

การปรับปรุงฮาอูสดอร์ฟ อาร์ทแมปสำหรับการรู้จำรูปภาพแบบไบนารี

MODIFIED HAUSDORFF ARTMAP FOR BINARY IMAGE RECOGNITION

ทรงพล รุ่งสุข
SONGPOL RUENSUK

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาระดับปริญญาตรี สาขาวิชาวิศวกรรมคอมพิวเตอร์

สาขาวิชาเทคโนโลยีสารสนเทศ

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2549

ISBN 974-15-2310-6

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

การปรับปรุงฮาอุดอร์ฟ อาร์ทแมพสำหรับการรู้จำรูปภาพแบบไบนารี

MODIFIED HAUSDORFF ARTMAP FOR BINARY IMAGE RECOGNITION

ทรงพล รุ่งสุข

SONGPOL RUENSUK

เลขหมู่.....
เลขทะเบียน.....**63364**
วัน,เดือน,ปี.....**28 ส.ค. 2549**

.b.....
.i.....

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2549

ISBN 974-15-2310-6

MODIFIED HAUSDORFF ARTMAP FOR BINARY IMAGE RECOGNITION

SONGPOL RUENSUK

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF SCIENCE PROGRAM IN INFORMATION TECHNOLOGY
SCHOOL OF GRADUATE STUDIES
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

2006

ISBN 974-15-2310-6

COPYRIGHT 2006

SCHOOL OF GRADUATE STUDIES

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

หัวข้อวิทยานิพนธ์	การปรับปรุงฮาอูสคอร์ดฟ อาร์ทแมพสำหรับการรู้จำรูปภาพแบบไบนารี
นักศึกษา	นายทรงพล รื่นสุข
รหัสนักศึกษา	45066014
ปริญญา	วิทยาศาสตรมหาบัณฑิต
สาขาวิชา	เทคโนโลยีสารสนเทศ
พ.ศ.	2549
อาจารย์ผู้ควบคุมวิทยานิพนธ์	รศ.ดร. อาริต ธรรมโน

บทคัดย่อ

วิทยานิพนธ์ฉบับนี้เสนอวิธีการปรับปรุงฮาอูสคอร์ดฟ อาร์ทแมพสำหรับการรู้จำรูปภาพแบบไบนารี (Modified Hausdorff ARTMAP for Binary Image Recognition) ซึ่งวิธีการนี้พัฒนามาจากฮาอูสคอร์ดฟ อาร์ทแมพ (Hausdorff ARTMAP) เนื่องจากวิธีการเดิมมีการสร้างโหนดใน Cluster Layer จำนวนมาก และลำดับของอินพุตที่ส่งเข้าไปเรียนรู้มีผลต่อความถูกต้องของระบบ โดยวิธีการที่นำเสนอพัฒนาขึ้นมาเพื่อใช้ในการรู้จำภาพลายเส้น หรือภาพเส้นขอบ ซึ่งเป็นภาพแบบขาวดำ และเลือกใช้วิธีการวัดค่าความเหมือนแบบฮาอูสคอร์ดฟ ดิสเทนซ์ (Hausdorff Distance) เพื่อแทนกระบวนการการดึงคุณลักษณะพิเศษของภาพ ในวิทยานิพนธ์ฉบับนี้ใช้ข้อมูลภาพในการทดสอบทั้งหมดสามประเภท คือ ข้อมูลภาพใบหน้า ข้อมูลภาพลายนิ้วมือ และข้อมูลภาพลายเซ็น และในวิทยานิพนธ์ได้นำเสนอถึงวิธีการเตรียมข้อมูลภาพที่ใช้ พร้อมทั้งอธิบายวิธีการเรียนรู้ของวิธีการที่นำเสนอโดยละเอียด

Thesis Title	Modified Hausdorff ARTMAP for Binary Image Recognition
Student	Mr. Songpol Ruensuk
Student ID.	45066014
Degree	Master of Science
Programme	Information Technology
Year	2006
Thesis Advisor	Assoc. Prof. Dr. Arit Thamno

ABSTRACT

This paper present Modified Hausdorff ARTMAP for Binary Image Recognition. The proposed algorithm is developed to correct two problems that the original Hausdorff ARTMAP has : (1) the performance of Hausdorff ARTMAP depends directly on the order in which the training images are examined, (2) the time used for recognition the subject is long due to its large reference pattern size. The Hausdorff distance is used in this research to measure the similarity among the input images. The experimental results on four benchmark databases, two face databases, one fingerprint database and one signature database.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้เป็นอย่างดีด้วยคำแนะนำ คำปรึกษา และความอนุเคราะห์จาก รศ.ดร. อาริต ธรรมโน ซึ่งเป็นอาจารย์ผู้ควบคุมวิทยานิพนธ์ ด้วยอาจารย์เป็นผู้ที่ให้ความสนใจแรงผลักดัน ห่วงใย และติดตามความก้าวหน้าการทำวิทยานิพนธ์อย่างใกล้ชิด ตลอดจนให้คำปรึกษาคำแนะนำที่เป็นประโยชน์อย่างยิ่งในการทำวิทยานิพนธ์แก่ข้าพเจ้า ข้าพเจ้ารู้สึกซาบซึ้ง และขอขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณครู อาจารย์ทุกท่านที่ได้ประสิทธิ์ประสาทวิชา ความรู้ให้แก่ข้าพเจ้าตั้งแต่ออดีตจนถึงปัจจุบัน

ขอขอบคุณคุณคุณจงกลณี รุ่งเรืองที่ให้ความรู้ ความเข้าใจ และแนะนำวิธีการทำวิทยานิพนธ์ ขอขอบคุณเพื่อน พี่ และน้องๆ ในคณะเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังทุกคนที่ให้คำแนะนำต่างๆ และคอยให้กำลังใจเสมอมา

สุดท้ายนี้ข้าพเจ้าขอขอบพระคุณ บิดา มารดา และครอบครัวของข้าพเจ้าที่เป็นกำลังใจ และให้การสนับสนุนในทุกเรื่องๆ ทำให้ข้าพเจ้าสามารถทำวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดี คุณค่า และประโยชน์อันพึงมาจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบแด่ผู้มีพระคุณทุกท่าน

ทรงพล รื่นสุข

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป.....	VIII
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา.....	1
1.3 ขอบเขตการวิจัย.....	1
1.4 ขั้นตอนของการศึกษา.....	2
บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง.....	3
2.1 บทนำ.....	3
2.2 บทวิจัยที่เกี่ยวข้อง.....	4
2.2.1 An Approach to Word Image Matching Based on Weighted Hausdorff Distance.....	4
2.2.2 Unconstrained Handwritten Numeral Recognition Using Hausdorff Distance and Multi-Layer Neural Network Classifier.....	6
2.2.3 Training Algorithms for Robust Face Recognition using a Template-matching Approach.....	7
2.3 Simplified Fuzzy ARTMAP (SFAM).....	8
2.4 Hausdorff Distance.....	12
บทที่ 3 Modified Hausdorff ARTMAP for Binary Image Recognition.....	22
3.1 บทนำ.....	22
3.2 การเตรียมข้อมูล.....	22
3.2.1 การเตรียมข้อมูลภาพใบหน้า.....	22

สารบัญ (ต่อ)

หน้า

4.2.1.2 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล ORL ด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP	44
4.2.2 การทดลอง และผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล Yale	46
4.2.2.1 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล Yale ด้วย Modified Hausdorff ARTMAP	46
4.2.2.2 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล Yale ด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP	50
4.3 การทดลอง และผลการทดลองการรู้จำลายนิ้วมือ	51
4.3.1 ผลการทดลองการรู้จำลายนิ้วมือด้วย Modified Hausdorff ARTMAP	51
4.3.2 ผลการทดลองการรู้จำลายนิ้วมือด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP	54
4.4 การทดลอง และผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP	55
4.4.1 ผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP	55
4.4.2 ผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP	60
บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ	65
บรรณานุกรม	67
ภาคผนวก	69
ประวัติผู้เขียน	81

สารบัญตาราง

ตารางที่	หน้า
3.1 ตัวอย่างเวกเตอร์แสดงการเป็นสมาชิก	38
4.1 ตารางแสดงหมายเลขภาพไบหน้าที่ใช้ในการเรียนรู้.....	41
4.2 ผลการทดลองการรู้จำภาพไบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้.....	43
4.3 ผลการทดลองการรู้จำภาพไบหน้าฐานข้อมูล ORL.....	43
4.4 ตารางแสดงภาพไบหน้า และระยะทางของไบหน้าที่ตอบผิดกลุ่มของฐานข้อมูล ORL	45
4.5 ตารางแสดงประเภทภาพไบหน้าที่ใช้ในการเรียนรู้.....	48
4.6 ผลการทดลองการรู้จำภาพไบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้.....	49
4.7 ผลการทดลองการรู้จำภาพไบหน้าฐานข้อมูล Yale	49
4.8 ตารางแสดงภาพไบหน้า และระยะทางของไบหน้าที่ตอบผิดกลุ่มของฐานข้อมูล Yale	51
4.9 ตารางแสดงหมายเลขภาพลายนิ้วมือที่ใช้ในการเรียนรู้ และการทดสอบ	52
4.10 ผลการทดลองการรู้จำภาพไบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้.....	53
4.11 ผลการทดลองการรู้จำภาพลายนิ้วมือฐานข้อมูล FINGDB.....	53
4.12 ตารางแสดงหมายเลขภาพลายนิ้วมือที่ใช้ในการเรียนรู้ และการทดสอบ	56
4.13 ผลการทดลองการรู้จำภาพไบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้.....	58
4.14 ผลการทดลองการรู้จำภาพลายเซ็น	58
4.15 ตารางแสดงระยะทางของลายเซ็นที่ตอบผิด.....	60

สารบัญรูป

รูปที่	หน้า
2.1 แสดงรายละเอียดของ perceptron.....	3
2.2 แสดงตัวอย่าง single neuron perceptron	4
2.3 ภาพตัวอักษรต้นฉบับ.....	5
2.4 ภาพตัวอักษรที่ทำการตัดช่องว่างระหว่างตัวอักษรแล้ว	6
2.5 (a) การแบ่ง weight สำหรับตัวอักษรภาษาอังกฤษ (b) การแบ่ง weight สำหรับ ตัวอักษรภาษาจีน	5
2.6 สถาปัตยกรรมของโครงข่าย HAVNET	6
2.7 สถาปัตยกรรมของซิมพลิไฟด์พีซซีอาร์ทแมพ	9
2.8 แสดงเซต A และเซต B	13
2.9 แสดงการหาระยะทางระหว่างจุด a1 ไปยังทุกๆ จุดในเซต B.....	13
2.10 แสดงการเลือกระยะ d11 ซึ่งเป็นระยะทางที่สั้นที่สุด	14
2.11 แสดงการหาระยะทางระหว่างจุด a2 ไปยังทุกๆ จุดในเซต B.....	14
2.12 แสดงการเลือกระยะ d23 ซึ่งเป็นระยะทางที่สั้นที่สุด	15
2.13 แสดงการเปรียบเทียบหาระยะทางที่หาได้	15
2.14 แสดงระยะทางที่เลือก	16
2.15 แสดงการหาระยะทางระหว่างจุด b1 ไปยังทุกๆ จุดในเซต A	16
2.16 แสดงการเลือกระยะ d11 ซึ่งเป็นระยะทางที่สั้นที่สุด	17
2.17 แสดงการหาระยะทางระหว่างจุด b2 ไปยังทุกๆ จุดในเซต A	17
2.18 แสดงการเลือกระยะ d22 ซึ่งเป็นระยะทางที่สั้นที่สุด	18
2.19 แสดงการหาระยะทางระหว่างจุด b3 ไปยังทุกๆ จุดในเซต A	18
2.20 แสดงการเลือกระยะ d32 ซึ่งเป็นระยะทางที่สั้นที่สุด	19
2.21 แสดงการเปรียบเทียบหาระยะทางที่หาได้	19
2.22 แสดงระยะทางที่เลือก	20
2.23 แสดงระยะทางที่ถูกเลือก	20
2.24 แสดงระยะทางที่เป็นคำตอบของ $H(A, B)$	20
3.1 แสดงตำแหน่งอ้างอิงของภาพใบหน้า.....	23
3.2 (a) ภาพใบหน้าต้นฉบับ (b) ภาพใบหน้าแบบลายเส้นระดับสีเทา (c) ภาพใบหน้าขาวดำ	24

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.3 (a) ภาพใบหน้าต้นฉบับ (b) ภาพใบหน้าหลังจากกระบวนการเตรียมข้อมูล	25
3.4 (a) ลายนิ้วมือแบบโค้ง (b) ลายนิ้วมือแบบโค้งกระโจม (c) ลายนิ้วมือแบบมัดหวายปิดซ้าย (d) ลายนิ้วมือแบบมัดหวายปิดขวา (e) ลายนิ้วมือแบบก้นหอย.....	26
3.5 แสดงลักษณะพิเศษบนลายนิ้วมือ.....	27
3.6 (a) ภาพลายนิ้วมือขาคำที่ได้จากวิธี RAT (b) ภาพลายนิ้วมือขาคำที่ได้จากวิธีการ GT	28
3.7 (a) ภาพลายนิ้วมือที่ไม่สามารถหาจุดซิงกูลาร์ที่แน่นอนได้ (b) ภาพลายนิ้วมือที่จุดอ้างอิง น้อยกว่าขนาดที่กำหนด	29
3.8 (a) ภาพลายนิ้วมือต้นแบบ (b) ภาพลายนิ้วมือแบบขาคำที่ทำ thinning แล้ว	29
3.9 (a) ภาพลายเส้นต้นฉบับ (b) ภาพลายเส้นที่ผ่านการทำ pre-processing แล้ว.....	30
3.10 แสดงจุดศูนย์กลางใหม่ที่ถูกกำหนดขึ้นเพื่อใช้ในการเปรียบเทียบภาพ	32
3.11 สถาปัตยกรรมของ Modified Hausdorff ARTMAP.....	32
4.1 (a) แสดงภาพต้นฉบับภาพใบหน้าฐานข้อมูล ORL (b) แสดงภาพที่ผ่านกระบวนการ เตรียมข้อมูลแล้ว	41
4.2 (a) แสดงภาพต้นฉบับภาพใบหน้าฐานข้อมูล Yale (b) แสดงภาพที่ผ่านกระบวนการ เตรียมข้อมูลแล้ว	47
4.3 (a) แสดงภาพต้นฉบับภาพลายนิ้วมือฐานข้อมูล FINGDB (b) แสดงภาพที่ผ่าน กระบวนการเตรียมข้อมูลแล้ว.....	51
4.4 (a) แสดงภาพต้นฉบับภาพลายเส้น (b) แสดงภาพที่ผ่านกระบวนการเตรียมข้อมูลแล้ว.....	55

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การรู้จำรูปแบบ (Pattern Recognition) ที่เป็นรูปภาพ โดยใช้โครงข่ายประสาทเทียมส่วนใหญ่มักมีวิธีการดึงคุณลักษณะพิเศษ (Feature Extraction) ของภาพออกมาก่อน ซึ่งค่าที่ได้นั้นเป็นค่าตัวเลขที่มีความเข้าใจยาก และต้องใช้กระบวนการคำนวณที่ซับซ้อนกว่าจะได้คำตอบ ดังนั้นจึงมีการนำวิธีการรู้จำของมนุษย์ที่สามารถแยกวัตถุต่างๆ โดยการมองภาพรวม และโครงร่างคร่าวๆ ของวัตถุ ร่วมกับโครงข่ายประสาทเทียมที่จะรู้จำสิ่งใหม่โดยไม่สิ้นความรู้เก่าที่เคยเรียนรู้มาก่อนหน้านี้ด้วย เพื่อให้ได้ประสิทธิภาพในการรู้จำที่ดี โดยวิธีการนี้เรียกว่า Hausdorff ARTMAP [1] วิธีการนี้สามารถแก้ปัญหาความยุ่งยากต่างๆ ในการดึงคุณลักษณะพิเศษได้ แต่ก็มีการสร้างโหนดใน Category Layer จำนวนมาก และลำดับในการส่งอินพุตเข้าสู่การเรียนรู้มีผลกระทบต่อผลการทดลองด้วย ดังนั้นในวิทยานิพนธ์ฉบับนี้ มีความพยายามในการพัฒนาวิธีการใหม่ที่สามารถลดจำนวนโหนดใน Category Layer และทำให้ลำดับในการส่งอินพุตเข้าสู่การเรียนรู้ไม่มีผลกระทบต่อผลการทดลอง โดยที่ยังคงความถูกต้องในผลการทดลองให้มีความถูกต้องเท่าเดิม หรือมากกว่า

1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา

1. เพื่อพัฒนากระบวนการรู้จำรูปแบบ ซึ่งใช้โครงข่ายประสาทเทียมที่อาศัยแนวคิดจากวิธีการมองเห็น และรู้จำรูปแบบของมนุษย์เป็นพื้นฐาน
2. เพื่อพัฒนาให้ได้กระบวนการรู้จำที่ง่ายต่อความเข้าใจ และให้ประสิทธิภาพในการรู้จำใกล้เคียงกับมนุษย์
3. เพื่อลดจำนวนโหนดจากวิธีการเดิมใน Cluster Layer ลง และเพื่อพัฒนาให้ลำดับในการส่งอินพุตเข้าสู่การเรียนรู้ไม่มีผลกระทบต่อผลการทดลอง

1.3 ขอบเขตการวิจัย

1. การวิจัยนี้เป็นการทดลองแบบ off-line
2. งานวิจัยนี้เน้นการพัฒนากระบวนการรู้จำสำหรับรูปแบบที่เป็นรูปภาพที่มีโครงสร้างที่ชัดเจนเท่านั้น
3. กระบวนการรู้จำที่พัฒนาขึ้นมาใช้สำหรับการรู้จำภาพที่เป็นไบนารีเท่านั้น

1.4 ขั้นตอนของการศึกษา

1. ศึกษากระบวนการสกัดลายเส้น และโครงร่างที่สำคัญออกจากรูปภาพ รวมถึงการปรับปรุงรูปภาพ
2. ศึกษาวิธีการวัดความเหมือนแบบฮาอูสดอร์ฟดิสเทนซ์ และการปรับใช้งาน
3. ศึกษาโครงข่ายประสาทเทียมแบบซิมพลิไฟด์ฟัซซีอาร์ทแมพ (Simplified Fuzzy ARTMAP)
4. ศึกษาโครงข่ายประสาทเทียมแบบฮาอูสดอร์ฟ อาร์แมพ (Hausdorff ARTMAP)
5. ศึกษา และทดลองปรับแนวคิดทั้งหมดมาใช้ร่วมกันด้วยวิธีต่างๆ
6. วิเคราะห์ และสรุปผล เพื่อเลือกหาแนวทางในการสร้างรูปแบบการเรียนรู้ ที่ประยุกต์เอาแนวคิดทั้งหมดมาใช้ร่วมกัน
7. สร้าง โครงสร้าง และกระบวนการรู้จำแบบใหม่ตามแนวทางที่ได้
8. ทดลอง และทดสอบกระบวนการรู้จำแบบใหม่ กับข้อมูลรูปแบบต่างๆ

บทที่ 2


หลักการและทฤษฎีที่เกี่ยวข้อง

2.1 บทนำ

การจัดกลุ่มข้อมูล คือกระบวนการค้นหาเซตของโมเดล (model) ซึ่งโมเดล (ตัวแทนของข้อมูลที่ใช้ในการเรียนรู้) ที่หามาได้จะนำไปใช้ในการทำนายกลุ่มของข้อมูลที่เรายังไม่ทราบว่าข้อมูลนั้นอยู่ในกลุ่มใด ซึ่งการจัดกลุ่มข้อมูลนี้มีกระบวนการเรียนรู้แบบมีผู้สอน (supervised learning) ในการจัดกลุ่มข้อมูลนั้น ข้อมูลทั้งหมดจะถูกแบ่งออกเป็น 2 ส่วนคือส่วนที่ใช้สำหรับการเรียนรู้ (training set) และส่วนที่ใช้สำหรับการทดสอบ (testing set)


การจัดกลุ่มข้อมูล (classification) สามารถแบ่งออกได้เป็น 3 ประเภท [2] คือ การจัดกลุ่มโดยอาศัยการเรียนรู้เชิงสัญลักษณ์ (symbolic learning) การจัดกลุ่มข้อมูลเชิงสถิติ (statistic) และการจัดกลุ่มข้อมูลโดยใช้โครงข่ายประสาทเทียม (neural network) โดยในที่นี้จะกล่าวถึงเฉพาะ neural network เท่านั้น

โครงข่ายประสาทเทียมเป็นการจำลองกระบวนการการทำงานของเซลล์ประสาทสมองของมนุษย์ โครงข่ายนี้พัฒนาขึ้นมาเพื่อใช้ในการพยากรณ์ข้อมูล และการเรียนรู้ข้อมูลจากข้อมูลที่เตรียมไว้แล้ว โครงข่ายประสาทเทียมมีส่วนประกอบพื้นฐานที่เรียกว่า perceptron โดย perceptron ประกอบด้วยส่วนประกอบย่อยอีก 5 ส่วนคือ input vector, weight, ฟังก์ชันผลรวม (summing function), ค่า threshold และค่าเอาต์พุต (output) ดังแสดงในรูปที่ 2.1 ค่า threshold เป็นค่าที่ผู้ใช้เป็นผู้กำหนดเอง โดยค่านี้มีไว้เพื่อเป็นเกณฑ์ในการกำหนดค่าให้กับเอาต์พุต ซึ่งจะพิจารณาจากผลรวมของ input vector หากค่าผลรวมของ input vector มีค่ามากกว่าค่า threshold ค่าเอาต์พุตที่ได้จะมีค่าเท่ากับ +1 แต่หากค่าผลรวมของ input vector มีค่าน้อยกว่าค่า threshold ค่าเอาต์พุตที่ได้จะมีค่าเท่ากับ -1



