

การรู้จำใบหน้าโดยการใช้แถบย่อยหลายระดับความละเอียดเฉพาะ



นางสาวปาริฉัตร เสริมวุฒิสาร

สถาบันวิทยบริการ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต


สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2550

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

FACE RECOGNITION USING SELECTIVE MULTIREOLUTION SUBBANDS



Miss Parichat Sermwuthisarn

สถาบันวิทยบริการ

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering Program in Electrical Engineering

Department of Electrical Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2007

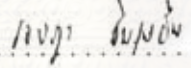
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การรู้จำใบหน้าโดยการใช้แถบย่อยหลายระดับ ความละเอียดเฉพาะ
โดย	นางสาวปาริฉัตร เสริมวุฒิสาร
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ ดร.สมชาย จิตะพันธ์กุล
อาจารย์ที่ปรึกษาร่วม	อาจารย์ ดร.วิทย์ากร อัครวิเศษ
อาจารย์ที่ปรึกษาร่วม	ดร.สรรพฤทธิ์ มฤคทัต

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้ให้นักศึกษานี้เป็นส่วน
หนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

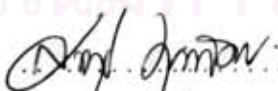
 คณบดีคณะวิศวกรรมศาสตร์
(รองศาสตราจารย์ ดร.บุญสม เลิศธีรวงศ์)

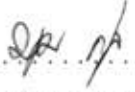
คณะกรรมการสอบวิทยานิพนธ์

 ประธานกรรมการ
(รองศาสตราจารย์ ดร.เจษฎา ชินรุ่งเรือง)

 อาจารย์ที่ปรึกษา
(รองศาสตราจารย์ ดร.สมชาย จิตะพันธ์กุล)

 อาจารย์ที่ปรึกษาร่วม
(อาจารย์ ดร.วิทย์ากร อัครวิเศษ)

 อาจารย์ที่ปรึกษาร่วม
(ดร.สรรพฤทธิ์ มฤคทัต)

 กรรมการ
(รองศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)

ปาริฉัตร เสริมวุฒิสาร : การรู้จำใบหน้าโดยการใช้แถบย่อยหลายระดับความละเอียดเฉพาะ (FACE RECOGNITION USING SELECTIVE MULTIREOLUTION SUBBANDS) อ.ที่ปรึกษา: รศ.ดร.สมชาย จิตะพันธ์กุล, อ.ที่ปรึกษาร่วม: อ.ดร.วิทย์ภากร อัครวิเศษ, ดร.สรรพทุทธิ มฤคทัต, 96 หน้า.

วิทยานิพนธ์นี้นำเสนอการรู้จำใบหน้าโดยการใช้แถบย่อยหลายระดับความละเอียดเฉพาะ แบ่งออกเป็น 4 วิธี วิธีแรกนำเสนอการรวมแถบย่อยสองระดับ โดยใช้ระบบหลายตัวจำแนกเป็นแนวคิดหลัก วิธีที่สองนำเสนอการคัดเลือกแถบย่อยจากแถบย่อยที่มีความซ้ำซ้อนกันน้อยที่สุด ซึ่งความซ้ำซ้อนวัดได้จากค่าสสารที่เกิดร่วมกัน (Mutual information) แถบย่อยที่เลือกได้จากวิธีที่สอง คือ เซ็ตของแถบย่อยที่มีความเป็นอิสระต่อกันมากที่สุด อย่างไรก็ตาม การใช้เซตแถบย่อยที่มีความเป็นอิสระต่อกัน อาจไม่ครอบคลุมสสารทั้งหมดได้ ดังนั้น ในวิธีที่สามนำเสนอการเลือกแถบย่อยจากการครอบคลุมของสสารแทนจากความเป็นอิสระต่อกันมากที่สุด โดยวัดการครอบคลุมของสสารจากค่าสสารที่เกิดร่วมกัน ในวิธีที่สอง และวิธีที่สาม การคัดเลือกแถบย่อยใหม่ขึ้นอยู่กับแถบย่อยที่เลือกได้ก่อนหน้า ซึ่งเซตของแถบย่อยที่คัดเลือกได้ไม่สามารถรับประกันได้ว่าเป็นเซตของแถบย่อยที่เหมาะสมที่สุด ดังนั้น ในวิธีที่สี่ เราคัดเลือกแถบย่อยโดยใช้การครอบคลุมของสสาร และทำการคัดเลือกเซตของแถบย่อยใหม่ ทุกครั้งตามจำนวนแถบย่อยที่กำหนด

สถาบันวิทยบริการ จุฬาลงกรณ์มหาวิทยาลัย

ภาควิชาวิศวกรรมไฟฟ้า.....
สาขาวิชาวิศวกรรมไฟฟ้า.....
ปีการศึกษา 2550.....

ลายมือชื่อนิสิต ปาริฉัตร
ลายมือชื่ออาจารย์ที่ปรึกษา
ลายมือชื่ออาจารย์ที่ปรึกษาร่วม
ลายมือชื่ออาจารย์ที่ปรึกษาร่วม

4870380821 : MAJOR ELECTRICAL ENGINEERING

KEYWORD : 2-LEVEL MULTIPLE CLASSIFIER SYSTEMS / SUBBAND SELECTION / MUTUAL INFORMATION / MULTIREOLUTION / EIGENFACE

PARICHAT SERMWUTHISARN: FACE RECOGNITION USING SELECTIVE MULTIREOLUTION SUBBANDS, THESIS ADVISOR: ASSOC. PROF. SOMCHAI JITAPUNKUL, Dr. Ing., THESIS COADVISOR: WIDHYAKORN ASDORNWISED, Ph. D., SANPARITH MARUKATAT, Ph.D., 96 pp.

This thesis proposes four novel methods based on multiresolution subbands for face recognition. The first method is based on Multiple Classifiers System. In this method, 2-level subbands fusion is proposed. The second method focuses on selecting the least redundant subbands. Mutual information is used to measure this redundancy. This leads to a set of subbands which are the most independent. However, using only independent subbands may not cover all information. Thus, in the third method, the subband selection is based on information coverage instead of the subband dependency as in the second method. Information coverage is measured according to mutual information. In the second and the third methods, the new subband selection depends on the previously selected subbands. The result of greedy incremental selection is not guaranteed to be optimal. Thus, in the fourth method, we use information coverage criterion and reselect a new set of subbands for each desired number of subbands.

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

Department..... Electrical Engineering..... Student's signature..... Parichat.....
 Field of study..... Electrical Engineering..... Advisor's signature..... Somchai.....
 Academic year..... 2007..... Co-Advisor's signature..... Widhyakorn.....
 Co-Advisor's signature..... Sanparith.....

กิตติกรรมประกาศ

ผู้วิจัยขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.สมชาย จิตะพันธ์กุล อาจารย์ที่ปรึกษา
วิทยานิพนธ์ อาจารย์ ดร.วิทยากร อัครวิเศษ และ ดร.สรรพฤทธิ์ มฤคทัต อาจารย์ที่ปรึกษาร่วม ที่
ร่วมกันให้คำปรึกษา และให้ความช่วยเหลืออย่างดียิ่งแก่ผู้วิจัยมาโดยตลอด ขอขอบพระคุณ
อาจารย์ทุกท่านที่ช่วยประสิทธิ์ประสาทวิชาความรู้อันมีค่าให้แก่ผู้วิจัย เป็นผลให้วิทยานิพนธ์ฉบับ
นี้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณทุนจากโครงการเสริมสร้างความเชื่อมโยงระหว่างภาควิชาชีพวิศวกรรมไฟฟ้า
และภาคเอกชนทางด้านการวิจัยและพัฒนา และทุนจากโครงการทุนสถาบันบัณฑิตวิทยาศาสตร์
และเทคโนโลยีไทย (TGIST) ที่ช่วยสนับสนุนในการทำวิจัยเป็นอย่างดี

สุดท้าย ผู้วิจัยขอกราบขอบพระคุณ คุณพ่อ คุณแม่ ที่เป็นกำลังใจ ดูแลเอาใจใส่ และให้
ความช่วยเหลืออย่างดียิ่ง และท้ายที่สุดขอขอบคุณเพื่อน ๆ ทุกคนที่ให้กำลังใจ และช่วยเหลือ
ผู้วิจัยตลอดมา

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง	ฌ
สารบัญภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ความสำคัญและเหตุผล.....	1
1.2 วิธีที่นำเสนอในวิทยานิพนธ์	4
1.2.1 การวิเคราะห์โดยใช้ระบบหลายตัวจำแนกสองระดับ	4
1.2.2 การวิเคราะห์โดยใช้การเลือกคุณลักษณะเพื่อเลือกแถบย่อย	5
1.3 วัตถุประสงค์ของงานวิจัย	5
1.4 เป้าหมายและขอบเขตของงานวิจัย.....	5
1.5 ขั้นตอนและวิธีการดำเนินงาน	6
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	6
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	7
2.1 การวิเคราะห์หลายอำนาจจำแนก.....	7
2.2 การวิเคราะห์องค์ประกอบหลัก.....	8
2.2.1 การคำนวณไบหน้าลักษณะเฉพาะ	10
2.2.2 PCA สำหรับการจำแนกไบหน้า.....	12
2.3 วิธีรวมแถบย่อย	13
2.3.1 การรวมแบบทางข้อมูล	13
2.3.2 การรวมแบบทางผลการตัดสินใจ	13
2.4 การเลือกคุณลักษณะ.....	14
2.4.1 ค่าพลังงานจากแถบย่อย	17
2.4.2 วิธีสภาวะที่เกิดร่วมกัน	18
2.4.3 การลดอันดับของแบบจำลอง	19
2.4.4 ขั้นตอนวิธีการรวมแถบย่อย	21

บทที่ 3 วิธีการที่นำเสนอ.....	23
3.1 การวิเคราะห์แถบย่อยสำหรับการรู้จำใบหน้า.....	23
3.2 ระบบหลายตัวจำแนกสองระดับ.....	24
3.2.1 การรวมแบบทางข้อมูลในระดับที่หนึ่ง.....	25
3.2.2 การรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง.....	25
3.2.3 ข้อมูลขาเข้าของระบบหลายตัวจำแนกสองระดับ.....	26
3.3 การเลือกแถบย่อย.....	27
3.3.1 พิจารณาจากความเป็นอิสระกันของแถบย่อย.....	29
3.3.2 พิจารณาจากการควบคุมข้อมูลของแถบย่อย.....	29
3.3.2.1 แถบย่อยที่เลือกถัดไปขึ้นอยู่กับแถบย่อยที่เลือก ก่อนหน้า.....	30
3.3.2.2 แถบย่อยที่เลือกถัดไปไม่ขึ้นอยู่กับแถบย่อยที่ตัด เลือกก่อนหน้า.....	30
บทที่ 4 การทดลอง.....	32
4.1 ฐานข้อมูลที่ใช้ทดลอง.....	32
4.1.1 ฐานข้อมูลใบหน้า Yale.....	32
4.1.2 ฐานข้อมูลใบหน้า AR.....	33
4.1.3 ฐานข้อมูลใบหน้า ORL.....	33
4.2 การวัดผลการรู้จำใบหน้า.....	34
4.3 ผลการทดลองจากวิธีที่นำเสนอ.....	34
4.3.1 ผลการทดลองจากวิธีระบบหลายตัวจำแนกสองระดับ.....	35
4.3.2 ผลการทดลองจากวิธีเลือกแถบย่อย.....	36
4.3.4 ผลการทดลองเปรียบเทียบ.....	40
บทที่ 5 บทสรุป.....	41
5.1 สรุปผลการวิจัย.....	41
5.2 ข้อดี.....	43
5.3 ข้อด้อย.....	43
5.4 ข้อเสนอแนะ.....	44
รายการอ้างอิง.....	45
ภาคผนวก.....	49

ภาคผนวก ก การประมาณค่าสาระที่เกิดร่วมกันในวิทยานิพนธ์.....	50
ภาคผนวก ข ผลการทดลองจากการใช้แต่ละใบหน้าในการทดสอบ.....	52
ภาคผนวก ค บทความที่ได้รับการตีพิมพ์.....	91
ประวัติผู้เขียนวิทยานิพนธ์.....	96



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ตารางที่ ข.27	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งใบหน้าที่ 13	78
ตารางที่ ข.28	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งใบหน้าที่ 14	79
ตารางที่ ข.29	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 1	80
ตารางที่ ข.30	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 2	81
ตารางที่ ข.31	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 3	82
ตารางที่ ข.32	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 4	83
ตารางที่ ข.33	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 5	84
ตารางที่ ข.34	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 6	85
ตารางที่ ข.35	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 7	86
ตารางที่ ข.36	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 8	87
ตารางที่ ข.37	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 9	88
ตารางที่ ข.38	แถบย่อยที่เลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งใบหน้าที่ 10	89
ตารางที่ ข.39	ผลการรู้จำเฉลี่ยจากเกณฑ์การเลือกที่นำเสนอบนฐานข้อมูล	
	Yale, AR และ ORL	90

สารบัญภาพ

	หน้า
รูปที่ 1.1 การวิเคราะห์โดยใช้ระบบหลายตัวจำแนกสองระดับ	4
รูปที่ 1.2 การวิเคราะห์โดยใช้การเลือกคุณลักษณะเพื่อเลือกแถบย่อย	5
รูปที่ 2.1 แผนผังต้นไม้ของการแยกเวฟเล็ต 2 มิติใน 1 ระดับ	7
รูปที่ 2.2 ภาพตัวอย่างและผลจากการแยกเวฟเล็ต 2 มิติใน 1 ระดับ	8
รูปที่ 2.3 แผนภาพบล็อกของการรวมแบบทางข้อมูล	13
รูปที่ 2.4 แผนภาพบล็อกของการรวมแบบทางผลการตัดสินใจ	14
รูปที่ 2.5 แผนภาพบล็อกของวิธีตัวกรอง	15
รูปที่ 2.6 แผนภาพบล็อกของวิธีห่อหุ้ม	15
รูปที่ 2.7 แผนภาพต้นไม้ของการแยกเวฟเล็ตสองระดับ	17
รูปที่ 2.8 การลดมิติของสภาวะที่เกิดร่วมกันผ่านฟังก์ชันการแปลงแบบหลายค่าสู่ค่าเดียว	19
รูปที่ 3.1 แผนภาพบล็อกระบบหลายตัวจำแนกสองระดับ	24
รูปที่ 3.2 แผนภาพบล็อกการรวมแบบทางข้อมูลในระดับที่หนึ่ง	25
รูปที่ 3.3 แผนภาพบล็อกการรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง	26
รูปที่ 3.4 แผนภาพต้นไม้ของการแยกเวฟเล็ตที่ใช้ในวิทยานิพนธ์	26
รูปที่ 3.5 แผนภาพบล็อกการเลือกแถบย่อยสำหรับการรู้จำใบหน้าที่น่าสนใจในวิทยานิพนธ์	28
รูปที่ 4.1 ตัวอย่างภาพจากฐานข้อมูลใบหน้า Yale	32
รูปที่ 4.2 ตัวอย่างภาพจากฐานข้อมูลใบหน้า AR	33
รูปที่ 4.3 ตัวอย่างภาพจากฐานข้อมูลใบหน้า ORL	33
รูปที่ 4.4 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล Yale	37
รูปที่ 4.5 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจ บนฐานข้อมูล Yale	37
รูปที่ 4.6 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล AR	38
รูปที่ 4.7 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจ บนฐานข้อมูล AR	38
รูปที่ 4.8 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล ORL	39
รูปที่ 4.9 ผลการทดลองจากวิธีเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจ บนฐานข้อมูล ORL	39
รูปที่ ก.1 ตัวอย่างกราฟจากคู่ลำดับ (X, T)	51

บทที่ 1

บทนำ

1.1 ความสำคัญและเหตุผล

การรู้จำใบหน้า (Face recognition) เป็นหนึ่งในการรู้จำแบบ (Pattern recognition) ที่กำลังได้รับความนิยมอย่างมากในปัจจุบัน เนื่องจากสามารถนำไปประยุกต์ใช้ในระบบต่าง ๆ ได้อย่างกว้างขวาง ตัวอย่างเช่น เอทีเอ็ม (ATM) การเข้ารหัสผ่านของคอมพิวเตอร์ เป็นต้น ซึ่งส่วนใหญ่แล้วจะเป็นงานในด้านการรักษาความปลอดภัย โดยมีข้อดีในแง่ของความเป็นส่วนตัวของผู้ใช้งานระบบ เพราะไม่จำเป็นต้องสัมผัสกับอุปกรณ์ใด ๆ ทำให้ง่ายและสะดวกต่อการใช้งาน โดยมีความแตกต่างจากการรู้จำในรูปแบบอื่น ๆ เช่น การรู้จำลายนิ้วมือ ที่จำเป็นต้องใช้นิ้วมือสัมผัสกับเครื่องสแกน เป็นต้น

การทำวิจัยเกี่ยวกับการรู้จำใบหน้าในช่วงเวลาที่ผ่านมา มีหลายทิศทาง ทั้งการวิเคราะห์โดยมนุษย์ และการใช้เครื่องเป็นผู้วิเคราะห์ สำหรับการวิเคราะห์โดยมนุษย์ กล่าวถึงมุมมองของนักจิตวิทยาฟิสิกส์ นักประสาทวิทยา และวิศวกร โดยนักจิตวิทยาฟิสิกส์กับนักประสาทวิทยาทำการศึกษาถึงความพิเศษใบหน้าของมนุษย์ รวมถึงมนุษย์มีความสามารถในการจดจำใบหน้าของแต่ละบุคคลได้อย่างไร ส่วนในมุมมองของวิศวกร จะทำการออกแบบและพัฒนาขั้นตอนวิธีการรู้จำใบหน้าโดยใช้คอมพิวเตอร์เป็นผู้วิเคราะห์ สำหรับการวิเคราะห์โดยเครื่องมีการกล่าวถึงภาพรวม และขั้นตอนวิธีต่าง ๆ ที่ใช้ในกระบวนการรู้จำใบหน้า [1]

วิธีพื้นฐานรูปลักษณะ (Appearance-based) เป็นวิธีหนึ่งที่ได้รับนิยามอย่างมากในกระบวนการรู้จำใบหน้า โดยวิธีนี้ใช้อาณาบริเวณของใบหน้าทั้งหมดเป็นข้อมูลขาเข้าสำหรับระบบการรู้จำ และได้มีการใช้การวิเคราะห์องค์ประกอบหลัก หรือ PCA (Principal Component Analysis) ซึ่งเป็นเทคนิคหนึ่งที่ใช้กันอย่างมากในการสกัดคุณลักษณะ (Feature extraction) เพื่อสร้างองค์ประกอบหลักจากเมทริกซ์ความแปรปรวนของภาพที่ใช้ฝึกสอน และเมื่อใช้สร้างคืนภาพ จะให้ค่าผิดพลาดกำลังสองเฉลี่ย (Mean square error) ต่ำที่สุด [2] แต่ว่า PCA มีข้อจำกัดเรื่องความสามารถในการแยกแยะ (Discriminant) ระหว่างคลาสของข้อมูลได้ไม่ดี

การแยกเวฟเล็ต (Wavelet decomposition) ถือเป็นเทคนิคหนึ่งของการวิเคราะห์หลายอำนาจการจำแนก (Multiresolution) ที่นิยมใช้กับการประมวลผลสัญญาณภาพ โดยเทคนิคนี้จะแบ่งภาพต้นฉบับออกเป็นหลายความละเอียด โดยมีการสังวัตนาการ (Convolution) กับเวฟเล็ตแม่ (Mother wavelet) ที่มีการเลื่อนขนาน และการปรับขนาดความละเอียด ทำให้ได้ภาพย่อยที่มี

ความละเอียดต่ำกว่าภาพต้นฉบับ จากนั้นจะทำการแยกลักษณะสำคัญออกจากภาพย่อย ซึ่งถูกนำไปใช้ในการอธิบายรายละเอียดของภาพนั้น ๆ สำหรับการคืนกลับภาพจากวิธีการแยกเวฟเล็ตนั้น จะให้การคืนกลับที่เหมาะสมแก่สัญญาณต้นแบบเช่นกัน [3]

มีการนำการแยกเวฟเล็ต มาประยุกต์ใช้กับ PCA โดยที่ PCA ทำหน้าที่สกัดคุณลักษณะที่มีความสำคัญจากแถบย่อยช่วงกลาง (Mid-Range) [5] นอกจากนี้ยังมีการนำการแปลงเวฟเล็ตมาใช้ในการสกัดคุณลักษณะ ที่เรียกว่า “เวฟเล็ตเฟส (Waveletface)” และนำการวิเคราะห์การแยกแยะความแตกต่างเชิงเส้น หรือ LDA (Linear Discriminant Analysis) มาประยุกต์ใช้กับเวฟเล็ตเฟส เพื่อเพิ่มความสามารถในการแยกแยะความแตกต่าง [5] ซึ่งวิธีการทั้งสองนี้ เลือกใช้โครงสร้างการแยกเวฟเล็ตแบบพีระมิดสามระดับ (3-Level pyramid wavelet decomposition) โดยเหตุผลที่ใช้โครงสร้างดังกล่าวได้มาจากการทดลอง โดยงานวิจัยทั้งสองนี้ ได้เลือกใช้แถบย่อยที่มีความละเอียดเพียงแถบเดียว แต่แถบย่อยที่เลือกนั้นไม่เหมือนกัน เกิดจากแนวทางที่ต้องการศึกษา และฐานข้อมูลใบหน้าที่เลือกใช้นั้นแตกต่างกัน แต่มีข้อสรุปหนึ่งที่เหมือนกัน คือ สามารถลดภาระในการคำนวณลงได้ นอกจากการเลือกใช้แถบย่อยเดียวที่ได้กล่าวมาแล้วนั้น ยังมีจุดสังเกตที่นำไปสู่การใช้หลายแถบย่อย ซึ่งมีความละเอียดหลายระดับ โดยมีแนวคิดหลักอยู่ 2 ประการ คือ คุณลักษณะที่เหมาะสมอาจอยู่ที่ความละเอียดระดับใดระดับหนึ่ง ที่เราต้องหาให้พบว่าเป็นระดับใด และมีหลายคุณลักษณะที่น่าสนใจ แต่พบว่าไม่มีแถบย่อยเดียวใด ๆ ที่สามารถแทนคุณลักษณะทั้งหมดได้ ด้วยเหตุนี้จึงได้มีงานวิจัยที่เสนอการนำสัญญาณภาพที่แทนโดยหลายแถบย่อยมาวิเคราะห์ร่วมกับการวิเคราะห์ปริภูมิย่อย [5-7] จากคุณสมบัติของ PCA ที่มีการคิดเฉพาะที่ (Localization) และความเป็นฐานที่ปรับตัวได้ (Adaptive basis) ของการวิเคราะห์หลายอำนาจจำแนก ทำให้มีการสร้าง PCA ที่มีความเป็นฐานที่ปรับตัวได้ และจากการใช้หลายแถบย่อยส่งผลให้มีการตัดสินใจออกมาหลายแบบ จึงได้มีการนำวิธีเสียงส่วนมาก (Majority vote) มาใช้ทำหน้าที่สรุปผลการตัดสินใจ [3] นอกจากนี้การรวม (Fusion) แถบย่อยแบบต่าง ๆ ก็เป็นวิธีหนึ่งที่ได้มีการนำเสนอขึ้น [6] ซึ่งจากงานวิจัยข้างต้นที่กล่าวมาแล้วนั้น พบว่าการรวมแบบทางผลการตัดสินใจ (Decision fusion) หรือเรียกอีกอย่างหนึ่งได้ว่าวิธีเสียงข้างมากนิยมใช้ในการสรุปผลส่วนแถบย่อยที่ใช้นั้นจะถูกกำหนดขึ้นเอง หรือบอกเพียงข้อสังเกตในการเลือกโดยไม่ได้มีหลักเกณฑ์ในการเลือกอย่างชัดเจน ซึ่งการใช้หลายแถบย่อยร่วมกันในการตัดสินใจนี้เป็นวิธีหนึ่งของระบบหลายตัวจำแนก (Multiple classifier systems) นั้นเอง

ระบบหลายตัวจำแนกนิยมใช้กับงานด้านการรู้จำแบบรูป โดยมีการพิจารณาทั้งด้านคุณลักษณะ และการจำแนกพร้อม ๆ กัน รวมทั้งเป็นแนวคิดที่สามารถใช้แก้ปัญหาที่เกี่ยวข้องกับเซตที่มีจำนวนมาก และตัวจำแนกที่มีความสามารถในการจำแนกไม่มากพอ การตัดสินใจโดยใช้หลายตัวจำแนกอาจแสดงโดยการจัดอันดับของกลุ่มในตัวจำแนกแต่ละตัว และนำผลจากที่ได้ของ

แต่ละตัวจำแนกมาสรุปได้เป็นผลสุดท้าย [8] ซึ่งระบบหลายตัวจำแนกสามารถแบ่งออกเป็น 2 ประเภทหลัก คือ ระบบที่มีตัวจำแนกต่างกัน และระบบที่มีตัวจำแนกเหมือนกัน โดยในระบบที่มีตัวจำแนกต่างกัมนั้น จะใช้ตัวจำแนกที่มีวิธีต่างกันมาประชุมร่วมกัน มีการใช้วิธีเสียงข้างมากในการสรุปผล [9] ในบทความ [10] นำเสนอว่า แต่ละตัวจำแนกนั้นมีความเหมาะสมกับฐานข้อมูลไบหน้าแต่ละแบบแตกต่างกัน จึงให้น้ำหนักในการตัดสินใจไม่เท่ากัน ส่วนระบบที่มีตัวจำแนกเหมือนกัน จะทำการเลือกใช้ตัวจำแนกวิธีเดียวกันทั้งระบบ มีงานวิจัยที่นำเสนอการใช้ข่ายงานระบบประสาทเทียม (Neural network) และการวิเคราะห์หลายอำนาจจำแนกกับข้อมูลด้านดาวเทียม โดยที่ข้อมูลขาเข้าถูกแทนโดยใช้แผนผังต้นไม้เวฟเล็ตแบบทั้งหมด (Full wavelet tree) จากการแปลงเวฟเล็ตแพคเกจ (Wavelet packet) หลังจากนั้นใช้ข่ายงานระบบประสาทเทียมในการฝึกสอน และมีการหาค่าตัวถ่วงน้ำหนัก (Weight) เพื่อใช้ในการตัดสินใจสำหรับแต่ละข่ายงาน [11] ซึ่งวิธีข่ายงานระบบประสาทเทียมนี้ เหมาะสมกับฐานข้อมูลที่มีขนาดใหญ่ เพราะสามารถให้ตัวอย่างในการฝึกสอนได้มาก และมีรูปแบบที่ครอบคลุม เช่น ฐานข้อมูลด้านตัวอักษร เป็นต้น

สำหรับงานด้านการรู้จำไบหน้านั้น มีการใช้การวิเคราะห์หลายอำนาจจำแนก เพื่อสกัดข้อมูลที่ฝังอยู่ในหลายแถบย่อย และนำระบบหลายตัวจำแนกแบบที่มีตัวจำแนกเหมือนกันมาใช้เพื่อสรุปผลการตัดสินใจที่หลากหลาย [5-7] โดยระบบหลายตัวจำแนกนั้นเป็นทางเลือกหนึ่ง ที่ใช้ในการสรุปผลการตัดสินใจ และให้ผลการรู้จำที่ดีขึ้น แต่จากหลายงานวิจัยที่ได้ศึกษามา พบว่าการเลือกคุณลักษณะ (Feature selection) หรือการเลือกแถบย่อยที่มีความเหมาะสมนั้น เป็นอีกวิธีที่ช่วยปรับปรุงให้ผลการรู้จำดีขึ้นเช่นกัน

เมื่อพบว่าลักษณะเด่นที่ดึงออกมาได้นั้น มีมากเกินไปจนความจำเป็นในการนำไปใช้ เราจึงต้องทำการเปรียบเทียบ และเลือก เพื่อหาว่ามีคุณลักษณะใดบ้างที่ควรนำมาใช้งาน เราเรียกขั้นตอนนี้ว่า การเลือกคุณลักษณะ โดยวิธีที่ใช้ในการเลือกสามารถแบ่งได้เป็น 2 ประเภทหลัก คือ วิธีตัวกรอง (Filters) และวิธีห่อหุ้ม (Wrappers) ซึ่งวิธีการนี้จะทำการเลือกเซตย่อยของตัวแปรก่อนการดำเนินการในขั้นตอนอื่น ๆ เพื่อลดมิติของปริภูมิ และมีการวิเคราะห์ที่รวดเร็วกว่าวิธีห่อหุ้ม สำหรับวิธีห่อหุ้ม จะทำการประเมินค่าของเซตย่อยของตัวแปรที่กำหนดโดยผลที่ดีจากตัวทำนายที่กำหนด ซึ่งวิธีห่อหุ้มมีการประเมินค่าก่อน ทำให้มีการวิเคราะห์ได้ช้ากว่า [12] งานวิจัยที่ทำการเลือกแถบย่อยจากการแยกเวฟเล็ตโดยใช้วิธีตัวกรอง เช่น งานวิจัยที่ [13-14] มีการใช้พลังงานที่กระจายอยู่ในแต่ละแถบย่อยเป็นคุณลักษณะในการวิเคราะห์ ซึ่งพลังงานของแต่ละแถบย่อยนั้นแสดงถึงลักษณะเฉพาะของแถบย่อยนั้น ๆ ของภาพ และมีคุณสมบัติที่สำคัญในการจำแนก โดยมีสมมติฐานที่ว่า พลังงานจากแต่ละแถบย่อยนั้น ต่างก็มีความเป็นอิสระต่อกัน แต่ทว่าสัมประสิทธิ์ของแถบย่อย มีความสัมพันธ์แบบพอลูก ซึ่งแสดงถึงความไม่เป็นอิสระต่อกัน ดังนั้น จึงจำเป็นต้องมีวิธีการที่ใช้วัดความไม่เป็นอิสระต่อกันของแต่ละแถบย่อยได้ ซึ่งมีหลายวิธีที่เป็นที่รู้จัก เช่น การ

