

บทที่ 1

บทนำ

1.1 ปัญหาและที่มา

ในปัจจุบันอัตราการเกิดโรคมะเร็งเต้านมมีแนวโน้มสูงขึ้นและเป็นสาเหตุหนึ่งที่เกี่ยวข้องกับการเสียชีวิต จากสถิติผู้ป่วยโรคมะเร็งเต้านมที่เข้ารับรักษาในสถาบันตามตารางที่ 1.1 แสดงให้เห็นว่ามีจำนวนผู้ป่วยเพิ่มขึ้นในแต่ละปี สาเหตุของการเกิดโรคมะเร็งเต้านมนั้นในปัจจุบันยังไม่ทราบสาเหตุที่แท้จริง อย่างไรก็ตามโรคมะเร็งเต้านมสามารถรักษาให้หายขาดได้ถ้าหากผู้ป่วยอยู่ในระยะเริ่มต้นของโรคซึ่งสามารถตรวจพบได้

ตารางที่ 1.1 สถิติผู้ป่วยมะเร็งเต้านมในประเทศไทยตั้งแต่ปี 2548 ถึง 2551 [1, 2]

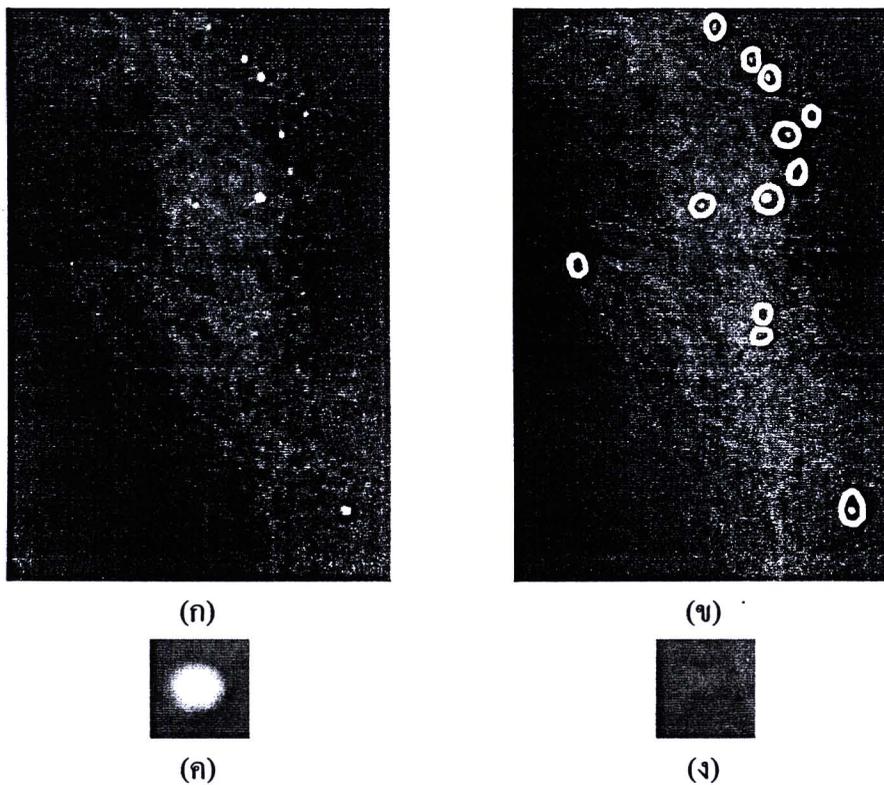
สถาบัน	จำนวนผู้ป่วย (ราย)			
	พ.ศ. 2548	พ.ศ. 2549	พ.ศ. 2550	พ.ศ. 2551
สถานวิทยามะเร็งศิริราช	782	843	1,010	1,186
สถาบันมะเร็งแห่งชาติ	686	749	793	801

ก้อนหินปูนขนาดเล็ก (Microcalcification) เป็นความผิดปกติสาเหตุหนึ่งที่ทำให้มีโอกาสเกิดเป็นโรคมะเร็งเต้านมซึ่งสามารถตรวจพบได้จากภาพรังสีเต้านม (Mammograms) โดยการวินิจฉัยจากรังสีแพทย์ ซึ่งหากผู้ป่วยทราบว่ามีการพบก้อนหินปูนขนาดเล็กปรากฏอยู่ ก็สามารถทำการรักษาเพื่อป้องกันการก่อให้เกิดขึ้นเป็นโรคมะเร็งเต้านมในอนาคตได้

การวิเคราะห์ความผิดปกติของเต้านมเพื่อที่จะตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านมที่ถูกต้องและแม่นยำนั้น ขึ้นอยู่กับองค์ประกอบที่สำคัญเช่น ลักษณะเต้านมของผู้ป่วย การถ่ายฟิล์มรังสี และประสิทธิภาพของรังสีแพทย์ สำหรับก้อนหินปูนที่มีขนาดเล็ก 1-3 มิลลิเมตร รังสีแพทย์อาจจะต้องใช้อุปกรณ์ขยายภาพฟิล์มรังสีเพื่อช่วยในการวิเคราะห์ซึ่งอาจทำให้เกิดความผิดพลาดขึ้นได้ ในปัจจุบันได้มีการนำเอาคอมพิวเตอร์มาช่วยในการวิเคราะห์ก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม [3 - 16] โดยภาพรังสีเต้านมจะอยู่ในรูปแบบที่เป็นดิจิทัล (Digital) และใช้กระบวนการความฉลาดทางการคำนวณ (Computational Intelligence: CI)

การนำเอาระบบฟัซซีลอจิกมาตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม [3 - 7] เป็นการนำเอาระบบอนุมานแบบฟัซซี (Fuzzy Inference System) มาประยุกต์ใช้ โดยการสร้างฟังก์ชัน

สมาชิกจากชุดข้อมูลเรียนรู้ (Training Dataset) เพื่อนำฟังก์ชันสมาชิกที่สร้างขึ้น ไปใช้ในระบบฟัซซีลอจิก ระบบจะทำการพิจารณาภาพย่อย (Sub-Image) จากภาพรังสีเต้านม เอาต์พุตจากระบบจะระบุว่ามีความเป็นก้อนหินปูนขนาดเล็กอยู่ระหว่าง 0 ถึง 1 หลังจากนั้นนำไปตัดสินใจว่าเป็นก้อนหินปูนขนาดเล็กด้วยค่าขีดแบ่ง (Threshold) ถ้าหากผลออกมาเป็นการระบุว่า เป็นก้อนหินปูนขนาดเล็ก ก็ทำการระบุตำแหน่งจากภาพย่อยลงบนภาพรังสีเต้านม ดังแสดงในรูปที่ 1.1



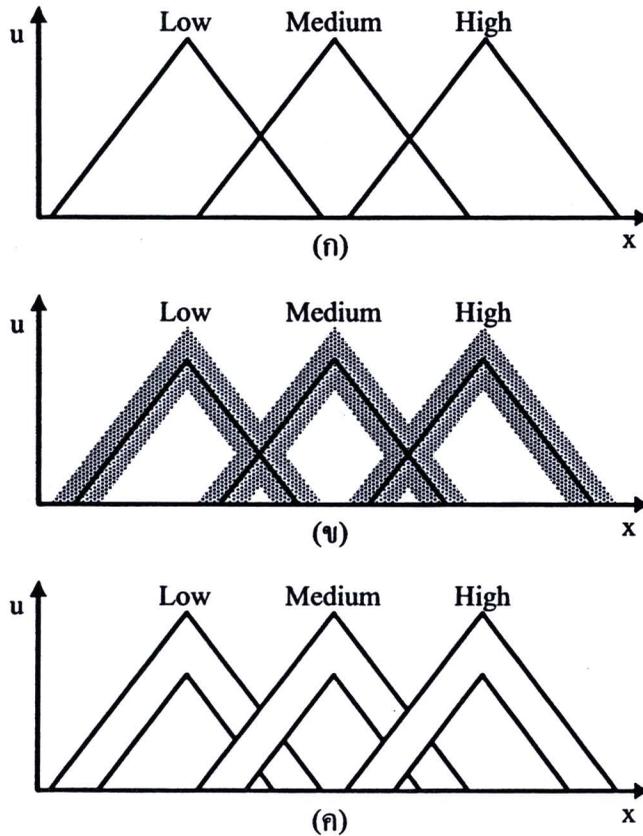
รูปที่ 1.1 ภาพรังสีเต้านม (ก) ภาพรังสีเต้านมก่อนตรวจจับก้อนหินปูนขนาดเล็ก
 (ข) แสดงตำแหน่งที่ปรากฏเป็นก้อนหินปูนขนาดเล็ก
 (ค) ภาพย่อยที่มีลักษณะเป็นก้อนหินปูนขนาดเล็ก
 (ง) ภาพย่อยที่มีลักษณะไม่เป็นก้อนหินปูนขนาดเล็ก

ระบบฟัซซีลอจิก [17] เป็นเทคนิคหนึ่งที่น่าสนใจในการคัดแยกข้อมูล (Classification) ซึ่งใช้อย่างแพร่หลายในงานรู้จำรูปแบบ การใช้ระบบฟัซซีลอจิกสามารถกำหนดความไม่แน่นอน (Uncertainty) โดยใช้ฟังก์ชันสมาชิก (Membership Function) ซึ่งการสร้างฟังก์ชันสมาชิกนี้สามารถสร้างจากชุดข้อมูล (Dataset) ได้หลายวิธี เช่น วิธีแบบสำนึก (Heuristic Methods) วิธีแบบภาพแบ่งความถี่ (Histogram Methods) หรือวิธีแบบการจัดกลุ่ม (Clustering Methods) [18] เป็นต้น สำหรับรูปร่าง (Shape) ของฟังก์ชันสมาชิกที่สามารถเลือกใช้ เช่น ฟังก์ชันสามเหลี่ยม (Triangular

Function) ฟังก์ชันสี่เหลี่ยมคางหมู (Trapezoidal Function) ฟังก์ชันเกาส์เซียน (Gaussian Function) ฟังก์ชันเอส (S-Function) และฟังก์ชันไพ (π -Function) เป็นต้น [19] ลักษณะดังกล่าวถูกนำมาสร้างฟังก์ชันสมาชิกเพื่อนำไปใช้ในกระบวนการตัดสินใจในระบบฟัซซีลอจิกหรือระบบอนุมานแบบฟัซซี (Fuzzy Inference System) และประเภทของระบบฟัซซีลอจิกที่มีความแตกต่างในการกำหนดความไม่แน่นอน ในปัจจุบันนิยมนำไปประยุกต์ใช้อยู่ 2 ระบบ [20] คือ ระบบไทป์วันฟัซซีลอจิก (Type-1 Fuzzy Logic System) และระบบไทป์ทูฟัซซีลอจิก (Type-2 Fuzzy Logic System)

