

## บทที่ 2

### แนวคิดและทฤษฎี

#### ประวัติและวิวัฒนาการของนิวรอลเน็ตเวิร์ก

นิวรอลเน็ตเวิร์กเป็นศาสตร์แขนงหนึ่งทางด้านคอมพิวเตอร์ที่ได้รับแรงบันดาลใจจากต้นแบบทางด้านชีววิทยา โดยพยายามเลียนแบบความสามารถของสมองมนุษย์ การศึกษาเริ่มกันอย่างจริงจังเมื่อปี ค.ศ.1950 โดยกลุ่มนักวิทยาศาสตร์แขนงต่าง ๆ เช่น นักฟิสิกส์ วิศวกร และนัก ชีววิทยา กลุ่มนักวิทยาศาสตร์ดังกล่าวข้างต้นได้เริ่มประยุกต์ใช้นิวรอลเน็ตเวิร์กเพื่อจะแก้ไขปัญหาการรู้จำต่าง ๆ อาทิเช่น การรู้จำอักขระ

ในปลายปี ค.ศ.1950 แฟรงค์ โรเซนเบรท (Frank Rosenblatt) แห่งมหาวิทยาลัยคอร์เนล (Cornell) ได้พัฒนาเพอร์เซปตรอน (Perceptron) ซึ่งเป็นระบบสมองประดิษฐ์ภายใต้ต้นแบบนิวรอลเน็ตเวิร์ก ระบบของเขามีขีดความสามารถที่จะเรียนรู้วิธีการรู้จำอักขระต่าง ๆ ซึ่งนับเป็นการพัฒนาอันสำคัญที่เป็นแรงผลักดันการค้นคว้าในด้านนี้เป็นอันมาก

ในปี ค.ศ.1969 มาร์วิน มินสกี (Marvin Minsky) ซึ่งเป็นผู้ก่อตั้งแขนงวิชาปัญญาประดิษฐ์ และเป็นผู้แต่งหนังสือชื่อ เพอร์เซปตรอน ในหนังสือเล่มดังกล่าวได้โต้แย้งแนวความคิดเกี่ยวกับ การใช้ซอฟต์แวร์เลียนแบบการทำงานของสมองมนุษย์ ซึ่งการโต้แย้งนี้มีอิทธิพลอย่างมาก ทำให้การพัฒนา นิวรอลเน็ตเวิร์กต้องหยุดชะงักมากกว่าทศวรรษ

ถึงแม้ว่าศาสตร์แขนงนี้เริ่มต้นมาตั้งแต่กลางปี ค.ศ.1950 แต่กลับไม่ได้รับการยอมรับในเชิงพาณิชย์มากนัก จนกระทั่งในกลางปี 1980 เทคโนโลยีทางด้านนิวรอลเน็ตเวิร์กได้ถูกพัฒนามาใช้ในเชิงพาณิชย์ ตัวอย่างเช่น การวิเคราะห์ความเสี่ยงในการลงทุนของสถาบันการเงินเอวีซีดี (AVCD Financial Services) การควบคุมขบวนการผลิตหลอดไฟฟ้าของจีทีอี (GTE) และตรวจค้นวัตถุระเบิดที่สนามบินนานาชาติจอห์นเอฟเคนเนดี (John F. Kennedy) ในกรุงนิวยอร์ก เป็นต้น

ปัจจัยที่มีส่วนผลักดันการพัฒนา นิวรอลเน็ตเวิร์ก ในเชิงพาณิชย์ ได้แก่ เครื่องคอมพิวเตอร์ส่วนบุคคลที่มีประสิทธิภาพสูงขึ้น การพัฒนาคอมพิวเตอร์ที่สามารถประมวลผลแบบขนาน และการพัฒนาทฤษฎีชื่อ เจนเนอรอลไรซ์เดลต้ารูล (Generalized Delta Rule) ซึ่งเป็นทฤษฎีที่กล่าวถึงขั้นตอนการเรียนรู้ ทฤษฎีดังกล่าวมีส่วนช่วยให้นิวรอลเน็ตเวิร์กสามารถแก้ปัญหาที่ซับซ้อนได้มากขึ้น

ปัจจัยหลักอีกอย่างหนึ่งคือ การเข้ามามีส่วนเกี่ยวข้องของหน่วยงานของรัฐบาลโดยเฉพาะอย่างยิ่ง กระทรวงกลาโหมของสหรัฐ โดยหน่วยงานที่ติดต่อกับกระทรวงกลาโหมกลุ่มหนึ่งได้ผลักดันแนวความคิดนิรอลเน็ตเวิร์กในเชิงพาณิชย์ขึ้น หน่วยงานดังกล่าวได้สร้างนิรอลเน็ตเวิร์กที่เป็นฮาร์ดแวร์สำหรับกระทรวงกลาโหม ในโครงการคาร์ปา DARPA (Defense Advanced Research Project Agency) และให้การสนับสนุนทางการเงินและผลักดันการพัฒนานิรอลเน็ตเวิร์ก

ไม่เพียงแต่รัฐบาลสหรัฐเท่านั้นที่ให้ความสนใจในศาสตร์แขนงนี้ รัฐบาลประเทศต่าง ๆ ทั่วโลกก็เล็งเห็นถึงความสำคัญ ไม่ว่าจะเป็ญีปุ่น หรือประเทศต่าง ๆ ในยุโรป

### การนำนิรอลเน็ตเวิร์กมาประยุกต์ใช้งาน

นิรอลเน็ตเวิร์กถูกนำไปใช้งานหลายประเภท เช่น การประมวลผลสัญญาณ (Signal Processing) การแพทย์ การวิเคราะห์เสียงพูด การจำแนกแบบอย่าง (Pattern Recognition) และการแปลภาษา (Language Translation) เป็นต้น

#### การประมวลผลสัญญาณ

ตัวอย่างงานประเภทนี้คือ ลคคคลื่นสัญญาณรบกวน บนสายโทรศัพท์ โดยใช้ขั้นตอนวิธีของ อาดาไลน์ (Adaline) ในการสอนให้แยกเสียงหรือสัญญาณรบกวนต่างๆออก เช่นเสียงสะท้อนออก เนื่องจาก Repeater Amplifiers ทำให้เกิดการสะท้อนของเสียง