รูปที่ 2.1 แสดงรายละเอียดของ perceptron

แนวคิดของ perceptron ได้รับการพัฒนาสู่ single neuron layer โดย input vector X ที่มีขนาด N ถูกส่งเข้าสู่โครงข่ายผ่านการเชื่อมต่อของ weight W ที่มีขนาด N เช่นกัน จากนั้นทำการหาผลรวมของผลคูณระหว่าง input X กับ weight W แล้วค่อยบวกกับค่า Bias เมื่อได้ผลรวมทั้งหมดนำผลรวมทำการเปรียบเทียบกับค่า threshold หากค่าผลรวมที่ได้มีค่ามากกว่าค่า threshold แสดงว่า perceptron นี้จะทำงาน แต่หากค่าผลรวมที่ได้มีค่าน้อยกว่าค่า threshold perceptron นี้จะไม่ทำงาน รูปที่ 2.2 แสดงตัวอย่าง single neuron perceptron



$$a = W_1 X_1 + W_2 X_2 + \dots + W_N X_N + \text{Bias}$$

$$\text{output} = \text{Threshold}[a]$$

$$\text{where } \text{Threshold}[a] = \begin{cases} -1, & \text{for all } a \leq 0 \\ 1, & \text{for all } a > 0 \end{cases}$$

รูปที่ 2.2 แสดงตัวอย่าง single neuron perceptron

ในปัจจุบันนี้ neuron network สามารถประยุกต์ใช้ได้กับงานหลากหลายประเภท เช่น การรู้จำรูปแบบ (pattern recognition), optical character recognition หรือการจำแนกกลุ่มของปัญหา (problem classification) เป็นต้น


2.2 บทวิจัยที่เกี่ยวข้อง

2.2.1 An Approach to Word Image Matching Based on Weighted Hausdorff Distance [3]

บทความนี้ได้นำเสนอวิธีการเปรียบเทียบรูปภาพตัวอักษรจากเอกสารโดยใช้ Weighted Hausdorff Distance (WHD) โดยคุณภาพของภาพตัวอักษรที่ได้นั้นจะขึ้นอยู่กับค่าความละเอียดในการสแกนเอกสาร หรืออาจจะเกิดจากคุณภาพการพิมพ์เอกสารนั้นก็ได้

ในขั้นตอนการเตรียมภาพตัวอักษรเพื่อใช้ในการเรียนรู้ นั้น จะทำการตัดช่องว่างระหว่างตัวอักษร โดยต้องการให้ตัวอักษรมีระยะห่างที่ชิดกันมากที่สุดเท่าที่จะสามารถทำได้ รูปที่ 2.3 แสดงภาพตัวอักษรต้นฉบับ และรูปที่ 2.4 แสดงภาพตัวอักษรที่ทำการตัดช่องว่างระหว่างตัวอักษรแล้ว


weight Hausdorff distance (WHD) สำหรับตัวอักษรภาษาอังกฤษจะทำการแบ่งภาพตัวอักษรออกเป็น 3 ส่วน คือ ส่วนบน ส่วนกลาง และส่วนล่าง ซึ่งจะมี weight สำหรับแต่ละส่วนแยกกัน คือ weight สำหรับส่วนบน weight สำหรับส่วนกลาง และ weight สำหรับส่วนล่าง จากนั้นจึงเข้าสู่กระบวนการหาค่าเหมือน (word matching) สำหรับตัวอักษรภาษาจีน (ภาษาจีนสิงคโปร์) การแบ่งจะแตกต่างไปจากตัวอักษรภาษาอังกฤษ โดยจะทำการแบ่งตรงส่วนมุมของตัวอักษร และตรงกลางของตัวอักษรในการพิจารณา ดังแสดงในรูปที่ 2.5



รูปที่ 2.3 ภาพตัวอักษรต้นฉบับ

wallet

รูปที่ 2.4 ภาพตัวอักษรที่ทำการตัดช่องว่างระหว่างตัวอักษรแล้ว



(a)

c	p	c
p	h	p
c	p	c

(b)

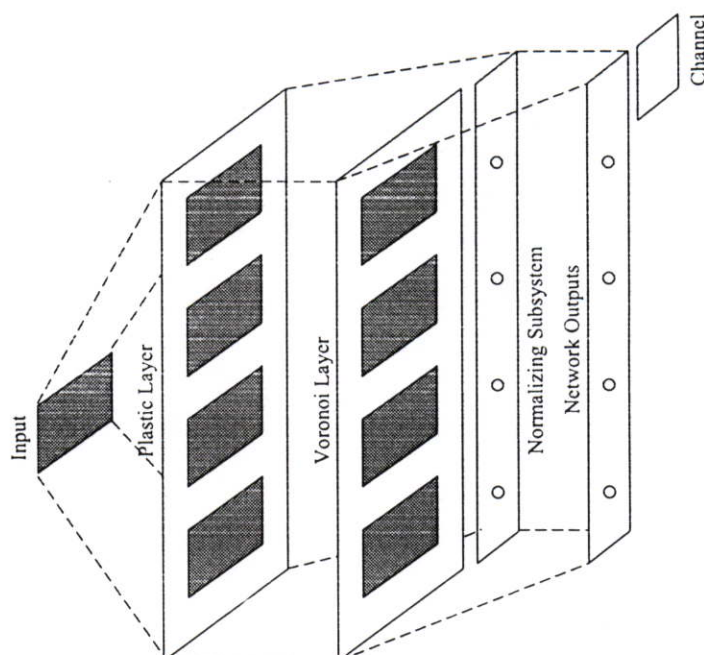
รูปที่ 2.5 (a) การแบ่ง weight สำหรับตัวอักษรภาษาอังกฤษ (b) การแบ่ง weight สำหรับตัวอักษรภาษาจีน

ผลการทดลองของ weight Hausdorff distance ทำการเปรียบเทียบกับ modified Hausdorff distance (MHD) โดยนำเอาระยะทางที่หาได้จากภาพคำต้นแบบ เปรียบเทียบกับภาพคำอื่นๆ มาใช้ในการเปรียบเทียบ ซึ่งผลที่ได้คือ weight Hausdorff distance ให้ค่าความเหมือนที่ดีกว่า และให้ค่าความต่างที่มากกว่า modified Hausdorff distance

2.2.2 Unconstrained Handwritten Numeral Recognition Using Hausdorff Distance and Multi-Layer Neural Network Classifier [4]

บทความนี้มุ่งเน้นที่จะศึกษาเกี่ยวกับลายมือเขียนของมนุษย์ โดยเจาะจงไปที่ตัวเขียนตัวเลขในรหัสไปรษณีย์ ซึ่งอินพุต (input) ที่ใช้ในการเรียนรู้ และทดสอบเป็นรูปภาพขาว-ดำเท่านั้น

HAVNET คือ โครงข่ายประสาทเทียม ที่ถูกออกแบบมาเพื่อการรู้จำภาพ 2 มิติ โดยเฉพาะ HAVNET มีรูปแบบโครงข่ายเป็น multi-channel ซึ่งในแต่ละ channel จะมี plastic layer weight ซึ่งใช้เป็นตัวแทนสำหรับแต่ละ pattern ที่ได้ทำการเรียนรู้โดยโครงข่าย สถาปัตยกรรมของ HAVNET แสดงดังรูปที่ 2.6



รูปที่ 2.6 สถาปัตยกรรมของโครงข่าย HAVNET

ในบทความนี้ยังได้นำเสนอ กฎการเรียนรู้ใหม่สำหรับ HAVNET ซึ่งมีอยู่ 3 ส่วนด้วยกัน คือ (1) supervised learning (2) competitive learning (3) self-organization

supervised learning ในส่วนนี้เป็นการกำหนดชนิดของกลุ่ม (class) ให้กับ channel ที่ได้ทำการเรียนรู้ โดยชนิดของกลุ่มของ channel จะเป็นกลุ่มเดียวกับอินพุตที่ได้ทำการเรียนรู้ไปแล้ว

competitive learning ในส่วนนี้จะเป็นการกระตุ้นให้ทุกๆ output node ทำการคำนวณ แล้วจึงเลือกโหนด (node) ที่ให้ค่ามากที่สุดออกมา หากค่าตอบของโหนดนั้นถูกต้อง ค่า plastic weight

ที่มีความสัมพันธ์กับโหนดที่ตอบผิดจะมีค่าน้อยลง และค่า plastic weight ที่มีความสัมพันธ์กับโหนดที่ตอบถูกจะมีค่าเพิ่มขึ้น หากเป็นค่าอื่น ค่า plastic weight จะไม่มีการเปลี่ยนแปลง

self-organization สำหรับวิธีการนี้ (Unconstrained Handwritten numeral recognition) ใช้ตัวแสดงคลาสเพียง 10 คลาส (0-9) ไม่เพียงพอ ดังนั้นจึงมีการสร้างตัวแทนขึ้นในแต่ละอัน ซึ่ง self-organization จะมียุ่เฉพาะในช่วงของการเรียนรู้เท่านั้น กระบวนการนี้มีความคล้ายกับ Adaptive Resonance Theory (ART) จำนวนของคลาสย่อยที่จะถูกสร้างนั้น จะสร้างโดยอัตโนมัติในช่วงระหว่างการเรียนรู้ของ self-organization

บทความนี้เลือกใช้ Hausdorff distance เป็นส่วนหนึ่งในของ HAVNET เนื่องจากให้ค่าความเหมือนที่ใกล้เคียงกับมนุษย์มากกว่าการวัดค่าความเหมือนแบบอื่นๆ (Euclidean Distance, Dot Product, Hamming Distance เป็นวิธีการวัดค่าที่ถูกนำมาเปรียบเทียบกับ Hausdorff distance)

การทดลองจะทำการแบ่งข้อมูลทั้งหมดออกเป็น 2 ส่วนคือ ส่วนที่ใช้สำหรับการเรียนรู้และส่วนที่ใช้สำหรับการทดสอบ ข้อมูลที่ใช้ในการเรียนรู้มีจำนวน 5000 ตัวอย่าง และข้อมูลที่ใช้ในการทดสอบมี 5000 ตัวอย่าง ซึ่งผลการทดลองอยู่ที่ความถูกต้อง 97%

2.2.3 Training Algorithms for Robust Face Recognition using a Template-matching Approach [5]

บทความนี้นำเสนอระบบการรู้จำใบหน้า เป็นการเปรียบเทียบภาพใดๆ กับแม่แบบที่เก็บไว้ และนำอัลกอริทึมสำหรับการเรียนรู้มาประยุกต์ใช้ เพื่อปรับปรุงประสิทธิภาพการทำงานของระบบ

ปัญหาที่ต้องการแก้ไข คือ (1) correct classification experiments คือค่าความถูกต้องในการรู้จำ และบอกได้ถูกต้องว่าภาพนี้อยู่ในฐานข้อมูล และ (2) false positive experiments คือค่าความถูกต้องที่สามารถระบุได้ว่าภาพนี้ไม่ได้อยู่ในฐานข้อมูล

การที่จะบอกว่าภาพใดอยู่ในฐานข้อมูลรูปภาพหรือไม่ นั้น จะมีตัวกำหนดค่า (threshold) อยู่ด้วยกันสองตัวคือ L_m และ U_m โดยที่ค่า L_m (lower threshold) คือ ค่าที่กำหนดไว้เพื่อบอกว่าอินพุต (input) กับ กลุ่มตัวอย่างนั้น มีความเหมือนกันเพียงพอ ส่วน U_m (upper threshold) คือ ค่าที่กำหนดเพื่อบอกว่าอินพุตกับ กลุ่มตัวอย่างนั้น มีความต่างกันเพียงพอ ที่จะทำให้เราสามารถทิ้งอินพุตตัวนี้ออกไปได้

ค่า L_m กับ U_m นั้นสามารถกำหนดได้โดย การแบ่งข้อมูลทั้งหมดออกเป็น 2 กลุ่มคือ classification training set X และ false positive training set Y โดยที่ classification training set ประกอบด้วยตัวอย่างใบหน้าของแต่ละคนในฐานข้อมูล และชุดข้อมูลนี้ใช้เพื่อการปรับปรุงความสามารถในการพิสูจน์บุคคล และความสามารถในการจำแนกบุคคลของระบบ ส่วน false positive training ประกอบด้วยตัวอย่างใบหน้าของแต่ละคน ที่ไม่ได้อยู่ในฐานข้อมูล และชุดข้อมูล

นี้จะถูกใช้เพื่อปรับปรุงความสามารถในการตัดใบหน้าของบุคคล ที่ไม่ได้อยู่ในฐานข้อมูลของระบบอีกด้วย

บทความนี้แบ่งข้อมูลใน classification training set ออกเป็น 2 ชุดข้อมูล (ชุดที่ 1 คือ X_1 และชุดที่ 2 คือ X_2) จากนั้นคำนวณหาระยะทางของข้อมูลแต่ละตัวของ x ของคนที่ m ใน X_1 เทียบกับทุกๆ ข้อมูลใน X_2 จะทำการเปรียบเทียบจนครบทุกๆ ข้อมูลของคนี่ m ใน X_1 จากนั้นจะใช้ค่าเฉลี่ยของระยะทางที่หาได้กำหนดเป็นค่า lower threshold (L_m) สำหรับภาพของคนี่ m นั้นๆ จากนั้นเราจะทำการคำนวณจนครบทุกๆ คนใน X_1

การหาค่า upper threshold (U_m) นั้นเราจะทำการคำนวณหาระยะทางระหว่างข้อมูล x ของคนที่ m เทียบกับทุกๆ ภาพใน เซต Y จากนั้นเลือกค่าระยะทางที่น้อยที่สุดเป็นค่า U_m สำหรับคนที่ m นั้นๆ

ภาพที่ใช้ในการทดลองนั้นเป็นภาพมาจากคนทั้งหมด 68 คน ใช้ภาพใบหน้าคนละ 10 ภาพ (รวมเป็น 680 ภาพ) ซึ่งจะมีทั้งภาพผู้ชาย และผู้หญิง และมีอายุที่แตกต่างกัน (อายุอยู่ในช่วง 15 – 50 ปี) ในการเรียนรู้เราจะแบ่งในการเรียนรู้ของแต่ละคนออกเป็น 2 กลุ่ม กลุ่มที่ 1 สำหรับการเรียนรู้ของระบบ จำนวน 8 ภาพ และกลุ่มที่ 2 สำหรับการทดสอบอีก 2 ภาพ ซึ่งขนาดภาพที่ใช้คือขนาด 72 x 72 พิกเซล

การทดลองใช้รูปภาพทั้งหมดจำนวน 680 ภาพ โดยผลการจำแนกกลุ่มมีค่าความถูกต้องมากกว่า 99% และค่าความผิดพลาดที่ไม่สามารถระบุได้ว่าภาพนี้ไม่ได้อยู่ในฐานข้อมูลนั้นน้อยกว่า 1.5%

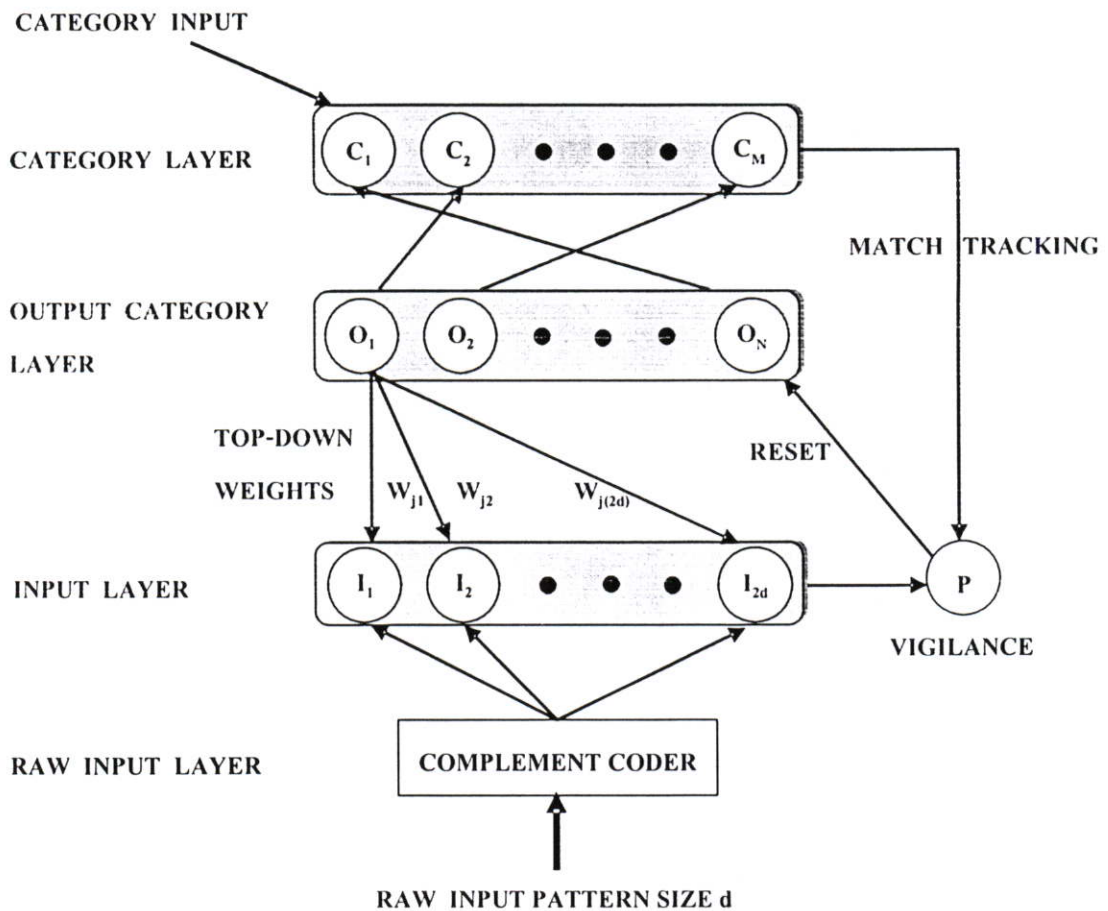
2.3 Simplified Fuzzy ARTMAP (SFAM)

โครงสร้างสถาปัตยกรรมของ Simplified Fuzzy ARTMAP ดังรูปที่ 2.1 อินพุทจะถูกส่งเข้าไปยังโครงข่ายโดยผ่านขั้นตอน complement coding ซึ่งจะทำการเพิ่มขนาดของอินพุทให้เป็นสองเท่า เมื่ออินพุทที่ได้ทำการเพิ่มขนาดแล้ว (I) จะถูกส่งไปยัง input layer โดยโหนดใน input layer จะทำการเชื่อมต่อกับโหนดใน output category layer ผ่านทางค่า weight (w) แบบบนลงล่าง (Top-down weight) ถัดไปคือ category layer เป็นชั้นที่บอกถึงประเภทของกลุ่มข้อมูลซึ่งโครงข่ายต้องเรียนรู้ทั้งหมด M ชั้น โดยที่หนึ่ง output node จะถูกจัดให้อยู่ได้ประเภทเดียวเท่านั้น ดังนั้น output node จะถูกชี้ไปยังตำแหน่งใน category layer ได้เพียงตำแหน่งเดียวเท่านั้น ส่วน category input สามารถเพิ่มเข้าไปยัง category layer ได้เฉพาะระหว่างการเรียนรู้ของโครงข่ายเท่านั้น ซึ่งการเรียนรู้ของโครงข่ายจะเป็นการเรียนรู้แบบมีผู้สอน (supervised learning)

สิ่งสำคัญอีกส่วนหนึ่งของสถาปัตยกรรมแบบนี้ คือ ρ (rho) เรียกว่า vigilance โดยใช้เป็นค่าตั้งต้นพื้นฐาน (base line) ซึ่งมีค่าระหว่าง 0 ถึง 1 เท่านั้น ซึ่งค่า vigilance เป็นพารามิเตอร์ตัวเดียว

เท่านั้นที่ผู้ใช้สามารถกำหนดค่าได้ ค่า vigilance จะเป็นตัวควบคุมการจัดกลุ่มของ output node ว่า input pattern จะต้องมีความคล้ายกันมากน้อยเพียงใดจึงจะสามารถจัดให้อยู่ในคลาสของเอาต์พุตเดียวกันได้ ยิ่งค่า vigilance สูง input pattern ยิ่งต้องมีความเหมือนกันมากจึงจะจัดให้อยู่ในคลาสของเอาต์พุตเดียวกันได้ และหากค่า vigilance มีค่าน้อย input pattern ที่มีความเหมือนกันน้อยก็สามารถจัดให้อยู่ในคลาสเดียวกันได้ ทั้งนี้ค่าของ vigilance ยิ่งสูงก็จะทำให้จำนวนโหนดของ output category ยิ่งมากขึ้นไปด้วย

