

## บทที่ 2

### นิวรอลเน็ตเวิร์ก

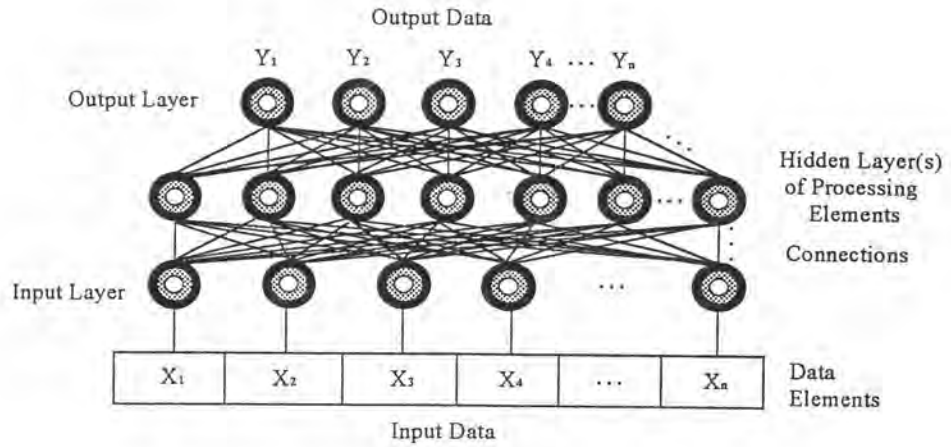
นิวรอลเน็ตเวิร์กคือ ระบบที่ประกอบไปด้วยหน่วยประมวลผลแบบง่าย ๆ หลาย ๆ ตัวที่อาจเชื่อมโยงกันอย่างทั่วถึงหรือไม่ทั่วถึงก็ได้ (Fully Connection or Partial Connection) การทำงานของระบบขึ้นกับลักษณะการเชื่อมโยงระหว่างหน่วยประมวลผลและค่าน้ำหนัก เป็นชุดสถาปัตยกรรมสำหรับการประมวลผลข้อมูลซึ่งอยู่ในรูปแบบต่างๆ อาจเป็นซอฟต์แวร์ หรือโครงสร้างของฮาร์ดแวร์ที่ถูกสอนให้รู้จักรูปแบบข้อมูลแบบต่างๆ สำหรับการดำเนินงานนิวรอลเน็ตเวิร์ก เรียนรู้จากการจำแนกข้อมูลจำนวนมากโดยเทียบกับข้อมูลเข้า-ออกที่กำหนด ปรับตัวแปร หรือค่าน้ำหนักที่จุดที่นิวรอลติดต่อซึ่งกันและกัน จากนั้นชั้นของหน่วยประมวลผลในแต่ละระดับจะสื่อสารกัน หน้าที่ของหน่วยประมวลผลเหล่านี้และโครงสร้างของการเชื่อมโยงได้แนวคิดจากการศึกษาระบบประสาทของมนุษย์

ระบบนี้มีความสามารถของการทำงานระดับสูง (High-Level Function) เช่น การปรับตัว หรือการเรียนรู้ได้โดยมีหรือไม่มีผู้สอน และยังมีมีความสามารถของการทำงานระดับล่าง (Low-Level Function) เช่น การมองเห็น และการประมวลผลคำพูด

รูปที่ 2.1 แสดงถึงส่วนประกอบของนิวรอลเน็ตเวิร์กซึ่ง ประกอบด้วยส่วนประกอบหลักดังนี้


- หน่วยประมวลผล (Processing Elements)
- ค่าน้ำหนักและฟังก์ชันการแปลงค่าจากหน่วยความจำไปยังหน่วยประมวลผล (Weight and Transfer Function)
- ชั้นข้อมูลนำเข้า (Input Layer)
- ชั้นแอบแฝงของหน่วยประมวลผล (Hidden Layer)
- ความหนาแน่นของจุดที่นิวรอลติดต่อซึ่งกันและกัน (Connections)
- การเรียนรู้ ซึ่งเกิดจากการปรับค่าน้ำหนักระหว่างหน่วยประมวลผล
- ชั้นแสดงผลลัพธ์ (Output Layer)

รูปที่ 2.2 แสดงถึงภาพของสถาปัตยกรรมของนิวรอลเน็ตเวิร์ก โดยมีอย่างน้อย 50 ชนิตที่ใช้ในการวิจัย หรือถูกนำไปพัฒนาระบบงาน และแม้ว่าทุกชนิตประกอบด้วยหน่วยประมวลผล แต่ก็มีความแตกต่างกันของอัลกอริทึมการเรียนรู้

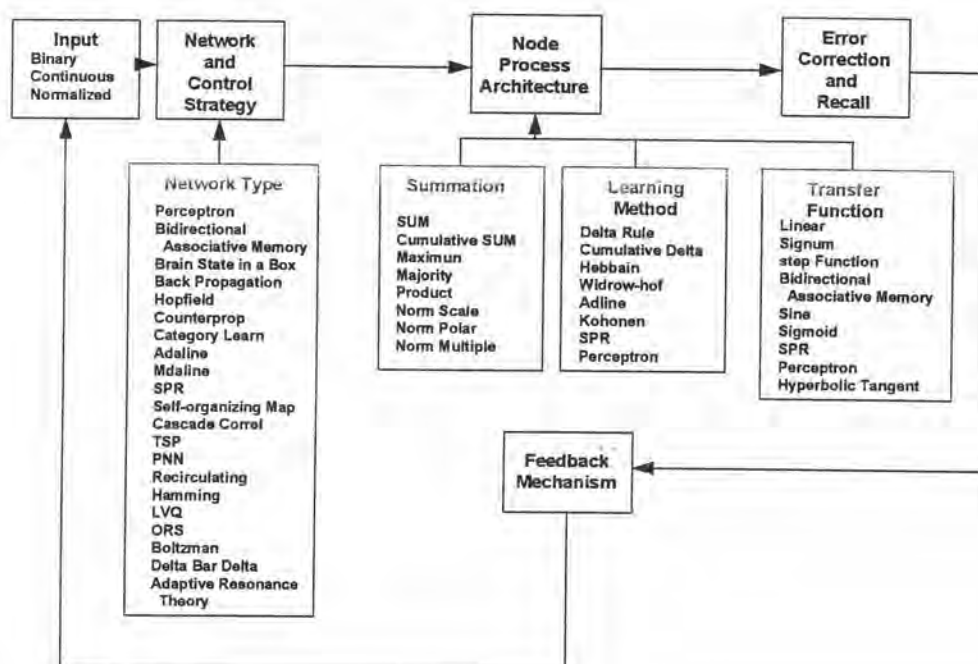


**Processing Element Detail**

$X_j$  = Input Signal (connection) from neuron  $j$   
 $W_i$  = Weight of connection  $j$   
 $T(I)$  = Transfer function



รูปที่ 2.1 ส่วนประกอบของนิวรอลเน็ตเวิร์ก




รูปที่ 2.2 สถาปัตยกรรมของนิวรอลเน็ตเวิร์ก

### ประวัติความเป็นมาและวิวัฒนาการ


นักประสาทวิทยาได้พัฒนาโมเดลซึ่งแสดงถึงวิธีที่สมองของมนุษย์ประมวลผลข้อมูลภายในสมองเซลล์ประสาทเชื่อมโยงกันอย่างซับซ้อนผ่านใยใยของเส้นทางนำข้อมูลเข้าและเส้นทางผลลัพธ์ นิวเคลียสของเซลล์ประสาทเปรียบเสมือนหน่วยประมวลผลง่าย ๆ ที่รับสัญญาณไฟฟ้าจากนิวรอลอื่นหลาย ๆ นิวรอลทางเส้นทางนำข้อมูลเข้า หรือที่เรียกว่าเดนไดรท์ (Dendrites) นิวรอลอื่นเป็นร้อยละนิวรอลจะรับข้อมูลนำเข้านั้นไปเช่นกัน ถ้าผลของข้อมูลนำเข้ามาสูงกว่าระดับการกระตุ้น (Threshold) ซึ่งขึ้นกับค่าความแข็งแกร่งและความถี่ของสัญญาณที่ได้รับจากแต่ละการเชื่อมโยง นิวรอลจะส่งสัญญาณไปยังเส้นทางของผลลัพธ์ (Axon) ดังแสดงในรูปที่ 2.3

นิวรอลที่ถูกกระตุ้นอาจเป็นตัวกระตุ้นนิวรอลอื่น แล้วนิวรอลที่ถูกกระตุ้นนั้นก็อาจเป็นตัวกระตุ้นนิวรอลอื่นอีกหลาย ๆ นิวรอลด้วยสัญญาณไฟฟ้า ทุกครั้งที่เหตุการณ์นี้เกิดขึ้นจะทำให้การเชื่อมโยงแข็งแกร่งขึ้น นั่นคือเกิดการเรียนรู้ ในสมองมนุษย์จะประกอบด้วยเซลล์ประสาทหรือนิวรอลประมาณ 100 พันล้านนิวรอล( $10^{11}$ ) และมีการเชื่อมโยงกันถึง  $10^{15}$  ซึ่งทำให้เกิดสัญญาณ  $10^{16}$  ครั้งต่อวินาที

