

การประยุกต์ใช้โครงข่ายประสาทเทียมสำหรับปัญหาชนิดคอมมิทเมนต์

สรายุทธ จิตะภาส, วรวัฒน์ เสี่ยงวิบูล และอนันต์ อรุณโสภณ

หน่วยวิจัยวิศวกรรมอิเล็กทรอนิกส์การเกษตร คณะวิศวกรรมศาสตร์, มหาวิทยาลัยมหาสารคาม,

ถนนก้นทรวงชัย, จังหวัดมหาสารคาม 44150, E-mail: wor_nui@yahoo.com

บทคัดย่อ

บทความฉบับนี้เป็นการนำเสนอการประยุกต์ใช้โครงข่ายประสาทเทียมสำหรับปัญหาชนิดคอมมิทเมนต์ โดยเลือกใช้โครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับ ข้อมูลอินพุตที่ใช้ในการฝึกสอนจะใช้เวลาต้องการโหลดและสถานะของเครื่องกำเนิดไฟฟ้า ระบบไฟฟ้าที่นำมาทดลองมี 3 ระบบ คือระบบไฟฟ้าที่มีจำนวนของเครื่องกำเนิดไฟฟ้า 10, 26 และ 100 เครื่อง จากการทดลองพบว่าโครงข่ายประสาทเทียมที่ผ่านการฝึกสอนสามารถหาคำตอบได้อย่างรวดเร็วและแม่นยำ โดยค่าเบี่ยงเบนมาตรฐานของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยอยู่ในเกณฑ์ที่ยอมรับได้ซึ่งมีค่าเท่ากับ 5.526, 7.197 และ 24.076 ตามลำดับ

คำสำคัญ : ปัญหาชนิดคอมมิทเมนต์, โครงข่ายประสาทเทียม, การแพร่ค่าย้อนกลับ

1. บทนำ

การวางแผนการผลิตกำลังไฟฟ้าต้องคำนึงถึงการผลิตกำลังไฟฟ้าให้เพียงพอกับความต้องการโหลดที่ต้นทุนการผลิตทั้งหมด ต่ำที่สุด หรืออีกนัยหนึ่งคือจะวางแผนอย่างไรให้เครื่องกำเนิดไฟฟ้าเครื่องใดบ้างควรเดินหรือหยุดเครื่อง เพื่อทำการผลิตกำลังไฟฟ้าให้เพียงพอกับความต้องการโหลดที่ ณ คาบเวลานั้น โดยใช้ต้นทุนในการผลิตกำลังไฟฟ้าต่ำที่สุด ซึ่ง เรียกกระบวนการ ทั้งหมดนี้ว่าปัญหาชนิดคอมมิทเมนต์ (Unit Commitment Problem : UCP) การแก้ปัญหาคอมมิทเมนต์จะพิจารณาทั้งในส่วนของคุณลักษณะของเครื่องกำเนิดไฟฟ้าและระบบ กำลังไฟฟ้า เช่น กำลังการผลิต (Generating Capacity) เวลาเดินเครื่องกำเนิดไฟฟ้าอย่างน้อยที่สุด (Minimum Up Time) เวลาหยุดเดินเครื่องกำเนิดไฟฟ้าอย่างน้อยที่สุด (Minimum Down Time) กำลังไฟฟ้าสำรอง (Spinning Reserve) กำลังไฟฟ้าสูญเสียเนื่องมาจากสายส่ง (Transmission Loss) และกำลังไฟฟ้าสมดุล (Power Balance) นอกจากการวิเคราะห์เงื่อนไขข้างต้นแล้วยังต้องวิเคราะห์ส่วนของการจ่ายโหลดอย่างประหยัด (Economic Dispatch) อีกด้วย [1] ดังนั้นในการแก้ปัญหาดังกล่าวจะ เป็นการแก้ปัญหของสมการที่ไม่เป็นเชิงเส้นหลายตัวแปรเพื่อให้ได้ค่าที่เหมาะสมที่สุด จึงส่งผลให้ปัญหามีความซับซ้อนมากยิ่งขึ้น

