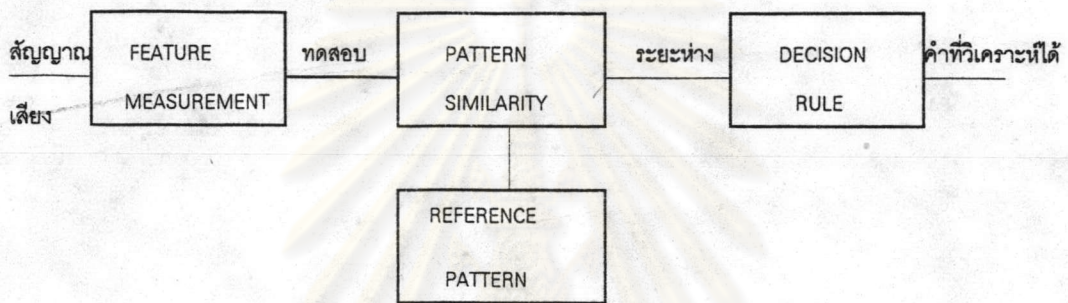




รูปแบบการรู้จำเสียง

ในรูป 2.1 แสดงโมเดลการรู้จำรูปแบบที่สำคัญของระบบการรู้จำเสียงแบบคำโดด (Rabiner and Levinson , 1981) แบ่งเป็น 3 ส่วน



รูป 2.1 โมเดลการรู้จำรูปแบบ

1. Feature measurement
2. Pattern similarity determination
3. Decision rule

โดยที่สัญญาณเข้าโมเดลเป็นคลื่นเสียง ส่วนสัญญาณออกเป็นเสียงวิเคราะห์ ที่ได้จากสัญญาณเข้าโมเดลดังกล่าวมีการใช้กันอย่างแพร่หลาย เนื่องจากเหตุผลหลายประการดังนี้

1. สามารถนำไปใช้ได้กับเสียงที่มีความแตกต่างกันของคำ, ผู้ใช้, feature รวมถึงวิธีที่ใช้ในการวิเคราะห์ และตัดสินใจ
2. ง่ายในการนำไปใช้และปรับปรุง
3. ใช้งานได้ดีในการทดสอบ

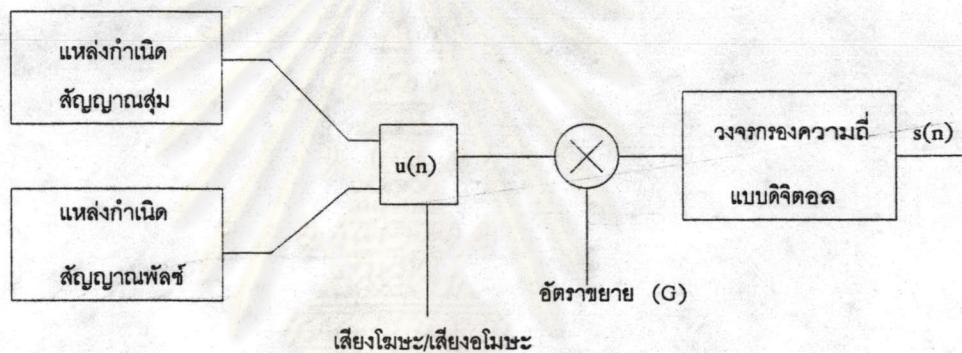
FEATURE MEASUREMENT

เป็นเทคนิคในการแปลงข้อมูลที่มีอยู่มากมายเป็นส่วนเล็กๆ ซึ่งส่วนเล็กๆ ดังกล่าวจะแสดงคุณสมบัติของคลื่นเสียงนั้นๆ โดยวิธีที่ใช้กันอยู่หลายวิธี เช่น Filter Bank-Analysis of Speech ซึ่งใช้วิธีการป้อนสัญญาณผ่าน filter และการประมาณพั่นระเชิงเส้น (Linear Predictive Coding)

### 1 การประมาณพหุเชิงเส้น (Linear Predictive Coding)

เป็นขบวนการทางคณิตศาสตร์ที่ใช้ในการหาเอกลักษณ์ของ ระบบ โดยพิจารณาว่าเสียงเกิดจากผลรวมเชิงเส้น (linear combination) ของสัญญาณที่ทราบค่าแล้ว โดยใช้วิธี กำลังสองน้อยที่สุด (method of least square) ในการเลือกค่าพารามิเตอร์ของระบบ หลักการประมาณพหุเชิงเส้นมีวิธีการใหญ่ 2 วิธี คือ วิธีการหาค่าความแปรปรวนร่วม และวิธีอิตส์สัมพันธ์ วิธี Linear Predictive coding สามารถแสดงคุณสมบัติได้ ใกล้เคียงกับพื้นฐานโมเดลการกำเนิดเสียงของมนุษย์ (Rabiner and Levinson, 1981) ในวิทยานิพนธ์นี้ นำการประมาณพหุเชิงเส้น โดยวิธีอิตส์สัมพันธ์มาหา feature ของเสียง

1.1 หลักการประมาณพหุเชิงเส้น รูป 2.2 เป็นแบบจำลองเสียงการประมวลสัญญาณเสียงพูดในการวิเคราะห์มักจะแบ่งระบบกำเนิด เสียงพูดเป็น 2 ส่วน คือ แหล่งกำเนิดสัญญาณกระตุ้น และท่อการเสียง (สุเอียร์ เกียรติสุนทร, 2525)



รูป 2.2 แสดงแบบจำลองของระบบกำเนิดเสียงพูดแบบดิจิทัล

สามารถเขียนความสัมพันธ์ได้ดังนี้ (Sadaoki Fumi, 1989)

$$H(z) = \frac{S(z)}{U(z)} = \frac{G}{1 - \sum_{i=1}^m a_i z^{-i}} \quad (2.1)$$

สามารถแสดงความสัมพันธ์ของสัญญาณค่า  $X_t$  โดยพิจารณาจากสัญญาณก่อนหน้าจำนวน  $p$  ค่า

$$x_t + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} = \varepsilon_t \quad (2.2)$$

