

รายการอ้างอิง

ภาษาอังกฤษ

- Chua, L.O., and Lin, G.N. 1984. Nonlinear Programming without Computation. **IEEE Transaction on Circuit and System.** 31: 182-188.
- Cichocki, A., and Unbehauen, R. 1993. **Neural Networks for Optimization and Signal Processing.** Chichester: Wiley & Sons.
- Fausett, L. 1994. **Fundamentals of Neural Networks Architecture, Algorithm, and Applications.** USA.: Prentice Hall International Inc.
- Glasos, M.P., Hui, S., and Zak, S.H. 1994. On Solving Constrained Optimization Problems with Neural Networks. **IEEE Conference on Neural Network.** 7: 4547-4552.
- Hopfield, J.J., and Tank, D.W. 1986. Simple ‘neural’ optimization network and a/d converter signal decision circuit and a linear programming circuit. **IEEE Transaction on Circuit and System.** 33: 533-541.
- Kai, H. 1993. **Advanced Computer Architecture.** Singapore: McGraw-Hill International Inc.
- Kennedy, M.P., and Chua, L.O. 1988. Neural Networks for Nonlinear Programming. **IEEE Transaction on Circuit and System.** 35: 554-562.
- Prithviraj, B. 1994. **Parallel Algorithms for VLSI Computer-Aided Design.** USA.: Prentice Hall International Inc.
- Rao, S.S. 1989. **Optimization Theory and Application.** India: Wiley Eastern Limited.
- Rodríguez-Vázquez, A., Domínguez-Castro, R., Rueda, A., Huertas, J.L., and Sánchez-Sinencio, E. 1990. Nonlinear Switched-Capacitor Neural Networks for Optimization Problems. **IEEE Transaction on Circuit and System.** 37: 384-398.
- Schalkoff, R. 1992. **Pattern Recognition.** Canada: Wiley & Sons.
- Utkin, V.I. 1978. **Sliding Modes and Their Application in Variable Structure Systems.** Moscow: MIR Publishers.
- Zurada, J.M. 1992. **Introduction to Artificial Neural Systems.** Singapore: West Publishing Company.



ภาคผนวก

ศูนย์วิทยบริพยากร
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ก.

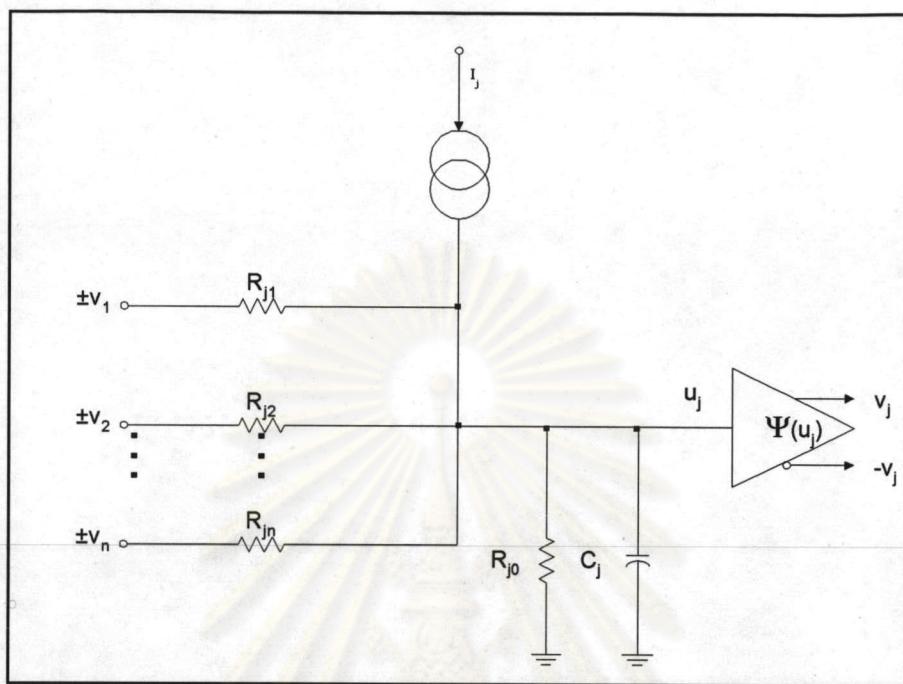
รูปแบบพื้นฐานของรูปแบบขอบเขต

ความนำ

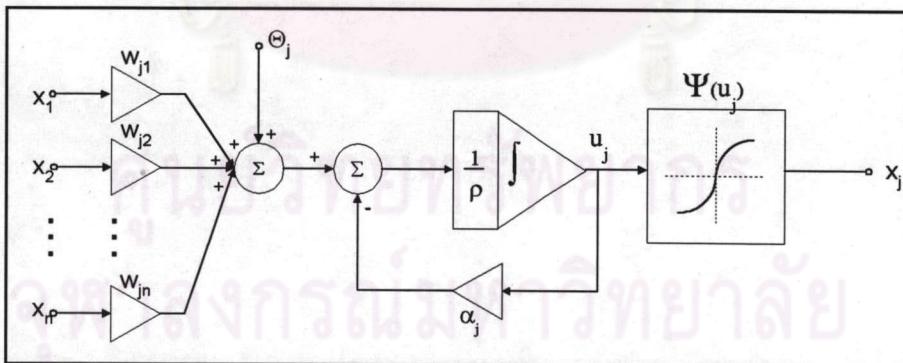
ในภาคผนวกนี้ กล่าวถึงรูปแบบพื้นฐานของรูปแบบขอบเขตซึ่งเป็นรูปแบบหนึ่งของเครือข่ายนิวรอลที่นิยมใช้ในการแก้ปัญหาการหาค่าอปติมัม รูปแบบขอบเขตนี้มีโครงสร้างที่ง่ายและมีลักษณะการทำงานที่ชินงานกัน ซึ่งในที่นี้แสดงในรูปของโครงสร้างวงจรไฟฟ้าและโครงสร้างทางบล็อกไดอะแกรม

