

การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้า
โดยใช้โครงข่ายประสาทเทียมและระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

RELIABILITY EVALUATION OF POWER GENERATION SYSTEMS
USING ARTIFICIAL NEURAL NETWORKS AND
ADAPTIVE NEURO-FUZZY INFERENCE SYSTEMS



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2561

KMITL-2018-EN-D-018-157

การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้า
โดยใช้โครงข่ายประสาทเทียมและระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

RELIABILITY EVALUATION OF POWER GENERATION SYSTEMS
USING ARTIFICIAL NEURAL NETWORKS AND
ADAPTIVE NEURO-FUZZY INFERENCE SYSTEMS



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ. 2561
KMITL-2018-EN-D-018-157

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

RELIABILITY EVALUATION OF POWER GENERATION SYSTEMS
USING ARTIFICIAL NEURAL NETWORKS AND
ADAPTIVE NEURO-FUZZY INFERENCE SYSTEMS



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
DOCTOR OF ENGINEERING IN ELECTRICAL ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2018
KMITL-2018-EN-D-018-157

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2018

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าโดยใช้โครงข่าย ประสาทเทียมและระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้
นักศึกษา	นางสาวชนิษฐา วรรณคำ
รหัสประจำตัว	55610154
ปริญญา	วิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2561
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.สมชาติ จิรวิภากร

บทคัดย่อ

วิทยานิพนธ์นี้นำเสนอวิธีการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าของระบบไฟฟ้าประเทศไทยด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Networks : ANN) ซึ่งโครงข่ายประสาทเทียมที่เลือกเป็นแบบมีหลายชั้นชนิดแพร่ค่าย้อนกลับ เปรียบเทียบกับระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems : ANFIS) ซึ่งเป็นการเรียนรู้แบบระบบผสมระหว่างโครงข่ายประสาทเทียมรวมกับกฎของฟัซซี โดยกำหนดให้การจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate เป็นอินพุท และดัชนี Expected Energy Not Supplied เป็นเอาท์พุท โดยข้อมูลที่ถูกป้อนเข้าไปในการเรียนรู้มาจากการคำนวณทางสถิติและความน่าจะเป็น พบว่าวิธีประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าด้วยวิธีโครงข่ายประสาทเทียมให้ผลลัพธ์ที่ดีกว่าระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้

รวมทั้งนำเสนอวิธีการจำลองข้อมูลพลังงานลมด้วยวิธีการกระจายข้อมูลแบบไวบูลล์, วิธีโครงข่ายประสาทเทียม และวิธีระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้ โดยใช้ข้อมูลค่าพลังงานที่ผลิตได้ย้อนหลัง 2 เดือน, ค่าพลังงานที่ผลิตได้ย้อนหลัง 1 เดือน และความเร็วลมเฉลี่ยเป็นอินพุท และค่าพลังงานที่ผลิตได้เป็นเอาท์พุท โดยข้อมูลที่ถูกป้อนเข้าไปในการเรียนรู้มาจากค่าที่บันทึกไว้ของการผลิตไฟฟ้าจากกังหันลมของสถานีพลังงานทดแทน แหลมพรหมเทพ จังหวัดภูเก็ต พบว่าวิธีโครงข่ายประสาทเทียมให้ผลลัพธ์ที่ดีที่สุด

Thesis	Reliability Evaluation of Power Generation Systems Using Artificial Neural Networks and Adaptive Neuro- Fuzzy Inference Systems
Student	Miss Khanittha Wannakam
Student ID.	55610154
Degree	Doctor of Engineering
Program	Electrical Engineering
Year	2018
Thesis Advisor	Assoc. Prof. Dr. Somchat Jiriwibhakorn

ABSTRACT

This thesis proposes a method for evaluating the reliability of the electrical power system of Thailand by Artificial Neural Networks (ANN), which is a multi-layer feed forward neural network. This method compares with Adaptive Neuro-Fuzzy Inference Systems (ANFIS), which is a hybrid method of artificial neural network and fuzzy rules. Determine the priority list of generator, installed capacity and Force Outage Rate are inputs. And Expected Energy Not Supplied Index is output. The information entered into the learning comes from statistical and probabilistic calculations. It was found that the method of evaluating the reliability of electricity generation using Artificial Neural Networks was better than Adaptive Neuro-Fuzzy Inference Systems.

In addition, the proposed method of wind energy data simulation using the Weibull Distribution, Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems. Determine the wind energy 2 month ago, wind energy 1 month ago and average wind speed are inputs. And wind energy is output. The information entered into the learning comes from the recorded value of wind power from the Promthep Alternative Energy Station, Phuket, Thailand. It was found that Artificial Neural Networks delivers the best results.

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จได้ด้วยความอนุเคราะห์จาก รศ.ดร.สมชาติ จิรวิภากร ซึ่งเป็นอาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ช่วยให้คำปรึกษาและตรวจทานจนประสบผลสำเร็จในทุกขั้นตอน รวมทั้งครอบครัวและเพื่อนที่ให้ความช่วยเหลือในทุกด้าน

ผู้เขียนจึงใคร่ขอขอบพระคุณทุกท่านที่ช่วยเหลือและให้กำลังใจจนงานทุกอย่างผ่านพ้นไปได้ด้วยดี

ชนิษฐา วรรณคำ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	I
บทคัดย่อภาษาอังกฤษ	II
กิตติกรรมประกาศ	III
สารบัญ	IV
สารบัญตาราง	VII
สารบัญรูป	VIII
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการศึกษา	2
1.3 ขอบเขตของการศึกษา	3
1.4 ขั้นตอนของการศึกษา	3
1.5 ประโยชน์ที่คาดว่าจะได้รับจากการศึกษา	3
บทที่ 2 โครงข่ายประสาทเทียม	4
2.1 พื้นฐานของโครงข่ายประสาทเทียม	4
2.2 โครงข่ายประสาทเทียมแบบมีผู้ฝึกสอน	4
2.2.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น	4
2.2.1.1 แบบจำลองของนิเวรอน	4
2.2.1.2 ฟังก์ชันถ่ายโอน	5
2.2.2 โครงสร้างของโครงข่ายประสาทเทียม	7
2.2.3 ขั้นตอนวิธีการเรียนรู้	8
2.2.3.1 วิธีการเรียนรู้แบบแพร่ค่าย้อนกลับ	8
2.2.3.2 Levenberg-Marquardt Algorithm	9
2.3 การเลือกชนิดของอินพุทและเอาท์พุท	10
2.4 การนอร์มอลไลซ์ของข้อมูลสำหรับสอนโครงข่ายประสาทเทียม	11
2.5 ตัวอย่างการเรียนรู้โดยใช้โครงข่ายประสาทเทียมบนโปรแกรม MATLAB	13
2.6 การวัดประสิทธิภาพของ ANN	15
บทที่ 3 ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้	18
3.1 พื้นฐานของระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้	18
3.1.1 กฎฟัซซี	18
3.1.2 ระบบนิวโรฟัซซี	19
3.2 โครงสร้างของระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้	20
3.3 ฟังก์ชันความเป็นสมาชิก	22
3.4 ขั้นตอนวิธีการเรียนรู้แบบไฮบริด	28
3.5 ตัวอย่างการเรียนรู้โดยใช้ระบบนิวโรฟัซซีแบบปรับตัวได้บนโปรแกรม MATLAB ..	28
3.6 การวัดประสิทธิภาพของ ANFIS	31
บทที่ 4 พลังงานลม	33

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1	พลังลม	33
4.1.1	เทคโนโลยีกังหันลม	33
4.1.2	ช่วงการทำงานของกังหันลม	34
4.2	การกระจายข้อมูลแบบไวบูลล์	35
4.3	หลักการวิเคราะห์การผลิตไฟฟ้าจากพลังงานลม	36
บทที่ 5	การวิเคราะห์ความเชื่อถือได้ในระบบไฟฟ้ากำลัง	38
5.1	แนวคิดและหลักการวิเคราะห์ความเชื่อถือได้ในระบบไฟฟ้ากำลัง	38
5.2	แบบจำลองการทำงานของอุปกรณ์	39
5.3	แบบจำลองของระบบผลิตไฟฟ้า	40
5.3.1	แบบจำลองรอบการทำงานของอุปกรณ์ในระบบ	40
5.3.2	แบบจำลองมาร์คอฟฟ์ 2 สถานะ	42
5.3.3	ตารางความน่าจะเป็นในการขาดกำลังการผลิต	43
5.4	แบบจำลองของโหลด	44
5.4.1	เส้นโค้งช่วงระยะเวลาของโหลด	45
5.5	Expected Energy Not Supplied (EENS)	46
5.5.1	การคำนวณค่าดัชนี Expected Energy not Supplied (EENS)	46
5.5.2	ตัวอย่างการคำนวณค่าดัชนีความเชื่อถือได้	47
บทที่ 6	การจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลม	51
6.1	วิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม	51
6.1.1	การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้การกระจายข้อมูลแบบไวบูลล์	52
6.1.2	การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม	54
6.1.3	การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้	54
6.2	ผลการทดสอบการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม	55
6.2.1	ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้การกระจายข้อมูลแบบไวบูลล์	55
6.2.2	ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม	56
6.2.3	ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้	58
6.2.4	ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมจากการจำลองทั้ง 3 วิธี	60
บทที่ 7	การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าจากพลังงานลม	64
7.1	ความเชื่อถือได้ของระบบผลิตไฟฟ้าของระบบทดสอบ IEEE RTS	64
7.1.1	การทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)	64
7.1.2	ผลการทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)	65

7.1.3 การทดสอบโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (ANFIS)	66
7.1.4 ผลการทดสอบโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (ANFIS)	67
7.2 ความเชื่อถือได้ของระบบผลิตไฟฟ้าของระบบไฟฟ้าของประเทศไทย	69
7.2.1 การทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)	70
7.2.2 ผลการทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)	70
7.2.3 การทดสอบโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (ANFIS)	72
7.2.4 ผลการทดสอบโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (ANFIS)	72
7.3 ผลการประเมินดัชนีความเชื่อถือได้เปรียบเทียบระหว่าง ANN และ ANFIS	75
7.3.1 การประเมินดัชนี EENS ของระบบ IEEE RTS	75
7.3.2 การประเมินดัชนี EENS ของระบบไฟฟ้าประเทศไทย	78
บทที่ 8 สรุปผลการวิจัยและข้อเสนอแนะ	83
8.1 วิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม	83
8.2 วิธีการประเมินดัชนีความเชื่อถือได้เมื่อเพิ่มกำลังการผลิตจากพลังงานลม	84
8.3 ข้อเสนอแนะ	84
เอกสารอ้างอิง	85
ภาคผนวก ก. ข้อมูลสมรรถนะเครื่องกำเนิดไฟฟ้า	88
ภาคผนวก ข. ข้อมูลระบบทดสอบสำหรับการเรียนรู้ของ ANN และ ANFIS	93
ภาคผนวก ค. ผลการลองผิดลองถูกของ ANN และ ANFIS	99
ภาคผนวก ง. รายการคำย่อและสัญลักษณ์	118
ภาคผนวก จ. เอกสารที่ได้รับการตีพิมพ์	120
ประวัติผู้เขียน	142

สารบัญตาราง

ตารางที่	หน้า
2.1 ข้อมูลสำหรับฝึกสอน 27 ข้อมูล	13
2.2 ข้อมูลสำหรับทดสอบ 5 ข้อมูล	14
2.3 ผลลัพธ์ที่ดีที่สุดที่ได้จากการเรียนรู้ของ ANN	16
3.1 การส่งผ่านในกระบวนการเรียนรู้แบบไฮบริดสำหรับ ANFIS	28
3.2 ผลลัพธ์ที่ดีที่สุดที่ได้จากการเรียนรู้ของ ANFIS	31
5.1 ตาราง COPT ของระบบทดสอบ IEEE Reliability Test System	48
5.2 ตารางแสดงผลคำนวณดัชนี EENS	49
6.1 ข้อมูลที่ใช้ในการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม	51
6.2 แสดงการเปรียบเทียบค่าพารามิเตอร์รูปร่างสำหรับการกระจายแบบไวบูลล์	53
6.3 แสดงการเปรียบเทียบระหว่างข้อมูลพลังงานลมจากสถานีแหลมพรหมเทพ ภูเก็ตกับ ข้อมูลจากการกระจายแบบไวบูลล์ของกังหันลมขนาด 150 kW	56
6.4 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ โครงข่ายประสาทเทียม	57
6.5 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ ระบบอนุमानนิวโรฟซีแบบปรับตัวได้	58
6.6 ค่าพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้วิธีการจำลองข้อมูลแบบต่างๆ.....	60
7.1 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ โครงข่ายประสาทเทียม	65
7.2 โครงสร้างที่ดีที่สุดของการทดสอบโดยใช้ระบบอนุमानนิวโรฟซีแบบปรับตัวได้	67
7.3 โครงสร้างที่ดีที่สุดของการประเมินดัชนี EENS โดยใช้โครงข่ายประสาทเทียม	70
7.4 โครงสร้างที่ดีที่สุดของการประเมินดัชนี EENS โดยใช้ระบบอนุमानนิวโรฟซีแบบปรับตัว ได้	72
7.5 เปรียบเทียบผลการทดสอบระหว่าง ANN และ ANFIS บนระบบ IEEE RTS	75
7.6 เปรียบเทียบค่าเอาท์พุท ANN และ ANFIS	75
7.7 เปรียบเทียบผลการทดสอบระหว่าง ANN และ ANFIS บนระบบไฟฟ้าประเทศไทย	78
7.8 เปรียบเทียบค่าเอาท์พุท ANN และ ANFIS	78

สารบัญรูป

รูปที่	หน้า
2.1 นิเวรอน 1 อินพุทแบบไม่มีค่าไบแอส	5
2.2 นิเวรอน 1 อินพุทแบบมีค่าไบแอส	5
2.3 นิเวรอน R อินพุทแบบมีค่าไบแอส	5
2.4 Linear transfer function	6
2.5 Log-sigmoid transfer function	6
2.6 Tan-sigmoid transfer function	7
2.7 โครงสร้างของ Multi-Layer Feed-forward Neural Networks	7
2.8 แผนภาพแสดงการเรียนรู้ของ ANN เพื่อหาผลลัพธ์ที่ดีที่สุด	15
2.9 ค่าผิดพลาดเฉลี่ยที่ดีที่สุดของข้อมูลทดสอบที่เกิดจากการเรียนรู้ของ ANN โดยใช้โปรแกรม MATLAB	16
2.10 เปรียบเทียบระหว่างค่าเอาต์พุทจริงและค่าเอาต์พุทที่ได้จาก ANN	17
3.1 โครงสร้างพื้นฐานของระบบฟัซซี	18
3.2 โครงสร้างของระบบอนุมานฟัซซีแบบปรับตัวได้	20
3.3 Triangular-shaped membership function	23
3.4 Trapezoidal-shaped membership function	24
3.5 Generalized bell-shaped membership function	24
3.6 Gaussian curve membership function	25
3.7 Gaussian combination membership function	25
3.8 π -shaped membership function	26
3.9 Difference of two sigmoidal membership function	27
3.10 Product of two sigmoidal membership function	27
3.11 ลักษณะกราฟข้อมูลสำหรับฝึกสอนและทดสอบบน ANFIS Toolbox	29
3.12 ป้อนค่า MFs และเลือกชนิดของ MFs บน ANFIS Toolbox	29
3.13 การฝึกสอน (Training) บน ANFIS Toolbox	30
3.14 การทดสอบ (Testing) บน ANFIS Toolbox	30
3.15 โครงสร้างของฟังก์ชันสมาชิกเมื่อปรับค่า MFs 6 3 2 บน ANFIS Toolbox	31
3.16 เปรียบเทียบระหว่างค่าเอาต์พุทจริงและค่าเอาต์พุทที่ได้จาก ANFIS	32
4.1 กังหันลมผลิตไฟฟ้าแบบแกนนอนและแบบแกนตั้ง	34
4.2 ความสัมพันธ์ระหว่างความเร็วลมและกำลังผลิตไฟฟ้า	34
4.3 การสุ่มค่าความเร็วลม	36
4.4 การแปลงความเร็วลมสู่กำลังผลิตไฟฟ้า	36
4.5 กำลังไฟฟ้าที่ผลิตได้จากกังหันลม Nordtank ขนาด 150 kW	37
5.1 ขอบเขตการทำงานพื้นฐานในระบบไฟฟ้ากำลัง	38
5.2 แบบจำลองระบบสำหรับการประเมินความเชื่อถือได้ในระดับชั้นที่ 1	39
5.3 แบบจำลองที่ใช้ในการประเมินค่าความเชื่อถือได้ของระบบผลิตไฟฟ้า	39
5.4 ลักษณะการทำงานของอุปกรณ์ในระบบไฟฟ้า	40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.5 การทำงานค่าสถานะการณ์ทำงานเฉลี่ยของอุปกรณ์ในระบบไฟฟ้า	41
5.6 แบบจำลองมาร์คอฟฟ์ 2 สถานะสำหรับเครื่องกำเนิดไฟฟ้า	42
5.7 เส้นโค้งโหลดรายชั่วโมง	44
5.8 เส้นโค้งช่วงระยะเวลาของโหลด	46
5.9 การคำนวณค่าดัชนี EENS	46
5.10 โหลดรายชั่วโมงของระบบตัวอย่าง IEEE-RTS	47
5.11 เส้นโค้งระยะเวลาสะสมของโหลดรายชั่วโมงของระบบ IEEE RTS	49
5.12 โหลดสะสมรายชั่วโมงของประเทศไทย	50
6.1 ฟังก์ชันความน่าจะเป็นของความเร็วลมเมื่อพารามิเตอร์รูปร่าง $k = 2$	54
6.2 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากการกระจายแบบไวบูลล์	56
6.3 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากโครงข่ายประสาทเทียม	57
6.4 ผลการฝึกสอนโดยใช้ ANFIS (MFs 8 2 4) บน MATLAB ANFIS Toolbox	58
6.5 ผลการทดสอบโดยใช้ ANFIS (MFs 8 2 4) บน MATLAB ANFIS Toolbox	58
6.6 โครงสร้าง MFs 8 2 4 บน MATLAB ANFIS Toolbox	59
6.7 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากระบบอนุมานนิวโรฟัชซีแบบปรับตัวได้	59
6.8 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากการจำลองทั้ง 3 วิธี	62
7.1 ผลการทดสอบที่มีค่าผิดพลาดน้อยที่สุด บน MATLAB	65
7.2 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANN	66
7.3 แสดงผลการฝึกสอนของ ANFIS บน MATLAB ANFIS Toolbox	67
7.4 แสดงผลการทดสอบของ ANFIS บน MATLAB ANFIS Toolbox	67
7.5 โครงสร้าง MFs 5 2 4 บน MATLAB ANFIS Toolbox	68
7.6 แสดงลักษณะของฟังก์ชันสมาชิกชนิด trimf	68
7.7 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANFIS	69
7.8 ผลการทดสอบที่มีค่าผิดพลาดน้อยที่สุด บน MATLAB	71
7.9 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANN	71
7.10 แสดงผลการฝึกสอนของ ANFIS บน MATLAB ANFIS Toolbox	73
7.11 แสดงผลการทดสอบของ ANFIS บน MATLAB ANFIS Toolbox	73
7.12 โครงสร้าง MFs 6 1 9 บน MATLAB ANFIS Toolbox	73
7.13 แสดงลักษณะของฟังก์ชันสมาชิกชนิด pimf	74
7.14 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANFIS	74
7.15 แสดงการเปรียบเทียบดัชนี EENS ระหว่าง ANN และ ANFIS	77
7.16 แสดงการเปรียบเทียบดัชนี EENS ระหว่าง ANN และ ANFIS	81

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

พลังงานไฟฟ้าเป็นสาธารณูปโภคพื้นฐานที่สำคัญต่อการพัฒนาสังคมและเศรษฐกิจของประเทศ ทำให้ต้องมีการวางแผนให้ระบบไฟฟ้ามีความเชื่อถือได้ตามเกณฑ์ที่กำหนดและสอดคล้องกับความต้องการใช้ไฟฟ้าที่เพิ่มสูงขึ้นในแต่ละปี

การผลิตพลังงานไฟฟ้าต้องอาศัยการเปลี่ยนรูปพลังงานรูปอื่น ๆ มาเป็นพลังงานไฟฟ้า เช่น การเปลี่ยนพลังงานกลเป็นพลังงานไฟฟ้าโดยใช้หลักการเหนี่ยวนำไฟฟ้า เป็นต้น ซึ่งต้องอาศัยแหล่งเชื้อเพลิงในการผลิตไฟฟ้า โดยนับจากอดีตถึงปัจจุบัน แหล่งพลังงานสำคัญที่สุดที่นำมาใช้ในการผลิตไฟฟ้า คือ เชื้อเพลิงฟอสซิล อันได้แก่ น้ำมันเชื้อเพลิง ก๊าซธรรมชาติ ถ่านหิน เป็นต้น นอกจากนี้ยังมีแหล่งพลังงานที่สามารถนำมาใช้ในอุตสาหกรรมผลิตไฟฟ้าอื่น ๆ อีก เช่น พลังงานนิวเคลียร์ พลังงานน้ำ พลังงานลม พลังงานแสงอาทิตย์ ฯลฯ

พลังงานหมุนเวียนเกิดจากแหล่งพลังงานที่เกิดขึ้นซ้ำเรื่อย ๆ ไม่หมดไป เช่น พลังงานแสงอาทิตย์ พลังงานลม ความร้อนจากใต้พิภพ ชีวมวลหรือพวกของเสียจากการกสิกรรม เป็นต้น ปัจจุบันทั่วโลกกำลังมีความสนใจในเรื่องการพัฒนาอย่างยั่งยืน ซึ่งเรื่อง พลังงานหมุนเวียน [15] ก็ถือเป็นหัวใจหลักของการพัฒนาดังกล่าวควบคู่กับการนำวัสดุกลับมาใช้ใหม่ เนื่องจากพลังงานหมุนเวียนจะไม่มีวันหมดไป แต่จะเกิดเวียนซ้ำ ดังนั้นความสำคัญของพลังงานหมุนเวียนจึงมีความสำคัญเพิ่มขึ้นอย่างมาก

สำหรับในประเทศไทยนั้น พลังงานที่ใช้ประโยชน์ในปัจจุบันและมีแนวโน้มที่จะถูกพัฒนามากขึ้นในอนาคต ได้แก่ พลังงานลม เห็นได้จากการเพิ่มขึ้นของการติดตั้งกังหันลมผลิตไฟฟ้าในหลายๆ ที่ แต่เนื่องจากการที่พลังงานลม ไม่สามารถทำการกำหนดการจ่ายกำลังไฟฟ้าตามที่ต้องการได้อย่างแน่นอนเนื่องจากความเร็วลมมีค่าไม่คงที่ [17] ซึ่งสิ่งเหล่านี้เป็นปัจจัยที่อ้างอิงกับธรรมชาติ ในการสนับสนุนการผลิตไฟฟ้าจากพลังงานลมให้เกิดขึ้นในประเทศ จึงสมควรต้องมีการศึกษาถึงคุณค่าทั้งทางด้านเศรษฐศาสตร์ ด้านสังคมสิ่งแวดล้อม และด้านวิศวกรรมไฟฟ้า เพื่อทำการประเมินการผลิตไฟฟ้าจากพลังงานลมที่มีต่อความเชื่อถือได้ของระบบผลิตไฟฟ้า ซึ่งอาจนำไปใช้เป็นแนวทางสำหรับส่งเสริมการผลิตไฟฟ้าจากพลังงานลมที่เหมาะสมต่อไป

ปัจจุบันการวางแผนขยายหน่วยการผลิตในอนาคตจำเป็นต้องมีการประเมินดัชนีความเชื่อถือได้ของระบบผลิต เพื่อพิจารณาความเพียงพอของการผลิตไฟฟ้าที่จะสามารถตอบสนองต่อความต้องการใช้ไฟฟ้าในอนาคตได้ [14] ดังนั้นดัชนีที่สำคัญต่อการพิจารณาคือดัชนี Expected Energy Not Supplied (EENS) ซึ่งเป็นดัชนีที่บ่งบอกถึงค่าพลังงานที่คาดว่าจะไม่ได้รับการจ่ายจากระบบผลิตไฟฟ้าอันเนื่องมาจากโหลดมีค่ามากกว่าปริมาณกำลังการผลิตที่มีอยู่ ซึ่งเป็นดัชนีที่นำเอาปริมาณความต้องการไฟฟ้า และสมรรถนะของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องของแต่ละโรงไฟฟ้ามาประกอบการพิจารณา โดยสามารถประเมินดัชนีนี้ได้หลายวิธี ได้แก่ วิธีการทางความน่าจะเป็น (Probabilistic method), variance reduction [26], pseudo-simulation [27]-[29], วิธีโครงข่ายประสาทเทียม (Artificial Neural Networks : ANN) [8], [12], [18], วิธีระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้ [22] (Adaptive Neuro-Fuzzy Inference Systems : ANFIS) เป็นต้น โดยวิธีการเหล่านี้สามารถ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประเมินดัชนีความเชื่อถือได้เพื่อประกอบการตัดสินใจในแผนการเพิ่มโรงไฟฟ้าให้เพียงพอต่อความต้องการใช้ไฟฟ้าในอนาคตตามแผนพัฒนาด้านพลังงานได้

ในวิทยานิพนธ์นี้นำเสนอวิธีการประเมินดัชนีความเชื่อถือได้ด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Networks : ANN) ซึ่งโครงข่ายประสาทเทียมที่เลือกเป็นแบบมีหลายชั้นชนิดแพร่ค่าย้อนกลับ เปรียบเทียบกับระบบอนุมานนิวโรฟซซีแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems : ANFIS) ซึ่งเป็นการเรียนรู้แบบระบบผสมระหว่างโครงข่ายประสาทเทียมรวมกับกฎของฟuzzy โดยกำหนดให้การจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate เป็นอินพุท และดัชนี Expected Energy Not Supplied เป็นเอาท์พุท โดยข้อมูลที่ถูกป้อนเข้าไปในการเรียนรู้มาจากการคำนวณทางสถิติและความน่าจะเป็น เพื่อนำเสนอวิธีการที่สามารถประเมินค่าได้อย่างรวดเร็วและมีความถูกต้องแม่นยำมากกว่าวิธีการคำนวณแบบดั้งเดิม รวมทั้งพิจารณาข้อดีและข้อเสียของแต่ละวิธีสำหรับเป็นทางเลือกในการวางแผนการประเมินค่าดัชนีความเชื่อถือได้ของระบบผลิตในระยะยาวต่อไป โดยในวิทยานิพนธ์นี้เพิ่มวิธีจำลองข้อมูลพลังงานลมด้วยวิธีการกระจายข้อมูลแบบไวบูลล์, วิธีโครงข่ายประสาทเทียม และวิธีระบบอนุมานนิวโรฟซซีแบบปรับตัวได้ โดยใช้ข้อมูลค่าพลังงานที่ผลิตได้ย้อนหลัง 2 เดือน, ค่าพลังงานที่ผลิตได้ย้อนหลัง 1 เดือน และความเร็วลมเฉลี่ยเป็นอินพุท และค่าพลังงานที่ผลิตได้เป็นเอาท์พุท โดยข้อมูลที่ถูกป้อนเข้าไปในการเรียนรู้มาจากค่าที่บันทึกไว้ของการผลิตไฟฟ้าจากกังหันลมของสถานีพลังงานทดแทน แผลมพรหมเทพ จังหวัดภูเก็ต ซึ่งเป็นกรณีศึกษาสำหรับแผนการเพิ่มการผลิตเกี่ยวกับพลังงานหมุนเวียนที่เป็นพลังงานทางเลือกที่กำลังสนใจกันอยู่ในปัจจุบัน เนื่องจากความเร็วลมมีค่าไม่คงที่ทำให้การจำลองข้อมูลที่เหมาะสมของแต่ละพื้นที่มีความสำคัญต่อการเพิ่มการผลิตเป็นอย่างมาก ดังนั้นจะทำให้สามารถพิจารณาวิธีการประเมินดัชนีความเชื่อถือได้ตามแผนการเพิ่มกำลังการผลิตที่เหมาะสมที่สุดได้

1.2 วัตถุประสงค์ของการศึกษา

1. เพื่อนำเสนอการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าด้วยวิธีโครงข่ายประสาทเทียม
2. เพื่อนำเสนอการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าด้วยวิธีระบบอนุมานนิวโรฟซซีแบบปรับตัวได้
3. เพื่อนำเสนอการเปรียบเทียบระหว่างการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าวิธีโครงข่ายประสาทเทียมและวิธีระบบอนุมานนิวโรฟซซีแบบปรับตัวได้ และหาวิธีที่ให้ผลลัพธ์ที่ดีที่สุด
4. เพื่อนำเสนอวิธีการจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมด้วยวิธีการกระจายข้อมูลแบบไวบูลล์
5. เพื่อนำเสนอวิธีการจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมด้วยวิธีโครงข่ายประสาทเทียม
6. เพื่อนำเสนอวิธีการจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมด้วยวิธีระบบอนุมานนิวโรฟซซีแบบปรับตัวได้
7. เพื่อนำเสนอการเปรียบเทียบการจำลองข้อมูลด้วยวิธีการกระจายข้อมูลแบบไวบูลล์, วิธีโครงข่ายประสาทเทียม และวิธีระบบอนุมานนิวโรฟซซีแบบปรับตัวได้ รวมทั้งหาวิธีที่ให้ผลลัพธ์ที่ดีที่สุดและเหมาะสมต่อการนำไปใช้มากที่สุด

1.3 ขอบเขตของการศึกษา

1. ศึกษาวิธีการจำลองข้อมูลจากพลังงานลมโดยใช้ข้อมูลจากสถานีพลังงานทดแทน แหลมพรหมเทพ จังหวัดภูเก็ตซึ่งเป็นข้อมูลจริงที่ถูกบันทึกไว้
2. ศึกษาและรวบรวมข้อมูลระบบการผลิตไฟฟ้าของไทย ในลักษณะเป็นข้อมูลทุติยภูมิโดยไม่ได้เป็นการเก็บสถิติการทำงานจากโรงไฟฟ้าโดยตรง โดยพิจารณาเฉพาะเครื่องกำเนิดไฟฟ้าที่ใช้เชื้อเพลิงจากธรรมชาติ
3. การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าจะไม่คำนึงถึงผลจากสายส่งและสายจำหน่าย
4. การประเมินความเชื่อถือได้จะพิจารณาจากดัชนี EENS
5. กำลังผลิตจากกังหันลมพิจารณาจากแผนพัฒนาศักยภาพพลังงานทดแทน กระทรวงพลังงาน โดยจะเพิ่มกังหันลมขนาด 0.15 MW จำนวน 10 เครื่องลงในระบบผลิต
6. กระบวนการเรียนรู้ของ ANN และ ANFIS ในแต่ละกรณีจะใช้ข้อมูลชุดเดียวกันในการเปรียบเทียบ
7. กระบวนการเรียนรู้ของ ANN และ ANFIS ทำบนโปรแกรม MATLAB R2017a (Student license) และรันโปรแกรมบนคอมพิวเตอร์ Window 7 enterprise (Intel core i5-3550 CPU 3.30 GHz 64-bit)
8. ANFIS ถูกรันบน MATLAB ANFIS Toolbox
9. ANN ถูกรันบน MATLAB ANN ที่ถูกปรับปรุงโครงสร้างเป็น 2 ชั้นซ่อน และ 1 เอาท์พุท

1.4 ขั้นตอนของการศึกษา

1. ศึกษาทฤษฎีพื้นฐานเกี่ยวกับการประเมินความเชื่อถือได้สำหรับระบบผลิตไฟฟ้ากำลัง
2. ศึกษาวิธีการจำลองข้อมูลเกี่ยวกับพลังงานลม
3. รวบรวมข้อมูลเกี่ยวกับระบบที่จะนำมาใช้ทดสอบ และข้อมูลอื่นๆที่จำเป็น
4. ศึกษาทฤษฎีพื้นฐานเกี่ยวกับโครงข่ายประสาทเทียม
5. ศึกษาทฤษฎีพื้นฐานเกี่ยวกับระบบอนุมานนิเวโรฟฟิซซีแบบปรับตัวได้
6. ศึกษาวิธีการใช้งาน ANFIS Toolbox บน MATLAB

1.5 ประโยชน์ที่คาดว่าจะได้รับจากการศึกษา

1. สามารถจำลองข้อมูลเกี่ยวกับการผลิตไฟฟ้าจากพลังงานลมได้เหมาะสมต่อการนำไปใช้มากที่สุด
2. สามารถประเมินดัชนีความเชื่อถือได้ของระบบผลิตเมื่อเพิ่มกำลังผลิตไฟฟ้าจากพลังงานลมได้
3. สามารถเลือกใช้วิธีการที่ให้ผลลัพธ์ที่ดีที่สุด และมีประสิทธิภาพที่สุดในการประเมินดัชนีความเชื่อถือได้

บทที่ 2

โครงข่ายประสาทเทียม

2.1 พื้นฐานของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial Neural Networks หรือ ANN) ประกอบด้วยเซลล์ประสาท (neuron) ที่จำลองมาจากการทำงานของสมองมนุษย์ด้วยการทำงานแบบเชื่อมต่อกัน การปรับค่าพารามิเตอร์ที่เชื่อมต่อกันระหว่างหน่วยพื้นฐานจะเป็นการสอนให้เกิดกระบวนการเรียนรู้และจดจำข้อมูลหรือฟังก์ชันซับซ้อนต่างๆ ของโครงข่ายประสาทเทียมเพื่อนำไปประยุกต์ใช้ในการแก้ปัญหาต่างๆ เช่น ด้านวิศวกรรม แพทย์ คณิตศาสตร์ เศรษฐศาสตร์ เป็นต้น

ประเภทของโครงข่ายประสาทเทียมแบ่งออกเป็น 2 ประเภท [20] ได้แก่

1. โครงข่ายประสาทเทียมแบบมีผู้ฝึกสอน (Supervised Neural Networks) แบ่งเป็น 2 ชนิด ได้แก่

1.1 Multi-Layer Feed Forward

1.2 Radial Basis Function

2. โครงข่ายประสาทเทียมแบบไม่มีผู้ฝึกสอน (Unsupervised Neural Networks) แบ่งเป็น 2 ชนิด ได้แก่

2.1 Kohonen Network

2.2 Hopfield Network

ในวิทยานิพนธ์ฉบับนี้จะกล่าวถึงเฉพาะโครงข่ายประสาทเทียมแบบมีผู้ฝึกสอน (Supervised Neural Networks) ชนิด Multi-Layer Feed Forward เนื่องจากมีการนำมาประยุกต์ใช้งานในระบบไฟฟ้ากำลังอย่างแพร่หลาย

2.2 โครงข่ายประสาทเทียมแบบมีผู้ฝึกสอน


ลักษณะโครงข่ายประสาทเทียมแบบมีผู้ฝึกสอนจะต้องใช้ข้อมูลอินพุตและเอาต์พุตที่เตรียมไว้แล้ว นำมาป้อนเข้าไปในกระบวนการเรียนรู้เพื่อให้เกิดการเรียนรู้และจดจำข้อมูลความสัมพันธ์ในรูปแบบต่างๆ แล้วแสดงผลออกมาเป็นเอาต์พุตของโครงข่ายประสาทเทียม

2.2.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น

โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น (Multi-Layer Feed Forward Neural Networks) จะมีการเชื่อมโยงจะเกิดขึ้นระหว่างชั้นที่ติดกัน โดยเชื่อมโยงระหว่างเซลล์ประสาททุกตัวจากชั้นหนึ่งไปยังเซลล์ประสาททุกตัวในชั้นถัดไป ซึ่งเป็น Neural Networks ที่นิยมนำมาใช้งานเป็นส่วนมาก ประกอบด้วยส่วนสำคัญดังนี้


2.2.1.1 แบบจำลองของนิวรอน

นิวรอนที่มี 1 อินพุตแบบไม่มีค่าไบแอส [20]แสดงดังรูปที่ 2.1 และแบบมีค่าไบแอสแสดงดังรูปที่ 2.2



$$a = F(w * p)$$


รูปที่ 2.1 นิวรอน 1 อินพุทแบบไม่มีค่าไบแอส



$$a = F(w * p + b)$$

รูปที่ 2.2 นิวรอน 1 อินพุทแบบมีค่าไบแอส

นิวรอนที่มี R อินพุทแบบมีค่าไบแอสแสดงดังรูปที่ 2.3



$$a = F(w * p + b)$$

$$n = p_1 * w(1,1) + p_2 * w(1,2) + \dots + p_R * w(1,R) + b$$

รูปที่ 2.3 นิวรอน R อินพุทแบบมีค่าไบแอส

โดยที่	p	คือ	อินพุท
	w	คือ	ค่าถ่วงน้ำหนัก (Weight)
	b	คือ	ค่าไบแอส (Bias)
	F	คือ	ฟังก์ชันถ่ายโอน (Transfer function)

ถ้าค่าอินพุทถูกคูณกับค่าถ่วงน้ำหนักและนำผลคูณทั้งหมดไปรวมกับค่าไบแอสที่จุดเชื่อมต่อ แล้วส่งค่าไปยังฟังก์ชันถ่ายโอนจะได้ค่าเอาต์พุท ค่าไบแอสจะมีค่ามากกว่าค่าถ่วงน้ำหนัก ยกเว้นกรณีอินพุทมีค่าคงที่ ค่าไบแอสจะเท่ากับหนึ่ง โดยวิทยานิพนธ์นี้เลือกใช้นิวรอนหลายอินพุทแบบมีค่าไบแอส


2.2.1.2 ฟังก์ชันถ่ายโอน

ฟังก์ชันถ่ายโอน (transfer Function) สามารถเลือกใช้ในกลุ่มเครื่องมือของโปรแกรม MATLAB การเลือกฟังก์ชันถ่ายโอนที่เหมาะสมจะมีผลต่อประสิทธิภาพของโครงข่ายประสาทเทียม ประกอบด้วย 3 ฟังก์ชัน [13], [20] ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Linear transfer function) เป็นฟังก์ชันที่ใช้กับโครงข่ายประสาทเทียมแบบตัวกรองเชิงเส้นทางด้านเอาต์พุต ในโปรแกรม MATLAB ใช้คำสั่งว่า “purelin” อธิบายตามสมการที่ (2.1)


$$a(n) = n \quad (2.1)$$



รูปที่ 2.4 Linear transfer function

2. ฟังก์ชันถ่ายโอนแบบล็อกซิกมอยด์ (Log-sigmoid transfer function) เป็นฟังก์ชันที่เอาต์พุตอยู่ระหว่าง 0 ถึง 1 ในโปรแกรม MATLAB ใช้คำสั่งว่า “logsig” อธิบายตามสมการที่ (2.2)


$$a(n) = \frac{1}{1 + e^{-n}} \quad (2.2)$$



รูปที่ 2.5 Log-sigmoid transfer function

3. ฟังก์ชันถ่ายโอนแบบแทนซิกมอยด์ (Tan-sigmoid transfer function) เป็นฟังก์ชันที่เอาต์พุตอยู่ระหว่าง -1 ถึง 1 ในโปรแกรม MATLAB ใช้คำสั่งว่า “tansig” อธิบายตามสมการที่ (2.3)

$$a(n) = \frac{1 - e^{-n}}{1 + e^{-n}} \tag{2.3}$$

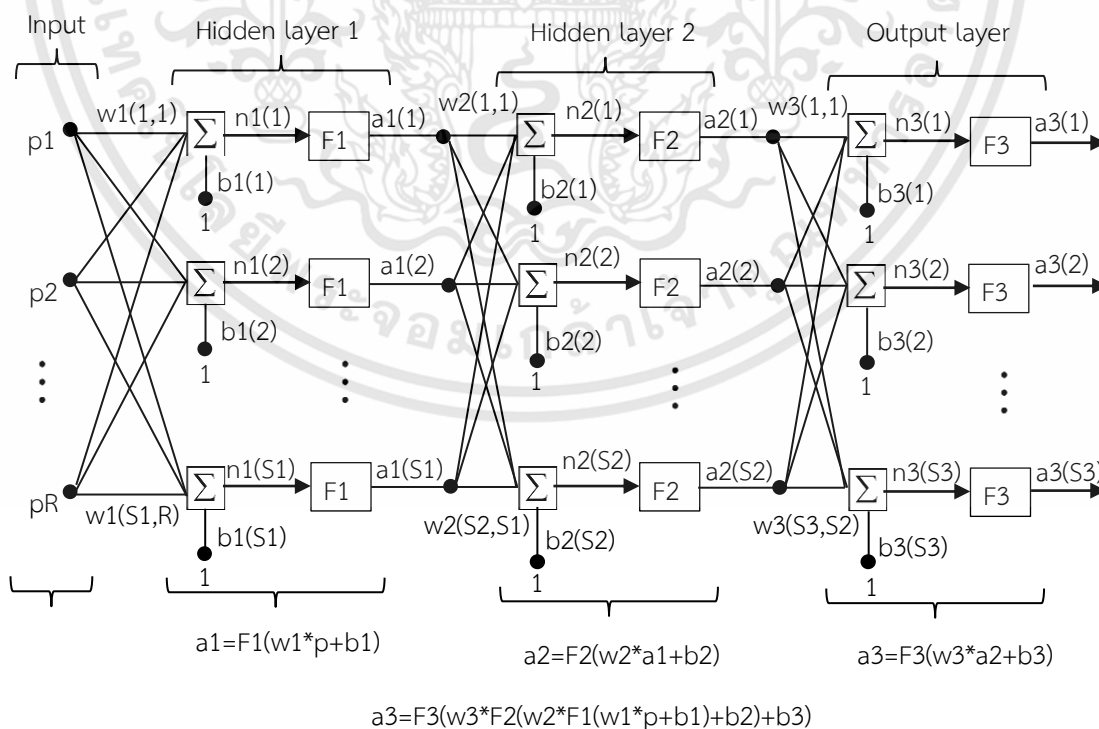


รูปที่ 2.6 Tan-sigmoid transfer function

โดยที่ a คือ เอาท์พุทของฟังก์ชันถ่ายโอน
 n คือ อินพุทที่ผ่านเข้ามายังฟังก์ชันถ่ายโอน

2.2.2 โครงสร้างของโครงข่ายประสาทเทียม

เมื่อนำนิวรอนหลายๆ ตัวมาเรียงขนานกันจะประกอบขึ้นเป็นชั้น (Layer) และถ้านำแต่ละชั้นมาเรียงอนุกรมกันจะเป็น Multi-Layer หรือเรียกว่า Multi-Layer Feed-forward Neural Networks [13], [20]



รูปที่ 2.7 โครงสร้างของ Multi-Layer Feed-forward Neural Networks [20]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ซึ่งเป็นโครงสร้างที่นิยมใช้กันอย่างแพร่หลายประกอบด้วยชั้นต่างๆ 3 ชั้น ได้แก่ ชั้นข้อมูลอินพุท (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นข้อมูลเอาต์พุท (Output Layer) โดยที่ชั้นซ่อนอาจมีมากกว่าหนึ่งชั้น ในแต่ละชั้นจะมีการเชื่อมโยงด้วยค่าถ่วงน้ำหนักและค่าไบแอส

จากรูปที่ 2.7 แสดงโครงข่ายประสาทเทียมที่ประกอบด้วยชั้นอินพุท, ชั้นซ่อนที่ 1, ชั้นซ่อนที่ 2 และชั้นเอาต์พุท แต่ละชั้นจะมีการเชื่อมโยงด้วยค่าถ่วงน้ำหนักและค่าไบแอส โดย a_1 , a_2 , a_3 คือเอาต์พุทของชั้นซ่อนที่ 1, ชั้นซ่อนที่ 2 และชั้นเอาต์พุท ตามลำดับ F_1 , F_2 , F_3 คือฟังก์ชันถ่ายโอนของชั้นซ่อนที่ 1, ชั้นซ่อนที่ 2 และชั้นเอาต์พุท ตามลำดับ

ค่า Error $e(i)$ เมื่อ $i = 1, 2, 3, \dots, s_3$ ที่ชั้นเอาต์พุทคือผลต่างของเอาต์พุท $a_3(i)$ ของโครงข่ายประสาทเทียมและค่าเป้าหมาย $t(i)$ ตามสมการที่ (2.4)

$$e(i) = t(i) - a_3(i) \quad ; \quad i = 1, 2, \dots, s_3 \quad (2.4)$$

โครงสร้างของโครงข่ายประสาทเทียมที่ใช้ในวิทยานิพนธ์นี้ ประกอบด้วยชั้นอินพุท, ชั้นซ่อนที่ 1, ชั้นซ่อนที่ 2 และชั้นเอาต์พุท ในแต่ละชั้นจะมีการเชื่อมโยงด้วยค่าถ่วงน้ำหนักและค่าไบแอส

การเลือกจำนวนนิวรอนในแต่ละชั้นซ่อนจากการลองผิดลองถูก เริ่มจากจำนวนนิวรอนน้อย ๆ และถูกเพิ่มมากขึ้นเรื่อยๆ จนถึงค่าสูงสุดที่ตั้งไว้ โดยกำหนดให้ชั้นซ่อนที่ 1 มีจำนวนนิวรอนมากกว่าชั้นซ่อนที่ 2 อยู่ 1 ตัว

2.2.3 ขั้นตอนวิธีการเรียนรู้

ในการฝึกสอนโครงข่ายประสาทเทียมนั้นจะต้องเตรียมข้อมูลฝึกสอนไว้ และอาศัยขั้นตอนวิธีการเรียนรู้เพื่อมาปรับพารามิเตอร์ 2 ตัวที่สำคัญในกระบวนการเรียนรู้คือค่าถ่วงน้ำหนัก และค่าไบแอส สำหรับ Multi-Layer Feed Forward Neural Networks มักจะนิยมใช้ขั้นตอนวิธีการเรียนรู้แบบแพร่ค่าย้อนกลับ (Back-Propagation Learning) [13], [20] โดยชนิดของฟังก์ชันถ่ายโอนที่นิยมใช้ คือ Log-sigmoid, Tan-sigmoid และ Linear โดยเฉพาะข้อมูลฝึกสอนที่มีจำนวนมากและมีความสัมพันธ์ไม่เป็นเชิงเส้น (Non-linear)

2.2.3.1 วิธีการเรียนรู้แบบแพร่ค่าย้อนกลับ

วิธีการเรียนรู้แบบแพร่ค่าย้อนกลับ (Back-Propagation Learning) หลักการคือการปรับค่าถ่วงน้ำหนักและค่าไบแอส ตามสมการที่ (2.5) และ (2.6) ตามลำดับ เพื่อให้ค่า Sum-Square Error (SSE) ตามสมการที่ (2.7) มีค่าลดลงเข้าใกล้ศูนย์

$$w_{\text{new}} = w_{\text{old}} + \Delta w \quad (2.5)$$

$$b_{\text{new}} = b_{\text{old}} + \Delta b \quad (2.6)$$

$$SSE = \sum_{i=1}^N (t_i - a_i)^2 \quad (2.7)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่	N	คือ	จำนวนของข้อมูลฝึกสอน
	w	คือ	ค่าถ่วงน้ำหนัก (Weight)
	b	คือ	ค่าไบแอส (Bias)
	t_i	คือ	ค่าเอาต์พุตเป้าหมาย
	a_i	คือ	ค่าเอาต์พุตของโครงข่ายประสาทเทียม
	SSE	คือ	Sum-Square Error

2.2.3.2 Levenberg-Marquardt Algorithm

กระบวนการเรียนรู้แบบแพร่ค่าย้อนกลับแบ่งออกเป็น 2 วิธี คือ Gradient Descent Algorithm และ Levenberg-Marquardt Algorithm ในวิทยานิพนธ์ฉบับนี้จะกล่าวถึงเฉพาะกระบวนการเรียนรู้แบบแพร่ค่าย้อนกลับด้วยวิธี Levenberg-Marquardt Algorithm [13], [20] เนื่องจากวิธีนี้มีประสิทธิภาพดีกว่าและใช้จำนวนรอบ (Epochs) ในการฝึกสอนน้อยกว่าทำให้ใช้เวลารวมในการฝึกสอนน้อยกว่า โดยทุกอินพุตจะถูกป้อนเข้าไปในโครงข่ายประสาทเทียมในแต่ละรอบของการคำนวณ ในระหว่างการฝึกสอนค่าถ่วงน้ำหนักและค่าไบแอสจะถูกปรับเปลี่ยนค่า ตามสมการที่ (2.8) และ (2.9) ตามลำดับ