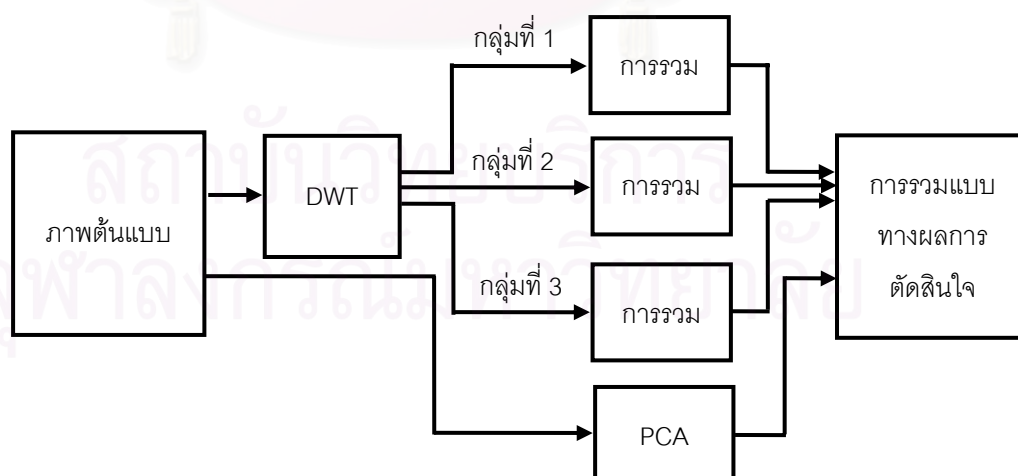
วัดค่าสารสนเทศที่เกิดร่วมกัน (Mutual information), การวัดค่าคูลแบค-ลิวเบอร์ไดเวอร์เจนซ์ (Kullback-Leibler divergence) เป็นต้น ซึ่งวิธีในการวัดความเป็นอิสระต่อกันที่กล่าวมานั้น ใช้ประโยชน์จากการวิเคราะห์สารสนเทศ ที่ได้จากคุณลักษณะที่ที่สกัดได้ [14-17] ซึ่งการวิเคราะห์ดังกล่าว หาความเป็นอิสระต่อกันระหว่างตัวแปรกับตัวแปร และตัวแปรกับเซตของตัวแปรเท่านั้น สำหรับการวิเคราะห์ความเป็นอิสระต่อกันระหว่างเซตของตัวแปรกับเซตของตัวแปร ก็เป็นปัญหาในการวิเคราะห์ที่น่าสนใจ เช่นกัน

1.2 วิธีที่นำเสนอในวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้นำเสนอการรู้จำใบหน้าแบบพื้นฐานรูปลักษณะ โดยเริ่มจากใช้กลุ่มแถบย่อยที่ได้จากการแยกเวฟเล็ตของการวิเคราะห์หลายอำนาจจำแนกเป็นข้อมูลขาเข้า และทำการวิเคราะห์ออกเป็น 2 แบบ ดังนี้

1.2.1 การวิเคราะห์โดยใช้ระบบหลายตัวจำแนกสองระดับ


ใช้แถบย่อยที่กำหนดไว้หลายกลุ่มเป็นข้อมูลขาเข้า จากนั้นใช้การรวมแบบต่าง ๆ ในการสร้างระบบหลายตัวจำแนกระดับที่หนึ่ง ซึ่งการรวมที่ใช้ในระดับที่หนึ่งมีอยู่ 2 ชนิด และใช้การรวมแบบทางผลการตัดสินใจในการสร้างระบบหลายตัวจำแนกระดับที่สอง โดยระบบหลายตัวจำแนกทั้งสองระดับนี้มีตัวจำแนกที่เหมือนกันในแต่ละระดับ แสดงดังรูปที่ 1.1



รูปที่ 1.1 การวิเคราะห์โดยใช้ระบบหลายตัวจำแนกสองระดับ

1.2.2 การวิเคราะห์โดยใช้การเลือกคุณลักษณะเพื่อเลือกแถบย่อย

นำเสนอ 3 เกณฑ์ในการเลือกแถบย่อย โดยมีพื้นฐานจากแนวคิดของวิธีสารสนเทศที่เกิดร่วมกัน (Mutual information) เพื่อเลือกกลุ่มแถบย่อยที่เหมาะสมจากแต่ละเกณฑ์ จากนั้นนำแถบย่อยที่เลือกได้ไปเป็นข้อมูลขาเข้าของการรวมแบบต่าง ๆ เพื่อสร้างระบบหลายตัวจำแนกต่อไป ซึ่งในการวิเคราะห์นี้เป็นระบบหลายตัวจำแนกเพียงหนึ่งระดับที่มีตัวจำแนกชนิดเดียวกัน แสดงดังรูปที่ 1.2



รูปที่ 1.2 การวิเคราะห์โดยใช้การเลือกคุณลักษณะเพื่อเลือกแถบย่อย

1.3 วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษา และออกแบบวิธีการ ซึ่งนำการวิเคราะห์หลายอำนาจการจำแนกมาใช้ร่วมกับวิธีวิเคราะห์ปริภูมิย่อย (Subspace analysis) สำหรับการรู้จำใบหน้า
2. เพื่อศึกษา และนำระบบหลายตัวจำแนก มาประยุกต์ใช้กับการเลือกคุณลักษณะ
3. เพื่อศึกษา และออกแบบการเลือกกลุ่มแถบย่อยที่เหมาะสมกับฐานข้อมูลใบหน้ามาตรฐานต่าง ๆ

1.4 เป้าหมายและขอบเขตของงานวิจัย

1. ใช้การวิเคราะห์หลายอำนาจจำแนก และการวิเคราะห์ปริภูมิย่อยในการสกัดคุณลักษณะ
2. เพิ่มประสิทธิภาพในการวิเคราะห์การรู้จำใบหน้าแบบความละเอียดหลายระดับโดยใช้ระบบหลายตัวจำแนกสองระดับ
3. ทำการเลือกแถบย่อยหลายระดับความละเอียดที่เหมาะสม
4. ศึกษา และพัฒนาการเลือกแถบย่อยหลายระดับความละเอียด เพื่อใช้ร่วมกับระบบหลายตัวจำแนก

1.5 ขั้นตอนและวิธีการดำเนินงาน

1. ศึกษาข้อดี ข้อเสีย และการนำไปใช้งานของระบบการรู้จำใบหน้า
2. ศึกษาความสามารถของเทคนิคการรู้จำใบหน้าแบบต่าง ๆ โดยเน้นวิธีพื้นฐานรูปลักษณะ
3. ศึกษา และวิเคราะห์เกี่ยวกับการรวมแบบต่าง ๆ
4. ศึกษา และวิเคราะห์การนำระบบหลายตัวจำแนกมาใช้ร่วมกับการรวมแบบต่าง ๆ
5. ศึกษา และวิเคราะห์การนำระบบหลายตัวจำแนกมาใช้ร่วมกับการเลือกคุณลักษณะ
6. ทดลองวิธีการที่ออกแบบ และเก็บผลการทดลอง
7. รวบรวม และสรุปผลการวิจัยทั้งหมด เพื่อเขียนวิทยานิพนธ์

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้ทราบถึงวิธีการนำระบบหลายตัวจำแนกมาประยุกต์ใช้กับวิธีต่าง ๆ
2. ได้ทราบถึงวิธีการเลือกคุณลักษณะแบบต่าง ๆ
3. ได้แนวคิดที่สามารถปรับปรุงอัตราการรู้จำให้ดีขึ้นได้
4. สามารถนำแนวคิดที่นำเสนอไปประยุกต์ให้เป็นแนวคิดอื่น ๆ ต่อไปได้

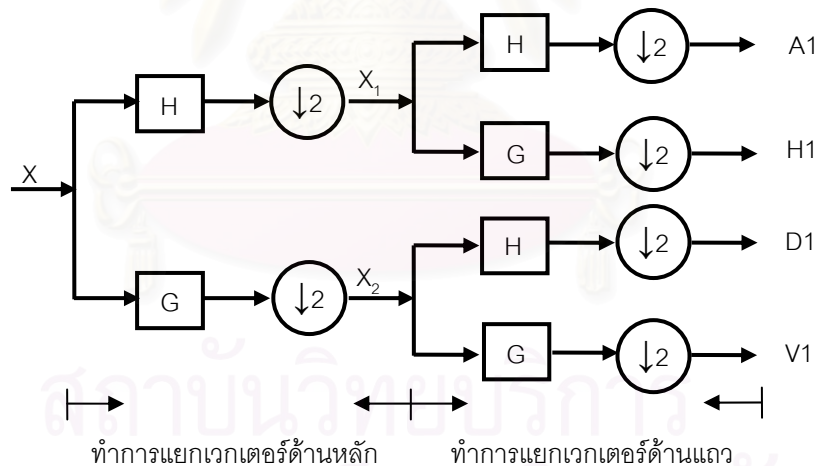
สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

2.1 การวิเคราะห์หลายอำนาจจำแนก (Multiresolution Analysis)


การวิเคราะห์หลายอำนาจจำแนก เป็นหนึ่งในเครื่องมือที่ใช้ในการวิเคราะห์สัญญาณที่มีความสามารถสูง ซึ่งนิยมใช้กันอย่างแพร่หลายในการสกัดคุณลักษณะ การบีบอัด และการลดสัญญาณรบกวน โดยเทคนิคหนึ่งของการวิเคราะห์หลายอำนาจจำแนก (Multiresolution) ที่นิยมใช้กับการประมวลผลสัญญาณภาพ คือ การแยกเวฟเล็ต (Wavelet decomposition) ซึ่งเทคนิคนี้จะแบ่งภาพต้นฉบับออกเป็นหลายความละเอียด โดยมีการสังวัตนาการ (Convolution) กับเวฟเล็ตแม่ (Mother wavelet) ที่มีการเลื่อนขนาน และการปรับขนาดความละเอียด ทำให้ได้ภาพย่อยที่มีความละเอียดต่ำกว่าภาพต้นฉบับ จากนั้น ทำการแยกลักษณะสำคัญออกจากภาพย่อย เพื่อนำไปใช้ในการอธิบายรายละเอียดของภาพนั้น ๆ และนอกจากนี้ การแยกเวฟเล็ตยังสามารถให้การคืนกลับที่เหมาะสมแก่สัญญาณต้นแบบได้อีกด้วย



รูปที่ 2.1 แผนผังต้นไม้ของการแยกเวฟเล็ต 2 มิติใน 1 ระดับ

การแปลงเวฟเล็ตแบบ 2 มิติ เป็นแนวคิดที่ได้จากการประยุกต์อย่างต่อเนื่องของการแปลงเวฟเล็ตแบบ 1 มิติ แสดงดังรูปที่ 2.1 โดยที่ G คือ ตัวกรองความถี่สูงผ่าน (High-pass filtering) และ H คือ ตัวกรองความถี่ต่ำผ่าน (Low-pass filtering) $\downarrow 2$ แสดงถึงการชักตัวอย่างต่ำลง (Down sampling) 2 ตามแนวที่กำหนด และในส่วนสุดท้าย จะได้ภาพแถบย่อยที่มีความละเอียด ขนาด

$N/2 \times N/2$ โดย A1 เป็นแถบย่อยที่เก็บรายละเอียดความถี่ต่ำ และเป็นแถบย่อยที่ให้ข้อมูลมากที่สุด รวมถึงมีความสามารถในการแยกแยะได้ดีที่สุดในการแยกเวฟเล็ต 2 มิติ 1 ระดับ สำหรับแถบย่อย H1 เป็นแถบย่อยที่แสดงรายละเอียดทางด้านแนวนอน แถบย่อย V1 เป็นแถบย่อยที่แสดงรายละเอียดทางด้านแนวตั้ง และสุดท้ายแถบย่อย D1 เป็นแถบย่อยที่แสดงรายละเอียดทางด้านแนวทแยง โดยในรูปที่ 2.2 เป็นภาพใบหน้าจากฐานข้อมูลใบหน้า ORL ซึ่งทำการแยกเวฟเล็ต 2 มิติตามแผนผังในรูปที่ 2.1



รูปที่ 2.2 ภาพตัวอย่าง และผลจากการแยกเวฟเล็ต 2 มิติใน 1 ระดับ

ในการแปลงเวฟเล็ตนั้นมีทั้งแบบต่อเนื่อง และไม่ต่อเนื่อง ซึ่งในงานวิจัยที่ศึกษามา [3-4, 6] ได้สนใจการใช้การแปลงเวฟเล็ตแบบไม่ต่อเนื่อง (Discrete wavelet transform หรือ DWT) เนื่องจากในการแปลงเวฟเล็ตแบบต่อเนื่อง (Continuous wavelet transform) นั้น ให้ค่าข้อมูลซ้ำซ้อนมาก และต้องใช้การคำนวณที่ซับซ้อนมากกว่า สำหรับการจำแนกประเภทนั้น มีการตั้งสมมติฐานว่า ความแตกต่างภายในกลุ่มจะอยู่ในส่วนของความถี่สูง และลักษณะที่พอเพียงในการจำแนกจะอยู่ในส่วนของความถี่ต่ำ

2.2 การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis หรือ PCA)

PCA ให้องค์ประกอบหลักที่มีค่าเฉลี่ยกำลังของความผิดพลาดในการสร้างคืนที่น้อยที่สุด PCA ถูกนำไปใช้ในการบีบอัดเซตของเวกเตอร์ที่มีมิติสูง ให้เป็นเซตของเวกเตอร์ที่มีมิติลดลง และมีความสามารถในการคืนกลับ (Reconstruction) ได้ดี นอกจากนี้ PCA จัดได้ว่าเป็นการวิเคราะห์แบบอิงพารามิเตอร์ (Non-parametric) และให้คำตอบเดียว ซึ่งเป็นอิสระต่อสมมติฐานต่าง ๆ ที่เกี่ยวกับการกระจายของข้อมูล (Data distribution) แต่อย่างไรก็ตาม ทั้งสองคุณสมบัติที่กล่าวมานั้น ถือได้ว่าเป็นทั้งข้อดี และข้อด้อย ส่งผลให้การบีบอัดโดยใช้วิธีนี้เกิดการสูญหายของข้อมูลได้ และถ้าพิจารณาในแง่ของการจับกลุ่ม (Clustering) พบว่าข้อจำกัดหลักของ PCA คือ ไม่มีความสามารถในการแยกคลาส เนื่องจากไม่ได้คำนึงถึงคลาสลาเบลของเวกเตอร์คุณลักษณะ โดย

ปกติแล้ว PCA จะสร้างพิกัดที่หมุนรอบได้ และจัดแกนที่แปลงแล้วให้อยู่ในทิศทางเดียวกันกับทิศทางที่มีความแปรปรวนสูงสุด แต่ทว่าทิศทางที่มีความแปรปรวนสูงสุดนั้น ไม่ได้หมายความว่าสามารถบรรจุคุณลักษณะที่ดีในการแยกแยะความแตกต่างได้ นอกจากนี้ PCA ยังมีสมมติฐานต่าง ๆ ดังต่อไปนี้ ที่มีความไม่เหมาะสมอยู่บ้าง

- PCA ตั้งสมมติฐานจากความเป็นเชิงเส้น ข้อมูลที่ใช้ในการวิเคราะห์ถูกสมมติว่าเป็นการรวมกันแบบเชิงเส้นของฐานหลักที่แน่นอน ดังนั้นเมื่อทำการวิเคราะห์โดยไม่สมมติให้เป็นเชิงเส้น เช่น การวิเคราะห์องค์ประกอบหลักแบบเคอร์เนล (Kernel PCA) อาจแก้ปัญหานี้ได้
- PCA ตั้งสมมติฐานว่าองค์ประกอบหลักต่าง ๆ ตั้งฉากต่อกัน มีวิธีอื่น เช่น การวิเคราะห์องค์ประกอบอิสระ (Independent Component Analysis หรือ ICA) ซึ่งละสมมติฐานนี้ทำให้ได้องค์ประกอบที่เหมาะสมกว่าในบางงาน
- PCA ตั้งสมมติฐานว่าที่ความแปรปรวนค่ามากมีนัยสำคัญมาก PCA จะสร้างพิกัดที่หมุนรอบได้ และจัดแกนที่แปลงแล้วให้อยู่ในทิศทางเดียวกันกับทิศทางที่มีความแปรปรวนสูงสุด สมมติฐานนี้จะเป็นจริงได้ก็ต่อเมื่อ เชื่อว่าข้อมูลที่ใช้นั้น มีอัตราส่วนของสัญญาณต่อสัญญาณรบกวน (Signal to noise ratio) สูง โดยจะส่งผลให้ที่องค์ประกอบหลักมีค่าความแปรปรวนสูงสัมพันธ์กับข้อมูลมาก และองค์ประกอบที่มีความแปรปรวนต่ำสัมพันธ์กับสัญญาณรบกวน

การใช้ PCA เพื่อการรู้จำใบหน้าสามารถปฏิบัติได้โดยการใช้ภาพใบหน้าเป็นข้อมูลในการวิเคราะห์ ซึ่งแนวคิดเบื้องต้นของ PCA สำหรับการรู้จำใบหน้า คือ สร้างตัวแทนของภาพใบหน้าต้นแบบให้มีมิติลดลง โดยใช้เวกเตอร์ลักษณะเฉพาะ ซึ่งสามารถคำนวณได้จากการแยกค่าลักษณะเฉพาะ (Eigenvalue decomposition) จากเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ของภาพใบหน้าต้นแบบ จากนั้น นำภาพที่ฉายลงบนปริภูมิที่ถูกสร้างจากเวกเตอร์ลักษณะเฉพาะนี้ มาเป็นข้อมูลขาเข้าที่ใช้ในการฝึกสอน เราเรียกภาพที่ได้จากเวกเตอร์ลักษณะเฉพาะว่า “ใบหน้าเฉพาะ” หลังจากนั้น นำภาพใบหน้าที่ได้จากการฉายลงบนปริภูมิใบหน้าเฉพาะไปทำในส่วนขั้นตอนการรู้จำใบหน้าต่อไป [18]

ส่วนต่อไปในหัวข้อที่ 2.2 เราได้กล่าวถึงรายละเอียดในการคำนวณใบหน้าลักษณะเฉพาะในหัวข้อที่ 2.2.1 และ การใช้ PCA สำหรับการจำแนกใบหน้าไว้ในหัวข้อ 2.2.2

2.2.1 การคำนวณใบหน้าลักษณะเฉพาะ

ทำการแปลงภาพของกลุ่มฝึกสอน (Training set) จำนวน T_n ภาพ และมีขนาด $N \times M$ จุดภาพ ให้เป็นเวกเตอร์ที่มีขนาด $(N \times M) \times 1$ ดังสมการที่ (2.1) โดยที่ $i = 1, \dots, N \times M$, $j = 1, \dots, N$ และ $k = 1, \dots, M$

$$\Gamma_i = \Gamma'_{j,k} \quad (2.1)$$

จากนั้นนำไปหาหาเวกเตอร์ Ψ ซึ่งคือ ใบหน้าเฉลี่ยของทุกภาพในกลุ่มฝึกสอน ดังสมการที่ (2.2)

$$\Psi = \frac{1}{T_n} \sum_{i=1}^{T_n} \Gamma_i \quad (2.2)$$

เมื่อคำนวณหาเวกเตอร์ใบหน้าเฉลี่ย Ψ ซึ่งมีขนาด $(N \times M) \times 1$ สำเร็จแล้วนำ Ψ ไปคำนวณหา Φ ซึ่งคือ ความแตกต่างระหว่างแต่ละภาพของกลุ่มฝึกสอน กับใบหน้าเฉลี่ย ดังสมการที่ (2.3) โดยที่ $i = 1, \dots, T_n$

$$\Phi_i = \Gamma_i - \Psi \quad (2.3)$$

จาก Φ_i ที่มีจำนวน T_n กลุ่ม นำมาจัดเป็นเมทริกซ์ \mathbf{A} ซึ่งคือ ปริภูมิรูป (Image space) ซึ่งมีขนาด $(N \times M) \times T_n$ โดยนำแต่ละ Φ_i มาเรียงต่อกันในแนวหลัก (Column) ดังสมการที่ (2.4)

$$\mathbf{A}_{i,j} = \Phi_{i,j} \quad (2.4)$$

นำเมทริกซ์ \mathbf{A} ไปหาเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) \mathbf{C} ซึ่งจะมีขนาด $(N \times M) \times (N \times M)$ ดังสมการที่ (2.5)

$$\mathbf{C} = \mathbf{A}\mathbf{A}^T \quad (2.5)$$

เนื่องจากภาพที่ใช้มีขนาดใหญ่มาก ซึ่งส่งผลให้เมทริกซ์ความแปรปรวนร่วมขนาด $(N \times M) \times (N \times M)$ มีขนาดใหญ่มากเกินไป ด้วยเหตุนี้ จึงได้มีการใช้วิธีผลคูณภายใน (Inner product) ซึ่งสามารถใช้ลดภาระการคำนวณในการหาค่าลักษณะเฉพาะจากเมทริกซ์ความแปรปรวนร่วมลงได้ดังสมการที่ (2.6)

$$\mathbf{L} = \mathbf{A}^T \mathbf{A} \quad (2.6)$$

โดยหาค่า λ และ \mathbf{v} เป็นค่าลักษณะเฉพาะ และเวกเตอร์ลักษณะเฉพาะ ของเมทริกซ์ความแปรปรวนร่วมแล้ว เรามีความสัมพันธ์ ดังสมการที่ (2.7)

$$\mathbf{A}^T \mathbf{A} \mathbf{v} = \lambda \mathbf{v} \quad (2.7)$$

หากเราคูณข้างซ้ายด้วย \mathbf{A} จะได้ดังสมการที่ (2.8)

$$\mathbf{A} \mathbf{A}^T \mathbf{A} \mathbf{v} = \lambda \mathbf{A} \mathbf{v} \quad (2.8)$$

นั่นหมายความว่า λ และ $\mathbf{A} \mathbf{v}$ เป็นค่าลักษณะ และเวกเตอร์ลักษณะเฉพาะของ $\mathbf{A} \mathbf{A}^T$ นั่นเอง จากเมทริกซ์ความแปรปรวนร่วม \mathbf{C} หรือ $\mathbf{A} \mathbf{A}^T$ เราสามารถคำนวณหาค่าลักษณะเฉพาะได้จำนวน $N \times M$ ค่า และเมทริกซ์ $\mathbf{A}^T \mathbf{A}$ สามารถคำนวณค่าลักษณะเฉพาะได้จำนวน T_n ค่า โดยที่ค่าลักษณะเฉพาะ ณ ตำแหน่งที่มากกว่า $(N \times M) - T_n$ มีค่าใกล้เคียงกับศูนย์ ซึ่งแสดงความหมายอีกนัยหนึ่งว่า ค่าลักษณะเฉพาะช่วงดังกล่าวมีนัยสำคัญน้อยนั่นเอง ดังนั้นจากที่กล่าวมาสามารถใช้เมทริกซ์ $\mathbf{A}^T \mathbf{A}$ ขนาด $T_n \times T_n$ ในการหาค่าลักษณะเฉพาะที่สำคัญได้ แต่เวกเตอร์ลักษณะเฉพาะที่คำนวณได้เป็นเวกเตอร์เชิงตั้งฉาก (Orthogonal vector) แต่ไม่เป็นเวกเตอร์เชิงตั้งฉากปกติ (Orthonormal vector) ซึ่งต่างจากค่าที่คำนวณได้จาก $\mathbf{A} \mathbf{A}^T$ ดังนั้น จึงต้องมีการปรับให้เป็นเวกเตอร์หนึ่งหน่วย (Unit vector) โดยขนาดของเวกเตอร์ลักษณะเฉพาะ $\|\mathbf{A} \mathbf{v}\|$ หาได้จากสมการที่ (2.9)

$$\begin{aligned} \|\mathbf{A} \mathbf{v}\|^2 &= (\mathbf{A} \mathbf{v})^T \mathbf{A} \mathbf{v} \\ &= \mathbf{v}^T \mathbf{A}^T \mathbf{A} \mathbf{v} \end{aligned} \quad (2.9)$$

จาก \mathbf{v} คือ เวกเตอร์ลักษณะเฉพาะของ $\mathbf{A}^T \mathbf{A}$ ดังนั้น แทนค่าสมการที่ (2.7) ลงในสมการที่ (2.9) ได้สมการที่ (2.10) ดังนี้

$$\begin{aligned} \|\mathbf{A} \mathbf{v}\|^2 &= \mathbf{v}^T (\lambda \mathbf{v}) \\ &= \lambda \mathbf{v}^T \mathbf{v} \\ &= \lambda \\ \therefore \|\mathbf{A} \mathbf{v}\| &= \sqrt{\lambda} \end{aligned} \quad (2.10)$$

เวกเตอร์หนึ่งหน่วยของเวกเตอร์ลักษณะเฉพาะ \mathbf{Av} สามารถคำนวณได้จาก สมการที่ (2.11)

$$\mathbf{v} = \mathbf{Av} \left(\frac{1}{\sqrt{\lambda}} \right) \quad (2.11)$$

เมื่อได้ค่าเวกเตอร์ลักษณะเฉพาะ \mathbf{v} จากสมการที่ (2.11) แล้ว จากนั้น ทำการคำนวณหา เมทริกซ์ \mathbf{U} ที่มีขนาด $(N \times M) \times T_n$ ซึ่งเป็นเมทริกซ์ของเวกเตอร์ลักษณะเฉพาะของเมทริกซ์ ความแปรปรวนร่วมเริ่มต้น \mathbf{C} ได้ดังสมการที่ (2.12)

$$\mathbf{U} = \mathbf{Av} \quad (2.12)$$

2.2.2 PCA สำหรับการจำแนกใบหน้า

ทำการสกัดใบหน้าลักษณะเฉพาะจากเมทริกซ์ความแปรปรวนร่วมของข้อมูลที่ใช้ฝึกสอน โดยใบหน้าลักษณะเฉพาะสร้างจากกลุ่มของคุณลักษณะที่สำคัญ ซึ่งอธิบายจากความแปรปรวนของกลุ่มใบหน้าตัวอย่าง จากนั้น ขั้นตอนถัดไป คือ ทำการฝึกสอน ซึ่งทุกภาพที่แทนกลุ่มต่าง ๆ จะถูกฉายลงบนปริภูมิใบหน้าลักษณะเฉพาะ (Eigenface space) โดยจะแทนได้จากการรวมกันเชิงเส้นของใบหน้าลักษณะเฉพาะ ซึ่งสังเกตได้ว่าเวกเตอร์ลักษณะเฉพาะ จำนวน $(N \times M) - T_n$ เท่านั้นที่จะถูกใช้ได้อย่างมีประสิทธิภาพ

การฉาย (Projection) ภาพที่ใช้ฝึกสอนลงบนปริภูมิใบหน้าลักษณะเฉพาะสามารถทำได้ ดังสมการที่ (2.13) โดยเมทริกซ์ $\mathbf{\Omega}_i$ มีขนาด $(N \times M) \times 1$ ซึ่ง T_n คือ จำนวนใบหน้าในกลุ่มฝึกสอน

$$\mathbf{\Omega}_i = \mathbf{U}^T (\mathbf{\Gamma}_i - \mathbf{\Psi}) \quad , i = 1, \dots, T_n \quad (2.13)$$

จากการฉายใบหน้าที่ต้องการฝึกสอนลงบนปริภูมิใบหน้าลักษณะเฉพาะแล้ว ต้องทำการฉายภาพใบหน้าที่ต้องการทดสอบลงไปบนปริภูมิใบหน้าลักษณะเฉพาะเช่นเดียวกัน ดังสมการที่ (2.14)

$$\mathbf{\Omega} = \mathbf{U}^T (\mathbf{\Gamma} - \mathbf{\Psi}) \quad (2.14)$$


จากนั้นจึงนำมาวัดหาระยะห่างระหว่าง $\mathbf{\Omega}_i$ และ $\mathbf{\Omega}$ โดยในวิทยานิพนธ์นี้ เราเลือกใช้ตัวจำแนกแบบเพื่อนบ้านที่ใกล้ที่สุด (Nearest neighbor) ในการจำแนกใบหน้าต่อไป

2.3 วิธีรวมแถบย่อย (Fusion of subbands methods)

วิธีรวมแถบย่อยมีการคิดค้นขึ้น เพื่อแก้ปัญหาในการนำหลายแถบย่อยจากการวิเคราะห์หลายอานาจจำแนก ซึ่งมีจำนวนมากมาใช้ในการรู้จำใบหน้า ในวิทยานิพนธ์นี้เลือกใช้ PCA ในการสกัดข้อมูลที่ใช้รวมแถบย่อยนี้ จากนั้นใช้ตัวจำแนกแบบเพื่อนบ้านที่ใกล้ที่สุด ในการจำแนกใบหน้าในระดับสุดท้าย โดยมีการวิเคราะห์ทั้งหมด 2 วิธี [6] ซึ่งคือ การรวมแบบทางข้อมูลในหัวข้อ 2.3.1 และ การรวมแบบทางผลการตัดสินใจในหัวข้อ 2.3.2 ดังต่อไปนี้

2.3.1 การรวมแบบทางข้อมูล (Data fusion)

การรวมแบบทางข้อมูล มีจุดประสงค์เพื่อวิเคราะห์ว่า ในกรณีที่มีข้อมูลของใบหน้าเดิมเพิ่มมากขึ้นจะส่งผลอย่างไรต่อระบบการรู้จำใบหน้า โดยมีขั้นตอนทำงาน คือ นำแถบย่อยต่าง ๆ ที่ได้จากการแปลงเวฟเล็ตแบบไม่ต่อเนื่องมารวมกัน ทำให้ได้เป็นเวกเตอร์ใหม่ที่เกิดจากการนำหลายแถบย่อยมาต่อกัน จากนั้นนำไปสกัดคุณลักษณะ และทำการจำแนกเพื่อตัดสินใจว่าเป็นบุคคลใดต่อไป แสดงดังรูปที่ 2.3 การรวมแบบทางข้อมูลนี้มีข้อสังเกตว่าถ้าแถบย่อยที่นำมารวมมีขนาดไม่เท่ากัน เช่น กรณีที่มีแถบย่อยขนาด 64×64 ซึ่งคือ เวกเตอร์ขนาด 4096×1 มารวมกับแถบย่อยขนาด 16×16 ซึ่งคือ เวกเตอร์ขนาด 256×1 พบว่าแถบย่อยมีขนาดใหญ่จะมีอิทธิพลต่อข้อมูลที่รวมแล้วมากกว่าแถบย่อยที่มีขนาดเล็กกว่า



รูปที่ 2.3 แผนภาพบล็อกของการรวมแบบทางข้อมูล

2.3.2 การรวมแบบทางผลการตัดสินใจ (Decision fusion)

