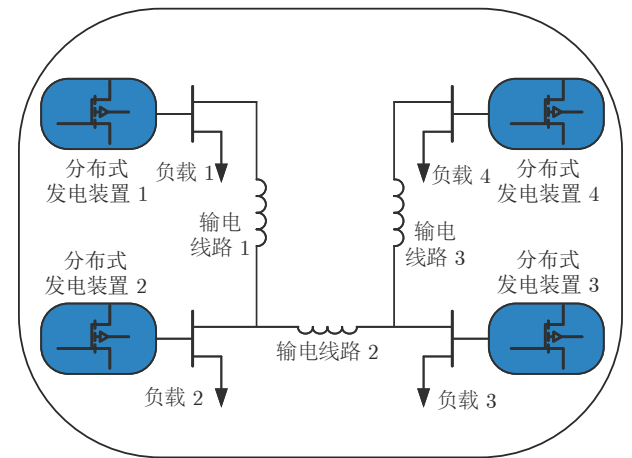


图 3 孤岛微电网测试系统

Fig.3 Islanded microgrid test system

到主电网. 以下将针对不同类型负载来解释所提出的数据驱动稀疏建模算法.

表 2 输电线路参数

Table 2 Parameters of transmission lines

输电线路	线路1	线路2	线路3
Ω^{-1}	10	10.67	9.82

表 3 微电网系统参数

Table 3 Parameters of the islanded microgrid

参数	μG_1	μG_2	μG_3	μG_4
$\tau_P(s)$	0.16	0.16	0.16	0.16
$K_P(s)$	4×10^{-5}	2×10^{-5}	3×10^{-5}	4×10^{-5}
$\tau_Q(s)$	0.16	0.16	0.16	0.16
$K_Q(s)$	4.2×10^{-4}	4.2×10^{-4}	4.2×10^{-4}	4.2×10^{-4}
P_Z	0.01	0.02	0.03	0.04
P_I	1	2	3	4
P_P	1×10^4	1.1×10^4	1.2×10^4	1.3×10^4
Q_Z	0.01	0.02	0.03	0.04
Q_I	1	2	3	4
Q_P	1×10^4	1.1×10^4	1.2×10^4	1.3×10^4

4.1 静态负载

4.1.1 ZIP 负载

在此仿真中, 负载分别设定为 100% 恒定阻抗负载, 100% 恒定电流负载和 100% 恒定功率负载. $t = 3$ s 时, 分布式控制器被激活, 电压可以快速恢复到其参考值 ($V^{\text{ref}} = 310$ V). 采样周期设为 0.01 s, 仿真周期设为 10 s, 以收集 1000 个数据点进行算法实施. 将 0.1% 高斯观测噪声添加到所有量测数据中.

对于表 4 所枚举的备选字典函数, 首先使用采集的时间序列生成备选字典函数矩阵. 对于负载 Z, I, P, 有功功率定义为输出. 对 1000 个采样点实施算法 1, 选定的字典函数如表 4 所示, 其中 1 个有效项可以从 5 个备选字典函数中稀疏学习得到. 在阈值 10^{-6} 下, 辨识得到的系数与表 2 中的设定值相同.

图 4~6 分别为恒定阻抗 (Z) 负载有功功率、恒定电流 (I) 负载有功功率和恒定功率 (P) 负载有功功率的辨识结果. 在图 4 中, 电压对辨识得到的恒定阻抗负载有功功率的影响是二次的, 因此, 有功功率变化最为明显的负载可以归结为此类负载; 在图 5 中, 电压对辨识得到的恒定阻抗负载有功功率的影响是线性的; 在图 6 中, 对于恒定功率负载, 辨识得到的有功功率保持恒定, 因为它与电压无关.

