

## บทที่ 2

### เอกสารและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงเนื้อหาที่ได้ทบทวนซึ่งแบ่งเนื้อหาเป็นส่วนต่างๆ ดังนี้  
ปัญญาประดิษฐ์ (Artificial Intelligence : AI)

วิธีการหาค่าเหมาะสม (Optimization Method)

งานวิจัยเกี่ยวกับอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียม

#### ปัญญาประดิษฐ์ (Artificial Intelligence : AI)

ในปัจจุบันนี้ได้มีการนำเอากองพิวเตอร์เข้ามาช่วยในการประมวลผลอย่างกว้างขวาง โดยเฉพาะในกระบวนการหาค่าตอบเหมาะสม (Optimization) ของแต่ละปัญหา สงผลให้ การศึกษาในเรื่องปัญญาประดิษฐ์ (Artificial Intelligence) สาขาต่างๆ นี้ได้รับความนิยมเพิ่มขึ้นอย่างสูง ซึ่งสามารถนำไปประยุกต์ใช้ได้กับงานหลากหลายสาขา ทั้งสาขาวิชาทางด้านเทคโนโลยีสารสนเทศที่เป็นสาขาที่มีการศึกษาเรื่องนี้โดยตรง ทั้งยังสามารถประยุกต์ใช้ได้กับสาขาวิทยาศาสตร์การแพทย์ สาขาวิศวกรรมศาสตร์ รวมไปถึง สาขาวิชาการเกษตร ซึ่งหลักการการทำงานในเรื่องของปัญญาประดิษฐ์นั้น จะทำงานในลักษณะการค้นหาค่าตอบเพื่อให้ได้ค่าตอบที่ดีที่สุดและเหมาะสมกับปัญหานั้น ๆ ดังนั้น จึงมีวิธีการเกี่ยวกับการค้นหาค่าตอบที่ดีที่สุดมากมายที่ได้ถูกคิดค้นขึ้นและพัฒนามาอย่างต่อเนื่อง โดยปกติวิธีที่ได้รับความนิยมเลือกใช้เพื่อค้นหาค่าตอบที่ดีที่สุดวิธีหนึ่ง คือ วิธีการค้นหาค่าตอบแบบสุ่ม หรือ Stochastic Search Methods ซึ่งแยกได้เป็น Simulated Annealing (SA), Genetic Algorithm (GA), Neural Network (NN), Ant Colony Optimization (ACO), Particle Swarm Optimization(PSO) ซึ่งวิธีเหล่านี้จะประยุกต์ใช้หลักการความน่าจะเป็นแบบสุ่ม (Stochastic Process) มาอธิบายการทำงานและถูกนำมาประยุกต์ใช้แก้ปัญหาต่างๆ มากมาย ซึ่งขึ้นอยู่กับความเหมาะสมสมกับลักษณะของปัญหานั้น

ในงานทางด้านวิศวกรรมนั้น มีการนำวิธีการค้นหาค่าตอบแบบสุ่มมาใช้ เพื่อหาค่าตอบที่เหมาะสมของปัญหาต่างๆ ซึ่งวิธีที่หนึ่งที่ได้รับความนิยมอย่างมาก คือ โครงข่ายประสาทเทียม (Neural Network : NN) จากการทบทวนเอกสารที่ผ่านมา พบว่า การใช้เครื่องข่ายประสาทเทียม เพื่อค้นหาค่าเหมาะสมเพื่อแก้ปัญหาได้ฯ นั้น ได้มีอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียมที่ถูก

คิดคันและพัฒนาขึ้นจำนวนมากในปัจจุบันเพื่อนำไปประยุกต์ใช้กับงานหลายหลายประเภท แต่โดยทั่วไปแล้ว พบว่า อัลกอริทึมที่ถูกพัฒนาขึ้นมาหนึ่ง มักจะมีคุณลักษณะและสมรรถนะที่แตกต่างกัน ยิ่งอัลกอริทึมเหล่านี้สามารถทำงานได้ด้วยประสิทธิภาพมากขึ้น ความต้องการ หน่วยความจำสำรองและความเร็วของหน่วยประมวลผลที่ใช้สำหรับประมวลผลด้วยกระบวนการ ของอัลกอริทึมเหล่านี้ยิ่งเพิ่มขึ้น ส่งผลให้ เป็นการสิ้นเปลืองทรัพยากรในการประมวลผลของ แต่ละอัลกอริทึม เมื่อต้องนำโครงข่ายประสาทเทียมมาประยุกต์ใช้ในงานทางด้านวิศวกรรมที่ ต้องการนำโครงข่ายประสาทเทียมมาดำเนินการด้วยอุปกรณ์ประมวลผลที่มีข้อจำกัดเรื่อง หน่วยความจำสำรอง ซึ่งมีจำนวนไม่มาก เช่น ไมโครคอนโทรลเลอร์ พบว่า ไม่สามารถบรรจุ กระบวนการการทำงานทั้งหมดของอัลกอริทึมเหล่านั้นลงในหน่วยความจำของ ไมโครคอนโทรลเลอร์ได้ ดังนั้น งานวิจัยฉบับนี้ ผู้วิจัยจึงได้ทำการศึกษาและพัฒนาอัลกอริทึมที่มี ขั้นตอนในการประมวลผลไม่ซับซ้อน ซึ่งเหมาะสมต่อการนำไปประยุกต์ใช้กับอุปกรณ์ประมวลผลที่มี หน่วยความจำขนาดเล็กหรือที่มีทรัพยากรการประมวลผลที่จำกัด

### วิธีการหาค่าเหมาะสม (Optimization Method)

เหตุผลหลักของการนำวิธีการหาค่าเหมาะสมมาประยุกต์ใช้เพื่อแก้ปัญหาใดๆ นั้น คือใน ปริภูมิ (Space) ของปัญหาต่างๆ ที่เราพิจารณาหนึ่ง เราไม่สามารถทราบได้ล่วงหน้าเลยว่าคำตอบที่ เหมาะสมนั้นมีค่าเท่าใดและอยู่ที่ใดในปริภูมิของปัญหา หรือมีเงื่อนไขเป็นอย่างไรบ้าง เพื่อให้ได้มา ซึ่งคำตอบที่เหมาะสมของปัญหาหนึ่งๆ ดังนั้น ใน การหาคำตอบที่เหมาะสมของปัญหาต่างๆ นั้น จึงจำเป็นต้องใช้วิธีการค้นหาคำตอบแบบสุ่ม ซึ่งมีรายวิธี เช่น Simulated Annealing (SA), Genetic Algorithm (GA), Neural Network (NN), Ant Colony Optimization (ACO), Particle Swarm Optimization (PSO) ซึ่งแต่ละวิธีนั้นจะถูกนำไปประยุกต์ใช้กับปัญหาที่แตกต่างกัน ในวิทยานิพนธ์นี้ จะกล่าวถึงวิธีการหาคำตอบเหมาะสมของวิธีการเหล่านี้อย่างคร่าวๆ แต่จะเน้น เนื้อหาในส่วนของ Neural Network (NN) เนื่องจากผู้วิจัยได้ทำการศึกษาและพัฒนาอัลกอริทึม เกี่ยวกับการฝึกสอน Neural Network (NN)

#### 1. Genetic Algorithm (GA)

การทำงาน ของเจเนติกอัลกอริทึม เป็นวิธีการหาคำตอบโดยอาศัยหลักการทำงาน จากการคัดสรรสิ่งที่ดีที่สุด ตามหลักวิวัฒนาการ ซึ่งคำตอบที่ดีที่สุดจะสามารถอยู่รอดในสิ่งแวดล้อมนั้น และได้รับการถ่ายทอดไปยังรุ่นต่อไป (Goldberg, 1989) การทำงานด้วย Genetic Algorithm นั้น เริ่มต้นจะมีการสร้างประชากร (Population) ขึ้นมาเป็นคำตอบจำนวนหนึ่ง โดยกำหนดให้แต่ละ คำตอบที่สรุปขึ้นมาหนึ่ง เรียกว่า โครโน่ แต่ละโครโน่จะประกอบไปด้วยหน่วยเล็กๆอย่าง

ไปอีก เรียกว่า ยีน (gene) จากนั้นแต่ละโครโมโซมจะถูกนำไปผ่านกระบวนการทางพันธุกรรม ซึ่งมีอยู่ 2 ประเภท คือ การสลับสายพันธ์ (Crossover) และการกลายพันธ์ (Mutation) ซึ่งจะเลือกทำอย่างใดอย่างหนึ่ง หรือว่าทั้งสองอย่างก็ได้ แล้วแต่ความเหมาะสม หลังจากผ่านขั้นตอนทางพันธุกรรมแล้ว จะทำการประเมินค่าความเหมาะสมของแต่ละโครโมโซม โดยที่โครโมโซมที่มีค่าความเหมาะสมมากสุดจะมีโอกาสอยู่รอบมากที่สุด และผ่านเข้าไปสู่กระบวนการคัดสร้างโดยในขั้นตอนการคัดสร่านี้ หากโครโมโซมใดที่สามารถผ่านกระบวนการคัดสร้างได้ จะทำให้โครโมโซมนั้นถูกเลือกเพื่อถ่ายทอดลักษณะทางพันธุกรรมให้แก่โครโมโซมในรุ่นต่อๆ ไป

ส่วนการตรวจสอบขั้นตอนการทำงานของเจนเดิกอัลกอริทึมนี้ จะตรวจสอบโดยการตรวจสอบเงื่อนไขหยุดการทำงาน ซึ่งขึ้นอยู่กับว่าผู้ใช้จะกำหนดเงื่อนไขไว้อย่างไร อาจจะกำหนดโดยระบุจำนวนรุ่น (Generation) ของประชากรที่ต้องการหรือเมื่อคำตอบมีค่าใกล้เคียงกับคำตอบเป้าหมายมากที่สุด

