


โครงข่ายประสาทเทียมและฮอปฟิลด์เน็ตเวิร์ก

2.1 กล่าวนำ

ในทางประสาทวิทยาทราบว่ามีสมองของมนุษย์ประกอบด้วยเซลล์ประสาท (neuron cell) จำนวน 10^{10} ถึง 10^{11} เซลล์ [3] ซึ่งโครงสร้างของเซลล์ประสาทประกอบด้วย

1. Soma เป็นตัวเซลล์ประสาท
2. Axon เป็นเส้นใยประสาทที่ต่อออกจากเซลล์ประสาทโดยทำหน้าที่เป็นด้านออกของเซลล์ประสาทเพื่อส่งต่อไปยังเซลล์ประสาทอื่น
3. Dendrites ทำหน้าที่เป็นด้านเข้าของเซลล์ประสาทเพื่อรับสัญญาณจากเซลล์ประสาทตัวอื่น โดยผ่าน axon ซึ่งต่อกับ synapses เพื่อส่งไปยัง soma
4. Synapses เป็นตัวต่อ dendrite กับ axon จากเซลล์ประสาทอื่น

โครงสร้างของเซลล์ประสาทนี้สามารถแสดงได้ดังรูปที่ 2.1

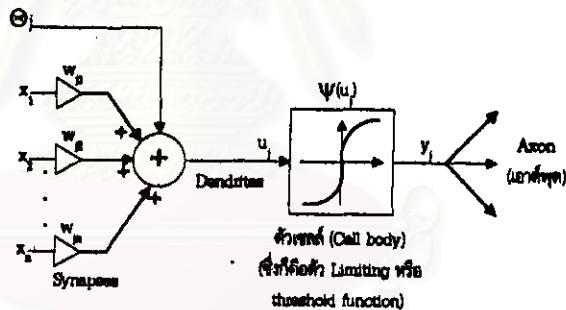


รูปที่ 2.1 โครงสร้างของเซลล์ประสาททางชีวภาพ

การทำงานของโครงข่ายประสาทจะทำงานกันแบบขนานไปพร้อมๆ กันในแต่ละเซลล์ประสาทจึงทำให้โครงข่ายประสาทสามารถทำการประมวลผลได้อย่างรวดเร็ว ด้วยเหตุนี้จึงได้มีการพยายามจำลองโครงข่ายประสาทขึ้นเพื่อใช้ในการแก้ปัญหาต่างๆ

2.2 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural networks) หรือเรียกสั้นๆ ว่า "นิวรอลเน็ตเวิร์ก" คือโครงข่ายที่สร้างขึ้นเพื่อเรียนแบบการทำงานของโครงข่ายประสาทจริงๆ กล่าวโดยทั่วไปแล้วโครงข่ายประสาทเทียมคือระบบประมวลสัญญาณที่ประกอบด้วยตัวประมวลผลอย่างง่าย ๆ จำนวนมากซึ่งเรียกทหน่วยประมวลผลเหล่านี้ว่า "นิวรอน (neuron)" มาต่อเข้าด้วยกันเป็นโครงข่าย ซึ่งการทำงานของโครงข่ายนี้จะกระทำแบบขนานไปพร้อมๆ กันในแต่ละนิวรอนเพื่อแก้ปัญหาที่ต้องการ โดยแบบจำลองพื้นฐานของนิวรอนแสดงดังรูปที่ 2.2



รูปที่ 2.2 แบบจำลองพื้นฐานของเซลล์ประสาทเทียม (artificial neuron cell)

