

## บทที่ 2

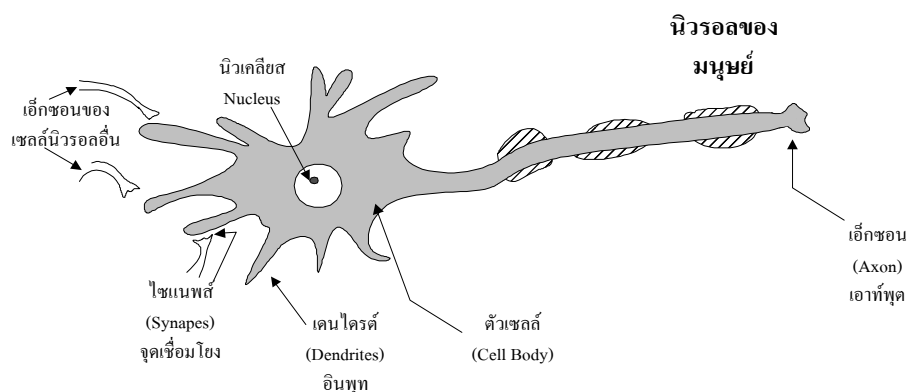
### การประยุกต์โครงข่ายประสาทในการกำจัดสัญญาณรบกวน

ในบทนี้จะเป็นการกล่าวถึงหลักการเบื้องต้นของโครงข่ายประสาท (Neural Network) การเรียนรู้ของโครงข่ายประสาท ADALINE และหลักการเบื้องต้นของการกำจัดสัญญาณรบกวนโดยใช้ Adaptive Filter

#### 2.1 ชีวิตลิสต์เบื้องต้นเกี่ยวกับเซลล์ประสาท

โครงข่ายประสาทของมนุษย์จะประกอบไปด้วยเซลล์ประสาทประมาณ  $10^{11}$  ตัว โดยแต่ละตัวจะมีการเชื่อมต่อกับเซลล์อื่นๆ ประมาณ  $10^4$  เซลล์ [Hagan, Martin T., 1996] ภาพประกอบที่ 2-1 แสดงองค์ประกอบสำคัญของเซลล์ประสาทของมนุษย์ ซึ่งประกอบไปด้วย 3 ส่วนหลักคือ เดนไดรต์ (Dendrite), ตัวเซลล์ (Cell Body) และแอกซอน (Axon) โดยมีหลักการทำงานดังนี้

เซลล์ประสาทรับข้อมูลอินพุตจากเซลล์ประสาทเซลล์อื่น โดยผ่านทางจุดเชื่อมต่อระหว่างเซลล์ที่เรียกว่า ซินแนปส์ (Synapse) สัญญาณข้อมูลจากซินแนปส์จะถูกส่งผ่านเดนไดรต์ซึ่งเป็นส่วนที่ทำหน้าที่รับสัญญาณอินพุตของเส้นใยประสาท และนำสัญญาณอินพุตซึ่งเป็นสัญญาณไฟฟ้าส่งต่อไปยังตัวเซลล์ สัญญาณข้อมูลอินพุตนี้จะได้รับการประมวลผลจากขบวนการที่เกิดขึ้นภายในตัวเซลล์และได้เป็นสัญญาณเอาต์พุตออกมา สัญญาณเอาต์พุตที่ได้จากเซลล์ประสาทนี้จะถูกส่งออกทางแอกซอนแล้วสัญญาณดังกล่าวนี้จะส่งผ่านซินแนปส์เป็นอินพุตของเซลล์ประสาทเซลล์อื่นต่อไป



ภาพประกอบ 2-1 โครงสร้างพื้นฐานของเซลล์ประสาทของมนุษย์

จากโครงสร้างและการทำงานของเซลล์ประสาทของมนุษย์ ได้เป็นแรงดลใจให้มีการคิดค้นรูปแบบของโครงข่ายประสาท โดยอาศัยลักษณะสำคัญของเซลล์ประสาทของมนุษย์ 4 ประการดังนี้

#### 1) ง่ายแต่จำนวนมหาศาล

โครงสร้างพื้นฐานของเซลล์ประสาทของมนุษย์มีฟังก์ชันการทำงานแบบง่าย ๆ แต่อาศัยว่ามีเซลล์ประสาทจำนวนมหาศาล โครงข่ายประสาทก็ควรจะประกอบไปด้วยเซลล์หน่วยประมวลผลจำนวนมาก ๆ เช่นกัน โดยแต่ละเซลล์เป็นหน่วยประมวลผลขนาดเล็กซึ่งมีโครงสร้างหรือมีฟังก์ชันการทำงานอย่างง่าย ๆ

#### 2) เครือข่ายการเชื่อมโยง

เซลล์ประสาทมนุษย์จำนวนมากนั้นเชื่อมต่อกันเป็นเครือข่าย การเชื่อมต่อถึงกันนั้นมีเงื่อนไขในรูปของน้ำหนักการต่อเชื่อม (Weighted Connections) ตัวน้ำหนักนี้จะเป็นตัวที่บรรจุความรู้ในรูปแบบต่าง ๆ ไว้