การแก้ปัญหาคอมมิทเมนต์ ที่ใช้ในปัจจุบันมีอยู่หลายวิธี เช่น วิธีเชิงพันธุกรรม (Genetic Algorithm : GA) [2] วิธีรายการลำดับความสำคัญ (Priority List : PL) [3] วิธีการโปรแกรมแบบผสมจำนวน

เต็ม (Mix-Integer Programming : MIP) [3] วิธีการโปรแกรมพลวัต (Dynamic Programming : DP) [4] วิธีการผ่อนคลายลากรังเจียน (Lagrangian Relaxation : LR) [5] เป็นต้น ซึ่งวิธีการต่างๆ ที่กล่าวมาเป็นการหาคำตอบในช่วงข้อมูล ณ เวลานั้นๆ ไม่มีการจดจำและเรียนรู้และต้องใช้สมการทางคณิตศาสตร์จำนวนมากในการวิเคราะห์ ดังนั้นจึงได้นักวิจัยเสนอแนวทางแก้ปัญหาที่แตกต่างออกไปโดยใช้วิธีโครงข่ายประสาทเทียม (Artificial Neural Networks : ANNs) มาประยุกต์ใช้ [6] ซึ่งมีความสามารถในการเรียนรู้ฟังก์ชันต่อเนื่องแบบไม่เป็นเชิงเส้นหลายชนิดได้อย่างแม่นยำภายในขอบเขตที่เรียนรู้ แต่ในงานวิจัยที่ผ่านมา [6] ได้ทดสอบกับระบบไฟฟ้าที่มีจำนวนของเครื่องกำเนิดไฟฟ้าไม่มากนัก ซึ่งไม่สอดคล้องกับระบบไฟฟ้าที่ใช้งานจริงในปัจจุบัน

ดังนั้นในบทความนี้จึงนำเสนอการประยุกต์โครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับ (Back Propagation Neural Network) ในการแก้ปัญหา UCP ซึ่งระบบไฟฟ้าที่นำมาทดสอบ มีจำนวนของเครื่องกำเนิดไฟฟ้า 10 26 และ 100 เครื่อง โดยไม่คำนึงถึงขั้นตอนการคำนวณทางคณิตศาสตร์ ที่ซับซ้อน แต่จะใช้เพียงข้อมูลป้อนเข้า (Input Data) และข้อมูลออก (Output Data) เท่านั้น แล้วนำผลการทดลองที่ได้จาก ANNs มาเปรียบเทียบกับคำตอบที่ได้จากวิธี GA [2] เพื่อทดสอบประสิทธิภาพของโครงข่าย

2. ปัญหายุทธศาสตร์การผูกมัดหน่วย (Unit Commitment Problem : UCP)

ปัญหายุทธศาสตร์การผูกมัดหน่วยจะประกอบไปด้วยฟังก์ชันเป้าหมายที่ต้องการหาค่าต่ำที่สุดเฉพาะที่ (Local minima) ดังสมการที่ (1) เพื่อให้การผลิตกำลังไฟฟ้าได้ตามความต้องการของโหลดที่ต้นทุนต่ำที่สุด หรือกล่าวอีกนัยหนึ่งก็จะวางแผนอย่างไรให้เครื่องกำเนิดไฟฟ้าเครื่องใดเดินหรือหยุดเครื่องเพื่อผลิตกำลังไฟฟ้าให้เพียงพอตามความต้องการโหลดที่ ณ คาบเวลานั้นโดยใช้ต้นทุนในการผลิตกำลังไฟฟ้าต่ำที่สุด

$$\text{Min. } F_{\text{Total cost}} = \sum_{t=1}^T \sum_{i=1}^N U_{it} F_i(P_{it}) + U_{it} (1 - U_{i(t-1)}) ST_i \quad (1)$$

เมื่อ T คือ จำนวนชั่วโมงที่พิจารณา

N คือ จำนวนเครื่องกำเนิดไฟฟ้า

U_{it} คือ สถานะเครื่องกำเนิดไฟฟ้าเครื่องที่ i ณ เวลาที่ t

เมื่อ $U_{it} = 0$ คือ สถานะหยุดเครื่องกำเนิดไฟฟ้า

$U_{it} = 1$ คือ สถานะเดินเครื่องกำเนิดไฟฟ้า

$F_i(P_{it})$ คือ ฟังก์ชันของต้นทุนค่าเชื้อเพลิงของเครื่องกำเนิดไฟฟ้าเครื่องที่ i ขณะผลิตกำลังไฟฟ้าขนาด P ที่เวลา t