สำหรับฟังก์ชันสมาชิกของไทป์ทู (Type-2 Membership Function) จะประกอบด้วยฟังก์ชันสมาชิกหลัก (Primary Membership Function) และฟังก์ชันสมาชิกรอง (Secondary Membership Function) ซึ่งก็คือจะมีฟังก์ชันสมาชิกรองในทุกช่วงของฟังก์ชันสมาชิกหลัก และสามารถกล่าวได้ว่าฟังก์ชันสมาชิกของไทป์วัน (Type-1 Membership Function) เป็นกรณีพิเศษของฟังก์ชันสมาชิกไทป์ทู ผลลัพธ์ของระบบไทป์ทูฟัซซีลอจิกสามารถให้ประสิทธิภาพที่ดีกว่าระบบไทป์วันฟัซซีลอจิก [21 - 23] แต่การคำนวณในระบบไทป์ทูฟัซซีลอจิกนั้นจะมีความซับซ้อนในขั้นตอนไทป์รีดักชัน (Type-Reduction) เพื่อลดปัญหาดังกล่าว Liang และ Mendel [23] ได้เสนอระบบอินเทอร์วัลไทป์ทูฟัซซีลอจิก (Interval Type-2 Fuzzy Logic) ซึ่งสามารถลดปัญหาดังกล่าวได้ โดยจะให้ค่าความเป็นสมาชิกของฟังก์ชันรองมีค่าเท่ากับหนึ่งในทุกค่าของช่วงฟังก์ชันหลัก ทำให้ฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทูเป็นลักษณะที่เรียกว่าขอบเขตความไม่แน่นอน (Footprint of Uncertainty: FOU) ประกอบด้วยสองฟังก์ชันคือ ฟังก์ชันสมาชิกขอบเขตบน (Upper Membership Function: UMF) และฟังก์ชันสมาชิกขอบเขตล่าง (Lower Membership Function: LMF) ดังแสดงในรูปที่ 1.2 เป็นตัวอย่างฟังก์ชันสมาชิกแบบสามเหลี่ยมทั้ง 3 ฟังก์ชันที่แตกต่างกันคือ ฟังก์ชันสมาชิกของไทป์วัน ฟังก์ชันสมาชิกของไทป์ทู และฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู ตามลำดับ

การสร้างฟังก์ชันสมาชิก (Membership Function Generation) เป็นปัญหาที่สำคัญปัญหาหนึ่งของระบบฟัซซีลอจิก เพราะจะมีผลกระทบต่อประสิทธิภาพในการนำระบบฟัซซีลอจิกไปประยุกต์ใช้งาน เช่น การนำไปแทนค่าความเป็นสมาชิก (Membership Value) หรือการนำไปจำแนกข้อมูล (Classification) เป็นต้น ฟังก์ชันสมาชิกสามารถสร้างจากชุดข้อมูลเรียนรู้โดยการพิจารณาพารามิเตอร์ของฟังก์ชันเพื่อให้เหมาะสมกับชุดข้อมูลเรียนรู้มากที่สุด สำหรับพารามิเตอร์ในการสร้างฟังก์ชันสมาชิกส่วนใหญ่จะกำหนดโดยผู้เชี่ยวชาญ แล้วทำการทดสอบและหลังจากนั้นก็ทำการปรับแต่งค่าพารามิเตอร์เพื่อให้ได้ฟังก์ชันสมาชิกที่สามารถนำไปใช้กับระบบฟัซซีลอจิกที่มีเอาต์พุตออกมาได้ความถูกต้องมากที่สุด



รูปที่ 1.2 ฟังก์ชันความเป็นสมาชิกแบบสามเหลี่ยม (ก) ฟังก์ชันสมาชิกของไต้หวัน
(ข) ฟังก์ชันสมาชิกของไต้หวัน และ (ค) ฟังก์ชันสมาชิกของอินเทอวัลไต้หวัน

การสร้างฟังก์ชันสมาชิกโดยผู้เชี่ยวชาญดังที่กล่าวมาวิธีนี้มีข้อเสียคือ ปัญหาจะเกิดขึ้นถ้าหากมีการเปลี่ยนแปลงของชุดข้อมูลเรียนรู้ ทำให้ต้องมีการสร้างฟังก์ชันสมาชิกใหม่ และต้องปรับแต่งค่าพารามิเตอร์ของฟังก์ชันสมาชิกใหม่ทั้งหมด ซึ่งจะทำให้เสียเวลาและเป็นการเพิ่มภาระสำหรับผู้เชี่ยวชาญ งานวิจัยนี้จึงได้เกิดแนวคิดสำหรับการสร้างฟังก์ชันสมาชิก (Membership Function Generation) โดยมีความสามารถในการคำนวณหาพารามิเตอร์ที่ใช้ในการสร้างฟังก์ชันสมาชิกให้เป็นแบบอัตโนมัติ (Automatic Generation) เพื่อที่นำไปใช้ในระบบฟัซซีลอจิก ซึ่งก็จะช่วยลดปัญหาดังกล่าวได้ ดังนั้นในงานวิจัยนี้จะเป็นการสร้างฟังก์ชันสมาชิกของอินเทอวัลไต้หวันในระบบอินเทอวัลไต้หวันฟัซซีลอจิกมาประยุกต์ใช้สำหรับการตรวจจับก่อนหินปูนขนาดเล็กในภาพรังสีเต้านม

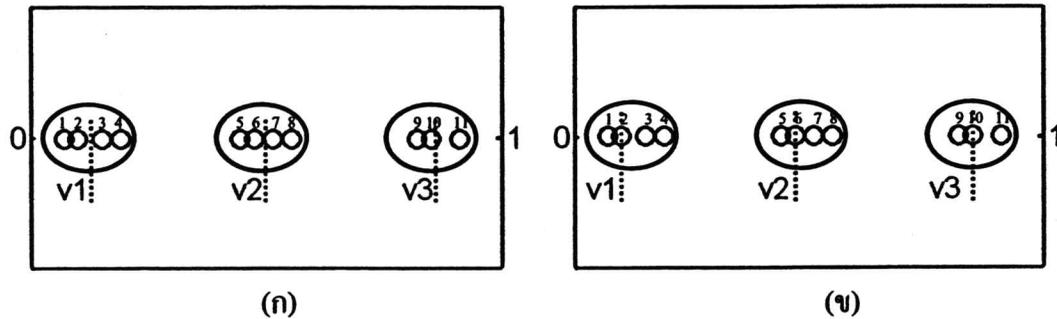
1.2 แนวทางแก้ปัญหา

จากการศึกษาในงานวิจัยที่เกี่ยวข้อง ได้จัดแบ่งเป็น 3 กลุ่มหลักคือ การตรวจจับก้อนหินปูนขนาดเล็กบนภาพรังสีเต้านม [3 - 16] การสร้างฟังก์ชันสมาชิกของไทป์วัน [24 - 32] และ การสร้างฟังก์ชันสมาชิกของไทป์ทู [33 - 36] ซึ่งทั้งหมดสามารถสรุปเป็นเทคนิควิธีการสร้างฟังก์ชันสมาชิกแบบต่างๆ คือ การสร้างฟังก์ชันสมาชิกจากผู้เชี่ยวชาญหรือกำหนดเอง (Manually) การสร้างฟังก์ชันสมาชิกจากการจัดกลุ่มแบบฟัซซีซีมีน (Fuzzy C-Means Methods) การสร้างฟังก์ชันสมาชิกจากภาพแท่งความถี่ (Histogram Methods) การสร้างฟังก์ชันสมาชิกด้วยอัลกอริทึมเชิงพันธุกรรม (Genetic Algorithms) การสร้างฟังก์ชันสมาชิกด้วยโครงข่ายประสาทเทียม (Neural Network) และการสร้างฟังก์ชันสมาชิกด้วยวิธี Self-Organizing Map

จากการศึกษางานวิจัยดังกล่าวข้างต้น การเลือกวิธีสร้างฟังก์ชันสมาชิกโดยวิธีการจัดกลุ่มข้อมูลจะมีข้อดีคือ มีขั้นตอนที่ไม่ซับซ้อน และการจัดเตรียมค่าพารามิเตอร์เริ่มต้นมีจำนวนไม่มาก ผลลัพธ์ที่ได้จากการจัดกลุ่มจะเป็นตำแหน่งกลางของข้อมูล (Centroid) พร้อมกับค่าความเป็นสมาชิก (Membership Values) ของข้อมูลในแต่ละกลุ่ม ซึ่งสามารถนำค่าความเป็นสมาชิกนี้มาสร้างเป็นฟังก์ชันสมาชิกได้

การจัดกลุ่มแบบพอสซิбилиลิสติกซีมีนส์ (Possibilistic C-Means: PCM) [37] เป็นวิธีการจัดกลุ่มข้อมูลที่ได้พัฒนามาจากการจัดกลุ่มแบบฟัซซีซีมีนส์ (Fuzzy C-Means: FCM) [38, 39] ซึ่งกำหนดให้ข้อมูลมีค่าความเป็นสมาชิกระหว่าง 0 ถึง 1 ($u_{ij} \in [0,1]$) คือค่าความเป็นสมาชิกข้อมูล j ในกลุ่มที่ i โดย PCM ได้ทำการเพิ่มเติมเงื่อนไขของฟังก์ชันเป้าหมาย (Objective Function) และวิธีแบบ PCM [37] มีคุณลักษณะข้อบังคับ (Constraint) ที่แตกต่างจาก FCM คือ วิธี PCM ให้ผลรวมของค่าความเป็นสมาชิกทั้งหมดไม่จำเป็นจะต้องเท่ากับจำนวนข้อมูลทั้งหมด ($0 < \sum_{j=1}^N u_{ij} \leq N$ สำหรับ i ทั้งหมด) แต่วิธี FCM จำเป็นจะต้องเท่ากับจำนวนข้อมูลทั้งหมด ($\sum_{j=1}^N u_{ij} = N$ สำหรับ i ทั้งหมด) ซึ่งการจัดกลุ่มแบบ PCM นี้มีความสามารถในการหลีกเลี่ยงข้อมูลรบกวน (Noise) หรือข้อมูลรบกวนมีผลกระทบต่อตำแหน่งกลาง (Centroid) ข้อมูลน้อยกว่าวิธีแบบ FCM

ตัวอย่างการเปรียบเทียบการจัดกลุ่มแบบ FCM และ PCM แสดงในรูปที่ 1.3 ค่าความเป็นสมาชิกและตำแหน่งกลางของกลุ่มทั้งสองวิธีแสดงค่าในตารางที่ 1.2 ซึ่งเป็นการจัดกลุ่มข้อมูล (Dataset) จำนวน 11 ตำแหน่งข้อมูล (Data Point) เรียงบนแกนจากด้านซ้ายไปด้านขวา ทำการจัดแบ่งกลุ่มออกเป็น 3 กลุ่ม ($V = 3$) โดยที่มีค่า v_1 , v_2 และ v_3 เป็น Prototype ของกลุ่มที่ 1, 2 และ 3 ตามลำดับ

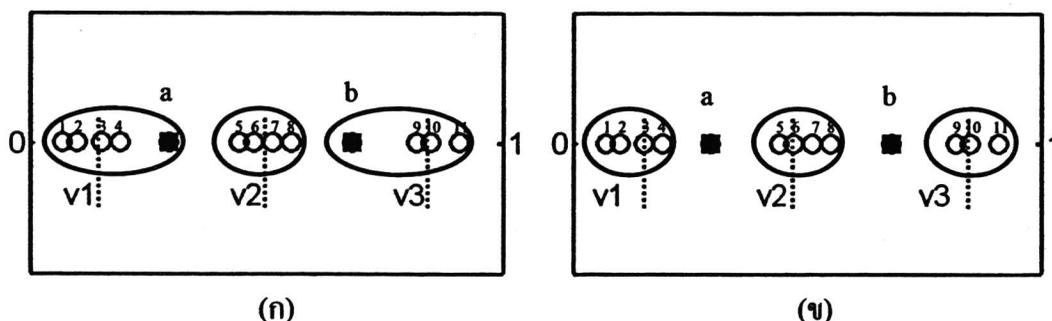


รูปที่ 1.3 ผลลัพธ์จากการแบ่งกลุ่มข้อมูล (ก) แบบ FCM และ (ข) แบบ PCM

ตารางที่ 1.2 ผลลัพธ์ค่าความเป็นสมาชิกหลังจากการจัดกลุ่มแบบ FCM และ PCM

Data Point	FCM			PCM		
	v1 = 0.127	v2 = 0.492	v3 = 0.880	v1 = 0.100	v2 = 0.469	v3 = 0.849
1	0.977	0.018	0.005	0.299	0.002	0.000
2	0.994	0.005	0.001	0.991	0.002	0.000
3	0.994	0.005	0.001	0.113	0.003	0.000
4	0.950	0.042	0.008	0.041	0.004	0.001
5	0.026	0.959	0.015	0.003	0.267	0.001
6	0.004	0.993	0.003	0.002	0.997	0.002
7	0.002	0.995	0.003	0.002	0.155	0.002
8	0.018	0.949	0.033	0.002	0.045	0.002
9	0.003	0.014	0.982	0.001	0.002	0.208
10	0.000	0.001	0.999	0.001	0.002	0.995
11	0.004	0.014	0.982	0.001	0.002	0.056