### 2. Ant Colony Optimization (ACO)

Ant colony Optimization หรือ ACO เป็นวิธีการหาค่าเหมาะสมโดยจำลองการทำงานมาจากการหาน้ำอาหารของมด เพื่อหาเส้นทางการค้นหาอาหารที่สั้นที่สุดระหว่างรังของมด และแหล่งอาหาร โดยรวมชาติการค้นหาอาหารของมดนั้น นัดแต่ละตัวจะเลือกเส้นทางการค้นหาอาหารแบบสุ่ม และกลับมาที่รังเมื่อค้นหาอาหารเจอ โดยในขณะที่เดินทางไปหาอาหารนั้น จะทิ้งหลักฐานไว้ตลอดทางเดิน เรียกว่า พิโรมน (Pheromone) โดยที่มดตัวต่อไปจะเลือกเดินตามทางที่มีความหนาแน่นของ พิโรมนสูง ซึ่งเป็นเส้นทางสั้นที่สุดที่สามารถพบแหล่งอาหารได้ เหตุผลที่ทำให้เชื่อว่า เน็นที่มีความหนาแน่นของ พิโรมนสูง นั้น เป็นเส้นทางที่สั้นที่สุดที่จะพบอาหารได้ คือ การระเหยได้ของ พิโรมนดังนั้น เส้นทางยาวๆ จะมีการปล่อยพิโรมนไว้เป็นเวลานาน จึงทำให้ความหนาแน่นของ พิโรมน ลดลง เมื่อเบร์ยบเทียบกับเส้นทางที่สั้นกว่าที่มีการปล่อยพิโรมนไว้เพียงเวลาสั้นๆ และมีการปล่อย พิโรมนช้ากันไปมา จึงทำให้ง่ายต่อการหาเส้นทางที่สั้นที่สุด และเหมาะสมที่สุด (Marco Dorigo, et al., 1996)

### 3. Particle swarm optimization (PSO)

PSO ถือว่าเป็นอีกเทคนิคของ Evaluation Computation เมื่อเทียบ Genetic Algorithm โดยขั้นตอนการทำงานของอัลกอริทึมนี้ จะเริ่มต้นจากการสรุณสร้างประชากร โดยเรียกประชากรที่สร้างขึ้นมาแต่ละตัวนั้นว่าพาทิเคิล (Particle) ในแต่ละพาทิเคิลนั้น จะมีพารามิเตอร์ที่กำหนดคุณลักษณะเฉพาะของพาทิเคิลแต่ละตัว ทำให้แต่ละพาทิเคิลมีคุณลักษณะที่แตกต่างกัน ในขั้นตอนเริ่มต้นของการคำนวณค้นหาคำตอบ แต่ละพาทิเคิลจะค้นหาคำตอบให้คลอบคลุมพื้นที่ทั้งหมดของปัญหา โดยที่แต่ละพาทิเคิลนั้น ไม่ทราบมาก่อนว่าคำตอบที่ดีที่สุดนั้นอยู่ที่ตำแหน่งใด

ของพื้นที่ปัญหานั้น แต่จะจำค่าความเหมาะสมของพารามิเตอร์ที่ผ่านมาก่อนหน้านั้น เพื่อเป็นประสบการณ์ในการปรับตัวเพื่อหาคำตอบที่ดีที่สุด โดยกำหนดให้ค่าความเหมาะสมของพารามิเตอร์ค่า  $pbest$  จากนั้นจะนำค่าความเหมาะสมของแต่ละพารามิเตอร์ค่า  $pbest$  มาเปรียบเทียบกับค่าความเหมาะสมของพารามิเตอร์อื่นๆ โดยค่าที่ดีที่สุด ที่ได้รับหลังจากการเบริ่ยนเทียบค่าความเหมาะสมของพารามิเตอร์ทั้งหมด นั้นจะเรียกว่า ค่า  $gbest$  จากนั้นจะนำค่า  $gbest$  ที่ได้จากการเบริ่ยนเทียบของพารามิเตอร์ทั้งหมด ไปปรับค่าความเร็วและตำแหน่งของแต่ละพารามิเตอร์ให้ แต่ละพารามิเตอร์สามารถตัดสินใจได้ถูกต้องและเหมาะสม (Kennedy and Eberhart, 1995)

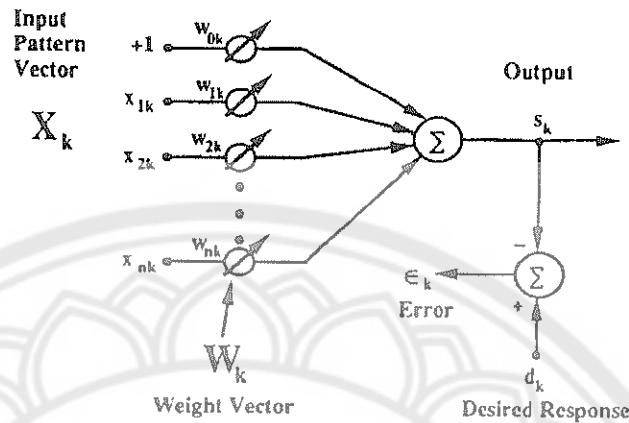
ถึงแม้ว่าวิธีของ PSO จะมีการทำงานที่คล้ายคลึงกับ GA แต่พบว่า มีบางขั้นตอนที่แตกต่างกับ GA อย่างชัดเจน คือ การทำงานของ PSO จะไม่มีการสลับสายพันธุ์ (Crossover) และการกลายพันธุ์ (Mutation) ซึ่งเป็นขั้นตอนที่สำคัญในการทำงานด้วยวิธีของ GA

#### 4. Neural Networks (NN)

โครงข่ายประสาทเทียมเป็นการทำงานที่จำลองพฤติกรรมการทำงานมาจากการเครือข่ายประสาทในสมองของมนุษย์ โดยลักษณะเด่นของการทำงานของโครงข่ายประสาทในสมองของมนุษย์ คือ การเรียนรู้จากประสบการณ์ที่ผ่านมาและสามารถใช้ประสบการณ์นั้นๆ มาสร้างความรู้ใหม่ได้ มีการจำลองการทำงานของสมองในลักษณะการทำงานแบบขั้นตอน ซึ่งประกอบด้วย เชลล์ประสาทจำนวนมาก

ในการศึกษาการทำงานของโครงข่ายประสาทเทียมนั้น จะต้องกล่าวถึงแนวคิดพื้นฐานขององค์ประกอบในโครงข่ายประสาทเทียม คือ Adaptive Linear Combiner หรืออย่างอื่นว่า Adaline (B. Widrow and M. A. Lehr, 1990) จากนั้นนำ Adaline หลายๆ ตัวมาเชื่อมตอกันเป็นโครงข่ายหลายชั้น เรียกว่า โครงข่ายประสาทเทียมแบบป้อนผลการคำนวณไปข้างหน้า (Artificial Feedforward neural networks)

โครงสร้างทั่วไปของ Adaline และส่วนประกอบของแต่ละ Adaline แสดงในภาพ 1



ภาพ 1 โครงสร้าง Adaptive Linear Combiner (Adaline)

Adaline แสดงในภาพ 1 เอ้าท์พุทที่ได้จาก Adaline จะเป็นค่าเอ้าท์พุทเชิงเส้น (Linear Output) ของอินพุตและค่าน้ำหนัก เมื่อ กำหนดให้วekเตอร์อินพุต (Input Vector :  $x_k$ ) มีค่าดัง สมการ (1)

$$x_k = [1 \quad x_{1k} \quad x_{2k} \quad \dots \quad x_{nk}]^T \quad (1)$$

เวกเตอร์ค่าน้ำหนัก (Weight Vector =  $w_k$ ) มีค่าดังสมการ (2)

$$w_k = [w_{1k} \quad w_{2k} \quad \dots \quad w_{nk}]^T \quad (2)$$

เอ้าท์พุทเชิงเส้น (Linear Output =  $s_k$ ) ระหว่างเวกเตอร์อินพุตและเวกเตอร์ค่าน้ำหนักมีค่าดังสมการ (3)

$$s_k = x_k^T w_k \quad (3)$$

ตัวแปรในภาพ 1 แทนค่าต่าง ๆ ดังต่อไปนี้

$d_k$  คือ ค่าเอาท์พุทที่ต้องการ (Desired Output)

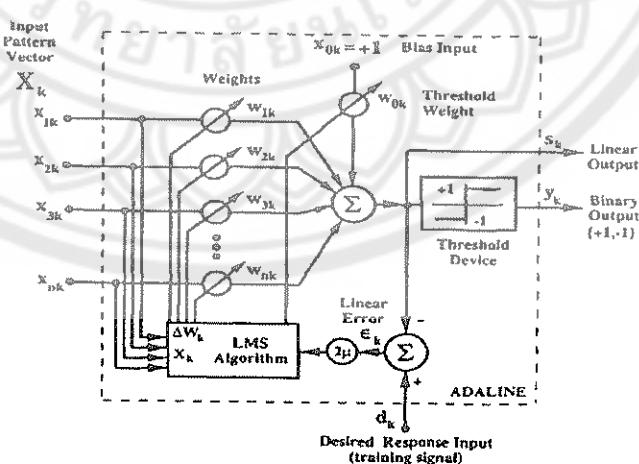
$w_{0k}$  คือ ค่าน้ำหนักไบแอส  $w_{0k}$  เป็นค่าคงที่ มีค่าเท่ากับ 1 เพื่อปรับค่าเทอร์โซล์ด์ของเอาท์พุทโครงข่าย

ในกระบวนการฝึกสอนโครงข่ายโดยทั่วไป เมื่ออินพุตฝึกสอนและค่าเอาท์พุทฝึกสอนโครงข่ายเข้าสู่โครงข่าย จะได้เอาท์พุทโครงข่ายออกมามาก่อนหนึ่ง เรียกว่า เอาท์พุทเชิงเส้น โดยที่อัลกอริทึมปรับค่าน้ำหนักโครงข่ายแต่ละอัลกอริทึม จะปรับค่าน้ำหนักโครงข่ายเพื่อให้เอาท์พุทโครงข่าย มีค่าใกล้เคียงเอาท์พุทฝึกสอนมากที่สุด

