

## บทที่ 2

### ขอบเขตของอัตราการเรียนรู้ในการลดระดับตามแนวเกรเดียนต์

การปรับอัตราการเรียนรู้ในข่ายงานระบบประสาท สามารถทำให้ประสิทธิภาพการเรียนรู้ดีขึ้นได้ดังที่กล่าวไว้ในความเบื้องต้นของบทที่ 1 แต่ต้องคำนึงถึงขอบเขตที่สามารถปรับได้โดยระบบไม่เสียเสถียรภาพในการเรียนรู้ ในบทนี้จึงได้กล่าวถึงลักษณะการลู่เข้าสู่ค่าเหมาะสมที่สุดของพารามิเตอร์ในระบบ การปรับค่าพารามิเตอร์ที่ใช้จะเป็นไปตามสมการ (1.5) ซึ่งอาศัยเกรเดียนต์เพื่อกำหนดค่าถัดไป

การปรับพารามิเตอร์โดยอาศัยเกรเดียนต์นี้ เรียกว่า การลดระดับตามแนวเกรเดียนต์ วิธีนี้จะกำหนดเวกเตอร์พารามิเตอร์ขึ้นใหม่เป็นลำดับเพื่อให้เข้าใกล้ค่าเหมาะสมที่สุดมากขึ้น โดยกำหนดให้ไปในทิศทางตรงข้ามเกรเดียนต์ และก้าวไปด้วยระยะเท่ากับ  $\beta/2$  ตามสมการ (1.5) ซึ่ง  $\beta$  ก็คือค่าอัตราการเรียนรู้ เป็นตัวกำหนดความยาวก้าวและเป็นตัวควบคุมลักษณะการลู่เข้า

นอกจากนี้ ยังได้กล่าวถึงบทบาทของอัตราการเรียนรู้ที่มีต่อการลดระดับตามแนวเกรเดียนต์ กรณีที่สัญญาณขาเข้ามีลักษณะเป็นกระบวนการสโตคาสติกส์ (stochastic process) ทั้งที่ทราบและไม่ทราบค่าทางสถิติของสัญญาณ ในกรณีที่ไม่ทราบค่าทางสถิติของสัญญาณจึงมีการปรับวิธีการหาค่าเกรเดียนต์เป็นวิธีเกรเดียนต์แบบสโตคาสติกส์ (Stochastic Gradient) หรือเรียกอีกอย่างว่า วิธีกำลังสองน้อยที่สุด (Least Mean Square) ซึ่งเป็นผลให้การปรับพารามิเตอร์ไม่สามารถก้าวถึงค่าเหมาะสมที่สุดได้ ความเข้าใจถึงบทบาทของอัตราการเรียนรู้นี้เป็นแนวทางสำหรับการปรับค่าให้เปลี่ยนแปลงตามเวลาอย่างเหมาะสม

เนื้อหาที่น่าสนใจกล่าวถึงในบทนี้ ได้นำมาจากหนังสือ Adaptive Filters ของ Honig M. L. และ Messerschmitt D. G. [14] โดยเลือกเนื้อหาในส่วนที่เกี่ยวข้องและนำมาเรียบเรียงและแก้ไขตามความเหมาะสม

#### 2.1 จุดเหมาะสมที่สุดของการลดระดับตามแนวเกรเดียนต์

ในหัวข้อนี้ แสดงถึงค่าเหมาะสมที่สุดของพารามิเตอร์ที่ทำการปรับโดยวิธีการลดระดับตามแนวเกรเดียนต์ (Gradient Descent) เมื่อใช้ฟังก์ชันเป้าหมายเป็นความผิดพลาดกำลังสองเฉลี่ย (mean-square error) หรือ MSE ในกรณีที่ทราบค่าทางสถิติของสัญญาณขาเข้า โดยใช้วิธี

การทางคณิตศาสตร์ เพื่อแสดงค่าเหมาะสมที่สุดที่เป็นเป้าหมายของการลดระดับตามแนวเกรเดียนต์

เมื่อกำหนดให้  $\underline{w}$  เป็นเวกเตอร์ที่มีส่วนประกอบ (component) เป็นพารามิเตอร์ของระบบ มีขนาดมิติเท่ากับ  $N$   $e(t)$  เป็นความผิดพลาดระหว่างสัญญาณอ้างอิง  $d(t)$  และสัญญาณขาออก  $o(t)$  พิจารณาข่ายงานระบบประสาทแบบชั้นเดียวที่มีลักษณะเป็นเชิงเส้น จะได้ว่า  $o(t) = \underline{w}^T \underline{x}(t)$  เมื่อ  $\underline{x}(t)$  เป็นเวกเตอร์สัญญาณขาเข้าของระบบที่มีขนาดมิติเท่ากับ  $N$  ค่าของ  $e(t)$  จะขึ้นอยู่กับ  $\underline{w}$ ,  $\underline{x}(t)$  และ  $d(t)$  ดังนี้

$$e(t) = d(t) - \underline{w}^T \underline{x}(t) \quad (2.1.1)$$

เราสามารถสร้างฟังก์ชันเป้าหมายในการหาจุดเหมาะสมที่สุดเป็นฟังก์ชันกำลังสอง (quadratic) ของ  $e(t)$  เพื่อให้มีค่ามากกว่าหรือเท่ากับศูนย์ และมีจุดเหมาะสมที่สุดเพียงจุดเดียว ซึ่งแสดงเป็นสมการได้ดังนี้

$$e^2(t) = d^2(t) - 2\underline{w}^T d(t)\underline{x}(t) + \underline{w}^T \underline{x}(t)\underline{x}^T(t)\underline{w} \quad (2.1.2)$$

ในกรณีที่สัญญาณขาเข้าของระบบมีลักษณะเป็นกระบวนการสโตคาสติกส์ เราไม่สามารถหาค่าที่แน่นอนของระบบได้ ดังนั้น เราจึงใช้ค่าทางสถิติเพื่อหาจุดเหมาะสมที่สุดแทน ซึ่งทำได้โดยใช้ค่าคาดหวัง (expectation value) ของฟังก์ชันเป้าหมายมาทำการหาจุดเหมาะสมที่สุด เราสามารถหาค่าคาดหวังของสมการ (2.1.2) ได้เป็น

$$\begin{aligned} E[e^2(t)] &= E[d^2(t)] - 2\underline{w}^T E[d(t)\underline{x}(t)] + \underline{w}^T E[\underline{x}(t)\underline{x}^T(t)]\underline{w} \\ &= E[d^2(t)] - 2\underline{w}^T \underline{p} + \underline{w}^T \Phi \underline{w} \end{aligned} \quad (2.1.3)$$

โดยที่สัญลักษณ์  $E$  แทนการหาค่าคาดหวัง สมการ (2.1.3) นี้จะเป็นฟังก์ชันกำลังสองของเวกเตอร์  $\underline{w}$  โดยเวกเตอร์  $\underline{p}$  และเมทริกซ์  $\Phi$  ถูกกำหนดขึ้นเพื่อใช้แทนค่าในสมการดังนี้

$$\underline{p} = E[d(t)\underline{x}(t)] \quad (2.1.4)$$

$$\Phi = E[\underline{x}(t)\underline{x}^T(t)] = \begin{bmatrix} \phi_{1,1} & \phi_{1,2} & \dots & \phi_{1,N} \\ \phi_{2,1} & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ \phi_{N,1} & \dots & \dots & \phi_{N,N} \end{bmatrix} \quad (2.1.5)$$

$$\phi_{ij} = E[x_i(t)x_j(t)]; \quad 1 \leq i, j \leq N \quad (2.1.6)$$

เมตริกซ์  $\Phi$  เป็นเมตริกซ์อัตโนมัติสหสัมพันธ์ (autocorrelation) ของสัญญาณขาเข้า  $\underline{x}(t)$  จึงมีคุณสมบัติเป็นเมตริกซ์สมมาตรและเป็นบวกกึ่งแน่นอน (positive semidefinite) ส่วนใหญ่เราจะกำหนดให้เมตริกซ์  $\Phi$  เป็นบวกแน่นอน (positive definite) เพื่อให้เป็นเมตริกซ์ไม่เอกฐานทำให้สามารถหาเมตริกซ์ผกผัน (inverse matrix) ได้ และมีค่าเฉพาะ (eigenvalue) เป็นจำนวนจริงบวก

สมการ (2.1.3) สามารถทำเป็นกำลังสองสมบูรณ์ ได้เป็น

$$E[e^2(t)] = E[d^2(t)] - \underline{p}^T \Phi^{-1} \underline{p} + (\Phi^{-1} \underline{p} - \underline{w})^T \Phi (\Phi^{-1} \underline{p} - \underline{w}) \quad (2.1.7)$$

เมื่อ  $\Phi$  เป็นเมตริกซ์บวกแน่นอน เทอมที่ 3 ของสมการ (2.1.7) ซึ่งเป็นเทอมกำลังสองจะมีค่ามากกว่าหรือเท่ากับศูนย์ เราสามารถหาเวกเตอร์พารามิเตอร์ที่จุดเหมาะสมที่สุด โดยกำหนดให้เทอมที่ 3 นี้เป็นศูนย์ เพราะเป็นเทอมเดียวที่มีเวกเตอร์  $\underline{w}$  เกี่ยวข้อง ดังนี้

$$(\Phi^{-1} \underline{p} - \underline{w})^T \Phi (\Phi^{-1} \underline{p} - \underline{w}) = 0$$

และหาเวกเตอร์พารามิเตอร์ที่จุดเหมาะสมที่สุด ได้เป็น

$$\underline{w}_{opt} = \Phi^{-1} \underline{p} \quad (2.1.8)$$

เมื่อเทอมที่ 3 ในสมการ (2.1.7) เป็น 0 ดังนั้น ค่าฟังก์ชันเป้าหมายที่จุดเหมาะสมที่สุด จะเป็น

$$E[e^2(t)] = E[d^2(t)] - \underline{p}^T \Phi^{-1} \underline{p} \quad (2.1.9)$$

$$= E[d^2(t)] - \underline{p}^T \underline{w}_{opt} \quad (2.1.10)$$

จากสมการ (2.1.8) ถึง (2.1.10) แสดงว่า เวกเตอร์พารามิเตอร์และฟังก์ชันเป้าหมายที่จุดเหมาะสมที่สุด สามารถหาได้เมื่อทราบเมตริกซ์อัตโนมัติ  $\Phi$  และเวกเตอร์สหสัมพันธ์ข้าม  $p$

## 2.2 หลักการความตั้งฉาก (Orthogonality Principle)

ในหัวข้อที่ 2.1 เราหาจุดเหมาะสมที่สุดได้โดยใช้ระบบสมการเชิงเส้นและเมตริกซ์ แต่เรายังสามารถใช้ในการหาอนุพันธ์ของฟังก์ชันเป้าหมายเทียบกับพารามิเตอร์เพื่อหาจุดเหมาะสมที่สุดได้เช่นกัน ผลที่ได้จะตรงกัน แต่สมการที่ได้จากการหาอนุพันธ์นี้สามารถแปลความหมายเพื่อแสดงความสัมพันธ์ระหว่างสัญญาณขาเข้า  $x(t)$  และความผิดพลาด  $e(t)$  ที่จุดเหมาะสมที่สุดได้