การรวมแบบทางผลการตัดสินใจมีจุดประสงค์เพื่อวิเคราะห์ผลการตัดสินใจจากการลงคะแนนของแต่ละแถบย่อย โดยมาจากแนวคิดพื้นฐานที่ว่า การใช้ผลการตัดสินใจจากหลายตัว

จำแนกมาช่วยกันพิจารณาน่าจะให้ผลการตัดสินใจที่ดีกว่าการใช้ตัวจำแนกเพียงตัวเดียว ซึ่งเป็นแนวคิดของระบบหลายตัวจำแนกนั่นเอง การรวมแบบทางผลการตัดสินใจจะทำการพิจารณาทุก ๆ แล้วย่อยอย่างเป็นอิสระต่อกันในทุก ๆ ขั้นตอน นับตั้งแต่ขั้นตอนการสกัดคุณลักษณะ ไปจนถึงขั้นตอนการจำแนก ซึ่งทำให้มีผลการตัดสินใจออกมาหลายแบบ ดังนั้น ในขั้นตอนสุดท้ายจะทำการสรุปผล โดยดูจากผลของการตัดสินใจที่มีการลงคะแนนให้มากที่สุด เพื่อสรุปว่าเป็นใบหน้าบุคคลใด ดังแสดงในรูปที่ 2.4 โดยจะสังเกตได้ว่าขนาดของแล้วย่อยที่นำมารวม ไม่มีผลในการรวมแบบทางผลการตัดสินใจ เนื่องจากแต่ละแล้วย่อยจะให้ผลการตัดสินใจออกมาเพียงหนึ่งเดียวเท่านั้น ซึ่งสามารถกล่าวได้ว่า วิธีการนี้เป็นหนึ่งในระบบหลายตัวจำแนกที่ไม่มีการถ่วงน้ำหนักนั่นเอง



รูปที่ 2.4 แผนภาพบล็อกของการรวมแบบทางผลการตัดสินใจ

2.4 การเลือกคุณลักษณะ (Feature selection)


การเลือกคุณลักษณะเป็นทางเลือกหนึ่งที่ใช้ในการแก้ไขปัญหา ในกรณีที่คุณลักษณะเด่นที่สกัดออกมาได้นั้น มีมากเกินไปจนต้องการใช้ ดังนั้น จึงควรมีวิธีที่ใช้ในการพิจารณาว่าควรเลือกคุณลักษณะใดบ้างมาใช้ การเลือกคุณลักษณะสามารถแบ่งออกเป็น 2 วิธีหลัก คือ วิธีตัวกรอง (Filters) และวิธีห่อหุ้ม (Wrappers)

วิธีตัวกรอง เลือกคุณลักษณะโดยใช้ขั้นตอนประมวลผลก่อน (Preprocessing step) ดังแสดงในรูปที่ 2.5 ทำงานเป็นอิสระกับขั้นตอนวิธีอุปนัย (Induction algorithm) ซึ่งคือฟังก์ชันที่ใช้ตัวจำแนกที่มีอยู่ในการสร้างตัวจำแนกใหม่ได้ วิธีตัวกรองทำหน้าที่เป็นตัวกรองในการกรองคุณลักษณะที่ไม่มีประโยชน์ออก จุดด้อยของวิธีนี้ คือ การไม่คำนึงถึงความเอนเอียงของขั้นตอนวิธีอุปนัย และเลือกเซตย่อยของคุณลักษณะที่เป็นอิสระต่อขั้นตอนวิธีอุปนัย ซึ่งทำให้วิธีนี้ไม่สามารถดึงคุณลักษณะที่ซ้ำซ้อน หรือไม่มีประโยชน์ออกได้อย่างมีประสิทธิภาพ [19]



รูปที่ 2.5 แผนภาพบล็อกของวิธีตัวกรอง

วิธีห่อหุ้ม มีขั้นตอนวิธีการเลือกเซตย่อยของคุณลักษณะเป็นตัวห่อหุ้มรอบขั้นตอนวิธีอุปนัย ซึ่งขั้นตอนวิธีการเลือกเซตย่อยของคุณลักษณะค้นหาเซตย่อยที่ดีที่สุดโดยใช้ขั้นตอนวิธีอุปนัย โดยตัวมันเองเป็นส่วนหนึ่งของฟังก์ชันในการประเมินค่าเซตย่อยคุณลักษณะ การทำงานของวิธีห่อหุ้มแสดงในรูปที่ 2.6



รูปที่ 2.6 แผนภาพบล็อกของวิธีห่อหุ้ม

โดยพิจารณาขั้นตอนวิธีอุปนัยเป็นกล่องดำ ขั้นตอนวิธีอุปนัยถูกดำเนินการบนชุดข้อมูลที่แบ่งออกเป็นชุดที่ฝึกสอนภายใน และชุดที่ปิดบังไว้ ซึ่งมีการนำเซตของคุณลักษณะที่ต่างกันออกจากข้อมูล เซตย่อยของคุณลักษณะที่มีการประเมินค่าสูงที่สุดถูกเลือกเป็นเซตสุดท้ายในการดำเนินการขั้นตอนวิธีอุปนัย ผลที่ได้จากตัวจำแนกถูกประเมินบนเซตทดสอบอิสระที่ไม่ได้ใช้ในการค้นหา จุดด้อยของวิธีนี้คือ ใช้เวลาในการคำนวณนาน และมีการคำนวณในขั้นตอนวิธีอุปนัยอย่างละเอียด ซึ่งคล้ายกับการทำแบบทุกกรณี (Brute force)

วิธีตัวกรองเป็นวิธีที่ง่าย, ใช้ตัวเลือกน้อยกว่า และทำงานได้รวดเร็วกว่าวิธีห่อหุ้ม เนื่องจากวิธีห่อหุ้มจำเป็นต้องสร้าง และฝึกสอนตัวจำแนกสำหรับในแต่ละเซตของคุณลักษณะ ในทางกลับกันวิธีตัวกรองก็ให้ประสิทธิภาพต่ำ ถ้าเกณฑ์ในการเลือกไม่เหมาะสมกับตัวจำแนก [20] ดังนั้นในวิทยานิพนธ์นี้เลือกใช้วิธีตัวกรองในการคัดเลือกคุณลักษณะ

ลำดับในการเลือกสามารถแบ่งการเลือกคุณลักษณะออกเป็น 2 วิธีหลัก ดังต่อไปนี้

1. การเลือกแบบไปข้างหน้าโดยลำดับ (Sequential Forward Selection หรือ SFS) ซึ่งวิธีนี้เป็นวิธีการคัดเลือกคุณลักษณะวิธีแรกที่ได้นำเสนอขึ้น โดยเริ่มต้นจากเซตว่าง ในแต่ละการวนซ้ำจะมีการเลือกคุณลักษณะที่เหมาะสมกับเกณฑ์การเลือกหนึ่งคุณลักษณะ แล้วนำมาบวกกับเซตคุณลักษณะที่ถูกเลือกแล้วก่อนหน้านั้น และทำการตัดคุณลักษณะที่ถูกเลือกแล้วออกจากเซตคุณลักษณะทั้งหมด จากนั้นนำคุณลักษณะที่ยังไม่ถูกเลือกมาใช้ในการพิจารณาในการวนซ้ำครั้งต่อไป

2. การเลือกแบบย้อนกลับโดยลำดับ (Sequential Backward Elimination หรือ SBE) วิธีนี้จะเริ่มต้นจากเซตของคุณลักษณะทั้งหมด และในแต่ละการวนซ้ำ คุณลักษณะที่ดูมีความเหมาะสมกับเกณฑ์การเลือกน้อยที่สุดจะถูกตัดออกหนึ่งคุณลักษณะ

ขั้นตอนวิธีในการเลือกคุณลักษณะที่นิยมใช้ คือ วิธีการจัดลำดับตัวแปร (Variable ranking) ซึ่งวิธีนี้ไม่จำเป็นต้องสร้างตัวทำนายขึ้น แต่จะใช้ความสัมพันธ์กันของตัวแปรเป็นเกณฑ์การคัดเลือกคุณลักษณะที่เหมาะสม [20] มีหลายงานวิจัยใช้เกณฑ์การเลือกคุณลักษณะจากทฤษฎีสารสนเทศ (Information theoretic) [21-24] ซึ่งเป็นการประมาณค่าที่ได้จากการทดลองของค่าสาระที่เกิดร่วมกัน (Mutual information) ระหว่างแต่ละตัวแปรกับตัวแปรที่ต้องการหาความสัมพันธ์ แต่ทว่าการประมาณค่าสาระที่เกิดร่วมกันจะปฏิบัติได้ยากขึ้นเมื่อจำนวนของคลาสและตัวแปรมีขนาดใหญ่

มีงานวิจัยที่ใช้ทฤษฎีสารสนเทศในการคัดเลือกคุณลักษณะ โดยพิจารณาการสกัดคุณลักษณะจากเวฟเล็ตแพ็คเกต โดยใช้การสกัดคุณลักษณะทางพลังงานจากทุกแถบย่อย และใช้พลังงานดังกล่าวในการจำแนกประเภท [25] การใช้คุณลักษณะทางพลังงานเป็นความรู้พื้นฐานทางด้านการรู้จำแบบ ซึ่งการคัดเลือกคุณลักษณะที่เหมาะสมเป็นการปรับปรุงความถูกต้องในการจำแนกเช่นกัน [26] ในขณะเดียวกันบางคุณสมบัติจากการแปลงเวฟเล็ต เช่น คุณลักษณะของการแทนต้นไม้โอเวอร์คอมพลีท (Overcomplete tree representation) สามารถช่วยให้มีผลการจำแนกที่ดีขึ้นได้ ในการเลือกแถบย่อย ทำการเลือกแถบย่อยที่มีความเป็นอิสระต่อกันมากที่สุดเท่าที่จะเป็นไปได้มาใช้ประกอบกัน เพื่อให้มีการแทนที่ใช้แถบย่อยจำนวนน้อย และมีผลการจำแนกที่ดีขึ้น [25, 27-29]

ในหัวข้อที่ 2.4 นี้แบ่งออกเป็น 4 หัวข้อดังต่อไปนี้ ซึ่งคือ ค่าพลังงานจากแถบย่อยในหัวข้อที่ 2.4.1 จากนั้นมีการกล่าวถึงวิธีสาระที่เกิดร่วมกันในหัวข้อที่ 2.4.2 การลดอันดับของแบบจำลองในหัวข้อที่ 2.4.3 และขั้นตอนวิธีการรวมแถบย่อยในหัวข้อที่ 2.4.4


2.4.1 ค่าพลังงานจากแถบย่อย

สำหรับการพิจารณาค่าพลังงานในการคัดเลือกแถบย่อย มีสมมติฐานว่าค่าพลังงานจากแถบย่อยที่แตกต่างกันเป็นอิสระต่อกัน แต่ทว่าในความจริงแล้วแถบย่อยที่ต่างกันยังคงมีความสัมพันธ์แบบพหุคูณ ซึ่งการวัดความเป็นอิสระต่อกันจากความสัมพันธ์ดังกล่าว สามารถวัดได้จากความมีสภาวะที่เกิดร่วมกัน [30] ได้

มีฟังก์ชันพลังงานมากมายที่ใช้ในการสกัดคุณลักษณะจากแถบย่อยเพื่อนำไปใช้ในการจำแนก ซึ่งฟังก์ชันพลังงานพื้นฐานที่มีการนำมาใช้นั้นประกอบด้วย ฟังก์ชันขนาด $|\bullet|$, ฟังก์ชันขนาดยกกำลังสอง $(\bullet)^2$ และฟังก์ชันเรกติไฟด์ซิกมอยด์ (Rectified sigmoid) $|\tan h(\alpha)\bullet|$ [31] ซึ่งทั้งฟังก์ชันขนาด และฟังก์ชันขนาดยกกำลังสองไม่มีการอิงตัวแปรเสริม แต่ว่าฟังก์ชันเรกติไฟด์ซิกมอยด์ มีการปรับตัวแปรเสริมจากตัวแปร α ซึ่งฟังก์ชันค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐานของสัมประสิทธิ์ของแถบย่อยก็สามารถใช้เป็นคุณลักษณะที่สกัดได้เช่นกัน [32-33] โดยทั่วไปแล้วฟังก์ชันพลังงานที่กล่าวมาต่างก็มีความสัมพันธ์ร่วมกัน แต่ในงานวิจัย [14] ได้เลือกใช้ฟังก์ชันขนาดยกกำลังสอง การวัดค่าพลังงานจากแถบย่อยมีการพิจารณา ซึ่งพลังงานจากแถบย่อยที่แตกต่างกันสามารถคำนวณได้จากสมการที่ (2.15)

$$\sigma_p^2(k) = \sum_i \sum_j [C_k^p(i, j)]^2 \quad (2.15)$$

โดยที่ $\sigma_p^2(k)$ คือ ค่าพลังงานที่โหนด (p, k) ของต้นไม้การแยกเวฟเล็ตซึ่งแสดงในรูปที่ 2.7 และ $C_k^p(i, j)$ คือ ค่าสัมประสิทธิ์เวฟเล็ตที่ตำแหน่ง (i, j) ของแถบย่อยที่โหนด (p, k) โดยสิ่งที่ได้จากพลังงานจากแต่ละแถบย่อยเป็นการวัดความเป็นลักษณะเฉพาะตัวของแถบย่อยนั้น ๆ และการแจกแจงของพลังงานยังมีคุณสมบัติเกี่ยวกับการแยกแยะที่สำคัญ ซึ่งสามารถใช้เป็นคุณลักษณะได้



รูปที่ 2.7 แผนภาพต้นไม้การแยกเวฟเล็ตสองระดับ

2.4.2 วิธีสสารที่เกิดร่วมกัน (Mutual information)

เมื่อพิจารณาความเป็นอิสระต่อกันระหว่างค่าพลังงานงานของสองแถบความถี่ย่อยพบว่าการใช้ค่าความแปรปรวนร่วม (Covariance) เป็นอีกวิธีหนึ่งที่สามารถนำมาใช้หาความเป็นอิสระต่อกันของสองตัวแปรได้ [14] แต่ทว่าวิธีนี้ไม่สามารถหาความเป็นอิสระต่อกันระหว่างตัวแปรกับเซตของตัวแปรได้ ยิ่งไปกว่านั้น เมื่อข้อมูลไม่ได้เป็นการแจกแจงแบบปกติ การหาความแปรปรวนร่วมอย่างเดียวก็น่าจะเพียงพอที่จะนำมาวัดความเป็นอิสระต่อกันได้ และนั่นคือเหตุผลในการนำวิธีสสารที่เกิดร่วมกันมาใช้ ซึ่งวิธีนี้สามารถใช้วัดความเป็นอิสระต่อกันระหว่างตัวแปรกับเซตของตัวแปรได้ ทั้งนี้วิธีสสารที่เกิดร่วมกันเป็นที่นิยมใช้อย่างกว้างขวางด้านกรวิจิสเทรชันภาพ (Image registration) การคัดเลือกคุณลักษณะ และการจำแนกประเภท [35-36]

พิจารณาตัวแปรสุ่ม $X \in \tilde{X}$ และ $Y \in \tilde{Y}$ ซึ่งมีการแจกแจงร่วม คือ $p(x, y)$ โดยสสารที่เกิดร่วมกันระหว่าง X และ Y สามารถนิยามได้ดังสมการที่ (2.16)

$$\begin{aligned} I(X;Y) &= \sum_{x \in \tilde{X}} \sum_{y \in \tilde{Y}} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \\ &= E_{XY} \left[\log \frac{p(x, y)}{p(x)p(y)} \right] \\ &= D(p(x, y) \| p(x)p(y)) \end{aligned} \quad (2.16)$$

โดยที่ $D(\bullet \| \bullet)$ คือ เอนโทรปีสัมพัทธ์ (Relative entropy) หรือ คูลแบค-ลิปเบลอร์ ไดเวอร์เจนซ์ (Kullback-Leibler divergence) ของฟังก์ชันความน่าจะเป็น $p(x, y)$ และ $p(x)p(y)$ ในสมการที่ (2.16) จากความสัมพันธ์ในสมการที่ (2.16) จะเห็นว่า สสารที่เกิดร่วมกันของ X และ Y มีความสมมาตร ไม่ใช่ค่าลบ (Nonnegative) และเป็นศูนย์เมื่อ X และ Y เป็นอิสระต่อกัน

ค่าสสารที่เกิดร่วมกัน $I(X;Y)$ แสดงให้เห็นว่ามีสสารใน Y เท่าไรที่สามารถแสดงถึง X ได้ การที่รู้ Y ซึ่งเป็นสสารเพิ่มเติมที่ใช้ในการอธิบาย X สามารถหาได้จากเอนโทรปีเงื่อนไข (Conditional entropy) $H(X | Y)$ [34] เป็นไปตามสมการที่ (2.17)

$$I(X;Y) = H(X) - H(X | Y) \quad (2.17)$$

โดยที่ $H(X)$ คือ เอนโทรปีของตัวแปรสุ่ม X ซึ่งคล้ายกันกับนิยามของเอนโทรปีเงื่อนไขซึ่งค่าสสารที่เกิดร่วมกันแบบเงื่อนไข (Conditional mutual information) ระหว่างตัวแปรสุ่ม X และ Y กำหนด Z แสดงในสมการที่ (2.18)

$$\begin{aligned}
 I(X;Z|Y) &= H(X|Z) - H(X|Y,Z) \\
 &= E_{p(x,y,z)} \left[\log \frac{p(X,Z|Y)}{p(X|Z)p(Y|Z)} \right]
 \end{aligned}
 \tag{2.18}$$


สาระแบบเงื่อนไขสามารถมองว่าคล้ายกันกับการคิดแบบค่าสาระที่เกิดร่วมกัน จากการนิยามข้างต้น ค่าสาระที่เกิดร่วมกันระหว่างเซตตัวแปรสุ่ม $\{X_1, X_2, \dots, X_n\}$ และตัวแปรสุ่มเดี่ยว Y สามารถนิยามได้ดังสมการที่ (2.19)

$$I(X_1, X_2, \dots, X_n; Y) = \sum_{i=1}^n I(X_i; Y | X_{i-1}, X_{i-2}, \dots, X_1)
 \tag{2.19}$$

นิยามของสาระที่เกิดร่วมกันสามารถนำไปใช้ในการประมาณค่าความเป็นอิสระต่อกันระหว่างคุณลักษณะที่สกัดได้จากเซตของแถบย่อย U และแถบย่อยเดี่ยว $WS_i(k)$ ได้ ซึ่งถ้าค่าสาระที่เกิดร่วมกันมีค่ามาก ค่านี้เป็นการแสดงถึงความสามารถในการประมาณการแจกแจงของ $WS_i(k)$ จาก U ได้ง่ายขึ้น ดังนั้น วิธีสาระที่เกิดร่วมกันนี้ สามารถใช้เป็นขั้นตอนหนึ่งในการเลือกแถบย่อยได้

2.4.3 การลดอันดับของแบบจำลอง

เมื่อพิจารณาพจน์ทางด้านขวามือของสมการที่ (2.19) พบว่าการประมาณค่าของฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (Joint probability density function) และเนื่องจากแถบย่อยซึ่งเป็นไปได้ว่าอาจจะมีขนาดใหญ่ของเซต U ส่งผลให้เกิดการคำนวณที่ยุ่งยากเมื่อต้องนำมาปฏิบัติจริง ตัวอย่างเช่น ถ้ามีภาพซึ่งถูกแยกโดยเวฟเล็ตเพ็คเก็ต 3 ระดับ พบว่ามีแถบย่อยถึง 85 แถบ การประมาณค่าการแจกแจงที่มีมิติสูงเช่นนั้นถือว่าการไม่มีประสิทธิภาพ และไม่น่าเชื่อถือพอ ดังนั้นเพื่อหลีกเลี่ยงปัญหาดังกล่าว ใน [14] ได้มีการสมมติว่าเซตของตัวแปรสุ่ม $\{X_1, X_2, \dots, X_n\}$ ให้สาระแก่ Y เป็นแบบหลายค่าสู่ค่าเดียว (Many-to-one) จึงทำการแปลงแบบสเกลาร์ (Scalar-mapping) เป็น $T = f(X_1, X_2, \dots, X_n)$ ดังนั้น สาระที่เกิดร่วมกัน $I(X_1, X_2, \dots, X_n; Y)$ สามารถคำนวณเป็น $I(T; Y)$ ได้ ซึ่งแสดงดังรูปที่ 2.8



รูปที่ 2.8 การลดมิติของสาระที่เกิดร่วมกันผ่านฟังก์ชันการแปลงแบบหลายค่าสู่ค่าเดียว

จากสมมติฐานว่าความสัมพันธ์ที่เกี่ยวเนื่องกันสร้างมาร์คอฟลูกโซ่ (Markov chain) โดยใช้ฟังก์ชัน $f(\bullet)$ มีความสัมพันธ์เป็น $Y \rightarrow \{X_1, X_2, \dots, X_n\} \rightarrow T$ เมื่อมีการประยุกต์ใช้ทฤษฎีการประมวลผลข้อมูล (Data-processing theorem) [21] กับความสัมพันธ์ข้างต้นทำให้ได้สมการที่ (2.20) ดังนี้

$$I(X_1, X_2, \dots, X_n; Y) \geq I(T; Y) \quad (2.20)$$

การเท่ากันของสมการที่ (2.20) จะเกิดขึ้นก็ต่อเมื่อ $T = f(X_1, X_2, \dots, X_n)$ มีความพอเพียงทางสถิติสำหรับ $\{X_1, X_2, \dots, X_n\}$ [34] ซึ่งเป็นการยากที่จะเกิดกรณีนี้ขึ้นได้ในทางปฏิบัติ ดังนั้นการหาฟังก์ชัน $f(\bullet)$ ที่เหมาะสมเป็นสิ่งสำคัญเพื่อนำไปสู่ค่าผิดพลาดที่น้อยที่สุด เมื่อค่าสภาวะที่เกิดร่วมกัน $I(X_1, X_2, \dots, X_n; Y)$ เป็นขอบบนของค่าสภาวะที่เกิดร่วมกันแบบประมาณ $I(T; Y)$ ดังนั้น ฟังก์ชัน $f(\bullet)$ ควรจะประมาณค่า $I(T; Y)$ ให้ได้ค่าสูงสุด

ปัญหาการเลือกฟังก์ชันแบบดังกล่าวเกิดขึ้นกับงานวิจัยทางด้านแบบจำลองทางสถิติของค่าสัมประสิทธิ์เวฟเล็ต (Statistic modeling of wavelet coefficients) และมีการแก้ปัญหาอยู่ในงานวิจัย [30, 37] มีการเสนอฟังก์ชัน $f(\bullet)$ ที่ได้จากการทดลองหลายทางเลือก ซึ่งมีการพิสูจน์แล้วว่าฟังก์ชันการรวมกันแบบเชิงเส้นให้ผลที่ดี ด้วยเหตุนี้ ในงานวิจัย [14] จึงได้เลือกใช้การรวมแบบเชิงเส้นของค่าพลังงานดังสมการที่ (2.21)

$$T = f(X_1, X_2, \dots, X_n) = \sum_{i=1}^n W_i X_i \quad (2.21)$$

ในทางทฤษฎีนั้น การเลือกสัมประสิทธิ์ตัวถ่วงน้ำหนัก $\{W_i\}$ ควรจะทำให้เกิดสภาวะที่เกิดร่วมกันตามสมการที่ (2.21) มีค่าสูงสุด ในงานวิจัย [14] ได้เสนอ 2 วิธีในการหาค่าสัมประสิทธิ์ตัวถ่วงน้ำหนัก $\{W_i\}$ คือ ให้ $W_i = 1$ และ ให้มีการปรับ W_i โดยขึ้นอยู่กับความสัมพันธ์ของ X_i และ Y ซึ่งกรณีที่ใช้การปรับ W_i ให้สภาวะที่เกิดร่วมกันแตกต่างจากกรณีที่ $W_i = 1$ น้อยมาก ดังนั้น เราได้เลือกใช้กรณี $W_i = 1$ ซึ่งเป็นการง่ายที่จะนำไปประยุกต์ใช้มากกว่า

จากนิยามเบื้องต้นของสภาวะที่เกิดร่วมกันเป็นการใช้ฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบต่อเนื่อง แต่ในการประยุกต์ใช้จริงนั้นเป็นการวัดค่าสภาวะที่เกิดร่วมกันระหว่างเวกเตอร์แบบไม่ต่อเนื่อง X และเวกเตอร์แบบไม่ต่อเนื่อง T ดังนั้น จึงจำเป็นต้องมีการประมาณค่าขึ้น ซึ่งปัญหาการประมาณค่าดังกล่าวมีการศึกษามาแล้วในงานวิจัย [38-39] โดยปกติแล้วขอบเขตของ X และ T สามารถแบ่งออกเป็น N_x และ N_T ช่วงตามลำดับได้ ฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบต่อเนื่อง $p(x, t)$ สามารถประมาณโดยใช้ฮิสโทแกรมสองมิติได้เป็น

$\{P_{X,T}(i,j), 1 \leq i \leq N_X, 1 \leq j \leq N_T\}$ ซึ่งในวิธีเดียวกัน การแจกแจงตามขอบ (Marginal Distribution) $p_X(x)$ และ $p_T(t)$ สามารถประมาณเป็น $P_X(i)$ และ $P_T(j)$ ตามลำดับได้ จากการประมาณการแจกแจงความน่าจะเป็นแบบไม่ต่อเนื่อง สาระที่เกิตร่วมกันสามารถคำนวณได้จากสมการที่ (2.22)

$$\hat{I}(X;T) = \sum_i \sum_j P_{X,T}(i,j) \log \frac{P_{X,T}(i,j)}{P_X(i)P_T(j)} \quad (2.22)$$

ถ้าการดำเนินการสุ่ม (Random process) X และ T เป็นแบบสเตชันนารี (Stationary) และเออร์โกดิก (Ergodic) ดังนั้น การใช้ฮิสโทแกรมจึงเป็นวิธีที่เชื่อถือได้ และส่งผลให้ $\hat{I}(X;T)$ ใกล้เคียง $I(X;T)$ [14]

2.4.4 ขั้นตอนวิธีการรวมแถบย่อย

ขั้นตอนวิธีการรวมแถบย่อยนำเสนอการรวมแถบย่อยซึ่งมาจากหลายเวฟเล็ตแม่ในการนำมาประกอบกัน โดยมีสมมติฐานว่าค่าพลังงานจากแถบย่อยที่แตกต่างกัน และจากเวฟเล็ตแม่ที่แตกต่างกันน่าจะมีเกี่ยวข้องกันอยู่ จากสมมติฐานนี้ทำให้เกิดแนวคิดการรวมแถบย่อยที่มีความเป็นอิสระจากทั้งหนึ่ง และหลาย ๆ เวฟเล็ตแม่ [14] เพื่อสร้างการแทนโดยใช้แถบย่อยจำนวนน้อยลง ในทางปฏิบัติแล้ว เนื่องจากไม่สามารถสร้างแบบจำลองทางสถิติของภาพได้ ดังนั้นจึงไม่สามารถคำนวณความเป็นอิสระต่อกันได้โดยตรง แต่อย่างไรก็ตาม ความสัมพันธ์ด้านความเป็นอิสระกันหรือไม่ ของค่าพลังงานจากแถบย่อยที่แตกต่างกัน สามารถประมาณได้โดยวิธีไม่อิงตัวแปรที่ใช้ตัวอย่างในการฝึกสอนได้ สำหรับตัวอย่างที่กำหนดใช้ในการฝึกสอนนั้น ค่าความเป็นอิสระต่อกันสามารถประมาณได้จากการใช้ข้อมูลในการฝึกสอน จากการประมาณค่านี้ทำให้สามารถเลือกแถบย่อยที่มีจำนวนน้อยในการแทนสำหรับการจำแนกต่อไปได้ กำหนดเซตตัวอย่างภาพที่ใช้ในการฝึกสอน T_n และเซตตัวอย่างที่ใช้ในการทดสอบ T_c ในการจำแนก และขั้นตอนวิธีการเลือกแถบย่อยจากหลายเวฟเล็ตแม่ $WS = \{WS_1, WS_2, \dots, WS_N\}$ ในการสร้างการแทนที่ใช้จำนวนน้อยสามารถสร้างได้ ดังนี้

1. ทำการสกัดค่าพลังงานจากทุกแถบย่อย ในแต่ละภาพ $A_i \in T_n$ โดยการแยกแถบย่อยในแต่ละระดับนั้น ขนาดของแถบย่อยจะลดลงไป 4 เท่า และถ้าแถบย่อยมีขนาดเล็กเกินไป พลังงานที่ได้จะไม่ทนทานพอ ดังนั้นในทางปฏิบัติจะใช้แถบย่อยที่มีขนาดเล็กที่สุดคือ 16×16 จุดภาพ

2. แบ่งแถบย่อยออกเป็นสองเซต คือ เซต U และเซต R โดยกำหนดเซต U เริ่มต้นให้เป็นแถบย่อยที่มีพลังงานสูงที่สุด และ $R = WS \setminus U$
3. ทำการเลือกแถบย่อย $WS_i(k)$ จากเซต R ไปรวมกับเซต U โดยเลือกแถบย่อย $WS_i(k)$ ที่มีความเป็นอิสระต่อเซต U มากที่สุด ดังสมการที่ (2.23)

$$(i, k) = \arg \min_{j, l} \{I(WS_j(l); U)\} \quad (2.23)$$

โดย $WS_i(k)$ คือ แถบย่อยลำดับที่ k จากเวฟเล็ตแม่ที่ i ซึ่งในที่นี้เลือกใช้วิธีสภาวะที่เกิดร่วมกัน I ในการวัดความเป็นอิสระต่อกัน โดยการคำนวณค่าสภาวะที่เกิดร่วมกันได้กล่าวไว้แล้วในหัวข้อ 2.4.3 โดยขั้นตอนส่วนนี้จะหยุดเมื่อจำนวนแถบย่อยใน U ถึงจำนวนที่กำหนดไว้ จากนั้นนำแถบย่อยจากในเซต U มาสร้างเป็นการแทนที่ใช้จำนวนน้อยได้ โดยจุดประสงค์ของการเลือกแถบย่อยนี้ใช้เมื่อการจำแนก ไม่ใช่เพื่อการคืนกลับของภาพ

