

การปรับปรุงอัลกอริทึมซอฟต์แวร์เมชชีนสำหรับการจำแนกข้อมูล
ภาพไบโอเมตริกซ์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2557

**THE IMPROVEMENT OF SUPPORT VECTOR
MACHINE ALGORITHM FOR BIOMETRIC
IMAGE IDENTIFICATION**

Ratiporn Chanklan



**A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Computer Engineering
Suranaree University of Technology
Academic Year 2014**

การปรับปรุงอัลกอริทึมซอฟต์แวร์แอมซันสำหรับการจำแนกข้อมูลภาพ
ไบโอเมตริกซ์

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์

(รศ. ดร.กิตติศักดิ์ เกิดประสพ)

ประธานกรรมการ

(รศ. ดร.นิตยา เกิดประสพ)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

(ผศ. ดร.ปรเมศวร์ ห่อแก้ว)

กรรมการ

(ศ. ดร.ชูกิจ ลิมปิจำนงค์)
รองอธิการบดีฝ่ายวิชาการและนวัตกรรม

(รศ. ร.อ. ดร.กนต์ธร ชำนิประศาสน์)
คณบดีสำนักวิชาวิศวกรรมศาสตร์

รติพร จันทร์กลิ่น : การปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนก
ข้อมูลภาพไบโอเมตริกซ์ (THE IMPROVEMENT OF SUPPORT VECTOR MACHINE
ALGORITHM FOR BIOMETRIC IMAGE IDENTIFICATION) อาจารย์ที่ปรึกษา :
รองศาสตราจารย์ ดร.นิตยา เกิดประสพ, 104 หน้า

งานวิจัยนี้ได้ศึกษาปัญหาการจำแนกข้อมูลไบโอเมตริกซ์ ซึ่งในการจำแนกข้อมูลไบโอเมตริกซ์นั้นนิยมใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแต่การรู้จำใช้เวลาาน จึงได้ใช้การลดมิติข้อมูลเข้ามาช่วยเพื่อลดเวลาการทำงาน การลดมิติข้อมูลเป็นขั้นตอนการเตรียมข้อมูลก่อนนำไปเข้าอัลกอริทึมที่ใช้ในการจำแนก ในอดีตได้มีหลายงานวิจัยที่ได้เสนอเทคนิคการจำแนกข้อมูลไบโอเมตริกซ์โดยใช้เทคนิคการลดมิติข้อมูลและส่วนใหญ่จะใช้กับข้อมูลภาพใบหน้า ซึ่งจะวัดประสิทธิภาพของโมเดลโดยการเปรียบเทียบค่าความแม่นยำเพียงอย่างเดียว การลดมิติข้อมูลที่สามารถใช้กับข้อมูลไบโอเมตริกซ์หลายชนิดและนำเวลาที่ใช้ในการจำแนกมาเปรียบเทียบจะมีความซับซ้อน จึงทำให้มีงานวิจัยด้านนี้ปรากฏค่อนข้างน้อย ผู้วิจัยได้เห็นความสำคัญในจุดนี้จึงได้เสนอการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลไบโอเมตริกซ์ที่เรียกว่า Bio-SVM เพื่อเพิ่มประสิทธิภาพและลดเวลาในการจำแนกข้อมูล โดยใช้เทคนิคการลดมิติข้อมูลได้แก่ การวิเคราะห์จำแนกประเภทเชิงเส้น (LDA) ร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลเส้นตรงสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์เชิงกายภาพ และใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลโพลิโนเมียลในการจำแนกข้อมูลภาพไบโอเมตริกซ์เชิงพฤติกรรม โดยใช้ภาษาไพธอนในการทดลอง งานวิจัยนี้ใช้ค่าความแม่นยำและเวลาที่ใช้ในการจำแนกข้อมูลมาใช้ในการประเมินประสิทธิภาพการจำแนกข้อมูลไบโอเมตริกซ์

สาขาวิชา วิศวกรรมคอมพิวเตอร์
ปีการศึกษา 2557

ลายมือชื่อนักศึกษา _____
ลายมือชื่ออาจารย์ที่ปรึกษา _____


RATIPORN CHANKLAN : THE IMPROVEMENT OF SUPPORT VECTOR
MACHINE ALGORITHM FOR BIOMETRIC IMAGE IDENTIFICATION.

THESIS ADVISOR : ASSOC. PROF. NITTAYA KERDPRASOP, Ph.D.,
104 PP.

DIMENSIONALITY REDUCTION/BIOMETRIC IDENTIFICATION/SUPPORT
VECTOR MACHINE

In this research, we study the problem of biometric data classification. The biometric data classification using support vector machine algorithm is widely used but the recognition takes long time. To decrease running time, dimensionality reduction is normally adopted. Dimensionality reduction is preprocessing step before importing data to the algorithm used in the classification step. In the past, many researchers have proposed techniques for the classification of biometric data using dimensionality reduction techniques and most of them are used with face image data. Model accuracy is the only performance measure metric. Dimensionality reduction can be applied to several kinds of biometric data and then compare the classification time. This scheme is however complex. As a result, research work of this kind rarely appear. We thus propose in this research the improvement of support vector machine algorithm for biometric identification called the Bio-SVM algorithm. The main objectives are to increase efficiency and reduce the time for data classification. We apply linear discriminant analysis (LDA) as a dimensionality reduction technique. Then, we use LDA with the algorithm support vector machine using linear kernel function for physiological biometric image identification and use support vector machine using polynomial function for behavioral biometric image identification. The

implementation and experimentation have been done with the Python language. This research uses accuracy and time as measurement to evaluate the performance of biometric data classification.



School of Computer Engineering

Academic Year 2014

Student's Signature _____

Advisor's Signature _____

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จได้ด้วยดี ผู้วิจัยขอขอบพระคุณ บุคคล และกลุ่มบุคคลต่างๆ ที่ได้กรุณาให้คำปรึกษา แนะนำ และช่วยเหลือ ทั้งในด้านวิชาการ และด้านการดำเนินงานวิจัยดังต่อไปนี้

รองศาสตราจารย์ ดร.กิตติศักดิ์ เกิดประสพ อาจารย์หัวหน้าสาขาวิชาวิศวกรรมคอมพิวเตอร์ และรองศาสตราจารย์ ดร.นิตยา เกิดประสพ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่คอยให้คำปรึกษาในการทำงานวิจัย ช่วยให้คำแนะนำ ตรวจสอบความถูกต้อง และการจัดการรูปแบบของวิทยานิพนธ์ฉบับนี้

คุณกัลญา พับ โปธิ์ เลขานุการสาขาวิชาวิศวกรรมคอมพิวเตอร์ ที่ให้ความช่วยเหลือในการประสานงานด้านเอกสารต่างๆระหว่างศึกษา

คุณเกตุกาญจน์ ไชยจันทร์ คุณอนุสรฯ หิรัญวนากุล คุณนันทวุฒิ คะอังกู และบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์ ทุกคนที่ให้คำแนะนำ ตรวจสอบความถูกต้องให้คำปรึกษาและให้ความช่วยเหลือมาโดยตลอด

นอกจากนี้ขอขอบคุณครู อาจารย์ทั้งในอดีตและปัจจุบันที่ให้ความรู้แก่ผู้วิจัยจนประสบความสำเร็จในชีวิต

และสุดท้าย ขอกราบขอบพระคุณ บิดา มารดา ที่ให้กำเนิด อบรม เลี้ยงดู ให้ความรัก และส่งเสริมการศึกษา ทำให้ผู้วิจัยมีความรู้ ความสามารถ มีจิตใจที่เข้มแข็ง และเป็นกำลังใจที่ให้แกผู้วิจัย จนทำให้ผู้วิจัยประสบความสำเร็จในชีวิตตลอดมา

รติพร จันทร์กลิ่น

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ง
สารบัญ.....	จ
สารบัญตาราง.....	ช
สารบัญรูป.....	ฉ
บทที่	
1 บทนำ.....	1
1.1 ความสำคัญและที่มาของปัญหาการวิจัย.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ข้อยกเว้นเบื้องต้น.....	2
1.4 ขอบเขตของการวิจัย.....	2
1.5 ประโยชน์ที่ได้รับ.....	3
2 ปรัชญาบรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 ไปโอเมตริกซ์.....	4
2.1.1 ความหมายและประเภทของไปโอเมตริกซ์.....	4
2.1.2 รูปแบบการใช้งานไปโอเมตริกซ์.....	6
2.1.3 ประโยชน์ของการเอาไปโอเมตริกซ์ไปใช้งาน.....	6
2.2 อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน.....	7
2.3 การวิเคราะห์จำแนกประเภทเชิงเส้น.....	9
2.4 มาตรฐานประสิทธิภาพของโมเดลจำแนกประเภทข้อมูล.....	11
2.5 ภาษาไพธอน.....	12
2.5.1 การประกาศตัวแปรในภาษาไพธอน.....	13
2.5.2 คำสั่งในการคำนวณและแสดงผล.....	13


สารบัญ (ต่อ)

	หน้า
2.5.3 ตัวอย่างโปรแกรมภาษาไพธอน.....	15
2.6 งานวิจัยที่เกี่ยวข้อง.....	17
3 วิธีดำเนินการวิจัย.....	21
3.1 กรอบแนวคิดของการวิจัย.....	21
3.2 การออกแบบอัลกอริทึม.....	22
3.2.1 ออกแบบอัลกอริทึมการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน สำหรับการจำแนกข้อมูลไบโอเมตริกซ์.....	22
3.2.2 ออกแบบการทดสอบประสิทธิภาพ โมเดลที่ใช้ทำนายข้อมูลภาพไบโอ เมตริกซ์.....	26
3.3 เครื่องมือที่ใช้ในการวิจัย.....	28
4 การทดสอบและอภิปรายผล.....	29
4.1 ข้อมูลที่ใช้ในการทดสอบ.....	29
4.1.1 ข้อมูลภาพลายนิ้วมือ.....	29
4.1.2 ข้อมูลภาพใบหน้า.....	29
4.1.3 ข้อมูลภาพลายมือชื่อ.....	30
4.2 การทดสอบประสิทธิภาพการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน สำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์.....	30
4.2.1 ผลของวิธีการใช้ SVM.....	32
4.2.2 ผลของวิธีการใช้ Bio-SVM กับข้อมูลไบโอเมตริกซ์เชิงกายภาพ.....	33
4.2.3 ผลของวิธีการใช้ Bio-SVM กับข้อมูลไบโอเมตริกซ์เชิงพฤติกรรม.....	36
4.3 เปรียบเทียบผลการทดลองการจำแนกข้อมูลภาพไบโอเมตริกซ์ด้วย อัลกอริทึมต่าง ๆ.....	36
4.4 อภิปรายผล.....	38
5 สรุปผลการวิจัยและข้อเสนอแนะ.....	40
5.1 ขั้นตอนการดำเนินงานวิจัย.....	40
5.2 สรุปผลการวิจัย.....	41

สารบัญ (ต่อ)

หน้า

5.3 ปัญหาและข้อเสนอแนะ.....	42
รายการอ้างอิง.....	43
ภาคผนวก	
ภาคผนวก ก. การใช้งานโปรแกรม.....	45
ภาคผนวก ข. รหัสต้นฉบับโปรแกรม.....	50
ภาคผนวก ค. บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา.....	56
ประวัติผู้เขียน.....	104



สารบัญตาราง


ตารางที่	หน้า
2.1 ตารางแสดงการแบ่งประเภทของระบบไบโอเมตริกซ์ตามคุณลักษณะเฉพาะ.....	5
2.2 ตารางแสดงการการประกาศตัวแปรของภาษาไพธอน	13
2.3 แสดงสัญลักษณ์ทางคณิตศาสตร์ที่ใช้ในการคำนวณในภาษาไพธอน	14
2.4 แสดงการแสดงความออกทางจอภาพ	14
2.5 แสดงสัญลักษณ์ที่ใช้ควบคุมการแสดงผล	15
2.6 สรุปเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการจำแนกข้อมูลไบโอเมตริกซ์.....	19
4.1 แสดงค่าความแม่นยำและเวลาที่ใช้ในการจำแนกข้อมูลไบโอเมตริกซ์แต่ละประเภท ด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน	32
4.2 แสดงผลการทดสอบข้อมูลภาพลายนิ้วมือด้วย LDA+SVM	34
4.3 แสดงผลการทดสอบข้อมูลภาพใบหน้าด้วย LDA+SVM	35
4.4 แสดงการสรุปผลการทดสอบด้วย SVM-linear, SVM-poly, Bio-SVM กับข้อมูล ไบโอเมตริกซ์เชิงกายภาพและเชิงพฤติกรรม	36

สารบัญรูป

รูปที่	หน้า
2.1	แสดงภาพตัวอย่างไปโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางกายภาพ.....5
2.2	แสดงภาพตัวอย่างไปโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางพฤติกรรม.....5
2.3	ตัวอย่างระนาบการตัดสินใจแบ่งกลุ่มข้อมูลของซัพพอร์ตเวกเตอร์แมชชีน.....8
2.4	ตัวอย่างการจำแนกข้อมูลของซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลเส้นตรง.....9
2.5	ตัวอย่างการจำแนกข้อมูลของซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลโพลิโนเมียล.....9
2.6	ตัวอย่างของคลาสที่ถูกจัดกลุ่มโดยใช้ LDA.....11
2.7	ตาราง Confusion Matrix.....12
2.8	แสดงตัวอย่างคำสั่งการแสดงผลตัวข้อความ.....15
2.9	แสดงตัวอย่างคำสั่งการคำนวณและค่าตัวแปร.....16
2.10	แสดงตัวอย่างคำสั่งการเชื่อมข้อความ.....16
3.1	กรอบแนวคิด Bio-SVM.....21
3.2	ผังงานแสดงขั้นตอน Bio-SVM.....23
3.3	แสดงตัวอย่างภาพใบหน้า.....24
3.4	แสดงตัวอย่างภาพลายนิ้วมือ.....24
3.5	แสดงตัวอย่างภาพลายมือชื่อ.....25
3.6	ตัวอย่างการทดสอบประสิทธิภาพโมเดลที่ใช้ทำนายข้อมูลภาพไปโอเมตริกซ์.....27
4.1	ตัวอย่างข้อมูลภาพสแกนลายนิ้วมือ.....29
4.2	ตัวอย่างข้อมูลภาพใบหน้า.....30
4.3	ตัวอย่างข้อมูลภาพภาพลายมือชื่อ.....30
4.4	แสดงแผนภาพวิธีการทดสอบประสิทธิภาพโมเดลสำหรับการจำแนกข้อมูลภาพไปโอเมตริกซ์.....31
4.5	กราฟแสดงการเปรียบเทียบค่าความแม่นยำจากวิธีการจำแนกภาพไปโอเมตริกซ์ด้วยอัลกอริทึมต่าง ๆ.....37

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.6 กราฟแสดงการเปรียบเทียบเวลาที่ใช้ในการประมวลผลจากวิธีการจำแนกภาพ ไบโอเมตริกซ์ด้วยอัลกอริทึมต่าง ๆ.....	37
ก.1 แสดงตัวอย่างการดึงค่าสีของภาพ.....	46
ก.2 แสดงตัวอย่างข้อมูลไฟล์ .csv.....	47
ก.3 แสดงตัวอย่างการใส่ข้อมูลคลาสที่คอลัมน์แรก.....	47
ก.4 แสดงตัวอย่างโปรแกรมในส่วนโค้ด.....	48
ก.5 แสดงตัวอย่างโปรแกรมในส่วนผลการรันโปรแกรม.....	49
ก.6 แสดงตัวอย่างผลการรันโปรแกรม.....	49



บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของปัญหาการวิจัย

ในปัจจุบันการที่จะระบุตัวบุคคล เพื่อการเข้าใช้ระบบคอมพิวเตอร์หรือการผ่านเข้าสถานที่ สามารถทำได้ง่ายโดยที่ไม่จำเป็นต้องใช้เอกสารหรือจํารหัส แต่จะนำเทคโนโลยี คอมพิวเตอร์และการรู้จํามาใช้สำหรับการตรวจสอบความถูกต้องของตัวบุคคล โดยใช้ข้อมูลทาง ชีวภาพ ไม่ว่าจะเป็นลักษณะเฉพาะทางกายภาพหรือพฤติกรรม มาใช้ในการตรวจสิทธิหรือแสดงตน เรียกข้อมูลทางชีวภาพที่เป็นลักษณะเฉพาะว่า ไบโอมेटริกซ์ (Biometrics) ตัวอย่างเช่น ลายนิ้วมือ ใบหน้า ม่านตา ลายมือเขียน ลายเส้น เป็นต้น แล้วนำสิ่งเหล่านั้นมาเปรียบเทียบกับคุณลักษณะที่ได้ มีการบันทึกไว้ในฐานข้อมูลก่อนหน้านี้ เพื่อแยกแยะและจําแนกความแตกต่างของแต่ละบุคคลนั้น ออกจากกัน หรือจําตัวแต่ละบุคคล

ไบโอมेटริกซ์สามารถนำไปใช้ควบคุมการเข้าออกสถานที่หรือเขตหวงห้าม เช่น การ ตรวจสอบการผ่านเข้าออกโดยใช้ลายนิ้วมือ รูปหน้า ลักษณะของเรตินาภายในดวงตา หรืออาจ นำไปใช้ตรวจสอบเวลาทำงานของพนักงาน ซึ่งการนำเอาไบโอมेटริกซ์มาใช้เป็นทางเลือกที่มี ประสิทธิภาพเนื่องจากเป็นข้อมูลที่ยากต่อการปลอมแปลง และสะดวกในการใช้งาน เพราะไม่มี ปัญหาเรื่องการลืม หรือการหายของเอกสารหรือข้อมูลต่างๆ

ในงานวิจัยนี้ได้นำข้อมูลภาพดิจิทัลที่เป็นภาพคุณลักษณะหรือภาพพฤติกรรมบางอย่างของ มนุษย์ ซึ่งเป็นคุณลักษณะที่เป็นเอกลักษณ์ สามารถใช้ในการระบุตัวบุคคลนั้นๆ แต่ภาพดิจิทัลใน ปัจจุบันมีความละเอียดค่อนข้างสูงหากนำไปประมวลผลเพื่อจําแนกด้วยคอมพิวเตอร์จะทำให้ การประมวลผลอาจจะใช้เวลานาน อีกทั้งยังต้องการใช้หน่วยความจําสำหรับการประมวลผลที่สูง จึงได้นำเทคนิคการลดมิติของข้อมูลเข้ามาช่วยในการลดการใช้ทรัพยากร และอาจเพิ่ม ประสิทธิภาพในการจําแนกข้อมูล เทคนิคการลดมิติของข้อมูลเป็นกระบวนการหนึ่งในขั้นตอน การเตรียมข้อมูล เป็นการทำให้ข้อมูลตั้งต้นมีขนาดลดลงโดยสูญเสียลักษณะสำคัญของข้อมูลน้อย ที่สุด เนื่องจากข้อมูลแต่ละตัวจะมีความสำคัญต่อการจัดกลุ่มข้อมูลและการจําแนกประเภทข้อมูล ไม่ เท่ากัน ด้วยเทคนิคการเลือกข้อมูลที่ดียิ่งจะทำให้สามารถเลือกข้อมูลที่มีความสำคัญและสามารถใช้ เป็นตัวแทนของข้อมูลส่วนใหญ่ สามารถลดเวลาที่ใช้ในการเรียนรู้ข้อมูล และลดความต้องการของ หน่วยความจําในการประมวลผลได้

จากปัญหาดังกล่าวผู้วิจัยจึงมีแนวคิด ที่จะปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน สำหรับการจำแนกข้อมูลใบโอเมตริกซ์ และเปรียบเทียบประสิทธิภาพโมเดลที่ได้จากการปรับปรุง เพื่อจะเพิ่มความสามารถการจำแนกข้อมูลให้แม่นยำมากขึ้นและลดเวลาในการประมวลผล

1.2 วัตถุประสงค์ของการวิจัย

จากแนวคิดในการทำงานผู้วิจัยได้ตั้งวัตถุประสงค์ในการวิจัยไว้ดังนี้

- 1) เพื่อเสนอแนวทางการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) สำหรับการจำแนกข้อมูลใบโอเมตริกซ์ได้หลายชนิด
- 2) เพื่อศึกษาหาแนวทางการเพิ่มประสิทธิภาพโมเดลที่ได้จากการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

1.3 ข้อตกลงเบื้องต้น

1) ข้อมูลที่ใช้ในการทดสอบประสิทธิภาพของการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเป็นข้อมูลจริงที่สามารถสืบค้นได้จากแหล่งต่าง ๆ ดังนี้

- ภาพใบหน้า (<http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>)
- ภาพลายนิ้วมือ (<http://fvs.sourceforge.net/download.html>)
- ภาพลายมือชื่อ (<https://sites.google.com/site/nhinganusaracpesut/signature/datasets>)

2) งานวิจัยนี้เลือกใช้ภาษาไพธอน ในการพัฒนาโปรแกรม

1.4 ขอบเขตของการวิจัย


จากการศึกษาค้นคว้าข้อมูล ผู้วิจัยได้กำหนดขอบเขตของการวิจัยไว้ดังนี้

- 1) เทคนิคลดมิติของข้อมูลใช้วิธีการวิเคราะห์จำแนกประเภทเชิงเส้น (Linear Discriminant Analysis : LDA)
- 2) การเรียนรู้เพื่อจำแนกประเภทข้อมูลใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน โดยเลือกใช้ 2 เคอร์เนล คือ เส้นตรง (Linear Kernel) และ โพลีโนเมียล (Polynomial Kernel)
- 3) การเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลภาพใบโอเมตริกซ์จะเปรียบเทียบค่าความแม่นยำ และเวลาที่ใช้ในการจำแนกข้อมูลของโมเดลที่ได้เสนอในการวิจัย
- 4) งานวิจัยนี้ใช้โปรแกรมภาษาไพธอน ในส่วนของการแปลงไฟล์ภาพเป็นข้อมูลตัวเลข การประมวลผล และการทดสอบประสิทธิภาพ

1.5 ประโยชน์ที่ได้รับ

ประโยชน์ที่เกิดขึ้นจากงานวิจัยนี้ ประกอบด้วย

- 1) การปรับปรุงอัลกอริทึมซอฟต์แวร์เครื่องแมชชีนสามารถจำแนกข้อมูลภาพใบโอเมตริกซ์ได้อย่างถูกต้อง
- 2) การปรับปรุงอัลกอริทึมซอฟต์แวร์เครื่องแมชชีนสำหรับการจำแนกข้อมูลภาพใบโอเมตริกซ์สามารถเพิ่มประสิทธิภาพการจำแนกข้อมูลและลดเวลาในการประมวลผล



บทที่ 2

ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง โดยมีรายละเอียดของไบโอเมตริกซ์ อัลกอริทึมซอฟต์แวร์แมชชีน การวิเคราะห์องค์ประกอบหลัก การวิเคราะห์จำแนกประเภทเชิงเส้น การประเมินประสิทธิภาพ ภาษาไพธอน และงานวิจัยที่เกี่ยวข้อง

2.1 ไบโอเมตริกซ์

2.1.1 ความหมายและประเภทของไบโอเมตริกซ์

ไบโอเมตริกซ์ ประกอบขึ้นจากคำว่า ไบโอ (Bio) ซึ่งหมายถึงสิ่งมีชีวิต และคำว่า เมตริกซ์ (Metrics) ซึ่งหมายถึงคุณลักษณะที่สามารถถูกวัดค่า หรือประเมินจำนวนได้ (Delac and Grgic, 2004) เมื่อรวมสองคำนี้มาตีความรวมกัน ไบโอเมตริกซ์จึงหมายถึงการผสมผสานเทคโนโลยีทางด้านชีวภาพ และทางการแพทย์ กับเทคโนโลยีทางคอมพิวเตอร์เข้าด้วยกัน โดยใช้วิธีการสกัดและแยกแยะเอกลักษณ์เฉพาะ ที่มีความแตกต่างและไม่ซ้ำกันอย่างสิ้นเชิงของมนุษย์เป็นดัชนีชี้วัด แล้วนำสิ่งเหล่านั้นมาเปรียบเทียบกับคุณลักษณะที่ได้มีการบันทึกไว้ในฐานข้อมูลก่อนหน้านี้ เพื่อใช้พิสูจน์ และยืนยันตัวตนของบุคคลผู้เป็นเจ้าของคุณลักษณะทางชีวภาพเหล่านั้น ได้อย่างถูกต้องแม่นยำ เชื่อถือได้ ไบโอเมตริกซ์สามารถแบ่งออกเป็น 2 ประเภทใหญ่ คือ การใช้ลักษณะทางกายภาพหรือทางสรีระ (Physiological Biometrics) และ การใช้ลักษณะทางพฤติกรรม (Behavioral Biometrics) ซึ่งจำแนกประเภทได้ดังตารางที่ 2.1 ข้อมูลในตารางแสดงการแบ่งประเภทของระบบไบโอเมตริกซ์ตามคุณลักษณะเฉพาะ และแสดงตัวอย่างภาพประเภทของไบโอเมตริกซ์ได้ดังรูปที่ 2.1 และ 2.2

ตารางที่ 2.1 ตารางแสดงการแบ่งประเภทของระบบไบโอเมตริกซ์ตามคุณลักษณะเฉพาะ

ลักษณะทางกายภาพ	ลักษณะทางพฤติกรรม
ลายนิ้วมือ (Fingerprint)	จังหวะการพิมพ์ (Keystroke Dynamics)
ใบหน้า (Face)	ลักษณะการเดิน (Gait)
ลักษณะของมือ (Hand Geometry)	เสียง (Voice)
ลักษณะของนิ้วมือ (Finger Geometry)	การเซ็นชื่อ (Signature)
ลักษณะใบหู (Ear Shape)	
ม่านตา (Iris)	
จอประสาทตา (Retina)	




