


## บทที่ 2

### เครือข่ายนิวรอล (Neural Network)

ในบทนี้ได้กล่าวถึงความเป็นมาของเครือข่ายนิวรอล การแบ่งประเภทและรายละเอียดเกี่ยวกับเครือข่ายนิวรอลชนิดที่ใช้ในวิทยานิพนธ์ ได้แก่ แบบจำลองคณิตศาสตร์ การเชื่อมต่อและการเรียนรู้ของ NN ซึ่งจะเสนอตามลำดับดังนี้

#### ความเป็นมาของเครือข่ายนิวรอล

เครือข่ายนิวรอล คือ แบบจำลองทางคณิตศาสตร์ที่พัฒนาขึ้นมา เพื่อจำลองการทำงานของเครือข่ายเซลล์ประสาทในสมองของมนุษย์ ด้วยจุดประสงค์ที่จะสร้างเครื่องมือ ซึ่งมีความสามารถในการเรียนรู้ การจำ การอนุมานความรู้(knowledge deduction) และการอุปมาความรู้(knowledge induction) เช่นเดียวกับความสามารถที่มีในสมองของมนุษย์ โดยทั่วไป NN ประกอบด้วยปมนิวรอลและแขนเชื่อมต่อระหว่างปม นิวรอลมีหน้าที่จัดการสัญญาณที่ได้รับจากปมอื่นผ่านทางแขนของปมแล้วส่งออกไปแก่ปมถัดไป ส่วนวิธีการจัดการสัญญาณภายในปมจะแตกต่างกันไปตามชนิดของ NN แขนของปมนอกจากมีหน้าที่รับส่งสัญญาณผ่านระหว่างปมแล้ว ยังมีหน้าที่ขยายหรือลดทอนขนาดของสัญญาณ ซึ่งอัตราขยายหรือลดทอนถูกกำหนดด้วยค่าน้ำหนัก(weight) ของแขน ตัวอย่างของ NN แบบหนึ่งแสดงในรูปที่ 2-1



รูปที่ 2-1 ตัวอย่างเครือข่ายนิวรอล

การพัฒนา NN ได้เริ่มต้นขึ้นในค.ศ. 1943 McCulloch และ Pitts ได้พัฒนาแบบจำลอง NN ขึ้นและได้ประยุกต์ใช้กับการคำนวณทางตรรกศาสตร์ ต่อมา D. Hebb ได้เสนออัลกอริทึม Hebb Learning Rule ซึ่งทำให้แบบจำลอง NN ของ McCulloch และ Pitts สามารถเรียนรู้ได้ ในค.ศ. 1958 F. Rosenblatt ได้ประดิษฐ์เครื่อง Perceptron ซึ่งมีความสามารถเรียนรู้และแยกแยะชนิดของรูปแบบได้(pattern classification) ในค.ศ. 1960 B. Widrow และ M. Hoff ได้เสนอแบบจำลอง ADALINE (ADaptive LINEar combiner)ซึ่งสามารถจำและแยกแยะรูปแบบชนิดต่างๆและเสนออัลกอริทึม Widrow & Hoff สำหรับการเรียนรู้ของ ADALINE ในค.ศ. 1972 S. Amari ได้พัฒนาทฤษฎีคณิตศาสตร์ของแบบจำลอง NN ขึ้น รวมถึงการวิเคราะห์แบบจำลองและอัลกอริทึมสำหรับการเรียนรู้ของ NN ในค.ศ. 1980 K. Fugushima และ Miyaka ได้พัฒนา Neocognitron ขึ้น Neocognitron เป็น NN ทำหน้าที่จำลองการทำงานของเรตินาในดวงตาของมนุษย์และประยุกต์ใช้ในการจำภาพ 2 มิติ ในค.ศ. 1982 T. Kohonen และ J. Anderson ได้พัฒนา Associative Memory และอัลกอริทึมสำหรับการเรียนรู้ขึ้น ในปีเดียวกันนี้ T. Kohonen ได้พัฒนา Self-organizing Map สำหรับจำรูปร่างของวัตถุ และ J. Hopfield ได้พัฒนา Recurrent Associative Memory ซึ่งมีความสามารถในการเรียนรู้แบบลำดับ(sequential learning) ในค.ศ. 1986 J. McClelland และ D. Rumelhart ได้เสนอ Backpropagation Neural Network (BNN) และอัลกอริทึม Backpropagation สำหรับการเรียนรู้ BNN เป็น NN ชนิดหลายชั้นและมีความสามารถในการประมาณค่าฟังก์ชัน นอกจากนี้ยังมีการพัฒนาแบบจำลอง NN แต่ละชนิดที่ได้กล่าวมาให้มีประสิทธิภาพดีขึ้น ได้แก่

Counterpropagation Network โดย Hecht-Neilson(1987)