โดยทั่วไปโครงข่ายประสาทเทียม จะมีลักษณะคล้ายคลึงกับโครงสร้างของ Adaline ดังแสดงในภาพ 1 แต่เมื่อถูกนำมาประยุกต์เพื่อแก้ปัญหาทางตรรกศาสตร์ เพื่อให้ค่าเอาท์พุทโครงข่ายมีความสอดคล้องกับเอาท์พุทฝึกสอน ซึ่งส่วนมากจะเป็นค่าระดับ ไบนารี (binary) ดังนั้น Adaline จึงจำเป็นต้องเชื่อมต่อกับตัวเบ่งระดับ (Threshold)

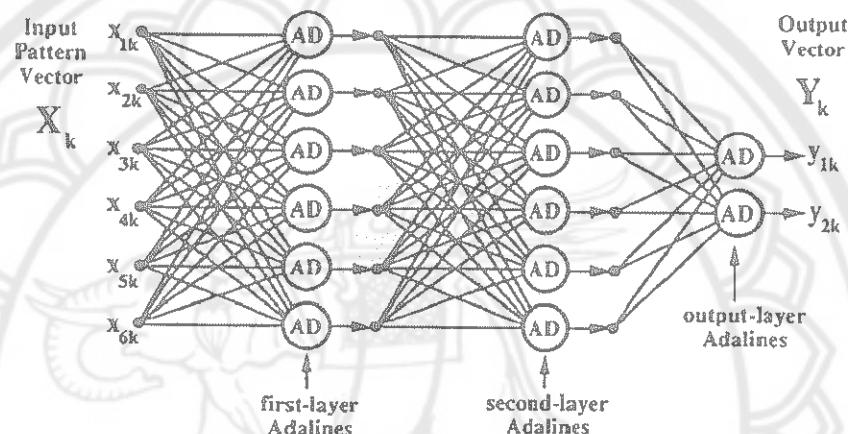
ภาพ 2 เป็นตัวอย่างการใช้ Adaline เชื่อมต่อกับตัวเบ่งระดับแบบ hard-limiting ซึ่งใช้สำหรับการสร้างเอาท์พุตจากโครงข่าย มีค่าเป็น  $\pm 1$  ซึ่งตัวเบ่งระดับนี้ สามารถเขียนแทนในรูปแบบสัญลักษณ์ของฟังก์ชันได้เป็น  $sgn$  (ซิกนัมฟังก์ชัน) ดังนั้น เพื่อให้ได้อเอาท์พุตโครงข่ายที่สอดคล้องกับเอาท์พุทฝึกสอน จึงต้องนำเอาท์พุตโครงข่ายเชื่อมต่อกับผ่านกับฟังก์ชันนี้ ดังแสดงในสมการ (4)

$$y_k = sgn(s_k) \quad (4)$$



ภาพ 2 โครงสร้างของ Adaline เชื่อมต่อกับตัวเบ่งระดับแบบ hard-limiting

จากที่ผ่านมาได้ศึกษาถึงลักษณะทั่วไปของ Adaline ซึ่งถือว่าเป็นหน่วยประมวลผลพื้นฐานของโครงข่ายประสาทเทียม เมื่อมีการนำ Adaline เชื่อมต่อกันหลายชั้น เรียกว่า โครงข่ายประสาทเทียม (multi-element neural network) โดยที่ไปจะเรียกโครงข่ายเหล่านี้ว่า โครงข่ายแบบหลายชั้น (multilayer neural network) หรือโครงข่ายประสาทเทียมหลายชั้นแบบไปข้างหน้า (Artificial Feedforwork Neural Network) ภาพ 3 แสดงตัวอย่างโครงข่ายประสาทเทียมแบบไปข้างหน้าที่มี 3 ชั้น



ภาพ 3 โครงข่ายประสาทเทียมแบบไปข้างหน้า (Artificial Feedforward Neura Network) แบบ 3 ชั้น

#### งานวิจัยเกี่ยวกับการฝึกสอนโครงข่ายประสาทเทียม

ตัวอย่างของงานวิจัยที่ศึกษาเกี่ยวกับอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียม ซึ่งดำเนินการโดยอนาล็อกคอมพิวเตอร์

Yutaka MAEDA, et al. (1991) ได้นำเสนอการเรียนรู้เพื่อฝึกสอนโครงข่ายประสาทเทียมแบบป้อนผลการคำนวนไปข้างหน้า โดยใช้ค่าผลต่างค่าความผิดพลาดกำลังสอง เพื่อปรับค่าน้ำหนักโครงข่าย ดังสมการปรับค่าน้ำหนักของโครงข่ายที่ (5)

$$w_i^{t+1} = w_i^t - \Delta w_i^t \quad (5)$$

เมื่อ

$w_i^t$  คือ ค่าน้ำหนักในดีที่  $i$  ถูกควบคุมด้วยค่าการรวมกวนค่าคงที่

$$c (w_1^t, \dots, w_i^t + c, \dots, w_n^t)^T$$

$w_i^{t+1}$  คือ ค่าน้ำหนักในดีที่  $i$  ที่ถูกปรับค่า

$\Delta w_i^t$  คือ ผลต่างระหว่างค่าความผิดพลาดกำลังสองของค่าน้ำหนัก  $w_i^t$  และ  $w^t$

เมื่อ  $\Delta w_i^t$  คำนวณได้จากสมการ (6)

$$\Delta w_i^t = \alpha \frac{E_p(w_i^t) - E_p(w^t)}{c} \quad (6)$$

เมื่อ

$E_p$  คือ ค่าเฉลี่ยความผิดพลาดกำลังสองระหว่างค่าน้ำหนัก  $w_i^t$  และ  $w^t$

$w_i^t$  คือ เวกเตอร์ค่าน้ำหนัก โดยที่ค่าน้ำหนักในดีที่  $i$  ถูกควบคุมด้วย

$$\text{ค่าการรวมกวนค่าน้ำหนัก } c (w_1^t, \dots, w_i^t + c, \dots, w_n^t)^T$$

$w^t$  คือ เวกเตอร์ค่าน้ำหนัก  $(w_1^t, w_2^t, w_3^t, w_4^t, \dots, w_n^t)^T$

$c$  คือ ค่าการรวมกวนค่าน้ำหนักค่าน้อยๆ (A perturbation) มีค่ามากกว่าศูนย์ ( $c > 0$ )

$\alpha$  คือ ค่าอัตราการเรียนรู้

$o_{pj}^{out}$  คือ ค่าเข้าพุทธิของข่ายของนิวรอลที่  $j$  pattern ที่  $p$  ในชั้น output

$t_{pj}$  คือ ค่าเข้าพุทธิฝึกสอนของข่ายที่  $j$  pattern ที่  $p$

เมื่อ

$$E_p(w^t) = \sum_j (t_{pj} - o_{pj}^{out})^2 \quad (7)$$

เมื่อ  $i = 1, 2, 3, \dots, n$

ค่ารวมกวนค่าน้ำหนัก  $c$  จะเป็นค่ารวมกวนน้อยๆ พนกว่าเมื่อ  $c$  มีค่าน้อยๆ ยิ่งทำให้ผลลัพธ์ที่ได้มีค่าใกล้เคียงกับค่าเกรเดียนท์มากขึ้นด้วย

Marwan Jabri and Barry Flower (1992) นำเสนองานวิจัยนี้ เนื่องจากถึงแม้ว่า อัลกอริทึมฝึกสอนโครงข่าย Back-propagation จะมีประสิทธิภาพสูงและสามารถทำงานโดยโครงข่าย ที่มีหลายชั้นได้ แต่พบว่า การกำหนดอัลกอริทึม Back-propagation ลงบนชิป (Chip) จำเป็นต้องใช้ทรัพยากรในการประมวลผลจำนวนมาก เช่น ต้องมีหน่วยความจำสำรองและความเร็วในการประมวลผลสูง ซึ่งมากเกินความสามารถที่ชิปตัวๆ หนึ่งจะทำได้ เพื่อแก้ปัญหาดังกล่าว Marwan Jabri and Barry Flower จึงได้ใช้การประมาณค่าเกรเดียนท์แทนการคำนวนค่าเกรเดียนท์โดยตรง โดยใช้หลักการการรับกวนค่าน้ำหนักแบบสุ่ม (Weight Perturbation) เพื่อนำมาประยุกต์ใช้กับงานทางด้านอนาคตอุตสาหกรรมแอลเอนจีไอ (VLSI : Very Large Scale Integrated) ใช้กับโครงข่ายเพอเซฟตรอนแบบหลายชั้นและประมวลผลด้วยอัลกอริทึมฝึกสอนโครงข่ายประสานเทียม Back-propagation โดยเรียกวิธีดังกล่าวว่า "การรับกวนค่าน้ำหนัก (Weight Perturbation)" ซึ่งพบว่า การประมาณด้วยวิธีนี้ใช้เพียงชั้นตอนในการคำนวนไปข้างหน้าอย่างเดียวโดยที่ไม่มีการคำนวนย้อนกลับ ทำให้ลดชั้นตอนการประมวลผลลงได้ ซึ่งเป็นข้อดี สำหรับการนำอัลกอริทึมนี้ไปทดสอบการทำงานบนเครื่องมืออนาคตอุตสาหกรรมแอลเอนจีไอ (VLSI) ที่มีการประมวลผลเชิงขนาน (Parallel Analog) ได้ และเหมาะสมเมื่อใช้กับโครงข่ายประสานเทียมแบบย้อนกลับ (Recurrent Networks)

