

บทที่ 4

วิธีการทดลอง

ในบทนี้จะเป็นวิธีการพยากรณ์ความต้องการพลังไฟฟ้าสูงสุด (Peak Demand) ระยะยาวในระบบของ กฟน. โดยใช้โครงข่ายประสาทเทียม โดยโครงข่ายประสาทเทียมที่ใช้จะเป็นแบบแพร่ค่าย้อนกลับ (Back-Propagation Neural networks) และโครงข่ายประสาทเทียมแบบ Generalized Regression (GRNN) โดยการนำปัจจัยที่เชื่อว่ามีผลต่อความต้องการพลังไฟฟ้าสูงสุด ซึ่งได้แก่ ค่าพลังงานไฟฟ้า (Energy) จำนวนผู้ใช้ไฟฟ้า และค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (Gross Regional Product:GRP) เป็นข้อมูลในการฝึกสอนและทดสอบโครงข่ายประสาทเทียม โดยใช้ Neural Networks Toolbox ของโปรแกรม MATLAB Version 6.5 ในการทดลอง



4.1 การเตรียมข้อมูล


ในการรวบรวมข้อมูลที่จะใช้ในการพยากรณ์ โดยการใช้ปัจจัยที่เชื่อว่ามีผลต่อการพยากรณ์ค่าความต้องการพลังไฟฟ้าดังกล่าวข้างต้นในวิทยานิพนธ์ฉบับนี้จะใช้ข้อมูลฝึกสอนและทดสอบโครงข่ายประสาทเทียมโดยใช้ ข้อมูลค่าพลังงานไฟฟ้า(Energy) ในช่วงปี พ.ศ.2531-2546 ข้อมูลจำนวนผู้ใช้ไฟฟ้า ในช่วงปี พ.ศ. 2531 – 2546 ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (Gross Regional Product:GRP) ในช่วงปี พ.ศ. 2531 – 2546 เป็นตัวแปรด้านอินพุตของโครงข่ายประสาทเทียม และข้อมูลความต้องการพลังไฟฟ้าสูงสุดของ กฟน. ในช่วงปี พ.ศ.2531 – 2546 เป็นตัวแปรด้านเอาต์พุตของโครงข่ายประสาทเทียม โดยลักษณะข้อมูลทั้ง 4 ชุดนี้ แสดงให้เห็นในตารางที่ 4.1 และกราฟใน รูปที่ 4.1 – 4.4

ในการพยากรณ์ความต้องการพลังไฟฟ้าสูงสุดของ กฟน. จะใช้ค่า GRP ตามค่าสมมติฐานในการพยากรณ์ทางเศรษฐกิจไทย 3 ระดับ ของสถาบันวิจัยเพื่อการพัฒนาประเทศไทย คือ กรณีสเศรษฐกิจขยายตัวช้า(LEG) กรณีสเศรษฐกิจขยายตัวปานกลาง(MEG) และกรณีสเศรษฐกิจขยายตัวตามเป้าหมาย(TEG) ในส่วนของจำนวนผู้ใช้ไฟฟ้า และค่าพลังงานไฟฟ้า จะใช้ค่าพยากรณ์ของ กฟน. ในการพยากรณ์ความต้องการพลังไฟฟ้าสูงสุด ในช่วงปี 2547 -2559


ตารางที่ 4.1 ข้อมูลที่ใช้เป็นชุดฝึกสอนและทดสอบโครงข่ายประสาทเทียม

Year	Peak Demand (MW)	Energy(GWh)	Number of Customer	GRP (Million Baht)
1988 (2531)	2,432.15	13,872.87	1,133,473	689,015
1989 (2532)	2,714.50	15,769.77	1,209,906	785,864
1990 (2533)	3,123.50	18,285.72	1,296,748	926,237
1991 (2534)	3,519.40	20,322.90	1,404,931	998,504
1992 (2535)	3,992.60	22,329.80	1,520,687	1,071,168
1993 (2536)	4,346.00	24,510.44	1,626,367	1,169,980
1994 (2537)	4,754.75	27,115.95	1,730,569	1,235,094
1995 (2538)	5,336.70	29,781.01	1,851,080	1,327,239
1996 (2539)	5,636.50	31,521.95	1,915,907	1,371,186
1997 (2540)	5,938.50	32,306.95	2,025,364	1,117,505
1998 (2541)	5,657.20	30,475.29	2,052,033	983,401
1999 (2542)	5,356.82	29,826.64	2,106,517	1,095,992
2000 (2543)	5,799.70	32,274.41	2,192,052	1,149,695
2001 (2544)	6,228.58	33,842.68	2,248,209	1,187,595
2002 (2545)	6,418.08	35,780.97	2,312,346	1,211,211
2003 (2546)	6,825.04	37,430.61	2,382,727	1,249,471

Demand(MW)**รูปที่ 4.1** ความต้องการพลังไฟฟ้าสูงสุดของ กฟน. ในช่วงปี พ.ศ.2531 – 2546**Energy(GWh)****รูปที่ 4.2** พลังงานไฟฟ้า ในช่วงปี พ.ศ.2531 – 2546