#### การแพทย์

ตัวอย่างงานประเภทนี้ถูกพัฒนาโดย แอนเดอร์สัน (Anderson) ในกลางปี 1980 โดยใช้แนวคิดนิรอลเน็ตเวิร์กในการสอนให้ระบบเรียนรู้ จากการเก็บข้อมูลจำนวนมากและข้อมูลอื่นซึ่งประกอบด้วย อาการ (Symptoms) การวินิจฉัยโรค (Diagnosis) และการรักษา (Treatment) พบว่าหลังการสอนให้ระบบเรียนรู้แล้ว สามารถให้ระบบวินิจฉัยโรคและวิธีการรักษาที่เหมาะสมตามลักษณะอาการต่างๆได้

#### การวิเคราะห์เสียง

การสอนให้อ่านออกเสียง (Phonetic Pronunciation) ในภาษาอังกฤษเป็นเรื่องยาก เพราะการออกเสียงขึ้นกับตัวอักษรอื่นที่อยู่รอบๆ วิธีการเก่าที่ไม่ใช้นิรอลเน็ตเวิร์กในการแก้ปัญหาจะทำ

การสร้างชุดของกฎการออกเสียงเก็บไว้เพื่อใช้ค้นหาตามรูปแบบที่เก็บไว้ ทำให้ระบบไม่สามารถอ่านคำใหม่ๆได้

ตัวอย่างระบบที่สร้างขึ้นโดยใช้นิวรอลเน็ตเวิร์กในการแก้ปัญหาคือ NetTalk มีโครงสร้างเป็นข่ายงานหลายชั้น (Multi Layer Neural Network) โดยมีข้อมูลนำเข้าเป็นชุดของภาษาเขียนที่ประกอบด้วยตัวอักษรที่ถูกอ่านและตัวอักษรก่อนและหลัง และการออกเสียงที่ถูกต้อง หลังการสอนพบว่าระบบสามารถอ่านคำใหม่ได้โดยมีข้อผิดพลาดน้อยมาก

การจดจำคำพูด (Speech Recognition) เป็นงานอีกรูปแบบหนึ่งที่ซับซ้อนและมักถูกจำกัดเรื่อง ไวยากรณ์ (Grammar) และการประมวลศัพท์ (Vocabulary) ระบบส่วนใหญ่ที่นำนิวรอลเน็ตเวิร์กมาแก้ปัญหาประเภทนี้ จะมีโครงสร้างเป็นข่ายงานหลายชั้น และบางระบบใช้การติดต่อแบบย้อนกลับ (Recurrent Network)

ระบบหนึ่งถูกพัฒนาโดย โคโฮเนน (Kohonen) เขาสร้าง Phonetic Typewriter โดยให้ข้อมูลนำเข้าเป็นคำพูดในลักษณะคลื่นสัญญาณ ผลลัพธ์ที่ได้จะถูกส่งไปยังการแปลและสะกดคำได้ถูกต้อง

#### การแปลภาษา (Language Translation)

เนชันเนล เซกเคียวริตี้ เอเจนซี (National Security Agency) ได้พัฒนาระบบทิปสเตอร์ (Tipster) ซึ่งสามารถจะอ่านเอกสารภาษาญี่ปุ่นแล้วแปลเป็นภาษาอังกฤษ และจัดส่งเอกสารที่แปลแล้วไปยังเจ้าหน้าที่ที่เกี่ยวข้องเพื่อวิเคราะห์ต่อไป

#### การรู้จำแบบอย่าง

การรู้จำลายมือ (Handwritten Recognition) เป็นตัวอย่างงานประเภทหนึ่ง ที่จะทำการจดจำ และสามารถหาความแตกต่างของขนาดตัวอักษร ตำแหน่ง ช่องว่าง และรูปแบบการเขียน ทำให้การใช้เทคนิคเดิมใช้ไม่ได้เนื่องจากลายมือของแต่ละบุคคลจะแตกต่างกันไป

ตัวอย่างหนึ่งในการวิเคราะห์งานประเภทนี้จะใช้แบ็กพรอพเกชัน (Back Propagation) ซึ่งมีโครงสร้างแบบหลายชั้น แต่ละชั้นมีการติดต่อถึงกันแบบใดนั้นขึ้นกับการทดลองปรับปรุงรูปแบบ เพื่อให้การเรียนรู้รวดเร็วขึ้น

บริษัทซอฟต์แวร์จำนวนมากได้ผลิตซอฟต์แวร์ที่ประยุกต์ใช้นิวรอลเน็ตเวิร์ก ในการจำแนกอักขระจากลายมือของผู้ใช้

งานอีกประเภทหนึ่งที่ใช้ในวิวัฒนาการคือ การจับคู่รูปแบบ (Pattern Matching) โดยรูปแบบนี้ในการประมวลผลข้อมูลนำเข้าจะประกอบด้วยค่าเลขฐานสอง (Binary Digits) หรือค่าจำนวนจริง (Real Number) ที่ใช้แทน ค่าสัญญาณที่เป็นอนาลอก (Analog Signals)

ลักษณะการจับคู่รูปแบบจะมี 2 แบบ คือ ถ้าให้รูปแบบ A เป็นข้อมูลนำเข้า แล้วต้องการได้รูปแบบ A ออกมาเช่นกัน เราเรียกว่า Auto Association เช่น เมื่อเราพยายามระลึกถึงใบหน้าคนที่ไม่ได้พบมานานและให้ข้อมูลนี้ซึ่งอาจจะไม่ชัดเจนเข้าในระบบการเรียนรู้ และผลลัพธ์ที่ต้องการเป็นใบหน้าที่ชัดเจนขึ้น แต่ถ้าให้รูปแบบ A แต่ต้องการผลลัพธ์เป็นรูปแบบ B เราเรียกว่า Hetero Association เช่น ต้องการรู้ชื่อของคนที่มีหน้าตาแบบนี้ ก็จะให้ข้อมูลใบหน้าหน้าแก่ระบบ เพื่อต้องการผลลัพธ์เป็นชื่อบุคคลนั้น

### ระบบขับเคลื่อนรถยนต์อัตโนมัติ

ระบบ ALVINN (Autonomous Land Vehicle in Neural Network) เป็นต้นแบบระบบขับเคลื่อนรถยนต์ด้วยตนเอง ซึ่งพัฒนาโดยนักศึกษาและศาสตราจารย์ของมหาวิทยาลัยเคเนกัมเมลลอน (Carnegie-Mellon) ระบบ ALVINN จะได้รับข้อมูลป้อนเข้ามาเป็นสัญญาณจากกล้องถ่ายภาพวิดีโอ สัญญาณดังกล่าวจะถูกส่งเข้าสู่ระบบคอมพิวเตอร์ ซึ่งจะเปรียบเทียบภาพวิดีโอเป็นพื้น ๆ ภาพที่ระบบเรียนรู้ ไม่ว่าจะเป็น ต้นไม้, รถที่จอดอยู่ และทางเท้า ระบบ ALVINN จะเรียนรู้การขับเคลื่อนโดยการจับการขับเคลื่อนของมนุษย์เป็นเวลาประมาณ 5 นาที ALVINN จะเรียนรู้การหลีกเลี่ยงวัตถุต่างๆ

### การประยุกต์ใช้วิวัฒนาการในงานของสถาบันการเงิน

สถาบันการเงินต่างๆมีการประยุกต์ใช้วิวัฒนาการหลายด้านในด้านช่วยการตัดสินใจ ลดความเสี่ยงในการทุจริต และหนี้สูญ เช่น

การสอนระบบให้รู้จักรูปแบบการใช้บัตรเครดิตปลอม 1,000 รูปแบบ จากนั้นได้ทำการทดสอบพบว่า ระบบสามารถที่จะแยกแยะรายการที่ใช้บัตรเครดิตปลอมได้อย่างถูกต้อง แม้ว่ารูปแบบการใช้บัตรเครดิตปลอมจะเปลี่ยนแปลงไป

การพัฒนา ระบบ ADAM ซึ่งเป็นการประยุกต์เทคนิควิวัฒนาการผสมผสานกับระบบผู้เชี่ยวชาญ (Expert System) ใช้ในการประเมินความเสี่ยงในแง่คุณสมบัติของผู้กู้เบื้องต้น

การพัฒนา ระบบประเมินเงินกู้รายบุคคล โดยประยุกต์ใช้วิวัฒนาการทำการตรวจสอบปัจจัย 27 อย่าง เพื่อพิจารณาว่าจะอนุมัติเงินกู้หรือไม่ และประเมินอสังหาริมทรัพย์

การประเมินความเป็นไปได้ที่บริษัทที่เป็นลูกค้าจะล้มละลาย จากผลการทำงานพบว่าระบบดังกล่าวสามารถพยากรณ์บริษัทที่มีโอกาสล้มละลายได้ถูกต้องสูงถึง 99 เปอร์เซ็นต์ การพัฒนาระบบที่ปรึกษาในการซื้อขายหลักทรัพย์ หุ้นกู้ และอนุพันธ์ต่าง ๆ

#### การประยุกต์ใช้ในหน่วยงานของรัฐ

การพัฒนาระบบฮาร์ดแวร์ สำหรับการประยุกต์ใช้นิวรอลเน็ตเวิร์ก โครงการต่าง ๆ เท่าที่เปิดเผยในปัจจุบัน ได้แก่ ระบบนำทางของอาวุธ ระบบจำแนกเป้าหมายสำหรับเครื่องบินรบและเรือดำน้ำ

นอกจากนี้รัฐบาลสหรัฐยังประยุกต์ใช้นิวรอลเน็ตเวิร์ก ในแขนงอื่น ๆ เช่น การเข้ารหัสข่าวสารและข้อมูลต่าง ๆ, การสำรวจอากาศ และการตรวจจับทุจริต และการหลีกเลี่ยงการเสียภาษี

#### การประยุกต์นิวรอลเน็ตเวิร์กในด้านอื่น ๆ

การประยุกต์นิวรอลเน็ตเวิร์ก ได้ถูกพัฒนาให้สามารถใช้งานในด้านอื่น ๆ อาทิเช่น การแต่งเพลง, การพยากรณ์ผลการแข่งขันกีฬา, การพยากรณ์อากาศ และการตรวจสอบบัตรโทรศัพท์ปลอม และวิทยาการด้านหุ่นยนต์

#### นิวรอลเน็ตเวิร์กทางชีววิทยา

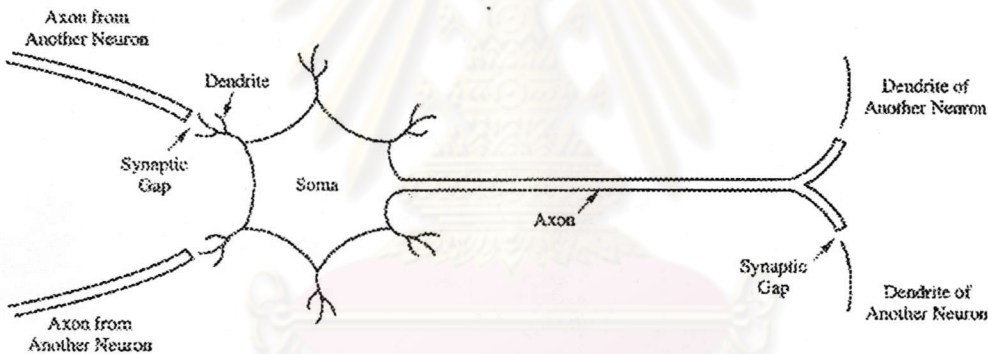
ในทางชีววิทยา นิวรอนมี 3 ประเภท คือ เดนไดรท์ (Dendrites), โซมา (Soma), แอคซอน (Axon) หลายๆ เดนไดรท์ จะได้รับสัญญาณจากนิวรอนอื่น สัญญาณนี้เป็นการกระตุ้นทางไฟฟ้าที่ถูกส่งข้ามช่องว่างระหว่างไซแนปส์ (Synapses) ด้วยค่าเฉลี่ยตามขั้นตอนทางเคมี การทำงานทางเคมีจะปรับปรุงสัญญาณที่รับเข้ามาด้วยการวัดความถี่ของสัญญาณที่ได้รับ ซึ่งคล้ายกับการทำงานของค่าน้ำหนักในนิวรอลเน็ตเวิร์กเทียม

โซมา หรือ ตัวเซลล์ (Cell Body) จะรวบรวมสัญญาณที่ส่งเข้ามา เมื่อรับสัญญาณเข้ามามากพอที่จะส่งผ่านแอคซอนไปยังเซลล์อื่น ความถี่ของการส่งสัญญาณจะแตกต่างกันไป และอาจจะมองในลักษณะของสัญญาณที่มากกว่าหรือน้อยกว่าค่าหนึ่ง

#### ความหมายของนิวรอลเน็ตเวิร์ก

นิวรอลเน็ตเวิร์ก หรือ ที่เรียกว่า นิวรอลเน็ตเวิร์กเทียม ( Artificial Neural Network ) เป็นระบบประมวลผลที่เลียนแบบลักษณะทั่วไปทางชีววิทยาของระบบสมอง นิวรอลเน็ตเวิร์กเทียมถูกพัฒนาขึ้นตามรูปแบบทางคณิตศาสตร์ของการจดจำของมนุษย์ โดยมีสมมุติฐานว่า

1. การประมวลผลข้อมูลต่างๆเกิดที่ส่วนประกอบเล็กๆจำนวนมากที่เรียกว่านิวรอน (Neuron)
2. การส่งสัญญาณ ( Signal ) ต่างๆระหว่างนิวรอนใช้ส่วนที่เชื่อมต่อระหว่างนิวรอนที่เรียกว่า คอนเนกชัน ลิงค์ (Connection Link)
3. แต่ละการเชื่อมต่อดังกล่าวนั้นจะมีค่าน้ำหนักที่ต่างกัน เพื่อบอกว่า นิวรอนได้รับอิทธิพลลักษณะใดจากนิวรอนอื่น
4. แต่ละนิวรอนจะได้รับข้อมูลจากนิวรอนอื่น โดยการผ่านแอกติเวชันฟังก์ชัน (Activation Function )



รูปที่ 2.1 แสดงนิวรอนในทางชีววิทยา

### การแบ่งประเภทของนิวรอลเน็ตเวิร์ก

นิวรอลเน็ตเวิร์กเทียมได้ถูกพัฒนารูปแบบต่างๆมากมาย ซึ่งจะสามารถแบ่งรูปแบบนิวรอลเน็ตเวิร์ก ตามลักษณะสำคัญ 3 ประการคือ

1. รูปแบบของสถาปัตยกรรมการเชื่อมต่อระหว่างนิวรอน
2. วิธีการหาค่าค้ำน้ำหนักของการเชื่อมต่อกัน
3. แอกติเวชันฟังก์ชันที่ใช้

นิเวรอลเน็ตเวิร์กประกอบด้วยกลุ่มของหน่วยประมวลผล (Processing Element) ที่เรียกกันหลายอย่างว่า นิเวรอน หรือหน่วย (Unit) หรือเซลล์ (Cell) หรือโหนด (Node) แต่ละนิเวรอนเชื่อมต่อด้วยค่าน้ำหนัก และค่าน้ำหนักชุดนั้นเป็นตัวแสดงถึงความรู้ที่จะนำไปใช้แก้ปัญหาในหลายๆรูปแบบซึ่งจะกล่าวต่อไป

ลักษณะของหน่วยประมวลผลย่อยของนิเวรอลเน็ตเวิร์กเทียม อาจอธิบายได้ตามคุณสมบัติทางชีววิทยาของนิเวรอนได้ดังนี้คือ หน่วยประมวลผลย่อยจะได้รับสัญญาณจากภายนอกมากมาย แต่ละสัญญาณจะถูกปรับปรุงด้วยค่าน้ำหนักที่ได้รับจากหน่วยประมวลผลย่อยอื่นๆ และทำการรวบรวมสัญญาณ เมื่อสภาพแวดล้อมเหมาะสมก็จะส่งสัญญาณไปยังหน่วยประมวลผลย่อยอื่นๆ ถัดไป

ชั้น (Layer) ในนิเวรอลเน็ตเวิร์กเทียม คือกลุ่มของหน่วยประมวลผลย่อยกลุ่มหนึ่ง ที่ทำการคำนวณแล้วส่งผลลัพธ์ไปยังชั้นถัดไป จนกระทั่งถึงชั้นสุดท้ายซึ่งอาจมีเพียงหนึ่งหน่วยประมวลผลหรือมากกว่าจะเป็นผลลัพธ์ของเน็ตเวิร์ก เราเรียกชั้นแรกนี้เป็นชั้นนำข้อมูลเข้า (Input Layer) และชั้นสุดท้ายเป็นชั้นผลลัพธ์ (Output Layer) และชั้นระหว่างชั้นแรกและชั้นสุดท้าย คือ ชั้นแอบแฝง (Hidden Layer) ซึ่งชั้นแอบแฝงนี้อาจมีมากกว่า 1 ชั้นขึ้นไปก็ได้

ลักษณะที่สำคัญและเหมือนกันอย่างหนึ่งระหว่างนิเวรอลเน็ตเวิร์กทางชีววิทยาและนิเวรอลเน็ตเวิร์กเทียมคือ (Fault Tolerance) ซึ่งนิเวรอลเน็ตเวิร์กทางชีววิทยาจะมีลักษณะ 2 แบบดังนี้คือ

1. สามารถจดจำ สัญญาณนำเข้า (Input Signal) ต่างๆ ที่แตกต่างจากที่เคยเจอมาก่อน เช่น จดจำบุคคลที่ไม่ได้พบมานาน
2. สามารถเรียนรู้ต่อไปในขณะที่มีบางเซลล์ตายไป เพราะสมองประกอบด้วยนิเวรอนมากกว่าพันล้านเซลล์ แม้บางเซลล์ตายไปก็จะมีเซลล์อื่นที่จะถูกสอนขึ้นมาทำหน้าที่แทน

#### สถาปัตยกรรม (Architecture)

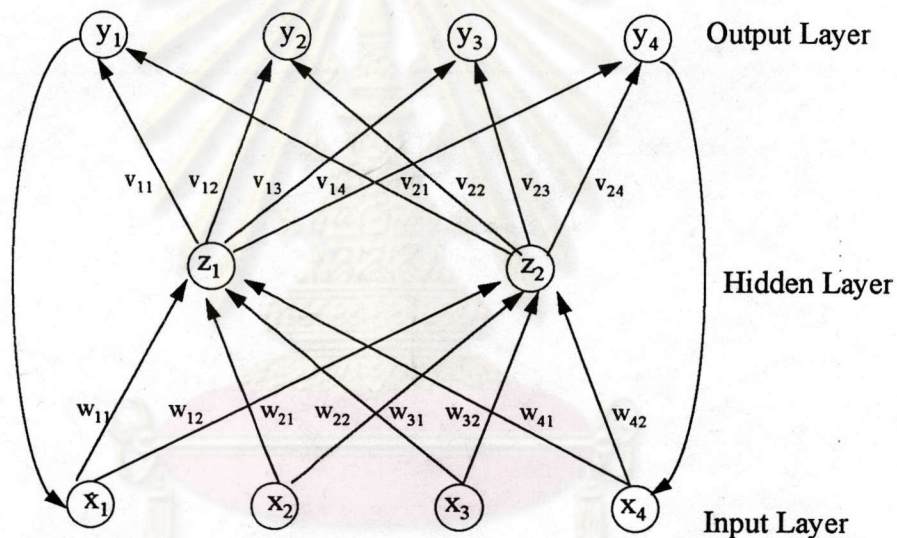
สามารถแบ่งประเภทนิเวรอลเน็ตเวิร์กตามจำนวนชั้นของข่ายงานแบบกว้างๆ ได้ 2 แบบคือ ข่ายงานชั้นเดียว (Single Layer) และ ข่ายงานหลายชั้น (Multi-Layer Network)

ในบางเอกสารกล่าวว่าข่ายงาน 2 ชั้น เป็นประเภทที่ไม่มีชั้นแอบแฝง คือจะมีชั้นนำเข้าข้อมูลและชั้นผลลัพธ์เท่านั้น แต่ในบางเอกสารไม่นับชั้นนำเข้าข้อมูลเนื่องจากที่ชั้นนี้จะไม่มีการประมวลผล จะนับเฉพาะชั้นที่มีการประมวลผลเท่านั้น ดังนั้นถ้าเป็นข่ายงานสองชั้นจะมี 1 ชั้นแอบแฝง

หรือการนับจำนวนชั้นจะนับจำนวนชั้นของค่าน้ำหนักที่เชื่อมต่อระหว่างนิวรอนเท่านั้น ในกรณีที่ จะกล่าวถึงชั้นของข่ายงานแบบไม่นับชั้นนำเข้าข้อมูล

รูปแบบส่วนใหญ่ของงานที่พัฒนาขึ้นจากนิวรอลเน็ตเวิร์กจะเป็นข่ายงาน 2 ชั้น และมีเพียง เล็กน้อยเท่านั้นที่เป็นข่ายงาน 1 ชั้น และยังมีบ้างกรณีที่เป็นข่ายงาน 3 ชั้นหรือมากกว่า

ทุก ๆ ข่ายงานจะมีชั้นของข้อมูลนำเข้า และส่วนใหญ่จะส่งข้อมูลนำเข้านี้ไปยังชั้นถัดไปโดย ไม่มีการคำนวณ แต่มีข่ายงานบางแบบจะมีกระบวนการติดต่อแบบย้อนกลับ (Recurrent Connections) เช่น ข่ายงานติดต่อย้อนกลับ (Recurrent Network) ตามรูป 2.2 ทำให้ชั้นนำข้อมูล เข้าจะต้องทำการประมวลผลด้วย



รูปที่ 2.2 แสดงการติดต่อย้อนกลับของข่ายงานติดต่อย้อนกลับ


### ข่ายงานชั้นเดียว

นิวรอลเน็ตเวิร์กที่เป็นแบบข่ายงานชั้นเดียว จะมีการรับสัญญาณเข้า และประมวลผลที่ชั้นนั้น รวมทั้งการหาผลลัพธ์ก็ทำที่ชั้นนั้นด้วย ข่ายงานรูปแบบนี้ จะมีความสามารถด้านการติดตั้งวงจร ไอซี (Integrated Circuit Implement) หรือการควบคุมแนวทางประกอบชิ้นส่วน (Assembly Line Control) และที่ใช้กันทั่วไป คือ การจดจำรูปแบบ (Pattern Recognition)

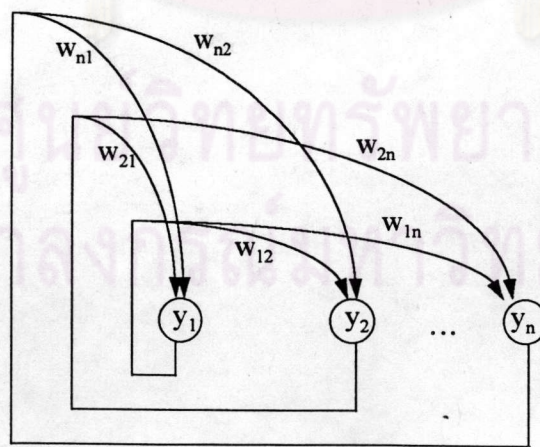
ตัวอย่างของข่ายงานชั้นเดียว คือ เพอเซปตรอนแบบง่าย (Simple Perceptron) และ ฮอปฟิลด์ เนตเวิร์ก (Hopfield Network)



เพอเซปตรอนแบบง่าย จะมีติดต่อกันระหว่างนิวรอนคนละชั้นกัน ชั้นนำข้อมูลเข้าเก็บ นิวรอนที่เป็นข้อมูลนำเข้า ชั้นถัดไปเก็บนิวรอนที่เป็นข้อมูลผลลัพธ์ จะไม่มีการเชื่อมติดกัน ระหว่างนิวรอนในชั้นเดียวกัน ตามรูป 2.3 แต่ฮอปฟิวเน็ตเวิร์กแล้ว ทุก ๆ นิวรอนในชั้นเดียวกัน จะเชื่อมติดต่อซึ่งกันและกัน ตามรูป 2.4



รูปที่ 2.3 แสดงตัวอย่างเพอเซปตรอนอย่างง่าย




รูปที่ 2.4 แสดงตัวอย่างฮอปฟิวเน็ตเวิร์ก

### ข่ายงานหลายชั้น

เป็นข่ายงานที่มีชั้นแอบแฝง ตั้งแต่ 1 ชั้นขึ้นไป ในกรณีของข่ายงานชั้นเดียวสามารถแก้ปัญหาต่างๆได้ แต่กรณีปัญหาที่ซับซ้อนจะไม่สามารถแก้ปัญหาด้วยข่ายงานชั้นเดียวได้ การแก้ปัญหานี้ต้องใช้ข่ายงานสองชั้นเป็นอย่างน้อย เช่น งานประเภทจดจำลายมือ มีความจำเป็นต้องใช้ข่ายงานแบบหลายชั้น

ตัวอย่างของข่ายงานสองชั้น คือ เบ็กพรอพเพกชันอย่างง่าย ( Simple Backpropagation) ตามรูป 2.5 และ บอลทซแมน แมชชีน ( Boltzman Machine) ตามรูป 2.6 เป็นต้น



รูปที่ 2.5 แสดงตัวอย่างโครงสร้างของเบ็กพรอพเพกชัน

### รูปแบบการเรียนรู้ (Learning) ของนิรอลเน็ตเวิร์ก


การเรียนรู้ของนิรอลเน็ตเวิร์ก เป็นการวิธีการกำหนดหรือหาค่าน้ำหนัก ดังนั้นวิธีการสอนให้ระบบเรียนรู้จะเป็นส่วนสำคัญในการแยกความแตกต่างระหว่างรูปแบบของนิรอลเน็ตเวิร์กได้ การวิธีการสอนให้ระบบเรียนรู้อาจแบ่งได้ 2 รูปแบบ คือ การเรียนรู้แบบมีครู (Supervised Learning) และ การเรียนรู้แบบไม่มีครู (Unsupervised Learning)

### การเรียนรู้แบบมีครู

การเรียนรู้จะต้องประกอบด้วย ชุดข้อมูลนำเข้าที่ใช้สอนกับผลลัพธ์ที่ต้องการ และค่าน้ำหนักที่ต้องการจะถูกปรับปรุงตามขั้นตอนวิธีการเรียนรู้ ( Learning Algorithm ) โดยกำหนดว่าการเรียนรู้จะสำเร็จได้ต้องมีการเปรียบเทียบผลลัพธ์จากการคำนวณกับค่าคำตอบที่ให้มา แล้วนำค่าความผิดพลาด (error) มาปรับปรุงค่าน้ำหนัก แล้วเข้ามาคำนวณใหม่จนได้ค่าน้ำหนักที่ดีที่สุด

### การเรียนรู้แบบไม่มีครู

เป็นการเรียนรู้แบบอิสระหรือเรียกว่าสามารถจัดการตัวเองได้ ( Self Organizing) เพียงระบุรูปแบบข้อมูลนำเข้าโดยไม่ต้องระบุเป้าหมายผลลัพธ์ที่ต้องการ ขอเพียงมีข้อมูลที่เหมาะสมที่จะหาคุณสมบัติของชุดข้อมูลนั้นได้ แล้วการเรียนรู้จะส่งคุณสมบัตินั้นไปยังผลลัพธ์ การหาคุณสมบัติเหล่านั้นช่างงานจะต้องเรียนรู้ที่จะจดจำตามรูปแบบ และวิธีการเรียนรู้ (Learning Method) ต่างๆ เอง



รูปที่ 2.6 แสดงตัวอย่างโครงสร้างของบอททแมนแมชชีน ในการแก้ปัญหา ENCODER

นอกจากการเรียนรู้ 2 แบบดังกล่าวแล้ว เพื่อให้เข้าใจถึงตัวอย่างต่างๆของนิเวศเน็ตเวิร์กที่จะกล่าวถึงต่อไปแล้ว คงต้องกล่าวถึงลักษณะการติดต่อระหว่างนิเวศในชั้นต่างๆ 2 ประการคือ

ลักษณะการติดต่อย้อนกลับ (Feedback) และ ลักษณะการติดต่อไปข้างหน้า (Feed-Forward)

### ลักษณะการติดต่อย้อนกลับ

โครงสร้างสมองมนุษย์มีลักษณะเป็นชั้น และส่วนใหญ่แต่ไม่ทั้งหมดจะมีลักษณะการติดต่อไปยังชั้นถัดไป ตัวอย่างหนึ่งของข่ายงานที่มีการติดต่อกลับมายังชั้นก่อนหน้าคือ ข่ายงานติดต่อย้อนกลับ เช่น บอลซแมน แมชชีน (Boltzmann Machine) ตามรูป 2.6

### ลักษณะการติดต่อไปข้างหน้า

แต่ละนิวรอนจะติดต่อไปยังนิวรอนอื่น ๆ ในชั้นถัดไปเท่านั้น หรือเป็นลักษณะติดต่อกันในทิศทางเดียว เช่น ข่ายงานเพอเซปตรอน และข่ายงานแบ็กพรอปเพกชัน ตามรูป 2.3 และ 2.5

จากรูปแบบทั้งสองนี้ ปัจจุบันได้มีการพัฒนาทฤษฎีและวิธีการเรียนรู้แบบใหม่ขึ้นอีกมากมาย และยังคงพัฒนาต่อไป จึงมักเกิดรูปแบบใหม่เสมอ แต่ละวิธีจะมีรูปแบบและวิธีการเรียนรู้ต่างกันออกไป ต่อไปนี้เป็นตัวอย่างกลุ่มหนึ่งเท่านั้น ของงานที่พัฒนาจากพื้นฐานของนิวรอลเน็ตเวิร์ก

## 1. การเรียนรู้แบบไม่มีครู (Unsupervised Learning)

### 1.1. แบบมีการติดต่อย้อนกลับ (Feedback Nets)

1.1.1. แอดดิทีฟ กรอสเบิร์ก Additive Grossberg (AG)

1.1.2. ชันทิง กรอสเบิร์ก Shunting Grossberg (SG)

1.1.3. ไบนารี อะแดปทีฟ เรโซแนนซ์ Binary Adaptive Resonance Theory (ART1)

1.1.4. อานาลอก อะแดปทีฟ เรโซแนนซ์ Analog Adaptive Resonance Theory (ART2)

1.1.5. ดิสครีท ฮอปฟีลด์ Discrete Hopfield (DH)

1.1.6. คอนตินิวอัส ฮอปฟีลด์ Continuous Hopfield (CH)

1.1.7. ดิสครีท ไบไดเรกชัน แอสโซซิเอทีฟ เมมโมรี Discrete Bidirectional Associative Memory (BAM)

1.1.8. เทมโพรอล แอสโซซิเอทีฟ เมมโมรี Temporal Associative Memory (TAM)

1.1.9. อะแดปทีฟ ไบไดเรกชัน แอสโซซิเอทีฟ เมมโมรี Adaptive Bidirectional Associative Memory (ABAM)

1.1.10. โคโฮเนน เซลล่อแกนไนซ์ซิง แมป โทโพโลยี ฟรีเซฟ แมป Kohonen Self-organizing Map/Topology-preserving map (SOM/TPM)

1.1.11. คอมเพทิทีฟ เลินนิง Competitive learning

1.2. แบบการติดต่อไปข้างหน้า (Feedforward-only Nets)

1.2.1. เลินนิง แมททริก Learning Matrix (LM)

1.2.2. ไครฟเวอร์ รีอินโฟสเมนต์ เลินนิง Driver-Reinforcement Learning (DR)

1.2.3. ลิเนียร์ แอสโซซิเอทีฟ เมมโมรี Linear Associative Memory (LAM)

1.2.4. ออปติไมซ์ ลิเนียร์ แอสโซซิเอทีฟ เมมโมรี Optimal Linear Associative Memory (OLAM)

1.2.5. สปาส คิสติบิว แอสโซซิเอทีฟ เมมโมรี Sparse Distributed Associative Memory (SDM)

1.2.6. ฟัสซี แอสโซซิเอทีฟ เมมโมรี Fuzzy Associative Memory (FAM)

1.2.7. เคาเตอร์โพรเกชัน Counterpropagation (CPN)

2. การเรียนรู้แบบมีครู (Supervised Learning)

2.1. แบบมีการติดต่อย้อนกลับ (Feedback Nets)

2.1.1. เบรน สเตท อิน อะ บอกซ์ Brain-State-in-a-Box (BSB)

2.1.2. ฟัสซี คอนจิทีฟ แมป Fuzzy Congitive Map (FCM)

2.1.3. บอลทซแมน แมชชีน Boltzmann Machine (BM)

2.1.4. มิน ฟิลด์ แอนนีลลิ่ง Mean Field Annealing (MFT)

2.1.5. รีเคอร์เรนท์ แคสเคด คอร์รีเลชัน Recurrent Cascade Correlation (RCC)

2.1.6. แบ็กพรอเพเกชัน ทู ทาม Backpropagation through time (BPTT)

2.1.7. เรียลทาม รีเคอร์เรนท์ เลินนิง Real-time recurrent learning (RTRL)

2.1.8. รีเคอร์เรนท์ เอกซเทนท์ คาลแมน ฟิลเตอร์ Recurrent Extended Kalman Filter (EKF)

2.2. แบบการติดต่อไปข้างหน้า (Feedforward-only Nets)

2.2.1. เพอร์เซปตรอน Perceptron

2.2.2. อาดาลีน แมดาลีน Adaline, Madaline

2.2.3. แบ็กพรอเพเกชัน Backpropagation (BP)

2.2.4. คอรัชี แมชชีน Cauchy Machine (CM)

2.2.5. อะแดปทีฟ ฮิวลิสติก คริติก Adaptive Heuristic Critic (AHC)

- 2.2.6. ทาม ดีเลย์ นิวรอล เนตเวิร์ก Time Delay Neural Network (TDNN)
- 2.2.7. แอสโซซิเอทีฟ รีวาร์ด พินอลตี Associative Reward Penalty (ARP)
- 2.2.8. อวาแลนซ์ แมชท์ ฟิวเตอร์ Avalanche Matched Filter (AMF)
- 2.2.9. แบคเพอร์โคเลชัน Backpercolation (Perc)
- 2.2.10. อาร์ทแมป Artmap
- 2.2.11. อะแดปทีฟ โลจิก เนตเวิร์ก Adaptive Logic Network (ALN)
- 2.2.12. แคสเคด คอรัลเลชัน Cascade Correlation (CasCor)
- 2.2.13. เอกซเทนส์ คาลแมน ฟิวเตอร์ Extended Kalman Filter(EKF)
- 2.2.14. เลินนิง เวกเตอร์ ควอนติเซชัน Learning Vector Quantization (LVQ)
- 2.2.15. พรอบเบบิลิสติก นิวรอล เนตเวิร์ก Probabilistic Neural Network (PNN)
- 2.2.16. เจนเนอรัล รีเกรสชัน นิวรอล เนตเวิร์ก General Regression Neural Network (GRNN)

### ขั้นตอนวิธีของการเรียนรู้ (Learning Algorithm)

การกำหนดวิธีการเรียนรู้ อาจกล่าวได้เป็น 2 ส่วนคือ

1. การกำหนดแอกติเวชันฟังก์ชัน (Activation Function) เพื่อจะจัดขอบเขตข้อมูลผลลัพธ์ก่อนส่งไปให้นิวรอนอื่น
2. การกำหนดวิธีการปรับปรุณค่าน้ำหนัก

#### 1. แอกติเวชันฟังก์ชัน

ลักษณะสำคัญที่ใช้กำหนดวิธีการประมวลผลคือ แอกติเวชันฟังก์ชัน และรูปแบบการติดต่อระหว่างนิวรอนที่ทำการรับส่งสัญญาณต่างๆ ปกติในแต่ละชั้น (Layer) มักจะใช้แอกติเวชันฟังก์ชันเดียวกัน และรูปแบบการติดต่อระหว่างนิวรอนก็เป็นรูปแบบเดียวกัน เช่น ในหลายๆ ประเภทของนิวรอลเน็ตเวิร์กจะมีลักษณะการติดต่อระหว่างนิวรอนแบบถึงกันหมด ( Fully Connected)

แอกติเวชันฟังก์ชัน เป็นหลักการทำงานพื้นฐานของนิวรอลเน็ตเวิร์ก ที่เกี่ยวกับการรวบรวมค่าน้ำหนักและข้อมูลนำเข้าต่างๆ แล้วทำการปรับปรุณเพื่อส่งออกไปให้กับนิวรอนอื่น

ผลลัพธ์ของทุกนิวรอนก่อนที่จะส่งไปยังนิวรอนถัดไป จะผ่านฟังก์ชันนี้และจะทำหน้าที่ลดขนาดของผลลัพธ์ เพื่อให้ผลลัพธ์มีความหมายสำหรับปัญหา

ฟังก์ชันที่ใช้กันบ่อย คือ ฟังก์ชันซิกมอยด์ (Sigmoid Function) ฟังก์ชันขั้นบันได (Step Function) , ฟังก์ชันลาดเอียง (Ramp Function) และ ฟังก์ชันเส้นตรง (Linear Function)

### 1.1. ฟังก์ชันซิกมอยด์

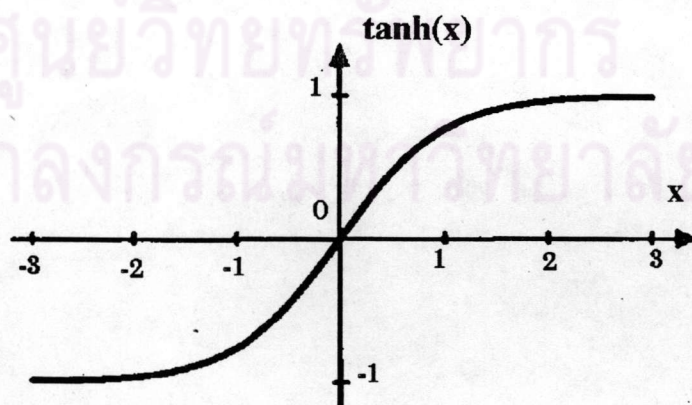
จะทำให้ผลลัพธ์จากแอกติเวชันมีค่าระหว่าง  $[0,1]$  จะเห็นว่าจะมีมากกว่า 1 ฟังก์ชันที่ใช้ชื่อซิกมอยด์เช่นกัน ฟังก์ชันเหล่านี้จะแตกต่างกันที่สูตรและขนาดของช่วง และทุกฟังก์ชันจะสามารถสร้างกราฟที่มีหน้าตาคล้ายตัว S เช่น ฟังก์ชันไฮเพอร์บอริกแทนเจนต์ (Hyperbolic Tangent Function) และ ฟังก์ชันโลจิสติก (Logistic Function)