จากตารางที่ 1.2 แสดงให้เห็นว่าการจัดกลุ่มแบบ FCM มีค่าความเป็นสมาชิกของหนึ่งตำแหน่งข้อมูลในแต่ละกลุ่มรวมกันจะต้องมีค่าเท่ากับ 1 เสมอ ($\sum_{i=1}^v u_{ij} = 1$ สำหรับ j ทั้งหมด) แต่การจัดกลุ่มแบบวิธี PCM จะได้ค่าความเป็นสมาชิกของหนึ่งตำแหน่งข้อมูลในแต่ละกลุ่มรวมกันไม่จำเป็นต้องมีค่าเท่ากับ 1 หรือ $\sum_{i=1}^v u_{ij} > 0$ สำหรับ j ทั้งหมด และวิธีแบบ PCM ตำแหน่งข้อมูลที่อยู่ใกล้ตำแหน่งกลางของกลุ่มจะมีค่าความเป็นสมาชิกเข้าใกล้ค่า 1 และตำแหน่งที่อยู่ห่างจากตำแหน่งกลางข้อมูลจะมีค่าเข้าใกล้ค่า 0 จากตัวอย่างดังกล่าวได้ทำการเพิ่มตำแหน่งข้อมูลรอบวงเพิ่มเข้าไปอีกจำนวน 2 ตำแหน่งแล้วทำการจัดกลุ่มข้อมูลใหม่ผลลัพธ์แสดงในรูปที่ 1.4 ค่าความเป็นสมาชิกและตำแหน่งกลางข้อมูลแสดงในตารางที่ 1.3



รูปที่ 1.4 ผลลัพธ์จากการแบ่งกลุ่มข้อมูลโดยทำการเพิ่มข้อมูลรบกวนจำนวน 2 ตำแหน่ง จากข้อมูลในรูปที่ 1.3 (ก) แบบ FCM และ (ข) แบบ PCM

ตารางที่ 1.3 ค่าความเป็นสมาชิกจากการจัดกลุ่มแบบ FCM และ PCM โดยทำการเพิ่มข้อมูลรบกวนจำนวน 2 ตำแหน่งแล้วทำการจัดกลุ่มใหม่

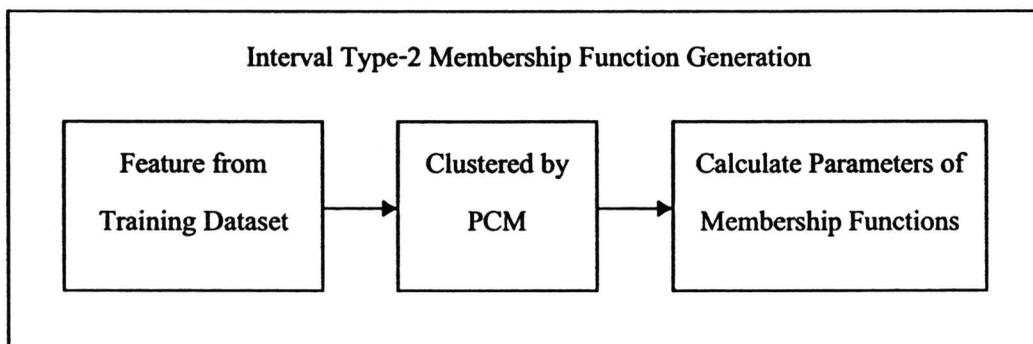
Data Point	FCM			PCM		
	v1 = 0.143	v2 = 0.494	v3 = 0.842	v1 = 0.151	v2 = 0.468	v3 = 0.845
1	0.963	0.029	0.009	0.099	0.007	0.001
2	0.985	0.012	0.003	0.217	0.008	0.001
3	0.999	0.000	0.000	0.998	0.011	0.001
4	0.972	0.023	0.005	0.324	0.014	0.001
5	0.032	0.951	0.017	0.009	0.581	0.003
6	0.006	0.990	0.004	0.007	0.997	0.004
7	0.002	0.996	0.002	0.006	0.388	0.005
8	0.018	0.948	0.034	0.005	0.142	0.006
9	0.001	0.005	0.994	0.002	0.009	0.444
10	0.000	0.000	0.999	0.001	0.008	0.959
11	0.008	0.026	0.967	0.001	0.006	0.109
a*	0.614	0.340	0.046	0.035	0.035	0.002
b**	0.049	0.412	0.538	0.003	0.024	0.018

* คือตำแหน่งจุดลี้ค่าที่ตำแหน่ง a ในรูปที่ 1.4 และ ** คือตำแหน่งจุดลี้ค่าที่ตำแหน่ง b ในรูปที่ 1.4

จากตารางที่ 1.3 ผลลัพธ์หลังทำการจัดกลุ่มข้อมูลใหม่โดยการเพิ่มตำแหน่งข้อมูลรบกวน จะเห็นได้ว่าตำแหน่งข้อมูลรบกวนที่เพิ่มเข้าไปนั้นค่าความเป็นสมาชิกวิธีแบบ FCM มีค่าความเป็นสมาชิกมากกว่าตำแหน่งที่อยู่ใกล้ตำแหน่งกลางของกลุ่ม (ตำแหน่งที่ 12 และ 13 ในตารางที่ 1.3) เพราะ FCM ยังต้องรักษาเงื่อนไขค่าความเป็นสมาชิกของทุกกลุ่มรวมกันมีค่าเท่ากับ 1 เสมอ แต่วิธีแบบ PCM จะได้ค่าความเป็นสมาชิกที่น้อยกว่าตำแหน่งที่อยู่ใกล้ตำแหน่งกลางข้อมูล ทำให้การ

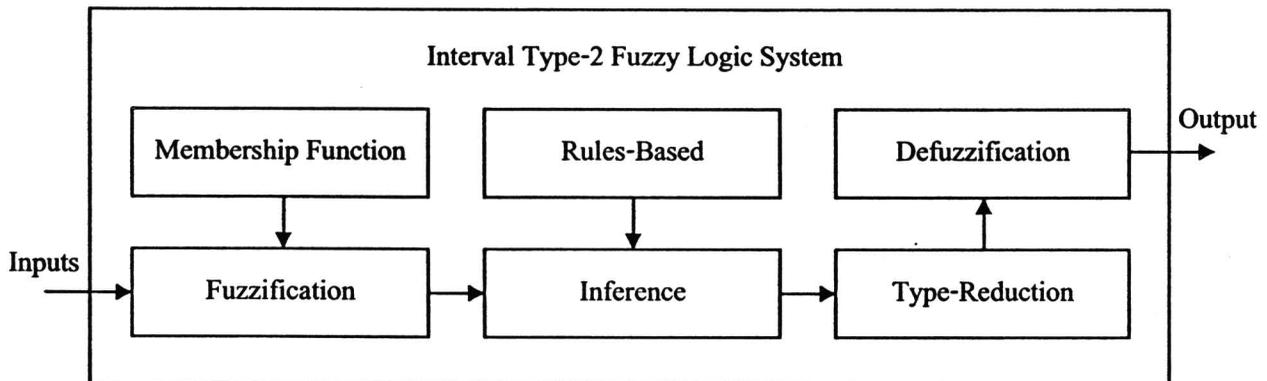
พิจารณาสมาชิกของแต่ละกลุ่มตามเงื่อนไขเคมิวิธี FCM จะนำข้อมูลข้อมูลรบกวนเป็นสมาชิกของกลุ่มด้วย แต่วิธี PCM ข้อมูลรบกวนจะไม่ถูกพิจารณาให้อยู่ในกลุ่มใด รวมถึงการเปลี่ยนแปลงของค่าตำแหน่งกลางข้อมูล (v_1 , v_2 และ v_3) โดยนำเอาค่าการเปลี่ยนแปลงตำแหน่งกลางข้อมูลรวมกัน จะเห็นได้ว่าวิธีแบบ FCM จะเกิดการเปลี่ยนแปลงตำแหน่งกลางมากกว่าวิธีแบบ PCM จากตัวอย่างดังกล่าวแสดงให้เห็นว่า การจัดกลุ่มแบบ PCM จะตอบสนองต่อข้อมูลรบกวนน้อยกว่าการจัดกลุ่มแบบ FCM

เพราะฉะนั้นงานวิจัยนี้ได้เลือกใช้วิธีการจัดกลุ่มแบบ PCM เพื่อนำมาค่าความเป็นสมาชิกมาสร้างเป็นฟังก์ชันสมาชิกของไทป์ทูของระบบอินเทอร์วัลไทป์ทูฟuzzyลอจิกประยุกต์ใช้ในการตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม โดยจะเป็นการคัดแยก (Classification) ระหว่างกลุ่มภาพย่อยที่มีลักษณะเป็นก้อนหินปูนขนาดเล็ก (Microcalcification) และกลุ่มภาพย่อยที่ไม่มีลักษณะเป็นก้อนหินปูนขนาดเล็ก (Non-microcalcification) เริ่มจากลักษณะภาพย่อยทั้งสองกลุ่มนี้จะถูกนำมาหาคุณลักษณะเด่นในแต่ละภาพ หลังจากนั้นทำการจัดกลุ่มที่ละคุณลักษณะเด่นด้วยวิธีแบบ PCM ผลลัพธ์ที่ได้เป็นตำแหน่งกลางของข้อมูลแต่ละกลุ่ม และค่าความเป็นสมาชิกของแต่ละกลุ่ม ข้อมูลรบกวน (Noise) ของแต่ละกลุ่มนั้นจะสามารถพิจารณาจากค่าความเป็นสมาชิกโดยการกำหนดค่าขีดแบ่ง (Threshold) เป็นเกณฑ์ในการพิจารณาข้อมูลออกจากกลุ่ม การสร้างฟังก์ชันสมาชิกจะนำค่าความเป็นสมาชิกของข้อมูลที่คัดแยกข้อมูลรบกวนออกแล้วมาสร้างเท่านั้น ซึ่งจำนวนฟังก์ชันสมาชิกที่ได้จะเท่ากับจำนวนกลุ่มที่ทำการจัดแบ่งในแต่ละคุณลักษณะเด่น จำนวนฟังก์ชันของแต่ละคุณลักษณะเด่นเรียกเป็นตัวแปรทางภาษา (Linguistic Variables) เช่น จัดกลุ่มเป็น 3 กลุ่มก็จะได้จำนวน 3 ฟังก์ชันแทนด้วย ต่ำ (Low) ปานกลาง (Medium) และสูง (High) ตามลำดับ สำหรับขั้นตอนการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทูโดยวิธีการจัดกลุ่มข้อมูลแบบ PCM แสดงในรูปที่ 1.5



รูปที่ 1.5 แผนภาพแสดงขั้นตอนของการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู

จากรูปที่ 1.5 แสดงขั้นตอนของการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู โดยเริ่มจากการนำเอาคุณลักษณะเด่นเป็นชุดข้อมูลเรียนรู้มาทำการจัดกลุ่มข้อมูล (Clustering) โดยจะทำการสร้างจัดกลุ่มที่ละคุณลักษณะเด่น ในงานวิจัยนี้จะเลือกใช้คุณลักษณะเด่นจำนวน 4 คุณลักษณะเด่น [6, 7] คือ B-descriptor D-Descriptor ค่าเฉลี่ยระดับสีเทาภายในวัตถุ และค่าความแตกต่างระหว่างค่าเฉลี่ยระดับสีเทาภายในวัตถุกับค่าเฉลี่ยระดับสีเทาภายนอกวัตถุ นำไปทำการจัดกลุ่มแบบวิธี PCM หลังจากการจัดกลุ่มข้อมูลแล้ว ตำแหน่งกลางของข้อมูลและค่าความเป็นสมาชิกแต่ละกลุ่มจะนำมาทำการคำนวณหาค่าพารามิเตอร์ของฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู เช่น ขอบเขตความไม่แน่นอนของฟังก์ชันหลัก จำนวนของตัวแปรทางภาษา เป็นต้น โดยงานวิจัยนี้จะเลือกฟังก์ชันสมาชิกประเภทสามเหลี่ยม และฟังก์ชันสมาชิกประเภทสี่เหลี่ยมคางหมู เมื่อได้ค่าพารามิเตอร์ที่เหมาะสมแล้ว จะนำฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู ไปใช้ในระบบอินเทอร์วัลไทป์ทูฟัซซีลอจิก ดังแสดงในรูปที่ 1.6



รูปที่ 1.6 ระบบอินเทอร์วัลไทป์ทูฟัซซีลอจิก

ในรูปที่ 1.6 แสดงถึงการทำงานของระบบอินเทอร์วัลไทป์ทูฟัซซีลอจิกมาประยุกต์ใช้สำหรับการตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม เริ่มจากอินพุต (Inputs) นำข้อมูลทดสอบ (Testing Dataset) ที่เป็นคุณลักษณะเด่นของภาพย่อยที่ต้องการตรวจจับก้อนหินปูนขนาดเล็ก ซึ่งจะเป็นค่าแบบคริสป์ (Crisp Values) นำมาทำให้เป็นรูปแบบฟัซซีโดยผ่านกระบวนการฟัซซิฟิเคชัน (Fuzzification) ค่าที่ได้นั้นขึ้นอยู่กับฟังก์ชันสมาชิกที่ถูกสร้างขึ้น หลังจากนั้นจะเข้าสู่ขั้นตอนการอนุมาน (Inference) โดยใช้รูปแบบฐานของกฎ (Rules-Based) ที่ถูกสร้างไว้ การอนุมานโดยใช้ฐานของกฎเรียกว่าระบบการอนุมานแบบฟัซซี (Fuzzy Inference System) ผลลัพธ์ที่ได้จะเป็นอินเทอร์วัลไทป์ทูฟัซซีเซต (Interval Type-2 Fuzzy Set) ขั้นตอนต่อไปเป็นกระบวนการลดไทป์ของเซต (Type-Reduction) เพื่ออยู่ในรูปแบบของฟัซซีไทป์วันเซต (Type-1

Fuzzy Set) และขั้นตอนสุดท้ายคือ การดีฟัซซิฟิเคชัน (Defuzzification) หรือเป็นการเปลี่ยนจากค่าที่เป็นฟัซซีให้เป็นค่าคริสป์ ผลลัพธ์ที่ได้หลังจากขั้นตอนนี้จะบ่งบอกถึงความเป็นก้อนหินปูนขนาดเล็กของภาพย่อยที่นำมาทดสอบ และสามารถตัดสินใจโดยค่าขีดแบ่ง (Thresholds) ว่ามีลักษณะเป็นก้อนหินปูนขนาดเล็กหรือไม่ หลังจากนั้นนำผลการทดสอบทั้งหมดไปหาอัตราความถูกต้อง (Correct Rate) และอัตราความผิดพลาด (Error Rate) ซึ่งพิจารณาโดยรังสีแพทย์

1.3 สรุปสาระสำคัญจากเอกสารที่เกี่ยวข้อง

1.3.1 การตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม

Cheng และคณะ [3] เสนอขั้นตอนวิธีที่ใช้ระบบการให้เหตุผลแบบฟัซซีตรวจจับความผิดปกติของภาพรังสีเต้านม ใช้ค่าของค่าระดับสีเทาและค่าอัตราส่วนระหว่างค่าความกว้างและความยาวของวัตถุในการหาก้อนหินปูน นำภาพมาผ่านกระบวนการฟัซซิฟิเคชัน (Fuzzification) โดยใช้ฟังก์ชันสมาชิกรูปแบบฟังก์ชันไพ สร้างฟังก์ชันโดยการกำหนดพารามิเตอร์โดยผู้เชี่ยวชาญและปรับให้เหมาะสม โดยวิธีนี้ต้องทำการเลือกบริเวณที่สนใจให้กับระบบและจำนวนของบริเวณที่สนใจให้กับระบบนั้นยังมีเพียง 75 บริเวณเท่านั้นมีค่าความถูกต้องของระบบเท่ากับร้อยละ 96 และมีค่าสัญญาณเตือนที่ผิดพลาดเท่ากับ 4 ต่อภาพ

Pandey และคณะ [4] สร้างระบบที่ใช้ตรวจจับก้อนหินปูนขนาดเล็กด้วยระบบการให้อนุมานแบบฟัซซี โดยค่าลักษณะเฉพาะที่แสดงความผิดปกติที่ใช้ในระบบการให้เหตุผลแบบฟัซซีนั้นใช้ค่าความสว่างของแต่ละจุดภาพ (Pixel) ค่าระยะห่างระหว่างจุดภาพ ค่าการเปลี่ยนแปลงของค่าความสว่างระหว่างจุดภาพ นำคุณลักษณะเด่นดังกล่าวมาสร้างเป็นฟังก์ชันสมาชิกโดยเลือกฟังก์ชันแบบ Gaussians กำหนดพารามิเตอร์ของฟังก์ชันจากข้อมูลที่เป็นก้อนหินปูนขนาดเล็กและไม่เป็นก้อนหินปูนขนาดเล็ก ทำให้ฟังก์ชันสมาชิกของแต่ละคุณลักษณะเด่นจะมีอย่างละ 2 ฟังก์ชันเท่านั้น จากนั้นใช้แบบจำลองแมมดानी (Mamdani) ได้ผลลัพธ์สุดท้ายเป็นค่าความน่าจะเป็นส่วนที่ผิดปกติ จากการทดลองพบว่ามีความถูกต้องเท่ากับร้อยละ 85 ที่ค่าสัญญาณเตือนที่ผิดพลาด (False Alarm) เท่ากับ 2.44 ต่อภาพ แต่ข้อจำกัดของงานวิจัยนี้คือต้องเลือกบริเวณที่สนใจ (Region of Interesting: ROI) เท่านั้น

Cheng และ Wang [5] เสนอวิธีตรวจจับความผิดปกติแบบก้อนหินปูนและก้อนทุมโดยใช้ทฤษฎีฟัซซีเซต (Fuzzy Set Theory) การปรับปรุงความแตกต่างในภาพด้วยฟัซซี (Fuzzy Contrast Enhancement) และสเกลสเปซ (Scale Space) โดยเริ่มจากการปรับปรุงภาพรังสีเต้านมเป็นภาพแบบฟัซซี (Fuzzified Image) สร้างฟังก์ชันสมาชิกแบบเอสฟังก์ชัน (S Function) ค่าพารามิเตอร์ของฟังก์ชันได้กำหนดขึ้นเองซึ่งเป็นค่าที่เหมาะสมแล้ว หลังจากนั้นจึงใช้วิธีสเกลสเปซและตัวกรอง

แบบลาปลาเซียนของเกาส์เซียน (Laplacian of a Gaussian Filter) ในการหาขนาดและตำแหน่ง วิธีการนี้มีความถูกต้องเท่ากับร้อยละ 97 โดยมีค่าความผิดพลาดแบบบวก (False Positive) เท่ากับ 3 ต่อภาพ เนื่องจากวิธีนี้จะต้องทำการปรับปรุงรูปมากกว่า 1 ครั้ง ทำให้ส่วนที่สำคัญของภาพบางส่วน อาจหายไป เพราะก้อนหินปูนนั้นมีขนาดเล็กมาก

Auephanwiriyaikul และคณะ [6] ได้พัฒนาระบบตรวจจับความผิดปกติของเต้านมที่ใช้ระบบการอนุมานแบบฟัซซี (Fuzzy Inference System) สำหรับตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม เป็นการสร้างไทป์วันฟังก์ชันสมาชิก โดยกำหนดพารามิเตอร์ของฟังก์ชันแบบสี่เหลี่ยม (Trapezoidal) และฟังก์ชันแบบสามเหลี่ยม (Triangular) ให้เหมาะสมกับชุดข้อมูลเรียนรู้ออกมาจะเลือกใช้แบบระบบแมมดานิ (Mamdani System) ผลการทดลองที่ได้มีความถูกต้องร้อยละ 78.07 ที่ค่าสัญญาณเตือนความผิดพลาดอยู่ที่ 20 ต่อภาพ ผลความถูกต้องขึ้นอยู่กับวิธีการเลือกฟังก์ชันสมาชิกที่ต้องกำหนดโดยผู้เชี่ยวชาญ

Thovutikul และคณะ [7] ได้เสนอวิธีการตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม โดยใช้ระบบอินเทอร์วัลไทป์ฟูฟัซซีลอจิก การสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ฟูฟัซซี โดยวิธีการกำหนดพารามิเตอร์ของฟังก์ชัน การระบุขอบเขตความไม่แน่นอน (FOU) ของฟังก์ชันสมาชิกจะพิจารณาตามลักษณะข้อมูลที่กระจายกันไปตามแต่ละคุณลักษณะเด่น ขั้นตอนแรกสร้างฟังก์ชันสมาชิกแบบไทป์วัน ให้ครอบคลุมคุณลักษณะเด่นในแต่ละช่วง และขั้นตอนที่สองทำการสร้างฟังก์ชันสมาชิกขอบเขตบน และฟังก์ชันสมาชิกขอบเขตล่าง โดยทำการเพิ่มขนาดฟังก์ชันในขั้นตอนแรกตามค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) เป็น UMF รวมทั้งลดขนาดฟังก์ชันเพื่อให้เป็น LMF ผลลัพธ์ที่ได้จากการทดลองในระบบอินเทอร์วัลไทป์ฟูฟัซซีลอจิก ได้อัตราความถูกต้องร้อยละ 90.36 ที่ค่าสัญญาณเตือนความผิดพลาดอยู่ที่ 4.73 ต่อภาพ ความถูกต้องขึ้นอยู่กับวิธีการปรับแต่งของฟังก์ชันสมาชิกที่นำมาใช้ และใช้ภาพรังสีเต้านมมาทดสอบจำนวน 11 ภาพ

Chitre และคณะ [8] พัฒนาระบบที่ใช้โครงข่ายประสาทเทียม (Neural Network) มาแยกแยะระหว่างกลุ่มเนื้องอกมีลักษณะเป็นรอยโรคที่ไม่อันตรายและกลุ่มเนื้องอกมีลักษณะเป็นรอยโรคที่มีอันตรายจากภาพรังสีเต้านมโดยใช้ภาพลักษณะฐานสอง (Binary Image) และลักษณะพื้นผิว (Texture) ผลการทดลองจากชุดข้อมูลเรียนรู้ (Training Data) มีความถูกต้องเพียงร้อยละ 60 เท่านั้น

Guliatto และคณะ [9] ได้เสนอระบบที่สามารถแยกเนื้องอก (Tumor) ในภาพรังสีเต้านมที่มีลักษณะความแตกต่างค่าระดับสีเทาไม่เด่นชัดและมีเส้นขอบไม่ชัดเจน โดยใช้การขยายบริเวณ (Region Growing) และใช้ฟังก์ชันค่าความเป็นสมาชิกแบบฟัซซี (Fuzzy Membership

