

บทที่ 2


หลักการ ทฤษฎีและขั้นตอนวิธีการที่เกี่ยวข้อง

ในบทนี้กล่าวถึงหลักการ ทฤษฎี และขั้นตอนวิธีการสำคัญที่อ้างอิงถึง และนำมาประยุกต์ใช้กับระบบการรู้จำผู้พูดในส่วนของกระบวนการแบ่งผู้พูดแบบขึ้นกับบทคำพูด สามารถแบ่งได้เป็นสี่หัวข้อใหญ่ๆ คือการประมวลผลสัญญาณเบื้องต้น การสกัดลักษณะสำคัญ ขั้นตอนวิธีการฝึกฝนชุดรหัส การควอนไทซ์แบบเวกเตอร์ และแบบจำลองฮิดเดนมาร์คอฟแบบดิสครีต

2.1 การประมวลผลสัญญาณเบื้องต้น (Signal Preprocessing)

การประมวลผลสัญญาณเบื้องต้นเป็นขั้นตอนในการจัดเตรียมสัญญาณเสียงพูด (Speech Signal) ที่ได้จากการบันทึกเสียง นำมาผ่านกรรมวิธีสัญญาณดิจิทัลได้เป็นข้อมูลเสียงพูด (Speech Data) เพื่อนำไปใช้กับการประมวลผลของขั้นตอนต่อไป เนื่องจากสัญญาณเสียงพูดมีค่าทางสถิติเปลี่ยนแปลงตามเวลา (Nonstationary) ทำให้ไม่สามารถจำลองสัญญาณเสียงพูดเป็นค่าทางสถิติได้ ดังนั้นในการประยุกต์ใช้สัญญาณเสียงพูดกับกรรมวิธีสัญญาณดิจิทัล จำเป็นต้องแบ่งสัญญาณเสียงพูดออกเป็นส่วนย่อย (Frame) โดยแต่ละส่วนย่อยจะมีความยาวประมาณ 10 ถึง 40 มิลลิวินาที ทำให้สัญญาณเสียงพูดในส่วนย่อยมีคุณสมบัติเปลี่ยนแปลงตามเวลาน้อยมากหรือไม่มีเลย จึงนิยามให้ส่วนย่อยนี้เป็นสัญญาณที่มีค่าทางสถิติไม่แปรเปลี่ยนตามเวลา (Stationary) ทำให้สามารถนำส่วนย่อยนี้มาคำนวณหาค่าทางสถิติเพื่อใช้แทนสัญญาณเสียงพูดได้ (Rabiner and Levinson, 1981; Furui, 1989)

ขั้นตอนในการประมวลผลสัญญาณเบื้องต้นสามารถแบ่งได้เป็น 2 ขั้นตอน คือ ขั้นตอนกรรมวิธีการเน้นล่วงหน้า (Preemphasis) ขั้นตอนกรรมวิธีการวางกรอบขนาดสัญญาณ (Smoothing Window) ดังแสดงในรูปที่ 2.1



รูปที่ 2.1 ขั้นตอนการประมวลผลสัญญาณเบื้องต้น

2.1.1 ขั้นตอนกรรมวิธีการเน้นล่วงหน้า (Preemphasis)

ขั้นตอนกรรมวิธีการเน้นล่วงหน้าเป็นการบีบอัดสัญญาณเสียงพูดในช่วงพิสัยพลวัต (Dynamic Range) มีผลทำให้อัตราส่วนสัญญาณต่อสัญญาณรบกวน (Signal to Noise Ratio) มีค่าสูงขึ้น โดยนำสัญญาณเสียงพูดผ่านวงจรกรองดิจิทัลอันดับที่หนึ่ง (First-Order Digital Filter) ที่มีฟังก์ชันถ่ายโอนดังแสดงในสมการที่ (2.1) และสมการผลต่างแสดงอยู่ในสมการที่ (2.2) (Furui, 1985)

$$H(z) = 1 - az^{-1} \quad (2.1)$$

$$\tilde{s}(n) = s(n) - as(n-1) \quad (2.2)$$

เมื่อ a เป็นค่าสัมประสิทธิ์ของวงจรกรองจะนิยมกำหนดให้เท่ากับ 0.95 (Rabiner and Juang, 1993)

$\tilde{s}(n)$ เป็นค่าของสัญญาณเสียงพูดขาออกที่ผ่านการมวีสู่ส่วนหน้าที่ n

$s(n)$ เป็นค่าของสัญญาณเสียงพูดขาเข้าที่ n

และ $s(n-1)$ เป็นค่าของสัญญาณเสียงพูดขาเข้าที่ $n-1$

2.1.2 ขั้นตอนการมวีสู่การวางกรอบขนาดสัญญาณ (Smoothing Window)

ขั้นตอนนี้เป็นการแบ่งสัญญาณเสียงพูดเป็นส่วนย่อยๆ โดยการคูณแต่ละค่าของสัญญาณเสียงพูดที่อยู่ในกรอบสัญญาณเสียงพูดที่กำหนดไว้ด้วยค่าฟังก์ชันกรอบ (Window Function) ในงานวิจัยได้เลือกใช้ฟังก์ชันกรอบชนิด Hamming Window ดังแสดงในรูปที่ 2.2 มีผลทำให้เกิดการลดทอนแอมพลิจูดอย่างช้าๆ ที่บริเวณปลายแต่ละข้างของกรอบสัญญาณเสียงพูด เพื่อป้องกันการเปลี่ยนแปลงที่ไม่ต่อเนื่องที่บริเวณปลายของส่วนย่อยๆ สัญญาณเสียงพูดที่ผ่านขั้นตอนนี้จะได้เป็นข้อมูลเสียงพูดเพื่อนำไปใช้กับการมวีสู่สัญญาณดิจิทัลต่อไป ซึ่งการมวีสู่การวางกรอบขนาดสัญญาณจะเป็นไปตามสมการที่ (2.3) และ (2.4)

$$\tilde{x}_l(n) = x_l(n) \cdot w(n) \quad (2.3)$$

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2.4)$$

เมื่อ $l=0,1,\dots,L-1$ และ $n=0,1,\dots,N-1$

กำหนดให้ $x_l(n)$ คือค่าสัญญาณเสียงพูดของข้อมูลที่ n

$\tilde{x}_l(n)$ คือค่าสัญญาณเสียงพูดที่ผ่านการมวีสู่การวางกรอบ


$w(n)$ คือฟังก์ชันกรอบชนิด Hamming Window

N คือจำนวนของข้อมูลในแต่ละกรอบสัญญาณเสียงพูด

n คือลำดับข้อมูลในกรอบสัญญาณเสียงพูดที่ l

L คือจำนวนของกรอบสัญญาณเสียงพูด

l คือลำดับของกรอบสัญญาณเสียงพูด



รูปที่ 2.2 ฟังก์ชันกรอบชนิด Hamming Window

2.2 การสกัดลักษณะสำคัญ (Feature Extraction)

การสกัดลักษณะสำคัญคือการวิเคราะห์หาค่าที่นำมาแทนข้อมูลเสียงพูดเพื่อนำไปใช้ในการสร้างแบบจำลองทางสถิติของสัญญาณเสียงพูดนั้นๆ เพราะฉะนั้นจำเป็นต้องเลือกใช้กรรมวิธีที่สามารถสกัดลักษณะสำคัญของสัญญาณเสียงพูดที่เรอบ่งความต่างของผู้พูดแต่ละบุคคลได้เป็นอย่างดี ในงานวิจัยได้นำเสนอการวิเคราะห์ลักษณะสำคัญ 3 ชนิดเพื่อนำมาประยุกต์ใช้กับระบบการบ่งชี้ผู้พูดแบบขึ้นกับบทคำพูดได้แก่ ค่าสัมประสิทธิ์ของการประมาณพัหระเชิงเส้น (Linear Prediction Coefficients, LPC) ค่าสัมประสิทธิ์เซปสตรอล (Cepstral Coefficient, CEP) และค่าสัมประสิทธิ์เซปสตรอลบนความถี่เมล (Mel Frequency Cepstral Coefficient, MFCC) ลักษณะสำคัญทั้งสามชนิดนี้เป็นลักษณะสำคัญของช่องทางเดินเสียง (Vocal Tract) (Campbell, 1997) ซึ่งเป็นลักษณะสำคัญประเภทหนึ่งที่ยอมรับใช้กับระบบการรู้จำผู้พูดดังกล่าวในบทที่ 1 เนื่องจากช่องทางเดินเสียงเป็นลักษณะทางกายภาพที่สามารถแสดงความแตกต่างของแต่ละบุคคลได้ (วิสิทธิ์ ลิลาศิริวงศ์, 2535) ส่วนรายละเอียดและวิธีการคำนวณของลักษณะสำคัญทั้งสามกล่าวในหัวข้อถัดไป

2.2.1 สัมประสิทธิ์ของการประมาณพัหระเชิงเส้น (Linear Prediction Coefficients, LPC)

การประมาณพัหระเชิงเส้น (Linear Prediction) เป็นเทคนิคหนึ่งที่ยอมรับใช้ในการวิเคราะห์คุณสมบัติทางกายภาพของสัญญาณ เช่น Spectral Magnitude ของสัญญาณในช่วงเวลาที่เรสนใจได้อย่างแม่นยำ รวดเร็วและมีประสิทธิภาพ โดยใช้แบบจำลองที่ใช้การวิเคราะห์ค่าพารามิเตอร์ (Parametric Model) ที่สันนิษฐานว่าค่าพารามิเตอร์ที่ได้นี้เกิดจากช่องทางเดินเสียงเพื่อจำลองเป็นสัญญาณเสียงพูด เพราะฉะนั้นสัมประสิทธิ์ของการประมาณพัหระเชิงเส้นได้จากแบบจำลองการประมาณพัหระเชิงเส้นของสัญญาณเสียงพูด ซึ่งแบบจำลองการประมาณพัหระเชิงเส้นคือการประมาณข้อมูลแบบ Linear Least Square หรือเรียกว่า Prediction (Sorenson, 1970) สำหรับงานวิจัยทางด้านสัญญาณเสียงพูดได้มีการนำค่าสัมประสิทธิ์ของการประมาณพัหระเชิงเส้นมาประยุกต์ใช้งานในเรื่องของการวิเคราะห์ สังเคราะห์ เข้รหัสสัญญาณเสียงพูด และสร้างเป็นชุดอ้างอิงของการรู้จำแบบรูป (Pattern Recognition) จำนวนมาก เนื่องจากค่าสัมประสิทธิ์ของการประมาณพัหระเชิงเส้นช่วยในการประมาณการสันเสทือนของช่องทางเดินเสียงขณะออกเสียงพูด รูปร่างของช่องทางเดินเสียง ความถี่และแบนด์วิดท์ของเรโซแนนซ์ที่ช่องทางเดินเสียง (O'Shaughnessy, 1988)

หลักการพื้นฐานของแบบจำลองการประมาณพัหระเชิงเส้น (Linear Prediction Model) คือการคำนวณหาค่าอนาคตของสัญญาณจากการประมาณการผสมเชิงเส้น (Linear Combination) ของค่าของสัญญาณก่อนหน้านั้น โดยสมมติให้สัญญาณที่เรสนใจเกิดจากแหล่งกำเนิดสัญญาณที่ถูกกระตุ้นจากวงจรกรองแบบเชิงเส้น ในงานวิจัยนี้สัญญาณที่สนใจคือสัญญาณเสียงพูดเพราะฉะนั้นจะกล่าวเฉพาะแบบจำลองสัญญาณเสียงพูดเท่านั้น แหล่งกำเนิดของสัญญาณก็คือลมที่พ่นผ่านช่องว่างระหว่างเส้นเสียง (Vocal Cord) ออกมาเป็นรายคาบหรือสัญญาณรบกวนที่เกิดจากช่องแคบของการหดตัวของช่องทางเดินเสียง และที่มีผลกระทบกับช่องทางเดินเสียงส่วนบน พิจารณาให้สัญญาณ $s(t)$ ถูกสุ่มตัวอย่างทุกๆ เวลา T วินาที ดังนั้น

$$s(n) \triangleq s(nT) \quad \text{เมื่อ } n \text{ คือจำนวนเต็ม} \quad (2.5)$$

และใช้การแปลงแบบแซดจะได้เป็น $S(z)$ ซึ่งเราสมมติให้แบบจำลองของการเกิดสัญญาณ $s(n)$ ประกอบไปด้วยแหล่งกำเนิดที่กระตุ้น (Excitation Source) $U(z)$ และผ่านวงจรกรองเชิงความถี่ $H(z)$ จะได้

$$S(z) = U(z)H(z) \quad (2.6)$$

การวิเคราะห์ค่าสัมประสิทธิ์การประมาณพัลส์เชิงเส้นของสัญญาณ $s(n)$ คือการประมาณดีคอนโวลูชัน (Deconvolves) ของ $\hat{U}(z)$ และ $\hat{H}(z)$ ซึ่งเป็นการหาค่าที่ใกล้เคียงที่สุดหรือค่าที่เป็นไปได้มากที่สุดในแง่ Mean Square จากสัญญาณ $S(z)$ นั้นเอง กำหนดให้ $\hat{h}(n)$ คือการประมาณผลตอบสนองต่ออิมพัลส์ (Impulse Response) ของระบบที่กำเนิดสัญญาณ $s(n)$ เนื่องจากไม่สามารถหา $h(n)$ ได้โดยตรง ปัญหาพื้นฐานของการจำลองคือ $\hat{U}(z)$ มักจะถูกกำหนดให้เป็น Flat Spectral Envelope ซึ่งเป็นการจำกัดรายละเอียดของสเปกตรัมใน $\hat{H}(z)$ ทำให้การจำลองสัญญาณเสียงอโฆระ (Unvoiced) ได้ไม่ดี เนื่องจากเสียงอโฆระเป็นการกระตุ้นของสัญญาณรบกวนที่เหมือนกับสัญญาณรบกวนสีขาว จึงทำให้การอบคลื่น (Envelope) ของสเปกตรัมไม่เรียบ ส่วนสัญญาณเสียงพูดในช่วงที่เป็นรายคาบคือเสียงโฆระ (Voiced) มีฮาร์โมนิกของเส้นสเปกตรัมเป็นพื้นที่สม่ำเสมอ (Uniform-Area) ทำให้มีเส้นสเปกตรัมเรียบ

สมมติให้วงจรกรอง $H(z)$ มีจำนวน Pole เท่ากับ p และจำนวน Zero เท่ากับ $q+1$ หมายความว่า การจำลองสัญญาณ $\hat{s}(n)$ เป็นการผสมแบบเชิงเส้น (Linear Combination) ของตัวอย่างขาออกก่อนหน้าจำนวน p ค่ากับตัวอย่างขาเข้าก่อนหน้าจำนวน $q+1$ ค่า เพื่อสังเคราะห์หาค่าสัมประสิทธิ์การประมาณพัลส์เชิงเส้น ดังสมการที่ (2.7)

$$\hat{s}(n) = \sum_{k=1}^p a_k \hat{s}(n-k) + G \sum_{l=0}^q b_l \hat{u}(n-l) \quad (2.7)$$