ST_i คือ ราคาการเริ่มเดินของเครื่องกำเนิดไฟฟ้าที่ i

P_{it} คือ กำลังไฟฟ้าที่ผลิตจากเครื่องกำเนิดไฟฟ้าที่ i ณ เวลาที่ t

โดย เงื่อนไขในการแก้ปัญหาหาค่าคอมมิทเมนต์ที่ต้องพิจารณา มีดังนี้

- ความสมดุลกำลังไฟฟ้า (Power balance) ดังสมการที่ (2)

$$\sum_{i=1}^N U_{it} P_{it} = D_t \quad (2)$$

เมื่อ D_t คือ ค่ากำลังไฟฟ้าที่โหลดต้องการ ณ เวลา t

P_{it} คือ ค่ากำลังไฟฟ้าที่ผลิตได้ของเครื่องกำเนิดไฟฟ้าเครื่องที่ i ที่เวลา t

- ความต้องการกำลังไฟฟ้าสำรอง (Spinning reserve requirements) ดังสมการที่ (3)

$$\sum_{i=1}^N U_{it} P_{i,max} \geq R_t + D_t \quad (3)$$

เมื่อ R_t คือ ค่ากำลังไฟฟ้าสำรอง ณ เวลา t

$P_{i,max}$ คือ ค่ากำลังไฟฟ้าสูงสุดที่ผลิตได้ของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

- เวลาเดินเครื่องอย่างน้อยที่สุด (Minimum up time) ดังสมการที่ (4)

$$(X_{i(t-1)}^{On} - min_up_i) * (U_{i(t-1)} - U_{it}) \geq 0 \quad (4)$$

เมื่อ $X_{i(t-1)}^{On}$ คือ จำนวนชั่วโมงของเครื่องกำเนิดไฟฟ้าเครื่องที่ i เดินเครื่อง

เป็นเวลาติดต่อกันจนถึงเวลาที่ $t-1$

min_up_i คือ เวลาเดินเครื่องอย่างน้อยที่สุดของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

- เวลาหยุดเครื่องอย่างน้อยที่สุด (Minimum down time) ดังสมการที่ (5)

$$(X_{i(t-1)}^{Off} - min_dw_i) * (U_{it} - U_{i(t-1)}) \geq 0 \quad (5)$$

เมื่อ $X_{i(t-1)}^{Off}$ คือ จำนวนชั่วโมงของเครื่องกำเนิดไฟฟ้าเครื่องที่ i หยุดเครื่อง

เป็นเวลาติดต่อกันจนถึงเวลาที่ $t-1$

min_dw_i คือ เวลาหยุดเครื่องอย่างน้อยที่สุดของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

- จำกัดกำลังการผลิต (Generating capacity) สมการที่ (6)


$$P_{i,min} \leq P_{it} \leq P_{i,max} \quad (6)$$

เมื่อ $P_{i,min}$ คือ ค่ากำลังไฟฟ้าต่ำสุดที่ผลิตได้ของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

$P_{i,max}$ คือ ค่ากำลังไฟฟ้าสูงสุดที่ผลิตได้ของเครื่องกำเนิดไฟฟ้าเครื่องที่ i

3. โครงข่ายประสาทเทียมแบบแพร่ค่าย้อนกลับ (Back Propagation Neural Networks : BPNN)