ขั้นตอนการทำ match tracking นั้น จะเป็นส่วนที่โครงข่ายทำการปรับค่า vigilance ระหว่างการเรียนรู้ โดยจะทำการเพิ่มค่าขึ้นเล็กน้อย ขั้นตอนนี้จะทำเมื่อมีความผิดพลาดในการจำแนกชนิดข้อมูลในระหว่างช่วงของการเรียนรู้ของโครงข่าย



รูปที่ 2.7 สถาปัตยกรรมของซิมพลิฟายด์ฟัชชีอาร์ทแมพ

กระบวนการทำงานของ Simplified Fuzzy ARTMAP (SFAM)

Input ที่เข้ามาจะทำการปรับโดยทำ complement coding ถ้า input pattern vector a มีพีเจอร์ทั้งหมด d พีเจอร์ เวกเตอร์ที่ทำคอมพลิเมนต์ \bar{a} แล้ว สามารถเขียนให้อยู่ในรูปสมการได้ดังนี้

$$\bar{a} = 1 - a \quad (2.1)$$

เนื่องจากโครงข่ายนี้มีการดำเนินการที่ใช้ Fuzzy Logic ดังนั้น input ทั้งหมดใน SFAM จะมีค่าระหว่าง 0 ถึง 1 และ input vector ที่ผ่านการทำคอมพลิเมนต์แล้วจะมีขนาดเป็น 2 เท่า คือ $2d$ และสามารถแทนค่าของ input ได้ดังนี้

$$I = (a, \bar{a}) = (a_1, \dots, a_d, \bar{a}_1, \dots, \bar{a}_d) \quad (2.2)$$

โดยที่

$$|I| = |(a, \bar{a})| = \sum_{i=1}^d a_i + \left(d - \sum_{i=1}^d a_i \right) = d \quad (2.3)$$

เมื่อค่า $| \cdot |$ สามารถคำนวณได้ดังนี้

$$|p| = \sum_{i=1}^d p_i \quad (2.4)$$

โครงข่ายนี้มีการกระตุ้นโหนดใน output category layer ให้มีการตอบสนองต่ออินพุตที่ถูกส่งเข้ามาในระบบ เรียกกระบวนการนี้ว่าฟังก์ชันกระตุ้น (activation function) สามารถคำนวณได้ดังนี้

$$T_j(I) = \frac{|I \wedge W_j|}{\alpha + |W_j|} \quad (2.5)$$

โดย T_j คือ ค่าการกระตุ้นของโหนดใน output category later เมื่อ j คือ ลำดับของ output node I คืออินพุตที่ผ่านการทำ complement-coding และค่า α เป็นค่าที่กำหนดไว้ให้มีค่าน้อยมากๆ ที่เข้าใกล้ 0 โดยปกติจะให้มีค่าประมาณ 0.0000001 ระบบจะทำการเลือก output node ที่มีค่า T_j สูงที่สุดให้เป็นโหนดที่ชนะ

$$\text{Winner} = \max(T_j) \quad (2.6)$$

หากมีโหนดที่มีค่า T_j สูงที่สุดเกินกว่า 1 โหนด ระบบจะทำการเลือก output node ที่ถูกสร้างในระบบก่อน output node อื่นๆ ที่มีค่า T_j เท่ากันให้เป็นโหนดที่ชนะ โดยชนิดของรูปแบบที่สัมพันธ์กับ output node ที่ชนะ คือ วิธีการจำแนกประเภทของ input pattern ที่โครงข่ายนี้ใช้นั่นเอง

Match function คือ การนำเอา input feature ที่ทำ complement-coding แล้ว เปรียบเทียบกับค่าน้ำหนักโดยจะนำมาพิจารณาพร้อมกับค่า vigilance เพื่อดูว่าอินพุตมีความเหมือนกับ output node ที่เกี่ยวข้องเพียงพอหรือไม่ หรือควรเพิ่ม output node ใหม่เพื่อเป็นตัวแทนของ input pattern นี้ หากค่า match function มีค่ามากกว่าค่า vigilance แล้ว แสดงว่าเกิดสภาวะที่เรียกว่า resonance ซึ่งสามารถแสดงได้ดังนี้

$$\frac{|I \wedge W_j|}{d} \geq p \quad (2.7)$$

การเกิด resonance หมายถึง output node j ดีเพียงพอที่จะเป็นตัวแทนของ input I ได้ และ output node j นี้จะต้องเป็น output node กลุ่มเดียวกันกับอินพุต I ด้วย จากนั้นค่าน้ำหนักของ output node j จะทำการปรับค่าเพื่อทำการเรียนรู้ input pattern ตัวใหม่นี้ แต่ถ้าหากกลุ่มของ output node j กับกลุ่มของอินพุต I ต่างกัน ค่าน้ำหนักจะไม่ทำการเปลี่ยนแปลงใดๆ โดยสังเกตเห็นได้ว่า จะมีเพียง output node เพียงโหนดเดียวเท่านั้นที่จะสามารถปรับค่าได้ เมื่ออินพุตหนึ่งตัวเข้ามาทำการเรียนรู้ในระบบ

เมื่อ output node j เป็น node ที่ชนะและผ่านเงื่อนไข (2.7) พร้อมทั้งเกิด resonance แล้ว ค่าน้ำหนักจะได้รับการปรับค่าตามสมการต่อไปนี้

$$w_j^{\text{new}} = \beta(I \wedge w_j^{\text{old}}) + (1 - \beta)w_j^{\text{old}} \quad (2.8)$$

ค่า β คือ ค่า learning rate จะมีค่าอยู่ระหว่าง 0 ถึง 1 ซึ่ง β มีค่ามากการเรียนรู้ก็จะรวดเร็วมากขึ้น ในการปรับค่าน้ำหนักสามารถทำให้ง่ายขึ้นได้โดยให้ learning rate มีค่าเท่ากับ 1 (fast learning) ดังนั้นสมการสำหรับปรับค่าน้ำหนักสามารถเขียนได้เป็น

$$w_j^{\text{new}} = (I \wedge w_j^{\text{old}}) \quad (2.9)$$

ในกรณีเงื่อนไข (2.7) เป็นเท็จ จะทำการเพิ่มค่า vigilance ขึ้นเล็กน้อย และพิจารณาค่า T ของโหนดที่มีค่ามากที่สุดถัดไป หากพิจารณาจนครบแล้วไม่มีค่า T ใดๆ ที่ผ่านเงื่อนไขนี้เลย หรือกลุ่มของ output node j กับกลุ่มของอินพุต I เป็นคนละกลุ่มกัน จะทำการเพิ่ม output node ใหม่ โดย output node ที่เพิ่มมานั้นเป็นกลุ่มเดียวกับอินพุต I และมีค่าน้ำหนักเท่ากับค่าอินพุต I ที่ทำ complement-coding แล้ว และในกรณีที่อินพุตแรกหรืออินพุตนั้นยังไม่ได้รับการเรียนรู้มาก่อนเลย ก็จะทำการสร้าง output node ใหม่ที่มีกลุ่มเป็นกลุ่มเดียวกับอินพุตนั้น และมีค่าน้ำหนักเท่ากับค่าอินพุตที่ทำ complement-coding แล้ว

2.4 Hausdorff Distance

Hausdorff Distance ได้รับการยอมรับว่าเป็นตัววัดค่าความเหมือน (Similarity Metric) ที่มีประสิทธิภาพ และมีหลักการทำงานใกล้เคียงกับวิธีการของมนุษย์มากกว่าตัววัดค่าความเหมือนอื่นๆ Hausdorff Distance เป็นการวัดระยะทางของแต่ละจุดในเซตของอินพุตว่าอยู่ใกล้กับจุดใดในโมเดล เป็นระยะทางเท่าใด โดยถ้ากำหนดให้ $A = \{a_1, \dots, a_p\}$ และ $B = \{b_1, \dots, b_q\}$ ซึ่งทั้งสองเซตเป็นเซตของจุดที่มีจำนวนสมาชิกจำกัด (finite point sets) Hausdorff Distance สามารถนิยามได้ดังนี้

$$H(A, B) = \max \{h(A, B), h(B, A)\} \quad (2.10)$$

เมื่อฟังก์ชัน $h(A, B)$ คือ directed Hausdorff Distance จาก A ไปยัง B สามารถคำนวณได้ดังนี้

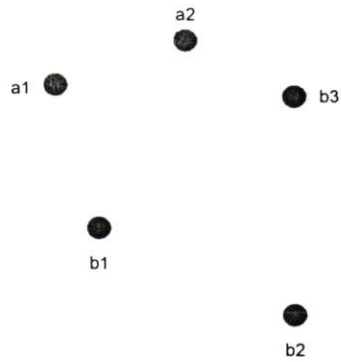
$$h(A, B) = \max_{a \in A} \{ \min_{b \in B} \{ \|a - b\| \} \} \quad (2.11)$$

เมื่อ $\|a - b\|$ ในที่นี้คือค่า Euclidean distance ระหว่างจุด a และ b

Hausdorff Distance คือ การหาจุดใน A ซึ่งอยู่ห่างจากจุดใน B ที่ใกล้จุดนั้นที่สุดเป็นระยะทางมากที่สุด แล้ววัดระยะทางนั้น


ตัวอย่างการหาค่า Hausdorff Distance $H(A, B)$

1. กำหนดเซต A และเซต B ดังรูปที่ 2.8




รูปที่ 2.8 แสดงเซต A และเซต B

2. เริ่มคำนวณหา $h(A, B)$ โดยเริ่มจากคำนวณหาระยะทางจาก a_1 ไปยังทุกๆ จุดในเซต B




รูปที่ 2.9 แสดงการหาระยะทางระหว่างจุด a_1 ไปยังทุกๆ จุดในเซต B

3. ทำการเลือกระยะทางที่สั้นที่สุด คือจุด d11




รูปที่ 2.10 แสดงการเลือกระยะ d11 ซึ่งเป็นระยะทางที่สั้นที่สุด

4. คำนวณหาระยะทางจาก a_2 ไปยังทุกๆ จุดในเซต B




รูปที่ 2.11 แสดงการหาระยะทางระหว่างจุด a_2 ไปยังทุกๆ จุดในเซต B

5. ทำการเลือกระยะทางที่สั้นที่สุด คือจุด d23

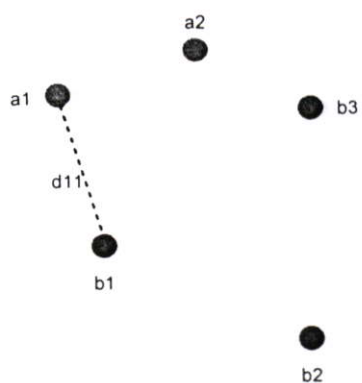


รูปที่ 2.12 แสดงการเลือกระยะ d23 ซึ่งเป็นระยะทางที่สั้นที่สุด

6. เมื่อทำครบทุกจุดในเซต A ให้นำเอาระยะทางที่หาได้นำมาเปรียบเทียบกัน ดังรูปที่ 2.13 จากนั้นเลือกระยะทางที่มากที่สุดเป็นคำตอบ ของ directed Hausdorff Distance จาก A ไปยัง B ดังรูปที่ 2.14




รูปที่ 2.13 แสดงการเปรียบเทียบหาระยะทางที่หาได้




รูปที่ 2.14 แสดงระยะทางที่เลือก

7. เริ่มคำนวณหา $h(B, A)$ โดยเริ่มจากคำนวณหาระยะทางจาก b_1 ไปยังทุกๆ จุดในเซต A




รูปที่ 2.15 แสดงการหาระยะทางระหว่างจุด b_1 ไปยังทุกๆ จุดในเซต A

8. ทำการเลือกระยะทางที่สั้นที่สุด คือจุด d11




รูปที่ 2.16 แสดงการเลือกระยะ d11 ซึ่งเป็นระยะทางที่สั้นที่สุด

9. กำหนดหาระยะทางจาก b2 ไปยังทุกๆ จุดในเซต A




รูปที่ 2.17 แสดงการหาระยะทางระหว่างจุด b2 ไปยังทุกๆ จุดในเซต A

10. ทำการเลือกระยะทางที่สั้นที่สุด คือจุด d22




รูปที่ 2.18 แสดงการเลือกระยะ d22 ซึ่งเป็นระยะทางที่สั้นที่สุด

11. กำหนดหาระยะทางจาก b3 ไปยังทุกๆ จุดในเซต A




รูปที่ 2.19 แสดงการหาระยะทางระหว่างจุด b3 ไปยังทุกๆ จุดในเซต A

12. ทำการเลือกระยะทางที่สั้นที่สุด คือจุด d_{32}

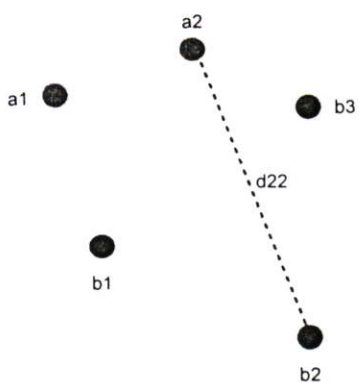


รูปที่ 2.20 แสดงการเลือกระยะ d_{32} ซึ่งเป็นระยะทางที่สั้นที่สุด

13. เมื่อทำครบทุกจุดในเซต B ให้นำเอาระยะทางที่หาได้นำมาเปรียบเทียบกัน ดังรูปที่ 2.21 จากนั้นเลือกระยะทางที่มากที่สุดเป็นคำตอบ ของ directed Hausdorff Distance จาก B ไปยัง A ดังรูปที่ 2.22




รูปที่ 2.21 แสดงการเปรียบเทียบหาระยะทางที่หาได้




รูปที่ 2.22 แสดงระยะทางที่เลือก

14. หา $H(A,B)$ จากรูปที่ 2.14 และรูปที่ 2.22



รูปที่ 2.23 แสดงระยะทางที่ถูกเลือก

15. เลือกระยะทางที่มากที่สุดจากรูปที่ 2.23 เพื่อเป็นคำตอบของ $H(A,B)$ ดังรูปที่ 2.24



รูปที่ 2.24 แสดงระยะทางที่เป็นคำตอบของ $H(A,B)$

ในการนำ Hausdorff Distance มาใช้กับโครงข่ายประสาทเทียมจำเป็นต้องมีการปรับวิธีการคำนวณหา directed Hausdorff Distance ในสมการ (2.11) ใหม่ เนื่องจากการคำนวณค่า directed Hausdorff Distance ต้องคำนวณจากทุกๆ จุด โดยคำนวณได้ดังนี้

$$d(a, B) = \min_{b \in B} \{ \|a - b\| \} \quad (2.12)$$

เมื่อ $d(a, B)$ คือ Hausdorff Distance แบบจุด (Pointwise Hausdorff Distance) ของจุดใดๆ ใน a และ Hausdorff Distance แบบจุดของ A คำนวณได้จากสมการต่อไปนี้

$$h(A, B) = \frac{\sum_{a \in A} d(a, B)}{|A|} \quad (2.13)$$

โดย $|A|$ คือจำนวนจุดในเซต A

บทที่ 3

Modified Hausdorff ARTMAP for Binary Image Recognition

3.1 บทนำ

ลักษณะทางกายภาพ และพฤติกรรมของมนุษย์ทางกายภาพของมนุษย์ ถูกนำมาประยุกต์ใช้อย่างแพร่หลายในปัจจุบัน ทั้งในส่วนของระบบสมาชิก การเข้า-ออกเวลาทำงาน รวมทั้งระบบรักษาความปลอดภัยในสนามบิน หรือธนาคาร โดยเทคนิคการระบุบุคคลโดยใช้คุณสมบัติทางกายภาพ หรือพฤติกรรมของมนุษย์เรียกว่า Biometrics [6] คุณสมบัติทางกายภาพ หรือพฤติกรรมของมนุษย์ที่จัดอยู่ใน Biometrics สามารถแบ่งออกเป็น 2 กลุ่ม [7] คือ กลุ่มคุณสมบัติทางกายภาพ (physiological) ประกอบด้วย รูม่านตา (retinal/iris) ใบหน้า (face) ลายนิ้วมือ (fingerprint) และกลุ่มคุณสมบัติทางพฤติกรรม ประกอบด้วย ลายเซ็น (signature) และเสียง (voice)

งานวิจัยชิ้นนี้ใช้ข้อมูลใบหน้า ลายนิ้วมือ และลายเซ็น โดยทั้ง 3 ชุดข้อมูลนี้ต้องเข้าสู่กระบวนการเตรียมข้อมูลก่อนการใช้งานจริง (pre-processing) ซึ่งข้อมูลแต่ละชุดมีวิธีการเตรียมข้อมูลที่แตกต่างกัน และได้นำเสนอในหัวข้อถัดไป

3.2 การเตรียมข้อมูล

การเตรียมข้อมูล (pre-processing) คือ กระบวนการจัดการกับข้อมูลดิบ (raw input) ให้มีความเหมาะสมกับอัลกอริทึมที่ต้องการนำเสนอ โดยอาจประกอบด้วยกระบวนการต่างๆ เช่น การกำจัดจุดรบกวน (noise) การปรับค่าของข้อมูล หรือปรับขนาดของข้อมูล (normalization) การหาโครงร่างรูปภาพ (skeleton)

3.2.1 การเตรียมข้อมูลภาพใบหน้า

รูปภาพใบหน้าในชุดข้อมูลเดิมเป็นภาพระดับสีเทา (gray scale image) มีความจำเป็นที่ต้องเปลี่ยนมาเป็นภาพขาวดำ (binary image) เพื่อใช้ในงานวิจัยนี้ และการหาเส้นขอบของภาพใบหน้าก็มีความสำคัญเช่นกัน กระบวนการเตรียมข้อมูลภาพใบหน้าที่มีดังต่อไปนี้

3.2.1.1 การหาตำแหน่งอ้างอิง

ตาทั้งสองข้างถูกใช้เป็นตำแหน่งอ้างอิง วิธีการหาตำแหน่งเป็นแบบ manual คือการหาตำแหน่งของดวงตาทั้งสองข้าง โดยคนเป็นผู้หา ตำแหน่งอ้างอิงที่ได้แสดงในรูปที่ 3.1



รูปที่ 3.1 แสดงตำแหน่งอ้างอิงของภาพใบหน้า

3.2.1.2 การหาเส้นขอบของภาพ และการแปลงภาพระดับสีเทาเป็นภาพขาวดำ

การใช้เส้นขอบของภาพแทนภาพใบหน้าทั้งหมด เพื่อแก้ปัญหาการเปลี่ยนแปลงความเข้มแสงที่ตกกระทบ (illumination) การแปลงภาพจากภาพระดับสีเทา เป็นภาพลายเส้นระดับสีเทา (gray edge image) $E(x,y)$ โดยใช้ morphological operation [8] กับภาพใบหน้า $f(x,y)$ ขั้นตอนการแปลงภาพแสดงได้ดังนี้


$$(f \oplus b) - (f \ominus b) = E \quad (3.1)$$

ในการดำเนินการวิจัยนี้ได้นำเอาภาพใบหน้าที่ต้นฉบับทำ dilation ภาพใบหน้าด้วย structure element ที่มีลักษณะที่เป็นสี่เหลี่ยมจัตุรัสขนาด 3×3 จากนั้นเอาภาพใบหน้าที่ต้นฉบับทำ erosion ภาพใบหน้าด้วย structure element แบบเดียวกัน นำภาพที่ได้จากการทำ dilation ตั้งแล้วลบ (subtraction) ด้วยภาพที่ได้จากการทำ erosion โดยภาพที่ได้จากการทำ subtraction คือภาพลายเส้นระดับสีเทาที่ต้องการ จากนั้นใช้วิธี adaptive thresholding ใน [9] เพื่อแปลงภาพลายเส้นระดับสีเทาเป็นภาพขาวดำที่ต้องการ โดยวิธีการใน [9] ให้ความสำคัญกับใบหน้า และ โครงหน้าซึ่งมักจะเป็นส่วนที่มีความลึก และค่าความเข้มของระดับสีเทา (gray level intensities) ต่ำกว่าส่วนอื่นๆ ของใบหน้า ฟังก์ชันที่ [9] เลือกใช้คือ

$$n(x,y) = \frac{E(x,y)}{f(x,y)} \quad (3.2)$$

นำค่า $n(x,y)$ ที่ได้จากสมการ (3.2) มาเรียงลำดับจากมากไปหาน้อย จากนั้นกำหนดค่า threshold เพื่อเลือกจุดที่มีค่า $n(x,y)$ มากที่สุดตามลำดับที่ได้เรียงไว้ โดยเลือกจำนวนจุดตามเปอร์เซ็นต์ที่ต้องการ ในงานวิจัยนี้เลือกจุดที่มีค่า $n(x,y)$ มากที่สุด 30% แรกตามลำดับที่เรียงไว้ โดยให้จุดนั้นมีค่าเท่ากับ 1 ส่วนจุดที่เหลือให้มีค่าเท่ากับ 0 ซึ่งจะได้ภาพขาวดำตามต้องการ รูปที่ 3.2

แสดงตัวอย่างในการแปลงภาพระดับสีเทา เป็นภาพขาวดำ รูป (a) แสดงภาพใบหน้าต้นฉบับเป็นภาพระดับสีเทา รูป (b) แสดงภาพใบหน้าแบบลายเส้นระดับสีเทา และรูป (c) แสดงภาพใบหน้าขาวดำ



รูปที่ 3.2 (a) ภาพใบหน้าต้นฉบับ (b) ภาพใบหน้าแบบลายเส้นระดับสีเทา (c) ภาพใบหน้าขาวดำ

