

แบบจำลองการใช้พลังงานไฟฟ้าของสิ่งอำนวยความสะดวกและการทำนายโหลดระยะปานกลางด้วยโครงข่ายประสาทเทียมและระบบอนุมานฟัซซีโครงข่ายปรับตัวได้

Facility Energy Usage Modeling and Medium Term Load Forecasting With Artificial Neural Networks And Adaptive Neuro-Fuzzy Inference Systems

ศุภเสกข์ เกตุรักษา และ สมชาติ จิรีวิภากร
สาขาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
Email : Sooppasek.katruksa@yahoo.com, kjsomcha@kmitl.ac.th

บทคัดย่อ

บทความนี้นำเสนอการสร้างแบบจำลองการใช้พลังงานของสิ่งอำนวยความสะดวกและการทำนายโหลดระยะปานกลางของอาคารคิวเฮ้าส์ลุมพินี เพื่อปรับปรุงประสิทธิภาพการใช้พลังงานในอาคารซึ่งสามารถประหยัดพลังงาน ลดค่าใช้จ่าย และปกป้องสิ่งแวดล้อม ในงานวิจัยนี้ได้ใช้โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) และระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ (ANFIS) เป็นแบบจำลองและทำนายการใช้พลังงานของสิ่งอำนวยความสะดวกในอาคารคิวเฮ้าส์ลุมพินี การทำนายขึ้นอยู่กับประวัติการใช้พลังงานของอาคาร การครอบครองอาคารของลูกค้า ซึ่งผลการทำนายโครงข่ายประสาทเทียมให้ผลการทำนายที่ดีกว่าระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ โดยผลการทดลองโครงข่ายประสาทเทียมมีค่าความผิดพลาดเฉลี่ยสมบูรณ์ (Mean Absolute Percentage Error : MAPE) ดีที่สุดเท่ากับ 1.2674 % ในส่วนของระบบอนุมานฟัซซีโครงข่ายปรับตัวมีค่า MAPE ดีที่สุดเท่ากับ 3.5157 %

คำสำคัญ

โครงข่ายประสาทเทียม ระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ แบบจำลองการใช้พลังงานไฟฟ้าของสิ่งอำนวยความสะดวก การทำนายโหลดระยะปานกลาง

Abstract

This paper presents facility energy usage modeling and medium term load forecasting for Qhouse Lumpini Building. Improving the energy efficiency of building can save energy, reduce cost, and protect the environment. In this research, Artificial Neural Network and Adaptive Neuro-Fuzzy Inference Systems are used to model and predict the facility power usage of Qhouse Lumpini building. The prediction is based on the building power usage history and occupancy rate. The results indicate

that ANN yields better performance than ANFIS. Artificial Neural Network has the best mean absolute percentage error of 1.2674 % whereas Adaptive Neuro-Fuzzy Inference Systems have the best mean absolute percentage error of 3.5157 %.

Keywords

Artificial Neural Networks, Adaptive Neuro-Fuzzy Inference Systems, Facility Energy Usage Modeling, Medium Term Load Forecasting

1. บทนำ

ด้วยแหล่งเชื้อเพลิงที่มีจำกัด และความต้องการพลังงานที่เพิ่มมากขึ้น การศึกษาการบริหารจัดการพลังงานได้มีความสำคัญมากขึ้น ระบบการบริหารจัดการประสิทธิภาพพลังงานในอาคาร สามารถใช้พลังงานได้อย่างเหมาะสม ปรับปรุงความสะดวกสบาย ลดต้นทุนการดำเนินงานในอาคาร และปกป้องสิ่งแวดล้อม


การบริหารจัดการสิ่งอำนวยความสะดวกเป็นสิ่งจำเป็นสำหรับการทำงานและบำรุงรักษาอาคาร การใช้พลังงานได้รวมเกี่ยวกับการดำเนินงานสิ่งอำนวยความสะดวกในอาคาร ได้แก่ การทำความร้อน การระบายอากาศ การปรับอากาศ แสงสว่าง การจ่ายน้ำประปา เป็นต้น

การทำนายการใช้พลังงานของอาคารบ่อยครั้งขึ้นอยู่กับสถิติ หรือการสร้างแบบจำลองเชิงตัวเลขของข้อมูลในอดีต อย่างเช่น รูปแบบการถดถอยเชิงเส้น อย่างไรก็ตาม รูปแบบเหล่านี้มักจะไม่ถูกต้อง และลำดับแบบจำลองถดถอยเชิงเส้นสูงมาก การวิจัยนี้แสดงให้เห็นว่าการใช้พลังงานในอาคารยังเกี่ยวกับการครอบครองอาคาร นอกจากนี้การประเมินการใช้พลังงานในอาคารยังขึ้นอยู่กับรูปแบบโครงสร้างทางกายภาพของอาคาร เช่นวัสดุที่ใช้อาคาร (เช่น แยกระหว่างภายในและภายนอกอาคาร ตัวอย่างเช่น ผนังก่ออิฐ) พื้นที่ในอาคาร วัสดุบนสุดของพื้น ความสูงของเพดาน ฯลฯ

บทความนี้ เน้นการสร้างแบบจำลองและการทำนายระยะปานกลาง การใช้พลังงานของสิ่งอำนวยความสะดวกในอาคารควิแฮร์สลุมนิ ข้อมูลการใช้พลังงานในอดีตและการครอบครองอาคารของลูกค้าได้ให้ไว้โดยแผนกช่างประจำอาคาร โดยการจำลองนี้ได้เปรียบเทียบผลการจำลองของโครงข่ายประสาทเทียมและระบบอนุมานฟัซซีโครงข่ายปรับตัวได้

2. รูปแบบโครงข่ายประสาทเทียมสำหรับการทำนายปริมาณการใช้พลังงานไฟฟ้า

ภาพที่ 1 แสดงองค์ประกอบของโครงข่ายประสาทซึ่งมี 2 ชั้นซ่อน ซึ่งนิวรอนในชั้นอินพุตจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นซ่อนแรก และทุกๆ นิวรอนในชั้นซ่อนแรกจะส่งสัญญาณไปยังทุกๆ นิวรอนชั้นที่สอง จนในที่สุดทุกๆ นิวรอนชั้นซ่อนที่ 2 จะส่งสัญญาณไปยังทุกนิวรอนในชั้นเอาต์พุต



ภาพที่ 1 รูปแบบโครงข่ายประสาทเทียมสำหรับทำนายการใช้พลังงานไฟฟ้า

Levenberg – Marquardt Algorithm เป็นตัวฝึกสอนโครงข่ายประสาท ซึ่งระหว่างฝึกสอนค่า weights และ biases จะถูกปรับโดยสมการ (1) และ (2) ตามลำดับ

$$\Delta W = (J^T(w)J(w) + \mu I)^{-1} J^T(w).e \quad (1)$$

$$\Delta b = (J^T(b)J(b) + \mu I)^{-1} J^T(b).e \quad (2)$$

โดยที่ $J(w)$ คือ Jacobian matrix ของ derivatives ของ error เทียบกับ weight

$J(b)$ คือ Jacobian matrix ของ derivatives ของ error เทียบกับ bias

e คือ matrix ของ errors ระหว่าง target data และ neural network output

μ คือ ค่าคงที่ ซึ่งค่าเริ่มต้นจะถูกเซตค่าต่ำๆ ในส่วนของชั้นซ่อนที่ 1 ชั้นซ่อนที่ 2 และชั้นเอาต์พุต ได้ทดลองใช้ linear transfer function, tan-sigmoid transfer function และ log-sigmoid transfer function สลับกันเพื่อหาค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสมบูรณ์ (mean absolute percentage error) น้อยที่สุด หาได้จากสมการที่ (3)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Real\ Result_i - Predicted\ Result_i}{Real\ Result_i} \right| \times 100\%$$

(3)

ก่อนฝึกสอนรูปแบบโครงข่ายประสาท จำนวนชั้นซ่อนและจำนวนเซลล์ซ่อนในแต่ละชั้นจะต้องระบุมิติหรือขนาดของโครงข่ายประสาทซึ่งอาจจะมีผลดีกับการเรียนรู้ของโครงข่ายประสาท โดยทั่วไปโครงข่ายประสาทขนาดใหญ่ (มีชั้นซ่อนมากหรือมีเซลล์ซ่อนมาก) สามารถประมาณฟังก์ชันไม่เชิงเส้นที่ซับซ้อนได้อย่างไรก็ตาม วิธีนี้อาจต้องการพื้นที่หน่วยความจำมากขึ้น และใช้เวลาในการคำนวณมาก นอกจากนี้ความสามารถทั่วไปอาจจะไม่ดี และเป็นสาเหตุของปัญหา Over Fitting (นั่นคือ โครงข่ายประสาทสามารถผ่านข้อมูลการฝึกสอนขณะที่ล้มเหลวในการสร้างเอาต์พุตที่ถูกต้องสำหรับข้อมูลการทดสอบ) อีกอย่างหนึ่ง โครงข่ายที่มีขนาดเล็กกว่า ทำงานเร็วกว่าแต่อาจได้รับข้อผิดพลาดของการฝึกสอนสูงขึ้น (เรียกว่า ปัญหา Under Fitting)

3. รูปแบบระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ (ANFIS)


3.1 โครงสร้าง ANFIS

เพื่อความเข้าใจสมมุติระบบอนุมานโดยฟัซซีภายใต้การพิจารณา 2 อินพุต คือ x และ y และ 1 เอาต์พุต f สำหรับโมเดลฟัซซี Sugeno ประกอบด้วย 2 ฟัซซี ใช้หลัก if – then ดังแสดงดังต่อไปนี้

กฎข้อที่ 1 : If x คือ A_1 และ y คือ B_1
then $f_1 = p_1x + q_1y + r_1$

กฎข้อที่ 2 : If x คือ A_2 และ y คือ B_2
then $f_2 = p_2x + q_2y + r_2$

เมื่อ p_1, q_1, r_1, p_2, q_2 และ r_2 เป็นพารามิเตอร์
ผลลัพธ์



ภาพที่ 2 แสดงโครงสร้างของ ANFIS

โครงสร้างของ ANFIS แสดงในภาพที่ 2 สามารถอธิบายได้ดังต่อไปนี้ (เอาต์พุตโหนด i ในชั้น l เช่น $(O_{l,i})$) ชั้นที่ 1 ทุกโหนด i ในชั้นนี้เป็นโหนดสี่เหลี่ยมซึ่งประกอบด้วยฟังก์ชันสมาชิกของตัวแปรอินพุตแต่ละตัว ดังนี้

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

เมื่อ x, y คือ อินพุตโหนดของโหนด i

A_i, B_{i-2} คือ สัญลักษณ์ทางภาษาที่เกี่ยวข้องกับฟังก์ชันสมาชิก

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

$O_{l,i}$ คือ ค่าฟังก์ชันสมาชิกของ A_i ที่เกิดจากค่า x ในงานวิจัยนี้ใช้ฟังก์ชันสมาชิกแบบ Gaussian function เพราะเป็นฟังก์ชันสมาชิกที่ทำให้ผลการทำนายมีความแม่นยำกว่าฟังก์ชันสมาชิกแบบอื่นโดยมีรูปแบบดังนี้

$$\mu_{A_i}(x) = e^{-\frac{(x-c_i)^2}{2\sigma_i^2}} \quad (5)$$

เมื่อ $c_{i,ai}$ คือ เซตพารามิเตอร์ พารามิเตอร์ในชั้นนี้

เรียกว่า พารามิเตอร์หลักฐาน (premise parameters)

ชั้นที่ 2 ทุกโหนดในชั้นนี้เป็นโหนดวงกลมสัญลักษณ์ π ซึ่งคือการคูณกันของสัญญาณที่เข้ามาและส่งออกไปเป็นเอาต์พุต ตัวอย่างเช่น

$$O_{2,i} = w_i \mu_{A_i}(x) \mu_{B_i}(y), i = 1, 2 \quad (6)$$

ชั้นที่ 3 ทุกโหนดในชั้นนี้เป็นโหนดวงกลมสัญลักษณ์ N ซึ่งจะทำการนอร์มอลไลซ์ค่าน้ำหนัก

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (7)$$

ชั้นที่ 4 ทุกโหนด i ในชั้นนี้เป็นโหนดสี่เหลี่ยมที่มีฟังก์ชันโหนด

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (8)$$

เมื่อ $\bar{w}_i$ คือ เอาต์พุตของชั้นที่ 3 และ $\{p_i, q_i, r_i\}$ เป็นเซตพารามิเตอร์ พารามิเตอร์ในชั้นนี้เรียกว่า พารามิเตอร์ที่เป็นผลลัพธ์ (Consequent parameter)

ชั้นที่ 5 ชั้นนี้มีโหนดเดียวเป็นโหนดวงกลมสัญลักษณ์ Σ ซึ่งเอาต์พุตที่ได้คือการรวมกันของสัญญาณเข้ามาทั้งหมด

$$O_{5,i} = \sum w_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (9)$$

3.2 ขั้นตอนวิธีการเรียนรู้แบบไฮบริด

ค่าพารามิเตอร์หลักฐาน (premise parameters) ที่ได้รับ เอาต์พุตทั้งหมดสามารถแสดงในรูปของผลรวมเชิงเส้นของพารามิเตอร์ที่เป็นผลลัพธ์ (consequent parameter) เพื่อให้ชัดเจนมากขึ้นเอาต์พุต f สามารถเขียนใหม่ได้ดังนี้

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2$$

$$\begin{aligned}
 &= w_1 f_1 + w_2 f_2 \\
 &= (w_1 x) p_1 + (w_1 y) q_1 + w_1 r_1 \\
 &\quad + (w_2 x) p_2 + (w_2 y) q_2 + w_2 r_2 \quad (10)
 \end{aligned}$$

ซึ่งเป็นเส้นตรงในพารามิเตอร์ที่เป็นผลลัพธ์ p_1, q_1, r_1, p_2, q_2 และ r_2 ดังนั้นขั้นตอนวิธีการเรียนรู้แบบไฮบริด ซึ่งมีการพัฒนาในส่วนก่อนหน้านี้สามารถนำมาใช้ได้โดยตรงมากขึ้น โดยเฉพาะในส่วน

คำนวณข้างหน้าของขั้นตอนวิธีการเรียนรู้แบบไฮบริด โหนดเอาต์พุตส่งผ่านไปข้างหน้าจนกระทั่งชั้นที่ 4 และพารามิเตอร์ที่เป็นผลลัพธ์ ถูกตรวจสอบโดยวิธีการกำลังสองน้อยที่สุด (Least Squares Method) ในส่วนการคำนวณค่าย้อนกลับสัญญาณค่าผิดพลาดถูกแพร่กลับมา และพารามิเตอร์หลักฐานถูกอัปเดตโดย gradient descent ดังแสดงในตารางที่ 1

ตารางที่ 1 แสดงกระบวนการการเรียนรู้แบบไฮบริดสำหรับ ANFIS

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

4. ข้อมูลที่ใช้เรียนรู้ของการจำลอง

ข้อมูลที่ใช้ในการเรียนรู้ในการศึกษานั้น ได้ใช้ข้อมูลความต้องการพลังงานไฟฟ้าในแต่ละเดือนและอัตราการครอบครองอาคารของลูกค้าแต่ละเดือนของอาคารคิวิเฮาส์ลุมพินี ตั้งแต่เดือนกันยายน 2549 ถึง เดือนตุลาคม 2555 ตัวอย่างข้อมูลแสดงในตารางที่ 2 ซึ่งการทำนายขึ้นอยู่กับประวัติการใช้พลังงานรหัสเดือนและการครอบครองอาคารของลูกค้า

ตารางที่ 2 แสดงอินพุตข้อมูลที่ใช้เรียนรู้


ลำดับ ที่	โหลดก่อนเดือน ทำนาย 3 เดือน (MWH)	โหลดก่อนเดือน ทำนาย 2 เดือน (MWH)	โหลดก่อนเดือน ทำนาย 1 เดือน (MWH)	รหัสเดือนที่ทำนาย (Month Code)	จำนวนการครอบครองอาคาร	
					ออฟฟิศให้เช่า (บริษัท)	ร้านค้าให้เช่า (ร้าน)
1	1457	1111	1457	12	55	50
2	1111	1457	1312	1	55	49
3	1457	1312	1326	2	68	49
4	1312	1326	1431	3	69	49
5	1326	1431	1415	4	77	50
6	1431	1415	1569	5	77	50
7	1415	1569	1645	6	77	50
8	1569	1645	1808	7	77	50
						•
						•
						•
51	1691	1809	1777	8	105	53
52	1809	1777	1826	9	105	53
53	1777	1826	1806	10	107	53

ตารางที่ 2 แสดงอินพุตข้อมูลที่ใช้เรียนรู้ (ต่อ)

ลำดับ ที่	โหลดก่อนเดือน ทำนาย 3 เดือน (MWH)	โหลดก่อนเดือน ทำนาย 2 เดือน (MWH)	โหลดก่อนเดือน ทำนาย 1 เดือน (MWH)	รหัสเดือนที่ทำนาย (Month Code)	จำนวนการครอบครองอาคาร	
					ออฟฟิศให้เช่า (บริษัท)	ร้านค้าให้เช่า (ร้าน)
54	1826	1806	1796	11	107	53
55	1806	1796	1834	12	106	53
56	1796	1834	1650	1	106	53
57	1834	1650	1743	2	106	53
58	1650	1743	1791	3	105	53
59	1743	1791	1744	4	105	53
60	1791	1744	1762	5	105	53
61	1744	1762	1796	6	107	53
62	1762	1796	1865	7	104	53
63	1796	1865	1840	8	104	53
64	1865	1840	1744	9	104	53
65	1840	1744	1874	10	104	53


5 ผลการจำลอง

หลังจากได้ทดลองโครงข่ายประสาทเทียมหลายครั้ง มีการเปลี่ยนจำนวนนิรอนแต่ละชั้นซ่อน ฟังก์ชันถ่ายโอน และ epoch ในส่วนของระบบอนุมานฟัซซี่โครงข่ายปรับตัวได้มีการเปลี่ยนฟังก์ชันสมาชิก และ epoch ผลการทดสอบเป็นที่น่าพอใจ ดังแสดงในภาพที่ 3 ภาพที่ 4 ตารางที่ 3 และ- ตารางที่ 4



ภาพที่ 3 แสดงผลการฝึกสอน

จากภาพที่ 3 แสดงให้เห็นว่ากราฟของพลังงานไฟฟ้าที่ได้จากการทำนายโดยโครงข่ายประสาทเทียมและระบบอนุมานฟัซซี่ปรับตัวได้ใกล้เคียงกับพลังงานไฟฟ้าที่ใช้จริง แสดงว่ามีการฝึกสอนได้อย่างแม่นยำทั้งสองระบบ



ภาพที่ 4 แสดงผลการทดสอบ

ตารางที่ 3 แสดงการเปรียบเทียบผลการทำนายการใช้พลังงานไฟฟ้าของ ANN และ ANFIS ของข้อมูลชุดทดสอบ

ลำดับที่	พลังงานไฟฟ้าที่ใช้จริง (MWH)	พลังงานไฟฟ้าที่ได้จากการทำนาย (MWH)	
		ANN	ANFIS
1	1834	1786.8	1790
2	1650	1669.7	1820
3	1743	1760.4	1760
4	1791	1804.9	1760
5	1744	1755.3	1560
6	1762	1806.9	1770
7	1796	1793	1790
8	1865	1827.2	1810
9	1840	1820	1820
10	1744	1764.7	1800
11	1874	1851.3	1740
12	1819	1804.6	1800

ตารางที่ 4 แสดงการเปรียบเทียบข้อมูลและค่าผิดพลาดระหว่าง ANN และ ANFIS

	ANN	ANFIS
Model	Back-Propagation	Sugeno
Transfer Function, MF	1st Layer Tan-Sigmoid	Input 1 Number of MFs 3, gaussmf
	2nd Layer Tan-Sigmoid	Input 2 Number of MFs 3, gaussmf
	Output Layer Tan-Sigmoid	Input 3 Number of MFs 3, gaussmf
		Input 4 Number of MFs 3, gaussmf
		Input 5 Number of MFs 3, gaussmf
		Input 6 Number of MFs 3, gaussmf
		Output MF, constant
Training (sets)	53	53
Testing (sets)	12	12
Training Method	Levenberg-Marquardt	Hybrid (Gradient Descent, LSE)
Epochs	1000	200
Train MAPE (%)	2.478E-01	1.4197E-01
Training Time (minute)	17.12	9.18
Test MAPE (%)	1.2674E+00	3.5157E+00

จากภาพที่ 4 และตารางที่ 3 จะเห็นว่ากราฟและค่าของพลังงานไฟฟ้าที่ได้จากการทำนายโดยโครงข่ายประสาทเทียมมีค่าใกล้เคียงกับพลังงานที่ใช้จริงกว่าระบบอนุมานฟuzzyโครงข่ายปรับตัวได้ จากตารางที่ 4 ข้อมูลชุดฝึกสอนและชุดทดสอบเป็นชุดเดียวกัน การทดสอบของโครงข่ายประสาทเทียมได้ค่าความผิดพลาดเฉลี่ยสมบูรณ์ (Mean Absolute Percentage Error : MAPE) น้อยกว่าระบบอนุมานฟuzzyโครงข่ายปรับตัวได้ แสดงให้ว่าประสิทธิภาพการทำนายโดยโครงข่ายประสาทเทียมดีกว่าระบบอนุมานฟuzzyปรับตัวได้

6 บทสรุปและข้อเสนอแนะ

วิธีการจำลองและการทำนายการใช้พลังงานไฟฟ้าในอาคารโดยโครงข่ายประสาทเทียมและระบบอนุมานฟuzzyโครงข่ายปรับตัวได้ที่ได้ศึกษาในบทความนี้

ผลการจำลองเป็นที่พอใจ โดยโครงข่ายประสาทเทียมและระบบอนุมานฟuzzyโครงข่ายปรับตัวได้มีค่า MAPE ของการฝึกสอนใกล้เคียงกัน ส่วนในการทดสอบโครงข่ายประสาทเทียมให้ค่า MAPE เท่ากับ 1.2674 % ซึ่งดีกว่าระบบอนุมานฟuzzyโครงข่ายปรับตัวได้ (MAPE เท่ากับ 3.5157 %) แต่โครงข่ายประสาทเทียมใช้เวลาเรียนรู้มากกว่า ซึ่งผลการจำลองนี้สามารถนำไปบริหารจัดการพลังงานไฟฟ้าในอาคาร และกำหนดค่า demand factor ในการออกแบบอาคารที่คล้ายกับที่ใช้ในงานวิจัยนี้ การทดสอบเพิ่มเติมจะต้องดำเนินการต่อไป เพื่อตรวจสอบประสิทธิภาพของแบบจำลองนี้ในอนาคต ตัวอย่างเช่นวิธีการนี้สามารถนำไปใช้ทดสอบโดยการรวบรวมข้อมูลของอาคารที่แตกต่างกัน จำนวนคนที่ใช้อาคาร เวลาทำงานของแต่ละบริษัทที่เข้าอาคาร การครอบครองอาคารเป็นตารางเมตร

คำขอบคุณ

ผู้เขียนขอขอบคุณ สำนักงานช่างอาคารคิวแฮร์ทล์มฟินีในการจัดหาข้อมูลที่ใช้ในวิจัยนี้

เอกสารอ้างอิง

- [1] สมชาติ จิรวิภากร. (2554). การประยุกต์ใช้งานโครงข่ายประสาทเทียมในระบบไฟฟ้ากำลัง (Applications of Neural Networks in power System). ครั้งที่ 1 คณะ-วิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- [2] นฤมล ชิงเกียรติตระกูล และสมชาติ จิรวิภากร. (2549). การพยากรณ์โหลดระยะสั้นโดยใช้โครงข่ายประสาทเทียม วารสารวิชาการพระจอมเกล้าพระนครเหนือ ปีที่ 16 ฉบับที่ 2.
- [3] Sunny W. and Xiao-Hua Y. (2010). “Facility Power Usage Modeling and Short Term Prediction with Artificial Neural Networks” Advance in Neural Networks-INSN 2010., Lecture Notes in Computer Science Volume 6064 , pp. 584 – 555.
- [4] Sivanandam S.N , Sumathi S. and Deepa S.N (2006). “Introduction to Neural Network” Tata McGraw-Hill Publishing Company Limited. NEW DELHI.
- [5] Technical Document 5 , Energy Vision 2020 Load Forecast.
- [6] Syed-Ahmad M.n, Bensenouci A. , Alghamdi Saleh A. and Abdel Ghany A.M. “Short –Term Load Forecasting Using Adaptive Neuro-Fuzzy Inference System (ANFIS) ” Electrical Technology College Of Technology At Al-Baha , Kingdom Of Saudi Arabia
- [7] ชัยโย ตระกูลไทยรักษ์ และ สมชาติ จิรวิภากร. (2555). การหาคำตอบอุป ตีโมลเพาเวอร์โพล์โดยใช้ระบบอนุมานฟัซซีโครงข่ายปรับตัวได้. วิศวกรรมสาร มก. ฉบับที่ 81 ปีที่ 25.
- [8] Jang. J.-S.R., 1993. “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, IEEE Trans. Syst., Man, Cyber., vol. 23, no. 3, pp. 665 - 685,.