4. ทำการสกัดค่าพลังงานจากเซตของแถบย่อย U ในทุกภาพใน T_c เพื่อใช้ในการทดสอบ
5. ใช้ระยะยุคลิด (Euclidean distance) ในการวัดประสิทธิภาพในการจำแนก โดยระยะยุคลิดระหว่างสองเวกเตอร์คุณลักษณะ F_1 และ F_2 แสดงในสมการที่ (2.24)

$$Dist = \sqrt{\sum_{k=1}^D |F_1(k) - F_2(k)|^2} \quad (2.24)$$

โดยที่ D คือ มิติของทั้งสองเวกเตอร์

บทที่ 3

วิธีการที่นำเสนอ

3.1 การวิเคราะห์แถบย่อยสำหรับการรู้จำใบหน้า

แถบย่อยที่ได้จากการวิเคราะห์หลายอำนาจจำแนก หรือการแปลงเวฟเล็ตในวิทยานิพนธ์นี้ สามารถนำมาใช้วิเคราะห์การรู้จำใบหน้าได้ เนื่องจากแถบย่อยนั้นมีจำนวนมากว่าหนึ่ง ซึ่งแต่ละแถบย่อยให้ข้อมูลสาระที่เหมือนกัน และแตกต่างกันทับซ้อนกันไป เพื่อปรับปรุงประสิทธิภาพของระบบการรู้จำใบหน้า การรวมแบบต่าง ๆ ที่กล่าวในบทที่ 2 เป็นวิธีหนึ่งที่ใช้ในการนำแถบย่อยหลายแถบมาใช้ประกอบกันในการวิเคราะห์ แต่ทว่าในงานวิจัยที่ผ่านมา [6] ได้เสนอเพียงแนวทางในการเลือกแถบย่อยมาประกอบกันเท่านั้น ไม่ได้กล่าวถึงหลักการในการเลือกแถบย่อยเพื่อทำการรู้จำใบหน้าที่ชัดเจน ในวิทยานิพนธ์นี้ได้นำเสนอแนวคิดจากการรวมแบบต่าง ๆ มาประยุกต์เป็นวิธีการรวมแบบใหม่ที่สามารถปรับปรุงระบบการรู้จำใบหน้าให้ดีขึ้นได้ ซึ่งมีการอธิบายในหัวข้อที่ 3.2

จากการพิจารณาปัญหาในการเลือกกลุ่มแถบย่อยที่เหมาะสมเพื่อนำมาใช้ในการรวม ดังนั้น เทคนิคการเลือกคุณลักษณะซึ่งนำมาใช้เพื่อเลือกแถบย่อยได้น่าจะเป็นทางเลือกหนึ่งของการแก้ปัญหา มีแนวคิดมากมายที่นำเสนอเพื่อทำการเลือกแถบย่อย แต่ในวิทยานิพนธ์นี้ได้เลือกแนวคิดจากวิธีสภาวะที่เกิดร่วมกัน (Mutual information) เป็นพื้นฐานในการประยุกต์ใช้ โดยวิธีนี้สามารถใช้วัดค่าการมีสภาวะร่วมกันของตัวแปรต่างๆ ซึ่งคือ แถบย่อยในวิทยานิพนธ์นี้ได้ สำหรับวิธีการที่นำเสนอเพื่อทำการเลือกจะกล่าวโดยละเอียดต่อไปในหัวข้อที่ 3.3

สำหรับการวิเคราะห์ปริภูมิย่อยในทุก ๆ การรวมได้เลือกใช้การวิเคราะห์โดย PCA โดยพิจารณาการเลือกจำนวนแกนจากอัตราส่วนของผลรวมของค่าลักษณะเฉพาะ λ โดยที่ k คือจำนวนแกนที่เลือก และ M คือ จำนวนแกนที่มีอยู่ทั้งหมด ดังแสดงในสมการที่ (3.1)

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{j=1}^M \lambda_j} \geq 0.99 \quad (3.1)$$

และ สำหรับตัวจำแนกที่เลือกใช้ในการรวม คือ ระยะทางแบบนอร์มหนึ่ง ดังแสดงในสมการที่ (3.2)

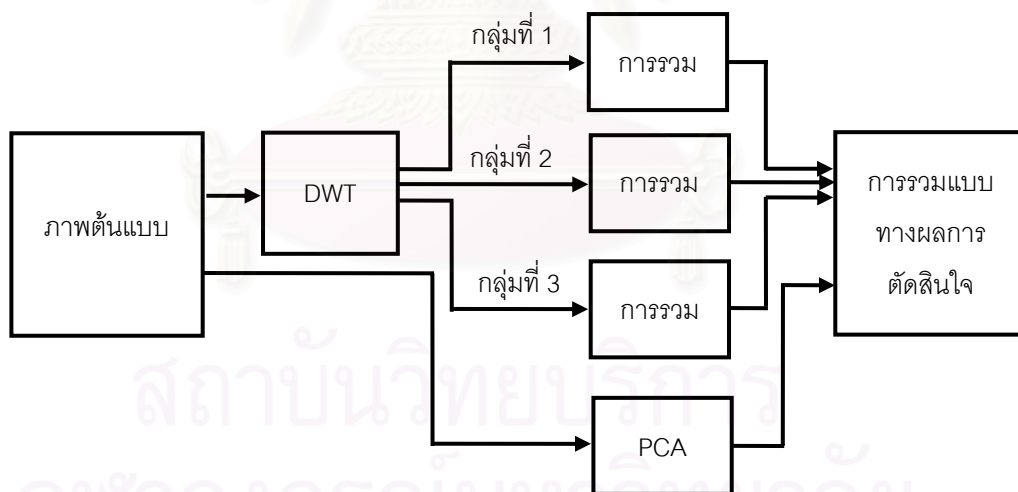
$$L1: d(\Omega_{training}, \Omega_{testing}) = \|\Omega_{training} - \Omega_{testing}\|_1 \quad (3.2)$$

3.2 ระบบหลายตัวจำแนกสองระดับ

จากแนวคิดของการรวม ซึ่งคือ ระบบหลายตัวจำแนกที่ได้จากการรวมตัวจำแนกต่าง ๆ ที่เป็นอิสระต่อกัน สามารถนำมาปรับปรุงประสิทธิภาพของระบบได้ ดังนั้นจึงได้มีการนำระบบหลายตัวจำแนกนี้มาพิจารณาทบทวนอีกระดับหนึ่ง โดยเรียกวิธีนี้ว่า “ระบบหลายตัวจำแนกสองระดับ” ซึ่งเป็นส่วนที่หนึ่งของแนวคิดที่นำเสนอในวิทยานิพนธ์ การที่เพื่อใช้ปรับปรุงประสิทธิภาพของระบบการรู้จำใบหน้าให้ดียิ่งขึ้นได้

วิธีระบบหลายตัวจำแนกสองระดับที่นำเสนอในวิทยานิพนธ์นี้ ได้ใช้การรวมแบบต่าง ๆ ซึ่งคือ การรวมแบบทางข้อมูล และการรวมแบบทางผลการตัดสินใจ เป็นระบบหลายตัวจำแนกในระดับที่หนึ่ง เพื่อทำการรวมโดยอาศัยคุณสมบัติที่ต่างกันของทั้งสองการรวมนี้ในการวิเคราะห์ ส่วนระบบหลายตัวจำแนกในระดับที่สอง ได้นำผลจากระดับแรกมารวมกันแบบทางผลการตัดสินใจ หรือ การลงคะแนนเสียงดังแสดงในรูปที่ 3.1


ในหัวข้อนี้กล่าวถึง การรวมแบบทางข้อมูลในระดับที่หนึ่งในหัวข้อที่ 3.2.1, การรวมแบบทางผลการตัดสินใจในหัวข้อที่ 3.2.2 และกล่าวถึงข้อมูลขาเข้าของระบบหลายตัวจำแนกสองระดับในหัวข้อที่ 3.2.3



รูปที่ 3.1 แผนภาพบล็อกของระบบหลายตัวจำแนกสองระดับ

3.2.1 การรวมแบบทางข้อมูลในระดับที่หนึ่ง (1st Level: Data fusion)

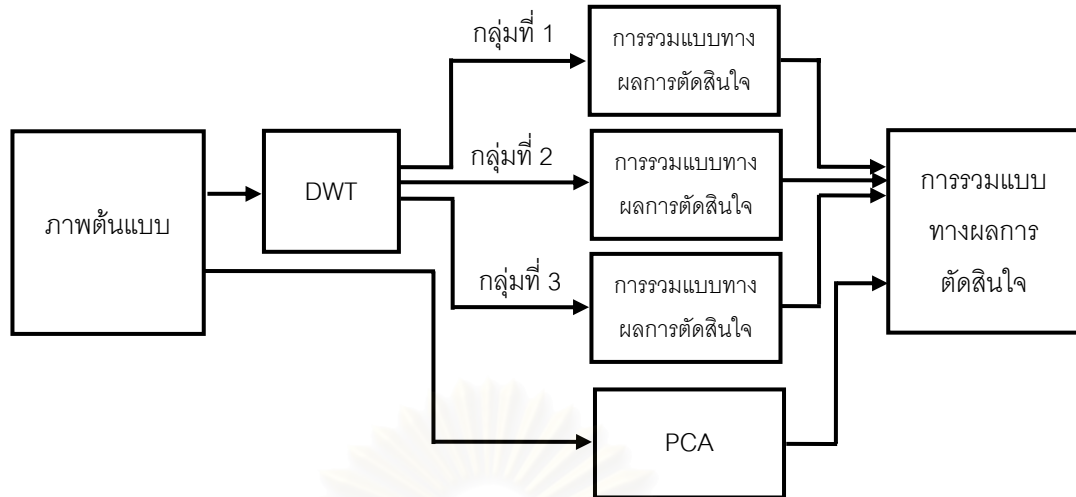
การนำการรวมแบบทางข้อมูลมาใช้ในระดับที่หนึ่ง เพราะต้องการให้มีข้อมูลมีเพิ่มขึ้นจากการรวมข้อมูลของกลุ่มแยกย่อยที่เป็นข้อมูลขาเข้า ซึ่งเป็นการรวมแบบขนาดของแยกย่อยมีผลต่อระบบ โดยผลการรู้จำจากการรวมแบบทางข้อมูลที่ได้มีตามจำนวนกลุ่มแยกย่อยที่ใช้เป็นข้อมูลขาเข้า ซึ่งแต่ละกลุ่มจะมีแยกย่อยที่สมาชิก ซึ่งอาจจะเหมือนและต่างกัน ดังนั้นผลที่ได้จากแต่ละกลุ่มแยกย่อยก็จะให้ผลที่แตกต่างกัน และใช้การรวมแบบทางผลการตัดสินใจเป็นระบบหลายตัวจำแนกระดับที่สองเพื่อสรุปผลที่แตกต่างกันจากระบบหลายตัวจำแนกระดับที่หนึ่ง ซึ่งน่าจะให้ผลการตัดสินใจที่แม่นยำมากขึ้นได้ โดยแผนภาพบล็อกของการรวมแบบทางข้อมูลระดับที่หนึ่งแสดงในรูปที่ 3.2



รูปที่ 3.2 แผนภาพบล็อกการรวมแบบทางข้อมูลในระดับที่หนึ่ง

3.2.2 การรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง (1st Level: Decision fusion)


การรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง เนื่องจากต้องการผลการตัดสินใจจากหลายผู้รู้ โดยผลการตัดสินใจที่ได้มาหลากหลายจากสมาชิกภายในกลุ่มแยกย่อยมาใช้ประกอบกันในการพิจารณา ซึ่งการรวมแบบทางผลการตัดสินใจในระดับที่หนึ่งนี้เป็นวิธีการรวมโดยต้องการพิจารณาขนาดของแต่ละแยกย่อยที่เป็นสมาชิกในกลุ่มมีความสำคัญต่อการรวมเท่ากัน ผลการตัดสินใจจากกลุ่มแยกย่อยที่ได้จากการรวมในระดับแรกจะถูกนำไปใช้ในการตัดสินใจในระบบหลายตัวจำแนกระดับที่สองอีกครั้ง ดังรูปที่ 3.3



รูปที่ 3.3 แผนภาพบล็อกการรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง

3.2.3 ข้อมูลขาเข้าของระบบหลายตัวจำแนกสองระดับ

ข้อมูลขาเข้าของระบบหลายตัวจำแนกสองระดับได้ประยุกต์ใช้การจัดการคุณสมบัติของข้อมูลขาเข้าซึ่งเป็นหนึ่งในวิธีชุดข้อมูลทั้งหมด โดยใช้การแปลงเวฟเล็ตแบบไม่ต่อเนื่อง ที่เป็นการแปลงสัญญาณจากโดเมนเวลาไปยังโดเมนความถี่ จากการคำนวณเวฟเล็ตในหลายระดับ ทำให้ได้ความละเอียดทางเวลา และความถี่อย่างหลากหลาย ซึ่งจากข้อมูลต้นแบบเดียวกันจะมีแทนที่แตกต่างกัน โดยมีความละเอียดทางเวลา และความถี่ต่างกัันนั่นเอง [12]



รูปที่ 3.4 แผนภาพต้นไม้ของการแยกเวฟเล็ตที่ใช้ในวิทยานิพนธ์

จากรูปที่ 3.4 กลุ่มแถบย่อยที่ได้จากการแปลงเวฟเล็ตแบบไม่ต่อเนื่องในระดับที่หนึ่ง คือ A1, H1, V1, และ D1 จะมีความละเอียดที่ 64×64 จุดภาพ จากนั้นในระดับที่สองจะทำการแยกเวฟเล็ตแบบไม่ต่อเนื่องเฉพาะกับแถบย่อย A1 เท่านั้น เนื่องจากในแถบย่อยอื่นๆ มีประสิทธิภาพในการจำแนกต่ำ ซึ่งแถบย่อยที่ได้ในระดับที่สอง คือ A2, H2, V2, และ D2 จะมีขนาด 32×32

จุดภาพ และในระดับที่สามจะทำการแยกเวฟเล็ตแบบไม่ต่อเนื่องเฉพาะกับแถบย่อย A2 เท่านั้น จากเหตุผลเดียวกันกับในระดับที่สองนั่นเอง โดยได้แถบย่อยที่อยู่ในระดับสุดท้าย คือ A3, H3, V3, และ D3 จะมีขนาดเป็น 16×16 จุดภาพ กลุ่มแถบย่อยที่ใช้เป็นข้อมูลขาเข้าของระบบหลายตัว จำแนกสองระดับในระดับที่หนึ่ง คือภาพต้นแบบที่ทำการปรับขนาดให้เป็น 128×128 จุดภาพ ประกอบกับ กลุ่มแถบย่อยที่ได้รับการเลือกแบบต้นไม้ออกเทพ (Octave tree) ในรูปที่ 3.4 ดังนี้


- ภาพต้นแบบขนาด 128×128 จุดภาพ
- กลุ่มที่ 1 เลือก A1 H1 V1 D1 ซึ่งเป็นแถบย่อยที่ระดับที่ 1 ทั้งหมด
- กลุ่มที่ 2 เลือก H1 V1 D1 A2 H2 V2 D2 ซึ่งเป็นแถบย่อยที่เกิดขึ้นระดับที่ 1 ยกเว้น A1 และแถบย่อยที่เกิดจากการแปลงเวฟเล็ตแบบไม่ต่อเนื่องของ A1 โดยอาจกล่าวได้ว่าเป็นตัวแทนของ A1 ในระดับที่ 2 นั่นเอง
- กลุ่มที่ 3 เลือก H1 V1 D1 H2 V2 D2 A3 H3 V3 D3 ซึ่งเป็นแถบย่อยที่เกิดขึ้นจากกลุ่มที่ 2 ประกอบกับแถบย่อยที่เกิดจากการแปลงเวฟเล็ตแบบไม่ต่อเนื่องของ A2 โดยอาจมองได้ว่าเป็นตัวแทนของ A2 ในระดับที่ 3 นั่นเอง

3.3 การเลือกแถบย่อย

ในวิทยานิพนธ์นี้ นำเสนอการนำวิธีตัวกรอง และมีการเลือกแบบ SFS ในการเลือกแถบย่อยเพื่อใช้สำหรับการรู้จำใบหน้า โดยวิธีพื้นฐานที่ใช้ในการสกัดคุณลักษณะจากแถบย่อยที่ได้จากการแยกเวฟเล็ต คือการวัดการกระจายของพลังงานจากแต่ละแถบย่อย [13-14] โดยพิจารณาค่าพลังงานที่ได้จากแต่ละแถบย่อยเป็นตัวแทนของแถบย่อยนั้น ๆ ซึ่งค่าพลังงานที่ได้เป็นการวัดค่าของลักษณะสำคัญของภาพในแต่ละแถบย่อย โดยฟังก์ชันค่าพลังงานที่เลือกใช้ในวิทยานิพนธ์นี้คือ ฟังก์ชันขนาดยกกำลังสอง $(\bullet)^2$ ดังสมการที่ (2.15) ตามที่ได้กล่าวไว้ในบทที่ 2

เนื่องจากแถบย่อยที่ได้จากการแปลงเวฟเล็ตซึ่งใช้ในวิทยานิพนธ์ตามรูปที่ 3.4 มีจำนวนทั้งหมด 12 แถบย่อย ซึ่งจำเป็นต้องมีเกณฑ์ในการเลือกแถบย่อยที่เหมาะสมขึ้น ในวิทยานิพนธ์นี้ได้ใช้ค่าสาระที่เกิตร่วมกัน (Mutual information) มาเป็นพื้นฐานในสร้างเกณฑ์การเลือกแถบย่อย โดยวิธีนี้เป็นเครื่องมือในการวัดความมีสาระที่เกิตร่วมกัน ซึ่งคือใช้วัดเป็นความสัมพันธ์ของตัวแปรหนึ่งตัวกับตัวแปรหนึ่งตัว หรือตัวแปรหนึ่งตัวกับเซตของตัวแปร ในวิทยานิพนธ์นี้ได้นำเสนอเกณฑ์การเลือกแถบย่อยทั้งหมด 3 วิธี โดยวิธีแรกได้นำขั้นตอนวิธีในการเลือกแถบย่อยที่กล่าวถึงในบทที่ 2 ซึ่งเป็นการพิจารณาเลือกแถบย่อยที่มีความเป็นอิสระต่อกันมากที่สุดมาประยุกต์ให้เข้ากับงานวิจัยทางด้านการรู้จำใบหน้า ส่วนอีก 2 เกณฑ์การเลือกนั้นได้นำเกณฑ์การ

เลือกที่นำเสนอในบทที่ 2 มาประยุกต์ใช้ โดยเป็นการพิจารณาวิธีสาระที่เกิดร่วมกันในอีกมุมมองหนึ่ง และเมื่อทำการเลือกแถบย่อยที่ต้องการได้แล้วนั้น แถบย่อยดังกล่าวได้ถูกนำไปรวมแบบทางข้อมูล และรวมแบบทางผลการตัดสินใจ เพื่อทำการรู้จำใบหน้าต่อไปนั่นเอง โดยมีแผนภาพการทำงานดังรูปที่ 3.5



รูปที่ 3.5 แผนภาพบล็อกการเลือกแถบย่อยสำหรับการรู้จำใบหน้าที่น่าสนใจในวิทยานิพนธ์

ในเกณฑ์การเลือกที่น่าสนใจมีการกำหนดตัวแปรต่าง ๆ ดังนี้

T_n = เซตตัวอย่างภาพที่ใช้ในการฝึกสอน

T_c = เซตตัวอย่างที่ใช้ในการทดสอบ

$WS = \{WS_1, WS_2, \dots, WS_N\}$ คือ แถบย่อยทั้งหมดที่ใช้ในการเลือก N

U = เซตของแถบย่อยที่เลือกได้

R = เซตของแถบย่อยที่ใช้ในการพิจารณา

I = ค่าสาระที่เกิดร่วมกัน

k = แถบย่อยที่ k ที่ถูกเลือก

ในหัวข้อการเลือกแถบย่อยที่น่าสนใจนำเสนอการเลือกแถบย่อย จากการพิจารณาเกณฑ์การเลือกที่แตกต่างกัน และจากลำดับของแถบย่อยที่เลือกต่างกัน ทั้งหมด 3 วิธี โดยการพิจารณาจากความเป็นอิสระต่อกันของแถบย่อยกล่าวถึงในหัวข้อที่ 3.3.1 และ พิจารณาจากการครอบคลุมข้อมูลของแถบย่อยในหัวข้อ 3.3.2 ที่แบ่งออกเป็นแบบแถบย่อยที่เลือกถัดไปขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้า เป็นหัวข้อที่ 3.3.2.1 และแบบแถบย่อยที่เลือกถัดไปไม่ขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้า ในหัวข้อที่ 3.3.2.2 สำหรับวิธีการประมาณค่าสาระที่เกิดร่วมกันที่ใช้ในทุกแนวคิด ที่นำเสนอของวิทยานิพนธ์นี้ ได้กล่าวในส่วนของภาคผนวก ก

3.3.1 พิจารณาจากความเป็นอิสระกันของแถบย่อย (Subband Independency หรือ SI)

เกณฑ์การเลือกนี้มีแนวทางเดียวกันกับในบทที่ 2 โดยในเกณฑ์การเลือกที่นำเสนอในวิทยานิพนธ์นี้เลือกใช้เพียงหนึ่งเวฟเล็ตแม่ ซึ่งคือ ดาบุซซี 4 และใช้เพียงการเลือกแถบย่อยที่เสนอในบทที่ 2 ซึ่งคือ เลือกจากแถบย่อยที่มีความเป็นอิสระต่อกันมากที่สุด

เกณฑ์การเลือกแบบ SI มีขั้นตอนการทำงาน ดังนี้

1. ทำการสกัดค่าพลังงานจากทุกแถบย่อย ในแต่ละภาพที่ใช้ในการฝึกสอน T_n
2. แบ่งแถบย่อยออกเป็นสองเซต คือ เซต U และ เซต R โดยกำหนดเซต U เริ่มต้นให้เป็นแถบย่อยที่มีพลังงานสูงที่สุด และ $R = WS \setminus U$
3. ทำการเลือกแถบย่อย WS_j จากเซต R ไปรวมกับเซต U โดยเลือกแถบย่อย WS_j ที่มีค่าสภาวะที่เกิดร่วมกันต่อเซต U น้อยที่สุด ดังสมการที่ (3.3)

$$(k) = \arg \min_j \{I(WS_j; U)\} \quad (3.3)$$

โดยหยุดการเลือกเมื่อทำการเลือกครบ 11 แถบย่อย

3.3.2 พิจารณาจากการครอบคลุมข้อมูลของแถบย่อย (Information Coverage หรือ IC)

จากเกณฑ์การเลือกแบบ SI ที่ใช้ความเป็นอิสระต่อกันที่วัดได้มากที่สุดของแถบย่อยในการเลือก และนำแถบย่อยดังกล่าวมาต่อรวมกัน ซึ่งการทำเช่นนี้อาจไม่มีประโยชน์ ถ้ากลุ่มแถบย่อยที่เลือกได้ให้ข้อมูลไม่ครอบคลุมกับข้อมูลทั้งหมด ดังนั้นในวิทยานิพนธ์นี้จึงได้นำเสนออีกเกณฑ์การเลือกซึ่งพิจารณาการครอบคลุมข้อมูลของแถบย่อยขึ้น ในความจริงแล้วพบว่ามีความคล้ายกันระหว่างการเลือกแถบย่อย และ PCA ซึ่งคือ เกณฑ์การเลือกแบบพิจารณาความเป็นอิสระต่อกันอาจอุปมาได้ว่าเป็นการตั้งฉากกันซึ่งเป็นคุณสมบัติหนึ่งของ PCA และการเลือกแบบครอบคลุมข้อมูลอาจอุปมาได้ว่าเป็นการคืนกลับแบบให้ค่าผิดพลาดน้อยที่สุดของ PCA ได้ โดยในการวัดการครอบคลุมข้อมูลนี้ เป็นการวัดความมีสภาวะที่เกิดร่วมกัน ระหว่างกลุ่มของแถบย่อยที่ทำการเลือกกับแถบย่อยทั้งหมดที่ใช้ในการฝึกสอน เมื่อพิจารณาจากลำดับแถบย่อยที่ได้ในแต่ละการเลือก เกณฑ์การเลือกแบบ IC นี้สามารถแบ่งได้เป็นอีก 2 เกณฑ์ คือ

3.3.2.1 แถบย่อยที่เลือกถัดไปขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้า (Information Coverage: Depend on Previously Selected Subbands หรือ IC:DPSS)

เนื่องจากในเกณฑ์การเลือกแบบ SI การเลือกแถบย่อยในลำดับถัดไปเกิดจากแถบย่อยที่เลือกได้ก่อนหน้ามาต่อกัน ซึ่งเปรียบเสมือนกับการหยิบลูกบอลสีออกจากถุง โดยไม่มีการใส่คืนก่อนการหยิบครั้งใหม่ นั่นเอง โดยยกตัวอย่างการเลือกโดยใช้เกณฑ์แบบ SI ดังนี้ ในการเลือกครั้งที่ 1 กำหนดแถบย่อยเริ่มต้น คือ A3 ในการเลือกครั้งที่ 2 เลือกได้ A1 ดังนั้นแถบย่อยที่เลือกในกรณีเลือกจำนวน 2 แถบย่อย คือ A3 A1 เช่นเดียวกันเมื่อทำการเลือกแถบย่อยครั้งที่ 3 อาจเลือกได้เป็น H2 แถบย่อยที่เลือกได้ในกรณีเลือกจำนวน 3 แถบย่อย คือ A3 A1 H2 เป็นต้น ในเกณฑ์การเลือกแบบ IC:DPSS ได้ทำการเลือกแบบนี้เช่นเดียวกัน

เกณฑ์การเลือกแบบ IC:DPSS มีขั้นตอนการทำงาน ดังนี้

1. ทำการสกัดค่าพลังงานจากทุกแถบย่อย ในแต่ละภาพที่ใช้ในการฝึกสอน T_n
2. แบ่งแถบย่อยออกเป็นสองเซต คือ เซต U และ เซต R โดยเซต U เริ่มต้น คือ แถบย่อยหนึ่งแถบที่มีสภาวะครอบคลุมข้อมูลทั้งหมดได้มากที่สุด หรือ แถบย่อย U ที่มีค่าสภาวะที่เกิดร่วมกันต่อเซต R มากที่สุดดังสมการที่ (3.4)

$$(k) = \arg \max_j \{I(W S_j; R)\} \quad (3.4)$$

และให้ $R = WS \setminus U$

3. ทำการเลือกแถบย่อย $W S_j$ จากเซต R ไปรวมกับเซต U ต่อไปจนทำการเลือกครบ 11 แถบย่อย

3.3.2.2 แถบย่อยที่เลือกถัดไปไม่ขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้า (Information Coverage: Not Depend on Previously Selected Subbands หรือ IC:NDPSS)

เนื่องจากเกณฑ์การเลือกแบบ IC:DPSS นั้น ในการเลือกแถบย่อยลำดับถัดไปเกิดจากการรวมเอาแถบย่อยที่เลือกได้ก่อนหน้ามาต่อไปเรื่อย ๆ ดังที่ได้กล่าวในเกณฑ์การเลือกแบบ IC:DPSS แต่ทว่าการเลือกแบบดังกล่าวแถบย่อยที่เลือกได้อาจครอบคลุมข้อมูลได้ไม่ดีพอ เนื่องจากในการพิจารณาแต่ละครั้งต้องขึ้นอยู่กับแถบย่อยที่เลือกได้ก่อนหน้าเสมอ ในเกณฑ์การเลือกแบบ IC:NDPSS ได้นำเสนอการเลือกแถบย่อยโดยไม่ขึ้นอยู่กับแถบย่อยที่เลือกได้ก่อนหน้า

ซึ่งเปรียบเสมือนกับการหยิบลูกบอลสีจากถุง โดยเมื่อทำการหยิบแล้วใส่ลูกบอลคืน ก่อนการหยิบครั้งใหม่นั้นเอง โดยยกตัวอย่างของการเลือกแถบย่อยที่ใช้เกณฑ์การเลือกแบบ IC:NDPSS ได้ดังนี้ ในการเลือกครั้งที่ 1 แถบย่อยเริ่มต้น คือ A3 ในการเลือกครั้งที่ 2 เลือกได้ A1 A2 เมื่อทำการเลือกแถบย่อยครั้งที่ 3 อาจเลือกได้เป็น H2 A3 A1 เป็นต้น จะสังเกตได้ว่าในแต่ละครั้งแถบย่อยที่เลือกได้ไม่จำเป็นต้องขึ้นอยู่กัแถบก่อนหน้านั้นเอง

โดยเกณฑ์การเลือกแบบ IC:DPSS มีขั้นตอนการทำงาน ดังนี้

1. ทำการสกัดค่าพลังงานจากทุกแถบย่อย ในแต่ละภาพที่ใช้ในการฝึกสอน T_n
2. แบ่งแถบย่อยออกเป็นสองเซต คือเซต U และ เซต R โดยเซต U เริ่มต้น คือ แถบย่อยหนึ่งแถบที่มีสภาวะครอบคลุมข้อมูลทั้งหมดได้มากที่สุด หรือ แถบย่อย U ที่มีค่าสภาวะที่เกิดขึ้นร่วมกันต่อเซต R มากที่สุดดังสมการที่ (3.5)

$$(k) = \arg \max_j \{I(WS_j; R)\} \quad (3.5)$$

และ ให้ $R = R$ เช่นเดิม

3. ทำการเลือกแถบย่อย WS_j จากเซต R ไปรวมกับเซต U ต่อไปจนทำการเลือกครบ 11 แถบย่อย

บทที่ 4

การทดลอง

ในบทนี้ได้แสดงผลการทดลองของการรู้จำใบหน้า จากวิธีที่นำเสนอในบทที่ 3 คือ ผลการทดลองจากวิธีระบบหลายตัวจำแนกสองระดับ และผลการทดลองจากการใช้แถบย่อยที่เลือกแล้วมาทำการรวมแบบต่าง ๆ สำหรับฐานข้อมูลที่ใช้ คือ ฐานข้อมูลใบหน้า Yale, AR, และ ORL เพื่อให้ผลการทดลองมีความเชื่อถือได้มากขึ้น ในการทดลองนี้ได้เลือกใช้วิธีการตรวจสอบไขว้แบบเคโฟลด์ (K-fold cross-validation) ในการวัดผลการรู้จำใบหน้า

