

分类号 TK01+8
U D C 621.3

密级
编号 10003

清 华 大 学

博 士 后 研 究 工 作 报 告

压缩感知与强化学习技术在能源互联网中的应用

梁 宏

工作完成日期 2019年10月—2021年10月

报告提交日期 2021年10月

清 华 大 学

2021年10月

压缩感知与强化学习技术在能源互联网中的应用
Application of compressive sensing and reinforcement learning technology
in Energy Internet

博 士 后 姓 名：梁宏

流动站（一级学科）名称：控制科学与工程

专 业（二级学科）名称：控制理论与控制工程

合 作 导 师：吉吟东 研究员

研究工作起止日期 2019年10月-2021年10月

摘要

本文主要介绍应用压缩感知和强化学习算法来求解能源互联网中的相关问题。首先，由于分布式能源的广泛并网，能源互联网中的潮流计算以及优化控制问题，通常含有随机性。由于压缩感知算法在求解随机问题上具有显著优势，因此本文给出了用压缩感知求解相应问题的算法原理和数值结果。其次，由于近年来，强化学习算法在求解无模型问题上的有效性，因此本文以微网储能控制问题为例，给出了强化学习算法在能源互联网中的应用流程。

主要研究结果如下：

1. 利用微网概率潮流随机变量展开的稀疏性，结合压缩感知算法理论，提出了将压缩感知理论用于能源互联网概率潮流求解的新方法，并数值验证所提方法的高效性。更进一步的，又提出了改进的压缩感知算法，通过主成分分析提取出特征基函数，使得随机状态变量的表达式在此基函数表达下更加稀疏，进而提高压缩感知的运算效率。

2. 提出将压缩感知技术与梯度下降法相结合求能源互联网随机控制问题的新解法，并对微网中两个具体的优化控制问题进行建模，得到两个高维、多约束，非线性随机优化问题，并数值验证了该方法在这两类问题上的有效性。

3. 以并网微网为研究对象，应用 Simulink 仿真技术，按照恒功率控制(PQ控制)原理，搭建了一个微网系统。然后以此仿真系统为基础，结合深度强化学习中的双重深度 Q 学习算法，训练得到储能控制的优化策略。

关键词：能源互联网，微网，概率潮流，压缩感知，随机控制，强化学习

Abstract

This report mainly introduces the application of compressive sensing and reinforcement learning algorithm in solving the related problems in Energy Internet. First of all, due to the extensive grid connection of distributed energy, the power flow calculation and optimal control problems in Energy Internet usually contain randomness. Due to the significant advantages of compressive sensing algorithm in solving stochastic problems, this report presents the algorithm flow and numerical results of solving corresponding problems with compressive sensing. Secondly, due to the effectiveness of reinforcement learning algorithm in solving model free problems in recent years, this report takes microgrid energy storage control problem as an example, and gives the application process of reinforcement learning algorithm in Energy Internet.

The main results are as follows:

1. Based on the sparsity of probabilistic power flow in microgrid and the theory of compressive sensing algorithm, a new method for probabilistic power flow in Energy Internet is proposed, and the efficiency of the proposed method is verified by numerical simulation. Further, an improved compressive sensing algorithm is proposed in this section. The feature basis function is extracted by principal component analysis, which makes the expression of random state variables more sparse under this expression, thus improving the computational efficiency of compressive sensing.

2. A new method is proposed to solve the Energy Internet stochastic control problem by combining compressive sensing technology with gradient descent method. Two specific optimization control problems in microgrid are modeled, and two high-dimensional, multi constraint, nonlinear stochastic optimization problems are obtained. Numerical results show the effectiveness of the method in such kinds of problems.

3. Taking the grid connected microgrid as the research object, a microgrid system is built according to the principle of constant power control (PQ) by using Simulink simulation technology. Then, based on the simulation system, combined with the double deep Q-learning algorithm in deep

reinforcement learning, the optimal strategy of energy storage control is trained.

Keywords: Energy Internet, Microgrid, Probabilistic Power Flow, Compressive Sensing, Stochastic Control, Reinforcement Learning

目录

摘要.....	2
目录.....	1
符号表.....	3
第一章 绪论.....	4
1.1 能源互联网概述.....	4
1.2 概率潮流概述.....	5
1.3 控制问题概述.....	6
1.4 压缩感知概述.....	7
1.5 强化学习概述.....	8
1.6 研究报告概要.....	9
第二章 压缩感知技术在概率潮流求解中的应用.....	10
2.1 引言.....	10
2.2 概率潮流计算模型.....	12
2.2.1 负荷功率波动模型.....	12
2.2.2 光伏功率波动模型.....	13
2.2.3 风机功率波动模型.....	13
2.2.4 概率潮流模型.....	14
2.3 基于压缩感知技术的概率潮流求解算法.....	15
2.3.1 相关性处理：Nataf 变换.....	15
2.3.2 PCE 展开.....	16
2.3.3 压缩感知算法流程.....	17
2.3.4 数值算例.....	18
2.4 基于改进的压缩感知技术的概率潮流求解算法.....	26
2.4.1 算法流程.....	26
2.4.2 数值算例.....	28
2.5 小结.....	34
第三章 压缩感知技术在能源互联网控制问题中的应用.....	35
3.1 引言.....	35
3.2 压缩感知求解控制问题算法.....	37
3.2.1 随机控制问题简介.....	37
3.2.2 布朗运动和白噪声.....	38

3.2.3 压缩感知算法.....	40
3.2.4 控制问题求解流程.....	44
3.3 基于压缩感知的能量路由器最优储能管理策略研究.....	46
3.3.1 背景介绍.....	46
3.3.2 系统建模.....	48
3.3.3 仿真结果.....	52
3.3.4 总结.....	60
3.4 基于压缩感知的家庭微网最优电力交易策略研究.....	61
3.4.1 背景介绍.....	61
3.4.2 系统建模.....	62
3.4.3 仿真结果.....	66
3.4.4 结论.....	69
3.5 小结.....	69
第四章 基于深度强化学习的微网储能系统控制策略研究.....	70
4.1 引言.....	70
4.2 微网组成与 Simulink 仿真设计.....	71
4.2.1 微网组成模块.....	72
4.2.2 Simulink 仿真设计.....	72
4.3 深度强化学习算法.....	75
4.3.1 算法框架.....	76
4.3.2 深度强化学习在微网控制问题中的应用.....	77
4.4 实验验证.....	79
4.4.1 实验设置.....	79
4.4.2 数值结果.....	80
4.5 总结.....	82
第五章 总结与展望.....	84
参考文献.....	85
致谢.....	96
附录 1: 118 节点仿真算例数值结果.....	97
附录 2: 第四章仿真模型参数设置.....	107
项目及研究成果.....	108
个人简介.....	110

符 号 表

EI	Energy Internet. 能源互联网
RES	Renewable Energy Source. 可再生能源
PPF	Probabilistic Power Flow. 概率潮流
PCE	Polynomial Chaos Expansion. 多项式混沌展开
MC	Monte Carlo. 蒙特卡罗
CS	Compressive Sensing. 压缩感知
PCA	Principle Component Analysis. 主成分分析
GDM	Gradient descent method. 梯度下降法
ER	Energy Router. 能量路由器
MG	Microgrid. 微网
DG	Distributed Generator. 分布式发电机
SODE	Stochastic Ordinary Differential Equation. 随机常微分方程
RL	Reinforcement Learning. 强化学习
DRL	Deep Reinforcement Learning. 深度强化学习
BES	Battery energy storage. 电池储能

第一章 绪论

1.1 能源互联网概述

能源互联网可以定义为使用先进的信息技术，电力电子设备和各种智能方式将大量分布式能量收集设备和能量存储设备互连的网络。在该网络中，可以实现节点之间能量的双向流动和交易^{[1][2]}。

传统化石资源对环境的破坏越来越严重。开发利用可再生能源是解决能源短缺和环境问题的重要手段。幸运的是，随着互联网技术的飞速发展，研究人员找到了一种利用新能源的有效途径，即以互联网为载体，将新能源与整个能源系统联系起来，形成一个庞大的能源互联网。能源互连的概念最早是在里夫金（Rifkin）的“第三次工业革命”中提出的^[3]。能源的相互联系是第三次工业革命的重要支撑。这一概念一经提出，便得到广泛认可。

到目前为止，能源互联网已经拥有较为完整的系统架构。微电网和分布式能源部门是能源互联网的基本组成部分。微网的能量收集，存储，传输，消耗和新能源产生构成了“局域网”。能源互联网已经实现了任何微分布式能源的并网访问。在以大型电网为骨干网的基础上，它可以访问各种分布式新能源。大电网在传输效率和稳定性方面具有绝对优势。新能源在灵活性方面具有优势，因此能源互联网结合了双方的优势，并实现了自下而上的分散式协作管理模型，该模型将分散式和集中式相结合，补充了现有的电力网络^[4-6]。

为了实现能源网络的互联调度，提高能源生产和分配水平，研究人员提出并设计了一种新型的电力设备——能量路由器^{[7][8]}（或称为能量集线器（energy hub）^[9]，或电力路由器（power router）^[10]）。能量路由器的概念最早是由美国研究人员提出的。2008年，一个名为未来可再生能源输送与管理系统的（FREEDM system）^[11]的项目研究了一种基于可再生能源发电和分布式储能设备的新型电网结构。FREEDM研究人员提出了能量路由器的概念，并实现了其原型设计^[8]。同年，瑞士的一个研究小组开发了所谓的能源中心^[9]。它源于计算机科学中的集线器概念，也称为能量控制中心。2013年，日本研究人员提出了功率路由器的概念，即能够调度和管理一定区域功率的装置。与信息路由器在互联网中的作用类似，能量路由器可以看作是能源互联网中的能量转发和缓存节点。作为能量交换的中间媒体，能量路由器可以实现整个网络的功率平衡^{[12][13]}。更重要的

是，能量路由器还可以通过收集和处理能源信息，有效地控制电能质量，优化能源传输成本。在能源互联网场景中，能量路由器被视为核心功率路由和控制设备。典型的能源互联网场景如图 1.1 所示。



图 1.1 区域能源互联网场景

1.2 概率潮流概述

潮流计算是研究电力系统规划和运行的最为基础的手段，其主要任务是根据发电运行方式，负荷和系统接线方式求解母线电压幅值和相角，各元件中通过的功率等等。电力系统潮流计算研究系统的平衡运行状态，不涉及元件的动态属性及其过渡过程，因此潮流计算的数学模型中不包含微分方程。潮流计算的本质为求解高阶非线性方程组，常用的方法包括高斯-赛德尔法，牛顿-拉弗逊法，PQ 解耦法等等^{[14][15]}。

随着智能电网和能源互联网的发展，电力系统运行工况日益复杂，电力系统中的不确定因素大大增加，确定性的潮流计算方法已不能全面地反映系统运行情况，不确定分析手段被引入到电力系统中。作为传统确定性方法的有效补充，概率潮流是分析电力系统随机特性的有效手段之一。概率潮流可计及各种随机因素的影响，获得节点电压和支路潮流的统计矩和概率分布，为系统规划和运行提供更加有效和全面的参考信息。

在电力系统规划和运行中，一直存在着众多不确定因素，例如负荷变化和故障等等。在传统电网中，电网规模较小，电力系统运行工

况简单，加之不确定因素对电网运行的影响较小，因此确定性的潮流分析方法能够较为准确地描述系统特性。随着我国电网的发展，加快西南水电开发，大规模发展太阳能发电和风电，依托特高压和智能电网将位于中西部的清洁能源输送到东部负荷中心是全面落实国家新能源发展规划的主要方式^{[16][17]}。特高压交直流输电系统的建设和发展使得我国电网规模不断扩大，新能源发电受气候和环境等因素的影响，与传统的火电和水电相比，发电机出力具有很强的不确定性和波动性^[18]。

概率潮流是分析电力系统随机特性的有效手段之一，其最早由 Borkowska 在 1974 年首先提出，随后有学者对其进行了一些拓展^[19-22]，但是概率潮流的相关研究并未受到学术界的重视。近年来，随着新能源发电和电动汽车的发展，概率潮流又重新成为电力系统分析领域的研究热点。概率潮流计算的本质为求解含随机变量的高维非线性方程组，概率潮流计算的目的是获得节点电压和线路潮流的变化信息。相比于传统的确定性潮流分析手段，概率潮流能够得到更加丰富的信息，包含节点电压和线路潮流的期望和标准差；节点电压和线路潮流最可能出现的数值；节点电压和线路潮流的分布区间；节点电压和线路潮流超过或者低于某阈值的可能性等等。

当前，概率潮流在已被成功应用于随机规划^[23-25]，静态安全分析^{[26][27]}，风险评估^[28-30]，新能源发电^[31-33]，电动汽车运行^[34]，发电机组检修^[35]等等领域。以静态安全分析为例，传统的静态安全分析一般进行 N-1 或 N-2 分析。N-1 方法是评估电网安全性的重要手段，但是也存在一定的不足：只分析故障产生的后果，没有考虑故障发生的可能性；研究单个元件故障对潮流的影响，忽略了对系统影响更加显著的多个元件同时故障。一种更为合理的方式是同时考虑系统运行状态和该状态存在的可能性，评估电网的运行风险。若将元件故障设置为服从离散分布的随机变量，则静态安全分析可以表示为概率潮流问题。通过对该问题进行求解，并分析节点电压和线路潮流的概率分布，即可获得系统运行的安全指标。

1.3 控制问题概述

由于可再生能源的接入，使得能源互联网的优化控制问题更加复杂。在电网发展迅速的今天，为了让微电网更加能够对可再生能源进行整合并且实现与配电网间的相互支撑和协调运行，在微电网的能量管理及控制策略方面国内外已经展开了深入的研究。文献[36]指出，能源互联网可以被视为智能电网的 2.0 版本。能源互联网是基于互联网的广域网，

其直接集成信息和能量，以主电网为骨干网，而局域网可以是微电网或分布式能源。基于文献[37-39]，能源互联网的基本能量管理准则是优先地、自主地实现单个微网功率供需平衡。如果该平衡难以实现，应当施加广域网络的能量交换。与其他形式的电力系统相比，能源互联网具有许多关键的技术特点。首先，在可再生能源高渗透下，能源互联网的能量控制与管理与传统电网有很大的区别^[40]。值得注意的是，分布式可再生能源将成为未来能源互联网的主体，其存在着不确定性、功率输出间歇性等缺陷^[41]。同时，当考虑电能交易时，实时电价的变化也具有随机性^[42]。因此，出于能源互联网系统中的动态随机特性，相关的控制、优化和调度问题正变得越来越具有挑战性^[43]。更重要的是，能源互联网运行在一个高信息量的环境中。分布式发电接入、储能和需求侧响应带来了海量数据，包括气象信息、用户功率特性和储能状态^[44]。随着先进测量技术的普及和应用，能源互联网中具有测量功能的智能终端数量将大幅增加，生成的数据量也将大幅增长^[45]。因此，能源互联网可以理解为一个由物质、能量和信息深度耦合的系统^[46]。作为一个社会、信息、物理相互依存的超大规模复杂网络，能源互联网比传统电网具有更大的开放性和系统复杂性^[47]。

1.4 压缩感知概述

近几年在图形图像以及信号处理等领域，发展出了一种非常有效的方法，即压缩感知方法。压缩感知方法是在 2004 年由 E. J. Candes、J. Romberg、T. Tao 和 D. L. Donoho 等科学家在信号处理领域提出的^[48-50]，该方法一经提出，就得到了广泛的认可和推广。传统的 Nyquist 采样定理要求，必须以信号带宽两倍的速率进行采样，才能精确地重建信号，这样就导致大部分的冗余信息在采集后又被丢弃，而采集信息的过程往往需要巨大的工作量，这样就造成了很大的资源浪费，进而 E. J. Candes 等人就考虑到利用信号本身的稀疏性，通过收集少量的信息就可以对信号进行精确的还原，所以提出了压缩感知方法，即直接感知压缩后的信息。压缩感知方法主要分为三个部分，第一信号的稀疏表达，需要选择一组标准正交基，使得信息在这组基下的表达式稀疏的，即信号中只有少数元素是非零的，其它都是零，第二是随机测量矩阵的选取，随机测量矩阵需要满足一定的不相关性，才能保证采集的信号能精确的还原成原信息，第三是信号还原的过程，因为该方法是以远低于带宽的速率收集信号的，所以最终在会得到一个关于原始信号和收集的样本直接的欠

定的方程组，因为信号的稀疏性，所以压缩感知方法中用传统的 L1 优化算法进行稀疏还原。

压缩感知方法创造性的将 L1 范数最小化稀疏约束与随机矩阵结合，得到一种稀疏信号重建的有效途径。由于大部分随机微分方程的解在某种随机多项式的表示下都具有稀疏性，因此考虑将压缩感知思想应用在随机偏微分方程的数值解上面，Doostan 等人已经做了很多应用压缩感知方法解随机微分方程的工作^{[51][52]}。

由于对能源互联网场景下的概率潮流问题和优化控制问题的求解都离不开对随机方程的求解，因此，为了克服传统方法在求解高维随机非线性等问题上的不适用性，本文采用压缩感知的思想求解类似问题。

1.5 强化学习概述

强化学习，又称再励学习、评价学习或增强学习，是机器学习的范式和方法论之一，用于描述和解决智能体在与环境的交互过程中通过学习策略以达成回报最大化或实现特定目标的问题。强化学习的常见模型是标准的马尔可夫决策过程。按给定条件，强化学习可分为基于模式的强化学习和无模式强化学习，以及主动强化学习和被动强化学习。强化学习的变体包括逆向强化学习、阶层强化学习和部分可观测系统的强化学习。求解强化学习问题所使用的算法可分为策略搜索算法和值函数算法两类。深度学习模型可以在强化学习中得到使用，形成深度强化学习。

随着人工智能技术的发展，强化学习受到研究者的关注，并开始应用于风储协作^[53]、风力发电控制^[54]、负荷响应^[55]等电力系统领域。文献[56]引入强化学习建立相应模型用于微网能量管理，取得了较好的效果。从这些研究来看，强化学习算法非常适用于解决能量调度及成本最小化问题。但是，这些研究多关注于微电网，而且基于传统强化学习算法，在面对复杂环境或连续动作时无法解决策略集的维数灾难，难以实际应用与推广，若将其推广到更为复杂的多能源网将面临更大的挑战。随着谷歌 Deepmind 团队在 2015 和 2016 年的《Nature》杂志上分别公布了基于 Atari 视频游戏的深度强化学习算法^[57]和计算机围棋机器人 AlphaGo^{[58][59]}，以深度强化学习为代表的新一代人工智能技术，迎来了蓬勃发展的新时代。将具备感知能力的深度学习引入具备决策能力的强化学习，形成的深度强化学习算法展现出了超越以往大部分人工智能算法的性能^[60]。近年来，深度强化学习算法在电力系统的应用也引起了一些学者的关注。文献[61]提出一种基于深度强化学习的微电网复合储能

协调控制方法，依据电网运行环境信息通过数据分析得到控制策略。文献[62]根据采用深度神经网络预测的负荷及光伏出力，结合强化学习对微电网系统进行最优能量调度，显著降低了用电成本。文献[63]基于能源互联网的运行优化问题，应用无模型深度强化学习算法得到解决方案，并通过数值模拟评估了所提方法的可行性和性能。

1.6 研究报告概要

本节主要简单地介绍了本报告中接下来每个章节的主要研究内容及贡献。

第二章利用微网概率潮流随机变量展开的稀疏性，结合压缩感知算法，提出了将压缩感知理论用于能源互联网概率潮流求解的新方法，并数值验证所提方法的高效性。更进一步的，本节又提出了改进的压缩感知算法，通过主成分分析提取出特征基函数，使得随机状态变量的表达式在此基函数表达下更加稀疏，进而提高压缩感知的运算效率。

第三章对微网的两个具体的优化调度问题进行建模，分别得到两个高维度、多约束，非线性随机优化问题，传统方法如线性规划、动态规划等受到计算复杂性影响难以求解。得益于压缩感知技术在求解随机微分方程上的高效性，本章提出将压缩感知技术与梯度下降法相结合求能源互联网随机控制问题的新解法，并数值验证了该方法的有效性。

第四章以并网微网为研究对象，应用 Simulink 仿真技术，按照恒功率控制(PQ 控制)原理，搭建了一个包含外部电源、光伏发电、储能，以及负荷的微网系统。然后以此仿真系统为基础，结合深度强化学习中的双重深度 Q 学习算法，以最小化微网 24 小时从外电网取电费用为目标，在满足微网系统电压偏差、功率平衡以及储能的荷电状态等约束下，以储能的实时充放电功率为控制变量，训练得到储能控制的优化策略。并通过实验验证与传统方法进行对比，分别从定性角度分析了储能充放电策略的合理性，和从定量角度展示了该文所提方法在优化购电费用上的有效性。

第五章总结了本研究报告的主要成果，并对未来研究方向做出适当展望。

第二章 压缩感知技术在概率潮流求解中的应用

2.1 引言

为应对全球能源危机与环境污染问题，大力发展清洁能源是全球各国的共同举措。能源互联网(Energy Internet, EI)作为一种集成分布式电源、储能系统，以及负荷的发配用电系统，能够有效消纳清洁能源，具有广阔的发展前景。然而，随着可再生能源(Renewable Energy Source, RES)的渗透率不断提高，以风电和太阳能为代表的间歇性能源所带来的不确定性因素增多，能源互联网的稳定运行受到挑战。由于不确定因素的影响，传统的确定性潮流分析方法将不再适用于对能源系统运行状态进行分析，由此发展起来了概率潮流计算方法。

概率潮流(Probabilistic Power Flow, PPF)计算能有效的考虑能源互联网系统的多种不确定因素，分析系统潮流的概率特性，帮助监测系统潜在危机，对保障系统的安全稳定运行具有重要意义。概率潮流最早由Borkowska于20世纪70年代提出，其实质是求解以节点注入功率等为输入随机变量、以电力系统状态量为输出随机变量的潮流方程，从而得到电力系统状态量的概率分布特征量^[64]。现有概率潮流解法主要有模拟法、解析法、近似法、多项式混沌展开法(Polynomial Chaos Expansion, PCE)四类。蒙特卡罗(Monte Carlo, MC)类方法以及其相关改进算法^{[65][66]}作为模拟法的代表被广泛应用，其基本思想是对输入变量进行大规模抽样，然后得到相应的样本解，再对样本解进行统计分析。该方法的优点是原理简单、操作方便，但是缺点是收敛率低，大规模采样会导致计算效率低下，大样本蒙特卡罗方法通常作为其他概率潮流准确度的对比评估标准。解析法主要指半不变量法^[67]，该方法不需要抽样，利用半不变量对线性函数的齐次可加性，直接由输入随机变量的各阶半不变量以及输入输出变量间的线性函数关系得到输出随机变量的各阶半不变量，进而得到输出随机变量的各阶矩，只需进行简单的算术运算即可获得随机潮流解，其突出特点是计算速度快，但其缺点是需要基准运行点处对潮流方程进行线性化，因而当输入随机变量波动范围大时其计算结果的误差较大。点估计法^[68]是典型的近似法，基本思想为根据各输入随机变量的前几阶矩来生成确定性的样本点及其权重，并利用这些样本点和权重求出输出随机变量的各阶矩。该方法的优点在于所需样本较少、计算速度快，但因为只利用了输入随机变量前几阶矩的信息（如三点估计方

法利用前四阶矩），因而对输出随机变量的高阶矩的计算误差较大。

广义混沌多项式法^[69-71]是基于多项式函数逼近理论的不确定性量化方法，其基本思想是用以输入随机变量为自变量的正交多项式基函数的线性组合逼近输入输出随机变量间的函数关系，再由该多项式逼近函数快速地求出输出变量的各阶矩和概率密度。该方法由于能用多项式函数精确逼近原输入输出变量间的函数关系，所以具有很高的计算精度。根据基函数系数计算方式的不同，广义混沌多项式法可分为随机 Galerkin 法^[72]和随机配置点法^[73]。随机 Galerkin 法先将系数待定的多项式逼近函数代入随机潮流方程，然后将该随机方程组转化为确定性的非线性方程组进行求解，从而得到基函数系数。其优点是求解过程为全解析计算，计算精度高。但该方法对潮流方程的转化操作较为复杂，且转化后的确定性非线性方程个数是原来的基函数项数倍，而基函数项数又随着随机变量数的增加而迅速增加，所以该方法在系统规模大、随机变量数多的情形下因所求解的非线性方程个数过大而难以应用。随机配置点法只需要从潮流方程中获得输入随机变量取每个积分点（即配置点）时相对应的输出变量的值，就可以计算出基函数系数。由于不涉及潮流方程的转换操作，所以随机配置点法能方便地应用于大规模系统的计算；但经典随机配置点法缺乏数值积分规则的选取准则，可能因选取的数值积分规则的代数精度偏低而基函数系数计算不准确，或因数值积分规则的代数精度偏高而计算量偏大、计算效率偏低。此外，如何选取合适的基函数集来构成多项式逼近函数也是随机 Galerkin 法和随机配置点法共同面临的一个难题。文献[74]提出了一种新型伪谱的随机配置点法—自适应稀疏伪谱逼近法，该方法一方面基于可自适应扩展的一般 Smolyak 稀疏网格实现了基函数集的灵活构造；另一方面利用张量积逼近网格与张量积积分规则的配对技术实现了基函数系数的准确计算；从而完全克服了经典随机配置点法的缺点而具有很高的计算效率。文献[75]对[74]进行了一些改进，从而提出了自适应稀疏伪谱逼近新方法，并将该方法应用于随机状态估计中，其计算效率远高于基于蒙特卡洛方法随机状态估计。文献[76]提出里基于随机响应面法的稀疏混沌多项式展开法，通过最小角回归方法降低多项式展开的基函数个数，进而分析可再生能源的不确定性对系统线路损耗、节点电压、频率等的影响。

本节在现有解法的基础上，利用微网概率潮流随机变量展开的稀疏性，结合图像处理领域非常热门的压缩感知 (Compressive Sensing, CS) 算法理论，提出了将压缩感知理论用于能源互联网概率潮流求解的新方法。该方法虽然形式上应用了 PCE 的随机多项式展开，但是在求解展开式系数时，采用抽样方法进行求解，避免了 PCE 中对大型复杂方程组的求解，

进而解决了维数灾难的问题，同时该方法相比于传统 MC 方法大大的减少了采样个数，提高了 MC 方法的运算效率。接下来，在传统压缩感知算法的基础上，利用主成分分析理论，对随机状态变量的协方差矩阵进行特征分解，得到一组由特征向量组成的标准正交基。然后，将随机状态变量的 PCE 展开系数进行特征变换，得到新的展开式系数，并且从理论上证明了特征变换后的展开式系数更加稀疏。因此，结合压缩感知的误差理论^[50]可知，展开式系数矩阵越稀疏，还原到相同精度所需样本数越少，并且通过数值结果证明所提方法在求解精度和运算效率上相较于传统压缩感知方法有显著提升。

本节结构安排如下：首先，在 2.1 引言中介绍概率潮流背景以及现有求解方法，然后在 2.2 中给出所要求解的概率潮流技术模型的具体形式。2.3 节为本章核心内容，详细的介绍了压缩感知算法求解概率潮流的流程，并通过仿真结果分析说明了压缩感知算法的有效性，并且作为 2.3 节的延申，2.4 节进一步介绍了改进的压缩感知算法，并通过与传统压缩感知算法对比，从理论和实验两方面说明了所提算法的高效性。最后，在 2.5 节中对本章内容进行简单总结。

2.2 概率潮流计算模型

本节所考虑的能源互联网潮流的随机性主要来自于节点负荷功率波动和可再生发电节点(如光伏和风力发电)的功率波动。本节分别给出负荷、光伏、风力发电的概率模型，然后给出相应的概率潮流方程。

2.2.1 负荷功率波动模型

受到地理环境、时间、用户行为等多种不确定因素的影响，电网中的负荷节点的功率波动具有一定的随机性。这种随机性通常可以用正态分布来描述，其概率密度函数为^[77]：

$$\begin{cases} f(P_L) = \frac{1}{\sqrt{2\pi}\sigma_{P_L}} \exp\left\{-\frac{(P_L - \mu_{P_L})^2}{2\sigma_{P_L}^2}\right\} \\ f(Q_L) = \frac{1}{\sqrt{2\pi}\sigma_{Q_L}} \exp\left\{-\frac{(Q_L - \mu_{Q_L})^2}{2\sigma_{Q_L}^2}\right\} \end{cases} \quad (2-1)$$

其中， P_L 为负荷有功功率， μ_{P_L} 和 σ_{P_L} 分别是负荷有功功率的期望和方差， Q_L 为负荷的无功功率， μ_{Q_L} 和 σ_{Q_L} 分别是负荷无功功率的期望和方差。通常情况下，方差 σ_{P_L} 和 σ_{Q_L} 的大小取为期望值 μ_{P_L} 和 μ_{Q_L} 的 5% 左右。

2.2.2 光伏功率波动模型

由于光伏发电功率的大小主要取决于太阳光照强度，且太阳光照强度的分布近似服从 Beta 分布，因此可以用 Beta 分布函数来描述光伏发电功率的波动，其概率密度函数为^[78]：

$$f(\hat{P}_{PV}) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \hat{P}_{PV}^{\alpha-1} (1 - \hat{P}_{PV})^{\beta-1} \quad (2-2)$$

其中， \hat{P}_{PV} 为光伏有功出力 P_{PV} 和光伏电源最大有功功率 P_{PV}^{\max} 的比值， $\Gamma(\cdot)$ 为 Gamma 函数， α 和 β 为 Beta 分布的参数。光伏发电的功率因数可视为一常数，无功功率可由有功功率确定。

2.2.3 风机功率波动模型

与光伏功率类似，风力发电功率的随机性主要受到风速的影响，且风速通常由双参数的 Weibull 分布描述，其概率密度函数为^[79]：

$$f(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} \exp\left\{-\left(\frac{v}{c}\right)^k\right\} \quad (2-3)$$

