

บทที่ 2

วรรณกรรมและผลงานวิจัยที่เกี่ยวข้อง

1. วรรณกรรมที่เกี่ยวข้อง

1.1 บุคคลชีวมาตร (Biometric)

บุคคลชีวมาตรเป็นศาสตร์ที่เกี่ยวข้องกับการใช้กระบวนการในการระบุตัวบุคคลหรือตรวจสอบตัวบุคคลโดยอัตโนมัติ ซึ่งสามารถแบ่งออกเป็น 2 ประเภทคือ การใช้ลักษณะทางกายภาพ (Physiological Biometrics) เช่น รูปแบบของลายนิ้วมือ (Fingerprint) รูปลักษณ์ของมือ (Hand Geometry) ลักษณะของเรตินา (Retina Pattern) ลักษณะของม่านตา (Iris Pattern) รูปลักษณ์ใบหน้า (Facial Recognition) กลิ่น (Human Scent) เป็นต้น ประเภทที่สองคือ การใช้ลักษณะทางพฤติกรรม (Behavioural Biometrics) เช่น เสียง (Voice Recognition) เอกลักษณ์ในการพิมพ์ (Keystroke Dynamics) ลักษณะท่าทางการเดิน (Gait Recognition) ลายมือชื่อ (Signature) เป็นต้น มนุษย์ใช้วิธีบุคคลชีวมาตรในการระบุตัวบุคคลอยู่ตลอดเวลา ใช้ลักษณะเฉพาะทางรูปร่าง ใบหน้า น้ำเสียง หรือแม้กระทั่งกลิ่นของแต่ละบุคคลในการระบุว่ารู้จักหรือไม่ ดังนั้นจึงถือได้ว่า บุคคลชีวมาตรเป็นรูปแบบหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence) [17]

การระบุตัวบุคคลโดยใช้บุคคลชีวมาตร สามารถนำมาประยุกต์ใช้งานได้ทั้งในภาครัฐบาลและภาคเอกชน เช่น งานทางด้านรักษาความปลอดภัย ช่วยผู้รักษากฎหมายในการจับตัวผู้กระทำความผิด ช่วยในการตรวจสอบผู้ใช้งานของระบบเครือข่ายคอมพิวเตอร์ การจัดการระบบบริหารงานบุคคล เช่น งานตรวจสอบเวลาการทำงาน ช่วยในการตรวจสอบตัวบุคคลในการซื้อขายสินค้าผ่านทางอินเทอร์เน็ต การจัดการเรื่องการเงินส่วนบุคคลของสถาบันการเงิน เป็นต้น

ข้อดีของการนำเอาบุคคลชีวมาตรมาใช้ในการตรวจสอบหรือระบุตัวบุคคล คือ ทำให้ผู้ใช้ไม่จำเป็นต้องใช้ความจำหรือจำเป็นต้องถือบัตรผ่านใดๆ ก่อให้เกิดความสะดวกและรวดเร็ว ผู้ใช้ไม่จำเป็นต้องจำรหัสผ่าน อีกทั้งยังเป็นการช่วยเพิ่มความปลอดภัย และป้องกันการสูญหายของบัตรผ่านหรือการลักลอบนำเอารหัสผ่านไปใช้ นอกจากนี้บุคคลชีวมาตรยังยากต่อการปลอมแปลง



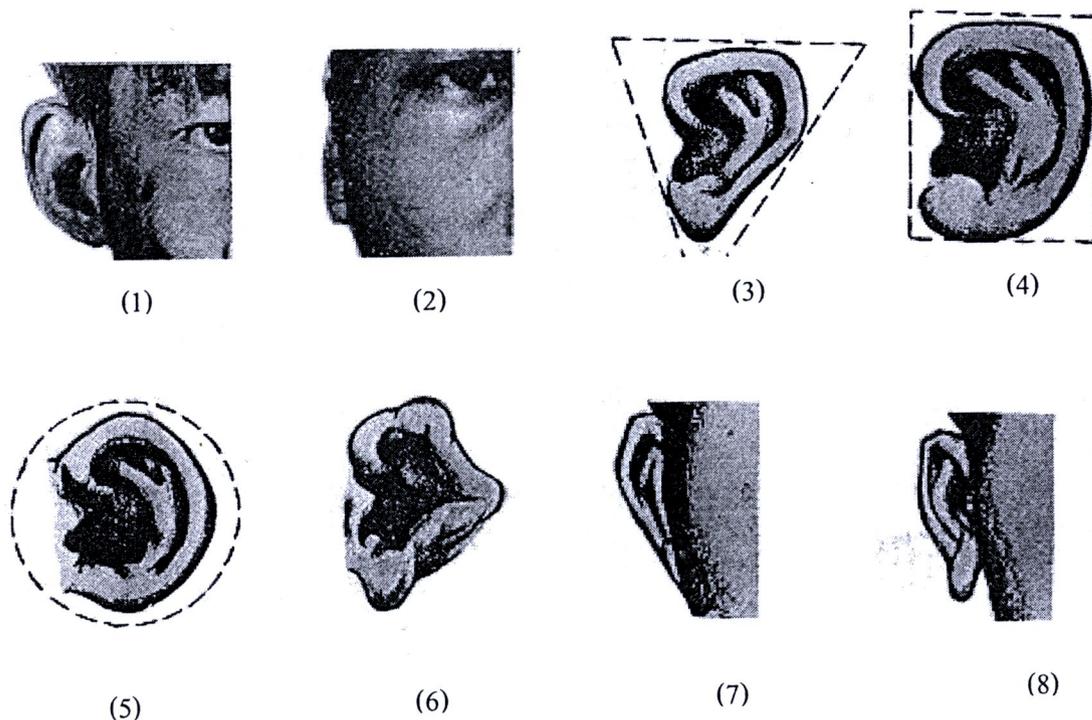
ภาพที่ 1 ตัวอย่างบุคคลชีวมาตรที่สามารถนำมาระบุตัวบุคคลได้

1.2 บุคคลชีวมาตรโดยใช้ไบฮู

บุคคลชีวมาตรโดยใช้ไบฮู เป็นอีกวิธีหนึ่งที่สามารถนำมาใช้ในการตรวจสอบหรือระบุตัวบุคคล ซึ่งในเบื้องต้นเกิดความไม่แน่ใจว่าไบฮูสามารถนำมาใช้ในการตรวจสอบหรือระบุตัวบุคคลได้และไม่เป็นที่น่าสนใจ แต่ได้มีการพิสูจน์ออกมาแล้วว่าไบฮูมีลักษณะไม่เหมือนกันและมีรูปร่างที่ไม่เปลี่ยนแปลงเหมือนใบหน้า [1]

1.2.1 ลักษณะของไบฮู

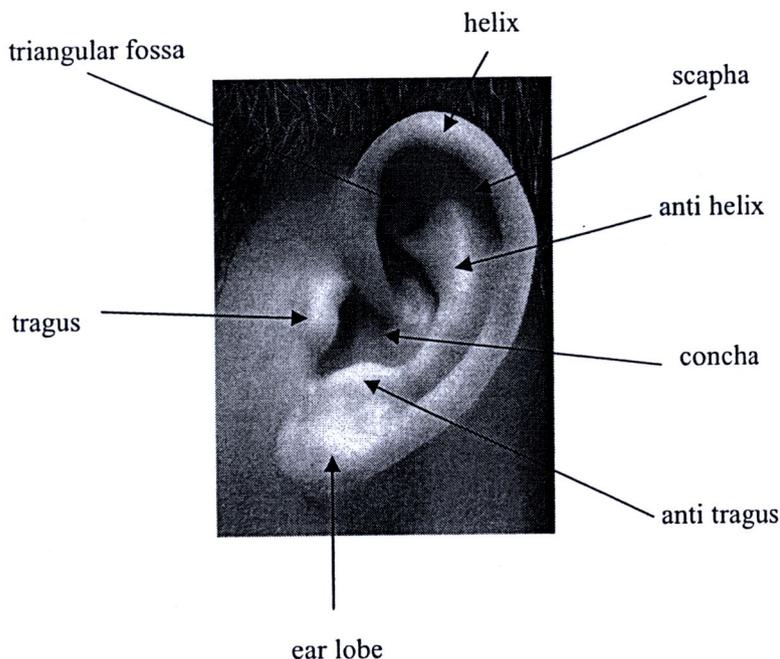
กองทะเบียนประวัติอาชญากร สำนักงานตำรวจแห่งชาติได้แบ่งลักษณะของไบฮูของมนุษย์ไว้ 8 ลักษณะ ได้แก่ หูกาง หูลีบ หูสามเหลี่ยม หูลี่เหลี่ยม หูกกลม หูกะหล่ำปลี หูตั้งราบและหูตั้งย้อย [16] ซึ่งมีลักษณะดังภาพที่ 2