### Biological Processing Element



### A Neural Network Processing Element



รูปที่ 2.3 โมเดลทางชีวภาพ

นิวรอลเน็ตเวิร์กเป็นการคำนวณชนิดหนึ่งที่ได้รับแรงบันดาลใจจากโมเดลทางชีวภาพ นั่นคือมีความพยายามที่จะลอกเลียนความสามารถของสมองมนุษย์ ทฤษฎีของนิวรอลเน็ตเวิร์ก เริ่มตั้งแต่ปีทศวรรษ 1950 โดยนักฟิสิกส์ จิตกร และนักชีววิทยา ผู้บุกเบิกเหล่านี้เริ่มต้นประยุกต์ นิวรอลเน็ตเวิร์กให้แก่ปัญหาในการจำแนกแยกแยะ เช่นการจำแนกแยกแยะตัวอักษร

ปลายทศวรรษ 1950 Frank Rosenblatt จากมหาวิทยาลัยคอร์เนล ได้พัฒนา Perceptron ซึ่งเป็นระบบประสาทเทียมเลียนแบบการทำงานของระบบประสาทสมองมนุษย์ ระบบ ของ Rosenblatt ซึ่งสามารถแยกแยะตัวอักษร ทำให้เกิดการพัฒนา เดิบโตในงานวิจัยด้าน นิวรอลเน็ตเวิร์ก

ปีค.ศ. 1969 Marvin Minsky ซึ่งเป็นหนึ่งในผู้ก่อตั้งความคิดในเรื่องปัญญาประดิษฐ์ ได้ ทำให้แนวทางจำลองแบบการทำงานของสมองต้องประสบความชะงักงันไปสิบกว่าปี โดยเขียน

หนังสือชื่อ Perceptron ร่วมกับ Papert โจมตีว่า Perceptron ปรากฏคุณค่าทางวิทยาศาสตร์ และได้พิสูจน์ให้เห็นว่า Perceptron ขณะนั้นไม่สามารถแก้ปัญหา non-linear logic (exclusive or) และปัญหาทางด้านแยกแยะรูปแบบบางอย่างได้เช่น ไม่สามารถแยกตัว T กับตัว C ออกจากกันได้ (Minsky และ Papert, 1969)

กลุ่มทางด้านนิรอลเน็ตเวิร์กไม่ได้มีผลงานอะไรอีกจนกระทั่งประมาณปีค.ศ. 1978 จึงมีการรวมตัวของนักภาษาศาสตร์ นักปรัชญา นักคอมพิวเตอร์ นักชีววิทยา นักฟิสิกส์ นักจิตวิทยา โดยมีศูนย์กลางอยู่ที่มหาวิทยาลัยซานดิเอโก และเรียกตัวเองว่า PDP Group (Parallel Distributed Processing) และนี่เองทำให้นิรอลเน็ตเวิร์กได้เกิดใหม่อีกครั้ง และในปี 1986 หนังสือ 2 เล่มชื่อ Parallel Distributed Processing Vol.I-II ที่ขณะนี้อยู่กันว่าเป็นคัมภีร์ของนิรอลเน็ตเวิร์กได้ตีพิมพ์จำหน่าย (มนตรี วงศ์ทองศรี, 2534)

ตารางที่ 2.1 แสดงถึงยุคต่างๆของการวิจัยทางนิรอลเน็ตเวิร์ก

เวลา	ผู้ค้นคว้า	งานวิจัย
แนวความคิดพื้นฐาน ค.ศ.1940-1960	McCulloch & 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) Cerebellum Model (CMAC) Linear Associative Learning NGO-Cognitron Adaptive Resonance Theory (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 Dadwin III (Neural Darwinish)

ตารางที่ 2.1 ยุคของการวิจัยทางนิรอลเน็ตเวิร์ก

แรงจูงใจที่ทำให้มีการศึกษานิวรอลเน็ตเวิร์ก (Herz, Krogh และ Palmer, 1991)

1. ความแข็งแกร่ง

เซลล์ประสาทสมองมนุษย์มีการตายทุกวัน ซึ่งเป็นสิ่งปกติเช่นเดียวกับเซลล์ผิวหนัง แต่ไม่มีผลต่อประสิทธิภาพในการทำงานของสมอง นั่นคือถ้าส่วนใดส่วนหนึ่งของนิวรอลเน็ตเวิร์กเสียไปก็ยังสามารถทำงานต่อไปได้

2. ความยืดหยุ่น

เนื่องจากมนุษย์มีความสามารถในการเรียนรู้ทำให้สามารถปรับสภาพให้เข้ากับสิ่งแวดล้อมต่างๆ ซึ่งเป็นสิ่งที่ต้องปรับปรุงอยู่เสมอของดิจิทัลคอมพิวเตอร์

3. ความสามารถในการบ่งชี้ข้อมูล

นิวรอลเน็ตเวิร์กมีความสามารถในการจัดการกับข้อมูลที่คลุมเคลือไม่สมบูรณ์หรือขัดแย้งกันได้อย่างสูง

4. ความสามารถในการทำงานคู่ขนาน

นิวรอลเน็ตเวิร์กมีการทำงานแบบคู่ขนาน จากชั้นหนึ่งซึ่งประกอบด้วยนิวรอลหลายนิวรอลไปอีกชั้นหนึ่งซึ่งประกอบด้วยหลายนิวรอล เช่นเดียวกับการทำงานของระบบประสาทมนุษย์

5. มีขนาดเล็กและใช้พลังงานน้อย

คุณสมบัติของนิวรอลเน็ตเวิร์ก (Wasserman, 1989)

นิวรอลเน็ตเวิร์กมีคุณสมบัติบางอย่างคล้ายกับสมองมนุษย์ เช่นสามารถเรียนรู้จากประสบการณ์ ตัวอย่าง สามารถปรับตัวเองเข้ากับสิ่งแวดล้อมได้เป็นอย่างดี และสามารถอนุมานจากสิ่งที่เรียนรู้ไปสู่สิ่งที่ไม่เคยเรียนรู้มาก่อน หรือที่เรียกว่าความสามารถในการบ่งชี้ทั่วไป (Generalization)

นิเวรอลเน็ตเวิร์กมีคุณสมบัติ 2 ประการคือ

- การเรียนรู้ (Learning)

นิเวรอลเน็ตเวิร์กสามารถเรียนรู้จากชุดการสอนที่เราป้อนให้

- การระลึกหรือจดจำได้ (Recall)

นิเวรอลเน็ตเวิร์กสามารถระลึกได้ทั้งชุดการสอนและชุดการทดสอบ หรือชุดทั่วไปได้ดีในระดับที่ยอมรับได้ โดยชุดการทดสอบจะมีความแตกต่างจากชุดการสอนอยู่บ้าง ซึ่งความแตกต่างเรียกว่ามีสิ่งปนเปื้อน หรือสิ่งบิดเบือนของข้อมูลประเภทนั้นๆ ซึ่งเป็นลักษณะของสภาพความเป็นจริงที่เกิดขึ้น

ข้อเปรียบเทียบระหว่างการประมวลผลแบบดั้งเดิมกับนิเวรอลเน็ตเวิร์ก

1. การประมวลผลแบบดั้งเดิม (Traditional Approach)

เป็นการวิเคราะห์ข้อมูลโดยมนุษย์ - ดังนั้นทรัพยากรมนุษย์จะถูกใช้ในการพัฒนาอัลกอริทึมและโปรแกรม ตัวอย่างเช่น การประมวลผลภาพในการระบุว่าเป็นแมว, สุนัข หรือกระต่าย ทำให้เกิดโปรแกรม 3 โปรแกรมในการบ่งบอกภาพแต่ละภาพ และเมื่อมีภาพชนิดใหม่ๆ ขึ้นมา โปรแกรมก็ไม่สามารถที่จะบอกได้ ต้องทำการพัฒนาอัลกอริทึมและโปรแกรมขึ้นมาใหม่

2. การประมวลผลแบบนิเวรอลเน็ตเวิร์ก (Neural Network Approach)

จากตัวอย่างการประมวลผลภาพแรกเริ่มเราจะให้ภาพแต่ละภาพเป็นข้อมูลนำเข้า และผลลัพธ์เป็นข้อความที่ระบุชนิดของภาพนั้นเช่น แมว, สุนัข หรือกระต่าย โดยผ่านกระบวนการสอนให้นิเวรอลเน็ตเวิร์กรู้จักจำแนกชนิดของภาพต่างๆโดยค่าน้ำหนักจะถูกปรับแต่งอยู่ตลอดเวลา

