

### บทที่ 3


## การประยุกต์ใช้โครงข่ายประสาท ในการพยากรณ์ความต้องการกำลังไฟฟ้าระยะสั้น

### 3.1 โครงข่ายประสาท

#### 3.1.1 ทฤษฎีโครงข่ายประสาท

โครงข่ายประสาท คือ ระบบที่ประกอบไปด้วยหน่วยประมวลผลแบบง่าย ๆ หลาย ๆ ตัวที่อาจเชื่อมโยงกันอย่างทั่วถึงหรือไม่ทั่วถึงก็ได้ การทำงานของระบบนั้นขึ้นอยู่กับลักษณะการเชื่อมโยงระหว่างหน่วยประมวลผลและค่าน้ำหนัก ซึ่งเป็นชุดสถาปัตยกรรมสำหรับการประมวลผลข้อมูลที่อยู่ในรูปแบบต่างๆอาจเป็นซอฟต์แวร์หรือโครงสร้างของฮาร์ดแวร์ที่ถูกสอนให้รู้จักรูปแบบข้อมูลแบบต่าง ๆ สำหรับการทำงานของโครงข่ายประสาทจะทำการเรียนรู้จาก การจำแนกข้อมูลจำนวนมากโดยเทียบกับข้อมูลเข้า - ออกเพื่อปรับตัวแปร หรือค่าน้ำหนักที่จุดที่เซลล์ประสาทติดต่อกันซึ่งกันและกัน จากนั้นชั้นของหน่วยประมวลผลในแต่ละระดับจะสื่อสารกัน หน้าที่ของหน่วยประมวลผลเหล่านี้และโครงสร้างของการเชื่อมโยงได้แนวคิดจากการศึกษาระบบประสาทของมนุษย์ ซึ่งประกอบด้วยส่วนประกอบหลัก ๆ ดังนี้

- ชั้นข้อมูลอินพุต (input layer)
- ชั้นซ่อนของหน่วยประมวลผล (hidden layer)
- ชั้นแสดงเอาต์พุต (output layer)



ภาพประกอบ 3-1 แสดงถึงส่วนประกอบหลักของโครงข่ายประสาท

◎ คือ เซลล์ประสาท

เนื่องจากสมองของมนุษย์มีความสามารถเหนือกว่าคอมพิวเตอร์ในงานหลายชนิด ตัวอย่างที่เห็นได้ชัดคือ กระบวนการจดจำภาพหรือรูปแบบ หน้าตาและวัตถุ โดยสามารถตัดสินใจว่าภาพหน้าตาหรือวัตถุดังกล่าวเป็นอะไรหรือเป็นใคร กระบวนการจดจำและการตัดสินใจนี้เป็นกระบวนการที่มีความสามารถเร็วกว่าวิธีการจดจำภาพหรือรูปแบบที่ใช้ในระบบคอมพิวเตอร์ ดังนั้นจึงมีการศึกษาเพื่อหาแบบจำลองของเซลล์ประสาท รูปแบบของโครงข่ายประสาทเทียม และกระบวนการเรียนรู้ (learning algorithm) แล้วได้นำมาประยุกต์ใช้ในเครื่องคอมพิวเตอร์ โครงข่ายประสาทได้ถูกพัฒนาขึ้นตั้งแต่ปี พ.ศ. 2483 โดย McCulloch and Pitts และได้รับการพัฒนาต่อมาจนถึงปัจจุบัน ซึ่งได้นำทฤษฎีนี้ไปประยุกต์ใช้กับงานต่าง ๆ เช่น งานในด้านการจดจำ การวินิจฉัยโรคทางการแพทย์ การบริหารฐานข้อมูลและการประมวลสัญญาณ เป็นต้น

### 3.1.2 ประวัติความเป็นมาและวิวัฒนาการ [চিত্রিংค์ ต้นประเสริฐ, 2542]

โครงข่ายประสาท เป็นการคำนวณชนิดหนึ่งที่ได้รับแรงบันดาลใจจากโมเดลทางชีวภาพ นั่นคือมีความพยายามที่จะลอกเลียนความสามารถของสมองมนุษย์ ทฤษฎีของโครงข่ายประสาท เริ่มตั้งแต่ปีทศวรรษ 1950 โดยนักฟิสิกส์ วิศวกรและนักชีววิทยา ผู้บุกเบิกเหล่านี้เริ่มต้นประยุกต์โครงข่ายประสาทให้แก้ปัญหาในการจำแนกแยกแยะ เช่น การจำแนกแยกแยะตัวอักษร เป็นต้น

ปลายทศวรรษ 1950 Frank Rosenblatt จากมหาวิทยาลัยคอร์เนล ได้พัฒนา Perceptron คือระบบประสาทเทียมเลียนแบบการทำงานของระบบประสาทสมองมนุษย์ ระบบของ Rosenblatt สามารถแยกแยะตัวอักษรซึ่งทำให้เกิดการพัฒนาเติบโตในงานวิจัยด้านโครงข่ายประสาท

ปี ค.ศ. 1969 Marvin Minsky ซึ่งเป็นหนึ่งในผู้ก่อตั้งความคิดในเรื่องปัญญาประดิษฐ์ ได้ทำให้การพัฒนาโครงข่ายประสาทนั้นต้องประสบความชะงักงันไปสิบกว่าปี โดยได้เขียนหนังสือชื่อว่า Perceptron ร่วมกับ Papert โจมตีว่า Perceptron ปราศจากคุณค่าทางวิทยาศาสตร์ และได้พิสูจน์ให้เห็นว่า Perceptron ขณะนั้นไม่สามารถแก้ปัญหาทางด้านแยกแยะรูปแบบบางอย่างได้ เช่น ไม่สามารถแยกตัว T กับตัว C ออกจากกันได้ (Minsky และ Papert, 1969)

กลุ่มทางด้านโครงข่ายประสาทไม่ได้มีผลงานอะไรอีกจนกระทั่งประมาณปี ค.ศ. 1978 จึงมีการรวมตัวของนักภาษาศาสตร์ นักปรัชญา นักคอมพิวเตอร์ นักชีววิทยา นักฟิสิกส์และนักจิตวิทยา โดยมีศูนย์กลางอยู่ที่มหาวิทยาลัยซานดิเอโก และเรียกตัวเองว่า PDP Group (parallel distributed processing group) ได้ทำให้โครงข่ายประสาทได้เกิดใหม่อีกครั้ง และในปี 1986 หนังสือ 2 เล่ม ชื่อ Parallel Distributed Processing Vol.1-II ซึ่งขณะนี้ถือกันว่าเป็นคัมภีร์ของโครงข่ายประสาทได้ดี พิมพ์จำหน่าย (มนตรี วงศ์ทองศรี, 2534)

ตาราง 3-1 แสดงถึงยุคต่าง ๆ ของการวิจัยทางโครงข่ายประสาท

เวลา	ผู้ค้นคว้า	งานวิจัย
แนวความคิดพื้นฐาน ค.ศ. 1940-1960	Mc Culloch & Pitts Farley & Clark/Hebb Rosenblatt Stienbuch, Taylor	Boolean Logic Synaptic Learning Rule Perceptron Associative Memory
ทฤษฎีขั้นพื้นฐาน ค.ศ. 1960-1980	Widrow & Hoff Albus Anderson Von Der Malsburg Fukushima Grossberg&Carpenter	LMS Algorithm (Adaline/Madaline) Linear Associative Learning NGO-Cognitron Adaptive Resonance Ttheory(ART) and Boundary Contour System (BCS)
ยุคเฟื่องฟู ค.ศ. 1980 - ปัจจุบัน	Kohonen Feldman & Ballard Hopfield Reily, ET.AL. Hinton & Sejnowski Rumelhart, Et.AL. Edeman, Reeke	Feature Maps Connectionist Models Associative Memory Theory Reduced Coulomb Energy Boltman Machine Backpropagation and PDP Books Dadrwin III (Neural Darwinish)

ตาราง 3-2 แบบจำลองของโครงข่ายประสาทเทียมในช่วงปี 1950-19867

ชื่อของแบบจำลอง	ผู้คิดค้น	ปีที่พัฒนา	การใช้งาน
1. Perceptron	F, Rosenblatt	1957	อ่านตัวพิมพ์ดีด
2. Madaline	B. Widrow	1960-62	Adaptive Equalizer
3. Avalanche	S. Grossberg	1967	เข้าใจคำพูด
4. Celebellatron	D. Mar, J. Albus & A. Pellionez	1969-82	ควบคุมการเคลื่อนไหวแขนของหุ่นยนต์
5. Back Propagation	P. Werbos, D. Parker & D. Rumelhart	1974-85	เขียนแบบฟังก์ชันทางคณิตศาสตร์ อ่านตัวเขียน, คำพูด, ทำนายหุ้น
6. Brain state in a box	J. Anderson	1977	สกัดข้อมูลบางอย่างจากฐานข้อมูล
7. Neocognition	K. Fukushima	1978-84	อ่านตัวเลขและตัวอักษรเขียน
8. Adaptive Resonance	G. Carpenter & S. Grossberg	1978-86	Pattern Recognition
9. Self organizing map	T. Kohonen	1980	จำลองลักษณะของพื้นผิววัตถุ เช่น ปีกเครื่องบิน
10. Hopfield	J. Hopfield	1982	ทำนายบางส่วนของข้อมูลที่หายไป เช่น บางส่วนของหน้าคน
11. Bidirection associative memory	B. Kosko	1985	Content addressable associative memory
12. Boltzmann & Cauchy machine	J. Hinton, T. Sejnowsky & H. Szu	1985-86	Pattern Recognition
13. Counter Propagation	R. Hecht-Nielsen	1986	อัดข้อมูลของภาพให้ย่อลง Table look up

### 3.1.3 คุณสมบัติของโครงข่ายประสาท [Wasserman, 1989]

โครงข่ายประสาทมีคุณสมบัติบางอย่างคล้ายกับสมองมนุษย์ เช่น สามารถเรียนรู้จากประสบการณ์ เช่น การปรับตัวเองเข้ากับสิ่งแวดล้อมได้เป็นอย่างดี และสามารถอนุมานจากสิ่งที่เรียนรู้ไปสู่สิ่งที่ไม่เคยเรียนรู้มาก่อนหรือที่เรียกว่าความสามารถในการบ่งชี้ทั่วไป (generalization)

โครงข่ายประสาทมีคุณสมบัติ 2 ประการคือ

1). การเรียนรู้ (learning)

โครงข่ายประสาทสามารถเรียนรู้จากชุดการสอนที่เราป้อนให้

2). การระลึกหรือจดจำได้ (recall)

โครงข่ายประสาทสามารถระลึกได้ทั้งชุดการสอนและชุดการทดสอบ หรือชุดทั่วไปได้ดี ในระดับที่ยอมรับได้ โดยชุดการทดสอบจะมีความแตกต่างจากชุดการสอนอยู่บ้าง ซึ่งความแตกต่าง เรียกว่ามีสิ่งปนเปื้อน หรือสิ่งบิดเบือนของข้อมูลประเภทนั้น ๆ ซึ่งเป็นลักษณะของสภาพความเป็นจริงที่เกิดขึ้น