3.2.1.3 การหมุนภาพ

การกำหนดให้ตาทั้งสองข้างเป็นจุดอ้างอิง ทำให้สามารถที่คำนวณมุมระหว่างจุด 2 จุดนี้ได้ สมมติฐานในการหมุนภาพคือ ตาของเราทั้งสองข้างควรวางอยู่ในแนวเดียวกัน ดังนั้นเมื่อได้มุมระหว่างตาทั้งสองแล้ว ทำการหมุนภาพเพื่อให้จุดอ้างอิงทั้งสองอยู่ในตำแหน่งที่ขนานกับแนวระนาบ ทฤษฎีสำหรับการหมุนภาพที่ใช้คือ ทฤษฎี nearest neighbor interpolation จากนั้นหาจุดอ้างอิงใหม่จากภาพที่หมุนแล้ว


3.2.1.4 การปรับขนาดภาพ

จาก 3.2.1.3 ได้จุดอ้างอิงใหม่จากภาพที่หมุนแล้ว ขั้นตอนต่อไปคือการคำนวณระยะห่างระหว่างจุดอ้างอิงทั้งสอง เทียบกับระยะห่างที่ต้องการ ซึ่งในงานวิจัยนี้กำหนดให้ทุกภาพมีระยะระหว่างดวงตาทั้งสองข้างเท่ากับ 30 พิกเซล จากนั้นคำนวณหาอัตราส่วนของระยะห่างดวงตาของภาพที่หมุนแล้ว กับระยะห่างดวงตาที่ต้องการ อัตราส่วนนี้คือจำนวนเท่าที่ต้องการปรับขนาด งานวิจัยนี้เลือกใช้ทฤษฎี nearest neighbor interpolation ในการปรับขนาดภาพ จากนั้นทำการหาจุดอ้างอิงใหม่จากภาพใบหน้าที่ปรับขนาดแล้ว

3.2.1.5 การเลื่อนตำแหน่งอ้างอิงของภาพใบหน้า และการเลือกบริเวณของภาพในส่วนที่ต้องการ

ขั้นตอนนี้ทำการเลื่อนจุดอ้างอิงทั้งสองให้อยู่ในบริเวณที่เหมาะสม และอยู่ในตำแหน่งเดียวกันทุกรูป โดยให้ตาซ้ายอยู่ที่ตำแหน่ง (45,60) จากนั้นปรับขนาดภาพให้มีขนาด 100×100 พิกเซล เท่ากันทุกภาพ โดยตัดส่วนเกินของภาพออกหากมีขนาดเกินจากขนาดที่กำหนด และหากภาพที่ได้มีขนาดน้อยกว่าที่กำหนดไว้จะทำการเติมส่วนที่ขาดไปให้เป็นช่องว่าง (มีค่าเป็นศูนย์)

ภาพใบหน้าที่ผ่านมากระบวนการเตรียมข้อมูลแสดงตัวอย่างในรูปที่ 3.3 ในคอลัมน์ (a) คือภาพใบหน้าต้นฉบับ และในคอลัมน์ (b) คือภาพใบหน้าหลังจากกระบวนการเตรียมข้อมูล



รูปที่ 3.3 (a) ภาพใบหน้าต้นฉบับ (b) ภาพใบหน้าหลังจากกระบวนการเตรียมข้อมูล

3.2.2 การเตรียมข้อมูลภาพลายนิ้วมือ


ขั้นตอนสำคัญหลัก 2 ขั้นตอนในการเตรียมข้อมูลภาพลายนิ้วมือ คือ ขั้นตอนการหาตำแหน่งอ้างอิง ซึ่งจะนำมาใช้เป็นจุดศูนย์กลางของภาพ และขั้นตอนการแปลงภาพจากภาพระดับสีเทา เป็นภาพแบบขาวดำ หรือภาพขาวดำ

ขั้นตอนการเตรียมข้อมูลภาพลายนิ้วมือมีขั้นตอนต่างๆ ดังนี้

3.2.2.1 การหาจุดอ้างอิง

รูปลายนิ้วมือแต่ละรูปมีการจัดวางตำแหน่งที่ไม่เหมือนกัน ดังนั้นจึงจำเป็นต้องหาตำแหน่งอ้างอิงของรูปลายนิ้วมือทุกๆ รูป และใช้ตำแหน่งอ้างอิงนี้เป็นจุดศูนย์กลางของภาพ

การหาตำแหน่งอ้างอิงทำได้โดยเลือกใช้ลักษณะพิเศษ (feature) ที่มีอยู่ในลายนิ้วมือ คือ จุดซิงกูลาร์ (singular points : SPs) ซึ่งประกอบด้วยจุด 2 ประเภท คือ จุดคอร์ (core) และจุดเดลตา (delta) จุดคอร์ คือ จุดที่เป็นส่วนบนสุดของเส้นโค้งที่อยู่ในสุด จุดเดลตา คือ จุดศูนย์กลางของพื้นที่สามเหลี่ยม ซึ่งมีทิศทางของเส้นในสามทิศทางมาบรรจบกัน [10] ลายนิ้วมือโดยทั่วไปมีอยู่ 5 แบบ [11] คือ ลายนิ้วมือแบบโค้ง ลายนิ้วมือแบบโค้งกระโจม ลายนิ้วมือแบบมัดหอยปิดซ้าย ลายนิ้วมือแบบมัดหอยปิดขวา ลายนิ้วมือแบบก้นหอย ดังแสดงในรูปที่ 3.4 และรูปที่ 3.5 แสดงลักษณะพิเศษบนลายนิ้วมือ



รูปที่ 3.4 (a) ลายนิ้วมือแบบโค้ง (b) ลายนิ้วมือแบบโค้งกระโจม (c) ลายนิ้วมือแบบมัดหอยปิดซ้าย (d) ลายนิ้วมือแบบมัดหอยปิดขวา (e) ลายนิ้วมือแบบก้นหอย



รูปที่ 3.5 แสดงลักษณะพิเศษบนลายนิ้วมือ

งานวิจัยนี้ใช้วิธีการหาจุดซิงกูลาร์ตามแนวทางใน [12] การหาจุดซิงกูลาร์ใน [12] อาศัยการเปลี่ยนแปลงของเครื่องหมายในรูปภาพเชิงทิศทาง (directional image) ซึ่งสามารถหาจุดซิงกูลาร์ได้อย่างถูกต้อง และใช้เวลาในการคำนวณน้อย วิธีการใน [12] ถูกนำไปทดสอบกับฐานข้อมูลลายนิ้วมือ FINGDB [13] แล้วให้ผลลัพธ์ดี และงานวิจัยนี้เลือกใช้ฐานข้อมูลลายนิ้วมือ FINGDB ในการทดสอบด้วยเช่นกัน

3.2.2.2 การแปลงภาพลายนิ้วมือระดับสีเทา เป็นภาพขาวดำ

งานวิจัยนี้ใช้วิธีการในการแปลงภาพระดับสีเทา เป็นภาพแบบขาวดำที่เรียกว่า Regional Average Thresholding (RAT) [14] เป็นการหาค่าเฉลี่ยในแต่ละบริเวณมาเป็นค่า threshold แนวคิดของ RAT มาจากการแก้ปัญหาการแปลงภาพระดับสีเทา เป็นภาพขาวดำ โดยการใช้ค่า threshold เพียงค่าเดียว ซึ่งทำให้เกิดการสูญเสียฟีเจอร์ (feature) บางอย่าง วิธีการที่ใช้ค่า threshold เพียงค่าเดียวคือ General Thresholding (GT) สามารถแสดงสมการได้ดังนี้

$$P(i, j) = \begin{cases} 1, & \text{if } I(i, j) > T \\ 0, & \text{if } I(i, j) \leq T \end{cases} \quad (3.3)$$

เมื่อ $I(i, j)$ คือ รูปภาพเริ่มต้นที่เป็นภาพขาวเทา

$P(i, j)$ คือ ภาพขาวดำที่ได้จากการแปลง

T คือ ระดับของ threshold

$i = 0, 1, \dots, N$

$j = 0, 1, \dots, M$

ขนาดภาพ = $N \times M$

วิธีการ RAT จะแบ่งภาพเริ่มต้นออกเป็นส่วนหน้าต่างย่อยๆ โดยใน [14] แบ่งออกขนาด 16×16 พิกเซล จากนั้นหาค่าเฉลี่ยของระดับค่าสีเทาในแต่ละหน้าต่าง ค่าเฉลี่ยของระดับค่าสีเทาหาได้จากสมการที่ 3.4

$$T = \frac{1}{N^2} \sum_{i=0}^N \sum_{j=0}^N I(i, j) \quad (3.4)$$

วิธีการ RAT นี้สามารถแก้ปัญหาที่เกิดขึ้นกับวิธี GT ได้ และยังคงรายละเอียดของลายนิ้วมือได้ดีกว่าวิธี GT ด้วย ในรูปที่ 3.6 แสดงภาพการแปลงลายนิ้วมือจากภาพระดับสีเทา เป็นภาพขาวดำ



รูปที่ 3.6 (a) ภาพลายนิ้วมือขาวดำที่ได้จากวิธี RAT (b) ภาพลายนิ้วมือขาวดำที่ได้จากวิธีการ GT

3.2.2.3 การปรับขนาดภาพ และการเลือกภาพลายนิ้วมือ

การปรับขนาดภาพงานวิจัยนี้เลือกใช้จุดซิงกูลาร์ที่หาได้จากขั้นตอนที่ 3.2.2.1 โดยหากจุดซิงกูลาร์ที่หาได้มีทั้งจุดคอร์ และจุดเคลตา งานวิจัยนี้จะเลือกใช้จุดคอร์เป็นจุดอ้างอิง แต่หากจุดซิงกูลาร์ที่หาได้มีเพียงจุดคอร์ หรือจุดเคลตา อย่างใดอย่างหนึ่ง จะเลือกจุดนั้นเป็นจุดอ้างอิง


เมื่อได้จุดซิงกูลาร์ที่ใช้เป็นจุดอ้างอิงแล้ว ทำการเลือกภาพในพื้นที่รอบจุดนี้ ขนาด 100×100 พิกเซล เป็นภาพที่ใช้งานจริง เนื่องจากบริเวณรอบจุดซิงกูลาร์เป็นบริเวณที่มีความสำคัญมาก (significance) มากที่สุด รูปที่ 3.7 เป็นตัวอย่างภาพลายนิ้วมือที่ไม่สามารถนำมาใช้งานได้



รูปที่ 3.7 (a) ภาพลายนิ้วมือที่ไม่สามารถหาจุดซิงกูลาร์ที่แน่นอนได้ (b) ภาพลายนิ้วมือที่จุดอ้างอิงน้อยกว่าขนาดที่กำหนด

3.2.2.4 การทำ thinning

การทำ thinning คือ การขจัดส่วนเกินที่ยื่นออกมาจากตัวเส้น ซึ่งทำให้ลายเส้นมีความเรียบมากขึ้น การทำ thinning ทำตามหลักการใน [15] ตัวอย่างภาพลายนิ้วมือที่ทำ thinning แล้วแสดงในรูปที่ 3.8



รูปที่ 3.8 (a) ภาพลายนิ้วมือต้นแบบ (b) ภาพลายนิ้วมือแบบขาวดำที่ทำ thinning แล้ว

3.2.3 การเตรียมข้อมูลภาพลายเซ็น

การเตรียมข้อมูลภาพลายเซ็นจำเป็นที่จะต้องทำ skeleton การตัดพื้นที่รอบข้างลายเซ็นที่ไม่ได้ใช้งาน รวมทั้งทำการปรับขนาดภาพลายเซ็นให้มีขนาดที่เท่ากันทั้งหมดด้วย การเตรียมข้อมูลลายเซ็นมีขั้นตอนต่างๆ ดังนี้

3.2.3.1 การนำภาพลายเซ็นเข้าคอมพิวเตอร์


ลายเซ็นทั้งหมดถูกเขียนบนกระดาษขนาด A4 สีขาว ในการนำภาพลายเซ็นเข้าคอมพิวเตอร์ที่งานวิจัยนี้เลือกใช้คือการใช้เครื่องสแกนเนอร์ การสแกนภาพใช้ความละเอียด 300 dpi และเลือกประเภทภาพเป็นภาพขาวดำ

3.2.3.2 การตัดขอบภาพ และการปรับขนาดภาพ

หลังจากที่เราทำการสแกนภาพลายเซ็นแล้ว ขั้นตอนถัดไปคือการตัดพื้นหลัง (background) รอบนอกในส่วนเกินจากลายเซ็น เพื่อให้ภาพมีขนาดที่พอดีกับลายเซ็น จากนั้นทำการปรับขนาดภาพให้มีขนาดเท่ากับ 100×150 พิกเซล เท่ากันทุกภาพ

3.2.3.3 การทำ skeleton

ขั้นตอนถัดมาคือการทำ skeleton เป็นการหาโครงสร้างในส่วนแกนกลางของลายเซ็น ในรูปที่ 3.9 (a) แสดงภาพตัวอย่างลายเซ็นต้นฉบับ และภาพ (b) เป็นภาพลายเซ็นที่ทำ pre-processing แล้ว



รูปที่ 3.9 (a) ภาพลายเซ็นต้นฉบับ (b) ภาพลายเซ็นที่ผ่านการทำ pre-processing แล้ว

3.3 การย้ายจุดศูนย์กลางอ้างอิง

การย้ายจุดศูนย์กลางอ้างอิง หรือการสแกน คือการย้ายจุดศูนย์กลางจากตำแหน่งจุดศูนย์กลางของภาพเดิม ไปยังตำแหน่งรอบๆ จุดศูนย์กลางนั้นใช้ควบคู่กับการเปรียบเทียบภาพในอัลกอริทึมที่นำเสนอ การย้ายตำแหน่งเพื่อให้เกิดความถูกต้องมากที่สุด หากภาพนั้นมีการเคลื่อนออกจากตำแหน่งจุดศูนย์กลางภาพ

การสแกนจะเกิดจากการกำหนดค่าพารามิเตอร์จากผู้ใช้โดยพารามิเตอร์ที่ใช้มีดังนี้

- จำนวนพิกเซลที่จะขยายออกไปจากจุดศูนย์กลางรูปภาพในแนวแกน x (x_area)
- จำนวนพิกเซลที่จะขยายออกไปจากจุดศูนย์กลางรูปภาพในแนวแกน y (y_area)
- จำนวนพิกเซลที่ข้ามเพื่อกำหนดจุดศูนย์กลางใหม่จุดถัดไป (step)

ตัวอย่างการหาจุดศูนย์กลาง เรากำหนดให้ $x_area = 6$, $y_area = 6$ step = 2 เราจะทำการขยายพื้นที่การพิจารณาดังนี้ ขยายไปทางด้านซ้าย และด้านขวาของจุดศูนย์กลางภาพ (x_area) เป็นจำนวนด้านละ 6 พิกเซล ขยายไปทางด้านบน และด้านล่างของจุดศูนย์กลางภาพ (y_area) เป็นจำนวนด้านละ 6 พิกเซล เราจะได้พื้นที่การพิจารณาขนาด 13×13 พิกเซล² จากนั้นให้ พิกเซล ซ้ายบนเป็นจุดศูนย์กลางใหม่ที่จะพิจารณา และทำการเลื่อนไปทางขวาอีก 2 พิกเซล (step) เพื่อกำหนดจุดศูนย์กลางใหม่ ทำไปจนครบพื้นที่การพิจารณา ด้วยวิธีนี้เราจะได้จุดศูนย์กลางใหม่ทั้งหมด 25 จุด ดังรูปที่ 3.10 เส้นสีดำทึบ คือขนาดภาพ จุดตรงกลาง คือจุดศูนย์กลางภาพ และจุดทั้ง 25 จุด คือจุดศูนย์กลางที่ใช้เพื่อการพิจารณา

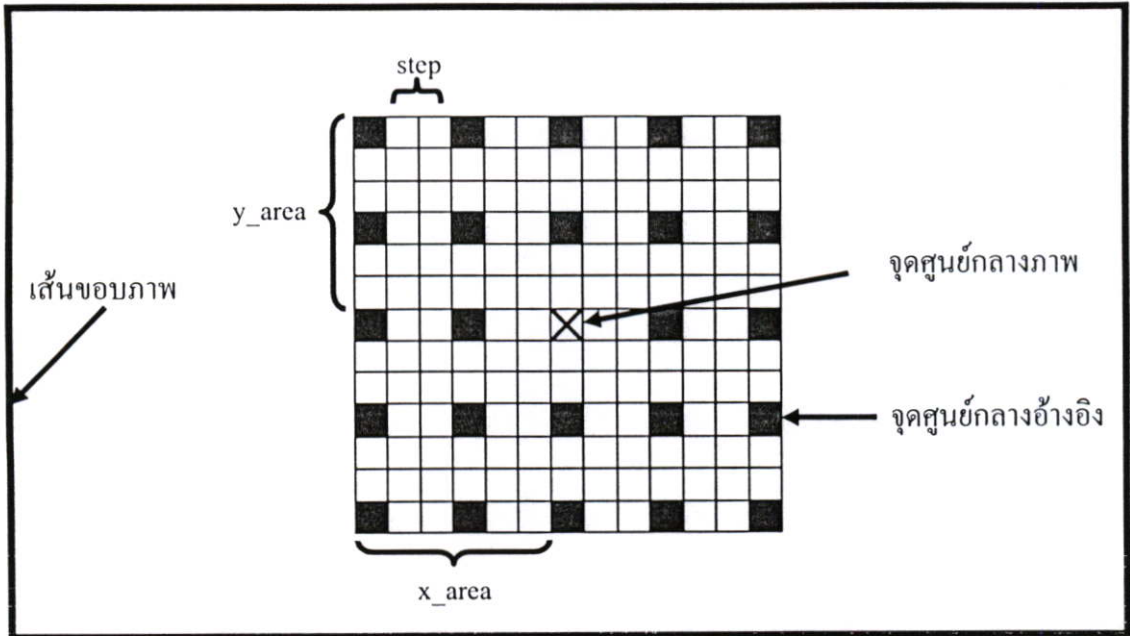
วิธีการคำนวณหาจำนวนจุดศูนย์กลาง สามารถหาได้ตามสมการนี้

$$c = \left[\left(2 \times \left(\frac{x_area}{(step + 1)} \right) \right) + 1 \right] \times \left[\left(2 \times \left(\frac{y_area}{(step + 1)} \right) \right) + 1 \right] \quad (3.5)$$


3.4 สถาปัตยกรรมของ Modified Hausdorff ARTMAP

กระบวนการการเรียนรู้นี้จะเป็นการนำเอาซิมพลิไฟด์ฟัซซีอาร์ทแมพมาใช้ โดยนำเอาฮาสูร์ฟดิสแทนซ์มาปรับใช้แทนการดำเนินการแบบฟัซซี (Fuzzy Operation) ในส่วนของอินพุทนั้นจะรับเข้าสู่โครงข่ายในรูปแบบของภาพสองมิติ (two-dimensional images) และภาพนั้นเป็นภาพขาวดำเท่านั้น (Binary Image)

วิธีการนี้ประกอบด้วย 3 ระดับชั้น ชั้นแรกคือชั้นอินพุท (Input Layer) ชั้นสองคือชั้นคลัสเตอร์ (Cluster Layer) ชั้นสุดท้ายคือชั้นเอาต์พุท (Output Layer)



รูปที่ 3.10 แสดงจุดศูนย์กลางใหม่ที่ถูกร่างขึ้นเพื่อใช้ในการเปรียบเทียบภาพ



รูปที่ 3.11 สถาปัตยกรรมของ Modified Hausdorff ARTMAP

ชั้นที่ 1 Input Layer มีขนาด M โหนด ซึ่งทำหน้าที่รับ input pattern ขนาด M มิติ

ชั้นที่ 2 Cluster Layer โหนดในชั้นนี้จะถูกสร้างขึ้นมาในระหว่างกระบวนการเรียนรู้ แต่ละโหนดใน Cluster Layer จะเชื่อมต่อแบบทั่วถึงกับทุกโหนดใน Input Layer โดยจะเชื่อมต่อผ่านทางค่าน้ำหนัก ซึ่งค่าน้ำหนักจะมีขนาดไม่แน่นอน แต่จะมีขนาดใหญ่ไม่เกินขนาดภาพของ input pattern และค่าน้ำหนักนี้จะเป็นตัวแทนของรูปแบบอ้างอิงใน Cluster Layer

ชั้นที่ 3 Output Layer แต่ละโหนดในชั้นนี้จะเป็นตัวแทนแสดงแต่ละประเภท หรือชนิด (class) เนื่องจากกระบวนการเรียนรู้นี้เป็นแบบ supervised ดังนั้นคำตอบจะถูกส่งเข้าไปในโครงข่ายพร้อมกับอินพุต นั่นก็คือชนิดของรูปแบบอินพุต (target output vector) นั่นเอง โดยคำตอบที่ถูกส่งเข้าไปในโครงข่ายจะถูกส่งเข้าไปเฉพาะช่วงของการเรียนรู้เท่านั้น

ค่าน้ำหนักในกระบวนการนี้จะใช้ในลักษณะโมเดลอ้างอิง (Reference Model) โดยต้องการสร้างโมเดลให้ครอบคลุม และเป็นตัวแทนกลุ่มที่ดีของกลุ่มข้อมูล โดยขนาดของโมเดลนั้นสามารถที่จะขยายได้จากขนาดที่กำหนดไว้ และจากแนวคิดที่ต้องการให้ลำดับในการรู้จำไม่มีผลต่อผลการทดลองจึงได้เพิ่มส่วนของการหาตัวแทนกลุ่มด้วย

3.5 กระบวนการเรียนรู้

การเรียนรู้ของกระบวนการนี้ใช้ input pattern เป็นแบบขาค่า (I^m) ซึ่งเป็นลักษณะของโครงสร้างโดยรวม ที่ถูกส่งเข้ามาในระบบสามารถแสดงได้ดังนี้

$$I_{x,y}^m = \{1,0\}, x = 1,2,\dots,X, y = 1,2,\dots,Y \quad (3.6)$$

เมื่อ I คือ รูปภาพของลักษณะ โครงสร้างโดยรวม

m คือ ลำดับของ input pattern ที่ถูกส่งไปยังโครงข่าย

X และ Y คือจำนวนพิกเซล ตามแนวแกน x และแกน y ของรูปภาพที่นำเข้ามาเป็นอินพุตของระบบ

ในระหว่างกระบวนการเรียนรู้ input pattern จะถูกแบ่งเป็น 2 กลุ่ม คือ (1) กลุ่มของคลาสที่กำลังพิจารณา และ (2) กลุ่มของคลาสที่อยู่นอกการพิจารณา หมายถึง กลุ่มของคลาสที่เหลือที่ไม่ได้อยู่ในกลุ่มที่ 1 การแบ่งกลุ่มนี้เพื่อต้องการให้ลำดับของ input pattern ไม่มีผลกระทบต่อลักษณะของโครงข่าย

กระบวนการเรียนรู้ของวิธีการนี้มีขั้นตอน ดังนี้

1. สร้างเซตของ input pattern P และ Q

กำหนดให้ P เป็นเซตของ input pattern ทั้งหมดที่เป็นสมาชิกของคลาสที่กำลังพิจารณา

$$P = \{P_j\} = \{I^m \mid I^m \in A\} \quad (3.7)$$

เมื่อ $j = 1, 2, \dots, c$ คือ อินเด็กซ์ของ input pattern ในเซต P

A คือ คลาสที่กำลังพิจารณา

c คือ จำนวน input pattern ที่เป็นสมาชิกของคลาส A

กำหนดให้ Q เป็นเซตของ input pattern ทั้งหมดที่เป็นสมาชิกของคลาสที่อยู่นอกการพิจารณา

$$Q = \{Q_c\} = \{I^m \mid I^m \in B\} \quad (3.8)$$

เมื่อ $c = 1, 2, \dots, d$ คือ อินเด็กซ์ของ input pattern ในเซต Q

B คือ คลาสที่อยู่นอกการพิจารณา

d คือ จำนวน input pattern ที่เป็นสมาชิกของคลาส B

2. สร้าง reference pattern

ขั้นตอนการหา reference pattern มีกระบวนการการย้ายจุดศูนย์กลาง ดังที่กล่าวไว้แล้วในบทที่ 3

ขั้นตอนการสร้าง reference pattern นี้พยายามหาตัวแทนที่ดีที่สุดของรูปแบบที่กำลังพิจารณา ซึ่งจะทำการพิจารณา input pattern ทั้งหมดในเซต P และเซต Q โดยใจความสำคัญของขั้นตอนนี้คือ พยายามหา reference pattern ที่มีความเหมือนกันมากที่สุดในกลุ่มที่กำลังพิจารณา ในขณะที่เดียวกันต้องมีความแตกต่างกับกลุ่มนอกการพิจารณามากที่สุดด้วย ในการสร้าง reference pattern มีขั้นตอนย่อย 2 ขั้นตอนดังนี้

2.1 หา reference pattern ในเซต P

ขั้นตอนนี้จะเป็นการเปรียบเทียบรูปแบบกันภายในกลุ่ม เพื่อหาตัวแทนกลุ่มที่มีความเหมือนกันมากที่สุด โดยการเปรียบเทียบหาได้จาก

$$d_i = \min_{j=1}^c (\min_{n=1}^c (H(w_i, P_j))) \quad (3.9)$$

เมื่อ i คือ อินเด็กซ์ของ reference pattern โดยที่ $i = 1, 2, \dots, c$

$n = 1, 2, \dots, c$

c = จำนวนจุดศูนย์กลางที่ใช้เพื่อพิจารณา

$j = 1, 2, \dots, c$

$i \neq j$

d คือ ค่าความเหมือนที่หาได้

$H(w_i, P_j)$ คือค่าฮาอูคอรฟ์ดิสแทนซ์ระหว่าง reference pattern w_i กับ input pattern P_j

w คือ reference pattern ของ P โดยที่ในตอนแรกนั้นขนาดของ reference pattern จะมีขนาดเท่ากับที่ผู้ใช้ได้กำหนดไว้

จากนั้นนำค่า d_i มาพิจารณาความคล้ายคลึงตามเงื่อนไข

$$d_i \leq \rho_{\text{similar}} \quad (3.10)$$

ค่า ρ_{similar} จะมีค่าระหว่าง 0 ถึงความยาวของเส้นทแยงมุมของ reference pattern ในขนาดปัจจุบัน ซึ่งในกระบวนการนี้ค่า ρ_{similar} หมายถึง ค่าความคล้ายคลึงกันของ reference pattern กับ P_j กรณี (3.10) เป็นจริง ให้ทำข้อ 2.2 ต่อ แต่หาก (3.10) เป็นเท็จจะทำข้อ 2.1 ซ้ำ โดยเพิ่มขนาดของ reference pattern ด้วย การเพิ่มขนาดนั้นจะเพิ่มขนาดให้ใหญ่ขึ้นตามที่กำหนดไว้ และขนาดที่ได้จะมีขนาดไม่ใหญ่เกินขนาดของ input pattern นั้น

2.2 ตรวจสอบความคล้ายคลึงที่น้อยพอของ reference pattern กับ Q

ขั้นตอนนี้จะนำเอา reference pattern ที่ได้จากข้อ 2.1 มาหาค่าความเหมือน โดยเปรียบเทียบกับทุกๆ input pattern ใน Q โดยหาได้จาก

$$dO_i = \min_{k=1}^d (\min_{n=1}^c (H(w_i, Q_k))) \quad (3.11)$$

เมื่อ i คือ อินเด็กซ์ของ reference pattern โดยที่ $i = 1, 2, \dots, c$

$k = 1, 2, \dots, d$

dO คือ ค่าความเหมือนที่หาได้

$H(w_i, Q_k)$ คือค่าฮาอูคอรฟ์ดิสแทนซ์ระหว่าง reference pattern เปรียบเทียบกับทุกๆ input pattern ใน Q

จากนั้นนำค่า dO_i มาพิจารณาตามเงื่อนไขนี้

$$dO_i > \rho_{\text{dissimilar}} \quad (3.12)$$

ค่า $\rho_{\text{dissimilar}}$ จะมีค่าระหว่าง 0 ถึงความยาวของเส้นทแยงมุมของ reference pattern ซึ่งในกระบวนการนี้ค่า $\rho_{\text{dissimilar}}$ หมายถึง ค่าความแตกต่างของ reference pattern เมื่อเทียบกับทุกๆ input pattern ใน Q กรณี (3.12) เป็นเท็จให้ย้อนกลับไปทำข้อ 2.1 ใหม่ โดยเพิ่มขนาดของ reference pattern ที่กำลังพิจารณาด้วย หาก (3.12) เป็นจริง reference pattern ที่ได้จะเป็นตัวแทนของ input pattern ปัจจุบัน และทำการหา reference pattern ของ input pattern ถัดไปจนกว่าจะครบทุก input pattern ใน P

3. สร้างเวกเตอร์แสดงการเป็นสมาชิก

ขั้นตอนนี้จะเป็นการบอกว่า reference pattern ที่หาได้มีความสามารถมากพอที่จะเป็นตัวแทนของ reference pattern อื่นได้หรือไม่ โดยนำเอา reference pattern ที่ได้ทั้งหมดมาหาค่าฮาอูคอรฟ์ดิสแทนซ์เทียบกับทุก input pattern ใน P โดยหาได้จาก

$$dD_{ij} = \min(H(w_i, P_j)) \quad (3.13)$$

เมื่อ dD คือ ค่าความเหมือนที่หาได้

$$i = 1, 2, \dots, c$$

$$j = 1, 2, \dots, c$$

$H(w_i, P_j)$ คือ ค่าฮาอูคอรฟ์ดิสแทนซ์ระหว่าง reference pattern w_i เปรียบเทียบกับทุกๆ input pattern ใน P

แล้วนำมาเปรียบเทียบกับค่า ρ_{similar} โดยการเปรียบเทียบนี้จะบอกถึงความสามารถของ reference pattern ที่หาได้ในการเป็นตัวแทนแทน input pattern ในเซต P ซึ่งการเก็บค่าการแสดงเป็นสมาชิกจะเป็นไว้ในเวกเตอร์ M ที่มีขนาดเท่ากับจำนวนของ input pattern ในเซต P โดยเวกเตอร์ M เป็นไบนารีเวกเตอร์ที่มีค่าเฉพาะ 0 และ 1 เท่านั้น ซึ่ง 0 หมายถึงการไม่เป็นสมาชิก และ 1 หมายถึงการเป็นสมาชิก ตามเงื่อนไขดังนี้

$$M(i, g) = \begin{cases} 1, & \text{if } dD_{ij} \leq \rho_{\text{similar}} \\ 0, & \text{otherwise} \end{cases} \quad (3.14)$$

เมื่อ $M(i, g)$ คือ เวกเตอร์แสดงการเป็นสมาชิกสำหรับ reference pattern w_i

4. เลือก reference pattern ที่เหมาะสม

จากข้อ 3. ทำให้เราทราบว่า reference pattern ตัวใดสามารถเป็นตัวแทนที่ดีที่สุด ซึ่งในขั้นตอนนี้จะทำการหา reference model ของโครงข่ายจาก reference pattern ที่หาได้ โดยใจความสำคัญของขั้นตอนนี้คือ หา reference model ที่สามารถเป็นตัวแทนของ input pattern ใน P ที่กำลังพิจารณาได้ โดยมีข้อจำกัดในการเลือกคือ เลือกจำนวน reference model ให้ได้จำนวนน้อยที่สุดที่สามารถครอบคลุมได้ทุก input pattern ใน P

reference model จะถูกเลือกทีละตัว โดยมีลำดับในการเลือกซึ่งพิจารณาตามเงื่อนไขต่อไปนี้

- เลือก reference pattern ที่ครอบคลุมจำนวนสมาชิกมากที่สุด
- เลือก reference pattern ที่ให้ค่าฮาอูคอร์ดฟิสแทนซ์น้อยที่สุด

โดยจะให้ความสำคัญกับเงื่อนไขแรกมากกว่า หากพบว่า reference pattern มากกว่า 1 ตัวที่เป็นไปตามเงื่อนไขแรก ก็จะพิจารณาเงื่อนไขถัดมา และขั้นตอนจะสิ้นสุดลงเมื่อสามารถหา reference model ครอบคลุมสมาชิกทั้งหมดในเซต P

วิธีการเลือก reference model ที่เหมาะสม สามารถเขียนได้ดังนี้

1. เลือก reference pattern ที่ครอบคลุมสมาชิกมากที่สุด เพื่อเป็น reference model ตัวแรก
2. ตรวจสอบ reference pattern ที่ถูกเลือก หากครอบคลุมสมาชิกทุกตัวแล้วให้สิ้นสุดการหา reference model แต่หากยังไม่ครอบคลุมสมาชิกทุกตัวให้หา reference pattern ตัวอื่นที่ทำให้การครอบคลุมจำนวนสมาชิกมากขึ้นเมื่อรวมกับจำนวนสมาชิกที่ได้จากข้อ 1 หากการหา reference pattern ในข้อนี้ได้ reference pattern 1 reference pattern ให้ reference pattern นั้นเป็น reference model แทนที่ แต่หากได้มากกว่า 1 ตัวให้ดำเนินการข้อ 3
3. ตรวจสอบค่าฮาอูคอร์ดฟิสแทนซ์ของ reference pattern ที่ได้จากกระบวนการเรียนรู้ข้อ 2.1 จากนั้นเลือก reference pattern ที่ให้ค่าฮาอูคอร์ดฟิสแทนซ์น้อยที่สุด เป็น reference model
4. ตรวจสอบความครอบคลุมสมาชิก หากครอบคลุมสมาชิกครบทุกตัวแล้วให้สิ้นสุดการหา reference model แต่หากยังไม่ครอบคลุมครบให้วนกลับไปทำข้อ 1 จนกว่าจะครอบคลุมสมาชิกทุกตัว

ตัวอย่างการเลือก reference pattern ที่เหมาะสม

จากข้อ 3. เราจะได้เวกเตอร์แสดงการเป็นสมาชิกดังตารางที่ 3.1 โดยในตัวอย่างมี input pattern จำนวน 3 pattern ในคลาสที่กำลังพิจารณาอยู่

ตารางที่ 3.1 ตัวอย่างเวกเตอร์แสดงการเป็นสมาชิก

	input pattern no. 1	input pattern no. 2	input pattern no. 3
ref. pattern no. 1	1	1	0
ref. pattern no. 2	0	1	0
ref. pattern no.3	0	0	1

จากตารางที่ 3.1 การพิจารณาในครั้งแรกจะพิจารณา reference pattern ที่ครอบคลุมจำนวนสมาชิกมากที่สุดก่อน ดังนั้นระบบจะเลือก reference pattern no. 1 เป็น reference model ตัวแรก ระบบจะทำการเลือก reference pattern ตัวถัดไป โดย reference pattern no. 3 จะถูกเลือกเป็น reference model ตัวที่สอง เนื่องจาก reference pattern no.3 นี้ทำให้ความครอบคลุมสมาชิกของ reference model เพิ่มมากขึ้น จากนั้นระบบจะทำการเลือก reference model ตัวถัดไป แต่เนื่องจากในตัวอย่างนี้ reference model ที่หาได้สามารถครอบคลุมจำนวนสมาชิกทั้งหมดแล้ว ดังนั้นขั้นตอนการเลือก reference pattern ที่เหมาะสมสำหรับตัวอย่างนี้จะได้ reference model จำนวน 2 ตัว

5. กำหนดให้ reference model เป็น model ของโครงข่าย

จากข้อ 4 เราจะได้ reference model ที่สามารถเป็นตัวแทน input pattern ทุกตัวในเซต P จากนั้นทำการกำหนดให้ reference model ที่ได้เป็น model ของโครงข่าย โดยมีชนิดของคลาสเป็นชนิดเดียวกับคลาสที่กำลังพิจารณาอยู่

6. วนซ้ำ

วนซ้ำข้อ 1 ถึงข้อ 5 กับคลาสอื่น จนกระทั่งครบทุกคลาส

บทที่ 4

การทดลอง และผลการทดลอง

ข้อมูลภาพที่ใช้ในงานวิจัยชิ้นนี้มี 3 ประเภท ประกอบด้วย ข้อมูลภาพใบหน้า ข้อมูลภาพลายนิ้วมือ และข้อมูลภาพลายเซ็น โดยข้อมูลภาพทั้ง 3 ประเภทจะถูกนำเข้าสู่กระบวนการเตรียมข้อมูลก่อน จากนั้นข้อมูลจะถูกนำเข้าสู่กระบวนการเรียนรู้ของ Modified Hausdorff ARTMAP ดังที่กล่าวไว้ในบทที่ 3

4.1 พารามิเตอร์ที่ใช้ในการทดลอง

การทดลองด้วย Modified Hausdorff ARTMAP มีพารามิเตอร์หลายตัวประกอบด้วย

- similar_vigilance คือ ค่า threshold ค่าหนึ่งบอกถึงค่าความแตกต่างที่สามารถยอมรับได้ หากค่าความเหมือนที่หาได้จากการเปรียบเทียบในกระบวนการเรียนรู้มีค่าน้อยกว่าค่า similar_vigilance แสดงว่ามีความเหมือนกันมากเพียงพอ
- dissimilar_vigilance คือ ค่า threshold ค่าหนึ่งที่บอกถึงค่าความแตกต่างที่สามารถยอมรับได้ หากค่าความเหมือนที่หาได้จากการเปรียบเทียบในกระบวนการเรียนรู้มีค่ามากกว่าค่า dissimilar_vigilance แสดงว่ามีความแตกต่างกันมากเพียงพอ
- x_size คือค่าขนาดความยาวของ reference pattern ในตอนเริ่มต้นของการเรียนรู้ในแต่ละ input pattern
- y_size คือค่าขนาดความกว้างของ reference pattern ในตอนเริ่มต้นของการเรียนรู้ในแต่ละ input pattern
- step คือจำนวนพิกเซลที่ข้ามเพื่อกำหนดจุดศูนย์กลางใหม่จุดถัดไป
- x_area คือพื้นที่ในแนวแกน x ที่ใช้ในการสแกน ในแต่ละด้านของจุดศูนย์กลางภาพ
- y_area คือพื้นที่ในแนวแกน y ที่ใช้ในการสแกน ในแต่ละด้านของจุดศูนย์กลางภาพ

4.2 การทดลอง และผลการทดลองการรู้จำภาพใบหน้าด้วย Modified Hausdorff ARTMAP

งานวิจัยชิ้นนี้เลือกใช้ภาพใบหน้าที่เป็นมาตรฐานจำนวน 2 ชุดข้อมูล คือ ชุดข้อมูลใบหน้า ORL [16] และชุดข้อมูลใบหน้า Yale [17]


4.2.1 การทดลอง และผลการทดลองการรู้จำภาพใบหน้าฐานข้อมูล ORL

4.2.1.1 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล ORL ด้วย Modified Hausdorff ARTMAP

ภาพใบหน้าในฐานข้อมูล ORL [16] ประกอบด้วยภาพใบหน้าบุคคล 40 คน คนละ 10 ภาพ ทั้งหมดเป็นภาพระดับสีเทา ขนาด 92×112 พิกเซล โดยแต่ละภาพมีการให้แสงในตำแหน่งแตกต่างกัน และมีการแสดงสีหน้าแตกต่างกัน เช่น ภาพยิ้มตา ภาพหลับตา ภาพขมึ้ม ภาพสวมแว่นตา หลังจากกระบวนการเตรียมข้อมูลภาพทั้งหมดถูกเปลี่ยนจากภาพระดับสีเทาเป็นภาพขาวดำ และขนาดของภาพถูกปรับขนาดเท่ากับ 100×100 พิกเซล งานวิจัยนี้ใช้ภาพในการเรียนรู้คนละ 4 ภาพ และใช้ในการทดสอบหาอัตราความถูกต้องคนละ 6 ภาพ รวมภาพที่ใช้เรียนรู้ทั้งหมด 160 ภาพ และใช้ในการทดสอบทั้งหมด 240 ภาพ โดยรูปที่ 4.1 แสดงตัวอย่างภาพใบหน้าฐานข้อมูล ORL ตารางที่ 4.1 แสดงหมายเลขภาพของแต่ละบุคคลที่ใช้ในการเรียนรู้ ตารางที่ 4.2 แสดงผลการทดลองระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

ตารางที่ 4.3 แสดงผลการทดลอง ซึ่งผลการทดลองใช้พารามิเตอร์ดังนี้

- similar_vigilance = 0.7
- dissimilar_vigilance = 1.5
- x_size = 73
- y_size = 73
- step = 6
- x_area = 6
- y_area = 6



รูปที่ 4.1 (a) แสดงภาพต้นฉบับภาพใบหน้าฐานข้อมูล ORL (b) แสดงภาพที่ผ่านกระบวนการเตรียมข้อมูลแล้ว

ตารางที่ 4.1 ตารางแสดงหมายเลขภาพใบหน้าที่ใช้ในการเรียนรู้

บุคคล	ภาพใบหน้าที่ใช้เรียนรู้
1	2, 3, 6, 8
2	12, 14, 15, 16
3	21, 22, 25, 28
4	31, 32, 34, 40
5	42, 43, 46, 50
6	51, 56, 57, 59
7	61, 63, 64, 70
8	73, 76, 79, 80
9	83, 87, 89, 90

ตารางที่ 4.1 (ต่อ)

บุคคล	ภาพใบหน้าที่ใช้เรียนรู้
10	94, 98, 99, 100
11	102, 104, 105, 110
12	113, 116, 117, 118
13	124, 126, 128, 130
14	131, 133, 139, 140
15	142, 144, 145, 148
16	157, 158, 159, 160
17	164, 165, 167, 170
18	172, 175, 176, 177
19	183, 184, 186, 188
20	191, 194, 198, 200
21	204, 205, 207, 210
22	212, 214, 216, 218
23	225, 227, 229, 230
24	231, 233, 237, 238
25	241, 242, 248, 249
26	252, 253, 254, 257
27	261, 262, 267, 270
28	272, 274, 276, 280
29	282, 285, 288, 289
30	293, 294, 295, 296
31	302, 307, 308, 310
32	311, 314, 317, 318
33	321, 325, 326, 328
34	331, 334, 337, 338
35	342, 343, 346, 349
36	352, 355, 357, 360
37	361, 366, 367, 370
38	376, 377, 378, 379
39	382, 384, 385, 390

ตารางที่ 4.1 (ต่อ)

บุคคล	ภาพใบหน้าที่ใช้เรียนรู้
40	392, 393, 397, 400
รวม	160

ตารางที่ 4.2 ผลการทดสอบการรู้จำภาพใบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

จำนวน reference pattern	จำนวนข้อมูลที่ใช้ในการเรียนรู้	ค่าความถูกต้อง (%)	จำนวนภาพที่ตอบผิด
152	160	100.00	-