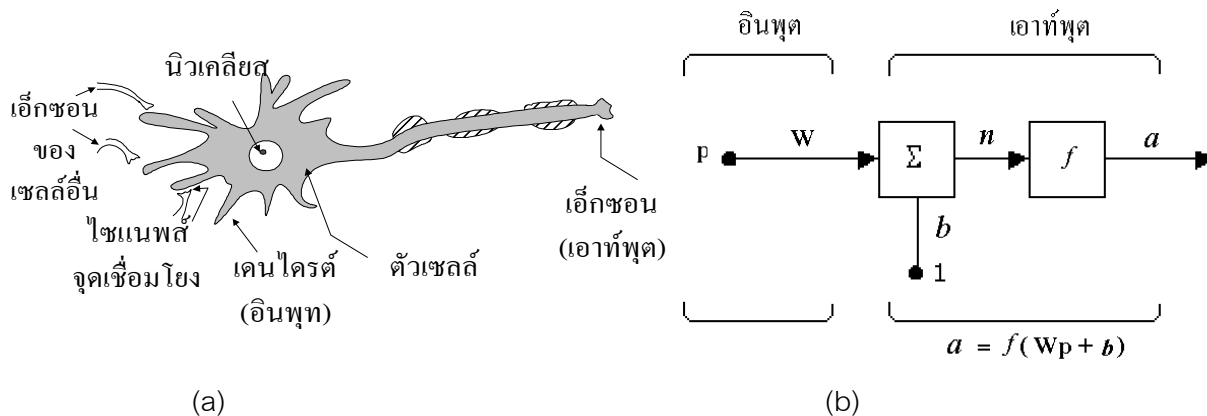
#### 3) ช่วยกันทำและกระจายอำนาจ

เซลล์ประสาทจำนวนมากช่วยกันทำงานในลักษณะขนาน (Massive Parallel Processing) ถึงแม้ว่าแต่ละเซลล์จะมีฟังก์ชันการทำงานแบบง่าย ๆ โดยแต่ละเซลล์ทำงานและรับผิดชอบงานในส่วนของตัวเองไปพร้อม ๆ กัน การควบคุมการทำงานของโครงข่ายประสาทจึงพยายามเลียนแบบการทำงานในลักษณะขนานและกระจายอำนาจ แม้ว่าโครงข่ายประสาทบางเซลล์ไม่สามารถทำงานได้ตามปกติ เช่น เสียหรือตายไป โครงข่ายก็ยังคงสามารถทำงานโดยรวมได้ถูกต้อง คุณสมบัติประการนี้เราเรียกว่า “คุณสมบัติของการทนต่อความผิดพลาด” (Fault Tolerance)

#### 4) ความสามารถในการเรียนรู้

เซลล์สมองของมนุษย์สามารถเรียนรู้ได้จากประสบการณ์จากกฎเกณฑ์ทั่วไปหรือได้จากตัวอย่าง นอกจากนี้ยังพบว่า โครงสร้างของเซลล์ประสาทบางส่วนจะถูกสร้างตั้งแต่เกิด ในขณะที่บางส่วนจะถูกพัฒนาผ่านการเรียนรู้ โดยโครงข่ายประสาทจะมีการเปลี่ยนแปลงอย่างต่อเนื่องตลอดชีวิต การเปลี่ยนแปลงนี้จะขึ้นอยู่กับความแข็งแรงหรือความอ่อนแอของรอยต่อไซแนปส์โครงข่ายประสาทเทียมจะไม่ยุ่งยากและซับซ้อนเท่ากับโครงข่ายประสาทของมนุษย์ โดยจะมีลักษณะที่คล้ายกันอยู่ 2 ประการคือ ประการแรกจะใช้เฉพาะการคำนวณแบบง่าย ๆ ได้แก่ การบวก การคูณ และการเปรียบเทียบ ประการที่สอง คือการเชื่อมต่อระหว่างเซลล์จะเป็นตัวกำหนดการทำงานของโครงข่าย

จากภาพประกอบ 2-2 แสดงการเปรียบเทียบระหว่างโครงสร้างพื้นฐานเซลล์ประสาทของมนุษย์ (a) กับแบบจำลองอย่างง่ายของโครงข่ายประสาทอินพุตเดียว (b) พบว่ามีโครงสร้างและการทำงานที่คล้ายกัน คือมีตัวรับข้อมูล (อินพุต) การเชื่อมต่อและการคำนวณอย่างง่าย ๆ และมีการส่งค่าเอาต์พุตเป็นค่าผลลัพธ์ต่อไป

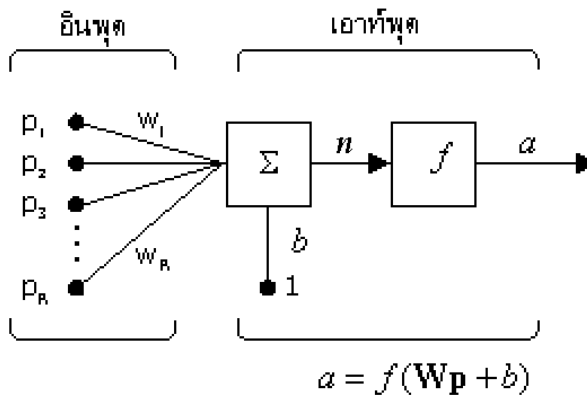


ภาพประกอบ 2-2 แสดงการเปรียบเทียบโครงสร้างพื้นฐานเซลล์ประสาทของมนุษย์ (a) กับแบบจำลองอย่างง่ายของโครงข่ายประสาทอินพุตเดี่ยว (b)