จากรูปที่ 2.2 จะเห็นว่าน้ำหนัก (weight, w_j) ทำหน้าที่เหมือนกับ synapses เพื่อต่อด้านเข้า x_i เข้าสู่ตัวรวมซึ่งทำหน้าที่เหมือนกับ dendrites เพื่อส่งสัญญาณเข้าสู่ตัว activation function ($\Psi(u)$) ซึ่งเปรียบเสมือนกับ soma ส่วน Θ_j เป็นค่าระดับอ้างอิงที่ป้อนจากภายนอก ผลของการประมวลผล (y_j) จะถูกส่งออกที่ด้านออกของตัวขยายแบบไม่เป็นเชิงเส้นซึ่งเปรียบเสมือนกับ axon สามารถเขียนสมการได้เป็น

$$y_j = \Psi \left(\sum_{i=1}^n w_{ji} x_i + \Theta_j \right) \quad (2.1)$$

ค่าระดับอ้างอิงจากภายนอก Θ_j สามารถเขียนในรูปของน้ำหนักได้โดย $w_{j0} = \Theta_j$ และ $x_0 = 1$ จึงทำให้สมการที่ (2.1) เขียนใหม่ได้เป็น

$$y_j = \Psi\left(\sum_{i=0}^n w_{ji} x_i\right) \quad (2.2)$$

เนื่องจากมีหลายวิธีในการต่อนิวรอนเข้าด้วยกันเป็นโครงข่ายขนาดใหญ่ ซึ่งรูปแบบของการต่อนี้เรียกว่าสถาปัตยกรรมซึ่งสถาปัตยกรรมของนิวรอลเน็ตเวิร์กสามารถแบ่งออกได้เป็น

1. Feedforward (multilayer) networks
2. Feedback (recurrent) networks
3. Cellular networks


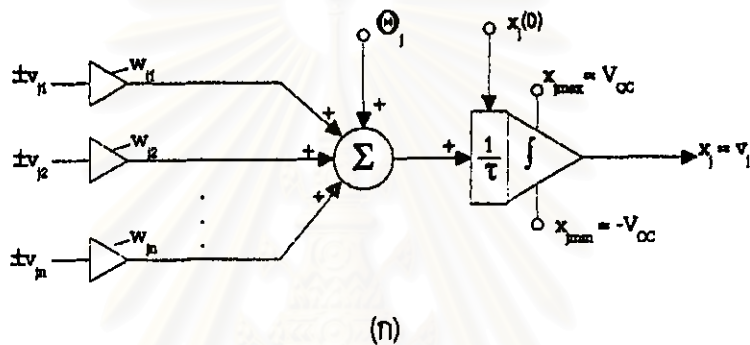
ได้มีการเสนอฮอปฟิลด์เน็ตเวิร์กในการแก้ปัญหาการหาค่าที่เหมาะสมที่สุด [4] ซึ่งฮอปฟิลด์เน็ตเวิร์กจัดเป็นนิวรอลเน็ตเวิร์กชนิดหนึ่ง โดยมีสถาปัตยกรรมเป็นแบบรีเคอร์เรนท์เน็ตเวิร์ก จากคุณสมบัติของนิวรอลเน็ตเวิร์กที่การประมวลผลจะกระทำแบบขนานไปพร้อมๆ กันในนิวรอนแต่ละตัว จึงทำให้สามารถประมวลผลได้อย่างรวดเร็ว ดังนั้นในการใช้ฮอปฟิลด์เน็ตเวิร์กเพื่อแก้ปัญหาการหาค่าที่เหมาะสมที่สุดจึงสามารถทำได้อย่างรวดเร็ว

วิทยานิพนธ์ฉบับนี้จึงใช้ฮอปฟิลด์เน็ตเวิร์กในการจัดสรรบัพเฟอร์ด้านเข้าของแพ็กเกตสวิตช์ เนื่องจากในการจัดสรรบัพเฟอร์ด้านเข้าของแพ็กเกตสวิตช์อาจต้องการความเร็วในการจัดสรรเพื่อให้ทันต่อการเปลี่ยนแปลงของค่าความเข้มทราฟฟิกที่เข้ามายังด้านเข้าต่างๆ ในที่นี้จะกล่าวถึงหลักการพื้นฐานของฮอปฟิลด์เน็ตเวิร์ก และฮอปฟิลด์เน็ตเวิร์กที่ใช้ในการแก้ปัญหาโปรแกรมมิ่งแบบไม่เป็นเชิงเส้นซึ่งเป็นปัญหาในที่นี้