รูปแบบพื้นฐานของรูปแบบขอบเขต

Hopfield Model เป็นรูปแบบหนึ่งของเครือข่ายนิวรอล (Neural Networks) ที่นิยมใช้ในการแก้ปัญหาการหาค่าอปติมัม ซึ่งแสดงในรูปที่ ก.1 และรูปที่ ก.2 โดยแสดงถึงโครงสร้างทางวงจรไฟฟ้าและโครงสร้างทางบล็อกไดอะแกรม โครงสร้างทางวงจรไฟฟ้าประกอบด้วยตัวความจุไฟฟ้า (Capacitor) C_j , ตัวความต้านทาน (Resistor) R_{ji} และตัวขยายไม่เชิงเส้น (Nonlinear Amplifier) หรือ Sigmoid activation function ซึ่งถ้าค่าน้ำหนัก (Weight) มีค่าเป็นบวก ตัวความต้านทาน R_{ji} จะต่อ กับ $+v$ และถ้าค่าน้ำหนักมีค่าเป็นลบ ตัวความต้านทาน R_{ji} จะต่อ กับ $-v$ โดยให้กระแส I_j เป็น Bias



รูปที่ ก.1 วงจรไฟฟ้าของเซลล์นิวรอลแบบชอปปิลต์



รูปที่ ก.2 บล็อกไซด์แกรมของเซลล์นิวรอลแบบชอปปิลต์

จาก Ohm's Law และ Kirchoff's Current Law จะได้ว่า

$$c_j \frac{du_j}{dt} = \frac{-u_j}{R_j} + \sum_{i=1}^n \frac{v_i}{R_{ji}} + I_j \quad (ก.1)$$

โดยที่

$$v_j = \Psi(u_j) \quad , j = 1, 2, \dots, n$$

$$\begin{aligned}\frac{1}{R_j} &= \frac{1}{R_{j0}} + \sum_{i=1}^n \frac{1}{R_{ji}} \\ &= G_{j0} + \sum_{i=1}^n G_{ji}\end{aligned}$$

จากสมการที่ (ก.1) สามารถเขียนให้อยู่ในรูปทั่วไปได้ดังนี้คือ

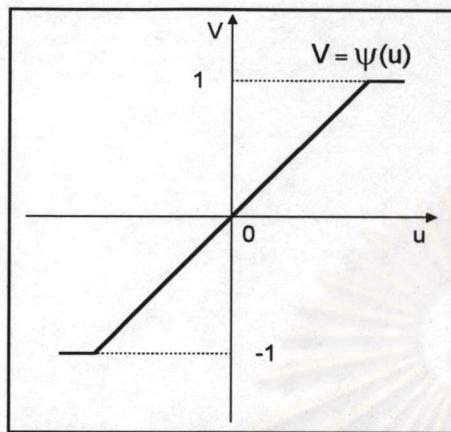
$$\rho \frac{du_j}{dt} = -\alpha_j u_j + \left(\sum_{i=1}^n w_{ji} x_i + \theta_j \right)$$

โดยที่

$$x_j = \Psi(u_j), \quad j = 1, 2, \dots, n$$

ฟัง Ψ คือ Sigmoid activation function โดยมีรูปแบบตามรูปที่ ก.3(1) - ก.3(4)

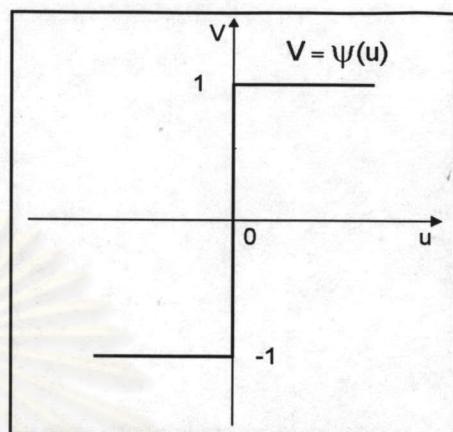
(1)



Saturation limiter

(Linear Lamp)

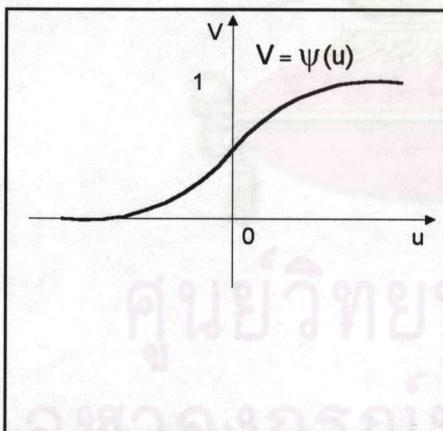
(2)



Hard limiter

(Signum function)

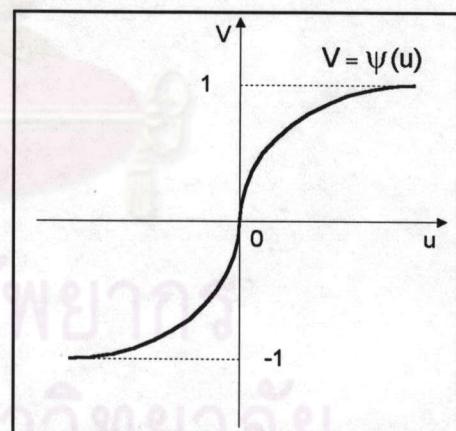
(3)



Sigmoid limiter

(Unipolar)

(4)

