

การจำแนกข้อมูลจากดาวเทียมและทฤษฎีสถิติที่เกี่ยวข้อง

3.1 วิธีการจำแนกประเภทข้อมูลจากดาวเทียม

การนำข้อมูลจากดาวเทียมสำรวจทรัพยากรมาใช้ในการศึกษาและวิเคราะห์นั้น มีขบวนการวิเคราะห์เพื่อให้ได้ตามวัตถุประสงค์คือ การจำแนกประเภทข้อมูล (Classification) ว่าวัตถุหรือสสารใดๆ บนพื้นโลกนั้น เป็นอะไร มีจำนวนหรือปริมาณเท่าใด ซึ่งแบ่งออกเป็น 2 วิธีตามลักษณะของการวิเคราะห์ ดังนี้

1. การแปลด้วยสายตา (Visual interpretation) เป็นการศึกษาและวิเคราะห์ข้อมูลจากดาวเทียม โดยการนำภาพถ่ายดาวเทียมมาแปลด้วยสายตา เพื่อแยกประเภทข้อมูล จากการพิจารณาระดับความเข้มของสี (Tone) ขนาด (Size) รูปร่าง (Shape) ความหยาบละเอียด (Texture) ตลอดจนสิ่งแวดล้อมข้างเคียง เป็นต้น ประกอบกับการสำรวจภาคพื้นดิน (Ground Truth) ก็สามารถที่จะแยกหรือจำแนกประเภทข้อมูลในแหล่งหรืออาณาบริเวณที่ต้องการว่าประกอบด้วยอะไรบ้าง สำหรับพื้นที่ของข้อมูลแต่ละประเภทวัดได้ด้วยเครื่องมือที่เรียกว่า Planimeter

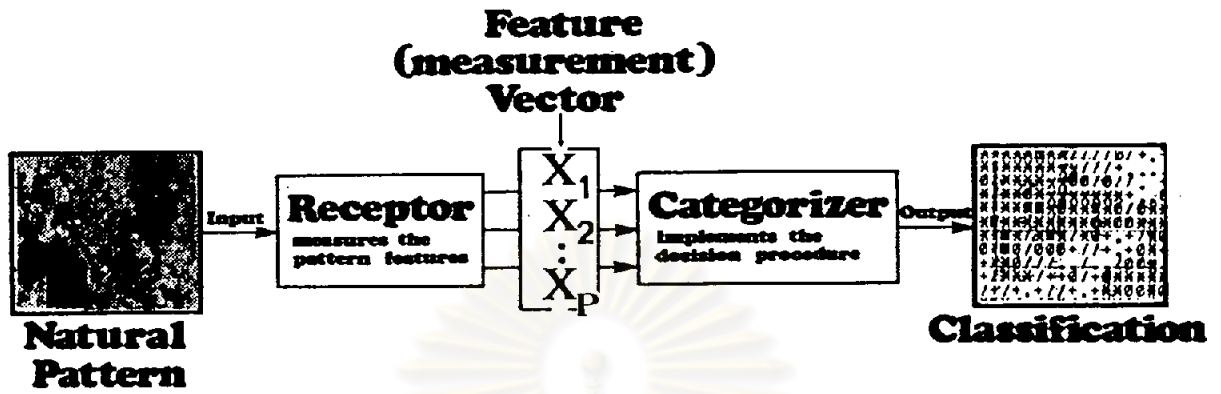
2. การวิเคราะห์ด้วยเครื่องคอมพิวเตอร์ เป็นการศึกษาและวิเคราะห์ข้อมูลจากดาวเทียมโดยการนำเทปบันทึกข้อมูลจากดาวเทียม (CCT) มาทำการวิเคราะห์ด้วยเครื่องคอมพิวเตอร์ ซึ่งมีวิธีการวิเคราะห์ 2 วิธีการ กล่าวคือ (7 : 177)

- 2.1 Supervised analysis เป็นการศึกษาวิเคราะห์โดยที่ผู้วิจัยจะต้องกำหนดพื้นที่ตัวอย่าง (Training area) โดยการสั่งการให้เครื่องคอมพิวเตอร์ได้รู้หรือรับทราบ ว่าพื้นที่ตัวอย่างจะต้องมีกี่ประเภทข้อมูล (Class) คอมพิวเตอร์จะอ่านค่าระดับสีเทา (Greytone level) ของข้อมูลแต่ละประเภทในพื้นที่ตัวอย่างมาคำนวณหาค่าสถิติ เช่น ค่าเฉลี่ย (mean) ค่าความแปรปรวนร่วม (covariance) ค่าสหสัมพันธ์ (correlation) เป็นต้น แล้วใช้ค่าสถิติต่างๆ เหล่านี้ไปแทนค่าในฟังก์ชันทางสถิติที่กำหนด เพื่อใช้ใน

การจำแนกประเภทข้อมูลของอาณานิคมทั้งหมดที่ต้องการได้ ทั้งนี้พื้นที่ตัวอย่างกำหนดได้จาก การตรวจสอบภาคพื้นดินแล้วว่า เป็นข้อมูลประเภทใดหรือเป็นวัตถุชนิดใด ซึ่งพื้นที่ตัวอย่างนี้จะต้องมีความเหมาะสมสามารถใช้เป็นตัวแทนของข้อมูลประเภทนั้นๆ ทั้งหมดอาณานิคมที่ศึกษา สำหรับการศึกษาค้างนี้กำหนดเลือกใช้วิธีดังกล่าวซึ่งจะอธิบายในรายละเอียดต่อไป

2.2 Unsupervised analysis เป็นการวิเคราะห์โดยที่ไม่จำเป็นต้องกำหนดพื้นที่ตัวอย่างหรือสิ่งการให้ เครื่องคอมพิวเตอร์ได้รับทราบข้อมูลที่ต้องการ จำแนกประเภทล่วงหน้าก่อนที่จะปฏิบัติงานเลย คอมพิวเตอร์จะทำการแยกประเภทข้อมูลทั้งหมดในอาณานิคมที่ศึกษาว่าควรจะมีกี่ประเภท ในลักษณะที่คล้ายๆ กับการกำหนดพื้นที่ตัวอย่างโดยอัตโนมัติ แล้วทำการจำแนกประเภทข้อมูลเพื่อให้ได้ผลลัพธ์ขั้นสุดท้าย อนึ่ง การวิเคราะห์ด้วยวิธีดังกล่าวนี้ ใช้ได้กับโปรแกรมสำเร็จรูปบางโปรแกรมเท่านั้น ซึ่งโปรแกรมสำเร็จรูป MOA - RECOGX ไม่สามารถกระทำได้

