

การจัดการพลังงานที่เหมาะสมในไมโครกริด โดยใช้เทคนิคการเรียนรู้
เสริมกำลังเชิงลึกแบบหลายเอเจนต์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2566

OPTIMAL ENGERGY MANAGEMENT IN MICROGRID USING MULTI-
AGENT DEEP REINFORCEMENT LEARNING TECHNIQUES



A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Electrical Engineering
Suranaree University of Technology
Academic Year 2023

การจัดการพลังงานที่เหมาะสมในไมโครกริด โดยใช้เทคนิคการเรียนรู้
เสริมกำลังเชิงลึกแบบหลายเอเจนต์

มหาวิทยาลัยเทคโนโลยีสุรนารีอนุมัติให้บัณฑิตวิทยาลัยฉบับนี้เป็นส่วนหนึ่งของการศึกษาตาม
หลักสูตรปริญญามหาบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์

(รศ. ดร. กীরติ ชยะกุลศิรี)

ประธานกรรมการ

(ผศ. ดร. บุญเรือง มะรังศรี)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

(ผศ. ดร. ธีระพงษ์ บุญรักษา)

กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี

(รองศาสตราจารย์ ดร. ยุพาพร รักสกุลพิวัฒน์)
รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ

(รองศาสตราจารย์ ดร. พรศิริ จงกล)
คณบดีสำนักวิชาวิศวกรรมศาสตร์

นนวนวิช โคตรศรีวงษ์ : การจัดการพลังงานที่เหมาะสมในไมโครกริด โดยใช้เทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ (OPTIMAL ENERGY MANAGEMENT IN MICROGRID USING MULTI-AGENT DEEP REINFORCEMENT LEARNING TECHNIQUES)

อาจารย์ที่ปรึกษา: ผู้ช่วยศาสตราจารย์ ดร.บุญเรือง มะรังศรี, 227 หน้า.

คำสำคัญ : การเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์/ ไมโครกริด/ การจัดการพลังงาน

งานวิจัยวิทยานิพนธ์นี้นำเสนอการจัดการพลังงานที่เหมาะสมสำหรับไมโครกริด โดยใช้เทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยแบ่งการศึกษาออกเป็นสองส่วน ประกอบด้วย 1) การศึกษาเชิงเปรียบเทียบเพื่อหาพารามิเตอร์ที่เหมาะสมโดยใช้สมการทดสอบฟังก์ชันฐานนิยมแบบเดียว และฟังก์ชันฐานนิยมหลายตัว 2) การศึกษาการประยุกต์ใช้การเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์เพื่อหาค่าที่เหมาะสมในไมโครกริด กลยุทธ์ที่นำมาใช้ในการจัดการคือ การหาขนาด และตำแหน่งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานด้วยแบตเตอรี่ โดยพิจารณาการปรับปรุงแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสีย ต้นทุนของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ กรณีศึกษาของระบบไมโครกริดอยู่บนพื้นฐานของระบบทดสอบโครงข่าย IEEE 33 โหนด โหลดพื้นฐานที่ใช้ในการจำลองคือ โหลดที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจ ซึ่งแบ่งการจำลองโหลดพื้นฐานเป็น 4 แบบคือ 1) โหลดพื้นที่พักอาศัยทั้งหมด 2) โหลดพื้นที่ธุรกิจทั้งหมด 3) โหลดพื้นที่พักอาศัยแบบผสมร่วมกับพื้นที่ธุรกิจที่โหนด 23, 24 และโหนดที่ 25 4) โหลดพื้นที่พักอาศัยแบบผสมร่วมกับพื้นที่ธุรกิจ โดยพื้นที่ธุรกิจคือ โหนด 23 ถึงโหนดที่ 33 กลยุทธ์การวิเคราะห์ร่วมกับการใช้พลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่ใช้ในการจำลองประกอบไปด้วย 1) การวิเคราะห์แรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียโดยไม่พิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า 2) การหาขนาด และตำแหน่งที่เหมาะสมของพลังงานหมุนเวียนในระบบไมโครกริด โดยไม่พิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า 3) การวิเคราะห์แรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสีย โดยพิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า 4) การหาขนาด และตำแหน่งที่เหมาะสมของพลังงานหมุนเวียนในระบบไมโครกริด โดยพิจารณาการใช้ระบบกักเก็บพลังงานแบบแบตเตอรี่ และสถานีอัดประจุยานยนต์ไฟฟ้า ผลการจำลองจากการศึกษาเชิงเปรียบเทียบในสมการทดสอบฟังก์ชันนิยมแบบเดียว และฟังก์ชันฐานนิยมหลายตัว โดยใช้พารามิเตอร์ที่เหมาะสมต่อการเปรียบเทียบอัลกอริทึม และรอบการฝึกอบรมที่ 5000 พบว่า

อัลกอริทึม MADDPG และ MASAC ให้คำตอบของสมการที่เข้าใกล้คำตอบศูนย์ และมีประสิทธิภาพของค่ารางวัลที่มากที่สุด โดยใช้พารามิเตอร์แลมบ์ดา (Lambda) มีค่า 1.00 ซึ่งสัมพันธ์กับอัลกอริทึม MAA2C และ MAA3C พารามิเตอร์แกมมา (Gamma) มีค่า 0.01 ซึ่งสัมพันธ์กับ MADDPG, MATD3 และ MASAC ผลการจำลองในการประยุกต์ใช้การเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์เพื่อหาค่าที่เหมาะสมในไมโครกริด โดยใช้พารามิเตอร์ที่เหมาะสมต่อการเปรียบเทียบ และรอบฝึกอบรมที่ 150 รอบ พบว่าอัลกอริทึม MADDPG ที่ให้ผลทดสอบในฟังก์ชันนิยมแบบเดียว และฟังก์ชันฐานนิยมหลายตัวที่มีผลลัพธ์ และมีประสิทธิภาพที่ดีนั้นไม่สามารถหาค่าที่เหมาะสมในไมโครกริดได้ ซึ่งอัลกอริทึมที่สามารถแสดงประสิทธิภาพได้ดีคือ MAA2C และ MASAC จากผลการศึกษาสรุปได้ว่าอัลกอริทึมที่สามารถแสดงประสิทธิภาพได้ดีในเงื่อนไขพารามิเตอร์ที่เหมือนกัน รอบการฝึกอบรมที่ 5,000 รอบ และ 150 รอบ คืออัลกอริทึม MASAC ที่สามารถหาค่าที่เหมาะสมของสมการทดสอบและการหาขนาด ตำแหน่งของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานด้วยแบตเตอรี่



สาขาวิชา วิศวกรรมไฟฟ้า

ปีการศึกษา 2566

ลายมือชื่อนักศึกษา

ลายมือชื่ออาจารย์ที่ปรึกษา

นาย ทวีวัฒน์
2020205

NONTHAWAT KHORTSRIWONG: OPTIMAL ENERGY MANAGEMENT IN MICROGRID USING MULTI-AGENT DEEP REINFORCEMENT LEARNING TECHNIQUES. THESIS ADVISOR: ASST.PROF. BOONRUANG MARUNGSRI, D. Eng., 227 PP.

Keyword: Multi Agent Deep Reinforcement Learning/ Microgrid/ Energy Management System

This thesis proposes an optimal energy management strategy for microgrids, employing multi-agent deep reinforcement learning techniques MAA2 C, MAA3 C, MADDPG, MATD3, and MASAC algorithms. The study is divided into two main parts: 1) A comparative analysis aimed at identifying the optimal parameters using both Unimodal test function as well as Multimodal test function, and 2) An investigation into the application of multi-agent deep reinforcement learning to determine optimal placement and sizing of renewable resources and energy storage systems within the microgrids considering voltage regulation improvements, power loss reductions, and the cost-effectiveness of renewable energy systems and battery energy storage solutions. IEEE- 33 bus test system is used for the implementation of proposed algorithm. This simulation considers both residential and commercial load and forms four scenarios: 1) fully residential area load. 2) all commercial area loads. 3) Mixed residential and commercial area loads with commercial loads at nodes 23, 24, and 25. 4) Mixed residential and commercial area loads, with commercial areas encompassing nodes 23 through 33. The analytical strategy is to determine the effect of the integration of renewable energy resources and battery energy storage system on microgrid on voltage regulation and power loss in four cases: 1) Base case: calculating voltage regulation and power loss without electric vehicle charging station. 2) optimal sizing and placement of renewable resources without electric vehicle charging stations. 3) optimal placement and sizing of renewable resources with electric vehicles charging stations. And 4) optimal placement and sizing of renewable resources and battery

energy storage system with electric vehicle charging stations in microgrid. The simulation results from the comparative study using Unimodal test function equation and Multimodal function definitions, with optimal parameters and 5000 training iterations, reveal that the MADDPG and MASAC algorithms provide solutions that closely approach zero and achieve the highest reward efficiency. The parameter lambda was set to 1.00 for the MAA2C and MAA3C algorithms, while the parameter gamma was set to 0.01 for the MADDPG, MATD3, and MASAC algorithms. When applying the multi-agent deep reinforcement learning methodology with appropriate parameters and 150 training iterations, MADDPG algorithm failed to find optimal values in the microgrid even performing well in Unimodal function and Multimodal function tests. The algorithms that demonstrated good performance were MAA2C and MASAC. The study concludes that the MASAC algorithm consistently performs better under the same parameter conditions, with 5000 and 150 training iterations. MASAC effectively identifies optimal solutions for test equations and determines the sizing and location of renewable energy sources in conjunction with battery energy storage systems.

มหาวิทยาลัยเทคโนโลยีสุรนารี

School of Electrical Engineering
ปีการศึกษา 2023

Student's Signature

Advisor's Signature

อนุชิต ทอมสิน
2/2/2565

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดี เนื่องจากได้รับความช่วยเหลืออย่างดียิ่ง ทั้งด้านวิชาการ และด้านดำเนินงานวิจัย จากบุคคลและกลุ่มบุคคลต่าง ๆ ได้แก่

ผู้ช่วยศาสตราจารย์ ดร.บุญเรือง มะรังศรี อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำปรึกษา แนะนำแนวทางอันเป็นประโยชน์ต่องานวิจัยเป็นอย่างยิ่งและให้ความรู้ด้านวิชาการมาโดยตลอด อีกทั้งยังได้ช่วยตรวจทานและแก้ไขรายงานวิทยานิพนธ์เล่มนี้จนมีความสมบูรณ์ยิ่งขึ้น

ผู้ช่วยศาสตราจารย์ ดร.ธีระพงษ์ บุญรักษา รองศาสตราจารย์ ดร.กীরติ ชยะกุลศิริ ที่กรุณาให้ คำปรึกษาแนะนำแนวทางสำหรับการทำวิจัย

ขอขอบคุณ สมาชิกกลุ่มวิจัยระบบไฟฟ้ากำลังและพลังงาน มหาวิทยาลัยเทคโนโลยีสุรนารีทุกท่าน ที่ให้คำแนะนำ และความช่วยเหลือในทุก ๆ เรื่อง

ขอขอบคุณสมาชิกบัณฑิตศึกษาทุกท่าน รวมถึงมิตรสหายทั้งในอดีตและปัจจุบันที่ทำให้ข้าพเจ้ามีกำลังใจในการทำวิจัยตลอดมา

ท้ายนี้ผู้วิจัยขอขอบพระคุณอาจารย์ผู้สอนทุกท่านที่ได้ให้ความรู้ทางด้านวิชาการทั้งในอดีต และปัจจุบัน และขอกราบขอบพระคุณ บิดาและมารดา ที่ให้ความรักความห่วงใย และการส่งเสริม ด้านการศึกษาอย่างเปี่ยมล้นตลอดมา ทำให้ผู้วิจัยไม่ย่อท้อต่ออุปสรรคต่าง ๆ ที่เกิดขึ้นตลอดมา

นนวัช โคตรศรีวงศ์

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ค
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ช
สารบัญตาราง.....	ฎ
สารบัญรูป.....	ฉ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	3
1.3 ข้อยกเว้นเบื้องต้น.....	3
1.4 ขอบเขตของการวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.6 รายละเอียดในวิทยานิพนธ์.....	4
2 ปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 กล่าวนำ.....	5
2.2 ระบบไฟฟ้ากำลัง.....	5
2.2.1 ระบบผลิตกำลังไฟฟ้า.....	6
2.2.2 ระบบส่งจ่ายไฟฟ้า.....	7
2.2.3 ระบบจำหน่ายไฟฟ้า.....	7
2.3 โหลดของระบบไฟฟ้า.....	8
2.3.1 ผลกระทบต่อระบบไฟฟ้าเมื่อมีการประจุไฟฟ้าของยานยนต์ไฟฟ้า.....	8

2.4	การคำนวณการไหลของกำลังไฟฟ้า	9
2.4.1	พารามิเตอร์ของสายส่ง.....	9
2.4.2	หลักการควบคุมการไหลของกำลังไฟฟ้า	10
2.4.3	ชนิดของโนด.....	10
2.4.4	การคำนวณการไหลของกำลังไฟฟ้าด้วยวิธีนิวตัน-ราฟสัน.....	13
2.5	ไมโครกริด	15
2.5.1	ระบบทดสอบ IEEE 33 โหนด	15
2.5.2	ระบบผลิตไฟฟ้าแบบกระจาย	16
2.5.3	ระบบพลังงานแสงอาทิตย์	17
2.5.4	ระบบพลังงานกักเก็บลม	18
2.5.5	ระบบกักเก็บพลังงานด้วยแบตเตอรี่.....	19
2.5.6	สถานีอัดประจุยานยนต์ไฟฟ้า.....	21
2.6	การเรียนรู้แบบเสริมกำลัง.....	21
2.6.1	กระบวนการตัดสินใจแบบมาร์คอฟ	22
2.6.2	ประเภทของการเรียนรู้เสริมกำลัง.....	24
2.6.3	วิธีการตามมูลค่า.....	25
2.6.4	วิธีการหานโยบายที่เหมาะสม	26
2.7	การเรียนรู้แบบเสริมกำลังหลายเอเจนต์.....	26
2.7.1	สโตแคสติกเกม.....	27
2.7.2	วิธีการตามมูลค่าแบบหลายเอเจนต์	28
2.8	การเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์.....	29
2.8.1	อัลกอริทึมแบบ MAA2C.....	29
2.8.2	อัลกอริทึมแบบ MAA3C.....	33
2.8.3	อัลกอริทึมแบบ MADDPG.....	34
2.8.4	อัลกอริทึมแบบ MATD3.....	37
2.8.5	อัลกอริทึมแบบ MASAC	41
2.9	ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง	44
2.10	สรุป.....	49

3	วิธีดำเนินการวิจัย	50
3.1	กล่าวนำ.....	50
3.2	การตรวจสอบสมรรถนะของ MADRL ด้วยฟังก์ชันมาตรฐาน	50
3.3	การจัดการพลังงานที่เหมาะสมของระบบโครงข่ายไฟฟ้า	51
3.3.1	กำลังไฟฟ้าสูญเสียในระบบไฟฟ้า	51
3.3.2	ค่าใช้จ่ายในการลงทุนของระบบ	52
3.3.3	เงื่อนไขของระบบโครงข่ายไฟฟ้า	52
3.3.4	ระบบกักเก็บพลังงานด้วยแบตเตอรี่.....	53
3.3.5	การหาขนาด และตำแหน่งแบตเตอรี่	54
3.3.6	ค่าใช้จ่ายของระบบกักเก็บพลังงาน	55
3.4	ชุดข้อมูลในการจำลองของระบบโครงข่ายไฟฟ้า	56
3.4.1	แบบจำลองพลังงานแสงอาทิตย์.....	56
3.4.2	แบบจำลองของพลังงานกังหันลม	58
3.4.3	แบบจำลองของระบบกักเก็บพลังงานแบบแบตเตอรี่	60
3.4.4	แบบจำลองของโหลดที่อยู่อาศัยและพื้นที่ประกอบธุรกิจในระบบโครงข่าย 33 โนด.....	61
3.4.5	แบบจำลองสถานีอัดประจุยานยนต์ไฟฟ้า.....	62
3.5	กรณีศึกษาของระบบโครงข่ายไฟฟ้า	63
3.6	พารามิเตอร์และการฝึกสอนแบบจำลอง	68
3.7	เครื่องมือที่ใช้ในการวิจัย	71
3.7.1	ไลบรารี Pandapower.....	72
3.7.2	ไลบรารี Gymnasium	72
3.7.3	ไลบรารี Rllib.....	73
3.8	สรุป.....	74
4	ผลการวิจัยและอภิปรายผล	75
4.1	กล่าวนำ.....	75
4.2	ผลการปรับค่าพารามิเตอร์แบบจำลอง.....	75
4.2.1	การปรับแต่งพารามิเตอร์อัลกอริทึม MAA2C และ MAA3C	76

4.2.2	การปรับแต่งพารามิเตอร์อัลกอริทึม MADDPG, MATD3 และ MASAC.....	77
4.3	ผลการตรวจสอบสมรรถนะของ MADRL ด้วยฟังก์ชันมาตรฐาน.....	79
4.3.1	ฟังก์ชันฐานนิยมแบบเดี่ยว	79
4.3.2	ฟังก์ชันฐานนิยมหลายตัว	82
4.4	ผลการจำลองผลกระทบของโหนดในระบบไมโครกริด 33 โหนด	85
4.4.1	กรณีศึกษาที่ 1 และกรณีศึกษาที่ 2	85
4.4.2	กรณีศึกษาที่ 3 และกรณีศึกษาที่ 4	89
4.5	ผลการจำลองหาขนาดและตำแหน่งติดตั้งพลังงานหมุนเวียน.....	93
4.5.1	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 1	93
4.5.2	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 2	104
4.5.3	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 3	115
4.5.4	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 4	126
4.6	ผลการจำลองผลกระทบของโหนดสถานีอัดประจุไฟฟ้า ในระบบไมโครกริด 33 โหนด.....	137
4.6.1	ผลการจำลองผลกระทบของโหนดสถานีอัดประจุไฟฟ้ากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2	137
4.6.2	ผลการจำลองผลกระทบของโหนดสถานีอัดประจุไฟฟ้ากรณีศึกษาที่ 3 และกรณีศึกษาที่ 4	142
4.7	ผลการจำลองหาขนาดและตำแหน่งติดตั้งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บ พลังงานแบบแบตเตอรี่ โดยพิจารณาโหนดของสถานีอัดประจุไฟฟ้ายานยนต์	147
4.7.1	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 1	147
4.7.2	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 2	159
4.7.3	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 3	171
4.7.4	ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 4	183
4.8	สรุป.....	195

5	สรุปและข้อเสนอแนะ	197
5.1	บทสรุป.....	197
5.2	ข้อเสนอแนะ.....	197
	รายการอ้างอิง.....	200
	ภาคผนวก ก ชุดคำสั่งโปรแกรม Python สำหรับการจำลองผล.....	208
	ภาคผนวก ข ระบบจำหน่ายไฟฟ้าที่ใช้ในงานวิจัย.....	220
	ภาคผนวก ค บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา.....	225
	ประวัติผู้เขียน.....	227



สารบัญตาราง

ตารางที่	หน้า
2.1	พารามิเตอร์ของโนดแต่ละชนิด..... 11
2.2	ประโยชน์และข้อเสียของแบตเตอรี่แต่ละชนิด 20
2.3	งานวิจัยที่เกี่ยวข้อง..... 44
3.1	ฟังก์ชันทดสอบ..... 51
3.2	ค่าใช้จ่ายของระบบพลังงานหมุนเวียนและระบบกักเก็บพลังงาน..... 52
3.3	ข้อมูลทางเทคนิคที่ใช้ในการจำลองของพลังงานเซลล์แสงอาทิตย์..... 57
3.4	ข้อมูลทางเทคนิคของกังหันลม..... 59
3.5	ข้อมูลคุณสมบัติของเครื่องชาร์จขนาด 150 kW..... 63
3.6	การกำหนดพื้นที่โหลดที่พักอาศัยและพื้นที่ธุรกิจสำหรับกรณีศึกษา..... 66
3.7	พารามิเตอร์ที่ใช้ในการจำลอง..... 69
4.1	ฟังก์ชันทดสอบฐานนิยมแบบเดี่ยว..... 80
4.2	ผลการทดสอบฟังก์ชัน F1 และ F2..... 80
4.3	ฟังก์ชันทดสอบฐานนิยมหลายตัว..... 82
4.4	ผลการทดสอบฟังก์ชัน F3 และ F4..... 83
4.5	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2..... 85
4.6	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4..... 89
4.7	ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 1..... 95
4.8	ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 2..... 106
4.9	ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 3..... 117
4.10	ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 4..... 128

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.11	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 1 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า137
4.12	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 2 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า138
4.13	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 3 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า142
4.14	แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 4 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า143
4.15	ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ แบตเตอรี่ของกรณีศึกษาที่ 1150
4.16	ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ แบตเตอรี่ของกรณีศึกษาที่ 2161
4.17	ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ แบตเตอรี่ของกรณีศึกษาที่ 3173
4.18	ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ แบตเตอรี่ของกรณีศึกษาที่ 4185

สารบัญรูป

รูปที่	หน้า
2.1	โครงสร้างระบบไฟฟ้า 6
2.2	ระบบโครงข่ายทดสอบ IEEE 33 โหนด 16
2.3	โครงสร้างและการทำงานของแผงเซลล์แสงอาทิตย์..... 17
2.4	โครงสร้างและส่วนประกอบของกังหันลม 18
2.5	ลำดับความเป็นมาของอัลกอริทึม 22
2.6	กระบวนการทำงานของการเรียนรู้แบบเสริมกำลัง..... 23
2.7	ประเภทของการเรียนรู้แบบเสริมกำลัง 25
2.8	กระบวนการทำงานของ A2C 30
2.9	การทำงานแบบพร้อมจังหวะกันของอัลกอริทึม A2C 31
2.10	ชุดโค้ดอัลกอริทึมของ A2C 32
2.11	การทำงานแบบไม่เป็นจังหวะเดียวกันของอัลกอริทึม A3C..... 33
2.12	ชุดโค้ดอัลกอริทึมของ A3C 34
2.13	กระบวนการทำงานของ DDPG 35
2.14	ชุดโค้ดอัลกอริทึมของ DDPG 37
2.15	กระบวนการทำของ TD3 38
2.16	ชุดโค้ดอัลกอริทึมของ TD3 40
2.17	กระบวนการทำงานของอัลกอริทึม SAC 41
2.18	ชุดโค้ดอัลกอริทึม SAC 43
3.1	ลักษณะอุณหภูมิแวดล้อมในหนึ่งปี 57
3.2	ลักษณะของความเข้มแสงในหนึ่งปี..... 58
3.3	ลักษณะเฉพาะของกำลังผลิตพลังงานเซลล์แสงอาทิตย์..... 58
3.4	ความเร็วลมที่ระดับความสูง 50 เมตร 59

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.5	ลักษณะเฉพาะของกำลังผลิตพลังงานกังหันลม.....60
3.6	ลักษณะการอัดประจุ และคลายประจุแบตเตอรี่..... 60
3.7	ลักษณะของโหลดที่อยู่อาศัยและพื้นที่ประกอบธุรกิจ61
3.8	โหลดที่อยู่อาศัยภายในระบบทดสอบ IEEE 33 โหนด.....62
3.9	โหลดพื้นที่ธุรกิจภายในระบบทดสอบ IEEE 33 โหนด62
3.10	ความต้องการกำลังไฟฟ้าของเครื่องอัดประจุในหนึ่งวัน.....63
3.11	กำลังไฟฟ้าเดิมของระบบทดสอบ IEEE 33 โหนด.....64
3.12	แรงดันไฟฟ้าเดิมของระบบทดสอบ IEEE 33 โหนด.....65
3.13	การแบ่งกรณีศึกษาด้วยโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจ66
3.14	ขั้นตอนการดำเนินการวิจัย.....67
3.15	ตำแหน่งสถานีอัดประจุยานยนต์ไฟฟ้าภายในไมโครกริด 33 โหนด68
3.16	พารามิเตอร์ภายในสภาพแวดล้อมที่เอเจนต์เรียนรู้.....70
3.17	หน้าเว็บไซต์ของไลบรารี Pandapower.....72
3.18	หน้าเว็บไซต์ของไลบรารี Gymnasium.....73
3.19	หน้าเว็บไซต์ของไลบรารี Rllib.....73
4.1	ผลการปรับค่า Lambda อัลกอริทึม MAA2C.....76
4.2	ผลการปรับค่า Lambda อัลกอริทึม MAA3C.....77
4.3	ผลการปรับค่า Gamma อัลกอริทึม MADDPG.....78
4.4	ผลการปรับค่า Gamma อัลกอริทึม MATD3.....78
4.5	ผลการปรับค่า Gamma อัลกอริทึม MASAC.....79
4.6	ผลการทดสอบฟังก์ชันฐานนิยมเดียวสมการที่ 1.....81
4.7	ผลการทดสอบฟังก์ชันฐานนิยมเดียวสมการที่ 2.....82
4.8	ผลการทดสอบฟังก์ชันฐานนิยมหลายตัวสมการที่ 3.....83
4.9	ผลการทดสอบฟังก์ชันฐานนิยมหลายตัวสมการที่ 4.....84

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.10	แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลาการณศึกษาที่ 1 และกรณศึกษาที่ 286
4.11	กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลาการณศึกษาที่ 1 และกรณศึกษาที่ 2 86
4.12	แรงดันไฟฟ้าเดิมของระบบกรณศึกษาที่ 1 และกรณศึกษาที่ 287
4.13	กำลังไฟฟ้าสูญเสียเดิมของระบบกรณศึกษาที่ 1 และกรณศึกษาที่ 2 88
4.14	แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลาของการณศึกษาที่ 3 และกรณศึกษาที่ 4..... 90
4.15	กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลาของการณศึกษาที่ 3 และกรณศึกษาที่ 4 90
4.16	แรงดันไฟฟ้าเดิมของระบบกรณศึกษาที่ 3 และกรณศึกษาที่ 4 91
4.17	กำลังไฟฟ้าสูญเสียเดิมของระบบกรณศึกษาที่ 3 และกรณศึกษาที่ 4 92
4.18	กรณศึกษาที่ 1 ด้วยโหลดแบบพื้นที่พักอาศัย..... 93
4.19	ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของ กรณศึกษาที่ 1..... 94
4.20	แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณศึกษาที่ 1 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC..... 97
4.21	กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของการณศึกษาที่ 1 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC 97
4.22	แรงดันไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 1 โดยรูปที่ ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C..... 98
4.23	แรงดันไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 1 โดยรูปที่ ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3 99
4.24	แรงดันไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 1 ด้วยอัลกอริทึม MASAC.....100
4.25	กำลังไฟฟ้าสูญเสียแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 1 โดยรูปที่ ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C101

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.26	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 โดยรูปที่	
ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	102
4.27	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1	
ด้วยอัลกอริทึม MASAC.....	103
4.28	
กรณีศึกษาที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจ.....	104
4.29	
ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของ	
กรณีศึกษาที่ 2	105
4.30	
แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม MAA2C, MAA3C,	
MADDPG, MATD3 และ MASAC.....	108
4.31	
กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม	
MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	108
4.32	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	109
4.33	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	110
4.34	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ด้วยอัลกอริทึม MASAC.....	111
4.35	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	112
4.36	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	113
4.37	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2	
ด้วยอัลกอริทึม MASAC	114

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.38 กรณศึกษาที่ 3 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ	115
4.39 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของ กรณศึกษาที่ 3.....	116
4.40 แรงด้นไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณศึกษาที่ 3 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	119
4.41 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณศึกษาที่ 3 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	119
4.42 แรงด้นไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C.....	120
4.43 แรงด้นไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	121
4.44 แรงด้นไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ด้วยอัลกอริทึม MASAC.....	122
4.45 กำลังไฟฟ้าสูญเสียแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	123
4.46 กำลังไฟฟ้าสูญเสียแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	124
4.47 กำลังไฟฟ้าสูญเสียแต่ละโนดก่อน และหลังปรับปรุงของกรณศึกษาที่ 3 ด้วยอัลกอริทึม MASAC.....	125
4.48 กรณศึกษาที่ 4 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ	126
4.49 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของ กรณศึกษาที่ 4.....	127

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.50 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC.....	130
4.51 กำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC.....	130
4.52 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C.....	131
4.53 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	132
4.54 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MASAC.....	133
4.55 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C.....	134
4.56 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3.....	135
4.57 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MASAC	136
4.58 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 โดยพิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า	138
4.59 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 โดยพิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า	139
4.60 แรงดันไฟฟ้าของระบบหลังเพิ่มโหนดสถานีอัดประจุยานยนต์ไฟฟ้ากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2.....	140

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.61 กำลังไฟฟ้าสูญเสียของระบบหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า กรณีศึกษาที่ 1 และกรณีศึกษาที่ 2.....	141
4.62 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลาหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าของ กรณีศึกษาที่ 3 และกรณีศึกษาที่ 4.....	143
4.63 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลาหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า ของกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4	144
4.64 แรงดันไฟฟ้าหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4.....	145
4.65 กำลังไฟฟ้าสูญเสียหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4.....	146
4.66 กรณีศึกษาที่ 1 ด้วยโหลดแบบพื้นที่แบบพักอาศัยพิจารณาร่วมกับสถานีอัดประจุ ยานยนต์ไฟฟ้า.....	148
4.67 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บ พลังงานแบบเตอรีของแต่ละเอเจนต์ของกรณีศึกษาที่ 1	149
4.68 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 1 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	152
4.69 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 1 ร่วมกับสถานีอัด ประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC.....	152
4.70 แรงดันไฟฟ้าแต่ละโนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	153

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.71 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	154
4.72 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ด้วยอัลกอริทึม MASAC	155
4.73 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA2C	156
4.74 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	157
4.75 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	158
4.76 กรณีศึกษาที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจพิจารณาร่วมกับสถานีอัดประจุ ยานยนต์ไฟฟ้า.....	159
4.77 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บ พลังงานแบบแบตเตอรี่ของแต่ละเอเจนต์ของกรณีศึกษาที่ 2.....	160
4.78 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	163
4.79 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 2 ร่วมกับสถานีอัด ประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	164

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.80	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C	
ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	165
4.81	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG	
ข) ปรับปรุงด้วยอัลกอริทึม MATD3	166
4.82	
แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	167
4.83	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C	
ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	168
4.84	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG	
ข) ปรับปรุงด้วยอัลกอริทึม MATD3	169
4.85	
กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	170
4.86	
กรณีศึกษาที่ 3 ด้วยโพลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า.....	171
4.87	
ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บ พลังงานแบบแบตเตอรี่แต่ละเอเจนต์ของกรณีศึกษาที่ 3 ร่วมกับสถานีอัดประจุ ยานยนต์ไฟฟ้า.....	172
4.88	
แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 3 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	175

สารบัญรูป (ต่อ)

รูปที่	หน้า	
4.89	กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 3 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC.....	176
4.90	แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	177
4.91	แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	178
4.92	แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	179
4.93	กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	180
4.94	กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	181
4.95	กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	182
4.96	กรณีศึกษาที่ 4 ด้วยโหนดแบบผสมผลสารระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า.....	183
4.97	ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่แต่ละเอเจนต์ของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า	184

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.98 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	187
4.99 กำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC	188
4.100 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	189
4.101 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	190
4.102 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	191
4.103 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C	192
4.104 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3	193
4.105 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC	194

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

วิกฤตพลังงานเชื้อเพลิงที่มีราคาสูง และแนวโน้มเชื้อเพลิงในการผลิตไฟฟ้าที่ลดลง พลังงานทางเลือกจึงเป็นหนึ่งในแนวทางแก้ไขปัญหาด้านพลังงาน พลังงานทางเลือกที่กำลังเป็นที่กล่าวถึงในปัจจุบัน เช่น ระบบพลังงานลม ระบบพลังงานเซลล์แสงอาทิตย์ และระบบผลิตพลังงานที่ได้จากน้ำ (Fateh, Eldoromi, and Birjandi, 2022) ซึ่งความต้องการในการใช้พลังงานไฟฟ้ามีแนวโน้มเพิ่มมากขึ้นไม่ว่าจะเป็น ที่อยู่อาศัยที่มีการใช้เครื่องปรับอากาศมากขึ้น และการเติบโตของรถยนต์พลังงานไฟฟ้าที่มีผลต่อพลังงานไฟฟ้าโดยตรง ไม่เพียงแต่ปริมาณยานยนต์ไฟฟ้าที่มากขึ้น สถานีอัดประจุไฟฟ้าก็มากขึ้นด้วยเช่นกัน (Castillo et al., 2022) จึงทำให้แหล่งเชื้อเพลิงธรรมชาติมีการลดลงอย่างรวดเร็ว (Rashedi, Khanam, and Jonkman, 2020) นั่นจึงเป็นเหตุให้มนุษย์ให้ความสนใจพลังงานทางเลือกหรือพลังงานหมุนเวียนเป็นอีกหนึ่งทางเลือกที่สามารถทดแทนพลังงานเหล่านี้ได้

อย่างไรก็ตามพฤติกรรมการใช้ไฟฟ้าของผู้คนมีการเปลี่ยนแปลงอยู่ตลอดเวลาตามยุคสมัย การเข้ามาของรถไฟฟ้าเป็นอีกจุดเปลี่ยนหนึ่งของการเพิ่มกิจกรรมการใช้พลังงานไฟฟ้า จึงทำให้เกิดการใช้ไฟฟ้าที่สูงขึ้น ซึ่งการแก้ปัญหาด้วยการเพิ่มพลังงานหมุนเวียนเข้าสู่ระบบก็เป็นอีกหนึ่งทางเลือกในการแก้ไข แต่ข้อสังเกตของพลังงานหมุนเวียนบางชนิดไม่สามารถผลิตได้ในตอนกลางคืนหรือปัญหาความไม่แน่นอนทางธรรมชาติ ถ้าหากเกิดการการใช้ไฟฟ้าที่มากขึ้นในช่วงเวลาหนึ่งที่กำลังผลิตของโครงข่ายและพลังงานหมุนเวียนไม่เพียงพอ นั่นอาจทำให้พลังงานไฟฟ้าไม่เพียงพอต่อผู้ใช้งาน (Saldarriaga-Zuluaga et al., 2022) ทางเลือกในการแก้ปัญหาที่กำลังเป็นที่นิยมก็คือวิธีการติดตั้งตัวเก็บประจุไฟฟ้าต่อเข้ากับระบบโครงข่ายไฟฟ้า เนื่องจากตัวเก็บประจุแบบแบตเตอรี่สามารถจ่ายพลังงานไฟฟ้าแทนที่พลังงานหมุนเวียนได้ในสถานการณ์ที่กำลังผลิตไม่เพียงพอต่อผู้ใช้ไฟฟ้า ในการที่นำแบตเตอรี่มาติดตั้งในระบบไฟฟ้านั้นจำเป็นต้องคำนึงถึง การไหลของพลังงานไฟฟ้า ขนาดของแบตเตอรี่ และตำแหน่งในการวางที่เหมาะสม เพื่อความเสถียรภาพและการลงทุนที่เหมาะสม (Wong et al., 2019)

เครื่องมือที่ใช้ในการจัดการพลังงานที่เหมาะสมมีอยู่หลากหลายวิธี ปัจจุบันวิธีการของปัญญาประดิษฐ์ (Artificial Intelligent: AI) ได้รับความนิยมเป็นอย่างมาก เนื่องจากมีความสามารถในการหาค่าที่เหมาะสมต่อระบบไฟฟ้าได้อย่างดี ไม่ว่าจะเป็นเทคนิค วิธีการเมตาฮีริสติก (Meta-heuristics Method) หรือ การเรียนรู้โดยเครื่อง (Machine Learning: ML) ได้แบ่งเป็นสามชนิดคือ 1. การเรียนรู้แบบมีผู้สอน (Supervised Learning) 2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) 3. การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning: RL) จากนั้นถูกพัฒนาจนมาถึงการเรียนรู้เชิงลึก (Deep Learning: DL) ซึ่งมีลักษณะที่คล้ายกับการเรียนรู้โดยเครื่อง แต่การทำงานของ การเรียนรู้เชิงลึกมีความซับซ้อนมากขึ้นโดยใช้โครงข่ายประสาทที่มีหลายชั้น (Deep Neural Network) เพื่อทำงานในระดับมากขึ้น และสามารถจำลองแบบจำลองทางคณิตศาสตร์ได้ซับซ้อน ทำให้สามารถประมวลผลของข้อมูลอย่างมหาศาลได้ และการเรียนรู้แบบเสริมกำลังนั้นก็ได้รับการพัฒนา เช่นเดียวกันสามารถวิเคราะห์ข้อมูลแบบซับซ้อน (Hubert and Karolina, 2022) รวมถึงการพัฒนาทำงานลักษณะที่เอเจนต์มากกว่าหนึ่งตัวได้เรียกว่า การเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ (Multi Agent Deep Reinforcement Learning: MADRL)

ความนิยมของปัญญาประดิษฐ์ได้มากขึ้นหลังจากการแข่งขันหมากล้อมที่ปัญญาประดิษฐ์สามารถเอาชนะผู้เล่นมนุษย์ได้ด้วยความสามารถในการเรียนรู้กฎกติกาการเล่นที่ซับซ้อน (Silver et al., 2016) นับตั้งแต่นั้นมาจึงเกิดกระแสให้ผู้คนหันมาสนใจการใช้ปัญญาประดิษฐ์มากขึ้นจนเกิดงานวิจัยหลากหลาย ในการประยุกต์ใช้ทางด้านไฟฟ้าก็เช่นกัน ไม่ว่าจะเป็นการจัดการพลังงานกำลังผลิตไฟฟ้าภายในไมโครกริด เพื่อหาช่วงเวลาที่เหมาะสมในการชาร์จแบตเตอรี่และคลายพลังงานของแบตเตอรี่ที่เหมาะสมต่อระบบไมโครกริด ซึ่งการเรียนรู้เชิงลึกแบบคิว (Deep Q-learning) สามารถประยุกต์ใช้ได้ดีในการหาค่าที่เหมาะสมต่อระบบ (Alabdullah and Abido, 2022) การใช้เพื่อระบุตำแหน่งที่ตั้งของพลังงานหมุนเวียนที่เหมาะสมในไมโครกริด (Wang et al., 2021) อีกทั้งอัลกอริทึมแบบ DDPG (Deep Deterministic Policy Gradient Algorithm: DDPG) และ อัลกอริทึมแบบ PPO (Proximal Policy Optimization Algorithm: PPO) ได้ถูกใช้ในการจัดการแรงดันในระบบไมโครกริดอีกด้วย (Wang et al., 2021), (Guo et al., 2021) ซึ่งที่ผ่านมามีการจัดการพลังงานนั้นอยู่บนพื้นฐาน การแก้ปัญหาความต้องการพลังงาน การลดพลังงานสูญเสียและความคุ้มค่าการลงทุนในการแก้ไข้ปัญหา

วิทยานิพนธ์ฉบับนี้ นำเสนอวิธีการจัดการพลังงานที่เหมาะสมในไมโครกริดในกรณีต่าง ๆ ด้วยวิธีการหาขนาดกำลังผลิตและตำแหน่งที่ตั้งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยใช้เทคนิคการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ เพื่อวิเคราะห์หาแนวทางการ

ลดกำลังสูญเสียในระบบ การปรับปรุงแรงดันไฟฟ้า และวิเคราะห์ต้นทุนของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อวิเคราะห์การไหลของกำลังไฟฟ้าของระบบทดสอบหลังการเพิ่มโหลดที่פקอาศัย โหลดพื้นที่ธุรกิจ และโหลดสถานีอัดประจุไฟฟ้ายานยนต์

1.2.2 เพื่อประยุกต์ใช้การเรียนรู้แบบเสริมกำลังเชิงลึกแบบหลายเอเจนต์ในการจัดการพลังงานที่เหมาะสม การลดพลังงานสูญเสีย ปรับปรุงแรงดันไฟฟ้า และความคุ้มค่าในการลงทุน

1.2.3 เพื่อประเมินกำลังไฟฟ้าสูญเสียของระบบ แรงดันไฟฟ้า และต้นทุนของระบบหลังจากการปรับปรุง และเปรียบเทียบประสิทธิภาพความแม่นยำของการเรียนรู้แบบเสริมกำลังเชิงลึกแบบหลายเอเจนต์ในแต่ละอัลกอริทึม

1.3 ข้อตกลงเบื้องต้น

1.3.1 การจำลองโครงข่ายไฟฟ้าอยู่บนพื้นฐานภาษา Python ด้วยไลบรารี Pandapower โดยใช้ระบบทดสอบมาตรฐาน IEEE 33 โหนด ในการจำลองกรณีศึกษาต่าง ๆ

1.3.2 การใช้ปัญญาประดิษฐ์หาค่าที่เหมาะสมที่สุดอยู่บนพื้นฐานภาษา Python ด้วยไลบรารี Rllib และ Gymnasium ได้แก่ Multi Agent Advantage Actor-Critic Algorithm (MAA2C), Multi Agent Asynchronous Advantage Actor-Critic (MAA3C), Multi Agent Deep Deterministic Policy Gradient Algorithm (MADDPG), Multi Agent Twin-Delayed Deep Deterministic Policy Gradient Algorithm (MATD3), Multi Agent Soft Actor-Critic (MASAC)

1.4 ขอบเขตของการวิจัย

1.4.1 การจำลองระบบโครงข่ายไฟฟ้าร่วมกับโหลดที่อยู่อาศัย โหลดพื้นที่ธุรกิจ และสถานีอัดประจุไฟฟ้า โดยสมมติเป็นระบบแบบสามเฟสสมดุล

1.4.2 ข้อมูลที่ใช้ในการจำลองระบบไมโครกริดเป็นข้อมูลแบบรายวันมีความละเอียด 15 นาที โดยมีข้อมูลโหลดพื้นที่แบบพักอาศัย โหลดพื้นที่ธุรกิจ กำลังการผลิตของพลังงานแสงอาทิตย์ กำลังผลิตพลังงานกังหันลม และระบบกักเก็บพลังงานแบบแบตเตอรี่ ในหนึ่งวันจะมีข้อมูลอย่างละ 96 ข้อมูล

1.4.3 ปรับพารามิเตอร์ของการเรียนเชิงลึกที่เสริมกำลังแบบหลายเอเจนต์ให้เหมาะสมต่อการเปรียบเทียบประสิทธิภาพ เพื่อวิเคราะห์ประสิทธิภาพการเรียนรู้เชิงลึกเสริมกำลังแบบหลายเอเจนต์ในเงื่อนไขที่พารามิเตอร์เหมาะสมกัน

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ได้รับความรู้และมีความสามารถจำลองการไหลของกำลังไฟฟ้า การหาตำแหน่งที่ติดตั้งและขนาดที่เหมาะสม ของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

1.5.2 ได้รู้ถึงวิธีการประยุกต์ใช้การเรียนรู้เชิงลึกหลายเอเจนต์ในการหาค่าที่เหมาะสม

1.5.3 ได้รู้ถึงข้อดีและข้อเสียแต่ละอัลกอริทึม เพื่อนำอัลกอริทึมไปใช้ในการแก้ปัญหาต่าง ๆ ให้เหมาะสม

1.5.4 ได้เผยแพร่งานวิจัยในการประยุกต์ใช้การเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ ในระบบโครงข่ายไฟฟ้า

1.6 รายละเอียดในวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้ประกอบด้วย 5 บท 3 ภาคผนวก ซึ่งได้จัดเรียงตามความเหมาะสม ดังนี้

บทที่ 1 บทนำ กล่าวถึงความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์ของการวิจัย ข้อตกลงเบื้องต้น ขอบเขตของการวิจัย ขั้นตอนการดำเนินงาน และประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย รวมทั้งแนะนำเนื้อหาพอส่งเขปที่เป็นองค์ประกอบของวิทยานิพนธ์ฉบับนี้

บทที่ 2 กล่าวถึงทฤษฎี ปรัชญาวิศวกรรมกรรม และงานวิจัยที่เกี่ยวข้องกับความเป็นมาของระบบจำหน่าย และการเรียนรู้แบบเสริมกำลังเชิงลึกแบบหลายเอเจนต์

บทที่ 3 กล่าวถึงวิธีการดำเนินงานวิจัยสำหรับ

บทที่ 4 กล่าวถึงผลการจำลอง

บทที่ 5 กล่าวถึงบทสรุปและข้อเสนอแนะ

ภาคผนวก ก ชุดคำสั่งภาษา Python ที่ใช้ในวิทยานิพนธ์

ภาคผนวก ข ระบบจำหน่ายไฟฟ้าที่ใช้ในงานวิจัย

ภาคผนวก ค บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่

บทที่ 2


ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.1 กล่าวนำ

ปัจจุบันความต้องการพลังงานไฟฟ้ามีแนวโน้มที่สูงขึ้นเรื่อย ๆ อันเนื่องมาจากการเปลี่ยนแปลงของอากาศที่คาดเดาได้ยาก ไม่ว่าจะเป็นโพลดในพื้นที่พักอาศัย หรือพื้นที่ธุรกิจ ที่มีการใช้พลังงานไฟฟ้าที่มากในช่วงกลางวัน และกลางคืน นอกจากนั้นการเข้ามามีบทบาทของยานยนต์ไฟฟ้า จึงทำให้มีการสร้างสถานีอัดประจุยานยนต์ไฟฟ้าที่มากขึ้น ซึ่งส่งผลกระทบต่อระบบโครงข่ายไฟฟ้าโดยตรง โดยเฉพาะแรงดันไฟฟ้าตกในระบบ และกำลังไฟฟ้าสูญเสีย หากเกิดบ่อยครั้งอาจทำให้เครื่องใช้ไฟฟ้า หรือเครื่องจักรเสียหายได้ การใช้วิธีการหาค่าที่เหมาะสมจึงเป็นสิ่งสำคัญ เพื่อการหาตำแหน่ง และขนาดของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ ซึ่งเป็นส่วนสำคัญในการปรับปรุงแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียในระบบโครงข่ายไฟฟ้า โดยอัลกอริทึมที่ใช้ในการหาค่าที่เหมาะสม และทฤษฎีเบื้องต้นของระบบไฟฟ้ามียรายละเอียดดังนี้

2.2 ระบบไฟฟ้ากำลัง

ระบบไฟฟ้ากำลัง หมายถึง ระบบโครงข่ายที่รวบรวมระบบ และอุปกรณ์ต่าง ๆ เข้าด้วยกัน เพื่อการเปลี่ยนรูปพลังงานที่ไม่ใช่ไฟฟ้าไปเป็นพลังงานไฟฟ้าในรูปแบบที่ต้องการ และส่งผ่านพลังงานไฟฟ้าด้วยระดับแรงดันไฟฟ้าสูงไปยังแหล่งหรือระบบใช้งานในรูปโครงข่ายปิดขนาดใหญ่ การจัดส่งไฟฟ้าให้กับผู้บริโภค โดยส่งจ่ายไฟฟ้าจากสถานีไฟฟ้าผ่านสายส่งไฟฟ้าแรงสูง สถานีไฟฟ้าย่อย และหม้อแปลงไฟฟ้าทำหน้าที่แปลงไฟฟ้าให้สูงขึ้นหรือลดลงได้ตามความต้องการให้มีความเหมาะสมสำหรับบริการให้กับผู้ใช้ไฟฟ้า โดยแรงดันไฟฟ้าที่ใช้ในระบบจำหน่ายไฟฟ้ามีหลายระดับ เช่น 22 kV หรือ 24 kV ซึ่งระดับแรงดัน 22 kV จะใช้ในการไฟฟ้าส่วนภูมิภาค (กฟภ.) ส่วนแรงดันไฟฟ้า 24 kV จะใช้ในการไฟฟ้านครหลวง (กฟน.) ได้แก่กรุงเทพฯ นนทบุรี และสมุทรปราการแล้วส่งไปยังหม้อแปลงเพื่อลดระดับแรงดันเป็นแรงดันต่ำแล้วจำหน่ายสู่บ้านผู้บริโภค เช่น ที่อยู่อาศัย โรงงานอุตสาหกรรม หรือสถานีอัดประจุไฟฟ้า โครงสร้างพื้นฐานของระบบไฟฟ้าแสดงดังรูปที่ 2.1 โดยโครงสร้างที่สำคัญของระบบจะถูกแบ่งย่อยออกเป็น 3 ระบบ ดังนี้



รูปที่ 2.1 โครงสร้างระบบไฟฟ้า (ธีระพงษ์ บุญรักษา, 2562)

2.2.1 ระบบผลิตกำลังไฟฟ้า

ระบบผลิตกำลังไฟฟ้า หมายถึง โรงไฟฟ้า ซึ่งประกอบด้วยเครื่องกำเนิดไฟฟ้า เช่น โรงไฟฟ้าพลังงานน้ำ โรงจักรไอน้ำ โรงจักรแบบกังหันแก๊ส โรงไฟฟ้านิวเคลียร์ และโรงจักรใช้ถ่านหิน เป็นต้น เลือกใช้โรงไฟฟ้าต้องพิจารณาปัจจัยต่าง ๆ เช่น สภาพแวดล้อม ทรัพยากร และราคาเป็นต้น โดยทั่วไปมีระดับแรงดันไฟฟ้าต้อง แต่ระดับ 11 kV ถึง 27 kV โดยใช้หม้อแปลงไฟฟ้ากำลังทำหน้าที่ เปลี่ยนระดับแรงดันไฟฟ้า โรงไฟฟ้าประกอบด้วยส่วนสำคัญ 3 ส่วน ดังต่อไปนี้ (ณัฐพล ชาตีสุข, 2561)

1) ระบบผลิตกระแสไฟฟ้าประกอบด้วย ตัวต้นกำลังหรือเครื่องกังหันไฟฟ้าทำหน้าที่เป็นตัวหมุนเครื่องกำเนิดไฟฟ้า แรงดันไฟฟ้าที่ผลิตออกมาจะเป็นแรงดันไฟฟ้า 3 เฟส โดยส่วนใหญ่ไม่เกิน 20 kV หากมากกว่า 20 kV จะก่อให้เกิดอันตรายต่อฉนวนตัวนำและส่งผลกระทบต่ออายุการใช้งานของโรงไฟฟ้า

2) ส่วนลานไกไฟฟ้า เป็นส่วนที่ทำหน้าที่เปลี่ยนแปลงระดับแรงดันไฟฟ้าที่ผลิตจากเครื่องกำเนิดไฟฟ้าให้สูงขึ้นแล้วส่งต่อไปยังสถานีไฟฟ้าที่อยู่ห่างไกล เพื่อลดความสูญเสียในระบบไฟฟ้าซึ่งประกอบด้วย หม้อแปลงไฟฟ้ากำลังทำหน้าที่แปลงระดับแรงดันไฟฟ้าและอุปกรณ์ระบบป้องกันทางไฟฟ้า

3) ส่วนที่ทำหน้าที่ป้องกันการเดินเครื่องและการควบคุมไฟฟ้า ได้แก่ การป้องกันเครื่องกำเนิดไฟฟ้า หม้อแปลงไฟฟ้ากำลัง และรีเลย์ตรวจจับ ความผิดปกติของระบบไฟฟ้า ความสามารถในการผลิตหรือกำลังการผลิตถูกกำหนดเป็น kWh หรือ MWh

2.2.2 ระบบส่งจ่ายไฟฟ้า

เป็นระบบที่รับพลังงานไฟฟ้าจากระบบผลิตกำลังไฟฟ้า ซึ่งสามารถส่งพลังงานไฟฟ้าเป็นระยะทางที่ไกล ๆ ได้ เนื่องจากระยะทางจากระบบผลิตกำลังไฟฟ้าจะอยู่ห่างไกลจากโหลดมาก โดยประเทศไทยมีระดับแรงดันไฟฟ้าตั้งแต่ระดับ 115 kV จนถึงระดับ 500 kV สำหรับระบบส่งกำลังไฟฟ้าแบ่งออกเป็น 2 ส่วนได้ดังนี้

- 1) ระบบไฟฟ้าเหนือศีรษะ เป็นสายส่งตัวนำบนเสาส่งผ่านที่โยงจากสถานีไฟฟ้าหนึ่งไปยังอีกสถานีไฟฟ้าหนึ่ง การบำรุงรักษาง่ายและตรวจสอบความผิดปกติของระบบไฟฟ้าได้ง่าย
- 2) ระบบไฟฟ้าใต้ดิน เป็นสายส่งตัวนำถูกฝังลงไปในดินตามรางเดินสาย เหมาะสำหรับการติดตั้งในที่ชุมชนหรือพื้นที่แออัดมีความต้องการพลังงานไฟฟ้าหรือโหลดสูง ๆ แต่การบำรุงรักษาทำได้ไม่สะดวกและมีราคาในการติดตั้งและซ่อมบำรุงค่อนข้างสูง

จุดมุ่งหมายหลักของระบบส่งกำลังไฟฟ้า ได้แก่ การส่งผ่านกำลัง ไฟฟ้าจากแหล่งผลิตไปยังผู้ใช้ไฟฟ้า การส่งกำลังไฟฟ้าไปยังศูนย์กลางการจ่ายโหลด การเชื่อมโยงระบบส่งกำลังไฟฟ้าเข้าด้วยกันการเพิ่มความเชื่อถือได้ และการลดความสูญเสียในระบบไฟฟ้า ดังนั้นระบบส่งกำลังไฟฟ้ามี 3 ระดับ ดังต่อไปนี้

- 1) ไฟฟ้าแรงสูง (High voltage) มีระดับแรงดันไฟฟ้าไม่เกิน 300 kV
- 2) ไฟฟ้าแรงสูงพิเศษ (Extra high voltage) มีระดับแรงดันไฟฟ้าตั้งแต่ 300 kV
- 3) ไฟฟ้าแรงสูงยิ่ง (Ultra high voltage) มีระดับแรงดันไฟฟ้าตั้งแต่ 765 kV ขึ้นไป

2.2.2 ระบบจำหน่ายไฟฟ้า

ระบบจำหน่ายไฟฟ้าเป็นระบบที่รับพลังงานไฟฟ้าที่ถูกสร้างมาจากระบบผลิตกำลังไฟฟ้า โดยผ่านระบบส่งกำลังไฟฟ้าเพื่อกระจายกำลังไฟฟ้าไปยังโหลดของผู้ใช้ไฟฟ้า ซึ่งมีส่วนประกอบที่สำคัญ คือ สถานีไฟฟ้าทำหน้าที่ปรับระดับแรงดันไฟฟ้าให้กับผู้ใช้ไฟฟ้า โดยส่วนใหญ่ระบบจำหน่ายไฟฟ้ามีระดับแรงดันไฟฟ้าครอบคลุมทั้งทางด้านปฏุมภูมิและทุติยภูมิ สำหรับประเทศไทยไม่เกิน 115 kV โดยหน่วยงานหลักของระบบไฟฟ้าในประเทศไทยมีหน่วยงานที่ทำหน้าที่รับผิดชอบในการจ่ายไฟฟ้าอยู่ 2 หน่วยงานหลัก ได้แก่

- 1) การไฟฟ้านครหลวง (Metropolitan Electricity Authority: MEA) มีหน้าที่ให้บริการด้านการจำหน่ายไฟฟ้าให้กับผู้ใช้ไฟฟ้า โดยเป็นผู้รับซื้อไฟฟ้าจากการไฟฟ้าฝ่ายผลิต และเป็นผู้ผลิตไฟฟ้าจากแหล่งพลังงานหมุนเวียนขนาดเล็ก เพื่อจัดจำหน่ายไฟฟ้าให้กับผู้ใช้ไฟฟ้าภายใน

เขตกรุงเทพมหานครฯ สมุทรปราการ และนนทบุรี การไฟฟ้านครหลวงมีระดับแรงดันไฟฟ้าที่ใช้งานคือ 115 kV, 69 kV, 24 kV, 400 V และ 240 V

2) การไฟฟ้าส่วนภูมิภาค (Provincial Electricity Authority: PEA) มีหน้าที่ให้บริการด้านการจำหน่ายไฟฟ้าให้กับผู้ใช้ไฟฟ้าทั้งภายในและภายนอกประเทศ โดยเป็นผู้รับซื้อไฟฟ้าจากการไฟฟ้าฝ่ายผลิต และผู้ผลิตไฟฟ้าจากแหล่งพลังงานหมุนเวียนขนาดเล็ก การไฟฟ้าส่วนภูมิภาคมีระดับแรงดันไฟฟ้าที่ใช้งานคือ 115 kV, 69 kV, 33 kV, 22 kV, 400 V และ 230 V

2.3 โหลดของระบบไฟฟ้า

การปรับปรุงระบบไฟฟ้าให้มีความเสถียรและความมั่นคงจำเป็นต้องคำนึงถึงความต้องการพลังงานไฟฟ้าภายในระบบไฟฟ้าในแต่ละโครงข่าย เนื่องจากพฤติกรรมแต่ละโครงข่ายมีการใช้พลังงานไฟฟ้าที่ไม่เท่ากัน ดังนั้น ความต้องการกำลังงานไฟฟ้าของผู้ใช้ไฟฟ้าจึงเป็นปัจจัยที่สำคัญสำหรับกำหนดการผลิตพลังงานไฟฟ้า เพื่อให้เพียงพอต่อความต้องการและไม่เหลือใช้โดยเปล่าประโยชน์ การศึกษาลักษณะของโหลดผู้ใช้ไฟฟ้าจึงสำคัญมากในการขยายระบบไฟฟ้า การผลิตไฟฟ้า การส่งจ่ายไฟฟ้าและการจำหน่ายไฟฟ้า ยังคำนึงถึงการควบคุมการส่งจ่ายพลังงานไฟฟ้าไปยังผู้ใช้ไฟฟ้าได้อย่างต่อเนื่อง โหลดของระบบไฟฟ้า ได้แก่ โรงงานอุตสาหกรรมห้างสรรพสินค้า บ้านเรือนสำนักงาน เป็นต้น โหลดแต่ละชนิดก็มีการใช้พลังงานแตกต่างกันไปตามช่วงเวลา (ธีระพงษ์ บุญรักษา, 2562)

2.3.1 ผลกระทบต่อระบบไฟฟ้าเมื่อมีการประจุไฟฟ้าของยานยนต์ไฟฟ้า

ยานยนต์ไฟฟ้าและสถานีประจุไฟฟ้าเมื่อถูกนำเข้ามาเชื่อมต่อในระบบไฟฟ้า โดยมุ่งประเด็นไปที่ผลกระทบที่อาจจะเกิดขึ้นกับโครงสร้างพื้นฐานของระบบไฟฟ้า นั่นคือเรื่องของแรงดันตกภายในระบบไฟฟ้า และกำลังไฟฟ้าสูญเสีย ซึ่งเกิดจากการอัดประจุไฟฟ้าให้กับยานยนต์ไฟฟ้าเป็นเหมือนการเพิ่มโหลดให้กับระบบไฟฟ้ามากขึ้น

เมื่อมีโหลดมากขึ้นภายในระบบสิ่งที่ตามมา นั่นคือ ขนาดหม้อแปลงที่ไม่เพียงพอต่อการรับโหลดภายในระบบไฟฟ้าถูกติดตั้งสถานีอัดประจุ ณ ปัจจุบัน หม้อแปลงได้ออกแบบขนาดตามพิกัดโหลดในพื้นที่นั้น ๆ หรือตามโหลดปัจจุบันที่มีอยู่ แต่หากในอนาคตมีการเพิ่มยานยนต์ไฟฟ้าเข้ามาในระบบจำหน่ายไฟฟ้า ต้องมีการปรับปรุงระบบไฟฟ้าเพื่อเตรียมพร้อมรองรับสำหรับการนำยานยนต์ไฟฟ้าเข้ามาใช้ในระบบจำหน่ายไฟฟ้า แม้ว่าหม้อแปลงจำหน่ายไฟฟ้าสามารถทนต่อโหลดเกินได้

ถึง 160% แม้กระทั่งขนาดของสายไฟฟ้าอาจไม่เพียงพอต่อโหลดที่มีขนาดมากขึ้นในอนาคต การเกิดกำลังสูญเสียที่มากขึ้นก็เช่นเดียวกัน อาจรวมไปถึงการเกิดแรงดันไฟฟ้าไม่สมดุล ความถี่ตก และการเกิดฮาร์โมนิกของกระแสไฟฟ้าในระบบ

2.4 การคำนวณการไหลของกำลังไฟฟ้า

ระบบสายส่งกำลังไฟฟ้าในปัจจุบันมีการเชื่อมโยงสถานีกำลังไฟฟ้าหลาย ๆ แห่งโดยการ ใช้สายส่งเชื่อมโยงถึงกันเพื่อส่งจ่ายกำลังไฟฟ้าให้กับกลุ่มโหลดการใช้งานไฟฟ้า ซึ่งมีการเปลี่ยนแปลงอยู่ตลอดเวลา ดังนั้น จึงต้องวางแผนการผลิตกำลังไฟฟ้าให้เพียงพอต่อปริมาณความต้องการ การวิเคราะห์การไหลของกำลังไฟฟ้าจึงมีความสำคัญต่อระบบไฟฟ้าเมื่อมีการขยายโหลดการใช้งานไฟฟ้าเพิ่มขึ้น การวิเคราะห์กำลังไฟฟ้าจะช่วยให้ทราบว่าขณะเกิดสภาวะผิดปกติพร้อมนั้นมีกำลังไฟฟ้าไหลไปยังจุดผิดปกติที่มีขนาดต่ำสุดหรือสูงสุดเท่าใด และยังช่วยในการวางแผนการสร้างสถานีไฟฟ้าเพื่อให้สมดุลกับกลุ่มโหลดในระบบ (Saadat, 1999)

การศึกษาการไหลของกำลังไฟฟ้าเป็นการคำนวณค่ากำลังไฟฟ้าจริง และกำลังไฟฟ้ารีแอกทีฟในสายส่งแต่ละวงจร รวมถึงการหาค่าขนาดและมุมเฟสของค่าแรงดันไฟฟ้าในแต่ละโหนดของเครื่องกำเนิดไฟฟ้าและโหลดผู้ใช้ไฟฟ้าในแต่ละช่วงเวลาที่มีการผลิตและส่งจ่ายกำลังไฟฟ้า ค่าที่ได้จากการคำนวณการไหลของกำลังไฟฟ้าจะนำมาใช้ในการวางแผนการส่งจ่ายกำลังไฟฟ้าจากเครื่องกำเนิดไฟฟ้าไปยังผู้ใช้ไฟฟ้าโดยไม่ทำให้สายส่งเกิดโหลดเกินรวมถึงมีระดับแรงดันไฟฟ้าอยู่ในเกณฑ์มาตรฐานที่ยอมรับได้

2.4.1 พารามิเตอร์ของสายส่ง

สายส่งที่ใช้ในการส่งจ่ายกำลังไฟฟ้าจากแหล่งผลิตไฟฟ้าไปยังผู้ใช้ไฟฟ้าเป็นระยะทางไกล ซึ่งมีพารามิเตอร์ต่าง ๆ ที่มีความสำคัญสำหรับการวิเคราะห์ระบบไฟฟ้ากำลัง ประกอบด้วย ความต้านทาน ความเหนี่ยวนำ ความจุไฟฟ้า และความนำไฟฟ้าเป็นพารามิเตอร์ของสายส่งไฟฟ้า

ความต้านทานของสายส่งจะมีค่ามากหรือน้อยนั้นขึ้นอยู่กับองค์ประกอบหลัก คือ พื้นที่หน้าตัดของสายส่ง ความยาวของสายส่ง และชนิดวัสดุที่ใช้สร้างสายส่ง ความต้านทานของสายส่งนั้นหากมีค่ามากจะทำให้เกิดแรงดันตกในสายส่งและเกิดกำลังงานสูญเสียในสายส่ง และความนำไฟฟ้าของสายส่งเกิดจากกระแสรั่วไหลที่ฉนวนลูกถ้วยโดยทั่วไปจะมีค่าน้อยมากจึงไม่ค่อยนำมาคิดในการวิเคราะห์ระบบส่งกำลังไฟฟ้า

ความเหนี่ยวนำของสายส่งถูกนิยามจากสมการแรงดันไฟฟ้าเหนี่ยวนำที่เกิดจากการเปลี่ยนแปลงของฟลักซ์คัลลิ่งเมื่อมีกระแสไฟฟ้าสลับไหลในสายส่ง ส่งผลให้จำนวนของฟลักซ์คัลลิ่งเป็นสัดส่วนโดยตรงกับกระแสไฟฟ้า ดังนั้น แรงดันไฟฟ้าเหนี่ยวนำจะเป็นสัดส่วนโดยตรงกับอัตราการเปลี่ยนแปลงของกระแสไฟฟ้า

ความจุไฟฟ้าของสายส่ง เป็นพารามิเตอร์ที่สำคัญของสายส่งที่เกิดขึ้นกับสายส่ง เนื่องจากความต่างศักย์ระหว่างสายส่งหรือระหว่างสายส่งกับดิน ความจุไฟฟ้าระหว่างสายส่ง คือ จำนวนประจุไฟฟ้าต่อหนึ่งหน่วยความต่างศักย์ไฟฟ้า ซึ่งความจุระหว่างสายส่งกับสายส่งจะมีค่ามากกว่าระหว่างสายส่งกับดิน

2.4.2 หลักการควบคุมการไหลของกำลังไฟฟ้า

การศึกษาการไหลของกำลังงานไฟฟ้าในสายส่งเพื่อให้เราทราบว่ากระแสไฟฟ้าที่ไหลผ่านอุปกรณ์หรือผ่านสายส่งแต่ละเส้น รวมทั้งแรงดันที่โหนดต่าง ๆ ว่าอยู่ที่เกณฑ์ที่เหมาะสม หรือไม่ สามารถทราบสถานะในการจ่ายไฟฟ้าของระบบปัจจุบันและอนาคต โดยการพยากรณ์ความต้องการโหลด วิธีการแก้ปัญหาสำหรับการศึกษาการไหลของกำลังไฟฟ้ามีด้วยกันหลายวิธี ในปัจจุบันมีการใช้คอมพิวเตอร์เข้ามาช่วยเพื่อให้ได้คำตอบที่เร็วที่สุด โดยใช้วิธีการแก้ปัญหาของ เกาส์-ไซเดล และวิธีแก้ปัญหานิวตัน-ราฟสัน เข้ามาช่วยในการแก้ปัญหา

2.4.3 ชนิดของโหนด

โหนดแต่ละชนิดนั้นมีข้อกำหนดหรือค่าพารามิเตอร์ต่าง ๆ ประกอบด้วย ขนาดแรงดันไฟฟ้า ($|V|$) มุมของแรงดันไฟฟ้า ($\angle V$) กำลังไฟฟ้าจริง (P) กำลังไฟฟ้าร์แอกทีฟ (Q) โดยทั่วไปแล้วในแต่ละโหนดจะทราบค่าพารามิเตอร์สองค่า อีกสองค่าสามารถหาได้จากการคำนวณดังตารางที่ 2.1

สแลคโหนด (Slack Node) หรือเรียกว่าสวิงโหนด (Swing Node) หรือโหนดอนันต์ (Infinite Node) หรือโหนดอ้างอิง (Reference Node) โหนดชนิดนี้มีขนาดแรงดันไฟฟ้า มุมคงที่และโดยทั่วไปให้เป็น มุมศูนย์โดยใช้โหนดนี้ไปใช้เป็นโหนดอ้างอิง โหนดนี้ถือว่าเป็นแหล่งผลิตพลังงานไฟฟ้าขนาดใหญ่หรือมีเครื่องกำเนิดไฟฟ้าต่ออยู่ที่สามารถให้กำลังไฟฟ้าตามที่ต้องการ โดยขนาดแรงดันไฟฟ้าและความถี่ไม่เปลี่ยนแปลงพารามิเตอร์ที่กำหนดให้คงที่ของโหนดนี้คือ ขนาดแรงดันไฟฟ้าและมุมของแรงดันไฟฟ้า โดยจะคำนวณหา กำลังไฟฟ้าจริง (P) และกำลังไฟฟ้าร์แอกทีฟ (Q)

โนดเครื่องกำเนิดไฟฟ้า (Generator node) เป็นโนดที่มีเครื่องกำเนิดไฟฟ้าต่ออยู่ หรือมีโหลดต่อร่วมอยู่กับแหล่งกำเนิดไฟฟ้า โหนดเครื่องกำเนิดไฟฟ้าสามารถควบคุมแรงดันไฟฟ้าให้มีขนาดคงที่ ดังนั้นขนาดแรงดันไฟฟ้าโนดมีค่าคงที่ กำลังไฟฟ้าจริงมีค่าคงที่ โหนดชนิดนี้อาจเรียกว่า PV Node บางทีอาจกำหนดให้มี กำลังไฟฟ้าจริงและกำลังไฟฟ้รีแอกทีฟคงที่หรือ PQ Node ถ้าโนดเป็นชนิด PV Node พารามิเตอร์ที่ต้องการหา คือ Q และ $\angle V$ ถ้าเป็นชนิด PQ Node พารามิเตอร์ที่ต้องการหา คือ $|V|$ และ $\angle V$

โนดโหลด (Load Node) เป็นโนดที่มีโหลดต่ออยู่ซึ่งทราบค่ากำลังไฟฟ้าจริง และกำลังไฟฟ้รีแอกทีฟ หรือเรียกว่า PQ Node ค่าพารามิเตอร์ที่ต้องการหา คือ ขนาดแรงดันไฟฟ้า และมุมแรงดันไฟฟ้า $\angle V$ การศึกษาการไหลของโหลดทุกวิธีจะเน้นหาแรงดันที่โนดต่าง ๆ ของระบบ ซึ่งจะนำไปสู่การหาค่ากระแสในสายส่ง กำลังไฟฟ้าจริง และกำลังไฟฟ้รีแอกทีฟ

ตารางที่ 2.1 พารามิเตอร์ของโนดแต่ละชนิด

ประเภทของโนด	ตัวแปรที่ทราบค่า	ตัวแปรที่ไม่ทราบค่า
สแลคโนด หรือสวิงโนด	$ V , \angle V$	P, Q
โนดเครื่องกำเนิดไฟฟ้า หรือ PV Node	$ V , P$	$Q, \angle V$
โนดโหลด หรือ PQ Node	P, Q	$ V , \angle V$

สมการการไหลของกำลังไฟฟ้าที่ใช้ในการแก้ไขปัญหาของระบบมีอยู่สองสมการที่สำคัญ คือ สมการหาแรงดันไฟฟ้าและสมการหาลำกำลังไฟฟ้า โดยสมการกำลังไฟฟ้าที่เข้าโนด k ใด ๆ ในระบบไฟฟ้ากำลังมีความสัมพันธ์กับแรงดันไฟฟ้าและกระแสไฟฟ้า แสดงดังสมการที่ (2.1)

$$S_k = V_k I_k^* \quad (2.1)$$

กำหนดให้ V_k คือ แรงดันไฟฟ้า และ I_k คือ กระแสไฟฟ้า

เป็นสมการกำลังไฟฟ้าที่หามาจากสมมติฐานที่กำลังไฟฟ้รีแอกทีฟมีค่าเป็นบวกเสมอ สำหรับโหลดล่าหลัง (Lagging load) หรือ I ตามหลังเวกเตอร์ P การใช้สมการที่ (2.1) ต้อง

ทำความเข้าใจว่าขึ้นอยู่กับสมมติฐานอะไร กำลังไฟฟ้าถูกนิยามเป็นกำลังไฟฟ้าที่ไหลเข้าโนดตามทิศทางกระแส I_k ที่ไหลเข้าโนด สมการแรงดันไฟฟ้าที่โนด k สามารถหาได้โดยสมการที่ (2.3) และหากระแสได้จากสมการที่ (2.4)

$$S_k = P_k + jQ_k = V_k I_k^* \quad (2.2)$$

$$S_k^* = P_k - jQ_k = (V_k I_k^*)^* \quad (2.3)$$

$$I_k = \frac{P_k - jQ_k}{V_k^*} \quad (2.4)$$

จากสมการเมตริก $[I_{BUS}] = [Y_{BUS}][V_{BUS}]$ สามารถเขียนสมการหากระแสไฟฟ้าที่โนด k ใด ๆ คือ I_k หาได้จากสำหรับระบบไฟฟ้าที่มี n โหนด

$$I_k = Y_{k1}V_1 + Y_{k2}V_2 + \dots + Y_{kn}V_n = \sum_{i=1}^n Y_{ki}V_i \quad (2.5)$$

แทนค่ากระแสเข้าไปในสมการที่ (2.4) จะได้

$$Y_{k1}V_1 + Y_{k2}V_2 + \dots + Y_{kk}V_k + \dots + Y_{kn}V_n = \frac{P_k - jQ_k}{V_k^*} \quad (2.6)$$

จัดรูปสมการใหม่จะได้

$$Y_{kk}V_k = \frac{P_k - jQ_k}{V_k^*} = (Y_{k1}V_1 + Y_{k2}V_2 + \dots + Y_{k(k-1)}V_{k-1} + \dots + Y_{k(k+1)}V_{k+1} + \dots + Y_{kn}V_n) \quad (2.7)$$

และแรงดันไฟฟ้าที่โนด k ใด ๆ แสดงดังสมการที่ (2.8)

$$V_k = \frac{1}{Y_{kk}} \left[\frac{P_k - jQ_k}{V_k^*} - \sum_{i=1, i \neq k}^n Y_{ki} V_i \right] \quad (2.8)$$

จากสมการที่ (2.8) เป็นสมการที่ไม่เป็นเชิงเส้น ดังนั้นการแก้ปัญหาเพื่อหาค่าแรงดันไฟฟ้าจึงไม่ใช่เรื่องง่าย จากกำลังไฟฟ้าในสมการที่ (2.3) เปลี่ยนให้อยู่ในรูปแรงดันไฟฟ้า และแอดมิตแตนซ์ของระบบได้โดยแทนเข้าไปในสมการจะได้สมการที่ (2.9)

$$S_k^* = P_k - jQ_k = V_k^* \sum_{i=1}^n Y_{ki} V_i \quad (2.9)$$

$$P_k = \operatorname{Re} \left[V_k^* \sum_{i=1}^n Y_{ki} V_i \right] \quad (2.10)$$

$$Q_k = -\operatorname{Im} \left[V_k^* \sum_{i=1}^n Y_{ki} V_i \right] \quad (2.11)$$

2.4.4 การคำนวณการไหลของกำลังไฟฟ้าด้วยวิธีนิวตัน-ราฟสัน

วิธีของนิวตัน-ราฟสัน เป็นวิธีที่มีประสิทธิภาพในการหาค่าตอบสูง ได้ผลลัพธ์โดยใช้รอบการคำนวณน้อย โดยใช้ทฤษฎีของอนุกรมเทเลอร์ (Taylor Series) ช่วยในการแก้ปัญหา ดังแสดงในสมการที่ (2.12) สำหรับ $f(x)$ ที่แทน x ด้วย x_0

$$y = f(x) = f(x_0) + \frac{df(x_0)}{dx} (\Delta x) + \frac{1}{2!} \cdot \frac{d^2f(x_0)}{dx^2} (\Delta x)^2 \dots \quad (2.12)$$

ถ้า $[\Delta x]$ มีค่าน้อยมากตั้งแต่เทอมที่ 1 ไปอาจตัดค่าทิ้งได้ ซึ่งสามารถเขียนสมการได้ดังสมการที่ (2.13)

$$y = f(x) = f(x_0) + \frac{df(x_0)}{dx}(\Delta x) \quad (2.13)$$

กรณีฟังก์ชัน $f(x)$ มีหลายตัวแปรสามารถประยุกต์ได้เป็น

$$y = f(x_1, x_2, \dots, x_n) = f(x_1^0, x_2^0, \dots, x_n^0) + \frac{\partial f}{\partial x_1} \Big|_{(0)} \Delta x_1 + \frac{\partial f}{\partial x_2} \Big|_{(0)} \Delta x_2 + \dots + \frac{\partial f}{\partial x_n} \Big|_{(0)} \Delta x_n \quad (2.14)$$

เมื่อ $x_1^0, x_2^0, \dots, x_n^0$ เป็นค่าเริ่มต้นที่แทนเข้าไปในฟังก์ชัน $\frac{\partial f}{\partial x_1} \Big|_{(0)}$ ซึ่งเป็นค่าของอนุพันธ์บางส่วนที่แทนด้วยค่า $x_1^0, x_2^0, \dots, x_n^0$ ดังนั้นสามารถจัดสมการใหม่ได้เป็น

$$\Delta y = y - f(x_1, x_2, \dots, x_n) = f(x_1^0, x_2^0, \dots, x_n^0) + \frac{\partial f}{\partial x_1} \Big|_{(0)} \Delta x_1 + \frac{\partial f}{\partial x_2} \Big|_{(0)} \Delta x_2 + \dots + \frac{\partial f}{\partial x_n} \Big|_{(0)} \Delta x_n \quad (2.15)$$

สำหรับสมการที่ไม่เป็นเชิงเส้นใด ๆ n สมการ สามารถเขียนใหม่โดยใช้สมการที่ 2.15 และจัดรูปเมตริกใหม่ได้ดังสมการที่ (2.16)

$$\begin{bmatrix} \Delta y_1 \\ \Delta y_2 \\ \vdots \\ \Delta y_n \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \dots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \dots & \frac{\partial f_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \dots & \frac{\partial f_n}{\partial x_n} \end{bmatrix} \begin{bmatrix} \Delta x_1 \\ \Delta x_2 \\ \vdots \\ \Delta x_n \end{bmatrix} \quad (2.16)$$

หรือสามารถเขียนแทนด้วยสมการเมตริก ดังสมการที่ (2.17)

$$[\Delta y] = [J][\Delta x] \quad (2.17)$$

ขั้นตอนการแก้ปัญหาของสมการโดยวิธีของนิวตัน-ราฟสัน สามารถสรุปได้ดังนี้

- 1) หาค่าโคเบียงเมตริก $[J]$ จากสมการที่กำหนด
- 2) สมมติค่าเริ่มต้นของตัวแปรและแทนค่าในสมการเพื่อหาค่าฟังก์ชัน $[\Delta y]$
- 3) แทนค่าฟังก์ชันที่เปลี่ยนแปลงในสมการที่ (2.15) เพื่อหาค่า $[\Delta x]$
- 4) หาค่าตัวแปรใหม่จาก ข้อ 2 และ 3
- 5) กลับไปหาค่าฟังก์ชันที่เปลี่ยนแปลง $[\Delta y]$ ในข้อ 2
- 6) วนซ้ำระหว่างข้อ 2 และ 5 จนได้ค่าตัวแปรที่เปลี่ยนแปลงมีค่าเข้าใกล้ศูนย์


2.5 ไมโครกริด

การใช้งานไมโครกริดร่วมกับระบบโครงข่ายไฟฟ้าหลัก ถือเป็นการรวมการผลิตไฟฟ้าแบบกระจายตัวขนาดเล็ก ภายในระบบไมโครกริด โดยเชื่อมต่อการผลิตไฟฟ้าแบบรวมศูนย์ขนาดใหญ่ (Centralized Generation) ซึ่งส่งผลให้มีแหล่งจ่ายพลังงานไฟฟ้าและเสถียรภาพทางไฟฟ้าที่มากขึ้น แต่ถ้าหากการเลือกตำแหน่งและพิกัดของกำลังผลิตที่เชื่อมต่อการจ่ายพลังงานหมุนเข้ากับระบบโครงข่ายหลักไม่เหมาะสมอาจส่งผลให้เกิดผลเสียได้ ไม่ว่าจะเป็นพลังงานที่ผลิตมากเกินไประบบสายส่งอาจรับไม่ไหว หรือความต้องการไฟฟ้าไม่สอดคล้องกับกำลังผลิต (Basit et al., 2020) ซึ่งได้มีตัวอย่างการนำเทคนิคการเรียนรู้แบบเสริมกำลังประยุกต์ใช้ในระบบ โดยงานวิจัยของคณะ Zhao et al., (2018) ได้กล่าวถึงยกตัวอย่างระบบทดสอบของ IEEE มาใช้ในการจำลองระบบไมโครกริดเพื่อใช้การเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ในการออกแบบตำแหน่งติดตั้งและหาขนาดกำลังผลิตไฟฟ้าที่เหมาะสมต่อไมโครกริดที่มีอยู่

2.5.1 ระบบทดสอบ IEEE 33 โหนด

ระบบทดสอบโครงข่าย IEEE 33 โหนด เป็นระบบโครงข่ายที่ถูกพัฒนาขึ้นโดยนักวิจัย Baran and Wu (1989) เพื่อศึกษาผลกระทบของโครงข่ายหลังถูกปรับปรุงระบบ โดยวิเคราะห์กำลัง

งานสูญเสียและสมดุลของโหลดเป็นหลัก ในเวลาต่อมาหลังจากแบบจำลอง IEEE 33 โหนดได้มีนำไปใช้เพื่อจำลองอย่างกว้างขวาง ไม่ว่าจะเป็นการปรับปรุงคุณภาพไฟฟ้าในฝั่งของพลังงานหมุนเวียน หรือการจัดการโหลดผู้ใช้ไฟฟ้า (Dolatabadi, Ghorbanian, Siano, and Hatziaargyriou, 2020) โดยพื้นฐานของระบบโครงข่ายเป็นระบบสามเฟสสมดุลที่มีโหนดจำนวน 33 โหนด 32 กิ่ง และมี Tie line 5 เส้นเพื่อปรับแรงดันรวมแล้ว 37 กิ่ง มีแรงดันพิกัดที่ 12.66 kV โหลดรวมในระบบ 3.72 MW, 2.3 MVAR และกำลังงานสูญเสียเดิมในระบบมีค่าอยู่ที่ 202.68 kW (Hassan, Sun, and Wang, 2020) โดยข้อมูลของสายส่งในระบบทดสอบ IEEE 33 โหนดมีพื้นฐานมาจากงานวิจัยของ Baran and Wu (1989) โครงสร้างของโครงข่ายแสดงดังรูปที่ 2.2 ข้อมูลโหลดของระบบทดสอบ IEEE 33 โหนด แสดงที่ภาคผนวกรูปที่ ข.1 และข้อมูลสายส่งแสดงที่ภาคผนวกรูปที่ ข.2



รูปที่ 2.2 ระบบโครงข่ายทดสอบ IEEE 33 โหนด (Hassan et al., 2020)


2.5.2 ระบบผลิตไฟฟ้าแบบกระจาย

ระบบผลิตไฟฟ้าแบบกระจาย (Distribution generator system: DGs) เป็นการผลิตไฟฟ้าขนาดเล็กที่เรียกว่าการผลิตแบบฝั่การกระจาย (Decentralized) ไม่ว่าจะเป็นจากพลังงานลม พลังงานแสงอาทิตย์ ชีวมวล เซลล์เชื้อเพลิง พลังงานจากน้ำหรือเขื่อน เป็นต้น การเชื่อมต่อของระบบผลิตไฟฟ้าแบบกระจายจะเชื่อมต่อใกล้กับลูกค้า บ้านเรือน และใช้สำหรับงานอุตสาหกรรม การค้า และการใช้งานในครัวเรือน ข้อดีหลักของการใช้หน่วยระบบผลิตไฟฟ้าแบบกระจาย คือ การปรับปรุงความเสถียรของแรงดัน การลดของกำลังไฟจริง ความน่าเชื่อถือ การเสริมแกร่งของไม่โครกริด และการลดปริมาณก๊าซ SO_2 , CO_2 ที่ปล่อยออกมา ถึงแม้ว่า DG จะมีข้อดีมากมาย ปัญหา

หลักในการวางระบบผลิตไฟฟ้าแบบกระจาย คือ การเลือกตำแหน่งและขนาดของหน่วยระบบผลิตไฟฟ้าแบบกระจาย หากหน่วยของระบบผลิตไฟฟ้าแบบกระจาย ไม่ได้วางและกำหนดขนาดอย่างเหมาะสม การไหลกลับของพลังงานจากระบบผลิตไฟฟ้าแบบกระจายขนาดใหญ่สามารถนำไปสู่การสูญเสียพลังงานในระบบที่สูงขึ้น

2.5.3 ระบบพลังงานแสงอาทิตย์

เซลล์แสงอาทิตย์ (Photovoltaic cell: PV) เป็นอุปกรณ์ไฟฟ้าที่เปลี่ยนแสงเป็นพลังงานไฟฟ้าผ่านปรากฏการณ์แสงอาทิตย์ ซึ่งทำจากวัสดุพิเศษที่เรียกว่าวัสดุสารกึ่งตัวนำใช้ในการแปลงพลังงานแสงอาทิตย์เป็นพลังงานไฟฟ้า โดยพลังงานจากแสงจะทำให้เกิดอิเล็กตรอน หรือการเคลื่อนที่ของกระแสไฟฟ้าขึ้นในสารกึ่งตัวนำ จึงทำให้เกิดกระแสไฟฟ้าง่ายๆที่สามารถนำไปใช้งานได้ ซึ่งปัจจุบันผู้ใช้งานไฟฟ้าเริ่มให้ความสนใจมากขึ้นในการเลือกใช้พลังงานทางเลือก เนื่องจากมีแสงอาทิตย์ให้ใช้งานโดยไม่จำกัด แต่ถึงกระนั้นพลังงานเซลล์แสงอาทิตย์ก็ไม่สามารถผลิตพลังงานในเวลาากลางคืนได้




รูปที่ 2.3 โครงสร้างและการทำงานของแผงเซลล์แสงอาทิตย์ (ชาคริต เลิศวิทยาประสิทธิ์, 2562)

จากรูปที่ 2.3 แสดงถึงโครงสร้างและการทำงานของแผงเซลล์แสงอาทิตย์สารกึ่งตัวนำแบบ n-type คือแผ่นซิลิกอนที่ผ่านการแปรรูปด้วยฟอสฟอรัส ดังนั้นจึงสามารถทำหน้าที่ส่งอิเล็กตรอนได้เมื่อรับพลังงานแสงอาทิตย์ สารกึ่งตัวนำ p-type เป็นแผ่นซิลิกอนที่ผ่านกระบวนการแปรรูปด้วยโบรอนซึ่งทำหน้าที่เป็นตัวรับอิเล็กตรอน พลังงานแสงอาทิตย์จะถ่ายโอนพลังงานแสงไปยังอิเล็กตรอน ทำให้อิเล็กตรอนเคลื่อนที่จาก หน้าสัมผัสข้างหน้า (Front Contact) ไปยัง หน้าสัมผัสข้าง

หลัง (Back Contact) จนครบรูปวงจรทำให้เกิดพลังงานไฟฟ้าในระบบ (ชาคริต เลิศวิทยาประสิทธิ์, 2562)

2.5.4 ระบบพลังงานกังหันลม

กังหันลม (Wind Turbine: WT) เป็นอุปกรณ์เปลี่ยนพลังงานจลน์ที่มากจากลมให้เป็นพลังงานไฟฟ้า โดยสามารถแบ่งเป็นสองแบบดังนี้ กังหันลมแกนหมุนแนวตั้ง (Vertical Axis Wind Turbine) เป็นกังหันลมที่มีแกนหมุนและใบพัดตั้งฉากกับการเคลื่อนที่ของลมในแนวราบและกังหันลมแกนหมุนแนวอน (Horizontal Axis Wind Turbine) เป็นกังหันลมที่มีแกนหมุนขนานกับการเคลื่อนที่ของลมในแนวราบ โดยมีใบพัดเป็นตัวตั้งฉากกับแรงลม อย่างไรก็ตามอุปสรรคหลักของกังหันลมคือกังหันลมมีกำลังผลิตที่คาดเดาได้ยากและไม่ต่อเนื่องในการผลิต รวมถึงมีต้นทุนการลงทุนที่สูง



รูปที่ 2.4 โครงสร้างและส่วนประกอบของกังหันลม (Caisheng Wang, 2006)

องค์ประกอบของกังหันลมหลัก ๆ ประกอบด้วยตัวเพลลา ใบพัด ทำงานโดยการหมุนเมื่อได้รับแรงลม และตัวเครื่องที่อยู่ภายในกังหันลม ซึ่งจะรับพลังงานจากการหมุนของตัวเพลลาแล้วแปลงเป็นพลังงานไฟฟ้า คล้ายกับระบบพลังงานเซลล์แสงอาทิตย์จำเป็นต้องใช้ตัวแปลง AC/DC เพื่อเชื่อมต่อกับกริด โดยส่วนประกอบของกังหันลมได้แสดงดังรูปที่ 2.4

ในการนำลมมาใช้ในการหมุนใบพัดกังหันลมนั้นจำเป็นต้องใช้ความเร็วที่เหมาะสมกับขนาดใบพัดกังหันลม ซึ่งโดยปกติธรรมชาติของลมนั้นไม่สามารถมีความเร็วคงที่ได้นั้นจึงทำให้กำลังผลิตไม่มีความแน่นอน ดังนั้นจึงจำเป็นต้องมีรูปแบบการควบคุมกังหันลมที่แตกต่างกันออกไป ซึ่งแบ่งเป็นสองแบบ คือ กังหันลมแบบความเร็วคงที่เพื่อขนาดของกำลังไฟฟ้าที่ต้องการและการทนต่อแรงทางกายภาพ และกังหันลมแบบแปรผันตามความเร็วลมเพื่อการผลิตกำลังไฟฟ้าทั้งความเร็วลมต่ำและสูง

2.5.5 ระบบกักเก็บพลังงานด้วยแบตเตอรี่

ระบบจัดเก็บพลังงานด้วยแบตเตอรี่ (Battery Energy Storage System: BESS) เป็นเทคโนโลยีที่ใช้ในการเก็บพลังงานไฟฟ้าจากแหล่งพลังงานที่สามารถสร้างได้ตลอดเวลา เช่น พลังงานแสงอาทิตย์และพลังงานลม แล้วนำพลังงานที่เก็บไว้ใช้งานในช่วงเวลาที่แหล่งพลังงานไม่สามารถสร้างพลังงานได้ เช่น ในช่วงกลางคืนที่แผงพลังงานเซลล์แสงอาทิตย์ไม่สามารถผลิตได้ หรือช่วงที่ไม่มีลมในการหมุนใบพัดกังหันสามารถใช้แบตเตอรี่มาสำรองจ่ายไฟฟ้าแทนได้

แบตเตอรี่หลายประเภทได้รับการพัฒนาและกำลังได้รับการพัฒนามากขึ้นตามความก้าวหน้าของการวิจัย ซึ่งได้พัฒนาให้แบตเตอรี่มีประสิทธิรูปที่สูงมากถึง 90% วงจรชีวิตที่มากขึ้นและต้นทุนที่ลดลง แต่ลักษณะเด่นของแบตเตอรี่ขึ้นอยู่กับเทคโนโลยีและส่วนประกอบทางเคมีไฟฟ้าต่างๆ ซึ่งองค์ประกอบทางเคมีของแบตเตอรี่ที่นิยมใช้ในปัจจุบัน ได้แก่ แบตเตอรี่ตะกั่ว-กรด, แบตเตอรี่ลิเธียม, แบตเตอรี่โซเดียม, แบตเตอรี่โซเดียม-ไอออน และแบตเตอรี่โซเดียม-กำมะถัน โดยการประยุกต์ใช้แบตเตอรี่ในระบบไฟฟ้าจำเป็นต้องมีอินเวอร์เตอร์เพื่อแปลงไฟฟ้าจากกระแสตรง เป็นกระแสสลับ เพื่อปรับความถี่ให้ตรงกับระบบกริด (Kerdphol, 2016)

ระบบกักเก็บพลังงานสามารถรองรับแบตเตอรี่ประเภทต่าง ๆ ได้ เช่น ลิเธียม-ไอออน, แบตเตอรี่ตะกั่ว-กรด, และนิเกิล-แคดเมียม 1 นอกจากนี้แต่ละประเภทของแบตเตอรี่ยังมีพารามิเตอร์ทางเทคนิคที่ระบุในการใช้งานของระบบกักเก็บพลังงาน และส่งผลต่อประสิทธิภาพการเก็บพลังงานของแบตเตอรี่ คุณสมบัติหลักของแบตเตอรี่คือ ความจุเก็บพลังงาน คุณสมบัติของพลังงาน ประสิทธิภาพของการอัดประจุ ความลึกของการปล่อยพลังงาน (Deep of Discharge:

DoD) และอายุการใช้งาน โดยงานวิจัยของคณะ Prakash et al., (2022) ได้ศึกษาและค้นคว้าข้อดี และข้อได้เปรียบของแบตเตอรี่แต่ละชนิด โดยแสดงในตารางที่ 2.2

ตารางที่ 2.2 ประโยชน์และข้อเสียของแบตเตอรี่แต่ละชนิด

ชนิดแบตเตอรี่	ข้อดี	ข้อเสีย
แบบลิเทียม-ไอออน (Li-ion)	<ul style="list-style-type: none"> - มีอายุไขที่ยาวนาน - ประสิทธิภาพ DoD สูง - กำลังไฟฟ้าและการกักเก็บพลังงานสูง - ทนความร้อนได้ดี - การปล่อยประจุมีความเสถียร 	<ul style="list-style-type: none"> - ทำลายสิ่งแวดล้อมและนำกลับมาใช้ใหม่ได้ยาก
แบบตะกั่ว-กรด (Lead acid)	<ul style="list-style-type: none"> - มีราคาถูก - ใช้งานง่าย เนื่องจากเป็นเทคโนโลยีเก่า 	<ul style="list-style-type: none"> - ประสิทธิภาพ DoD ต่ำ - มีอายุไขต่ำ - ความจุของพลังงานต่ำ
แบบโซเดียม-นิกเกิล-คลอไรด์ (Sodium Nickel Chloride)	<ul style="list-style-type: none"> - มีอายุไขที่ยาวนาน - กำลังไฟฟ้าและการกักเก็บพลังงานสูง - ต้นทุนการสร้างถูกกว่า Li-ion 	<ul style="list-style-type: none"> - มีต้นทุนการติดตั้งและบำรุงสูง - มีอัตราการปล่อยประจุสูงเกินไป - ต้องอยู่ในอุณหภูมิที่เหมาะสม

จากตารางที่ 2.2 ได้กล่าวถึงแบตเตอรี่ชนิด แบบตะกั่ว-กรด มีราคาที่ถูก เมื่อวิเคราะห์ประสิทธิภาพพบว่ามีประสิทธิภาพในการกักเก็บความหนาแน่นของพลังงานไม่สูงมากนัก เปรียบเทียบแบบโซเดียม-นิกเกิล-คลอไรด์ ที่มีประสิทธิภาพที่ครอบคลุมแต่ด้วยปัญหาที่มีเงื่อนไขในการใช้และต้นทุนที่สูง นั่นจึงทำให้แบตเตอรี่แบบลิเทียม-ไอออน เป็นที่น่าสนใจทั้งในเรื่องของความจุ ความคงทน ทนต่อสภาพอากาศเปลี่ยนแปลง ด้วยเหตุผลนี้จึงถูกนำมาใช้ในการสร้างยานยนต์ไฟฟ้าหลากหลายแบบ เนื่องจากคุณสมบัติดังที่กล่าวข้างต้น (Sun et al. 2015)

2.5.6 สถานีอัดประจุยานยนต์ไฟฟ้า

สถานีอัดประจุยานยนต์ไฟฟ้า (Electric Vehicle Charging Station: EVCS) คือ สถานที่ที่ใช้สำหรับการชาร์จแบตเตอรี่ของยานพาหนะไฟฟ้า (Electric Vehicle: EV) สถานีอัดประจุยานยนต์ไฟฟ้าสามารถติดตั้งได้ทั้งในสถานที่สาธารณะเช่น สถานีบริการน้ำมัน โรงแรม ห้างสรรพสินค้า และสถานีรถไฟ หรือซื้อมาติดตั้งในบ้านหรือที่ทำงานได้เช่นกัน การใช้งานสถานีอัดประจุไฟฟ้าจะช่วยส่งเสริมการใช้นยานพาหนะไฟฟ้าที่มีประสิทธิภาพและเป็นมิตรกับสิ่งแวดล้อม เพราะเป็นแหล่งจ่ายพลังงานที่สะอาด และช่วยลดการปล่อยก๊าซเรือนกระจกของยานพาหนะและเสียงดังในพื้นที่ชุมชน โดยระดับการชาร์จได้แบ่งเป็น 3 ระดับดังนี้ (ณัฐพล ชาติสุข, 2561)

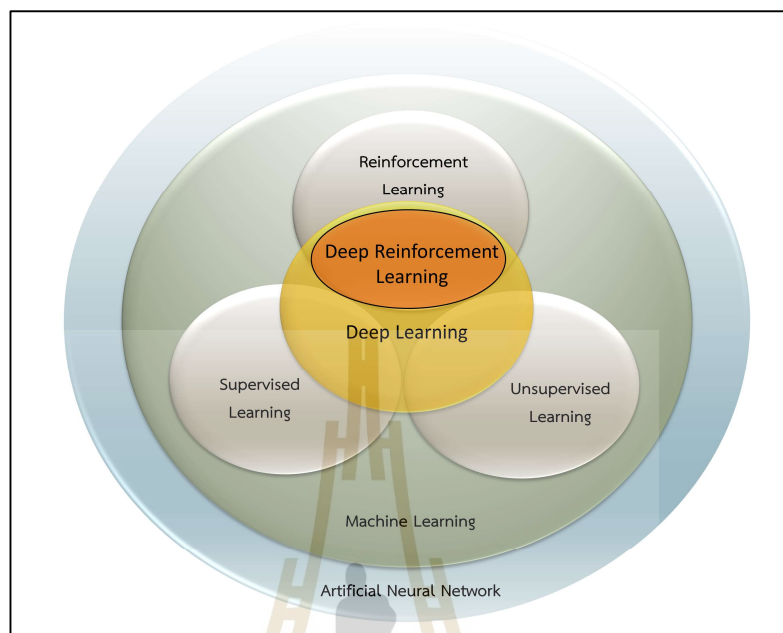
1) โหมดชาร์จระดับ 1 มีช่วงพิกัดกำลังไฟฟ้าใช้ได้ตั้งแต่ 1.4 – 1.9 kW โหมดการชาร์จระดับที่ 1 นี้จะใช้เวลาเฉลี่ย 8-12 ชั่วโมงในการชาร์จให้แบตเตอรี่มีสถานะการชาร์จ (SOC) 100% ข้อดีของโหมดการชาร์จระดับ 1 คือไม่ต้องมีโครงสร้างพื้นฐานเพิ่มเติมสำหรับบ้านและสถานที่ทำงาน ทำให้ประหยัดต้นทุนในการติดตั้ง

2) โหมดชาร์จระดับ 2 มีช่วงพิกัดกำลังไฟฟ้าใช้ได้ตั้งแต่ 7.4 - 22 kW เป็นตัวเลือกที่เหมาะสมที่สุดสำหรับสถานที่ชาร์จส่วนตัว สำหรับการติดตั้งแบบส่วนตัว โหมดนี้กำหนดให้มีกระแสสลับ 240 V และความสามารถในการจัดการกระแส 40 A และ 80 A สำหรับแหล่งจ่ายไฟ 400 V จึงทำให้การชาร์จรถไฟฟ้าทำได้เร็วกว่าโหมดการชาร์จที่ 1

3) โหมดชาร์จระดับ 3 เป็นการชาร์จแบบเร็วมีช่วงพิกัดกำลังไฟฟ้าตั้งแต่ 50 kW ขึ้นไป ซึ่งสามารถชาร์จแบตเตอรี่ได้ภายใน 20-30 นาที เป็นมาตรฐานในสถานที่ทางการค้าและอุตสาหกรรม ดังนั้น พื้นที่จุดเติมชาร์จในเมือง เช่น ห้างสรรพสินค้า, สนามบิน, สวนสาธารณะ, โรงแรม, ปั้มน้ำมัน และสถานที่สาธารณะอื่น ๆ

2.6 การเรียนรู้แบบเสริมกำลัง

การเรียนรู้แบบเสริมกำลังเป็นส่วนหนึ่งของการเรียนรู้ของเครื่อง และยังเป็นส่วนหนึ่งของปัญญาประดิษฐ์ ลำดับความเป็นมาของอัลกอริทึมแสดงดังรูปที่ 2.5 โดยการเรียนรู้ของเครื่องแบ่งออกเป็นสามชนิด ได้แก่ การเรียนรู้แบบมีผู้สอน การเรียนรู้แบบไม่มีผู้สอน และการเรียนรู้แบบเสริมกำลัง ซึ่งภายหลังการเรียนรู้แบบเครื่องได้มีการพัฒนาเป็น การเรียนรู้เชิงลึก ที่มีโครงข่ายประสาทเทียมที่มีหลายเลเยอร์ในการประมวลผลข้อมูล เพื่อการแก้ปัญหาที่ซับซ้อน และความแม่นยำที่มากขึ้น



รูปที่ 2.5 ลำดับความเป็นมาของอัลกอริทึม (Li, 2018)

ลักษณะการทำงานของการเรียนรู้แบบเสริมกำลังมีพื้นฐานมาจากการลองผิดลองถูก (Trial and Error) ที่ตัวเอเจนต์เรียนรู้การตัดสินใจโดยการโต้ตอบกับสิ่งแวดล้อม ตัวเอเจนต์จะได้รับข้อมูลคืนตอบกลับมาในรูปแบบของรางวัล หรือโทษและปรับปรุงการกระทำของตนเองเพื่อรางวัลสูงสุดตามเป้าหมายที่ตั้งไว้ (Yang, 2021) โดยทฤษฎีพื้นฐานของการเรียนรู้แบบเสริมกำลังมาจากกระบวนการตัดสินใจแบบมาร์คอฟ (Markov Decision Process : MDP)

2.6.1 กระบวนการตัดสินใจแบบมาร์คอฟ

กระบวนการตัดสินใจแบบมาร์คอฟเป็นกรอบทางคณิตศาสตร์ที่ใช้ในการจำลองปัญหาการตัดสินใจของการเรียนรู้แบบเสริมกำลัง กระบวนการตัดสินใจแบบมาร์คอฟประกอบด้วย 5 ส่วนดังต่อไปนี้

1) สถานะ (State: s) เป็นเซตข้อมูลที่ได้จากสภาพแวดล้อม และส่งไปที่ฟังก์ชันการเปลี่ยนสถานะเพื่อช่วยในการวิเคราะห์ในการกระทำของตัวเอเจนต์ครั้งถัดไป

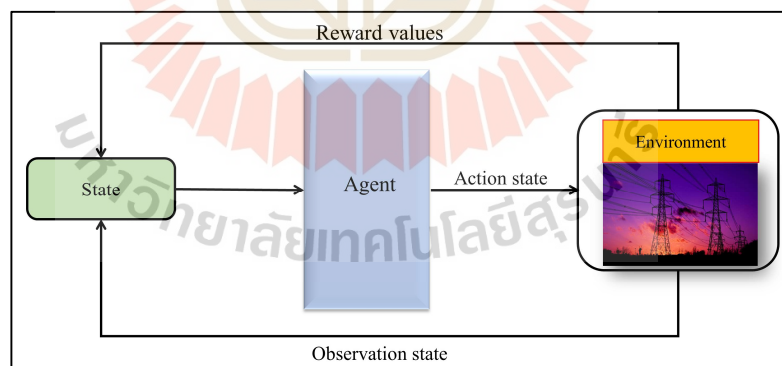
2) การกระทำ (Action: a_t) เป็นเซตข้อมูลของตัวเอเจนต์ที่ส่งไปกระทำต่อสิ่งแวดล้อมในแต่ละช่วงเวลานั้น ๆ

3) ฟังก์ชันการเปลี่ยนสถานะ (Transition Function) เป็นฟังก์ชันความน่าจะเป็น $P(s_{t+1} | s_t, a_t)$ ที่กำหนดความน่าจะเป็นของการเปลี่ยนสถานะจากสถานะ s_t เป็นสถานะที่เปลี่ยนแปลงไป s_{t+1} เมื่อตัวเอเจนต์ดำเนินการด้วยการกระทำ a_t โดยฟังก์ชันการเปลี่ยนแปลงสถานะจะบ่งบอกถึงการเปลี่ยนแปลงของสถานะหลังจากตัวเอเจนต์ดำเนินการกระทำที่สภาพแวดล้อม

4) ฟังก์ชันรางวัล (R) ฟังก์ชันรางวัลจะส่งค่ากลับมาที่ตัวเอเจนต์ เมื่อเอเจนต์กระทำต่อสิ่งแวดล้อมสำเร็จ โดยฟังก์ชันรางวัลจะช่วยให้เอเจนต์ตัดสินใจในการกระทำครั้งต่อไป

5) ค่าส่วนลด (Discount Factor: γ) เป็นค่าจำนวนจริงระหว่าง 0 ถึง 1 ที่ใช้กำหนดความสำคัญของฟังก์ชันรางวัล หรือปรับน้ำหนักของค่าฟังก์ชันรางวัล เพื่อปรับสมดุลให้เหมาะสมของการเรียนรู้แบบเสริมแรง

กระบวนการทำงานของการเรียนรู้แบบเสริมกำลังแสดงในรูปที่ 2.6 ซึ่งเอเจนต์มีเป้าหมายหลักคือการหาวิธีกระทำต่อสิ่งแวดล้อมที่เหมาะสมที่สุดเพื่อรับค่ารางวัลให้ได้มากที่สุด



รูปที่ 2.6 กระบวนการทำงานของการเรียนรู้แบบเสริมกำลัง

กำหนดให้ π คือ กลยุทธ์หรือนโยบาย (Policy) ที่ต้องปฏิบัติตามเพื่อการตัดสินใจในการกำหนดฟังก์ชันสถานะและการกระทำ (State-Action Function) หรือเรียกอีกชื่อหนึ่งคือ

Q-function ซึ่งเป็นฟังก์ชันที่ได้จากการนำเนินการกระทำในสถานะช่วงเวลาหนึ่งดังสมการที่ (2.18) และฟังก์ชันรางวัลที่ได้จาก นโยบายในสถานะช่วงเวลาหนึ่ง ดังสมการที่ (2.19)

$$Q^\pi(s, a) = E^\pi \left[\sum_{t \geq 0} \gamma^t R(s_t, a_t, s_{t+1}) \mid a_t = a, s_t = s \right] \quad (2.18)$$

$$V^\pi(s) = E^\pi \left[\sum_{t \geq 0} \gamma^t R(s_t, a_t, s_{t+1}) \mid s_t = s \right] \quad (2.19)$$

กำหนดให้	E^π	คือ	ค่าที่คาดหวังภายใต้ความน่าจะเป็นของ P^π
	s_t	คือ	สถานะของสิ่งแวดล้อมช่วงเวลาหนึ่ง
	s_{t+1}	คือ	ค่าสถานะหลังถูกกระทำหรือปรับปรุง
	a_t	คือ	การกระทำของเอเจนต์
	R	คือ	ฟังก์ชันรางวัล
	$Q^\pi(s, a)$	คือ	ค่า Q-function ในนโยบายขณะนั้นที่กระทำโดย a_t
	$V^\pi(s)$	คือ	ฟังก์ชันมูลค่าในนโยบายขณะนั้น

2.6.2 ประเภทของการเรียนรู้เสริมกำลัง

การเรียนรู้แบบเสริมกำลังได้แบ่งเป็นประเภทหลัก ๆ 2 ประเภท

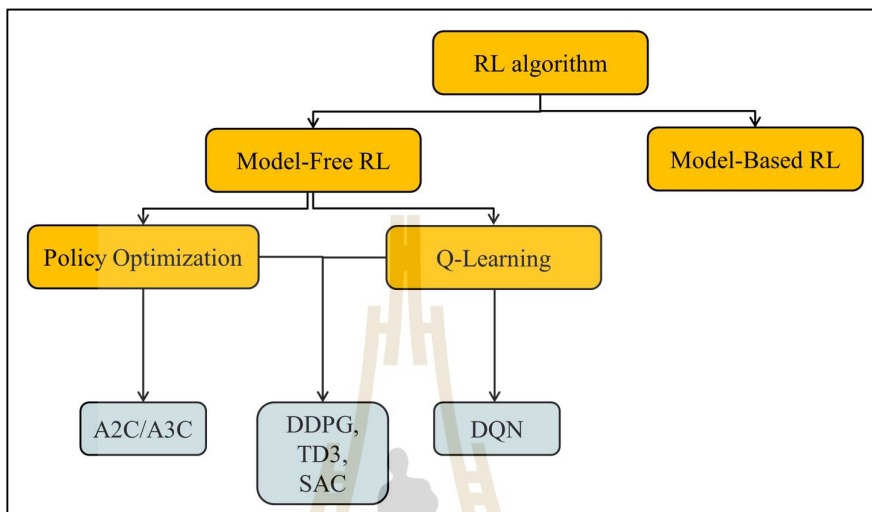
1. การเรียนรู้เสริมกำลังแบบไร้โมเดล (Model-Free Reinforcement Learning)

คือ รูปแบบของการเรียนรู้จากประสบการณ์ของการลองผิดลองถูกที่ผ่านมาในอดีต ทำให้ใช้เวลานานในการเรียนรู้ ระบบจะรู้เพียงแค่ว่าสิ่งใดที่ควรทำหรือสิ่งใดที่ไม่ควรทำ โดยการเรียนรู้เสริมกำลังแบบไร้โมเดลเหมาะสมกับข้อมูลที่ไม่มีกฎกติกาการเรียนรู้มารองรับ และ การเรียนรู้เสริมกำลังแบบไร้โมเดลสามารถแบ่งย่อยได้เป็น 2 ประเภท คือ การหาโยบายที่เหมาะสม (Policy Optimization) และ วิธีการตามมูลค่า (Value-Based Method)

2. การเรียนรู้เสริมแรงแบบใช้โมเดลเป็นฐาน (Model-Based Reinforcement Learning)

คือ รูปแบบของการเรียนรู้ที่มีกฎกติกาช่วยในการจำกัดขอบเขตของการตัดสินใจให้แคบลง ทำให้ใช้เวลาในการเรียนรู้ที่สั้น เช่น กระบวนการเรียนรู้ของเกมโกะ ที่มีกฎการเดินหมากมาช่วยในการจำกัดขอบเขตการเรียนรู้ โดยโมเดลแบบกำหนดขึ้นเอง สามารถแบ่งย่อยได้เป็น 2 ประเภท

คือ Learn the Model และ Given the Model (ณัฐวัฒน์ เอกธรรมนิทัศน์, 2563) ดังแผนผังแสดงในรูปที่ 2.7



รูปที่ 2.7 ประเภทของการเรียนรู้แบบเสริมกำลัง

วิทยานิพนธ์นี้ได้มุ่งเน้นไปที่การเรียนรู้เสริมกำลังแบบไร้โมเดลที่ประกอบไปด้วย การหา นโยบายที่เหมาะสม และการเรียนรู้แบบคิว เนื่องจากมีการเรียนรู้ที่อิสระ และยืดหยุ่นต่อการประยุกต์ใช้ในสถานการณ์ต่าง ๆ

2.6.3 วิธีการตามมูลค่า

วิธีการตามมูลค่าเป็นวิธีการมุ่งเน้นเรียนรู้ Q-function โดยเฉพาะ โดยการประมาณหาค่า Q-function ที่ได้จากการเปรียบเทียบค่า Q-function เก่าเทียบกับค่า Q-function ใหม่ และส่งค่าดังกล่าวให้เอเจนต์ เพื่อการกระทำครั้งถัดไปในสิ่งแวดล้อมดังสมการที่ (2.20)

$$\hat{Q}(s_t, a_t) = Q(s_t, a_t) + \alpha \cdot \left[R_t + \gamma \cdot \max_{a \in A} Q(s_t, a) - Q(s_t, a_t) \right] \quad (2.20)$$

กำหนดให้	$\hat{Q}(s_t, a_t)$	คือ	ค่า Q-function หลังจากผ่านการปรับปรุง
	$Q(s_t, a_t)$	คือ	ค่า Q-function ก่อนปรับปรุง
	α	คือ	ค่าอัตราการเรียนรู้ของเอเจนต์ (Learning Rate)

2.6.4 วิธีการหาโยบายที่เหมาะสม

วิธีการหานโยบายที่เหมาะสม (Policy Optimization) ถูกออกแบบมาเพื่อการค้นหานโยบายที่เหมาะสมที่สุด ซึ่งนำค่าฟังก์ชันรางวัลมาวิเคราะห์เพื่อหาสูตรศาสตร์ที่เหมาะสมในการกระทำครั้งต่อไป โดยแสดงดังสมการที่ (2.21)

$$\nabla_{\theta} V^{\pi_{\theta}}(s) = E^{\pi} \left[\nabla_{\theta} \log \pi_{\theta}(a | s) \cdot Q^{\pi_{\theta}}(s, a) \right] \quad (2.21)$$

กำหนดให้	$V^{\pi_{\theta}}$	คือ	สถานะที่อยู่ภายใต้้นโยบายของ π_{θ}
	$\nabla_{\theta} \log \pi_{\theta}(a s)$	คือ	ค่าคะแนนรางวัลจากนโยบายขณะนั้น
	E^{π}	คือ	ค่าความน่าจะเป็นที่คาดหวังที่นโยบายขณะนั้น

2.7 การเรียนรู้แบบเสริมกำลังหลายเอเจนต์

การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ เป็นการทำงานที่มีความคล้ายคลึงกับการเรียนรู้แบบเสริมกำลังแบบปกติ ซึ่งในการแก้ไขปัญหาดังกล่าว ยังคงใช้แนวคิดในการทำงานคือกระบวนการตัดสินใจแบบมาร์คอฟ โดยแต่ละเอเจนต์สามารถมีการทำงานร่วมกัน หรือแยกทำงานกัน ในการรับค่าสถานะ และค่ารางวัลความสำเร็จที่ได้จากสิ่งแวดล้อม ซึ่งในการพัฒนาอัลกอริทึมที่มีกระบวนการตัดสินใจแบบมาร์คอฟแบบหลายตัว เรียกว่า สโตแคสติกเกม (Stochastic Game) หรือเรียกอีกอย่างหนึ่งว่า มาร์คอฟเกม (Markov Game)

2.7.1 สโตแคสติกเกม

ในการทำงานของสโตแคสติกเกมมีหลักการที่คล้ายกับการทำงานของการเรียนรู้เสริมกำลังแบบเดี่ยว (Zhang, Yang and Basar, 2019) โดยมีหลักการทำงานหลัก ๆ ดังนี้

1) จำนวนเอเจนต์ (The number of agents) โดยปกติแล้วเอเจนต์ในการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์จะมีมากกว่าหรือเท่ากับสองตัวขึ้นไป

2) สถานะ (State: s) เป็นเซตข้อมูลสถานะของสิ่งแวดล้อมที่ใช้ร่วมกับเอเจนต์ทั้งหมด

3) การกระทำ (Action: a_t) เป็นเซตข้อมูลของการกระทำที่ตัวเอเจนต์แต่ละตัว

4) ฟังก์ชันการเปลี่ยนสถานะ (Transition Function) เป็นฟังก์ชันการเปลี่ยนแปลงสถานะที่ได้จากการกระทำร่วมกันของเอเจนต์หลายตัว

5) ฟังก์ชันรางวัล (R): ในฟังก์ชันรางวัลของ MARL จะใช้หลักการค้นหาเอเจนต์ตัวไหนได้รางวัลมากที่สุด R_{max}

6) ค่าส่วนลด (Discount Factor: γ) เป็นค่าจำนวนจริงระหว่าง 0 กับ 1 ที่ใช้กำหนดความสำคัญของรางวัล ณ เวลาหนึ่ง โดยกระบวนการทำงานของภายใต้กรอบของสโตแคสติกเกมแสดงดังสมการที่ (2.22) โดยที่ i เป็นจำนวนของเอเจนต์

$$V_{\pi^i, \pi^{-i}}^i(s) = \mathbb{E} \left[\sum_{t \geq 0} \gamma^t R_t^i(s_t, a_t, s_{t+1}) \mid a_t^i \sim \pi^i(\cdot \mid s_t), s_0 = s \right] \quad (2.22)$$

กำหนดให้	t	คือ	ช่วงเวลาหนึ่ง
	s_t	คือ	สถานะของสิ่งแวดล้อมช่วงเวลาหนึ่ง
	a_t	คือ	การกระทำของเอเจนต์
	R_t^i	คือ	ฟังก์ชันรางวัล
	γ^t	คือ	ค่าส่วนลด
	π^i	คือ	ข้อกำหนดของเอเจนต์แต่ละตัว
	E	คือ	ค่าความน่าจะเป็นที่คาดหวัง

2.7.2 วิธีการตามมูลค่าแบบหลายเอเจนต์

ในการเรียนรู้เสริมกำลังหลายตัวยังคงรูปแบบแนวคิดคล้ายกับการเรียนรู้เสริมกำลังแบบเดี่ยวเช่นกันนั่นคือการอัปเดตค่า Q-function ซึ่งการอัปเดตค่านั้นสามารถทำได้โดยการอัปเดตให้เอเจนต์แบบอิสระ (Independent Learning) หรือให้แต่ละเอเจนต์ใช้ค่าพารามิเตอร์ร่วมกันแบบศูนย์กลางก็ได้ (Centralize Learning) โดยหลักการทำงานพื้นฐานของวิธีการตามมูลค่าแบบหลายเอเจนต์แสดงดังสมการที่ (2.23)

$$\hat{Q}^i(s_t, a_t) = Q^i(s_t, a_t) + \alpha \cdot \left[R_t^i + \gamma \cdot \underset{a \in A}{eval} \left(\{Q^i(s_{t+1})\}_{i \in \{1, \dots, N\}} \right) - Q^i(s_t, a_t) \right] \quad (2.23)$$

กำหนดให้	$\hat{Q}^i(s_t, a_t)$	คือ	ค่า Q-function หลังจากผ่านการปรับปรุง
	$Q^i(s_t, a_t)$	คือ	ค่า Q-function ก่อนปรับปรุง
	α	คือ	ค่าอัตราการเรียนรู้ของเอเจนต์

2.7.3 วิธีการตามนโยบายที่เหมาะสมแบบหลายเอเจนต์

แนวคิดของวิธีการตามนโยบายยังคงมีความคล้ายคลึงกับการเรียนรู้เสริมกำลังแบบเดี่ยว แต่สิ่งที่ต่างออกไป คือการอัปเดตค่าพารามิเตอร์สามารถทำได้โดยการอัปเดตให้เอเจนต์แบบอิสระ หรือแบบศูนย์กลางได้ โดยแสดงดังสมการที่ (2.24)

$$\nabla_{\theta^i} J^i(\theta) = E^\pi \left[\nabla_{\theta} \log \pi_{\theta^i}(a^i | s) \cdot Q^{i, \pi_{\theta}}(s, a) \right] \quad (2.24)$$

กำหนดให้	θ^i	คือ	ปรับปรุงพารามิเตอร์
	s_t	คือ	สถานะของสิ่งแวดล้อม
	a^i	คือ	การกระทำของเอเจนต์
	R_t^i	คือ	ฟังก์ชันรางวัล
	π^i	คือ	ข้อกำหนดของเอเจนต์แต่ละตัว

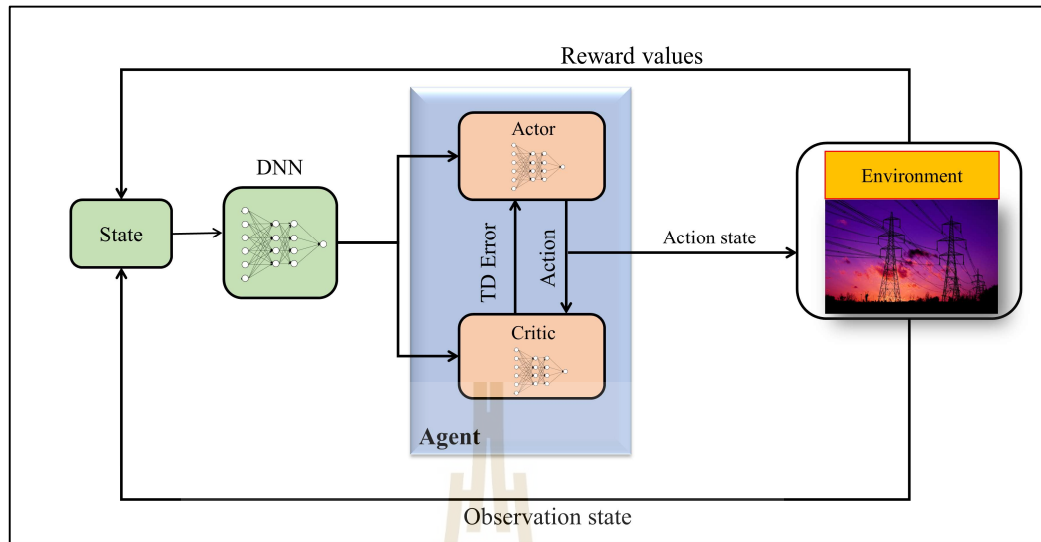
2.8 การเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์

การเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ มีพัฒนาการจากการเสริมเรียนรู้เชิงลึก ซึ่งช่วยให้เทคนิคการเรียนรู้เสริมกำลังสามารถจัดการกับข้อมูลที่มีมิติสูงและซับซ้อนได้ดีขึ้น โดยใช้เครือข่ายประสาทเทียมเพื่อหาความสัมพันธ์และลักษณะเด่นในข้อมูล และสามารถนำมาประยุกต์เข้ากับเทคนิคการเรียนรู้เสริมกำลังแบบหลายตัว โดยช่วยในการปรับปรุงประสิทธิภาพในการวิเคราะห์ของการเรียนรู้แบบเสริมกำลังหลายตัว ส่วนที่มีการปรับปรุงแบ่งเป็นสองส่วนหลักนั้นคือ วิธีการตามมูลค่า และวิธีการหานโยบายที่เหมาะสม ซึ่งจะกล่าวต่อไป

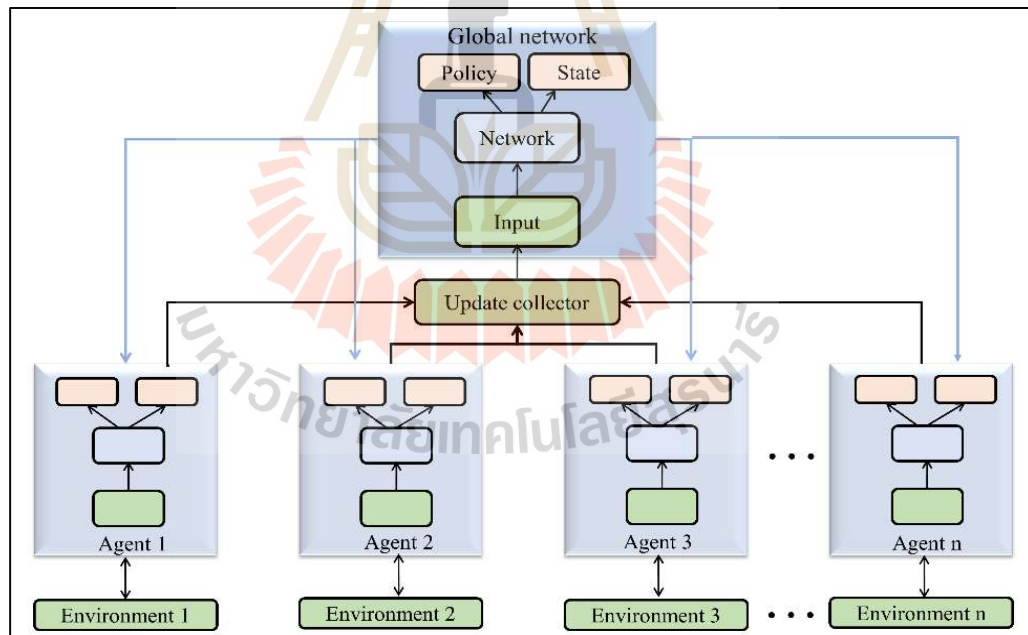
2.8.1 อัลกอริทึมแบบ A2C

อัลกอริทึมแบบ A2C (Advantage Actor-Critic Algorithm : A2C) เป็นการรวมกันของเทคนิควิธีการตามมูลค่า และวิธีการหานโยบายที่เหมาะสมของการเรียนรู้แบบเสริมกำลัง โดยมีสองส่วนหลักที่สำคัญคือ ผู้วิจารณ์ (Critic) ที่มีหน้าที่ในการประมาณค่าจาก ฟังก์ชันมูลค่า และผู้กระทำ (Actor) เป็นส่วนที่คอยปรับปรุงนโยบายตามทิศทางที่ผู้วิจารณ์สั่ง (Mnih et al., 2016), (Jang, Huang, and Chiu, 2020), (Paczolay and Harmati, 2020)

การปรับปรุงนโยบายด้วยผู้วิจารณ์เป็นเทคนิคที่มุ่งเน้นไปที่การหาความเหมาะสมของนโยบาย ซึ่งส่วนที่สำคัญของเทคนิคการปรับปรุงนโยบายด้วยผู้วิจารณ์นั้น คือ ผู้วิจารณ์ โดยมีหน้าที่ในการวิเคราะห์พารามิเตอร์ที่เอเจนต์ส่งออกมาเพื่อทำการปรับปรุงนโยบาย โดยผู้วิจารณ์นั้นจะรอเอเจนต์ทุกตัวกระทำกับสภาพแวดล้อมให้เสร็จทุกตัวก่อนที่จะวิเคราะห์และส่งเอาต์พุตเพื่อปรับปรุงนโยบายให้ใช้ร่วมกันในครั้งต่อไป ซึ่งในรอบการเทรนนิ่งครั้งถัดไปเหล่าเอเจนต์จะใช้นโยบายที่ปรับปรุงแล้วผ่านผู้วิจารณ์ โดยโครงสร้างของเทคนิคแสดง และการทำงานแบบจังหวะเดียวกันดังรูปที่ 2.8 และ 2.9



รูปที่ 2.8 กระบวนการทำงานของ A2C (Alibabaei et al., 2022)



รูปที่ 2.9 การทำงานแบบพร้อมกันของอัลกอริทึม A2C

ในการปรับปรุงนโยบายของเทคนิคการปรับปรุงนโยบายด้วยผู้วิจารณ์นั้นได้นำวิธีการหาค่าความแตกต่างกันของเวลา (Temporal difference error: TD error) มาใช้ในการวิเคราะห์ Q-function โดยนำค่ารางวัลที่ได้นำมาประมาณค่า Q-function และให้ตัวเอเจนต์นำไปเรียนรู้และปรับปรุงลักษณะการทำงานในแต่ละการกระทำ โดยสมการของ TD error แสดงดังสมการที่ (2.25)

$$\delta_t = R_{t+1} + \gamma Q_{(s_{t+1})} - Q_{(s_t)} \quad (2.25)$$

กำหนดให้ s_{t+1} คือ สถานะที่ถูกกระทำและปรับปรุงหลังจากสถานะ s_t
 R_{t+1} คือ ค่ารางวัลหลังจากถูกกระทำ
 $Q_{(s_t)}$ และ $Q_{(s_{t+1})}$ คือ ค่า Q-function ก่อนถูกกระทำ และ Q-function หลังถูกกระทำ

แบบจำลองของผู้วิจารณ์ (Critic model) ได้นำค่า TD error มาใช้ในการประมาณค่าและวิเคราะห์เพื่อหาค่าพารามิเตอร์ที่เหมาะสมของนโยบายโดยแสดงดังสมการที่ (2.26) ซึ่งการวิเคราะห์ของแบบจำลองของผู้วิจารณ์ช่วยให้ความผิดพลาดในการวิเคราะห์พารามิเตอร์น้อยลงและการเรียนรู้ที่มีความเสถียรมากขึ้น โดยอัลกอริทึมส่วนหลัก ๆ ได้แสดงดังรูปที่ 2.9

$$L_{\pi_\theta} = - \sum_{t=0}^T (\log \pi_\theta(a_t | s_t)) \delta_t \quad (2.26)$$

กำหนดให้ L_{π_θ} คือ ผลลัพธ์ที่ได้จากการคำนวณของแบบจำลองของผู้วิจารณ์
 θ คือ ค่าน้ำหนักถ่วงดุล (Weight)

ซูโด้โค้ดอัลกอริทึมของการปรับปรุงนโยบายด้วยผู้วิจารณ์ ในรูปที่ 2.10 โดยการทำงานหลัก ๆ เริ่มต้นด้วยการสุ่มค่าจำนวนหนึ่งเพื่อถ่วงดุลให้กับแบบจำลองของผู้วิจารณ์ และ

นโยบายของผู้กระทำ จากนั้นเริ่มการกระทำต่อสภาพแวดล้อมที่สร้างขึ้นตามจำนวนรอบการทำงาน ที่ตั้งค่าไว้รวมถึงการคำนวณ TD error และค่าความผิดพลาดต่าง ๆ

```


Algorithm 1: A2C algorithm.
Initialize training environment
Randomly initialize critic model with random weight  $\omega$ 
Randomly initialize actor policy model with random weight  $\theta$ 
For episode=1 to max_episode do
  done = False
  While done = False do
    Sample action  $a_t$  according to the current policy
    next_SWTD, reward, done=env(current_state_action)
    next_state=Concatenate (next_SWTD, next_climate_data)
    if done = True and episode=3 then
      calculate TD error
      update critic by minimizing  $\delta_t^2$ 
      update actor by minimizing loss from Equation 2.31
    end if
    current_state=new_state
  end
end
end

```

รูปที่ 2.10 ชุดโค้ดอัลกอริทึมของ A2C

2.8.2 อัลกอริทึมแบบ A3C

อัลกอริทึมแบบ A3C (Asynchronous Advantage Actor-Critic : A3C) เป็นอัลกอริทึมที่มีพื้นฐานเดียวกับ A2C นั่นคือการหานโยบายที่เหมาะสมของการเรียนรู้แบบเสริมกำลัง โดยสิ่งที่ต่างออกไปจาก A2C คือ กายัพเตพพารามิเตอร์แบบ A3C เป็นการอัปเดตแบบไม่เป็นจังหวะเดียวกัน (Asynchronous) โดยวิธีการนี้ได้ส่งผลให้การลู่เข้าของคำตอบนั้นเร็วขึ้น และลดระยะเวลาในการฝึกอบรมของเอเจนต์ (Minh et al., 2016) โดยการทำงานแบบไม่เป็นจังหวะเดียวกันแสดงดังรูปที่ 2.11 และการทำงานแบบไม่จังหวะเดียวกันแสดงดังรูปที่ 2.12



รูปที่ 2.11 การทำงานแบบแบบไม่จังหวะเดียวกันของอัลกอริทึม A3C

```

Algorithm 2: A3C algorithm.
// Assume global shared parameter vector  $\theta$ .
// Assume global shared target parameter vector  $\theta^-$ .
// Assume global shared counter  $T = 0$ .
Initialize thread step counter  $t \leftarrow 1$ 
Initialize target network parameters  $\theta^- \leftarrow \theta$ 
Initialize thread-specific parameters  $\theta = \theta$ 
Initialize network gradients  $d\theta \leftarrow 0$ 
repeat
  Clear gradients  $d\theta \leftarrow 0$ 
  Synchronize thread-specific parameters  $\theta = \theta^-$ 

   $t_{start} = t$ 
  Get state  $s_t$ 
  repeat
    Take action  $a_t$  according to the  $\epsilon$ -greedy policy based on  $Q(s, a; \theta)$ 
    Receive reward  $r_t$  and new state  $s_{t+1}$ 

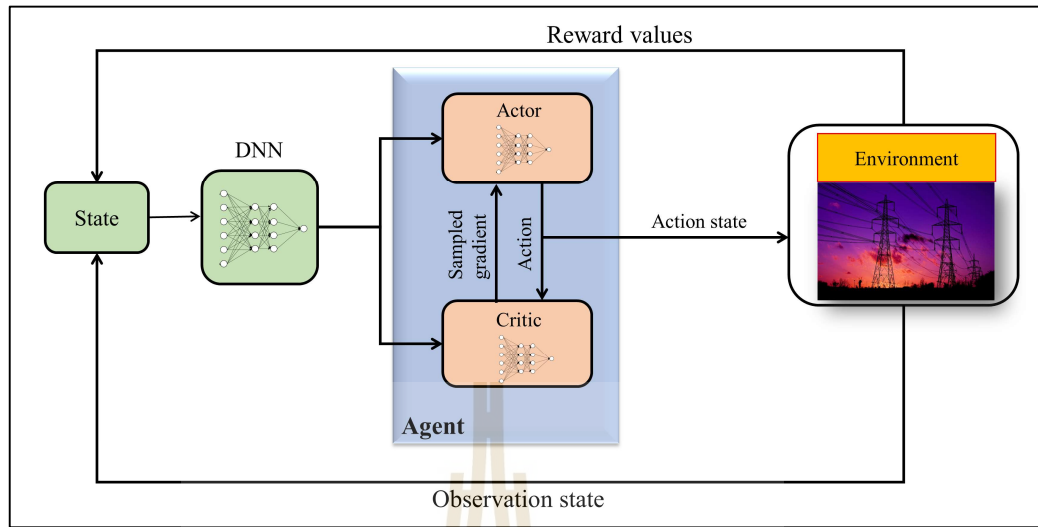
     $t \leftarrow t + 1$ 
     $T \leftarrow T + 1$ 
  until terminal  $s_t$  or  $t - t_{start} = t_{max}$ 
   $R = \begin{cases} 0 & \text{for terminal } s_t \\ \max_a Q(s_t, a; \theta) & \text{for non-terminal } s_t \end{cases}$ 
  for  $i \in \{t-1, \dots, t_{start}\}$  do
     $R \leftarrow r_i + \gamma R$ 
    Accumulate gradients wrt  $\theta$ :  $d\theta \leftarrow d\theta + \frac{\partial(R - Q(s_i, a_i; \theta))^2}{\partial \theta}$ 
  end for
  Perform asynchronous update of  $\theta$  using  $d\theta$ 
  If  $T \bmod t_{sync} = 0$  then
     $\theta^- \leftarrow \theta$ 
  end if
Until  $T > T_{max}$ 

```

รูปที่ 2.12 ชุดโค้ดอัลกอริทึมของ A3C

2.8.3 อัลกอริทึมแบบ DDPG

อัลกอริทึมแบบ DDPG (Deep Deterministic Policy Gradient Algorithm: DDPG) เป็นเทคนิคที่มีแนวคิดในการหาโพลีบายที่เหมาะสม เพื่อแก้ปัญหาของ DQN ที่ให้ค่าฟังก์ชันรางวัลที่ไม่เสถียรและมีค่าที่มากเกินไป ซึ่งในการพัฒนาเทคนิค DDPG ไม่สามารถใช้เทคนิคแบบดั้งเดิมอย่าง Q-Learning มาเป็นพื้นฐานได้ เนื่องจากเทคนิคนี้ใช้เวลาในการหาค่าที่เหมาะสมมากในสถานะการณ์ที่มีความซับซ้อน จึงเป็นเหตุเลือกใช้พื้นฐานมาจากสถาปัตยกรรมของ Actor-critic ที่มีความสามารถในการแก้ปัญหาที่มีความซับซ้อนได้ดีกว่าเป็นพื้นฐานในการพัฒนาเทคนิค (Lillicrap et al., 2015) โดยกระบวนการทำงานของ DDPG แสดงดังรูปที่ 2.13



รูปที่ 2.13 กระบวนการทำงานของ DDPG (Garrido, Nishtala, and Carpenter, 2019)

ในการพัฒนาเริ่มจากเทคนิค Deterministic Policy Gradient (Silver et al., 2014) นั่นคือสมการการหานโยบายที่เหมาะสมต่อระบบโดยวิเคราะห์ค่า Q-function แสดงดังสมการที่ (2.27)

$$\nabla_{\theta^\mu} J \approx \mathbb{E}_{s_t \sim \rho^\beta} \left[\nabla_a Q(s, a | \theta^Q) \Big|_{s=s_t, a=\mu(s_t)} \nabla_{\theta^\mu} \mu(s | \theta^\mu) \Big|_{s=s_t} \right] \quad (2.27)$$

กำหนดให้	$\mu(s \theta^\mu)$	คือ	ฟังก์ชันการกระทำที่ผ่านการปรับปรุงนโยบายของ DDPG
	$Q(s, a \theta^Q)$	คือ	Critic ที่เรียนรู้จากสมการ Q-function
	s และ s_t	คือ	สถานะและสถานะในขณะช่วงเวลานั้น
	a และ a_t	คือ	การกระทำและการกระทำในขณะช่วงเวลานั้น
	θ^Q	คือ	ฟังก์ชันการประมาณค่าเพื่อการปรับปรุงพารามิเตอร์


ρ^π คือ Discounted state ของนโยบาย ซึ่งทำหน้าที่เหมือนค่า γ ที่อยู่ใน Q-function

ต่อมาโครงข่ายประสาทเทียมเชิงลึกได้ถูกประยุกต์ใช้ในเทคนิค DQN ซึ่งแสดงให้เห็นถึงศักยภาพในการคำนวณและวิเคราะห์ในปัญหาที่ซับซ้อน อัลกอริทึม Deterministic Policy Gradient ก็ได้ถูกดัดแปลงในเวลาต่อมาจนกลายเป็น Deep Deterministic Policy Gradient (DDPG) ซึ่งความท้าทายในการใช้อัลกอริทึม DDPG คือ การออกแบบขอบเขตการกระทำ (Action space) เนื่องจาก DDPG จะปรับปรุงนโยบายตามค่า Q-function ซึ่งเกิดจากการกระทำของเอเจนต์ โดยการค้นหานโยบายที่เหมาะสมแสดงดังสมการที่ (2.28)

$$\mu'(s_t) = \mu(s_t | \theta_t^\mu) + N \quad (2.28)$$

กำหนดให้ μ' คือ ผลของการค้นหานโยบายที่เหมาะสม
 N คือ ค่าสัญญาณรบกวนในระบบ (Noise)

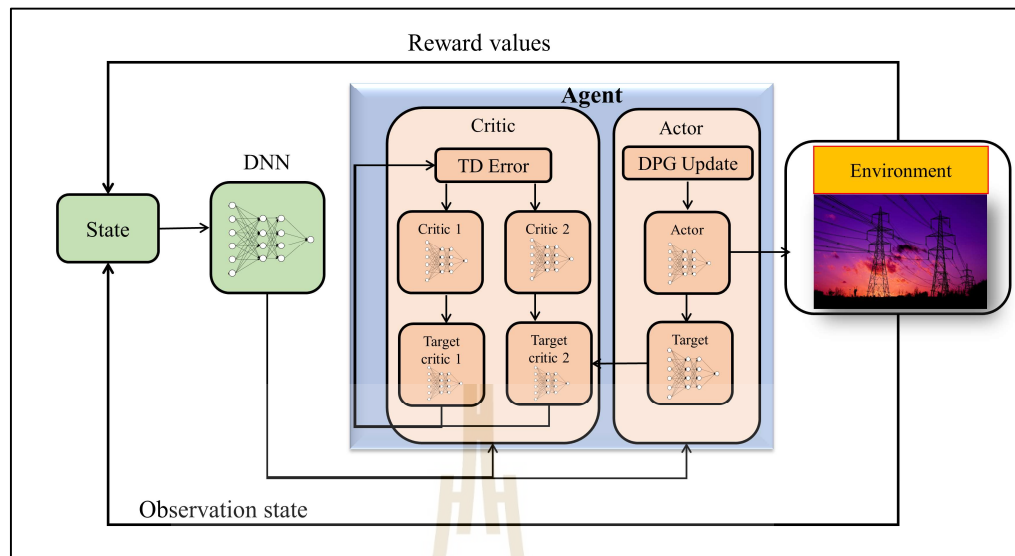
ชุดโค้ดอัลกอริทึมของ DDPG ในรูปที่ 2.14 แสดงถึงการปรับปรุงนโยบายที่ผ่านจากการคำนวณของ ผู้วิจารณ์ และผู้กระทำ



รูปที่ 2.14 ชุดโค้ดอัลกอริทึมของ DDPG

2.8.4 อัลกอริทึมแบบ TD3

อัลกอริทึมแบบ TD3 (Twin-Delayed Deep Deterministic Policy Gradient Algorithm: TD3) ได้พัฒนามาจากเทคนิค DDPG อันเนื่องมาจากการทำงานของอัลกอริทึมในบางครั้งเกิดความบกพร่องในการคำนวณ Q-function ที่ให้เกิดค่าประมาณที่มากเกินไป ซึ่งค่าที่ได้ทำให้การปรับปรุง Policy ผิดพลาด จึงทำให้การเรียนรู้ล้มเหลวเนื่องจากการคำนวณ Q-function นั้นจึงเป็นเหตุให้พัฒนา Twin Delayed DDPG (TD3) ขึ้นมาเพื่อแก้ปัญหาที่เกินขึ้นของการประมาณค่าที่ผิดพลาดของ Q-function (Fujimoto, Van Hoof, and Meger, 2018) โดยกระบวนการทำงานแสดงดังรูปที่ 2.15



รูปที่ 2.15 กระบวนการทำของ TD3 (Zhou, Xue, Xue, Liao et al., 2021)

Q-Learning เป็นแบบคู่ (Double Q-Learning) ในการเพิ่ม Q-Learning ให้ทำงานแบบคู่ โดยทั้งสองฟังก์ชันจะอยู่ภายใต้นโยบายเดียวกันแต่เป้าหมายในการหาค่าที่เหมาะสมจะแตกต่างกัน ซึ่งเป็นวิธีการลดการเกิดการประมาณค่าที่มากเกินไปดังสมการที่ (2.29) และ (2.30)

$$y_1 = r + \gamma Q_{\theta_2}(s', \pi_{\phi_1}(s)) \quad (2.29)$$

$$y_2 = r + \gamma Q_{\theta_1}(s', \pi_{\phi_2}(s)) \quad (2.30)$$

กำหนดให้ π_{ϕ_1} และ π_{ϕ_2} คือ ค่าของการกระทำในนโยบายขณะนั้น
 y_1 และ y_2 คือ ค่าประมาณที่ใช้ในการปรับปรุงนโยบาย

การคัดกรองฟังก์ชัน Q-Learning (Clipped Double-Q Learning) อย่างไรก็ตามถึงแม้จะมี Double Q-Learning แต่ก็ยังมีโอกาสเกิดการประมาณค่าที่มากเกินไป ฉะนั้นจำเป็นต้องหาค่า Q-Learning ที่น้อยที่สุดใน Double Q-Learning เพื่อตัดค่าประมาณที่มากเกินไปออกไปจากการคำนวณ โดยการกรองค่าประมาณที่มากแสดงดังสมการที่ (2.31) ซึ่งค่าที่จะนำไปปรับปรุงนโยบายในครั้งต่อไป

$$y = r + \gamma \min_{i=1,2} Q_{\theta_i} (s', \pi_{\phi_i} (s')) \quad (2.31)$$

กำหนดให้ y คือ ค่าที่ได้คือค่าที่ผ่านการหาค่าที่เหมาะสมของ Double Q-Learning

การปรับนโยบายเพื่อการทำงานให้ราบรื่น (Target policy smoothing) สิ่งที่น่ากังวลในการปรับปรุงนโยบายในบางครั้งนโยบายสามารถเกิดเหตุการณ์จดจำข้อมูลโดยที่ไม่เกิดการเรียนรู้ที่แท้จริง (Overfitting) ซึ่งแนวทางการแก้ไขต้องเพิ่มการรบกวน (Noise) ของสมการการคำนวณเพื่อลดโอกาสการเกิดจดจำข้อมูลโดยที่ไม่เกิดการเรียนรู้ที่แท้จริง แสดงดังสมการที่ (2.33) และ (2.34)

$$y = r + \gamma Q_{\theta_i} (s', \pi_{\phi_i} (s')) + \mathcal{E} \quad (2.32)$$

$$\mathcal{E} \sim \text{clip} (N(0, \sigma), -c, c) \quad (2.33)$$

กำหนดให้ \mathcal{E} คือ ค่าประมาณที่คาดหวังที่คำนวณร่วมกันกับค่าที่สุ่มค่ารบกวนเข้ามา $-c$ และ c คือ ค่าคงที่ในการกำหนด

ซูโดโค้ดอัลกอริทึมของ TD3 ในรูปที่ 2.16 แสดงถึงการปรับปรุงนโยบาย โดยผ่านการคำนวณ Q-function แบบคู่ การคัดกรองค่าที่ได้จาก Q-function แบบคู่ และปรับปรุงค่าที่นำไปคำนวณในการเปลี่ยนแปลงนโยบายเพื่อลดการเกิดค่ารบกวนในระบบ

Algorithm 4: TD3 algorithm.

Initialize critic networks $Q_{\theta_1}, Q_{\theta_2}$ and actor π_ϕ with random parameters θ_1, θ_2, ϕ
Initialize target networks $\theta'_1 \leftarrow \theta_1, \theta'_2 \leftarrow \theta_2, \phi' \leftarrow \phi$
Initialize replay buffer B
for $t = 1$ to T **do**
 Select action with exploration noise $a \sim \pi_\phi(s) + \varepsilon, \varepsilon \sim N(0, \sigma)$
 and observe reward r and new state s'
 Store transition tuple (s, a, r, s') in B
 Sample mini-batch of N transitions (s, a, r, s') from B
 $a \leftarrow \pi_\phi(s') + \varepsilon, \varepsilon \sim \text{clip}(N(0, \sigma), -c, c)$
 $y \leftarrow r + \gamma \min_{i=1,2} Q_{\theta'_i}(s', a)$
 Update critics $\theta_i \leftarrow \text{argmin}_{\theta_i} N^{-1} \sum (y - Q_{\theta_i}(s, a))^2$
 if $t \bmod d$ **then**
 Update ϕ by the deterministic policy gradient:

$$\nabla_\phi J(\phi) = N^{-1} \sum \nabla_a Q_{\theta'_i}(s, a) \Big|_{a=\pi_\phi(s)} \nabla_\phi \pi_\phi(s)$$

 Update target networks:

$$\theta'_i \leftarrow \tau \theta_i + (1 - \tau) \theta'_i$$

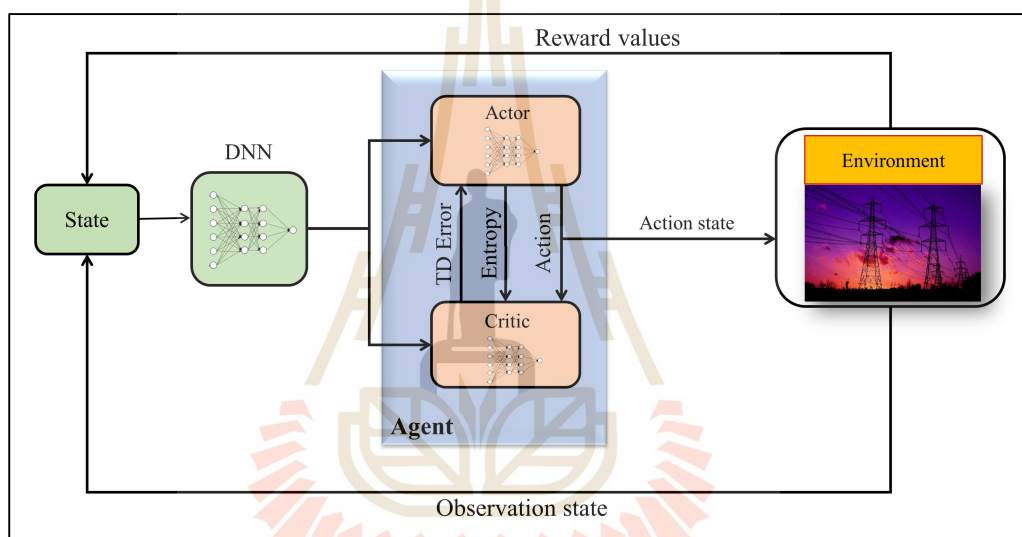
$$\phi' \leftarrow \tau \phi + (1 - \tau) \phi'$$

 end if
end for

รูปที่ 2.16 ซูโดโค้ดอัลกอริทึมของ TD3

2.8.5 อัลกอริทึมแบบ SAC

อัลกอริทึมแบบ SAC (Soft Actor-Critic : SAC) เป็นวิธีการเรียนรู้การเสริมกำลังแบบ Model-free โดยอัลกอริทึมมีพื้นฐานลักษณะการทำงานมาจาก DDPG ส่วนที่สำคัญของ SAC คือ หลักการ Entropy regularization หลักการดังกล่าวถูกใช้ในกระบวนการฝึกอบรมการหา นโยบายที่เหมาะสม ซึ่งส่งผลให้เอเจนต์มีการสำรวจหาคำตอบที่มากขึ้น อีกทั้งยังเพิ่มอัตราการเรียนรู้ที่เร็วขึ้น และยังสามารถลดความเสี่ยงที่จะติดอยู่ที่ Local value โดยโครงสร้างของอัลกอริทึม SAC แสดงดังรูปที่ 2.17 (Haarnoja et al., 2018)



รูปที่ 2.17 กระบวนการทำงานของอัลกอริทึม SAC

หลักการที่สำคัญของอัลกอริทึม SAC นั้นคือ Entropy-regularized ของการเรียนรู้แบบเสริมกำลัง โดยเอนโทรปี คือ ลักษณะการสุ่มค่า ซึ่งสมการการคำนวณดังสมการที่ (2.34)

$$H(P) = E_{x \sim P} [-\log P(x)] \quad (2.34)$$

กำหนดให้	X	คือ	ตัวแปรสุ่มร่วมกับฟังก์ชันความน่าจะเป็น หรือ ความหนาแน่นของข้อมูล P
	H	คือ	ตัวแปรเอนโทรปี ซึ่งคำนวณได้จากฟังก์ชัน P

ใน Entropy-regularized ของการเรียนรู้แบบเสริมกำลัง ปกติเอเจนต์จะรับรางวัลในแต่ละช่วงเวลา (Time step) เมื่อรวมสมการเอนโทรปีเข้าไปในการคำนวณในสมการฟังก์ชันรางวัลที่ 2.19 ในแต่ละช่วงเวลา โดยเป็นไปตามสมการที่ (2.35)

$$\pi^* = \operatorname{argmax}_{\pi} E_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t \left(R(s_t, a_t, s_{t+1}) + \alpha H(\pi(\cdot | s_t)) \right) \right] \quad (2.35)$$

กำหนดให้ α คือ ค่าคงที่ที่อยู่ในช่วงที่มากกว่าศูนย์

จากนั้นแทนค่าลงในฟังก์ชันมูลค่าที่อยู่ในกระบวนการของ Q-function ซึ่งแสดงดังสมการที่ 2.20

$$V^{\pi}(s) = E_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t \left(R(s_t, a_t, s_{t+1}) + \alpha H(\pi(\cdot | s_t)) \right) \middle| s_0 = s \right] \quad (2.36)$$

$$Q^{\pi}(s, a) = E_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1}) + \alpha \sum_{t=1}^{\infty} \gamma^t H(\pi(\cdot | s_t)) \middle| s_0 = s, a_0 = a \right] \quad (2.37)$$

เมื่อนำสมการที่ (2.36) และ (2.37) แทนค่าจะได้สมการความสัมพันธ์ระหว่างเอนโทรปี และ Q-function เป็นไปตามสมการที่ (2.38)

$$V^{\pi} = E_{\tau \sim \pi} \left[Q^{\pi}(s, a) \right] + \alpha H(\pi(\cdot | s)) \quad (2.38)$$

ชุดโค้ดอัลกอริทึมของ SAC ในรูปที่ 2.18 แสดงถึงขั้นตอนของอัลกอริทึม SAC การเริ่มต้นอินพุต การโต้ตอบกับสภาพแวดล้อม การปรับปรุงโครงข่ายโดยใช้บัฟเฟอร์แบบวนซ้ำ และการอัปเดตเป้าหมายเพื่อให้ได้รางวัลสูงที่สุด

Algorithm 5: SAC algorithm.

Input: initial policy parameters θ , Q-function parameters ϕ_1, ϕ_2 , empty replay buffer D

Set target parameters equal to main parameters $\phi_{\text{arg},1} \leftarrow \phi_1, \phi_{\text{arg},2} \leftarrow \phi_2$

repeat

Observe state s and select action $a \sim \pi_\theta(\cdot | s)$

Execute a in the environment

Observe next state s' , reward r , and done signal d to indicate whether s' is terminal

Store (s, a, r, s', d) in replay buffer D

If s' is terminal, reset environment state.

If it's time to update **then**

Randomly sample a batch of transitions, $B = \{(s, a, r, s', d)\}$ from D

Compute targets for the Q functions:

$$y(r, s', d) = r + \gamma(1-d)(\min_{i=1,2} Q_{\phi_{\text{arg},i}}(s', \tilde{a}') - \alpha \log \pi_\theta(\tilde{a}' | s')), \quad \tilde{a}' \sim \pi_\theta(\cdot | s')$$

Update Q-functions by one of gradient descent using

$$\nabla_{\phi_i} \frac{1}{|B|} \sum_{(s,a,r,s',d) \in B} (Q_{\phi_i}(s,a) - y(r,s',d))^2 \quad \text{for } i = 1, 2$$

Update policy by one step of gradient ascent using

$$\nabla_{\theta} \frac{1}{|B|} \sum_{s \in B} (\min_{i=1,2} Q_{\phi_i}(s, \tilde{a}_\theta(s)) - \alpha \log \pi_\theta(\tilde{a}_\theta(s) | s))$$

Update target networks with

$$\phi_{\text{arg},i} \leftarrow \rho \phi_{\text{arg},i} + (1-\rho)\phi_i \quad \text{for } i = 1, 2$$

end for

end if

until convergence

รูปที่ 2.18 ซูโดโค้ดอัลกอริทึมของ SAC

2.9 ปรัชญ์นวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ปรัชญ์นวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับแนวทางการจัดการพลังงานที่เหมาะสมต่อไมโครกริด พิจารณาโหลดที่อยู่อาศัย โหลดพื้นที่ธุรกิจ และสถานีชาร์จยานยนต์ไฟฟ้า พร้อมทั้งประเมินผลกระทบของยานยนต์ไฟฟ้าที่มีต่อระบบไมโครกริด เทคนิคที่ใช้ในการดำเนินงาน และต้นทุนที่เหมาะสม

ตารางที่ 2.3 งานวิจัยที่เกี่ยวข้อง

ค.ศ.	คณะผู้ทำวิจัย	การดำเนินงานวิจัย
2015	Dubey and Santoso	บทความนี้มุ่งเน้นในการศึกษาผลกระทบของสถานีอัดประจุยานยนต์ไฟฟ้าต่อแรงดันไฟฟ้าภายในระบบจำหน่าย พบว่าผลกระทบจากสถานีชาร์จได้ส่งผลกระทบต่อระบบจำหน่ายโดยตรง ในเรื่องของแรงดันตกเมื่อยานยนต์ไฟฟ้าเข้าชาร์จไฟ การเพิ่มสถานีชาร์จที่ใกล้เคียงทำให้เกิดแรงดันตกเป็นสองเท่า และการเพิ่มขึ้นของยานยนต์ไฟฟ้าที่ส่งผลกระทบต่อความต้องการไฟฟ้าที่มากขึ้น
2015	Sun, Li, Niu and Foley	บทความนี้ได้วิเคราะห์ผลกระทบของการอัดประจุยานยนต์ไฟฟ้า โดยศึกษารูปแบบการชาร์จ 3 ระดับได้แก่ ระดับการอัดประจุที่พักอาศัย (กระแส 16 A) ระดับการอัดประจุพื้นที่สาธารณะ (กระแส 32 A) และระดับการชาร์จแบบเร็ว (กระแส 63 A) โดยศึกษาร่วมกับกราฟคุณลักษณะของโหลดการอัดประจุยานยนต์ไฟฟ้าทั้งการอัดประจุในเวลา off-peak และ on-peak ภายในประเทศไอร์แลนด์ ซึ่งได้แสดงถึงพฤติกรรมของคนที่ใช้ยานยนต์ไฟฟ้าเป็นอย่างดี

ตารางที่ 2.3 งานวิจัยที่เกี่ยวข้อง (ต่อ)

ค.ศ.	คณะผู้ทำวิจัย	การดำเนินงานวิจัย
2017	Deb, Tammi, Kalita, and Mahanta	บทความนี้ได้วิเคราะห์ผลกระทบของสถานีอัดประจุยานยนต์ไฟฟ้าที่มีผลกระทบต่อระบบโครงข่าย 33 โนด โดยมีขนาดโหลด 1500-7500 kW พิจารณาตำแหน่งการติดตั้งที่โนด 2 14 15 และ 19 ซึ่งโนดที่ 2 และ 19 เป็นโนดที่แรงดันคงที่ ส่วนโนดที่ 14 และ 15 เป็นโนดที่แรงดันต่ำกว่าเกณฑ์ ผลที่ได้จากการศึกษาและวิเคราะห์พบว่าแบบจำลองโครงข่าย ที่ตำแหน่งโนด 14 และ 15 เป็นโนดที่มีความอ่อนแออย่างมากในการตั้งสถานีชาร์จจึงทำให้เกิดแรงดันตกไปจนถึงโนดที่ 18 เมื่อเทียบกับการติดตั้งที่โนด 2 และ 19 พบว่าแรงดันมีความเปลี่ยนแปลงเพียงเล็กน้อยและสามารถรับโหลดสถานีอัดประจุยานยนต์ไฟฟ้าได้มากถึง 7500 kW
2019	Hesaroor and Das	ได้นำเสนอการหาขนาดของระบบกักเก็บพลังงานที่เหมาะสมเพื่อรองรับความไม่แน่นอนของโหลดและพลังงานหมุนเวียนโดยการจัดเก็บพลังงานในช่วงที่มีความต้องการพลังงานต่ำ และปล่อยพลังงานออกมาเมื่อเกิดภาวะที่ขาดแคลนพลังงาน โดยใช้ฟังก์ชัน วัตถุประสงค์เป็นค่าใช้จ่ายที่น้อยที่สุด ในการพิจารณาขนาดระบบกักเก็บพลังงานในระบบทดสอบ IEEE 33 โนด ใช้เทคนิคเมตาฮีวิริสติกในการหาค่าที่เหมาะสม โดยสามารถลดค่าใช้จ่ายเดิมได้ถึง 48 % นับว่าเป็นครั้งหนึ่งของค่าใช้จ่ายเดิมของระบบกักเก็บพลังงาน
2021	Guo, Wang, Zheng and Zhang	บทความนี้ได้แสดงประสิทธิภาพในการใช้เทคนิค DDPG DQN และ Double DQN ในการควบคุมการซื้อ-ขายไฟฟ้าระหว่างไมโครกริด และเปรียบเทียบประสิทธิภาพความแม่นยำกับเทคนิค (Genetic Algorithm: GA) โดยแสดงให้เห็นถึงวิวัฒนาการของความสามารถ DRL ที่มีความแม่นยำมากกว่า Genetic Algorithm

ตารางที่ 2.3 งานวิจัยที่เกี่ยวข้อง (ต่อ)

ค.ศ.	คณะผู้ทำวิจัย	การดำเนินงานวิจัย
2021	Wang, Xu, Hee and Yan	นำเสนอวิธีการหาขนาดของพลังงานเซลล์แสงอาทิตย์ เพื่อควบคุมแรงดันไฟฟ้าในระบบ IEEE 33 โนด โดยใช้ MADDPG และ MADQN และวิเคราะห์ความสามารถในการหาขนาดที่เหมาะสมเพื่อควบคุมแรงดันไฟฟ้า และการสูญเสียพลังงานของทั้งระบบ ในขณะที่ติดตั้งพลังงานเซลล์แสงอาทิตย์ โดยใช้เทคนิคดังกล่าว
2021	Wang, Xu, Gu, Song and Green	ในบทความนี้ได้มุ่งเน้นไปที่การควบคุมแรงดันภายในระบบไมโครกริด โดยใช้ MATD3 และ MADDPG ทดสอบผ่านโครงข่าย 33 โนด โดยปัญหาที่พบในการจำลองผลนั้น คือ การเปลี่ยนแปลงของระบบไฟฟ้าที่เร็วเกินไปหรือที่ซับซ้อนเกินไป และการแชร์นโยบาย อาจทำให้เอเจนต์ไม่สามารถตอบสนองต่อระบบโครงข่ายได้ทัน และการแชร์นโยบายของเอเจนต์ทำให้การหาค่าที่เหมาะสมผิดเพี้ยนในบางกรณี
2021	Gillera, Bonnema, Woods, Mishra, et al.	ผู้วิจัยได้นำเสนอถึงผลกระทบของสถานีอัดประจุไฟฟ้าความเร็วสูงมีขนาดตั้งแต่ 50 150 และ 350 kW มีจำนวนหัวชาร์จตั้งแต่ 2 หัวชาร์จจนถึง 6 หัวชาร์จ โดยสร้างกรณีศึกษาสถานีอัดประจุยานยนต์ไฟฟ้าผ่านโปรแกรม EnergyPlus เพื่อศึกษาแนวโน้มความต้องการไฟฟ้าในแต่ละช่วงเวลา
2022	Lee, Kang and Kim	นำเสนอการหาขนาดระบบกักเก็บพลังงาน ร่วมกับพลังงานเซลล์แสงอาทิตย์เพื่อแก้ไขปัญหาที่พลังงานเซลล์แสงอาทิตย์มีความผันผวนในการผลิตพลังงานไฟฟ้า เนื่องจากสภาพอากาศที่คาดการณ์ได้ยาก โดยพิจารณาขนาดของระบบกักเก็บพลังงานร่วมกับค่าใช้จ่ายการลงทุน

ตารางที่ 2.3 งานวิจัยที่เกี่ยวข้อง (ต่อ)

2023	Deeum, Charoenchan, Janjamraj, Romphochai, Baum, Ohgaki, Mithulananthan and Bhumkittipich	ในบทความนี้ได้ศึกษาการหาตำแหน่งที่เหมาะสมของสถานีอัดประจุยานยนต์ไฟฟ้า ร่วมกับระบบผลิตพลังงานจากเซลล์แสงอาทิตย์ และระบบกักเก็บพลังงานแบบแบตเตอรี่ ในระบบโครงข่ายทดสอบ IEEE-33 โหนด โดยวิเคราะห์ตำแหน่งที่เหมาะสม ด้วยการแบ่งพื้นที่การวิเคราะห์เป็น 5 ส่วน โดยพื้นที่แต่ละส่วนจะมีโหลดพื้นฐานที่แตกต่างกัน
------	---	---

การศึกษาเกี่ยวกับการแนวทางการจัดการพลังงานที่เหมาะสมต่อไมโครกริด โดยพิจารณาโหลดที่อยู่อาศัย โหลดพื้นที่ธุรกิจและสถานีชาร์จยานยนต์ไฟฟ้า มีงานวิจัยและเอกสารที่เผยแพร่ออกมาเป็นจำนวนมากในช่วงไม่กี่ปีที่ผ่านมา ในการศึกษาขั้นต้นมีการศึกษาเกี่ยวกับผลกระทบของสถานีชาร์จยานยนต์ไฟฟ้าที่มีผลต่อไมโครกริด ในเรื่องของแรงดันตกเมื่อยานยนต์ไฟฟ้าเข้าชาร์จไฟ หรือการเพิ่มขึ้นของยานยนต์ ซึ่งนำไปสู่ความต้องการพลังงานไฟฟ้าและความเชื่อมั่นที่มากขึ้น (Dubey and Santoso, 2015) ต่อมาได้มีการวิเคราะห์ถึงคุณลักษณะความต้องการพลังงานไฟฟ้าของสถานีอัดประจุแบบเร็วที่ขนาด 50 150 และ 350 kW ในพื้นที่สาธารณะ เพื่อสังเกตแนวโน้มของกำลังไฟฟ้าที่เกิดขึ้นในช่วงเวลาที่มีการอัดประจุยานยนต์ไฟฟ้า (Gilleran et al., 2021) การศึกษาพฤติกรรมชาร์จทั้งช่วงกลางวันและกลางคืน พบว่าในเขตที่พักอาศัยมีพฤติกรรมชาร์จตั้งแต่ 18.00 น. ถึง 24.00 น. และ 00.00 น. ถึง 05.00 น. นอกจากนั้นได้มีการศึกษาผลกระทบของการติดตั้งสถานีชาร์จยานยนต์ไฟฟ้าในระบบทดสอบ IEEE 33 โหนด โดยติดตั้งไว้ที่ตำแหน่งที่โหนดแรงดันต่ำ เพื่อศึกษาหากเกิดสถานการณ์ที่ต้องติดตั้งในระบบโครงข่ายที่มีแรงดันต่ำ ซึ่งในการแก้ปัญหาที่แพร่หลายนั้นคือการติดตั้ง RES ร่วมกับระบบกักเก็บพลังงาน เพื่อช่วยในการรองรับในช่วงที่พลังงานหมุนเวียนไม่เพียงพอต่อระบบ (Lee, Kang and Kim, 2022) นอกจากนี้มีการศึกษาการหาตำแหน่งของการติดตั้งสถานีอัดประจุไฟฟ้า ร่วมกับพลังงานเซลล์แสงอาทิตย์ และระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยวิเคราะห์เป็นแบบ 5 ส่วนในระบบ IEEE 33 โหนด ในแต่ละส่วนจะมีโหลดที่แตกต่างกัน ซึ่งเป็นกรณีศึกษาที่มีความซับซ้อนมากขึ้นในการหาค่าที่เหมาะสม โดยใช้ปัญญาประดิษฐ์

ที่ผ่านมาปัญญาประดิษฐ์อย่างการเรียนรู้แบบเสริมกำลังเชิงลึกได้ถูกประยุกต์ใช้งานใน วัตถุประสงค์ทางไฟฟ้าต่าง ๆ อย่างเช่นในงานของ Guo et al. (2021) ที่พิสูจน์ประสิทธิภาพการใช้ DRL ด้วยเทคนิค DDPG DQN และ Double DQN เปรียบเทียบกับเทคนิคดั้งเดิมอย่าง GA ด้วยการ ประยุกต์ใช้ในการซื้อ-ขาย ไฟฟ้าในระบบไมโครกริด ซึ่งผลการเปรียบเทียบที่ได้พบว่า DRL มี ประสิทธิภาพที่เหนือกว่าเทคนิค GA อย่างชัดเจน นอกจากนี้ในการหาขนาดของบทความ Wang et al. (2021) ได้ประยุกต์ใช้ MADRL เทคนิค MADDPG และ MADQN เพื่อหาขนาดของพลังงานเซลล์ แสงอาทิตย์ เพื่อปรับปรุงแรงดันและลดกำลังงานสูญเสียในระบบไมโครกริด และในบทความของ Wang et al. (2022) ก็เช่นกันในการประยุกต์ใช้ MATD3 และ MADDPG ซึ่งปัญหาที่อาจเกิดขึ้นเมื่อ ใช้เทคนิคเหล่านี้ อาจทำให้เอเจนต์ไม่สามารถตอบสนองต่อระบบโครงข่ายได้ทันที และการแชร์ ค่าพารามิเตอร์บางอย่างระหว่างเอเจนต์อาจทำให้การหาค่าที่เหมาะสมผิยในบางครั้ง

จากงานวิจัยที่ผ่านมาในการรวมพลังงานหมุนเวียนร่วมกับระบบกักเก็บพลังงาน เพื่อแก้ไข ปัญหาทั้งในเรื่องของแรงดันตกในระบบโครงข่าย กำลังไฟฟ้าสูญเสียที่มากขึ้น เนื่องจากโหลดที่มาก ขึ้น และการหาค่าที่เหมาะสมโดยใช้เทคนิค MADRL มาประยุกต์ใช้เพื่อหาขนาดของแหล่งจ่ายที่ เหมาะสม โดยแสดงให้เห็นถึงประสิทธิภาพของ MADRL ที่นำมาประยุกต์ใช้ในการวิเคราะห์ทางไฟฟ้า แต่ยังไม่ครอบคลุมในเรื่องของการวิเคราะห์ระบบพลังงานหมุนเวียนอย่าง กังหันลม พลังงานเซลล์ แสงอาทิตย์ และระบบกักเก็บพลังงานแบบแบตเตอรี่ เพื่อจัดการพลังงานที่เหมาะสมในงานวิจัยนี้จึง ได้วิเคราะห์การหาตำแหน่งและขนาดของพลังงานหมุนเวียน และระบบจัดเก็บพลังงาน พิจารณา โหลดที่พักอาศัย โหลดพื้นที่ธุรกิจ และสถานีชาร์จยานยนต์ไฟฟ้า โดยมีวัตถุประสงค์ในการปรับปรุง แรงดันไฟฟ้า ลดกำลังสูญเสียของระบบ และหาค่าใช้จ่ายที่น้อยที่สุด

2.10 สรุป

ในบทนี้ได้กล่าวถึงความรู้พื้นฐานที่สำคัญสำหรับการศึกษาการจัดการพลังงานในระบบโครงข่ายไฟฟ้า สถานีอัดประจุยานยนต์ไฟฟ้า และอัลกอริทึมการเรียนรู้เสริมกำลังเชิงลึกหลายเอเจนต์ สิ่งที่ต้องศึกษา ได้แก่ วิเคราะห์การไหลของกำลังไฟฟ้าของระบบโครงข่าย หรือการประยุกต์ใช้การเรียนรู้เสริมกำลังเชิงลึกแบบหลายตัวในการปรับปรุงแรงดัน และกำลังไฟฟ้าสูญเสีย โดยปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้องของการจัดการพลังงานในระบบโครงข่าย โดยมีโหนดที่פקอาศัย โหลดพื้นที่ธุรกิจ รวมถึงสถานีอัดประจุยานยนต์ไฟฟ้าแบบเร็ว และแนวทางในการปรับปรุงคุณภาพของระบบโครงข่ายไฟฟ้า เพื่อเป็นแนวทางและกรณีศึกษาของการปรับปรุงระบบไฟฟ้า โดยใช้เทคนิคการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ ในบทถัดไปเป็นการอธิบายถึงขั้นตอนวิธีการดำเนินการวิจัยของงานวิทยานิพนธ์นี้

บทที่ 3

วิธีดำเนินการวิจัย

3.1 กล่าวนำ

การจัดการพลังงานในไมโครกริด โดยประยุกต์ใช้การเรียนรู้เสริมกำลังเชิงลึกหลายเอเจนต์ เพื่อหาขนาด และตำแหน่งที่ตั้งของพลังงานหมุนเวียนร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ จำเป็นต้องมีการทดสอบประสิทธิภาพของอัลกอริทึม เพื่อหาพารามิเตอร์ที่เหมาะสมทั้งข้อดี และ ข้อด้อยของแต่ละอัลกอริทึม การวางแผนออกแบบกรณีศึกษาลักษณะของโหลดภายในไมโครกริด และตำแหน่งที่ตั้งสถานีอัดประจุยานยนต์ไฟฟ้า เพื่อจำลองปัญหาที่หลากหลาย และศึกษา ผลกระทบแต่ละกรณีศึกษา โดยใช้อัลกอริทึมการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์หา ตำแหน่ง ขนาดที่ตั้งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่เหมาะสม โดย วิธีดำเนินการวิจัยหรือขั้นตอนการจำลองได้อธิบายไว้ในบทนี้

3.2 การตรวจสอบสมรรถนะของ MADRL ด้วยฟังก์ชันมาตรฐาน

ก่อนเริ่มการจำลองในระบบโครงข่ายไฟฟ้าจำเป็นต้องทดสอบสมรรถนะของแบบจำลอง ปัญหาประดิษฐ์เพื่อตรวจสอบการทำงานของแต่ละแบบจำลองสามารถหาคำตอบได้หรือไม่ (Sovann Ang, 2017) ซึ่งในวิทยานิพนธ์ได้มีแบบจำลอง MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยการทดสอบพารามิเตอร์เช่น อัตราการเรียนรู้ (Learning Rate) หรือจำนวนเอเจนต์จะใช้ ค่าที่เท่ากันเพื่อความสมดุลในการเปรียบเทียบประสิทธิภาพ โดยได้นำสมการคณิตศาสตร์ ฟังก์ชัน Unimodal Function และ ฟังก์ชัน Multimodal Function เป็นสมการทดสอบในครั้งนี้แสดงดัง ตารางที่ 3.1

ตารางที่ 3.1 ฟังก์ชันทดสอบ (Zhang et al., 2016)

ลำดับ	ฟังก์ชัน	ช่วง	f_{min}
F1	$F(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
F2	$F(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-100, 100]$	0
F3	$F(x) = \sum_{i=1}^n x_i^2 - 10 \cos(2\pi x_i) + 10 $	$[-5.12, 5.12]$	0
F4	$F(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600, 600]$	0

3.3 การจัดการพลังงานที่เหมาะสมของระบบโครงข่ายไฟฟ้า

ในงานวิจัยนี้ได้มุ่งเน้นหาตำแหน่ง และขนาดติดตั้งที่เหมาะสมของพลังงานแสงอาทิตย์ พลังงานกังหันลม และระบบกักเก็บพลังงานด้วยแบตเตอรี่ เพื่อปรับปรุงคุณภาพของระบบไฟฟ้าโดยมีจุดประสงค์เพื่อลดกำลังสูญเสียในระบบ และค่าใช้จ่ายน้อยที่สุด โดยกล่าวดังสมการต่อไปนี้

3.3.1 กำลังไฟฟ้าสูญเสียในระบบไฟฟ้า

งานวิจัยของ Junhuathon (2018) ได้แสดงการวิเคราะห์กำลังไฟฟ้าสูญเสียของระบบรวมของระบบ โดยสมมติให้คือกำลังไฟฟ้าสูญเสียรวมของแต่ละโหนด แสดงดังสมการที่ (3.1) และ (3.2)

$$S_{total\ loss} = \sum_{i=1}^n \sum_{j=1}^n (S_{ik} + S_{ki}) \quad (3.1)$$

$$P_{loss} = \text{real} \left(\sum_{i=1}^n S_{iTotal\ loss} \right) \quad (3.2)$$

กำหนดให้ S_{ik} และ S_{ki} คือ กำลังไฟฟ้าปรากฏระหว่างโหนดนั้น ๆ
 i และ j คือ ตำแหน่งโหนด i และตำแหน่งโหนด j

$S_{total\ loss}$	คือ	กำลังปรากฏที่สูญเสียในระบบ
P_{loss}	คือ	กำลังไฟฟ้าจริงที่สูญเสียในระบบ

3.3.2 ค่าใช้จ่ายในการลงทุนของระบบ

ในวิทยานิพนธ์ฉบับนี้ ได้วิเคราะห์การจัดการพลังงานที่เหมาะสม โดยคำนึงถึงการลงทุนที่ต่ำที่สุดดังสมการที่ (3.3) และอ้างอิงราคาต้นทุนจากงานวิจัยของ Tooryan et al. (2020) โดยแสดงราคาต้นทุนการติดตั้งพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ดังตารางที่ 3.2

ตารางที่ 3.2 ค่าใช้จ่ายของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงาน

ชนิดของพลังงาน	ต้นทุนติดตั้ง (บาท/kW)	ค่าบำรุงรักษา (บาท/kW)	ค่าเปลี่ยนอุปกรณ์ ใหม่ (บาท/kW)
พลังงานเซลล์แสงอาทิตย์	42,000	105	42,000
พลังงานกังหันลม	64,750	3500	49,000
ระบบกักเก็บพลังงานแบบ แบตเตอรี่	5,250	525	5,250

$$C_{Total} = C_{Cost,PV} + C_{Cost,WT} + C_{Cost,BESS} \quad (3.3)$$

กำหนดให้	C_{Total}	คือ	ค่าลงทุนในการติดตั้งทั้งหมด
	$C_{Cost,PV}$	คือ	ค่าลงทุนในการติดตั้งของพลังงานเซลล์แสงอาทิตย์
	$C_{Cost,WT}$	คือ	ค่าลงทุนในการติดตั้งกังหันลมผลิตไฟฟ้า
	$C_{Cost,BESS}$	คือ	ค่าลงทุนในการติดตั้งของระบบกักเก็บพลังงาน

3.3.3 เงื่อนไขของระบบโครงข่ายไฟฟ้า

การหาขนาดและตำแหน่งติดตั้งที่เหมาะสมจำเป็นต้องอยู่ภายใต้มาตรฐานที่กำหนดให้ พิกัดแรงดันไฟฟ้า และกำลังไฟฟ้า (Elifura Reuben Mmary, 2017) แสดงดังสมการที่ (3.4) และ (3.5)

$$V_{\min} \leq V_i \leq V_{\max} \quad (3.4)$$

$$P_{\min} \leq P_i \leq P_{\text{total demand}} \quad (3.5)$$

กำหนดให้	V_{\min} และ V_{\max}	คือ	แรงดันไฟฟ้าต่ำสุดและมากที่สุดในระบบโครงข่าย
	V_i	คือ	แรงดันไฟฟ้าที่โหนดนั้น ๆ
	P_{\min} และ $P_{\text{total demand}}$	คือ	กำลังไฟฟ้าน้อยที่สุดและความต้องการกำลังไฟฟ้ารวมในระบบ
	P_i	คือ	กำลังไฟฟ้าที่โหนดนั้น ๆ

3.3.4 ระบบกักเก็บพลังงานด้วยแบตเตอรี่

การหาขนาดและตำแหน่งแบตเตอรี่จำเป็นต้องคำนึงถึงโหลด และพลังงานหมุนเวียนในระบบโครงข่ายนั้น ๆ (Zagoras et al., 2015) แสดงดังสมการที่ (3.6) และ (3.7)

$$P^{BESS} = \sum_{t=1}^n (P_t^{Load} + P_t^{Loss} - P_t^{PV} - P_t^{WT} - P_t^{Grid}) \quad (3.6)$$

$$P^{BESS_{\min}} \leq P_i^{BESS} \leq P^{BESS_{\max}} \quad (3.7)$$

กำหนดให้	P_t^{PV} และ P_t^{WT}	คือ	กำลังไฟฟ้าที่ได้จากเซลล์แสงอาทิตย์และกังหันลม
	P_t^{Load} และ P_t^{Loss}	คือ	โหลดรวมภายในระบบและกำลังงานสูญเสียของระบบ
	$P^{BESS_{\min}}$ และ $P^{BESS_{\max}}$	คือ	พลังงานที่สามารถกักเก็บได้ต่ำสุดและสูงสุด
	P_i^{BESS}	คือ	พลังงานของระบบกักเก็บพลังงานในขณะนั้น
	P_t^{Grid}	คือ	พลังงานที่ได้จากกริด

ปริมาณที่สามารถชาร์จและคายประจุได้แสดงดังสมการที่ (3.8)

$$P_{\text{Dischard}}^{\text{BESS}} \leq P_t^{\text{BESS}} \leq P_{\text{Charge}}^{\text{BESS}} \quad (3.8)$$

กำหนดให้ $P_{\text{Dischard}}^{\text{BESS}}$ และ $P_{\text{Charge}}^{\text{BESS}}$ คือ กำลังไฟฟ้าที่สามารถคายประจุได้ต่ำสุดและชาร์จได้มากที่สุด

P_t^{BESS} คือ กำลังไฟฟ้าของแบตเตอรี่ในขณะเวลานั้น

3.3.5 การหาขนาด และตำแหน่งแบตเตอรี่

ในงานวิจัยของ Junhuathon (2018) ได้กล่าวถึงวิธีการการหาขนาดและตำแหน่งที่เหมาะสม ในการเลือกขนาดพิกัดในการติดตั้ง เมื่อได้ค่าที่เหมาะสมผ่านอัลกอริทึมสามารถนำค่าที่ได้มาคูณเพื่อปรับปรุงขนาดของพิกัดในการติดตั้งดังสมการที่ (3.9)

$$P^{\text{Optimal}} = \rho P_{\text{min}}^{\text{Size}} \quad (3.9)$$

กำหนดให้ P^{Optimal} คือ ขนาดของพิกัดที่เหมาะสม

ρ คือ ค่าที่ได้จากการหาค่าที่เหมาะสมผ่านอัลกอริทึมเพื่อปรับแก้ขนาดพิกัด

การหาตำแหน่งที่เหมาะสมสามารถทำได้โดยการนำกำลังสูญเสียรวมในระบบมาเปรียบเทียบ ณ ตำแหน่งติดตั้งแหล่งพลังงาน หรือแบตเตอรี่ตำแหน่งนั้น ๆ เพื่อหาตำแหน่งติดตั้งที่ลดกำลังไฟฟ้าสูญเสียได้ดีที่สุดแสดงดังสมการที่ (3.10)

$$F^{\text{Place}} = \sum_{i=1}^n X_{\text{Best lost}}^i \quad (3.10)$$

กำหนดให้ i คือ ตำแหน่งโนด

F^{Place} คือ ตำแหน่งที่เหมาะสมในการติดตั้ง

$X_{\text{Best lost}}^i$ คือ ค่ากำลังไฟฟ้าสูญเสีย ณ ตำแหน่งนั้น

3.3.6 ค่าใช้จ่ายของระบบกักเก็บพลังงาน

ในการหาค่าใช้จ่ายของระบบกักเก็บพลังงานมีปัจจัยอยู่หลัก ๆ นั่นคือ ขนาดของระบบกักเก็บพลังงานไฟฟ้า ค่าใช้จ่ายในขั้นตอนการดำเนินงาน (Operation cost) และการบำรุงรักษา (Maintenance cost) โดยแสดงดังสมการที่ (3.11) – (3.13) ตามลำดับ (Kerdphol, 2016)

$$C_{Capital} = C_P P_{BESS} + C_W C_{BESS} \quad (3.11)$$

$$C_{O\&M,BESS} = C_{OM,Bath/W} P_{BESS} + C_{OM,Bath/Wh} C_{BESS} \quad (3.12)$$

$$C_{Cost,BESS} = C_{O\&M,BESS} + C_{Capital} \quad (3.13)$$

กำหนดให้

$C_{Capital}$	คือ	ค่าลงทุนในการติดตั้ง (บาท)
$C_{O\&M,BESS}$	คือ	ค่าลงทุนในการดำเนินงานและบำรุงรักษา (บาท/W)
P_{BESS}	คือ	กำลังไฟฟ้าของระบบกักเก็บพลังงาน (W)
C_{BESS}	คือ	ขนาดของระบบกักเก็บพลังงานไฟฟ้า (บาท/W)
C_P	คือ	ค่าใช้จ่ายของกำลังงานต่อหน่วยของระบบกักเก็บพลังงานไฟฟ้า (บาท/W)
C_W	คือ	ค่าใช้จ่ายของขนาดของระบบต่อหน่วยของระบบกักเก็บพลังงานไฟฟ้า (บาท/Wh)
$C_{OM,Bath/W}$	คือ	ค่าดำเนินงานและบำรุงรักษาของระบบกักเก็บพลังงาน (บาท/W)
$C_{OM,Bath/Wh}$	คือ	ค่าการทำงานและบำรุงรักษาของระบบกักเก็บพลังงาน (บาท/Wh)
$C_{Cost,BESS}$	คือ	ค่าลงทุนในการติดตั้งของระบบกักเก็บพลังงาน (บาท)

3.4 ชุดข้อมูลในการจำลองของระบบโครงข่ายไฟฟ้า

การจำลองพลังงานแสงอาทิตย์ และพลังงานกังหันลมได้พิจารณาตำแหน่งที่ละติจูด 14.86 องศาเหนือ ลองจิจูด 101.56 องศาตะวันออก เป็นตำแหน่งที่ตั้งของ ศูนย์อนุรักษ์พันธุกรรมพืชอันเนื่องมาจากพระราชดำริสมเด็จพระเทพรัตนราชสุดาฯ สยามบรมราชกุมารี มหาวิทยาลัยเทคโนโลยีสุรนารี ต.คลองไผ่ อ.สีคิ้ว จ.นครราชสีมา โดยข้อมูลความเข้มแสงและความเร็วลมที่ได้ในการจำลองพลังงานแสงอาทิตย์ และพลังงานกังหันลมมาจากเว็บไซต์องค์กร NASA (The National Aeronautics and Space Administration, 2023) โหลดพื้นที่อยู่อาศัยและพื้นที่ธุรกิจได้ใช้ข้อมูลจากการไฟฟ้าส่วนภูมิภาคของจังหวัดนครราชสีมา (การไฟฟ้าส่วนภูมิภาค, 2023) โดยขนาดสูงสุดอยู่ที่ 300 kW และโหลดสถานีอัดประจุไฟฟ้ายานยนต์แบบเร็วที่ขนาด 150 kW จำนวนหกหัวชาร์จ (Gilleran et al., 2021) โดยที่กล่าวมาการจำลองจะอยู่บนพื้นฐานภาษา Python และวิธีการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ เพื่อการจัดการพลังงานที่เหมาะสม โดยการจัดการขนาดและตำแหน่งที่ตั้งที่เหมาะสม ซึ่งคำนึงถึงการปรับปรุงแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียและความคุ้มค่าในการลงทุน

3.4.1 แบบจำลองพลังงานแสงอาทิตย์

ปัจจัยสำคัญที่มีผลต่อกำลังผลิตพลังงานไฟฟ้าเซลล์แสงอาทิตย์ คือ ความเข้มแสง (W/m^2) อุณหภูมิ ความชื้น และประสิทธิภาพของแผงโซลาร์เซลล์ เป็นต้น โดยข้อมูลอุณหภูมิแวดล้อม ความเข้มแสงที่ตกกระทบผิวโลก และคุณลักษณะของกำลังผลิตของพลังงานเซลล์แสงอาทิตย์แสดงดังรูปที่ 3.1 3.2 และ 3.3 โดยรูปที่ 3.3 ได้นำเอาค่าสูงสุดของกำลังผลิตมาคำนวณเพื่อเปลี่ยนเป็นต่อหน่วย ในการใช้งานจริงทางวิศวกรรมสามารถหาค่าประมาณกำลังผลิตพลังงานเซลล์แสงอาทิตย์ได้จากสมการที่ (3.14) สมการคำนวณต้นทุนที่ (3.15) และข้อมูลที่ใช้ในการจำลองแสดงดังตารางที่ 3.3

$$P_{PV}(t) = \eta_m * [1 - \beta(T_C - T_{ref})] * A * G(t) \quad (3.14)$$

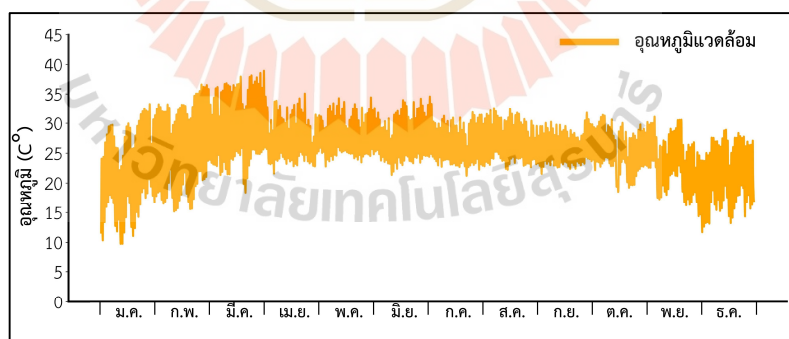
$$C_{Cost,PV} = C_{PV} P_{PV} \quad (3.15)$$

กำหนดให้	P_{PV}	คือ	กำลังผลิตของพลังงานเซลล์แสงอาทิตย์
	T_C	คือ	อุณหภูมิของแผงเซลล์แสงอาทิตย์


T_{ref}	คือ	อุณหภูมิอ้างอิงโดยปกติอยู่ที่ 25 C° จากมาตรฐาน Standard Test Condition (STC) และ $G(t)$ คือ ความเข้มข้นของแสงอาทิตย์
$C_{Cost,PV}$ และ C_{PV}	คือ	ค่าลงทุนในการติดตั้ง และ ค่าใช้จ่ายของกำลังงานต่อบาทของระบบก็ก เก็บพลังงานไฟฟ้า หน่วย บาท/kW

ตารางที่ 3.3 ข้อมูลทางเทคนิคที่ใช้ในการจำลองของพลังงานเซลล์แสงอาทิตย์ (Solar Thailand, 2023)

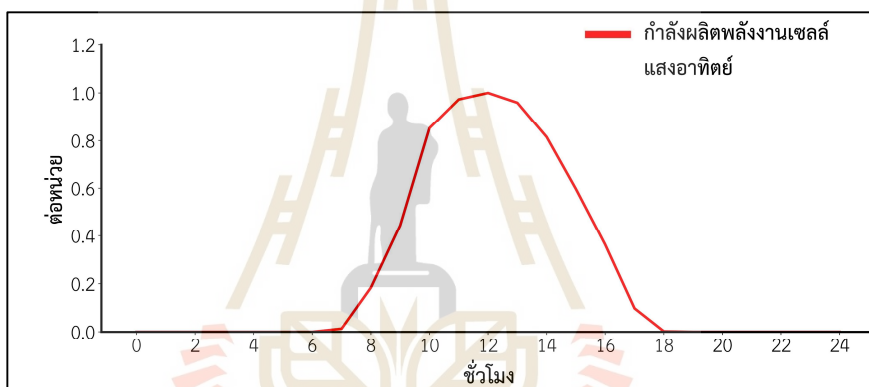
พารามิเตอร์	รายละเอียด
ยี่ห้อ	JA Solar Panel 550 W
ชนิดแผง	ผลึกแบบเดี่ยว
ขนาดกำลังไฟฟ้า (W)	550
Standard test condition (%)	16.6
อุณหภูมิปกติของแผง (°C)	40
อายุการใช้งาน (ปี)	25



รูปที่ 3.1 ลักษณะอุณหภูมิเฉลี่ยในแต่ละเดือน



รูปที่ 3.2 ลักษณะของความเข้มแสงในหนึ่งปี



รูปที่ 3.3 ลักษณะเฉพาะของกำลังผลิตพลังงานเซลล์แสงอาทิตย์

3.4.2 แบบจำลองของกำลังผลิตไฟฟ้ากังหันลม

โดยการคำนวณกำลังผลิตของกังหันลมนั้นจะประกอบไปด้วย ความเร็วลม ขนาด และพื้นที่หน้าตัดของใบพัดของกังหันลม โดยแสดงดังสมการที่ (3.16) และสมการคำนวณต้นทุนที่ (3.17) ข้อมูลความเร็วลมวัดในระดับ 50 เมตร ใช้ในการจำลองแสดงดังรูปที่ 3.4 และคุณลักษณะของกำลังผลิตของพลังงานกังหันลมแสดงดังรูปที่ 3.5 ได้นำเอาค่าสูงสุดของกำลังผลิตมาคำนวณเพื่อเปลี่ยนเป็นต่อหน่วย และข้อมูลในการจำลองกำลังผลิตกังหันลมแสดงดังตารางที่ 3.4


$$P_{WT} = \frac{1}{2} \cdot \rho \cdot A \cdot C_p \cdot v^3 \quad (3.16)$$

$$C_{Cost,WT} = C_{WT} P_{WT} \quad (3.17)$$


กำหนดให้	P_{WT}	คือ	กำลังผลิตของกังหันลม (kW)
	ρ	คือ	ความหนาแน่นของอากาศมีค่า 1.255 kg/m ³
	C_p	คือ	ค่าสัมประสิทธิ์ของกังหันลมที่สามารถผลิตพลังงานได้ โดยมีค่าสูงสุดอยู่ที่ 59.7% (kg/m ³)
	V	คือ	ความเร็วลม (m/s)
	A	คือ	พื้นที่หน้าตัดของใบพัด (m ²)
	C_{WT}	คือ	ค่าใช้จ่ายของกำลังงานต่อบาทของระบบกักเก็บพลังงานไฟฟ้า (บาท/kW)
	$C_{Cost,WT}$	คือ	การลงทุนในการติดตั้งของพลังงานกังหันลม (บาท)

ตารางที่ 3.4 ข้อมูลทางเทคนิคของกังหันลม (FT ENERGY, 2023)

พารามิเตอร์	รายละเอียด
ขนาดกำลังไฟฟ้า (kW)	100
ความสูง (m)	30
พื้นที่หน้าตัดของใบพัด (m ²)	459.7
ความเร็วลมที่เริ่มทำงาน (m/s)	2.5
อายุการใช้งาน (ปี)	30



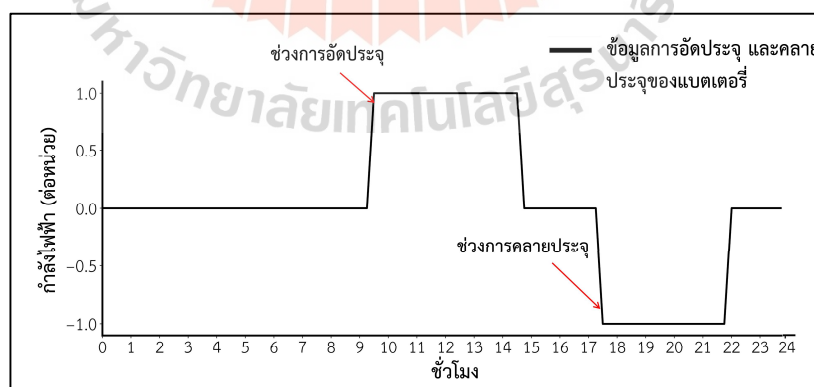
รูปที่ 3.4 ความเร็วลมที่ระดับความสูง 50 เมตร



รูปที่ 3.5 ลักษณะเฉพาะของกำลังผลิตพลังงานกังหันลม

3.4.3 แบบจำลองของระบบกักเก็บพลังงานแบบแบตเตอรี่

การนำระบบกักเก็บพลังงานแบบแบตเตอรี่มาใช้ในระบบไมโครกริด เพื่อแก้ปัญหาการเกิดโหลดที่พุ่งสูงขึ้นในช่วงที่พลังงานหมุนเวียนไม่พอ หรือไม่สามารถผลิตได้ โดยเฉพาะพลังงานเซลล์แสงอาทิตย์ที่หมดไปในช่วงเวลากลางคืน เมื่อวิเคราะห์ภาพรวมในหนึ่งวันลักษณะโหลดที่เกิดขึ้นเป็นลักษณะของ Duck curve ซึ่งการอัดประจุ และคลายประจุได้ออกแบบตามช่วงเวลาที่เกิดโหลดพุ่งสูงขึ้นในช่วงเวลาที่ไม่มีความหมุนเวียน (Pitra and Musti, 2021) โดยลักษณะการอัดประจุ และคลายประจุแบตเตอรี่แสดงดังรูปที่ 3.6 การอัดประจุจะเกิดขึ้น ณ เวลา 09.00 น. ถึง 15.00 น. และเริ่มคลายประจุ ณ เวลา 17.00 น. ถึง 22.00 น. ในเวลาที่มากการใช้พลังงานสูง

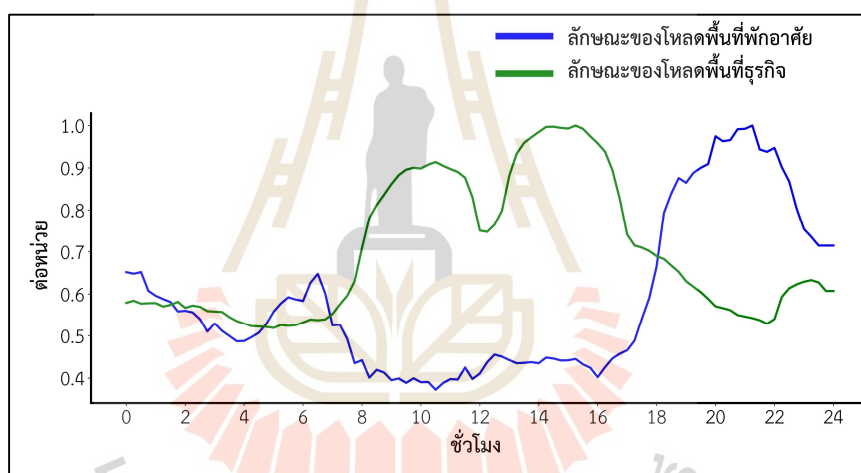


รูปที่ 3.6 ลักษณะการอัดประจุ และคลายประจุแบตเตอรี่

3.4.4 แบบจำลองของโหลดที่อยู่อาศัยและพื้นที่ประกอบธุรกิจในระบบโครงข่าย

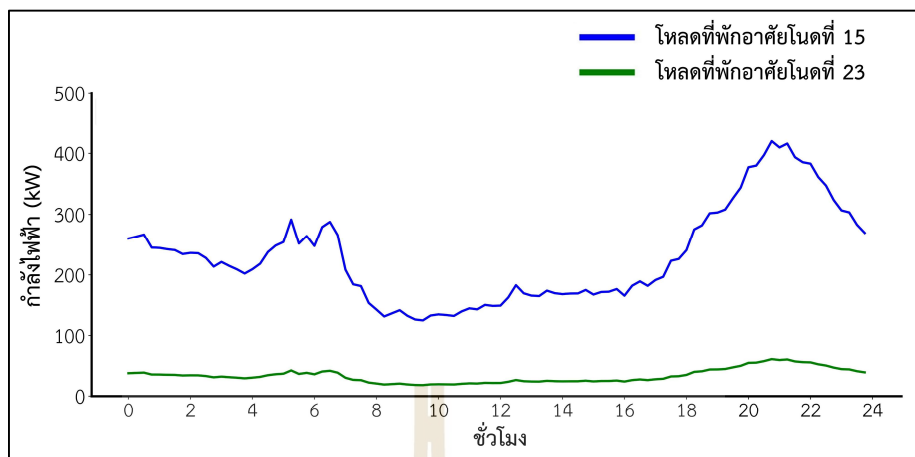
33 โหนด

โหลดที่อยู่อาศัยและโหลดพื้นที่ธุรกิจได้ใช้ข้อมูลคุณลักษณะโหลดจากการไฟฟ้าส่วนภูมิภาคของจังหวัดนครราชสีมา (การไฟฟ้าส่วนภูมิภาค, 2023) โดยเป็นคุณลักษณะต่อหน่วยด้วยการเอาค่าสูงสุดมาคำนวณ ดังรูปที่ 3.7 แสดงให้เห็นถึงพฤติกรรมการใช้ไฟฟ้าของพื้นที่อยู่อาศัย และพื้นที่ประกอบธุรกิจ จะเห็นได้ว่าคุณลักษณะของโหลดที่อยู่อาศัยมีการใช้ไฟฟ้าที่มากในช่วงเย็นถึงกลางดึก นั่นคือ 16.00 น. ถึง 20.00 น. เป็นช่วงที่มีการใช้ไฟฟ้ามาก และลดลงตั้งแต่ช่วง 20.00 น. เป็นต้นไป จนถึง เวลา 08.00 น. และช่วงที่มีการใช้ไฟฟ้าน้อยที่สุดเป็นเวลา 08.00 น. ถึง 16.00 น. ส่วนโหลดพื้นที่ประกอบธุรกิจมีการใช้พลังงานไฟฟ้ามากในช่วงกลางวันตั้งแต่ 08.00 น. ถึง 18.00 น.

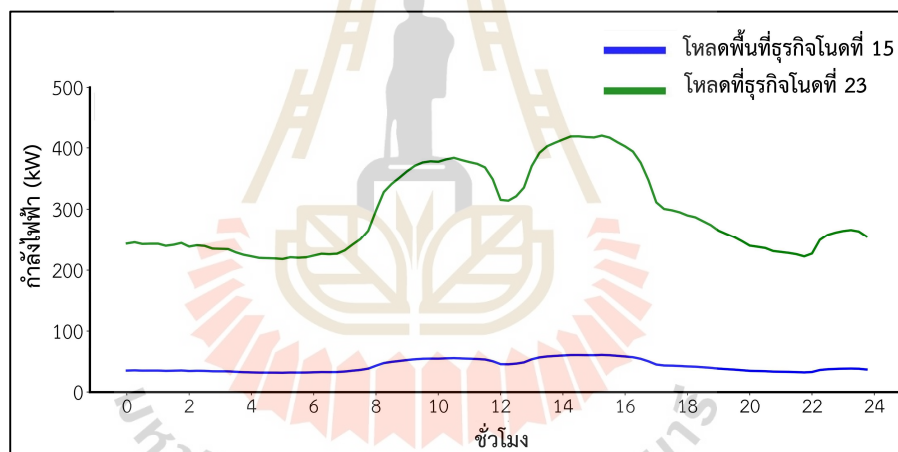


รูปที่ 3.7 ลักษณะของโหลดที่อยู่อาศัยและพื้นที่ประกอบธุรกิจ

โหลดพื้นที่อยู่อาศัยและพื้นที่ธุรกิจภายในระบบทดสอบ 33 โหนด ได้ใช้คุณลักษณะของโหลดที่อยู่อาศัยของจังหวัดนครราชสีมา โดยการปรับคูนจากโหลดที่มีอยู่แต่เดิมภายในระบบ ซึ่งโหลดของระบบทดสอบได้แสดงในภาคผนวกรูปที่ ข.1 โดยคุณลักษณะของโหลดหลังเพิ่มเข้าไปในระบบทดสอบเป็นดังรูปที่ 3.8 และ 3.9 ซึ่งแต่ละโหนดจะมีคุณลักษณะใกล้เคียงกันต่างกันเพียงขนาดสูงสุด โดยรูปที่แสดงคือโหลดที่พักอาศัยและพื้นที่ธุรกิจที่มีโหลดมากที่สุดที่ตำแหน่งโหนดที่ 23 และต่ำที่สุดที่โหนด 15



รูปที่ 3.8 โหลดที่อยู่อาศัยภายในระบบทดสอบ IEEE 33 โหนด

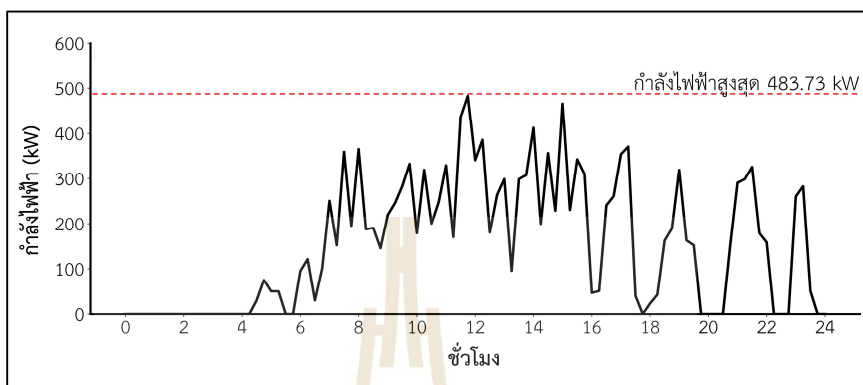


รูปที่ 3.9 โหลดพื้นที่ธุรกิจภายในระบบทดสอบ IEEE 33 โหนด

3.4.5 แบบจำลองสถานีอัดประจุยานยนต์ไฟฟ้า

Gilleran et al. (2021) ได้วิเคราะห์ถึงคุณลักษณะความต้องการพลังงานไฟฟ้าของสถานีอัดประจุแบบเร็วในพื้นที่สาธารณะที่ขนาด 50 150 และ 350 kW โดยมีหัวชาร์จแบบ 2 หัวชาร์จ และ 6 หัวชาร์จต่อเครื่อง เพื่อสังเกตแนวโน้มของกำลังไฟฟ้าที่เกิดขึ้นในช่วงเวลาที่มีการอัดประจุยานยนต์ไฟฟ้า ซึ่งเครื่องอัดประจุแบบเร็วที่การไฟฟ้ารองรับมีขนาด 150 kW (PEA Volta, 2023) เช่นเดียวกับบทความดังกล่าว การจำลองสถานีอัดประจุยานยนต์ไฟฟ้าได้นำกราฟคุณลักษณะมาปรับ

ใช้ในการวิจัยการจัดการพลังงานภายในระบบไมโครกริด โดยมีลักษณะโหลดการอัดประจุยานยนต์ ไฟฟ้าดังรูปที่ 3.10



รูปที่ 3.10 ความต้องการกำลังไฟฟ้าของเครื่องอัดประจุในวัน

ตารางที่ 3.5 ข้อมูลคุณสมบัติของเครื่องชาร์จขนาด 150 kW (PEA Volta, 2023)


พารามิเตอร์	รายละเอียด
ยี่ห้อ	ATESS EVD-150D
ขนาดกำลังไฟฟ้า (kW)	150
ขนาดพิกัดกระแส (A)	200
แรงดันเอาต์พุต (แรงดันไฟฟ้ากระแสตรง: V_{DC})	200 - 850

3.5 กรณีศึกษาของระบบโครงข่ายไฟฟ้า


ในการรวมระบบไมโครกริดเข้ากับระบบพลังงานหมุนเวียนที่ประกอบไปด้วยพลังงานกังหันลม และพลังงานเซลล์แสงอาทิตย์ เพื่อลดภาระจากการรับพลังงานมาจากกริดหลัก (Kumar and Majid., 2020) ซึ่งในบางตำแหน่งของโนดที่ห่างไกล อย่างโนด 18 และ 33 มีแรงดันที่ต่ำกว่ามาตรฐานของระบบ (Elkadeem et al., 2019) โดยพลังงานหมุนเวียนก็เป็นอีกแนวทางในการแก้ปัญหา หรือการบรรเทาแรงดันตกในระบบโครงข่ายไฟฟ้า อย่างที่ทราบกันข้อเสียของพลังงานหมุนเวียนนั้นไม่สามารถให้กำลังผลิตไฟฟ้าได้ตลอดเวลา เช่น พลังงานเซลล์แสงอาทิตย์ที่สามารถผลิต

ได้ในกลางวัน ซึ่งไม่สามารถลดภาระของกริดหลักได้ในตอนกลางคืน และ พลังงานกังหันลมก็มีความผันผวนในส่งจ่ายกำลังผลิต เช่นกัน

ในงานวิจัยของ Deb et al. (2018) ได้วิเคราะห์ผลกระทบของสถานีอัดประจุไฟฟ้าทั้งการชาร์จแบบแบบเร็ว โดยใช้ระบบทดสอบ IEEE 33 โหนด ที่เป็นระบบส่งจ่ายไฟฟ้า ซึ่งมีทั้งหมดหกกรณีศึกษาแต่ละกรณีใช้พิกัดสถานีอัดประจุแบบเร็วตัวละ 50 kW โดยวิเคราะห์ผลที่ได้จากการติดตั้งสถานีชาร์จไว้ที่ตำแหน่งที่แรงดันไฟฟ้าที่ดีที่สุดที่ตำแหน่งโหนด 2 และ 19 และวิเคราะห์ผลการติดตั้งที่ตำแหน่งที่แรงดันต่ำนั้นคือตำแหน่งที่โหนด 14 และ 15 ซึ่งผลการวิเคราะห์ที่ได้นั้นคือการติดตั้งโหลดที่โหนดที่มีแรงดันที่ดีและใกล้จุดเชื่อมต่อของกริด จะไม่เกิดแรงดันตกมาก หากต้องการเห็นแรงดันที่ลดลงต้องใช้โหลดถึง 7.5 MW จุดที่บัพพร้อมและแตกต่างกันจริง ๆ นั้นคือตำแหน่งที่โหนด 14 และ 15 เมื่อติดตั้งสถานีชาร์จเข้าระบบกริด ส่งผลให้แรงดันตั้งแต่โหนด 14 จนถึงโหนด 18 มีแรงดันที่ต่ำกว่าเกณฑ์มาตรฐาน แนวทางการแก้ไขดังกล่าวนั้นคือการเพิ่มพลังงานหมุนเวียนในระบบกริด แต่นั่นก็ไม่สามารถครอบคลุมได้ทุกกรณีหากเกิดการใช้โหลดเกินพิกัดพลังงานหมุนเวียน หรือสภาพอากาศที่ไม่แน่นอนจึงทำให้กำลังผลิตไม่พอ ดังนั้นระบบระบบกักเก็บพลังงาน หรือ ระบบกักเก็บพลังงาน มาช่วยจ่ายพลังงานในโครงข่าย เมื่อระบบพลังงานหมุนเวียนไม่เพียงพอต่อความต้องการไฟฟ้าในระบบโครงข่าย โดยการหาตำแหน่งที่ติดตั้งและขนาดของระบบกักเก็บพลังงานที่เหมาะสมที่สุด พิจารณาภายใต้ตำแหน่งและขนาดที่ให้กำลังงานสูญเสียในระบบรวมน้อยที่สุด (Power loss) รวมถึงค่าไฟที่ต่ำสุด (Cost of electricity: COE) โดยแรงดันไฟฟ้าก่อนปรับปรุงแสดงดังรูปที่ 3.11 และกำลังสูญเสียดังรูปที่ 3.12



รูปที่ 3.11 กำลังไฟฟ้าเดิมของระบบทดสอบ IEEE 33 โหนด



รูปที่ 3.12 แรงดันไฟฟ้าเดิมของระบบทดสอบ IEEE 33 โหนด


จากรูปที่ 3.11 และ 3.12 ระบบทดสอบโครงข่าย IEEE 33 โหนด มีแรงดันไฟฟ้าอยู่ระหว่าง 0.91 ถึง 1.00 โดยจุดที่แรงดันต่ำที่สุดอยู่ที่โหนด 18 และ 33 มีกำลังไฟฟ้าสูญเสียเดิมทั้งระบบโครงข่ายรวมอยู่ที่ 202.68 kW

ข้อมูลการจำลองพลังงานหมุนเวียนได้พิจารณาตำแหน่งที่ละติจูด 14.86 ลองจิจูด 101.56 เป็นตำแหน่งที่ตั้งของ ศูนย์อนุรักษ์พันธุกรรมพืชอันเนื่องมาจากพระราชดำริสมเด็จพระเทพรัตนราชสุดาฯ สยามบรมราชกุมารี มหาวิทยาลัยเทคโนโลยีสุรนารี ต.คลองไผ่ อ.สีคิ้ว จ.นครราชสีมา

โดยข้อมูลนำมาจากเว็บไซต์องค์กร NASA (The National Aeronautics and Space Administration, 2023) โหลดพื้นที่อยู่อาศัยและพื้นที่ธุรกิจได้ใช้ข้อมูลจากการไฟฟ้าส่วนภูมิภาคของจังหวัดนครราชสีมา (การไฟฟ้าส่วนภูมิภาค, 2023) โดยขนาดสูงสุดอยู่ที่ 300 kW และโหลดสถานีอัดประจุไฟฟ้ายานยนต์แบบเร็วที่ขนาด 150 kW จำนวนหกหัวชาร์จ (Gilleran et al., 2021) เพื่อการจัดการพลังงานที่เหมาะสมโดยการหาขนาด และตำแหน่งที่ตั้งที่เหมาะสม ซึ่งคำนึงถึงกำลังไฟฟ้าสูญเสียและความคุ้มค่าในการลงทุน โดยมีกำหนดโหลดที่พักอาศัย และพื้นที่ธุรกิจได้แบ่งกรณีศึกษา ดังตารางที่ 3.6


ตารางที่ 3.6 การกำหนดพื้นที่โหลดที่พักอาศัย และพื้นที่ธุรกิจสำหรับกรณีศึกษา

กรณีศึกษา	โหลดพื้นที่พักอาศัย	โหลดพื้นที่ธุรกิจ
1	พื้นที่ 1, 2, 3 และ 4	-
2	-	พื้นที่ 1, 2, 3 และ 4
3	พื้นที่ 1, 2 และ 3	พื้นที่ 4
4	พื้นที่ 1 และ 3	พื้นที่ 2 และ 4



รูปที่ 3.13 การแบ่งกรณีศึกษาด้วยโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจ

การแบ่งพื้นที่กรณีศึกษาตามตารางที่ 3.6 ได้แสดงดังรูปที่ 3.13 ซึ่งลักษณะโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจมีคุณลักษณะดังรูปที่ 3.8 และ 3.9 โดยกรณีศึกษาที่ 1 ได้ใช้คุณลักษณะโหลดพื้นที่พักอาศัยทั้งหมดนับตั้งแต่โนด 1 ถึงโนดที่ 33 ในกรณีศึกษาที่ 2 ได้ใช้คุณลักษณะโหลดพื้นที่ธุรกิจทั้งหมดตั้งแต่โนด 1 ถึงโนด 33 ในกรณีศึกษาที่ 3 ได้ใช้คุณลักษณะของโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจ ผสมกัน โดยกำหนดให้สัดส่วนโหลดพื้นที่พักอาศัยอยู่พื้นที่ที่ 1, 2 และ 3 โหลดพื้นที่ธุรกิจอยู่พื้นที่ที่ 4 กรณีศึกษาที่ 4 ได้ผสมผสานคุณลักษณะโหลดร่วมกัน โดยกำหนดให้โหลดพื้นที่พักอาศัยอยู่พื้นที่ที่ 1 และ 3 โหลดพื้นที่ธุรกิจอยู่พื้นที่ที่ 2 และ 4 ในการดำเนินการจัดการพลังงานที่เหมาะสมเพื่อหาขนาด และตำแหน่งของพลังงานแสงอาทิตย์ พลังงานกักเก็บ และระบบกักเก็บพลังงานด้วยแบตเตอรี่ มีขั้นตอนดำเนินงานวิจัยดังรูปที่ 3.14



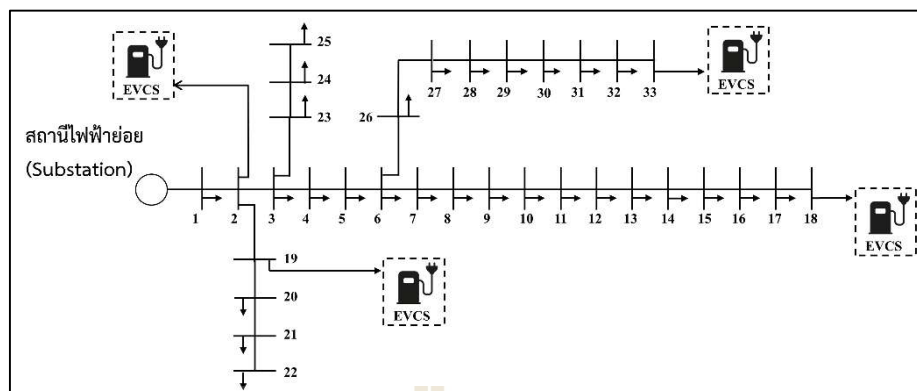
รูปที่ 3.14 ขั้นตอนการดำเนินการวิจัย

ขั้นตอนที่ 1 : ศึกษาการไหลของพลังงานไฟฟ้า เพื่อตรวจสอบกำลังไฟฟ้าสูญเสีย และแรงดันไฟฟ้าในแต่ละกรณีศึกษาภายในระบบไมโครกริด

ขั้นตอนที่ 2 : จำลองผลหาขนาด และตำแหน่งที่เหมาะสมของพลังงานแสงอาทิตย์ และพลังงานกักเก็บในในแต่ละกรณีศึกษาภายในไมโครกริด

ขั้นตอนที่ 3 : ศึกษาการไหลของพลังงานไฟฟ้า เพื่อตรวจสอบกำลังไฟฟ้าสูญเสีย และแรงดันไฟฟ้าในแต่ละกรณีศึกษาภายในระบบไมโครกริด และดำเนินการติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าในตำแหน่งที่โนด 2, 18, 19, 33 ดังรูปที่ 3.15 และดำเนินการวิเคราะห์ผลกระทบของโหลดสถานีอัดประจุยานยนต์ไฟฟ้า

ขั้นตอนที่ 4 : จำลองหาขนาด และตำแหน่งติดตั้งที่เหมาะสมของพลังงานแสงอาทิตย์ พลังงานกักเก็บ และระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยดำเนินการติดตั้งโหลดสถานีอัดประจุยานยนต์ไฟฟ้าที่ตำแหน่ง 2, 18, 19 และ 33



รูปที่ 3.15 ตำแหน่งสถานีอัดประจุยานยนต์ไฟฟ้าภายในไมโครกริด 33 โหนด

3.6 พารามิเตอร์และการฝึกสอนแบบจำลอง

ในการฝึกสอนแบบจำลองจากอัลกอริทึมเทคนิคการเรียนรู้เชิงลึกหลายเอเจนต์ สิ่งที่สำคัญในการดำเนินงานนั้นคือการปรับพารามิเตอร์ให้เหมาะสมแก่งานวิจัย เพื่อให้โมเดลมีประสิทธิภาพและแก้ปัญหาที่มีความซับซ้อนได้ดีที่สุด ในวิทยานิพนธ์นี้ได้ตั้งค่าพารามิเตอร์โดยมีพื้นฐานมาจากการวิจัยของ Alabdullah and Abido (2022) ได้ศึกษาผลกระทบจากการปรับจำนวน Hidden layers และ Gamma* ในการฝึกอบรมแบบจำลองของอัลกอริทึมชนิด Q-Learning โดยจำนวนที่เหมาะสมอยู่ที่ 2 เลเยอร์ ขนาดของโครงข่ายอยู่ในช่วง 256 -512 อัลกอริทึมของ A2C และ A3C ปรับค่า Lambda และ Gamma อยู่ที่ 0.1 และ 0.99 ซึ่งเป็นค่าที่เหมาะสมต่อการฝึกอบรมเพื่อให้ได้ค่ารางวัลที่สูง (Guo et al., 2022) และอัลกอริทึม DDPG, TD3 และ SAC ที่ปรับพารามิเตอร์คล้ายอัลกอริทึมของ A2C และ A3C เนื่องจากอัลกอริทึม DDPG, TD3 และ SAC ได้พัฒนามาจาก Policy Optimization เช่นกัน สิ่งที่เพิ่มเข้ามาคือ Clipping Range และเปลี่ยนจากฟังก์ชัน TD Error Coefficient เป็น Entropy Coefficient (Alonso et al., 2023)

โดยพารามิเตอร์ที่ใช้ในการหาค่าตอบในฟังก์ชันคณิตศาสตร์ และการฝึกอบรมเพื่อหาค่าที่เหมาะสมในโครงข่ายไฟฟ้าได้ตั้งค่ารอบการฝึกอบรมที่ต่างกัน เนื่องจากทรัพยากรคอมพิวเตอร์ที่มีอยู่มีขีดจำกัดของความเร็วในการประมวลผล จึงตั้งพารามิเตอร์รอบการอบรมของฟังก์ชันทดสอบ และการฝึกอบรมร่วมโครงข่ายไฟฟ้าแสดงดังตารางที่ 3.7


จำนวนเอเจนต์ที่ใช้ในการทดสอบในฟังก์ชันทดสอบ การหาขนาด และตำแหน่งใช้จำนวนสองตัวเท่ากัน โดยค่ารางวัลเอเจนต์จะแสดงผลรวมของเอเจนต์ทั้งหมด เพื่อดูประสิทธิภาพ

โดยรวมของอัลกอริทึม และการประยุกต์ใช้ในไมโครกริดกำหนดให้เอเจนต์หนึ่งตัวหาตำแหน่ง ขนาดของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

ตารางที่ 3.7 พารามิเตอร์ที่ใช้ในการจำลอง

อัลกอริทึม	พารามิเตอร์	รายละเอียด
A2C และ A3C	Lambda	0.1
	TD Error Coefficient	0.01
	Gamma (Discount Factor)	1.00
DDPG, TD3 และ SAC	Clipping Range	0.2
	Lambda	0.1
	Entropy Coefficient	0.01
	Gamma (Discount Factor)	1.00
พารามิเตอร์ใช้ร่วมกัน	Number of Hidden Layers	2
	Number of Agent	2
	Size of Hidden Layers	(256, 256)
	Activation Function	Relu
	Learning Rate	0.0001
	Batch Size	256
	Iteration (Test Function)	5,000
	Iteration (Power System)	150

ในสิ่งแวดล้อมที่ใช้สำหรับการเรียนรู้ของการเรียนรู้แบบเสริมกำลังหลายเอเจนต์มีใจความสำคัญอย่าง สภาพสิ่งแวดล้อม (Environment), ฟังก์ชันการกระทำ (Action Function), สถานะ (State) และฟังก์ชันรางวัล โดยสภาพสิ่งแวดล้อมเป็นระบบไมโครกริดตามกรณีศึกษาทั้งสี่แบบดังรูปที่ 3.13 ส่วนฟังก์ชันการกระทำมีสองอย่างคือ การหาขนาด ตำแหน่งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ ซึ่งในการเรียนรู้หาค่าที่เหมาะสมของเอเจนต์เพื่อบรรลุเป้าหมาย ได้กำหนดค่าสถานะ และค่าฟังก์ชันรางวัล คือ แรงดันเฉลี่ยในระบบดีซัน กำลังสูญเสียในระบบลดลง และค่าใช้จ่ายการลงทุนของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานน้อยที่สุด โดยพารามิเตอร์ภายในสภาพแวดล้อมที่เอเจนต์เรียนรู้แสดงดังรูปที่ 3.16



รูปที่ 3.16 พารามิเตอร์ภายในสภาพแวดล้อมที่เอเจนต์เรียนรู้

ในวิทยานิพนธ์นี้ ผลลัพธ์ของการดำเนินการถูกกำหนดให้เป็นผลลัพธ์จากการไหลของพลังงานไฟฟ้าในไมโครกริด โดยมีวัตถุประสงค์เพื่อปรับปรุงแรงดันไฟฟ้า ลดกำลังไฟฟ้าสูญเสีย และใช้ต้นทุนน้อยที่สุดในระบบไมโครกริด ตัวแปรที่สำคัญในการเรียนรู้เสริมกำลังเชิงลึกหลายเอเจนต์อย่างตัวแปร สถานะของสภาพแวดล้อม (State) การกระทำของเอเจนต์ (Action) และฟังก์ชันรางวัล (Reward Function) ที่ใช้ในการค้นหาค่าที่เหมาะสมที่สุดในอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC แสดงไว้ดังต่อไปนี้

1) สถานะของสภาพสิ่งแวดล้อม ในสถานะนี้จะพิจารณาแรงดันไฟฟ้า การสูญเสียกำลังไฟฟ้า พลังงานทั้งหมดของระบบ และต้นทุนของระบบ โดยที่ t คือช่วงเวลาหนึ่ง, $V_{i,t}$ แรงดันไฟฟ้า ณ ตำแหน่งที่พิจารณา, $P_{total,t}^{loss}$ คือผลรวมของการสูญเสียพลังงานของระบบ และ S_t คือสถานะของสภาพแวดล้อม ซึ่งแสดงดังแสดงในสมการที่ (3.18)

$$S_t : \{ V_{i,t}, P_{total,t}^{loss}, C_{Cost,WT}, C_{Cost,PV}, C_{Cost,BESS} \} \quad (3.18)$$

2) การกระทำของเอเจนต์ในวิทยานิพนธ์นี้คือการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงาน โดยกำหนดให้ P_t^{Sizing} คือขนาดของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานด้วยแบตเตอรี่ $P_t^{Location}$ คือ ตำแหน่งที่เหมาะสม ณ ตำแหน่งการติดตั้ง ดังสมการที่ (3.19)

$$A_t : \{P_t^{WT,Location}, P_t^{WT,Sizing}, P_t^{PV,Location}, P_t^{PV,Sizing}, P_t^{BESS,Location}, P_t^{BESS,Sizing}\} \quad (3.19)$$

3) ฟังก์ชันรางวัล เป็นฟังก์ชันที่ไว้สำหรับระบุความถูกต้อง และบอกความแม่นยำให้แก่เอเจนต์ โดยรางวัลที่ได้มาจากการปรับปรุงแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียที่ลดลง และต้นทุนที่น้อยที่สุด ซึ่งในสมการจะมีการปรับค่าแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียให้อยู่ในหน่วยเดียวกันเพื่อความเหมาะสมในการคำนวณค่ารางวัล และผลกระทบของราคาที่มีผลต่อฟังก์ชันรางวัลได้อ้างอิงจากตารางที่ 3.2 ดังสมการที่ (3.20)

$$R_t = - \left\{ \begin{aligned} &10(1.00 - V_{avg}) + 10(V_{min} - V_{i,t}) + 10(P_{total,t}^{loss} - P_{normally}^{loss}) \\ &+ (1.85C_{Cost,WT} + 1.2C_{Cost,PV} + 0.15C_{Cost,BESS}) \end{aligned} \right\} \quad (3.20)$$

กำหนดให้ $(1.00 - V_{avg})$ คือ ค่ารางวัลเมื่อแรงดันมีค่าเฉลี่ยเข้าใกล้ 1.00 ต่อหน่วย

$(V_{min} - V_{i,t})$ คือ ค่ารางวัลเมื่อแรงดันมีค่ามากกว่าค่าต่ำสุดของระบบเดิม

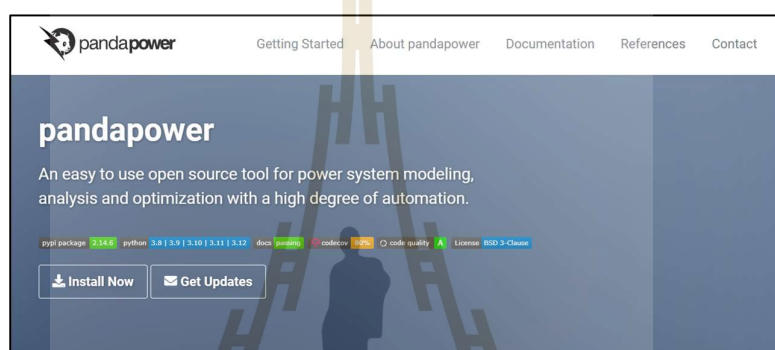
$(P_{total,t}^{loss} - P_{normally}^{loss})$ คือ ค่ารางวัลเมื่อกำลังไฟฟ้าสูญเสียมีน้อยลง

3.7 เครื่องมือที่ใช้ในการวิจัย

การดำเนินวิจัยอยู่บนพื้นฐานภาษา Python เป็นภาษาที่ใช้กันอย่างแพร่หลายในการวิจัย เนื่องจากมีไลบรารี Open source จำนวนมากให้เลือกใช้ในการวิจัย พื้นฐานระบบไฟฟ้าแบบกระจายก็เช่นกันได้เลือกใช้ Pandapower เป็นไลบรารีในการวิเคราะห์การไหลของกำลังไฟฟ้า และการเรียนรู้แบบเสริมกำลังแบบเชิงลึกหลายเอเจนต์ได้ใช้ไลบรารี Gymnasium และ Rllib ร่วมกัน โดยคอมพิวเตอร์ที่ใช้ในการจำลองครั้งนี้คือ Intel(R) Core(TM) i7-8750H @ 2.20 GHz processor ใช้แรมทั้งหมด 32 Gigabyte สำหรับการจำลองครั้งนี้

3.7.1 ไลบรารี Pandapower

Pandapower เป็นไลบรารี Python แบบ Open source สำหรับการจำลองระบบโครงข่ายไฟฟ้า หน้าเว็บไซต์แสดงดังรูปที่ 3.17 โดยเน้นไปที่เครือข่ายการจำหน่ายไฟฟ้า (Distribution system) การออกแบบมาเพื่อจำลองการปรับเปลี่ยนกลยุทธ์กับสถานการณ์ต่างๆ รวมถึงการวิเคราะห์ระบบกำลัง การคำนวณการไหลของโหลด การวิเคราะห์การลัดวงจร และการไหลของกำลังที่เหมาะสมที่สุด

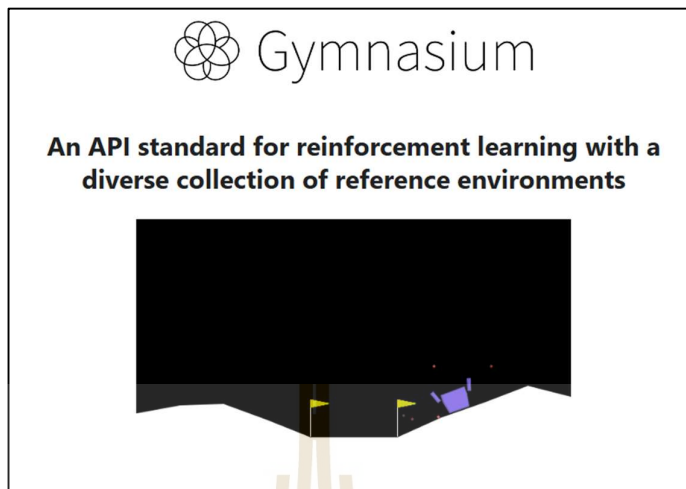


รูปที่ 3.17 หน้าเว็บไซต์ของไลบรารี Pandapower

แหล่งที่มา : <https://www.pandapower.org/> (เข้าถึงเมื่อ 6/05/2567)

3.7.2 ไลบรารี Gymnasium

Gymnasium เป็นไลบรารี Open source สำหรับการพัฒนาและเปรียบเทียบอัลกอริทึมการเรียนรู้แบบเสริมกำลัง ได้รับการพัฒนาโดยบริษัท OpenAI และมีสภาพแวดล้อม หรือสถานการณ์ที่หลากหลายสำหรับการฝึกอบรมและการทดสอบอัลกอริทึมการเรียนรู้แบบเสริมกำลัง หน้าเว็บไซต์แสดงดังรูปที่ 3.18 โดย Gymnasium ได้รับการออกแบบมาให้ใช้งานง่ายและเข้ากันได้กับอัลกอริทึมการเรียนรู้แบบเสริมกำลังและเฟรมเวิร์ค (Framework) ต่างๆ เช่น TensorFlow และ PyTorch ซึ่งเป็นไลบรารีที่สำคัญสำหรับนักวิจัยที่ต้องการใช้เทคนิคการเรียนรู้แบบเสริมกำลัง



รูปที่ 3.18 หน้าเว็บไซต์ของไลบรารี Gymnasium
แหล่งที่มา : <https://gymnasium.farama.org/> (เข้าถึงเมื่อ 6/05/2567)

3.7.3 ไลบรารี Rllib

Rllib เป็นไลบรารี Open source สำหรับการเรียนรู้แบบเสริมกำลังที่รองรับการใช้งานการเรียนรู้เสริมกำลังเชิงลึกหลายเอเจนต์ ได้แก่อัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC รวมถึงรองรับการนำไลบรารีอื่น ๆ เข้ามาประยุกต์ใช้ร่วมกันอย่าง Gymnasium เพื่อการสร้าง Environment ที่สะดวกยิ่งขึ้น อีกทั้งยังมีตัวอย่างการประยุกต์ใช้ Rllib ให้สามารถศึกษา และทำความเข้าใจเกี่ยวกับกระบวนการเบื้องต้นได้ โดยหน้าเว็บไซต์แสดงดังรูปที่ 3.19 ซึ่งจะนำมาประยุกต์ใช้ในงานวิจัยต่อไป



รูปที่ 3.19 หน้าเว็บไซต์ของไลบรารี Rllib
แหล่งที่มา : <https://docs.ray.io/en/latest/rllib/index.html> (เข้าถึงเมื่อ 6/05/2567)

3.8 สรุป

ในบทนี้ได้กล่าวถึงทฤษฎี และกรณีที่ใช้ในการวิจัย ซึ่งประกอบไปด้วย ฟังก์ชันทดสอบสำหรับ อัลกอริทึมการเรียนรู้เชิงลึกหลายเอเจนต์ เพื่อทดสอบ และปรับปรุงหาพารามิเตอร์ที่เหมาะสมก่อน นำมาประยุกต์ใช้ในงานวิจัย การคำนวณหาขนาด และตำแหน่งที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ เพื่อลดกำลังไฟฟ้าสูญเสีย และปรับปรุงแรงดันไฟฟ้าในระบบ ด้วยอัลกอริทึมการเรียนรู้แบบเสริมกำลังเชิงลึกแบบหลายตัว ข้อมูลที่นำมาปรับใช้ในการวิจัย ในแต่ละกรณีศึกษา ซึ่งแบ่งกรณีศึกษาจากคุณลักษณะโหนดที่แตกต่างกัน แบ่งเป็นทั้งหมด 4 กรณีศึกษา โดยใช้วิธีการดำเนินเหมือนกันทั้งหมดในทุกกรณีศึกษา และเครื่องมือวิจัยที่ใช้การจำลอง ทั้งหมดของระบบไมโครกริดอยู่บนพื้นฐานภาษา Python ไลบรารี Pandapower เช่นเดียวกับการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์อยู่บนพื้นฐานไลบรารี Gymnasium และ Rllib โดยผลการ จำลอง และการวิเคราะห์ผลแสดงไว้ในบทที่ 4 ต่อไป



บทที่ 4

ผลการวิจัยและอภิปรายผล

4.1 กล่าวนำ


การวิจัยเรื่องการจัดการพลังงานที่เหมาะสมในไมโครกริด โดยประยุกต์ใช้เทคนิคการเรียนรู้เสริมกำลังแบบหลายเอเจนต์ ได้ศึกษาออกแบบพารามิเตอร์ของเทคนิคการเรียนรู้แบบเสริมกำลังแบบหลายตัวสำหรับการทดสอบในสมการคณิตศาสตร์ และจำลองในไมโครกริดด้วยระบบทดสอบโครงข่าย 33 โนด ดังนั้น การวิเคราะห์หาพารามิเตอร์ที่เหมาะสมจึงเป็นเรื่องที่สำคัญ เพื่อนำไปประยุกต์ใช้การเรียนรู้เสริมกำลังเชิงลึกหลายเอเจนต์ในไมโครกริดที่มีกรณีศึกษาต่าง ๆ ดังนั้น ในบทนี้จึงแสดงผลการวิจัยที่ได้จากวิธีการดำเนินการในบทที่ 3 ดังต่อไปนี้

4.2 ผลการปรับค่าพารามิเตอร์แบบจำลอง


ในหัวข้อนี้แสดงผลการดำเนินการจำลองการปรับแต่งพารามิเตอร์ที่ส่งผลต่อประสิทธิภาพของการฝึกอบรม ซึ่งการทำงานรวมกับการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ สิ่งที่บ่งบอกประสิทธิภาพของโมเดลได้นั้นคือผลของรางวัลที่เอเจนต์ได้รับในขณะที่ฝึกอบรม ดังนั้น การหาพารามิเตอร์ที่เหมาะสมจึงมีความสำคัญ โดยการแสดงผลการปรับแต่งของอัลกอริทึมทั้งห้าได้แก่ MAA2C, MAA3C, MADDPG, MATD3 และ MASAC เพื่อนำค่าพารามิเตอร์ที่เหมาะสมประยุกต์ใช้ในขั้นตอนการตรวจสอบสมรรถนะด้วยฟังก์ชันมาตรฐานหัวข้อที่ 4.3 และการประยุกต์ใช้ในไมโครกริดในหัวข้อที่ 4.5 และ 4.7 ผลลัพธ์ที่ได้แสดงเป็นผลลัพธ์ที่ได้จากผลรวมของค่ารางวัลเอเจนต์ โดยการปรับแต่งพารามิเตอร์นั้นได้ใช้สมการที่ F1 จากตารางที่ 3.6 เป็นฟังก์ชันพื้นฐานสำหรับทดสอบอัลกอริทึมดังกล่าว

4.2.1 การปรับแต่งพารามิเตอร์อัลกอริทึม MAA2C และ MAA3C

การปรับแต่งพารามิเตอร์ที่เหมาะสมของอัลกอริทึม MAA2C และ MAA3C โดยการปรับแต่งพารามิเตอร์ได้ตั้งค่ารอบการฝึกอบรมที่ 5,000 รอบเพื่อสังเกตแนวโน้มของประสิทธิภาพที่ชัดเจนด้วยการตั้งค่าจำนวน Hidden layers, Learning rate และ Batch size ดังตารางที่ 3.6 โดยพบว่าพารามิเตอร์ Lambda ได้ส่งผลกระทบต่อผลการฝึกอบรม โดยการทดสอบได้ปรับค่า Lambda ตั้งแต่ 0.01 ถึง 1 มีส่วนสำคัญในการวิเคราะห์ฟังก์ชันการกระทำ เพื่อหาฟังก์ชันการกระทำที่ให้รางวัลแก่เอเจนต์ได้ดี ซึ่งผลการปรับแต่งของอัลกอริทึม MAA2C และ MAA3C ได้ค่าที่เหมาะสมต่อกรณีศึกษานี้คือค่า 0.01 โดยอัลกอริทึม MAA3C จะแสดงผลของค่ารางวัลน้อยกว่า MAA2C เมื่อเปรียบเทียบกับรูปที่ 4.1 และ 4.2 เมื่อเปรียบเทียบกับค่า Lambda ที่ 1.00 และ 0.50 ในเงื่อนไขรอบการฝึกอบรมที่ 5,000 รอบ การปรับค่า Lambda ที่ 0.01 ส่งผลให้เอเจนต์ได้รับค่ารางวัลที่สูง และมีประสิทธิภาพที่ดี



รูปที่ 4.1 ผลการปรับค่า Lambda อัลกอริทึม MAA2C




รูปที่ 4.2 ผลการปรับค่า Lambda อัลกอริทึม MAA3C

4.2.2 การปรับแต่งพารามิเตอร์อัลกอริทึม MADDPG, MATD3 และ MASAC


การปรับแต่งพารามิเตอร์ที่เหมาะสมของอัลกอริทึม MADDPG, MATD3 และ MASAC โดยการปรับแต่งพารามิเตอร์ได้ใช้พื้นฐานแบบเดียวกับอัลกอริทึม MAA2C และ MAA3C เพื่อการเปรียบเทียบที่เหมาะสม โดยพบว่าพารามิเตอร์ Gamma โดยการทดสอบได้ปรับค่าตั้งแต่ 0.01 ถึง 1 เช่นกัน ซึ่งในการวิเคราะห์ฟังก์ชันการกระทำ เพื่อหาฟังก์ชันการกระทำที่ให้รางวัลแก่เอเจนต์ได้ดีที่สุด โดยค่า Gamma ที่ปรับจะกำหนดความน่าเชื่อถือของฟังก์ชันการกระทำในทุก ๆ รอบการฝึกอบรมแบบจำลอง

ผลลัพธ์จากการปรับแต่งของอัลกอริทึมได้ค่าที่เหมาะสมต่อกรณีศึกษาครั้งนี้คือค่า 1.00 โดยรูปที่ 4.3, 4.4 และ 4.5 แสดงให้เห็นถึงรางวัลที่เอเจนต์ได้รับมีค่ามากที่สุด เมื่อเทียบกับค่า Gamma ที่ 0.01 และ 0.50 จะมีการลู่เข้าของค่ารางวัลช้ากว่า และจะไต่ระดับใกล้เคียงกันในรอบที่ 4500 – 5000 รอบ จากเงื่อนไขรอบการฝึกอบรมที่ 5000 รอบ การปรับค่า Gamma ที่ 1.00 ส่งผลให้เอเจนต์ได้รับค่ารางวัลที่ลู่เข้าได้เร็ว และมีแนวโน้มที่คงที่เร็วที่สุด โดยอัลกอริทึม MADDPG มีค่ารางวัลมากที่สุดที่ค่า 200 แม้ว่าค่ารางวัลที่สูงของอัลกอริทึม MASAC ที่มีค่ารางวัลสูงสุดที่ 150.25 ที่ค่า 0.01 ของตัวแปร Gamma แต่ในรอบการฝึกอบรมตั้งแต่ 2000 จนถึงรอบที่ 5000 ค่ารางวัลที่แสดงออกมามีความผันผวนสูง และคาดการณ์แนวโน้มของค่ารางวัลได้ยาก 4.5 ค่า 1.00 ของ


Gamma จึงเป็นค่าที่มีความเหมาะสมในการประยุกต์ใช้ในการจำลองครั้งถัดไป เนื่องจากมีแนวโน้มของค่ารางวัลที่คงที่ดังรูปที่ 4.5



รูปที่ 4.3 ผลการปรับค่า Gamma อัลกอริทึม MADDPG



รูปที่ 4.4 ผลการปรับค่า Gamma อัลกอริทึม MATD3



รูปที่ 4.5 ผลการปรับค่า Gamma อัลกอริทึม MASAC

4.3 ผลการตรวจสอบสมรรถนะของ MADRL ด้วยฟังก์ชันมาตรฐาน

การทดสอบอัลกอริทึมก่อนประยุกต์ใช้ในงานวิจัยเป็นสิ่งสำคัญอย่างยิ่งในการบวนาการจำลอง เพื่อพิสูจน์ความสามารถในการหาค่าตอบของอัลกอริทึมนั้น ๆ ก่อนที่จะนำไปประยุกต์ใช้เพื่อหาขนาด และตำแหน่งที่เหมาะสมของ พลังงานหมุนเวียน และระบบกักเก็บพลังงานด้วยแบตเตอรี่ วิทยานิพนธ์นี้จึงได้ประยุกต์ใช้อัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ในสมการทดสอบต่าง ๆ นั้นคือ ฟังก์ชันฐานนิยมเดียว (Unimodal Function) และ ฟังก์ชันฐานนิยมหลายตัว (Multimodal Function) โดยใช้พารามิเตอร์การฝึกอบรมที่เท่ากันอยู่ที่ 5,000 รอบ ดังตารางที่ 3.6 เพื่อศึกษาดูแนวโน้ม และประสิทธิภาพ จุดเด่น และจุดด้อยของแต่ละอัลกอริทึม

4.3.1 ฟังก์ชันฐานนิยมแบบเดียว

การทดสอบอัลกอริทึมได้ใช้สมการในตารางที่ 4.1 ได้แก่ F1 และ F2 โดยมีจุดประสงค์ในการหาค่าตอบลู่เข้าศูนย์ให้มากที่สุด


ตารางที่ 4.1 ฟังก์ชันทดสอบฐานนิยมแบบเดียว

ลำดับ	ฟังก์ชัน	ช่วง	f_{min}
F1	$F(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
F2	$F(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-100, 100]$	0

ผลการทดสอบฟังก์ชัน F1 และ F2 ของอัลกอริทึมทั้งห้าได้แสดงดังตารางที่ 4.2 และแนวโน้มค่ารางวัลของแต่ละอัลกอริทึมแสดงดังรูปที่ 4.6 และ 4.7 ในการทดสอบฟังก์ชันแรกเพื่อหาคำตอบของฟังก์ชันเข้าใกล้ศูนย์ พบว่าการลู่เข้าของคำตอบระหว่างอัลกอริทึม MAA3C และ MATD3 มีแนวโน้มค่ารางวัลที่ไม่สูง และจะคงที่ไปเรื่อย ๆ จนไปถึงรอบที่ 5,000 ดังรูปที่ 4.3 ส่วนอัลกอริทึมของ MAA2C มีแนวโน้มของฟังก์ชันรางวัลที่เพิ่มขึ้นแบบคงที่ และยังมีแนวโน้มที่สามารถมากขึ้นได้ ซึ่งต้องการจำนวนรอบในการฝึกอบรมที่มากขึ้น ส่วนอัลกอริทึม MADDPG และ MASAC ได้แสดงแนวโน้มของค่ารางวัลที่อย่างก้าวกระโดดจากการได้รับค่ารางวัลจากการแก้สมการทดสอบ โดยอัลกอริทึม MADDPG มีค่ารางวัลที่ลู่เข้าเร็วที่สุด และมากที่สุด


ตารางที่ 4.2 ผลการทดสอบฟังก์ชัน F1 และ F2

อัลกอริทึม	ผลลัพธ์ฟังก์ชัน F1	ผลลัพธ์ฟังก์ชัน F2
MAA2C	1,022.76	40,575.08
MAA3C	17,660.33	34,233.57
MADDPG	15.91	122.01
MATD3	6,920.81	4,783.71
MASAC	282.95	592.05



รูปที่ 4.6 ผลการทดสอบฟังก์ชันฐานนิยมเดียวสมการที่ 1

ผลการทดสอบฟังก์ชัน F2 ของอัลกอริทึมทั้งห้าได้แสดงดังตารางที่ 4.2 และแนวโน้มค่ารางวัลของแต่ละอัลกอริทึมแสดงดังรูปที่ 4.4 โดยอัลกอริทึม MAA2C มีอัตราการได้รับรางวัลที่ลดลงเมื่อเทียบกับสมการ F1 ส่วนอัลกอริทึม MAA3C และ MATD3 มีแนวโน้มในการแก้สมการหาคำตอบเพื่อให้ได้รางวัล มีประสิทธิภาพดีกว่าสมการ F1 ซึ่งในช่วงแรกของการฝึกอบรมอัลกอริทึม MADDPG MATD3 และ MASAC มีแนวโน้มการได้ค่ารางวัลที่พุ่งสูงขึ้นจนเข้าใกล้จุดสูงสุดของค่ารางวัล โดยอัลกอริทึม MATD3 มีแนวโน้มที่ต่ำลงในช่วงรอบการอบรมที่ 600 นั้นอาจเกิดจากการปรับพารามิเตอร์ของอัลกอริทึม เช่น จำนวนของโครงข่ายประสาทเทียม จำนวนค่า Gamma เป็นต้น นั้นเป็นสาเหตุให้โมเดลมีการเรียนรู้ที่ผิดพลาด (Underfitting) ส่วนอัลกอริทึมที่แสดงแนวโน้มค่ารางวัลที่ดีและสูงสุดในสมการ F2 คือ MADDPG มีการลู่เข้าที่เร็ว โดยมีการลู่เข้าตั้งแต่รอบที่ 300 และคงที่จนถึง 5,000 รอบ



รูปที่ 4.7 ผลการทดสอบฟังก์ชันฐานนิยมเดียวสมการที่ 2

4.3.2 ฟังก์ชันนิยมหลายตัว

การทดสอบอัลกอริทึมที่ใช้สมการในตารางที่ 4.3 ได้แก่ F3 และ F4 จะมีความซับซ้อนมากขึ้นในการแก้ไขปัญหาของฟังก์ชัน มีทั้งฟังก์ชันคอส และการดอปโปรดัก จึงทำให้มีความซับซ้อนมากขึ้น โดยจุดประสงค์ในแก่สมการทดสอบคือการหาค่าตอบคู่เข้าสู่ศูนย์เช่นเดียวกัน

ตารางที่ 4.3 ฟังก์ชันทดสอบฐานนิยมหลายตัว

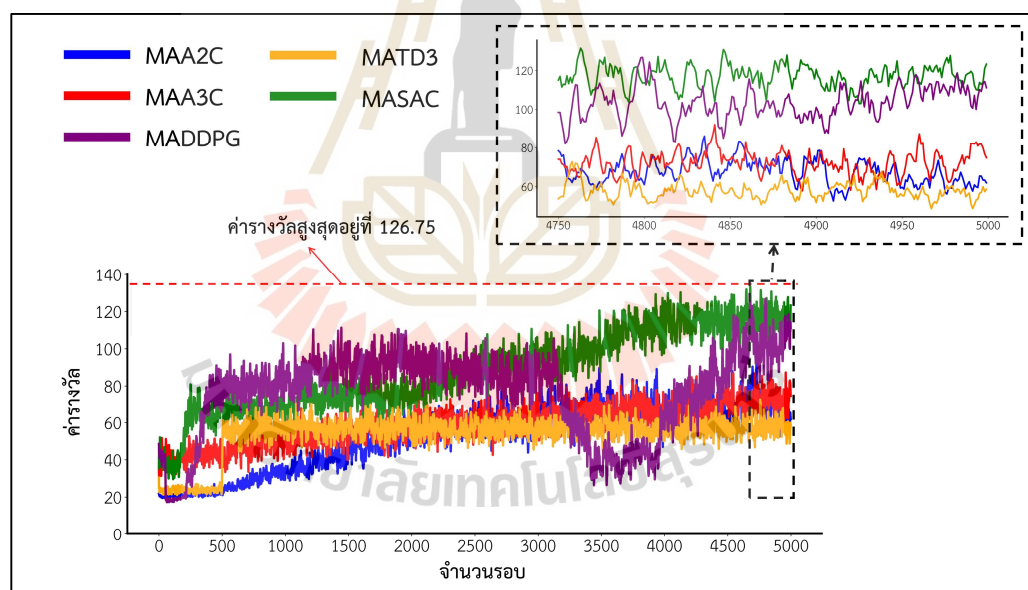
ลำดับ	ฟังก์ชัน	ช่วง	f_{min}
F3	$F(x) = \sum_{i=1}^n x_i^2 - 10 \cos(2\pi x_i) + 10 $	$[-5.12, 5.12]$	0
F4	$F(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600, 600]$	0

ผลการทดสอบฟังก์ชัน F3 และ F4 ของอัลกอริทึมทั้งห้าได้แสดงดังตารางที่ 4.4 และแนวโน้มค่ารางวัลของแต่ละอัลกอริทึมแสดงดังรูปที่ 4.8 และ 4.9 โดยสมการทั้งสองนี้มีความซับซ้อนที่มากขึ้นในการแก้สมการเพื่อให้ได้คำตอบที่เข้าใกล้ศูนย์ ในการใช้อัลกอริทึมกับสมการทดสอบของ F3 พบว่าอัลกอริทึมทั้งห้ามีค่ารางวัลที่ไม่ค่อยเสถียร โดยอัลกอริทึมนี้มีอัตราการคู่เข้าของค่ารางวัลที่สูง และแนวโน้มที่ดีเป็นอัลกอริทึม MASAC ที่มีแนวโน้มได้รับรางวัลที่เพิ่มขึ้นจนถึงรอบที่กำหนด โดย MADDPG มีแนวโน้มค่ารางวัลที่ดีเช่นกัน แต่มีข้อสังเกตในช่วงรอบ 3,500 ถึงรอบ

ที่ 4,000 มีแนวโน้มการได้รับค่ารางวัลที่ลดลง หลังจากนั้นจึงเพิ่มสูงขึ้นในรอบที่ 4,750 ถึงรอบที่ 5,000 เทียบเท่า MASAC นั้นอาจเป็นช่วงการเรียนรู้ที่บ่งชี้ของโมเดล ซึ่งคำตอบที่ได้ของ MADDPG และ MASAC มีค่าที่ใกล้เคียงเช่นกัน

ตารางที่ 4.4 ผลการทดสอบฟังก์ชัน F3 และ F4


อัลกอริทึม	ผลลัพธ์ฟังก์ชัน F3	ผลลัพธ์ฟังก์ชัน F4
MAA2C	9.08	3.78
MAA3C	11.18	5.55
MADDPG	0.52	2.34
MATD3	16.90	12.48
MASAC	2.46	10.80



รูปที่ 4.8 ผลการทดสอบฟังก์ชันฐานนิยมหลายตัวสมการที่ 3

ผลการทดสอบฟังก์ชัน F4 ของอัลกอริทึมทั้งห้าได้แสดงดังตารางที่ 4.4 และแนวโน้มค่ารางวัลของแต่ละอัลกอริทึมแสดงดังรูปที่ 4.6 พบว่าในช่วงรอบการฝึกอบรมที่ 0 ถึงรอบที่ 500 มีอัตราการเปลี่ยนแปลงของค่ารางวัลที่สูง โดยเฉพาะอัลกอริทึม MADDPG MATD3 และ

MASAC มีแนวโน้มที่เข้าใกล้ค่าแรงวัลที่สูง เมื่อผ่านไป 3,500 อัลกอริทึม MADDPG และ MATD3 มีแนวโน้มที่ลดลง ลักษณะที่แนวโน้มลดลงเหมือนกันนี้เกิดจากอัลกอริทึมทั้งสองนี้เป็นอัลกอริทึมชนิดเดียวกัน ซึ่งอัลกอริทึม MATD3 ได้พัฒนามาจาก MADDPG นั้นเอง และในช่วงรอบการอบรมที่ 4,750 ถึง 5,000 รอบนั้น MAA2C และ MAA3C มีแนวโน้มที่เพิ่มมากขึ้นจนใกล้เคียงกับอัลกอริทึม MADDPG และ MATD3 ต่างจาก MASAC ที่มีแนวโน้มค่าแรงวัลที่คงที่ และมีค่าแรงวัลสูงสุดที่ 192.30



รูปที่ 4.9 ผลการทดสอบฟังก์ชันฐานนิยมหลายตัวสมการที่ 4


4.4 ผลการจำลองผลกระทบของโหลดในระบบไมโครกริด 33 โหนด

4.4.1 กรณีศึกษาที่ 1 และกรณีศึกษาที่ 2


ในกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 ได้ใช้คุณลักษณะโหลดแบบพื้นที่อาศัย และ โหลดพื้นที่ธุรกิจ ซึ่งดำเนินการแบบไม่ผสมผสานโหลด โดยที่กรณีศึกษาที่ 1 เป็นโหลดแบบพื้นที่พักอาศัย ซึ่งการใช้พลังงานจะมีค่าน้อยในช่วงเวลา 08.00 น. ถึง 17.00 น. หลังจากนั้นจะมีการใช้ไฟฟ้าที่มากขึ้นตามพฤติกรรมของมนุษย์ในช่วง 17.00 น. จนถึง 22.00 น. เมื่อวิเคราะห์การไหลของไฟฟ้าโดยใช้วิธีนิวตัน-ราฟสัน เพื่อวิเคราะห์แรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียโดยรวมพบว่าในกรณีศึกษาที่หนึ่งจะมีแรงดันตกในช่วงเวลา 18.00 น. จนถึงจุดต่ำสุดที่ 21.00 น. มีค่าที่ต่ำกว่า 0.95 ต่อหน่วย ซึ่งแปรผันตรงกับกำลังไฟฟ้าสูญเสีย ณ เวลาเดียวกันมีค่าที่สูงในช่วงเวลาเดียวกัน และกรณีศึกษาที่ 2 เป็นโหลดแบบพื้นที่ธุรกิจ โดยผลกระทบที่เห็นชัดนั้นเกิดในช่วงเวลา 08.00 น. ถึง 17.00 น. ที่มีการใช้พลังงานอย่างมากจึงทำให้เกิดแรงดันตก และการเพิ่มขึ้นของกำลังไฟฟ้าสูญเสีย เมื่อเปรียบเทียบกับกรณีศึกษาที่หนึ่งแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสีย นั้น ค่อนข้างกว่ากรณีศึกษาที่ 1 โดยแรงดันไฟฟ้าเฉลี่ยในระบบแต่ละช่วงเวลาแสดงดังรูปที่ 4.10 และกำลังไฟฟ้าสูญเสียรวมในแต่ละช่วงเวลาแสดงดังรูปที่ 4.11

ตารางที่ 4.5 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2

พารามิเตอร์	กรณีศึกษาที่ 1	กรณีศึกษาที่ 2
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9484 และ 0.9742	0.9484 และ 0.9663
แรงดันเฉลี่ย (ต่อหน่วย)	0.9551	0.9496
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	10.2778	12.7123




รูปที่ 4.10 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลากรณีสึกษาที่ 1 และกรณีสึกษาที่ 2




รูปที่ 4.11 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลากรณีสึกษาที่ 1 และกรณีสึกษาที่ 2

การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีทีหนึ่ง และกรณีสึกษาที่ 2 ที่แสดงผลกระทบของโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจได้แสดงดังรูปที่ 4.12 พบว่าแรงดันที่ตำแหน่งโนด 18 และ 33 ของกรณีทีหนึ่ง และกรณีทีสอง เกิดแรงดันตกมากที่สุดเมื่อเทียบกับโนดอื่น ๆ และผลของกำลังไฟฟ้าสูญเสียเกิดมากที่สุดที่โนด 2 โดยมีค่ากำลังสูญเสียสูงสุดทั้งสองกรณีมีค่า 51.79 kW และมีแรงดันไฟฟ้าเฉลี่ยกรณีสึกษาที่หนึ่ง และกรณีสึกษาที่สองอยู่ที่ 0.9551 และ 0.9496 ต่อหน่วย ดังรูปที่ 4.13



รูปที่ 4.12 แรงดันไฟฟ้าเดิมของระบบกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2




รูปที่ 4.13 กำลังไฟฟ้าสูญเสียเดิมของระบบกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2

4.4.2 กรณีศึกษาที่ 3 และกรณีศึกษาที่ 4


ในกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4 ได้ใช้คุณลักษณะโหลดแบบพื้นที่อาศัย และ โหลดพื้นที่ธุรกิจ ซึ่งดำเนินการแบบผสมผสานโหลดทั้งแบบพื้นที่พักอาศัย ผลลัพธ์ได้แสดงดังรูปที่ 4.14 และ 4.15 ซึ่งลักษณะการใช้พลังงานของทั้ง 2 กรณีนี้เมื่อวิเคราะห์การไหลของไฟฟ้า โดยใช้วิธี นิวตัน-ราฟสัน สำหรับวิเคราะห์แรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียโดยรวมพบว่าในกรณีที่ 3 จะมีแรงดันตกในช่วงเวลา 18.00 น. จนไปถึงจุดต่ำสุดที่ 21.00 น. มีค่าที่ต่ำกว่ากรณีศึกษาที่ 4 โดยโหลดแบบพื้นที่ธุรกิจติดตั้งที่โหนด 23 24 และ 25 ทำให้เกิดแรงดันตกเล็กน้อยในช่วง 08.00 น. ถึง 17.00 น. เมื่อเทียบกับกรณีศึกษาที่ 4 เป็นโหลดแบบผสมผสานโดยพื้นที่ธุรกิจที่โหนด 23 ถึง 25 และโหนดที่ 26 ถึงโหนดที่ 33 ผสมกับโหลดพื้นที่อาศัยที่โหนด 2 ถึงโหนด 18 พบว่าแรงดันช่วง 08.00 น. ถึง 17.00 น. มีแรงดันเฉลี่ยแต่ละช่วงเวลาน้อยกว่ากรณีที่ 3 เนื่องจากมีการใช้กำลังไฟฟ้าช่วงกลางวันมากขึ้น เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียมีค่า 11.17 MWh มากกว่ากรณีที่ 3 มีค่าอยู่ 10.52 MWh ดังตารางที่ 4.6

ตารางที่ 4.6 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4

พารามิเตอร์	กรณีศึกษาที่ 3	กรณีศึกษาที่ 4
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9559 และ 0.9677	0.9503 และ 0.9719
แรงดันเฉลี่ย (ต่อหน่วย)	0.9528	0.9546
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	10.5172	11.1712




รูปที่ 4.14 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลาของกรณีสถานการณ์ที่ 3 และกรณีสถานการณ์ที่ 4




รูปที่ 4.15 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลาของกรณีสถานการณ์ที่ 3 และกรณีสถานการณ์ที่ 4

การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 3 และกรณีสถานการณ์ที่ 4 ที่แสดงผลกระทบของโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจแบบผสมผสานได้แสดงดังรูปที่ 4.16 พบว่าแรงดันที่ตำแหน่งโนด 18 เป็นจุดที่มีแรงดันไฟฟ้าต่ำที่สุดในระบบ และผลของกำลังไฟฟ้าสูญเสียเกิดมากที่สุดที่โนด 2 ดังรูปที่ 4.17 ในกรณีสถานการณ์ที่ 3 และ 4 มีค่ากำลังไฟฟ้าสูญเสียสูงสุดอยู่ที่ 43.22 และ 35.22 kW แรงดันไฟฟ้าเฉลี่ยอยู่ที่ 0.9528 และ 0.9546 ต่อหน่วย



รูปที่ 4.16 แรงดันไฟฟ้าเดิมของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4




รูปที่ 4.17 กำลังไฟฟ้าสูญเสียเดิมของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4

4.5 ผลการจำลองหาขนาดและตำแหน่งติดตั้งพลังงานหมุนเวียน

ในการปรับปรุงแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียของระบบ ด้วยวิธีการเพิ่มพลังงานหมุนเวียนเข้าไปในระบบไมโครกริดทั้งสี่กรณีศึกษา ใช้อัลกอริทึมที่หาค่าที่เหมาะสมของพลังงานหมุนเวียน โดยหัวข้อที่ 4.5.1 กล่าวถึงการหาค่าที่เหมาะสมในกรณีที่ 1 เป็นโหลดพื้นที่พักอาศัยหมด หัวข้อที่ 4.5.2 กรณีที่ 2 เป็นโหลดพื้นที่ธุรกิจ หัวข้อที่ 4.5.3 และหัวข้อที่ 4.5.4 กล่าวถึงการหาค่าที่เหมาะสมในกรณีที่ 3 และกรณีที่ 4 โดยทั้งสองเป็นโหลดผสมผสานระหว่างโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจ


4.5.1 ผลการหาค่าตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 1

ในการดำเนินตามกรณีศึกษาที่ 1 ได้จำลองโหลดแบบพื้นที่พักอาศัยในระบบทดสอบ IEEE 33 โหนดตั้งแต่โหนดที่ 1 ถึงโหนดที่ 33 ดังรูปที่ 4.18 โดยข้อมูลการดำเนินงานได้แสดงไว้ดังตารางที่ 3.6 เพื่อหาค่าที่เหมาะสมในสถานะการณ์ที่มีการใช้โหลดน้อยในช่วงเวลา 08.00 น. ถึง 17.00 น. และใช้โหลดมากในช่วงกลางคืนตั้งแต่ในช่วง 17.00 น. จนถึง 22.00 น.



รูปที่ 4.18 กรณีศึกษาที่ 1 ด้วยโหลดแบบพื้นที่พักอาศัย

จากการประยุกต์ใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึมทั้งหมด เพื่อหาตำแหน่ง และขนาดที่เหมาะสม พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึมมีการลู่อเข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MADDPG อยู่ที่ 75.23 สังเกตได้ว่าความสามารถในการลู่อเข้าของอัลกอริทึม MADDPG และ MATD3 มีการลู่อเข้าที่เร็วกว่ามาก เมื่อเปรียบเทียบกับอัลกอริทึมอื่น ๆ ที่มีการลู่อเข้าเป็นแนวโน้มอย่าง MAA2C, MAA3C และ MASAC ซึ่งมีค่ารางวัลที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 โดยภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.19



รูปที่ 4.19 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของกรณีศึกษาที่ 1

เมื่อวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 1 ความสามารถในการอบรมจะมีช่วงนี้การลู่อเข้าที่ใกล้เคียงกัน ซึ่งผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.7 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย และค่าใช้จ่ายของระบบพลังงานหมุนเวียน พบว่าความสามารถในการปรับปรุงแรงดันในระบบ MAA2C และ MASAC มีความสามารถโดดเด่นมากที่สุด มีค่าแรงดันต่ำที่สุดเท่ากันในระบบอยู่ที่ 0.9791 ต่อหน่วย อัลกอริทึมที่หาค่าเฉลี่ยของแรงดันได้ดีที่สุดคือ MASAC มีค่าเฉลี่ยที่สูงถึง 0.9866 ต่อหน่วย


ตารางที่ 4.7 ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 1

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	10.2777	6.3120	6.5998	6.1364	7.3808	8.2874
การลด กำลังไฟฟ้า สูญเสียที่ทำ ได้ (%)	-	62.83	55.73	67.49	39.25	24.02
แรงดัน ต่ำสุด (ต่อ หน่วย)	0.9484	0.9733	0.9721	0.9726	0.9715	0.9791
แรงดันเฉลี่ย (ต่อหน่วย)	0.9551	0.9820	0.9815	0.9818	0.9813	0.9866
ตำแหน่ง ของ PV	-	21, 33	33, 33	33, 33	33, 33	31, 30
ขนาดของ PV (kW)	-	210, 130	161, 148	300, 300	31, 119	117, 26
ตำแหน่ง ของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 20
ขนาดของ WT (kW)	-	300, 300	250, 157	300, 300	226, 5	275, 273
ค่าใช้จ่าย รวม (ล้านบาท)	-	53.13	39.33	64.50	36.21	41.48


เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียหลังจากติดตั้งพลังงานหมุนเวียนของแต่ละอัลกอริทึม พบว่าอัลกอริทึม MAA2C ได้จัดการกับค่ากำลังไฟฟ้าสูญเสียมากที่สุด โดยผลกระทบจากขนาดของพลังงานกังหันลมที่มีขนาดมากที่สุด ด้วยคุณลักษณะของข้อมูลพลังงานกังหันลมที่ใช้ในงานวิจัยนี้มีการผลิตพลังงานมากในช่วงกลางวัน และไม่มีพลังงานเซลล์แสงอาทิตย์ จึงทำให้อัลกอริทึมเพิ่มขนาดกังหันลมไปที่ขนาดสูงสุด เพื่อลดกำลังไฟฟ้าสูญเสียให้ได้มากที่สุด แต่นั่นก็ทำให้ค่าใช้จ่ายของระบบพลังงานหมุนเวียนสูงขึ้นไปด้วย เมื่อเปรียบเทียบผลของ MASAC ที่มีค่าแรงดันไฟฟ้าที่ใกล้เคียงกัน พบว่าการลดกำลังไฟฟ้าสูญเสียไม่ได้มาก โดยลดลงไปแค่ 14.14 % จากเดิม เมื่อเทียบกับ MAA2C ลดกำลังไฟฟ้าสูญเสียได้ถึง 34.60 % โดยแรงดันไฟฟ้าเฉลี่ยแสดงดังรูปที่ 4.20

จากขนาดที่ใช้ในการติดตั้งมีความสัมพันธ์กับต้นทุนดังตารางที่ 4.7 ด้วยเงื่อนไขในการจำลองให้ต้นทุนน้อยที่สุดสำหรับการปรับปรุงแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียของระบบไมโครกริด พบว่าอัลกอริทึมที่ปรับปรุงระบบไมโครกริดที่มีประสิทธิภาพดีอย่าง MAA2C ที่โดดเด่นที่สุด มีต้นทุนที่สูงถึง 53.13 ล้านบาท โดยเป็นรองของอัลกอริทึม MADDPG ที่ใช้ต้นทุนมากที่สุดถึง 64.50 ล้านบาท ซึ่งผลลัพธ์ไม่ได้ดีกว่าอัลกอริทึม MAA2C อัลกอริทึมที่ใช้ต้นทุนน้อยที่สุดเป็น MATD3 มีต้นทุนอยู่ที่ 36.21 ล้านบาท เมื่อเทียบต้นทุนที่ใกล้เคียงกันอย่าง MAA3C และ MASAC ที่มีค่าใกล้เคียงกันมีต้นทุนอยู่ที่ 39.33 และ 41.48 ล้านบาท โดยระบบไมโครกริดที่ปรับปรุงด้วยอัลกอริทึม MATD3 จะมีประสิทธิภาพที่ดีกว่า MASAC ในเรื่องกำลังไฟฟ้าสูญเสียที่น้อยกว่า แต่ด้อยกว่าอัลกอริทึม MAA3C โดยกำลังไฟฟ้าสูญเสียเฉลี่ยของระบบแต่ละช่วงเวลาแสดงดังรูปที่ 4.24


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 1 ด้วยโหลดแบบพื้นที่พักอาศัย โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.22 ถึงรูปที่ 4.24 ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.25 ถึงรูปที่ 4.27



รูปที่ 4.20 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 1 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.21 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 1 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.22 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.23 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1

ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.24 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 ด้วยอัลกอริทึม MASAC



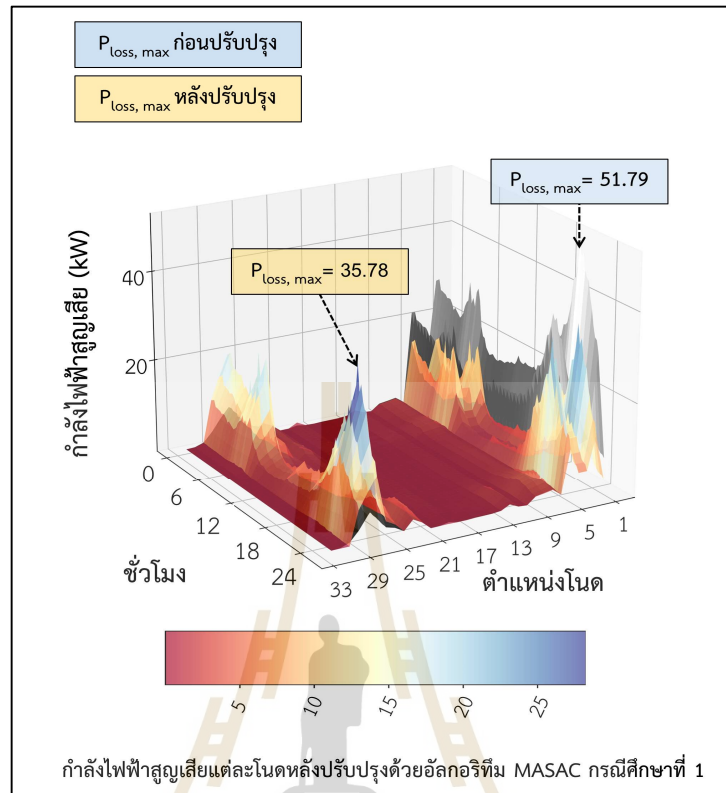
รูปที่ 4.25 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



รูปที่ 4.26 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1


ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.27 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 ด้วยอัลกอริทึม MASAC


4.5.2 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 2

ในการดำเนินการตามกรณีศึกษาที่ 2 ได้จำลองโหลดแบบพื้นที่ธุรกิจในระบบทดสอบ IEEE 33 โหนดตั้งแต่โหนดที่ 1 ถึงโหนดที่ 33 ดังรูปที่ 4.28 โดยข้อมูลการดำเนินงานได้แสดงไว้ดังตารางที่ 3.6 เพื่อหาค่าที่เหมาะสมในสถานะการณ์ที่มีการใช้โหลดมากในช่วงเวลา 08.00 น. ถึง 17.00 น. และใช้โหลดน้อยในช่วงกลางคืนตั้งแต่ในช่วง 17.00 น. จนถึง 22.00 น.



รูปที่ 4.28 กรณีศึกษาที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจ

เมื่อวิเคราะห์ผลการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 2 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึมที่กล่าวมาข้างต้น พบว่าความสามารถในการรับค่าแรงวัตต์ในแต่ละอัลกอริทึมมีการลู่เข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่าแรงวัตต์สูงสุดเป็นของอัลกอริทึม MADDPG อยู่ที่ 74.91 สังเกตได้ว่าความสามารถในการลู่เข้าของอัลกอริทึม MADDPG และ MATD3 มีค่าคล้ายคลึงกับกรณีศึกษาที่ 1 โดยอัลกอริทึมอื่น ๆ ก็เช่นกัน ซึ่งมีการลู่เข้าเป็นแนวโน้มอย่าง MAA2C, MAA3C และ MASAC เหมือนกับกรณีศึกษาที่ 1 สังเกตได้จากค่าแรงวัตต์ที่มีการลู่เข้าในลักษณะที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 โดยภาพรวมค่าแรงวัตต์ของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.28



รูปที่ 4.29 ค่าแรงจลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของ
กรณีศึกษาที่ 2

เมื่อวิเคราะห์ค่าแรงจลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 2 มีความสามารถในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกัน ซึ่งผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.8 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย และค่าใช้จ่ายของระบบพลังงานหมุนเวียน หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบด้วยอัลกอริทึมการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ พบว่าทุกอัลกอริทึมมีแรงดันเฉลี่ยที่ใกล้เคียงกัน โดยแรงดันเฉลี่ยที่มากที่สุดปรับปรุงด้วยอัลกอริทึม MASAC มีค่าแรงดันเฉลี่ยอยู่ที่ 0.9798 ต่อหน่วย และมีค่าแรงดันต่ำสุด 0.9740 ต่อหน่วย แต่มีผลลัพธ์การลดกำลังไฟฟ้าสูญเสียอยู่ที่ 35.01 % ซึ่งน้อยกว่าอัลกอริทึม MAA2C, MAA3C และ MADDPG โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 แสดงดังรูปที่ 4.29


ตารางที่ 4.8 ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 2

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	12.7123	8.8711	9.2848	8.0990	9.6988	9.4159
การลด กำลังไฟฟ้า สูญเสียที่ทำ ได้ (%)	-	43.30	36.92	56.96	31.07	35.01
แรงดัน ต่ำสุด (ต่อ หน่วย)	0.9484	0.9723	0.9723	0.9724	0.9717	0.9740
แรงดันเฉลี่ย (ต่อหน่วย)	0.9496	0.9783	0.9782	0.9786	0.9782	0.9798
ตำแหน่ง ของ PV	-	33, 33	33, 33	33, 33	33, 33	32, 32
ขนาดของ PV (kW)	-	300, 300	300, 300	300, 300	91, 248	289, 277
ตำแหน่ง ของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 32
ขนาดของ WT (kW)	-	181, 1	1, 42	300, 300	300, 3	148, 73
ค่าใช้จ่าย รวม (ล้านบาท)	-	36.98	27.98	64.50	33.86	38.08


แม้ว่าอัลกอริทึม MAA2C, MAA3C, MADDPG และ MATD3 มีผลลัพธ์การปรับปรุงแรงดันไฟฟ้าที่ต่ำกว่าอัลกอริทึม MASAC แต่การปรับปรุงกำลังไฟฟ้าสูญเสียภายในระบบไมโครกริดทำได้ดีกว่าอัลกอริทึม MASAC แสดงดังรูปที่ 4.30 โดยอัลกอริทึมที่ทำได้ดีที่สุดคืออัลกอริทึม MADDPG สามารถลดกำลังไฟฟ้าสูญเสียในระบบได้ถึง 56.96 % โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 300 kW ที่โหนดที่ 33 และพลังงานกังหันลมสองตัวที่โหนดที่ 33 มีขนาด 300 kW เช่นกัน และรองลงมาเป็นอัลกอริทึม MAA2C ที่สามารถลดกำลังไฟฟ้าสูญเสียภายในระบบไมโครกริดได้ 43.30 % โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวมีขนาด 300 kW ที่โหนดที่ 33 และพลังงานกังหันลมสองตัวที่โหนดที่ 33 มีขนาด 181 kW และ 1 kW

เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียน ซึ่งสัมพันธ์กับค่าใช้จ่ายในการติดตั้งพบว่าขนาดของพลังงานเซลล์แสงอาทิตย์จะมีความมากกว่ากรณีหนึ่ง เนื่องจากคุณลักษณะโหลดแบบพื้นที่ธุรกิจมีการใช้พลังงานมากในช่วงกลางวัน จึงทำให้ผลลัพธ์ที่ได้จากการหาค่าที่เหมาะสมของพลังงานเซลล์แสงอาทิตย์มีขนาดที่มากกว่าพลังงานกังหันลมในกรณีศึกษาที่ 2 ซึ่งอัลกอริทึม MADDPG ให้ขนาดพลังงานหมุนเวียนมากที่สุด ซึ่งทำให้มีค่าการติดตั้งที่สูงที่สุด เมื่อเปรียบเทียบกับอัลกอริทึมที่มีค่ากำลังไฟฟ้าสูญเสียที่ใกล้เคียงคืออัลกอริทึม MAA2C ที่มีค่าการติดตั้งที่น้อยกว่า แต่มีประสิทธิภาพการลดกำลังไฟฟ้าสูญเสีย และแรงดันเฉลี่ยที่ใกล้เคียงกันดังตารางที่ 4.8 เมื่อวิเคราะห์อัลกอริทึม MAA3C ที่มีค่าการติดตั้งที่น้อยที่สุด แต่นั่นก็ทำให้ค่ากำลังไฟฟ้าสูญเสียลดลงเพียง 36.92 % ซึ่งมีความมากกว่าอัลกอริทึม MATD3 โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 2 แสดงดังรูปที่ 4.31


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีศึกษาที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจ โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.32 ถึงรูปที่ 4.34 และภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.35 ถึงรูปที่ 4.37



รูปที่ 4.30 แร่งต้นไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.31 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC



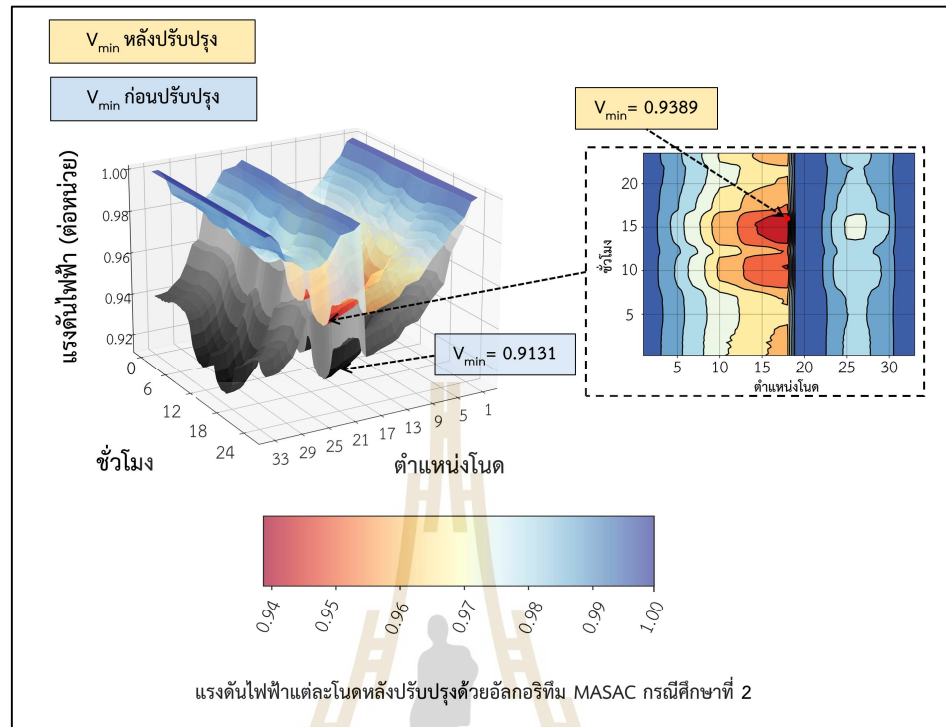
รูปที่ 4.32 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.33 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2

ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.34 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม MASAC




รูปที่ 4.35 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



รูปที่ 4.36 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2


ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.37 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 ด้วยอัลกอริทึม MASAC

4.5.3 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 3


ในการดำเนินการตามกรณีศึกษาที่ 3 ได้จำลองโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจในระบบทดสอบ IEEE 33 โหนด โดยดำเนินการงานได้แสดงไว้ดังตารางที่ 3.6 โหนดตั้งแต่โหนดที่ 1 – 18, 19 – 22 และโหนดที่ 26 – 33 เป็นโหลดพื้นที่พักอาศัย โหนดที่ 23 - 25 เป็นโหนดที่เชื่อมต่อโหลดพื้นที่ธุรกิจ เพื่อปรับเปลี่ยนสถานะการณของโหลดภายในระบบไมโครกริดให้มีการใช้พลังงานมากขึ้นในช่วง 08.00 – 17.00 น. โดยภาพรวมของระบบได้ดังรูปที่ 4.38



รูปที่ 4.38 กรณีศึกษาที่ 3 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ

เมื่อวิเคราะห์ผลการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 3 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึมมีการลู่ออกที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MAA2C อยู่ที่ 82.25 สังเกตได้ว่าความสามารถในการลู่ออกของอัลกอริทึม MADDPG และ MATD3 มีค่าคล้ายคลึงกับกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 ซึ่งอัลกอริทึมอย่าง MAA2C, MAA3C และ MASAC ยังคงมีประสิทธิภาพการเรียนรู้รับเพื่อให้ได้ค่ารางวัลเป็นแนวโน้มเหมือนกับกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 สังเกตได้จากค่ารางวัลที่มีการลู่ออกในลักษณะที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 โดยอัลกอริทึมที่โดดเด่นอย่างชัดเจนใน

เรื่องของประสิทธิภาพเป็นอัลกอริทึม MAA2C ภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.39



รูปที่ 4.39 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของกรณีศึกษาที่ 3

เมื่อวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 3 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกัน ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.9 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย และค่าใช้จ่ายของระบบพลังงานหมุนเวียน หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบ พบว่าอัลกอริทึม MASAC มีค่าแรงดันต่ำสุด 0.9796 ต่อหน่วย และแรงดันไฟฟ้าเฉลี่ย 0.9859 ต่อหน่วย เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, และ MATD3 จะมีค่าแรงดันไฟฟ้ามากที่สุด โดยติดตั้งพลังงานแสงอาทิตย์ที่โนด 32 และ 30 มีขนาด 256 และ 151 kW พลังงานกังหันลมโนดที่ 32 และ 30 มีขนาด 264 และ 98 kW

ตารางที่ 4.9 ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 3


พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	10.5172	6.3483	7.1163	6.2501	6.8864	7.6678
การลด กำลังไฟฟ้า สูญเสียที่ทำได้ (%)	-	65.67	47.79	68.27	52.72	37.16
แรงดันต่ำสุด (ต่อหน่วย)	0.9559	0.9739	0.9750	0.9739	0.9732	0.9796
แรงดันเฉลี่ย (ต่อหน่วย)	0.9528	0.9812	0.9825	0.9814	0.9811	0.9859
ตำแหน่งของ PV	-	33, 33	33, 31	33, 33	33, 33	32, 30
ขนาดของ PV (kW)	-	275, 1	264, 244	300, 300	247, 104	256, 151
ตำแหน่งของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 30
ขนาดของ WT (kW)	-	300, 300	206, 144	300, 300	260, 99	264, 98
ค่าใช้จ่าย รวม (ล้านบาท)	-	38.97	43.99	64.50	37.99	40.53

เมื่อเปรียบเทียบตำแหน่งที่ได้ และขนาดที่ได้ พบว่ามีตำแหน่งที่แตกต่างจากอัลกอริทึมอื่น ๆ มักจะติดตั้งที่ตำแหน่งโนดสุดท้ายที่มีแรงดันต่ำที่สุด คือโนดที่ 33 แต่อัลกอริทึม MASAC นั้นต่างออกไป นั่นจึงทำให้แรงดันเฉลี่ย และแรงดันไฟฟ้าที่ต่ำที่สุดมีค่าสูงกว่าอัลกอริทึมอื่น ๆ โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 3 แสดงดังรูปที่ 4.40


แม้ว่าอัลกอริทึม MASAC จะมีผลลัพธ์ค่าแรงดันไฟฟ้าที่สูงกว่าอัลกอริทึมอื่น ๆ แต่เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสีย พบว่ามีการลดกำลังไฟฟ้าสูญเสียมีค่าต่ำกว่าอัลกอริทึมอื่น ๆ อย่าง MAA2C, MAA3C, MADDPG และ MATD3 ที่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 65.67 %, 47.79 %, 68.27 %, 52.72 % ตามลำดับ โดยอัลกอริทึม MASAC สามารถลดได้เพียง 37.16 % และอัลกอริทึมที่สามารถลดกำลังไฟฟ้าสูญเสียได้มากที่สุดคือ MADDPG โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 300 kW ที่โนดที่ 33 และพลังงานกังหันลมสองตัวที่โนดที่ 33 มีขนาด 300 kW เช่นกัน และรองลงมาเป็นอัลกอริทึม MAA2C ติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 275 kW และ 1 kW ที่โนดที่ 33 และพลังงานกังหันลมสองตัวที่โนดที่ 33 มีขนาด 300 kW และ 300 kW โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 3 แสดงดังรูปที่ 4.41

เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียนที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 3 เป็นโหลดแบบผสมผสานระหว่างโหลดพื้นที่แบบพักอาศัยร่วมกับโหลดแบบพื้นที่แบบธุรกิจที่โนด 23, 24 และ 25 พบว่าขนาดของพิกัดพลังงานหมุนเวียนที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MATD3 ที่มีค่าใช้จ่ายอยู่ 37.99 ล้านบาท แต่เมื่อสังเกตกำลังไฟฟ้าสูญเสียสามารถลดได้ถึง 52.72 % เมื่อเปรียบเทียบอัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่าง อัลกอริทึม MAA2C ที่มีค่าใช้จ่ายอยู่ 38.97 ล้านบาท แต่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 65.67 % นั่นเป็นเพราะขนาดของพลังงานกังหันลมของอัลกอริทึม MAA2C มีค่าสูงจึงสามารถลดกำลังไฟฟ้าสูญเสียที่เกิดจากโหลดพื้นที่พักอาศัยที่มักเกิดในช่วงกลางคืนได้ จึงทำให้เปอร์เซ็นต์การลดกำลังไฟฟ้าสูญเสียสูงกว่า MATD3


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 3 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัยและพื้นที่แบบธุรกิจ โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.42 ถึงรูปที่ 4.43 และภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.45 ถึงรูปที่ 4.47



รูปที่ 4.40 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 3 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.41 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 3 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.42 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.43 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3

ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.44 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 ด้วยอัลกอริทึม MASAC




รูปที่ 4.45 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



รูปที่ 4.46 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3


ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.47 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 ด้วยอัลกอริทึม MASAC

4.5.4 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของกรณีศึกษาที่ 4


ในการดำเนินการตามกรณีศึกษาที่ 4 ได้จำลองโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจในระบบทดสอบ IEEE 33 โหนด โดยดำเนินการงานได้แสดงไว้ดังตารางที่ 3.6 โหนดตั้งแต่โหนดที่ 1 – 18 และโหนดที่ 19 – 22 เป็นโหลดพื้นที่พักอาศัย ร่วมกับโหนดที่ 23 – 25 และโหนดที่ 26 - 33 เป็นโหนดที่เชื่อมต่อโหลดพื้นที่ธุรกิจ เพื่อปรับเปลี่ยนสถานะการณของโหลดภายในระบบไมโครกริดให้มีการใช้พลังงานมากขึ้นในช่วง 08.00 – 17.00 น. โดยภาพรวมของระบบได้ดังรูปที่ 4.45



รูปที่ 4.45 กรณีศึกษาที่ 4 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ

เมื่อวิเคราะห์ผลการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 4 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึมมีการลู่อเข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MAA2C อยู่ที่ 84.42 สังเกตได้ว่าความสามารถในการลู่อเข้าของอัลกอริทึม MADDPG และ MATD3 มีค่าคล้ายคลึงกับกรณีศึกษาที่ 1 กรณีศึกษาที่ 2 และกรณีศึกษาที่ 3 เช่นกัน ซึ่งอัลกอริทึม MAA2C, MAA3C และ MASAC ยังคงมีประสิทธิภาพการเรียนรู้เพื่อให้ได้ค่ารางวัลเป็นแนวโน้มเหมือนกับกรณีศึกษาที่ 1 กรณีศึกษาที่ 2 และกรณีศึกษาที่ 3 สังเกตได้จากค่ารางวัลที่มีการลู่อเข้าในลักษณะที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 โดย

อัลกอริทึมที่โดดเด่นอย่างชัดเจนในเรื่องของประสิทธิภาพเป็นอัลกอริทึม MAA2C ภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.49



รูปที่ 4.49 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียนแต่ละเอเจนต์ของกรณีศึกษาที่ 4

เมื่อวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 4 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกัน ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.10 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย และค่าใช้จ่ายของระบบพลังงานหมุนเวียน หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบ พบว่าอัลกอริทึม MASAC มีค่าแรงดันต่ำสุด 0.9775 ต่อหน่วย และแรงดันไฟฟ้าเฉลี่ย 0.9830 ต่อหน่วย เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, และ MATD3 จะมีค่าแรงดันไฟฟ้ามากที่สุด โดยติดตั้งพลังงานแสงอาทิตย์ทั้งสองที่โหนด 31 มีขนาด 290 kW และ 93 kW ตามลำดับ พลังงานกังหันลมทั้งสองติดตั้งที่โหนด 32 มีขนาด 264 kW และ 98 kW ตามลำดับ โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 แสดงดังรูปที่ 4.50


ตารางที่ 4.10 ตำแหน่งและขนาดของพลังงานหมุนเวียนของกรณีศึกษาที่ 4

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	11.1712	7.0794	6.8374	6.4637	7.5139	8.0165
การลด กำลังไฟฟ้า สูญเสียที่ทำ ได้ (%)	-	57.80	63.38	72.83	48.67	39.35
แรงดัน ต่ำสุด (ต่อ หน่วย)	0.9503	0.9750	0.9752	0.9756	0.9749	0.9775
แรงดันเฉลี่ย (ต่อหน่วย)	0.9546	0.9807	0.9808	0.9809	0.9806	0.9830
ตำแหน่ง ของ PV	-	33, 33	33, 30	33, 33	33, 33	31, 31
ขนาดของ PV (kW)	-	300, 213	300, 255	300, 300	300, 109	290, 93
ตำแหน่ง ของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 32
ขนาดของ WT (kW)	-	300, 62	231, 199	300, 300	239, 60	277, 109
ค่าใช้จ่าย รวม (ล้านบาท)	-	44.98	51.15	64.50	48.67	41.08


ในกรณีศึกษาที่ 4 อัลกอริทึม MASAC ยังคงเป็นอัลกอริทึมที่ให้ผลลัพธ์ขนาด และ ตำแหน่งที่ปรับปรุงแรงดันไฟฟ้าในระบบได้สูงที่สุด แต่ก็ยังมีข้อสังเกตในเรื่องของกำลังไฟฟ้าสูญเสีย ยังคงมีค่ามากกว่าอัลกอริทึมอื่น ๆ มีค่ากำลังไฟฟ้าสูญเสียอยู่ที่ 8.0165 MWh หรือลดกำลังสูญเสีย ลดได้เพียง 39.35 % เมื่อวิเคราะห์อัลกอริทึมที่สามารถลดกำลังสูญเสียได้มากที่สุดคือ MADDPG และรองลงมาคือ MAA3C ที่สามารถลดกำลังไฟฟ้าได้ 64.50 % และ 51.15 % โดยขนาด และ ตำแหน่งของอัลกอริทึมคือ MAA3C มีตำแหน่งพลังงานแสงอาทิตย์อยู่ที่ 33 และ 30 พิกัดที่ 300 kW และ 255 kW พลังงานกังหันลมมีตำแหน่งที่ 33 ทั้งสองตำแหน่ง มีขนาดที่ 231 kW และ 199 kW ตามลำดับ ส่วนอัลกอริทึม MADDPG มีตำแหน่ง และขนาดคงเดิม พลังงานแสงอาทิตย์ และ พลังงานกังหันลมติดตั้งตำแหน่งที่ 33 และมีขนาด 300 kW ทั้งพลังงานแสงอาทิตย์ และกังหันลม โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 แสดงดังรูปที่ 4.51

เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียนที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 4 เป็นโหลดแบบผสมผสานระหว่างโหลดพื้นที่แบบพักอาศัยร่วมกับโหลดแบบพื้นที่แบบ ธุรกิจที่โนด 23, 24, 25 และโนดที่ 26, 27, 28, 29, 30, 31, 32, 33 พบว่าขนาดของพิกัดพลังงาน หมุนเวียนที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MASAC ที่มีค่าใช้จ่ายอยู่ 41.08 ล้านบาท แต่เมื่อสังเกตกำลังไฟฟ้าสูญเสียสามารถลดได้ถึง 39.35 % เมื่อเปรียบเทียบกับ อัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่างอัลกอริทึม MAA2C ที่มีค่าใช้จ่ายอยู่ 44.98 ล้านบาท แต่ สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 57.80 % ถึงอัลกอริทึม MASAC ในกรณีนี้มีจุดอ่อนเรื่องการ กำลังไฟฟ้าสูญเสีย แต่ยังมีข้อได้เปรียบเรื่องของแรงดันไฟฟ้าเฉลี่ย และแรงดันไฟฟ้าต่ำสุดที่ดีกว่า อัลกอริทึมอื่น ๆ


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 4 ด้วยโหลด แบบผสมผสานระหว่างพื้นที่แบบพักอาศัยและพื้นที่แบบธุรกิจ โดยดำเนินการหาค่าที่เหมาะสมด้วย อัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลัง ปรับปรุงของแต่ละโนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.52 ถึงรูปที่ 4.54 และ ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูป ที่ 4.55 ถึงรูปที่ 4.57



รูปที่ 4.50 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.51 กำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.52 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.53 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4

ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.54 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MASAC




รูปที่ 4.55 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4

ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



รูปที่ 4.56 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4

ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.57 กำลังไฟฟ้สูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 ด้วยอัลกอริทึม MASAC

4.6 ผลการจำลองผลกระทบของโหลดสถานีอัดประจุยานยนต์ไฟฟ้าในระบบ

ไมโครกริด 33 โนด

4.6.1 ผลการจำลองผลกระทบของโหลดสถานีอัดประจุยานยนต์ไฟฟ้ากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2

ในกรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 ได้ใช้คุณลักษณะโหลดแบบพื้นที่อาศัย และ โหลดพื้นที่ธุรกิจ ได้ดำเนินการเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าในกรณีที่ 1 และกรณีที่ 2 โดยมีขนาดของโหลดสถานีอัดประจุยานยนต์ไฟฟ้าสูงสุดอยู่ช่วงเวลาที่ 12.00 น. มีค่า 483.73 kW ดังรูปที่ 3.10


หลังจากที่วิเคราะห์การไหลของกำลังไฟฟ้าด้วยวิธีการนิวตัน-ราฟสัน ผลกระทบที่เกิดขึ้นจากโหลดสถานีอัดประจุยานยนต์ไฟฟ้าต่อแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียในระบบ ไมโครกริดแสดงดังรูปที่ 4.58 และรูปที่ 4.59 รายละเอียดของค่าแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสีย กรณีที่ 1 ได้แสดงดังตารางที่ 4.11 และกรณีที่ 2 แสดงดังตารางที่ 4.12 โดยแรงดันไฟฟ้าของกรณีที่ 1 ได้มีค่าลดลง เนื่องจากโหลดที่เพิ่มขึ้น ซึ่งแรงดันที่ต่ำอยู่ช่วง 21.00 น. ถึง 22.00 น. เป็นช่วงที่มีการใช้พลังงานไฟฟ้าที่เยอะ มีค่าแรงดันต่ำสุดอยู่ที่ 0.9484 ต่อหน่วย และกรณีศึกษาที่ 2 เป็นโหลดแบบพื้นที่ธุรกิจ โดยผลกระทบจากการติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าที่เห็นชัดเจนเกิดในช่วงเวลา 08.00 น. ถึง 17.00 น. ที่มีการใช้พลังงานอย่างมากจึงทำให้เกิดแรงดันตก ซึ่งมีค่าแรงดันต่ำกว่า 0.95 ต่อหน่วย และการเพิ่มขึ้นของกำลังไฟฟ้าสูญเสียในช่วงเวลาดังกล่าว

ตารางที่ 4.11 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 1 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า


พารามิเตอร์	ก่อนติดตั้งสถานี อัดประจุยานยนต์ไฟฟ้า	กรณีศึกษาที่ 1
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9484 และ 0.9742	0.9363 และ 0.9691
แรงดันเฉลี่ย (ต่อหน่วย)	0.9652	0.9591
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	10.2778	13.0490

ตารางที่ 4.12 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 2 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า

พารามิเตอร์	ก่อนติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า	กรณีศึกษาที่ 2
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9484 และ 0.9663	0.9291 และ 0.9675
แรงดันเฉลี่ย (ต่อหน่วย)	0.9596	0.9533
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	12.7123	16.8571




รูปที่ 4.58 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 โดยพิจารณาสถานีอัดประจุยานยนต์ไฟฟ้า




รูปที่ 4.59 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2 โดยพิจารณา สถานีอัดประจุยานยนต์ไฟฟ้า

การจำลองผลของการติดตั้งโหลดสถานีอัดประจุยานยนต์โดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีทีหนึ่ง และกรณีศึกษาที่ 2 ที่แสดงผลกระทบของโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจได้แสดงดังรูปที่ 4.60 และเมื่อวิเคราะห์ผลของกำลังไฟฟ้าสูญเสียที่มีค่ามากที่สุดของกรณีที่ 1 ที่มากที่สุดคือ 68.29 kW ที่ตำแหน่งโหนดที่ 2 กรณีที่ 2 ก็เช่นกันมีค่ากำลังไฟฟ้าสูญเสียอยู่ที่ 80.25 kW ที่ตำแหน่งโหนดที่ 2 โดยภาพรวมของกำลังไฟฟ้าสูญเสียได้แสดงดังรูปที่ 4.61



รูปที่ 4.60 แรงดันไฟฟ้าของระบบหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้ากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2



รูปที่ 4.61 กำลังไฟฟ้าสูญเสียของระบบหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้ากรณีศึกษาที่ 1 และกรณีศึกษาที่ 2

4.6.2 ผลการจำลองผลกระทบของโหลดสถานีอัดประจุยานยนต์ไฟฟ้ากรณีศึกษาที่ 3 และกรณีศึกษาที่ 4

ในกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4 ได้ใช้คุณลักษณะโหลดแบบพื้นที่อาศัย และ โหลดพื้นที่ธุรกิจแบบผสมผสานกัน ได้ดำเนินการเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าในกรณีที่ 3 และกรณีที่ 4 โดยมีขนาดของโหลดสถานีอัดประจุยานยนต์ไฟฟ้าสูงสุดอยู่ช่วงเวลาที่ 12.00 น. มีค่า 483.73 kW ดังรูปที่ 3.10


หลังจากที่วิเคราะห์การไหลของกำลังไฟฟ้าด้วยวิธีการนิวตัน-ราฟสัน ผลกระทบที่เกิดขึ้นจากโหลดสถานีอัดประจุยานยนต์ไฟฟ้าต่อแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียในระบบ ไมโครกริดแสดงดังรูปที่ 4.62 และรูปที่ 4.63 รายละเอียดของค่าแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสีย กรณีที่ 3 ได้แสดงดังตารางที่ 4.13 และกรณีที่ 4 แสดงดังตารางที่ 4.14 โดยแรงดันไฟฟ้าของกรณีที่ 3 ได้มีค่าลดลงเป็นแนวโน้มอย่างต่อเนื่อง เนื่องจากโหลดที่มีการใช้ตลอดทั้งวัน ร่วมกับลักษณะโหลด สถานีอัดประจุยานยนต์ไฟฟ้า โดยมีค่าแรงดันต่ำสุดอยู่ที่ 0.9503 ต่อหน่วย และกรณีศึกษาที่ 4 เป็น โหลดแบบพื้นที่พักอาศัยผสมผสานร่วมกับพื้นที่ธุรกิจ โดยผลกระทบจากการติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าที่เห็นชัดนั้นเกิดในช่วงเวลา 08.00 น. ถึง 17.00 น. ที่มีการใช้พลังงานอย่างมากจึงทำให้เกิดแรงดันไฟฟ้าโดยรวมลดลงมากกว่ากรณีที่ 3

ตารางที่ 4.13 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 3 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า


พารามิเตอร์	ก่อนติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า	กรณีศึกษาที่ 3
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9503 และ 0.9719	0.9382 และ 0.9691
แรงดันเฉลี่ย (ต่อหน่วย)	0.9646	0.9591
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	10.5172	13.3844

ตารางที่ 4.14 แรงดันและกำลังไฟฟ้าสูญเสียของระบบในกรณีศึกษาที่ 4 หลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้า

พารามิเตอร์	ก่อนติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า	กรณีศึกษาที่ 4
แรงดันต่ำสุด และแรงดันสูงสุด (ต่อหน่วย)	0.9559 และ 0.9677	0.9424 และ 0.9668
แรงดันเฉลี่ย (ต่อหน่วย)	0.9628	0.9566
กำลังไฟฟ้าสูญเสียรวมทั้งระบบ (MWh)	11.712	14.5426




รูปที่ 4.62 แรงดันไฟฟ้าเฉลี่ยในแต่ละช่วงเวลาหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าของกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4




รูปที่ 4.63 กำลังไฟฟ้าสูญเสียเฉลี่ยในแต่ละช่วงเวลาหลังเพิ่มโหลดสถานีอัดประจุยานยนต์ไฟฟ้าของกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4

การจำลองผลของการติดตั้งโหลดสถานีอัดประจุยานยนต์ไฟฟ้าโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 1 และกรณีศึกษาที่ 2 ที่แสดงผลกระทบของโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจได้แสดงดังรูปที่ 4.64 และเมื่อวิเคราะห์ผลของกำลังไฟฟ้าสูญเสียที่มีค่ามากที่สุดของกรณีที่ 3 ที่มากที่สุดคือ 57.93 kW ที่ตำแหน่งโหนดที่ 2 กรณีที่ 4 ก็เช่นกันมีค่ากำลังไฟฟ้าสูญเสียอยู่ที่ 54.11 kW ที่ตำแหน่งโหนดที่ 2 โดยภาพรวมของกำลังไฟฟ้าสูญเสียได้แสดงดังรูปที่ 4.65



รูปที่ 4.64 แรงดันไฟฟ้าหลังเพิ่มโหนดสถานีอัดประจุยานยนต์ไฟฟ้าของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4




รูปที่ 4.65 กำลังไฟฟ้าสูญเสียหลังเพิ่มโหนดสถานีอัดประจุยานยนต์ไฟฟ้าของระบบกรณีศึกษาที่ 3 และกรณีศึกษาที่ 4

4.7 ผลการจำลองหาขนาดและตำแหน่งติดตั้งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยพิจารณาโหลดของสถานีอัดประจุยานยนต์ไฟฟ้า

ในหัวข้อนี้ได้กล่าวถึงการปรับปรุงแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียของระบบ ด้วยวิธีการเพิ่มพลังงานหมุนเวียนเข้าไปร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ในระบบไมโครกริดทั้ง 4 กรณีศึกษา พิจารณาโหลดของสถานีอัดประจุยานยนต์ไฟฟ้า โดยใช้เทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์มีอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ในการหาค่าที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยหัวข้อที่ 4.7.1 และหัวข้อที่ 4.7.2 กล่าวถึงการหาค่าที่เหมาะสมในกรณีที่ 1 และกรณีที่ 2 เป็นโหลดพื้นที่พักอาศัยหมดตามด้วยโหลดพื้นที่ธุรกิจ หัวข้อที่ 4.7.3 และหัวข้อที่ 4.7.4 กล่าวถึงการหาค่าที่เหมาะสมในกรณีที่ 3 และกรณีที่ 4 โดยทั้งสองเป็นโหลดผสมผสานระหว่างโหลดพื้นที่พักอาศัย และพื้นที่ธุรกิจ โดยทุกกรณีศึกษาพิจารณาโหลดของสถานีอัดประจุยานยนต์ไฟฟ้า


4.7.1 ผลการหาค่าตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 1

ในการดำเนินตามกรณีศึกษาที่ 1 ได้จำลองโหลดแบบพื้นที่พักอาศัยในระบบทดสอบ IEEE 33 โหนด โดยดำเนินงานได้แสดงไว้ดังตารางที่ 3.6 ได้พิจารณาร่วมกับโหลดสถานีอัดประจุยานยนต์ไฟฟ้าที่มีปริมาณการใช้โหลดสูงสุดอยู่ที่ 483.73 kW ที่โหนด 2, 18, 19 และโหนดที่ 33 โดยภาพรวมของระบบได้ดังรูปที่ 4.66



รูปที่ 4.66 กรณีสึกษาที่ 1 ด้วยโหนดแบบพื้นที่แบบพักอาศัยพิจารณาพร้อมกับสถานีอัดประจุยานยนต์ไฟฟ้า

ผลการวิเคราะห์ความสามารถอัลกอริทึมในการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีสึกษาที่ 1 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึม เมื่อเปรียบเทียบในรูปที่ 4.19 มีค่ารางวัลที่น้อยลงกว่าค่ารางวัลของกรณีสึกษาที่ 1 แบบไม่เชื่อมต่อโหนดสถานีอัดประจุไฟฟ้า เมื่อวิเคราะห์การลู่เข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MADDPG อยู่ที่ 82.50 และรองลงมาคืออัลกอริทึม MASAC ที่มีค่ารางวัลที่สูง เมื่อวิเคราะห์ถึงแนวโน้มความสามารถในการได้รับค่ารางวัลจากการฝึกอบรมของอัลกอริทึม MAA2C, MAA3C และ MASAC มีแนวโน้มการของค่ารางวัลที่เป็นแนวโน้มเดียวกัน แต่อัลกอริทึม MASAC นั้นจะมีค่าน้อยกว่าอัลกอริทึมอื่น ๆ ในช่วงแรก และจะเริ่มลู่เข้าในช่วงระหว่างรอบที่ 125 ถึง 150 เมื่อเปรียบเทียบอัลกอริทึม MADDPG และ MATD3 ที่มี ความต่างกันเล็กน้อย ในช่วงรอบที่ 0 ถึงรอบที่ 50 หลังจากนั้นอัลกอริทึม MADDPG มีแนวโน้มของค่ารางวัลที่เพิ่มขึ้นเป็นขั้นบันได ส่วนอัลกอริทึม MATD3 มีแนวโน้มที่คงที่จนถึงรอบการฝึกอบรมสุดท้าย โดยภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.67



รูปที่ 4.67 ค่าแรงวัตที่ได้จากการฝึกรอบเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ของแต่ละเอเจนต์ของกรณีศึกษาที่ 1

เมื่อวิเคราะห์ค่าแรงวัตที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกรอบเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 1 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 ค่าแรงวัตที่มากที่สุดคือ MADDPG และน้อยที่สุดคือ MATD3 ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.16 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย ค่าใช้จ่ายของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบให้ดีขึ้น เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าอัลกอริทึม MASAC มีค่าแรงดันต่ำสุด 0.9707 ต่อหน่วย และแรงดันไฟฟ้าเฉลี่ย 0.9807 ต่อหน่วย โดยติดตั้งพลังงานแสงอาทิตย์ที่โนด 32 และโนดที่ 31 มีขนาด 190 kW และ 270 kW พลังงานกักเก็บลมนโนดที่ 32 และโนดที่ 31 ทั้งสองตัวขนาดที่ 272 kW และ 293 kW ระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 2 และโนดที่ 6 ขนาดที่ 94 kW และ 81 kW เมื่อเปรียบเทียบตำแหน่งที่ได้ และขนาดที่ได้ พบว่ามีตำแหน่งที่แตกต่างจากอัลกอริทึมอื่น ๆ มักจะติดตั้งที่ตำแหน่งโนดสุดท้ายที่มีแรงดันต่ำที่สุด คือโนดที่ 33 โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 1 แสดงดังรูปที่ 4.68


ตารางที่ 4.15 ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ
แบตเตอรี่ของกรณีศึกษาที่ 1

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	13.0490	8.6277	8.5529	8.5145	10.4046	9.6756
การลด กำลังไฟฟ้า สูญเสียที่ทำได้ (%)	-	51.25	52.57	53.26	25.42	34.87
แรงดันต่ำสุด (ต่อหน่วย)	0.9363	0.9664	0.9712	0.9676	0.9661	0.9707
แรงดันเฉลี่ย (ต่อหน่วย)	0.9591	0.9784	0.9783	0.9784	0.9781	0.9807
ตำแหน่งของ PV	-	33, 33	33, 33	33, 33	33, 33	32, 31
ขนาดของ PV (kW)	-	300, 300	285, 300	300, 300	157, 300	190, 270
ตำแหน่งของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 31
ขนาดของ WT (kW)	-	300, 300	300, 295	300, 300	127, 52	272, 293
ตำแหน่งของ BESS	-	2, 2	6, 16	33, 33	33, 33	2, 6
ขนาดของ BESS (kW)	-	10, 471	475, 10	25, 25	1100, 563	94, 81
ค่าใช้จ่ายรวม (ล้านบาท)	-	66.52	65.59	64.31	39.52	56.82


แม้ว่าอัลกอริทึม MASAC จะมีผลลัพธ์การปรับปรุงค่าแรงดันไฟฟ้าที่สูงที่สุด แต่เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียพบว่ามีกรณีลดกำลังไฟฟ้าสูญเสียมีค่าต่ำกว่าอัลกอริทึมอื่น ๆ อย่าง MAA2C, MAA3C และ MADDPG ที่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 51.25 %, 52.57 % และ 53.26 % ตามลำดับ โดยอัลกอริทึม MASAC สามารถลดได้กำลังไฟฟ้าสูญเสียได้ 34.87 % และอัลกอริทึมที่สามารถลดกำลังไฟฟ้าสูญเสียได้มากที่สุดคือ MADDPG โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 300 kW ที่โนดที่ 33 พลังงานกังหันลมสองตัวที่โนดที่ 33 ขนาด 300 kW และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 33 สองตัวมีขนาดที่ 25 kW และ 25 kW รองลงมาเป็นอัลกอริทึม MAA3C ติดตั้งพลังงานเซลล์แสงอาทิตย์ที่โนด 33 ทั้งสองตัวมีขนาด 285 kW และ 300 kW พลังงานกังหันลมสองตัวที่โนดที่ 33 ทั้งสองตัวเช่นกันมีขนาด 300 kW และ 295 kW ตามลำดับ และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 6 และโนดที่ 16 มีขนาดที่ 475 kW และ 10 kW โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 1 แสดงดังรูปที่ 4.69

เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 1 เป็นโหลดพื้นที่แบบพักอาศัย โดยพิจารณาโหลดสถานีอัดประจุยานยนต์ไฟฟ้า พบว่าขนาดของพิกัดพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MATD3 ที่มีค่าใช้จ่ายอยู่ 39.52 ล้านบาท สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 25.42 % เมื่อเปรียบเทียบกับอัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่างอัลกอริทึม MASAC ที่มีค่าใช้จ่ายอยู่ 56.82 ล้านบาท แต่สามารถลดกำลังไฟฟ้าสูญเสียได้เพียง 34.87 % และมีค่าแนวโน้มค่ารางวัลที่ดีมีความน่าเชื่อถือมากกว่า จึงเป็นเหตุให้ผลของแบบจำลอง MATD3 ไม่ถูกพิจารณาให้เป็นแนวทางในการปรับปรุงแรงดัน และลดกำลังไฟฟ้าสูญเสีย ดังนั้นอัลกอริทึม MASAC เป็นอัลกอริทึมที่มีต้นทุนต่ำสุด ที่สามารถปรับปรุงแรงดันได้ดีกว่าอัลกอริทึมอื่น ๆ และกำลังไฟฟ้าสูญเสียได้


การจำลองผลโดยรวมของแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสียในกรณีที่ 1 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัยและพื้นที่แบบธุรกิจ และโหลดสถานีอัดประจุยานยนต์ไฟฟ้า โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.70 ถึงรูปที่ 4.72 ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.73 ถึงรูปที่ 4.75



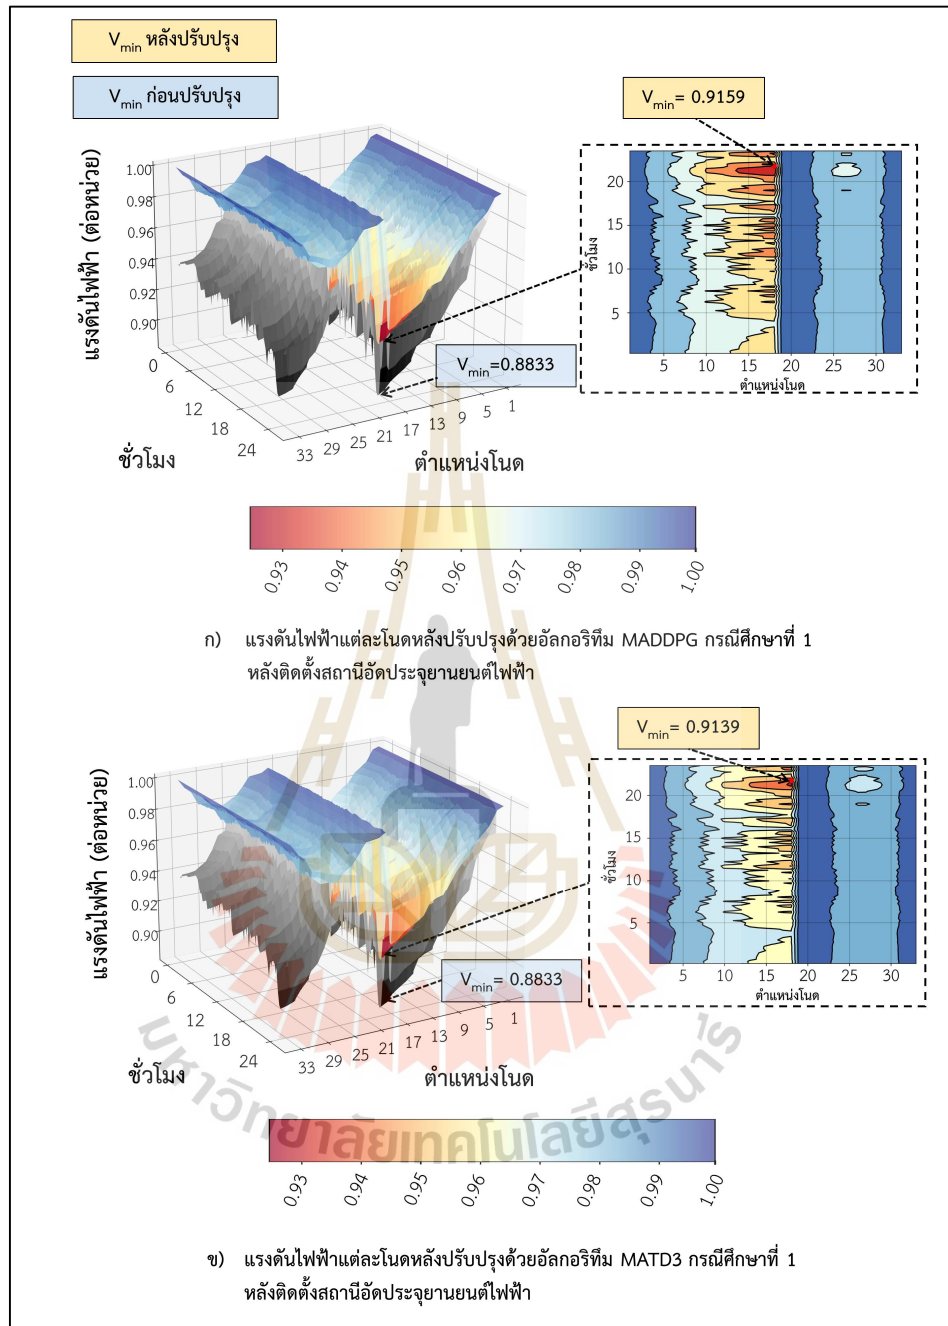
รูปที่ 4.68 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 1 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.69 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 1 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.70 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C
ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.71 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.72 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ด้วยอัลกอริทึม MASAC



รูปที่ 4.73 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.74 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.75 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 1 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC

4.7.2 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 2


ในการดำเนินการตามกรณีศึกษาที่ 2 ได้จำลองโหลดแบบพื้นที่พักอาศัยในระบบทดสอบ IEEE 33 โหนด โดยดำเนินการงานได้แสดงไว้ดังตารางที่ 3.6 ได้พิจารณาร่วมกับโหลดสถานีอัดประจุยานยนต์ไฟฟ้าที่มีปริมาณการใช้โหลดสูงสุดอยู่ที่ 483.73 kW ที่โหนด 2, 18, 19 และโหนดที่ 33 โดยภาพรวมของระบบได้ดังรูปที่ 4.76



รูปที่ 4.76 กรณีศึกษาที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจพิจารณาร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า

ผลการวิเคราะห์ความสามารถอัลกอริทึมในการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 2 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึม เมื่อเปรียบเทียบในรูปที่ 4.29 มีค่ารางวัลที่น้อยลงกว่าค่ารางวัลของกรณีศึกษาที่ 2 แบบไม่เชื่อมต่อโหลดสถานีอัดประจุยานยนต์ไฟฟ้า เนื่องจากกรณีศึกษาที่ 2 ร่วมกับโหลดสถานีอัดประจุยานยนต์ไฟฟ้ามีกำลังไฟฟ้าสูญเสียถึง 16.8571 MWh ทำให้แบบจำลองแต่ละอัลกอริทึมมีค่าเริ่มต้นของรางวัลที่ต่ำ เมื่อวิเคราะห์การเข้าสู่ที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MADDPG อยู่ที่ 80.21 และรองลงมาคืออัลกอริทึม MAA2C ที่มีค่ารางวัลที่สูง เมื่อ

วิเคราะห์ถึงแนวโน้มความสามารถในการได้รับค่ารางวัลจากการฝึกอบรมของอัลกอริทึม MAA2C, MAA3C และ MASAC มีแนวโน้มการของค่ารางวัลที่เป็นแนวโน้มเดียวกัน โดย MASAC นั้นยังคงลักษณะที่มีค่าน้อยกว่าอัลกอริทึมอื่น ๆ ในช่วงแรก และจะเริ่มลู่เข้าในช่วงระหว่างรอบที่ 125 ถึง 150 เมื่อเปรียบเทียบกับอัลกอริทึม MADDPG และ MATD3 ที่มีความต่างกันเล็กน้อยในช่วงรอบที่ 0 ถึงรอบที่ 50 หลังจากนั้นอัลกอริทึม MADDPG มีแนวโน้มของค่ารางวัลที่เพิ่มขึ้นเป็นขั้นบันได ส่วนอัลกอริทึม MATD3 มีแนวโน้มที่คงที่จนถึงรอบการฝึกอบรมสุดท้าย โดยภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.77



รูปที่ 4.77 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ของแต่ละเอเจนต์ของกรณีศึกษาที่ 2

ตารางที่ 4.16 ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ
แบตเตอรี่ของกรณีศึกษาที่ 2

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	16.8571	14.4662	17.6304	14.9195	18.1022	15.5658
การลด กำลังไฟฟ้า สูญเสียที่ทำได้ (%)	-	16.53	-4.38	12.98	-6.87	8.29
แรงดันต่ำสุด (ต่อหน่วย)	0.9291	0.9610	0.9627	0.9615	0.9603	0.9627
แรงดันเฉลี่ย (ต่อหน่วย)	0.9675	0.9748	0.9760	0.9749	0.9745	0.9775
ตำแหน่งของ PV	-	33, 33	2, 33	33, 33	33, 33	32, 31
ขนาดของ PV (kW)	-	300, 300	300, 300	300, 300	296, 18	298, 284
ตำแหน่งของ WT	-	33, 33	2, 33	33, 33	33, 33	31, 31
ขนาดของ WT (kW)	-	221, 152	300, 300	300, 300	209, 236	282, 291
ตำแหน่งของ BESS	-	2, 2	2, 2	33, 33	33, 33	11, 5
ขนาดของ BESS (kW)	-	10, 10	10, 2000	25, 25	2000, 908	149, 343
ค่าใช้จ่ายรวม (ล้านบาท)	-	55.91	66.41	64.31	57.27	64.12

การวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 2 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกันในช่วงรอบที่ 125 ถึงรอบที่ 150 ค่ารางวัลมากที่สุดคือ MADDPG และน้อยที่สุดคือ MATD3 ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.17 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย ค่าใช้จ่ายของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบให้ดีขึ้น


เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าอัลกอริทึม MASAC มีค่าแรงดันต่ำสุด 0.9627 ต่อหน่วย และแรงดันไฟฟ้าเฉลี่ย 0.9775 ต่อหน่วย โดยติดตั้งพลังงานแสงอาทิตย์ที่โนด 32 และโนดที่ 31 มีขนาดที่ 298 kW และ 284 kW พลังงานกังหันลมโนดที่ 31 และโนดที่ 31 ทั้งสองตัวขนาดที่ 282 kW และ 291 kW ระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 11 และโนดที่ 5 มีขนาด 149 kW และ 343 kW เมื่อเปรียบเทียบตำแหน่งที่ได้ และขนาดที่ได้ พบว่ามีตำแหน่งที่แตกต่างจากอัลกอริทึมอื่น ๆ มักจะติดตั้งที่ตำแหน่งโนดสุดท้ายที่มีแรงดันต่ำที่สุด คือโนดที่ 33 โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 แสดงดังรูปที่ 4.78

แม้ว่าอัลกอริทึม MASAC จะมีผลลัพธ์การปรับปรุงค่าแรงดันไฟฟ้าที่สูงที่สุด แต่เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียพบว่าการลดกำลังไฟฟ้าสูญเสียมีค่าต่ำกว่าอัลกอริทึมอื่น ๆ อย่าง MAA2C และ MADDPG ที่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 16.53 % และ 12.98 % ตามลำดับ โดยอัลกอริทึม MASAC สามารถลดได้กำลังไฟฟ้าสูญเสียได้ 8.29 % ซึ่งในกรณีศึกษานี้ยังพบอีกว่ามีอัลกอริทึมที่ให้ผลลัพธ์การปรับปรุงกำลังไฟฟ้าสูญเสียได้ไม่ดี นั่นคืออัลกอริทึม MAA3C และ MATD3 มีค่า -4.38 % และ -6.87 ตามลำดับ แสดงให้เห็นว่าอัลกอริทึม MAA3C และ MATD3 ไม่สามารถหาขนาด และตำแหน่งที่เหมาะสมในการลดกำลังไฟฟ้าสูญเสียได้ โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 2 พิจารณาร่วมกับสถานีอัดประจุยานยนต์แสดงดังรูปที่ 4.79


ในการวิเคราะห์ถึงขนาดของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 2 เป็นโหนดพื้นที่แบบธุรกิจ พิจารณาร่วมกับโหนดสถานีอัดประจุยานยนต์ไฟฟ้า พบว่าขนาดของฟักัดพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MAA2C ที่มีค่าใช้จ่ายอยู่ 55.91 ล้านบาท สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 16.53 % เมื่อเปรียบเทียบอัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่างอัลกอริทึม MATD3 ที่มีค่าใช้จ่ายอยู่ 57.27 ล้านบาท แต่ไม่

สามารถลดกำลังสูญเสียของระบบได้ ดังนั้น อัลกอริทึม MASAC จึงเด่นกว่า โดยมีต้นทุนอยู่ที่ 64.12 ล้านบาท ถึงแม้ว่าอัลกอริทึม MASAC จะลดกำลังไฟฟ้าสูญเสียได้น้อยกว่า MAA2C แต่ผลลัพธ์ที่ได้นั้นมีค่าแรงดันเฉลี่ยที่สูงกว่า


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 2 ด้วยโหลดแบบพื้นที่แบบธุรกิจ และพิจารณารวมกับโหลดสถานีอัดประจุยานยนต์ไฟฟ้า โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวันดังรูปที่ 4.80 ถึงรูปที่ 4.82 ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.83 ถึงรูปที่ 4.85




รูปที่ 4.78 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 2 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.79 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของกรณีศึกษาที่ 2 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.80 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.81 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.82 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC



รูปที่ 4.83 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



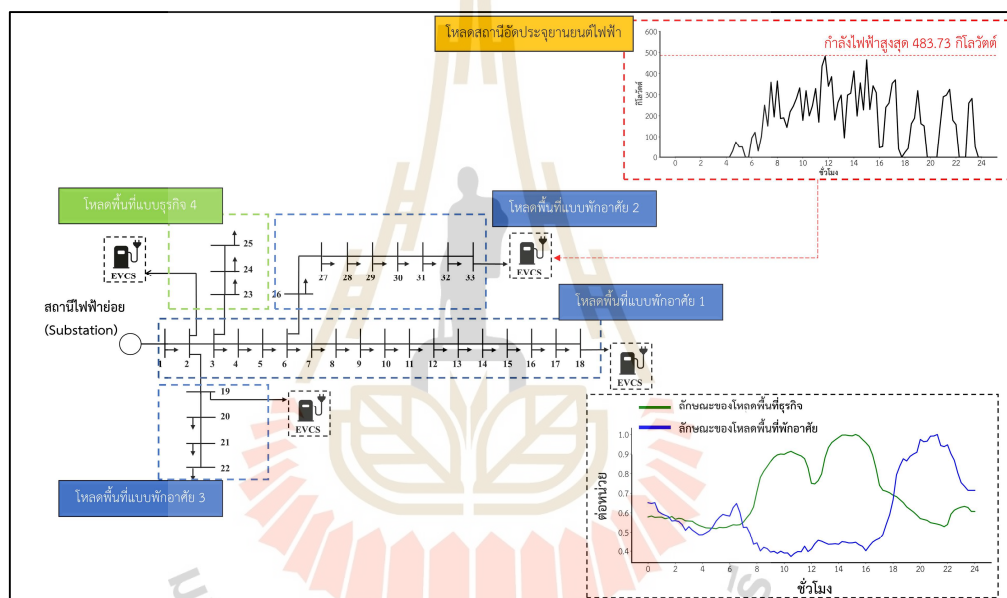
รูปที่ 4.84 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.85 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 2 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC

4.7.3 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 3


ในการดำเนินการตามกรณีศึกษาที่ 3 ได้จำลองโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจในระบบทดสอบ IEEE 33 โหนด โดยดำเนินการงานได้แสดงไว้ดังตารางที่ 3.6 โหนดตั้งแต่โหนดที่ 1 – 18, 19 – 22 และโหนดที่ 26 – 33 เป็นโหลดพื้นที่พักอาศัย โหนดที่ 23 - 25 เป็นโหนดที่เชื่อมต่อโหลดพื้นที่ธุรกิจ ซึ่งได้ติดตั้งโหลดสถานีอัดประจุไฟฟ้ายานยนต์ที่มีปริมาณการใช้โหลดสูงสุดอยู่ที่ 483.73 kW ที่โหนด 2, 18, 19 และโหนดที่ 33 โดยภาพรวมของระบบได้ดังรูปที่ 4.86



รูปที่ 4.86 กรณีศึกษาที่ 3 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า

ผลการวิเคราะห์ความสามารถอัลกอริทึมในการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 3 โดยใช้การเรียนรู้แบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึม เมื่อเปรียบเทียบกับรูปที่ 4.39 มีค่ารางวัลที่น้อยลงกว่ารางวัลในกรณีที่สามแบบไม่เชื่อมต่อโหลดสถานีอัดประจุไฟฟ้า เมื่อวิเคราะห์การลู่เข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MAA2C อยู่ที่ 82.92 ซึ่งมีค่าที่ใกล้เคียงกับอัลกอริทึม MADDPG เมื่อ

วิเคราะห์ถึงแนวโน้มความสามารถในการรับค่ารางวัลจากการฝึกอบรมของอัลกอริทึม MAA2C, MAA3C และ MASAC มีแนวโน้มการของค่ารางวัลที่เป็นแนวโน้มเดียวกัน แต่อัลกอริทึม MASAC นั้นจะมีค่าน้อยกว่าอัลกอริทึมอื่น ๆ ในช่วงแรก และจะเริ่มลู่เข้าในช่วงระหว่างรอบที่ 125 ถึง 150 เมื่อเปรียบเทียบกับอัลกอริทึม MADDPG และ MATD3 ที่มีความต่างกันเล็กน้อยในเรื่องของการปรับปรุงค่าตัวแปรภายในแบบจำลอง มีผลแนวโน้มค่ารางวัลที่ใกล้เคียงกันในกรณีศึกษา นี้ โดยภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.87



รูปที่ 4.87 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่แต่ละเอเจนต์ของกรณีศึกษาที่ 3 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า

เมื่อวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 3 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่เข้าที่ใกล้เคียงกัน ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.17 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย ค่าใช้จ่ายของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

ตารางที่ 4.17 ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ
แบตเตอรี่ของกรณีศึกษาที่ 3


พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย(MWh)	13.3844	9.6286	10.0839	8.9437	9.5402	12.0141
การลด กำลังไฟฟ้า สูญเสียที่ทำได้ (%)	-	39.01	32.73	49.65	40.30	11.41
แรงดันต่ำสุด (ต่อหน่วย)	0.9382	0.9694	0.9678	0.9688	0.9689	0.9761
แรงดันเฉลี่ย (ต่อหน่วย)	0.9591	0.9778	0.9777	0.9780	0.9779	0.9828
ตำแหน่งของ PV	-	33, 33	33, 33	33, 33	33, 33	31, 31
ขนาดของ PV (kW)	-	300, 143	300, 179	300, 300	163, 300	256, 151
ตำแหน่งของ WT	-	33, 33	33, 33	33, 33	33, 33	30, 30
ขนาดของ WT (kW)	-	300, 181	267, 51	300, 300	233, 300	264, 98
ตำแหน่งของ BESS	-	8, 3	2, 28	33, 33	33, 33	11, 6
ขนาดของ BESS (kW)	-	10, 465	10, 10	27, 48	1306, 109	530, 96
ค่าใช้จ่ายรวม (ล้านบาท)	-	52.24	40.72	64.44	65.72	43.82

หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบให้ดีขึ้น เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าอัลกอริทึม MASAC มีค่าแรงดันต่ำสุด 0.9761 ต่อหน่วย และแรงดันไฟฟ้าเฉลี่ย 0.9828 ต่อหน่วย โดยติดตั้งพลังงานแสงอาทิตย์ที่โนด 31 ทั้งสองตัวขนาดที่ 256 kW และ 151 kW พลังงานกังหันลมโนดที่ 30 ทั้งสองตัวขนาดที่ 264 kW และ 98 kW ระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 11 และโนดที่ 6 ขนาดที่ 530 kW และ 96 kW เมื่อเปรียบเทียบตำแหน่งที่ได้ และขนาดที่ได้ พบว่ามีตำแหน่งที่แตกต่างจากอัลกอริทึมอื่น ๆ มักจะติดตั้งที่ตำแหน่งโนดสุดท้ายที่มีแรงดันต่ำที่สุด คือโนดที่ 33 โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 3 แสดงดังรูปที่ 4.88


แม้ว่าอัลกอริทึม MASAC จะมีผลลัพธ์การปรับปรุงค่าแรงดันไฟฟ้าที่สูงที่สุด แต่เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียพบว่าการลดกำลังไฟฟ้าสูญเสียมีค่าต่ำกว่าอัลกอริทึมอื่น ๆ อย่าง MAA2C, MAA3C, MADDPG และ MATD3 ที่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 39.01 %, 32.73 %, 49.65 %, 40.30 % ตามลำดับ โดยอัลกอริทึม MASAC สามารถลดได้เพียง 11.41 % และอัลกอริทึมที่สามารถลดกำลังไฟฟ้าสูญเสียได้มากที่สุดคือ MADDPG โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 300 kW ที่โนดที่ 33 พลังงานกังหันลมสองตัวที่โนดที่ 33 ขนาด 300 kW และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 33 สองตัวมีขนาดที่ 27 kW และ 48 kW รองลงมาเป็นอัลกอริทึม MATD3 ติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 163 kW และ 300 kW ที่โนดที่ 33 และพลังงานกังหันลมสองตัวที่โนดที่ 33 มีขนาด 233 kW และ 300 kW และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 33 สองตัวมีขนาดที่ 1306 kW และ 109 kW โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 3 แสดงดังรูปที่ 4.89

เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 3 เป็นโหลดแบบผสมผสานระหว่างโหลดพื้นที่แบบพักอาศัยร่วมกับโหลดแบบพื้นที่แบบธุรกิจที่โนด 23, 24 และ 25 โดยติดตั้งโหลดสถานีอัดประจุยานยนต์ไฟฟ้า พบว่าขนาดของพิกัดพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MAA2C ที่มีค่าใช้จ่ายอยู่ 52.24 ล้านบาท สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 39.01 % เมื่อเปรียบเทียบอัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่าง อัลกอริทึม MATD3 ที่มีค่าใช้จ่ายอยู่ 40.72 ล้านบาท แต่สามารถลดกำลังไฟฟ้าสูญเสียได้เพียง 32.73 % นั่นเป็นเพราะขนาดของระบบกักเก็บพลังงานของอัลกอริทึม MAA3C มีค่าน้อยเกินไป จึงทำให้มีต้นทุนโดยรวมที่น้อยกว่า และความสามารถในการลดกำลังไฟฟ้าสูญเสียลดลงได้ไม่มาก


การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีที่ 3 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัยและพื้นที่แบบธุรกิจ และโหลดสถานีอัดประจุยานยนต์ไฟฟ้า โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวัน ดังรูปที่ 4.90 ถึงรูปที่ 4.92 ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.93 ถึงรูปที่ 4.95




รูปที่ 4.88 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 3 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.89 กำลังไฟฟ้าสูญเสียหลังปรับปรุงในแต่ละช่วงเวลาของภาคเรียนที่ 3 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.90 การเปรียบเทียบแรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C
ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.91 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.92 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC



รูปที่ 4.93 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C
ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.94 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.95 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 3 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC

4.7.4 ผลการหาตำแหน่ง และขนาดที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในกรณีศึกษาที่ 4


ในการดำเนินการตามกรณีศึกษาที่ 4 ได้จำลองโหลดแบบพื้นที่พักอาศัย และโหลดแบบพื้นที่ธุรกิจในระบบทดสอบ IEEE 33 โหนด โดยดำเนินการงานได้แสดงไว้ดังตารางที่ 3.6 ซึ่งได้ติดตั้งโหลดสถานีอัดประจุไฟฟ้ายานยนต์ที่มีปริมาณการใช้โหลดสูงสุดอยู่ที่ 483.73 kW ที่โหนด 2, 18, 19 และโหนดที่ 33 โดยภาพรวมของระบบได้ดังรูปที่ 4.96



รูปที่ 4.96 กรณีศึกษาที่ 4 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า

ผลการวิเคราะห์ความสามารถอัลกอริทึมในการจำลองการหาตำแหน่ง และขนาดพลังงานของกรณีศึกษาที่ 4 โดยใช้การเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าความสามารถในการรับค่ารางวัลในแต่ละอัลกอริทึม เมื่อเปรียบเทียบในรูปที่ 4.49 มีค่ารางวัลที่น้อยลงกว่ารางวัลในกรณีที่สี่แบบไม่เชื่อมต่อโหลดสถานีอัดประจุไฟฟ้า เมื่อวิเคราะห์การลู่เข้าที่จำนวนรอบ 125 ถึงรอบที่ 150 โดยค่ารางวัลสูงสุดเป็นของอัลกอริทึม MADDPG อยู่ที่ 81.63 ซึ่งมีค่าที่ใกล้เคียงกับอัลกอริทึม MAA2C เมื่อวิเคราะห์ถึงแนวโน้มความสามารถในการได้รับค่ารางวัลจากการฝึกอบรมของอัลกอริทึม MAA2C,

MAA3C และ MASAC มีแนวโน้มการของค่ารางวัลที่เป็นแนวโน้มเดียวกัน แต่อัลกอริทึม MAA3C นั้นจะมีค่าน้อยกว่า และใกล้เคียงกับอัลกอริทึม MATD3 โดยแต่ละอัลกอริทึมจะเริ่มลู่อู่เข้าในช่วงระหว่างรอบที่ 125 ถึง 150 โดยภาพรวมค่ารางวัลของแต่ละอัลกอริทึมได้แสดงดังรูปที่ 4.97



รูปที่ 4.97 ค่ารางวัลที่ได้จากการฝึกอบรมเพื่อหาตำแหน่งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่แต่ละเอเจนต์ของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า

เมื่อวิเคราะห์ค่ารางวัลที่เป็นตัวแทนของประสิทธิภาพของแต่ละอัลกอริทึม และผลลัพธ์ที่ได้จากการฝึกอบรมเพื่อหาตำแหน่ง และขนาดที่เหมาะสมในกรณีศึกษาที่ 4 ซึ่งมีประสิทธิภาพในการอบรมจะมีช่วงนี้การลู่อู่เข้าที่ใกล้เคียงกัน ผลลัพธ์ที่ได้ของการหาขนาด และตำแหน่งของอัลกอริทึมทั้งห้าแสดงดังตารางที่ 4.18 โดยแสดงให้เห็นถึงการปรับปรุงค่าแรงดัน การลดกำลังไฟฟ้าสูญเสีย ค่าใช้จ่ายของระบบพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

ตารางที่ 4.18 ตำแหน่งและขนาดของพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบ
แบตเตอรี่ของกรณีศึกษาที่ 4

พารามิเตอร์	ระบบ กรณีศึกษา	MAA2C	MAA3C	MADDPG	MATD3	MASAC
กำลังไฟฟ้า สูญเสีย (MWh)	14.5426	11.3474	14.1738	10.2467	13.0651	10.8809
การลด กำลังไฟฟ้า สูญเสียที่ทำได้ (%)	-	28.16	2.60	41.92	11.31	33.65
แรงดันต่ำสุด (ต่อหน่วย)	0.9424	0.9673	0.9694	0.9696	0.9691	0.9688
แรงดันเฉลี่ย (ต่อหน่วย)	0.9566	0.9776	0.9769	0.9775	0.9770	0.9773
ตำแหน่งของ PV	-	2, 33	33, 33	33, 33	33, 33	32, 32
ขนาดของ PV (kW)	-	300, 300	10, 10	300, 300	274, 250	282, 249
ตำแหน่งของ WT	-	33, 33	33, 33	33, 33	33, 33	32, 32
ขนาดของ WT (kW)	-	10, 10	300, 300	300, 300	37, 101	288, 282
ตำแหน่งของ BESS	-	2, 2	2, 2	33, 33	33, 33	4, 13
ขนาดของ BESS (kW)	-	10, 23	10, 10	25, 25	2000, 680	30, 168
ค่าใช้จ่ายรวม (ล้านบาท)	-	27.78	38.94	64.31	50.26	60.24


หลังจากการวิเคราะห์ความสามารถในการปรับปรุงแรงดันในระบบให้ดีขึ้น เมื่อเปรียบเทียบกับอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC พบว่าอัลกอริทึม MAA3C มีค่าแรงดันต่ำสุด 0.9696 ต่อหน่วย และอัลกอริทึม MAA2C มีค่าแรงดันไฟฟ้าเฉลี่ย 0.9776 ต่อหน่วย โดยอัลกอริทึม MAA3C ติดตั้งพลังงานแสงอาทิตย์ที่โนด 2 และโนดที่ 33 มีขนาด 300 kW และ 300 kW พลังงานกังหันลมโนดที่ 33 ทั้งสองตัวขนาดที่ 10 kW และ 10 kW ระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 2 ทั้งสองตัวขนาดที่ 10 kW และ 23 kW โดยแรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 แสดงดังรูปที่ 4.98

เมื่อวิเคราะห์อัลกอริทึม MAA3C ที่มีผลลัพธ์การปรับปรุงค่าแรงดันไฟฟ้าที่ดีที่สุด แต่เมื่อวิเคราะห์กำลังไฟฟ้าสูญเสียพบว่าการลดกำลังไฟฟ้าสูญเสียมีค่าเปอร์เซ็นต์ต่ำกว่าอัลกอริทึมอื่น ๆ อย่าง MAA2C, MADDPG, MATD3 และ MASAC ที่สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 28.16 %, 41.92 %, 11.31 %, 33.65 % ตามลำดับ โดยอัลกอริทึม MAA3C สามารถลดได้เพียง 2.60 % เนื่องจากขนาดของพลังงานแสงอาทิตย์ที่น้อยเกินไป และอัลกอริทึมที่สามารถลดกำลังไฟฟ้าสูญเสียได้มากที่สุดคือ MADDPG โดยติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 300 kW ที่โนดที่ 33 พลังงานกังหันลมสองตัวที่โนดที่ 33 ขนาด 300 kW และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 33 สองตัวมีขนาดที่ 25 kW และ 25 kW รองลงมาเป็นอัลกอริทึม MASAC ติดตั้งพลังงานเซลล์แสงอาทิตย์สองตัวขนาด 282 kW และ 249 kW ที่โนดที่ 33 และพลังงานกังหันลมสองตัวที่โนดที่ 33 ขนาด 288 kW และ 282 kW และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่โนด 33 สองตัวมีขนาดที่ 30 kW และ 168 kW โดยกำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 แสดงดังรูปที่ 4.99


เมื่อวิเคราะห์ถึงขนาดของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่สัมพันธ์กับค่าใช้จ่ายในการติดตั้ง ในกรณีศึกษาที่ 4 เป็นโหลดแบบผสมผสานระหว่างโหลดพื้นที่แบบพักอาศัยร่วมกับโหลดแบบพื้นที่แบบธุรกิจที่โนด 23, 24, 25 และโนดที่ 26, 27, 28, 29, 30, 31, 32, 33 โดยเพิ่มเติมการติดตั้งโหลดสถานีอัดประจุยานยนต์ไฟฟ้า พบว่าขนาดของพิกัดพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ที่ลดกำลังไฟฟ้าสูญเสียได้ดี และค่าใช้จ่ายต่ำที่สุด คืออัลกอริทึม MAA2C ที่มีค่าใช้จ่ายอยู่ 27.78 ล้านบาท สามารถลดกำลังไฟฟ้าสูญเสียได้ถึง 28.16 % เมื่อเปรียบเทียบอัลกอริทึมที่มีค่าใช้จ่ายที่ใกล้เคียงอย่าง อัลกอริทึม MAA3C ที่มีค่าใช้จ่ายอยู่ 38.94 ล้านบาท แต่สามารถลดกำลังไฟฟ้าสูญเสียได้เพียง 2.60% เนื่องจากพลังงานแสงอาทิตย์ที่น้อยเกินไป

การจำลองผลโดยรวมของแรงดันไฟฟ้า กำลังไฟฟ้าสูญเสียในกรณีศึกษาที่ 4 ด้วยโหลดแบบผสมผสานระหว่างพื้นที่แบบพักอาศัยและพื้นที่แบบธุรกิจ และโหลดสถานีอัดประจุยานยนต์


ไฟฟ้า โดยดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่แรงดันต่ำที่สุดในหนึ่งวัน ดังรูปที่ 4.100 ถึงรูปที่ 4.102 ภาพรวมของแรงดันไฟฟ้าหลังปรับปรุงของแต่ละโหนดโดยแสดงจุดที่ กำลังไฟฟ้าสูญเสียมากที่สุดดังรูปที่ 4.103 ถึงรูปที่ 4.105




รูปที่ 4.98 แรงดันไฟฟ้าเฉลี่ยหลังปรับปรุงของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.99 กำลังไฟฟ้าสูญเสียหลังปรับปรุงของกรณีศึกษาที่ 4 ร่วมกับสถานีอัดประจุยานยนต์ไฟฟ้า ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC




รูปที่ 4.100 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C ข) ปรับปรุงด้วยอัลกอริทึม MAA3C




รูปที่ 4.101 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3




รูปที่ 4.102 แรงดันไฟฟ้าแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC



รูปที่ 4.103 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MAA2C
 ข) ปรับปรุงด้วยอัลกอริทึม MAA3C



รูปที่ 4.104 กำลังไฟฟ้าสูญเสียแต่ละโหนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้า ก) ปรับปรุงด้วยอัลกอริทึม MADDPG ข) ปรับปรุงด้วยอัลกอริทึม MATD3



รูปที่ 4.105 กำลังไฟฟ้าสูญเสียแต่ละโนดก่อน และหลังปรับปรุงของกรณีศึกษาที่ 4 หลังติดตั้งสถานีอัดประจุยานยนต์ไฟฟ้าด้วยอัลกอริทึม MASAC

4.8 สรุป

ในบทที่ 4 นี้ได้แสดงถึงการวิเคราะห์หาค่าพารามิเตอร์ที่เหมาะสมของอัลกอริทึมด้วยการทดสอบในฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว เพื่อตรวจสอบกระบวนการทำงานของการเรียนรู้แบบเสริมกำลังเชิงลึกหลายเอเจนต์ และหาพารามิเตอร์ที่เหมาะสมก่อนประยุกต์ใช้ในระบบไมโครกริด โดยใช้อัลกอริทึม MAA2C และ MADDPG เป็นต้นแบบในการหาพารามิเตอร์ที่เหมาะสม โดยพารามิเตอร์ที่เกี่ยวข้องคือ แลมด้า (Lambda) และตัวแปร แกรมม่า (Gamma) ที่ส่งผลต่อประสิทธิภาพของแบบจำลองในการฝึกอบรมเพื่อให้ได้รับค่ารางวัลที่ดี โดยค่าแลมด้าจะปรับใช้ในอัลกอริทึม MAA2C และ MAA3C ส่วนค่าแกรมม่าจะปรับใช้กับอัลกอริทึม MADDPG, MATD3 และ MASAC

ในการจำลองของระบบไมโครกริดที่ใช้เป็นระบบทดสอบ IEEE 33 โหนดนั้นจะถูกจำลองผ่านไลบรารี Pandapower ซึ่งไมโครกริดแบ่งออกเป็น 4 กรณีศึกษาได้แก่ กรณีที่ 1 ไมโครกริดแบบโหลดพื้นที่พักอาศัย กรณีที่ 2 ไมโครกริดแบบพื้นที่ธุรกิจ กรณีที่ 3 และ 4 เป็นแบบผสมผสานระหว่างโหลดแบบพื้นที่แบบพักอาศัย และพื้นที่แบบธุรกิจ โดยผลการจำลองแสดงให้เห็นถึงความแตกต่าง ของแรงดันที่ลดลงของระบบ และกำลังไฟฟ้าสูญเสียในแต่ละช่วงเวลา โหลดพื้นที่แบบพักอาศัยจะใช้พลังงานไฟฟ้ามากในช่วงกลางคืน และพื้นที่ธุรกิจก็จะใช้พลังงานมากในตอนกลางวัน เมื่อผสมผสานโหลดก็จะทำให้มีการใช้พลังงานมากขึ้นในช่วงกลางวัน และกลางคืน

การปรับปรุงระบบไมโครกริดที่ได้รับผลกระทบจากโหลดแบบพื้นที่พักอาศัย พื้นที่แบบธุรกิจ และโหลดสถานีอัดประจุยานยนต์ไฟฟ้า โดยในวิทยานิพนธ์เล่มนี้ได้แบ่งผลการจำลองออกเป็น 2 หัวข้อ คือ ผลการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียน ผลการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยพิจารณาโหลดสถานีอัดประจุยานยนต์ไฟฟ้าที่โหนด 2, 18, 19 และโหนดที่ 33

ผลการดำเนินการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียนในกรณีศึกษาทั้ง 4 กรณีด้วยโหลดพื้นที่แบบพักอาศัย พื้นที่แบบธุรกิจ และแบบผสมผสาน ด้วยเทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ทั้งหมดหาอัลกอริทึม ได้แก่ MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยใช้พารามิเตอร์ที่พิสูจน์จากการประยุกต์ใช้ฟังก์ชันทดสอบที่กล่าวมา ซึ่งการลู่เข้าหาคำตอบของอัลกอริทึม หรือการได้รับค่ารางวัลที่สูง แต่ละอัลกอริทึมจะมีการลู่เข้าที่รอบใกล้เคียงกันระหว่าง 125 ถึง 150 รอบ โดยอัลกอริทึมที่ให้ผลลัพธ์ และการลู่เข้าของรางวัลที่ดีคืออัลกอริทึม MADDPG ซึ่งเมื่อวิเคราะห์ตำแหน่ง และขนาดที่ได้พบว่าอัลกอริทึมนี้ไม่ได้มีการเปลี่ยนแปลงทั้ง

ตำแหน่ง และขนาด จึงสรุปได้ว่าอัลกอริทึม MADDPG มีการเรียนรู้ที่ผิดพลาดทำให้แสดงผลการหาขนาด แหล่งตำแหน่งที่ผิดพลาดออกไป และอัลกอริทึม MAA2C จึงเป็นอัลกอริทึมที่มีความเชื่อมั่นที่มีค่ารางวัลที่ดี ในเรื่องของผลของการปรับปรุงแรงดันไฟฟ้า ผลของการลดกำลังไฟฟ้าสูญเสีย และค่าใช้จ่ายในการลงทุนสำหรับกรณีศึกษาในครั้งนี้

ในการดำเนินการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยพิจารณาโหลดสถานีอัดประจุยานยนต์ไฟฟ้าในกรณีศึกษาทั้ง 4 กรณีด้วย โหลดพื้นที่แบบพักอาศัย พื้นที่แบบธุรกิจ และแบบผสมผสาน ด้วยเทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยใช้พารามิเตอร์ที่พิสูจน์จากการประยุกต์ใช้ฟังก์ชันทดสอบที่กล่าวมา ซึ่งการลู่เข้าหาคำตอบของอัลกอริทึม หรือการได้รับค่ารางวัลที่สูง แต่ละอัลกอริทึมจะมีการลู่เข้าที่รอบใกล้เคียงกันระหว่าง 125 ถึง 150 รอบ โดยอัลกอริทึมที่ให้ผลลัพธ์ และการลู่เข้าของรางวัลที่ดีคืออัลกอริทึม MADDPG ซึ่งเมื่อวิเคราะห์ตำแหน่ง และขนาดที่ได้พบว่าอัลกอริทึมนี้ยังคงบ่งพร่องในการเรียนรู้ ซึ่งอัลกอริทึมในกรณีศึกษาที่สามารถปรับปรุงแรงดันไฟฟ้า ปรับปรุงกำลังไฟฟ้าสูญเสียได้ดี และมีความเชื่อมั่น นั่นคืออัลกอริทึม MAA2C และ MASAC ซึ่งทั้งสองอัลกอริทึมนี้สามารถแสดงประสิทธิภาพได้ดีในรอบการฝึกอบรม 150 รอบ และการปรับแต่งพารามิเตอร์ที่มีพื้นฐานดังกล่าว



บทที่ 5

สรุปและข้อเสนอแนะ

5.1 บทสรุป

การศึกษาวิจัยในวิทยานิพนธ์นี้มุ่งเน้นการศึกษาการจัดการพลังงานที่เหมาะสมในไมโครกริด โดยใช้เทคนิคการเรียนรู้เชิงลึกแบบหลายเอเจนต์ วิธีการที่ใช้ในการจัดการพลังงานของวิทยานิพนธ์นี้ คือ การหาขนาด และตำแหน่งที่เหมาะสมของพลังงานแสงอาทิตย์ และพลังงานของกังหันลมร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ มีจุดประสงค์ในการปรับปรุงแรงดันไฟฟ้า ลดกำลังไฟฟ้าสูญเสีย และคำนึงถึงต้นทุนที่เหมาะสม ด้วยเทคนิคการเรียนรู้เชิงลึกเสริมกำลังแบบหลายเอเจนต์มีทั้งหมด 5 อัลกอริทึมได้แก่ MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยเครื่องมือทางวิจัยระบบไฟฟ้า และการเรียนรู้เชิงลึกเสริมกำลังแบบหลายเอเจนต์มีพื้นฐานอยู่บนภาษา Python และมีไลบรารีหลัก ๆ คือ Rllib, Gymnasium ซึ่งการดำเนินการก่อนประยุกต์ใช้ในระบบไมโครกริด จำเป็นต้องมีการตรวจสอบความถูกต้องของกระบวนการเขียนโปรแกรมโดยการทดสอบในฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว เพื่อตรวจสอบกระบวนการทำงานของการเรียนรู้เชิงลึกเสริมกำลังแบบหลายเอเจนต์ และหาพารามิเตอร์ที่เหมาะสมก่อนประยุกต์ใช้ในระบบไมโครกริด โดยใช้อัลกอริทึม MAA2C และ MADDPG เป็นต้นแบบในการหาพารามิเตอร์ที่เหมาะสม โดยพารามิเตอร์ที่เกี่ยวข้องคือ แลมด้า (Lambda) และตัวแปร แกรมม่า (Gamma) ที่ส่งผลต่อประสิทธิภาพของแบบจำลองในการฝึกอบรมเพื่อให้ได้รับค่ารางวัลที่ดี โดยอัลกอริทึม MAA2C ได้ค่าแลมด้าที่เหมาะสมจากการทดสอบฟังก์ชัน คือ 1.00 และอัลกอริทึม MADDPG ได้ค่าแกรมม่าที่เหมาะสมอยู่ที่ 0.01 เช่นกัน โดยค่าแลมด้าจะปรับใช้ในอัลกอริทึม MAA2C และ MAA3C ส่วนค่าแกรมม่าจะปรับใช้กับอัลกอริทึม MADDPG, MATD3 และ MASAC

ในการนำอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC ทดสอบในฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว โดยจุดประสงค์ของแต่ละฟังก์ชันคือการหาผลลัพธ์ของฟังก์ชันให้เข้าใกล้ศูนย์มากที่สุด โดยการทดสอบฟังก์ชัน F1 และ F2 เป็นฟังก์ชันฐานนิยมแบบเดี่ยว จะกำหนดพารามิเตอร์ให้มีความเหมาะสมแก่การเปรียบเทียบประสิทธิภาพกัน ผลลัพธ์ที่ได้

พบว่าอัลกอริทึม MADDPG มีค่ารางวัลที่มากที่สุดเมื่อเปรียบเทียบกับอัลกอริทึมอื่น ๆ โดยสามารถหาผลลัพธ์ของสมการที่มีจุดประสงค์ให้เข้าใกล้ศูนย์ของ F1 และ F2 โดยมีค่าอยู่ที่ 15.91 และ 122.0

อัลกอริทึมรองลงมาจาก MADDPG คืออัลกอริทึม MASAC ที่มีค่าฟังก์ชัน F1 และ F2 อยู่ที่ 282.95 และ 592.05 เมื่อวิเคราะห์อัลกอริทึมอื่น ๆ อย่าง MAA2C MAA3C และ MATD3 พบว่ามีการให้คำตอบที่ไม่ใกล้เคียงคำตอบของสมการ ในส่วนของการทดสอบในฟังก์ชันฐานนิยมหลายตัวอย่าง F3 และ F4 ที่มีจุดประสงค์ของแต่ละฟังก์ชันคือการหาผลลัพธ์ของฟังก์ชันให้เข้าใกล้ศูนย์เช่นกัน ผลลัพธ์ที่ได้พบว่าอัลกอริทึม MADDPG และ MASAC มีค่ารางวัลที่ใกล้เคียงกันอย่างมาก โดย MASAC มีค่ามากที่สุดอยู่ที่ 126.75 เมื่อวิเคราะห์ถึงผลลัพธ์ของฟังก์ชัน F3 และ F4 ได้ผลลัพธ์ 2.46 และ 10.80 ตามลำดับ เมื่อเปรียบเทียบกับ MADDPG ที่มีค่าผลลัพธ์ F3 และ F4 อยู่ที่ 0.52 และ 2.34 พบว่ามีค่าที่ใกล้เคียงศูนย์มากกว่าอัลกอริทึม MASAC เมื่อวิเคราะห์อัลกอริทึมอื่น ๆ อย่าง MAA2C MAA3C และ MATD3 พบว่ามีการให้คำตอบที่ไม่ใกล้เคียงคำตอบของสมการเมื่อเปรียบเทียบกับอัลกอริทึม MADDPG และ MASAC จากผลลัพธ์ของการทดสอบฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมแบบหลายตัว พบว่าอัลกอริทึมที่แสดงประสิทธิภาพดีในการหาคำตอบสมการได้ดี คือ อัลกอริทึม MADDPG ที่ให้คำตอบสู่ศูนย์ และมีค่ารางวัลที่ได้จากการฝึกอบรมสูง รองลงมาที่ใกล้เคียงกันคืออัลกอริทึม MASAC

จากการทดสอบฟังก์ชันทดสอบฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว เมื่อวิเคราะห์อัลกอริทึมที่มีความโดดเด่นอย่าง MADDPG และ MASAC เปรียบเทียบกับผลลัพธ์ในไมโครกริดแต่ละกรณีศึกษา ด้วยการดำเนินการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียนในกรณีศึกษาทั้ง 4 กรณีด้วยโหลดพื้นที่แบบพักอาศัย พื้นที่แบบธุรกิจ และแบบผสมผสาน โดยมีผลลัพธ์ของอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยใช้พารามิเตอร์เช่นเดียวกับฟังก์ชันทดสอบที่กล่าวมา ซึ่งการลู่เข้าหาคำตอบของอัลกอริทึม หรือการได้รับค่ารางวัลที่สูง ในแต่ละอัลกอริทึมจะมีการลู่เข้าที่รอบใกล้เคียงกันระหว่าง 125 ถึง 150 รอบ โดยอัลกอริทึมที่ให้ผลลัพธ์ และการลู่เข้าของรางวัลที่ดีคืออัลกอริทึม MADDPG ซึ่งมีความโดดเด่นเช่นเดียวกับฟังก์ชันทดสอบ ถึงแม้จะมีค่ารางวัลที่ดี แต่เมื่อวิเคราะห์ตำแหน่ง และขนาดที่ได้พบว่าอัลกอริทึมนี้ไม่ได้มีการเปลี่ยนแปลงทั้งตำแหน่ง และขนาดในทุกกรณี จึงสรุปได้ว่าอัลกอริทึม MADDPG มีการเรียนรู้ที่ผิดพลาดทำให้แสดงผลการหาขนาด และ ตำแหน่งที่ผิดพลาดออกไป อันเนื่องมาจากการปรับพารามิเตอร์อาจไม่เหมาะสมกับงานวิจัยไมโครกริด ดังนั้น อัลกอริทึม MAA2C จึงเป็นอัลกอริทึมที่มีความเหมาะสม และความเชื่อมั่นที่มีค่ารางวัลที่ดี ในเรื่องของผลของการปรับปรุงแรงดันไฟฟ้า ผลของการลดกำลังไฟฟ้าสูญเสีย และ ค่าใช้จ่ายในการลงทุน สำหรับกรณีศึกษาในครั้งนี้

ในการดำเนินการจำลองหาขนาด และตำแหน่งติดตั้งพลังงานหมุนเวียน ร่วมกับระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยพิจารณาโหลดสถานีอัดประจุยานยนต์ไฟฟ้าในกรณีศึกษาทั้ง 4 กรณีด้วย โหลดพื้นที่แบบพักอาศัย พื้นที่แบบธุรกิจ และแบบผสมผสาน ด้วยเทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ด้วยอัลกอริทึม MAA2C, MAA3C, MADDPG, MATD3 และ MASAC โดยใช้พารามิเตอร์ที่พิสูจน์จากการประยุกต์ใช้ฟังก์ชันทดสอบที่กล่าวมา ซึ่งการลู่เข้าหาคำตอบของอัลกอริทึม หรือการได้รับรางวัลที่สูง แต่ละอัลกอริทึมจะมีการลู่เข้าที่รอบใกล้เคียงกันระหว่าง 125 ถึง 150 รอบ โดยอัลกอริทึมที่ให้ผลลัพธ์ และการลู่เข้าของรางวัลที่ดีคืออัลกอริทึม MADDPG แต่ผลลัพธ์ที่ได้กลับไม่มีการเปลี่ยนแปลงนั้นอาจเป็นการปรับพารามิเตอร์ที่ยังไม่เหมาะสมกับแบบจำลองนี้ แม้แต่อัลกอริทึม MAA3C และ MATD3 ที่มีแนวโน้มของประสิทธิภาพที่ดีกว่า MADDPG ซึ่งอัลกอริทึมในกรณีศึกษาที่สามารถปรับปรุงแรงดันไฟฟ้า ปรับปรุงกำลังไฟฟ้าสูญเสียได้ดี และมีความเชื่อมั่น นั่นคืออัลกอริทึม MAA2C และ MASAC ซึ่งทั้งสองอัลกอริทึมนี้สามารถแสดงประสิทธิภาพได้ดีในรอบการฝึกอบรม 150 รอบ

5.2 ข้อเสนอแนะ

5.2.1 ควรศึกษาผลการจำลองเพิ่มเติม โดยการเพิ่มรอบจำนวนการวนซ้ำ และหาพารามิเตอร์การฝึกอบรมที่เหมาะสมต่อการหาค่าที่เหมาะสมในไมโครกริด เนื่องจากทรัพยากรคอมพิวเตอร์ที่มีจำกัดจึงสามารถกำหนดรอบการจำลองได้น้อย

5.2.2 ควรศึกษาระบบไมโครกริดแบบแยกออกจากกริดเพิ่มเติม เพื่อศึกษาผลการหาค่าที่เหมาะสมของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่

5.2.3 การใช้เทคนิคการเรียนรู้เชิงลึกแบบเสริมกำลังหลายเอเจนต์ยังสามารถจัดการตารางการจ่ายพลังงานของระบบกักเก็บพลังงานได้ เพื่อการลดกำลังไฟฟ้าสูญเสียที่ไม่พึงประสงค์ในระบบได้อย่างแม่นยำ

รายการอ้างอิง

- การไฟฟ้าส่วนภูมิภาค (กฟภ.). (2566). รายงานลักษณะการใช้ไฟฟ้าของจังหวัดนครราชสีมา ปี 2566. [ออนไลน์] สืบค้นได้จาก: <http://peaoc.pea.co.th/loadprofile/>
- ชาคริต เลิศวิทยาประสิทธิ์ (2562). ระบบจัดการพลังงานแสงอาทิตย์สำหรับการใช้งานแบบแยกเดี่ยว: การวิเคราะห์กลยุทธ์การจัดการพลังงานภายใต้รูปแบบของความเข้มแสงที่แตกต่างกัน. วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมเคมี มหาวิทยาลัยจุฬาลงกรณ์. หน้าที่ 6.
- ณัฐพลชาติสุข (2561). การศึกษาผลกระทบของยานพาหนะไฟฟ้าแบบอัดประจุไฟฟ้าเร็วต่อระบบจำหน่ายไฟฟ้า กรณีศึกษาอำเภอเมือง จังหวัดนครราชสีมา. วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี. หน้าที่ 20-23.
- ณัฐวัฒน์ เอกธรรมนิรัตน์ (2563). การจัดการวัตถุดิบคลังของร้านอาหาร โดยใช้ Proximal Policy Optimization. วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาศาสตร์ สถาบันบัณฑิตพัฒนบริหารศาสตร์. หน้าที่ 5.
- ธีระพงษ์ บุญรักษา (2562). การวางแผนเชิงกลยุทธ์ของสถานีประจุไฟฟ้าเร็วสำหรับระบบรถโนดไฟฟ้าขนส่งสาธารณะ: กรณีศึกษา อำเภอเมือง จังหวัดนครราชสีมา. วิทยานิพนธ์ปริญญาวิศวกรรมศาสตร์ดุษฎีบัณฑิต สาขาวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี. หน้าที่ 70-77.
- สำนักงานนโยบายและแผนพลังงาน (2566). คู่มือโครงการจัดทำแผนการพัฒนาสถานีประจุแบตเตอรี่สำหรับยานยนต์ไฟฟ้า เพื่อรองรับเป้าหมายการส่งเสริมยานยนต์ไฟฟ้าของประเทศ. [ออนไลน์]. สืบค้นได้จาก : https://www.eppo.go.th/images/energy-conservation/EV/EV_Manual.pdf
- PEA Volta. (2023). ธุรกิจลงทุนสถานีอัดประจุไฟฟ้า. [ออนไลน์]. แหล่งข้อมูลจาก : <https://peavoltaev.pea.co.th/product-dc-wallbox>

- Alabdullah, M.H., and Abido, M.A. (2022). Microgrid Energy Management using Deep Q-Network Reinforcement Learning. **Alexandria Engineering Journal**. Vol. 61, No. 11, pp. 9069-9078.
- Alibabaei, K., Gaspar, P. D., Assunção, E., Alirezazadeh, S., Lima, T. M., Soares, V. N. G. J., and Caldeira, J. M. L. P. (2022). Comparison of On-Policy Deep Reinforcement Learning A2C with Off-Policy DQN in Irrigation Optimization: A Case Study at a Site in Portugal, **Computers**. Vol. 11, No. 7, pp. 104.
- Alonso, M., Amaris, H., Martin, D., and Escalera L., d., A. (2023). Proximal Policy Optimization for Energy Management of Electric Vehicles and PV Storage Units. **Energy**. pp. 5689
- Atia, R., and Yamada, N. (2016). Sizing and Analysis of Renewable Energy and Battery Systems in Residential Microgrids. **IEEE Transactions on Smart Grid**, Vol. 7, No. 3, pp. 1204-1213
- Baran, M. E., and Wu, F. F. (1989). Network Reconfiguration in Distribution Systems for Loss Reduction and Load alancing. **IEEE Transactions on Power Delivery**, Vol. 4, No. 2, pp. 1401-1407
- Basit, M.A., Dilshad, S., Badar, R., and Sami ur Rehman, S.M. (2020). Limitations, challenges, and solution approaches in grid-connected renewable energy systems. **International Journal of Energy Research**, Vol. 44, No. 6, pp. 4132-4162.
- Caisheng Wang (2006), Modeling and Control of Hybrid Wind/Photovoltaic/Fuel cell distributed generation systems. **Department of Electrical and Computer Engineering, Montana State University**.
- Castillo, V. Z., de Boer, H. S., Muñoz, R. M., Gernaat, D. E. H. J., Benders, R., and Van Vuuren, D. (2022). Future Global Electricity Demand Load Curves. **Energy**, Vol. 258, pp. 124741.
- Silver, D., Lever, G., Heess, N., Degris, T., Wierstra, D., and Riedmiller, M. (2014) Deterministic Policy Gradient Algorithms. Proceedings of the 31st International Conference on Machine Learning. Vol. 32, pp. 387-395.

- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lilicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., and Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. **Nature**, Vol. 529, pp. 484-489.
- Deb, S., Tammi, K., Kalita, K., and Mahanta, P. (2018). Impact of Electric Vehicle Charging Station Load on Distribution Network. **Energies**, Vol. 11, No. 1, pp. 178.
- Deeum, S., Charoenchan, T., Janjamraj, N., Romphochai, S., Baum, S., Ohgaki, H., Mithulanathan, N., and Bhumkittipich, K. (2023). Optimal Placement of Electric Vehicle Charging Stations in an Active Distribution Grid with Photovoltaic and Battery Energy Storage System Integration. **Energies**, Vol. 16, pp. 7628.
- Dolatabadi, S. H., Ghorbanian, M., Siano, P., and Hatziargyriou, N.D. (2021). An Enhanced IEEE 33 Node Benchmark Test System for Distribution System Studies. **IEEE Transactions on Power Systems**. Vol. 36, No. 3, pp. 2565-2572.
- Dubey, A., and Santoso, S. (2015). Electric Vehicle Charging on Residential Distribution Systems: Impacts and Mitigations. **IEEE Access**, Vol. 3, pp. 1871-189.
- Ebeed, M., and Abdel Aleem, S.H.E. (2021). Chapter 1 - Overview of Uncertainties in Modern Power Systems: Uncertainty Models and Methods. *Uncertainties in Modern Power Systems*. **Academic Press**. pp. 1-34
- Electric Vehicle Database. (2023). **Tesla Model Y Long Range Dual Motor**. [Online]. Available: <https://ev-database.org/car/1619/Tesla-Model-Y-Long-Range-Dual-Motor#battery>.

- Elifura Reuben Mmary (2017). Performance Enhancement of Power Distribution Network Integration with Hybrid Renewable Energy Source and Battery Energy Storage. **Degree of Master Engineering in Electrical Engineering. Suranaree University of Technology.** pp 71.
- Elkadeem, M. R., Abd Elaziz, M., Ullah, Z., Wang, S., and Sharshir, S. W. (2019). Optimal Planning of Renewable Energy-Integrated Distribution System Considering Uncertainties. **IEEE Access**, Vol. 7, pp. 164887-164907
- Fateh, D., Eldoromi, M., and Birjandi, A. A. M. (2022). Uncertainty Modeling of Renewable Energy Sources in Scheduling and Operation of Virtual Power Plants. **Elsevier.** pp. 193-208.
- FT ENERGY. (2023). **Low Speed Wind Turbine.** [Online] Available: <http://www.ft-energy.co.th/product-A-04.html>
- Fujimoto, S., Van Hoof, H., and Meger, D. (2018). Addressing Function Approximation Error in Actor-Critic Methods. **CoRR**, Vol. abs/1802.09477
- Garrido, L., Nishtala, R., and Carpenter, P. (2019). Continuous-Action Reinforcement Learning for Memory Allocation in Virtualized Servers. **Springer International Publishing.** pp. 13-24.
- Gilleran, M. Bonnema, E., Woods, J., Mishra, P., Doebber, I., Hunter, C., Mitchell, M., and Mann, M. (2021) Impact of Electric Vehicle Charging on the Power Demand of Retail Buildings. **Advances in Applied Energy**, Vol. 4, p. 100062.
- Guo, C., Wang, X., Zheng, Y., and Zhang, F. (2021). Optimal Energy Management of Multi-microgrids Connected to Distribution System Based on Deep Reinforcement Learning. **International Journal of Electrical Power & Energy Systems.** Vol. 131, p. 107048.
- Hassan, A.S., Sun, Y., and Wang, Z. (2022). Multi-objective for optimal placement and sizing DG units in reducing loss of power and enhancing voltage profile using BPSO-SLFA. **Energy Reports**, Vol. 6, pp. 1581-1589.

- Haarnoja, T., Zhou, A., Abbeel, P., and Levine, S., (2018). Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor. **arXiv**.
- Hesaroor, K. and Das, D. (2019). Optimal Sizing of Energy Storage System in Islanded Microgrid using Incremental Cost Approach. **Journal of Energy Storage**, Vol. 24, pp. 100768.
- Hu, C., Cai, Z., and Zhang, Y. (2021). A multi-agent deep reinforcement learning approach for temporally coordinated demand response in microgrids. **CSEE Journal of Power and Energy Systems**.
- Jang, H. C., Huang, Y. C. and Chiu, H. A. (2020). A Study on the Effectiveness of A2C and A3C Reinforcement Learning in Parking Space Search in Urban Areas Problem. 2020 International Conference on Information and Communication Technology Convergence (ICTC). pp. 567-571.
- Junhuathon, N. and Marungsri, B. (2018). Optimal Location and Size for the Battery Energy Storage System Installation in a Microgrid. Proceedings of the 2018 2nd International Conference on Electrical Engineering and Automation (ICEEA 2018). pp. 86-89.
- Koo, J., Mendiratta, V., Rahman, M. R., and Walid, A. (2019). Deep Reinforcement Learning for Network Slicing with Heterogeneous Resource Requirements and Time Varying Traffic Dynamics. 15th International Conference on Network and Service Management (CNSM), Halifax, NS, Canada, 2019, pp. 1-5.
- Kumar, J., and Majid, M.A. (2020). Renewable Energy for Sustainable Development in India: Current Status, Future Prospects, Challenges, Employment, and Investment Opportunities. **Energy Sustain. Soc** 10.
- Lee, Y. R., Kang, H. J., and Kim, M. K. (2022). Optimal Operation Approach with Combined BESS Sizing and PV Generation in Microgrid. **IEEE Access**, Vol. 10, pp. 27453-27466.
- Li, Y. (2018). Deep Reinforcement Learning. **CoRR**. Vol. abs/1810.06339

- Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., and Wierstra, D. (2019). Continuous control with deep reinforcement learning. **arXiv**.
- Mnih, V., Puigdomènech Badia, A., Mirza, M., Graves, A., Lillicrap, T. P., Harley, T., Silver, D., and K. Kavukcuoglu, K. (2016). Asynchronous Methods for Deep Reinforcement Learning. **CoRR**, Vol. abs/1602.01783
- Muratori, M. Impact of Uncoordinated Plug-in Electric Vehicle Charging on Residential Power Demand. (2018). **Nature Energy 3**, pp.193–201
- Paczolay, G. and Harmati, I. (2022). A New Advantage Actor-Critic Algorithm for Multi-Agent Environments. 23rd International Symposium on Measurement and Control in Robotics (ISMCR), Budapest, Hungary, 2020, pp. 1-6
- Pitra, M. G., and Musti, S., K.S., (2021). Duck Curve with Renewable Energies and Storage Technologies. 13th International Conference on Computational Intelligence and Communication Networks (CICN), Lima, Peru, 2021, pp. 66-71
- Prakash, K., Ali, M., Siddique, M. N. I., Chand, A. A., Kumar, N. M., Dong, D., and Pota, H. R. (2022). A Review of Battery Energy Storage Systems for Ancillary Services in Distribution Grids: Status, Challenges and Future Directions," **Frontiers in Energy Research**, Vol. 10, pp. 1-17.
- Rashedi, A., Khanam, T., and Jonkman, M. (2020). On Reduced Consumption of Fossil Fuels in 2020 and Its Consequences in Global Environment and Exergy Demand. **Energies**, Vol. 13, No. 22
- Saadat, H. (1999). Power System Analysis. **The McGraw-Hill companies**. Inc.
- Saldarriaga-Zuluaga, S.D., López-Lezama, J.M., Zuluaga Ríos, C.D., and Villa Jaramillo, A. (2022). Effects of the Incorporation of Electric Vehicles on Protection Coordination in Microgrids. **World Electric Vehicle Journal**, Vol. 13, no. 9, article no. 163
- Solar Thailand. (2023). ข้อมูลแผงโซลาร์เซลล์ MONO-550W-JAsolar. [Online]. Available: <https://www.solar-thailand.com/TM/Product/MONO-550W-JAsolar/>

- Sovann Ang (2017). Optimal Placement and Sizing of Distributed Generation using Whale Optimization Algorithm. **Degree of Master Engineering in Electrical Engineering. Suranaree University of Technology.**
- Sun, Z., Li, K., Yang, Z., Niu, Q., and Foley, A. (2015). Impact of Electric Vehicles on a Carbon Constrained Power System A Post 2020 Case Study. **Journal of Power and Energy Engineering**, Vol.3 No.4
- Szczepaniuk, H. and Szczepaniuk, E. K. (2023). Applications of Artificial Intelligence Algorithms in the Energy Sector. **Energies**. Vol. 16, No. 1
- The National Aeronautics and Space Administration (2023). **NASA Access View**. [ออนไลน์]. ได้จาก: <https://power.larc.nasa.gov/data-access-viewer/>
- Tooryan, F., HassanzadehFard, H., Collins, R. E., Jin, S., and Ramezani, B. (2020). Optimization and energy management of distributed energy resources for a hybrid residential microgrid. **Energies**. Vol. 30.
- Thongchart Kerdphol (2016). Optimization of Battery Energy Storage Systems for Microgrids. **A dissertation the degree of Doctor of Philosophy, Department of Electrical and Electronics Engineering, Kyushu Institute of Technology.**
- Wang, B., Xu, Y., Hee, S.B. and Yan, Z. (2021). A Multi-Agent Deep Reinforcement Learning Based Multi- Timescale Voltage Control for Distribution System. IEEE 5th Conference on Energy Internet and Energy System Integration (EI2), Taiyuan, China, pp. 2825-2830.
- Wang, J., Xu, W., Gu, Y., Song, W. and Green, T. C. (2021). Multi-Agent Reinforcement Learning for Active Voltage Control on Power Distribution Networks. **CoRR**. Vol. abs/2110.14300, 2021.
- Wang, R., Wang, P., and Xiao., G. (2018). Intelligent Microgrid Management and EV Control Under Uncertainties in Smart Grid. **The Springer companies, Inc.**
- Wong, L. A., Ramachandaramurthy, V. K., Taylor, P., Ekanayake, J. B., Walker, S. L. and Padmanaban, S. (2019). Review on the Optimal Placement, Sizing and Control of an Energy Storage System in the Distribution Network. **Journal of Energy Storage**. Vol. 21, pp. 489-504.

- Yaodong Yang (2021). Many-Agent Reinforcement Learning. **Department of Computer Science, University College London.**
- Zagoras, N., Balasubramaniam, K., Karagiannidis, I., and Makram, E. B. (2015). Battery Energy Storage Systems. North American Power Symposium (NAPS), Charlotte, NC, USA, 2015, pp. 1-6.
- Zhang K., Yang Z., and Basar T. (2019). Multi-Agent Reinforcement Learning: A Selective Overview of Theories and Algorithms, **CoRR**, vol. abs/1911.10635.
- Zhang, L., Liu, L., Yang, X.-S., and Dai, Y. (2016). A Novel Hybrid Firefly Algorithm for Global Optimization. **PLOS ONE**. Vol. 11, No. 9, pp.
- Zhao, B., Wang, X., Lin, D., Calvin, M. M., Morgan, J. C., Qin, R. and Wang, C. (2018). Energy Management of Multiple Microgrids Based on a System of Systems Architecture. **IEEE Transactions on Power Systems**, Vol. 33, No. 6, pp. 6410-6421.
- Zhou, J., Xue, S., Xue, Y., Liao, Y., Liu, J., and Zhao, J. (2021). A Novel Energy Management Strategy of Hybrid Electric Vehicle via an Improved TD3 Deep Reinforcement Learning. **Energy**. Vol. 224, p. 120118.



ภาคผนวก ก

ชุดคำสั่งโปรแกรม PYTHON สำหรับการจำลองผล

ชุดคำสั่งโปรแกรม PYTHON สำหรับการจำลองผล

โดย นายธนรัช โคตรศรีวงษ์ สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี พ.ศ.
2567 ชุดคำสั่งโปรแกรม Python ที่ใช้ในงานประกอบด้วย 2 ชุดคำสั่งดังนี้

1. ชุดคำสั่งโปรแกรมสำหรับการทดสอบอัลกอริทึมในฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว
2. ชุดคำสั่งโปรแกรมสำหรับการหาขนาด และตำแหน่งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในระบบไมโครกริด เพื่อปรับปรุงแรงดัน ลดกำลังไฟฟ้าสูญเสีย และคำนวณต้นทุนของระบบ

1. ชุดคำสั่งโปรแกรมสำหรับการทดสอบอัลกอริทึมในฟังก์ชันฐานนิยมแบบเดี่ยว และฐานนิยมหลายตัว

```
In [ ]: #--> Library พื้นฐานของ Python ใช้สำหรับการจัดการข้อมูล Matrix และ Array
import os
import random
import pandas as pd
import numpy as np

#--> Library พื้นฐานของ Reinforcement Learning (RL) ได้แก่ State, Action
import gymnasium as gym
# ฟังก์ชันใช้สำหรับกำหนดระยะเวลาการค้นห และช่วงของการกระทำ
from gymnasium import spaces
# ฟังก์ชันคำนวณฟังก์ชันของกรการกระทำ
from gymnasium.spaces import Box
# ฟังก์ชันใช้สำหรับคำนวณค่าในโครงสร้างระบบ RL
from gymnasium.utils import seeding

#--> Library พื้นฐานของ Multi-Agent Deep Reinforcement Learning (MADRL)
# Library หลักของ RLlib
import ray
# ฟังก์ชันสำหรับการฝึกอบรมแบบจำลอง
from ray import air, tune
# ฟังก์ชันสำหรับปรับแต่ง Environment ร่วมกับ RLLib
from ray.tune.registry import register_env
# ฟังก์ชันใช้สำหรับระบุให้ Environment เป็น MADRL
from ray.rllib.env.multi_agent_env import MultiAgentEnv
# ฟังก์ชันการบีบอัด Environment
from ray.rllib.env.wrappers.multi_agent_env_compatibility import MultiAgentEnvCompatibility
# เรียกใช้ฟังก์ชันที่ใช้
from ray.rllib.algorithms.a2c.a2c import A2CConfig
from ray.rllib.algorithms.a3c.a3c import A3CConfig
from ray.rllib.algorithms.ddpg.ddpg import DDPGConfig
from ray.rllib.algorithms.td3.td3 import TD3Config
from ray.rllib.algorithms.sac.sac import SACConfig

In [ ]: #--> สร้าง Environment โดยฟังก์ชันที่สำคัญได้แก่ __init__, Reset, Step และ Render
## ฟังก์ชัน __init__ คือ การกำหนดค่าเริ่มต้น และการประกาศตัวแปรที่ใช้ทำงานใน Environment
## ฟังก์ชัน Reset คือ การคืนค่าเดิม หลังการฝึกซ้อมเสร็จสิ้น เพื่อเริ่มฝึกซ้อมในรอบต่อไป
## ฟังก์ชัน Step คือ ฟังก์ชันที่รับค่าการกระทำ จากนักแสดงและส่งค่ารางวัล และสถานะหลังจากการกระทำ
### ไปให้เจมส์ตัวละครหาค่าที่เหมาะสมในการกระทำครั้งต่อไป
## ฟังก์ชัน Render คือ การแสดงที่เป็นลักษณะรูปภาพ โดยในงานวิจัยฟังก์ชัน Render จะไม่ถูกใช้งาน

class MultiAgentTestFunction(MultiAgentEnv):
    def __init__(self, *args, **kwargs):
```

```

self.control_rewards = [0 for _ in range(self.n_agent)]

self._cumulative_rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
self.last_dones = [False for _ in range(self.n_agent)]

self.agents = self.possible_agents[:]
self.rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
self._obs_return = dict(zip(self.agents, [(0) for _ in self.agents]))
self._cumulative_rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
self.terminateds = dict(zip(self.agents, [False for _ in self.agents]))
self.truncated = dict(zip(self.agents, [False for _ in self.agents]))

self.infos = dict(zip(self.agents, [{} for _ in self.agents]))

return self.observations, self.infos

def step(self, action):
    num_reward = 0
    # กำหนดตัวแปรสำหรับการหยุดทำงาน เมื่อ self.timestep >= self.max_cycles
    terminated, truncated = {}, {}

    # เก็บชื่อเอเจนต์ไว้สำหรับการวนซ้ำ
    agent_ids = action.keys()

    for agent_id in agent_ids:
        self.raw_reward = 0
        get_action = np.asarray(action[agent_id], dtype=np.float32)

        ##### การคำนวณคะแนน F1 #####

        Equation_cal = []
        result_fc = []
        for i in range(len(get_action)):
            Equation_cal.append((round(get_action[i],4)*100)**2)
            sum_box_one = np.sum(Equation_cal)
            result_fc.append(sum_box_one)

        ##### การคำนวณคะแนน F2 #####

        for i in range(len(get_action)):
            Equation_cal.append(abs(round(get_action[i],4)*100))

```

```

super().__init__()
self.seed()
# การกำหนดจำนวนเอเจนต์
self.n_agent = 2
self.num_agents = self.n_agent

# ฟังก์ชันสำหรับสถานะของภาครถท่า
self.action_space = spaces.Box(low=-1, high=1, shape=(10,), dtype=np.float32)

# ฟังก์ชันใช้สำหรับการกำหนดระยะเวลาการคิดหา
self.observation_space = spaces.Box(low=-100000, high=100000, shape=(1,), dtype=np.float32)

# การกำหนดโหนดเริ่มต้นตามลำดับระดับหา และการกระทำที่ตั้งค่าขนาด
self.agents = ["agent_" + str(n) for n in range(self.n_agent)]
self.agent_name_mapping = dict(zip(self.agents, list(range(self.num_agents))))
self.possible_agents = self.agents[:]
self.last_dones = [False for _ in range(self.n_agent)]
self.has_reset = False
self.control_rewards = [0 for _ in range(self.n_agent)]

# การกำหนดระยะเวลาที่เอเจนต์กระทำใน Environment ต่อ 1 รอบการฝึกอบรม
self.timestep = 0
self.max_cycles = 10

# ค่าเริ่มต้นของฟังก์ชัน
self.sum_fc_one = 0

# ค่าเริ่มต้นของรางวัล
self.raw_reward = 0

def reset(self, *, seed=None, options=None):
    # การคืนค่าเริ่มต้นให้กับส่วนแปร หลังจากฝึกอบรมเสร็จในแต่ละรอบ
    self.timestep = 0
    self.max_cycles = 10
    self.max_cycles = 10

    self.has_reset = True
    state_random = np.random.uniform(-100,100)

    obs_list = {agent: [np.random.uniform(-100,100)] for agent in self.agents}

    self.observations = obs_list
    self.last_obs = obs_list
    self.last_rewards = [np.float32(0) for _ in range(self.n_agent)]

```

```

sum_box_one = np.sum(Equation_cal)
sum_box_two = math.prod(Equation_cal)
sum_total_function = sum_box_one + sum_box_two

result_fc.append(sum_total_function)

##### การคำนวณสมการ F3 #####

for i in range(len(get_action)):
    #print('number of action = {}'.format(i))
    Equation_cal.append((round(get_action[i],2)*5.12)**2
                        -10*math.cos(2*math.pi*np.array(get_action[i])*5.12)+10)

result_fc = np.sum(Equation_cal)

##### การคำนวณสมการ F4 #####

Equation_sep1 = []
Equation_sep2 = []
result_fc = []
for i in range(len(get_action)):
    #print('number of action = {}'.format(i))
    Equation_sep1.append((get_action[i]*600)**2)
    Equation_sep2.append(math.cos(np.array(get_action[i]*600)/math.sqrt(4+1))+1)

sum_box_one = np.sum(Equation_sep1)*1/4000
sum_box_two = math.prod(Equation_sep2)
result_fc = sum_box_one - sum_box_two

##### สิ้นสุดโค้ดของสมการ F1, F2, F3 และ F4 #####

# เก็บผลลัพธ์ที่ได้จากการคำนวณฟังก์ชัน
self.sum_fc_one = result_fc
self_obs_return[agent_id] = self.sum_fc_one
diff_reward = np.asarray(self.sum_fc_one, dtype=np.float32)

# การคำนวณฟังก์ชันรางวัล
if diff_reward >= 5000*len(get_action) or diff_reward <= -5000*len(get_action):
    self.raw_reward += -5
elif diff_reward >= 1000*len(get_action) or diff_reward <= -1000*len(get_action):
    self.raw_reward += 10
elif diff_reward >= 100*len(get_action) or diff_reward <= -100*len(get_action):

```

```

    policy_mapping_fn= (lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 5000}
#--> เริ่มสิ้นการฝึกอบรม MAA2C

model_fit = tune.Tuner(
    "A2C",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=1000,
        ),
    ),
    param_space=config,
).fit()

In [ ]: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MAA3C
config = (
    A3CConfig()
    .environment('TestFunction')
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1) #
    .reporting(min_time_s_per_iteration=0.1,)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        train_batch_size=256,
        lambda_ = 0.01,
        lr = 0.0001,
        model={"fcnet_activation": "relu",
              'fcnet_hidden': [256,256]},)
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn= (lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 5000}

```

```

def seed(self, seed=None):
    self.np_random, seed = seeding.np_random(seed)
    return [seed]

def get_agent_ids(self):
    self.agents = set(self.agents)
    return self.agents

def observation_spaces(self, agent):
    return self.observation_spaces[agent]

def action_space(self, agent):
    return self.action_space[agent]

In [ ]: # เรียกใช้ Environment ที่สร้างขึ้น
env = MultiAgentTestFunction()

In [ ]: #--> การเรียกใช้ MultiAgentTestFunction() เข้ากับไลบรารี Rllib
def env_v(args, **kwargs):
    env = MultiAgentMaze(**kwargs)
    return env

env = env_v({})
ray.rllib.util.check_env(env)
register_env("TestFunction", env_v)

In [ ]: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MAA2C
config = (
    A2CConfig()
    .environment('TestFunction')
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1) #
    .reporting(min_time_s_per_iteration=0.1,)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        train_batch_size=256,
        lambda_ = 0.01,
        lr = 0.0001,
        model={"fcnet_activation": "relu",
              'fcnet_hidden': [256,256]},)
    .multi_agent(
        policies=env.get_agent_ids(),

```

```

        self.raw_reward += 20
    elif diff_reward >= 50*len(get_action) or diff_reward <= -50*len(get_action):
        self.raw_reward += 30
    elif diff_reward >= 10*len(get_action) or diff_reward <= -10*len(get_action):
        self.raw_reward += 80
    elif diff_reward >= 0.1 or diff_reward <= -0.1:
        self.raw_reward += 100

    # การเพิ่มฟังก์ชันรางวัล
    self.control_rewards[num_reward] = np.array(self.raw_reward, dtype=np.float32) ##### reward ทางเบ็ดเสร็จคิด E
    num_reward += 1

    for r in self.rewards:
        self.rewards[r] = self.control_rewards[self.agent_name_mapping[r]]

    if self.timestep >= self.max_cycles:
        self.truncated = dict(zip(self.agents, [True for _ in self.agents]))
    else:
        self.terminations = dict(zip(self.agents, [False for _ in self.agents]))

    self._accumulate_rewards()

    self.timestep += 1
    self.infos = dict(zip(self.agents, [{ for _ in self.agents}]))

    terminated["__all__"] = len(self.terminations) == len(self.agents)
    truncated["__all__"] = len(self.truncated) == len(self.agents)

    return self_obs_return, self.rewards, terminated, truncated, self.infos

def render(self, *args, **kwargs):
    pass

# ส่วนนี้ที่จำเป็นใน Library RLlib สำหรับการเก็บรางวัล ระบบการคืนรางวัลของเอเจนต์ และการกรรพหำ
def _accumulate_rewards(self) -> None:
    for agent, reward in self.rewards.items():
        self._cumulative_rewards[agent] += reward

```

```

#----> เริ่มต้นการฝึกอบรม MAA3C

model_fit = tune.Tuner(
    "ABC",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=1000,
        ),
        param_space=config,
    ).fit()

In [ ]: #----> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MADDPG
config = (
    DDPGConfig()
    .environment('TestFunction')
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1)
    .reporting(min_sample_timesteps_per_iteration=20)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        lr = 0.0001,
        gamma = 1.00,
        target_noise_clip = 0.2,
        model={"fcnet_activation": "relu",
              'fcnet_hidden': [256,256]},
    )
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 5000}

#----> เริ่มต้นการฝึกอบรม MADDPG

model_fit = tune.Tuner(
    "DDPG",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(

```

```

        checkpoint_frequency=10000,
    ),
),
param_space=config,
).fit()

In [ ]: #--> การกำหนดพารามิเตอร์สำหรับการฝึกของ MAT3
config = (
    TD3Config()
    .environment('TestFunction')
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1)
    .reporting(min_sample_timesteps_per_iteration=20)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        lr = 0.0001,
        gamma = 1.00,
        target_noise_clip = 0.2,
        model={"fcnet_activation": "relu",
              "fcnet_hidden": [256,256]},
    )
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 5000}

#--> เริ่มต้นการฝึกของ MAT3
model_fit = tune.Tuner(
    "TD3",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=10000,
        ),
    ),
    param_space=config,
).fit()

```

```

In [ ]: #--> การกำหนดพารามิเตอร์สำหรับการฝึกของ MASAC
config = (
    SACConfig()
    .environment('TestFunction')
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1)
    .reporting(min_sample_timesteps_per_iteration=20)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        lr = 0.0001,
        gamma = 1.00,
        lambda_ = 0.01,
        target_noise_clip = 0.2,
        model={"fcnet_activation": "relu",
              "fcnet_hidden": [256,256]},
    )
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 5000}

#--> เริ่มต้นการฝึกของ MASAC
model_fit = tune.Tuner(
    "SAC",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=10000,
        ),
    ),
    param_space=config,
).fit()

```



```

In [ ]: #--> เริ่มต้นทดสอบแบบจำลองหลังฝึกอบรม
result_grid = model_fit
best_result = result_grid.get_best_result(metric="episode_reward_mean", mode="max")
best_checkpoint = best_result.checkpoint
algo = Algorithm.from_checkpoint(best_result.checkpoint)

In [ ]: #--> วิเคราะห์ผลลัพธ์หลังฝึกอบรมเฉพาะจุด
obs, info = env.reset()
done = False
error_cal = []
for i in range(10):
    action = algo.compute_actions(
        observations=obs, policy_id='agent_0')
    next_obs, reward, done, truncated, _, sum_error = env.step(action)
    error_cal.append(sum_error)

error_cal_avg = np.sum(error_cal)/10
print("Minimize function result is {}".format(error_cal_avg))

```

2. ชุดคำสั่งโปรแกรมสำหรับการหาขนาด และตำแหน่งของพลังงานหมุนเวียน และระบบกักเก็บพลังงานแบบแบตเตอรี่ในระบบไมโครกริด เพื่อปรับปรุงแรงดัน ลดกำลังไฟฟ้าสูญเสีย และคำนวณต้นทุนของระบบ

```

In [ ]: #--> โมดูลพื้นฐานของ Python ใช้สำหรับการจัดการข้อมูล Matrix และ Array
import os
import random
import pandas as pd
import numpy as np

#--> โมดูลพื้นฐานของ Reinforcement Learning (RL) ได้แก่ State, Action
import gymnasium as gym
# ฟังก์ชันใช้สำหรับการกำหนดสถานะการค้นหา และช่วงของการกระทำ
from gymnasium import spaces
# ฟังก์ชันใช้สำหรับลักษณะของกล่อง
from gymnasium.spaces import Box
# ฟังก์ชันใช้สำหรับขั้นตอนวิธีโครงสร้างระบบ RL
from gymnasium.utils import seeding

#--> โมดูลของ Multi-Agent Deep Reinforcement Learning (MADRL)
# Library หลักของ RLlib
import ray
# ฟังก์ชันสำหรับการฝึกแบบจำลอง
from ray import air, tune
# ฟังก์ชันสำหรับปรับแต่ง Environment ร่วมกับ RLlib
from ray.tune.registry import register_env
# ฟังก์ชันใช้สำหรับปรับแต่ง Environment เป็น MADRL
from ray.rllib.env.multi_agent_env import MultiAgentEnv
# ฟังก์ชันการปรับแต่ง Environment
from ray.rllib.env.wrappers.multi_agent_env_compatibility import MultiAgentEnvCompatibility
# เรียกใช้ฟังก์ชันที่ใช้
from ray.rllib.algorithms.a2c.a2c import A2CConfig
from ray.rllib.algorithms.a3c.a3c import A3CConfig
from ray.rllib.algorithms.ddpg.ddpg import DDPGConfig
from ray.rllib.algorithms.td3.td3 import TD3Config
from ray.rllib.algorithms.sac.sac import SACConfig

#--> โมดูลพื้นฐานของระบบไฟฟ้า Pandapower
# การเรียกใช้ฟังก์ชันพื้นฐานของ Pandapower
#* เช่น การสร้างระบบโครงข่าย 33 บัส หรือการเพิ่มเครื่องกำเนิดไฟฟ้าในระบบ
import pandapower as pp
import pandapower.networks as pn
import pandapower.control as control
# ฟังก์ชันสำหรับแปลงระบบเป็นให้เป็นระบบแบบอนุกรมเวลา (Timeseries)
import pandapower.timeseries as timeseries
from pandapower import timeseries as ts
from pandapower.timeseries.data_sources.frame_data import DFData

```

```

In [ ]: #--> สร้าง Environment โดยฟังก์ชันที่สำคัญได้แก่ __init__, Reset, Step และ Render
## ฟังก์ชัน __init__ คือ การกำหนดค่าเริ่มต้น และการเรียกใช้ตัวแปรที่ใช้งานใน Environment
## ฟังก์ชัน Reset คือ การรีเซ็ตค่าเริ่มต้น และทำการรีเซ็ตค่าเริ่มต้นของตัวแปรที่เกี่ยวข้อง
## ฟังก์ชัน Step คือ ฟังก์ชันที่รับค่าการกระทำ จากโปรแกรมที่รัน และคำนวณผลตอบแทน
## ฟังก์ชัน Render คือ การแสดงผลเป็นลักษณะรูปภาพ โดยในกรณีของฟังก์ชัน Render จะไม่ถูกใช้งาน

class MultiAgentMicrogrid(MultiAgentEnv):

    def __init__(self, *args, **kwargs):
        super().__init__()
        self.seed()
        # การกำหนดจำนวนเอเจนต์
        self.n_agent = 2
        self.num_agents = self.n_agent

        # ฟังก์ชันสำหรับคำนวณค่าของกริด
        # คิวบิก Low = [WT_location, WT_sizing, PV_location, PV_sizing, BESS_location, BESS_sizing]
        #           High = [WT_location, WT_sizing, PV_location, PV_sizing, BESS_location, BESS_sizing]
        #           [ 1, -0.99, 1, -0.99, 1, -0.99]
        #           [ 32, 2.00, 32, 2.00, 32, 2.00]
        self.action_space = Box(low=np.array([1, -0.99, 1, -0.99, 1, -0.99]),
                                high=np.array([32, 2.00, 32, 2.00, 32, 2.00]), dtype=np.float32)

        # ฟังก์ชันใช้สำหรับการกำหนดกริดการกระทำ
        self.observation_space = spaces.Box(low=0, high=32, shape=(5,), dtype=np.float32)

        # การคำนวณค่าของตัวแปรสถานะ และกริดการกระทำที่กำหนด
        self.agents = ["agent." + str(r) for r in range(self.n_agent)]
        self.agent_name_mapping = dict(zip(self.agents, list(range(self.num_agents))))
        self.possible_agents = self.agents[:]
        self.last_dones = [False for _ in range(self.n_agent)]
        self.has_reset = False
        self.control_rewards = [0 for _ in range(self.n_agent)]

        # การกำหนดระยะเวลาที่เอเจนต์กระทำใน Environment ต่อ 1 รอบการฝึกอบรม
        self.timestep = 0
        self.max_cycles = 10

        # การคำนวณระบบโครงข่ายไฟฟ้าจาก Pandapower และส่วนโปรที่เชื่อมกับระบบ
        self.net = pn.case33bw()
        self.p_reward = 0

        # สถานะเริ่มต้นของ PV, WT และ BESS

```

```

self.cost_wt = 1
self.cost_pv = 1
self.cost_bess = 1

# ข้อมูลการใช้โหลดแบบที่ที่พิกัดคือ ที่นันทบุรี และแบบผสมผสาน
self.df = pd.read_excel(n+"\15min-residential100-EV-case1.xlsx")
# ข้อมูลค่าตั้งต้นของตัวแปรสถานะ
self.df_wind = pd.read_excel(n+"\wind_kw-true.xlsx")
# ข้อมูลค่าตั้งต้นของตัวแปรสถานะ
self.df_pv = pd.read_excel(n+"\15min-pv_kw-true.xlsx")
# ข้อมูลการวัดประจุ และสถานะประจุระบบที่เก็บพลังงานแบบแบตเตอรี่
self.df_BESS = pd.read_excel(n+"\BESS-min15.xlsx")

# การเปลี่ยนระบบ IEEE 33 เป็นระบบแบบอนุกรมเวลา ด้วยข้อมูลโหลดจากโปรแกรม Excel
def network_model(self):
    self.net = pn.case33bw()
    ds_load = DFData(self.df, multi=False)
    const_load = control.ConstControl(self.net, element='load', element_index=self.net.load.index,
                                     variable='p_mw', data_source=ds_load, profile_name = self.df.columns,
                                     recycle=False, scale_factor=0.001)

    n_timesteps = 95
    self.time_steps = range(0, n_timesteps)
    self.net2 = self.net
    self.path_dir = n+"\Time-series-sim-ieee33-multi-action"
    self.output_dir = os.path.join(self.path_dir, "A2C_time_series_example-EV-Find-PV-WT-BESS-case1")
    ow = timeseries.OutputWriter(self.net, output_path=self.output_dir, output_file_type=".xlsx")
    ow_log_variable('res_bus', 'vm_pu', eval_function=np.average, eval_name="vm_avg")
    ow_log_variable('res_line', 'p1_mw', eval_function=np.sum, eval_name="p1_sum_each_time")
    # ฟังก์ชันคำนวณการไหลของระบบไฟฟ้า
    timeseries.run_timeseries(self.net2, time_steps=self.time_steps, continue_on_divergence=True)

# กระบวนการเก็บค่าแรงดันไฟฟ้า และกำลังไฟฟ้าสูญเสีย หลังส่วนการไหลของไฟฟ้า
def observe_list(self):
    self.network_model()
    vm_pu_file = os.path.join(self.output_dir, "res_bus", "vm_pu.xlsx")
    vm_pu = pd.read_excel(vm_pu_file)

    p_mw_file = os.path.join(self.output_dir, "res_line", "p1_mw.xlsx")
    p_mw = pd.read_excel(p_mw_file)

    self.vol = mean(vm_pu["vm_avg"])
    self.p_reward = sum(p_mw["p1_sum_each_time"])

```

```

observe_list = {agent: [self.cost_wt, self.cost_pv, self.cost_bess
                      , self.vol, self.P_reward] for agent in self.agents}

return observe_list

def reset(self, *, seed=None, options=None):
    # การคืนค่าเริ่มต้นให้กับตัวแปร หลังจากฝึกจบรอบเสร็จในแต่ละรอบ
    self.timestep = 0
    self.max_cycles = 10
    self.has_reset = True
    obs_list = self.observe_list()
    self.observations = self.observe_list()
    self.last_obs = obs_list
    self.last_rewards = [np.float32(0) for _ in range(self.n_location)]
    self.control_rewards = [0 for _ in range(self.n_location)]
    self._cumulative_rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
    self.last_dones = [False for _ in range(self.n_location)]
    self.agents = self.possible_agents[:]
    self._obs_return = dict(zip(self.agents, [(0) for _ in self.agents]))
    self.rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
    self._cumulative_rewards = dict(zip(self.agents, [(0) for _ in self.agents]))
    self.terminateds = dict(zip(self.agents, [False for _ in self.agents]))
    self.truncated = dict(zip(self.agents, [False for _ in self.agents]))
    self.infos = dict(zip(self.agents, [{} for _ in self.agents]))

    return self.observations, self.infos

def step(self, action):
    # กำหนดตัวแปรสำหรับการหยุดทำงาน เมื่อ self.timestep >= self.max_cycles
    terminated, truncated = {}, {}

    # เก็บชื่อเอเจนต์ไว้ใช้สำหรับการวนซ้ำ
    agent_ids = action.keys()

    # ตัวแปรสำหรับการวนรอบ
    num_reward = 0
    agent_index_number = 0

    for agent_id in agent_ids:
        # พึงที่รับการสร้าง WT และ PV โดยค่าตั้งเริ่มต้นอ้างอิงจากข้อมูลอนุกรมเวลา
        ## ในขณะเดียวกันเอเจนต์ใช้สำหรับการหาตำแหน่งในการติดตั้งหลังจางังกล่าว

```

```

pp.create_gen(self.net2, bus= int(action[agent_id][0]) ,
              p_mw=0.5, vm_pu=1.00, name="Generator {}".format(agent_id), index= agent_index_number)

pp.create_gen(self.net2, bus= int(action[agent_id][2]) ,
              p_mw=0.5, vm_pu=1.00, name="Generator {}".format(agent_id), index= agent_index_number +2)

# พึงที่รับการสร้าง BESS โดยมีการตั้งราคา และค่าคงที่ราคาอ้างอิงจากข้อมูลอนุกรมเวลา
## ในขณะเดียวกันเอเจนต์ใช้สำหรับการหาตำแหน่งในการติดตั้งหลังจางังกล่าว
store_el = pp.create_storage(self.net2, bus= int(action[agent_id][4]), p_mw = 1, q_mvar = 0,
                             max_e_mwh = 1.0*(action[agent_id][5]+self.cost_bess),
                             max_p_mw=0.08, min_p_mw=0.01, index= agent_index_number + 4)

# การกระทำเห็นขนาด หรือลดขนาดของเอเจนต์
sizing_wt = self.df_wind*(action[agent_id][1] + self.cost_wt )
sizing_pv = self.df_pv*(action[agent_id][3] + self.cost_pv )
sizing_bess = self.df_BEES*(action[agent_id][5]+self.cost_bess)

ds_wind = DFData(sizing_wt, multi=False)
ds_pv = DFData(sizing_pv, multi=False)
data_BEES = ts.DFData(sizing_bess)

ctrl = Storage(net=self.net2, gid=store_el, data_source=data_BEES, p_profile='BESS_cal3_soc')

const_wind = control.ConstControl(self.net2, element='gen',
                                  element_index= self.net2.gen.index[agent_index_number],
                                  variable='p_mw', data_source = ds_wind,
                                  profile_name = self.df_wind.columns[0]
                                  , recycle=True, scale_factor=0.001)

const_pv = control.ConstControl(self.net2, element='gen',
                                 element_index= self.net2.gen.index[ agent_index_number+1],
                                 variable='p_mw', data_source = ds_pv,
                                 profile_name = self.df_pv.columns[0]
                                 , recycle=False, scale_factor=0.1)

ow = timeseries.OutputWriter(self.net, output_path=self.output_dir, output_file_type=".xlsx")
ow.log_variable('res_bus', 'vm_pu', eval_function=np.average, eval_name="vm_avg")
ow.log_variable('res_line', 'pl_mw', eval_function=np.sum, eval_name="pl_sum_each_time")
ow.log_variable("storage", "soc_percent", eval_function=np.max, eval_name="soc_percent")

# พึงที่นับจำนวนการไหลของรอบมาไว้ที่ๆ หลังที่เห็นจำนวนหมุนเวียน และรอบจบก็เก็บทั้งหมดด้วย
timeseries.run_timeseries(self.net2, time_steps =self.time_steps, continue_on_divergence=True)

```

```

# ครอบคลุมการเก็บค่าแรงคืนไฟฟ้า และกำลังไฟฟ้าสูญเสีย หลังคำนวณการไหลของไฟฟ้า
vm_pu_file = os.path.join(self.output_dir, "res_bus", "vm_pu.xlsx")
vm_pu = pd.read_excel(vm_pu_file)

p_mw_file = os.path.join(self.output_dir, "res_line", "pl_mw.xlsx")
p_mw = pd.read_excel(p_mw_file)

soc_file = os.path.join(self.output_dir, "storage", "soc_percent.xlsx")
soc_cal = pd.read_excel(soc_file)

self.vol = mean(vm_pu["vm_avg"])
self.P_1_reward = sum(p_mw["pl_sum_each_time"])

# ครอบคลุมการคำนวณต้นทุนในการจัดหุ้ระบบ
total_cost_wt = action[agent_id][1] + self.cost_wt # 1850 $/kw
total_cost_pv = action[agent_id][3] + self.cost_pv # 1200 $/kw
total_cost_bess = action[agent_id][5] + self.cost_bess # 150 $/kw

# ครอบคลุมการคำนวณค่ารางวัล
raw_reward = -float(10*(self.P_1_reward-13.0490) + 10*(1.00 - self.vol)
              + 1.85*(total_cost_wt)+ 1.2*(total_cost_pv)+ 0.15*(total_cost_bess))

# การวนกลับค่าของราคา WT, PV และ BESS รวมถึงแรงคืนไฟฟ้า และกำลังไฟฟ้าสูญเสียถึงปรับปรุง
self.observations[agent_id] = [self.cost_wt, self.cost_pv, self.cost_bess, self.vol, self.P_1_reward]
self.control_rewards[num_reward] = np.array(raw_reward)
# ส่วนปรับสำหรับการรอบ
num_reward += 1
agent_index_number += 1

for r in self.rewards:
    self.rewards[r] = self.control_rewards[self.agent_name_mapping[r]]

# กำหนดตัวแปรสำหรับการหยุดทำงาน เมื่อ self.timestep >= self.max_cycles
if self.frames >= self.max_cycles:
    self.truncated = dict(zip(self.agents, [True for _ in self.agents]))
else:
    self.terminations = dict(zip(self.agents, [False for _ in self.agents]))
self.network_model()

self._accumulate_rewards()

self.timestep += 1

```

```

self.infos = dict(zip(self.agents, [(_) for _ in self.agents]))

terminated["_all_"] = len(self.terminated) == len(self.agents)
truncated["_all_"] = len(self.truncated) == len(self.agents)

return self.observations, self.rewards, terminated, truncated, self.infos

def render(self, *args, **kwargs):
    pass

# ตัวแปรที่จำเป็นใน Library RLlib สำหรับการทำงานร่วมกับ ระยะเวลาที่หาของเอเจนต์ และการกระทำ
def _accumulate_rewards(self) -> None:
    for agent, reward in self.rewards.items():
        self._cumulative_rewards[agent] += reward

def seed(self, seed=None):
    self.np_random, seed = seeding.np_random(seed)
    return [seed]

def get_agent_ids(self):
    self.agents = set(self.agents)
    return self.agents

def observation_spaces(self, agent):
    return self.observation_spaces[agent]

def action_space(self, agent):
    return self.action_space[agent]

```

```
In [ ]: # เรียกใช้ Environment ที่สร้างขึ้น
env = MultiAgentMicrogrid()
```

```
In [ ]: # --> การปรับใช้ MultiAgentTestFunction() เข้ากับไลบรารี RLlib
def env_v(args, **kwargs):
    env = MultiAgentMicrogrid(**kwargs)
    return env

env = env_v({})
ray.rllib.utils.check_env(env)
register_env("Microgrid", env_v)
```

```
In [ ]: # --> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MAA2C
config = (
    A2CConfig()
```

```

.environment('Microgrid')
.environment(disable_env_checking= True)
.resources(num_gpus=0)
.rollouts(num_rollout_workers=1) #
.reporting(min_time_s_per_iteration=0.1,)
.training(
  actor_hiddens=[256,256],
  critic_hiddens=[256,256],
  train_batch_size=256,
  lambda_ = 0.01,
  lr = 0.0001,
  model={"fcnet_activation": "relu",
        'fcnet_hiddens': [256,256]},)
.multi_agent(
  policies=env.get_agent_ids(),
  policy_mapping_fn= (lambda agent_id, *args, **kwargs: agent_id)
)
)

stop = {"episode_total": 150}

#--> เริ่มต้นการฝึกอบรม MAA2C
model_fit = tune.Tuner(
  "A2C",
  run_config=air.RunConfig(
    stop=stop,
    checkpoint_config=air.CheckpointConfig(
      checkpoint_frequency=1000,
    ),
  ),
  param_space=config,
).fit()

```

In []: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MAA3C

```

config = (
  A3CConfig()
  .environment('Microgrid')
  .environment(disable_env_checking= True)
  .resources(num_gpus=0)
  .rollouts(num_rollout_workers=1) #
  .reporting(min_time_s_per_iteration=0.1,)
  .training(
    actor_hiddens=[256,256],

```

```

critic_hiddens=[256,256],
train_batch_size=256,
lambda_ = 0.01,
lr = 0.0001,
model={"fcnet_activation": "relu",
      'fcnet_hiddens': [256,256]},)
.multi_agent(
  policies=env.get_agent_ids(),
  policy_mapping_fn= (lambda agent_id, *args, **kwargs: agent_id)
)
)

```

stop = {"episode_total": 150}

#--> เริ่มต้นการฝึกอบรม MAA3C

```

model_fit = tune.Tuner(
  "A3C",
  run_config=air.RunConfig(
    stop=stop,
    checkpoint_config=air.CheckpointConfig(
      checkpoint_frequency=1000,
    ),
  ),
  param_space=config,
).fit()

```

In []: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MADDPG

```

config = (
  DDPGConfig()
  .environment('Microgrid')
  .environment(disable_env_checking= True)
  .resources(num_gpus=0)
  .rollouts(num_rollout_workers=1)
  .reporting(min_sample_timesteps_per_iteration=20)
  .training(
    actor_hiddens=[256,256],
    critic_hiddens=[256,256],
    lr = 0.0001,
    gamma = 1.00,
    target_noise_clip = 0.2,
    model={"fcnet_activation": "relu",
          'fcnet_hiddens': [256,256]},)
  )
)

```

```

        .multi_agent(
            policies=env.get_agent_ids(),
            policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
        )
    )

stop = {"episode_total": 150}
#--> เริ่มต้นการฝึกอบรม MDDPG

model_fit = tune.Tuner(
    "DDPG",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=10000,
        ),
    ),
    param_space=config,
).fit()

```

In []: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MATD3

```

config = (
    TD3Config()
    .environment("Microgrid")
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1)
    .reporting(min_sample_timesteps_per_iteration=20)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        lr = 0.0001,
        gamma = 1.00,
        target_noise_clip = 0.2,
        model={"fcnet_activation": "relu",
              'fcnet_hidden': [256,256]},
    )
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 150}

```

```

#--> เริ่มต้นการฝึกอบรม MATD3

model_fit = tune.Tuner(
    "TD3",
    run_config=air.RunConfig(
        stop=stop,
        checkpoint_config=air.CheckpointConfig(
            checkpoint_frequency=10000,
        ),
    ),
    param_space=config,
).fit()

```

In []: #--> การกำหนดพารามิเตอร์สำหรับการฝึกอบรมของ MASAC

```

cconfig = (
    SACConfig()
    .environment("Microgrid")
    .environment(disable_env_checking= True)
    .resources(num_gpus=0)
    .rollouts(num_rollout_workers=1)
    .reporting(min_sample_timesteps_per_iteration=20)
    .training(
        actor_hidden=[256,256],
        critic_hidden=[256,256],
        lr = 0.0001,
        gamma = 1.00,
        lambda_ = 0.01,
        target_noise_clip = 0.2,
        model={"fcnet_activation": "relu",
              'fcnet_hidden': [256,256]},
    )
    .multi_agent(
        policies=env.get_agent_ids(),
        policy_mapping_fn=(lambda agent_id, *args, **kwargs: agent_id)
    )
)

stop = {"episode_total": 150}
#--> เริ่มต้นการฝึกอบรม MASAC

model_fit = tune.Tuner(
    "SAC",
    run_config=air.RunConfig(

```

```

stop=stop,
checkpoint_config=air.CheckpointConfig(
    checkpoint_frequency=10000,
),
),
param_space=config,
).fit()

```

In []: *#--> เริ่มต้นทดสอบแบบจำลองหลังฝึกอบรม*

```

result_grid = model_fit
best_result = result_grid.get_best_result(metric="episode_reward_mean", mode="max")
best_checkpoint = best_result.checkpoint
algo = Algorithm.from_checkpoint(best_result.checkpoint)

```

In []: *#--> วิเคราะห์ผลลัพธ์หลังฝึกอบรมเฉพาะ*

```

obs, info = env.reset()
done = False

for i in range(33):
    action = algo.compute_actions(
        observations=obs, policy_id='agent_0')
    #print(action)
    next_obs, reward, done, truncated,_, total_cost_wt,total_cost_pv,total_cost_bess = env.step(action)
    obs = next_obs
    print('reward is {}'.format(reward))
    print('WT sizing is {} and PV sizing is {}'.format(total_cost_wt,total_cost_pv))
    print('WT location is {} and PV location {}'.format(int(action[agent_id][0]),int(action[agent_id][2])))
    print('BESS sizing is {}'.format(total_cost_bess))
    print('BESS location is {}'.format(int(action[agent_id][4])))
    print('Iteration {}'.format(i))
    print('='*50)

```



ภาคผนวก ข

ระบบจำหน่ายไฟฟ้าที่ใช้ในงานวิจัย

Line number	From node	To node	P (kW)	Q (kVar)	Line number	From node	To node	P (kW)	Q (kVar)
1	0	1	100.00	60.00	17	16	17	90.00	40.00
2	1	2	90.00	40.00	18	1	18	90.00	40.00
3	2	3	120.00	80.00	19	18	19	90.00	40.00
4	3	4	60.00	30.00	20	19	20	90.00	40.00
5	4	5	60.00	20.00	21	20	21	90.00	40.00
6	5	6	200.00	100.00	22	2	22	90.00	50.00
7	6	7	200.00	100.00	23	22	23	420.00	200.00
8	7	8	60.00	20.00	24	23	24	420.00	200.00
9	8	9	60.00	20.00	25	5	25	60.00	25.00
10	9	10	45.00	30.00	26	25	26	60.00	25.00
11	10	11	60.00	35.00	27	26	27	60.00	20.00
12	11	12	60.00	35.00	28	27	28	120.00	70.00
13	12	13	120.00	80.00	29	28	29	200.00	600.00
14	13	14	60.00	10.00	30	29	30	150.00	70.00
15	14	15	60.00	20.00	31	30	31	210.00	100.00
16	15	16	60.00	20.00	32	31	32	60.00	40.00

รูปที่ ข.1 โหลดพื้นฐานในระบบทดสอบ IEEE 33 โหนด

Line number	From node	To node	R (ohms)	jX (ohms)	Line number	From node	To node	R (ohms)	jX (ohms)
1	0	1	0.0922	0.0470	19	18	19	1.5042	1.3554
2	1	2	0.4930	0.2511	20	19	20	0.4095	0.4784
3	2	3	0.3660	0.1864	21	20	21	0.7089	0.9373
4	3	4	0.3811	0.1941	22	2	22	0.4512	0.3083
5	4	5	0.8190	0.7070	23	22	23	0.8980	0.7091
6	5	6	0.1872	0.6188	24	23	24	0.8960	0.7011
7	6	7	0.7114	0.2351	25	5	25	0.2030	0.1034
8	7	8	1.0300	0.7400	26	25	26	0.2842	0.1447
9	8	9	1.0440	0.7400	27	26	27	1.0590	0.9337
10	9	10	0.1966	0.0650	28	27	28	0.8042	0.7006
11	10	11	0.3744	0.1238	29	28	29	0.5042	0.2585
12	11	12	1.4680	1.1550	30	29	30	0.9744	0.3630
13	12	13	0.5416	0.7129	31	30	31	0.3105	0.3619
14	13	14	0.5910	0.5260	32	31	32	0.3410	0.5302
15	14	15	0.7463	0.5450	33	7	20	2.0000	2.0000
16	15	16	1.2890	1.7210	34	8	14	2.0000	2.0000
17	16	17	0.7320	0.5740	35	11	21	2.0000	2.0000
18	1	18	0.1640	0.1565	36	17	32	0.5000	0.5000
					37	24	28	0.5000	0.5000

รูปที่ ข.2 ข้อมูลสายส่งทดสอบ IEEE 33 โหนด



ภาคผนวก ค

บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา

รายชื่อวารสารวิชาการที่ได้รับการตีพิมพ์เผยแพร่ 1 บทความ

Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., Pinthurat, W., and Marungsri, B. (2023). Performance of Deep Learning Techniques for Forecasting PV Power Generation: A Case Study on a 1.5 MWp Floating PV Power Plant. **Energies**, Vol. 16, No. 5

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ 3 บทความ

Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., and Marungsri, B. (2022). Weekly Power Generation Forecasting using Deep Learning Techniques: Case Study of a 1.5 MWp Floating PV Power Plant. **2022 International Conference on Power, Energy, and Innovations (ICPEI)**, Pattaya Chonburi, Thailand, 2022, pp. 1-4.

นนธวัช โคตรศรีวังษ์, อธิระพงษ์ บุญรักษา, พรหมพัคตร์ บุญรักษา, ทิพย์วรรณ พิงสุวรรณรักษ์, อัญญา บุญศรีรัตน์ และบุญเรือง มะรังศรี. การพยากรณ์กำลังการผลิตโดยใช้เทคนิคการเรียนรู้เชิงลึก : กรณีศึกษาระบบผลิตกำลังงานไฟฟ้าจากเซลล์แสงอาทิตย์แบบทุ่นลอยน้ำขนาด 1.5 MWp. การประชุมวิชาการรูปแบบพลังงานทดแทนสู่ชุมชนแห่งประเทศไทย ครั้งที่ 15. ชุมพร, 27 – 29 ตุลาคม 2565.

Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., and Marungsri, B. (2023). Short-term Load Demand Forecasting using Supervised Deep Learning Techniques: A Case Study of Suranaree University of Technology. **2023 International Electrical Engineering Congress (IEECON)**, Krabi, Thailand, 2023, pp. 417-421

ประวัติผู้เขียน

นายธนวัช โคตรศรีวงษ์ เกิดเมื่อวันที่ 3 สิงหาคม พ.ศ. 2542 ที่อำเภอเมือง จังหวัดนครราชสีมา เริ่มศึกษาระดับอนุบาล ที่โรงเรียนพิสุทธิ์วิทยาคม อำเภอสูงเนิน จังหวัดนครราชสีมา ต่อมาเริ่มศึกษาระดับประถมศึกษา ที่โรงเรียนมงคลกุลวิทยา อำเภอสีคิ้ว จังหวัดนครราชสีมา สำเร็จการศึกษาระดับมัธยมศึกษาตอนต้น และระดับมัธยมศึกษาตอนปลาย จากโรงเรียนราชสีมาวิทยาลัย อำเภอเมือง จังหวัดนครราชสีมา เมื่อ พ.ศ. 2560 ในภายหลังได้เข้าศึกษาต่อระดับปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี และสำเร็จการศึกษาในปี พ.ศ. 2565 จากนั้น ได้ศึกษาต่อปริญญาวิศวกรรมศาสตรมหาบัณฑิต สำนักวิศวกรรมศาสตร์ สาขาวิชา วิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี มีความสนใจศึกษาการพยากรณ์กำลังผลิตพลังงาน และการจัดการพลังงานของไมโครกริดที่ใช้พลังงาน และระบบกักเก็บพลังงานแบบแบตเตอรี่ โดยมีผลงานตีพิมพ์ และเอกสารการประชุมทางวิชาการดังแสดงไว้ในภาคผนวก



มหาวิทยาลัยเทคโนโลยีสุรนารี