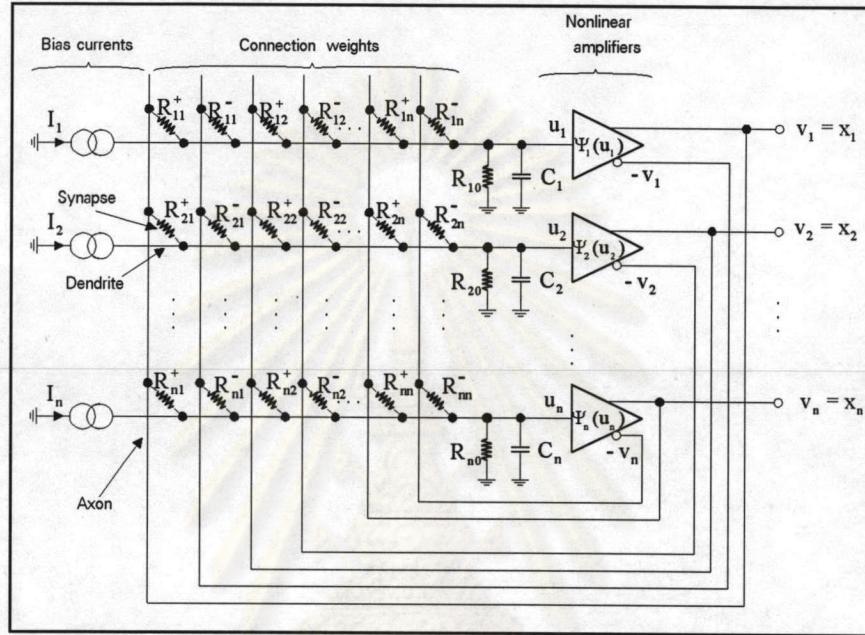


Sigmoid limiter

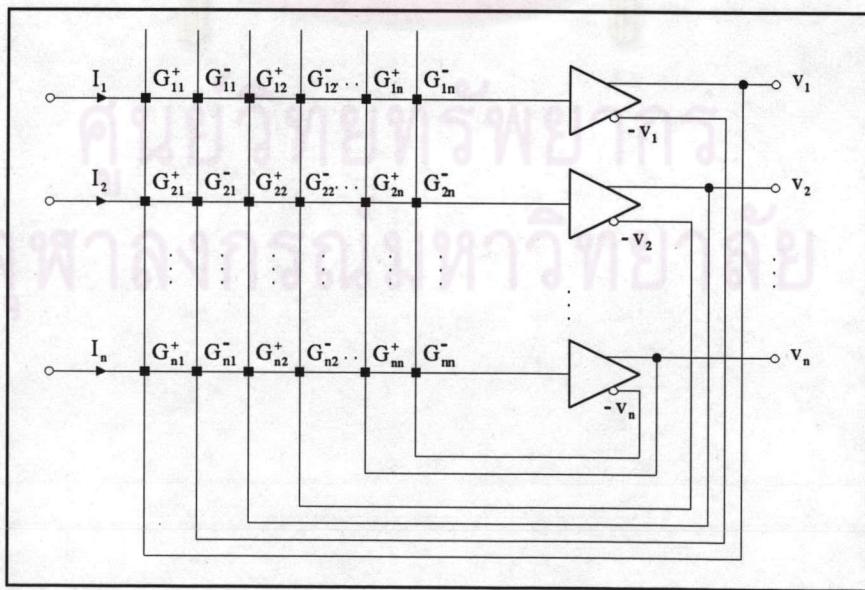
(Bipolar)

รูปที่ ๓ Sigmoid activation functions แบบต่างๆที่ใช้ในเครือข่ายนิวรอค

รูปแบบพื้นฐานของ Hopfield Model ประกอบด้วยตัวความจุไฟฟ้า, ตัวความต้านทาน, ตัวขยายไม่เชิงเส้น และแหล่งกำเนิดกระแสไฟฟ้า (Bias current sources) ดังแสดงในรูปที่ ก.4 และรูปที่ ก.5



รูปที่ ก.4 เครือข่ายนิวรอลแบบขอบพิล์ด



รูปที่ ก.5 โครงสร้างแบบง่ายๆ ของรูปแบบขอบพิล์ด

จากรูปที่ ก.4 จะได้ว่า

$$c_j \frac{du_j}{dt} = \sum_{i=1}^n G_{ji}(x_i - u_j) + I_j - \frac{u_j}{R_{j0}}$$

โดยที่

$$x_j = \Psi_j(u_j)$$

ซึ่งสามารถเขียนใหม่เป็น

$$c_j \frac{du_j}{dt} = -\frac{u_j}{R_j} + \sum_{i=1}^n G_{ji}x_i + I_j, \quad j = 1, 2, \dots, n$$

ซึ่ง

$c_j > 0$ เป็นตัวความจุไฟฟ้า

u_j และ x_j เป็นแรงดันไฟฟ้าเข้า และแรงดันไฟฟ้าออกของนิวรอลตัวที่ j

G_{ji} เป็น Conductance จากนิวรอลตัวที่ i ไปยังนิวรอลตัวที่ j

$$G_{ji} = \frac{1}{R_{ji}^+} - \frac{1}{R_{ji}^-} \quad \text{ซึ่ง } R_{ji}^\pm > 0$$

หรือ

$$G_{ji} = \begin{cases} \frac{1}{R_{ji}^+} & \text{if } G_{ji} > 0 \text{ with } R_{ji}^- = \infty \\ -\frac{1}{R_{ji}^-} & \text{if } G_{ji} < 0 \text{ with } R_{ji}^+ = \infty \end{cases}$$

$$\frac{1}{R_j} = \frac{1}{R_{j0}} + \sum_{i=1}^n \left(\frac{1}{R_{ji}^+} + \frac{1}{R_{ji}^-} \right)$$

และ $\Psi_j(u_j)$ คือ Monotonically increasing activation function สามารถเขียนเป็น

$$\Psi_j(u_j) = [1 + e^{-\gamma_j u_j}]^{-1} \quad \text{or} \quad \Psi_j(u_j) = \tanh(\gamma_j u_j)$$

ตารางที่ ก.1 การเปรียบเทียบข้อดีและข้อเสียของ Sigmoid activation function ที่นิยมใช้ทั่วไป

Activation Function	ข้อดี	ข้อเสีย
Hard Limter (Signum Function)	-เร็วและง่ายต่อการนำไปใช้ในกฎข้อรับ -เวอร์	-ไม่สามารถหาส่วนกลับได้ -ไม่มีส่วนที่เป็นเชิงเส้น -ไม่สามารถสร้างฟังก์ชันที่เรียบได้
Saturation Limiter (Linear Lamp)	-มีส่วนที่เป็นเชิงเส้น -สามารถสร้างฟังก์ชันที่เรียบได้ -ง่ายต่อการนำไปใช้งานจริง	-ไม่สามารถหาส่วนกลับได้
Sigmoid Limiter (Unipolar)	-สามารถหาส่วนกลับได้ -มีส่วนที่สามารถสร้างฟังก์ชันที่เรียบได้	-ยกต่อการนำไปใช้ในทางปฏิบัติ -ค่าสัญญาณออกจะมีแต่เฉพาะ ค่าบวก
Sigmoid Limiter (Bipolar)	-สามารถหาส่วนกลับได้ -มีส่วนที่สามารถสร้างฟังก์ชันที่เรียบได้ -ค่าสัญญาณออกจะมีแต่เฉพาะค่าบวก และค่าลบ	-ยกต่อการนำไปใช้ในทางปฏิบัติ

ภาคผนวก ๔.