(ก) ใบหน้า

(ข) ลายนิ้วมือ

(ค) ลักษณะมือ

(ง) ลักษณะใบหู

รูปที่ 2.1 แสดงภาพตัวอย่างไบโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางกายภาพ



(ก) การเซ็นชื่อ

(ข) จังหวะการพิมพ์

(ค) ลักษณะการเดิน

(ง) เสียง

รูปที่ 2.2 แสดงภาพตัวอย่างไบโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางพฤติกรรม

2.1.2 รูปแบบการใช้งานไบโอเมตริกซ์

รูปแบบการใช้งานไบโอเมตริกซ์จำแนกตามวัตถุประสงค์ของการใช้งานได้ทั้งหมด 2 ลักษณะดังนี้

1) การระบุตัวผู้ใช้ (Identification) เป็นการจับคู่เปรียบเทียบลักษณะแบบหนึ่งต่อจำนวนทั้งหมด (1:N) ผู้ใช้จะต้องส่งข้อมูลทางไบโอเมตริกซ์ของตนเองให้กับระบบก่อนเรียกว่า ขั้นตอนการลงทะเบียน หลังจากนั้นในขั้นตอนการตรวจสอบระบบจะทำการจับคู่ข้อมูลที่รับมา กับข้อมูลในฐานข้อมูลเพื่อระบุว่าผู้ที่ส่งข้อมูลคือใคร กระบวนการนี้ค่อนข้างใช้เวลานานเพราะระบบจะต้องมีการเปรียบเทียบข้อมูลเป็นจำนวนมาก เช่น การค้นหาใบหน้าของผู้ใช้ถ้ามีรูปแบบใด ในฐานข้อมูลตรงกับใบหน้าของผู้ใช้การอนุญาตให้ใช้ระบบก็จะเกิดขึ้น

2) การตรวจพิสูจน์ (Verification) เป็นการจับคู่เปรียบเทียบลักษณะเฉพาะแบบหนึ่งต่อหนึ่ง (1:1) ผู้ใช้จะต้องป้อนรหัสประจำตัว หรือ PIN (Personal Identification Number) ที่ระบุถึงตัวผู้ใช้เองก่อน เพื่อเป็นการระบุข้อมูลทางไบโอเมตริกซ์ของตนเองให้กับระบบ หลังจากนั้นระบบจะตรวจดูว่าข้อมูลที่ได้รับมาตรงกับข้อมูลที่ได้อีกบันทึกไว้ก่อนหน้านี้หรือไม่ กระบวนการนี้ใช้เวลาไม่มาก เพราะข้อมูลที่ต้องเปรียบเทียบมีไม่มาก เช่น การใช้ลายนิ้วมือเพื่อยืนยันความเป็นเจ้าของโทรศัพท์เคลื่อนที่

2.1.3 ประโยชน์ของการนำไบโอเมตริกซ์ไปใช้งาน

การยืนยันตัวบุคคลด้วยไบโอเมตริกซ์ มีข้อดีกว่าการใช้บัตรผ่านหรืออุปกรณ์ประเภทอื่น ๆ ดังต่อไปนี้

- 1) ทำให้ผู้ใช้ไม่จำเป็นต้องพกเอกสาร จึงสะดวกรวดเร็ว
- 2) ยากในการปลอมแปลงและการลักลอบนำไปใช้งาน
- 3) ช่วยลดค่าใช้จ่าย เช่น พนักงานไม่สามารถลงเวลาแทนกันได้
- 4) ผู้ใช้ไม่สามารถปฏิเสธความรับผิดชอบได้ เช่น ในการใช้รหัสผ่าน หรือบัตรผ่าน เจ้าของบัตรอาจอ้างได้ว่ารหัสผ่านหรือบัตรถูกผู้อื่นนำไปใช้ แต่ถ้าใช้การตรวจสอบหรือระบุตัวบุคคลด้วยไบโอเมตริกซ์ ทำให้ผู้ใช้ไม่สามารถปฏิเสธความรับผิดชอบได้

ข้อด้อยของระบบไบโอเมตริกซ์ที่ใช้งานอยู่ในปัจจุบัน คือ ความแม่นยำในการรู้จำเพื่อจำแนกข้อมูลตัวบุคคลยังไม่ถึง 100% จึงยังต้องการการวิจัยพัฒนาเพื่อเพิ่มประสิทธิภาพด้านความแม่นยำของระบบไบโอเมตริกซ์

2.2 อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

ซัพพอร์ตเวกเตอร์แมชชีน หรือ SVM เป็นอัลกอริทึมในการคัดแยกกลุ่มเพื่อจัดประเภทหรือจำแนกประเภทข้อมูลที่มีการนำมาใช้ในด้านการศึกษาผลภาพ เป็นวิธีการจำแนกกลุ่มข้อมูลที่อาศัยระนาบการตัดสินใจที่เรียกว่า ระนาบเกิน หรือไฮเปอร์เพลน (Hyperplane) มาใช้ในการจำแนกกลุ่มข้อมูล โดยใช้สมการเส้นตรงในการแบ่งข้อมูลออกเป็น 2 กลุ่มแยกออกจากกัน (Ali et al., 2011) ซัพพอร์ตเวกเตอร์ แมชชีนมีรูปแบบในการเรียนรู้เป็นกระบวนการเลือกแบบจำลองที่เหมาะสมที่สุด จะทำให้ได้ค่าที่เหมาะสมที่สุดเป็นคำตอบ ดังนั้นซัพพอร์ตเวกเตอร์แมชชีนจึงเป็นที่นิยมและเริ่มนำไปใช้งานด้านความรู้จำรูปแบบซึ่งจะเลือกใช้ซัพพอร์ตเวกเตอร์แมชชีนแบบแบ่งกลุ่ม

ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการแบ่งกลุ่มข้อมูลนั้นจะใช้ระนาบเกินที่เหมาะสมที่สุด (Optimal Hyperplane) ในการแบ่งกลุ่ม ในการสร้างระนาบเกินที่ใช้ในการแบ่งกลุ่มข้อมูลสามารถสร้างได้หลายแบบ แต่จะมีระนาบเกินที่เหมาะสมที่สุดเพียงระนาบเดียวเท่านั้น ที่สามารถรักษาระยะห่างมากที่สุดระหว่างข้อมูล 2 กลุ่มที่ใกล้กันมากที่สุดได้

กำหนดให้ $(x_i, y_i), \dots, (x_n, y_n)$ เมื่อ $x \in R^m, y \in \{-1, 1\}$ เป็นตัวอย่างที่ใช้สำหรับการสอน โดย

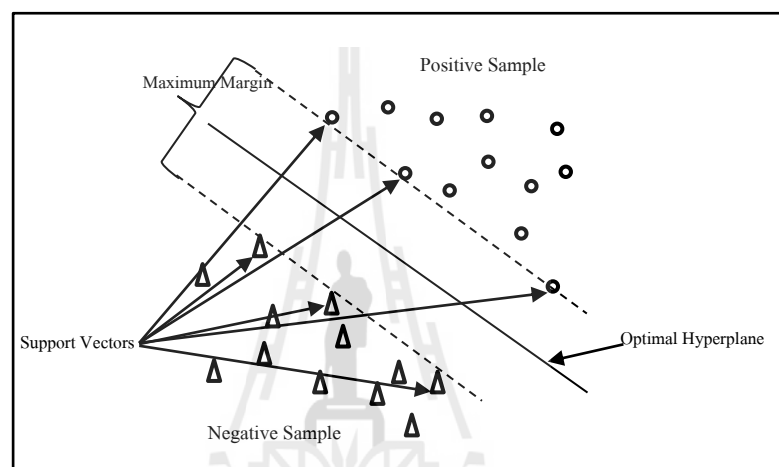
- n คือ จำนวนข้อมูลตัวอย่าง
- m คือ จำนวนมิติของข้อมูลเข้า
- x คือ ข้อมูลนำเข้า
- y คือ ประเภทหรือกลุ่มของข้อมูล ซึ่งประกอบด้วย 2 กลุ่ม มีค่า +1 หรือ -1
(+1 = “ข้อมูลบวก”, -1 = “ข้อมูลลบ”)

สำหรับปัญหาเชิงเส้น ข้อมูลมิติขนาดสูงได้ถูกแบ่งเป็น 2 กลุ่ม โดยใช้ระนาบตัดสินใจพิจารณาชุดของกลุ่มข้อมูล x โดยที่กำหนดให้กลุ่มข้อมูล x_1 เป็นข้อมูล x_i ที่มีค่าเป็นบวก และ x_2 เป็นข้อมูล x_i ที่มีค่าเป็นลบ การสร้างระนาบตัดสินใจเพื่อแบ่งแยกกลุ่มข้อมูลสามารถคำนวณได้ดังสมการที่ 2.1

$$(w * x_1) + b > 0 \text{ ถ้า } y_i = +1 \text{ และ } (w * x_2) + b < 0 \text{ ถ้า } y_i = -1 \quad (2.1)$$


- w คือ เวกเตอร์น้ำหนัก
- x_1 คือ เวกเตอร์ข้อมูลที่มีค่าเป็นบวก
- x_2 คือ เวกเตอร์ข้อมูลที่มีค่าเป็นลบ
- b คือ ค่า bias

ในการหาระนาบเกินที่เหมาะสมที่สุด จะทำการหาตำแหน่งของซัพพอร์ตเวกเตอร์ (Support Vector) เพื่อใช้เป็นตัวแทนของกลุ่มข้อมูลทั้งหมด ในการพิจารณาเกณฑ์แบ่งกลุ่มโดยอาศัยหลักการ คือ จะใช้ระยะนาบเกินที่เป็นระยะห่างที่สุดระหว่างข้อมูล 2 กลุ่ม ที่อยู่ใกล้กันมากที่สุดเพียงระยะนาบเดียวเท่านั้น ในทางทฤษฎีจะต้องไม่มีข้อมูลเกินเข้ามาในระหว่างขอบระยะนาบทั้งสอง จากนั้นจึงหาระนาบที่รักษาระยะห่างจากขอบมากที่สุด (Maximum Margin) และถือว่าระยะนาบดังกล่าวคือระยะนาบสำหรับการแบ่งกลุ่มที่เหมาะสมที่สุดแสดงดังรูปที่ 2.3




รูปที่ 2.3 ตัวอย่างระยะนาบการตัดสินใจแบ่งกลุ่มข้อมูลของซัพพอร์ตเวกเตอร์แมชชีน

จากที่กล่าวข้างต้นเป็นการแบ่งกลุ่มข้อมูลด้วยระยะนาบการตัดสินใจแบบเชิงเส้นเท่านั้น โดย SVM มีเคอร์เนลฟังก์ชัน (Kernel Function) แบบอื่นให้ผู้ใช้สามารถประยุกต์ใช้ในการแก้ปัญหาได้หลายวิธี (พรพล ธรรมรงค์รัตน์, 2551) ดังนั้นเพื่อให้อัลกอริทึมดังกล่าวสามารถแบ่งแยกกลุ่มข้อมูลที่มีลักษณะไม่เป็นเชิงเส้น (Nonlinear Dataset) จะต้องแปลงกลุ่มข้อมูลตัวอย่างไปสู่มิติที่สูงขึ้น (Higher Dimensional Space) ซึ่งถูกเรียกว่า Feature Space โดยการแปลงดังกล่าวจะกระทำผ่านฟังก์ชันที่ไม่เป็นเชิงเส้นและสร้างฟังก์ชันวัดระยะห่างที่เรียกว่าเคอร์เนลฟังก์ชัน (Kernel Function) บน Feature Space ซึ่งเหมาะสมสำหรับข้อมูลที่มีมิติข้อมูลสูง โดยมีวัตถุประสงค์ที่จะพยายามจะทำการลดความผิดพลาดในการทำนายกลุ่มข้อมูล (Minimize Error) พร้อมกับเพิ่มระยะแยกแยะโดยพยายามสร้างเส้นแบ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตทั้งสองกลุ่มมากที่สุด (Maximized Margin) ใช้สำหรับข้อมูลที่มีลักษณะมิติของข้อมูลที่สูงมาก โดยงานวิจัยของวิทยานิพนธ์นี้ได้ใช้ 2 เคอร์เนล คือ เส้นตรง และโพลิโนเมียล ในการทดลองกับข้อมูลไบโอเมตริกซ์



รูปที่ 2.4 ตัวอย่างการจำแนกข้อมูลของซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลเส้นตรง



รูปที่ 2.5 ตัวอย่างการจำแนกข้อมูลของซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลโพลิโนเมียล

2.3 การวิเคราะห์จำแนกประเภทเชิงเส้น

การวิเคราะห์จำแนกประเภทเชิงเส้น (Linear Discriminant Analysis : LDA) เป็นเทคนิคที่ใช้กันทั่วไปสำหรับการลดมิติและจัดหมวดหมู่ข้อมูล โดยจะพิจารณารักษาจำนวนกลุ่มของข้อมูลให้มากที่สุดแต่ก็จะพยายามหาทิศทางตามกลุ่มข้อมูลเพื่อให้ถูกแยกออกให้ดีที่สุด (Juwei Lu et al., 2003) วิธีการ LDA จะคำนึงถึงการกระจายของข้อมูลภายในกลุ่มและการกระจายระหว่างกลุ่ม นอกจากนี้ยังสามารถจำแนกภาพที่แตกต่างกันอันเนื่องมาจากปัจจัยอื่น ๆ เช่น ไฟส่องสว่างและลักษณะการถ่ายภาพ (Balakrishnama and Ganapathiraju, 1998)

ผลลัพธ์ของการวิเคราะห์ LDA เป็นฟังก์ชันเพื่อฉาย (Project) ลงบนปริภูมิย่อยหรือ Subspace ในลักษณะที่ ข้อมูลที่มาจาก Class ต่างกันจะอยู่แยกจากกัน และข้อมูลใน Class เดียวกันจะเกาะกลุ่มกันเพื่อให้สามารถจำแนกประเภทได้ง่าย (Tang and Tao, 2006) LDA เป็นเทคนิคที่ใช้

สำหรับการเรียนรู้แบบมีผู้สอน โดยใช้เทคนิคการหากลุ่มของปริมาณ (Base Vector) โดยมีชุดข้อมูล D ที่ประกอบด้วยข้อมูล n ตัว ข้อมูลแต่ละตัวประกอบด้วย $\{x_i, y_i\}$ ซึ่ง $x_i \in R^L$, $y_i \in \{c_1, c_2, \dots, c_k\}$ โดย c คือชื่อคลาสของข้อมูล, λ คือค่าไอเกน ซึ่งหาได้จาก $\det(B - \lambda S) = 0$ และ w เป็นเวกเตอร์ฉายของกลุ่มตัวอย่าง ให้ L เป็นมิติของชุดข้อมูล สามารถแสดงสมการ w ได้ดังนี้

$$Bw = \lambda Sw$$

$$(S^{-1}B)w = \lambda w \quad (2.2)$$

เมื่อ B คือ เมตริกซ์การกระจายระหว่างคลาส (Between-Class Scatter matrix) สามารถคำนวณหาได้จากสมการ (2.3)

$$B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \quad (2.3)$$

โดย μ_1 คือ ค่าเฉลี่ยข้อมูลของคลาสที่ 1

μ_2 คือ ค่าเฉลี่ยข้อมูลของคลาสที่ 2

ซึ่งค่าเฉลี่ยของข้อมูลสามารถคำนวณได้จากสมการที่ 2.4 โดยที่ n_c จำนวนข้อมูลคลาส c ทั้งหมด, x_i ข้อมูลของคลาส c ตัวที่ i และ D_c ชุดข้อมูลของคลาส c

$$\mu_c = \frac{1}{n_c} \sum_{x_i \in D_c} x_i \quad (2.4)$$

เราสามารถคำนวณหา S_c คือ เมตริกซ์การกระจายภายในคลาส (Within-Class Scatter Matrix) ได้จากสมการ 2.5 และ S_c เป็นเมตริกซ์ไม่เอกฐาน (Non-singular Matrix) คือสามารถหาค่าอินเวอร์สของเมตริกซ์ได้ (S_c^{-1})

$$S_c = \sum_{x_i \in D_c} (x_i - \mu_1)(x_i - \mu_1)^T \quad (2.5)$$

แต่ถ้าข้อมูลมี 2 คลาสจะสามารถคำนวณเวกเตอร์ฉายของกลุ่มตัวอย่าง (w) ได้โดยตรงจากสมการ (2.6) หลังจากคำนวณหาค่า w จากสมการ 2.6 แล้วจะต้องหาค่าเวกเตอร์หนึ่งหน่วยของ w ซึ่งจะได้เวกเตอร์ฉายของกลุ่มตัวอย่างของสองคลาสนั้น

$$w = S_c^{-1}(\mu_1 - \mu_2) \quad (2.6)$$



รูปที่ 2.6 ตัวอย่างของคลาสที่ถูกจัดกลุ่มโดยใช้ LDA (Juwei Lu et al., 2003)

LDA มีวิธีการทำงานที่คล้ายกับ PCA แต่มีวัตถุประสงค์ต่างกันเล็กน้อยใน PCA ต้องหาปริภูมิย่อยที่เมื่อฉาย (Project) ข้อมูลลงไปแล้ว ข้อมูลมีการกระจายตัวสูงสุด แต่ใน LDA ต้องการหาปริภูมิย่อยที่เมื่อฉายข้อมูลลงไปแล้ว ข้อมูลจาก class เดียวกันเข้าใกล้กันมากขึ้น และข้อมูลจากต่าง class กันจะอยู่ห่างกันมากขึ้นดังในรูปที่ 2.6 แต่ละบล็อกแสดงภาพบุคคลที่มีความแตกต่างกันน้อยจะถูกจัดให้อยู่ในคลาสเดียวกัน ส่วนภาพที่มีความแตกต่างกันมากจะจัดให้อยู่คนละบล็อกหรืออยู่ต่างคลาสนั้น

2.4 มาตรการวัดประสิทธิภาพของโมเดลจำแนกประเภทข้อมูล

ในการวัดประสิทธิภาพของโมเดลจำแนกประเภทข้อมูลนั้น จะใช้ Confusion Matrix ในการเก็บบันทึกผลการจำแนกประเภทข้อมูล โมเดล (Predicted Labels) เปรียบเทียบกับประเภทที่ถูกต้องของข้อมูล (Actual Labels) โดยที่ตารางนั้นจะมีขนาด $m \times m$ โดยที่ m คือจำนวนของกลุ่มหรือจำนวน Label ที่เป็นไปได้ทั้งหมด ในกรณีที่ข้อมูลจำแนกประเภทได้เป็น 2 กลุ่มคือ Positive และ Negative ค่าที่ได้จาก Confusion Matrix จะมี 4 ค่า (รูปที่ 2.7) ได้แก่

True Positive (TP) คือ จำนวนข้อมูลที่โมเดลทำนายว่า Positive และประเภทที่แท้จริงของข้อมูลคือ Positive

True Negative (TN) คือ จำนวนข้อมูลที่โมเดลทำนายว่า Negative และประเภทที่แท้จริงของข้อมูลคือ Negative

False Positive (FP) คือ จำนวนข้อมูลที่โมเดลทำนายว่า Positive แต่ประเภทที่แท้จริงของข้อมูลคือ Negative

False Negative (FN) คือ จำนวนข้อมูลที่โมเดลทำนายว่า Negative แต่ประเภทที่แท้จริงของข้อมูลคือ Positive

		Preditd Lables:	
		Positive	Negative
Actual Lables:	Positive	TP	FN
	Negative	FP	TN

รูปที่ 2.7 ตาราง Confusion Matrix

Accuracy คือ ค่าความแม่นยำที่บอกว่าโมเดลทำนายประเภทหรือคลาสของข้อมูลได้ถูกต้องมากน้อยเพียงใด สามารถสร้างโมเดลที่ใช้ทำนายข้อมูลได้ถูกต้องขนาดไหน สามารถคำนวณหาได้จากสมการที่ 2.7

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (2.7)$$

2.5 ภาษาไพธอน

ภาษาไพธอน (Python) พัฒนาโดยชาวเนเธอร์แลนด์ชื่อ กีโด ฟาน รอสซัม (Guido van Rossum) ในพ.ศ. 2533 ภาษาไพธอนถูกพัฒนาให้สามารถทำงานได้หลายแพลตฟอร์มคือรันได้ทั้งบนระบบ Linux, Unix, Windows2000 แม้แต่ระบบ MAC OS X, Palm, Nokia Mobile เป็นต้น ปัจจุบันดูแลโดย มูลนิธิซอฟต์แวร์ไพธอน ภาษาไพธอนเป็นโปรแกรมประเภท Open Source ที่แจกจ่ายให้ใช้งานฟรีโดยไม่ต้องเสียค่าใช้จ่าย โปรแกรมภาษาไพธอนสามารถดาวน์โหลดได้จากเว็บไซต์ <http://www.python.org> มีความปลอดภัยสูง เนื่องจากภาษาไพธอนทำงานอยู่ด้าน Server เป็นหลัก เมื่อมีการร้องขอจากเครื่อง Client จะประมวลผลที่เครื่อง Server ทำให้ผู้ใช้ทั่วไปไม่สามารถเข้าถึงเครื่อง Server ได้โดยตรงจึงมีความปลอดภัยสูงกว่า ในปัจจุบันภาษาที่ใช้ในการพัฒนา Web Application มีมากมายหลายภาษา อาทิเช่น ภาษา Perl, PHP, JAVA, ASP แต่ด้วยข้อดีหลายประการของภาษาไพธอนทำให้มีผู้นิยมใช้ภาษาไพธอนในการพัฒนาเว็บแอปพลิเคชันและแอปพลิเคชันด้านอื่น ๆ มากขึ้นเรื่อย ๆ

2.5.1 การประกาศตัวแปรในภาษาไพธอน

การตั้งชื่อตัวแปรมีเงื่อนไขที่ต้องคำนึงตามกฎการตั้งชื่อตัวแปรของภาษาไพธอน มีดังต่อไปนี้

- 1) ต้องขึ้นต้นด้วยตัวอักษร ห้ามใช้ตัวเลขหรือสัญลักษณ์ใด ๆ
- 2) ห้ามมีช่องว่าง หรือเว้นวรรค
- 3) ห้ามใช้เครื่องหมายต่อไปนี้ในการตั้งชื่อตัวแปร !, @, #, \$, %, ^, &, *, (,), -, =, \, |, +, ~
- 4) ห้ามตั้งชื่อตัวแปรซ้ำกับคำสงวน
- 5) ควรตั้งชื่อตัวแปรที่สื่อความหมายให้ชัดเจน เพื่อผู้อื่นตีความหมายได้เข้าใจ แต่ถ้ามีความยาวมากให้ย่อ เช่น student_name ควรใช้ st_name เป็นต้น
- 6) ตัวแปรที่มีตัวพิมพ์ใหญ่และตัวพิมพ์เล็กผสมกันจะมีความหมายต่างกับตัวพิมพ์เล็กเพียงอย่างเดียว เช่น St_Id แตกต่างจากตัวแปร st_id เป็นต้น

ตารางที่ 2.2 ตารางแสดงการการประกาศตัวแปรของภาษาไพธอน

ชนิดข้อมูล	ตัวอย่างการใช้งาน
integer	i = 0 j = 5
float	i = 0.0 j = 5.0
character	ch = 'Y'
string	text = 'Programming Language'
boolean	Boo = True Boo = False

จากตารางที่ 2.2 จะสังเกตได้ว่าภาษาไพธอนสามารถกำหนดค่าให้กับตัวแปรนั้น ๆ ได้โดยไม่ต้องประกาศชื่อและชนิดข้อมูลล่วงหน้า ตัวแปล (Interpreter) ของภาษาไพธอนจะเรียนรู้จากข้อมูลที่เรากำหนดให้ เช่น i = 0 หมายถึง ตัวแปร i เก็บข้อมูลประเภทตัวเลขจำนวนเต็ม (integer)

2.5.2 คำสั่งในการคำนวณและแสดงผล

คำสั่งในการคำนวณของภาษาไพธอนมีลักษณะคล้ายภาษาระดับสูงทั่วไป ตัวอย่างเครื่องหมายที่ใช้ในการคำนวณแสดงได้ดังตารางที่ 2.3

ตารางที่ 2.3 แสดงสัญลักษณ์ทางคณิตศาสตร์ที่ใช้ในการคำนวณในภาษาไพธอน

สัญลักษณ์	การคำนวณ	ตัวอย่าง
+	บวก	$a + b$ มีค่า 30
-	ลบ	$a - b$ มีค่า -10
*	คูณ	$a * b$ มีค่า 200
/	หาร	b / a มีค่า 2
%	เศษของการหาร	$b \% a$ มีค่า 0
**	ยกกำลัง	$a ** b$ หมายถึง 10^{20}
//	หารปัดเศษทิ้ง	$9 // 2$ มีค่า 4 และ $9.0 // 2.0$ มีค่า 4.0

จากตารางที่ 2.3 สมมติให้ a มีค่า 10 และ b มีค่า 20 จะเห็นว่าสัญลักษณ์ที่ใช้คำนวณในภาษาไพธอนจะมีอยู่ 6 ตัวด้วยกันคือ บวก ลบ คูณ หาร หารเอาเศษยกกำลังและหารไม่ปัดเศษ ซึ่งการคำนวณจะขึ้นอยู่กับชนิดของตัวแปรว่าเป็นชนิดแบบใดที่มากกระทำต่อกัน ซึ่งผลที่ได้เมื่อคำนวณเสร็จแล้วอาจจะเป็นชนิดข้อมูลแบบเดิมหรืออาจจะกลายเป็นชนิดข้อมูลตัวใหม่ก็ได้

การแสดงผลในภาษาไพธอนจะใช้คำสั่ง `print` เพื่อแสดงผลทางจอภาพ ตัวอย่างการแสดงความออกทางจอภาพแสดงได้ดังตารางที่ 2.4