โครงข่ายประสาทเทียม คือระบบการคำนวณที่สร้างเลียนแบบการทำงานของระบบสมองมนุษย์เพื่อคาดคะเนเหตุการณ์โดยการเรียนรู้จากข้อมูลที่มีอยู่ และ การเรียนรู้แบบแพร่ค่าย้อนกลับ ซึ่งเป็นการเรียนรู้รูปแบบหนึ่งโดยใช้การสอน ดังรูปที่ 1 ซึ่งสามารถเลือกใช้ฟังก์ชันการถ่ายโอนแบบไม่เป็นเชิงเส้นที่แตกต่างกันได้ การเรียนรู้แบบแพร่ค่าย้อนกลับใช้เทคนิคการ หาค่าความเหมาะสม แบบ Gradient descent ทำการปรับค่าถ่วงน้ำหนักเพื่อลดค่าความคลาดเคลื่อนของระบบระหว่างการเรียนรู้รูปแบบของอินพุต (Input pattern) จะส่งเข้าสู่โครงข่ายตามลำดับผ่านชั้นต่างๆ ในทิศทางไปข้างหน้าจนได้รูปแบบของเอาต์พุต (Output pattern) ค่าเอาต์พุตที่ได้จะนำไปเปรียบเทียบกับค่าเป้าหมาย (Target values) และค่าความคลาดเคลื่อนที่ได้จะถูกแพร่ค่าย้อนกลับ เพื่อปรับค่าถ่วงน้ำหนัก (Weight : w) และค่าไบแอส (Bias : b) ในแต่ละชั้นในทิศทางย้อนกลับ จะเป็นดังกระบวนการนี้ไปจนกว่าค่าความคลาดเคลื่อนที่เกิดขึ้นอยู่ในช่วงที่ยอมรับได้ จึงถือว่าการเรียนรู้ของโครงข่ายสิ้นสุดลง



รูปที่ 1 การแพร่ค่าย้อนกลับของ ANNs

3.1 การออกแบบโครงข่ายประสาทเทียมเพื่อหาคำตอบ UCP

สำหรับบทความนี้ได้นำโครงข่ายประสาทเทียมมาทดสอบกับระบบไฟฟ้าที่มีเครื่องกำเนิดไฟฟ้า 10 26 และ 100 เครื่อง ความต้องการโหลดแต่ละชั่วโมงมีลักษณะดังรูปที่ 2 และในการเตรียมข้อมูลสำหรับโครงข่ายประสาทเทียมจะใช้คำตอบที่ได้จากวิธี GA [2] เป็นข้อมูลสำหรับอินพุตและเอาต์พุตแสดงดังตารางที่ 1 เนื่องจากข้อมูลมีจำนวนมากจึงแสดงเฉพาะระบบไฟฟ้าขนาด 10 เครื่อง โดยที่ข้อมูลอินพุตคือความต้องการโหลดของระบบไฟฟ้าตั้งแต่ชั่วโมงที่ 1 ถึงชั่วโมงที่ 24 และสถานะของเครื่องกำเนิดไฟฟ้าเมื่อ $U_{it} = 0$ คือหยุดเครื่องกำเนิดไฟฟ้าและ $U_{it} = 1$ คือเดินเครื่องกำเนิดไฟฟ้า ส่วนข้อมูลเอาต์พุตคือกำลังไฟฟ้าที่ผลิตจากเครื่องกำเนิดไฟฟ้าทุกเครื่องในแต่ละชั่วโมง



รูปที่ 2 ความต้องการโหลดใน 24 ชั่วโมง [2]

ตารางที่ 1 ตัวอย่างข้อมูลอินพุตและเอาต์พุตที่ได้จากวิธี GA สำหรับกรณีเครื่องกำเนิดไฟฟ้า 10 เครื่อง [2]