การหาค่าอ้อปติมัมแบบพื้นฐาน

ความนำ

ในภาคผนวกนี้แบ่งเป็น 2 ส่วนคือ ส่วนแรกกล่าวถึงการหาค่าอ้อปติมัมแบบพื้นฐานซึ่งวิธีที่ใช้ในการหาค่าอ้อปติมัมมี 4 วิธีคือ วิธี Steepest Descent , วิธี Newton , วิธี Quasi-Newton และวิธี Conjugate Gradient และส่วนที่สองกล่าวถึงรูปแบบทางคณิตศาสตร์ของเครื่องข่ายนิวรอลซึ่งสามารถจัดให้อยู่ในรูปแบบที่ต่อเนื่องทางเวลาคือในรูปของสมการอนุพันธ์ และรูปแบบที่ไม่ต่อเนื่องทางเวลาคือในรูปของสมการผลต่าง

การหาค่าอ้อปติมัมแบบพื้นฐาน

ถ้าปัญหาการหาค่าอ้อปติมัมอยู่ในรูปของ

หา \mathbf{x} ซึ่งทำให้ $f(\mathbf{x})$ มีค่าต่ำสุด

โดยที่ $\mathbf{x} \in \mathbb{R}^n$ (๔.๑)

ถ้าสมการที่ (๔.๑) สามารถหา Gradient vector และ Hessian matrix ของ Cost function ได้แล้วถ้าให้ $\mathbf{x}^{(k)}$ เป็นจุดค้นหา (Search point) จะได้ว่า

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \eta^{(k)} \mathbf{d}_k, \quad k = 0, 1, 2, \dots$$

โดยที่ $\mathbf{x}^{(0)} = \mathbf{x}(0)$ และพารามิเตอร์ $\eta^{(k)} > 0$ โดยก้าวไปในทิศทางของเวคเตอร์ $\mathbf{d}_k \equiv \Delta \mathbf{x}^{(k)}$

การหาค่าอ้อปติมัมแบบพื้นฐานมีวิธีที่ใช้ในการหาค่าอ้อปติมัม 4 วิธีคือ

1. วิธี Steepest Descent (วิธี Gradient) ซึ่ง

$$\mathbf{d}_k = -\nabla f(\mathbf{x}^{(k)})$$

2. วิธี Newton ซึ่ง

$$\mathbf{d}_k = -[\nabla f(\mathbf{x}^{(k)})]^{-1} \nabla f(\mathbf{x}^{(k)})$$

3. วิธี Quasi-Newton ซึ่ง

$$\mathbf{d}_k = -[\nabla^2 f(\mathbf{x}^{(k)})]^{-1} \nabla f(\mathbf{x}^{(k)})$$

4. วิธี Conjugate Gradient ชี้ง

โดยที่

$$\mathbf{d}_k = -\nabla f(\mathbf{x}^{(k)}) + \beta_k \mathbf{d}_{k-1}, \quad k = 1, 2, \dots$$

$$\mathbf{d}_0 = -\nabla f(\mathbf{x}^{(0)})$$

และ

$$\beta_k = \left(\frac{\|\nabla f(\mathbf{x}^{(k)})\|}{\|\nabla f(\mathbf{x}^{(k-1)})\|} \right)^2$$

วิธีการหาค่าอปติมัมแบบพื้นฐานนี้มีข้อดีข้อเสียคือ วิธี Steepest Descent เป็นวิธีที่ง่ายมากและประยุกต์ในการที่จะ Implement จริง แต่มีข้อเสียคือสู่เข้าหาค่าอปติมัมช้ามาก ส่วนวิธี Newton มีการเพิ่มอัตราการสู่เข้าหาค่าอปติมัมแต่การนำไปใช้ในการ Implement จริงนั้น สิ้นเปลือง และต้องสามารถหาค่า Inverse Hessian matrix ซึ่งยากและบางปัญหาเป็น Singular matrix ส่วนวิธี Quasi-Newton ต้องการหน่วยความจำในการเก็บค่าต่างๆ ของ Hessian matrix ในแต่ละรอบ ส่วนวิธี Conjugate Gradient ต้องการหน่วยความจำในการเก็บข้อมูลน้อยกว่า วิธี Quasi-Newton แต่ต้องหาค่าพารามิเตอร์ $\gamma^{(k)}$, ค่านวนค่า $\beta_{(k)}$ และต้องหาค่า Gradient 2 ครั้ง หรือมากกว่านั้น แต่วิธีนี้ประหยัดเวลาและหน่วยความจำ

Basic Gradient System ของเครือข่ายนิวรอล

จากสมการที่ (๑.๑) สามารถจัดให้อยู่ในรูปแบบทางคณิตศาสตร์ของเครือข่ายนิวรอล โดยอยู่ในรูปของสมการอนุพันธ์ (Differential equation) คือ

$$\frac{dx_j}{dt} = -\lambda(t) \frac{\partial f}{\partial x_j} \quad (๑.๒)$$

ชี้ง

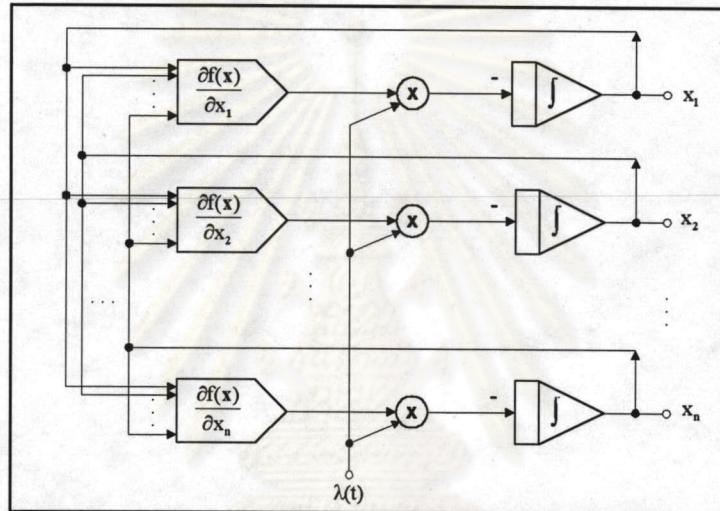
$$x_j(0) = x_j^{(0)}, \quad j = 1, 2, \dots, n$$