ตารางที่ 2.4 แสดงการแสดงผลข้อความออกทางจอภาพ

คำสั่ง Print	ผลลัพธ์
<code>print "Hello, World!"</code>	Hello, World!
<code>print "Hello \nWorld"</code>	Hello World
<code>print "A 'B' C"</code>	A 'B' C
<code>print 'A "B" C'</code>	A "B" C
<code>print "A \"B\" C"</code>	A "B" C

จากตาราง 2.4 แสดงการใช้เครื่องหมาย \ เพื่อควบคุมการแสดงผล เช่น \n เป็นการสั่งเพื่อให้ขึ้นบรรทัดใหม่ นอกจากคำสั่งที่แสดงให้เห็นตามตัวอย่างแล้ว ยังมีการควบคุมด้วยอักขระอื่น ๆ ดังแสดงในตารางที่ 2.5 ดังนี้

ตารางที่ 2.5 แสดงสัญลักษณ์ที่ใช้ควบคุมการแสดงผล

สัญลักษณ์ที่ใช้	การใช้งาน
\n	New line : ใช้ขึ้นบรรทัดใหม่
\t	Horizontal tab : ใช้เหมือนการกดปุ่ม Tab
\r	Carriage return : ให้เคอร์เซอร์ อยู่ที่ต้นบรรทัดใหม่
\b	Backspace : ใช้ลบตัวอักษรด้านหน้า 1 ตัวอักษร
\a	Alert : แสดงเสียง Alert
\\	แสดงเครื่องหมาย \
\"	แสดงเครื่องหมาย "
\'	แสดงเครื่องหมาย '

2.5.3 ตัวอย่างโปรแกรมภาษาไพธอน

ตัวอย่างการใช้แสดงการแสดงผลข้อความออกทางจอภาพและการเครื่องหมายแสดงได้ดังตัวอย่างในรูปที่ 2.8, 2.9 และ 2.10

```
>>> print "Hello \nWorld"
Hello
World
```

รูปที่ 2.8 แสดงตัวอย่างคำสั่งการแสดงผลตัวข้อความ

จากรูปที่ 2.8 แสดงการแสดงผลข้อความร่วมกับสัญลักษณ์ที่ใช้ในการขึ้นบรรทัดใหม่ ในคำสั่งที่ต้องการให้แสดงข้อความให้พิมพ์ข้อความอยู่ภายใต้เครื่องหมาย " "


```

>>> print 3, 4, 3 + 4
3 4 7
>>> print 5-1, 10/2
4 5

>>> pi = 3.141

>>> print "ค่า pi = ", str(pi) + " และค่า pi คำนวณด้วย Python = ",22.0/7.0
ค่า pi = 3.141 และค่าของ pi คำนวณด้วย Python = 3.14285714286

```

รูปที่ 2.9 แสดงตัวอย่างคำสั่งการคำนวณและค่าตัวแปร

จากรูปที่ 2.9 แสดงการแสดงผลคำสั่งการคำนวณ การแสดงผลตัวแปรและมีข้อความอยู่ตรงกลาง เมื่อต้องการแสดงผลตัวแปร หรือมีฟังก์ชันให้คั่นด้วยเครื่องหมาย “;” ถ้าหากต้องการแสดงข้อความต่อท้ายอีกให้ใช้เครื่องหมายบวก (+) คั่นข้อความ

```

>>> a = 'Programming'
>>> b = '\n Language'

>>> print a + b

Programming
Language

```

รูปที่ 2.10 แสดงตัวอย่างคำสั่งการเชื่อมข้อความ

รูปที่ 2.10 เป็นการแสดงผลข้อความเชื่อมข้อความ ข้อความนั้นอาจจะเก็บเป็นตัวแปร หรือที่สร้างขึ้นมาเอง สามารถเชื่อมคำด้วยเครื่องหมายบวก (+)

2.6 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการใช้เทคนิคการลดมิติของข้อมูลมีมากมาย ซึ่งจะประกอบด้วยงานในส่วนของการนำเสนอแนวคิด การปรับปรุงอัลกอริทึม ผู้วิจัยได้ทำการศึกษาค้นคว้างานวิจัยที่มีความเกี่ยวข้องกับงานวิจัยที่จะทำโดยมีรายละเอียดโดยสรุปดังนี้

Aleix และ Avinash (2001) ได้ศึกษา PCA และ LDA และทำการทดลองเพื่อพยายามพิสูจน์ว่าอาจจะไม่เสมอไปที่ LDA มีประสิทธิภาพดีกว่า PCA จึงได้ใช้เทคนิคการลดมิติของข้อมูล PCA เปรียบเทียบกับ LDA โดยใช้ Nearest Neighbor Classification ในการจำแนกข้อมูลรูปภาพใบหน้าบุคคลที่มีการปิดและไม่ปิดบังใบหน้าบางส่วนและถ่ายในระยะเวลาที่ต่างกัน โดยแบ่งการทดลองเป็น PCA, PCA โดยไม่เอา 3 โยแกนเวกเตอร์แรก และ LDA ผลการทดลองปรากฏว่า LDA สามารถจำแนกรูปภาพได้ดีที่สุด แต่ถ้าชุดข้อมูลการฝึกสอนมีขนาดเล็กอาจจะทำให้ PCA สามารถให้ผลการจำแนกข้อมูลได้ดีกว่า LDA นอกจากนี้ PCA ยังมีผลกระทบต่อข้อมูลที่มีความแตกต่างกัน

Ergun Gumus, Niyazi Kilic และคณะ (2010) ได้ศึกษาวิธีการสกัดคุณลักษณะสองวิธีการคือ PCA และ Wavelets โดยใช้ในการจำแนกระยะใกล้ที่สุด (Nearest Distance Classification) และ SVM (ใช้เคอร์เนลสามแบบคือ RBF Kernel, Linear Polynomial Kernel และ Quadratic Polynomial Kernel) สำหรับขั้นตอนการจัดหมวดหมู่ จากนั้นตรวจสอบความถูกต้องจำแนกตามขนาดที่เพิ่มขึ้นของชุดการฝึกโดยมี 6 ชุดฝึก ในการเปรียบเทียบความถูกต้องในการจัดหมวดหมู่ ใช้ฐานข้อมูลใบหน้า ORL-Face-Database ซึ่งเป็นฐานข้อมูลมาตรฐานที่นิยมใช้งานในการรู้จำใบหน้าที่มีจำนวน 400 ภาพ จากจำนวนคน 40 คน ผลการทดลองพบว่าวิธีการ Wavelet-SVM (Quadratic Polynomial Kernel) ให้ค่าความถูกต้องดีที่สุดที่ 98.1%

M.N.Shah Zainudin และคณะ (2012) ได้ศึกษาเปรียบเทียบ PCA และ LDA ที่เป็นอัลกอริทึมที่นิยมใช้ในการรู้จำ โดยฐานข้อมูลภาพใบหน้าที่นำมาทดลองคือ ATT Face Database ขนาดภาพ 92x112 พิกเซล ถ่ายที่มุมกล้องเดิมซึ่งภาพที่ได้ไม่ค่อยแตกต่างกัน และฐานข้อมูล Indian Face Database (IFD) ขนาดภาพ 64 x48 พิกเซล มีการเปลี่ยนมุมกล้อง ใช้โปรแกรม MATLAB ในการทดสอบ ผลการทดลองปรากฏว่าเมื่อใช้ข้อมูล ATT ประสิทธิภาพของ LDA ดีกว่า PCA และใช้เวลาน้อยกว่า ส่วนฐานข้อมูล IFD ประสิทธิภาพของ LDA ดีกว่า PCA แต่ใช้เวลามากกว่า และประสิทธิภาพการรู้จำของฐานข้อมูล ATT จะสูงกว่า IFD เนื่องจาก IFD มีการถ่ายภาพที่ต่างมุมกล้องและภาพพื้นหลังมีขนาดกว้างทำให้การรับรู้ของ LDA มีประสิทธิภาพลดลง

Changjun Zhou, Lan Wang และคณะ (2013) นำเสนอวิธีการใหม่ที่อยู่บนพื้นฐานของการใช้ PCA ในการสร้างภาพ และ LDA สำหรับการรู้จำใบหน้า โดยขั้นตอนแรกจะหาค่าเมตริกซ์ความแปรปรวนภายในกลุ่มเพื่อคัดเลือกคุณลักษณะที่ใช้ในการสร้างเมตริกซ์และ โยแกนเวกเตอร์ใน

แต่ละบุคคลแล้วจะได้ภาพที่สร้างขึ้นใหม่ นอกจากนี้ภาพที่เหลือจะคำนวณโดยการหาค่ากับภาพที่สร้างขึ้นใหม่จากภาพใบหน้าเดิม ภาพที่เหลือจะนำไปใช้กับ LDA ที่จะได้รับค่าสัมประสิทธิ์เมตริกซ์ การจำแนกภาพใช้วิธีการสองแบบคือการจำแนกด้วยวิธีระยะทางน้อยที่สุด (Minimum Distance Classifier) และ SVM บทความนี้ใช้ข้อมูลใบหน้า ORL-Face-Database ซึ่งมีทั้งหมด 400 ภาพ มีขนาด 112×92 พิกเซล มีการปรับความคมชัด และปรับแสงก่อนนำไปใช้งาน วิธีการที่ออกแบบคือ PCA+LDA และ PCA+LDA+SVM โดยใช้ Feature Dimension ทั้งหมด 7 ค่า ได้แก่ 3, 4, 5, 6, 7, 8, 9 ใช้ค่าเปอร์เซ็นต์การรู้จำในการเปรียบเทียบประสิทธิภาพการจำแนกข้อมูล ผลการทดลองปรากฏว่า PCA+LDA+SVM มีประสิทธิภาพดีที่สุดในค่า Feature Dimension เท่ากับ 9 และค่าเปอร์เซ็นต์การรู้จำเท่ากับ 97.74%

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่าอัลกอริทึมที่นำมาใช้ในการลดมิติข้อมูลในแต่ละงานวิจัยนั้นมีการนำมาใช้กับอัลกอริทึมอื่นเพื่อใช้ในการจำแนก ซึ่งจะเหมาะสมกับลักษณะข้อมูลที่แตกต่างกันออกไป โดยงานวิจัยส่วนมากจะใช้กับข้อมูลทดสอบเพียงข้อมูลเดียวโดยจะเน้นการเปรียบเทียบประสิทธิภาพในแต่ละเทคนิคในการลดมิติข้อมูล และจะวัดประสิทธิภาพจากค่าความถูกต้องในการจำแนก เนื่องจากการทดสอบและเปรียบเทียบประสิทธิภาพของการจำแนกข้อมูลภาพใบโอเมตริกซ์นั้นค่อนข้างซับซ้อนและต้องใช้เวลาในการดำเนินงานวิจัยนี้ได้เสนอเทคนิคการลดมิติข้อมูลเพื่อที่จะลดเวลาในการประมวลผลและสามารถใช้กับข้อมูลที่เป็นใบโอเมตริกซ์ได้หลายชนิด ได้แก่ ข้อมูลใบหน้า ข้อมูลลายนิ้วมือ และข้อมูลลายมือชื่อ เสนอการวัดประสิทธิภาพการลดมิติข้อมูลจากค่าความแม่นยำและการจับเวลาในการจำแนก สำคัญในงานวิจัยนี้เมื่อเปรียบเทียบกับงานวิจัยอื่นสรุปได้ดังตารางที่ 2.6

ตารางที่ 2.6 สรุปเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการจำแนกข้อมูลไบโอเมตริกซ์

กระบวนการทำงาน	งานวิจัยที่เกี่ยวข้อง				
	ก	ข	ค	ง	จ*
อัลกอริทึมที่ใช้ในการลดมิติข้อมูล					
Principal Component Analysis	✓	✓	✓	✓	
Linear Discriminant Analysis	✓		✓	✓	✓
Wavelets		✓			
อัลกอริทึมที่ใช้ในการจำแนกข้อมูล					
Nearest Neighbor Classification	✓				
Nearest Distance Classification		✓			
Minimum Distance Classifier				✓	
Support Vector Machine		✓	✓	✓	✓
ลักษณะการจำแนกข้อมูลไบโอเมตริกซ์					
การรู้จำใบหน้า	✓	✓	✓	✓	✓
การรู้จำลายนิ้วมือ					✓
การรู้จำลายมือชื่อ					✓
เกณฑ์การประเมินประสิทธิภาพ					
Accuracy	✓	✓	✓	✓	✓
Time			✓		✓
Number of Dimensions	✓	✓		✓	✓
ขอบเขตของการวิจัย					
วิจัยเพื่อทดสอบประสิทธิภาพ	✓	✓	✓	✓	✓
วิจัยเพื่อเสนอแนวคิดใหม่	✓	✓	✓	✓	✓
มีการประยุกต์ใช้กับข้อมูลจริง	✓	✓	✓	✓	✓

หมายเหตุ งานวิจัยที่เกี่ยวข้อง ประกอบด้วย

- ก แทนงานวิจัยของ Aleix และAvinash (2001)
 ข แทนงานวิจัยของ Ergun Gumus, Niyazi Kilic และคณะ (2010)
 ค แทนงานวิจัยของ M.N.Shah Zainudin และคณะ (2012)
 ง แทนงานวิจัยของ Changjun Zhou, Lan Wang และคณะ (2013)

จ* แทนงานวิจัยของ การปรับปรุงอัลกอริทึมซอฟต์แวร์เมชชีน
สำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์
(งานวิจัยของวิทยานิพนธ์ฉบับนี้)



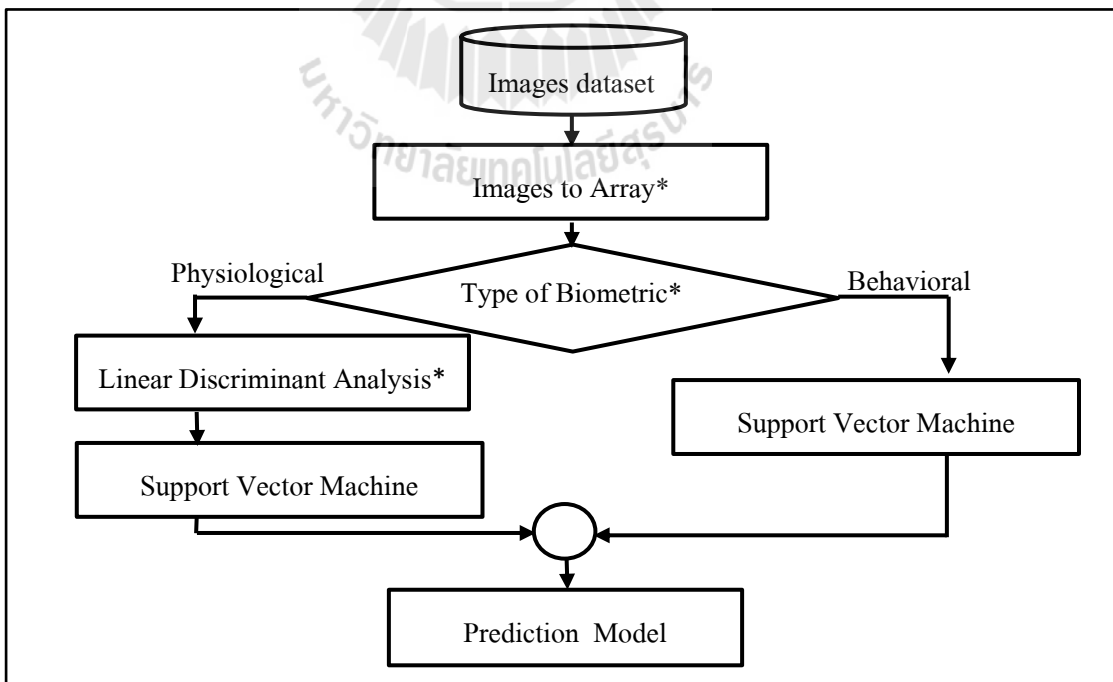
บทที่ 3

วิธีดำเนินการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อเสนออัลกอริทึม Bio-SVM ซึ่งเป็นการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่สามารถจำแนกข้อมูลภาพไบโอเมตริกซ์ได้หลากหลายชนิด ในบทนี้จะกล่าวถึงข้อมูลที่ใช้ในการวิจัย วิธีการวิจัย เครื่องมือที่ใช้ในการวิจัย และกระบวนการต่าง ๆ ของการวิจัย โดยมีรายละเอียดดังนี้

3.1 กรอบแนวคิดของการวิจัย

แนวคิดหลักของงานวิจัยนี้คือ ออกแบบขั้นตอนวิธีและเปรียบเทียบ โมเดลที่ได้จากการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์โดยเลือกใช้เทคนิคในการลดมิติข้อมูลก่อนนำข้อมูลเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพิ่มประสิทธิภาพในการจำแนกข้อมูลรูปภาพที่มีลักษณะทางพฤติกรรม โดยกรอบแนวคิดของงานวิจัยแสดงดังรูป 3.1



รูปที่ 3.1 กรอบแนวคิด Bio-SVM

จากรูปที่ 3.1 กรอบแนวคิดของขั้นตอนวิธี Bio-SVM ในส่วนที่มีเครื่องหมายดอกจัน (*) จะหมายถึงส่วนที่เพิ่มขึ้นมาเพื่อปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ ซึ่ง Bio-SVM โดยจะประกอบไปด้วย 3 ขั้นตอนย่อย ดังนี้

1) นำข้อมูลรูปภาพแปลงเป็นอาร์เรย์ซึ่งแทนค่าระดับความเข้มของสีเทา คือ 0-255 แล้วนำอาร์เรย์ที่แปลงได้แต่ละแถวมาต่อกันเป็นแถวยาว 1 แถวแทนข้อมูลรูปภาพ 1 ภาพ เช่นรูปภาพขนาด 60x60 พิกเซล จะแปลงได้อาร์เรย์ขนาด 60x60 นำมาแปลงเป็น 1 แถวที่มีความยาวเท่ากับ 3600 คอลัมน์

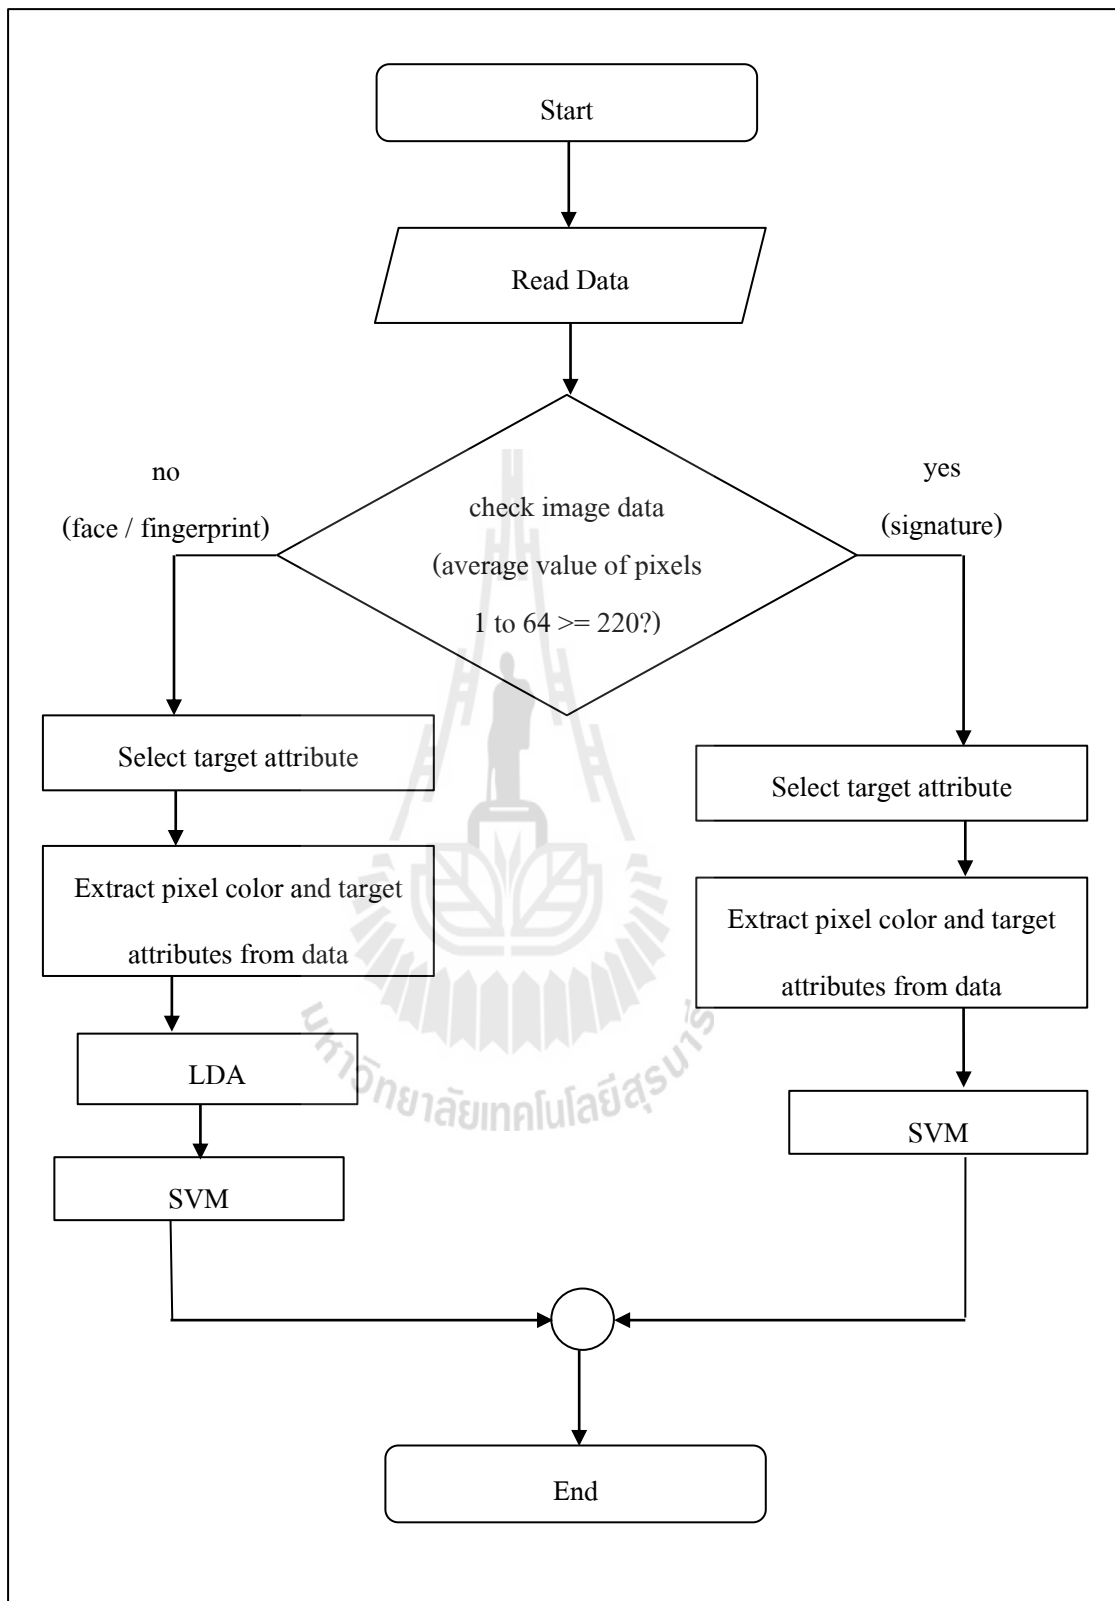
2) ตรวจสอบประเภทข้อมูลภาพไบโอเมตริกซ์ว่าเป็นภาพไบโอเมตริกซ์ลักษณะทางกายภาพหรือภาพไบโอเมตริกซ์ลักษณะทางพฤติกรรม เพื่อเลือกใช้วิธีการในการสร้างโมเดลที่ใช้ในการจำแนกข้อมูล

3) ถ้าข้อมูลรูปภาพมีลักษณะทางกายภาพจะเลือกใช้การวิเคราะห์การจำแนกเชิงเส้นก่อน แล้วจึงนำข้อมูลเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน หลังจากนั้นจะได้โมเดลที่ใช้ในการจำแนกข้อมูลภาพไบโอเมตริกซ์ลักษณะทางกายภาพออกมา ถ้าข้อมูลรูปภาพมีลักษณะทางพฤติกรรมจะนำข้อมูลเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนจากนั้นจะได้โมเดลที่เหมาะสมสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ลักษณะทางพฤติกรรม

3.2 การออกแบบอัลกอริทึม

3.2.1 ออกแบบอัลกอริทึมการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลไบโอเมตริกซ์

สำหรับการออกแบบอัลกอริทึมการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ ซึ่งในงานวิจัยนี้ได้เสนอขั้นตอนการลดมิติข้อมูลด้วยการวิเคราะห์การจำแนกเชิงเส้น ก่อนนำไปเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพื่อทำการจำแนกข้อมูลภาพไบโอเมตริกซ์ลักษณะทางกายภาพ ส่วนข้อมูลรูปภาพมีลักษณะทางพฤติกรรมจะใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ขั้นตอนการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์แสดงได้ดังรูปที่ 3.2



รูปที่ 3.2 ฟังงานแสดงขั้นตอน Bio-SVM


จากรูปที่ 3.2 เป็นรูปแสดงขั้นตอน Bio-SVM ซึ่งมีขั้นตอนในการทำงานจะเริ่มจากการตรวจสอบข้อมูลก่อนว่าเป็นข้อมูลภาพเป็นข้อมูลภาพไบโอเมตริกซ์ชนิดใดเพื่อเลือกวิธีการในการสร้างโมเดลที่ใช้ในการจำแนกข้อมูลที่เข้ามา โดยในส่วนขั้นตอนต่างๆ ของการปรับปรุงอัลกอริทึมซอฟต์แวร์แมชชีนมีดังต่อไปนี้