2.2 แบบจำลองของเซลล์ประสาทและสถาปัตยกรรมของโครงข่าย [ชูศักดิ์ ลิ่มสกุล, 2541]

2.2.1 แบบจำลองของเซลล์ประสาท

โครงข่ายประสาทเซลล์เดี่ยวที่มีหลายอินพุต สามารถจำลองได้ดังภาพประกอบที่ 2-3



ภาพประกอบ 2-3 เซลล์ประสาทที่มีหลายอินพุต

โดยทั่วไปแล้วเซลล์ประสาทจะมีอินพุตมากกว่า 1 อินพุต สมมติให้มี R อินพุต คือ  $p_1, p_2, \dots, p_R$  แต่ละอินพุตมีค่าน้ำหนักคือ  $w_{1,1}, w_{1,2}, \dots, w_{1,R}$  เซลล์ประสาทมีไบอัสเท่ากับ  $b$  จะได้เอาต์พุตของวงจรรวมซึ่งเรียกว่าเน็ตอินพุต ( $n$ ) เท่ากับ

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (2-1)$$

และได้สมการของเอาต์พุต ( $a$ ) ของโครงข่ายเป็น

$$a = f(\mathbf{Wp} + b) \quad (2-2)$$

โดยที่  $\mathbf{W} = [w_{1,1} \ w_{1,2} \ \dots \ w_{1,R}]$

$$\mathbf{p} = [p_1 \ p_2 \ \dots \ p_R]^T$$


$f$  คือ ทรานส์เฟอร์ฟังก์ชันของโครงข่าย

### 2.2.2 ทรานส์เฟอร์ฟังก์ชันของโครงข่าย (Transfer Function)

ทรานส์เฟอร์ฟังก์ชันของโครงข่าย อาจเป็นฟังก์ชันเชิงเส้นหรือไม่เป็นเชิงเส้นก็ได้ ทรานส์เฟอร์ฟังก์ชันที่ใช้ในโครงข่ายประสาทมีหลายชนิด ชนิดของทรานส์เฟอร์ฟังก์ชันที่นิยมใช้กันเช่น

#### 1) Hard Limit Transfer Function


ทรานส์เฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุต 2 ค่าตามค่าเน็ตอินพุต กล่าวคือ หากค่าเน็ตอินพุตมีค่าต่ำกว่า 0 จะให้ค่าเอาต์พุตเป็น 0 และหากค่าเน็ตอินพุตมีค่ามากกว่าหรือเท่ากับ 0 จะให้ค่าเอาต์พุตเป็น 1



$$a = \text{hardlim}(n) = \text{hardlim}(\mathbf{Wp} + b) \quad , a = \begin{cases} 0, n < 0 \\ 1, n \geq 0 \end{cases}$$

#### 2) Linear Transfer Function


ทรานส์เฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุตตามค่าเน็ตอินพุตที่ป้อนเข้ามา กล่าวคือหากค่าเน็ตอินพุตมีค่าเท่าใดก็จะให้ค่าเอาต์พุตเป็นค่าเท่ากับเน็ตอินพุตนั้น ๆ



$$a = \text{purelin}(n) = \text{purelin}(\mathbf{Wp} + b) = n$$

3) Log-Sigmoid Transfer Function


ทรานส์เฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุตระหว่างค่า 0 ถึง 1



$$a = \text{logsig}(n) = \text{logsig}(\mathbf{Wp} + b) \quad , a = \frac{1}{1 + e^{-n}}$$

4) Hyperbolic Tangent-Sigmoid Transfer Function

ทรานส์เฟอร์ฟังก์ชันชนิดนี้จะให้ค่าเอาต์พุตระหว่างค่า -1 ถึง 1



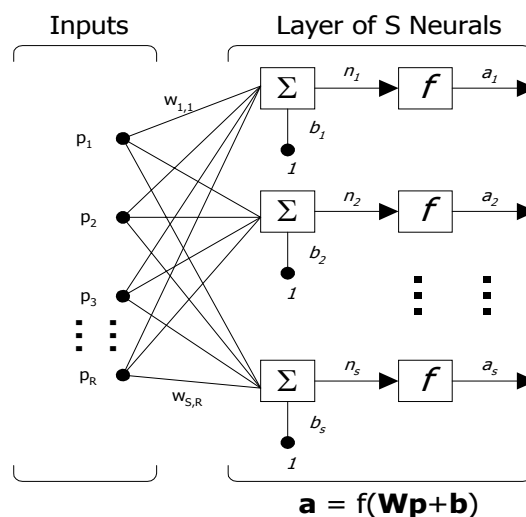
$$a = \text{tansig}(n) = \text{tansig}(\mathbf{Wp} + b) \quad , a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$$

2.2.3 สถาปัตยกรรมของโครงข่าย

สถาปัตยกรรมของโครงข่ายแบ่งได้ 2 รูปแบบ

2.2.3.1 เซลล์ประสาทชั้นเดียว

ชั้นของโครงข่ายประสาทประกอบด้วยเมทริกซ์น้ำหนัก ( $\mathbf{W}$ ), วงจรรวม ( $\Sigma$ ), เวกเตอร์ไบอัส ( $\mathbf{b}$ ), ทรานส์เฟอร์ฟังก์ชัน ( $f$ ), และเวกเตอร์เอาต์พุต ( $\mathbf{a}$ )