4.1 ฐานข้อมูลที่ใช้ทดลอง

ฐานข้อมูลที่ใช้ทดลองในวิทยานิพนธ์นี้ ประกอบด้วยฐานข้อมูลใบหน้า Yale, AR, และ ORL ซึ่งในฐานข้อมูลใบหน้า Yale และ AR มีลักษณะเฉพาะตัวของภาพที่ค่อนข้างคล้ายคลึงกัน ส่วนในฐานข้อมูลใบหน้า ORL นั้น ลักษณะของภาพจะแตกต่างจากทั้งสองฐานข้อมูลใบหน้าที่กล่าวถึงข้างต้น โดยทั้ง 3 ฐานข้อมูลใบหน้าต่างมีจำนวนภาพที่แตกต่างกัน โดยจะกล่าวถึงรายละเอียดในหัวข้อที่ 4.1.1, 4.1.2 และ 4.1.3 ตามลำดับ

4.1.1 ฐานข้อมูลใบหน้า Yale

ฐานข้อมูลใบหน้า Yale [39] ประกอบด้วย 165 ภาพ จากทั้งหมด 15 บุคคล ซึ่งคือ มี 11 ภาพต่อบุคคล โดยในชุดภาพของแต่ละบุคคลจะมีการแสดงความรู้สึกทางสีหน้า หรือ โครงสร้างภาพภายนอก ดังนี้ มีแสงส่องอยู่ตรงกลางใบหน้า, ใส่แว่นตา, มีความสุข, แสงส่องทางด้านซ้ายของใบหน้า, ไม่ได้ใส่แว่นตา, ทำสีหน้าปกติ, แสงส่องทางขวาของใบหน้า, ทำสีหน้าเศร้า, หลับตา, ตกใจ และ ขยิบตา โดยในแต่ละภาพได้ถูกตัด และปรับให้มีขนาด 100×80 จุดภาพ สำหรับภาพเริ่มต้น ดังแสดงตัวอย่างภาพใบหน้าของบุคคลที่ 1 จากฐานข้อมูล Yale ในรูปที่ 4.1 และจากนั้นก็ทำการปรับให้มีขนาด 128×128 จุดภาพเพื่อใช้ในการทดลองจริง



รูปที่ 4.1 ตัวอย่างภาพจากฐานข้อมูลใบหน้า Yale

4.1.2 ฐานข้อมูลใบหน้า AR

ฐานข้อมูลใบหน้า AR [40] มีภาพใบหน้าจาก 126 คน ประกอบด้วยใบหน้าผู้หญิง 56 ใบหน้า และใบหน้าผู้ชาย 70 ใบหน้า โดยเป็นภาพใบหน้ามีลักษณะตรง แต่จะมีการแสดงสีหน้า, ความสว่างของแสง, และ มีการปกปิด (เช่น การใส่แว่นกันแดด, การใส่ผ้าพันคอ) ที่แตกต่างกัน และไม่มีข้อกำหนดข้อจำกัด เช่น การสวมใส่ (เช่น การใส่เสื้อผ้า, การใส่แว่นตา เป็นต้น), การแต่งหน้า, ทรงผม แก่ผู้เข้าร่วมในฐานข้อมูล ในแต่ละผู้เข้าร่วมในฐานข้อมูล จะประกอบไปด้วยสองส่วน คือ จะเป็นภาพใบหน้าลักษณะเดียวกัน แต่ระยะห่างกัน 2 สปีดาร์ห์ สำหรับการทดลองในวิทยานิพนธ์นี้ได้ทำการทดลองบน 840 ภาพ จากใบหน้าของผู้ชาย 60 คน โดยไม่มีมีการปกปิดใด ๆ โดยมีการตัดให้เป็นเฉพาะภาพใบหน้า จากนั้นทำการปรับภาพให้มีขนาด 100×80 จุดภาพ แสดงในรูปที่ 4.2 และทำการปรับให้มีขนาด 128×128 จุดภาพเพื่อใช้ในการทดลองจริง



รูปที่ 4.2 ตัวอย่างภาพจากฐานข้อมูลใบหน้า AR

4.1.3 ฐานข้อมูลใบหน้า ORL

ฐานข้อมูลใบหน้า ORL [41] มีใบหน้าจาก 40 บุคคล โดยประกอบด้วยบุคคลละ 10 ภาพ ภาพแต่ละบุคคลในฐานข้อมูลนี้ มีลักษณะแสดงสีหน้าต่าง ๆ มีการเปิดตา, ปิดตา, ยิ้ม, ไม่ยิ้ม, รวมถึงมีการใส่แว่น และไม่ใส่แว่น ซึ่งเป็นกรณีของแต่ละบุคคล โดยภาพใบหน้ามีการเอียงทำมุมต่าง ๆ กันไม่เกิน 20 องศา และบางภาพมีขนาดใหญ่กว่าประมาณ 10 เปอร์เซ็นต์ ซึ่งภาพทั้งหมดในฐานข้อมูลนี้เป็นแบบสเกลสีเทา และทำเป็นบรรทัดฐานให้มีขนาด 112×92 จุดภาพ ดังแสดงในรูปที่ 4.3 จากนั้น ทำการปรับให้มีขนาด 128×128 จุดภาพเพื่อใช้ในการทดลองจริง



รูปที่ 4.3 ตัวอย่างภาพจากฐานข้อมูลใบหน้า ORL

4.2 การวัดผลการรู้จำใบหน้า

ในวิทยานิพนธ์นี้เลือกใช้การตรวจสอบไขว้แบบเคโฟลด์ ในการวัดผลการรู้จำ ซึ่งวิธีนี้เป็น การวัดความถูกต้องของการทำนายข้อมูล ที่ไม่ผ่านการฝึกสอนจากขั้นตอนวิธีการเรียนรู้ โดยวิธีนี้ มักจะใช้ในงานด้านการเรียนรู้ของเครื่อง (Machine learning) ในการตรวจสอบไขว้แบบเคโฟลด์ จะมีการฝึกสอนขั้นตอนวิธีการเรียนรู้เป็นจำนวนหลายต่อหลายครั้ง และในแต่ละครั้ง จะมีเพียง หนึ่งเซตจากเซตข้อมูลทั้งหมดที่ถูกดึงออกมาเพื่อใช้ในการทดสอบสำหรับการรู้จำใบหน้า การ ตรวจสอบไขว้แบบเคโฟลด์นั้นใช้การแบ่งที่มีลักษณะเฉพาะ คือ

1. กำหนดให้ตัวอย่างใบหน้าของแต่ละบุคคลมีจำนวนเท่ากัน
2. แบ่งข้อมูลเป็น K เซต โดยที่เซตที่ i ประกอบด้วยตัวอย่างใบหน้าที่ i ของแต่ละ บุคคล เช่น ในฐานข้อมูลมีภาพใบหน้าจาก 40 บุคคล บุคคลละ 10 ภาพ ในกรณีนี้ สามารถแบ่งข้อมูลออกเป็น 10 เซต โดยในเซตที่ 1 ประกอบด้วยใบหน้าที่ 1 ของทุก บุคคล ซึ่งคือจำนวน 40 ภาพ เป็นต้น
3. ให้เซตที่ 1 เป็นชุดทดสอบ โดยทำการฝึกสอนกับ $K - 1$ เซตที่เหลือ
4. ทำซ้ำข้อ 3 โดยเปลี่ยนชุดทดสอบเป็นเซตถัดไปจากข้อ 3 จนถึงเซตที่ K
5. หาค่าเฉลี่ยจากการทดลอง K ครั้ง

4.3 ผลการทดลองจากวิธีที่นำเสนอ

ในหัวข้อนี้เป็นการแสดงผลการทดลองจากวิธีที่นำเสนอในบทที่ 3 โดยแบ่งเป็น 3 ส่วนคือ ผลการทดลองจากวิธีระบบตัวจำแนกสองระดับดังแสดงในหัวข้อที่ 4.3.1, ผลการทดลองจาก วิธีเลือกแถบย่อยในหัวข้อที่ 4.3.2 และ ผลการทดลองเปรียบเทียบระหว่างสองวิธีหลักข้างต้น กับผลการทดลองจากวิธี PCA ที่มีการตรวจสอบไขว้แบบเคโฟลด์แสดงในหัวข้อที่ 4.3.3 โดยผล การทดลอง ซึ่งคือ ผลการรู้จำ และแถบย่อยที่ทำการเลือกได้ในแต่ละเกณฑ์การเลือก จากแต่ละ การทดสอบของการตรวจสอบไขว้ได้แสดงไว้ในภาคผนวก ข

4.3.1 ผลการทดลองจากวิธีระบบหลายตัวจำแนกสองระดับ

ผลการรู้จำจากวิธีระบบหลายตัวจำแนกสองระดับได้แสดงในตารางที่ 4.1 เมื่อพิจารณาการรวมแบบทางข้อมูลในระดับที่หนึ่ง (1st Level: Data fusion) พบว่าการรวมโดยใช้กลุ่มแถบย่อยที่ 1 ถึง กลุ่มแถบย่อยที่ 3 + PCA ให้ผลการรู้จำที่ดีกว่า ในฐานะข้อมูลใบหน้า Yale, AR และ ORL ในการรวมแบบทางผลการตัดสินใจ (1st Level: Decision fusion) การใช้ข้อมูลขาเข้า ซึ่งคือ กลุ่มแถบย่อยที่ 1 ถึง กลุ่มแถบย่อยที่ 3 รวมกับ PCA ให้ผลการรู้จำที่ดีกว่า ในทั้ง 3 ฐานข้อมูลใบหน้าที่เลือกใช้

ตารางที่ 4.1 ผลการรู้จำจากวิธีระบบหลายตัวจำแนกสองระดับ

วิธีที่ทดลอง	Yale	AR	ORL
1 st Level: Data fusion (กลุ่มที่1-3)	90.91	91.90	94.00
1 st Level: Data fusion (กลุ่มที่1-3 + PCA)	92.73	92.02	95.00
1 st Level: Decision fusion (กลุ่มที่1-3)	84.85	86.31	47.50
1 st Level: Decision fusion (กลุ่มที่1-3 + PCA)	90.30	88.81	60.00


4.3.2 ผลการทดลองจากวิธีเลือกแถบย่อย

ผลการทดลองที่แสดงในหัวข้อย่อยนี้เป็นการเปรียบเทียบผลการรู้จำระหว่างเกณฑ์การเลือกที่นำเสนอไปทั้งหมด 3 วิธี และการทำทั้งหมด (Brute force) ซึ่งคือ ผลการรู้จำที่ดีที่สุดที่เป็นไปได้ในการทดลอง โดยผลการทดลองที่ได้ เกิดจากการเลือกแถบย่อยที่มีการรวมแบบทางข้อมูล และการรวมแบบทางผลการตัดสินใจ โดยในการรวมที่ต่างวิธีกัน กราฟที่แสดงอาจมีสเกลทางแกน Y ที่ไม่เท่ากัน ในขณะที่เป็นฐานข้อมูลเดียวกัน เนื่องจากผลการรู้จำที่ได้จากแต่ละเกณฑ์การเลือกของการรวมแบบทางข้อมูล ให้ผลที่ค่อนข้างใกล้เคียงกันมาก โดยอาจแยกแยะผลจากแต่ละเกณฑ์ไม่ได้ หากใช้สเกลเดียวกันกับการรวมแบบใช้ผลการตัดสินใจ โดยแสดงในรูปที่ 4.4-4.9


เมื่อพิจารณาผลการทดลองจากการเลือกแถบย่อย โดยมีการรวมแบบทางข้อมูล โดยแสดงในรูปที่ 4.4, 4.6 และ 4.8 พบว่าในฐานข้อมูลไบเบหน้า Yale และ AR เกณฑ์การเลือกแบบ IC:NDPSS ค่อนข้างให้ผลการรู้จำที่ดีกว่าเกณฑ์การเลือกแบบ IC:DPSS และ SI เมื่อพิจารณาภาพรวมทั้งหมดจากจำนวนแถบย่อยเมื่อทำการเลือกได้เพิ่มขึ้น แต่ผลการรู้จำจากฐานข้อมูลไบเบหน้า ORL แสดงให้เห็นว่าเกณฑ์การเลือกแบบ SI ให้ผลการรู้จำที่ดีกว่าเกณฑ์การเลือกแบบ IC:DPSS และ IC:NDPSS

เมื่อพิจารณาผลจากการเลือกแถบย่อย โดยมีการรวมแบบทางผลการตัดสินใจ ซึ่งแสดงในรูปที่ 4.5, 4.7 และ 4.9 พบว่า สำหรับฐานข้อมูลไบเบหน้า Yale และ AR แล้ว เมื่อจำนวนแถบย่อยที่เลือกได้ในจำนวน 3 แถบย่อยแรก เกณฑ์การเลือกแบบ SI สามารถให้ผลการรู้จำที่ดีกว่า แต่เมื่อจำนวนแถบย่อยเพิ่มขึ้น เกณฑ์การเลือกแบบ IC:NDPSS กลับสามารถให้ผลการรู้จำที่ดีกว่า และเมื่อพิจารณาผลการทดลอง จากฐานข้อมูลไบเบหน้า ORL แสดงให้เห็นว่า เกณฑ์การเลือกแบบ IC:NDPSS ให้ผลการรู้จำที่ดีกว่า หรือเท่ากับเกณฑ์การเลือกแบบอื่น ๆ ในทุกจำนวนแถบย่อยที่เพิ่มขึ้นได้ ซึ่งหากพิจารณาตามภาพรวมของผลการรู้จำจากทั้ง 3 เกณฑ์การเลือกแล้วจะเห็นได้ว่า เกณฑ์การเลือกแบบ IC:NDPSS ให้ผลการเลือกแถบย่อยที่ดีกว่า เมื่อใช้การรวมแบบทางข้อมูล และการรวมแบบทางผลการตัดสินใจ


จุฬาลงกรณ์มหาวิทยาลัย




รูปที่ 4.4 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล Yale




รูปที่ 4.5 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจบนฐานข้อมูล Yale




รูปที่ 4.6 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล AR



รูปที่ 4.7 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจบนฐานข้อมูล AR



รูปที่ 4.8 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางข้อมูลบนฐานข้อมูล ORL



รูปที่ 4.9 ผลการรู้จำจากการเลือกแถบย่อยโดยรวมแบบทางผลการตัดสินใจบนฐานข้อมูล ORL

4.3.3 ผลการทดลองเปรียบเทียบ

ในหัวข้อย่อนี้เป็นการนำผลการรู้จำที่ดีที่สุด จากในแต่ละวิธีที่นำเสนอมาเปรียบเทียบกัน โดยมีผลการทดลองจาก PCA เป็นฐานในการเปรียบเทียบ ดังแสดงในตารางที่ 4.2 โดยวิธีที่นำเสนอนั้น สามารถปรับปรุงผลการรู้จำเมื่อเปรียบเทียบกับการใช้ PCA ในการวิเคราะห์โดยตรงได้ เมื่อพิจารณาจากทั้ง 3 ฐานข้อมูลไปหน้าแล้วพบว่า สำหรับวิธีระบบหลายตัวจำแนกสองระดับ การรวมแบบทางข้อมูลในระดับที่หนึ่ง เหมาะสมกว่าการใช้การรวมแบบทางผลการตัดสินใจระดับที่หนึ่ง และในส่วนของวิธีการเลือกแถบย่อมนั้น เกณฑ์การเลือกแบบ IC:NDPSS สามารถเลือกแถบย่อมนั้นได้มีประสิทธิภาพดีกว่าเกณฑ์การเลือกแบบ SI และ IC:DPSS เมื่อทำการพิจารณาทั้งสองวิธีหลักที่นำเสนอพบว่า วิธีการเลือกแถบย่อมนั้นข้างจำเป็นกับการพิจารณาแถบย่อมนั้นไปใช้ ซึ่งผลการทดลองแสดงให้เห็นว่า เมื่อสามารถทำการเลือกแถบย่อมนั้นที่เหมาะสมได้ ผลการรู้จำสามารถปรับปรุงให้มีประสิทธิภาพเพิ่มสูงขึ้นได้

ตารางที่ 4.2 ผลการทดลองเปรียบเทียบ

วิธีการ	Yale		AR		ORL	
	ผลการรู้จำ	วิธีที่นำเสนอ	ผลการรู้จำ	วิธีที่นำเสนอ	ผลการรู้จำ	วิธีที่นำเสนอ
ระบบหลายตัวจำแนกสองระดับ	92.73	1 st L: Data fusion (กลุ่มที่1-3+ PCA)	92.02	1 st L: Data fusion (กลุ่มที่1-3+ PCA)	95.00	1 st L: Data fusion (กลุ่มที่1-3+ PCA)
การเลือกแถบย่อมนั้น	93.33	IC:NDPSS +Decision fusion	93.69	IC:NDPSS +Decision fusion	97.75	IC:NDPSS +Decision fusion
PCA	90.91	-	90.83	-	92.75	-

บทที่ 5

บทสรุป

5.1 สรุปผลการวิจัย

วิทยานิพนธ์นี้นำเสนอการใช้แถบย่อยจากการวิเคราะห์หลายอำนาจการจำแนกมาใช้ในการรู้จำใบหน้า สามารถแบ่งเป็น 2 ส่วนหลัก คือ ส่วนของระบบหลายตัวจำแนกสองระดับ และ ส่วนของวิธีการคัดเลือกแถบย่อย ซึ่งทั้งสองส่วนนั้น ทำการทดลองบนฐานข้อมูลใบหน้า Yale, AR และ ORL และใช้การตรวจสอบไขว้แบบเคโฟลต์ในการวัดผลการรู้จำ

มีบทความกล่าวถึงการนำคุณลักษณะที่เข้าช้อนมาใช้ร่วมกันว่าสามารถปรับปรุงผลการจำแนกได้ [19-20] จากผลการทดลองได้แสดงให้เห็นว่า เมื่อนำแถบย่อยที่มีการเข้าช้อนกันมารวมแบบต่าง ๆ สามารถปรับปรุงผลการรู้จำได้

จากการทดลองโดยใช้วิธีระบบหลายตัวจำแนกสองระดับ พบว่าเมื่อใช้การรวมแบบทางข้อมูลในระดับที่หนึ่ง สามารถให้ผลการรู้จำที่ดีกว่าเมื่อใช้การรวมแบบทางผลการตัดสินใจในระดับที่หนึ่ง

- เนื่องจาก แถบย่อยที่ใช้เป็นข้อมูลขาเข้าที่กำหนดไว้ตายตัว ไม่เหมาะสมกับการรวมแบบทางผลการตัดสินใจ แต่เหมาะสมกับการรวมแบบทางข้อมูลมากกว่า
- เนื่องจาก ขนาดของแถบย่อย ซึ่งเป็นข้อมูลขาเข้าของการรวมแบบต่าง ๆ มีอิทธิพลผลการรู้จำ โดยการรวมแบบทางผลการตัดสินใจนั้น แม้ขนาดของแถบย่อยที่ใช้มีขนาดต่างกัน แต่ทำให้ความสำคัญเท่ากัน สำหรับการรวมแบบทางข้อมูล เมื่อแถบย่อยที่ใช้มีขนาดต่างกัน แถบย่อยที่มีขนาดใหญ่กว่าจะมีผลต่อกรรู้จำมากกว่าแถบย่อยที่มีขนาดเล็กกว่า

เมื่อพิจารณาข้อมูลขาเข้า ซึ่งคือ แถบย่อยกลุ่มที่ 1-3 กับแถบย่อยกลุ่มที่ 1-3 + PCA พบว่าเมื่อนำผลจาก PCA รวมเข้าไปด้วยแล้ว การรวมแบบทางผลการตัดสินใจในระดับที่สอง สามารถให้ผลการรู้จำที่ดีกว่า

- เนื่องจาก ผลการรู้จำโดยใช้ PCA ค่อนข้างให้ผลการรู้จำที่ดี ดังนั้น เมื่อนำมาเป็นอีกคะแนนเสียงหนึ่งประกอบการตัดสินใจ ก็สามารถช่วยให้ตัดสินใจอย่างถูกต้องมากขึ้นได้

เมื่อนำผลการรู้จำมาเปรียบเทียบกับกรทำโดยใช้ PCA เพียงอย่างเดียว วิธีระบบหลายตัวจำแนกสองระดับ สามารถใช้ได้ดีกับฐานข้อมูลใบหน้าที่มีการเปลี่ยนแปลงทางแสง, การแสดงสีหน้า และเมื่อมีการหมุนใบหน้าได้ ดังแสดงในตารางที่ 4.2

จากการทดลองโดยใช้วิธีคัดเลือกแถบย่อยมาทำการเลือกแถบย่อยก่อนทำการรวมแบบต่าง ๆ พบว่า เมื่อพิจารณาการใช้การรวมแบบทางข้อมูลทั้ง 3 เกณฑ์การเลือกที่น่าเสนอ ผลการรู้จำได้ไม่ต่างกันมากนัก โดยเกณฑ์การเลือกแบบ IC:NDPSS ใช้ได้ดีกับฐานข้อมูลใบหน้า Yale และ AR แต่สำหรับฐานข้อมูลใบหน้า ORL นั้น เกณฑ์การเลือกแบบ SI ให้ผลการรู้จำที่ดีกว่า ซึ่งสังเกตได้ว่า ผลการทดลองจากวิธีการคัดเลือกแถบย่อยโดยใช้การรวมแบบทางข้อมูลนั้น เกณฑ์การเลือกแบบ SI และ IC สามารถใช้ได้อย่างมีประสิทธิภาพทั้งคู่ แต่ว่าเกณฑ์การเลือกแบบ IC:NDPSS จะเหมาะสมกับฐานข้อมูลที่มีการเปลี่ยนแปลงทางแสง ส่วนเกณฑ์การเลือกแบบ SI เหมาะกับฐานข้อมูลที่มีการหมุนของภาพ แถบย่อยที่เลือกได้จากเกณฑ์การเลือกแบบ IC:DPSS และ IC:NDPSS ให้ผลการรู้จำไม่ต่างกันมากนัก ซึ่งแสดงให้เห็นว่าความซ้ำซ้อนกันทางข้อมูลที่ได้จากแถบย่อยมีผลต่อการรวมแบบนี้้น้อยมาก

ผลการทดลองจากวิธีการคัดเลือกแถบย่อยโดยใช้การรวมแบบใช้ผลการตัดสินใจได้แสดงให้เห็นอย่างชัดเจนว่า เมื่อจำนวนแถบย่อยที่ทำการคัดเลือกเพิ่มขึ้น เกณฑ์การคัดเลือกแบบ IC:DPSS และ IC:NDPSS ให้แถบย่อยในการคัดเลือกได้ต่างกัน เกณฑ์การเลือกแบบ IC:NDPSS สามารถเลือกแถบย่อยที่มีความซ้ำซ้อนกันน้อยที่สุดได้ ในขณะที่เกณฑ์การเลือกแบบ SI สามารถเลือกแถบย่อยได้ดีกว่าเมื่อเทียบกับเกณฑ์การเลือกแบบ IC เมื่อเลือกไม่เกิน 3 แถบย่อย ผลการทดลองแสดงให้เห็นว่าเกณฑ์การเลือกแบบ IC:NDPSS เป็นวิธีที่เหมาะสมในการเลือกแถบย่อยสำหรับการรวมแบบใช้ผลการตัดสินใจ

การเลือกแถบย่อยแบบขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้านี้ ซึ่งในวิทยานิพนธ์นี้ คือแบบ SI และ IC:DPSS เป็นการเลือกแบบไปข้างหน้าโดยลำดับ หรือ SFS มีการคำนวณที่รวดเร็วกว่าแบบไม่ขึ้นอยู่กับแถบย่อยที่เลือกได้ก่อนหน้านี้ ซึ่งคือ แบบ IC:NDPSS ในวิทยานิพนธ์นี้ เนื่องจากแถบย่อยถูกเลือกแล้วไม่มีการนำมาคำนวณซ้ำ แต่การเลือกแบบไม่ขึ้นอยู่กับแถบย่อยที่เลือกได้ก่อนหน้านี้ มีการนำแถบย่อยที่ถูกเลือกแล้ว มาคำนวณซ้ำทุกครั้งที่จำนวนแถบย่อยที่ต้องการเลือกเพิ่มขึ้น ซึ่งทำให้มีการคำนวณเพิ่มขึ้น หากผลการรู้จำจาก IC:DPSS และ IC :NDPSS ให้ผลการรู้จำได้ไม่ต่างกันมาก เกณฑ์การเลือกแบบ IC:DPSS เป็นวิธีที่น่าสนใจกว่า แต่หากสนใจแต่ผลการรู้จำแล้วเกณฑ์การเลือกแบบ IC:NDPSS ก็เป็นทางเลือกที่ดีกว่าให้เลือกใช้

เมื่อพิจารณาถึงจำนวนแถบย่อยที่ควรเลือก จะสังเกตได้ว่า การเลือกเพียงไม่เกิน 5 แถบย่อยจะให้ผลการรู้จำที่เพิ่มขึ้น แต่เมื่อใช้จำนวนของแถบย่อยมากกว่านั้นจะให้ผลการรู้จำคงที่ หรือลดลง ซึ่งแสดงให้เห็นว่าเมื่อใช้จำนวนแถบย่อยมากเกินไป ส่งผลให้มีความซ้ำซ้อนของข้อมูลมากเกินไป ซึ่งไม่สามารถช่วยปรับปรุงผลการรู้จำได้

จากผลการทดลองสังเกตได้ว่า เมื่อฐานข้อมูลใบหน้าเปลี่ยนไป วิธีที่ให้ผลดีในการเลือกใช้ก็ต่างกัน ซึ่งจะสังเกตได้จากผลการทดลองจากฐานข้อมูล Yale และ AR ให้ผลการทดลองที่

ค่อนข้างไปในแนวทางเดียวกัน เนื่องจากฐานข้อมูลที่ใช้มีลักษณะคล้ายกัน สำหรับฐานข้อมูล ORL ให้ผลการทดลองค่อนข้างแตกต่างจากทั้งสองฐานข้อมูลข้างต้น เมื่อทำการวิเคราะห์เฉพาะแต่ละฐานข้อมูลจากผลการทดลองแบบลิฟต์วันเอาร์ทพบว่า เมื่อภาพใบหน้าที่ใช้ทดลอง เช่น ในฐานข้อมูลใบหน้า Yale และ AR มีลักษณะต่างออกไปจากกลุ่มภาพใบหน้าที่ใช้ฝึกสอนมาก เช่น มีการยิ้มที่กว้างมากกว่าภาพอื่น ๆ มาก หรือ มีแสงที่ผิดไปจากภาพอื่น ๆ มาก ส่งผลให้ผลการรู้จำตกลงอย่างชัดเจน แต่ในขณะที่ภาพในฐานข้อมูลใบหน้า ORL มีจำนวนของภาพที่ลักษณะต่าง ๆ กันคละกันไปในจำนวนที่ใกล้เคียงกัน ทำให้การทดสอบไม่ว่าภาพใดก็มักจะให้ผลการรู้จำที่สูงมากเสมอ

5.2 ข้อดี

1. การทำวิธีระบบหลายตัวจำแนกสองระดับสามารถใช้กลุ่มแถบย่อยที่กำหนดตายตัวได้ ซึ่งสามารถปรับปรุงผลการรู้จำได้เมื่อเปรียบเทียบกับการใช้เพียง PCA ในการรู้จำใบหน้า
2. การใช้วิธีคัดเลือกแถบย่อยเลือกแถบย่อยที่เหมาะสม สามารถช่วยลดภาวะการคำนวณจากการใช้ทุกแถบย่อยในการคำนวณได้
3. วิธีคัดเลือกแถบย่อยสามารถหาเซตของแถบย่อยที่เหมาะสมกับแต่ละฐานข้อมูลได้
4. การใช้เกณฑ์การเลือกแบบ IC:NDPSS สามารถเลือกเซตของแถบย่อยที่มีการซ้ำซ้อนของสาระต่ำกว่า เกณฑ์การเลือกแบบ IC:DPSS
5. การรวมแบบทางข้อมูล ถ้าใช้แถบย่อยที่มีสาระมากเพียงหนึ่งแถบ รวมกับแถบย่อยหลายแถบที่มีสารถน้อย แถบย่อยที่มีสารถน้อยสามารถช่วยให้เพิ่มข้อมูลให้กับแถบย่อยที่มีสารถมากได้
6. ในการรวมแบบทางผลการตัดสินใจ ถ้าสามารถเลือกเซตของแถบย่อยที่เหมาะสมได้ วิธีนี้จะให้ผลการรู้จำสูงที่สุด

5.3 ข้อด้อย

1. การทำวิธีระบบหลายตัวจำแนกสองระดับใช้การคำนวณที่ยุ่งยากกว่า เมื่อเปรียบเทียบกับการใช้เพียง PCA และให้ผลปรับปรุงขึ้นเพียงเล็กน้อย
2. เกณฑ์การเลือกแบบขึ้นอยู่กับแถบย่อยที่เลือกก่อนหน้า ทำให้ได้ข้อมูลที่มีความซ้ำซ้อนกันมาก เนื่องจากแถบย่อยใหม่ที่เลือกได้ถูกบังคับจากเซตของแถบย่อยที่เลือกได้ก่อนหน้า

3. เกณฑ์การเลือกแบบ IC:NDPSS มีภาระการคำนวณสูงกว่าเกณฑ์การเลือกแบบ SI และ IC:DPSS
4. การรวมแบบทางผลทางการตัดสินใจให้ผลการรู้จำต่ำ ถ้าจำนวนแถบย่อยที่ใช้มีความสามารถในการรู้จำต่ำมากกว่า จำนวนแถบย่อยที่มีความสามารถในการรู้จำสูง
5. การรวมแบบทางข้อมูลใช้เวลามากกว่าการรวมแบบทางผลทางการตัดสินใจเมื่อจำนวนแถบย่อยมากขึ้น เนื่องจาก การคำนวณขนาดของข้อมูลใหญ่หนึ่งครั้งสามารถคำนวณได้ซ้ำกว่าใช้ข้อมูลขนาดเล็กหลาย ๆ ครั้ง

5.4 ข้อเสนอแนะ

1. เมื่อจำนวนแถบย่อยที่คัดเลือกมีจำนวนเพิ่มขึ้น ผลการทดลองจากการรวมแบบทางผลการตัดสินใจให้กราฟในลักษณะกว้าง ซึ่งในกรณีแสดงให้เห็นว่าแถบย่อยที่มีความสามารถในการแยกแยะต่ำ และแถบย่อยที่มีความสามารถในการแยกแยะสูงมีอำนาจในการออกเสียงเท่ากัน ดังนั้นควรมีการใช้ค่าตัวถ่วงน้ำหนักเพื่อให้แถบย่อยที่มีความสามารถในการแยกแยะต่ำมีอำนาจในการออกเสียงน้อยกว่า แถบย่อยที่มีความสามารถในการแยกแยะสูง
2. การออกแบบวิธี IC:NDPSS เกิดจากการสนใจว่า เมื่อไม่สนใจการเลือกแถบย่อยที่เลือกได้ก่อนหน้า ซึ่งคือ ทำการเลือกใหม่ทุกครั้งเมื่อต้องการเลือกจำนวนแถบย่อยเพิ่มขึ้น ซึ่งแสดงให้เห็นว่าเป็นวิธีที่มีประสิทธิภาพในการเลือก เนื่องจากวิธี SI ที่ได้นำเสนอไปเป็นการเลือกแบบขึ้นอยู่กับแถบย่อยก่อนหน้า หรือ SI:DPSS หากมีการนำแนวคิดที่ไม่สนใจการเลือกแถบย่อยที่เลือกก่อนหน้ามาประยุกต์เพื่อสร้างการคัดเลือกอีกวิธีหนึ่ง ซึ่งคือ SI:NDPSS ก็เป็นวิธีหนึ่งที่น่าสนใจเช่นกัน

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

รายการอ้างอิง

- [1] W. Zhao, R. Chellappa, A. Rosenfeld, and J. Phillips. Face recognition: A literature survey. ACM computing surveys. 12 (2003): 399-458.
- [2] M. A. Turk and A. P. Pentland. Face recognition using eigenfaces. Proc. IEEE Conf. Computer Vision and Pattern Recognition. 1991: 586-591.
- [3] G. C. Feng, P. C. Yuen, and D. Q. Dai. Human Face Recognition Using PCA on Wavelet Subband. SPIE Journal of Electronic Imaging. 9 (2000): 226-233.
- [4] J. T. Chien and C. C. Wu. Discriminant waveletfaces and nearest feature classifiers for face recognition. IEEE Trans. Pattern Analysis and Machine Intelligence. 24 (December 2002): 1644-1649.
- [5] V. T. Brennen. Principal component analysis with multiresolution. Ph.D. dissertation. Electrical and computer engineering. University of Florida, May 2001.
- [6] H. K. Ekenel and B. Sankur. Multiresolution face recognition. Image and Vision Computing. 3 (2005): 469-477.
- [7] F. Goudail, E. Lange, T. Iwamoto, K. Kyuma, and N. Otsu. Face recognition system using local autocorrelations and multiscale integration. IEEE Trans. Pattern Analysis and Machine Intelligence. 18 (October 1996): 1024-1028.
- [8] T. K. Ho, J. J. Hull, and S. N. Srihari. Decision combination in multiple classifier systems. IEEE Trans. Pattern Analysis and Machine Intelligence. 16 (January 1994): 66-75.
- [9] A. K. Jain, X. Lu, and Y. Wang, Combining classifiers for face recognition. In Proc. ICME. July 2003: 13-16.
- [10] T. H.-Man. Face recognition committee machine: Methodology, experiments and a system application. M. thesis. Computer science and engineering. Chinese university of Hong Kong, July 2003.
- [11] J. A. Benediktsson and O. K. Ersoy. Parallel consensual neural networks. IEEE Trans. Neural Networks. 8 (1997): 54-64.
- [12] J. C. Filho. Feature selection from huge feature sets in the context of computer vision. Ph.D. dissertation. Department of computer sciences. Colorado State University, 2000.

- [13] T. Rande and J. Husoy. Filtering for texture classification: a comparative study. IEEE Trans. Pattern Analysis and Machine Intelligence. 21 (1999): 291-310.
- [14] K. Huang and S. Aviyente. Information-theoretic wavelet packet subband selection for texture classification. Signal Processing 86. 2006: 1410-1420.
- [15] J. Liu, P. Moulin. Information-theoretic analysis of interscale and intrascale dependencies between image wavelet coefficient. IEEE Trans. Image Processing. 10 (2001): 1647-1658.
- [16] H. Schneiderman. Learning statistical structure for object detection. Computer Analysis of Images and Patterns. 10th International Conference (CAIP). 2003: 434-441.
- [17] S. Ullman, M. Vidal-Naquet and E. Sali. Visual features of intermediate complexity and their use in classification. Nature Neuroscience. 5 (2002): 682-687.
- [18] I. Atalay. Face recognition using eigenface. M. Sc. Thesis. Istanbul Technical University, 1996.
- [19] R. Kohavi and G. H. John. Wrappers for feature subset selection. Artificial Intelligence. 1-2 (December. 1997): 273-324.
- [20] I. Guyon and A. Elisseeff. An introduction to variable and feature selection. The Journal of Machine Learning Research. 3 (2003): 1157-1182.
- [21] R. Bekkerman, R. El-Yaniv, N. Tishby, and Y. Winter. Word clusters vs. words for text categorization. The Journal of Machine Learning Research. 3 (March 2003): 1183-1208.
- [22] I. Dhillon, S. Mallela, and R. Kumar. A divisive information theoretic feature clustering algorithm for text classification. The Journal of Machine Learning Research. 3 (March 2003): 1265-1287.
- [23] G. Forman. An extensive empirical study of feature selection metrics for text classification. The Journal of Machine Learning Research. 3 (March 2003): 1289-1305.
- [24] K. Torkkola. Feature extraction by non-parametric mutual information maximization. The Journal of Machine Learning Research. 3 (March 2003): 1415-1438.

- [25] A. Laine, J. Fan. Texture classification by wavelet packet signatures. IEEE Transactions on Pattern Analysis and Machine Intelligence. 15 (November 1993): 1186-1191.
- [26] R. O. Duda, P. E. Hart, and D. G. Stork. Pattern Classification (2nd Edition). Wiley-Interscience. 2000.
- [27] R. R. Coifman and M. V. Wickerhauser. Entropy-based algorithms for best basis selection. IEEE Trans. Information Theory. 38 (2) (1992): 713-718.
- [28] T. Chang and C. Kuo. Texture analysis and classification with tree-structured wavelet transform. IEEE Trans. Image Processing. 2 (4) (1993): 429-441.
- [29] N. M. Nasir. Texture classification using discriminant wavelet packet subbands. In: 45th IEEE Midwest Symposium on Circuits and Systems, 2002.
- [30] J. Liu and P. Moulin. Information-theoretic analysis of interscale and intrascale dependencies between image wavelet coefficients. IEEE Trans. Image Processing. 10 (11) (2001): 1647-1658.
- [31] T. Randen and J. Husoy. Filtering for Texture Classification: A Comparative Study. IEEE Trans Pattern Analysis and Machine Intelligence. 21 (4) (April 1999): 291-310.
- [32] L. Ma, T. Tan, Y. Wang, and D. Zhang. Personal identification based on iris texture analysis: IEEE Trans Pattern Analysis and Machine Intelligence. 25 (12) (December 2003): 1519-1533.
- [33] C. Garcia, G. Zikos, and G. Tziritas. Wavelet packet analysis for face recognition. Image Vision Computing. 18 (4) (2000): 289-297.
- [34] T. M. Cover and J. A. Thomas. Elements of information theory. Wiley-Interscience. New York. NY., 1991.
- [35] M. Zaffalon and M. Hutter. Robust feature selection by mutual information distributions. In: Proceedings of the 18th International Conference on Uncertainty in Artificial Intelligence (UAI-2002). 2002: 577-584.
- [36] E. P. Simoncelli. Modeling the joint statistics of images in the wavelet domain. In: Proceedings of the SPIE, 44th Annual Meeting. 3813 (1999): 188-195.
- [37] R. Moddemeijer. On estimation of entropy and mutual information of continuous distributions. Signal Processing. 16 (3) (1989): 233-246.

- [38] L. Paninski. Estimation of entropy and mutual information. Neural Computation. 15 (6) (June 2003): 1191-1253.
- [39] Yale University, The Yale face database., 1997. Available from <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>.
- [40] Martinez, A. and Benavente, R., The AR face database., 1998. Available from http://rv11.ecn.purdue.edu/~aleix/aleix_face_DB.html.
- [41] The AT&T (Olivetti) Research Laboratory, The (Olivetti) Research laboratory face database (ORL), 1992. Available from <http://www.cl.cam.ac.uk/Research/DTG/attarchive/facedatabase.html>.



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



ภาคผนวก

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ก

การประมาณค่าสาระร่วมกันที่ใช้ในวิทยานิพนธ์

จากนิยามของสาระที่เกิดร่วมกันที่กล่าวถึงในหัวข้อที่ 2.4.2 และการลดอันดับของแบบจำลองในหัวข้อที่ 2.4.3 เป็นการใช้ฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบต่อเนื่อง แต่ในการประยุกต์ใช้จริงนั้นเป็นการวัดค่าสาระที่เกิดร่วมกันระหว่างเวกเตอร์แบบไม่ต่อเนื่อง X และเวกเตอร์แบบไม่ต่อเนื่อง T ดังนั้น จึงจำเป็นต้องมีการประมาณค่าขึ้น ซึ่งปัญหาการประมาณค่าดังกล่าวมีการศึกษามาแล้วในงานวิจัย [38-39] สำหรับในวิทยานิพนธ์นี้มีขั้นตอนการประมาณค่าสาระที่เกิดร่วมกัน ดังต่อไปนี้

กำหนด

T คือ เวกเตอร์แบบไม่ต่อเนื่องของผลรวมแบบเชิงเส้นของพลังงานจากแถบย่อยที่คัดเลือกแล้ว โดยมีการรวมดังสมการที่ (2.21)

X คือ เวกเตอร์แบบไม่ต่อเนื่องของพลังงานจากแถบย่อยที่ยังไม่ถูกคัดเลือก

N_T คือ ช่วงที่แบ่งของเวกเตอร์ T

N_X คือ ช่วงที่แบ่งของเวกเตอร์ X

T_r คือ จำนวนตัวอย่างที่ใช้ทดสอบ

1. ทำการแบ่งเวกเตอร์ T ออกเป็น N_T ช่วง และแบ่งเวกเตอร์ X ออกเป็น N_X ช่วง โดยที่


$$N_T = N_X = \frac{T_r}{2} \quad (\text{ก.1})$$

2. ทำการนอมัลไลซ์เวกเตอร์ T และเวกเตอร์ X จากนั้นจัดให้สมาชิกในเวกเตอร์ T และเวกเตอร์ X ที่ทำการนอมัลไลซ์แล้วอยู่ในช่วงต่าง ๆ ใน N_T และ N_X ตามลำดับ ดังนี้

$$T = \frac{T}{T_{\max}} \times N_T \quad (\text{ก.2})$$

$$X = \frac{X}{X_{\max}} \times N_X \quad (\text{ก.3})$$

3. นำเวกเตอร์ T และเวกเตอร์ X ที่ทำการนอร์มัลไลซ์ และแบ่งช่วงแล้ว จากในข้อ 2 มาจัดเป็นคู่ลำดับ (X, T) เช่นตัวอย่าง สมมติให้เวกเตอร์ $X = \{0.7, 1.5, 0.7, 2.5, 1.5\}$ และเวกเตอร์ $T = \{0.7, 0.7, 1.5, 2.5, 0.5\}$ จะได้คู่ลำดับ $(X, T) = \{(0.7, 0.7), (1.5, 0.7), (0.7, 1.5), (2.5, 2.5), (1.5, 0.5)\}$
4. นำคู่ลำดับที่ได้จากข้อที่ 3 มาพล็อตเป็นกราฟ โดยที่แกน x คือ ค่าในเวกเตอร์ X และแกน y คือ ค่าในเวกเตอร์ T ดังตัวอย่างในรูปที่ ก.1



รูปที่ ก.1 ตัวอย่างกราฟจากคู่ลำดับ (X, T)

5. คำนวณหาค่าความน่าจะเป็น P_x และค่าความน่าจะเป็น P_T จากการแจกแจงตามขอบตามแนวแกน X และแกน T ตามลำดับ จากกราฟที่ได้ในข้อที่ 4
6. คำนวณหาค่าความน่าจะเป็นร่วม $P_{X,T}$ จากการใช้อิสโทแกรมสองมิติจากกราฟคู่ลำดับที่สร้างได้ในข้อที่ 4
7. นำค่าที่ได้จากข้อที่ 5 และข้อที่ 6 มาแทนในสมการที่ (2.22) เพื่อหาค่าสภาวะที่เกิดร่วมกันระหว่างค่าพลังงานจากแถบย่อยที่คัดเลือกแล้ว และค่าพลังงานจากแถบย่อยที่ยังไม่ถูกคัดเลือก

ภาคผนวก ข

ผลการทดลองจากการใช้แต่ละใบหน้าในการทดสอบ

ตารางที่ ข.1 ผลการรู้จำจากวิธีระบบหลายตัวจำแนกสองระดับบนฐานข้อมูลใบหน้า Yale

ใบหน้าที่ทดสอบ	L1: Data fusion (กลุ่มที่1-3)	L1: Data fusion (กลุ่มที่1-3 + PCA)	L1: Decision fusion (กลุ่มที่1-3)	L1: Decision fusion (กลุ่มที่1-3 + PCA)
1	73.33	80.00	86.67	86.67
2	100.00	100.00	86.67	100.00
3	93.33	100.00	86.67	93.33
4	66.67	60.00	60.00	60.00
5	100.00	100.00	100.00	100.00
6	100.00	100.00	100.00	100.00
7	66.67	80.00	66.67	73.33
8	100.00	100.00	93.33	93.33
9	100.00	100.00	80.00	100.00
10	100.00	100.00	86.67	86.67
11	100.00	100.00	86.67	100.00
ผลเฉลี่ย	90.91	92.73	84.85	90.30

ตารางที่ ข.2 ผลการรู้จำจากวิธีระบบหลายตัวจำแนกสองระดับบนฐานข้อมูลใบหน้า AR

ใบหน้าที่ทดสอบ	L1: Data fusion (กลุ่มที่1-3)	L1: Data fusion (กลุ่มที่1-3 + PCA)	L1: Decision fusion (กลุ่มที่1-3)	L1: Decision fusion (กลุ่มที่1-3 + PCA)
1	91.67	93.33	86.67	91.67
2	93.33	95.00	85.00	88.33
3	93.33	90.00	81.67	85.00
4	68.33	71.67	56.67	61.67
5	95.00	95.00	93.33	95.00
6	98.33	100.00	100.00	100.00
7	96.67	95.00	91.67	98.33
8	96.67	96.67	90.00	91.67
9	95.00	96.67	86.67	91.67
10	95.00	93.33	86.67	90.00
11	78.33	76.67	63.33	66.67
12	93.33	90.00	93.33	91.67
13	100.00	100.00	96.67	96.67
14	91.67	95.00	96.67	95.00
ผลเฉลี่ย	91.90	92.02	86.31	88.81

ตารางที่ ข.3 ผลการรู้จำจากวิธีระบบหลายตัวจำแนกสองระดับบนฐานข้อมูลใบหน้า ORL

ใบหน้าที่ทดสอบ	L1: Data fusion (กลุ่มที่1-3)	L1: Data fusion (กลุ่มที่1-3 + PCA)	L1: Decision fusion (กลุ่มที่1-3)	L1: Decision fusion (กลุ่มที่1-3 + PCA)
1	97.50	97.50	45.00	57.50
2	100.00	100.00	50.00	60.00
3	100.00	100.00	50.00	65.00
4	92.50	95.00	62.50	80.00
5	97.50	97.50	42.50	67.50
6	92.50	95.00	50.00	60.00
7	92.50	92.50	62.50	72.50
8	90.00	90.00	42.50	52.50
9	87.50	90.00	30.00	40.00
10	90.00	92.50	40.00	45.00
ผลเฉลี่ย	94.00	95.00	47.50	60.00

ตารางที่ ข.4 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 1

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	86.67	86.67	A3	86.67	86.67	A3	86.67	86.67
2	A3 A1	86.67	73.33	A3 V3	80.00	53.33	A3 V3	80.00	53.33
3	A3 A1 H1	86.67	66.67	A3 V3 D2	80.00	46.67	A3 H3 V3	80.00	80.00
4	A3 A1 H1 H3	73.33	80.00	A3 V3 D2 V2	80.00	66.67	A1 A3 H3 V3	80.00	86.67
5	A3 A1 H1 H3 D2	73.33	60.00	A3 V3 D2 V2 H2	80.00	60.00	A1 A2 A3 H3 V3	80.00	80.00
6	A3 A1 H1 H3 D2 V2	73.33	53.33	A3 V3 D2 V2 H2 A2	80.00	80.00	A1 A2 A3 H3 V3 D3	73.33	80.00
7	A3 A1 H1 H3 D2 V2 H2	66.67	60.00	A3 V3 D2 V2 H2 A2 D1	80.00	80.00	A1 H1 A2 A3 H3 V3 D3	73.33	80.00
8	A3 A1 H1 H3 D2 V2 H2 A2	66.67	73.33	A3 V3 D2 V2 H2 A2 D1 V1	80.00	73.33	A1 H1 V1 A2 A3 H3 V3 D3	73.33	73.33
9	A3 A1 H1 H3 D2 V2 H2 A2 D1	66.67	80.00	A3 V3 D2 V2 H2 A2 D1 V1 H1	80.00	73.33	A1 H1 V1 D1 A2 A3 H3 V3 D3	73.33	80.00
10	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1	66.67	73.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	73.33	73.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	73.33	80.00
11	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1 V3	73.33	80.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	73.33	80.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	73.33	80.00

ตารางที่ ข.5 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 2

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	93.33	80.00	A3 V3	93.33	80.00
3	A3 A1 H3	93.33	100.00	A3 V3 D2	93.33	80.00	A3 H3 V3	93.33	100.00
4	A3 A1 H3 D2	93.33	100.00	A3 V3 D2 V2	93.33	80.00	A1 A3 H3 V3	93.33	100.00
5	A3 A1 H3 D2 H1	93.33	100.00	A3 V3 D2 V2 H2	93.33	80.00	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H3 D2 H1 V2	93.33	100.00	A3 V3 D2 V2 H2 A2	93.33	86.67	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H3 D2 H1 V2 H2	93.33	93.33	A3 V3 D2 V2 H2 A2 D1	93.33	86.67	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H3 D2 H1 V2 H2 A2	93.33	100.00	A3 V3 D2 V2 H2 A2 D1 V1	93.33	86.67	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H3 D2 H1 V2 H2 A2 D1	93.33	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1	93.33	86.67	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H3 D2 H1 V2 H2 A2 D1 V1	93.33	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	93.33	93.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H3 D2 H1 V2 H2 A2 D1 V1 V3	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	100.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00

ตารางที่ ข.6 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 3

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	93.33	93.33	A3	93.33	93.33	A3	93.33	93.33
2	A3 A1	93.33	100.00	A3 V3	93.33	93.33	A3 V3	93.33	93.33
3	A3 A1 H1	93.33	93.33	A3 V3 D2	93.33	93.33	A3 H3 V3	93.33	93.33
4	A3 A1 H1 D2	93.33	66.67	A3 V3 D2 V2	93.33	93.33	A1 A3 H3 V3	93.33	93.33
5	A3 A1 H1 D2 V2	93.33	93.33	A3 V3 D2 V2 H2	93.33	93.33	A1 A2 A3 H3 V3	93.33	93.33
6	A3 A1 H1 D2 V2 H2	93.33	86.67	A3 V3 D2 V2 H2 A2	93.33	93.33	A1 A2 A3 H3 V3 D3	93.33	93.33
7	A3 A1 H1 D2 V2 H2 A2	93.33	93.33	A3 V3 D2 V2 H2 A2 D1	93.33	93.33	A1 H1 A2 A3 H3 V3 D3	93.33	93.33
8	A3 A1 H1 D2 V2 H2 A2 D1	93.33	93.33	A3 V3 D2 V2 H2 A2 D1 V1	93.33	93.33	A1 H1 V1 A2 A3 H3 V3 D3	93.33	93.33
9	A3 A1 H1 D2 V2 H2 A2 D1 V1	93.33	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1	93.33	93.33	A1 H1 V1 D1 A2 A3 H3 V3 D3	93.33	93.33
10	A3 A1 H1 D2 V2 H2 A2 D1 V1 H3	93.33	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	93.33	93.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	93.33	93.33
11	A3 A1 H1 D2 V2 H2 A2 D1 V1 H3 V3	93.33	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	93.33	93.33	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	93.33	93.33

ตารางที่ ข.7 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 4

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	60.00	60.00	A3	60.00	60.00	A3	60.00	60.00
2	A3 A1	60.00	60.00	A3 H3	53.33	60.00	A3 H3	53.33	60.00
3	A3 A1 H1	60.00	53.33	A3 H3 D1	53.33	40.00	A2 A3 H3	53.33	60.00
4	A3 A1 H1 H2	53.33	53.33	A3 H3 D1 V1	53.33	46.67	A1 A3 H3 V3	53.33	66.67
5	A3 A1 H1 H2 A2	53.33	66.67	A3 H3 D1 V1 H1	53.33	26.67	A1 A2 A3 H3 V3	53.33	66.67
6	A3 A1 H1 H2 A2 D1	53.33	60.00	A3 H3 D1 V1 H1 A1	53.33	46.67	A1 A2 A3 H3 V3 D3	53.33	66.67
7	A3 A1 H1 H2 A2 D1 V1	53.33	60.00	A3 H3 D1 V1 H1 A1 D2	53.33	40.00	A1 H1 A2 A3 H3 V3 D3	53.33	66.67
8	A3 A1 H1 H2 A2 D1 V1 H3	53.33	60.00	A3 H3 D1 V1 H1 A1 D2 V2	53.33	40.00	A1 H1 V1 A2 A3 H3 V3 D3	53.33	66.67
9	A3 A1 H1 H2 A2 D1 V1 H3 D2	53.33	60.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	53.33	40.00	A1 H1 V1 D1 A2 A3 H3 V3 D3	53.33	60.00
10	A3 A1 H1 H2 A2 D1 V1 H3 D2 V2	53.33	60.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	53.33	60.00	A1 H1 V1 D1 A2 H2 A3 H3 V3 D3	53.33	66.67
11	A3 A1 H1 H2 A2 D1 V1 H3 D2 V2 V3	53.33	66.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	53.33	66.67	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	60.00	66.67

ตารางที่ ข.8 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 5

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	93.33	A3 V3	100.00	93.33
3	A3 A1 H1	100.00	100.00	A3 V3 D2	100.00	93.33	A3 H3 V3	100.00	100.00
4	A3 A1 H1 H3	100.00	100.00	A3 V3 D2 V2	100.00	93.33	A1 A3 H3 V3	100.00	100.00
5	A3 A1 H1 H3 D2	100.00	100.00	A3 V3 D2 V2 H2	100.00	93.33	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H1 H3 D2 V2	100.00	100.00	A3 V3 D2 V2 H2 A2	100.00	93.33	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H1 H3 D2 V2 H2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1	100.00	93.33	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H1 H3 D2 V2 H2 A2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1	100.00	93.33	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H1 H3 D2 V2 H2 A2 D1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	86.67	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	93.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1 V3	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	100.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00

ตารางที่ ข.9 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 6

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	100.00	A3 V3	100.00	100.00
3	A3 A1 H1	100.00	100.00	A3 V3 D2	100.00	100.00	A3 H3 V3	100.00	100.00
4	A3 A1 H1 H3	100.00	100.00	A3 V3 D2 V2	100.00	100.00	A1 A3 H3 V3	100.00	100.00
5	A3 A1 H1 H3 D2	100.00	100.00	A3 V3 D2 V2 H2	100.00	100.00	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H1 H3 D2 V2	100.00	100.00	A3 V3 D2 V2 H2 A2	100.00	100.00	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H1 H3 D2 V2 H2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1	100.00	100.00	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H1 H3 D2 V2 H2 A2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1	100.00	100.00	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H1 H3 D2 V2 H2 A2 D1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	100.00	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	100.00	A1 H1 V1 D1 A2 H2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1 V3	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	100.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00

ตารางที่ ข.10 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไปหน้าที่ 7

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	66.67	66.67	A3	66.67	66.67	A3	66.67	66.67
2	A3 A1	66.67	73.33	A3 V3	73.33	66.67	A3 V3	73.33	66.67
3	A3 A1 H1	66.67	80.00	A3 V3 D2	73.33	40.00	A3 H3 V3	66.67	73.33
4	A3 A1 H1 H2	73.33	80.00	A3 V3 D2 V2	73.33	66.67	A1 A3 H3 V3	66.67	86.67
5	A3 A1 H1 H2 A2	60.00	80.00	A3 V3 D2 V2 H2	66.67	46.67	A1 A2 A3 H3 V3	66.67	80.00
6	A3 A1 H1 H2 A2 D1	60.00	66.67	A3 V3 D2 V2 H2 A2	66.67	46.67	A1 A2 A3 H3 V3 D3	66.67	80.00
7	A3 A1 H1 H2 A2 D1 V1	60.00	66.67	A3 V3 D2 V2 H2 A2 D1	66.67	53.33	A1 H1 A2 A3 H3 V3 D3	66.67	86.67
8	A3 A1 H1 H2 A2 D1 V1 H3	73.33	86.67	A3 V3 D2 V2 H2 A2 D1 V1	66.67	60.00	A1 H1 V1 A2 A3 H3 V3 D3	66.67	86.67
9	A3 A1 H1 H2 A2 D1 V1 H3 D2	73.33	80.00	A3 V3 D2 V2 H2 A2 D1 V1 H1	66.67	73.33	A1 H1 V1 D1 A2 A3 H3 V3 D3	66.67	80.00
10	A3 A1 H1 H2 A2 D1 V1 H3 D2 V2	73.33	66.67	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	66.67	66.67	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	66.67	80.00
11	A3 A1 H1 H2 A2 D1 V1 H3 D2 V2 V3	66.67	80.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	66.67	80.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	66.67	80.00

ตารางที่ ข.11 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งเป้าหมายที่ 8

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	80.00	A3 V3	100.00	80.00
3	A3 A1 H3	100.00	100.00	A3 V3 D2	100.00	80.00	A3 H3 V3	100.00	80.00
4	A3 A1 H3 D2	100.00	93.33	A3 V3 D2 V2	100.00	80.00	A1 A3 H3 V3	100.00	100.00
5	A3 A1 H3 D2 V2	100.00	80.00	A3 V3 D2 V2 H2	100.00	66.67	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H3 D2 V2 H2	100.00	73.33	A3 V3 D2 V2 H2 A2	100.00	86.67	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H3 D2 V2 H2 A2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1	100.00	93.33	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H3 D2 V2 H2 A2 D1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1	100.00	80.00	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H3 D2 V2 H2 A2 D1 V1	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	80.00	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H3 D2 V2 H2 A2 D1 V1 H1	100.00	86.67	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	93.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H3 D2 V2 H2 A2 D1 V1 H1 V3	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	93.33	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	93.33

ตารางที่ ข.12 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งเป้าหมายที่ 9

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	93.33	A3 V3	100.00	93.33
3	A3 A1 H3	100.00	100.00	A3 V3 D2	100.00	93.33	A3 H3 V3	100.00	93.33
4	A3 A1 H3 D2	100.00	100.00	A3 V3 D2 V2	100.00	86.67	A1 A3 H3 V3	100.00	100.00
5	A3 A1 H3 D2 H1	100.00	93.33	A3 V3 D2 V2 H2	100.00	93.33	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H3 D2 H1 H2	100.00	80.00	A3 V3 D2 V2 H2 A2	100.00	100.00	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H3 D2 H1 H2 A2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1	100.00	93.33	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H3 D2 H1 H2 A2 D1	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1	100.00	93.33	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H3 D2 H1 H2 A2 D1 V1	100.00	86.67	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	86.67	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H3 D2 H1 H2 A2 D1 V1 V2	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	100.00	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H3 D2 H1 H2 A2 D1 V1 V2 V3	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	100.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00

ตารางที่ ข.13 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งไบนารีที่ 10

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	80.00	A3 V3	100.00	80.00
3	A3 A1 H3	100.00	100.00	A3 V3 D2	100.00	93.33	A3 H3 V3	100.00	86.67
4	A3 A1 H3 D2	100.00	100.00	A3 V3 D2 V2	100.00	86.67	A1 A3 H3 V3	100.00	100.00
5	A3 A1 H3 D2 H1	100.00	86.67	A3 V3 D2 V2 H2	100.00	80.00	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H3 D2 H1 H2	100.00	66.67	A3 V3 D2 V2 H2 A2	100.00	93.33	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H3 D2 H1 H2 A2	100.00	93.33	A3 V3 D2 V2 H2 A2 D1	100.00	93.33	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H3 D2 H1 H2 A2 V2	100.00	86.67	A3 V3 D2 V2 H2 A2 D1 V1	100.00	86.67	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H3 D2 H1 H2 A2 V2 D1	100.00	86.67	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	86.67	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H3 D2 H1 H2 A2 V2 D1 V1	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	93.33	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H3 D2 H1 H2 A2 V2 D1 V1 V3	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	93.33	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	93.33

ตารางที่ ข.14 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล Yale เมื่อตั้งเป้าหมายที่ 11

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 A1	100.00	100.00	A3 V3	100.00	80.00	A3 V3	100.00	80.00
3	A3 A1 H1	100.00	100.00	A3 V3 D2	100.00	86.67	A3 H3 V3	100.00	80.00
4	A3 A1 H1 H3	100.00	93.33	A3 V3 D2 V2	100.00	93.33	H1 A3 H3 V3	100.00	73.33
5	A3 A1 H1 H3 D2	100.00	80.00	A3 V3 D2 V2 H2	100.00	93.33	A1 A2 A3 H3 V3	100.00	100.00
6	A3 A1 H1 H3 D2 V2	100.00	93.33	A3 V3 D2 V2 H2 A2	100.00	100.00	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 A1 H1 H3 D2 V2 H2	100.00	86.67	A3 V3 D2 V2 H2 A2 D1	100.00	100.00	A1 H1 A2 A3 H3 V3 D3	100.00	100.00
8	A3 A1 H1 H3 D2 V2 H2 A2	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1	100.00	100.00	A1 H1 V1 A2 A3 H3 V3 D3	100.00	100.00
9	A3 A1 H1 H3 D2 V2 H2 A2 D1	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1	100.00	86.67	A1 H1 V1 D1 A2 A3 H3 V3 D3	100.00	100.00
10	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1	100.00	93.33	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1	100.00	100.00	A1 H1 V1 D1 A2 V2 A3 H3 V3 D3	100.00	100.00
11	A3 A1 H1 H3 D2 V2 H2 A2 D1 V1 V3	100.00	100.00	A3 V3 D2 V2 H2 A2 D1 V1 H1 A1 H3	100.00	100.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00