ในกระบวนการสอน จะมีการสอนวนซ้ำหลายๆรอบ เพื่อให้นิเวรอลเน็ตเวิร์กเกิดการเรียนรู้ เมื่อสิ้นสุดการสอนแล้วนิเวรอลเน็ตเวิร์กก็จะสามารถจำแนกชนิดของภาพได้ และเมื่อมีภาพใหม่ๆที่ต้องการให้นิเวรอลเน็ตเวิร์กรู้จักก็สามารถทำในทำนองเดียวกัน และต้องมีการสอนใหม่ แต่ทำให้ประหยัดเวลาและแรงงานในการพัฒนาโปรแกรมขึ้นมาใหม่

การเก็บข้อมูลของนิเวรอลเน็ตเวิร์กเป็นแบบกระจายและถูกใช้ร่วมกันโดยหลายๆนิเวรอล ซึ่งต่างกับแบบดั้งเดิมคือข้อมูลจะเก็บไว้ในหน่วยความจำ

การเก็บข้อมูลของนิเวศเน็ตเวิร์กแบบกระจายนั้นทำให้เกิดความซ้ำซ้อน ซึ่งเป็นการเพิ่มความปลอดภัย คือเป็นระบบสำรองทดแทน (Fault/Error Tolerance System) ได้ อย่างดี

ชุดการสอนที่ใช้สอนนิเวศเน็ตเวิร์กมีผลต่อการเรียนรู้ ถ้าเป็นชุดตัวอย่างที่ดีจะทำให้เกิดการเรียนรู้ได้ดีและเร็ว แต่ถ้าเป็นชุดข้อมูลการสอนที่ไม่ดีทำให้การเรียนรู้ไม่ดีเท่าที่ควร หรือไม่เกิดการเรียนรู้เลย

ตารางที่ 2.2 แสดงการเปรียบเทียบระหว่างการประมวลผลแบบดั้งเดิมกับนิเวศเน็ตเวิร์ก

การประมวลผลแบบดั้งเดิม	นิเวศเน็ตเวิร์ก
การพัฒนาเน้นไปที่อัลกอริธึมสำหรับทุกกรณีที่เกิดขึ้น	การพัฒนาเน้นที่ระบบการสอน
ต้องเขียนโปรแกรมล่วงหน้า - ใช้กฎและตรรกเพื่อสร้างผลลัพธ์	เรียนรู้จากตัวอย่างเพื่อผลลัพธ์ที่ต้องการ
ขึ้นกับกฎ/ตรรก	สถิติ ขึ้นกับความสัมพันธ์
ประมวลผลโดยอาศัยขั้นตอนต่างๆที่แน่นอนและให้ผลออกมาตามที่คาดคะเนเอาไว้	อาศัยวิธีการประมวลผลข้อมูลที่แตกต่างกันไปในแต่ละกรณีของปัญหา
การตัดสินใจต้องใช้ความรู้และข้อมูลทั้งหมด	สามารถจัดการกับข้อมูลที่ไม่สมบูรณ์ หรือข้อมูลที่มีความสับสนได้
ตัดสินใจในรูปของ ใช่หรือ ไม่ใช่ทางคณิตศาสตร์ หรือตรรกศาสตร์	ตัดสินใจโดยอาศัยตัวเลขแสดงน้ำหนัก บนฐานของข้อมูลตัวเลขที่สามารถแสดงความเอนเอียง (Fuzzy) ตลอดจนยอมรับข้อมูลที่ไม่สมบูรณ์ได้
ได้คำตอบเดิมเสมอ	บางครั้งอาจผิดพลาด - จะเตรียมคำตอบที่ยอมรับได้แต่ไม่จำเป็นต้องเป็นคำตอบที่ดีที่สุด
ให้คำตอบที่แน่นอน เมื่อให้เวลาคำนวณอย่างเพียงพอ	ให้คำตอบโดยประมาณสำหรับปัญหาที่ซับซ้อนมากๆ



การประมวลผลแบบดั้งเดิม	นิวรอลเน็ตเวิร์ก
เหมาะสำหรับระบบที่ต้องการความแม่นยำในการคำนวณ, มีการไหลของข้อมูลเป็นลำดับ และมีตรรกที่ดี	เหมาะสมเมื่อไม่มีกฎที่แน่นอนและต้องการการตัดสินใจ
ประมวลผลข้อมูลในรูปแบบไบนารี	ประมวลผลสัญญาณที่อยู่ในรูปของสัญญาณอนาล็อก ที่แปรปรวนอยู่ตลอดเวลา
อยู่บนพื้นฐานของสัญลักษณ์	อยู่บนพื้นฐานของรูปแบบ
สามารถอธิบายและตรวจสอบได้	ไม่สามารถอธิบายการตัดสินใจได้ทั้งหมด
ไม่สามารถจัดการกับข้อยกเว้นต่างๆได้	จัดการกับข้อยกเว้นต่างๆได้ดี
ค้นหาสิ่งที่ต้องการจากฐานข้อมูลขนาดใหญ่ เพื่อให้ได้สิ่งที่ตรงกับความต้องการ	ค้นหาข้อมูลจากฐานข้อมูลโดยอาศัยหลักของความใกล้เคียงที่สุดเป็นเกณฑ์
มีวิธีการเก็บข้อมูลจำเพาะแน่นอน	เก็บข้อมูลโดยอาศัยเนื้อที่ที่มีอยู่ในสื่อบันทึกข้อมูลเช่นเครื่องบอกตำแหน่งที่เก็บข้อมูลมากกว่าการจำเป็นที่จะต้องรู้ตำแหน่งที่เก็บตั้งแต่แรก
ตายตัว	ปรับได้
แบบอนุกรม	แบบขนาน

ตารางที่ 2.2 (ต่อ) เปรียบเทียบระหว่างการประมวลผลแบบดั้งเดิมกับนิวรอลเน็ตเวิร์ก

### สารสนเทศที่ใช้ในนิวรอลเน็ตเวิร์ก

#### 1. ข้อมูลนำเข้า (Input)

ต้องเป็นค่าตัวเลข ถ้าเป็นข้อมูลเชิงคุณภาพต้องแปลงให้อยู่ในเชิงปริมาณที่นิวรอลเน็ตเวิร์กยอมรับเข้าไปเพื่อเรียนรู้ได้ นั่นคือกระบวนการเบื้องต้นก่อนการประเมินผล (Preprocess)

## 2. ผลลัพธ์ (Output)

คือผลลัพธ์ที่เกิดขึ้นจริง (Actual Output) จากกระบวนการเรียนรู้ของ  
นิวรอลเน็ตเวิร์ก

## 3. ค่าน้ำหนัก (Weights)

คือสิ่งที่ได้จากการเรียนรู้ของนิวรอลเน็ตเวิร์ก หรือเรียกอีกอย่างหนึ่งว่าค่า  
ความรู้ (Knowledge) ค่าน้ำหนักเป็นสิ่งที่สำคัญมากของนิวรอลเน็ตเวิร์ก และค่าเหล่านี้จะไม่มีการ  
เปลี่ยนแปลงอีกต่อไป ค่าเหล่านี้จะใช้ในการระลึกข้อมูลอื่นๆที่อยู่ในรูปแบบเดียวกัน

## 4. ฟังก์ชันผลรวม (Summation Function)

เป็นผลรวมของข้อมูลนำเข้า ( $a_i$ ) และค่าน้ำหนัก

$$S = \sum_{i=1}^n a_i w_i$$

## 5. ฟังก์ชันการแปลงค่า (Transfer Function)

เป็นการคำนวณการจำลองการทำงานของนิวรอลต่างๆ ฟังก์ชันที่นิยมใช้คือ  
ฟังก์ชันซิกมอยด์ (Sigmoid Function)

$$f(x) = 1 / (1 + e^{-x})$$

จุดประสงค์ของการแปลงค่าคือ เพื่อให้ผลลัพธ์ที่ได้อยู่ในช่วง 0-1 มิเช่นนั้น  
ค่าที่ได้จะโตมาก ดังนั้นจึงต้องมีการแปลงค่าข้อมูลที่ใช้ในการสอนและทดสอบ เพื่อให้สอดคล้อง  
กับฟังก์ชันที่ใช้

## ประเภทการเรียนรู้ของนิวรอลเน็ตเวิร์ก

การเรียนรู้ของนิวรอลเน็ตเวิร์กสามารถแบ่งออกเป็น 3 ประเภทคือ

### 1. การเรียนรู้แบบมีครู (Supervised Learning)

การเรียนรู้แบบมีครูต้องการชุดข้อมูลนำเข้าและผลลัพธ์เป้าหมายเป็นชุด การสอนควบคู่ (Training Pair) โดยปกติการสอนเน็ตเวิร์กจะใช้ชุดการสอนควบคู่หลายชุด ในระหว่างการสอนเน็ตเวิร์กจะเกิดผลลัพธ์จริงขึ้น ผลต่างระหว่างผลลัพธ์จริงกับผลลัพธ์เป้าหมายคือค่าความคลาดเคลื่อน หรือค่าความผิดพลาด

การเรียนรู้ประเภทนี้ได้แก่ Adaptive Linear Neural Element (ADALINE) Backpropagation Recurrent Neural Network (RNN) เป็นต้น

### 2. การเรียนรู้แบบไม่มีครู (Unsupervised Learning)

การเรียนรู้แบบไม่มีครูถูกพัฒนาขึ้นเพื่อให้ใกล้เคียงกับระบบการเรียนรู้ของสมองมนุษย์มากยิ่งขึ้น โดยมีเพียงชุดข้อมูลนำเข้า กระบวนการเรียนรู้จะใช้หลักการทางสถิติ โดยหาค่าทางสถิติของชุดการสอน และจัดกลุ่มข้อมูลออกเป็นระดับต่างๆ นิวรอลเน็ตเวิร์กจะหาค่าผลลัพธ์เอง จากความสัมพันธ์ระหว่างข้อมูลนำเข้าและผลลัพธ์

การเรียนรู้ประเภทนี้ได้แก่ Hopfield Network Neocognitron และ Self Organizing Feature Map (SOFM) เป็นต้น

### 3. การเรียนรู้เชิงบังคับ (Reinforcement Learning)

การเรียนรู้เชิงบังคับเป็นการเรียนรู้ทั้งแบบมีครูและไม่มีครู การเรียนรู้แบบไม่มีครูคือในระหว่างการสอนมีเพียงชุดข้อมูลนำเข้า การเรียนรู้แบบมีครูคือเมื่อได้ผลลัพธ์จะบอกว่าถูกหรือผิด แต่ไม่ได้บอกว่าผลลัพธ์ที่ถูกคืออะไร

## การเรียนรู้แบบย้อนกลับ (Backpropagation)

Werbos ได้เสนอแนวความคิดของการเรียนรู้แบบย้อนกลับในปีค.ศ. 1974 จากนั้น Parker ได้นำเสนออีกครั้งในปีค.ศ. 1982 และได้ทำให้เป็นที่รู้จักมากยิ่งขึ้นโดย Rumelhart และคณะในปีค.ศ. 1986 ในหนังสือชื่อ Parallel Distributed Processing ซึ่งกล่าวถึงศักยภาพของนิวรอลเน็ตเวิร์กและการเรียนรู้แบบย้อนกลับ

งานประยุกต์เริ่มแรกของการเรียนรู้แบบย้อนกลับเป็นโปรแกรม NETTALK ซึ่งสร้างโดย Sejnowski และ Rosenberg ในมหาวิทยาลัยจอห์นฮอปกิน

การเรียนรู้แบบย้อนกลับเป็นรูปแบบหนึ่งของนิวรอลเน็ตเวิร์กที่ใช้กันอย่างกว้างขวางและนำมาประยุกต์กับการศึกษาในงานประเภทต่างๆ เช่น ทางทหาร การช่วยในการวินิจฉัยของแพทย์ การรู้จำคำพูด การรู้จำตัวอักษร


การเรียนรู้แบบย้อนกลับสามารถแก้ปัญหาที่ต้องการรูปแบบ โดยการป้อนรูปแบบเข้าไป นิวรอลเน็ตเวิร์กก็จะให้รูปแบบผลลัพธ์ที่เกี่ยวข้องกันออกมา (Dayhoff, 1990)

การเรียนรู้แบบย้อนกลับเป็นวิธีการหนึ่งของนิวรอลเน็ตเวิร์กที่ถ่ายทอดความเข้าใจ เนื่องจากกระบวนการเรียนรู้และปรับปรุงแก้ไขนั้นเป็นไปด้วยตัวเอง ถ้านิวรอลเน็ตเวิร์กให้คำตอบที่ผิดค่าน้ำหนักก็จะถูกปรับจนกว่าค่าความผิดพลาดจะน้อยลง หรืออยู่ในเกณฑ์ที่ยอมรับได้ นั่นคือค่าที่ได้ในครั้งต่อไปจะมีความถูกต้องมากยิ่งขึ้น

การเรียนรู้แบบย้อนกลับมีโครงสร้างเป็นชั้นๆ แต่ละชั้นเชื่อมโยงกันอย่างทั่วถึงกับชั้นที่อยู่ด้านบนและชั้นที่อยู่ด้านล่าง เมื่อเน็ตเวิร์กได้รับข้อมูลนำเข้าจะทำการคำนวณค่าน้ำหนักของหน่วยประมวลผลนำเข้าไปยังชั้นแอบแฝง และจากชั้นแอบแฝงไปยังชั้นแสดงผล เมื่อเกิดผลต่างระหว่างผลลัพธ์จริงกับผลลัพธ์เป้าหมาย เน็ตเวิร์กจะปรับค่าความผิดพลาดจากหน่วยแสดงผลและแพร่ย้อนกลับไปยังชั้นแอบแฝง จากชั้นแอบแฝงไปยังชั้นข้อมูลนำเข้า


## โครงสร้างของการเรียนรู้แบบย้อนกลับ

การเรียนรู้แบบย้อนกลับมีโครงสร้างเป็นชั้นๆ โดยมีโครงสร้างอย่างง่าย ๆ 3 ชั้นคือ ชั้นข้อมูลนำเข้า ชั้นแอบแฝงและชั้นแสดงผล แต่ละชั้นจะติดต่อกันอย่างสมบูรณ์ดังรูปที่ 2.4




รูปที่ 2.4 รูปแบบของการเรียนรู้แบบย้อนกลับชนิด 3 ชั้น

จากรูปที่ 2.4 แสดงรูปแบบของการเรียนรู้แบบย้อนกลับชนิด 3 ชั้น ชั้นล่างคือชั้นข้อมูลนำเข้าซึ่งนำข้อมูลจากภายนอก ชั้นถัดมาคือชั้นแอบแฝงซึ่งจะติดต่อกับทั้งชั้นข้อมูลนำเข้าและชั้นแสดงผลพัทธ์ที่อยู่ด้านบน



รูปที่ 2.5 รูปแบบของการเรียนรู้แบบย้อนกลับชนิด 5 ชั้น

จากรูปที่ 2.5 เป็นตัวอย่างของการเรียนรู้แบบย้อนกลับชนิด 5 ชั้นที่เชื่อมโยงติดต่อกันอย่างสมบูรณ์ โดยมีชั้นแอบแฝง 3 ชั้น



รูปที่ 2.6 หน่วยประมวลผล

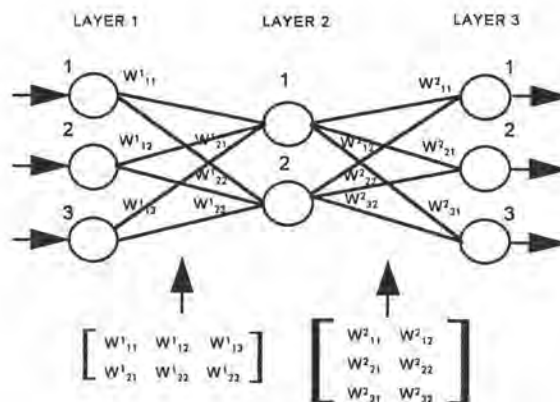
จากรูปที่ 2.6 จะเห็นว่าข้อมูลนำเข้าอยู่ทางด้านซ้าย ทางด้านขวาคือหน่วยที่รับผลลัพธ์จากหน่วยที่  $j$

หน่วยประมวลผลกลางประกอบด้วย ผลรวมถ่วงน้ำหนักของข้อมูลนำเข้า ( $S_j$ ) ผลลัพธ์ ( $f(S_j)$ ) และค่าความผิดพลาด ( $\delta_j$ ) ที่ใช้ในการปรับค่าน้ำหนัก

ค่าน้ำหนักที่เกี่ยวข้องเนื่องกับการติดต่อแต่ละชั้นจะถูกปรับแต่งตลอดเวลาระหว่างการเรียนรู้ เพื่อลดค่าความแตกต่างระหว่างผลลัพธ์ที่ได้กับผลลัพธ์ที่ต้องการ

ค่าน้ำหนักจากหน่วยที่  $i$  ไปยังหน่วยที่  $j$  คือ  $W_{ij}$  เมื่อจบการเรียนรู้แล้วค่าน้ำหนักนี้จะใช้ในกระบวนการการระลึก

