

การพยากรณ์ความต้องการใช้ไฟฟ้าระยะสั้นโดยเวฟเลทร่วมกับโครงข่ายประสาทเทียม

กวีพจน์ บรรลือวงศ์¹ และสุปราณี กิจเจริญศักดิ์กุล²

¹สาขาวิทยาการคอมพิวเตอร์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยมหาสารคาม มหาสารคาม

²ศูนย์นวัตกรรมใหม่ มหาวิทยาลัยมหาสารคาม มหาสารคาม

Emails: kaveepoj.b@msu.ac.th , schin0505@hotmail.com

บทคัดย่อ

บทความนี้นำเสนอวิธีการพยากรณ์ความต้องการใช้ไฟฟ้าระยะสั้นโดยใช้เวฟเลทแยกข้อมูลอนุกรมเวลาให้เป็นสัญญาณแบบหลายระดับความละเอียด (Wavelet multi-resolution decomposition) และโครงข่ายประสาทเทียมแบบเพอร์เซพตรอนหลายชั้น (Multilayer Perceptrons: MLPs) แต่ละโครงข่าย ทำการพยากรณ์แต่ละสัมประสิทธิ์ของเวฟเลท ซึ่งแต่ละค่าสัมประสิทธิ์ของเวฟเลทที่พยากรณ์ได้ จะถูกรวมกลับให้เป็นผลลัพธ์ความต้องการใช้ไฟฟ้า โดยสามารถรวมได้สองวิธีคือ ใช้โครงข่ายประสาทเทียมแบบ MLP ในส่วนของการรวมค่าสัมประสิทธิ์เวฟเลทและรวมสัมประสิทธิ์โดยใช้เวฟเลท รวมกลับ (wavelet reconstruction: wv) ข้อมูลที่ใช้ในการทดลอง เป็นข้อมูลการใช้ไฟฟ้ารายชั่วโมงจากผลการทดลองพบว่าวิธีการที่ผู้วิจัยนำเสนอ ให้ค่าความผิดพลาดในการพยากรณ์ต่ำกว่าวิธีการใช้โครงข่ายประสาทเทียมแบบ MLP โครงข่ายเดี่ยว (Single Neural Network :SNN) ในการพยากรณ์อนุกรมเวลาชุดต้นแบบ

คำสำคัญ -- โครงข่ายประสาทเทียม; เวฟเลท; อนุกรมเวลา; การพยากรณ์ไฟฟ้าระยะสั้น; โครงข่ายประสาทเทียมแบบเพอร์เซพตรอนหลายชั้น

1. บทนำ

การพยากรณ์ความต้องการใช้ไฟฟ้ามีประโยชน์ในการวางแผนการผลิตไฟฟ้า เนื่องจากไฟฟ้าเป็นสิ่งจำเป็นในการดำรงชีวิตประจำวันและเป็นปัจจัยพื้นฐานที่สำคัญ ในการขับเคลื่อนทางเศรษฐกิจ และเนื่องจากไฟฟ้าเป็นสิ่งที่ไม่สามารถกักเก็บได้ ผู้ผลิตไฟฟ้าจึงจำเป็นต้องจัดหากระแสไฟฟ้าให้เพียงพอกับความต้องการของผู้ใช้ไฟฟ้าอยู่ตลอดเวลา ซึ่งหากผลของการพยากรณ์ความต้องการใช้ไฟฟ้ามีความแม่นยำสูงจะทำให้การผลิตไฟฟ้ามีต้นทุนต่ำและเกิดการบริหารจัดการ การผลิตอย่างมีประสิทธิภาพ[1]

การพยากรณ์ปริมาณการใช้ไฟฟ้า โดยทั่วไปใช้วิธีการทางสถิติ และวิธีทางปัญญาประดิษฐ์ซึ่งใช้โครงข่ายประสาทเทียมในการพยากรณ์ โดยโครงข่ายที่นิยมใช้ในการพยากรณ์ที่นิยมกันอย่างแพร่หลายคือ MLP และใช้การเรียนรู้แบบแพร่ย้อนกลับ (back propagation :BP)[1,2,3] มีความ