ตารางที่ ข.15 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 1

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	93.33	93.33	A3	93.33	93.33	A3	93.33	93.33
2	A3 A1	93.33	93.33	A3 H3	91.67	80.00	A3 H3	91.67	80.00
3	A3 A1 D2	93.33	90.00	A3 H3 D1	91.67	75.00	A2 A3 H3	93.33	86.67
4	A3 A1 D2 V2	93.33	86.67	A3 H3 D1 V1	91.67	76.67	H1 A2 A3 H3	93.33	80.00
5	A3 A1 D2 V2 H2	93.33	83.33	A3 H3 D1 V1 H1	91.67	68.33	A1 A2 A3 H3 V3	93.33	95.00
6	A3 A1 D2 V2 H2 A2	93.33	93.33	A3 H3 D1 V1 H1 A1	91.67	88.33	A1 A2 A3 H3 V3 D3	91.67	95.00
7	A3 A1 D2 V2 H2 A2 D1	93.33	93.33	A3 H3 D1 V1 H1 A1 D2	91.67	85.00	A1 A2 H2 A3 H3 V3 D3	93.33	93.33
8	A3 A1 D2 V2 H2 A2 D1 V1	93.33	88.33	A3 H3 D1 V1 H1 A1 D2 V2	91.67	85.00	A1 A2 H2 V2 A3 H3 V3 D3	91.67	95.00
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	93.33	88.33	A3 H3 D1 V1 H1 A1 D2 V2 H2	91.67	81.67	A1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	93.33	90.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	93.33	90.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	91.67
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	93.33	90.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	93.33	90.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	90.00

ตารางที่ ข.16 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 2

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	95.00	95.00	A3	95.00	95.00	A3	95.00	95.00
2	A3 A1	95.00	93.33	A3 H3	93.33	60.00	A3 H3	93.33	60.00
3	A3 A1 D2	95.00	91.67	A3 H3 D1	93.33	60.00	A2 A3 H3	93.33	81.67
4	A3 A1 D2 V2	95.00	91.67	A3 H3 D1 V1	93.33	63.33	H1 A2 A3 H3	93.33	91.67
5	A3 A1 D2 V2 H2	95.00	88.33	A3 H3 D1 V1 H1	93.33	61.67	A1 A2 A3 H3 V3	93.33	96.67
6	A3 A1 D2 V2 H2 A2	95.00	95.00	A3 H3 D1 V1 H1 A1	93.33	80.00	A1 A2 A3 H3 V3 D3	93.33	96.67
7	A3 A1 D2 V2 H2 A2 D1	95.00	93.33	A3 H3 D1 V1 H1 A1 D2	93.33	80.00	A1 A2 H2 A3 H3 V3 D3	93.33	93.33
8	A3 A1 D2 V2 H2 A2 D1 V1	95.00	91.67	A3 H3 D1 V1 H1 A1 D2 V2	93.33	80.00	A1 A2 H2 V2 A3 H3 V3 D3	93.33	91.67
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	95.00	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2	93.33	78.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	93.33	93.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	93.33	88.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	93.33	88.33	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	93.33	90.00
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	93.33	90.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	93.33	90.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	93.33	90.00

ตารางที่ ข.17 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 3

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	88.33	88.33	A3	88.33	88.33	A3	88.33	88.33
2	A3 A1	88.33	88.33	A3 H3	85.00	51.67	A3 H3	85.00	51.67
3	A3 A1 D2	88.33	83.33	A3 H3 D1	85.00	51.67	A2 A3 H3	91.67	81.67
4	A3 A1 D2 V2	90.00	78.33	A3 H3 D1 V1	85.00	53.33	A2 A3 H3 D3	90.00	91.67
5	A3 A1 D2 V2 H2	90.00	78.33	A3 H3 D1 V1 H1	85.00	50.00	A1 A2 A3 H3 V3	93.33	93.33
6	A3 A1 D2 V2 H2 A2	88.33	91.67	A3 H3 D1 V1 H1 A1	86.67	75.00	A1 A2 A3 H3 V3 D3	93.33	93.33
7	A3 A1 D2 V2 H2 A2 D1	88.33	91.67	A3 H3 D1 V1 H1 A1 D2	86.67	71.67	A1 A2 H2 A3 H3 V3 D3	93.33	93.33
8	A3 A1 D2 V2 H2 A2 D1 V1	88.33	90.00	A3 H3 D1 V1 H1 A1 D2 V2	88.33	73.33	A1 A2 H2 V2 A3 H3 V3 D3	91.67	93.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	88.33	90.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	90.00	68.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	93.33	88.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	91.67	88.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	91.67	88.33	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	91.67	88.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	93.33	88.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	93.33	88.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	93.33	85.00

ตารางที่ ข.18 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 4

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	70.00	70.00	A3	70.00	70.00	A3	70.00	70.00
2	A3 A1	70.00	71.67	A3 H3	70.00	20.00	A3 H3	70.00	20.00
3	A3 A1 H3	68.33	73.33	A3 H3 D1	70.00	15.00	A2 A3 H3	71.67	40.00
4	A3 A1 H3 D2	70.00	65.00	A3 H3 D1 V1	70.00	13.33	H1 A2 A3 H3	71.67	63.33
5	A3 A1 H3 D2 V2	71.67	63.33	A3 H3 D1 V1 H1	70.00	15.00	A1 A2 A3 H3 V3	71.67	71.67
6	A3 A1 H3 D2 V2 H2	71.67	53.33	A3 H3 D1 V1 H1 A1	68.33	56.67	A1 A2 A3 H3 V3 D3	70.00	71.67
7	A3 A1 H3 D2 V2 H2 A2	71.67	66.67	A3 H3 D1 V1 H1 A1 D2	70.00	41.67	A1 A2 H2 A3 H3 V3 D3	68.33	68.33
8	A3 A1 H3 D2 V2 H2 A2 D1	71.67	65.00	A3 H3 D1 V1 H1 A1 D2 V2	71.67	33.33	A1 A2 H2 V2 A3 H3 V3 D3	70.00	66.67
9	A3 A1 H3 D2 V2 H2 A2 D1 V1	71.67	61.67	A3 H3 D1 V1 H1 A1 D2 V2 H2	71.67	26.67	A1 H1 A2 H2 V2 A3 H3 V3 D3	70.00	63.33
10	A3 A1 H3 D2 V2 H2 A2 D1 V1 H1	71.67	61.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	71.67	61.67	A1 H1 V1 A2 H2 V2 A3 H3 V3 D3	70.00	58.33
11	A3 A1 H3 D2 V2 H2 A2 D1 V1 H1 V3	68.33	60.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	68.33	60.00	A1 H1 V1 D1 A2 H2 V2 A3 H3 V3 D3	70.00	56.67

ตารางที่ ข.19 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 5

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	85.00	85.00	A3	85.00	85.00	A3	85.00	85.00
2	A3 A1	86.67	95.00	A3 H3	90.00	85.00	A3 H3	90.00	85.00
3	A3 A1 D2	86.67	90.00	A3 H3 D1	90.00	76.67	A2 A3 H3	90.00	95.00
4	A3 A1 D2 V2	86.67	91.67	A3 H3 D1 V1	90.00	83.33	H1 A2 A3 H3	90.00	93.33
5	A3 A1 D2 V2 H2	86.67	91.67	A3 H3 D1 V1 H1	90.00	80.00	A1 A2 A3 H3 V3	88.33	93.33
6	A3 A1 D2 V2 H2 A2	86.67	93.33	A3 H3 D1 V1 H1 A1	90.00	93.33	A1 A2 A3 H3 V3 D3	90.00	95.00
7	A3 A1 D2 V2 H2 A2 D1	86.67	91.67	A3 H3 D1 V1 H1 A1 D2	90.00	88.33	A1 A2 H2 A3 H3 V3 D3	90.00	93.33
8	A3 A1 D2 V2 H2 A2 D1 V1	86.67	91.67	A3 H3 D1 V1 H1 A1 D2 V2	88.33	86.67	A1 A2 H2 V2 A3 H3 V3 D3	90.00	93.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	86.67	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2	88.33	86.67	A1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	90.00	93.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	90.00	93.33	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	88.33	93.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	88.33	93.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33

ตารางที่ ข.20 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 6

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	96.67	96.67	A3	96.67	96.67	A3	96.67	96.67
2	A3 A1	98.33	100.00	A3 H3	98.33	96.67	A3 H3	98.33	96.67
3	A3 A1 D2	98.33	96.67	A3 H3 D1	98.33	93.33	A2 A3 H3	98.33	100.00
4	A3 A1 D2 V2	98.33	100.00	A3 H3 D1 V1	98.33	95.00	A2 A3 H3 D3	98.33	100.00
5	A3 A1 D2 V2 H2	98.33	98.33	A3 H3 D1 V1 H1	98.33	91.67	A1 A2 A3 H3 V3	98.33	100.00
6	A3 A1 D2 V2 H2 A2	98.33	100.00	A3 H3 D1 V1 H1 A1	98.33	98.33	A1 A2 A3 H3 V3 D3	98.33	100.00
7	A3 A1 D2 V2 H2 A2 D1	98.33	100.00	A3 H3 D1 V1 H1 A1 D2	98.33	95.00	A1 A2 H2 A3 H3 V3 D3	98.33	100.00
8	A3 A1 D2 V2 H2 A2 D1 V1	98.33	100.00	A3 H3 D1 V1 H1 A1 D2 V2	98.33	98.33	A1 A2 H2 V2 A3 H3 V3 D3	98.33	100.00
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	98.33	100.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	98.33	98.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	98.33	100.00
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	98.33	100.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	98.33	100.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	98.33	100.00
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	98.33	100.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	98.33	100.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	98.33	100.00

ตารางที่ ข.21 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 7

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	91.67	91.67	A3	91.67	91.67	A3	91.67	91.67
2	A3 A1	91.67	95.00	A3 H3	95.00	98.33	A3 H3	95.00	98.33
3	A3 A1 D2	91.67	93.33	A3 H3 D1	95.00	93.33	A2 A3 H3	95.00	98.33
4	A3 A1 D2 V2	90.00	96.67	A3 H3 D1 V1	95.00	91.67	A2 A3 H3 D3	95.00	98.33
5	A3 A1 D2 V2 H2	91.67	93.33	A3 H3 D1 V1 H1	95.00	90.00	A1 A2 A3 H3 V3	96.67	96.67
6	A3 A1 D2 V2 H2 A2	93.33	98.33	A3 H3 D1 V1 H1 A1	95.00	95.00	A1 A2 A3 H3 V3 D3	96.67	98.33
7	A3 A1 D2 V2 H2 A2 D1	93.33	96.67	A3 H3 D1 V1 H1 A1 D2	95.00	90.00	A1 A2 H2 A3 H3 V3 D3	96.67	98.33
8	A3 A1 D2 V2 H2 A2 D1 V1	93.33	95.00	A3 H3 D1 V1 H1 A1 D2 V2	95.00	93.33	A1 A2 H2 V2 A3 H3 V3 D3	96.67	100.00
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	93.33	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	95.00	96.67	A1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	95.00	96.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	95.00	96.67	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	96.67	98.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	96.67	98.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33

ตารางที่ ข.22 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 8

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	96.67	96.67	A3	96.67	96.67	A3	96.67	96.67
2	A3 A1	96.67	96.67	A3 H3	98.33	85.00	A3 H3	98.33	85.00
3	A3 A1 D2	96.67	95.00	A3 H3 D1	98.33	85.00	A2 A3 H3	98.33	98.33
4	A3 A1 D2 V2	96.67	95.00	A3 H3 D1 V1	98.33	88.33	A3 H3 V3 D3	96.67	98.33
5	A3 A1 D2 V2 H2	96.67	95.00	A3 H3 D1 V1 H1	98.33	85.00	A1 A2 A3 H3 V3	96.67	98.33
6	A3 A1 D2 V2 H2 A2	96.67	98.33	A3 H3 D1 V1 H1 A1	98.33	93.33	A1 A2 A3 H3 V3 D3	96.67	98.33
7	A3 A1 D2 V2 H2 A2 D1	96.67	98.33	A3 H3 D1 V1 H1 A1 D2	98.33	90.00	A1 A2 H2 A3 H3 V3 D3	96.67	98.33
8	A3 A1 D2 V2 H2 A2 D1 V1	96.67	98.33	A3 H3 D1 V1 H1 A1 D2 V2	98.33	90.00	A1 A2 H2 V2 A3 H3 V3 D3	96.67	98.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	96.67	96.67	A3 H3 D1 V1 H1 A1 D2 V2 H2	98.33	90.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	98.33	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	98.33	95.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	96.67	98.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	96.67	98.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33

ตารางที่ ข.23 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งไบนารีที่ 9

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	96.67	96.67	A3	96.67	96.67	A3	96.67	96.67
2	A3 A1	96.67	96.67	A3 H3	95.00	70.00	A3 H3	95.00	70.00
3	A3 A1 D2	96.67	95.00	A3 H3 D1	95.00	71.67	A2 A3 H3	95.00	93.33
4	A3 A1 D2 V2	96.67	95.00	A3 H3 D1 V1	95.00	65.00	A2 A3 H3 D3	96.67	98.33
5	A3 A1 D2 V2 H2	96.67	91.67	A3 H3 D1 V1 H1	95.00	65.00	A1 A2 A3 H3 V3	95.00	96.67
6	A3 A1 D2 V2 H2 A2	96.67	98.33	A3 H3 D1 V1 H1 A1	95.00	90.00	A1 A2 A3 H3 V3 D3	96.67	96.67
7	A3 A1 D2 V2 H2 A2 D1	96.67	98.33	A3 H3 D1 V1 H1 A1 D2	95.00	86.67	A1 A2 H2 A3 H3 V3 D3	95.00	96.67
8	A3 A1 D2 V2 H2 A2 D1 V1	96.67	96.67	A3 H3 D1 V1 H1 A1 D2 V2	95.00	86.67	A1 A2 H2 V2 A3 H3 V3 D3	95.00	96.67
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	96.67	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	95.00	83.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	96.67
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	95.00	96.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	95.00	96.67	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	96.67
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	96.67	96.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	96.67	96.67	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	96.67

ตารางที่ ข.24 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งเป้าหมายที่ 10

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	96.67	96.67	A3	96.67	96.67	A3	96.67	96.67
2	A3 A1	96.67	93.33	A3 H3	95.00	71.67	A3 H3	95.00	71.67
3	A3 A1 D2	96.67	93.33	A3 H3 D1	95.00	71.67	A2 A3 H3	95.00	91.67
4	A3 A1 D2 V2	96.67	90.00	A3 H3 D1 V1	95.00	70.00	A2 V2 A3 H3	95.00	96.67
5	A3 A1 D2 V2 H2	96.67	86.67	A3 H3 D1 V1 H1	95.00	66.67	A1 A2 A3 H3 V3	96.67	96.67
6	A3 A1 D2 V2 H2 A2	98.33	93.33	A3 H3 D1 V1 H1 A1	95.00	91.67	A1 A2 A3 H3 V3 D3	96.67	95.00
7	A3 A1 D2 V2 H2 A2 D1	98.33	91.67	A3 H3 D1 V1 H1 A1 D2	95.00	81.67	A1 A2 H2 A3 H3 V3 D3	96.67	95.00
8	A3 A1 D2 V2 H2 A2 D1 V1	98.33	88.33	A3 H3 D1 V1 H1 A1 D2 V2	93.33	80.00	A1 H1 A2 H2 A3 H3 V3 D3	96.67	95.00
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	98.33	85.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	91.67	78.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	95.00
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	95.00	86.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	95.00	86.67	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	93.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	96.67	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	96.67	91.67	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	91.67

ตารางที่ ข.25 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งเป้าหมายที่ 11

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	75.00	75.00	A3	75.00	75.00	A3	75.00	75.00
2	A3 A1	75.00	76.67	A3 H3	75.00	13.33	A3 H3	75.00	13.33
3	A3 A1 D2	75.00	68.33	A3 H3 D2	75.00	11.67	A3 H3 V3	73.33	43.33
4	A3 A1 D2 V2	76.67	70.00	A3 H3 D2 V2	71.67	16.67	A2 A3 H3 D3	75.00	71.67
5	A3 A1 D2 V2 H2	76.67	66.67	A3 H3 D2 V2 H2	75.00	15.00	A1 A2 A3 H3 V3	71.67	81.67
6	A3 A1 D2 V2 H2 A2	80.00	78.33	A3 H3 D2 V2 H2 A2	75.00	60.00	A1 A2 A3 H3 V3 D3	73.33	80.00
7	A3 A1 D2 V2 H2 A2 D1	80.00	76.67	A3 H3 D2 V2 H2 A2 V3	75.00	58.33	A1 A2 H2 A3 H3 V3 D3	73.33	75.00
8	A3 A1 D2 V2 H2 A2 D1 V1	80.00	76.67	A3 H3 D2 V2 H2 A2 V3 A1	75.00	73.33	A1 A2 H2 V2 A3 H3 V3 D3	73.33	73.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	80.00	75.00	A3 H3 D2 V2 H2 A2 V3 A1 D1	75.00	71.67	A1 A2 H2 V2 D2 A3 H3 V3 D3	73.33	71.67
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	75.00	75.00	A3 H3 D2 V2 H2 A2 V3 A1 D1 H1	75.00	70.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	73.33	70.00
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	75.00	63.33	A3 H3 D2 V2 H2 A2 V3 A1 D1 H1 V1	75.00	63.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	73.33	63.33

ตารางที่ ข.26 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งเป้าหมายที่ 12

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	86.67	86.67	A3	86.67	86.67	A3	86.67	86.67
2	A3 A1	85.00	91.67	A3 H3	81.67	90.00	A3 H3	81.67	90.00
3	A3 A1 D2	85.00	85.00	A3 H3 D1	81.67	80.00	A2 A3 H3	83.33	96.67
4	A3 A1 D2 V2	85.00	91.67	A3 H3 D1 V1	81.67	81.67	H1 A2 A3 H3	83.33	95.00
5	A3 A1 D2 V2 H2	85.00	91.67	A3 H3 D1 V1 H1	81.67	81.67	A1 A2 A3 H3 V3	86.67	95.00
6	A3 A1 D2 V2 H2 A2	86.67	93.33	A3 H3 D1 V1 H1 A1	81.67	91.67	A1 A2 A3 H3 V3 D3	91.67	93.33
7	A3 A1 D2 V2 H2 A2 D1	86.67	93.33	A3 H3 D1 V1 H1 A1 D2	81.67	90.00	A1 A2 H2 A3 H3 V3 D3	91.67	93.33
8	A3 A1 D2 V2 H2 A2 D1 V1	86.67	91.67	A3 H3 D1 V1 H1 A1 D2 V2	81.67	91.67	A1 A2 H2 V2 A3 H3 V3 D3	90.00	93.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	86.67	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2	83.33	90.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	83.33	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	83.33	91.67	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	88.33	91.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	88.33	91.67	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	90.00	93.33

ตารางที่ ข.27 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งเป้าหมายที่ 13

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	96.67	96.67	A3	96.67	96.67	A3	96.67	96.67
2	A3 A1	95.00	100.00	A3 H3	98.33	91.67	A3 H3	98.33	91.67
3	A3 A1 D2	95.00	96.67	A3 H3 D1	98.33	90.00	A2 A3 H3	98.33	98.33
4	A3 A1 D2 V2	95.00	96.67	A3 H3 D1 V1	98.33	90.00	A2 V2 A3 H3	98.33	98.33
5	A3 A1 D2 V2 H2	95.00	98.33	A3 H3 D1 V1 H1	98.33	90.00	A1 A2 A3 H3 V3	96.67	100.00
6	A3 A1 D2 V2 H2 A2	98.33	96.67	A3 H3 D1 V1 H1 A1	98.33	95.00	A1 A2 A3 H3 V3 D3	96.67	100.00
7	A3 A1 D2 V2 H2 A2 D1	98.33	96.67	A3 H3 D1 V1 H1 A1 D2	98.33	93.33	A1 A2 H2 A3 H3 V3 D3	96.67	96.67
8	A3 A1 D2 V2 H2 A2 D1 V1	98.33	96.67	A3 H3 D1 V1 H1 A1 D2 V2	98.33	95.00	A1 A2 H2 V2 A3 H3 V3 D3	96.67	98.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	98.33	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	98.33	93.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	98.33	96.67	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	98.33	96.67	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	96.67	98.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	96.67	98.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	96.67	98.33

ตารางที่ ข.28 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล AR เมื่อตั้งเป้าหมายที่ 14

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	88.33	88.33	A3	88.33	88.33	A3	88.33	88.33
2	A3 A1	88.33	93.33	A3 H3	93.33	95.00	A3 H3	93.33	95.00
3	A3 A1 D2	88.33	88.33	A3 H3 D1	93.33	86.67	A2 A3 H3	91.67	98.33
4	A3 A1 D2 V2	90.00	91.67	A3 H3 D1 V1	93.33	86.67	A2 A3 H3 D3	91.67	100.00
5	A3 A1 D2 V2 H2	90.00	91.67	A3 H3 D1 V1 H1	93.33	88.33	A1 A2 A3 H3 V3	95.00	96.67
6	A3 A1 D2 V2 H2 A2	90.00	95.00	A3 H3 D1 V1 H1 A1	91.67	93.33	A1 A2 A3 H3 V3 D3	95.00	96.67
7	A3 A1 D2 V2 H2 A2 D1	90.00	95.00	A3 H3 D1 V1 H1 A1 D2	91.67	88.33	A1 A2 H2 A3 H3 V3 D3	95.00	96.67
8	A3 A1 D2 V2 H2 A2 D1 V1	90.00	95.00	A3 H3 D1 V1 H1 A1 D2 V2	91.67	93.33	A1 A2 H2 V2 A3 H3 V3 D3	95.00	98.33
9	A3 A1 D2 V2 H2 A2 D1 V1 H1	90.00	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2	91.67	93.33	A1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	98.33
10	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3	93.33	95.00	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2	93.33	95.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	98.33
11	A3 A1 D2 V2 H2 A2 D1 V1 H1 H3 V3	95.00	98.33	A3 H3 D1 V1 H1 A1 D2 V2 H2 A2 V3	95.00	98.33	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	98.33

ตารางที่ ข.29 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 1

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	2.50	A3 A2	97.50	97.50	A2 A3	97.50	97.50
3	A3 D1 V3	97.50	47.50	A3 A2 H3	97.50	97.50	A2 A3 V3	100.00	97.50
4	A3 D1 V3 H3	97.50	82.50	A3 A2 H3 D2	97.50	97.50	A2 A3 H3 V3	97.50	97.50
5	A3 D1 V3 H3 D2	97.50	57.50	A3 A2 H3 D2 V2	97.50	82.50	A1 A2 A3 H3 V3	97.50	97.50
6	A3 D1 V3 H3 D2 V2	97.50	32.50	A3 A2 H3 D2 V2 V3	97.50	87.50	A1 A2 A3 H3 V3 D3	97.50	97.50
7	A3 D1 V3 H3 D2 V2 H2	97.50	27.50	A3 A2 H3 D2 V2 V3 V1	97.50	82.50	A1 A2 V2 A3 H3 V3 D3	97.50	97.50
8	A3 D1 V3 H3 D2 V2 H2 A2	97.50	70.00	A3 A2 H3 D2 V2 V3 V1 D1	97.50	62.50	A1 A2 H2 V2 A3 H3 V3 D3	97.50	95.00
9	A3 D1 V3 H3 D2 V2 H2 A2 V1	97.50	55.00	A3 A2 H3 D2 V2 V3 V1 D1 H1	97.50	47.50	A1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	92.50
10	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1	97.50	47.50	A3 A2 H3 D2 V2 V3 V1 D1 H1 A1	97.50	85.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	87.50
11	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1 A1	97.50	70.00	A3 A2 H3 D2 V2 V3 V1 D1 H1 A1 H2	97.50	70.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	82.50

ตารางที่ ข.30 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 2

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 D1	100.00	2.50	A3 A2	100.00	100.00	A2 A3	100.00	100.00
3	A3 D1 H3	100.00	65.00	A3 A2 H3	100.00	100.00	A2 A3 V3	100.00	100.00
4	A3 D1 H3 V3	100.00	75.00	A3 A2 H3 D2	100.00	100.00	A2 A3 H3 V3	100.00	97.50
5	A3 D1 H3 V3 D2	100.00	62.50	A3 A2 H3 D2 V2	100.00	82.50	A1 A2 A3 H3 V3	100.00	100.00
6	A3 D1 H3 V3 D2 V2	100.00	40.00	A3 A2 H3 D2 V2 V3	100.00	87.50	A1 A2 A3 H3 V3 D3	100.00	100.00
7	A3 D1 H3 V3 D2 V2 H2	100.00	35.00	A3 A2 H3 D2 V2 V3 D1	100.00	77.50	A1 A2 V2 A3 H3 V3 D3	100.00	100.00
8	A3 D1 H3 V3 D2 V2 H2 A2	100.00	67.50	A3 A2 H3 D2 V2 V3 D1 V1	100.00	67.50	A1 A2 H2 V2 A3 H3 V3 D3	100.00	100.00
9	A3 D1 H3 V3 D2 V2 H2 A2 V1	100.00	57.50	A3 A2 H3 D2 V2 V3 D1 V1 H1	100.00	55.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	97.50
10	A3 D1 H3 V3 D2 V2 H2 A2 V1 H1	100.00	50.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	100.00	85.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	92.50
11	A3 D1 H3 V3 D2 V2 H2 A2 V1 H1 A1	100.00	77.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	100.00	77.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	87.50

ตารางที่ ข.31 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 3

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	2.50	A3 A2	97.50	97.50	A2 A3	97.50	97.50
3	A3 D1 V3	97.50	47.50	A3 A2 H3	97.50	97.50	A2 A3 V3	97.50	97.50
4	A3 D1 V3 H3	97.50	77.50	A3 A2 H3 D2	97.50	95.00	A2 A3 H3 V3	97.50	97.50
5	A3 D1 V3 H3 D2	97.50	57.50	A3 A2 H3 D2 V2	97.50	87.50	A1 A2 A3 H3 V3	97.50	100.00
6	A3 D1 V3 H3 D2 V2	97.50	42.50	A3 A2 H3 D2 V2 V3	97.50	90.00	A1 A2 A3 H3 V3 D3	97.50	100.00
7	A3 D1 V3 H3 D2 V2 H2	97.50	42.50	A3 A2 H3 D2 V2 V3 D1	97.50	75.00	A1 A2 V2 A3 H3 V3 D3	97.50	97.50
8	A3 D1 V3 H3 D2 V2 H2 A2	97.50	67.50	A3 A2 H3 D2 V2 V3 D1 V1	97.50	60.00	A1 A2 H2 V2 A3 H3 V3 D3	97.50	97.50
9	A3 D1 V3 H3 D2 V2 H2 A2 V1	97.50	57.50	A3 A2 H3 D2 V2 V3 D1 V1 H1	97.50	47.50	A1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	95.00
10	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1	97.50	47.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	97.50	75.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	87.50
11	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1 A1	97.50	72.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	97.50	72.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	80.00

ตารางที่ ข.32 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 4

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	5.00	A3 A2	97.50	97.50	A2 A3	97.50	97.50
3	A3 D1 V3	97.50	55.00	A3 A2 H3	97.50	97.50	A2 A3 V3	97.50	97.50
4	A3 D1 V3 H3	97.50	70.00	A3 A2 H3 D2	97.50	97.50	A2 A3 H3 V3	97.50	97.50
5	A3 D1 V3 H3 D2	97.50	60.00	A3 A2 H3 D2 V2	97.50	92.50	A1 A2 A3 H3 V3	97.50	97.50
6	A3 D1 V3 H3 D2 V2	97.50	55.00	A3 A2 H3 D2 V2 V3	97.50	92.50	A1 A2 A3 H3 V3 D3	97.50	97.50
7	A3 D1 V3 H3 D2 V2 H2	97.50	50.00	A3 A2 H3 D2 V2 V3 D1	97.50	80.00	A1 A2 V2 A3 H3 V3 D3	97.50	97.50
8	A3 D1 V3 H3 D2 V2 H2 A2	97.50	67.50	A3 A2 H3 D2 V2 V3 D1 V1	97.50	72.50	A1 A2 H2 V2 A3 H3 V3 D3	97.50	87.50
9	A3 D1 V3 H3 D2 V2 H2 A2 V1	97.50	67.50	A3 A2 H3 D2 V2 V3 D1 V1 H1	97.50	67.50	A1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	85.00
10	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1	97.50	55.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	97.50	85.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	82.50
11	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1 A1	97.50	85.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	97.50	85.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	82.50

ตารางที่ ข.33 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 5

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	5.00	A3 A2	97.50	97.50	A2 A3	97.50	97.50
3	A3 D1 V3	97.50	55.00	A3 A2 H3	97.50	97.50	A2 A3 V3	97.50	97.50
4	A3 D1 V3 H3	97.50	75.00	A3 A2 H3 D2	97.50	97.50	A2 A3 H3 V3	97.50	92.50
5	A3 D1 V3 H3 D2	97.50	55.00	A3 A2 H3 D2 V2	97.50	85.00	A1 A2 A3 H3 V3	97.50	97.50
6	A3 D1 V3 H3 D2 V2	97.50	45.00	A3 A2 H3 D2 V2 V3	97.50	80.00	A1 A2 A3 H3 V3 D3	97.50	97.50
7	A3 D1 V3 H3 D2 V2 H2	97.50	50.00	A3 A2 H3 D2 V2 V3 D1	97.50	67.50	A1 A2 V2 A3 H3 V3 D3	97.50	95.00
8	A3 D1 V3 H3 D2 V2 H2 A2	97.50	67.50	A3 A2 H3 D2 V2 V3 D1 V1	97.50	60.00	A1 A2 H2 V2 A3 H3 V3 D3	97.50	95.00
9	A3 D1 V3 H3 D2 V2 H2 A2 V1	97.50	65.00	A3 A2 H3 D2 V2 V3 D1 V1 H1	97.50	50.00	A1 H1 A2 H2 V2 A3 H3 V3 D3	97.50	90.00
10	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1	97.50	55.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	97.50	72.50	A1 H1 V1 A2 H2 V2 A3 H3 V3 D3	97.50	87.50
11	A3 D1 V3 H3 D2 V2 H2 A2 V1 H1 A1	97.50	75.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	97.50	75.00	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	97.50	77.50