ภาพที่ 2 ลักษณะของใบหู [16] (1) หูกาง (2) หูลีบ (3) หูสามเหลี่ยม (4) หูลี่เหลี่ยม
(5) หูกลม (6) หูกะหล่ำปลี (7) หูดังราบ (8) หูดังย้อย

1.2.2 โครงสร้างของใบหู

โครงสร้างของใบหูมีลักษณะที่ซับซ้อน ซึ่งแต่ละส่วนมีรายละเอียดดังภาพที่ 3 ประกอบไปด้วยขอบนอกของใบหู (Helix) เป็นส่วนที่อยู่ขอบนอกของใบหู ขอบกลางของใบหู (Anti Helix) เป็นขอบที่อยู่ถัดจากขอบนอก สแคปฟา (Scapha) เป็นส่วนร่องหูที่อยู่กลางระหว่างขอบนอกกับขอบกลางของใบหู ถ้วยคองกา (Concha) เป็นส่วนใบหูที่มีรูปร่างเหมือนถ้วยอยู่ระหว่างขอบรูหูและขอบกลางของใบหู ดั้งหู (Lobe) เป็นส่วนท่อนล่างสุดของใบหูที่ไม่มีกระดูกอ่อน ใช้สำหรับใส่ต่างหู ทรากัส (Tragus) เป็นส่วนดิ่งที่มีรูปบริเวณขอบหน้าของรูหู แอนติทรากัส (Anti Tragus) เป็นส่วนดิ่งที่มีรูปบริเวณเหนือดิ่งหู และ โพรงรูปสามเหลี่ยม (Triangular Fossa) คือบริเวณโพรงที่มีลักษณะเป็นรูปสามเหลี่ยมอยู่ระหว่างขอบนอกด้านบนกับขอบกลางของใบหู [14,15]



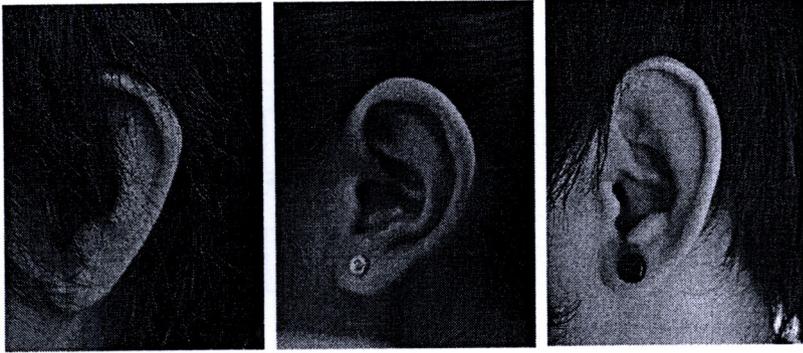
ภาพที่ 3 โครงสร้างใบหู

1.2.3 ตำแหน่งสำคัญของใบหู

มีหลายงานวิจัยได้กล่าวถึงการหาคำแหน่งสำคัญของใบหูในลักษณะที่แตกต่างกัน ดังจะกล่าวในผลงานวิจัยที่เกี่ยวข้อง โดยการหาคำแหน่งสำคัญของใบหูจะหาจากโครงสร้างของใบหู งานวิจัยเรื่อง Ear Recognition Base on Statical Shape Model [6] ทำการทดลองหาคำแหน่งของใบหูจากภาพระดับสีเทา (Gray Scale) งานวิจัยเรื่อง Shape and Structural Feature Based Ear Recognition [12] ทำการทดลองหาคำแหน่งของใบหูจากเส้นขอบโดยวิธีโซเบล (Sobel) ทั้งหาเส้นขอบที่อยู่ภายในและภายนอกภาพใบหู งานวิจัยเรื่อง A Simple Geometric Approach for Ear Recognition [3] ทำการหาคำแหน่งของใบหูจากเส้นขอบโดยขั้นตอนวิธีของแคนนี่ (Canny Edge Algorithm)

1.2.4 อุปสรรคในการค้นหาคำแหน่งใบหู

ในการหาคำแหน่งใบหูนั้นมีข้อจำกัดคือ ลักษณะใบหูจะต้องไม่มีการปิดบังจากสิ่งต่าง ๆ เช่น เส้นผม ต่างหู ผ้าพันคอ ผ้าโพกหัวของชาวอิสลาม หรือสิ่งอื่น เป็นต้น [1]

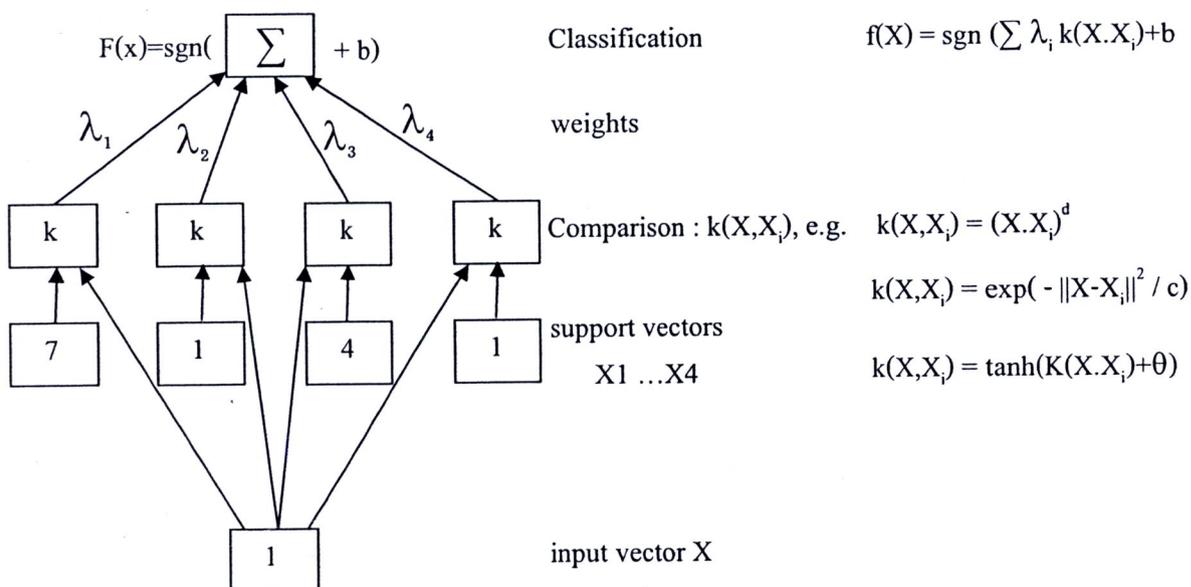


ภาพที่ 4 ลักษณะของใบหน้าที่เป็นอุปสรรคไม่สามารถนำมาระบุตัวบุคคลได้

1.3 ทฤษฎีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines : SVM)

