

บทที่ 3

วิธีดำเนินการวิจัย

ในบทนี้จะกล่าวถึงการนำทฤษฎีที่ได้ศึกษามาแล้วนั้น มาประยุกต์ใช้กับการวิจัย และพัฒนาอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียม โดยได้แบ่งเนื้อหาในบทนี้เป็น 2 ส่วน คือ ส่วนที่ 1 เครื่องมือและอุปกรณ์ที่ใช้ในการดำเนินการวิจัย และส่วนที่ 2 ขั้นตอนการดำเนินการวิจัย

เครื่องมือและอุปกรณ์ที่ใช้ในการดำเนินการวิจัย

1. เครื่องคอมพิวเตอร์แล็ปท็อป 1 เครื่อง สำหรับเขียนและรัน (RUN) โปรแกรมเพื่อบันทึกผลการทดลอง มีรายละเอียดดังนี้

1.1 หน่วยประมวลผลกลาง Intel Pentium R ความเร็วสูงสุด 1.90 GHz

1.2 หน่วยความจำหลัก 1.99 GB.

1.3 ความจุฮาร์ดดิสก์ 2.93 GHz.

1.4 ใช้ซอฟต์แวร์ระบบปฏิบัติการไมโครซอฟท์ วินโดวส์เอ็กซ์พี โปรเฟสชันแนล (Windows XP Profession)

2. ภาษาที่ใช้ในการพัฒนาอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียม คือ MATLAB เวอร์ชัน 2008a พร้อม Neural Network

ขั้นตอนของการดำเนินการวิจัย

1. ศึกษารวบรวมข้อมูล

2. การประยุกต์ใช้วิธีการหาค่าเหมาะสมที่สุดโดยอาศัยการรบกวนแบบสุ่มเพื่อฝึกสอนโครงข่ายประสาทเทียม

1. ศึกษารวบรวมข้อมูล

ในการศึกษาเกี่ยวกับอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียมที่ผ่านมา พบว่าปัจจุบันได้มีอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียมมากมายที่ถูกคิดค้นขึ้น ซึ่งความซับซ้อนและขั้นตอนการทำงานของแต่ละอัลกอริทึมนั้นขึ้นอยู่กับความต้องการของผู้ใช้ ว่ามีความต้องการพัฒนาเพื่อนำอัลกอริทึมนั้นไปประยุกต์ใช้กับงานชนิดใด ซึ่งงานบางลักษณะต้องการความรวดเร็วและประสิทธิภาพในการประมวลผลสูง จากบทที่ 2 ได้ทำการทบทวนเอกสารที่ศึกษาเกี่ยวกับอัลกอริทึมที่ใช้ฝึกสอนโครงข่ายประสาทเทียมที่มีความสามารถในการประมวลผลได้รวดเร็วและมี

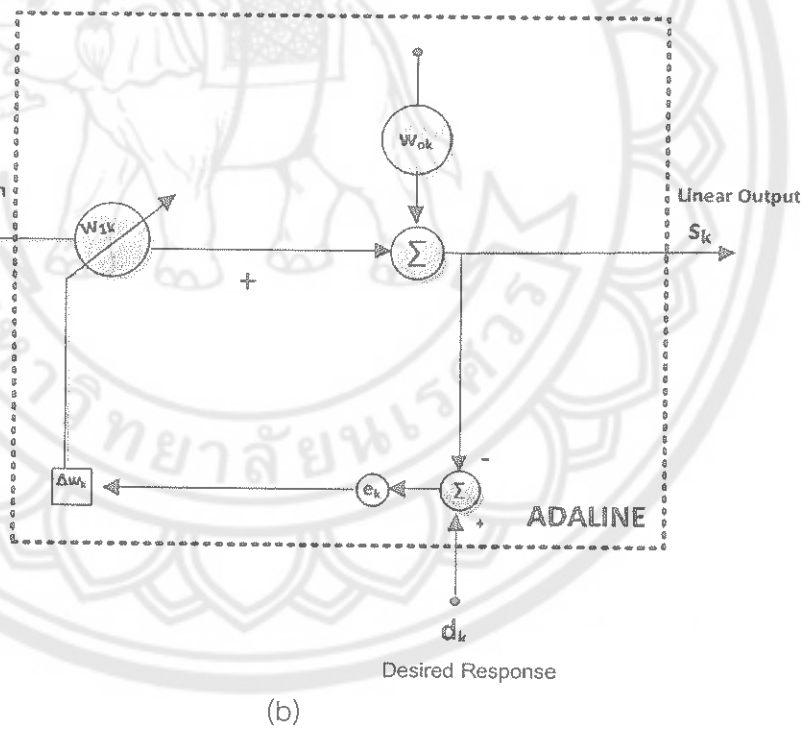
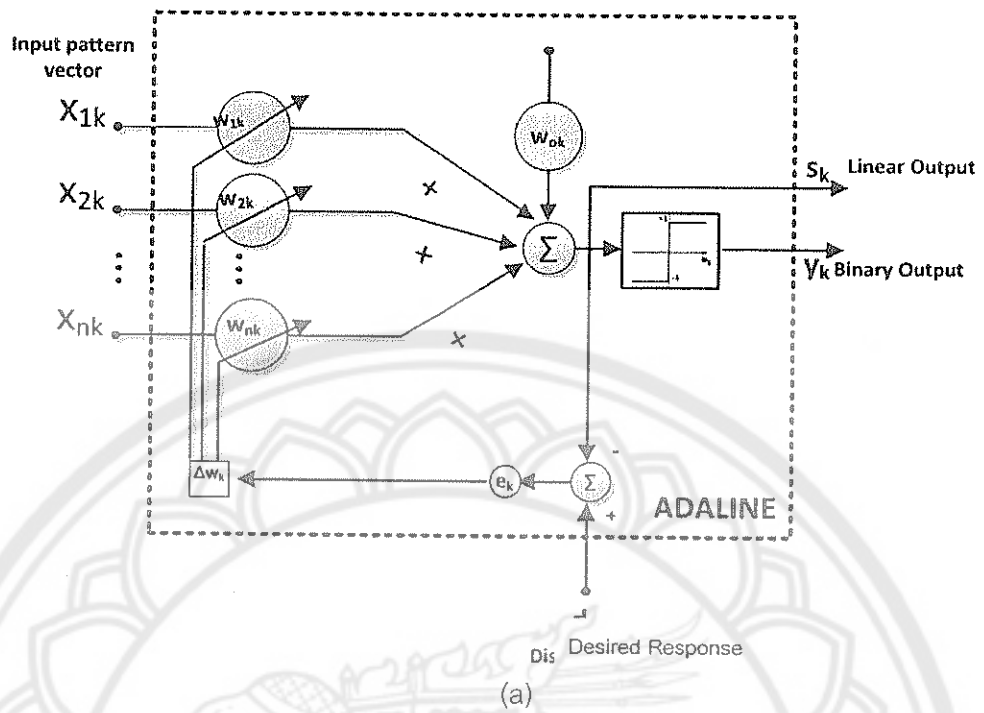
ประสิทธิภาพสูง เช่น Back propagation Algorithm และ Levenverg Marquardt Algorithm ซึ่งอัลกอริทึมเหล่านี้ สามารถประมวลผลได้รวดเร็วและมีประสิทธิภาพสูงเมื่อเปรียบเทียบกับการทำงานกับอัลกอริทึมอื่นๆ เมื่อทดลองนำอัลกอริทึม Back-propagation Algorithm และ Levenverg Marquardt Algorithm ไปทดสอบการทำงานบนดิจิทัลคอมพิวเตอร์ที่มีความสามารถสูง อัลกอริทึมเหล่านี้สามารถทำงานได้อย่างรวดเร็วและมีประสิทธิภาพสูง แต่จากงานวิจัยที่ผ่านมา พบว่า หากจำเป็นต้องทดสอบการทำงานของโครงข่ายประสาทเทียมด้วยอัลกอริทึมดังกล่าว โดยใช้คอมพิวเตอร์ขนาดเล็ก เช่น ไมโครคอนโทรลเลอร์แล้ว พบว่า ไม่สามารถจะบรรจุกระบวนการทำงานของอัลกอริทึมเหล่านี้ลงในคอมพิวเตอร์ขนาดเล็กได้ทั้งหมด เนื่องจากข้อจำกัดเรื่องหน่วยความจำที่มีอยู่ในอนาล็อกคอมพิวเตอร์ ซึ่งส่วนมากแล้ว มักมีจำนวนจำกัด จากการทบทวนเอกสารงานวิจัยเกี่ยวข้องที่ผ่านมา ทำให้ผู้วิจัยต้องการศึกษาและพัฒนาอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียม ที่มีขั้นตอนในการประมวลผลไม่ซับซ้อนและสามารถใช้ทดสอบการทำงานของโครงข่ายประสาทเทียมด้วยเครื่องมือคอมพิวเตอร์ขนาดเล็กได้