Hamming Net และ Maxnet โดย Lippman(1987)

Adaptive Resonance Network โดย G. carpenter และ S. Grossberg(1987)

Adaptive BAM โดย B. Kosko(1987)

Bidirectional Associative Memory(BAM) โดย B. Kosko(1988)

Wavelet Network โดย Zhang และ Benveniste(1992)



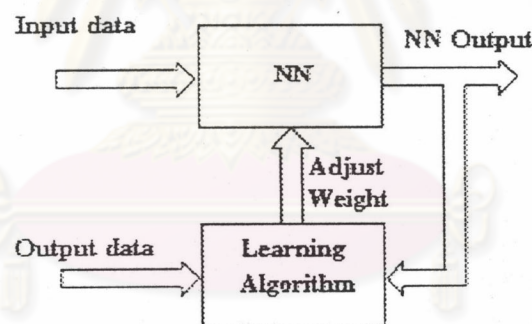
## ประเภทของเครือข่ายนิวรอล

จากการพัฒนาเครือข่ายนิวรอลที่ได้กล่าวมาแล้ว NN แต่ละชนิดมีคุณสมบัติที่แตกต่างกันไปตามวิธีการเรียนรู้ โครงสร้างการเชื่อมต่อภายใน และลักษณะการทำงาน การแบ่งประเภทของ NN ได้แบ่งตามคุณสมบัติที่สำคัญ ซึ่งมีดังนี้ (Jacek,1993)

### 1) การเรียนรู้ของ NN มี 2 แบบ คือ

#### 1.1) การเรียนรู้โดยใช้การแนะนำ(supervised learning)

ความรู้ที่ใช้ในการเรียนรู้วิธีนี้ ประกอบด้วย 2 ส่วน คือ ข้อมูลอินพุต คือ ข้อมูลที่แสดงถึงรูปแบบ(pattern)หรือสถานะของความรู้ และข้อมูลเอาต์พุต คือ ข้อมูลที่แสดงถึงระดับหรือผลตอบสนองต่อข้อมูลอินพุต การเรียนรู้ของ NN ทำโดยป้อนข้อมูลอินพุตให้แก่ NN แล้วนำข้อมูลเอาต์พุตมาเปรียบเทียบกับค่าเอาต์พุตของ NN จากนั้นนำความแตกต่างระหว่างค่าทั้งสองไปปรับค่าพารามิเตอร์ของ NN เพื่อให้ NN สามารถจำข้อมูลอินพุตและส่งเอาต์พุตออกมาเท่ากับข้อมูลเอาต์พุตที่ให้เรียนรู้ การเรียนรู้ด้วยวิธีนี้แสดงในรูปที่ 2-2

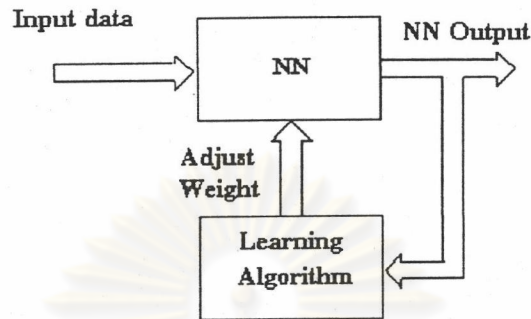


รูปที่ 2-2 การเรียนรู้ของเครือข่ายนิวรอลโดยใช้การแนะนำ

#### 1.2) การเรียนรู้โดยไม่ใช้การแนะนำ (unsupervised learning)

การเรียนรู้ของวิธีนี้ ใช้ในกรณีที่ความรู้ประกอบด้วยข้อมูลอินพุตเพียงอย่างเดียว ไม่มีความรู้ในรูปของข้อมูลเอาต์พุตสำหรับเปรียบเทียบเพื่อปรับค่าพารามิเตอร์ของ NN การปรับค่าพารามิเตอร์จึงใช้เฉพาะค่าเอาต์พุตของ NN การปรับสามารถทำได้หลายวิธี โดยแต่ละวิธีมีจุดประสงค์เพื่อให้ NN สามารถจำ

และแยกแยะรูปแบบ(pattern classification)ของข้อมูลอินพุตได้ การเรียนรู้ของวิธีนี้แสดงในรูปที่ 2-3



รูปที่ 2-3 การเรียนรู้ของเครือข่ายนิวรอลโดยไม่ใช้การแนะนำ

## 2) การเชื่อมต่อภายในของเครือข่ายนิวรอล

### 2.1) การเชื่อมต่อแบบป้อนไปข้างหน้า (feedforward connection)

เป็นการเชื่อมต่อ ซึ่งมีการส่งผ่านสัญญาณไปในทิศทางเดียว โดยมีทิศทางจากส่วนอินพุตของ NN ไปสู่ส่วนเอาต์พุตของ NN ดังแสดงในรูปที่ 2-4