โดย  $\{\varepsilon_t\}$  มีค่ากลางเป็นศูนย์ ค่า variance เป็น  $\sigma^2$



สามารถคาดคะเนสัญญาณค่าถัดไปเมื่อทราบค่าก่อนหน้า  $p$  ค่า

$$\hat{x}_t = -\sum_{i=1}^p \alpha_i x_{t-i} \quad (2.3)$$

จากสมการ (2.2), (2.3)

$$x_t - \hat{x}_t = \varepsilon_t \quad (2.4)$$

ถ้าสมมติ

$$F(z) = -\sum_{i=1}^p \alpha_i z^{-i} \quad (2.5)$$

และ  $\hat{X}(z) \leftrightarrow \hat{x}_t, X(z) \leftrightarrow x_t$  Z-Transform ของสมการ (2.3) สามารถแสดงได้

$$\hat{X}(z) = F(z)X(z) \quad (2.6)$$

ทำการพิจารณาสัมประสิทธิ์  $\{\alpha_i\}$  ที่ทำให้ความคลาดเคลื่อนในการประมาณค่ามีค่าต่ำสุด เมื่อพิจารณาในช่วง  $[t_0, t_1]$  ค่าคลาดเคลื่อนกำลังสองรวมคือ  $\beta$

$$\begin{aligned} \beta &= \sum_{t=t_0}^{t_1} \varepsilon_t^2 \\ &= \sum_{t=t_0}^{t_1} \left( \sum_{i=0}^p \alpha_i x_{t-i} \right)^2 \\ &= \sum_{t=t_0}^{t_1} \sum_{i=0}^p \sum_{j=0}^p \alpha_i \alpha_j x_{t-i} x_{t-j} \end{aligned} \quad (2.7)$$

โดยที่  $\alpha_0 = 1$  และสมมติ

$$c_{ij} = \sum_{t=t_0}^{t_1} x_{t-i} x_{t-j} \quad (2.8)$$

ค่า  $\beta$  สามารถเขียนอีกอย่างได้ว่า

$$\beta = \sum_{i=0}^p \sum_{j=0}^p \alpha_i c_{ij} \alpha_j \quad (2.9)$$

ทำการหาค่าต่ำสุดของ  $\beta$  โดยการหาค่าอนุพันธ์ส่วนย่อยของค่า  $\beta$  และให้เท่ากับศูนย์

$$\frac{\partial \beta}{\partial \alpha_j} = 2 \sum_{i=0}^p \alpha_i c_{ij} = 0 \quad (j = 1, 2, \dots, p) \quad (2.10)$$

ค่าสัมประสิทธิ์  $\{\alpha_i\}$  สามารถหาได้ถ้าเราทราบค่า  $c_{ij}$  ( $i = 0, 1, 2, \dots, p$ ;  $j = 1, 2, \dots, p$ ) จากสมการ (2.8) ได้จากการพิจารณาค่า  $X_t$  จาก  $t_0 - p$  จนถึง  $t_1$  ในการหาค่าตอบ

ในการหาค่าตอบของ sequence  $N$  ที่  $\{X_t\} = \{X_0, X_1, \dots, X_{N-1}\}$  มี 2 กรณีที่ต้องพิจารณาคือ วิธีการแปรปรวนร่วม และวิธีการอัตโนมัติ

วิธีการอัตโนมัติจะทำการพิจารณา  $t_0 = -\infty$  และ  $t_1 = \infty$  โดยการให้  $X_t = 0$  เมื่อ  $t < 0$  และ  $t \geq N$  (Markel, 1972)

$$\begin{aligned} c_{ij} &= \sum_{t=-\infty}^{\infty} x_{t-i} x_{t-j} \\ &= \sum_{t=-\infty}^{\infty} x_t x_{t+|i-j|} \\ &= \sum_{t=0}^{N-1-|i-j|} x_t x_{t+|i-j|} \\ &= r_{|i-j|} \end{aligned} \quad (2.11)$$

ค่า  $\alpha_i$  จะสามารถหาได้จาก

$$\sum_{i=0}^p \alpha_i r_{|i-j|} = 0 \quad (j = 1, 2, \dots, p) \quad (2.12)$$

$$r_\tau = \sum_{t=0}^{N-1-\tau} x_t x_{t+\tau}, (\tau \geq 0) \quad (2.13)$$

จากสมการ (2.13) เราสามารถเขียนอยู่ในรูปของเมตริกซ์ได้คือ

$$\begin{bmatrix} r_0 & r_1 & \dots & r_{p-1} \\ r_1 & r_0 & \dots & \\ \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & \dots & \dots & r_0 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_p \end{bmatrix} = - \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} \quad (2.14)$$

1.2 วิธีออตสัมพันธ์ส่วนย่อย วิธีออตสัมพันธ์ส่วนย่อยหรือวิธี PARCOR (Partial Autocorrelation) เป็นวิธีการหาค่าพารามิเตอร์ ในการประมาณค่าสัญญาณ ด้วยวิธีประมาณฟังก์ชันเชิงเส้นวิธีหนึ่ง โดยใช้คุณสมบัติของผลคูณภายใน (inner product) และความสัมพันธ์เชิงพิภักตฉาก (orthogonal relationship) ของฟังก์ชันพหุคูณ (polynomial function) ในการเลือกค่าพารามิเตอร์ที่ทำให้เกิดความคลาดเคลื่อนต่ำสุด

กำหนดให้  $x_m^+(n)$  เป็นความคลาดเคลื่อนในการประมาณค่าแบบก้าวหน้า (forward prediction) ของสัญญาณ  $\{x(n) | n_0 \leq n \leq n_1\}$  โดยใช้สัมประสิทธิ์ในการกะประมาณค่า  $m$  ตัว  $\{a_{mi} | 1 \leq i \leq m\}$

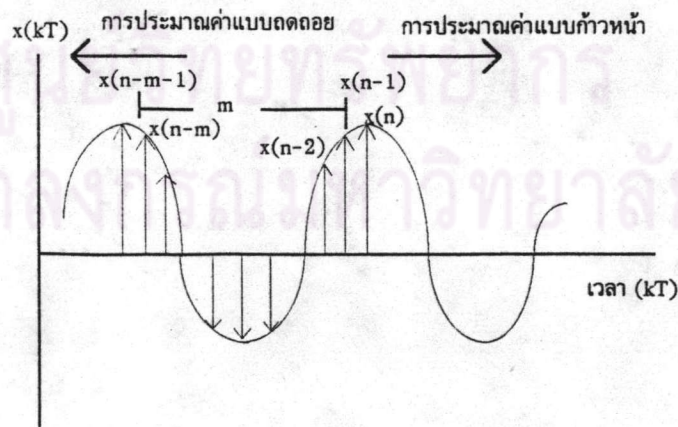
$$x_m^+(n) = x(n) - \left\{ -\sum_{i=1}^m a_{mi} x(n-i) \right\} \quad (2.15)$$

$$= \sum_{i=0}^m a_{mi} x(n-i) \quad \text{เมื่อ } a_{m0} = 1 \quad (2.16)$$

ในทำนองเดียวกันกับความคลาดเคลื่อนในการประมาณค่าแบบถดถอย (backward prediction)  $x_m^-(n)$  ของสัญญาณ  $\{x(n-m-1) | n_0 \leq n \leq n_1\}$  โดยใช้สัมประสิทธิ์ในการกะประมาณค่า  $m$  ตัว  $\{b_{mi} | 1 \leq i \leq m\}$

$$x_m^-(n) = x(n-m-1) - \left\{ -\sum_{i=1}^m b_{mi} x(n-i) \right\} \quad (2.17)$$

$$= \sum_{i=1}^{m+1} b_{mi} x(n-i) \quad \text{เมื่อ } b_{m, m+1} = 1 \quad (2.18)$$