รูปที่ 4.3 จำนวนผู้ใช้ไฟฟ้า ในช่วงปี พ.ศ.2531 – 2546



รูปที่ 4.4 ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กพน. (GRP) ในช่วงปี พ.ศ.2531 – 2546

4.2 การพิจารณาความสัมพันธ์ระหว่างข้อมูลอินพุตและข้อมูลเอาต์พุต

จากกราฟแสดงข้อมูลของปัจจัยทั้ง 3 ค่า และค่าความต้องการพลังไฟฟ้าสูงสุดในปี พ.ศ. 2531-2546 สามารถหาความสัมพันธ์ระหว่างปัจจัยที่มีผลต่อค่าพยากรณ์นั้นคือตัวแปรด้านอินพุตของโครงข่ายประสาทเทียม(ข้อมูลค่าพลังงานไฟฟ้า(Energy) ข้อมูลจำนวนผู้ใช้ไฟฟ้า ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) ในช่วงปี พ.ศ.2531 – 2546) และตัวแปรด้านเอาต์พุต (ความต้องการพลังไฟฟ้าสูงสุดของ กฟน. ในช่วงปี พ.ศ.2531 – 2546) โดยใช้โปรแกรม SPSS หาสัมประสิทธิ์การตัดสินใจพหุคูณ (Coefficient of Multiple Determination) และสัมประสิทธิ์สหสัมพันธ์พหุคูณ (Coefficient of Multiple Correlation) เพื่อพิจารณาว่าค่าตัวแปรด้านอินพุตและเอาต์พุตสัมพันธ์กันมากน้อยเพียงใด

4.2.1 สัมประสิทธิ์การตัดสินใจพหุคูณ (Coefficient of Multiple Determination) [22]

เป็นสัดส่วน หรือเปอร์เซ็นต์ที่ตัวแปรอิสระ $X_1, X_2, \dots, X_k$ สามารถอธิบายการเปลี่ยนแปลงของ Y ได้ หรือกล่าวได้ว่าเป็นสัดส่วนหรือเปอร์เซ็นต์ของความผันแปร Y ที่มีสาเหตุมาจากความผันแปรของ $X_1, X_2, \dots, X_k$ ซึ่งจะใช้สัญลักษณ์ $R^2_{Y.123\dots k}$ แต่โดยทั่วไปจะใช้ R^2

$$r^2 = R^2 = \frac{\text{ความผันแปรของ } Y \text{ เนื่องจากอิทธิพลของ } X_1, X_2, \dots, X_k}{\text{ความผันแปรทั้งหมด}} \\ = \frac{SSR}{SST}$$

$$\text{หรือ} \quad r^2 = R^2 = \frac{(SST - SSE)}{SST} = 1 - \frac{SSE}{SST} \quad (4.1)$$

โดยที่ $0 \leq R^2, r^2 \leq 1$

SST(Sum Square of Total) คือ ค่าแปรปรวนทั้งหมดของ Y

SSR (Sum Square of Regression) คือ ค่าแปรปรวนของ Y เนื่องจากอิทธิพลของ $X_1, X_2, \dots, X_k$

SSE(Sum Square of Error) คือ ค่าแปรปรวนของ Y เนื่องจากอิทธิพลอื่นๆ

ถ้า R^2 ที่เข้าใกล้ 1 จะหมายถึง $X_1, X_2, \dots, X_k$ มีความสัมพันธ์กับ Y มาก แต่ถ้า R^2 ที่เข้าใกล้ 0 จะหมายถึง $X_1, X_2, \dots, X_k$ มีความสัมพันธ์กับ Y น้อย

4.2.2 สัมประสิทธิ์สหสัมพันธ์พหุคูณ (Coefficient of Multiple Correlation) [22]

เป็นค่าที่วัดทิศทางและระดับความสัมพันธ์ระหว่างตัวแปรตาม Y และตัวแปรอิสระทั้งหมดรวมกัน โดยมีค่าเท่ากับรากที่สองของสัมประสิทธิ์การตัดสินใจพหุคูณ

$$r_{Y.12\dots k} = r = \sqrt{R_{Y.12\dots k}^2} \quad \text{โดยที่ } 0 \leq r \leq 1 \quad (4.2)$$

ถ้าค่า r เข้าใกล้ 0 แสดงว่า Y มีความสัมพันธ์กับ $X_1, X_2, \dots, X_k$ น้อยมาก และถ้าค่า r เท่ากับ 0 แสดงว่า Y ไม่มีความสัมพันธ์กับ $X_1, X_2, \dots, X_k$ เลย แต่ถ้าค่า r เท่ากับ 1 แสดงว่า Y มีความสัมพันธ์กับตัวแปรอิสระ k ตัวมาก ซึ่งจาก Correlation จะทำให้ทราบดังนี้

1. เครื่องหมายของ r จะบอกถึงทิศทางของความสัมพันธ์ระหว่างตัวแปร

บวก	เมื่อตัวแปรตัวหนึ่งเพิ่มขึ้นแล้ว อีกตัวแปรหนึ่งจะเพิ่มขึ้นด้วย
ลบ	เมื่อตัวแปรตัวหนึ่งเพิ่มขึ้นแล้ว อีกตัวแปรหนึ่งจะลดลง
ใกล้ศูนย์	ตัวแปรทั้งหมดไม่มีความสัมพันธ์ซึ่งกันและกัน


2. ขนาดของ r จะบอกถึง Strength ของความสัมพันธ์ ซึ่งถ้าห่างจากศูนย์มากขึ้นแสดงว่ายังมีความสัมพันธ์มากขึ้น

4.2.3 การหาความสัมพันธ์ระหว่างตัวแปร


วิธีการคือสร้างสมการแสดงความสัมพันธ์ของตัวแปรด้านอินพุตและตัวแปรด้านเอาต์พุต โดยใช้วิธี Multiple Linear Regression ด้วยโปรแกรม SPSS Version 11 โดยกำหนดให้ตัวแปรด้านอินพุตเป็นตัวแปรอิสระ (Independent Variable) และตัวแปรเอาต์พุตเป็นตัวแปรตาม (Dependent Variable) โดยมีขั้นตอนดังนี้

1. สร้างฐานข้อมูลตัวแปรด้านอินพุต ซึ่งได้แก่ ค่าพลังงานไฟฟ้า (Energy) จำนวนผู้ใช้ไฟฟ้า ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) และข้อมูลตัวแปรด้านเอาต์พุต ซึ่งได้แก่ ค่าความต้องการพลังไฟฟ้าสูงสุดในพื้นที่ กฟน. (Demand)


2. Plot กราฟเพื่อดูความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตามที่ละคู่ดังแสดงในกราฟรูปที่ 4.5 – 4.7



รูปที่ 4.5 กราฟแสดงความสัมพันธ์ระหว่าง Demand กับ Energy



รูปที่ 4.6 กราฟแสดงความสัมพันธ์ระหว่าง Demand กับ จำนวนผู้ใช้ไฟฟ้า



รูปที่ 4.7 กราฟแสดงความสัมพันธ์ระหว่าง Demand กับ GRP

จากกราฟความสัมพันธ์ระหว่างตัวแปรอินพุตและตัวแปรเอาต์พุตในแต่ละคู่จะมีความสัมพันธ์ในลักษณะที่มีการกระจายมีแนวโน้มที่จะเป็นเส้นตรงซึ่งถือได้ว่ามีความสัมพันธ์กันในลักษณะที่เป็นเชิงเส้น

3. จากข้อที่ 2 เราสามารถตรวจสอบถึงระดับความสัมพันธ์ของตัวแปรแต่ละตัวได้โดยการวิเคราะห์หาค่าสัมประสิทธิ์สหสัมพันธ์หรือ Correlation ได้ผลดังตารางที่ 4.2

จากตารางที่ 4.2 จะเห็นได้ว่าค่าความต้องการพลังไฟฟ้าสูงสุด (Demand) จะมีความสัมพันธ์กับค่าพลังงานไฟฟ้า (Energy) มากที่สุด ($r = 0.999$) รองลงมาคือ จำนวนผู้ใช้ไฟฟ้า ($r = 0.984$) และค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน.(GRP) น้อยที่สุด ($r = 0.776$)

4. วิเคราะห์หาสมการแสดงความสัมพันธ์ระหว่างตัวแปรอินพุตและตัวแปรเอาต์พุตโดยใช้วิธี Linear Regression จากนั้นพิจารณาความสัมพันธ์ของตัวแปรได้ดังตารางที่ 4.3

จากตารางที่ 4.3 ค่าสัมประสิทธิ์ในการตัดสินใจ (R Square) มีค่าเท่ากับ 0.998 อธิบายได้ว่าตัวแปรด้านอินพุตสามารถอธิบายการเปลี่ยนแปลงของตัวแปรเอาต์พุตได้ถึง 99.8% ดังนั้นจึงสรุปได้ว่าตัวแปรอินพุตเป็นปัจจัยที่มีผลต่อตัวแปรเอาต์พุต จึงเชื่อว่าจะสามารถนำไปใช้ในการพยากรณ์ได้อย่างแม่นยำ

ตารางที่ 4.2 ผลลัพธ์ของการหา Correlation ระหว่างตัวแปร

Correlations		DEMAND	ENERGY	CUSTOMER	GRP
DEMAND	Pearson Correlation	1	.999**	.984**	.776*
	Sig. (2-tailed)	.	.000	.000	.000
	N	16	16	16	16
ENERGY	Pearson Correlation	.999**	1	.982**	.797*
	Sig. (2-tailed)	.000	.	.000	.000
	N	16	16	16	16
CUSTOMER	Pearson Correlation	.984**	.982**	1	.699*
	Sig. (2-tailed)	.000	.000	.	.003
	N	16	16	16	16
GRP	Pearson Correlation	.776*	.797*	.699*	1
	Sig. (2-tailed)	.000	.000	.003	.
	N	16	16	16	16

** . Correlation is significant at the 0.01 level (2-tailed).

ตารางที่ 4.3 ผลลัพธ์ของการวิเคราะห์โดยใช้วิธี Linear Regression


Model Summary				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.999 ^a	.998	.998	62.34691

a. Predictors: (Constant), GRP, CUSTOMER, ENERGY

4.2.4 การพิจารณาปัจจัยอื่นๆที่มีผลต่อความต้องการพลังงานไฟฟ้าสูงสุด

บทความใน[5] – [7] ได้กล่าวถึงปัจจัยที่มีผลต่อการพยากรณ์ค่าความต้องการพลังงานไฟฟ้าสูงสุดระยะยาวซึ่งมีอยู่หลายปัจจัย ได้แก่ อุณหภูมิ ราคาไฟฟ้า GDP GNP ฯลฯ และได้ทำการพิจารณาปัจจัยเหล่านี้ว่ามีผลต่อค่าความต้องการพลังงานไฟฟ้าสูงสุดมากน้อยเพียงใด วิทยานิพนธ์ฉบับนี้จึงได้ทำการพิจารณาปัจจัยอื่นๆที่สามารถหาได้ มาทำการทดลองหาความสัมพันธ์ระหว่างตัวแปรอินพุตและเอาต์พุตดังที่ได้พิจารณาในหัวข้อ 4.2.3 เพื่อดูความเป็นไปได้ในการนำปัจจัยอื่นๆเพิ่มเติม เพื่อฝึกสอนโครงข่ายประสาทเทียมให้สามารถพยากรณ์ได้อย่างแม่นยำต่อไป


งานวิจัยนี้จะพิจารณาปัจจัยอุณหภูมิสูงสุดในรอบปี เพื่อเป็นตัวแปรเพิ่มเติมในการพยากรณ์ โดยมีข้อมูลแสดงดังรูปที่ 4.8



รูปที่ 4.8 ค่าอุณหภูมิสูงสุดในรอบปี ในช่วงปี พ.ศ.2531 – 2546

ทำการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอินพุตและเอาต์พุตตามหัวข้อที่ 4.2.3 โดยใช้โปรแกรม SPSS Version 11 ได้ผลดังรูปที่ 4.9

จากนั้นทำการวิเคราะห์หา Corelation ระหว่างตัวแปรอินพุตและเอาต์พุตได้ผลดังตารางที่ 4.4



รูปที่ 4.9 กราฟแสดงความสัมพันธ์ระหว่าง Demand กับ อุณหภูมิสูงสุดในรอบปี

ตารางที่ 4.4 ผลลัพธ์ของการวิเคราะห์โดยใช้วิธี Linear Regression

Correlations

		DEMAND	MAX_TEMP
DEMAND	Pearson Correlation	1	-.005
	Sig. (2-tailed)	.	.987
	N	16	16
MAX_TEMP	Pearson Correlation	-.005	1
	Sig. (2-tailed)	.987	.
	N	16	16

จากผลการหาความสัมพันธ์ระหว่างตัวแปรพบว่าค่า Correlation (r) มีค่าเท่ากับ -0.005 นั้นแสดงว่าตัวแปรอุณหภูมิมีผลต่อค่าความต้องการพลังไฟฟ้าสูงสุดน้อยมาก จึงไม่ควรนำมาพิจารณาเป็นตัวแปรอินพุตในการพยากรณ์

ในส่วนของราคาค่าไฟฟ้านั้น ในแต่ละปีจะมีราคาเท่ากัน และจะมีการปรับราคาค่าไฟฟ้าเป็นบางครั้ง เมื่อเปรียบเทียบปริมาณการใช้ไฟฟ้าที่เพิ่มขึ้นทุกปีนั้นพบว่า การเพิ่มขึ้นของตัวแปรทั้งสองยังไม่สอดคล้องกัน จึงเชื่อว่าราคาค่าไฟฟ้ายังไม่ใชปัจจัยที่มีผลต่อค่าความต้องการพลังไฟฟ้าสูงสุด

4.3 การพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับ(Back propagation Neural Networks)

4.3.1 การกำหนดข้อมูลชุดฝึกสอนและชุดทดสอบ

จากข้อมูลปีจ้อยทั้ง 3 ค่า และค่าความต้องการพลังไฟฟ้าสูงสุดในปี พ.ศ. 2531 – 2546 จะนำข้อมูลแต่ละชุดมาแบ่งเป็นชุดฝึกสอนและชุดทดสอบ เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมไปใช้ในการพยากรณ์ความต้องการพลังไฟฟ้าสูงสุดในปี 2547 – 2559 โดยจะแบ่งข้อมูลเป็น 3 ชุด ดังนี้

1. ชุดข้อมูลฝึกสอน (Training)

- ข้อมูลค่าพลังงานไฟฟ้า ในช่วงปี พ.ศ.2531 – 2543
- จำนวนผู้ใช้ไฟฟ้า ในช่วงปี พ.ศ.2531 – 2543
- ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) ในช่วงปี พ.ศ.2531 – 2543
- ความต้องการพลังไฟฟ้าสูงสุดของ กฟน. ในช่วงปี พ.ศ.2531 – 2543

2. ชุดข้อมูลทดสอบ (Testing)

- ข้อมูลค่าพลังงานไฟฟ้า ในช่วงปี พ.ศ.2544 – 2546
- จำนวนผู้ใช้ไฟฟ้า ในช่วงปี พ.ศ.2544 – 2546
- ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) ในช่วงปี พ.ศ.2544 – 2546
- ความต้องการพลังไฟฟ้าสูงสุดของ กฟน. ในช่วงปี พ.ศ.2544 – 2546

3. ชุดข้อมูลพยากรณ์ (Forecasting)

- ข้อมูลค่าพลังงานไฟฟ้า ในช่วงปี พ.ศ.2547 – 2559
- จำนวนผู้ใช้ไฟฟ้า ในช่วงปี พ.ศ.2547 – 2559
- ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) ในช่วงปี พ.ศ.2547 – 2559

การทดลองจะเป็นการหาโครงสร้างของโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่เหมาะสมกับการพยากรณ์ความต้องการพลังไฟฟ้าสูงสุด โดยทำการฝึกสอนและทดสอบโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับ ในแต่ละครั้งของการทดสอบก็จะวัดประสิทธิภาพของโครงข่ายประสาทเทียมเพื่อเปรียบเทียบกัน โดยดูจากค่าเปอร์เซ็นต์เฉลี่ยผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) ของชุดทดสอบ ถ้าโครงสร้างใดที่ให้ค่า MAPE ของชุดทดสอบมีค่าต่ำสุดแสดงว่าโครงข่ายประสาทเทียมแบบนั้นมีประสิทธิภาพดีที่สุด สำหรับการหาค่า MAPE นั้นเราสามารถหาได้จากสมการดังนี้

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Peak\ Demand_{actual, i} - Peak\ Demand_{ANN, i}}{Peak\ Demand_{actual, i}} \right| \times 100\% \quad (4.3)$$

โดยที่ $Peak\ Demand_{ANN}$ คือ ค่าความต้องการไฟฟ้าสูงสุดที่ได้จากโครงข่ายประสาทเทียม

$Peak\ Demand_{actual}$ คือ ค่าความต้องการไฟฟ้าสูงสุดที่เกิดขึ้นจริง
 N คือ จำนวนข้อมูลของชุดทดสอบ

การพิจารณาปัจจัยที่มีผลต่อการเรียนรู้ของโครงข่ายประสาทเทียมในวิทยานิพนธ์ฉบับนี้ยังได้ทดลองพิจารณาปัจจัยที่ใช้ฝึกสอนและทดสอบโครงข่ายประสาทเทียมที่มีความสัมพันธ์กันมาก ซึ่งได้แก่ ค่าพลังงานไฟฟ้า และจำนวนผู้ใช้ไฟฟ้า โดยทดลองตัดปัจจัยค่าพลังงานไฟฟ้าออก แล้วทำการฝึกสอนและทดสอบโครงข่ายประสาทเทียม เพื่อพิจารณาค่า MAPE ของชุดทดสอบจะต่างจากกรณีที่มีปัจจัยทั้งสามอย่างไร โดยจะแสดงผลการทดลองในบทที่ 5 ต่อไป

4.3.2 โครงสร้างของโครงข่ายประสาทเทียม

ในการหาโครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมจะต้องมีการพิจารณาถึงปัจจัยหลายประการ โดยการพิจารณาค่าเปอร์เซ็นต์เฉลี่ยผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) ของชุดทดสอบ ถ้าโครงสร้างใดที่ให้ค่า MAPE ของชุดทดสอบมีค่าต่ำสุดแสดงว่าโครงข่ายประสาทเทียมแบบนั้นมีประสิทธิภาพดีที่สุด ดังที่ได้กล่าวมาแล้วในบทที่ 2 ว่าโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับประกอบด้วยชั้นอินพุต ชั้นซ่อน และชั้นเอาต์พุต ในวิทยานิพนธ์ฉบับนี้ได้ป้อนข้อมูลในชั้นอินพุตเป็น ข้อมูลค่าพลังงานไฟฟ้า(Energy) ข้อมูลจำนวนผู้ใช้ไฟฟ้า ค่าผลิตภัณฑ์มวลรวมในพื้นที่ กฟน. (GRP) และชั้นเอาต์พุตจะเป็นข้อมูลค่าความต้องการพลังงานไฟฟ้าสูงสุดของ กฟน. โดยจะทำการทดลองตัดชุดข้อมูลอินพุตคือค่าพลังงานไฟฟ้าออกด้วย ในส่วนของชั้นซ่อนจะทำการปรับเปลี่ยนจำนวนเซลล์ประสาทและจำนวนชั้นซ่อนเป็น 1 ชั้นและ 2 ชั้น ในวิทยานิพนธ์ฉบับนี้ได้ทำการทดสอบโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่มีชั้นซ่อน 1 ชั้นและ 2 ชั้น โดยในการทดสอบโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่มีชั้นซ่อน 1 ชั้นนั้นจะทำการฝึกสอนโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นซ่อนตั้งแต่ 2 โหนด ไปจนถึง 16 โหนด เพื่อหาจำนวนโหนดในชั้นซ่อนที่ดีที่สุดที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพดีที่สุด สำหรับการทดสอบด้วยโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่มีชั้นซ่อน 2 ชั้นนั้นจะกำหนดให้จำนวนโหนดของชั้นซ่อนที่ 1 มากกว่าจำนวนโหนดของชั้นซ่อนที่ 2 อยู่จำนวน 1 โหนด และจะทำการฝึกสอนโครงข่ายประสาทเทียมที่มีจำนวนโหนดชั้นซ่อนที่ 1 จำนวน 2 โหนด และจำนวนโหนดในชั้นซ่อนที่ 2 จำนวน 1 โหนด ไปจนถึงโครงสร้างที่มีจำนวนโหนดในชั้นซ่อนที่ 1 จำนวน 16 โหนด และจำนวนโหนดในชั้นซ่อนที่ 2 มีจำนวน 15 โหนด

ในส่วนของชั้นซ่อนและชั้นเอาต์พุตจะมีการปรับเปลี่ยนฟังก์ชันถ่ายโอน คือ ถ่ายโอนชนิด Purelinear , Log-sigmoid และ Tan-sigmoid ดังสมการที่ (4.4) (4.5) และ (4.6) ตามลำดับ

$$f(n) = n \quad (4.4)$$

$$f(n) = \frac{1}{1 + e^{-n}} \quad (4.5)$$

$$f(n) = \frac{1 - e^{-n}}{1 + e^n} \quad (4.6)$$

4.3.3 การฝึกสอนโครงข่ายประสาทเทียม

ในวิทยานิพนธ์นี้ได้ทำการฝึกสอนโครงข่ายประสาทเทียมแบบ Back-propagation Neural Network โดยใช้วิธีของ Levenberg-Marquardt Algorithm ในการปรับค่าถ่วงน้ำหนักและค่าไบแอสที่ได้กล่าวมาแล้วในบทที่ 2 โดยในการฝึกสอนจะได้ทำการกำหนดเงื่อนไขในการฝึกสอนดังนี้

4.3.3.1 ค่าเริ่มต้นที่ใช้เป็นค่าถ่วงน้ำหนัก (weight) และค่าไบแอส (bias)

ในการเลือกค่าเริ่มต้นที่จะใช้เป็นค่าถ่วงน้ำหนักและค่าไบแอสในการสอนโครงข่ายประสาทเทียมในการทดลองครั้งนี้ จะใช้วิธีการให้โปรแกรมทำการสุ่มเลือกค่าถ่วงน้ำหนักและค่าไบแอส

4.3.3.2 ลำดับขั้นตอนการปรับค่าถ่วงน้ำหนักและค่าไบแอส

ในการทดสอบนี้ได้กำหนดให้มีการปรับค่าถ่วงน้ำหนักและค่าไบแอสเป็นจำนวน 1,000 ครั้ง (Epoch) โดยได้กำหนดให้ทำการปรับค่าถ่วงน้ำหนักและค่าไบแอสด้วยจำนวนนี้ในทุกการทดสอบเพื่อเปรียบเทียบเวลาที่ใช้ในการฝึกสอน ในการปรับค่าถ่วงน้ำหนักและค่าไบแอสในแต่ละรอบนั้นจะทำการคำนวณหาค่าผิดพลาดของค่าตอบของข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบแต่ละชุด เพื่อเปรียบเทียบค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Square Error : MSE) ของชุดข้อมูลทดสอบในรอบการคำนวณปัจจุบันกับค่า MSE ของข้อมูลทดสอบที่ได้จากการคำนวณในรอบก่อนหน้านี้ และบันทึกค่าถ่วงน้ำหนักและค่าไบแอสในรอบที่ทำให้ค่า MSE ของข้อมูลชุดทดสอบมีค่าต่ำที่สุด

4.3.3.3 จำนวนรอบของการฝึกสอน

จากที่ได้กล่าวมาแล้วว่าในวิทยานิพนธ์ฉบับนี้ได้ทำการปรับค่าถ่วงน้ำหนักและค่าไบแอสเป็นจำนวน 1,000 ครั้ง ซึ่งเมื่อโครงข่ายประสาทเทียมทำการปรับค่าถ่วงน้ำหนักและค่าไบแอสจนครบ 1,000 ครั้งแล้ว เราจะถือว่าเป็นหนึ่งรอบของการฝึกสอน หลังจากจบหนึ่งรอบการฝึกสอนแล้วก็จะทำการสุ่มค่าถ่วงน้ำหนักเริ่มต้นขึ้นมาใหม่ ซึ่งจะเป็นค่าที่ต่างจากค่าเริ่มต้นที่ผ่านมา และจะทำจนครบจำนวนรอบที่เราได้กำหนดไว้ โดยในวิทยานิพนธ์ฉบับนี้ได้กำหนดให้จำนวนรอบของการฝึกสอนในแต่ละโครงสร้างของโครงข่ายประสาทเทียมคือ 30 รอบต่อโครงสร้าง และเราจะเลือกรอบของการฝึกสอนที่ทำให้ค่า MAPE ของชุดทดสอบมีค่าต่ำที่สุด

4.3.3.4 เงื่อนไขของการสิ้นสุดการฝึกสอน


ในการฝึกสอนโครงข่ายประสาทเทียมและใช้กระบวนการปรับค่าถ่วงน้ำหนักและค่าไบอัสด้วยวิธี Levenberg-Marquardt Algorithm นั้นจะมีเงื่อนไขพื้นฐานที่เกี่ยวข้องกับการสิ้นสุดการฝึกสอนดังนี้

- ค่า Gradient Factor เป็นพารามิเตอร์หนึ่งที่ใช้ในการพิจารณาถึงการสิ้นสุดของการฝึกสอน (ค่า g ในสมการที่ 2.2) ในการปรับค่าถ่วงน้ำหนักและค่าไบอัสแต่ละรอบนั้นค่า Gradient Factor จะเปลี่ยนแปลงไปขึ้นอยู่กับค่าผิดพลาด (e) ที่เกิดขึ้นใน Epoch นั้น ๆ โดยการฝึกสอนจะสิ้นสุดลงเมื่อ Gradient Factor มีค่าน้อยกว่า $1e^{-10}$
- ค่า Mu Factor ค่า μ หรือ Learning Factor ในสมการที่ 2.1 เป็นค่าคงที่ที่ใช้เร่งการปรับค่าถ่วงน้ำหนักและค่าไบอัสให้ลู่เข้าหาคำตอบ ในการปรับค่าถ่วงน้ำหนักและค่าไบอัสแต่ละรอบนั้นหากค่า Gradient Factor มีค่าเพิ่มขึ้น จะมีการปรับค่า μ ให้เพิ่มขึ้นจนกระทั่งค่า Gradient Factor มีแนวโน้มที่จะลดลง จากนั้นค่า μ จะถูกปรับลดลงเรื่อย ๆ และมีการปรับเพิ่มขึ้นอีกครั้งเมื่อค่า Gradient Factor มีค่าเพิ่มขึ้น โดยที่ค่า μ เริ่มต้นจะมีค่าเท่ากับ 0.001 การปรับค่า μ เพิ่มขึ้นนั้นจะทำได้โดยการคูณด้วย Increased Factor ซึ่งมีค่าเท่ากับ 10 และการปรับค่า μ ลดลงนั้นจะทำได้โดยการคูณด้วย Decreased Factor ซึ่งมีค่าเท่ากับ 0.1 และการฝึกสอนจะสิ้นสุดลงเมื่อค่า μ มีค่ามากกว่า $1e^{10}$


4.3.4 โครงข่ายประสาทเทียมที่เหมาะสมในการพยากรณ์ความต้องการพลังงานไฟฟ้าสูงสุด

จากขั้นตอนของการฝึกสอนและทดสอบโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับในข้างต้น จะมีการนำค่า MAPE ของชุดทดสอบในแต่ละโครงสร้างมาทำการเปรียบเทียบกัน โดยจะเลือกโครงสร้างที่ให้ค่า MAPE ต่ำที่สุดมาใช้ในการพยากรณ์ค่าความต้องการพลังงานไฟฟ้าสูงสุดต่อไป

ขั้นตอนในการใช้โครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับแสดงได้ดังรูปที่ 4.10 และ 4.11 ในส่วนของผลการทดลองจะแสดงในบทถัดไป



รูปที่ 4.10 การพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่มีชั้นซ่อน 1 ชั้น



รูปที่ 4.11 การพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับที่มีชั้นซ่อน 2 ชั้น

4.4 การทดลองฝึกสอนด้วยโครงข่ายประสาทเทียมแบบ Generalized Regression Neural Network (GRNN)





วิธีการฝึกสอนโครงข่ายประสาทเทียมแบบ Generalized Regression นั้นจะมีลักษณะแตกต่างจากการฝึกสอนโครงข่ายประสาทเทียมแบบ Back-propagation เนื่องจากโครงข่ายประสาทเทียมแบบ GRNN นั้นเราไม่สามารถเปลี่ยนฟังก์ชันการถ่ายโอนที่ใช้ในชั้นต่างๆ ของโครงข่ายประสาทเทียมได้เหมือนกับโครงข่ายประสาทเทียมแบบ Back-propagation โดยฟังก์ชันการถ่ายโอนที่ใช้ในโครงข่ายประสาทเทียมแบบ Generalized Regression นั้นจะใช้ฟังก์ชันการถ่ายโอนชนิด Radial Basis Function ในชั้นซ่อน (Hidden Layer) หรือชั้นฐานรัศมี (Radial Basis Layer) และใช้ฟังก์ชันการถ่ายโอนแบบ Linear ในชั้นเอาต์พุต (Output Layer) หรือชั้นเชิงเส้นพิเศษ (Special Linear Layer) และโครงข่ายประสาทเทียมแบบ Generalized Regression นั้นเราจะไม่สามารถปรับเปลี่ยนจำนวนนิวรอนในชั้นซ่อนได้ เนื่องจากจำนวนโหนดในชั้นซ่อนของโครงข่ายประสาทเทียมแบบ Generalized Regression นั้นจะเท่ากับจำนวนชุดฝึกสอนของข้อมูล

ดังนั้นการปรับโครงข่ายประสาทเทียมในการฝึกสอนในวิทยานิพนธ์ฉบับนี้จะทำใน 2 ลักษณะ คือ ทำการปรับขนาดความกว้างของฟังก์ชัน Radial Basis Function และทำการปรับค่า Spread

4.4.1 ผลจากการปรับขนาดความกว้างของฟังก์ชัน Radial Basis Functions

ในการปรับขนาดความกว้างของ Radial Basis Function นั้นจะมีผลทำให้ค่าไบแอสของโครงข่ายประสาทเทียมแบบ Generalized Regression ในชั้นซ่อนมีขนาดเปลี่ยนแปลงตามไปด้วย ซึ่งวิธีการปรับขนาดความกว้างของ Radial Basis Function จะทำโดยการเพิ่มค่าคงที่เข้าไปสมการปกติ คือ $a(n) = e^{-n^2}$ โดยในงานวิทยานิพนธ์ครั้งนี้จะทำการปรับค่าคงที่ 4 ค่า ทำให้ได้สมการในการฝึกสอนทั้งหมด 4 สมการ ดังจะแสดงสมการและกราฟของฟังก์ชัน และสมการในการหาค่าไบแอส ได้ตามตารางที่ 4.5

ตารางที่ 4.5 กราฟและสมการ Radial Basis Function และสมการที่ใช้ในการหาค่าไบแอส

กราฟ Radial Basis Function	สมการ Radial Basis function	สมการที่ใช้ในการหาค่าไบแอสในชั้นซ่อน
	$a(n) = e^{-0.5n^2}$	$\text{bias} = \frac{1.1774}{\text{spread}}$
	$a(n) = e^{-n^2}$	$\text{bias} = \frac{0.8326}{\text{spread}}$
	$a(n) = e^{-1.5n^2}$	$\text{bias} = \frac{0.6800}{\text{spread}}$
	$a(n) = e^{-2n^2}$	$\text{bias} = \frac{0.5877}{\text{spread}}$

4.4.2 ผลจากการปรับ Spread


จากตารางที่ 4.5 จะให้ได้ว่าค่าการปรับค่า Spread จะมีผลต่อค่าไบแอสในชั้นซ่อน ดังนั้นในการปรับค่า Spread หลายๆ ค่าจะทำให้เราสามารถหาค่า Spread ที่ดีที่สุดซึ่งจะทำให้โครงข่ายประสาทเทียมแบบ GRNN มีประสิทธิภาพดีที่สุดได้ โดยในการศึกษานี้จะให้ค่า Spread เป็นไปตามสมการที่ 4.7

$$\text{Spread} = n / \text{ค่าคงที่} \quad (4.7)$$

โดยให้ค่า n เป็นตัวเลขที่เป็นจำนวนเต็ม มีค่าตั้งแต่ 1-100 และในการฝึกสอนเราจะทำการเปลี่ยนค่าคงที่ไปเรื่อยๆ และทำการฝึกสอนโครงข่ายประสาทเทียมใหม่หลังจากปรับค่าคงที่ 1 ค่า หลังจากฝึกสอนเสร็จก็บันทึกค่า MAPE มาเปรียบเทียบกับโครงข่ายที่มีประสิทธิภาพดีที่สุด

ขั้นตอนในการฝึกสอนโครงข่ายประสาทเทียมแบบ GRNN ในวิทยานิพนธ์ฉบับนี้จะสามารถสรุปเป็นแผนผังการทำงานได้ตามรูปที่ 4.12

โดยค่าที่ได้จากการทดลองฝึกสอนโครงข่ายประสาทเทียมแบบ GRNN โดยการปรับขนาดความกว้างของ Radial Basis Function และขนาดของ Spread จะถูกบันทึกไว้และนำไปวิเคราะห์ในบทถัดไป



รูปที่ 4.12 การพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบ GRNN