2.3 หลักการพื้นฐานของฮอปฟิลด์เน็ตเวิร์ก

2.3.1 แบบจำลองของนิวรอนที่ใช้ในฮอปฟิลด์เน็ตเวิร์ก

ฮอปฟิลด์เน็ตเวิร์กประกอบด้วยหลายๆ นิวรอนนำมาเชื่อมต่อกันเป็นโครงข่ายโดยมีการป้อนกลับค่าจากด้านออกของนิวรอนแต่ละตัวเพื่อไปยังด้านเข้าของนิวรอนแต่ละตัวรวมทั้งตัวเอง ซึ่งแบบจำลองของตัวนิวรอนในฮอปฟิลด์เน็ตเวิร์กแสดงดังรูปที่ 2.3



รูปที่ 2.3 (ก) บล็อกไดอะแกรม (ข) วงจรไฟฟ้าพื้นฐานของนิวรอนในฮอปฟิลด์เน็ตเวิร์ก

จากรูปที่ 2.3 จะเห็นว่าประกอบด้วยตัวอินทิเกรตซึ่งทำหน้าที่เสมือน soma, ตัวรวมสัญญาณที่เข้ามาซึ่งเสมือน dendrites และค่าน้ำหนัก $w_{ji} = \frac{1}{R_{ji}}$ ซึ่งเปรียบเสมือน synapses

สังเกตว่าที่ด้านออกของตัวอินทิเกรตจะให้ค่าที่ด้านออก 2 ค่าคือ $+v_j$ และ $-v_j$ ทั้งนี้เนื่องจากต้องการทำให้ตัวด้านทานซึ่งเปรียบเสมือน synaptic weight เป็นได้ทั้งค่าบวกหรือลบ นั่นคือถ้า synaptic weight เป็นบวกซึ่งได้จากการต่อ R_{ji} กับ $+v_j$ และ synaptic weight เป็นลบได้จากการต่อ R_{ji} กับ $-v_j$ จากรูปที่ 2.3 (ก) สามารถเขียนสมการเชิงอนุพันธ์เป็น

$$\tau_j \frac{dv_j}{dt} = \sum_{i=1}^n v_i w_{ji} + \Theta_j \quad (2.3)$$

หรือจากรูปที่ 2.3 (ข) จะได้เป็น

$$\begin{aligned} C_j \frac{dv_j}{dt} &= \sum_{i=1}^n \frac{v_i}{R_{ji}} + I_j \\ &= \sum_{i=1}^n v_i G_{ji} + I_j \end{aligned} \quad (2.4)$$

เมื่อ $\tau_j = C_j$ เป็นค่าคงที่เวลาของนิวรอน, $\Theta_j = I_j$ เป็นค่าคงที่หรือกระแสที่ป้อนจากภายนอกเพื่อเป็นระดับอ้างอิงของตัวนิวรอน และ G_{ji} เป็นค่าความนำไฟฟ้า (conductance) ซึ่งเป็นส่วนกลับของ R_{ji}

ค่าคงที่เวลาของนิวรอน τ_j นี้จะมีผลต่อการอัตราการเรียนรู้ของนิวรอนเน็ตเวิร์ก μ เนื่องจากเป็นส่วนกลับต่อกันนั่นคือถ้าค่าคงที่เวลาของนิวรอนมีค่ามากก็จะทำให้อัตราการเรียนรู้เร็ว แต่ถ้าค่าคงที่เวลาของ นิวรอนมีค่าน้อยก็จะทำให้อัตราการเรียนรู้ของเน็ตเวิร์กช้า

ค่า synaptic weight ก็คือค่าของ $w_{ji} = G_{ji} = \frac{1}{R_{ji}}$ ที่ต่อจากด้านออกของตัวขยายที่ j ไปยังด้านเข้าของตัวขยายที่ i ซึ่งถ้าเป็น excitatory synapse ($w_{ji} > 0$) ก็จะต่อ R_{ji} เข้ากับ $+v_j$ และ inhibitory synapse ($w_{ji} < 0$) ก็จะต่อ R_{ji} เข้ากับ $-v_j$

2.3.2 ฮอปฟิลด์เน็ตเวิร์ก

เมื่อนานิวรอนที่ได้กล่าวมาแล้วในบทที่ 2.3.1 มาต่อเข้าด้วยกันเป็นโครงข่ายแสดงดังรูปที่ 2.4 จะได้โครงข่ายที่เรียกว่า "ฮอปฟิลด์เน็ตเวิร์ก (Hopfield Network)" ซึ่งประกอบด้วยนิวรอนจำนวน n ตัวที่

ต่อเข้าด้วยกัน โดยด้านออกที่เป็นอินเวอร์สของตัวขยายแต่ละตัวจะทำหน้าที่เพื่อให้ได้น้ำหนักเป็นลบ (inhibitory) และผลรวมของน้ำหนักจะได้จากการรวมของกระแสที่ไหลผ่านตัวต้านทานที่ด้านเข้าของตัวขยายแต่ละตัว ดังนั้นจากกฎกระแสของเคอร์ชอฟฟ์ (Kirchhoff's Current Law (KCL)) จะได้

$$C \frac{dx}{dt} = Wx + \Theta \quad (2.5)$$

เมื่อ

$C = \text{diag}(C_1, C_2, \dots, C_n)$ ซึ่งเป็นค่าคงที่เวลา


$\bar{x} = [x_1, x_2, \dots, x_n]^T$ เวกเตอร์ด้านออกของตัวอินทิเกรต

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ w_{n1} & w_{n2} & \dots & w_{nn} \end{bmatrix} \quad \text{เป็นเมตริกซ์ของการต่อ หรือ เมตริกซ์ของ synaptic}$$

weights


$$\Theta = [\Theta_1, \Theta_2, \dots, \Theta_n]^T \quad \text{เวกเตอร์ของค่าคงที่ซึ่งป้อนจากภายนอก}$$

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



(ก)

รูปที่ 2.4 (ก) บล็อกโดยะแกรมพื้นฐานของฮอปฟิลด์เน็ตเวิร์ก



(ข)

รูปที่ 2.4 (ข) วงจรไฟฟ้าพื้นฐานของฮอปฟิลด์เน็ตเวิร์ก

สมการพลังงานของเน็ตเวิร์ก

$$E(\bar{x}) = -\frac{1}{2} \bar{x}^T W \bar{x} - \bar{x}^T \bar{b} \quad (2.6)$$

และ

$$\frac{d\bar{x}}{dt} = -\nabla_{\bar{x}} E(\bar{x}) = W \bar{x} + \bar{b} \quad (2.7)$$

เมื่อ

$$\bar{x} = [x_1, x_2, \dots, x_n]^T$$

$$\nabla_{\bar{x}} E(\bar{x}) = \left[\frac{\partial E}{\partial x_1}, \frac{\partial E}{\partial x_2}, \dots, \frac{\partial E}{\partial x_n} \right]^T$$

2.4 การเขียนปัญหาการหาค่าที่เหมาะสมที่สุดแบบไม่มีข้อบังคับในรูปของฮอปฟิลด์เน็ตเวิร์ก

ถ้า $E(\bar{x})$ เป็นฟังก์ชันใดๆ ดังนั้นในการหาเวกเตอร์ \bar{x} ซึ่งทำให้ค่าของฟังก์ชันวัตถุประสงค์ $E(\bar{x})$ มีค่าต่ำสุดโดยไม่มีข้อบังคับโดยใช้วิธีการเดียนแดลเซนต์ แสดงได้เป็น


$$\bar{x}^{(k+1)} = \bar{x}^{(k)} - \mu \nabla E(\bar{x}^{(k)}) \quad (2.8)$$

$$\frac{d\bar{x}}{dt} = -\mu \nabla_{\bar{x}} E(\bar{x}) \quad (2.9)$$

$\bar{x}^{(k)}$ เป็นค่าของเวกเตอร์ \bar{x} ในรอบของการทำซ้ำที่ k ($k = 0, 1, 2, \dots$) และ $\bar{x}^{(0)}$ คือค่าเวกเตอร์ \bar{x} เริ่มต้นที่ประมาณใกล้จุดที่เวกเตอร์ \bar{x} ทำให้ฟังก์ชันวัตถุประสงค์ต่ำสุด (\bar{x}^*) ซึ่งเป็น local minimum ของฟังก์ชัน $E(\bar{x})$ ณ จุดนี้จะทำให้ $\nabla E(\bar{x}) = 0$ และ $\frac{d\bar{x}}{dt} = 0$