รูป 2.3 การประมาณฟังก์ชันเชิงเส้น

ค่าความคลาดเคลื่อนกำลังสองรวม (total square error) แบบก้าวหน้า  $\alpha_m$  และแบบถดถอย  $\beta_m$  เมื่อ  $m = 1, 2, \dots, M$  ในช่วง  $[n_0, n_1]$  มีค่า

$$\alpha_m = \sum_{n=n_0}^{n_1} \{x_m^+(n)\}^2 \quad (2.19)$$

$$\beta_m = \sum_{n=n_0}^{n_1} \{x_m^-(n)\}^2 \quad (2.20)$$

ขั้นตอนต่อไปในการประมาณพารามิเตอร์เชิงเส้น คือการเลือกค่าสัมประสิทธิ์ในการประมาณค่า  $\{a_{mi}\}$  และ  $\{b_{mi}\}$  ที่ทำให้ค่า  $\alpha_m$  และ  $\beta_m$  มีค่าต่ำสุด

1.3 สัมประสิทธิ์ PARCOR การเลือกค่าพารามิเตอร์ของระบบกำเนิดเสียงโดยวิธี PARCOR คือการหาค่าของสัมประสิทธิ์  $\{k_m | 1 \leq m \leq M\}$  ที่ทำให้สามารถแสดงฟังก์ชันพหุคูณ  $A_m(z)$  ในรูปผลรวมเชิงเส้นของ  $A_{m-1}(z)$  และ  $B_{m-1}(z)$  โดยเริ่มจาก

$$A_0(z) = 1 \quad (2.21)$$

และ

$$B_0(z) = z^{-1} \quad (2.22)$$

และสำหรับค่า  $m$  ใดๆ ที่มากกว่าศูนย์

$$A_m(z) = A_{m-1}(z) + k_m B_{m-1}(z) \quad (2.23)$$

ผลคูณภายใน

$$\langle A_m(z), z^{-m} \rangle = \langle A_{m-1}(z), z^{-m} \rangle + k_m \langle B_{m-1}(z), z^{-m} \rangle \quad (2.24)$$

จากคุณสมบัติเชิงพิกัดฉากของฟังก์ชันพหุคูณ

$$\langle A_m(z), z^{-m} \rangle = 0 \quad (2.25)$$

$$\begin{aligned} \langle A_{m-1}(z), z^{-m} \rangle &= \langle A_{m-1}(z), B_{m-1}(z) \rangle \\ &= \langle 1, B_{m-1}(z) \rangle \end{aligned} \quad (2.26)$$

และ

$$\begin{aligned} \langle B_{m-1}(z), z^{-m} \rangle &= \langle B_{m-1}(z), B_{m-1}(z) \rangle \\ &= \|B_{m-1}(z)\|^2 \\ &= \beta_{m-1} \end{aligned} \quad (2.27)$$

แทนค่าในสมการ (2.24)

$$\begin{aligned}
 k_m &= \frac{-1}{\beta_{m-1}} \langle A_{m-1}(z), B_{m-1}(z) \rangle \\
 &= \frac{-1}{\beta_{m-1}} \left\{ \sum_{n=n_0}^{n_1} \sum_{i=0}^{m-1} a_{mi} x(n-i) \right\} \\
 &= \left\{ \sum_{n=n_0}^{n_1} \sum_{j=0}^m b_{mj} x(n-j) \right\} \\
 &= \frac{-1}{\beta_{m-1}} \left\{ \sum_{n=n_0}^{n_1} x_m^+(n) \right\} \left\{ \sum_{n=n_0}^{n_1} x_m^-(n) \right\} \quad (2.28)
 \end{aligned}$$

จาก

$$A_m(z) = \sum_{i=0}^m a_{mi} z^{-i} \quad (2.29)$$

$$\begin{aligned}
 z^{-(m+1)} A_m(z^{-1}) &= z^{-(m+1)} \sum_{i=0}^m a_{mi} z^i \\
 &= \sum_{i=0}^m a_{mi} z^{i-m-1} \quad (2.30)
 \end{aligned}$$

ให้  $j = -(i-m-1)$

$$z^{-(m+1)} A_m(z^{-1}) = \sum_{j=1}^{m+1} a_{m, m+1-j} z^{-j} \quad (2.31)$$

เมื่อ

$$b_{mj} = a_{m, m+1+j} \quad (2.32)$$

$$B_m(z) = z^{-(m+1)} A_m(z^{-1}) \quad (2.33)$$

และ

$$A_m(z) = z^{-(m+1)} B_m(z^{-1}) \quad (2.34)$$

จากสมการ (2.23)

$$z^{-(m+1)} A_m(z^{-1}) = z^{-1} \left\{ z^{-m} A_{m-1}(z^{-1}) + k_m z^{-m} B_{m-1}(z^{-1}) \right\} \quad (2.35)$$

$$B_m(z) = z^{-1} \left\{ k_m A_{m-1}(z) + B_{m-1}(z) \right\} \quad (2.36)$$

จากสมการ (2.16) และ (2.18)

$$X_m^+(z) = A_m(z) X(z)$$

$$X_m^-(z) = B_m(z)X(z) \quad (2.37)$$

แทนค่าทั้งสองลงในสมการ (2.23) และ (2.36)

$$\begin{aligned} X_m^+(z) &= X_{m-1}^+(z) + k_m X_{m-1}^-(z) \\ X_m^-(z) &= z^{-1} \{ k_m X_{m-1}^+(z) + X_{m-1}^-(z) \} \end{aligned} \quad (2.38)$$

หรือแสดงความสัมพันธ์ในเชิงเวลา

$$\begin{aligned} x_m^+(z) &= x_{m-1}^+(n) + k_m x_{m-1}^-(n) \\ x_m^-(z) &= k_m x_{m-1}^+(n-1) + x_{m-1}^-(n-1) \end{aligned} \quad (2.39)$$