เราสามารถหาอนุพันธ์ของฟังก์ชันเป้าหมายเทียบกับพารามิเตอร์ และกำหนดให้เท่ากับศูนย์เพื่อหาจุดเหมาะสมที่สุดได้ดังนี้

$$0 = \frac{\partial}{\partial w_m} E[e^2(t)], \quad 1 \leq m \leq N \quad (2.2.1)$$

$$= 2E \left[ e(t) \frac{\partial}{\partial w_m} e(t) \right], \quad 1 \leq m \leq N \quad (2.2.2)$$

$$= -2E[e(t)x_m(t)], \quad 1 \leq m \leq N \quad (2.2.3)$$

สมการ (2.2.3) แสดงให้เห็นว่า ความผิดพลาดไม่มีสหสัมพันธ์ (uncorrelate) กับสัญญาณขาเข้าของระบบ เพราะค่าคาดหวังของผลคูณที่เกิดจากสัญญาณทั้งสองมีค่าเป็นศูนย์ เช่นเดียวกับลักษณะของเวกเตอร์ตั้งฉาก (orthogonal) ที่ผลคูณภายใน (inner product) มีค่าเป็นศูนย์ จึงตั้งชื่อหลักการนี้ว่า “หลักการความตั้งฉาก”

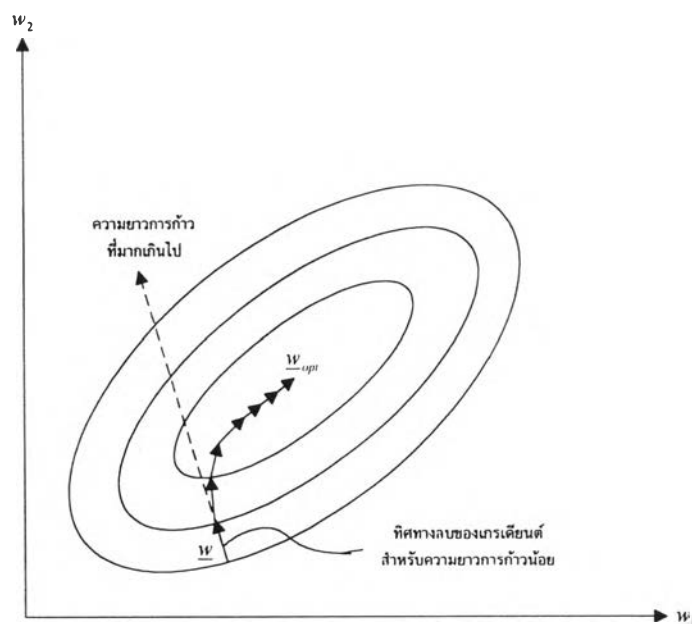
## 2.3 การหาจุดเหมาะสมที่สุดด้วยวิธีการลดระดับตามแนวเกรเดียนต์

เราสามารถหาจุดเหมาะสมที่สุดโดยใช้วิธีการทางคณิตศาสตร์ อย่างระบบสมการเชิงเส้นหรือการหาเกรเดียนต์ ในกรณีที่เราไม่สามารถหาเกรเดียนต์ของฟังก์ชันเป้าหมายหรือการคำนวณหาเมตริกซ์ผกผัน  $\Phi^{-1}$  มีความยุ่งยากซับซ้อน โดยเฉพาะในกรณีที่สัญญาณขาเข้ามีจำนวนมาก

เราสามารถใช้อัตนอนการปรับพารามิเตอร์เพื่อให้เข้าใกล้จุดเหมาะสมมากขึ้นเรื่อยๆ จนไปถึงจุดเหมาะสมที่สุดได้ ซึ่งวิธีที่ใช้กันโดยทั่วไปสำหรับการหาจุดเหมาะสมที่สุดแบบนี้ คือ การลดระดับตามแนวเกรเดียนต์

การลดระดับตามแนวเกรเดียนต์ ใช้การกำหนดเวกเตอร์พารามิเตอร์ชั้นใหม่เป็นลำดับ การกำหนดเวกเตอร์แต่ละครั้งจะเข้าใกล้จุดเหมาะสมที่สุดมากขึ้นโดยอาศัยเกรเดียนต์เพื่อกำหนดเวกเตอร์ใหม่ในทิศทางตรงข้าม เพราะว่า ฟังก์ชันเป้าหมายมีอัตราการเพิ่มสูงสุดเมื่อปรับพารามิเตอร์ไปในทิศทางของเกรเดียนต์ ดังนั้น เมื่อกำหนดเวกเตอร์ใหม่โดยให้ก้าวไปในทิศทางตรงข้ามเพียงเล็กน้อย ทำให้ฟังก์ชันเป้าหมายมีค่าลดลงและเวกเตอร์ใหม่เข้าใกล้จุดเหมาะสมที่สุดมากขึ้น

ในกรณีที่มีพารามิเตอร์ของระบบ 2 ตัวสามารถแสดงการก้าวในวิธีการลดระดับตามแนวเกรเดียนต์ได้ดังในรูปที่ 2.1 เห็นได้ว่าคอนทัวร์ (contour) ของฟังก์ชันเป้าหมายซึ่งเป็นฟังก์ชันกำลังสองเป็นรูปวงรี ส่วนลูกศรในรูปที่ 2.1 จะแสดงทิศทางที่กำหนดเวกเตอร์ใหม่ขึ้น ซึ่งต้องกำหนดความยาวก้าว (step size) ให้มีค่าน้อยพอที่จะทำให้ลู่อู่เข้าสู่จุดเหมาะสมที่สุดได้ ถ้ากำหนดให้มีค่ามากเกินไปจะทำให้ก้าวข้ามจุดเหมาะสมที่สุด



รูปที่ 2.1 การหาจุดเหมาะสมที่สุดโดยวิธีการลดระดับตามแนวเกรเดียนต์

การลระดับตามแนวเกรเดียนต์ สามารถแสดงเป็นสมการสำหรับปรับพารามิเตอร์ ได้ดังนี้

$$\underline{w}_{j+1} = \underline{w}_j - \frac{\beta}{2} \nabla_{\underline{w}_j} \{E[e^2(t)]\} \quad (2.3.1)$$

เมื่อ  $\underline{w}_{j+1}$  เป็นเวกเตอร์ที่กำหนดขึ้นใหม่จากเวกเตอร์  $\underline{w}_j$  ที่ถูกกำหนดขึ้นก่อนหน้า โดยที่  $j$  เป็นดัชนีของครั้งที่ทำการปรับ ส่วน  $\beta$  เป็นค่าคงตัวที่มีค่าเป็นบวกน้อยๆ ค่า  $\beta$  นี้เป็นความยาวก้าวซึ่งจะต้องกำหนดให้น้อยพอที่จะทำให้ลู่เข้าจุดเหมาะสมที่สุดได้

เราสามารถหาเกรเดียนต์ของฟังก์ชันเป้าหมายเทียบกับพารามิเตอร์ในสมการ (2.1.7) ได้เป็น  $2\Phi(\Phi^{-1}\underline{p} - \underline{w})$  และนำมาแทนในสมการ (2.3.1) ซึ่งจะได้สมการสำหรับปรับพารามิเตอร์เป็น

$$\underline{w}_{j+1} = \underline{w}_j + \beta(\underline{p} - \Phi\underline{w}_j) \quad (2.3.2)$$

$$= (I - \beta\Phi)\underline{w}_j + \beta\underline{p} \quad (2.3.3)$$

เมื่อ  $I$  เป็นเมตริกซ์เอกลักษณ์ (Identity matrix)

ขั้นตอนของการลระดับตามแนวเกรเดียนต์เริ่มจากกำหนดเวกเตอร์เริ่มต้น  $\underline{w}_0$  และปรับค่าเวกเตอร์พารามิเตอร์เพื่อก้าวเข้าใกล้เวกเตอร์ที่จุดเหมาะสมที่สุด  $\underline{w}_{opt}$  ดังแสดงไว้ในหัวข้อที่ 2.1 ทำให้เกิดเวกเตอร์พารามิเตอร์เป็นลำดับ เราจะพิจารณาการลู่เข้าสู่จุดเหมาะสมที่สุดของลำดับเวกเตอร์ที่เกิดขึ้นนี้ โดยกำหนด

$$\underline{q}_j = \underline{w}_j - \Phi^{-1}\underline{p} \quad (2.3.4)$$

ซึ่งเป็นเวกเตอร์ผลต่างระหว่างเวกเตอร์พารามิเตอร์ที่กำหนดขึ้นในปัจจุบันกับเวกเตอร์ที่จุดเหมาะสมที่สุด เมื่อนำค่า  $\underline{w}_{opt}$  ลบจากทั้ง 2 ข้างของสมการ (2.3.3) จะได้สมการใหม่ในรูปของเวกเตอร์  $\underline{q}_j$  ดังนี้

$$\underline{q}_{j+1} = (I - \beta\Phi)\underline{q}_j \quad (2.3.5)$$

เราสามารถหาค่า  $\underline{q}_{j+1}$  ด้วยสมการ (2.3.5) ไปเรื่อย ๆ จนอยู่ในรูปของ  $\underline{q}_0$  ซึ่งเป็นค่าเริ่มต้นของเวกเตอร์  $\underline{q}$  ซึ่งจะได้เป็น

$$\underline{q}_{j+1} = (I - \beta\Phi)^j \underline{q}_0 \quad (2.3.6)$$

ถ้าเวกเตอร์พารามิเตอร์ก้าวเข้าใกล้สู่จุดเหมาะสมที่สุด เวกเตอร์  $\underline{q}_j$  จะต้องเข้าใกล้เวกเตอร์ศูนย์  $\underline{0}$  ดังนั้น สิ่งที่ต้องพิจารณาคือ ในสมการที่ (2.3.6) เวกเตอร์  $\underline{q}_j$  สามารถลู่อเข้าใกล้เวกเตอร์ศูนย์หรือไม่?