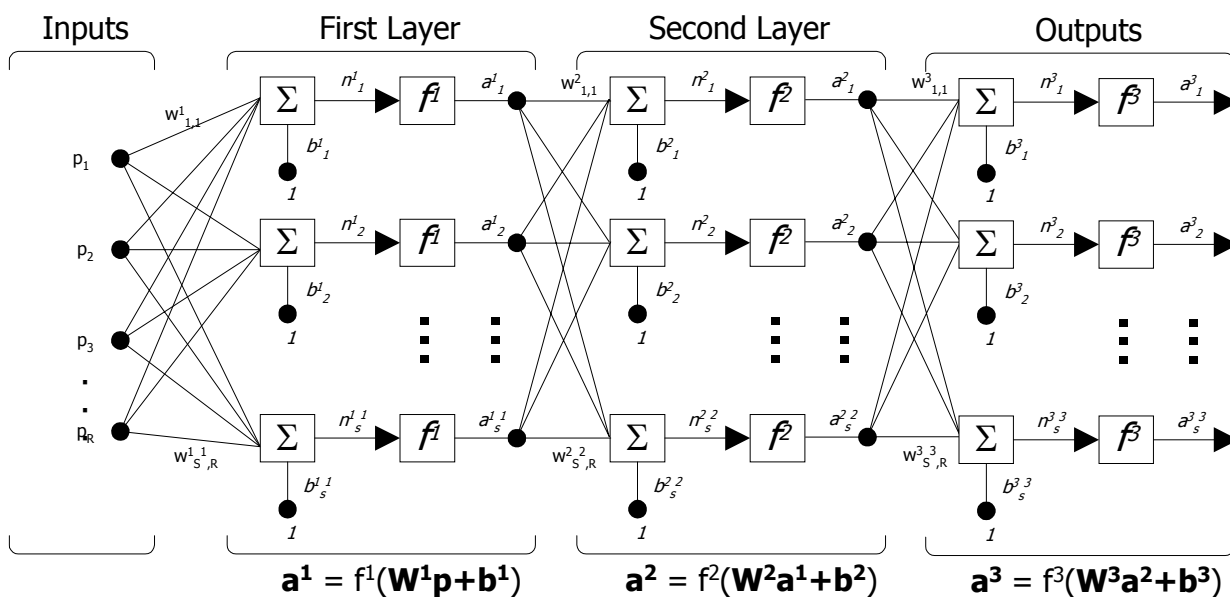


ภาพประกอบ 2-4 เซลล์ประสาทชั้นเดียว

โดย 
$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix}, \mathbf{p} = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_R \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_s \end{bmatrix} \text{ และ } \mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_s \end{bmatrix}$$

2.2.3.2 เซลล์ประสาทหลายชั้น

ภาพประกอบ 2-5 แสดงเซลล์ประสาทหลายชั้น โดยตัวเลขยกกำลังเป็นตัวเลขกำกับชั้น ชั้นที่มีอินพุตเป็นอินพุตของโครงข่ายเรียกว่าชั้นอินพุต (Input Layer), ชั้นที่มีเอาต์พุตเป็นเอาต์พุตของโครงข่ายเรียกว่าชั้นเอาต์พุต (Output Layer) ส่วนชั้นอื่นๆเรียกว่าชั้นซ่อน (Hidden Layer) ในการเรียกชื่อโครงสร้างของโครงข่ายจะเรียกตามโครงสร้างของแต่ละชั้น เช่น โครงข่าย “2-4-1” จะหมายถึงโครงข่ายที่มีชั้นอินพุต ชั้นซ่อนและชั้นเอาต์พุต โดยในชั้นอินพุตจะมี 2 อินพุต ในชั้นซ่อนจะมี 4 เซลล์ และในชั้นเอาต์พุตจะมี 1 เอาต์พุต เป็นต้น



ภาพประกอบ 2-5 เซลล์ประสาทหลายชั้น

จากภาพประกอบ 2-5 จะได้สมการเอาต์พุตของชั้นซ่อนชั้นแรกเป็น

$$\mathbf{a}^1 = f^1(\mathbf{W}^1\mathbf{p} + \mathbf{b}^1) \quad (2-3)$$

สมการเอาต์พุตของชั้นซ่อนชั้นที่สองจะได้

$$\mathbf{a}^2 = f^2(\mathbf{W}^2\mathbf{a}^1 + \mathbf{b}^2) \quad (2-4)$$

และสมการเอาต์พุตของชั้นเอาต์พุตจะได้ว่า

$$\mathbf{a}^3 = f^3(\mathbf{W}^3\mathbf{a}^2 + \mathbf{b}^3) \quad (2-5)$$

โดย เวกเตอร์อินพุต ( $\mathbf{p}$ ), เมทริกซ์ของค่าน้ำหนัก ( $\mathbf{W}$ ), เวกเตอร์ไบอัส ( $\mathbf{b}$ ) และ เวกเตอร์เอาต์พุต ( $\mathbf{a}$ ) มีลักษณะเหมือนในเซลล์ประสาทชั้นเดียว