另外, 对于 Z, I, P 这三种负载综合组成的

表 4 负载 Z, I, P 稀疏辨识结果

Table 4 Sparse identification results for Z, I, P load

字典函数	Z	I	P
1	0	0	1×10^{-4}
V_1	0	1.001	0
V_1^2	0.098	0	0
V_1^3	0	0	0
V_1^4	0	0	0
1	0	0	1.1×10^{-4}
V_2	0	1.998	0
V_2^2	0.019	0	0
V_2^3	0	0	0
V_2^4	0	0	0
1	0	0	1.2×10^{-4}
V_3	0	2.999	0
V_3^2	0.031	0	0
V_3^3	0	0	0
V_3^4	0	0	0
1	0	0	1.4×10^{-4}
V_4	0	3.999	0
V_4^2	0.039	0	0
V_4^3	0	0	0
V_4^4	0	0	0




图 4 电压输出和恒定阻抗 (Z) 负载有功功率辨识结果

Fig. 4 Voltage output and identified real power of constant impedance load

ZIP 模型, 我们对其在孤岛微电网测试系统进行仿真, 其中电压输出如图 7 所示. 为验证所提出稀疏建模方法对噪声的鲁棒性, 添加 0.1% 高斯观测噪声到量测数据中.

在 4 个负载上分别实施算法 1 后, 3 个有效项从 7 个冗余字典函数中稀疏学习得到, 模型的参数经过多次迭代修正展示在表 5 中. 在阈值 10^{-6} 下,




图 5 电压输出和恒定电流 (I) 负载有功功率辨识结果
Fig.5 Voltage output and identified real power of constant current load




图 6 电压输出和恒定功率 (P) 负载有功功率辨识结果
Fig.6 Voltage output and identified real power of constant power load




图 7 孤岛微电网对于 ZIP 负载的电压输出
Fig.7 Voltage output of the islanded microgrid for ZIP load

表 5 ZIP 负载稀疏辨识结果
Table 5 Sparse identification results for ZIP load

字典函数	1	V	V ²	V ³	V ^{3.5}	V ⁴	V ⁶
负载1	1×10^4	1.001	0.011	0	0	0	0
负载2	1.1×10^4	2.005	0.019	0	0	0	0
负载3	1.2×10^4	2.993	0.029	0	0	0	0
负载4	1.3×10^4	4.009	0.041	0	0	0	0

辨识得到的系数与表 2 中真实设定值相同. 图 8 为 ZIP 负载有功功率和无功功率辨识结果, 其中功率输出在某种程度上取决于电压. 因此, 可以通过选择的模型结构和校准的模型参数来对 ZIP 负载进行稀疏建模.




图 8 ZIP 负载有功功率和无功功率辨识结果
Fig.8 Identified real and reactive power output of ZIP load

4.1.2 指数负载

对于指数负载, 表 1 中的空调、泵电机、大型工业电机和小型工业电机分别在图 3 孤岛微电网测试系统的四个负载中给予考虑. 给定冗余备选字典函数, 我们的目标是确定静态负载组成元件.

采样周期设为 0.01 s, 仿真周期设为 10 s, 以得到 1000 个采样点. 添加 0.1% 高斯观测噪声到量测数据中. 在实施算法 1 后, 指数负载稀疏辨识结果如表 6 所示, 与表 1 中的真实设定值相同. 对于稀疏学习得到的指数负载, 其有功功率和无功功率辨识结果如图 9 所示.

4.2 动态负载

在此仿真实验中, 一个包括有功功率和无功功率的动态负载添加到测试系统的负载 1 中. 为生成

表 6 指数负载稀疏辨识结果

Table 6 Sparse identification results for exponential load

字典函数	1	$V^{0.05}$	$V^{0.08}$	$V^{0.1}$	$V^{0.5}$	V	$V^{2.5}$
空调	0	0	0	0	1	0	0
泵机	0	0	1	0	0	0	0
大型工业电机	0	1	0	0	0	0	0
小型工业电机	0	0	0	1	0	0	0




图 9 指数负载有功功率和无功功率辨识结果

Fig.9 Identified real and reactive power output of exponential load

仿真数据, 动态负载模型表示为式 (25) 和式 (26) 的二阶系统

$$\begin{cases} \dot{x}_p = \begin{bmatrix} 0 & 1 \\ 1.6 & -0.8 \end{bmatrix} x_p + \begin{bmatrix} 0 \\ 1 \end{bmatrix} w_p \\ P_L = [1, 0]x_p \\ w_p = 0.9 + 0.4V + 0.173V^2 \end{cases} \quad (25)$$

$$\begin{cases} \dot{x}_q = \begin{bmatrix} 0 & 1 \\ 0.9 & -0.5 \end{bmatrix} x_q + \begin{bmatrix} 0 \\ 1 \end{bmatrix} w_q \\ Q_L = [1, 0]x_q \\ w_q = 0.8901 + 0.0979V + 0.4451V^2 \end{cases} \quad (26)$$

等效常微分方程模型表示为 $\dot{P}_L - 1.6\dot{P}_L + 0.8P_L = 0.9 + 0.4V + 0.173V^2$, 并且 $\dot{Q}_L - 0.9\dot{Q}_L + 0.5Q_L = 0.8901 + 0.0979V + 0.4451V^2$ 为对动态负载建模, 有功功率数据和无功功率数据将被采集以稀疏学习 Hammerstein 系统模型.