จากรายละเอียดที่กล่าวข้างต้นนี้ เมื่อนำมาอธิบายในลักษณะรูปแบบจำลอง (Model) ของวิธีการจำแนกประเภทข้อมูลได้ดังนี้ จะเห็นว่าวัตถุนบนพื้นผิวโลกจะถูกบันทึกเก็บรวบรวมโดยเครื่องบันทึกภาพ (Sensors) ที่ติดตั้งบนดาวเทียม เครื่องบันทึกภาพดังกล่าวนี้สามารถเทียบได้กับ Receptor ที่อยู่ในแบบจำลอง ข้อมูลขาเข้า (input) ซึ่งอาจเป็นไปได้ทั้งระบบ MSS หรือ TM อย่างใดอย่างหนึ่ง ข้อมูลขาเข้าทั้งหมดก็คือชุดของค่าสังเกต (observation) หรือจำนวนจุดภาพ (pixel) ทั้งหมด n จุดภาพ ในค่าสังเกตหรือจุดภาพหนึ่งๆ จะประกอบด้วยชุดของค่าระดับสีเทา (Greytone level) ของวัตถุชนิดหนึ่งที่เกิดจากการบันทึกด้วยขนาดช่วงคลื่นหรือแบนด์ (Band or Channel) ต่างๆ เป็น p แบนด์ สำหรับ Categorizer นั้นเทียบได้กับเครื่องมือที่ประกอบด้วยวิธีการทางสถิติต่างๆ ที่ใช้ในการตัดสินใจว่าข้อมูลที่ต้องการจะศึกษาหรือจุดภาพนั้นๆ ว่า ควรเป็นกลุ่มหรือประเภทข้อมูลใด ซึ่งเป็นข้อมูลขาออก (output)



รูปที่ 10 รูปแบบจำลองวิธีการจำแนกข้อมูลจากดาวเทียม



รูปที่ 11 ภาพถ่ายดาวเทียม (Photographic image) ขาว-ดำ ที่ใช้สำหรับแปลภาพด้วยสายคา

3.2 ทฤษฎีสถิติที่เกี่ยวข้อง

วิธีการทางสถิติที่ใช้ในการศึกษาค้างนี้ เกี่ยวข้องและอ้างอิงถึงทฤษฎีสถิติต่างๆ เช่น ทฤษฎีการแจกแจงของตัวแปรสุ่ม (Distribution Theory) ทฤษฎีการตัดสินใจ (Decision Theory) ดังนั้น จำเป็นต้องกล่าวถึงทฤษฎีสถิติดังกล่าวนี้ เพื่อใช้ประกอบในการอธิบายวิธีการทางสถิติต่างๆ ซึ่งจะกล่าวต่อไป

3.2.1 ทฤษฎีการแจกแจงของตัวแปรสุ่ม (Distribution Theory)

ทฤษฎีการแจกแจงของตัวแปรสุ่มที่จะกล่าวถึงนี้ เป็นการเสนอฟังก์ชันของตัวแปรสุ่มที่มีการแจกแจงแบบปกติ (Normal Distribution) ที่สำคัญ เพื่อใช้อ้างอิงในการนำไปประยุกต์ใช้ต่อไปนับตั้งแต่กรณีของ Univariate Normal Distribution เป็นอันดับแรก

1. Univariate Normal Distribution (1-dimensional)

เมื่อ x มีการแจกแจงแบบปกติ โดยมี pdf เป็น

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{1}{2} \left(\frac{x-\mu}{\sigma} \right)^2 \right], \quad -\infty < x < \infty \dots(1)$$

ซึ่งมีค่าเฉลี่ย (mean)

$$\begin{aligned} E[X] &= \int_{-\infty}^{\infty} xp(x)dx \\ &= \mu \end{aligned}$$

และความแปรปรวน (variance)

$$\begin{aligned} E[X-\mu]^2 &= \int_{-\infty}^{\infty} (x-\mu)^2 p(x)dx \\ &= \sigma^2 \end{aligned}$$

2. Bivariate Normal Distribution (2-dimensional)

ให้ X เป็นเวกเตอร์สุ่ม (random vector) ของ 2 ตัวแปร

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

ที่มีการแจกแจงเป็น Bivariate normal distribution มี pdf เป็น

$$p(X) = \frac{1}{2\pi \sigma_1 \sigma_2 \sqrt{1-\rho^2}} \exp \left[-\frac{1}{2(1-\rho^2)} \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1^2} - 2\rho \frac{(x_1 - \mu_1)}{\sigma_1} \frac{(x_2 - \mu_2)}{\sigma_2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} \right\} \right]$$

$$-\infty < x_1, x_2 < \infty \dots\dots\dots(2)$$

เมื่อนิยาม σ_{ii} คือ ความแปรปรวน และ σ_{ij} คือความแปรปรวนร่วม

โดยที่ $i, j = 1, 2$

ซึ่งมี $E [X_i] = \mu_i$

$$\sigma_i^2 = E [x_i - \mu_i]^2$$

$$= \sigma_{ii}$$

และ ρ คือ สัมประสิทธิ์สหสัมพันธ์ (correlation coefficient) ของ x_1 และ x_2

$$; -1 < \rho < 1$$

$$\rho = \frac{\sigma_{ij}}{\sqrt{\sigma_{11}\sigma_{22}}} ; i \neq j$$

สามารถเขียนได้ในรูปเมทริกซ์ (matrix) ได้ดังนี้

mean vector $\mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$

covariance vector

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{bmatrix}$$

$$|\Sigma| = \sigma_{11}\sigma_{22} - \sigma_{12}\sigma_{21}$$

$$\Sigma^{-1} = \frac{1}{\sigma_{11}\sigma_{22} - \sigma_{12}\sigma_{21}} \begin{pmatrix} \sigma_{22} & -\sigma_{12} \\ -\sigma_{21} & \sigma_{11} \end{pmatrix}$$

$$\sigma_{12} = \rho\sqrt{\sigma_{11}\sigma_{22}} = \sigma_{21}$$


$$\begin{aligned} \text{ดังนั้น } p(x) &= \frac{1}{2\pi |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (x-\mu)' \Sigma^{-1} (x-\mu) \right] \\ &= \frac{1}{2\pi (\sigma_{11}\sigma_{22} - \sigma_{12}\sigma_{21})^{\frac{1}{2}}} \exp \left[Q \right] \dots\dots\dots(3) \end{aligned}$$

$$\begin{aligned} \text{เมื่อ } Q &= \frac{1}{2(\sigma_{11}\sigma_{22} - \sigma_{12}\sigma_{21})} \{ \sigma_{22}(x_1 - \mu_1)^2 - (\sigma_{12} + \sigma_{21})(x_1 - \mu_1)(x_2 - \mu_2) \\ &\quad + \sigma_{11}(x_2 - \mu_2)^2 \} \\ &= \frac{1}{2(1 - \frac{\sigma_{12}\sigma_{21}}{\sigma_{11}\sigma_{22}})} \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_{11}} - \frac{(\sigma_{12} + \sigma_{21})(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_{11}\sigma_{22}} \right. \\ &\quad \left. + \frac{(x_2 - \mu_2)^2}{\sigma_{22}} \right\} \\ &= \frac{1}{2(1 - \frac{\sigma_{12}\sigma_{21}}{\sigma_{11}\sigma_{22}})} \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_{11}} - \frac{(\sigma_{12} + \sigma_{21})}{\sqrt{\sigma_{11}} \sqrt{\sigma_{22}}} \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sqrt{\sigma_{11}} \sqrt{\sigma_{22}}} \right. \\ &\quad \left. + \frac{(x_2 - \mu_2)^2}{\sigma_{22}} \right\} \\ &= -\frac{1}{2(1 - \rho^2)} \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1} - 2\rho \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1 \sigma_2} \right. \\ &\quad \left. + \frac{(x_2 - \mu_2)^2}{\sigma_2} \right\} \end{aligned}$$