### 2.3 โครงข่าย ADALINE

โครงข่าย ADALINE (Adaptive Linear Neural Network) หรือโครงข่ายที่ใช้การเรียนรู้ของ Widrow-Hoff ซึ่งเป็นโครงข่ายที่ใช้ในงานวิจัยนี้และเป็นโครงข่ายที่ใช้ทรานเฟอร์ฟังก์ชันแบบเชิงเส้น ตัวอย่างโครงข่าย ADALINE 2 อินพุตดังแสดงในภาพประกอบ 2-6 นั้น การเรียนรู้ของโครงข่าย ADALINE จะมีดัชนีชี้สมรรถนะคือ ค่าเฉลี่ยกำลังสองของความผิดพลาดต่ำสุด (Least Mean Square Error)

การเรียนรู้ของโครงข่าย ADALINE สามารถสรุปได้ดังนี้

ขั้นที่ 1 สมมติค่าน้ำหนัก ( $\mathbf{W}$ ), ค่าไบอัส ( $b$ ) และค่าอัตราการเรียนรู้ ( $\alpha$ ) เริ่มต้นให้แกโครงข่ายประสาท

ขั้นที่ 2 ป้อนอินพุต  $\mathbf{p}(k)$  ให้แกโครงข่าย

ขั้นที่ 3 คำนวณหาค่าเอาต์พุต  $a(k)$  ของโครงข่ายประสาท

$$a(k) = f(\mathbf{W}\mathbf{p}(k) + b) \quad (2-6)$$

ขั้นที่ 4 หาค่าความผิดพลาด  $e(k)$  จากผลต่างของเอาต์พุตเป้าหมาย  $t(k)$  กับ เอาต์พุตของโครงข่ายประสาท  $a(k)$


$$e(k) = t(k) - a(k) \quad (2-7)$$

ขั้นที่ 5 ปรับค่าน้ำหนักและไบอัสของโครงข่ายประสาทใหม่จากสมการ

$$\mathbf{W}(k+1) = \mathbf{W}(k) + 2\alpha e(k)\mathbf{p}(k) \quad (2-8)$$

$$b(k+1) = b(k) + 2\alpha e(k) \quad (2-9)$$

ขั้นที่ 6 กลับไปเริ่มทำตั้งแต่ขั้นตอนที่ 2 ใหม่จนโครงข่ายประสาทจะ Converge โดยดูจากค่าของความผิดพลาด



ภาพประกอบ 2-6 ตัวอย่างของโครงข่าย ADALINE 2 อินพุต

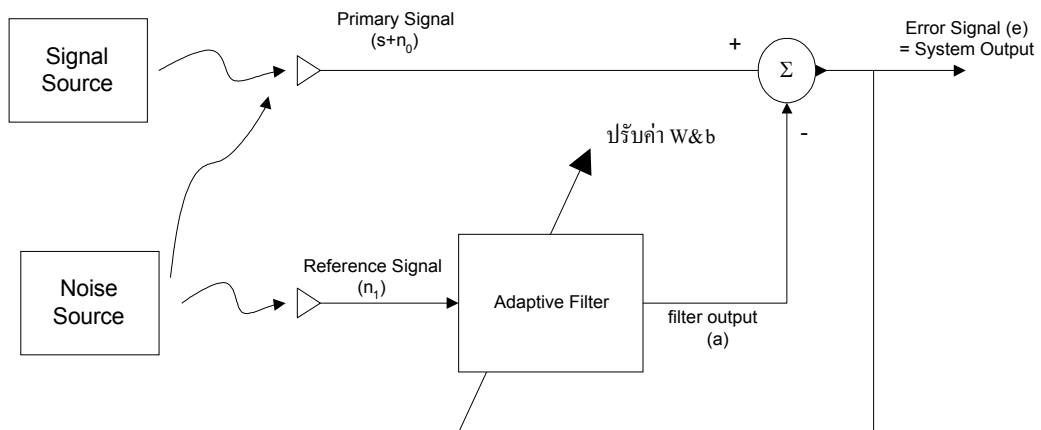
## 2.4 หลักการพื้นฐานของ Adaptive Filter และการประยุกต์ใช้โครงข่ายประสาทเป็น

### Adaptive Filter

#### 2.4.1 การกำจัดสัญญาณรบกวนโดยใช้ Adaptive Filter ชนิดที่ใช้สัญญาณอ้างอิงจากภายนอก

หลักการพื้นฐานของการกำจัดสัญญาณรบกวนโดยใช้ Adaptive Filter สมมติให้สัญญาณที่วัดได้ซึ่งในที่นี้จะเรียกว่าสัญญาณปฐมภูมิ (Primary Signal or Measured Signal :  $m$ ) คือสัญญาณข่าวสาร (Information Signal :  $s$ ) ที่มีสัญญาณรบกวน (Noise Signal :  $n_0$ ) ปนอยู่ ส่วนสัญญาณอ้างอิง (Reference Signal) คือสัญญาณรบกวน (Noise Signal :  $n_1$ ) ที่มีการเปลี่ยนแปลงเฟสหรือขนาดโดยจะป้อนให้กับ Adaptive Filter เพื่อสร้างสัญญาณเอาต์พุตของฟิลเตอร์ (Output Signal :  $a$ ) ขึ้นมาเพื่อไปหักล้างกับสัญญาณที่วัดได้ ผลลัพธ์ที่ได้คือค่าสัญญาณความผิดพลาด (Error Signal :  $e(t)$ ) ซึ่งก็คือสัญญาณข่าวสารที่มีการกำจัดสัญญาณรบกวนแล้ว และทำการป้อนสัญญาณความผิดพลาดนี้กลับให้แก่ Adaptive Filter เพื่อทำการปรับค่าน้ำหนัก ( $w$ ) และค่าไบอัส ( $b$ ) ของ Adaptive Filter ดังภาพประกอบ 2-7 ซึ่งแสดงถึงหลักการในการใช้ Adaptive Filter ในการกำจัดสัญญาณรบกวน [Widrow, B., 1985]