	ข้อมูลเอาต์พุต										ข้อมูลอินพุต										
ชั่วโมง ที่	กำลังไฟฟ้าที่ผลิต (MW)										ความต้องการ โหลด (MW)	สถานะของเครื่องกำเนิดไฟฟ้า (ON-OFF)									
	U ₁	U ₂	U ₃	U ₄	U ₅	U ₆	U ₇	U ₈	U ₉	U ₁₀		U ₁	U ₂	U ₃	U ₄	U ₅	U ₆	U ₇	U ₈	U ₉	U ₁₀
1	455	245	0	0	0	0	0	0	0	0	700	1	1	0	0	0	0	0	0	0	0
2	455	295	0	0	0	0	0	0	0	0	750	1	1	0	0	0	0	0	0	0	0
3	455	370	0	0	25	0	0	0	0	0	850	1	1	0	0	1	0	0	0	0	0
4	455	455	0	0	40	0	0	0	0	0	950	1	1	0	0	1	0	0	0	0	0
5	455	390	0	130	25	0	0	0	0	0	1000	1	1	0	1	1	0	0	0	0	0
6	455	360	130	130	25	0	0	0	0	0	1100	1	1	1	1	1	0	0	0	0	0
7	455	410	130	130	25	0	0	0	0	0	1150	1	1	1	1	1	0	0	0	0	0
8	455	455	130	130	30	0	0	0	0	0	1200	1	1	1	1	1	0	0	0	0	0
9	455	455	130	130	85	20	25	0	0	0	1300	1	1	1	1	1	1	1	0	0	0
10	455	455	130	130	162	33	25	10	0	0	1400	1	1	1	1	1	1	1	1	0	0
11	455	455	130	130	162	73	25	10	10	0	1450	1	1	1	1	1	1	1	1	1	0
12	455	455	130	130	162	80	25	43	10	10	1500	1	1	1	1	1	1	1	1	1	1
13	455	455	130	130	162	33	25	10	0	0	1400	1	1	1	1	1	1	1	1	0	0
14	455	455	130	130	85	20	25	0	0	0	1300	1	1	1	1	1	1	1	0	0	0
15	455	455	130	130	30	0	0	0	0	0	1200	1	1	1	1	1	0	0	0	0	0
16	455	310	130	130	25	0	0	0	0	0	1050	1	1	1	1	1	0	0	0	0	0
17	455	260	130	130	25	0	0	0	0	0	1000	1	1	1	1	1	0	0	0	0	0
18	455	360	130	130	25	0	0	0	0	0	1100	1	1	1	1	1	0	0	0	0	0
19	455	455	130	130	30	0	0	0	0	0	1200	1	1	1	1	1	0	0	0	0	0
20	455	455	130	130	162	33	25	10	0	0	1400	1	1	1	1	1	1	1	1	0	0
21	455	455	130	130	85	20	25	0	0	0	1300	1	1	1	1	1	1	1	0	0	0
22	455	455	0	0	145	20	25	0	0	0	1100	1	1	0	0	1	1	1	0	0	0
23	455	425	0	0	0	20	0	0	0	0	900	1	1	0	0	0	1	0	0	0	0
24	455	345	0	0	0	0	0	0	0	0	800	1	1	0	0	0	0	0	0	0	0

เลือกใช้ ANNs แบบแพร่ค่าย้อนกลับ โดยแบ่งข้อมูลออกเป็นสองชุด คือ ชุดข้อมูลในการฝึกสอน (Training data) และชุดข้อมูลในการทดสอบ (Testing data) ซึ่งในการแบ่งข้อมูลสำหรับโครงข่ายประสาทเทียมนั้น ถ้ากำหนดให้ข้อมูลในการฝึกสอนมีจำนวนน้อยเกินไปจะส่งผลให้ค่าความผิดพลาดมากขึ้น แต่ถ้ากำหนดให้ข้อมูลในการฝึกสอนมีจำนวนมากเกินไปแทนที่จะเพิ่มประสิทธิภาพของโครงข่าย แต่อาจทำให้โครงข่ายเกิดการจดจำมากกว่าการเรียนรู้ ซึ่งส่งผลให้เกิดความคลาดเคลื่อนได้เช่นกัน ดังนั้นการวิจัยในครั้งนี้จะแบ่งข้อมูลในอัตราส่วน 5 ต่อ 1 ดังนี้ ข้อมูลในการฝึกสอนใช้ทั้งหมด 20 ชุด คือข้อมูลชั่วโมงที่ 1 ถึงชั่วโมงที่ 20 และข้อมูลในการทดสอบใช้ทั้งหมด 4 ชุด คือข้อมูลชั่วโมงที่ 21 ถึงชั่วโมงที่ 24 ซึ่งข้อมูลทั้งสองชุดที่นำเข้าโครงข่ายจะต้องจัดให้อยู่ในรูปแบบเมตริกซ์ และในตารางที่ 2 เป็นแสดงขนาดเมตริกซ์ของข้อมูล

โครงข่ายประสาทเทียมจะสามารถหาคำตอบได้ด้นขึ้นขึ้นอยู่กับปริมาณและคุณภาพของข้อมูลชุดฝึกสอน โดยที่คุณภาพของชุดข้อมูลจะการใช้การกระจายของข้อมูลเป็นเกณฑ์ สำหรับการฝึกสอนโครงข่ายประสาทเทียมจะใช้ฟังก์ชันการฝึกสอนแบบ Resilient Back Propagation [7]

ตารางที่ 2 ข้อมูลสำหรับ ANNs

	10 Units	26 Units	100 Units
Input data	[20×11]	[20×27]	[20×101]
Output data	[20×10]	[20×26]	[20×100]
Testing data	[4×11]	[4×27]	[4×101]

สำหรับฟังก์ชันการถ่ายโอนของโครงข่ายจะทดลองใช้ฟังก์ชัน 4 รูปแบบโดยการสับเปลี่ยนตำแหน่งดังตารางที่ 3 ส่วนการปรับขนาดโครงสร้างของโครงข่าย เช่นจำนวนนิวรอน (H_1, H_2) ค่าถ่วงน้ำหนัก (w) และค่าไบแอส (b) ทดลองปรับค่าตามขั้นตอนดังรูปที่ 3

ตารางที่ 3 ฟังก์ชันการถ่ายโอน

รูปแบบ	ฟังก์ชันการถ่ายโอน	
	ชั้นซ่อน (H_1)	ชั้นเอาต์พุต (H_2)
1	<i>log sig</i>	<i>log sig</i>
2	<i>tan sig</i>	<i>tan sig</i>
3	<i>log sig</i>	<i>tan sig</i>
4	<i>tan sig</i>	<i>log sig</i>


การทดสอบประสิทธิภาพของ ANNs จะใช้ค่าเบี่ยงเบนมาตรฐานของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : $RMSE$) เป็นตัวชี้วัดประสิทธิภาพดังสมการที่ 2

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (GA\ result_i - ANNs\ result_i)^2} \quad (2)$$

เมื่อ $GA\ result$ คือ ค่าคำตอบจากวิธี GA

$ANNs\ result$ คือ ค่าคำตอบจากโครงข่าย

n คือ จำนวนชุดทดสอบ



รูปที่ 3 ขั้นตอนการปรับ w, b และจำนวนนิวรอน

4. ผลการทดลอง

ผู้วิจัยได้แสดงผลการทดลองจากโครงข่ายประสาทเทียมที่ผ่านการฝึกสอนเปรียบเทียบกับผลจากวิธีเชิงพันธุกรรม ดังแสดงในตารางที่ 4 ถึง 6 สำหรับประสิทธิภาพของ ANNs จำนวนนิวรอน และฟังก์ชันการถ่ายโอนที่ใช้ในการฝึกสอนแสดงในตารางที่ 7

ตารางที่ 4 ตัวอย่างผลการทดลองเปรียบเทียบคำตอบจากวิธี GA และ ANNs สำหรับกรณี 10 เครื่อง

Hours Units	21:00			22:00			23:00			24:00		
	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE
U ₂	455.00	455.00	0.00	455.00	454.98	0.02	425.00	443.66	18.66	345.00	350.01	5.01
U ₄	130.00	130.00	0.00	0.00	4.64	4.64	0.00	0.00	0.00	0.00	0.00	0.00
U ₅	85.00	85.02	0.02	145.00	139.87	5.13	0.00	0.01	0.01	0.00	0.00	0.00
U ₆	20.00	20.15	0.15	20.00	0.00	20.00	20.00	0.00	20.00	0.00	0.00	0.00
U ₇	25.00	25.00	0.00	25.00	25.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
U ₁₀	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

ตารางที่ 5 ตัวอย่างผลการทดลองเปรียบเทียบคำตอบจากวิธี GA และ ANNs สำหรับกรณี 26 เครื่อง

Hours Units	21:00			22:00			23:00			24:00		
	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE
U ₂	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
U ₁₀	76.00	75.998	0.002	76.00	75.99	0.01	76.00	69.80	6.20	0.00	0.004	0.004
U ₁₃	76.00	75.999	0.001	76.00	75.999	0.001	76.00	75.908	0.092	0.00	0.0019	0.0019
U ₁₇	155.00	155.00	0.00	155.00	155.00	0.00	155.00	155.00	0.00	155.00	144.00	11.00
U ₂₁	134.00	112.84	21.16	0.00	7.808	7.808	0.00	0.008	0.008	0.00	0.00	0.00
U ₂₆	400.00	400.00	0.00	400.00	400.00	0.00	400.00	400.00	0.00	400.00	400.00	0.00

ตารางที่ 6 ตัวอย่างผลการทดลองเปรียบเทียบคำตอบจากวิธี GA และ ANNs สำหรับกรณี 100 เครื่อง

Hours Units	21:00			22:00			23:00			24:00		
	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE	GA	ANNs	RMSE
U ₂	50.00	49.999	0.001	50.00	50.00	0.00	50.00	49.067	0.933	16.00	46.93	33.93
U ₉	13.00	13.00	0.00	13.00	13.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
U ₁₉	200.00	200.00	0.00	200.00	200.00	0.00	200.00	200.00	0.00	200.00	142.72	57.28
U ₆₈	185.00	169.58	15.42	185.00	169.19	15.81	0.00	0.00	0.00	0.00	0.00	0.00
U ₈₆	600.00	600.00	0.00	600.00	600.00	0.0	600.00	600.00	0.00	600.00	600.00	0.00
U ₁₀₀	800.00	800.00	0.00	800.00	800.00	0.00	800.00	800.00	0.00	800.00	800.00	0.00


จากตารางที่ 4 ถึง 6 พบว่าการหาคำตอบ UCP ด้วยโครงข่ายประสาทเทียมที่ผ่านการฝึกสอนแล้ว จะได้คำตอบที่มีความแม่นยำโดยเฉลี่ยแล้วอยู่ในเกณฑ์ที่ยอมรับได้และยังพบว่า ANNs ที่ผ่านการฝึกสอนแล้ว จะใช้เวลาในการหาคำตอบน้อยมาก ทั้งนี้เนื่องจาก ANNs ที่ฝึกสอนแล้วสามารถหาคำตอบได้โดยการคำนวณเพียงครั้งเดียว ซึ่งต่างจากวิธี GA ที่ต้องคำนวณแบบทำซ้ำ

ตารางที่ 7 โครงสร้างและประสิทธิภาพของ ANNs


ระบบไฟฟ้า	จำนวนนิวรอน		ฟังก์ชันการถ่ายโอน		RMSE
	ชั้นซ่อน	ชั้นเอาต์พุต	ชั้นซ่อน	ชั้นเอาต์พุต	
10 Units	47	9	<i>log sig</i>	<i>tan sig</i>	5.526
26 Units	67	17	<i>log sig</i>	<i>tan sig</i>	7.197
100 Units	46	37	<i>log sig</i>	<i>tan sig</i>	24.076

จากตารางที่ 7 จะพบว่าจำนวนนิวรอนในชั้นซ่อนทั้งสองชั้นที่ใช้เป็นโครงสร้างของโครงข่ายจะมากหรือน้อยไม่ได้ขึ้นอยู่กับขนาดของระบบไฟฟ้าที่ทดลอง แต่จะขึ้นอยู่กับคุณภาพของชุดข้อมูลซึ่งจะอาศัยการกระจายของข้อมูลเป็นเกณฑ์ ถ้าการกระจายของข้อมูลดีจะส่งผลให้โครงสร้างของโครงข่ายมีขนาดเล็กลง และจากการทดลองยังพบอีกว่า ANNs ที่มีประสิทธิภาพของโครงข่ายสูงสุด ไม่จำเป็นต้องมีขนาดโครงข่ายใหญ่ที่สุดเสมอไป


รูปที่ 4 ถึง 6 คือกราฟแสดงความสัมพันธ์ของการผลิตกำลังไฟฟ้ารวมของแต่ละชั่วโมง ระหว่างคำตอบจาก ANNs ที่ผ่านการฝึกสอนกับคำตอบจากวิธี GA จะพบว่าลักษณะของกราฟเป็นไปตามกัน



รูปที่ 4 การผลิตกำลังไฟฟ้ารวมทั้งหมด กรณี 10 เครื่อง



รูปที่ 5 การผลิตกำลังไฟฟ้ารวมทั้งหมด กรณี 26 เครื่อง



รูปที่ 6 การผลิตกำลังไฟฟ้ารวมทั้งหมด กรณี 100 เครื่อง

5. สรุป

การใช้โครงข่ายประสาทเทียม ในลักษณะที่ไม่คำนึงถึงขั้นตอนการคำนวณทางคณิตศาสตร์ ที่ยุ่งยาก แต่ใช้เพียงแค่ ข้อมูลป้อนเข้าและข้อมูลออก ดังที่นำเสนอไว้แล้วข้างต้น ทำให้สามารถลดขั้นตอนการหาคำตอบซึ่งใช้เพียงแค่หลักการคูณและบวกเมตริกซ์เท่านั้น ส่งผลให้เวลาที่ใช้ในการหาคำตอบจากโครงข่ายที่ผ่านการฝึกสอนแล้วน้อยมากซึ่งต่างจากวิธีการอื่นที่ต้องใช้การคำนวณแบบทำซ้ำ ส่วนประสิทธิภาพของโครงข่ายอยู่ในเกณฑ์ที่ดีและยอมรับได้และสามารถประยุกต์ใช้กับระบบไฟฟ้าขนาดใหญ่ได้อีกทั้งคำตอบที่

ได้ยังเป็นคำตอบไปข้างหน้าซึ่งต่างจากคำตอบของวิธีอื่น อย่างไรก็ตามข้อเสียของ ANNs คือการเลือกโครงสร้างที่เหมาะสมของโครงข่ายสำหรับการฝึกสอนยังไม่มีวิธีที่ชัดเจนขึ้นอยู่กับข้อมูลที่ใช้ฝึกสอนจึงต้องใช้เวลาในการหาโครงสร้างที่เหมาะสมและจากการทดลองยังพบอีกว่าปริมาณและคุณภาพของชุดข้อมูลมีผลต่อประสิทธิภาพของโครงข่ายอีกด้วย

เอกสารอ้างอิง

- [1] Allen J.Wood and Bruce F.Wollenberg, “Power Generation Operation & Control,” *Power Technologies Inc.*, John Wiley & Sons, New York, 1984.
- [2] ธวัช เกิดชื่น , “การแก้ปัญหาชนิดคอมมิทเมนต์โดยวิธีเจเนติก ,” วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า บัณฑิตวิทยาลัย มหาวิทยาลัยขอนแก่น, 2541.
- [3] Erik Delarue and William D’haeseleer, “Advanced Priority Listing Versus Mixed Integer Programming In Solving The Unit Commitment Problem,” *TMEWORKING PAPER - Energy and Environment*, Last update, June 2008.
- [4] W. L. Snyder, H. D. Powell and J. C. Rayburn, “Dynamic programming approach to unit commitment,” *IEEE Trans. on Power Systems*, vol. 2, no. 2, pp. 339-351, 1987.
- [5] Chuan-Ping Cheng, Chih-Wen Liu and Chun-Chang Liu, “Unit Commitment by Lagrangian Relaxation and Genetic Algorithms,” *IEEE Trans. on Power Systems*, Vol. 15, no. 2, pp. 707-714, May 2000.
- [6] R. Kaur and P. Nijhawan, “Optimal Short-Term Unit Commitment Using Neural Network,” *Dept of Electrical & Instrumentation Engineering University of Thapar*, June 2008.
- [7] Howard Demuth, Mark Beale and Martin Hagan, “Neural Network Toolbox 5 User’s Guide,” *The Mathworks Inc.*, September 2007.

บทความนี้ส่งเข้ามาเมื่อ 1 สิงหาคม 2554 และได้รับพิจารณาให้ตีพิมพ์เมื่อ 18 สิงหาคม 2554.