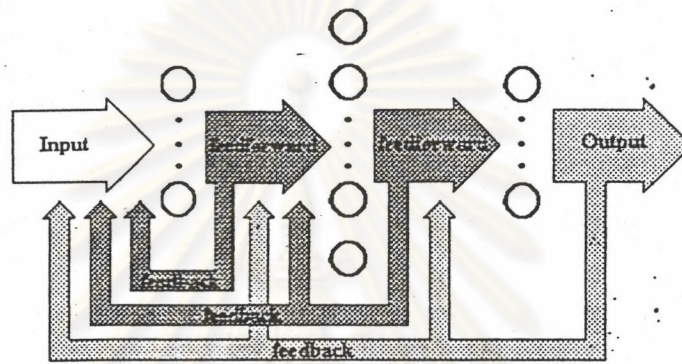
รูปที่ 2-4 การเชื่อมต่อของเครือข่ายนิวรอลแบบป้อนไปข้างหน้า

## 2.2) การเชื่อมต่อแบบหมุนเวียน (recurrent connection)

เป็นการเชื่อมต่อ ซึ่งมีการส่งผ่านสัญญาณ 2 ทิศทาง คือ

- ก) ทิศทางจากส่วนอินพุตของ NN ไปสู่ส่วนเอาต์พุตของ NN หรือป้อนไปข้างหน้า (feedforward)
- ข) ทิศทางจากส่วนเอาต์พุตไปสู่ส่วนอินพุต หรือ ป้อนกลับ (feedback)

รูปแสดงการเชื่อมต่อชนิดนี้ แสดงดังในรูป 2-5



รูปที่ 2-5 การเชื่อมต่อของเครือข่ายนิรอลแบบหมุนเวียน

## 3) ภาวะการทำงานของเครือข่ายนิรอล แบ่งออกเป็น 2 ภาวะ คือ

3.1) ภาวะการทำงานในโดเมนเวลาที่ต่อเนื่อง (continuous-time operation mode)

3.2) ภาวะการทำงานในโดเมนเวลาที่ไม่ต่อเนื่อง (discrete-time operation mode)

การแบ่งประเภทของเครือข่ายนิรอลชนิดต่างๆ ได้แสดงไว้ในตารางที่ 2-11



ตารางที่ 2-1 การแบ่งประเภทของเครือข่ายนิวรอล

ชนิดเครือข่ายนิวรอล	วิธีการเรียนรู้ *	การเชื่อมต่อ *	ภาวะการทำงาน *
	Sup , Unsup	FF , REC	CT , DT
Single-layer Perceptrons	Sup	FF	CT , DT
Backpropagation Neural Network	Sup	FF	CT , DT
Linear Associative Memory	Sup	FF	CT , DT
Autoassociative Memory	Sup	REC	CT , DT
BAM และ Adaptive BAM	Sup	REC	CT , DT
Selforganized Map	Unsup	FF	CT , DT
Temporal Associative Memory	Sup	REC	CT , DT
Counterpropagation Network	Sup , Unsup	FF	CT , DT
Hamming Net	Unsup	FF	CT , DT
Maxnet	Unsup	REC	CT , DT
Adaptive Resonance Network	Unsup	REC	CT , DT
Wavelet Network	Sup	FF	CT , DT

\* หมายเหตุ

Sup หมายถึง Supervised learning และ Unsup หมายถึง Unsupervised learning

FF หมายถึง Feed-Forward connection และ REC หมายถึง REcurrent Connection

CT หมายถึง Continuous-Time mode และ DT หมายถึง Discrete-Time mode

สำหรับเครือข่ายนิวรอลที่ใช้ในวิทยานิพนธ์ ได้เลือกเครือข่ายนิวรอลชนิด


Backpropagation สำหรับการใช้งาน ด้วยเหตุผลดังนี้

- เป็น NN ซึ่งมีการเรียนรู้แบบใช้การแนะนำ(supervised learning)
- มีความสามารถในการประมาณค่าฟังก์ชันและสามารถสร้างความสัมพันธ์ในรูปแบบฟังก์ชันขึ้นได้จากข้อมูลที่ให้เรียนรู้ คุณสมบัตินี้ได้พิสูจน์โดย Cybenko (1989)
- เป็น NN ชนิดหลายชั้น ซึ่งการเพิ่มจำนวนชั้นทำให้สามารถจำรูปแบบที่ซับซ้อนและประมาณค่าที่ซับซ้อนได้มากขึ้น