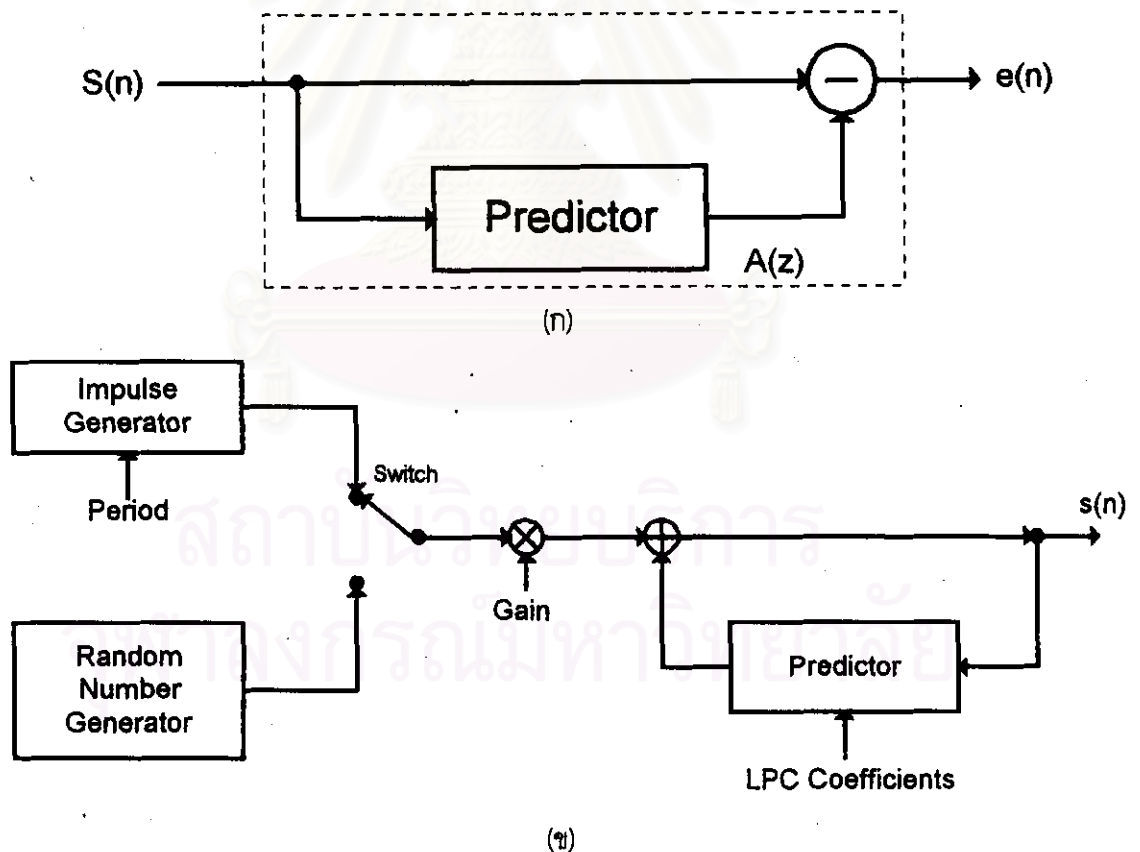
เมื่อ G คืออัตราขยาย (Gain Factor) ของการกระตุ้น โดยสมมติให้ $b_0 = 1$ และ a_k คือค่าสัมประสิทธิ์การประมาณพัลส์เชิงเส้น จากสมการที่ (2.6) จะได้

$$\hat{H}(z) = \frac{\hat{S}(z)}{\hat{U}(z)} = G \frac{1 + \sum_{l=1}^q b_l z^{-l}}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (2.8)$$

แบบจำลองของวงจรกรองที่ใช้ในการหาค่าสัมประสิทธิ์ของการประมาณพัลส์เชิงเส้นมี 3 แบบจำลองดังนี้ (O'Shaughnessy, 1988)

1. แบบจำลอง All-Pole หรือเรียกว่า Autoregressive Model (AR Model) โดยกำหนดให้ $q = 0$
2. แบบจำลอง All-Zero มีอีกชื่อหนึ่งว่า Moving Average Model (MA Model) โดยกำหนดให้ข้อมูลออกเกิดจากการหาค่าเฉลี่ยของน้ำหนักจากข้อมูลเข้า เมื่อจำนวน Zero เท่ากับ $q+1$ ค่า
3. แบบจำลองที่อยู่ในรูปทั่วไปของทั้งสองแบบคือมีทั้ง Pole และ Zero รู้จักกันดีในชื่อของ Autoregressive Moving Average Model (ARMA Model) โดยให้ $p, q > 0$

การหาค่าสัมประสิทธิ์ของการประมาณพหุเชิงเส้นจากแบบจำลอง AR เป็นการแก้สมการเชิงเส้น (Linear Equation) ส่วนแบบจำลอง MA จะใช้สมการไม่เชิงเส้น (Nonlinear Equation) ซึ่งแบบจำลอง ARMA ให้ผลที่แม่นยำกว่าทั้งสองแบบจำลองที่กล่าวมา แต่แบบจำลองที่อยู่ในรูปอย่างง่ายก็คือแบบจำลอง AR ซึ่งเป็นแบบจำลองที่จำลองสเปกตรัมของสัญญาณได้ดีมากเฉพาะในช่วงเรโซแนนซ์เท่านั้น ค่าพลังานที่ความถี่ต่างๆ แสดงคุณสมบัติทางกายภาพของสัญญาณมากกว่าช่วงที่ไม่มีค่า ซึ่งหมายความว่าสัญญาณที่มียอดของสเปกตรัม (Spectral Peak) แสดงคุณสมบัติได้ดีกว่าสัญญาณที่มีค่า Zero ตัวอย่างเช่น ช่องทางเดินเสียงแสดงลักษณะของหลอดเสียง (Acoustic Tube) จากการเปลี่ยนแปลงพื้นที่ของช่องทางเดินเสียงโดยแสดงเป็นความถี่เรโซแนนซ์หนึ่งค่าต่อแบนด์วิดท์หนึ่งกิโเฮิร์ต และค่า Zero ในสเปกตรัมของสัญญาณเสียงพูดขึ้นอยู่กับการเปลี่ยนแปลงเส้นทางเดินของเสียง เช่น เสียงที่ผ่านจากปอดทั้งสองข้างหรือโพรงจมูกมีผลต่อการได้ยินน้อยกว่าเสียงที่พ่นออกมาจากปาก เป็นต้น แสดงให้เห็นว่าระบบการได้ยินของมนุษย์ไวต่อยอดของสเปกตรัม (Spectral Peak) มากกว่ารูปคลื่นในช่วงที่ไม่มีค่าหรือพลังาน ทำให้สามารถประมาณผลกระทบที่เกิดจากค่า Zero จากแบบจำลอง All-Pole ได้ (Markel and Gray, 1980; O'Shaughnessy, 1988)



รูปที่ 2.3 แบบจำลอง All-Pole ที่ใช้วิเคราะห์หาค่าสัมประสิทธิ์การประมาณพหุเชิงเส้น (O'Shaughnessy, 1988)

(ก) แบบจำลองของการวิเคราะห์การประมาณพหุเชิงเส้นสำหรับเสียงพูด

(ข) แบบจำลองการสังเคราะห์เสียงพูดจากแบบจำลองการประมาณพหุเชิงเส้น

ให้สัญญาณ $s(n)$ คือสัญญาณที่ถูกกรองโดยวงจร Inverse หรือ Predictor ดังแสดงในรูปที่ 2.3 (ก) เป็นการ Inverse ของสัญญาณที่ได้จากวงจรกรองแบบ All-Pole ที่ใช้ในการสังเคราะห์ $\hat{H}(z)$ ดังสมการที่ (2.9)

$$A(z) = 1 - \sum_{k=1}^p a_k z^{-k} \quad (2.9)$$

และเอาท์พุทที่ได้คือ $e(n)$ เรียกว่าค่าผิดพลาด (Error) หรือสัญญาณ Residual ดังสมการที่ (2.10)

$$e(n) = s(n) - \sum_{k=1}^p a_k s(n-k) \quad (2.10)$$

ในสัญญาณเสียงโฆระค่าผิดพลาดคือสัญญาณที่มีค่า Peak สูงมากและอยู่ห่างกันในทางเวลาของความถี่ Pitch ส่วนค่าผิดพลาดของสัญญาณเสียงโฆระสังเกตุได้จากการสังเคราะห์ค่าสัมประสิทธิ์การประมาณพื้นที่เชิงเส้นและสัญญาณเรบกวานสีขาว ซึ่งมีคุณสมบัติทางกายภาพของสัญญาณบางอย่างที่วงจรกรองแบบ All-Pole ไม่สามารถจำลองได้

วิธีการ Least-squares

วิธีการ Least-squares เป็นวิธีการเลือกค่าสัมประสิทธิ์ a_k ให้มีค่าเฉลี่ยพลังงานของ $e(n)$ ในแต่ละเฟรม (Frame) มีค่าน้อยที่สุด สามารถคำนวณหาค่าสัมประสิทธิ์ a_k ได้สองวิธีคือวิธีอัตโนมัติสหสัมพันธ์ (Autocorrelation) กับวิธีแปรปรวนร่วม (Covariance) ในงานวิจัยนี้ได้ใช้วิธีอัตโนมัติสหสัมพันธ์ จึงกล่าวถึงแต่เฉพาะวิธีอัตโนมัติสหสัมพันธ์เท่านั้น ให้สัญญาณเสียงพูด $s(n)$ ที่ผ่านการประมวลผลสัญญาณเบื้องต้นและวางกรอบขนาดสัญญาณแบบ Hamming คือ $x(n)$ ดังสมการที่ (2.3)

กำหนดให้ E คือพลังงานของค่าผิดพลาด เมื่อ $e(n)$ คือค่าผิดพลาดของสัญญาณ $x(n)$ ดังสมการที่ (2.11)

$$E = \sum_{n=-\infty}^{\infty} e^2(n) \quad (2.11)$$

$$= \sum_{n=-\infty}^{\infty} \left[x(n) - \sum_{k=1}^p a_k x(n-k) \right]^2 \quad (2.12)$$

$$= \sum_{n=-\infty}^{\infty} x^2(n) - \sum_{n=-\infty}^{\infty} \left[2x(n) \sum_{k=1}^p a_k x(n-k) \right] + \sum_{n=-\infty}^{\infty} \left[\sum_{k=1}^p a_k x(n-k) \right]^2 \quad (2.13)$$

$$= \sum_{n=-\infty}^{\infty} x^2(n) - 2 \sum_{k=1}^p a_k \sum_{n=-\infty}^{\infty} x(n)x(n-k) + \sum_{n=-\infty}^{\infty} \left[\sum_{k=1}^p a_k x(n-k) \right]^2 \quad (2.14)$$

การหาค่า a_k ที่ทำให้ E มีค่าต่ำที่สุดสามารถกระทำได้โดยการหา $\partial E / \partial a_k = 0$ ในสมการที่ (2.14) ของแต่ละค่า $i = 1, 2, 3, \dots, p$ เมื่อ $k = 1, 2, 3, \dots, p$ ได้เป็นสมการเชิงเส้น p สมการ และในแต่ละสมการมี k ค่า ซึ่งก็คือ a_k ที่ไม่ทราบค่า p ตัวดังนี้

$$\frac{\partial E}{\partial a_i} = 0 = -2 \sum_{n=-\infty}^{\infty} x(n)x(n-i) + 2 \sum_{n=-\infty}^{\infty} \left[\sum_{k=1}^p a_k x(n-k) \right] x(n-i) \quad (2.15)$$

$$\sum_{n=-\infty}^{\infty} x(n-i)x(n) = \sum_{k=1}^p a_k \sum_{n=-\infty}^{\infty} x(n-i) \cdot x(n-k) \quad (2.16)$$

เนื่องจากพจน์แรกเป็นอัตสหสัมพันธ์ $R(i)$ ของ $x(n)$ ที่มีความยาวจำกัด สามารถเขียนสมการที่ (2.16) ใหม่ได้เป็นสมการที่ (2.17)

$$\sum_{k=1}^p a_k R(i-k) = R(i), \quad 1 \leq i \leq p \quad (2.17)$$

$$\text{เมื่อ} \quad R(i) = \sum_{n=i}^{N-1} x(n)x(n-i) \quad (2.18)$$

เมื่อแก้สมการที่ (2.14) ซึ่งประกอบไปด้วยสมการเชิงเส้น p สมการได้เป็นค่าสัมประสิทธิ์ a_k ที่ต้องการออกมา โดยเขียนสมการที่ (2.14) ให้อยู่ในรูปเมทริกซ์ $Ra = r$

$$\begin{bmatrix} r_0 & r_1 & \cdots & r_{p-1} \\ r_1 & r_0 & & \vdots \\ \vdots & & \ddots & r_1 \\ r_{p-1} & \cdots & r_1 & r_0 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} \quad (2.19)$$

จากสมการที่ (2.16) เห็นได้ว่าเมทริกซ์ R เป็นเมทริกซ์ชนิด Toeplitz ซึ่งเป็นเมทริกซ์ที่สมมาตรคือมีค่าในแนวทแยงมุมเท่ากันทั้งหมดทุกแนว ดังนั้นการคำนวณหาค่าสัมประสิทธิ์ a_k จะอาศัยวิธีการวนซ้ำของ Levinson-Durbin (Picone, 1996; O'Shaughnessy, 1988)

ขั้นตอนวิธีการวนซ้ำของ Levinson-Durbin

ขั้นตอนวิธีการวนซ้ำของ Levinson-Durbin เป็นเทคนิคที่ใช้ในการคำนวณหาค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้น a_i ในเมทริกซ์ a เมื่อ $i=1,2,3,\dots,p$ และ p เป็นอันดับ (Order) ของการวิเคราะห์หาค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้นจากวิธีอัตสหสัมพันธ์ มีขั้นตอนวิธีการดังต่อไปนี้

วนซ้ำขั้นตอนที่ 1 ถึง 4 ของค่า i แต่ละค่า เมื่อ $i=1,2,3,\dots,p$

ขั้นตอนที่ 1 กำหนดค่าเริ่มต้น

$$E_0 = R(0) \quad \text{และ} \quad \alpha_0 = 0 \quad (2.20)$$

ขั้นตอนที่ 2 คำนวณหาค่าสัมประสิทธิ์การสะท้อน (Reflection Coefficient)

$$k_i = \frac{R(i) - \sum_{j=1}^{i-1} \alpha_{i-1}(j)R(i-j)}{E_{i-1}} \quad (2.21)$$

เมื่อ $R(i)$ และ $R(i-j)$ คำนวณได้จากสมการที่ (2.18)

ขั้นตอนที่ 3 คำนวณหาค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้น

$$\alpha_i(i) = k_i \quad (2.22)$$

$$\alpha_i(j) = \alpha_{i-1}(j) - k_i \alpha_{i-1}(i-j) \quad (2.23)$$

วนซ้ำสมการที่ (2.22) และ (2.23) เมื่อ $j = 1, 2, 3, \dots, i-1$
 ขั้นตอนที่ 4 คำนวณค่าผิดพลาดใหม่

$$E_i = (1 - k_i^2) E_{i-1} \quad (2.24)$$

เมื่อสิ้นสุดการวนซ้ำขั้นตอนทั้งสี่แล้ว เราจะได้ค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้นที่รอบสุดท้าย ($i = p$) คือ $\alpha_p(j)$ เมื่อ $j = 1, 2, 3, \dots, p$ นั่นคือค่าสัมประสิทธิ์ที่มีค่าความผิดพลาดของการประมาณพหุคูณเชิงเส้นน้อยที่สุดนั่นเอง ดังในสมการที่ (2.25)

$$a_k = \alpha_p(k) \quad (2.25)$$

เมื่อ k คืออันดับของค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้น

2.2.2 สัมประสิทธิ์เซปสตรอล (Cepstral Coefficients, CEP)

สัมประสิทธิ์เซปสตรอลสามารถคำนวณหาได้หลายวิธี เช่น คำนวณจากการแปลงฟูริเยร์อย่างรวดเร็ว (Fast Fourier Transform) และคำนวณจากแบบจำลองการประมาณพหุคูณเชิงเส้น เป็นต้น ในงานวิจัยนี้ ได้เลือกใช้ค่าสัมประสิทธิ์เซปสตรอล (c_m) ที่คำนวณจากแบบจำลองการประมาณพหุคูณเชิงเส้นเนื่องจากง่ายต่อการคำนวณและใช้เวลาอย่างมาก วิธีการคำนวณหาสัมประสิทธิ์เซปสตรอลแสดงในสมการที่ (2.26) และ (2.27) (Rabiner and Juang, 1993)

$$c_m = a_m + \sum_{k=1}^{m-1} \left(\frac{k}{m}\right) c_k a_{m-k}, \quad 1 \leq m \leq p \quad (2.26)$$


$$c_m = \sum_{k=1}^{m-1} \left(\frac{k}{m}\right) c_k a_{m-k}, \quad m > p \quad (2.27)$$

เมื่อ p คืออันดับของค่าสัมประสิทธิ์ของการประมาณพหุคูณเชิงเส้น

2.2.3 สัมประสิทธิ์เซปสตรอลบนความถี่เมล (Mel Frequency Cepstral Coefficients, MFCC)

สัมประสิทธิ์เซปสตรอลบนความถี่เมลคำนวณได้จากการวิเคราะห์โดยไม่ใช้พารามิเตอร์ (Non-Parametric Analysis) คือไม่มีการสร้างแบบจำลองสัญญาณเพื่อปรับค่าพารามิเตอร์ในแบบจำลองให้ได้เป็นสัญญาณที่เราต้องการ แต่เป็นการนำสัญญาณผ่านวงจรกรองแบบผ่านแถบความถี่ (Band Pass Filter) หลายวงจร โดยแต่ละวงจรกรองมีช่วงความถี่ที่ผ่านได้แตกต่างกันดังแสดงในรูปที่ 2.4 และวงจรกรองที่ใช้เป็นชุดวงจรกรองแบบดิจิทัล (Digital Filter Bank) ที่ใช้วิเคราะห์สเปกตรัมของสัญญาณเสียงพูด โดยเลียนแบบตามการได้ยินของมนุษย์สามารถทำได้หลายวิธีขึ้นอยู่กับกรรมวิธีที่นำมาใช้กับแกนความถี่ได้แก่ (Tolba and O'Shaughnessy, 1998; Tuzun, Demirekler and Nakiboglu, 1994)

- Uniform Spacing (FFT)
- Exponential Spacing (Wavelet Transform)
- Perceptually-Derived Spacing (Mel Scale หรือ Bark Scale)



รูปที่ 2.4 Mel Scale ของความถี่สัญญาณเสียง

ในงานวิจัยนี้ได้เลือกใช้กรรมวิธี Perceptually-derived Spacing หรือเรียกอีกชื่อหนึ่งว่า Mel scale เป็นการเปลี่ยนแกนความถี่ของสัญญาณเสียง (Acoustic Frequency) ไปเป็นแกนความถี่ของการได้ยิน (Perceptual Frequency) จึงกล่าวถึงแต่กรรมวิธีนี้เท่านั้น Mel scale ใช้หลักการ Mapping จากการประมาณความถี่ช่วงที่เป็นเชิงเส้น (Linear Frequency Scale) ให้เป็นความถี่ที่ไม่เชิงเส้น (Nonlinear Frequency Scale) ตามลักษณะการได้ยินของมนุษย์ดังแสดงสมการที่ (2.28) (Tolba and O'Shaughnessy, 1998)

$$mel(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (2.28)$$

เมื่อ f คือช่วงความถี่ที่ยังเป็นเชิงเส้น จากรูปที่ 2.4 เห็นได้ว่าลักษณะการได้ยินของมนุษย์ในช่วงที่เป็นเชิงเส้น (Linear scale) คือประมาณช่วงความถี่ตั้งแต่ 0 ถึง 1000 Hz และช่วงที่ไม่เป็นเชิงเส้น (Logarithmic scale) คือช่วงความถี่ตั้งแต่ 1000 Hz ขึ้นไป แนวคิดวิธีของวงจรรองสามารถคำนวณได้จากสมการที่ (2.29) ดังนี้

$$BW_{critical} = 25 + 75 \left[1 + 1.4 \left(\frac{f}{1000} \right)^2 \right]^{0.69} \quad (2.29)$$

วิธีการคำนวณแบบจำลองของชุดวงจรรอง (Filter Bank Model) ที่ง่ายที่สุดและให้ผลที่มีประสิทธิภาพดีคือการแปลงแบบฟูริเยร์ (Fourier Transform) ของสัญญาณและหาข้อมูลออกของชุดวงจรรองของแต่ละวงจรถือ (X_N) จากความถี่ที่ใส่เข้าไป การคำนวณหาข้อมูลออกของชุดวงจรรองสามารถคำนวณได้ตามสมการที่ (2.30)

$$X_N = \frac{1}{N_{FB}} \sum_{k=1}^{N_{FB}} \omega_{FB}(k) X(f + \delta f(f, k)) \quad (2.30)$$

เมื่อ N_{FB} คือจำนวนของตัวอย่างที่ใช้ในการหาค่าเฉลี่ย

ω_{FB} คือฟังก์ชันการถ่วงน้ำหนัก

$\delta f(f, k)$ คือฟังก์ชันที่อธิบายถึงความถี่ที่อยู่ใกล้เคียงกับความถี่ f เพื่อนำมาใช้คำนวณหาค่าเฉลี่ย


ในการคำนวณหาค่าสัมประสิทธิ์เซปสตรอลบนความถี่เมลใช้ค่าข้อมูลออกที่ได้จากวงจรกรองแถบผ่าน N วงจรเมื่อใส่ค่าลอการิทึมของขนาดสเปกตรัมของสัญญาณเสียงเข้าไป เพื่อประมาณความถี่ตอบสนองของ Basilar Membrane ใน Cochlea ที่อยู่ในหูชั้นใน วงจรกรองที่นำมาใช้นี้เป็นวงจรกรองแถบผ่านแบบสามเหลี่ยมดังแสดงในรูปที่ 2.5 เพราะฉะนั้นการคำนวณหาค่าสัมประสิทธิ์เซปสตรอลบนความถี่เมล (C_n) สามารถหาได้จากสมการดังต่อไปนี้ (Tolba and O'Shaughnessy, 1998)

$$C_n = \sum_{k=1}^N X_k \cos\left(\frac{\pi n}{N}(k-0.5)\right), \quad n=1,2,\dots,M \quad (2.31)$$

เมื่อ M คือจำนวนของสัมประสิทธิ์เซปสตรอล

N คืออันดับในการวิเคราะห์

X_k คือค่าลอการิทึมของพลังงานที่ค่าข้อมูลออกของวงจรกรอง k วงจร เมื่อ $k=1,2,\dots,N$

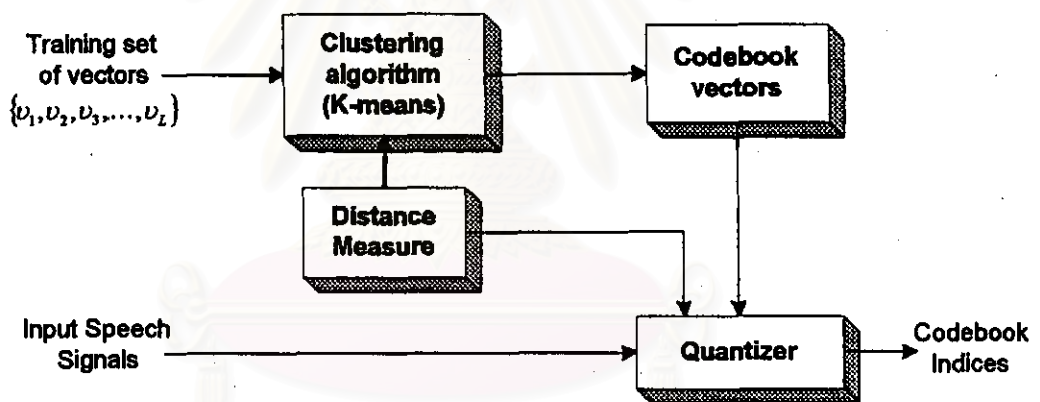


รูปที่ 2.5 วงจรกรองแถบผ่านแถบความถี่ที่ให้ค่าสัมประสิทธิ์เซปสตรอลบนความถี่เมล

2.3 การควอนไทซ์แบบเวกเตอร์ (Vector Quantization, VQ)

การควอนไทซ์ (Quantization) คือกระบวนการประมาณค่าแอมพลิจูดของสัญญาณต่อเนื่องโดยใช้สัญญาณไม่ต่อเนื่อง ซึ่งเป็นกระบวนการสำคัญในการบีบอัดข้อมูล (Data Compression) หรือการเข้ารหัส (Coding) เพื่อเป็นการลดจำนวนบิตที่จำเป็นในการส่งหรือเก็บข้อมูล การควอนไทซ์สามารถแบ่งได้เป็น 2 ประเภทคือการควอนไทซ์แบบสเกลาร์ (Scalar Quantization) และการควอนไทซ์แบบเวกเตอร์ (Vector Quantization) การควอนไทซ์ที่อิสระกับแต่ละค่าสัญญาณหรือพารามิเตอร์เรียกว่าการควอนไทซ์แบบสเกลาร์ ส่วนการควอนไทซ์แบบเวกเตอร์จะควอนไทซ์ชุดของค่าพารามิเตอร์เป็นเวกเตอร์เดียว

การควอนไทซ์แบบเวกเตอร์ได้รับความนิยมใช้ในการเข้ารหัสสัญญาณเสียงพูด (Speech Coding) การเข้ารหัสข้อมูลภาพ (Image Coding) และการรู้จำเสียงพูด (Speech Recognition) ในระบบการรู้จำเสียงพูดที่ใช้แบบจำลองฮิดเดนมาร์คอฟ (Hidden Markov Models, HMM) การควอนไทซ์แบบเวกเตอร์มีความสำคัญในการอธิบายต้นแบบสัญญาณเสียงดิสครีต (Discrete Acoustic Prototype) ของสัญญาณเสียงพูดของแบบจำลองฮิดเดนมาร์คอฟแบบดิสครีต (Discrete Hidden Markov Models, DHMM)



รูปที่ 2.6 การควอนไทซ์แบบเวกเตอร์ (Zhang, 1996)

หลักการพื้นฐานของการควอนไทซ์แบบเวกเตอร์โดยทั่วๆ ไปแบ่งได้เป็น 2 ช่วงคือช่วงการออกแบบชุดรหัสและช่วงการควอนไทซ์ ดังในรูปที่ 2.6 ช่วงการออกแบบชุดรหัสสร้างชุดรหัสและฝึกฝนชุดรหัสจากข้อมูลสัญญาณเสียงในชุดฝึกฝน เพื่อนำไปสร้างเป็นต้นแบบอ้างอิงชุดรหัส (Codebook Reference Template) ส่วนในช่วงของการควอนไทซ์คือการนำสัญญาณเสียงพูดมาควอนไทซ์กับต้นแบบอ้างอิงชุดรหัส และได้เป็นค่ารหัสของสัญญาณเสียงพูดนั้นๆ สามารถสรุปได้ว่าการควอนไทซ์แบบเวกเตอร์คือการแบ่งข้อมูลของปริภูมิสัญญาณ (Signal Space) ไปตามจำนวนของพื้นที่หรือเรียกว่าเซลล์ (Cell) และใช้เวกเตอร์จุดศูนย์กลาง (Centroid Vector) ของแต่ละพื้นที่แทนจุดของข้อมูลทั้งหมดที่อยู่ในพื้นที่นั้นๆ สามารถอธิบายตามหลักการและทฤษฎีได้ดังนี้ (Huang, 1989; Zhang, 1995)

สมมติให้ $x = [x_1, x_2, x_3, \dots, x_d] \in R^d$ คือเวกเตอร์ที่มีมิติเท่ากับ d และประกอบไปด้วย $x_k, 1 \leq k \leq d$ และเป็นค่าจำนวนจริงที่ได้จากตัวแปรสุ่มที่มีแอมพลิจูดแบบต่อเนื่อง (Continuous-

amplitude Random Variable) ในการควอนไทซ์แบบเวกเตอร์จะเปลี่ยนเวกเตอร์ x ให้เป็นค่าจำนวนจริงที่ได้จากแอมพลิจูดไม่ต่อเนื่องที่ขนาดเวกเตอร์เท่ากับ d มิติ (y) เราเรียกว่าเวกเตอร์ x ถูกควอนไทซ์ไปเป็นเวกเตอร์ y


$$y = q(x) \quad (2.32)$$

จากสมการที่ (2.32) $q(\cdot)$ คือโอเปอเรเตอร์ของการควอนไทซ์ (Quantisation Operator) y คือเวกเตอร์ที่ประกอบไปด้วยเซตจำกัด $Y = \{y_i, 1 \leq i \leq L$ เมื่อ $y_i = [y_{i1}, y_{i2}, y_{i3}, \dots, y_{id}]$ เซต Y นี้คือชุดรหัส (Codebook) L คือขนาดของชุดรหัสและ $\{y_i\}$ คือเซตของเวกเตอร์รหัส (Codeword) ขนาด L ของชุดรหัสเรียกว่า "จำนวนขั้นในชุดรหัส"

การออกแบบชุดรหัสคือการแบ่งปริภูมิที่มีขนาด d มิติของเวกเตอร์ x ที่ถูกสุ่มมาจากสัญญาณตั้งต้นออกเป็น L เซลล์ $C_i, 1 \leq i \leq L$ และแทนแต่ละเซลล์ C_i ด้วยเวกเตอร์ y_i ตัวควอนไทซ์ถูกแทนด้วยเวกเตอร์รหัส y_i ถ้า x อยู่ใน C_i

$$q(x) = y_i, \text{ if } x \in C_i \quad (2.33)$$

กระบวนการออกแบบในขั้นตอนนี้เรียกว่า "การฝึกฝนชุดรหัส" ตัวอย่างการแบ่งข้อมูลในปริภูมิที่มีขนาด 2 มิติ ($d = 2$) เพื่อนำไปใช้ในการควอนไทซ์แสดงดังในรูปที่ 2.7



รูปที่ 2.7 การแบ่งปริภูมิที่มีขนาด 2 มิติ (Huang, 1989)

เมื่อ x ถูกควอนไทซ์เป็น y ผลของความผิดพลาดที่เกิดจากการควอนไทซ์และค่าความเพี้ยนวัดเป็นระยะห่างระหว่าง x กับ y คือ $d(x, y)$ ซึ่งเป็นการวัดคุณภาพของการควอนไทซ์ การวัดนี้ต้องบอกถึงความแตกต่างของค่าความเพี้ยนที่ใช้บอกความแตกต่างของสัญญาณเสียงพูดได้ การวัดที่ธรรมดาที่สุดวิธีหนึ่งคือการวัดระยะห่างของยูคลิเดียน (Euclidean Distance) ดังสมการที่ (2.34) โดยสมมติให้ความแตกต่างของค่าความเพี้ยนของการควอนไทซ์พารามิเตอร์ต่างๆ มีค่าเท่ากัน

$$d(x, y) = (x - y)^T (x - y) \quad (2.34)$$

แต่ถ้ามีการถ่วงน้ำหนักไม่เท่ากันจะใช้การวัดระยะห่างของมาฮาลานอบิส (Mahalanobis Distance) โดยมีการใช้ความแปรปรวนผกผันของ y มาคิดด้วย ดังสมการที่ (2.35)

$$d(x, y) = (x - y)^T \Sigma^{-1} (x - y) \quad (2.35)$$

การออกแบบชุดรหัส L ระดับคือการแบ่งข้อมูลในปริภูมิ (Space) d มิติออกเป็น L เซลล์และแทนแต่ละเซลล์ด้วยเวกเตอร์ที่ถูกควอนไทซ์แล้ว การหาเวกเตอร์ของตัวควอนไทซ์ที่เหมาะสมสามารถหาได้จากค่าความเพี้ยนรวมทั้งหมดของแต่ละระดับของชุดรหัสที่มีค่าต่ำที่สุด ค่าความเพี้ยนรวมทั้งหมดสามารถหาได้จาก

$$D = E[d(x, y_i)] \quad (2.36)$$

$$= \sum_{i=1}^L \Pr(x \in C_i) E[d(x, y_i) | x \in C_i] \quad (2.37)$$

$$= \sum_{i=1}^L \Pr(x \in C_i) \int_{x \in C_i} d(x, y_i) f(x) dx \quad (2.38)$$

เมื่อ $\Pr(x \in C_i)$ คือค่าความน่าจะเป็นแบบดิสครีต (Discrete Probability) ของ x ที่อยู่ในเซลล์ C_i $f(x)$ คือฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function) ของ x และ $E[]$ คือค่าคาดหวัง

2.3.1 การออกแบบชุดรหัส (Codebook Design)

การออกแบบชุดรหัสอาจเรียกได้ว่าเป็นการจัดกลุ่มของข้อมูลแบบหนึ่ง เพื่อนำไปสร้างเป็นต้นแบบอ้างอิงชุดรหัส (Codebook Reference Template) ใช้ในการทดสอบความคล้ายคลึงกันของรูปแบบของชุดข้อมูลที่เข้ามาทดสอบกับต้นแบบอ้างอิงชุดรหัสก่อนควอนไทซ์แบบเวกเตอร์และเข้าสู่แบบจำลองทางสถิติต่อไป การจัดกลุ่มคือการควอนไทซ์ที่เหมาะสมเมื่อสมการที่ (2.38) มีค่าน้อยที่สุดจากทุกๆ L ระดับของตัวควอนไทซ์ ซึ่งหมายความว่าต้องเป็นไปตามเงื่อนไขของความเหมาะสมที่จำเป็นทั้ง 2 ประการ ประการแรกคือ ตัวควอนไทซ์ที่เหมาะสมที่สุดต้องเป็นไปตามกฎความเพี้ยนน้อยที่สุด (Minimum Distortion) หรือกฎการเลือกบริเวณที่ใกล้เคียงที่สุด (Nearest Neighbour Rule) ดังนี้

$$q(x) = y_i \text{ if and only if } d(x, y_i) \leq d(x, y_j), \quad j \neq i, \quad 1 \leq j \leq L \quad (2.39)$$

จากสมการที่ (2.39) หมายความว่าตัวควอนไทซ์ต้องเลือกเวกเตอร์รหัส (Codeword) ที่มีความเพี้ยนน้อยที่สุดเมื่อเทียบกับ x

เงื่อนไขที่สองคือ การเลือกเวกเตอร์รหัส y_i ต้องให้ความเพี้ยนเฉลี่ยในเซลล์ C_i มีค่าน้อยที่สุด นั่นคือ y_i เป็นเวกเตอร์ y ที่ทำให้สมการที่ (2.40) มีค่าน้อยที่สุด

$$D_i = E[d(x, y) | x \in C_i] \quad (2.40)$$

$$= \int_{x \in C_i} d(x, y) f(x) dx \quad (2.41)$$

เวกเตอร์ดังกล่าวนี้เรียกว่า "จุดศูนย์กลางถ่วง" (Centroid) ของเซลล์ C_i ซึ่งเขียนได้เป็น

$$y_i = \text{cent}(C_i) \quad (2.42)$$

การคำนวณหาค่าจุดศูนย์กลางถ่วงของแต่ละบริเวณนั้นขึ้นอยู่กับนิยามของการวัดค่าความเพี้ยนในทางปฏิบัติต้องกำหนดให้ชุดของเวกเตอร์ฝึกฝน $\{x_k, 1 \leq k \leq T\}$ โดยที่ชุดย่อย K_i ของเวกเตอร์นี้อยู่ในเซลล์ C_i เพราะฉะนั้นค่าความเพี้ยนเฉลี่ย (D_i) ในเซลล์ C_i เป็นไปตามสมการที่ (2.43)

$$D_i = \frac{1}{K_i} \sum_{x \in C_i} d(x, y_i) \quad (2.43)$$

ค่าความเพี้ยนเฉลี่ยโดยรวมสามารถคำนวณได้จาก

$$D = \sum_{i=1}^L D_i / T \quad (2.44)$$

ให้ค่าความเพี้ยนที่วัดได้ในกลุ่มคือ C_i และ $d(x, y)$ คือค่า D_i ที่น้อยที่สุด จากสมการที่ (2.43) เขียนใหม่ได้เป็น

$$y_i = \frac{1}{K_i} \sum_{x \in C_i} x \quad (2.45)$$

เมื่อ y_i คือค่าเฉลี่ยของตัวอย่างที่ได้จากชุดเวกเตอร์ฝึกฝนทั้งหมด (x) ที่อยู่ในกลุ่ม C_i ขั้นตอนวิธีการแบ่งกลุ่มที่ใช้การวนซ้ำคือขั้นตอนวิธีการหนึ่งที่ใช้ในการออกแบบชุดรหัส เพื่อให้ได้ความเพี้ยนเฉลี่ยน้อยที่สุด (Iteratively Minimise The Average Distortion) เช่น ขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วน (K-means Algorithm) ขั้นตอนวิธีการ Linde, Buzo และ Gray (LBG Algorithm) และขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด (Expectation Maximization Algorithm) เป็นต้น (Huang, 1989) ขั้นตอนในการออกแบบชุดรหัสสามารถแบ่งได้เป็นสองขั้นตอนคือ การสร้างชุดรหัสและการฝึกฝนชุดรหัส เนื่องจากงานวิจัยนี้ได้ใช้ขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วน และขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด จึงกล่าวถึงเฉพาะรายละเอียดและทฤษฎีของขั้นตอนวิธีการทั้งสองวิธีนี้เท่านั้น

ขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วน (K-means Algorithm)

ขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วนเป็นขั้นตอนวิธีการที่ได้รับความนิยมมากที่สุดในการแบ่งกลุ่มแบบวนซ้ำ (Iterative Clustering Algorithm) (Huang, 1989) ที่ใช้พื้นฐานของการแบ่งชุดข้อมูลฝึกฝนเป็น L กลุ่ม $\{C_i, 1 \leq i \leq L\}$ ที่ต้องใช้เงื่อนไขที่จำเป็นดังที่กล่าวไว้ข้างต้นในการหาค่าที่เหมาะสม เพื่อให้ได้ค่าความเพี้ยนเฉลี่ย (Average Distortion) น้อยที่สุด โดยใช้พื้นฐานการแบ่งชุดของเวกเตอร์ฝึกฝน $\{x(n)\}$ ออกเป็น L กลุ่ม เมื่อกำหนดให้ $L = K$ มีขั้นตอนดังต่อไปนี้

ขั้นตอนการสร้างชุดรหัสเริ่มต้น (Initial Codebook)

ขั้นตอนในการสร้างชุดรหัสมีหลายวิธี (Makhoul, Roucos, and Gish, 1985) ได้แก่ การค้นหาแบบทวิภาค (Binary Search) การควอนไทซ์แบบต่อเรียงกัน (Cascade Quantization) รหัสผลคูณ (Product Codes) และชุดรหัสแบบสุ่ม (Random Codebooks) สำหรับงานวิจัยนี้ใช้วิธีการชุดรหัสแบบสุ่มในการสร้างชุดรหัสเริ่มต้นเพื่อนำไปใช้ในการฝึกฝนชุดรหัสต่อไป เนื่องจากการสร้างชุดรหัสแบบสุ่มมีความรวดเร็วและทำได้ง่ายกว่าวิธีอื่น วิธีการสร้างชุดรหัสแบบนี้คือการสุ่มเลือกเวกเตอร์รหัสเริ่มต้นจากชุดข้อมูลฝึกฝนตามขนาดของชุดรหัส (L)

ขั้นตอนการฝึกฝนชุดรหัส (Codebook Training)

ขั้นตอนนี้เป็นขั้นตอนในการหาค่าเหมาะสมที่สุดจากชุดเวกเตอร์ฝึกฝนมี 4 ขั้นตอนดังนี้

ขั้นตอนที่ 1 การสร้างชุดรหัสเริ่มต้น (Initialisation)

สร้างชุดรหัสแบบสุ่มจากชุดข้อมูลฝึกฝนที่มีชุดเวกเตอร์ของตัวควอนไทซ์เท่ากับ $y_i, 1 \leq i \leq L$

ขั้นตอนที่ 2 การจำแนก (Classification)

จำแนกข้อมูลในชุดเวกเตอร์ฝึกฝน (Training Vectors) x_i ที่ละตัวว่าอยู่ในกลุ่มของ C_i กลุ่มใด โดยใช้กฎการเลือกเพื่อนบ้านข้างเคียงใกล้ที่สุด (Nearest Neighbor Rule) ดังนี้

$$x \in C_i, \text{ iff } d(x, y_i) \leq d(x, y_j) \text{ for all } j \neq i \quad (2.46)$$

ขั้นตอนที่ 3 การปรับชุดรหัส (Codebook Updating)

เป็นการปรับค่าเวกเตอร์รหัสในทุกๆ กลุ่มโดยใช้การคำนวณจุดศูนย์กลางของชุดเวกเตอร์ฝึกฝนในแต่ละกลุ่มใหม่ดังนี้

$$y_i = \text{cent}(C_i), 1 \leq i \leq L \quad (2.47)$$

ขั้นตอนที่ 4 การสิ้นสุด (Termination)


ถ้าค่าความเพี้ยนโดยรวม D ในรอบปัจจุบันเทียบกับค่าความเพี้ยนโดยรวมในรอบก่อนหน้านี้นี้มีค่าต่ำกว่าจุดเริ่มเปลี่ยน (Threshold) ก็จะสิ้นสุดขั้นตอนวิธีการแต่ถ้าไม่ก็จะวนซ้ำในขั้นตอนที่ 2 ต่อไป

ในกระบวนการหาค่าความเพี้ยนเฉลี่ยต่ำที่สุดของขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วนจะสิ้นสุดใน 2 กรณี คือเมื่อได้ค่าศูนย์กลาง y_i หรือค่าเฉลี่ยของแต่ละกลุ่มข้อมูล C_i แล้วใช้กระบวนการหาค่าต่ำที่สุด (Minimization Process) เพื่อแบ่งกลุ่มของเวกเตอร์ทั้งหมดที่สอดคล้องกับค่าศูนย์กลางที่อยู่ใกล้ที่สุด โดยใช้การวัดค่าความเพี้ยนเฉลี่ย D_i เป็นตัวตัดสิน หรือในทางตรงกันข้ามถ้าแบ่งกลุ่มของข้อมูลได้ทั้งหมดแล้วใช้กระบวนการหาค่าต่ำที่สุด เพื่อหาจุดศูนย์กลางใหม่ในแต่ละกลุ่มข้อมูลให้ค่าความเพี้ยนเฉลี่ยต่ำสุด

D_i จากการวนซ้ำของทั้งสองกรณีทำให้ค่าความเพี้ยนเฉลี่ย D_i ใหม่ที่มีค่าน้อยกว่าค่าในรอบก่อนหน้านี้ อย่างไรก็ตามขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วนลู่เข้าสู่ค่าที่เหมาะสมที่สุดเฉพาะแห่ง (Local Optimum) ทำให้ผลลัพธ์ที่ได้ไม่เป็นหนึ่งเดียว ดังนั้นการหาค่าที่เหมาะสมที่สุดที่ครอบคลุมโดยรวม (Global Optimum) กระทำได้โดยการใช้ค่าเริ่มต้นของเวกเตอร์รหัสหลายค่าที่แตกต่างกันแล้วทำตามขั้นตอนวิธีการแบ่งเฉลี่ย K ส่วน และซ้ำขั้นตอนนี้กับค่าเริ่มต้นที่แตกต่างกันหลายๆ ครั้ง เพื่อให้ชุดรหัสที่มีค่าความเพี้ยนโดยรวมทั้งหมดน้อยที่สุด

ขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด (Expectation Maximization Algorithm, EM)

ขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดเป็นขั้นตอนวิธีการแบ่งกลุ่มข้อมูลที่อยู่ในปริภูมิ d มิติ โดยใช้แบบจำลองแบบเกาส์ (Gaussian) ในการจำลองการแจกแจงข้อมูลแต่ละกลุ่ม ดังแสดงในรูปที่ 2.8 โดยใช้หลักการพื้นฐานจากการฝึกฝนแบบ Unsupervised ถือว่าข้อมูลที่ได้จากการสุ่มตัวอย่าง (x) เป็นข้อมูลที่สังเกตได้ (Observable Data) และถูกเรียกว่า "ข้อมูลไม่บริบูรณ์" (Incomplete Data) เพราะยังขาดข้อมูลที่สังเกตไม่ได้ (Unobservable Data) เพราะฉะนั้นข้อมูลที่มีทั้งข้อมูลที่สังเกตได้กับข้อมูลที่สังเกตไม่ได้เรียกว่า "ข้อมูลบริบูรณ์" (Complete Data) จุดประสงค์ของขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดคือการหาค่าลอการิทึมของความน่าจะเป็นจริง (Log-likelihood) ที่มากที่สุดจากข้อมูลไม่สมบูรณ์ โดยใช้การวนซ้ำเพื่อให้การคาดหวังค่าลอการิทึมของความน่าจะเป็นจริงมากที่สุดจากข้อมูลสมบูรณ์ ในแต่ละรอบของการวนซ้ำของขั้นตอนวิธีการนี้จะประกอบไปด้วย 2 ขั้นตอนคือ ขั้นตอนการคาดหวัง (Expectation Step) กับขั้นตอนการหาค่ามากที่สุด (Maximization) จึงเรียกขั้นตอนวิธีการนี้ว่า "ขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด" (Expectation Maximization, EM) อาจกล่าวได้ว่าขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดเป็นวิธีการประมาณค่าความน่าจะเป็นจริงที่มากที่สุด (Maximum Likelihood Estimation Method) ที่มีการคำนวณความซับซ้อนน้อยและมีความน่าเชื่อถือว่าลู่เข้าสู่ค่าที่เหมาะสมที่สุดครอบคลุมโดยรวม (Huang, 1989; Zhang, Alder & Togneri, 1994; Zhang, 1995)



รูปที่ 2.8 การแบ่งบริภูมิที่มีขนาด 2 มิติโดยใช้แบบจำลองการแจกแจงแบบเกาส์ (Huang, 1989)

ทฤษฎีและหลักการสำคัญที่เกี่ยวข้องกับขั้นตอนวิธีการมีดังต่อไปนี้ การหาฟังก์ชันความหนาแน่นของความน่าจะเป็น (Probability Density Function) แบบเกาส์ทำได้ตามสมการต่อไปนี้

$$f(x) = \frac{|C|^{-1/2}}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2}(x-\mu)^T C^{-1}(x-\mu)\right\} \quad (2.48)$$

เมื่อ C คือเมตริกซ์ของความแปรปรวนแบบเกาส์

μ คือเวกเตอร์ค่าเฉลี่ยของข้อมูลที่อยู่แบบจำลองแบบเกาส์

x คือเวกเตอร์ข้อมูลที่เราจะหาความหนาแน่นความน่าจะเป็น

n คือมิติของเวกเตอร์ของข้อมูล x

Multivariate Gaussian Mixture ($g(x|\theta)$) ที่ประกอบไปด้วยการแจกแจงแบบเกาส์ k กลุ่ม สามารถคำนวณหาได้จาก

$$g(x|\theta) = \sum_{i=1}^k w_i f_i(x|\mu_i, \Sigma_i) \quad (2.49)$$

เมื่อ $f_i(x|\mu_i, \Sigma_i)$ คือฟังก์ชันความหนาแน่นความน่าจะเป็นแบบเกาส์ที่ i ซึ่งแสดงการแจกแจงข้อมูลที่มีค่าเฉลี่ย (Mean, μ_i) เป็นเวกเตอร์ขนาด d มิติ ความแปรปรวนเป็นเมตริกซ์ขนาด

$d \times d$ มิติ w_i คือค่าถ่วงน้ำหนักการแจกแจงแบบเกาส์ที่ i และ $\sum_{i=1}^k w_i = 1$ จากสมการที่ (2.49) θ คือเวกเตอร์ที่ประกอบไปด้วยพารามิเตอร์ w_i, μ_i และ Σ_i เมื่อ $i = 1, 2, 3, \dots, k$

$g(x|\theta)$ คือความน่าจะเป็นจริง (Likelihood) ของ x และใช้บอกระยะระหว่างจุดของข้อมูล กับแบบจำลองแบบเกาส์แต่ละกลุ่ม กำหนดให้ N คือจำนวนของข้อมูลที่มีขนาด d มิติ $X = x_1, x_2, x_3, \dots, x_N$ สามารถจำลองได้จาก $g(x|\theta)$ ที่มีการแจกแจงแบบเกาส์จำนวน k เกาส์ การวัดว่าการจำลองข้อมูลด้วยการแจกแจงแบบเกาส์เข้าใกล้ข้อมูลมากหรือน้อยวัดได้จากค่าความน่าจะเป็นจริงโดยรวม (Total Likelihood) ค่าความน่าจะเป็นจริงของแต่ละกลุ่มคำนวณได้จาก

$$L(X/\theta) = \prod_{j=1}^N g(x_j|\theta) \quad (2.50)$$

เพราะฉะนั้นค่าลอการิทึมความน่าจะเป็นจริงโดยรวม (Log Total Likelihood) คำนวณได้ดังนี้

$$\ell(X/\theta) = \log L(X/\theta) = \sum_{j=1}^N \log g(x_j|\theta) \quad (2.51)$$

สังเกตได้ว่าปัญหาของการจำลองข้อมูลด้วยการแจกแจงแบบเกาส์คือการหา $\theta = \hat{\theta}$ และค่าลอการิทึมของความน่าจะเป็นจริงโดยรวมที่มีค่ามากที่สุด ขั้นตอนวิธีการที่ใช้ในการหาค่าประมาณลอการิทึมของความน่าจะเป็นจริงที่มากที่สุดและสอดคล้องกับการประมาณ $\theta = \hat{\theta}$ ก็คือขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด เป็นขั้นตอนวิธีการที่ใช้กระบวนการวนซ้ำเพื่อสร้างลำดับ (Sequence) ของการประมาณ $\{\theta^m\}$ กระบวนการนี้สามารถเข้าสู่ค่าลอการิทึมของความน่าจะเป็นจริงโดยรวมที่เหมาะสมที่สุดเฉพาะแห่ง แต่ถ้าปรับเปลี่ยนเงื่อนไขเริ่มต้น (θ^0) ทำให้การสร้างลำดับสู่เข้าค่า $\hat{\theta}$ และมีค่าลอการิทึมของความน่าจะเป็นจริงโดยรวมที่แตกต่างกันตามเงื่อนไขเริ่มต้น การแก้ปัญหานี้คือการหาวิธีการเลือกเงื่อนไขเริ่มต้นที่ไม่เปลี่ยนแปลงการประมาณค่า $\hat{\theta}$ และได้ค่าลอการิทึมของความน่าจะเป็นจริงที่เหมาะสม

วิธีการสร้างชุดรหัสเริ่มต้นให้กับขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดจะใช้กลยุทธ์แบบสุนัขกับกระต่าย (Dog-Rabbit Strategy) เพื่อหาจุดศูนย์กลางของกลุ่มข้อมูล

ขั้นตอนการสร้างชุดรหัสเริ่มต้น (Initial Codebook)

การสร้างชุดรหัสเริ่มต้นให้กับขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดในงานวิจัยนี้ไม่ได้ใช้การสุ่มแต่ได้เลือกใช้ขั้นตอนวิธีการแบบสุนัขกับกระต่าย (Dog Rabbit Algorithm) เนื่องจากวิธีแบบสุนัขกับกระต่ายเป็นวิธีการแบ่งกลุ่มได้ดีกว่าวิธีการแบ่งเฉลี่ย K ส่วน (McKenzie and Alder, 1995) และช่วยลดเวลาที่ใช้ในขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดให้น้อยลง ขั้นตอนวิธีการแบบสุนัขกับกระต่ายเป็นกระบวนการวนซ้ำแบบพลวัต (Dynamic Process) เพื่อเคลื่อนย้ายจุด k หรือจุดศูนย์กลางของกลุ่มไปใกล้จุดศูนย์กลางของชุดข้อมูล

ขั้นตอนวิธีการแบบสุนัขกับกระต่ายมีทั้งหมด 6 ขั้นตอนดังนี้

ขั้นตอนที่ 1 กำหนดสัญลักษณ์เริ่มต้น k ตัว ที่อยู่ในตำแหน่ง c_j เมื่อ $j=1,2,3,\dots,k$ ที่ได้จากการสุ่มตำแหน่งจากขอบเขตของข้อมูล และกำหนดค่าความอ่อนล้า (Fatigue) ของสัญลักษณ์ $f_j = 1$

ขั้นตอนที่ 2 เลือกกระต่าย x แบบสุ่มจากชุดข้อมูล

ขั้นตอนที่ 3 คำนวณหาระยะห่างของสัญลักษณ์แต่ละตัวกับกระต่าย x และหาสัญลักษณ์ที่อยู่ใกล้ที่สุด c_c

ขั้นตอนที่ 4 เคลื่อนย้ายตำแหน่งของสัญลักษณ์เข้าหากกระต่ายแบบพลวัตดังนี้

$$c'_c = c_c + \frac{2D_c}{(1+D_c)^{f_c}}(x - c_c) \quad (2.52)$$

$$c'_j = c_j + \frac{D_j}{\Lambda + D_j} \frac{2D_j}{(1+D_j)^{f_j}}(x - c_j) \quad , \quad j \neq c \quad (2.53)$$

เมื่อ D_c และ D_j คือระยะห่างแบบยูคลิดีเนียน ($D_j = \|c_j - x\|$)

ขั้นตอนที่ 5 ถ้า $D_c < 1$ ให้เพิ่มค่าความอ่อนล้า f_c ของ c_c ซึ่งคือสัญลักษณ์ที่ใกล้กระต่ายมากที่สุด

ขั้นตอนที่ 6 วนซ้ำขั้นตอนที่ 2 ใหม่จนกว่าสัญลักษณ์จะเคลื่อนย้ายตำแหน่งน้อยกว่าค่าจุดเริ่มเปลี่ยนที่กำหนดไว้

ขั้นตอนการฝึกฝนชุดรหัส (Codebook Training)

ขั้นตอนการฝึกฝนชุดรหัสเป็นขั้นตอนการหาค่าพารามิเตอร์ของแบบจำลองการแจกแจงแบบเกาส์ โดยใช้กระบวนการวนซ้ำเพื่อหาค่าประมาณความน่าจะเป็นจริงมากที่สุดจากชุดข้อมูล มีขั้นตอนโดยทั่วไปดังนี้

ขั้นตอนที่ 1 เลือกพารามิเตอร์ θ เริ่มต้นได้แก่ ค่าจุดศูนย์กลางของกลุ่ม เมตริกซ์ความแปรปรวนของกลุ่มข้อมูล และค่าถ่วงน้ำหนักของแต่ละกลุ่มข้อมูลที่ต้องการแบ่งกลุ่มจากวิธีแบบสุ่มกับกระต่าย

ขั้นตอนที่ 2 คำนวณหาค่าคาดหวังจาก

$$Q(\theta, \theta^m) = E[\log g(Y/\theta)/X, \theta^m] \quad (2.54)$$

ขั้นตอนที่ 3 เลือก θ^{m+1} ที่ทำให้ $Q(\theta, \theta^m)$ มีค่ามากที่สุด

ขั้นตอนที่ 4 กำหนดให้ $\theta = \theta^{m+1}$ และวนซ้ำในขั้นตอนที่ 2 จนกว่าจะลู่เข้า

เมื่อ Y คือชุดของข้อมูลบริบูรณ์และมีชุดข้อมูลไม่บริบูรณ์ (X) รวมอยู่ด้วย m คือรอบของการวนซ้ำ และคำนวณค่าพารามิเตอร์ θ ในแต่ละรอบของการวนซ้ำได้จากสมการต่อไปนี้

$$w_i^{m+1} = \frac{1}{N} \sum_{j=1}^N \frac{w_i^m f_i(x_j | \mu_i^m, \Sigma_i^m)}{g(x_j | \theta^m)} \quad (2.55)$$

$$\mu_i^{m+1} = \frac{1}{n_i^m} \sum_{j=1}^N \frac{w_i^m f_i(x_j | \mu_i^m, \Sigma_i^m)}{g(x_j | \theta^m)} x_j \quad (2.56)$$

$$\Sigma_i^{m+1} = \frac{1}{n_i^m} \sum_{j=1}^N \frac{w_i^m f_i(x_j | \mu_i^m, \Sigma_i^m)}{g(x_j | \theta^m)} (x_j - \mu_i^m)(x_j - \mu_i^m)^T \quad (2.57)$$

โดยที่ $n_i^m = \sum_{j=1}^N \frac{w_i^m f_i(x_j | \mu_i^m, \Sigma_i^m)}{g(x_j | \theta^m)} \quad (2.58)$

เมื่อ w_i^m คือค่าถ่วงน้ำหนักของการแจกแจงแบบเกาส์ที่ i ในรอบที่ m

μ_i^m คือค่าเฉลี่ยของการแจกแจงแบบเกาส์ที่ i ในรอบที่ m

Σ_i^m คือค่าความแปรปรวนของการแจกแจงแบบเกาส์ที่ i ในรอบที่ m

n_i^m คือจำนวนของข้อมูลที่อยู่ในการแจกแจงแบบเกาส์ที่ i ในรอบที่ m

x_j คือข้อมูลในชุดฝึกฝน

N คือจำนวนของข้อมูลในชุดฝึกฝน

สมการที่ (2.55) ถึง (2.58) เป็นสมการที่ใช้การคำนวณค่าความน่าจะเป็นจริงของแต่ละจุดข้อมูลกับค่าพารามิเตอร์ในการจำลองการแจกแจงแบบเกาส์ของแต่ละกลุ่ม $w_i^m f_i(x_j | \mu_i^m, \Sigma_i^m)$ สรุปได้ว่าขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุดคำนวณค่าพารามิเตอร์ต่างๆ ของการแจกแจงแบบเกาส์ใหม่จนกว่าจะได้ค่าลอการิทึมความน่าจะเป็นจริงโดยรวมลู่เข้า ซึ่งหมายถึงความแตกต่างของค่าลอการิทึมความน่าจะเป็นจริงโดยรวมในรอบการวนซ้ำก่อนหน้านั้นกับค่าลอการิทึมความน่าจะเป็นจริงโดยรวมในรอบปัจจุบันมีค่าน้อยกว่าจุดเริ่มเปลี่ยนที่กำหนดไว้

2.4 แบบจำลองฮิดเดนมาร์คอฟแบบดิสครีต (Discrete Hidden Markov Models)

แบบจำลองฮิดเดนมาร์คอฟเป็นแบบจำลองทางสถิติ (Statistical Model) คือการใช้วิธีการทางสถิติและความน่าจะเป็นมาใช้ในจำแนกรูปแบบ โดยอาศัยคุณสมบัติทางสถิติของสัญญาณในการแยกแยะสัญญาณ มีงานวิจัยจำนวนมากที่นิยมใช้แบบจำลองฮิดเดนมาร์คอฟแบบดิสครีตในการรู้จำเสียงพูดเนื่องจากเป็นแบบจำลองที่ใช้เทคนิคความน่าจะเป็นจากการศึกษาอนุกรมของเวลาแบบไม่ต่อเนื่องซึ่งตรงกับลักษณะของสัญญาณเสียงพูดที่มีคุณสมบัติเปลี่ยนแปลงตามเวลา (Rabiner, 1989; Huang, 1989; Zhang, 1995)

ค่าความน่าจะเป็นที่ออกจากแบบจำลองนี้เป็นค่าความน่าจะเป็นระหว่างลำดับของสถานะ (State Sequence) ของแบบจำลองกับค่าสังเกตของอนุกรมเวลา ทำให้ผลของการจำลองนี้เป็นกระบวนการพินสุ่ม (Stochastic Process) ข้อนกับกระบวนการพินสุ่มที่ไม่สามารถสังเกตได้ เนื่องจากว่าลำดับของสถานะไม่สามารถสังเกตได้จึงเป็นที่มาของคำว่า "ฮิดเดน" (Hidden)

แบบจำลองฮิดเดนมาร์คอฟได้ใช้พื้นฐานของลูกโซ่มาร์คอฟ (Markov Chain) ในการจำลองการเปลี่ยนแปลงค่าทางสถิติที่ได้จากค่าสังเกตของสัญญาณเสียงพูด แบบจำลองฮิดเดนมาร์คอฟจึงเป็นแบบจำลองที่ใช้พารามิเตอร์ในการจำลอง (Parametric Model) ขั้นตอนกระบวนการในแบบจำลองฮิดเดนมาร์คอฟเรียกว่า "กระบวนการมาร์คอฟ" (Markov Process) แบบจำลองฮิดเดนมาร์คอฟสามารถแบ่งตามลักษณะการนิยามการแจกแจงความน่าจะเป็นของสัญลักษณ์ของค่าสังเกตได้เป็น 3 ชนิด (Huang, 1992) คือแบบจำลองฮิดเดนมาร์คอฟแบบดิสครีต (Discrete Hidden Markov Models, DHMM) แบบจำลองฮิดเดนมาร์คอฟแบบต่อเนื่อง (Continuous Hidden Markov Models, CHMM) และแบบจำลองฮิดเดนมาร์คอฟแบบกึ่งต่อเนื่อง (Semi-Continuous Hidden Markov Models, SCHMM) ซึ่งมีลักษณะเด่นและด้อยแตกต่างกันไปตามแต่ลักษณะการใช้งาน เนื่องจากงานวิจัยนี้ได้เลือกใช้แบบจำลองฮิดเดนมาร์คอฟแบบดิสครีตจึงขอลำถึงเฉพาะนิยามและขั้นตอนวิธีการที่เกี่ยวข้องกับแบบจำลองนี้เท่านั้น

2.4.1 กระบวนการมาร์คอฟ

กระบวนการมาร์คอฟคือกระบวนการเฟ้นสุ่มซ้อนกระบวนการเฟ้นสุ่ม ที่ไม่สามารถสังเกตลูกโซ่มาร์คอฟได้ โดยนิยามให้เป็นเมตริกซ์ของการเปลี่ยนแปลงสถานะ และแต่ละสถานะของลูกโซ่มาร์คอฟจะถูกแทนด้วยการแจกแจงความน่าจะเป็นขออกแบบดิสครีต (Discrete Output Probability Distribution) ดังนั้นกระบวนการเฟ้นสุ่มถูกอธิบายโดยกระบวนการมาร์คอฟลำดับที่ j เพื่อแสดงลักษณะบางอย่างที่มีความน่าจะเป็นขนาดใหญ่ที่มักเกิดขึ้นในภาษาที่ใช้พูด ซึ่งถูกรวบรวมโดยคุณสมบัติของมาร์คอฟ (Markov Property) คือทุกๆ ลำดับของเหตุการณ์ในโดเมนทางเวลาขึ้นอยู่กับเงื่อนไขความหนาแน่นของความน่าจะเป็นของเหตุการณ์ในปัจจุบันกับเหตุการณ์ในอดีตทั้งหมด และเหตุการณ์ในปัจจุบันขึ้นอยู่กับเหตุการณ์ที่เกิดขึ้นบ่อยที่สุด j ครั้งเท่านั้น กระบวนการที่เป็นไปตามคุณสมบัติมาร์คอฟถูกเรียกว่า "กระบวนการมาร์คอฟ"


ยกตัวอย่างของกระบวนการมาร์คอฟลำดับที่หนึ่งอย่างง่าย กำหนดให้สัญลักษณ์ 3 ตัวอักษรคือ a, b, c และให้ค่าความน่าจะเป็นของสัญลักษณ์ a ที่ตามด้วยทุกตัวอักษรเป็น $1/3$ ให้ค่าความน่าจะเป็นของสัญลักษณ์ b ที่ตามด้วย b เป็น $1/2$ และตามด้วยสัญลักษณ์อื่นๆ เป็น $1/4$ และให้ค่าความน่าจะเป็นของสัญลักษณ์ c ที่ตามด้วย c เป็น $1/2$ และตามด้วย a, b เป็น $1/4$ เพราะฉะนั้นสรุปได้ว่า

$$\Pr(a|a) = \frac{1}{3}, \Pr(b|a) = \frac{1}{3}, \Pr(c|a) = \frac{1}{3}$$

$$\Pr(a|b) = \frac{1}{4}, \Pr(b|b) = \frac{1}{2}, \Pr(c|b) = \frac{1}{4}$$

$$\Pr(a|c) = \frac{1}{4}, \Pr(b|c) = \frac{1}{4}, \Pr(c|c) = \frac{1}{2}$$

และเขียนเป็นกราฟการเปลี่ยน (Transition Graph) เพื่อแสดงให้เห็นกระบวนการมาร์คอฟดังในรูปที่ 2.9 ในกรณีนี้เห็นได้ว่ามีสถานะของแบบจำลองเท่ากับ 3 คือ a, b, c ที่เป็นรูปวงกลม



รูปที่ 2.9 กระบวนการมาร์คอฟที่มี 3 สถานะ (Zhang, 1996)

จากรูปที่ 2.9 เส้นแต่ละเส้นคือการเปลี่ยนจากสถานะหนึ่งไปสถานะอื่นที่มีค่าความน่าจะเป็นของการเปลี่ยนคือตัวเลขที่อยู่ข้างๆ เส้น ตัวอย่างเช่น $Pr(a|b)$ คือเส้นที่ลากจากสถานะ b ไปยังสถานะ a และมีความน่าจะเป็นของการเปลี่ยนเท่ากับ $1/4$ จากรูปเห็นได้ว่าแต่ละสถานะมีเส้นลากออกและลากเข้าอย่างละ 3 เส้น ถ้าใช้แบบจำลองมาร์คอฟนี้ในการทำนายสภาพอากาศ โดยกำหนดให้สถานะ a มีข้อมูลออกเป็นแดดออก สถานะ b มีข้อมูลออกเป็นเมฆมากและสถานะ c มีข้อมูลออกเป็นฝนตก ถ้าให้วันนี้เป็นวันที่แดดออกหมายความว่าโอกาสที่พรุ่งนี้สภาพอากาศจะมีแดดออก เมฆมากหรือฝนตกมีโอกาสเท่ากันๆ แต่ถ้าวันนี้สภาพอากาศเป็นเมฆมากหรือฝนตกโอกาสที่พรุ่งนี้จะมีสภาพอากาศเหมือนเดิมคือร้อยละ 50 และมีโอกาสเพียง 1 ใน 4 ที่วันพรุ่งนี้จะมีสภาพอากาศเป็น 2 อย่างที่เหลือ ดังนั้นกระบวนการเห็นสุ่มของการทำนายสภาพอากาศสามารถอธิบายได้อย่างคร่าวๆ ด้วยกระบวนการมาร์คอฟ

สมมติให้สถานะ a, b และ c ถูกแทนด้วยหมายเลข 1 2 และ 3 ฉะนั้นกราฟการเปลี่ยนในรูปที่ 2.9 สามารถเขียนให้อยู่ในรูปเมตริกซ์ เมื่อสมาชิกของเมตริกซ์ a_{ij} คือความน่าจะเป็นของการเปลี่ยนจากสถานะปัจจุบัน i ไปยังสถานะต่อไป j เมตริกซ์การเปลี่ยน (A) คือ

$$A = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/4 & 1/2 & 1/4 \\ 1/4 & 1/4 & 1/2 \end{bmatrix} \quad (2.59)$$

จากสมการที่ (2.59) แสดงให้เห็นว่าการบวกสมาชิกในแต่ละแถวภายในเมตริกซ์การเปลี่ยนจะได้เท่ากับ 1 เสมอ

สรุปได้ว่าแบบจำลองมาร์คอฟใช้การศึกษาค่าสังเกตที่อยู่ในรูปของอนุกรมของเวลาแบบไม่ต่อเนื่อง ลำดับของสถานะถูกสังเกตได้จากแบบจำลองมาร์คอฟ เช่น สภาพอากาศ (แดดออก เมฆมาก หรือฝนตก) เป็นต้น อย่างไรก็ตามแบบจำลองถูกจำกัดให้ใช้กับเฉพาะปัญหาที่สนใจเท่านั้น ในแบบจำลองฮิดเดนมาร์คอฟมีข้อมูลออกของแต่ละสถานะสอดคล้องกับการแจกแจงความน่าจะเป็นที่ข้อมูลออก ซึ่งถูกแทนที่ด้วยเหตุการณ์ที่จะเกิดขึ้น ความน่าจะเป็นของข้อมูลออกได้มาจากลำดับสถานะของแบบจำลองกับอนุกรมทางเวลาของค่าสังเกต โดยลำดับของสถานะไม่สามารถสังเกต

2.4.2 นิยามของแบบจำลองฮิดเดนมาร์คคอฟ

เพื่อให้อธิบายแบบจำลองฮิดเดนมาร์คคอฟและให้คำจำกัดความของค่าพารามิเตอร์ต่างๆ ดังต่อไปนี้

- (1) N คือจำนวนของสถานะที่อยู่ในแบบจำลอง
- (2) L คือจำนวนสัญลักษณ์ของค่าสังเกต
- (3) S คือเซตของสถานะ $\{s\}$ เช่นสถานะ i ที่เวลา t สามารถเขียนได้ดังนี้ $s_t = i$
- (4) $v = \{v_1, v_2, v_3, \dots, v_L\}$ คือเซตแบบไม่ต่อเนื่องของสัญลักษณ์ของค่าสังเกตที่เป็นไปได้ ซึ่ง O_t คือสัญลักษณ์ของค่าสังเกต

(5) A คือการแจกแจงความน่าจะเป็นในการเปลี่ยนแปลงสถานะ (State Transition Probability Distribution)

$$A = \{a_{ij} \mid a_{ij} = \Pr(s_{t+1} = j \mid s_t = i)\}, \quad 1 \leq i, j \leq N \quad (2.60)$$

เมื่อ a_{ij} คือความน่าจะเป็นในการเปลี่ยนสถานะ i ไปสถานะ j

(6) B คือการแจกแจงความน่าจะเป็นของสัญลักษณ์ของค่าสังเกต (Observation Symbol Probability Distribution)

$$B = \{b_j(O_t) \mid b_j(O_t) = \Pr(O_t = j \mid s_t = j)\} \quad (2.61)$$

แต่ละสถานะ B จะสอดคล้องกับความน่าจะเป็นของข้อมูลออก ในแบบจำลองฮิดเดนมาร์คคอฟแบบดิสครีตหมายถึงความน่าจะเป็นที่ได้จากสัญลักษณ์ที่เป็นแบบไม่ต่อเนื่อง v_k ในสถานะ j ซึ่งเขียนใหม่ได้เป็น

$$b_j(k) = \Pr(v_k \mid s_t = j) \quad \text{เมื่อ } 1 \leq j \leq N \text{ และ } 1 \leq k \leq L \quad (2.62)$$

(7) π คือการแจกแจงสภาวะเริ่มต้น (Initial State Distribution)

$$\pi = \{\pi_i \mid \pi_i = \Pr(s_1 = i)\}, \quad 1 \leq i \leq N \quad (2.63)$$

โดยการกำหนดค่าที่เหมาะสมให้กับพารามิเตอร์ N, L, A, B, π ของแบบจำลองฮิดเดนมาร์คคอฟที่ใช้ในการกำเนิดลำดับค่าสังเกต

$$O = O_1, O_2, O_3, \dots, O_T \quad (2.64)$$

เมื่อแต่ละค่าสังเกต O_t เป็นสัญลักษณ์ที่ได้จาก v และ T เป็นจำนวนค่าสังเกตทั้งหมดที่มีในลำดับ โดยมีขั้นตอนวิธีการกำเนิดค่าสังเกตดังนี้

ขั้นตอนที่ 1 เลือกสถานะเริ่มต้น $s_1 = i$ ที่สัมพันธ์กับการแจกแจงสภาวะเริ่มต้น π

ขั้นตอนที่ 2 กำหนดให้ $t = 1$

- ขั้นตอนที่ 3 เลือก $O_i = v_k$ ที่สัมพันธ์กับการแจกแจงความน่าจะเป็นของสัญลักษณ์ในสถานะ i เช่น $b_i(k)$
- ขั้นตอนที่ 4 เปลี่ยนไปยังสถานะใหม่ $s_{t+1} = j$ ที่สัมพันธ์กับการแจกแจงความน่าจะเป็นในการเปลี่ยนแปลงสถานะสำหรับสถานะ i
- ขั้นตอนที่ 5 กำหนดให้ $t = t + 1$ แล้ววนซ้ำขั้นตอนที่ 3 ใหม่ถ้า $t < T$ นอกเหนือจากนี้ให้ยุติกระบวนการ

ขั้นตอนดังกล่าวนี้สามารถใช้เพื่อกำเนิดค่าสังเกตและเป็นแบบจำลองเพื่อบอกถึงความเหมาะสมในการกำเนิดลำดับค่าสังเกตด้วยแบบจำลองฮิดเดนมาร์คคอฟ ดังนั้นการกำหนดคุณสมบัติเฉพาะของแบบจำลองฮิดเดนมาร์คคอฟต้องการคุณสมบัติเฉพาะของพารามิเตอร์ของแบบจำลองสองค่า (N และ L) คือคุณสมบัติเฉพาะของสัญลักษณ์ของค่าสังเกต และคุณสมบัติเฉพาะของการวัดค่าความน่าจะเป็นได้แก่ A, B และ π โดยเขียนอยู่ในรูปแบบอย่างย่อเพื่อบ่งบอกชุดของพารามิเตอร์ที่สมบูรณ์ของแบบจำลองดังนี้

$$\lambda = (A, B, \pi) \quad (2.65)$$

2.4.3 ขั้นตอนวิธีการพื้นฐานของแบบจำลองฮิดเดนมาร์คคอฟ

จากนิยามของแบบจำลองฮิดเดนมาร์คคอฟในหัวข้อที่แล้ว เห็นได้ว่าการประยุกต์แบบจำลองเพื่อใช้งานนั้นต้องแก้ปัญหาพื้นฐานสามข้อที่เกิดขึ้น โดยมีรายละเอียดของปัญหาดังนี้

- (1) ปัญหาการประเมินค่า (Evaluation Problem) โดยกำหนดให้ลำดับค่าสังเกต $O = O_1, O_2, O_3, \dots, O_T$ และพารามิเตอร์ของแบบจำลอง $\lambda = (A, B, \pi)$ เพื่อคำนวณหาความน่าจะเป็นของลำดับค่าสังเกต $\Pr(O | \lambda)$ ตามแบบจำลองที่กำหนดให้ได้อย่างไร
- (2) ปัญหาการประมาณค่า (Estimation Problem) กำหนดให้ลำดับค่าสังเกต O จะปรับค่าพารามิเตอร์ของแบบจำลอง $\lambda = (A, B, \pi)$ อย่างไรเพื่อให้ค่าความน่าจะเป็นของลำดับค่าสังเกต $\Pr(O | \lambda)$ มีค่ามากที่สุด
- (3) ปัญหาการถอดรหัส (Decoding Problem) กำหนดให้ลำดับค่าสังเกต O และพารามิเตอร์ของแบบจำลอง $\lambda = (A, B, \pi)$ แล้วเลือกลำดับสถานะ $S = S_1, S_2, S_3, \dots, S_T$ ให้สอดคล้องและเหมาะสมที่สุดกับแบบจำลองที่กำหนดให้ได้อย่างไร

ปัญหาข้อที่ 1 เป็นการหาค่าความน่าจะเป็นของลำดับค่าสังเกตของแบบจำลอง โดยกำหนดให้ลำดับค่าสังเกตและพารามิเตอร์ของแบบจำลองมาให้ ซึ่งเป็นการแสดงว่าแบบจำลองที่กำหนดให้เข้าคู่กับลำดับค่าสังเกตที่ให้มาได้ดีแค่ไหน ตัวอย่างเช่น ในกรณีที่พิจารณาเลือกกระหว่างแบบจำลองหลายแบบกับลำดับค่าสังเกตที่ให้มา การแก้ปัญหาข้อที่ 1 จะทำให้เราได้แบบจำลองที่เข้าคู่กับลำดับค่าสังเกตได้ดีที่สุด

ปัญหาข้อที่ 2 คือการทำให้พารามิเตอร์ของแบบจำลองเหมาะสมที่สุด เพื่ออธิบายลำดับค่าสังเกตได้ดีที่สุด ลำดับค่าสังเกตที่ใช้ในการปรับพารามิเตอร์ของแบบจำลองเรียกว่า “ลำดับฝึกฝน” (Training Sequence) เนื่องจากถูกใช้ในการฝึกฝนแบบจำลองฮิดเดนมาร์คอฟ การแก้ปัญหในการฝึกฝนนี้จะช่วยให้ปรับแต่งพารามิเตอร์ของแบบจำลองให้เหมาะสมมากที่สุดกับข้อมูลฝึกฝนที่สังเกตได้

ปัญหาข้อที่ 3 เป็นความพยายามที่จะเปิดเผยส่วนที่แบบจำลองปิดบังไว้ เพื่อหาลำดับสถานะที่ถูกต้อง ในกรณีของแบบจำลองที่ด้อยประสิทธิภาพทำให้ไม่สามารถหาลำดับสถานะที่ถูกต้องได้ ดังนั้นในทางปฏิบัติจึงต้องใช้กฎเกณฑ์ที่เหมาะสมที่สุดในการแก้ปัญหานี้แทนที่จะทำได้

ขั้นตอนวิธีการไปหน้าและย้อนกลับ (Forward-Backward Algorithm)

ขั้นตอนวิธีการไปหน้าและย้อนกลับเป็นวิธีการคำนวณหาความน่าจะเป็นของค่าสังเกตอย่างตรงไปตรงมาที่สุด โดยหาค่าทุกลำดับสถานะที่มีความยาว T ที่เป็นไปได้ทั้งหมดตามลำดับ เมื่อ T คือจำนวนของค่าสังเกต สมมติให้ลำดับสถานะมีจำกัดดังนี้

$$S = s_1, s_2, s_3, \dots, s_T \quad (2.66)$$

ความน่าจะเป็นของลำดับค่าสังเกต O คือ

$$\Pr(O | S, \lambda) = b_{s_1}(O_1)b_{s_2}(O_2)\dots b_{s_T}(O_T) \quad (2.67)$$

ความน่าจะเป็นของแต่ละสถานะ S คือ

$$\begin{aligned} \Pr(S | \lambda) &= \pi_{s_1} a_{s_1 s_2} a_{s_2 s_3} \dots a_{s_{T-1} s_T} \\ &= a_{s_0 s_1} a_{s_1 s_2} a_{s_2 s_3} \dots a_{s_{T-1} s_T} \end{aligned} \quad (2.68)$$

เมื่อให้ π_{s_1} แทนด้วย $a_{s_0 s_1}$

ความน่าจะเป็นร่วมระหว่าง O และ S เป็นผลคูณของสมการ 2 สมการข้างต้นดังนี้

$$\Pr(O, S | \lambda) = \Pr(O | S, \lambda)\Pr(S | \lambda) \quad (2.69)$$

ความน่าจะเป็น $\Pr(O | \lambda)$ คือผลรวมของสมการที่ (2.69) ของลำดับสถานะที่เป็นไปได้

ทั้งหมดดังนี้

$$\begin{aligned} \Pr(O | \lambda) &= \sum_{\text{all } S} \Pr(O | S, \lambda)\Pr(S | \lambda) \\ &= \sum_{\text{all } S} \prod_{t=1}^T a_{s_{t-1} s_t} b_{s_t}(O_t) \end{aligned} \quad (2.70)$$

จากสมการที่ (2.70) เป็นการเริ่มการเปลี่ยนจากสถานะเริ่มต้นที่เวลา $t = 1$ มีความน่าจะเป็น $a_{s_0 s_1}(\pi_{s_1})$ กำเนิดสัญลักษณ์ O_1 และมีความน่าจะเป็นขาออกคือ $b_{s_1}(O_1)$ โดยสอดคล้องกับสถานะ s_1 ไปยังสถานะ s_2 ที่มีความน่าจะเป็นการเปลี่ยนคือ $a_{s_1 s_2}$ กำเนิดสัญลักษณ์ O_2 และมีความน่าจะเป็นขาออกคือ $b_{s_2}(O_2)$ ที่สอดคล้องกับสถานะ s_2 จะกระทำต่อไปเรื่อยๆ จนถึงการเปลี่ยนสุดท้ายจากสถานะ s_{T-1} ไปยังสถานะ s_T ที่มีความน่าจะเป็นการเปลี่ยนคือ $a_{s_{T-1} s_T}$ และความน่าจะเป็นขาออกคือ $b_{s_T}(O_T)$ กำเนิดสัญลักษณ์ O_T

ภาวะในกระบวนการคำนวณที่กล่าวมานั้นมีประมาณ $O(N^T)$ ครั้ง ที่ทุกๆ เวลา $t=1,2,\dots,T$ และ N คือสถานะที่เป็นไปได้ที่จะเข้าถึง ขั้นตอนวิธีการที่มีประสิทธิภาพในการคำนวณจากคุณลักษณะดังกล่าวเรียกว่า "ขั้นตอนวิธีการไปหน้าและย้อนกลับ" แบ่งได้เป็นสองขั้นตอนคือขั้นตอนวิธีการไปหน้าและขั้นตอนวิธีการย้อนกลับมีรายละเอียดดังต่อไปนี้

กำหนดให้ตัวแปรไปหน้า $\alpha_t(i)$ คำนวณหาได้ตามสมการที่ (2.71)

$$\alpha_t(i) = \Pr(O_1, O_2, \dots, O_t, s_t = i \mid \lambda) \quad (2.71)$$

$\alpha_t(i)$ คือความน่าจะเป็นของลำดับค่าสังเกตบางส่วนและสถานะ i ที่เวลา t เมื่อกำหนดพารามิเตอร์ของแบบจำลอง λ มาให้ สามารถคำนวณหา $\alpha_t(i)$ ได้ดังต่อไปนี้

ขั้นตอนวิธีการไปหน้า

ขั้นตอนที่ 1 กระบวนการเริ่มต้น

$$\alpha_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (2.72)$$


ขั้นตอนที่ 2 กระบวนการอุปนัย

$$\alpha_t(j) = \left[\sum_{i=1}^N \alpha_{t-1}(i) a_{ij} \right] b_j(O_t), \quad 2 \leq t \leq T, \quad 1 \leq i \leq N \quad (2.73)$$

ขั้นตอนที่ 3 กระบวนการสิ้นสุด

$$\Pr(O \mid \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (2.74)$$

จากกระบวนการข้างต้นนี้ ขั้นตอนแรกเป็นการกำหนดความน่าจะเป็นเริ่มต้นให้กับทุกๆ สถานะของแบบจำลอง และสมการที่ (2.73) แสดงถึงสถานะ j ที่สามารถเข้าถึงได้ที่เวลา t จากสถานะที่เป็นไปได้ i สถานะที่เวลา $t-1$ ดังแสดงในรูปที่ 2.10 เมื่อ $\alpha_{t-1}(i)$ คือความน่าจะเป็นร่วมของค่าสังเกต O_1, O_2, \dots, O_{t-1} ที่สถานะ i ดังนั้นผลคูณของ $\alpha_{t-1}(i) a_{ij}$ คือความน่าจะเป็นร่วมของค่าสังเกต O_1, O_2, \dots, O_{t-1} ที่เข้าถึงสถานะ j ที่เวลา t และผ่านสถานะ i ที่เวลา $t-1$ ผลรวมของผลคูณของสถานะที่เป็นไปได้ทั้งหมด (i) ที่เวลา $t-1$ ได้ผลลัพธ์เป็นความน่าจะเป็นในการเข้าถึงสถานะ j ที่เวลา t โดยผ่านค่าสังเกตบางส่วนก่อนหน้านั้นทั้งหมด และคูณด้วยความน่าจะเป็นของค่าสังเกต ($b_j(O_t)$) ที่เข้าถึงสถานะ j ที่กำเนิด O_t ผลของ $\alpha_t(j)$ คือความน่าจะเป็นของลำดับค่าสังเกตใหม่ O_1, O_2, \dots, O_{t-1} ที่เวลา t และสถานะ j



รูปที่ 2.10 รายละเอียดของตัวแปรในการคำนวณค่าตัวแปรไปหน้า $\alpha_t(i)$ (Rabiner, 1989)

ในขั้นตอนที่ 3 เป็นการคำนวณหา $\Pr(O|\lambda)$ ซึ่งคือผลบวกตัวแปรไปหน้าสุดท้ายที่สถานะสุดท้าย เพราะว่า $\alpha_T(i) = \Pr(O_1, O_2, \dots, O_T, s_T = i | \lambda)$ และการเปลี่ยนสถานะจะสิ้นสุดที่ s_T การคำนวณหา $\alpha_t(i)$ ด้วยขั้นวิธีการไปหน้าใช้คำนวณเพียง $O(N^2T)$ ครั้งเท่านั้น

ในลักษณะเดียวกันกำหนดให้ตัวแปรย้อนกลับ $\beta_t(i)$ คำนวณได้ตามสมการที่ (2.75)

$$\beta_t(i) = \Pr(O_{t+1}, O_{t+2}, \dots, O_T, s_t = i | \lambda) \quad (2.75)$$

ความน่าจะเป็นของลำดับค่าสังเกตบางส่วนจาก $t+1$ ไปสิ้นสุดการสังเกตที่ T เมื่อกำหนดให้สถานะ i ที่เวลา t และพารามิเตอร์ของแบบจำลอง λ จะสามารถหา $\beta_t(i)$ โดยอุปนัยคล้ายๆ กับการหาตัวแปรไปหน้า $\alpha(\cdot)$ ได้ดังต่อไปนี้

ขั้นตอนวิธีการย้อนกลับ

ขั้นตอนที่ 1 กระบวนการเริ่มต้น

$$\beta_T(i) = 1, \quad 1 \leq i \leq N \quad (2.76)$$


ขั้นตอนที่ 2 กระบวนการอุปนัย

$$\beta_t(j) = \sum_{i=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(i), \quad t = T-1, T-2, \dots, 1, \quad 1 \leq i \leq N \quad (2.77)$$

ขั้นตอนที่ 3 กระบวนการสิ้นสุด

$$\Pr(O|\lambda) = \sum_{i=1}^N \pi_i b_i(O_1) \beta_1(i) \quad (2.78)$$

ในขั้นตอนที่ 1 เป็นการกำหนดค่าเริ่มต้นให้กับ $\beta_t(i)$ มีค่าเท่ากับ 1 ทุกสถานะ i ในขั้นตอนที่ 2 เป็นการหา $\beta_t(i)$ ในสถานะ j ที่เวลา t และเปลี่ยนจากสถานะ j ไปทุกๆ สถานะที่เป็นไปได้ที่เวลา $t+1$ มีสัญลักษณ์ค่าสังเกต O_{t+1} และลำดับค่าสังเกตที่สอดคล้องกับสถานะ ความซับซ้อนในการคำนวณหา $\beta_t(i)$ เหมือนกับการคำนวณหา $\alpha_t(i)$



รูปที่ 2.11 รายละเอียดของตัวแปรในการคำนวณค่าตัวแปรย้อนกลับ $\beta_t(i)$ (Rabiner, 1989)


จากที่กล่าวมาทั้งขั้นตอนวิธีการไปหน้าและย้อนหลังใช้เพื่อคำนวณหา $\Pr(O|\lambda)$ เพื่อแก้ปัญหาในข้อที่ 1

ขั้นตอนวิธีการประมาณค่าซ้ำของ Baum-Welch (Baum-Welch Reestimation Algorithm)

ปัญหาที่ยากที่สุดในแบบจำลองฮิดเดนมาร์คอฟคือทำอะไรจึงจะปรับค่าพารามิเตอร์ของแบบจำลอง $\lambda = (A, B, \pi)$ เพื่อทำให้ความน่าจะเป็นของลำดับค่าสังเกตมีค่ามากที่สุดเมื่อกำหนดค่าพารามิเตอร์ของแบบจำลองมาให้ เนื่องจากไม่มีวิธีการที่แน่นอนในหาความน่าจะเป็นดังกล่าวให้ได้มากที่สุด ดังนั้นจึงได้มีการนำขั้นตอนวิธีการแบบวนซ้ำหรือเทคนิคเกรเดียนต์ (Gradient Technique) เพื่อหาค่าที่เหมาะสม ขั้นตอนวิธีการวนซ้ำที่นำมาใช้กับแบบจำลองฮิดเดนมาร์คอฟคือขั้นตอนวิธีการของ Baum-Welch ซึ่งเป็นเทคนิคการหาค่าเหมาะสมเหมือนกับขั้นตอนวิธีการหาค่าคาดหวัง (EM Algorithm) นั้นเอง

กำหนดให้ $\xi_t(i, j)$ เป็นความน่าจะเป็นของการอยู่ในสถานะ i ที่เวลา t และสถานะ j ที่เวลา $t+1$ เมื่อกำหนดให้แบบจำลองและลำดับค่าสังเกตมาให้สามารถหาได้ดังสมการที่ (2.79)

$$\xi_t(i, j) = \Pr(s_t = i, s_{t+1} = j | O, \lambda) \quad (2.79)$$



รูปที่ 2.12 ลำดับของเหตุการณ์ที่ต้องใช้ในการคำนวณเหตุการณ์ร่วมของระบบในสถานะ i ที่เวลา t และสถานะ j ที่เวลา $t+1$ (Rabiner, 1989)

ลำดับของเหตุการณ์ที่นำไปสู่เงื่อนไขที่จำเป็นในสมการที่ (2.79) แสดงในรูปที่ 2.12 จากนิยามของตัวแปรไปหน้าและย้อนกลับสามารถเขียน $\xi_t(i, j)$ ได้ดังนี้

$$\begin{aligned}\xi_t(i, j) &= \frac{\alpha_t(i)b_j(O_{t+1})\beta_{t+1}(j)}{\Pr(O|\lambda)} \\ &= \frac{\alpha_t(i)b_j(O_{t+1})\beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i)b_j(O_{t+1})\beta_{t+1}(j)}\end{aligned}\quad (2.80)$$

เมื่อพจน์เศษเป็น $\Pr(s_t = i, s_{t+1} = j, O|\lambda)$ และหารด้วย $\Pr(O|\lambda)$

กำหนดให้ $\gamma_t(i)$ เป็นความน่าจะเป็นของการอยู่ในสถานะ i ที่เวลา t เมื่อกำหนดลำดับค่าสังเกตและแบบจำลองมาให้ ดังนั้นความสัมพันธ์ระหว่าง $\gamma_t(i)$ และ $\xi_t(i, j)$ เกิดจากผลรวมในสถานะ j ทั้งหมดดังนี้

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (2.81)$$

ถ้าผลรวมของ $\gamma_t(i)$ ในทางเวลาเป็นจำนวนของเวลาที่คาดว่าจะมีเข้าไปในสถานะ i หรือเป็นจำนวนการเปลี่ยนที่คาดว่าจะมีจากสถานะ i ผลรวมของ $\xi_t(i, j)$ บน t คือ $t=1$ ถึง $t=T-1$ เป็นจำนวนการเปลี่ยนที่คาดว่าจะมีจากสถานะ i ไปยังสถานะ j ดังนี้

$$\sum_{t=1}^{T-1} \gamma_t(i) \text{ คือจำนวนการเปลี่ยนที่คาดว่าจะมีจากสถานะ } i \quad (2.82)$$

$$\sum_{t=1}^{T-1} \xi_t(i, j) \text{ คือจำนวนการเปลี่ยนที่คาดว่าจะมีจากสถานะ } i \text{ ไปยังสถานะ } j \quad (2.83)$$

ใช้สมการทั้งสองที่กล่าวมาเพื่อหาวิธีการประมาณค่าพารามิเตอร์ของแบบจำลองฮิดเดน มาร์คอฟที่ไปประกอบด้วย π, A และ B ได้ดังนี้

$$\bar{\pi}_i = \gamma_i(i) \quad (2.84)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (2.85)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1}^{T-1} \eta_{t,j}(k)}{\sum_{t=1}^{T-1} \gamma_t(j)} \quad (2.86)$$

ถ้ากำหนดให้แบบจำลองในปัจจุบันคือ $\lambda = (A, B, \pi)$ เพื่อใช้คำนวณค่าทางด้านขวาของสมการที่ (2.86) ถึง (2.88) และกำหนดให้แบบจำลองที่ประมาณค่าใหม่คือ $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$ ที่อยู่ด้านซ้ายของสมการที่ (2.86) ถึง (2.88) นอกจากนี้สมการทั้งสามยังเป็นไปตามเงื่อนไขดังนี้ แบบจำลองเริ่มต้น λ เป็นตัวกำหนดจุดวิกฤตของฟังก์ชันความน่าจะเป็นจริงในกรณีที่ $\bar{\lambda} = \lambda$ หรือแบบจำลอง $\bar{\lambda}$ มีความน่าจะเป็นจริงมากกว่าแบบจำลอง λ เมื่อ $\Pr(O|\bar{\lambda}) > \Pr(O|\lambda)$ หมายความว่าลำดับค่าสังเกตที่มีความเป็นจริงมากกว่าจะให้กำเนิดแบบจำลองใหม่ $\bar{\lambda}$

จากกระบวนการข้างต้น ถ้ากระทำซ้ำโดยนำ $\bar{\lambda}$ แทนที่ λ และคำนวณการประมาณค่าใหม่เพื่อเป็นการปรับปรุงความน่าจะเป็นของ O ที่ถูกสังเกตจากแบบจำลองจนถึงจุดสิ้นสุดผลลัพธ์สุดท้ายของขั้นตอนวิธีการประมาณค่านี้เรียกว่า "การประมาณความน่าจะเป็นจริงสูงสุดของแบบจำลองฮิดเดนมาร์คอฟ"

สมการในการประมาณค่าคำนวณสามารถหาได้โดยตรงจากการหาค่าสูงสุดของฟังก์ชันเสริมของ Baum บน $\bar{\lambda}$ ดังนี้

$$Q(\lambda, \bar{\lambda}) = \sum_Q \Pr(Q|O, \lambda) \log[\Pr(O, Q|\bar{\lambda})] \quad (2.87)$$

การทำให้ $Q(\lambda, \bar{\lambda})$ มีค่ามากที่สุดเป็นการทำให้ความน่าจะเป็นจริงมีค่าสูงขึ้นด้วย โดยทำให้ฟังก์ชันความน่าจะเป็นจริงเข้าสู่จุดวิกฤตจุดหนึ่งดังนี้

$$\max_{\bar{\lambda}} [Q(\lambda, \bar{\lambda})] \Rightarrow \Pr(O|\bar{\lambda}) \geq \Pr(O|\lambda) \quad (2.88)$$

ขั้นตอนวิธีการประมาณค่าใหม่สามารถแสดงให้เห็นเป็นขั้นตอนวิธีการหาค่าคาดหวังที่มากที่สุด (EM Algorithm) โดยขั้นตอนในการหาค่าคาดหวังคือการคำนวณหาฟังก์ชันเสริม $Q(\lambda, \bar{\lambda})$ และขั้นตอนในการหาค่ามากที่สุดก็คือการหาค่า $Q(\lambda, \bar{\lambda})$ ที่มีค่ามากที่สุดบน $\bar{\lambda}$ นอกจากนี้ขั้นตอนวิธีการประมาณค่าใหม่จะต้องเป็นไปตามเงื่อนไขเฟินสุ่ม (Stochastic Constraint) ของพารามิเตอร์แบบจำลองฮิดเดนมาร์คอฟ ดังต่อไปนี้

$$\sum_{i=1}^N \bar{\pi}_i = 1 \quad (2.89)$$

$$\sum_{j=1}^N \bar{a}_{ij} = 1, \quad 1 \leq i \leq N \quad (2.90)$$

$$\sum_{k=1}^L \bar{b}_j(k) = 1, \quad 1 \leq j \leq N \quad (2.91)$$

ขั้นตอนวิธีการ Viterbi (Viterbi Algorithm)

ขั้นตอนวิธีการ Viterbi เป็นขั้นตอนวิธีการหาลำดับสถานะของแบบจำลองฮิดเดนมาร์คอฟที่ถูกต้องเนื่องจากว่าลำดับสถานะนี้บอกถึงโครงสร้างของแบบจำลอง ค่าเฉลี่ยทางสถิติและลักษณะอื่นๆ ของแบบจำลองที่แสดงได้จากลำดับสถานะ วิธีในการหาลำดับสถานะที่เป็นไปได้เมื่อกำหนดลำดับค่าสังเกตมาให้คือการเลือกสถานะ s_t ด้วยวิธีที่เหมาะสมเพื่อให้ได้เส้นทางที่ดีที่สุดและมีความน่าจะเป็น $\Pr(O, S | \lambda)$ มากที่สุด เทคนิคที่ใช้ในการหาลำดับสถานะที่ดีที่สุดเพียงลำดับเดียวเรียกว่า "ขั้นตอนวิธีการ Viterbi" ซึ่งคล้ายๆ กับขั้นตอนวิธีการเทียบทางเวลาแบบพลวัต (Dynamic Time Warping, DTW) โดยกำหนดให้ลำดับค่าสังเกต $O = \{O_1, O_2, \dots, O_T\}$ และมีลำดับสถานะที่ดีที่สุดคือ $S = \{s_1, s_2, \dots, s_T\}$ กำหนดตัวแปรได้ดังนี้

$$\delta_t(i) = \max_{s_1, s_2, \dots, s_{t-1}} \Pr[s_1, s_2, \dots, s_{t-1} = i, O_1, O_2, \dots, O_{t-1} | \lambda] \quad (2.92)$$

โดยที่ $\delta_t(i)$ เป็นความน่าจะเป็นที่มีค่าสูงสุดของเส้นทางเดียวที่เวลา t ซึ่งเป็นค่าสังเกต t ค่าแรกและสิ้นสุดในสถานะ i ด้วยวิธีอุปนัยดังนี้

$$\delta_{t+1}(j) = \left[\max_i \delta_t(i) a_{ij} \right] \cdot b_j(O_{t+1}) \quad (2.93)$$

ในการเรียกใช้ค่าลำดับสถานะจำเป็นต้องติดตามค่าอาร์กิวเมนต์ที่ทำให้สมการที่ (2.93) มีค่ามากที่สุดสำหรับแต่ละค่า t และ j โดยอาศัยแถวลำดับ $\psi_t(j)$ รายละเอียดของขั้นตอนวิธีการ Viterbi มีดังนี้

ขั้นตอนที่ 1 กำหนดเงื่อนไขเริ่มต้นให้กับทุกๆ สถานะ i

$$\delta_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (2.94)$$

$$\psi_1(i) = 0 \quad (2.95)$$

ขั้นตอนที่ 2 การวนซ้ำ

$$\delta_t(j) = \max_i [\delta_{t-1}(i) a_{ij}] b_j(O_t) \quad (2.96)$$

$$\psi_t(j) = \arg \max_i [\delta_{t-1}(i) a_{ij}] \quad (2.97)$$

ขั้นตอนที่ 3 การสิ้นสุด

$$P^* = \max_{s \in S_T} [\delta_T(s)] \quad (2.98)$$

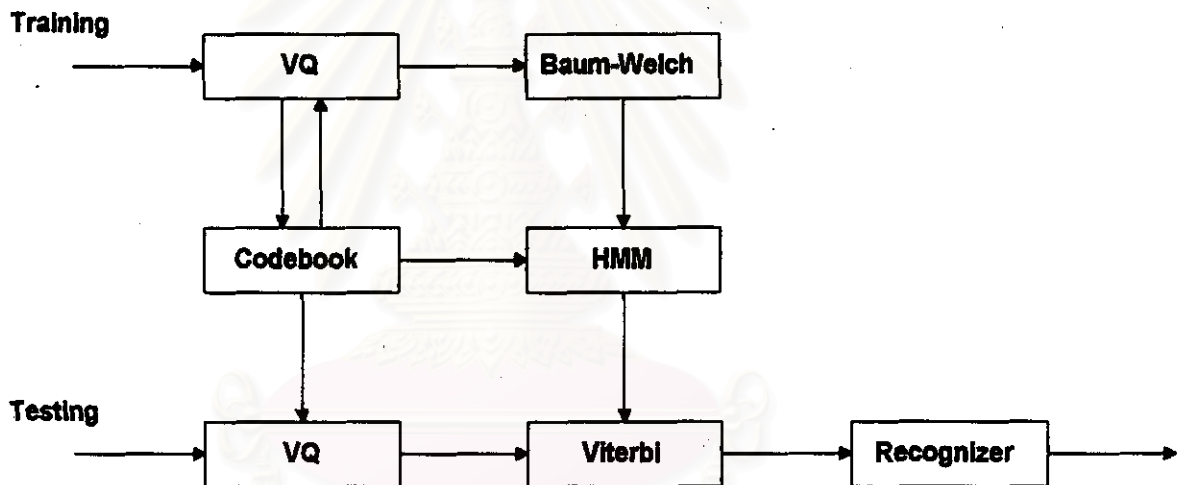
$$s_T^* = \arg \max_{s \in S_T} [\delta_T(s)] \quad (2.99)$$

ขั้นตอนที่ 4 การย้อนกลับเส้นทาง

$$s_t^* = \psi_{t+1}(s_{t+1}^*) , t = T-1, T-2, \dots, 1 \quad (2.100)$$

จากขั้นตอนวิธีการไปหน้าและย้อนกลับที่กล่าวไปก่อนหน้านี้เป็นการหาความน่าจะเป็น $\Pr(O|\lambda)$ ซึ่งความน่าจะเป็นนี้เป็นผลรวมของ $\Pr(O, S|\lambda)$ บนทุกๆ ลำดับสถานะที่เป็นไปได้ S แต่ขั้นตอนวิธีการ Viterbi เป็นเพียงการหาประสิทธิภาพของค่าสูงสุดของความน่าจะเป็น $\Pr(O, S|\lambda)$ ในทุกๆ สถานะ S ดังนั้นจึงมองว่าขั้นตอนวิธีการ Viterbi เป็นขั้นตอนวิธีการในกรณีพิเศษของจากขั้นตอนวิธีการไปหน้าและย้อนกลับ

เมื่อนำขั้นตอนวิธีการที่กล่าวมาใช้แก้ปัญหาพื้นฐานทั้ง 3 ข้อของแบบจำลองฮิดเดนมาร์คอฟแบบดิสครีต และการควอนไทซ์แบบเวกเตอร์มาประยุกต์ใช้งานร่วมกันได้เป็นระบบการรู้จำเสียงพูดดังแสดงในรูปที่ 2.13




รูปที่ 2.13 ระบบการรู้จำเสียงพูดโดยใช้แบบจำลองฮิดเดนมาร์คอฟ (Zhang, 1996)


2.4.4 ประเภทของแบบจำลองฮิดเดนมาร์คอฟ

แบบจำลองฮิดเดนมาร์คอฟส่วนใหญ่เป็นการพิจารณาเพียงกรณีพิเศษของแบบจำลองฮิดเดนมาร์คอฟประเภทเออร์กอดิกมาตรฐาน ซึ่งเป็นแบบจำลองฮิดเดนมาร์คอฟที่ทุกสถานะต่อเชื่อมถึงกันหมด โดยทุกสถานะของแบบจำลองสามารถเข้าถึงสถานะอื่นๆ ได้ในเส้นทางเดียวดังแสดงในรูปที่ 2.14(ก) เมื่อจำนวนสถานะของแบบจำลอง $N = 4$ สถานะและมีคุณสมบัติเฉพาะของสัมประสิทธิ์ a_{ij} มีค่าเป็นบวก จากรูปที่ 2.14(ก) จะได้สมการของค่าสัมประสิทธิ์ a_{ij} ได้ดังนี้

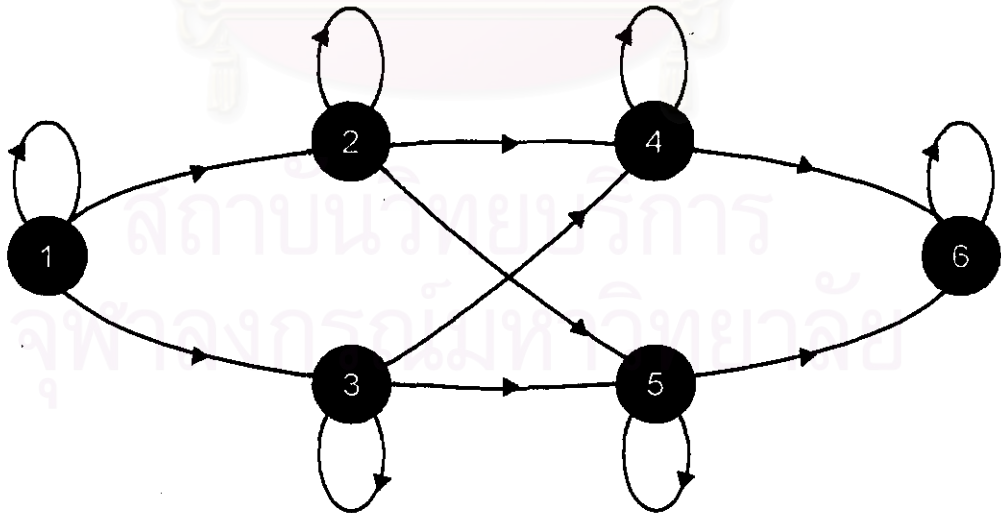
$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} \quad (2.101)$$



(ก)



(ข)



(ค)

รูปที่ 2.14 แบบจำลองฮิดเดนมาร์คอฟ 3 ประเภท (ก) แบบจำลองเออร์กอดิก 4 สถานะ (ข) แบบจำลองซ้ายไปขวา 4 สถานะ (ค) แบบจำลองเส้นทางขนานซ้ายไปขวา 6 สถานะ (Rabiner, 1989)

ในการประยุกต์ใช้งานแบบจำลองฮิดเดนมาร์คอฟกับงานเฉพาะอย่างนั้น ได้มีการเสนอแบบจำลองฮิดเดนมาร์คอฟประเภทอื่นที่เหมาะสมกับคุณสมบัติของสัญญาณเสียงพูดได้ดีกว่าแบบจำลองประเภทเออร์กอดิกมาตรฐาน คือแบบจำลองซ้ายไปขวา (Left-Right Model) หรือแบบจำลอง Bakis ดังแสดงในรูปที่ 2.14(ข) เพราะว่าลำดับสถานะของแบบจำลองมีคุณสมบัติตามเวลา คือเมื่อเวลาเพิ่มขึ้นดัชนีของสถานะจะเพิ่มขึ้นหรืออยู่ที่เดิมเปรียบเสมือนดำเนินจากซ้ายไปขวา ดังนั้นแบบจำลองซ้ายไปขวาก็เหมาะสมในการจำลองสัญญาณที่มีคุณสมบัติเปลี่ยนแปลงตามเวลา เช่น สัญญาณเสียงพูด เป็นต้น

คุณสมบัติพื้นฐานของแบบจำลองฮิดเดนมาร์คอฟประเภทซ้ายไปขวานั้น คือค่าสัมประสิทธิ์ของการเปลี่ยนสถานะต้องมีคุณสมบัติดังนี้

$$a_{ij} = 0, \quad j < i \quad (2.102)$$

จากสมการที่ (2.102) หมายความว่าไม่มีการเปลี่ยนสถานะไปยังสถานะที่มีดัชนีต่ำกว่าดัชนีของสถานะปัจจุบัน และมีความน่าจะเป็นเริ่มต้นมีคุณสมบัติตามสมการที่ (2.103)

$$\pi_i = \begin{cases} 0, & i \neq 1 \\ 1, & i = 1 \end{cases} \quad (2.103)$$

เนื่องจากลำดับสถานะต้องเริ่มต้นจากสถานะที่ 1 และสิ้นสุดในสถานะที่ N ดังนั้นแบบจำลองซ้ายไปขวาต้องเพิ่มเงื่อนไขของสัมประสิทธิ์การเปลี่ยนสถานะ เพื่อไม่ให้เกิดการเปลี่ยนแปลงของดัชนีมากเกินไปดังนี้

$$a_{ij} = 0, \quad j > i + \Delta \quad (2.104)$$

จากรูปที่ 2.14(ข) จะกำหนดให้ $\Delta = 2$ และไม่มีการข้ามสถานะเกินกว่า 2 สถานะ สามารถเขียนการเปลี่ยนสถานะให้อยู่ในรูปเมตริกซ์ได้ดังนี้

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 \\ 0 & a_{22} & a_{23} & a_{24} \\ 0 & 0 & a_{33} & a_{34} \\ 0 & 0 & 0 & a_{44} \end{bmatrix} \quad (2.105)$$

และที่สถานะสุดท้ายของแบบจำลองประเภทซ้ายไปขวามีสัมประสิทธิ์ของการเปลี่ยนสถานะดังสมการต่อไปนี้

$$a_{NN} = 1 \quad (2.106)$$

$$a_{Ni} = 0, \quad i < N \quad (2.107)$$

นอกจากนี้ยังมีแบบจำลองฮิดเดนมาร์คอฟประเภทอื่นๆ ที่เป็นไปได้อีกมากขึ้นอยู่ลักษณะการนำไปประยุกต์ใช้งาน ตัวอย่างดังในรูปที่ 2.14(ค) เป็นแบบจำลองฮิดเดนมาร์คอฟประเภทซ้ายไปขวาต่อขวากันสองชุด ซึ่งแบบจำลองประเภทนี้มีความยืดหยุ่นมากกว่าแบบจำลองประเภทซ้ายไปขวา