โดยสมการที่ปรับค่าน้ำหนักที่ได้นำเสนอ เป็นดังสมการที่ (8) กำหนดให้

$$\Delta w_{ij} = G(pert_{ij}) \Delta E(w_{ij}, pert_{ij}) \quad (8)$$

เมื่อ

$$G(pert_{ij}) = \frac{-\beta}{pert_{ij}} \quad (9)$$

และ

$$\Delta E(w_{ij}, pert_{ij}) = E(w_{ij} + pert_{ij}) - E(w_{ij}) \quad (10)$$

เมื่อ

$\Delta E$  คือ ผลต่างของค่าความผิดพลาดกำลังสองระหว่างค่าน้ำหนักที่ถูกรับกวนและค่าน้ำหนักที่ไม่ถูกรับกวน

$pert_{ij}$  คือ ค่าคงที่ เพื่อใช้รับกวนค่าน้ำหนัก

$\beta$  คือ ค่าคงที่ใช้ปรับค่าน้ำหนัก

$w_{ij}$  คือ ค่าน้ำหนักโครงข่าย

$E(w_{ij})$  คือ ค่าความผิดพลาดกำลังสองของค่าน้ำหนักที่ไม่ถูกทราบ

$E(w_{ij} + pert_{ij})$  คือ ค่าความผิดพลาดกำลังสองของค่าน้ำหนักที่ถูกทราบ

$\Delta w_{ij}$  คือ ผลต่างค่าน้ำหนักโครงข่ายที่ใช้ปรับค่าน้ำหนักโครงข่าย

ซึ่งขั้นตอนการประมวลผล สามารถกำหนดได้ดังนี้

```

For each pattern p {
    E = ForwardPass ( )
    ClearDeltaWeight ( )
    For each weight  $W_{ij}$  do {
        Epert = ApplyPerturbate ( $W_{ij}$ )
        DeltaError = Epert - E
        DeltaW[i][j] =  $-\beta \cdot \text{DeltaError}/\text{Perturbation}$ 
        RemovePerturbation ( $W_{ij}$ )
    }
}

```

ภาพ 4 ขั้นตอนการประมวลผล

จากบทความนี้ เราสามารถสรุปได้ว่า การหาค่าเกรเดียนท์จากหลักการ การทราบค่าน้ำหนัก (Weight Perturbation) นั้น ทำให้โครงข่ายประสาทเทียมที่ได้มีขนาดเล็กเพียงพอที่ทำ การทดลองและจำลองการทำงานของอัลกอริทึมลงในชิปตัวนึงได้ ซึ่งเป็นอุปกรณ์ที่มี หน่วยความจำและความเร็วในการประมวลผลที่จำกัด แทนการหาค่าเกรเดียนท์จากการหาอนุพันธ์ อันดับหนึ่งหรือสองซึ่งมีขั้นตอนการประมวลผลที่ซับซ้อนเกินความสามารถที่จะบรรจุขั้นตอน การทำงานเหล่านั้นลงชิปตัวนึงๆ ได้

Kenichi Hirotsu and Martin A. Brooke (1993) พบว่า อัลกอริทึมฝึกสอนโครงข่าย ประสาทเทียมส่วนใหญ่ที่ใช้ดิจิตอลคอมพิวเตอร์ (Digital Computer) ในการดำเนินการนั้น ใช้เวลา ในการประมวลผลมาก จึงเป็นเรื่องยากที่จะนำไปประยุกต์ใช้กับปัญหาที่เกิดขึ้นจริงในทางปฏิบัติ ดังนั้น จึงได้เสนออัลกอริทึมที่สามารถดำเนินการด้วยชิป VLSI เพื่อนำไปประยุกต์ใช้กับปัญหาจริง โดยได้เรียกว่า "Random Weight Change Learning Algorithm" ซึ่งมีหลักการ คือ ค่าน้ำหนัก ( $w_{ij}$ ) จะถูกเปลี่ยนไปในลักษณะสุ่ม จากสถานะเดิมตัวอย่างๆ มีค่าอยู่ระหว่าง

±δ ถ้าผลรวมค่าความผิดพลาดระหว่างจุดเอกสารที่พุ่มไม้ในกรอบข่ายและเอกสารที่พุ่มไม้ที่ต้องการมีค่าลดลง โดยใช้ค่าน้ำหนักที่ถูกเปลี่ยนแปลงไปนั้น ค่าน้ำหนักตัวดังกล่าวจะถูกใช้ฝึกโครงข่ายต่อไปจนกว่าทั้งค่าความผิดพลาดมีค่าเพิ่มขึ้น และเมื่อค่าความผิดพลาดมีค่าเพิ่มขึ้นแล้ว ค่าน้ำหนักตัวดังกล่าวจะถูกเปลี่ยนแปลงด้วยค่าสูมน้อยๆ อีกครั้งหนึ่ง

ดังสมการปรับค่าน้ำหนักที่นำเสนอดังสมการ (12)

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n+1) \quad (11)$$

เมื่อ

$$\Delta w_{ij}(n+1) = \Delta w_{ij}(n) : \text{if } E(n+1) < E(n)$$

$$\Delta w_{ij}(n+1) = \delta \cdot \text{Rand}(n) : \text{if } E(n+1) \geq E(n)$$

$\text{Rand}(n)$  คือ พังก์ชันสุ่ม มีค่าสองระดับ คือ ±1

δ คือ ค่าคงที่ควบคุมลักษณะการกระจายตัวของพังก์ชันสุ่ม  $\text{Rand}(n)$

Gert Gauwenberghs (1993) ได้นำเสนอภูมิปัญญา Stochastic Error-Descent เพื่อหาเหมาะสมของค่าน้ำหนักในโครงข่ายที่กำหนดและทำให้ค่าความผิดพลาดของโครงข่ายมีค่าลดลง

พังก์ชันค่าเฉลี่ยความผิดพลาดกำลังสอง คำนวณได้จากสมการ (12)

$$\varepsilon(p) = \frac{1}{2} \sum_{\alpha} \sum_k (x_k^{T(\alpha)} - x_k^{(\alpha)})^2 \quad (12)$$

เมื่อ

$x_k^{T(\alpha)}$  คือ เอกสารที่ต้องการ

$x_k^{(\alpha)}$  คือ เอกสารที่โครงข่าย

$\alpha$  คือ ลำดับครั้งในการฝึกสอนโครงข่าย

$k$  คือ ลำดับ pattern ที่ใช้ฝึกสอนโครงข่าย

$p$  ค่าคงที่ซึ่งทำให้พังก์ชันค่าเฉลี่ยความผิดพลาดกำลังสองมีค่าน้อยสุด

เมื่อกำหนดให้

$$\hat{p} = p + \pi \quad (13)$$

เมื่อ

$$\hat{\varepsilon} = \varepsilon(\hat{p}) - \varepsilon(p) \quad (14)$$

โดยที่

$$\Delta p = -\mu \hat{\epsilon} \pi \quad (15)$$

เมื่อ

- $\hat{\epsilon}$  คือ ผลต่างค่าความผิดพลาดกำลังสองระหว่างค่าคงที่  $\hat{p}$  และค่าคงที่  $p$
- $\pi$  คือ ค่าการรวมกันซึ่งเลือกจากภาระกระจายตัวในลักษณะสุ่ม (Random Distribution)
- $\hat{p}$  คือ ค่าคงที่ ซึ่งบวกด้วยค่าการรวมกัน ( $\pi$ ) ซึ่ง  $\hat{p} = p + \pi$
- $\mu$  คือ ค่าคงที่น้อยๆ มีค่าเป็นบวกเสมอ

Paul W.Hollis and John J.Paulos (1994) ได้นำเสนอแนวคิดเพื่อหาค่าเหมาะสมเมื่อดำเนินการด้วยอุปกรณ์ VLSI ซึ่งการปรับค่าน้ำหนักประมาณได้จากการเปลี่ยนแปลงค่าความผิดพลาดที่ได้จากการรวมกันน้ำหนักเพื่อหาค่าเกรดเดียนที่ในแต่ละจุด (Local Gradient) โดยทั่วไป สมการที่ใช้ปรับค่าน้ำหนักแสดงดังสมการที่ (16)

$$\Delta w_{ji} = -n \frac{E_{norm} - E_{pert}}{w_{ji_{nom}} - w_{ji_{pert}}} = -n \frac{\Delta E}{\uparrow w_{ji}} \quad (16)$$

เมื่อ

- $\Delta w_{ji}$  คือ ค่าน้ำหนักที่ถูกเปลี่ยนไป ในกระบวนการคำนวณจากชั้น  $i$  ไปที่ชั้น  $j$
- $n$  คือ อัตราการเรียนรู้
- $\uparrow w_{ji}$  คือ ค่าผลต่างระหว่างค่าน้ำหนักเฉลี่ย ( $w_{ji_{nom}}$ ) และค่าน้ำหนักที่ใช้ร่วกันค่าน้ำหนักในโครงข่าย ( $w_{ji_{pert}}$ )
- $\Delta E$  คือ ผลต่างระหว่างค่าความผิดพลาดกำลังสองของค่าน้ำหนักเฉลี่ยและค่าน้ำหนักที่ใช้ร่วกันค่าน้ำหนักในโครงข่าย ( $E_{norm} - E_{pert}$ ) ซึ่งเป็นผลจาก การเปลี่ยนแปลงค่าน้ำหนักด้วยค่า  $\uparrow w_{ji}$

Gert Gauwenberghs (1994) ได้นำเสนอการเรียนรู้แบบมีผู้ฝึกสอน (Supervisor Training) ในโครงข่ายประสาทเทียม โดยทดลองในชิปอนาคตที่มีการเปลี่ยนแปลงตลอดเวลา (Dynamical Features) กับโครงข่ายแบบย้อนกลับ (Recurrent Network)

สมการปรับค่าน้ำหนักเป็นดังสมการ (17)

$$p^{(k+1)} = p^{(k)} - \mu \cdot \hat{\epsilon}^{(k)} \pi^{(k)} \quad (17)$$

และ

$$\hat{\varepsilon}^{(k)} = \frac{1}{2} (\varepsilon(p^{(k)} + \pi^{(k)}) - \varepsilon(p^{(k)} - \pi^{(k)})) \quad (18)$$

