

บทที่ 3

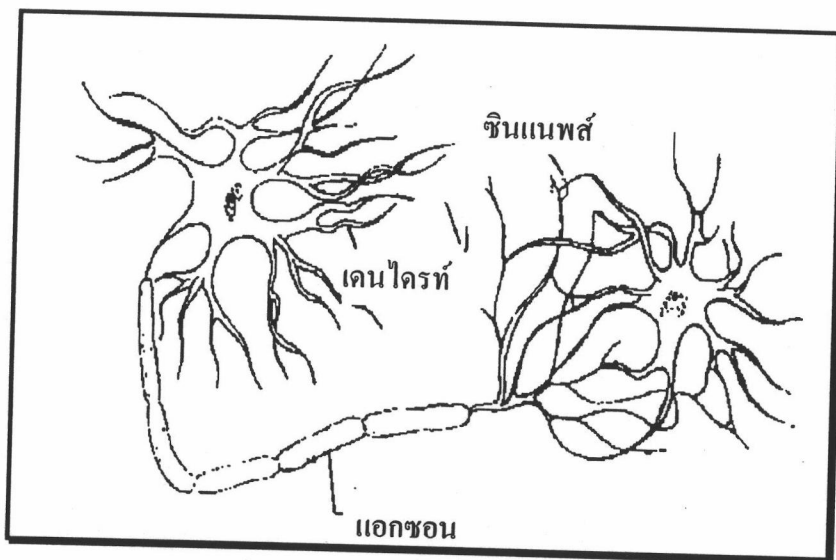
ทฤษฎีเกี่ยวกับข่ายงานนิเวศ

บทนี้กล่าวถึงการศึกษาเกี่ยวกับข่ายงานนิเวศซึ่งได้แก่โครงสร้างของข่ายงานในยุคแรก ๆ และโครงสร้างของข่ายงานในปัจจุบัน โครงสร้างของข่ายงานโดยทั่วไปเป็นแบบจำลองข่ายงานนิเวศที่ใช้แนวความคิดมาจากระบบประสาทโดยมีองค์ประกอบอยู่ 3 ส่วนคือ ตัวเซลล์นิวรอน, เดนไดรต์ และซินแนปส์ โครงสร้างของข่ายงานในยุคแรก ๆ จะมีชั้นของนำหนักเพียงชั้นเดียวซึ่งทำให้ข่ายงานนี้สามารถแก้ปัญหาแบบเชิงเส้นได้ แต่ไม่สามารถแก้ปัญหาแบบไม่เชิงเส้น หลังจากนั้นนักวิจัยต่าง ๆ ได้ศึกษาโครงสร้างของข่ายงานที่มีความซับซ้อนมากขึ้นโดยการเพิ่มชั้นของนำหนัก และสามารถแก้ปัญหาแบบไม่เชิงเส้นได้เป็นอย่างดี ในตอนท้ายกล่าวถึงอัลกอริทึมการกระจายย้อนกลับ และการเรียนรู้โดยการให้โมเมนตัมซึ่งจะช่วยเร่งให้เกิดการเรียนรู้ได้เร็วขึ้น

3.1 ชีวิตวิทยาของนิวรอนและแบบจำลองของข่ายงานนิวรัลในยุคแรก ๆ

ข่ายงานนิวรัลได้แนวคิดมาจากการเลียนแบบโครงสร้างระบบประสาทของมนุษย์ ซึ่งประกอบด้วยกลุ่มของนิวรอนจำนวนมาก โดยสามารถติดต่อกับนิวรอนหน่วยอื่น ๆ ด้วยแอกซอน (axon) และซินแนปส์ (synapses) ข้อสมมติฐานเกี่ยวกับแบบจำลองของระบบประสาทคือการติดต่อกันระหว่างนิวรอนที่อาศัยการกระตุ้นทางไฟฟ้า และการทำงานของนิวรอนนั้นเกิดขึ้นเนื่องจากกระบวนการทางชีวเคมี ในทางชีววิทยานิวรอนมีองค์ประกอบ 3 ส่วนซึ่งแสดงในรูปที่

3.1 คือ



รูปที่ 3.1 โครงสร้างของเซลล์ประสาท

1. ตัวเซลล์นิวรอน (cell body) ทำหน้าที่รวบรวมสัญญาณจากเดนไดรต์ และส่งไปให้แก่แอกซอน
2. เดนไดรต์ (dendrite) ทำหน้าที่รับสัญญาณจากแอกซอนของนิวรอนตัวอื่นเข้ามา และส่งต่อไปยังตัวเซลล์นิวรอน


3. แอกซอน (axon) ทำหน้าที่นำสัญญาณที่ออกจากตัวเซลล์นิวรอน และส่งไปยังเดนไดรต์ของนิวรอนถัดไป

เดนไดรต์จะรับสัญญาณจากแอกซอนของนิวรอนอื่นเข้ามาและส่งต่อไปให้ตัวเซลล์นิวรอน ตัวเซลล์นิวรอนจะรวมสัญญาณที่ได้รับส่งต่อไปให้แอกซอนจนถึงรอยต่อซินแนปส์ ซึ่งเป็นรอยต่อระหว่างแอกซอนของนิวรอนตัวปัจจุบัน และเดนไดรต์ของนิวรอนตัวถัดไป จากแนวความคิดพื้นฐานดังกล่าว นักวิจัยจึงได้สนใจที่จะศึกษากลไก และโครงสร้างของระบบประสาทของมนุษย์ซึ่งนำไปสู่การพัฒนาของแบบจำลองสำหรับการแก้ปัญหาที่ซับซ้อนซึ่งได้แก่การแก้ปัญหาแบบไม่เชิงเส้น


McCulloch และ Pitts (1943) ซึ่งเป็นผู้บุกเบิกของข่ายงานนิวรัล ได้เสนอตรรกเทรีสโพลด์ (threshold logic) ซึ่งแสดงในรูปที่ 3.2 แบบจำลองของ McCulloch และ Pitts มีค่าอินพุตและเอาต์พุตเป็น 0 กับ 1 เท่านั้น และค่าน้ำหนักมีค่าคงที่ อีกทั้งไม่มีการติดต่อกันระหว่างนิวรอน แบบจำลองชนิดนี้ใช้ได้กับระบบเชิงเส้น เนื่องจากมีเพียงนิวรอนเพียงหน่วยเดียวเท่านั้นโดยไม่มีการเชื่อมกับนิวรอนหน่วยอื่น สัญญาณที่ออกจากนิวรอนกำหนดด้วยเงื่อนไขดังสมการ (3.1)

$$O_{k+1} = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_{ik} \geq T \\ 0 & \text{if } \sum_{i=1}^n w_i x_{ik} < T \end{cases} \quad (3.1)$$

Rosenblatt (1958) เป็นผู้เสนอแบบจำลองเปอร์เซปตรอนซึ่งเป็นแบบจำลองข่ายงานแบบตัดสินใจเพื่อใช้ในการแยกข้อมูล 2 คลาสออกจากกัน Minsky และ Papert (1969) พิสูจน์



รูปที่ 3.2 แบบจำลองการทำงานของนิวรอนเสนอโดย McCulloch และ Pitts



รูปที่ 3.3 หน้าที่และการทำงานของนิวรอน

คุณสมบัติของเปอร์เซปตรอน และชี้ให้เห็นถึงข้อจำกัดของแบบจำลองนี้ซึ่งสามารถแก้ปัญหาเฉพาะระบบที่เป็นเชิงเส้นเท่านั้น