$$\lambda(t) > 0, \quad \lambda(t) \in C^1$$

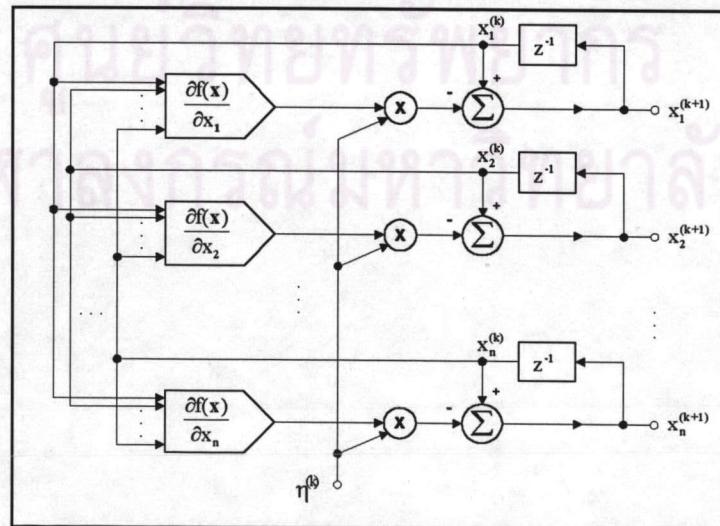
โดยที่ $\lambda(t)$ เป็นฟังก์ชันสเกลาร์บวก (Positive scalar function) ซึ่งเป็นค่าคงที่ และสมการที่ (๑.๒) เรียกว่า basic dynamic gradient system โดยที่รูปที่ ๑.๑ เป็นบล็อกไซด์แกรมของเครือข่ายนิวรอล สำหรับการหาค่าอปติมัมแบบต่อเนื่องทางเวลา (Continue-time) และรูปที่ ๑.๒ เป็นบล็อกไซด์แกรมของเครือข่ายนิวรอลสำหรับการหาค่าอปติมัมแบบไม่ต่อเนื่องทางเวลา (Discrete-time) ซึ่งการหาค่าอปติมัมแบบไม่ต่อเนื่องทางเวลาสามารถเขียนในรูปของสมการผลต่าง (Difference equations) คือ

$$\begin{aligned} x_j^{(k+1)} &= x_j^{(k)} - \eta^{(k)} \frac{\partial f(x^{(k)})}{\partial x_j} \\ \eta^{(k)} > 0 \quad , \quad k &= 0, 1, 2, \dots \end{aligned} \quad (\text{ข.3})$$

การใช้อัลกอริทึมการทำข้ามของสมการที่ (ข.3) อาจทำให้เกิดการซิกแซก (zigzag) ซึ่งสามารถแก้ไขได้โดยใช้ Continuous-time gradient system



รูปที่ ข.1 เครื่อข่ายนิวรอลแบบต่อเนื่องทางเวลา



รูปที่ ข.2 เครื่อข่ายนิวรอลแบบไม่ต่อเนื่องทางเวลา

ภาคผนวก ค.

การหาค่าอปติมัมแบบมีเงื่อนไขด้วยเครือข่ายนิวรอล

ความนำ

ในภาคผนวกนี้แบ่งเป็น 2 ส่วนคือ ส่วนแรกกล่าวถึงวิธีการหาค่าอปติมัมแบบมีเงื่อนไขด้วยเครือข่ายนิวรอล การหาค่าอปติมัมนี้ใช้วิธี Penalty function แปลงจากปัญหาการหาค่าอปติมัมแบบมีเงื่อนไขให้เป็นปัญหาการหาค่าอปติมัมแบบไม่มีเงื่อนไข จากนั้นแปลงปัญหาการหาค่าอปติมัมแบบไม่มีเงื่อนไขให้เป็นปัญหาของการแก้สมการอนุพันธ์ของตัวแปรสถานะซึ่งมี Forcing function เป็นพังก์ชันของ Steepest descent direction ผลตอบของสมการอนุพันธ์ เป็นผลตอบของปัญหาการหาค่าอปติมัมแบบไม่มีเงื่อนไข และผลตอบของสมการอนุพันธ์นี้หาได้จากการจำลองสมการอนุพันธ์ด้วยวงจรไฟฟ้า โดยที่สมการอนุพันธ์ดังกล่าวสามารถทำเป็น Parallel processing ได้ นั่นคือสามารถจัดให้อยู่ในรูปแบบทางคณิตศาสตร์ของเครือข่ายนิวรอล ระหว่างวงจรไฟฟ้านี้เปรียบเสมือนเครือข่ายนิวรอล โดยที่ Integrators คือตัวนิวรอล(Neurons) และ Functional nonlinear generators สร้างขึ้นมาเพื่อเชื่อมต่อระหว่างตัวนิวรอลเหล่านี้ และส่วนที่สองกล่าวถึงการพิสูจน์การถูกเข้าหาค่าอปติมัมของวิธี Steepest Descent

การหาค่าอปติมัมแบบมีเงื่อนไขด้วยเครือข่ายนิวรอล

วิธีนี้ในการแก้ปัญหาการหาค่าอปติมัมแบบมีเงื่อนไขคือวิธี Penalty function ซึ่งแปลงจากปัญหาการหาค่าอปติมัมแบบมีเงื่อนไขให้เป็นปัญหาการหาค่าอปติมัมแบบไม่มีเงื่อนไข

ถ้าปัญหาการหาค่าอปติมัมแบบมีเงื่อนไขอยู่ในรูปของ

หา x ซึ่งทำให้ $f(x)$ มีค่าต่ำสุด

โดยที่ $g_i(x) \leq 0 , i = 1, 2, \dots, m$

สามารถแปลงให้เป็นปัญหาการหาค่าอปติมัมแบบไม่มีเงื่อนไขคือ

หา x ซึ่งทำให้ $p(x)$ มีค่าต่ำสุด

(ค.1)

โดยที่ $\mathbf{x} \in \mathbb{R}^n$, $f: \mathbb{R}^n \rightarrow \mathbb{R}$, $\mu_i > 0$, $p(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^m \mu_i q_{ig}(g_i(\mathbf{x}))$ และ $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$,
 $i = 1, 2, \dots, m$

สังเกตได้ว่าฟังก์ชัน $p(\mathbf{x})$ ประกอบด้วย Objective function $f(\mathbf{x})$ และพจน์ของ $q_{ig}(g_i(\mathbf{x}))$ ซึ่งค่า $p(\mathbf{x})$ จะเพิ่มขึ้นเมื่อมีการละเมิดเงื่อนไขนั้นคือ $\{g_i(\mathbf{x}) > 0\}$, $i = 1, 2, \dots, m$ โดยถ้ายังมีการละเมิดเงื่อนไขมากเท่าไร ค่าพังก์ชัน $p(\mathbf{x})$ ยิ่งเพิ่มขึ้นเท่านั้น ซึ่งรูปแบบทั่วไปของ $q_{ig}(g_i(\mathbf{x}))$ มีดังต่อไปนี้คือ

$$q_{ig}(g_i(\mathbf{x})) = -\min\{0, -g_i(\mathbf{x})\}, i = 1, 2, \dots, m \quad (\text{ค.2})$$

หรือ

$$q_{ig}(g_i(\mathbf{x})) = \frac{1}{2} [\min\{0, -g_i(\mathbf{x})\}]^2, i = 1, 2, \dots, m \quad (\text{ค.3})$$

สังเกตได้ว่าถ้ามีการละเมิดเงื่อนไขจะทำให้ $\min\{0, -g_i(\mathbf{x})\} = -g_i(\mathbf{x}) < 0$, $i = 1, 2, \dots, m$ ดังนั้นสมการที่ (ค.2) เท่ากับ $q_{ig}(g_i(\mathbf{x})) = g_i(\mathbf{x}) > 0$, $i = 1, 2, \dots, m$ และสมการที่ (ค.3) เท่ากับ $q_{ig}(g_i(\mathbf{x})) = \frac{1}{2} [\min\{0, -g_i(\mathbf{x})\}] (-g_i(\mathbf{x})) = \frac{1}{2} (g_i(\mathbf{x}))^2 > 0$, $i = 1, 2, \dots, m$ และถ้าไม่มีการละเมิดเงื่อนไขจะทำให้ $\min\{0, -g_i(\mathbf{x})\} = 0$, $i = 1, 2, \dots, m$ ซึ่งทำให้สมการที่ (ค.2) และสมการที่ (ค.3) เท่ากับ $q_{ig}(g_i(\mathbf{x})) = 0$, $i = 1, 2, \dots, m$

เมื่อนำสมการที่ (ค.3) แทนลงในสมการที่ (ค.1) จะได้ว่า

$$p(\mathbf{x}) = f(\mathbf{x}) + \frac{1}{2} \sum_{i=1}^m \mu_i [\min\{0, -g_i(\mathbf{x})\}]^2 \quad (\text{ค.4})$$

โดยที่ $\mu_i > 0$ และถ้าอสมการเงื่อนไข $g_i(\mathbf{x})$ สามารถหาอนุพันธ์อย่างต่อเนื่องได้

$$\tilde{g}_i(\mathbf{x}) = \frac{1}{2} (\min\{0, -g_i(\mathbf{x})\})^2 := \frac{1}{2} (-g_i(\mathbf{x}))_-^2$$

$$\frac{\partial \tilde{g}_i(\mathbf{x})}{\partial \mathbf{x}_j} = -[-g_i(\mathbf{x})]_- \frac{\partial g_i(\mathbf{x})}{\partial \mathbf{x}_j} \quad \text{สำหรับทุกๆ ค่า } \mathbf{x} \in \mathbb{R}^n \quad (\text{ค.5})$$

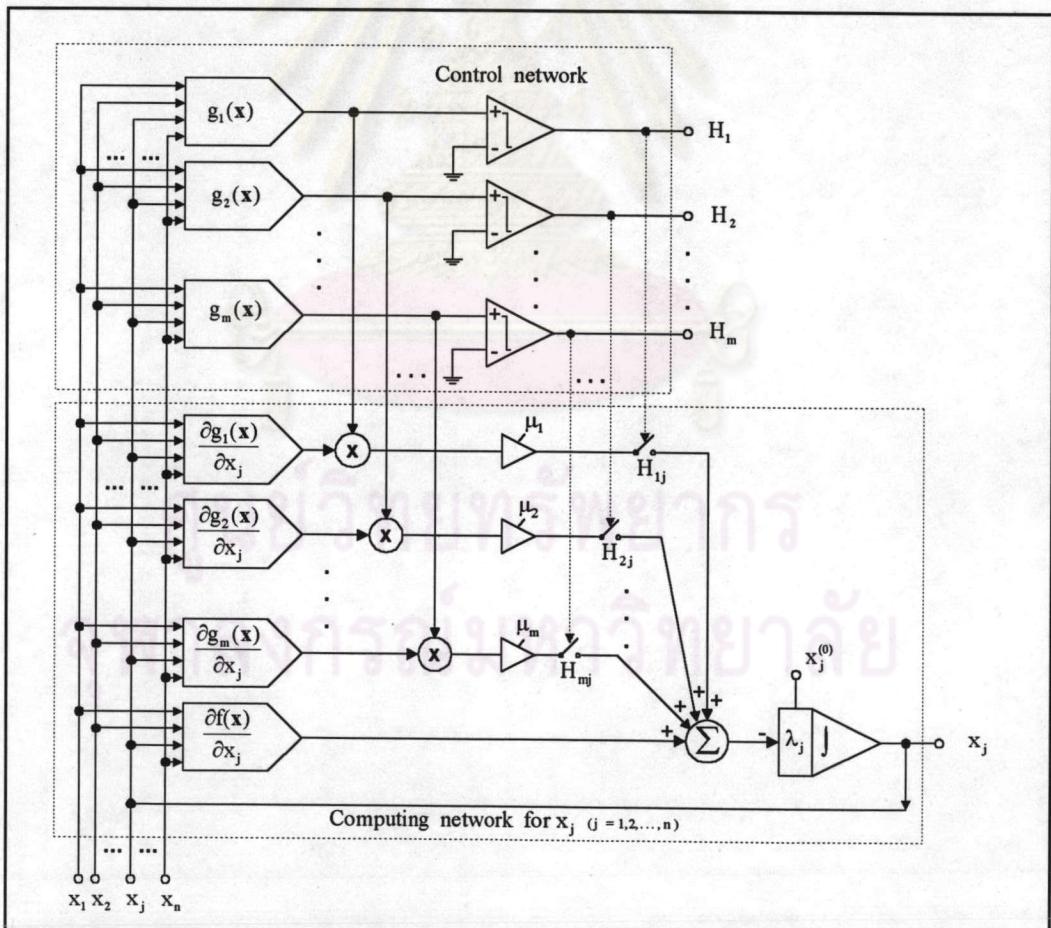
จากสมการที่ (ค.4) สามารถใช้ Gradient หาค่าออบติมัม ซึ่งสามารถจัดให้อยู่ในรูปของ สมการอนุพันธ์ โดยจากสมการอนุพันธ์ดังกล่าวและจากสมการที่ (ค.5) สามารถเขียนได้ดังนี้คือ