ตารางที่ 4.3 ผลการทดสอบการรู้จำภาพใบหน้าฐานข้อมูล ORL

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
1	6	4	2	16, 30
2	6	6	-	-
3	6	4	2	38, 40
4	6	5	1	17
5	6	6	-	-
6	6	6	-	-
7	6	6	-	-
8	6	6	-	-
9	6	6	-	-
10	6	6	-	-
11	6	6	-	-
12	6	6	-	-
13	6	6	-	-
14	6	6	-	-
15	6	6	-	-
16	6	6	-	-
17	6	6	-	-
18	6	6	-	-

ตารางที่ 4.3 (ต่อ)

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
19	6	6	-	-
20	6	6	-	-
21	6	6	-	-
22	6	6	-	-
23	6	3	3	9, 38, 39
24	6	6	-	-
25	6	6	-	-
26	6	6	-	-
27	6	6	-	-
28	6	6	-	-
29	6	6	-	-
30	6	6	-	-
31	6	6	-	-
32	6	6	-	-
33	6	6	-	-
34	6	6	-	-
35	6	6	-	-
36	6	6	-	-
37	6	6	-	-
38	6	6	-	-
39	6	6	-	-
40	6	6	-	-
รวม	240	232	8	-
เปอร์เซ็นต์		96.67	3.33	-











4.2.1.2 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล ORL ด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP [1]

ผลการทดลองจากตารางที่ 4.3 Modified Hausdorff ARTMAP ให้ค่าความถูกต้อง 96.67 % โดยจำนวนโหนดที่ถูกรูปร่างใน Cluster Layer มีจำนวนเท่ากับ 152 โหนด ซึ่งขนาดของ






reference pattern ในตอนเริ่มต้นการเรียนรู้มีขนาดเท่ากับ 73×73 พิกเซล แต่เมื่อเสร็จสิ้นกระบวนการเรียนรู้ ขนาดของ reference pattern มีขนาดเท่ากับ 83×83 พิกเซล จำนวน 152 โหนด ตารางที่ 4.4 แสดงภาพใบหน้าที่ใช้ในการทดสอบ และภาพใบหน้าที่ตอบผิด รวมทั้งระยะทางที่หาได้จากภาพใบหน้าที่ตอบผิด และภาพใบหน้าในกลุ่มเดียวกัน

ผลการทดลองของ Hausdorff ARTMAP [1] ให้ค่าความถูกต้องระหว่าง 94.17-95.42 % จำนวนโหนดใน Cluster Layer มีจำนวน 152-153 โหนด ค่าความถูกต้อง และจำนวนโหนดที่ได้นั้นขึ้นอยู่กับลำดับของ input pattern ที่เข้าสู่กระบวนการเรียนรู้ โดยขนาดของ reference pattern ถูกกำหนดไว้ที่ขนาด 100×100 พิกเซล ซึ่งมีขนาดเท่ากับขนาดของ input pattern

ตารางที่ 4.4 ตารางแสดงภาพใบหน้า และระยะทางของใบหน้าที่ตอบผิดกลุ่มของฐานข้อมูล ORL

กลุ่มของภาพที่ทดสอบ	ภาพที่ทดสอบ	กลุ่มของภาพที่ตอบผิด	ภาพที่ตอบผิด	ระยะทางของภาพที่ตอบผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
1		18		1.1167	1.4204
1		30		1.3113	1.4068
3		40		1.0718	1.4627
3		38		1.0438	1.6214
4		17		1.7600	4.3837

ตารางที่ 4.4 (ต่อ)

กลุ่มของ ภาพที่ ทดสอบ	ภาพที่ทดสอบ	กลุ่มของ ภาพที่ตอบ ผิด	ภาพที่ตอบผิด	ระยะทางของ ภาพที่ตอบผิด	ระยะทางของ ภาพที่น้อยที่สุด ในกลุ่มเดียวกัน
23		38		0.8719	1.0514
23		9		1.2550	1.5028
23		39		1.4210	1.5657


4.2.2 การทดลอง และผลการทดลองการรู้จำภาพใบหน้าฐานข้อมูล Yale

4.2.2.1 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล Yale ด้วย Modified Hausdorff ARTMAP

ภาพใบหน้าในฐานข้อมูล Yale [17] ประกอบด้วยภาพใบหน้าบุคคล 15 คน คนละ 11 ภาพ ทั้งหมดเป็นภาพระดับสีเทา ขนาด 320×243 พิกเซล โดยแต่ละภาพมีการให้แสงในตำแหน่งแตกต่างกัน และมีการแสดงสีหน้าแตกต่างกัน ได้แก่ ภาพที่มีแสงเข้าจากตรงกลาง (center-light) ภาพสวมแว่นตา (w/glasses) ภาพใบหน้าที่มีความสุข (happy) ภาพที่แสงเข้าจากทางด้านซ้าย (left-light) ภาพใบหน้าที่ไม่สวมแว่นตา (w/no glasses) ภาพใบหน้าในอารมณ์ปกติ (normal) ภาพที่แสงเข้าทางด้านขวา (right-light) ภาพใบหน้าที่แสดงอารมณ์เศร้า (sad) ภาพหลับตา (sleepy) ภาพใบหน้าที่แสดงความประหลาดใจ (surprised) และภาพใบหน้าที่กำลังขยิบตา (wink) หลังจากกระบวนการเตรียมข้อมูลภาพทั้งหมดถูกเปลี่ยนจากภาพระดับสีเทาเป็นภาพขาวดำ และขนาดของภาพถูกปรับขนาดเท่ากับ 100×100 พิกเซล งานวิจัยนี้ใช้ภาพในการเรียนรู้คนละ 6 ภาพ และใช้ในการทดสอบหาอัตราความถูกต้องคนละ 5 ภาพ รวมภาพที่ใช้ในการเรียนรู้ทั้งหมด 90 ภาพ และใช้ในการทดสอบทั้งหมด 75 ภาพ โดยรูปที่ 4.2 แสดงตัวอย่างภาพใบหน้าฐานข้อมูล Yale ตารางที่ 4.5 แสดงประเภทภาพของแต่ละบุคคลที่ใช้ในการเรียนรู้ ตารางที่ 4.6 แสดงผลการทดลองระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

ตารางที่ 4.7 แสดงผลการทดลอง ซึ่งผลการทดลองใช้พารามิเตอร์ดังนี้

- similar_vigilance = 0.5
- dissimilar_vigilance = 1.1
- x_size = 73
- y_size = 73
- step = 2
- x_area = 2
- y_area = 2



รูปที่ 4.2 (a) แสดงภาพต้นฉบับภาพใบหน้าฐานข้อมูล Yale (b) แสดงภาพที่ผ่านกระบวนการเตรียมข้อมูลแล้ว

ตารางที่ 4.5 ตารางแสดงประเภทภาพใบหน้าที่ใช้ในการเรียนรู้

บุคคลที่	ภาพที่ใช้ในการเรียนรู้
1	center-light, happy, w/no glasses, sad, surprised, wink
2	center-light, left-light, w/no glasses, normal, surprised, wink
3	center-light, w/glasses, left-light, right-light, surprised, wink
4	happy, left-light, w/no glasses, normal, right-light, sleepy
5	w/glasses, happy, left-light, w/no glasses, right-light, sleepy

ตารางที่ 4.5 (ต่อ)

บุคคลที่	ภาพที่ใช้ในการเรียนรู้
6	center-light, w/glasses, left-light, w/no glasses, surprised, wink
7	center-light, w/glasses, happy, left-light, right-light, sleepy
8	center-light, w/glasses, left-light, normal, right-light, sad
9	center-light, w/glasses, left-light, normal, right-light, sad
10	center-light, w/glasses, normal, right-light, sad, wink
11	center-light, left-light, w/no glasses, right-light, sleepy, wink
12	center-light, w/glasses, happy, left-light, right-light, surprised
13	center-light, w/glasses, w/no glasses, normal, sad, sleepy
14	w/glasses, happy, left-light, w/no glasses, sad, sleepy
15	center-light, left-light, w/no glasses, normal, right-light, surprised
รวม	90

ตารางที่ 4.6 ผลการทดลองการรู้จำภาพใบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

จำนวน reference pattern	จำนวนข้อมูลที่ใช้ในการเรียนรู้	ค่าความถูกต้อง (%)	จำนวนภาพที่ตอบผิด
36	90	96.67	3

ตารางที่ 4.7 ผลการทดลองการรู้จำภาพใบหน้าฐานข้อมูล Yale

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
1	5	5	-	-
2	5	4	1	12
3	5	5	-	-
4	5	5	-	-
5	5	5	-	-
6	5	5	-	-
7	5	5	-	-
8	5	5	-	-
9	5	5	-	-

ตารางที่ 4.7 (ต่อ)

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
10	5	5	-	-
11	5	5	-	-
12	5	5	-	-
13	5	5	-	-
14	5	5	-	-
15	5	5	-	-
รวม	75	74	1	-
เปอร์เซ็นต์		98.67	1.33	-

4.2.2.2 ผลการทดลองการรู้จำลายภาพใบหน้าฐานข้อมูล Yale ด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP [1]

ผลการทดลองจากตารางที่ 4.7 Modified Hausdorff ARTMAP ให้ค่าความถูกต้อง 98.67 % โดยจำนวนโหนดที่ถูกสร้างใน Cluster Layer มีจำนวนเท่ากับ 36 โหนด ซึ่งขนาดของ reference pattern ในตอนเริ่มต้นการเรียนรู้มีขนาดเท่ากับ 73×73 พิกเซล แต่เมื่อเสร็จสิ้นกระบวนการเรียนรู้ ขนาดของ reference pattern มีขนาดเท่ากับ 93×93 พิกเซล จำนวน 35 โหนด และขนาด 88×88 พิกเซล จำนวน 1 โหนด ตารางที่ 4.8 แสดงภาพใบหน้าที่ใช้ในการทดสอบ และภาพใบหน้าที่ตอบผิด รวมทั้งระยะทางที่หาได้จากภาพใบหน้าที่ตอบผิด และภาพใบหน้าในกลุ่มเดียวกัน

ผลการทดลองของ Hausdorff ARTMAP [1] ให้ค่าความถูกต้องอยู่ระหว่าง 86.67-96.00 % จำนวนโหนดใน Cluster Layer มีจำนวน 35-43 โหนด ค่าความถูกต้อง และจำนวนโหนดที่ได้ นั้นขึ้นอยู่กับลำดับของ input pattern ที่เข้าสู่กระบวนการเรียนรู้ โดยขนาดของ reference pattern ถูกกำหนดไว้ที่ขนาด 100×100 พิกเซล ซึ่งมีขนาดเท่ากับขนาดของ input pattern

ตารางที่ 4.8 ตารางแสดงภาพใบหน้า และระยะทางของใบหน้าที่ตอบผิดกลุ่มของฐานข้อมูล Yale

กลุ่มของ ภาพที่ ทดสอบ	ภาพที่ทดสอบ	กลุ่มของ ภาพที่ตอบ ผิด	ภาพที่ตอบผิด	ระยะทางของ ภาพที่ตอบผิด	ระยะทางของ ภาพที่น้อยที่สุด ในกลุ่มเดียวกัน
2		12		0.5657	0.8326


4.3 การทดลอง และผลการทดลองการรู้จำลายนิ้วมือ

4.3.1 ผลการทดลองการรู้จำลายนิ้วมือด้วย Modified Hausdorff ARTMAP

งานวิจัยชิ้นนี้ใช้ข้อมูลลายนิ้วมือ FINGDB [13] ประกอบด้วยภาพลายนิ้วมือนิ้วหัวแม่มือของบุคคล 21 คน คนละ 8 ภาพ ทั้งหมดเป็นภาพระดับสีเทา ขนาด 256×256 พิกเซล หลังจากกระบวนการเตรียมข้อมูลมีขั้นตอนการแปลงภาพจากภาพระดับสีเทาเป็นภาพขาวดำ มีขั้นตอนการหาจุดซิงกูลาร์ และมีการปรับขนาดภาพให้มีขนาดเท่ากับ 100×100 พิกเซล กระบวนการเตรียมข้อมูลนี้ทำให้ภาพที่บางภาพไม่สามารถใช้ในการเรียนรู้ได้ เนื่องจากการหาจุดซิงกูลาร์ไม่ได้ หรือเนื่องจากมีขนาดของภาพไม่ได้ตามขนาดที่กำหนดไว้ ทำให้ภาพลายนิ้วมือที่สามารถใช้ในการเรียนรู้ได้มีจำนวน 138 ภาพ โดยหมายเลขภาพลายนิ้วมือที่สามารถใช้ในการเรียนรู้ และหมายเลขภาพที่ใช้ในการทดสอบ แสดงไว้ในตารางที่ 4.9 และรูปที่ 4.3 แสดงตัวอย่างภาพลายนิ้วมือฐานข้อมูล FINGDB 4.10 แสดงผลการทดลองระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

ตารางที่ 4.11 แสดงผลการทดลอง ซึ่งผลการทดลองใช้พารามิเตอร์ดังนี้

- similar_vigilance = 0.9
- dissimilar_vigilance = 1.1
- x_size = 73
- y_size = 73
- step = 3
- x_area = 6
- y_area = 6



รูปที่ 4.3 (a) แสดงภาพต้นฉบับภาพลายนิ้วมือฐานข้อมูล FINGDB (b) แสดงภาพที่ผ่านกระบวนการเตรียมข้อมูลแล้ว

ตารางที่ 4.9 ตารางแสดงหมายเลขภาพลายนิ้วมือที่ใช้ในการเรียนรู้ และการทดสอบ

บุคคล	ภาพที่ใช้ในการเรียนรู้	ภาพที่ใช้ในการทดสอบ
1	1, 3, 4, 5, 6	7, 8
2	1, 2, 3, 4, 5	6, 8
3	1, 2, 3, 4, 5, 6	7, 8
4	1, 2, 3, 4, 5	6, 8
5	1, 2, 3, 4, 5, 6	7, 8
6	1, 2, 3, 4, 5, 6	7, 8
7	1, 4, 5, 7	8
9	1, 2, 3, 4	5, 7
10	1, 2, 3, 4, 5, 6	7, 8

ตารางที่ 4.9 (ต่อ)

บุคคล	ภาพที่ใช้ในการเรียนรู้	ภาพที่ใช้ในการทดสอบ
11	1, 2, 3, 4, 5, 6	7, 8
12	1, 2, 3, 4	6, 8
13	1, 2, 3, 4, 5, 6	7, 8
14	1, 2, 3, 4, 6	7, 8
15	2, 3, 4, 5, 6	7, 8
16	1, 2, 3, 4, 5, 6	7, 8
17	1, 2, 3, 5	7, 8
18	1, 2, 3, 4, 5, 6	7, 8
19	1, 4, 5, 6	7, 8
20	1, 2, 3, 4	7, 8
21	1, 4, 7	8
รวม	100	38

ตารางที่ 4.10 ผลการทดลองการรู้จำภาพใบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

จำนวน reference pattern	จำนวนข้อมูลที่ใช้ในการเรียนรู้	ค่าความถูกต้อง (%)	จำนวนภาพที่ตอบผิด
39	100	100.00	-

ตารางที่ 4.11 ผลการทดลองการรู้จำภาพลายนิ้วมือฐานข้อมูล FINGDB

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
1	2	2	-	-
2	2	2	-	-
3	2	2	-	-
4	2	2	-	-
5	2	2	-	-
6	2	2	-	-
7	1	1	-	-
9	2	2	-	-

ตารางที่ 4.11 (ต่อ)

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
10	2	2	-	-
11	2	2	-	-
12	2	2	-	-
13	2	2	-	-
14	2	2	-	-
15	2	2	-	-
16	2	2	-	-
17	2	2	-	-
18	2	2	-	-
19	2	2	-	-
20	2	2	-	-
21	1	1	-	-
รวม	38	38	0	-
เปอร์เซ็นต์		100.00	0.00	-

4.3.2 ผลการทดลองการรู้จำลายนิ้วมือด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP [1]

ผลการทดลองจากตารางที่ 4.11 Modified Hausdorff ARTMAP ให้ค่าความถูกต้อง 100 % โดยจำนวนโหนดที่ถูกสร้างใน Cluster Layer มีจำนวนเท่ากับ 39 โหนด ซึ่งขนาดของ reference pattern ในตอนเริ่มต้นการเรียนรู้มีขนาดเท่ากับ 73×73 พิกเซล แต่เมื่อเสร็จสิ้นกระบวนการเรียนรู้ขนาดของ reference pattern มีขนาดเท่ากับ 83×83 พิกเซล จำนวน 31 โหนด ขนาด 78×78 พิกเซล จำนวน 3 โหนด และขนาด 73×73 พิกเซล จำนวน 5 โหนด

ผลการทดลองของ Hausdorff ARTMAP [1] ให้ค่าความถูกต้อง 100 % เช่นกัน แต่จำนวนโหนดใน Cluster Layer มีจำนวนเท่ากับ 57 โหนด โดยขนาดของ reference pattern ถูกกำหนดไว้ที่ขนาด 80×80 พิกเซล


4.4 การทดลอง และผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP

4.4.1 ผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP


งานวิจัยชิ้นนี้ทำการเก็บลายเซ็นด้วยตัวผู้ทำวิจัยเอง โดยให้ผู้เซ็นลายเซ็น เซ็นลายเซ็นลงบนกระดาษ A4 สีขาว โดยทำการเก็บลายเซ็นจำนวน 50 คน คนละ 40 ลายเซ็น ภาพทั้งหมดนำเข้าสู่อุปกรณ์คอมพิวเตอร์โดยสแกนเนอร์ ใช้ความละเอียดในการสแกนเท่ากับ 300 dpi และเลือกชนิดการสแกนแบบสีขาวดำ จากนั้นเข้าสู่กระบวนการเตรียมข้อมูล ดังที่กล่าวไว้ในบทที่ 3 หลังจากกระบวนการเตรียมข้อมูลทำการแบ่งข้อมูลออกเป็นสองส่วน ส่วนแรกเป็นส่วนที่ใช้ในการเรียนรู้จำนวนคนละ 10 ภาพ ส่วนที่สองเป็นส่วนที่ใช้ในการทดสอบจำนวนคนละ 15 ภาพ รวมภาพที่ใช้ในการเรียนรู้ทั้งหมด 500 ภาพ และใช้ในการทดสอบทั้งหมด 750 ภาพ โดยรูปที่ 4.4 แสดงตัวอย่างภาพลายเซ็น ตารางที่ 4.12 แสดงหมายเลขภาพลายเซ็นของแต่ละบุคคลที่ใช้ในการเรียนรู้ 4.13 แสดงผลการทดลองระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

ตารางที่ 4.14 แสดงผลการทดลอง ซึ่งผลการทดลองใช้พารามิเตอร์ดังนี้

- similar_vigilance = 0.0182
- dissimilar_vigilance = 0.5
- x_size = 103
- y_size = 63
- step = 1
- x_area = 2
- y_area = 2



(a)



(b)

รูปที่ 4.4 (a) แสดงภาพต้นฉบับภาพลายเซ็น (b) แสดงภาพที่ผ่านกระบวนการเตรียมข้อมูลแล้ว

ตารางที่ 4.12 ตารางแสดงหมายเลขภาพลายนิ้วมือที่ใช้ในการเรียนรู้ และการทดสอบ

บุคคล	ภาพที่ใช้ในการเรียนรู้	ภาพที่ใช้ในการทดสอบ
1	2, 3, 5, 6, 7, 8, 9, 10, 11, 12	13, 14, 15, 16, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29
2	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
3	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
4	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
5	1, 6, 8, 9, 14, 16, 22, 27, 28, 29	2, 3, 4, 5, 7, 10, 11, 12, 13, 15, 20, 21, 23, 25, 26
6	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
7	4, 5, 6, 7, 8, 9, 10, 11, 12, 13	16, 17, 18, 21, 24, 25, 26, 27, 28, 29, 30, 32, 33, 37, 39
8	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25

ตารางที่ 4.12 (ต่อ)

บุคคล	ภาพที่ใช้ในการเรียนรู้	ภาพที่ใช้ในการทดสอบ
9	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
10	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
11	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
12	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
13	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 23, 24, 25, 28, 29
14	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
15	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25
16	6, 11, 14, 17, 18, 30, 38, 43, 49, 53	1, 5, 7, 8, 12, 15, 20, 21, 22, 23, 27, 28, 29, 39, 50
17	12, 19, 20, 22, 23, 24, 25, 26, 27, 28	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 15, 16, 17, 18
18	1, 4, 6, 9, 13, 15, 21, 22, 23, 27	5, 7, 8, 12, 14, 16, 17, 18, 19, 20, 24, 25, 28, 29, 30
19	12, 18, 25, 27, 34, 35, 36, 37, 39, 40	2, 3, 4, 7, 8, 11, 15, 21, 22, 23, 26, 29, 30, 31, 32
20	1, 3, 4, 6, 10, 11, 29, 31, 34, 36	7, 12, 13, 14, 17, 18, 19, 22, 23, 24, 26, 27, 28, 35, 37
21	19, 29, 30, 31, 32, 33, 34, 35, 36, 38	1, 2, 3, 4, 5, 6, 11, 12, 13, 14, 17, 22, 23, 24, 26
22	2, 9, 17, 18, 26, 27, 31, 32, 36, 40	1, 3, 8, 10, 11, 13, 15, 20, 21, 23, 24, 30, 33, 37, 39
23	11, 21, 22, 23, 24, 31, 32, 34, 38, 40	1, 2, 3, 4, 5, 9, 13, 14, 15, 16, 17, 19, 28, 29, 36
24	3, 4, 13, 14, 21, 22, 23, 25, 33, 36	2, 5, 7, 11, 12, 17, 18, 19, 20, 24, 26, 28, 32, 34, 37
25	57, 58, 59, 60, 61, 62, 63, 64, 66, 67	1, 2, 3, 4, 5, 6, 7, 8, 10, 15, 16, 20, 21, 22, 28
26	12, 19, 26, 29, 32, 33, 37, 39, 40, 44	1, 3, 4, 7, 8, 10, 11, 14, 15, 16, 17, 18, 20, 21, 22
27	7, 10, 14, 16, 23, 25, 28, 33, 34, 37	2, 4, 8, 9, 11, 12, 15, 17, 18, 21, 24, 26, 29, 30, 31
28	9, 13, 20, 21, 26, 28, 29, 32, 34, 38	3, 4, 5, 6, 7, 8, 11, 12, 14, 15, 17, 18, 22, 23, 25
29	8, 11, 12, 18, 20, 23, 24, 31, 33, 36	5, 7, 9, 10, 14, 15, 16, 17, 19, 21, 22, 26, 29, 32, 38
30	26, 28, 30, 32, 34, 36, 40, 43, 49, 50	1, 2, 3, 6, 8, 10, 12, 14, 16, 17, 18, 19, 20, 21, 31
31	8, 18, 31, 32, 34, 37, 38, 40, 42, 43	1, 2, 4, 6, 7, 11, 16, 17, 20, 22, 23, 24, 26, 27, 28
32	12, 14, 17, 21, 24, 29, 32, 35, 36, 40	4, 5, 6, 7, 8, 9, 10, 11, 18, 26, 27, 28, 30, 38, 39
33	1, 2, 5, 6, 8, 16, 20, 23, 25, 30	3, 4, 7, 9, 10, 12, 13, 14, 15, 17, 18, 21, 22, 24, 29
34	1, 3, 4, 9, 10, 25, 30, 31, 36, 37	6, 7, 11, 12, 13, 15, 19, 21, 24, 27, 32, 33, 34, 35, 38
35	20, 23, 24, 25, 26, 27, 28, 29, 30, 37	1, 2, 3, 4, 7, 8, 9, 10, 12, 13, 15, 16, 17, 18, 19
36	11, 16, 22, 25, 30, 32, 34, 39, 43, 48	4, 7, 8, 12, 13, 14, 15, 17, 18, 19, 23, 26, 27, 33, 35
37	2, 7, 11, 15, 19, 22, 25, 32, 33, 34	4, 5, 14, 16, 17, 18, 20, 23, 24, 26, 27, 28, 35, 38, 40
38	3, 7, 26, 27, 30, 32, 33, 36, 38, 39	1, 2, 4, 5, 6, 10, 11, 13, 14, 15, 16, 17, 18, 20, 31
39	17, 18, 19, 20, 21, 23, 24, 25, 30, 31	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16
40	1, 3, 10, 11, 16, 18, 23, 26, 28, 34	2, 6, 7, 8, 9, 12, 14, 15, 21, 24, 29, 33, 36, 38, 39
41	6, 8, 12, 18, 20, 23, 31, 35, 36, 40	4, 11, 13, 14, 15, 16, 17, 19, 24, 25, 26, 28, 30, 32, 34
42	6, 7, 9, 24, 25, 26, 27, 33, 34, 39	1, 2, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22

ตารางที่ 4.12 (ต่อ)

บุคคล	ภาพที่ใช้ในการเรียนรู้	ภาพที่ใช้ในการทดสอบ
43	7, 9, 24, 25, 26, 29, 30, 32, 33, 37	1, 2, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22
44	3, 9, 26, 29, 30, 31, 36, 37, 38, 40	2, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 24
45	6, 8, 15, 20, 23, 26, 27, 30, 35, 39	2, 5, 7, 10, 12, 13, 14, 17, 19, 22, 24, 28, 29, 31, 40
46	4, 5, 10, 19, 22, 27, 31, 32, 33, 39	6, 7, 8, 9, 14, 15, 17, 18, 30, 34, 35, 36, 37, 38, 40
47	23, 24, 25, 26, 27, 28, 31, 32, 33, 34	1, 2, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22
48	1, 11, 12, 13, 18, 21, 24, 25, 32, 35	3, 4, 5, 6, 7, 8, 9, 23, 30, 31, 36, 37, 38, 39, 40
49	4, 5, 6, 7, 8, 9, 32, 34, 38, 39	1, 3, 10, 12, 13, 14, 16, 18, 19, 20, 21, 23, 24, 28, 30
50	4, 5, 6, 7, 8, 9, 24, 31, 36, 40	1, 2, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22
รวม	500	750

ตารางที่ 4.13 ผลการทดลองการรู้จำภาพใบหน้าระหว่าง reference pattern กับชุดข้อมูลที่ใช้ในการเรียนรู้

จำนวน reference pattern	จำนวนข้อมูลที่ใช้ในการเรียนรู้	ค่าความถูกต้อง (%)	จำนวนภาพที่ตอบผิด
452	500	99.60	2

ตารางที่ 4.14 ผลการทดลองการรู้จำภาพลายเส้น

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
1	15	15	-	
2	15	14	1	38
3	15	9	6	7
4	15	14	1	1
5	15	11	4	25, 26, 36
6	15	15	-	-
7	15	15	-	-
8	15	14	1	7
9	15	15	-	-
10	15	14	1	8
11	15	13	2	12, 22
12	15	10	5	10, 13, 14, 25, 30

ตารางที่ 4.14 (ต่อ)

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
13	15	15	-	-
14	15	12	3	13
15	15	14	1	48
16	15	12	3	35, 43
17	15	15	-	-
18	15	12	3	12, 35
19	15	13	2	10, 40
20	15	12	3	24, 39, 47
21	15	14	1	2
22	15	14	1	13
23	15	13	2	6
24	15	11	4	9, 19, 29, 36
25	15	13	2	2, 3
26	15	14	1	25
27	15	12	3	1
28	15	11	4	4, 13, 21
29	15	13	2	9, 48
30	15	12	3	10, 13, 27
31	15	12	3	18, 26
32	15	10	5	2, 4, 20, 29, 47
33	15	15	-	-
34	15	11	4	4, 13, 27
35	15	14	1	21
36	15	14	1	21
37	15	10	5	16, 19, 27, 30, 34
38	15	11	4	1, 4
39	15	14	1	1
40	15	15	-	-
41	15	11	4	4

ตารางที่ 4.14 (ต่อ)

บุคคล	จำนวนภาพที่ใช้ในการทดสอบ	จำนวนภาพที่ตอบถูก	จำนวนภาพที่ตอบผิด	ลำดับบุคคลที่ตอบผิด
42	15	14	1	3
43	15	13	2	27
44	15	11	4	36, 40, 50
45	15	11	4	40, 50
46	15	12	3	20, 43
47	15	13	2	10, 30
48	15	10	5	1, 4, 40, 41
49	15	13	2	24, 41
50	15	14	1	40
รวม	750	639	111	
เปอร์เซ็นต์		85.20	14.80	-

4.4.2 ผลการทดลองการรู้จำลายเซ็นด้วย Modified Hausdorff ARTMAP เปรียบเทียบกับ Hausdorff ARTMAP [1]

ผลการทดลองจากตารางที่ 4.14 Modified Hausdorff ARTMAP ให้ค่าความถูกต้อง 85.20 % โดยจำนวนโหนดที่ถูกสร้างใน Cluster Layer มีจำนวนเท่ากับ 452 โหนด ซึ่งขนาดของ reference pattern ในตอนเริ่มต้นการเรียนรู้มีขนาดเท่ากับ 63×103 พิกเซล แต่เมื่อเสร็จสิ้นกระบวนการเรียนรู้ ขนาดของ reference pattern มีขนาดเท่ากับ 93×133 พิกเซล จำนวน 452 โหนด ตารางที่ 4.15 แสดงระยะทางที่หาได้จากภาพลายเซ็นที่ตอบผิด และภาพลายเซ็นในกลุ่มเดียวกัน

ผลการทดลองของ Hausdorff ARTMAP [1] ให้ค่าความถูกต้อง 81.07 % เช่นกัน จำนวนโหนดใน Cluster Layer มีจำนวนเท่ากับ 497 โหนด โดยขนาดของ reference pattern ถูกกำหนดไว้ที่ขนาด 100×150 พิกเซล ซึ่งมีขนาดเท่ากับขนาดของ input pattern

ตารางที่ 4.15 ตารางแสดงระยะทางของลายเซ็นที่ตอบผิด

กลุ่มของลายเซ็นที่ทดสอบ	กลุ่มของลายเซ็นที่ตอบผิด	ระยะทางของภาพที่ตอบผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
2	38	0.0302	0.0314
3	7	0.0136	0.0138
3	7	0.0129	0.0140

ตารางที่ 4.15 (ต่อ)

กลุ่มของลายเซ็นที่ทดสอบ	กลุ่มของลายเซ็นที่ตอบผิด	ระยะทางของภาพที่ตอบผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
3	7	0.0116	0.0130
3	7	0.0131	0.0141
3	7	0.0124	0.0134
3	7	0.0122	0.0133
4	1	0.0230	0.0235
5	36	0.030	0.0301
5	14	0.0294	0.0297
5	26	0.0287	0.0308
5	26	0.0288	0.0301
8	7	0.0147	0.0149
10	8	0.0285	0.0292
11	22	0.0326	0.0327
11	16	0.0343	0.0344
12	10	0.0277	0.0304
12	13	0.0266	0.0292
12	25	0.0281	0.0287
12	30	0.0292	0.0300
12	14	0.0280	0.0288
14	13	0.0237	0.0244
14	13	0.0268	0.0269
14	13	0.0237	0.0242
15	48	0.0312	0.0323
16	43	0.0325	0.0328
16	43	0.0287	0.0313
16	35	0.0311	0.0314
18	16	0.0396	0.0398
18	35	0.0408	0.0410
18	35	0.0381	0.0391
19	40	0.0349	0.0355

ตารางที่ 4.15 (ต่อ)

กลุ่มของลายเซ็นที่ทดสอบ	กลุ่มของลายเซ็นที่คอปผิด	ระยะทางของภาพที่คอปผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
19	7	0.0290	0.0295
20	39	0.0366	0.0368
20	47	0.0388	0.0409
20	24	0.0304	0.0304
21	2	0.0189	0.0192
22	16	0.0232	0.0238
23	6	0.0705	0.0707
23	6	0.0657	0.0667
24	9	0.0280	0.0287
24	29	0.0434	0.0435
24	36	0.0339	0.0356
24	19	0.0358	0.0358
25	2	0.0233	0.0246
25	3	0.0241	0.0251
26	28	0.0255	0.0288
27	1	0.0191	0.0197
27	1	0.0205	0.0207
27	1	0.0191	0.0192
28	13	0.0283	0.0284
28	4	0.0260	0.0265
28	4	0.0273	0.0278
28	21	0.0323	0.0324
29	48	0.0377	0.0379
29	9	0.0362	0.0365
30	10	0.0295	0.0295
30	13	0.0269	0.0275
30	27	0.0277	0.0282
31	18	0.0419	0.0445
31	26	0.0430	0.0452

ตารางที่ 4.15 (ต่อ)

กลุ่มของลายเซ็นที่ทดสอบ	กลุ่มของลายเซ็นที่ตอบผิด	ระยะทางของภาพที่ตอบผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
31	26	0.0436	0.0460
32	47	0.0449	0.0459
32	2	0.0461	0.0478
32	29	0.0410	0.0467
32	4	0.0429	0.0453
32	20	0.0442	0.0468
34	4	0.0275	0.0276
34	21	0.0274	0.0276
34	21	0.0246	0.0247
34	13	0.0253	0.0264
35	21	0.0296	0.0327
36	21	0.0256	0.0280
37	30	0.0357	0.0367
37	34	0.0382	0.0395
37	27	0.0338	0.0373
37	16	0.0382	0.0407
37	19	0.0372	0.0377
38	4	0.00268	0.0037
38	1	0.0257	0.0260
38	1	0.0234	0.0266
38	4	0.0241	0.0265
38	1	0.0254	0.0262
41	4	0.0232	0.0268
41	4	0.0242	0.0261
41	4	0.0277	0.0279
41	4	0.0229	0.0255
42	3	0.0190	0.0228
43	27	0.0246	0.0256
43	27	0.0229	0.0249

ตารางที่ 4.15 (ต่อ)

กลุ่มของลายเซ็นที่ทดสอบ	กลุ่มของลายเซ็นที่ตอบผิด	ระยะทางของภาพที่ตอบผิด	ระยะทางของภาพที่น้อยที่สุดในกลุ่มเดียวกัน
44	40	0.0405	0.0415
44	50	0.0430	0.0435
44	50	0.0403	0.0404
44	36	0.0384	0.0387
45	40	0.0425	0.0430
45	50	0.0384	0.0421
45	50	0.0403	0.0411
45	40	0.0411	0.0442
46	20	0.0417	0.0446
46	43	0.0337	0.0358
46	43	0.0288	0.0325
47	10	0.0362	0.0367
47	30	0.0358	0.0359
48	1	0.0286	0.0290
48	40	0.0305	0.0321
48	28	0.0308	0.0309
48	4	0.0262	0.0272
48	41	0.0278	0.0283
49	41	0.0346	0.0375
49	24	0.0312	0.0367
50	40	0.0376	0.0381

บทที่ 5

สรุปผลการวิจัย และข้อเสนอแนะ

งานวิจัยชิ้นนี้พัฒนามาจาก โครงข่ายประสาทเทียม Hausdorff ARTMAP ซึ่งเป็นโครงข่ายที่ใช้แนวคิดในการรู้จำโดยใช้โครงร่างของวัตถุ เช่น ลายเส้น หรือเส้นขอบ งานวิจัยชิ้นนี้เลือกใช้การรู้จำด้วยโครงร่าง แทนการรู้จำโดยใช้ค่าพิกเจอร์ (feature) ที่มีค่าซับซ้อน โดยในกระบวนการ Modified Hausdorff ARTMAP นำเอาตัววัดค่าความเหมือนที่เรียกว่า ฮาอุดอร์ฟ ดิสเทนซ์ (hausdorff distance) มาใช้แทนการดำเนินการแบบพีชคณิต

งานวิจัยนี้ใช้ข้อมูล 3 ประเภท คือ ข้อมูลภาพใบหน้า ข้อมูลภาพลายนิ้วมือ และข้อมูลภาพลายเซ็น เป็นข้อมูลที่ใช้ในการทดสอบประสิทธิภาพของ Modified Hausdorff ARTMAP โดยผลการทดลองสรุปได้ดังนี้

- การรู้จำข้อมูลใบหน้า ORL ด้วย Modified Hausdorff ARTMAP ใช้ข้อมูลภาพใบหน้าจาก 40 คน โดยแบ่งภาพข้อมูลทั้งหมดจาก 400 ภาพ เป็นสองส่วน ส่วนแรกเป็นข้อมูลภาพในการเรียนรู้จำนวน 160 ภาพ และส่วนที่สองเป็นข้อมูลภาพในการทดสอบความถูกต้องจำนวน 240 ภาพ เปอร์เซ็นต์ความถูกต้องที่ได้คือ 95.42 % จำนวนโหนดที่ถูกสร้าง Cluster Layer มีจำนวน 152 โหนด โดยมีขนาด 83×83 พิกเซล จำนวน 152 โหนด

- การรู้จำข้อมูลใบหน้า Yale ด้วย Modified Hausdorff ARTMAP ใช้ข้อมูลภาพใบหน้าจาก 15 คน โดยแบ่งภาพข้อมูลทั้งหมดจาก 165 ภาพ เป็นสองส่วน ส่วนแรกเป็นข้อมูลภาพในการเรียนรู้จำนวน 90 ภาพ และส่วนที่สองเป็นข้อมูลภาพในการทดสอบความถูกต้องจำนวน 75 ภาพ โดยเปอร์เซ็นต์ความถูกต้องที่ได้คือ 98.67 % จำนวนโหนดที่ถูกสร้าง Cluster Layer มีจำนวน 36 โหนด โดยมีขนาด 93×93 พิกเซล จำนวน 35 โหนด และขนาด 88×88 พิกเซล จำนวน 1 โหนด

- การรู้จำข้อมูลลายนิ้วมือ ด้วย Modified Hausdorff ARTMAP ใช้ข้อมูลภาพใบหน้าจาก 20 คน โดยแบ่งภาพข้อมูลทั้งหมดจาก 138 ภาพ เป็นสองส่วน ส่วนแรกเป็นข้อมูลภาพในการเรียนรู้จำนวน 100 ภาพ และส่วนที่สองเป็นข้อมูลภาพในการทดสอบความถูกต้องจำนวน 38 ภาพ โดยเปอร์เซ็นต์ความถูกต้องที่ได้คือ 100 % จำนวนโหนดที่ถูกสร้าง Cluster Layer มีจำนวน 39 โหนด โดยมีขนาด 83×83 พิกเซล จำนวน 31 โหนด ขนาด 78×78 พิกเซล จำนวน 3 โหนด และขนาด 73×73 พิกเซล จำนวน 5 โหนด

- การรู้จำข้อมูลลายเซ็น ด้วย Modified Hausdorff ARTMAP ใช้ข้อมูลภาพใบหน้าจาก 50 คน โดยแบ่งภาพข้อมูลทั้งหมดจาก 1250 ภาพ เป็นสองส่วน ส่วนแรกเป็นข้อมูลภาพในการเรียนรู้จำนวน 500 ภาพ และส่วนที่สองเป็นข้อมูลภาพในการทดสอบความถูกต้องจำนวน 750 ภาพ โดย

เปอร์เซ็นต์ความถูกต้องที่ได้คือ 85.20 % จำนวนโหนดที่ถูกสร้าง Cluster Layer มีจำนวน 452 โหนด โดยมีขนาด 93×133 พิกเซล จำนวน 452 โหนด

ในงานวิจัยนี้ทำการเปรียบเทียบ Modified Hausdorff ARTMAP กับ Hausdorff ARTMAP

การทดลอง Modified Hausdorff ARTMAP มีการสุ่มลำดับของ input pattern ที่ถูกส่งเข้าสู่การเรียนรู้ เพื่อทดสอบว่าลำดับของ input pattern มีผลต่อผลการทดลองหรือไม่ โดยผลการทดลองที่ได้ไม่มีการเปลี่ยนแปลงไปตามลำดับของ input pattern ที่ถูกส่งเข้าสู่การเรียนรู้ รวมทั้งจำนวนโหนดใน Cluster Layer มีจำนวนเท่ากันในทุกๆ การเรียนรู้ แต่ใน Hausdorff ARTMAP ผลการทดลอง และจำนวนโหนดใน Cluster Layer มีการเปลี่ยนแปลงไปในทุกครั้งที่ทำการเรียนรู้

การปรับ weight โดยปกติแล้วจะเกิดขึ้นช่วงเรโซแนนซ์ของการเรียนรู้ แต่ Modified Hausdorff ARTMAP ไม่มีการปรับ weight เนื่องจาก Modified Hausdorff ARTMAP ใช้การมองภาพรวมของทุก input pattern ในคลาสที่สนใจทั้งหมด จากนั้นทำการเลือก reference pattern ที่มีความครอบคลุมมากที่สุด จึงไม่เกิดเรโซแนนซ์ทำให้ไม่ต้องทำการปรับ weight และด้วยวิธีการนี้ทำให้จำนวนโหนดใน Cluster Layer ของ Modified Hausdorff ARTMAP มีจำนวนน้อยกว่าจำนวนโหนดในชั้นเดียวกันของ Hausdorff ARTMAP

การย้ายจุดศูนย์กลางอ้างอิงมีส่วนอย่างมากในการเรียนรู้ และการทดสอบ ซึ่งวิธีการนี้ทำให้ผลการทดลองมีความถูกต้องสูงขึ้นมา แต่การย้ายจุดศูนย์กลางอ้างอิงนี้ ทำให้ในช่วงการเรียนรู้ และการทดสอบ ต้องใช้เวลามากกว่า Hausdorff ARTMAP ด้วยเช่นกัน โดยเวลาที่ใช้จะช้า หรือเร็วขึ้นอยู่กับพารามิเตอร์ $step_{x_area}$ และ $step_{y_area}$ ยิ่ง $step$ มีค่าน้อย จำนวนจุดศูนย์กลางอ้างอิงที่ใช้ในการอ้างอิงนั้นก็ยิ่งมากขึ้น ทำให้เวลาในกระบวนการทั้งหมดนานขึ้นด้วย

การขยายขนาดของ reference pattern โดยส่วนใหญ่เป็นการขยายขนาดเพื่อเพิ่มค่าความแตกต่างระหว่าง reference pattern กับ input pattern ในเซต Q แต่การขยายขนาดของ reference pattern นี้ทำให้เกิดค่าความเหมือนทั้งเพิ่มค่าขึ้น และลดค่าลง

บรรณานุกรม

- [1] จงกลณี รุ่งเรือง. “การรู้จำรูปภาพใบนารีโดยใช้ฮ้าอูสเตอร์ฟอาร์ทแมพ” วิทยานิพนธ์
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ บัณฑิตวิทยาลัย, สถาบัน
เทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง. 2547.
- [2] Ross D. King., Cao Feng., A. Sutherland. “StatLog : Comparison of Classification
Algorithms on Large Real-World Problems” **Applied Artificial Intelligence**. 1995. vol.
9, issue 3. pp . 289-333.
- [3] Yue Lu., Chew Lim Tan., Weihua Huang. “An Approach to Word Image Matching Based on
Weighted hausdorff Distance” **Proceedings. Sixth International Conference on
Document Analysis and Recognition**. 10-13 September 2001. pp. 921-925.
- [4] Xuejing Wu., Pengfei Shi. “Unconstrained handwritten numeral recognition using Hausdorff
distance and multi-layer neural network classifier” **Proceedings of the Fifth
International Conference on Document Analysis and Recognition**. 20-22 Sept. 1999.
pp. 249-252.
- [5] X Mu., M Artiklar., M Artiklar., M Hassoun., P Watta. “Training algorithms for robust face
recognition using a template-matching approach” **Proceedings. International Joint
Conference on Neural Networks. IJCNN’01**. vol. 4, 15-19 July 2001 pp.2877-2882.
- [6] Jain A.K., Lin Hong., Pankanti S., Bolle R. “An identity-authentication system using
fingerprints” **Proceedings of the IEEE**. vol.85, no. 9. 1997. pp. 1365-1388.
- [7] Cyber SIGN Incorporated. “**Technology Overview.**” [Online].Available :
http://www.cybersign.com/techoverview_what.htm. 2006.
- [8] Gonzalez R.C., Woods R.E. **Digital Image Processing**. Englewood Cliffs, NJ : Prentice-
Hall. 2002.
- [9] Kwan-Ho Lin., Kin-Man Lam., Wan-Chi Siu., K.H. Lin et al. “Spatially eigen-weighted
Hausdorff distances for human face recognition.” **Pattern Recognition**. vol. 36, no. 8.
August 2003. pp. 1827-1834.
- [10] Asker M. Bazen., Sabih H. Gerez. “Systematic Methods for the Computation of the
Directional Fields and Singular Points of Fingerprints.” **IEEE Transactions on Pattern
Analysis and Machine Intelligence**. vol. 24, issue 7. July 2002. pp. 905-919.

- [11] Suliman M. Mohamen., Henry O. Nyongesa. "Automatic Fingerprint Classification System Using Fuzzy Neural Techniques." **Proceedings of the IEEE International Conference on Fuzzy Systems, 2002. FUZZ-IEEE'02.** vol. 1. May 2002. pp. 358-362.
- [12] Pauti Ramo., Marius Tico., Vesa Onnai., Jukka Saarinen. "Optimizes Singular Point Detection Algorithm for Fingerprint Images." **Proceedings of the International Conference on Image Processing, 2001.** vol. 3. October 2001. pp. 242-245.
- [13] Biometrics Systems Lab., University of Bologna, Cesena-Italy. [Online].Available : http://www.csr.unibo.it/research/biolab/bio_tree.html. 2004.
- [14] Suliman M. Mohamed., Henry O. Nyongesa. "Automatic Fingerprint Classification System Using Fuzzy Neural Techniques." **Proceedings of the 2002 IEEE International Conference on Fuzzy Systems, 2002. FUZZ-IEEE'02.** vol.1. May 2002. pp. 358-362.
- [15] Haralick., Robert M., Linda G. Shapiro. **Computer and Robot Vision.** Volume I. Addison-Wesley. 1992.
- [16] AT&T, Laboratories, Cambridge, University,, UK. "**ORL, Face, Database.**" [Online].Available : <http://www.uk.research.att.com/facedatabase.html>. 2004.
- [17] Yale University. "**Yale, University, Face, Database.**" [Online].Available : <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>. 2004.

ภาคผนวก

ผลงานทางวิชาการที่ได้รับการตีพิมพ์

De-Shuang Huang
Xiao-Ping Zhang
Guang-Bin Huang (Eds.)

LNCS 3645

Advances in Intelligent Computing

International Conference on Intelligent Computing, ICIC 2005
Hefei, China, August 2005
Proceedings, Part II

Part II

 Springer

Human Face Recognition Using Modified Hausdorff ARTMAP

Arit Thammano* and Songpol Ruensuk**

Faculty of Information Technology
King Mongkut's Institute of Technology Ladkrabang,
Bangkok, 10520 Thailand
E-mail: arit@it.kmitl.ac.th* and r.songpol@gmail.com**

Abstract. This paper proposes a new neural network approach specifically designed for solving two dimensional binary image recognition problems. The proposed neural network is an extension of the Hausdorff ARTMAP introduced by Thammano and Rungruang [1]. The objectives of this research are to improve the accuracy and correct the drawbacks of the original network. The performance of this proposed model has been compared with that of the original Hausdorff ARTMAP. The experimental results on two benchmark databases, the ORL and Yale face databases, show that the proposed network surpasses the original Hausdorff ARTMAP in both performance and processing time.

1 Introduction

Person identification has received increasing attention in recent years. In general, there are three ways to identify an individual: the person knows something (e.g., a PIN, a password); the person possesses something (e.g., an ID card, a passport); or by measuring something about the person's body [2]. The latter encompasses the biometric identification. Among all of the biometric identification methods, face recognition is the most natural, non-intrusive, and user-friendly biometric measure because it requires no disturbance to the person being identified. While more intrusive biometric recognition systems (e.g., palm, fingerprint) are presently more accurate, face recognition still has a critical role in certain domains since the person being identified may be at a distance from the sensor, the person does not have to be compliant, and recognition can be performed continuously.

A variety of techniques have been applied to deal with the face recognition problems. The reader should pay attention to Chellappa et al. [3] and the references therein for a more complete survey of previous research works on face recognition. In the early years, many researchers used the structure parameters of faces as the features in the facial image recognition. Kelly [4] used various kinds of facial features, including width of the head and distances between eyes, top of head to eyes, between eyes and nose and the distance from eyes to mouth. During the past decade, researchers have paid much attention to the statistical approaches -- such as eigenfaces [5], KL transform [6], and SVD [7] -- and the neural network approaches [8, 9]. Neural network is very suitable for face recognition systems. It has the ability

to automatically learn the rules from the given collection of representative examples, instead of following a set of human-designed rules [10]. Moreover, it is well-known that the neural network is more robust to noise than other methods. Thammano and Rungruang [1] proposed the Hausdorff ARTMAP neural network, which employs the concept of the Hausdorff distance to measure the likeness or similarity between the incoming input pattern and the reference patterns of each subject. The results show that the Hausdorff ARTMAP is very effective in dealing with the face recognition problems. It outperforms many different techniques studied in the past. The research described in this paper concerns a modification of the Hausdorff ARTMAP neural network in order to further improve the accuracy and correct its drawbacks. The ORI and Yale face databases are used in this study to evaluate the performance of the proposed neural network.

Following this introduction, section 2 briefly describes the concept of the Hausdorff distance. The original Hausdorff ARTMAP is introduced in section 3. Section 4 presents the proposed model. In section 5, the experimental results are demonstrated and discussed.

2 Hausdorff Distance

The Hausdorff distance, when used as a measure of similarity between two two-dimensional binary patterns, has shown to agree closely with human performance [11]. The Hausdorff distance measures the extent to which each point of an input pattern lies near some point of a reference pattern. Given two finite sets $A = \{a_1, a_2, \dots, a_n\}$ and $B = \{b_1, b_2, \dots, b_m\}$, the Hausdorff distance between sets A and B is defined as:

$$H(A, B) = \max \{h(A, B), h(B, A)\}, \quad (1)$$

where the function $h(A, B)$ is called the directed Hausdorff distance from set A to set B , which can be computed as follows:

$$h(A, B) = \max_{a \in A} \{ \min_{b \in B} (\|a - b\|) \}, \quad (2)$$

where $\|a - b\|$ is the Euclidean distance between point a and point b . The Hausdorff distance exhibits many desirable properties for pattern recognition. However, some modifications of the directed Hausdorff distance are made in this study in order to increase the noise immunity of the measurement.

$$h(A, B) = \frac{\sum_{a \in A} h(a, B)}{|A|}, \quad (3)$$

where $|A|$ is the number of points in set A . $h(a, B)$ is the pointwise Hausdorff distance for point a . The pointwise Hausdorff distance is computed as follows:

$$h(a, B) = \min_{b \in B} (\|a - b\|) \quad (4)$$

3 Hausdorff ARTMAP

The architecture of the Hausdorff ARTMAP is a three-layer neural network as shown in Figure 1. The first layer is the input layer, which consists of $X \times Y$ nodes. Each node represents a pixel in the input pattern. The second layer is the cluster layer. The nodes in this second layer are constructed during the training phase. The third layer is the output layer. Each node in the output layer represents a class that the Hausdorff ARTMAP has to learn to recognize. During the supervised learning, the binary input pattern I^m is presented to the model, together with its respective target output vector. The input pattern is denoted by

$$I^m_x = \{1, 0\} \quad ; x = 1, 2, \dots, X; y = 1, 2, \dots, Y \quad (5)$$

where m is the m^{th} input pattern. X and Y are the dimensions of the input pattern.




Fig. 1. Architecture of the Hausdorff ARTMAP

Each node in the cluster layer is fully connected to the nodes in the input layer via the connections w^j . The weight w^j , which has the same dimension as the input pattern, represents the reference pattern of the j^{th} node in the cluster layer. Once the input pattern is transmitted to the cluster layer, the choice function of each j^{th} node in the cluster layer is evaluated as follows:

$$T_j(I^m) = H(I^m, w^j) \quad (6)$$

where $H(I^m, w^j)$ is the Hausdorff distance between the input pattern I^m and the reference pattern of the j^{th} node (w^j). The system then makes a cluster choice by selecting the winning node J with minimum choice function value, among all the nodes j in the cluster layer. The cluster choice is indexed by J , where

$$T_j(I^m) = \min \{ T_j(I^m) \} \quad ; j=1, 2, \dots, N, \quad (7)$$

where N is the number of nodes in the cluster layer. In case of a tie, the node with the smallest index is chosen. Next, the vigilance criterion is evaluated to check whether the degree of mismatch between the input pattern and the reference pattern of the chosen cluster is within an acceptable level

$$T_j(I^m) \leq \rho, \quad (8)$$

where ρ is the vigilance parameter, which has the value between 0 and the length of the diagonal line. Resonance will occur if the chosen cluster meets the above criterion. However, if the condition in (8) is not satisfied, a new cluster node J is recruited to code the input pattern. The weight of this new node is initialized to be equal to the input pattern and this new node will automatically satisfy (8).

$$w^J = I^m \quad (9)$$

Next, the system associates the winning node J in the cluster layer with the target output vector. If the winning node J does not belong to the correct class defined by the target output vector, a new cluster node J is recruited and its weight is initialized using equation (9). Then the connection between a new cluster node and the target output is created. However, if the winning node represents the class to which I^m belongs, the weight vector w^j is then updated according to

$$b_{s,y}^j = \sum_{u=1}^S \sum_{v=1}^S I_{u,v}^m \quad (10)$$

$$w_{s,y}^{j^{new}} = \begin{cases} w_{s,y}^j & \text{if } b_{s,y}^j > 0 \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

where S is a positive integer value; it tells the model how many pixels surrounding the current x, y position should be considered during the weight adjustment.

During testing, each test pattern is applied in turn and its class is predicted. The class whose cluster node returns the minimum output value is the result of the prediction.

Results of the experiment conducted by Thammano and Rungruang [1] show that the Hausdorff ARTMAP is very effective in dealing with the face recognition problems. It outperforms many different techniques studied in the past. However, the Hausdorff ARTMAP suffers from the following problems. First, the performance of the Hausdorff ARTMAP depends directly on the order in which the training images are examined. Second, the time used for recognizing the subject is long due to its large reference pattern size. The above drawbacks motivate the development of the proposed model presented in the next section.

4 Modified Hausdorff ARTMAP

The architecture of the modified Hausdorff ARTMAP is exactly the same as the Hausdorff ARTMAP. The modifications are done to the training algorithm. The details of the training algorithm are presented as follows:

1. The closest similarity between the input pattern m and other input patterns within the same output class K is located.

$$d_m = \min_{\forall n, n \in K, n \neq m} \left[\min_{c=1}^c [H(I^n, w^m)] \right] \quad (12)$$

where I^n represents the input pattern n which belongs to the same class as the input pattern m . w^m is the small area on the input pattern m ; it is used to represent the whole I^m image. c is the number of locations on the input pattern n , which w^m is compared to.

Next, d_m is compared to the similarity threshold (ρ_{similar}). ρ_{similar} is a predetermined value between 0 and the length of the diagonal line. If d_m is less than or equal to ρ_{similar} , the process will continue to the next step. However, if d_m exceeds ρ_{similar} , w^m size will be increased by predefined pixels and this step will be repeated.

2. After w^m is identified, its similarities with other input patterns outside the output class K are determined. The minimum of the above similarities is compared to the dissimilarity threshold ($\rho_{\text{dissimilar}}$) based on equation 14.

$$d_{o_m} = \min_{\forall p, p \notin K} \left[\min_{c=1}^c [H(I^p, w^m)] \right] \quad (13)$$

$$d_{o_m} > \rho_{\text{dissimilar}} \quad (14)$$

where P represents the input pattern p which does not belong to the same class as the input pattern m . $\rho_{\text{dissimilar}}$ is a predetermined value between 0 and the length of the diagonal line. However, it must be greater than or equal to ρ_{similar} . If the condition in (14) is satisfied, the process will continue to the next step. If not, w^m size will be increased by predefined pixels and then go back to step 1.

3. This third step determines the capability of w^m in representing the input patterns within the same output class.

$$R_{mn} = \begin{cases} 1, & \text{if } d_{mn} \leq \rho_{\text{similar}} \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

$$d_{mn} = \min_{0 \leq i \leq c} [H(I^n, w^m)] \quad (16)$$

where $m = 1, 2, 3, \dots, c$ and $n = 1, 2, 3, \dots, c$ is the number of input patterns in class K . " $R_{mn} = 1$ " means that w^m is capable of representing the input pattern n . On the contrary, " $R_{mn} = 0$ " means that w^m is incapable of representing the input pattern n .

4. In this step, the nodes in the cluster layer are created and a select group of w^m is used to be their reference weights. w^m which is capable of representing the maximum number of input patterns in the class is the first to be chosen. The next most capable w^m are subsequently picked until all input patterns in the class are represented. In case of a tie, the averages of the similarities between each w^m in question and the rest of the input patterns in the same class are calculated; the one with the smallest average is selected.

5 Experimental Results

To test the performance of the modified Hausdorff ARTMAP for face recognition, the experiments have been conducted on 2 databases: the ORI face database [12][13] and the Yale face database [14][15]. The results of the experiments are then compared to those of the original Hausdorff ARTMAP. In order to be comparable, the preprocessing step of this study replicates that of Thammano and Rungruang's study. First, the gray-level edge image $E(x, y)$ is obtained by applying morphological operations [16] on the original face image $f(x, y)$. Then, the gray-level edge image is converted to a binary edge image using the adaptive threshold method.

$$n(x, y) = \frac{E(x, y)}{f(x, y)} \quad (17)$$

The values of the function $n(x, y)$ are then sorted in descending order, and the threshold is set so that 30% of the points with the largest magnitudes in $n(x, y)$ are selected.

For the ORL database, there are 10 different images of each of 40 distinct subjects; therefore, the total of 400 different face images are used in this experiment. The images of each subject were taken at different times with different lighting, facial expressions (open/closed eyes, smiling/non-smiling), and facial details (glasses/no-glasses) as shown in Figure 2(a). Four images of each subject are randomly chosen for training and the remaining six images are used for testing. Previously, Lin et al. [17] carried out a comparison study of many different techniques – the principal component analysis (PCA), the conventional Hausdorff distance (HD), the doubly modified Hausdorff distance (M2HD), the spatially weighted Hausdorff distance (SWHD), the spatially weighted doubly Hausdorff distance (SW2HD), the spatially eigen-weighted Hausdorff distance (SEWHD), and the spatially eigen-weighted doubly Hausdorff distance (SEW2HD) – on this ORL face database. The reported recognition rates varied from 46 – 91%. The best recognition rate (91%) was achieved from the SEW2HD. Table 1 shows the recognition results of both the Hausdorff ARTMAP and the modified Hausdorff ARTMAP on the ORL database. The best performance of the Hausdorff ARTMAP is obtained when the vigilance parameter (ρ) is set at 0.8 and S is 2. However, the performance of the model might be lower if the sequence of the training images is changed. For the modified Hausdorff ARTMAP, the best recognition rate of 95.83% is achieved when ρ_{similar} and $\rho_{\text{dissimilar}}$ are 0.35 and 0.9 respectively.



(a)




Fig. 2. Examples of the original face images and the binary edge images of the ORI. (a) and Yale (b) face databases

The Yale database (Figure 2(b)) contains 165 different face images of 15 distinct subjects. There are 11 images per subject, one per different facial expression or configuration: center-light, w/glasses, happy, left-light, w/no glasses, normal, right-light, sad, sleepy, surprised, and wink. In this experiment, randomly picked 90 images (6 images per subject) are included in the training set. The remaining 75 images (5 images per subject) are included in the testing set. The recognition results of the Hausdorff ARTMAP vary from 89.33 – 96.00% depending on the order in which the training images are examined. On the other hand, the recognition results of the modified Hausdorff ARTMAP are always 96.00%, whatever the order of the training images is.

Table 1. Experimental results on ORL database

	Number of Cluster Nodes	Size of Reference Patterns	% Correct
Hausdorff ARTMAP	152-153	100x100	94.58-95.42
Modified Hausdorff ARTMAP	159	85x85, 59x59	95.83

Table 2. Experimental results on Yale database

	Number of Cluster Nodes	Size of Reference Patterns	% Correct
Hausdorff ARTMAP	83-88	100x100	89.33-96
Modified Hausdorff ARTMAP	63	93x93, 61x61	96

References

1. Thammano, A., Rungruang, C.: Hausdorff ARTMAP for Human Face Recognition. WSEAS Transactions on Computers, Issue 3, Vol. 3. (2004) 667-672
2. Martinez, A. M., Yang, M., Kriegman, D. J.: Special Issue on Face Recognition. Computer Vision and Image Understanding, Vol. 91, No. 1-2. Academic Press (2003) 1-5
3. Chellappa, R., Wilson, C. L., Sirohey, S.: Human and Machine Recognition of Faces: A Survey. Proceedings of the IEEE, Vol. 83, No. 5. (1995) 705-740
4. Kelly, M. D.: Visual Identification of People by Computer. Technical Report AI-130. Stanford AI Project, Stanford CA (1970)
5. Turk, M. A., Pentland, A. P.: Face Recognition Using Eigenfaces. Proceedings of the International Conference on Pattern Recognition (1991) 586-591
6. Akamatsu, S., Sasaki, T., Fukumachi, H., Suenaga, Y.: A Robust Face Identification Scheme - KL Expansion of an Invariant Feature Space. SPIE Proc.: Intelligent Robots and Computer Vision X: Algorithms and Techniques, Vol. 1607. (1991) 71-84
7. Cheng, Y., Liu, K., Yang, J., Wang, H.: A Robust Algebraic Method for Human Face Recognition. Proceedings of 11th International Conference on Pattern Recognition. (1992) 221-224
8. Kung, S. Y., Lin, S. H., Fang, M.: A Neural Network Approach to Face/Palm Recognition. Proceedings of the IEEE Workshop on Neural Networks for Signal Processing. (1995) 323-332
9. El-Bakry, H. M., Abo Elsooud, M. A.: Human Face Recognition Using Neural Networks. Proceedings of 16th National Radio Science Conference (NRSC'99). (1999)
10. Lin, S., Kung, S., Lan, L.: Face Recognition/Detection by Probabilistic Decision-Based Neural Network. IEEE Transactions on Neural Networks, Vol. 8, No. 1. (1997) 114-132
11. Rosandich, R. G.: HAVNET: A New Neural Network Architecture for Pattern Recognition. Neural Networks, Vol. 10, No. 1. Pergamon Press (1997) 139-151
12. Samaria, F., Harter, A.: Parameterisation of a Stochastic Model for Human Face Identification. Proceedings of 2nd IEEE Workshop on Applications of Computer Vision (1994)
13. ORL Face Database: Retrieved from <http://www.uk.research.att.com/face/database.html>

14. Bellhumer, P. N., Hespanha, J., Kriegman, D.: Eigenfaces vs. Fisherfaces: Recognition using Class Specific Linear Projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Special Issue on Face Recognition, Vol. 17, No. 7, (1997) 711-720
15. Yale Face Database: Retrieved from <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
16. Gonzalez, R. C., Woods, R. E.: *Digital Image Processing*. Prentice-Hall, Englewood Cliffs NJ (2002)
17. Lin, K., Lam, K., Siu, W.: Spatially Eigen-weighted Hausdorff Distances for Human Face Recognition. *Pattern Recognition*, Vol. 36, No. 8. Pergamon Press (2003) 1827-1834

ประวัติผู้เขียน

ชื่อ	นายทรงพล รื่นสุข
วัน เดือน ปีเกิด	18 กรกฎาคม 2524
ที่อยู่	เลขที่ 14 หมู่ 5 ถนนลำไทร แขวงโลกแฝด เขตหนองจอก กทม. 10530
ประวัติการศึกษา	2545 วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมไฟฟ้า- คอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีมหานคร