

2.1.7 การคำนวณเนื้อภาพ (Texture Analysis)

การวัดค่าความเป็นพื้นผิว นับเป็นเครื่องมือที่สำคัญในงานด้านการประมวลผลภาพ ยกตัวอย่างเช่น การตรวจสอบวัตถุด้วยลักษณะพื้นผิวถูกใช้ในการตรวจสอบอุปกรณ์กึ่งตัวนำ (Semiconductor) และการวัดค่าความเป็นพื้นผิวจะถูกกำหนดด้วยค่าการกระจายตัวของค่าระดับสีเทาที่อยู่ในบริเวณใกล้เคียงกัน วิธีการวัดค่าความเป็นพื้นผิวถูกแยกเป็น 2 แบบคือ วิธีการทางสถิติ (Statistic methods) และวิธีการเชิงโครงสร้าง (Structural methods) โดยงานวิจัยนี้ จะอธิบายวิธีการทางสถิติเพื่อใช้ในการตัดแยกกึ่งที่มีเส้นเลือดกลางหลังออกจากกึ่งที่ไม่มีเส้นเลือดกลางหลัง วิธีการทางสถิติเป็นการนำค่าความเป็นพื้นผิวด้วยการกระจายของค่าระดับสีเทามาทำการพิจารณาความเป็นพื้นผิว โดยจะนำมาสร้างเป็นเมตริกซ์การเกิดร่วมกันของค่าระดับสีเทา (Gray-level co-occurrence matrix) เมตริกซ์ดังกล่าวจะถูกนำมาใช้ในการคำนวณและใช้ในการวิเคราะห์หาความเป็นพื้นผิวต่อไป เมตริกซ์การเกิดร่วมกันของค่าระดับสีเทา แทนด้วยเมตริกซ์ $p[i, j]$ และการกำหนดทิศทางในการนับคู่ของค่าระดับสีเทาด้วยเวกเตอร์ $d = (d_x, d_y)$ โดย $p_d(i, j)$ เป็นจำนวนการเกิดค่าระดับสีเทาที่เกิดระหว่างพิกัด (x, y) และพิกัด $(x + d_x, y + d_y)$ โดยที่ค่าระดับสีเทาที่พิกัด (x, y) แทนด้วยสัญลักษณ์ $I(x, y) = i$ และค่าระดับสีเทาที่พิกัด $(x + d_x, y + d_y)$ แทนด้วยสัญลักษณ์ $I(x + d_x, y + d_y) = j$ ในเมตริกซ์ $p[i, j]$ ดังสมการที่ 16


$$p_d(i, j) = \text{number of } \{(x, y), (x + dx, y + dy)\} \in R_d \quad (16)$$

โดยสามารถยกตัวอย่างการหาเมตริกซ์การเกิดร่วมกันของค่าระดับสีเทาจากรูปที่มีค่าระดับสีเทา 3 ค่าคือ 0, 1 และ 2 ดังรูปที่ 1

0	1	2	3
2	0	1	1
3	2	0	2
1	0	3	0

ภาพที่ 2.9 ภาพที่มีระดับสีเทา 3 ค่า


กระบวนการ GLCM สามารถสร้างได้โดยการนับจำนวนคู่จุดภาพ $(k, 1)$ และ (m, n) ที่อยู่ใกล้กัน (Neighboring Cells) ที่มีระยะห่าง (Distance) ระหว่างกันเท่ากับ d และทำมุมกันเท่ากับ θ โดยในที่นี้ เราสนใจมุมที่มีค่าเท่ากับ $0^\circ, 45^\circ, 90^\circ$ และ 135° ดังภาพที่ 2.10 และ GLCMs นั้นสามารถคำนวณได้จากสมการที่ (17) ถึง สมการที่ (20) ตามลำดับ โดยเครื่องหมาย # ในสมการหมายถึงค่าจำนวนหรือค่าความถี่



รูปที่ 2.10 จุดภาพข้างเคียงในมุม $0^\circ, 45^\circ, 90^\circ$ และ 135° ในระยะห่างต่างๆ

ในการคำนวณ GLCMs นั้นกำหนดให้

(m, n) แทนจุดภาพ (pixel) บนภาพ 2 มิติใดๆ ของภาพดิจิทัล I ทิศทางของแกน x และ y แสดงดังรูปที่ 2.3