รูปที่ 2.7 แสดงถึงการแทนค่าน้ำหนักด้วยเมตริกซ์ โดยมีค่ากำกับบน (Subscript) บ่งบอกถึงชั้นที่ต่างกัน เช่น  $W'_{21}$  หมายถึงค่าน้ำหนักจากหน่วยประมวลผลที่ 2 ในระดับชั้นที่ 1 ไปยังหน่วยที่ประมวลผลที่ 1 ในระดับชั้นที่ 2



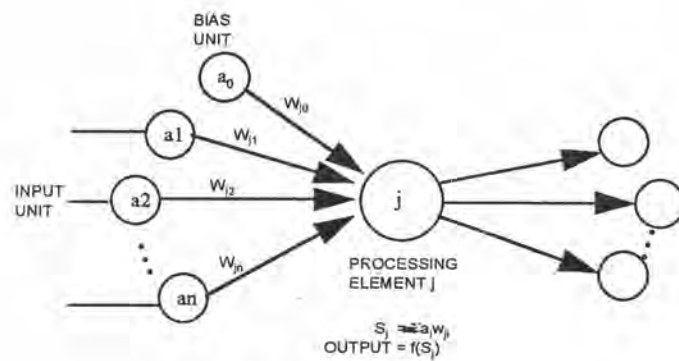
รูปที่ 2.7 การแทนค่าน้ำหนักด้วยเมตริกซ์

## ขั้นตอนการเรียนรู้แบบย้อนกลับ

ประกอบด้วย 2 ขั้นตอน

### 1. การแพร่เดินทาง (Forward Propagation)

ขั้นตอนนี้เริ่มเมื่อเน็ตเวิร์กได้รับข้อมูลนำเข้าและค่าของหน่วยประมวลผลในขั้นข้อมูลนำเข้าถูกกำหนด ขั้นอื่นๆจึงจะเริ่มทำการแพร่เดินทาง



รูปที่ 2.8 ขั้นตอนการแพร่เดินทาง

จากรูปเป็นการคำนวณผลรวมของผลลัพท์ที่เข้ามายังหน่วยที่  $j$  ดังสมการ


$$S_j = \sum a_i w_{ij}$$

โดยที่  $a_i$  = ข้อมูลจากหน่วยที่  $i$

$w_{ij}$  = ค่าน้ำหนักจากหน่วยที่  $i$  ไปยังหน่วยที่  $j$

จากนั้นจะทำการแปลงค่าข้อมูลโดยคำนวณหาค่า  $f(S_j)$  โดยซิกมอยด์

ฟังก์ชัน



รูปที่ 2.9 ซิกมอยด์ฟังก์ชัน

จากรูปที่ 2.9 ปลายทั้งสองข้างของเส้นกราฟมีความชันน้อย แต่เส้นกราฟจะมีความชันมากในช่วงกลาง นั่นคือเมื่อ  $x$  น้อยกว่า  $-3$  ค่าของ  $f(x)$  จะเข้าใกล้ 0 และเมื่อ  $x$  มากกว่า 3 ค่าของ  $f(x)$  จะเข้าใกล้ 1 อีกนัยหนึ่งคือ ค่าของ  $f(x)$  จะเข้าใกล้ 1 เมื่อ  $x$  มีค่ามาก และ  $f(x)$  จะเข้าใกล้ 0 เมื่อ  $x$  มีค่าน้อย สมการของซิกมอยด์คือ

$$f(x) = 1 / 1 + e^{-x}$$

เมื่อ  $x$  เป็นค่าผลรวมของหน่วยที่  $j$  ดังนั้น

$$f(S_j) = 1 / 1 + e^{-S_j}$$

เมื่อได้รับค่า  $f(S_j)$  แล้วค่า  $f(S_j)$  จะกลายเป็นผลลัพธ์ของหน่วยที่  $j$  ซึ่งก็คือค่า  $a_j$  ดังรูปที่ 2.8 โดยจะส่งค่าออกไปยังหน่วยอื่นๆด้วยค่า  $a_j$  ที่เท่ากัน

สำหรับชั้นข้อมูลนำเข้าจะเป็นกรณีพิเศษ โดยที่หน่วยประมวลผลในชั้นนี้จะไม่ทำการคำนวณผลรวมจากข้อมูลนำเข้าและจะไม่ทำการแปลงค่าข้อมูล เนื่องจากแต่ละหน่วยประมวลผลจะใช้ค่าของข้อมูลนำเข้าเป็นค่าของตัวเอง

จากรูปที่ 2.8 หน่วยเอนเอียง (Bias Unit) เป็นหน่วยที่มีค่าเป็น 1 และเชื่อมโยงกับหน่วยอื่นๆหน่วย และค่าน้ำหนักของหน่วยนี้จะถูกปรับในระหว่างการเรียนรู้เช่นกัน หน่วยนี้จะให้ค่าคงที่กับหน่วยอื่นซึ่งบางครั้งทำให้การเรียนรู้ (Convergence Time) ของ



นิเวศน์ตเวริกเร็วขึ้น หน่วยเอนเอียงมีผลต่อระดับการกระตุ้น (Threshold) ของหน่วยอื่น นั่นคือเมื่อค่าน้ำหนักคงที่และ

$$C = w_{ij}$$

$$S_j = \sum a_i w_{ji}$$

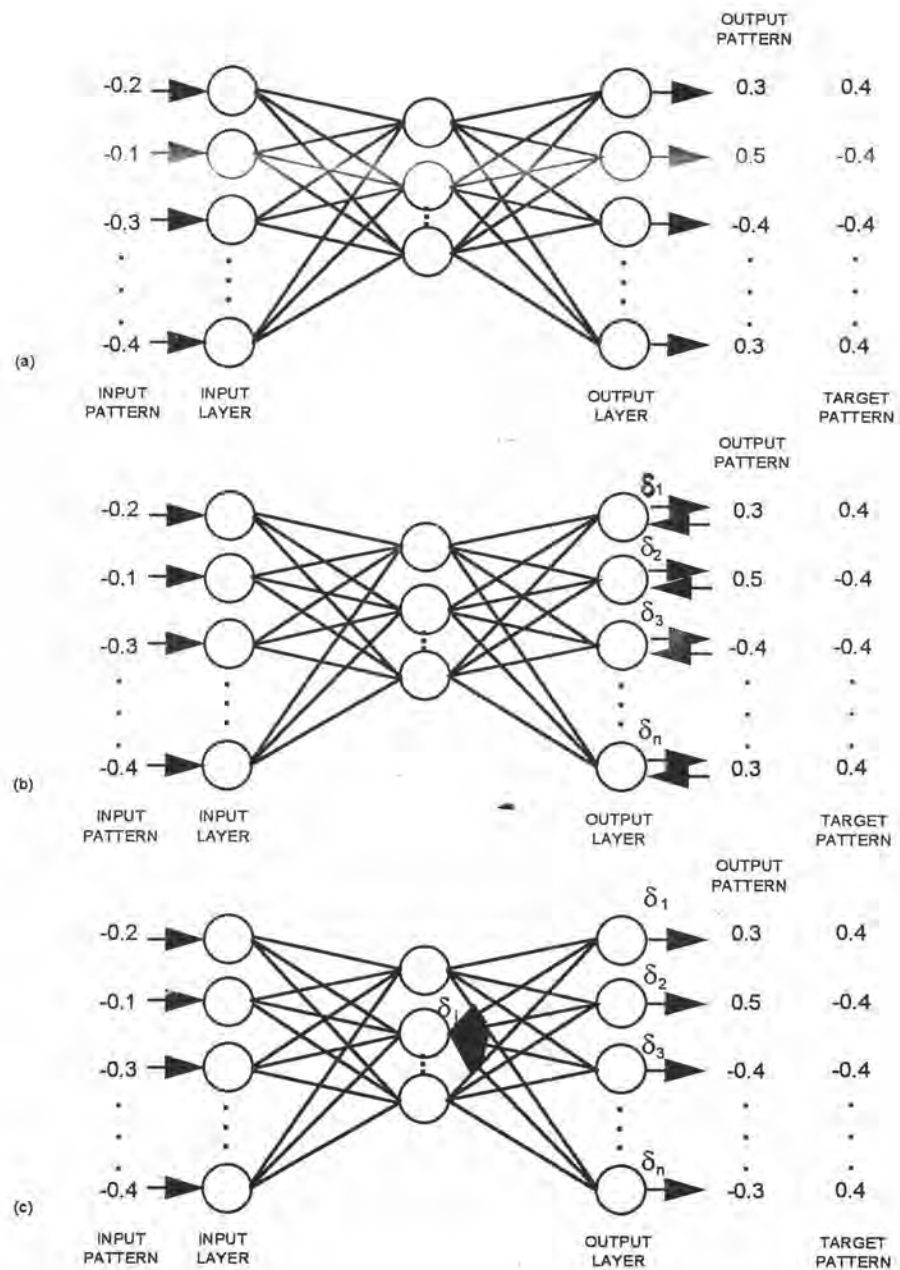
ดังนั้นผลรวมของหน่วยที่  $j = S + C$  ซึ่งจะทำให้กราฟของสมการซิกมอยด์ขยับไปทางซ้าย  $C$  หน่วยดัง ด้วยวิธีนี้จะทำให้ระดับการกระตุ้นของหน่วยเป้าหมายเปลี่ยนไป

เหตุที่ต้องใช้ซิกมอยด์เนื่องจากต้องการให้ระดับการกระตุ้นเป็นแบบอ่อน (Soft Threshold) มากกว่าการกระตุ้นแบบแรง (Hard Threshold) นั่นคือซิกมอยด์ฟังก์ชันให้ค่าที่ต่อเนื่องกัน

## 2. การแพร่ย้อนกลับ (Backward Propagation)

จากรูป 2.10 แสดงขั้นตอนการแพร่ย้อนกลับ ชั้นนี้ค่าความผิดพลาด  $\delta$  จะถูกคำนวณสำหรับทุกหน่วยและคำนวณค่าน้ำหนักที่จะเปลี่ยนทุกการเชื่อมโยง การคำนวณนี้เริ่มที่ชั้นแสดงผลลัพธ์และแพร่ย้อนกลับไปยังชั้นข้อมูลนำเข้า

ชั้นปรับปรุงความผิดพลาดเกิดหลังจากที่ดำเนินการแพร่เดินหน้าแล้ว หน่วยประมวลผลแต่ละหน่วยในชั้นแสดงผลลัพธ์จะให้ค่าผลลัพธ์ ที่จะเปรียบเทียบกับผลลัพธ์เป้าหมายในชุดการสอน(รูปที่ 2.10a) ความแตกต่างที่เกิดคือค่าความผิดพลาดสำหรับแต่ละหน่วยในชั้นแสดงผลลัพธ์ดังรูปที่ 2.10b ค่าน้ำหนักของทุกการเชื่อมโยงไปยังชั้นแสดงผลลัพธ์จะถูกปรับ จากนั้นค่าความผิดพลาดของหน่วยในชั้นแอบแฝงที่ต่ำกว่าชั้นแสดงผลลัพธ์(รูปที่ 2.10c) จะถูกคำนวณ แล้วค่าน้ำหนักของทุกการเชื่อมโยงไปยังชั้นแอบแฝงจะถูกปรับ กระบวนการนี้จะดำเนินไปจนกว่าชั้นสุดท้ายจะถูกปรับค่าน้ำหนัก



รูปที่ 2.10 ขั้นตอนการแพร่ย้อนกลับ

ค่า  $\delta$  คือค่าความผิดพลาดท้องถิ่น (Local Error) สามารถหาได้จากการคำนวณง่ายๆ สำหรับชั้นแสดงผลลัพธ์ และซับซ้อนขึ้นสำหรับชั้นแอบแฝง ถ้าหน่วย  $j$  เป็นหน่วยที่อยู่ในชั้นแสดงผลลัพธ์แล้วการคำนวณค่าความผิดพลาดจะได้จากสมการ

$$\delta_j = (t_j - a_j)f'(S_j)$$

เมื่อ  $t_j$  = ค่าเป้าหมายของหน่วยที่  $j$

$a_j$  = ค่าผลลัพธ์ของหน่วยที่  $j$

$f'(x)$  = อนุพันธ์ของซิกมอยด์ฟังก์ชัน

$S_j$  = ผลรวมของข้อมูลนำเข้ามาหน่วยที่  $j$

ถ้าหน่วย  $j$  เป็นหน่วยที่อยู่ในชั้นแอบแฝงแล้วค่าความผิดพลาดจะได้จาก


$$\delta_j = [\sum \delta_k w_{kj}]f'(S_j)$$

การปรับค่าน้ำหนักจะปรับโดยใช้ค่าของ  $\delta$  ทุกหน่วยที่รับผลลัพธ์จากหน่วยที่  $j$  ค่าน้ำหนักแต่ละค่าจะถูกปรับโดยนำค่า  $\delta$  ของหน่วยที่รับจากข้อมูลนำเข้าจากการเชื่อมโยงนั้น ค่าน้ำหนักจะถูกปรับโดยสมการ

$$w_{ji}^{\text{new}} = w_{ji}^{\text{old}} + \Delta w_{ji}$$

$$\Delta w_{ji} = \eta \delta_j a_i$$

รูปที่ 2.11 แสดงถึงการปรับค่าน้ำหนัก  $w_{ji}$  ซึ่งค่านี้ขึ้นกับตัวแปร 3 ตัวคือ  $\eta$ ,  $\delta_j$  และ  $a_i$



รูปที่ 2.11 การปรับค่าน้ำหนัก

ตัวแปร  $\eta$  คือค่าสัมประสิทธิ์การเรียนรู้ซึ่งจะถูกกำหนดโดยผู้ใช้ ถ้าค่า  $\eta$  มากจะทำให้เน็ตเวิร์กไม่คงที่และการเรียนรู้ไม่เป็นที่น่าพอใจ ถ้าเล็กเกินไปจะทำให้การเรียนรู้ช้า

บางครั้งค่า  $\eta$  สามารถเปลี่ยนได้เพื่อทำให้การเรียนรู้มีประสิทธิภาพขึ้น เช่นเริ่มต้นใช้ค่า  $\eta$  มากๆ และลดลงในระหว่างการสอน

นอกจากค่า  $\eta$  แล้วยังมีค่าโมเมนตัม  $\alpha$  ซึ่งคิดค้นโดย Rumelhart Hinton และ William ในปีค.ศ.1986 เพื่อช่วยให้การเรียนรู้เร็วขึ้น ดังนั้นค่าน้ำหนักจะถูกปรับโดยสมการ

$$\Delta w_{ji}(k+1) = \eta \delta_j a_i + \alpha |\Delta w_{ji}(k)|$$

เมื่อ  $k$  คือดัชนีเวลา (Time Index) หรือจำนวนรอบของการปรับปรุงค่าน้ำหนัก

### การสอนการเรียนรู้แบบย้อนกลับ

การสอนเน็ตเวิร์กชนิดการเรียนรู้แบบย้อนกลับ เป็นการสอนแบบมีครู โดยมีการกำหนดรูปแบบข้อมูลนำเข้าควบคู่กับรูปแบบเป้าหมาย มีการกำหนดชุดการสอนหลายๆรูปแบบ เพื่อให้เน็ตเวิร์กสามารถเรียนรู้

ในกระบวนการสอนเพื่อให้เน็ตเวิร์กสามารถเรียนรู้ได้ดีนั้นจะต้องใช้การวนซ้ำสอนหลายๆรอบ การสอนเน็ตเวิร์กจะสำเร็จหรือไม่ดูจากค่า RMS ดังสมการ

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

โดย  $n_p$  = จำนวนของรูปแบบในชุดการสอน

$n_o$  = จำนวนหน่วยในชั้นแสดงผลลัพธ์

$t_{jp}$  = ค่าเป้าหมายของหน่วยที่  $j$  หลังจากเสนอรูปแบบ  $p$


$a_{jp}$  = ค่าผลลัพธ์ที่ได้จากหน่วยที่  $j$  หลังจากเสนอรูปแบบ  $p$

ซึ่งสมการนี้ใช้ในการพิจารณาหาจุดเหมาะสมสำหรับรูปแบบหรือสมการพยากรณ์ (Optimal Forecasting Models) ด้วยการประมาณค่าพารามิเตอร์ของสมการที่ทำให้ค่า RMS มีค่าน้อยที่สุดด้วยเช่นกัน (สุพล ดุรงค์วัฒนา, 2537)

เมื่อค่า RMS เข้าใกล้ศูนย์ หรือลดลงต่ำกว่า 0.1 หมายความว่าเน็ตเวิร์กได้เกิดการเรียนรู้แล้ว

ถ้าเน็ตเวิร์กตกอยู่ภายใต้จุดต่ำสุดท้องถิ่น (Local Minimum) นั่นคือเน็ตเวิร์กได้หยุดการเรียนรู้แล้ว หรือไม่สามารถระลึกชุดการทดสอบได้เลย แม้ว่าจะระลึกชุดการสอนได้

ถ้าเน็ตเวิร์กตกอยู่ต่ำสุดโดยรวม (Global Minimum) นั่นคือ ค่า RMS ของเน็ตเวิร์กได้ถึงจุดต่ำสุดแล้ว และสามารถระลึกได้ทั้งชุดการสอนและชุดการทดสอบได้ในระดับที่พอใจ



รูปที่ 2.12 จุดต่ำสุดท้องถิ่นและจุดต่ำสุดโดยรวม

ข้อดีและข้อจำกัดของการเรียนรู้แบบย้อนกลับ (Dayhoff, 1990)