ซัพพอร์ตเวกเตอร์แมชชีน [11] เป็นการเรียนรู้แบบมีผู้สอน (Supervised Learning) ที่ใช้แนวความคิดของ Structural Risk Minimization (SRM) คือ ความพยายามที่จะหาสมมติฐานที่จะบอกได้ว่าสามารถทำนายข้อมูลทดสอบที่ไม่เคยพบเห็นให้เกิดความผิดพลาดต่ำที่สุด โดยซัพพอร์ตเวกเตอร์แมชชีนจะพยายามลดความผิดพลาดทั่วไปให้ต่ำที่สุดแทนที่จะลดความผิดพลาดของการเรียนรู้ให้ต่ำที่สุดเพียงเท่านั้น ตามหลักการของ SRM ฟังก์ชันที่สามารถแยกประเภทของข้อมูลทดสอบได้อย่างถูกต้อง จะเป็นส่วนหนึ่งของกลุ่มของฟังก์ชันที่มี VC Dimension ที่ต่ำที่สุด โดยทั่วไปขนาดของ Input Space ที่ต่ำที่สุด (จำนวน Feature ที่น้อย) จะแสดงผลลัพธ์ได้ดีที่สุด จากหลักการนี้ ทำให้ซัพพอร์ตเวกเตอร์แมชชีนหาฟังก์ชันแบบสมการเชิงเส้น ที่มีขนาด VC Dimension ต่ำที่สุดจากกลุ่มของตัวอย่างข้อมูลที่เราสนใจ

ซัพพอร์ตเวกเตอร์แมชชีนจะทำการเปรียบเทียบเพื่อจัดกลุ่มเฉพาะของข้อมูลที่สนใจ (Class-of-Interest) ซึ่งข้อมูลที่ไม่ถูกจัดกลุ่มจะถูกแยกออกเป็นข้อมูลที่ไม่สนใจ จากภาพที่ 5 จะแสดงสถาปัตยกรรมของซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine Architecture) ในส่วนของขอบเขตการตัดสินใจของซัพพอร์ตเวกเตอร์แมชชีนและโครงสร้างฟังก์ชันในการตัดสินใจ



ภาพที่ 5 แสดงสถาปัตยกรรมของซัพพอร์ตเวกเตอร์แมชชีน [11]

1.3.1 การจัดกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน

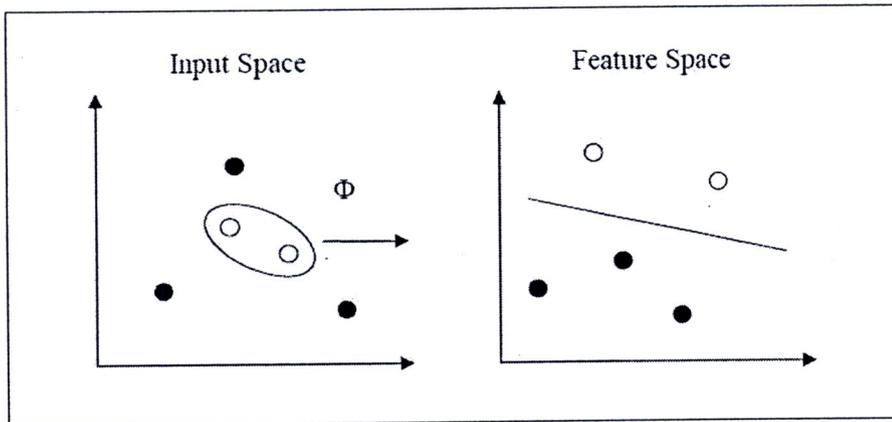
1.3.1.1 ข้อมูลที่เป็น Input จะถูกแบ่งเป็นกลุ่มของข้อมูลโดยใช้เส้น Linear ในการแบ่งกลุ่มของข้อมูล ส่วนในกรณีที่เส้น Linear ไม่สามารถแบ่งได้จะต้องทำการ Map กลุ่มของข้อมูลให้อยู่ในมิติที่สูงขึ้นและใช้ฟังก์ชันที่เป็น Non-Linear

1.3.1.2 ในการแบ่งกลุ่ม (Classification) จะหาไฮเปอร์เพลน (Hyperplane) ที่เหมาะสมที่สุด โดยเงื่อนไขที่ทำให้ได้ไฮเปอร์เพลนที่เหมาะสมที่สุด ประกอบด้วย

- (1) ค่าความผิดพลาดในการฝึกฝนเป็นศูนย์ (Zero Training Error)
- (2) ระยะระหว่างซัพพอร์ตเวกเตอร์ของทั้ง 2 ชนิดห่างกันมากที่สุด

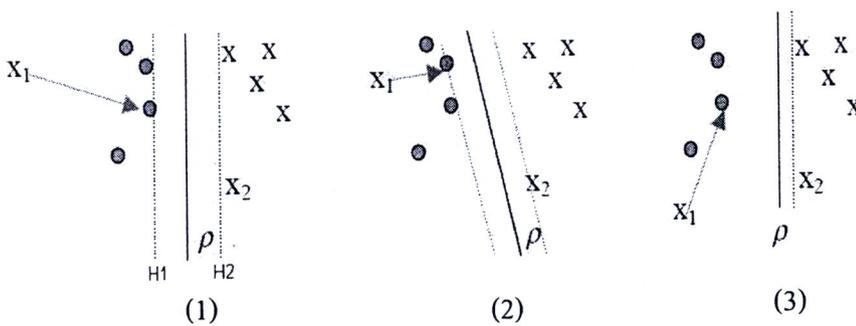
(Maximum Margin)

ในกรณีการแบ่งกลุ่มแบบ Non-Linear เป็น Linear ซัพพอร์ตเวกเตอร์แมชชีนจะอาศัยการแปลงข้อมูล Input Space ให้เป็น Feature Space ที่มีมิติสูงขึ้น ดังภาพที่ 6 ซัพพอร์ตเวกเตอร์แมชชีนทำการแปลงข้อมูลที่ใช้ในการเรียนรู้แบบไม่เชิงเส้นไปเป็นขนาด Feature Space ที่ใหญ่ขึ้นผ่านฟังก์ชันเคอร์เนล (Kernel Function) และสร้างระนาบซึ่งแบ่งข้อมูลสองกลุ่มได้ดีที่สุด



ภาพที่ 6 การแปลง Input Space เป็นมิติสูงขึ้น [11]

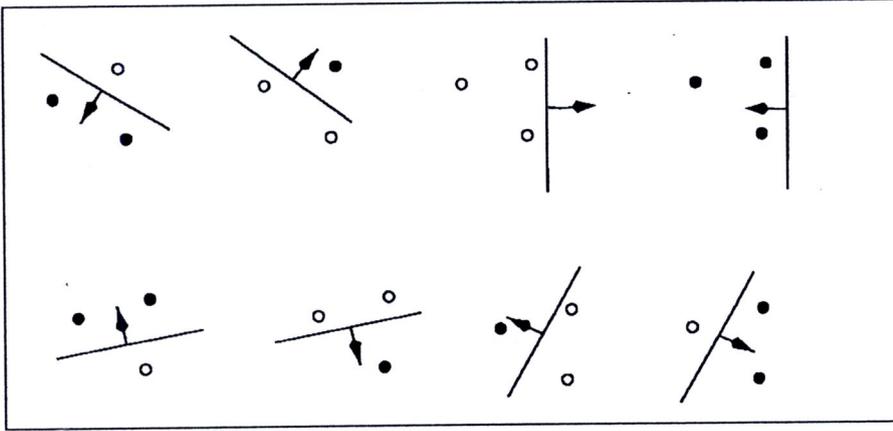
ในกรณีการแบ่งกลุ่มจะหาไฮเปอร์เพลนที่เหมาะสมที่สุด ซึ่งจาก ภาพที่ 7 นั้น X_1, X_2 คือ Support Vector และ H_1, H_2 คือไฮเปอร์เพลน โดยภาพที่ (1) จะได้ไฮเปอร์เพลนที่เหมาะสมที่สุด ภาพที่ (2) Margin จะลดลงเนื่องจากเส้นแบ่งมีตำแหน่งที่เปลี่ยนไป ภาพที่ (3) เป็นกรณีที่ผิด



ภาพที่ 7 ไฮเปอร์เพลน [11] (1) ไฮเปอร์เพลนที่เหมาะสมที่สุด (2) Margin จะลดลง (3) กรณีที่ผิด