จากความสัมพันธ์ทั้งหมดที่กล่าวมาทำให้สามารถหาค่าพารามิเตอร์ของการวิเคราะห์สัญญาณ ซึ่งต่อไปจะเรียกพารามิเตอร์ที่ได้ด้วยวิธีนี้ว่า สัมประสิทธิ์ PARCOR หรือสัมประสิทธิ์การสะท้อน (reflection coefficient)

จากสมการ (2.23) เมื่อ  $A_0(z) = 1$

$$A_m(z) = 1 + \sum_{i=1}^m k_i B_{i-1}(z) \quad (2.40)$$

$$\|A_m(z) - 1\|^2 = \sum_{i=1}^m k_i^2 \beta_{i-1} \quad (2.41)$$

และ

$$\begin{aligned} \|A_m(z) - 1\|^2 &= \|A_m(z)\|^2 - 2\langle A_m(z), 1 \rangle + \|1\|^2 \\ &= \alpha_m - 2\alpha_m + \|1\|^2 \\ &= \|1\|^2 - \alpha_m \end{aligned} \quad (2.42)$$

แทนค่าดังกล่าวลงในสมการ (2.41)

$$\alpha_m = \|1\|^2 - \sum_{i=1}^m k_i^2 \beta_{i-1} \quad (2.43)$$

และ

$$\alpha_{m+1} = \|1\|^2 - \sum_{i=1}^{m+1} k_i^2 \beta_{i-1} \quad (2.44)$$

จากผลต่างของสมการทั้งสอง

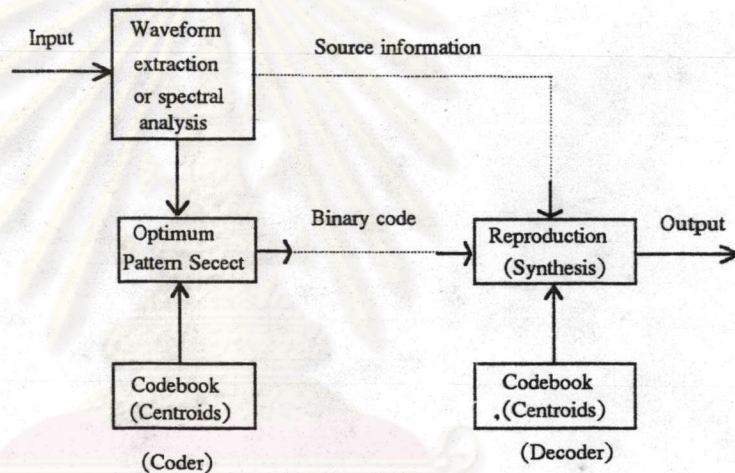
$$\alpha_{m+1} = \alpha_m - k_{m+1}^2 \beta_m \quad (2.45)$$



## 2 Vector Quantization(VQ)

เป็นวิธีการลดโดเมนชั้น (Dimension) ของข้อมูล โดยทำการหาค่าใดค่าหนึ่งซึ่งเป็นตัวแทนของข้อมูลจำนวนมากหนึ่ง ๆ โดยเริ่มแรก วิธีนี้ใช้เพื่อการบีบอัดข้อมูล (Compression) แต่ในกรณีนี้ จะนำวิธีนี้มาใช้เพื่อทำให้ข้อมูลที่ผ่านมาจากการคำนวณพินระเชิงเส้นเป็นข้อมูลที่ไม่ต่อเนื่อง (Discrete)

2.1 หลักการ Vector Quantization วิธี Vector Quantization (VQ) เป็นวิธีการควอนไตซ์คลื่นเสียงหรือ spectral envelope เป็นเซตแทนการ ควอนไตซ์ทีละตัว เช่น การควอนไตซ์แบบสเกลลาร์ VQ จะสามารถควอนไตซ์พารามิเตอร์ของ linear predictive coding(LPC) ได้อย่างมีประสิทธิภาพ ในรูป 2.4 เป็นขั้นตอนการทำงานของ Vector Quantization (Sadaoki Furui, 1989)



รูป 2.4 ขั้นตอนการทำงานของ VQ

ในการควอนไตซ์แบบเวกเตอร์ มีวิธีการควอนไตซ์ดังนี้คือ จะมีเวกเตอร์ code หรือ templates ที่เก็บไว้ อินพุตที่เข้ามาจะถูกทำการเปรียบเทียบกับ codebook ที่มีอยู่ โดยจะพิจารณาว่าอินพุตที่เข้ามานั้นห่างจาก codebook ไตน้อยที่สุด อินพุตดังกล่าวจะถูกแทนด้วยเวกเตอร์ code นั้น

codebook ที่ใช้จะเหมาะสมเพียงใด ขึ้นกับความคลาดเคลื่อนรวมทั้งหมดของต้นแบบที่ใช้หาเมื่อต้นแบบที่พิจารณามีจำนวนจำกัด codebook ที่มีความคลาดเคลื่อนน้อยที่สุด จะได้จากการทำซ้ำจนกว่าจะได้ค่าที่เหมาะสม โดยเหตุนี้จึงขึ้นกับ random learning และ clustering-base random learning คือการเลือกค่าขึ้นมา จำนวนหนึ่งซึ่งเท่ากับขนาดของ codebook จากข้อมูลต้นแบบ เพื่อใช้เป็นค่าเริ่มต้นในการ clustering ซึ่งเป็นวิธีการที่ใช้ใน Lloyd's algorithm (K-means algorithm) ในวิธีการนี้ข้อมูลต้นแบบที่ต้องการหาถูกแยกไปอยู่ในแต่ละกลุ่มของค่าเริ่มต้น จะทำการหาค่าเฉลี่ยของแต่ละกลุ่มเพื่อเป็นค่ากลางของกลุ่ม ทำวิธีการดังกล่าวซ้ำจนกว่าความคลาดเคลื่อนรวมทั้งหมดจะต่ำกว่าค่า ๆ หนึ่งหรือการลดลงของความคลาดเคลื่อนรวมทั้งหมดต่ำกว่าค่า ๆ หนึ่ง (ในวิทยานิพนธ์นี้ใช้ 0.00001 เนื่องจากค่าที่น้อยกว่านี้จะใช้เวลาคำนวณนานโดยให้ผล

ของระยะห่างของต้นแบบที่นำมาคำนวณหาค่าควอนไตซ์ใกล้เคียงกับ 0.00001) โดยค่ากลางดังกล่าวของกลุ่มจะถูกเก็บเป็นเวกเตอร์ code แต่แน่นอนว่าค่าความคลาดเคลื่อนรวมจะลดลงทุกครั้งที่มีการคำนวณซ้ำใหม่ จึงขึ้นกับค่าที่กำหนดว่าต้องการให้ความคลาดเคลื่อนรวมน้อยเพียงใด

2.2 การคำนวณ Vector Quantization ถ้าสมมุติ  $x = [x_1, x_2, \dots, x_N]^T$  มี  $N$  มิติ เราจะทำกรหาควอนไตซ์ของเวกเตอร์  $x$  กับ codebook เราสามารถเขียนว่า  $y$  เป็นควอนไตซ์ของค่า  $x$

$$y = q(x) \quad (2.46)$$

โดย  $q(\cdot)$  เป็นโอเปอเรเตอร์เรเตอร์ของควอนไตซ์  $y$  ถูกเรียกว่าเอาท์พุทเวกเตอร์ของค่า  $x$  โดย  $y$  เป็นค่าใดค่าหนึ่งใน  $Y = \{y_i, 1 \leq i \leq L\}$  โดย  $y_i = [y_{i1} \ y_{i2} \ \dots \ y_{iN}]^T$   $Y$  เป็นเซตของ codebook,  $L$  เป็น ขนาดของ codebook และ  $\{y_i\}$  เป็นเซตของเวกเตอร์ code  $y_i$  อาจเรียกว่าเป็น code อ้างอิง และ  $L$  อาจเรียกว่าจำนวนระดับขั้น เมื่อเทียบกับสเกลาร์ควอนไตซ์ ทำการแบ่งเวกเตอร์  $x$  ไปใน  $L$  เซล  $\{C_i, 1 \leq i \leq L\}$  เมื่อ  $x$  อยู่ในเซล  $C_i$

$$q(x) = y_i \quad \text{ถ้า } x \in C_i \quad (2.47)$$

ถ้า  $x$  ถูกควอนไตซ์ได้ค่า  $y$  ค่าความคลาดเคลื่อนจากการควอนไตซ์สามารถแสดงได้โดยระยะห่างของทั้งสอง  $d(x, y)$  โดยความคลาดเคลื่อนรวมคือ

$$D = \lim_{m \rightarrow \infty} \frac{1}{M} \sum_{n=1}^M d[x(n), y(n)] \quad (2.48)$$

การคำนวณหา codebook มีหลายวิธี แต่ที่จะนำมาใช้คือ Lloyd Algorithm (Furui, 1989)

2.3 การวัดความคลาดเคลื่อน การวัดความคลาดเคลื่อนเป็นส่วนจำเป็นและเป็นเครื่องมือที่เป็นประโยชน์ต่อการออกแบบ coding ซึ่ง ในปัจจุบันมีวิธีการหลายแบบ แต่ที่จะนำมาใช้ในวิทยานิพนธ์นี้คือ square error distortion.

The squared error distortion:

ถ้าสัญญาณที่เข้ามามี  $K$  มิติ เราสามารถหาระยะห่างระหว่างสัญญาณเข้ากับเวกเตอร์ code

$$d(x, y) = \|x - y\|^N = \sum_{i=0}^{k-1} (x_i - y_i)^N \quad (2.49)$$

หรือ

$$d(x, y) = \|x - y\|^2 = \sum_{i=0}^{k-1} (x_i - y_i)^2 \quad (2.50)$$

วิธีนี้เป็นวิธีแบบง่าย ๆ ที่ใช้กันทั่วไป ซึ่งมีความซับซ้อนน้อย ง่ายต่อการคำนวณ เราสามารถหา signal-to-noise ratio ได้ดังนี้

$$\text{SNR} = 10 \log_{10} \frac{E(\|x\|^2)}{E[d(x,y)]} \quad (2.51)$$

2.4 การสุ่มค่าเริ่มต้น วิธีหนึ่งที่ใช้ในการออกแบบ codebook คือการเลือกค่าเริ่มต้นของ codebook ในการสุ่มตัวอย่างจาก ข้อมูลที่จะนำมาคำนวณ เราเรียก codebook ที่ได้จากการสุ่มค่าเริ่มต้นนี้ว่า random codebook ถึงแม้ว่าการสุ่มค่า เริ่มต้นจะไม่ใช่วิธีที่ดีนักแต่ codebook ที่ได้จากการสุ่มค่าเริ่มต้น ให้ผลที่ยอมรับได้ (Makhoul, Roucos and Gish, 1985)

2.5 ขั้นตอนการทำงาน ในการออกแบบ codebook สิ่งสำคัญที่สุดคือขั้นตอนการหา codebook K-means algorithm จะต้องมี การสุ่มค่า codebook เริ่มต้น

2.5.1 การหา codebook K-means initialization วิธีการ K-means ไม่ยืนยันว่า คำตอบจะได้ค่าที่มีความคลาดเคลื่อนน้อยที่สุด จะต้องทำการสุ่มค่า codebook เริ่มต้นจากหลายๆ คำ codebook ที่ได้ความคลาดเคลื่อนน้อยที่สุดจะถูกเลือก

2.5.2 การเปรียบเทียบ เมื่อมี codebook เรียบร้อย สิ่งที่จะนำไปหาโมเดลโดยวิธี HMM จะต้องผ่านขั้นตอนนี้ เพื่อหา ตัวแทนของสัมประสิทธิ์การสะท้อนในรูปของคovanoidซ์

#### PATTERN SIMILARITY DETERMINATION

ในที่นี้หมายถึง การหาตัวแทนที่จะนำมาเปรียบเทียบกับสิ่งที่เราไม่ทราบ Hidden Markov Model เป็นวิธีการที่ใช้กันอย่างแพร่หลาย แรกเริ่มมีการเสนอวิธีนี้ในการวิเคราะห์คำต่อเนื่อง (Continuous Word) ก่อน เมื่อได้ผลดี จึงมีการนำมาใช้กับคำโดด (Isolated Word) ซึ่งได้ผลดีเช่นเดียวกัน (Rabiner, Levinson and Sondhi, 1982)

#### 1. Hidden Markov Model (HMM)

HMM เป็นระบบ doubly stochastic HMM เป็นวิธีการใช้ทฤษฎีความน่าจะเป็น มาอธิบายการเกิดของ sequence 2 ตัว คือ state และค่าปรากฏ โดยผู้สังเกตจะเห็นเพียงเอาท์พุทของแต่ละ state (ค่าปรากฏ) แต่จะไม่ทราบแน่ชัดว่าอยู่ที่ state ไต จึงเรียกว่า Hidden Markov Model (HMM)