กรณี ฟังก์ชันไฮเพอร์บอริกแทนเจนต์ จะมีสูตรตาม (1) จะทำให้ค่าผลลัพธ์มีค่าอยู่ในช่วง  $-1$  และ  $1$  สามารถสร้างกราฟได้ตามรูป 2.7


$$F(x) = \tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad \dots(1)$$

กรณี ฟังก์ชันโลจิสติก จะมีสูตรตาม (2) จะทำให้ค่าผลลัพธ์มีค่าอยู่ในช่วง  $0$  และ  $1$  โดยจะสามารถสร้างกราฟได้ตามรูป 2.8

$$F(x) = 1 / (1 + e^{-x}) \quad \dots(2)$$



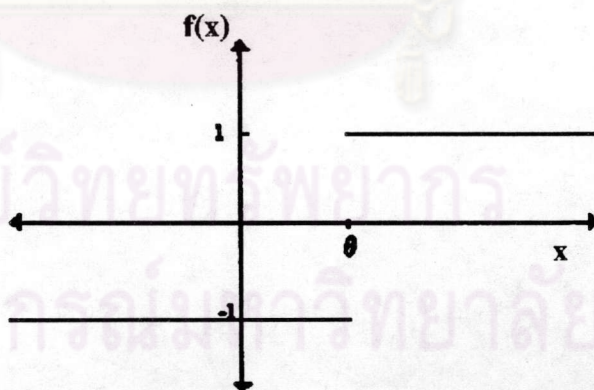
รูปที่ 2.7 แสดงฟังก์ชันไฮเพอร์บอริกแทนเจนต์



รูปที่ 2.8 แสดงฟังก์ชันโลจิสติก

### 1.2. ฟังก์ชันขั้นบันได

เป็นฟังก์ชันที่ใช้กันบ่อย มีลักษณะคล้ายขั้นบันได มีค่าเริ่มต้นที่ 0 และมีค่าเป็น 0 เมื่อฟังก์ชันนั้นอยู่ทางซ้ายของค่าขีดแบ่ง ( $\theta$ ) และจะกระโดดเป็น 1 เมื่ออยู่ทางขวาของค่าขีดแบ่งและมีค่าเป็น 1 ต่อไปถ้ายังอยู่ทางขวา นอกจาก 0 และ 1 แล้วยังสามารถใช้ค่าอื่นที่จะเป็นช่วงของฟังก์ชันได้ ตามรูป 2.9




รูปที่ 2.9 แสดงฟังก์ชันขั้นบันได

### 1.3. ฟังก์ชันลาดเอียง



จากฟังก์ชันขั้นบันไดที่ค่ากระโดดจาก 0 เป็น 1 ได้เลย ก็เปลี่ยนรูปแบบเป็นเส้นตรงคล้ายทางลาดแทน ดังนั้นค่าเปลี่ยนจาก 0 เป็น 1 จะได้กราฟดังรูป 2.10



รูปที่ 2.10 แสดงฟังก์ชันลาดเอียง

#### 1.4. ฟังก์ชันเส้นตรง

จะมีรูปแบบดังนี้

$$F(x) = \alpha x + \beta$$

ถ้า  $\alpha$  เป็น 1 แล้ว ฟังก์ชันชนิดแบ่งนี้มีค่าเป็นการเพิ่มค่าความเบี่ยงเบน( $\beta$ ) เท่านั้น

#### 2. การปรับปรุงค่าน้ำหนัก

เมื่อนิวรอลเน็ตเวิร์กถูกพัฒนาขึ้นในรูปแบบของการเรียนรู้แบบมีครู จะต้องกำหนดขั้นตอนการเรียนรู้ที่เหมาะสม ซึ่งขึ้นกับทฤษฎีของรูปแบบในการแก้ไขปัญหาต่างๆ สมการเริ่มต้นในการปรับปรุงค่าน้ำหนักจะเป็นการหาค่าอนุพันธ์ หลังจากปรับปรุงสมการอนุพันธ์ให้ง่ายขึ้นโดยการกำหนดค่าเริ่มต้นให้กับตัวแปรที่เหมาะสม จะทำให้สมการที่ซับซ้อนกลายเป็นเพียงสมการพีชคณิตเพื่อให้ง่ายและคำนวณได้รวดเร็ว

กฎการเรียนรู้ที่สำคัญมี 2 รูปแบบ คือ การเรียนรู้ของเฮบเบียน (Hebbian learning) และการเรียนรู้ของเดลต้า (Delta learning) นอกจาก 2 รูปแบบนี้แล้ว จะมีกฎการเรียนรู้อื่น ๆ ที่ปรับปรุงจากพื้นฐานของ 2 กฎนี้

### 2.1. กฎของเฮบ (Hebb's Rule)

โดยโดนัลด์ เฮบ (Donald Hebb) เป็นกฎที่เกี่ยวกับการวัดค่าแอกติเวชัน (ค่าผลรวมของการคูณระหว่างค่าข้อมูลนำเข้ากับค่าน้ำหนักที่เป็นคู่กัน) ของนิวรอนแรกที่จะมีผลต่อค่าแอกติเวชันของนิวรอนที่สอง จึงได้สูตรที่ใช้ปรับปรุ้ค่าน้ำหนัก ดังนี้

$$\Delta w_{ij} = \mu a_i a_j$$

$\mu$  เป็นอัตราการเรียนรู้ (learning rate)

$a_i$  เป็นค่าแอกติเวชัน ของนิวรอนที่ I

$a_j$  เป็นค่าแอกติเวชัน ของนิวรอนที่ j

### 2.2. กฎของเดลต้า Delta Rule

หรือเรียกอีกอย่างหนึ่งว่า Least Mean Squared Error Rule (LMS) โดยมีจุดหมายว่าจะหาชุดของค่าน้ำหนักที่ทำให้ค่ากำลังสองของค่าความผิดพลาด (mean squared error) มีค่าน้อยที่สุด ซึ่งจำเป็นสำหรับการสอนรอบถัดไป โดย วิดรอพ และ ฮอฟ (Widrow and Hoff) โดยใช้วิธีการคำนวณเพื่อปรับปรุ้ค่าน้ำหนักดังนี้

$$\Delta w_{ij} = 2\mu x_i (\text{desired output value} - \text{computed output value})_j$$

$\mu$  คือ อัตราการเรียนรู้ ซึ่งมีค่าน้อยกว่า 1 แต่ไม่เป็นค่าลบ

$x_i$  คือ นิวรอนลำดับที่ i