### 1. ข้อดี

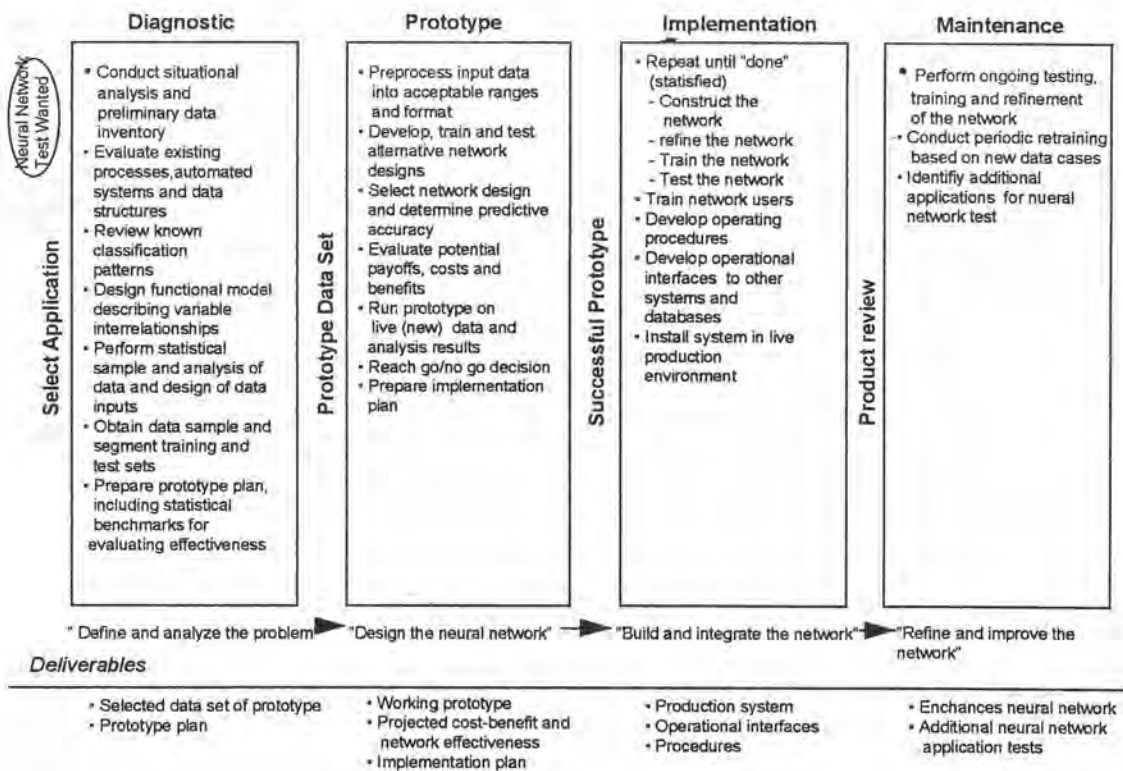
คือมีความสามารถในการจัดจํารูปแบบของปัญหา (Pattern Mapping) ซึ่งการเรียนรู้แบบย้อนกลับสามารถที่จะเรียนรู้ความสัมพันธ์ของรูปแบบได้มากมาย โดยการเรียนรู้แบบย้อนกลับต้องการตัวอย่างรูปแบบที่จะเรียนรู้ ไม่ต้องการความรู้ทางด้านคณิตศาสตร์เพื่อแมพ (map) รูปแบบของข้อมูลนำเข้าและผลลัพธ์ ความยืดหยุ่นของการเรียนรู้อยู่ที่ความหลากหลายในการออกแบบทางเลือกต่างๆ เช่น จำนวนชั้น เส้นเชื่อมโยง จำนวนของนิวรอน ค่าสัมประสิทธิ์การเรียนรู้ ค่าโมเมนตัม ที่เรากำหนดขึ้นและการแทนรูปแบบของข้อมูล ความยืดหยุ่นนี้ทำให้การเรียนรู้แบบย้อนกลับสามารถแก้ปัญหางานประยุกต์ได้อย่างมากมาย

2. ข้อจำกัด

คือการใช้เวลามากในการสอนนิเวรอลเน็ตเวิร์กให้เกิดการเรียนรู้ (Convergence Time) สำหรับการเรียนรู้การแก้ปัญหา สำหรับระบบงานจริงอาจมีชุดตัวอย่างถึง 1,000 ตัวอย่างและต้องใช้เวลาในการคำนวณเป็นวันหรือมากกว่านั้นเพื่อให้การสอนสมบูรณ์

จุดอ่อนอีกข้อหนึ่งของการเรียนรู้แบบย้อนกลับคือความล้มเหลวในการสอน นั่นคือเน็ตเวิร์กตกอยู่ที่จุดต่ำสุดท้องถิ่น โดยที่การเพิ่มชุดการสอนไม่สามารถปรับเน็ตเวิร์กได้ หรือก็คือเน็ตเวิร์กหยุดการเรียนรู้แล้ว แต่ข้อจำกัดนี้สามารถแก้ไขได้โดย ปรับค่า  $\eta$  และ  $\alpha$  เพิ่มจำนวนนิเวรอลในชั้นแอบแพ่ง หรือเพิ่มจำนวนชั้นแอบแพ่ง เปลี่ยนฟังก์ชันการแปลงค่า เปลี่ยนชุดการสอน หรือเปลี่ยนโครงสร้างของเน็ตเวิร์ก

ขั้นตอนการทำให้ระบบงานนิเวรอลเน็ตเวิร์กเกิดผล (Implementation) (Apicella และ Villars , 1993)



รูปที่ 2.13 ขั้นตอนการ implement ระบบงานนิเวรอลเน็ตเวิร์ก

### 1. ขั้นวินิจฉัย (Diagnostic Phase)

ปัญหาจะถูกวิเคราะห์เพื่อตัดสินใจว่านิรอลเน็ตเวิร์กจะเหมาะสมกับปัญหานั้นหรือไม่ ระบบงานบางอย่างก็เหมาะสมกับแนวทางของนิรอลเน็ตเวิร์ก ซึ่งส่วนใหญ่จะเป็นการแยกแยะรูปแบบ (Pattern Recognition) หรือ การแมพ (map) ทางสถิติ แต่ระบบงานบางอย่าง เช่น งานเงินเดือน หรืองานบัญชีก็ไม่เหมาะสม เพราะต้องการความถูกต้องเที่ยงตรง

เมื่อปัญหาถูกกำหนดจะมีการศึกษาเรื่องของข้อมูล และการแบ่งหมวดหมู่ของข้อมูล (เช่น การแบ่งกลุ่ม) สาเหตุสำคัญที่จะทำให้ระบบงานนิรอลเน็ตเวิร์กจะสำเร็จคือความเข้าใจถึงปัญหาเป็นอย่างดีและรู้ว่าข้อมูลใดที่เหมาะสม เพื่อช่วยให้ความเข้าใจดีขึ้น โมเดลการทำงานจะถูกสร้าง เพื่ออธิบายถึงความสัมพันธ์ระหว่างตัวแปรและระบุถึงตัวแปรอิสระ สิ่งที่จะได้รับในช่วงนี้คือ แผนงานในการสร้างต้นแบบของระบบ และตัวอย่างของข้อมูลที่จะใช้ในการสอนและทดสอบเน็ตเวิร์ก

### 2. ขั้นต้นแบบ (Prototype Phase)

ขั้นนี้จะมีการสร้างต้นแบบ แล้วนำไปสอนและทดสอบ ระหว่างการสร้างมีสิ่งที่จะต้องคำนึงถึงทางด้านเทคนิค ดังนี้

- วิธีการนำข้อมูลนำเข้าที่เหมาะสมกับเน็ตเวิร์ก
- การเลือกชุดข้อมูลการสอน และชุดข้อมูลทดสอบ
- ขนาดของนิรอลเน็ตเวิร์ก จำนวนชั้น และโทโพโลยี (Topology) ของ

เน็ตเวิร์ก

- เวลาในการสอนและทดสอบเน็ตเวิร์ก

เมื่อต้นแบบถูกพัฒนา, สอน, ทดสอบ, ดำเนินงานกับข้อมูลจริง และวิเคราะห์ผลลัพธ์ การคาดการณ์ความแม่นยำของเน็ตเวิร์ก ค่าใช้จ่ายและผลดีของการใช้จะถูกประเมิน เพื่อตัดสินใจว่าจะดำเนินงานต่อไปหรือไม่ สิ่งที่จะได้รับในขั้นนี้คือ ต้นแบบของงาน, การวิเคราะห์ค่าใช้จ่าย/ ผลดี และแผนการนำระบบไปใช้งาน

### 3. ขั้นนำไปใช้งาน (Implementation Phase)

จะเป็นขั้นการสร้าง ปรับปรุงระบบ และทดสอบต่อจากขั้นต้นแบบ ในขั้นนี้จะทำงานซ้ำหลายรอบ และเวลาที่ใช้จะไม่แน่นอนขึ้นกับระบบที่จะพัฒนา โปรแกรม

นิเวศเน็ตเวิร์กจะใช้เวลาในการติดตั้ง ทั้งการสอนเน็ตเวิร์กด้วยข้อมูลที่ซับซ้อนก็จะใช้เวลา หลังจากนั้นก็จะใช้เวลาอีกส่วนหนึ่งในการตรวจสอบผล

งานอื่นในขั้นนี้รวมถึงการสอนผู้ใช้, การจัดทำคู่มือการใช้งาน และคู่มือระบบ และการนำไปติดตั้งในสถานที่ใช้งาน สิ่งที่จะได้รับคือ นิเวศเน็ตเวิร์กที่สมบูรณ์ ติดตั้งเชื่อมกับระบบงานอื่นๆ และคู่มือการใช้งานของผู้ใช้

#### 4. ขั้นบำรุงรักษา (Maintenance Phase)

การทดสอบ, สอน และ แก้ไขปรับปรุงเน็ตเวิร์กจะดำเนินต่อ ตามคาบของเวลา บนพื้นฐานของกรณีใหม่ที่เกิดขึ้นของข้อมูล เพื่อให้แน่ใจว่าเน็ตเวิร์กยังคงทำงานได้อย่างมีประสิทธิภาพ

#### นิเวศเน็ตเวิร์กกับการพยากรณ์อนุกรมเวลา

Ginzberg และ Horn (1991) ได้ทำการทดลองชี้ให้เห็นว่าสามารถสอนนิเวศเน็ตเวิร์กให้เรียนรู้อนุกรมเวลา และสามารถใช้นิเวศเน็ตเวิร์กพยากรณ์ค่าถัดไปของอนุกรม โดยออกแบบนิเวศเน็ตเวิร์กให้มีชั้นนำเข้า 4 นิเวศ ชั้นแอบแฝง 6 นิเวศ และชั้นแสดงผลลัพธ์ 1 นิเวศ ด้วยการใช้ข้อมูลที่สร้างจากสมการ

$$y_n = 4y_{n-1}(1 - y_{n-1})$$

ทำการทดลองเปรียบเทียบการใช้ฟังก์ชันแปลงค่าระหว่างฟังก์ชันซิกมอยด์กับฟังก์ชันพีชคณิต ฟังก์ชันพีชคณิตนี้ประกอบด้วยนิเวศที่ใช้สมการเส้นตรง 2 นิเวศ นิเวศที่ใช้สมการควอดราติก (Quadratic) 2 นิเวศ และนิเวศที่ใช้สมการกำลังสามของผลรวมของค่าน้ำหนักคูณกับข้อมูลนำเข้าไปที่นิเวศนั้น 2 นิเวศ จากการทดลองปรากฏว่าผลที่ได้จากการใช้ฟังก์ชันพีชคณิตให้ผลดีมากกว่าการใช้ฟังก์ชันซิกมอยด์ในการพยากรณ์ระยะยาว นั่นคือแสดงว่านิเวศเน็ตเวิร์กสามารถค้นพบรูปแบบข้อมูล จากเกณฑ์ที่ว่าค่าความคลาดเคลื่อนจากชุดการสอนและชุดการทดสอบเข้าใกล้ศูนย์



Chan และ Prager (1991) ได้ทำการออกแบบนิเวรอลเน็ตเวิร์กให้เรียนรู้อนุกรมเวลาด้วยการใช้ข้อมูลที่สร้างจากสมการ

$$\text{Tent : } x_{n+1} = 2x_n, 0 < x_n < 0.5$$

$$x_{n+1} = 2(1-x_n), 0.5 < x_n < 1$$

$$\text{Henon : } x_{n+1} = 1 - ax_n^2 + y_n$$

$$y_{n+1} = bx_n$$

เมื่อ  $a = 1.4$  และ  $b = 0.3$  โดยทำการทดลองหาจำนวนนิเวรอลของชั้นข้อมูลนำเข้า และชั้นแอบแฝง ด้วยจำนวนนิเวรอลของชั้นแสดงผลลัพธ์ 1 นิเวรอล และใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันแปลงค่า ด้วยชุดการสอน 50 ชุด ผลการทดลองปรากฏว่านิเวรอลเน็ตเวิร์กสามารถค้นพบรูปแบบของสมการทั้ง 2 สมการ

Matsuba (1991) ทำระบบงานการพยากรณ์ราคาหุ้นในระยะยาวโดยใช้ 2 เนตเวิร์ก โดยเน็ตเวิร์กแรกจะต่อเชื่อมกันอย่างสมบูรณ์ (Fully Connected Network) และ เนตเวิร์กที่สองเป็นแบบฟีดแบกหลายชั้น (Feedback Multilayer) เชื่อมต่อกัน ซึ่งทั้ง 2 เนตเวิร์กใช้หลักการของการเรียนรู้แบบย้อนกลับ โดยข้อมูลนำเข้าของเน็ตเวิร์กที่สองจะมาจากผลลัพธ์ของเน็ตเวิร์กแรก โดยใช้จำนวนนิเวรอลของชั้นรับข้อมูล, ชั้นแอบแฝง และชั้นแสดงผลลัพธ์ เท่ากับ 20, 40 และ 10 ตามลำดับ

Refenes (1991) พัฒนาระบบพยากรณ์อัตราแลกเปลี่ยนเงินตราในระยะยาว โดยใช้การเรียนรู้แบบย้อนกลับ โดยในระหว่างการสอนถ้าเน็ตเวิร์กมีความผิดพลาดมากจะเพิ่มนิเวรอลใหม่เข้าไปในชั้นแอบแฝง แล้วจะทำการสอนเฉพาะนิเวรอลนั้นให้แก้ไขข้อผิดพลาดของผลลัพธ์ ข้อดีของวิธีนี้คือ เนตเวิร์กเรียนรู้ได้เร็วขึ้นเพราะสอนเฉพาะนิเวรอลใหม่เท่านั้น และแต่ละนิเวรอลจะแก้ปัญหาเฉพาะอย่าง วิธีนี้ไม่ต้องเดาขนาดของเน็ตเวิร์กเพราะจะสร้างเองอัตโนมัติ

Sriengar และ Looi (1991) ได้ทดลองลดเวลาในการสอนเน็ตเวิร์ก โดยใช้การเรียนรู้แบบย้อนกลับแบบ 2 ชั้นแอบแฝง ซึ่งชั้นแรกจะเชื่อมต่อบางส่วนกับชั้นข้อมูลนำเข้า และชั้นที่สองจะเชื่อมต่อกันอย่างทั่วถึง ในการพยากรณ์เวลาที่จะเกิดจุดดับในดวงอาทิตย์, ยอดขายของห้างสรรพสินค้า และดัชนีทางการเงิน

Miao และ Li (1991) ได้พัฒนานิวรอลเน็ตเวิร์กเพื่อแก้ปัญหาในการพยากรณ์แบบไม่เป็นเชิงเส้น (Nonlinear) ประกอบด้วย 2 เนตเวิร์ก โดยเน็ตเวิร์กแรกจะเรียนรู้พฤติกรรมของระบบ (Learning Network) และพยากรณ์โดยเน็ตเวิร์กที่สอง (Prediction Network) โดยคิดค่าพยากรณ์จากค่าน้ำหนักจากเน็ตเวิร์กแรก ทั้งสองได้พบว่าวิธีนี้สามารถใช้ได้ กับระบบที่มีตัวแปรที่ไม่ทราบ (Unknown Nonlinear) มากๆ

Weigend Rumelhart และ Huberman (1991) ได้ทดลองกำจัดค่าน้ำหนักที่ไม่จำเป็นของเน็ตเวิร์กในโมเดลการเรียนรู้แบบย้อนกลับเพื่อการพยากรณ์ผลตอบแทนจากอัตราการแลกเปลี่ยนเงิน โดยใช้ 45 หน่วยรับข้อมูลผลตอบแทนสำหรับเงินเยอรมัน 5 หน่วยรับข้อมูลสำหรับผลตอบแทนของเงินทุกสกุลเฉพาะข้อมูลวันจันทร์ และ 11 หน่วยรับข้อมูลสำหรับแนวโน้ม สำหรับชั้นแอมพลีมี 5 นิวรอลและใช้ซิกมอยด์ฟังก์ชันในการแปลงค่าและชั้นผลลัพธ์ใช้ 2 นิวรอล โดยนิวรอลแรกจะเป็นค่าพยากรณ์ข้อมูลวันรุ่งขึ้นและปรับข้อผิดพลาดแบบควอดราติก (Quadratic) ส่วนนิวรอลหลังเน้นที่การเปลี่ยนแปลง (บวก,ลบ) และใช้การปรับข้อผิดพลาดโดยซิกมอยด์ฟังก์ชัน