เมื่อ

$p^{(k+1)}$  คือ ค่าคงที่ในโครงข่าย ที่ถูกปรับค่าแล้ว

$p^{(k)}$  คือ ค่าคงที่ ก่อนจะถูกปรับค่า

$\mu$  คือ อัตราการเรียนรู้ที่ใช้ในโครงข่าย

$\hat{\varepsilon}^{(k)}$  คือ ค่าเฉลี่ยความผิดพลาดของการรับกวนค่าน้ำหนักทั้งสองด้าน

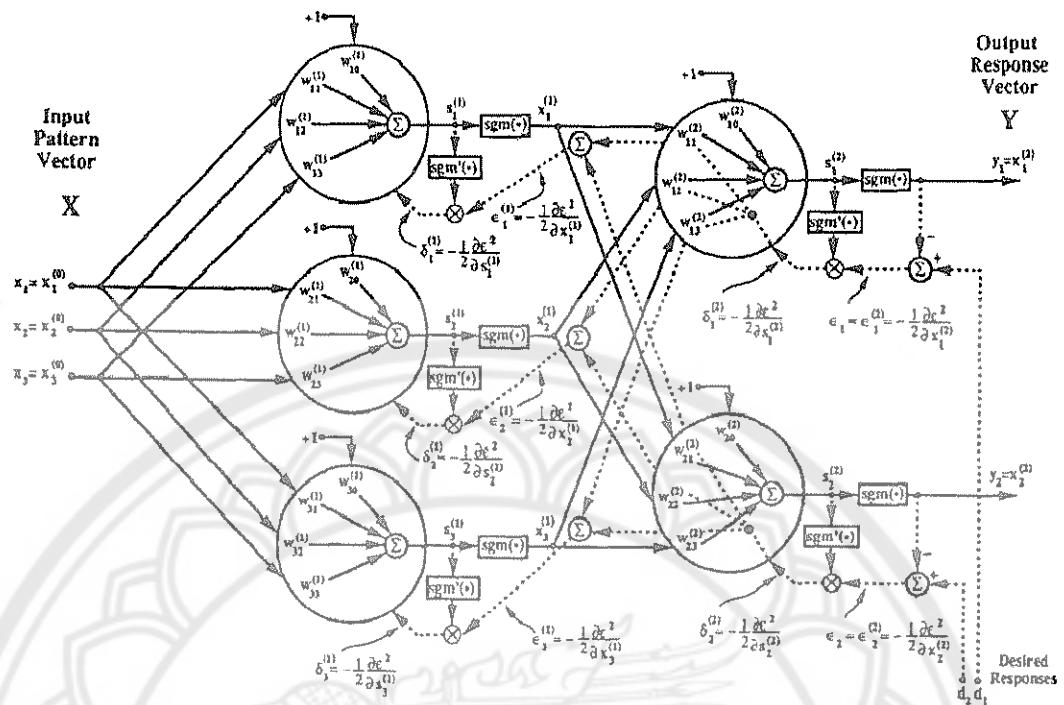
$\pi^{(k)}$  คือ ค่าการรับกวนแบบสุ่มของตัวแปร  $p^{(k)}$  โดยกำหนดขนาด

เป็นค่าคงที่ โดยทั่วไปมีค่าเท่ากับค่าความแปรปรวนของตัวแปรสุ่ม  $p^{(k)}$

การปรับค่าน้ำหนักแบบนี้叫做การรับกวนค่าน้ำหนักทั้งสองด้าน (Two-Side Perturbation) เมื่อกำหนดให้ขนาดของค่าการรับกวน คือ  $\pi_i^{(k)}$  มีค่าเท่ากับค่าความแปรปรวนให้กับตัวแปร  $p^{(k)}$  หรือ  $\pm\sigma$

ตัวอย่างของงานวิจัยที่ศึกษาเกี่ยวกับอัลกอริทึมฝึกสอนโครงข่ายประสาทเทียมที่ประมวลผลได้รวดเร็วและมีประสิทธิภาพสูง

Bernard Widrow and Michael A. LEHR (1960) นำเสนอกระบวนการ การประมวลผลในโครงข่ายแบบการแพร์ค่าย้อนกลับ (Backpropagation for Network) เมื่อนำไปประยุกต์ใช้กับโครงข่ายที่เชื่อมต่อกันเป็นโครงข่าย ดังแสดงในภาพ 5



ภาพ 5 ตัวอย่างโครงข่าย 2 ชั้น (Layer) เมื่อใช้กับการเรียนรู้แบบแพร์ค่าข้อนกลับ

โครงข่ายในภาพ 5 จะทำการปรับค่าน้ำหนักโครงข่าย ด้วยหลักการแพร์ค่าข้อนกลับ (Backpropagation) ในทิศทางตรงกันข้ามโดยใช้ค่าเกรดเดียนท์ชั่วขณะ (Instantaneous Gradient) ซึ่งคำนวนได้ตามสมการ (19)

$$\widehat{\nabla}_k = \frac{\partial \epsilon_k^2}{\partial W_k} = \begin{matrix} \frac{\partial \epsilon_k^2}{\partial W_{1k}} \\ \vdots \\ \frac{\partial \epsilon_k^2}{\partial W_{mk}} \end{matrix} \quad (19)$$

เมื่อ  $W_k$  เป็นเวกเตอร์ค่าน้ำหนักโครงข่าย มีจำนวนองค์ประกอบทั้งหมดในเวกเตอร์เท่ากับ  $m$  ค่าเขียนแทนได้เป็น  $W_k = [w_{1k}, w_{2k}, \dots, w_{mk}]$  เมื่อ  $k$  เป็นค่าคงที่ ดังนีบอกรอบคั่ง ของการคำนวน

ผลรวมค่าความผิดพลาดกำลังสอง (Sum Square Error) หรือ  $\epsilon_k^2$  ของแต่ละเอาท์พุท คำนวนได้ตามสมการ (20)

$$\epsilon_k^2 = \sum_{i=1}^{N_y} \epsilon_{ik}^2 \quad (20)$$

เมื่อ

$i$  คือ จำนวนในดเอกท์พุตโครงข่าย ในภาพ 4 พบว่า  $i = 1, 2$  เมื่อจากมีในดเอกท์พุตจำนวน 2 ในด

$K$  คือ ตัวนับอกลำดับครั้งของการคำนวณ

$N_y$  คือ จำนวนโนดเอกท์พุต ในชั้นเอกท์พุต ซึ่งในภาพ 5  $N_y = 2$

จากตัวอย่างโครงข่ายภาพ 5 ผลรวมค่าความผิดพลาดกำลังสอง (Sum Square Error) ของแต่ละโนดเอกท์พุตโครงข่าย คำนวณได้ตามสมการ (21)

$$\varepsilon_k^2 = (d_1 - y_1)^2 + (d_2 - y_2)^2 \quad (21)$$

เมื่อ

$d_1$  คือ เอกท์พุตฝึกสอนโครงข่าย ในดเอกท์พุต ที่ 1

$y_1$  คือ เอกท์พุตโครงข่าย ในดเอกท์พุต ที่ 1

$d_2$  คือ เอกท์พุตฝึกสอนโครงข่าย ในดเอกท์พุต ที่ 2

$y_2$  คือ เอกท์พุตโครงข่าย ในดเอกท์พุต ที่ 2

กระบวนการฝึกสอนโครงข่ายแบบแพร่ค่าย้อนกลับ เริ่มต้นจาก นำเวกเตอร์อินพุตฝึกสอน ( $X$ ) เข้าสู่โครงข่าย สร้างเอกท์พุตโครงข่าย ( $y$ ) และคำนวณค่าความผิดพลาดของแต่ละเอกท์พุต จากนั้นนำค่าเอกท์พุตโครงข่าย ( $y$ ) เปรียบเทียบกับค่าเอกท์พุตฝึกสอน ( $d_k$ ) เพื่อคำนวณค่าความผิดพลาด กำลังสอง  $\varepsilon_k^2$  จากนั้นนำค่าความผิดพลาดกำลังสองไปคำนวณหาค่าเกรเดียนท์ โดยการหาอนุพันธ์ ค่าความผิดพลาดกำลังสอง (Square Error Derivative) เปรียบเทียบกับค่าน้ำหนักโครงข่าย  $(\frac{\partial \varepsilon_k^2}{\partial w_k})$  ซึ่งแทนด้วยสัญลักษณ์  $\delta$  ในแต่ละเอกท์พุต จากนั้น ปรับค่าน้ำหนักโครงข่ายด้วย ค่าเกรเดียนท์ที่คำนวณได้ และนำเวกเตอร์อินพุตฝึกสอนโครงข่ายตัวถัดไปเข้าสู่โครงข่าย และทำตามกระบวนการแบบเดิม การกำหนดค่าน้ำหนักในตอนเริ่มต้นการฝึกสอนโครงข่าย โดยทั่วไปแล้วจะกำหนดค่าน้ำหนักโครงข่ายในช่วงเริ่มต้นเป็นค่าสุ่มน้อยๆ

การเรียนรู้แบบแพร่ค่าย้อนกลับในภาพ 5 วงกลมใหญ่ทั้ง 5 วงกลม เปรียบเสมือน Adaptive Linear Combiner (Adaline) แต่ละตัว โดยที่สัญลักษณ์ที่เป็นเส้นทึบ แทน เส้นทาง การคำนวณไปข้างหน้าภายในโครงข่าย และสัญลักษณ์เส้นบาง แทน การคำนวณย้อนกลับตลอด โครงข่าย ซึ่งจะเกี่ยวข้องกับการคำนวณค่าเกรเดียนท์ ( $\delta$ ) โดยการหาอนุพันธ์