1.3.2 VC-dimension (Vapnik Chervonenkis dimension) ปริมาณที่ใช้วัดความสมบูรณ์ (Richness) หรือความยืดหยุ่น (Flexibility) ของชนิดฟังก์ชันซึ่งส่งผลถึงความจุของระบบ รู้จักเรียกว่า VC-dimension การควบคุมความจุได้ย่อมทำให้ประสิทธิภาพของระบบดีขึ้น ตัวอย่างมิติ VC ของปริภูมิสมมุติฐานในกรณี มี 2 ชนิด จะเท่ากับจำนวนที่มากที่สุด d ของตัวอย่างที่สามารถแบ่งเป็น 2 กลุ่มด้วย 2^d วิธี ใด ๆ โดยใช้ปริภูมิสมมุติฐานนั้น

มิติ VC ของปริภูมิสมมุติฐานใน R^n คือ $N+1$ เช่น ใน R^2 จะได้ มิติ VC = 3 ดังภาพที่ 8 จากภาพพบว่า มีจำนวนมากที่สุดที่สามารถแบ่งออกได้ $2^3 = 8$



ภาพที่ 8 มิติ VC ของปริภูมิสมมุติฐานใน 2^3 [11]

1.3.3 Structural Risk Minimization เป็นวิธีการที่ช่วยในการหาฟังก์ชันตัดสินใจ กระบวนการเรียนรู้ที่ให้ความผิดพลาดน้อยที่สุด โดยฟังก์ชันซึ่งแยกประเภทของข้อมูลทดสอบได้อย่างถูกต้องจะเป็นส่วนหนึ่งของกลุ่มของฟังก์ชันที่มี VC Dimension ที่ต่ำที่สุด โดยทั่วไปขนาดของ Input Space ที่ต่ำที่สุด (จำนวน Feature ที่น้อย) จะแสดงผลลัพธ์ที่ดีที่สุด หลักการนี้ทำให้ซัพพอร์ตเวกเตอร์แมชชีนเชิงเส้น (Linear SVMs) ใช้ Systematic Approach เพื่อหาฟังก์ชันแบบ Linear ที่มีขนาด VC Dimension ต่ำที่สุดจากกลุ่มของตัวอย่างข้อมูลที่ใช้ในการเรียนรู้

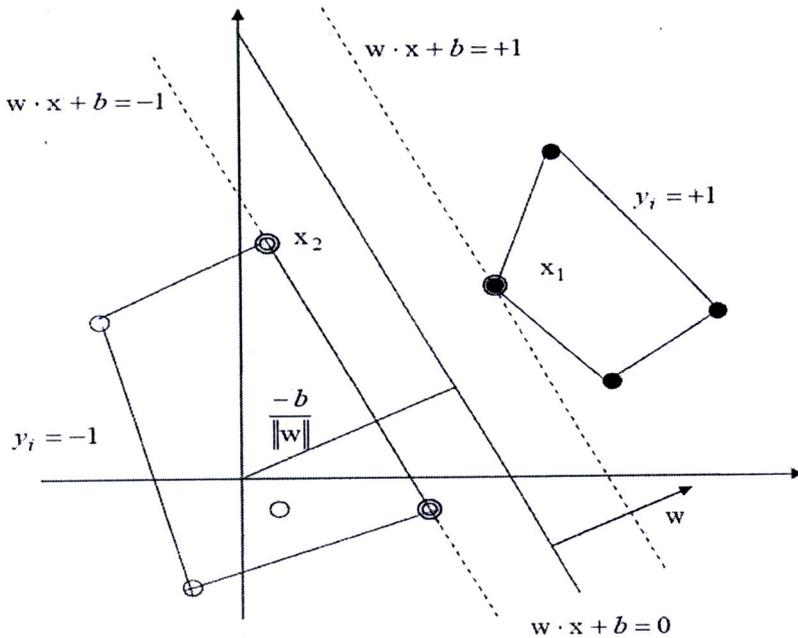
กำหนดให้ลักษณะของข้อมูลที่ใช้ในการเรียนรู้ที่มีขนาด M เป็น (\bar{x}_i, y_i) ซึ่ง $\bar{x}_i \in R^N$ โดยที่ $i = 1, \dots, l$ และ $y_i \in \{-1, +1\}$ จะทำการหาระนาบที่แบ่งตัวอย่างบวกและลบออกจากกัน โดยแสดงให้เห็นจากภาพที่ 9 จุด x เป็นจุดที่อยู่บนระนาบ $w \cdot x + b = 0$ เมื่อ w คือความชันของระนาบ และ $|b|/\|w\|$ เป็นความยาวของเส้นที่ตั้งฉากกับระนาบถึงจุดกำเนิด (Origin) ในกรณีการหาระนาบเชิงเส้น (Linear Hyperplane) ตัวจำแนกหมวดหมู่ของซัพพอร์ตเวกเตอร์แมชชีนจะทำการหาระนาบที่ดีที่สุดจะสามารถแบ่งส่วนของข้อมูลเหล่านั้นให้มีระยะห่างจากระนาบให้มากที่สุด แสดงถึงระยะห่าง (Margin) ที่มากที่สุดที่มีความสมดุลกับขนาดของ VC ที่ต่ำที่สุดในการสร้างระนาบที่เหมาะสม ซึ่งสามารถเขียนอยู่ในรูปแบบสมการ

$$x_i \cdot w + b \geq +1 \text{ for } y_i = +1 \quad (1)$$

$$x_i \cdot w + b \leq -1 \text{ for } y_i = -1 \quad (2)$$

โดยสามารถรวม 2 สมการข้างต้นให้อยู่ในรูปแบบ

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall i \quad (3)$$



ภาพที่ 9 ระนาบเส้นตรงที่ใช้ในการแบ่งกลุ่มตัวอย่าง [11]

จากภาพที่ 9 ยังแสดงให้เห็นถึงระนาบเส้นตรงที่ใช้ในการแบ่งกลุ่มตัวอย่าง โดยข้อมูลทั้งหมดอยู่ภายใต้เงื่อนไขของสมการที่ 3 และจุดข้อมูลที่ทำให้ได้สมการระนาบหลายมิติแบ่งแยกดีที่สุด (Optimal Hyperplane) ซึ่งแสดงให้เห็นจากภาพคือจุดที่ถูกวงกลมล้อมรอบเรียกว่า Support Vectors

จากเงื่อนไขที่ทำให้ได้ไฮเปอร์เพลน (Hyperplane) ที่เหมาะสมที่สุด ประกอบด้วย

- (1) ค่าความผิดพลาดในการฝึกฝนเป็นศูนย์ (Zero Training Error)
- (2) ระยะระหว่างซัพพอร์ตเวกเตอร์ของทั้ง 2 ชนิดห่างกันมากที่สุด (Maximum Margin)

ในการหาค่าที่เหมาะสมที่สุด (Optimization) โดยวิธีแบบ Lagrange สามารถอาศัยคุณสมบัติคู่อลิติ (Duality) เพื่อทำให้การแก้ไขปัญหานั้นทำได้ง่ายขึ้นคือ ทำได้โดยการกำหนดปัญหาที่เราต้องการ (Optimization Problem)



Optimization Problem:

$$\text{Minimize } J(\vec{w}, b) = \frac{1}{2} \vec{w} \cdot \vec{w} \tag{4}$$

$$\text{Subject to } y_i [\vec{w} \cdot \vec{x}_i + b] \geq 1, \quad \forall i \in [1..l]$$

กำหนดตัวคูณ Lagrange บวก (α_i)

$$\alpha_i \geq 0, \quad i = 1, \dots, l \tag{5}$$

จาก สมการที่ 4 และ 5 เราจะได้ Primal Optimal Problem ดังนี้

Primal Optimal Problem:

$$\text{Minimize } L(\vec{w}, b, \vec{\alpha}) = \frac{1}{2} \vec{w} \cdot \vec{w} - \frac{1}{2} \sum_i \alpha_i [y_i [\vec{w} \cdot \vec{x}_i + b] - 1] \tag{6}$$

$$\text{Subject to } \alpha_i \geq 0, \quad i = 1, \dots, l$$

หาอนุพันธ์ย่อยของสมการที่ 6 เทียบกับ \vec{w} และ b จะได้

$$\frac{\partial L(\vec{w}, b, \vec{\alpha})}{\partial \vec{w}} = \vec{w} - \sum_{i=1}^l y_i \alpha_i \vec{x}_i \tag{7}$$

$$\frac{\partial L(\vec{w}, b, \vec{\alpha})}{\partial b} = \sum_{i=1}^l y_i \alpha_i$$

เนื่องจากค่า \vec{w} และ b ทำให้ $L(\vec{w}, b, \vec{\alpha})$ มีค่าน้อยที่สุดดังนั้นเราจะได้

$$\vec{w} = \sum_{i=1}^l y_i \alpha_i \vec{x}_i \tag{8}$$

$$0 = \sum_{i=1}^l y_i \alpha_i$$

เมื่อนำสมการที่ 8 ไปแทนค่าลงในสมการที่ 6 เราจะได้ Dual Optimal Problem ดังนี้

Dual Optimal Problem:

$$\text{Maximize } L(\vec{w}, b, \vec{\alpha}) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (9)$$

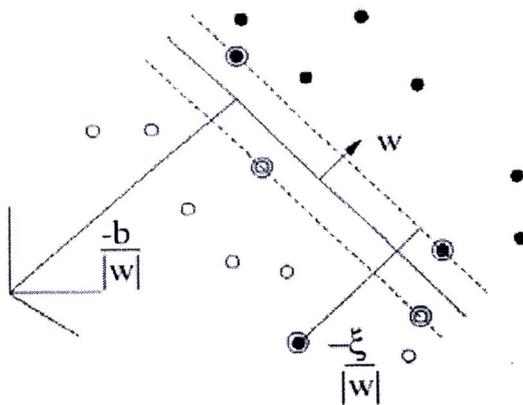
$$\text{Subject to } \sum_i \alpha_i y_i = 0 \quad \alpha_i \geq 0, \quad i = 1, \dots, l$$

ผลตอบที่ได้จาก Primal Optimal Problem และ Dual Optimal Problem มีค่าเดียวกัน คือ

$$\vec{w} = \sum_i \alpha_i y_i \vec{x}_i \quad \text{และ} \quad b = \frac{1}{2} (\vec{w}_0 \cdot \vec{x}^{pos} + \vec{w}_0 \cdot \vec{x}^{neg}) \quad (10)$$

ผลตอบที่ได้มีหนึ่งเดียว และตัวอย่างที่ค่า $\alpha_i \geq 0$ จะเป็นซัพพอร์ตเวกเตอร์

1.3.4 กรณีไม่สามารถแยกข้อมูลได้ด้วยไฮเปอร์เพลน เราทำได้เพียงหาไฮเปอร์เพลนที่สามารถแยกจุดตัวอย่างออกจากกันให้ได้มากที่สุด และยอมให้มีจุดตัวอย่างส่วนน้อยเพียงบางจุดที่ผิดพลาด ดังแสดงในภาพที่ 10



ภาพที่ 10 ไฮเปอร์เพลนแบบเชิงเส้นกรณีแยกกันไม่ได้ [11]

เราจึงไม่สามารถใช้ขอบเขตแบบแข็ง (Hard Margin):

$$\text{Minimize } J(\vec{w}, b) = \frac{1}{2} \vec{w} \cdot \vec{w} \quad (11)$$

$$\text{Subject to } y_i [\vec{w} \cdot \vec{x}_i + b] \geq 1$$



ได้เหมือนในกรณีแยกกันได้ ดังนั้นเราจึงใช้ขอบเขตแบบอ่อน (Soft Margin) แทน

$$\text{Minimize } J(\bar{w}, b, \xi) = \frac{1}{2} \bar{w} \cdot \bar{w} + C \sum_{i=1}^n \xi_i \tag{12}$$

$$\text{Subject to } y_i [\bar{w} \cdot \bar{x}_i + b] \geq 1 - \zeta_i, \quad \zeta_i \geq 0$$

C คือ ค่าควบคุมการ Trade-off ระหว่างขอบเขตกับค่าผิดพลาด

Dual Optimal Problem :

$$\text{Maximize } L(\bar{\alpha}) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \bar{x}_i \cdot \bar{x}_j \tag{13}$$

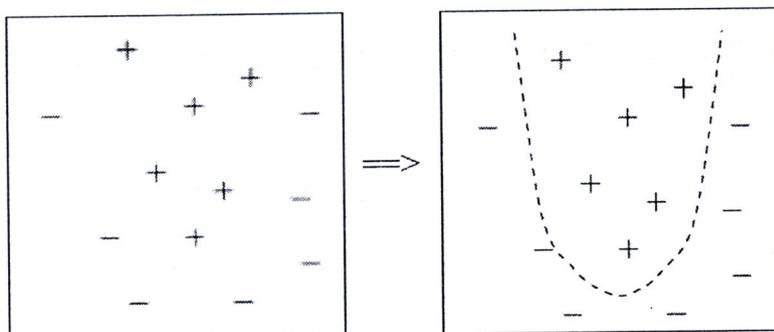
$$\text{Subject to } \sum_i \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, l$$

ผลตอบที่ได้มีหนึ่งเดียว

ตัวอย่างที่เป็น Support Vector ที่ $\zeta_i = 0$ ก็ต่อเมื่อ $0 < \alpha_i < C$

ตัวอย่างที่เป็น Support Vector ที่ $\zeta_i > 0$ ก็ต่อเมื่อ $\alpha_i = C$

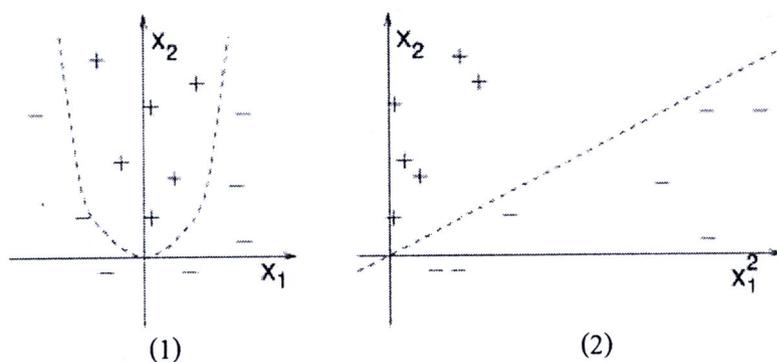
1.3.5 ซัพพอร์ตเวกเตอร์แมชชีนแบบไม่เชิงเส้น ในงานบางประเภทมีลักษณะไม่เป็นเชิงเส้นจึงไม่สามารถใช้ไฮเปอร์เพลนมาจำแนกประเภทได้ดังภาพที่ 11



ภาพที่ 11 โครงสร้างข้อมูลแบบไม่เป็นเชิงเส้น [11]

วิธีประยุกต์ใช้ซัพพอร์ตเวกเตอร์แมชชีนกับกรณีไม่เชิงเส้นนี้ทำได้โดยการส่ง (Map) จากปริภูมิขาเข้า (Input Space) ไปสู่ปริภูมิลักษณะ (Feature Space) โดยผ่านฟังก์ชัน $\Phi(\vec{x})$ ดังภาพที่

12



ภาพที่ 12 ปริภูมิขาเข้าไปสู่ปริภูมิลักษณะ [11] (1) ปริภูมิขาเข้า (2) ปริภูมิลักษณะ

จากรูปเป็นตัวอย่างของการส่งจาก

$$\text{Input Space : } \vec{x} = (x_1, x_2) \quad (2 \text{ คุณลักษณะ})$$

$$\text{Feature Space : } \Phi(\vec{x}) = (x_1^2, x_2^2, \sqrt{2x_1}, \sqrt{2x_2}, \sqrt{2x_1x_2}, 1) \quad (6 \text{ คุณลักษณะ})$$

หลังจากส่งไปสู่ปริภูมิลักษณะแล้วเราจะสามารถหาไฮเปอร์เพลนมาจำแนกประเภทได้

1.3.6 เคอร์เนล (Kernels) เนื่องจากมีจำนวนของคุณลักษณะสำคัญ (Attribute) มากมายจากโพลิโนเมียลระดับชั้น p บน N คุณลักษณะสำคัญในปริภูมิขาเข้าไปเป็น $O(N^p)$ คุณลักษณะสำคัญในปริภูมิคุณลักษณะสำคัญ

Kernel functions :

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (14)$$

จาก $\Phi(\vec{x}) = (x_1^2, x_2^2, \sqrt{2x_1}, \sqrt{2x_2}, \sqrt{2x_1x_2}, 1)$ เราสามารถหาฟังก์ชันเคอร์เนลได้เป็น

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) = [\vec{x}_i \cdot \vec{x}_j + 1]^2 \quad (15)$$

จากสมการที่ 13 เราปรับปรุงใหม่โดยใช้ฟังก์ชันเคอร์เนลได้ดังนี้

Dual Optimal Problem :

$$\text{Maximize } L(\vec{\alpha}) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(\vec{x}_i \cdot \vec{x}_j) \quad (16)$$

$$\text{Subject to } \sum_i \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, l$$

Hyperplane :
$$h(\vec{x}) = \text{sign} \left[\sum_{\vec{x}_i \in SV} \alpha_i y_i K(\vec{x}_i \cdot \vec{x}_j) + b \right] \quad (17)$$

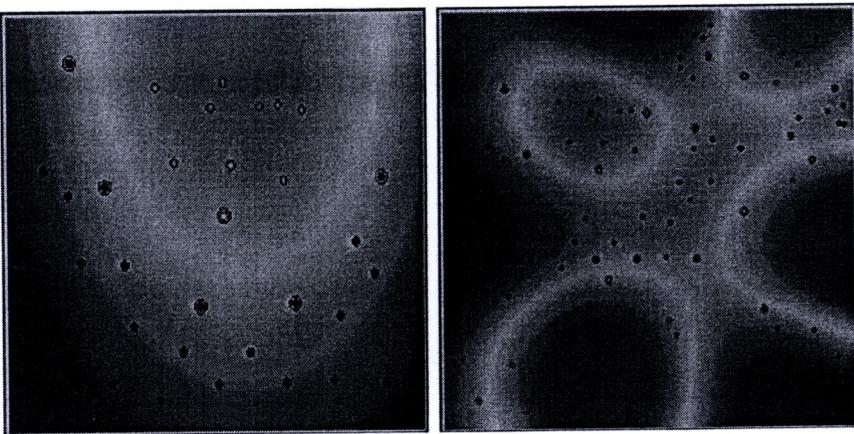
ฟังก์ชันเคอร์เนลมีหลากหลายขึ้นกับการใช้งาน เช่น

Linear :
$$K(\vec{x}_i \cdot \vec{x}_j) = \vec{x}_i \cdot \vec{x}_j \quad (18)$$

Polynomial :
$$K(\vec{x}_i \cdot \vec{x}_j) = [\vec{x}_i \cdot \vec{x}_j + 1]^d \quad (19)$$

Radial Basis Function (RBF) :
$$K(\vec{x}_i \cdot \vec{x}_j) = \exp(-\|\vec{x}_i \cdot \vec{x}_j\|^2 / (2\sigma^2)) \quad (20)$$

Quadratic :
$$K(\vec{x}_i \cdot \vec{x}_j) = \Phi \vec{x}_i \cdot \Phi \vec{x}_j \quad (21)$$



ภาพที่ 13 ฟังก์ชัน Kernels แบบ Polynomial (ซ้าย) และแบบ RBF (ขวา) [11]

1.3.7 การจำแนกข้อมูลแบบหลายกลุ่ม

1.3.7.1 วิธีแบบหนึ่งต่อหนึ่ง (One – Against – One : OAO) เป็นวิธีที่ช่วยลดจำนวนข้อมูลที่ไม่สามารถจำแนกกลุ่มได้ [13] มีประสิทธิภาพโดยใช้การตัดสินใจทำงานทั้งหมดเท่ากับ $\frac{n(n-1)}{2}$ โดยที่ n คือจำนวนกลุ่มของข้อมูลทั้งหมด เมื่อใช้ฟังก์ชันการตัดสินใจเพื่อจำแนกกลุ่มข้อมูลที่ i กับกลุ่มข้อมูลที่ j จะได้ค่าระยะห่างเส้นแบ่งที่มากที่สุดระหว่างข้อมูลที่เหมาะสมที่สุด (D_{ij}) ตามสมการนี้

$$D_{ij}(x) = w_{ij}^T \Phi(x) + b_{ij} \quad (22)$$

โดยที่ $w_{ij}^T \Phi$ คือเวกเตอร์ m มิติ $\Phi(x)$ คือฟังก์ชันที่นำค่าข้อมูล x ไปสู่มิติที่ m และ b_{ij} เป็นค่าคงที่และ $D_{ij}(x) = -D_{ji}(x)$

1.3.7.2 วิธีแบบหนึ่งต่อทั้งหมด (One – Against – All : OAA) เป็นการจำแนกข้อมูลระหว่างกลุ่มที่ต้องการเปรียบเทียบกับกลุ่มข้อมูลที่เหลือทั้งหมด [13] เพื่อหาเส้นแบ่งระนาบที่เหมาะสมระหว่างกลุ่มข้อมูลสองกลุ่มออกจากกันได้อย่างเหมาะสม เช่น การมองกลุ่มข้อมูลที่ i กับกลุ่มข้อมูลที่เหลือทั้งหมด มีระยะห่างระหว่างระนาบเส้นแบ่งที่มากที่สุด (D_i) ดังสมการ

$$D_i(x) = w_i^T \Phi(x) + b_i = 0 \quad (23)$$

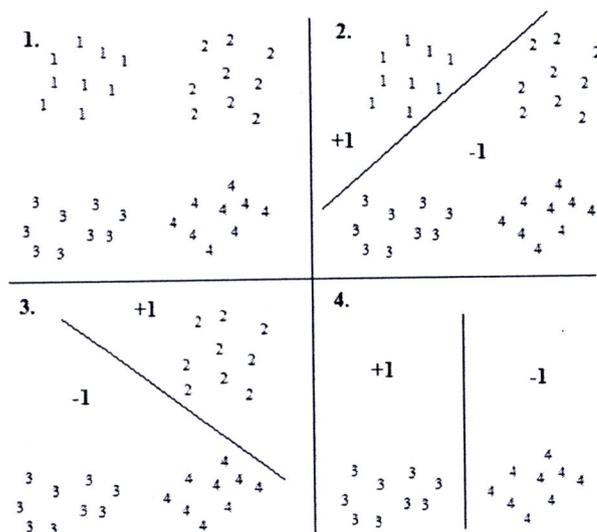
โดยที่ $w_i^T \Phi$ คือเวกเตอร์ m มิติ $\Phi(x)$ คือฟังก์ชันที่นำค่าข้อมูล x ไปสู่มิติที่ m และ b_i เป็นค่าคงที่ การจำแนกข้อมูล x เข้ากลุ่ม ดังสมการ

$$D_i(x) > 0 \quad (24)$$

ถ้าค่าที่ได้มากกว่า 0 แสดงว่าข้อมูล x อยู่ในกลุ่มข้อมูลที่ i นอกนั้นอยู่กลุ่มข้อมูลอื่นหรืออาจเป็นส่วนที่ไม่สามารถจำแนกได้ สามารถใช้เทคนิคการหาค่ามากที่สุดดังนี้

$$\arg \max D_i(x) \mid i = 1, \dots, n \quad (25)$$

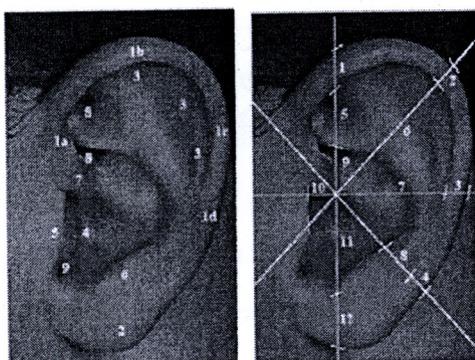
รูปแบบการแบ่งกลุ่มข้อมูลใช้การเปรียบเทียบแบบหนึ่งต่อทั้งหมดที่เหลือเพื่อสอนให้ระบบรู้จำ ดังภาพที่ 14



ภาพที่ 14 การเปรียบเทียบชุดข้อมูลแบบหนึ่งต่อทั้งหมด

2. ผลงานวิจัยที่เกี่ยวข้อง

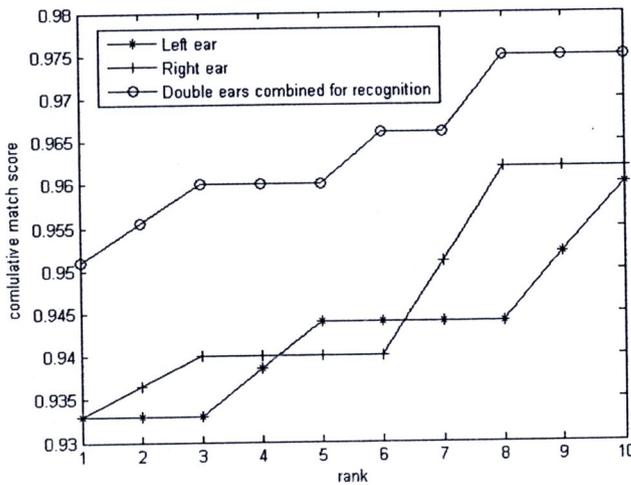
2.1 Ear Recognition Base on Statical Shape Model [6] ได้วิเคราะห์การรู้จำบนพื้นฐานของโมเดลรูปร่างของใบหูเชิงสถิติ ใช้ตัวแบบแอคทีฟเชพ (Active Shape Models) ในการทดลองได้เปลี่ยนภาพใบหูเป็นระดับสีเทา ซึ่งใช้ในระบบออเฟรด (Alfred System) ที่ได้แบ่งขนาดของใบหูออกเป็น 12 ส่วนในการรู้จำและหาตำแหน่งสำคัญ ดังภาพที่ 15



ภาพที่ 15 การหาตำแหน่งสำคัญของระบบออเฟรด (Alfred System)

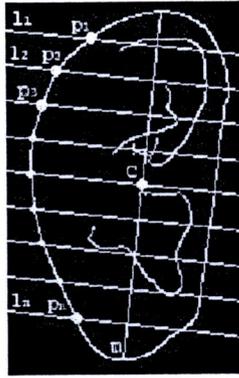


ความยากของการประยุกต์ใช้ระบบออฟเฟรดคือ การหาตำแหน่งจุดกึ่งกลางของภาพ ใบหู ถ้าตำแหน่งจุดกึ่งกลางผิด จะมีผลทำให้ความแม่นยำผิดไปด้วย ตัวแบบแอกทิฟเซพจะใช้วิธีการ ทางสถิติในการประมวลผล ส่วนของการรู้จำได้ทำการทดลองโดยใช้ตัวแบบอีเจนเชพ (Eigenshape Model) ในการรู้จำซึ่งในบทความนี้เรียกว่า อีเจนเอียงเซพ (Eigenshape) ใช้ภาพถ่ายใบหูจำนวน 168 ภาพ โดยทำการทดลองรู้จำใบหูด้านซ้ายและใบหูด้านขวาตามลำดับ ผลการทำทดลองสรุปว่า การรู้จำหูทางด้านซ้ายมีประสิทธิภาพ 93.3 % การรู้จำหูทางด้านขวามีประสิทธิภาพ 93.3 % และการรู้จำหูทั้งสองข้างรวมกัน 95.5 % ประสิทธิภาพแสดงดังภาพที่ 16



ภาพที่ 16 กราฟประสิทธิภาพในการรู้จำใบหูโดยใช้อีเจนเอียงเซพ (Eigenshape)

2.2 A Simple Geometric Approach for Ear Recognition [3] ได้เสนอวิธีการทางด้านเรขาคณิตพื้นฐานในการรู้จำภาพถ่ายใบหู โดยแบ่งขั้นตอนออกเป็น 2 ขั้นตอน ขั้นตอนแรกหาบริเวณเส้นขอบของใบหู และขั้นตอนที่สองคือ หาตำแหน่งอื่น ๆ ที่อยู่ภายในใบหู ก่อนการประมวลผล ได้ค้นหาเส้นขอบของใบหูโดยใช้ขั้นตอนวิธีของแคนนี่ (Canny Edge Detection Algorithm) จากนั้นได้ทำการหาตำแหน่งสำคัญ โดยแบ่งออกเป็น 2 เวกเตอร์ ได้แก่ max-line และ normal lines โดย max-line สามารถหาได้จากเส้นที่ยาวที่สุดของจุดสิ้นสุดของเส้นขอบรอบนอก ส่วน normal lines คือเส้นที่ตั้งฉากกับ max-line แล้วหารเป็นส่วนเท่า ๆ กันจากความยาวของ max-line (n+1) แสดงดังภาพที่ 17 การทดลองได้ทำการทดลองกับรูปถ่ายใบหู 80 ใบหู 160 ภาพ ใช้ normal lines จำนวน 19 เส้น มีความผิดพลาด 5 %



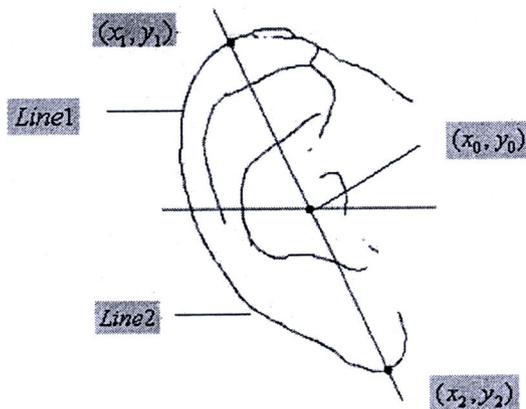
ภาพที่ 17 แสดง max-line และ normal lines

2.3 Shape and Structural Feature Based Ear Recognition [12] นำเสนอวิธีการหาตำแหน่งสำคัญของใบหูและการรู้จำด้วยวิธีการทางคณิตศาสตร์ โดยทำการค้นหาเส้นขอบของใบหูด้วยวิธีโซเบล (Sobel) จากนั้นได้หาตำแหน่ง ที่สำคัญโดยการหาตำแหน่งสำคัญของเส้นขอบรอบนอกของภาพใบหูและหาตำแหน่งสำคัญของ เส้นขอบภายในของภาพใบหู

การหาตำแหน่งสำคัญของเส้นขอบรอบนอกของภาพใบหู

(1) ค้นหาระยะห่างที่ยาวที่สุดระหว่างจุด (x_1, y_1) และ (x_2, y_2) ในเส้นขอบนอกของภาพใบหูและเชื่อมจุดสองจุดเข้าด้วยกัน จากนั้นหาจุดกึ่งกลาง (x_0, y_0) ของเส้น ด้วยสมการคือ $x_0 = (x_1 + x_2) / 2$ และ $y_0 = (y_1 + y_2) / 2$

(2) เนื่องจากเส้นโค้งรอบนอกมีความซับซ้อน จึงถูกแบ่งออกเป็น 2 ส่วน คือ Line1 และ Line2 ซึ่งถูกแบ่งโดยจุด (x_0, y_0) ดังภาพที่ 18

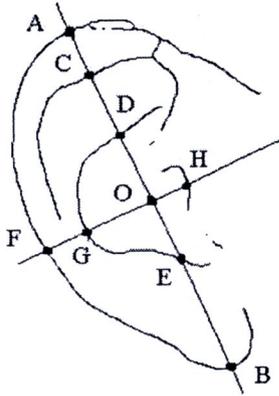


ภาพที่ 18 การหาเส้นแกนและแบ่งส่วนของเส้นขอบรอบนอกภาพใบหู

(3) สำหรับแต่ละเส้นโค้งนั้น เราจะหาค่าคงที่ของเส้น ซึ่งเรามีอยู่สองเส้น คำนวณได้จากสมการ $L1 = a_n x^n + a_{n-1} x^{n-1} + \dots + a_0$ และ $L2 = b_n x^n + b_{n-1} x^{n-1} + \dots + b_0$ ค่าสัมประสิทธิ์ของเวกเตอร์ $[a_n a_{n-1} \dots a_0]$ ของสมการ $L1$ คือตำแหน่งรูปร่างของ Line1 ในลักษณะเดียวกัน ค่าสัมประสิทธิ์ของเวกเตอร์ $[b_n b_{n-1} \dots b_0]$ ของสมการ $L2$ คือตำแหน่งรูปร่างของ Line2