จากการทบทวนเอกสารงานวิจัยที่เกี่ยวข้อง พบว่า โครงข่ายประสาทเทียมจะมีข้อดีเหนือกว่า Genetic Algorithm และ Particle Swarm Optimization คือ การทำงานของโครงข่ายประสาทเทียมนั้นไม่มีการสุ่มสร้างประชากร (Population) ทำให้การทำงานของโครงข่ายประสาทเทียมใช้หน่วยความจำน้อยกว่าการทำงานของ Genetic Algorithm และ Particle Swarm Optimization ดังนั้น จากข้อดีดังกล่าว ผู้วิจัยจึงได้เลือกศึกษาการทำงานของโครงข่ายประสาทเทียมเพื่อนำไปประยุกต์ใช้กับงานชนิดอื่นๆ ที่มีข้อจำกัดในเรื่องของหน่วยความจำต่อไป

2. ออกแบบการทดลอง

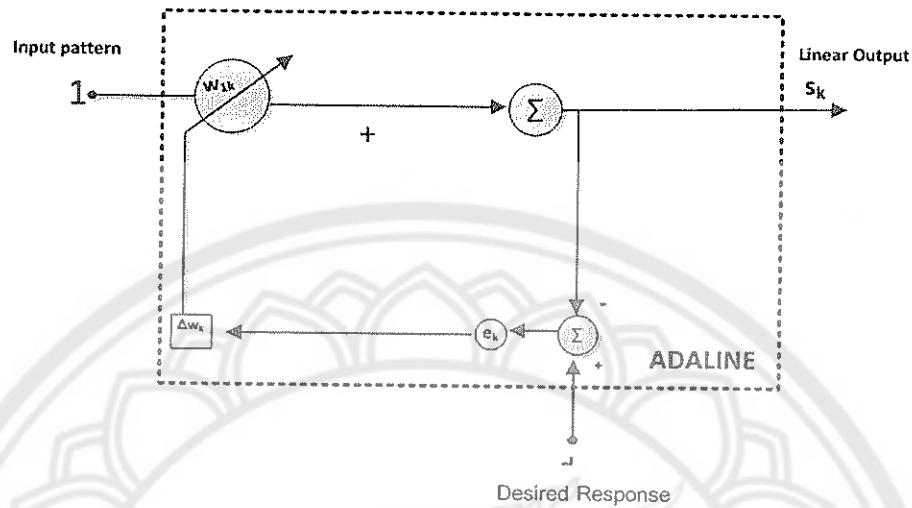
ในขั้นตอนเริ่มต้นการทดลองได้ทดลองสร้างระบบปรับตัวเองอย่างง่าย โดยกำหนดให้ใช้ Adaptive Linear Combiner เพียงตัวเดียว เพื่อปรับค่าน้ำหนักของโครงข่าย โดยการทดลองปรับค่าน้ำหนักของโครงข่ายด้วยอัลกอริทึมที่ใช้หลักการการรบกวนค่าน้ำหนักแบบสุ่ม เพื่อปรับน้ำหนักโครงข่าย

ภาพ 7 แสดงโครงสร้างของ Adaline เปรียบเทียบกับระบบปรับตัวเองอย่างง่ายที่มีค่าน้ำหนักเพียงตัวเดียว



ภาพ 7 (a) โครงสร้าง Adaline (b) ระบบปรับตัวเองอย่างง่ายที่มีค่าน้ำหนักเพียงตัวเดียว

เพื่อความง่ายในการคำนวณ กำหนดให้ อินพุตโครงข่ายมีค่าเท่ากับ 1 แสดงดังภาพ 8



ภาพ 8 ระบบปรับตัวเองอย่างง่ายที่มีค่าน้ำหนักเพียงตัวเดียว และมีค่าอินพุตเข้าโครงข่ายเป็น 1

โดยทั่วไปแล้ว การทำงานของโครงข่ายประสาทเทียมด้วยดิจิตอลคอมพิวเตอร์ จะเริ่มต้นจากการมีอินพุตฝึกสอนและเอาต์พุตฝึกสอนโครงข่ายเข้าสู่โครงข่าย จากนั้นนำอินพุตฝึกสอนโครงข่ายคูณด้วยค่าน้ำหนักโครงข่าย (Weight) แต่ละสาขาของอินพุตฝึกสอนนั้นๆ ได้ผลลัพธ์เป็นเอาต์พุตเชิงเส้น (Linear Output) และถูกนำไปเปรียบเทียบกับค่าระดับหรือเทรชโฮลด์ที่กำหนดไว้ หากเอาต์พุตเชิงเส้นที่ได้นั้นมีค่ามากกว่าค่าระดับก็จะส่งเอาต์พุตออกไปยังหน่วยประมวลผลตัวต่อไปซึ่งมีการเชื่อมต่อกันเป็นโครงข่าย โดยทั่วไปแล้ว อัลกอริทึมปรับค่าน้ำหนักของโครงข่าย จะต้องสามารถปรับค่าน้ำหนักของโครงข่ายเพื่อให้เอาต์พุตโครงข่ายนั้น มีค่าใกล้เคียงกับเอาต์พุตฝึกสอนมากที่สุด

เมื่อกำหนดให้ค่าอินพุตที่เข้าสู่โครงข่ายมีค่าเท่ากับ 1 แล้ว สามารถคำนวณค่าเอาต์พุตโครงข่าย (s_k) ได้ดังสมการ (66)

$$s_k = (1 \cdot w_{1k}) \quad (66)$$

จะได้เป็นเอาต์พุตเชิงเส้น (s_k) ดังสมการ (67)

$$s_k = w_{1k} \quad (67)$$

จากสมการ (67) จะเห็นได้ว่า เมื่อกำหนดให้อินพุตฝึกสอนโครงข่ายมีค่าเท่ากับ 1 ค่าเอาต์พุตเชิงเส้น (s_k) จะมีค่าเท่ากับค่าน้ำหนักโครงข่าย (w_{1k})

โดยทั่วไปแล้ว ในการฝึกสอนโครงข่ายประสาทเทียม เราจะวัดประสิทธิภาพของการฝึกสอนโครงข่ายจากค่าความผิดพลาดกำลังสอง (Squared Error) ที่ได้จากการฝึกสอนโครงข่ายในแต่ละรอบ ซึ่งคำนวณได้ตามสมการ (68)

$$e^2 = (d_k - s_k)^2 \quad (68)$$

เมื่อ

e^2 คือ ค่าความผิดพลาดกำลังสอง

d_k คือ ค่าเอาต์พุตฝึกสอนโครงข่าย

s_k คือ ค่าเอาต์พุตเชิงเส้น (Linear Output)

ซึ่งการฝึกสอนโครงข่ายประสาทเทียมส่วนใหญ่แล้ว มีจุดประสงค์หลัก คือ การทำให้ค่าความผิดพลาดกำลังสองมีค่าน้อยที่สุด (Minimization) หรือทำให้ค่าความผิดพลาดกำลังสองมีค่าเท่ากับ 0

ดังนั้น สมการ (68) จะกลายเป็น

$$0 = (d_k - s_k)^2 \quad (69)$$

จากการแก้สมการ (69) เราทราบว่า เอาต์พุตเชิงเส้น หรือ s_k มีค่าตามสมการ (67)

$$s_k = w_{1k} \quad (70)$$

ดังนั้น แทนค่า $s_k = w_{1k}$ ในสมการ (70) ลงในสมการ (69) จะได้เป็นดังสมการ (71)

$$0 = (d_k - w_{1k})^2 \quad (71)$$

ทำการแก้สมการ (71) จะได้เป็น

$$w_{1k} = d_k \quad (72)$$

ในกรณีที่เป็นกรฝึกสอนโครงข่ายแบบมีผู้ฝึกสอน (Supervisor Training) เราจะต้องทราบค่าเอาต์พุตฝึกสอน (d_k) ก่อนที่จะทำการฝึกสอนโครงข่าย ดังนั้น ค่า d_k จะมีค่าเป็นค่าคงที่ค่าหนึ่ง ตามที่ผู้ฝึกสอนโครงข่ายกำหนดขึ้น ซึ่งจะมีตัวอย่างแสดงการคำนวณอย่างละเอียดในส่วนของตัวอย่างการคำนวณต่อไป

จะเห็นว่าในกรณีที่ค่าอินพุตฝึกสอนที่เข้าสู่โครงข่ายมีค่าเท่ากับ 1 แล้ว ค่าน้ำหนักโครงข่าย (w_{1k}) ที่ทำให้ค่าความผิดพลาดกำลังสองมีค่าเท่ากับ 0 คือ ค่าน้ำหนักนั้นต้องมีค่าเท่ากับค่าอินพุตฝึกสอนโครงข่าย (d_k) ดังแสดงไว้ในสมการ (72)