รายละเอียดเกี่ยวกับ NN ชนิดนี้ได้แสดงไว้ในหัวข้อดังต่อไปนี้

### เครือข่ายนิวรอลชนิด Backpropagation


เครือข่ายนิวรอลชนิด Backpropagation (BNN) เป็น NN ชนิดหลายชั้น มีการเรียนรู้แบบใช้การแนะนำ (supervised learning) และมีความสามารถในการประมาณค่าฟังก์ชัน ภายใน BNN ประกอบด้วย ปมนิวรอล ปมไบแอสซึ่งเป็นปมที่มีค่าเอาท์พุตเท่ากับ 1 ตลอดเวลาและแขนเชื่อมต่อระหว่างปม การเชื่อมต่อภายในของ BNN ใช้การเชื่อมต่อแบบป้อนไปข้างหน้า(feedforward connection) ดังแสดงในรูปที่ 2-6 วงกลมแทนปมนิวรอล สี่เหลี่ยมแทนปมไบแอสและเส้นตรงแทนแขนเชื่อมต่อ



รูปที่ 2-6 เครือข่ายนิวรอลชนิด Backpropagation

การจัดเรียงปมภายใน BNN แบ่งปมออกเป็นชั้นๆ ได้แก่ ชั้นนอกสุดทางซ้าย หรือชั้นอินพุต(input layer) ถัดมาทางขวาคือชั้นซ่อนภายใน(hidden layer)และชั้นนอกสุดทางขวาหรือชั้นเอาต์พุต(output layer) ปมนิวรอลในชั้นอินพุตทำหน้าที่รับสัญญาณอินพุตหรือข้อมูลอินพุตเข้าแล้วส่งออกไปให้แก่ปมนิวรอลในชั้นภายใน ปมนิวรอลในชั้นภายในทำหน้าที่เข้ารหัสความรู้(knowledge encoding)จากสัญญาณที่ได้รับ แล้วส่งสัญญาณรหัสออกไปให้แก่ปมนิวรอลในชั้นเอาต์พุต ปมนิวรอลในชั้นเอาต์พุตทำหน้าที่ตัดสินใจแล้วส่งสัญญาณออกเป็นค่าเอาต์พุตของ BNN

จากภาพรวมกว้างๆเกี่ยวกับการทำงานของ BNN ต่อไปจะกล่าวถึงสมการคณิตศาสตร์สำหรับปมนิวรอลของ BNN ในรูปที่ 2-7



รูปที่ 2-7 ปมนิวรอลของเครือข่ายนิวรอลชนิด Backpropagation

สมการปมนิวรอลของ BNN คือ 
$$y = \sigma \left( \sum_{i=1}^N w_i \cdot x_i + wb \right) \quad (2-1)$$

โดยที่  $y$  คือ ค่าเอาต์พุตของปม

$x_i$  คือ ค่าอินพุตของแชนที่  $i$  ของปม

$w_i$  คือ ค่าน้ำหนักของแชนที่  $i$  ของปม

$wb$  คือ ค่าน้ำหนักไบแอสของปม


$N$  คือ จำนวนแชนของปม

$\sigma(x) = 1/(1+\exp(-a \cdot x))$  เรียก  $\sigma(.)$  ว่าฟังก์ชันซิกมอยด์

และ  $a$  คือค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์



กราฟของฟังก์ชันซิกมอยด์ที่ค่า  $a$  ต่างๆกัน แสดงในรูป



รูปที่ 2-8 กราฟของฟังก์ชันซิกมอยด์ ที่ค่า  $a$  ต่างๆ

ฟังก์ชันซิกมอยด์เป็นฟังก์ชันต่อเนื่องและมีค่าไม่ลดลง (monotonic and non-decreasing) โดยมีค่าเพิ่มจาก 0 ไปยัง 1 เมื่อค่า  $x$  เปลี่ยนจากค่า  $-\infty$  ไปยังค่า  $+\infty$  ค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์เป็นค่าที่กำหนดระยะเวลาเปลี่ยนขนาดจาก 0 ไปยัง 1 ของฟังก์ชันซิกมอยด์ ถ้ามีค่าน้อย ระยะเวลาเปลี่ยนมีค่ากว้าง ในทางกลับกันถ้ามีค่ามาก ระยะเวลาเปลี่ยนแปลงจะแคบ ข้อดีของฟังก์ชันซิกมอยด์ คือ ทำให้ BNN มีคุณสมบัติของฟังก์ชันต่อเนื่องและมีค่าอนุพันธ์ ซึ่งสามารถใช้เทคนิคการอพติไมเซชันแบบเกรเดียนต์ สร้างอัลกอริทึมการเรียนรู้ของ BNN ได้

ต่อไปเป็นการแปลง BNN ให้อยู่ในรูปสมการคณิตศาสตร์ เพื่อให้ทราบถึงนิยามของสัญลักษณ์ต่างๆที่ใช้ใน BNN อันเป็นการช่วยเสริมความเข้าใจเพื่อความสะดวกในการคำนวณหาอัลกอริทึมการเรียนรู้ของ BNN การนำเสนอ BNN ได้จัดเรียงตามลำดับดังนี้