โครงข่ายประสาทเทียมในทัศนะของคอมพิวเตอร์จะประกอบด้วย processing elements (PE) เชื่อมโยงกันหลายๆตัวทำงานในลักษณะขนานคล้ายกับเซลล์ประสาทในสมองมนุษย์ เพื่อแปลงข้อมูลจากรูปหนึ่งเป็นอีกรูปหนึ่ง การใช้งานโครงข่ายประสาทนี้จะเป็นไปในรูปแบบของการ “สอน” แทนที่จะเป็นการป้อนโปรแกรม ส่วนจุดมุ่งหมายของการสอนโครงข่ายประสาทคือ การกระทำให้โครงข่ายนี้สามารถแสดงคำตอบที่ยอมรับได้ ส่วนการป้อนข้อมูลก็จะเป็นไปในรูปของการป้อนข้อมูลที่ถือว่ารู้อยู่แล้วเข้าไปในโครงข่ายประสาทพร้อมด้วยตัวเลขที่แสดงค่าน้ำหนักกำกับไว้ที่คอนเน็คชั่นต่าง ๆ ที่ปรากฏอยู่ในสถาปัตยกรรมของโครงข่ายประเภทนี้ แล้วบอกให้โครงข่ายทำงาน ซึ่งในขณะที่โครงข่ายทำงานอยู่จะมีการปรับค่าของตัวเลขที่แสดงน้ำหนัก โดยใช้ criteria ต่าง ๆ เข้าช่วย จนกระทั่งเอาที่พุดที่ได้ออกมา นั้นถูกต้องแม่นยำและจัดอยู่ในเกณฑ์ที่น่าพอใจ ตัวเลขที่เป็นกลไกที่ทำให้โครงข่ายประสาทสามารถเรียนรู้และจดจำได้จะอยู่ในรูปที่เรียกว่า weighted matrix of interconnections ลักษณะการทำงานแบบนี้จะทำให้ผู้ใช้โครงข่ายประสาทสามารถป้อนข้อมูลใหม่ ๆ เข้าไปแล้วปล่อยให้ทำหน้าที่ของโครงข่ายเพื่อที่จะหาทางตอบรับเอาเองว่าจะจัดการกับข้อมูลที่เพิ่มในภายหลังอย่างไร

โครงข่ายประสาทต่างจากดิจิทัลคอมพิวเตอร์ตรงที่โครงข่ายประสาทไม่เหมาะที่จะใช้ในการคำนวณที่ต้องการความละเอียดสูง เนื่องจากโครงข่ายแบบนี้เหมือนสมองคนมากกว่าดิจิทัลคอมพิวเตอร์ นอกจากนี้ในขณะที่แก้ปัญหา นั้น โครงข่ายประสาทจะบอกไม่ได้ว่าแก้ปัญหาให้อย่างไร ส่วนสถานภาพของเทคโนโลยีในด้านโครงข่ายประสาทเท่าที่เป็นอยู่ในขณะนี้ยังไม่มีโครงข่ายประสาทของแท้ที่เรียกว่า biological neural network clones จะมีเพียงความสามารถในการทำ ซิมูเลชันสำหรับอาร์ติฟิเชียลโครงข่ายประสาทในดิจิทัลแมชีนเท่านั้น จึงเหมาะสำหรับงานทางด้าน pattern recognition และ functional synthesis

## ข้อเปรียบเทียบระหว่างการประมวลผลแบบดั้งเดิมกับโครงข่ายประสาท

### 1.) การประมวลผลแบบดั้งเดิม (traditional approach)

เป็นการวิเคราะห์ข้อมูลโดยมนุษย์ คำนึงทรัพยากรมนุษย์จะถูกใช้ในการพัฒนาอัลกอริทึมและโปรแกรม ตัวอย่างเช่น การประมวลผลภาพในการระบุว่าเป็นแมว, สุนัข หรือกระต่าย ทำให้เกิดโปรแกรม 3 โปรแกรมในการบ่งบอกภาพแต่ละภาพ และเมื่อมีภาพชนิดใหม่ ๆ ขึ้นมา โปรแกรมก็ไม่สามารถที่จะบอกได้ ต้องทำการพัฒนาอัลกอริทึมและโปรแกรมขึ้นมาใหม่

### 2.) การประมวลผลแบบโครงข่ายประสาท (neural network approach)

จากตัวอย่างการประมวลผลภาพ เริ่มแรกเราจะให้ภาพแต่ละภาพเป็นข้อมูลอินพุต และเอาที่พุตเป็นข้อความที่ระบุชนิดของภาพนั้น เช่น แมว สุนัข หรือกระต่าย โดยผ่านกระบวนการสอนให้โครงข่ายประสาทรู้จักจำแนกชนิดของภาพต่าง ๆ โดยค่าน้ำหนักจะถูกปรับแต่งอยู่ตลอดเวลา

ในกระบวนการสอน จะมีการสอนวนซ้ำหลาย ๆ รอบ เพื่อให้โครงข่ายประสาทเกิดการเรียนรู้เมื่อสิ้นสุดการสอนแล้วโครงข่ายประสาทก็จะสามารถจำแนกชนิดของภาพได้ และเมื่อมีภาพใหม่ ๆ ที่ต้องการให้โครงข่ายประสาทรู้จักก็สามารถทำในทำนองเดียวกันและต้องมีการสอนใหม่ แต่ทำให้ประหยัดเวลาและแรงงานในการพัฒนาโปรแกรมขึ้นมาใหม่

การเก็บข้อมูลของโครงข่ายประสาทเป็นแบบกระจายและถูกใช้ร่วมกันโดยหลาย ๆ เซลประสาท ซึ่งต่างกับแบบดั้งเดิมคือข้อมูลจะเก็บไว้ในหน่วยความจำ การเก็บข้อมูลของโครงข่ายประสาทแบบกระจายนั้นทำให้เกิดความซ้ำซ้อน ซึ่งเป็นการเพิ่มความปลอดภัย คือเป็นระบบสำรองทดแทน (fault/error tolerance system) ได้อย่างดี

ชุดการสอนที่ใช้สอนโครงข่ายประสาทมีผลต่อการเรียนรู้ ถ้าเป็นชุดตัวอย่างที่ดีจะทำให้เกิดการเรียนรู้ได้ดีและเร็ว แต่ถ้าเป็นชุดข้อมูลการสอนที่ไม่ดีทำให้การเรียนรู้ไม่ดีเท่าที่ควร หรือไม่เกิดการเรียนรู้เลย

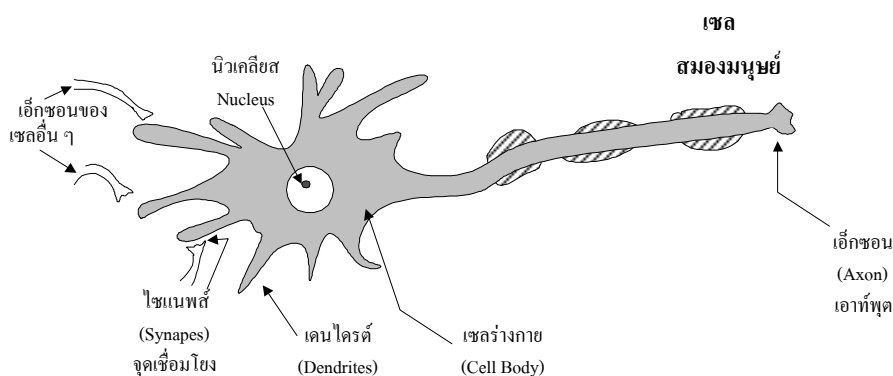
ตาราง 3-3 แสดงการเปรียบเทียบระหว่างการประมวลผลแบบดั้งเดิมกับโครงข่ายประสาท

การประมวลผลแบบดั้งเดิม	โครงข่ายประสาท
การพัฒนาเน้นไปที่อัลกอริทึมสำหรับทุกกรณีที่เกิดขึ้น	การพัฒนาเน้นที่ระบบการสอน
ต้องเขียนโปรแกรมล่วงหน้า-ใช้กฎและตรรกเพื่อสร้างเอาต์พุต	เรียนรู้จากตัวอย่างเพื่อเอาต์พุตที่ถูกต้อง
ขึ้นกับกฎ/ตรรก	ขึ้นกับความสัมพันธ์
ประมวลผลโดยอาศัยขั้นตอนต่าง ๆ ที่แน่นอนและให้ผลออกมาตามที่คาดคะเนเอาไว้	อาศัยวิธีการประมวลผลข้อมูลที่แตกต่างกันไปในแต่ละกรณีของปัญหา
การตัดสินใจต้องใช้ความรู้และข้อมูลทั้งหมด	สามารถจัดการกับข้อมูลที่ไม่สมบูรณ์ หรือข้อมูลที่มีความสับสนได้
ตัดสินใจในรูปของ ใช่ หรือ ไม่ใช่ทางคณิตศาสตร์หรือตรรกศาสตร์	ตัดสินใจโดยอาศัยตัวเลขแสดงน้ำหนักบนฐานของข้อมูลตัวเลขที่สามารถแสดงความเอนเอียง (Fuzzy) ตลอดจนยอมรับข้อมูลที่ไม่สมบูรณ์ได้
ได้คำตอบเดิมเสมอ	บางครั้งอาจผิดพลาด-จะเตรียมคำตอบที่ยอมรับได้ แต่ไม่จำเป็นต้องเป็นคำตอบที่ดีที่สุด
ให้คำตอบที่แน่นอน เมื่อให้เวลาคำนวณอย่างเพียงพอ	ให้คำตอบโดยประมาณสำหรับปัญหาที่ซับซ้อนมาก ๆ
เหมาะสำหรับระบบที่ต้องการความแม่นยำในการคำนวณ, มีการไหลของข้อมูลเป็นลำดับและมีตรรกที่ดี	เหมาะสมเมื่อไม่มีกฎที่แน่นอนและต้องการการตัดสินใจ
ประมวลผลข้อมูลในรูปไบนารี	ประมวลผลสัญญาณที่อยู่ในรูปของสัญญาณอนาล็อก ที่แปรปรวนอยู่ตลอดเวลา
อยู่บนพื้นฐานของสัญลักษณ์	อยู่บนพื้นฐานของรูปแบบ
สามารถอธิบายและตรวจสอบได้	ไม่สามารถอธิบายการตัดสินใจได้ทั้งหมด
ไม่สามารถจัดการกับข้อยกเว้นต่าง ๆ ได้	จัดการกับข้อยกเว้นต่าง ๆ ได้ดี
ค้นหาสิ่งที่ต้องการฐานข้อมูลขนาดใหญ่เพื่อให้ได้สิ่งที่ตรงกับความต้องการ	ค้นหาข้อมูลจากฐานข้อมูลโดยอาศัยหลักของความใกล้เคียงที่สุดเป็นเกณฑ์
มีวิธีการเก็บข้อมูลจำเพาะแน่นอน	เก็บข้อมูลโดยอาศัยเนื้อที่มีอยู่ในสื่อบันทึกข้อมูลเป็นเครื่องบอกตำแหน่งที่เก็บข้อมูลมากกว่าการจำเป็นที่ต้องรู้ตำแหน่งที่เก็บตั้งแต่แรก
ตายตัว	ปรับได้
แบบอนุกรม	แบบขนาน


### 3.1.4 แบบจำลองของเซลล์ประสาทและสถาปัตยกรรมของโครงข่ายประสาท

#### 3.1.4.1 แบบจำลองเซลล์ประสาท

เราอาจจะจำลองแบบโครงสร้างพื้นฐานของเซลล์ประสาทหรือเซลล์สมองของมนุษย์ ได้ดังภาพประกอบที่ 3-2 โดยมีหลักการทำงานดังนี้ เซลล์ประสาทรับข้อมูลอินพุตจากเซลล์ประสาทเซลล์อื่น โดยผ่านทางจุดเชื่อมโยงระหว่างเซลล์ที่เรียกว่า ซิแนปส์ (Synapse) สัญญาณข้อมูลจากซิแนปส์จะถูกส่งผ่านเดนไดรต์(Dendrite) ซึ่งเป็นส่วนที่ระโยงระยางรอบข้างของเซลล์ร่างกาย (cell body) สัญญาณข้อมูลอินพุตนี้จะได้รับการประมวลผลจากขบวนการที่เกิดขึ้นภายในเซลล์ร่างกาย และได้เป็นสัญญาณเอาต์พุตออกมา สัญญาณเอาต์พุตที่ได้จากเซลล์ประสาทนี้จะถูกส่งออกทางส่วนหนึ่งของเซลล์ที่เรียกว่า เอ็กซอน (Axon) แล้วสัญญาณดังกล่าวนี้ จะกระโดดข้ามผ่านซิแนปส์เป็นอินพุตของเซลล์ประสาทเซลล์อื่นต่อไป



**Biological processing element**



**A Neural network processing element**

ภาพประกอบ 3-2 แสดงโครงสร้างพื้นฐานเซลล์ประสาทของสมองมนุษย์

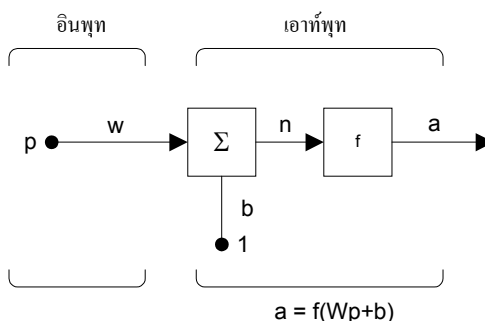


นักประสาทวิทยาได้พัฒนาโมเดล ซึ่งแสดงถึงวิธีที่สมองของมนุษย์ประมวลผลข้อมูลภายในสมองเซลล์ประสาทเชื่อมโยงกันอย่างซับซ้อนผ่านใยไขของเส้นทางการนำข้อมูลอินพุตและเส้นทางการเอาต์พุต ซึ่งนิเวศของเซลล์ประสาทเปรียบเสมือนหน่วยประมวลผลง่าย ๆ ที่รับสัญญาณไฟฟ้าจากเซลล์ประสาทอื่นหลาย ๆ เซลล์ประสาททางเส้นทางการนำข้อมูลเข้า (Dendrites) เซลล์ประสาทอื่น ๆ เป็นร้อย ๆ เซลล์ประสาทจะรับข้อมูลอินพุตนั้นเช่นกัน ถ้าผลของข้อมูลอินพุตมากกว่าระดับการกระตุ้น (Threshold) ซึ่งขึ้นกับค่าความแข็งแรงและจำนวนครั้งของสัญญาณที่ได้รับจากแต่ละการเชื่อมโยง เซลล์ประสาทจะส่งสัญญาณไปยังเส้นทางของเอาต์พุต (Axon)

เซลล์ประสาทที่ถูกกระตุ้นอาจเป็นตัวกระตุ้นเซลล์ประสาทอื่น แล้วเซลล์ประสาทที่ถูกกระตุ้นก็อาจจะเป็นตัวกระตุ้นเซลล์ประสาทอื่น อีกหลาย ๆ เซลล์ประสาทด้วยสัญญาณไฟฟ้า ทุกครั้งที่เหตุการณ์นี้เกิดขึ้นจะทำให้การเชื่อมโยงแข็งแรงขึ้น นั่นคือเกิดการเรียนรู้ ในสมองมนุษย์จะประกอบด้วยเซลล์ประสาทประมาณ 100 พันล้านเซลล์ประสาท ( $10^{11}$ ) และมีการเชื่อมโยงกันถึง  $10^{15}$  ซึ่งทำให้เกิดสัญญาณ  $10^{16}$  ครั้งต่อวินาที

ซึ่งสามารถแบ่งลักษณะของแบบจำลองเซลล์ประสาทได้ดังนี้ [ชูศักดิ์ ลิมสกุล, 2541]

### 1.) เซลล์ประสาทอินพุตเดียว

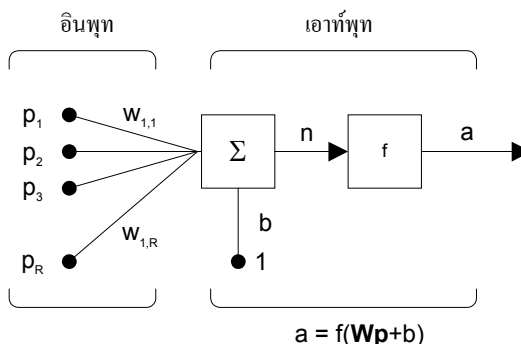


ภาพประกอบ 3-3 เซลล์ประสาทที่มีอินพุตเดียว

อินพุต  $p$  ถูกคูณด้วยค่าน้ำหนัก  $W$  รวมกับอีกอินพุตซึ่งมีค่าเท่ากับ  $1$  แล้วคูณด้วยไบอัส  $b$  ได้เป็นเอาต์พุตของวงจรรวม (net input,  $n$ ) หลังจากนั้นเอาต์พุตของวงจรรวมจะผ่านทรานส์เฟอร์ฟังก์ชัน (transfer function,  $f$ ) และให้เอาต์พุตเป็นเอาต์พุตของเซลล์ประสาท (output,  $a$ ) สามารถเขียนเป็นสมการได้เป็น

$$a = f(Wp + b) \quad (3-1)$$

2.) เซลล์ประสาทหลายอินพุต



ภาพประกอบ 3-4 เซลล์ประสาทที่มีหลายอินพุต

โดยทั่วไปแล้วเซลล์ประสาทจะมีอินพุตมากกว่า 1 อินพุต สมมติให้มี R อินพุต คือ  $p_1, p_2, \dots, p_R$  แต่ละอินพุตมีค่าน้ำหนักคือ  $w_{1,1}, w_{1,2}, \dots, w_{1,R}$  เซลล์ประสาทมีไบอัสเท่ากับ b จะได้เอาต์พุตของวงจรรวม (net input, n) เท่ากับ

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (3-2)$$


และได้สมการของเอาต์พุตของโครงข่ายเป็น  $a = f(Wp+b)$

3.1.4.2 ทรานส์เฟอร์ฟังก์ชันของโครงข่าย (transfer function)

ทรานส์เฟอร์ฟังก์ชันของโครงข่ายอาจเป็นฟังก์ชันเชิงเส้นหรือไม่เป็นเชิงเส้นก็ได้ ทรานส์เฟอร์ฟังก์ชันที่ใช้ในโครงข่ายประสาทมีหลายชนิด ที่นิยมใช้กันเช่น

1.) Hard Limit Transfer Function


ทรานส์เฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุต 2 ค่า ตามค่าเน็ตอินพุต กล่าวคือหา ค่าเน็ตอินพุตมีค่าต่ำกว่า 0 จะให้เอาต์พุตเป็น 0 และหากค่าเน็ตอินพุตมีค่ามากกว่าหรือเท่ากับ 0 จะให้ค่าเอาต์พุตเป็น 1



$$a = \text{hardlim}(n) = \text{hardlim}(Wp+b) \quad , a = \begin{cases} 0, n < 0 \\ 1, n \geq 0 \end{cases}$$

2.) Linear Transfer Function

ทรานเฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุตตามค่าเน็ตอินพุตที่ป้อนเข้ามา กล่าวคือ หากค่าเน็ตอินพุตมีค่าเท่าใดก็จะให้ค่าเอาต์พุตเป็นค่าเท่ากับเน็ตอินพุตนั้น ๆ



$$a = \text{purelin}(n) = \text{purelin}(Wp+b) = n$$

3.) Log-Sigmoid Transfer Function

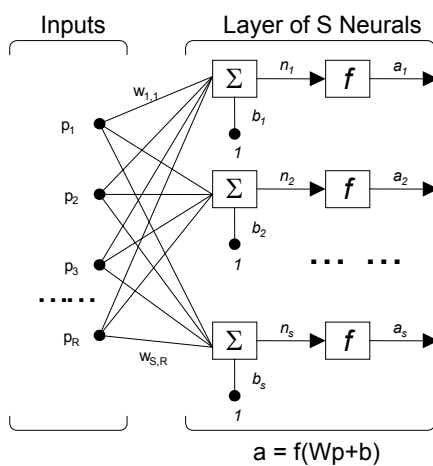
ทรานเฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุตระหว่าง 0 ถึง 1 โดยมีความสัมพันธ์ดังสมการข้างล่างนี้



$$a = \text{logsig}(n) = \text{logsig}(Wp+b) \quad , \quad a = \frac{1}{1 + e^{-n}}$$

3.1.4.3 สถาปัตยกรรมของโครงข่าย

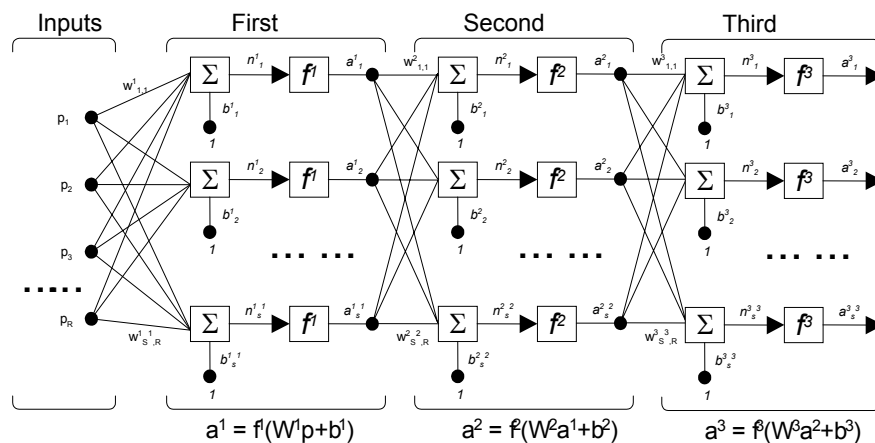
1.) เซลล์ประสาทชั้นเดียว



ภาพประกอบ 3-5 เซลล์ประสาทชั้นเดียว

โครงข่ายประสาทประกอบด้วยเมทริกซ์น้ำหนัก (**W**), วงจรรวม ( $\Sigma$ ), เวกเตอร์ไบอัส (**b**), ทรานส์เฟอร์ฟังก์ชัน (*f*), และเวกเตอร์เอาต์พุต (**a**)

## 2.) เซลประสาทหลายชั้น



ภาพประกอบ 3-6 เซลประสาทหลายชั้น

ภาพประกอบที่ 3-6 แสดงเซลล์ประสาทหลายชั้น โดยตัวเลขยกกำลังเป็นตัวเลขกำกับชั้น ชั้นที่มีอินพุตเป็นอินพุตของโครงข่ายเรียกว่าชั้นอินพุต (input layer), ชั้นที่มีเอาต์พุตเป็นเอาต์พุตของโครงข่ายเรียกว่าชั้นเอาต์พุต (output layer) ส่วนชั้นอื่น ๆ เรียกว่าชั้นซ่อน (hidden layer)

ในการเรียกชื่อโครงสร้างของโครงข่ายจะเรียกตามโครงสร้างของแต่ละชั้น เช่น โครงข่าย “2-4-1” จะหมายถึง โครงข่ายที่มี 1 ชั้นอินพุต 1 ชั้นซ่อน และ 1 ชั้นเอาต์พุต โดยในชั้นอินพุตจะมี 2 อินพุต ในชั้นซ่อนจะมี 4 เซล และในชั้นเอาต์พุตจะมี 1 เอาต์พุต เป็นต้น