为验证算法对噪声的鲁棒性, 在输出量测噪声为零且标准差为 $\sigma = 10^{-4}$ 的情况下实施算法 2 用于稀疏学习 Hammerstein 系统. 通过使用采集的 120 个数据点, 模型参数被辨识为表 7 中的一个稀疏向量, 其中真实值 $\theta = [1, 1.6, 0.8, 0.9, 0.4, 0.173]$.

对于负载 1, 0.5 s 间隔内的电压输出和动态负载有功功率辨识结果如图 10 所示. 图 11 的结果表明, 随着迭代次数增加, 有功功率真实值与估计值的拟

表 7 动态负载稀疏辨识结果

Table 7 Sparse identification results for dynamic load

字典函数	有功功率	无功功率
$y(t)$	1.0001	1.0001
$q^{-1}y(t)$	-1.6003	-0.8997
$q^{-2}y(t)$	0.7998	0.5003
$q^{-3}y(t)$	0	0
$q^{-4}y(t)$	0	0
1	0.9002	0.8905
$V(t)$	0.4003	0.0984
$V^2(t)$	0.1727	0.4447
$V^3(t)$	0	0
$V^4(t)$	0	0





图 10 电压输出和动态负载有功功率辨识结果

Fig.10 Voltage output and identified real power of dynamic load




图 11 有功功率真实值与拟合残差

Fig.11 Fitting error of real power

合残差迅速降低. 所提出算法可以用一组系统输入和系统输出组成的基函数组来稀疏辨识未知 Hammerstein 系统. 因此, 动态负载可以通过选择合适的模型阶数或结构以及校准的模型参数来进行稀疏建模.

5 结束语

本文研究了一类数据驱动建模方法以从量测数据中稀疏学习静态负载和动态负载. 本文的主要贡献是同时实现了负载模型的结构选择和参数校准以规避以往研究方法所存在的模型误差问题. 这表明了一种可行的技术方式以建立具有电气特性的广义负载模型. 仿真研究说明所提出算法在孤岛微电网测试系统中对于负载稀疏建模合理性和对噪声的鲁棒性都具有良好的表现. 与此同时, 这项工作还有助于更好地理解非线性系统, 并有助于以数据驱动的方式对互联可再生能源系统进行研究.

References

- 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)
- R. H. Lasseter. Smart distribution: Coupled microgrids. *Proceedings of the IEEE*, 2011, **99**(6): 1074–1082
- Pepermans G, Driesen J, Haeseldonckx D, Belmans R, Dhaeseleer W. Distributed generation: Definition, benefits and issues. *Energy Policy*, 2005, **33**(6): 787–798
- Sun Q Y, Han R K, Zhang H G, Zhou J G, Guerrero J M. A multiagent-based consensus algorithm for distributed coordinated control of distributed generators in the energy internet. *IEEE Transactions on Smart Grid*, 2015, **6**(6): 3006–3019
- Sun Q Y, Zhang Y B, He H B, Ma D Z, Zhang H W. A novel energy function-based stability evaluation and nonlinear control approach for energy internet. *IEEE Transactions on Smart Grid*, 2017, **8**(3): 1195–1210
- Zhang Y, Xie L, Ding Q F. Interactive control of coupled microgrids for guaranteed system-wide small signal stability. *IEEE Transactions on Smart Grid*, 2016, **7**(2): 1088–1096
- Guedes R B L, Silva F H J R, Alberto L F C, Bretas N G. Large disturbance voltage stability assessment using extended Lyapunov function and considering voltage dependent active loads. In: Proceedings of the 2005 IEEE Power Engineering Society General Meeting. San Francisco, CA, USA: IEEE, 2005. 1760–1767
- Zhang K Q, Zhu H, Guo S M. Dependency analysis and improved parameter estimation for dynamic composite load modeling. *IEEE Transactions on Power Systems*, 2017, **32**(4): 3287–3297
- Ballanti A, Ochoa L F. Voltage-led load management in whole distribution networks. *IEEE Transactions on Power Systems*, 2018, **33**(2): 1544–1554
- Xu W, Vaahedi E, Mansour Y, Tamby J. Voltage stability load parameter determination from field tests on BC hydro's system. *IEEE Transactions on Power Systems*, 1997, **12**(3): 1290–1297
- Knyazkin V, Cañizares C, Soder L. On the parameter estimation and modeling of aggregate power system loads. *IEEE Transactions on Power Systems*, 2004, **19**(2): 1023–1031
- Jazayeri P, Rosehart W, Westwick D T. Multistage algorithm for identification of nonlinear aggregate power system loads. *IEEE Transactions on Power Systems*, 2007, **22**(3): 1072–1079
- Ding F, Liu X P, Liu G J. Identification methods for Hammerstein nonlinear systems. *Digital Signal Processing*, 2011, **21**(2): 215–238
- Karlsson D, Hill D J. Modelling and identification of nonlinear dynamic loads in power systems. *IEEE Transactions on Power Systems*, 1994, **9**(1): 157–166
- Choi B K, Chiang H D, Li Y H, Li H, Chen Y T, Huang D H, Lauby M G. Measurement-based dynamic load models: Derivation, comparison, and validation. *IEEE Transactions on Power Systems*, 2006, **21**(3): 1276–1283
- Ju P, Handschin E, Karlsson D. Nonlinear dynamic load modeling: Model and parameter estimation. *IEEE Transactions on Power Systems*, 1996, **11**(4): 1689–1697
- Rouhani A, Abur A. Real-time dynamic parameter estimation for an exponential dynamic load model. *IEEE Transactions on Smart Grid*, 2016, **7**(3): 1530–1536
- Regulski P, Vilchis-Rodriguez D S, Djurovic S, Terzija V. Estimation of composite load model parameters using an improved particle swarm optimization method. *IEEE Transactions on Power Delivery*, 2015, **30**(2): 553–560
- Miranian A, Rouzbehi K. Nonlinear power system load identification using local model networks. *IEEE Transactions on Power Systems*, 2013, **28**(3): 2872–2881
- Bostanci M, Koplowitz J, Taylor C W. Identification of power system load dynamics using artificial neural networks. *IEEE Transactions on Power Systems*, 1997, **12**(4): 1468–1473
- Chang G W, Chen C I, Liu Y J. A neural-network-based method of modeling electric arc furnace load for power engineering study. *IEEE Transactions on Power Systems*, 2010, **25**(1): 138–146
- Lu C H. Wavelet fuzzy neural networks for identification and predictive control of dynamic systems. *IEEE Transactions on Industrial Electronics*, 2011, **58**(7): 3046–3058
- Kontis E O, Papadopoulos T A, Chrysochos A I, Papagiannis G K. Measurement-based dynamic load modeling using the vector fitting technique. *IEEE Transactions on Power Systems*, 2018, **33**(1): 338–351
- Arif A, Wang Z Y, Wang J H, Mather B, Bashualdo H, Zhao D B. Load modeling—A review. *IEEE Transactions on Smart Grid*, 2018, **9**(6): 5986–5999
- Majumder R, Chaudhuri B, Ghosh A, Ledwich G, Zare F. Improvement of stability and load sharing in an autonomous microgrid using supplementary droop control loop. *IEEE Transactions on Power Systems*, 2010, **25**(2): 796–808
- 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)