$$\frac{dx_j}{dt} = -\lambda_j \left[\frac{\partial f(\mathbf{x})}{\partial x_j} + \sum_{i=1}^m \mu_i H_i g_i(\mathbf{x}) \frac{\partial g_i(\mathbf{x})}{\partial x_j} \right], \quad j = 1, 2, \dots, n \quad (\text{ค.6})$$

ซึ่ง $\lambda_j > 0, \mu_j > 0$

และ $H_i = \begin{cases} 1 & \text{if } g_i(\mathbf{x}) > 0 \\ 0 & \text{if } g_i(\mathbf{x}) \leq 0 \end{cases}$ (ค.7)

จากสมการข้างบนสามารถนำมา Implement ในรูปที่ ค.1 โดยที่บล็อกไดอะแกรมนี้ได้มาจากสมการที่ (ค.6) และสมการที่ (ค.7) วงจรไฟฟ้านี้เปรียบเสมือนเครือข่ายนิวรอต์ โดยที่ Integrators คือตัวนิวรอต์ (Neurons) และ Functional nonlinear generators สร้างขึ้นมาเพื่อเชื่อมต่อระหว่างตัวนิวรอต์เหล่านี้



รูปที่ ค.1 บล็อกไดอะแกรมจากสมการที่ (ค.6) และสมการที่ (ค.7)

จากสมการที่ (ค.1) สามารถใช้ gradient หาค่าอุปติมัม โดยจัดให้อยู่ในรูปของสมการอนุพันธ์ จากนั้นนำสมการที่ (ค.2) แทนลงในสมการอนุพันธ์นั้น ซึ่งสามารถเขียนได้ดังนี้คือ

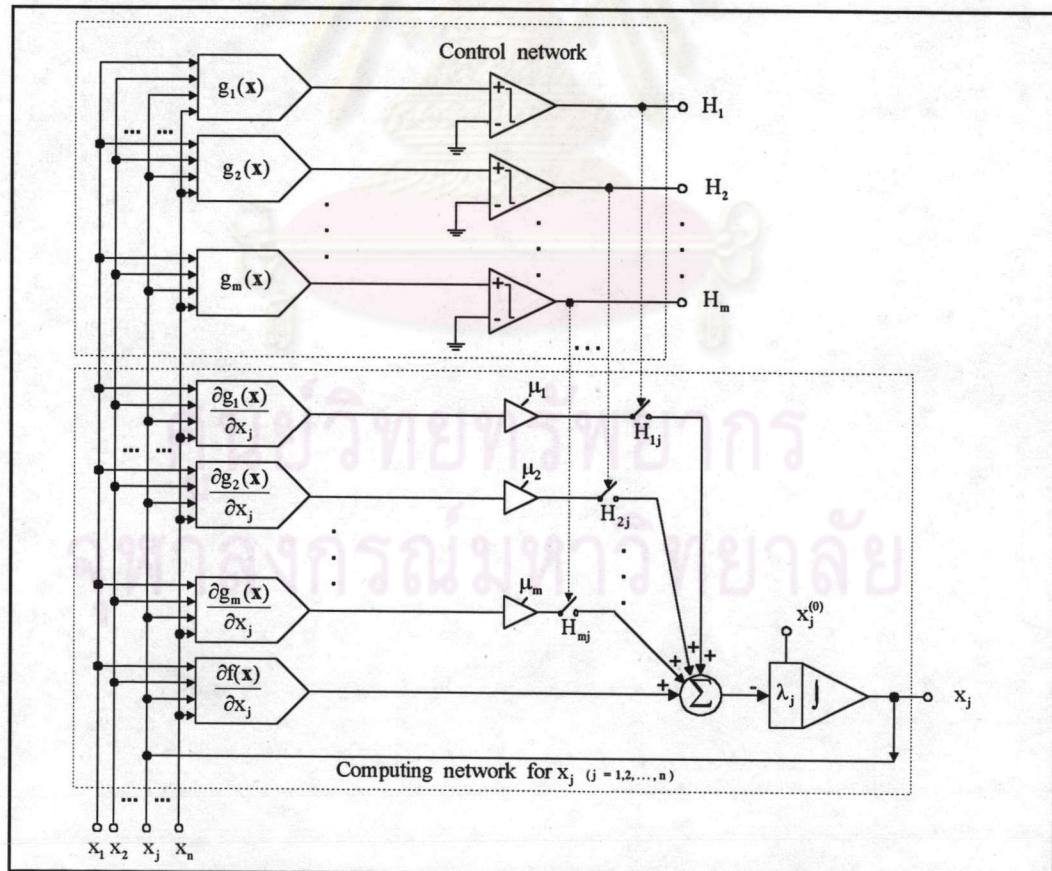
$$\frac{dx_j}{dt} = -\lambda_j \left[\frac{\partial f(\mathbf{x})}{\partial x_j} + \sum_{i=1}^m \mu_i H_i \frac{\partial g_i(\mathbf{x})}{\partial x_j} \right], \quad j = 1, 2, \dots, n \quad (\text{ค.8})$$