สำหรับ BNN ที่มีจำนวนชั้นเท่ากับ  $L$  และจำนวนปมในชั้นที่  $l$  เท่ากับ  $N_l$  โดย  $l = 1, 2, \dots, L$  สามารถเขียนสมการปมนิเวรอลที่ชั้นต่างๆ ได้ดังนี้  
 ปมนิเวรอลในชั้นอินพุตมีหน้าที่แตกต่างจากปมในชั้นอื่น คือทำหน้าที่รับสัญญาณอินพุตเข้าแล้วส่งออกไปให้ปมในชั้นถัดไป สมการปมอินพุตปมที่  $n$  ในชั้นอินพุตหรือชั้นที่ 1 คือ

$$y_n^1(k) = x_n(k) \quad (2-2)$$

โดยที่  $n = 1, 2, \dots, N_1$

$x_n(k)$  คือค่าอินพุตที่ป้อนให้แก่ปม  $n$  ที่เวลา  $k$  ในชั้นอินพุตของ BNN

และ  $y_n^1(k)$  คือค่าเอาต์พุตของปม  $n$  ที่เวลา  $k$  ในชั้นอินพุตของ BNN

ส่วนปมนิเวรอลในชั้นซ่อนภายใน(hidden layer)และชั้นเอาต์พุต ซึ่งทำหน้าที่เข้ารหัสความรู้และตัดสินใจ มีสมการปมเช่นเดียวกับสมการ(2-1) สมการปมนิเวรอลปมที่  $i$  ในชั้นที่  $l$  สามารถเขียนได้ดังนี้คือ

$$y_i^l(k) = \sigma_i^l \left( \sum_{j=1}^{N_{l-1}} w_{ji}^l \cdot y_j^{l-1}(k) + wb_i^l \right) \quad (2-3)$$

โดยที่  $i = 1, 2, \dots, N_l$

$N_l$  คือจำนวนปมนิเวรอลในชั้นที่  $l$

$w_{ji}^l$  คือค่าน้ำหนักของแกนซึ่งส่งผ่านสัญญาณจากปมนิเวรอล  $j$  ในชั้น  $l-1$  ไปยังปมนิเวรอล  $i$  ในชั้น  $l$

$wb_i^l$  คือค่าน้ำหนักไบแอสของปมนิเวรอล  $i$  ในชั้น  $l$

$\sigma_i^l(\cdot)$  คือค่าฟังก์ชันซิกมอยด์ของปมนิเวรอล  $i$  ในชั้น  $l$  และมีค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์ประจำปม คือ  $a_i^l$

และ  $y_i^l(k)$  คือค่าเอาต์พุตของปมนิเวรอล  $i$  ที่เวลา  $k$  ในชั้น  $l$  ของ BNN

สมการปมเอาต์พุตปมที่  $m$  ในชั้นเอาต์พุตหรือชั้นที่  $L$  ของ BNN สามารถเขียนได้ดังนี้คือ

$$y_m^L(k) = \sigma_m^L \left( \sum_{j=1}^{N_{L-1}} w_{jm}^L \cdot y_j^{L-1}(k) + wb_m^L \right) \quad (2-4)$$

โดยที่  $m = 1, 2, \dots, N_L$

$N_L$  คือจำนวนปมนิเวรอลในชั้นที่  $L$

## การเรียนรู้ของเครือข่ายนิเวรอลชนิด Backpropagation

การเรียนรู้ของเครือข่ายนิเวรอลเป็นการแปลงความรู้ ซึ่งประกอบด้วยข้อมูล 2 ส่วนคือ ข้อมูลอินพุต( $x$ )และข้อมูลเอาต์พุต( $r$ )ให้อยู่ในรูปของพารามิเตอร์ของ BNN ได้แก่ ค่าน้ำหนัก ค่าน้ำหนักไบแอส และค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์ ในกระบวนการเรียนรู้ BNN สร้างความสัมพันธ์ระหว่างข้อมูลอินพุตและข้อมูลเอาต์พุตด้วยการปรับค่าพารามิเตอร์ภายในตัวมัน การปรับค่าน้ำหนักที่แต่ละแชนเป็นการปรับค่าเพื่อให้ BNN สามารถเข้ารหัสความรู้(knowledge encoding)ได้ การปรับค่าน้ำหนักไบแอสที่แต่ละปมมีผลทำให้จุดศูนย์กลางของฟังก์ชันซิกมอยด์เคลื่อนที่ไป การปรับค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์ที่แต่ละปมมีผลต่อรูปร่างของฟังก์ชันซิกมอยด์ ผลกระทบของค่าต่างๆของสัมประสิทธิ์ต่อฟังก์ชันซิกมอยด์แสดงในรูปที่ 2-8 วิธีการปรับค่าพารามิเตอร์ทั้ง 3 แบบได้ใช้อัลกอริทึม Backpropagation ซึ่งพัฒนาโดย D. Rumelhart (1986) อัลกอริทึม Backpropagation เป็นอัลกอริทึมที่ใช้หลักการอพติไมเซชันปรับค่าพารามิเตอร์ในทิศทางลบของค่าอนุพันธ์ของครรชนีสมรรถนะ(performance index)เทียบกับค่าพารามิเตอร์ ครรชนีสมรรถนะที่ใช้เป็นผลรวมของกำลังสองของค่าความแตกต่างระหว่างข้อมูลเอาต์พุตที่ให้เรียนรู้กับค่าเอาต์พุตของ BNN ครรชนีสมรรถนะ( $J$ )เขียนได้ดังนี้ คือ

$$J = \sum_{k=0}^M \sum_{m=1}^{N_L} (LE_m(k))^2 \quad (2-5)$$

โดยที่  $LE_m(k)$  คือค่าผิดพลาดของการเรียนรู้ของปมเอาต์พุตปมที่  $m$  ที่เวลา  $k$

มีค่าเท่ากับ  $LE_m(k) = r_m(k) - y_m^L(k)$

$L$  คือชั้นนอกสุดมีค่าเท่ากับจำนวนชั้นของ BNN

$M$  คือจำนวนขั้นเวลาที่เรียนรู้มีค่าเท่ากับจำนวนชุดข้อมูลที่ป้อนให้เรียนรู้

$N_L$  คือจำนวนปมนิเวรอลในชั้นที่  $L$

$r_m(k)$  คือค่าข้อมูลเอาต์พุตที่เวลา  $k$  ที่ต้องการ ซึ่งป้อนให้ปมเอาต์พุตปม  $m$  ในชั้น  $L$  ของ BNN เรียนรู้

และ  $y_m^L(k)$  คือค่าเอาต์พุตของปม  $m$  ที่เวลา  $k$  ในชั้นที่  $L$  ของ BNN



การคำนวณหาสมการการปรับค่าน้ำหนักของ BNN คำนวณจากค่าอนุพันธ์ของ  
 ธรรมชาติสมรรถนะเทียบกับน้ำหนัก โดยใช้สมการ(2-2)ถึง(2-5) ได้ดังนี้คือ

$$\frac{\partial J}{\partial w_{ij}^l(k)} = \sum_{m=1}^{N_L} \frac{\partial J}{\partial y_m^L(k)} \cdot \frac{\partial y_m^L(k)}{\partial w_{ij}^l(k)} \quad (2-6)$$

โดยที่  $\frac{\partial y_m^L(k)}{\partial w_{ij}^l(k)} = \sum_{s=1}^{N_{L-1}} \frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} \cdot \frac{\partial y_s^{L-1}(k)}{\partial w_{ij}^l(k)}$

$$\frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} = \sigma'_m \left( \sum_{n=1}^{N_{L-1}} w_{nm}^L \cdot y_n^{L-1}(k) + w b_m^L \right) \cdot w_{sm}^L$$

การคำนวณค่า  $\frac{\partial y_m^L(k)}{\partial w_{ij}^l(k)}$  เป็นการคำนวณแบบสืบทอด(recursive) ซึ่งคำนวณจน  
 กระทั่งชั้นของปมนิเวรอลเท่ากับชั้นของค่าน้ำหนักที่กำลังพิจารณา การคำนวณแบบสืบ  
 ทอดจึงยุติลงที่สมการต่อไปนี้

$$\frac{\partial y_p^l(k)}{\partial w_{ij}^l(k)} = \sigma'_p \left( \sum_{n=1}^{N_{l-1}} w_{np}^l \cdot y_n^{l-1}(k) + w b_p^l \right) \cdot y_i^{l-1}(k)$$

เมื่อ  $p=j$

= 0 เมื่อ  $p \neq j$

โดยที่  $\sigma'(x) = \frac{\partial \sigma}{\partial x}(x)$

การปรับค่าน้ำหนักได้ใช้ค่าอนุพันธ์ของธรรมชาติสมรรถนะเทียบกับน้ำหนัก และ  
 ค่าโมเมนต์คัมของน้ำหนัก ซึ่งคำนวณได้จากค่าผลต่างสืบเนื่องย้อนหลังของน้ำหนัก  
 การใช้วิธีโมเมนต์คัมร่วมในการปรับค่าจะช่วยเร่งให้ธรรมชาติสมรรถนะเข้าสู่ศูนย์เร็วขึ้น  
 อัตราการปรับค่าน้ำหนัก คำนวณได้ดังนี้คือ

$$\Delta w_{ij}^l(k) = -\eta_w \cdot \frac{\partial J}{\partial w_{ij}^l(k)} + \mu_w \cdot (w_{ij}^l(k) - w_{ij}^l(k-1)) \quad (2-7)$$

โดยที่  $\eta_w$  คือ อัตราการเรียนรู้ของน้ำหนัก และ  $\mu_w$  คือ อัตราโมเมนต์คัมของน้ำหนัก  
 $\eta_w$  และ  $\mu_w$  มีความหมายเช่นเดียวกับค่าความยาวก้าว(step size)ในหลักการอพติไม-  
 เซชันแบบเกรเดียนต์

คำนวณค่าน้ำหนักที่เวลา  $k+1$  ได้คือ

$$w_{ij}^l(k+1) = w_{ij}^l(k) + \Delta w_{ij}^l(k) \quad (2-8)$$

การคำนวณหาสมการการปรับค่าน้ำหนักไบแอสของ BNN คำนวณจากค่าอนุพันธ์ของครรชนีสมรรถนะเทียบกับค่าน้ำหนักไบแอส โดยใช้สมการ(2-2)ถึง(2-5)ได้คือ

$$\frac{\partial J}{\partial w b_j^l(k)} = \sum_{m=1}^{N_L} \frac{\partial J}{\partial y_m^L(k)} \cdot \frac{\partial y_m^L(k)}{\partial w b_j^l(k)} \quad (2-9)$$

$$\text{โดยที่ } \frac{\partial y_m^L(k)}{\partial w b_j^l(k)} = \sum_{s=1}^{N_{L-1}} \frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} \cdot \frac{\partial y_s^{L-1}(k)}{\partial w b_j^l(k)}$$

$$\frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} = \sigma_m^L \left( \sum_{n=1}^{N_{L-1}} w_{nm}^L \cdot y_n^{L-1}(k) + w b_m^L \right) \cdot w_{sm}^L$$

$$\frac{\partial y_p^l(k)}{\partial w b_j^l(k)} = \sigma_p^l \left( \sum_{n=1}^{N_{l-1}} w_{np}^l \cdot y_n^{l-1}(k) + w b_p^l \right) \quad \text{เมื่อ } p=j$$

$$= 0 \quad \text{เมื่อ } p \neq j$$

การปรับค่าน้ำหนักไบแอสได้ใช้ค่าอนุพันธ์ของครรชนีสมรรถนะเทียบกับน้ำหนักไบแอสและค่าโมเมนต์คัมของน้ำหนักไบแอส อัตราการปรับค่าน้ำหนักไบแอสคำนวณได้ดังนี้คือ

$$\Delta w b_j^l(k) = -\eta_b \cdot \frac{\partial J}{\partial w b_j^l(k)} + \mu_b \cdot (w b_j^l(k) - w b_j^l(k-1)) \quad (2-10)$$

โดยที่  $\eta_b$  คือ อัตราการเรียนรู้ของน้ำหนักไบแอส

$\mu_b$  คือ อัตราโมเมนต์คัมของน้ำหนักไบแอส

คำนวณค่าน้ำหนักไบแอสที่เวลา  $k+1$  ได้คือ

$$w b_j^l(k+1) = w b_j^l(k) + \Delta w b_j^l(k) \quad (2-11)$$

การคำนวณสมการการปรับค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์ของ BNN คำนวณจากค่าอนุพันธ์ของครรชนีสมรรถนะเทียบกับค่าสัมประสิทธิ์ โดยใช้สมการ(2-2)ถึง(2-5)ได้คือ

$$\frac{\partial J}{\partial a_j^l(k)} = \sum_{m=1}^{N_L} \frac{\partial J}{\partial y_m^L(k)} \cdot \frac{\partial y_m^L(k)}{\partial a_j^l(k)} \quad (2-12)$$

$$\begin{aligned} \text{โดยที่ } \frac{\partial y_m^L(k)}{\partial a_j^l(k)} &= \sum_{s=1}^{N_{L-1}} \frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} \cdot \frac{\partial y_s^{L-1}(k)}{\partial a_j^l(k)} \\ \frac{\partial y_m^L(k)}{\partial y_s^{L-1}(k)} &= \sigma'_m \left( \sum_{n=1}^{N_{L-1}} w_{nm}^L \cdot y_n^{L-1}(k) + w b_m^L \right) \cdot w_{sm}^L \\ \frac{\partial y_p^l(k)}{\partial a_j^l(k)} &= \frac{\partial \sigma_p^l}{\partial a_j^l} \left( \sum_{n=1}^{N_{l-1}} w_{np}^l \cdot y_n^{l-1}(k) + w b_p^l \right) \text{ เมื่อ } p=j \\ &= 0 \quad \text{เมื่อ } p \neq j \end{aligned}$$

$$\text{และ } \frac{\partial \sigma}{\partial a}(x) = -a \cdot \exp(-a \cdot x) \cdot (\sigma(x))^2$$

การปรับค่าสัมประสิทธิ์ได้ใช้ค่าอนุพันธ์ของครรชนีสมรรถนะเทียบกับน้ำหนัก ร่วมกับค่าโมเมนต์ของค่าสัมประสิทธิ์ อัตราการปรับค่าน้ำหนักไบแอสคำนวณได้ ดังนี้คือ

$$\Delta a_j^l(k) = -\eta_a \cdot \frac{\partial J}{\partial a_j^l(k)} + \mu_a \cdot (a_j^l(k) - a_j^l(k-1)) \quad (2-13)$$

โดยที่  $\eta_a$  คือ อัตราการเรียนรู้ของค่าสัมประสิทธิ์

$\mu_a$  คือ อัตราโมเมนต์ของค่าสัมประสิทธิ์

คำนวณค่าสัมประสิทธิ์ที่เวลา  $k+1$  ได้คือ

$$a_j^l(k+1) = a_j^l(k) + \Delta a_j^l(k) \quad (2-14)$$

ขั้นตอนการเรียนรู้ของ BNN สามารถสรุปได้ดังนี้ คือ

- 1) สุ่มค่าน้ำหนักของ BNN ในแต่ละชั้น จากค่าจำนวนจริงในช่วง -10 ถึง +10
- 2) กำหนดค่าน้ำหนักไบแอสของปมในแต่ละชั้น โดยแบ่งช่วงของจำนวนจริงอย่างเท่าๆกันตั้งแต่ -10 ถึง +10 เพื่อกระจายค่าน้ำหนักไบแอสในแต่ละชั้นให้อยู่ในช่วงของจำนวนจริงตั้งแต่ -10 ถึง +10 อย่างเท่าๆกัน
- 3) กำหนดค่าสัมประสิทธิ์( $a$ )ของฟังก์ชันซิกมอยด์แต่ละปม สำหรับการทดลองได้ กำหนดให้มีค่าเท่ากับ 0.2
- 4) เมื่อเก็บข้อมูลอินพุตและข้อมูลเอาต์พุตแล้ว แปลงพิสัย(range)ของข้อมูลเอาต์พุตให้อยู่ในช่วง [0.1, 0.9] เพื่อให้ BNN เรียนรู้ข้อมูลความรู้แล้วได้ค่าน้ำหนักที่มีค่าจำกัด (finite value) ซึ่งทำให้ฟังก์ชันของปมแมพ(map)จากอินพุตซึ่งมีค่าจำกัดไปสู่เอาต์พุต



ซึ่งมีค่าจำกัด ในทางกลับกันถ้าแปลงพิสัยให้อยู่ในช่วง  $[0, 1]$  ต้องใช้ค่าน้ำหนักเท่ากับค่า  $-\infty$  หรือ  $+\infty$  เพื่อให้ฟังก์ชันของปมแมพจากอินพุตซึ่งมีค่าจำกัดไปสู่ค่าเอาต์พุตซึ่งมีค่า 0 หรือค่า 1 ตามลำดับ เพราะฟังก์ชันซิกมอยด์มีค่าเข้าใกล้ 0 หรือ 1 ต่อเมื่อตัวแปรอินพุตของฟังก์ชันมีค่าเข้าใกล้ค่า  $-\infty$  หรือค่า  $+\infty$  ตามลำดับ

5) ป้อนข้อมูลอินพุตที่ใช้เรียนรู้เข้าทางชั้นอินพุต คำนวณค่าเอาต์พุตของ BNN จากนั้นนำข้อมูลเอาต์พุตที่แปลงพิสัยแล้ว มาเปรียบเทียบกับค่าเอาต์พุตของ BNN แล้วใช้อัลกอริทึม Backpropagation ตามสมการ(2-6)ถึง(2-14) ในตอนเริ่มต้นปรับค่าพารามิเตอร์ของ BNN โดยใช้ค่า  $\eta_w = 0.2$   $\eta_b = 0.1$  และ  $\eta_a = 0.002$

6) เมื่อป้อนข้อมูลอินพุตจนครบหมดทุกค่าแล้ว คำนวณค่าครรชนีสมรรถนะของข้อมูลความรู้ทั้งหมด จากนั้นเริ่มป้อนข้อมูลความรู้ใหม่และคำนวณค่าครรชนีสมรรถนะในแต่ละรอบของการเรียนรู้ เมื่อค่าของครรชนีสมรรถนะมีค่าต่ำสุด ปรับค่า  $\eta_w$   $\eta_b$  และ  $\eta_a$  ให้ลดค่าลง 1/2 เท่า และลดค่าลงเช่นนี้ทุกครั้งที่ค่าของครรชนีสมรรถนะมีค่าต่ำสุด จนกระทั่งค่าของครรชนีสมรรถนะไม่สามารถลดลงได้อีก

โปรแกรมจำลองการเรียนรู้และการทำงานของ BNN บนคอมพิวเตอร์ ได้แสดงไว้ในภาคผนวกที่ 2