การหาค่าตำแหน่งสำคัญของเส้นขอบภายในของภาพใบหู

- (1) คำนวณหาความยาวของเส้นแกนยาว AB ดังภาพที่ 19 A และ B คือจุดที่หาได้จากเส้นขอบรอบนอกภาพใบหู ดังนั้น $|AB|$ คือความยาวของเส้นนี้
- (2) หาเส้นตั้งฉากแบ่งครึ่งเส้นแกนยาว เรียกว่า แกนสั้น จะได้เส้น FOH ซึ่งตั้งฉากกับเส้น AOB และตัดกันที่จุด O
- (3) หาจุดตัด C, D และ E ระหว่างเส้นแกนยาว และจุดตัด F, G และ H ระหว่างเส้นแกนสั้น

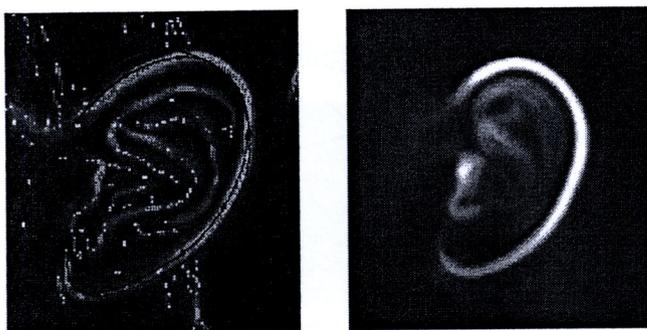


ภาพที่ 19 จุดสำคัญภายในภาพใบหู

(4) หาอัตราส่วนของความยาวระหว่างจุดทั้งหมด ได้เวกเตอร์ คือ $[OA/AB, OB/AB, OC/AB, OD/AB, OE/AB, OF/AB, OG/AB, OH/AB]$ ค่าที่ได้จะเป็นค่าคงที่

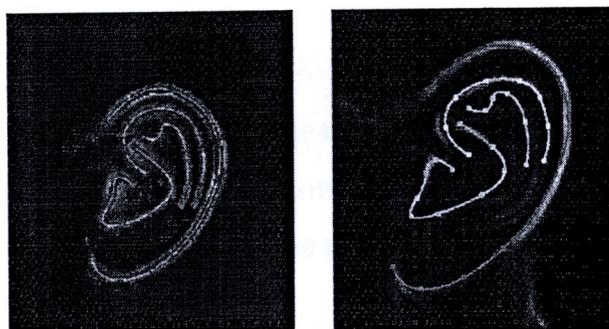
การทดลองได้ทดลองกับภาพถ่ายใบหูจำนวน 77 ใบหู แต่ละใบหูมี 4 ลักษณะที่มีความแตกต่างกัน แบ่งเป็นชุดทดลองที่ 1 และชุดทดลองที่ 2 โดยใช้นิรอรลเน็ตเวิร์กแบบแบคพรอพา-เกชัน (BP network) ในการรู้จำ ผลการทดลองมีประสิทธิภาพ 85% ในการทดลองกับฐานข้อมูลชุดที่ 1 และผลการปฏิเสธ 98% ในการทดลองกับฐานข้อมูลชุดที่ 2

2.4 Model-Based Human Ear Identification [4] นำเสนอ Model-Based Human Ear Identification เป็นกระบวนการสกัดคุณลักษณะสำคัญของภาพถ่ายใบหู 4 ขั้นตอน ได้แก่ ขั้นตอนที่ 1 คือ หาขอบภาพถ่ายใบหู โดยใช้วิธีเซลล์อัตโนมัติและความแตกต่าง (Cell Automata models and Different Rules) ขั้นตอนที่ 2 ทำการปรับเส้นขอบรอบนอกให้ชัดเจน โดยทำให้เส้นขอบรอบนอกเกิดความเรียบ ดังภาพที่ 20 ขั้นตอนที่ 3 ทำการย้ายเส้นขอบต่างๆ ทั้งรอบนอกใบหูและภายในใบหู จะได้เส้นขอบภายในทั้งหมด 3 เส้น และหาจุดต่างๆ ตามเส้นขอบ ดังภาพที่ 21 และขั้นตอนที่ 4 เป็นกระบวนการสกัดคุณลักษณะโดยวิธีการทางคณิตศาสตร์โดยการหาระยะห่างระหว่างจุดตั้งฉากแต่ละจุดเป็นค่าคงที่ทั้งหมด 83 ค่า



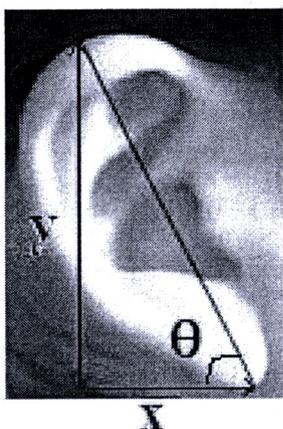
ภาพที่ 20 การหาเส้นขอบและการปรับเส้นขอบรอบนอกให้เรียบ

ได้ทำการทดลองจากภาพถ่ายใบหูได้จากกล้องวงจรปิด จำนวน 28 คน คนละ 125 ภาพรวมเป็น 3,500 ภาพ ผลการสกัดคุณลักษณะให้ค่าความผิดพลาดร้อยละ 7.6



ภาพที่ 21 การย้ายเส้นขอบภายนอกและภายในใบหูและการหาจุดต่างๆ

2.5 Using 2D Wavelet and Principal Component Analysis for Personal Identification Based On 2D Ear Structure [23] ได้นำเสนอวิธีการสกัดคุณลักษณะโดยใช้เส้นขอบและจุดสำคัญในโครงสร้างของใบหู โดยประยุกต์ใช้วิธี 2D Wavelet ในการจัดการรูปภาพ ได้แบ่งส่วนประกอบของภาพออกเป็น 3 ส่วน คือ แนวตั้ง แนวอนและแนวทแยงมุม ด้วย Wavelet แล้วค้นหาคุณลักษณะสำคัญทั้งสามทิศทาง จากนั้นรวมเอาคุณลักษณะสำคัญเข้าด้วยกัน อยู่ในรูปของเมตริกซ์ แล้วประยุกต์เอา Principal Component Analysis (PCA) มาใช้สำหรับทำให้จำนวนมิติลดน้อยลง การทดลองใช้ USTB Database มีประสิทธิภาพในการรู้จำร้อยละ 90.5 และ Carreira-Perpinan Database มีประสิทธิภาพในการรู้จำร้อยละ 95.05



ภาพที่ 22 การคำนวณหาทิศทางของรูปภาพใบหู

จากวรรณกรรมและงานวิจัยที่เกี่ยวข้องที่ได้นำเสนอข้างต้นจะพบว่า ระบบบุคคลชีวมาตรโดยใช้ใบหูในการรู้จำ มีประเด็นที่สำคัญที่ต้องคำนึงถึง 2 ประเด็น ประเด็นแรกคือ การได้มาของตำแหน่งสำคัญของภาพถ่ายใบหู ซึ่งหลายงานวิจัยได้นำเสนอวิธีการระบุตำแหน่งสำคัญแตกต่างกัน วิทยานิพนธ์นี้ได้นำเสนอวิธีระบุตำแหน่งสำคัญอยู่ 2 วิธีการเพื่อนำมาเปรียบเทียบกัน คือ วิธีระบุตำแหน่งสำคัญแบบใช้โครงสร้างของใบหูและวิธีระบุตำแหน่งสำคัญโดยการแปลงเวกเตอร์ของภาพ ประเด็นที่สองที่ต้องคำนึงคือ ตัวแบบที่นำมาใช้ในการรู้จำลักษณะของใบหู วิทยานิพนธ์นี้เลือกใช้ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน เนื่องจากความสามารถในการแบ่งกลุ่มด้วยระยะห่างที่มากที่สุด สามารถลดความเสี่ยงในการระบุตัวบุคคลผิดพลาดได้ ซึ่งแตกต่างจากตัวแบบที่ใช้ในการแบ่งกลุ่มอื่น ๆ