จาก (๓) จะได้

$$\begin{aligned}
 p(X) &= \frac{1}{2\pi\sqrt{\sigma_{11}\sigma_{22}}\left(1 - \frac{\sigma_{12}\sigma_{21}}{\sigma_{11}\sigma_{22}}\right)^{\frac{1}{2}}} \exp\left[Q\right] \\
 &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left[-\frac{1}{2(1-\rho^2)}\left\{\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - \right.\right. \\
 &\quad \left.\left.2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right\}\right]
 \end{aligned}$$

ซึ่งก็คือ (๒) นั่นเอง



mean vector $M = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$

covariance matrix $\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{pmatrix}$

correlation coefficient $\rho = \sigma_{12} / (\sigma_1\sigma_2)^{\frac{1}{2}}$

รูปที่ 12 ลักษณะของ Bivariate Normal Distribution

3. Multivariate Normal Distribution (n-dimensional)

ให้ X เป็นเวกเตอร์สุ่มของ p ตัวแปร

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix}$$

ที่มีการแจกแจงเป็น Multivariate normal distribution มี pdf เป็น

$$p(\underline{X}) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\underline{X}-\underline{\mu})' \Sigma^{-1} (\underline{X}-\underline{\mu}) \right] \dots\dots\dots(4)$$

เมื่อ

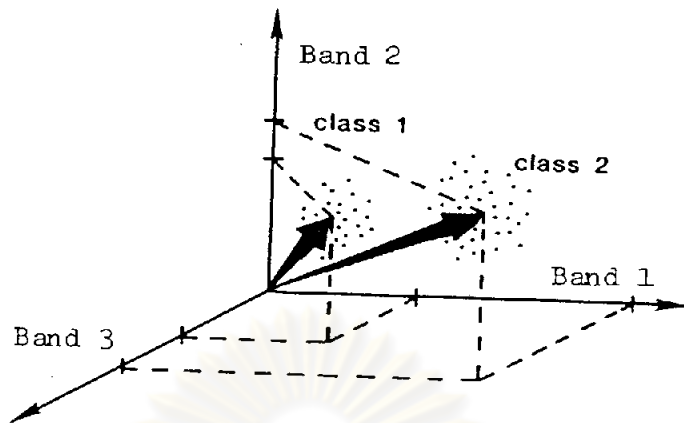
\underline{X} คือ p -component column vector

$\underline{\mu}$ คือ p -component mean vector

$$\underline{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix} = E \left[\underline{X} \right]$$

Σ คือ $p \times p$ covariance matrix ซึ่งเป็น symmetric positive definite matrix

$$\Sigma = E \left[(\underline{X}-\underline{\mu})(\underline{X}-\underline{\mu})' \right]$$



รูปที่ 13 เวกเตอร์ของจุดภาพในรูป 3 มิติ

3.2.2 ทฤษฎีการตัดสินใจ (Decision Theory)

โดยปกติแล้วการดำเนินกิจกรรมใดๆ ก็ตาม ซึ่งอาจจะเป็นงานที่มีความยุ่งยากสลับซับซ้อน มีหลายขั้นตอน เช่น โครงการอวกาศ หรือแม้แต่การดำเนินชีวิตประจำวันของมนุษย์ ผู้ที่ต้องรับผิดชอบในกิจกรรมนั้นๆ มักจะต้องมีปัญหาคัดเลือกที่จะดำเนินการหรือปฏิบัติอย่างไรจึงจะถูกต้องเหมาะสม นั่นคือ ต้องมีการหาเกณฑ์หรือข้อมูลข่าวสาร มาเป็นตัวกำหนดแนวทางซึ่งก็มักมีแนวทางที่จะต้องเลือกอยู่หลายแนวทาง จึงเกิดปัญหาคัดเลือกที่จะเลือกแนวทางที่ดีที่สุดเกิดการสูญเสียน้อยที่สุดขึ้น ในทฤษฎีการตัดสินใจจะมีปัญหาคัดเลือกที่ประกอบด้วย กลุ่มสภาวะการณ (State of nature) กลุ่มทางเลือก (Action space) และฟังก์ชันความสูญเสีย (Loss function) ในการนี้ผู้ตัดสินใจก็จะเลือกทางเลือก (action) ที่ดีที่สุดจากกลุ่มหรือเซต (Set) ทางเลือกทั้งหมดที่มี ซึ่งถ้าทำการเลือกโดยไม่ใช้ข้อมูลอื่นๆ มาประกอบก็จะเรียกวิธีการเช่นนี้ว่า Decision without Information และถ้ามีการใช้ข้อมูลอื่นมาประกอบ ซึ่งอาจเป็นการเก็บรวบรวมข้อมูลแบบปฐมภูมิ (Primary data) หรือข้อมูลทุติยภูมิ (Secondary data) ก็ดี การใช้ข้อมูลสนเทศเหล่านี้มาประกอบการตัดสินใจในลักษณะเช่นนี้ เรียกว่า Decision with Information

สำหรับในการศึกษาคำนี้มีการเก็บรวบรวมข้อมูล คือ จุดภาพ (pixel) นั้นก็คือ เป็นการนำลักษณะการแจกแจงของตัวแปรสุ่มที่มีการแจกแจงความน่าจะเป็นแสดงได้ด้วยฟังก์ชันความหนาแน่นที่เรียกว่า Prior probability density function และนำมาประกอบกับหลักเกณฑ์ของทฤษฎีการตัดสินใจ เป็นฟังก์ชัน การตัดสินใจที่ใช้สำหรับการจำแนกประเภทข้อมูลหรือตัดสินใจ เลือกจุดภาพที่เก็บรวบรวมมาขึ้นว่า เป็นวัตถุหรือสสารใดนั่นเอง เรียกฟังก์ชันการตัดสินใจลักษณะดังกล่าวนี้ว่า Discriminant function ซึ่งอธิบายได้ดังนี้ (7 : 152)

กำหนดให้

Ω คือ State of nature หรือ Parameter space

$$\Omega = (\theta_1, \theta_2, \dots, \theta_m)$$

A คือ Action space

$$A = (a_1, a_2, \dots, a_m)$$

$L(a, \theta)$ คือ เซต (Set) ของฟังก์ชันสูญเสีย (Loss function) ดังนั้น

$L(a_i, \theta_j)$ คือ การสูญเสียที่เกิดขึ้นเมื่อตัดสินใจเลือกเป็น class ที่ i
ทั้งๆ ที่เป็น class ที่ j

$$; i, j = 1, 2, \dots, m$$

ถ้ากำหนดให้ค่าเฉลี่ยของการสูญเสียที่เป็นไปได้ทั้งหมด (Average loss) คือ ความเสี่ยง (Risk) โดยที่

$R_X(a)$ เป็นฟังก์ชันการเสี่ยงที่เกิดขึ้น

$$R_X(a_i) = E[L(a_i, \theta_j)] \dots \dots \dots (5)$$

ด้วยวิธีการตัดสินใจแบบเบย์ (Bayes Optimal Decision) จะต้องทำการ Minimize

$R_X(a)$ ดังนั้นจาก (5)

$$R_X(a_i) = \sum_{j=1}^m L(a_i, \theta_j) p(\theta_j | X) \dots \dots \dots (6)$$

โดยที่ $p(\theta_j|X)$ คือ Posterior probability density function of θ_j given X จาก Bayes' rule

$$p(\theta_j|X) = p(X|\theta_j) p(\theta_j)/p(X) \dots\dots\dots(7)$$

เมื่อ $p(X|\theta_j)$ คือ Conditional probability density function of X given θ_j

$p(\theta_j)$ คือ Prior probability density function of θ_j

$p(X)$ Marginal probability density function of X ซึ่ง

$$p(X) = \sum_{j=1}^m p(X|\theta_j)p(\theta_j)$$

ดังนั้นจาก (6)

$$R_X(a_i) = \sum_{j=1}^m L(a_i, \theta_j)p(X|\theta_j)p(\theta_j)/p(X) \dots\dots(8)$$

จากข้อกำหนดต่อไปนี้จะนำมาประกอบการสร้างฟังก์ชันการตัดสินใจต่อไป คือ

(1) การ Mimimize เซตของฟังก์ชันใดๆ ก็เปรียบเสมือนการ Maximize ค่าลบของฟังก์ชันชุดเดียวกัน $\dots\dots\dots(9-1)$

(2) กำหนดให้เซตของฟังก์ชันสูญเสีย (Loss function) เป็น

$$L(a_i, \theta_j) = \begin{cases} 0 & \text{เมื่อตัดสินใจถูกต้อง } (i = j) \\ 1 & \text{เมื่อตัดสินใจผิด } (i \neq j) \end{cases} \dots\dots\dots(9-2)$$

(3) ถ้า $\{g_i(X), i = 1, 2, \dots, m\}$ คือ เซตของฟังก์ชันการตัดสินใจใดๆ เราสามารถที่จะทำการ บวก ลบ คูณ ด้วยตัวคงที่ หรือใส่ \ln กับฟังก์ชันนั้นๆ (Monotonic-transformation) ก็จะไม่ทำให้การตัดสินใจ เปลี่ยนแปลง กล่าวคือ

$$g_i^1(X) = g_i(X) \pm k \quad \text{เมื่อ } k \text{ คือตัวคงที่} \quad \dots\dots\dots(9-3)$$

$$g_i^2(X) = g_i(X) \cdot k \quad \text{เมื่อ } k \text{ คือตัวคงที่} \quad \dots\dots\dots(9-4)$$

$$g_i^3(X) = \ln g_i(X) \quad \dots\dots\dots(9-5)$$

จาก (8) และ (9-1) ซึ่งเป็นการเปลี่ยนจากการ Minimize เป็น Maximize จะได้
ฟังก์ชันการตัดสินใจ คือ

$$\begin{aligned}
 g_i(X) &= -R_X(a_i) \\
 &= -\sum_{j=1}^m L(a_i, \theta_j) p(X|\theta_j) p(\theta_j) / p(X) \\
 &= -\sum_{\substack{j=1 \\ i \neq j}}^m p(X|\theta_j) p(\theta_j) / p(X) \\
 &= \frac{-1}{p(X)} \sum_{\substack{j=1 \\ j \neq i}}^m p(X|\theta_j) p(\theta_j) \dots\dots\dots(10)
 \end{aligned}$$

ในที่นี้ $p(X)$ จะเป็นตัวคงที่ ซึ่งจาก (9-4) จะได้ฟังก์ชันการตัดสินใจตัวใหม่
กล่าวคือ

$$\hat{g}_i(X) = -\sum_{\substack{j=1 \\ i \neq j}}^m p(X|\theta_j) p(\theta_j) \dots\dots\dots(11-1)$$

$$\text{จาก } p(X) = \sum_{j=1}^m p(X|\theta_j) p(\theta_j)$$

$$= p(X|\theta_i) p(\theta_i) + \sum_{\substack{j=1 \\ i \neq j}}^m p(X|\theta_j) p(\theta_j)$$

$$\sum_{\substack{j=1 \\ i \neq j}}^m p(X|\theta_j) p(\theta_j) = p(X) - p(X|\theta_i) p(\theta_i) \dots\dots\dots(11-2)$$

แทนค่า (11-2) ลงใน (11-1)

$$\hat{g}_i(X) = -p(X) + p(X|\theta_i) p(\theta_i)$$

จาก (9-2) และ $p(X)$ เป็นตัวคงที่ และจะได้ฟังก์ชันการตัดสินใจตัวใหม่ กล่าวคือ

$$\begin{aligned} g_i''(X) &= g_i'(X) + p(X) \\ &= p(X|\theta_i)p(\theta_i) \dots\dots\dots(12) \end{aligned}$$

นั่นคือ ฟังก์ชันการตัดสินใจที่ได้จะเท่ากับผลคูณระหว่าง Conditional probability function of X given θ [$p(X|\theta_i)$] กับ Prior probability density function [$p(\theta_i)$] และเรียกฟังก์ชันการตัดสินใจนี้ว่า

Discriminant function โดยจะตัดสินใจเลือก X อยู่ในกลุ่มที่ i ($X \in \theta_i$) ถ้า

$$p(X|\theta_i)p(\theta_i) > p(X|\theta_j)p(\theta_j) \quad ; \quad j = 1, 2, \dots, m$$

นั่นคือ ถ้าให้ $g_i(X) = p(X|\theta_i)p(\theta_i) \dots\dots\dots(13-1)$

$$g_j(X) = p(X|\theta_j)p(\theta_j) \dots\dots\dots(13-2)$$

ดังนั้นจะตัดสินใจเลือก X อยู่ใน class ที่ i ก็ต่อเมื่อ

$$g_i(X) > g_j(X) \quad i \neq j \dots\dots\dots(13-3)$$

3.3 การประยุกต์

จากทฤษฎีสถิติที่กล่าวแล้วในข้อที่ 3.2 เมื่อนำมาประยุกต์ใช้เพื่อการจำแนกประเภทข้อมูลจากดาวเทียมตามวัตถุประสงค์ของการศึกษา อธิบายได้ดังนี้ กำหนดให้

$\Omega = (\theta_1, \theta_2, \dots, \theta_c)$ เป็น เซต (set) ของกลุ่มหรือประเภทข้อมูล (class) ซึ่งในการศึกษาครั้งนี้แบ่งประเภทข้อมูลออกเป็น 4 ประเภท (class) คือ ป่าไม้ ปาล์มน้ำมัน นาข้าว และถนน ดังนั้น

$$\Omega = (\text{ป่าไม้}, \text{ปาล์มน้ำมัน}, \text{นาข้าว}, \text{ถนน})$$

$A = (a_1, a_2, a_3, a_4)$ เป็น เซตของการเลือกหรือการตัดสินใจที่เหมาะสม โดยที่ a_1 คือ การตัดสินใจเลือกจุดภาพ (pixel) ใดๆ ในอาณาบริเวณที่ศึกษาว่าเป็นข้อมูลประเภทป่าไม้ในทำนองเดียวกัน a_4 คือ การตัดสินใจเลือกจุดภาพ (pixel) ในอาณาบริเวณที่ศึกษาว่าเป็นข้อมูลประเภทถนน เป็นต้น

$L(a_i, \theta_j)$ = ฟังก์ชันความสูญเสีย (Loss function) ที่เกิดขึ้นเมื่อทำการตัดสินใจเลือก a_i เมื่อกำหนด θ_j ทั้งนี้ $i, j = 1, 2, 3, 4$

$$L(a_i, \theta_j) = \begin{cases} 0 & \text{เมื่อตัดสินใจเลือกจุดภาพนั้นๆ} \\ & \text{เป็นประเภทข้อมูล (class) ที่ถูกต้อง} \dots\dots\dots(14) \\ 1 & \text{เมื่อตัดสินใจเลือกจุดภาพนั้นๆ} \\ & \text{เป็นประเภทข้อมูล (class) ที่ผิด} \end{cases}$$

เช่น เกิดความสูญเสีย เมื่อตัดสินใจจุดภาพนั้นให้ เป็นปาล์มน้ำมัน โดยความเป็นจริงแล้ว เป็นป่าไม้หรือในทำนองกลับกันตัดสินใจให้จุดภาพนั้น เป็นป่าไม้ ทั้งๆ ที่ความเป็นจริง เป็นปาล์มน้ำมัน

X = จุดภาพ (pixel) ที่เป็น 4-component vector ซึ่งแต่ละ component คือ ค่าระดับสีเทาที่อ่านได้จากแต่ละแชนด์ในที่กำหนดใช้จำนวนแชนด์ทั้งหมด 4 แชนด์ ดังนี้

$$(p = 4) \quad X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix}$$

ทั้งนี้ภายใต้สมมติฐาน (assumption) ให้ X มีการแจกแจงเป็นแบบ Multivariate Normal Distribution

$$P(X) = \text{Marginal pdf ของ } X$$

$$h(\theta_j) = \text{Prior probability ของ } \theta_j \text{ (หรือความน่าจะเป็นที่จะเกิดประเภทข้อมูลที่ } j)$$

$$P(X|\theta_j) = \text{Conditional probability density function of } X \text{ given } \theta_j$$

$$P(\theta_j|X) = \text{Posterior probability density function of } \theta_j \text{ given } X$$

ในทำนองเดียวกันกับ (13-1) และ (13-2) จะได้

$$g_i(X) = P(X|\theta_i)h(\theta_i) \dots\dots\dots(15-1)$$

$$g_j(X) = P(X|\theta_j)h(\theta_j) \dots\dots\dots(15-2)$$

ซึ่งเป็นฟังก์ชันการตัดสินใจที่ใช้ในการจำแนกประเภทข้อมูลโดยตัดสินใจเลือก Pixel(X) อยู่ในประเภทข้อมูลหรือ class ที่ i ถ้า

$$g_i(X) > g_j(X) \text{ สำหรับทุกค่าของ } i \neq j \dots\dots\dots(15-3)$$

โดยสรุปจะเห็นได้ว่า การตัดสินใจของเราจะขึ้นอยู่กับ X ซึ่งเป็นตัวอย่างสุ่ม และ $h(\theta)$ ซึ่งเป็น Prior probability density ของ class ที่เราพิจารณาอยู่ เรียกฟังก์ชันการตัดสินใจ ($g_i(X)$) นี้ว่า Discriminant function

เมื่อนำทฤษฎีการแจกแจงของตัวอย่างสุ่มที่ได้จาก (1) หรือ (2) หรือ

(4) และพิจารณา pdf ของ X เป็นแบบมีเงื่อนไข เมื่อกำหนด θ นั่นก็คือ จะได้ $P(X|\theta_i)$ เป็นไปในแต่ละกรณี กล่าวคือ

ในกรณีของ Univariate Normal Distribution

$$P(X|\theta_i) = \frac{1}{\sqrt{2\pi} \sigma_i} \exp \left[-\frac{1}{2} \left(\frac{X-\mu_i}{\sigma_i} \right)^2 \right] \dots\dots\dots(16)$$

ดังนั้น

$$g_i(X) = \frac{1}{\sqrt{2\pi} \sigma_i} \exp \left[-\frac{1}{2} \left(\frac{X-\mu_i}{\sigma_i} \right)^2 \right] h(\theta_i) \dots\dots(17)$$

หรือ ในกรณีของ Multivariate Normal Distribution

$$P(X|\theta_i) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (X-\mu_i)' \Sigma_i^{-1} (X-\mu_i) \right] \dots\dots(18)$$

$$g_i(X) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (X-\mu_i)' \Sigma_i^{-1} (X-\mu_i) \right] h(\theta_i) \dots(19)$$

3.4 การประมาณค่าสถิติจากตัวอย่าง

จาก Discriminant function ที่กล่าวแล้วนั้น (18) จำเป็นต้องใช้ค่าสถิติเกี่ยวกับค่าเฉลี่ย (μ_i) และค่าความแปรปรวนร่วม (Σ_i) ซึ่งไม่สามารถทราบค่าที่แท้จริงของมัน จึงต้องประมาณค่าเหล่านี้จากพื้นที่ตัวอย่าง (Training area) โดยการกำหนดพื้นที่ตัวอย่างที่เหมาะสมในแต่ละประเภทข้อมูล (class) แล้วคำนวณค่าสถิติที่ต้องการจากพื้นที่ตัวอย่างนั้น

กำหนดให้

$$\text{Pixel } X = \begin{bmatrix} x_{i11} \\ x_{i21} \\ x_{i31} \\ x_{i41} \end{bmatrix}$$

x_{ijl} = ค่าระดับสีเทาในพื้นที่ตัวอย่างของจุดภาพที่ l ของแพนดที่ j class ที่ i
 ; $i = 1, 2, 3, 4$
 $j = 1, 2, 3, 4$
 $l = 1, 2, \dots, t_i$

เมื่อ t_i = จำนวนจุดภาพทั้งหมดในพื้นที่ตัวอย่างทุกพินของ class ที่ i

$$m_{ij} = \frac{1}{t_i} \sum_{l=1}^{t_i} x_{ijl} \dots\dots\dots(20-1)$$

$$\text{Sample mean vector } M_i = \begin{bmatrix} m_{i1} \\ m_{i2} \\ m_{i3} \\ m_{i4} \end{bmatrix}$$

s_{ijk} = ค่าความแปรปรวนร่วมที่คำนวณจากพื้นที่ตัวอย่างระหว่าง Band ที่ j กับ k ของ class ที่ i

$$s_{ijk} = \frac{1}{t_i - 1} \cdot \sum_{l=1}^{t_i} (x_{ijl} - m_{ij})(x_{ikl} - m_{ik}) \dots \dots \dots (20-2)$$

$$\text{Sample covariance matrix } S_i = \begin{bmatrix} s_{i11} & s_{i12} & s_{i13} & s_{i14} \\ s_{i21} & s_{i22} & s_{i23} & s_{i24} \\ s_{i31} & s_{i32} & s_{i33} & s_{i34} \\ s_{i41} & s_{i42} & s_{i43} & s_{i44} \end{bmatrix}$$

โดยวิธีการประมาณค่าแบบ Maximum-Likelihood Estimation จะได้ M_i และ S_i เป็นตัวประมาณที่ไม่เอนเอียง (unbiased estimators) สำหรับ μ_i และ Σ_i ตามลำดับ

สำหรับ Priori probability ($h(\theta_i)$) ซึ่งเป็นความน่าจะเป็นของการเกิดประเภทข้อมูล (class) ใดๆ ตามที่กำหนดนั้น สามารถคำนวณได้ดังนี้

1. Equal priori probability คือให้ความน่าจะเป็นในการที่จะเกิด class ใดๆ เท่ากัน ดังนี้

ถ้าให้ C = จำนวนประเภทข้อมูลทั้งหมดที่ได้กำหนด

$$h(\theta_1) = h(\theta_2) = \dots = h(\theta_i) = \frac{1}{C}$$

2. Priori probability proportional to size คือให้ความน่าจะเป็นในการที่จะเกิด class ใดๆ ไม่เท่ากัน ทั้งนี้โดยการพิจารณาข้อมูลที่ได้จากแหล่งอื่นประกอบ เช่น จากผลการสำรวจที่ผ่านมา (Previous survey) ตลอดจนจากประสบการณ์ที่พอจะทราบขนาดของเนื้อที่ของประเภทข้อมูลใดๆ ในท้องที่หรือพื้นที่ที่ต้องการจะศึกษา

ดังนั้น Discriminant function ที่จะนำมาใช้ในการจำแนกข้อมูลจาก
ดาวเทียม คือ จาก (19) จะเป็น

$$g_i(X) = \frac{1}{(2\pi)^{\frac{p}{2}} |S_i|^{1/2}} \exp \left[-\frac{1}{2}(X-M_i)' S_i^{-1}(X-M_i) \right] h(\theta_i) \dots (21)$$

3.5 วิธีการทางสถิติที่ใช้จำแนกประเภทข้อมูล

จากวิธีการจำแนกประเภทข้อมูลจากดาวเทียมทั้งหมดที่กล่าวมาแล้วในข้อที่ 3.1

นั้น กำหนดใช้วิธีการจำแนกประเภทข้อมูลจากดาวเทียมด้วยเครื่องคอมพิวเตอร์เป็นแบบ
Supervised analysis สำหรับการศึกษาคั้งนี้ จากความสามารถของโปรแกรมสำเร็จรูป
MOA-RECOGX มีวิธีการทางสถิติที่ใช้จำแนกประเภทข้อมูลจากดาวเทียม 3 วิธีด้วยกัน นับตั้งแต่
การใช้วิธีการและสมมติฐานทางสถิติขั้นพื้นฐานจนถึงการสถิติขั้นสูง ทั้งนี้ขึ้นอยู่กับข้อสมมติฐานที่
กำหนดใช้ในแต่ละวิธี ได้แก่ Level Slicing, Euclidean distance และ Maximum-
likelihood ทั้งนี้ในแต่ละวิธีการมีหลักการ ดังต่อไปนี้

3.5.1 Level Slicing (LS) เป็นวิธีการทางสถิติขั้นพื้นฐาน ใช้หลักการ

ทางสถิติง่ายๆ ประกอบกับการพิจารณาตัดสินใจของผู้วิจัย (subjective) ที่จะเลือกใช้ข้อมูล
ข่าวสาร (information) ใดๆ อาทิเช่น จากประสบการณ์ของผู้วิจัยเองหรือผลการสำรวจ
ทางภาคพื้นดิน (Ground Truth) ตลอดจนผลการวิจัยแหล่งอื่นๆ ที่ผ่านมา เป็นต้น ตัวอย่าง
หลักการทางสถิตินั้นอาจพิจารณาได้จาก

(1) กราฟแผนภูมิแท่ง (Histogram) ที่แสดงความถี่ของระดับสีเทา

ในพื้นที่ตัวอย่าง (Training area) ศึกษาลักษณะการกระจายของค่าระดับสีเทาของประเภท
ข้อมูล (class) แต่ละประเภทในแต่ละแถบแล้วพิจารณาเลือกค่าระดับสีเทาสูงสุด (maximum)
และต่ำสุด (minimum) จากกราฟแผนภูมิแท่ง ทั้งนี้พิจารณาว่าค่าระดับสีเทาของแต่ละประเภท
ข้อมูลมีความเหลื่อมซ้อน (overlap) กันมากน้อยเพียงใด ถ้าเหลื่อมซ้อนกันจะทำให้ค่าสูงสุดและต่ำสุด
ของแต่ละประเภทข้อมูลคู่หนึ่งๆ เป็นค่าเดียวกันหรือใกล้เคียงกัน ทำให้พิจารณาตัดสินใจเลือก
จุดภาพกระทำไม่ได้จำเป็นต้องปรับค่าสูงสุดหรือต่ำสุดเสียใหม่ ตัวอย่างเช่น จากรูปที่ 14 อาจ
พิจารณากำหนดค่าสูงสุดเท่ากับ 45 ค่าต่ำสุดเท่ากับ 20 เป็นต้น



รูปที่ 14 แผนภูมิแท่ง ใช้พิจารณาค่าสูงสุดและต่ำสุดในวิธีการแบบ Level Slicing

(2) ค่าสถิติต่างๆ ที่ได้จากพื้นที่ตัวอย่าง (Training area)

ของกลุ่มหรือประเภทข้อมูล (class) ที่กำหนดไว้ ค่าสถิตินั้นได้แก่ ค่าเฉลี่ยของระดับสีเทา และค่า เบี่ยงเบนมาตรฐาน เมื่อนำค่าสถิติดังกล่าวนี้มากำหนดค่าระดับสีเทาสูงสุดและต่ำสุด จากสมการ

$$\text{ค่าระดับสีเทาสูงสุด} = \text{ค่าเฉลี่ยของระดับสีเทา} + (k) \text{ ค่า เบี่ยงเบนมาตรฐาน} \dots\dots\dots(22)$$


$$\text{ค่าระดับสีเทาต่ำสุด} = \text{ค่าเฉลี่ยของระดับสีเทา} - (k) \text{ ค่า เบี่ยงเบนมาตรฐาน} \dots\dots\dots(23)$$

โดยอาศัยทฤษฎีการแจกแจงตัวอย่าง (Sampling distribution) ที่กล่าวว่าตัวอย่างสุ่มจากประชากรที่มีการแจกแจงเป็นแบบปกติแล้ว การแจกแจงของค่าเฉลี่ยตัวอย่างของทุกครั้ง เรือนตัวอย่างที่เป็นไปได้ทั้งหมด ก็จะมีการแจกแจงเป็นแบบปกติด้วย ดังนั้นค่าเฉลี่ยตัวอย่างที่เป็นไปได้จะเกิดภายใต้พื้นที่เส้นโค้งปกติด้วยความน่าจะเป็นต่างๆ กัน

เมื่อพิจารณา เฉพาะจุดภาพ ที่อยู่ภายใต้พื้นที่เส้นโค้งปกติด้วยความ

น่าจะเป็นต่างๆ กัน กล่าวคือ กำหนดให้เท่ากับ 0.68 (หรือ $k = 1$) , 0.95 (หรือ $k = 2$) และ 0.99 (หรือ $k = 3$) ผลจากการกำหนดค่าความน่าจะเป็นดังกล่าวมาน้อยแตกต่างกัน เปรียบได้เสมือนกับการกำหนดระดับความมั่นใจ (coefficient of confidence) ที่ใช้ในการประมาณค่าแบบช่วง คือ ถ้ากำหนดระดับความมั่นใจค่าก็จะทำให้ช่วงการประมาณค่าแคบ แต่ให้ค่าประมาณที่ใกล้