ภาพที่ 2.11 ทิศทางของแกน x และแกน y

- $L_x = \{1, 2, \dots, N_x\}$ และ $L_y = \{1, 2, \dots, N_y\}$ คือโดเมนเชิงพื้นที่ (Spatial Domain) ของ x และ y ตามลำดับโดย N_x คือ จำนวนจุดภาพในแนวแกน x และ N_y คือจำนวนจุดภาพในแนวแกน y
- $L_x \times L_y$ คือ เซตของจุดภาพของภาพที่เรียงลำดับในลักษณะหลักและแถว
- $G = \{1, 2, \dots, N_g\}$ คือ เซตค่าโทนสีเทา โดยที่ N_g คือ ค่าสีสูงสุดที่เป็นไปได้ในภาพ ซึ่งก็คือค่าสีที่แตกต่างกันในภาพ

ในที่นี้เพื่อให้เกิดความเข้าใจโดยง่าย จะขอยกตัวอย่างภาพ I ที่มีขนาด 4×4 จุดภาพ ที่มี $L_x = \{1, 2, 3, 4\}$ และ $L_y = \{1, 2, 3, 4\}$ ดังรูปที่ 2.4(ก) ตัวอย่าง GLCM เขียนได้ดังรูปที่ 2.4 (ข) และสำหรับ GLCM ที่มีค่า $d = 1$ และมุม θ เท่ากับ $0^\circ, 45^\circ, 90^\circ$ และ 135° ดังรูปที่ 2.4 (ค) – 2.4(ฉ) ตามลำดับ

0	1	2	3
2	0	1	1
3	2	0	2
1	0	3	0

(ก) ตัวอย่างภาพ I ขนาด 4x4

		ระดับค่าสีเทา (j)			
		#(0,0)	#(0,1)	#(0,2)	#(0,3)
ระดับ	ค่า	#(1,0)	#(1,1)	#(1,2)	#(1,3)
	สีเทา	#(2,0)	#(2,1)	#(2,2)	#(2,3)
	(i)	#(3,0)	#(3,1)	#(3,2)	#(3,3)

(ข) รูปแบบมาตรฐานของเมตริกซ์ร่วมสัมพันธ์ สำหรับ

ค่าระดับสีเทาที่ 0-3

$$\begin{pmatrix} 0 & 3 & 3 & 2 \\ 3 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 2 & 0 & 2 & 0 \end{pmatrix}$$

(ค) ค่า GLCM ที่มุม 0

$$\begin{pmatrix} 0 & 2 & 4 & 1 \\ 2 & 0 & 2 & 2 \\ 4 & 2 & 0 & 1 \\ 1 & 2 & 1 & 0 \end{pmatrix}$$

(ง) ค่า GLCM ที่มุม 45

$$\begin{pmatrix} 6 & 0 & 0 & 1 \\ 0 & 2 & 2 & 0 \\ 0 & 2 & 2 & 1 \\ 1 & 0 & 1 & 0 \end{pmatrix}$$

(จ) ค่า GLCM ที่มุม 90

$$\begin{pmatrix} 2 & 1 & 1 & 1 \\ 1 & 0 & 3 & 1 \\ 1 & 3 & 0 & 1 \\ 1 & 1 & 1 & 0 \end{pmatrix}$$

(ฉ) ค่า GLCM ที่มุม 135

รูปที่ 2.12 ตัวอย่างการคำนวณ GLCMs ที่มีค่าระยะห่างมีค่า $d=1$ และมุม θ เท่ากับ $0^\circ, 45^\circ, 90^\circ$ และ 135°

$$P(i, j, d, 0^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k - m| = 0, |l - n| = d, I(k, l) = i, I(m, n) = j \end{array} \right\} \quad (17)$$

$$P(i, j, d, 45^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |(k - m = d, l - n = -d) \text{ or } (k - m = -d, l - n = d)|, \\ I(k, l) = i, I(m, n) = j \end{array} \right\} \quad (18)$$

$$P(i, j, d, 90^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k - m = d, l - n = 0, I(k, l) = i, I(m, n) = j \end{array} \right\} \quad (19)$$

$$P(i, j, d, 135^\circ) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |(k - m = d, l - n = -d) \text{ or } (k - m = -d, l - n = d)|, \\ I(k, l) = i, I(m, n) = j \end{array} \right\} \quad (20)$$