Function) ในการเลือกจุดเริ่มต้น (Seed Point) นั้นให้ผลลัพธ์ที่ดีแต่ต้องปรับค่าพารามิเตอร์ (Parameter) และยังคงเลือกบริเวณที่สนใจ (Region of Interesting: ROI)

Wang และ Karayiannis [10] เสนอวิธีการตรวจจับก้อนหินปูนขนาดเล็กที่ใช้การแยกภาพย่อยด้วยความถี่จากการแปลงเวฟเลต (Wavelet-based Subband Image Decomposition) ในการแยกแยะความผิดปกติโดยอาศัยลักษณะของก้อนหินปูนขนาดเล็กที่มีขนาดเล็กและมีค่าความสว่างสูงเมื่อเปรียบเทียบกับจุดภาพข้างเคียง โดยบริเวณที่เป็นก้อนหินปูนจะมีค่าความถี่สูงในองค์ประกอบของส่วนประกอบแถบภาพ (Spectrum) และในการนำกลับมาสร้างใหม่จะใช้เพียงค่าความถี่สูงเท่านั้นซึ่งเป็นเรื่องที่ปัญหาคงงานวิจัยนี้คือ หลักในการเลือกคุณสมบัติของตัวกรองเวฟเลต (Wavelet Filter) สำหรับการแยกความถี่ ค่าความเปรียบต่าง (Contrast) ของความสว่างระหว่างบริเวณพื้นหลังและบริเวณเนื้อนม ความละเอียดของภาพรังสีด้านมที่คงไม่มีการเปลี่ยนแปลงค่าความละเอียด สุดท้ายคือสิ่งแปลกปลอมที่อยู่ในภาพรังสีด้านม

Tobias และคณะ [11] ได้ทำการเซกเมนต์ (Segmentation) แผ่นภาพรังสีด้านมในบริเวณที่สงสัยว่าจะเป็นก้อนหินปูน โดยแบ่งการทดลองออกเป็น 2 กลุ่มคือ กลุ่มที่อยู่ในการควบคุมและกลุ่มที่ไม่อยู่ในการควบคุม ทำการเลือกบริเวณที่สงสัยโดยมนุษย์จากนั้นจึงทำการทดลองว่าพื้นที่ที่สงสัยนั้นมีก้อนหินปูนหรือไม่ด้วยวิธีการจัดกลุ่มสมาชิกใกล้เคียงกัน (K-Nearest Neighbor) และฟัซซีซีมีน (Fuzzy C-Means) ซึ่งผลลัพธ์ที่ได้นั้นจะมีอัตราความผิดพลาดที่สูงมากเมื่อพิจารณาเฉพาะโดยใช้ความสว่างของระดับค่าสีเทาเพียงอย่างเดียว ในการวิเคราะห์ว่าเป็นก้อนหินปูนหรือไม่แต่ถ้าใช้ลักษณะอื่นรวมด้วยเช่น ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานก็จะทำให้อัตราความถูกต้องเพิ่มขึ้น

Riyahi-Alam และคณะ [12] สร้างระบบเซกเมนต์ส่วนที่เป็นก้อนหินปูนในภาพรังสีด้านม โดยเริ่มจากใช้เวฟเลต (Wavelet) เพื่อปรับปรุงส่วนที่มีความถี่สูงของรูป จากนั้นจึงใช้หลักการพิจารณากราฟแสดงค่าของสถิติความถี่แบบเวฟเลต (Wavelet Histogram) เพื่อนำไปสร้างลักษณะเฉพาะที่นำไปเป็นอินพุต (Input) ของฐานกฎฟัซซี (Fuzzy Rule Base) และทำการทดสอบโดยเอาลักษณะเฉพาะของค่าความสว่างค่าระดับสีเทาไปเป็นอินพุตของระบบฐานกฎฟัซซี ระบบนี้มี ความถูกต้องอยู่ที่ร้อยละ 87 โดยมีค่าความผิดพลาดแบบบวกเฉลี่ยอยู่ที่ 0.5 ต่อภาพ สำหรับวิธีนี้ได้ทดสอบกับภาพรังสีด้านมที่ปรากฏก้อนหินปูนอย่างเด่นชัดเท่านั้น

López-Aligué และคณะ [13] ได้เสนอวิธีตรวจจับก้อนหินปูนที่มีขนาดเล็ก โดยใช้วิธีโครงข่ายประสาทเทียมเพื่อเป็นการเลือกบริเวณที่น่าสนใจว่าจะมีความผิดปกติของมะเร็งด้านมแบบก้อนหินปูนที่สามารถทนต่อการแพร่กระจาย (Dispersion) การหมุน (Rotation) การเปลี่ยน



ขนาด (Scaling) การย้ายที่ (Displacement) และสัญญาณรบกวน ด้วยการทำให้เชิงโทโปโลยี (Topological) ก่อนที่จะเริ่มกระบวนการหลัก ทั้งนี้ความถูกต้องยังขึ้นอยู่กับวิธีการเลือกบริเวณที่สนใจ

Arodz และคณะ [14] สร้างระบบที่ใช้ในการตรวจจับกลุ่มของก้อนหินปูนโดยใช้ตัวกรอง 2 มิติ (2-D Filter) ตัวกรองโดยใช้มัธยฐาน (Median Filter) ซึ่งสามารถสร้างความแตกต่างของรูปที่ ทำให้เห็นส่วนที่มีความผิดปกติแบบก้อนหินปูน ได้ชัดเจน จากนั้นนำผลลัพธ์ที่ได้ไปปรับปรุงโดยใช้ขั้นตอนวิธีปรับปรุงด้วยเวฟเลต (Wavelet-Based Sharpening Algorithm) และใช้ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) ในการแบ่งแยกว่าเป็นก้อนทวมหรือไม่ เนื่องจากมีกระบวนการหลายขั้นตอนในการปรับปรุงรูปภาพ จึงอาจทำให้เกิดการสูญหายของข้อมูลได้ และยังคงเลือกบริเวณที่สนใจอีกด้วย

Juarez และคณะ [15] พัฒนาขั้นตอนวิธีสำหรับตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านมโดยใช้การแปลงเวฟเลตที่มีขั้นตอนดังนี้ เริ่มจากการทำรูปภาพรังสีเต้านมให้เป็นภาพแบบลบ (Negative Image) แล้วจึงนำไปผ่านเวฟเลตจากนั้นทำให้เป็นภาพลักษณะฐานสอง ของสัมประสิทธิ์ของส่วนการประมาณ (Approximation Coefficient) สุดท้ายนำภาพลักษณะฐานสองไประบุบริเวณที่มีก้อนหินปูนขนาดเล็กผลลัพธ์ที่ได้จากการทดลองเท่ากับร้อยละ 80 โดยไม่ได้มีการกล่าวถึงความผิดพลาดแบบบวกลบแต่อย่างใด ในงานวิจัยนี้ทำการทดลองกับฟังก์ชันเวฟเลตเพียง 4 ฟังก์ชัน ได้แก่ DB2 DB4 DB8 และ DB16 ซึ่งยังไม่มีหลักการในการเลือกใช้ฟังก์ชันเวฟเลตดังกล่าว

Bhattacharya และ Das [16] เสนอวิธีการเซกเมนต์ภาพรังสีเต้านม โดยระเบียบวิธีนี้ใช้คุณสมบัติความละเอียดหลากหลาย (Multiresolution Properties) ของเวฟเลตวิยุต (Discrete Wavelet Transform) เป็นวิธีการหลักและในการปรับปรุงภาพใช้ระเบียบวิธีรูปร่างลักษณะวิธีทอปเฮท (Morphological Tophat Algorithm) และใช้ฟัซซีมีนในการเซกเมนต์ โดยผลลัพธ์ที่ได้จากระเบียบวิธีนี้นำไปเปรียบเทียบกับวิธีการค่าขีดแบ่งครอบคลุม (Global Thresholding Method) ที่มีการปรับปรุงภาพด้วยรูปร่างลักษณะวิธีการกร่อนที่ช่วยลดค่าความผิดพลาดแบบบวกลบว่าการกำหนดขนาดของส่วนประกอบโครงสร้าง (Structuring Element) ต้องใช้ขนาดที่แตกต่างกันเมื่อใช้กับบริเวณที่สนใจที่ต่างกัน ระบบที่พัฒนานี้สามารถทำงาน ได้อัตโนมติและไม่ขึ้นกับค่าตัวแปร แต่ในงานวิจัยก็ไม่ได้บอกถึงผลความถูกต้องแต่อย่างใด

1.3.2 การสร้างฟังก์ชันสมาชิกของไทป์วัน

Liao และคณะ [24] ได้เสนอการสร้างฟังก์ชันสมาชิกด้วยการจัดกลุ่มข้อมูล FCM โดยนำค่าความเป็นสมาชิกหลังจากการแบ่งกลุ่มข้อมูล นำเอาตำแหน่งกลางของข้อมูลเป็นตำแหน่งค่าความเป็นสมาชิกของฟังก์ชันเท่ากับ 1



ทางด้านขวา ซึ่งในการทดลองได้สร้างฟังก์ชันรูปแบบ ฟังก์ชันสามเหลี่ยม และฟังก์ชัน π พารามิเตอร์ของฟังก์ชันได้กำหนดขึ้นเอง และให้การ Overlap ของแต่ละฟังก์ชันเป็น 0.5 การทดลองได้ทดลองกับข้อมูลจำนวน 600 tuples (ได้จากการหาคุณลักษณะเด่นของภาพถ่ายรังสี) เป็นการหาฟังก์ชันที่พอดี (Fit) กับค่าความเป็นสมาชิก แล้วหาความผิดพลาดแบบ Mean Square Error (MSE) หลังจากการทดลองประสิทธิภาพของฟังก์ชัน π มีค่า MSE ต่ำสุดอยู่ที่ 0.003 ในการกำหนดค่า m เท่ากับ 2 วิธีนี้เป็นการเริ่มต้นค่าพารามิเตอร์แบบสุ่ม (Random) แล้วนำมาเพิ่มค่าจนกว่าได้ค่าที่เหมาะสม ฟังก์ชันสมาชิกที่ได้จากการทดลองขึ้นอยู่กับค่าที่เพิ่มในแต่ละครั้งเท่านั้น

Chen และ Wang [25] เสนอการสร้างฟังก์ชันสมาชิกโดยวิธี FCM สำหรับงานวิจัยนี้ได้พิจารณาความเหมาะสมของจำนวน Cluster ว่าเท่าใดจึงจะเหมาะต่อการสร้างฟังก์ชันสมาชิกโดยเพิ่มจำนวนกลุ่ม แล้วหาอัตราการเปลี่ยนแปลง จำนวนกลุ่มที่ดีที่สุดก็คือจำนวนกลุ่มมีอัตราการเปลี่ยนแปลงน้อยที่สุด ฟังก์ชันเลือกสร้างเป็นแบบ Gaussians การเปลี่ยนแปลงจำนวนกลุ่มจะใช้วิธีการเปลี่ยนแปลงแบบ Equalized Universe Method (EUM), วิธี Subtractive Clustering Method (SCM) และวิธี Enhance FCM จากผลการทดลองกับข้อมูลที่จำลองมาแบบ 1 Dimensional และ 2 Dimensional ทำการหาความผิดพลาดแบบ Root Mean Square Error (RMSE) ผลลัพธ์เป็นจำนวน Epoch ที่ทำให้ค่า RMSE ลดลงต่ำที่สุด ซึ่งก็คือวิธีแบบ EFCM เนื่องจากการทดลองนี้ได้ใช้กับข้อมูลที่จำลองมาเท่านั้นประสิทธิภาพที่ได้จึงอยู่ในขีดจำกัด