ดัง

$$\lambda_j > 0, \mu_j > 0 \quad \text{และ}$$

$$H_i = \begin{cases} 1 & \text{if } g_i(\mathbf{x}) > 0 \\ 0 & \text{if } g_i(\mathbf{x}) \leq 0 \end{cases} \quad (\text{ค.9})$$

จากสมการที่ (ค.8) และสมการที่ (ค.9) สามารถนำมาเขียนในรูปบล็อกได้如 รูปที่ ค.2



รูปที่ ค.2 บล็อกไดอะแกรมจากสมการที่ (ค.8) และสมการที่ (ค.9)

การพิสูจน์การลู่เข้าหาค่าอ้อปติมัมของวิธี Steepest Descent

การพิสูจน์การลู่เข้าหาค่าอ้อปติมัมของวิธี Steepest Descent สามารถพิสูจน์ได้ดังนี้คือ ถ้าให้ $s_p(\mathbf{x}(k))$ เป็น Steepest descent direction ที่ k และ $p(\mathbf{x}(k))$ เป็น Penalty Function จะได้ว่า

จากสมการที่ (2.17) และ (2.19) สามารถเขียนใหม่ได้เป็น

$$\begin{aligned} \tau \left\{ \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\} &= -\nabla p(\mathbf{x}(k)) \quad , k = 0, 1, 2, \dots \\ \nabla p(\mathbf{x}(k)) &= -\tau \left\{ \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\} \quad , k = 0, 1, 2, \dots \end{aligned} \quad (\text{ค.10})$$

โดยที่พารามิเตอร์ τ และ μ มีค่าคงที่เป็นจำนวนจริงบวก, $T = t_{k+1} - t_k$, $k=0,1,2,\dots$

ในการพิสูจน์การลู่เข้าหาค่าอ้อปติมัม เราสามารถพิสูจน์ได้โดยการพิจารณา $\frac{dp}{dt}$ ถ้า $\frac{dp}{dt}$ น้อยกว่าหรือเท่ากับศูนย์แสดงว่า p มีการเปลี่ยนแปลงในแนวทางที่ลดลงหรือไม่มีการเปลี่ยนแปลงตามลำดับ เหตุการณ์ดังกล่าวแสดงว่า p ลู่เข้าหาค่าที่นิ่งหรือค่า minimum นั้นเอง ซึ่งเขียนได้ดังนี้คือ

$$\begin{aligned} \frac{dp}{dt} &= \frac{\partial p}{\partial \mathbf{x}}^T \frac{d\mathbf{x}}{dt} \\ &= \nabla p(\mathbf{x})^T \dot{\mathbf{x}} \end{aligned} \quad (\text{ค.11})$$

จากสมการที่ (ค.11) สามารถจัดให้อยู่ในรูปแบบที่เมื่อต่อเนื่องทางเวลาได้ดังนี้คือ

$$\left\{ \frac{p(\mathbf{x}(k+1)) - p(\mathbf{x}(k))}{T} \right\} = \nabla p(\mathbf{x}(k))^T \left\{ \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\} , k = 0, 1, 2, \dots \quad (\text{ค.12})$$

และเมื่อแทน $\nabla p(\mathbf{x}(k))$ ในสมการที่ (ค.12) ด้วยสมการที่ (ค.10) จะได้ว่า

$$\begin{aligned} \left\{ \frac{p(\mathbf{x}(k+1)) - p(\mathbf{x}(k))}{T} \right\} &= \left[-\tau \left\{ \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\} \right]^T \left\{ \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\} \\ &= -\tau \left\| \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\|^2 \quad , \quad k = 0, 1, 2, \dots \quad (\text{ค.13}) \end{aligned}$$

ซึ่ง \because พารามิเตอร์ $\tau > 0$ และ $\left\| \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T} \right\|^2 \geq 0$, $k = 0, 1, 2, \dots$ ดังนั้นจากสมการที่ (ค.13)
จะได้ว่า

$$\left\{ \frac{p(\mathbf{x}(k+1)) - p(\mathbf{x}(k))}{T} \right\} \leq 0$$

จากสมการที่ (ค.13) สามารถพิสูจน์ได้ว่าการหาค่าอุปติมัมโดยใช้วิธี Steepest Descent นั้นสามารถหาค่า minimum ได้ เมื่อจากพจน์ทางด้านขวาอยู่กว่าหรือเท่ากับศูนย์เสมอ

ประวัติผู้เขียน

นางสาวยุพาพร จากรุศริพจน์ เกิดวันที่ 21 กันยายน พ.ศ 2513 ที่อำเภอเมือง จังหวัดนครปฐม จบการศึกษาวิชากรรมศาสตรบัณฑิต สาขาวิชากรรมไฟฟ้าระบบควบคุม ภาควิชา วิศวกรรมไฟฟ้า คณะวิชากรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง เมื่อปีการศึกษา พ.ศ 2535

พ.ศ 2536 ได้เข้าทำงานในตำแหน่งวิศวะระบบ ฝ่ายวางแผนระบบ แผนกวิชากรรม บมจ.โทเทล แอ็คเซส คอมมูนิเคชั่น

พ.ศ 2537 ได้เข้าศึกษาต่อระดับปริญญาโทบัณฑิต สาขาวิชาระบบควบคุม ภาควิชา วิศวกรรมไฟฟ้า จุฬาลงกรณ์มหาวิทยาลัย โดยได้รับอนุญาตให้พักงานมาเรียนจาก บมจ.โทเทล แอ็คเซส คอมมูนิเคชั่น

ปัจจุบันทำงานในตำแหน่งวิศวะระบบอาชุส ฝ่ายวางแผนระบบ แผนกวิชากรรม บมจ.โทเทล แอ็คเซส คอมมูนิเคชั่น



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย