


บทที่ 2

โครงข่ายเซลล์ประสาทมนุษย์ และ โครงข่ายประสาทเทียม

2.1 โครงข่ายเซลล์ประสาทมนุษย์

แบบจำลองโครงสร้างพื้นฐานของนิวรอน หรือเซลล์สมองของมนุษย์ ในรูปของวงจรเชิงอิเล็กทรอนิกส์แบบง่ายๆ หรือที่นิยมกันคือการจำลองแบบการทำงานของเครือข่ายนิวรอนในรูปของฟังก์ชันคณิตศาสตร์



รูป 2.1 โครงสร้างพื้นฐานเซลล์นิวรอนสมองมนุษย์ [5]

จากรูป 2.1 แสดงองค์ประกอบสำคัญของเซลล์สมองมนุษย์ เซลล์นิวรอนรับข้อมูลอินพุต จากนิวรอนเซลล์อื่น โดยผ่านทางจุดเชื่อมต่อระหว่างเซลล์เรียกว่า “ไซแนปส์” (Synapse) สัญญาณข้อมูลจากไซแนปส์ จะถูกส่งผ่านเดนไดรต์ (Dendrite) ซึ่งเป็นส่วนรับสัญญาณของเซลล์ร่างกาย (Cell Body) สัญญาณข้อมูลอินพุต จะได้รับการประมวลผลบางประการตามขบวนการที่เกิดขึ้นภายในเซลล์ร่างกาย สัญญาณแอกซอนเทอมินัลจากเซลล์นิวรอน จะถูกส่งออกจากส่วนของเซลล์ที่เรียกว่า “แอกซอน” (Axon) ซึ่งสัญญาณนี้จะกระโดดข้ามผ่านไซแนปส์ ซึ่งเป็นส่วนอินพุต ของเซลล์อื่นต่อไป

สมองของมนุษย์ประกอบไปด้วยเซลล์นิวรอน ซึ่งแต่ละเซลล์มีจุดเชื่อมต่อไซแนปส์และแอดซัน การเชื่อมต่อไซแนปส์ซึ่งเป็นจุดเชื่อมต่อของเอ็กซอน (อุปกรณ์แอดซัน) ของนิวรอนเซลล์หนึ่ง และเดนไดรต์ (อุปกรณ์อินพุต) ของอีกเซลล์หนึ่ง มีฟังก์ชันการทำงาน 2 ลักษณะคือ “ไซแนปส์กระตุ้น” (Excitatory Synapses) และ “ไซแนปส์ยับยั้ง” (Inhibitory Synapses) ไซแนปส์กระตุ้น เป็นไซแนปส์ชนิดที่จะทำให้สัญญาณแอดซัน ที่ส่งผ่านมามีความถี่สูงขึ้น ส่วนไซแนปส์ยับยั้ง จะทำให้สัญญาณแอดซันมีความถี่ต่ำลง นอกจากนี้ความถี่สัญญาณแอดซัน ยังขึ้นอยู่กับความแรงหรือปริมาณของสัญญาณอินพุต และเงื่อนไขที่แสดงในรูปของน้ำหนักของจุดเชื่อมต่อไซแนปส์ด้วย คุณสมบัติ ในการจดจำ (Memory) และการประมวลผล (Processing) ของสมองมนุษย์ จะขึ้นอยู่กับโครงสร้างของการเชื่อมต่อและน้ำหนักของจุดเชื่อมต่อไซแนปส์เหล่านี้

2.2 โครงข่ายประสาทเทียม (Artificial Neural Networks)

โครงข่ายประสาทเทียม (Artificial Neural Networks) เป็นระบบประมวลผลข้อมูลที่มีคุณลักษณะการทำงานเทียบได้กับโครงข่ายประสาททางชีววิทยา โครงข่ายประสาทเทียมนี้ได้พัฒนาการรู้คิดหรือระบกก้งของมนุษย์ให้เป็นแบบจำลองทางคณิตศาสตร์ ภายใต้สมมติฐานดังนี้

- 1) โครงข่ายประสาทเทียม ประกอบด้วยหน่วยประมวลผลจำนวนมากมาย เรียกว่า นิวรอน (Neuron , Unit , Cells หรือ Nodes) การประมวลผลข้อมูลจะเกิดขึ้นได้ที่ นิวรอนนี้
- 2) สัญญาณต่างๆ ส่งผ่านนิวรอนได้ด้วยการเชื่อมต่อกันเป็นลิงค์ (Link)
- 3) แต่ละลิงค์จะมีความสัมพันธ์กับค่าน้ำหนัก (Weight) ซึ่งเปรียบเสมือน เป็นค่าที่ให้โครงข่ายในการตัดสินใจแก้ปัญหา โดยทั่วไป ค่าน้ำหนักนี้จะถูกคูณเข้ากับสัญญาณอินพุตเพื่อ ส่งออกไปยังนิวรอนอื่นๆ
- 4) แต่ละนิวรอนจะมีค่าสถานะภายใน (Internal State) เรียกว่าระดับการกระตุ้น (Activation หรือ Activity Level) ที่จะให้ฟังก์ชันการกระตุ้น (Activation Function) ของสัญญาณอินพุตผลลัพธ์ เพื่อส่งเป็นสัญญาณแอดซันออกไป ให้แก่นิวรอนตัวอื่นๆ ฟังก์ชันการกระตุ้นนี้ปกติฟังก์ชันที่ไม่เป็นเชิงเส้น (Nonlinear) ส่วนสัญญาณอินพุตผลลัพธ์ จะเป็นค่าผลรวมทั้งหมดของค่าน้ำหนัก คูณกับ ค่าระดับการกระตุ้น


พิจารณารูป 2.2 นิวรอน Y ซึ่งจะรับอินพุตจากนิวรอน X_1 , X_2 และ X_3 มีค่าระดับการกระตุ้นเป็น X_1 , X_2 และ X_3 ตามลำดับ ค่าน้ำหนักจากนิวรอน X_1 , X_2 และ X_3 ไปยังนิว

รอน Y คือ w_1 , w_2 และ w_3 จะได้ความสัมพันธ์กับอินพุตลัพท์ Y_{in} ที่ส่งไปให้นิวรอน Y เป็นผลรวมของค่าน้ำหนักกับค่าระดับการกระตุ้นจากนิวรอน X_1 , X_2 และ X_3

$$y_{in} = w_1 x_1 + w_2 x_2 + w_3 x_3 \quad \dots(2.1)$$


ค่าระดับการกระตุ้น y ของนิวรอน Y จะเป็นฟังก์ชันของค่าอินพุตลัพท์ดังนี้

$$y = f(y_{in}) \quad \dots(2.2)$$



รูป 2.2 รูปแบบนิวรอนอย่างง่าย [5]

ซึ่งฟังก์ชันการกระตุ้นนี้มีได้หลายรูปแบบ ถ้าให้นิวรอน Y เชื่อมต่อกับนิวรอน Z_1 และ Z_2 ด้วยค่าน้ำหนัก v_1 และ v_2 ดังรูป 2.3 นิวรอน Y จะส่งสัญญาณ y ไปยังนิวรอนเหล่านี้ ซึ่งค่าที่นิวรอน Z_1 และ Z_2 ได้รับจะแตกต่างกันขึ้นอยู่กับค่าน้ำหนัก v_1 และ v_2 นั่นเอง ในทำนองเดียวกัน ค่าระดับการกระตุ้น Z_1 และ Z_2 ของนิวรอน Z_1 และ Z_2 จะขึ้นอยู่กับอินพุตที่มาจากนิวรอนตัวอื่น ๆ อีก



รูป 2.3 โครงข่ายประสาทเทียมอย่างง่าย [5]

2.2.1 คุณลักษณะสมบัติของโครงข่ายประสาทเทียม

จากหลักการเบื้องต้นของโครงข่ายประสาทเทียม จะเห็นได้ว่าคุณลักษณะของโครงข่ายประสาทเทียมจะถูกกำหนดโดย

- 1) รูปแบบของการเชื่อมต่อ (Connection) ระหว่างนิวรอน เรียกว่าสถาปัตยกรรมโครงข่าย (Net Architecture)
- 2) วิธีการหาค่าน้ำหนักบนการเชื่อมต่อ เรียกว่าการเรียนรู้ (Training , Learning หรือ Algorithm)
- 3) ฟังก์ชันการกระตุ้น (Activation Function)

2.2.2 สถาปัตยกรรมโครงข่าย (Net Architecture)

โดยปกติโครงสร้างของนิวรอนจะจัดอยู่ในรูปของชั้น นิวรอนที่อยู่ในชั้นเดียวกันจะมีองค์ประกอบ (Factor) ต่างๆ เหมือนกันองค์ประกอบเหล่านี้ได้แก่ฟังก์ชันการกระตุ้น , รูปแบบของค่าน้ำหนัก (Pattern of Weight) และรูปแบบของการเชื่อมต่อ (Pattern Connections) ไปยังนิวรอนอื่นๆ

จำนวนชั้นในโครงข่าย จะคิดจากจำนวนชั้นของค่าน้ำหนักที่เชื่อมต่อระหว่างนิวรอน เช่น รูปที่ 2.3 จะได้ว่ามีจำนวนชั้นของโครงข่ายประสาทเทียม 2 ชั้น


1) โครงข่ายแบบชั้นเดียว (Single-Layer Net)

สถาปัตยกรรมโครงข่ายแบบนี้ จะมีจำนวนชั้นของค่าน้ำหนักเพียงชั้นเดียว ดังรูป 2.4 ซึ่งหน่วยอินพุต (Input Units) จะเชื่อมต่อกับหน่วยเอาต์พุต (Output Units) แบบตัวต่อตัว (Fully Connected) คืออินพุตหนึ่งตัวจะเชื่อมต่อเอาต์พุตทุกตัว แต่จะไม่เชื่อมต่อกันเองกับอินพุตตัวอื่น เช่นเดียวกับที่หน่วยเอาต์พุตซึ่งแต่ละตัวจะไม่เชื่อมต่อกันเอง


2) โครงข่ายแบบหลายชั้น (Multilayer Net)

โครงข่ายลักษณะนี้จะมีชั้นของโครงข่ายประสาทเทียมอีก 1 ชั้น หรือมากกว่า คั่นอยู่ระหว่างหน่วยอินพุต และ หน่วยเอาต์พุต หน่วยที่คั่นอยู่เรียกว่าหน่วยชั้นซ่อน (Hidden Units) ดังนั้นชั้นของค่าน้ำหนัก ก็จะมีเพิ่มมากขึ้นมาระหว่างหน่วยที่ติดกันด้วย เช่นจากรูป 2.5 จะมีค่าน้ำหนัก ระหว่างหน่วยอินพุต กับหน่วย ชั้นซ่อน และ ระหว่างหน่วยชั้นซ่อนกับหน่วยเอาต์พุต

โดยทั่วไปโครงข่ายแบบหลายชั้นสามารถแก้ปัญหาที่มีความซับซ้อนได้มากกว่าโครงข่ายแบบชั้นเดียว แต่ก็จะทำให้การเรียนรู้ยากขึ้นตามไปด้วย



รูป 2.4 โครงข่ายแบบชั้นเดียว [9]



รูป 2.5 โครงข่ายแบบหลายชั้น [9]

3) โครงข่ายแบบคอมพิติฟเลเยอร์ (Competitive Layer)


เป็นรูปแบบของโครงข่ายประสาทเทียมขนาดใหญ่ ข้อแตกต่างประการสำคัญคือ โครงข่ายแบบชั้นเดียวและโครงข่ายแบบหลายชั้นนั้น จะมีโครงสร้างแบบป้อนไปข้างหน้า (Feedforward Net) คือสัญญาณจะมีการผ่านจากหน่วยอินพุตไปยังหน่วยเอาต์พุตเท่านั้น แต่สำหรับโครงข่ายแบบคอมพิติฟเลเยอร์ จะมีโครงสร้างแบบวนกลับ (Recurrent Net) คือมีการส่งสัญญาณวนกลับภายในหน่วยอินพุตเองด้วย ดังรูป 2.6

2.2.3 การเรียนรู้ (Training)

การตั้งค่าน้ำหนักของนิวรอน จะเรียกว่าการเรียนรู้ (Training , Learning หรือ Algorithm ของโครงข่าย) ซึ่งเป็นส่วนสำคัญทำให้แยกแยะโครงข่ายให้แตกต่างกัน

1) Supervised Training

วิธี Supervised Training นี้เป็นการเรียนรู้ที่จะกำหนดเทรนนิ่งเวกเตอร์ (Training Vector) ให้มีความสัมพันธ์กับเอาต์พุตที่ต้องการ โดยที่ค่าน้ำหนักจะถูกปรับค่าไปในช่วงขั้นตอนของการเรียนรู้ วิธีง่าย ๆ ของการเรียนรู้แบบนี้ เช่น การกำหนดค่าอินพุตเวกเตอร์ (Input Vector) มีรูปแบบตรงตามที่กำหนดไว้จะให้ค่าเอาต์พุตเป็น 1 แต่ถ้าไม่ตรงกันให้เอาต์พุตเป็น -1



รูป 2.6 โครงข่ายแบบคอมพิติฟเลเยอร์ [9]

โครงข่ายจะได้รับการเรียนรู้ ด้วยการกำหนดอินพุตเวกเตอร์ให้มีความสัมพันธ์กับค่าของเอาต์พุตเวกเตอร์ ซึ่งกำหนดไว้อีกเช่นกัน เรียกว่า Associative Memory ถ้าเอาต์พุตเวกเตอร์ ที่ต้องการเหมือนกับอินพุตเวกเตอร์จะเรียกว่า Autoassociative Memory แต่ถ้าเอาต์พุตเวกเตอร์ ที่ต้องการแตกต่างจากอินพุตเวกเตอร์ เรียกว่า Heteroassociative Memory

หลังจากเกิดการเรียนรู้ขึ้นแล้ว Associative Memory จะสามารถเรียกหน่วยที่เก็บค่านำหน้าขึ้นมาใช้ได้อีก เมื่อมีอินพุตเวกเตอร์ที่เหมือนกันหรือคล้ายคลึงกับที่เคยผ่านการเรียนรู้มาแล้ว ผ่านเข้ามาอีกครั้งหนึ่ง

สำหรับโครงข่ายแบบหลายชั้นนั้น การเรียนรู้ที่เหมาะสมคือกระบวนการเรียนรู้แบบแพร่กลับ (Backpropagation)

2) Unsupervised Training

การเรียนรู้แบบนี้มีลักษณะเป็นการเรียนรู้ด้วยตัวเอง (Self-Organizing Neural Net) โดยป้อนค่าอินพุตเวกเตอร์ให้โครงข่าย แต่ไม่ได้รับเอาต์พุตที่ต้องการไว้ ดังนั้นโครงข่ายจะทำการปรับปรุงค่านำหน้าด้วยการจัดกลุ่มอินพุตเวกเตอร์ที่มีลักษณะเดียวกันไว้กับกลุ่มเอาต์พุต ที่มีลักษณะเดียวกัน

3) Fixed Weight Nets

เป็นเทคนิคที่ใช้ในการแก้ปัญหาของ Constrain Optimization Problems ค่านำหน้าจะถูกกำหนดไว้ ตั้งแต่ตอนที่โครงข่ายได้รับการออกแบบ

2.2.4 ฟังก์ชันการกระตุ้น (Activation Function)

ฟังก์ชันการกระตุ้นเป็นส่วนสำคัญในการกำหนดค่าระดับการกระตุ้นภายใน นิวรอน นั้นๆ ฟังก์ชันการกระตุ้นนี้ โดยมากเป็นฟังก์ชันแบบไม่เป็นเชิงเส้น (Nonlinear)


1) ไคเอนดิตีฟังก์ชัน (Identity Function)

$$f(x) = x \quad \text{for all } x \quad \dots(2.3)$$

ฟังก์ชันการกระตุ้นแบบนี้มีใช้ในโครงข่ายแบบชั้นเดียว


2) ไบนารีสเตปฟังก์ชัน (Binary Step Function : with Threshold θ)

$$f(x) = \begin{cases} 1 & \text{if } x \geq \theta \\ 0 & \text{if } x < \theta \end{cases} \quad \dots(2.4)$$



รูป 2.7 ไอเดนติตี้ฟังก์ชัน [5]

โครงข่ายแบบชั้นเดียวใช้สเต็ปฟังก์ชัน เพื่อแปลงค่าอินพุตจากสัญญาณที่มีการแปรค่าอย่างต่อเนื่อง ให้ได้สัญญาณหน่วยเอาต์พุตเป็นไบนารี (Binary) คือ 0 กับ 1 หรือ ไบโพลาร์ (Bipolar) คือ 1 กับ -1 ฟังก์ชันการกระตุ้นแบบไบนารีสเต็ปฟังก์ชันนี้ เรียกอีกอย่างว่า Threshold Function หรือ Heaviside Function



รูป 2.8 ไบนารีสเต็ปฟังก์ชัน [5]

3) ไบนารีซิกมอยด์ (Binary Sigmoid)

$$f(x) = \frac{1}{1 + \exp(-\alpha x)} \quad \dots(2.5)$$

$$f'(x) = \alpha f(x)[1 - f(x)] \quad \dots(2.6)$$

ฟังก์ชันซิกมอยด์ (Sigmoid Function หรือ S-Shaped Curve หรือ Logistic Function) เป็นฟังก์ชันการกระตุ้นที่นิยมใช้ในการเรียนรู้แบบแพร่กลับเพราะว่าสัมพันธ์ระหว่างค่า

ของฟังก์ชันที่จุดใดๆ กับค่าอนุพันธ์ของฟังก์ชันที่จุดใดๆ จะมีค่าลดลงในช่วงของการเรียนรู้

ฟังก์ชันซิกมอยด์นี้จะมีค่าอยู่ในช่วงของ 0 ถึง 1 จึงนำไปใช้กับฟังก์ชันการกระตุ้นที่ต้องการให้ค่าเอาต์พุตอยู่ระหว่างค่า 0 ถึง 1 ค่าพารามิเตอร์ที่สำคัญคือ σ เรียกว่า Steepness Parameter

ถ้าค่าของฟังก์ชันซิกมอยด์อยู่ระหว่างค่า -1 ถึง 1 จะเรียกว่าฟังก์ชันไบโพลาร์ (Bipolar Function) ซึ่งฟังก์ชันนี้มีความสัมพันธ์กับ ฟังก์ชันไฮเพอร์บอริกแทนเจนต์ (Hyperbolic Tangent Function) โดยเหมาะที่จะนำไปใช้เมื่อค่าเอาต์พุตที่ต้องการ มีค่าอยู่ระหว่าง -1 ถึง 1 ดังนั้นนิยามฟังก์ชันไบโพลาร์ซิกมอยด์ (Bipolar Sigmoid) ดังนี้

$$g(x) = 2f(x) - 1 = \frac{2}{1 - \exp(-\sigma x)} - 1 \quad \dots(2.7)$$

$$= \frac{1 - \exp(-\sigma x)}{1 - \exp(-\sigma x)} \quad \dots(2.8)$$

$$g'(x) = \frac{\sigma}{2} [1 + g(x)][1 - g(x)] \quad \dots(2.9)$$

สมมติว่า ค่า $\sigma = 1$ เราแสดงความสัมพันธ์ กับฟังก์ชันไฮเพอร์บอริกแทนเจนต์ ได้ดังนี้

$$g(x) = \frac{1 - \exp(-x)}{1 - \exp(-x)} \quad \dots(2.10)$$


นิยามฟังก์ชันไฮเพอร์บอริกแทนเจนต์

$$h(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad \dots(2.11)$$

$$= \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \quad \dots(2.12)$$

ค่าอนุพันธ์ของฟังก์ชันไฮเพอร์บอริกแทนเจนต์

$$h'(x) = [1 + h(x)][1 - h(x)] \quad \dots(2.13)$$



รูป 2.9 (ก) แสดงไบนารีซิกมอยด์
 (ข) แสดงไบโพลาร์ซิกมอยด์ [5]

โดยที่ ค่าตัวแปร มีค่าดังนี้

x_i, y_j ค่าระดับการกระตุ้นของนิวรอน X_i, Y_j โดยที่

สำหรับหน่วยอินพุต X_i

$$x_i = \text{สัญญาณอินพุต}$$

สำหรับหน่วยอื่น ๆ Y_j

$$y_j = f(y_{in_j}) \quad \dots(2.14)$$

w_{ij} คำนวณน้ำหนักของการเชื่อมต่อจากนิวรอน X_i ไปยังนิวรอน Y_j
 b_j ค่าไบแอส (Bias) ของนิวรอน Y_j
 ค่าไบแอสนี้คือค่าน้ำหนักของการเชื่อมต่อจากหน่วยที่มีค่า
 ระดับการกระตุ้นคงที่เท่ากับ 1

y_{in_j} อินพุตสุทธิ (Net Input) ของนิวรอน Y_j

$$y_{in_j} = b_j + \sum_i x_i w_{ij} \quad \dots(2.15)$$

W เมตริกซ์ค่าน้ำหนัก (Weight Matrix)

$$W = \{w_{ij}\} \quad \dots(2.16)$$

w_j เวกเตอร์ค่าน้ำหนัก (Vector of Weight)

$$w_j = (w_{1j}, w_{2j}, \dots, w_{nj})^T \quad \dots(2.17)$$

 เมื่อเมตริกซ์ค่าน้ำหนักมีจำนวน j สดมภ์

$\|x\|$ ขนาดของเวกเตอร์ x
 θ_1 ระดับต่ำสุด (Threshold) สำหรับค่าระดับการกระตุ้นของนิวรอน Y_j
 สำหรับฟังก์ชันการกระตุ้น แบบสเตป (Step Activation Function) จะตั้งค่าระดับการกระตุ้นของนิวรอนให้เท่ากับ 1 ถ้าอินพุตสุทธิ มีค่ามากกว่าต่ำสุด θ_j ที่กำหนดไว้ แต่ถ้าน้อยกว่าให้ค่าระดับการกระตุ้นเท่ากับ 0

S เทรนนิ่งอินพุตเวกเตอร์ (Training Input Vector)

$$S = (s_1, \dots, s_i, \dots, s_n) \quad \dots(2.18)$$

t เทรนนิ่งเอาต์พุตเวกเตอร์ (Training Output Vector)

$$t = (t_1, \dots, t_j, \dots, t_m) \quad \dots(2.19)$$

x อินพุตเวกเตอร์สำหรับโครงข่าย

$$x = (x_1, \dots, x_i, \dots, x_n) \quad \dots(2.20)$$

Δw_{ij} ค่าน้ำหนักที่เปลี่ยนไป

$$\Delta w_{ij} = [w_{ij}(new) - w_{ij}(old)] \quad \dots(2.21)$$

α อัตราการเรียนรู้ (Learning Rate)
 อัตราการเรียนรู้นี้ใช้เพื่อควบคุมจำนวนของการปรับปรุงค่าน้ำหนักในแต่ละขั้นของการเรียนรู้


2.2.5 วิธีการคูณเมตริกซ์เพื่อคำนวณอินพุตสุทธิ

(Matrix Multiplication Method for Calculating Net Input)

ถ้าค่าน้ำหนักของโครงข่ายเก็บไว้ในเมตริกซ์ $W = \{w_{ij}\}$ แล้วค่าอินพุตสุทธิที่ส่งไปให้นิวรอน Y_j (ไม่มีค่าไบแอสที่นิวรอน j) สามารถคำนวณได้ง่ายๆ ด้วยการทำผลคูณเชิงสเกลาร์ระหว่างเวกเตอร์ $x = (x_1, \dots, x_i, \dots, x_n)$ กับ w_j (เวกเตอร์ค่าน้ำหนักมีจำนวน j สดมภ์)

2.2.6 ค่าไบแอส (Bias)

ค่าไบแอสก็คือการเพิ่มองค์ประกอบ $x_0 = 1$ ให้กับเวกเตอร์ x เช่น $x = (1, x_1, \dots, x_i, \dots, x_n)$ ค่าไบแอสนี้ จึงมีความหมายว่าเป็นค่าน้ำหนักตัวหนึ่งหรือ $w_{ij} = b_j$ จะได้อินพุตสุทธิที่ส่งให้นิวรอน Y_j ดังรูป 2.10



รูป 2.10 นิวรอนที่มีค่าไบแอส [5]