

การทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมรายเดือน ของการไฟฟ้าส่วนภูมิภาค โดยใช้โครงข่ายประสาทเทียมและ ระบบอนุมานฟัซซี่โครงข่ายปรับตัวได้

Monthly Energy of Industrial Sector Forecasting for Provincial Electricity Authority Using
Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems

ชาญชลิต อินทสุก และ สมชาติ จิรวិภากร
ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
E-mail : charnchalit@gmail.com และ kjsomcha@kmitl.ac.th



บทคัดย่อ

บทความนี้นำเสนอวิธีการทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมแบบรายเดือน ของการไฟฟ้าส่วนภูมิภาค โดยนำค่าอัตราขยายตัวสาขาอุตสาหกรรม ค่าอุณหภูมิสูงสุด ค่าความชื้นสัมพัทธ์เฉลี่ย จำนวนผู้ใช้ไฟฟ้าภาคอุตสาหกรรม และความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม มาวิเคราะห์ร่วมกัน ด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Networks : ANN) และวิธีระบบอนุมานฟัซซี่โครงข่ายปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems: ANFIS) โดยกำหนดให้ค่าความต้องการพลังงานไฟฟ้าเป็นเอาต์พุตของโครงข่ายประสาทเทียม (ANN) และระบบอนุมานฟัซซี่โครงข่ายปรับตัวได้ (ANFIS) ซึ่งวิธีการ ANN ให้ผลการทำนายที่ดีกว่า ANFIS



คำสำคัญ

โครงข่ายประสาทเทียม ระบบอนุมานฟัซซี่โครงข่ายปรับตัวได้ การทำนายพลังงานไฟฟ้า



Abstract

This paper presented a method to monthly energy of industrial sector forecasting for Provincial Electricity Authority (PEA). Manufacturing sector growth rate, max temperature, relative humidity, number of customers and energy demands were brought to be analyzed together by approach Artificial Neural Networks (ANN) and Adaptive Neuro-Fuzzy Inference Systems (ANFIS). By requiring energy demands, it was an output of ANN and ANFIS. The results indicated that the performance of ANN yielded better than that of ANFIS.



Key words

Artificial Neural Networks, Adaptive Neuro-Fuzzy Inference Systems, energy forecasting

1. บทนำ

การทำนายความต้องการพลังงานไฟฟ้าที่แม่นยำ จะต้องมีการนำปัจจัยหลายอย่างที่มีผลกระทบต่อปริมาณการใช้พลังงานไฟฟ้า เช่น สภาพเศรษฐกิจ จำนวนประชากร จำนวนเครื่องใช้ไฟฟ้า พฤติกรรมการใช้ไฟฟ้าของผู้ใช้ไฟฟ้า สภาพอากาศ เป็นต้น มาช่วยในการวิเคราะห์

การทำนายความต้องการพลังงานไฟฟ้ามีหลายวิธี ได้แก่ วิธีเอกโพเนนเชียลลสมูตติง (Exponential Smoothing) [1] การถดถอยพหุคูณ (Multiple-regression) [2] การใช้เทคนิคจีเนติก อัลกอริทึม (Genetic Algorithm) [3,4] การใช้เทคนิคฟัซซีลอจิก (Fuzzy Logic) [5] การใช้เทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) [6-8] และการใช้ระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems: ANFIS) [9] ซึ่งเป็นเทคนิคเชิงปัญญาประดิษฐ์

ในบทความนี้นำเสนอการนำระบบ ANFIS และ ANN มาใช้ทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมรายเดือนของการไฟฟ้าส่วนภูมิภาค (กฟภ.) โดยใช้ข้อมูลความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม จำนวนผู้ใช้ไฟฟ้าภาคอุตสาหกรรม สภาพภูมิอากาศ ชนิดของเดือน ชนิดของปี และอัตราขยายตัวสาขาอุตสาหกรรม มาเป็นปัจจัยในการวิเคราะห์เพื่อใช้ในการทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมรายเดือนของการไฟฟ้าส่วนภูมิภาค และได้เปรียบเทียบผลที่ได้จากการวิเคราะห์ของ ANN และ ANFIS

2. โครงข่ายประสาทเทียม (Artificial Neural Networks : ANN)

โครงข่ายประสาทเทียมเป็นโมเดลทางคณิตศาสตร์ที่มีการประมวลผลข้อมูลที่ถูกพัฒนาโดยอาศัยหลักการทำงานของโครงข่ายประสาทชีววิทยามนุษย์ ในบทความ

นี้จะโครงข่ายประสาทเทียมแบบที่ต้องมีผู้สอน (Supervised Learning) เพื่อช่วยกำหนดเอาต์พุตเป้าหมาย (Output target) ให้กับโครงข่ายประสาทเทียม และเลือกใช้แบบหลายชั้น (Multi-Layer Feed Forward Neural Network) ชนิดที่มีการแพร่ย้อนกลับ (Back-propagation) เนื่องจากเป็นข้อมูลที่ค่อนข้างซับซ้อน และไม่เชิงเส้น

โครงข่ายประสาทเทียมชนิดแพร่ย้อนกลับนั้น จะประกอบไปด้วย ตัวแปรด้านเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และตัวแปรด้านออก (Output Layer) ในแต่ละชั้นจะมีการต่อแบบเชื่อมถึงกันหมด (Fully Connect) โดยในแต่ละนิวรอนจะประกอบไปด้วย ค่าถ่วงน้ำหนัก (Weight) และค่าไบแอส (Bias) ซึ่งเริ่มต้นจากการสุ่ม นอกจากนี้ยังมีตัวกระตุ้น (Activation Function) หรือฟังก์ชันถ่ายโอน (Transfer Function) ช่วยในการคำนวณหาค่าที่เหมาะสม [10] เช่น Tan-Sigmoid, Log-Sigmoid และ Linear

โดยเอาต์พุตที่ได้จากโครงข่ายประสาทเทียมนั้น สามารถวัดค่าความแม่นยำของเอาต์พุต ที่ได้โดยอาศัยค่าผิดพลาดเฉลี่ยสัมบูรณ์ (Mean Absolute Percent Error : MAPE) [8] เป็นเกณฑ์ในการพิจารณาซึ่งสามารถหาได้จากสมการ (1)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{output_{actual_i} - output_{ANN_i}}{output_{actual_i}} \right| \times 100\% \quad (1)$$

เมื่อ $output_{ANN_i}$ คือ ค่าเอาต์พุตที่เป็นค่าตอบของโครงข่ายประสาทเทียม

$output_{actual_i}$ คือ ค่าเอาต์พุตที่เป็นจริง

n คือ จำนวนข้อมูลฝึกสอนหรือทดสอบ

3. ระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ (Adaptive Neuro-Fuzzy Inference System : ANFIS)

ประเภทของโครงข่ายที่มีการปรับตัวบนกรอบพื้นฐานของการปรับตัวระบบอนุมานโดยฟัซซี (Fuzzy Inference Systems : FIS) โครงข่ายชนิดนี้เรียกว่า

ANFIS ซึ่งย่อมาจาก Adaptive Network-based Fuzzy Inference Systems หรือ Adaptive Neuro-Fuzzy Inference Systems [11,12]

3.1 โครงสร้าง ANFIS

เพื่อให้ง่ายต่อความเข้าใจสมมุติระบบอนุมานโดยฟัซซี่ ภายใต้การพิจารณามี 2 อินพุต คือ x และ y และ 1 เอาท์พุท f สำหรับโมเดลฟัซซี่ Sugeno อันดับที่ 1 โดยทั่วไปหลักปฏิบัติเซตของ 2 ฟัซซี่ คือหลัก if-then สามารถแสดงเป็น

กฎข้อที่ 1 : ถ้า x คือ A_1 และ y คือ B_1

$$\text{เมื่อ } f_1 = p_1x + q_1y + r_1$$

กฎข้อที่ 2 : ถ้า x คือ A_2 และ y คือ B_2

$$\text{เมื่อ } f_2 = p_2x + q_2y + r_2$$

เมื่อ p_1, q_1, r_1, p_2, q_2 และ r_2 เป็นพารามิเตอร์ผลลัพธ์

โครงสร้างของ ANFIS ดังภาพที่ 1 สามารถอธิบายได้ดังต่อไปนี้ (เอาท์พุทโหนด i ในชั้น l เช่น $O_{l,i}$)
ชั้นที่ 1 ทุกโหนด i ในชั้นนี้คือการปรับโหนด โหนดเอาท์พุทกำหนดโดย

$$O_{1,i} = \mu_{A_i}(x) \text{ for } i = 1,2 \text{ หรือ } O_{1,i} = \mu_{B_{i-2}}(y) \text{ for } i = 3,4 \quad (2)$$

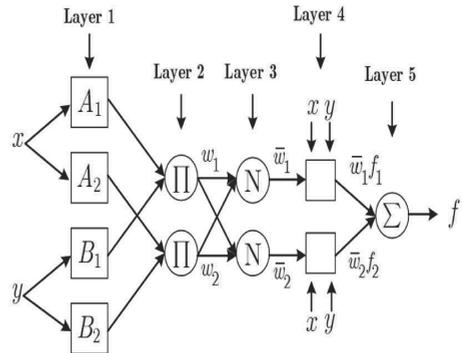
เมื่อ x, y คือ อินพุทของโหนด

A_i, B_{i-2} คือ สัญลักษณ์ทางภาษาที่เกี่ยวกับฟังก์ชันสมาชิก

$\mu_{A_i}, \mu_{B_{i-2}}$ คือ ฟังก์ชันสมาชิก

$O_{1,i}$ คือ ค่าฟังก์ชันสมาชิกของ A_i for $i = 1,2$ ที่เกิดจากค่า x หรือ

$O_{1,i}$ คือ ค่าฟังก์ชันสมาชิกของ B_{i-2} for $i = 3,4$ ที่เกิดจากค่า y



ภาพที่ 1 โครงสร้างของ ANFIS

ในงานวิจัยนี้ใช้ฟังก์ชันสมาชิกแบบ Gaussian function เพราะเป็นฟังก์ชันสมาชิกที่ทำให้ผลการทำนายมีความแม่นยำกว่าฟังก์ชันสมาชิกแบบอื่น โดยมีรูปแบบดังนี้

$$\mu_{A_i}(x) = e^{-\frac{(x-c_i)^2}{2a_i^2}} \quad (3)$$

เมื่อ c_i, a_i คือ เซตพารามิเตอร์ พารามิเตอร์ในชั้นนี้เรียกว่า พารามิเตอร์หลักฐาน (premise parameters)

ชั้นที่ 2 ทุกโหนดในชั้นนี้เป็นโหนดวงกลมสัญลักษณ์ π ซึ่งคือการคูณกันของสัญญาณที่เข้ามาและส่งออกไปเป็นเอาท์พุท ตัวอย่างเช่น

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i = 1,2 \quad (4)$$

ชั้นที่ 3 ทุกโหนดในชั้นนี้เป็นโหนดวงกลมสัญลักษณ์ N ซึ่งจะทำการนอร์มอลไลซ์ค่าน้ำหนัก

$$O_{3,i} = w_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2 \quad (5)$$

ชั้นที่ 4 ทุกโหนด i ในชั้นนี้เป็นโหนดสี่เหลี่ยมที่มีฟังก์ชันโหนด

$$O_{4,i} = w_i f_i = w_i(p_i x + q_i y + r_i) \quad (6)$$

เมื่อ w_i คือ เอาท์พุทของชั้นที่ 3 และ $\{p_i, q_i, r_i\}$ เป็นเซตพารามิเตอร์ พารามิเตอร์ในชั้นนี้เรียกว่า พารามิเตอร์ที่เป็นผลลัพธ์ (Consequent parameter) ชั้นที่ 5 ชั้นนี้มีโหนดเดียวเป็นโหนดวงกลมสัญลักษณ์ Σ ซึ่งเอาท์พุทที่ได้คือการรวมกันของสัญญาณเข้ามาทั้งหมด

$$O_{5,i} = \sum w_j f_i = \frac{\sum_i w_j f_i}{\sum_i w_i} \quad (7)$$

3.2 ขั้นตอนวิธีการเรียนรู้แบบผสม

ค่าพารามิเตอร์หลักฐาน (premise parameters) ที่ได้รับเอาต์พุตทั้งหมดสามารถแสดงในรูปของผลรวมเชิงเส้นของพารามิเตอร์ที่เป็นผลลัพธ์ (consequent parameter) เพื่อให้เกิดความชัดเจนมากขึ้น เอาต์พุต f สามารถเขียนใหม่ได้ดังนี้

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= w_1 \bar{f}_1 + w_2 \bar{f}_2 \\ &= (w_1 \bar{x}) p_1 + (w_1 \bar{y}) q_1 + w_1 \bar{r}_1 \\ &+ (w_2 \bar{x}) p_2 + (w_2 \bar{y}) q_2 + w_2 \bar{r}_1 \quad (8) \end{aligned}$$

ซึ่งเป็นเส้นตรงในพารามิเตอร์ที่เป็นผลลัพธ์ p_1, q_1, r_1, p_2, q_2 และ r_2 ดังนั้นขั้นตอนวิธีการเรียนรู้แบบผสมซึ่งมีการพัฒนาในส่วนก่อนหน้านี้นี้สามารถนำมาใช้ได้โดยตรงมากขึ้น โดยเฉพาะในส่วนคำนวณข้างหน้าของขั้นตอนวิธีการเรียนรู้แบบผสม โหนดเอาต์พุตส่งผ่านไปข้างหน้าจนกระทั่งขั้นที่ 4 และพารามิเตอร์ที่เป็นผลลัพธ์ ถูกตรวจสอบโดยวิธีการกำลังสองน้อยที่สุด (Least Squares Method) ในส่วนการคำนวณ ค่าย้อนกลับสัญญาณค่าผิดพลาดถูกแพร่กลับมา และพารามิเตอร์หลักฐานถูกอัปเดตโดย gradient descent ดังแสดงในตารางที่ 1

ตารางที่ 1 กระบวนการเรียนรู้แบบผสมสำหรับ ANFIS

-	Forward Pass	Backward Pass
Premise Parameters	Fixed	Gradient Descent
Consequent Parameters	Least Squares Estimate	Fixed
Signals	Node Outputs	Error Rates

โครงข่ายประสาทเทียมที่เลือกใช้เป็นโครงข่ายประสาทเทียมแบบสองชั้นซ่อน มีการแพร่ค่าย้อนกลับและออกแบบให้จำนวนนิวรอนในชั้นซ่อนที่ 2 น้อยกว่าชั้นซ่อนที่ 1 อยู่หนึ่งนิวรอนตามหลักการออกแบบรูปทรงพีระมิด โดยเงื่อนไขในการเลือกค่า Weight และ

4. วิธีการ

ข้อมูลที่ใช้ในการวิเคราะห์เพื่อทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมรายเดือนนั้น ได้นำข้อมูลอัตราขยายตัวสาขาอุตสาหกรรม (Manufacturing Sector Growth : MSG) ได้แก่อุณหภูมิสูงสุด ค่าความชื้นสัมพัทธ์ จำนวนผู้ใช้ และความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม โดยจำนวนผู้ใช้และความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรมแบ่งเป็นภาคอุตสาหกรรมขนาดเล็ก ขนาดกลาง และขนาดใหญ่ ข้อมูลที่ใช้อยู่ในช่วงเดือนมกราคม ปี ค.ศ. 2006 ถึงเดือนธันวาคม ปี ค.ศ. 2010 มีจำนวนข้อมูลฝึกสอน 48 ชุด (ม.ค. 2006 – ธ.ค. 2009) และข้อมูลทดสอบ 12 ชุด (ม.ค. 2010 – ธ.ค. 2010) แบ่งการทดลองแต่ละขนาดอุตสาหกรรม และแยกแต่ละขนาดอุตสาหกรรมเป็น 2 แบบ คือแบบที่ 1 ข้อมูลจำนวนผู้ใช้ไฟฟ้าตรงกับเดือนที่ทำนาย และแบบที่ 2 ใช้ข้อมูลจำนวนผู้ใช้ไฟฟ้าย้อนหลัง 3 เดือน

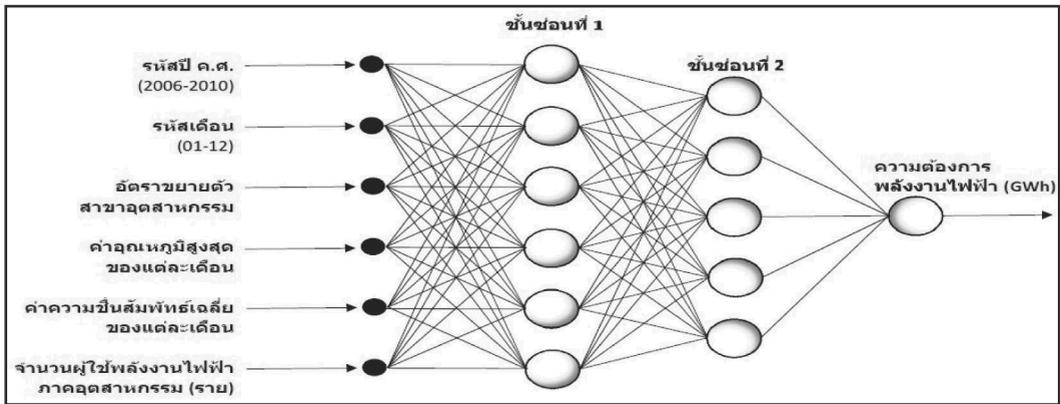
โครงสร้างของ ANFIS เลือกใช้โมเดลฟัซซี่ Sugeno และฟังก์ชันสมาชิกอินพุตที่เลือกใช้จะปรับเปลี่ยนเป็น trimf, trapmf, gbellmf, gaussmf, pimf, dsigmf และ psigmf ส่วนฟังก์ชันสมาชิกเอาต์พุตที่เลือกใช้จะปรับเปลี่ยนเป็น constant และ linear

Bias จะเลือกโดยการสุ่ม (Random) ทำการเรียนรู้ 30 รอบ เพื่อให้การฝึกสอนแต่ละรอบมีทิศทางลู่ออกแตกต่างกันไป และฟังก์ชันถ่ายโอนที่เลือกใช้ปรับเปลี่ยนฟังก์ชันถ่ายโอนเป็น Tan-Sigmoid, Log-Sigmoid และ Linear ทั้งในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 เพื่อ

หาค่าที่ดีที่สุดสำหรับการทำนาย ใช้กระบวนการเรียนรู้แบบ Levenberg - Marquardt 500 epochs ซึ่งโครงข่ายประสาทเทียมที่ใช้สำหรับการทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม แสดงดังภาพที่ 2 การปรับโครงสร้างของโครงข่ายประสาทเทียมเริ่มต้นจากจำนวนนิวรอนในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 เป็น 2-1 ตามลำดับ ไปจนถึง จำนวนนิวรอนในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 เป็น 16-15 ตามลำดับ

5. ผลการจำลอง

การจำลองการทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม แบ่งเป็นอุตสาหกรรมขนาดเล็ก ขนาดกลาง และขนาดใหญ่ โดยใช้ ANN เปรียบเทียบกับ ANFIS ซึ่งแต่ละวิธีแบ่งเป็นข้อมูลแบบที่ 1 ใช้ข้อมูลจำนวนผู้ใช้พลังงานไฟฟ้าในเดือนที่ทำนาย และข้อมูลแบบที่ 2 ใช้ข้อมูลจำนวนผู้ใช้ย้อนหลัง 3 เดือน



ภาพที่ 2 โครงข่ายประสาทเทียมสำหรับการทำนายความต้องการพลังงานไฟฟ้าภาคอุตสาหกรรม

ตารางที่ 2 เปรียบเทียบผลการจำลองภาคอุตสาหกรรมขนาดเล็ก โดยใช้ ANN

แบบที่	ฟังก์ชันถ่ายโอน			จำนวนนิวรอน		เวลาฝึกสอน(นาท)	MAPE(%) การเรียนรู้	MAPE(%) การทดสอบ
	ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต	ชั้นซ่อน1	ชั้นซ่อน2			
1	Linear	Log-Sigmoid	Tan- Sigmoid	9	8	1.0901	0.0730	2.1194
2	Linear	Tan- Sigmoid	Linear	5	4	2.5705	1.0055	2.3116

ตารางที่ 3 เปรียบเทียบผลการจำลองภาคอุตสาหกรรมขนาดกลาง โดยใช้ ANN

แบบที่	ฟังก์ชันถ่ายโอน			จำนวนนิวรอน		เวลาฝึกสอน(นาท)	MAPE(%) การเรียนรู้	MAPE(%) การทดสอบ
	ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต	ชั้นซ่อน1	ชั้นซ่อน2			
1	Log-Sigmoid	Log-Sigmoid	Tan- Sigmoid	4	3	2.5864	0.5477	2.0304
2	Linear	Tan- Sigmoid	Linear	3	2	2.1822	2.1398	1.8669

ตารางที่ 4 เปรียบเทียบผลการจำลอง ภาคอุตสาหกรรมขนาดใหญ่ โดยใช้ ANN

แบบที่	ฟังก์ชันถ่ายโอน			จำนวนนิวรอน		เวลาฝึกสอน(นาท)	MAPE(%) การเรียนรู้	MAPE(%) การทดสอบ
	ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต	ชั้นซ่อน1	ชั้นซ่อน2			
1	Tan- Sigmoid	Tan- Sigmoid	Linear	3	2	2.5135	0.6638	2.3578
2	Linear	Tan- Sigmoid	Linear	7	6	2.7655	3.0998	2.6527

ตารางที่ 5 เปรียบเทียบผลการจำลองภาคอุตสาหกรรมขนาดเล็ก โดยใช้ ANFIS

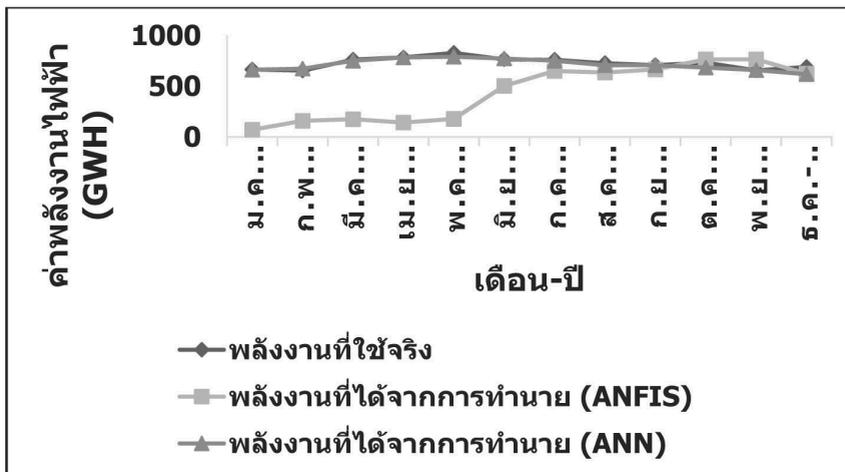
แบบที่	ฟังก์ชันสมาชิก อินพุต	ฟังก์ชันสมาชิก เอาต์พุต	เวลาที่ใช้ในการเรียนรู้ (นาทีก)	MAPE (%) การฝึกสอน	MAPE (%) การทดสอบ
1	trimf	constant	0.2133	0.0363	41.7146
2	trimf	linear	5.4296	0.0363	64.6160

ตารางที่ 6 เปรียบเทียบผลการจำลองภาคอุตสาหกรรมขนาดกลาง โดยใช้ ANFIS

แบบที่	ฟังก์ชันสมาชิก อินพุต	ฟังก์ชันสมาชิก เอาต์พุต	เวลาที่ใช้ในการเรียนรู้ (นาทีก)	MAPE (%) การฝึกสอน	MAPE (%) การทดสอบ
1	trimf	constant	0.1946	0.2135	24.6136
2	trimf	constant	0.2073	0.2135	60.3057

ตารางที่ 7 เปรียบเทียบผลการจำลองภาคอุตสาหกรรมขนาดใหญ่ โดยใช้ ANFIS

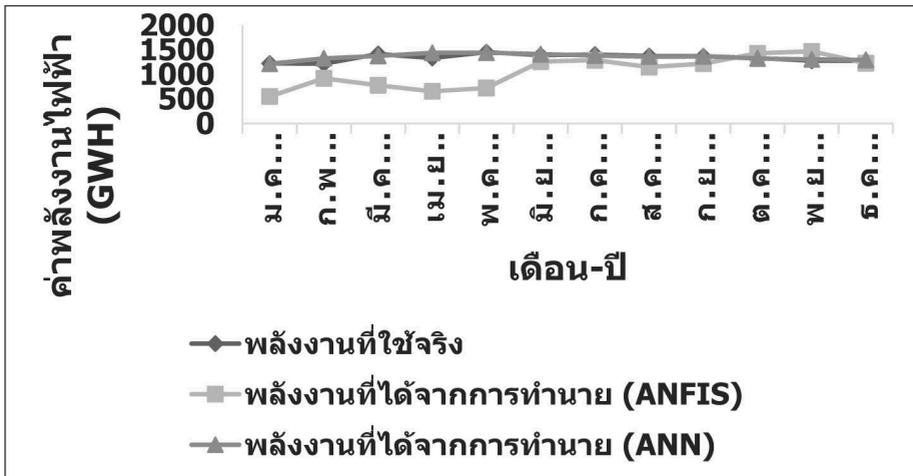
แบบที่	ฟังก์ชันสมาชิก อินพุต	ฟังก์ชันสมาชิก เอาต์พุต	เวลาที่ใช้ในการเรียนรู้ (นาทีก)	MAPE (%) การฝึกสอน	MAPE (%) การทดสอบ
1	trimf	linear	5.3004	0.0887	46.0578
2	trimf	linear	5.2911	0.0887	70.3987



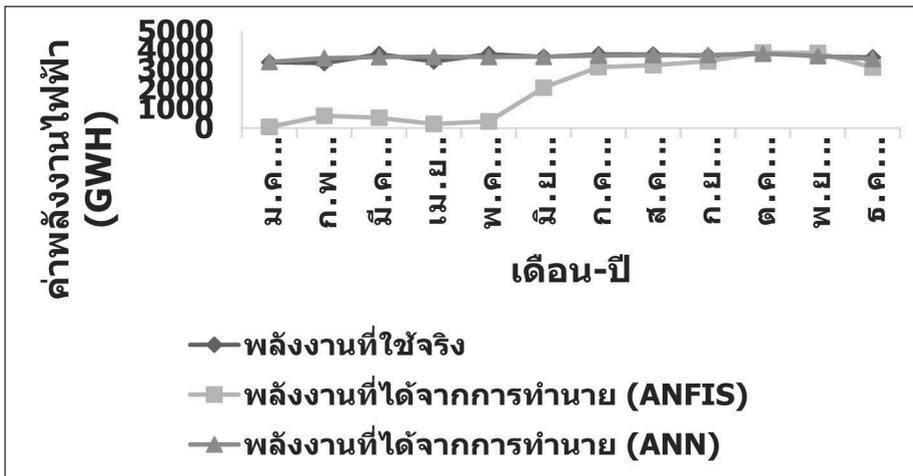
ภาพที่ 3 เปรียบเทียบผลการทดสอบ ANN (แบบที่ 1) และ ANFIS (แบบที่ 1) ภาคอุตสาหกรรมขนาดเล็ก

จากตารางที่ 2-7 ผลการจำลองส่วนใหญ่แบบที่ 1 จะดีกว่าแบบที่ 2 ทั้งค่า MAPE ของข้อมูลชุดฝึกสอนและชุดทดสอบ และเวลาที่ใช้ในการเรียนรู้ ยกเว้นตารางที่ 3 ที่ผลการจำลองแบบที่ 2 ดีกว่าแบบที่ 1 ในส่วนของเวลาที่ใช้ในการเรียนรู้ และค่า MAPE ของข้อมูลชุดทดสอบ ถึงแม้ว่าค่า MAPE ของข้อมูลชุดฝึกสอน ผลการจำลองแบบที่ 1 จะดีกว่าผลการจำลองแบบที่ 2

จากภาพที่ 3-5 จะเห็นว่ากราฟค่าพลังงานไฟฟ้าที่ได้จากการทำนายโดยวิธี ANN มีค่าใกล้เคียงค่าพลังงานไฟฟ้าที่ใช้จริงมากกว่าการทำนายโดยวิธีระบบ ANFIS อย่างเห็นได้ชัด โดยข้อมูลชุดฝึกสอนและชุดทดสอบของทั้ง 2 วิธี เป็นข้อมูลชุดเดียวกัน การทดสอบวิธี ANN ได้ค่า MAPE น้อยกว่าวิธี ANFIS แสดงให้เห็นว่าการทดลองนี้ประสิทธิภาพการทำนายโดย ANN ดีกว่า ANFIS



ภาพที่ 4 เปรียบเทียบผลการทดสอบ ANN(แบบที่ 2)และANFIS(แบบที่ 1) ภาคอุตสาหกรรมขนาดกลาง



ภาพที่ 5 เปรียบเทียบผลการทดสอบ ANN(แบบที่ 1)และANFIS(แบบที่1) ภาคอุตสาหกรรมขนาดใหญ่

6. บทสรุปและข้อเสนอแนะ

จากผลการทดลองแสดงให้เห็นถึงการทำนายการใช้พลังงานไฟฟ้าภาคอุตสาหกรรมของการไฟฟ้าส่วนภูมิภาคโดยวิธีโครงข่ายประสาทเทียม (ANN) เปรียบเทียบกับวิธีระบบอนุมานฟuzzyโครงข่ายปรับตัวได้ (ANFIS) ผลที่ได้จากการจำลองนี้คือ ค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของ ANN มีค่าน้อยกว่า ANFIS จากการใช้ข้อมูลในการฝึกสอนและทดสอบชุดเดียวกัน หมายถึงข้อมูลที่น่ามาใช้ในการทดลองนี้เหมาะสมกับ ANN มากกว่า ทำให้ ANN มีประสิทธิภาพดีกว่า ANFIS

และการทดสอบเพิ่มเติมจะต้องดำเนินต่อไปเพื่อเพิ่มประสิทธิภาพในการทำนายให้มีความถูกต้องแม่นยำยิ่งขึ้น โดยปรับเปลี่ยนตัวแปรอื่นๆ เช่น ใช้ข้อมูลค่าอุณหภูมิย้อนหลัง ข้อมูลค่าความชื้นสัมพัทธ์ย้อนหลัง เป็นต้น ซึ่งเป็นแนวทางในการทำวิจัยต่อไป

7. กิตติกรรมประกาศ

ผู้วิจัยขอขอบพระคุณ การไฟฟ้าส่วนภูมิภาค และกรมอุตุนิยมวิทยาเป็นอย่างสูง ที่เอื้อเฟื้อข้อมูลสำหรับงานวิจัยนี้

8. เอกสารอ้างอิง

- [1] Christiaanse, W.R., (1971) "Short-term load forecasting using exponential smoothing", IEEE.
- [2] Thompson, R.p. (1976) "Weather sensitive demand and energy analysis on a large geographically diverse power system: application to short-term hourly electric demand forecasting", IEEE.
- [3] Du, X, Tian, F. and Tan SG, (2010) "Study of Power System Short-term Load Forecast Based on Artificial Neural Network and Genetic Algorithm", IEEE.
- [4] Farahat M. A. and Talaat M., (2010) "A New Approach for Short-Term Load Forecasting Using Curve Fitting Prediction Optimized by Genetic Algorithms", MEPCON Proceedings., Paper ID 125.
- [5] Hinojosa V.H. and Hoese A., (2010) "Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", IEEE.
- [6] นฤมล ชิ่งเถียรตระกูล และสมชาติ จิรวิภากร. (เม.ย.-มิ.ย. 2549). การพยากรณ์โหลดระยะสั้นโดยใช้โครงข่ายประสาทเทียม.วารสารวิชาการพระจอมเกล้าพระนครเหนือ กรุงเทพฯ
- [7] Amit J. and Satish B., (Nov. 2008) "Integrated Approach for Short Term Load Forecasting using SVM and ANN", TENCON.
- [8] Vikram K., Akhil G. and Aggarwal, S, (Jan. 2014) "Artificial Neural Network Based Load Forecasting Using Levenberg-Marquardt Method", IJARCSSE., Vol. 4, Issue 1, pp. 403-407.
- [9] Thai, N. and Yuan L, (Nov. 2011) "Short-Term Load Forecasting Based on Adaptive Neuro-Fuzzy Inference System", JCP., Vol. 6, NO. 11, pp. 2267-2271.
- [10] สมชาติ จิรวิภากร. (2554). การประยุกต์ใช้งานโครงข่ายประสาทเทียมในระบบไฟฟ้ากำลัง.คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังกรุงเทพฯ
- [11] Jang. J.-S.R., (May/Jun. 1993) "ANFIS: Adaptive Network-Based Fuzzy Inference System", IEEE Trans. Syst., Cybern., vol. 23, pp. 665-685.
- [12] Jang. J.-S.R. and Chuen-Tsai S., (Mar. 1995) "Neuro-fuzzy modeling and control", IEEE Proceedings., vol. 83, no. 3, pp. 378-406.