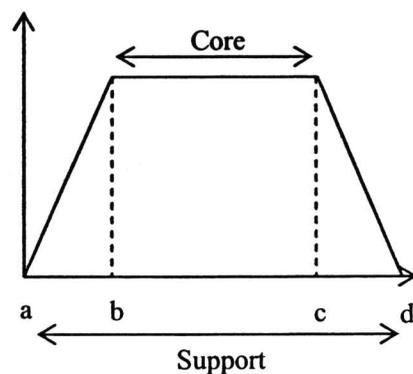
Chen และ Philip [26] ได้นำเสนอวิธีสร้างฟังก์ชันสมาชิกแบบ FCM โดยการนำเอาค่าความเป็นสมาชิกหลังจากการจัดกลุ่มแล้วมาสร้าง Shape ของฟังก์ชัน ในการทดลองได้ทำการสร้างฟังก์ชันแบบสามเหลี่ยมและฟังก์ชันแบบสี่เหลี่ยม ซึ่งเป็นปรับ Shape ให้พอดีกับค่าความเป็นสมาชิกนั่นเอง ซึ่งได้ทำการทดลองเปลี่ยนค่า m เป็น 1, 1.25, 1.5, 1.75 และ 2 ตามลำดับ ทำการจัดกลุ่มข้อมูลที่จำลองขึ้นจำนวน 168 tuples ซึ่งผลลัพธ์ที่ดีที่สุดอยู่ที่ค่า m เท่ากับ 2 สำหรับวิธีนี้ ฟังก์ชันสมาชิกที่ได้ขึ้นอยู่กับค่าพารามิเตอร์ของฟังก์ชัน เพื่อที่จะให้พอดีกับค่าความเป็นสมาชิก

Dou และคณะ [27] ได้เสนอวิธีการสร้างฟังก์ชันสมาชิกโดยนำค่าจากการสร้าง Histogram โดยเริ่มจากนำภาพ MRI ตรงบริเวณที่สนใจ (ROI) หลังจากนั้นนำจำนวนทั้งหมดมาสร้างเป็น Histogram แล้วให้ Histogram ที่ได้แทนเป็นฟังก์ชันสมาชิก การอ่านค่าความเป็นสมาชิกจะใช้วิธี Interpolation ในงานวิจัยนี้ได้นำมาประยุกต์ฟังก์ชันสมาชิกที่ได้เป็นฟังก์ชันของคุณลักษณะเด่นของภาพ MRI หรือเป็นการทำ Feature Extraction ด้วยฟังก์ชันสมาชิก ในการทดลองได้นำภาพ MRI ที่ลักษณะใกล้เคียงกันมาทดสอบหาค่าคุณลักษณะเด่น แล้วเปรียบเทียบว่ามีความแตกต่างกัน

อย่างไรผลลัพธ์ที่ได้อยู่ที่อัตราการเรียนรู้เปลี่ยนแปลงเฉลี่ย 1.41 เปอร์เซ็นต์ สำหรับวิธีนี้มีข้อเสียคือการสร้าง Histogram จำนวนข้อมูลความละเอียดของภาพเท่านั้น

Liang และคณะ [28] ได้เสนอวิธีการสร้างฟังก์ชันสมาชิกโดยใช้โครงข่ายประสาทเทียม ซึ่งสามารถสร้างฟังก์ชันที่มีลักษณะตัวแปรทางภาษา (Linguistic Variables) ได้หลายระดับ โดยการสร้างของโครงข่ายประสาทเทียม พิจารณาค่าฟังก์ชันสมาชิก จะเลือกพิจารณาที่ชั้นอินพุต มีการเรียนรู้จนได้ค่าความเป็นสมาชิก หรือ u (แทนค่า w) ทำให้น้ำหนักในชั้นซ่อน (Hidden Layer) ได้ค่าผลลัพธ์ที่ทำให้ชั้นเอาต์พุตมีความผิดพลาดน้อยที่สุด ซึ่งในชั้นซ่อนนี้จำนวนโหนดจะแทนด้วยจำนวนของกฎของการอนุมานแบบฟัซซีซึ่งจะต้องกำหนดไว้ก่อน ในการทดลองได้สร้าง Training Samples ด้วยการ Random ผลความถูกต้องอยู่ที่ 93 เปอร์เซ็นต์ สำหรับฟังก์ชันสมาชิกที่ได้จากวิธีนี้ขึ้นอยู่กับข้อกำหนดฟังก์ชันที่ชั้นอินพุตซึ่งในงานวิจัยนี้เลือกฟังก์ชันแบบ π

Derbel และ Hachani [29] งานวิจัยนี้ได้เสนออัลกอริทึมในการปรับค่าพารามิเตอร์ สำหรับการสร้างฟังก์ชันสมาชิก โดยเสนอขั้นตอนการสร้าง 3 ขั้นตอนคือ ขั้นตอนแรกทำการเลือกรูปปร่างของฟังก์ชันสมาชิก (เช่น สามเหลี่ยม (Triangular) หรือ สี่เหลี่ยมคางหมู (Trapezoidal) เพื่อจัดเตรียมพารามิเตอร์ หลังจากนั้นทำการจัดกลุ่มข้อมูลโดยกำหนด จำนวนกลุ่มข้อมูลให้เหมาะสม ขั้นตอนที่สองทำการแยกชุดข้อมูลออกเป็นกลุ่ม (Determination of Membership Function Number) ตามกลุ่ม ในขั้นตอนแรกจะใช้ระยะทางเป็นตัวตัดสินว่าจะเป็นสมาชิกของกลุ่มข้อมูลใด ขั้นตอนสุดท้ายเป็นการกำหนดค่าพารามิเตอร์ของฟังก์ชัน (Identification of Membership Functions Parameters) ขั้นตอนนี้จะเป็นการปรับแต่งค่าพารามิเตอร์ของฟังก์ชันคือ Core และ Support หลังจากนั้นทำการคำนวณหาตำแหน่ง a , b , c และ d ที่เหมาะสม ในงานวิจัยได้ทดสอบกับข้อมูล Census Income DB และ Thyroid แล้ววิเคราะห์ถึงฟังก์ชันสมาชิกที่ได้แต่ไม่ระบบผลการคัดแยก สำหรับวิธีนี้ขึ้นอยู่กับข้อกำหนดตำแหน่งของ a , b , c และ d ซึ่งยังไม่เป็นแบบอัตโนมัติ

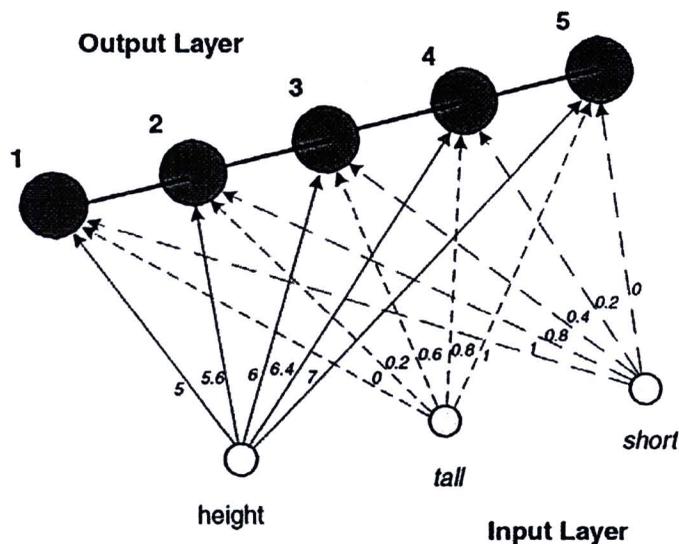


รูปที่ 1.7 พารามิเตอร์สำหรับฟังก์ชันสมาชิกแบบสี่เหลี่ยม

Zhou และ Khotanzad [30] เสนอการสร้างฟังก์ชันสมาชิกโดยวิธีขั้นตอนเชิงพันธุกรรม (Genetic Algorithms) เป็นการกำหนดค่าพารามิเตอร์เริ่มต้นของฟังก์ชันสมาชิก ในแต่ละรอบจะมีการวัด (Measure) ประสิทธิภาพกับชุดข้อมูลเรียนรู้โดยกฎที่กำหนดไว้ หลังจากนั้นก็ปรับแต่งค่าพารามิเตอร์ของฟังก์ชันสมาชิกด้วยวิธี GA จนกว่าได้ค่าที่เหมาะสมที่สุด พารามิเตอร์ที่ใช้เป็นฟังก์ชันแบบ Gaussians ทดลองกับข้อมูล Wine Database ได้ผลการคัดแยกด้วยความถูกต้อง 93.5 เปอร์เซ็นต์ โดยการสร้างฟังก์ชันสมาชิกโดยใช้ขั้นตอนเชิงพันธุกรรมนี้จำเป็นจะต้องใช้เวลามากกว่าวิธีอื่น

Shinn-Ying และคณะ [31] ได้นำวิธีการของอัลกอริทึมเชิงพันธุกรรม (Genetic Algorithm: GA) มาทำการคำนวณหาค่าพารามิเตอร์ของฟังก์ชันสมาชิกแบบสี่เหลี่ยม เพื่อให้ได้ค่าที่เหมาะสมที่สุด สำหรับชุดข้อมูลเรียนรู้ โดยกำหนดพารามิเตอร์สำหรับอัลกอริทึมเชิงพันธุกรรมใช้ค่า V มีค่าอยู่ระหว่าง 0 ถึง 1 แทน Parametric Genes ซึ่งมีจำนวนทั้งหมด 5 Genes ตามสมการของการสร้างฟังก์ชันสมาชิก ผลการทดลองได้ทำการนำไปทดสอบกับชุดข้อมูล Iris มีผลลัพธ์ความถูกต้องเฉลี่ยอยู่ที่ 97.73% สำหรับวิธีนี้จะใช้เวลาในการสร้างฟังก์ชันสมาชิกมากกว่าวิธีอื่น

Chih-Chung และ Bose [32] เสนอวิธีการสร้างฟังก์ชันสมาชิกโดยวิธีการ Self Organizing Feature Map (SOFM) จากชุดข้อมูลเรียนรู้ กำหนดจำนวนมิติของคุณลักษณะเด่น (Feature Dimension) และจำนวนโหนดทั้งหมดของชั้นเอาต์พุต จากสมการของ SORM จะเป็นการหาโหนดที่เป็นผู้ชนะ (Winner Node) เพื่อที่จะทำการปรับปรุ้งค่าน้ำหนักของโหนดเพื่อนบ้าน (Neighborhood Node) หลังจากนั้นจึงทำการปรับเปลี่ยนตัวชุดข้อมูลเพื่อที่จะได้ผลลัพธ์จากค่าน้ำหนักของ SORM มาเป็นค่าฟังก์ชันสมาชิก โดยจะพิจารณาสองขั้นตอนคือ ขั้นตอนแรกจัดคุณลักษณะเด่นใหม่โดยการเพิ่มเวกเตอร์ผลลัพธ์ (Output Vector) ฟังก์ชันสมาชิกเข้าไปเพื่อนำไปเรียนรู้โดยการปรับปรุ้งค่าน้ำหนัก ขั้นตอนที่สองปรับค่าน้ำหนัก (Weight) ให้สัมพันธ์กับขั้นตอนแรก หลังจากนั้นทำการเรียนรู้เพื่อให้ SOFM สร้างน้ำหนักของแต่ละโหนดในโครงข่ายให้ได้เป็นค่าของฟังก์ชันสมาชิก การทดลองในงานวิจัยนี้ได้นำมาเปรียบเทียบกับการสร้างฟังก์ชันสมาชิกโดยวิธี FCM และประสิทธิภาพฟังก์ชันสมาชิกวิธีนี้ขึ้นอยู่กับข้อกำหนดประเภทคลาสของชุดข้อมูลเรียนรู้เท่านั้น หากกำหนดประเภทคลาสผิดพลาดก็ผิดพลาดเช่นกัน