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w) \cdot e \quad (2.8)$$

$$\Delta b = [J^T(b)J(b) + \mu I]^{-1} J^T(b) \cdot e \quad (2.9)$$

$$J(w) = \begin{bmatrix} \frac{\partial e(1)}{\partial w_3(1,1)} & \frac{\partial e(1)}{\partial w_3(1,2)} & \dots & \frac{\partial e(1)}{\partial w_3(1,s_2)} \\ \frac{\partial e(2)}{\partial w_3(2,1)} & \frac{\partial e(2)}{\partial w_3(2,2)} & \dots & \frac{\partial e(2)}{\partial w_3(2,s_2)} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e(s_3)}{\partial w_3(s_3,1)} & \frac{\partial e(s_3)}{\partial w_3(s_3,2)} & \dots & \frac{\partial e(s_3)}{\partial w_3(s_3,s_2)} \end{bmatrix} \quad (2.10)$$

$$J(b) = \begin{bmatrix} \frac{\partial e(1)}{\partial b_3(1)} \\ \frac{\partial e(2)}{\partial b_3(2)} \\ \vdots \\ \frac{\partial e(s_3)}{\partial b_3(s_3)} \end{bmatrix} \quad (2.11)$$

โดยที่ $J(w)$ คือ Jacobian Matrix ของอนุพันธ์ของ Error เทียบกับค่าถ่วงน้ำหนัก ตามสมการที่ (2.10)

$J(b)$ คือ Jacobian Matrix ของอนุพันธ์ของ Error เทียบกับค่าไบแอส ตามสมการที่ (2.11)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- e คือ Matrix ของ Error ระหว่างข้อมูลเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียม
- μ คือ ค่าคงที่ ซึ่งค่าเริ่มต้นจะถูกตั้งค่าไว้ค่าต่ำๆ เช่น 0.001

ระหว่างการฝึกสอน μ จะถูกคูณด้วยค่าคงที่เช่น 10 ถ้า SSE ใหม่มีค่าเพิ่มขึ้นและจะถูกลดด้วย 10 ถ้า SSE ใหม่มีค่าลดลง

ถ้า norm ของ $J^T(w) \cdot e$ หรือ $J^T(b) \cdot e$ มีค่าน้อยกว่าค่าต่ำสุดที่กำหนดไว้หรือ μ มีค่ามากกว่าค่าสูงสุดที่กำหนดไว้ โปรแกรมที่ฝึกสอนโครงข่ายประสาทเทียมจะหยุดการฝึกสอนทันที

โดยทั่วไปค่าที่ได้จากการสุ่มที่มีค่าน้อยๆ ระหว่าง 0 ถึง 1 ของค่าถ่วงน้ำหนักและค่าไบแอสมักถูกใช้เป็นพารามิเตอร์เริ่มต้นของการเรียนรู้และปรับเปลี่ยนตลอดเวลาในช่วงการเรียนรู้แต่ละรอบ

ในการฝึกสอนและทดสอบของโครงข่ายประสาทเทียมจะใช้ข้อมูลที่แตกต่างกัน 2 ชุด คือ ข้อมูลสำหรับฝึกสอนซึ่งใช้ในการฝึกสอนโครงข่ายประสาทเทียม และข้อมูลสำหรับทดสอบซึ่งเป็นข้อมูลใหม่ที่โครงข่ายประสาทเทียมไม่เคยเห็นมาก่อน โดยหลังจากการเรียนรู้สิ้นสุดลงโครงข่ายประสาทเทียมจะประมาณค่าเอาต์พุตของข้อมูลสำหรับทดสอบ

ข้อดีของกระบวนการเรียนรู้แบบนี้คือ โครงสร้างของโครงข่ายประสาทเทียมจะไม่ถูกกำหนดไว้ตายตัวก่อนการเรียนรู้ แต่ข้อเสียคือจะทำให้กระบวนการเรียนรู้ใช้เวลานานขึ้นในการเลือกโครงสร้างที่เหมาะสม

2.3 การเลือกชนิดของอินพุตและเอาต์พุต

ถ้าอินพุตมีความสัมพันธ์กับเอาต์พุตจะทำให้ประสิทธิภาพของโครงข่ายประสาทเทียมหลังกระบวนการเรียนรู้ดีขึ้น ลักษณะอินพุตและเอาต์พุตมี 2 แบบ คือแบบต่อเนื่อง (Continuous) เช่น การเปลี่ยนแปลงของระดับโพลต เป็นต้น และแบบไม่ต่อเนื่อง (Discrete) เช่นการเปลี่ยนตำแหน่งที่เกิดพอลท์ เป็นต้น ในกรณีที่ลักษณะอินพุตและเอาต์พุตเป็นแบบต่อเนื่องเราสามารถแทนค่าได้ด้วยจำนวนจริง ส่วนในกรณีที่ลักษณะอินพุตและเอาต์พุตเป็นแบบไม่ต่อเนื่องเราสามารถแทนค่าด้วยจำนวนเต็ม ตัวเลขแบบฐานสอง หรือเกรย์โค้ด (Gray code) [20]

ในวิทยานิพนธ์นี้สำหรับการประเมินดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้า จะพิจารณาความเพียงพอของกำลังผลิตจากสถานการณ์ขีดข้องของเครื่องกำเนิดไฟฟ้า โดยพิจารณาดัชนี Expected Energy Not Supplied (EENS) ซึ่งเป็นดัชนีที่บ่งบอกปริมาณพลังงานไฟฟ้าที่ไม่สามารถจ่ายได้เป็นเอาต์พุตมาจากการคำนวณด้วยวิธีการทางความน่าจะเป็น ดังนั้นการเลือกอินพุตต้องมีความสัมพันธ์กันมากที่สุด ได้แก่ ลำดับการเพิ่มเครื่องกำเนิดไฟฟ้า (Priority Lists), กำลังผลิตติดตั้ง (Installed capacity) และ Force outage rate (FOR) ซึ่งเป็นข้อมูลที่สำคัญต่อการประเมินดัชนี EENS เป็นอย่างมาก

สำหรับการจำลองข้อมูลพลังงานลม จะพิจารณาจากพลังงานที่ผลิตได้จริงซึ่งเป็นค่าที่ถูกบันทึกไว้เป็นเอาต์พุต ดังนั้นการเลือกอินพุตต้องมีความสัมพันธ์กันมากที่สุด ได้แก่ พลังงานย้อนหลัง 1 เดือน, พลังงานย้อนหลัง 2 เดือน และความเร็วลมเฉลี่ย ซึ่งเป็นข้อมูลที่สำคัญต่อการจำลองข้อมูลพลังงานลมเป็นอย่างมาก

2.4 การนอร์มอลไลซ์ของข้อมูลสำหรับสอนโครงข่ายประสาทเทียม

วิธีการนอร์มอลไลซ์ (Normalization) ของข้อมูลฝึกสอนมีจุดประสงค์เพื่อลดเวลาในการสอนโครงข่ายประสาทเทียม และเพิ่มความแม่นยำให้กับเอาต์พุตของโครงข่ายประสาทเทียม ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพสูงขึ้นเมื่อเปรียบเทียบกับการใช้ข้อมูลดิบมาฝึกสอน

การ Normalized ของค่าอินพุตและเอาต์พุตอยู่บนพื้นฐานของการแจกแจงแบบปกติโดยมีค่าเฉลี่ยเท่ากับศูนย์ ($\mu=0$) และค่าเบี่ยงเบนมาตรฐานเท่ากับหนึ่ง ($\sigma=1$) [20] ตามสมการที่ (2.12)

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (2.12)$$

สำหรับอินพุตหรือเอาต์พุตใดๆ ถ้าประกอบด้วยข้อมูล n ชุด (X_1, X_2, \dots, X_n) แล้วจะสามารถทำการ Normalized ตามสมการที่ (2.13) ถึง (2.16) ตามลำดับ

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} ; \mu_X = \frac{\sum_{i=1}^n X_i}{n} \quad (2.13)$$

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} X_1 - \mu_X \\ X_2 - \mu_X \\ \vdots \\ X_n - \mu_X \end{bmatrix} ; \mu_Y = 0 \quad (2.14)$$

$$\sigma_Y = \sqrt{\frac{\sum_{i=1}^n (Y_i)^2}{n}} \quad (2.15)$$

$$Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix} = Y \cdot \frac{1}{\sigma_Y} = \begin{bmatrix} (X_1 - \mu_X)/\sigma_Y \\ (X_2 - \mu_X)/\sigma_Y \\ \vdots \\ (X_n - \mu_X)/\sigma_Y \end{bmatrix} ; \sigma_Z = 1, \mu_Z = 0 \quad (2.16)$$

และควรทำการ Scaled ตามสมการที่ (2.17) ถึง (2.19) โดยสร้างรูปแบบการกระจายข้อมูลให้เป็นแบบเชิงเส้นที่มีค่าระหว่าง $[0.1, 0.9]$ สำหรับแต่ละข้อมูลอินพุต และให้มีค่าระหว่าง $[-0.9, 0.9]$ สำหรับแต่ละข้อมูลเอาต์พุต

$$\text{เมื่อ Normalized Matrix } [Z] = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix}$$

$$aw = \frac{(b-a)}{mx - mn} \quad (2.17)$$

$$bw = b - aw \cdot mx \quad (2.18)$$

โดยที่ a, b คือ ช่วงของการ Scaling [a , b] หรือเท่ากับ [0.1,0.9]

mx คือ ค่าสูงสุดของ Normalized Matrix [Z]

mn คือ ค่าต่ำสุดของ Normalized Matrix [Z]

$$\text{ดังนั้น } \text{output after scaling} = aw \cdot Z_i + bw \quad ; \quad i = 1, 2, \dots, n \quad (2.19)$$

วิธีการ Unnormalized ข้อมูล

เมตริกซ์ [O] คือ เอาท์พุทที่ถูก Normalized และ Scaled ระหว่างการฝึกสอน และเมตริกซ์

[Q] คือ เอาท์พุทของชุดฝึกสอนข้อมูล n ชุดที่ถูก interpolated ที่จะนำไปเปรียบเทียบกับค่าเอาท์พุทเป้าหมาย ตามสมการที่ (2.20) ถึง (2.21)

$$[L] = \begin{bmatrix} O_1 / aw - bw / aw \\ O_2 / aw - bw / aw \\ \vdots \\ O_n / aw - bw / aw \end{bmatrix} \quad (2.20)$$

$$[Q] = \begin{bmatrix} L_1 \cdot \sigma_y + \mu_x \\ L_2 \cdot \sigma_y + \mu_x \\ \vdots \\ L_n \cdot \sigma_y + \mu_x \end{bmatrix} \quad (2.21)$$

เมตริกซ์ [T] แทนการ Normalized และการ Scaled ของข้อมูลเอาท์พุทในระหว่างการทดสอบ และเมตริกซ์ [H] คือ เอาท์พุทของชุดทดสอบข้อมูล n ชุดที่ถูก interpolated ที่จะนำไปเปรียบเทียบกับค่าเอาท์พุทเป้าหมาย ตามสมการที่ (2.22) ถึง (2.23)

$$[R] = \begin{bmatrix} T_1 / aw - bw / aw \\ T_2 / aw - bw / aw \\ \vdots \\ T_n / aw - bw / aw \end{bmatrix} \quad (2.22)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$[H] = \begin{bmatrix} R_1 \cdot \sigma_y + \mu_x \\ R_2 \cdot \sigma_y + \mu_x \\ \vdots \\ R_n \cdot \sigma_y + \mu_x \end{bmatrix} \quad (2.23)$$

การ scaled ข้อมูลมีความสำคัญเมื่อข้อมูลถูกเรียนรู้โดยใช้นิวรอนเอาท์พุท สามารถทำให้กระบวนการเรียนรู้ง่ายขึ้นซึ่งค่าถ่วงน้ำหนักทั้งหมดยังมีค่าน้อย ๆ และเพื่อปรับปรุง interpretability ของค่าถ่วงน้ำหนักในโครงข่ายประสาทเทียม

2.5 ตัวอย่างการเรียนรู้โดยใช้โครงข่ายประสาทเทียมบนโปรแกรม MATLAB

ขั้นตอนการใช้งานและการทดสอบ ANN มีขั้นตอนดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลของเครื่องกำเนิดไฟฟ้าที่จะใช้ในการเรียนรู้ของ ANN ในตัวอย่างนี้เลือกใช้ข้อมูลของระบบทดสอบ IEEE RTS ขนาด 32 เครื่อง แสดงข้อมูลในภาคผนวก ข โดยกำหนด Priority level, Installed capacity และ Force outage rate ของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องเป็นค่าเอาท์พุท และดัชนี EENS ของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องเป็นค่าเอาท์พุท

ขั้นตอนที่ 2 สุ่มเลือกข้อมูลออกเป็น 2 ชุด คือข้อมูลสำหรับการฝึกสอน 27 ข้อมูลและข้อมูลสำหรับทดสอบ 5 ข้อมูล แสดงตามตารางที่ 2.1 และ 2.2 ตามลำดับ

ตารางที่ 2.1 ข้อมูลสำหรับฝึกสอน 27 ข้อมูล

Priority list	Installed capacity (MW)	Force Outage Rate	EENS (MWh)
1	50	0.01	14864643
2	50	0.01	14432211
3	50	0.01	13999779
5	50	0.01	13134915
6	50	0.01	12702483
7	400	0.12	9627411
9	76	0.02	5927422
10	76	0.02	5317900
11	76	0.02	4735460
12	76	0.02	4183912
13	155	0.04	3195017
14	155	0.04	2340412
15	155	0.04	1632254
17	350	0.08	355137.7
18	20	0.10	329783.5
19	20	0.10	306014.4
20	20	0.10	283726.2

Priority list	Installed capacity (MW)	Force Outage Rate	EENS (MWh)
21	20	0.10	262788.6
22	12	0.02	249765.7
23	12	0.02	237282.9
24	12	0.02	225293.5
26	12	0.02	202776.7
27	100	0.04	129490.8
28	100	0.04	79204.51
29	100	0.04	46592.79
30	197	0.05	15562.42
32	197	0.05	1176.3

ตารางที่ 2.2 ข้อมูลสำหรับทดสอบ 5 ข้อมูล

Priority list	Installed capacity (MW)	Force Outage Rate	EENS (MWh)
4	50	0.01	13567347
8	400	0.12	6559729
16	155	0.04	1083618
25	12	0.02	213805
31	197	0.05	4569.41

ขั้นตอนที่ 3 นำข้อมูลอินพุต และเอาต์พุต มาทำการ normalized และ scaled

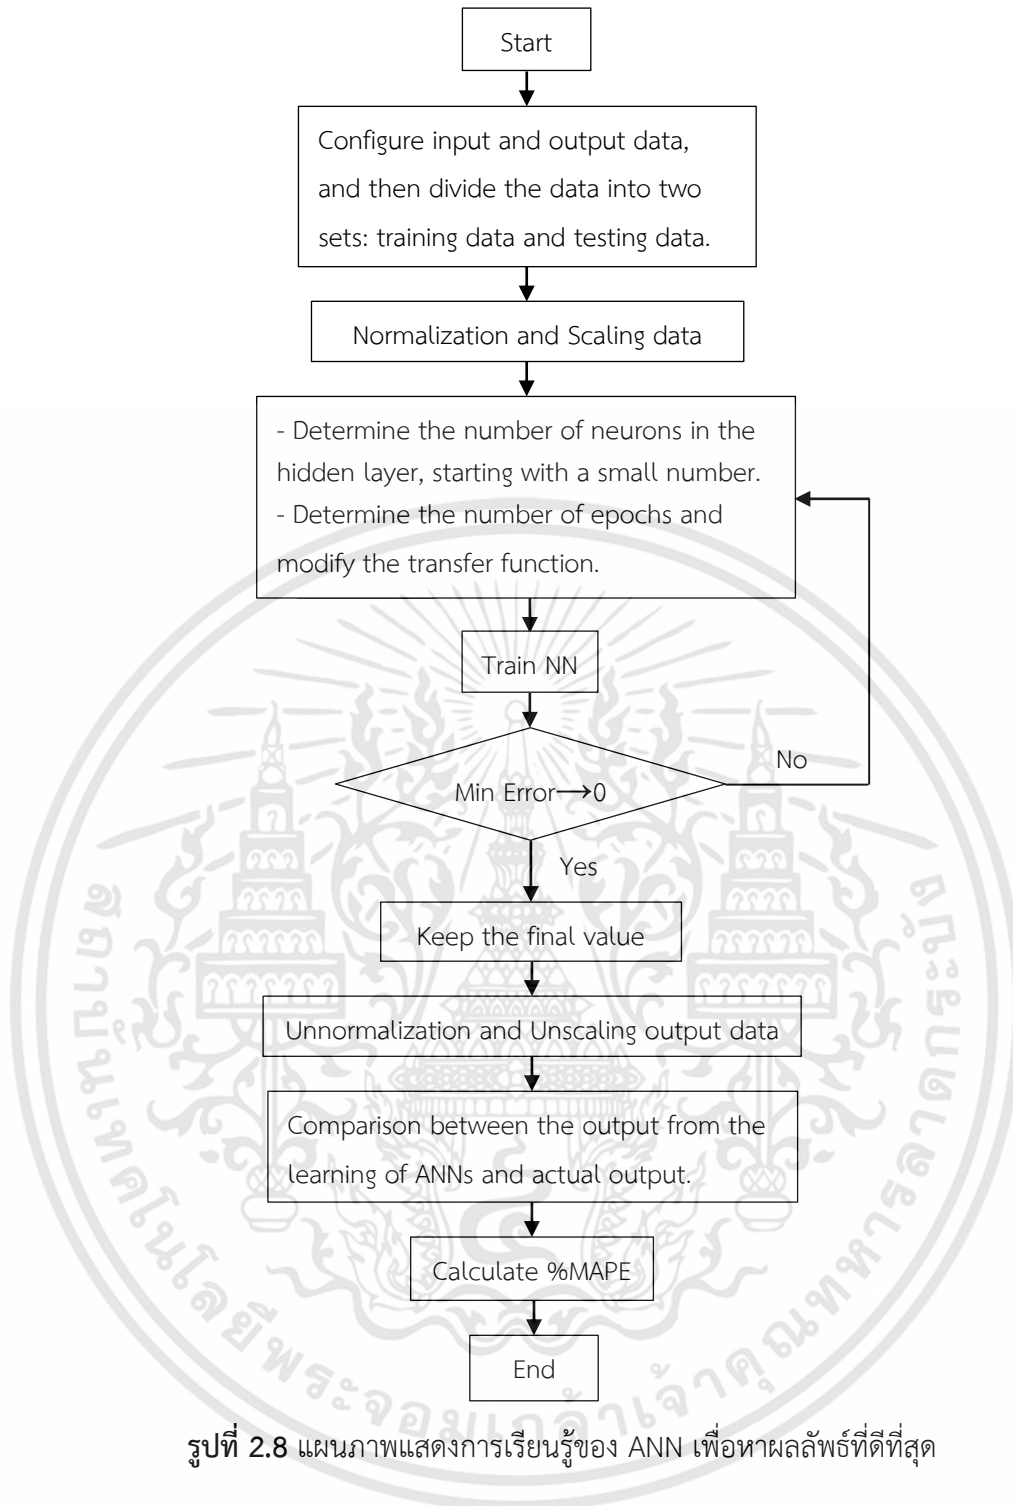
ขั้นตอนที่ 4 กำหนดจำนวนนิรอนในแต่ละชั้นซ่อน จำนวนรอบ (Epochs) และฟังก์ชันถ่ายโอน (Transfer function) ของแต่ละชั้นซ่อนและชั้นเอาต์พุต

ขั้นตอนที่ 5 คำนวณโดยใช้โปรแกรม MATLAB ซึ่ง ANN จะเรียนรู้และจดจำข้อมูลฝึกสอน และแสดงผลลัพธ์ออกมา

ขั้นตอนที่ 6 Unnormalized ข้อมูลเอาต์พุตที่ได้จาก ANN

ขั้นตอนที่ 7 นำค่าเอาต์พุตที่ได้จาก ANN มาเปรียบเทียบกับค่าจริง

ขั้นตอนที่ 8 ลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด แสดงขั้นตอนการเรียนรู้ของ ANN ตามรูปที่ 2.8



รูปที่ 2.8 แผนภาพแสดงการเรียนรู้ของ ANN เพื่อหาผลลัพธ์ที่ดีที่สุด

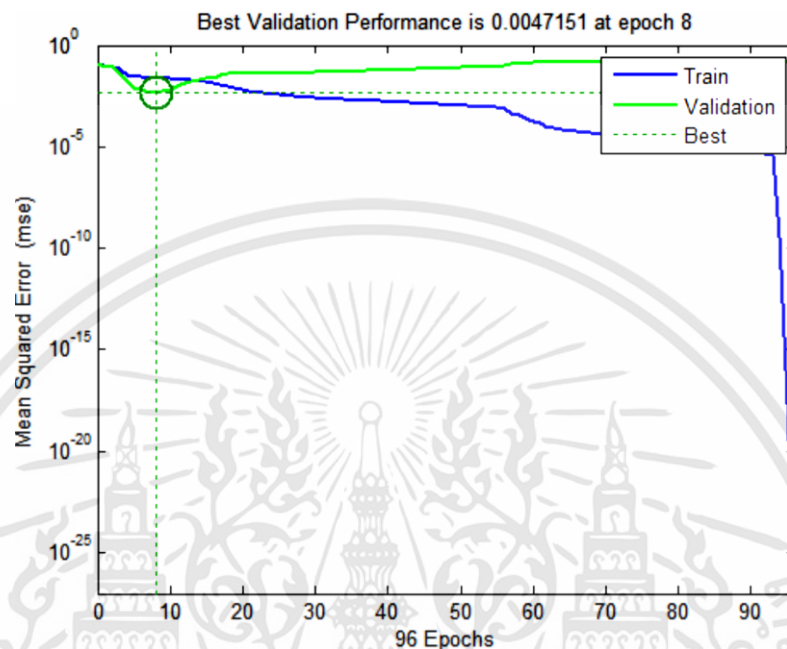
2.6 การวัดประสิทธิภาพของ ANN

การวัดความแม่นยำของ ANN จะใช้ค่าผิดพลาดเฉลี่ยสมบูรณ์ (Mean Absolute Percentage Error, MAPE) จากค่าความคลาดเคลื่อนของค่าพยากรณ์ที่เป็นคำตอบของ ANN ที่ผ่านการฝึกสอนแล้วเปรียบเทียบกับคำตอบจริง [20] ตามสมการที่ (2.24)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{OP_{\text{actual}} - OP_{\text{ANN}}}{OP_{\text{actual}}} \right| \times 100\% \quad (2.24)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่ OP_{actual} คือ เอาท์พุทจริง
 OP_{ANN} คือ เอาท์พุทที่ได้จาก ANN
 N คือ จำนวนข้อมูลทดสอบ



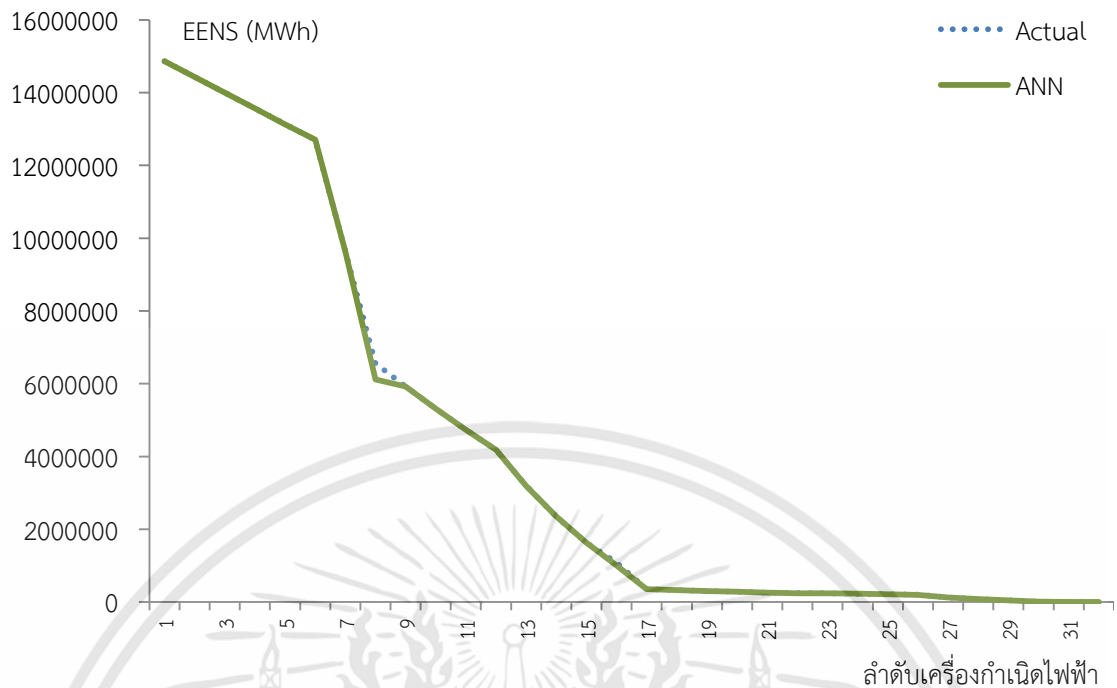
รูปที่ 2.9 ค่าผิดพลาดเฉลี่ยที่ดีที่สุดของข้อมูลทดสอบที่เกิดจากเรียนรู้ของ ANN โดยใช้โปรแกรม MATLAB

จากรูปที่ 2.9 แสดงค่าผิดพลาดเฉลี่ยที่ดีที่สุดของข้อมูลทดสอบซึ่งเกิดขึ้น เมื่อจำนวนรอบในการเรียนรู้ (Epochs) คือ 96 ในกระบวนการเรียนรู้ของ ANN ต้องใช้การปรับค่าพารามิเตอร์ต่างๆ เช่น กำหนดจำนวนนิวรอนในแต่ละชั้นซ่อน จำนวนรอบ (Epochs) และฟังก์ชันถ่ายโอน (Transfer function) ของแต่ละชั้นซ่อนและชั้นเอาท์พุท เป็นต้น เพื่อให้ ANN ได้เรียนรู้และจดจำและต้องใช้วิธีการลองผิดลองถูก เพื่อหาโครงสร้างที่เหมาะสมและได้ผลลัพธ์ที่ดีที่สุด แสดงตามตารางที่ 2.3

ตารางที่ 2.3 ผลลัพธ์ที่ดีที่สุดที่ได้จากการเรียนรู้ของ ANN

Number of neurons	Transfer Function			%MAPE	
	Hidden Layer 1	Hidden Layer 2	Output Layer	Train	Test
13 12	tansig	purelin	purelin	1.2488	2.3963

เมื่อเลือกโครงสร้างที่เหมาะสมได้แล้ว นำเอาท์พุทที่ได้จากกระบวนการเรียนรู้ของ ANN และเอาท์พุทจริงมาเปรียบเทียบเพื่อหาค่าผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) รวมทั้งพิจารณาลักษณะของค่าที่ได้จากการทดสอบ ANN แสดงตามรูปที่ 2.10 เพื่อนำไปเปรียบเทียบกับวิธีการอื่นๆ ต่อไป



รูปที่ 2.10 เปรียบเทียบระหว่างค่าเอาต์พุตจริงและค่าเอาต์พุตที่ได้จาก ANN

จากรูปที่ 2.10 แสดงการเปรียบเทียบการประเมินดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้าระหว่างค่าจริงกับค่าที่ได้จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม (ANN) พบว่ามี %MAPE ของข้อมูลฝึกสอนเป็น 1.2488% และ %MAPE ของข้อมูลทดสอบเป็น 2.3963%

บทที่ 3

ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

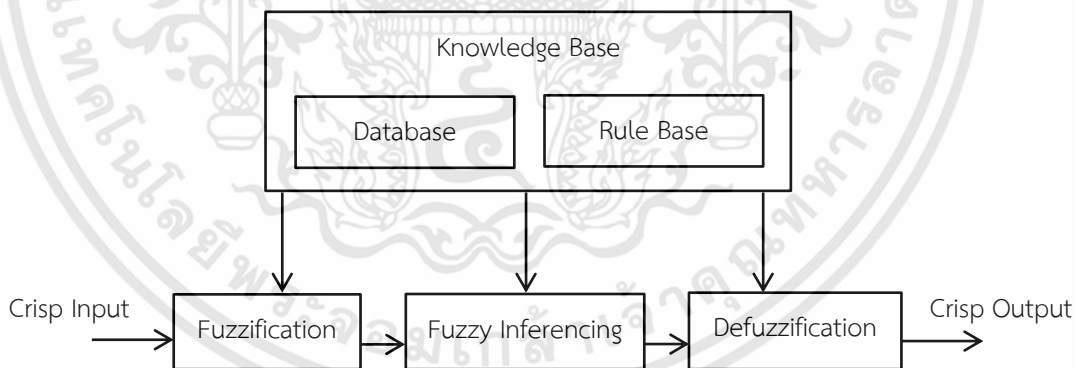
3.1 พื้นฐานของระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference System หรือ ANFIS) เป็นการประยุกต์ใช้ระบบโครงข่ายประสาทเทียมมาใช้กับกฎฟัซซี เป็นระบบผสม (Hybrid System) เพื่อนำข้อดีของแต่ละวิธีมารวมกันและขจัดข้อจำกัดของแต่ละวิธีออกไป

3.1.1 กฎฟัซซี

ฟัซซีลอจิกหรือตรรกศาสตร์คลุมเครือ (Fuzzy Logic หรือ FL) เป็นวิธีทางคณิตศาสตร์ที่ช่วยในการตัดสินใจภายใต้ความคลุมเครือ ไม่ชัดเจนคล้ายกับตรรกะทางความคิดของมนุษย์ คิดค้นโดย L. A. Zadeh ในปี ค.ศ. 1965 ที่อาศัยฟัซซีเซต (Fuzzy Set) เพื่อสื่อถึงความไม่แน่นอน โดยในฟัซซีเซตนี้จะกำหนดค่าความเป็นสมาชิก (Degree of Membership) ให้มีค่าอยู่ระหว่าง 0 และ 1

ซึ่งแตกต่างจากเซตแบบฉบับ (Classical Set) ที่มีการกำหนดค่าความเป็นสมาชิกเพียงสองค่าเท่านั้นคือ 0 หมายถึง ไม่เป็นสมาชิก และ 1 หมายถึง เป็นสมาชิก การกำหนดระดับความเป็นสมาชิกของตัวแปรที่สนใจนั้นอาศัยฟังก์ชันความเป็นสมาชิก (Membership Function) ซึ่งมีอยู่หลายชนิด เช่น ฟังก์ชันสามเหลี่ยม ฟังก์ชันสี่เหลี่ยมคางหมู ฟังก์ชันซิกมอยด์ ฟังก์ชันเกาส์เซียน เป็นต้น การเลือกใช้ฟังก์ชันความเป็นสมาชิกจะขึ้นอยู่กับข้อมูลของตัวแปรนั้นๆ นอกจากนี้ ฟัซซีเซตยังใช้กับตัวแปรเชิงภาษา (Linguistic Variables) เพื่อแสดงคุณภาพหรือปริมาณได้อีกด้วย



รูปที่ 3.1 โครงสร้างพื้นฐานของระบบฟัซซี [7]

จากรูปที่ 3.1 โครงสร้างพื้นฐานของระบบฟัซซี มี 3 ขั้นตอน คือ ขั้นตอนที่ 1 การแปลงค่าของข้อมูลด้านเข้าเป็นค่าฟัซซีด้านเข้า (Fuzzification) เป็นการคำนวณค่าความเป็นสมาชิกของข้อมูลด้านเข้า (Crisp Input) โดยใช้ฟังก์ชันความเป็นสมาชิก ขั้นตอนที่ 2 การอนุมานหรือตีความ (Fuzzy Inferencing) เป็นการนำค่าฟัซซีด้านเข้าไปตีความหรืออนุมานผ่านกฎฟัซซีที่ตั้งขึ้นมาและได้ผลลัพธ์เป็นค่าฟัซซีด้านออก โดยกฎฟัซซีที่นิยมใช้คือ กฎฟัซซีแบบ ถ้า-แล้ว (Fuzzy If-Then Rule) ที่อาศัยหลักการของเหตุและผล และในขั้นตอนสุดท้าย การทำค่าฟัซซีให้เป็นค่าปกติ (Defuzzification) เป็น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การนำค่าฟัซซีด้านออกมาแปลงเป็นค่าปกติ (Crisp Output) ซึ่งมีหลายวิธี เช่น วิธีการหาค่าเฉลี่ยถ่วงน้ำหนัก, วิธีการหาจุดศูนย์ถ่วง เป็นต้น จะเห็นได้ว่าการทำงานของกฎฟัซซีคล้ายกับโครงข่ายประสาทเทียมในการประมาณค่าความสัมพันธ์ ต่างกันตรงที่กฎฟัซซีไม่ได้ใช้การเรียนรู้ แต่อาศัยองค์ความรู้ที่อยู่ในฐานความรู้ (Knowledge Base)

กฎฟัซซีถูกนำไปใช้ในการพยากรณ์เนื่องจากมีจุดเด่นตรงที่มีตรรกะการใช้เหตุผลเหมือนมนุษย์ และใช้ประสบการณ์ของผู้เชี่ยวชาญมากกว่าการใช้ทฤษฎี นอกจากนี้ยังสามารถรองรับกับพฤติกรรมแบบพลวัต (Dynamic Behaviors) รวมถึงความไม่แน่นอนได้ด้วย แต่ทั้งนี้กฎฟัซซีเองก็มีข้อจำกัดในการใช้เช่นกัน กล่าวคือ กฎฟัซซีเป็นการประมาณโดยใช้ตรรกะภายใต้ความไม่แน่นอน ดังนั้นจึงไม่เหมาะที่จะใช้กับงานที่ต้องการความแม่นยำสูง นอกจากนี้ การที่กฎฟัซซีไม่มีความสามารถในการเรียนรู้ด้วยตัวเอง จึงไม่สามารถใช้หาคำตอบของปัญหาที่ไม่มีใครรู้คำตอบ ดังนั้นผู้เชี่ยวชาญจึงมีความจำเป็นอย่างมากในการตั้งกฎฟัซซีในฐานความรู้ หากไม่สามารถหาผู้เชี่ยวชาญมาช่วยได้ก็ไม่สามารถใช้กฎฟัซซีได้อย่างมีประสิทธิภาพ

3.1.2 ระบบนิวโรฟัซซี

วิธีต่างๆ ทางคณิตศาสตร์ที่ได้กล่าวไปต่างก็มีข้อดีและข้อเสียแตกต่างกัน ไม่มีวิธีใดที่จะดีกว่าวิธีอื่นในทุกๆ ด้าน ยกตัวอย่างเช่น โครงข่ายประสาทเทียม (Artificial Neural Networks) มีข้อดีตรงที่มีความสามารถในการเรียนรู้และจดจำรูปแบบต่างๆ ได้ และยังสามารถปรับแต่งความรู้ที่ซ่อนอยู่ภายในโครงข่ายได้ แต่มีข้อเสียตรงที่ไม่สามารถอธิบายเหตุผลของการตัดสินใจได้ ในขณะที่ฟัซซีลอจิกหรือตรรกศาสตร์คลุมเครือ (Fuzzy Logic) มีจุดเด่นตรงที่มีการใช้เหตุผลในเชิงตรรกะเหมือนความคิดของมนุษย์ สามารถอธิบายการตัดสินใจได้จากกฎฟัซซีและสามารถใช้กับข้อมูลที่คลุมเครือได้ แต่ข้อเสียของกฎฟัซซีอยู่ตรงที่ไม่สามารถเรียนรู้และปรับแต่งกฎต่างๆ ด้วยตัวเอง ต้องอาศัยผู้เชี่ยวชาญหรือผู้มีความรู้มากำหนดโครงสร้างและกฎให้ ด้วยเหตุนี้จึงมีนักวิจัยสนใจนำวิธีต่างๆ มาผสมกันเป็นระบบผสม (Hybrid System) เพื่อนำข้อดีของแต่ละวิธีมารวมกันและขจัดข้อจำกัดของแต่ละวิธีออกไป หนึ่งในระบบผสมดังกล่าวได้แก่ การนำ ANN ผสมกับ FL ได้เป็นระบบโครงข่ายประสาทเทียมแบบฟัซซี หรือระบบนิวโรฟัซซี ซึ่งระบบนิวโรฟัซซีที่เป็นที่นิยม ได้แก่ ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems หรือ ANFIS) [7]

ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้จะใช้ขั้นตอนการเรียนรู้แบบผสม (Hybrid Learning Algorithm) จากวัฏจักรการเรียนรู้แบบสองทาง โดยในการคำนวณไปข้างหน้า (Forward Pass) จะปรับค่าพารามิเตอร์ของข้อตามโดยใช้วิธีการประเมินกำลังสองน้อยที่สุด (Least Squares Estimate) ในขณะที่การคำนวณย้อนหลัง (Backward Pass) จะใช้วิธีปรับตามความลาดชัน (Gradient Descent) สำหรับการปรับค่าพารามิเตอร์ของข้อตั้ง

การใช้ ANFIS ในการพยากรณ์เริ่มได้รับความนิยมมากขึ้นในปัจจุบันเนื่องจากคุณสมบัติในการเรียนรู้และการใช้เหตุผล ทำให้ผลลัพธ์มีความแม่นยำมากขึ้น ส่วนเรื่องข้อจำกัดของ ANFIS นั้น เวลาที่ ANFIS ใช้ในการเรียนรู้ เป็นสิ่งที่ผู้ใช้ ANFIS ต้องตระหนักถึง ปัญหานี้จะทวีความรุนแรงมากขึ้นเมื่อใช้กับระบบที่มีพฤติกรรมแบบพลวัตชนิดไม่เชิงเส้น (Non-linear Dynamic Behaviors) เพราะในระบบแบบนี้จะมีกฎฟัซซีแบบ ถ้า-แล้ว จำนวนมาก ทำให้ต้องใช้เวลาในการเรียนรู้นานมากขึ้น จึงไม่เหมาะกับการนำไปใช้งานแบบทำงานทันที (Real-time Applications)

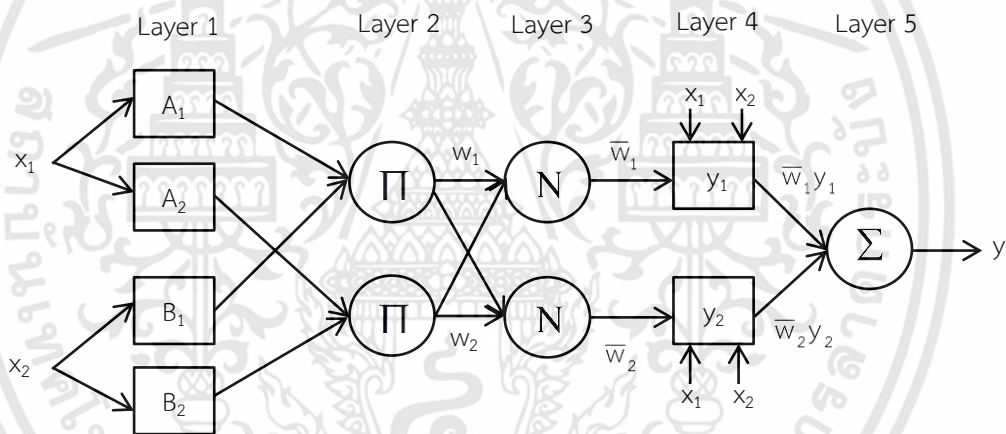
3.2 โครงสร้างของระบบอนุมานนิเวศวิธีแบบปรับตัวได้

การพิจารณา มี 2 อินพุต x_1 และ x_2 และมี 1 เอาท์พุต y และมีกฎฟuzzy แบบ Takagi-Sogeno-Kang (TSK) ดังนี้

กฎข้อที่ 1	ถ้า x_1 คือ A_1 และ x_2 คือ B_1 แล้ว $y_1 = p_1 x_1 + q_1 x_2 + r_1$
กฎข้อที่ 2	ถ้า x_1 คือ A_2 และ x_2 คือ B_2 แล้ว $y_2 = p_2 x_1 + q_2 x_2 + r_2$
\vdots	\vdots
กฎข้อที่ R	ถ้า x_1 คือ A_R และ x_2 คือ B_R แล้ว $y_R = p_R x_1 + q_R x_2 + r_R$

โดยที่ A_1, A_2, B_1 และ B_2 เป็นฟuzzy เซตของพจน์ภาษา เช่น เล็ก กลาง ใหญ่ ส่วน p_1, p_2, q_1, q_2, r_1 และ r_2 เป็นพารามิเตอร์ของข้อตามของกฎฟuzzy

โครงสร้างพื้นฐานสามารถอธิบายสัญลักษณ์ได้โดยโหนดรูปสี่เหลี่ยมแสดงถึงโหนดที่มีพารามิเตอร์ที่สามารถปรับค่าได้ ในขณะที่โหนดรูปวงกลมแสดงถึงโหนดที่ไม่สามารถปรับค่าของพารามิเตอร์ได้ [7]



รูปที่ 3.2 โครงสร้างของระบบอนุมานฟuzzy แบบปรับตัวได้

โครงสร้างของ ANFIS แบ่งออกเป็น 5 ชั้น [7], [25] ได้แก่

ชั้นที่ 1 Premise Parameters Layer

ทำหน้าที่แปลงข้อมูลด้านเข้า (x) เป็นค่าฟuzzy โดยการคำนวณค่าความเป็นสมาชิกจาก ฟังก์ชันความเป็นสมาชิก $\mu_{A_i}(x_1)$ และ $\mu_{B_i}(x_2)$ ตามสมการที่ (3.1) ถึง (3.2) และโหนดในชั้นนี้เป็นรูปสี่เหลี่ยมแสดงว่าค่าพารามิเตอร์สามารถปรับค่าได้ ซึ่งพารามิเตอร์ในโหนดนี้ หมายถึง พารามิเตอร์ของฟังก์ชันความเป็นสมาชิก เรียกว่า พารามิเตอร์ของข้อตั้ง (Premise Parameters)

$$O_i^1 = \mu_{A_i}(x_1) \quad ; i = 1,2 \quad (3.1)$$

$$O_i^1 = \mu_{B_i}(x_2) \quad ; i = 3,4 \quad (3.2)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่ O_i^1 คือ ผลลัพธ์ของชั้นที่ 1, โดยค่าความเป็นสมาชิกด้านเข้า
 $\mu_{A_i}(x_1)$ คือ ค่าความเป็นสมาชิกด้านเข้า x_1 ในฟัซซีเซต A_i ของโหนดที่ i
 $\mu_{B_i}(x_2)$ คือ ค่าความเป็นสมาชิกด้านเข้า x_2 ในฟัซซีเซต B_i ของโหนดที่ i

ซึ่งชนิดของฟังก์ชันความเป็นสมาชิกอาจเป็นแบบระฆังคว่ำ ตามสมการที่ (3.3)

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (3.3)$$

หรือแบบเกาส์เซียน ตามสมการที่ (3.4)

$$\mu_{A_i}(x) = \exp \left(- \left(\frac{x - c_i}{a_i} \right)^2 \right) \quad (3.4)$$

เมื่อ $\{a_i, b_i, c_i\}$ เป็นเซตพารามิเตอร์ c_i เป็นค่ากลางของฟังก์ชัน, a_i และ b_i เป็นตัวกำหนดความชันของฟังก์ชัน ส่วนฟังก์ชันความเป็นสมาชิกอื่น ๆ ที่สามารถหาค่าอนุพันธ์ได้ เช่น ฟังก์ชันสามเหลี่ยม (triangular membership function) ฟังก์ชันสี่เหลี่ยม (trapezoidal membership function)

ชั้นที่ 2 T-norm Operator Layer

ทำหน้าที่คูณสัญญาณที่ส่งมาจากชั้นที่ 1 เข้าด้วยกันโดยใช้ T-norm Operator และส่งออกไปยังชั้นที่ 3 ซึ่งจำนวนโหนดในชั้นนี้จะมีจำนวนเท่ากับจำนวนของกฎฟัซซีและสัญญาณที่ส่งออกไป (w) เป็น Firing Strength ของกฎแต่ละข้อ ตามสมการที่ (3.5) โหนดในชั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้ โดยมีสัญลักษณ์เป็นเครื่องหมาย Π

$$O_i^2 = w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \quad ; i = 1, 2 \quad (3.5)$$

โดยที่ w_i คือ ค่า firing strength จากกฎแต่ละข้อ

ชั้นที่ 3 Normalized Firing Strength Layer

ทำหน้าที่ปรับค่า Firing Strength ให้มีผลรวมจากกฎทุกข้อมีค่าเป็นหนึ่ง โดยการหารค่า Firing Strength ด้วยผลรวมของ Firing Strength จากกฎทุกข้อ ผลลัพธ์ที่ได้เรียกว่า Normalized Firing Strength (\bar{w}) ตามสมการที่ (3.6) โหนดในชั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้ โดยมีสัญลักษณ์เป็นเครื่องหมาย N

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad ; i = 1, 2 \quad (3.6)$$

ชั้นที่ 4 Consequent Parameters Layer

ทำหน้าที่คำนวณผลลัพธ์จากข้อตามของกฎฟัซซี ตามสมการที่ (3.7) โหนดในชั้นนี้เป็นรูปสี่เหลี่ยมแสดงว่าพารามิเตอร์ของโหนดนี้ (p_i , q_i และ r_i) สามารถปรับค่าได้พารามิเตอร์เหล่านี้เรียกว่า พารามิเตอร์ของข้อตาม (Consequent Parameters) สำหรับข้อมูลด้านออกจากชั้นนี้หาได้จาก

$$O_i^4 = \bar{w}_i y_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad ; i = 1, 2 \quad (3.7)$$

โดยที่ $\{p_i, q_i, r_i\}$ เป็นเซตของค่าพารามิเตอร์ใน Rule consequent ซึ่งใช้การประมาณค่าด้วยวิธีกำลังสองน้อยที่สุด (least means square) สำหรับการกำหนดค่าพารามิเตอร์

ชั้นที่ 5 Overall Output Layer

ทำหน้าที่รวมสัญญาณจากทุกโหนดของชั้นที่ 4 เข้าด้วยกัน ได้เป็นข้อมูลด้านออก (y) ตามสมการที่ (3.8) โหนดในชั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้ โดยมีสัญลักษณ์ของโหนดเป็นเครื่องหมาย Σ สำหรับข้อมูลด้านออกหาได้จาก

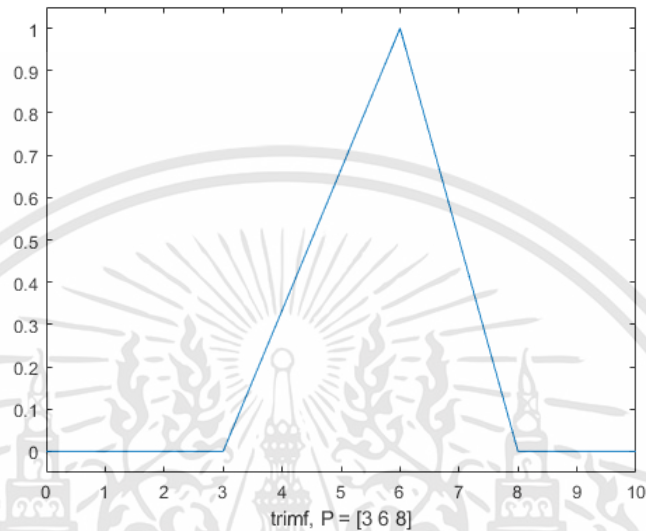
$$O_i^5 = \bar{w}^T y = \sum_{i=1}^2 \bar{w}_i y_i = \frac{\sum_{i=1}^2 w_i y_i}{w_1 + w_2} \quad (3.8)$$

3.3 ฟังก์ชันความเป็นสมาชิก

ฟังก์ชันความเป็นสมาชิก (membership function) เป็นฟังก์ชันที่มีการกำหนดระดับความเป็นสมาชิกของตัวแปรที่ต้องการใช้งาน โดยเริ่มจากการแทนที่กับตัวแทนที่มีความไม่ชัดเจน ไม่แน่นอน และคลุมเครือ ดังนั้นส่วนที่สำคัญต่อคุณสมบัติหรือการดำเนินการของฟัซซี เพราะรูปร่างของฟังก์ชันความเป็นสมาชิกมีความสำคัญต่อกระบวนการคิดและแก้ไขปัญหา โดยฟังก์ชันความเป็นสมาชิกจะไม่สมมาตรกันหรือสมมาตรกันทุกประการก็ได้ ชนิดของฟังก์ชันความเป็นสมาชิกที่ใช้งานทั่วไปมีหลายชนิด [21] โดยในโปรแกรม MATLAB ANFIS Toolbox มีฟังก์ชันสมาชิกให้เลือกทั้งหมด 8 ฟังก์ชัน ดังนี้

1. Triangular-shaped membership function มีทั้งหมด 3 พารามิเตอร์คือ $\{a, b, c\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.9) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.3


$$f(x : a, b, c) = \begin{cases} 0 & ; x < a \\ \frac{x - a}{b - a} & ; a \leq x < b \\ \frac{c - x}{c - b} & ; b \leq x < c \\ 0 & ; x \geq c \end{cases} \quad (3.9)$$



รูปที่ 3.3 Triangular-shaped membership function

2. Trapezoidal-shaped membership function มีทั้งหมด 4 พารามิเตอร์คือ $\{a, b, c, d\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.10) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.4

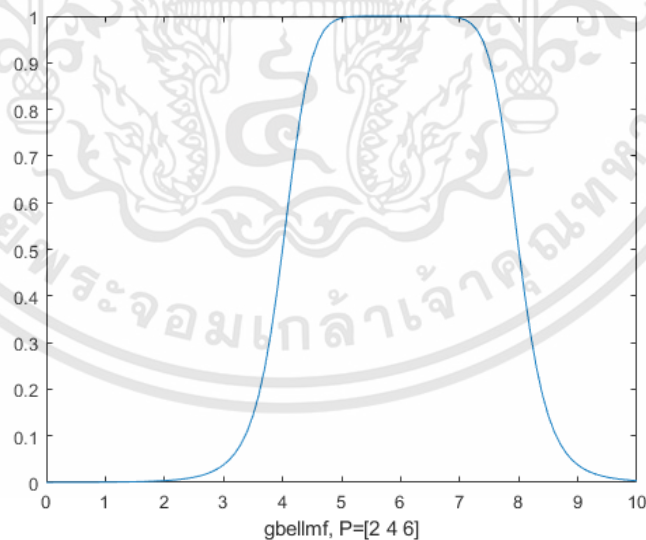
$$f(x : a, b, c, d) = \begin{cases} 0 & ; x < a \\ \frac{x - a}{b - a} & ; a \leq x < b \\ 1 & ; b \leq x < c \\ \frac{d - x}{d - c} & ; c \leq x < d \\ 0 & ; x \geq d \end{cases} \quad (3.10)$$



รูปที่ 3.4 Trapezoidal-shaped membership function

3. Generalized bell-shaped membership function มีพารามิเตอร์ทั้งหมด 3 ค่าคือ $\{a, b, c\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.11) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.5


$$f(x : a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (3.11)$$



รูปที่ 3.5 Generalized bell-shaped membership

4. Gaussian curve membership function มีทั้งหมด 2 พารามิเตอร์คือ $\{c, \sigma\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.12) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.6

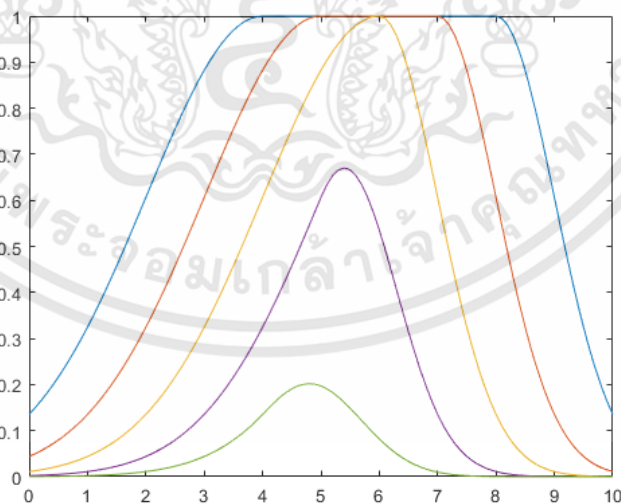
$$f(x : c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (3.12)$$



รูปที่ 3.6 Gaussian curve membership function

5. Gaussian combination membership function มีทั้งหมด 4 พารามิเตอร์คือ $\{c_1, \sigma_1, c_2, \sigma_2\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.13) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.7

$$f(x : c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (3.13)$$

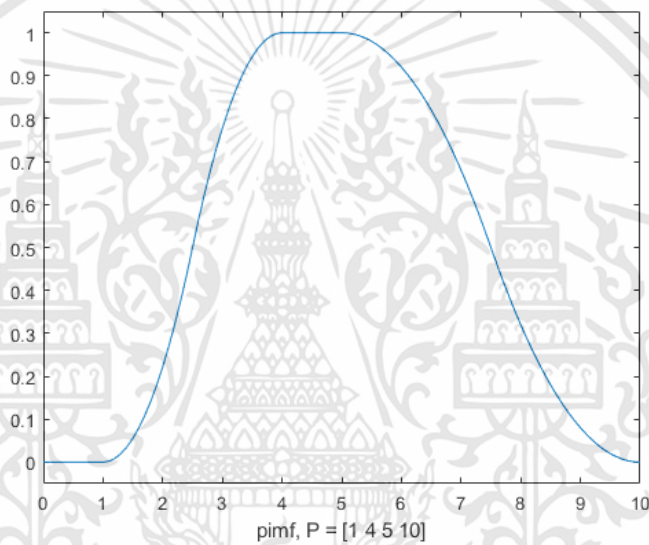


รูปที่ 3.7 Gaussian combination membership function

6. π -shape membership function มีพารามิเตอร์ทั้งหมด 4 ค่าคือ $\{a, b, c, d\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.14) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$f(x : a, b) = \begin{cases} 0 & ; x \leq a \\ 2\left(\frac{x-a}{b-a}\right)^2 & ; a < x \leq \frac{a+b}{2} \\ 1 - 2\left(\frac{x-b}{b-a}\right)^2 & ; \frac{a+b}{2} < x \leq b \\ 1 & b < x \leq c \\ 1 - 2\left(\frac{x-c}{d-c}\right)^2 & c < x \leq \frac{c+d}{2} \\ 2\left(\frac{x-d}{d-c}\right)^2 & \frac{c+d}{2} < x \leq d \\ 0 & x > d \end{cases} \quad (3.14)$$




รูปที่ 3.8 π -shape membership function

7. Difference between two sigmoidal membership function มีพารามิเตอร์ทั้งหมด 4 ค่าคือ $\{a_1, c_1, a_2, c_2\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.15) ถึง (3.16) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.9

$$f(x : a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (3.15)$$

และผลต่างระหว่าง 2 ฟังก์ชันคือ $f_1(x : a_1, c_1) - f_2(x : a_2, c_2)$ (3.16)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

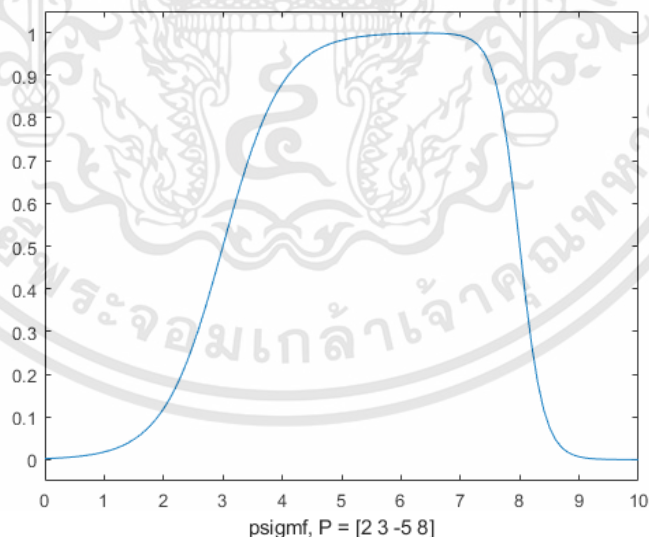


รูปที่ 3.9 Difference between two sigmoidal membership function

8. Product of two sigmoidal membership function มีพารามิเตอร์ทั้งหมด 4 ค่าคือ $\{a_1, c_1, a_2, c_2\}$ แสดงเงื่อนไขของฟังก์ชันตามสมการที่ (3.17) ถึง (3.18) และแสดงลักษณะการกระจายของฟังก์ชันตามรูปที่ 3.10

$$f(x : a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (3.17)$$

และผลต่างระหว่าง 2 ฟังก์ชันคือ $f_1(x : a_1, c_1) \times f_2(x : a_2, c_2)$ (3.18)



รูปที่ 3.10 Product of two sigmoidal membership function

การเลือกฟังก์ชันของความเป็นสมาชิก จะต้องเลือกตามความเหมาะสมความครอบคลุมของข้อมูลที่จะรับเข้ามา โดยสามารถที่ทับซ้อนกันเพื่อให้การดำเนินงานราบเรียบ ซึ่งมีความเป็นสมาชิกหลายค่าได้ และฟังก์ชันความเป็นสมาชิกเปลี่ยนแปลงแก้ไขให้เหมาะกับงานที่กำลังปฏิบัติงานหรือตามความต้องการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4 ขั้นตอนวิธีการเรียนรู้แบบไฮบริด

จากโครงสร้างของ ANFIS เมื่อค่าพารามิเตอร์หลักฐานถูกกำหนดไม่ให้เปลี่ยนแปลงเอาท์พุททั้งหมดสามารถแสดงในรูปของผลรวมเชิงเส้นของพารามิเตอร์ที่เป็นผลลัพธ์ได้ตามสมการที่ (3.19)

$$\begin{aligned} y &= \frac{w_1}{w_1 + w_2} y_1 + \frac{w_2}{w_1 + w_2} y_2 \\ &= \bar{w}_1 y_1 + \bar{w}_2 y_2 \\ &= (\bar{w}_1 x_1) p_1 + (\bar{w}_2 x_2) q_1 + \bar{w}_1 r_1 + (\bar{w}_2 x_1) p_2 + (\bar{w}_1 x_2) q_2 + \bar{w}_2 r_2 \end{aligned} \quad (3.19)$$

ดังนั้นขั้นตอนวิธีการเรียนรู้แบบไฮบริด (Hybrid) สามารถนำมาใช้ได้โดยตรงมากขึ้น โดยเฉพาะในส่วนของ การคำนวณไปข้างหน้า โหนดเอาท์พุทส่งผ่านไปข้างหน้าจนกระทั่งขั้นที่ 4 และพารามิเตอร์ที่เป็นผลลัพธ์ถูกตรวจสอบโดยวิธีการกำลังสองน้อยที่สุด (Least Squares Method) ในส่วนการคำนวณค่าย้อนกลับสัญญาณค่าผิดพลาดถูกแพร่กลับมา และพารามิเตอร์หลักฐานถูกอัปเดตโดย gradient descent [7], [21] แสดงตามตารางที่ 3.1

ตารางที่ 3.1 การส่งผ่านในกระบวนการเรียนรู้แบบไฮบริดสำหรับ ANFIS

กระบวนการเรียนรู้	ส่งผ่านไปข้างหน้า	ส่งผ่านกลับมา
พารามิเตอร์หลักฐาน	ไม่เปลี่ยนแปลง	ปรับด้วยวิธีความลาดชันที่ต่ำสุด
พารามิเตอร์ผลลัพธ์	ปรับด้วยวิธีการประเมินค่ากำลังสองน้อยที่สุด	ไม่เปลี่ยนแปลง
สัญญาณ	โหนดเอาท์พุท	สัญญาณความผิดพลาด

พารามิเตอร์ผลลัพธ์ถูกตรวจสอบให้เหมาะสมภายใต้เงื่อนไขที่พารามิเตอร์หลักฐานถูกกำหนดไม่ให้เปลี่ยนแปลงนั้น วิธีการแบบผสมจะลู่เข้าหาคำตอบได้เร็วมากขึ้น เนื่องจากลดมิติของพื้นที่ว่างในการค้นหาของวิธีการแพร่ค่าย้อนกลับแบบดั้งเดิม

ในวิทยานิพนธ์ฉบับนี้เลือกใช้ระบบอนุมานฟัซซีแบบปรับตัวได้ โดยใช้โมเดล Sugeno อันดับที่ 1 วิธีการเรียนรู้แบบไฮบริด และใช้วิธีการลองผิดลองถูก (Trial and Error) สำหรับปรับค่าฟังก์ชันสมาชิก โดยเริ่มจากการปรับเปลี่ยนชนิดของฟังก์ชันสมาชิกจนครบทั้งหมดแล้วเลือกวิธีที่ดีที่สุดเพื่อใช้เปรียบเทียบกับค่าจริง

3.5 ตัวอย่างการเรียนรู้โดยใช้ระบบนิวโรฟัซซีแบบปรับตัวได้บนโปรแกรม MATLAB

ขั้นตอนการใช้งานและการทดสอบ ANFIS มีขั้นตอนดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลของเครื่องกำเนิดไฟฟ้าที่จะใช้ในการเรียนรู้ของ ANFIS ในตัวอย่างนี้เลือกใช้ข้อมูลของระบบทดสอบ RTS ขนาด 32 เครื่อง แสดงข้อมูลในภาคผนวก ข โดยกำหนด Priority level, Installed capacity และ Force outage rate ของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องเป็นค่าอินพุท และดัชนี EENS ของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องเป็นค่าเอาท์พุท

ขั้นตอนที่ 2 สุ่มเลือกข้อมูลออกเป็น 2 ชุด คือข้อมูลสำหรับการฝึกสอน 27 ข้อมูลและข้อมูลสำหรับทดสอบ 5 ข้อมูล ตามที่ได้แสดงไปแล้วในตารางที่ 2.1 และ 2.2 ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ขั้นตอนที่ 3 นำข้อมูลอินพุท และเอาต์พุท มาทำการ normalized และ scaled

ขั้นตอนที่ 4 นำชุดข้อมูลที่จัดเตรียมไว้ป้อนในโปรแกรม MATLAB R2017a โดยกำหนดให้เมตริกซ์ train เป็นข้อมูลฝึกสอน และเมตริกซ์ test เป็นข้อมูลทดสอบ ชุดข้อมูลจะถูกบันทึกเข้าสู่ Workspace เพื่อเตรียมพร้อมสำหรับการเรียกใช้งาน

ขั้นตอนที่ 5 ใช้คำสั่ง >>anfisedit เพื่อเรียกใช้งาน ANFIS Toolbox บนโปรแกรม MATLAB

ขั้นตอนที่ 6 เลือก Load Data เพื่อนำชุดข้อมูลฝึกสอน (Train) เข้ามาใส่ใน ANFIS

ขั้นตอนที่ 7 เลือก Load Data เพื่อนำชุดข้อมูลทดสอบเข้ามาใส่ใน ANFIS จะขึ้นลักษณะกราฟข้อมูลสำหรับทดสอบ ที่ซ้อนทับกับกราฟข้อมูลสำหรับฝึกสอน ตามรูปที่ 3.11



รูปที่ 3.11 ลักษณะกราฟข้อมูลสำหรับฝึกสอนและทดสอบ บน ANFIS Toolbox

ขั้นตอนที่ 8 เลือกช่อง Generate FIS จะขึ้นหน้าต่าง และป้อนค่าจำนวน MFs และเลือกชนิดของ MFs ที่เราต้องการ ตามรูปที่ 3.12

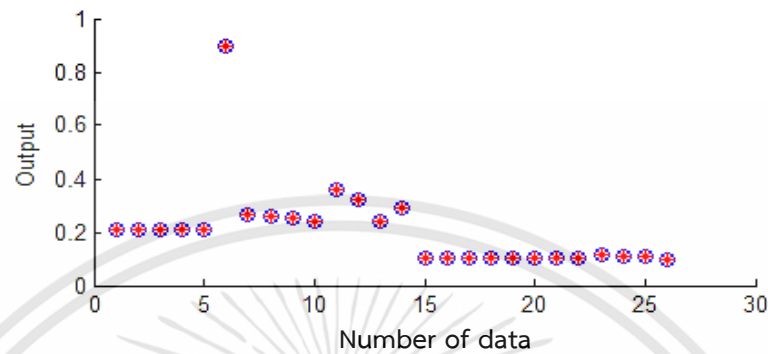
INPUT	
Number of MFs:	MF Type:
6 3 2	<ul style="list-style-type: none"> trimf trapmf gbellmf <li style="background-color: #e0ffff;">gaussmf gauss2mf pimf dsigmf psigmf
To assign a different number of MFs to each input, use spaces to separate these numbers.	
OUTPUT	
MF Type:	<ul style="list-style-type: none"> constant linear

รูปที่ 3.12 ป้อนค่า MFs และเลือกชนิดของ MFs บน ANFIS Toolbox


ขั้นตอนที่ 9 เลือกที่ช่อง Train FIS ใส่ค่า Epochs แล้วเลือกที่ Train Now โปรแกรม ANFIS จะทำการเรียนรู้และแสดงค่า error ของการฝึกสอน (Training) ออกมา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ขั้นตอนที่ 10 เลือก Testing data แล้วเลือก Test Now จะได้ค่า error ของการทดสอบ (Testing) ออกมา หลังจากนั้นทำการปรับเปลี่ยนจำนวน ชนิดของ MFs โดยใช้วิธีการลองผิดลองถูก จนกว่าจะได้ค่า error ที่เรายอมรับได้ โดยผลการฝึกสอนของ ANFIS แสดงตามรูปที่ 3.13 และผลการทดสอบของ ANFIS แสดงตามรูปที่ 3.14



รูปที่ 3.13 การฝึกสอน (Training) บน ANFIS Toolbox

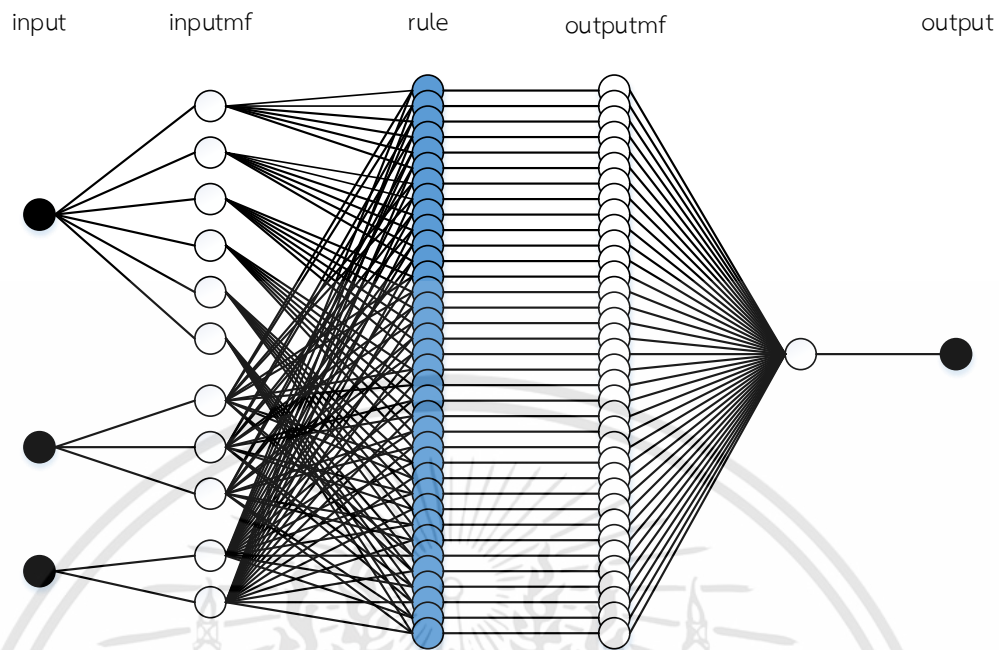


รูปที่ 3.14 การทดสอบ (Testing) บน ANFIS Toolbox

ขั้นตอนที่ 11 เมื่อได้ค่า error ที่ยอมรับได้ ทำการ export file เพื่อนำกระบวนการเรียนรู้ของ ANFIS ไปใช้ในการพยากรณ์ค่า โดยสามารถแสดงลักษณะโครงสร้างของฟังก์ชันสมาชิกตามที่กำหนดได้ตามรูปที่ 3.15

ขั้นตอนที่ 12 หากคำตอบ ใช้คำสั่ง `>>evalfis` ([เซตข้อมูล input ที่ต้องการทราบค่า output], ชื่อไฟล์) โปรแกรมจะแสดงค่าข้อมูลด้านออก (output) ที่สัมพันธ์กับค่าข้อมูลด้านเข้า (input)

ขั้นตอนที่ 13 นำค่าข้อมูลด้านออก (output) ที่ได้มาทำการ Unnormalized และ Unscaled เพื่อหาค่าจริง



รูปที่ 3.15 โครงสร้างของฟังก์ชันสมาชิกเมื่อปรับค่า MFs 6 3 2 บน ANFIS Toolbox

จากรูปที่ 3.15 แสดงลักษณะของโครงสร้างที่มีอินพุต 3 ตัว และจำนวนฟังก์ชันสมาชิกของอินพุต เป็น 6 3 2 ตามลำดับ โดยใช้กฎของฟัชซี คือ and ซึ่งจากการปรับเปลี่ยนกฎของฟัชซีแล้วพบว่า กฎ and ให้ผลลัพธ์ที่มีค่าผิดพลาดน้อยที่สุด

3.6 การวัดประสิทธิภาพของ ANFIS

การวัดความแม่นยำของ ANFIS จะใช้จะใช้ค่าผิดพลาดเฉลี่ยสมบูรณ์ (Mean Absolute Percentage Error, MAPE) จากค่าความคลาดเคลื่อนของค่าพยากรณ์ที่เป็นคำตอบของ ANFIS ที่ผ่านการฝึกสอนแล้วเปรียบเทียบกับคำตอบจริง [20] ตามสมการที่ (3.20)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{OP_{actual} - OP_{ANFIS}}{OP_{actual}} \right| \times 100\% \quad (3.20)$$

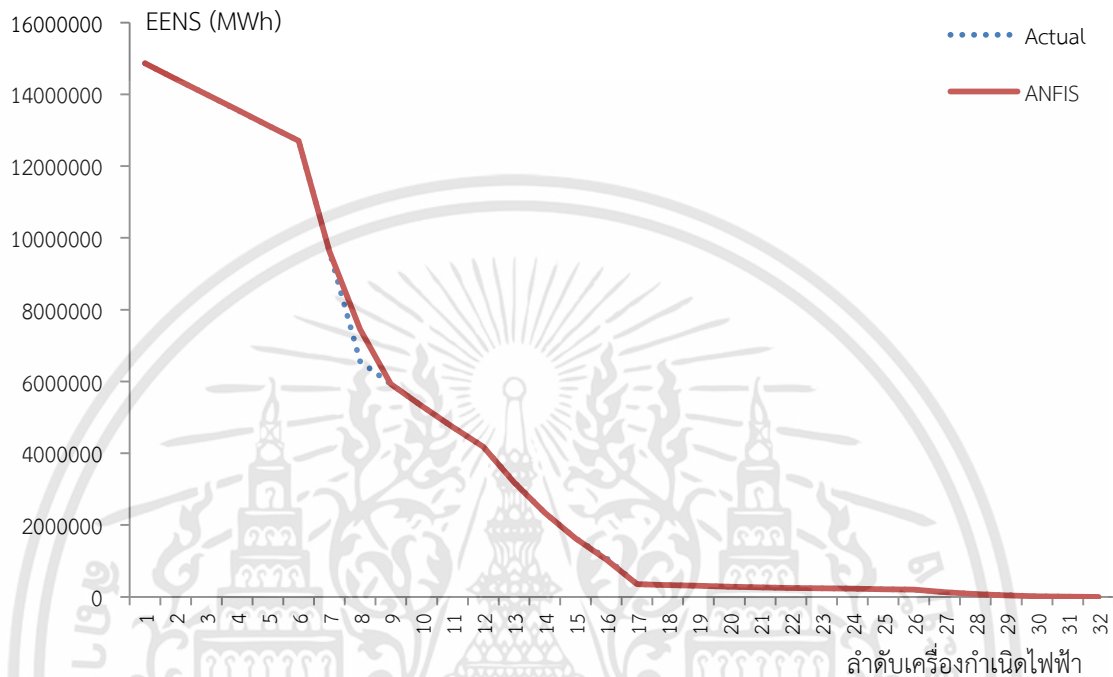
โดยที่ OP_{actual} คือ เอาท์พุทจริง
 OP_{ANFIS} คือ เอาท์พุทที่ได้จาก ANFIS
 N คือ จำนวนข้อมูลทดสอบ

ตารางที่ 3.2 ผลลัพธ์ที่ดีที่สุดที่ได้จากการเรียนรู้ของ ANFIS

ระบบที่ใช้ในการฝึกสอน	โครงสร้างที่ดีที่สุด	MF Type		ค่า MAPE ของชุดฝึกสอน (%)	ค่า MAPE ของชุดทดสอบ (%)
		trimf	linear		
ANFIS	7 2 5	trimf	linear	0.0736	4.1499

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการทดสอบต้องใช้ในการปรับค่าพารามิเตอร์ต่างๆ ของ ANFIS เช่น ปรับค่าฟังก์ชันสมาชิก ปรับค่าโครงสร้าง เป็นต้น เพื่อให้ ANFIS ได้เรียนรู้และจดจำและต้องใช้วิธีการลองผิดลองถูก เพื่อหาผลลัพธ์ที่ดีที่สุด แสดงตามตารางที่ 3.2 จากนั้นนำค่าประมาณที่ได้จาก ANFIS มาเปรียบเทียบกับค่าจริง แสดงตามรูปที่ 3.16



รูปที่ 3.16 เปรียบเทียบระหว่างค่าเอาต์พุตจริงและค่าเอาต์พุตที่ได้จาก ANFIS

จากรูปที่ 3.16 แสดงการเปรียบเทียบการประเมินดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้า ระหว่างค่าจริงกับค่าที่ได้จากกระบวนการเรียนรู้ของระบบอนุมานนิเวโรฟซซีแบบปรับตัวได้ (ANFIS) พบว่ามี %MAPE ของข้อมูลฝึกสอนเป็น 0.0736% และ %MAPE ของข้อมูลทดสอบเป็น 4.1499%

บทที่ 4

พลังงานลม

4.1 พลังลม

โดยทั่วไปเราสามารถผลิตพลังงานไฟฟ้าจากพลังงานลมได้โดยใช้เครื่องกำเนิดไฟฟ้าที่ติดตั้งในแนวอนบนหอสูงประมาณ 30 – 50 เมตร ซึ่งตามปกติแล้วมักจะใช้เครื่องผลิตไฟฟ้าที่มีขนาดประมาณ 300 – 500 kW โดยโรเตอร์จะถูกผูกด้วยกังหันลมชนิด 2 หรือ 3 ใบพัด จากนั้นจึงเกิดการเปลี่ยนพลังกลเป็นพลังงานไฟฟ้าเช่นเดียวกับโรงไฟฟ้าทั่วไป ซึ่งอุปกรณ์ที่ช่วยในการเปลี่ยนจากพลังงานลมออกมาเป็นพลังงานในรูปอื่นๆ [5] เช่น พลังงานไฟฟ้า หรือ พลังงานกล ได้แก่ กังหันลม เป็นต้น

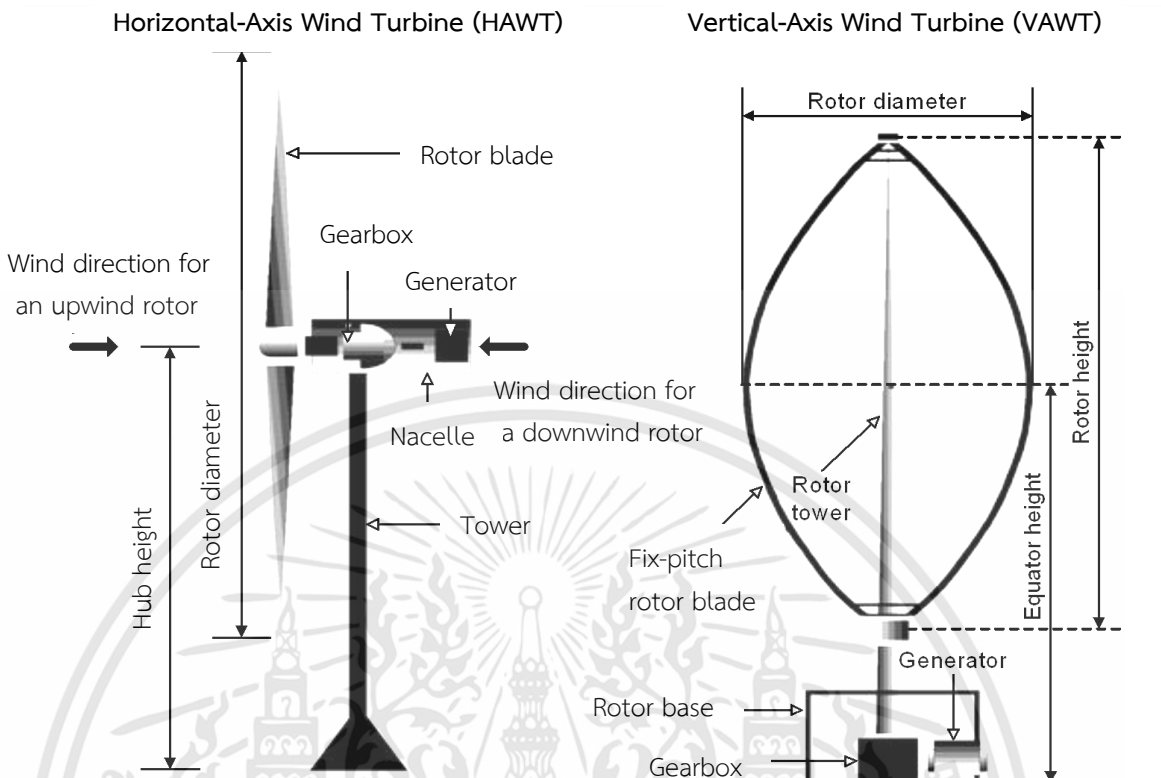
สำหรับประเทศไทยซึ่งมีความเร็วลมเฉลี่ยต่ำจำเป็นต้องใช้จำนวนกังหันลมและพื้นที่มากเพื่อผลิตพลังงานไฟฟ้าตามที่ต้องการ จะเห็นได้ว่าความเร็วของลมมีผลต่อกำลังการผลิตสูงมาก ที่ความเร็วลมต่ำๆ จะมีพลังงานไม่เพียงพอสำหรับหมุนกังหันลมที่ต่ออยู่กับเครื่องกำเนิดไฟฟ้าจึงไม่สามารถผลิตพลังงานขึ้นได้ กังหันลมโดยทั่วไปจะมีเส้นผ่านศูนย์กลางของแกนหมุนประมาณ 20 เมตร และหมุนด้วยความเร็วประมาณ 100 – 150 rpm เพื่อที่จะนำไปขับเคลื่อนเครื่องกำเนิดไฟฟ้า เหนียววนที่ถูกกระตุ้นด้วยไฟฟ้าจากระบบจ่ายไฟ ประเทศไทยมีศักยภาพของการใช้พลังงานในการผลิตไฟฟ้าไม่มากนักเนื่องจากพื้นที่ทั่วไปมีความเร็วลมเฉลี่ยต่ำกว่าที่จะนำมาใช้ประโยชน์ได้ ยกเว้นบริเวณชายฝั่งทะเลบางแห่ง

4.1.1 เทคโนโลยีกังหันลม

กังหันลมจะทำหน้าที่เปลี่ยนพลังงานลมที่อยู่ในรูปของพลังงานจลน์ไปเป็นพลังงานกลโดยการหมุนของใบพัด แรงจากการหมุนของใบพัดนี้จะถูกส่งผ่านแกนหมุนทำให้เฟืองเกียร์ที่ติดอยู่กับแกนหมุนเกิดการหมุนตามไปด้วย พลังงานกลที่ได้จะไปขับเคลื่อนให้เครื่องกำเนิดไฟฟ้าทำงาน ด้วยหลักการนี้เครื่องกำเนิดไฟฟ้าจะสามารถผลิตกระแสไฟฟ้าออกมาได้ กังหันลมสามารถแบ่งออกได้เป็น 2 ประเภท [17] คือ

1. กังหันลมที่มีแกนเพลลาอยู่ในแนวอน (Horizontal-axis type wind turbine, HAWT) เป็นกังหันลมที่มีแกนหมุนวางตัวอยู่ในทิศทางกับทิศทางของลม โดยมีใบเป็นตัวยึดรับแรงลม กังหันลมประเภทนี้ได้รับการพัฒนาอย่างต่อเนื่องและมีการนำมาใช้งานมากในปัจจุบัน เนื่องจากมีประสิทธิภาพในการเปลี่ยนพลังงานสูงแต่ต้องติดตั้งบนเสาที่มีความสูงมาก และมีชุดควบคุมให้กังหันลมหันหน้าเข้ารับแรงลมได้ทุกทิศทางในแนวอนตลอดเวลา แสดงตามรูปที่ 4.1

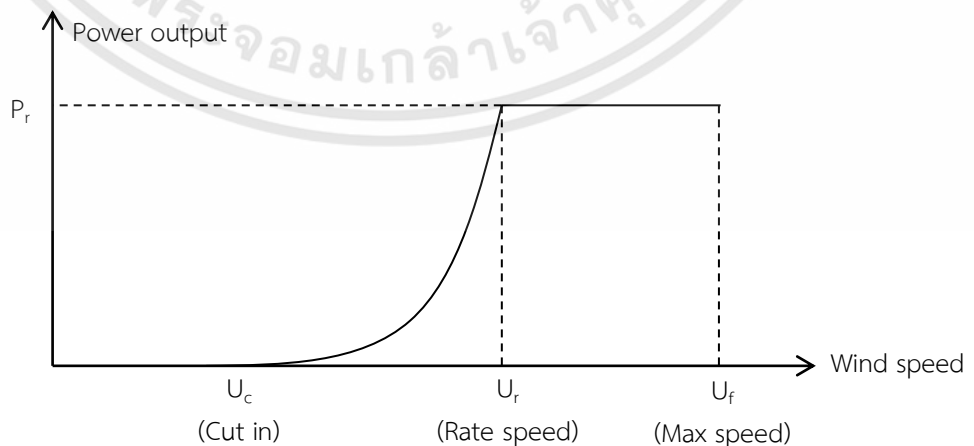
2. กังหันลมที่มีแกนเพลลาอยู่ในแนวตั้ง (Vertical-axis type wind turbine, VAWT) เป็นกังหันลมที่มีแกนหมุนตั้งฉากกับทิศทางของลม ซึ่งสามารถรับลมได้ทุกทิศทางและติดตั้งอยู่ในระดับต่ำได้ ข้อดีของกังหันลมแนวตั้งคือ สามารถรับลมได้ทุกทิศทาง ชุดปรับความเร็ว (gear box) และเครื่องกำเนิดไฟฟ้าสามารถติดตั้งอยู่ที่ระดับพื้นล่างได้ นอกจากนี้ตัวเสาของกังหันลมยังไม่สูงมากนัก แต่มีข้อเสียคือประสิทธิภาพต่ำเมื่อเทียบกับกังหันลมที่มีแกนเพลลาแบบแนวอน ดังนั้นจึงมีการใช้งานอยู่น้อย แสดงตามรูปที่ 4.1



รูปที่ 4.1 กังหันลมผลิตไฟฟ้าแบบแกนนอนและแบบแกนตั้ง [17]

4.1.2 ช่วงการทำงานของกังหันลม

โดยทั่วไปกังหันลมจะเริ่มผลิตกำลังไฟฟ้าได้ที่ความเร็ว U_c (ประมาณ 3 – 5 m/s) และจะเพิ่มขึ้นตามความเร็วลมจนกระทั่งถึงค่ากำลังพิกัด P_r ที่ความเร็ว U_r หลังจากนั้นกังหันจะถูกควบคุมโดยใช้มุมหรือการบิดของใบพัด เพื่อผลิตกำลังงานพิกัดได้ที่ความเร็วลมสูงสุด U_f ถ้าลมมีความเร็วมากกว่าจุด U_f ใบพัดจะเก็บลงและหยุดเดินเครื่องเพื่อความปลอดภัยและป้องกันความเสียหายที่อาจเกิดขึ้นกับกังหันลม [6] แสดงตามรูปที่ 4.2



รูปที่ 4.2 ความสัมพันธ์ระหว่างความเร็วลมและกำลังผลิตไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2 การกระจายข้อมูลแบบไวบูลล์

การกระจายตัวของความเร็วลมโดยทั่วไปจะมีลักษณะเป็นแบบเบ้ไปข้างใดข้างหนึ่ง (Skew function) ซึ่งไม่ใช่การกระจายตัวแบบสมมาตร (Normal distribution) ฟังก์ชันที่นิยมเพื่อนำมาใช้งานอย่างแพร่หลาย [2] คือ การกระจายแบบไวบูลล์ (Weibull distribution) และการกระจายแบบเรย์เลย์ (Rayleigh distribution) ซึ่งเรย์เลย์ฟังก์ชันถือเป็นกรณีพิเศษของไวบูลล์ฟังก์ชันที่มีค่าพารามิเตอร์รูปร่างเท่ากับ 2 ผลที่ได้จากการเปรียบเทียบระหว่างไวบูลล์ฟังก์ชันและเรย์เลย์ฟังก์ชันพบว่าไวบูลล์จะให้ความแม่นยำกว่าเนื่องจากค่า k ของไวบูลล์เป็นตัวแปรที่เหมาะสมของลมในแต่ละพื้นที่

ซึ่งการกระจายข้อมูลแบบไวบูลล์สามารถแสดงในรูปของฟังก์ชันความหนาแน่นของการกระจาย (Probability density function) หรือแทนความน่าจะเป็นของความเร็วลมแต่ละช่วง 1 m/s ได้ตามสมการที่ (4.1)

$$f(u) = \frac{k}{A} \left(\frac{u}{A}\right)^{k-1} \exp\left\{-\left(\frac{u}{A}\right)^k\right\} \quad (4.1)$$

และเขียนในรูปของฟังก์ชันความหนาแน่นสะสม (Cumulative density function) ได้ตามสมการที่ (4.2)

$$f(u) = 1 - \exp\left\{-\left(\frac{u}{A}\right)^k\right\} \quad (4.2)$$

โดยที่ u คือ ความเร็วเฉลี่ย (m/s), $u > 1$
 k คือ Weibull's shape parameter, $k > 0$
 A คือ Weibull's scale parameter, $A > 1$,

พารามิเตอร์ A สามารถคำนวณได้ตามสมการที่ (4.3)

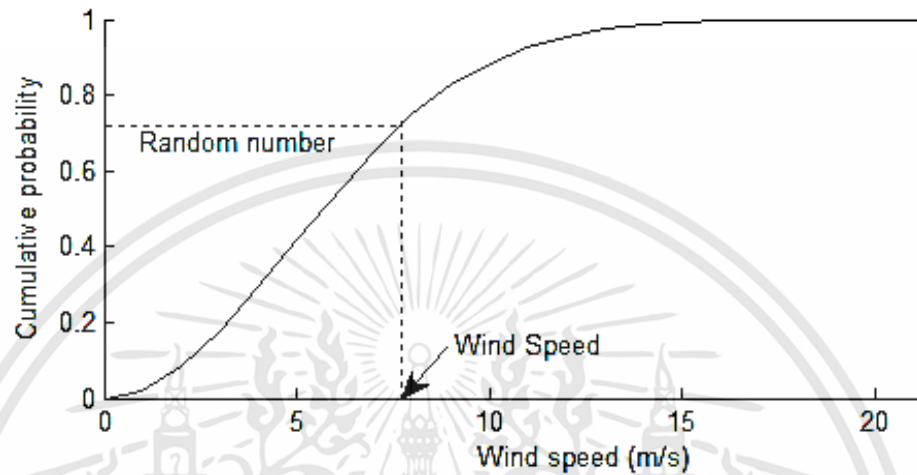
$$A = \frac{u}{\Gamma\left(1 + \frac{1}{k}\right)} \quad (4.3)$$

โดยที่ $\Gamma(x)$ = Gamma function = $\int_0^{\infty} e^{-t} t^{x-1} dt$

สำหรับพารามิเตอร์ k ในวิทยานิพนธ์ฉบับนี้ได้ทำการทดสอบเพื่อหาค่า k ที่ดีที่สุดสำหรับลักษณะการกระจายข้อมูล พบว่า $k = 2$ ให้ผลการทดสอบที่ดีที่สุด ซึ่งแสดงผลการทดสอบในบทที่ 6

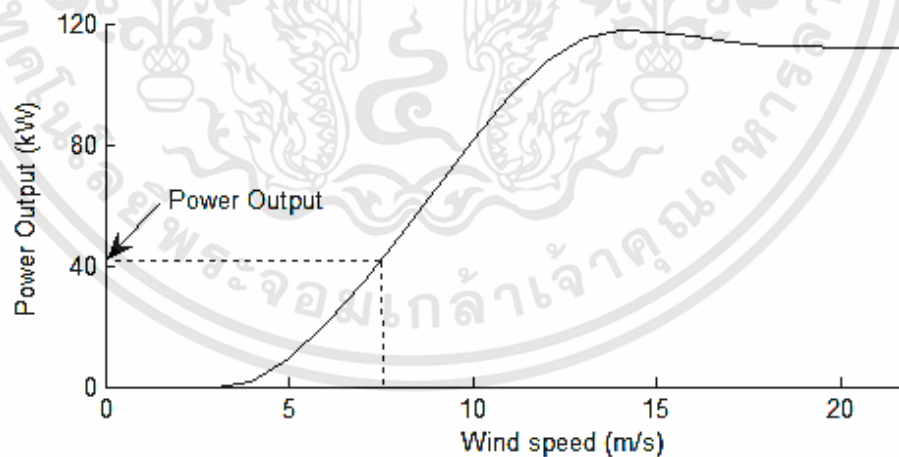
4.3 หลักการวิเคราะห์การผลิตไฟฟ้าจากพลังงานลม

การคำนวณกำลังไฟฟ้าขาออกจากกังหันลมจะเริ่มประมาณค่าความเร็วลมที่เวลาต่าง ๆ โดยอาศัยการสุ่มตัวเลขเทียบกับกราฟความหนาแน่นสะสมในสมการที่ (4.2) ผลจากการสุ่มความเร็วลมทั้งหมดจะทำให้มีค่าความเร็วลมเฉลี่ยของพื้นที่ที่จะติดตั้งกังหันลมใกล้เคียงกับค่าที่ทราบจากการตรวจวัดในเบื้องต้น ตัวอย่างการสุ่มค่าความเร็วลมได้นำแสดงในรูปที่ 4.3



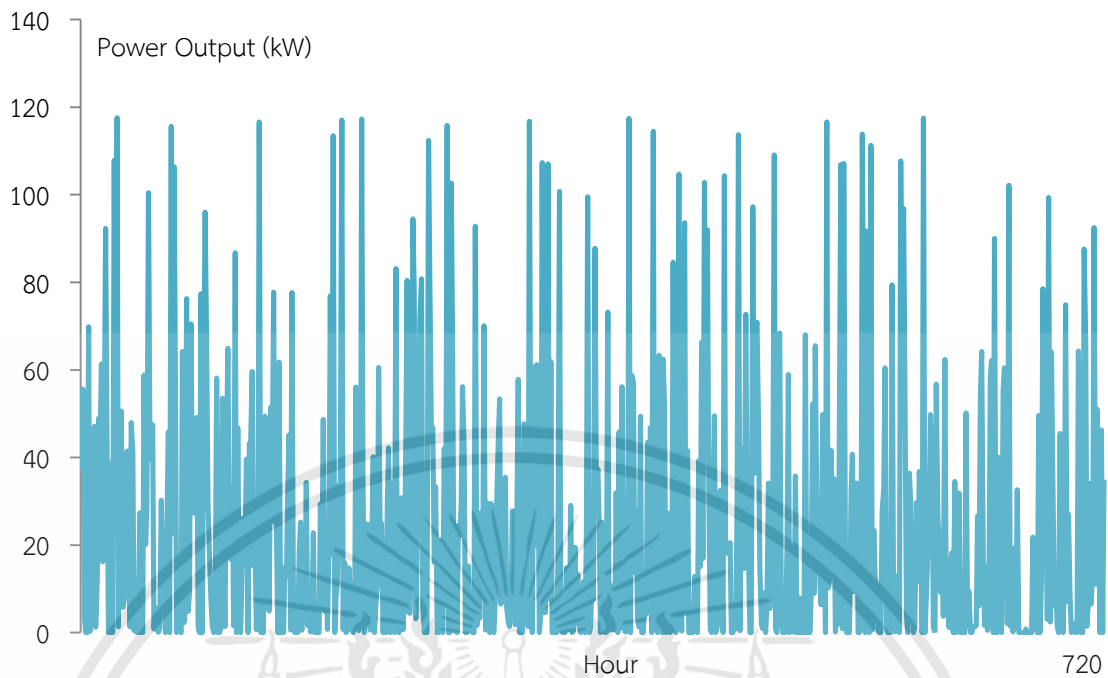
รูปที่ 4.3 การสุ่มค่าความเร็วลม

จากนั้นค่าความเร็วลมที่ได้จะใช้ในการหาค่ากำลังไฟฟ้าที่ผลิตโดยใช้การเปรียบเทียบระหว่างความเร็วลมเฉลี่ยรายชั่วโมงและกราฟกำลังไฟฟ้าขาออกของกังหันลม Nordtank ขนาด 150 kW ซึ่งแสดงดังรูปที่ 4.4



รูปที่ 4.4 การแปลงความเร็วลมสู่กำลังผลิตไฟฟ้า

กำลังไฟฟ้าขาออกจากกังหันลม Nordtank ขนาด 150 kW ที่ได้จากการวิเคราะห์ แสดงดังรูปที่ 4.5



รูปที่ 4.5 กำลังไฟฟ้าที่ผลิตได้จากกังหันลม Nordtank ขนาด 150 kW

จากรูปที่ 4.5 จะเห็นว่ากำลังไฟฟ้าที่กังหันลมสามารถผลิตได้ในแต่ละชั่วโมงมีค่าไม่คงที่ ขึ้นอยู่กับกำลังลมที่สามารถทำให้กังหันลมผลิตไฟฟ้าได้ แต่ค่ากำลังไฟฟ้าที่ได้จากการคำนวณซึ่งจะนำไปใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไป อาจมีการคลาดเคลื่อนเพราะเป็นค่าจากการสุ่มตัวเลข ดังนั้นจึงต้องมีการเปรียบเทียบค่าจากการคำนวณกับข้อมูลที่ตรวจบันทึกไว้ เพื่อปรับค่าพารามิเตอร์ k ในการคำนวณให้สามารถคำนวณค่ากำลังไฟฟ้าได้สอดคล้องกับความเป็นจริงมากที่สุด ในวิทยานิพนธ์ฉบับนี้ได้นำข้อมูลที่ตรวจบันทึกไว้จากสถานีแหลมพรหมเทพ ภูเก็ต ซึ่งเป็นข้อมูลผลรวมพลังงานที่กังหันลมสามารถผลิตได้ในแต่ละปีมาเปรียบเทียบกับข้อมูลที่ได้จากการทดสอบ โดยนำเสนอการสร้างแบบจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) และระบบนิรนัยแบบปรับตัวได้ Adaptive Neuro-Fuzzy Inference System, ANFIS) มาทดสอบเพื่อเปรียบเทียบหาผลลัพธ์ที่ดีที่สุดสำหรับการจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลม ซึ่งแสดงในบทที่ 6

บทที่ 5

การวิเคราะห์ความเชื่อถือได้ในระบบไฟฟ้ากำลัง

5.1 แนวคิดและหลักการวิเคราะห์ความเชื่อถือได้ในระบบไฟฟ้ากำลัง

โดยทั่วไปสามารถแบ่งการพิจารณาความเชื่อถือได้ของระบบไฟฟ้ากำลังได้ดังนี้ [9]


1. ความเพียงพอของระบบ (System adequacy)

หมายถึง ความสามารถของระบบไฟฟ้ากำลังที่จะสามารถจ่ายกระแสไฟฟ้าและพลังงานทั้งหมดได้อย่างเพียงพอต่อความต้องการใช้ไฟฟ้า โดยที่อุปกรณ์ต่างๆในระบบไฟฟ้ากำลังยังคงทำงานภายในพิกัดและมีระดับแรงดันอยู่ในช่วงที่กำหนด การศึกษาความเชื่อถือได้ที่เกี่ยวข้องกับความเพียงพอของระบบ เป็นการวิเคราะห์ระบบไฟฟ้ากำลังในสภาวะอยู่ตัว (Steady-state condition) เพื่อทำการตรวจสอบปัญหาที่อาจจะเกิดขึ้นต่อระบบไฟฟ้ากำลัง

2. ความมั่นคงของระบบ (System security)

หมายถึง ความสามารถของระบบไฟฟ้ากำลังที่สามารถทนต่อการเปลี่ยนแปลงแบบทันทีทันใดซึ่งเกิดขึ้นกับระบบไฟฟ้ากำลัง เช่น เกิดการลัดวงจรขึ้นในระบบหรืออุปกรณ์ในระบบเกิดขัดข้องทันทีทันใดโดยไม่ทราบล่วงหน้า เป็นต้น การศึกษาความเชื่อถือได้ในด้านความมั่นคงของระบบจะทำการวิเคราะห์ในสภาวะพลวัต (Dynamic condition)

ในการวางแผนการผลิตไฟฟ้านั้นจะคำนึงถึงความเชื่อถือได้ในแง่ของความเพียงพอของระบบเป็นหลัก โดยที่จะต้องมีการเพิ่มโรงไฟฟ้าเข้ามาในระบบเพื่อให้เพียงพอต่อความต้องการของผู้ใช้ไฟฟ้าโดยทั่วไป เราสามารถจำแนกหน้าที่การทำงานของระบบไฟฟ้ากำลังได้เป็น 3 ส่วน ได้แก่ระบบผลิตไฟฟ้า ระบบส่งไฟฟ้า และระบบจำหน่ายไฟฟ้า ดังนั้นในการศึกษาความเชื่อถือได้จึงสามารถแบ่งระดับชั้นในการศึกษาได้ 3 ระดับ



รูปที่ 5.1 ขอบเขตการทำงานพื้นฐานในระบบไฟฟ้ากำลัง

จากรูปที่ 5.1 หากพิจารณาในแง่การประเมินความเชื่อถือได้โดยรวมแล้วจะสามารถแบ่งลำดับชั้น (Hierarchical level: HL) ของการศึกษาได้เป็น 3 ระดับ ดังนี้

ลำดับชั้นที่ 1 (Hierarchical Level One: HL1) เป็นการพิจารณาเฉพาะระบบผลิตไฟฟ้า

ลำดับชั้นที่ 2 (Hierarchical Level Two: HL2) เป็นการพิจารณาระบบผลิตไฟฟ้าร่วมกับระบบส่งไฟฟ้า

ลำดับชั้นที่ 3 (Hierarchical Level Three: HL3) เป็นการพิจารณารวมทั้ง 3 ระบบ คือ ระบบผลิตไฟฟ้า ระบบส่งไฟฟ้าและระบบจำหน่ายไฟฟ้า

ในการวางแผนกำลังการผลิตไฟฟ้าส่วนใหญ่เป็นการศึกษาระดับชั้นที่ 1 คือ พิจารณาเฉพาะระบบผลิตไฟฟ้าเพียงระบบเดียวซึ่งเป็นการศึกษาถึงความสามารถของระบบผลิตไฟฟ้าที่สามารถจ่ายไฟฟ้าได้อย่างเพียงพอต่อความต้องการใช้ไฟฟ้าของระบบไฟฟ้ากำลัง และเป็นการหาค่าความเชื่อถือได้ของระบบ อันเป็นผลเนื่องจากสถานะการเกิดเหตุการณ์ขัดข้องในเครื่องกำเนิดไฟฟ้าเพียงอย่างเดียว ซึ่งอาจทำให้กำลังการผลิตรวมของระบบไม่เพียงพอกับความต้องการของโหลด ในการสร้างแบบจำลองจะพิจารณารายละเอียดเฉพาะเครื่องกำเนิดไฟฟ้าและแบบจำลองความต้องการใช้ไฟฟ้า ดังนั้นจึงสามารถจำลองระบบที่ทำการประเมินความเชื่อถือได้ในระดับชั้นที่ 1 ได้ตามรูปที่ 5.2

กำลังการผลิตไฟฟ้ารวมของระบบ



โหลดรวมของระบบ


รูปที่ 5.2 แบบจำลองระบบสำหรับการประเมินความเชื่อถือได้ในระดับชั้นที่ 1

5.2 แบบจำลองการทำงานของอุปกรณ์

การพิจารณาค่ากำลังผลิตที่เพียงพอกับความต้องการไฟฟ้านั้น เป็นปัญหาที่สำคัญประการหนึ่งในการวางแผนกำลังผลิตในระบบไฟฟ้า การพิจารณาค่าความเพียงพอของการผลิตจะมีการสร้างแบบจำลองพื้นฐานเพื่อเป็นตัวแทนของระบบไฟฟ้าที่จำเป็น 3 ส่วน ได้แก่

1. แบบจำลองการผลิต (Generation model)
2. แบบจำลองโหลด (Load model)
3. แบบจำลองความเสี่ยง (Risk model)

โดยแบบจำลองการผลิตและโหลด จะถูกนำมารวมกันเป็นแบบจำลองของความเสี่ยงที่เหมาะสมแสดงตามรูปที่ 5.3



รูปที่ 5.3 แบบจำลองที่ใช้ในการประเมินค่าความเชื่อถือได้ของระบบผลิตไฟฟ้า [4]

แบบจำลองของระบบผลิตไฟฟ้าสามารถแสดงได้โดยการสร้างตารางความน่าจะเป็นของการขาดกำลังการผลิต (Capacity Outage Probability Table: COPT) โดยตารางนี้จะแสดงสถานะกำลังการผลิตที่เกิดเหตุขัดข้องที่เป็นไปได้ทั้งหมด อีกทั้งยังแสดงค่าความน่าจะเป็นและความถี่ของการเกิดสถานะต่างๆ ดังกล่าว ส่วนแบบจำลองของโหลดนั้นสามารถพิจารณาได้หลายแบบ ยกตัวอย่างเช่น แบบจำลองการเปลี่ยนแปลงของโหลดสูงสุดรายวัน (Daily peak load variation curve) ซึ่งจะพิจารณาเฉพาะโหลดสูงสุดรายวันเท่านั้น หรือโหลดที่เวลาต่างๆ (Load Duration Curve) ซึ่งพิจารณาการเปลี่ยนแปลงของโหลดทุกๆ ชั่วโมงหรือทุกๆ วัน ส่วนแบบจำลองความเสี่ยงนั้น สามารถคำนวณได้โดยการรวมแบบจำลองของระบบผลิตไฟฟ้าและแบบจำลองของโหลดเข้าด้วยกัน ซึ่งก็จะทำให้สามารถคำนวณค่าดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้าได้ในที่สุด


5.3 แบบจำลองของระบบผลิตไฟฟ้า

การสร้างแบบจำลองของระบบผลิตไฟฟ้านั้นสามารถแบ่งการพิจารณาออกเป็น 3 ส่วน คือ แบบจำลองรอบการทำงานของอุปกรณ์ในระบบ แบบจำลองมาร์คอฟฟ์ 2 สถานะ และตารางความน่าจะเป็นในการขาดกำลังการผลิต ดังต่อไปนี้

5.3.1 แบบจำลองรอบการทำงานของอุปกรณ์ในระบบ

การทำงานของอุปกรณ์ในช่วงระยะเวลาหนึ่ง พบว่าการทำงานปกติของอุปกรณ์มีลักษณะเป็นช่วงตามคาบเวลาที่ไม่สม่ำเสมอ (Non-periodic) ประกอบด้วยสถานะทำงานปกติ “สถานะดี” (Operable state) สลับกับสถานะขัดข้อง “สถานะเสีย” (Failed state) โดย “สถานะเสีย” นั้นมักเกิดจากการที่อุปกรณ์ขัดข้องหรือเสียหายแต่หลังจากทำการซ่อมแซมเสร็จเรียบร้อยแล้วก็สามารถใช้งานได้ต่อไป

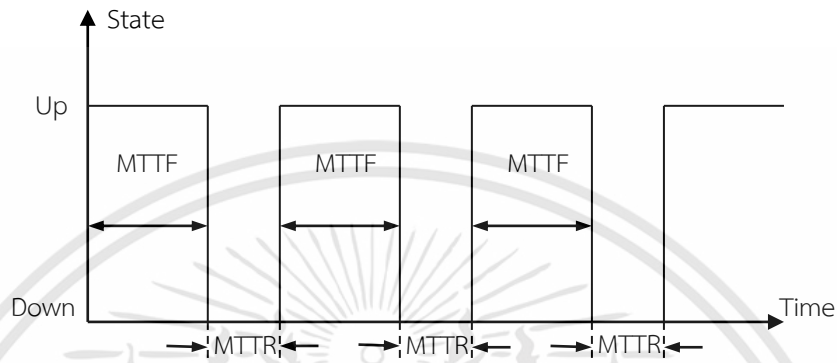
หากพิจารณาอุปกรณ์ที่มีแบบจำลองการทำงานเป็นแบบ 2 สถานะ คือ “ดี” และ “เสีย” จะพบว่าการทำงานของอุปกรณ์ต่างๆ เหล่านี้จะมีลักษณะเป็นวัฏจักรของเวลา [4] แสดงตามรูปที่ 5.4



รูปที่ 5.4 ลักษณะการทำงานของอุปกรณ์ในระบบไฟฟ้า

โดยที่ TTF_i คือ ระยะเวลาที่อุปกรณ์อยู่ในสถานะ “ดี” ซึ่งสามารถทำงานได้ในครั้งที่ i
 TTR_i คือ ระยะเวลาที่อุปกรณ์อยู่ในสถานะ “เสีย” ซึ่งแสดงถึงระยะเวลาในการซ่อมแซมอุปกรณ์ ครั้งที่ i

จะเห็นว่าช่วงเวลาที่อุปกรณ์อยู่ในสถานะ “ดี” และช่วงเวลาที่ระยะเวลาที่อุปกรณ์อยู่ในสถานะ “เสีย” ในแต่ละช่วงอาจจะมีค่าไม่เท่ากัน ดังนั้นในการพิจารณาแบบจำลองของอุปกรณ์ไฟฟ้าในระบบ เพื่อเป็นตัวแทนการทำงานของอุปกรณ์ดังกล่าวในระยะยาวจะใช้ค่าประมาณเป็นระยะเวลาเฉลี่ยในสถานะ “ดี” และระยะเวลาเฉลี่ยที่อุปกรณ์อยู่ในสถานะ “เสีย” ส่วนช่วงคาบเวลาแสดงพฤติกรรมของอุปกรณ์จะมีลักษณะเป็นคาบเวลาสม่ำเสมอ (Periodic) [4] แสดงตามรูปที่ 5.5



รูปที่ 5.5 การทำงานค่าสถานการณ์ทำงานเฉลี่ยของอุปกรณ์ในระบบไฟฟ้า

โดยที่ MTTF คือ ระยะเวลาโดยเฉลี่ยที่อุปกรณ์อยู่ในสถานะ “ดี” (ค่าเฉลี่ยของ TTF_i)
 MTTR คือ ระยะเวลาโดยเฉลี่ยที่อุปกรณ์อยู่ในสถานะ “เสีย” (ค่าเฉลี่ยของ TTR_i)

แนวคิดทางด้านความถี่และช่วงเวลาการทำงานของอุปกรณ์สามารถอธิบายได้โดยอาศัยแบบจำลองของอุปกรณ์ที่สามารถซ่อมได้ (Repairable component) ตามรูปที่ 5.5 จะเห็นว่าสถานะการทำงานของอุปกรณ์มี 2 สถานะคือ ดี (Up) และ เสีย (Down) ดังนั้น สามารถแสดงการหาความน่าจะเป็นได้ตามสมการที่ (5.1)

$$P(s) = \frac{M(s)}{T(s)} \tag{5.1}$$

โดยที่ P (s) คือ ความน่าจะเป็นของภาวะที่อยู่ในสถานะ s
 M (s) คือ ช่วงเวลาโดยเฉลี่ยที่จะอยู่ในสถานะ s
 T (s) คือ ช่วงเวลาโดยเฉลี่ยเมื่อกลับมาสู่สถานะ s อีกครั้ง หรือคาบของเวลา


จากรูปที่ 5.5 ความน่าจะเป็นที่จะอยู่ในสถานะ “ดี (Up) “ และ สถานะ “เสีย (Down) “ แสดงได้ตามสมการที่ (5.2)

$$P_{up} = \frac{m}{m+r} \quad \text{และ} \quad P_{down} = \frac{r}{m+r} \tag{5.2}$$

โดยที่ m คือ MTTF ระยะเวลาโดยเฉลี่ยที่อุปกรณ์อยู่ในสถานะดี
 r คือ MTTR ระยะเวลาโดยเฉลี่ยที่อุปกรณ์อยู่ในสถานะเสีย

5.3.2 แบบจำลองมาร์คอฟ 2 สถานะ

โดยทั่วไปลักษณะการทำงานของอุปกรณ์ต่างๆในระบบไฟฟ้า เช่น เครื่องกำเนิดไฟฟ้าจะมีลักษณะการทำงานเป็นคาบเวลาระหว่างสถานะที่ทำงานได้และทำงานไม่ได้สลับกันไป โดยสถานะที่ทำงานไม่ได้นั้นมักเกิดจากการที่อุปกรณ์ขัดข้องหรือเสียหายแต่หลังจากทำการซ่อมแซมเสร็จเรียบร้อยแล้วก็สามารถใช้งานได้ต่อไป เราสามารถแสดงแบบจำลองการทำงานของเครื่องกำเนิดไฟฟ้าโดยอาศัยแบบจำลองมาร์คอฟ 2 สถานะ (2-state Markov model) [4] ได้ตามรูปที่ 5.6



รูปที่ 5.6 แบบจำลองมาร์คอฟ 2 สถานะสำหรับเครื่องกำเนิดไฟฟ้า

พิจารณาแบบจำลองมาร์คอฟ 2 สถานะในรูปที่ 5.6 จากการประยุกต์ใช้เมทริกซ์ความน่าจะเป็นในการเปลี่ยนสถานะแบบ Stochastic (Stochastic transitional probability matrix) สำหรับกระบวนการมาร์คอฟแบบต่อเนื่อง (Continuous Markov process) เราจะได้สมการการเปลี่ยนสถานะแบบ Stochastic (Stochastic transition equation) ตามสมการที่ (5.3) ถึง (5.5)

$$\begin{bmatrix} 1-\lambda & \mu \\ \lambda & 1-\mu \end{bmatrix} \begin{bmatrix} P_{up} \\ P_{down} \end{bmatrix} = \begin{bmatrix} P_{up} \\ P_{down} \end{bmatrix} \quad (5.3)$$

$$\text{และสมการตามกฎของความน่าจะเป็นคือ} \quad P_{up} + P_{down} = 1 \quad (5.4)$$

ผลลัพธ์ของสมการที่ (5.3) คือ

$$P_{up} = \frac{\mu}{\lambda + \mu} \quad \text{และ} \quad P_{down} = \frac{\lambda}{\lambda + \mu} \quad (5.5)$$

โดยที่	P_{up}	คือ	ความน่าจะเป็นในสถานะอยู่ตัว (steady state) ที่อุปกรณ์จะอยู่ในสถานะดี
	P_{down}	คือ	ความน่าจะเป็นในสถานะอยู่ตัว (steady state) ที่อุปกรณ์จะอยู่ในสถานะเสีย
	λ	คือ	อัตราการเสีย (Failure rate) หรืออัตราการออกจากสถานะดี
	μ	คือ	อัตราการซ่อม (Repair rate) หรืออัตราการเข้าสู่สถานะดี

จากสมการที่ (5.3) และ (5.5) ค่า P_{down} คือ ค่าความน่าจะเป็นที่อุปกรณ์จะอยู่ในสถานะเสีย หรือเรียกว่า ค่า FOR (Forced Outage Rate) ซึ่งแสดงถึงช่วงเวลาเครื่องกำเนิดไฟฟ้าอยู่ในสถานะที่ไม่สามารถทำงานได้ภายในช่วงเวลาการทำงานทั้งหมดโดยช่วงเวลาการทำงานทั้งหมด คือผลรวมของเวลาที่เครื่องกำเนิดไฟฟ้าถูกกำหนดให้ทำงาน โดยไม่คำนึงถึงกรณีที่เครื่องกำเนิดไฟฟ้าจะสามารถทำงานตามที่กำหนดได้หรือไม่ ซึ่งสามารถเขียนได้ตามสมการที่ (5.6)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$FOR = \left(\frac{FOH}{FOH + SH} \right) \times 100 \quad (5.6)$$

โดยที่ FOH คือ ระยะเวลาที่เครื่องกำเนิดไฟฟ้าอยู่ในสถานะไม่พร้อมใช้งานทั้งที่ไม่ได้วางแผน
SH คือ ระยะเวลาที่เครื่องกำเนิดไฟฟ้าอยู่ในสถานะทำงาน

ในทางตรงกันข้าม ค่า P_{up} คือ ค่าความน่าจะเป็นที่อุปกรณ์จะสามารถทำงานได้ โดยปกติแล้ว ค่าความน่าจะเป็นของสถานะต่างๆและอัตราการเปลี่ยนแปลงระหว่างสถานะต่างๆนั้น เราสามารถทราบได้จากสถิติการทำงานของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องซึ่งโดยทั่วไปหน่วยงานที่รับผิดชอบจะมีการบันทึกไว้

5.3.3 ตารางความน่าจะเป็นในการขาดกำลังการผลิต

การคำนวณความเชื่อถือได้ของระบบผลิตไฟฟ้านั้น ขั้นแรกจะต้องสร้างแบบจำลองของระบบผลิตไฟฟ้าขึ้นมาก่อน โดยการสร้างเป็นตารางการขาดกำลังการผลิตขนาดต่างๆกันที่มีโอกาสเกิดขึ้นเนื่องจากเครื่องกำเนิดไฟฟ้าในระบบเกิดเหตุขัดข้อง ตารางดังกล่าวประกอบด้วยข้อมูล 2 ส่วนคือ ความน่าจะเป็นและความถี่ของค่ากำลังผลิตที่อาจจะเกิดเหตุขัดข้องหรือค่ากำลังผลิตที่ใช้งานได้ ซึ่งจะได้อธิบายดังนี้

การสร้างแบบจำลองของเครื่องกำเนิดไฟฟ้าในส่วนของความน่าจะเป็น เรียกว่า การสร้างตารางความน่าจะเป็นในการขาดกำลังการผลิต หรือตาราง COPT (Capacity Outage Probability Table) [4] โดยการสร้างตาราง COPT จะอาศัยวิธีการคำนวณซ้ำขั้นตอนเดิม (Recursive method) โดยมีหลักการคือ การเพิ่มเครื่องกำเนิดไฟฟ้าในระบบเข้าไปในการคำนวณเพื่อคำนวณหาความน่าจะเป็นที่ขาดกำลังการผลิตในแต่ละระดับกำลังไฟฟ้าเนื่องจากการที่ระบบสูญเสียเครื่องกำเนิดไฟฟ้า จนครบทุกเครื่องที่มีอยู่ในระบบหลังจากดำเนินการครบขั้นตอนดังกล่าวจะได้ผลลัพธ์เป็นตาราง COPT ของระบบผลิตไฟฟ้า ส่วนต่อไปนี้จะนำเสนอถึงวิธีการสร้างตาราง COPT ในกรณีที่เครื่องกำเนิดไฟฟ้ามีลักษณะการทำงานแบบ 2 สถานะคือ ดีและเสีย ที่นิยามตามแบบจำลองมาร์คอฟฟ์ ดังต่อไปนี้

เราสามารถคำนวณค่าความน่าจะเป็นสะสม (Cumulative probability) [4] ของสถานะกำลังการผลิตที่เกิดขัดข้อง X MW หลังจากรวมเครื่องกำเนิดไฟฟ้าขนาด C MW ซึ่งมีค่า $FOR = U$ เข้าไปแล้วได้ตามสมการที่ (5.7) คือ

$$P(X) = (1 - U)P'(X) + UP'(X - C) \quad (5.7)$$

กำหนดค่าเริ่มต้น (Initial condition) คือ $P'(X) = 1.0$ เมื่อ $X \leq 0$ และ $P'(X) = 0$ เมื่อ $X > 0$

โดยที่ $P'(X)$ คือ ความน่าจะเป็นสะสมของสถานะกำลังผลิตที่เกิดเหตุขัดข้องขนาด X MW ก่อนเพิ่มเครื่องกำเนิดไฟฟ้าขนาด C MW

$P(X)$ คือ ความน่าจะเป็นสะสมของสถานะกำลังผลิตที่เกิดเหตุขัดข้องขนาด X MW หลังเพิ่มเครื่องกำเนิดไฟฟ้าขนาด C MW

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากนี้เราสามารถคำนวณค่าความน่าจะเป็นของแต่ละสถานะกำลังการผลิต (Individual probability) ที่เกิดขัดข้อง X MW หลังจากรวมเครื่องกำเนิดไฟฟ้าขนาด C MW ซึ่งมีค่า $FOR = U$ ได้ตามสมการที่ (5.8) คือ

$$p(X) = (1 - U)p'(X) + Up'(X - C) \quad (5.8)$$

กำหนดค่าเริ่มต้น (Initial condition) คือ $p(X) = 1.0$ เมื่อ $X = 0$ และ $p(X) = 0$ เมื่อ $X \neq 0$ โดยที่ $p'(X)$ คือ ค่าความน่าจะเป็นของสถานะกำลังการผลิตที่เกิดเหตุขัดข้องขนาด X MW หลังจากเพิ่มเครื่องกำเนิดไฟฟ้าขนาด C MW


$p(X)$ คือ ค่าความน่าจะเป็นของสถานะกำลังการผลิตที่เกิดเหตุขัดข้องขนาด X MW ก่อนเพิ่มเครื่องกำเนิดไฟฟ้า

C คือ ขนาดกำลังการผลิตไฟฟ้า (MW) ที่กำลังเพิ่มเข้าสู่การก่อสร้าง COPT

5.4 แบบจำลองของโหลด

ในการประเมินค่าดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้านั้น โดยทั่วไปมีการเลือกใช้โหลดลักษณะต่างๆ ตามความเหมาะสมประกอบด้วย [4]

1. โหลดสูงสุดประจำเดือน (Monthly Load Curve)
2. โหลดสูงสุดประจำวัน (Daily Load Curve)
3. โหลดสูงสุดประจำชั่วโมง (Hourly Load Curve)



รูปที่ 5.7 เส้นโค้งโหลดรายชั่วโมง [14]

รูปที่ 5.7 แสดงให้เห็นตัวอย่างการแปรเปลี่ยนความต้องการใช้ไฟฟ้า หรือเรียกเป็นเส้นโค้งโหลดรายชั่วโมง (Hourly load curve) ของประเทศไทยที่เกิดขึ้นจริงของวันหนึ่งในเดือนเมษายน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2543 เราพอจะแบ่งลักษณะเส้นโค้งโหลดนี้ออกได้เป็น 3 ระดับ คือ โหลดฐาน (Base load) โหลดปานกลาง (Intermediate load) และโหลดสูงสุด (Peak load)


ทั้งนี้โหลดฐานหมายถึงปริมาณโหลดขั้นต่ำที่เกิดขึ้นในช่วงเวลาที่สนใจ โรงไฟฟ้าที่ใช้ผลิตเพื่อจ่าย โหลดในช่วงนี้มักจะเดินเครื่องตลอดเวลาและผลิตกำลังไฟฟ้าค่อนข้างคงที่ โหลดปานกลางหมายถึงช่วงโหลดที่มีค่าสูงกว่าโหลดฐาน โหลดในช่วงนี้มีอัตราการเปลี่ยนแปลงที่ไม่สูงมากนัก ทำให้โรงไฟฟ้าที่ใช้จ่ายกำลังไฟฟ้าให้แก่โหลดในช่วงเวลาดังกล่าวไม่จำเป็นต้องเดินและหยุดเครื่องบ่อยนัก อีกทั้งไม่จำเป็นต้องมีความสามารถในการปรับระดับโหลดได้อย่างรวดเร็วมาก [14] เช่นเดียวกับโรงไฟฟ้าที่ใช้จ่ายไฟฟ้าในช่วงโหลดสูง ซึ่งมักเป็นช่วงที่มีการเปลี่ยนแปลงระดับโหลดที่รวดเร็ว เครื่องกำเนิดไฟฟ้าที่ใช้จ่ายโหลดสูงนี้จึงต้องมีความกระฉับกระเฉงสูงหรือมีความเฉื่อย (Inertia) ต่ำ ตัวเครื่องจึงมักมีขนาดเล็กเมื่อเทียบกับเครื่องกำเนิดไฟฟ้าที่ใช้จ่ายโหลดในช่วงอื่น ๆ

จากรูปที่ 5.7 เราจะพบว่ามีการแปรเปลี่ยนของปริมาณการใช้ไฟฟ้าในแต่ละช่วงเวลาของวันที่พิจารณา ค่าโหลดสูงสุด (P_{max}) และโหลดต่ำสุด (P_{min}) มีค่าประมาณ 15,500 MW และ 9,500 MW ตามลำดับโดยมีค่าเฉลี่ยที่ประมาณ 12,500 MW นอกจากนี้เราจะพบว่าโหลดดังกล่าวมีค่าสูงตั้งแต่ช่วงเวลาประมาณ 9.00 – 22.00 นาฬิกา ส่วนช่วงเวลาอื่น ๆ จะมีการใช้ไฟฟ้าค่อนข้างต่ำโดยเฉพาะช่วงเวลาประมาณ 2.00 – 4.00 นาฬิกา ทั้งนี้ลักษณะโหลดดังกล่าวอาจเปลี่ยนแปลงไปบ้างตามฤดูกาล และระยะเวลาที่เปลี่ยนไปขึ้นอยู่กับพฤติกรรมและปริมาณการใช้ไฟฟ้าของผู้ใช้แต่ละประเภท ซึ่งเราไม่สามารถจะทราบล่วงหน้าได้อย่างชัดเจน

ในการดำเนินงานเกี่ยวกับธุรกิจกรรมทางไฟฟ้านั้น การทราบถึงปริมาณและลักษณะโหลดจะส่งผลต่อผลประกอบการของแต่ละหน่วยงานได้เป็นอย่างมาก เช่น หากเราสามารถพยากรณ์ความต้องการใช้ไฟฟ้า ที่จะเกิดขึ้นในอนาคตได้อย่างแม่นยำ ก็ย่อมจะส่งผลให้วิศวกรสามารถจัดเตรียมแผนการเดินเครื่องกำเนิดไฟฟ้า การจัดสรรกำลังการผลิตไฟฟ้า แผนการบำรุงรักษาเครื่องกำเนิดไฟฟ้า ตลอดจนแผนการขยายกำลังการผลิตไฟฟ้าได้อย่างเหมาะสม อันจะสามารถลดค่าใช้จ่ายในการผลิตไฟฟ้า อีกทั้งยังสามารถลดความเสี่ยงที่จะเกิดการขาดแคลนการผลิตไฟฟ้าได้ แต่หากผลการพยากรณ์ความต้องการใช้ไฟฟ้าคลาดเคลื่อนจากความเป็นจริงมากก็ย่อมส่งผลให้ค่าใช้จ่ายของระบบสูงขึ้นหรือมีความเสี่ยงต่อสถานะมีกำลังไฟฟ้าไม่เพียงพอต่อความต้องการได้เพิ่มมากขึ้น

5.4.1 เส้นโค้งช่วงระยะเวลาของโหลด

การวางแผนกำลังการผลิตในระยะยาวนั้น อาจไม่จำเป็นต้องทราบลักษณะความต้องการใช้ไฟฟ้าเป็นรายชั่วโมง หากเพียงต้องการทราบค่าโดยประมาณของปริมาณความต้องการใช้พลังงานไฟฟ้าและกำลังไฟฟ้าสูงสุดที่คาดว่าจะเกิดขึ้นเป็นหลัก ในกรณีเช่นนี้เราจะอาศัยเส้นโค้งช่วงเวลาโหลด (Load duration curve) [4] ดังแสดงในรูปที่ 5.8 ซึ่งปรับเปลี่ยนมาจากเส้นโค้งโหลดรายชั่วโมง เมื่อเราทราบรายละเอียดของโหลดสูงสุดในแต่ละชั่วโมงแล้วเราจะสามารถนำข้อมูลเหล่านี้มาสร้างแบบจำลองโหลดโดยเรียงโหลดจากค่ามากไปน้อยจนครบช่วงเวลาที่เราพิจารณา

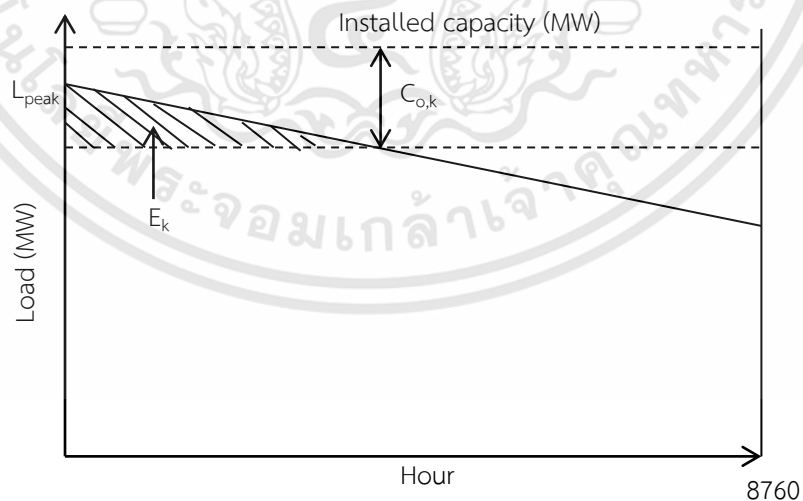


รูปที่ 5.8 เส้นโค้งช่วงระยะเวลาของโหลด

5.5 Expected Energy Not Supplied (EENS)

5.5.1 การคำนวณค่าดัชนี Expected Energy not Supplied (EENS)

EENS คือ ค่าดัชนีที่บ่งบอกถึงค่าพลังงานที่คาดว่าจะไม่ได้รับการจ่ายจากระบบผลิตไฟฟ้าอันเนื่องจากโหลดมีค่ามากกว่าปริมาณกำลังการผลิตที่มีอยู่ โดยดัชนีดังกล่าวแสดงถึงปริมาณพลังงานไฟฟ้าที่ไม่ได้รับการจ่ายจากการที่มีกำลังผลิตไม่เพียงพอ [4]



รูปที่ 5.9 การคำนวณค่าดัชนี EENS

การคำนวณค่าดัชนี EENS โดยอาศัยเส้นโค้งระยะเวลาของโหลดสะสม (Cumulative Load Duration Curve: CLDC) สามารถทำได้โดยการพิจารณาปริมาณพลังงานที่ไม่ได้รับการจ่ายเมื่อกำลังเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การผลิตขาดหายไปสูงกว่าค่ากำลังการผลิตสำรองโดยพิจารณาเส้นโค้ง CLDC จากรูปที่ 5.9 E_k คือพลังงานที่ไม่ได้รับการจ่ายเนื่องจากการผลิตขาดหายไปเป็นปริมาณเท่ากับ $C_{o,k}$ MW ดังนั้นเราสามารถคำนวณค่าดัชนี EENS ได้จากสมการที่ (5.9) ถึง (5.10)


$$EENS_0 = t * \sum_{i=1}^n L_i \quad (5.9)$$

$$EENS_q = \sum_{k=1}^n p_k E_k \quad (5.10)$$

โดยที่	t	คือ	ช่วงเวลาทั้งหมดที่พิจารณา
	L_i	คือ	ความต้องการไฟฟ้าชั่วโมงที่ i
	$EENS_0$	คือ	พลังงานที่ผลิตได้ทั้งหมดในช่วงเวลาที่พิจารณา
	$EENS_q$	คือ	ปริมาณพลังงานที่คาดว่าจะไม่ได้รับการจ่ายที่เครื่องกำเนิดไฟฟ้าลำดับที่ q
	p_k	คือ	ค่าความน่าจะเป็นแบบ Individual ของ state k
	E_k	คือ	ปริมาณพลังงานที่ไม่ได้รับการจ่ายเนื่องจากการขาดหายของกำลังการผลิตของ state k

5.5.2 ตัวอย่างการคำนวณค่าดัชนีความเชื่อถือได้

ระบบที่ใช้เป็นตัวอย่างในการคำนวณ คือ ระบบ IEEE Reliability Test System ซึ่งมีจำนวนเครื่องกำเนิดไฟฟ้าทั้งหมด 32 เครื่อง และมีกำลังการผลิตติดตั้งทั้งหมดเท่ากับ 3405 MW โหลดสูงสุดในระบบมีค่าเท่ากับ 2850 MW โดยรายละเอียดของค่าสมรรถนะของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องรวมถึงข้อมูลโหลดได้นำมาแสดงไว้ในภาคผนวก ก ซึ่งสามารถแสดงโหลดสูงสุดสะสมรายชั่วโมงตามรูปที่ 5.10



รูปที่ 5.10 โหลดรายชั่วโมงของระบบตัวอย่าง IEEE-RTS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากข้อมูลของระบบผลิตไฟฟ้าจะสามารถสร้างตารางน่าจะเป็นในการขาดกำลังการผลิต (Capacity outage probability table: COPT) ได้ดังตารางที่ 5.1


ตารางที่ 5.1 ตาราง COPT ของระบบ IEEE Reliability Test System

State (1)	Capacity outage (MW) (2)	Individual Probability (3)	Cumulative Probability (4)
1	0	0.23639512	1
31	100	0.02999156	0.547601144
40	118	5.52E-09	0.512059147
153	265	1.3116E-05	0.335566652
288	400	0.06572831	0.261873431
444	556	3.4527E-06	0.084578061
488	600	0.00035769	0.062112861
838	950	6.4306E-05	0.007491953
1088	1200	2.4132E-05	0.000791252
1388	1500	2.9915E-07	4.04351E-05

โดยที่ คอลัมน์ที่ 1 คือ สถานะที่ i ของแบบจำลองระบบผลิตไฟฟ้าที่พิจารณา
 คอลัมน์ที่ 2 คือ ปริมาณกำลังไฟฟ้าที่ขาดกำลังการผลิต ของสถานะที่ i
 คอลัมน์ที่ 3 คือ ความน่าจะเป็นที่จะเกิดการขาดกำลังการผลิตเป็นปริมาณกำลังผลิตไฟฟ้าดังคอลัมน์ 2 ของแต่ละสถานะ i
 คอลัมน์ที่ 4 คือ ความน่าจะเป็นสะสมที่จะเกิดการขาดกำลังการผลิตเป็นอย่างน้อยเป็นปริมาณกำลังผลิตไฟฟ้าดังคอลัมน์ 2 ของแต่ละสถานะ i

จากตารางที่ 5.1 เป็นการแสดงตารางการขาดกำลังกำลังการผลิต โดยตารางความน่าจะเป็นในการขาดกำลังการผลิตมีทั้งหมด 1388 สถานะ ซึ่งยกมาเป็นตัวอย่างเพียงส่วนหนึ่งเท่านั้น

จากนั้นการคำนวณค่าดัชนี EENS โดยอาศัยเส้นโค้งระยะเวลาของโหลดสะสม (Cumulative Load Duration Curve: CLDC) ตามรูปที่ 5.11 ได้จากสมการที่ (5.9) ถึง (5.10) แสดงผลการคำนวณดัชนี EENS ตามตารางที่ 5.2 ซึ่งเป็นดัชนี EENS ที่คำนวณออกมาหลังจากเพิ่มเครื่องกำเนิดไฟฟ้าเข้าไปที่ละเครื่องจนครบ



รูปที่ 5.11 เส้นโค้งระยะเวลาสะสมของโหลดรายชั่วโมงของระบบ IEEE RTS

ตารางที่ 5.2 ตารางแสดงผลคำนวณดัชนี EENS

No. unit (1)	Capacity (MW) (2)	Expected Energy Not Supplied (MWh) (3)	No. unit (1)	Capacity (MW) (2)	Expected Energy Not Supplied (MWh) (3)
1	50	14,864,642.71	17	350	355,137.71
2	50	14,432,210.71	18	20	329,783.45
3	50	13,999,778.71	19	20	306,014.43
4	50	13,567,346.71	20	20	283,726.17
5	50	13,134,914.71	21	20	262,788.58
6	50	12,702,482.71	22	12	249,765.67
7	400	9,627,410.71	23	12	237,282.90
8	400	6,559,728.82	24	12	225,293.46
9	76	5,927,422.34	25	12	213,804.95
10	76	5,317,899.95	26	12	202,776.69
11	76	4,735,459.89	27	100	129,490.77
12	76	4,183,912.33	28	100	79,204.51
13	155	3,195,016.90	29	100	46,592.79
14	155	2,340,412.29	30	197	15,562.42
15	155	1,632,253.84	31	197	4,569.41
16	155	1,083,617.59	32	197	1,176.30


เอกสารนี้เป็นเอกสารทบทวนวิชาสำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- โดยที่ คอลัมน์ที่ 1 คือ เครื่องกำเนิดไฟฟ้าเครื่องที่ i ที่เพิ่มเข้าสู่ระบบ
- คอลัมน์ที่ 2 คือ กำลังการผลิตติดตั้งของเครื่องกำเนิดไฟฟ้าเครื่องที่ i
- คอลัมน์ที่ 3 คือ ดัชนี EENS ของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

สำหรับระบบไฟฟ้าของประเทศไทยที่นำมาใช้ในวิทยานิพนธ์นี้เป็นระบบที่มีเครื่องกำเนิดไฟฟ้า 85 เครื่อง ความต้องการใช้ไฟฟ้าสูงสุดมีค่าเท่ากับ 22,500 MW ส่วนข้อมูลสมรรถนะของเครื่องกำเนิดไฟฟ้ากำหนดให้มีค่าตามมาตรฐานของ NERC [16] โดยสามารถแยกประเภทได้ดังนี้ [23]

1. โรงไฟฟ้าพลังความร้อนจำนวน 23 เครื่อง มีกำลังผลิตติดตั้งรวม 8,586.5 MW
2. โรงไฟฟ้าพลังความร้อนร่วมจำนวน 49 เครื่อง มีกำลังผลิตติดตั้งรวม 15,081.9 MW
3. โรงไฟฟ้ากังหันแก๊สจำนวน 13 เครื่อง มีกำลังผลิตติดตั้งรวม 847 MW

โดยรายละเอียดของค่าสมรรถนะของเครื่องกำเนิดไฟฟ้าแต่ละเครื่องรวมถึงข้อมูลโหลดได้นำมาแสดงไว้ในภาคผนวก ซึ่งสามารถแสดงโหลดสูงสุดสะสมรายชั่วโมงตามรูปที่ 5.12



รูปที่ 5.12 โหลดสะสมรายชั่วโมงของประเทศไทย [23]

การคำนวณดัชนีความเชื่อถือได้คือดัชนี EENS ตามที่กล่าวไปแล้วนี้จะถูกนำมาใช้เป็นข้อมูลเอาท์พุท และข้อมูลอินพุทมาจากสมรรถนะของเครื่องกำเนิดไฟฟ้าที่บันทึกไว้ตามคุณลักษณะของเครื่องกำเนิดไฟฟ้าแต่ละเครื่อง ข้อมูลเหล่านี้ถูกใช้สำหรับป้อนเข้าไปในกระบวนการเรียนรู้โดยใช้โครงข่ายประสาทเทียมและระบบอนุमानนิโรฟิซซีแบบปรับตัวได้ โดยจะใช้ข้อมูลชุดเดียวกันในการเปรียบเทียบทั้งสองวิธี

บทที่ 6

การจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลม

6.1 วิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม

ในวิทยานิพนธ์ฉบับนี้จะนำเสนอวิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม 3 วิธีคือ การจำลองโดยใช้การกระจายข้อมูลแบบไวบูลล์ การจำลองโดยใช้โครงข่ายประสาทเทียม และการจำลองโดยใช้ระบบอนุमानนิเวศน์แบบปรับตัวได้ เพื่อเปรียบเทียบผลลัพธ์ของการจำลองข้อมูลที่ดีที่สุด โดยใช้ข้อมูลพลังงานไฟฟ้าที่ผลิตได้ที่ถูกบันทึกไว้จากสถานีพลังงานทดแทนแหลมพรหมเทพ จังหวัดภูเก็ต ของกังหันลมขนาด 150 kW โดยแสดงข้อมูลที่ใช้ในการทดสอบตามตารางที่ 6.1

ตารางที่ 6.1 ข้อมูลที่ใช้ในการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม

ปี	เดือน	พลังงานไฟฟ้า ย้อนหลัง 1 เดือน (kWh)	พลังงานไฟฟ้า ย้อนหลัง 2 เดือน (kWh)	ความเร็วลมเฉลี่ย (m/s)	พลังงานไฟฟ้า ที่ผลิตได้ (kWh)
2005	3	9974	21858	5.22	18804
2005	4	18804	9974	4	28178
2005	5	28178	18804	5.24	6546
2005	6	6546	28178	7.08	26298
2005	7	26298	6546	7.38	34800
2005	8	34800	26298	6.39	31980
2005	9	31980	34800	6.48	30090
2005	10	30090	31980	4.74	9036
2005	11	9036	30090	4.44	8952
2005	12	8952	9036	5.64	13410
2006	1	13410	8952	5.49	15936
2006	2	15936	13410	4.98	17046
2006	3	17046	15936	4.15	7410
2006	4	7410	17046	3.43	3270
2006	5	3270	7410	4.75	13650
2006	6	13650	3270	4.99	18246
2006	7	18246	13650	7.7	37344
2006	8	37344	18246	6.78	20058
2006	9	20058	37344	4.95	25668
2006	10	25668	20058	4.87	13194
2006	11	13194	25668	4.43	6444
2006	12	6444	13194	5.23	12660
2007	1	12660	6444	5.26	6060

เอกสารนี้เป็นเอกสารสงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอญูญาติให้ไปเผยแพร่บนสื่อออนไลน์

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ปี	เดือน	พลังงานไฟฟ้า ย้อนหลัง 1 เดือน (kWh)	พลังงานไฟฟ้า ย้อนหลัง 2 เดือน (kWh)	ความเร็วลมเฉลี่ย (m/s)	พลังงานไฟฟ้า ที่ผลิตได้ (kWh)
2007	2	6060	12660	5.41	19266
2007	3	19266	6060	4.29	11820
2007	4	11820	19266	3.86	6612
2007	5	6612	11820	3.75	6660
2007	6	6660	6612	4.48	13920
2007	7	13920	6660	5.5	15618
2007	8	15618	13920	6.56	37470
2007	9	37470	15618	5.53	11172
2007	10	11172	37470	4.74	8124
2007	11	8124	11172	4.19	9012
2007	12	9012	8124	5.89	17406
2008	1	17406	9012	5.47	15672
2008	2	15672	17406	5.23	11670
2008	3	11670	15672	4.73	9966
2008	4	9966	11670	3.83	9738
2008	5	9738	9966	6.44	6072
2008	6	6072	9738	4.86	12672
2008	7	12672	6072	4.6	13734
2008	8	13734	12672	4.69	27720
2008	9	27720	13734	5.84	28368
2008	10	28368	27720	4.16	16020
2008	11	16020	28368	4.16	6942
2008	12	6942	16020	5.24	11052

6.1.1 การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้การกระจายข้อมูลแบบไวบูลล์

การจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมจะประมาณค่าการกระจายข้อมูลความเร็วลมแบบไวบูลล์ โดยใช้ค่าความเร็วลมเฉลี่ยจากตารางที่ 6.1 จากนั้นนำไปแปลงค่าเป็นค่ากำลังไฟฟ้าที่ผลิตได้ของกังหันลม โดยใช้กราฟกำลังไฟฟ้าขาออกของกังหันลม Nordtank ขนาด 150 kW ซึ่งสามารถแสดงขั้นตอนการคำนวณข้อมูลพลังงานลมได้ดังนี้

ขั้นตอนที่ 1 รวบรวมข้อมูลความเร็วลมเฉลี่ยรายเดือนที่บันทึกไว้แสดงในตารางที่ 6.1 สุ่มตัวเลข และคำนวณฟังก์ชันความหนาแน่นสะสมสำหรับความเร็วลมเฉลี่ยของเดือนที่พิจารณา โดยพิจารณาช่วงเวลาทุกๆ 1 ชั่วโมง เช่น เดือนที่พิจารณามี 30 วัน และค่าความเร็วลมเฉลี่ยเท่ากับ 6.03 m/s ดังนั้นจะต้องสุ่มตัวเลขจำนวน 720 ค่า และใช้ความเร็วลมเฉลี่ย 6.03 m/s ในการคำนวณ

ฟังก์ชันความหนาแน่นสะสมของการกระจายแบบไวบูลล์ในสมการที่ (4.2) โดยกำหนดพารามิเตอร์ A ตามสมการที่ (4.3) และพารามิเตอร์ k เท่ากับ 2 ซึ่งเป็นพารามิเตอร์รูปร่างที่ให้ผลลัพธ์ที่ดีที่สุด และเหมาะสมกับลักษณะการกระจายของข้อมูลมากที่สุด แสดงการเปรียบเทียบค่าพารามิเตอร์ k ดังตารางที่ 6.2

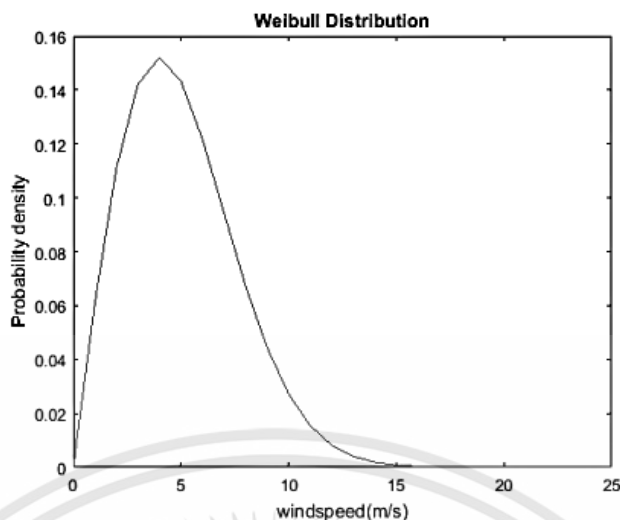
ขั้นตอนที่ 2 คำนวณการสุ่มค่าความเร็วลมรายชั่วโมง โดยเปรียบเทียบระหว่างตัวเลขสุ่มแต่ละค่าและความน่าจะเป็นสะสมของการกระจายแบบไวบูลล์ ที่ความเร็วลมเฉลี่ยที่พิจารณา แสดงดังรูปที่ 4.3

ขั้นตอนที่ 3 แปลงค่าการสุ่มความเร็วลมเป็นค่ากำลังไฟฟ้าที่ผลิตได้ของพลังลม โดยเปรียบเทียบระหว่างความเร็วลมเฉลี่ยรายชั่วโมงและกราฟกำลังไฟฟ้าขาออกของกังหันลม Nordtank ขนาด 150 kW แสดงดังรูปที่ 4.4 จะได้ค่ากำลังไฟฟ้าที่ผลิตได้จากกังหันลมขนาด 150 kW หากต้องการพิจารณาเดือนอื่นให้กำหนดจำนวนตัวเลขสุ่มและความเร็วลมเฉลี่ยรายเดือนแล้วคำนวณตามขั้นตอนที่ 1-3

ตารางที่ 6.2 แสดงการเปรียบเทียบค่าพารามิเตอร์รูปร่างสำหรับการกระจายแบบไวบูลล์

เดือน-ปี	ค่าพลังงานไฟฟ้าจริง (kWh)	ค่าพลังงานไฟฟ้าที่ได้จากการกระจายแบบไวบูลล์ (kWh)			
		เมื่อ k = 1.8	เมื่อ k = 1.9	เมื่อ k = 2.0	เมื่อ k = 2.1
Jun-05	21858	22654	23898	21505	22314
Feb-05	9974	12255	11772	11600	9977
Mar-05	18804	16076	15831	16039	16680
Apr-05	28178	7756.2	7166.2	6868.4	7477.1
May-05	6546	16642	16624	16705	14130
Jun-05	26298	29202	29095	30673	29674
Jul-05	34800	31123	33259	33740	32018
Aug-05	31980	27439	23524	25731	24542
Sep-05	30090	27209	25907	25287	23964
Oct-05	9036	13956	13578	11027	12437
Nov-05	8952	10971	10258	9324	8965.1
Dec-05	13410	20293	18818	20116	18184
%Error		7.4207	6.1189	5.5405	6.6922

จากตารางที่ 6.2 พบว่าพารามิเตอร์ k เท่ากับ 2 เป็นพารามิเตอร์รูปร่างที่ให้ผลลัพธ์ที่ดีที่สุด และเหมาะสมกับลักษณะการกระจายของข้อมูลมากที่สุด โดยพิจารณาจากการเปรียบเทียบเปอร์เซ็นต์ความผิดพลาดที่เกิดขึ้นระหว่างค่าจริงกับค่าที่ได้จากการคำนวณด้วยวิธีจำลองตามขั้นตอนของการกระจายแบบไวบูลล์ดังที่กล่าวไปแล้ว โดยแสดงลักษณะการกระจายของลมตามฟังก์ชันความน่าจะเป็นของความเร็วลม เมื่อกำหนด k=2 แสดงตามรูปที่ 6.1



รูปที่ 6.1 ฟังก์ชันความน่าจะเป็นของความเร็วลมเมื่อพารามิเตอร์รูปร่าง $k = 2$

6.1.2 การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม

การจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมสามารถแสดงขั้นตอนได้ดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลที่จะใช้ในการเรียนรู้ของ ANN โดยกำหนดค่าอินพุตเป็นความเร็วลมเฉลี่ย, พลังงานไฟฟ้าย้อนหลัง 1 เดือน และพลังงานไฟฟ้าย้อนหลัง 2 เดือน และกำหนดค่าเอาต์พุตเป็นพลังงานไฟฟ้าที่ผลิตได้ รวมข้อมูลทั้งหมด 46 ค่า โดยเลือกอินพุตจากข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุด ตามตารางที่ 6.1

ขั้นตอนที่ 2 สุ่มเลือกข้อมูลออกเป็น 2 ชุด คือข้อมูลสำหรับการฝึกสอน 40 ข้อมูลและข้อมูลสำหรับทดสอบ 6 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANN ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 นำข้อมูลอินพุต และเอาต์พุต มาทำการ normalized และ scaled

ขั้นตอนที่ 4 กำหนดจำนวนนิรอนในแต่ละชั้นซ่อน จำนวน Epochs และฟังก์ชันถ่ายโอน (Transfer function) ของแต่ละชั้นซ่อนและชั้นเอาต์พุต

ขั้นตอนที่ 5 คำนวณโดยใช้ ANN เรียนรู้บนโปรแกรม MATLAB และจดจำข้อมูลฝึกสอน และแสดงผลลัพธ์ออกมา

ขั้นตอนที่ 6 Unnormalized ข้อมูลเอาต์พุตที่ได้จาก ANN

ขั้นตอนที่ 7 นำค่าเอาต์พุตที่ได้จาก ANN มาเปรียบเทียบกับค่าจริง

ขั้นตอนที่ 8 ลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด โดยแสดงผลลัพธ์ในรูปของ โครงสร้างที่ดีที่สุด ที่ให้ค่า Mean Absolute Percentage Error (%MAPE) ที่น้อยที่สุด ซึ่งแสดงถึงความถูกต้องและแม่นยำของการจำลองข้อมูล

6.1.3 การจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

การจำลองข้อมูลการผลิตไฟฟ้าจากพลังงานลมสามารถแสดงขั้นตอนได้ดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลที่จะใช้ในการเรียนรู้ของ ANFIS โดยกำหนดค่าอินพุตเป็นความเร็วลมเฉลี่ย, พลังงานไฟฟ้าย้อนหลัง 1 เดือน และพลังงานไฟฟ้าย้อนหลัง 2 เดือน และกำหนดค่า

เอาท์พุทเป็นพลังงานไฟฟ้าที่ผลิตได้ รวมข้อมูลทั้งหมด 46 ค่า โดยเลือกอินพุทจากข้อมูลที่มีนัยสำคัญ ต่อเอาท์พุทมากที่สุด ตามตารางที่ 6.1

ขั้นตอนที่ 2 สุ่มเลือกข้อมูลออกเป็น 2 ชุด คือข้อมูลสำหรับการฝึกสอน 40 ข้อมูลและข้อมูล สำหรับทดสอบ 6 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANFIS ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 นำข้อมูลอินพุท และเอาท์พุท มาทำการ normalized และ scaled

ขั้นตอนที่ 4 ป้อนข้อมูลฝึกสอน และข้อมูลทดสอบเข้าสู่ ANFIS Toolbox >>anfisedit

ขั้นตอนที่ 5 กำหนดชนิดของฟังก์ชันสมาชิก จำนวนโครงสร้าง และจำนวน Epochs

ขั้นตอนที่ 6 คำนวณโดยใช้ ANFIS เรียนรู้บนโปรแกรม MATLAB และจดจำข้อมูลฝึกสอน และแสดงผลลัพธ์ออกมา

ขั้นตอนที่ 7 Unnormalized ข้อมูลเอาท์พุทที่ได้จาก ANFIS

ขั้นตอนที่ 8 นำค่าเอาท์พุทที่ได้จาก ANFIS มาเปรียบเทียบกับค่าจริง

ขั้นตอนที่ 9 ลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด โดยแสดงผลลัพธ์ในรูปของ โครงสร้าง ที่ดีที่สุด ที่ให้ค่า Mean Absolute Percentage Error (%MAPE) ที่น้อยที่สุด ซึ่งแสดงถึงความ ถูกต้องและแม่นยำของการจำลองข้อมูล

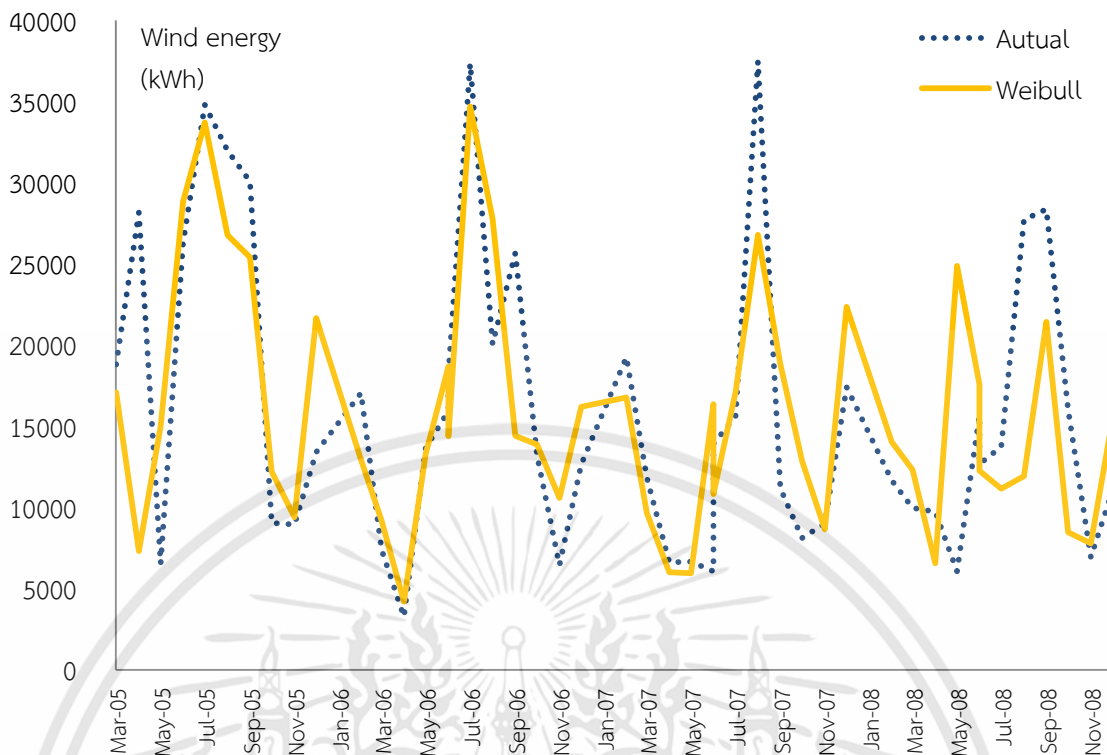
6.2 ผลการทดสอบการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม

ในวิทยานิพนธ์ฉบับนี้จะใช้วิธีการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมจาก วิธีการจำลองที่ได้กล่าวไปแล้วเพื่อหาวิธีการจำลองข้อมูลที่ดีที่สุด เพื่อเป็นตัวแทนในการพิจารณา ในหัวข้อต่อไป

6.2.1 ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้การ กระจายข้อมูลแบบไวบูลล์

จากรูปที่ 6.2 จะเห็นว่ากำลังไฟฟ้าที่กังหันลมสามารถผลิตได้มีค่าไม่คงที่ ขึ้นอยู่กับกำลังลมที่สามารถทำให้กังหันลมผลิตไฟฟ้าได้ แต่ค่ากำลังไฟฟ้าที่ได้จากการคำนวณซึ่งจะนำไปใช้เพื่อประเมิน ความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไป อาจมีการคลาดเคลื่อนจากค่าจริงที่ถูกบันทึกไว้เพราะ เป็นค่าจากการสุ่มตัวเลข ดังนั้นจึงต้องมีการเปรียบเทียบค่าจากการคำนวณกับข้อมูลที่ตรวจบันทึกไว้ เพื่อปรับค่าพารามิเตอร์ ในการคำนวณให้สามารถคำนวณค่ากำลังไฟฟ้าได้สอดคล้องกับความเป็นจริง มากที่สุด

ในวิทยานิพนธ์ฉบับนี้ได้ นำข้อมูลที่ตรวจบันทึกไว้จากสถานีแหลมพรหมเทพ ภูเก็ต ซึ่งเป็น ข้อมูลผลรวมพลังงานที่กังหันลมสามารถผลิตได้ในแต่ละปีมาเปรียบเทียบกับข้อมูลที่ได้จากการ ทดสอบ โดยพิจารณาจากค่า Plant factor แสดงผลการเปรียบเทียบค่าพลังงานที่ผลิตได้และค่า Plant factor ตามตารางที่ 6.3



รูปที่ 6.2 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากการกระจายแบบไวบูลล์

ตารางที่ 6.3 แสดงการเปรียบเทียบระหว่างข้อมูลพลังงานลมจากสถานีแหลมพรหมเทพ ภูเก็ตกับข้อมูลจากการกระจายแบบไวบูลล์ของกังหันลมขนาด 150 kW

ปี	ค่าจริงจากสถานีแหลมพรหมเทพ ภูเก็ต		ค่าจากการกระจายแบบไวบูลล์	
	พลังงาน (kWh)	Plant factor (%)	พลังงาน (kWh)	Plant factor (%)
2005	239,926	18	218,300	18.1
2006	190,926	15	191,183	14.6
2007	163,140	12	167,880	12.8
2008	169,626	13	170,440	12.9

จากตารางที่ 6.3 จะเห็นว่าผลการเปรียบเทียบค่าพลังงาน และค่า Plant Factor ข้อมูลจากการทดสอบมีค่าใกล้เคียงกับข้อมูลจริงจากสถานีแหลมพรหมเทพ ภูเก็ต ปี 2005-2008 โดย Plant factor คำนวณจากพลังงานที่โรงไฟฟ้าผลิตได้จริงใน 1 ปี ดังนั้นหลักการคำนวณค่ากำลังไฟฟ้าที่ผลิตได้นี้จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

6.2.2 ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม


จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมและวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าฟังก์ชันถ่ายโอน และจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 โดยเลือกโครงสร้างที่ดีที่สุด

จากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 6.4 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

ตารางที่ 6.4 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม

No. of neurons	Transfer function			%MAPE	
	Hidden layer 1	Hidden layer 2	Output layer	Train	Test
11 10	tansig	tansig	purelin	2.524	3.3041

โดยโครงสร้างที่ดีที่สุดมีจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เป็น 11 และ 10 ตามลำดับ และมีฟังก์ชันถ่ายโอนในชั้นซ่อนที่ 1, 2 และชั้นเอาต์พุตเป็น tansig, tansig และ purelin ตามลำดับ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 2.524% และมีค่า%MAPE ที่น้อยที่สุดของชุดทดสอบคือ 3.3041% หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว นำค่าเอาต์พุตที่ได้จากโครงข่ายประสาทเทียมมาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 6.3



รูปที่ 6.3 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากโครงข่ายประสาทเทียม

จากรูปที่ 6.3 โครงข่ายประสาทเทียมให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


6.2.3 ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้

จากกระบวนการเรียนรู้ของระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้และวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าชนิดของฟังก์ชันสมาชิก และจำนวนของฟังก์ชันสมาชิก โดยเลือกโครงสร้างที่ดีที่สุดจากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 6.5 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

ตารางที่ 6.5 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้ระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้


No. of MFs	MFs Type	%MAPE	
		Train	Test
8 2 4	dsigmf linear	2.1912	4.5678

โดยโครงสร้างที่ดีที่สุดมีจำนวนฟังก์ชันสมาชิกของอินพุตเป็น 8, 2 และ 4 ตามลำดับ ชนิดของฟังก์ชันสมาชิกของอินพุตเป็น dsigmf ตามลำดับ และฟังก์ชันสมาชิกของเอาต์พุตเป็น linear โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 2.1912% และมีค่า%MAPE ที่น้อยที่สุดของชุดทดสอบคือ 4.5678% โดยแสดงลักษณะโครงสร้างของฟังก์ชันสมาชิก และผลการฝึกสอนและทดสอบ บน ANFIS Toolbox แสดงตามรูปที่ 6.4 ถึง 6.6



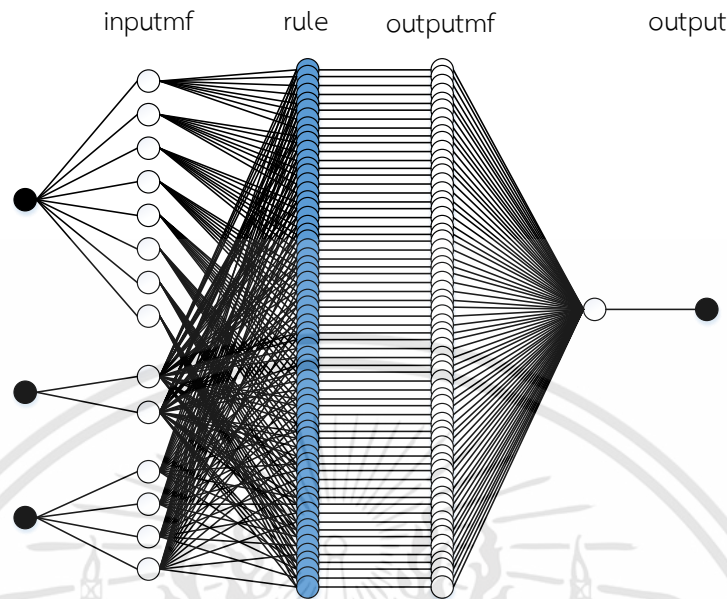
รูปที่ 6.4 ผลการฝึกสอนโดยใช้ ANFIS (MFs 8 2 4) บน MATLAB ANFIS Toolbox

จากรูปที่ 6.4 แสดงผลการฝึกสอน โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 2.1912% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์ที่ค่อนข้างแม่นยำ



รูปที่ 6.5 ผลการทดสอบโดยใช้ ANFIS (MFs 8 2 4) บน MATLAB ANFIS toolbox


จากรูปที่ 6.5 แสดงผลการทดสอบ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 4.5678% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์บางค่าที่ไม่ตรงกับค่าเป้าหมาย



รูปที่ 6.6 โครงสร้าง MFs 8 2 4 บน MATLAB ANFIS Toolbox

จากรูปที่ 6.6 แสดงลักษณะของโครงสร้างที่มีอินพุต 3 ตัว และจำนวนฟังก์ชันสมาชิกของอินพุต เป็น 8 2 4 ตามลำดับ โดยใช้กฎของฟัซซี คือ and ซึ่งจากการปรับเปลี่ยนกฎของฟัซซีแล้วพบว่า กฎ and ให้ผลลัพธ์ที่มีค่าผิดพลาดน้อยที่สุด

หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว นำค่าเอาต์พุตที่ได้จากระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้มาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 6.7



รูปที่ 6.7 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 6.7 ระบบอนุมานนิวโรฟซีแบบปรับตัวได้ ให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

6.2.4 ผลการทดสอบการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมจากการจำลองทั้ง 3 วิธี

การเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากการจำลองทั้ง 3 วิธี แสดงใน ตารางที่ 6.6 โดยแสดงการเปรียบเทียบตามรูปที่ 6.8 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค


ตารางที่ 6.6 ค่าพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้วิธีการจำลองข้อมูลแบบต่างๆ

เดือน - ปี	พลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม (kWh)			
	ค่าจริง	ไวบูลล์	ANN	ANFIS
Mar-05	18804	17095	18786	18803.83
Apr-05	28178	7304	28192	28177.94
May-05	6546	15006	6526	6546.001
Jun-05	26298	28834	26309	26297.98
Jul-05	34800	33711	34802	34799.97
Aug-05	31980	26780	32015	31979.95
Sep-05	30090	25412	30157	30090.03
Oct-05	9036	12189	9148	9035.995
Nov-05	8952	9402.2	9024	8951.978
Dec-05	13410	21673	13420	13409.34
Jun-06	15936	18678	14150	15934.53
Feb-06	17046	12920	17004	17048.22
Mar-06	7410	9202.2	8447	7410.143
Apr-06	3270	4198.2	3201	3270.11
May-06	13650	13279	13645	13801.39
Jun-06	18246	14396	18017	18245.75
Jul-06	37344	34706	37299	37343.98
Aug-06	20058	27762	20120	20057.99
Sep-06	25668	14409	26061	25667.98
Oct-06	13194	13880	13303	13193.98
Nov-06	6444	10572	6373	6443.881
Dec-06	12660	16203	12592	12660.71
Jun-07	6060	16358	7027	6060.873
Feb-07	19266	16778	19198	20167.17

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เดือน - ปี	พลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม (kWh)			
	ค่าจริง	ไวบูลล์	ANN	ANFIS
Mar-07	11820	9661.5	11864	11819.97
Apr-07	6612	6003.9	6409	6611.99
May-07	6660	5951	7417	6659.928
Jun-07	13920	10827	13992	13920.46
Jul-07	15618	17082	16622	15619.26
Aug-07	37470	26781	37434	37469.96
Sep-07	11172	18821	11187	11171.99
Oct-07	8124	12849	8138	8124.13
Nov-07	9012	8644.4	8915	9011.824
Dec-07	17406	22348	17388	16027.98
Jun-08	15672	17574	16038	15671.82
Feb-08	11670	14035	11729	11670.6
Mar-08	9966	12323	9647	9965.889
Apr-08	9738	6551.8	8477	9738.013
May-08	6072	24869	6096	6072.361
Jun-08	12672	12249	12845	12670.99
Jul-08	13734	11151	13809	13734.35
Aug-08	27720	11913	27624	27716.89
Sep-08	28368	21417	28379	28367.98
Oct-08	16020	8472.3	16013	4906.239
Nov-08	6942	7772.2	6934	5268.762
Dec-08	11052	15468	11045	11122.07

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 6.8 แสดงการเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงและค่าที่ได้จากการจำลองทั้ง 3 วิธี

จากรูปที่ 6.8 พบว่าเมื่อเปรียบเทียบพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมระหว่างค่าจริงกับการจำลองข้อมูลทั้ง 3 วิธี พบว่า การจำลองข้อมูลโดยใช้ ANN ให้ผลที่ดีที่สุด รองลงมาคือ ANFIS และการกระจายแบบไวบูลล์

การจำลองข้อมูลโดยใช้ ANN ให้ผลที่ใกล้เคียงกับค่าจริงมากที่สุด ใช้เวลาในการเรียนรู้สั้นแม้จะมีโครงสร้างที่ซับซ้อนมากขึ้น สามารถใช้งานได้ดีกับลักษณะข้อมูลของพลังงานลมที่ไม่คงที่ แต่เนื่องด้วยข้อจำกัดเกี่ยวกับลักษณะของข้อมูลอินพุตและเอาต์พุตที่จะป้อนเข้าไปอาจทำให้ไม่สามารถใช้งานได้ตามที่ต้องการ ทำให้การจำลองข้อมูลโดยใช้ ANN มีประสิทธิภาพลดลงเพราะจำเป็นต้องหาข้อมูลที่มีนัยสำคัญต่อพลังงานไฟฟ้าจากพลังงานลมมาใช้จึงจะได้ค่าที่ดีที่สุด และไม่สามารถบอกเหตุผลของการตัดสินใจของ ANN ได้

การจำลองข้อมูลโดยใช้ ANFIS ให้ผลรองลงมา แต่ก็เป็นการจำลองที่ให้ผลดีเช่นเดียวกัน สามารถใช้งานได้ดีกับลักษณะข้อมูลของพลังงานลมที่ไม่คงที่ ปัญหาของ ANFIS คือเมื่อกำหนดโครงสร้างที่ซับซ้อนมากขึ้นทำให้การทำงานของ ANFIS ช้าลงมากจึงไม่เหมาะสำหรับการใช้งานที่มีลักษณะโครงสร้างที่ซับซ้อนมากเกินไป

การจำลองข้อมูลโดยใช้การกระจายแบบไวบูลล์ให้ผลที่มีค่าผิดพลาดมากกว่าวิธีอื่น แต่เมื่อนำมาพิจารณาค่า Plant Factor แล้ว มีค่าใกล้เคียงกับค่าจริง อาจเป็นเพราะการจำลองนี้ใช้วิธีสุ่มตัวเลขทางสถิติทำให้คลาดเคลื่อนจากค่าจริงแต่เป็นที่ยอมรับได้ ข้อดีของวิธีนี้คือเราสามารถจำลองข้อมูลตามจำนวนข้อมูลที่ต้องการได้ และใช้เพียงความเร็วลมเฉลี่ยในการประเมินเท่านั้น จึงเหมาะสำหรับการนำไปใช้ในวิธีการทางความน่าจะเป็นซึ่งเป็นวิธีที่จะใช้ในการประเมินความเชื่อถือต่อไป

จะเห็นว่าทั้ง 3 วิธีมีข้อดีและข้อเสียแตกต่างกัน เราสามารถเลือกใช้ให้เหมาะสมกับลักษณะงานได้ สำหรับวิทยานิพนธ์ฉบับนี้เลือกการจำลองข้อมูลแบบไวบูลล์จะเหมาะสมที่สุด เพราะการประเมินความเชื่อถือได้ในบทต่อไปต้องการข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมแบบรายชั่วโมง ซึ่งการสุ่มตัวเลขและการกระจายแบบไวบูลล์สามารถให้ผลลัพธ์ตรงกับที่ต้องการมากที่สุด โดยได้ทำการปรับพารามิเตอร์ต่างๆ ให้ใกล้เคียงกับค่าจริงมากที่สุดแล้ว



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 7

การประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้า

ในวิทยานิพนธ์ฉบับนี้จะนำเสนอวิธีการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้า โดยแสดงในรูปของดัชนี EENS (Expected Energy Not Supplied) ซึ่งเป็นดัชนีที่แสดงพลังงานที่คาดว่าจะไม่สามารถผลิตได้เมื่อเพิ่มเครื่องกำเนิดไฟฟ้าเข้าไปที่ละเครื่อง โดยข้อมูลทั้งหมดได้มาจากการคำนวณดัชนีความเชื่อถือได้ของเครื่องกำเนิดไฟฟ้าเมื่อเกิดเหตุขัดข้อง ซึ่งแสดงการคำนวณในบทที่ 5 ข้อมูลที่ได้จากการคำนวณจะถูกนำมาใช้เป็นข้อมูลอินพุตและเอาต์พุตที่ใช้ทดสอบในกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม (ANN) เปรียบเทียบกับระบบอนุมานนิเวโรฟซึแบบปรับตัวได้ (ANFIS)

ในการทดสอบจะเลือกใช้การประเมินค่าดัชนี EENS โดยใช้โครงข่ายประสาทเทียม (ANN) เปรียบเทียบกับระบบอนุมานนิเวโรฟซึแบบปรับตัวได้ (ANFIS) เพื่อหาวิธีการที่ดีที่สุดสำหรับการประเมินความเชื่อถือได้ของการผลิตไฟฟ้า

ระบบทดสอบที่ใช้ในการหาค่าดัชนี EENS คือระบบ IEEE RTS และระบบไฟฟ้าของประเทศไทย แสดงข้อมูลของระบบทั้งสองในภาคผนวก ก.

7.1 ความเชื่อถือได้ของระบบผลิตไฟฟ้าของระบบทดสอบ IEEE RTS

ระบบทดสอบ IEEE RTS เป็นระบบที่มีเครื่องกำเนิดไฟฟ้า 32 เครื่อง กำลังการผลิตติดตั้งทั้งหมด 3,405 MW ความต้องการใช้ไฟฟ้าสูงสุดมีค่าเท่ากับ 2,850 MW สำหรับการเพิ่มกำลังการผลิตไฟฟ้าจากพลังงานลมจะใช้ข้อมูลจำนวนเครื่องกำเนิดไฟฟ้าและกำลังผลิตติดตั้งจากแผนพัฒนาพลังงานทดแทนสำหรับผลิตไฟฟ้า ของกระทรวงพลังงาน [15] ซึ่งในวิทยานิพนธ์ฉบับนี้จะเพิ่มกำลังผลิตจากกังหันลมขนาด 0.15 MW จำนวน 10 เครื่อง เพื่อหาค่าดัชนี EENS ด้วยวิธีการทางความน่าจะเป็นซึ่งแสดงในบทที่ 5 เพื่อเป็นข้อมูลอินพุตและเอาต์พุตสำหรับการทดสอบทั้งหมด 42 ข้อมูลแสดงในภาคผนวก ข.

7.1.1 การทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)

มีขั้นตอนการทดสอบดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลอินพุตและเอาต์พุตทั้งหมด 42 ข้อมูล โดยกำหนดข้อมูลอินพุต เป็นการจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate (FOR) และกำหนดข้อมูลเอาต์พุต เป็น ดัชนี EENS โดยเลือกอินพุตจากข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุด แสดงข้อมูลในภาคผนวก ข

ขั้นตอนที่ 2 แบ่งข้อมูลออกเป็น 2 ส่วน คือข้อมูลฝึกสอนจำนวน 34 ข้อมูล และข้อมูลทดสอบจำนวน 8 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANN ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 กำหนดจำนวนนิเวรอน, จำนวน Epochs และฟังก์ชันถ่ายโอน

ขั้นตอนที่ 4 ทดสอบโดยใช้การเรียนรู้ของ ANN บน MATLAB

ขั้นตอนที่ 5 ทำการลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด ซึ่งมีค่าผิดพลาดน้อยที่สุด

ขั้นตอนที่ 6 นำข้อมูลเอาต์พุตที่ได้จาก ANN มาเปรียบเทียบกับค่าจริง


7.1.2 ผลการทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)

จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมและวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าฟังก์ชันถ่ายโอน และจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 โดยเลือกโครงสร้างที่ดีที่สุดจากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 7.1 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

ตารางที่ 7.1 โครงสร้างที่ดีที่สุดของการจำลองข้อมูลพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลมโดยใช้โครงข่ายประสาทเทียม


No. of neurons	Transfer function			%MAPE	
	Hidden layer 1	Hidden layer 2	Output layer	Train	Test
10 9	tansig	tansig	purelin	0.2567	0.7687

โดยโครงสร้างที่ดีที่สุดมีจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เป็น 9 และ 8 ตามลำดับ และมีฟังก์ชันถ่ายโอนในชั้นซ่อนที่ 1, 2 และชั้นเอาต์พุตเป็น tansig, logsig และ purelin ตามลำดับ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 0.2567% และมีค่า %MAPE ที่น้อยที่สุดของชุดทดสอบคือ 0.7687% หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว



รูปที่ 7.1 ผลการทดสอบที่มีค่าผิดพลาดน้อยที่สุดบน MATLAB

นำค่าเอาต์พุตที่ได้จากโครงข่ายประสาทเทียมมาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 7.1



รูปที่ 7.2 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANN

จากรูปที่ 7.2 โครงข่ายประสาทเทียมให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

7.1.3 การทดสอบโดยใช้ระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้ (ANFIS)

มีขั้นตอนการทดสอบดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลอินพุตและเอาต์พุตทั้งหมด 42 ข้อมูล โดยกำหนดข้อมูลอินพุต เป็นการจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate (FOR) และกำหนดข้อมูลเอาต์พุต เป็น ดัชนี EENS โดยเลือกข้อมูลอินพุตจากข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุด แสดงข้อมูลในภาคผนวก ข

ขั้นตอนที่ 2 แบ่งข้อมูลออกเป็น 2 ส่วน คือข้อมูลฝึกสอนจำนวน 34 ข้อมูล และข้อมูลทดสอบจำนวน 8 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANFIS ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 ทำการ Normalized ข้อมูล เพื่อลดเวลาเรียนรู้ของ ANFIS

ขั้นตอนที่ 4 ทดสอบโดย ANFIS Toolbox >>anfisedit

ขั้นตอนที่ 5 ป้อนข้อมูลอินพุต และเอาต์พุต

ขั้นตอนที่ 6 กำหนดชนิดของฟังก์ชันสมาชิก, จำนวนโครงสร้าง และจำนวน Epochs จากนั้นจึงทดสอบโดยใช้การเรียนรู้ของ ANFIS บน MATLAB

ขั้นตอนที่ 7 ทำการลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด ซึ่งมีค่าผิดพลาดน้อยที่สุด

ขั้นตอนที่ 8 ทำการ Unnormalized ข้อมูลเอาต์พุตและนำข้อมูลเอาต์พุตที่ได้จาก ANFIS มาเปรียบเทียบกับค่าจริง


7.1.4 ผลการทดสอบโดยใช้ระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้ (ANFIS)

จากกระบวนการเรียนรู้ของระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้และวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าชนิดของฟังก์ชันสมาชิก และจำนวนของฟังก์ชันสมาชิก โดยเลือกโครงสร้างที่ดีที่สุดจากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 7.2 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

ตารางที่ 7.2 โครงสร้างที่ดีที่สุดของการทดสอบโดยใช้ระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้


No. of MFs	MFs Type	%MAPE	
		Train	Test
6 2 7	trimf linear	0.2916	0.6483

โดยโครงสร้างที่ดีที่สุดมีจำนวนฟังก์ชันสมาชิกของอินพุตเป็น 6 2 7 ตามลำดับ ชนิดของฟังก์ชันสมาชิกของอินพุตเป็น trimf ตามลำดับ และฟังก์ชันสมาชิกของเอาต์พุตเป็น linear โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 0.2916% และมีค่า %MAPE ที่น้อยที่สุดของชุดทดสอบคือ 0.6483% โดยแสดงลักษณะโครงสร้างของฟังก์ชันสมาชิก และผลการฝึกสอนและทดสอบ บน ANFIS Toolbox แสดงตามรูปที่ 7.3 ถึง 7.6



รูปที่ 7.3 แสดงผลการฝึกสอนของ ANFIS บน MATLAB ANFIS Toolbox

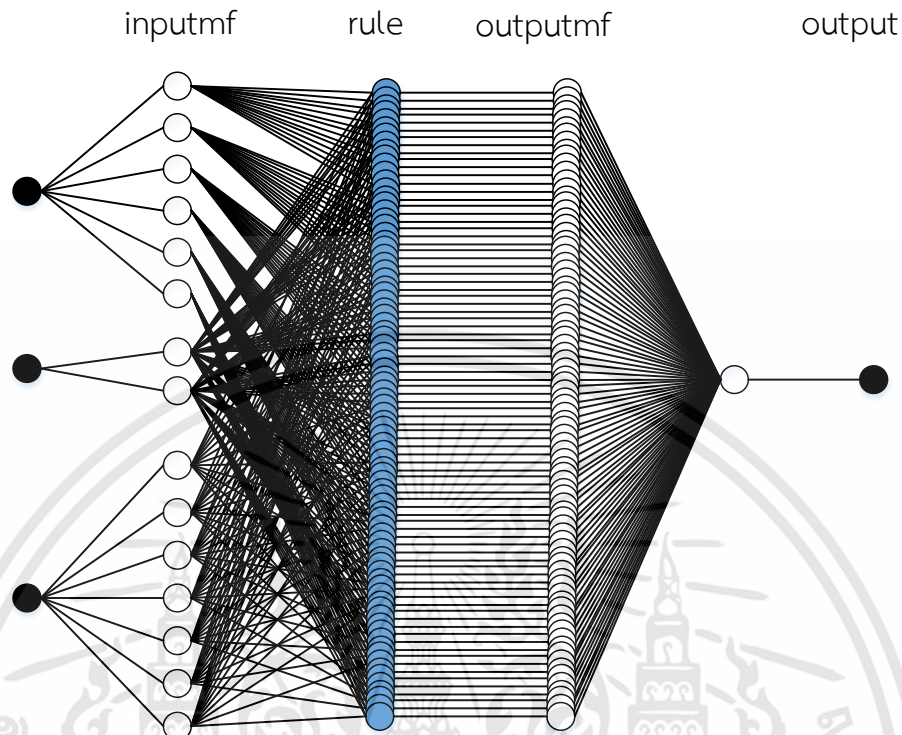
จากรูปที่ 7.3 แสดงผลการฝึกสอน โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 0.2916% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์ที่ค่อนข้างแม่นยำ



รูปที่ 7.4 แสดงผลการทดสอบของ ANFIS บน MATLAB ANFIS Toolbox


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 7.4 แสดงผลการทดสอบ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 0.6483% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์ที่ค่อนข้างแม่นยำ



รูปที่ 7.5 โครงสร้าง MFs 6 2 7 บน MATLAB ANFIS Toolbox

จากรูปที่ 7.5 แสดงลักษณะของโครงสร้างที่มีอินพุต 3 ตัว และจำนวนฟังก์ชันสมาชิกของอินพุต เป็น 6 2 7 ตามลำดับ โดยใช้กฎของฟัซซี คือ and ซึ่งจากการปรับเปลี่ยนกฎของฟัซซีแล้วพบว่า กฎ and ให้ผลลัพธ์ที่มีค่าผิดพลาดน้อยที่สุด




รูปที่ 7.6 แสดงลักษณะของฟังก์ชันสมาชิกชนิด trimf บน MATLAB ANFIS Toolbox

จากรูปที่ 7.6 แสดงลักษณะการกระจายของฟังก์ชันสมาชิกชนิด trimf ของอินพุตทั้ง 3 ตัว โดยมีค่าอยู่ระหว่าง 0 – 1

หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว นำค่าเอาต์พุตที่ได้จากระบบอนุมานนิเวศฟัซซีแบบปรับตัวได้มาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 7.7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 7.7 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANFIS

จากรูปที่ 7.7 ระบบอนุमानนิวโรฟซึแบบปรับตัวได้ ให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

7.2 ความเชื่อถือได้ของระบบผลิตไฟฟ้าของระบบไฟฟ้าของประเทศไทย

ระบบไฟฟ้าของประเทศไทยที่นำมาใช้ในวิทยานิพนธ์นี้เป็นระบบที่มีเครื่องกำเนิดไฟฟ้า 85 เครื่อง ความต้องการใช้ไฟฟ้าสูงสุดมีค่าเท่ากับ 22,500 MW ส่วนข้อมูลสมรรถนะของเครื่องกำเนิดไฟฟ้ากำหนดให้มีค่าตามมาตรฐานของ NERC โดยสามารถแยกประเภทได้ดังนี้ [23]

1. โรงไฟฟ้าพลังความร้อนจำนวน 23 เครื่อง มีกำลังผลิตติดตั้งรวม 8,586.5 MW
2. โรงไฟฟ้าพลังความร้อนร่วมจำนวน 49 เครื่อง มีกำลังผลิตติดตั้งรวม 15,081.9 MW
3. โรงไฟฟ้ากังหันแก๊สจำนวน 13 เครื่อง มีกำลังผลิตติดตั้งรวม 847 MW

สำหรับการเพิ่มกำลังการผลิตไฟฟ้าจากพลังงานลมจะใช้ข้อมูลจำนวนเครื่องกำเนิดไฟฟ้าและกำลังผลิตติดตั้งจากแผนพัฒนาพลังงานทดแทนสำหรับผลิตไฟฟ้า ของกระทรวงพลังงาน ซึ่งในวิทยานิพนธ์ฉบับนี้จะเพิ่มกำลังผลิตจากกังหันลมขนาด 0.15 MW จำนวน 10 เครื่อง เพื่อหาดัชนี EENS ด้วยวิธีการทางความน่าจะเป็นซึ่งแสดงในบทที่ 5 เพื่อเป็นข้อมูลอินพุตและเอาต์พุตสำหรับการทดสอบทั้งหมด 95 ข้อมูลแสดงในภาคผนวก ข.

7.2.1 การทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)

มีขั้นตอนการทดสอบดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลอินพุตและเอาต์พุต โดยกำหนดข้อมูลอินพุตทั้งหมด 95 ข้อมูล เป็นการจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate (FOR) และกำหนดข้อมูลเอาต์พุต เป็น ดัชนี EENS โดยเลือกอินพุตจากข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุด แสดงข้อมูลในภาคผนวก ข

ขั้นตอนที่ 2 แบ่งข้อมูลออกเป็น 2 ส่วน คือข้อมูลฝึกสอนจำนวน 80 ข้อมูล และข้อมูลทดสอบจำนวน 15 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANN ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 กำหนดจำนวนนิวรอน, จำนวน Epochs และฟังก์ชันถ่ายโอน

ขั้นตอนที่ 4 ทดสอบโดยใช้การเรียนรู้ของ ANN บน MATLAB

ขั้นตอนที่ 5 ทำการลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด ซึ่งมีค่าผิดพลาดน้อยที่สุด

ขั้นตอนที่ 6 นำข้อมูลเอาต์พุตที่ได้จาก ANN มาเปรียบเทียบกับค่าจริง


7.2.2 ผลการทดสอบโดยใช้โครงข่ายประสาทเทียม (ANN)

จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมและวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าฟังก์ชันถ่ายโอน และจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 โดยเลือกโครงสร้างที่ดีที่สุดจากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 7.3 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

ตารางที่ 7.3 โครงสร้างที่ดีที่สุดของการประเมินดัชนี EENS โดยใช้โครงข่ายประสาทเทียม


No. of neurons	Transfer function			%MAPE	
	Hidden layer 1	Hidden layer 2	Output layer	Train	Test
9 8	purelin	logsig	purelin	3.1513	4.1918

โดยโครงสร้างที่ดีที่สุดมีจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เป็น 9 และ 8 ตามลำดับ และมีฟังก์ชันถ่ายโอนในชั้นซ่อนที่ 1, 2 และชั้นเอาต์พุตเป็น purelin, logsig และ purelin ตามลำดับ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 3.1513% และมีค่า %MAPE ที่น้อยที่สุดของชุดทดสอบคือ 4.1918% หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว



รูปที่ 7.8 ผลการทดสอบที่มีค่าผิดพลาดน้อยที่สุดบน MATLAB

นำค่าเอาต์พุตที่ได้จากโครงข่ายประสาทเทียมมาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 7.9



รูปที่ 7.9 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANN

จากรูปที่ 7.9 โครงข่ายประสาทเทียมให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

7.2.3 การทดสอบโดยใช้ระบบอนุมานนิเวโรฟฟิซซีแบบปรับตัวได้ (ANFIS)

มีขั้นตอนการทดสอบดังนี้

ขั้นตอนที่ 1 เตรียมข้อมูลอินพุตและเอาต์พุต โดยกำหนดข้อมูลอินพุตทั้งหมด 95 ข้อมูล เป็นการจัดลำดับเครื่องกำเนิดไฟฟ้า, กำลังผลิตติดตั้ง และค่า Force Outage Rate (FOR) และกำหนดข้อมูลเอาต์พุต เป็น ดัชนี EENS โดยเลือกอินพุตจากข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุด แสดงข้อมูลในภาคผนวก ข

ขั้นตอนที่ 2 แบ่งข้อมูลออกเป็น 2 ส่วน คือข้อมูลฝึกสอนจำนวน 80 ข้อมูล และข้อมูลทดสอบจำนวน 15 ข้อมูล โดยข้อมูลสำหรับทดสอบต้องเป็นข้อมูลที่ ANFIS ไม่เคยเห็นมาก่อน

ขั้นตอนที่ 3 ทำการ Normalized ข้อมูล เพื่อลดเวลาเรียนรู้ของ ANFIS

ขั้นตอนที่ 4 ทดสอบโดย ANFIS Toolbox >>anfisedit

ขั้นตอนที่ 5 ป้อนข้อมูลอินพุต และเอาต์พุต

ขั้นตอนที่ 6 กำหนดชนิดของฟังก์ชันสมาชิก, จำนวนโครงสร้าง และจำนวน Epochs จากนั้นจึงทดสอบโดยใช้การเรียนรู้ของ ANFIS บน MATLAB

ขั้นตอนที่ 7 ทำการลองผิดลองถูกจนกว่าจะได้ผลลัพธ์ที่ดีที่สุดซึ่งมีค่าผิดพลาดน้อยที่สุด

ขั้นตอนที่ 8 ทำการ Unnormalized ข้อมูลเอาต์พุตและนำข้อมูลเอาต์พุตที่ได้จาก ANFIS มาเปรียบเทียบกับค่าจริง


7.2.4 ผลการทดสอบโดยใช้ระบบอนุมานนิเวโรฟฟิซซีแบบปรับตัวได้ (ANFIS)

จากกระบวนการเรียนรู้ของระบบอนุมานนิเวโรฟฟิซซีแบบปรับตัวได้และวิธีการลองผิดลองถูก โดยการปรับเปลี่ยนค่าชนิดของฟังก์ชันสมาชิก และจำนวนของฟังก์ชันสมาชิก โดยเลือกโครงสร้างที่ดีที่สุดจากการพิจารณา %MAPE ของชุดฝึกสอนและชุดทดสอบที่น้อยที่สุดมาแสดงตามตารางที่ 7.4 โดยแสดงผลการลองผิดลองถูกทั้งหมดในภาคผนวก ค

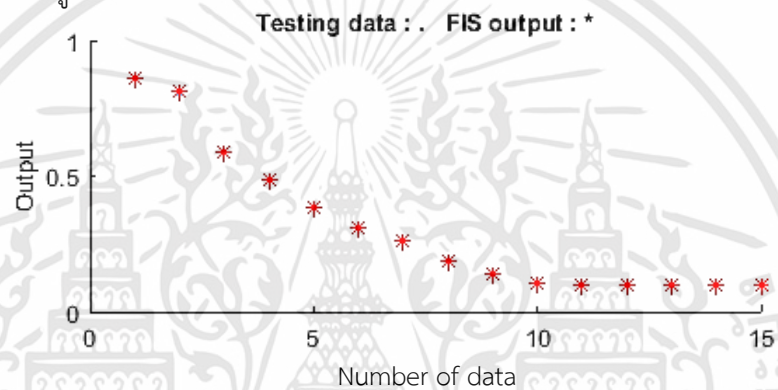
ตารางที่ 7.4 โครงสร้างที่ดีที่สุดของการประเมินดัชนี EENS โดยใช้ระบบอนุมานนิเวโรฟฟิซซีแบบปรับตัวได้

No. of MFs	MFs Type	%MAPE	
		Train	Test
6 1 9	pimf linear	4.2509	6.4769

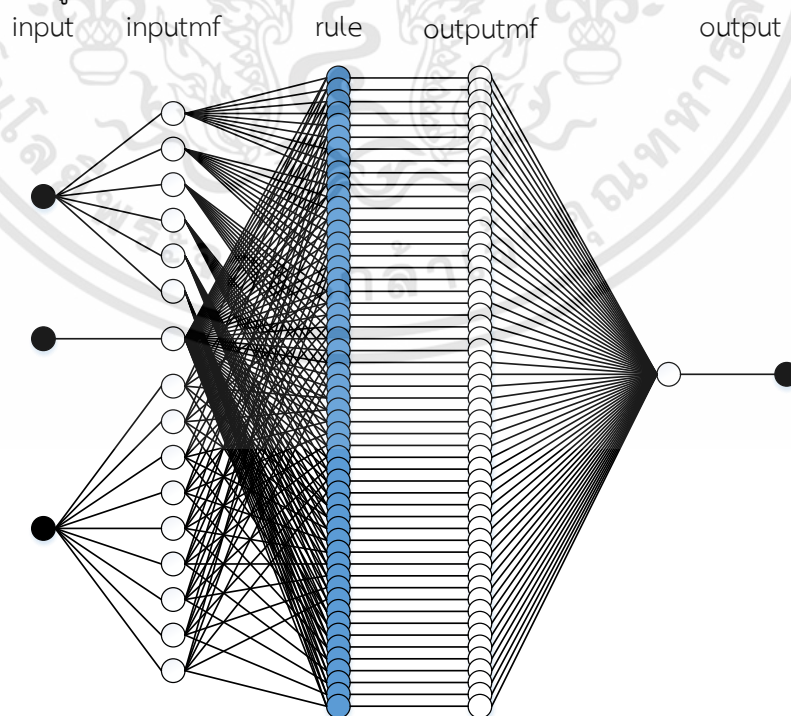
โดยโครงสร้างที่ดีที่สุดมีจำนวนฟังก์ชันสมาชิกของอินพุตเป็น 6, 1 และ 9 ตามลำดับ ชนิดของฟังก์ชันสมาชิกของอินพุตเป็น pimf ตามลำดับ และฟังก์ชันสมาชิกของเอาต์พุตเป็น linear โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 4.2509% และมีค่า %MAPE ที่น้อยที่สุดของชุดทดสอบคือ 6.4769% โดยแสดงลักษณะโครงสร้างของฟังก์ชันสมาชิก และผลการฝึกสอนและทดสอบ บน ANFIS Toolbox แสดงตามรูปที่ 7.10 ถึง 7.13



รูปที่ 7.10 แสดงผลการฝึกสอนของ ANFIS บน MATLAB ANFIS Toolbox
จากรูปที่ 7.10 แสดงผลการฝึกสอน โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 4.2509% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์ที่ค่อนข้างแม่นยำ




รูปที่ 7.11 แสดงผลการทดสอบของ ANFIS บน MATLAB ANFIS Toolbox
จากรูปที่ 7.11 แสดงผลการทดสอบ โดยมีค่า %MAPE ที่น้อยที่สุดของชุดฝึกสอนคือ 6.4769% พบว่าข้อมูลฝึกสอนที่ได้จากการประมาณค่าของ ANFIS มีผลลัพธ์ที่ค่อนข้างแม่นยำ



รูปที่ 7.12 โครงสร้าง MFs 6 1 9 บน MATLAB ANFIS Toolbox

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากรูปที่ 7.12 แสดงลักษณะของโครงสร้างที่มีอินพุต 3 ตัว และจำนวนฟังก์ชันสมาชิกของอินพุต เป็น 6 1 9 ตามลำดับ โดยใช้กฎของฟัชซี คือ and ซึ่งจากการปรับเปลี่ยนกฎของฟัชซีแล้วพบว่า กฎ and ให้ผลลัพธ์ที่มีค่าผิดพลาดน้อยที่สุด



รูปที่ 7.13 แสดงลักษณะของฟังก์ชันสมาชิกชนิด pimf

จากรูปที่ 7.6 แสดงลักษณะการกระจายของฟังก์ชันสมาชิกชนิด pimf ของอินพุตทั้ง 3 ตัว โดยมีค่าอยู่ระหว่าง 0 – 1

หลังจากเลือกโครงสร้างที่ดีที่สุดได้แล้ว นำค่าเอาต์พุตที่ได้จากระบบอนุมานนิวโรฟัชซีแบบปรับตัวได้มาเปรียบเทียบกับเอาต์พุตที่เป็นค่าจริงแสดงตามรูปที่ 7.14



รูปที่ 7.14 แสดงการเปรียบเทียบดัชนี EENS ระหว่างค่าจริงกับค่าที่ได้จาก ANFIS

จากรูปที่ 7.14 ระบบอนุมานนิวโรฟัชซีแบบปรับตัวได้ให้ผลลัพธ์ที่แม่นยำมาก และใช้เวลาในการเรียนรู้ที่รวดเร็วเหมาะสมสำหรับนำไปจำลองข้อมูลพลังงานลมได้อย่างมีประสิทธิภาพมาก จึงสามารถนำไปประยุกต์ใช้เพื่อประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าในบทต่อไปได้

7.3 ผลการประเมินความเชื่อถือได้ของระบบผลิตไฟฟ้าเปรียบเทียบเทียบระหว่าง ANN และ ANFIS

7.3.1 การประเมินดัชนี EENS ของระบบ IEEE RTS

ตารางที่ 7.5 เปรียบเทียบผลการทดสอบระหว่าง ANN และ ANFIS บนระบบ IEEE RTS

	ANN	ANFIS
Model	Back-Propagation	Sugeno
Structure	Multi-Layer Feed Forward	Sugeno 1 st
Training Method	Levenberg-Marquardt	Hybrid (Gradient descent)
Training data	34	34
Testing data	8	8
Transfer function, Membership function	Hidden layer 1: tansig, 10 neurons Hidden layer 2: tansig, 9 neurons Output layer: purelin	Input 1: MFs 6, trimf Input 2: MFs 2, trimf Input 3: MFs 7, trimf Output MF, linear
Epochs	500	100
%MAPE Train	0.2567	0.2916
%MAPE Test	0.7687	0.6483

ตารางที่ 7.5 เป็นการเปรียบเทียบดัชนี EENS ของระบบ IEEE RTS เมื่อเพิ่มกำลังผลิตไฟฟ้าจากพลังงานลม สำหรับโครงข่ายประสาทเทียม (ANN) ชั้นซ่อนที่ 1 มี 10 นิวรอนใช้ฟังก์ชันถ่ายโอนเป็น tansig ชั้นซ่อนที่ 2 มี 9 นิวรอนใช้ฟังก์ชันถ่ายโอนเป็น tansig ชั้นเอาต์พุตใช้ฟังก์ชันถ่ายโอนเป็น purelin และใช้กระบวนการเรียนรู้แบบ Levenberg-Marquardt 500 epochs โดยค่า weight และ bias เริ่มต้นจากการสุ่ม ทำการเรียนรู้ 30 รอบ เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด สำหรับระบบอนุมานนิวโรฟuzzyแบบปรับตัวได้ (ANFIS) ใช้โมเดลฟuzzy Sugeno อันดับที่ 1 จำนวนฟังก์ชันสมาชิกของทั้ง 3 อินพุตคือ 6 2 7 ใช้ฟังก์ชันสมาชิกชนิด trimf ชั้นเอาต์พุตใช้ฟังก์ชันสมาชิก linear โดยใช้กระบวนการเรียนรู้แบบ Hybrid 100 epochs

ตารางที่ 7.6 เปรียบเทียบค่าเอาต์พุต ANN และ ANFIS

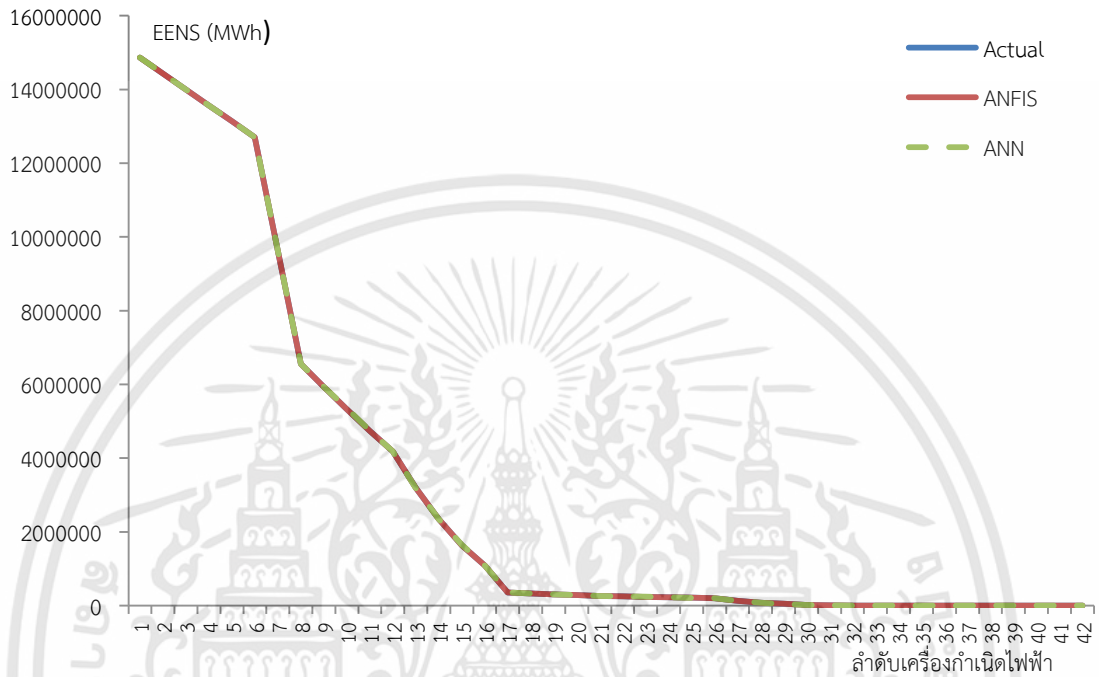
ดัชนี EENS (MWh)		
ค่าจริง	ANN	ANFIS
14862974	14862944	14862306
14430542	14430653	14430962
13998110	13997971	13998636
13565678	13565746	13566031
13134915	13133779	13133144

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดัชนี EENS (MWh)		
ค่าจริง	ANN	ANFIS
12700814	12700809	12699977
9625742	9625742	9625552
6558091	6558091	6558249
5925833	5925834	5925051
5317900	5319505	5346315
4734008	4734008	4737152
4182558	4182558	4180374
3193846	3193845	3188881
2339415	2339415	2346536
1632254	1632493	1644747
1083019	1083018	1080764
354871.4	354871.5	354869.2
329531.6	329533.1	329492
305778.3	305775.3	305837.8
283726.2	283031.4	283527.7
262577.9	262578.7	262554.1
249562.6	249554.1	249374
237089.1	237116.7	237837.5
225106.6	225086	224651.4
213805	213352	209824.8
202605.1	202610.1	202564.3
129372.7	129372.2	128447.2
79126.62	79125.9	80958.54
46542.68	46541.17	45639.78
15562.42	15306.23	15784.12
4562.855	4561.954	4542.341
1174.335	1174.31	1185.272
1173.209	1201.153	1164.733
1172.085	1134.462	1180.063
1170.961	1137.266	1175.289
1169.837	1160.216	1171.328
1168.715	1176.579	1168.182
1167.592	1178.208	1165.85
1166.471	1169.738	1164.332
1165.35	1161.203	1163.629

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดัชนี EENS (MWh)		
ค่าจริง	ANN	ANFIS
1164.23	1159.606	1163.739
1163.111	1160.26	1164.664



รูปที่ 7.15 แสดงการเปรียบเทียบดัชนี EENS ระหว่าง ANN และ ANFIS

พบว่าโครงข่ายประสาทเทียม (ANN) ให้ผลลัพธ์ที่ดีเท่ากับระบบอนุมานนิเวศวิทยาแบบปรับตัว (ANFIS) พิจารณาจากค่า %MAPE ของ ANN ใกล้เคียงกับ %MAPE ของ ANFIS โดยแสดงการเปรียบเทียบค่าเอาต์พุตที่ได้ดังตารางที่ 7.6 จะเห็นว่า ANN และ ANFIS ให้คำตอบใกล้เคียงค่าจริง

7.3.2 การประเมินดัชนี EENS ของระบบระบบไฟฟ้าประเทศไทย

ตารางที่ 7.7 เปรียบเทียบผลการทดสอบระหว่าง ANN และ ANFIS บนระบบไฟฟ้าประเทศไทย

	ANN	ANFIS
Model	Back-Propagation	Sugeno
Structure	Multi-Layer Feed Forward	Sugeno 1 st
Training Method	Levenberg-Marquardt	Hybrid (Gradient descent)
Training data	80	80
Testing data	15	15
Transfer function, Membership function	Hidden layer 1: purelin, 9 neurons Hidden layer 2: logsig, 8 neurons Output layer: purelin	Input 1: MFs 6, pimf Input 2: MFs 1, pimf Input 3: MFs 9, pimf Output MF, linear
Epochs	500	100
%MAPE Train	3.1513	4.2509
%MAPE Test	4.1918	6.4769

ตารางที่ 7.7 เป็นการเปรียบเทียบดัชนี EENS ของระบบไฟฟ้าประเทศไทยเมื่อเพิ่มกำลังผลิตไฟฟ้าจากพลังงานลม สำหรับโครงข่ายประสาทเทียม (ANN) ชั้นซ่อนที่ 1 มี 9 นิวรอนใช้ฟังก์ชันถ่ายโอนเป็น purelin ชั้นซ่อนที่ 2 มี 8 นิวรอนใช้ฟังก์ชันถ่ายโอนเป็น logsig ชั้นเอาต์พุตใช้ฟังก์ชันถ่ายโอนเป็น purelin และใช้กระบวนการเรียนรู้แบบ Levenberg-Marquardt 500 epochs โดยค่า weight และ bias เริ่มต้นจากการสุ่ม ทำการเรียนรู้ 30 รอบ เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด สำหรับระบบอนุมานนิเวศวิทยาแบบปรับตัวได้ (ANFIS) ใช้โมเดลฟัซซี Sugeno อันดับที่ 1 จำนวนฟังก์ชันสมาชิกของทั้ง 3 อินพุตคือ 6 1 9 ใช้ฟังก์ชันสมาชิกชนิด pimf ชั้นเอาต์พุตใช้ฟังก์ชันสมาชิก linear โดยใช้กระบวนการเรียนรู้แบบ Hybrid 100 epochs

ตารางที่ 7.8 เปรียบเทียบค่าเอาต์พุต ANN และ ANFIS

ดัชนี EENS (MWh)		
Actual	ANN	ANFIS
146918132.4	146396484.1	147842515.3
145679818.8	145188578.3	145988167
144441505.2	143831385.4	144133818.7
143203191.6	142311232.9	142279470.4
39911888.12	39739004.69	39861312.68
38146539.12	38380951.11	38077956.3
36393985.52	36946432.59	36374114.7
34656397.85	35350764.39	34670273.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ดัชนี EENS (MWh)		
Actual	ANN	ANFIS
32936584.61	33530820.95	32966431.51
31165462.58	31422485.36	31220182.03
29421396.03	29050708.57	29516340.43
27536656.61	26392354.27	27384621.69
22794755.96	22643900.34	22720465.63
20272603.48	20650772.17	20687059.27
17907192.11	18177477.83	17591802.49
16026387.88	16200157.9	15683327.06
14268043.65	14476475.1	14237334.11
13651204.81	13845112.27	14010456.92
13044151.93	12947543.61	13259156.58
12452686.42	12341129.95	12532557.22
11867910.24	11893843.43	11799309.16
11296864.5	11481900.64	11071601.69
10736073.32	10952753.03	10341308.61
9472737.23	9448129.339	8988623.735
8311866.08	8513481.306	8287511.043
7213522.32	7301354.63	7552785.5
6143707.35	5908862.088	6777798.411
4075131.04	3876464.561	4073427.539
2479495.64	2663263.326	2481215.129
1535299.47	1753964.278	1534468.22
877392.51	986065.9485	1097240.95
432852.65	332131.6079	434857.8247
192819.34	8112.614169	191667.9818
119651.39	289529.1009	119724.8644
71973.06	150072.0405	71844.66815
64074.72	139934.8334	61725.71963
56925.63	65366.57622	56693.92769
55677.45	44871.91534	57408.02978
140726564.4	140397638.1	139170302.9
138249937.2	138487607.4	137315954.6
135773310	136374499.9	135461606.3
133296682.8	134048109.8	133607258.1
130820055.6	131500635.5	131752909.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดัชนี EENS (MWh)		
Actual	ANN	ANFIS
128343428.4	128727428.6	130332591.6
122816311.4	122379656.9	122813796.6
117289194.4	118936151.1	117332711.1
114410220.4	117226887.4	117225660.9
112518323.2	113864989.7	113703788.2
110626426	109985689.4	109771593.3
108652272.4	105934378.6	105805205
103017709	100316706.7	100351398.7
97465401.99	96142268.45	96453397.34
91863741.15	91899673.12	92500686.37
88931300.49	88792563.48	89678071.08
85998859.83	84642891.55	85745876.22
79961240.07	79382920.82	80522876.18
73923881.96	75502603.1	76590681.32
72032473.64	73270448.41	74381839.62
70141394.24	69668193.35	70449644.77
68168532.97	66240280.95	66483256.4
62419663.69	61933824.54	60978159.85
56685454.13	59052618.24	57019981.91
54805524.53	57371956.8	55100916.76
52928194.48	54851137.71	52480255.47
50891304.62	52508788.54	50722745.34
49996558.26	50634796.11	50077185.88
49102886.06	48701780.11	49056449.13
48169914.27	46934437.2	48075314.52
46551071.59	45220477.81	46587026
44937810.6	43746246.12	44996691.91
43186827.85	42347591.37	43213335.53
41545030.91	41041924.66	41565154.28
54360.57	20843.09633	52306.28783
53071.48	9941.116438	47304.47447
28427.5	32239.72984	28417.07826
27607.13	6140.852205	37100.99056
26808.24	8075.798813	32099.1772
25744.39	10195.06802	26497.79229

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดัชนี EENS (MWh)		
Actual	ANN	ANFIS
24718.97	12809.07717	21495.97893
19670.91	24416.17023	19700.92383
15708.1	3754.409927	12758.39977
12489.75	7842.136	16357.80487
9888.42	10978.91388	10772.11341
7795.58	13340.0995	4694.229
6119.63	15084.27466	7393.440003
6118.54	1773.657588	5441.6299
6117.46	5859.93978	8051.662907
6116.23	8951.467308	5268.91921
6115.74	11277.92709	5001.606519
6114.24	13020.22376	5343.349186
6113.36	14319.24382	5685.091853
6112.48	15283.70814	6026.834519
6111.22	15996.88002	6368.577186
6110.64	16522.11698	6710.319852
6109.79	16907.36275	7052.062519



รูปที่ 7.16 แสดงการเปรียบเทียบดัชนี EENS ระหว่าง ANN และ ANFIS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พบว่าโครงข่ายประสาทเทียม (ANN) ให้ผลลัพธ์ที่ดีกว่าระบบอนุมานนิวโรฟซีแบบปรับตัวได้ (ANFIS) พิจารณาจากค่า %MAPE ของ ANN น้อยกว่า %MAPE ของ ANFIS โดยแสดงการเปรียบเทียบค่าเอาต์พุตที่ได้ดังตารางที่ 7.8 จะเห็นว่า ANN ให้คำตอบใกล้เคียงค่าจริงมากกว่า ANFIS



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 8

สรุปผลการวิจัยและข้อเสนอแนะ

8.1 วิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม

ในวิทยานิพนธ์ฉบับนี้จะนำเสนอวิธีการจำลองพลังงานไฟฟ้าที่ผลิตได้จากพลังงานลม โดยใช้วิธีการกระจายแบบไวบูลล์, วิธีโครงข่ายประสาทเทียม และวิธีระบบอนุมานนิเวศวิธีแบบปรับตัวได้ กำหนดความเร็วลมเฉลี่ย พลังงานไฟฟ้าย้อนหลัง 1 เดือน และข้อมูลพลังงานไฟฟ้าย้อนหลัง 2 เดือน เป็นข้อมูลอินพุต และกำหนดพลังงานไฟฟ้าที่ผลิตได้จริงเป็นข้อมูลเอาต์พุต ซึ่งผลที่ได้พบว่าการจำลองข้อมูลโดยใช้โครงข่ายประสาทเทียมให้ผลลัพธ์ที่ดีที่สุด พิจารณาจาก %MAPE ของ ANN มีค่าน้อยที่สุด แสดงว่าลักษณะข้อมูลพลังงานลมเหมาะสมสำหรับการจำลองโดยใช้วิธีโครงข่ายประสาทเทียมมากที่สุด รองลงมาคือวิธีระบบอนุมานนิเวศวิธีแบบปรับตัวได้ และวิธีการกระจายแบบไวบูลล์ตามลำดับ ซึ่งสามารถสรุปลักษณะข้อดีและข้อเสียแต่ละวิธีได้ดังนี้

วิธีโครงข่ายประสาทเทียม สามารถประมวลผลข้อมูลที่มีจำนวนมากและซับซ้อนได้ดี, ไม่จำเป็นวิธีการทางคณิตศาสตร์ และผลการทดสอบแม่นยำและมีประสิทธิภาพมากที่สุด แต่ใช้เวลาในการเรียนรู้มากกว่า ANFIS, ต้องการข้อมูลอินพุตและเอาต์พุตที่ดีจึงจำเป็นต้องหาข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุดซึ่งอาจเกิดปัญหาในการรวบรวมข้อมูลหรือลักษณะข้อมูลไม่เป็นไปตามที่ต้องการ

วิธีระบบอนุมานนิเวศวิธีแบบปรับตัวได้ สามารถประมวลผลข้อมูลได้อย่างรวดเร็ว, ไม่จำเป็นวิธีการทางคณิตศาสตร์, มีฟังก์ชันสมาชิกให้เลือกใช้ได้อย่างหลากหลาย และผลการทดสอบแม่นยำและมีประสิทธิภาพดีแต่น้อยกว่า ANN แต่เมื่อมีจำนวนข้อมูลมากหรือโครงสร้างซับซ้อนจะทำงานได้ช้าลงและใช้เวลาในการเรียนรู้มากขึ้น บางครั้งมีข้อมูลมากเกินไปจะทำให้กฎการกระทำมากจนโปรแกรมไม่สามารถทำงานได้, ต้องการข้อมูลอินพุตและเอาต์พุตที่ดีจึงจำเป็นต้องหาข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุดซึ่งอาจเกิดปัญหาในการรวบรวมข้อมูลหรือลักษณะข้อมูลไม่เป็นไปตามที่ต้องการ

วิธีการกระจายแบบไวบูลล์ เป็นการคำนวณตามวิธีการทางคณิตศาสตร์ที่มีสมการในการคำนวณตามแบบแผนโดยมีการศึกษาจากหลายๆ งานวิจัยแล้วพบว่าการกระจายแบบไวบูลล์เหมาะสำหรับการกระจายข้อมูลที่ไม่สมมาตรของพลังงานลมมากที่สุด โดยเราสามารถกำหนดจำนวนเอาต์พุตตามที่ต้องการนำไปใช้งานได้อาจเป็นรายชั่วโมง รายเดือนหรือรายปีแล้วแต่ความต้องการของผู้ใช้ ซึ่งข้อมูลที่ทดสอบแล้วมีค่าใกล้เคียงกับค่าจริง พิจารณาจากค่า Plant factor ของพลังงานไฟฟ้าที่ผลิตได้จากกังหันลมในแต่ละเดือนมีค่าใกล้เคียงความเป็นจริงเป็นอย่างมาก จึงเหมาะสำหรับการนำไปใช้ต่อการคำนวณทางสถิติและความน่าจะเป็น ค่าความผิดพลาดมากกว่า ANN และ ANFIS ซึ่งเป็นข้อเสียที่เกิดจากการสุ่มตัวเลขทำให้เกิดความคลาดเคลื่อนมากกว่าวิธีอื่น

ดังนั้นจึงควรเลือกใช้ใช้งานวิธีการจำลองข้อมูลตามความเหมาะสมและความต้องการในการใช้งานต่อไป

8.2 วิธีการประเมินดัชนีความเชื่อถือได้ของระบบผลิตไฟฟ้า

ในวิทยานิพนธ์ฉบับนี้จะนำเสนอวิธีการประเมินดัชนี ของระบบผลิตไฟฟ้า โดยใช้วิธีโครงข่ายประสาทเทียม และวิธีระบบอนุมานนิวโรฟซีแบบปรับตัวได้ กำหนดการจัดลำดับความสำคัญ (Priority list), กำหนดการผลิตติดตั้ง และค่า Force outage rate (FOR) ของเครื่องกำเนิดไฟฟ้าที่เพิ่มเข้าไปที่ละเครื่องเป็นข้อมูลอินพุต และกำหนดดัชนี EENS เป็นเอาต์พุต ซึ่งข้อมูลทั้งหมดได้จากการคำนวณดัชนี EENS ตามหลักการความเชื่อถือได้ของระบบผลิตไฟฟ้าบนระบบทดสอบ IEEE RTS และบนระบบไฟฟ้าประเทศไทย ซึ่งผลที่ได้พบว่าการจำลองข้อมูลโดยใช้โครงข่ายประสาทเทียมให้ผลลัพธ์ที่ดีที่สุด พิจารณาจาก %MAPE ของ ANN มีค่าน้อยที่สุด แสดงว่าลักษณะข้อมูลเหมาะสมสำหรับการประเมินดัชนีความเชื่อถือได้โดยใช้วิธีโครงข่ายประสาทเทียมมากที่สุด รองลงมาคือวิธีระบบอนุมานนิวโรฟซีแบบปรับตัวได้ ซึ่งสามารถสรุปลักษณะข้อดีและข้อเสียแต่ละวิธีได้ดังนี้

วิธีโครงข่ายประสาทเทียม สามารถประมวลผลข้อมูลที่มีจำนวนมากและซับซ้อนได้ดี, ไม่จำเป็นต้องใช้วิธีการทางคณิตศาสตร์ และผลการทดสอบแม่นยำและมีประสิทธิภาพมากที่สุด แต่ใช้เวลาในการเรียนรู้มากกว่า ANFIS, ต้องการข้อมูลอินพุตและเอาต์พุตที่ดีจึงจำเป็นต้องหาข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุดซึ่งอาจเกิดปัญหาในการรวบรวมข้อมูลหรือลักษณะข้อมูลไม่เป็นไปตามที่ต้องการ

วิธีระบบอนุมานนิวโรฟซีแบบปรับตัวได้ สามารถประมวลผลข้อมูลได้อย่างรวดเร็ว, ไม่จำเป็นต้องใช้วิธีการทางคณิตศาสตร์, มีฟังก์ชันสมาชิกให้เลือกใช้ได้อย่างหลากหลาย และผลการทดสอบแม่นยำและมีประสิทธิภาพดีแต่น้อยกว่า ANN แต่เมื่อมีจำนวนข้อมูลมากหรือโครงสร้างซับซ้อนจะทำงานได้ช้าลงและใช้เวลาในการเรียนรู้มากขึ้น บางครั้งมีข้อมูลมากเกินไปจะทำให้กฎการกระทำมากจนโปรแกรมไม่สามารถทำงานได้, ต้องการข้อมูลอินพุตและเอาต์พุตที่ดีจึงจำเป็นต้องหาข้อมูลที่มีนัยสำคัญต่อเอาต์พุตมากที่สุดซึ่งอาจเกิดปัญหาในการรวบรวมข้อมูลหรือลักษณะข้อมูลไม่เป็นไปตามที่ต้องการ

ดังนั้นการประเมินความเชื่อถือได้นอกจากใช้วิธีการทางคณิตศาสตร์แล้วยังสามารถเลือกใช้งานวิธีโครงข่ายประสาทเทียม หรือวิธีระบบอนุมานนิวโรฟซีแบบปรับตัวได้ ซึ่งมีการเรียนรู้ที่รวดเร็วกว่าและมีผลลัพธ์ที่แม่นยำและถูกต้องมาก

8.3 ข้อเสนอแนะ

1. การประเมินความเชื่อถือได้สามารถประเมินค่าผ่านดัชนีชนิดอื่นได้ เช่น ดัชนี LOLE, ดัชนี SAIFI, ดัชนี SAIDI ขึ้นอยู่กับความต้องการในการคาดการณ์หรือการประเมินของผู้ใช้
2. พลังงานหมุนเวียนในประเทศไทย เช่น พลังงานแสงอาทิตย์ พลังงานชีวมวล พลังน้ำ เป็นต้น สามารถใช้วิธีการประเมินความเชื่อถือได้กรณีเพิ่มกำลังการผลิตได้เช่นเดียวกับในวิทยานิพนธ์นี้
3. การจำลองข้อมูลจะมีประสิทธิภาพมากขึ้นถ้ามีข้อมูลมากเพียงพอและมีนัยสำคัญเพียงพอต่อเอาต์พุตที่ต้องการ
4. จำนวนอินพุตไม่มีผลต่อประสิทธิภาพของ ANN และ ANFIS มากเท่ากับการเลือกข้อมูลที่สัมพันธ์กันเพื่อให้ได้คำตอบตรงกับค่าจริงมากที่สุด
5. เราสามารถปรับชุดข้อมูลฝึกสอนและข้อมูลทดสอบเพื่อปรับปรุงประสิทธิภาพได้

เอกสารอ้างอิง

- [1] อนุบุตร สง่าศรี. การประเมินคุณค่าและความเชื่อถือได้ของการผลิตไฟฟ้าจากพลังงานหมุนเวียน, วิทยานิพนธ์ปริญญาโทมหาบัณฑิต, สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2546.
- [2] ธเนศ ไชยชนะ, สัมพันธ์ ไชยเทพ และ ณัฐวุฒิ ดุษฎี. การวิเคราะห์ศักยภาพพลังงานลมโดยใช้วิธีการแจกแจงแบบ Weibull และ Rayleigh. ใน รายงานการประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 22, หน้า 234-240. 1-4 พฤศจิกายน 2551 ณ มหาวิทยาลัยธรรมศาสตร์ ศูนย์รังสิต จังหวัดปทุมธานี, 2551.
- [3] Billinton, R. and Harrington, P.G. Wind Reliability evaluation in energy limited generating capacity studies. **IEEE Transactions on Power Apparatus and System**, Vol. PAS-97, No. 6, Nov/Dec 1978.
- [4] Billinton, R. and Allan, R. N. **Reliability Evaluation of Power Systems**. London: Pitman Advance Publishing, 1984.
- [5] พัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ, กรม. พลังงานลม (Wind Energy), กรุงเทพมหานคร: กรมพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ, 2545.
- [6] Zuwei Yu Tuzuner, A. Wind speed modeling and energy production simulation with Weibull sampling. **IEEE Transactions on Power System**, Vol. 22, Issue. 4, July 2008.
- [7] Jyh Shing, Roger Jang, ANFIS: Adaptive Network based Fuzzy Inference System, **IEEE Transaction on power Systems**, vol. 23, n.3, May/June 1993, pp. 665-685.
- [8] Nima Amjady, Mehdi Ehsan, Evaluation of Power Systems Reliability by an Artificial Neural Network, **IEEE Transaction on Power Systems**, vol. 14, n. 1, Feb 1999, pp. 287-292.
- [9] พรเทพ เทียบรัตน์. การวางแผนกำลังการผลิตไฟฟ้าที่คำนึงถึงความไม่แน่นอนของการพยากรณ์ความต้องการไฟฟ้า, วิทยานิพนธ์ปริญญาโทมหาบัณฑิต, สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2550.
- [10] D.C. Park, M.A. El-Sharkawi, R.J. Marks II, Electric Load Forecasting Using An Artificial Neural Network, **IEEE Transaction on Power Systems**, vol. 6, n. 2, May 1991, pp. 440-449.
- [11] S.Kalyani, K. Shanyi, Study of Neural Network Models for Security Assessment in Power System, **International Journal of Research and Reviews in Applied Sciences**, vol. 1, Issue 2, Nov 2009, pp. 104-117.
- [12] Armando M., Leonidas C., Vladimiro M., Luiz A., Composite Reliability Assessment Based on Monte Carlo Simulation and Artificial Neural Networks, **IEEE Transaction on Power Systems**, vol. 22, n. 3, Aug 2007, pp. 1202-1209.

- [13] H. Demuth, M. Hagan, M. Beale, **Neural Network Toolbox™ User's Guide (The Math Works, Inc.1992- 2017).**
- [14] การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. **แผนพัฒนากำลังการผลิตแห่งประเทศไทยพ.ศ.2551-2564.** กรุงเทพมหานคร: การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย,2552.
- [15] พัฒนาพลังงานทดแทนและอนุรักษ์พลังงาน, กรม. **รายงานพลังงานของประเทศไทย2560.** กรุงเทพมหานคร: กรมพัฒนาพลังงานทดแทนและอนุรักษ์พลังงาน, 2560.
- [16] NERC. **Generating Unit Statistical Brochure.** [ออนไลน์]. 2018. แหล่งที่มา: <http://www.nerc.com/page.php?cid=4|43>. [2018, March 20]
- [17] การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. **ไฟฟ้าจากพลังงานลม.** [ออนไลน์]. 2018. แหล่งที่มา: http://www3.egat.co.th/re/egat_wind/egat_wind.htm. [2018, May 2]
- [18] P.S. Rajpal, K.S. Shishodia, G.S. Sekhon, An artificial neural network for modeling reliability, availability and maintainability of a repairable system, **Elsevier Science Limited**, 2005, pp. 809-819.
- [19] พลังงาน, กระทรวง. **แผนพัฒนาพลังงานทดแทน 15 ปี.** [ออนไลน์]. 2018. แหล่งที่มา: <http://www.efe.or.th/pdf/RenewableEnergy-15years.pdf> [2018, Jan 11]
- [20] Somchat Jiriwibhakorn, **Application of Neural Networks in Power Systems** (Electrical Engineering Faculty: KMITL, 2011).
- [21] **Fuzzy logic Toolbox™: Adaptive neuro fuzzy modeling.** The Math Works, Received Feb 2017 from <https://www.mathworks.com/help/fuzzy/adaptive-neuro-fuzzy-inference-systems.html>
- [22] A. Badri, Z. Ameli, A. MototieBirjandi, Application of Artificial Neural Networks and Fuzzy Logic Methods for Short Term Load Forecasting, **Elsevier Science Limited**, 2012, pp. 1883-1888.
- [23] **Power Development Plan: PDP 2015**, Ministry of Energy, Received Apr 2017 from www.eppo.go.th/index.php/th/plan-policy/tieb/pdp.
- [24] K. Xie, H. Zhang, C. Singh, Reliability forecasting models for electrical distribution systems considering component failures and planned outage, **Elsevier Science Limited**, 2016, pp. 228-234.
- [25] Y. Yang, Y. Chen, Y. Wang. C. Li, L. Li, Modeling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting, **Elsevier Science Limited**, 2016, pp. 663-675.
- [26] G. J. Anders, J. Endrenyi, M. V. Pereira, L. M. V. G. Pinto, C. G. Oliveira, and S. H. F. Cunha, "Fast Monte-Carlo simulation techniques for power system reliability studies," **presented at the Proc. 1990 CIGRE Meeting, Paris, France, Sep. 1990, Paper 38-205.**

- [27] A. M. Leite da Silva, L. A. F. Manso, J. C. O. Mello, and R. Billinton, "Pseudo-chronological simulation for composite reliability analysis with time varying loads," *IEEE Trans. Power Syst.*, vol. 15, no. 1, pp. 73–80, Feb. 2000.
- [28] J. C. O. Mello, M. V. F. Pereira, and A. M. Leite da Silva, "Evaluation of reliability worth in composite system based on pseudo-sequential Monte Carlo simulation," *IEEE Trans. Power Syst.*, vol. 9, no. 3, pp. 1318–1326, Aug. 1994.
- [29] J. C. O. Mello, A. M. Leite da Silva, and M. V. F. Pereira, "Efficient loss-of-load cost evaluation by combined pseudo-sequential and state transition simulation," *Proc. Inst. Elect. Eng. C*, vol. 144, no. 2, pp. 147–154, Mar. 1997.





เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.1 ข้อมูลของเครื่องกำเนิดไฟฟ้าในระบบ IEEE-RTS

จำนวนเครื่องกำเนิดไฟฟ้า	กำลังผลิตติดตั้ง (MW)	ค่า FOR
5	12	0.02
4	20	0.10
6	50	0.01
4	76	0.02
3	100	0.04
4	155	0.04
3	197	0.05
1	350	0.08
2	400	0.12

ตาราง ก.2 รายละเอียดข้อมูลเครื่องกำเนิดไฟฟ้าประเภทโรงไฟฟ้าพลังความร้อนของระบบไฟฟ้าของประเทศไทย

โรงไฟฟ้า	จำนวน	กำลังผลิต (MW)	FOR (%) NERC
Mae Moh	4	150	0.0576
Mae Moh	6	300	0.0576
BLCP(IPP)	2	673.3	0.0629
EPEC (IPP)	1	350	0.061
IPT (IPP)	2	230	0.061
IPT (IPP)	1	240	0.061
Ratchaburi (IPP)	1	685	0.061
Ratchaburi (IPP)	1	675	0.061
Ratchaburi (IPP)	1	681	0.061
GLOW (IPP)	2	356.5	0.061
GPG(IPP)	2	734	0.061
TECO (IPP)	2	230	0.061
TECO (IPP)	1	240	0.061
RGCO power(IPP)	2	700	0.061
Chana	2	230	0.061
Chana	1	250	0.061
South Bangkok	2	110	0.061

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โรงไฟฟ้า	จำนวน	กำลังผลิต (MW)	FOR (%) NERC
South Bamgkok	1	115	0.061
South Bamgkok	2	200	0.061
South Bamgkok	1	218	0.061
Wang Noi	2	205.4	0.061
Wang Noi	4	223.4	0.061
Wang Noi	2	233	0.061
Wang Noi	1	256.7	0.061
KEGCO (IPP)	1	678	0.061
Bang Pakong	2	386.3	0.061
Bang Pakong	2	328.5	0.061
Nam Phong	1	120.7	0.061
Nam Phong	2	121.9	0.061
Nam Phong	1	123.7	0.061
Nam Phong	1	124	0.061
Nam Phong	1	125	0.061
REGCO (IPP)	1	294.5	0.061
REGCO (IPP)	1	287.6	0.061
REGCO (IPP)	1	289.8	0.061
REGCO (IPP)	1	302.9	0.061
Ratchaburi (IPP)	2	720	0.1125
Bang Pakong	2	550	0.0696
Bang Pakong	2	600	0.0696
South Bangkok	2	310	0.0531
KEGCO (IPP)	1	69.9	0.0836
KEGCO (IPP)	1	70.2	0.0836
Lan Krabu	1	13	0.0836
Lan Krabu	2	14	0.0836
Krabi	1	340	0.0387

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


โรงไฟฟ้า	จำนวน	กำลังผลิต (MW)	FOR (%) NERC
Lan Krabu	2	16	0.0836
Lan Krabu	2	22	0.0836
Lan Krabu	1	120	0.0621
Surat Thani	2	122	0.1046
Nong Chok	3	122	0.1046

ตาราง ก.3 ข้อมูลกำลังไฟฟ้าขาออกของกังหันลมขนาด 150 kW

Wind Speed (m/s)	Power Output (kW)
0	0
1	0
2	0
3	0
4	1.68
5	9.38
6	21.28
7	34.51
8	49.63
9	65.73
10	81.41
11	95.69
12	107.73
13	115.15
14	117.6
15	117.18
16	115.57
17	113.68
18	112.63
19	112
20	112
21	112
22	112
23	112
24	112
25	112

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Power curve of Nordtank 150 kW wind turbine



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.1 ข้อมูลระบบทดสอบ IEEE RTS สำหรับการเรียนรู้ของ ANN และ ANFIS

Priority list	Installed capacity (MW)	FOR	EENS (MWh)
1	50	0.01	14862974
2	50	0.01	14430542
3	50	0.01	13998110
4	50	0.01	13565678
5	50	0.01	13133246
6	50	0.01	12700814
7	400	0.12	9625742
8	400	0.12	6558091
9	76	0.02	5925833
10	76	0.02	5316376
11	76	0.02	4734008
12	76	0.02	4182558
13	155	0.04	3193846
14	155	0.04	2339415
15	155	0.04	1631467
16	155	0.04	1083019
17	350	0.08	354871.4
18	20	0.1	329531.6
19	20	0.1	305778.3
20	20	0.1	283502
21	20	0.1	262577.9
22	12	0.02	249562.6
23	12	0.02	237089.1
24	12	0.02	225106.6
25	12	0.02	213626.3
26	12	0.02	202605.1
27	100	0.04	129372.7
28	100	0.04	79126.62
29	100	0.04	46542.68
30	197	0.05	15542.74
31	197	0.05	4562.855
32	197	0.05	1174.335
33	0.15	0.2	1173.209
34	0.15	0.2	1172.085

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Priority list	Installed capacity (MW)	FOR	EENS (MWh)
35	0.15	0.2	1170.961
36	0.15	0.2	1169.837
37	0.15	0.2	1168.715
38	0.15	0.2	1167.592
39	0.15	0.2	1166.471
40	0.15	0.2	1165.35
41	0.15	0.2	1164.23
42	0.15	0.2	1163.111



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.2 ข้อมูลระบบไฟฟ้าประเทศไทยสำหรับการเรียนรู้ของ ANN และ ANFIS

Priority list	Installed capacity (MW)	FOR	EENS (MWh)
1	150	0.0576	146918132.4
2	150	0.0576	145679818.8
3	150	0.0576	144441505.2
4	150	0.0576	143203191.6
5	300	0.0576	140726564.4
6	300	0.0576	138249937.2
7	300	0.0576	135773310
8	300	0.0576	133296682.8
9	300	0.0576	130820055.6
10	300	0.0576	128343428.4
11	673.3	0.0629	122816311.4
12	673.3	0.0629	117289194.4
13	350	0.061	114410220.4
14	230	0.061	112518323.2
15	230	0.061	110626426
16	240	0.061	108652272.4
17	685	0.061	103017709
18	675	0.061	97465401.99
19	681	0.061	91863741.15
20	356.5	0.061	88931300.49
21	356.5	0.061	85998859.83
22	734	0.061	79961240.07
23	734	0.061	73923881.96
24	230	0.061	72032473.64
25	230	0.061	70141394.24
26	240	0.061	68168532.97
27	700	0.061	62419663.69
28	700	0.061	56685454.13
29	230	0.061	54805524.53
30	230	0.061	52928194.48
31	250	0.061	50891304.62
32	110	0.061	49996558.26
33	110	0.061	49102886.06
34	115	0.061	48169914.27

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Priority list	Installed capacity (MW)	FOR	EENS (MWh)
35	200	0.061	46551071.59
36	200	0.061	44937810.6
37	218	0.061	43186827.85
38	205.4	0.061	41545030.91
39	205.4	0.061	39911888.12
40	223.4	0.061	38146539.12
41	223.4	0.061	36393985.52
42	223.4	0.061	34656397.85
43	223.4	0.061	32936584.61
44	233	0.061	31165462.58
45	233	0.061	29421396.03
46	256.7	0.061	27536656.61
47	678	0.061	22794755.96
48	386.3	0.061	20272603.48
49	386.3	0.061	17907192.11
50	328.5	0.061	16026387.88
51	328.5	0.061	14268043.65
52	120.7	0.061	13651204.81
53	121.9	0.061	13044151.93
54	121.9	0.061	12452686.42
55	123.7	0.061	11867910.24
56	124	0.061	11296864.5
57	125	0.061	10736073.32
58	294.5	0.061	9472737.23
59	287.6	0.061	8311866.08
60	289.8	0.061	7213522.32
61	302.9	0.061	6143707.35
62	720	0.1125	4075131.04
63	720	0.1125	2479495.64
64	550	0.0696	1535299.47
65	550	0.0696	877392.51
66	600	0.0696	432852.65
67	600	0.0696	192819.34
68	310	0.0531	119651.39
69	310	0.0531	71973.06

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Priority list	Installed capacity (MW)	FOR	EENS (MWh)
70	69.9	0.0836	64074.72
71	70.2	0.0836	56925.63
72	13	0.0836	55677.45
73	14	0.0836	54360.57
74	14	0.0836	53071.48
75	340	0.0387	28427.5
76	16	0.0836	27607.13
77	16	0.0836	26808.24
78	22	0.0836	25744.39
79	22	0.0836	24718.97
80	120	0.0621	19670.91
81	122	0.1046	15708.1
82	122	0.1046	12489.75
83	122	0.1046	9888.42
84	122	0.1046	7795.58
85	122	0.1046	6119.63
86	0.15	0.2	6118.54
87	0.15	0.2	6117.46
88	0.15	0.2	6116.23
89	0.15	0.2	6115.74
90	0.15	0.2	6114.24
91	0.15	0.2	6113.36
92	0.15	0.2	6112.48
93	0.15	0.2	6111.22
94	0.15	0.2	6110.64
95	0.15	0.2	6109.79

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก ค.
ผลการลองผิดลองถูก
ของ ANN และ ANFIS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.1 ผลการลองผิดลองถูกการจำลองข้อมูลพลังงานลมด้วยกระบวนการเรียนรู้ของ ANN

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
tansig	tansig	purelin	3	2	3.7556	16.6757
tansig	tansig	purelin	4	3	3.3149	13.9971
tansig	tansig	purelin	5	4	3.4024	14.6903
tansig	tansig	purelin	6	5	3.5997	5.2898
tansig	tansig	purelin	7	6	5.1228	3.9066
tansig	tansig	purelin	8	7	5.8191	4.0654
tansig	tansig	purelin	9	8	2.1208	4.6555
tansig	tansig	purelin	10	9	2.6945	4.6070
tansig	tansig	purelin	11	10	2.524	3.3041
tansig	tansig	purelin	12	11	2.7018	3.4110
tansig	tansig	purelin	13	12	2.4362	4.0023
tansig	tansig	purelin	14	13	4.8377	4.5352
tansig	tansig	purelin	15	14	4.6878	9.4804
tansig	tansig	purelin	16	15	6.7049	7.1181
tansig	logsig	purelin	4	3	8.2584	5.1389
tansig	logsig	purelin	5	4	3.6894	7.1247
tansig	logsig	purelin	6	5	5.9192	4.5583
tansig	logsig	purelin	7	6	4.7548	6.1915
tansig	logsig	purelin	8	7	3.7411	5.9508
tansig	logsig	purelin	9	8	6.0421	3.9977
tansig	logsig	purelin	10	9	8.6775	5.2015
tansig	logsig	purelin	11	10	4.1522	8.0882
tansig	logsig	purelin	12	11	4.0376	4.7215
logsig	logsig	purelin	3	2	6.0234	11.2841
logsig	logsig	purelin	4	3	6.2356	15.4433
logsig	logsig	purelin	5	4	4.4440	6.3211
logsig	logsig	purelin	6	5	6.2341	6.9654
logsig	logsig	purelin	7	6	5.0137	6.3666
logsig	logsig	purelin	8	7	4.2379	7.0149
logsig	logsig	purelin	9	8	3.3467	7.2504
logsig	logsig	purelin	10	9	6.1245	5.0023
logsig	logsig	purelin	11	10	6.1243	3.3401
logsig	logsig	purelin	12	11	4.0029	8.4009

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
logsig	tansig	purelin	3	2	9.0805	17.0657
logsig	tansig	purelin	4	3	9.0134	12.0409
logsig	tansig	purelin	5	4	9.0541	12.1876
logsig	tansig	purelin	6	5	7.1451	12.2484
logsig	tansig	purelin	7	6	8.2353	12.0281
logsig	tansig	purelin	8	7	8.4596	12.1409
logsig	tansig	purelin	9	8	8.4441	4.2701
logsig	tansig	purelin	10	9	5.4571	6.1242
logsig	tansig	purelin	11	10	5.4578	6.1124
logsig	tansig	purelin	12	11	5.1569	6.1806
logsig	purelin	purelin	6	5	11.1123	22.2584
logsig	purelin	purelin	7	6	12.3321	22.6288
logsig	purelin	purelin	8	7	22.7210	14.8444
logsig	purelin	purelin	9	8	22.6787	11.5543
logsig	purelin	purelin	10	9	22.2643	13.1145
logsig	purelin	purelin	11	10	22.3248	16.6806
logsig	purelin	purelin	12	11	20.2591	14.7679
tansig	purelin	purelin	5	4	26.5459	18.3797
tansig	purelin	purelin	6	5	20.0078	16.2074
tansig	purelin	purelin	7	6	20.0555	19.7187
tansig	purelin	purelin	8	7	20.1226	15.5240
tansig	purelin	purelin	9	8	20.0040	15.1369
tansig	purelin	purelin	10	9	22.0805	17.0657
tansig	purelin	purelin	11	10	20.0314	10.7210
tansig	purelin	purelin	12	11	19.2134	17.6787
tansig	purelin	purelin	13	12	12.3146	12.2643
tansig	purelin	purelin	14	13	6.5497	12.3248
tansig	purelin	purelin	15	14	5.2436	10.2591
purelin	tansig	purelin	6	5	11.4305	16.5459
purelin	tansig	purelin	7	6	12.0678	10.0078
purelin	tansig	purelin	8	7	20.6468	10.0555
purelin	tansig	purelin	9	8	23.9416	10.1226
purelin	tansig	purelin	10	9	20.0365	10.0040
purelin	tansig	purelin	11	10	20.0544	12.0805

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
purelin	tansig	purelin	12	11	11.0512	15.5228
purelin	tansig	purelin	13	12	17.3188	20.9797
purelin	tansig	purelin	14	13	12.1456	19.1696
purelin	tansig	purelin	15	14	11.4305	15.9190
purelin	tansig	purelin	16	15	11.0678	10.7210
purelin	tansig	purelin	17	16	10.6468	17.6787
purelin	logsig	purelin	3	2	23.9416	52.2643
purelin	logsig	purelin	4	3	20.0365	12.3248
purelin	logsig	purelin	5	4	50.0544	50.2591
purelin	logsig	purelin	6	5	50.1788	52.1463
purelin	logsig	purelin	7	6	50.7210	54.8444
purelin	logsig	purelin	8	7	57.6787	51.5543
purelin	logsig	purelin	9	8	52.2643	53.1145
purelin	logsig	purelin	10	9	52.3248	56.6806
purelin	logsig	purelin	11	10	50.2591	14.7679
purelin	logsig	purelin	12	11	26.5459	18.3797
purelin	logsig	purelin	13	12	20.0078	16.2074
purelin	logsig	purelin	14	13	20.0555	19.7187
purelin	logsig	logsig	9	8	20.1226	15.5240
purelin	logsig	logsig	10	9	20.0040	15.1369
purelin	logsig	logsig	11	10	12.0805	17.0657
purelin	logsig	logsig	12	11	13.0134	12.0409
purelin	tansig	tansig	3	2	22.0541	32.1876
purelin	tansig	tansig	4	3	22.1451	22.2484
purelin	tansig	tansig	5	4	12.2353	22.0281
purelin	tansig	tansig	6	5	12.4596	22.1409
purelin	tansig	tansig	7	6	13.4441	24.2701
purelin	tansig	tansig	8	7	13.4571	12.1242
purelin	tansig	tansig	9	8	13.4578	11.1124
purelin	tansig	tansig	10	9	12.1569	11.1806
purelin	tansig	tansig	11	10	11.1123	12.2584
purelin	tansig	tansig	12	11	12.3321	12.6288
purelin	tansig	tansig	13	12	13.2121	16.5241
purelin	tansig	tansig	14	13	14.2011	25.3012

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.2 ผลการลองผิดลองถูกการจำลองข้อมูลพลังงานลมด้วยกระบวนการเรียนรู้ของ ANFIS

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
3	3	3	trimf	constant	13.6946	183.1436
3	3	3	trimf	linear	0.0089	94.2735
4	3	3	trimf	linear	0.1115	143.0931
4	2	3	trimf	linear	1.3787	203.3537
4	2	4	trimf	linear	0.4757	780.0478
4	2	5	trimf	linear	0.0742	278.3023
4	2	6	trimf	linear	0.0603	187.1519
4	2	7	trimf	linear	0.0594	227.8867
4	2	8	trimf	linear	0.0384	253.7069
4	2	9	trimf	linear	0.0110	248.3055
4	2	10	trimf	linear	0.0069	57.3381
4	3	5	trimf	linear	0.0284	67.9756
5	2	9	trimf	linear	0.0119	72.3775
6	2	6	trimf	linear	0.0186	62.9453
6	2	7	trimf	linear	0.0091	95.6900
6	2	9	trimf	linear	0.0013	51.8285
6	2	8	trimf	linear	0.0107	51.2383
6	2	8	trimf	constant	0.0403	31.1618
6	1	9	trapmf	constant	14.8430	114.6456
6	1	8	trapmf	linear	10.0207	48.4626
6	1	7	trapmf	linear	11.0182	124.1462
6	1	10	trapmf	linear	12.0067	46.0994
6	2	7	trapmf	linear	15.0032	60.6930
4	2	8	trapmf	linear	22.0023	50.6183
4	2	9	trapmf	linear	12.0090	69.6852
5	2	6	trapmf	linear	13.0031	32.6110
6	2	9	trapmf	linear	11.0046	64.3293
6	2	8	trapmf	linear	11.0023	50.6183
6	2	9	trapmf	constant	11.6154	61.2763
6	2	10	trapmf	linear	10.0014	46.9315
6	1	9	trapmf	linear	9.0322	74.7266
7	2	9	trapmf	linear	12.1569	65.0507
7	2	6	trapmf	linear	9.6542	22.5699
7	2	4	trapmf	linear	10.0060	28.5217

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
8	2	4	trapmf	linear	10.0037	28.8809
6	2	5	gbellmf	linear	2.0097	83.4739
6	2	6	gbellmf	linear	2.0070	41.1735
6	2	7	gbellmf	linear	2.0044	59.6341
6	2	8	gbellmf	linear	2.0013	45.4542
6	2	9	gbellmf	linear	2.0093	59.9276
8	2	4	gbellmf	linear	2.0042	36.5840
8	2	5	gbellmf	linear	2.0018	59.5105
7	2	9	gbellmf	linear	2.3028	33.1838
7	2	8	gbellmf	linear	2.8464	29.6683
6	3	6	gbellmf	linear	2.0028	61.8660
6	3	9	gbellmf	linear	2.94444	59.0616
6	2	9	gaussmf	linear	2.7918E-04	45.8170
6	2	9	gaussmf	constant	0.0014	39.5218
6	3	9	gaussmf	constant	0.0041	73.8461
6	3	8	gaussmf	linear	5.1695E-04	48.4943
7	2	9	gaussmf	linear	6.1414 E-04	35.5813
7	2	8	gaussmf	linear	9.5505 E-04	24.6826
7	1	8	gaussmf	linear	0.0041	30.8507
6	3	5	gaussmf	linear	0.0027	44.3090
6	3	7	gaussmf	linear	0.0012	75.6689
6	2	7	gaussmf	linear	0.0059	65.6415
6	1	6	gaussmf	linear	0.0316	81.6154
6	2	9	gauss2mf	linear	0.0038	66.7857
6	2	8	gauss2mf	linear	0.0065	49.6412
6	3	9	gauss2mf	linear	0.0019	84.8973
7	2	9	gauss2mf	constant	0.0013	48.2891
7	2	9	gauss2mf	linear	1.7513 E-04	67.2845
7	2	8	gauss2mf	linear	1.9676 E-04	37.2286
7	2	8	gauss2mf	constant	0.4448	44.0323
7	2	6	gauss2mf	linear	0.0017	19.0456
6	3	5	gauss2mf	linear	0.0024	49.8276
7	3	8	gauss2mf	linear	3.8649 E-04	46.0569
8	2	8	gauss2mf	linear	2.1298 E-04	36.5991
6	2	9	pimf	linear	0.0028	59.6181

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
6	2	8	pimf	linear	0.0018	43.9435
6	1	9	pimf	linear	0.0323	65.7898
6	3	8	pimf	linear	0.0011	47.8588
6	3	9	pimf	linear	0.0011	59.2514
6	1	8	pimf	linear	0.0213	46.6496
6	3	7	pimf	linear	0.0019	53.8943
7	2	9	pimf	linear	1.5510 E-04	67.0655
7	2	8	pimf	linear	3.4135 E-04	41.8175
7	1	8	pimf	linear	0.0022	43.6510
6	3	5	pimf	linear	0.0023	47.9124
6	3	7	pimf	linear	0.0019	53.8943
6	2	7	pimf	linear	0.0020	53.4209
7	3	9	pimf	linear	1.5962 E-04	76.5576
7	1	9	pimf	linear	3.0037	62.8429
8	1	8	pimf	linear	2.0030	7.5842
8	2	8	pimf	linear	2.2227	8.6995
6	2	8	dsigmf	linear	0.0050	5.5021
6	3	9	dsigmf	linear	0.0016	8.9614
6	3	8	dsigmf	linear	6.4846	7.6383
7	2	9	dsigmf	linear	11.7991	14.0131
7	2	8	dsigmf	linear	2.5508	5.1189
7	1	8	dsigmf	linear	0.0089	8.2843
7	2	6	dsigmf	linear	1.4522	6.4049
6	3	5	dsigmf	linear	6.0022	5.2986
6	2	7	dsigmf	linear	5.0022	6.4849
8	2	4	dsigmf	linear	2.1912	4.5678
5	2	5	dsigmf	linear	6.0074	11.1727
6	2	8	psigmf	linear	3.0050	4.5020
5	2	4	psigmf	linear	5.0210	6.0743
5	2	5	psigmf	linear	2.0074	6.1898
7	2	9	psigmf	linear	1.7983	5.0149
7	2	8	psigmf	linear	2.6149	13.3389
7	1	8	psigmf	linear	3.0089	13.2843
6	3	5	psigmf	linear	3.0022	6.2972
6	3	7	psigmf	linear	8.0015	5.7052

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.3 ผลการลองผิดลองถูกการประเมินความเชื่อถือได้ด้วยกระบวนการเรียนรู้ของ ANN บนระบบ IEEE RTS

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
tansig	logsig	purelin	3	2	397.4742	112.7699
tansig	logsig	purelin	4	3	15.0307	9.6346
tansig	logsig	purelin	5	4	6.6180	1.1363
tansig	logsig	purelin	6	5	24.9226	10.4221
tansig	logsig	purelin	7	6	9.9098	3.9727
tansig	logsig	purelin	8	7	7.1580	8.3383
tansig	logsig	purelin	9	8	0.6019	3.4729
tansig	logsig	purelin	10	9	2.6109	5.5927
tansig	logsig	purelin	11	10	0.3029	2.6118
tansig	logsig	purelin	12	11	0.9922	3.0198
tansig	logsig	purelin	13	12	0.4946	2.4560
tansig	logsig	purelin	14	13	13.9325	4.5720
tansig	logsig	purelin	15	14	14.0684	3.5661
tansig	tansig	purelin	3	2	80.4273	84.1629
tansig	tansig	purelin	4	3	191.4661	36.8944
tansig	tansig	purelin	5	4	7.4373	3.1657
tansig	tansig	purelin	6	5	13.0660	4.2854
tansig	tansig	purelin	7	6	28.5227	7.8167
tansig	tansig	purelin	8	7	1.2935	2.2911
tansig	tansig	purelin	9	8	6.1544	2.7327
tansig	tansig	purelin	10	9	0.2567	0.7687
tansig	tansig	purelin	11	10	8.9178	2.8013
tansig	tansig	purelin	12	11	8.0115	4.2345
logsig	logsig	purelin	3	2	33.2884	34.7078
logsig	logsig	purelin	4	3	17.8925	10.4603
logsig	logsig	purelin	5	4	3.2576	10.3191
logsig	logsig	purelin	6	5	13.2279	6.0472
logsig	logsig	purelin	7	6	21.6697	2.3550
logsig	logsig	purelin	8	7	5.8953	4.6345
logsig	logsig	purelin	9	8	1.4031	4.1326
logsig	logsig	purelin	10	9	13.1171	5.2424
logsig	logsig	purelin	11	10	3.0143	2.2732

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
logsig	tansig	purelin	3	2	49.6271	46.3973
logsig	tansig	purelin	4	3	15.6005	7.4762
logsig	tansig	purelin	5	4	33.0614	9.0169
logsig	tansig	purelin	6	5	4.2254	9.7138
logsig	tansig	purelin	7	6	45.0536	9.4292
logsig	tansig	purelin	8	7	24.7104	6.9387
logsig	tansig	purelin	9	8	19.6106	8.1169
logsig	tansig	purelin	10	9	2.4755	4.0730
logsig	tansig	purelin	11	10	7.9958	1.5213
logsig	tansig	purelin	12	11	18.2231	3.8001
logsig	purelin	purelin	6	5	44.8702	37.3736
logsig	purelin	purelin	7	6	43.0916	21.9631
logsig	purelin	purelin	8	7	13.5402	22.8944
logsig	purelin	purelin	9	8	44.5625	16.2498
logsig	purelin	purelin	10	9	32.1676	15.5073
logsig	purelin	purelin	11	10	42.3487	26.4149
logsig	purelin	purelin	12	11	12.1143	13.8822
tansig	purelin	purelin	5	4	52.7057	17.7876
tansig	purelin	purelin	6	5	14.2046	14.3337
tansig	purelin	purelin	7	6	13.0951	10.1496
tansig	purelin	purelin	8	7	40.0870	27.5593
tansig	purelin	purelin	9	8	33.5528	32.5045
tansig	purelin	purelin	10	9	21.4651	25.8021
tansig	purelin	purelin	11	10	6.2720	10.8786
tansig	purelin	purelin	12	11	8.4953	7.1174
tansig	purelin	purelin	13	12	5.4875	12.9862
tansig	purelin	purelin	14	13	2.7884	4.7386
tansig	purelin	purelin	15	14	5.7616	10.3784
purelin	tansig	purelin	6	5	54.1928	38.4569
purelin	tansig	purelin	7	6	81.1705	20.9744
purelin	tansig	purelin	8	7	49.8308	16.7596
purelin	tansig	purelin	9	8	13.5327	8.6086
purelin	tansig	purelin	10	9	1.4234	6.6378
purelin	tansig	purelin	11	10	13.9767	7.9767

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
purelin	tansig	purelin	12	11	1.8980	5.1367
purelin	tansig	purelin	13	12	4.8747	4.1463
purelin	tansig	purelin	14	13	10.5272	3.2810
purelin	logsig	purelin	3	2	547.3695	211.2726
purelin	logsig	purelin	4	3	47.7738	41.4742
purelin	logsig	purelin	5	4	36.2074	37.5518
purelin	logsig	purelin	6	5	16.1733	23.1349
purelin	logsig	purelin	7	6	16.4296	22.4553
purelin	logsig	purelin	8	7	19.5173	11.5740
purelin	logsig	purelin	9	8	8.2147	6.4148
purelin	logsig	purelin	10	9	7.7073	3.5252
purelin	logsig	purelin	11	10	32.8916	10.0399
purelin	logsig	purelin	12	11	1.6451	4.0387
purelin	logsig	purelin	13	12	3.0925	4.0632
purelin	logsig	purelin	14	13	33.5741	9.2959
purelin	logsig	logsig	9	8	1.6967E+05	1.8946E+05
purelin	logsig	logsig	10	9	1.6967E+05	1.8946E+05
purelin	logsig	logsig	11	10	1.6967E+05	1.8946E+05
purelin	logsig	logsig	12	11	1.6967E+05	1.8946E+05
purelin	tansig	tansig	3	2	31.4702	19.8377
purelin	tansig	tansig	4	3	192.0550	96.4687
purelin	tansig	tansig	5	4	64.6183	49.9005
purelin	tansig	tansig	6	5	154.1365	64.1438
purelin	tansig	tansig	7	6	3404729	21.5267
purelin	tansig	tansig	8	7	2.9335	7.8218
purelin	tansig	tansig	9	8	27.4878	25.6536
purelin	tansig	tansig	10	9	19.2473	4.7181
purelin	tansig	tansig	11	10	6.8581	7.9120
purelin	tansig	tansig	12	11	2.3613	7.1185
purelin	tansig	tansig	13	12	3.9103	7.8036
purelin	tansig	tansig	14	13	8.8732	8.0200
purelin	tansig	logsig	11	10	1.6967E+05	1.8946E+05
purelin	tansig	logsig	12	11	1.6967E+05	1.8946E+05
purelin	purelin	purelin	12	11	2.6739E+04	2.4919E+04

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.4 ผลการลองผิดลองถูกการประเมินความเชื่อถือได้ด้วยกระบวนการเรียนรู้ของ ANFIS
บนระบบ IEEE RTS

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
3	3	3	trimf	constant	98.6524	72.4852
3	3	3	trimf	linear	31.4354	33.2589
4	3	3	trimf	linear	1.1222	26.6414
4	2	3	trimf	linear	4.1208	26.3330
4	2	4	trimf	linear	2.6224	15.1354
4	2	5	trimf	linear	0.6655	27.9028
4	2	6	trimf	linear	0.4341	24.9942
4	2	7	trimf	linear	0.2301	9.9696
4	2	8	trimf	linear	0.1711	1.4673
4	2	9	trimf	linear	0.1446	3.3300
4	2	10	trimf	linear	0.1066	4.3350
4	3	5	trimf	linear	0.4875	33.5489
5	2	9	trimf	linear	0.9344	28.4840
6	2	6	trimf	linear	0.3884	5.3789
6	2	7	trimf	linear	0.2916	0.6483
6	2	9	trimf	linear	0.3769	1.2409
6	2	8	trimf	linear	0.3191	1.6253
6	2	8	trimf	constant	2.6207	6.6420
6	1	9	trapmf	linear	0.2919	17.3397
6	1	8	trapmf	linear	0.3053	29.2886
6	2	10	trapmf	linear	0.3372	25.8833
6	1	10	trapmf	linear	0.3227	35.3037
6	2	7	trapmf	linear	0.2979	28.9609
4	2	8	trapmf	linear	1.3554	9.1848
4	2	9	trapmf	linear	1.7933	9.7425
5	2	9	trapmf	linear	0.7037	7.7272
6	2	9	trapmf	linear	0.3312	16.2986
6	2	8	trapmf	linear	0.3586	21.9765
6	2	9	trapmf	constant	2.5433	6.6154
6	2	10	trapmf	linear	0.3372	25.8833
6	1	9	trapmf	linear	0.2919	17.3397
7	2	9	trapmf	linear	0.9907	12.8015
7	2	6	trapmf	linear	0.9933	7.9948

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
8	2	4	trapmf	linear	2.3753	14.0626
6	2	5	gbellmf	linear	1.0299	3.8686
6	2	6	gbellmf	linear	0.9715	2.8247
6	2	7	gbellmf	linear	1.1621	2.71906
6	2	8	gbellmf	linear	1.2213	1.1705
6	2	9	gbellmf	linear	1.1694	3.6856
8	2	4	gbellmf	linear	2.5783	34.9703
8	2	5	gbellmf	linear	2.5464	27.1258
7	2	9	gbellmf	linear	1.4628	18.2631
7	2	8	gbellmf	linear	1.3839	17.4394
6	3	6	gbellmf	linear	1.2723	3.4398
6	3	9	gbellmf	linear	1.2028	4.1864
6	2	9	gaussmf	linear	1.3197	6.7588
6	2	8	gaussmf	linear	1.3213	3.9072
6	3	9	gaussmf	linear	1.2469	8.6953
6	3	8	gaussmf	linear	1.2546	6.4428
7	2	9	gaussmf	linear	2.4677	25.6119
7	2	8	gaussmf	linear	2.4383	24.3000
7	1	8	gaussmf	linear	2.3550	13.6215
6	3	5	gaussmf	linear	1.3256	4.5793
6	3	7	gaussmf	linear	1.2575	3.2691
6	2	7	gaussmf	linear	1.3129	5.2828
6	1	6	gaussmf	linear	1.1036	15.8193
6	2	9	gauss2mf	linear	2.9093	25.2368
6	2	8	gauss2mf	linear	2.9322	30.9770
6	3	9	gauss2mf	linear	2.8328	26.5946
6	3	8	gauss2mf	linear	2.8393	42.1730
7	2	9	gauss2mf	linear	0.5995	14.8985
7	2	8	gauss2mf	linear	0.5648	4.0216
7	2	8	gauss2mf	constant	2.7883	9.9557
7	1	8	gauss2mf	linear	0.4598	6.8765
6	3	5	gauss2mf	linear	2.8150	59.0869
7	3	8	gauss2mf	linear	0.5103	6.4092
8	2	8	gauss2mf	linear	2.2703	21.2468
6	2	9	pimf	linear	0.5448	26.5469

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
6	2	8	pimf	linear	0.8262	25.0181
6	3	9	pimf	linear	0.5448	26.5469
6	3	8	pimf	linear	0.4638	73.0160
7	2	9	pimf	linear	2.3163	20.9433
7	2	8	pimf	linear	2.2431	6.7882
7	1	8	pimf	linear	2.2359	12.6919
6	3	5	pimf	linear	0.2668	162.0233
6	3	7	pimf	linear	0.2742	156.7981
6	2	7	pimf	linear	0.5471	28.9338
7	3	9	pimf	linear	2.2286	21.0747
7	1	9	pimf	linear	2.3251	20.8982
8	1	8	pimf	linear	1.9237	12.5021
8	2	8	pimf	linear	1.6055	13.1636
6	2	8	dsigmf	linear	1.3137	23.1915
6	3	9	dsigmf	linear	1.2235	20.4443
6	3	8	dsigmf	linear	1.2197	31.9018
7	2	9	dsigmf	linear	0.7616	11.5798
7	2	8	dsigmf	linear	0.7996	6.1358
7	1	8	dsigmf	linear	1.0451	24.1429
7	2	6	dsigmf	linear	0.7191	8.5956
6	3	5	dsigmf	linear	1.1963	50.6260
6	2	7	dsigmf	linear	1.1927	28.0226
5	2	4	dsigmf	linear	1.7599	4.6691
5	2	5	dsigmf	linear	2.0543	7.1550
6	2	8	psigmf	linear	1.3137	23.1913
5	2	4	psigmf	linear	1.7599	4.6690
5	2	5	psigmf	linear	2.0543	7.1550
7	2	9	psigmf	linear	0.7616	11.5798
7	2	8	psigmf	linear	0.7996	6.1354
7	1	8	psigmf	linear	1.0451	24.1429
6	3	5	psigmf	linear	1.1963	50.6260
6	3	7	psigmf	linear	1.1937	42.7372
6	2	7	psigmf	linear	1.1957	28.0225
8	2	9	psigmf	linear	2.1477	31.1222
8	2	8	psigmf	linear	2.2008	23.1122

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.5 ผลการลองผิดลองถูกการประเมินความเชื่อถือได้ด้วยกระบวนการเรียนรู้ของ ANN บนระบบไฟฟ้าประเทศไทย

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
tansig	logsig	purelin	3	2	247.1285	11.2808
tansig	logsig	purelin	4	3	68.6599	10.8940
tansig	logsig	purelin	5	4	105.8923	10.7430
tansig	logsig	purelin	6	5	208.6245	21.9876
tansig	logsig	purelin	7	6	26.5476	20.4875
tansig	logsig	purelin	8	7	42.1294	21.0052
tansig	logsig	purelin	9	8	67.0760	30.8307
tansig	logsig	purelin	10	9	72.3878	41.1243
tansig	logsig	purelin	11	10	70.9599	50.4371
tansig	logsig	purelin	12	11	116.5409	51.2220
tansig	logsig	purelin	13	12	82.3163	51.1411
tansig	logsig	purelin	14	13	136.0362	50.5910
tansig	logsig	purelin	15	14	78.1311	51.0737
tansig	logsig	purelin	16	15	31.5027	50.6481
tansig	tansig	purelin	4	3	145.6278	92.2434
tansig	tansig	purelin	5	4	56.4478	90.8847
tansig	tansig	purelin	6	5	86.8420	91.1002
tansig	tansig	purelin	7	6	22.5803	81.1315
tansig	tansig	purelin	8	7	104.7186	82.2335
tansig	tansig	purelin	9	8	37.4860	71.2070
tansig	tansig	purelin	10	9	38.3890	71.5843
tansig	tansig	purelin	11	10	8.5984	70.9089
tansig	tansig	purelin	12	11	31.5385	70.8121
logsig	logsig	purelin	3	2	166.4778	71.8071
logsig	logsig	purelin	4	3	113.5583	60.8878
logsig	logsig	purelin	5	4	36.6817	61.1247
logsig	logsig	purelin	6	5	38.8555	60.9903
logsig	logsig	purelin	7	6	62.8418	60.6939
logsig	logsig	purelin	8	7	116.6945	62.0882
logsig	logsig	purelin	9	8	39.0084	60.7022
logsig	logsig	purelin	10	9	29.7508	60.8091
logsig	logsig	purelin	11	10	24.8142	60.9281

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2	Train	Test
logsig	tansig	purelin	3	2	34.4871	58.9177
logsig	tansig	purelin	4	3	47.1481	58.0058
logsig	tansig	purelin	5	4	25.1309	58.1276
logsig	tansig	purelin	6	5	84.7434	59.3480
logsig	tansig	purelin	7	6	75.8122	59.9522
logsig	tansig	purelin	8	7	71.0788	59.5207
logsig	tansig	purelin	9	8	58.8142	59.5209
logsig	tansig	purelin	10	9	62.4561	59.6761
logsig	tansig	purelin	11	10	32.8243	59.5473
logsig	tansig	purelin	12	11	21.6287	59.9023
logsig	purelin	purelin	6	5	3.6046	59.4939
logsig	purelin	purelin	7	6	29.6452	26.6080
logsig	purelin	purelin	8	7	11.9627	12.3287
logsig	purelin	purelin	9	8	15.1944	10.0468
logsig	purelin	purelin	10	9	25.0309	25.6294
logsig	purelin	purelin	11	10	28.3076	29.2477
logsig	purelin	purelin	12	11	19.3612	12.8448
tansig	purelin	purelin	5	4	19.3624	12.8450
tansig	purelin	purelin	6	5	10.0263	13.8384
tansig	purelin	purelin	7	6	10.1295	17.8599
tansig	purelin	purelin	8	7	10.1753	9.1046
tansig	purelin	purelin	9	8	10.1367	8.3614
tansig	purelin	purelin	10	9	10.1194	14.9435
tansig	purelin	purelin	11	10	10.1114	25.6122
tansig	purelin	purelin	12	11	10.1232	19.2168
tansig	purelin	purelin	13	12	10.1231	19.2160
tansig	purelin	purelin	14	13	10.3220	12.3106
tansig	purelin	purelin	15	14	10.1715	12.3233
purelin	tansig	purelin	6	5	10.2245	7.9294
purelin	tansig	purelin	7	6	10.2884	3.9335
purelin	tansig	purelin	8	7	10.1334	24.5015
purelin	tansig	purelin	9	8	10.1106	37.2993
purelin	tansig	purelin	10	9	10.2195	22.7384
purelin	tansig	purelin	11	10	10.1340	7.0309

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Transfer Function			Number of neurons		%MAPE	
Hidden layer 1	Hidden layer 2	Output layer	Hidden layer 1	Hidden layer 2		
purelin	tansig	purelin	12	11	10.1340	17.0309
purelin	tansig	purelin	13	12	56.8574	11.6470
purelin	tansig	purelin	14	13	19.6116	10.9644
purelin	tansig	purelin	15	14	30.8462	11.5873
purelin	tansig	purelin	16	15	90.3288	13.0554
purelin	tansig	purelin	17	16	54.6024	10.8233
purelin	logsig	purelin	3	2	9.3612	5.8448
purelin	logsig	purelin	4	3	9.3624	5.8450
purelin	logsig	purelin	5	4	6.0263	3.8384
purelin	logsig	purelin	6	5	5.1295	7.8599
purelin	logsig	purelin	7	6	5.1753	9.1046
purelin	logsig	purelin	8	7	5.1367	8.3614
purelin	logsig	purelin	9	8	3.1513	4.1918
purelin	logsig	purelin	10	9	3.1106	7.2993
purelin	logsig	purelin	11	10	3.2195	8.7384
purelin	logsig	purelin	12	11	3.1340	8.0309
purelin	logsig	purelin	13	12	3.1121	9.5530
purelin	logsig	purelin	14	13	3.1586	8.1019
purelin	logsig	logsig	9	8	10.1340	7.0309
purelin	logsig	logsig	10	9	29.6452	26.6080
purelin	logsig	logsig	11	10	11.9627	12.3287
purelin	logsig	logsig	12	11	15.1944	10.0468
purelin	tansig	tansig	3	2	25.0309	25.6294
purelin	tansig	tansig	4	3	28.3076	29.2477
purelin	tansig	tansig	5	4	9.3612	12.8448
purelin	tansig	tansig	6	5	9.3624	12.8450
purelin	tansig	tansig	7	6	9.0263	13.8384
purelin	tansig	tansig	8	7	5.1295	17.8599
purelin	tansig	tansig	9	8	5.1753	9.1046
purelin	tansig	tansig	10	9	5.1367	8.3614
purelin	tansig	tansig	11	10	0.1194	14.9435
purelin	tansig	tansig	12	11	5.1114	25.6122
purelin	tansig	tansig	13	12	5.1232	19.2168
purelin	tansig	tansig	14	13	5.1231	19.2160

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.6 ผลการลองผิดลองถูกการประเมินความเชื่อถือได้ด้วยกระบวนการเรียนรู้ของ ANFIS
บนระบบไฟฟ้าประเทศไทย

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
3	3	3	trimf	constant	363.1478	483.8889
3	3	3	trimf	linear	115.3201	113.1807
4	3	3	trimf	linear	21.3656	109.7984
4	2	3	trimf	linear	36.8464	132.4071
4	2	4	trimf	linear	22.8471	227.7104
4	2	5	trimf	linear	14.4657	205.7907
4	2	6	trimf	linear	35.9787	130.7946
4	2	7	trimf	constant	10.7350	50.0194
4	2	8	trimf	constant	12.2482	38.9449
4	2	9	trimf	constant	11.6253	46.1314
4	2	10	trimf	constant	4.7621	29.6477
4	3	5	trimf	constant	14.1502	32.6924
5	2	9	trimf	constant	3.1717	105.9997
6	2	6	trimf	constant	26.8422	31.7939
6	2	7	trimf	constant	12.2911	51.2879
6	2	9	trimf	constant	4.1610	6.9925
6	2	8	trimf	linear	2.3835	104.8867
6	2	8	trimf	constant	4.9340	6.6510
6	1	9	trapmf	constant	80.3854	9.3847
6	1	8	trapmf	linear	3.6682	6.6717
6	1	7	trapmf	linear	3.9094	6.7366
6	1	10	trapmf	linear	3.6228	9.3244
6	2	7	trapmf	linear	4.2510	8.3317
4	2	8	trapmf	linear	7.4916	9.9555
4	2	9	trapmf	linear	11.2525	11.8494
5	2	9	trapmf	linear	20.8033	6.7496
6	2	9	trapmf	linear	3.6074	7.0052
6	2	8	trapmf	linear	3.3807	9.2404
6	2	9	trapmf	constant	22.2000	15.2928
6	2	10	trapmf	linear	3.5656	9.2976
6	1	9	trapmf	linear	3.4427	7.7093
7	2	9	trapmf	linear	3.9585	16.1606
7	2	6	trapmf	linear	10.4986	99.6290

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
8	2	4	trapmf	linear	2.3807	11.6497
6	2	5	gbellmf	linear	10.8768	115.2211
6	2	6	gbellmf	linear	19.4308	147.6488
6	2	7	gbellmf	linear	9.1705	40.6537
6	2	8	gbellmf	linear	5.7081	30.6882
6	2	9	gbellmf	linear	7.0786	55.6123
8	2	4	gbellmf	linear	8.3469	18.0810
8	2	5	gbellmf	linear	6.3360	37.3828
7	2	9	gbellmf	linear	5.2166	68.5936
7	2	8	gbellmf	linear	3.8480	22.8624
6	3	6	gbellmf	linear	4.9483	26.7770
6	3	9	gbellmf	linear	4.2032	88.9593
6	2	9	gaussmf	linear	7.2157	43.2972
6	2	8	gaussmf	linear	5.0772	34.4127
6	3	9	gaussmf	linear	4.9036	19.2673
6	3	8	gaussmf	linear	5.2890	46.9574
7	2	9	gaussmf	linear	4.6952	33.5293
7	2	8	gaussmf	linear	4.6223	34.8574
7	1	8	gaussmf	linear	5.0969	25.3966
6	3	5	gaussmf	linear	7.0761	120.2927
6	3	7	gaussmf	linear	5.2549	25.9202
6	2	7	gaussmf	linear	4.8017	40.4181
6	1	6	gaussmf	linear	47.5430	174.7961
6	2	9	gauss2mf	linear	5.2574	52.8553
6	2	8	gauss2mf	linear	4.0478	20.0298
6	3	9	gauss2mf	linear	3.9961	16.2645
7	2	9	gauss2mf	constant	5.4635	9.4951
7	2	9	gauss2mf	linear	3.7085	13.8791
7	2	8	gauss2mf	linear	3.7332	22.0805
7	2	8	gauss2mf	constant	6.4277	8.0960
7	1	8	gauss2mf	linear	5.0779	166.0694
6	3	5	gauss2mf	linear	5.5214	54.5948
7	3	8	gauss2mf	linear	3.0926	17.5013
8	2	8	gauss2mf	linear	3.6559	5.7391
8	1	8	gauss2mf	linear	3.6210	5.0331

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Input			Output	%MAPE		
Number of MFs		MFs Type	MFs Type	Train	Test	
6	2	8	pimf	linear	4.2067	9.7717
6	1	9	pimf	linear	4.2510	6.4769
6	3	8	pimf	linear	4.0107	6.4639
6	3	9	pimf	linear	3.9473	7.5863
6	1	8	pimf	linear	5.4212	5.6931
6	3	7	pimf	linear	4.2373	20.3990
7	2	9	pimf	linear	3.4393	25.9168
7	2	8	pimf	linear	3.5276	26.0736
7	1	8	pimf	linear	9.5803	81.2883
6	3	5	pimf	linear	4.0096	35.7680
6	3	7	pimf	linear	4.2373	20.3990
6	2	7	pimf	linear	4.1003	9.9019
7	3	9	pimf	linear	3.1333	24.7484
7	1	9	pimf	linear	4.7470	26.8471
8	1	8	pimf	linear	3.8214	8.2956
8	2	8	pimf	linear	2.2016	9.7056
6	2	8	dsigmf	linear	4.6331	18.2195
6	3	9	dsigmf	linear	3.8514	38.4874
6	3	8	dsigmf	linear	3.9371	25.3121
7	2	9	dsigmf	linear	4.0590	22.2337
7	2	8	dsigmf	linear	4.1116	29.0985
7	1	8	dsigmf	linear	6.5942	206.9235
7	2	6	dsigmf	linear	7.3160	124.2532
6	3	5	dsigmf	linear	4.3317	42.4581
6	2	7	dsigmf	linear	4.7180	24.7270
5	2	4	dsigmf	linear	12.5178	32.7496
5	2	5	dsigmf	linear	5.8744	40.0943
6	2	8	psigmf	linear	4.6331	18.2192
5	2	4	psigmf	linear	12.5184	32.7510
5	2	5	psigmf	linear	5.8747	40.0946
7	2	9	psigmf	linear	4.0590	22.2337
7	2	8	psigmf	linear	4.1116	29.0985
7	1	8	psigmf	linear	6.5942	206.9235
6	3	5	psigmf	linear	4.3317	42.4583
6	3	7	psigmf	linear	3.7401	14.5259

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คำย่อและสัญลักษณ์

คำย่อและสัญลักษณ์	ความหมาย
ANN	Artificial Neural Networks
ANFIS	Adaptive Neuroo-Fuzzy Inference Systems
EENS	Expected Energy Not Supplied
MAPE	Mean Absolute Percentage Error
IEEE RTS	IEEE Reliability Test System
MFs	Membership Functions
FOR	Force Outage Rate
COPT	Capacity Outage Probability Table
NERC	The North American Electric Reliability Corporation
tansig	Tan-sigmoid Transfer Function
logsig	Log-sigmoid Transfer Function
purelin	Linear Transfer Function
trimf	Triangular-shaped membership function
trapmf	Trapezoidal-shaped membership function
gbellmf	Generalized bell-shaped membership function
gaussmf	Gaussian curve membership function
gauss2mf	Gaussian combination membership function
pimf	π -shaped membership function
dsigmf	Difference of two sigmoidal membership function
psigmf	Product of two sigmoidal membership function



ภาคผนวก จ.

เอกสารที่ได้รับการตีพิมพ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารที่ได้รับการตีพิมพ์

1. Evaluation of Wind Energy Production using Weibull Distribution and Artificial Neural Networks

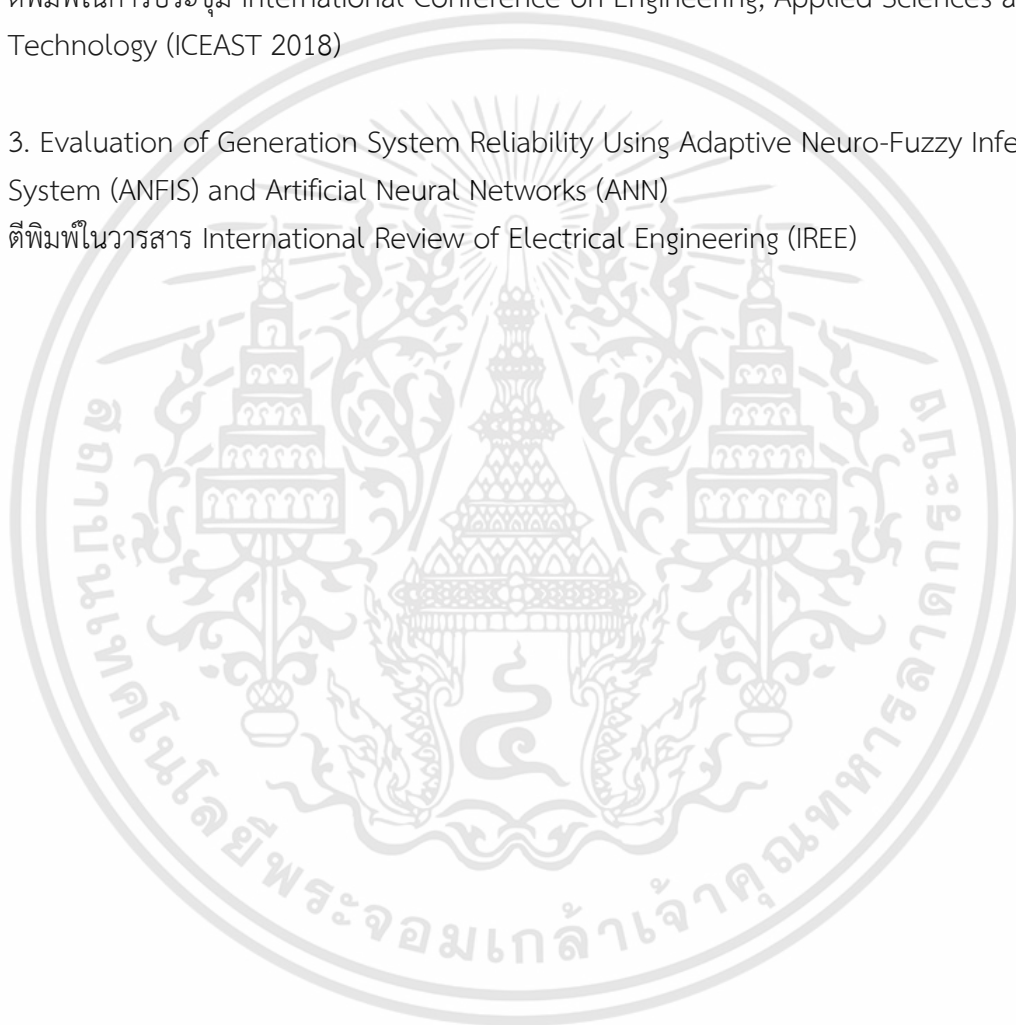
ตีพิมพ์ในการประชุม International Conference on Engineering, Applied Sciences and Technology (ICEAST 2018)

2. Assessment of Wind Power Generation

ตีพิมพ์ในการประชุม International Conference on Engineering, Applied Sciences and Technology (ICEAST 2018)


3. Evaluation of Generation System Reliability Using Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANN)

ตีพิมพ์ในวารสาร International Review of Electrical Engineering (IREE)



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

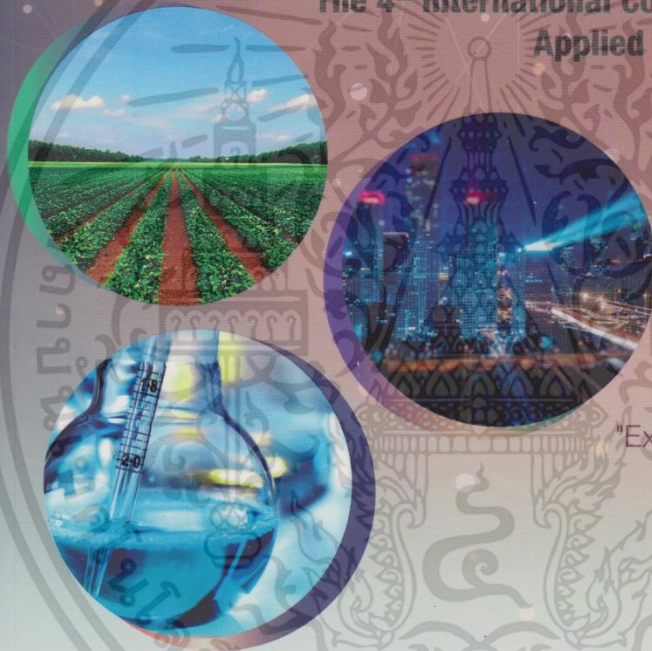
Conference Abstracts



iceast


2018

The 4th International Conference on Engineering,
Applied Sciences and Technology



"Exploring Innovative Solutions
for Smart Society"

Swissôtel Resort Phuket Patong Beach
Phuket, Thailand
July 4-7, 2018
iceast2018@kmitl.ac.th
www.iceast.org



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Evaluation of Wind Energy Production using Weibull Distribution and Artificial Neural Networks

Khanittha Wannakam

Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Ladkrabang, Bangkok, Thailand
Email: bee_m_m@hotmail.com

Somchat Jiriwibhakorn

Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Ladkrabang, Bangkok, Thailand
Email: somchat_j@yahoo.com

Abstract— Wind turbine power generation planning requires prediction estimation. Wind power is uncertain depending on the location, wind speed and wind turbine efficiency. This paper presents a method for evaluating wind energy production using Weibull distribution and Artificial neural networks to compare the data recorded by Promthep Alternative Energy Station, Phuket, Thailand. The results show that wind energy estimation using artificial neural networks produces the most accurate results. Mean Absolute Percentage Error is used to determine the minimum error value. Minimal error of training data is 2.524% and the test data is 3.3041%.

Keywords—Wind energy production; Weibull distribution; Artificial neural networks (ANN)

I. INTRODUCTION

At present, the energy situation is experiencing a shortage of fuel power. Energy from oil and natural gas is the main fuel for the generation of power plants. In the future, these fuels are going to run out and have a very high price [3]. So natural renewable energy is the best choice for solving this shortage of fuel. Renewable energy used in Thailand is wind energy, solar energy, hydro energy, etc. This paper studies renewable energy from wind turbines. Wind Turbine Power is a renewable energy that can be used as a substitute. Wind power is a difficult predictor, depending on the location, wind speed, weather conditions and wind turbine efficiency [5]. Therefore, in order to plan the power generation from wind power, it is necessary to evaluate the power capacity that can be produced to increase the reliability of the power system to suit the electricity demand.

Wind power generation can be evaluated in several ways, such as statistical and probability methods or neural network method. This paper presents two methods of estimation: 1) Probabilistic methods using Weibull distribution [4,10], which is the appropriate method for distributing wind speed data, is likely to be close to the actual value recorded. 2) Artificial neural networks (ANN) [6-7] methods, which is the method used by neurons to learn and try to correct errors to predict the most accurate results. The results of these two methods are compared to the energy data generated by the WTG150kW wind turbine recorded by Promthep Alternative Energy Station, Phuket, Thailand. Since the installation of the wind turbine is the first of the Electricity Generating Authority of Thailand and have all the information recorded to fit the technique used. The

wind turbine data is recorded monthly and is provided for data in this paper. These data is recorded in the form of the total energy of each month. This evaluation will be beneficial to future planning of wind power generation.

II. WEIBULL DISTRIBUTION

Weibull distribution is the basis for random sampling of wind speed.

A. Weibull distribution function

Probability density function or the probability of each wind speed of 1 m/s [4,10], is as follows.

$$f(u) = \frac{k}{A} \left(\frac{u}{A}\right)^{k-1} \exp\left[-\left(\frac{u}{A}\right)^k\right] \quad (1)$$

The cumulative density function is as follows.

$$F(u) = 1 - \exp\left[-\left(\frac{u}{A}\right)^k\right] \quad (2)$$

where, u is average wind speed (m/s), $u > 1$

k is shape parameter, $k > 0$

A is scale parameter, $A > 1$

$$A = \frac{u}{\Gamma(1+1/k)} \quad (3)$$

where, $\Gamma(x)$ = Gamma function = $\int_0^{\infty} e^{-t} t^{x-1} dt$

III. WIND ENERGY PRODUCTION

Calculate the wind speed at time interval by random number and compare the cumulative density function in (2).

All of the wind speed results in an average wind speed similar to the average wind speed recorded by the Electricity Generating Authority of Thailand.

The wind speed is used to determine the wind power comparing with the wind power curve of a WTG150kW wind turbine.




Fig. 1. Example of wind speed randomization.




Fig. 2. Conversion of wind speed into wind power.

Then calculate the total power of the month considered and collect the value.




Fig. 3. The power produced by the WTG150kW.

All data derived from the Weibull distribution are recorded as a monthly sum of wind energy for comparison to the data recorded by Promthep Alternative Energy Station, Phuket, Thailand.

IV. ARTIFICIAL NEURAL NETWORKS

Feed-forward back propagation neural networks consist of a number of neurons in layers, i.e., the input layer, the output layer, and the hidden layer [8-9].

The neurons in the input layer will signal to the neurons in the hidden layer 1. And the neurons in the hidden layer 1 will send signals to the next hidden layer. Until the neurons in the last hidden layer send signals to the neurons in the output layer [2].

In each of the hidden layers, there is a connection between neurons with a weight and a bias that can be adjusted. There are also transfer functions that help in calculating the optimal value.

Artificial neural networks with 2 layers of the hidden layer, as shown in Fig. 4. Hidden layer 1 has inputs p_1, p_2, \dots, p_R and output a_1 . Hidden layer 2 has input a_1 and output a_2 . And output layer has input a_2 and output a_3 . f_1, f_2 and f_3 are transfer function [1].




Fig. 4. The structure of Artificial neural networks (ANN).

$$a_1 = f_1(w_1 * p + b_1) \tag{4}$$

$$a_2 = f_2(w_2 * a_1 + b_2) \tag{5}$$

$$a_3 = f_3(w_3 * a_2 + b_3) \tag{6}$$

- where, w_1 is weight that connects the input and the hidden layer 1.
- w_2 is weight that connects the hidden layer 1 and the hidden layer 2.
- w_3 is weight that connects the hidden layer 2 and the output layer.
- b_1 is bias in the hidden layer 1.
- b_2 is bias in the hidden layer 2.
- b_3 is bias in the output layer.

The Levenberg-Marquardt Algorithm during weight and bias training is adjusted [11-15].

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w) \cdot e \tag{7}$$

$$\Delta b = [J^T(b)J(b) + \mu I]^{-1} J^T(b) \cdot e \tag{8}$$

- where, $J(w)$ is the Jacobian matrix comparing the derivative of the error function with weight.
- $J(b)$ is the Jacobian matrix comparing the derivative of the error function with bias.
- e is the output error between the neural network and the target output.
- μ is a learning parameter.

ANN will train this network with Levenberg-Marquardt Algorithm ('trainlm'). The modified transfer function [2].




Fig. 5. Transfer function.

For calculation of Mean Absolute Percentage Error.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Output_{actual} - Output_{predicted}}{Output_{actual}} \right| \times 100\% \quad (9)$$

V. CASE STUDY

A. Wind energy production assessment using Weibull distribution

Step 1: Compile average monthly wind speed data recorded randomly and calculate the cumulative density function for the average wind speed of the month considered. Considering the intervals of 1 hour, such as the 30-day period, and the average wind velocity of 6.03 m/s, 720 random numbers and an average wind speed of 6.03 m/s were used to calculate the cumulative density function in (2).

Step 2: Calculate the hourly wind speed. By comparing between each random number and the cumulative probability of Weibull distribution at the average wind speed considered, shown in Fig. 1.

Step 3: Randomly convert wind speed to wind power. Compared to the average hourly wind speed and the output power of the WTG 150 kW wind turbine, and calculate the wind energy production value by calculating the total power of the month considered and keep the data. Consider another month, calculate the number of random numbers and monthly average wind speed, shown in Fig. 2, then calculate the steps 1-3.

Step 4: Wind energy production was compared to the value recorded to calculate the error value.




Fig. 6. Comparison of wind energy production between weibull distribution and actual data recorded.

Based on the Weibull distribution, it was found that, when the results were compared with the actual values recorded, the values were likely to be the same and could be used for statistical analysis of wind energy. Some of these ranges are highly erroneous, which can be due to uncertainty of wind speed and wind turbine efficiency. However, this evaluation is acceptable and effective in simulating data. This model is suitable for estimating wind energy statistics. The results of the predictive results comparison with the recorded data are shown in Fig. 6.

B. Wind energy production assessment using Artificial neural networks

Step 1: Set input parameters are wind speed, energy 1 month ago, and energy 2 month ago. And set output parameter is wind energy production. The total amount of data is 46.

Step 2: Set 40 training data and 6 test data. Apply training and test data to normalization.

Step 3: Set number of neurons in hidden layer, epochs and transfer function.

Step 4: Calculate base on ANN. Program the program to calculate it until it reaches the smallest error value by modifying the number of neurons and transfer functions. Keep the MAPE to a minimum.

Step 5: Unnormalize and unscaling output values for real values. Compare the results to the smallest error.

TABLE I. LEARNING DATA FOR ANN

Date	Energy of 1 month ago	Energy of 2 month ago	Average wind speed (m/s)	Wind energy Production (kWh)
*Mar-05	9974	21858	5.22	18804
Apr-05	18804	9974	4.00	28178
May-05	28178	18804	5.24	6546
Jun-05	6546	28178	7.08	26298
⋮	⋮	⋮	⋮	⋮
Nov-08	16020	28368	4.16	6942
Dec-08	6942	16020	5.24	11052

* These data are used in paper ID 640-641 of ICEAST2018.

TABLE II. TEST RESULTS USING ANN

No. of neurons	Transfer function			%MAPE	
	Layer1	Layer2	Layer3	Train	Test
11 10	tansig	tansig	purelin	2.524	3.3041

In ANN tests, the smallest error was 3.3041%. The ANN was feed-forward back propagation neural networks. The neurons in the hidden layer were 11 10, Transfer function was "tansig tansig purelin", set epochs to 100 and Levenberg-Marquardt Algorithm. During the test, ANN was able to train well. When the structure is larger, ANN is well trained and learned. However, in training and testing, until the error value is minimal, if the structure is more complex, but ANN can learn well. Test results are very good and high accuracy. The results of the predictive results comparison with the recorded data are shown in the Fig. 7.




Fig. 7. Comparison of wind energy production between Artificial neural networks and actual data recorded.

C. Comparative study of wind energy production assessment

TABLE III. COMPARATIVE WIND ENERGY PRODUCTION ASSESSMENT

Month	Actual data	Weibull	ANN
Mar-05	18804	16039	18786
Apr-05	28178	6868.4	28192
May-05	6546	16705	6526
Jun-05	26298	30673	26309
Jul-05	34800	33740	34802
Aug-05	31980	25731	32015
...
Oct-08	16020	8472	16013
Nov-08	6942	7772	6934
Dec-08	11052	15468	11045

Comparison of wind energy production assessment found that ANN performed the best performance. ANN can predict the wind energy production as well. The processing is done well, although the structure is more complex. Weibull distribution is a statistical way of probability. Predictions may be very erroneous, but tend to approximate the actual values recorded.




Fig. 8. Comparison of wind energy production

VI. CONCLUSION


Wind energy production requires the collection of data from the operation of wind turbines. There are many methods of mathematical evaluation that are presented, such as statistical methods, probabilities or artificial neural methods. Each has different advantages and disadvantages.

In this paper, we propose two ways to predict Weibull distribution and ANN, which can be predicted for all two values. The most effective way is ANN, for the most accurate results. The selection of learning data, the number of inputs, or the adjustment of weight and bias may make ANN more learnable and less time consuming. For Weibull distribution produces less accurate results, but the trend of results is close to the actual value, which is acceptable. The parameters of the distribution function can be adjusted to provide more accurate data distribution. Both methods are suitable for evaluating wind energy production from wind turbines. This turbine power data can be used to determine the increase in wind power capacity. Considering the reliability of the power generation system and the cost of electricity generation from wind power in the future.

REFERENCES

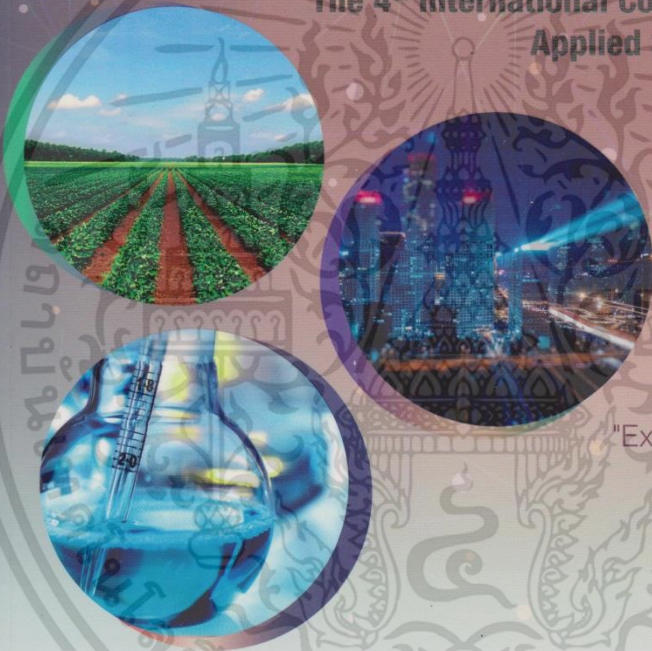
- [1] H. Demuth, M. Hagan, M. Beale, Neural Network Toolbox™ User's Guide (The Math Works, Inc.1992-2017).
- [2] Somchat Jiriwibhakorn, Application of Neural Networks in Power Systems (Electrical Engineering Faculty: KMITL, 2011).
- [3] Power Development Plan: PDP 2015, Ministry of Energy, Received Apr 2017 from www.eppo.go.th/index.php/th/plan-policy/tieb/pdp.
- [4] A. Kadhem, N. Wahab, I. Aris, J. Jasni and A. Abdalla, Advanced Wind Speed Prediction Model Based on a Combination of Weibull Distribution and an Artificial Neural Network, Journal MDPI Energies, Oct.2017, pp.1-17.
- [5] Wind resource assessment of Thailand, Department of energy development and promotion, Received Feb 2018 from http://www2.dede.go.th/renew/Twm/MAIN.htm.
- [6] N. Housas and P. Bertrand, Wind Farm Power Forecasting, Hindawi Publishing Corporation, Jul 2013, pp1-6.
- [7] H. Nogay, T. Akinci and M. El, Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey, Journal of Energy in Southern Africa, vol. 23, no.4, Nov 2012, pp 1-6.
- [8] B. Zhu, M. Chen, N. Wade and L. Ran, A prediction model for wind farm power generation based on fuzzy modeling, ICSE2011, Elsevier, 2012.
- [9] M. Carolin and E. Fernandez, Estimation Energy Yield From Wind Farm Using Artificial Neural Networks, IEEE Transactions on Energy Conversion, vol. 24, no. 2, Jun 2009, pp 459-463.
- [10] Y. Alper, Determination of the best Weibull methods for wind power assessment in the southern region of Turkey, Journal IET Renewable Power Generation, 2016, pp 175-182.
- [11] F. Pelletier, C. Masson and A. Tahan, Wind turbine power curve modeling using artificial neural network, Elsevier renewable energy, 2016, pp 207-214.
- [12] S. Li, D. Wunsch, E. A. and M. G., Using Neural Networks to Estimate Wind Turbine Power Generation, IEEE Transactions on Energy Conversion, vol. 16, no. 3, Sep 2001, pp 276-282.
- [13] Kanna B. and S.N. Singh, AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network, IEEE Transactions on Sustainable Energy, vol. 3, no. 2, Apr 2012, pp 306-315.
- [14] M. Lydia, A. Selvakumar, S. Kumar and G. Kumar, Advanced Algorithms for Wind Turbine Power Curve Modeling, IEEE Transactions on Sustainable Energy, vol. 4, no. 3, Jul 2013, pp 827-835.
- [15] T. G., John B.,M. C., and P. D., Long-Term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models, IEEE Transactions on Energy Conversion, vol. 21, no. 1, Mar 2006, pp 273-284.

Conference Abstracts


iceast 2018

The 4th International Conference on Engineering,
Applied Sciences and Technology



"Exploring Innovative Solutions
for Smart Society"

Swissôtel Resort Phuket Patong Beach
Phuket, Thailand
July 4-7, 2018
iceast2018@kmitl.ac.th
www.iceast.org



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Assessment of Wind Power Generation

Khanittha Wannakam

Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Ladkrabang, Bangkok, Thailand
Email: bee_m_m@hotmail.com

Somchat Jiriwibhakorn

Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Ladkrabang, Bangkok, Thailand
Email: somchat_j@yahoo.com

Abstract— Wind power generation is an unstable source of renewable energy. Electricity depends on the weather at the installation location of the wind turbine. This paper presents the prediction of wind power by using the Weibull distribution and Adaptive Neuro-Fuzzy Inference System. The lowest error rates from the Adaptive Neuro-Fuzzy Inference System were 2.1912% and 4.5678%. This is the error value of the training data and the test data respectively.

Keywords— Wind power generation; Weibull distribution; Adaptive neuro-fuzzy inference system (ANFIS)

I. INTRODUCTION

Natural renewable energy is used as a source of energy for electricity, such as wind, solar and water. Wind is the energy that can be used to generate electricity from wind turbines. Wind power is difficult to predict due to the uncertainty of wind speed in each area, resulting in unstable wind turbines. Unlike other energy such as hydro power, which can determine the flow of water to rotate the propeller, the generator can generate electricity as needed. Therefore, the installation of wind turbines must consider the main factor is the wind speed in the location to be installed.

This paper presents the predictions of wind turbine power generation using the recorded wind speed and power data. A database for predicting electrical energy using Weibull distribution [2,5] and Adaptive Neuro-Fuzzy Inference System (ANFIS) [1]. This prediction is useful for planning power generation and optimizing the use of wind turbine power to meet the demand for electricity.

II. WEIBULL DISTRIBUTION

The wind speed sampling method is a probability method commonly used for Weibull distribution [2,6]. Because the distribution of wind speeds is generally skewed to one side, the distribution is asymmetric and unstable. The cumulative density function is used to determine random values. The cumulative density function is as follows.

$$f(u) = 1 - \exp\left\{-\left(\frac{u}{A}\right)^k\right\} \quad (1)$$

where, u is average wind speed (m/s), $u > 1$
 k is shape parameter, $k > 0$

$$A \text{ is scale parameter, } A > 1, A = \frac{u}{\Gamma(1+1/k)}$$

The wind speed calculation uses random numbers ranging from 0-1 to represent cumulative probability in (1) and then converted the random number to the wind speed as Fig. 1.




Fig. 1. Cumulative density function convert to wind speed.

The wind speed is then converted to the power produced by the power curve of the WTG150kW wind turbine as Fig. 2.




Fig. 2. Wind speed convert to wind power.

Finally, the collected wind power is monthly wind power [1] to compare with the recorded values.




Fig. 3. The wind power produced.

The most popular functions are the Weibull Function and the Rayleigh Function. The Weibull Function consists of two important parameters, the Shape Parameter (k) and the Scale Parameter (A), which can be adjusted to suit the distribution. The Rayleigh Function is a special case of the Weibull function, which defines the constants of the shape parameter

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(k). The result is a comparison between the Weibull and Rayleigh functions. Weibull function will provide more accuracy. Due to the k value of the Weibull function is the appropriate variable of wind in each area.

III. ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM

Adaptive Neuro-Fuzzy Inference System (ANFIS) is an ANN applied to the fuzzy logic system as a hybrid system. The purpose is to bring the advantages of each approach together and eliminate the limitations of each approach. Creating fuzzy rules from inputs and outputs to help make fuzzy diagnostics easier is a boon to fuzzy logic [3-4]. And the advantages of ANN are used to calculate the function of the data group. The system learns from the prototype and then trains the system to know to solve a wider problem and to make the forecast more accurate [7-10].




Fig. 4. The structure of Adaptive neuro-fuzzy inference system (ANFIS).

Layer 1: Premise Parameters Layer

Transforms the input (\$x_i\$) into a fuzzy value by computing the membership function.

$$O_i^1 = \mu_{A_i}(x_1) \quad ; i = 1,2 \quad (2)$$

$$O_i^1 = \mu_{B_i}(x_2) \quad ; i = 3,4 \quad (3)$$

Layer 2: T-norm Operator

Multiply the signals sent from layer 1 using T-norm operator and output to layer 3. The number of nodes in this layer is equal to the number of fuzzy rule requests. And the output signal (\$w\$) is the Firing Strength of each rule.

$$O_i^2 = w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \quad ; i = 1,2 \quad (4)$$

Layer 3: Normalized Firing Strength Layer

Firing Strength is the sum of all rules equal to one. Firing Strength is divided by the sum of Firing Strength from all rules.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad ; i = 1,2 \quad (5)$$

Layer 4: Consequent Parameters Layer

Calculates the result of the fuzzy rule. where, \$\{p_i, q_i, r_i\}\$ is the set of parameters in the consequent rule, which uses the least mean square method.

Layer 5: Overall Output Layer

Combines the signals from every node of layer 4 into the output data (y).

$$O_i^5 = \bar{w} \cdot y = \sum_{i=1}^2 \bar{w}_i y_i = \frac{\sum_{i=1}^2 w_i y_i}{w_1 + w_2} \quad (6)$$

For calculation of Mean Absolute Percentage Error (MAPE).

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Output_{actual} - Output_{predicted}}{Output_{actual}} \right| \times 100\% \quad (7)$$

IV. CASE STUDY

A. Weibull distribution

Step 1: Calculate the cumulative density function in (1) using the monthly average wind speed recorded.

Step 2: Random numbers ranging from 0-1 to represent the cumulative density function. The number of random numbers depends on the number of hours in each month.

Step 3: Bring cumulative probability density derived from random numbers converted to wind speed values.

Step 4: The wind speed is converted into the output power. Using power curve of WTG150kw wind turbine is reference data.

Step 5: Calculate the wind power by calculating the total power of the month considered and keep the data. For another month, calculate the steps 1-3.

Step 6: Wind power generation was compared to the value recorded to calculate the error value.

Weibull distribution is ideal for creating wind speed models for the calculation of wind power. From Equation 1, the scale parameter (A) and the shape parameter (k) are parameters that can be adjusted. In this section, we will study the most appropriate parameters for this actual data to determine the constants for other tests. The scale parameter is relative to shape parameter as described in (1)

In this section, only k values are evaluated and tests are performed to find the most appropriate parameter for the data, taking into account the k value giving the lowest error value compared to the actual wind data recorded. shown in Table I.




Fig. 5. Probability density function of shape parameter (k = 2).

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

TABLE I. COMPARISON OF SHAPE PARAMETER OF WEIBULL DISTRIBUTION

Weibull	Actual data	k=1.8	k=1.9	k=2.0	k=2.1
Jun-05	21858	22654	23898	21505	22314
Feb-05	9974	12255	11772	11600	9977
Mar-05	18804	16076	15831	16039	16680
Apr-05	28178	7756.2	7166.2	6868.4	7477.1
May-05	6546	16642	16624	16705	14130
Jun-05	26298	29202	29095	30673	29674
Jul-05	34800	31123	33259	33740	32018
Aug-05	31980	27439	23524	25731	24542
Sep-05	30090	27209	25907	25287	23964
Oct-05	9036	13956	13578	11027	12437
Nov-05	8952	10971	10258	9324	8965.1
Dec-05	13410	20293	18818	20116	18184
%Error		7.4207	6.1189	5.5405	6.6922

The results from Table I. show that the adjustment of shape parameters (k = 2) produces the lowest error of 5.5405%. It is suitable for simulation of data using Weibull distribution.




Fig. 6. Comparison of wind power generation between weibull distribution and actual data recorded.

Weibull distribution, Adjusting the shape parameter makes the wind speed more accurate. Therefore, the calculation of wind turbine power is more accurate. But since Weibull Distribution is a random distribution of data, resulting in a very large error value, but within acceptable limits. Because they tend to be close to the actual value.

B. Adaptive neuro-fuzzy inference system

Step 1: Set input parameters are wind speed, energy 1 month ago, and energy 2 month ago. And set output parameter is wind power generation. The total amount of data is 46.

Step 2: Set 40 training data and 6 test data. Apply training and test data to normalization. The value of the data is based on the normal distribution. The mean is 0 ($\mu=0$) and the variance is 1 ($\sigma=1$). This method is used to increase the accuracy of ANFIS output data and to reduce the learning time of ANFIS.

Step 3: Import training data and test data to the ANFIS toolbox "anfisedit".

Step 4: Set the number and the type of Membership function. MFs have multiple functions. (trimf, trapmf, gbellmf, gaussmf, ...). Modify values of MFs to make the results with the least error value. And set the number of epochs.

Step 5: Start training and testing. Consider the error value and try to get the wrong value until the least error value.

Step 6: Unnormalize and unscaling output values for real values. Compare the results to the smallest error.




Fig. 7. Results of training using ANFIS.




Fig. 8. Results of testing using ANFIS.




Fig. 9. System structure of ANFIS (MFs 8 2 4).

TABLE II. LEARNING DATA FOR ANFIS

Date	Energy of 1 month ago	Energy of 2 month ago	Average wind speed (m/s)	Wind energy Production (kWh)
*Mar-05	9974	21858	5.22	18804
Apr-05	18804	9974	4.00	28178
May-05	28178	18804	5.24	6546
Jun-05	6546	28178	7.08	26298
⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮
Nov-08	16020	28368	4.16	6942
Dec-08	6942	16020	5.24	11052

* These data are used in paper ID 640-641 of ICEAST2018.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

TABLE III. TEST RESULTS USING ANFIS

No. of MFs	MFs Type	%MAPE	
		Train	Test
8 2 4	dsigmf linear	2.1912	4.5678

ANFIS, the smallest error was 4.5678%. The membership function is "dsigmf, linear" and is structured as "8 2 4". Set epochs to 100 and use hybrid method. During testing, ANFIS was able to train well. But when the structure is larger, ANFIS is slower. Because the structure is more complex, fuzzy rule processing takes longer. Test results are acceptable and high accuracy. The results of the predictive results comparison with the recorded data are shown in the Fig. 10.




Fig. 10. Comparison of wind power generation between Adaptive neuro-fuzzy inference system and actual data recorded.

C. Comparative study of wind power generation assessment

TABLE IV. COMPARATIVE WIND POWER GENERATION ASSESSMENT

Month	Actual data	Weibull	ANFIS
Mar-05	18804	16039	18803
Apr-05	28178	6868.4	28177
May-05	6546	16705	6546
Jun-05	26298	30673	26297
...
Oct-08	16020	8472	4906
Nov-08	6942	7772	5268
Dec-08	11052	15468	11122



Fig. 11. Comparison of wind power generation.

Comparison of wind power generation assessment found that ANFIS performed the best performance. ANFIS can predict wind energy production well. But when the structure is more complex, it takes more processing time. Weibull


distribution is probability method. Predictions may be very erroneous, but tend to approximate the actual values recorded.

V. CONCLUSION

Predicting the electric power produced by wind turbines is very useful for planning the electricity generation. Weibull distribution is a distribution of statistical data and probabilities using random numbers. The error value is very high. However, Weibull The distribution is also acceptable. The overall average of wind energy tends to be close to the actual value. If the researcher wants to predict the data hourly, daily or monthly, this method will be able to display the values as needed, so it can be used in many analyzes. For ANFIS, it is an artificial neural prediction that can learn from the significant data for wind turbine power generation, and predicts the most accurate and least error values, but when the structure of the data distribution is larger, ANFIS performance is slower, sometimes the program stops working, which limits the program to improve. In order to use it, it is necessary to determine the most significant inputs to the output data to reduce the size of the structure. Both of these techniques can be used to evaluate the power produced by wind turbines to determine the capacity of wind turbine installations, based on the reliability of the generating system and the cost of electricity to support further investment.

REFERENCES

- [1] J.P.S., H.M.I. and V.M.F., Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal, IEEE Transactions on Sustainable Energy, vol. 2, no. 1, Jun 2011, pp 50-59.
- [2] Y. Alper, Determination of the best Weibull methods for wind power assessment in the southern region of Turkey, Journal IET Renewable Power Generation, 2016, pp 175-182.
- [3] B. Zhu, M. Chen, N. Wade and L. Ran, A prediction model for wind farm power generation based on fuzzy modeling, ICSE2011, Elsevier, 2012.
- [4] Yi Yang, Yanhua Chen, Yachen Wang, Caihong Li and Lian Li. "Modeling a combined method based on ANFIS and neural network improved by DE Algorithm: A case study for short-term electricity demand forecasting", Elsevier Science Limited, 2016, pp. 663-675.
- [5] A. Kadhem, N. Wahab, I. Aris, J. Jasni and A. Abdalla, Advanced Wind Speed Prediction Model Based on a Combination of Weibull Distribution and an Artificial Neural Network, Journal MDPI Energies, Oct 2017, pp.1-17.
- [6] Meik S., Ilmar F. and Sofiane A., Using Data-Mining Approaches for Wind Turbine Power Curve Monitoring: A Comparative Study, IEEE Transactions on Sustainable Energy, vol. 4, no. 3, Jul 2013, pp 671-679
- [7] J.P.S., H.M.I. and V.M.F., Hybrid intelligent approach for short-term wind power forecasting in Portugal, Journal IET Renewable Power Generation, 2010, pp 251-257.
- [8] G.N., G.S. and E.F., Wind Power Forecasting Using Advanced Neural Networks Models, IEEE Transactions on Energy Conversion, vol. 11, no. 4, Dec 1996, pp 762-767.
- [9] Fuzzy logic Toolbox™. Adaptive neuro-fuzzy modeling. The Math Works, Received Feb 2017 from <https://www.mathworks.com/help/fuzzy/adaptive-neuro-fuzzy-inference-systems.html>.
- [10] Jyh Shing, Roger Jang, ANFIS: Adaptive Network based Fuzzy Inference System, IEEE Transaction on power Systems, vol. 23, n.3, May/June 1993, pp. 665-685.
- [11] Power Development Plan: PDP 2015, Ministry of Energy, Received Apr 2017 from www.eppo.go.th/index.php/th/plan-policy/tieb/pdp.



Praise Worthy Prize

**International Review of
Electrical Engineering
(IREE)**

HOME
PRAISE WORTHY PRIZE
ABOUT
USER HOME
PWP ONLINE LIBRARY
CURRENT
ARCHIVES
ANNOUNCEMENTS
OTHER JOURNALS
DOWNLOAD ISSUES
SUBMIT YOUR PAPER
SPECIAL ISSUE

Home > Archives > Vol 13, No 3 (2018)

Vol 13, No 3 (2018)

Open Access
 Subscription or Fee Access

Full Issue

View or download the full issue

[VOL 13 N 3](#)

Table of Contents

Articles

Hard Real Time Software Design for Three Phase SPWM Generation Systems by Using Fixed Point Arithmetic Computation in Low Cost 16 Bit DSC dsPIC30F4011	PDF 172-177
<i>Iwan Setiawan, Syaqi Muttaqin, Mochammad Facta, Hermawan Hermawan, Trias Andromeda</i>	
Prototpye of Implementation SVPWM Inverter in RTI with V/F Control Based Reluctance Machines Application	PDF 178-184
<i>Mohammed Saadi Hasan, Ghassan Abdullah Salman, Husham Idan Hussein</i>	
Profitable Multi-Use of Battery Energy Storage in Outage Mitigation and as Frequency Reserve	PDF 185-194
<i>Olli Vilppo, Antti Rautiainen, Jenni Rekola, Joni Markkula, Kai Vuorilehto, Pertti Järventausta</i>	
Fractal Geometry for Modelling the Dynamic Behavior of Power Networks with Respect to the Distributed Nature of Transmission Lines	PDF 195-203
<i>Siham Lekrih, Jaouad Oloum</i>	
Evaluation of Generation System Reliability Using Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANNs)	PDF 204-212
<i>Khanittha Wannakam, Somchat Jirivibhakorn</i>	
New Mathematical Model Based on OFDM Technique for Smart Lighting Systems in Smart City	PDF 213-228
<i>Mehdi Laraki, Aqwatif Hayar</i>	
The Energy Sustainability of the Small Agricultural Farms Isolated of Electric Power Grid	PDF 229-236
<i>Irena Rozić, Besim Imamović, Jerko Pavličević, Andrej Ferdo Gubina, Suad Smail Halilčević</i>	
Network Topological Notions for Power Systems Security Assessment	PDF 237-245
<i>Ricardo Moreno-Chuquen, Johan Obando-Ceron</i>	
Design of Zero Energy Consumption System for Small DC Residential Home Based on Off-Grid PV System	PDF 246-258
<i>Nidchabendha Chandanachulaka, Werachet Khan-ngern</i>	

Please send any question about this web site to info@praiseworthyprize.com
Copyright © 2005-2018 Praise Worthy Prize

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Evaluation of Generation System Reliability Using Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANNs)

Khanitha Wannakam, Somchat Jiriwibhakorn

Abstract – This paper presents an evaluation of the reliability index of power generation systems using the Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANNs) to compare the results obtained from the basic method of probability. The reliability index used in this study is the Expected Energy Not Supplied (EENS) index, which is used in planning to increase the installed capacity for the adequate demand for electricity. The ANFIS and ANNs techniques will learn the relationship between the priority level, the installed capacity and the force outage rate (FOR) of the generator, which significantly affect the EENS index. The results indicated that the ANNs techniques have the best predictive performance. The best accuracy of the training data was 1.2488% and the testing data was 2.3963%, calculated using a Mean Absolute Percentage Error (MAPE). Furthermore, the ANNs took more time to learn faster than the ANFIS. Copyright © 2018 Praise Worthy Prize S.r.l. - All rights reserved.

Keywords: Adaptive Neuro-Fuzzy Inference System (ANFIS), Artificial Neural Networks (ANNs), Expected Energy Not Supplied (EENS), Generation System, Reliability

I. Introduction

Currently, the development of industrial equipment or facilities requires electrical energy power sources. An electricity supply is therefore a basic part of an infrastructure and it is important to national development. Continued population growth and ongoing economic growth have increased the annually demands for electricity. Thus, electricity is very important in daily living and is fundamental in driving the economy. If there were insufficient power to supply the demand, this would have a severe effect on the Thai economy. To ensure the capacity of power plants used in production to be large enough to generate a sufficient amount of electricity, it is necessary to plan for reliable electrical systems in accordance with the specified criteria, then they should meet the increasing demand for electricity each year [1]-[27].

The reliability index used for evaluation is the Expected Energy Not Supplied (EENS), which is an index used for decision-making to increase the installed capacity of generators in response to the demand for electricity. In calculation by the probabilistic method, to find the Reliability Index, the Reliability Test System is used to compute the database [1]. The calculation is based on the probability principle of the reliability index calculation. For the ANFIS and ANNs applications [7], [13] the program calculates the correlation of the input and output variables by using a trial and an error method, which allows accurate and fast evaluation of the reliability index.

This was used to make decisions about increasing the installed capacity to respond to the demand for electricity.

Accurate and reliable evaluation are critical to the adequacy of electrical power, as they can determine the timing of future investments and operations in electricity generation. If the evaluation fails, this could affect the reliability and adequacy of the system. This may result in insufficient power to meet the needs of the consumer or in insufficient investment in building power plants.

II. Generation Systems

Most power generation planning is considered only for a single power system, which is used to study the adequacy of the power demand of the system and to determine its reliability. This is due to the failure status of the generator, which may result in the total system capacity being insufficient for the load requirements. In modeling, the specifics of the generator and the model of the demand for electricity [1] were considered.

Generally, the operation of the electrical equipment, such as, generators, is characterized by a period of time between the available and unavailable states.




Fig. 1. Conventional system model

The status of the work is not always due to failure or damage of the equipment, but after repairs have been completed, the operation can continue. The researchers can show the model of the generator using the two-state Markov model [1].




Fig. 2. Two-state Markov model for generating system

The basic generating unit parameter used in the capacity evaluation is the probability of finding the unit on a forced outage of time. This probability is defined in power systems as the unit unavailability. The unit force outage rate (FOR) is the ratio of the time value [1]:

$$Unavailability(FOR) = \frac{\lambda}{\lambda + \mu} = \frac{MTTR}{MTTF + MTTR} \quad (1)$$

$$Availability = \frac{\mu}{\mu + \lambda} = \frac{MTTF}{MTTF + MTTR} \quad (2)$$

Considering the model of the electrical equipment in the system to be a long-term agent, the Mean time to failure is "Up" and the Mean time to repair is "Down". For this reason, the behavior of the device is periodic.




Fig. 3. Status of equipment in the electrical system

Regarding the long-term capacity planning, it is important to know the estimated amount of the electricity demand and expected peak power. In this case, the researchers used the load duration curve, which changed from an hourly load curve.




Fig. 4. Cumulative load duration curve (CLDC)

The generation and load models were combined to set up the appropriate risk model [1].




Fig. 5. Generating capacity reliability evaluation

III. Reliability Index

Expected Energy Not Supplied (EENS) is an index that indicates the expected energy value of an uninterruptible power supply because the load is greater than the available capacity. The index represents the amount of unrepresented power generated by an inadequate capacity [1]:

$$EENS_0 = t \times \sum_{i=1}^N L_i \quad (3)$$

$$EENS_q = \sum_{i=1}^N p_k E_k \quad (4)$$




Fig. 6. EENS index calculation

IV. Adaptive Neuro-Fuzzy Inference System (ANFIS)

The Adaptive Neuro-Fuzzy Inference System uses a hybrid learning algorithm from a two-way learning cycle. In the forward pass, parameters are adjusted using the Least Squares Estimate method while the Backward Pass uses the gradient method, the Gradient Descent for adjusting the parameters of a set [2], [21], [28].

IV.1. The Structure of Adaptive Neuro-Fuzzy Inference System (ANFIS)

Layer I would transform input (x) into fuzzy values by calculating the value of the functions $\mu_A(x_1)$ and $\mu_B(x_2)$, which may be an inverted bell function or another derivative function, such as, a triangular function. Trapezoid functions and the nodes in this layer would be rectangular, which would indicate that the

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

parameters could be adjusted. The parameters in this node would refer to the parameters of the membership function called Premise Parameters.




Fig. 7. The structure of Adaptive Neuro-Fuzzy Inference System [13]

Layer 2 would be responsible for multiplying the signals sent from the first layer together using the T-norm Operator and exporting them to the third layer. The number of nodes in this layer would be equal to the number of fuzzy rules and signals. Export (w) would be the Firing Strength of each rule. The nodes in this class would be in a circular form, which would indicate that the parameters could not be adjusted.



Layer 3 would adjust the Firing Strength to one rule by dividing Firing Strength by Firing Strength. From all rules, the result is called Normalized Firing Strength (\bar{w}). In this class, a circle would indicate that the parameter could not be adjusted.

Layer 4 would be useful to calculate the result of the fuzzy rule. The nodes in this layer would be rectangular, indicating that the parameters of this node could be adjusted. These parameters are called Consequent Parameters.

Layer 5 would serve as the aggregate of the signals from all four nodes together. Regarding the outgoing data (y), the nodes in this class would be in a circular form, which would indicate that the parameters could not be adjusted.

IV.2. Membership Function

Selecting a member's function to choose the appropriate data coverage to be received [2] by being able to be overlapped for a smooth operation would have many member values, so the membership function would be changed to suit the purpose:



V. Artificial Neural Networks (ANNs)

The neural network is a mathematical model that simulates the human brain in learning and memorizing by connecting, processing, and analyzing information. The result, called knowledge, is the outcome of the learning process.

In general, neurons of the ANNs are simulated. When input data are sent, they could be multiplied by the weight, which would represent the importance of each input. The sum of the weighted values resulting from the input data multiplications and the weight values would be analyzed by the transfer function as a result of the output data.




Fig. 8. Neuron network model [7]

Various researchers have proposed a variety of ANNs structures or architecture for use in a variety of applications; such as, feed forward, feedback, or recurrent, and competitive models. In order for the network to learn and show the desired behavior, learning would be divided into two types: Supervised Learning and Unsupervised Learning. In this article, the researchers focused on Supervised Learning, as it is used up to 80% of the time.

Supervised neural network modeling is the process of learning. It requires input and output data to be used to learn and memorize relationships [12].

V.1. Multi-Layer Feed Forward Neural Networks

1 input neuron model (Fig. 9).




Fig. 9. Neuron with no bias and bias [7]

Multi-input neuron model (Fig. 10).

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Fig. 10. Single neuron with R inputs [7]


Each layer is connected by weight (w) and bias (b). a_1 , a_2 and a_3 are the outputs of the hidden layers 1 and 2 and the output layers. f_1 , f_2 and f_3 are the transfer functions of the hidden layers 1 and 2 and the output layer [22]-[23].

The error $e(i)$ when $i = 1, 2, 3, \dots, s_3$ at the output layer is the difference in the output of $a_3(i)$ of the neural network and the value of $t(i)$:

$$e(i) = t(i) - a_3(i); \quad i = 1, 2, 3, s_3 \quad (5)$$

V.2. Transfer Function [7]

Typical transfer functions are illustrated below:



V.3. The structure of Artificial Neural Networks (ANNs)

When taking multiple neurons in parallel, they are made up of layers, and if each layer is serialized, it is a multilayer. When layered together, these are called multilayer feed-forward neural networks. The most popular structure is the multilayer neural network. This is a forward-feeding structure consisting of three layers: the input layer, the hidden layer, and the output layer. The hidden layer may have more than one layer [3]-[6].

Each layer consists of one or more nodes, and data are sent from the input side to the output side without being returned.

The nodes in the same layer are not connected. As shown in Fig. 11, the researchers used the backpropagation technique [14]-[18], which is a way to adjust weight values connected between the nodes, based on the difference between the actual and desired results.




Fig. 11. The structure of Artificial Neural Networks [12]

The neural network consists of an input layer, a hidden layer (layer 1 and 2) and an output layer (layer 3).

V.4. Algorithm

Therefore, in learning, the training data and algorithm would need to be adjusted for two important parameters in the learning process: weight and bias. Furthermore, multilayer feed-forward neural networks would use the backpropagation algorithm [8]-[10].

The principle of backpropagation would be to adjust the weight and bias according to Equations (6)-(7), so that the error sum of squares (SSE) of Equation (8) would approach zero [12]:

$$w_{new} = w_{old} + \Delta w \quad (6)$$

$$b_{new} = b_{old} + \Delta b \quad (7)$$

$$SSE = \sum_{i=1}^N (t_i - a_i)^2 \quad (8)$$

The Levenberg-Marquardt algorithm (LMA) during the weight and bias training was adjusted by Equations (9)-(10):

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w) \cdot e \quad (9)$$

$$\Delta b = [J^T(b)J(b) + \mu I]^{-1} J^T(b) \cdot e \quad (10)$$

During learning, μ would be multiplied by a constant; such as, 10 if the new SSE increased and divided by 10 if the new SSE decreased.

If the norm of $J^T(w) \cdot e$ or $J^T(b) \cdot e$ was less than the minimum value set, or was greater than the maximum value set, the program would stop the training immediately:

$$J(w) = \begin{bmatrix} \frac{\partial e(1)}{\partial w_3(1,1)} & \frac{\partial e(1)}{\partial w_3(1,2)} & \dots & \frac{\partial e(1)}{\partial w_3(1,s_2)} \\ \frac{\partial e(2)}{\partial w_3(2,1)} & \frac{\partial e(2)}{\partial w_3(2,2)} & \dots & \frac{\partial e(2)}{\partial w_3(2,s_2)} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e(s_3)}{\partial w_3(s_3,1)} & \frac{\partial e(s_3)}{\partial w_3(s_3,2)} & \dots & \frac{\partial e(s_3)}{\partial w_3(s_3,s_2)} \end{bmatrix} \quad (11)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$J(b) = \begin{bmatrix} \frac{\partial e(1)}{\partial b3(1)} \\ \frac{\partial e(2)}{\partial b3(2)} \\ \vdots \\ \frac{\partial e(s3)}{\partial b3(s3)} \end{bmatrix} \quad (12)$$

$$bw = b - aw \cdot mx \quad (18)$$

$$Scaling = aw \cdot Z_i + bw \quad ; i = 1, 2, \dots, n \quad (19)$$

V.5. Normalization Method

The methodology was used to increase the accuracy of the ANNs output data and to reduce the learning time of the ANNs. The normalization input and output data sets must be made prior to the ANNs learning process, so that the value of the data would be based on the normal distribution. The mean is zero ($\mu=0$) and the variance is one ($\sigma=1$).

If each input or output side contains "n", the data set would be (X_1, X_2, \dots, X_n). Thus, the normalization data sets could be obtained using Equations (13)-(16), respectively [12]:

$$\text{If } X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \text{ then } \mu_x = \frac{\sum_{i=1}^n X_i}{n} \quad (13)$$

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} X_1 - \mu_x \\ X_2 - \mu_x \\ \vdots \\ X_n - \mu_x \end{bmatrix} ; \mu_y = 0 \quad (14)$$

$$\sigma_y = \sqrt{\frac{\sum_{i=1}^n (Y_i)^2}{n}} \quad (15)$$

$$Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix} = Y \cdot \frac{1}{\sigma_y} = \begin{bmatrix} (X_1 - \mu_x) / \sigma_y \\ (X_2 - \mu_x) / \sigma_y \\ \vdots \\ (X_n - \mu_x) / \sigma_y \end{bmatrix} ; \sigma_z = 1 ; \mu_z = 0 \quad (16)$$

These should then be scaled or bundled into the transfer function using Equations (17)-(19) to enhance the efficiency of the ANNs after the learning process created the a linear distribution model with values between [0.1,0.9] for "n" and there would be a value between [-0.9,0.9] for the "n" set of the output data to be used for learning:

$$aw = \frac{b-a}{mx-mn} \quad (17)$$

V.6. Unnormalization Method

If the O matrix represents the normalization and scaling of the data set on the output side of each learning curve, then each ANNs output field could be realized by unscaling and unnormalization using Equations (20)-(21), respectively [12].

The Q matrix represents the "n" data set of each ANNs derived data set that would be compared against each target data set. After the learning is completed, the weight and bias values would be stored:

$$[L] = \begin{bmatrix} O_1 / aw - bw / aw \\ O_2 / aw - bw / aw \\ \vdots \\ O_n / aw - bw / aw \end{bmatrix} \quad (20)$$

$$[Q] = \begin{bmatrix} L_1 \cdot \sigma_y + \mu_x \\ L_2 \cdot \sigma_y + \mu_x \\ \vdots \\ L_n \cdot \sigma_y + \mu_x \end{bmatrix} \quad (21)$$

VI. Test

VI.1. Test procedures using Adaptive Neuro-Fuzzy Inference System (ANFIS) [13]

Step 1: Bring the input and output data to normalization from Equations (13)-(19).

Define 3 input variables:

- 1) Priority level of the generator.
- 2) Installed capacity of the generator.
- 3) FOR of the generator.

Define output 1 variable:

- 1) EENS index of the generator.

Step 2: Select data as training data and testing data.

The priority level, installed capacity and FOR are input values and the EENS index is the output value.

Step 3: Put the prepared data set into the M-file in the MATLAB. The train matrix is the training data and the test matrix is the testing data. Then click on the Run & Save button. The data set is saved to the workspace in the MATLAB and it is prepared for the run.

Step 4: Use the "anfisedit" in the command window to run the ANFIS.

Step 5: In the Load data field, select the workspace, then choose Load Data and type "train" into the input variable name field to bring the Train data into the ANFIS.

Step 6: Select Load Data and type "test" into the input variable name field to bring the testing data into the ANFIS.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Khanitha Wannakam, Somchat Jirivibhakorn




Fig. 12. Graph of training and testing input data

Step 7: Select the Generate FIS box. Enter the number of MFs and choose the type of MFs.

Step 8: Select the Train FIS box, enter the Epochs, then select Train Now to get the error value of the training.

Step 9: Select Testing data and select Test Now to get the error value of the test. Then try to correct it until obtaining the acceptable error value.




Fig. 13. Results of training & testing using ANFIS

Step 10: When the acceptable error value is exported, export the file to the ANFIS learning process for the forecasting value by Export to the workspace.

Step 11: Find the answer using "evalfis" on the command window. The program displays the output data.

Step 12: Unnormalize and unscaling the output values for real values are derived using Equations (20)-(21).

VI.2. Test procedures using Artificial Neural Networks (ANNs) [7]

Step 1: Provide training and testing data.

- Define 3 input variables:

 - 1) Priority level of the generator.
 - 2) Installed capacity of the generator.
 - 3) FOR of the generator.

Define output 1 variable:

- 1) EENS index of the generator.




Fig. 14. System structure of ANFIS (MFs 6 3 2)

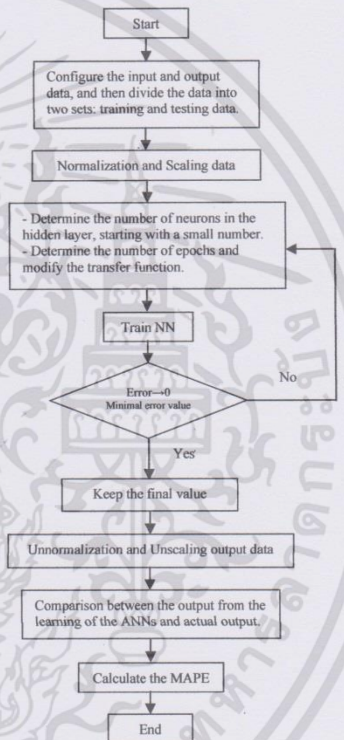


Fig. 15. Chart of Artificial neural networks (ANNs)

Step 2: Bring the training and testing data to normalization from Equations (13)-(19).

Step 3: Determine the number of neurons in the hidden layer, set the number of epochs (set to 100-500, but more configurable if the data is very complex) and modify the transfer function.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Step 4: Calculate by allowing the ANNs learn from the training data and use the test data in the ANNs learning test.

Step 5: The output obtained from the ANNs is compared to the actual output in the form of error values.

Step 6: Let the ANNs learn until they receive the smallest error value.

Step 7: Unnormalize and unscaling using Equations (20)-(21) to find the optimal result. Perform the procedure shown in Fig. 16.




Fig. 16. Results & error of the ANNs training program

VII. Performance Measurement of ANFIS and ANNs

The measurement of the accuracy of the ANFIS and ANNs used the Mean Absolute Percentage Error (MAPE) from the ANFIS and ANNs programs, which were compared with the reference output as follows [12]:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Output_{actual} - Output_{predicted}}{Output_{actual}} \right| \times 100\% \quad (22)$$

VIII. Results

In Case 1, 32 units of the IEEE Reliability Test System (RTS) were used in the testing in which the installed capacity was 3405 MW and the peak load was 2850 MW [11]. All the learning was done on the MATLAB program using the ANFIS / ANNs Toolbox to find the minimum error value. Case 1 compared the results between the ANFIS and the ANNs using the same set of data. For the RTS systems, there were 32 data sets: 27 training data and five testing data. The input data were the priority level of the generator, installed capacity, and FOR. The output data were the EENS.

Case 1: Learning using the ANFIS technique on the RTS system: When defining a system structure as 7 2 5 using a linear membership function of the type "trimf", the ANFIS learning had the least error value. The MAPE of the training error was 2.2344% and the testing error was 3.9895%, as shown in Table I. For learning using the ANNs technique on the RTS system, when determining the number of neurons to 13 12 and the transfer function of the hidden layer 1, 2 and 3 was "tansig", "purelin" and "purelin", respectively, it was found that the learning of the ANNs would be the smallest error. The MAPE of the training error was 1.2488% and the testing error was 2.3963%, as shown in Table II. When comparing the values between the ANFIS and ANNs, the ANNs showed results closer to the real values than the ANFIS, as displayed in Fig. 17.

TABLE I
TEST RESULTS USING THE ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM IN THE RTS SYSTEMS

No. of MFs	MFs Type	%MAPE	
		Train	Test
7 2 5	trimf linear	2.2344	3.9895

TABLE II
TEST RESULTS USING THE ARTIFICIAL NEURAL NETWORKS IN THE RTS SYSTEMS

No. of neurons	Transfer function			%MAPE	
	Layer1	Layer2	Layer3	Train	Test
13 12	tansig	purelin	purelin	1.2488	2.3963




Fig. 17. Comparison of the results between the ANFIS and ANNs in Case 1

In Case 2 using Thai thermal power plant systems, 85 units based on PDP 2015 were used in testing in which the installed capacity was 37,612 MW and the peak load was 30,218 MW [19]. All learning was done on the MATLAB program using the ANFIS / ANNs Toolbox to find the minimum error value. Case 2 compared the results between the ANFIS and ANNs using the same set of data. For Thai thermal power plant systems, there were 85 data sets: 70 new training data and 15 new testing data. The input data were the priority level of generator, installed capacity, and FOR. The output data were the EENS.

Case 2: Learning using the ANFIS technique on the RTS system: When defining a system structure as 6 3 6

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

using a linear membership function of the type "gbellmf", ANFIS learning had the least error value. The MAPE of the training error was 2.1225% and the testing error was 4.0133%, as shown in Table III. For learning using the ANNs technique on the RTS system, when determining the number of neurons to 11 10 and the transfer function of the hidden layer 1, 2 and 3 was "tansig", "logsig" and "purelin", respectively, it was found that the learning of the ANNs would be the smallest error. The MAPE of the training error was 2.4739% and the testing Error was 3.5219%, as shown in Table IV. When comparing the values between the ANFIS and ANNs, the ANNs showed results closer to the real values than the ANFIS, as displayed in Fig. 18.

TABLE III
TEST RESULTS USING THE ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM IN THE THAI THERMAL POWER PLANT SYSTEMS

No. of MFs	MFs Type	%MAPE	
		Train	Test
6 3 6	gbellmf linear	2.1225	4.0133

TABLE IV
TEST RESULTS USING THE ARTIFICIAL NEURAL NETWORKS IN THE THAI THERMAL POWER PLANT SYSTEMS

No. of neurons	Transfer function			%MAPE	
	Layer1	Layer2	Layer3	Train	Test
11 10	tansig	logsig	purelin	2.4739	3.5219




Fig. 18. Comparison of the results between the ANFIS and ANNs in Case 2

IX. Conclusion

The reliability evaluation of power generation using the Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANNs) was based on a comparison of the accuracy of the learning of each technique. The test found out that the average error was good and acceptable. However, the ANFIS would take more time to learn than the ANNs. Because of the more variable input and membership functions that would make the structure be more complex, the ANFIS would run slower or stop working, which was a limitation of the ANFIS that could not be solved. The ANNs technique was therefore found to be the most appropriate technique to use in evaluating the reliability of various test systems, as it took time to learn quickly and produced results that

were closer to the actual values that were the most accurate. The ANNs could also be improved by adding the number of hidden layers to make learning more effective.

As such, the preparation of the training and test data must be simulated from the program, which would take a long time, so it should be prepared faster. The test data must be different from the training data and must never be used for learning. The input variables used must be significant for the output variables because if they are too large, they will consume more time and memory and would not improve the performance. The preparation of the training data must be distributed consistently and sufficiently in quantity, so that they are of good quality, resulting in better performance and less time. Thus, these techniques could be used to plan long-term capacity expansion.

References

- [1] Billinton R., Allan R.N., *Reliability Evaluation of power Systems* (London: Pitman Advance Publishing, 1984, 6-68).
- [2] Jyh Shing, Roger Jang, ANFIS: Adaptive Network based Fuzzy Inference System, *IEEE Transaction on power Systems*, vol. 23, n.3, May/June 1993, pp. 665-685.
- [3] Nima Amjadi, Mehdi Ehsan, Evaluation of Power Systems Reliability by an Artificial Neural Network, *IEEE Transaction on Power Systems*, vol. 14, n. 1, Feb 1999, pp. 287-292.
- [4] D.C. Park, M.A. El-Sharkawi, R.J. Marks II, Electric Load Forecasting Using An Artificial Neural Network, *IEEE Transaction on Power Systems*, vol. 6, n. 2, May 1991, pp. 440-449.
- [5] S.Kalyani, K. Shanyi, Study of Neural Network Models for Security Assessment in Power System, *International Journal of Research and Reviews in Applied Sciences*, vol. 1, Issue 2, Nov 2009, pp. 104-117.
- [6] Armando M., Leonidas C., Vladimiro M., Luiz A., Composite Reliability Assessment Based on Monte Carlo Simulation and Artificial Neural Networks, *IEEE Transaction on Power Systems*, vol. 22, n. 3, Aug 2007, pp. 1202-1209.
- [7] H. Demuth, M. Hagan, M. Beale, *Neural Network Toolbox™ User's Guide* (The Math Works, Inc.1992-2017).
- [8] N. Amjadi, Generation adequacy assessment of power systems by time series and fuzzy neural network, *IEEE Transactions on Power Systems*, Vol. 21, Issue. 3, Aug 2006, pp. 1340-1349.
- [9] Swaroop R., Hussein A., Load Forecasting for Power System Planning and Operation using Artificial Neural Network at Al Batinah Region Oman, *Journal of Engineering, Science and Technology*, vol. 7, no. 4, 2012, pp. 498-504.
- [10] P.S. Rajpal, K.S. Shishodia, G.S. Sekhon, An artificial neural network for modeling reliability, availability and maintainability of a repairable system, *Elsevier Science Limited*, 2005, pp. 809-819.
- [11] IEEE RTS Task Force of APM Subcommittee, The IEEE Reliability Test System-1996, *IEEE Transactions on Power Systems*, vol. 14, n. 3, Aug 1999, pp. 1010-1020.
- [12] Somchat Jiriwibhakorn, *Application of Neural Networks in Power Systems* (Electrical Engineering Faculty: KMUTL, 2011).
- [13] Fuzzy logic Toolbox™. Adaptive neuro fuzzy modeling. The Math Works, Received Feb 2017 from <https://www.mathworks.com/help/fuzzy/adaptive-neuro-fuzzy-inference-systems.html>.
- [14] A. Badri, Z. Ameli, A. MototieBirjandi, Application of Artificial Neural Networks and Fuzzy Logic Methods for Short Term Load Forecasting, *Elsevier Science Limited*, 2012, pp. 1883-1888.
- [15] J. AbdulJaleel, Sreedevi R.C., Reliability Prediction of 220 kV Kerala Power system using Neural Network, *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 3, Issue 2, Aug 2013, pp. 141-144.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [16] M. Hadow, N. Abd Allah, P. Abdul Karim, Reliability Evaluation of Distribution Power Systems Based on Artificial Neural Network Techniques, *Journal of Electrical and Computer Engineering*, 2012, pp.1-5.
- [17] A. Shrivastava, A. Bhandakkar, Power System Planning and Operation Using Artificial Neural Networks, *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 4, Issue 1, pp.1-6.
- [18] S. Quaiyum, Y. Lbrahim Khan, S. Rahman, Artificial Neural Network based Short Term Load Forecasting of Power System, *International Journal of Computer Applications*, 2011, pp.1-7.
- [19] Power Development Plan: PDP 2015, Ministry of Energy, Received Apr 2017 from www.eppo.go.th/index.php/th/plan-policy/tieb/pdp.
- [20] K. Xie, H. Zhang, C. Singh, Reliability forecasting models for electrical distribution systems considering component failures and planned outage, *Elsevier Science Limited*, 2016, pp. 228-234.
- [21] Y. Yang, Y. Chen, Y. Wang, C. Li, L. Li, Modeling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting, *Elsevier Science Limited*, 2016, pp. 663-675.
- [22] C. N. Lu, H.T. Wu, S. Vemuri, "Neural network based short term load forecasting", *IEEE Transactions on Power Systems*, vol. 8, Issue. 1, Feb 1993, pp. 336-342.
- [23] A. S. Khwaja, X. Zhang, A. Anpalagan, B. Venkatesh, Boosted neural networks for improved short-term electric load forecasting, *Elsevier Science Limited*, 2016, pp. 431-437.
- [24] Galiveeti, H., Goswami, A., Dev Choudhury, N., A Hybrid Method for Distribution Substation Reliability Evaluation, (2017) *International Review of Electrical Engineering (IREE)*, 12 (2), pp. 142-150.
- [25] Rahmat, M., Jovanovic, S., Lo, K., Reliability and Availability Modelling of Uninterruptible Power Supply Systems Using Monte-Carlo Simulation, (2017) *International Journal on Energy Conversion (IRECON)*, 5 (2), pp. 60-66.
- [26] Lin, O., Miyauchi, H., Reliability Forecasting in Distribution System Considering Variable Failure Rate: Combination of Equipment Inspection Method and Weibull Analysis, (2017) *International Review of Electrical Engineering (IREE)*, 12 (1), pp. 67-72.
- [27] Ganesan, E., Dash, S., A New Approach in Modelling and Control of Distributed Energy Resources for Performance Optimisation and Reliability Improvement in a Micro Grid, (2015) *International Review on Modelling and Simulations (IREMOS)*, 8 (1), pp. 26-40.
- [28] Indrawati, A., Girsang, A., Electricity Demand Forecasting Using Adaptive Neuro-Fuzzy Inference System and Particle Swarm Optimization, (2016) *International Review of Automatic Control (IREACO)*, 9 (6), pp. 397-404.

Authors' information

Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Ladkrabang, Bangkok, Thailand.

E-mails: bee_m_m@hotmail.com
somchat.ji@kmitl.ac.th



Khanittha Wannakam received a B.S. in Electrical Engineering from Burapha University, Thailand, in 2007, an M.S. degree in Electrical Engineering from Chulalongkorn University, Thailand, in 2010. She is currently pursuing a Doctorate degree in the Faculty of Electrical Engineering at King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand.

Her research interests are in power system reliability and neural networks in power systems.



Somchat Jirivibhakorn received B.S. and M.S. degrees in Electrical Engineering from King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand, in 1994 and 1997, respectively, and a Ph.D. in Electrical Engineering from Imperial College, University of London, UK, in 2000. He was a lecturer from 1994 to 2002, an Associate Professor from 2006 to the present with the Faculty of Electrical Engineering, King Mongkut's Institute of Technology Ladkrabang at Bangkok, Thailand. His present research interests are in power system stability, power system planning and forecasting, and applications of neural networks and anfis in power engineering.

ประวัติผู้เขียน

นางสาวชนิษฐา วรรณคำ

การศึกษา

- สำเร็จการศึกษาปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา เมื่อปี พ.ศ. 2550
- สำเร็จการศึกษาปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย พ.ศ. 2554
- ปัจจุบันกำลังศึกษาหลักสูตร ปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้