จากสมการ (2.3.5) และ (2.3.6) เวกเตอร์  $\underline{q}_j$  จะเข้าใกล้เวกเตอร์ศูนย์หรือไม่ ขึ้นกับค่าเฉพาะ (eigenvalue) ของเมทริกซ์อัตโนมัติสหสัมพันธ์  $\Phi$  ซึ่งจะกำหนดเป็น  $\lambda_1, \lambda_2, \dots, \lambda_N$  เมื่อ  $N$  เป็นมิติ (dimension) ของเมทริกซ์  $\Phi$  ถ้าเมทริกซ์  $\Phi$  เป็นแบบบวกแน่นอนจะได้ค่าเฉพาะเป็นจำนวนจริงบวก ถ้าเป็นเมทริกซ์บวกกึ่งแน่นอนจะได้ค่าเฉพาะเป็นจำนวนจริงที่มากกว่าหรือเท่ากับศูนย์เท่านั้น ค่าเฉพาะเหล่านี้ถ้ามีค่าไม่ซ้ำกันจะได้เวกเตอร์เฉพาะ (eigenvector) จากค่าเฉพาะเหล่านี้  $N$  เวกเตอร์ กำหนดให้เป็น  $\underline{v}_1, \underline{v}_2, \dots, \underline{v}_N$  และเป็นเวกเตอร์ปกติ (normalized vector) มีขนาดเป็น 1 และตั้งฉาก (orthogonal) ซึ่งกันและกัน ทำให้ผลคูณภายในของเวกเตอร์เป็น

$$\underline{v}_i^T \underline{v}_j = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases} \quad (2.3.7)$$

เมทริกซ์  $\Phi$  สามารถเขียนในรูปผลรวมของเทอมที่มีค่าเฉพาะและเวกเตอร์เฉพาะเหล่านี้ ได้เป็น

$$\Phi = \sum_{i=1}^N \lambda_i \underline{v}_i \underline{v}_i^T \quad (2.3.8)$$

จากสมการ (2.3.8) เราสามารถเขียนค่าในวงเล็บของสมการ (2.3.6) ได้เป็น

$$(I - \beta\Phi)^j = \sum_{i=1}^N (1 - \beta\lambda_i)^j \underline{v}_i \underline{v}_i^T \quad (2.3.9)$$

พิจารณาสมการ (2.3.9) และ (2.3.6) จะเห็นว่า เวกเตอร์  $\underline{q}_j$  เกิดจากผลรวมของเทอมที่มีค่าเฉพาะทั้ง  $N$  ตัว และแต่ละเทอมจะแปรผันตาม  $(1 - \beta\lambda_j)^j$  ดังนั้น เทอมที่ลดลงได้เร็วที่สุด คือเทอมของค่าเฉพาะสูงสุด และเทอมที่ลดลงได้ช้าที่สุดจะเป็นเทอมของค่าเฉพาะต่ำสุด ความเร็วในการลู่เข้าสู่จุดเหมาะสมที่สุดจะถูกกำหนดโดยค่า  $\beta$  ถ้าค่า  $\beta$  มากจนทำให้ค่าในวงเล็บมีขนาดมากกว่า 1 เวกเตอร์  $\underline{q}_j$  จะมีค่ามากขึ้นในแต่ละครั้งที่กำหนดเวกเตอร์ใหม่ เช่นเดียวกับที่แสดงไว้ในรูปที่ 2.1 ที่ความยาวก้าวมากเกินไปทำให้ก้าวข้ามจุดเหมาะสมที่สุด และค่าฟังก์ชันเป้าหมายจะเพิ่มขึ้นได้

เราสามารถหาช่วงของค่า  $\beta$  ที่ทำให้ค่าในวงเล็บ  $(1 - \beta\lambda_j)^j$  น้อยกว่า 1 ได้โดยใช้ค่าเฉพาะมากที่สุดและน้อยที่สุด กำหนดเป็น  $\lambda_{\max}$  และ  $\lambda_{\min}$  ตามลำดับ เราสามารถตั้งสมการโดยกำหนดให้ค่าในวงเล็บมีค่าระหว่าง -1 ถึง 1 ดังนี้

$$-1 < (1 - \beta\lambda) < 1 \quad (2.3.10)$$


$$\text{หรือ} \quad 0 < \beta < \frac{2}{\lambda_{\max}} \quad (2.3.11)$$

$\lambda_{\max}$  ทำให้ได้ขอบเขตแคบที่สุด ดังนั้น ค่า  $\beta$  ที่ทำให้ผลรวมทุกเทอมในสมการ (2.3.9) ลู่เข้าสู่ศูนย์ต้องน้อยกว่า  $\frac{2}{\lambda_{\max}}$  ดังนั้น (2.3.11) จึงเป็นขอบเขตที่ทำให้ลู่เข้า เมื่อกำหนดให้  $\beta$  เป็นค่าคงตัว ก็จะมีค่าหนึ่งที่ทำให้ลู่เข้าเร็วที่สุดในช่วง 0 ถึง  $\frac{2}{\lambda_{\max}}$  การหา  $\beta$  ค่านี้ ให้พิจารณารูปที่ 2.2 ซึ่งเป็นกราฟแสดงขนาดของค่าในวงเล็บ  $|1 - \beta\lambda_j|$  เทียบกับ  $\beta$

จากรูปที่ 2.2 การเลือกค่า  $\beta = \beta_{opt}$  จะทำให้ลู่เข้าเร็วที่สุด เพราะว่าความยาวก้าวนี้ทำให้ขนาดของค่าในวงเล็บสำหรับเทอมของ  $\lambda_{\min}$  และ  $\lambda_{\max}$  ในสมการ (2.3.9) เท่ากัน ความเร็วในการลู่เข้าของทั้งสองเทอมก็จะเท่ากัน ค่า  $\beta_{opt}$  นี้หาได้จาก

$$\beta_{opt} = \frac{2}{\lambda_{\min} + \lambda_{\max}} \quad (2.3.12)$$






รูปที่ 2.2 กราฟแสดงค่า  $|1 - \beta\lambda|$  เทียบกับ  $\beta$

เมื่อแทน  $\beta_{opt}$  นี้ในวงเล็บ จะได้เป็น

$$\left( \left( \frac{\lambda_{\max}}{\lambda_{\min}} - 1 \right) / \left( \frac{\lambda_{\max}}{\lambda_{\min}} + 1 \right) \right)^2 \quad (2.3.13)$$

โดยแทนค่า  $\lambda$  ด้วย  $\lambda_{\min}$  เนื่องจากเป็นเทอมที่ลู่เข้าช้าที่สุด จึงเป็นเทอมที่กำหนดความเร็วในการลู่เข้า ในรูปที่ 2.3 แสดงกราฟของค่าในวงเล็บ  $\left( \frac{\lambda_{\max}}{\lambda_{\min}} - 1 \right) / \left( \frac{\lambda_{\max}}{\lambda_{\min}} + 1 \right)$  เทียบกับอัตราส่วน  $\frac{\lambda_{\max}}{\lambda_{\min}}$

อัตราส่วน  $\frac{\lambda_{\max}}{\lambda_{\min}}$  ถูกเรียกว่า การแผ่ออกของค่าเฉพาะ (eigenvalue spread) ซึ่งมีค่าได้ตั้งแต่ 1 ถึงไม่จำกัดและมีความสำคัญต่อความเร็วในการลู่เข้าอย่างมาก จากรูปที่ 2.3 เห็นได้ว่าเมื่อค่าอัตราส่วนนี้มากขึ้น ค่าในวงเล็บจะเข้าใกล้ 1 มากขึ้น ทำให้การลู่เข้าสู่ศูนย์ของสมการ (2.3.9) ช้าลง เมื่อการแผ่ออกของค่าเฉพาะมีค่าเป็น 1 จะทำให้ลู่เข้าเร็วที่สุด



รูปที่ 2.3 กราฟแสดงค่า  $\left(\frac{\lambda_{\max}}{\lambda_{\min}} - 1\right) / \left(\frac{\lambda_{\max}}{\lambda_{\min}} + 1\right)$  เทียบกับอัตราส่วน  $\frac{\lambda_{\max}}{\lambda_{\min}}$

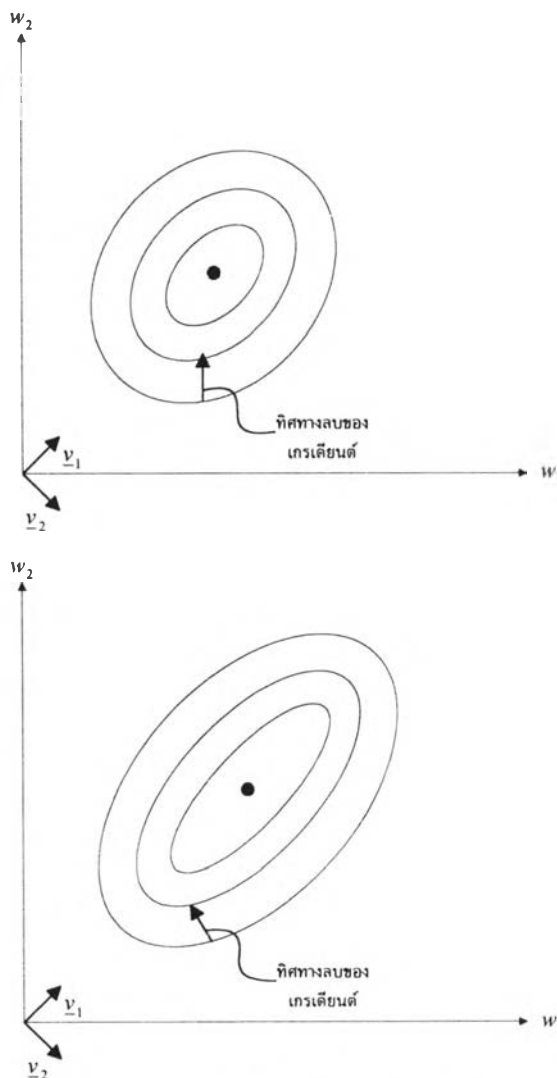
เมื่อการแผ่อกของค่าเฉพาะมากขึ้นแล้วความเร็วในการลู่เข้าจะน้อยลง สามารถพิจารณาได้จากสมการแสดงความแตกต่างระหว่างความผิดพลาดกำลังสองเฉลี่ยที่เกิดขึ้นในปัจจุบันกับค่าต่ำสุด ซึ่งแสดงเป็นสมการได้ดังนี้

$$E[e^2(t)] - E[e^2(t)]_{\min} = (\underline{w} - \underline{w}_{opt})^T \Phi(\underline{w} - \underline{w}_{opt}) \quad (2.3.14)$$

$$= \sum_{i=1}^N \lambda_i \left[ (\underline{w} - \underline{w}_{opt})^T \underline{v}_i \right]^2 \quad (2.3.15)$$

จากสมการ (2.3.15) ผลต่างของความผิดพลาดกำลังสองเฉลี่ยเท่ากับผลรวมของขนาดเวกเตอร์ผลต่าง  $\underline{w} - \underline{w}_{opt}$  ในทิศทางของเวกเตอร์เฉพาะ  $\underline{v}_i$ ;  $1 \leq i \leq N$  กำลังสอง คูณด้วยค่าเฉพาะ  $\lambda_i$ ;  $1 \leq i \leq N$  ดังนั้น ค่าเฉพาะที่ทำให้เกิดค่าผลต่างมากที่สุดคือ  $\lambda_{\max}$  และที่ทำให้ผลต่างน้อยที่สุดคือ  $\lambda_{\min}$  หมายความว่า เกิดการเปลี่ยนแปลงมากที่สุดในทิศของ  $\lambda_{\max}$  และน้อยที่สุดในทิศของ  $\lambda_{\min}$  ดังนั้น ทิศทางของเวกเตอร์เฉพาะที่เกิดจาก  $\lambda_{\max}$  จะลู่เข้าสู่จุดเหมาะสมที่สุดได้เร็วที่สุด และทิศทางของเวกเตอร์เฉพาะที่เกิดจาก  $\lambda_{\min}$  จะช้าที่สุด ความยาวก้าวสูงสุดถูก