3.2 แบบจำลองของข่ายงานนิวรัลในปัจจุบัน

แบบจำลองของข่ายงานนิวรัลในปัจจุบันประกอบด้วยชั้นของนิวรอน และส่วนเชื่อมโยงระหว่างอินพุทและเอาต์พุทที่เรียกว่าน้ำหนัก (weight) อินพุทของนิวรอนซึ่งจะถูกนำมารวมกันโดยใช้ฟังก์ชันมูลฐาน (basis function) เอาต์พุทที่ออกจากฟังก์ชันมูลฐานจะถูกแปลงด้วยฟังก์ชันกระตุ้น (activation function) ซึ่งจะได้เอาต์พุทของนิวรอน และส่งเอาต์พุทของนิวรอนนี้ไปเป็นอินพุทของนิวรอนถัดไปเป็นทอด ๆ

หน้าที่ของนิวรอนแต่ละหน่วยซึ่งแสดงในรูปที่ 3.3 มีดังนี้

1. รับสัญญาณจากนิวรอนหน่วยอื่น
2. รวมสัญญาณจากนิวรอนหน่วยอื่นเข้าด้วยกันโดยใช้ฟังก์ชันมูลฐาน
3. แปลงสัญญาณที่รวมได้โดยใช้ฟังก์ชันกระตุ้น
4. ส่งผลลัพธ์ที่ได้จากฟังก์ชันกระตุ้นไปยังนิวรอนถัดไป

น้ำหนัก (weight) หรือที่เรียกว่าสัญญาณที่เชื่อมโยงระหว่างนิวรอนจะถูกปรับเปลี่ยนค่าอยู่ตลอดเวลา ในระหว่างการเรียนรู้ข่ายงานสร้างแบบจำลองภายในขึ้นมาเพื่อให้มีค่าใกล้เคียงกับระบบแบบจำลองของข่ายงานนิวรัลซึ่งสามารถใช้แทนแบบจำลองของกระบวนการได้ก็คือเมื่อค่าผลลัพธ์ที่ออกจากระบบมีค่าใกล้เคียงกับค่าผลลัพธ์ที่ออกจากข่ายงาน โครงสร้าง

ของข่ายงานประกอบไปด้วยชั้นของน้ำหนักอย่างน้อย 1 ชั้น สำหรับจำนวนชั้นของนิวรอนขึ้นอยู่กับจำนวนชั้นของน้ำหนัก ถ้าข่ายงานมีชั้นของน้ำหนัก 1 ชั้นข่ายงานจะมีชั้นของนิวรอน 2 ชั้นซึ่งได้แก่ชั้นอินพุท และชั้นเอาต์พุท ถ้าข่ายงานมีชั้นของน้ำหนักตั้งแต่ 2 ชั้นขึ้นไป ข่ายงานจะมีชั้นของนิวรอน 3 ชั้นซึ่งได้แก่ชั้นอินพุท ชั้นซ่อน และชั้นเอาต์พุท ในข่ายงานนิวรัลชั้นของนิวรอนสองชั้นจะติดต่อกันโดยใช้โครงสร้างเชื่อมโยง

ในข่ายงานนิวรัลหนึ่ง ๆ จะมีฟังก์ชันมูลฐาน ฟังก์ชันกระตุ้น และโครงสร้างการเชื่อมโยงที่แตกต่างกันกันไป โดยสามารถแบ่งประเภทของฟังก์ชันมูลฐาน ฟังก์ชันกระตุ้น และโครงสร้างการเชื่อมโยงได้ดังนี้

3.2.1 ฟังก์ชันมูลฐาน (Basis function)

ฟังก์ชันมูลฐานคือการแทนการแมพฟังก์ชัน (mapping) ทางคณิตศาสตร์ด้วยฟังก์ชัน, $u(w, x)$ เมื่อ w คือ เมทริกซ์ของน้ำหนักและ x คืออินพุทเวกเตอร์ ฟังก์ชันมูลฐานทำหน้าที่ในการรวมสัญญาณที่ได้รับมาจากนิวรอนหน่วยอื่น ๆ เข้าด้วยกัน และฟังก์ชันกระตุ้นจึงแปลงสัญญาณนี้เป็นเอาต์พุทของนิวรอน ฟังก์ชันมูลฐานสามารถแบ่งเป็น 2 ประเภท (ดูรูปที่ 3.4) คือ

ก. ฟังก์ชันมูลฐานเชิงเส้น (linear basis function)


เป็นฟังก์ชันชนิดไฮเปอร์เพลน (hyperplane) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 1 ค่า net ที่ได้เป็นผลรวมเชิงเส้นของค่าอินพุทซึ่งแสดงในสมการ (3.3)

$$u_i(w, x) = \sum_{j=1}^n w_{ij} x_j \quad (3.3)$$

ข. ฟังก์ชันมูลฐานเชิงรัศมี (radial basis function)

เป็นฟังก์ชันไฮเปอร์สเฟียร์ (hypersphere) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 2 ค่า
net ที่ได้จะแทนระยะทางไปยังชุดข้อมูลอ้างอิง ซึ่งแสดงในสมการ (3.4)

$$u_i(w, x) = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} \quad (3.4)$$



รูปที่ 3.4 ฟังก์ชันมูลฐาน (a) linear (hyperplane) (b) radial (hypersphere)


3.2.2 ฟังก์ชันกระตุ้น (Activation function)

ฟังก์ชันกระตุ้นทำหน้าที่แปลงค่า net ที่อยู่ในรูปของฟังก์ชันมูลฐานให้เป็นเอาต์พุทของ
นิวรอน ฟังก์ชันกระตุ้นแบ่งเป็น 2 ประเภทคือ ฟังก์ชันกระตุ้นแบบเชิงเส้น และฟังก์ชันกระตุ้น
แบบไม่เชิงเส้น


3.2.2.1 ฟังก์ชันกระตุ้นแบบเชิงเส้น (Linear activation function)

ฟังก์ชันกระตุ้นแบบเชิงเส้นได้แก่ฟังก์ชันแบบสเต็ป (step function) ฟังก์ชันแรมพ์
(ramp function) ซึ่งแสดงในรูปที่ 3.5 (a) และ 3.5 (b) ตามลำดับ โดยมีสมการคณิตศาสตร์ดังนี้คือ

ก. ฟังก์ชันแบบสเต็ป



(a)



(b)

รูปที่ 3.5 ฟังก์ชันกระตุ้นแบบเชิงเส้น (a) ฟังก์ชันแบบสเต็ป (step function)

(b) ฟังก์ชันแรมพ์ (ramp function)

$$f(net) = \begin{cases} 1 & \text{if } net > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.5)$$

ข. ฟังก์ชันแรมพ์ (ramp function)

$$f(net) = \begin{cases} 1 & \text{if } net \geq 1 \\ net & \text{if } |net| < 1 \\ -1 & \text{if } net \leq -1 \end{cases} \quad (3.6)$$

3.2.2.2 ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น (Nonlinear activation function)

ฟังก์ชันกระตุ้นแบบไม่เชิงเส้นได้แก่ ฟังก์ชันซิกมอยด์ (sigmoid function) และฟังก์ชันเกาส์เซียน (gaussian function) ซึ่งแสดงในรูปที่ 3.6 (a) และ 3.6 (b) ตามลำดับ ฟังก์ชันกระตุ้นที่นิยมใช้กันมากที่สุดคือ ฟังก์ชันซิกมอยด์

สมการคณิตศาสตร์ของฟังก์ชันกระตุ้นแบบไม่เชิงเส้นคือ

ก. ฟังก์ชันซิกมอยด์


$$f(net) = \frac{1}{1 + e^{-net}} \quad (3.7)$$

ข. ฟังก์ชันเกาส์เซียน


$$f(net) = ce^{-net^2} \quad (3.8)$$

3.2.3 โครงสร้างเชื่อมโยงของน้ำหนักระหว่างชั้นของข่ายงานนิวรัล

ข่ายงานนิวรัลประกอบด้วยนิวรอน และแมทริกซ์ของน้ำหนัก ประสิทธิภาพของข่ายงานขึ้นกับการเชื่อมโยงระหว่างนิวรอน ชั้นของนิวรอนสองชั้นติดต่อกันโดยผ่านข่ายงานเชื่อมต่อที่เป็นน้ำหนักแสดงในรูปที่ 3.7 ซึ่งแบ่งเป็น 4 ประเภทคือ



(a)



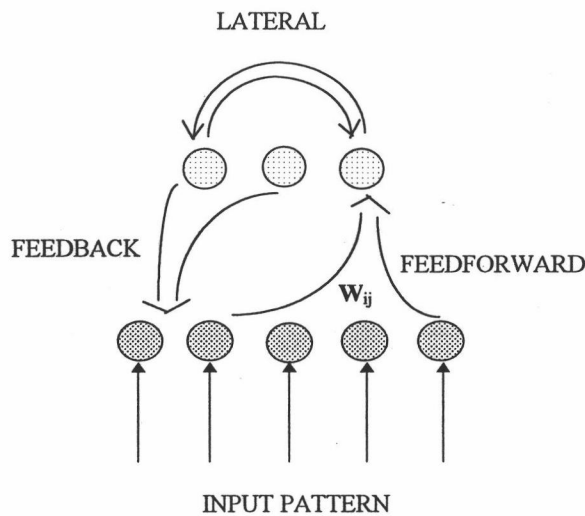
(b)

รูปที่ 3.6 ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น (a) ฟังก์ชันซิกมอยด์ (sigmoid function)

(b) ฟังก์ชันเกาส์เซียน (gaussian function)

ก. การเชื่อมโยงแบบป้อนไปข้างหน้า (feedforward connection) เป็นการนำข้อมูลของนิวรอนจากชั้นที่ต่ำกว่าและนำไปใช้ในชั้นที่อยู่เหนือกว่า

ข. การเชื่อมโยงแบบป้อนกลับ (feedback connection) เป็นการนำข้อมูลจากชั้นที่อยู่เหนือกว่าและส่งกลับลงมายังชั้นที่อยู่ต่ำกว่า



รูปที่ 3.7 โครงสร้างพื้นฐานของข่ายงานนิวรัลที่แสดงการเชื่อมโยงแบบต่าง ๆ

ค. การเชื่อมโยงภายในชั้น (lateral connections) เป็นการนำข้อมูลภายในชั้นเดียวกันและกระจายกลับมาใช้ในชั้นเดิม

ง. การเชื่อมโยงแบบหน่วงเวลา (time-delayed connections) เป็นการนำข้อมูลมาหน่วงเวลาแล้วนำเข้าไปรวมกับการเชื่อมโยงของข้อมูล เพื่อให้ได้แบบจำลองเป็นไดนามิกเชิงเวลา (temporal dynamics) ซึ่งนำมาประยุกต์ใช้กับการระลึกรูปแบบเชิงเวลา (temporal pattern recognition)

3.3 การจำแนกข่ายงานนิวรัล


ข่ายงานนิวรอนสามารถจำแนกได้เป็นสองประเภทคือข่ายงานนิวรัลแบบมีการชี้นำ (supervised neural network) และข่ายงานนิวรัลแบบไม่มีการชี้นำ (unsupervised neural network) สุรพล คำสุภา (1995) แนะนำว่าข่ายงานนิวรัลแบบมีการชี้นำเรียนรู้ได้รวดเร็วกว่าข่ายงานนิวรัลแบบไม่มีการชี้นำเนื่องจากมีผู้ฝึกช่วยในการเรียนรู้ งานวิจัยนี้จะใช้ข่ายงานที่ใช้ข่ายงานนิวรัลแบบมีการชี้นำประเภทการกระจายย้อนกลับ (backpropagation)

3.3.1 ข่ายงานนิวรัลแบบมีการชี้นำ (Supervised neural network)


ข่ายงานนิวรัลที่มีการเรียนรู้แบบที่มีการชี้นำถูกฝึกโดยใช้คู่ลำดับของค่าอินพุท และเอาต์พุท ค่าอินพุทใช้เป็นอินพุทให้แก่ข่ายงาน และค่าเอาต์พุทใช้เป็นผู้สอน (teacher) ซึ่งแสดงในรูปที่ 3.8 (a) การฝึกจะทำโดยการปรับค่าน้ำหนักของข่ายงานเพื่อให้ค่าความแตกต่างระหว่างเอาต์พุทที่ต้องการและเอาต์พุทของข่ายงานให้มีค่าน้อยที่สุด กระบวนการนี้อาจทำซ้ำจน (iteration) กระทั่งค่าผิดพลาดเป็นค่าน้อย ๆ ที่ยอมรับได้ ตัวอย่างของข่ายงานประเภทนี้ได้แก่เปอร์เซปตรอน (perceptron), อะดาไลน์ (adaline), และการกระจายย้อนกลับ (backpropagation) ซึ่งแสดงในรูปที่ 3.9

3.3.2 ข่ายงานนิวรัลแบบไม่มีการชี้นำ (Unsupervised neural network)

ข่ายงานนิวรัลที่มีการเรียนรู้แบบที่ไม่มีการชี้นำต้องการเพียงค่าอินพุทในการฝึกข่ายงาน โดยไม่มีผู้สอนซึ่งแสดงในรูปที่ 3.8 (b) ในระหว่างการฝึกค่าน้ำหนักของข่ายงานถูกปรับเพื่อให้อินพุทที่คล้าย ๆ กันสร้างเอาต์พุทที่คล้ายกัน การเรียนรู้ของข่ายงานประเภทนี้คล้ายกับ

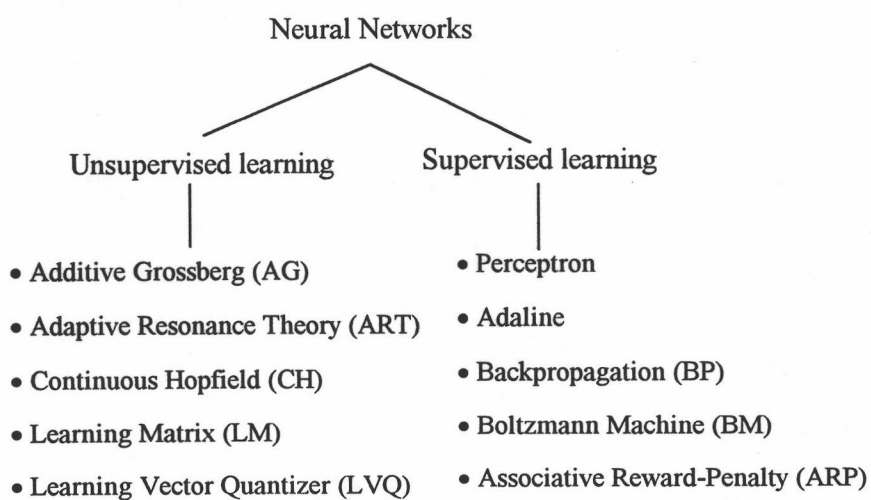


(a) supervised learning



(b) unsupervised learning

รูปที่ 3.8 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนัก



รูปที่ 3.9 ข่ายงานนิวรัลสามารถจำแนกเป็นแบบมีการชี้้นำ และแบบไม่มีการชี้้นำ

สมองของมนุษย์ที่เปลี่ยนแปลงโครงสร้างของมันภายใต้อิทธิพลของประสบการณ์โดยไม่มีผู้สอน ตัวอย่างการเรียนรู้ของข่ายงานนิวรัลประเภทนี้ได้แก่ AG (additive grossberg) และ ART (adaptive resonance theory) ซึ่งแสดงในรูปที่ 3.9

3.4 ข่ายงานนิวรัลแบบมีการชี้แนะ

ข่ายงานนิวรัลแบบมีการชี้แนะได้แก่ ข่ายงานเปอร์เซปตรอน (perceptron) ข่ายงานแบบอะดาไลน์ (adaline) และข่ายงานแบบกระจายย้อนกลับ ข่ายงานแบบเปอร์เซปตรอน และอะดาไลน์เป็นข่ายงานที่มีชั้นของน้ำหนักเพียงชั้นเดียว ดังนั้นข่ายงานทั้งสองนี้จึงสามารถแก้ปัญหาได้เฉพาะปัญหาแบบเชิงเส้น สำหรับข่ายงานแบบกระจายย้อนกลับเป็นข่ายงานที่มีชั้นของน้ำหนักตั้งแต่ 2 ชั้นขึ้นไป ดังนั้นข่ายงานจึงสามารถแก้ปัญหาแบบไม่เชิงเส้นได้เป็นอย่างดี

ข่ายงานนิวรัลแบบมีการชี้แนะจะใช้ชุดข้อมูลที่ประกอบไปด้วยค่าอินพุทและเอาต์พุทที่เป็นคู่ที่สอดคล้องกัน

$$[u, o] = \{[u_1, o_1], [u_2, o_2], \dots, [u_n, o_n]\} \quad (3.9)$$

เมื่อ n คือจำนวนชุดของข้อมูลที่ใช้ในการฝึก วัตถุประสงค์ในการฝึกข่ายงานคือหาค่าน้ำหนักที่เหมาะสม และทำให้ความแตกต่างของเป้าหมายกับค่าที่ออกจากข่ายงานให้มีค่าน้อยที่สุด ข้อกำหนดของค่าความแตกต่างคือผลรวมของความแตกต่างระหว่างค่าเป้าหมายกับเอาต์พุทของข่ายงานกำลังสอง (sum square error, SSE) ฟังก์ชันของผลต่างกำลังสองคือ

$$E = [t - f(u, w)]^2 \quad (3.10)$$

ฟังก์ชันพลังงาน หรือฟังก์ชันต้นทุน (energy function or cost function) ของระบบ แบบจำลองของข่ายงานเป็นฟังก์ชันของอินพุต และแมทริกซ์ของน้ำหนัก, $y = f(u,w)$ แมทริกซ์ของน้ำหนักสามารถปรับค่าเพื่อให้ฟังก์ชันพลังงานมีค่าต่ำลงให้เหลือน้อยที่สุดไปในทิศทางลดลงของเกรเดียนท์ (gradient)

3.4.1 ข่ายงานแบบเปอร์เซปตรอน (Perceptron)

Rosenblatt (1958) เสนอข่ายงานเปอร์เซปตรอน ข่ายงานเปอร์เซปตรอนเป็นแบบจำลองของข่ายงานนิเวศแบบตัดสินใจ โดยมีขอบเขตการตัดสินใจเป็นแบบเชิงเส้น รูปที่ 3.10 แสดงโครงสร้างของข่ายงานเปอร์เซปตรอนซึ่งมีชั้นของน้ำหนักเพียงชั้นเดียว ในการเรียนรู้ข่ายงานอาศัยสัญญาณการเรียนรู้จากค่าความแตกต่างระหว่างค่าเป้าหมายกับค่าเอาต์พุตที่ออกจากข่ายงานนิเวศ ดังนั้นวิธีการเรียนรู้แบบนี้จึงเป็นการเรียนรู้แบบชี้นำ เปอร์เซปตรอนใช้ฟังก์ชันมาตรฐานเป็นฟังก์ชันมาตรฐานเชิงเส้น และฟังก์ชันกระตุ้นเป็นฟังก์ชันแบบไม่ต่อเนื่องซึ่งได้แก่ฟังก์ชันแบบไบโพลาสเต็ป (bipolar step function) ดังนั้นสมการคณิตศาสตร์ของฟังก์ชันกระตุ้นแบบไบโพลาสเต็ปคือ

$$f(net) = \begin{cases} 1 & \text{if } net > 0 \\ -1 & \text{otherwise} \end{cases} \quad (3.11)$$

สัญญาณการเรียนรู้แสดงดังสมการ (3.7)

$$r = d_i - o_i \quad (3.12)$$

เมื่อ $o_i = f(u,w)$ และ d_i คือค่าเป้าหมายโดยการปรับค่าน้ำหนักแสดงดังสมการ (3.13)

$$\Delta w_{ij} = \eta [d_i - f(w_{ij}^T u)] x_j \quad \text{เมื่อ } j = 1, 2, 3 \dots n \quad (3.13)$$

การเรียนรู้แบบเปอร์เซปตรอนนำไปประยุกต์ใช้ได้เฉพาะระบบตัวเลขไบนารีเท่านั้น ดังนั้นแบบจำลองนี้จึงสามารถนำไปใช้ในการแยกข้อมูล 2 คลาสออกจากกัน ซึ่งการปรับค่าน้ำหนักจะถูกกระทำก็ต่อเมื่อค่าเอาต์พุตจากข่ายงานนิวรัลไม่ตรงกับค่าเป้าหมาย

3.4.2 ข่ายงานนิวรัลแบบอะดาไลน์ (ADALINE)


McClelland และ Rumelhart (1986) เสนอแบบจำลองของข่ายงานที่เรียกว่า ADALINE (ADaptive LINear Element) ที่ใช้กฎการเรียนรู้แบบเดลตาในการหาค่าน้ำหนัก

กฎการเรียนรู้แบบเดลตา (delta learning rule) เป็นการเรียนรู้แบบชี้นำเพียงชนิดเดียวที่ใช้กับฟังก์ชันกระตุ้นแบบต่อเนื่องซึ่งได้แก่ฟังก์ชันซิกมอยด์ และฟังก์ชันเกาส์เซียน ฟังก์ชันมูลฐานเป็นฟังก์ชันมูลฐานเชิงเส้น โครงสร้างของการเรียนรู้ของข่ายงานแบบอะดาไลน์มีชั้นของน้ำหนักเพียง 1 ชั้น (ดูรูปที่ 3.11) โดยมีนิยามของสัญญาณการเรียนรู้ (learning signal, r) ดังนี้

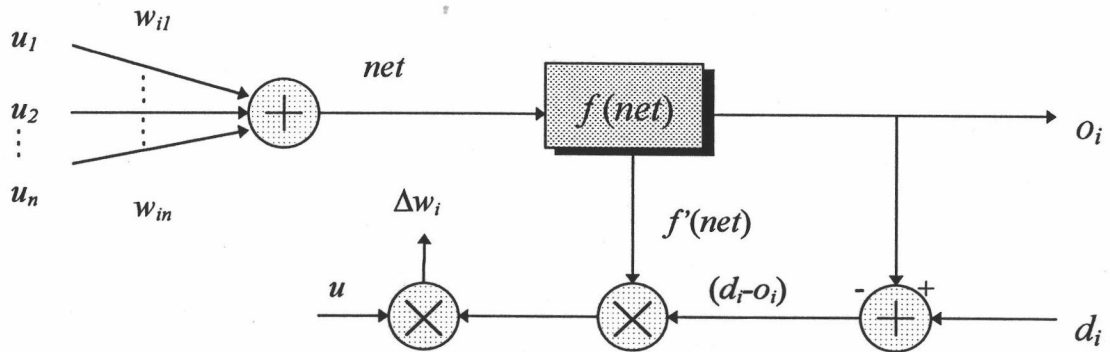
$$r = [d_i - f(\text{net})] f'(\text{net}) \quad (3.14)$$

เมื่อ $f'(\text{net})$ เป็นอนุพันธ์ของฟังก์ชันกระตุ้น, $f(\text{net})$ ซึ่งคำนวณจาก $\text{net} = w_{ij}u$

กฎการเรียนรู้สามารถหาได้จากค่าผิดพลาดระหว่าง o_i และ d_i ยกกำลังสอง การคำนวณเกรเดียนต์เวกเตอร์ (gradient vector) ได้จากการหาค่าอนุพันธ์ของค่าผิดพลาดเทียบกับ w_i เพื่อปรับค่าน้ำหนักซึ่งการเรียนรู้อยู่บนพื้นฐานการลดค่ากำลังสองของค่าความแตกต่างให้มีค่าน้อยที่สุด โดยมีนิยามดังนี้



รูปที่ 3.10 ข่ายงานแบบเปอร์เซปตรอน



รูปที่ 3.11 ข่ายงานแบบอะคาไลน์

$$\text{minimize } E = \frac{1}{2} \sum (d_i - o_i)^2 \quad (3.15)$$


เมื่อเปรียบเทียบการเรียนรู้ของข่ายงานแบบเซลล์กับเปอร์เซปตรอนพบว่ากฎการเรียนรู้แบบเซลล์ใช้ค่าความแตกต่างของค่าเป้าหมาย, d_i เอาที่พุทของข่ายงาน, o_i ป้อนกลับ โดยใช้การออปติไมซ์ แต่การเรียนรู้แบบเปอร์เซปตรอนใช้ค่าความแตกต่างระหว่างค่าเป้าหมายกับค่าเอาที่พุทของข่ายงานนิเวรลโดยตรงเพื่อใช้ในการปรับค่าน้ำหนัก

3. 4.3 ข่ายงานนิเวรลแบบการกระจายย้อนกลับ (Backpropagation neural network)

เนื่องจากข่ายงานนิเวรลชั้นเดียวแบบเปอร์เซปตรอนและ แบบอะคาไลนมีชั้นของน้ำหนักระดับเดียว ซึ่งสามารถแก้ปัญหาแบบเชิงเส้นเท่านั้น ต่อมาจึงได้มีการพัฒนาข่ายงานนิเวรลแบบกระจายย้อนกลับซึ่งเป็นข่ายงานแบบหลายชั้น เพื่อแก้ปัญหาแบบไม่เชิงเส้น โดยจำนวนชั้นในข่ายงานนิเวรลหมายถึงชั้นของน้ำหนักระดับ (weight layers) ชั้นน้ำหนักระดับจะเป็นตัวแทนของการเปลี่ยนแปลงแบบเชิงเส้นแต่ชั้นของนิเวรอนจะเกิดการเปลี่ยนแปลงแบบไม่เชิงเส้น ในทางปฏิบัติพบว่าชั้นซ่อนเพียงสองชั้นถือว่าเพียงพอต่อการแก้ปัญหาระบบต่าง ๆ ได้ทุกระบบ (สุรพล, 1995) ข่ายงานนิเวรลนี้จะใช้อัลกอริทึมการกระจายย้อนกลับ (backpropagation algorithm) ในการฝึกข่ายงานนิเวรล และใช้ฟังก์ชันมุลฐานเป็นฟังก์ชันเชิงเส้น ฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์ และโครงสร้างการเชื่อมโยงเป็นแบบป้อนไปข้างหน้า (feedforward)

3. 4.3.1 โครงสร้างของข่ายงานนิเวรลแบบกระจายย้อนกลับ

ข่ายงานนิเวรลแบบกระจายย้อนกลับแสดงในรูปที่ 3.12 ประกอบไปด้วยหลาย ๆ นิเวรอนที่มีการเชื่อมโยงแบบป้อนไปข้างหน้า



รูปที่ 3.12 ข่ายงานนิวรัลเปลี่ยนไปข้างหน้าแบบสองชั้น

โครงสร้างของข่ายงานประกอบไปด้วยชั้นของนิวรอนอยู่ 3 ชั้น ได้แก่

1. ชั้นอินพุท (input layer) ทำหน้าที่รับข้อมูลที่ใช้ในการฝึกข่ายงาน
2. ชั้นซ่อน (hidden layer) ทำหน้าที่รวมสัญญาณจากชั้นอินพุท และแปลงค่าโดยใช้

ฟังก์ชันกระตุ้น หลังจากนั้นจึงส่งสัญญาณที่ได้ให้แก่นิวรอนในชั้นเอาต์พุท โดยชั้นซ่อนมีได้มากกว่าหนึ่งชั้น

3. ชั้นเอาต์พุท (output layer) ทำหน้าที่รวมสัญญาณจากชั้นซ่อนและแปลงค่าโดยใช้ฟังก์ชันกระตุ้น หลังจากนั้นจึงส่งสัญญาณที่ได้เพื่อเป็นเอาต์พุทที่ออกจากข่ายงาน

ชั้นอินพุทประกอบด้วยนิวรอนที่ไม่มีการคำนวณใด ๆ แต่จะกระจายค่าอินพุทให้แก่ทุก ๆ นิวรอนในชั้นถัดไป ชั้นซ่อนอยู่ระหว่างชั้นอินพุทและชั้นเอาต์พุทซึ่งข่ายงานนิวรัลสามารถมีชั้นซ่อนหลายชั้นแต่จะพิจารณาในที่นี้เพียงชั้นเดียวเท่านั้น เพื่อความง่ายต่อการเข้าใจ และชั้นสุดท้ายคือชั้นเอาต์พุท โดยจะทำหน้าที่ส่งค่าเอาต์พุทสุดท้ายของข่ายงานนิวรัล นิวรอนในชั้นอินพุทรับค่าอินพุทเป็น I_1, \dots, I_{N_1} และมีน้ำหนักเป็น W_{1j}, \dots, W_{N_1j} ผลรวมน้ำหนักของอินพุทของนิวรอนลำดับที่ j ในชั้นซ่อนคือ

$$S_j = \sum_{i=1}^{N_1} w_{ij} I_i + b_j \quad 1 \leq j \leq N_2 \quad (3.16)$$

เอาต์พุทของนิวรอนลำดับที่ j ในชั้นซ่อนคือ

$$O_j = f(S_j) \quad 1 \leq j \leq N_2 \quad (3.17)$$

เอาต์พุทของนิวรอนในชั้นซ่อนใช้เป็นอินพุทให้แก่นิวรอนในชั้นเอาต์พุทอีกทอดหนึ่ง

$$S_k = \sum_{j=1}^{N_2} w_{jk} O_j + b_k \quad 1 \leq k \leq N_3 \quad (3.18)$$

นิเวรอนในชั้นเอาต์พุตสร้างเอาต์พุตของกระบวนการที่ถูกทำนายในช่วงหนึ่งคาบการเก็บตัวอย่าง (one sampling period) ดังแสดงในสมการ (3.19)

$$O_k = f(S_k) \quad (3.19)$$

เมื่อ b_i และ b_j เป็นเทอมไบอัส (bias term) ซึ่งเป็นน้ำหนัก โดยใช้ค่าอินพุตมีค่าเป็น 1 และ O_k หมายถึงค่าเอาต์พุตจากข่ายงานนิเวรล

เมื่อ f แทนด้วยฟังก์ชันกระตุ้น ฟังก์ชันกระตุ้นมักจะเป็นฟังก์ชันซิกมอยด์ (sigmoid function) โดยมีสมการดังนี้คือ

$$f(x) = \frac{1}{1 + e^{(-x)}} \quad (3.20)$$

และอนุพันธ์ของฟังก์ชันซิกมอยด์คือ

$$f'(x) = x(1 - x) \quad (3.21)$$

ค่าอนุพันธ์ของฟังก์ชันซิกมอยด์จะนำไปใช้ในอัลกอริทึมการกระจายย้อนกลับ ซึ่งจะกล่าวถึงในหัวข้อถัดไป


3.4.3.2 ตัวอย่างของการหาเอาต์พุตของข่ายงานแบบกระจายย้อนกลับ

สมมติว่าทราบค่าเมตริกซ์ของน้ำหนักของข่ายงานนี้ซึ่งข่ายงานนี้ได้รับการฝึกโดยใช้ อัลกอริทึมการกระจายย้อนกลับเพื่อหาค่าน้ำหนักแล้ว โดยข่ายงานมีโครงสร้างดังในรูปที่ 3.13

ก. การคำนวณค่าเอาต์พุตของนิเวรอนในชั้นซ่อนตัวแรก

$$0.0 * -4.8 + 1.0 * 4.6 - 2.6 = 2.0$$

กำหนดให้ข่ายงานนี้ใช้ฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์ และฟังก์ชันมาตรฐานเป็นฟังก์ชันมาตรฐานเชิงเส้น จากฟังก์ชันซิกมอยด์ในรูปที่ 3.8 (a) อินพุตเท่ากับ 2.0 จะได้เอาต์พุตของนิวรอนในชั้นซ่อนตัวแรกเป็น 0.88



รูปที่ 3.13 ตัวอย่างการคำนวณค่าเอาต์พุตของข่ายงานนิวรัล

ข. การคำนวณค่าเอาต์พุตของนิวรอนในชั้นซ่อนตัวที่สอง

$$0.0 * 5.1 + 1.0 * -5.2 - 3.2 = -8.4$$

จากฟังก์ชันซิกมอยด์ในรูปที่ 3.8 (a) อินพุตเท่ากับ -8.4 จะได้เอาต์พุตของนิวรอนในชั้นซ่อนตัวที่สองมีค่าเข้าใกล้ 0


ค. การคำนวณค่าเอาต์พุตของนิวรอนในชั้นเอาต์พุต

$$0.88 * 5.9 + 0.0 * 5.2 - 2.7 = 2.5$$

จากฟังก์ชันซิกมอยด์ในรูปที่ 3.8 (a) อินพุตเท่ากับ 2.5 เอาต์พุตของนิวรอนในชั้นเอาต์พุตเป็น 0.92 ดังนั้นข่ายงานในตัวอย่างนี้ให้ค่าเอาต์พุตเป็น 0.92

3.5 อัลกอริทึมการกระจายย้อนกลับ (Backpropagation algorithm)

Werbos (1974) พัฒนาอัลกอริทึมการกระจายย้อนกลับ (backpropagation algorithm) Rumelhart (1986) เสนออัลกอริทึมนี้อีกครั้งทำให้อัลกอริทึมนี้เป็นที่รู้จักกันอย่างกว้างขวาง และเป็นอัลกอริทึมมาตรฐานที่ใช้ในการฝึกข่ายงาน อัลกอริทึมการกระจายย้อนกลับเป็นวิธีที่คำนวณเกรเดียนต์อย่างได้ผล (Kung, 1993) ข่ายงานนิเวศแบบการกระจายย้อนกลับที่มีฟังก์ชันมูลฐานเป็นฟังก์ชันมูลฐานเชิงเส้น และมีฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์มีสมการทางไดนามิกดังสมการ (3.22) และ (3.23) และแสดงในรูปที่ 3.14




รูปที่ 3.14 แสดงแบบจำลองของนิวรอนในชั้นที่ l

$$u_i(l) = \sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l) \quad (3.22)$$

$$a_i(l) = f(u_i(l)) \quad 1 \leq i \leq N_i; \quad 1 \leq l \leq L \quad (3.23)$$

รูปที่ 3.15 แสดงข่ายงานนิเวศสามชั้นแบบไม่เชิงเส้น เมื่ออินพุตคือ $x_i \equiv a_i(0)$ และเอาต์พุตแทนด้วย $y_i \equiv a_i(L)$ เมื่อ L คือจำนวนชั้นทั้งหมดของข่ายงานนิเวศ



รูปที่ 3.15 ข่ายงานนิวรัลแบบหลายชั้น ซึ่งแสดงชั้นของน้ำหนักสามชั้น

3.5.1 วิธีการออปติไมซ์ (Optimization method)

อัลกอริธึมการกระจายย้อนกลับต้องการลดค่าผิดพลาดกำลังสองระหว่างค่าเป้าหมายกับผลลัพธ์จากข่ายงาน โดยใช้วิธีการออปติไมซ์ (optimization method) ซึ่งแสดงในสมการที่

(3.24)

$$\text{minimize } E = \frac{1}{2} \sum_{i=1}^{N_t} (t_i - a_i(L))^2 \quad (3.24)$$

subject to: $t_{max} > t_i > t_{min}$

$$a_{max} > a_i(L) > a_{min}$$

เมื่อ t_i คือค่าเป้าหมาย $a_i(L)$ คือค่าเอาต์พุทของข่ายงาน t_{max} และ t_{min} คือค่าสูงสุด และต่ำสุดของค่าเป้าหมาย a_{max} และ a_{min} คือค่าสูงสุด และค่าต่ำสุดของเอาต์พุทของข่ายงาน ถ้า

ทราบอนุพันธ์ย่อย (partial derivative) ของค่าผิดพลาดเทียบกับค่าน้ำหนักแต่ละค่าจะทำให้รู้ทิศทางที่น้ำหนักไปในทิศทางที่ลดค่าผิดพลาด สำหรับอัลกอริทึมการกระจายย้อนกลับจะทำการปรับค่าน้ำหนัก (w_{ij}) เพื่อให้ค่า E มีค่าต่ำสุด สมการการเรียนรู้แบบเกรเดียนต์แสดงในสมการ (3.25)

$$w_{ij}^{new}(l) = w_{ij}^{old}(l) + \Delta w_{ij}(l) \quad (3.25)$$

อนุพันธ์ของค่าผิดพลาดจะใช้วิธีการตามเทคนิคของกฎลูกโซ่ (Chain rule)

$$\begin{aligned} \Delta w_{ij}(l) &= -\eta \frac{\partial E}{\partial w_{ij}(l)} \\ &= -\eta \frac{\partial E}{\partial a_i(l)} \frac{\partial a_i(l)}{\partial w_{ij}(l)} \end{aligned} \quad (3.26)$$

จากสมการ (3.26) นำมาแยกพิจารณาที่ละเทอมและจากสมการ (3.22) และ (3.23) จะได้

$$\begin{aligned} \frac{\partial a_i(l)}{\partial w_{ij}(l)} &= \frac{\partial f(u_i(l))}{\partial w_{ij}(l)} \\ &= \frac{\partial f(\sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l))}{\partial w_{ij}(l)} \\ &= f'(u_i(l))a_j(l-1) \end{aligned} \quad (3.27)$$

กำหนดให้สัญญาณความผิดพลาด, $\delta_i(l)$ เป็น

$$\delta_i(l) = -\frac{\partial E}{\partial a_i(l)} \quad (3.28)$$

สมการ (3.27) และ (3.28) แทนในสมการ (3.26) จะได้สมการ (3.29)

$$\Delta w_{ij}(l) = \eta \delta_i(l) f'(u_i(l)) a_j(l-1) \quad (3.29)$$

ก. ค่าสัญญาณความแตกต่างในชั้นเอาท์พุทสามารถหาได้จากการแทนค่า E ลงในสม

การ (3.28)

$$\begin{aligned}\delta_i(L) &= -\frac{\partial E}{\partial a_i(L)} \\ &= -\frac{\partial\left(\frac{1}{2}\sum_{i=1}^N(t_i - a_i(L))^2\right)}{\partial a_i(L)} \\ &= -\frac{1}{2}(2)(t_i - a_i(L))(-1) \\ \delta_i(L) &= t_i - a_i(L)\end{aligned}\tag{3.30}$$

ข. ค่าสัญญาณความแตกต่างในชั้นซ่อนคือ

$$\begin{aligned}\delta_i(l) &= -\frac{\partial E}{\partial a_i(l)} \\ &= -\sum_{j=1}^{N_{l+1}} \frac{\partial E}{\partial u_j(l+1)} \frac{\partial u_j(l+1)}{\partial a_i(l)}\end{aligned}\tag{3.31}$$

สมการ (3.31) นำมาแยกพิจารณาทีละเทอม โดยพิจารณาเทอมแรกจะได้

$$\begin{aligned}-\frac{\partial E}{\partial u_i(l+1)} &= -\frac{\partial\left(\frac{1}{2}(t_i - a_i(L))^2\right)}{\partial u_i(l+1)} \\ &= (t_i - a_i(L)) \frac{\partial a_i(L)}{\partial u_i(l+1)}\end{aligned}$$

สมการ (3.23) แทนค่าลงใน $a_i(L)$ จะได้

$$-\frac{\partial E}{\partial u_i(l+1)} = (t_i - a_i(L)) \frac{\partial f(u_i(L))}{\partial u_i(l+1)}$$

ในกรณีนี้ $L = l+1$ ดังนั้น

$$-\frac{\partial E}{\partial u_i(l+1)} = (t_i - a_i(L))f'(u_i(l+1))$$

สมการ (3.30) แทนค่า $(t_i - a_i(L))$ จะได้

$$-\frac{\partial E}{\partial u_i(l+1)} = \delta_i(l+1)f'(u_i(l+1)) \quad (3.32)$$

สมการ (3.31) เทอมที่ 2 ที่ได้จากการแทนสมการ (3.22) คือ

$$\begin{aligned} \frac{\partial u_i(l+1)}{\partial a_i(l)} &= \frac{\partial(w_{ij}(l+1)a_i(l) + \theta_i(l+1))}{\partial a_i(l)} \\ &= w_{ij}(l+1) \end{aligned} \quad (3.33)$$

สมการ (3.32) และ (3.33) แทนในสมการ (3.31) โดย $l = L - 1, \dots, 1$ จะได้สัญญาณความแตกต่างในชั้นซ่อนคือ

$$\delta_i(l) = \sum_{j=1}^{N_{l+1}} \delta_j(l+1)f'(u_i(l+1))w_{ij}(l+1) \quad (3.34)$$

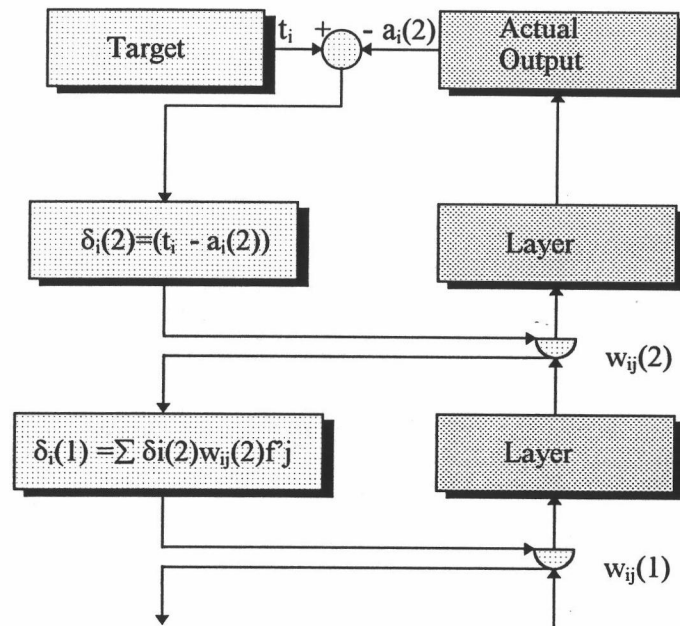
ถ้ามีชั้นซ่อนจำนวน n ชั้นต้องคำนวณหาค่าสัญญาณความแตกต่างในสมการ (3.34) จำนวน n ครั้งเพื่อนำไปใช้เป็นเฟคเตอร์ในการปรับค่าน้ำหนัก

แทนค่าสมการ (3.29 ลงในสมการ (3.25) ค่าน้ำหนักเชื่อมโยงระหว่างชั้นที่ l กับชั้นที่ $l-1$ สามารถปรับค่าโดยความสัมพันธ์ดังนี้ (ตามลำดับของ $l = L-1, \dots, 1$)

$$w_{ij}^{new}(l) = w_{ij}^{old}(l) + \eta \delta_i(l)f'(u_i(l))a_i(l-1) \quad (3.35)$$

สำหรับการเรียนรู้ที่ใช้อัลกอริทึมการกระจายย้อนกลับสัญญาณความแตกต่างของชั้นที่ต่ำกว่า $\delta_i(l)$ สามารถคำนวณได้โดยการรวมสัญญาณความแตกต่างของชั้นที่อยู่เหนือกว่า, $\delta_i(l+1)$ ดัง

นั้นสัญญาณความแตกต่างจึงสามารถกระจายย้อนกลับผ่านชั้นทั้งหมดจากชั้นบนลงสู่ชั้นล่าง ซึ่งหมายถึงว่าชั้นอยู่เหนือกว่าจะมีอิทธิพลต่อชั้นที่อยู่ต่ำกว่าซึ่งแสดงในรูปที่ 3.16



รูปที่ 3.16 อัลกอริธึมการกระจายย้อนกลับ (backpropagation) สำหรับข่ายงานนิวรัลแบบสองชั้น

3.5.2 ขั้นตอนของอัลกอริธึมการกระจายย้อนกลับ

อัลกอริธึมการกระจายย้อนกลับสำหรับข่ายงานนิวรัลแบบสองชั้น ซึ่งแสดงในรูปที่

3.12 ต้องกำหนดจำนวนคู่ลำดับของอินพุต, u_i และค่าเป้าหมาย, t_i จำนวน p คู่

$$\{(u_1, t_1), (u_2, t_2), (u_3, t_3), \dots, (u_p, t_p)\} \quad (3.36)$$

ก. ขั้นตอนที่ 1 กำหนดค่าอัตราการเรียนรู้ (learning rate, η) ให้มีค่ามากกว่าศูนย์ กำหนดค่าผิดพลาดต่ำสุด (E_{min}) และกำหนดค่าเริ่มต้นให้กับน้ำหนัก (weight) ที่เชื่อมต่อระหว่าง นิวรอนแต่ละชั้น $w_{ij}(1)$, $w_{ij}(2)$ โดยใช้ตัวเลขสุ่มค่าน้ำหนักที่มีค่าน้อย ๆ กำหนดข้อมูลคู่แรก เข้ามา $p = 1$ ค่าผิดพลาดเริ่มต้น $E = 0$ และเริ่มการเรียนรู้ $q = 1$

ข. ขั้นตอนที่ 2 ส่งอินพุตและ ค่าเป้าหมายที่สอดคล้องกันให้นิวรอนของชั้นอินพุตเพื่อรับข้อมูลซึ่งคือ $u = u_p$, $t = t_p$ และคำนวณค่าผลลัพธ์ให้นิวรอนในชั้นซ่อน และ ชั้นเอาต์พุต โดยใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น

ค. ขั้นตอนที่ 3 คำนวณค่าผิดพลาด

$$E^{new} = E^{old} + \frac{1}{2} \sum_{i=1}^{N_3} \{t_i - a_i(2)\}^2 \quad (3.37)$$

เมื่อ N_3 คือจำนวนนิวรอนในชั้นเอาต์พุต t_i คือค่าเป้าหมายของนิวรอนในชั้นเอาต์พุตตัวที่ i และ a_i คือเอาต์พุตของนิวรอนในชั้นเอาต์พุตตัวที่ i

ง. ขั้นตอนที่ 4 คำนวณค่าเวกเตอร์สัญญาณความผิดพลาด

สัญญาณความผิดพลาดสำหรับชั้นเอาต์พุต

$$\delta_i(2) = (t_i - a_i(2)) \quad \text{เมื่อ } i = 1, 2, \dots, N_3 \quad (3.38)$$

สัญญาณความผิดพลาดสำหรับชั้นซ่อน

$$\delta_i(1) = \left(\sum_{j=1}^{N_3} \delta_j(2) W_{ij}(2) \right) a_i(1) (1 - a_i(1)) \quad \text{เมื่อ } i = 1, 2, \dots, N_2 \quad (3.39)$$

ในกรณีที่มีจำนวนชั้นซ่อน n ชั้นต้องหาค่าสัญญาณความผิดพลาด n ครั้งด้วย

จ. ขั้นตอนที่ 5 ปรับค่าน้ำหนักที่เชื่อมระหว่างชั้นเอาต์พุตกับชั้นซ่อน

$$W_{ij}(2)^{new} = W_{ij}(2)^{old} + \eta \delta_i(2) a_j(1) \quad (3.40)$$

เมื่อ $i=1, 2, \dots, N_3$ และ $j=1, 2, \dots, N_2$

ฉ. ขั้นตอนที่ 6 ปรับค่าน้ำหนักที่เชื่อมระหว่างชั้นอินพุตกับชั้นซ่อน

$$W_{ij}(1)^{new} = W_{ij}(1)^{old} + \eta \delta_i(1) a_j(0) \quad (3.41)$$

เมื่อ $j=1, 2, \dots, N_2$ และ $i=1, 2, \dots, N_1$

ข. ขั้นตอนที่ 7 ตรวจสอบชุดข้อมูลการเรียนรู้

ถ้าชุดข้อมูลยังไม่ถูกทำงานจนครบรอบ ($p < P$) ให้ส่งข้อมูลของชุดถัดไป ไปยังนิเวศในชั้นอินพุต โดยที่ $p = p + 1$ และ $q = q + 1$ แล้วจึงกลับไปทำขั้นตอนที่ 2 แต่ถ้าชุดข้อมูลได้ถูกเรียนรู้จนครบแล้ว ($p = P$) ให้ไปดำเนินการขั้นตอนที่ 8

ข. ขั้นตอนที่ 8 ตรวจสอบค่าความผิดพลาดกับค่าต่ำสุดที่ตั้งไว้

ขั้นตอนการเรียนรู้จะเสร็จสมบูรณ์เมื่อ ค่าความผิดพลาดในการเรียนรู้มีค่าน้อยกว่าค่าความผิดพลาดต่ำสุดที่ตั้งไว้ ($E < E_{min}$) ถ้า $E > E_{min}$ แล้วให้ $E = 0$ และ $p = 1$ แล้วเริ่มวงจรการเรียนรู้ใหม่ตามขั้นตอนที่ 2 ในรูปที่ 3.16 เป็นไดอะแกรมของอัลกอริทึมการกระจายย้อนกลับ

3.6 การเรียนรู้โดยใช้โมเมนตัม

การเรียนรู้โดยใช้โมเมนตัมช่วยเร่งให้การเรียนรู้ของข่ายงานเข้าสู่ค่าเป้าหมายได้เร็วขึ้น โดยการนำค่าน้ำหนักล่าสุดมาใช้ในการปรับค่าน้ำหนักในปัจจุบันตามขั้นตอนที่ 5 และขั้นตอนที่ 6 ในหัวข้อ 3.5.2 ตามสัดส่วนของค่าโมเมนตัมดังสมการ (3.42)

$$\Delta w(t) = -\eta \nabla E(t) + \alpha \Delta w(t-1) \quad (3.42)$$

เมื่อ α คือ แฟคเตอร์โมเมนตัมที่มักเลือกค่าอยู่ระหว่าง 0 - 1 รูปที่ 3.17 แสดงวิธีการเร่งการเรียนรู้ของข่ายงานโดยใช้โมเมนตัม และการเรียนรู้เริ่มต้นที่จุด A' ค่าเกรเดียนท์ของค่า

ความผิดพลาดเมื่อเทียบกับค่านำหนัก $\partial E/\partial w_1$ และ $\partial E/\partial w_2$ ที่จุด A' , และ A'' มีเครื่องหมายตรงกัน ดังนั้นองค์ประกอบเกรเดียนท์จะถูกลำมารวมกันซึ่งทำให้การเข้าสู่เป้าหมายรวดเร็วขึ้น โดยการปรับน้ำหนักที่จุด A'' ซึ่งอาศัยค่านำหนักที่จุด A' เข้ามาร่วมด้วยตามสัดส่วนของค่าโมเมนตัม

3.7 บทสรุป

ในบทนี้เป็นการกล่าวถึงทฤษฎีทั่ว ๆ ไปของข่ายงานนิเวรต์ อัลกอริทึมการกระจายย้อนกลับ และการเรียนรู้โดยใช้โมเมนตัม บทที่ 4 จะเป็นเนื้อหาเกี่ยวกับการนำข่ายงานนิเวรต์ไปประยุกต์ใช้กับวิศวกรรมเคมี โดยพิจารณาถึงโครงสร้างการเรียนรู้ โครงสร้างการควบคุม และการระบุกระบวนการ