จากที่กล่าวมาก่อนหน้านั้น เมื่อเราเกตเอนอร์อินพุทฟีกสอน ( $X$ ) เข้าสู่โครงข่าย จะผ่านการคำนวณค่าความผิดพลาดกำลังสอง (Square Error) โดยเปรียบเทียบระหว่างเอาท์พุทโครงข่ายและเอาท์พุทฟีกสอนโครงข่าย ขั้นตอนต่อไป คือ การแพร่ค่าเกรดเดย์นท์ที่คำนวณได้ย้อนกลับเข้ามาในโครงข่ายเพื่อบรรบค่าหน้าหัก เรียกว่า Back-Propagation

การคำนวณอนุพันธ์ค่าความผิดพลาดกำลังสองของ Adaline ลำดับที่  $j$  ในชั้นที่ 1 นิยามดังสมการ (22)

$$\delta_j^{(1)} = -\frac{1}{2} \frac{\partial \varepsilon^2}{\partial s_j^{(1)}} \quad (22)$$

จากสมการ (22) เราสามารถคำนวณอนุพันธ์ค่าความผิดพลาดกำลังสองของ Adaline ลำดับที่ 1 ในชั้น 2 ของโครงข่าย ซึ่งจะเขียนแทนได้ คือ  $\delta_1^{(2)}$  ดังสมการ (23)

$$\delta_1^{(2)} = -\frac{1}{2} \frac{\partial \varepsilon^2}{\partial s_1^{(2)}} \quad (23)$$

เมื่อ

$s_1^{(2)}$  คือ เอาท์พุตโครงข่ายของ Adaline ลำดับที่ 1 ชั้นที่ 2 ในโครงข่าย

แทนค่า  $\varepsilon^2$  จากสมการ (21) ลงในสมการ (23) ได้ตามสมการ (24) และ (25)

$$\delta_1^{(2)} = -\frac{1}{2} \frac{\partial (d_1 - y_1)^2 + (d_2 - y_2)^2}{\partial s_1^{(2)}} \quad (24)$$

แทนค่า  $y_1 = \text{sgm}(s_1^{(2)})$  และ  $y_2 = \text{sgm}(s_2^{(2)})$  ลงในสมการ (24) ได้สมการ (25)

$$= -\frac{1}{2} \frac{\partial (d_1 - \text{sgm}(s_1^{(2)}))^2}{\partial s_1^{(2)}} - \frac{1}{2} \frac{\partial (d_2 - \text{sgm}(s_1^{(2)}))^2}{\partial s_1^{(2)}} \quad (25)$$

สังเกตในพจน์ที่สองของสมการ (25) มีค่าเท่ากับศูนย์ ได้สมการ (26)

$$\delta_1^{(2)} = -\frac{1}{2} \frac{\partial \left( d_1 - sgm(s_1^{(2)}) \right)^2}{\partial s_1^{(2)}} \quad (26)$$

จากสมการ (26) ตัวแปร  $d_1$  และ  $s_1^{(2)}$  เป็นตัวแปรอิสระไม่เกี่ยวข้องกัน ดังนั้น เมื่อทำ การอนุพันธ์แล้วได้ดังสมการ (27)

$$\delta_1^{(2)} = -\left( d_1 - sgm(s_1^{(2)}) \right) \frac{\partial \left( -sgm(s_1^{(2)}) \right)^2}{\partial s_1^{(2)}} \quad (27)$$

$$= \left( d_1 - sgm(s_1^{(2)}) \right) sgm'(s_1^{(2)}) \quad (28)$$

เมื่อ  $(d_1 - sgm(s_1^{(2)}))$  สามารถเขียนแทนได้ด้วย  $\varepsilon_1^{(2)}$  ดังนั้น อนุพันธ์ค่าความผิดพลาด กำลังสองของ Adaline ลำดับที่ 1 ชั้นที่ 2 ในโครงข่าย ที่สอดคล้องกับสมการที่ (28) จะกล้ายเป็น

$$\delta_1^{(2)} = \varepsilon_1^{(2)} sgm'(s_1^{(2)}) \quad (29)$$

จากภาพ 5 กำหนดให้  $\delta_1^{(1)}$  แทน อนุพันธ์ค่าความผิดพลาดกำลังสองของ Adaline ลำดับที่ 1 ชั้นที่ 1 ในโครงข่าย เรียนแทนได้ดังสมการ (30)

$$\delta_1^{(1)} \equiv -\frac{1}{2} \frac{\partial \varepsilon^2}{\partial s_1^{(1)}} \quad (30)$$

เมื่อใช้คุณสมบัติของ กฎลูกโซ่ (Chain Rule) โดยสังเกตจากค่า  $\varepsilon^2$  จะถูกกำหนดค่าใน พจน์ของ  $s_1^{(2)}$  และ  $s_2^{(2)}$  เรียนแทนได้ตามสมการ (31)

$$\delta_1^{(1)} = -\frac{1}{2} \left( \frac{\partial \varepsilon^2}{\partial s_1^{(2)}} \frac{\partial s_1^{(2)}}{\partial s_1^{(1)}} + \frac{\partial \varepsilon^2}{\partial s_2^{(2)}} \frac{\partial s_2^{(2)}}{\partial s_1^{(1)}} \right) \quad (31)$$

เมื่อ

$s_1^{(2)}$  คือ เอกพุตโครงข่ายของ Adaline ลำดับที่ 1 ชั้นที่ 2 ในโครงข่าย

$s_2^{(2)}$  คือ เอกพุตโครงข่ายของ Adaline ลำดับที่ 2 ชั้นที่ 2 ในโครงข่าย

จากภาพ 5 จะได้ความสัมพันธ์ของ  $s_1^{(2)}, s_2^{(2)}$  และ  $\delta_1^{(1)}, \delta_2^{(2)}$

แทนค่า  $s_1^{(2)} = (w_{10}^{(2)} + \sum_{i=1}^3 w_{1i}^{(2)} \operatorname{sgm}(s_i^{(1)}))$  และ  $s_2^{(2)} = (w_{20}^{(2)} + \sum_{i=1}^3 w_{2i}^{(2)} \operatorname{sgm}(s_i^{(1)})$

ลงในสมการ (31) จะได้สมการ (32) และ (33) ตามลำดับ

เมื่อ

$w_{10}^{(2)}$  คือ ค่าน้ำหนักไปแอกซของ adaline ลำดับที่ 1 ชั้นที่ 2 ในโครงข่าย

(เมื่อ 0 แสดงว่าเป็นค่าน้ำหนักไปแอกซ)

$w_{20}^{(2)}$  คือ ค่าน้ำหนักไปแอกซของ adaline ลำดับที่ 2 ชั้นที่ 2 ในโครงข่าย

(เมื่อ 0 แสดงว่าเป็นค่าน้ำหนักไปแอกซ)

$i$  คือ จำนวน adaline ทั้งหมดในชั้นที่ 1 ตั้งนั้น

$w_{1i}^{(2)}$  คือ เวกเตอร์ค่าน้ำหนักของ adaline ลำดับที่ 1 ชั้นที่ 2 ในโครงข่าย  
สามารถเขียนแทนได้  $w_{1i}^{(2)} = [w_{11}^{(2)}, w_{12}^{(2)}, w_{13}^{(2)}]$

$s_i^{(1)}$  คือ เวกเตอร์เอกพุทธัณฑ์ของ adaline ชั้นที่ 2 ในโครงข่าย

สามารถเขียนแทนได้  $s_i^{(1)} = [s_1^{(1)}, s_2^{(1)}, s_3^{(1)}]$

$$\delta_1^{(1)} = \delta_1^{(2)} \frac{\partial s_1^{(2)}}{s_1^{(1)}} + \delta_2^{(2)} \frac{\partial s_2^{(2)}}{s_1^{(1)}} \quad (32)$$

$$\begin{aligned} &= \delta_1^{(2)} \frac{\partial}{\partial s_1^{(1)}} (w_{10}^{(2)} + \sum_{i=1}^3 w_{1i}^{(2)} \operatorname{sgm}(s_i^{(1)})) \\ &\quad + \delta_2^{(2)} \frac{\partial}{\partial s_1^{(1)}} (w_{20}^{(2)} + \sum_{i=1}^3 w_{2i}^{(2)} \operatorname{sgm}(s_i^{(1)})) \end{aligned} \quad (33)$$

เมื่อ

สังเกตที่ชั้นช่อน (l),  $\frac{\partial [\operatorname{sgm}(s_i^{(l)})]}{\partial s_j^{(l)}} = 0$  เมื่อ  $i \neq j$  จะได้ตั้งสมการ (34)

$$\delta_1^{(1)} = \delta_1^{(2)} w_{11}^{(2)} \operatorname{sgm}'(s_1^{(1)}) + \delta_2^{(2)} w_{21}^{(2)} \operatorname{sgm}'(s_1^{(1)})$$

$$\equiv [\delta_1^{(2)} w_{11}^{(2)} - \delta_2^{(2)} w_{21}^{(2)}] sgm'(s_1^{(1)}) \quad (34)$$

เรา定义  $\varepsilon_1^{(1)}$  ตามสมการ (35)

$$\varepsilon_1^{(1)} \equiv \delta_1^{(2)} w_{11}^{(2)} - \delta_2^{(2)} w_{21}^{(2)} \quad (35)$$

ดังนั้น  $\delta_1^{(1)}$  จากสมการ (35) จะกลายเป็น

$$\delta_1^{(1)} = \varepsilon_1^{(1)} sgm'(s_1^{(1)}) \quad (36)$$

จากภาพ 5 เราทราบได้ว่า 俤ราค่อนุพันธ์ค่าความผิดพลาดกำลังสอง ของ Adaline ลำดับที่ 1 ขั้นที่ 1 ของโครงข่าย ซึ่งเขียนแทนได้เป็น  $\delta_1^{(1)}$  สามารถคำนวณได้ตามสมการ (36)

หลังจากคำนวณค่าเกรเดียนท์ ( $\delta$ ) โดย俤ราค่อนุพันธ์ของแต่ละ Adaline ในโครงข่ายแล้ว ใช้ค่าเกรเดียนท์ที่คำนวณได้ ไปปรับค่าน้ำหนักในโครงข่าย โดยกำหนดให้เวกเตอร์ค่าน้ำหนัก โครงข่ายมีค่าเป็น  $W_k$  และเวกเตอร์อินพุตโครงข่ายมีค่าเป็น  $X_k$

ดังนั้น ค่าเอ้าท์พุตโครงข่ายย่อย คำนวณได้ตามสมการ (37)

$$S_k = W_k^T X_k \quad (37)$$

ค่าเกรเดียนท์ของแต่ละ Adaline ลำดับที่  $k$  คำนวณได้ดังสมการ (38)

$$\hat{V}_k = \frac{\partial \varepsilon_k^2}{\partial W_k} \quad (38)$$

เราสามารถเขียนได้เป็นอีกรูปแบบหนึ่ง ตามสมการ (39)

$$\hat{V}_k = \frac{\partial \varepsilon_k^2}{\partial W_k} = \frac{\partial \varepsilon_k^2}{\partial S_k} \frac{\partial S_k}{\partial W_k} \quad (39)$$

สังเกตว่า ค่า  $W_k$  และ  $X_k$  เป็นตัวแปรอิสระ ดังนั้น หลังจากทำการอ่อนุพันธ์จะได้ดัง สมการ (40)

$$\frac{\partial s_k}{\partial W_k} = \frac{\partial W_k^T X_k}{\partial W_k} = X_k \quad (40)$$

ดังนั้น จะได้เป็นค่าเกรเดียนท์เป็น ดังสมการ (41)

$$\hat{V}_k = \frac{\partial \varepsilon_k^2}{\partial s_k} X_k \quad (41)$$

จะได้  $\delta_k$  ตามสมการ (42)

$$\delta_k = -\frac{1}{2} \frac{\partial \varepsilon_k^2}{\partial s_k} \quad (42)$$

แทนค่า  $\delta_k$  จากสมการ (42) ลงในสมการ (41) จะได้ค่าเกรเดียนท์ตามสมการ (43)

$$\hat{V}_k = -2\delta_k X_k \quad (43)$$

จากนั้นปรับค่าน้ำหนักโครงข่ายด้วยวิธีของ Steepest descent โดยปรับค่าน้ำหนักในทิศทางตรงข้ามด้วยค่าเกรเดียนท์ที่คำนวณได้ สมการปรับค่าน้ำหนักโครงข่ายแสดงดังสมการ (44)

$$W_{k+1}^{(2)} = W_k^2 + \mu(-\hat{V}_k) = W_k^2 + \mu \delta_k^{(2)} X_k^{(1)} \quad (44)$$

จากนั้นปรับค่าน้ำหนักโครงข่ายโดย ด้วยวิธีของ Steepest descent เอาท์พุตโครงข่ายตัวแรกในชั้นเอาท์พุต ( $y_1$ ) แทนค่าเกรเดียนท์ที่คำนวณได้สมการ (30)  $\delta_1^{(2)} = \varepsilon_1^{(2)} \operatorname{sgm}'(s_1^{(2)})$  ลงในสมการ (44) จะได้สมการปรับค่าน้ำหนักของเอาท์พุต  $y_1$  ในภาพ 5 ได้ตามสมการ (45)

$$W_{k+1}^{(2)} = W_k + \mu(-\hat{V}_k) = W_k^2 + \mu \varepsilon_1^{(2)} \operatorname{sgm}'(s_1^{(2)}) X_k^{(1)} \quad (45)$$

Amir Abolfazl Suratgar, et al. (2005) ได้เสนออัลกอริทึมฟิกสอนโครงข่ายประสาทเทียมที่มีการลู่เข้าที่รวดเร็วและมีประสิทธิภาพสูง ซึ่งพัฒนามาจาก Levenberg-Marquardt Algorithm โดยใช้การคำนวณหาค่าเมทริกซ์อนุพันธ์อันดับสอง เรียกว่า Hessian Matrix เพื่อใช้ปรับค่าน้ำหนักโครงข่าย ซึ่งแทนด้วยสัญลักษณ์  $H$  แต่เนื่องจากการคำนวณค่าของเมตริกซ์นั้น

มีความสุ่มยาก อีกทั้งกระบวนการคำนวณนั้นมีความซับซ้อน ดังนั้น Amir Abolfazl Suratgar, et al. จึงได้ทำการประมาณค่าของ  $H$  จากการคำนวณค่า Jacobian แทน ซึ่งใน Levenberg-Marquardt Algorithm จะประมาณค่าของ  $H$  ดังสมการ (46) เมื่อ  $J$  เรียกว่า ค่า Jacobian (Jacobian)

$$H = J^T J \quad (46)$$

เช่นเดียวกับค่าเกรเดียนที่คำนวณได้จากการนำค่า Jacobian ( $J$ ) คูณด้วยค่าเวกเตอร์ค่าความผิดพลาด ( $e$ ) คำนวณได้ตามสมการ (47)

$$g = J^T e \quad (47)$$

เมื่อ

$H$  คือ Hessian Matrix

$J$  คือ Jacobian Matrix

$e$  คือ เวกเตอร์ค่าความผิดพลาด

นิยาม กำหนดให้  $X_k = [x_1 \ x_2 \ \dots \ x_n]^T$  และ  $f(X)$  เป็นสเกลาร์ฟังก์ชันของ  $x$  ดังนั้น อนุพันธ์ลำดับที่ 2 ของ  $f(X)$  เทียบกับ  $x$  ซึ่งเรียกว่า Hessian matrix หรือ Hessian นิยามโดย

$$H_f = \nabla^2 f(x) = \begin{bmatrix} \frac{\partial^2}{\partial x_1^2} f(x) & \frac{\partial^2}{\partial x_1 \partial x_2} f(x) & \dots & \frac{\partial^2}{\partial x_1 \partial x_n} f(x) \\ \frac{\partial^2}{\partial x_2 \partial x_1} f(x) & \frac{\partial^2}{\partial x_2^2} f(x) & \dots & \frac{\partial^2}{\partial x_2 \partial x_n} f(x) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_n \partial x_1} f(x) & \frac{\partial^2}{\partial x_n \partial x_2} f(x) & \dots & \frac{\partial^2}{\partial x_n^2} f(x) \end{bmatrix} \quad (48)$$

$J$  คือ Jacobian ซึ่งสามารถนิยามได้ดังต่อไปนี้

นิยาม กำหนดให้  $X_k = [x_1 \ x_2 \ \dots \ x_n]^T$  และ  $f(X)$  เป็นสเกลาร์ฟังก์ชันของ  $x$  โดยที่  $f(X) = [f_1(x) \ f_2(x) \ \dots \ f_n(x)]^T$  ดังนั้นอนุพันธ์ของ  $f(X)$  เทียบกับ  $x$  ซึ่งเรียกว่า Jacobian

$$\mathbf{J}_f = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & & \vdots \\ \frac{\partial f_m}{\partial x_1} & \dots & \frac{\partial f_m}{\partial x_n} \end{bmatrix} \quad (49)$$

$\mathbf{g}$  คือ gradient ซึ่งสามารถนิยามได้ดังต่อไปนี้

นิยาม กำหนดให้  $\mathbf{X}_k = [x_1 \ x_2 \ \dots \ x_n]^T$  และ  $f(\mathbf{X})$  เป็นสเกลาร์ฟังก์ชันของ  $x$  ดังนั้นอนุพันธ์ของ  $f(\mathbf{X})$  เทียบกับ  $x$  ซึ่งเรียกว่า เกรเดียนท์เวกเตอร์ หรือ เกรเดียนท์

$$\nabla f(\mathbf{x}) = \left[ \frac{\partial}{\partial x_1} f(x) \ \ \frac{\partial}{\partial x_2} f(x) \ \ \dots \ \ \frac{\partial}{\partial x_m} f(x) \right]^T \quad (50)$$

$\mathbf{e}$  คือ เวกเตอร์ค่าความผิดพลาดของโครงข่าย มีค่าเป็นดังสมการ (51)

$$\mathbf{e} = [e_1 \ e_2 \ \dots \ e_n]^T \quad (51)$$

สมการที่ใช้ปรับค่าน้ำหนักของโครงข่าย มีค่าเป็นดังสมการ (52)

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (52)$$

ตัวอย่างของงานวิจัยที่ศึกษาเกี่ยวกับการหาค่าที่เหมาะสมโดยอาศัยการรับกวนแบบสุ่ม

Bernard Widrow and Samuel D.Stearns (1985) ได้ศึกษาการหาค่าเกรเดียนในลักษณะสุ่ม และใช้ค่าเกรเดียนที่ได้นี้ ปรับค่าน้ำหนักโครงข่าย โดยเรียกวิธีดังกล่าวว่า Linear Random-Search algorithm (LRS)

โดยสมการที่ใช้ในการ ปรับค่าน้ำหนักที่นำเสนอนี้ มีค่าเป็นดังสมการ (53)

$$\mathbf{W}_{k+1} = \mathbf{W}_k + \frac{\mu}{\sigma^2} [\xi (\mathbf{W}_k) - \xi (\mathbf{W}_k + \mathbf{U}_k)] \mathbf{U}_k \quad (53)$$

วช  
ศธ  
บด  
เศรษฐ  
สหฯ



เมื่อ

23 ส.ป. 2554

1.55 ๓๒๑๑๙

สำนักหอสมุด

$U_k$  คือ ค่าสุ่มน้อยมาก

$\xi (W_k)$  คือ ค่าเฉลี่ยความผิดพลาดกำลังสองของค่าน้ำหนัก

$\xi (W_k + U_k)$  คือ เป็นค่าเฉลี่ยความผิดพลาดกำลังสองของค่าน้ำหนักๆ

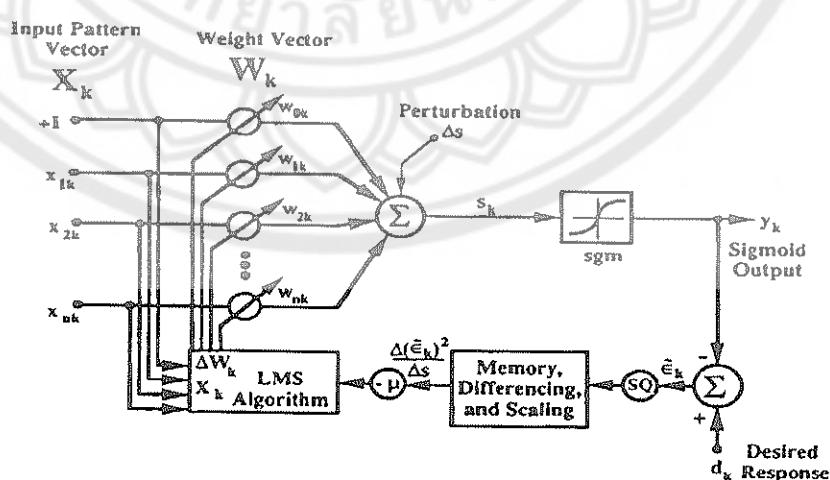
ที่บวกด้วยค่าสุ่มน้อยมาก

$\mu$  คือ ค่าคงที่มีผลต่ออัตราการลู่เข้า

$\sigma^2$  คือ ค่าคงที่ที่มีผลต่อเสถียรภาพและช่วงขั้น (step) ของการลู่เข้า

วิธีการปรับค่าน้ำหนักด้วยวิธีนี้คล้ายคลึงกับวิธีของ Least Mean Square ซึ่งมีอัตราการลู่เข้าค่าน้ำหนักเหมาะสมอย่างช้าๆ แต่มีเสถียรสูง บางครั้งถูกนำไปใช้ฝึกสอนโครงข่ายแทนวิธี Least Mean Square ในกรณีที่ไม่สามารถหาค่าเกรเดียนท์ได้โดยตรงเนื่องจากการเปลี่ยนแปลงค่าความผิดพลาดกำลังสองนั้นมีการเปลี่ยนแปลงน้อยมาก ดังนั้น จึงใช้หลักการสุ่มเพื่อรับทราบค่าน้ำหนัก และนำค่าน้ำหนักที่ถูกเปลี่ยนแปลงไปปรับค่าน้ำหนักโครงข่าย

Bernard Widrow and Michael A. LEHR (1960) ได้นำเสนอกฎ Madaline Rule III หรือ MR III เพื่อเป็นตัวอย่างของโครงข่ายที่มีการปรับโครงข่ายแบบไม่เป็นเชิงเด่น (Sigmoid Adaline) จะเห็นได้ว่า ไม่มีการหาค่าอนุพันธ์ของ Sigmoid Function โดยตรง แต่แทนการคำนวนค่าอนุพันธ์ด้วย การรบกวนในด (Node Perturbation) ด้วยสัญญาณค่ารบกวนน้อยมากๆ (a small perturbation signal) เวiy กว่า  $\Delta s$  โดยการบวกค่าน้อยๆ เข้ากับเอกสารพุทธเชิงเส้น ( $s_k$ ) ที่ในเอกสารพุทธเชิงเส้นมีค่าเป็น  $s_k + \Delta s$ , เอกสารพุทธโครงข่ายที่ได้มีค่าเป็น  $y_k$  และค่าความผิดพลาดของโครงข่ายมีค่าเป็น  $\xi_k$



ภาพ 6 การประมวลผลด้วยอัลกอริทึม MRIII

จากภาพ 6 สามารถคำนวณค่าเกรเดียนท์ประมาณชั่วขณะ (instantaneous estimated gradient) ได้จากการ (54)

$$\hat{v}_k = \frac{\partial(\hat{\epsilon}_k)^2}{\partial W_k} = \frac{\partial(\hat{\epsilon}_k)^2 \partial s_k}{\partial s_k \partial W_k} = \frac{\partial(\hat{\epsilon}_k)^2}{\partial s_k} X_k \quad (54)$$

เนื่องจาก ค่า  $\Delta s$  มีค่าน้อยมาก จึงทำการประมาณค่าเกรเดียนท์ชั่วขณะได้ดังสมการ (55)

$$\hat{v}_k = \frac{\Delta(\hat{\epsilon}_k)^2}{\Delta s_k} X_k \quad (55)$$

อีกวิธีหนึ่งของการประมาณค่าเกรเดียนท์ชั่วขณะ คือ การอนุพันธ์สมการ (54) ได้ดังสมการ (56)

$$\hat{v}_k = \frac{\partial(\hat{\epsilon}_k)^2}{\partial s_k} X_k = 2\hat{\epsilon}_k \frac{\partial \hat{\epsilon}_k}{\partial s_k} X_k \approx 2\hat{\epsilon}_k \frac{\Delta \hat{\epsilon}_k}{\Delta s_k} X_k \quad (56)$$

การหาค่าเกรเดียนท์ของอัลกอริทึม MRIII ที่ใช้สำหรับโครงข่ายแบบ Sigmoid Adaline โดยอาศัยพื้นฐานของ Steepest Descent จะสามารถปรับค่าน้ำหนักได้ตามสมการ (57)

$$W_{k+1} = W_k - \mu \frac{\Delta(\hat{\epsilon}_k^2)}{\Delta s} X_k \quad (57)$$

หรือ

$$W_{k+1} = W_k - 2\mu \frac{\Delta(\hat{\epsilon}_k)}{\Delta s} X_k \quad (58)$$

เมื่อพิจารณา ค่าเฉลี่ยกำลังสองของพังก์ชันซิกมอยด์ (mean square of the sigmoid) มีค่าดังสมการ (59)

$$\epsilon_k = d_k - y_k = d_k - \text{sgm}(s_k) \quad (59)$$

การเพิ่ม  $\Delta s$  เข้าไปใน Adaline ทำให้ค่า  $\epsilon_k$  กลายเป็น

$$\Delta \hat{\varepsilon}_k = -\Delta y_k \quad (60)$$

ดังนั้น สมการในการปรับค่าน้ำหนัก มีค่าเป็นไปตามสมการ (61)

$$W_{k+1} = W_k - 2\mu \frac{\Delta y_k}{\Delta s} X_k \quad (61)$$

เนื่องจากค่า  $\Delta s$  มีค่าน้อยมาก ดังนั้น อัตราการเพิ่มขึ้นของค่าน้ำหนัก อาจจะแทนด้วย ค่าที่เพิ่มขึ้นได้ด้วยการหาอนุพันธ์ของเอาท์พุตที่เปลี่ยนแปลงไป จะกลายเป็น

$$W_{k+1} = W_k - 2\mu \hat{\varepsilon}_k \frac{\partial y_k}{\partial s} X_k \quad (62)$$

$$W_{k+1} = W_k - 2\mu \hat{\varepsilon}_k \text{sgm}(s_k) X_k \quad (63)$$

อัลกอริทึมนี้จะเทียบเท่ากับวิธีของอัลกอริทึม Backpropagation of the Sigmoid Adaline ถ้าค่าการรบกวน (Perturbation)  $\Delta s$  มีค่าที่น้อยมากๆ ซึ่งทำให้อัลกอริทึมนี้มีความคงทน (Robust) แม้ว่าจะนำไปใช้งานกับเครื่องมือแบบอนาคต

Akaraphunt Vongkunghae (2005) ในเรื่องการหาค่าที่เหมาะสม (Optimization) นั้น ได้นำหลักการ การรบกวนแบบสุ่ม (random perturbation) มาประยุกต์ใช้โดยกำหนดให้ ค่าการรบกวน มีคุณลักษณะการกระจายตัวเป็นสูมแบบเกาจ์เชียน (Gaussian Distribution) รบกวนค่าน้ำหนักของโครงข่ายเพื่อค้นหาค่าเหมาะสม โดยสมการที่ใช้ปรับค่าน้ำหนัก เป็นดังนี้

$$\Delta e = e(W_n + v\Delta P) - e(W_n - v\Delta P) \quad (64)$$

$$W_{n+1} = W_n - \mu \cdot \Delta e \cdot v\Delta P \quad (65)$$

เมื่อ

$W_{n+1}$  คือ ค่าน้ำหนักที่ปรับค่าแล้ว

$W_n$  คือ ค่าน้ำหนักเดิม

$\Delta P$  คือ ค่าการรบกวน มีลักษณะการกระจายตัวเป็นสูมแบบเกาจ์เชียน และมีค่าเบี่ยงเบนมาตรฐาน เท่ากับ 1.0

- $v$  คือ เปี่ยงเปนมาตรฐานควบคุมการกระจายตัวของค่าการรวมกวน  $e(W_n + v\Delta P)$  คือ เฉลี่ยวความผิดพลาดกำลังสองของค่าน้ำหนักที่บวกค่าการบกวน  $e(W_n - v\Delta P)$  คือ เฉลี่ยวความผิดพลาดกำลังสองของค่าน้ำหนักที่ลบค่าการบกวน  $\Delta e$  คือ ผลต่างของค่าเฉลี่ยวความผิดพลาดกำลังสองระหว่างค่าน้ำหนักบวก ด้วยการค่าการรวมกวนและค่าน้ำหนักลบด้วยค่าการรวมกวน
- $\mu$  คือ ค่าอัตราการเรียนรู้

ซึ่งในวิทยานิพนธ์เรื่องนี้ ได้ใช้หลักการทางค่าหมายสมจาก Akaraphunt Vongkunghae (2005) เพื่อใช้ฝึกสอนโครงข่ายประสาทเทียมแบบป้อนผลการคำนวณไปข้างหน้าเพื่อเบรียบเทียบการทำงานกับอัลกอริทึมของ Levenberg-Marquardt backpropagation (LM), Gradient descent with adaptive learning rule backpropagation (GDA) และ Gradient descent backpropagation (GD)