จากภาพประกอบ จะได้สมการเอาต์พุตของชั้นซ่อนชั้นแรกเป็น

$$a^1 = f^1(W^1 p + b^1) \quad (3-3)$$

สมการเอาต์พุตของชั้นซ่อนชั้นที่สองจะได้

$$a^2 = f^2(W^2 a^1 + b^2) \quad (3-4)$$

และสมการเอาต์พุตของชั้นเอาต์พุตจะได้ว่า

$$a^3 = f^3(W^3 a^2 + b^3) \quad (3-5)$$

โดยเวกเตอร์อินพุต ( $p$ ), เมทริกซ์ของค่าน้ำหนัก ( $W$ ), เวกเตอร์ไบอัส ( $b$ ), ทรานส์เฟอร์ฟังก์ชัน ( $f$ ), และเวกเตอร์เอาต์พุต ( $a$ ) มีลักษณะเหมือนในเซลล์ประสาทชั้นเดียว

ความสามารถของโครงข่ายแบบเซลล์ประสาทหลายชั้น สามารถสรุปได้ดังนี้

- โครงข่ายเซลล์ประสาทหลายชั้นจะมีความสามารถสูงกว่าโครงข่ายเซลล์ประสาทชั้นเดียว
- จำนวนอินพุตและเอาต์พุตของโครงข่ายขึ้นอยู่กับลักษณะของแต่ละปัญหา
- โครงข่ายที่มีไบอัสจะมีความสามารถสูงกว่าโครงข่ายที่ไม่มีไบอัส

### 3.1.5 การเรียนรู้ของโครงข่ายประสาท (learning of neural network) [Wasserman, 1989]

โดยทั่วไปการเรียนรู้ของโครงข่ายประสาท ก็คือ การสอนโครงข่ายให้ทำการคำนวณข้อมูลเอาต์พุตพร้อมกับปรับปรุงค่าน้ำหนักโดยใช้ข้อมูลอินพุตที่ป้อนให้กับโครงข่ายโดยอาศัยกระบวนการทำซ้ำ (iterative) สามารถแบ่งเป็น 3 ประเภท คือ

#### 1.) การเรียนรู้แบบมีครู (supervised learning)

การเรียนรู้แบบมีครูต้องการชุดข้อมูลอินพุตและเอาต์พุตเป้าหมายเป็นชุดการสอนควบคู่ (training pair) โดยปกติการสอนโครงข่ายจะใช้ชุดการสอนควบคู่หลายชุด ในระหว่างการสอนโครงข่ายจะเกิดเอาต์พุตจริงซึ่งแตกต่างจากเอาต์พุตเป้าหมายทำให้ได้ค่าความคลาดเคลื่อนหรือค่าความผิดพลาด โครงข่ายจะเรียนรู้ข้อมูลทั้งสองโดยการปรับค่าน้ำหนัก เพื่อลดค่าความแตกต่างระหว่างค่าของตัวแปรเอาต์พุตของโครงข่ายกับค่าของข้อมูลเอาต์พุตที่ต้องการให้น้อยที่สุด การปรับค่าน้ำหนัก จะปรับค่าทีละน้อย ๆ โดยอาศัยกระบวนการทำซ้ำกับข้อมูลที่ละชุด จนกระทั่งค่าน้ำหนักในโครงข่ายลู่เข้า (converge) ซึ่งทั้งหมดนี้เรียกว่า การเรียนรู้ (learning or training) จากนั้นเมื่อเราป้อนค่าข้อมูลอินพุตล่าสุดซึ่งเป็นข้อมูลชุดใหม่ก็จะได้ค่าตัวแปรเอาต์พุตของโครงข่าย เช่น การให้โครงข่ายเรียนรู้ข้อมูลอินพุตเกี่ยวกับค่าความต้องการไฟฟ้าสูงสุด อุณหภูมิสูงสุดของวันในอดีต และข้อมูลเอาต์พุตเกี่ยวกับค่าความต้องการไฟฟ้าของวันถัดไปที่เกิดขึ้นในอดีต เมื่อโครงข่ายทำการเรียนรู้แล้วก็จะป้อนข้อมูลอินพุตล่าสุดให้กับโครงข่าย เพื่อที่จะหาค่าของตัวแปรเอาต์พุตซึ่งก็คือค่าพยากรณ์ความต้องการไฟฟ้าสูงสุดของวันถัดไป เป็นต้น ซึ่งในวิทยานิพนธ์นี้จะใช้ supervised learning เท่านั้น

การเรียนรู้ประเภทนี้ได้แก่ adaptive linear neural network (ADALINE) และ backpropagation neural network (BNN) เป็นต้น

## 2.) การเรียนรู้แบบไม่มีครู (unsupervised learning)

การเรียนรู้แบบไม่มีครูถูกพัฒนาขึ้นเพื่อให้ใกล้เคียงกับระบบการเรียนรู้ของสมองมนุษย์มากยิ่งขึ้น โดยมีเพียงชุดข้อมูลอินพุต กระบวนการเรียนรู้จะใช้หลักการทางสถิติ โดยหาค่าทางสถิติของชุดการสอน และจัดกลุ่มข้อมูลออกเป็นระดับต่าง ๆ โครงข่ายประสาทจะหาค่าเอาต์พุตเองจากความสัมพันธ์ระหว่างข้อมูลอินพุตและเอาต์พุต

การเรียนรู้ประเภทนี้ได้แก่ Hopfield network recognition และ self organizing feature map (SOFM) เป็นต้น

## 3.) การเรียนรู้เชิงบังคับ (reinforcement learning)

การเรียนรู้เชิงบังคับเป็นการเรียนรู้ทั้งแบบมีครูและไม่มีครู การเรียนรู้แบบไม่มีครู คือ ในระหว่างการสอนมีเพียงชุดข้อมูลอินพุต การเรียนรู้แบบมีครูคือเมื่อได้เอาต์พุตจะบอกว่าถูกหรือผิด แต่ไม่ได้บอกว่าเอาต์พุตที่ถูกต้องคืออะไร

### 3.1.6 การเรียนรู้แบบแพร่กลับ (Backpropagation learning algorithm)

[สหัส พรหมสิทธิ์, 2538]

Werbos ได้เสนอแนวความคิดของการเรียนรู้แบบแพร่กลับในปี ค.ศ. 1974 จากนั้น Parker ได้นำเสนออีกครั้งในปี ค.ศ. 1982 และได้ทำให้เป็นที่รู้จักมากยิ่งขึ้น โดย Rumelhart และคณะในปี ค.ศ. 1986 ในหนังสือชื่อ Parallel distributed processing ซึ่งกล่าวถึงศักยภาพของโครงข่ายประสาทและการเรียนรู้แบบแพร่กลับ งานประยุกต์เริ่มแรกของการเรียนรู้แบบแพร่กลับเป็นโปรแกรม NETTALK ซึ่งสร้างโดย Sejnowski และ Rosenberg ในมหาวิทยาลัยจอห์นฮอปกิน


การเรียนรู้แบบแพร่กลับเป็นรูปแบบหนึ่งของโครงข่ายประสาทที่ใช้กันอย่างกว้างขวางและนำมาประยุกต์กับการศึกษาในงานประเภทต่าง ๆ เช่น ทางทหาร การช่วยในการวินิจฉัยของแพทย์ การรู้จำคำพูด การรู้จำตัวอักษร เป็นต้น

การเรียนรู้แบบแพร่กลับเป็นการเรียนรู้แบบมีครูสามารถแก้ปัญหาที่ต้องการรูปแบบ โดยการป้อนรูปแบบเข้าไปให้กับโครงข่ายประสาทซึ่งก็จะให้รูปแบบเอาต์พุตที่เกี่ยวข้องกันออกมา และยังเป็นวิธีการหนึ่งของโครงข่ายประสาทที่ง่ายต่อความเข้าใจ เนื่องจากกระบวนการเรียนรู้และปรับปรุงแก้ไขนั้นเป็นไปด้วยตนเอง ถ้าโครงข่ายประสาทให้คำตอบที่ผิด ค่าน้ำหนักก็จะถูกปรับจนกว่าค่าความผิดพลาดจะน้อยลง หรืออยู่ในเกณฑ์ที่ยอมรับได้ นั่นคือค่าที่ได้ในครั้งต่อไป จะมีความถูกต้องมากยิ่งขึ้น

การเรียนรู้แบบแพร่กลับมีโครงข่ายเป็นชั้น ๆ โดยแต่ละชั้นเชื่อมโยงกันอย่างทั่วถึงกับชั้นที่อยู่ด้านบนและชั้นที่อยู่ด้านล่าง เมื่อโครงข่ายได้รับข้อมูลอินพุท จะทำการคำนวณค่าน้ำหนักของหน่วยประมวลผลจากชั้นอินพุทไปยังชั้นซ่อนและจากชั้นซ่อนไปยังชั้นเอาต์พุท เมื่อเกิดผลต่างระหว่างเอาต์พุทจริงกับเอาต์พุทเป้าหมาย โครงข่ายจะนำค่าความผิดพลาดจากชั้นเอาต์พุทกลับไปยังชั้นซ่อน จากชั้นซ่อนไปยังชั้นข้อมูลอินพุท เพื่อปรับค่าน้ำหนักของแต่ละชั้น


### 1). โครงสร้างของการเรียนรู้แบบแพร่กลับ

การเรียนรู้แบบแพร่กลับมีโครงสร้างเป็นชั้น ๆ โดยมีโครงสร้างอย่างง่าย ๆ 3 ชั้น คือ ชั้นข้อมูลอินพุท ชั้นซ่อน และชั้นข้อมูลเอาต์พุท แต่ละชั้นจะติดต่อกันอย่างสมบูรณ์ ดังภาพประกอบที่ 3-7



ภาพประกอบ 3-7 รูปแบบของการเรียนรู้แบบแพร่กลับชนิด 3 ชั้น

ภาพประกอบที่ 3-7 แสดงรูปแบบของการเรียนรู้แบบแพร่กลับชนิด 3 ชั้น ชั้นล่างคือ ชั้นข้อมูลอินพุท ซึ่งนำข้อมูลจากภายนอก ชั้นถัดมาคือ ชั้นซ่อน ซึ่งจะติดต่อกับ ทั้งชั้นข้อมูลอินพุท และชั้นแสดงเอาต์พุทที่อยู่ด้านบน



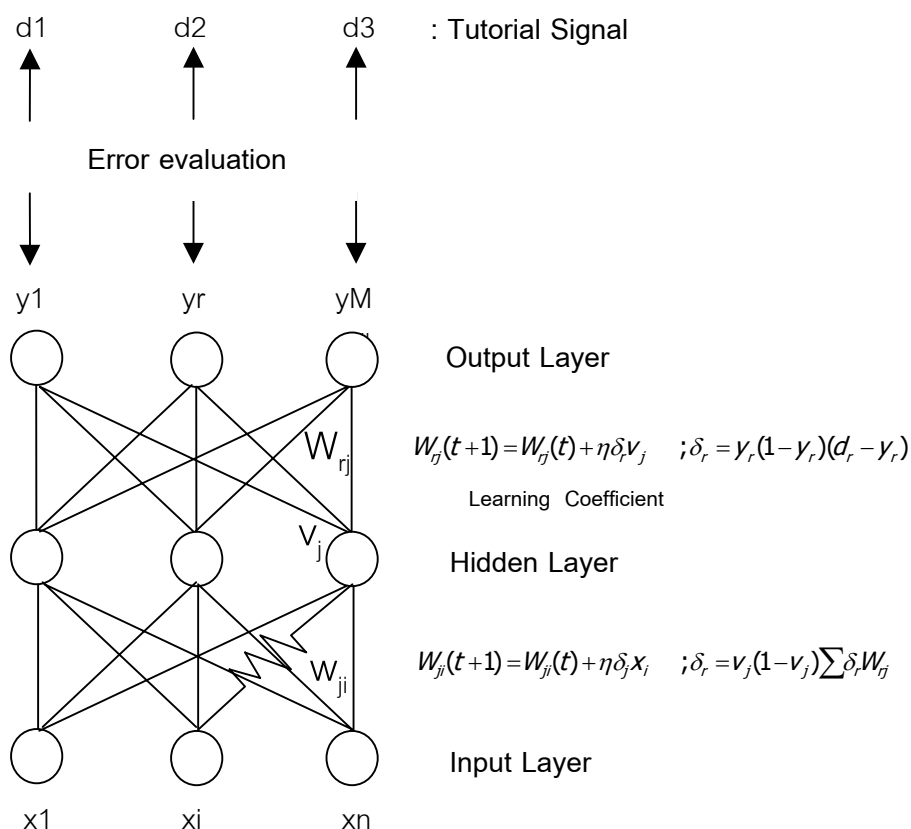
ภาพประกอบ 3-8 การแทนค่าน้ำหนักด้วยเมตริกซ์

ภาพประกอบที่ 3-8 แสดงการแทนค่าน้ำหนักด้วยเมตริกซ์ โดยมีค่ากำกับด้านบนบ่งบอกถึงชั้นที่ต่างกัน เช่น  $W^1_{21}$  หมายถึงค่าน้ำหนักจากอินพุตที่ 1 ของหน่วยประมวลผลที่ 2 ในระดับชั้นที่ 1

## 2.) การสอนการเรียนรู้แบบแพร่กลับ [วรเชษฐ์ อุบลสุวรรณิช, 2541]

การสอนโครงข่ายชนิดการเรียนรู้แบบแพร่กลับ เป็นการสอนแบบมีครู โดยมีการกำหนดรูปแบบข้อมูลอินพุตควบคู่กับรูปแบบเป้าหมาย มีการกำหนดชุดการสอนหลาย ๆ รูปแบบ เพื่อให้โครงข่ายประสาทสามารถเรียนรู้





ภาพประกอบที่ 3-9 โครงสร้างแบบจำลองที่มีการเรียนรู้แบบแพร่กลับ

จากภาพประกอบที่ 3-9 เป็นการคำนวณหาค่าน้ำหนักในแต่ละชั้นโดยวิธีการแพร่กลับ โดยที่

$d_r$  = ค่าเอาต์พุตที่ใช้ในการฝึกสอน

$y_i$  = ค่าเอาต์พุตที่ได้จากการประมวลผลของโครงข่ายประสาทในชั้นเอาต์พุต

$v_j$  = ข้อมูลอินพุตลำดับที่  $j$  ในชั้นซ่อน

$w_{rj}$  = ค่าน้ำหนักของเซลล์ประสาทลำดับที่  $r$  กับ  $j$  ในระหว่างชั้นซ่อนกับชั้นเอาต์พุต

$w_{ji}$  = ค่าน้ำหนักของเซลล์ประสาทลำดับที่  $j$  กับ  $i$  ในระหว่างชั้นอินพุตกับชั้นซ่อน

$x_i$  = ข้อมูลอินพุตลำดับที่  $i$  ในชั้นอินพุต

ในการคำนวณหาค่าน้ำหนักจะเริ่มคำนวณจากชั้นเอาต์พุตผ่านไปยังชั้นซ่อนและผ่านไปยังชั้นอินพุต ตามลำดับ ซึ่งสามารถคำนวณจากสมการ

$$w_{rj}(t+1) = w_{rj}(t) + \eta \delta_r v_j \quad (3-6)$$

เมื่อ  $w_{rj}$  เป็นน้ำหนักระหว่างชั้นเอาต์พุตกับชั้นซ่อน

$\eta$  เป็นค่าสัมประสิทธิ์ของการเรียนรู้ (learning coefficient)

$\delta_r$  เป็นฟังก์ชันความผิดพลาด (error function) ลำดับที่  $r$

$v_j$  เป็นเอาต์พุตลำดับที่  $j$  ในชั้นซ่อน

จากสมการ 3-6 สามารถคำนวณหาน้ำหนัก  $w_{rj}$  ตัวใหม่ได้จาก  $w_{rj}$  ตัวเดิมรวมกับผลคูณของค่าสัมประสิทธิ์ของการเรียนรู้ ( $\eta$ ) ฟังก์ชันความผิดพลาดที่  $r$  ( $\delta_r$ ) และเอาต์พุตลำดับที่  $j$  ของชั้นซ่อน ซึ่งค่าของ  $\delta_r$  หาได้จากเอาต์พุตลำดับที่  $r$  ของชั้นเอาต์พุตกับเอาต์พุตในการเรียนรู้มาหาความสัมพันธ์ดังนี้

$$\delta_r = y_r(1 - y_r)(d_r - y_r) \quad (3-7)$$

ชั้นอินพุต คำนวณน้ำหนักในชั้นนี้จะคำนวณจากสมการที่ 3-8

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_j x_i \quad (3-8)$$

เมื่อ  $w_{ji}$  เป็นน้ำหนักระหว่างชั้นอินพุตกับชั้นซ่อน

$\eta$  เป็นค่าสัมประสิทธิ์ของการเรียนรู้

$\delta_j$  เป็นฟังก์ชันความผิดพลาดลำดับที่  $j$

$x_i$  เป็นอินพุตลำดับที่  $i$

การคำนวณจะแทนที่น้ำหนัก  $w_{ji}$  ใหม่ด้วยน้ำหนัก  $w_{ji}$  ตัวเดิมรวมผลคูณของค่าคงที่ของการเรียนรู้ ( $\eta$ ), ค่าความผิดพลาดลำดับที่  $j$  ( $\delta_j$ ) และอินพุตลำดับที่  $i$  ของชั้นอินพุต ซึ่งค่าของ  $\delta_j$  ได้จากการนำเอาต์พุตลำดับที่  $j$  ของชั้นซ่อน กับน้ำหนัก  $w_{rj}$  มาหาความสัมพันธ์ดังนี้

$$\delta_j = v_j(1 - v_j) \sum \delta_r w_{rj} \quad (3-9)$$

จะเห็นว่าการคำนวณในแต่ละชั้น ค่าความผิดพลาดจะถูกส่งจากชั้นเอาต์พุตไปยังชั้นซ่อนและไปยังชั้นอินพุต ตามลำดับ น้ำหนักที่เชื่อมต่อของแต่ละเซลล์จะถูกปรับค่าไปตามความ

มากขึ้นของค่าความผิดพลาดที่ได้รับ กระบวนการการส่งค่าความผิดพลาดจะทำซ้ำ ๆ เพื่อให้โครงข่ายปรับค่าน้ำหนักที่จะทำให้ค่าความผิดพลาดต่ำกว่าค่าความผิดพลาดที่ได้ตั้งไว้ จึงจะหยุดกระบวนการการปรับค่าน้ำหนัก กระบวนการดังกล่าวเรียกอีกอย่างว่า กระบวนการการเรียนรู้ และเนื่องจากการคำนวณปรับค่าน้ำหนักจะเริ่มจากชั้นเอาต์พุตผ่านมายังชั้นซ่อนและชั้นอินพุต ตามลำดับ กระบวนการการปรับค่าน้ำหนักหรือการเรียนรู้ในลักษณะนี้ถูกเรียกว่า วิธีการแพร่กลับ หลังจากผ่านขั้นตอนการเรียนรู้เพื่อให้เซลล์แต่ละชั้นทำการปรับค่าน้ำหนักของเซลล์แต่ละชั้นจนได้ค่าที่เหมาะสมในการเรียนรู้และจดจำลักษณะที่แตกต่างของอินพุตแล้ว จึงจะนำโครงข่ายที่ได้ไปทำการจำแนกข้อมูลอินพุตอื่น ๆ ตามความต้องการ ในปัจจุบันวิธีการแพร่กลับก็แบ่งย่อยอีกได้หลายวิธี เช่นการแพร่กลับแบบที่มีการเปลี่ยนแปลงอัตราการเรียนรู้ วิธี Conjugate Gradient และ วิธี Levenberg-Marquardt เพื่อทำการเปรียบเทียบผลการจำแนกข้อมูลที่ได้จากโครงข่ายที่ได้โดยมีการเรียนรู้ในวิธีการที่แตกต่างกันซึ่งสมการ 3-10 และสมการ 3-11 เป็นสมการการปรับค่าน้ำหนักและค่าไบอัสของการเรียนรู้แบบที่มีค่าโมเมนตัม ตามลำดับ

$$\Delta W^m(k) = \gamma \Delta W^m(k-1) - (1-\gamma)\alpha S^m(a^{m-1})^T \quad (3-10)$$

$$\Delta b^m(k) = \gamma \Delta b^m(k-1) - (1-\gamma)\alpha S^m \quad (3-11)$$

ในสมการที่ 3-10 และ 3-11 เป็นสมการการคำนวณหาค่าการเปลี่ยนแปลงของค่าน้ำหนักและค่าไบอัสของโครงข่ายที่มีการเรียนรู้แบบแพร่กลับแบบมีค่าโมเมนตัม ซึ่งจะมีสมการเช่นเดียวกับสมการของโครงข่ายที่มีการเรียนรู้แบบมีการเปลี่ยนแปลงอัตราการเรียนรู้แต่จะมีข้อแตกต่างกันตรงเงื่อนไขของการเปลี่ยนค่าโมเมนตัมและค่าอัตราการเรียนรู้ซึ่งการคำนวณจะเริ่มจากการกำหนดค่าโมเมนตัม( $\gamma$ ) , ค่าอัตราการเรียนรู้ ( $\alpha$ ) ,ค่าน้ำหนักเริ่มต้น ( $w$ ) และ ค่าไบอัส ( $b$ ) เริ่มต้นจากนั้นก็จะเป็นอินพุตให้กับโครงข่ายเพื่อหาค่าเอาต์พุตไปทำการหาค่าความผิดพลาดเทียบกับค่าเป้าหมายทำให้ได้ค่าความผิดพลาดกำลังสอง นำ  $\Delta w$  และ  $\Delta b$  ที่คำนวณได้ไปรวมกับค่าน้ำหนักเริ่มต้นและไบอัสเริ่มต้น ต่อจากนั้นก็จะเป็นอินพุตให้กับโครงข่ายประสาทเทียมอีกครั้ง ซึ่งอินพุตที่ป้อนจะถูกนำไปคำนวณกับค่าน้ำหนักและค่าไบอัสที่เปลี่ยนไป จะทำให้ได้ค่าเอาต์พุตออกมาอีกค่าหนึ่งแล้วนำค่าเอาต์พุตที่ได้ไปทำการหาค่าความผิดพลาดกำลังสอง ซึ่งหากว่าค่าความผิดพลาดกำลังสองตัวใหม่มีค่าเพิ่มขึ้นมากกว่าค่าที่ตั้งไว้ (โดยทั่วไปจะมีอยู่ในช่วง 1-5 %) ค่าน้ำหนักตัวใหม่จะไม่ถูกนำมาใช้ ค่าอัตราการเรียนรู้จะถูกคูณด้วยค่าคงที่  $\rho$  ที่มีค่ามากกว่าศูนย์แต่น้อยกว่าหนึ่ง

ส่วนค่าโมเมนต์จะถูกปรับให้เป็นศูนย์ หากว่าค่าความผิดพลาดกำลังสองมีค่าลดลงจะนำค่าน้ำหนักตัวใหม่ที่เปลี่ยนไปนั้นนำไปใช้งานในรอบต่อไป ค่าอัตราการเรียนรู้จะถูกคูณด้วยค่าคงที่  $\eta$  ที่มีค่ามากกว่าหนึ่ง ส่วนค่าโมเมนต์หากก่อนหน้าถูกปรับให้เป็นศูนย์ก็จะปรับให้มีค่ากลับไปสู่ค่าเริ่มต้นที่ได้ตั้งค่าเอาไว้ แต่หากว่า ค่าความผิดพลาดกำลังสองมีค่าเพิ่มขึ้นไม่มากไปกว่าค่าที่ได้ตั้งไว้ ค่าน้ำหนักใหม่จะถูกนำไปใช้ในการคำนวณรอบต่อไป ส่วนค่าอัตราการเรียนรู้และค่าโมเมนต์จะไม่เปลี่ยนแปลง ซึ่งขั้นตอนที่ได้กล่าวมาจะกระทำซ้ำไปจนกว่าค่าความผิดพลาดจะมีค่าน้อยกว่าค่าความผิดพลาดที่ได้กำหนดไว้

ในกระบวนการสอนเพื่อให้โครงข่ายประสาทสามารถเรียนรู้ได้ดึนั้น จะต้องใช้การวนซ้ำสอนหลายๆ รอบ การสอนโครงข่ายประสาทจะสำเร็จหรือไม่ดูจากค่า RMS ดังสมการที่

3-12

$$RMS = \sqrt{\sum_p \sum_j (t_{jp} - a_{jp})^2 / n_p n_o} \quad (3-12)$$


โดย  $n_p$  = จำนวนของรูปแบบในชุดการสอน  
 $n_o$  = จำนวนหน่วยในชั้นเอาต์พุต  
 $t_{jp}$  = ค่าเป้าหมายของเซลล์ประสาทลำดับที่  $j$  หลังจากเสนอรูปแบบ  $p$   
 $a_{jp}$  = ค่าเอาต์พุตที่ได้จากเซลล์ประสาทลำดับที่  $j$  หลังจากเสนอรูปแบบ  $p$

ซึ่งสมการนี้ใช้ในการพิจารณาหาจุดเหมาะสมสำหรับรูปแบบหรือสมการการพยากรณ์ ด้วยการประมาณค่าพารามิเตอร์ของสมการที่ทำให้ค่า RMS มีค่าน้อยที่สุดด้วยเช่นกัน (สุพล ดุรงค์วัฒนา, 2537)

เมื่อค่า RMS เข้าใกล้ศูนย์ หรือลดลงต่ำกว่า 0.1 หมายความว่าโครงข่ายได้เกิดการเรียนรู้แล้ว

ถ้าโครงข่ายตกอยู่ภายใต้จุดต่ำสุดท้องถิ่น (local minimum) นั่นคือโครงข่ายได้หยุดการเรียนรู้แล้ว หรือไม่สามารรถลึกลับชุดการทดสอบได้เลย แต่อาจจะให้ค่าเอาต์พุตที่มีค่าไม่ถูกต้องเมื่อทำการทดสอบ

ถ้าโครงข่ายตกอยู่ต่ำสุดโดยรวม (global minimum) นั่นคือ ค่า RMS ของโครงข่ายได้ถึงจุดต่ำสุดแล้ว และสามารถลึกลับได้ทั้งชุดการสอนและชุดการทดสอบได้ในระดับที่พอใจ



ภาพประกอบ 3-10 จุดต่ำสุดท้องถิ่นและจุดต่ำสุดโดยรวม

### 3.) ข้อดีและข้อจำกัดของการเรียนรู้แบบแพร่กลับ (Dayhoff, 1990)

ข้อดี คือ มีความสามารถในการจดจำรูปแบบของปัญหา (pattern mapping) ซึ่งการเรียนรู้แบบแพร่กลับสามารถที่จะเรียนรู้ความสัมพันธ์ของรูปแบบได้มากมาย โดยการเรียนรู้แบบแพร่กลับต้องการตัวอย่างรูปแบบที่จะเรียนรู้ ไม่ต้องการความรู้ทางด้านคณิตศาสตร์เพื่อแมพ (map) รูปแบบของข้อมูลอินพุตและเอาต์พุต ความยืดหยุ่นของการเรียนรู้อยู่ที่ความหลากหลายในการออกแบบทางเลือกต่าง ๆ เช่น จำนวนชั้น เส้นเชื่อมโยง จำนวนของเซลล์ประสาท ความสัมพันธ์การเรียนรู้ ค่าโมเมนตัม ที่เรากำหนดขึ้นและการแทนรูปแบบของข้อมูล ความยืดหยุ่นนี้ ทำให้การเรียนรู้แบบแพร่กลับสามารถแก้ปัญหาทางงานประยุกต์ได้อย่างมากมาย

ข้อจำกัด คือ การใช้เวลามากในการสอนเซลล์ประสาทให้เกิดการเรียนรู้ (convergence time) สำหรับการเรียนรู้การแก้ปัญหา สำหรับระบบงานจริงอาจมีชุดตัวอย่างถึง 1,000 ตัวอย่างและต้องใช้เวลาในการคำนวณเป็นวันหรือมากกว่านั้นเพื่อให้การสอนสมบูรณ์

จุดอ่อนอีกข้อหนึ่งของการเรียนรู้แบบแพร่กลับ คือ ความล้มเหลวในการสอน นั่นคือ โครงข่ายตกอยู่ที่จุดต่ำสุดท้องถิ่น โดยที่การเพิ่มชุดการสอนไม่สามารถปรับโครงข่ายได้ ซึ่งหมายถึงโครงข่ายหยุดการเรียนรู้แล้ว แต่ข้อจำกัดนี้สามารถแก้ไขได้โดย ปรับค่า  $\eta$  และ  $\alpha$  เพิ่มจำนวนเซลล์ประสาทในชั้นซ่อนหรือเพิ่มจำนวนชั้นซ่อน เปลี่ยนฟังก์ชันการแปลงค่า เปลี่ยนชุดการสอน หรือเปลี่ยนโครงสร้างของโครงข่าย

### 3.2 หลักการพื้นฐานของการพยากรณ์ความต้องการกำลังไฟฟ้าโดยใช้โครงข่ายประสาท

#### 3.2.1 การกำหนดข้อมูลที่ใช้ในการสอนโครงข่าย

##### 3.2.1.1 ข้อมูลภูมิอากาศ

เนื่องจากการพยากรณ์ความต้องการไฟฟ้าสูงสุด/ต่ำสุดในแต่ละวัน มีความเกี่ยวข้องอย่างมากกับอุณหภูมิสูงสุดและต่ำสุด โดยเฉพาะสำหรับประเทศไทยซึ่งโหลดส่วนใหญ่เป็นเครื่องทำความเย็น และเนื่องจากประเทศไทยมีภูมิอากาศที่แตกต่างกัน 6 เขต (เขตของอูดุณิยมวิทยา) ดังนี้

- 1 เขตภาคเหนือ
- 2 เขตภาคตะวันออกเฉียงเหนือ
- 3 เขตภาคกลาง
- 4 เขตภาคตะวันออก
- 5 เขตภาคใต้ฝั่งตะวันออก
- 6 เขตภาคใต้ฝั่งตะวันตก

ในวิทยานิพนธ์นี้ได้เลือกข้อมูลตัวอย่างจากจังหวัดเชียงใหม่ จังหวัดนครราชสีมา จังหวัดกรุงเทพฯ จังหวัดระยอง จังหวัดสงขลาและจังหวัดภูเก็ต เป็นตัวแทนของทั้ง 6 เขตตามลำดับ โดยจะนำข้อมูลทั้งอุณหภูมิสูงสุดและอุณหภูมิต่ำสุดมาใช้

เนื่องจากอุณหภูมิสูงสุดและต่ำสุดนั้น มีค่าใหญ่มากสำหรับเป็นค่าตัวแปรอินพุทของโครงข่ายประสาท จึงจำเป็นที่จะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์เสียก่อนที่จะนำไปใช้คำนวณ ซึ่งในวิทยานิพนธ์นี้จะทำการหารค่าอุณหภูมิสูงสุดและต่ำสุด ด้วย 50

##### 3.2.1.2 ข้อมูลความต้องการกำลังไฟฟ้า

นอกจากค่าอุณหภูมิสูงสุด (ต่ำสุด) ที่มีผลต่อความต้องการไฟฟ้าสูงสุด (ต่ำสุด) แล้ว ค่าของความต้องการกำลังไฟฟ่ารายชั่วโมงและค่าพลังงานไฟฟ้า ของวันชนิดเดียวกันในอดีตก็มีผลต่อการพยากรณ์เช่นกัน สำหรับข้อมูลความต้องการกำลังไฟฟ้าซึ่งข้อมูลที่ได้ทำวิจัยนั้น เป็นค่าความต้องการไฟฟ่ารายชั่วโมงในอดีตของทั้งประเทศ ซึ่งจะต้องนำข้อมูลเหล่านี้มาแยกชนิดของกลุ่มวัน โดยได้ทำการศึกษารูปแบบของโหลดสามารถแยกชนิดของวันที่จะพยากรณ์ได้ ดังนี้

ตาราง 3-4 รูปแบบของโหลดแยกตามชนิดของกลุ่มวัน

Code Number	Day Type	Describe
1	Weekly	วันอังคาร-วันศุกร์
2	Monday	วันจันทร์
3	Sunday	วันอาทิตย์
4	Holiday-A	วันเสาร์-วันหยุดราชการ*-วันหยุดทางศาสนา
5	Holiday-B	วันพิเศษ (วันหยุดเทศกาลนาน ๆ)**


#### หมายเหตุ

\* เป็นวันหยุดราชการที่หยุดเพียง 1 วัน

\*\* เป็นวันหยุดเทศกาลนาน ๆ ที่มากกว่า 2 วันขึ้นไป

#### ก. วันทำงาน (Weekday)


วันทำงานเป็นวันที่มีความต้องการกำลังไฟฟ้าสูงสุดในบรรดาวันชนิดต่าง ๆ ตั้งแต่ช่วงเวลา 8.00 น. จนถึง 20.00 น. ดังภาพประกอบที่ 3-11



ภาพประกอบ 3-11 กราฟแสดงค่าความต้องการไฟฟ้ารายชั่วโมง ในวันทำงาน

#### ข. วันจันทร์ (Monday)


วันจันทร์เป็นวันที่มีรูปแบบโหลดคล้ายคลึงกับวันทำงานแต่จะต่างกันในช่วงเวลา 1.00 จนถึง 6.00 น. ดังภาพประกอบที่ 3-12 ซึ่งจะมีความต้องการกำลังไฟฟ้าน้อยกว่าวันทำงาน อันเป็นผลสืบเนื่องมาจากอยู่ถัดจากวันอาทิตย์ ซึ่งมีกิจกรรมการใช้ไฟฟ้าค่อนข้างน้อย



ภาพประกอบ 3-12 กราฟแสดงค่าความต้องการไฟฟ้ารายชั่วโมง ในวันจันทร์

#### ค. วันอาทิตย์ (Sunday)


วันอาทิตย์เป็นวันที่มีความต้องการกำลังไฟฟ้าน้อยกว่าวันทำงานและวันจันทร์มาก โดยเฉพาะตั้งแต่เวลา 9.00 น. จนถึง 17.00 น. ดังภาพประกอบที่ 3-13



ภาพประกอบ 3-13 กราฟแสดงค่าความต้องการไฟฟ้ารายชั่วโมง ในวันอาทิตย์

#### ง. วันเสาร์ (Holiday-A)

วันเสาร์ ซึ่งจะรวมไปถึงวันหยุดราชการหรือวันสำคัญทางศาสนา ซึ่งเป็นวันที่มีความต้องการกำลังไฟฟ้าน้อยกว่าวันทำงาน ตั้งแต่เวลาประมาณ 8.00 จนถึง 22.00 ดังภาพประกอบที่ 3-14




ภาพประกอบ 3-14 กราฟแสดงค่าความต้องการไฟฟ้ารายชั่วโมงในวันเสาร์- วันหยุดราชการ



### จ. วันพิเศษ (Holiday-B)

วันพิเศษ ได้แก่วันหยุดเทศกาลต่าง ๆ ที่หยุดกันยาวนาน เช่นเทศกาลวันสงกรานต์ เป็นต้น ซึ่งเป็นวันที่ความต้องการกำลังไฟฟ้าน้อยที่สุดในบรรดาวันชนิดต่าง ๆ ดังภาพประกอบที่ 3-15



ภาพประกอบ 3-15 กราฟแสดงค่าความต้องการไฟฟ้ารายชั่วโมง ในวันพิเศษ

เนื่องจากค่าความต้องการกำลังไฟฟ้าสูงสุด (ต่ำสุด) นั้นมีค่าที่ใหญ่มาก สำหรับเป็นค่าตัวแปรอินพุตและตัวแปรเอาต์พุตของโครงข่ายประสาธ เช่นเดียวกับค่าอุณหภูมิสูงสุดและต่ำสุด ซึ่งในวิทยานิพนธ์นี้จะหาค่าความต้องการกำลังไฟฟ้าสูงสุด (ต่ำสุด) ด้วย 15000

### 3.2.2 รูปแบบโครงสร้างที่ใช้ในการสอนโครงข่าย

ได้จัดการทดลองไว้ 3 ส่วนใหญ่ ๆ ตามลำดับการทดสอบ ซึ่งประกอบไปด้วย 5 โมเดลโครงข่ายของการเรียนรู้ ทั้งในส่วนของ input และ output unit ดังนี้

3.2.2.1 ทำการเรียนรู้ข้อมูลค่ากำลังไฟฟ้าในส่วนของ input unit ในระยะเวลา 14 วัน (2 สัปดาห์) ติดต่อกัน ได้แก่ โมเดลที่ 1 และ 2 (MODEL 1 and MODEL 2) ซึ่งมีรายละเอียดดังต่อไปนี้

### รูปแบบข้อมูลต่างๆ ที่ใช้ในการเรียนรู้ของโครงข่ายประสาทโมเดลที่ 1

Input Unit จะประกอบไปด้วย

- วันที่ <sup>1</sup> (Date) เดือน <sup>2</sup> (Month) ชนิดของวัน <sup>3</sup> (Day) และอุณหภูมิสูงสุด/ต่ำสุด <sup>4</sup> จริง (T1-T12) ของวันที่ทำการพยากรณ์*	15	อินพุต
- วันที่ (Date <sub>01</sub> ) เดือน (Month <sub>01</sub> ) ชนิดของวัน (Day <sub>01</sub> ) อุณหภูมิสูงสุด/ต่ำสุดจริง (T1 <sub>01</sub> -T12 <sub>01</sub> ) และค่ากำลังไฟฟ้ารายชั่วโมงจริง <sup>5</sup> (L1 <sub>01</sub> - L24 <sub>01</sub> ) ของวันก่อนวันที่ทำการพยากรณ์ 1 วัน	39	อินพุต
- ชนิดของวัน (Day <sub>02</sub> ) อุณหภูมิสูงสุด/ต่ำสุดจริง (T1 <sub>02</sub> -T12 <sub>02</sub> ) และค่ากำลังไฟฟ้ารายชั่วโมงจริงของวันในอดีต (L1 <sub>02</sub> - L24 <sub>02</sub> ) ที่เป็นวันชนิดเดียวกันกับวันพยากรณ์**ล่าสุด	37	อินพุต
<b>รวม จำนวนอินพุต ทั้งหมดในชั้นอินพุต</b>	<b><u>91</u></b>	<b>อินพุต</b>

\* เป็นวันที่ทำการพยากรณ์ค่ากำลังไฟฟ้ารายชั่วโมงของวันพยากรณ์\*\*

\*\* เป็นวันที่ต้องการทราบค่ากำลังไฟฟ้ารายชั่วโมง

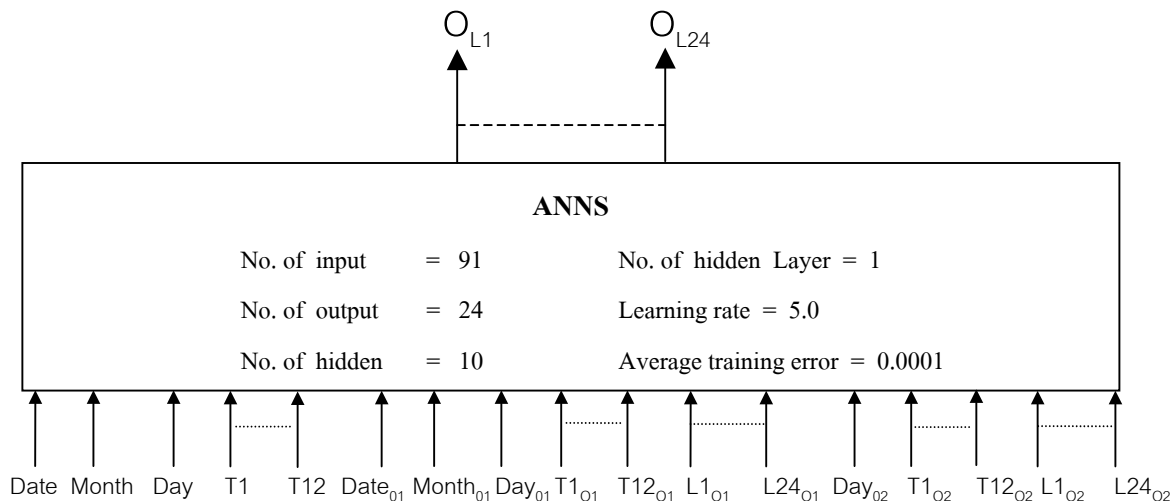
<sup>1</sup> เป็นค่าตัวเลขวันที่ในเดือนนั้นๆ ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 31

<sup>2</sup> เป็นค่าตัวเลขของเดือนนั้น ๆ โดยใช้ตัวเลขแทนสัญลักษณ์ เช่น เดือนมกราคม แทนด้วย 1, เดือนกุมภาพันธ์ แทนด้วย 2 ..... เดือนธันวาคม แทนด้วย 12 ตามลำดับ ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 12

<sup>3</sup> เป็นค่าตัวเลขแทนรูปแบบของโพลเดียมตามชนิดของกลุ่มวัน ดังตาราง 3-4 ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 5

<sup>4</sup> เป็นค่าอุณหภูมิสูงสุด/ต่ำสุดทั้ง 6 จังหวัด ได้แก่จังหวัดเชียงใหม่ นครราชสีมา กรุงเทพฯ ระยอง สงขลาและภูเก็ต เป็นตัวแทนของทั้ง 6 เขตตามลำดับ จังหวัดละ 2 อินพุต จึงรวมแล้วได้ค่า 12 อินพุต ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์เสียก่อนก่อนที่จะนำไปใช้คำนวณ โดยทำการหารค่าอุณหภูมิสูงสุด/ต่ำสุด ด้วย 50

<sup>5</sup> เป็นค่ากำลังไฟฟ้ารายชั่วโมงทั้ง 24 ชั่วโมงในวันนั้น ๆ เริ่มตั้งแต่เวลา 01.00 น. จนถึง 24.00 น. รวมเป็น 24 อินพุต ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 15000

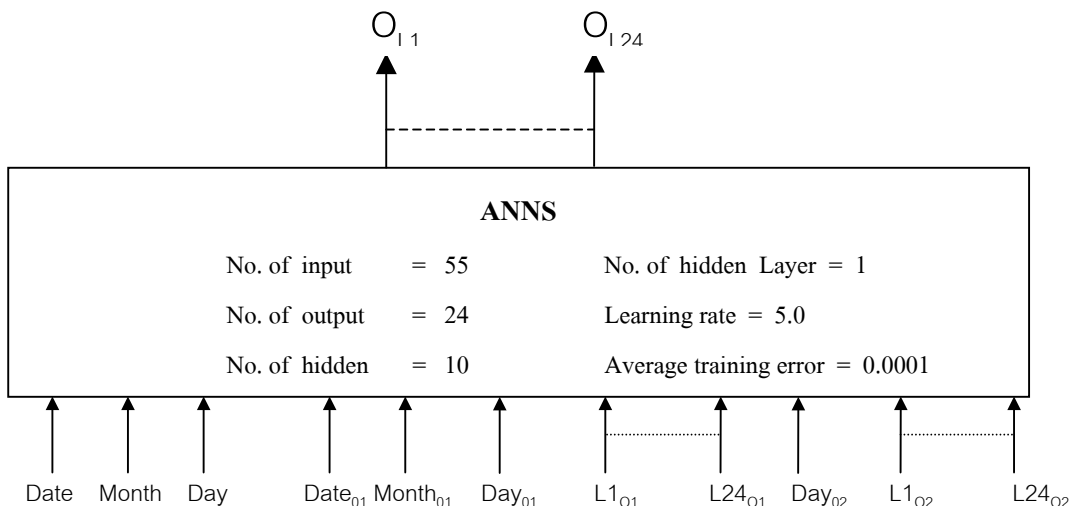


ภาพประกอบที่ 3-16 แสดงไดอะแกรมของการเรียนรู้โครงข่ายประสาทโมเดลที่ 1

รูปแบบข้อมูลต่างๆ ที่ใช้ในการเรียนรู้ของโครงข่ายประสาทโมเดลที่ 2

Input Unit จะประกอบไปด้วย

- วันที่ (Date) เดือน (Month) และชนิดของวัน (Day) ของวันที่ทำการพยากรณ์ 3    อินพุต
  - วันที่ (Date<sub>01</sub>) เดือน (Month<sub>01</sub>) ชนิดของวัน (Day<sub>01</sub>) และค่ากำลังไฟฟ้ารายชั่วโมงจริง (L1<sub>01</sub> - L24<sub>01</sub>) ของวันก่อนวันที่ทำการพยากรณ์ 1 วัน 27    อินพุต
  - ชนิดของวัน (Day<sub>02</sub>) และค่ากำลังไฟฟ้ารายชั่วโมงจริงของวันในอดีต (L1<sub>02</sub> - L24<sub>02</sub>) ที่เป็นวันชนิดเดียวกันกับวันพยากรณ์ล่าสุด 25    อินพุต
- รวม จำนวนอินพุต ทั้งหมดในชั้นอินพุต                    55    อินพุต**



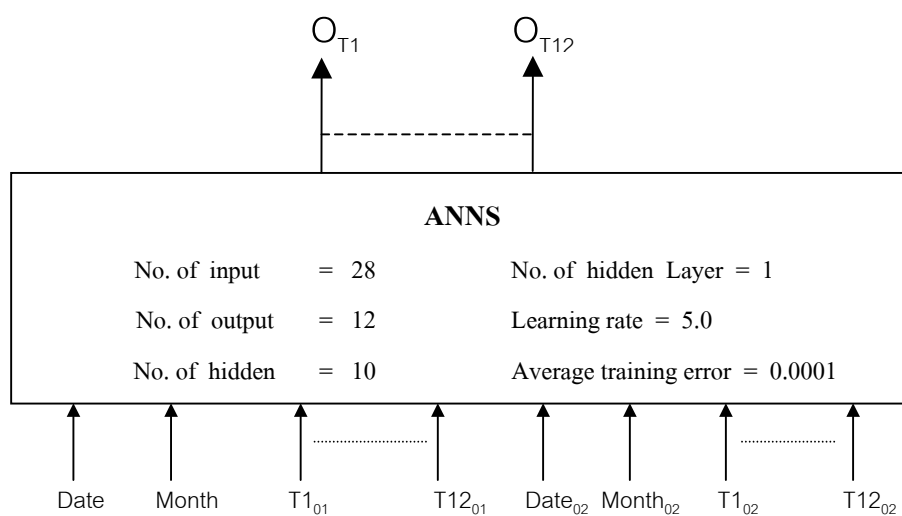
ภาพประกอบที่ 3-17 แสดงไดอะแกรมของการเรียนรู้โครงข่ายประสาทโมเดลที่ 2

3.2.2.2 ทำการเรียนรู้ข้อมูลค่าอุณหภูมิในส่วนของ input unit ดังโมเดลที่ 3 (MODEL 3)

รูปแบบข้อมูลต่างๆ ที่ใช้ในการเรียนรู้ของโครงข่ายประสาทโมเดลที่ 3

Input Unit จะประกอบไปด้วย

- |  |                  |               |
|--|------------------|---------------|
| - วันที่ (Date) เดือน (Month)<br>และอุณหภูมิสูงสุด/ต่ำสุดจริง ( $T_{1_{01}}$ - $T_{12_{01}}$ )<br>ของวันก่อนวันที่ทำการพยากรณ์ 1 วัน                   | 14               | อินพุต        |
| - วันที่ ( $Date_{02}$ ) เดือน ( $Month_{02}$ )<br>และอุณหภูมิสูงสุด/ต่ำสุดจริง ( $T_{1_{02}}$ - $T_{12_{02}}$ )<br>ของวันก่อนวันที่ทำการพยากรณ์ 2 วัน | 14               | อินพุต        |
| <b>รวม จำนวนอินพุต ทั้งหมดในชั้นอินพุต</b>   | <b><u>28</u></b> | <b>อินพุต</b> |



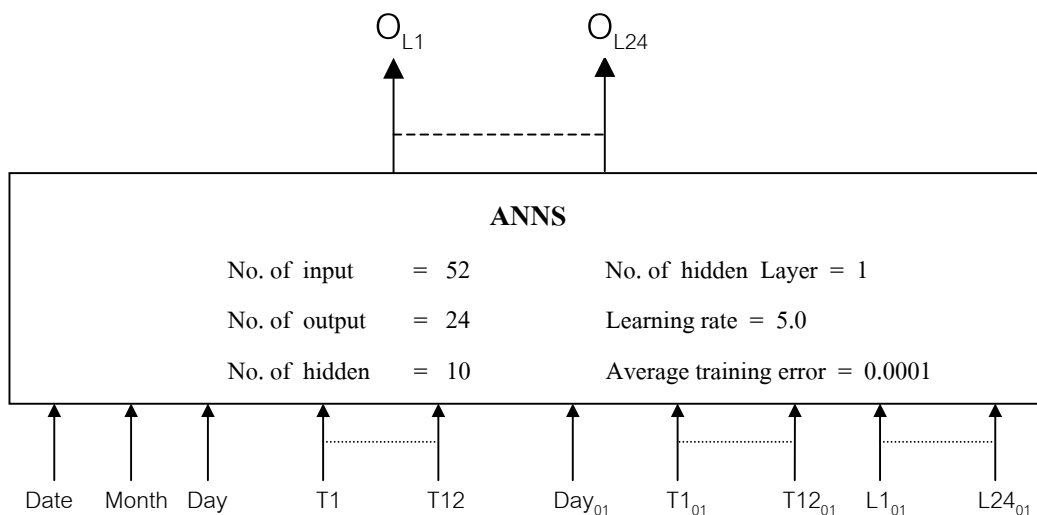
ภาพประกอบที่ 3-18 แสดงไดอะแกรมของการเรียนรู้โครงข่ายประสาทโมเดลที่ 3

3.2.2.3 ทำการเรียนรู้ข้อมูลค่ากำลังไฟฟ้าในส่วนของ input unit โดยแบ่งประเภทของกลุ่มวัน ได้แก่ โมเดลที่ 4 และ 5 (MODEL 4 and MODEL 5) ซึ่งมีรายละเอียดดังต่อไปนี้

รูปแบบข้อมูลต่างๆ ที่ใช้ในการเรียนรู้ของโครงข่ายประสาทโมเดลที่ 4

Input Unit จะประกอบไปด้วย

- วันที่ (Date) เดือน (Month) ชนิดของวัน (Day) 15 อินพุต และอุณหภูมิสูงสุด/ต่ำสุดจริง (T1-T12) ของวันที่ทำการพยากรณ์
  - ชนิดของวัน (Day<sub>01</sub>) อุณหภูมิสูงสุด/ต่ำสุดจริง (T1<sub>01</sub>-T12<sub>01</sub>) 37 อินพุต และค่ากำลังไฟฟ้ารายชั่วโมงจริง (L1<sub>01</sub>-L24<sub>01</sub>) ของวันก่อนวันที่ทำการพยากรณ์ 1 วัน ที่เป็นกลุ่มวันชนิดเดียวกันกับวันพยากรณ์ที่ติดต่อกัน
- รวม จำนวนอินพุต ทั้งหมดในชั้นอินพุต 52 อินพุต**

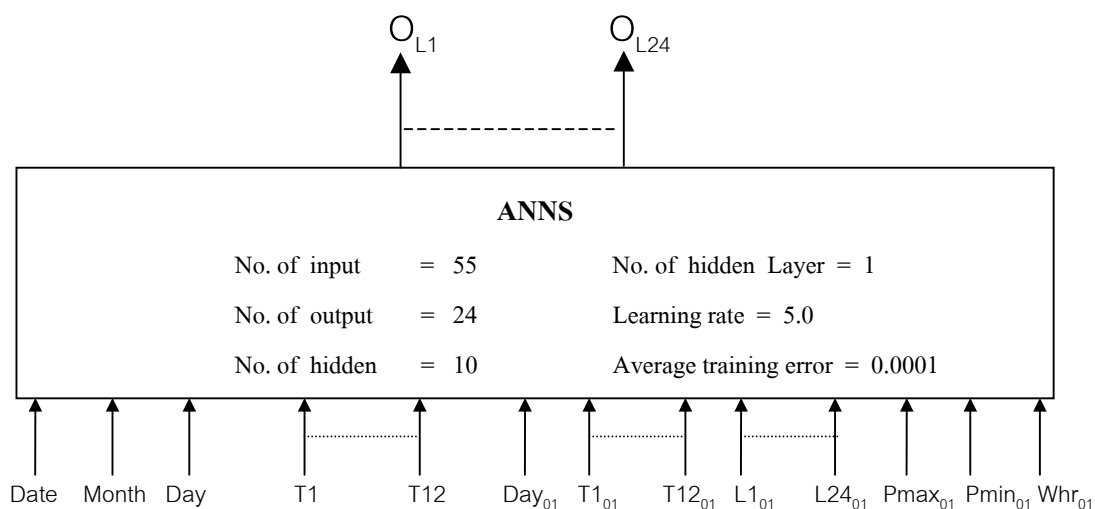


ภาพประกอบที่ 3-19 แสดงไดอะแกรมของการเรียนรู้โครงข่ายประสาทโมเดลที่ 4

### รูปแบบข้อมูลต่างๆ ที่ใช้ในการเรียนรู้ของโครงข่ายประสาทโมเดลที่ 5

Input Unit จะประกอบไปด้วย

- วันที่ (Date) เดือน (Month) ชนิดของวัน (Day) 15 อินพุต  
และอุณหภูมิสูงสุด/ต่ำสุดจริง (T1-T12)  
ของวันที่ทำการพยากรณ์
  - ชนิดของวัน (Day<sub>01</sub>) อุณหภูมิสูงสุด/ต่ำสุดจริง (T1<sub>01</sub>-T12<sub>01</sub>) 40 อินพุต  
ค่ากำลังไฟฟ้ารายชั่วโมงจริง (L1<sub>01</sub>- L24<sub>01</sub>)  
ค่ากำลังไฟฟ้าสูงสุด/ต่ำสุดจริง<sup>6</sup> (Pmax<sub>01</sub>) / (Pmin<sub>01</sub>)  
และพลังงานไฟฟ้าจริง<sup>7</sup> (Whr<sub>01</sub>) ของวันก่อนวันที่ทำการพยากรณ์ 1 วัน  
ที่เป็นกลุ่มวันชนิดเดียวกันกับวันพยากรณ์ที่ติดต่อกัน
- รวม จำนวนอินพุต ทั้งหมดในชั้นอินพุต **55** อินพุต



ภาพประกอบที่ 3-20 แสดงไดอะแกรมของการเรียนรู้โครงข่ายประสาทโมเดลที่ 5

<sup>6</sup> เป็นค่ากำลังไฟฟ้าสูงสุดและต่ำสุดของวันนั้น ๆ รวมเป็น 2 อินพุตซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 15000

<sup>7</sup> เป็นค่าพลังงานไฟฟ้าในวันนั้น ๆ ซึ่งจะต้องทำให้เป็นค่ามาตรฐานด้วยการนอร์มอลไลซ์ โดยทำการหารด้วย 360000

hidden unit ในที่นี้ จะใช้เพียง 1 ชั้นเท่านั้น

แต่อาจจะมีการปรับเปลี่ยนจำนวนเซลล์ในชั้นซ่อน โดยจะทำการปรับเปลี่ยนที่ 5 10 15 และ 20 เซลล์ ซึ่งจะใช้ทดสอบทุก ๆ โมเดล เพื่อหาค่าการพยากรณ์ที่ให้ผลดีที่สุด

output unit

- ค่าความต้องการไฟฟ้ารายชั่วโมง (โมเดลที่ 1 2 4 และ 5) 24 เอาท์พุท
- ค่าอุณหภูมิสูงสุด/ต่ำสุด (โมเดลที่ 3) 12 เอาท์พุท

ตาราง 3-5 สรุปความแตกต่างทั้ง 5 โมเดลของโครงข่ายการเรียนรู้

โมเดลที่	ลักษณะของโมเดล
1	เป็นโมเดลการพยากรณ์ค่ากำลังไฟฟ้ารายชั่วโมง ซึ่งจะป้อนข้อมูลค่าอุณหภูมิสูงสุด/ต่ำสุด และค่ากำลังไฟฟ้ารายชั่วโมงในอดีต ช่วงระยะเวลา 14 วัน ติดต่อกัน
2	เป็นโมเดลการพยากรณ์ค่ากำลังไฟฟ้ารายชั่วโมง เหมือนกับโมเดลที่ 1 ต่างกันตรงที่โมเดลนี้จะไม่ใช่ค่าอุณหภูมิสูงสุด/ต่ำสุดในอดีต
3	เป็นโมเดลการพยากรณ์ค่าอุณหภูมิสูงสุด/ต่ำสุด
4	เป็นโมเดลการพยากรณ์ค่ากำลังไฟฟ้ารายชั่วโมง ซึ่งจะป้อนข้อมูลค่าอุณหภูมิสูงสุด/ต่ำสุดจริงและค่ากำลังไฟฟ้ารายชั่วโมงจริงในอดีต โดยจะแบ่งประเภทของกลุ่มวัน
5	เป็นโมเดลการพยากรณ์ค่ากำลังไฟฟ้ารายชั่วโมง เหมือนกับโมเดลที่ 4 ต่างกันตรงที่จะเพิ่มอีก 3 อินพุท ได้แก่ ค่ากำลังไฟฟ้าสูงสุด/ต่ำสุดจริงและพลังงานไฟฟ้าจริง