- 27 Sun Qiu-Ye, Wang Rui, Ma Da-Zhong, Liu Zhen-Wei. An islanding control strategy research of we-energy in energy internet. *Proceedings of the CSEE*, 2017, **37**(11): 3087–3098 (孙秋野, 王睿, 马大中, 刘振伟. 能源互联网中自能源的孤岛控制研究. 中国电机工程学报, 2017, **37**(11): 3087–3098)
- 28 Zhang Y, Xie L. A transient stability assessment framework in power electronic-interfaced distribution systems. *IEEE Transactions on Power Systems*, 2016, **31**(6): 5106–5114
- 29 Kolluri R R, Mareels I, Alpcan T, Brazil M, Hoog J, Thomas D A. Power sharing in angle droop controlled microgrids. *IEEE Transactions on Power Systems*, 2017, **32**(6): 4743–4751
- 30 Kundur P. *Power System Stability and Control*. New York: McGraw-Hill, 1994.
- 31 Bokhari A, Alkan A, Doğan R, Diaz-Aguilo M, De Leon F, Czarkowski D, Zabar Z, Birenbaum L. Experimental determination of the ZIP coefficients for modern residential, commercial, and industrial loads. *IEEE Transactions on Power Delivery*, 2013, **29**(3): 1372–1381
- 32 Collin A J, Tsagarakis G, Kiprakis A E, McLaughlin S. Development of low-voltage load models for the residential load sector. *IEEE Transactions on Power Systems*, 2014, **29**(5): 2180–2188
- 33 Milanovic J V, Yamashita K, Villanueva S M, Djokic S Z, Korunovic L M. International industry practice on power system load modeling. *IEEE Transactions on Power Systems*, 2013, **28**(3): 3038–3046
- 34 Hatipoglu K, Fidan I, Radman G. Investigating effect of voltage changes on static ZIP load model in a microgrid environment. In: *Proceedings of the Conference on North American Power Symposium*. Champaign, USA: IEEE, 2012. 1–5
- 35 Bao Y, Wang L Y, Wang C S, Wang Y. Hammerstein models and real-time system identification of load dynamics for voltage management. *IEEE Access*, 2018, **6**: 34598–34607
- 36 Pan W, Yuan Y, Goncalves J, Stan G B. A sparse Bayesian approach to the identification of nonlinear state-space systems. *IEEE Transactions on Automatic Control*, 2016, **61**(1): 182–187
- 37 Qu Q, Sun J, Wright J. Finding a sparse vector in a subspace: linear sparsity using alternating directions. *IEEE Transactions on Information Theory*, 2016, **62**(10): 5855–5880
- 38 Palmer J A, Kreutz-Delgado K, Wipf D P, Rao B D. Variational EM algorithms for non-Gaussian latent variable models. *Advances in Neural Information Processing Systems*, 2006, **18**: 1059–1066
- 39 Zhang Z, Xu Y, Yang J, Li X L, Zhang D. A survey of sparse representation: Algorithms and applications. *IEEE Access*, 2015, **3**(1): 490–530
- 40 Guo F H, Wen C Y, Mao J F, Song Y D. Distributed secondary voltage and frequency restoration control of droop-controlled inverter-based microgrids. *IEEE Transactions on Industrial Electronics*, 2015, **62**(7): 4355–4364



平作为 华中科技大学人工智能与自动化学院博士研究生. 主要研究方向为智能电网, 系统辨识与非线性控制. E-mail: pingzuowei@hust.edu.cn (PING Zuo-Wei Ph.D. candidate at the School of Artificial Intelligence and Automation, Huazhong University of Science and Technology. His research interest covers smart grid, system identification, and nonlinear control.)



何 维 华中科技大学电气与电子工程学院博士后. 主要研究方向为电力电子装备建模, 稳定分析与控制. E-mail: hewei5590@hust.edu.cn (HE Wei Postdoctor at the School of Electrical and Electronic Engineering, Huazhong University of Science and Technology. His research interest covers modeling, stability analysis and control of power-electronized power systems.)



李俊林 华中科技大学人工智能与自动化学院博士研究生. 主要研究方向为系统辨识, 稀疏信号恢复, 非凸优化与高维统计. E-mail: jlli@hust.edu.cn (LI Jun-Lin Ph.D. candidate at the School of Artificial Intelligence and Automation, Huazhong University of Science and Technology. His research interest covers system identification, sparse signal recovery, nonconvex optimization, and high-dimensional statistics.)



杨 涛 东北大学流程工业综合自动化国家重点实验室教授. 主要研究方向为工业人工智能, 信息物理系统, 分布式协同控制和优化. 本文通信作者. E-mail: yangtao@mail.neu.edu.cn (YANG Tao Professor at the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University. His research interest covers industrial artificial intelligence, cyber physical system, and distributed collaborative control and optimization. Corresponding author of this paper.)