หากเปรียบเทียบกับฮิสโตแกรมของภาพ (Image Histogram) ซึ่งบ่งบอกถึงการกระจายความน่าจะเป็นของค่าโทนสีเทาของภาพแล้ว ค่า GLCM นั้นก็จะแสดงถึงความน่าจะเป็นร่วมกัน

(Joint Probability) ของคูโทนสี ณ ตำแหน่งเชิงสัมพัทธ์ (Relative Position) ที่กำหนดหนึ่งในภาพ โดยทั่วไปแล้วจะมีการสร้าง GLCMs ขึ้นมาหลายเมตริกซ์ แต่ละเมตริกซ์สำหรับค่าเชิงสัมพัทธ์หนึ่งๆซึ่งในที่นี้ได้แก่ระยะห่าง d และมุม θ ทั้งนี้เพื่อให้เกิดการวิเคราะห์ข้อมูลเชิงพื้นผิวในทิศทางต่างๆ รวมทั้งมีการวิเคราะห์ข้อมูลเชิงพื้นผิวในลักษณะเดียวกันแต่ต่างขนาด (Scale) โดยค่าลักษณะเด่นเชิงพื้นผิวต่างๆ ที่สามารถคำนวณได้จาก GLCMs นั้น เรามักจะนำเอาค่าเฉลี่ยของทุกๆ เมตริกซ์ที่หามาได้เพื่อนำมาเป็นตัวแทนของภาพ เพื่อให้เกิดความครอบคลุมข้อมูลลักษณะพื้นผิวในทุกทิศทางและกำจัดปัญหาการขึ้นต่อการหมุนของภาพ (Rotation Variant)

GLCMs นั้นมีคุณสมบัติในการบอกลักษณะการกระจายเชิงพื้นที่ของค่าโทนสีในภาพ ยกตัวอย่างเช่น หากในเมตริกซ์นั้นมีค่าจำนวนมากอยู่ในช่องแนวทแยงมุมแสดงว่าภาพมีลักษณะหยาบตามค่าระยะห่าง d ที่ใช้ในการคำนวณ เป็นต้น ข้อมูลเชิงพื้นผิวที่ นำเสนอนั้นแสดงดังสมการที่ (21) ถึง (34)

เมื่อทำการคำนวณหาค่าของเมตริกซ์การเกิดร่วมกันของค่าระดับสีเทาแล้ว การนำมาใช้ประโยชน์ในการวัดค่าความเป็นพื้นผิวโดยการใช้เครื่องมือในการวัดต่างๆ ยกตัวอย่างเช่น เอนโทรปี (Entropy), พลังงาน, การวัดค่าสีที่ตัดกัน (Contrast), การวัดค่าความเป็นเนื้อเดียวกัน (Homogeneity) และออโตคอร์เรลชัน (Autocorrelation)

- เอนโทรปี (Entropy) เป็นการวัดการกระจายของข้อมูล โดยข้อมูลที่มีการกระจุกตัวจะมีค่า เอนโทรปีที่เพิ่มมากขึ้น โดยสมการในการคำนวณเอนโทรปีจะใช้ค่าของเมตริกซ์การเกิดร่วมกันของค่าระดับสีเทา ดังสมการที่ 21

$$Entropy = -\sum_{i,j} p(i,j) \log p(i,j) \quad (21)$$

- พลังงาน (Energy) เป็นการวัดค่าของการกระจายของข้อมูล โดยบริเวณที่มีการกระจายของค่าระดับสีเทาจะมีค่าพลังงานน้อยกว่าบริเวณที่มีการกระจุกของข้อมูลคำนวณได้จากสมการที่ 22

$$Energy = \sum_{i,j} p(i,j)^2 \quad (22)$$

- การวัดค่าสีที่ตัดกัน (Contrast) เป็นการวัดค่าความแตกต่างของค่าระดับสีเทาในบริเวณที่สนใจ สามารถคำนวณได้จากสมการที่ 23

$$Contrast = \sum_{i,j} (i-j)^2 p(i,j) \quad (23)$$

- การวัดค่าความเป็นเนื้อเดียวกัน (Homogeneity) เป็นการวัดค่าของการกระจายตัวของค่าระดับสีเทาบนภาพ ว่ามีการกระจายเป็นเนื้อเดียวกันมากน้อยเพียงใด สามารถคำนวณได้จากสมการที่ 24