แม่นยำในการพยากรณ์มากกว่าวิธีการทางสถิติ[4] งานวิจัยของ Clement R.Tu และคณะ [5,6] นำ โครงข่ายประสาทเทียมแบบ Committee Network (CN) ซึ่งใช้หลายโครงข่ายประสาทเทียมช่วยกันพยากรณ์และนำผลลัพธ์แต่ละโครงข่ายมารวมกันให้ค่าความถูกต้องสูงกว่าโครงข่ายแบบ SNN [5]

งานวิจัยนี้จึงนำเสนอ วิธีการพยากรณ์ข้อมูลอนุกรมเวลาความต้องการใช้ไฟฟ้าระยะสั้นโดยเวฟเลทและ โครงข่ายประสาทเทียม WNN-STLF (Wavelet and Neural Networks for Short-Term Load Forecasting) โดยใช้การแปลงเวฟเลทกั้นทะเลแยกข้อมูลอนุกรมเวลาให้เป็นสัญญาณหลายความถี่ ซึ่งเป็นส่วนประกอบสัมประสิทธิ์ของเวฟเลท ผลลัพธ์การพยากรณ์จะได้ออกมาจากรวมสัมประสิทธิ์ที่พยากรณ์ได้โดยใช้โครงข่ายประสาทเทียมแบบ MLP หรือใช้ wavelet reconstruction

ในส่วนที่ 2 ของบทความ จะกล่าวถึงทฤษฎีเวฟเลทที่ทำการแยกข้อมูลอนุกรมเวลาให้เป็นสัญญาณหลายระดับความละเอียด ส่วนที่ 3 กล่าวถึงขั้นตอนการพยากรณ์ WNN-STLF ส่วนที่ 4 ผลการทดลอง และส่วนที่ 5 สรุปผลการทดลองและข้อเสนอแนะ

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การใช้เวฟเลทแปลงอนุกรมเวลาให้เป็นสัญญาณหลายระดับความละเอียดและการรวมสัญญาณ

การแปลงเวฟเลท[7,8] (wavelet Transform) คือการลดระดับความละเอียดของสัญญาณ หากพิจารณาข้อมูลอนุกรมเวลาความต้องการใช้ไฟฟ้าเป็นสัญญาณ ข้อมูลนั้นจะเป็นสัญญาณเวลาไม่ต่อเนื่อง $x(t) (t=1, 2, \dots, N)$ การแปลงเวฟเลทกั้นทะเล (Discrete Wavelet Transform :DWT) จะแยกส่วน ประกอบของอนุกรมเวลาโดยใช้เวฟเลทฟังก์ชัน $\psi_{j,k}(t)$ ตามสมการที่ (1) และ Scaling ฟังก์ชัน $\phi_{j,k}(t)$ ตามสมการที่ (2)

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k) \quad (1)$$

$$\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k) \quad (2)$$

เมื่อ $j, k \in \mathbb{Z}, j > 0$ คือ ระดับของความละเอียดในการแยก

สัญญาณ ถ้าค่า j มากขึ้นสัญญาณจะมีความถี่ต่ำลงโดยค่า k จะเป็นการเลื่อนพารามิเตอร์ $k=1,2,\dots,N/2$ N เป็นจำนวนข้อมูล และ Z เป็นเซตของจำนวนจริง

โดยสัญญาณ DWT จะถูกแทนด้วยผลรวมของ ฟังก์ชันหลายฟังก์ชันในเชิงตั้งฉาก เวฟเลตส่วนการประมาณค่า สัญญาณเวลาของ $x(t)$ จะถูก

แปลงเป็นแอมพลิจูดของค่าสัมประสิทธิ์ของแต่ละฟังก์ชันจาก

$c_{j,k}, d_{j,k}, \dots, d_{1,k}$ สัญญาณสามารถถูกรวมกลับได้โดยผลบวกของค่าสัมประสิทธิ์ ตามสมการที่ (3)

$$x(t) = \sum_k c_{j,k} \varphi_{j,k}(t) + \sum_k d_{j,k} \psi_{j,k}(t) + \sum_k d_{j-1,k} \varphi_{j-1,k}(t) + \dots + \sum_k d_{1,k} \psi_{1,k}(t) \quad (3)$$