ค่าจริง (parameter) มากขึ้น ในทำนองเดียวกัน เมื่อกำหนดระดับความมั่นใจสูงก็ จะทำให้ช่วงการประมาณค่ากว้าง แต่ให้ค่าประมาณที่ห่างไปจากค่าจริง เมื่อนำ เปรียบ- เทียบกับจุดภาพของแต่ละประ เภทข้อมูลที่อยู่ใต้พื้นที่ เส้น โค้งปกติ ซึ่งอาจจะเหลื่อมซ้อนกัน (overlap) ทำให้ส่วนที่เหลื่อมซ้อนกันนั้น ไม่สามารถตัดสินใจได้ว่า จุดภาพนั้นๆ เป็น ข้อมูลประ เภทใด จึงไม่นำจุดภาพที่เหลื่อมซ้อนกันนั้นมาพิจารณา โดยตัดออกจากการตัดสินใจ เลยทำให้จุดภาพที่ไต่จะ เสนอผลออกมาในลักษณะที่เรียกว่าไม่สามารถจำแนกได้ (unclassification)



รูปที่ 15 พื้นที่ใต้ เส้น โค้งปกติ ส่วนที่แรเงาหมายถึงพื้นที่ใต้ เส้น โค้งปกติ เมื่อ $k = 1, 2$ และ 3

ค่าระดับสี เทาสูงสุดและต่ำสุดของประ เภทข้อมูลใดๆ ใน แต่ละแผนด์จะ เป็นช่วง ที่ใช้ เป็น เกณฑ์พิจารณาจำแนกข้อมูลทั้งหมดของบริษัท เวทที่ศึกษา ข้อมูลหรือจุดภาพใดที่อยู่ในช่วง ค่า สูงสุดและต่ำสุดครบทุกแผนด์ ก็จะมีการพิจารณาคัดสินใจให้จุดภาพนั้น เป็นประ เภทข้อมูลนั้น ตัวอย่าง เช่น เมื่อนำค่าระดับสี เทาของจุดภาพในพื้นที่ตัวอย่างของประ เภทข้อมูลปาล์มน้ำมัน มาคำนวณหาค่า เฉลี่ยและส่วน เบี่ยงเบนมาตรฐานได้ในแต่ละแผนด์ ดังนี้

	ค่า เฉลี่ย	ส่วน เบี่ยงเบนมาตรฐาน
แผนด์ที่ 4	48.40	2.99
แผนด์ที่ 5	52.78	4.64
แผนด์ที่ 6	81.30	4.91
แผนด์ที่ 7	99.71	7.02

สมมติว่าจากการศึกษากราฟแผนภูมิแท่งประกอบข้อมูลภาคพื้นดิน พบว่าค่าระดับสีเทาของจุดภาพประเภทข้อมูลปาล์มน้ำมัน เหลื่อมซ้อนกับข้อมูลประเภทป่าไม้มาก จึงพิจารณาจุดภาพเฉพาะพื้นที่ได้ โค้งปกติ เป็นร้อยละ 68.27 ของพื้นที่ได้ เส้นโค้งปกติของจุดภาพทั้งหมด นั่นคือ กำหนดใช้ $k = 1$ คำนวณหาค่าสูงสุดและต่ำสุดของประเภทข้อมูลปาล์มน้ำมันในแต่ละแบนด์ได้เป็น (51.39 , 45.41) (57.42 , 48.14) (86.21 , 76.39) (106.73 , 92.69) ดังนั้น เกณฑ์การตัดสินใจ เลือกจุดภาพใดๆ ว่าเป็นข้อมูลประเภทใด เช่น จุดภาพ x_1 มีค่าระดับสีเทาเป็น 47.25, 50.29, 78.92 และ 100.45 ในแบนด์ที่ 4, 5, 6, และ 7 ตามลำดับ จะเห็นว่า จุดภาพ x_1 มีค่าระดับสีเทาอยู่ในช่วงระหว่างค่าสูงสุดและต่ำสุดในทุกแบนด์ ดังนั้นจะตัดสินใจ เลือกจุดภาพ x_1 นั้นเป็น ปาล์มน้ำมัน

3.5.2 Maximum-likelihood (ML) เป็นวิธีการทางสถิติที่นำมาใช้ในการจำแนกประเภท เพื่อคัดเลือกตัวแปรกลุ่มหนึ่งหรือชุดหนึ่งที่ต้องการศึกษาออกเป็นประเภทข้อมูลใดๆ ตามที่กำหนดไว้ โดยการนำ Discriminant function (21) แทนค่าในฟังก์ชันดังกล่าวด้วยค่าสถิติต่างๆ เช่น ค่าเฉลี่ย และ เมตริกความแปรปรวนร่วม ตลอดจน Prior probability ของการที่เกิดประเภทข้อมูลใดๆ คำนวณได้ค่าจำนวนหนึ่งใช้เป็นเกณฑ์ในการตัดสินใจ กล่าวคือ จากทฤษฎีการตัดสินใจของเบย์ส์ (Optimal Bayes Decision) จะพิจารณาเลือกจุดภาพหนึ่งๆ อยู่ในประเภทข้อมูลที่ i ถ้า

$$g_i(X) > g_j(X) \quad \text{สำหรับทุกค่าของ } i \neq j$$

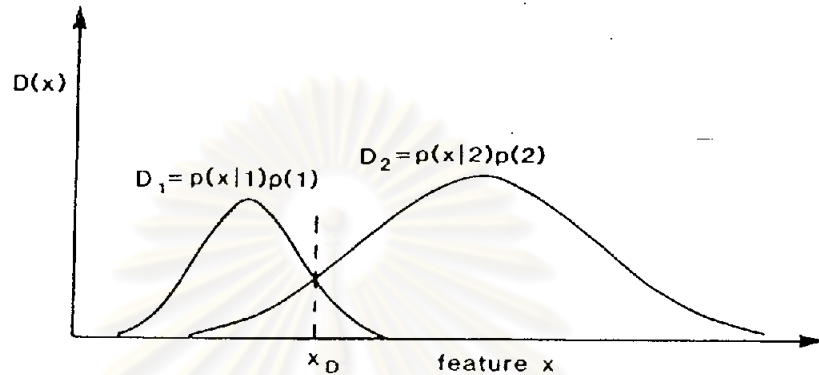
นั่นคือถ้า กำหนดให้มีประเภทข้อมูลอยู่ 2 ประเภท (2 class)

$$\text{จุดภาพนั้นอยู่ในประเภทข้อมูลที่ 1 ถ้า } g_1(X) > g_2(X)$$

$$\text{หรือ จุดภาพนั้นอยู่ในประเภทข้อมูลที่ 2 ถ้า } g_2(X) > g_1(X)$$

$$\text{โดยที่ } g_i(X) = P(X/\theta_i)h(\theta_i)$$

อาจแสดงด้วยภาพ 1 มิติ ในกรณีสมมติว่า มี 2 ประเภทข้อมูล ดังนี้



รูปที่ 16 แสดง Discriminant function ของ Optimal Bayes Decision

ด้วยคุณสมบัติของทฤษฎีการตัดสินใจ เราสามารถที่จะ ขวาก ลบ คูณ หรือใส่ ln ด้วยตัวคงที่กับ Discriminant function ใดๆ แล้วจะไม่มีผลต่อการตัดสินใจ ตัวอย่างเช่น

$$g_i(X) = a \left[P(X|\theta_i)h(\theta_i) \right] + b \dots\dots\dots(24-1)$$

$$g_i(X) = \ln \left[P(X|\theta_i)h(\theta_i) \right] \dots\dots\dots(24-2)$$

ซึ่งฟังก์ชันทั้งสอง ก็ยังคง เป็น Discriminant function ที่ใช้ในการตัดสินใจอยู่นั่นเอง จาก (24)

$$g_i(X) = \ln|h(\theta_i)| - \frac{p}{2} \ln(2\pi) - \frac{1}{2} \ln |S_i| - \left[\frac{1}{2}(X-M_i)'S_i^{-1}(X-M_i) \right] \dots\dots\dots(25)$$

จะเห็นว่า $-\frac{p}{2} \ln(2\pi)$ จะเป็นตัวคงที่ซึ่งปรากฏอยู่ในทุกๆ $g_i(X)$ ทำให้สามารถตัดออก จากสมการได้ โดยไม่ทำให้ผลการตัดสินใจไม่เปลี่ยนแปลง ดังนั้น ผลที่เหลือก็คือ

$$g_i(X) = \ln|h(\theta_i)| - \frac{1}{2} \ln|S_i| - \frac{1}{2}(X-M_i)' S_i^{-1}(X-M_i) \dots(26)$$

เรียกสมการที่ได้ชื่อว่า Maximum-likelihood ซึ่งเป็น Discriminant function ที่ใช้ในการพิจารณาตัดสินใจเลือกจุดภาพ (pixel) ใด ๆ

3.5.3 Euclidean distance (ED) เป็นการนำ Discriminant function มาใช้ในการจำแนกประเภท เช่นเดียวกับกับในวิธี Maximum-likelihood โดยพิจารณาเฉพาะระยะทางของจุดภาพต่างๆ ที่กระจายอยู่ในรูปหลายมิติ จุดภาพใดที่มีระยะทางใกล้กับค่าเฉลี่ยของประเภทข้อมูลนั้นๆ มากที่สุดก็จะตัดสินใจเลือกจุดภาพใด เป็นประเภทข้อมูลนั้น

เมื่อพิจารณากรณีพิเศษ (special case) ของวิธี Maximum-likelihood กล่าวคือ (9 : 49)

1. ถ้าเราสมมติ เมตริกของภาพความแปรปรวนร่วม (covariance matrix) ของทุกๆ ประเภทข้อมูล (class) เท่ากัน

$$\Sigma_i = \Sigma_j = \dots = \Sigma_o \dots\dots\dots(27)$$

นั่นคือ $S_i = S_j = \dots = S_o \dots\dots\dots(28)$

2. กำหนดให้ priori probability ของการเกิดประเภทข้อมูลนั้นๆ เท่ากัน ทุกๆ class

$$h(\theta_i) = h(\theta_j) = \dots = h(\theta_o) \dots\dots\dots(29)$$

ดังนั้น Discriminant function จาก (26) จะเปลี่ยนเป็น

$$g_i(X) = A - \frac{1}{2} (X-M_i)' S_o^{-1} (X-M_i) \dots\dots\dots(30)$$

ซึ่ง A จะเป็นค่าคงที่และเท่ากับ

$$A = \ln|h(\theta_o)| - \frac{1}{2} \ln|S_o| \dots\dots\dots(31)$$

สามารถตัด A ออกจากสมการได้ ดังนั้น จาก (30) จะเปลี่ยนเป็น

$$g_i(X) = -\frac{1}{2} (X-M_i)' S_o^{-1} (X-M_i) \dots\dots\dots(32)$$

เรียกฟังก์ชันที่ได้ชื่อว่า Mahalanobis distance

เมื่อพิจารณาได้ค่าระดับสีเทาของจุดภาพ (pixel) ในแต่ละแผนดไม่มีความสัมพันธ์กัน (uncorrelated) ดังนั้น ความแปรปรวนร่วมจะมีค่าเป็นศูนย์ ทำให้

$$\Sigma_i = \begin{bmatrix} \sigma_{i11} & & & \\ & \sigma_{i22} & & \\ & & \sigma_{i33} & \\ & & & \sigma_{i44} \end{bmatrix} \dots\dots\dots(33)$$

ดังนั้น $S_i = \begin{bmatrix} S_{i11} & & & \\ & S_{i22} & & \\ & & S_{i33} & \\ & & & S_{i44} \end{bmatrix} \dots\dots\dots(34)$

จาก (32) จะได้

$$g_i^1(X) = \frac{1}{2} (X-M_i)' S_i^{-1} (X-M_i)$$

หรือจาก (9-1) และ (9-2) จะได้

$$g_i^2(X) = (X-M_i)' S_i^{-1} (X-M_i)$$

$$g_i^2(X) = \frac{4}{-2} \sum_{j,k=1}^4 \frac{(x_j - m_{ij})^2}{S_{ijj}} ; i \neq j \dots\dots(35)$$

จะเรียก (35) นี้ว่า Euclidean distance ซึ่งเป็น Discriminant function ที่ใช้พิจารณาเลือกจุดภาพ (pixel) X อยู่ใน class ที่ i เมื่อ

$$g_i(X) > g_j(X) ; \text{สำหรับทุกค่าของ } i \neq j$$

กล่าวโดยสรุป จะเห็นว่า Discriminant function จาก (26) และ (35) จะใช้ข้อมูลข่าวสาร (information) ที่ได้ ดังนี้

Maximum-likelihood จะใช้ข้อมูลข่าวสารเกี่ยวกับ

1. ค่าเฉลี่ย (mean vector) : μ_i
2. ค่าความแปรปรวนร่วม (covariance matrix) : Σ_i
3. Priori probability : $h(\theta_i)$

จะพิจารณาเลือก pixel X อยู่ใน class ที่ i ถ้า

$$g_i(X) > g_j(X) \quad \text{สำหรับทุกค่าของ } i \neq j$$

ซึ่งเป็น Discriminant function ที่ใช้ ความน่าจะเป็นของการเกิด class หนึ่งๆ ของกลุ่มหรือชุดของข้อมูลทั้งหมดที่ศึกษา เป็นส่วนประกอบของฟังก์ชันดังกล่าวนี้ ซึ่งอาจกล่าวได้ว่า ถ้า Priori probability ของ class ใดสูง ก็จะทำให้ $g_i(X)$ มีค่าสูงตามไปด้วย

Euclidean distance จะใช้ข้อมูลข่าวสารเกี่ยวกับ

1. ค่าเฉลี่ย (mean vector) : μ_i
2. ค่าระดับสีเทาของจุดภาพในแต่ละแบนด์ ไม่มีความสัมพันธ์ (uncorrelated)

ดังนั้น ความแปรปรวนร่วม = 0 จึงใช้แต่ค่าความแปรปรวน (Variance)

จะพิจารณาเลือก Pixel X อยู่ใน class ที่ i ถ้า

$$g_i(X) > g_j(X) \quad \text{สำหรับทุกค่าของ } i \neq j$$

ซึ่งเป็น Discriminant function ที่พิจารณาถึงระยะทางระหว่างค่าสี เทากับค่า เฉลี่ย

ศูนย์วิทยุวิทยุ
จุฬาลงกรณ์มหาวิทยาลัย