其中， v 为风速， k 和 c 分别为 Weibull 分布的形状参数和尺度参数。

根据风力发电的技术原理，当风速小于一定值时或者大于某个阈值时，风机发电功率为零。因此，只有在合理的风速区间，风机才能正常工作。具体地，风力发电的有功功率与风速满足如下的分段函数关系式 (2-4)，其中， $P_w(v)$ 示风速为 v 时的有功功率， P_r 为风力机组额定功率， v_{ci} , v_r , v_{co} 分别为切入风速、额定风速和切出风速。

$$P_W(v) = \begin{cases} 0, & v \leq v_{ci} \\ \frac{P_r(v-v_{ci})}{v_r-v_{ci}}, & v_{ci} \leq v \leq v_r \\ P_r, & v_r \leq v \leq v_{co} \\ 0, & v \geq v_{co} \end{cases} \quad (2-4)$$

结合式(2-3)和(2-4)可推出风力发电有功功率概率分布为:

$$f(P_W) = \begin{cases} 1 - \exp\left\{-\left(\frac{v_{ci}}{c}\right)^k\right\} + \exp\left\{-\left(\frac{v_{co}}{c}\right)^k\right\}, & P_W = 0 \\ \frac{k}{k_1} \left(\frac{P_W - k_2}{k_1 c}\right)^{k-1} \exp\left\{-\left(\frac{P_W - k_2}{k_1 c}\right)^k\right\}, & 0 \leq P_W \leq P_r \\ \exp\left\{-\left(\frac{v_r}{c}\right)^k\right\} + \exp\left\{-\left(\frac{v_{co}}{c}\right)^k\right\}, & P_W = P_r \end{cases} \quad (2-5)$$

其中, $k_1 = P_r / (v_r - v_{ci})$, $k_2 = -k_1 v_{ci}$ 。在通常情况下, 风机采用恒功率因数控制的方式接入电网。因此, 风力发电的无功功率可由有功功率给出:

$$Q_W = P_W \tan(\cos^{-1} \phi_W) \quad (2-6)$$

其中, ϕ_W 表示风机发电的功率因数。

2.2.4 概率潮流模型

时刻保持功率平衡是电力系统正常运行的基本条件, 这需要各个节点的功率都满足如下的潮流方程^[80]:

$$\begin{cases} P_i = V_i \sum_{j=1}^m V_j (G_{ij} \cos \delta_{ij} + B_{ij} \sin \delta_{ij}) \\ Q_i = V_i \sum_{j=1}^m V_j (G_{ij} \sin \delta_{ij} - B_{ij} \cos \delta_{ij}) \end{cases} \quad (2-7)$$

其中 $i=1,2,\dots,M$ ， M 表示电网节点总数， P_i 和 Q_i 分别表示节点 i 的有功功率和无功功率，节点 i 可以是负载节点、光伏节点或者风机节点， V_i 表示节点 i 的电压幅值（同理， V_j 表示节点 j 的电压幅值）， δ_{ij} 表示节点 i 和相邻节点 j 之间的相位差， B_{ij}, G_{ij} 分别为系统导纳矩阵的虚部和实部。

由于系统节点注入功率包含随机负载、光伏和风力发电，因此注入有功功率 P_i 和无功功率 Q_i 是随机变量，式(2-7)即为所要求的概率潮流方程。通过给定的节点有功功率和无功功率，可以求出节点的电压幅值和相角的统计信息，进而求得相关线路潮流。

为讨论方便，式(2-7)可以简写为：

$$\mathbf{X} = F(\mathbf{Y}) \quad (2-8)$$

其中， \mathbf{X} 为随机潮流中所有随机变量构成的随机向量（如 P_i, Q_i 等，包括输入的负载、光伏和风力发电等的随机功率）， \mathbf{Y} 为所要求的状态变量组成的向量（如 V_i, δ_{ij} 等节点的电压幅值和相角）， $F(\cdot)$ 为由式(2-7)决定的随机向量 \mathbf{X} 和状态变量 \mathbf{Y} 之间的函数关系。

2.3 基于压缩感知技术的概率潮流求解算法

2.3.1 相关性处理：Nataf 变换

应用压缩感知理论进行概率潮流求解的前提是将随机状态变量进行 PCE 展开，然后利用展开式系数的稀疏特性，进行稀疏还原。对随机状态变量 PCE 进行展开要求随机变量之间是相互独立的，然而由于在同一能源互联网系统中，随机变量之间通常具有相关性，因此不能直接进行展开，而是要进行相应的预处理，本节采用 Nataf 变换方法处理随机变量之间的相关性。所以本节先介绍 Nataf 变换原理和 PCE 变换，然后再给出压缩感知算法具体流程。

Nataf 变换用于处理输入变量之间的相关性，是在已知输入变量边缘分布的情况下重构联合分布的数学方法^[81]。对任意的 d 维输入变量 $\mathbf{Y}=[y_1, y_2, \dots, y_d]$ ，令 $[\eta_{Y_{ij}}]_{d \times d}$ 表示其相关系数矩阵，其中

$$\eta_{Y_{ij}} = \frac{\text{cov}(y_i, y_j)}{\sigma_i \sigma_j}$$

其中， σ_i, σ_j 分别为 y_i 和 y_j 的标准差， $\text{cov}(y_i, y_j)$ 为 y_i 和 y_j 的协方差。

y_j 的协方差, η_{y_j} 为相关系数。随机向量 Y 可以用 Nataf 变换转化为标准正态分布向量 $Z=[z_1, z_2, \dots, z_d]$:

$$Z_i = \phi^{-1}(\varphi_i(Y_i)), \quad i=1,2,\dots,d. \quad (2-9)$$

其中, φ_i 为 Y_i 的累积分布函数, ϕ 为标准正太分布的累积分布函数。

通过相关数学计算, 可由 X 的相关系数矩阵 $[\eta_{y_j}]_{d \times d}$ 计算出 Z 的相关系数矩阵, 进而得到满足正态分布的随机向量 Z , 然后通过 (2-9) 式的逆变换, 得到原随机向量 X 。因此原概率潮流方程 (2-8) 变为:

$$X = F(Y) = G(Z) \quad (2-10)$$

将随机输入变量转换成标准正态分布以后, 随机状态变量就可以用 Hermite 正交多项式进行展开。

2.3.2 PCE 展开

PCE 展开是采用一组正交多项式作为基函数, 然后截取有限项来逼近随机变量^[82], 对于概率潮流方程 (2-10), 可以用 Hermite 正交多项式进行展开:

$$X = G(Z) = \sum_{|i| \leq n} c_i H_i(Z) \quad (2-11)$$

式中, $i = (i_1, i_2, \dots, i_d) \in N_0^d$ 是多级指标, 且满足 $|i| = i_1 + i_2 + \dots + i_d$, n 是多项式展开阶数。 H_i 为 d 维随机变量的正交 Hermite 基函数, 由单重 Hermite 基函数的张量积 h_i 组成, 即:

$$H_i(Z) = h_{i_1}(z_1)h_{i_2}(z_2)\dots h_{i_d}(z_d)$$

且多重正交多项式 H_i 满足:

$$E[H_i(Z)H_j(Z)] = \int H_i(Z)H_j(Z)\rho(Z) = \gamma_i \chi_{ij} \quad (2-12)$$

χ_{ij} 为 Kronecker 函数 (当 $i=j$ 时为 1, 其他情况为 0), $\rho(Z)$ 为随机变量 Z 的联合概率密度函数, γ_i 为常数。 (2-11) 式中的 c_i 即是待求的展开式系数。已有研究证明, Hermite 正交基函数是满足独立分布的正态随机变量

的最佳平方逼近。因此求得展开式的系数就可以确定随机变量的各阶矩和概率分布。

目前已有的求解 PCE 展开式系数的方法，如 Galerkin 投影法^[72]、配置点法^[73]等都会有操作复杂和维数灾难等问题，因此本文利用随机变量展开的稀疏性，采用压缩感知算法对展开式系数进行还原。该方法采用样本解对系数进行还原，既继承了 MC 方法操作简单特点，又克服了 PCE 方法维数的问题。

2.3.3 压缩感知算法流程

由于展开式(2-11)中的系数 c 具有稀疏性，根据稀疏还原理论^[83]，可以通过采样方式，利用样本解来还原展开式系数 c ，具体流程为根据随机变量 Z 的概率分布随机选取 N 个样本点 $[Z^{(1)}, Z^{(2)}, \dots, Z^{(N)}]$ ，然后分别带入概率潮流方程(2-10)，得到 N 个样本解 $u = [X^{(1)}, X^{(2)}, \dots, X^{(N)}]$ ，并且满足方程：

$$\mathbf{u} = \Psi \mathbf{c} \quad (2-13)$$

其中， Ψ 为测量矩阵，由随机样本点 $[Z^{(1)}, Z^{(2)}, \dots, Z^{(N)}]$ 带入多重 Hermite 正交多项式得到，即：

$$\Psi = \begin{bmatrix} H_1(Z^{(1)}) & H_2(Z^{(1)}) & \dots & \psi_p(Z^{(1)}) \\ H_1(Z^{(2)}) & H_2(Z^{(2)}) & \dots & \psi_p(Z^{(2)}) \\ \vdots & \vdots & \ddots & \vdots \\ H_1(Z^{(N)}) & H_2(Z^{(N)}) & \dots & \psi_p(Z^{(N)}) \end{bmatrix}$$

Ψ 的维数为 $N \times p$ 维， p 是基函数个数，当 $p > N$ 时，方程组(2-13)是欠定方程组，因此系数 c 有无穷多组解，为了保证解的唯一性，需要施加额外的约束条件。通常希望尽可能减少展开式基函数的个数，即尽可能增加系数 c 的稀疏性，所以对 c 增加稀疏性约束，变成如下优化问题：

$$\min \|c\|_0 \quad s.t. \quad \Psi c = \mathbf{u} \quad (2-14)$$

其中 $\|\cdot\|_0$ 表示 l_0 范数，即 c 中非零元素的个数。但是由于 l_0 范数不连续，所以问题(14)是 NP 问题，求解困难，所以考虑对其进行松弛，其中 l_1 范数代替 l_0 范数就是最常用的松弛方式， l_1 范数表示的是矩阵中的所有元素

的绝对值之和。因此问题(2-14)就变为如下 l_1 最优化问题：

$$\min \|c\|_1 \quad s.t. \Psi c = \mathbf{u} \quad (2-15)$$

研究表明，问题(2-15)的解可以精确的近似问题(2-14)的解，而且 l_1 最优化问题求解更加方便，本文采样正交匹配追踪算法进行求解^[84]。

综上所述，基于压缩感知求解概率潮流方程的算法流程如下：

算法 1 {压缩感知 (Compressive Sensing, CS) 算法}：

- 根据随机输入的概率分布进行 Nataf 变换；
 - 将变换后的概率潮流方程进行 PCE 展开；
 - 根据正态分布随机选取 N 个样本点，用 Newton Raphson 等传统方法^[85] 求出样本解；
 - 构造压缩感知优化问题；
 - 采样正交匹配追踪算法进行求解，得到系数 c；
 - 将系数 c 带回展开式，得到状态变量的统计信息，然后进行分析。
-
-

2.3.4 数值算例

我们将上述求解概率潮流的算法在标准的 IEEE 30 节点上进行验证，并通过和 MC 方法对比来说明算法的准确性和高效性。概率潮流计算程序由 Matlab R2020 开发，潮流计算部分由 Matpower 软件包实现，计算平台为 Intel i7-8586U CPU，2G 内存独立显卡。

2.3.4.1 仿真设置

本节在 IEEE 30 节点的网架结构基础上，分别在节点 7，25 接入两

个风机，在节点 2，19 接入两个光伏，其中将节点 2 设置为 PV 节点，其余风机和光伏节点处理为 PQ 节点。同时将节点 3，12，18，26 设置为含有随机波动的负荷节点。系统线路参数与基准容量与 Matpower 自带的 30 节点算例一致。风机、光伏和随机负荷的参数设置分别在表 2.1, 2.2, 2.3 中给出。

表 2.1 风机参数

风机	P_r (MW)	v_r (m/s)	v_{co} (m/s)	c	k
WT 1	15	20	10.7	4	0.9
WT 2	14	22	8	3	3

表 2.2 光伏参数

光伏	P_{PV}^{max} (MW)	α	β
PV 1	50	0.9	0.85
PV 2	80	0.8	0.75

表 2.3 随机负荷参数

负载	μ_{PL} (MW)	μ_{QL} (MW)	σ_{PL} (MW)	σ_{QL} (MW)
Load 1	2.4	1.2	0.12	0.06
Load 2	11.2	7.5	0.56	0.375
Load 3	3.2	0.9	0.16	0.045
Load 4	3.5	2.3	0.175	0.115

并且两处风机发电直接的相关系数为 0.6，光伏发电的相关系数为 0.8，四处随机负荷之间的相关系数矩阵为：

$$\rho_{Load} = \begin{pmatrix} 1 & 0.6 & 0.2 & 0.7 \\ 0.6 & 1 & 0.3 & 0.4 \\ 0.2 & 0.3 & 1 & 0.4 \\ 0.7 & 0.4 & 0.8 & 1 \end{pmatrix} \quad (2-16)$$

2.3.4.2 仿真结果

为了验证基于压缩感知算法的概率潮流方法的准确性，以采样规模

为 500000 次的简单随机采样 MC 方法的计算结果作为参考。本节分别从算法准确性和计算效率两个方面对仿真结果进行分析。

1) 算法准确性

用各个节点输出电压幅值和相角的期望与标准差的相对误差的平均值 $\bar{\mu}$, $\bar{\sigma}$ 来刻画算法的精确度。

$$\begin{cases} \bar{\mu} = \frac{1}{M} \sum_{i=1}^M \frac{\mu_{i1} - \mu_{MC}}{\mu_{MC}} \\ \bar{\sigma} = \frac{1}{M} \sum_{i=1}^M \frac{\sigma_{i1} - \sigma_{MC}}{\sigma_{MC}} \end{cases} \quad (2-17)$$

如下所示,表 2.4, 2.5, 2.6 是由算法 1 计算得到的随机潮流的具体结果,包括整个系统信息、节点数据、和线路数据。

表 2.4 系统信息

System Summary				
How many?		How much?	P (MW)	Q (MVar)
Buses	30	Total Gen Capacity	335.0	-95.0 to 405.9
Generators	6	On-line Capacity	335.0	-95.0 to 405.9
Committed Gens	6	Generation (actual)	180.1	84.8
Loads	21	Load	176.3	88.0
Fixed	21	Fixed	176.3	88.0
Dispatchable	0	Dispatchable	-0.0 of -0.0	-0.0
Shunts	2	Shunt (inj)	-0.0	0.2
Branches	41	Losses ($I^2 * Z$)	3.73	12.72
Transformers	0	Branch Charging (inj)	-	15.6
Inter-ties	7	Total Inter-tie Flow	61.9	28.7
Areas	3			
		Minimum		Maximum
Voltage Magnitude		0.943 p.u. @ bus 19		1.000 p.u. @ bus 1
Voltage Angle		-8.04 deg @ bus 19		0.06 deg @ bus 2
P Losses ($I^2 * R$)		-	0.42 MW @ line 10-20	
Q Losses ($I^2 * X$)		-	2.09 MVar @ line 12-13	

表 2.5 节点数据

Bus Data						
Bus #	Voltage		Generation		Load	
	Mag (pu)	Ang (deg)	P (MW)	Q (MVar)	P (MW)	Q (MVar)
1	1.000	0.000*	14.39	2.86	-	-
2	1.000	0.062	60.97	8.06	1.73	0.25
3	0.983	-1.631	-	-	2.84	1.21
4	0.980	-1.917	-	-	7.60	1.60
5	0.990	-1.225	-	-	-	-
6	0.975	-2.310	-	-	-	-
7	0.980	-1.941	-	-	2.68	1.30
8	0.962	-2.788	-	-	30.00	30.00
9	0.980	-4.179	-	-	-	-
10	0.984	-5.149	-	-	5.80	2.00
11	0.980	-4.179	-	-	-	-
12	0.986	-3.146	-	-	11.82	7.56
13	1.000	-0.133	37.00	11.23	-	-
14	0.975	-4.201	-	-	6.20	1.60
15	0.976	-4.446	-	-	8.20	2.50
16	0.977	-4.324	-	-	3.50	1.80
17	0.976	-5.139	-	-	9.00	5.80
18	0.952	-6.832	-	-	3.57	1.02
19	0.943	-8.038	-	-	31.71	4.52
20	0.952	-7.356	-	-	2.20	0.70
21	0.993	-5.297	-	-	17.50	11.20
22	1.000	-5.211	21.59	41.46	-	-
23	1.000	-3.693	19.20	10.65	3.20	1.60
24	0.987	-4.492	-	-	8.70	6.70
25	0.985	-3.308	-	-	3.57	1.73
26	0.968	-3.801	-	-	3.52	2.08
27	1.000	-1.960	26.91	10.59	-	-
28	0.976	-2.428	-	-	-	-
29	0.980	-3.260	-	-	2.40	0.90
30	0.968	-4.173	-	-	10.60	1.90

Total:	180.06	84.85	176.33	87.96
--------	--------	-------	--------	-------

表 2.6 线路数据

Branch Data									
Branch #	From Bus	To Bus	From Bus P (MW)	Injection Q (MVar)	To Bus P (MW)	Injection Q (MVar)	Loss ($I^2 * Z$)		
							P (MW)	Q (MVar)	
1	1	2	-1.61	-0.96	1.61	-2.04	0.001		0.00
2	1	3	16.00	3.82	-15.86	-5.26	0.140		0.53
3	2	4	21.45	3.37	-21.17	-4.52	0.288		0.82
4	3	4	13.03	4.05	-13.01	-3.97	0.019		0.08
5	2	5	11.66	1.18	-11.59	-2.88	0.070		0.28
6	2	6	24.51	5.29	-24.13	-6.09	0.384		1.15
7	4	6	18.60	8.83	-18.56	-8.65	0.044		0.18
8	5	7	11.59	3.07	-11.51	-3.86	0.075		0.18
9	6	7	-8.81	-3.44	8.84	2.56	0.027		0.07
10	6	8	25.65	24.49	-25.52	-23.96	0.132		0.53
11	6	9	14.84	-2.34	-14.84	2.84	0.000		0.50
12	6	10	8.48	-1.34	-8.48	1.77	0.000		0.43
13	9	11	0.00	0.00	0.00	0.00	0.000		0.00
14	9	10	14.84	-2.84	-14.84	3.10	0.000		0.26
15	4	12	7.97	-1.94	-7.97	2.12	0.000		0.18
16	12	13	-37.00	-9.13	37.00	11.23	0.000		2.09
17	12	14	7.11	0.65	-7.04	-0.51	0.063		0.14
18	12	15	16.21	-1.06	-16.02	1.41	0.190		0.35
19	12	16	9.84	-0.13	-9.75	0.33	0.090		0.20
20	14	15	0.84	-1.09	-0.84	1.09	0.004		0.00
21	16	17	6.25	-2.13	-6.21	2.22	0.037		0.09

22	15	18	18.50	1.85	-18.10	-1.05	0.399	0.80
23	18	19	14.53	0.03	-14.39	0.27	0.140	0.30
24	19	20	-17.32	-4.79	17.43	5.05	0.109	0.25
25	10	20	20.04	6.72	-19.63	-5.75	0.416	0.97
26	10	17	2.81	8.08	-2.79	-8.02	0.023	0.06
27	10	21	-1.82	-12.62	1.87	12.73	0.050	0.12
28	10	22	-3.52	-9.05	3.58	9.20	0.068	0.15
29	21	22	-19.37	-23.93	19.46	24.13	0.096	0.19
30	15	23	-9.84	-6.85	9.99	7.16	0.151	0.30
31	22	24	-1.46	8.14	1.54	-8.02	0.082	0.12
32	23	24	6.01	1.89	-5.96	-1.78	0.052	0.11
33	24	25	-4.28	3.14	4.34	-3.04	0.055	0.10
34	25	26	3.57	2.15	-3.52	-2.08	0.045	0.07
35	25	27	-11.47	-0.83	11.62	1.12	0.150	0.29
36	28	27	-1.99	-5.94	1.99	6.11	-0.000	0.17
37	27	29	6.17	1.68	-6.08	-1.51	0.090	0.17
38	27	30	7.12	1.67	-6.95	-1.35	0.171	0.32
39	29	30	3.68	0.61	-3.65	-0.55	0.035	0.07
40	8	28	-4.48	-6.04	4.51	4.26	0.030	0.10
41	6	28	2.53	-2.62	-2.52	1.68	0.002	0.01
Total:							3.728	12.72

具体的，通过对以上结果进行整理分析，我们得出更加直观的数值结果，表格 2.7 给出了用算法 1 计算的各电压幅值 V 和相角 δ 的均值和标准差与 500000 次 MC 方法作为参照的误差值。

表 2.7 误差估计

算法 1	$\bar{\mu}_V$	$\bar{\delta}_V$	$\bar{\mu}_\delta$	$\bar{\sigma}_\delta$
最大误差	1.59e-6	5.08e-7	8.14e-5	6.75e-4
平均误差	2.33e-7	1.71e-7	3.53e-5	1.91e-45

从表格 2.7 中可以看出，用压缩感知算法求得的概率潮流的输出状态变量的期望和标准差都具有较高的精度。具体的，以节点 12 为例，图 2.1 中分别给出了由压缩感知算法求得的节点 12 的电压幅值和相角的概率密度函数和累积密度函数，从图中可以看出，该方法求得的分布函数与 MC

方法求解的基本重合，进一步说明了该算法的准确性。




图 2.1 节点 12 的电压和相角的概率分布

说明了算法的准确性之后，图 2.2 给出了由算法 1 求得的 30 个节点的电压幅值和相角的 PCE 展开式系数的稀疏度。本算例中截取基函数最高阶数为 3 阶，随机变量维度为 16 维，因此基函数个数为 $P = \frac{(16+3)!}{16!} = 969$ ，

即展开式系数 c 的维度为 969 维，图中的稀疏比 s 由下式计算得到：

$$s = \frac{\#\{c \geq \tau\}}{969} \quad (2-18)$$

其中 $\#\{c \geq \tau\}$ 表示系数矩阵 c 中元素大于等于阈值 τ 的元素的个数。

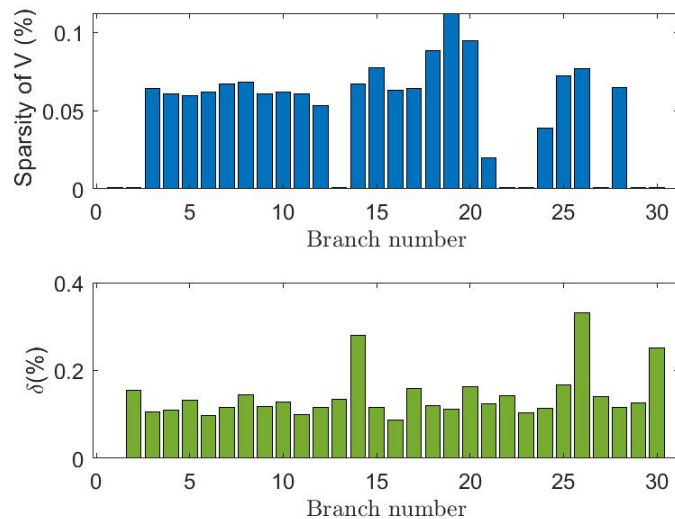


图 2.2 系数矩阵稀疏度

从图 2.2 中可以看出各个节点的电压幅值和相角在 Hermite 正交基的展开下的稀疏性，平均稀疏程度小于 3%，因此说明了压缩感知原理的适用性。

综合上述数据与图表，充分说明了压缩感知算法在求解概率潮流问题上的适用性和准确性。

2) 计算效率

证明了算法的准确性之后，本节继续分析压缩感知算法在效率上的优势。首先图 2.3 展示了算法 1 与 MC 方法的求得的电压幅值期望的误差收敛性对比，从图中可以看出，两种方法的误差都随着样本点数的增多而减少。然后算法 1 的误差随样本个数快速收敛，而且当样本点数达到一定水平时，增加样本个数，误差基本不变，而 MC 方法的误差收敛较慢。在相同样本水平下，压缩感知算法的误差明显强于 MC 方法。关于节点的其他输出状态变量的误差分析结果类似，不再重复给出。




图 2.3 CS 方法和 MC 方法误差对比

表 2.8 给出了相同误差水平下，CS 算法和 MC 算法所需的样本规模和计算耗时数据。从数据中可以直观的看出，要达到相同的运算精度，CS 算法的运算时长大概是 MC 方法的 1/20，这极大的提高了概率潮流的运算效率。而且与 MC 方法一样采用的是样本解进行求解，简化了算法的实现过程。

表 2.8 运算效率对比

	$\bar{\mu}_v$	$\bar{\sigma}_v$	样本点数	耗时 (s)
CS	2.33e-7	5.53e-5	50	12.187
MC	1.02e-7	2.155e-5	10000	1992.643

综上所述，CS 算法求解概率潮流问题时，可以在保障精度的前提下，极大的提高求解效率，因此可以代替 MC 方法广泛的应用于概率潮流的求解。

2.4 基于改进的压缩感知技术的概率潮流求解算法

2.4.1 算法流程

应用压缩感知理论求解概率潮流方程，是将随机状态变量进行 PCE 展开，然后利用展开式系数的稀疏特性进行压缩还原。本节所提的基于主成分分析 (principle component analysis, PCA) 的压缩感知算法是在压缩还原之前，通过对随机变量的协方差进行特征分解，得到一组特征基函数，使得随机变量在这组基函数的表达下更加稀疏，然后在这组基函数下进行压缩还原。由压缩感知的误差理论可知，提高稀疏性可以减少还原所需样本解的数量，进而提高求解效率。

2.4.1.1 PCA 法提取特征基函数

PCA 方法通过提取数据的主要特征，在数据降维领域具有广泛的应用。在本节所提的算法中，利用 PCA 方法将随机变量映射到其特征空间，使得随机变量的展开式在特征空间的表达下更加稀疏。

首先，通过求解下述特征值问题，得到特征基函数 $\{\phi_j\}_{j=1}^m$ (m 为电力系统节点个数)：

$$C(\mathbf{X}, \mathbf{X}')\phi_j = \mu_j\phi_j \quad (2-19)$$

其中：

- $C(\mathbf{X}, \mathbf{X}')$ 表示随机变量 X 的协方差矩阵，定义为：

$$C(\mathbf{X}, \mathbf{X}') = E[(\mathbf{X} - E\mathbf{X})(\mathbf{X}' - E\mathbf{X}')] \quad (2-20)$$

协方差矩阵通过随机选取 H 个样本解进行求解。根据随机变量 X 的概率分布随机选取 H 个样本点，然后分别带入概率潮流方程，得到 H 个样本解 $\hat{\mathbf{u}} = [\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(H)}]$ ，进而有：

$$C(\mathbf{X}, \mathbf{X}') = \hat{\mathbf{u}}\hat{\mathbf{u}}^T \quad (2-21)$$

- $\{\mu_j\}_{j=1}^m$ 表示特征向量 $\{\phi_j\}_{j=1}^m$ 对应的特征值，在计算过程中默认将特征值降序排列。由于协方差矩阵是对称正定的，因此特征值 $\{\mu_j\}_{j=1}^m$ 为非负实数。

得到特征基函数 $\{\phi_j\}_{j=1}^m$ 之后，将随机变量 X 在这组基函数下展开，则有：

$$\mathbf{X} = \sum_{i=1}^p s_i \psi_i = \sum_{i=1}^p \sum_{j=1}^m S_{ij} \psi_i \phi_j \quad (2-22)$$

其中, p 为多重指标集 $\mathbf{i} = (i_1, i_2, \dots, i_d) \in N_0^d$ 的基数, 也即随机多项式基函数 ψ_i 的个数。

得到 X 的展开式之后, 就可以通过压缩感知的稀疏还原算法, 还原得到 X 的展开式系数 S 。

2.4.1.2 改进的压缩感知算法

本节所提算法基于传统的压缩感知算法, 通过主成分分析理论, 对随机变量进行特征变换, 使其表达式系数更加稀疏, 然后再进行压缩还原。根据 X 的表达式 (2-22), 将 N 个样本解 $\mathbf{u} = [\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(N)}]$ 写成如下的矩阵形式:

$$\mathbf{u} = \Psi \mathbf{S} \Phi \quad (2-23)$$

其中, Ψ 为测量矩阵, 形式同 2.2 节中的测量矩阵, Φ 为由特征基函数组成的特征矩阵, S 为待求的展开式系数。进而, 通过求解如下优化问题, 可以还原系数 S :

$$\min \|\mathbf{S}\|_1 \quad s.t. \quad \Psi \mathbf{S} \Phi = \mathbf{u} \quad (2-24)$$

并且 S 的稀疏性由定理 1 给出:

定理 1 X 的展开式系数 S 与特征值 μ 之间满足如下关系式:

$$\sum_{i=2}^p |S_{ij}|^2 = \mu_j, \quad j = 1, \dots, m$$

其中, μ_j 表示特征分解问题的第 j 个特征值。

证明: 由于 Hermite 多项式 H 满足

$$E(\psi_i) = \begin{cases} 1, & i = 1 \\ 0, & i \neq 1 \end{cases}$$

于是有:

$$E\mathbf{X} = E \left[\sum_{i=1}^p \sum_{j=1}^m S_{ij} \psi_i \phi_j \right] = \sum_{j=1}^m S_{1j} \phi_j \quad (2-25)$$

结合式 (2-25) 和 (2-20) 可得:

$$\begin{aligned}
C(X, X') &= E[(X - EX)(X' - EX')] \\
&= \left(\sum_{i=2}^p \sum_{j=1}^m s_{ij} \psi_i \phi_j \right) \left(\sum_{i=2}^p \sum_{j'=1}^m s_{ij'} \psi_i \phi_{j'} \right) \\
&= \sum_{i=2}^p \left(\sum_{j=1}^m s_{ij} \phi_j \right) \left(\sum_{j'=1}^m s_{ij'} \phi_{j'} \right)
\end{aligned} \tag{2-26}$$

将表达式(26)带入特征分解方程(19)中可得：

$$\sum_{i=2}^p \left(\sum_{j=1}^m s_{ij} \phi_j \right) \left(\sum_{j'=1}^m s_{ij'} \phi_{j'} \right) \phi_j = \sum_{i=2}^p |s_{ij}|^2 \phi_j = \mu_j \phi_j$$

定理得证。 □

定理 1 说明了随机变量的展开式系数矩阵的每一列值的大小，都可以被相对应的特征值的大小控制。另外，由于在实际应用中，降序排列的特征值的下降速度非常快，因此当特征值趋于 0 的时候，系数矩阵的对应列的分量元素值就趋于 0。换言之，特征值下降速度越快，在这组特征基函数的表示下，系数矩阵就越稀疏。这一点也会在后面数值算例中得到证明。

综上所述, 基于改进的压缩感知算法 (PCA-CS) 求解概率潮流方程的流程如下：

算法 2 (PCA-CS 算法) :

- 将概率潮流方程进行 PCE 展开；
 - 根据正态分布随机选取 H 个样本点，用 Newton-Raphson 法^[85] 求出样本解；
 - 求解特征分解问题，并求出特征基函数；
 - 在特征基函数表达下，构造压缩还原问题；
 - 采样正交匹配追踪 OMP 算法进行求解，得到系数矩阵 S ；
 - 将系数 S 带回展开式，得到状态变量的统计信息，然后进行分析
-
-

2.4.2 数值算例

本节将上面提出的 PCA-CS 算法在标准 IEEE 118 节点上进行验证, 通

过和 MC 方法以及传统压缩感知算法对比，从算法的准确度和计算效率两个方面对数值结果进行分析。概率潮流计算程序由 Matlab R2020 开发，潮流计算部分由 Matpower 软件包实现，计算平台为 Intel i7-8586U CPU, 2G 内存独立显卡。

2.4.2.1 仿真设置

本算例在 IEEE 118 节点的基础网架上，分别在节点 6、15、42、60、92、115 接入风机，在节点 2、7、27、41、58、98 接入光伏，同时将节点 3、11、23、50、57、75、84、88、93、102 设置为含有随机波动的负荷节点。其它系统线路参数与基准容量与 Matpower 程序包自带的 118 节点算例一致。风机、光伏和随机负载的参数设置分别在表 2.9, 2.10, 2.11 中给出：

表 2.9 风机参数

风机	P_r (MW)	v_{ci} (m/s)	v_r (m/s)	v_{co} (m/s)	c	k
WT 1	13	3	20	10	8	3
WT 2	20	3	16	11	8	3
WT 3	25	2.4	19	12.4	8	3
WT 4	15	3.5	23	13.6	8	3
WT 5	10	2	15	11.9	8	3
WT 6	16	4	22	10.7	8	3

表 2.10 光伏参数

光伏	P_{PV}^{\max} (MW)	α	β
PV 1	50	0.9	0.8
PV 2	60	0.8	0.85
PV 3	55	0.85	0.75
PV 4	70	0.7	0.9
PV 5	45	0.8	0.8
PV 6	80	0.75	0.9

表 2.11 随机负荷参数

负载	μ_{PL} (MW)	μ_{QL} (MW)	σ_{PL} (MW)	σ_{QL} (MW)
Load 1	3.2	2.3	0.16	0.115

Load 2	4.4	4.2	0.22	0.210
Load 3	7.5	6.5	0.375	0.325
Load 4	2.8	1.6	0.140	0.080
Load 5	8.3	4.4	0.415	0.220
Load 6	4.7	1.8	0.235	0.090
Load 7	5.8	2.7	0.290	0.135
Load 8	6.3	5.2	0.315	0.260

2.4.2.2 仿真结果

为了验证 PCA-CS 算法在求解概率潮流方程中的有效性, 本节分别从算法准确度与计算效率两个方面进行数值分析, 并与 MC 方法以及传统 CS 方法对比, 说明所提方法的优势。本算例中, 以采样规模为 100000 次的简单随机采样的 MC 方法的计算结果作为误差参考标准。

1) 算法准确度

为了说明算法的准确度, 首先需要选取衡量准确度的指标。本节采用各个节点输出电压幅值和相角的期望与标准差的相对误差的平均值 $\bar{E}, \bar{\sigma}$ 来刻画算法的准确度:

$$\begin{cases} \bar{E} = \frac{1}{m} \sum_{j=1}^m \left(\frac{E^{(j)} - E_{MC}^{(j)}}{E_{MC}^{(j)}} \right) \\ \bar{\sigma} = \frac{1}{m} \sum_{j=1}^m \left(\frac{\sigma^{(j)} - \sigma_{MC}^{(j)}}{\sigma_{MC}^{(j)}} \right) \end{cases} \quad (2-27)$$

计算所得具体节点和参数数据见附录 1, 具体的, 表 2.12 给出了用 PCA-CS、CS、MC 三种算法在相同样本点个数下分别计算的各电压幅值 V 和相角 δ 的均值和标准差的相对误差值。

表 2.12 三种方法误差对比

方法	$V_{\bar{E}}$	$V_{\bar{\sigma}}$	$\delta_{\bar{E}}$	$\delta_{\bar{\sigma}}$	样本数
PCA-CS	7.23e-8	5.29e-9	2.95e-4	2.61e-3	30
CS	8.45e-7	3.93e-9	1.13e-4	2.08e-3	30
MC	6.42e-3	5.27e-4	1.76e-2	9.34e-2	30

从表 2.12 中的数据可以看出, 在样本个数比较低时, 用 PCA-CS 与传统的 CS 算法求得的概率潮流的输出状态变量的期望和标准差都具有较高的准确度, 而 MC 方法在样本个数比较低时, 结果准确性较差。这

是因为 MC 方法是半阶收敛的，需要大量的样本解才能达到相应精度，这也是 MC 算法的缺陷。

具体地，此处选取节点 58, 60, 50 作为代表，给出点的输出状态变量的概率分布图。图 2.4 给出了由 PCA-CS 算法与 CS 算法求得的节点 58, 60, 50 的电压幅值和相角的概率密度函数，并与 100000 个样本可以看出，PCA-CS 算法与 CS 算法求得的分布函数基本重合并与标准参考解吻合，进一步说明了该算法的准确性。




图 2.4 节点电压幅值和相角的概率密度

从准确度的数值分析中可以看出，虽然 PCA-CS 是在传统 CS 方法基础上，通过主成分提取进行了一次基函数变换，但是并没有影响结果精度。这是因为，PCA-CS 算法只是通过主成分分析的特征分解得到了一组正交的特征基函数，但在随机变量展开时，并没有舍弃小特征值对应的

基函数，因而最大限度地保证了特征变换的精度。相反，在特征变换之后，展开式的稀疏性得到了提高。由压缩感知的误差理论^[86]可知，稀疏性提高，达到相同精度所需样本解的数目减少。因此，相比于传统 CS 方法，PCA-CS 方法可以在相同精度下，进一步提高运算效率。

2) 计算效率

验证了算法的准确度之后，本章节通过实验数据进一步说明 PCA-CS 算法在计算效率方面的优势。首先需要引入稀疏比率 λ 的概念，即系数矩阵中的系数的绝对值的阈值大于等于某个参考值 τ 的元素的个数占矩阵元素总数的比值，计算公式表示如下：

$$\lambda = \frac{\#\{\mathbf{s} \geq \tau\}}{p \times 118}$$

其中 $\#\{\mathbf{s} \geq \tau\}$ 表示系数矩阵 \mathbf{s} 中元素大于等于阈值 τ 的元素的个数， p 表示等于随机基函数的维度。本算例中截取基函数最高阶数为 2 阶，随机变量维度为 40 维，因此基函数个数为 $p = \frac{(40+2)!}{40!2!} = 881$ ，即展开式系数

\mathbf{s} 的维度为 881×118 维。稀疏比率 λ 越小，说明稀疏矩阵越稀疏。

图 2.5 和图 2.6 分别给出了由 PCA-CS 算法和传统 CS 算法求得的 118 个节点的电压幅值和相角 PCE 展开式系数的稀疏度的直观显示以及总的稀疏比率的值。




图 2.5 CS 方法系数矩阵稀疏度

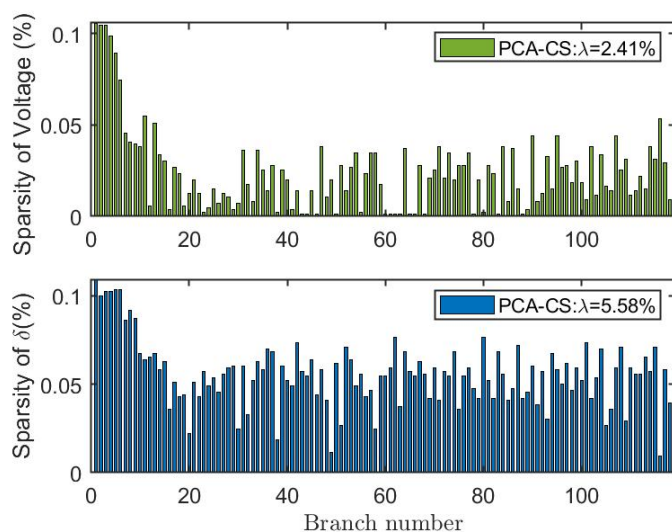


图 2.6 PCA-CS 方法系数矩阵稀疏度

从图 2.5 和图 2.6 中可以看出各个节点的电压幅值和相角在 Hermite 正交基的展开下的稀疏性，两种方法的平均稀疏程度均小于 1%，说明了压缩感知思路的适用性。通过对比可知，引入主成分分析之后，电压幅值 V 的展开式系数的稀疏度从 3.14% 下降到 2.41%，稀疏性提高了 23.2%，相角 δ 的稀疏度从 9.34% 下降到 5.58%，稀疏性提高了 40.3%。由此证明，PCA-CS 算法相比于 CS 算法，结果的稀疏性显著提高，结果符合定理 1 的分析。因此，PCA-CS 算法可以通过更少量的样本解达到和 CS 算法相同的计算精度。两种方法的误差收敛性对比以及计算耗时对比数据分别在图 2.7 和表 2.13 中给出。

表 2.13 PCA-CS、CS 与 MC 方法计算效率对比

方法	V_E	样本数	计算耗时(s)
PCA-CS	7.85e-7	15	10.43
CS	7.93e-7	40	20.69
MC	8.42e-7	10 000	4 328.47

从图 2.7 中可以看出，两种方法的误差都随着样本点数的增多而减少。并且当样本点数达到一定水平时，即使继续增加样本个数，误差也基本不变。但在相同样本的水平下，PCA-CS 算法的误差均低于 CS 算法的误差。由表 2.13 中数据可知，在达到相同的运算精度情况下，PCA-CS 算法的运算时长比 CS 少 10 s，且两种方法的耗时远小于 MC 方法。这极大地提高了概率潮流的运算效率。而且与 MC 方法一样采用的是样本

解进行求解，简化了算法的实现过程。




图 2.7 PCA-CS 与 CS 两种方法的误差估计

综上所述，PCA-CS 算法求解概率潮流问题时，可以在保障精度的前提下，极大地提高求解效率，因此可以代替 MC 方法广泛的应用于概率潮流的求解。

2.5 小结

本节考虑了能源互联网系统的输入不确定性，首先建立了概率潮流模型。考虑到同一个能源互联网之间的节点具有相关性，采用 Nataf 变换对变量相关性进行了去相关处理，然后提出了基于压缩感知原理的概率潮流计算方法，用以求解微网系统的相关输出随机变量。该方法利用概率潮流随机状态变量展开的稀疏性，采用远低于 MC 方法的样本解，就可以精确的还原出微网概率潮流的相关随机状态变量。数值结果表明，基于压缩的概率潮流求解方法可以极大的提高微网潮流计算效率，并且相较于 PCE 等方法，原理更加简单，便于操作实现。更进一步的，在压缩感知解法基础上，我们通过主成分分析对随机状态变量展开进行特征变换，进一步提高随机状态变量展开的稀疏性。数值结果表明，所提的 PCA-CS 方法可以进一步提高 CS 方法的计算效率，并且该方法与传统 CS 方法以及 MC 方法类似，属于样本点法，因此原理简单，便于操作实现，更适合实际应用。基于本节研究，未来的研究方向可以利用优化理论中的加权 l_1 优化等原理继续改进 PAC-CS 算法，进一步提升求解效率。

第三章 压缩感知技术在能源互联网控制问题中的应用

3.1 引言

能源互联网是里夫金^[3]在阐述第三次工业革命时提出的全新理念，主要内容是利用能源网与信息网深度融合技术实现广域范围内分布式可再生能源近乎免费地综合利用，以有效解决因化石能源长期、大量使用而造成的供需失衡、环境污染问题。能源互联网将电能、信息、交通、天然气等网络紧密耦合在一起，形成多能互换、信息管控、高效利用的信息物理网络，是实现分布式可再生能源高效利用和传统能源网络转型升级、更新换代的有效途径。

然而，分布式能源具有多变性、相对不可预测性、多端口性，大规模并网必然对电力系统安全稳定运行造成极大影响。微网作为分布式能源、负荷、储能装置的集成，有利于分布式能源的大规模接入，通过制定控制策略，可实现系统经济、安全的运行目标^{[87][88]}。相较于交流微网，直流微网有功潮流易控制，逆变器利用率高，不存在功角、频率稳定问题，已成为分布式能源并网的新方式、微网研究的新方向^[89-91]。

作为能源互联网最基本的优化单元，微网由众多互联的可调度/非可调度产能、用能、储能单元构成并独立完成网内各可调度资源间的供需平衡优化。在每个微网内，各可调度资源均能够与局域能量控制器实现信息的双向互动、共享，并可以按约或自主决定是否参与某个（些）时段的能量交易。在此期间，能量路由器负责统筹管理，通过预判这些可调度资源的输入/输出关系，在一定的范围内实现用户局部利益与系统全局利益的协调。

微网可在离、并网两种模式下可靠运行。在并网模式下，每个微网参与到其所在输配电网系统的能量调度与优化中，据此实现自下而上的需求传递、自上而下的指令执行及同级各能源局域网间的供需响应和能量交换。其中，独立系统运营商和配电网运营商构成了输配电网系统不同层面的两个主要载体，前者通过批零和辅助市场引入更多的激励机制以促成辖区范围内更加广泛、灵活、多样的交易；后者一方面负责收集其管辖区内各能源局域网的需求信息并将汇集后的总需求信息上传至独立系统运营商，另一方面接收来自于独立系统运营商的调度指令并据此协调不同微网间的能量交互、实现实时供需平衡。

文献[92]针对含蓄电池多能微网，建立储能系统优化配置模型，提出了并网、孤岛两种运行方式下储能装置的配置方法。文献[93]针对含光伏直流微网，设计多种运行模式，研究了该微网的能量管理方式，但其仅考虑单一电池储能，未研究加入超级电容器后混合储能的综合控制策略。文献[94]从经济性出发，针对微网运行特点，提出了以预测模型为基础的微网能量管理策略，通过以改进遗传算法对算例进行求解，说明所提能量管理模型可有效优化微网各部分间的能量流，可为微网分布式能源组合及经济效益评估提供参考。文献[95]综合考虑可再生能源出力波动性、负荷预测误差及储能装置实际运行情况，以微网运行经济性、环保性为目标，研究了含混合储能系统直流微网孤岛模式运行下的能量管理优化方法，通过多组仿真实验对比，验证了所提管理模型的有效性。储能单元的引入，有效地降低了分布式能源间歇性对系统稳定性、电能质量造成的不利影响，在一定程度上将分布式能源转化为可调度电源^[96]。然而，储能装置投资与运行费用较高、运行约束较为复杂，必须对其经济、合理、高效地利用。微网能量优化管理是通过能源出力及负荷信息的预测，选取合理的优化目标，制定科学的控制约束，实现微网潮流的最优控制，进而达到安全、经济、稳定、高效的运行目标。目前微网能量优化管理主要以最小化投资成本、运行费用、环境排放成本为目标，通过模型求解，基本可实现在保证系统安全稳定运行的前提下，为分布式能源、负荷的调度提供可参考依据[97][98]。

微网能量优化管理本质上是高维度、多约束，非线性随机优化问题，传统方法如线性规划、动态规划等受到计算复杂性影响难以求解。得益于压缩感知技术在求解随机微分方程上的高效性^{[51][52]}，本节采用压缩感知技术求解高维度能源互联网随机控制问题，并给出两个具体应用场景。其一为通过调节微网内分布式电源的发电功率和从外电网的取电功率来实现能量路由器储能最小化，此场景考虑的是多个微网并网运行的场景，涉及的随机变量维度高且目标函数是非线性的，因此传统方法无法求解，应用本节所提算法可以有效求解。第二个应用场景为制定能量交易策略，通过调节能量路由器的功率波动，来实现单个微网从外电网取点费用最低。

本节结构安排如下，首先在 3.1 节介绍能源互联网相关控制问题研究背景和研究现状，然后在 3.2 节重点介绍压缩感知技术求解控制问题算法流程，并且分别在 3.3 节和 3.4 节对两个具体应用场景进行问题建模，并用仿真结果验证压缩感知算法的有效性，最后在 3.5 节中进行总结。

3.2 压缩感知求解控制问题算法

3.2.1 随机控制问题简介

随机控制理论是控制理论的一个分支。随机控制理论通过控制器的最优设计来预测被控系统的随机偏差量值的大小和极限，并使这种随机偏差的量值达到最小。当随机信号进入系统时，使系统不能准确地跟踪规定的路线，而偏离一个随机变化的数量。对于这种动态系统的分析和控制，要依靠随机控制理论。随机控制理论通过对随机过程的数学描述，对系统传输特性的分析、测量和模拟，对系统输出效应的调节和控制等，在总体平均的意义上考虑系统的随机干扰、随机初始条件和随机测量误差，寻求使系统的性能指标在总体平均的意义上达到极值。

使随机控制系统的某个性能指标泛函取极小值的控制称为随机最优控制。由于存在随机因素，这种性能指标泛函需要表示为数学期望的形式。一般的，连续型随机最优控制可以表述为：

$$\begin{aligned} \min \quad & J = E\left\{\int_{t_0}^T L[x(t), u(t), t] dt\right\} \\ \text{s.t.} \quad & dx(t) = f[x(t), u(t), \xi, t] dt + g[x(t), \omega, t] d\omega(t) \\ & h[x(t), u(t), \xi, t] \leq 0 \end{aligned} \quad (3-1)$$

式中 J 表示性能指标，即控制目标， $E\{\}$ 表示数学期望， $x(t)$ 为状态向量， $u(t)$ 为控制变量， ξ 为随机输入参数， t 表示时间， $\omega(t)$ 通常为布朗运动， $d\omega(t)$ 表示白噪声。 $L[\cdot], f[\cdot], g[\cdot], h[\cdot]$ 表示的是 $x(t)$ 和 $u(t)$ 满足的函数关系。因此随机最优控制问题可以简述为，通过调节控制变量 $u(t)$ ，使得状态变量 $x(t)$ 满足的性能指标 J 最小。

随机最优控制有两个重要的性质。由于存在不确定性，控制作用常宁可取得弱一些，保守一些。这称为谨慎控制。另一方面为更好和更快地进行估计，必须不断激发系统中各种运动模式，为此需要加入一些试探作用。试探作用的大小，则根据增加的误差、直接费用和所带来的好处等因素加以折衷权衡进行选择。谨慎和试探已成为设计随机控制策略的两个重要原则。

对于线性、二次型、高斯等随机控制问题，目前已经有比较成熟的理论研究和数值解法，但是对于高维非线性随机控制问题，理论求解几

乎不可能，数值求解也面临巨大的挑战，本章以能源互联网中的相关应用场景为背景，提出应用压缩感知技术求解随机控制问题的新方法。

3.2.2 布朗运动和白噪声

数值求解随机问题，要首先将随机空间离散化，因此需要对白噪声进行展开。

Brownian 运动^[99] $\omega(\cdot)$ 是刻画粒子在分子撞击下的无规则运动的，又叫 Wiener 过程，是满足下面几条性质的随机过程：

1. $\omega(0) = 0$ a.s.;
2. 任取 $t \geq s \geq 0$, $\omega(t) - \omega(s)$ 满足均值为 0，方差为 $t - s$ 的正态分布，即 $\omega(t) - \omega(s) \sim N(0, t - s)$;
3. 独立增量过程，即满足对所有的时间 $0 < t_1 < t_2 < \dots < t_n$ ，随机变量 $\omega(t_1), \omega(t_2) - \omega(t_1), \dots, \omega(t_n) - \omega(t_{n-1})$ 是独立的。

并且注意到，对任意的 $t \geq 0$ ，有 $E(\omega(t)) = 0, E(\omega^2(t)) = t$ 。已知 Brownian 运动 $\omega(s)$ 可以由傅里叶展开逼近，令 $\{\varphi_i\}_{i=1}^{\infty}$ 表示 $L^2([0, t])$ 上的一组正交基，那么有：

$$\omega(s) = \sum_{i=1}^{\infty} \xi_i \int_0^s \varphi_i(\tau) d\tau \quad (3-2)$$

其中 $\xi_i \sim N(0, 1)$ 是独立同分布的随机变量，而且 Itô 积分满足 $\int_0^t \varphi_i d\omega(s) \sim N(0, 1), i.i.d.$ ，因此如果令

$$\xi_i = \int_0^t \varphi_i d\omega(s) \quad (3-3)$$

那么有：

$$\omega(s) = \int_0^s \chi_{[0, s]}(\tau) d\omega(\tau) = \sum_{i=1}^{\infty} \int_0^s (\chi_{[0, s]}, \varphi_i) \varphi_i(\tau) d\omega(\tau) = \sum_{i=1}^{\infty} \xi_i \int_0^s \varphi_i(\tau) d\tau \quad (3-4)$$

其中， $\chi_{[0, s]}(\tau)$ 是 $[0, s]$ 上的特征函数，展开式 (3-4) 均方收敛到 $\omega(s)$ ，即任取 $s \leq t$ 满足：

$$\lim_{N \rightarrow \infty} E[\omega(s) - \sum_{i=1}^N \xi_i \int_0^s \varphi_i(\tau) d\tau]^2 = 0$$

Brownian 运动在不同的基函数 $\{\varphi_i\}_{i=1}^{\infty}$ 下展开的对比在文献 [100] 中有详细的讨论。

白噪声则定义为 Brownian 运动关于时间的微分，记为 $\dot{\omega}(t)$ ，即：

$$\dot{\omega}(t) = \frac{d\omega(t)}{dt} \quad (3-5)$$

然而实际上 Brownian 运动关于时间是不可微的，但是可以证明下面的公式成立：

$$E(\dot{\omega}(t)\dot{\omega}(s)) = \delta_0(s-t) \quad (3-6)$$

其中 $\delta_0(s-t)$ 是 0 点处的单位质量函数，即在 0 点取值无穷大，在其它点取值为 0。

注释 3.1: 如果一个实值随机变量 $X(\cdot)$ 满足任取 $t \geq 0, E(X^2(t)) < \infty$ ，那么它的自相关函数可以定义为：

$$r(t, s) = E(\dot{\omega}(t)\dot{\omega}(s))$$

如果自相关函数 $r(t, s) = g(t-s)$ ，且有 $E(X(t)) = E(X(s))$ ，那就说 $X(\cdot)$ 是一个宽平稳过程，其中 $g: R \rightarrow R$ 是一个函数。

所以白噪声 $\dot{\omega}(t)$ 就是一个满足 $g(\cdot) = \delta_0$ 的宽平稳随机过程，又因为随机过程 $X(\cdot)$ 的功率谱密度定义为：

$$f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} e^{-i\lambda t} g(t) dt, \quad \lambda \in R$$

那么对于白噪声就有：

$$f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} e^{-i\lambda t} \delta_0 dt = \frac{1}{2\pi}$$

可以看出，白噪声的功率谱密度是一个常数，也就是说所有的频率对这个随机过程的贡献是一样的，联想到白色光是由所有其它颜色的光均匀合成的，所以将这样的随机过程取名为白噪声。

有了白噪声的定义以后，可以给出 Hermite 多项式展开的收敛性定理：

定理 3.1: [Cameron-Martin 定理]^[101] 对所有的 $(x, s) \in D \times [0, t)$ ，如果 $u(x, s)$ 是一个包含布朗运动 ω 的随机函数且 $E[u(x, s)^2] < \infty$ ，那么 $u(x, s)$ 可以展开为：

$$u(x, s) = \sum_{\alpha \in I} u_{\alpha}(x, s) H_{\alpha}(\xi) \quad (3-7)$$

其中， $\{H_{\alpha}\}_{\alpha \in I}$ 是多重随机 Heimite 多项式， I 是多重指标集， $\xi = (\xi_1, \xi_2, \dots)$ 中的分量满足 $\xi_i \sim N(0,1)$ 且是独立同分布的， u_{α} 表示展开式系数。不难看出， $u(x, s)$ 的一阶和二阶统计矩为：

$$\begin{aligned} E(u(x, s)) &= u_0(x, s) \\ E[u(x, s)]^2 &= \sum_{\alpha \in I} |u_{\alpha}(x, s)|^2. \end{aligned}$$

注释 3.2: 从 Brownian 运动的展开式可以推出：

$$\omega(s) = \sum_{\substack{\alpha \in I \\ |\alpha|=1}} \int_0^s \varphi_j(\tau) H_{\alpha}(\xi).$$

3.2.3 压缩感知算法

压缩感知 (Compressive Sensing, CS) 一词最早是由 E. J. Candes、J. Romberg、T. Tao 和 D. L. Donoho 等科学家于 2004 年提出的^[48-50]，是一种新兴的有效处理稀疏信号还原的方法。压缩感知方法是将原有的 L1 范数最小化问题与随机矩阵相结合所产生的新的方法，经过近几年的快速发展，已经有了比较完善的理论基础，在图像处理^[102]，医学成像^[103]、计算机科学^[104]等领域具有广泛的应用。在应用数学领域，近年来也已经有很多应用压缩感知方法解随机微分方程的相关工作^{[51][52]}。在本节中就以压缩感知在解随机微分方程中的应用为例来简要介绍一下该方法解决问题的具体步骤。

已知，定义在概率测度空间上的一个平方可积的随机函数 $u(x, \xi)$ 可以用随机空间上的一组随机多项式基函数展开，而且这种展开是均方收敛的，在误差允许的范围内取截断之后即得到展开式 (3-8)：

$$u(x, \xi) = \sum_{i=1}^p c_i(x) \psi_i(\xi) \quad (3-8)$$

那么要求得随机微分方程的解 $u(x, \xi)$ ，等价于确定展开式系数 $c_i\{x\}$ 。

传统的确定系数 $c_i\{x\}$ 的方法有很多，比如多项式展开法 (PCE)、随机 Galerkin 方法、随机 Collocation 方法等^{[105][106]}，但随着随机空间维数的上升，这些方法就会出现所谓的维数灾难问题，因此需要寻求更有效的处理高维问题的方法。

因为大部分随机微分方程的解在某种随机多项式基的展开下具有稀疏性，所以想到应用压缩感知方法来解随机偏微分方程，用以减少实际计算所需的样本点个数，从而大大的降低运算代价。

首先给出压缩感知中强调的稀疏性的概念^[48]：

稀疏性：如果在展开式(3-8)中，对任意固定的空间点 x ，只有一小部分非零系数 $c_i\{x\}$ 占主要地位，其它系数皆为零，那么说随机函数 $u(x,\xi)$ 在点 x 处的展开具有稀疏性，且若非零元素个数为 k ，则说 $\bar{c}=(c_1,c_2,\dots,c_p)$ 是 k 稀疏的。

另一个相关的定义是可压缩性：

可压缩性：如果在展开式(3-8)中，对任意固定的空间点 x ，只有一小部分非零系数 $c_i\{x\}$ 占主要地位，其它系数皆趋于零，那么说随机函数 $u(x,\xi)$ 在点 x 处具有可压缩性。

因为对任意的空间点 x ， $u(x,\xi)$ 在某组基的展开下通常都具有可压缩性，具有可压缩性的随机函数又都可以被一个具有稀疏性的函数很好的逼近[86]，因此可以用压缩感知方法精确地还原随机微分方程的解。具体的做法是，从样本空间 Ω 中按照随机变量的概率分布随机选取 M 个样本点 $\bar{\xi}=(\xi_1,\xi_2,\dots,\xi_M)$ ，对于任意固定的空间点 x ，有：

$$u(\xi_i) = \sum_{i=1}^p c_i \psi_i(\xi_i), \quad i=1,\dots,M \quad (3-9)$$

对于固定一个随机样本点的取值，随机偏微分方程就变成一个确定性的方程，就可以用确定性偏微分方程的数值解法来求解样本解，比如常用的有限元方法、有限差分法等，在本节中，选择用有限元方法来求解确定性空间的问题。循环确定性的算法程序，可以得到样本解向量 $\bar{u}=(u(\xi_1),u(\xi_2),\dots,u(\xi_M))$ ，然后可以把(3-9)式重新写成矩阵的形式：

$$\Psi \bar{c} = \bar{u} \quad (3-10)$$

其中 $\bar{c}=(c_1,c_2,\dots,c_p)$ 是 R^p 空间中的一个向量，也是所要求的系数， $\Psi \in R^{M \times p}$ 叫做信息矩阵，它的每一列元素值是由随机多项式基函数 ψ_j 在样本点 ξ_i 处的取值得到的，即：

$$\Psi(i, j) = \psi_j(\xi_i), \quad i = 1, \dots, M, \quad j = 1, \dots, p. \quad (3-11)$$

因为用压缩感知方法求解随机问题的突出优势是求解所需样本点数很少，通常样本点个数 M 满足 $M \ll p$ ，所以方程组 (3-10) 是欠定的，原则上有无穷多个解。但是当 \bar{c} 具有稀疏性时，可以加上一些约束使得此方程组是适定的，比如说寻找一个解 \bar{c} ，使得它中的元素尽可能多的为零，也即寻找一个最稀疏的解，就是通常所说的 l_0 最优化问题：

$$\min \|\bar{c}\|_0 \quad \text{s.t.} \quad \Psi\bar{c} = \bar{u} \quad (3-12)$$

其中 l_0 范数 $\|\bar{c}\|_0$ 表示向量中非零元素的个数，但是数值求解上述 l_0 最优化问题是困难的，因为 (3-12) 是一个完全 NP 问题。所以又提出用 l_1 范数代替 l_0 范数，其中 l_1 范数定义为向量中各个元素绝对值之和，也叫做稀疏规则算子。它是 l_0 范数的最优凸近似，而且 l_1 -最优化问题是一个凸优化问题，比 l_0 -最优化问题具有更好的求解特性。所以在压缩感知求解过程中，通常用 l_1 -最优化代替 l_0 -最优化问题来求解^[107]。 l_1 -最优化问题也叫做 BP 问题，形式如下：

$$(BP): \quad \min \|\bar{c}\|_1 \quad \text{s.t.} \quad \Psi\bar{c} = \bar{u} \quad (3-13)$$

注意到在展开式 (3-9) 中随机方程的解 $u(\xi)$ 是取 p 个随机基函数的截断得到的，所以存在截断误差 δ ，考虑截断误差以后，BP 问题可以改进为 BPDN 问题：

$$(BPDN): \quad \min \|\bar{c}\|_1 \quad \text{s.t.} \quad \|\Psi\bar{c} - \bar{u}\|_2 \leq \delta \quad (3-14)$$

所以最后可以通过解上述 BPDN 问题 (3-14) 得到原随机微分方程的解的系数，进而求得方程的解。

压缩感知中另外两个重要的概念就是信息矩阵的 RIC 常数和相互一致性常数，只有当信息矩阵的这两个常数足够小的时候，压缩感知才满足稳定性条件^{[86][108]}，才能进行精确的还原。这两个常数分别定义如下：

RIC 常数： 信息矩阵 $\Psi \in R^{M \times p}$ 的 RIC 常数 $\varepsilon(\Psi)$ 定义为使得下述不等式对所有的 k -稀疏向量 $x \in R^p$ 都成立的最小的常数，

$$1 - \varepsilon(\Psi) \leq \frac{\|\Psi x\|_2}{\|x\|_2} \leq 1 + \varepsilon(\Psi), \quad 0 \leq \varepsilon(\Psi) \leq 1. \quad (3-15)$$

相互一致性常数：信息矩阵 $\Psi \in R^{M \times p}$ 的相互一致性常数 $\mu(\Psi)$ 是指矩阵中任意两列的内积规范化后的最大值，如果用 Ψ_j 和 Ψ_k 分别表示矩阵 Ψ 中的不同两列，则一致性常数可以表示为：

$$\mu(\Psi) = \max_{1 \leq j, k \leq p} \frac{|\Psi_j^T \Psi_k|}{\|\Psi_j\|_2 \|\Psi_k\|_2}, \quad 0 \leq \mu(\Psi) \leq 1. \quad (3-16)$$

一致性常数是度量一个矩阵与正交矩阵的相似程度的，一致性常数越小，矩阵越接近正交阵，压缩感知的还原效果越好。

从定义可知 RIC 常数和一致性常数都是度量信息矩阵的正交程度的，它们的值越小，越有利于压缩还原，更多关于这两个条件的理论分析可以参考文献[109]。然而要计算一个矩阵的这两个系数是非常复杂的，需要很大的工作量，幸运的是，已经证明一个 $M \times p$ 维的随机矩阵，当 $M \geq c_1 k \log(p/k)$ 时的 RIC 常数和相互一致性常数是满足精确还原的条件的^[110]，其中 $M \times p$ 维随机矩阵是指矩阵中的元素是将 M 个满足一定概率分布的随机样本点分别带入 p 个随机基函数中得到的值。这里介绍的信息矩阵 Ψ 就是一个随机矩阵。在条件 $M \geq c_1 k \log(p/k)$ 中， M 是样本点的个数， p 是随机空间基函数的个数， k 是稀疏的系数向量中的非零元素个数， c_1 表示一个常数。

最后介绍一下压缩感知还原的收敛性定理，现有工作中关于压缩感知的收敛定理有很多种形式，参照[107]中的定理 2.1，介绍其中一种形式：

定理 3.2: [收敛性分析] 假设信息矩阵 Ψ 的 RIC 常数或相互一致性常数满足稳定性条件，那么 BPDN 问题(3-14)的解 \bar{c}^* 满足：

$$\|\bar{c} - \bar{c}^*\|_2 \leq c_2 \delta + c_3 \frac{\|\bar{c} - \bar{c}_s\|_1}{\sqrt{k}} \quad (3-17)$$

其中 \bar{c}_s 是选取 \bar{c} 中最大的 k 个元素组成的 \bar{c} 的最优 k -稀疏逼近， c_2, c_3 为常数。

从定理中可以看出，压缩感知还原的误差主要来自于两部分。其中第一部分为随机函数展开的截断误差，当随机多项式基函数的个数固定

时，截断误差 δ 是固定的。从第二部分可以看出，系数向量 \bar{c} 越稀疏，这部分误差越小。所以当随机函数的展开具有稀疏性且信息矩阵 Ψ 满足稳定性条件时，可以通过解 BPDN 问题 (3-14) 精确地还原原问题的解。关于还原所需具体算法已经有大量的工作^{[107][111]}，本文中主要用 SPGL1 算法^[112] 求解 l_1 -最优化问题，该算法可以有效解决 BPDN, BP 以及 Lasso 问题。

注释 3.3: 压缩感知的优势是可以很少的样本点进行精确地还原，从而降低运算代价，那么到底样本点可以减少多少呢，在参考文献^{[110][113]}中给出了压缩感知还原所需要的样本点个数的估计，即需要 $M \approx k \log^4(p)$ 个样本点进行精确还原，可以看到 M 是远小于 p 的，而且在实际计算中，所需要的样本点数更少。

压缩感知方法在解随机微分方程中得到了广泛的应用，现在已经有改进的压缩感知算法。比如利用多项式系数的先验信息进行加权的压缩感知算法^[114]，或者是动态的选取随机基函数的自适应的压缩感知算法^[115]。还有一些改进样本点选取的压缩感知的方法，比如样本点的选取遵循切比雪夫概率分布等^[112]。

3.2.4 控制问题求解流程

有了压缩感知算法求解随机状态方程的基础之后，就可以结合梯度下降法、牛顿法、共轭梯度法等迭代算法来求解最优控制问题，由于原理类似，本章以梯度下降法为例来说明算法流程。

为了用梯度法求解控制问题 (3-1)，首先，需要对控制目标 J 求梯度，因此引进 Hamilton 函数^[116]：

$$H = J + \lambda'(t)(f[x(t), u(t), \omega, t]) + g[x(t), \omega, t]dW) \quad (3-18)$$

其中 $\lambda'(t)$ 是共轭状态变量，对 Hamilton 函数求偏导，得到 Hamilton 等价系统：

$$\begin{cases} dx = \frac{\partial H}{\partial \lambda} \\ d\lambda = -\frac{\partial H}{\partial x} \\ 0 = \frac{\partial H}{\partial u} \end{cases} \quad (3-19)$$

有了上述 Hamilton 等价系统之后，就可以应用梯度法求解控制问题 (3-1)，具体算法流程如下。

算法 3 (CS-GDM 算法)

1. 初始化:

1a) 根据 PCE 展开式的精度以及稀疏性需要，选取合适的随机空间维数 d 和随机多项式的阶数 q ，确定多重指标集 $I_{d,q}$ ；

1b) 选取下降步长 α 和误差控制参数 ε ；

1c) 确定时间步长 Δt ；

1d) 选择控制变量初始值 u^0 ；

1e) 用于压缩感知算法求解状态方程，得到初始状态 x^0 ；

1f) 带入目标方程，求出初始性能指标 J^0 ；

2. 优化过程循环:

对任意 $l=1,2,\dots$

2a) 利用压缩感知算法求解 Hamilton 系统，由 x^{l-1} 和 u^{l-1} 求出共轭状态变量 λ^{l-1} ；

2b) 由 x^{l-1} ， u^{l-1} 和 λ^{l-1} 确定下降方向 $\frac{\partial H}{\partial u^{l-1}}$ ；

2c) 由 $\frac{\partial H}{\partial u^{l-1}}$ 和 u^{l-1} 确定新的控制变量 u^l ：

$$u^l = u^{l-1} - \alpha \frac{\partial H}{\partial u^{l-1}},$$

2d) 将 u^l 带回状态方程，求解出新的状态变量 x^l ；

2e) 由 u^l 和 x^l 计算新的性能指标 J^l ；

2f) 如果 $J^l \leq J^{l-1}$ ，并且 $(J^l - J^{l-1})/J^{l-1} \leq \varepsilon$ ，那么循环结束，输出结果；

如果 $J^l \leq J^{l-1}$ ，并且 $(J^l \geq -J^{l-1})/J^{l-1} \varepsilon$ ，那么跳到步骤 2a)，继续循环；

如果 $J^l \geq J^{l-1}$ ，令 $\alpha = \alpha/2$ 并且跳转到步骤 2b)，继续循环，直至输出结果。

3.3 基于压缩感知的能量路由器最优储能管理策略研究

3.3.1 背景介绍

能源互联网改变了能量的模式和结构，能量供需从集中式自上而下的管理模式向集中式自上而下和分布式自下而上相结合的交互式模式转变，满足用户对电力服务的需求，有效解决电力峰谷矛盾，满足能源安全性和可靠性要求^[117]，冷、热、电、气等多种能源形式在发电、输电、消费侧充分融合，充分利用多种能源的互补性，通过能源梯级利用，提高终端能源利用效率。受到互联网的影响，通过能源的自由选择和互动管理，相关产业兴起，经济结构甚至社会习惯都正在变革。

在未来的能源互联网场景中，基于数据和广域信息平台的需求侧响应将改善能源生产和传输效率^[118]。能量路由器 (Energy Router, ER) 作为能源的连通枢纽，是实现信息传输和能量开放对等传输路由的关键设备^[119]。能量路由器是一种基于先进电力电子技术的新兴设备，能够在能源互联网中实现灵活和动态的功率分配，类似于互联网中信息路由器^[120]。

近年来，关于能量路由器的研究不断深入。文献[121]介绍了能量路由器的架构、功能和实现原理。文献[122]研究了一种基于固态变压器的能量路由器并给出了基于经济调度的能量路由策略。文献[123]指出路由算法的目标是改进路由协议的功能，降低路由代价。文献[124]中的作者强调能量路由算法必须是鲁棒的，在发生异常或不可预见的事件时，它必须仍能正常工作。在能源互联网场景中考虑电动汽车时，如何正确部署能量路由器在文献[125]中有所讨论。为了验证能量路由器的实际功能，在文献[126]中研究了能源互联网场景中能量路由器的概率模型的检

查和调度实现。在考虑广域最优能量管理问题时，文献[127]提出了基于深度强化的能量路由策略。

类似于互联网中路由器的数据缓存功能，能量路由器需要快速可靠的储能能力，以便在未来能源互联网场景中实现灵活的能量共享。在这个意义上，文献[128]中提出了一个新的术语，称为能量缓存，它指的是附在能源互联网中的能量存储系统。文献[129]从微观角度出发，提出能源缓存由 H_{∞} 方法调节，即不考虑 MG 组件（包括光伏发电机、风力发电机、分布式发电设备等）的功率动态。本节我们从宏观的角度考虑了储能系统的储能管理问题，从这个意义上说，应该是在考虑了发电功率和负荷功率的随机性的前提下，为所有的互联微网设计控制策略，而不是为单个的微网设计控制策略。值得注意的是，这种针对能量路由器的宏观的能量管理策略在之前的文献中都没有被研究过。我们假设控制器设置在 DGs 和 ERs 中。采用常微分方程和随机微分方程来描述系统的功率动态特性。然后，将 ER 储能管理问题描述为一个非线性随机优化问题。

我们分析了用解析方法来解决这个问题几乎是不可能的，因此需要考虑数值方法。近年来，动态规划方法在工程控制问题中得到了广泛的应用；例如，见[130]，但它往往受到问题维数的限制，在处理高维随机控制问题时，这可能导致维数灾难。另一种方法是蒙特卡罗方法及其几种改进形式^[131]。通常，蒙特卡罗方法的收敛速度相对较低。因此，为了获得期望的计算精度，它常常导致令人望而却步的高计算复杂度。因此，为了克服由于计算量大而导致的效率低下的问题，我们考虑采用压缩感知技术解决非线性的 ER 能量管理问题，而不是使用蒙特卡罗等方法。仿真结果表明了该方法的有效性。

综上所述，本节研究内容主要有以下几个方面的创新：

1. 虽然关于能量路由器的研究在过去几年发展迅速，但是目前大部分工作仅考虑了如何开发 ER 原型，并没有从宏观层面对 ER 的储能进行能量优化管理，因此，本节的研究内容填补了这方面的空缺。

2. 在系统建模方面，本文将复杂的 ER 储能管理问题转化为一类随机非线性系统的优化问题，提出了一种有效的能量管理方案。此外，本文所采用的数学方法可以有效地应用于 EI 领域的各种实际应用，特别是对于那些可以转化为类似形式的优化问题。

3. 本节用压缩感知算法求解这样的随机非线性优化问题。仿真结果表明，在计算量相同的情况下，该方法的精度远高于蒙特卡罗方法，从技术上讲，这也意味着为了达到相同的计算精度，该方法可以明显降低计算量。

3.3.2 系统建模

在本节中，我们考虑一个特殊的 EI 场景，其中各种微网 (Microgrid, MG) 相互连接而不接入公用电网，从某种意义上说，此类 EI 在离网模式下运行。图 3.1 给出了简化的配置图。这种主要依靠可再生能源发电的 EI 情景适合于一些农村或偏远地区。对于图 3.1 中的 EI 场景，我们的建模重点放在互联的单个 MG 上，其中每个 MG 包含多种类型的可再生能源 (Renewable Energy Sources, RESs)、分布式发电机 (Distributed Generators, DGs) 和负载，这些设备分别与 ER 相连，且该 ER 与另一个 MG 中的 ER 从外部相连，如图 3.2。

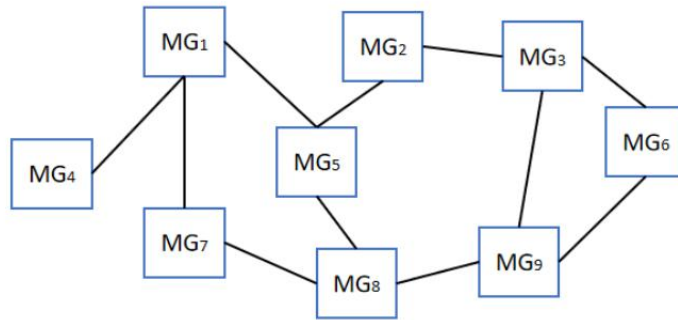


图 3.1 典型离网运行 EI 网络




图 3.2 单个微网

这里采用线性化建模方法来描述 MG 中各个设备的功率波动，用含有布朗运动的随机微分方程来刻画 RES 和负荷功率波动的随机性：

$$\begin{aligned} d\Delta P_{Load} &= -\theta_l(\Delta P_{Load} - \mu_l) + \sigma_l dW_l \\ d\Delta P_{RES} &= -\theta_r(\Delta P_{RES} - \mu_r) + \sigma_r dW_r \end{aligned} \quad (3-20)$$

其中， w_l 和 w_r 表示布朗运动，标量 $\theta_l, \theta_r, \mu_l, \mu_r, \sigma_l$ 和 σ_r 是系统参数。为了简化方程，这里省略了时间变量 t 。

本节所考虑的 MG 中的 DGs，可以是涡轮发电机、柴油发电机、燃料电池等，下面的常微分方程刻画了一般 GDs 的功率波动情况：

$$d\Delta P_{DG} = -\frac{1}{T_{DG}}(\Delta P_{DG} - u_G)dt \quad (3-21)$$

其中 T_{DG} 是 DGs 的时间常量， u_G 是对 DGs 的功率波动的调节，也是本节控制问题的控制变量。

由图 3.2 可知，各个设备与 ER 相连，因此 ER 中需要存储的功率波动应该满足：

$$\Delta P = \Delta P_{RES} + \Delta P_G - \Delta P_{Load} + \Delta P_{out}(1 - u_{ER}) \quad (3-22)$$

其中， u_{ER} 表示连接到该 ER 的其它 ER 的功率的平均传输抑制率，是系统的另外一个控制输入。与负荷和 RES 的功率波动类似，从外部获取的功率波动 ΔP_{out} 同样具有随机性，因此 ΔP_{out} 满足如下方程：

$$d\Delta P_{out} = -\theta_p(\Delta P_{out} - \mu_p)dt + \sigma_p dW_p \quad (3-23)$$

类似的， w_p 表示布朗运动， $\theta_p, \mu_p, \sigma_p$ 是系统常数。

所考虑的 ER 的荷电状态 s_{ER} 满足：

$$ds_{ER} = \eta \Delta P dt \quad (3-24)$$

其中， η 表示 ER 中储能装置额能量转换效率，并且 s_{ER} 的取值区间为 $[0, 1]$ 。

综上，线性模型(3-20)-(3-24)完全描述了一个典型的 MG 内的各个组成模块的功率波动。类似的建模方法，读者可以参考文献[132]。

令 $x = [\Delta P_{Load}, \Delta P_{RES}, \Delta P_G, \Delta P_{out}, s_{ER}]'$, $u = [u_G, u_{ER}]'$, $W = [W_l, W_r, W_p]'$ ，则系统(3-20)-(3-24)可以写成：

$$dx = [A(u)x + Bu + C]dt + DdW \quad (3-25)$$

其中：

$$A(u) = \begin{pmatrix} -\theta_l & 0 & 0 & 0 & 0 \\ 0 & -\theta_r & 0 & 0 & 0 \\ 0 & 0 & -\frac{1}{T_g} & 0 & 0 \\ 0 & 0 & 0 & -\theta_p & 0 \\ -\eta & \eta & \eta & \eta(1-u_{ER}) & 0 \end{pmatrix} \quad (3-26)$$

$$B = \begin{pmatrix} 0 & 0 \\ 0 & 0 \\ \frac{1}{T_g} & 0 \\ 0 & 0 \\ 0 & 0 \end{pmatrix}, \quad C = \begin{pmatrix} \theta_l \mu_l \\ \theta_r \mu_r \\ 0 \\ \theta_p \mu_p \\ 0 \end{pmatrix}, \quad D = \begin{pmatrix} \sigma_l & 0 & 0 \\ 0 & \sigma_r & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \sigma_p \\ 0 & 0 & 0 \end{pmatrix} \quad (3-27)$$

因此，一个微网系统 MG 的功率波动可以用随机状态方程 (3-25) 表示，其中 $x(t)$ 表示随机状态变量， $u(t)$ 为系统控制变量。值得注意的是，系数矩阵 $A(u)$ 实际上不是时间独立的，因此系统 (3-25) 实际上是关于时间的非线性系统。

有了系统的状态方程以后，接下来就要构造系统的性能指标。由 EI 的能量管理原则，电力系统的自主运行最好在 MG 级别实现。作为 MGs 之间提供能量共享功能的关键设备，ERs 有望实现高稳定性的长期运行。为此，一个重要的方面是随着时间的推移将所考虑的 ER 的能量储存状态保持在一个稳定的水平。这一目标可以通过限制所考虑的 ER 中的能量存储的功率吞吐量来实现。然而，过限的功率吞吐可能会损害 ER 的能量存储能力并降低能量利用率。因此从这个角度出发，本节利用 (3-28) 中的成本函数代替二次正则成本函数来刻画系统性能。

$$J_0 = E \int_0^T \{ \varepsilon_1 \log(1 + e^{\Delta P^2}) + \varepsilon_2 u_G^2 \} dt \quad (3-28)$$

E 是数学期望的表示符号， ε_1 和 ε_2 是权重参数。(3-28) 式中的第一项是对 ER 中储能的功率波动的控制，由于当 ΔP 很小时有 $\log(1 + e^{\Delta P^2}) \geq \Delta P^2$ ，而当 ΔP 很大时，有 $\log(1 + e^{\Delta P^2}) \leq \Delta P^2$ ，这意味着应用 (3-28) 式中的性能指标能得到更小的 ΔP ，因此应用 $\log(1 + e^{\Delta P^2})$ 比直接应用 ΔP^2 具有更好的调节作用。(3-28) 式中的第二项是为了避免过度控制而引入的对控制变量的

约束项，并且通过调节参数 ε_1 和 ε_2 他来调整这两项所占比重。

用 C_{\max} 和 C_{\min} 表示 S_{ER} 取值的上下限度，则整个系统的控制问题可以描述为：

$$\begin{aligned}
 & \min J_0 \\
 & \text{s.t. } (3-20)-(3-24) \\
 & \quad C_{\min} \leq S_{ER} \leq C_{\max} \\
 & \quad 0 \leq u_{ER} \leq 1.
 \end{aligned}
 \tag{3-29}$$

引入惩罚项 P 处理问题 (3-29) 中的不等式约束：

$$P = \left(\frac{S_{ER} - \frac{1}{2}(C_{\max} + C_{\min})}{C_{\max} - C_{\min}} \right)^2 + \left(u_{ER} - \frac{1}{2} \right)^2 \tag{3-30}$$

通过增大惩罚项前面的权重系数 ε_3 ，可以控制 S_{ER} 和 u_{ER} 在中间值附近波动。由此，不等式约束控制问题 (3-29) 可以改写成如下不包含不等式约束的形式：

$$\begin{aligned}
 & \min J = E \int_0^T \{ \varepsilon_1 \log(1 + e^{x'Qx}) + \varepsilon_2 u'Ru + \varepsilon_3 P \} dt. \\
 & \text{s.t. } (3-20)-(3-24)
 \end{aligned}
 \tag{3-31}$$

其中：

$$Q = \begin{pmatrix} 1 & -1 & -1 & u_{ER} - 1 & 0 \\ -1 & 1 & 1 & 1 - u_{ER} & 0 \\ -1 & 1 & 1 & 1 - u_{ER} & 0 \\ 1 - u_{ER} & 1 - u_{ER} & 1 - u_{ER} & (1 - u_{ER})^2 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}, \quad R = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}.$$

因此通过求解随机非线性最优控制问题 (3-31) 可以得到 ER 的最优储能管理策略。如 3.2 节所述，传统的方法，如动态规划或蒙特卡罗方法，在计算效率上是有限的，不适用于高维问题。因此本文用 3.2 节介绍的压缩感知算法对此类问题进行数值求解，具体数值结果在下节给出。

3.3.3 仿真结果

在仿真结果这节，我们分成三个部分来说明所提 CS-GDM 算法的有效性。首先，给出用 CS 算法求解随机常微分状态方程组的结果，并与 MC 和 PCE 结果进行对比，说明 CS 算法在运行效率上的优势。然后给出用 CS-GDM 算法求解的单个微网的 EI 能量控制问题，说明所提算法的合理性和有效性。最后给出多个微网互联的求解结果，用以说明该算法在高维问题上的适用性。所有的仿真结果都是基于 Matlab 程序包 SPGL1 提供的相关 CS 稀疏重构算法，仿真的硬件配置为带有 Intel Core i7-7700 CPU 的 Ubuntu18.04 服务器和一个带有 2GB 内存的 GPU 卡。

1) CS 算法求解随机状态方程

由于我们提出的算法 1 的主要创新点是用 CS 方法代替其它方法求解随机状态方程 (3-25)，并与优化算法相结合求解优化问题。因此，本部分首先通过与两种传统求解随机微分方程的方法，即 MC 法和 PCE 法的仿真结果进行对比，验证了 CS 法的适用性和有效性。各相关参数的取值见表 3.1。

表 3.1: 参数设置

Parameter	value	Parameter	value	Parameter	value
θ_l	0.4	μ_l	0.7	σ_l	0.4
θ_r	0.5	μ_r	0.2	σ_r	0.12
θ_p	0.1	μ_p	0.1	σ_p	0.43
T_{DG}	0.4	η	0.05	-	-
C_{max}	0.8	C_{min}	0.3	-	-

图 3.3 展示了系数矩阵 c 的稀疏程度，我们将时间区间 $[0, 1]$ 分成 100 等份，并用横轴表示时间节点轴，纵轴为 Hermite 多项式的维数，在本节仿真结果中，取 Hermite 多项式的维数为 20 维。图 3.3 中的每一行，表示在整个时间区间内的 Hermite 的各个展开式系数的值，如果系数值大于给定的阈值 τ ，则表示维蓝色原点，如果小于阈值 τ ，则不展示出来。所以从图 3.3 中可以看出，随机状态变量 $x(t, \xi)$ 的各个分量的展开式系数都具有稀疏性，这也证明了 CS 算法的适用性。

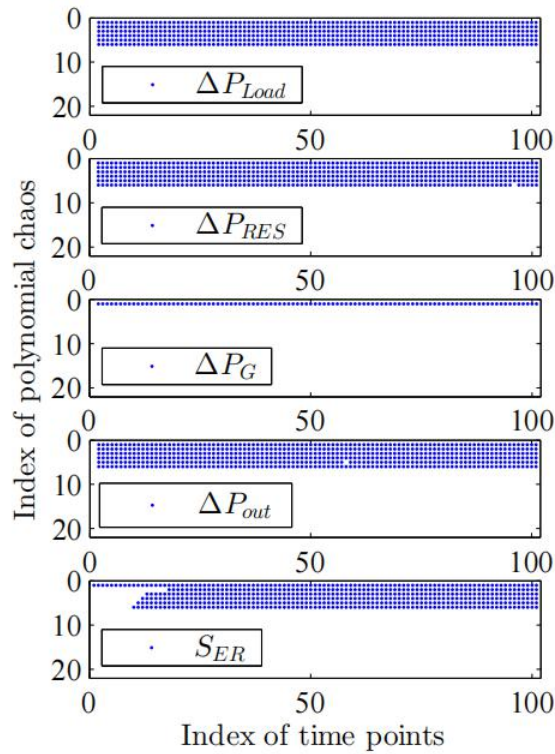


图 3.3 在时间区间[0, 1]内，展开式系数矩阵 c 中大于阈值 $\tau = 1 \times 10^{-5}$ 的元素示意图




图 3.4 CS 方法还原得到的 ΔP

图 3.4 给出了用压缩感知算法还原得到的流入/流出 ER 的功率在 10s 内的波动 ΔP 的结果图，这里先给定控制变量 $u_{ER} = 0.1, u_G = 1$ 。接下来，为了说明 CS 算法在求解随机状态方程上的优势，我们在表 3.2 中给出 CS 方法和 MC 方法求解相同问题的误差估计。从表 3.2 中可以看出，当达到相同误差精度的时候，CS 方法只需要 30 个样本的，而 MC 方法则需要 1000 个样本点。而且，CS 方法的误差快速收敛，当样本点个数达到一定值时，再增加样本点数，也不会使误差减小，而 MC 方法则是以 1/2 的收敛阶慢

速收敛，误差随着样本点数的增多而减少。因此，在实际应用中，CS 方法相较于 MC 方法，可以极大的提高运算效率。

表 3.2 CS 方法与 MC 方法在求解分量 S_{ER} 的期望时的误差对比

Number of Sample(n)	Error ^{MC} $\times 10^{-2}$	Error ^{CS} $\times 10^{-2}$
10	7.83	12.71
20	5.49	2.20
30	4.69	0.72
50	3.35	0.006
100	2.41	0.006
150	2.05	0.006
200	1.69	0.006
1000	0.72	0.006

表 3.3 CS 方法与 PCE 方法求解分量 S_{ER} 的误差对比

	CS method	PCE method
Expectation error	6.1×10^{-5}	6.3×10^{-5}
Variance error	1.9×10^{-4}	2.3×10^{-4}
Sparsity(s)	0.2894	0.2579

为了进一步的验证 CS 方法的准确性，我们在表 3.3 中给出了 CS 方法与传统 PCE 方法在求解随机微分方程上额定误差对比结果。PCE 方法的主要原理是，将随机变量进行随机多项式展开，然后将展开式带回原方程，得到下述高维方程组：

$$d \sum_{j=1}^p c_j(t) \varphi_j(\xi) = \sum_{j=1}^p [A c_j(t) \varphi_j(\xi) + B u + C + D dW] \quad (3-32)$$

然后通过求解此方程组得到展开式系数 c 的值，上述方程组的维度是原始状态方程组的 p 倍，因此这使得 PCE 方法的求解过程非常复杂，常常受到维数的限制。表 3.3 中关于期望和方差的误差结果是将 CS 和 PCE 两种方法得到的结果与 3000 个样本的 MC 方法的结果进行比较得到的，其中的稀疏度(s)是稀疏矩阵 c 中大于等于阈值 τ 的元素个数与 c 的元素总个数的比值。从结果中可以看出，CS 方法可以达到和 PCE 方法相同的精度和稀疏度，但是不需要将原状态方程重新改写成一个高维方程组，大大简化了求解流程。

综上所述，CS 方法不仅克服了 MC 方法收敛慢的问题，也克服了 PCE

方法编程复杂、难以实现的困难，因此 CS 方法更适合作为求解随机状态方程的方法和优化算法想结合来求解随机控制问题。在接下来的仿真中，我们就分别给出用 CS 与梯度下降法结合求解的单个微网和多个微网互联的控制问题的结果。

2) 单个 MG 的控制结果

在本节中，我们以单个微网为例，给出 3.3.2 中所构造的控制问题的仿真结果。其中取 $t \in [0, T], T = 10s$ ，权重参数 $\varepsilon_1 = 1, \varepsilon_2 = 0.01, \varepsilon_3 = 1$ ，初始状态值 $x_0 = (0, 0, 0, 0, 0.5)$ ，控制变量 u_G 和 u_{ER} 的初值从 $(0, 1)$ 区间内随机选取。相应的数值结果如下。

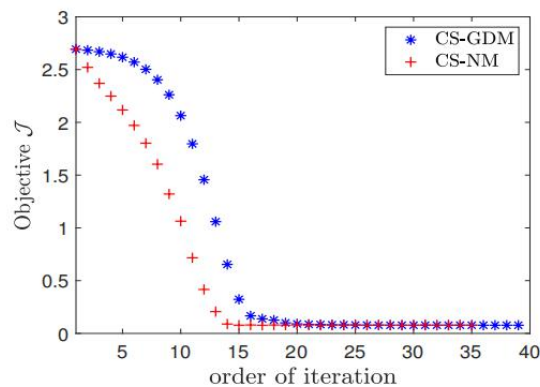


图 3.5 由 CS-GDM 和 CS-NM 两种方法得到的性能指标的收敛结果

图 3.5 中，蓝色标记是用 CS-GDM 方法得到的性能指标 J 在每一步循环中的标量值，红色标记则是将 3.2 节中所提的算法 1 中的梯度下降法换成牛顿法得到的性能指标的值，也即用 CS 方法和牛顿法结合求解微网控制问题，表示为 CS-NM 法。这两种方法的数值结果充分说明了用 CS 方法和迭代法结合求解随机优化控制问题的有效性。尽管牛顿法的收敛性在求解优化问题时比梯度法要高一些，但是由于梯度法的原理最为简单，方便实现，所以我们仍然以梯度法为例来说明将 CS 与迭代法结合的这种思想的合理性。




图 3.6 控制前后 ΔP 对比图




图 3.7 控制前后 S_{ER} 对比图

图 3.6 给出了控制前后的流过 EI 的功率的波动 ΔP ，从图中可以看出，加入控制策略以后，流经 EI 的功率的波动明显减小，因此说明了所设置的控制指标的合理性。与图 3.6 类似，图 3.7 给出了控制前后的 EI 中储能的荷电状态 S_{ER} 的对比结果，同样的，加入控制之后，所得到的储能的荷电状态波动趋于稳定，荷电状态的稳定性在实际的能源储能场景中是非常重要的。

计算得到最优控制器的 u_G 和 u_{ER} 如图 3.8 所示，由于惩罚项 (3-30) 的存在，ERs 的最优平均传输抑制率 u_{ER} 被适当地保持在约束范围内，最优功率调节 u_G 控制 DGs 的功率输出随时间变化，以满足系统的稳定性。




图 3.8 最优控制器的 u_G 和 u_{ER}

接下来，为了说明控制变量 u_G 在 ER 能量管理过程中的作用，我们分别给出在不同权重系数 ε_2 下的结果。其中，图 3.9 展示了不同 ε_2 下的 u_G 的最优结果，从图中可以看出，较小的 ε_2 对应的 u_G 波动范围较大，因此为了避免过度控制，在做优化控制时，应该选择合理的权重系数。图 3.10 给出了不同的 ε_2 下得到的 ER 的储能的荷电状态的最优结果，可以看出，较小的 ε_2 ，储能的荷电状态的波动越趋于稳定。




图 3.9 不同的 ε_2 下的控制器 u_G 的取值




图 3.10 不同的 ε_2 下对应的最优的 S_{ER} 的期望

最后，我们对比了 CS-GDM 算法与 MC 方法在求解相同控制问题上的精度与耗时，从表 3.4 和表 3.5 中可以看出，在相同的误差水平下，CS-GDM 方法的时间复杂度要远低于 MC 方法。因此，我们所提方法的高效性得到证明。

表 3.4 CS-GDM 方法与 MC 方法时间复杂度对比

Optimal Objective	Time Cost ^{MC} (s)	Time Cost ^{CS} (s)
0.0106($\varepsilon_1 = 1, \varepsilon_2 = 0.01, \varepsilon_3 = 0.1$)	4672.84	423.91
0.0776($\varepsilon_1 = 1, \varepsilon_2 = 0.01, \varepsilon_3 = 1$)	3833.15	444.81
1.7280($\varepsilon_1 = 1, \varepsilon_2 = 1, \varepsilon_3 = 1$)	2934.98	278.64

表 3.5 CS-GDM 方法与 MC 方法误差对比

Optimal Objective	Err ^{MC} × 10 ⁻⁵	Err ^{CS} × 10 ⁻⁵
0.0106(ε ₁ = 1, ε ₂ = 0.01, ε ₃ = 0.1)	2.34	4.87
0.0776(ε ₁ = 1, ε ₂ = 0.01, ε ₃ = 1)	1.56	2.35
1.7280(ε ₁ = 1, ε ₂ = 1, ε ₃ = 1)	2.14	3.91

3) 多个 MG 互联的控制结果

在这一部分，我们给出多个微网互联场景下的 ER 控制问题的数值结果，来说明所提算法在高维问题上的适用性。这里以四个相互连接并且离网运行的微网场景为例，拓扑结构如图 3.11 所示。不失一般性，除了参数 θ_p 和 μ_p 设置不同以外，四个微网的状态方程的其它参数设置都同表 3.1。 θ_p 和 μ_p 是控制外来输入功率波动 ΔP_{out} 的参数，由于四个微网连接方式不同，所以 θ_p 和 μ_p 在设置上应该有所差异，特别的，我们取 $\theta_p^1 = 0.1, \theta_p^2 = 0.2, \theta_p^3 = 0.5, \theta_p^4 = 0.8$ ， $\mu_p^1 = 0.1, \mu_p^2 = 0.2, \mu_p^3 = 0.5, \mu_p^4 = 0.8$ ，并且由于系统是离网运行，所以需要满足 (3-33) 式。最后将性能指标的权重系数设置为 $\varepsilon_1 = 1, \varepsilon_2 = 0.01, \varepsilon_3 = 1$ 。那么所得到的相关数值结果如下文所示。

$$\sum_{i=1}^4 \Delta P_{out} = 0 \quad (3-33)$$




图 3.11 仿真所用的互联微网结构图

表 3.7 CS 方法和 MC 方法的时间复杂度随微网数量的变化

Number of MGs	Time Cost ^{MC} (s)	Time Cost ^{CS} (s)
1	4672.84	423.91
2	5463.32	607.11
3	7566.14	772.84
4	11426.35	901.76
5	12648.73	1240.51
6	15971.54	1426.23




图 3.12 四个 ERs 分别对应的最优 ΔP

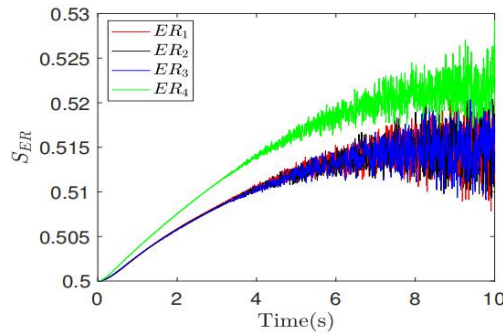


图 3.13 四个 ERs 分别对应的最优 S_{ER}

图 3.12 和 3.13 给出了对 ERs 实施控制以后, 经过每个 ER 的功率波动 ΔP 和储能的荷电状态 S_{ER} 的情况。可以看出, 四个 ER 的功率波动和储能状态都得到了很好的控制, 这说明了所提算法的有效性。而且 ER_1 , ER_2 , ER_3 的功率波动和储能状态基本一致, 而 ER_4 作为中心节点, 需要与其它三个 ERs 都交换能量, 所以其功率波动和储能的荷电状态变化都相对强一些。

图 3.14 给出了最优控制器 u_{ER} 的结果, 与单个微网的结果类似, 四个微网互联的情况下, 每个 ER 的平均传输功率抑制率都被控制在合理的约束范围内。而且对 ER_4 的控制对整个系统的稳定起到了重要的作用。




图 3.14 四个 ERs 分别对应的最优控制 u_{ER}

表 3.6 用 MC 和 CS 两种方法还原 S_{ER} 的期望的误差对比

Number of Sample(n)	Error ^{MC} $\times 10^{-2}$	Error ^{CS} $\times 10^{-2}$
30	10.45	23.59
50	8.18	10.42
80	6.46	4.21
100	5.29	1.12
500	2.31	0.054
1000	1.67	0.054
2000	1.39	0.054
3000	1.13	0.054

最后，我们给出 CS-GDM 算法和 MC 方法在求解多微网问题时的对比结果。首先，表 3.6 中的数据是分别用 CS 方法和 MC 方法求解四个微网的状态方程还原得到 s_{ER} 的期望的误差随样本点数的变化的对比。从数据中可以看出，CS 方法只需要 100 个样本点就可以达到 MC 方法用 3000 个样本的计算得到的精度，由此说明 CS 方法在高维随机问题的求解效率上有明显的优势。由于迭代法求解控制问题的关键步骤就是求解随机状态方程，因此用 CS 方法代替 MC 方法求解状态方程会大大的减少运算代价。具体的，在表 3.7 中我们给出了不同的微网个数下，两种方法求解优化问题所需运算耗时的对比。由数据可知，两种方法的计算时间都随着微网个数的增多而增多，并且 MC 方法的计算时间几乎都是 CS 方法的十倍。以上的数据结果充分说明了 CS-GDM 方法在求解高维随机控制问题上的高效性。

综上所述，3.3 节通过数值仿真结果说明了我们所提的 CS-GDM 算法在计算高维非线性随机控制问题上的合理性和有效性。

3.3.4 总结

本节提出了一个面向能量路由器储能管理的控制问题的框架，并通过常微分方程对系统状态变量进行建模，得到一个非线性的随机控制问题。然后通过调节给定的能量路由器的平均传输抑制率和微网内分布式发电设备的期望功率，使能量路由器的储能状态保持稳定。通过 3.2 节所提的 CS-GDM 方法来求解此场景下的控制问题，并且通过仿真试验，验证了该方法在这类随机非线性控制问题上的有效性。

3.4 基于压缩感知的家庭微网最优电力交易策略研究

3.4.1 背景介绍

随着可再生能源的迅速发展,近年来,基于 RES 的分布式发电机(DG)在电力系统中得到了广泛的应用,特别是在家庭微电网(MG)系统中^[133]。例如,2019年12月,英国安装了1025000多块太阳能光伏板,总发电量约为13356MW,此外,一半以上的电力来自小于5MW的小型设备^[134]。可以预见,未来随着中小型MGs应用的日益广泛,电力系统领域将发生一场重大的革命。这场革命将有助于发展更多的可再生清洁能源,以避免环境污染。另一方面,电力系统结构的这场革命将带来许多需要应对的挑战^[135]。

为了更好地应对即将到来的革命,面对电力系统领域不可预知的挑战,能源互联网(EI)的新概念已经被定义^[136]。根据EI概念,未来电力市场的特征是开放和平等^[137-139]。作为未来电力市场的一个重要组成部分,家用MG受到了广泛的关注^[140-143],这种双重角色意味着,在未来电力市场交易的中间,权利可以在这两个角色之间切换。文献[144]所提出的公式将允许市场自行优化利益的分配,然后实现更有效和更公平的利益分配。因此,MG是目前主要的研究课题之一,已有大量文献进行了广泛的研究。文献[145]研究了一种基于混合整数非线性规划的智能调度策略来优化建筑能源系统的运行调度。该文提出的最优调度策略通过考虑运行能源成本的不确定性和有关电厂开关成本的惩罚,将整体运营成本最小化。在文献[146]中,通过调节家庭PHEVs的充电模式来消除家庭MG中的负载方差的不确定性。为了促进国内需求响应,有效应对能源价格和配电网条件下的压力,文献[147]提出了一种新的客户和配电网运营商共享国内能源蓄电池的调度策略。

未来电力市场的另一个关键特征是电价的波动。与传统电力系统的固定价格相比,未来电力市场的电价将随着生产成本和发电能力的增加而发生动态变化。此外,未来的EI也可以基于对客户电费数据的分析提供相应的服务,使电力的价值最大化^[149]。在电价预测方面,文献[150]提供了一种结合小波变换与自回归移动平均、核心极限学习机和自适应粒子群优化的混合电价预测方法。

作为MG与外部交流和交流能量的中介人,ER在EI中扮演着至关重要的作用^{[151][152]}。文献[153]设计了一种交流直流混合多端口电流配电

网，由高压交流端口、低压交流端口和低压直流端口组成，而[156]则提出一种连续马尔可夫链模型，为系统提供了形式上的验证解决方案。

受上述信息的启发，本节提出了一种不需要可控分布式电网的家庭 MG 系统的电力交易策略。考虑到 RESs、负载和电价的功率动力学的不确定性，随机微分方程在这些条件下对系统提供了最完整的描述^{[148][154][155]}。因此，在本节工作中，同样应用随机微分方程(Stochastic Ordinary Differential Equation, SODE)来建模。值得注意的是，为了捕捉在电价中观察到的平均回归和急剧峰值^[157]，我们使用在金融数学领域流行的 CIR 模型来建模电价。首先利用 SODE 来模拟 ER 的功率动力学。然后，将所考虑的 MG 系统改写为非线性 SODE。为了通过电力交易最大化利润，提出了一个具有约束条件的非线性随机优化问题。由于非线性随机问题的复杂性，采用了基于压缩感知的梯度下降方法 CS-GDM。为了证明该方法的可行性，进行了数值计算实例。

本文节主要重要性和贡献如下：

1. 这是第一次通过将电价描述为非线性 SDE 来研究电力交易策略。CIR 扩散过程可以更准确地描述电价。
2. 通过采用基于压缩感知的方法，我们能够处理复杂的非线性随机问题。现有的大多数方法，如蒙特卡罗方法，都未能有效地解决这个问题。
3. 与现有的固定电力模型相比，所提出的控制方案对未来的电力市场更加实用。

本节的其余部分组织如下。在 3.4.2 中描述了一个典型家庭的电力模型，并将 MG 运行和电力交易问题表述为一个非线性随机优化问题。在 3.4.3 中，采用了基于压缩感知的梯度下降方法来解决该问题并给了数值结果。最后，对本节内容进行简单总结。

3.4.2 系统建模

本节研究了一种典型的家用 MG 系统。如图 3.15 所示。MG 通常由 RES、负载和 ER 组成。在这样的 MG 中，所有的发电都依赖于 RESs。在所考虑的此类 MG 中，ER 扮演着两个角色：一方面，MG 可以将能源卖

给电力公司，或者通过 ER 从电力公司购买能源；另一方面，ER 可以作为电池，这意味着 ER 可以储存能量和放电。




图 3.15 一个典型的家庭微网结构

为了简化符号法，除非有必要，否则本文省略了所有变量的时间 t 。为了表征 RESs 和负载功率的不确定性和波动，采用线性 SODEs 如下^[132]：

$$\begin{aligned} dP_R &= -\theta_r(P_R - \mu_r)dt + \sigma_r dW_r, \\ dP_L &= -\theta_l(P_L - \mu_l)dt + \sigma_l dW_l, \end{aligned} \quad (3-34)$$

其中 w_r 和 w_l 表示标量维纳过程， μ_r 和 μ_l 表示 P_R 和 P_L 的期望值，参数 $\theta_r, \sigma_r, \theta_l$ 和 σ_l 表示系统参数。所有的系统参数均可通过参数估计方法^[158]来确定。

与文献[37]相似，我们应用以下线性 SODEs 来描述所考虑的 MG 中 ER 的存储分量的功率动力学。

$$\begin{aligned} dP_{ER} &= -\frac{1}{T_{ER}}(P_{ER} - B_{ER}u)dt, \\ dS_{ER} &= \eta P_{ER}dt. \end{aligned} \quad (3-35)$$

在(3-35)中， T_{ER} 是 ER 中储能对应的时间常数， B_{ER} 表示 P_{ER} 的最大绝对值， u 是控制输入信号。此外， S_{ER} 表示 ER 中储能的电荷状态，而在(3-35)中的 η 是一个与充放电效率有关的系数。此外， u 和 S_{ER} 的约束条件如下：

$$\begin{aligned} -1 &\leq u \leq 1, \\ C_{\min} &\leq S_{ER} \leq C_{\max}, \end{aligned} \quad (3-36)$$

其中， C_{\min} 和 C_{\max} 分别表示荷电状态 s_{ER} 的最小值和最大值。

由于需求的非弹性和可再生发电的影响，使得电力价格大幅波动。此外，电价还受到发电成本、电力质量和其他因素的影响。因此，在未来的电力市场中，电价类似于股票、期货或期权的价格，而不是恒定值^[159]。为了描述电价的波动，本文应用了一种非线性 SODE 的模型。

根据 Cox - Ingersoll - Ross (CIR) 扩散过程^[160]，电力公司与所考虑的 MG 之间的电价制定如下：

$$d\lambda = -\theta_p(\lambda - \mu_p)dt + \sigma_p\sqrt{\lambda}dW_p, \quad (3-37)$$

其中， λ 为电价， μ_p 代表 λ 的期望值， θ_p 和 σ_p 是系统参数。(3-37) 式中的平方根项强调了价格的动态波动实际上是非线性的。

令 $x = [P_R, P_L, \lambda, P_{ER}, S_{ER}]^T$ ， $W = [W_r, W_l, W_p]^T$ ，则上述所考虑的系统可以简写为：

$$dx = (Ax + Bu + C)dt + D(x)dW, \quad (3-38)$$

其中：

$$A = \begin{pmatrix} -\theta_r & 0 & 0 & 0 & 0 \\ 0 & -\theta_l & 0 & 0 & 0 \\ 0 & 0 & -\theta_p & 0 & 0 \\ 0 & 0 & 0 & -\frac{1}{T_{ER}} & 0 \\ 0 & 0 & 0 & \eta & 0 \end{pmatrix}, \quad B = \begin{pmatrix} 0 \\ 0 \\ 0 \\ \frac{B_{ER}}{T_{ER}} \\ 0 \end{pmatrix}, \quad C = \begin{pmatrix} \theta_r\mu_r \\ \theta_l\mu_l \\ \theta_p\mu_p \\ 0 \\ 0 \end{pmatrix}, \quad D = \begin{pmatrix} \sigma_r & 0 & 0 \\ 0 & \sigma_l & 0 \\ 0 & 0 & \sigma_p\sqrt{\lambda} \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

在上述表达下，我们所研究的 MG 系统已经转化为随机控制系统 (3-38)。应注意，矩阵 $D(x)$ 是与系统状态 $x(t)$ 相关的时变矩阵，因此 $D(x)dW$ 表示系统 (3-38) 确实是一个非线性随机系统。

有了系统模型之后，所考虑的 MG 的能量交易策略被表述为一个最优控制问题。具体说明如下：

为了保持所研究的 MG 的功率平衡，可得到以下方程式：

$$P_R = R_L + P_{ER} + P_{out}, \quad (3-39)$$

这里 P_{out} 表示 MG 和电力公司直接的能量交换，并且有三种可能，

- 1) 当 P_{out} 大于零时, MG 将向电力公司销售电力;
- 2) 当 P_{out} 为零时, MG 无需电能交换即可保持电力平衡;
- 3) 当 P_{out} 小于零时, MG 就会从电力公司购买电力。

作为一种能源交易策略,我们的目标是通过能源交易实现利润最大化。使用上述符号, $\lambda(t)P_{out}(t)$ 表示单位时间 MG 的利润,考虑时间段 T, 使得其值应最小目标函数定义如下:

$$J_0 = E \int_0^T -\lambda P_{out} dt \quad (3-40)$$

其中 E 表示数学期望,积分表示在时间大 T 内的 MG 的利润的负值。通过将等式(3-39)带入目标函数(3-40),原问题重新写成:

$$J_0 = E \int_0^T -\lambda(P_R - P_L - P_{ER})dt = E \int_0^T x^T Q x dt, \quad (3-41)$$

其中,

$$Q = \frac{1}{2} \begin{pmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ -1 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

那么最优控制问题可以总结为:

$$\begin{aligned} \min_u \quad & J_0, \\ \text{s.t.} \quad & (3-34)-(3-37) \end{aligned} \quad (3-42)$$

为了处理不等式约束(3-36),需要对目标函数引入了一个惩罚项 P:

$$P = \varepsilon_1 \left(S_{ER} - \frac{C_{\min} + C_{\max}}{2} \right)^2 + \varepsilon_2 (-\log(u+1) - \log(1-u)), \quad (3-43)$$

其中, ε_1 和 ε_2 是权重系数。在(3-43)中,第一项对应的是 S_{ER} 的约束条件,第二项是对控制项 u 的对数形式的约束。当一个约束条件是时,其对数障碍函数 $\phi(x) = -\log(-f(x))$ 是可微的,且当 $f(x)$ 趋向于零时, $\phi(x)$ 趋向于无穷^[161]。

增加约束条件的惩罚项之后,问题(3-42)可以重新写成一个等式约束问题:

$$\begin{aligned} \min_u J &= E \int_0^T \{x^T Qx + P\} dt, \\ \text{s.t.} & \quad (3-34), (3-35), (3-37) \end{aligned} \quad (3-44)$$

当 ε_2 趋近于 0 时，该控制问题等价于原控制问题。值得注意的是，目标函数由于对障碍函数是非线性的。通过求解随机非线性最优控制问题 (3-44)，可以得到所考虑的家庭 MG 的最优能量交易策略。

同样，我们应用 3.2 节介绍的 CS-GDM 算法求解上述问题，首先，我们需要推导出问题 (3-42) 的 Hamilton 系统：

$$\begin{aligned} dx &= Ax + Bu + C + D(x)dW, \\ d\lambda &= -\frac{\partial J}{\partial x} - (A + \frac{\partial D}{\partial x})' \lambda, \\ \frac{\partial H}{\partial u} &= \frac{\partial J}{\partial x} + B\lambda. \end{aligned} \quad (3-45)$$

有了上述 Hamilton 系统，就可以应用 CS-GDM 方法求解该随机控制问题，具体数值结果在下一节中给出。

3.4.3 仿真结果

为了证明该策略，本节对所考虑的家庭 MG 系统进行了仿真，并评估了所提出的能源交易策略的控制性能。模拟周期为 $t \in [0, 60] \text{min}$ ，时间增量为 1min。利用 MATLAB2019a 环境求解相关的最优随机控制问题。

所考虑的 MG 系统 (3-34)–(3-37) 的参数见表 3.8。由方程 (3-34) 求解得到的 P_R 和 P_L 如图 3.16 和图 3.17 所示。由于 P_L 初始值为 15KW，而期望值 μ_L 设置为 10KW，因此图 3.17 中的图中 P_L 曲线呈下降趋势。

表 3.8 仿真参数设置

Parameters	Value	Parameters	Value	Parameters	Value
θ_r	2	μ_r	15 KW	σ_r	2
θ_l	1.5	μ_l	10 KW	σ_l	1.5
θ_p	0.5	μ_p	0.15\$/KWh	σ_p	0.1
T_{ER}	1 h	B_{ER}	4 KW	η	0.2
ε_1	2	ε_2	1		




图 3.16. : P_R 一小时内的功率波动




图 3.17: P_L 一小时内的功率波动

采用非线性 SDE 模型 (3-37) 求得的电价波动如图 3.18 所示。从图中可以清晰地看出 λ 在后面的 30 分钟内波动较为剧烈。

根据所提出的能源交易策略，图 3.19 中给出了 ER 储能部分的功率和荷电状态。很明显，在所研究的时间段内，荷电状态 S_{ER} 被限制在一个适当的范围内。此外，从图中可以看出，在时间段 $[0, 15]$ min 内，功率 P_{ER} 大于零，并且电荷的状态增加。然而在区间 $[15, 60]$ min 中，功率 P_{ER} 小于零，荷电状态减小。因此图 3.19 说明，ER 在前面一刻钟充电然后在其余时间进行放电。

家庭 MG 的电力交易利润在图 3.20 中给出。可以看出，在区间 $[0, 10]$ min 内，RES 提供的功率小于负荷所需功率，所以家庭 MG 需要向电力公司购买电能。10min 之后， P_R 大于 P_L ，所以 MG 向电力公司出售电能。




图 3.18 电价波动




图 3.19 P_{ER} 和 S_{ER} 一小时内的波动曲线

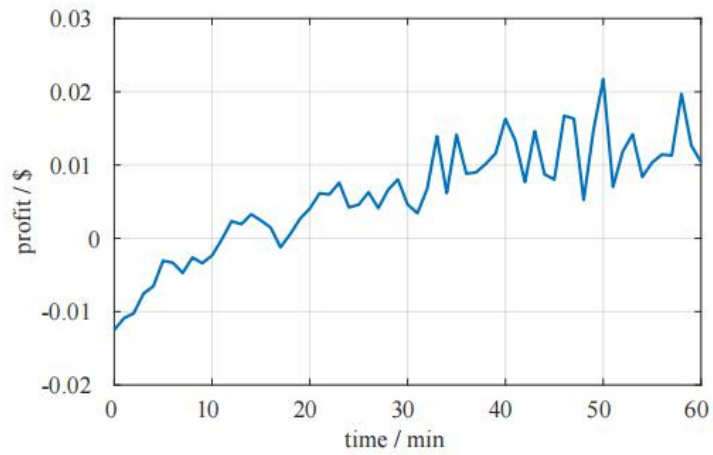


图 3.20 家庭 MG 每分钟的电力交易收益

上述数值例子正确地表明了所提出的能源交易策略的可行性，并评价了 CS-GDM 方法的有效性。

3.4.4 结论

本节提出了一种无可控 DGs 的家庭 MG 系统的最优电力交易策略。利用 CS-GDM 方法，解决了该随机优化控制问题。仿真部分的结果表明，最优电力交易策略具有较好的性能，可以将 ER 中储能部件的荷电状态控制在适当的范围内的基础上实现电力交易利润最大化的目标。

3.5 小结

微网能量优化管理本质上是高维度、多约束，非线性随机优化问题，传统方法如线性规划、动态规划等受到计算复杂性影响难以求解。得益于压缩感知技术在求解随机微分方程上的高效性，本节采用压缩感知技术求解高维度能源互联网随机控制问题，并给出两个具体应用场景。其一为通过调节微网内分布式电源的发电功率和从外电网的取电功率来实现能量路由器储能最小化，此场景考虑的是多个微网并网运行的场景，涉及的随机变量维度高且目标函数是非线性的，因此传统方法无法求解，应用本节所提算法可以有效求解。第二个应用场景为制定能量交易策略，通过调节能量路由器的功率波动，来实现单个微网从外电网取点费用最低。仿真实验充分说明了 CS-GDM 方法的有效性。

压缩感知技术在求解随机控制问题上还可以进一步改进，后续我们考虑将压缩感知技术于随机梯度下降法、博弈论等方法结合，来进一步提升求解效率。

第四章 基于深度强化学习的微网储能系统控制策略研究

究

4.1 引言

微网是为解决光伏发电、风力发电等分布式能源并网问题而快速发展起来的小型发配电系统^[162]。为维持微网的功率平衡，降低分布式能源出力不确定性对微网的影响，配置储能装置十分必要。因此典型的微网通常包含各种可再生能源发电装置、储能装置、负荷等组件，以及能量转换器、控制器等辅助设备^[163]。对微网的研究包含众多方面，如对微网体系架构的研究、电力电子技术研究、投资和运营成本研究、安全与运维研究、能量调度控制策略研究等等。其中储能控制策略作为微网能量调度的研究重点被广泛关注。

经典优化方法^[164-165]、基于规划的方法^[166-167]、启发式算法^[168-170]等都可以用来处理微网的能量调度控制问题，但是当实际场景较为复杂难以用明确数学模型描述，且数据量巨大时，上述算法将很难适用。近年来随着人工智能的发展而兴起的深度强化学习(Deep Reinforcement learning, DRL.) 强化学习算法则为处理复杂微网控制问题提供了新的思路。深度强化学习是实现人工智能的关键技术，随着 2016 年谷歌 Deep Mind 创建的 AlphaGo 问世，深度强化学习作为处理序列控制问题的有效手段被研究者们广泛应用并发展^[171-173]。

微网能量控制问题作为典型的时序控制问题，符合深度强化学习求解框架，目前已有很多突出的工作。文献[63]给出了基于异步优势的深度强化学习算法在求解无模型、多目标、多微网的能量调度控制问题中的应用，并通过具体数值算例，说明深度神经网络的搭建依据。文献[61]以维护孤岛微网系统稳定性和运行经济效益为目标，通过深度强化学习算法给出微网的复合储能协调控制策略。文献[174]建立了基于能量总线的微网框架模型，对比深度 Q 学习算法相较于启发式算法在能量调度控制问题上的优势。文献[62]针对微网光伏出力的随机性，采用神经网络预测的数据进行强化学习训练，降低微网用电成本。文献[175]综合考虑负荷、光伏、实时电价的波动和潮流计算，提出一种基于模型的近似动态规划算法，然后用卷积神经网络来近似深度强化学习中的值函数。文献[176]从电网运行安全角度出发，提出一种基于深度强化学习的电网切机控制策略。文献[177]从分销系统运营商的角度出发，以降低需求侧峰值比和保

护用户隐私为目标，通过蒙特卡罗强化学习算法给出零售定价策略。文献 [178] 在智能电网环境下探索使用深度强化学习对建筑能源管理系统的进度进行在线优化的好处，并在大型 Pecan Street Inc. 数据库上验证方法的有效性。

与已有工作不同，本文应用深度强化学习算法求解储能的充放电控制策略时，采用的训练数据是通过 Simulink 搭建的微网仿真环境运行出来的实时数据。在仿真环境中，可以考虑微网各个组成模块的有功功率和无功功率，并且应用 PQ 控制策略保证有功和无功的可控性。用仿真环境运行得到的信息进行强化学习训练，可以添加电压、电流、相角等更多状态信息，从而更全面的考虑各种状态信息对目标函数的影响，相比于数学公式逼近的状态数据更加真实可靠。本文结构安排如下，首先在第 4.2 节给出所研究的微网对象的组成和各个模块的 Simulink 仿真设计，然后在第 4.3 节重点介绍所用深度强化学习算法框架以及其在储能控制问题上的应用流程。在第 4.4 节实验验证中，通过与已有算法对比来说明本文算法流程的有效性。最后给出总结与下一步工作展望。

4.2 微网组成与 Simulink 仿真设计

本文考虑并网运行的微网能量调度问题，给出典型微网的拓扑结构如图 4.1 所示。




图 4.1 微网结构图

下面给出各个组成模块的详细介绍。

4.2.1 微网组成模块

1) 光伏发电。得益于太阳能发电技术的成熟，光伏发电成为微网系统分布式能源的重要组成部分，因此本文以光伏发电作为分布式发电的代表进行详细讨论。光伏发电功率可由式(4-1)给出：

$$P_{PV}(t) = R(t) \times S \times \eta_{PV} \quad (4-1)$$

式中： $R(t)$ 为时间 t 时刻的太阳辐射强度，单位为 W/m^2 ； S 为布置的太阳能电池板的面积。太阳辐射强度与电池板面积的乘积为太阳能辐射功率，再乘以光伏发电的转换效率 η_{PV} ，得到 t 时刻光伏发电的功率。

2) 储能系统。由于光伏和风力等分布式发电模式具有间歇性等不稳定的特点，因此需要添加储能系统来维护微网稳定运行和平滑系统功率。蓄电池作为高效的储能设备被广泛应用，蓄电池中能量状态满足式(4-2)：

$$E_{bat}(t) = E_{bat}(t-1) + P_{bat}(t) \times \Delta t \quad (4-2)$$

式中： $P_{bat}(t)$ 为 t 时刻蓄电池的充放电功率； Δt 为两次充放电动作之间的时间间隔。

在微网系统中，储能系统的充放电功率通常作为重要的控制变量参与微网能量调度，也是本文的控制重点。

3) 负荷。负荷是微网系统中消耗电能部分的总称，针对固定微网系统，负荷需求由当地气候环境和微网性质决定，因此通常不可调节，在本文能量调度问题中，负荷曲线作为固定量输入到微网系统。

4.2.2 Simulink 仿真设计

本节详细介绍微网系统各组成模块的仿真模型搭建原理。与图 4.1 微网结构相对应，图 4.2 是利用 Matlab/Simulink 工具箱，搭建的微网系统的仿真模型。下面对各个仿真模块进行详细说明。

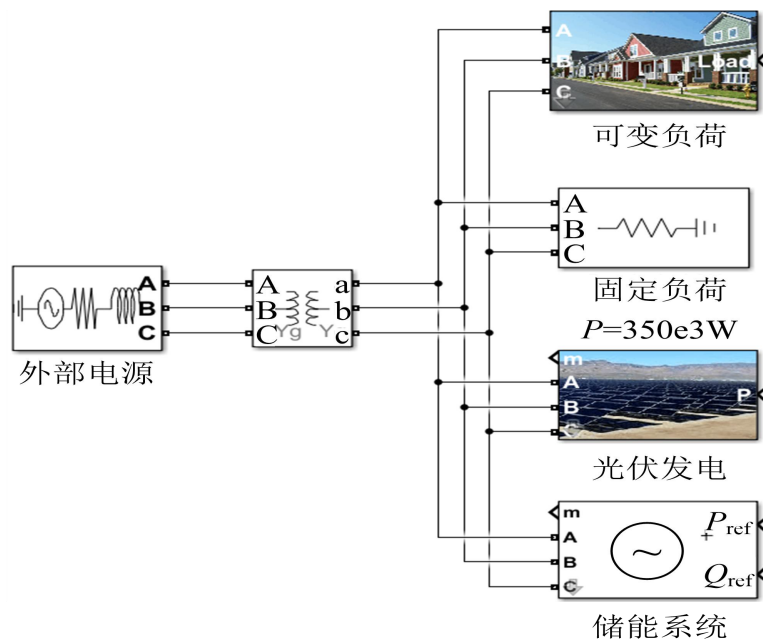


图 4.2 微网仿真结构图

1) 外部电源。本文所用外部电源由 Simulink 自带的三相交流电源模块替代，模块的参数设置需要根据实际仿真需求给出，具体包括线电压有效值、A 相初相相角、频率、内部连接方式等。然后通过变阻器模块与微网系统内部模块相连，为系统内部提供所需电能。

2) 光伏发电。本文考虑的微网系统是在并网模式下工作，为保证电网发电和用电平衡，要求光伏发电系统的有功功率与无功功率可调节。因此针对光伏发电采用 PQ 控制策略^[179]。具体模型如图 4.3 所示。其中输入端口 1 的光伏功率由 1.1 节中的光伏功率计算公式给出，然后通过一个三相动态负荷模块实现 PQ 控制，最后在输出端口 1 输出有功功率数据。

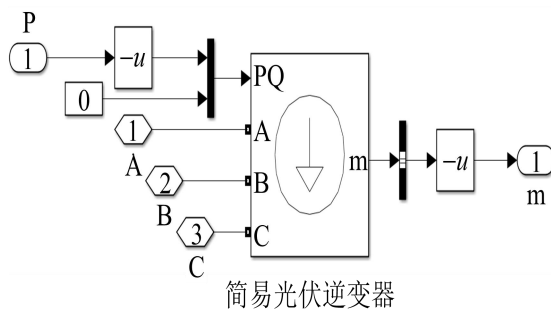


图 4.3 光伏系统模型

3) 储能系统。储能系统的充放电功率是本文的主要控制对象，因此要求搭建的储能系统模型可调节充放电功率，所以同样用三相动态负荷来达到 PQ 控制效果。如图 4 所示，从输入端口输入外部控制指令，然后通过一个计算模块，检查电池是否过度充放电，并且根据式(4-2)计算电池的有功功率 p 和无功功率 q 。最后将得到的 p 、 q 值带入三相动态负荷模块，得到储能系统最终输出的有功功率和无功功率。

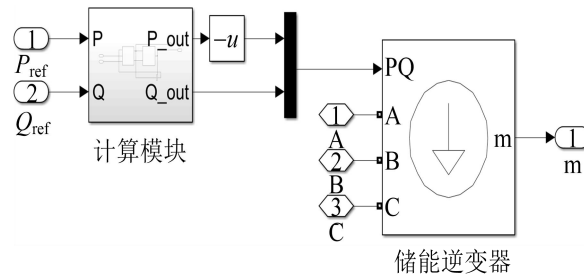


图 4.4 储能系统模型

4) 负荷。在仿真实验中，由于负荷的随机性，微网负荷通常由 2 部分组成，其中一部分是可变负荷，模型如图 4.5 所示。从输入端口输入负荷功率数据，通过计算式 $q^2 + p^2 = p^2 \mu^2$ 计算得到 q 值，其中 μ 表示功率因数。最后通过三相动态负荷模块得到输出结果。另一部分是固定负荷，在仿真模型中直接由 Simulink 中的电阻模块充当。

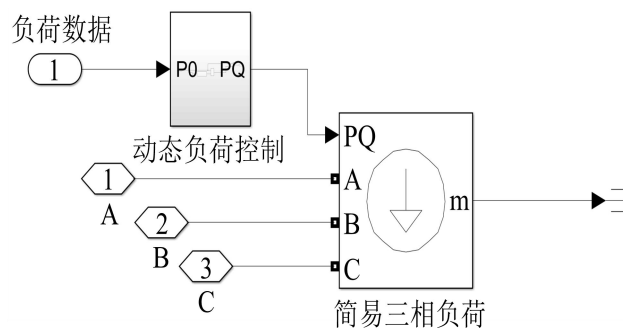


图 4.5 可变负荷模型

综上，本文利用 Simulink 工具箱为并网运行的微网系统搭建了一套完整的仿真模型。为保证微网系统与外界电网交互的稳定性与可控性，各个分布式能源的仿真模块均采用 PQ 控制策略进行控制。本文在此仿真模型的基础上进行深度强化学习训练，可以综合考虑系统电压、各个模块的有功功率、无功功率、电池的 SOC 状态等各个状态变量对微网系统从外电网购电费用的影响，从而得到优化的储能系统充放电控制策略，

相较于传统的以数学公式为基础的强化学习训练，可以综合考虑更加丰富的状态变量对控制目标的影响。

4.3 深度强化学习算法

强化学习是以最大化预期回报为目标，通过智能体 (Agent) 和环境 (Environment) 的不断交互，得到环境的状态变量 (State) 与智能体的动作变量 (Action) 之间的映射关系，为智能体提供优化的动作策略 (Policy)。深度强化学习则是在传统强化学习的基础之上，利用深度神经网络来创建状态变量与动作变量之间的对应关系。由于深度神经网络强大的表达能力，深度强化学习可以处理更加复杂、更加接近实际的策略决策问题。近年来，深度强化学习在优化控制、机器人控制、自动驾驶等领域的应用已经取得突破性的进展。

深度强化学习通常是基于马尔可夫决策过程的 (Markov Decision Process, MDP)，即智能体与环境在下一时刻的交互结果只与当前的环境状态有关，而与之前的环境状态无关。传统的 MDP 过程包含 4 个要素，由 (S, A, R, π) 四元组给出^[180]。其中 S 表示环境状态的集合； A 表示智能体可以采取的动集合； R 表示奖励函数，即智能体在某一状态下采取某种动作后得到的奖励； π 表示策略集合，是状态和动作之间的对应关系。

强化学习优化策略的求解算法可以分为基于价值函数求解、基于策略梯度求解、基于搜索与监督求解 3 大类^[181]。本文重点介绍基于价值函数的求解方法，典型的有动态规划算法、蒙特卡洛算法、时序差分算法等，其中动态规划算法适合求解有模型且状态空间维数较低的情况。蒙特卡洛算法是一种不基于模型的简易算法，但是缺点是需要完整的状态序列信息，这在很多非周期的过程中是很难获取的。时序差分法则不需要完整的状态序列就可以逼近价值函数，经典的时序差分法包括在线差分算法 SARSA 和离线差分算法 Q-Learning 算法，这 2 种方法都是通过维护一个 Q 表的方式求解小型强化学习问题。当状态和动作空间是连续的或者是规模非常大的离散的情况下，需要维护的 Q 表异常巨大，会给存储带来困难。但是神经网络的发展，使得这一问题得到解决，用深度神经网络代替 Q 表，得到更加适合于复杂问题的深度强化学习算法，一类典型的算法为深度 Q-Learning (Deep Q Network, DQN) 算法。

4.3.1 算法框架

本文的微网控制问题采用的是 DQN 的改进版本，即双重深度 Q-Learning (Double Deep Q Network, DDQN) 算法^[182]。

Q-Learning 算法是通过更新公式式 (4-3) 来更新定义的 Q 函数。

$$Q(S, A) = Q(S, A) + \alpha(R + \gamma \max Q(S', a) - Q(S, A)) \quad (4-3)$$

式中： $Q(S, A)$ 为动作价值函数； α 为学习率。当更新公式收敛时，可以得到强化学习的最优控制策略。

DQN 则是用深度神经网络 $Q(S, A | \omega)$ 来代替 Q-Learning 中的 Q 函数，如图 4-6。

然后由式 (4-3) 计算出当前目标 Q 值，根据当前目标 Q 值与 Q 网络给出的 Q 值之间的均方误差来更新神经网络的参数 ω 。




图 4.6 神经网络估计 DQN 价值函数

DDQN 算法则是在 DQN 的基础上进行两点改进。首先是引入两个网络，一个是目标网络 $Q'(S, A | \omega')$ 用来计算目标 Q 值，另一个是更新网络 $Q(S, A | \omega)$ 用来更新 Q 值，这样可以减小目标 Q 值和更新网络参数之间的依赖关系。目标网络与 Q 值网络具有完全相同的结构，并且定时从 Q 值网络同步参数。

其次是解耦目标式 (4-3) 中目标 Q 值的动作选择和目标 Q 值的计算过程，从而减小因为贪婪算法导致的过度估计。具体做法是计算目标 Q 值时，不再从目标 Q 网络中找出动作对应的最大 Q 值，而是先在更新网络中找出最大 Q 值对应的动作：

$$\tilde{a}(S' | \omega) = \arg \max_{a \in A} Q(S, A | \omega) \quad (4-4)$$

然后利用这个动作 $\tilde{a}(S' | \omega)$ 在目标网络 $Q'(S, A | \omega')$ 中计算目标 Q 值：

$$Q' = R + \gamma Q'(S', \tilde{a}(S' | \omega) | \omega') \quad (4-5)$$

通过以上两点改进，使得 DDQN 算法解决了传统 DQN 算法的强依赖与过度估计问题，其它算法流程与 DQN 相同。

4.3.2 深度强化学习在微网控制问题中的应用

本节，首先给出微网控制问题的描述，然后给出如何将微网控制问题转化成适合深度强化学习求解的形式。

4.3.2.1 控制问题:

1) 控制目标。

根据微网系统的不同需求，可以设置不同的控制目标，比如最小化污染物排放量、最小化燃料发电成本、最小化电压偏移、最小化网络有功损耗，或最大化电压稳定性等。通常可以设置单一控制目标，或者以上多种控制目标的组合，本文所考虑的算例以最小化外电网取电费用为目标。具体形式如式(4-6)：

$$C_{ost} = \int_{t=0}^T C_{out}(t) \cdot P_{out}(t) dt \quad (4-6)$$

式中： C_{ost} 为在时间 $[0, T]$ 内，整个微网从外部获取电能的总费用； $C_{out}(t)$ 和 $P_{out}(t)$ 分别为 t 时刻的实时电价和外电网发电功率，且 $P_{out}(t)$ 满足功率平衡公式式(4-7)：

$$P_{PV}(t) + P_{bat}(t) + P_{out}(t) = P_{load}(t) \quad (4-7)$$

左侧为电源组件功率，右侧为负荷功率。

2) 控制变量。

本文算例研究的是对微网储能系统的控制，因此控制变量选择为储能系统的充放电功率 P_{bat} ，其它变量如 P_{PV} ， P_{out} ， P_{Load} 以及仿真系统的电压 V ，储能的荷电状态 SOC 等都是状态变量。这些状态变量的值由 4.2.2 节

中搭建的仿真模型动态给出。

3) 约束条件。

结合实际情况，要求储能控制问题满足功率约束和荷电状态约束，即：

$$\begin{aligned} P_{bat}^{\min} \leq P_{bat}(t) \leq P_{bat}^{\max} \\ SOC^{\min} \leq SOC(t) \leq SOC^{\max} \end{aligned} \quad (4-8)$$

综上，微网储能控制问题可以表述为：在 4.2.2 节搭建的仿真环境中，通过控制储能充放电功率 $P_{bat}(t)$ ，在满足约束条件(4-8)的情况下，使得从外电网取电费用 C_{out} 尽可能小。

4.3.2.2 算法流程

将上述控制问题转化为强化学习算法 DDQN 的求解形式，4.2.2 节搭建的微网仿真模型充当强化学习问题的环境，储能充放电功率控制器则为智能体，强化学习的目标是通过智能体和环境的不断交互来得到优化的控制策略。与此对应，需要确定此问题的马尔可夫状态序列四元组 (S, A, R, π) 的具体表达。

1) 状态变量 $S = (P_{PV}, P_{Wind}, P_{out}, P_{load}, V, SOC)$ ，是仿真环境实时给出的动态结果。

2) 动作变量 $A = (P_{bat})$ 是智能体的决策变量。

3) 奖励函数 R 的构造需要结合目标函数(4-6)和约束条件(4-8)。从当前状态 s_t 到下一状态 s_{t+1} 的奖励函数定义为：

$$R(s_t, t) = -[\int_t^{t+1} C_{out}(t) \cdot P_{out}(t) dt + \beta(t)] \quad (4-9)$$

式中：第一部分是此时间段内电费消费情况，第二部分是为了刻画约束条件而设置的惩罚项，即当约束条件(4-8)满足时， $\beta(t) = 0$ ，当约束条件不满足时，给 $\beta(t)$ 赋值成一个量级非常大的常数。因为强化学习的目的是使奖励函数最大化，因此需要在这两部分之前加上负号。

4) 策略函数 π 是微网的各个状态变量和储能功率之间的对应关系，

也即 DDQN 算法中所要求的深度神经网络。有关策略 π 满足的神经网络的设计本文将在数值算例中详细给出。

有了上面的一一对应关系之后，用深度强化学习算法来求解微网储能控制问题的思路就可以用图 4.7 清晰的给出。具体网络结构和参数设计将在第 4.4 节实验验证中详细给出。

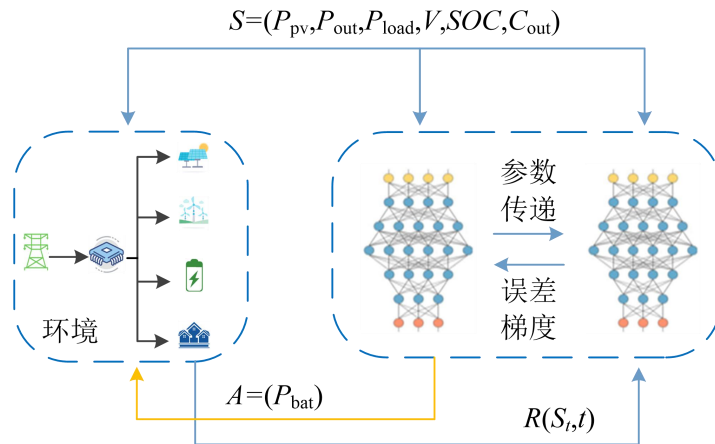


图 4.7 微网控制问题求解流程

4.4 实验验证

本节通过具体数值算例来说明 DDQN 算法在求解微网储能控制问题中的应用，并与最大功率点追踪(Maximum Power Point Tracking, MPPT)控制进行比较，说明 DDQN 算法的有效性。

4.4.1 实验设置

为了加速 Simulink 的仿真速度，在仿真实验验证中，本文不考虑风力发电等其它分布式发电模块，在微网中只考虑光伏发电、储能、负荷和外电网相连。各个仿真模块具体参数设置详见附录 2。

约束条件(4-8)中的上下限约束设置为：

$$P_{bat}^{\min} = -4e5(w), P_{bat}^{\max} = 4e5(w),$$

$$SOC^{\min} = 0.19, SOC^{\max} = 0.85.$$

另外一个重要的设置就是 DDQN 算法中 Q 值估计神经网络的设置，根据经验以及不断的调试验证，本文所用神经网络为 4 层 24 节点的全连接

层，并且以 relu 函数作为中间层激活函数，具体如图 4.8。




图 4.8 神经网络拓扑结构

4.4.2 数值结果

结合 Reinforcement Learning Toolbox 工具箱提供的深度强化学习算法与 Simulink 搭建的仿真环境完成 DDQN 算法的构建,然后在具有 Intel i7-8586U CPU 和 2G 内存独立显卡的设备上进行训练。

本文实验算例是在给定微网 24 小时的光伏发电功率曲线、负荷用电功率曲线与实时电价的前提下，通过调节储能充放电功率，来优化全天 24 小时从外电网取电费用。在进行 DDQN 算法训练时，需要将状态变量的各个分量进行归一化处理之后再带入 DDQN 的目标网络中进行训练，考虑到本文的控制目标是最小化外电网购电费用，所以为了在训练过程中增大电价波动对控制目标的影响，本文在训练时给电价状态变量乘上 2 倍的放大系数。训练时间步长取为 300s，因此一个训练周期为 288 步。本实验在 100 000 组训练周期下得到结果。

图 4.9 给出了光伏、储能、外电网和负荷在全天 24 小时内的有功功率曲线。横坐标是时间轴，以小时 h 为单位，纵坐标表示功率，以 kW 为单位。其中光伏和负载曲线是事先给定的外部数据，储能功率是由 DDQN 训练得到的神经网络输出的策略结果，然后根据功率平衡得到外电网有功功率。




图 4.9 各模块有功功率波动曲线

结合图 4.10, 看出 DDQN 算法得到的储能充放电策略为, 大约在 0h~2h 之间, 此时光伏发电不工作, 储能先放电, 储能的 SOC 到达下限之后, 此时由外电网发电。然后当光伏开始工作时, 大约是 7h~11h, 储能开始充电, 将多余的光伏发电存储起来。在 11h~17h 之间储能充满电后停止工作, 多余的光伏发电反馈给外电网。然后在 17h~22h 用电高峰时刻, 此时实时电价升高, 从外电网取电成本增高, 储能在此时段放电供微电网负荷使用。综上此控制策略是在白天太阳能充足时将太阳能存储起来供晚上实时电价比较高的用电高峰时刻利用, 以此来达到节约购电成本的目的。因此从逻辑上分析, 此控制策略是合理的。相比于 DDQN 算法得到的控制策略, DQN 算法在相同训练周期内得到的控制策略为在 0h~1h 对储能进行放电, 然后储能一直处于闲置状态直到 14h 左右对储能开始充电, 然后在 18h 电价开始升高时储能进行放电。从数据结果可以看出 DDQN 算法得到的控制策略效果优于 DQN 算法得到的控制效果。




图 4.10 储能 SOC 与实时电价对照图

前面结果给出了储能控制策略的定性分析,图 11 和表 1 则给出定量的数据结果来说明 DDQN 算法训练得到的控制策略相比于传统控制方法和 DQN 算法更加优化。传统的基于光伏发电的 MPPT 控制,是简单的状态机控制方法,即判断微网中负荷和光伏的功率差的正负,在储能满足给定的 SOC 状态下,按照光伏最大功率追踪原理给出储能的充放电功率,具体算法流程见文献[183]。

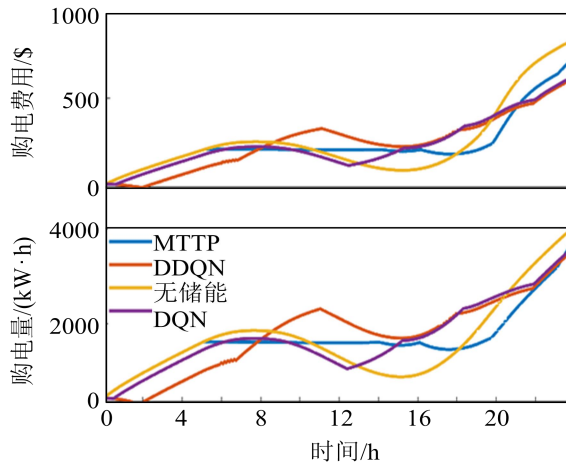


图 4.11 DDQN、DQN、MPPT、无储能 4 种情况对比结果

表 4.1 DDQN、DQN、MPPT、无储能 4 种情况数据结果

方法	购电量/(kW·h)	费用/\$
无储能	4344.6	840.1
MPPT	4003.6	735.7
DQN	3833.5	626.9
DDQN	3762.4	613.7

从图 4.11 和表格 4.1 的对比数据可以看出,相比于 MPPT 算法,强化学习算法训练得到控制策略更加节省购电费用,且在相同的训练周期下,DDQN 算法比 DQN 算法费用更低。相比于不加储能的微网运行,DDQN 算法将节省 26.95%的购电费用,远大于 MPPT 算法的 12.43%,这充分说明 DDQN 算法的有效性。

4.5 总结

本节在深度强化学习算法框架下,以 Simulink 搭建的仿真模型作为

环境向智能体提供状态信息，通过仿真模型与智能体的交互训练得到微网储能控制问题的优化策略。由于深度强化学习在处理无模型问题上的优势，本节研究不需要知道并网微网的控制目标、控制变量与状态信息之间的显示关系，而是通过训练由神经网络逼近的 Q 值函数来寻找控制目标与状态变量之间的作用关系，这对于处理由仿真环境提供状态数据的微网控制问题非常有效。第 4.4 节数值验证的结果表明本文求解思路的有效性。

由于篇幅有限，本节只讨论了一种应用实例，但是本文所提方法完全可以推广到多种微网能量控制场景中，比如在仿真模型中增删不同的分布式发电模块、改变不同的控制目标、设置不同的控制变量等等。在后续工作中，我们将从提高控制问题复杂性和提高深度强化学习的求解效率两方面入手。首先通过综合考虑多种控制目标、控制变量以及约束条件使得构建的控制问题更加符合实际生产运作需求，然后通过结合压缩感知算法来进一步提高强化学习在微网控制问题中的状态采集效率，进而加速训练过程，提高算法效率。

第五章 总结与展望

本研究报告主要针对能源互联网的相关应用场景从数值上提出了相应的解法。具体的，分为以下几点：

首先，针对能源互联网中的概率潮流问题，提出了压缩感知算法以及基于主成分分析的改进压缩感知算法在概率潮流求解上的应用，并且以 IEEE 30 节点和 IEEE118 节点为例进行仿真，验证了所提方法相比于传统方法的优势。

其次，介绍了能源互联网的另一类应用场景，即能源互联网中的控制问题。本报告针对两个不同的场景，分别建模，得到两类高维非线性随机优化控制问题。由于该类问题的复杂性，传统动态规划、蒙特卡洛、鲁棒控制等方法难以求解。因此，报告中提出将压缩感知算法与梯度法等循环优化算法相结合，用以此类问题，并且仿真结果充分说明了所提算法的有效性。

最后，在深度强化学习算法框架下，以 Simulink 搭建的仿真模型作为环境向智能体提供状态信息，通过仿真模型与智能体的交互训练得到微网储能控制问题的优化策略。本研究不需要知道并网微网的控制目标、控制变量与状态信息之间的显示关系，而是通过训练由神经网络逼近的 Q 值函数来寻找控制目标与状态变量之间的作用关系。

综上，本研究报告的主要内容是基于压缩感知和强化学习算法求解能源互联网相关问题。基于本报告内容，我们的未来研究重点为将压缩感知算法与强化学习算法相结合，来进一步提高求解效率，比如可以预先采用强化学习手段，训练得到一组新的基函数，使得压缩感知所要还原的状态量在这组基函数下的表达更加稀疏，进而提高还原效率。

参考文献

- [1] 王继业, 郭经红, 曹军威, 等. 能源互联网信息通信关键技术综述[J]. 智能电网, 2015(6): 473-485.
- [2] 曹军威, 杨明博, 张德华, 等. 能源互联网-信息与能源的基础设施一体化 [J]. 南方电网技术, 2014, 8(4): 1-10.
- [3] J. Rifkin. *The Third Industrial Revolution: How Lateral Power Is Transforming Energy, the Economy, and the World*, New York: Palgrave Macmillan, 2011.
- [4] 张国荣, 陈夏冉. 能源互联网未来发展综述[J]. 电力自动化设备, 2017 37(1): 1-7.
- [5] 田世明, 栾文鹏, 张东霞. 能源互联网技术形态与关键技术[J]. 中国电机工程学报, 2015, 35(14): 3482-3494.
- [6] 刘振亚. 全球能源互联网[M]. 北京: 中国电力出版社, 2015.
- [7] Y. Ma, X. Wang, X. Zhou and Z. Gao. An overview of energy routers, in *Proceedings of the 29th Chinese Control and Decision Conference*, Chongqing, China, 2017.
- [8] Y. Xu, J. H. Zhang and W. Y. Wang. Energy router: Architectures and functionalities toward energy internet, in *Proceedings of the 2011 IEEE International Conference on Smart Grid Communication*, Brussels, Belgium, 2011.
- [9] M. Geidl, G. Koepfel, P. Favre-Perrod, et al., Energy hubs for the future, *IEEE Power Energy Mag.*, vol. 5, p. 24–30, 2007.
- [10] J. Boyd. An internet-inspired electricity grid, *IEEE Spectr.*, vol. 50, p. 12–14, 2013.
- [11] A. Q. Huang, M. L. Crow, G. T. Heydt, et al., The Future Renewable Electric Energy Delivery and Management (FREEDM) System: The Energy Internet, *Proc. IEEE*, vol. 99, p. 133–148, 2010.
- [12] J. Miao, N. Zhang, C. Kang, et al., Steady-state power flow model of energyrouter embedded AC network and its application in optimizing power system operation, *IEEE Trans. Smart Grid*, vol. 9, no. 5, pp. 4828-4837, 2018.
- [13] M. Gao, K. Wang and L. He. Probabilistic model checking and scheduling implementation of energy router system in energy Internet for green cities, *IEEE Trans. Ind. Inform.*, vol. 14, no. 4, pp. 1501-1510, 2018.
- [14] 王锡凡. 现代电力系统分析[M]. 科学出版社, 2003.
- [15] Zhang B, Yan Z. *Advanced electric power network analysis*[M]. Cengage Learning Asia 2011.
- [16] 刘振亚, 智能电网技术[M]. 中国电力出版社, 2010.
- [17] 刘振亚, 张启平, 董存, 等. 通过特高压直流实现大型能源基地风, 光, 火电力大规模高效率安全外送研究[J]. 中国电机工程学报, 2014, 34(16): 2513-2522.
- [18] 张丽英, 叶廷路, 辛耀中. 大规模风电接入电网的相关问题及措施[J]. 中国电机工程学报, 2010, 30(25): 1-9.
- [19] B. Borkowska. Probabilistic load flow[J]. *IEEE Transactions on Power Apparatus and Systems*, 1974, 93(3): 752-759.
- [20] R. N. Allan, M.R.G. Al-Shakarchi. Probabilistic ac load flow[C]//*Proceedings of the*

-
- Institution of Electrical Engineers, IET Digital Library,1976,123(6): 531-536.
- [21] A.D. Silva, V.L. Arienti, R.N. Allan. Probabilistic load flow considering dependence between input nodal powers[J], IEEE Transactions on Power Apparatus and Systems, 1984, 6(PAS- 103): 1524-1530.
- [22] L.A. Sanabria, T.S. Dillon. Stochastic power flow using cumulants and Von Mises functions[J]. International Journal of Electrical Power & Energy Systems, 1986,8(1):47-60.
- [23] S.M.P. Ribeiro, V.L. Arienti, R.N. Allan, et al., Probabilistic load flow techniques applied to power system expansion planning[J]. Power Systems, IEEE Transactions on, 1990, 5(4): 1047-1053.
- [24] N. Nikmehr, S. Najafi Ravadanegh. Heuristic probabilistic power flow algorithm for microgrids operation and planning[J]. Generation, Transmission & Distribution, IET, 2015, 9(11): 985-995.
- [25] W. Li. Framework of probabilistic power system planning[J]. Power and Energy Systems, CSEE Journal of, 2015, 1(1): 1-8.
- [26] 张传成. 概率潮流在静态安全分析中的应用[D]. 北京: 华北电力大学, 2008.
- [27] 王永辉, 王克文, 刘畅, 等. 概率潮流在电力系统静态 N-1 校验中的应用[J]. 计算机仿真, 2013, 30(2): 125-129.
- [28] 刘怡芳, 张步涵, 李俊芳, 等. 考虑电网静态安全风险的随机潮流计算[J]. 中国电机工程学报, 2011, 31(1): 59-64.
- [29] 秦文萍, 任琛, 韩肖清, 等. 考虑负荷波动极限的电力系统电压稳定性风险评估[J]. 中国电机工程学报, 2015, 35(16): 4102-4111.
- [30] 任曦骏, 严正, 赵建伟, 等. 计及可控串联补偿器的系统电压失稳概率研究[J]. 水电能源科学, 2015, 33(8): 170-173.
- [31] 王锐, 顾伟, 孙蓉, 等. 基于概率最优潮流的风电接入能力分析[J]. 电网技术, 2011, 35(12): 214-220.
- [32] 刘宇, 高山, 杨胜春, 等. 电力系统概率潮流算法综述[J]. 电力系统自动化, 2014, 23: 022
- [33] P. Jorgensen, J.S. Christensen, I.O. Tande. Probabilistic load flow calculation using Monte Carlo techniques for distribution network with wind turbines[C]//Harmonics and Quality of Power Proceedings,1998. Proceedings.8th International Conference On.IEEE,1998.2:1146-1151.
- [34] 张祥文, 江星星, 王龙, 等. 配电网接纳电动汽车能力评估方法研究[J]. 电力系统保护与控制, 2015, 43(12): 14-20.
- [35] 张节潭, 王茂春, 徐有蕊, 等. 采用最小累积风险度法的含风电场电力系统发电机组检修计划[J]. 电网技术, 2011, 35(5): 97-102
- [36] J. Cao and M. Yang. Energy Internet-towards smart grid 2.0, in Proceedings of the Fourth International Conference on Networking & Distributed Computing, Los Angeles, USA, 2013.
- [37] H. Hua, Y. Qin, C. Hao and J. Cao. Stochastic optimal control for energy Internet: A bottom-up energy management approach, IEEE Trans. Ind. Inform., vol. 15, no. 3, pp. 1788-1797, 2019.
- [38] L. H. Tsoukalas and R. Gao. From smart grids to an energy Internet: assumptions,

-
- architectures and requirements, in Proceedings of the Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, Nanjing, China, 2008.
- [39] K. Han, F. Yang, C. Bai and et al., An open energy routing network for low-voltage distribution power grid, in Proceedings of the First IEEE International Conference on Energy Internet, Beijing, China, 2017.
- [40] W. Q. Zhang, X. Y. Zhang, S. W. Huang, et al., Evolution of a transmission network with high proportion of renewable energy in the future, *Renew. Energy*, vol. 102, pp. 372–379, 2016.
- [41] Y. Kuang, Y. Zhang, B. Zhou, et al., A review of renewable energy utilization in islands, *Renew. Sustain. Energy Rev.*, vol. 59, pp. 504–513, 2016.
- [42] L. P. Qian, Y. J. A. Zhang, J. Huang et al., Demand response management via real-time electricity price control in smart grids, *IEEE J. Sel. Areas Commun.*, vol. 31, pp. 1268–1280, 2013.
- [43] Y. Zhang, Z. Chen, Z. Cai and et al., New generation of cyber-energy system:energy internet, *Electr. Power Autom. Equip.*, vol. 36, no. 9, pp. 1-7, 2016.
- [44] C. Guo, Z. Wang, J. Ji et al., Model simulation of electricity characteristics in power user data based on data mining, *Comput. Simul.*, vol. 33, pp. 447–450, 2016.
- [45] S. Yu, Y. Sun, X. Niu et al., Energy Internet system based on distributed renewable energy generation, *Electr. Power Autom. Equip.*, vol. 30, pp. 104-108, 2010.
- [46] S. T. Shah, K. W. Choi, S. F. Hasan et al., Energy harvesting and information processing in two-way multiplicative relay networks, *Electron. Lett.*, vol. 52, pp. 751–753, 2016.
- [47] Z. Chen, Y. Zhang, Z. Cai, et al., Characteristics and technical challenges in energy Internet cyber-physical system, in Proceedings of the PES Innovative Smart Grid Technologies Conference Europe, Torino, Italy, 2017.
- [48] E.J. Candes, et al., Compressive sampling[C]//Proceedings of the international congress of mathematicians: volume 3. Madrid, Spain, 2006: 1433-1452.
- [49] E.J. Candes, J. Romberg, T. Tao. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. *arXiv preprint math/0409186*, 2004.
- [50] E.J. Candes, M.B. Wakin. An introduction to compressive sampling[J]. *IEEE signal processing magazine*, 2008, 25(2): 21-30.
- [51] A. Doostan, H. Owhadi. A non-adapted sparse approximation of PDEs with stochastic inputs[J], *Journal of Computational Physics*. 2011, 230(8); 3015-3034.
- [52] J. Hampton, A. Doostan. Compressive sampling of polynomial chaos expansions: Convergence analysis and sampling strategies[J]. *Journal of Computational Physics*, 2015, 280: 363-386.
- [53] 刘国静, 韩学山, 王尚, 等. 基于强化学习方法的风储合作决策[J]. *电网技术*, 2016, 40(9): 2729-2736.
- [54] Y. Tang, H. He, J. Wen, et al., Power system stability control for a wind farm based on adaptive dynamic programming[J]. *IEEE Transactions on Smart Grid*, 2015, 6(1): 166-177.
- [55] F. Ruelens, B. Claessens, S. Vandael, et al., Residential demand response of thermostatically controlled loads using batch Reinforcement Learning[J]. *IEEE*

-
- Transactions on Smart Grid, 2017, 8(5): 2149-2159.
- [56] E. Foruzan, L.K. Soh, S. Asgarpoor. Reinforcement Learning Approach for Optimal Distributed Energy Management in a Microgrid[J]. IEEE Transactions on Power Systems, 2018: 1-1.
- [57] V. Mnih, K. Kavukcuoglu, D. Silver, et al., Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529.
- [58] D. Silver, A. Huang, C.J. Maddison, et al., Mastering the game of Go with deep neural networks and tree search[J]. Nature, 2016, 529(7587): 484-489.
- [59] 唐振韬, 邵坤, 赵冬斌, 等. 深度强化学习进展: 从 AlphaGo 到 AlphaGo Zero[J]. 控制理论与应用, 2017, 34(12): 1529-1546.
- [60] 赵冬斌, 邵坤, 朱圆恒, 等. 深度强化学习综述: 兼论计算机围棋的发展[J]. 控制理论与应用, 2016, 33(6): 701-717.
- [61] 张自东, 邱才明, 张东霞, 等. 基于深度强化学习的微电网复合储能协调控制方法[J]. 电网技术, 2019, 43(6): 1914-1921.
- [62] V. Francoislavet, D. Taralla, D. Emst, et al., Deep Reinforcement learning solutions for energy microgrids management[C]//European Workshop on Reinforcement Learning (EWRL 2016).
- [63] H. Hua, Y. Qin, et al., Optimal energy management strategies for energy Internet via deep reinforcement learning approach[J]. Applied Energy, 2019(239): 598 -609.
- [64] B. Borkowska. Probabilistic load flow[J]. IEEE Transactions on Power Apparatus and Systems, 1974, 93(3): 752-759.
- [65] 徐青山, 黄煜, 刘建坤, 等. 采用混合高斯模型及边缘变换技术的蒙特卡洛随机潮流方法[J]. 电力系统自动化, 2016, 40(16): 23-30.
- [66] X. Xu, Z. Yan. Probabilistic load flow calculation with quasi-Monte Carlo and multiple linear regression[J]. International Journal of Electrical Power & Energy Systems, 2017, 88: 1-12.
- [67] 刘俊, 郝旭东, 程佩芬, 等. 结合 M-Copula 理论与半不变量的随机潮流方法[J]. 电网技术, 2018, 42(2): 578-584.
- [68] Y. Che, X. Wang, X. Lv, et al., Probabilistic load flow using improved three point estimate method[J]. International Journal of Electrical Power & Energy Systems, 2020, 117: 105618.
- [69] D. Xiu, G.E. Karniadakis. The wiener-asky polynomial chaos for stochastic differential equations[J]. SIAM Journal on Scientific Computing, 2002, 24(2): 619-644.
- [70] D. Xiu. Numerical methods for stochastic computations: A spectral method approach[M]. Princeton: Princeton University Press, 2010.
- [71] J. Laowanitwattana, S. Uatrongjit, Probabilistic power flow analysis based on arbitrary polynomial chaos expansion for networks with uncertain renewable sources, IEEE Transactions on Electrical and Electronic Engineering, vol.13(12), 2018, pp. 1754-1759.
- [72] Y. Sun, R. Mao, Z. Li, et. al., Constant jacobian matrix-based stochastic galerkin method for probabilistic load flow[J]. Energies, 2016, 9((3): 153.
- [73] 孙英云, 毛瑞, 董雷, 等. 基于随机配置点法的概率潮流算法[J]. 电力系统自

-
- 动化, 2015, 39(23): 111-118.
- [74] P.R. Conrad, Y.M. Marzouk. Adaptive smolyak pseudo spectral approximations[J]. *SIAM Journal on Scientific Computing*, 2013, 35(6): A2643-A2670.
- [75] 林济铿, 申丹枫, 陶向红, 等. 基于自适应稀疏伪谱逼近新方法的随机状态估计: 模型及算法[J]. *中国电机工程学报*, 2019, 39(1): 192-203.
- [76] 何琨, 徐潇源, 严正, 等. 基于稀疏多项式混沌展开的孤岛微电网概率潮流计算[J]. *电力系统自动化*, 2019, 43(002): 67-75.
- [77] 杨欢, 邹斌. 含相关性随机变量的概率潮流三点估计法[J]. *电力系统自动化*, 2012, 36(15): 51-56.
- [78] M. Aien, M.G. Khajeh, M. Rashidinejad, et. al., Probabilistic power flow of correlated hybrid wind-photovoltaic power systems[J]. *IET Renewable Power Generation*, 2014, 8(6): 649-658.
- [79] H.R. Baghaee, M. Mirsalim, G.B. Gharehpetian, et. al., Application of RBF neural networks and unscented transformation in probabilistic power-flow of microgrids including correlated wind/PV units and plug-in hybrid electric vehicles[J]. *Simulation Modelling Practice and Theory*, 2017, 72: 51-68.
- [80] X. Li, D. Du, J. Pei, et. al. Probabilistic load flow calculation with Latin hypercube sampling applied to grid-connected induction wind power system[J]. *Transactions of the Institute of Measurement and Control*, 2013, 35(1): 56-65.
- [81] X. Lin, Y. Jiang, S. Peng, et. al., An efficient Nataf transformation based probabilistic power flow for high-dimensional correlated uncertainty sources in operation[J]. *International Journal of Electrical Power & Energy Systems*, 2020, 116: 105543.
- [82] J. Laowanitwattana, S. Uatrongjit. Probabilistic power flow analysis based on arbitrary polynomial chaos expansion for networks with uncertain renewable sources[J]. *IEEE Transactions on Electrical and Electronic Engineering*, 2018, 13(12): 1754-1759.
- [83] E. C. Marques, N. Maciel, L. Naviner, et.al., A review of sparse recovery algorithms, *IEEE access*, vol. 7, 2018, pp. 1300-1322.
- [84] J. A. Tropp, A. C. Gilbert, Signal recovery from random measurements via orthogonal matching pursuit, *IEEE Transactions on information theory*, vol. 53(12), 2007 pp. 4655-4666.
- [85] T. Kulworawanichpong. Simplified Newton - Raphson power-flflow solution method, *International journal of electrical power & energy systems*, vol. 32(6), 2010, pp. 551-558.
- [86] E.J. Candès, J.K. Romberg, T. Tao. Stable signal recovery from incomplete and inaccurate measurements[J]. *Communications on pure and applied mathematics*, 2006, 59(8): 1207-1223.
- [87] 别朝红, 李更丰, 王锡凡. 含微网的新型配电系统可靠性评估综述[J]. *电力自动化设备*, 2011, 31(1): 1-6.
- [88] 陈洁, 杨秀, 朱兰, 等. 微网多目标经济调度优化[J]. *中国电机工程学报*, 2013(19): 57-66.
- [89] 吴卫民, 何远彬, 耿攀, 等. 直流微网研究中的关键技术[J]. *电工技术学报*, 2012(1): 98-106.

-
- [90] 李武华, 顾云杰, 王宇翔, 等. 新能源直流微网的控制架构与层次划分[J]. 电力系统自动化, 2015, 39(9): 156-163.
- [91] 王晶, 李瑞环, 束洪春. 基于智能多代理的能量协调控制在直流微网中的应用[J]. 电力自动化设备, 2013, 33(7): 132-138.
- [92] 杨秀, 陈洁, 朱兰, 等. 基于经济调度的微网储能优化配置[J]. 电力系统保护与控制, 2013(1): 53-60.
- [93] 刘家赢, 韩肖清, 王磊, 等. 直流微电网运行控制策略[J]. 电网技术, 2014(9): 2356-2362.
- [94] 陈昌松, 段善旭, 蔡涛, 等. 基于改进遗传算法的微网能量管理模型[J]. 电工技术学报, 2013, 28(4):196-201.
- [95] 江渝, 黄敏, 毛安, 等. 孤立微网的多目标能量管理[J]. 高电压技术, 2014, 40(11): 3519-3527.
- [96] 李蓓, 郭剑波. 平抑风电功率的电池储能系统控制策略[J]. 电网技术, 2012, 61(8): 38-43.
- [97] 孟润泉, 刘家赢, 文波, 等. 直流微网混合储能控制及系统分层协调控制策略[J]. 高电压技术, 2015, 41(7): 2186-2193.
- [98] 李逢兵, 谢开贵, 张雪松, 等. 基于锂电池充放电状态的混合储能系统控制策略设计[J]. 电力系统自动化, 2013, 37(1): 70-75.
- [99] L. C. Evans. An introduction to stochastic differential equations, volume 82[M]. American Mathematical Soc, 2012.
- [100] D. Xiu, G.E. Karniadakis. The Wiener-Askey polynomial chaos for stochastic differential equations[J]. SIAM Journal on Scientific Computing, 2002,24(2): 619-644.
- [101] R.H. Cameron, W.T. Martin. The orthogonal development of non-linear functionals in series of Fourier-Hermite functionals[J]. Annals of Mathematics, 1947: 385-392.
- [102] X. Yuan, P. Llull, X. Liao, et al., Low-cost compressive sensing for color video and depth[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2014: 3318-3325.
- [103] D. Friboulet, H. Liebgott, R. Prost. Compressive sensing for raw RF signals reconstruction in ultrasound[C]//2010 IEEE International Ultrasonics Symposium. IEEE, 2010: 367-370.
- [104] J. Romberg. Compressive sensing by random convolution[J]. SIAM Journal on Imaging Sciences 2009,2(4): 1098-1128.
- [105] I. Babuska, F. Nobile, R. Tempone. A stochastic collocation method for elliptic partial differential equations with random input data[J]. SIAM Journal on Numerical Analysis, 2007, 45(3): 1005-1034.
- [106] R.G. Ghanem, P.D. Spanos. Stochastic finite elements:a spectral approach[M]. Courier Corporation, 2003.
- [107] S. Becker, J. Bobin, E.J. Candes. NESTA:a fast and accurate first-order method for sparse recovery[J]. SIAM Journal on Imaging Sciences,2011, 4(1): 1-39.
- [108] R. G. Baraniuk. Compressive sensing[J]. IEEE signal processing magazine, 2007,24(4).
- [109] R. Baraniuk, M. Davenport, R. DeVore, et. al., A simple proof of the restricted

-
- isometry property for random matrices[J]. *Constructive Approximation*, 2008, 28(3): 253-263.
- [110] H. Rauhut, R. Ward. Sparse Legendre expansions via ℓ_1 -minimization[J]. *Journal of Approximation Theory*, 2012, 164(5): 517-533.
- [111] E. Van Den Berg, M.P. Friedlander. Probing the Pareto frontier for basis pursuit solutions[J]. *SIAM Journal on Scientific Computing*, 2008, 31(2): 890-912.
- [112] H. Qiu, X. Chen, W. Liu, et. al., A fast ℓ_1 -solver and its applications to robust face recognition[J] *Journal of Industrial and Management Optimization*, 2012, 8:163-178.
- [113] L. Yan, L. Guo, D. Xiu. Stochastic collocation algorithms using ℓ_1 -minimization [J]. *International Journal for Uncertainty Quantification*, 2012, 2(3).
- [114] J. Peng, J. Hampton, A. Doostan. A weighted ℓ_1 -minimization approach for sparse polynomial chaos expansions[J]. *Journal of Computational Physics*, 2014. 267: 92-111.
- [115] J.D. Jakeman, M.S. Eldred, K. Sargsyan. Enhancing ℓ_1 -minimization estimates of polynomial chaos expansions using basis selection[J]. *Journal of Computational Physics*, 2015, 289: 18-34.
- [116] C. C. Remsing. Optimal control and Hamilton-Poisson formalism. *Int. J. Pure Appl. Math*, vol. 59, no. 1, pp. 11-17, 2010.
- [117] J. Cao, H. Hua, and G. Ren. Energy use and the Internet. *The SAGE Encyclopedia of the Internet*. Newbury Park, CA, USA, pp. 344-350, 2018.
- [118] A. Q. Huang, M. L. Crow, G. T. Heydt, et. al., The future renewable electric energy delivery and management (FREEDM) system: The energy Internet, *Proc. IEEE*, vol. 99, no. 1, pp. 133-148, Nov. 2010.
- [119] K. Wang, X. Hu, H. Li, et.al., A survey on energy internet communications for sustainability, *IEEE Trans. Sust. Comput.*, vol. 2, no. 3, pp.231-254, 2017.
- [120] J. Miao, N. Zhang, C. Kang, et al., Steady-state power flow model of energy router embedded AC network and its application in optimizing power system operation, *IEEE Trans. Smart Grid*, vol. 9, no. 5, pp. 4828-4837, Sept. 2018.
- [121] X. She, X. Yu, F. Wang, A. Q. Huang. Design and demonstration of a 3.6-kV-120-V/10-kVA solid-state transformer for smart grid application, *IEEE Trans. Power Electron.*, vol. 29, no. 8, pp. 3982-3996, Aug. 2014.
- [122] S. Hambridge, A. Q. Huang, and R. Yu. Solid state transformer (SST) as an energy router: Economic dispatch based energy routing strategy, in *Proc. 2015 IEEE Energy Convers. Congress and Exposition*, Montreal, QC, Canada, pp. 2355-2360, Sept. 2015.
- [123] X. Han et al., An open energy routing network for low-voltage distribution power grid, in *Proc. 1st IEEE Int. Conf. on Energy Internet*, Beijing, China, pp. 320-325, Apr. 2017.
- [124] H. Hua, Y. Qin, H. Xu, C. Hao, and J. Cao. Robust control method for DC microgrids and energy routers to improve voltage stability in energy Internet, *Energies*, vol. 12, Art. no. 1622, 2019.
- [125] B. Luo, D. Liu, T. Huang and J. Liu. Output tracking control based on adaptive dynamic programming with multistep policy evaluation, *IEEE Trans. Systems, Man, and Cybernetics: Systems*, vol. 49, no. 10, 2017.
- [126] P. Yi, T. Zhu, B. Jiang, R. Jin, and B. Wang. Deploying energy routers in an energy

-
- Internet based on electric vehicles, *IEEE Trans. Vehicular Technology*, vol. 65, no. 6, pp. 4714-4725, Jun. 2016.
- [127] M. Gao, K. Wang, and L. He. Probabilistic model checking and scheduling implementation of an energy router system in energy Internet for green cities, *IEEE Trans. Ind. Inform.*, vol. 14, no. 4, pp. 1501-1510, Apr. 2018.
- [128] H. Hua, Y. Qin, C. Hao, and J. Cao. Optimal energy management strategies for energy Internet via deep reinforcement learning approach, *Appl. Energy*, vol. 239, pp. 598-609, Apr. 2019.
- [129] W. Zhong, R. Yu, S. Xie, Y. Zhang, and D. H. K. Tsang. Software defined networking for flexible and green energy Internet, *IEEE Communications Magazine*, vol. 54, no. 12, pp. 68-75, Dec. 2016.
- [130] Y. Qin, H. Hua, and J. Cao. Short-term energy cache regulation for energy router: A robust H-infinity approach, in *Proc. 3rd IEEE International Conference on Energy Internet*, Nanjing, China, pp. 161- 166, May 2019.
- [131] R. Hemmati, H. Saboori, and M. A. Jirdehi. Stochastic planning and scheduling of energy storage systems for congestion management in electric power systems including renewable energy resources, *Energy*, vol. 133, pp. 380-387, 2017.
- [132] H. Bevrani, M. R. Feizi, and S. Ataei. Robust frequency control in an islanded microgrid: H_∞ and μ -synthesis approaches, *IEEE Trans. Smart Grid*, vol. 7, no. 2, pp. 706-717, Mar. 2016.
- [133] B.V. Mathiesen, H. Lund, D. Connolly, et al., Smart Energy Systems for coherent 100% renewable energy and transport solutions, *Applied Energy*, vol. 145, pp. 139-154, 2015.
- [134] Monthly Deployment of all Solar Photovoltaic Capacity in the United Kingdom (Department of Energy and Climate Change); <http://go.nature.com/8RYnfb>.
- [135] Y. Parag and B. Sovacool. Electricity market design for the prosumer era, *Nat Energy* 1, 16032, 2016.
- [136] J. Rifkin, *The third industrial revolution: how lateral power is transforming energy, the economy, and the world*, New York (US): Palgrave Macmillan; pp. 31–46, 2013.
- [137] K. Zhou, S. Yang, Z. Shao. Energy internet: the business perspective[J]. *Applied Energy*, 2016, 178: 212-222.
- [138] H. Hua, Y. Qin, Z. He, L. Li and J. Cao. Energy sharing and frequency regulation in energy Internet via mixed H_2/H_∞ control with Markovian jump,” *CSEE Journal of Power and Energy Systems*, DOI: 10.17775/CSEEJPES.2019.01900.
- [139] H. Hua, C. Hao, and Y. Qin. Internet thinking for layered energy infrastructure, in: A. Zobaa, J. Cao (eds), *Energy Internet: Systems and Applications*, Springer Nature Switzerland AG, 2020, pp. 421-437.
- [140] N. Balta-Ozkan, B. Boteler, and O. Amerighi. European smart home market development: Public views on technical and economic aspects across the United Kingdom, Germany and Italy, *Energy Research & Social Science*, vol. 3, pp. 65-77, 2014.
- [141] T. M. Skjolsvold, M. Ryghaug, and T. Berker. A traveler’s guide to smart grids and the social sciences, *Energy & Social Science*, vol. 9, pp. 1-8, 2015.
- [142] K. Jones, D. Zoppo, and A. Smarter. *Greener Grid: Forging Environmental Progress through Smart Energy Policies and Technologies*, Praegar, 2014.

-
- [143] A. Saad al-sumaiti, M. H. Ahmed, and M. M. A. Salama. Smart home activities: a literature review, *Electr. Pow. Compo. Sys.*, vol. 42, pp. 294–305, 2014.
- [144] W. Lee, L. Xiang, R. Schober and V. W. S. Wong. Direct Electricity Trading in Smart Grid: A Coalitional Game Analysis, *IEEE J. Sel. Area Comm.*, vol. 32, no. 7, pp. 1398-1411, Jul. 2014.
- [145] Y. Lu, S. Wang, Y. Sun, et al., Optimal scheduling of buildings with energy generation and thermal energy storage under dynamic electricity pricing using mixed-integer nonlinear programming, *Applied Energy*, vol. 147, pp. 49-58, 2015.
- [146] L. Jian, H. Xue, G. Xu, et. al., Regulated Charging of Plug-in Hybrid Electric Vehicles for Minimizing Load Variance in Household Smart Microgrid,” *IEEE Transactions on Industrial Electronics*, vol. 60, no. 8, pp. 3218-3226, Aug. 2013.
- [147] Z. Wang, C. Gu, F. Li, P. Bale and H. Sun. Active Demand Response Using Shared Energy Storage for Household Energy Management, *IEEE Transactions on Smart Grid*, vol. 4, no. 4, pp. 1888-1897, Dec. 2013.
- [148] R. Herzallah, Probabilistic DHP adaptive critic for nonlinear stochastic control systems, *Neural Networks*, vol. 42, pp. 74-82, 2013.
- [149] N. Nasim, Y. Wang. Real-time electricity pricing for industrial customers: Survey and case studies in the United States, *Applied Energy*, vol. 195, pp. 1023-1037, 2017.
- [150] Y. Zhang, C. Li, L. Li. Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods, *Applied Energy*, vol. 190, pp 291-305, 2017.
- [151] Y. Xu, J. Zhang, W. Wang, et. al., Energy router: Architectures and functionalities toward Energy Internet, 2011 IEEE International Conference on Smart Grid Communications (SmartGridComm), Brussels, pp. 31-36, 2011.
- [152] Y. Qin, H. Hua, and J. Cao. Short-term energy cache regulation for energy router: A robust H-infinity approach, in *Proc. 3rd IEEE International Conference on Energy Internet*, Nanjing, China, pp. 161- 166, May 2019.
- [153] L. Yuan, S. Wei, J. Ge, Z. Zhao and R. Huang. Design and implementation of AC-DC hybrid multi-port energy router for power distribution networks, in 2015 18th International Conference on Electrical Machines and Systems (ICEMS), Pattaya, pp. 591-596, 2015.
- [154] R. Herzallah and D. Lowe. Multi-valued control problems and mixture density network, in *IFAC International Conference on Intelligent Control Systems and Signal Processing*, Faro, Portugal, pp. 387-392, Apr. 2003.
- [155] R. Herzallah and D. Lowe. A novel approach to modeling and exploiting uncertainty in stochastic control systems, *International Conference on Artificial Neural Networks*, Madrid, Spain, pp. 801- 806, August 2002.
- [156] M. Gao, K. Wang and L. He. Probabilistic Model Checking and Scheduling Implementation of an Energy Router System in Energy Internet for Green Cities, *IEEE Transactions on Industrial Informatics*, vol. 14, no. 4, pp. 1501-1510, Apr. 2018.
- [157] M. A. Rafael, L. Li, D. Mitchell, and Z. Mo. Modelling Electricity Prices: A Time Change Approach, *Quantitative Finance*, vol.16, 2015.
- [158] H. Hua, J. Cao, G. Yang, and G. Ren. Voltage Control for Uncertain Stochastic Nonlinear System with Application to Energy Internet: Non-fragile Robust H_∞

-
- Approach, *Journal of Mathematical Analysis and Applications*, vol. 463, no, 1, pp. 93-110, 2018.
- [159] S. Borovkova and M. D. Schmeck. Electricity price modeling with stochastic time change, *Energy Economics*, vol. 63, pp. 51-65, 2017.
- [160] P. Chalasani, and S. Jha. Steven Shreve: *Stochastic Calculus and Finance*, Lecture Notes, October 1997.
- [161] S. Boyd, and L. Vandenberghe. *Interior-point methods, Convex optimization*, Cambridge university press, 2004.
- [162] 杨新法, 苏剑, 吕志鹏, 等. 微电网技术综述[J]. *中国电机工程学报*, 2014, 34(1): 57-70.
- [163] 李霞林, 郭力, 王成山, 等. 直流微电网关键技术研究综述[J]. *中国电机工程学报*, 2016, 36(1): 2-16.
- [164] A. OLama, P.R.C. Mendes, E.F. Camacho. Lyapunov-based hybrid model predictive control for energy management of microgrids[J]. *IET Generation, Transmission & Distribution*, 2018, 12(21): 5770-5780.
- [165] W. Shi, N. Li, C. Chu, et. al., Real-time energy management in microgrids[J]. *IEEE Transactions on Smart Grid*, 2017, 8(1): 228-238.
- [166] 马天祥, 贾伯岩, 张智远, 等. 基于二层规划的能源互联微电网能量优化调度方法[J]. *电力系统自动化*, 2019, 43(16): 34-43.
- [167] V. S. Tabar, M.A. Jirdehi, R. Hemmati. Energy management in microgrid based on the multi objective stochastic programming incorporating portable renewable energy resource as demand response option[J]. *Energy*, 2017, 118: 827-83.
- [168] 张少明, 盛四清. 基于改进粒子群算法的微网优化运行[J]. *中国电力*, 2020, 53(5): 24-31.
- [169] 禹威威, 刘世林, 陈其工, 等. 考虑电动汽车充电和需求侧响应的光伏微电网多目标优化调度[J]. *电力系统及其自动化学报*, 2018, 30(1): 88-97.
- [170] 周楠, 樊玮, 刘念, 等. 基于需求响应的光伏微网储能系统多目标容量优化配置[J]. *电网技术*, 2016, 40(6): 1711-1718.
- [171] T.T. Nguyen, N.D. Nguyen, S. Nahavandi. Deep reinforcement learning for multiagent systems: a review of challenges, solutions, and applications[J]. *IEEE Transactions on Cybernetics*, 2020, 50(9): 3826-3839.
- [172] 万里鹏, 兰旭光, 张翰博, 等. 深度强化学习理论及其应用综述[J]. *模式识别与人工智能*, 2019, 32(1): 67-81.
- [173] N. C. Luong, D.T. Hoang, S. Gong, et. al., Applications of deep reinforcement learning in communications and networking: a survey[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(4): 3133-3174.
- [174] 刘俊峰, 陈剑龙, 王晓生, 等. 基于深度强化学习的微能源网能量管理与优化策略研究[J]. *电网技术*, 2020, 44(10): 3794-3803.
- [175] P. Zeng, H. Li, H. He, et. al., Dynamic energy management of a microgrid using approximate dynamic programming and deep recurrent neural network learning[J]. *IEEE Transactions on Smart Grid*, 2019, 10(4): 4435-4445.
- [176] 刘威, 张东霞, 王新迎, 等. 基于深度强化学习的电网紧急控制策略研究[J]. 中

-
- 国电机工程学报, 2018, 38(1): 109-119.
- [177] Y. Du, F. Li. Intelligent multi-microgrid energy management based on deep neural network and model-free reinforcement learning[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1066-1076.
- [178] E. Mocanu, D.C. Mocanu, P.H. Nguyen, et. al., On-line building energy optimization using deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 3698-3708.
- [179] 吕志鹏, 罗安, 荣飞, 等. 电网电压不平衡条件下微网 PQ 控制策略研究[J]. 电力电子技术, 2010, 44(6): 71-74.
- [180] R.S. Sutton, A.G. Barto Reinforcement learning: an introduction[M]. 2nd ed. Cambridge: MIT Press, 2018.
- [181] 刘建伟, 高峰, 罗雄麟. 基于值函数和策略梯度的深度强化学习综述[J]. 计算机学报, 2019, 42(6): 1406-1438.
- [182] V. Hasselt, Hado, A. Guez, D. Silver. Deep reinforcement learning with double q-learning[C]. Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 30. No. 1. 2016.
- [183] X. Liu, P. Wang, P.C. Loh . A hybrid AC/DC microgrid and its coordination control[J]. IEEE Transactions on Smart Grid, 2011, 2(2): 278-286.

致 谢

两年的博士后生涯转瞬即逝，这段时光虽然短暂，但却弥足珍贵。在合作导师曹军威老师和吉吟东老师的精心指导下，本人得以顺利完成博后工作，不论在工作中，还是在生活中，他们的言传身教都将使我终生受益。

同时要感谢曹老师实验组里面的所有同事们。感谢大家在工作上给我提供了宝贵的意见，尤其要感谢华昊辰博士在工作中对我的指导，使我快速地投入到博后这两年所从事的领域中。也感谢大家在生活上对我的照顾，一起相处的时光虽然短暂，却留下了很多美好的回忆。同时要感谢信研院的行政老师阚淑文老师和自动化系的行政老师们，耐心的帮助我办理各种手续。

还要感谢我的家人，感谢你们的支持和鼓励，你们永远是我前行的最大动力。

最后，真诚地感谢各位专家在百忙之中对我出站报告的审阅和指正。

附录 1: 118 节点仿真算例数值结果

表 1 系统信息

System Summary						
How many?		How much?		P (MW)	Q (MVar)	
Buses	118	Total Gen Capacity	9966.2	-7345.0 to 11777.0		
Generators	54	On-line Capacity	9966.2	-7345.0 to 11777.0		
Committed Gens	54	Generation (actual)	3836.5	651.5		
Loads	99	Load	3709.8	1345.8		
Fixed	99	Fixed	3709.8	1345.8		
Dispatchable	0	Dispatchable	-0.0 of -0.0	-0.0		
Shunts	14	Shunt (inj)	-0.0	84.3		
Branches	186	Losses ($I^2 * Z$)	126.69	731.89		
Transformers	11	Branch Charging (inj)	-	1342.0		
Inter-ties	0	Total Inter-tie Flow	0.0	0.0		
Areas	1					
		Minimum		Maximum		
Voltage Magnitude	0.943 p.u. @ bus 76			1.050 p.u. @ bus 25		
Voltage Angle	21.45 deg @ bus 41			57.59 deg @ bus 10		
P Losses ($I^2 * R$)	-			5.80 MW @ line 23-25		
Q Losses ($I^2 * X$)	-			59.22 MVar @ line 9-10		

表 2 节点数据

Bus Data								
#	Bus		Voltage		Generation		Load	
	Mag(pu)	Ang(deg)	P (MW)	Q (MVar)	P (MW)	Q (MVar)	P (MW)	Q (MVar)
1	0.955	34.884	0.00	-10.02	51.00	27.00		
2	0.967	34.745	-	-	39.68	13.04		
3	0.973	35.995	-	-	3.21	2.26		
4	0.998	38.632	0.00	-22.19	39.00	12.00		
5	1.002	38.999	-	-	-	-		
6	0.990	37.320	0.00	-13.11	2.11	1.02		

7	0.988	36.654	-	-	23.72	7.79
8	1.015	42.760	0.00	54.10	28.00	0.00
9	1.043	50.014	-	-	-	-
10	1.050	57.595	450.00	-51.04	-	-
11	0.990	36.687	-	-	4.33	3.93
12	0.990	36.000	85.00	74.83	47.00	10.00
13	0.972	34.795	-	-	34.00	16.00
14	0.983	34.721	-	-	14.00	1.00
15	0.970	32.842	0.00	-44.18	4.75	2.30
16	0.984	34.688	-	-	25.00	10.00
17	0.994	34.325	-	-	11.00	3.00
18	0.973	32.103	0.00	29.93	60.00	34.00
19	0.962	31.641	0.00	-12.91	45.00	25.00
20	0.958	31.651	-	-	18.00	3.00
21	0.960	32.603	-	-	14.00	8.00
22	0.971	34.436	-	-	10.00	5.00
23	0.999	38.224	-	-	7.07	6.08
24	0.992	35.707	0.00	2.82	13.00	0.00
25	1.050	46.554	220.00	48.59	-	-
26	1.015	48.587	314.00	9.46	-	-
27	0.968	35.722	0.00	-7.88	48.62	15.98
28	0.962	33.930	-	-	17.00	7.00
29	0.963	32.863	-	-	24.00	4.00
30	0.985	38.294	-	-	-	-
31	0.967	32.953	7.00	32.96	43.00	27.00
32	0.963	34.695	0.00	-25.90	59.00	23.00
33	0.970	29.571	-	-	23.00	9.00
34	0.984	27.312	0.00	-18.44	59.00	26.00
35	0.980	26.842	-	-	33.00	9.00
36	0.980	26.846	0.00	7.80	31.00	17.00
37	0.991	27.736	-	-	-	-
38	0.963	32.408	-	-	-	-
39	0.970	23.794	-	-	27.00	11.00
40	0.970	22.392	0.00	48.24	66.00	23.00
41	0.958	21.455	-	-	69.68	22.90

42	0.985	24.100	0.00	-7.55	3.39	1.64
43	0.978	24.984	-	-	18.00	7.00
44	0.988	24.144	-	-	16.00	8.00
45	0.989	24.760	-	-	53.00	22.00
46	1.005	26.513	19.00	-9.60	28.00	10.00
47	1.019	27.688	-	-	34.00	0.00
48	1.021	27.956	-	-	20.00	11.00
49	1.025	28.959	204.00	89.69	87.00	30.00
50	1.005	27.268	-	-	2.84	1.63
51	0.959	23.618	-	-	17.00	8.00
52	0.951	22.709	-	-	18.00	5.00
53	0.943	21.904	-	-	23.00	11.00
54	0.955	22.955	48.00	6.56	113.00	32.00
55	0.952	22.666	0.00	4.61	63.00	22.00
56	0.954	22.828	0.00	8.76	84.00	18.00
57	0.972	24.340	-	-	12.00	3.00
58	0.946	22.393	-	-	37.84	12.44
59	0.985	27.394	155.00	76.33	277.00	113.00
60	0.995	32.055	-	-	3.40	1.65
61	0.995	32.549	160.00	-47.49	-	-
62	0.998	31.902	0.00	-2.59	77.00	14.00
63	0.969	30.640	-	-	-	-
64	0.985	32.331	-	-	-	-
65	1.005	34.563	391.00	65.28	-	-
66	1.050	35.032	392.00	1.90	39.00	18.00
67	1.020	32.810	-	-	28.00	7.00
68	1.003	32.354	-	-	-	-
69	1.035	30.000*	-24.46	-21.11	-	-
70	0.984	27.629	0.00	-6.44	66.00	20.00
71	0.987	28.036	-	-	-	-
72	0.980	31.110	0.00	-8.75	12.00	0.00
73	0.991	27.823	0.00	9.91	6.00	0.00
74	0.958	26.238	0.00	-17.24	68.00	27.00
75	0.972	27.268	-	-	7.52	4.15
76	0.943	26.354	0.00	0.87	68.00	36.00

77	1.006	31.479	0.00	16.65	61.00	28.00
78	1.003	31.258	-	-	71.00	26.00
79	1.009	31.715	-	-	39.00	32.00
80	1.040	34.403	477.00	110.85	130.00	26.00
81	0.997	33.148	-	-	-	-
82	0.986	34.147	-	-	54.00	27.00
83	0.981	36.129	-	-	20.00	10.00
84	0.978	39.929	-	-	11.00	7.00
85	0.985	42.091	0.00	-8.21	24.00	15.00
86	0.987	40.721	-	-	21.00	10.00
87	1.015	40.981	4.00	11.02	-	-
88	0.994	46.777	-	-	4.61	1.85
89	1.005	50.174	607.00	-14.09	-	-
90	0.985	43.726	0.00	59.37	163.00	42.00
91	0.980	43.689	0.00	-13.10	10.00	0.00
92	0.990	44.144	0.00	-26.97	6.45	3.13
93	0.986	40.121	-	-	5.86	2.82
94	0.988	36.884	-	-	30.00	16.00
95	0.978	35.417	-	-	42.00	31.00
96	0.990	34.630	-	-	38.00	15.00
97	1.010	34.168	-	-	15.00	9.00
98	1.024	34.048	-	-	27.64	9.09
99	1.010	34.323	0.00	-17.42	42.00	0.00
100	1.017	36.060	252.00	102.96	37.00	18.00
101	0.990	38.593	-	-	22.00	15.00
102	0.987	42.182	-	-	5.87	5.03
103	1.010	32.319	40.00	75.42	23.00	16.00
104	0.971	29.749	0.00	2.39	38.00	25.00
105	0.965	28.645	0.00	-18.33	31.00	26.00
106	0.961	28.385	-	-	43.00	16.00
107	0.952	25.584	0.00	6.56	50.00	12.00
108	0.966	27.445	-	-	2.00	1.00
109	0.967	26.992	-	-	8.00	3.00
110	0.973	26.145	0.00	0.28	39.00	30.00
111	0.980	27.790	36.00	-1.84	-	-

112	0.975	23.046	0.00	41.51	68.00	13.00
113	0.993	34.224	0.00	9.25	6.00	0.00
114	0.964	34.954	-	-	8.00	3.00
115	0.964	35.047	-	-	0.23	0.11
116	1.005	31.915	0.00	68.98	184.00	0.00
117	0.974	34.459	-	-	20.00	8.00
118	0.952	26.384	-	-	33.00	15.00
Total:			3836.54	651.47	3709.85	1345.85

表 3 线路数据

Branch Data									
Branch #	From Bus	To Bus	From Bus P (MW)	Injection Q (MVar)	To Bus P (MW)	Injection Q (MVar)	Loss ($I^2 * Z$)		
							P (MW)	Q (MVar)	
1	1	2	-1.23	-12.62	1.28	10.41	0.044	0.15	
2	1	3	-49.77	-24.40	50.20	24.82	0.431	1.42	
3	4	5	-87.11	-31.26	87.26	31.73	0.151	0.69	
4	3	5	-50.42	-15.44	51.12	15.80	0.698	3.13	
5	5	6	56.20	10.04	-55.81	-9.70	0.388	1.76	
6	6	7	53.70	-4.44	-53.57	4.51	0.136	0.62	
7	8	9	-440.64	-89.73	445.25	24.43	4.620	57.75	
8	8	5	253.67	117.97	-253.67	-98.29	0.000	19.68	
9	9	10	-445.25	-24.43	450.00	-51.04	4.745	59.22	
10	4	11	48.11	-2.93	-47.62	2.80	0.487	1.60	
11	5	11	59.09	0.55	-58.38	0.10	0.706	2.37	
12	11	12	54.86	-16.97	-54.66	17.14	0.200	0.66	
13	2	12	-40.95	-23.45	41.39	23.39	0.438	1.44	
14	3	12	-2.99	-11.64	3.04	7.90	0.053	0.17	
15	7	12	29.85	-12.31	-29.76	11.81	0.091	0.36	
16	11	13	46.81	10.14	-46.29	-10.22	0.525	1.73	
17	12	14	30.83	-0.59	-30.62	-0.49	0.209	0.69	
18	13	15	12.29	-5.78	-12.16	0.28	0.125	0.41	
19	14	15	16.62	-0.51	-16.45	-3.71	0.172	0.56	
20	12	16	27.01	-0.02	-26.85	-1.44	0.158	0.62	
21	15	17	-67.08	-35.05	67.86	33.36	0.784	2.59	

22	16	17	1.85	-8.56	-1.83	4.08	0.020	0.08
23	17	18	80.11	23.25	-79.24	-20.94	0.869	3.57
24	18	19	19.24	16.86	-19.16	-17.58	0.080	0.35
25	19	20	0.49	1.53	-0.49	-4.27	0.002	0.01
26	15	19	51.05	4.19	-50.72	-4.03	0.335	1.10
27	20	21	-17.51	1.27	17.58	-2.97	0.062	0.29
28	21	22	-31.58	-5.03	31.81	3.80	0.230	1.07
29	22	23	-41.81	-8.80	42.46	7.91	0.651	3.03
30	23	24	86.60	-9.45	-85.58	8.23	1.020	3.72
31	23	25	-192.35	-16.28	198.15	36.96	5.802	29.75
32	26	25	103.06	22.01	-103.06	-18.21	0.000	3.79
33	25	27	124.91	29.84	-119.95	-22.45	4.952	25.38
34	27	28	34.08	-0.82	-33.85	-0.13	0.237	1.06
35	28	29	16.85	-6.87	-16.77	4.99	0.081	0.32
36	30	17	182.04	90.93	-182.04	-75.68	0.000	15.25
37	8	30	158.96	25.86	-157.79	-63.58	1.172	13.70
38	26	30	210.94	-12.55	-207.40	-40.17	3.542	38.12
39	17	31	18.36	10.01	-18.13	-13.09	0.231	0.76
40	29	31	-7.23	-8.99	7.25	8.26	0.015	0.05
41	23	32	56.22	11.74	-55.12	-19.03	1.102	4.01
42	31	32	-25.12	10.79	25.36	-12.31	0.247	0.82
43	27	32	22.11	-1.00	-21.99	-0.40	0.119	0.39
44	15	33	39.88	-12.19	-39.19	11.44	0.689	2.25
45	19	34	24.39	-17.83	-23.73	14.02	0.664	2.18
46	35	36	0.26	4.15	-0.26	-4.41	0.000	0.00
47	35	37	-33.26	-13.15	33.40	12.52	0.144	0.65
48	33	37	16.19	-20.44	-15.92	17.85	0.270	0.93
49	34	36	30.83	4.51	-30.74	-4.79	0.088	0.27
50	34	37	-88.92	-45.57	89.18	45.58	0.263	0.97
51	38	37	221.73	118.38	-221.73	-96.06	0.000	22.31
52	37	39	63.10	1.32	-61.79	0.39	1.305	4.31
53	37	40	51.97	-5.74	-50.33	6.35	1.640	4.65
54	30	38	183.15	12.82	-181.49	-33.61	1.656	19.28
55	39	40	34.79	-11.39	-34.54	10.78	0.259	0.85
56	40	41	35.26	13.05	-35.04	-13.44	0.220	0.74

57	40	42	-16.39	-4.94	16.56	1.02	0.163	0.54
58	41	42	-34.65	-9.46	35.21	8.07	0.564	1.86
59	43	44	4.59	-7.69	-4.56	1.94	0.028	0.11
60	34	43	22.82	-3.85	-22.59	0.69	0.223	0.91
61	44	45	-11.44	-0.19	11.47	-1.88	0.030	0.12
62	45	46	-23.64	-5.70	23.87	3.19	0.235	0.80
63	46	47	-18.11	-6.86	18.24	4.07	0.134	0.45
64	46	48	-14.76	-5.83	14.90	1.42	0.137	0.43
65	47	49	-36.65	0.53	36.90	-1.40	0.248	0.81
66	42	49	-27.58	-9.14	28.16	3.07	0.579	2.61
67	42	49	-27.58	-9.14	28.16	3.07	0.579	2.61
68	45	49	-40.83	-4.63	42.00	3.31	1.169	3.18
69	48	49	-34.90	3.21	35.11	-3.93	0.212	0.60
70	49	50	44.60	10.75	-44.06	-11.16	0.540	1.52
71	49	51	75.83	23.64	-72.87	-18.67	2.959	8.34
72	51	52	26.41	4.57	-26.25	-5.38	0.160	0.46
73	52	53	8.25	0.38	-8.22	-3.89	0.033	0.13
74	53	54	-14.78	-7.11	14.85	4.66	0.074	0.34
75	49	54	39.64	12.80	-38.36	-14.95	1.285	5.09
76	49	54	39.57	10.85	-38.10	-13.08	1.474	4.93
77	54	55	7.05	1.46	-7.04	-3.26	0.010	0.04
78	54	56	22.20	3.30	-22.19	-3.91	0.015	0.05
79	55	56	-19.05	-6.60	19.08	6.32	0.022	0.07
80	56	57	-28.04	-8.70	28.36	7.35	0.318	0.90
81	50	57	41.21	9.52	-40.36	-10.35	0.856	2.42
82	56	58	8.67	3.35	-8.64	-5.43	0.036	0.10
83	51	58	29.45	6.10	-29.20	-7.01	0.254	0.72
84	54	59	-32.65	-6.83	33.25	3.92	0.597	2.72
85	56	59	-30.04	-3.31	30.86	0.45	0.818	2.49
86	56	59	-31.48	-2.99	32.36	0.55	0.875	2.60
87	55	59	-36.91	-7.53	37.63	5.54	0.725	3.30
88	59	60	-53.34	5.40	54.29	-4.75	0.947	4.33
89	59	61	-56.85	6.62	57.96	-5.32	1.117	5.11
90	60	61	-61.02	10.19	61.12	-11.11	0.103	0.52
91	60	62	3.33	-7.08	-3.32	5.65	0.006	0.03

92	61	62	26.81	-14.13	-26.73	13.50	0.075	0.34
93	63	59	145.91	69.02	-145.91	-59.16	0.000	9.86
94	63	64	-145.91	-69.02	146.36	53.67	0.453	5.27
95	64	61	-14.11	17.07	14.11	-16.94	0.000	0.13
96	38	65	-40.23	-84.77	40.52	-13.49	0.284	3.11
97	64	65	-132.25	-70.74	132.81	39.43	0.561	6.30
98	49	66	-123.33	1.54	125.93	9.10	2.607	13.31
99	49	66	-123.33	1.54	125.93	9.10	2.607	13.31
100	62	66	-29.89	-19.36	30.45	15.84	0.564	2.55
101	62	67	-17.06	-16.39	17.19	13.83	0.132	0.60
102	65	66	-24.97	72.34	24.97	-70.46	0.000	1.88
103	66	67	45.71	20.32	-45.19	-20.83	0.521	2.36
104	65	68	242.64	-33.01	-241.83	-21.95	0.804	9.33
105	47	69	-15.59	-4.61	15.79	-2.22	0.198	0.65
106	49	69	-6.31	-5.54	6.35	-3.12	0.039	0.13
107	68	69	123.18	110.43	-123.18	-101.62	0.000	8.81
108	69	70	40.87	26.06	-40.11	-35.26	0.765	3.24
109	24	70	33.35	-0.91	-33.33	-4.32	0.025	4.72
110	70	71	-20.05	-2.93	20.08	2.23	0.037	0.15
111	24	72	39.23	-4.50	-38.46	2.83	0.765	3.07
112	71	72	-26.10	8.76	26.46	-11.58	0.367	1.48
113	71	73	6.01	-10.99	-6.00	9.91	0.013	0.07
114	70	74	21.27	11.47	-21.02	-13.79	0.259	0.85
115	70	75	6.21	4.60	-6.17	-7.93	0.035	0.11
116	69	75	51.62	30.41	-50.09	-38.32	1.527	4.60
117	74	75	-46.98	-19.44	47.33	19.61	0.344	1.14
118	76	77	-62.87	-20.35	65.02	24.02	2.149	7.16
119	69	77	-15.92	29.37	16.34	-38.79	0.425	1.39
120	75	77	-37.12	-6.30	38.00	4.37	0.886	2.95
121	77	78	34.51	9.47	-34.47	-10.59	0.048	0.16
122	78	79	-36.53	-15.41	36.62	15.13	0.085	0.38
123	77	80	-119.13	-28.35	121.63	30.53	2.497	7.12
124	77	80	-55.25	-16.96	56.21	18.00	0.959	3.43
125	79	80	-75.62	-26.77	76.60	29.22	0.978	4.41
126	68	81	-65.48	-4.58	65.57	-75.02	0.097	1.12

127	81	80	-65.57	75.02	65.57	-71.79	0.000	3.23
128	77	82	-40.49	34.89	41.43	-40.33	0.931	2.67
129	82	83	-79.27	37.45	80.17	-38.17	0.902	2.95
130	83	84	-37.87	20.51	39.11	-20.37	1.239	2.62
131	83	85	-62.30	17.28	64.20	-14.12	1.895	6.52
132	84	85	-50.11	13.37	50.96	-12.74	0.854	1.81
133	85	86	17.17	-7.35	-17.05	5.09	0.119	0.42
134	86	87	-3.95	-15.09	4.00	11.02	0.053	0.39
135	85	88	-76.61	7.98	77.84	-4.42	1.228	6.26
136	85	89	-79.72	3.03	81.29	3.70	1.573	11.38
137	88	89	-82.46	2.57	83.41	0.40	0.958	4.91
138	89	90	58.55	-4.78	-56.79	5.94	1.760	6.39
139	89	90	111.46	-5.52	-108.53	7.29	2.927	12.26
140	90	91	2.32	4.15	-2.31	-6.19	0.008	0.03
141	89	92	206.98	-2.59	-202.78	18.56	4.199	21.42
142	89	92	65.30	-5.31	-63.64	7.88	1.663	6.69
143	91	92	-7.69	-6.91	7.72	3.86	0.035	0.12
144	92	93	76.01	-16.70	-74.42	19.78	1.585	5.21
145	92	94	73.31	-18.20	-70.55	23.32	2.767	9.09
146	93	94	68.56	-22.60	-67.37	24.66	1.186	3.89
147	94	95	58.75	5.13	-58.28	-4.65	0.471	1.55
148	80	96	3.25	25.41	-2.98	-29.16	0.263	1.34
149	82	96	-16.15	-4.67	16.20	-0.49	0.044	0.14
150	94	96	40.13	-14.46	-39.64	13.80	0.493	1.59
151	80	97	10.75	30.00	-10.57	-31.72	0.186	0.95
152	80	98	9.13	12.14	-9.07	-14.91	0.060	0.27
153	80	99	3.86	11.34	-3.77	-16.66	0.092	0.42
154	92	100	44.60	-17.78	-43.13	19.73	1.473	6.71
155	94	100	9.05	-54.65	-8.54	50.21	0.502	1.64
156	95	96	16.28	-26.35	-16.11	25.45	0.165	0.53
157	96	97	4.53	-24.60	-4.43	22.72	0.101	0.51
158	98	100	-18.58	5.83	18.74	-10.08	0.157	0.71
159	99	100	-38.23	-0.75	38.49	-0.30	0.258	1.16
160	100	101	-28.85	27.42	29.30	-28.67	0.450	2.05
161	92	102	58.33	-7.71	-57.89	8.25	0.433	1.97

162	101	102	-51.30	13.67	52.02	-13.28	0.718	3.27
163	100	103	121.75	-22.15	-119.40	24.36	2.351	7.72
164	100	104	56.18	10.65	-54.73	-9.41	1.455	6.58
165	103	104	32.45	13.87	-31.85	-15.83	0.597	2.03
166	103	105	43.35	12.85	-42.25	-13.48	1.103	3.35
167	100	106	60.36	9.48	-58.14	-7.12	2.225	8.42
168	104	105	48.58	2.63	-48.33	-2.61	0.250	0.95
169	105	106	8.86	3.88	-8.85	-5.15	0.015	0.06
170	105	107	26.75	-2.37	-26.35	-0.55	0.407	1.41
171	105	108	23.97	-11.13	-23.77	9.92	0.191	0.51
172	106	107	23.98	-3.73	-23.65	0.55	0.331	1.14
173	108	109	21.77	-10.92	-21.71	10.39	0.066	0.18
174	103	110	60.60	8.35	-59.15	-6.15	1.450	6.73
175	109	110	13.71	-13.39	-13.61	11.77	0.102	0.28
176	110	111	-35.70	0.96	36.00	-1.84	0.297	1.02
177	110	112	69.46	-30.61	-68.00	28.51	1.459	3.78
178	17	113	6.53	1.98	-6.53	-2.72	0.004	0.01
179	32	113	-0.40	-16.50	0.53	11.98	0.132	0.44
180	32	114	-6.85	-0.66	6.86	-0.82	0.007	0.03
181	27	115	15.14	0.40	-15.10	-2.06	0.040	0.18
182	114	115	-14.86	-2.18	14.87	1.95	0.006	0.03
183	68	116	184.13	-83.90	-184.00	68.98	0.134	1.60
184	12	117	20.15	5.20	-20.00	-8.00	0.153	0.65
185	75	118	38.53	28.79	-38.17	-28.70	0.360	1.19
186	76	118	-5.13	-14.78	5.17	13.70	0.042	0.14
							-----	-----
Total:							126.687	731.89

附录 2：第四章仿真模型参数设置

表 2 仿真模型参数设置

模块	参数	数值
三相交流外部电源模块	线电压有效值/Vrms	1.38e4
	A 相初相角/degrees	0.071
	频率/Hz	60
光伏模块三相动态负载	初始有功功率 Po/W	2.5e4
	初始无功功率 Qo/var	3.39e 13
	初始正序电压	[0.999 0.0039]
储能模块三相动态负载	初始有功功率 Po/W	1e5
	初始无功功率 Qo/var	3.39e 13
	初始正序电压	[0.999 0.0039]
负荷模块三相动态负载 固定负荷	初始有功功率 Po/W	2e5
	初始无功功率 Qo/var	4.59e4
	初始正序电压	[0.999 0.0039]
	有功功率 P/W	3.50e5

项目及研究成果

参与项目:

- (1) 国网大数据中心项目: 基于人工智能海量分布式新能源数据质量控制;
- (2) 丰田-清华联合科技项目: 信息物理融合的城市能源系统综合状态感知、安全评估以及能量管理;
- (3) 中车国创中心(青岛)科技项目: 高效能城市轨道交通系统建模与综合智能优化;
- (4) 南网重大科技项目: 基于新一代人工智能和 5G 通信技术的电能质量数据监测管理与分析。

期刊论文:

- (1) 梁宏, 曹军威, 等, "基于深度强化学习的微网储能系统控制策略研究." 电网技术 (录用并在线发表)
- (2) Guo Jian, **Liang Hong**, et.al., "Improved approximate minimum degree ordering method and its application for electrical power network analysis and computation." Tsinghua Science and Technology, vol. 26, no. 4, pp. 464-474, Aug. 2021.
- (3) **Liang Hong**, Qin Yuchao, et.al., "Stochastic Optimal Energy Storage Management for Energy Routers via Compressive Sensing." IEEE Transactions on Industrial Informatics(accepted)
- (4) 梁宏, 王同贺, 曹军威, "基于压缩感知的概率潮流分析", 电工技术学报 (审稿中)

会议论文:

- (1) Guo Jian, Wu Xiaobo, **Liang Hong**, et al. Digital-Twin Based Power Supply System Modeling and Analysis for Urban Rail Transportation(ICEI2020)
- (2) Qin Zhaoming, Hua Haochen, **Liang Hong**, et.al., "Optimal Electricity Trading Strategy for a Household Microgrid." In 2020 IEEE 16th International Conference on Control & Automation (ICCA) (pp. 1308-1313). IEEE.
- (3) **Liang Hong**, Wang Tonghe, Guo Jian, et al., "Probabilistic Power Flow

Calculation of Microgrid Based on L1-Minimization" (ICEI 2021)

申请发明专利：

- (1) 数据采集方法、系统、设备及存储介质
- (2) 基于压缩感知改进的深度神经网络算法在能源微网故障诊断中的应用
- (3) 基于压缩采样的深度强化学习算法在多微网能量调度问题中的应用
- (4) 基于压缩样本集的本征正交基算法在能源互联网系统降阶建模中的应用
- (5) 基于本征正交分解的深度强化学习算法在优化微网储能充放电策略中的应用

个人简介

梁宏，女，汉族，1991年3月生，吉林长春人。

2009-2013年，武汉大学数学与统计学院计算数学专业攻读学士学位；

2013-2019年，清华大学高等研究院应用数学方向攻读博士学位；

2019-2021年，清华大学自动化系控制科学与工程流动站做博后。