3. ตัวอย่างการคำนวณด้วยมือ

ในการฝึกสอนโครงข่ายประสาทเทียมดังอัลกอริทึมต่างๆ นั้น โดยทั่วไปแต่ละอัลกอริทึมจะมีขั้นตอนในการปรับค่าน้ำหนักแตกต่างกันไป ซึ่งอัลกอริทึมที่ใช้ปรับค่าน้ำหนักส่วนมากนั้น มักจะมีการดัดแปลงมาจากเทคนิคการหาค่าเหมาะสมที่สุด (Optimization Technique)


ในส่วนนี้ ได้ศึกษาการปรับค่าน้ำหนักเหมาะสมที่สุด โดยอาศัยหลักการ การรบกวนแบบสุ่ม (Random Perturbation) ตามเอกสารที่ได้ทบทวนมาแล้ว ดังนี้

1. Bernard Widrow and Samuel D.Stearns (1985)
2. Akaraphunt Vongkunghae (2005)

การทดลองในส่วนนี้ ได้ยึดหลักการการปรับค่าน้ำหนักตามงานวิจัยทั้งสองรายการที่กล่าวมา เพื่อเปรียบเทียบสมรรถนะและประสิทธิภาพในการปรับค่าน้ำหนักจากทั้งสองวิธี และเป็นเหตุผลประกอบในการวิเคราะห์ผลวิจัยต่อไป ในส่วนต่อไป เป็นตัวอย่างการคำนวณอย่างละเอียด ในการฝึกสอนโครงข่ายประสาทเทียม โดยอาศัยการปรับค่าน้ำหนักจาก Bernard Widrow and Samuel D.Stearns (1985) และ Akaraphunt Vongkunghae (2005)

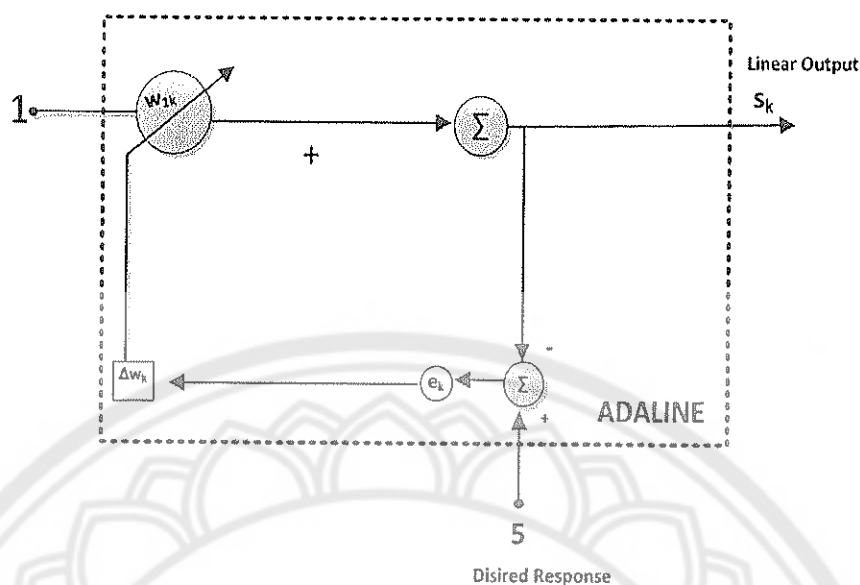
ตัวอย่างการคำนวณ

ในการหาค่าเหมาะสมที่สุดของโครงข่าย ระบบต้องการหาค่าที่น้อยที่สุด (Minimization) กราฟเส้นดังกล่าว กำหนดให้ จุดที่ต่ำสุด คือ 5 ดังแสดงในภาพ 9 ซึ่งภาพนี้ได้จากความสัมพันธ์ $e^2 = (d_k - w_{1k} \cdot 1)^2$ เมื่อ $d_k = 5$



ภาพ 9 ค่าความผิดพลาดกำลังสองเทียบกับค่าน้ำหนักของโครงข่าย ขั้นตอนการคำนวณ

จากภาพ 9 จะเห็นว่า ค่าของ w_{1k} ทำให้มีค่าที่ทำให้ค่าความผิดพลาดกำลังสองมีค่าน้อยสุดหรือมีค่าเท่ากับศูนย์ คือ 5 เนื่องจากการฝึกสอนโครงข่ายที่ทำการทดลองนี้ เป็นการฝึกสอนโครงข่ายแบบมีผู้ฝึกสอน (Supervisor Training) ดังนั้น เราจึงทราบได้ว่า ค่าเอาต์พุตฝึกสอนโครงข่ายหรือ d_k ของปัญหานี้ คือ 5 และกำหนดให้ระบบมีอินพุตฝึกสอนโครงข่ายเริ่มต้นมีค่าเท่ากับ 1 แสดงดังภาพ 10



ภาพ 10 โครงข่ายที่มีค่าอินพุตโครงข่ายมีค่าเท่ากับ 1 ค่าเอาต์พุตฝึกสอนโครงข่าย $d_k = 5$

เมื่อกำหนดให้ค่าอินพุตโครงข่ายเริ่มต้น มีค่าเท่ากับ 1 แล้ว สามารถคำนวณค่าเอาต์พุตเชิงเส้น (s_k) ของโครงข่ายได้เป็น ดังสมการ (73)

$$s_k = (1 \cdot w_{1k}) \quad (73)$$

จะได้เป็นดังสมการ (74)

$$s_k = w_{1k} \quad (74)$$

กำหนดให้ความผิดพลาดกำลังสองมีค่าน้อยที่สุด (Minimization) มีค่าเท่ากับ 0 สมการ (68) จะกลายเป็นดังสมการ (75)

$$0 = (d_k - s_k)^2 \quad (75)$$

จากการแก้สมการ (75) เราทราบว่าเอาต์พุตเชิงเส้นของโครงข่าย (s_k) คำนวณได้ดังสมการ (70)