รูปที่ 1.8 การใช้ SOFM ทำการสร้างฟังก์ชันสมาชิก

1.3.3 การสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู

Woei-Wan และคณะ [33] เสนอวิธีการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู (Interval Type-2 Membership Function) โดยใช้วิธีการสร้างขอบเขตความไม่แน่นอน (FOU) เสนอขั้นตอนสร้างดังนี้คือ สร้างฟังก์ชันสมาชิกขอบเขตบน (Upper Membership Function: UMF) โดยวิธีการจัดกลุ่มแบบฟัซซีซีมีน (Fuzzy C-Means) ใช้ค่า m เป็นพารามิเตอร์มีค่าเท่ากับ 2 และจำนวนกลุ่มข้อมูลที่น่ามาจัดกลุ่มจะเลือก 3 กลุ่ม ขั้นตอนการสร้างฟังก์ชันสมาชิกขอบเขตล่าง (Lower Membership Function: LMF) ทำได้โดยการหาค่าระยะทางรวมของสมาชิกข้อมูลแต่ละกลุ่มกับค่าศูนย์กลางของแต่ละกลุ่มเป็นการวัดระยะทางแบบ Euclidean Distance หลังจากนั้นค่าระยะทางของแต่ละกลุ่มข้อมูลนำมา نرمอลไลซ์ (Normalize) ให้ระยะทางเป็นค่าผลรวมมีค่าเท่ากับ 1 เพื่อที่จะแบ่งฟังก์ชันขอบเขตล่าง ของแต่ละกลุ่มข้อมูลนั้นเป็นระยะห่างจากฟังก์ชันขอบเขตบน และมีการคำนวณหาค่าขอบเขตทางด้านซ้ายและขอบเขตทางด้านขวาของแต่ละกลุ่มข้อมูล กล่าวได้ว่าหนึ่งกลุ่มข้อมูลสามารถแทนด้วยหนึ่งฟังก์ชันสมาชิก ในงานวิจัยนี้ได้นำไปใช้กับข้อมูลของ MIT Arrhythmia Database ได้ผลลัพธ์ความถูกต้องเฉลี่ย 91.64 เปอร์เซ็นต์ ฟังก์ชันสมาชิกที่ได้จากงานวิจัยนี้ขึ้นอยู่กับจำนวนสมาชิกที่อยู่ในแต่ละกลุ่ม ทำให้บริเวณ FOU จะมีพื้นที่ตามจำนวนข้อมูลเรียนรู้เท่านั้น

Byung-In และคณะ [34] ได้เสนอวิธีการสร้าง FOU ของอินเทอร์วัลไทป์ทูฟังก์ชันสมาชิก โดยวิธีการจัดกลุ่มแบบ Interval Type-2 Fuzzy C-Means Algorithm สำหรับการจัดกลุ่มแบบวิธีนี้จะคล้ายกับวิธีการของอัลกอริทึม Fuzzy C-Means เพียงแต่จะต้องเลือกค่า m จำนวน 2 ค่าเพื่อจะได้ค่าความเป็นสมาชิกของแต่ละกลุ่มเป็นฟังก์ชันขอบเขตบน (UMF) และฟังก์ชันขอบเขตล่าง (LMF)

หลังจากได้ค่าศูนย์กลางของแต่ละกลุ่มข้อมูล ลำดับต่อไปจะเป็นการหาค่าความเป็นสมาชิกของแต่ละคุณลักษณะได้ โดยใช้ค่า m ทั้งสองค่าที่เลือกแล้วนำมาสร้าง FOU จากสมการลักษณะเดียวกัน เพียงแต่พิจารณาแต่ละคุณลักษณะเด่นเท่านั้น และข้อเสียคือ ฟังก์ชันสมาชิกที่ได้ขึ้นอยู่กับสมการที่นำมาใช้เท่านั้น

Rhee และ Byung-In [35] ได้เสนอวิธีการสร้างอินเทอร์วัลไทป์ฟูฟังก์ชันสมาชิก โดยทำการพิจารณาจากค่าของภาพแท่งความถี่ (Histogram) ของแต่ละคุณลักษณะเด่นเพื่อสังเกตว่ามีค่าความถี่ตำแหน่งไหนที่สูงสุด และมีจำนวนระดับความถี่ที่สูงอยู่จำนวนเท่าไร เพื่อนำมาสร้างขอบเขตความไม่แน่นอน (FOU) ของฟังก์ชันสมาชิก ซึ่งได้เสนอขั้นตอนไว้ 5 ขั้นตอนคือ ขั้นตอนแรกทำการสร้างภาพแท่งความถี่ พร้อมกับทำการราบเรียบ (Smooth) จากชุดข้อมูล ขั้นตอนที่สองทำการปรับพอดีของฟังก์ชัน (Function Fitting) โดยเลือกใช้ฟังก์ชันพหุนาม (Polynomial Function) เพื่อให้ทราบถึงพารามิเตอร์ เช่น จำนวนของฟังก์ชัน ตำแหน่งของค่าฟังก์ชัน และความสูงของฟังก์ชัน ที่พอดีกับฟังก์ชันพหุนาม ปรับให้พอดีโดยใช้ค่า Least Square Error เป็นตัวเลือกค่าความผิดพลาดของการเลือกค่าดีกรี (Degree) ขั้นตอนที่สามทำการปรับพอดีฟังก์ชันโดยใช้ ปรับพอดีโดยฟังก์ชันเกาส์เซียน (Gaussian Function Fitting) ทำคล้ายกับข้อที่สองเพียงแต่เลือกฟังก์ชันสมาชิกแบบเกาส์เซียน ทำการปรับพอดีให้ได้ค่าความผิดพลาดน้อยที่สุดให้ครบจำนวนของฟังก์ชันที่หาได้ ทำการสร้างฟังก์ชันสมาชิกขอบเขตบน และฟังก์ชันสมาชิกขอบเขตล่าง ขั้นตอนที่สุดท้ายทำการนอมอลไลซ์ฟังก์ชัน (Normalize Function) สมาชิกขอบเขตบน และฟังก์ชันสมาชิกขอบเขตล่างให้มีค่าฟังก์ชันอยู่ระหว่าง 0 ถึง 1 ได้ทำการทดลองกับข้อมูล T-Shape ผลความถูกต้องอยู่ที่ 89.55 เปอร์เซ็นต์ ข้อจำกัดของวิธีนี้คือ ชุดข้อมูลที่นำมาสร้างฟังก์ชันสมาชิกจะต้องมีจำนวนมากพอต่อการสร้างภาพแท่งความถี่รวมถึงการกำหนดช่วงของภาพแท่งความถี่ด้วย

Chua และ Woei-Wan [36] เสนอวิธีการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ฟู เพื่อนำมาประยุกต์ใช้ในการคัดแยกสัญญาณคลื่นไฟฟ้าหัวใจ (ECG Arrhythmic Classification) เลือกรูปร่างของฟังก์ชันแบบเกาส์เซียน (Gaussian Shape) สำหรับวิธีการสร้างขอบเขตความไม่แน่นอน (FOU) ใช้อัลกอริทึมเชิงพันธุกรรม โดยเสนอขั้นตอนไว้ 4 ขั้นตอน ขั้นตอนที่หนึ่งกำหนดจำนวนกฎของระบบฟัซซีให้เหมาะสมกับชุดข้อมูลที่นำมาสร้าง ขั้นตอนที่สองสร้างไทป์วันฟังก์ชันสมาชิกอ้างอิงจากชุดข้อมูลเดิม ขั้นตอนที่สามสร้างขอบเขตความไม่แน่นอน (FOU) โดยพิจารณาจากพารามิเตอร์ของฟังก์ชันเกาส์เซียน และขั้นตอนที่สุดท้ายทำการปรับขอบเขตความไม่แน่นอนโดยใช้ อัลกอริทึมเชิงพันธุกรรม ได้ทดลองกับข้อมูล MIT Arrhythmia Database ได้ผลลัพธ์ความถูกต้องเฉลี่ยอยู่ที่ 89.93 เปอร์เซ็นต์ สำหรับวิธีนี้จะมีข้อเสียคือใช้เวลาในการประมวลผลมากกว่าวิธีอื่น

1.4 วัตถุประสงค์ของการวิจัย

1.4.1 เพื่อพัฒนาระบบตรวจจับก่อนหिनปูนขนาดเล็กในภาพรังสีเต้านมโดยใช้ระบบอินเทอร์วัลไทป์ทิวซ์ซีลอกจิก โดยที่ระบบสามารถสร้างฟังก์ชันสมาชิกแบบอัตโนมัติจากการจัดกลุ่มด้วย PCM

1.4.2 เพื่อพัฒนาโปรแกรมคอมพิวเตอร์ ที่มีความสามารถในการตรวจจับก่อนหिनปูนขนาดเล็กในภาพรังสีเต้านม

1.5 ประโยชน์ที่ได้จากการวิจัย เจริญทฤษฎีหรือเชิงประยุกต์

1.5.1 ได้ระบบตรวจจับก่อนหिनปูนขนาดเล็กในภาพรังสีเต้านมโดยใช้ระบบอินเทอร์วัลไทป์ทิวซ์ซีลอกจิกที่มีความสามารถในการสร้างฟังก์ชันสมาชิกแบบอัตโนมัติด้วย PCM

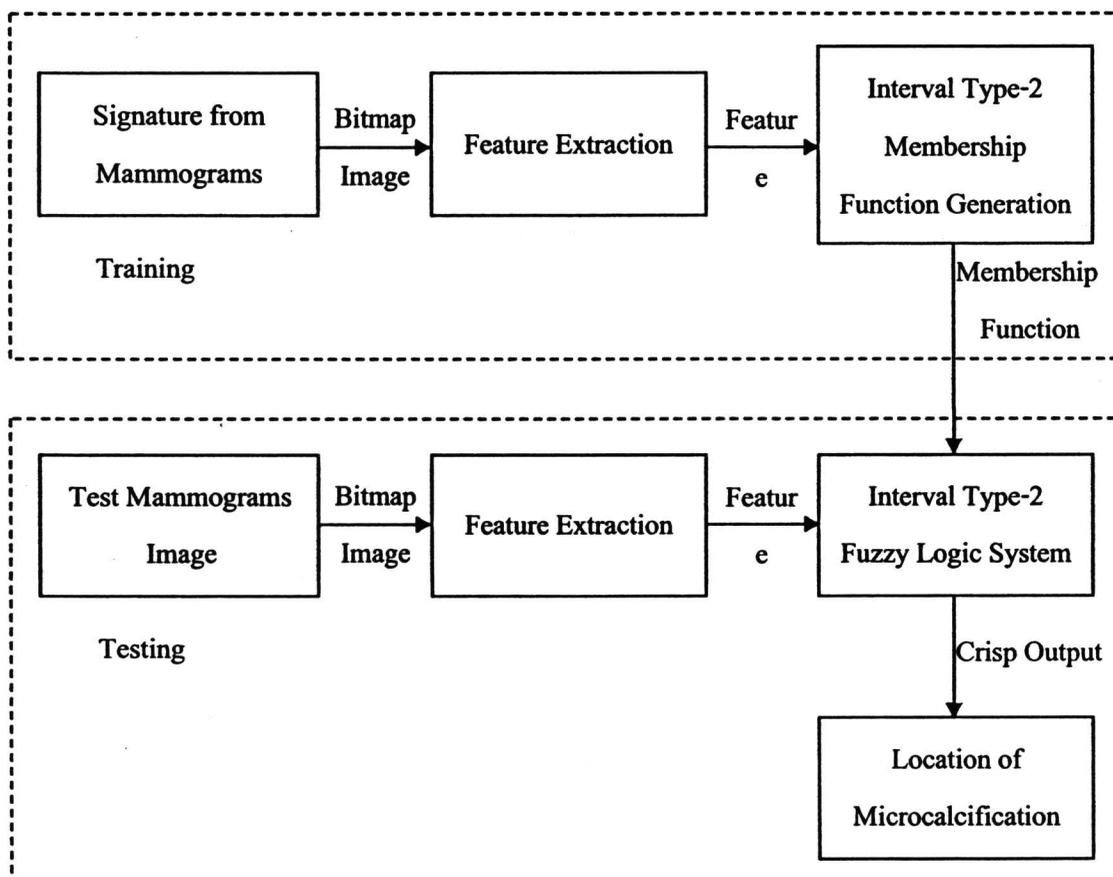
1.5.2 ได้โปรแกรมคอมพิวเตอร์ที่มีความสามารถในการตรวจจับก่อนหिनปูนขนาดเล็กในภาพรังสีเต้านม