กำหนดจาก  $\lambda_{\max}$  เพราะว่าเกรเดียนต์มีขนาดมากที่สุดทิศทางของเวกเตอร์เฉพาะของ  $\lambda_{\max}$  เมื่อความยาวก้าวมากขึ้นการเปลี่ยนแปลงในทิศของเวกเตอร์เฉพาะของ  $\lambda_{\max}$  ก็ยังมีผลมากขึ้นกว่าทิศทางอื่นๆ



รูปที่ 2.4 แสดงลักษณะของคอนทัวร์ที่มีผลต่อการเข้าสู่จุดเหมาะสมที่สุด

เมื่อพิจารณาคอนทัวร์ในกรณีที่มีพารามิเตอร์ 2 ตัว ซึ่งเป็นรูปวงรี โดยแกนหลัก (แกนที่ยาวกว่า) จะอยู่ในแนวเดียวกับเวกเตอร์เฉพาะของ  $\lambda_{\min}$  แกนรอง (แกนที่สั้นกว่า) อยู่ในแนวเดียวกับเวกเตอร์เฉพาะของ  $\lambda_{\max}$  ดังแสดงในรูปที่ 2.4 ดังนั้น การลู่เข้าสู่จุดเหมาะสมที่สุดให้เร็วควรก้าวไปในทิศทางของเวกเตอร์เฉพาะของ  $\lambda_{\max}$  มากกว่าทิศทางของเวกเตอร์เฉพาะของ  $\lambda_{\min}$  ในกรณีที่การแผ่ออกของค่าเฉพาะมีค่าสูง คอนทัวร์จะมีลักษณะเป็นวงรีมาก ถ้าค่า  $\beta$  ถูกกำหนด

จาก  $\lambda_{\max}$  การก้าวในทิศทางของแกนรองจะไม่ข้ามจุดเหมาะสมที่สุดแน่นอน และ  $\beta$  จะมีผลมากขึ้นเมื่อก้าวไปในทิศของแกนรองมากกว่าทิศของแกนหลัก เพราะว่า ทำให้ผลต่างของความผิดพลาดกำลังสองเฉลี่ยมากยิ่งขึ้น

พิจารณารูปที่ 2.4 ประกอบกับรูปที่ 2.2 ถ้าจุดเริ่มต้น  $\underline{w}_0$  อยู่บนแกนรองของคอนทัวร์ และกำหนดค่า  $\beta < 1/\lambda_{\max}$  จะทำให้ไม่ก้าวข้ามจุดเหมาะสมที่สุด แต่ครั้งที่ก้าวก็จะเข้าใกล้มากขึ้นจนกระทั่งถึงจุดเหมาะสมที่สุด ถ้าเลือก  $\beta = 1/\lambda_{\max}$  จะสามารถเข้าสู่จุดเหมาะสมที่สุดได้ในการก้าวเพียงครั้งเดียว และถ้าเลือก  $\beta > 1/\lambda_{\max}$  จะทำให้ก้าวข้ามจุดเหมาะสมที่สุดและเกิดการแกว่งไปมา แต่ถ้ายังเลือกให้  $\beta < 2/\lambda_{\max}$  ฟังก์ชันเป้าหมายจะลดลงจนถึงจุดเหมาะสมที่สุด ตัวอย่างเช่น เลือกให้  $\beta = \beta_{opt}$  ซึ่งทำให้ก้าวข้ามจุดเหมาะสมที่สุด แต่ยังสามารถเข้าสู่จุดเหมาะสมที่สุดได้เร็วกว่าการก้าวตามทิศทางของแกนหลัก ซึ่งเป็นทิศของเวกเตอร์เฉพาะจาก  $\lambda_{\min}$

#### 2.4 การหาจุดเหมาะสมที่สุดโดยใช้วิธีเกรเดียนต์แบบสโตคาสติกส์

ในหัวข้อ 2.1 ถึง 2.3 เราสามารถหาจุดเหมาะสมที่สุดของการลดระดับตามแนวเกรเดียนต์ได้ เพราะทราบค่าทางสถิติของสัญญาณขาเข้า คือเมตริกซ์อัตโนมัติสหสัมพันธ์  $\Phi$  และเวกเตอร์สหสัมพันธ์ข้าม  $\underline{p}$  แต่ค่าทั้งสองจำเป็นต้องใช้การหาค่าเฉลี่ยทั้งชุด (ensemble average) จึงจะได้ค่าที่แท้จริง ซึ่งไม่สามารถทำได้ในการใช้งานส่วนใหญ่ ดังนั้น จึงจำเป็นต้องใช้การหาค่าเฉลี่ยตามเวลา (time average) ซึ่งเป็นเพียงการประมาณแทน ในหัวข้อนี้ กล่าวถึงวิธีเกรเดียนต์แบบสโตคาสติกส์ (Stochastic Gradient) ซึ่งใช้การประมาณดังกล่าวสำหรับปรับพารามิเตอร์

การปรับให้ใช้ค่าเฉลี่ยตามเวลาแทน ถึงแม้จะทำให้สามารถใช้งานได้กว้างขวางกว่า แต่ทำให้ไม่สามารถลู่เข้าจนถึงจุดเหมาะสมที่สุดได้ และยังคงไม่สามารถใช้ในกรณีที่สัญญาณขาเข้ามีค่าทางสถิติเปลี่ยนแปลงตามเวลา (nonstationary) ได้

ในหัวข้อที่ผ่านมา เกรเดียนต์  $\nabla_{\underline{w}} \{E[e^2(t)]\}$  มีค่าเป็นไปตามสมการ

$$\nabla_{\underline{w}} \{E[e^2(t)]\} = -2E[e(t)\underline{x}(t)] \quad (2.4.1)$$

การหาค่าของเครื่องหมาย  $E$  ซึ่งเป็นค่าเฉลี่ยทั้งชุดไม่สามารถทำได้ ดังนั้น วิธีเกรเดียนต์แบบสโตคาสติกส์จึงไม่ใส่เครื่องหมายนี้ และให้เกรเดียนต์เป็นผลคูณระหว่างค่าผิดพลาด  $e(t)$  และ

สัญญาณขาเข้า  $\underline{x}(t)$  ซึ่งมีลักษณะเป็นกระบวนการสโตคาสติกส์ ดังนั้น สมการปรับพารามิเตอร์ สำหรับวิธีเกรเดียนต์แบบสโตคาสติกส์จะเป็น

$$\underline{w}(t) = \underline{w}(t-1) - \frac{\beta}{2} \nabla_{\underline{w}} [e^2(t)] \quad (2.4.2)$$

$$= \underline{w}(t-1) + \beta e(t) \underline{x}(t) \quad (2.4.3)$$

$$= [I - \beta \underline{x}(t) \underline{x}^T(t)] \underline{w}(t-1) + \beta d(t) \underline{x}(t) \quad (2.4.4)$$

นอกจากการใช้ค่าเฉลี่ยตามเวลาแทนแล้ว ข้อแตกต่างจากการลดระดับตามแนวเกรเดียนต์ปกติอีกข้อ คือ การใช้สัญญาณลักษณะของเวลา  $t$  แทนสัญญาณแสดงจำนวนครั้งที่ปรับ  $j$  เพราะว่าในวิธีนี้ การคำนวณเกิดขึ้น 1 รอบใน 1 ช่วงเวลา สัญญาณแสดงจำนวนรอบจึงสามารถแทนได้ด้วยสัญญาณของเวลาหรือจำนวนครั้งที่ทำการเก็บข้อมูลเข้ามาในระบบ และใช้สัญญาณ  $\underline{x}(t) \underline{x}^T(t)$  แทนเมตริกซ์  $\Phi$  เพราะไม่มีการหาค่าคาดหวัง และใช้  $d(t) \underline{y}(t)$  แทนเวกเตอร์  $\underline{p}$  โดยมีเหตุผลเช่นเดียวกัน

พิจารณา สมการปรับค่าพารามิเตอร์ตัวที่  $i$  ตามวิธีเกรเดียนต์แบบสโตคาสติกส์ ดังนี้

$$w_i(t) = w_i(t-1) + \beta e(t) x_i(t) \quad (2.4.5)$$

จากสมการ (2.4.5) จะเห็นว่า ค่าพารามิเตอร์ในรอบถัดไป เป็นค่าพารามิเตอร์ในรอบปัจจุบันบวกผลคูณของความยาวก้าว  $\beta$ , ค่าผิดพลาด  $e(t)$  และสัญญาณขาเข้า  $x_i(t)$  ซึ่งเป็นกระบวนการสโตคาสติกส์ ทำให้ผลคูณนี้เป็นกระบวนการสโตคาสติกส์ และเห็นได้ว่า ค่าพารามิเตอร์เป็นผลบวกสะสมตั้งแต่เริ่มต้นของผลคูณนี้ ดังนั้น พารามิเตอร์จึงเป็นกระบวนการสโตคาสติกส์เช่นกัน การพิจารณาค่าของผลคูณหรือพารามิเตอร์จึงต้องใช้ค่าเฉลี่ยมาพิจารณาแทน

ในวิธีนี้ หลักการความตั้งฉาก สามารถแปลความหมายต่างจากที่แสดงในหัวข้อที่ 2.2 ได้ ดังนี้ หลักการความตั้งฉากกล่าวว่า เมื่อถึงจุดเหมาะสมที่สุดแล้วผลคูณของค่าผิดพลาดและสัญญาณขาเข้ามีค่าเฉลี่ยเป็นศูนย์ สิ่งนี้หลักการเชิงตั้งฉากบอกทางอ้อมเมื่อยังไม่ถึงจุดเหมาะสมที่สุด คือ เครื่องหมายของค่าเฉลี่ยของผลคูณเป็นทิศทางที่จะเคลื่อนไปสู่จุดเหมาะสมที่สุด ซึ่งสามารถอธิบายได้โดยพิจารณาผลคูณระหว่างค่าผิดพลาดและสัญญาณขาเข้า  $e(t)x_i(t)$  ส่วนที่มี

ผลของค่าพารามิเตอร์ก็คือ  $-w_i(t-1)x_i^2(t)$  (แทนค่า  $e(T)$  ด้วย  $d(t) - \sum_{k=1}^N w_k(t)x_k(t)$  ในสมการที่ (2.4.5) และพิจารณาเฉพาะเทอมที่มีผลของพารามิเตอร์  $w_i(t)$ ) ถ้าพารามิเตอร์  $w_i(t-1)$  เป็นบวก เทอมนี้จะเป็นลบมากขึ้น ทำให้ค่าเฉลี่ยตามเวลาของพารามิเตอร์ของ  $w_i(t)$  น้อยกว่า  $w_i(t-1)$  และถ้าพารามิเตอร์  $w_i(t-1)$  เป็นลบ เทอมนี้ก็จะกลายเป็นบวก ค่าเฉลี่ยของ  $w_i(t)$  ก็จะมากขึ้น เพื่อให้ผลเฉลี่ยเข้าสู่ศูนย์

การศึกษาถึงการลู่เข้าที่เป็นประโยชน์อันหนึ่งคือ การสมมติให้สัญญาณขาเข้าเป็นกระบวนการสโตคาสติกส์คงที่แบบกว้าง (wide-sense stationary) โดยทราบค่าทางสถิติบางตัว (ฟังก์ชันสหสัมพันธ์ เป็นต้น) ซึ่งคาดว่าเวกเตอร์พารามิเตอร์สามารถลู่เข้าได้จากการหาค่าที่เหมาะสมโดยอาศัยค่าสถิติที่ทราบ ถึงแม้ความเร็วในการลู่เข้า (speed of convergence) ของเงื่อนไขนี้ไม่สามารถใช้ได้เมื่อค่าสถิติของสัญญาณขาเข้าเปลี่ยนแปลงตามเวลา (nonstationary) แต่ก็สามารถชี้ให้เห็นถึงประสิทธิภาพการลู่เข้าได้อย่างดี

เมื่อสัญญาณขาเข้าเป็นกระบวนการสโตคาสติกส์คงที่แบบกว้าง เราสามารถหาค่าคาดหวังของสมการ (2.4.4) ได้เป็น

$$E[\underline{w}(t)] = E[(I - \beta \underline{x}(t)\underline{x}^T(t))\underline{w}(t-1)] + \beta E[d(t)\underline{x}(t)] \quad (2.4.6)$$

$$\approx (I - \beta \Phi)E[\underline{w}(t-1)] + \beta \underline{p} \quad (2.4.7)$$

ซึ่งใช้การประมาณว่า เวกเตอร์ของพารามิเตอร์และสัญญาณขาเข้าไม่มีสหสัมพันธ์ต่อกันได้ เพราะว่า เวกเตอร์พารามิเตอร์มีการเปลี่ยนแปลงไปแบบช้าๆ ซึ่งเป็นผลจาก  $\beta$  ที่มีค่าน้อย หลังจากประมาณแล้ว สมการที่ (2.4.6) จะเหมือนกับการลดระดับตามแนวเกรเดียนต์ปกติ การลู่เข้าจะเหมือนกับที่แสดงในหัวข้อที่ 2.3 แต่ค่าของเวกเตอร์พารามิเตอร์ไม่ได้ก้าวเข้าสู่จุดเหมาะสมที่สุดจริงๆ เพียงแต่ค่าเฉลี่ยของเวกเตอร์พารามิเตอร์และค่าเฉลี่ยอื่นๆ เท่านั้นที่ไปถึงจุดเหมาะสมที่สุด ซึ่งความจริงเวกเตอร์พารามิเตอร์กระเพื่อมรอบๆ จุดเหมาะสมที่สุด เพราะว่ายังมีเทอมผลคูณในสมการ (2.4.5) ซึ่งเป็นกระบวนการสโตคาสติกส์อยู่ โดยค่า  $\beta$  ยิ่งมากก็ยิ่งทำให้ผลจากเทอมนี้มีมากขึ้น การกระเพื่อมก็จะมากขึ้น

การประมาณที่ใช้จะใกล้เคียงความจริงเมื่อ  $\beta$  มีค่าน้อย โดยปกติ จะต้องน้อยกว่าค่า  $\beta_{opt}$  ที่กล่าวไว้ในหัวข้อที่ 2.3 มาก ซึ่งเป็นผลให้ความเร็วในการลู่เข้าช้าลงด้วย การเพิ่มความ

ยาวก้าวจะสามารถเพิ่มความเร็วในการลู่เข้า แต่ว่าการกระเพื่อมที่เกิดขึ้นจะมากขึ้นตามไปด้วย ถ้าเพิ่มความยาวก้าวมากขึ้นเรื่อยๆ เมื่อเริ่มแรกจะสามารถเพิ่มความเร็วในการลู่เข้าได้ แต่ถ้าเพิ่มขึ้นอีก ความเร็วในการลู่เข้าก็จะลดลงและขาดเสถียรภาพในที่สุด ดังนั้น การเลือกความยาวก้าวให้มีค่ามากควรอยู่ในขอบเขตที่ทำให้ความเร็วในการลู่เข้าเพิ่มขึ้น

อาศัยการประมาณนี้ ขั้นตอนวิธีสามารถปรับพารามิเตอร์เพื่อให้เข้าสู่จุดเหมาะสมที่สุดได้ แต่จะมีการกระเพื่อมซึ่งเกิดขึ้นจากการใช้  $\beta$  เป็นค่าคงตัว ถ้าเปลี่ยน  $\beta$  ให้มีค่าเปลี่ยนตามเวลาจะสามารถลู่เข้าสู่จุดเหมาะสมที่สุดได้ แต่ต้องตั้งเงื่อนไขสำหรับเปลี่ยนขนาดอย่างระมัดระวัง เพราะอาจทำให้ไม่ลู่เข้าได้ ปกติ  $\beta$  ควรเริ่มมีค่ามากในตอนเริ่ม เพื่อให้สามารถลู่เข้าได้เร็ว เมื่อเข้าใกล้จึงลดขนาดลงเรื่อยๆ เพื่อให้ก้าวเข้าสู่จุดเหมาะสมที่สุดได้ นั่นคือ  $\beta$  มีค่าเข้าใกล้ศูนย์เมื่อเข้าใกล้จุดเหมาะสมที่สุด การลดค่า  $\beta$  ก่อนอาจทำให้ไม่สามารถไปถึงจุดเหมาะสมที่สุดได้เช่นกัน ดังนั้น การกำหนด  $\beta$  ให้เปลี่ยนตามเวลาเพื่อให้เข้าสู่จุดเหมาะสมที่สุด จึงควรจะเป็นไปตามสมการ

$$\sum_{i=0}^{\infty} \beta(t) = \infty \quad (2.4.8)$$

และ 
$$\sum_{i=0}^{\infty} \beta^2(t) < \infty \quad (2.4.9)$$

ถ้าสัญญาณขาเข้าเปลี่ยนแปลงตามเวลา การประมาณนี้จะไม่สามารถทราบได้ว่า สัญญาณเปลี่ยนแปลงไปเช่นไร แต่ถ้าการเปลี่ยนแปลงยังไม่เร็วนัก ขั้นตอนวิธีก็อาจสามารถปรับพารามิเตอร์ให้ลู่เข้าสู่จุดเหมาะสมที่สุดได้ แต่ถ้าการเปลี่ยนแปลงเร็ว ขั้นตอนวิธีจะไม่สามารถปรับพารามิเตอร์ได้ทัน การปรับค่า  $\beta$  ให้เปลี่ยนตามเวลาทำให้ขั้นตอนวิธีลู่เข้าสู่จุดเหมาะสมที่สุดเร็วขึ้นก็อาจช่วยแก้ไขปัญหานี้ได้ดีขึ้น

## 2.5 การลู่เข้าโดยวิธีเกรเดียนต์แบบสโตคาสติกส์

วิธีเกรเดียนต์แบบสโตคาสติกส์สามารถทำให้การประยุกต์ใช้งานกว้างขวางขึ้น เพราะว่าสามารถใช้ได้โดยไม่ต้องทราบค่าทางสถิติของสัญญาณขาเข้า แต่ก็ทำให้ค่าพารามิเตอร์กระเพื่อมรอบๆ จุดเหมาะสมที่สุดโดยไม่สามารถเข้าสู่จุดเหมาะสมที่สุดอย่างแท้จริงได้ แต่ผลจากการใช้เกรเดียนต์แบบสโตคาสติกส์แทนยังทำให้พารามิเตอร์ที่ปรับมีลักษณะเป็นกระบวนการสโตคาสติกส์ เป็นผลให้ช่วงความยาวก้าวที่ทำให้ลู่เข้าแคบลงกว่าที่เคยแสดงไว้ในหัวข้อที่ 2.3 โดย

ควมยวทวจะตงทอให้ควมแปรปรวนของพารมเตอร์ลู่เข้าดวย ในทวชอนี้ จะแสดงลักษณะการลู่เข้าของพารมเตอร์ในวธีเกรเดียนต์แบบสโตคาสติกส์ และหาช่วงของควมยวทวที่ทอให้ลู่เข้าของวธีนี้

การปรับพารมเตอร์ในวธีเกรเดียนต์แบบสโตคาสติกส์ จะเป็นไปตามสมการ

$$\underline{w}(t) = \underline{w}(t-1) + \beta e(t) \underline{x}(t) \quad (2.5.1)$$

$$= [I - \beta \underline{x}(t) \underline{x}^T(t)] \underline{w}(t-1) + \beta d(t) \underline{x}(t) \quad (2.5.2)$$

### 2.5.1 ค่ำเฉลี่ยของเวกเตอร์พารมเตอร์

เนื่องจาก ค่ำพารมเตอร์ในสมการที่ (2.5.1) และ (2.5.2) เป็นกระบวนการสโตคาสติกส์ ค่ำคาดหวังของสมการทั้งสอง จะเป็น

$$E[\underline{w}(t)] = E[\underline{w}(t-1)] + \beta E\{[d(t) - \underline{x}^T(t) \underline{w}(t-1)] \underline{x}(t)\} \quad (2.5.3)$$

$$= E[(I - \beta \underline{x}(t) \underline{x}^T(t)) \underline{w}(t-1)] + \beta E[d(t) \underline{x}(t)] \quad (2.5.4)$$

โดยปกติ การหาค่ำคาดหวังเทอมทางด้านขวามือทำได้ยาก เนื่องจากเวกเตอร์พารมเตอร์ขึ้นอยู่กบสัญญาณขาเข้า และเป็นฟังก์ชันไม่เชิงเส้นของเวกเตอร์ในอดีต แต่ถ่าตั้งสมมติฐานให้เวกเตอร์พารมเตอร์และสัญญาณขาเข้าไม่มีสหสัมพันธ์กัน โดยพิจารณาแยกกันในแต่ละรอบ ซึ่งมีเหตุผลสนับสนุนจากการกำหนดให้  $\beta$  มีค่าน้อยทอให้เวกเตอร์  $\underline{w}(t)$  ไม่กระเพื่อมห่างจากจุดเหมาะสมที่สุดมากนัก  $\beta$  ยิ่งมีค่าน้อยผลจากสัญญาณขาเข้าต่อเวกเตอร์พารมเตอร์ก็จะยิ่งน้อย การประมาณจะใกล้เคียงมากขึ้น

เมื่อใช้การประมาณแล้ว สมการ (2.5.4) จะสามารถเขียนใหม่ ได้เป็น

$$E[\underline{w}(t)] \approx (1 - \beta \Phi) E[\underline{w}(t-1)] + \beta \underline{p} \quad (2.5.5)$$



โดยกำหนดให้  $\Phi \equiv E[\underline{x}(t)\underline{x}^T(t)]$  เป็นเมตริกซ์อัตโนมัติสหสัมพันธ์ที่มีขนาดเป็น  $N \times N$  และ  $\underline{p} \equiv E[d(t)\underline{x}(t)]$  เป็นเวกเตอร์สหสัมพันธ์ข้าม (cross-correlation) ที่มีขนาดเป็น  $N \times 1$  เมตริกซ์  $\Phi$  จะเป็นเมตริกซ์สมมาตร และถ้ากำหนดให้เป็นเมตริกซ์แบบบวกแน่นอน จะสามารถแยกเป็นผลคูณเมตริกซ์ได้ดังนี้

$$\Phi = V\Lambda V^T \quad (2.5.6)$$

เมื่อ  $\Lambda$  เป็นเมตริกซ์แนวทแยงของค่าเฉพาะ แทนด้วยสัญลักษณ์ได้ดังนี้

$$\Lambda = \text{diag}[\lambda_1 \quad \lambda_2 \quad \dots \quad \lambda_N] \quad (2.5.7)$$

และ  $V$  เป็นเมตริกซ์ที่ประกอบด้วยเวกเตอร์เฉพาะ  $\underline{v}_i$  ที่ได้จากค่าเฉพาะ  $\lambda_i$  ของเมตริกซ์  $\Phi$  ที่คอลัมน์  $i$  เวกเตอร์  $\underline{v}_i$  จะมีคุณสมบัติตามที่กล่าวไว้ในสมการ (2.3.7) ซึ่งทำให้  $V^{-1} = V^T$

เราจะกำหนดเวกเตอร์ผลต่าง  $\underline{q}(t)$  และทำการแปลงให้ไปอยู่ในทิศทางของเวกเตอร์เฉพาะ เพื่อให้เทอมที่เป็นผลคูณข้าม (cross term) มีค่าเป็นศูนย์ ดังนี้

$$\underline{q}(t) \equiv \underline{w}(t) - \underline{w}_{opt} \quad (2.5.8)$$

$$\underline{\tilde{q}}(t) \equiv V^T \underline{q}(t) \quad (2.5.9)$$

โดยที่  $\underline{\tilde{q}}(t)$  เป็นเวกเตอร์ที่แปลงแล้ว เวกเตอร์สัญญาณขาเข้า  $\underline{x}(t)$  จะแปลงในลักษณะเดียวกัน ดังนี้

$$\underline{\tilde{x}}(t) = V^T \underline{x}(t) \quad (2.5.10)$$

และเวกเตอร์  $\underline{w}_{opt}$  เป็นเวกเตอร์พารามิเตอร์ที่จุดเหมาะสมที่สุด ดังแสดงในหัวข้อที่ 2.1

$$\underline{w}_{opt} = \Phi^{-1} \underline{p} \quad (2.5.11)$$

เช่นเดียวกัน ถ้าต้องการแปลงส่วนประกอบที่  $i$  ของเวกเตอร์ สามารถทำได้โดยการคูณเวกเตอร์เดิมที่มีส่วนประกอบนั้นด้วยเวกเตอร์เฉพาะ  $\underline{v}_i^T$  ทางด้านหน้า ส่วนประกอบของเวกเตอร์ที่แปลงไปแล้วจะไม่มีสหสัมพันธ์ต่อกัน ผลจากการแปลงจะได้ว่า

$$E[\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t)] = \Lambda \quad (2.5.12)$$

จากสมการ (2.5.4) คูณ  $V^T$  เข้าทางด้านซ้ายทั้งสองข้างของสมการ ได้เป็น

$$E[\underline{\tilde{q}}(t)] \approx [I - \beta\Lambda]E[\underline{\tilde{q}}(t-1)] \quad (2.5.13)$$

เนื่องจาก  $\Lambda$  เป็นเมตริกซ์แนวทแยง (diagonal matrix) สมการ (2.5.13) จะสามารถเขียนเป็นสมการของส่วนประกอบในเวกเตอร์  $\underline{\tilde{q}}(t)$  ได้ดังนี้

$$E[\tilde{q}_i(t)] \approx (1 - \beta\lambda_i)' \tilde{q}_i(0) \quad (2.5.14)$$

เมื่อ  $\tilde{q}_i(t)$  เป็นส่วนประกอบที่  $i$  ของ  $\underline{\tilde{q}}(t)$

ค่าเฉลี่ยของเวกเตอร์ผลต่าง  $E[\underline{q}(t)] = VE[\underline{\tilde{q}}(t)]$  จะลู่เข้าสู่เวกเตอร์ศูนย์ในแบบเอ็กซ์โปเนนเชียล (exponential) ตามค่าเฉพาะทั้ง  $N$  โมดคูณด้วยความยาวก้าว  $\beta$  ซึ่งจะถูกเลือกให้อยู่ระหว่าง 0 ถึง  $2/\lambda_{\max}$  โดย  $\lambda_{\max}$  เป็นค่าเฉพาะมากที่สุดของเมตริกซ์ฮัสซันท์  $\Phi$  จากสมการ (2.5.14) ค่าคงตัวทางเวลา (time constant) ที่เกิดจากค่าเฉพาะที่  $i$  (เวลาที่  $E[\tilde{q}_i(t)]$  ใช้ในการลดลงเป็น  $\frac{1}{e} \tilde{q}_i(0)$ ) จะเป็น

$$\tau_i \approx \frac{1}{\ln(1 - \beta\lambda_i)} \approx \frac{1}{\beta\lambda_i} \quad (2.5.15)$$

ดังนั้น เมื่อ  $\beta$  มีค่าน้อย สมการ (2.5.5) ซึ่งแสดงค่าเฉลี่ยของเวกเตอร์พารามิเตอร์ สามารถเขียนใหม่ได้ ดังนี้

$$E[\underline{w}(t)] \approx \underline{w}_{opt} + V(I - \beta\Lambda)' \underline{\tilde{q}}(0) \quad (2.5.16)$$

ค่าเฉลี่ยเวกเตอร์พารามิเตอร์  $E[\underline{w}(t)]$  จะลู่เข้าหาเวกเตอร์  $\underline{w}_{opt}$  ดังที่กล่าวไว้ในหัวข้อที่ 2.3 ดังนั้น ทอมที่ 2 ทางด้านขวามือของสมการ (2.5.16) จะลู่เข้าสู่ศูนย์ โดยที่  $\beta$  มีค่าน้อยและความเร็วในการลู่เข้าถูกกำหนดด้วยค่าเฉพาะน้อยที่สุด  $\lambda_{\min}$  ซึ่งทำให้เกิดค่าคงตัวทางเวลามากที่สุด

### 2.5.2 ความผิดพลาดกำลังสองเฉลี่ย

ความผิดพลาดกำลังสองเฉลี่ย สามารถเขียนในรูปของเวกเตอร์พารามิเตอร์  $\underline{w}(t)$  ได้เป็น

$$\begin{aligned} \varepsilon(t) &= E[d^2(t)] - 2\underline{w}^T(t)\underline{p} + \underline{w}^T(t)\Phi\underline{w}(t) \\ &= E[d^2(t)] - \underline{w}_{opt}^T \Phi \underline{w}_{opt} + 2\underline{w}^T(t) [\Phi \underline{w}_{opt} - \underline{p}] + \\ &\quad [\underline{w}(t) - \underline{w}_{opt}]^T \Phi [\underline{w}(t) - \underline{w}_{opt}] \end{aligned} \quad (2.5.17)$$

โดยที่ฟังก์ชัน  $\varepsilon(t)$  เป็นความผิดพลาดกำลังสองเฉลี่ย ซึ่งเป็นฟังก์ชันเป้าหมายของการหาจุดเหมาะสมที่สุด โดยสมการ (2.5.17) ใช้สมมติฐานว่า เวกเตอร์พารามิเตอร์ไม่ขึ้นกับสัญญาณขาเข้า และจากสมการ (2.5.11)  $\underline{w}_{opt} = \Phi^{-1} \underline{p}$  เราสามารถเขียนสมการ (2.5.17) ได้เป็น

$$\varepsilon(t) = \varepsilon_{\min} + \underline{q}^T(t) \Phi \underline{q}(t) \quad (2.5.18)$$

โดยที่

$$\varepsilon_{\min} = E[d^2(t)] - \underline{p}^T \Phi \underline{p} \quad (2.5.19)$$

ซึ่งเป็นความผิดพลาดกำลังสองเฉลี่ยต่ำสุด ถ้าเราหาค่าเฉลี่ยของสมการ (2.5.17) แล้วใช้การแปลงเวกเตอร์ไปอยู่ในแนวของเวกเตอร์เฉพาะในสมการ (2.5.8) และ (2.5.9) จะได้สมการความผิดพลาดกำลังสองเฉลี่ยที่เกินจากค่าต่ำสุด  $\varepsilon_{ex}(t)$  จากการปรับพารามิเตอร์เป็น

$$\varepsilon_{ex}(t) = E[\underline{\tilde{q}}(t) \Lambda \underline{\tilde{q}}(t)] = \sum_{k=1}^N \lambda_k E[\tilde{q}_k^2(t)] \quad (2.5.20)$$

ถ้าไม่หาค่าคาดหวังทางด้านขวา สมการจะเหมือนในหัวข้อที่ 2.3 ซึ่งเป็นความผิดพลาดกำลังสองเฉลี่ยของการลระดับตามแนวเกรเดียนต์ตามปกติ แต่ในกรณีของวิธีเกรเดียนต์แบบสโตคาสติกส์ เราต้องหาค่าเฉลี่ยทั้งชุดของพารามิเตอร์ สำหรับการหาค่า  $\varepsilon_{ex}(t)$  ในรูปของค่าสถิติอันดับสองของสัญญาณขาเข้า เราจะกำหนดเมตริกซ์ความแปรปรวนของเวกเตอร์ผลต่างซึ่งได้แปลงไปอยู่ในแนวของเวกเตอร์เฉพาะแล้ว ดังนี้

$$Q(t) \equiv E[\underline{\tilde{q}}(t)\underline{\tilde{q}}^T(t)] \quad (2.5.21)$$

โดยใช้นิยามนี้ สมการ (2.5.20) สามารถเขียนใหม่ได้เป็น

$$\varepsilon_{ex} = \text{trace}\{\Lambda Q(t)\} \quad (2.5.22)$$

การแปลงสมการให้อยู่ในรูปของ  $Q(t)$  เราจะใช้เวกเตอร์พารามิเตอร์ที่จุดเหมาะสมที่สุด  $\underline{w}_{opt}$  ลบจากสองข้างของสมการ (2.5.2) และแปลงเวกเตอร์ของสมการ (2.5.8) ถึง (2.5.10) ให้อยู่ในแนวเวกเตอร์เฉพาะ ได้เป็น

$$\begin{aligned} \underline{\tilde{q}}(t) &= \underline{\tilde{q}}(t-1) + \beta e(t)\underline{\tilde{x}}(t) \\ &= [I - \beta(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))]\underline{\tilde{q}}(t-1) + \beta e_{opt}(t)\underline{\tilde{x}}(t) \end{aligned} \quad (2.5.23)$$

โดยที่ความผิดพลาดที่เกิดจากเวกเตอร์พารามิเตอร์ที่จุดเหมาะสมที่สุด  $e_{opt}(t)$  เป็น

$$e_{opt}(t) \equiv d(t) - \underline{w}_{opt}^T \underline{x}(t) \quad (2.5.24)$$

แล้วทำการแปลงสมการ (2.5.23) เพื่อให้อยู่ในรูปของเมตริกซ์ความแปรปรวนของเวกเตอร์ผลต่าง  $Q(t) = \left[ \underline{w}(t) - \underline{w}_{opt} \right] \left[ \underline{w}(t) - \underline{w}_{opt} \right]^T$  ซึ่งจะได้เป็น

$$\begin{aligned} \underline{\tilde{q}}(t)\underline{\tilde{q}}^T(t) &= [I - \beta(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))]\underline{\tilde{q}}(t-1)\underline{\tilde{q}}^T(t-1)[I - \beta(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))] \\ &\quad + 2\beta[I - \beta(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))](\underline{\tilde{q}}(t-1)\underline{\tilde{x}}^T(t))e_{opt}(t) + \beta^2 e_{opt}^2(t)(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t)) \end{aligned} \quad (2.5.25)$$

สมการนี้จะต้องหาค่าคาดหวังเพื่อให้อยู่ในรูปของเมตริกซ์ความแปรปรวนของเวกเตอร์ผลต่าง  $Q(t)$  และต้องใช้การประมาณค่าหลายอย่างเพื่อให้ได้ผลลัพธ์ของการเฉลี่ยนี้ เมื่อใช้สมมติฐานว่า เวกเตอร์พารามิเตอร์และสัญญาณขาเข้าไม่มีสหสัมพันธ์กัน จะได้ค่าประมาณของเทอมแรกด้านขวามือในสมการ (2.5.25) เป็น

$$E\left\{\left(I - \beta(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))\right)\underline{\tilde{q}}(t-1)\underline{\tilde{q}}^T(t-1)\left(I - (\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))\right)\right\} \\ \approx Q(t-1)(I - 2\beta\Lambda) + \beta^2 E\left[(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))Q(t-1)(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))\right] \quad (2.5.26)$$

โดยที่  $\tilde{x}_i(t)$  เป็นส่วนประกอบที่  $i$  ของเวกเตอร์  $\underline{\tilde{x}}(t)$  และ  $\tilde{q}_i(t)$  เป็นส่วนประกอบที่  $i$  ของเวกเตอร์  $\underline{\tilde{q}}(t)$  ค่าประมาณที่  $l, m$  ของเมตริกซ์  $\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t)$  ในเทอมสุดท้ายของสมการ (2.5.26) เป็น

$$\begin{aligned} & \left\{ E\left[(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))Q(t-1)(\underline{\tilde{x}}(t)\underline{\tilde{x}}^T(t))\right] \right\}_{l,m} \\ &= E\left([\tilde{x}_l \underline{\tilde{x}}^T(t)]Q[\tilde{x}_m \underline{\tilde{x}}(t)]\right) \\ &= \sum_{k=1}^N \sum_{i=1}^N E[\tilde{q}_k \tilde{q}_i] E[\tilde{x}_l \tilde{x}_k \tilde{x}_i \tilde{x}_m] \\ &\approx \sum_{i=1}^N E[\tilde{q}_i^2] E[\tilde{x}_l^2] E[\tilde{x}_i^2] \delta_{lm} \\ &= \sum_{i=1}^N E[\tilde{q}_i^2] \lambda_l \lambda_i \delta_{lm} \\ &= \delta_{lm} \lambda_l \text{trace}[\Lambda Q(t-1)] \end{aligned} \quad (2.5.27)$$

$$\text{เมื่อ } \delta_{lm} = \begin{cases} 1; & x_l = x_i, x_m; \lambda_l = \lambda_i, \lambda_m \\ 0; & \text{others} \end{cases} \quad 1 \leq i \leq N$$

ค่าสถิติอันดับสี่ของเทอมสุดท้ายในสมการ (2.5.26) จะถูกประมาณด้วยค่าสถิติอันดับสองเมตริกซ์ที่ได้ในสมการ (2.5.27) เป็นเมตริกซ์แนวทแยง ซึ่งค่าที่อยู่นอกแนวทแยงถูกประมาณเป็นศูนย์ เพราะว่ามีสหสัมพันธ์ระหว่างคู่ส่วนประกอบของเวกเตอร์ผลต่างที่ถูกแปลงแล้วคือ  $\tilde{q}_k$  และ  $\tilde{q}_i$  มีค่าน้อยมาก เช่นเดียวกับ ค่านอกแนวทแยงของเมตริกซ์ค่าสถิติอันดับสี่ของสัญญาณขาเข้า  $\tilde{x}_i, 1 \leq i \leq N$  ที่ไม่มีสหสัมพันธ์กัน

การหาเทอมที่ 2 ทางด้านขวามือของสมการ (2.5.25) ทำได้โดยใช้สมมติฐานว่า เวกเตอร์พารามิเตอร์ไม่ขึ้นกับสัญญาณขาเข้าเช่นกัน ซึ่งได้เป็น

$$\begin{aligned} & E\left\{2\beta(I - \beta(\tilde{\underline{x}}(t)\tilde{\underline{x}}^T(t)))\left[\tilde{q}(t-1)\tilde{\underline{x}}^T(t)\right]e_{opt}(t)\right\} \\ & \approx 2\beta E\left[\tilde{q}(t-1)\right]\left\{E\left[e_{opt}(t)\tilde{\underline{x}}^T(t)\right] - \beta E\left[\tilde{\underline{x}}^T(t)\right] - \beta E\left[\tilde{\underline{x}}^T(t)\tilde{\underline{x}}(t)\right]e_{opt}(t)\tilde{\underline{x}}^T(t)\right\} \end{aligned} \quad (2.5.28)$$

เนื่องจาก  $E[\underline{w}(t)]$  ลู่เข้าหา  $\underline{w}_{opt}$  และเป็นไปตามสมการ (2.5.7) และ (2.5.8) ดังนั้นค่า  $E[\tilde{q}(t-1)]$  จะลู่เข้าหาเวกเตอร์ศูนย์ หรือมีค่าน้อยมากเมื่อ  $t$  มีค่ามาก และหลักการเชิงตั้งฉากได้แสดงว่า

$$E\left[e_{opt}(t)\tilde{\underline{x}}(t)\right] = \underline{0} \quad (2.5.29)$$

ดังนั้น เทอมที่แสดงในสมการ (2.5.28) ควรจะมีค่าน้อยมากเมื่อเทียบกับเทอมที่แสดงในสมการ (2.5.27) จึงประมาณเทอมนี้เป็นศูนย์ ส่วนเทอมสุดท้ายในสมการ (2.5.25) จะมีค่าเป็น

$$E\left[\beta^2 e_{opt}^2(t)\tilde{\underline{x}}(t)\tilde{\underline{x}}^T(t)\right] \approx \beta^2 \varepsilon_{\min} \Lambda \quad (2.5.30)$$

ซึ่งเป็นการประมาณเนื่องจากการใช้สมมติฐานว่าเวกเตอร์พารามิเตอร์และสัญญาณขาเข้าไม่มีสหสัมพันธ์กัน

เมื่อรวมทุกเทอมในสมการ (2.5.27) ถึง (2.5.30) จะได้เป็น

$$\underline{Q}(t) \approx \underline{Q}(t-1)(I - 2\beta\Lambda) + \beta^2 \Lambda \text{trace}[\Lambda \underline{Q}(t-1)] + \beta^2 \varepsilon_{\min} \Lambda \quad (2.5.31)$$

เมตริกซ์  $\underline{Q}(t)$  ในสมการ (2.5.31) เป็นเมตริกซ์แนวทแยง และค่านอกแนวทแยงเป็นศูนย์ เราสามารถกำหนดเวกเตอร์  $\underline{s}(t)$  ซึ่งมีส่วนประกอบที่  $i$  เป็น  $E[\tilde{q}_i^2(t)]$  (ความแปรปรวนของผลต่างพารามิเตอร์จากจุดเหมาะสมที่สุด) ในสมการ (2.5.34) ได้เป็น

$$\underline{s}(t) \approx A\underline{s}(t-1) + \beta^2 \varepsilon_{\min} \underline{\lambda} \quad (2.5.32)$$

เมื่อ  $\underline{\lambda}$  เป็นเวกเตอร์ค่าเฉพาะที่มีขนาดเท่ากับ  $N$  ส่วนค่าในเมตริกซ์  $A$  ซึ่งมีขนาด  $N \times N$  จะมีองค์ประกอบ (element) ที่  $l, m$  เป็น

$$A_{lm} = (1 - 2\beta\lambda_l)\delta_{lm} + \beta^2 \lambda_l \lambda_m \quad (2.5.33)$$

โดย  $\delta_{lm}$  มีค่าเป็น 1 เมื่อค่าเฉพาะ  $\lambda = \lambda_l, \lambda_m$  ถ้าไม่ใช่จะมีค่าเป็น 0 เราสามารถเขียน  $A$  ในรูปสมการของเมตริกซ์ได้เป็น

$$A = \beta^2 \underline{\lambda}\underline{\lambda}^T + (I - 2\beta\Lambda) \quad (2.5.34)$$

สมการ (2.5.20) ได้แสดงความสัมพันธ์ระหว่างความผิดพลาดที่มากเกินไปจากค่าต่ำสุด ( $\varepsilon_{ex}$ ) และเวกเตอร์  $\underline{s}(t)$  ส่วนสมการ (2.5.32) แสดงลักษณะพลวัตของเวกเตอร์  $\underline{s}(T)$  ซึ่งขึ้นอยู่กับค่าเฉพาะของเมตริกซ์  $A$  โดยใช้สัญลัษณ์  $\mu_i, 1 \leq i \leq N$  แทน เนื่องจาก  $A$  เป็นเมตริกซ์สมมาตร และ  $\beta$  มีค่าน้อยพอที่จะทำให้องค์ประกอบที่อยู่ใน  $A$  มีค่าเป็นบวก ดังนั้น  $A$  จะสามารถแยกเป็นผลคูณเมตริกซ์ได้ในแบบเดียวกับเมตริกซ์ออสทิสสัมพันธ์  $\Phi$  ดังนี้

$$A = U M U^T \quad (2.5.35)$$

เมื่อ  $M$  เป็นเมตริกซ์แนวทแยงสำหรับค่าเฉพาะ  $\mu_i; 1 \leq i \leq N$  ของ  $A$  และคอลัมน์ที่  $i$  ของ  $U$  เป็นเวกเตอร์ตั้งฉากปกติ (orthonormal vector)  $\underline{u}_i; 1 \leq i \leq N$  ที่ได้จากค่าเฉพาะ  $\mu_i$  และทำการแปลงเวกเตอร์  $\underline{s}(t)$  ให้ไปอยู่ในแนวเวกเตอร์เฉพาะ  $\underline{u}_i; 1 \leq i \leq N$  ดังนี้

$$\underline{\tilde{s}}(t) \equiv U^T \underline{s}(t)$$

และใช้แทนเวกเตอร์  $\underline{s}(T)$  ในสมการ (2.5.32) เพื่อให้เทอมคูณกันระหว่างส่วนประกอบมีค่าเป็นศูนย์ จะได้สมการเป็น

$$\underline{\tilde{s}}(t) = M \underline{\tilde{s}}(t-1) + \beta^2 \varepsilon_{\min} U^T \underline{\lambda} \quad (2.5.36)$$

สมการ (2.5.36) นี้ (ได้แสดงไว้แตกต่างจากต้นฉบับ) สามารถแปลความหมายได้เช่นเดียวกับสมการค่าเฉลี่ยของเวกเตอร์ผลต่างในสมการ (2.5.13) คือ ในการก้าวแต่ละครั้ง ส่วน

ประกอบของ  $\underline{s}(t)$  จะถูกปรับไปในทิศทางของเวกเตอร์เฉพาะ  $\underline{u}_i$  ของ  $A$  ขนาดที่ถูกปรับในแต่ละทิศทางหาได้จากค่าเฉพาะ  $\mu_i$  ของเวกเตอร์เฉพาะนั้น และความผิดพลาดกำลังสองเฉลี่ยที่ได้จากสมการ (2.5.20) และ (2.5.32) จะลดลงตามผลรวมถ่วงน้ำหนัก (weighted sum) ของส่วนประกอบในเวกเตอร์  $\underline{s}$

เนื่องจากเมตริกซ์  $A$  มีองค์ประกอบเป็นจำนวนจริงและเป็นเมตริกซ์สมมาตร ค่าเฉพาะของ  $A$  จึงเป็นจำนวนจริง ค่าตอบของสมการ (2.5.36) หรือสมการ (2.5.35) (ที่ยังไม่แปลงเวกเตอร์) จะลู่เข้า ก็ต่อเมื่อ  $|\mu_i| < 1$ ;  $1 \leq i \leq N$  และเนื่องจากค่าเฉพาะ  $\mu_i$  ขึ้นกับความยาวก้าว  $\beta$  ดังนั้น ค่า  $\beta$  ที่ทำให้ความแปรปรวนของพารามิเตอร์ลู่เข้า ก็คือค่าที่ทำให้ทุกค่าเฉพาะของ  $A$  น้อยกว่า 1 นั่นเอง ซึ่งความผิดพลาดกำลังสองเฉลี่ยในสมการ (2.5.20) จะลู่เข้าด้วย ลองพิจารณาผลบวกขององค์ประกอบในแถวที่  $l$  ของ  $A$  ซึ่งจะได้เป็น (แสดงไว้แตกต่างจากต้นฉบับ)

$$\sum_{m=1}^N [(1 - 2\beta\lambda_l) + \beta^2 \lambda_l \lambda_m] = 1 - \beta\lambda_l \left( 2 - \beta \sum_{m=1}^N \lambda_m \right) \quad (2.5.37)$$

ผลบวกนี้จะมีค่าน้อยกว่า 1 เมื่อ

$$0 < \beta < \frac{2}{\sum_{m=1}^N \lambda_m} = \frac{2}{N\phi_0} \quad (2.5.38)$$

โดยที่  $\phi_0 = \lambda_{av}$  เป็นค่าเฉลี่ยของค่าเฉพาะในเมตริกซ์  $A$  เงื่อนไขนี้จะทำให้องค์ประกอบของเมตริกซ์  $A$  ตามสมการ (2.5.34) เป็นบวกทั้งหมด เมตริกซ์ที่มีองค์ประกอบเป็นบวกทั้งหมดและผลรวมของแต่ละแถวน้อยกว่า 1 จะมีค่าเฉพาะที่มีขนาดน้อยกว่า 1 ดังนั้น เงื่อนไขในสมการ (2.5.38) เป็นขอบเขตของค่า  $\beta$  ที่ทำให้ความแปรปรวนของพารามิเตอร์ลู่เข้า และเงื่อนไขนี้จะจำกัดและถูกต้องกว่าในสมการ (2.3.11) ซึ่งเป็นขอบเขตสำหรับการลู่เข้าของค่าเฉลี่ยของเวกเตอร์พารามิเตอร์ เหตุผลที่ทำให้สมการ (2.5.38) จำกัดกว่าสมการ (2.3.11) เพราะในสมการ (2.3.11) ไม่ได้คิดถึงค่าความแปรปรวนของพารามิเตอร์ด้วย จากสมการ (2.5.38) และ (2.3.11) ยังทำให้รู้ว่า มีค่า  $\beta$  ช่วงหนึ่งที่ทำให้ค่าเฉลี่ยของพารามิเตอร์ลู่เข้าแต่ค่าความแปรปรวนไม่ลู่เข้า



### 2.5.3 ค่าลู่เข้าของความผิดพลาดกำลังสองเฉลี่ยและความแปรปรวนของพารามิเตอร์

เมื่อแสดงลักษณะของความผิดพลาดกำลังสองเฉลี่ยในรูปฟังก์ชันของเวลาแล้ว การคำนวณค่าลู่เข้าของความแปรปรวนพารามิเตอร์ และความผิดพลาดกำลังสองเฉลี่ย ทำได้โดยแทนเมตริกซ์  $A$  ในสมการ (2.5.34) ลงในสมการ (2.5.32) และใช้ค่า  $\varepsilon_{ex}$  จากสมการ (2.5.20) จะได้

$$\underline{s}(t) \approx (I - 2\beta\Lambda)\underline{s}(t-1) + \beta^2[\varepsilon_{ex}(t) + \varepsilon_{\min}]\underline{\lambda} \quad (2.5.39)$$

ถ้าค่า  $\beta$  ที่เลือกเป็นไปตามเงื่อนไขในสมการ (2.5.38) แล้วค่า  $\lim_{t \rightarrow \infty} \underline{s}(t) = \lim_{t \rightarrow \infty} \underline{s}(t-1)$  ถ้าหาลิมิต (limit) ทั้งสองข้างของสมการ (2.5.39) โดยให้  $t \rightarrow \infty$  จะได้เป็น

$$\lim_{t \rightarrow \infty} 2\beta\Lambda \underline{s}(t) \approx \beta^2 \left[ \lim_{t \rightarrow \infty} \varepsilon_{ex}(t) + \varepsilon_{\min} \right] \underline{\lambda} \quad (2.5.40)$$

หรือ

$$\lim_{t \rightarrow \infty} \underline{s}(t) = \frac{\beta}{2} \mathbf{1} \left[ \lim_{t \rightarrow \infty} \varepsilon_{ex}(t) + \varepsilon_{\min} \right] \quad (2.5.41)$$

เมื่อ  $\mathbf{1}$  เป็นเวกเตอร์ที่มีส่วนประกอบทุกตัวเป็น 1 เมื่อคูณสมการ (2.5.41) ทางด้านหน้าด้วย  $\underline{\lambda}^T$  จะได้

$$\lim_{t \rightarrow \infty} \varepsilon_{ex}(t) = \frac{\beta}{2} \left( \sum_{j=1}^N \lambda_j \right) \left[ \lim_{t \rightarrow \infty} \varepsilon_{ex}(t) + \varepsilon_{\min} \right] \quad (2.5.42)$$

แทน  $N\phi_0$  ด้วย  $\sum_{j=1}^N \lambda_j$  และแก้สมการหาค่า  $\varepsilon_{ex}(\infty)$  จะได้สมการแสดงค่าลู่เข้าของความผิดพลาดกำลังสองเฉลี่ยที่เกินจากค่าต่ำสุด ซึ่งเกิดจากการปรับค่าพารามิเตอร์เป็น

$$\lim_{t \rightarrow \infty} \varepsilon_{ex}(t) = \frac{\beta \varepsilon_{\min} N \phi_0}{2 - \beta N \phi_0} \quad (2.5.43)$$

และแทนสมการ (2.5.43) ในสมการ (2.5.41) จะได้สมการแสดงค่าลู่เข้าของความแปรปรวนของพารามิเตอร์ เป็น

$$\lim_{t \rightarrow \infty} E[\tilde{q}_t^2(t)] = \frac{\beta \varepsilon_{\min}}{2 - \beta N \phi_0} \quad (2.5.44)$$

สมการ (2.5.15) และ (2.5.44) แสดงให้เห็นว่า เมื่อค่า  $\beta$  มีค่ามากขึ้น เวลาที่ใช้ในการลู่เข้าของระบบจะลดลง แต่ค่าของความผิดพลาดกำลังสองเฉลี่ยและความแปรปรวนของพารามิเตอร์จะเพิ่มขึ้น ในกรณีของสัญญาณขาเข้ามีค่าสถิติไม่เปลี่ยนแปลงตามเวลา (stationary) จะต้องกำหนดให้ค่า  $\beta$  มีค่ามากในตอนเริ่มต้นเพื่อให้ลู่เข้าได้เร็วและลดลงในเวลาต่อมาเพื่อให้ความผิดพลาดกำลังสองเฉลี่ยต่ำสุด ส่วนกรณีที่สัญญาณขาเข้ามีการเปลี่ยนแปลงตามเวลา (nonstationary) ต้องให้ความยาวก้าวในตอนเริ่มต้นมีค่ามากทำให้สามารถลดความผิดพลาดกำลังสองเฉลี่ยได้เร็ว และลดค่าความยาวลงตามลำดับเพื่อให้ขั้นตอนวิธีติดตามการเปลี่ยนแปลงที่น้อยลงและทำให้การกระเพื่อมน้อยลงด้วย

## 2.6 สรุป

ในบทนี้ ได้กล่าวถึงรายละเอียดของการลดระดับตามแนวเกรเดียนต์ เพื่อหาขอบเขตของความยาวก้าว ในกรณีที่สัญญาณขาเข้ามีลักษณะเป็นกระบวนการสโตคาสติกส์โดยใช้ความผิดพลาดกำลังสองเฉลี่ยเป็นฟังก์ชันเป้าหมาย ในกรณีที่ไม่ทราบค่าทางสถิติของสัญญาณขาเข้า การหาจุดเหมาะสมที่สุดจะใช้วิธีเกรเดียนต์แบบสโตคาสติกส์ เป็นผลให้พารามิเตอร์ที่ถูกปรับในระบบมีลักษณะเป็นกระบวนการสโตคาสติกส์ ค่าพารามิเตอร์จะไม่สามารถก้าวเข้าสู่จุดเหมาะสมที่สุดเมื่อใช้ความยาวก้าวเป็นค่าคงตัว แต่จะเกิดการกระเพื่อมรอบจุดเหมาะสมที่สุด การกระเพื่อมนี้เกิดขึ้นมากน้อยตามค่าความยาวก้าวที่ใช้ และผลของการใช้วิธีเกรเดียนต์แบบสโตคาสติกส์ยังทำให้ขอบเขตของความยาวก้าวแคบลง ขอบเขตซึ่งปกติถูกกำหนดด้วยค่าเฉพาะสูงสุดของเมตริกซ์อัตสหสัมพันธ์ของสัญญาณขาเข้า จะถูกจำกัดด้วยผลรวมของค่าเฉพาะทุกค่า ซึ่งความยาวก้าวที่อยู่ระหว่างช่วงทั้งสองนี้ ทำให้ค่าเฉลี่ยพารามิเตอร์ลู่เข้าแต่ความแปรปรวนไม่ลู่เข้า

สำหรับบทต่อไป จะกล่าวถึงขั้นตอนการปรับอัตราการเรียนรู้ที่ได้นำมาทดสอบในวิทยานิพนธ์ฉบับนี้ ค่าอัตราการเรียนรู้ของข่ายงานระบบประสาทจะถูกใช้เป็นความยาวก้าวในการปรับพารามิเตอร์ของระบบ ดังนั้น เนื้อหาที่กล่าวถึงในบทนี้ จึงสามารถนำไปใช้พิจารณาหรือวิเคราะห์อัตราการเรียนรู้สำหรับการประยุกต์ใช้งานต่าง ๆ ได้