ทิศทางของการเคลื่อนตำแหน่งจากจุด $\bar{x}^{(k)}$ ไปยังจุด $\bar{x}^{(k+1)}$ จะไปตามทิศทางของ $-\nabla E(\bar{x})$ โดยความยาวของการเคลื่อนที่ในแต่ละขั้นจะขึ้นอยู่กับค่า μ นั่นคือถ้า μ มีค่ามากความยาวในการเคลื่อน

ที่จากจุด $\bar{x}^{(k)}$ ไปยังจุด $\bar{x}^{(k+1)}$ ก็จะมากยิ่งขึ้นทำให้การเคลื่อนเข้าสู่อันดับ \bar{x}^* เร็ว และถ้า μ มีค่าน้อยความยาวในการเคลื่อนที่จากจุด $\bar{x}^{(k)}$ ไปยังจุด $\bar{x}^{(k+1)}$ ก็จะน้อยจึงทำให้การเคลื่อนเข้าสู่อันดับ \bar{x}^* ช้า ในการเลือกค่า μ นี้จะต้องเลือกให้พอเหมาะเนื่องจากถ้า ความยาวของการเคลื่อน μ ยาวเกินไปอาจเคลื่อนที่ข้ามจุด \bar{x}^* ไปจึงทำให้ไม่สามารถเข้าสู่อันดับ \bar{x}^* นี้ได้เนื่องจากจะเกิดการข้ามไปมาบริเวณจุด \bar{x}^* นี้แน่นอน แต่ถ้า μ มีค่าน้อยเกินไปการเคลื่อนเข้าสู่อันดับ \bar{x}^* ก็จะช้า จากสมการที่ (2.8)-(2.9) สามารถเขียนเป็นบล็อกไดอะแกรมได้ดังรูปที่ 2.5



รูปที่ 2.5 บล็อกไดอะแกรมของฮอปฟิลด์เน็ตเวิร์กที่ใช้ในการหาค่าต่ำสุดของฟังก์ชันวัตถุประสงค์แบบไม่มีข้อบังคับ

2.5 การแก้ปัญหาโปรแกรมเชิงแบบควอดราติกซึ่งมีข้อบังคับโดยใช้ฮอปฟิลด์เน็ตเวิร์ก

ในบทนี้จะเป็นตัวอย่างเป็นตัวอย่างของการนำวิธีที่กล่าวในบทที่ 2.4 มาใช้ในการแก้ปัญหาโปรแกรมเชิงแบบควอดราติกซึ่งเป็นกรณีหนึ่งของปัญหาโปรแกรมเชิงแบบไม่มีข้อบังคับเป็นแบบเชิงเส้น โดยที่ปัญหาโปรแกรมเชิงแบบควอดราติกเขียนในรูปมาตรฐานได้เป็น

หาค่าต่ำสุด $f(x) = c^T x + \frac{1}{2} x^T G x$ (2.10)

$$\text{ข้อบังคับ} \quad Ax \geq \bar{b}, \quad \bar{x} \geq 0$$

เมื่อ G เป็นเมทริกซ์สมมาตรขนาด $n \times n$ ซึ่งปัญหาข้างต้นสามารถเขียนในรูปของสเกลาร์ดังนี้

$$\text{หาค่าต่ำสุด} \quad f(\bar{x}) = \sum_{j=1}^n c_j x_j + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n g_{ij} x_i x_j \quad (2.11)$$

$$\text{ข้อบังคับ} \quad \sum_{j=1}^n a_{ij} x_j \geq b_j, \quad x_j \geq 0$$

ถ้า $G = 0$ จะทำให้ปัญหาโปรแกรมมิงแบบควอดราติกกลายเป็นปัญหาโปรแกรมมิงแบบเชิงเส้น

ในการแก้ปัญหาเพื่อหาค่าที่เหมาะสมที่สุดของสมการในที่นี่จะใช้วิธีพินอลตี (penalty method) [3] ซึ่งเป็น การเปลี่ยนปัญหาโปรแกรมมิงแบบมีข้อบังคับไปเป็นปัญหาโปรแกรมมิงแบบไม่มีข้อบังคับ โดยการรวมพินอลตีฟังก์ชัน (penalty function) เข้ากับฟังก์ชันวัตถุประสงค์ $f(\bar{x})$ ซึ่งเทอมของพินอลตีที่เพิ่มเข้าไปนี้จะมีค่าสูงเมื่อมีการละเมิด ข้อบังคับของปัญหาโปรแกรมมิงที่ต้องการหาค่าต่ำสุด ดังนั้นสามารถเขียนสมการพลังงานได้เป็น


$$\begin{aligned} E(\bar{x}, \kappa) &= f(\bar{x}) - \kappa \sum_{i=1}^m [r_i(\bar{x})]_- \\ &= \sum_{j=1}^n c_j x_j + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n g_{ij} x_i x_j - \kappa \sum [r_i(\bar{x})]_- \end{aligned} \quad (2.12)$$

ซึ่ง $\bar{x} \geq 0$ และ κ เป็นพินอลตีพารามิเตอร์ (penalty parameter) และ

$$r_i(\bar{x}) = \sum_{j=1}^n a_{ij} x_j - b_i \quad (2.13)$$

$$[r_i]_- = \min\{0, r_i\}$$

โดยแสดงความสัมพันธ์ระหว่าง $r_i(\bar{x})$ กับ $\min\{0, r_i(x)\}$ ดังรูปที่ 2.6



รูปที่ 2.6 ความสัมพันธ์ระหว่าง $r_j(x)$ กับ $\min\{0, r_j(x)\}$

โดยที่

$$\begin{aligned} \min\{0, r_j\} &= 0 & \text{ถ้า } r_j > 0 \\ &= r_j & \text{ถ้า } r_j \leq 0 \end{aligned}$$

ซึ่ง $\min\{0, r_j\}$ คือฟังก์ชันฟังกชัน

ใช้วิธีการเดียวกันเพื่อหาค่าต่ำสุดของสมการพลังงาน ซึ่งเขียนเป็นสมการเชิงอนุพันธ์ได้เป็น

$$\frac{dx_j}{dt} = -\mu \nabla E = -\mu \left[c_j + \sum_{i=1}^n g_{ji} x_i + \kappa \sum_{i=1}^m S_i a_{ij} \right] \quad (j=1, 2, \dots, n) \quad (2.14)$$


เมื่อ $\mu > 0, \kappa > 0$ ซึ่ง μ คืออัตราการเรียนรู้ของเน็ตเวิร์ก (ความยาวในการเคลื่อนที่จากจุด $\vec{x}^{(k)}$ ไปยังจุด $\vec{x}^{(k+1)}$)

$$\begin{aligned} S_i &= 1, & \text{ถ้า } r_i(\vec{x}) < 0 \\ &= 0, & \text{ถ้า } r_i(\vec{x}) \geq 0 \end{aligned}$$

กำหนดให้ $\frac{dx_j^{(k)}}{dt}$ เป็นอัตราการเปลี่ยนแปลงของเอาต์พุตของเน็ตเวิร์กในรอบที่ k ซึ่งจะนำค่าที่ได้นี้ไปคูณกลับไปยังอินพุตเพื่อทำการปรับค่าเอาต์พุตของเน็ตเวิร์กในรอบที่ $k+1$ ดังนั้นจึงเขียนได้ว่า

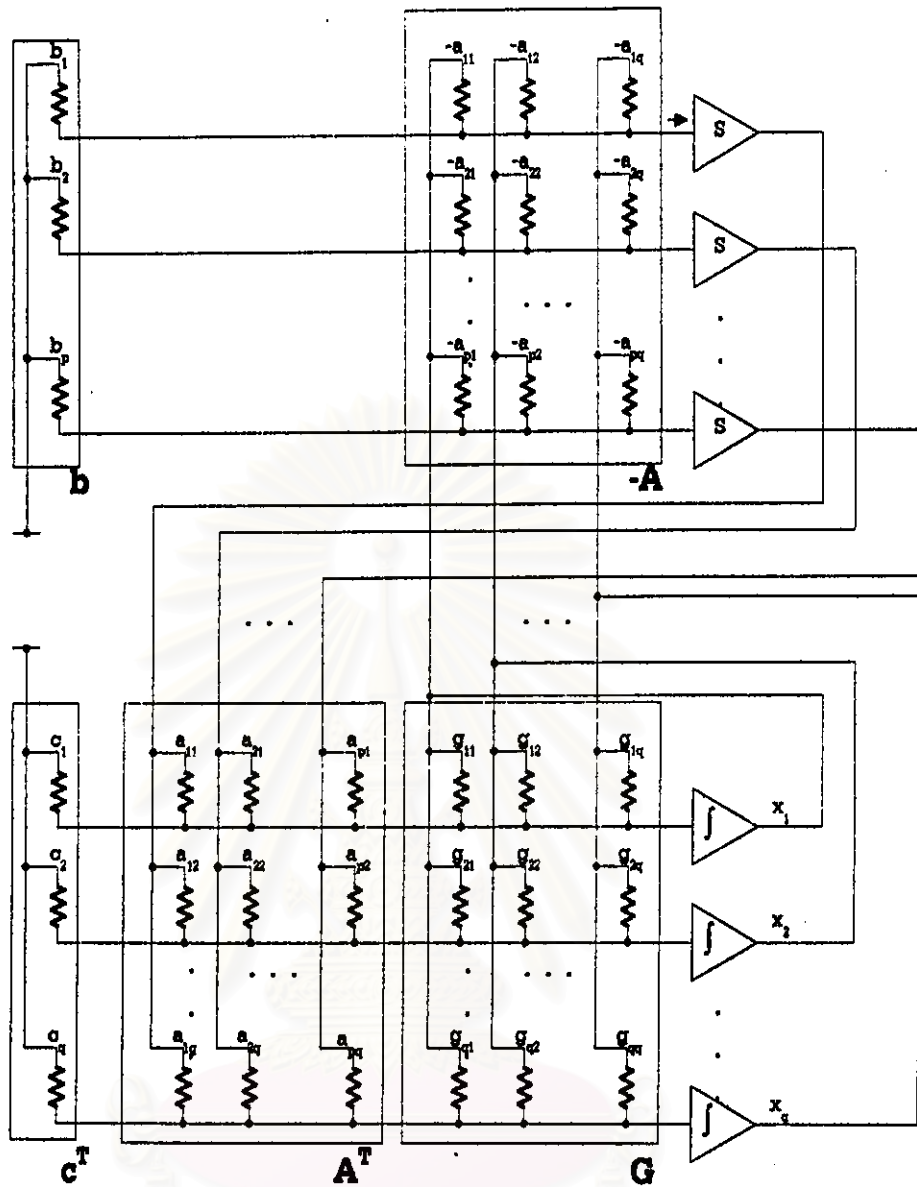
$$x_j^{(k+1)} = x_j^{(k)} - \mu^{(k)} \left[c_j + \sum_{i=1}^n g_{ji} x_i^{(k)} + \kappa \sum_{i=1}^m S_i^{(k)} a_{ij} \right] \quad (2.15)$$

สามารถเขียนบล็อกไดอะแกรมได้ดังรูปที่ 2.7(ก) และวงจรมุมูลย์ดังรูปที่ 2.7(ข)



รูปที่ 2.7 (ก) บล็อกไดอะแกรมของฮอปฟิลด์เน็ตเวิร์กที่ใช้ในการแก้ปัญหาโปรแกรมมิงแบบควอดราติก

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 2.7 (ข) วงจรสมมุทธ์ของฮอปฟิลด์เน็ตเวิร์กที่ใช้ในการแก้ปัญหาโปรแกรมเรียงแบบควอดราติก

สถาบันวิจัยดาราศาสตร์
จุฬาลงกรณ์มหาวิทยาลัย