1.6 แผนการดำเนินการ ขอบเขต และวิธีการทำวิจัย

แผนการดำเนินการเริ่มจาก ศึกษาวิธีการสร้างฟังก์ชันสมาชิกด้วยวิธีการจัดกลุ่มข้อมูลของชุดข้อมูลเรียนรู้ ทั้งฟังก์ชันสมาชิกของไทป์วันและฟังก์ชันสมาชิกของไทป์ทิวซ์ และศึกษาวิธีการจัดกลุ่มข้อมูลด้วยพอสซิбилиลิสติกซีมีนส์ (Possibilistic C-Means: PCM) โดยจะทำการจัดกลุ่มที่ละคุณลักษณะเด่นซึ่งในการทดลองจะทำการกำหนดค่าเริ่มต้นพารามิเตอร์ในการจัดกลุ่ม เช่น จำนวนกลุ่ม ค่าความเป็นฟัซซี และค่าขีดแบ่งที่ใช้ในการกำจัดข้อมูลรบกวน การเริ่มต้นค่าพารามิเตอร์ดังกล่าวจะทำการเปลี่ยนแปลงค่าใหม่เพื่อที่จะได้ค่าที่เหมาะสมที่สุด

เมื่อได้ค่าพารามิเตอร์ที่เหมาะสมแล้วจะนำผลลัพธ์จากการจัดกลุ่มด้วยวิธี PCM ซึ่งจะมีค่าตำแหน่งกลางและค่าความเป็นสมาชิกของแต่ละกลุ่ม หลังจากนั้นจะนำค่าดังกล่าวมาสร้างเป็นฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทิวซ์ โดยการสร้างจะทำการหาขอบเขตความไม่แน่นอนประกอบด้วยฟังก์ชันขอบเขตบนและฟังก์ชันขอบเขตล่าง รูปแบบฟังก์ชันสมาชิกที่สร้างจะเป็นแบบสามเหลี่ยม (Triangular Function) และฟังก์ชันแบบสี่เหลี่ยม (Trapezoidal Function)

การออกแบบและพัฒนาระบบตรวจจับก่อนหिनปูนขนาดเล็กในภาพรังสีเต้านมโดยใช้ระบบอินเทอร์วัลไทป์ทิวซ์ซีลอกจิกที่มีความสามารถในการสร้างฟังก์ชันสมาชิกแบบอัตโนมัติด้วย PCM สามารถแสดงออกมาเป็นแผนภาพการทำงานโดยแยกออกเป็น 2 ส่วนคือ ส่วนแรก กระบวนการเรียนรู้ (Training Process) และส่วนที่สองกระบวนการทดสอบ (Testing Process) ตามแผนภาพแสดงในรูปที่ 1.9



รูปที่ 1.9 การทำงานของการตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม

จากรูปที่ 1.9 แสดงการทำงานของระบบที่พัฒนา ในส่วนแรกเป็นกระบวนการเรียนรู้จะนำภาพบิตแมพ (Bitmap Images) ขนาดเล็กที่ตัดมาจากภาพรังสีเต้านม โดยเลือกออกมาแยกเป็น 2 กลุ่มด้วยกัน กลุ่มแรกคือภาพที่มีลักษณะของก้อนหินปูนขนาดเล็กรูปแบบต่าง ๆ และกลุ่มที่สองคือภาพที่มีลักษณะปกติหรือภาพที่ไม่ใช่ลักษณะของกลุ่มที่เป็นก้อนหินปูนขนาดเล็ก โดยขนาดของภาพทั้งสองกลุ่มจะมีขนาดเท่ากันทั้งหมด เพื่อนำมาเข้าสู่กระบวนการแยกหาคุณลักษณะเด่น (Feature Extraction) สำหรับในงานวิจัยนี้จะเลือกการหาคุณลักษณะเด่นของภาพ 4 คุณลักษณะเด่น [6, 7] คือ ค่าเฉลี่ย B-Descriptor, ค่าเฉลี่ย D-Descriptor, ค่าเฉลี่ยระดับสีเทา (Intensity) ภายในวัตถุ และค่าความแตกต่างระหว่างค่าเฉลี่ยระดับสีเทาภายในวัตถุกับค่าเฉลี่ยระดับสีเทาภายนอกวัตถุ หลังจากหาคุณลักษณะเด่นจะได้เป็นเวกเตอร์คุณลักษณะเด่น (Feature Vectors) ของทุก ๆ ภาพทั้งหมดรวมกันจะเป็นชุดข้อมูลเรียนรู้ (Training Dataset) หลังจากนั้นจะนำไปสู่กระบวนการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทู (Interval Type-2 Membership Function Generation) ดังที่กล่าวมาแล้วในข้างต้น

ส่วนที่สองกระบวนการทดสอบ (Testing Process) จะนำภาพรังสีเต้านมที่ต้องการมาทดสอบเข้าสู่กระบวนการหาคุณลักษณะเด่นเหมือนกับขั้นตอนในส่วนแรก ภาพขนาดเล็กจะได้รับการเก็บภาพขนาดเล็กจากภาพที่ต้องการนำมาทดสอบ ซึ่งจะเริ่มเก็บภาพจากซ้ายไปขวา และบนลงล่าง ในการเก็บภาพแต่ละครั้งจะได้เวกเตอร์คุณลักษณะเด่น (Feature Vector) หลังจากนั้นจึงเข้าสู่ขั้นตอนของระบบอินเทอร์วัลไทป์ทิวพีซซีลอจิก ขั้นตอนนี้จะทำการตัดสินใจว่าภาพที่เข้ามาทำการทดสอบนี้มีความเป็นก้อนหินปูนขนาดเล็กแบบพีซซีเท่าใด ขั้นตอนต่อไปจึงนำค่าที่ได้ไปเลือกว่าจะเป็นก้อนหินปูนขนาดเล็กหรือไม่เป็น ถ้าหากเป็นก้อนหินปูนขนาดเล็กก็แสดงว่าตำแหน่งภาพที่นำมาทดสอบนี้ถูกตรวจจับได้

1.7 แผนดำเนินการวิจัย

- 1.7.1 ศึกษาเก็บรวบรวมข้อมูลปัญหาของการสร้างฟังก์ชันสมาชิก และปัญหาของการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทิวพีซซีลอจิก
- 1.7.2 ศึกษาทฤษฎีที่เกี่ยวข้องกับการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทิวพีซซีลอจิก
- 1.7.3 เก็บรวบรวมข้อมูล ข้อมูลมาตรฐาน และข้อมูลภาพรังสีเต้านม แยกคุณลักษณะเด่นโดยพิจารณาจากรังสีแพทย์
- 1.7.4 สรุปผลที่ได้เปรียบเทียบกับรังสีแพทย์พร้อมปรับแต่งระบบ

1.8 ขอบเขตการวิจัย

- 1.8.1 ระบบที่พัฒนาเป็นการสร้างฟังก์ชันสมาชิกของอินเทอร์วัลไทป์ทิวพีซซีลอจิกแบบอัตโนมัติด้วย PCM นำไปใช้ในระบบอินเทอร์วัลไทป์ทิวพีซซีลอจิก และนำมาประยุกต์ตรวจจับก้อนหินปูนขนาดเล็กในภาพรังสีเต้านม
- 1.8.2 โปรแกรมที่พัฒนาสามารถตรวจจับความผิดปกติที่เป็นก้อนหินปูนขนาดเล็กไม่เกินหน้าต่าย่อยความกว้าง 50 จุดภาพ และความสูง 50 จุดภาพ บนภาพรังสีเต้านม
- 1.8.3 ภาพที่นำมาใช้เป็นภาพดิจิทัลความละเอียดตั้งแต่ 300 จุดภาพต่อนิ้ว (Dots Per Inch) ขึ้นไปและเป็นภาพระดับสีเทา (Gray Level)
- 1.8.4 อินพุตของโปรแกรมเป็นภาพรังสีเต้านมที่ได้จากโรงพยาบาลมหาราชนครเชียงใหม่ อำเภอเมือง จังหวัดเชียงใหม่ ที่ต้องการตรวจจับก้อนหินปูนขนาดเล็ก และเอาต์พุตของโปรแกรมเป็นตำแหน่งที่ระบุถึงความผิดปกติของก้อนหินปูนขนาดเล็ก เปรียบเทียบความถูกต้องกับการวินิจฉัยของรังสีแพทย์

1.9 วิธีการวิจัย

- 1.9.1 ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้องกับการสร้างฟังก์ชันสมาชิก ระบบอนุมานแบบฟัซซี การสร้างฟังก์ชันสมาชิกของอินเทอร์เน็ตวัดไต้ปู้ และระบบอินเทอร์เน็ตวัดไต้ปู้ฟัซซีลอจิก
- 1.9.2 ศึกษาข้อมูลกลุ่มข้อมูล เก็บรวบรวมลักษณะเด่นของภาพรังสีเต้านม จากกลุ่มข้อมูล มาตรฐาน เพื่อนำมาแยกหาลักษณะเด่น
- 1.9.3 ออกแบบและทดลองวิธีการสร้างฟังก์ชันสมาชิกของอินเทอร์เน็ตวัดไต้ปู้ โดยวิธีการจัดกลุ่มของคุณลักษณะเด่นแบบ PCM แล้วนำมาใช้กับระบบอินเทอร์เน็ตวัดไต้ปู้ฟัซซีลอจิก
- 1.9.4 ออกแบบและพัฒนาระบบ อินเทอร์เน็ตวัดไต้ปู้ฟัซซีลอจิก
- 1.9.5 ปรับปรุงแก้ไข และทดสอบระบบโดยเปรียบเทียบผลการทดลองกับผู้เชี่ยวชาญ
- 1.9.6 วิเคราะห์ และสรุปผลการทดลอง
- 1.9.7 จัดทำวิทยานิพนธ์ฉบับสมบูรณ์

1.10 สถานที่ทำการวิจัย

ห้องวิจัยความฉลาดทางการคำนวณ (Computational Intelligence Research Laboratory)
ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่

1.11 ระยะเวลาดำเนินงานวิจัย

สำหรับเวลาที่ใช้ในการทำวิจัยจะใช้ทั้งหมด 8 เดือน รายละเอียดแสดงในตารางที่ 1.4

ตารางที่ 1.4 ระยะเวลาในการทำวิจัย

การดำเนินการ	ระยะเวลา (เดือนที่)							
	1	2	3	4	5	6	7	8
1. ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง	←→							
2. ศึกษารวบรวมลักษณะเด่นของภาพรังสีเต้านม		←→						
3. สร้างฟังก์ชันสมาชิกของอินเทอร์เน็ตวัดไต้ปู้			←→					
4. ออกแบบและพัฒนาระบบ				←→				
5. ปรับปรุงแก้ไข และทดสอบระบบ				←→				
6. วิเคราะห์ และสรุปผลการทดลอง					←→			
7. จัดทำวิทยานิพนธ์ฉบับสมบูรณ์							←→	