จากสมการที่ 3 เริ่มต้นด้วยแทนด้วยฟังก์ชันที่มีระดับความละเอียดที่ j จากนั้นระดับความละเอียดจะเพิ่มเป็น $j+1$ สัมประสิทธิ์ของ DWT $c_{j,k}$ และ $d_{j,k}$ โดยการหาผลคูณภายใน ของฟังก์ชันพื้นฐานและสัญญาณต้นแบบตามสมการที่ 4 และสมการที่ 5

$$c_{j,k} = \langle x, \varphi_{j,k} \rangle = \sum_t x(t) \varphi_{j,k}(t) \quad (4)$$

$$d_{j,k} = \langle x, \psi_{j,k} \rangle = \sum_t x(t) \psi_{j,k}(t) \quad (5)$$

ระดับความละเอียดที่ j ซึ่งจะถูกรวบรวมเป็นสองส่วนตามสมการที่ 6

$$A_j(t) = \sum_k c_{j,k} \varphi_{j,k}(t), D_j(t) = \sum_k d_{j,k} \psi_{j,k}(t) \quad (6)$$


$A_j(t)$ ซึ่งเป็นรายละเอียดของสัญญาณแบบหยาบๆจะเรียกว่าเป็นสัมประสิทธิ์สัญญาณส่วนประมาณระดับที่ j ของ $x(t)$ ซึ่งจะบรรจุไปด้วยสัญญาณที่มีความถี่ต่ำซึ่งเป็นส่วนประกอบ ของ $x(t)$ ส่วน $D_j(t)$ จะเรียกว่าเป็นสัมประสิทธิ์สัญญาณส่วนส่วนรายละเอียดที่ระดับ j ของ $x(t)$ ถ้าหากใช้ความละเอียด j เป็นระดับของการแยกส่วนประกอบโดยเวฟเลต สัญญาณที่ถูกแยกจะถูกรวมกลับเป็น $x(t)$ ได้ โดยนำสัมประสิทธิ์สัญญาณส่วนประมาณค่า มารวมกับสัมประสิทธิ์สัญญาณส่วนรายละเอียดในระดับต่างๆ ตามสมการที่ (7)

$$x(t) = A_j(t) + D_j(t) + D_{j-1}(t) + \dots + D_1(t) \quad (7)$$

3. การพยากรณ์ความต้องการใช้ไฟฟ้าระยะสั้นโดยใช้โครงข่ายประสาทเทียม และเวฟเลต

สำหรับงานวิจัยนี้ได้นำเสนอขั้นตอน WNN-STLF โดยกำหนดให้อนุกรมเวลาเป็น $X(t), t = (1, \dots, N)$ เมื่อ t คือเวลา N คือจำนวนข้อมูลจุดประสงค์ของวิธีการนี้คือการพยากรณ์ล่วงหน้า 1 หน่วยเวลา คือ $X(N+1)$ วิธี WNN-STLF แบ่งเป็น 3 ขั้นตอนหลักคือ ขั้นตอนที่ 1 ขั้นตอนการเตรียมข้อมูล ขั้นตอนที่ 2 เตรียมโครงข่ายประสาทเทียมในการพยากรณ์ ขั้นตอนที่ 3 ทำการเรียนรู้และทดสอบการพยากรณ์ของ

โครงข่าย ดังรูปที่ 2 ซึ่งขั้นตอนวิธี WNN-STLF สามารถอธิบายรายละเอียดของทั้งสามได้ดังนี้




รูปที่ 2 แนวความคิดของวิธีการ WNN-STLF

3.1 การเตรียมข้อมูล

3.1.1 ข้อมูลอนุกรมเวลาการใช้ไฟฟ้าจะถูกแยกสัญญาณโดยเวฟเลต Daubechies2 [8] ที่ระดับความละเอียด 2 ทำให้ได้ 3 สัมประสิทธิ์ของเวฟเลตดังนี้ คือ สัญญาณสัมประสิทธิ์ส่วนประมาณค่า A_2 สัญญาณสัมประสิทธิ์ในส่วนรายละเอียด D_2 และ D_1 ดังรูปที่ 3

3.1.2 ข้อมูลต้นฉบับและสัมประสิทธิ์ของเวฟเลตจะถูกปรับค่า (Scaling) จากช่วงของข้อมูลจริงให้มีค่าอยู่ในช่วงระหว่าง $[-1,1]$ เพื่อใช้ในการฝึกสอนโครงข่ายประสาทเทียม

3.1.3 ข้อมูลต้นฉบับและสัญญาณสัมประสิทธิ์ของเวฟเลตจะถูกแปลงข้อมูลออกมาเป็นชุดทดสอบและชุดเป้าหมายโดยใช้ Sliding Window โดยมี Windows Size เท่ากับ 30



รูปที่ 3 ข้อมูลรัฐควินแลนด์ที่ถูกแยกสัญญาณ โดยเวฟเลต Daubechies2

ระดับ 2

3.2 การเตรียมโครงข่ายประสาทเทียมในการพยากรณ์

หลังจากที่ทำการเตรียมสัญญาณเสร็จแล้ว จะทำการพยากรณ์แต่ละสัญญาณสัมประสิทธิ์ของเวฟเลตโดยใช้โครงข่ายประสาทเทียม โดยการเตรียมโครงข่ายแบ่งออกเป็น 2 ส่วนคือ การเตรียมโครงข่ายสำหรับพยากรณ์แต่ละสัญญาณสัมประสิทธิ์ของเวฟเลต และการเตรียมโครงข่ายส่วนของการรวมกลับสัมประสิทธิ์ของเวฟเลต โดยทั้งสองแบบใช้โครงข่าย MLP และใช้การเรียนรู้แบบแพร่ย้อนกลับ (back-

propagation) และปรับน้ำหนักวิธี แบบ Scale Conjugate Gradient (SCG)[9]

3.2.1 โครงข่ายประสาทเทียมแบบ MLP สำหรับพยากรณ์สัญญาณสัมประสิทธิ์ของเวฟเลทที่ความละเอียดต่างๆที่แยกโดยเวฟเลท จำนวนของโครงข่ายพยากรณ์สัญญาณจะถูกสร้างเท่ากับจำนวนของจำนวนสัมประสิทธิ์ของสัญญาณที่แยกจากเวฟเลท โดยโครงข่ายทั้งหมดใช้สถาปัตยกรรมเหมือนกันทั้งหมดคือ 30:16:1 ชั้นนำเข้า 30 โหนด (พิจารณาโดยดูจากฤดูกาลของข้อมูลการใช้ไฟฟ้า คือ 1 วัน) ชั้นซ่อน 16 โหนด (โดยนำจำนวนโหนดชั้นนำเข้าข้อมูลมารวมกับชั้นแสดงผลแล้วหารด้วยสอง) ชั้นผลลัพธ์ ชั้นแสดงผล 1 โหนด ในชั้นซ่อนใช้ฟังก์ชันกระตุ้นแบบ Tangent sigmoid ส่วนชั้นแสดงผลใช้ฟังก์ชันกระตุ้นแบบผลรวมเชิงเส้น ใช้รอบการเรียนรู้ 1,000 รอบ

3.2.2 โครงข่ายประสาทเทียมส่วนรวมสัญญาณกลับให้เป็นค่าที่พยากรณ์ ใช้โครงข่ายแบบ MLP แบบ 3:1 คือในชั้นนำเข้า จะมีจำนวนเท่า 3 โหนด โดยได้จาก ผลลัพธ์โครงข่ายประสาทที่ใช้พยากรณ์สัญญาณของแต่ละระดับความละเอียดได้ และชั้นแสดงผล 1 โหนด ซึ่งเป็นผลลัพธ์ของการพยากรณ์ล่วงหน้าหนึ่งหน่วยเวลาโดยชั้นแสดงผลใช้ฟังก์ชันกระตุ้น ผลรวมเชิงเส้น ใช้รอบการเรียนรู้ 1,000 รอบ

3.3 การพยากรณ์ WNN-STLF

การทำงานของโครงข่ายในการพยากรณ์ความต้องการไฟฟ้าแบ่งออกเป็น 2 ขั้นตอนคือ

3.3.1 ขั้นตอนการเรียนรู้ในข้อมูลชุดทดสอบใช้วิธีการ Iterative Forecasting [1] ซึ่งเป็นกระบวนการเรียนรู้โดยการป้อนชุดข้อมูลทดสอบและชุดเป้าหมายเข้าในโครงข่ายเพื่อให้โครงข่ายมีการปรับค่าน้ำหนักเพื่อลดความผิดพลาดให้อยู่ในระดับที่ยอมรับได้ หรือไม่มีความผิดพลาดเลย การฝึกโครงข่ายให้โครงข่ายสามารถประมาณค่าฟังก์ชันได้

3.3.2 ขั้นตอนการพยากรณ์ข้อมูลในชุดทดสอบ โครงข่ายที่ใช้ในการพยากรณ์สัญญาณและโครงข่ายรวมสัญญาณของความละเอียดแต่ละระดับใช้วิธีพยากรณ์แบบอนุกรมเวลาล่วงหน้าไป หนึ่งหน่วยเวลา (One Step Direct Forecasting) [1] โดยใช้ชุดข้อมูลชุดทดสอบสำหรับทดสอบโดยเฉพาะ

3.4 ประมวลผลข้อมูลหลังการพยากรณ์

3.4.1 ประเมินประสิทธิภาพของการพยากรณ์ของโครงข่ายโดยใช้วิธีการวัดประสิทธิภาพที่ได้รับความนิยมได้ซึ่งจะอธิบายในหัวข้อที่ 4.2

3.4.2 ปรับแก้ผลลัพธ์ที่พยากรณ์ได้ระหว่างช่วง [-1,1] ให้เป็นค่าในช่วงของข้อมูลอนุกรมเวลาความต้องการใช้ไฟฟ้าเพื่อนำไปในการวางแผน

4. การทดลองและผลการทดลอง

ในงานวิจัยนี้วิธีการ WNN-STLF ที่นำเสนอ ในส่วนของผลการพยากรณ์ ใช้วิธีรวมกลับสัญญาณให้เป็นค่าที่โครงข่ายพยากรณ์ได้โดย 2 แบบคือ

(1) รวมโดยเวฟเลทสัญญาณกลับ(WNN-STLF-WV)

(2) รวมโครงข่ายแบบ MLP (WNN-STLF-MLP)

โดยวิธี WNN-STLF ทำการเปรียบเทียบกับผลกับวิธีการพยากรณ์ 2 วิธีการพยากรณ์คือ

1) วิธีพยากรณ์โดยใช้โครงข่าย MLP แบบ SNN ในการเรียนรู้และพยากรณ์ข้อมูลอนุกรมเวลาชุดต้น (MLP-SSN) โดย 30:16:1 ประกอบด้วย ชั้นนำเข้า 30 โหนด ชั้นซ่อน 16 โหนด และชั้นแสดงผล 1 โหนด วิธีการเรียนรู้และปรับน้ำหนัก รับการเรียนรู้ และฟังก์ชันกระตุ้นเหมือนกับโครงข่ายในหัวข้อที่ 3.2.1

4.1 ข้อมูลที่นำมาใช้ในการทดลอง

ข้อมูลที่นำมาใช้ในการทดลองเป็นข้อมูลอนุกรมเวลาจัดเก็บโดย [10] คือ ควินส์แลนด์ เดือนมกราคม ค.ศ. 1999 มีจำนวน 1400 ระเบียบ

ลักษณะของการจัดเก็บข้อมูลแสดงตามตารางที่ 1 ข้อมูลความต้องการใช้ไฟฟ้าจะถูกบันทึกทุกๆ 30 นาที ค่าการใช้กระแสไฟฟ้ามีหน่วยวัดเป็นเมกะวัตต์ (MW) ค่ามากที่สุด ค่าน้อยสุดและค่าเฉลี่ยของข้อมูลทั้งสองชุด แสดงในตารางที่ 2 ข้อมูลถูกแบ่งเป็นสองส่วน ส่วนแรกเป็นข้อมูลในการเรียนรู้ของโครงข่าย 1,000 ระเบียบ และส่วนที่สองเป็นข้อมูลทดสอบความถูกต้องของโครงข่าย 400 ระเบียบ

ตารางที่ 1 ตัวอย่างข้อมูลรัฐควินส์แลนด์

REGION	SETTLEMENTDATE	DEMAND
QLD1	1/1/1999 0:30	5,153.98
QLD1	1/1/1999 1:00	5,002.30
QLD1	1/1/1999 1:30	4,880.10
QLD1	1/1/1999 2:00	4,718.89
QLD1	1/1/1999 2:30	4,619.37

ตารางที่ 2 แสดงค่าที่ได้จากการวัดการใช้ไฟฟ้า

DATA	MIN	MEAN	MAX
QDL/01/1999	3,783.16	4071.59	4,360.02

4.2 การวัดประสิทธิภาพของการพยากรณ์

ในงานวิจัยนี้ได้ทำการวัดประสิทธิภาพของผลการทดลองโดยวิธีร้อยละของค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error : MAPE)[6] วิธีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์(Mean Absolute Error :

MAE), วิธีบรรทัดฐานของค่าคลาดเคลื่อนกำลังสองเฉลี่ย(Normalize Mean squared error : NMSE) และวิธีรากที่สองของค่าความคลาดเคลื่อนเฉลี่ย (Root Mean Square Error :RMSE) [11]

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right| \times 100\% \quad (8)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |x(t) - \hat{x}(t)| \quad (9)$$

$$NMSE = \frac{1}{\sigma^2 N} \sum_{t=1}^N (x(t) - \hat{x}(t))^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (x(t) - \hat{x}(t))^2} \quad (11)$$

โดย $x(t)$ หมายถึง ค่าจริงของข้อมูล ณ เวลา t

$\hat{x}(t)$ หมายถึง ค่าพยากรณ์ข้อมูล $x(t)$

σ^2 หมายถึง ค่าความแปรปรวนของข้อมูล

N หมายถึง จำนวนข้อมูลทั้งหมดที่ใช้พยากรณ์


การวัดประสิทธิภาพของวิธีการ WNN-STLF ที่นำเสนอ ผู้วิจัยได้เพิ่มการวิเคราะห์ความผิดพลาด โดยทำการคำนวณหาค่าความแปรปรวนของค่าคลาดเคลื่อนสัมบูรณ์ด้วยสัญลักษณ์ σ^2_{APE} เพื่อทำการวัดการกระจายตัวของความค่าผิดพลาดและ วิเคราะห์อันดับของค่าคลาดเคลื่อนสัมบูรณ์ด้วยสัญลักษณ์ η_{APE} เพื่อทำการแจกแจงสะสมของค่าร้อยละความคลาดเคลื่อนเฉลี่ย (APE) ที่ 90 % [6]

4.3 ผลการทดลอง

ผลการทดลองข้อมูลชุดทดสอบรัฐควีนส์แลนด์ เดือน มกราคม ค.ศ. 1999 แสดงในตารางที่ 3 วิธีการวัดประสิทธิภาพทั้ง 4 มิติ พบว่าวิธีการ WNN-STLF ที่นำเสนอ ให้ผลลัพธ์การพยากรณ์ที่มีความแม่นยำสูงกว่าวิธี MLP ที่พยากรณ์ข้อมูลอนุกรมเวลาชุดต้นแบบ

5. สรุปผลการทดลองและข้อเสนอแนะ

การพยากรณ์ความต้องการใช้ไฟฟ้ามีความสำคัญในส่วนของการวางแผนการผลิตและการบริหารจัดการระบบความมั่นคงด้านไฟฟ้า โดยใช้เวลา และ โครงข่ายประสาทเทียมแบบ MLP แต่ละโครงข่าย ทำการพยากรณ์แต่ละสัปดาห์ของเวลา ซึ่งแต่ละค่าสัปดาห์ของเวลาที่พยากรณ์ได้ จะถูกรวมกลับ โดยโครงข่ายประสาทเทียม ทำให้มีความแม่นยำสูงและมีค่าความผิดพลาดต่ำกว่าการใช้โครงข่าย SNN ในการพยากรณ์ ข้อเสนอแนะในการปรับปรุงให้การพยากรณ์ดีขึ้นคือ 1.ควรหาเวลาและ การเลือกกระดัดความละเอียดที่เหมาะสมในการเตรียมข้อมูลเพื่อป้อนเข้าสู่โครงข่ายประสาทเทียม 2. ควรหาวิธีที่จะทำให้แต่ละโครงข่ายมีการวางนัยโดยทั่วไปเช่นวิธี GA , PSO , หรือวิธีดัดแปลงโครงข่าย เพราะต้องใช้จำนวนโครงข่ายมากกว่าวิธี SNN 3.ควรนำปัจจัยอื่นๆที่เกี่ยวข้องใช้ในการพยากรณ์ให้โครงข่ายมีความแม่นยำขึ้น



รูปที่ 4 ผลการทดลองการพยากรณ์ความต้องการใช้ไฟฟ้า และค่าความผิดพลาด APE ในวิธีการพยากรณ์แบบต่างๆโดยใช้ชุดทดสอบความต้องการใช้ไฟฟ้ารัฐควีนส์แลนด์เดือน มกราคม ค.ศ. 1999

ตารางที่ 3 ผลการทดลอง ข้อมูลชุดทดสอบรัฐควินส์แลนด์เดือนมกราคม ค.ศ. 1999

วิธีการ	ค่าความผิดพลาดของการวัดประสิทธิภาพในมิติต่างๆ					
	MAPE	σ_{APF}^2	η_{APE}	$RMSE \times 10^{-2}$	$NMSE10^{-3}$	$MAE \times 10^{-2}$
WNN-STLF-MLP	0.5981	0.2794	1.3573	2.2587	2.6565	2.0550
WNN-STLF-WR	0.5982	0.2794	1.3575	2.7495	2.6568	2.0550
MLP	0.8525	0.5715	1.6394	3.3132	4.4976	2.5310

เอกสารอ้างอิง

- [1] H.S. Hippert, C.E. Perdreira, and R.C Souza, "Neural Networks for Short-Term Load Forecasting A Review and Evaluation".IEEE transaction on perwer system, 2001.Vol. 16, No.1.
- [2] Roiger J.R., and Geatz M.W., "Data Mining A Tutorial-Based Primer", Addison Wesley, Boston, 2003 P56-65.
- [3] Yoshio Kajitani, Keith W. Hipel ,A.Ian Mcleod. "Forecasting Nonlinear Time Series With Feed-Forward Neural Network: A Case Study of Canadian Lynx data."Journal of Forecasting.2005 p.102-107.
- [4] Haykin S. "Neural Network a comprehensive foundation"1999;International Edition, second edition: 50-312.
- [5] Clemen R.T., "Combining forecast : A review and annotated bibliography". International Journal of Forecasting. 1989 p.59-583.
- [6] Bai-Ling Zhang, Zhao-Yang Dong, 2001 "An adaptive neural-wavelet model for Short term load forecasting."Electric Power Systems Research. p.121-129.
- [7] S.G. MALLET, "A Theory for Multiresolution Signal Decomposition:The Wavelet Representation" IEEE TRANSECTION ON PATTERN AND MACHINE INTELLIGENCE. 1989VOL.11 NO.7
- [8] Shuyan C,Wei Wang, "A hybrid approach of Volume forecasting based on wavelet transform, neural network and markov model" IEEE transaction 2005
- [9] Martin Fodslette Moller. A scaled conjugate gradient algorithm for fast supervised learning. Neural Networks, 6:525--533, 1993.
- [10] Australian National Electricity Market Management Company Limited(NEMMCO) <http://www.nemmco.com.au/>
- [11] กัลยา วานิชย์บัญชา. การวิเคราะห์สถิติ : สถิติสำหรับการบริหารและวิจัย. 2539. พิมพ์ครั้งที่ 6 โรงพิมพ์จุฬาลงกรณ์มหาวิทยาลัย. หน้า 360-397.