##### 1.1 พารามิเตอร์ใน HMM

T = ความยาวของค่าปรากฏ

N = จำนวน state ในโมเดล

M = จำนวนค่าปรากฏ

Q =  $\{q_1, q_2, \dots, q_N\}$  state

V =  $\{v_1, v_2, \dots, v_N\}$  ค่าปรากฏ

A =  $\{a_{ij}\}$ ,  $a_{ij} = \Pr(q_j \text{ ที่เวลา } t+1 / q_i \text{ ที่เวลา } t)$  คือ ความน่าจะเป็นของการเปลี่ยน state

B =  $\{b_j(k)\}$ ,  $b_j(k) = \Pr(v_k \text{ ที่เวลา } t / q_j \text{ ที่เวลา } t)$  คือ ความน่าจะเป็นของ

การเกิดค่าปรากฏ

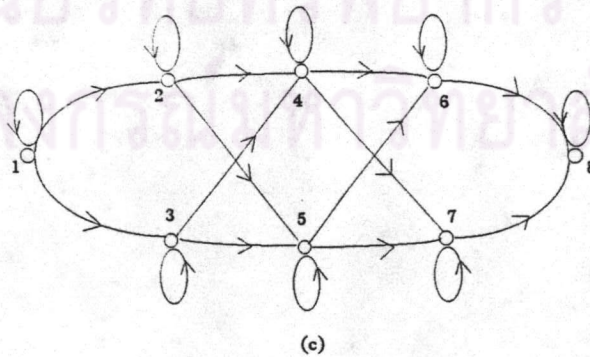


$\pi = \{ \pi_i \}$ ,  $\pi_i = \Pr(q_i \text{ ที่เวลา } t=1)$  ความน่าจะเป็นที่แต่ละ state จะเป็น state เริ่มต้น

1.2 โครงสร้างของ Hidden Markov (HMM) มีอยู่ 3 ชนิดคือ

1.2.1. unconstrained model โมเดลนี้ทุก state สามารถติดต่อกับ state อื่นๆ ได้ทุก state ดังรูป 2.5(a) โดยค่า  $a_{ij}$  ทุกตัวจะมีค่า ( $a_{ij} \neq 0$ )

1.2.2. constrained serial model ในโมเดลนี้เมื่อผ่าน state ใดไปแล้วจะไม่มีกรย้อนกลับมาที่ state นั้น อีก ดังรูป 2.5(b)

1.2.3. constrained parallel model ในโมเดลนี้จะมีคุณสมบัติเช่นเดียวกับ constrained serial model แต่มีความซับซ้อนกว่า ดังรูป 2.5(c)



รูป 2.5 โครงสร้างแบบต่างๆ

1.3 ปัญหาของ HMM มีปัญหา 3 อย่างซึ่งต้องใช้ algorithm ต่างๆ ในการคำนวณ (Fabiner, and Jung, 1986)

- ปัญหา 1: ถ้ามี sequence ของค่าปรากฏ  $O = O_1, O_2, \dots, O_T$  และมีโมเดล  $\lambda = (A, B, \pi)$  เราจะคำนวณหา  $\Pr(O/\lambda)$  ของ sequence ค่าปรากฏได้อย่างไร
- ปัญหา 2: ถ้ามี sequence ของค่าปรากฏ  $O = O_1, O_2, \dots, O_T$  เราจะหา sequence ของ state ที่  $I = i_1, i_2, \dots, i_T$  ที่ให้ค่าปรากฏนั้นได้อย่างไร
- ปัญหา 3: จะหาโมเดล  $\lambda = (A, B, \pi)$  ที่ให้ค่า  $\Pr(O/\lambda)$  มากที่สุดอย่างไร

ปัญหา 1: เมื่อให้โมเดลและ sequence ค่าปรากฏ เราจะคำนวณความน่าจะเป็นที่โมเดลนั้นให้ค่าปรากฏที่กำหนดมา หรือ อาจกล่าวได้ว่า เมื่อมีโมเดลและ sequence ของค่าปรากฏ เราจะหาว่าโมเดลนั้นมีโอกาสให้ค่า sequence ค่าปรากฏนั้นด้วยค่าเท่าไร หรือโมเดลนั้นเหมาะสมกับค่าปรากฏมากหรือน้อย

ปัญหา 2: เป็นส่วนที่เราพยายามจะระบุ state ให้กับ sequence ของค่าปรากฏ ซึ่งทราบอยู่แต่แรกแล้วว่า state เป็นค่าที่ไม่แน่ชัด มีหลายวิธีในการคำนวณ

ปัญหา 3: พยายามหาโมเดลที่เหมาะสมจาก sequence ค่าปรากฏ เราเรียกขั้นตอนนี้ว่า การหาโมเดลของเสียง เพื่อสร้างรูปแบบโมเดลที่เหมาะสมให้กับเสียงนั้น

ถ้าเราจะพิจารณาหาโมเดล เราจะต้องกำหนดค่า N-state สำหรับแต่ละค่าเราใช้ Vector Quantization (VQ) มาช่วย เราทำการแทนสัญญาณเสียงด้วยค่าใดค่าหนึ่งใน codebook ของ VQ จาก codebook ที่มีขนาด M เริ่มต้นการหาโมเดลของเสียง จาก sequence ค่าปรากฏจำนวนหนึ่งของแต่ละค่า โดยค่าหนึ่งๆ จะมีผู้พูดหลายคน ใช้ปัญหา 3 ในการพิจารณา หลังจากนั้นเราจะระบุ state ให้กับ sequence ค่าปรากฏ โดยปัญหา 2 จนขั้นตอนสุดท้ายเราจะหาว่า sequence ใดๆ เมื่อนำมาเปรียบเทียบกับโมเดลที่ทำได้ มีความเป็นไปได้ที่โมเดลจะให้ค่าปรากฏดังกล่าวมากน้อยเพียงไร ใช้ ปัญหา 1

#### 1.4 การคำนวณของ HMM

ปัญหา 1:

ในการคำนวณว่าโมเดล  $\lambda$  ให้ความน่าจะเป็นที่จะได้ sequence ค่าปรากฏ  $O$  มากน้อยเพียงใด โดยมีการระบุ state ต่างๆ ให้กับ sequence ค่าปรากฏยาว T  $I = i_1 i_2 \dots i_T$  ความน่าจะเป็นของค่าปรากฏ  $O$  คือ  $\Pr(O/I, \lambda)$

$$\Pr(O/I, \lambda) = b_{i_1}(O_1) b_{i_2}(O_2) \dots b_{i_T}(O_T) \quad (2.52)$$

$$\Pr(I/\lambda) = \pi_{i_1} a_{i_1 i_2} a_{i_2 i_3} \dots a_{i_{T-1} i_T} \quad (2.53)$$

หรืออาจเขียนได้ว่า

$$\Pr(O, I/\lambda) = \Pr(O/I, \lambda) \Pr(I/\lambda) \quad (2.54)$$

โดยที่ความน่าจะเป็นของ  $O$  คือผลรวมของ joint probability ของทุก state ที่เป็นไปได้

$$\Pr(O/\lambda) = \sum_{all I} \Pr(O/I, \lambda) \Pr(I/\lambda)$$

$$= \sum_{i_1, i_2, \dots, i_T} \pi_{i_1} b_{i_1}(O_1) a_{i_1 i_2} b_{i_2}(O_2) \dots a_{i_{T-1} i_T} b_{i_T}(O_T) \quad (2.55)$$

ถ้าเรากำหนด forward variable  $\alpha_t(i)$

$$\alpha_t(i) = \Pr(O_1, O_2, \dots, O_t, i_t = q_i / \lambda) \quad (2.56)$$

เราจะได้ว่า  $\alpha_1(i) = \pi_i b_i(O_1)$ ,  $1 \leq i \leq N$  (2.57)


และที่เวลา  $t$  ต่างๆ ดังในรูป 2.6

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

$$, 1 \leq j \leq N \quad (2.58)$$

ทำให้สมการ (2.55) เขียนเป็น

$$\Pr(O/\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (2.59)$$



รูป 2.6 แสดงการพิจารณา forward variable


ถ้ากำหนด backward variable  $\beta_t(i)$

$$\beta_t(i) = \Pr(O_{t+1}, O_{t+2}, \dots, O_T / i_t = q_i, \lambda) \tag{2.60}$$

โดย  $\beta_T(i) = 1, 1 \leq i \leq N$  (2.61)

และที่เวลา  $t$  ใดๆ ดังรูป 2.7

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}(j)), \quad t = T-1, T-2, \dots, 1, \quad 1 \leq i \leq N \tag{2.62}$$



รูป 2.7 แสดงการพิจารณา backward variable

ปัญหา 2:

เมื่อกำหนด

$$\gamma_t(i) = \Pr(i_t = q_i / O, \lambda) \tag{2.63}$$

ความน่าจะเป็นที่ state  $q_i$  ที่เวลา  $t$  ให้ sequence ค่าปรากฏด้วยโมเดล  $\lambda$  และ  $\gamma_t(i)$  สามารถเขียนในรูป  $\alpha$  และ  $\beta$  ได้

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{\Pr(O/\lambda)} \tag{2.64}$$



โดย  $\alpha_t(i)$  เริ่มจาก  $O_1, O_2, \dots, O_t$  จนถึง state  $q_i$  ที่เวลา  $t$  ส่วน  $\beta_t(i)$  เริ่มจาก  $O_{t+1}, \dots, O_T$  จนถึง  $q_i$  ที่เวลา  $t$

ค่า  $\gamma_t(i)$  เป็น conditional probability จึงเขียนได้ว่า

$$\sum_{i=1}^N \gamma_t(i) = 1 \tag{2.65}$$

ปัญหา 3:


เมื่อมี sequence ค่าปรากฏจำนวนหนึ่ง ทำการหาโมเดลที่จะให้ผลตามค่าปรากฏเหล่านี้  $\lambda = (A, B, \pi)$  เราจะใช้การทำซ้ำ โดยใช้วิธี Baum-Welch หรือ gradient techniques ถ้ากำหนด

$$\xi_t(i, j) = \Pr(i_t = q_i, i_{t+1} = q_j / O, \lambda) \tag{2.66}$$

ความน่าจะเป็นที่ state  $q_i$  ที่เวลา  $t$  ทำการเปลี่ยนไปที่ state  $q_j$  ที่เวลา  $t+1$  จากรูป 2.8 เราสามารถเขียน  $\xi_t(i, j)$  ได้

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\Pr(O / \lambda)} \tag{2.67}$$

$\alpha_t(i)$  เริ่มจากเวลา  $t=1$  ที่ค่าปรากฏแรก จนถึง state  $q_i$  ที่เวลา  $t$  ค่า  $a_{ij} b_j(O_{t+1})$  เป็นการเปลี่ยน state  $q_i$  ที่เวลา  $t$  ไปเป็น  $q_j$  ที่เวลา  $t+1$  และให้ค่าปรากฏ  $O_{t+1}$



รูป 2.8 การพิจารณา forward และ backward



เราสามารถเขียนความสัมพันธ์ของ  $\xi_t(i, j)$   $x \xrightarrow{1-1} \xi$  กับ  $\gamma_t(i)$  ได้ดังนี้

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (2.68)$$

ใช้ Baum-Welch reestimation ในการประมาณค่า  $\pi$ , A, B ตามสมการ (2.69-2.71)

$$\bar{\pi}_i = \gamma_1(i) \quad , 1 \leq i \leq N \quad (2.69)$$

$$\bar{a}_{ij} = \sum_{t=1}^{T-1} \xi_t(i, j) / \sum_{t=1}^{T-1} \gamma_t(i) \quad (2.70)$$

$$\bar{b}_j(k) = \sum_{\substack{t=1 \\ O_t=k}}^T \gamma_t(j) / \sum_{t=1}^T \gamma_t(j) \quad (2.71)$$

## DECISION RULE

การใช้วิธีใดในการตัดสินใจ จะต้องคำนึงถึงวิธีการที่ใช้ใน pattern similarity determination ต้องมีความสอดคล้องกัน

### 1 Viterbi Algorithm (VA)

ถูกเสนอในปี 1967 ในการ decode convolution codes ต่อมามีการนำไปใช้ในทางอื่นๆ เช่น VA ที่ใช้กับ state ของระบบ stochastic โดยใช้ recursive method ในการหาค่าที่เหมาะสม วิธีนี้จะทำให้การคำนวณรวดเร็วยิ่งขึ้น เพราะพิจารณาเฉพาะ path ที่มีค่าความน่าจะเป็นสูงสุด (Forney, 1973)

1.1 ทฤษฎี VA นำ VA มาใช้กับระบบ Markov state  $x_k$  ที่เวลา  $k$  เป็นหนึ่งในจำนวนทั้งหมด  $M$  state  $1 \leq m \leq M$ ,  $\{1, 2, \dots, M\}$  โดยเราสมมุติว่าระบบจะเริ่มที่เวลา  $t=0$  จนถึง  $t=K$  และจะเริ่มที่ state  $x_0$  จนถึง state  $x_K$  โดยสามารถเขียน state sequence ได้เป็น  $X = \{x_0, x_1, \dots, x_K\}$

ในระบบของ Markov ซึ่งจะอยู่ในรูปความน่าจะเป็น  $P(x_{k+1}/x_0, x_1, \dots, x_k)$  ใน state  $x_{k+1}$  ที่เวลา  $k+1$  จะขึ้นกับ state  $x_k$  ที่เวลา  $k$  เท่านั้น

$$P(x_{k+1}/x_0, x_1, \dots, x_k) = P(x_{k+1}/x_k) \quad (2.72)$$

เราสามารถเขียน transition  $\xi_k$  ที่เวลา  $k$  ในรูปของ state


$$\xi_k \triangleq (x_{k+1}, x_k) \quad (2.73)$$

โดย  $\Xi$  คือเซตของ transitions  $\xi_k = (x_{k+1}, x_k)$  ซึ่ง  $P(x_{k+1}/x_k) \neq 0$  และ  $|\Xi| \leq M^2$   
 ความสัมพันธ์ ของ state sequence  $x$  และ transition sequence  $\xi = \xi_0, \dots, \xi_{K-1}$  เป็นแบบ 1:1  
 $x \xleftrightarrow{1-1} \xi$

เราสามารถเขียน sequence ของค่าปรากฏ  $z_k$  ที่ขึ้นกับค่าความน่าจะเป็นของ transition  $\xi_k$  ที่เวลา  $k$

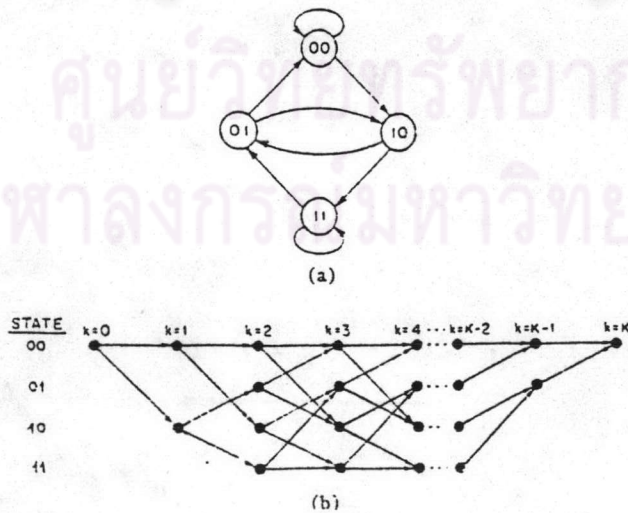
$$P(z/x) = P(z/\xi) = \prod_{k=0}^{K-1} P(z_k / \xi_k) \quad (2.74)$$

จากรูป 2.9 จะเห็นว่า  $z$  จะเป็นค่าเอาต์พุตที่ออกจาก channel โดยอินพุตคือ sequence ของ  $\xi$



รูป 2.9 โมเดลของ Viterbi

1.2 Algorithm จากรูป 2.10(a) แสดงถึง state diagram ของระบบ Markov ที่พิจารณา ในช่วงเวลาที่ต่อเนื่อง ซึ่งมี 4 state โดย node แสดงถึง state เส้นเชื่อมแสดงถึง transition



รูป 2.10 โครงสร้าง state และ trellis ของ Viterbi

ในรูป 2.10(b) เป็น trellis โดย node แสดง state และเส้นเชื่อมแสดงการเปลี่ยนจาก state หนึ่งไปอีก state หนึ่ง ในเวลาถัดไป โดยเราจะทราบ state เริ่มต้นและ state สิ้นสุด  $x_0$  และ  $x_K$

เมื่อให้ sequence ของค่าปรากฏ  $z$  เราจะหา state sequence ที่ให้ค่า  $P(x/z)$  มากที่สุด หรือ  $P(x,z) = P(x/z)P(z)$  มีค่ามากที่สุด โดยให้ระยะทาง  $-\ln P(x,z)$  สั้นที่สุด ซึ่งความสัมพันธ์ path และ sequence เป็นแบบ 1:1

$$P(x,z) = P(x)P(z/x)$$

$$= \prod_{k=0}^{K-1} P(x_{k+1} / x_k) \prod_{k=0}^{K-1} P(z_k / x_{k+1}, x_k) \quad (2.75)$$

โดยระยะทางหาได้จาก

$$\lambda(\xi_k) \triangleq -\ln P(x_{k+1}, x_k) - \ln P(z_k / \xi_k) \quad (2.76)$$

ระยะทางทั้งหมดของ path

$$-\ln P(x,z) = \sum_{k=0}^{K-1} \lambda(\xi_k) \quad (2.77)$$

การหาระยะทางที่สั้นที่สุด ถูกเสนอโดย Minty ในปี 1957 แต่วิธีที่เสนอนี้ไม่เหมาะสมจะคำนวณโดยคอมพิวเตอร์ แต่วิธีการหาระยะทางที่สั้นที่สุดจำเป็นสำหรับ VA


ถ้าเรากำหนด  $x_0^k$  เป็น state sequence ตั้งแต่  $x_0$  จนถึง  $x_k$  ซึ่งมีหลายเส้นทางที่เป็นไปได้ ซึ่งสามารถเขียนได้เป็น

$$\lambda(x_0^k) = \sum_{i=0}^{k-1} \lambda(\xi_i) \quad (2.78)$$

โดยระยะทางที่สั้นที่สุดเรียกว่า survivor โดยปลายทางคือ node  $x_k$  เขียนได้เป็น  $\hat{x}(x_k)$  ถ้า  $k > 0$  ที่ค่า  $k$  ต่างๆ เขียนทางที่จะเป็นไปได้ทั้งหมด แล้วเลือกทางที่สั้นที่สุด เมื่อค่า  $k$  เพิ่มขึ้น เลือกทางที่สั้นที่สุดสำหรับ  $k$  นั้นๆ อีก จนกระทั่งถึง  $k=K$  จะได้ระยะทางรวมสั้นที่สุด ดังรูป 2.11(a),(b)

หาระยะทางโดย

$$\Gamma(x_k) \triangleq \lambda[\hat{x}(x_k)] \quad (2.79)$$



รูป 2.11 การหาระยะที่สั้นที่สุดโดยวิธี Viterbi