$$Homogeneity = \sum_{i,j} \frac{p(i,j)}{i+|i-j|} \quad (24)$$

- ออโตคอรีเลชัน (Autocorrelation) เป็นการวัดค่าพื้นผิวของภาพ หากค่าของออโตคอรีเลชัน ค่อยๆ ลดลง แสดงว่า ภาพมีความหยาบของพื้นผิวมาก แต่ถ้าค่าของออโตคอรีเลชัน ลดลงอย่างรวดเร็ว แสดงว่าพื้นผิวของภาพเรียบและสามารถคำนวณได้จากสมการที่ 25

$$p[k,l] = \frac{\frac{1}{(N-k)(N-1)} \sum_{i=1}^{(N-k)} \sum_{j=1}^{N-1} f[i,j](i+k, j+1)}{\frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N f^2[i,j]}, 0 \leq k, l \leq N-1 \quad (25)$$

- ค่าโมเมนต์อันดับที่สองของมุม (Angular Second Moment, ASM) จุดภาพใกล้เคียงกันมีการเปลี่ยนแปลงค่าโทนสีไปในแนวทางเดียวกันซ้ำๆ ทำให้ค่าโมเมนต์อันดับที่สองของมุมของกลุ่มภาพ กิ่งที่ปกติมีค่ามาก แต่ในขณะที่ข้อมูลกลุ่มภาพกิ่งที่การเปลี่ยนแปลงค่าโทนสีไปในแนวเดียวกันที่ น้อยกว่า จึงทำให้ค่าโมเมนต์อันดับที่สองของมุมของกลุ่มภาพกิ่งที่มีความผิดปกติมีค่าน้อยกว่า

$$ASM = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \{p(i,j)\}^2 \quad (26)$$

- ผลรวมกำลังสองของค่าความแปรปรวน (Sum of Squares: Variance) เป็นการหาลักษณะการ กระจายของความน่าจะเป็น ข้อมูลภาพกลุ่มกิ่งที่ปกติมีโทนสีที่กลมกลืนทำให้มีจำนวนของโทนสี ของจุดภาพใกล้เคียงที่เหมือนกันมีจำนวนมากและมีการกระจายน้อย จึงทำให้ผลรวมกำลังสอง ของค่าความแปรปรวนมีค่ามาก

$$Variance = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i,j) \quad (27)$$

- ค่าผั้กลับของผลต่างโมเมนต์ (Inverse Difference Moment) เป็นค่าที่แสดงถึงความเหมือนกัน ของโทนสีของจุดภาพใกล้เคียง ซึ่งข้อมูลภาพกิ่งที่มีความปกติมีความเหมือนกันของโทนสีของจุด ภาพใกล้เคียงมาก ทำให้ค่าผั้กลับของผลต่างโมเมนต์มากด้วย

$$IDM = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-\mu)^2} p(i,j) \quad (28)$$

- ผลรวมของค่าเฉลี่ย (Sum Average) หากมีจำนวนของจุดภาพใกล้เคียงที่มีค่าสีเทาแตกต่างกันอยู่จำนวนมากก็จะทำให้ค่าความต่างมีค่ามาก แต่ข้อมูลภาพกลุ่มกึ่งที่มีความปกติ และกึ่งที่มีความผิดปกติมีความต่างของโทนสีน้อย ทำให้ค่าผลรวมค่าเฉลี่ยผลต่างน้อย

$$SumAverage = \sum_{i=2}^{2N_g} ip_{x+y}(i, j) \quad (29)$$

- ผลรวมของค่าความแปรปรวน (Sum Variance) ข้อมูลภาพกลุ่มภาพกึ่งที่มีความปกติมีโทนสีที่กลมกลืนทำให้มีจำนวนโทนสีของจุดภาพใกล้เคียงที่เหมือนกันมีมาก จึงทำให้ผลรวมของค่าความแปรปรวนมีค่าน้อย

$$SumVariance = \sum_{i=2}^{2N_g} (i - f_g)^2 p_{x+y}(i) \quad (30)$$

- ผลต่างของความแปรปรวน (Difference Variance) แสดงความแปรปรวนของเมตริกซ์ร่วมสัมพันธ์

$$Difference\ Variance = \text{variance of } p_{x=y} \quad (31)$$

- ผลต่างของเอนโทรปี (Difference Entropy) เป็นการแสดงการแจกแจงองค์ประกอบของเมตริกซ์ร่วมสัมพันธ์โดยการรวมค่าความเป็นไปได้เมื่อ $|i, j|$ เป็นค่าคงที่

$$DifferenceEntropy = - \sum_{i=0}^{N_g-1} p_{x=y}(i) \log \{ p_{x=y}(i) \} \quad (32)$$

- การวัดสหสัมพันธ์ของสหสัมพันธ์แบบที่ 1 (Information Measures of Correlation) เป็นการพิจารณาว่ามีข้อมูลของความสัมพันธ์โทนสีค่าหนึ่งแล้วเกิดการลดลงของการเปลี่ยนแปลงค่าของความสัมพันธ์โทนสีอีกค่าหนึ่งอย่างไร ซึ่งข้อมูลภาพรูปกึ่งที่มีความปกติมีจำนวนโทนสีของจุดภาพใกล้เคียงที่เหมือนกันมาก จึงทำให้ค่าการวัดสหสัมพันธ์ของสหสัมพันธ์มีค่ามากด้วย

$$f_1 = \frac{HXY - HXY1}{\max \{HX, HY\}} \quad (33)$$

- การวัดสหสัมพันธ์ของสหสัมพันธ์แบบที่ 2 (Information Measures of Correlation)

$$f_2 = (1 - \exp[-2.0(HXY2 - HXY)])^{\frac{1}{2}} \quad (34)$$

โดยที่

- $p(i, j)$ คือ ค่า $p(i, j)$ ที่ผ่านการนอร์มัลไลเซชัน (Normalization) โดยคำนวณได้จาก $p(i, j) = \frac{P(i, j)}{R}$ โดยที่ R คือจำนวนคู่ของภาพทั้งหมดในภาพ
- $p_x(i)$ คือ ค่าในช่องที่ i ของ Marginal Probability Vector ที่คำนวณได้จากผลรวมของ $p(i, j)$ ในทุกหลักของแถว i หรือ $p_x(i) = \sum_{j=1}^{N_g} p(i, j)$
- $p_y(j)$ คือ ค่าในช่องที่ j ของ Marginal Probability Vector ที่คำนวณได้จากผลรวมของ $p(i, j)$ ในทุกหลักของแถว j หรือ $p_y(j) = \sum_{i=1}^{N_g} p(i, j)$
- $p_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \quad k = 2, 3, \dots, 2N_g$
- $p_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \quad k = 0, 1, \dots, N_g - 1$

ในงานวิจัยนี้ เรากำหนดระยะห่าง d เป็น 1 และค่าลักษณะเด่นเชิงพื้นผิวของทั้ง 13 ลักษณะ เป็นการคำนวณจาก $p(i, j)$ ในแต่ละทิศทาง แล้วนำไปใช้ค่าเฉลี่ย เพื่อให้เกิดความครอบคลุมข้อมูลลักษณะพื้นผิวในทุกทิศทาง และกำจัดปัญหาการขึ้นต่อการหมุนของภาพ

2.2 งานวิจัยที่เกี่ยวข้อง

LCdr. Nikorn Chaichuay. [1] ได้นำเสนอวิธีจดจำเรือเดินทะเลต่างชนิดกันโดยใช้ลักษณะตัวอธิบายฟูเรียร์ด้วย 36 ค่าสัมประสิทธิ์ แทนลักษณะของเส้นรอบขอบรูปทั้งหมดของรูปเรือ Tyler Karrels [4] ได้เสนอวิธีการดึงลักษณะเฉพาะและกำหนดข้อมูลที่อยู่ในภาพโดยใช้ตัวอธิบายฟูเรียร์ในการจดจำภาพของใบไม้ L. Xu. [7] ได้นำเสนอการแยกส่วนของภาพ (Segmentation) ของมะเร็งผิวหนัง โดยการหาค่าขีดแบ่งความเข้มแสง Øivind Due Trier. [9] ได้นำเสนอและอธิบายอย่างคร่าวๆของวิธีการดึงลักษณะเฉพาะสำหรับการจดจำลักษณะเฉพาะของการดึงลักษณะเฉพาะ วิธีการดึงลักษณะเฉพาะที่แตกต่างกันและออกแบบการแทนที่แตกต่างของลักษณะเฉพาะ เช่น ลักษณะเฉพาะของเส้นรอบโครงร่าง (Contour)