ตารางที่ ข.34 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 6

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 D1	100.00	2.50	A3 A2	100.00	97.50	A2 A3	100.00	97.50
3	A3 D1 H3	97.50	65.00	A3 A2 H3	97.50	97.50	A2 A3 V3	100.00	97.50
4	A3 D1 H3 D2	97.50	32.50	A3 A2 H3 D2	97.50	97.50	A2 A3 H3 V3	100.00	97.50
5	A3 D1 H3 D2 V2	97.50	32.50	A3 A2 H3 D2 V2	97.50	77.50	A1 A2 A3 H3 V3	97.50	97.50
6	A3 D1 H3 D2 V2 H2	97.50	27.50	A3 A2 H3 D2 V2 V3	100.00	82.50	A1 A2 A3 H3 V3 D3	95.00	95.00
7	A3 D1 H3 D2 V2 H2 A2	97.50	52.50	A3 A2 H3 D2 V2 V3 D1	100.00	72.50	A1 A2 V2 A3 H3 V3 D3	95.00	95.00
8	A3 D1 H3 D2 V2 H2 A2 V1	97.50	52.50	A3 A2 H3 D2 V2 V3 D1 V1	100.00	65.00	A1 A2 H2 V2 A3 H3 V3 D3	95.00	95.00
9	A3 D1 H3 D2 V2 H2 A2 V1 H1	97.50	42.50	A3 A2 H3 D2 V2 V3 D1 V1 H1	100.00	57.50	A1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	85.00
10	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1	97.50	65.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	100.00	80.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	82.50
11	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1 V3	97.50	72.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	97.50	72.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	95.00	77.50

ตารางที่ ข.35 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 7

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	100.00	100.00	A3	100.00	100.00	A3	100.00	100.00
2	A3 D1	100.00	0.00	A3 A2	100.00	97.50	A2 A3	100.00	97.50
3	A3 D1 H3	100.00	52.50	A3 A2 H3	100.00	97.50	A2 A3 V3	100.00	97.50
4	A3 D1 H3 D2	100.00	30.00	A3 A2 H3 D2	100.00	95.00	A2 A3 H3 V3	100.00	97.50
5	A3 D1 H3 D2 V2	100.00	12.50	A3 A2 H3 D2 V2	100.00	82.50	A1 A2 A3 H3 V3	100.00	97.50
6	A3 D1 H3 D2 V2 H2	100.00	15.00	A3 A2 H3 D2 V2 V3	100.00	85.00	A1 A2 A3 H3 V3 D3	100.00	95.00
7	A3 D1 H3 D2 V2 H2 A2	100.00	60.00	A3 A2 H3 D2 V2 V3 D1	100.00	77.50	A1 A2 V2 A3 H3 V3 D3	100.00	95.00
8	A3 D1 H3 D2 V2 H2 A2 V1	100.00	52.50	A3 A2 H3 D2 V2 V3 D1 V1	100.00	65.00	A1 A2 H2 V2 A3 H3 V3 D3	100.00	90.00
9	A3 D1 H3 D2 V2 H2 A2 V1 H1	100.00	50.00	A3 A2 H3 D2 V2 V3 D1 V1 H1	100.00	55.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	87.50
10	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1	100.00	77.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	100.00	80.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	80.00
11	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1 V3	100.00	77.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	100.00	77.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	100.00	80.00

ตารางที่ ข.36 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 8

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	2.50	A3 A2	97.50	95.00	A2 A3	97.50	95.00
3	A3 D1 H3	97.50	65.00	A3 A2 H3	97.50	95.00	A2 A3 V3	95.00	95.00
4	A3 D1 H3 D2	97.50	32.50	A3 A2 H3 D2	97.50	95.00	A2 A3 H3 V3	92.50	95.00
5	A3 D1 H3 D2 V2	97.50	25.00	A3 A2 H3 D2 V2	97.50	77.50	A1 A2 A3 H3 V3	92.50	92.50
6	A3 D1 H3 D2 V2 H2	95.00	27.50	A3 A2 H3 D2 V2 V3	92.50	72.50	A1 A2 A3 H3 V3 D3	92.50	92.50
7	A3 D1 H3 D2 V2 H2 A2	97.50	57.50	A3 A2 H3 D2 V2 V3 D1	92.50	60.00	A1 A2 V2 A3 H3 V3 D3	92.50	90.00
8	A3 D1 H3 D2 V2 H2 A2 V1	97.50	50.00	A3 A2 H3 D2 V2 V3 D1 V1	92.50	57.50	A1 A2 H2 V2 A3 H3 V3 D3	92.50	90.00
9	A3 D1 H3 D2 V2 H2 A2 V1 H1	97.50	40.00	A3 A2 H3 D2 V2 V3 D1 V1 H1	92.50	50.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	90.00
10	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1	97.50	55.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	92.50	60.00	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	70.00
11	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1 V3	92.50	57.50	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	92.50	57.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	70.00

ตารางที่ ข.37 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อดึงใบหน้าที 9

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	97.50	97.50	A3	97.50	97.50	A3	97.50	97.50
2	A3 D1	97.50	2.50	A3 A2	97.50	92.50	A2 A3	97.50	92.50
3	A3 D1 H3	95.00	65.00	A3 A2 D2	97.50	92.50	A2 A3 V3	95.00	92.50
4	A3 D1 H3 D2	95.00	30.00	A3 A2 D2 H3	95.00	92.50	A2 A3 H3 V3	92.50	92.50
5	A3 D1 H3 D2 V2	95.00	15.00	A3 A2 D2 H3 V2	95.00	80.00	A1 A2 A3 H3 V3	92.50	92.50
6	A3 D1 H3 D2 V2 H2	92.50	12.50	A3 A2 D2 H3 V2 V3	92.50	80.00	A1 A2 A3 H3 V3 D3	92.50	92.50
7	A3 D1 H3 D2 V2 H2 A2	92.50	55.00	A3 A2 D2 H3 V2 V3 A1	92.50	85.00	A1 A2 V2 A3 H3 V3 D3	92.50	87.50
8	A3 D1 H3 D2 V2 H2 A2 V1	92.50	45.00	A3 A2 D2 H3 V2 V3 A1 H1	92.50	85.00	A1 A2 H2 V2 A3 H3 V3 D3	92.50	80.00
9	A3 D1 H3 D2 V2 H2 A2 V1 H1	92.50	30.00	A3 A2 D2 H3 V2 V3 A1 H1 V1	92.50	80.00	A1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	72.50
10	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1	92.50	62.50	A3 A2 D2 H3 V2 V3 A1 H1 V1 D1	92.50	67.50	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	72.50
11	A3 D1 H3 D2 V2 H2 A2 V1 H1 A1 V3	92.50	62.50	A3 A2 D2 H3 V2 V3 A1 H1 V1 D1 H2	92.50	62.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	92.50	67.50

ตารางที่ ข.38 แถบย่อยที่คัดเลือกได้ และผลการรู้จำบนฐานข้อมูล ORL เมื่อตั้งไบนารีที่ 10

จำนวน แถบย่อย	SI			IC:DPSS			IC:NDPSS		
	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion	แถบย่อยที่คัดเลือก	%Data fusion	%Dec. fusion
1	A3	92.50	92.50	A3	92.50	92.50	A3	92.50	92.50
2	A3 D3	92.50	30.00	A3 A2	90.00	87.50	A2 A3	90.00	87.50
3	A3 D3 H3	87.50	72.50	A3 A2 H3	87.50	87.50	A2 A3 V3	87.50	87.50
4	A3 D3 H3 D2	87.50	67.50	A3 A2 H3 D2	87.50	82.50	A2 A3 H3 V3	87.50	85.00
5	A3 D3 H3 D2 V2	87.50	42.50	A3 A2 H3 D2 V2	87.50	80.00	A1 A2 A3 H3 V3	87.50	90.00
6	A3 D3 H3 D2 V2 H2	87.50	42.50	A3 A2 H3 D2 V2 V3	87.50	80.00	A1 A2 A3 H3 V3 D3	87.50	92.50
7	A3 D3 H3 D2 V2 H2 A2	87.50	65.00	A3 A2 H3 D2 V2 V3 D1	87.50	62.50	A1 A2 V2 A3 H3 V3 D3	87.50	87.50
8	A3 D3 H3 D2 V2 H2 A2 D1	87.50	55.00	A3 A2 H3 D2 V2 V3 D1 V1	87.50	55.00	A1 A2 H2 V2 A3 H3 V3 D3	87.50	85.00
9	A3 D3 H3 D2 V2 H2 A2 D1 V1	87.50	45.00	A3 A2 H3 D2 V2 V3 D1 V1 H1	87.50	47.50	A1 A2 H2 V2 D2 A3 H3 V3 D3	87.50	80.00
10	A3 D3 H3 D2 V2 H2 A2 D1 V1 H1	87.50	40.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1	87.50	67.50	A1 H1 A2 H2 V2 D2 A3 H3 V3 D3	87.50	72.50
11	A3 D3 H3 D2 V2 H2 A2 D1 V1 H1 A1	87.50	60.00	A3 A2 H3 D2 V2 V3 D1 V1 H1 A1 H2	87.50	57.50	A1 H1 V1 A2 H2 V2 D2 A3 H3 V3 D3	87.50	72.50

ตารางที่ ข.39 ผลการรู้จำเฉลี่ยจากเกณฑ์การเลือกที่นำเสนอบนฐานข้อมูล Yale, AR, และ ORL

จำนวน แถบย่อย	Yale						AR						ORL					
	SI		IC:DPSS		IC:NDPSS		SI		IC:DPSS		IC:NDPSS		SI		IC:DPSS		IC:NDPSS	
	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion	%Data fusion	%Dec. fusion
1	91.52	91.52	91.52	91.52	91.52	91.52	51.50	51.50	51.50	51.50	51.50	51.50	97.75	97.75	97.75	97.75	97.75	97.75
2	91.52	91.52	90.30	80.00	90.30	80.00	52.75	36.91	52.08	58.26	52.75	36.91	97.75	5.50	97.50	96.00	97.50	96.00
3	90.91	90.30	90.30	76.97	89.70	86.06	52.56	25.99	52.08	51.98	53.82	32.08	96.75	59.00	97.00	96.00	97.00	96.00
4	89.70	87.88	90.30	81.21	89.70	91.52	52.95	31.21	53.43	57.97	53.82	58.07	96.75	57.25	96.75	95.00	96.25	95.00
5	88.48	85.45	89.70	75.76	90.30	92.73	53.04	33.53	53.43	56.43	54.30	60.48	96.75	42.00	96.75	82.75	96.00	96.25
6	88.48	80.00	89.70	84.24	89.70	92.73	54.49	49.08	53.43	55.94	55.17	60.29	96.25	34.00	96.25	83.75	95.75	96.00
7	87.88	86.67	89.70	84.24	89.70	93.33	54.49	44.64	53.43	51.50	55.07	57.58	96.50	49.50	96.25	74.00	95.75	94.25
8	89.09	90.91	89.70	82.42	89.70	92.73	54.49	40.48	53.82	47.92	54.98	57.68	96.50	59.50	96.25	65.00	95.75	91.50
9	89.09	88.48	89.70	81.21	89.70	92.12	54.49	35.94	53.43	48.70	54.98	55.46	96.50	51.00	96.25	55.75	95.75	87.50
10	89.09	87.27	89.09	87.88	89.70	92.73	54.30	51.59	54.49	50.05	54.98	53.91	96.50	55.50	96.25	75.75	95.75	81.50
11	89.70	91.52	89.70	91.52	90.30	91.52	54.40	51.88	54.40	51.88	54.98	52.75	96.00	71.00	96.00	70.75	95.75	77.75

ภาคผนวก ค

บทความที่ได้รับการตีพิมพ์

P. Sermwuthisarn, W. Asdonwised, S. Jitapunkul, and S. Marukatat, "Decision combination of multiple classifier systems for multiresolution face recognition," The 2007 ECTI International Conference, Thailand, 9-12 May 2007.



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

Decision Combination of Multiple Classifier Systems for Multiresolution Face Recognition

P. Sermwuthisarn¹, W. Asdornwised¹, S. Jitapunkul¹, and S. Marukatat²

¹Department of Electrical Engineering, Chulalongkorn University, Bangkok, Thailand

²National Electronics and Computer Technology Center (NECTEC), Pathumthani, Thailand

Abstract- In this paper, we propose an amelioration of the Principal Component Analysis (PCA) for face recognition using an ensemble method to multiresolution analysis. Indeed, the input data are first decomposed into several frequency subbands by Discrete Wavelet Transform (DWT) for representation. We consider several fusions of frequency subbands. Then, for each fusion, PCA is used in feature extraction and classification is done independently. The final decision is obtained from the majority vote of decision from each fusion. The experimental results show that our proposed method outperforms both PCA and Two-Dimensional Principal Component Analysis (2DPCA) in term of recognition accuracy rate.

I. INTRODUCTION

Face recognition is one of the most interested pattern recognition problems which are growing in many applications. Among face recognition algorithms, appearance-based approach [1] is the most popular. This approach relies on the pixel intensity-derived features. It can be further classified in 3 categories, which are holistic matching method, featured-based matching method and hybrid method [1]. Holistic matching method is used in this work. Holistic matching method uses the whole face region as the raw input to a recognition system, therefore it is also known as appearance-based method. In this approach, Principal Component Analysis (PCA) is widely used as feature extraction technique. PCA selects components at the source resolution that are optimal for minimizing mean square error in reconstructing the original input [2]. For classification, where discriminability among classes puts an additional constraint on representations, PCA is no longer optimal.

Features utilizing multiresolution have been demonstrated to preserve discriminability better than a single scale representation. Multiresolution is widely used techniques for signal representation. Wavelet decomposition is the most widely used multiresolution technique in image processing. The components are chosen to provide good representations of the input signal at several resolutions. The full set of components provides an exact reconstruction of the original signal. In Ref. [3], PCA and wavelet transform were using to reduce computation complexity. PCA was applied to extract meaningful features from one mid-range frequency subband. Moreover, Linear Discriminant Analysis (LDA) has also been used with multiresolution to reinforce discriminant power [4]. LDA was incorporated into low frequency subimage of three-level pyramid structured wavelet decomposition. While there are 2 main motivations for representation an image in several

resolutions. First, a given feature may be best observed at some scale, but the appropriate scale may not be known. Second, several features may be of interest, but no single resolution is satisfactory for all features. For example, in Ref. [5], a hybrid (local/global) model of the localized kernel feature and multiresolution feature for face representation and recognition has been presented. This approach exploited the intrinsic discriminating power of the face kernels. They were not only capable of exhibit performance comparable with other hybrid kernel methods, but also computationally efficient. In Ref. [6], the author investigated the performance of a technique for face recognition. This approach based on the computation of 25 local autocorrelation coefficients. It operated at a speed of one face per second and gave the good performance. In Ref. [7], the authors investigated the use of eigenface-like features computed on different portion of input image. They performed PCA to provide an adaptive basis for multiresolution and multiresolution provided localization to PCA. The feature extraction point of view was analyzed that projection to high dimensional spaces also enhances the chance of obtaining better feature. In Ref. [8], the authors considered an ensemble classifier working on frequency subbands similar to this work. Indeed, they first compared each individual subband. They considered the fusion of best performing subbands. It was shown that the fusion improve recognition accuracy compare to using a single subband. The studied papers of multiresolution have been demonstrated that information integrating from multiple sources is essential for reliably performing. Therefore, we also consider multiple classifier system, in which each classifier focuses on some particular resolutions, in order to improve the recognition accuracy.

The multiple classifier systems have been used in several pattern recognition works. They are powerful solutions to difficult pattern recognition problems involving large class sets and noisy input. Because, they allow simultaneous use of arbitrary feature descriptors and classification procedures. Decisions by the classifiers can be represented as rankings of classes so that they are comparable across different types of classifiers and different instances of a problem [9]. There are heterogeneous classifier ensembles and homogeneous classifier ensembles. The heterogeneous ensemble method integrates various pattern recognition algorithms as experts in a committee machine. In Ref. [10], the authors used the sum rule and RBF-based integration strategies to combine three face classifiers based on PCA, ICA, and LDA representations. This

approach could improve the performance of face identification system. However, each classifier is appropriate in different kind of database. Therefore, the dynamics face recognition committee was proposed in Ref. [11]. The authors formulated gating network to determine suitable weights for the experts. This face recognition system could combine the strong points of each representation and performed the better performance.

The homogeneous ensemble method relies on the same type of classifier in the system. It has been used in non-face and face recognition frameworks. In Ref. [12], the authors used multiresolution wavelet analysis and an ensemble of classifier for the early diagnosis of Alzheimer's disease. They performed on event related potential EEG signal which were used with the ensemble of classifiers based Learn++ algorithm. Parallel Consensus Neural Network (PCNN) in Ref. [13] is another homogeneous ensemble method that uses neural networks to satellite data classification. Indeed, each network is trained on different input full wavelet tree representations. Then, the decision is taken by class-specific weighted averages in the framework of consensus theory. However, the small size of face database makes it not suitable for applying this neural network based approach. In face recognition framework, multiresolution was applied to multiple classifier systems in the several previous works [5-8]. The experimental results of the previous works demonstrated that there was hidden information in many resolutions. They used the homogenous expert to classify and gave various decisions. Multiple classifier systems were the simple way to combine decisions and gave the better result.

In this paper, we consider face recognition from intensity images in multiresolution analysis and the homogeneous ensemble classifier. In this work, the input image is first decomposed into several frequency subbands. Four groups of frequency subbands are chosen due to their information coverage. For each group different kinds of fusion are considered. PCA is used in each group to reduce computational load while retaining meaningful features. We can further consider these 4 groups as independent classifiers in parallel classifiers system [14]. Thus new decision can be drawn from the majority vote of these 4 classifiers. Experimental results show that our proposed method outperform the classical approach of "PCA" and its recent extension of "2DPCA" [15] on the well known ORL face database.

II. BACKGROUND

A. Multiresolution Analysis

Multiresolution methods provide powerful signal analysis tools, which are widely used in feature extraction, image compression and denoising applications. Wavelet decomposition is the most widely used technique in image processing. Images have typically locally varying statistics that result from different combinations of abrupt features like edges, of textured regions and of relatively low-contrast homogeneous regions. While such variability and spatial nonstationarity defied any single statistical characterization,

the multiresolution components are more easily handled. Wavelet transform can be performed for every scale and translation, resulting in continuous wavelet transform (CWT), or only at multiples of scale and translation intervals, resulting in discrete wavelet transform (DWT). Since, CWT provides redundant information and requires a lot of computation, generally DWT is preferred.

B. Ensemble Method

Ensemble method is one of the major developments in machine learning in the past decade. It finds a highly accurate classifier by combining many moderately accurate component classifiers. Bagging, Boosting, and Random Subspace methods are the most successful techniques for constructing ensemble classifier [16, 17].

There have been many previous studies on how to create the ensemble of models. The methods for constructing the ensemble of models can be categorized into five groups [16] : 1) Bayesian voting, which creates an ensemble of model by sampling them from an estimated posterior model distribution; 2) Manipulating the training examples, which creates multiple subset of training examples and trains a classifier for each subset; 3) Manipulating input features, which creates a number of subsets of the input features and a classifier is built for each subset of input features; 4) Manipulating the output targets or error-correct output code (ECOC) [18], which converts a multiple class problem into a set of binary class problems; 5) Injecting randomness, that generates ensembles of classifiers by injecting randomness into the learning algorithm.

Among the five categories, our work is closely related to the third method, which creates multiple classifiers by manipulating input features. This method only works when the input features are highly redundant. And it is optimal for multiresolution input.

C. PCA and Eigenface for Face Recognition

PCA was also known as the Karhunen Loeve (KL) expansion in communication theory or Hotelling transform in image processing. It is a well-known approach for feature extraction. It is a method of identifying patterns of data, and expressing the data in a way to highlight their similarities and differences. The basic idea of PCA is to discard all redundancy existing in the original set of features thus allows representing the same object in a more compact way. Therefore the dimension of the image can be greatly reduced. In face recognition, the eigenface method is more generally called "PCA", which is used to find a low dimensional representation of face image data.

D. Fusion

There are 3 architectures of fusing frequency subbands [8], which are "data fusion", "feature fusion", and "decision fusion". We fuse raw pixel values of the frequency subbands in data fusion as shown in Fig. 1. The block diagram of feature fusion is shown in Fig. 2. We fuse feature vectors that extracted from the frequency subbands. For decision fusion, we fuse in classification decisions of the frequency subbands as showed in Fig. 3.




Figure 1. Block diagram of the data fusion scheme




Figure 2. Block diagram of the feature fusion scheme




Figure 3. Block diagram of the decision fusion scheme

III. PROPOSED METHOD

There are many fusion techniques in [8] as shown in previous section. The authors proposed only trend to select group of frequency subbands for fusing. In this paper, we propose new architecture for fusing frequency subbands. We use the conception of multiple classifier systems to decide the results of each fusion again.

The schematic of the wavelet decomposition, which used in this paper is shown in Fig. 4. There is approximation (A), horizontal detail (H), vertical detail (V), and diagonal detail (D) coefficients respectively. A 128 x 128 pixels original face image is decomposed in the first level, and four 64 x 64 pixels resolution frequency subband images A1, H1, V1 and D1 are obtained. In the second level, we decompose only A1, yielding four 32 x 32 frequency subband images A2, H2, V2 and D2. And in the third level, we decompose A2 component to produce four 16 x 16 frequency subband images. In summary, we obtain 12 different subband images from the original face image and input them into the multiple classification scheme in

Fig. 1-3. The octave decomposition is used in our proposed. We found that classification performance of individual H, V, and D were very low [3].

We define the group of frequency subbands in each level from octave DWT. The several frequency subbands are decomposed as Fig. 4. It consists of information from the different stage networks. Each stage has alike original input data with different time frequency resolutions. We divide the group of frequency subbands to 4 levels.

- 0 level : The 128 x 128 pixels of original image.
- 1 level : A1H1V1D1
- 2 level : H1V1D1A2H2V2D2
- 3 level : H1V1D1H2V2D2A3H3V3D3

Our proposed scheme in Fig. 5 is the fusion of fusion architecture. First, the original image is decomposed to be 3 level octave tree DWT. The frequency subbands are concatenated to 1-3 level groups of subbands. Then, we use similarly fusion scheme for fusing every level of frequency subbands. The fusion blocks in Figure 5 are three types of fusion, which are Fig. 1, Fig. 2, and Fig. 3. Finally, we combine all decision of fusion blocks together with decision fusion (majority vote). It gives the final decision. We choose Daubechies 4 wavelet for the experiments because it gave the optimum results [3, 4].

IV. EXPERIMENTAL RESULTS

We tested on ORL face database in Appendix B [19]. The database has 400 pictures, which made up from 10 pictures of 40 people. The images are 112 x 92 pixels, 8 bit gray scale images. The pictures show variation in background lighting, scale, orientation and facial expression. The tolerance in scale is about 20% and tolerance for tilting is about. All of face images are scaled to 128 x 128 pixels resolution. We use first 5 images for training and last 5 images for testing. In recognition stage, we conserve 90% of energy for reducing computation.




Figure 4. Wavelet decomposition tree in the study




Figure 5. Block diagram of the proposed fusion scheme

The nearest neighbor classifier is chosen for classification. We evaluated comparatively three different distances namely the $L1$, the $L2$ norm, and the normalized correlation coefficient (CC). The top 3 results of PCA on single wavelet transform subband are shown in Table 1. Our proposed method's recognition accuracy rates are shown in Table 2. For example, in 1-3 level (Data Fusion), the 1 level, 2 level, and 3 level are selected to be multiresolution input and data fusion is chosen in fusion block in Fig. 5. The subbands in each level are fused by data fusion separately. After that, three level display 3 individual decision result. The decision fusion is used to combine 3 decisions and give final decision. Almost fusing several subbands levels give better accuracy recognition rate than original and single subband. It shows that manipulating the input features of ensemble method and multiple classifier systems are appropriate to our proposed method. The 0-3 level fusing subbands which first fused by decision fusion gives the best result.

Our best architecture can improve recognition accuracy rate to the ORL database. We compared our proposed method's best result to the classic PCA approach's result and the new approach of PCA which is called "2DPCA" [15] result. The size of images tested for PCA and 2DPCA is 112 x 92 pixels. The result in Table 3 indicate that our proposed give the best result which better than PCA 15.5% and better than 2DPCA 2.5%.

V. CONCLUSIONS

In this paper, a framework of ensemble frequency subbands are proposed for face recognition to be one approach to select group of fusing frequency subbands. One of the advantages of adding redundant features is good for classification problem as long as the redundant information supplied to ensemble classifiers is not harmfully correlated. But it has to spend more computation time and more complexity than 2 compared methods. If there are high speed enough CPU and large enough memory machine in the future, our proposed method will be one option.

TABLE I
TOP 3 RESULTS OF PCA ON SINGLE WAVELET TRANSFORM SUBBAND AND D3

Wavelet Subband	L1	L2	CC
A1	85.5	78	84.5
A2	86.5	80.5	83.5
A3	86.5	78.5	87
D3	53.5	59.5	69

TABLE II
OUR PROPOSED METHOD'S RESULTS

Level Fusion	L1	L2	CC
0 level (original)	85.5	78.5	85
1-3 level (Data Fusion)	75	82	93
1-3 level (Feature Fusion)	81	83	88.5
1-3 level (Decision Fusion)	79	82	92.5
0-3 level (Data Fusion)	84	78.5	91.5
0-3 level (Feature Fusion)	84	81	89.5
0-3 level (Decision Fusion)	84.5	84	94

TABLE III
THE TOP RECOGNITION ACCURACY COMPARISONS OF PCA AND 2DPCA

Method	PCA	2DPCA	Proposed (Best)
Accuracy (%)	78.5	91.5	94

ACKNOWLEDGMENT

Thanks to Thailand Graduate Institute of Science and Technology (TGIST) and Cooperation Project between Department of Electrical Engineering and Private Sector for Research and Development, Chulalongkorn University, Thailand.

REFERENCES

- [1] W. Zhao, R. Chellappa, A. Rosenfeld, and J. Phillips, "Face Recognition A Literature Survey," *ACM Computing Surveys*, vol. 12, pp. 399-458, 2003.
- [2] M. A. Turk and A. P. Pentland, "Eigenfaces for Recognition," *Journal of Cognitive Neuroscience*, vol. 3, no. 1, pp. 71-86, March 1991.
- [3] G. C. Feng, P. C. Yuen, and D. Q. Dai, "Human Face Recognition Using PCA on Wavelet Subband," *SPIE Journal of Electronic Imaging*, vol. 9, no. 2, pp. 226-233, 2000.
- [4] J. T. Chien and C. C. Wu, "Discriminant Waveletfaces and Nearest Feature Classifiers for Face Recognition," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 24, no. 12, December 2002.
- [5] M. Pavlou and N. M. Allinson, "Unsupervised Multiresolution Face - Kernel Recognition Models," *Invited Talk Proc. Irish Machine Vision & Image Processing Conference 2005*, Belfast, Northern Ireland, August 2005.
- [6] F. Goudail, E. Lange, T. Iwamoto, K. Kyuma, and N. Otsu, "Face Recognition System Using Local Autocorrelations and Multiscale Integration," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 18, no. 10, October 1996.
- [7] V. T. Brennan, "Principal Component Analysis with Multiresolution," PhD thesis, University of Florida, May 2001.
- [8] H. K. Ekenel and B. Sankur, "Multiresolution Face Recognition," *Image and Vision Computing*, vol. 3, no. 5, pp. 469-477, 2005.
- [9] T. K. Ho, J. J. Hull, and S. N. Srihari, "Decision Combination in Multiple Classifier Systems," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 16, no. 1, January 1994.
- [10] A. K. Jain, X. Lu, and Y. Wang, "Combining Classifiers for Face Recognition," in *Proc. ICME 2003*, pp. 13-16, Baltimore, MD, July 2003.
- [11] T. Ho-Man, "Face Recognition Committee Machine: Methodology, Experiments and A System Application," Master thesis, Chinese University of Hong Kong, July 2003.
- [12] G. Jacques, J. L. Frymiare, J. Kounios, C. Clark, and R. Polikar, "Multiresolution Wavelet Analysis and Ensemble of Classifiers for Early Diagnosis of Alzheimer's Disease," *Proc. of 30th IEEE Int. Conf. on Acoustics, Speech and Signal Processing 2005*, vol. 5, pp. 389-392, Philadelphia, PA, March 2005.
- [13] J. A. Benediktsson, J. R. Sveinsson, O. K. Ersoy, and P. H. Swain, "Parallel Consensual Neural Networks," *IEEE Trans. Neural Networks*, vol. 8, no. 1, pp. 54-64, 1997.
- [14] N. M. Wanas, "Multiple Classifier System," Focus Group, PAMI Lab, December 2003.
- [15] P. Sanguansat, W. Asdornwised, S. Jitapunkul, and S. Marukatat, "Two-Dimensional Linear Discriminant Analysis of Principle Component Vectors for Face Recognition," *IEICE-Trans. on Inf. and Sys.*, vol. E89-D, no. 7, pp. 2164-2170, 2006.
- [16] T. G. Dietterich, "Learning Research: Four Current Direction," *AI Magazine*, pp. 97-136, winter 1997.
- [17] R. Polikar, "Ensemble Based Systems in Decision Making," *IEEE Circuit and Systems Magazine*, pp. 21-45, 2006.
- [18] T. G. Dietterich and G. Bakiri, "Solving Multiclass Learning Problems via Error-Correcting Output Codes," *Journal of Artificial Intelligence Research*, vol. 2, pp. 263-286, 1995.
- [19] <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

ประวัติผู้เขียนวิทยานิพนธ์

นางสาวปาริฉัตร เสริมวุฒิสาร เกิดวันที่ 24 กันยายน พ.ศ. 2525 ที่กรุงเทพมหานคร สำเร็จการศึกษาระดับปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ ในปีการศึกษา 2547 และเข้าศึกษาต่อในหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต ในสังกัดห้องปฏิบัติการวิจัยกรรมวิธีสัตตัญญาณดิ จิตต์ ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2548



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย