

การพยากรณ์ความต้องการไฟฟ้าระยะสั้นของระบบจำหน่ายสถานีไฟฟ้าบ้านไผ่ โดยใช้โครงข่ายประสาทเทียม

โกวิทย์ แสนพงษ์ วรรณ เสริมวิบูล และ นิวัตร อังควิชิตพันธุ์
หน่วยวิจัยวิศวกรรมอิเล็กทรอนิกส์การเกษตร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยมหาสารคาม
ถนนกัณฑ์รัชย์, จังหวัดมหาสารคาม 44150, E-mail:wor_nui@yahoo.com

บทคัดย่อ

บทความนี้นำเสนอการพยากรณ์ความต้องการไฟฟ้าระยะสั้นของระบบจำหน่ายแรงดัน 22 กิโลวัตต์ สถานีไฟฟ้าบ้านไผ่ ของการไฟฟ้าส่วนภูมิภาค เขต 1 (ภาคตะวันออกเฉียงเหนือ) จังหวัดขอนแก่น โดยใช้เทคนิคโครงข่ายประสาทเทียม (Artificial Neural Networks ; ANN) ชนิดที่มีการแพร่ค่าย้อนกลับ (Back-Propagation Learning Algorithm) ลักษณะการเรียนรู้แบบมีผู้สอน (Supervised Learning) และใช้ความสัมพันธ์ระหว่างความต้องการพลังงานไฟฟ้าของผู้ใช้ไฟ กับอุณหภูมิสูงสุด – ต่ำสุด มาร่วมวิเคราะห์ โดยผลการทดลองมีค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) ที่ดีที่สุดเท่ากับ 6.579% ซึ่งผลการพยากรณ์เป็นที่ยอมรับได้เมื่อเปรียบเทียบกับข้อมูลความต้องการไฟฟ้าจริงของการไฟฟ้า

คำสำคัญ : การพยากรณ์ความต้องการไฟฟ้าระยะสั้น โครงข่ายประสาทเทียม การแพร่ย้อนกลับ

1. บทนำ

ปัจจุบันความต้องการไฟฟ้าของประเทศไทยมีแนวโน้มสูงขึ้น ไฟฟ้าซึ่งถือว่าเป็นสิ่งจำเป็นในการดำรงชีวิตประจำวันและเป็นปัจจัยพื้นฐานที่สำคัญในการขับเคลื่อนทางเศรษฐกิจที่กำลังขยายตัวมากขึ้น การพยากรณ์ความต้องการไฟฟ้าที่น่าเชื่อถือจึงมีความสำคัญอย่างมากต่อความมั่นคงด้านพลังงานไฟฟ้าของประเทศ ดังนั้นไม่เพียงแต่การพยากรณ์ความต้องการไฟฟ้าระยะสั้นมาก ระยะปานกลางและระยะยาวเท่านั้นที่มีความสำคัญ การพยากรณ์ความต้องการไฟฟ้าระยะสั้นก็มีความสำคัญในด้านการวางแผนการทำงานของโรงจักร (Unit Commitment) หรือการวางแผนการผลิตของโรงจักรไฟฟ้า (Scheduling and Operative Reserve) อีกทั้งยังเป็นเครื่องมือในการตัดสินใจด้านการพิจารณาการถ่ายทอดให้กับ ผู้ปฏิบัติงานควบคุมการจ่ายไฟ (Operator)

ในบทความนี้ได้นำเสนอการพยากรณ์ความต้องการพลังงานไฟฟ้าโดยสร้างแบบจำลองการทำงานของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Feed forward Back-Propagation Neural Networks) ซึ่งเป็นโครงข่ายประสาทเทียมแบบต้องผู้สอน (Supervised Learning) และใช้สภาพอากาศ อุณหภูมิสูงสุด – ต่ำสุด

มาเป็นปัจจัยในการวิเคราะห์[1] ซึ่งข้อมูลที่น่ามาใช้ในการพยากรณ์นี้ ได้จากความต้องการกำลังไฟฟ้า(MW) ในแต่ละวันเป็นรายชั่วโมงของการไฟฟ้าบ้านไผ่ จ.ขอนแก่น

2. หลักการและทฤษฎี

2.1 สถาปัตยกรรมของโครงข่ายประสาทเทียม

สถาปัตยกรรมของโครงข่ายประสาทเทียมออกแบบโดยใช้เทคนิคการเรียนรู้ของโครงข่ายประสาทเทียม ซึ่งโดยทั่วไปจะมีรูปแบบการจัดเซลล์ประสาทเป็นชั้นๆ (Layer) ประกอบไปด้วย ชั้นอินพุต(Input Layer) การทำงานของ Input Layer จะทำหน้าที่รับข้อมูลเข้าสู่โครงข่าย , ชั้นซ่อน(Hidden Layer) ทำหน้าที่ช่วยในการประมวลผล ซึ่งในการทำงานของแต่ละชั้นซ่อนจะถูกกำหนดโดยการทำงานของชั้นอินพุต , ค่าถ่วงน้ำหนัก(weight) และค่าตัวทค(bias) บนความสัมพันธ์ระหว่างชั้นอินพุตและชั้นซ่อน , ชั้นเอาต์พุต (Output Layer) ทำหน้าที่ผลิตผลตอบสนองของโครงข่าย นอกจากนี้ยังมีทรานเฟอร์ฟังก์ชัน(transfer function) ช่วยในการคำนวณหาค่าที่เหมาะสม


ทุกๆ นิวรอนในชั้นอินพุตจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นซ่อนแรก และทุกๆ นิวรอนในชั้นซ่อนแรกจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นถัดไป จนในที่สุดทุกๆ นิวรอนในชั้นซ่อนชั้นสุดท้าย จะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นเอาต์พุต ดังรูปที่ 1

รูปที่ 1 แสดงโครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน มี p_1, p_2, \dots, p_R เป็นอินพุตของโครงข่าย , a^1 เป็นเอาต์พุตของชั้นซ่อนที่ 1 และเป็นอินพุตของชั้นซ่อนที่ 2, a^2 เป็นเอาต์พุตของชั้นซ่อนที่ 2 และเป็นอินพุตของชั้นข้อมูลด้านเอาต์พุต และ a^3 เป็นเอาต์พุตของโครงข่าย โดยมี f^1, f^2 และ f^3 เป็นทรานเฟอร์ฟังก์ชัน ซึ่งค่า a^1, a^2 และ a^3 สามารถหาได้จากสมการต่อไปนี้

$$a^1 = f^1(W^1 p + b^1) \quad (1)$$

$$a^2 = f^2(W^2 a^1 + b^2) \quad (2)$$

$$a^3 = f^3(W^3 a^2 + b^3) \quad (3)$$



รูปที่ 1 โครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน

โดยที่

- W^1 คือ ค่าถ่วงน้ำหนัก(weight) ที่เชื่อมระหว่างชั้นข้อมูลด้านอินพุตและชั้นซ่อนที่ 1
- W^2 คือ ค่าถ่วงน้ำหนัก(weight) ที่เชื่อมระหว่างชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2
- W^3 คือ ค่าถ่วงน้ำหนัก(weight) ที่เชื่อมระหว่างชั้นซ่อนที่ 2 และชั้นข้อมูลด้านเอาต์พุต
- b^1 คือ ค่าไบแอสในชั้นซ่อนที่ 1
- b^2 คือ ค่าไบแอสในชั้นซ่อนที่ 2
- b^3 คือ ค่าไบแอสในชั้นเอาต์พุต

ในการศึกษาจะใช้ Neural Network Toolbox ของโปรแกรม Matlab[2] ฝึกสอนโครงข่ายประสาทเทียม ด้วย Levenberg-Maquardt Algorithm(trainlm) โดยทดลองใช้ทรานเฟอร์ฟังก์ชัน ในสมการที่ 4-6 สลับกันใน f^1, f^2 และ f^3 เพื่อหาเปอร์เซ็นต์ความผิดพลาดเฉลี่ยสมบูรณ์น้อยที่สุด (Mean Absolute Percentage Error) หารได้จากสมการที่ 7

linear transfer function (purelin)

$$a(n) = n \quad (4)$$

tan - sigmoid transfer function (tansig)

$$a(n) = \frac{1 - e^{-n}}{1 + e^{-n}} \quad (5)$$

log - sigmoid transfer function (logsig)

$$a(n) = \frac{1}{1 + e^{-n}} \quad (6)$$

Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_{real} - E_{ANN}}{E_{real}} \right| \times 100\% \quad (7)$$

โดยที่ E_{ANN} คือ กำลังไฟฟ้าที่ได้จากโครงข่ายประสาทเทียม(MW)
 E_{real} คือ กำลังไฟฟ้าที่ได้จากข้อมูลของ กฟภ.(MW)
 N คือ จำนวนข้อมูลที่ใช้ในการทดสอบ

2.2 ข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม

ข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียมในการศึกษานั้น ได้ใช้ข้อมูลความต้องการกำลังไฟฟ้า(MW)ในแต่ละวันเป็นรายชั่วโมงของสถานีไฟฟ้าบ้านไผ่ ซึ่งมีผู้ใช้ไฟหลายประเภท เช่น บ้านที่อยู่อาศัย ,ธุรกิจ, โรงงานอุตสาหกรรม มีปริมาณโหลดสูงสุดประมาณ 30 MW ตั้งแต่วันที่ 1 กรกฎาคม – 31 สิงหาคม 2554 รวมทั้งหมด 62 วัน รวม 1,488 ชั่วโมง และใช้ข้อมูลอุณหภูมิสูงสุด-ต่ำสุด ในแต่ละวันของกรมอุตุนิยมวิทยา จังหวัดขอนแก่น ในการศึกษาจะเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทเทียมที่ผ่านการฝึกสอนด้วยทรานเฟอร์ฟังก์ชัน(สมการที่ 4-6) ในชั้นซ่อนที่มีความชัน เท่ากับ 1.0 โดยเงื่อนไขจะเลือกค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบแอสโดยการสุ่มเลือก และในการเรียนรู้ของโครงข่ายประสาทเทียม ข้อมูลอินพุตจะมี 22 อินพุต ดังแสดงในตารางที่ 1

ตารางที่ 1 แสดงอินพุตทั้งหมดที่ใช้ในการพยากรณ์[3]

ที่	ข้อมูลการเรียนรู้	โครงสร้างอินพุต	จำนวนอินพุต
1	ชนิดของวัน	เลขฐานสอง	3
2	ช่วงของเดือน	เลขฐานสอง	4
3	ช่วงของเวลา	เลขฐานสอง	5
4	อุณหภูมิสูงสุดเมื่อวาน	จำนวนจริง	1
5	อุณหภูมิต่ำสุดเมื่อวาน	จำนวนจริง	1
6	Load ของเมื่อวาน ณ ช่วงเวลาเดียวกัน	จำนวนจริง	1
7	Load ของสัปดาห์ที่แล้ว ณ ช่วงเวลาเดียวกัน	จำนวนเต็ม	1
8	Load ตั้งแต่ 6 ชั่วโมงที่แล้ว จนถึง 1 ชั่วโมง ที่แล้ว ณ ช่วงเวลาที่พยากรณ์	จำนวนเต็ม	6

จากตารางที่ 1 จะเห็นว่าอินพุตที่ใช้ในโครงข่ายประสาทเทียมมีหลายรูปแบบ เช่น จำนวนเต็ม เลขฐานสองเป็นต้นอินพุตที่ใช้และ โครงสร้างของอินพุตที่ใช้ในการวิจัย แสดงดังในตารางที่ 2 ถึงตารางที่ 4

ตารางที่ 2 โครงสร้างของอินพุตที่เป็นแบบเลขฐานสองตามชนิดของวัน (Day code : DC)[3]

Day	Mon	Tue	Wed	Thu	Fri	Sat	Sun
DC 1	0	0	0	1	1	1	1
DC 2	0	1	1	0	0	1	1
DC 3	1	0	1	0	1	0	1

ตารางที่ 3 โครงสร้างของอินพุตที่เป็นแบบเลขฐานสองตามช่วงของเดือน (Mont code : MC)[3]

เดือน	โครงสร้างอินพุต	เดือน	โครงสร้างอินพุต
มกราคม	0001	กรกฎาคม	0111
กุมภาพันธ์	0010	สิงหาคม	1000
มีนาคม	0011	กันยายน	1001
เมษายน	0100	ตุลาคม	1010
พฤษภาคม	0101	พฤศจิกายน	1011
มิถุนายน	0110	ธันวาคม	1100

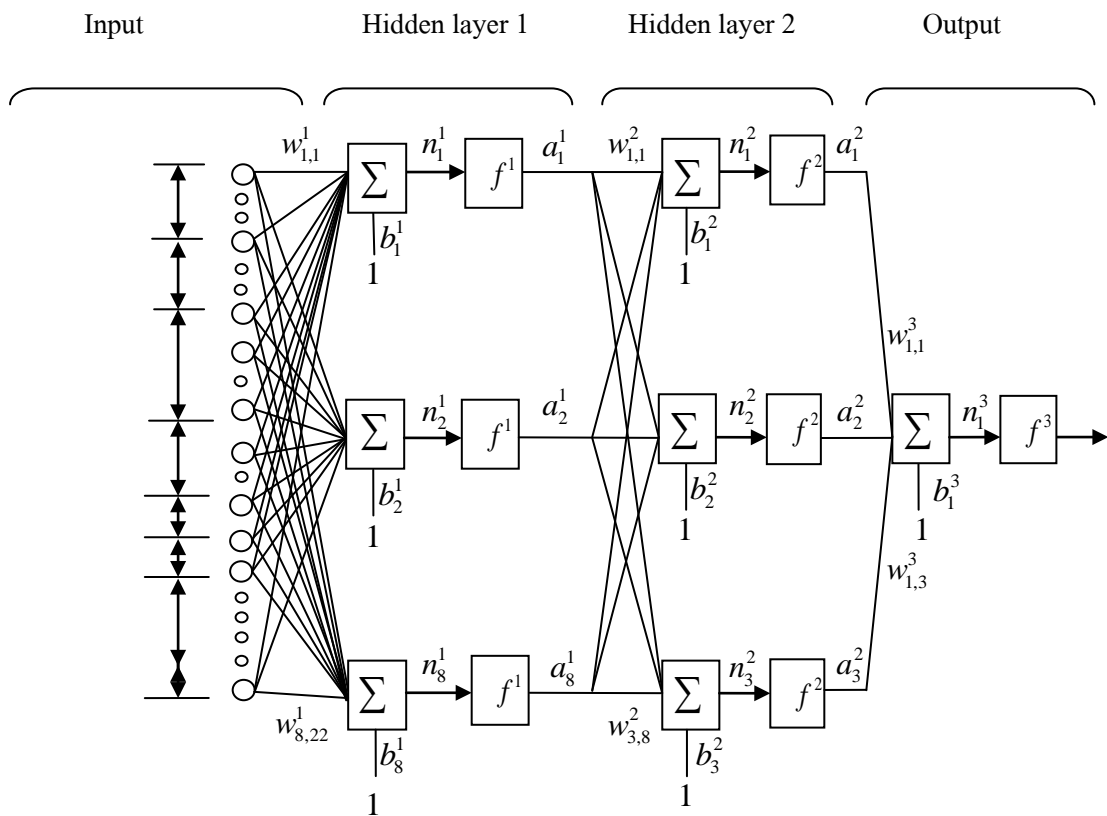
ตารางที่ 4 โครงสร้างของอินพุตที่เป็นแบบเลขฐานสองตามช่วงของเวลา (Time code : TC)[3]

ช่วงของเวลา	โครงสร้างอินพุต	ช่วงของเวลา	โครงสร้างอินพุต
01:00	00001	13:00	01101
02:00	00010	14:00	01110
03:00	00011	15:00	01111
04:00	00100	16:00	10000
05:00	00101	17:00	10001
06:00	00110	18:00	10010
07:00	00111	19:00	10011
08:00	01000	20:00	10100
09:00	01001	21:00	10101
10:00	01010	22:00	10110
11:00	01011	23:00	10111
12:00	01100	24:00	11000

ในการศึกษาจะใช้ข้อมูลชุดฝึกสอน (Training Patterns) ทั้งหมด 47 วัน (1,128 ชั่วโมง) คือ ตั้งแต่ วันที่ 1 กรกฎาคม – 15 สิงหาคม 2554 และใช้ข้อมูลทดสอบ(Test Patterns) ทั้งหมด 15 วัน(360 ชั่วโมง) คือ ตั้งแต่ วันที่ 16-31 สิงหาคม 2554 และใช้โครงข่ายประสาทเทียมที่มีจำนวน 2 ชั้นซ่อน[4] ดังแสดงในรูปที่ 2 เมื่อ *input* คือ 1) เวลา 2) วัน 3) เดือน 4) อุณหภูมิสูงสุด-ต่ำสุด 5) ภาระโหลด 24 ชั่วโมงที่ผ่านมา 6) ภาระโหลด 24 ชั่วโมงที่ผ่านมา ของสัปดาห์ที่แล้ว และ 7) ภาระโหลด 6 ชั่วโมงที่ผ่านมาจนถึงก่อน 1 ชั่วโมงของการพยากรณ์ ขณะที่ *output* คือ ความต้องการพลังงานไฟฟ้าที่พยากรณ์ 1 ชั่วโมง ซึ่งมีแนวโน้มที่จะสามารถแก้ไขปัญหาได้ดีกว่าโครงสร้างที่มีจำนวน 1 ชั้นซ่อน และใช้ระยะเวลาในการเรียนรู้ได้เร็วกว่า โครงสร้างที่มีจำนวน 3 ชั้นซ่อน โดยที่โครงข่ายประสาทเทียมจะมีจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 แตกต่างกันทั้ง 4 กรณี ดัง แสดงในตารางที่ 5 โดยแต่ละกรณีจะฝึกสอนด้วยรูปแบบฟังก์ชันถ่ายโอน (*Transfer function*) ของแต่ละชั้นซ่อนที่แตกต่างกันทั้ง 4 กรณี

ตารางที่ 5 แสดงโครงสร้างของโครงข่ายประสาทเทียมที่ใช้ในการศึกษา[1]

ที่	จำนวนนิวรอนในชั้นซ่อนที่ 1	จำนวนนิวรอนในชั้นซ่อนที่ 2
1	8	3
2	15	8
3	30	24
4	32	28



รูปที่ 2 โครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์

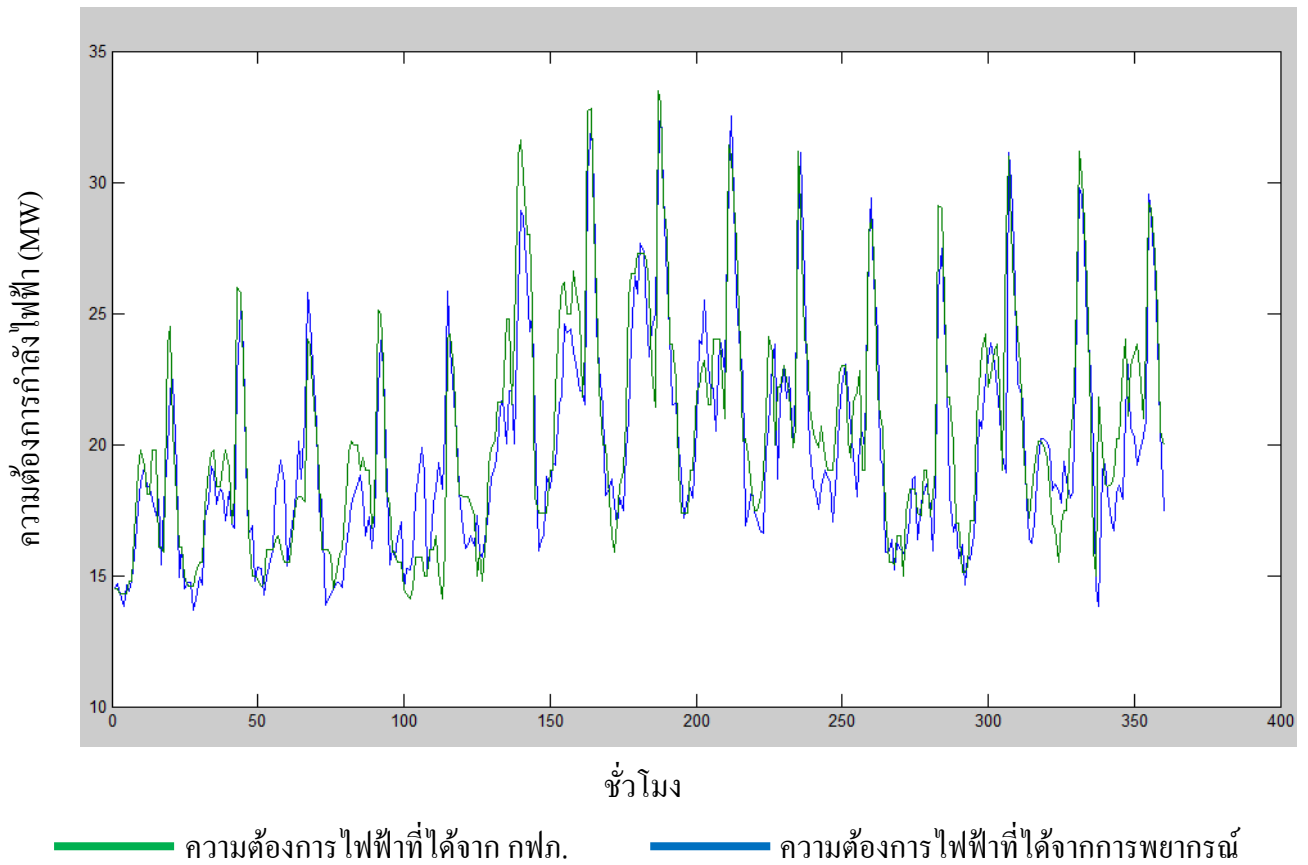
3. ผลการทดลอง

หลังจากที่ได้ทำการทดลองหลายครั้งโดยการปรับเปลี่ยนจำนวนนิวรอนในแต่ละชั้นซ่อนจากการลองผิดลองถูก(trial and error) และทำการฝึกสอนโดยใช้โครงข่ายประสาทเทียม 3 ชั้น ผลการวิเคราะห์โครงข่ายประสาทเทียม เมื่อเปรียบเทียบการทดสอบการทำงานของโครงข่ายจากตารางที่ 6 รูปแบบโครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมกับการพยากรณ์ความต้องการไฟฟ้าของการทดสอบนี้คือ โครงสร้างที่ให้ค่า MAPE มีค่าน้อยที่สุด คือ โครงสร้างที่มีจำนวนนิวรอนในชั้นที่ 1 และ 2 จำนวน 8 และ 3 นิวรอนตามลำดับ ซึ่งมีค่า MAPE ของข้อมูลชุดเรียนรู้เท่ากับ 4.932 % ค่า MAPE ของข้อมูลชุดทดสอบ

เท่ากับ 6.579 % และใช้ทรานเฟอร์ฟังก์ชันในชั้นซ่อนแรกเป็น logsig ชั้นซ่อนที่สองเป็น tansig และชั้นเอาต์พุตเป็น tansig ซึ่งใช้เวลาการประมวลผล 0:23 นาที

ตารางที่ 6 แสดงผลการเรียนรู้โดยโครงข่ายประสาทเทียมในการพยากรณ์ความต้องการไฟฟ้าและฟังก์ชันถ่ายโอนที่แตกต่างกัน 4 กรณี

ที่	จำนวน นิวรอน ในชั้นซ่อน ที่ 1	จำนวน นิวรอน ในชั้นซ่อน ที่ 2	รูปแบบฟังก์ชันกระตุ้น			เวลาที่ใช้ ในการเรียนรู้ (นาที)	MAPE(%) จากการ เรียนรู้	MAPE(%) จากการ ทดสอบ
			ชั้นซ่อน	ชั้นซ่อน	ชั้น			
			แรก	ที่สอง	เอาต์พุต			
1	8	3	logsig	tansig	tansig	0:23	4.932	6.579
2	15	8	logsig	tansig	tansig	0:46	4.957	7.273
3	31	24	logsig	purelin	purelin	5:22	4.834	7.313
4	32	28	tansig	purelin	tansig	7:02	4.957	7.557



รูปที่ 3 กราฟแสดงค่าเปรียบเทียบระหว่างความต้องการไฟฟ้าจริงกับความต้องการที่ได้จากการพยากรณ์ ทั้ง 360 ชั่วโมง

4.อภิปรายผล

จากผลการพยากรณ์สามารถนำมาเปรียบเทียบกับความต้องการกำลังไฟฟ้าจริงที่ได้จาก กฟภ. ได้ดังแสดงในรูปที่ 3 จากการเปรียบเทียบผลการพยากรณ์ของโครงสร้างโครงข่ายประสาทยูทิลิตี้ พบว่าจำนวนนิเวรอนในชั้นชอนที่มีจำนวนมาก ไม่ได้ทำให้ค่าความผิดพลาดเฉลี่ยสมบูรณ์ (MAPE) ดีขึ้น อาจเป็นผลมาจากการสุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบแอส นอกจากนี้สามารถจำแนกปัจจัยที่มีผลกระทบต่อการพยากรณ์ ในการทดลองได้ดังนี้

1. ลักษณะโหลด จากการทดลองพบว่า โครงข่ายประสาทยูทิลิตี้จะทำงานโดยอาศัยการหาความสัมพันธ์ของข้อมูลอินพุตและเอาต์พุต ดังนั้นหากมีการเปลี่ยนแปลงข้อมูลโหลด โครงข่ายประสาทยูทิลิตี้จะมีแนวโน้มเปลี่ยนแปลงไปในทิศทางเดียวกันกับที่เปลี่ยนแปลงข้อมูลไป ข้อมูลการใช้โหลดจึงเป็นเพียงสิ่งที่แสดงถึงระดับของการใช้พลังงานไฟฟ้าอ้างอิงที่สภาวะแวดล้อมนั้นๆ

2. เวลา ถือเป็นปัจจัยที่สำคัญอีกปัจจัยหนึ่ง เนื่องจากลักษณะการใช้พลังงานไฟฟ้าในแต่ละวันมีความแตกต่างกันออกไปตามช่วงเวลา ในการเรียนรู้ของโครงข่ายประสาทยูทิลิตี้ ที่มีรูปแบบของอินพุตที่แสดงถึงเวลาจะทำให้โครงข่ายสามารถเรียนรู้ถึงสภาพการใช้พลังงานไฟฟ้าได้อย่างมีประสิทธิภาพ

3. อุณหภูมิ อุณหภูมิเป็นปัจจัยที่สำคัญอีกประการหนึ่งที่ส่งผลกระทบต่ออัตราการใช้กำลังไฟฟ้า รูปแบบลักษณะการใช้พลังงานไฟฟ้าของระบบจำหน่ายจะขึ้นกับสภาพอากาศ ขณะที่อัตราใช้พลังงานไฟฟ้าเพิ่มขึ้นหรือลดลงจะขึ้นกับจำนวนของผู้ใช้ไฟฟ้าที่เชื่อมต่ออยู่กับระบบ

5. สรุปและข้อเสนอแนะ

การนำเทคนิคโครงข่ายประสาทยูทิลิตี้มาประยุกต์ใช้ในการพยากรณ์ความต้องการไฟฟ้าระยะสั้น เป็นอีกวิธีหนึ่งในการหาความสัมพันธ์ของการเปลี่ยนแปลงของความต้องการพลังงานไฟฟ้ากับสภาพแวดล้อม โดยอาศัยคุณลักษณะของโครงข่ายประสาทยูทิลิตี้ที่มีความสามารถในการประมวลผลข้อมูลที่มีความซับซ้อน ซึ่งโครงข่ายประสาทยูทิลิตี้สามารถเพิ่มประสิทธิภาพในการพยากรณ์ความต้องการไฟฟ้า เพื่อให้มีความถูกต้องแม่นยำมากยิ่งขึ้นได้โดยเพิ่มข้อมูลค่าตัวแปรสภาพอากาศ เช่น ความชื้นสัมพัทธ์ ความร้อนสะสม หรือข้อมูลสถานะทางเศรษฐกิจ มาเป็นปัจจัยในการพยากรณ์ นอกจากนี้ยังต้องพิจารณาถึงข้อมูลในอดีตที่นำมาฝึกสอน ซึ่งจะต้องมีข้อมูลมากพอ และมีความถูกต้อง ใดๆก็ตามข้อเสียของ ANN_s คือการเลือกโครงสร้างที่เหมาะสมของโครงข่ายสำหรับการฝึกสอนยังไม่มีวิธีที่ชัดเจนขึ้นอยู่กับข้อมูลที่ใช้ฝึกสอน จึงต้องใช้เวลาในการหาโครงสร้างของโครงข่ายที่เหมาะสม

เอกสารอ้างอิง

- [1] นฤมล ชิ่งเสถียรตระกูล และ สมชาติ จีรวินากร , “ การพยากรณ์โหลดระยะสั้นโดยใช้โครงข่ายประสาทเทียม ”, วิศวกรรมลาดกระบัง ปีที่ 23,ฉบับที่ 4 ธันวาคม 2549 ,หน้าที่ 166-172.
- [2] Howard Demuth, Mark Beale and Martin Hagan, “Neural Network Toolbox 5 User’s Guide,” *The Mathworks Inc.*,September 2007.
- [3] ธฤติ บุญญาชน และ อุดลย์พิเชษฐ์ ฤกษ์ปรีดาพงศ์, “การพยากรณ์ความต้องการไฟฟ้าระยะสั้นมากโดยใช้โครงข่ายประสาทเทียม ”, วิทยานิพนธ์ ปรัชญาวิทยาลัย มหาวิทยาลัยเกษตรศาสตร์, 2549.
- [4] Du Xin-hui, Tian Feng, Tan Shao-qiong, “Study of Power System Short-term Load Forecasts Based on Artificial Neural Network and Genetic Algorithm,” *College of Electrical and Power Engineering Taiyuan University of Technology* ,July 2010.

บทความนี้ส่งเข้ามาเมื่อ 5 มีนาคม 2555 และได้รับพิจารณาให้ตีพิมพ์เมื่อ 26 มีนาคม 2555