$$s_k = w_{1k} \quad (76)$$

ดังนั้น แทนค่า $s_k = w_{1k}$ ตามสมการ (76) ลงในสมการ (75) จะได้เป็น

$$0 = (d_k - w_{1k})^2 \quad (77)$$

ในกรณีเฝ้าทราบว่ารระบบของเรานั้น มีเอาท์พุทฝึกสอนโครงข่าย หรือ $d_k = 5$ แทนค่า ลงในสมการ (77) จะได้ดังสมการ (78)

$$0 = (5 + w_{1k})^2 \quad (78)$$

กระจายสมการกำลังสอง ของสมการ (78) จะได้ดังสมการ (79)

$$w_{1k}^2 + 2(5)(w_{1k}) + 25 = 0 \quad (79)$$

จะได้เป็น

$$w_{1k}^2 + 10w_{1k} + 25 = 0 \quad (80)$$

กระจายผลต่างกำลังสองของสมการ (80) ได้เป็นดังสมการ (81)

$$(w_{1k} + 5)(w_{1k} + 5) = 0 \quad (81)$$

ดังนั้น จากสมการ (81) จะได้ค่า (w_{1k}) เป็นดังสมการ (82)

$$w_{1k} = -5 \quad (82)$$

4. ตัวอย่างการคำนวณด้วยโปรแกรม MATLAB

จากหัวข้อที่ผ่านมาเป็นการคำนวณด้วยมือ ในส่วนนี้ได้ทำการทดลองปรับค่าน้ำหนัก ในโครงข่ายด้วยโปรแกรม MATLAB

โดยในการทดลองได้ปรับค่าน้ำหนักโดยใช้หลักการจากทั้งสองวิธีนี้ ได้แก่

1. Bernard Widrow and Samuel D. Stearns (1985) เรียกวิธีนี้ดังกล่าวว่า Linear Random Search Algorithm (LRS) จะปรับค่าน้ำหนักโดยรายละเอียดดังนี้

$$w_{k+1} = w_k + \frac{\mu}{\sigma^2} [\varepsilon(w_k) - \varepsilon(w_k + U_k)] U_k$$

2. Akaraphunt Vongkunghae (2005) เรียกวิธีนี้ดังกล่าวว่า Random Perturbation จะปรับค่าน้ำหนักโดยรายละเอียดดังนี้

$$\Delta e = e(W_n + v\Delta P) - e(W_n - v\Delta P)$$

$$W_{n+1} = W_n - \mu \cdot \Delta e \cdot v\Delta P$$

ขั้นตอนการปรับค่าน้ำหนักโดยโปรแกรม MATLAB นั้น ได้กำหนดค่าตัวแปรเริ่มต้นที่สำคัญของทั้งสองวิธีให้มีค่าเท่ากัน ดังต่อไปนี้

จำนวนรอบ (Epoch) ที่ใช้ฝึกโครงข่ายเท่ากับ 10,000 รอบ

v คือ ค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) ของการกระจายตัวแปรสุ่ม

$$v = 0.001 \tag{83}$$

ΔP คือ การกระจายตัวแปรสุ่มเกาส์เซียน (Gaussian Distribution)

$$\Delta P = \text{randn}[-\infty, \infty] \tag{84}$$

$v \cdot \Delta P$ คือ การกระจายตัวแปรสุ่มแบบเกาส์เซียน (Gaussian Distribution) ที่มีค่าเบี่ยงเบนมาตรฐานเท่ากับ v

$$v \cdot \Delta P = v \cdot \text{randn}[-\infty, \infty] \tag{85}$$

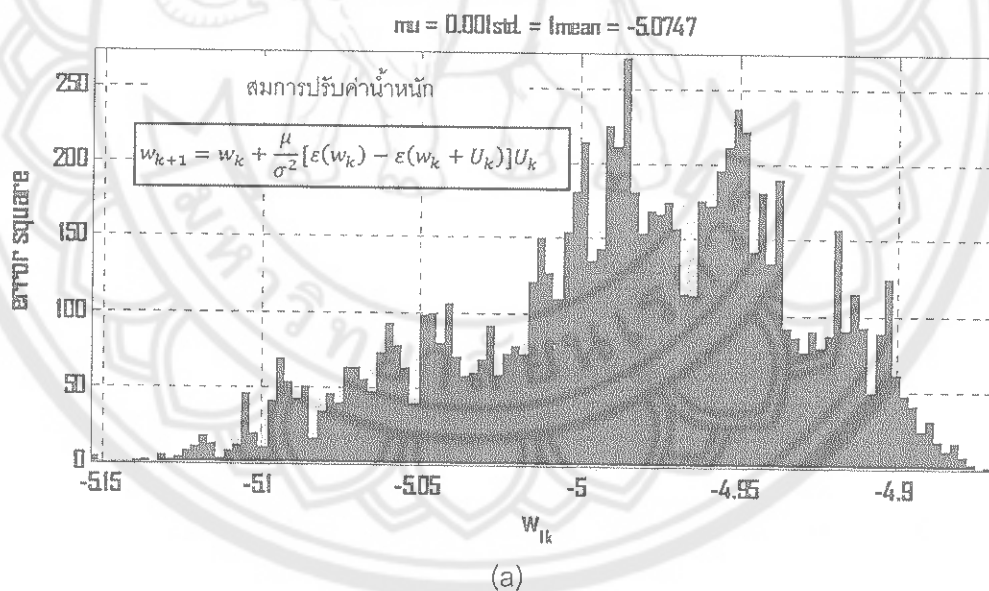
μ คือ ค่าอัตราการเรียนรู้ (Learning rate)

$$\mu = 0.001 \tag{86}$$

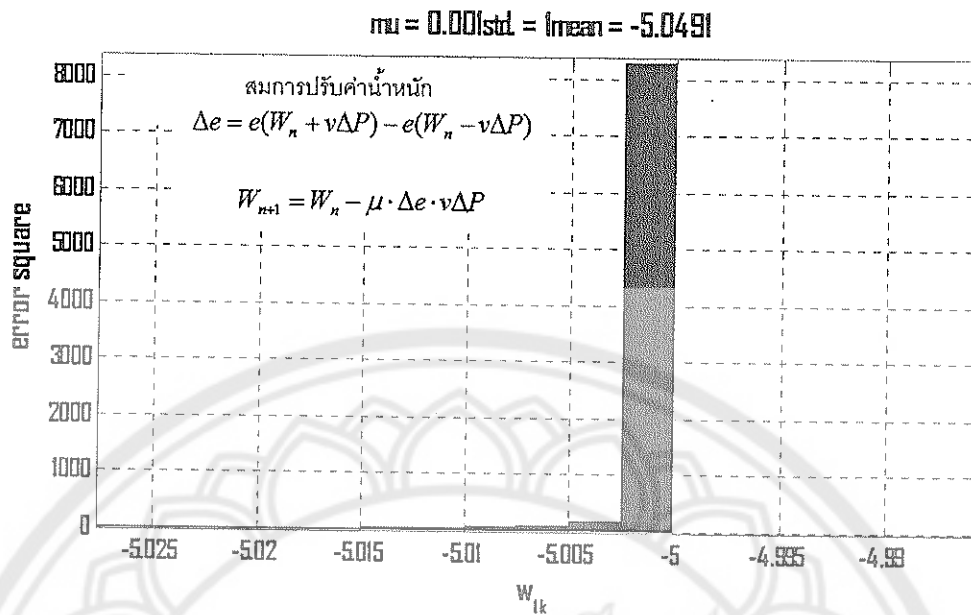
จากสมการ (82) เราทราบว่า ค่าน้ำหนักที่ถูกต้อง คือ $w_{1k} = -5$ หลักจากใช้อัลกอริทึมปรับค่าน้ำหนักของโครงข่ายตาม Bernard Widrow and Samuel D.Stearns (1985) และ Akaraphunt Vongkunghae (2005) แล้ว ค่าน้ำหนักที่ได้จากการใช้อัลกอริทึมทั้งสองปรับค่าน้ำหนักของโครงข่าย ได้ทำการพล็อตกราฟเพื่อแสดงความหนาแน่นความน่าจะเป็น (Probability Density Function : PDF) ของค่าน้ำหนัก w_{1k} ซึ่งได้แสดงในภาพ 10 (a) และ (b) จากทั้งสองวิธีตามลำดับ

5. วิเคราะห์และเปรียบเทียบผลการทดลอง

จากภาพ 11 จะเห็นได้ว่าการกระจายตัวของค่าน้ำหนักจากทั้งสองวิธีนั้นมีความแตกต่างกัน ดังนั้น เพื่อเปรียบเทียบประสิทธิภาพของของค่าน้ำหนักที่ได้จากกระบวนการปรับค่าน้ำหนักของทั้งสองวิธี โดยได้พิจารณาค่าน้ำหนักที่มีค่าอยู่ระหว่าง -5 ± 0.001 ของการหาราค่าน้ำหนักทั้งหมด 10,000 ค่า ทั้งจากวิธีของ Bernard Widrow and Samuel D.Stearns (1985) และ Akaraphunt Vongkunghae (2005) จากนั้นค่าน้ำหนักที่ได้มาคำนวณค่าความน่าจะเป็น พบว่า



ภาพ 11 ฟังก์ชันความหนาแน่นความน่าจะเป็นของค่าน้ำหนัก w_{1k} โดย
 (a) ปรับค่าน้ำหนักโดยใช้อัลกอริทึม Bernard Widrow and Samuel D.Stearns (1985) (b) ปรับค่าน้ำหนักโดยใช้อัลกอริทึม Akaraphunt Vongkunghae (2005)



ภาพ 11 (ต่อ)

ค่าน้ำหนักที่มีค่าอยู่ระหว่าง -5 ± 0.001 โดยวิธีของ Bernard Widrow and Samuel D.Stearns (1985) มีค่าคำนวณได้ดังสมการ (87) ตามลำดับ

$$\frac{3906}{10000} \times 100 = 39.06 \% \quad (87)$$

ค่าน้ำหนักที่มีค่าอยู่ระหว่าง -5 ± 0.001 โดยวิธีของ Akaraphunt Vongkunghae (2005) มีค่าคำนวณได้ดังสมการ และ (88) ตามลำดับ

$$\frac{8193}{10000} \times 100 = 81.93 \% \quad (88)$$

จากการคำนวณค่าความน่าจะเป็นของค่าน้ำหนักที่มีค่าอยู่ระหว่าง -5 ± 0.001 จากทั้งสองอัลกอริทึมแล้วนั้น พบว่า อัลกอริทึมที่นำเสนอใน Akaraphunt Vongkunghae (2005) มีค่าความน่าจะเป็นของน้ำหนักที่ถูกต้อง สูงกว่า อัลกอริทึมของ Bernard Widrow and Samuel D.Stearns (1985)

ดังนั้น ในวิทยานิพนธ์เรื่องนี้ผู้วิจัยจึงได้นำอัลกอริทึมนี้ ใช้เป็นวิธีการหลักในการฝึกสอนโครงข่ายประสาทเทียมแบบป้อนผลการคำนวณไปข้างหน้า (Feedforward Neural Network) เพื่อเปรียบเทียบกับอัลกอริทึมอื่นๆ

6. การประยุกต์ใช้วิธีการหาค่าเหมาะสม (Optimization) โดยอาศัยการรบกวนแบบสุ่ม (Random Perturbation)

ในส่วนนี้เป็นการนำหลักการ การปรับค่าน้ำหนักแบบสุ่ม จาก Akaraphunt Vongkumhae (2005) มาฝึกสอนโครงข่ายประสาทเทียมแบบป้อนผลการคำนวณไปข้างหน้ามีขั้นตอนสรุป ได้ดังนี้

ขั้นที่ 1 ทำการคำนวณค่าความผิดพลาดกำลังสอง (error square) ของโครงข่ายดังสมการ (89) เพื่อเก็บไว้ใช้ตรวจสอบการลู่เข้าสู่ค่าตอบและใช้ในเงื่อนไขที่จะหยุดฝึกสอนเมื่อค่าความผิดพลาดกำลังสองเฉลี่ยเป็นที่ยอมรับได้

$$\varepsilon(\mathbf{w}_k) = \sum_{p=1}^N (t_p - y_{p \mathbf{w}_k})^2 \quad (89)$$

ขั้นที่ 2 ทำการสุ่มค่าเวกเตอร์ ΔP

ขั้นที่ 3 ทำการรบกวนค่าน้ำหนักของโครงข่ายด้วย $v \cdot \Delta P$ ทั้งด้านบวกและด้านลบ ดังแสดง ในสมการ (90) และ (91)

$$\mathbf{w}_+ = \mathbf{w}_k + v \cdot \Delta P = [w_{+1} \quad w_{+2} \quad \dots \quad w_{+i}]^T \quad (90)$$

$$\mathbf{w}_- = \mathbf{w}_k - v \cdot \Delta P = [w_{-1} \quad w_{-2} \quad \dots \quad w_{-i}]^T \quad (91)$$

ขั้นที่ 4 ทำการคำนวณค่าความผิดพลาดกำลังสอง ของโครงข่ายที่ถูกรบกวนค่าน้ำหนักด้วย $v \cdot \Delta P$ ทั้งด้านบวกและด้านลบดังแสดง ในสมการ (92) และ (93)

$$\varepsilon(\mathbf{w}_+) = \sum_{p=1}^N (t_p - y_{p \mathbf{w}_+})^2 \quad (92)$$

$$\varepsilon(\mathbf{w}_-) = \sum_{p=1}^N (t_p - y_{p \mathbf{w}_-})^2 \quad (93)$$

ขั้นที่ 5 ทำการคำนวณค่าผลต่างของค่าความผิดพลาดกำลังสอง $\Delta\varepsilon$, คำนวณได้ดังสมการที่ (94)

$$\Delta\varepsilon = \varepsilon(w_+) - \varepsilon(w_-) \quad (94)$$

ขั้นที่ 6 ทำการปรับค่าน้ำหนักโครงข่าย โดยใช้หลักการการค่าสัมพันธระหว่างผลต่างค่าความผิดพลาดกำลังสอง ($\Delta\varepsilon$) กับค่าการรบกวน ($v \cdot \Delta P$) ดังสมการที่ (95)

$$w_{k+1} = w_k - \mu \cdot \Delta\varepsilon \cdot v \Delta P \quad (95)$$

ขั้นที่ 7 ย้อนกลับไปทำขั้นที่ 1

โดยที่สัญลักษณ์ในสมการมีความหมายดังที่แสดงไว้ดังต่อไปนี้

$\varepsilon(w_k)$ คือ ผลรวมความผิดพลาดกำลังสอง เมื่อค่าน้ำหนัก คือ w_k

$\varepsilon(w_+)$ คือ ผลรวมความผิดพลาดกำลังสอง เมื่อค่าน้ำหนัก คือ w_+

$\varepsilon(w_-)$ คือ ผลรวมความผิดพลาดกำลังสอง เมื่อค่าน้ำหนัก คือ w_-

i คือ จำนวนสมาชิกในเวกเตอร์ค่าน้ำหนัก

K คือ ครั้งที่ปรับค่าน้ำหนัก 1,2,3,....

w_k คือ เวกเตอร์ค่าน้ำหนักก่อนปรับค่า $w_k = [w_{k1} \ w_{k2} \ \dots \ w_{ki}]^T$

w_{k+1} คือ เวกเตอร์ค่าน้ำหนักหลังถูกปรับค่า

w_+ คือ เวกเตอร์ค่าน้ำหนักที่ถูกปรับทางด้านบวก

$$w_+ = w_k + v \cdot \Delta P = [w_{+1} \ w_{+2} \ \dots \ w_{+i}]^T$$

w_- คือ เวกเตอร์ค่าน้ำหนักที่ถูกปรับทางด้านลบ

$$w_- = w_k - v \cdot \Delta P = [w_{-1} \ w_{-2} \ \dots \ w_{-i}]^T$$

t_p คือ ค่าเอาต์พุตที่ต้องการ ของข้อมูลอินพุตฝึกสอน ลำดับที่ p
ค่าน้ำหนัก คือ w_{+k} ฝึกสอนโครงข่าย

$y_{p w_+}$ คือ ค่าเอาต์พุตโครงข่ายของข้อมูลอินพุตฝึกสอน ลำดับที่ p เมื่อ
ค่าน้ำหนัก คือ w_+

- $y_{p w_-}$ คือ ค่าเอาต์พุตโครงข่ายของข้อมูลอินพุตฝึกสอน ลำดับที่ p เมื่อ
ค่าน้ำหนัก คือ w_-
- $y_{p w_k}$ คือ ค่าเอาต์พุตโครงข่ายของข้อมูลอินพุตฝึกสอน ลำดับที่ p เมื่อ
ค่าน้ำหนัก คือ w_k
- N คือ จำนวนอินพุตฝึกสอนทั้งหมด
- v คือ ค่าคงที่ควบคุมลักษณะการกระจายตัวแปรสุ่ม
- ΔP คือ เวกเตอร์การรบกวน มีลักษณะการกระจายตัวแปรสุ่มแบบเกาส์เซียน
ปรกติ (Normal Gaussian Distribution) มีค่าเบี่ยงเบนมาตรฐาน
เท่ากับ 1.0
- $v \cdot \Delta P$ คือ เวกเตอร์ค่าการรบกวน มีลักษณะการกระจายตัวแปรสุ่มเกาส์เซียน
(Gaussian Distribution) มีค่าเบี่ยงเบนมาตรฐาน เท่ากับ v
- $\Delta \varepsilon$ คือ ผลต่างระหว่างค่าความผิดพลาดกำลังสองของค่าน้ำหนักที่ถูกรบกวน
ด้านบน ($w + v \cdot \Delta P$) และค่าความผิดพลาดกำลังสองของค่าน้ำหนัก
ที่ถูกรบกวนด้านล่าง ($w - v \cdot \Delta P$)
- μ คือ ค่าอัตราการเรียนรู้

จากสมการ (95) เป็นสมการปรับค่าน้ำหนัก โดยใช้สหสัมพันธ์ไขว้น้อยสุดระหว่าง
ผลต่างค่าความผิดพลาดกำลังสอง ($\Delta \varepsilon$) กับค่าการรบกวน ($v \cdot \Delta P$) จะเห็นว่าในทุกขั้นตอนก่อน
การปรับค่าน้ำหนักโครงข่าย จะไม่มีการคำนวณค่าอนุพันธ์ใดๆ ซึ่งทำให้ขั้นตอนการประมวลผล
ไม่ซับซ้อนเมื่อเปรียบเทียบกับอัลกอริทึมอื่นๆ ที่ปรับค่าน้ำหนักโดยการอนุพันธ์เพื่อคำนวณ
ค่าเกรเดียนท์ จึงทำให้ประหยัดทรัพยากรในการคำนวณ เมื่อนำสมการ (95) มาหาค่าเฉลี่ยหรือ
ค่าคาดหวัง (Expect Value) ดังแสดงในสมการ (96)

$$E[w_{k+1}] = E[w_k - \mu \cdot \Delta \varepsilon \cdot v \Delta P] \quad (96)$$

จากสมการ (96) ในขณะที่ทำการพิจารณานี้ เรากำลังพิจารณาที่จุด w_k จุดใดจุดหนึ่ง
ดังนั้นเราจะเห็นว่าจุด w_k นั้นเป็นตัวแปรคงที่อิสระไม่ขึ้นอยู่กับ $\mu \cdot \Delta \varepsilon \cdot v \Delta P$ และเมื่อพิจารณา
พจน์ $\mu \cdot \Delta \varepsilon \cdot v \Delta P$ จะเห็นว่า ตัวแปร μ นั้น มีค่าคงที่ไม่เปลี่ยนแปลง ดังนั้น สมการที่ (96) จึงถูก
เขียนใหม่ ดังสมการ (97)

$$E[w_{k+1}] = E[w_k] - \mu \cdot E[\Delta \varepsilon \cdot v \Delta P] \quad (97)$$

เมื่อพิจารณาสมการ (97) เราจะสังเกตว่าเมื่อสหสัมพันธ์ไขว้ระหว่าง $\Delta\varepsilon$ และ $v\Delta P$ นั้น มีค่าเป็นศูนย์สามารถเขียนเป็นสมการ (98)

$$E[\Delta\varepsilon \cdot v\Delta P] = 0 \quad (98)$$

นำสมการ (98) แทนลงใน (97) จะเป็นผลให้ การปรับค่าน้ำหนักนั้นไม่ขึ้นอยู่กับ การรบกวน แสดงในสมการ (99)

$$E[w_{k+1}] = E[w_k] \quad (99)$$

ที่จุดนี้เราคาดหวังว่า w_{k+1} จะมีค่าเท่ากับ w_k และเราคาดหวังว่า $E[\Delta\varepsilon \cdot v\Delta P]$ จะมีค่าเป็นศูนย์ ซึ่งนั่น คือ ผลการรบกวนค่าน้ำหนักทั้งที่เป็นทางด้านบวกและทางด้านลบให้ผลของ ค่าความผิดพลาดกำลังสองมีค่าเท่ากัน หรือ $\varepsilon(w_+) = \varepsilon(w_-)$ เป็นผลทำให้ค่า $\Delta\varepsilon$ มีค่าเท่ากับ ศูนย์

ถ้าหากว่าเราพิจารณาในกรณีที่ $\Delta\varepsilon \cdot v\Delta P$ มีค่าเป็นบวก ย่อมแสดงว่า การรบกวน ค่าน้ำหนักในด้านบวก เป็นผลให้เกิด $\varepsilon(w_+)$ มีค่ามากกว่า $\varepsilon(w_-)$ ที่เกิดจากการรบกวน ค่าน้ำหนักในด้านลบ จากสมการ (94) จะเห็นว่า ในกรณีนี้ค่าน้ำหนักจะถูกปรับให้มีค่าลดลง เท่ากับ $\mu \cdot \Delta\varepsilon \cdot v\Delta P$ เมื่อ $\Delta\varepsilon \cdot v\Delta P$ เป็นบวกเกิดจากการรบกวนค่าน้ำหนักด้านบวกเป็นผลให้เกิด ค่าความผิดพลาดกำลังสองมากกว่าการรบกวนค่าน้ำหนักด้านลบ $\varepsilon(w_+) > \varepsilon(w_-)$ จะเห็นว่า การทำเช่นนี้ เป็นวิธีการหาค่าเหมาะสมอีกวิธีการหนึ่ง โดยที่ค่าน้ำหนักนี้ จะถูกปรับเข้าหาค่าๆ หนึ่ง ซึ่งเป็นผลให้ค่าสหสัมพันธ์ไขว้น้อยสุดระหว่าง $\Delta\varepsilon$ และ $v\Delta P$ มีค่าเป็นศูนย์ ด้วยเหตุนี้เองจึงเรียก วิธีการปรับค่าน้ำหนักด้วยวิธีนี้ วิธีการสหสัมพันธ์ไขว้น้อยสุด (LCC: Least Cross Correlation) ขอให้สังเกตว่าการเข้าสู่ค่าเหมาะสม (Optimum Point) ซึ่งเป็นคำตอบของการหาค่าเหมาะสม ที่สุดนั้น ไม่ใช่คำตอบเดียวกับการใช้วิธีการที่อยู่บนพื้นฐานของการคำนวณค่าอนุพันธ์ คำตอบของ วิธีการที่นำเสนอนี้จะอยู่ ณ จุดที่ $E[\Delta\varepsilon \cdot v\Delta P] = 0$ ไม่ใช่จุดที่ค่าเกรเดียนต์หรือ $\nabla = \frac{\partial \varepsilon}{\partial w} = 0$ คำตอบที่แตกต่างกันนี้จะแสดงให้เห็นเพิ่มเติมในหัวข้อถัดไป