ภาพประกอบ 2-7 Adaptive Filter ชนิดที่ใช้สัญญาณอ้างอิงจากภายนอก

สมมติให้สัญญาณ  $s, n_0, n_1$  และ  $a$  มีคุณสมบัติทางสถิติไม่แปรผันตามเวลา (Statistical Stationary) โดยสัญญาณ  $s$  ไม่มีความสัมพันธ์ (Uncorrelated) กับสัญญาณ  $n_0$  และ  $n_1$  แต่สัญญาณ  $n_1$  มีความสัมพันธ์ (Correlated) กับสัญญาณ  $n_0$

สัญญาณความผิดพลาดซึ่งก็คือสัญญาณเอาต์พุตของระบบ (System Output :  $e$ ) คือ

$$e = (s + n_0) - a \quad (2-10)$$

$$e = s + (n_0 - a) \quad (2-11)$$

ยกกำลังสองทั้งสองข้าง

$$e^2 = s^2 + 2(n_0 - a)s + (n_0 - a)^2 \quad (2-12)$$

หาค่าเฉลี่ยของสัญญาณ

$$E[e^2] = E[s^2] + E[(n_0 - a)^2] + 2E[s(n_0 - a)] \quad (2-13)$$

เนื่องจากสัญญาณ  $s$  ไม่มีความสัมพันธ์ (Uncorrelated) กับสัญญาณ  $n_0$  และ  $n_1$  และ ไม่มีความสัมพันธ์กับสัญญาณ  $a$  ดังนั้นเทอมสุดท้ายของสมการ 2-13 จะมีค่าเท่ากับศูนย์ และจะได้สมการใหม่เป็น

$$E[e^2] = E[s^2] + E[(n_0 - a)^2] \quad (2-14)$$

ทำการปรับค่าน้ำหนักและค่าไบอัสของ Adaptive Filter เพื่อที่จะหาค่าต่ำสุดของค่ากำลังของสัญญาณเอาต์พุต (Output Power :  $E[e^2]$ ) โดยจะไม่ส่งผลต่อค่ากำลังของสัญญาณข่าวสาร (Signal Power :  $E[s^2]$ ) และได้สมการค่าต่ำสุดของค่ากำลังของสัญญาณเอาต์พุตเป็น

$$E_{\min}[e^2] = E[s^2] + E_{\min}[(n_0 - a)^2] \quad (2-15)$$

หรือกล่าวคือเมื่อ Adaptive Filter ถูกปรับค่าน้ำหนักและไบอัสจนค่ากำลังของสัญญาณเอาต์พุตมีค่าต่ำที่สุดจะทำให้ ค่าของ  $E[(n_0 - a)^2]$  มีค่าต่ำที่สุดนั่นเอง

ดังนั้นจึงพิจารณาได้ว่าค่าเอาต์พุตของ Adaptive Filter ( $a$ ) จึงเป็นค่ากำลังสองต่ำสุด (Least Square) โดยประมาณ ที่ดีที่สุดของสัญญาณรบกวน (Noise Signal :  $n_0$ ) และจากสมการที่ 2-11

$$e = s + n_0 - a \quad (2-16)$$

นั่นคือ

$$e - s = n_0 - a \quad (2-17)$$

$$E(e - s)^2 = E(n_0 - a)^2 \quad (2-18)$$

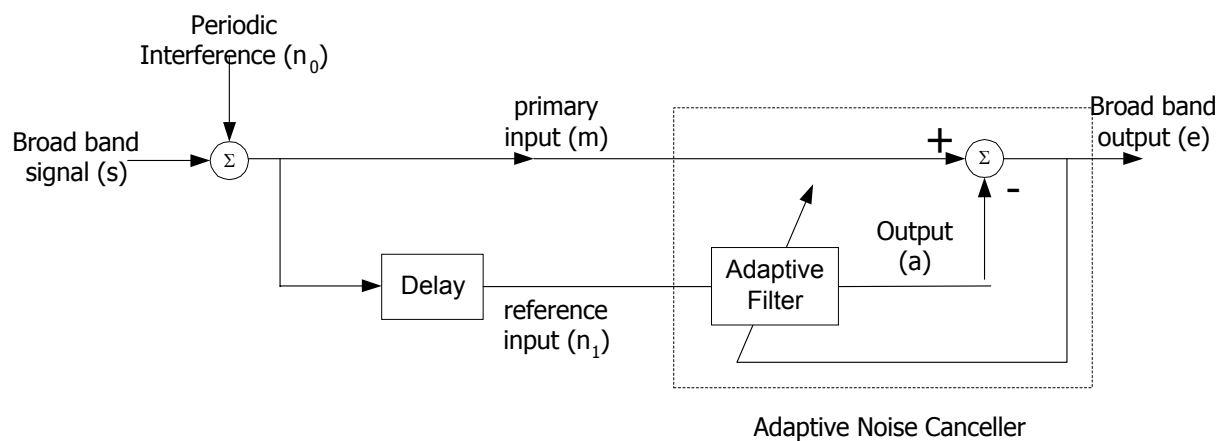
ดังนั้นเมื่อค่า  $E[(n_0 - a)^2]$  มีค่าต่ำที่สุดจึงทำให้ค่าของ  $E[(e - s)^2]$  มีค่าต่ำที่สุดด้วย กล่าวคือเป็นการทำให้ค่าสัญญาณความผิดพลาดหรือเอาต์พุตของระบบ (System Error :  $e$ ) เป็นค่าต่ำสุดกำลังสอง (Least Square) ซึ่งเป็นการประมาณค่าที่ดีที่สุดของสัญญาณข่าวสารที่เราต้องการ ( $s$ ) ด้วยเช่นกัน

#### 2.4.2 การกำจัดสัญญาณรบกวนโดยใช้ Adaptive Filter ชนิดที่ไม่ใช้สัญญาณอ้างอิงจากภายนอก

การกำจัดสัญญาณรบกวนโดยใช้ Adaptive Filter ที่ได้กล่าวมาในหัวข้อ 2.4.1 จะเป็นการป้อนสัญญาณอ้างอิงจากภายนอกเป็นอินพุตให้แก่ Adaptive Filter ซึ่งในกรณีนี้สามารถใช้ได้ก็ต่อเมื่อเราทราบถึงคุณสมบัติของสัญญาณรบกวนที่มารบกวน แต่มีหลายกรณีที่สัญญาณข่าวสารถูกรบกวนโดยสัญญาณรบกวนที่เป็นคาบ (Periodic Interference) แต่ไม่ทราบถึงคุณลักษณะของสัญญาณรบกวนนี้ หรือกล่าวคือไม่สามารถผลิตสัญญาณอ้างอิงจากภายนอก เพื่อป้อนให้แก่ Adaptive Filter ได้ ในกรณีเช่นนี้เราสามารถใช่วิธีการหน่วงเวลาที่มีช่วงในการหน่วงคงที่ค่าหนึ่ง (Fixed Delay) ของสัญญาณที่วัดได้ (สัญญาณปฐมภูมิ) ทำหน้าที่เป็นสัญญาณอ้างอิง

เพื่อป้อนให้แก่ Adaptive Filter แทน โดยช่วงหน่วงเวลาควรมีช่วงที่ยาวเพียงพอที่จะทำให้ส่วนของสัญญาณข่าวสารที่ป้อนให้แก่ Adaptive Filter ไม่มีความสัมพันธ์กับสัญญาณปรุณภูมิ

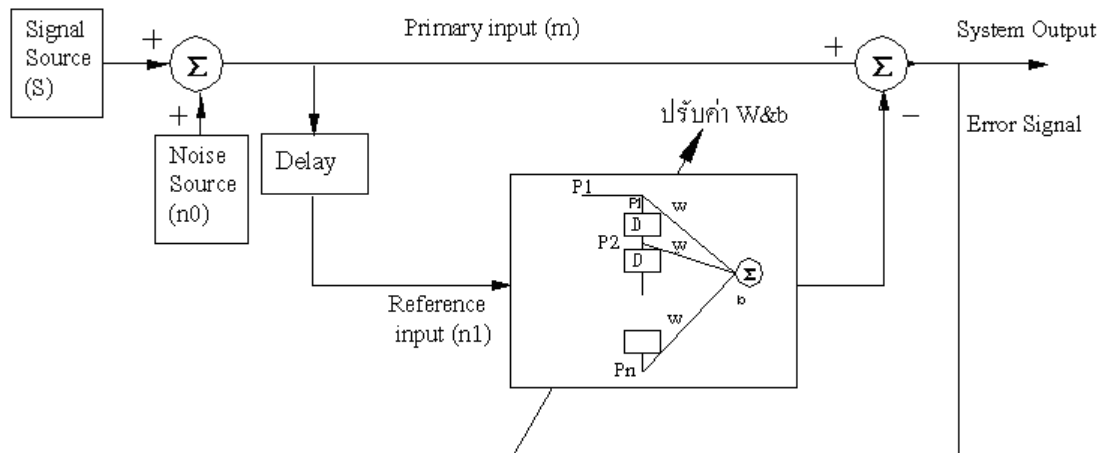
จากภาพประกอบ 2-8 แสดงถึง Adaptive Filter ชนิดที่ไม่ใช้สัญญาณอ้างอิงจากภายนอก Adaptive Filter จะทำการผลิตเอาต์พุต ( $a$ ) เพื่อประมาณค่าของสัญญาณรบกวน ( $n_0$ ) และนำไปหักล้างจากสัญญาณที่วัดได้ ผลลัพธ์สุดท้ายที่ได้จากระบบคือสัญญาณข่าวสารที่ทำการกำจัดสัญญาณรบกวนแล้ว [B.Widrow, 1985]



ภาพประกอบ 2-8 Adaptive Filter ชนิดที่ไม่ต้องใช้สัญญาณอ้างอิงจากภายนอก

## 2.5 การประยุกต์ใช้โครงข่าย ADALINE เป็น Adaptive Filter ชนิดที่ไม่ต้องใช้สัญญาณอ้างอิงจากภายนอก

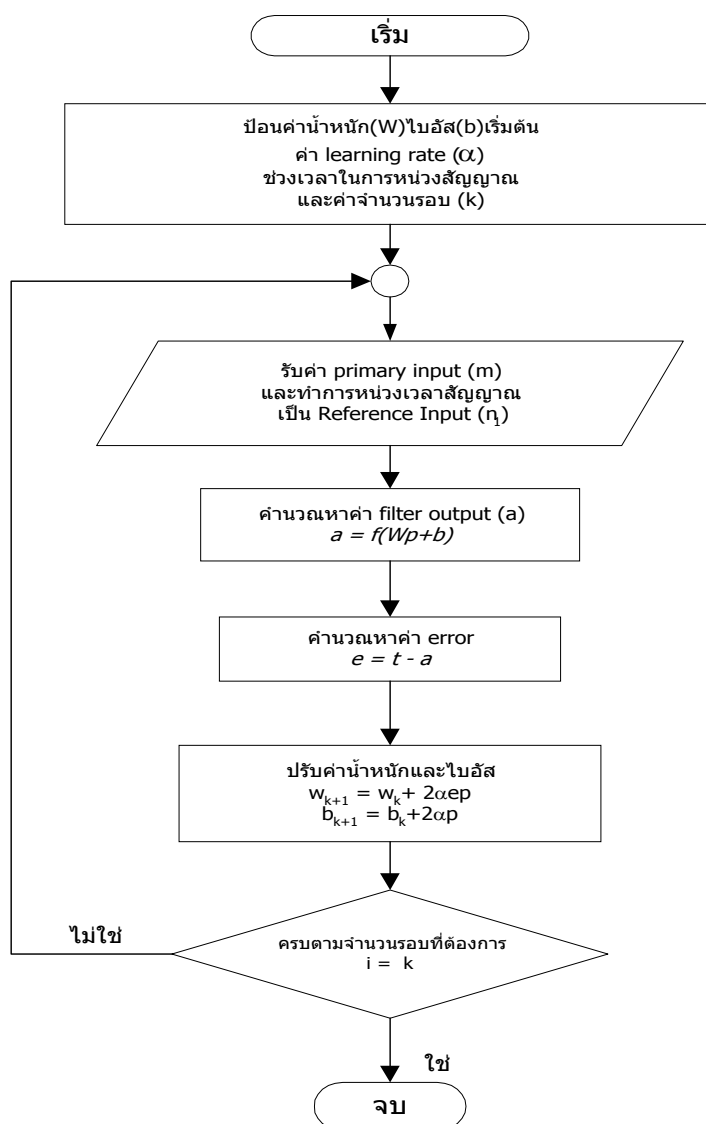
ภาพประกอบ 2-9 แสดงถึงการประยุกต์ใช้โครงข่าย ADALINE เป็น Adaptive Filter ชนิดที่ไม่มีการป้อนสัญญาณอ้างอิงจากภายนอก ซึ่งสามารถนำโครงข่าย ADALINE มาทำหน้าที่แทน Adaptive Filter ได้ โดยสัญญาณอินพุตที่ได้ทำการหน่วงเวลา จะเป็นสัญญาณอ้างอิง โครงข่ายจะทำการคำนวณหาค่าเอาต์พุตและนำไปหักล้างกับสัญญาณปรุณภูมิ จะได้เป็นสัญญาณความผิดพลาด และนำสัญญาณความผิดพลาดนี้ไปทำการปรับค่าน้ำหนักตามกฎการเรียนรู้ของโครงข่าย ADALINE และสัญญาณความผิดพลาดนี้จะเป็นสัญญาณข่าวสารที่ต้องการที่ได้ทำการกำจัดสัญญาณรบกวนแล้ว



ภาพประกอบ 2-9 การประยุกต์ใช้โครงข่าย ADALINE เป็น Adaptive Filter (แบบที่ไม่ใช้สัญญาณอ้างอิงจากภายนอก)

## 2.6 การพัฒนาโปรแกรมเพื่อประยุกต์ใช้โครงข่ายประสาทเป็น Adaptive filter

การพัฒนาโปรแกรม ได้ทำการเขียนโปรแกรมด้วยภาษาซี ให้ทำหน้าที่เป็นโครงข่ายประสาท ADALINE เพื่อกำจัดสัญญาณรบกวนของสัญญาณไฟฟ้าของกล้ามเนื้อลาย และนำโปรแกรมที่เขียนไปประยุกต์ใช้ด้วยไมโครคอนโทรลเลอร์ AVR ATmega32 และไมโครคอนโทรลเลอร์ dsPIC30F2010 โดยกระบวนการเขียนโปรแกรมของโครงข่ายประสาท ADALINE เป็นดังโพลซาร์ทด้านล่าง



ภาพประกอบ 3-18 โพลซาร์ทการทำงานของโครงข่าย ADALINE ในการประยุกต์ใช้เป็น Adaptive Filter แบบที่ไม่ใช้สัญญาณอ้างอิงจากภายนอก