ขั้นตอน Read Data : เป็นขั้นตอนการอ่านข้อมูลจากไฟล์ .csv ซึ่งเป็นไฟล์ที่คอลัมน์แรกจะใส่ตัวเลขที่เป็นคลาสเป้าหมายของภาพไว้ (target) ส่วนคอลัมน์ที่สองจนถึงสุดท้ายจะเป็นค่าระดับสีในแต่ละจุดของภาพ ข้อมูลในไฟล์ .csv หนึ่งบรรทัดหมายถึงภาพหนึ่งภาพ


ขั้นตอน check image data : เป็นการตรวจสอบชนิดข้อมูลที่เข้ามา โดยงานวิจัยนี้จะแบ่งข้อมูลออกเป็น 2 ลักษณะคือ ข้อมูลลักษณะทางพฤติกรรม และข้อมูลลักษณะกายภาพ โดยจะแบ่งลักษณะข้อมูลจากการหาค่าเฉลี่ยของข้อมูลค่าสีที่คอลัมน์ที่ 1 ถึงคอลัมน์ที่ 64 ถ้าค่าเฉลี่ยมีค่ามากกว่าหรือเท่ากับ 220 แสดงว่าข้อมูลนั้นเป็นข้อมูลลักษณะทางพฤติกรรม แต่ถ้าค่าเฉลี่ยมีค่าน้อยกว่า 220 แสดงว่าข้อมูลนั้นเป็นข้อมูลลักษณะกายภาพ เลือกใช้ค่าสีเฉลี่ยที่ 220 เนื่องจากไฟล์ภาพที่ใช้ในการทดลองที่เป็นข้อมูลลักษณะกายภาพ ได้แก่ ภาพลายนิ้วมือ ภาพใบหน้า และข้อมูลลักษณะทางพฤติกรรม ภาพลายมือชื่อ ดังแสดงในรูปที่ 3.3 3.4 และ 3.5 ซึ่งจากรูปจะเห็นว่าข้อมูลภาพลายมือชื่อที่บริเวณหัวภาพจะเป็นสีขาว (ค่าสี 255) แต่จะมีบางลายมือชื่อที่ถูกควัดปากกาทำให้บางจุดบนหัวภาพเป็นระดับสีเทาทำให้เราไม่สามารถแยกภาพลายนิ้วมือด้วยค่าเฉลี่ยสีที่ 255 เราจึงเลือกใช้ค่าเฉลี่ยสีที่ 220 ในใช้จำแนกลักษณะของภาพเป็นข้อมูลลักษณะทางพฤติกรรม



รูปที่ 3.3 แสดงตัวอย่างภาพใบหน้า



รูปที่ 3.4 แสดงตัวอย่างภาพลายนิ้วมือ



รูปที่ 3.5 แสดงตัวอย่างภาพถ่ายลายมือชื่อ

ขั้นตอน Select target attribute : ในขั้นตอนนี้จะทำเลือกคลาสเป้าหมาย เนื่องจากอัลกอริทึม SVM เป็นอัลกอริทึมแบบมีผู้ฝึกสอน ดังนั้นจึงต้องมีการเตรียมข้อมูลก่อน โดยจะต้องทำการกำหนดคอลลัมน์เป้าหมายให้กับอัลกอริทึม ซึ่งในงานวิจัยนี้จะกำหนดข้อมูลคอลลัมน์แรกเป็นคอลลัมน์เป้าหมาย ดังนั้นในขั้นตอนนี้จึงทำการเลือกคลาสเป้าหมายที่คอลลัมน์แรกของข้อมูล

ขั้นตอน Extract pixel color and target attributes from data : เป็นขั้นตอนการดึงค่าคลาสเป้าหมายที่คอลลัมน์แรกและข้อมูลที่เป็นค่าระดับของแต่ละจุดบนภาพที่คอลลัมน์ที่สองจนถึงคอลลัมน์สุดท้ายออกจากไฟล์ข้อมูล โดยจะแยกเก็บคลาสเป้าหมายและข้อมูลที่เป็นค่าระดับสีไว้ในรูปแบบของอาร์เรย์ โดยจะเก็บคลาสเป้าหมายไว้ที่ตัวแปร target ส่วนข้อมูลค่าสีเก็บค่าไว้ที่ตัวแปร data


ขั้นตอน LDA : เป็นขั้นตอนการนำข้อมูลที่เป็นเฉพาะค่าระดับสีบนแต่ละจุดของภาพมาทำการลดมิติข้อมูลด้วยวิธีการวิเคราะห์การจำแนกเชิงเส้น

ขั้นตอน SVM : ในขั้นตอนนี้จะเป็นการใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพื่อใช้ในการจำแนกข้อมูลภาพไบโอเมตริกซ์ ซึ่งในงานวิจัยนี้เลือกใช้คอร์เนลของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน 2 คอร์เนล ได้แก่ คอร์เนลเส้นตรง และคอร์เนลเส้นโพลิโนเมียล โดยถ้าข้อมูลที่เข้ามาเป็นข้อมูลภาพที่มีลักษณะเชิงกายภาพจะใช้คอร์เนลเส้นตรง และใช้คอร์เนลเส้นโพลิโนเมียลสำหรับข้อมูลภาพที่เข้ามาเป็นข้อมูลลักษณะเชิงทางพฤกษศาสตร์

3.2.2 ออกแบบการทดสอบประสิทธิภาพโมเดลที่ใช้ทำนายข้อมูลภาพใบโอเมตริกซ์

การทดสอบประสิทธิภาพโมเดลที่ใช้ทำนายจะวัดประสิทธิภาพด้วยมาตรวัดความแม่นยำโดยวิธีพิจารณาค่าความแม่นยำและเวลาที่ใช้ในการประมวลผล โดยจะทำการแบ่งข้อมูลออกเป็นชุดข้อมูลฝึกและชุดข้อมูลทดสอบ ซึ่งในส่วนของ การทดสอบประสิทธิภาพจะใช้ชุดข้อมูลทดสอบมาใช้ประเมินผลการทำนายแต่ละโมเดลที่ได้จากการอัลกอริทึมซอฟต์แวร์เวกเตอร์แมชชีน ซึ่งได้ค่าความแม่นยำออกมา ส่วนเวลาที่ใช้ในการประมวลผลจะจับเวลาตั้งแต่เริ่มขั้นตอนการลดมิติข้อมูลไปจนถึงขั้นตอนการทดสอบประสิทธิภาพชุดข้อมูลทดสอบ ซึ่งตัวอย่างการทดสอบประสิทธิภาพโมเดลที่ใช้ทำนายข้อมูลภาพใบโอเมตริกซ์สามารถแสดงได้ดังรูปที่ 3.6 โดยจะใช้ลูกศรที่เป็นเส้นประ (- ->) จะแสดงการวัดประสิทธิภาพของข้อมูลที่ไม่ได้ถูกลดมิติก่อนนำไปสร้างโมเดล และลูกศรที่เป็นเส้นตรง (—>) จะแสดงการวัดประสิทธิภาพของข้อมูลที่ถูกลดมิติด้วยการวิเคราะห์การจำแนกเชิงเส้นก่อนนำข้อมูลที่ถูกลดมิติข้อมูลแล้วไปสร้างโมเดล

จากตัวอย่างในรูปที่ 3.6 จะเห็นว่าเมื่อใช้ข้อมูลทดสอบชุดเดียวกันการลดมิติข้อมูลจะทำให้ผลการทำนายใบหน้า มีความแม่นยำสูงถึง 80% ในขณะที่ถ้าไม่ใช้เทคนิคการลดมิติข้อมูลความแม่นยำของการทำนายภาพใบหน้าชาย-หญิง มีความแม่นยำเพียง 60% งานวิจัยนี้จึงเลือกใช้เทคนิคการลดมิติข้อมูลเป็นขั้นตอนหนึ่งของการรู้จำภาพใบโอเมตริกซ์เชิงกายภาพ แต่ในกรณีของภาพใบโอเมตริกซ์เชิงพฤติกรรมที่เป็นภาพลายมือชื่อรายละเอียดของภาพจะไม่มากเท่าภาพใบหน้าหรือลายนิ้วมือจึงไม่จำเป็นต้องใช้เทคนิคการลดมิติข้อมูลเพราะจะทำให้ใช้เวลาในการประมวลผลมากเกินไป



รูปที่ 3.6 ตัวอย่างการทดสอบประสิทธิภาพโมเดลที่ใช้ทำนายข้อมูลภาพใบโอมเมตริกซ์

3.3 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้ในงานวิจัยนี้ ประกอบด้วยฮาร์ดแวร์และซอฟต์แวร์ ดังนี้

- 1) เครื่องคอมพิวเตอร์ โดยมีรายละเอียดดังนี้
 - หน่วยประมวลผลกลาง : Intel® Core i3
 - หน่วยความจำสำรอง : 320 GB
 - หน่วยความจำหลัก : 2 GB
 - อุปกรณ์เสริมอื่น ๆ เช่น เมาส์ แป้นพิมพ์ เป็นต้น
- 2) ระบบปฏิบัติการและโปรแกรมประยุกต์สำหรับโปรแกรม Bio-SVM ประกอบไปด้วย
 - ระบบปฏิบัติการ : Windows 7 Ultimate 32-bit Operating System
 - เครื่องมือในการพัฒนาโปรแกรม : spyder 2.2.5(python 2.7), Microsoft Excel 2010



บทที่ 4

การทดสอบและอภิปรายผล

การทดสอบประสิทธิภาพของระบบนั้น จะทดสอบประสิทธิภาพการปรับปรุง อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ (Bio-SVM) โดยการเปรียบเทียบประสิทธิภาพอัลกอริทึม Bio-SVM นั้นกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแบบปกติ ซึ่งจะเปรียบเทียบค่าความแม่นยำ (Accuracy) ของโมเดลและเวลาที่ใช้ในการทำงาน

4.1 ข้อมูลที่ใช้ในการทดสอบ

ในการทดสอบการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ (Bio-SVM) จะใช้ข้อมูลทั้งหมด 3 ข้อมูลได้แก่

4.1.1 ข้อมูลภาพลายนิ้วมือ

ข้อมูลทั้งหมดมี 168 ภาพ เป็นภาพลายนิ้วมือของ 21 คน โดยที่ลายนิ้วมือ 1 ลายนิ้วมือจะมีข้อมูลทั้งหมด 8 ภาพ ในแต่ละภาพมีความละเอียดภาพละ 80x80 พิกเซล (6400 พิกเซล) สามารถดาวน์โหลดได้ที่ <http://fvs.sourceforge.net/download.html>



รูปที่ 4.1 ตัวอย่างข้อมูลภาพสแกนลายนิ้วมือ

4.1.2 ข้อมูลภาพใบหน้า


ข้อมูลทั้งหมดมี 400 ภาพ เป็นภาพใบหน้าบุคคล 40 คน โดยใบหน้าของแต่ละบุคคล จะมีข้อมูลทั้งหมด 10 ภาพ เป็นภาพใบหน้าผู้ชาย 36 คน (360 ภาพ) และภาพใบหน้าผู้หญิง 4 คน (40 ภาพ) ในแต่ละภาพมีความละเอียดภาพละ 64x64 พิกเซล (4096 พิกเซล) สามารถดาวน์โหลดได้ที่ <http://fvs.sourceforge.net/download.html>



รูปที่ 4.2 ตัวอย่างข้อมูลภาพใบหน้า

4.1.3 ข้อมูลภาพลายมือชื่อ


ข้อมูลมีทั้งหมด 600 ภาพ เป็นภาพลายมือชื่อ 30 บุคคล โดยที่ลายมือชื่อของแต่ละบุคคล จะเก็บข้อมูลเอาไว้ทั้งหมด 20 ภาพ ในแต่ละภาพลายมือชื่อจะมีความละเอียดภาพละ 38x144 พิกเซล (5472 พิกเซล) สามารถดาวน์โหลดข้อมูลภาพลายมือชื่อได้จาก <https://sites.google.com/site/nhinganusarapesut/signature/datasets>



รูปที่ 4.3 ตัวอย่างข้อมูลภาพลายมือชื่อ

4.2 การทดสอบประสิทธิภาพการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน สำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์

วิธีทดสอบประสิทธิภาพการจำแนกข้อมูลภาพไบโอเมตริกซ์จะใช้ค่าความแม่นยำเป็นตัวชี้วัดหลัก โดยแบ่งข้อมูลทดสอบออกเป็น 2 ชุด ได้แก่ ข้อมูลที่ใช้ในการเรียนรู้ 75% และข้อมูลที่ใช้ในการทดสอบ 25% ซึ่งข้อมูลในการเรียนรู้และข้อมูลที่ใช้ในการทดสอบจะถูกนำไปผ่านขั้นตอนการลดมิติข้อมูลจากนั้นจะนำข้อมูลการเรียนรู้ที่ถูกลดมิติแล้วเข้าสู่อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพื่อสร้างโมเดลที่ใช้ในการจำแนกข้อมูลภาพไบโอเมตริกซ์ และสุดท้ายจะนำข้อมูลทดสอบที่ผ่านการลดมิติเข้าไปในโมเดลเพื่อทดสอบและหาเป็นค่าความแม่นยำออกมา ดังรูปที่ 4.4 ที่แสดงแผนภาพวิธีการทดสอบประสิทธิภาพการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์ โดยที่จะใช้ลูกศรที่เป็นเส้นประ (-->) จะแสดงขั้นตอนการวัดประสิทธิภาพของโมเดล Bio-SVM เชิงพหุคูณและลูกศรที่เป็นเส้นตรง (—>) แสดงขั้นตอนการวัดประสิทธิภาพของโมเดล Bio-SVM เชิงกายภาพ



รูปที่ 4.4 แสดงแผนภาพวิธีการทดสอบประสิทธิภาพ โมเดลสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์

4.2.1 ผลของวิธีการใช้ SVM

ในการทดสอบการจำแนกภาพใบโอเมตริกซ์ด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน วิธีการนี้จะเป็นการแบ่งข้อมูลออกเป็นข้อมูลที่ใช้ในการเรียนรู้ 75% และข้อมูลที่ใช้ในการทดสอบ 25% ซึ่งข้อมูลในการเรียนรู้จะนำเข้าสู่อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพื่อสร้างโมเดลที่ใช้ในการจำแนกข้อมูลภาพใบโอเมตริกซ์ และสุดท้ายจะนำข้อมูลทดสอบเข้าไปในโมเดลเพื่อทดสอบการจำแนกภาพของโมเดลและหาเป็นค่าความแม่นยำออกมา ผลการทดสอบของวิธีการนี้จะเอาไว้เปรียบเทียบกับเมื่อปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแล้วจะทำไมประสิทธิภาพในการจำแนกภาพใบโอเมตริกซ์ดีขึ้นหรือไม่ ซึ่งผลการทดสอบได้ผลดังนี้

ข้อมูลภาพลายนิ้วมือที่เคอร์เนลเส้นตรงให้ค่าความแม่นยำร้อยละ 52 ใช้เวลา 0.475 วินาที และเคอร์เนลโพลิโนเมียลให้ค่าความแม่นยำร้อยละ 59 ใช้เวลา 0.495 วินาที

ข้อมูลภาพใบหน้าผลจากการใช้เคอร์เนลเส้นตรงให้ค่าความแม่นยำร้อยละ 96 ใช้เวลา 1.138 วินาที และเคอร์เนลโพลิโนเมียลให้ค่าความแม่นยำร้อยละ 97 ใช้เวลา 2.184 วินาที

ข้อมูลภาพลายมือชื่อเมื่อใช้เคอร์เนลเส้นตรงให้ค่าความแม่นยำร้อยละ 94.7 ใช้เวลา 3.600 วินาที และเคอร์เนลโพลิโนเมียลให้ค่าความแม่นยำร้อยละ 95.3 ใช้เวลา 3.640 วินาที

ซึ่งผลจากการทดสอบการใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนกับภาพใบโอเมตริกซ์ 3 ชนิดสามารถสรุปได้ดังตารางที่ 4.1

ตารางที่ 4.1 แสดงค่าความแม่นยำและเวลาที่ใช้ในการจำแนกข้อมูลใบโอเมตริกซ์แต่ละประเภทด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

Data	SVM Kernel Function	Accuracy(%)	Time(sec)
ลายนิ้วมือ	linear	52.0	0.475
	polynomial	59.0	0.495
ใบหน้า	linear	96.0	1.138
	polynomial	97.0	2.184
ลายมือชื่อ	linear	94.7	3.600
	polynomial	95.3	3.640

4.2.2 ผลของวิธีการใช้ Bio-SVM กับข้อมูลไบโอเมตริกซ์เชิงกายภาพ

ถ้าข้อมูลภาพไบโอเมตริกซ์เป็นลักษณะทางกายภาพในงานวิจัยนี้จะสร้างโมเดลที่ใช้ในการจำแนกด้วยการวิเคราะห์จำแนกประเภทเชิงเส้นมาใช้ร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน โดยใช้เคอร์เนลเส้นตรง การทดลองจะลดขนาดของข้อมูลจากการเลือกใช้อังก์ประกอบน้อยไปจนถึงเท่ากับขนาดของภาพเพื่อดูค่าความแม่นยำและใช้อังก์ประกอบของข้อมูลที่เท่าใดจะให้ค่าความแม่นยำสูงที่สุดซึ่งผลการทดสอบให้ผลได้ดังนี้

ข้อมูลภาพลายนิ้วมือที่เคอร์เนลเส้นตรงใช้ 32 อังก์ประกอบสามารถให้ค่าความแม่นยำที่ร้อยละ 73.8 ใช้เวลา 0.461 วินาที และเคอร์เนลโพลีโนเมียลใช้ 16 อังก์ประกอบให้ค่าความแม่นยำร้อยละ 47.6 ใช้เวลา 0.478 วินาที

ข้อมูลภาพใบหน้าผลจากการใช้เคอร์เนลเส้นตรงใช้ 41 อังก์ประกอบให้ค่าความแม่นยำร้อยละ 98 ใช้เวลา 0.548วินาที และเคอร์เนลโพลีโนเมียลใช้ 41 อังก์ประกอบให้ค่าความแม่นยำร้อยละ 91 ใช้เวลา 0.633 วินาที

ซึ่งผลจากการทดสอบทั้งหมดของ Bio-SVM เชิงกายภาพกับภาพไบโอเมตริกซ์ 2 ชนิดสามารถสรุปได้ดังตารางที่ 4.2 และ 4.3



ตารางที่ 4.2 แสดงผลการทดสอบข้อมูลภาพลายนิ้วมือด้วย LDA+SVM

% reduce data	n_components	linear	Time(sec)
0.16%	10	0.643	0.466
0.25%	16	0.69	0.472
0.50%	32	0.738	0.461
1%	64	0.738	0.467
2.5%	160	0.738	0.467
5%	320	0.738	0.47
10%	640	0.738	0.464
20%	1280	0.738	0.465
30%	1920	0.738	0.472
40%	2560	0.738	0.461
50%	3200	0.738	0.466
60%	3840	0.738	0.478
70%	4480	0.738	0.47
80%	5120	0.738	0.468
90%	5760	0.738	0.482
100%	6400	0.738	0.477

ตารางที่ 4.3 แสดงผลการทดสอบข้อมูลภาพใบหน้าด้วย LDA+SVM

% reduce data	n_components	linear	Time(sec)
0.25%	10	0.92	0.523
0.37%	15	0.95	0.544
0.50%	20	0.96	0.542
1%	41	0.98	0.548
2.5%	102	0.98	0.536
5%	205	0.98	0.536
10%	410	0.98	0.54
20%	819	0.98	0.548
30%	1229	0.98	0.573
40%	1638	0.98	0.6
50%	2048	0.98	0.56
60%	2458	0.98	0.572
70%	2867	0.98	0.594
80%	3278	0.98	0.589
90%	3686	0.98	0.618
100%	4096	0.98	0.621

4.2.3 ผลของวิธีการใช้ Bio-SVM กับข้อมูลไบโอเมตริกซ์เชิงพฤติกรรม


ถ้าข้อมูลภาพไบโอเมตริกซ์เป็นลักษณะทางพฤติกรรมในงานวิจัยนี้จะสร้างโมเดลที่ใช้ในการจำแนกด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน โดยเลือกใช้คอร์เนลโพลิโนเมียล โดยจะเป็นการแบ่งข้อมูลออกเป็นข้อมูลที่ใช้ในการเรียนรู้ 75% เพื่อใช้สร้างโมเดลที่ใช้ในการจำแนกข้อมูลไบโอเมตริกซ์ลักษณะทางพฤติกรรม และข้อมูลที่ใช้ในการทดสอบโมเดล 25% ซึ่งผลการทดสอบข้อมูลภาพลายมือชื่อให้ค่าความแม่นยำร้อยละ 95.3 ใช้เวลา 3.640 วินาที

4.3 เปรียบเทียบผลการทดลองการจำแนกข้อมูลภาพไบโอเมตริกซ์ด้วยอัลกอริทึมต่าง ๆ


การทดลองการใช้เทคนิคการลดขนาดมิติข้อมูลรวมกับการใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนนั้นให้ประสิทธิภาพที่ดี โดยงานวิจัยนี้ได้เลือกใช้ข้อมูลภาพ 3 ชนิดได้แก่ ภาพลายนิ้วมือ ภาพใบหน้า และภาพลายมือชื่อ ในการทดสอบประสิทธิภาพ ซึ่งได้เปรียบเทียบกับการใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน กับอัลกอริทึมที่ผู้วิจัยได้เสนอขึ้นมาใหม่คือ Bio-SVM แบ่งเป็น 2 โมเดลได้แก่ Bio-SVM เชิงกายภาพและ Bio-SVM เชิงพฤติกรรม การเปรียบเทียบจะใช้ค่าความแม่นยำในการจำแนกภาพไบโอเมตริกซ์แต่ละชนิดและเวลาที่ใช้ในการทดสอบ โดยจะแสดงการเปรียบเทียบในตารางที่ 4.4 สรุปเป็นกราฟเปรียบเทียบค่าความแม่นยำแสดงดังรูปที่ 4.5 และกราฟเปรียบเทียบเวลาที่ใช้ในการทำงานของโมเดลแสดงในรูปที่ 4.6

ตารางที่ 4.4 แสดงการสรุปผลการทดสอบด้วย SVM-linear, SVM-poly, Bio-SVM กับข้อมูลไบโอเมตริกซ์เชิงกายภาพและเชิงพฤติกรรม

Data	SVM-linear		SVM-poly		Bio-SVM		
	Acc. (%)	Time (sec)	Acc. (%)	Time (sec)	Acc. (%)	Time (sec)	
ไบโอเมตริกซ์เชิงกายภาพ	ลายนิ้วมือ	52.0	0.475	59.0	0.495	73.8	0.461
	ใบหน้า	96.0	1.138	97.0	2.184	98.0	0.548
ไบโอเมตริกซ์เชิงพฤติกรรม	ลายมือชื่อ	94.7	3.600	95.3	3.640	95.3	3.640



รูปที่ 4.5 กราฟแสดงการเปรียบเทียบค่าความแม่นยำจากวิธีการจำแนกภาพไบโอเมตริกซ์ด้วยอัลกอริทึมต่าง ๆ



รูปที่ 4.6 กราฟแสดงการเปรียบเทียบเวลาที่ใช้ในการประมวลผลจากวิธีการจำแนกภาพไบโอเมตริกซ์ด้วยอัลกอริทึมต่าง ๆ

4.4 อภิปรายผล

จากผลการทดสอบประสิทธิภาพโมเดลการจำแนกภาพไบโอเมตริกซ์ ด้วยอัลกอริทึม SVM-linear SVM-poly และ Bio-SVM สำหรับการจำแนกภาพไบโอเมตริกซ์ 3 ชนิดได้แก่ ภาพลายนิ้วมือจำนวน 168 ภาพ ภาพใบหน้าจำนวน 400 ภาพ และภาพลายมือชื่อจำนวน 600 ภาพ สามารถสรุปผลการทดสอบเปรียบเทียบได้ดังนี้

การเปรียบเทียบโดยใช้ตัวชี้วัดคือค่าความแม่นยำจากตารางที่ 4.4 จะเห็นว่าเมื่อใช้อัลกอริทึม Bio-SVM แล้วทำให้ผลในการวัดประสิทธิภาพด้วยค่าความแม่นยำที่ดีที่สุดสำหรับข้อมูลเชิงกายภาพเมื่อเทียบกับอัลกอริทึม SVM-linear และ SVM-poly โดยที่ข้อมูลลายนิ้วมือให้ค่าความแม่นยำที่ดีที่สุดร้อยละ 73.8 และข้อมูลภาพใบหน้าให้ค่าความแม่นยำที่ร้อยละ 98 ส่วนในข้อมูลภาพลายมือชื่ออัลกอริทึม Bio-SVM มีประสิทธิภาพที่ดีเท่ากับ SVM-poly โดยให้ค่าความแม่นยำที่ร้อยละ 95.3

การเปรียบเทียบโดยใช้ตัวชี้วัดคือเวลาที่ใช้ในการประมวลผลจากตารางที่ 4.4 จะเห็นว่าที่อัลกอริทึม Bio-SVM ใช้เวลาในการประมวลผลน้อยกว่าอัลกอริทึม SVM-linear และ SVM-poly ที่ข้อมูลเชิงกายภาพซึ่งข้อมูลลายนิ้วมือใช้เวลาในการประมวลผลเพียง 0.461 วินาที และข้อมูลลายนิ้วมือใช้เวลาในการประมวลผล 0.548 วินาที ส่วนข้อมูลลายมือชื่อเวลาที่ใช้ในการประมวลผลของอัลกอริทึม Bio-SVM และ SVM-poly ใช้เวลาเท่ากันที่ 3.640 วินาที

จากผลการทดสอบประสิทธิภาพการจำแนกภาพไบโอเมตริกซ์ ผลการทดสอบสรุปได้ว่าการเปรียบเทียบโดยใช้ตัวชี้วัดที่เป็นค่าความแม่นยำและเวลาที่ใช้ในการประมวลผลที่ข้อมูลเชิงกายภาพได้แก่ ข้อมูลภาพใบหน้าและข้อมูลลายนิ้วมืออัลกอริทึม Bio-SVM ให้ค่าที่ดีที่สุดจะเห็นการใช้เทคนิคการลดมิติข้อมูลด้วยการวิเคราะห์จำแนกประเภทเชิงเส้น มีผลสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์เชิงกายภาพซึ่งเป็นเหตุผลสำคัญที่ให้อัลกอริทึม Bio-SVM ให้ค่าความแม่นยำและเวลาที่ใช้ในการประมวลผลมากกว่าอัลกอริทึมอื่น และไม่จำเป็นต้องใช้ข้อมูลทั้งหมดในการจำแนกข้อมูลก็สามารถให้ประสิทธิภาพในการจำแนกที่ดีได้ ในการประมวลผลที่ข้อมูลเชิงพฤติกรรมอัลกอริทึม Bio-SVM มีประสิทธิภาพที่ดีเท่ากับ SVM-poly

ข้อมูลเชิงกายภาพนั้นมีรายละเอียดของข้อมูลมากและมีลักษณะเฉพาะตัว ภาพใบหน้าจะมีลักษณะเป็นวงกลมและมีส่วนที่เป็น ตา จมูก ปาก เหมือนกันแต่ในส่วนนี้ของภาพแต่ละบุคคลจะมีรายละเอียดไม่เหมือนกัน ภาพลายนิ้วมือจะมีลักษณะเป็นเส้นโค้งและกันหอยในแต่ละบุคคลจะแตกต่างกันทำให้การคำนวณหาความแปรปรวนในการวิเคราะห์จำแนกประเภทเชิงเส้นมีค่าที่แตกต่างกันชัดเจนทำให้สามารถดึงลักษณะเด่นของภาพออกมาได้ดี ส่วนข้อมูลภาพลายมือชื่อเป็นข้อมูลที่มีรายละเอียดของข้อมูลค่อนข้างน้อยและไม่มีลักษณะเฉพาะตัวทำให้การหาความ

แปรปรวนในการวิเคราะห์จำแนกประเภทเชิงเส้นมีค่าใกล้เคียงกันทำให้ถึงลักษณะเด่นของภาพ
ออกมาได้ไม่ดีเป็นผลทำให้ประสิทธิภาพในการจำแนกข้อมูลได้ไม่ดี ดังนั้นจึงไม่เลือกใช้การ
วิเคราะห์จำแนกประเภทเชิงเส้นกับข้อมูลเชิงพฤติกรรมก่อนนำข้อมูลมาสร้างโมเดลในการรู้จำ



บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

ปัจจุบันอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนถูกนำมาใช้ในการจำแนกข้อมูลภาพใบโอเมตริกซ์อย่างแพร่หลาย แต่การจำแนกข้อมูลภาพนั้นไม่ถูกต้องสมบูรณ์และในการจำแนกภาพค่อนข้างใช้เวลานาน จึงได้มีหลายงานวิจัยเสนอแนวทางต่างๆแต่วิธีการเหล่านั้นสามารถใช้ได้กับข้อมูลภาพเพียงแบบเดียวเท่านั้น ดังนั้นจึงต้องใช้วิธีการที่สามารถจำแนกข้อมูลภาพได้หลายแบบ และใช้เวลาในการจำแนกข้อมูลภาพน้อยลงคือการจัดการกับข้อมูลก่อนนำไปเข้าอัลกอริทึมที่ใช้ในการจำแนกซึ่งเป็นขั้นตอนก่อนการประมวลผลที่เรียกว่าการลดมิติข้อมูล

ในงานวิจัยนี้มุ่งเน้นในกระบวนการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ซึ่งปรับปรุงโดยการนำการลดมิติของข้อมูลซึ่งเป็นเทคนิคในการเตรียมข้อมูล เป็นการทำให้ข้อมูลตั้งต้นมีขนาดลดลงและสูญเสียความถูกต้องของผลลัพธ์น้อยที่สุดมาใช้งานร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน โดยมีจุดมุ่งหมายว่าเมื่อปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแล้วสามารถจำแนกภาพใบโอเมตริกซ์ได้หลายแบบ ใช้เวลาในการประมวลผลน้อย และให้ประสิทธิภาพในการจำแนกภาพดี

5.1 ขั้นตอนการดำเนินงานวิจัย

งานวิจัยนี้ได้ปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพใบโอเมตริกซ์ ชื่อ Bio-SVM ขั้นตอนของงานวิจัยนี้แบ่งออกเป็นดังนี้

- 1) ศึกษาการทำงานของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และการศึกษาการเขียนโปรแกรมด้วยภาษาไพธอน (Python) ซึ่งเป็นภาษาที่เหมาะสมสำหรับการทำเหมืองข้อมูล และการวิเคราะห์ข้อมูล ซึ่งทำให้ง่ายในการนำไปใช้ในการพัฒนาอัลกอริทึม

- 2) การศึกษางานวิจัยที่เกี่ยวข้องกับการจำแนกข้อมูลภาพใบโอเมตริกซ์และหาวิธีการที่จะปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนซึ่งก็คือการนำเทคนิคการลดมิติข้อมูลเข้ามาใช้ร่วม

- 3) การออกแบบปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน จะปรับปรุงโดยการนำข้อมูลไปทำการลดมิติข้อมูลก่อนนำข้อมูลไปเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ซึ่งการลดมิติข้อมูลนั้นจะมีวิธีการเลือกใช้วิธีการในการลดมิติข้อมูล โดยถ้าข้อมูลภาพที่เข้ามามีลักษณะเชิงกายภาพหรือทางสรีระ (Physiological Biometrics) จะใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่

เคอร์เนลโพลิโนเมียล และถ้าภาพมีลักษณะเชิงพฤติกรรม (Behavioral Biometrics) จะใช้การวิเคราะห์จำแนกประเภทเชิงเส้นเพื่อลดมิติข้อมูลภาพก่อนเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

4) กระบวนการออกแบบวิธีการสำหรับการทดสอบประสิทธิภาพ โมเดลที่ได้จากการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเพื่อใช้จำแนกภาพไบโอเมตริกซ์ โดยจะนำชุดข้อมูลทดสอบมาใช้ในการประเมินผลการจำแนกข้อมูลภาพในแต่ละโมเดล ซึ่งจะได้ผลการประเมินออกมาเป็นค่าความแม่นยำและจะจับเวลาที่ใช้ในการประมวลผล

การทดสอบประสิทธิภาพโมเดลที่ได้จากการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน จะทดสอบกับภาพลายนิ้วมือ ภาพใบหน้า และภาพลายมือชื่อ ซึ่งเป็นชุดข้อมูลที่มีการเผยแพร่สาธารณะ การเปรียบเทียบประสิทธิภาพจะทำการเปรียบเทียบจากการทดสอบประสิทธิภาพโมเดลที่ได้จากแต่ละวิธีของการปรับปรุงซัพพอร์ตเวกเตอร์แมชชีนและเปรียบเทียบกับการใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแบบปกติ และใช้มาตรวัดความแม่นยำ (Accuracy) และเวลาที่ใช้ในการประมวลผลในการจำแนกข้อมูลภาพไบโอเมตริกซ์ เพื่อแสดงให้เห็นถึงประสิทธิภาพการจำแนกข้อมูลภาพของโมเดลที่ได้จากการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

5.2 สรุปผลการวิจัย

ผลการทดสอบประสิทธิภาพการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์โดยเปรียบเทียบโมเดลที่ใช้ในการจำแนกภาพไบโอเมตริกซ์ทั้งหมด 3 โมเดล ได้แก่ SVM-linear SVM-poly และ Bio-SVM การทดสอบใช้ตัวชี้วัดคือค่าความแม่นยำและเวลาที่ใช้ในการประมวลผล จากผลการทดลองสามารถสรุปได้ว่าการใช้เทคนิคลดมิติข้อมูลด้วย LDA และใช้งานร่วมกับอัลกอริทึมที่ใช้ในการจำแนกด้วย SVM-linear ที่เรียกว่า Bio-SVM เซึ่งกายภาพ ทำให้ประสิทธิภาพดีและใช้เวลาน้อยกว่า SVM-linear และ SVM-poly ส่วน Bio-SVM เซึ่งพฤติกรรม เหมาะสมกับข้อมูลที่มีลักษณะไม่ชัดเจนมากกว่าการใช้การลดมิติ แต่ประสิทธิภาพในการจำแนกและเวลาในการประมวลผลเท่าเทียมกับ SVM-poly และพบว่าการใช้เทคนิคการลดมิติข้อมูลด้วยการวิเคราะห์จำแนกประเภทเชิงเส้นจะใช้อุปกรณ์ประกอบประมาณ 1% จากองค์ประกอบทั้งหมดก็เพียงพอที่จะนำไปจำแนกข้อมูลภาพไบโอเมตริกซ์ซึ่งกายภาพซึ่งเป็นข้อมูลที่มีลักษณะที่เด่นชัดมีรูปร่างตายตัว โดยมีประสิทธิภาพในการจำแนกที่ดีขึ้นและสามารถลดเวลาเมื่อเทียบกับ SVM-linear และ SVM-poly

5.3 ปัญหาและข้อเสนอแนะ

ในขั้นตอนการลดมิติข้อมูลแต่ละวิธีจะมีกระบวนการคำนวณหาตัวแทนข้อมูลที่แตกต่างกันไป ถ้าชุดข้อมูลภาพมีความละเอียดสูงมากอาจทำให้ต้องใช้เวลาในการลดมิติข้อมูล และในขั้นตอนการสร้างโมเดลที่ใช้ในการจำแนกข้อมูล ถ้าจำนวนข้อมูลภาพแต่ละชนิดมีจำนวนข้อมูลน้อยจะทำให้โมเดลที่ใช้ในการจำแนกข้อมูลจะให้ประสิทธิภาพที่ไม่ดี

ในอนาคตถ้านำเทคนิคการลดมิติข้อมูลแบบอื่นมาใช้งานร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน อาจทำให้โมเดลใหม่ที่ได้มีประสิทธิภาพสูงขึ้นกว่าเดิม



รายการอ้างอิง

- พรพล ชรรวมรงค์รัตน์, ลัดดา ปรีชาวีรกุล, และวิภาดา เวทย์ประสิทธิ์. (2551). การจำแนกประเภทเว็บเพจโดยใช้ค่าความถี่เอกสารและซัพพอร์ตเวกเตอร์แมชชีน [ออนไลน์]. ได้จาก: <http://www.ssruii.ssruii.ac.th/bitstream/ssruii/377/1/080-53.pdf>
- Ali, W., Shamsuddin, S.M., and Ismail A.S. (2011). Web Proxy Cache Content Classification based on Support Vector Machine. **Journal of Artificial Intelligence**. 4(1): 100-109.
- Alex M. M., and Avinash C. K. (2001). PCA versus LDA. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 23(2) : 28-233.
- Balakrishnama, S., and Ganapathiraju, A. (1998). **Linear discriminant analysis: a brief tutorial**. Mississippi State (MS): Institute for Signal and information Processing, Mississippi State University.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2): 121-167.
- Changjun, Z., Lan , W., Qiang, Z., and Xiaopeng, W.(2013) . Face recognition based on PCA image reconstruction and LDA. **International Journal for Light and Electron Optics** 124 : 5599–5603.
- Delac, K., and Grgic, M. (2004). A Survey of Biometric Recognition Methods. In **Proceedings of the 46th International Symposium on Electronics in Marine** (pp. 184-193).
- Dinh, M. V., and Young, L. S. (2005). Two-dimensional Weighted PCA algorithm for Face Recognition. In **Proceedings of the IEEE Symposium on Computational intelligence in Robotics and Automation** (pp. 219-223).
- Ergun G., Niyazi K., Ahmet S., and Osman N. U . (2010). Evaluation of face recognition techniques using PCA, wavelets and SVM. **Expert Systems with Applications** 37 : 6404–6408.
- Juwei L., Plataniotis, K.N., Venetsanopoulos, A.N. (2003). Boosting Linear Discriminant Analysis for Face Recognition. In **Proceedings IEEE International Conference on Image Processing** (pp. 657-660).

- Kresimir, D., Mislav, G., and Sonja, G. (2005). Independent Comparative Study of PCA, ICA, and LDA on the FERET Data Set. **International Journal of Imaging Systems and Technology** 15(5): 252–260.
- Lin, C., and Fan, K. (2004). Biometric verification using thermal images of palm- dorsa vein Patterns. **IEEE Transactions on Circuits and Systems for Video Technology**. 14(2): 199 –213.
- Li, Z., Bo, C., and Jing, Z. (2014). A comparative study of dimensionality reduction methods for large-scale image retrieval. **Journal of Neurocomputing**. 141: 202-210.
- Shah Zainudin, M.N., Radi H.R., S.Muniroh Abdullah., Rosman Abd. Rahim., M.Muzafar Ismail., M.Idzdihar Idris., H.A.Sulaiman., and Jaafar A. (2012). Face Recognition using Principle Component Analysis (PCA) and Linear Discriminant Analysis (LDA). **International Journal of Electrical & Computer Sciences IJECS-IJENS**. 12(5):50-55.
- Turk, M., and Pentland, A. (1991). Eigenfaces for recognition. **Journal of Cognitive Neuroscience**. 3: 71-86.
- Wankou, Y., Changyin S., Lei, Z., and Karl R. (2010). Laplacian bidirectional PCA for face recognition. **Journal of Neurocomputing** 74: 487–493.



ภาคผนวก ก

การใช้งานโปรแกรม

การใช้งานโปรแกรม

เนื้อหาส่วนนี้จะอธิบายการใช้งานของโปรแกรมสำหรับการปรับปรุงอัลกอริทึมซอฟต์แวร์
เวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์โดยจะมีวิธีการทำงานของโปรแกรม
ดังต่อไปนี้

1. การเตรียมข้อมูล

การใช้งาน โปรแกรมสำหรับจำแนกข้อมูลไบโอเมตริกซ์นี้จะสามารถใช้งานได้กับ
ไฟล์ข้อมูล .csv ดังนั้นเราจึงต้องทำการเตรียมข้อมูลภาพให้อยู่ในรูปแบบไฟล์ที่กำหนดไว้ก่อนใช้
งานโปรแกรม โดยวิธีการเตรียมข้อมูลจะทำการแปลงข้อมูลจากไฟล์ภาพให้เป็นอาร์เรย์ที่เก็บไว้
ในไฟล์ .csv ซึ่งในไฟล์ .csv ที่คอลัมน์แรกจะใส่ตัวเลขที่เป็นคลาสเป้าหมายของภาพไว้ (target)
ซึ่งขั้นตอนการเตรียมข้อมูลมีรายละเอียดดังต่อไปนี้

- 1) ทำการอ่านข้อมูลภาพเข้ามาในโปรแกรมจากนั้นดึงค่าสีแต่ละจุดบนภาพในแต่ละแถว
มาเรียงต่อกันให้เป็นข้อมูลตัวเลขที่เป็นอาร์เรย์ 1 แถวคือ 1 ภาพ



[[119 90 111 97 110 103 111 95 104 100..., 104 107 103 21 22 21 105 107 106 106]]

รูปที่ ก.1 แสดงตัวอย่างการดึงค่าสีของภาพ

2) ทำการบันทึกข้อมูลอาร์เรย์ลงในไฟล์ .csv

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
1	22	22	28	28	20	23	26	17	21	19	17	16	15	15	16	16	20	7	38	27	16
2	15	16	24	25	18	21	24	16	15	12	12	16	17	16	17	21	13	6	28	14	2
3	21	24	31	26	17	24	29	20	13	14	15	15	14	15	18	21	21	18	12	29	16
4	30	27	29	26	23	33	34	20	28	20	15	19	22	20	16	15	25	14	23	27	15
5	16	14	20	21	15	18	21	11	10	11	11	9	8	9	12	15	13	3	14	27	30
6	14	14	20	20	13	17	22	15	9	6	4	6	11	14	14	13	21	10	3	15	32
7	23	20	25	25	20	24	25	14	19	16	14	13	15	18	19	20	9	33	2	32	19
8	25	24	29	27	18	21	25	17	16	15	14	11	10	11	14	18	8	17	27	32	0
9	14	15	22	21	12	17	23	17	16	14	12	11	13	15	15	15	2	18	14	23	30
10	15	18	21	20	18	17	20	23	19	16	14	15	13	11	13	19	13	11	30	14	26
11	19	27	33	32	29	29	28	26	18	19	18	16	14	14	17	19	21	26	15	15	24
12	21	18	25	28	21	22	27	22	20	15	13	14	14	14	17	22	23	24	18	32	52
13	16	18	22	26	27	24	19	15	18	12	9	12	14	15	18	22	19	15	22	24	26
14	33	25	26	25	18	21	27	23	18	17	16	14	13	16	21	26	15	22	28	28	51
15	24	31	32	39	28	20	33	24	22	20	18	18	19	20	20	19	12	30	21	26	33
16	25	25	35	39	30	28	31	26	27	22	19	19	17	17	22	29	26	22	17	31	35
17	20	17	22	21	14	18	21	12	6	12	15	11	12	17	20	18	16	23	18	7	58
18	26	32	35	32	30	30	28	25	24	18	16	19	20	20	22	26	38	40	46	44	27
19	23	29	26	31	23	23	41	31	22	18	16	18	20	20	24	30	19	37	51	30	30
20	18	22	22	19	19	22	21	18	18	12	8	11	13	15	18	23	9	25	31	38	45
21	23	22	25	29	25	18	19	25	19	19	18	14	10	11	16	22	19	29	45	24	19
22	16	21	23	22	22	24	23	19	14	14	15	16	13	11	19	29	19	39	20	15	29
23	25	19	27	34	25	20	25	27	14	13	13	12	9	9	19	30	17	18	25	21	50
24	12	17	22	23	21	18	19	20	21	16	14	16	16	15	17	22	19	38	13	31	51
25	25	28	32	36	36	31	25	20	23	20	18	18	18	17	22	29	25	21	24	39	54
26	19	25	32	36	35	32	29	28	22	18	16	16	14	12	15	21	17	27	21	19	33

รูปที่ ก.2 แสดงตัวอย่างข้อมูลไฟล์ .csv

3) เปิดไฟล์ .csv โดยโปรแกรม Microsoft Excel แทรกคอลัมน์แรกแล้วใส่ค่าคลาสของภาพแต่ละภาพเสร็จแล้วบันทึกไฟล์

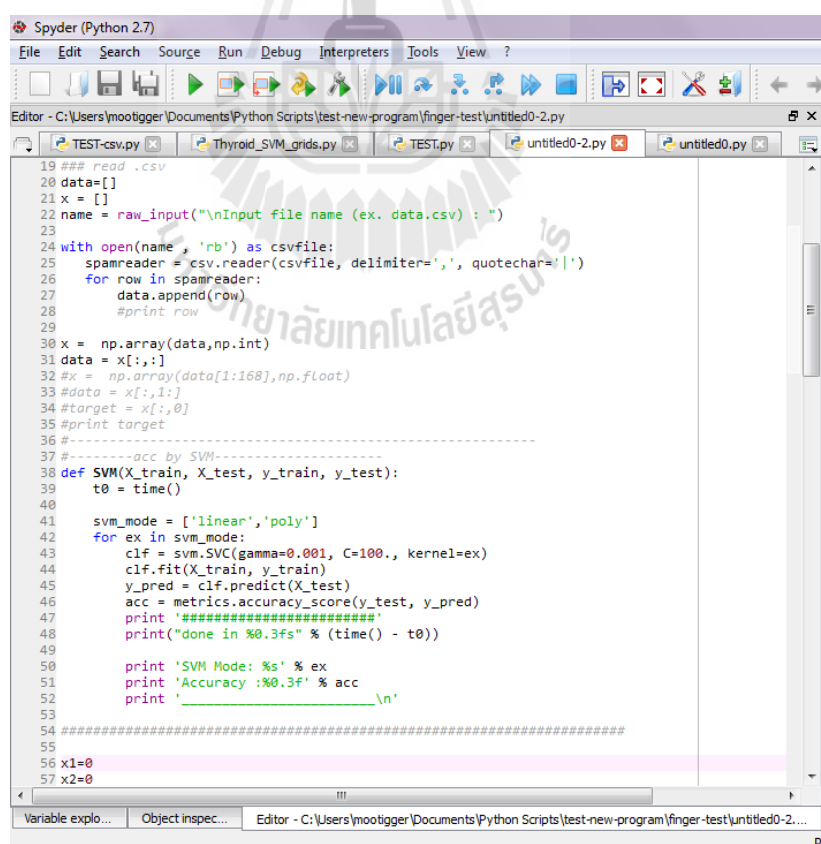
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
1	1	22	22	28	28	20	23	26	17	21	19	17	16	15	15	16	16	20	7	38	27
2	1	15	16	24	25	18	21	24	16	15	12	12	16	17	16	17	21	13	6	28	14
3	1	21	24	31	26	17	24	29	20	13	14	15	15	14	15	18	21	21	18	12	29
4	1	30	27	29	26	23	33	34	20	28	20	15	19	22	20	16	15	25	14	23	27
5	1	16	14	20	21	15	18	21	11	10	11	11	9	8	9	12	15	13	3	14	27
6	1	14	14	20	20	13	17	22	15	9	6	4	6	11	14	14	13	21	10	3	15
7	1	23	20	25	25	20	24	25	14	19	16	14	13	15	18	19	20	9	33	2	32
8	1	25	24	29	27	18	21	25	17	16	15	14	11	10	11	14	18	8	17	27	32
9	2	14	15	22	21	12	17	23	17	16	14	12	11	13	15	15	15	2	18	14	23
10	2	15	18	21	20	18	17	20	23	19	16	14	15	13	11	13	19	13	11	30	14
11	2	19	27	33	32	29	29	28	26	18	19	18	16	14	14	17	19	21	26	15	15
12	2	21	18	25	28	21	22	27	22	20	15	13	14	14	14	17	22	23	24	18	32
13	2	16	18	22	26	27	24	19	15	18	12	9	12	14	15	18	22	19	15	22	24
14	2	33	25	26	25	18	21	27	23	18	17	16	14	13	16	21	26	15	22	28	28
15	2	24	31	32	39	28	20	33	24	22	20	18	18	19	20	20	19	12	30	21	26
16	2	25	25	35	39	30	28	31	26	27	22	19	19	17	17	22	29	26	22	17	31
17	3	20	17	22	21	14	18	21	12	6	12	15	11	12	17	20	18	16	23	18	7
18	3	26	32	35	32	30	30	28	25	24	18	16	19	20	20	22	26	38	40	46	44
19	3	23	29	26	31	23	23	41	31	22	18	16	18	20	20	24	30	19	37	51	30
20	3	18	22	22	19	19	22	21	18	18	12	8	11	13	15	18	23	9	25	31	38
21	3	23	22	25	29	25	18	19	25	19	19	18	14	10	11	16	22	19	29	45	24
22	3	16	21	23	22	22	24	23	19	14	14	15	16	13	11	19	29	19	39	20	15
23	3	25	19	27	34	25	20	25	27	14	13	13	12	9	9	19	30	17	18	25	21
24	3	12	17	22	23	21	18	19	20	21	16	14	16	16	15	17	22	19	38	13	31
25	4	25	28	32	36	36	31	25	20	23	20	18	18	18	17	22	29	25	21	24	39
26	4	19	25	32	36	35	32	29	28	22	18	16	16	14	12	15	21	17	27	21	19

รูปที่ ก.3 แสดงตัวอย่างการใส่ข้อมูลคลาสที่คอลัมน์แรก

2. การใช้งานในส่วนโปรแกรม

ในขั้นตอนนี้จะใช้ไฟล์ .csv ที่เตรียมไว้ในการทำงาน โดยไฟล์ .csv ต้องอยู่ในโฟลเดอร์เดียวกับไฟล์ .py ของโปรแกรม ซึ่งการทำงานมีขั้นตอนการใช้งานดังต่อไปนี้

- 1) เมื่อคลิกเริ่ม โปรแกรมจะให้ใส่ชื่อไฟล์ .csv
- 2) หลังจากใส่ชื่อไฟล์แล้ว โปรแกรมจะทำการแยกชนิดของข้อมูลแต่ละแถวในไฟล์ .csv เพื่อตรวจสอบว่าข้อมูลแต่ละแถวนั้นเป็นข้อมูลประเภทใด
- 3) หลังจากแยกประเภทแล้ว โปรแกรมจะให้ใส่จำนวนองค์ประกอบ
- 4) เมื่อใส่จำนวนองค์ประกอบแล้ว โปรแกรมจะนำข้อมูลเข้าอัลกอริทึมสำหรับการลดมิติข้อมูล
- 5) หลังจากได้ข้อมูลที่ลดมิติแล้วจะนำข้อมูลเข้าอัลกอริทึม SVM แล้วจะได้ค่าความแม่นยำและเวลาในการประมวลผลออกมา



```

19 ## read .csv
20 data=[]
21 x = []
22 name = raw_input("\nInput file name (ex. data.csv) : ")
23
24 with open(name, 'rb') as csvfile:
25     spamreader = csv.reader(csvfile, delimiter=',', quotechar='|')
26     for row in spamreader:
27         data.append(row)
28         #print row
29
30 x = np.array(data,np.int)
31 data = x[:,:]
32 #x = np.array(data[1:168],np.float)
33 #data = x[:,1:]
34 #target = x[:,0]
35 #print target
36 #-----
37 #-----acc by SVM-----
38 def SVM(X_train, X_test, y_train, y_test):
39     t0 = time()
40
41     svm_mode = ['linear','poly']
42     for ex in svm_mode:
43         clf = svm.SVC(gamma=0.001, C=100., kernel=ex)
44         clf.fit(X_train, y_train)
45         y_pred = clf.predict(X_test)
46         acc = metrics.accuracy_score(y_test, y_pred)
47         print '#####'
48         print("done in %0.3fs" % (time() - t0))
49
50         print 'SVM Mode: %s' % ex
51         print 'Accuracy :%0.3f' % acc
52         print '_____\n'
53
54 #####
55
56 x1=0
57 x2=0

```

รูปที่ ก.4 แสดงตัวอย่างโปรแกรมในส่วนโค้ด

```

C:\Users\mootigger\Documents\Python Scripts
Console
Python 1 00:12:42
done in 0.094s
SVM Mode: linear
Accuracy :0.214

#####
done in 0.094s
SVM Mode: poly
Accuracy :0.119

>>> runfile('C:/Users/mootigger/Documents/Python Scripts/test-new-program/finger-test/untitled0-2.py', wdir='C:/Users/mootigger/Documents/Python Scripts/test-new-program/finger-test')

Input file name (ex. data.csv) : data_finger.csv

+++++
Data is Physiological Biometrics

Input component : 2

done in 0.518s
#####
done in 0.250s
SVM Mode: linear
Accuracy :0.310

#####
done in 0.250s
SVM Mode: poly
Accuracy :0.095

>>>

```

รูปที่ ก.5 แสดงตัวอย่าง โปรแกรมในส่วนผลการรันโปรแกรม

```

Input file name (ex. data.csv) : data_finger.csv

+++++
Data is Physiological Biometrics

Input component : 1

done in 0.519s
#####
done in 0.094s
SVM Mode: linear
Accuracy :0.214

#####
done in 0.109s
SVM Mode: poly
Accuracy :0.119

>>> |

```

รูปที่ ก.6 แสดงตัวอย่างผลการรันโปรแกรม



ภาคผนวก ข

รหัสต้นฉบับของโปรแกรม

โปรแกรมการปรับปรุงอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนสำหรับการจำแนกข้อมูลภาพไบโอเมตริกซ์

```

import numpy as np
from sklearn import svm
from sklearn import metrics
import csv
from time import time
from sklearn.cross_validation import train_test_split
from sklearn.decomposition import RandomizedPCA
from sklearn.lda import LDA

#-----read .csv-----
data=[]
x = []
name = raw_input("\nInput file name (ex. data.csv) : ")

with open(name , 'rb') as csvfile:
    spamreader = csv.reader(csvfile, delimiter=',', quotechar='"')
    for row in spamreader:
        data.append(row)
x = np.array(data,np.int)
data = x[:,:]

#-----acc by SVM-----
def SVM(X_train, X_test, y_train, y_test):
    t0 = time()
    svm_mode = ['linear','poly']
    for ex in svm_mode:
        clf = svm.SVC(gamma=0.001, C=100., kernel=ex)

```

```

        clf.fit(X_train, y_train)

        y_pred = clf.predict(X_test)

        acc = metrics.accuracy_score(y_test, y_pred)

        print '#####'

        print("done in %0.3fs" % (time() - t0))

        print 'SVM Mode: %s' % ex

        print 'Accuracy :%0.3f' % acc

        print '_____ \n'

#-----
x1=0
x2=0
check1 = False
check2 = False

for x in range(0,len(data)):
    check=0
    for y in range(0,64):
        check=check+data[x,y]
    check=check/64

#-----signature-----
    if check>=220:
        check1 = True
        if x1==0:
            imgarr1 = np.array([data[x]])
            x1=x1+1
        else:
            X = np.array([data[x]])
            imgarr1= np.concatenate(( imgarr1,X ))
            x1=x1+1

```

```

#-----face or fingerprint-----
    else:
        check2 = True
        if x2==0:
            imgarr2 = np.array([data[x]])
            x2=x2+1
        else:
            X = np.array([data[x]])
            imgarr2 = np.concatenate((imgarr2,X))
            x2=x2+1

#-----signature use SVM -----
c1=0
if check1==True:
    print
    "\ndata_finger.csv+++++++"
    print "Data is Behavioural Biometrics"
    for x in range(0,len(imgarr1)):
        if c1==0:
            target1=np.array([imgarr1[x][0]])
            c1=c1+1
        else:
            T1 = np.array([imgarr2[x][0]])
            target1 = np.concatenate((target1,T1))
            c1=c1+1

    imgarr1 = np.delete(imgarr1,[0], axis=1)

#----- Split into a training set and a test set using a stratified k fold-----
    X_train, X_test, y_train, y_test = train_test_split( imgarr1, target1, test_size=0.25,
    random_state=42)

```

```

#----- Use SVM-----

    t0 = time()

    SVM(X_train, X_test, y_train, y_test)

    print("done in %0.3fs" % (time() - t0))

#-----face or fingerprint -----

c2=0

if check2==True:

    print

"\n+++++++"

    print "Data is Physiological Biometrics"

    for x in range(0,len(imgarr2)):

        if c2==0:

            target2=np.array([imgarr2[x][0]])

            c2=c2+1

        else:

            T2 = np.array([imgarr2[x][0]])

            target2 = np.concatenate((target2,T2))

            c2=c2+1

    imgarr2 = np.delete(imgarr2,[0], axis=1)

# -----Split into a training set and a test set using a stratified k fold-----

    X_train, X_test, y_train, y_test = train_test_split( imgarr2, target2, test_size=0.25,

    random_state=42)

# -----Use dimension reduce by LDA -----

    component1 = int(raw_input("\nInput component : "))


    t0 = time()

    n_component =[component1]

    print "\n"

```

```
for c in n_component:  
    lda = LDA(n_components=c)  
    lda.fit(X_train,y_train)  
    X_train = lda.transform(X_train)  
    X_test = lda.transform(X_test)  
    print("done in %0.3fs" % (time() - t0))  
SVM(X_train, X_test, y_train, y_test)
```



ภาคผนวก ค

บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา



รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

รติพร จันทร์กลิ่น, อนุสรฯ หิรัญวานากุล, กิตติศักดิ์ เกิดประสพ, นิตยา เกิดประสพ. 2557. การจำแนกหน้าชายหญิงโดยใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน. ในการประชุมวิชาการระดับชาติมหาวิทยาลัยเทคโนโลยีราชมงคล ครั้งที่ 6. มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ ศูนย์หันตรา. 23 - 25 กรกฎาคม 2557

อนุสรฯ หิรัญวานากุล, รติพร จันทร์กลิ่น, กิตติศักดิ์ เกิดประสพ, นิตยา เกิดประสพ. 2557. การศึกษาเปรียบเทียบเทคนิคเพื่อเพิ่มประสิทธิภาพโมเดลจำแนกภาพ. ในการประชุมวิชาการระดับชาติมหาวิทยาลัยเทคโนโลยีราชมงคล ครั้งที่ 6. มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ ศูนย์หันตรา. 23 - 25 กรกฎาคม 2557

รติพร จันทร์กลิ่น, กิตติศักดิ์ เกิดประสพ, นิตยา เกิดประสพ. 2557. การศึกษาวิธีการลดมิติเพื่อเพิ่มความเร็วในการจำแนกใบโอเมตริกซ์. ในการประชุมวิชาการระดับชาติ “มศว วิจัย” ครั้งที่ 8. มหาวิทยาลัยศรีนครินทรวิโรฒ. 26-27 พฤศจิกายน 2557

Ratiporn Chanklan, Kedkarn Chaiyakhan, Anusara Hirunyananakul, Kittisak Kerdprasop, Nittaya Kerdprasop. 2015. Fingerprint Recognition with Edge Detection and Dimensionality Reduction Techniques. In **Proceedings of the 3rd International Conference on Industrial Application Engineering 2015**, Kitakyushu, Japan. 28-31 Mach 2015.

Kedkarn Chaiyakhan, Anusara Hirunyananakul, Ratiporn Chanklan, Kittisak Kerdprasop, Nittaya Kerdprasop. 2015. Traffic Sign Classification using Support Vector Machine and Image Segmentation. In **Proceedings of the 3rd International Conference on Industrial Application Engineering 2015**, Kitakyushu, Japan. 28-31 Mach 2015.

Anusara Hirunyananakul, Kedkarn Chaiyakhan, Ratiporn Chanklan, Kittisak Kerdprasop, Nittaya Kerdprasop. 2015. A New Efficient Method to Improve Handwritten Signature Recognition. In **Proceedings of the 3rd International Conference on Industrial Application Engineering 2015**, Kitakyushu, Japan. 28-31 Mach 2015.

การจำแนกหน้าชายหญิงโดยใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน
Male-Female Face Classification Using Support Vector Machine Algorithm

รติพร จันทร์กลิ่น^{*}, อุนสุรา หิรัญวานากุล, กิตติศักดิ์ เกิดประสพ, นิตยา เกิดประสพ
 Ratipom Chanklan, Anusara Nunyuang, Kittisak Kerdprasop, Nittaya Kerdprasop

บทคัดย่อ

งานวิจัยนี้นำเสนอวิธีการจำแนกรูปใบหน้าระหว่างชาย-หญิง ด้วยอัลกอริทึม ซัพพอร์ตเวกเตอร์แมชชีนโดยงานวิจัยจะมุ่งเน้น การปรับปรุงโมเดลเพื่อให้ตรวจจับรูปใบหน้าที่ตรวจจับได้ยากและถ้ารูปบางรูปมีจำนวนน้อย จะต้องสามารถตรวจจับได้ถูกต้องมากที่สุด เทคนิคการปรับปรุงโมเดลเพื่อให้การจำแนกรูปใบหน้าที่มีประสิทธิภาพสูงขึ้นประกอบด้วย 3 วิธี ได้แก่ วิธีการปรับอัตราส่วนระหว่างหน้าชาย-หญิงให้สมดุล, วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดล และ วิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัดเพื่อใช้ในโมเดล การทดสอบประสิทธิภาพจะใช้วิธีการเปรียบเทียบความแม่นยำในการจำแนก โดยเทียบกับวิธีการดั้งเดิมที่ไม่มีการปรับปรุงโมเดล ผลการทดลองพบว่าการปรับปรุงโมเดลด้วยวิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดลให้ความแม่นยำเพิ่มขึ้นจาก 50% เป็น 85%

คำสำคัญ: การจำแนกใบหน้าระหว่างชายและหญิง, ซัพพอร์ตเวกเตอร์แมชชีน, ภาษาไพธอน

Abstract

This research demonstrates a method of classification between male and female faces using support vector machine algorithm. It focuses on improving the model to detect faces that are difficult to detect and if the number of some pictures is limited, the method is able to classify faces with high accuracy. The proposed techniques to improve classification accuracy are balancing male-female ratio, using obvious female face shape, and using unobvious female shape. To evaluate efficiency of the proposed techniques, we compare classification accuracy of the models obtained from the proposed three techniques against the traditional face classification method. From the experimental results, we found that the use of obvious female face shape can improve model accuracy from 50% to 85%.

Keywords: classification between male and female faces, Support Vector Machine, Python language

สาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี นครราชสีมา 30000
 School of Computer Engineering, Institute of Engineering, Suranaree University of Technology,
 Nakhon Ratchasima, Thailand.

^{*}Corresponding author. E-mail: mootigger@gmail.com

1. บทนำ

ในปัจจุบันรูปภาพดิจิทัลได้เพิ่มปริมาณขึ้นอย่างรวดเร็วด้วยเทคโนโลยีทางการถ่ายภาพนั้นได้พัฒนาขึ้นอย่างต่อเนื่อง และหลากหลาย รูปถ่ายเหล่านี้จะถูกเก็บไว้อย่างกระจัดกระจาย ดังนั้นการจัดกลุ่มหรือจำแนกนั้นจะเป็นไปได้ยากเนื่องจากโดยปกติแล้วคอมพิวเตอร์ไม่สามารถมองวัตถุแล้วสามารถบอกได้ว่าวัตถุนั้นคืออะไร ซึ่งแตกต่างจากมนุษย์ที่มองรูปภาพแล้วสามารถบอกได้ทันที ดังนั้นจึงได้มีการนำวิธีการ และ โมเดลต่าง ๆ ในเชิงวิชาการเข้ามาช่วยในการแก้ปัญหาดังกล่าว

ระบบรู้จำใบหน้าถูกออกแบบมาให้ทำการเปรียบเทียบใบหน้าบุคคลที่ตรวจจับมาทำการประมวลผลแล้วนำมาเปรียบเทียบกับฐานข้อมูล ซึ่งถือว่าเป็นเทคนิคการจำแนกรูปภาพที่สามารถนำมาใช้ให้เกิดประโยชน์ในชีวิตประจำวันได้ เช่น “การจำแนกใบหน้าระหว่างคนที่ยิ้มและไม่ยิ้ม” เพื่อใช้ประโยชน์ในการตั้งโปรแกรมถ่ายรูปแบบอัตโนมัติซึ่งมีการนำ “การจำแนกใบหน้าของแต่ละบุคคล” เพื่อระบุตัวตนในการ Log-on อุปกรณ์อิเล็กทรอนิกส์ส่วนตัว เช่น คอมพิวเตอร์ และ โทรศัพท์มือถือ ซึ่งทางผู้วิจัยได้เล็งเห็นถึงประโยชน์ในการจำแนก “ใบหน้าระหว่างชายและหญิง” เช่นการแต่งรูปภาพเฉพาะใบหน้าของเพศใดเพศหนึ่งในรูปหมู่หรือการนำไปใช้ช่วยสืบสวนคดีอาชญากรรมต่าง ๆ ซึ่งงานวิจัยชิ้นนี้ได้นำเสนอเทคนิคการเพิ่มประสิทธิภาพโมเดลเพื่อการจำแนกใบหน้าจากภาพถ่ายของหญิงและชาย ซึ่งจากการค้นคว้างานวิจัยที่เกี่ยวข้องยังไม่พบงานวิจัยในด้านนี้โดยตรง ทางผู้วิจัยจึงนำเสนอเทคนิคการจำแนกภาพถ่ายของหญิงและชาย ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) ซึ่งเป็นอัลกอริทึมในการคัดแยกที่มีความชัดเจนในการแบ่งมากและมีการนำมาใช้กันอย่างกว้างขวางในด้านการประมวลผลและการจำแนกภาพดิจิทัล โดยมุ่งเน้นการปรับปรุงโมเดลเพื่อให้มีความถูกต้องมากขึ้น

วัตถุประสงค์ของงานวิจัย

งานวิจัยชิ้นนี้มีวัตถุประสงค์เพื่อศึกษาการจำแนกใบหน้าระหว่างชาย-หญิงด้วย เทคนิค Support Vector Machine (SVM) เพื่อที่จะพยายามตรวจจับรูปใบหน้าที่มีความคล้ายคลึงกันทำให้ตรวจจับยากให้ตรวจจับได้ถูกต้อง และถ้ารูปบางรูปมีจำนวนน้อยทำให้มีการตรวจจับได้ยาก ซึ่งผู้วิจัยพยายามจะแก้ไขปัญหาโดยจะมุ่งเน้นไปที่การปรับปรุงโมเดลด้วยวิธีการต่างๆ เช่น การปรับอัตราส่วนระหว่างจำนวนใบหน้าของผู้ชาย และ ผู้หญิง หรือการเลือกใบหน้าผู้หญิงที่มีความเด่นชัดเพื่อใช้ในการสร้างโมเดลเพื่อให้โมเดลมีความแม่นยำมากยิ่งขึ้น

2. งานวิจัยและทฤษฎีที่เกี่ยวข้อง

2.1 การรู้จำใบหน้า (Face recognition)

ระบบรู้จำใบหน้า[3] ถูกออกแบบมาให้ทำการเปรียบเทียบใบหน้าบุคคลที่ตรวจจับได้และประมวลผลแล้วจากขั้นตอนการตรวจ มาเปรียบเทียบกับฐานข้อมูลใบหน้าที่มีอยู่เพื่อระบุว่าใบหน้าที่ตรวจจับได้ตรงกับบุคคลใดโดยอัลกอริทึมที่ใช้ในขั้นตอนการสร้างแม่แบบและขั้นตอนการเปรียบเทียบอาจแตกต่างกันไปแล้วแต่การออกแบบระบบของแต่ละระบบ

ระบบรู้จำใบหน้าจะประกอบไปด้วย 2 ขั้นตอนคือ

2.1.1 การตรวจจับใบหน้า (Face Detection) คือกระบวนการค้นหาใบหน้าของบุคคลจากภาพหรือวิดีโอ หลังจากนั้นก็จะทำการประมวลผลภาพใบหน้าที่ได้สำหรับขั้นตอนถัดไปเพื่อให้ภาพใบหน้าที่ตรวจจับได้

ง่ายต่อการจำแนก ในขั้นตอนการตรวจจับใบหน้าที่ดี ต้องมีความแม่นยำและรวดเร็วในการค้นหารูป ใบหน้าในระบบโดยจะอาศัย อัลกอริทึมต่าง ๆ มาช่วยในการแบ่งแยกและจำแนกใบหน้า

2.1.2 การรู้จำใบหน้า (Face Recognition) คือกระบวนการที่ได้นำภาพใบหน้าที่ตรวจจับได้และนำไปประมวลผลแล้วจากขั้นตอนการตรวจจับใบหน้ามาเปรียบเทียบกับฐานข้อมูลของใบหน้าเพื่อระบุใบหน้า ที่ตรวจจับได้ตรงกับบุคคลใด

2.2 อัลกอริทึมการจำแนกประเภท (Classification Algorithm)

การจำแนกข้อมูลจัดเป็นการทำเหมืองข้อมูล ที่สำคัญเทคนิคหนึ่ง เป็นกระบวนการสร้างโมเดล จัดการข้อมูลให้อยู่ในกลุ่มที่กำหนดมาให้ โดยการสร้างกฎ หรือโมเดลในรูปแบบอื่น ๆ เพื่อช่วยในการตัดสินใจจากข้อมูลที่มีอยู่ เพื่อให้ทำนายแนวโน้มการเกิดขึ้นของข้อมูลที่ยังไม่เกิดขึ้น การจำแนกข้อมูล ประเภทเรียนรู้แบบมีผลเฉลย (Supervised Learning) สามารถแบ่งขั้นตอนวิธีการจำแนกประเภทได้เป็น 2 ขั้นตอนคือ การเรียนรู้เพื่อสร้างกลุ่มต้นแบบและ จำแนกประเภทของกลุ่มตัวอย่างที่สนใจ โดยการ ตรวจสอบหาความคล้ายกับกลุ่มตัวอย่างต้นแบบ

งานวิจัยนี้ศึกษากระบวนการรู้จำใบหน้า โดยใช้ซัพพอร์ตเวกเตอร์แมชชีน หรือ SVM เป็นอัลกอริทึมหลัก ในการจำแนกประเภทใบหน้าบุคคล เป็นอัลกอริทึมในการตัดแยกที่มีการนำมาใช้กันอย่างกว้างขวางใน ด้านการประมวลผลเป็นภาพดิจิทัล [2], [4] แนวคิดหลักของวิธีการนี้ใช้เพื่อหาระนาบการตัดสินใจในการ แบ่งข้อมูลออกเป็นสองกลุ่ม โดยจะพยายามสร้างเส้นแบ่งตรงกึ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่าง ขอบเขตของทั้งสองกลุ่มมากที่สุด SVM จะใช้ฟังก์ชันแม่สำหรับย้ายข้อมูลจาก Input Space ไปยัง Feature Space และสร้างฟังก์ชันวัดความคล้ายที่เรียกว่าเคอร์เนลฟังก์ชัน (Kernel Function) บน Feature Space เหมาะใช้สำหรับข้อมูลที่มีมิติของข้อมูลสูง

กำหนดให้ $(x_1, y_1), \dots, (x_n, y_n)$ เป็นข้อมูลตัวอย่างที่ใช้สำหรับการสอน n คือจำนวนข้อมูลตัวอย่าง m คือจำนวนมิติข้อมูลเข้าและ y คือผลลัพธ์มีค่า $+1$ หรือ -1

เมื่อ $+1$ แทนกลุ่มของสมาชิกจำนวนเต็มบวก และ -1 แทนกลุ่มของสมาชิกจำนวนเต็มลบ ดังสมการ ต่อไปนี้

$$(x_i, y_i), \dots, (x_n, y_n) \text{ เมื่อ } x \in R^m, y \in \{+1, -1\}$$

สำหรับปัญหาเชิงเส้น 2 มิติ สามารถคำนวณได้ ดังสมการ

$$(w * x) + b$$


เมื่อ w คือค่าน้ำหนักและ b คือค่า bias สมการใช้สำหรับจำแนกประเภทของข้อมูล ได้แก่

$$(w * x) + b > 0 \text{ ถ้า } y_i = +1 \text{ และ } (w * x) + b < 0 \text{ ถ้า } y_i = -1$$

โดย SVM มีเคอร์เนลฟังก์ชัน ให้ผู้ใช้สามารถประยุกต์ใช้ในการแก้ปัญหาได้หลายฟังก์ชัน เช่น Linear, Polynomial, Radial Basis Function โดยงานวิจัยนี้ได้ใช้ Linear Kernel ในการทดลอง

ยกตัวอย่างง่าย ๆ จากรูปที่ 1 หากเราต้องการตัดแยกข้อมูลออกเป็น 2 กลุ่ม กลุ่มที่เป็นวงกลม และกลุ่มที่เป็นสี่เหลี่ยม โดยใช้เส้นแบ่งที่เป็นเส้นตรง จะพบว่ามีเส้นตรงจำนวนมากที่สามารถตัดแยกกลุ่ม ทั้งสองออกจากกันได้ เราจะนิยาม Margin เป็นผลรวมระยะห่างของเส้นตรงที่เป็นเส้นแบ่ง ถึงเส้นตรงที่

ผ่านข้อมูลที่ใกล้ที่สุดและขนานกับเส้นแบ่งของทั้งสองกลุ่ม ซึ่งหากเราใช้โมเดลอื่นในการแบ่งกลุ่มเราอาจได้รูปร่างฝั่งซ้ายซึ่งสามารถแบ่งกลุ่มได้ก็จริง แต่จะมีระยะขอบที่ค่อนข้างแคบ (Small margin) แต่หากเราเลือกใช้โมเดลซัพพอร์ตเวกเตอร์แมชชีนในการแบ่งกลุ่ม เราจะได้รูปร่างฝั่งขวา ซึ่งนอกจากจะแบ่งกลุ่มทั้งสองได้แล้วนั้น โมเดลยังทำให้เกิดระยะขอบที่กว้างขึ้นอีกด้วย (Large margin)



รูปที่ 1 ตัวอย่าง SVM ในสองมิติ

แหล่งที่มา: <http://www.dtrek.com/svm.htm>

2.3 Confusion Matrix

Confusion Matrix [1] คือการประเมินผลลัพธ์การทำนายของโมเดล หรือผลลัพธ์จากโปรแกรม (Predicted Labels) เปรียบเทียบกับผลลัพธ์จริงๆ ที่ทำโดยคน หรือจากผลเฉลยที่ทราบค่าที่แท้จริงอยู่ก่อนแล้ว (Actual Labels)

ในกรณีที่มีข้อมูลจำแนกประเภทได้เป็น 2 กลุ่มคือ Positive และ Negative ค่าที่ได้จาก Confusion Matrix จะมี 4 ค่า (รูปที่ 2) ได้แก่

True Positive (TP) คือ สิ่งที่โปรแกรมทำนายว่าจริงและคนบอกว่ามันจริง ถือว่าเป็นการทำนายถูก

True Negative (TN) คือ สิ่งที่โปรแกรมทำนายว่าไม่จริงและคนบอกว่ามันไม่จริง ถือว่าเป็นการทำนายถูก

False Positive (FP) คือ สิ่งที่โปรแกรมทำนายว่าจริงแต่คนบอกว่ามันไม่จริง ถือว่าเป็นการทำนายผิด

False Negative (FN) คือ สิ่งที่โปรแกรมทำนายว่าไม่จริงแต่คนบอกว่ามันจริง ถือว่าเป็นการทำนายผิด

		Predicted Labels :	
		True	False
Actual Labels :	True	TP	FN
	False	FP	TN

รูปที่ 2 ตาราง Confusion Matrix

ในงานวิจัยชิ้นนี้จะใช้มาตรวัดที่คำนวณได้จาก Confusion Matrix ด้วยกัน 3 มาตรวัด ได้แก่ Accuracy, Recall และ Precision

2.3.1 Accuracy คือ ค่าความแม่นยำที่บอกว่าโปรแกรมทำนาย สามารถสร้างโมเดลที่ใช้ทำนายข้อมูลได้ถูกต้องขนาดไหน

$$\text{ค่าความแม่นยำคำนวณได้จาก } (TP + TN) / (TP + TN + TP + FN)$$

2.3.2 Recall (True Positive Rate) คือ ค่าระลึทที่บอกว่าโปรแกรมทำนายได้ว่าข้อมูลเป็นประเภท positive จริง เป็นอัตราส่วนเท่าไรของข้อมูลจริงในกลุ่ม positive ทั้งหมด


$$\text{ค่าระลึทนี้ คำนวณได้จาก } TP / (TP + FN)$$

2.3.3 Precision คือ ค่าความเที่ยงที่บอกว่าโปรแกรมทำนายว่าข้อมูลเป็นประเภท positive ได้เที่ยงตรงมากน้อยเพียงใด โดยการทำนายผิดที่ระบุข้อมูลเป็น positive ทั้งที่ข้อมูลนั้นมีประเภทที่แท้จริงเป็น negative จะส่งผลให้ค่าความเที่ยงของการทำนายลดลง

$$\text{ค่าความเที่ยงนี้ คำนวณได้จาก } TP / (TP + FP)$$





3. ขั้นตอนดำเนินงานวิจัย

งานวิจัยชิ้นนี้ ใช้ฐานข้อมูลที่เป็นรูปใบหน้าคนจาก <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html> จำนวน 400 รูป เป็นรูปใบหน้าผู้ชายจำนวน 360 รูปและ 40 รูปที่เหลือเป็นรูปใบหน้าผู้หญิง ซึ่งทั้งหมด 400 รูปนี้มีความละเอียด 64x64 pixels (4096 pixels) โมเดลจำแนกใบหน้าในงานวิจัยนี้ จะทำขึ้นเพื่อแบ่งแยกรูปใบหน้าระหว่างชาย-หญิง โดยใช้อัลกอริทึม SVM และเรียกโมเดลที่ได้จากอัลกอริทึม SVM นี้ว่าโมเดลด้วยวิธีการดั้งเดิม (Traditional Method) จากนั้นผู้วิจัยทำการปรับปรุงคุณภาพการจำแนกของโมเดลด้วยวิธีการต่าง ๆ 3 วิธีคือ วิธีการปรับอัตราส่วนระหว่างหน้าชาย-หญิงให้สมดุล (Balancing Male-Female Ratio), วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดล (Using obvious female face shape) และ วิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัดเพื่อใช้ในโมเดล (Using unobvious female face shape) แผนภาพการดำเนินงานแสดงได้ ดังรูปที่ 3 และตัวอย่างภาพใบหน้าชาย-หญิงที่มีลักษณะชัดเจนและไม่ชัดเจน แสดงได้ดังตารางที่ 1



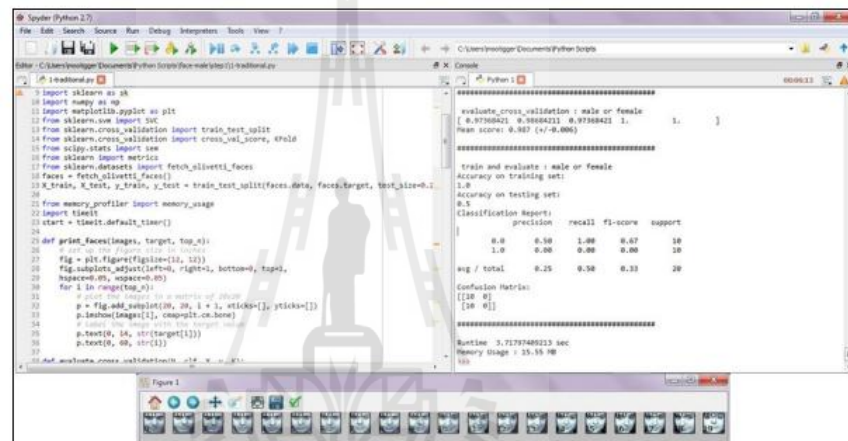
รูปที่ 3 โครงร่างขั้นตอนการดำเนินงาน

ตารางที่ 1 ตัวอย่างรูปใบหน้าที่มีลักษณะการบ่งบอกเพศที่ชัดเจน และไม่ชัดเจน

เพศ ลักษณะรูป	ชัดเจน	ไม่ชัดเจน
ชาย		
หญิง		

4. ผลการทดลอง

จากข้อมูลรูปใบหน้าทั้งหมด 400 รูป ผู้วิจัยใช้ภาษา python 2.7 เขียนโปรแกรม spyder ดังจะเห็นตัวอย่างได้จากรูปที่ 4 และได้ผลการทดลองดังต่อไปนี้



```

1 import sklearn as sk
2 import numpy as np
3 import matplotlib.pyplot as plt
4 from sklearn.svm import SVC
5 from sklearn.cross_validation import train_test_split
6 from sklearn.cross_validation import cross_val_score, cross_val_predict
7 from sklearn.metrics import accuracy_score
8 from sklearn import svm
9 from sklearn import datasets
10 from sklearn.cross_validation import cross_val_score
11 faces = fetch_olivetti_faces()
12 X_train, X_test, y_train, y_test = train_test_split(faces.data, faces.target, test_size=0.1)
13
14 from memory_profiler import memory_usage
15 import time
16 start = time.time()
17
18 def print_faces(images, target, top_n):
19     # sort on the y-axis in the order
20     fig = plt.figure(figsize=(10, 10))
21     fig.subplots_adjust(left=0.05, right=0.95, bottom=0.05, top=0.95)
22     for i in range(top_n):
23         p = plt.subplot(2, 2, i+1)
24         p.imshow(images[i], cmap=plt.cm.gray)
25         p.set_title('target: %s' % target[i])
26         p.text(0.05, 0.95, str(i))
27
28 def main():
29     evaluate_cross_validation : male or female
30     [ 0.9706021 0.9684213 0.97388421 1. ]
31     Mean score: 0.967 (+/-0.006)
32
33     train and evaluate : male or female
34     Accuracy on training set:
35     1.0
36     Accuracy on testing set:
37     0.5
38     Classification Report:
39     precision    recall  f1-score   support
40
41     0.0    0.50    0.00    10
42     1.0    0.00    0.00    10
43
44     avg / total    0.25    0.50    0.33    20
45
46     Confusion Matrix:
47     [[10  0]
48      [ 0 10]]
49
50     Runtime: 3.71797480213 sec
51     Memory usage: 12.55 MB
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100

```

รูปที่ 4 ตัวอย่างผลลัพธ์ของวิธีการดั้งเดิม (Traditional Method)

4.1 วิธีการดั้งเดิม (Traditional Method) เป็นวิธีการที่ให้โมเดลเลือกใบหน้ามาทำการ train และ test แบบสุ่มซึ่งผลลัพธ์ที่ได้คือ โมเดลทำนายได้ค่าความถูกต้องน้อยมาก อยู่ที่ 50% และส่วนใหญ่ยอมทำนายข้อมูลใหม่ให้เป็นใบหน้าของผู้ชาย ด้วยเหตุผลที่ว่า จำนวนใบหน้าผู้ชายมีเยอะกว่าใบหน้าผู้หญิงมาก จะเห็นได้ว่าค่าเรียก (Recall) และค่าความเที่ยง (Precision) รวมกันต่ำ ดังจะเห็นได้จากรูปที่ 5 และหากพิจารณาต่อไปในเฉพาะเพศหญิงจะพบว่าทั้งสองค่าที่กล่าวมา มีค่าเป็น 0 ดังจะเห็นได้จากตารางที่ 3

4.2 วิธีการปรับอัตราส่วนระหว่างหน้าชาย - หญิงให้สมดุล (Balancing Male-Female Ratio) วิธีการนี้เราจะลดจำนวนหน้าผู้ชายที่ใช้การ train และ test ให้มีอัตราส่วนเท่ากับจำนวนหน้าของผู้หญิง ผลลัพธ์ที่ได้นั้น คือ โมเดลเริ่มยอมทำนายข้อมูลใหม่ว่าเป็นใบหน้าผู้หญิงมากขึ้นกว่าเดิม แต่ความถูกต้องยังถือว่ายังไม่สูงนัก อยู่ที่ 65%


4.3 วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดล (Using obvious female face shape) วิธีการนี้ผู้วิจัยจะทำการเลือกใบหน้าผู้หญิงที่มีความเด่นชัด มาเพื่อใช้ในการ train และ test รวมถึงยังคงใช้อัตราส่วนที่เท่ากัน ระหว่างใบหน้าชาย และ หญิงผลลัพธ์ที่ได้นั้น มีความถูกต้องและแม่นยำสูงขึ้นมา โดยสามารถทำนายผลใบหน้าผู้หญิงด้วยความแม่นยำถึง 80% ดังจะเห็นได้จากตารางที่ 2 ไม่เพียงแค่นั้น ค่าระลึก (Recall) และค่าความเที่ยง (Precision) รวมกันสูงขึ้นมา ดังจะเห็นได้จากรูปที่ 5

4.4 วิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัดเพื่อใช้ในโมเดล (Using unobvious female face shape) วิธีการนี้ ผู้วิจัยจะทำการเลือกใบหน้าผู้หญิงที่มีความไม่เด่นชัด มาเพื่อใช้ในการ train และ test รวมถึงยังคงใช้อัตราส่วนที่เท่ากัน ระหว่างใบหน้าชาย และ หญิงผลลัพธ์ที่ได้นั้น มีความแม่นยำอยู่ในระดับที่ไม่สูงนัก ซึ่งค่อนข้างคล้ายกับ ผลลัพธ์ในข้อ 4.2

จากผลลัพธ์การทดลองข้างต้น ผู้วิจัยได้ทำการแสดงผลให้อยู่ในรูปแบบตาราง และกราฟเพื่อวัดผลระหว่างวิธีการทั้ง 4 ซึ่ง (A) คือวิธีการดั้งเดิม, (B) คือวิธีการปรับอัตราส่วนระหว่างหน้าชาย - หญิงให้สมดุล, (C1) คือวิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดล และ (C2) คือวิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัดเพื่อใช้ในโมเดลตามรูปด้านล่างนี้

ตารางที่ 2 แสดงค่าความแม่นยำ (Accuracy) ของแต่ละวิธีการ

Method	(A = traditional)	(B = balancing)	(C1 = obvious)	(C2 = unobvious)
Accuracy	0.50	0.65	0.85	0.65



รูปที่ 5 กราฟแสดงค่าระลึก (Recall) และค่าความเที่ยง (Precision) ของแต่ละวิธีการ

ตารางที่ 3 แสดงค่าระลึก (Recall) และค่าความเที่ยง (Precision) ของแต่ละวิธีการโดยแยกชาย-หญิง

Method	Male				Female			
	(A)	(B)	(C1)	(C2)	(A)	(B)	(C1)	(C2)
Recall	1.0	0.55	1.00	1.00	0.00	0.75	0.70	0.30
Precision	0.5	0.69	0.77	0.59	0.00	0.62	1.00	1.00

จากการทดลองจะเห็นได้ว่าในขั้นตอนแรก ได้นำข้อมูลมาทำการตรวจจัดโดยใช้วิธีการดั้งเดิม ผลลัพธ์ที่ได้มีประสิทธิภาพค่อนข้างต่ำ โดยเฉพาะกลุ่มใบหน้าเพศหญิง ด้วยสาเหตุที่ในข้อมูลมีจำนวนใบหน้าผู้หญิงค่อนข้างน้อยจึงได้ทดลองลดจำนวนหน้าผู้ชายที่ใช้การ train และ test ให้มีอัตราส่วนเท่ากับจำนวนหน้าของผู้หญิง ผลลัพธ์ที่ได้ดีขึ้นแต่ค่าความถูกต้องยังค่อนข้างต่ำจึงคิดว่าความชัดเจนของรูปภาพน่าจะมีส่วนในการตรวจจัดรูปจึงได้แบ่งรูปภาพที่ชัดเจนและไม่ชัดเจนออกจากกันเพื่อใช้ในโมเดล ผลลัพธ์วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในการสร้างโมเดลได้ผลลัพธ์ที่ดี ส่วนวิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัดเพื่อใช้ในโมเดลได้ผลลัพธ์เท่ากับวิธีการปรับอัตราส่วนระหว่างหน้าชาย - หญิงให้สมดุล จากผลการทดลองทำให้ทราบว่า การตรวจจัดใบหน้าให้มีประสิทธิภาพนั้นขึ้นอยู่กับจำนวนข้อมูลและความชัดเจนในการบ่งบอกเพศของรูปใบหน้าซึ่งรูปใบหน้าผู้หญิงบางรูปมีความคล้ายคลึงกับรูปใบหน้าผู้ชายทำให้แยกแยะออกยาก

อภิปรายผล

จากผลการทดลองข้างต้นนี้แสดงให้เห็นถึง ความสำคัญในกระบวนการ Data Preparation ซึ่งเราสามารถเห็นได้อย่างชัดเจนว่า การเตรียมข้อมูลให้มีอัตราส่วนระหว่างใบหน้าชาย-หญิง ด้วยอัตราส่วนที่เท่า ๆ กันจะทำให้เห็นผลลัพธ์ที่ดีขึ้น นอกจากนั้นผู้วิจัยยังพบอีกว่า ความเด่นชัดในการบ่งบอกเพศของใบหน้าผู้หญิงนั้น มีผลเป็นอย่างมากในการสร้างโมเดลเพื่อทำให้ความถูกต้องและแม่นยำสูงขึ้น ซึ่งเป็นวิธีการที่ดีที่สุดในการคัดเลือกข้อมูลเพื่อใช้ในอัลกอริทึมจำแนกประเภท

5. สรุปผลงานวิจัย

งานวิจัยนี้นำเสนอวิธีการจำแนกรูปใบหน้าระหว่างชาย-หญิง ซึ่งเท่าที่ค้นคว้าวรรณกรรมที่เกี่ยวข้อง ยังไม่พบว่ามีการวิจัยใด นำเสนอเทคนิค Support Vector Machine เพื่อที่จะจำแนกใบหน้าชาย-หญิงมาก่อน โดยงานวิจัยชิ้นนี้จะมุ่งเน้นการปรับปรุงโมเดลเพื่อให้ตรวจจัดรูปใบหน้าที่ตรวจจัดได้ยากและถ้ารูปในบางกลุ่มมีจำนวนน้อย โมเดลจะต้องสามารถตรวจจัดได้ถูกต้องมากที่สุด ซึ่งในการทำงานวิจัยชิ้นนี้พบกับความยากลำบากในการแยกใบหน้าชาย-หญิง อาทิเช่น ข้อมูลตัวอย่างนั้นมีจำนวนใบหน้าของผู้หญิงมีน้อยมากเมื่อเทียบอัตราส่วนกับใบหน้าของผู้ชาย นอกจากนี้รูปหน้าของชายและหญิงบางรูปไม่มีความเด่นชัดในการบ่งบอกเพศ โดยทางผู้วิจัยได้พยายามปรับปรุงโมเดลด้วยวิธีการต่าง ๆ เพื่อให้การจำแนกเพศจากรูปใบหน้ามีประสิทธิภาพยิ่งขึ้น จากนั้นจึงนำมาวัดผลถึงประสิทธิภาพการจำแนกด้วย confusion matrix โดยวิธีการปรับปรุงโมเดล ประกอบไปด้วย วิธีการปรับอัตราส่วนระหว่างหน้าชาย-หญิงให้สมดุล, วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัด และ วิธีการคัดเลือกใบหน้าผู้หญิงที่ไม่เด่นชัด

จากผลการทดลอง ผู้วิจัยพบว่า วิธีการคัดเลือกใบหน้าที่บ่งบอกลักษณะความเป็นผู้หญิงที่เด่นชัด หลังจากการปรับอัตราส่วนระหว่างจำนวนภาพใบหน้าชายและหญิงให้สมดุลแล้ว เป็นวิธีการให้ความแม่นยำที่ดีที่สุด โดยมีค่าความแม่นยำ 0.85 หรือ 85% เมื่อเปรียบเทียบกับการจำแนกภาพที่ไม่มีการปรับปรุงกระบวนการจำแนกจะให้ค่าความแม่นยำเพียง 50%

6. เอกสารอ้างอิง

- [1] กิตติศักดิ์ เกิดประสพ และ นิตยา เกิดประสพ (2014) Data Mining Application. from: https://sites.google.com/site/kittisakthailand56/home/3_56-dm-applications Retrieved Mar 01, 2014
- [2] พรพล ธรรมรงค์รัตน์, ลัดดา ปรีชาวีรกุล, และวิภาดา เวทย์ประสิทธิ์. “การจำแนกประเภทเว็บเพจโดยใช้ค่าความถี่เอกสารและซัพพอร์ตเวกเตอร์แมชชีน”, The 12th National Computer Science and Engineering Conference, 2008.
- [3] M. A. Turk and A. P. Pentland, “Face recognition using Eigen Faces”, Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR '91, pp. 586-591, 1991.
- [4] Joachims, “Text categorization with support vector machines: Learning with many relevant features”, Proceedings of the 10 th European Conference on Machine Learning, pp.137-142, 1998.



การศึกษาเปรียบเทียบเทคนิคเพื่อเพิ่มประสิทธิภาพโมเดลจำแนกภาพ
A Comparative Study of Techniques to Improve Image Classification Model

อนุสรฯ หิรัญวานกุล^{*}, รติพร จันทร์กลิ่น, กิตติศักดิ์ เกิดประสพ, นิตยา เกิดประสพ
Anusara Hirunyanakul^{*}, Ratiporn Chanklan, Kittisak Kerdprasop, Nittaya Kerdprasop

บทคัดย่อ

กรณีศึกษาในงานวิจัยชิ้นนี้จะเป็นการจำแนกภาพใบหน้าชาย และ หญิง ด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน โดยงานวิจัยชิ้นนี้ นำเสนอการศึกษาเปรียบเทียบระหว่างเทคนิคต่าง ๆ ในการนำมาเพิ่มประสิทธิภาพความแม่นยำของโมเดลจำแนกภาพ เพื่อจำแนกโดยเน้นในขั้นตอนการเตรียมข้อมูล เทคนิคที่จะนำมาทำการเปรียบเทียบ ได้แก่ การวิเคราะห์องค์ประกอบหลัก (พีซีเอ), การวิเคราะห์จำแนกประเภทเชิงเส้น (แอลดีเอ) และการคัดเลือกฟีเจอร์ บนพื้นฐานของโคสแควร์ ซึ่งผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพระหว่างเคอร์เนลฟังก์ชันสี่ชนิด คือ ฟังก์ชันเชิงเส้น, ฟังก์ชันพหุนาม, ฟังก์ชันเรเดียลเบสิส และฟังก์ชันซิกมอยด์ จากผลการทดลองพบว่า การใช้เทคนิคพีซีเอ ที่จำนวนองค์ประกอบหลักเท่ากับ 3 ในเคอร์เนลฟังก์ชันเรเดียลเบสิส ให้ความแม่นยำสูงถึง 95% ซึ่งเป็นความแม่นยำที่สูงที่สุดในเทคนิคต่าง ๆ ในงานวิจัยชิ้นนี้ โดยเพิ่มขึ้นถึง 10% เมื่อเปรียบเทียบกับ ความแม่นยำของการจำแนกใบหน้าชาย และ หญิง โดยไม่ได้ใช้เทคนิคอื่นช่วยในขั้นตอนการเตรียมข้อมูล ซึ่งจะมีความแม่นยำอยู่เพียง 85%

คำสำคัญ: โมเดลจำแนกภาพ, การจำแนกใบหน้าระหว่างชาย และ หญิง, ซัพพอร์ตเวกเตอร์แมชชีน, พีซีเอ, แอลดีเอ, การคัดเลือกฟีเจอร์

Abstract

The case study in this research is about male-female image classification using Support Vector Machine (SVM). This research demonstrates a comparison between pre-processing techniques including Principal Component Analysis (PCA), Linear Discriminant Analysis (LDA) and Feature Selection based on Chi-square. We also compare the efficiency of image recognition and classification among four kinds of kernel functions, that is, Linear Function, Polynomial Function, Radial Basis Function, and Sigmoid Function. From the experimental results, we found that the classification accuracy of PCA technique with 3 components and trained with the RBF kernel function is 95%. This is the highest accuracy compared to all techniques studied in this research. The increase is 10% from the baseline 85%, which is the accuracy of male-female classification without any pre-processing technique.

Keywords: Image recognition model, Classification between male and female faces, Support Vector Machine, PCA, LDA, Feature Selection

สาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี นครราชสีมา 30000
School of Computer Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima, Thailand.

^{*}Corresponding author. E-mail: Nhingsan@gmail.com


1. บทนำ

ในปัจจุบันข้อมูลภาพเป็นข้อมูลที่มีความละเอียดสูงจึงมีจำนวนมิติสูง ส่งผลให้เมื่อนำข้อมูลภาพไปหน้าไปประมวลผลด้วยคอมพิวเตอร์จะใช้เวลาประมวลผลนาน อีกทั้งยังต้องใช้หน่วยความจำสำหรับการประมวลผลที่สูงมาก งานวิจัยนี้จึงใช้การลดขนาดข้อมูลเป็นกระบวนการหนึ่งในขั้นตอนการเตรียมข้อมูลเป็นการทำให้ข้อมูลตั้งต้นมีขนาดลดลงโดยสูญเสียลักษณะสำคัญของข้อมูลน้อยที่สุดและสูญเสียความถูกต้องของผลลัพธ์น้อยที่สุด เนื่องจากข้อมูลแต่ละตัวจะมีความสำคัญต่อการจัดกลุ่มข้อมูลไม่เท่ากัน ด้วยเทคนิคการเลือกข้อมูลที่ตีจะทำให้สามารถเลือกข้อมูลที่มีความสำคัญและสามารถใช้เป็นตัวแทนของข้อมูลส่วนใหญ่ สามารถลดเวลาในการเรียนรู้ข้อมูล และลดความต้องการของหน่วยความจำ [1] ซึ่งเทคนิคการลดขนาดข้อมูลที่น่าสนใจ ได้แก่ การวิเคราะห์องค์ประกอบหลัก (พีซีเอ), การวิเคราะห์จำแนกประเภทเชิงเส้น (แอลดีเอ) และการคัดเลือกพีเจอร์ บนพื้นฐานของโคสแควร์ หลังจากนั้นจึงส่งข้อมูลภาพที่ผ่านการลดมิติแล้วเข้าประมวลผลด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนซึ่งเป็นอัลกอริทึมในการจำแนกที่มีการนำมาใช้กันอย่างกว้างขวางในด้านการประมวลผลภาพดิจิทัล [2] และเป็นวิธีการที่มีประสิทธิภาพในการจำแนกประเภทข้อมูล และถูกนำมาใช้ในการรู้จำรูปแบบอย่างง่าย [9] จากนั้นงานวิจัยนี้จะทำการเปรียบเทียบประสิทธิภาพระหว่างการเลือกใช้คอร์เนลฟังก์ชันในซัพพอร์ตเวกเตอร์แมชชีนสี่ชนิดได้แก่ ฟังก์ชันเชิงเส้น, ฟังก์ชันพหุนาม, ฟังก์ชันเรเดียลเบสิส และฟังก์ชันซิกมอยด์

วัตถุประสงค์หลักของงานวิจัยฉบับนี้ เพื่อศึกษาเปรียบเทียบเทคนิคการลดมิติเพื่อลดเวลาและเพิ่มความถูกต้องในการจำแนก โดยเน้นในขั้นตอนการเตรียมข้อมูล เทคนิคที่จะนำมาทำการเปรียบเทียบได้แก่ การวิเคราะห์องค์ประกอบหลัก (พีซีเอ), การวิเคราะห์จำแนกประเภทเชิงเส้น (แอลดีเอ) และการคัดเลือกพีเจอร์ บนพื้นฐานของโคสแควร์ แล้วส่งข้อมูลที่ผ่านการลดมิติเข้าประมวลผลด้วยซัพพอร์ตเวกเตอร์แมชชีนต่าง ๆ เพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของโมเดลสำหรับจำแนกข้อมูล

2. งานวิจัยและทฤษฎีที่เกี่ยวข้อง

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) [3] เป็นวิธีการจำแนกกลุ่มข้อมูลที่อาศัยระนาบการตัดสินใจมาใช้ในการแบ่งข้อมูลออกเป็น 2 ส่วน โดยพยายามสร้างเส้นแบ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตทั้งสองกลุ่มมากที่สุด ดังตัวอย่างในรูปที่ 1 ซึ่งซัพพอร์ตเวกเตอร์แมชชีนจะใช้ฟังก์ชันแมปปิง (Mapping Function) เพื่อแปลงข้อมูลจากโดเมนเดิมไปยังโดเมนที่เรียกว่า ฟีเจอร์สเปซ (Feature Space) และใช้ฟังก์ชันเคอร์เนล (Kernel Function) ในการวัดความคล้ายกันของข้อมูลในฟีเจอร์สเปซ ในงานวิจัยนี้ใช้เคอร์เนลฟังก์ชัน คือ ฟังก์ชันเชิงเส้น, ฟังก์ชันพหุนาม, ฟังก์ชันเรเดียลเบสิส และฟังก์ชันซิกมอยด์ในการทดสอบเปรียบเทียบประสิทธิภาพในการจำแนกข้อมูล



รูปที่ 1 ระบายการตัดสินใจของซัพพอร์ตเวกเตอร์แมชชีน (Ali, Shamsuddin and Ismail, 2011)

การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis : PCA) [4] เป็นวิธีการที่ใช้ในการแปลงข้อมูลไปสู่ระนาบใหม่ (เรียกว่า องค์ประกอบ) ที่สามารถกระจายข้อมูลออกจากกันได้มากที่สุด โดยมีขั้นตอนการทำงานคือ 1) ทำการแปลงโครงสร้างเมตริกซ์ข้อมูลไปเป็นเวกเตอร์แถว 2) คำนวณหาไอเกนเวกเตอร์ที่สอดคล้องกับกับค่าไอเกน 3) นำไปคำนวณหาลักษณะเด่นของภาพเพื่อนำไปใช้ในการรู้จำ

ถ้ากำหนดให้ภาพที่ใช้ในการฝึกสอนมีจำนวน N ภาพ และมีขนาด $N \times N$ โดยข้อมูลภาพจะมีรูปแบบเป็น X_1, X_2, \dots, X_n และแปลงเมตริกซ์ภาพเป็นเวกเตอร์ขนาด $1 \times D$ โดยที่ $D = N^2$ จะทำให้ได้ชุดข้อมูลฝึกสอนดังนี้ [5]

$$\mu = \{\mu_1, \mu_2, \dots, \mu_N\} \quad (1)$$

นำข้อมูลไปคำนวณหาค่าความแปรปรวนร่วมของข้อมูลเมตริกซ์ (Covariance Matrix)

$$C = AA^T \\ = \frac{1}{N} \sum_{i=1}^N (\mu_i - \mu)(\mu_i - \mu)^T \quad (2)$$

เมื่อ $\mu = \frac{1}{N} \sum_{i=1}^N \rho_i$ แทนค่าเฉลี่ยโดยที่ C เป็นเมตริกซ์ความแปรปรวนร่วม μ ได้มาจากภาพที่ i ลบด้วยค่าเฉลี่ยภาพ $\mu_i = \mu_i - \mu$ และนำค่า C ไปคำนวณหาไอเกนเวกเตอร์ที่สอดคล้องกับค่าไอเกนจากสมการที่(3)

$$C u = \lambda u \quad (3)$$

เรียงลำดับไอเกนเวกเตอร์ที่สอดคล้องกับค่าไอเกนจากมากไปน้อยแล้วคัดเอาเฉพาะค่าที่ไม่เท่ากับศูนย์ $U_{PCA} = [u_1, u_2, u_3, \dots, u_{N-1}]$ แล้วทำการสกัดเอาลักษณะเด่นของภาพ (Feature extraction) เพื่อนำไปใช้ในการรู้จำ จากสมการที่(4)

$$Y_k = U_d^T(u_k - \mu) \text{ โดยที่ } k = 1, 2, \dots, N \quad (4)$$

เมื่อ Y_k แทน ลักษณะเด่นภาพที่ k ส่วน d เป็นค่ามิติที่เลือกระหว่าง 1 ถึง $N - 1$ และ k เป็นจำนวนภาพ จากทั้งหมด N ภาพ

การวิเคราะห์จำแนกประเภทเชิงเส้น (Linear Discriminant Analysis : LDA) [6] เป็นเทคนิคที่ใช้สำหรับการเรียนรู้แบบมีผู้สอน ใช้เทคนิคการหากลุ่มของปริมาณ (Base vector) โดย W_k เป็นเวกเตอร์ของกลุ่มตัวอย่าง สามารถแสดงสมการ W_k ได้ดังนี้

$$\begin{aligned} W_{opt} &= \frac{\operatorname{argmax}_W |W^t S_C W|}{|W^t S_V W|} \\ &= [W_1, W_2, \dots, W_L] \end{aligned} \quad (5)$$

โดยที่ $\{W_k | 1 \leq K \leq L\}$ กำหนดให้ L เป็นมิติของชุดข้อมูล S_C และ S_V เป็นเมตริกซ์ที่อยู่ใน class สามารถคำนวณหาเมตริกซ์ S_C และ S_V ได้จากสมการที่(6) และสมการที่(7)

$$S_C = \sum_{k=1}^a M_X (\mu_k - \mu)(\mu_k - \mu)^T \quad (6)$$

$$S_V = \sum_{k=1}^a \sum_{(x_u = x_k)} (x_u - \mu_k)(x_u - \mu)^T \quad (7)$$

เมื่อ a แทน จำนวน class และ $X \in R^n$ เป็นข้อมูล

x_k แทน ข้อมูลทดสอบของ class k

μ_k แทน ข้อมูลทั้งหมดของ class k

M_k คือ จำนวนข้อมูลที่ใช้ทดสอบใน class k ถ้า S_V เป็น non-singular ที่ใช้ค้นหา W_k จากสมการที่(5) ซึ่ง L แรกจะมีขนาดใหญ่มากกว่าโอเคน $\{W_k | 1 \leq K \leq L\}$

วิธีการคัดเลือกคุณลักษณะ (Feature Selection Methods) [7] การคัดเลือกคุณลักษณะเป็นกระบวนการที่เลือกกลับเซตจากเซตของคุณลักษณะ (Feature Set) ของต้นฉบับ จะทำให้ได้คุณลักษณะที่เหมาะสมเพื่อนำไปใช้ในการจำแนกหมวดหมู่ โดยที่เซตของคุณลักษณะ คือ เซตของ term ที่เกิดขึ้นในข้อมูลทั้งหมด ซึ่งวิธีการคัดเลือกคุณลักษณะนี้จะช่วยเพิ่มประสิทธิภาพในการจำแนกข้อมูลและหลีกเลี่ยงการเกิด overfitting ได้ ซึ่งงานวิจัยนี้ได้เลือกใช้วิธีการคัดเลือกคุณลักษณะบนพื้นฐานของไคสแควร์ (Chi Squared : CHI) [8] เป็นการวัดความสัมพันธ์ระหว่าง term และ category ซึ่งคำนวณได้จากสมการดังนี้

$$X^2(t, c) = \frac{N \times (p(t,c) \times p(\bar{t}, \bar{c}) - p(t, \bar{c}) \times p(\bar{t}, c))^2}{p(t) \times p(\bar{t}) \times p(c) \times p(\bar{c})} \quad (8)$$

$$X^2(t) = \text{avg}_{i=1}^m \{X^2(t, c_i)\} \quad (9)$$

โดยที่ N คือ จำนวนของภาพในฐานข้อมูล

3. ขั้นตอนดำเนินงานวิจัย

งานวิจัยขั้นนี้ ใช้ฐานข้อมูลที่เป็นรูปใบหน้าคน จาก <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html> จำนวน 400 รูป เป็นรูปใบหน้าผู้ชายจำนวน 360 รูป และ 40 รูปที่เหลือเป็นรูปใบหน้าผู้หญิง ซึ่งทั้งหมด 400 รูปนี้มีความละเอียด 64x64 pixels (4096 pixels) โมเดลจำแนกใบหน้าในงานวิจัยนี้ ได้ค่าความถูกต้องของการจำแนกใบหน้าเพศหญิงต่ำมาก ผู้วิจัยจึงได้นำเสนอแนวทางการปรับปรุงโมเดลเพื่อเพิ่มความถูกต้องของการจำแนกด้วย วิธีการปรับอัตราส่วนระหว่างหน้าชาย-หญิงให้สมดุล (Balancing male-female ratio) และ วิธีการคัดเลือกใบหน้าผู้หญิงที่เด่นชัดเพื่อใช้ในโมเดล (Using obvious female face shape) ซึ่งความแม่นยำในการจำแนก ณ ขณะนี้มีค่าเท่ากับ 0.85 ดังที่ได้แสดงไว้ในรูปที่ 2


ทางผู้วิจัยได้ทดลองใช้เทคนิค PCA, LDA และ Feature Selection บนพื้นฐานของโคสแควร์ ในขั้นตอนการลดมิติของข้อมูล เพื่อเพิ่มความแม่นยำในการจำแนกใบหน้า หญิง - ชายให้มากยิ่งขึ้น โดยทดสอบกับทุก Kernel ของ SVM Algorithm จากนั้นจึงนำผลการทดลองมาเปรียบเทียบกัน ทั้งระหว่างแต่ละเทคนิคของการลดมิติข้อมูล และระหว่างของแต่ละ Kernel ภายในเทคนิคเดียวกันเอง โดยแผนภาพการดำเนินการวิจัยได้แสดงไว้ในรูปที่ 3

```

44 print ("Mean score: (0.85) (%.1f%%)" % (0.85))
45 np.mean(scores), see(scores))
46
47 def train_and_evaluate(X_train, X_test, y_train, y_test):
48     clf = clf(X_train, y_train)
49     print ("Training and evaluating")
50     print ("Accuracy on training set")
51     print clf.score(X_train, y_train)
52     print ("Accuracy on testing set")
53     print clf.score(X_test, y_test)
54
55
56 y_pred = clf.predict(X_test)
57 print ("Classification Report")
58 print metrics.classification_report(y_test, y_pred)
59 print ("Confusion Matrix")
60 print metrics.confusion_matrix(y_test, y_pred)
61
62 def create_target(segments):
63     # create a new array of target size initialized with zeros
64     y = np.zeros(faces.target.shape[0])
65     # put 1 in the array if we have segments
66     for (start, end) in segments:
67         y[start:end + 1] = 1
68     return y
69
70 def array_gm(s):
71     g = []
72
73     for i, s in enumerate(s):
74         #
75         #
76         #
77         #
78         #
79         #
80         #
81         #
82         #
83         #
84         #
85         #
86         #
87         #
88         #
89         #
90         #
91         #
92         #
93         #
94         #
95         #
96         #
97         #
98         #
99         #
100        #
101        #
102        #
103        #
104        #
105        #
106        #
107        #
108        #
109        #
110        #
111        #
112        #
113        #
114        #
115        #
116        #
117        #
118        #
119        #
120        #
121        #
122        #
123        #
124        #
125        #
126        #
127        #
128        #
129        #
130        #
131        #
132        #
133        #
134        #
135        #
136        #
137        #
138        #
139        #
140        #
141        #
142        #
143        #
144        #
145        #
146        #
147        #
148        #
149        #
150        #
151        #
152        #
153        #
154        #
155        #
156        #
157        #
158        #
159        #
160        #
161        #
162        #
163        #
164        #
165        #
166        #
167        #
168        #
169        #
170        #
171        #
172        #
173        #
174        #
175        #
176        #
177        #
178        #
179        #
180        #
181        #
182        #
183        #
184        #
185        #
186        #
187        #
188        #
189        #
190        #
191        #
192        #
193        #
194        #
195        #
196        #
197        #
198        #
199        #
200        #
201        #
202        #
203        #
204        #
205        #
206        #
207        #
208        #
209        #
210        #
211        #
212        #
213        #
214        #
215        #
216        #
217        #
218        #
219        #
220        #
221        #
222        #
223        #
224        #
225        #
226        #
227        #
228        #
229        #
230        #
231        #
232        #
233        #
234        #
235        #
236        #
237        #
238        #
239        #
240        #
241        #
242        #
243        #
244        #
245        #
246        #
247        #
248        #
249        #
250        #
251        #
252        #
253        #
254        #
255        #
256        #
257        #
258        #
259        #
260        #
261        #
262        #
263        #
264        #
265        #
266        #
267        #
268        #
269        #
270        #
271        #
272        #
273        #
274        #
275        #
276        #
277        #
278        #
279        #
280        #
281        #
282        #
283        #
284        #
285        #
286        #
287        #
288        #
289        #
290        #
291        #
292        #
293        #
294        #
295        #
296        #
297        #
298        #
299        #
300        #
301        #
302        #
303        #
304        #
305        #
306        #
307        #
308        #
309        #
310        #
311        #
312        #
313        #
314        #
315        #
316        #
317        #
318        #
319        #
320        #
321        #
322        #
323        #
324        #
325        #
326        #
327        #
328        #
329        #
330        #
331        #
332        #
333        #
334        #
335        #
336        #
337        #
338        #
339        #
340        #
341        #
342        #
343        #
344        #
345        #
346        #
347        #
348        #
349        #
350        #
351        #
352        #
353        #
354        #
355        #
356        #
357        #
358        #
359        #
360        #
361        #
362        #
363        #
364        #
365        #
366        #
367        #
368        #
369        #
370        #
371        #
372        #
373        #
374        #
375        #
376        #
377        #
378        #
379        #
380        #
381        #
382        #
383        #
384        #
385        #
386        #
387        #
388        #
389        #
390        #
391        #
392        #
393        #
394        #
395        #
396        #
397        #
398        #
399        #
400        #
401        #
402        #
403        #
404        #
405        #
406        #
407        #
408        #
409        #
410        #
411        #
412        #
413        #
414        #
415        #
416        #
417        #
418        #
419        #
420        #
421        #
422        #
423        #
424        #
425        #
426        #
427        #
428        #
429        #
430        #
431        #
432        #
433        #
434        #
435        #
436        #
437        #
438        #
439        #
440        #
441        #
442        #
443        #
444        #
445        #
446        #
447        #
448        #
449        #
450        #
451        #
452        #
453        #
454        #
455        #
456        #
457        #
458        #
459        #
460        #
461        #
462        #
463        #
464        #
465        #
466        #
467        #
468        #
469        #
470        #
471        #
472        #
473        #
474        #
475        #
476        #
477        #
478        #
479        #
480        #
481        #
482        #
483        #
484        #
485        #
486        #
487        #
488        #
489        #
490        #
491        #
492        #
493        #
494        #
495        #
496        #
497        #
498        #
499        #
500        #
501        #
502        #
503        #
504        #
505        #
506        #
507        #
508        #
509        #
510        #
511        #
512        #
513        #
514        #
515        #
516        #
517        #
518        #
519        #
520        #
521        #
522        #
523        #
524        #
525        #
526        #
527        #
528        #
529        #
530        #
531        #
532        #
533        #
534        #
535        #
536        #
537        #
538        #
539        #
540        #
541        #
542        #
543        #
544        #
545        #
546        #
547        #
548        #
549        #
550        #
551        #
552        #
553        #
554        #
555        #
556        #
557        #
558        #
559        #
560        #
561        #
562        #
563        #
564        #
565        #
566        #
567        #
568        #
569        #
570        #
571        #
572        #
573        #
574        #
575        #
576        #
577        #
578        #
579        #
580        #
581        #
582        #
583        #
584        #
585        #
586        #
587        #
588        #
589        #
590        #
591        #
592        #
593        #
594        #
595        #
596        #
597        #
598        #
599        #
600        #
601        #
602        #
603        #
604        #
605        #
606        #
607        #
608        #
609        #
610        #
611        #
612        #
613        #
614        #
615        #
616        #
617        #
618        #
619        #
620        #
621        #
622        #
623        #
624        #
625        #
626        #
627        #
628        #
629        #
630        #
631        #
632        #
633        #
634        #
635        #
636        #
637        #
638        #
639        #
640        #
641        #
642        #
643        #
644        #
645        #
646        #
647        #
648        #
649        #
650        #
651        #
652        #
653        #
654        #
655        #
656        #
657        #
658        #
659        #
660        #
661        #
662        #
663        #
664        #
665        #
666        #
667        #
668        #
669        #
670        #
671        #
672        #
673        #
674        #
675        #
676        #
677        #
678        #
679        #
680        #
681        #
682        #
683        #
684        #
685        #
686        #
687        #
688        #
689        #
690        #
691        #
692        #
693        #
694        #
695        #
696        #
697        #
698        #
699        #
700        #
701        #
702        #
703        #
704        #
705        #
706        #
707        #
708        #
709        #
710        #
711        #
712        #
713        #
714        #
715        #
716        #
717        #
718        #
719        #
720        #
721        #
722        #
723        #
724        #
725        #
726        #
727        #
728        #
729        #
730        #
731        #
732        #
733        #
734        #
735        #
736        #
737        #
738        #
739        #
740        #
741        #
742        #
743        #
744        #
745        #
746        #
747        #
748        #
749        #
750        #
751        #
752        #
753        #
754        #
755        #
756        #
757        #
758        #
759        #
760        #
761        #
762        #
763        #
764        #
765        #
766        #
767        #
768        #
769        #
770        #
771        #
772        #
773        #
774        #
775        #
776        #
777        #
778        #
779        #
780        #
781        #
782        #
783        #
784        #
785        #
786        #
787        #
788        #
789        #
790        #
791        #
792        #
793        #
794        #
795        #
796        #
797        #
798        #
799        #
800        #
801        #
802        #
803        #
804        #
805        #
806        #
807        #
808        #
809        #
810        #
811        #
812        #
813        #
814        #
815        #
816        #
817        #
818        #
819        #
820        #
821        #
822        #
823        #
824        #
825        #
826        #
827        #
828        #
829        #
830        #
831        #
832        #
833        #
834        #
835        #
836        #
837        #
838        #
839        #
840        #
841        #
842        #
843        #
844        #
845        #
846        #
847        #
848        #
849        #
850        #
851        #
852        #
853        #
854        #
855        #
856        #
857        #
858        #
859        #
860        #
861        #
862        #
863        #
864        #
865        #
866        #
867        #
868        #
869        #
870        #
871        #
872        #
873        #
874        #
875        #
876        #
877        #
878        #
879        #
880        #
881        #
882        #
883        #
884        #
885        #
886        #
887        #
888        #
889        #
890        #
891        #
892        #
893        #
894        #
895        #
896        #
897        #
898        #
899        #
900        #
901        #
902        #
903        #
904        #
905        #
906        #
907        #
908        #
909        #
910        #
911        #
912        #
913        #
914        #
915        #
916        #
917        #
918        #
919        #
920        #
921        #
922        #
923        #
924        #
925        #
926        #
927        #
928        #
929        #
930        #
931        #
932        #
933        #
934        #
935        #
936        #
937        #
938        #
939        #
940        #
941        #
942        #
943        #
944        #
945        #
946        #
947        #
948        #
949        #
950        #
951        #
952        #
953        #
954        #
955        #
956        #
957        #
958        #
959        #
960        #
961        #
962        #
963        #
964        #
965        #
966        #
967        #
968        #
969        #
970        #
971        #
972        #
973        #
974        #
975        #
976        #
977        #
978        #
979        #
980        #
981        #
982        #
983        #
984        #
985        #
986        #
987        #
988        #
989        #
990        #
991        #
992        #
993        #
994        #
995        #
996        #
997        #
998        #
999        #
1000       #

```

รูปที่ 2 ค่าความแม่นยำในการจำแนก โดยไม่มีการลดขนาดของมิติ



รูปที่ 3 โครงร่างขั้นตอนการดำเนินงาน

4. ผลการทดลอง

จากข้อมูลรูปใบหน้าคนทั้งหมดจำนวน 400 รูป การจำแนกใบหน้าชายและหญิง โดยใช้ภาษา Python 2.7 เขียนบนโปรแกรม Spyder จะได้ผลการทดลองทั้งหมดแสดงได้ดังตารางที่ 1

ตารางที่ 1 แสดงค่าความแม่นยำ ของแต่ละเทคนิคในการลดมิติข้อมูล

Accuracy of testing datasets									
SVM (kernel)	PCA				LDA				
	Linear	Poly	Rbf	Sigmoid	Linear	Poly	Rbf	Sigmoid	
n-component									
1	0.40	0.45	0.50	0.50	0.70	0.60	0.70	0.50	
3	0.25	0.65	0.95	0.50	0.70	0.60	0.70	0.50	
5	0.80	0.85	0.95	0.50	0.70	0.60	0.70	0.50	
7	0.85	0.80	0.90	0.50	0.70	0.60	0.70	0.50	
9	0.90	0.80	0.95	0.50	0.70	0.60	0.70	0.50	
10	0.85	0.85	0.90	0.50	0.70	0.60	0.70	0.50	
15	0.70	0.85	0.95	0.50	0.70	0.60	0.70	0.50	
20	0.75	0.75	0.50	0.50	0.70	0.60	0.70	0.50	
25	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
30	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
35	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
40	0.75	0.75	0.50	0.50	0.70	0.60	0.70	0.50	
45	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
50	0.75	0.75	0.50	0.50	0.70	0.60	0.70	0.50	
55	0.75	0.75	0.50	0.50	0.70	0.60	0.70	0.50	
60	0.75	0.75	0.50	0.50	0.70	0.60	0.70	0.50	
80	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
90	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
100	0.80	0.80	0.50	0.50	0.70	0.60	0.70	0.50	
10%	410	0.80	0.80	0.50	0.70	0.60	0.70	0.50	
25%	1025	0.80	0.80	0.50	0.70	0.60	0.70	0.50	
50%	2025	0.80	0.80	0.50	0.70	0.60	0.70	0.50	
75%	3075	0.80	0.80	0.50	0.70	0.60	0.70	0.50	
100%	4096	0.80	0.80	0.45	0.50	0.70	0.60	0.70	0.50

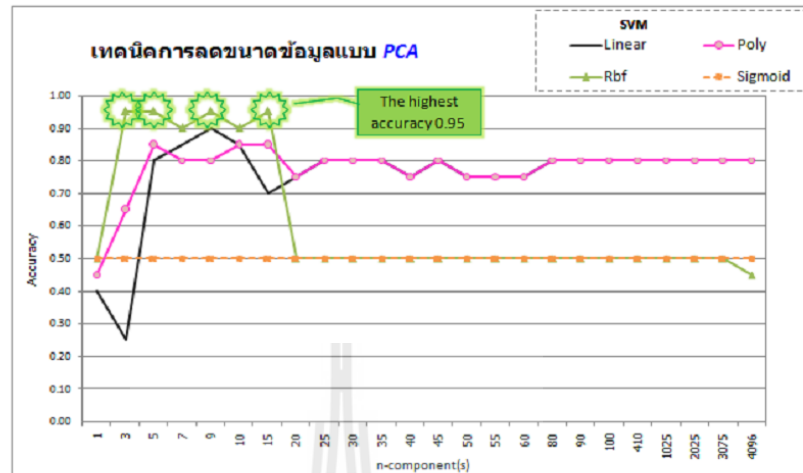
Feature Selection				
SVM (kernel)	Linear	Poly	Rbf	Sigmoid
percentile				
1	0.35	0.45	0.50	0.50
3	0.55	0.45	0.50	0.50
5	0.50	0.45	0.50	0.50
7	0.45	0.45	0.50	0.50
9	0.35	0.45	0.55	0.50
10	0.40	0.45	0.45	0.50
15	0.40	0.45	0.45	0.50
20	0.35	0.45	0.45	0.50
25	0.45	0.45	0.50	0.50
30	0.60	0.50	0.55	0.50
35	0.75	0.50	0.55	0.50
40	0.65	0.50	0.55	0.50
45	0.80	0.50	0.55	0.50
50	0.80	0.55	0.55	0.50
55	0.85	0.55	0.55	0.50
60	0.85	0.55	0.55	0.50
65	0.85	0.55	0.55	0.50
70	0.85	0.55	0.60	0.50
75	0.85	0.55	0.60	0.50
80	0.85	0.55	0.60	0.50
85	0.85	0.55	0.60	0.50
90	0.85	0.55	0.60	0.50
95	0.85	0.55	0.60	0.50
100	0.85	0.55	0.60	0.50

ด้วยเทคนิคการลดมิติข้อมูลแบบ PCA ดังแสดงผลในรูปที่ 4 จะสังเกตได้ว่าที่ kernel Linear จะมีค่า accuracy แกว่งในช่วงจำนวน component 1 ถึง 15 หลังจากนั้นค่าความแม่นยำจะเริ่มคงที่ ที่ประมาณ 0.8

ที่ kernel Rbf ค่า accuracy เมื่อจำนวน component = 3, 5, 9 และ 15 สูงถึง 0.95

ที่ kernel Poly จะมีค่า accuracy แกว่งในช่วง component 1 ถึง 15 หลังจากนั้นค่าความแม่นยำจะเริ่มคงที่ ที่ประมาณ 0.8

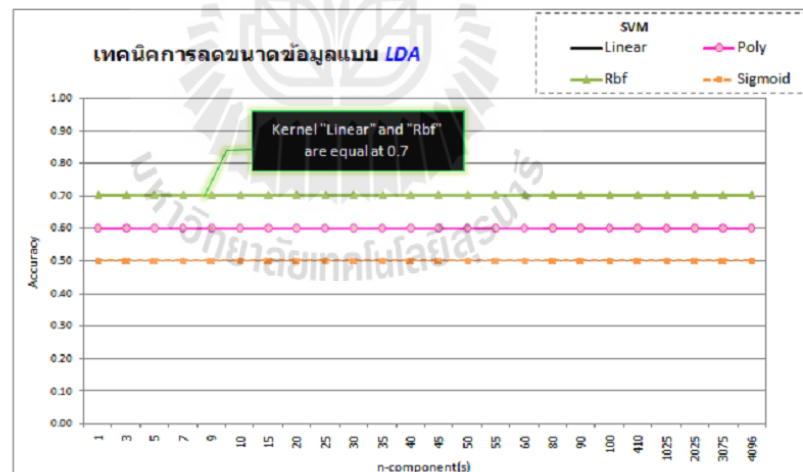
ที่ kernel sigmoid ค่า accuracy จะคงที่ ที่ 0.5 ไม่ว่าจะมีความจำนวน component จะเป็นเท่าใด



รูปที่ 4 กราฟแสดงการเปรียบเทียบ ความแม่นยำระหว่างแต่ละ kernel ในเทคนิคลดมิติด้วย PCA


ด้วยเทคนิคการลดมิติข้อมูลแบบ LDA ดังแสดงผลในรูปที่ 5 ค่า accuracy จะคงที่ โดยจะแตกต่างกันออกไปตามแต่ละ kernel โดยค่าที่ได้ มีดังต่อไปนี้ ที่ kernel Linear และ Rbf จะมีความแม่นยำเท่ากันอยู่ที่ 0.7 และคงที่ ไม่ว่าจำนวน component จะเปลี่ยนแปลงไปมากเท่าไร

ที่ kernel Poly ค่า accuracy จะคงที่อยู่ที่ 0.6 และ ที่ kernel Sigmoid ค่า accuracy คงที่อยู่ที่ 0.5 (ซึ่งจะเท่ากับ เทคนิคการลดมิติข้อมูลแบบ PCA)



รูปที่ 5 กราฟแสดงการเปรียบเทียบ ความแม่นยำระหว่างแต่ละ kernel ในเทคนิคลดมิติด้วย LDA

ในส่วนของการลดมิติข้อมูลด้วยวิธี Feature Selection บนพื้นฐานของโคสแควร์ ดังรูปที่ 6 พบว่าที่ Kernel Linear ค่า accuracy นั้นจะสูงขึ้นเรื่อย ๆ ตาม percentile ของจำนวนมิติข้อมูล อย่างเห็นได้ชัดเจน และ สูงสุดที่ 0.85 โดยจะเริ่มคงที่ เมื่อ percentile=55 ส่วนใน Kernel อื่น ๆ ค่า accuracy จะเพิ่มขึ้นเล็กน้อยตาม percentile



รูปที่ 6 กราฟแสดงการเปรียบเทียบ ความแม่นยำระหว่าง Kernel ต่างๆ ในเทคนิค Feature Selection บนพื้นฐานโคสแควร์

อภิปรายผล

ผลการทดลองนี้แสดงให้เห็นถึงความสำคัญในการลดมิติข้อมูล โดยในแต่ละเทคนิค จะให้ผลลัพธ์ต่างกันอย่างชัดเจน โดยในแต่ละ kernel จะมีค่าความแม่นยำเปลี่ยนแปลงไปตาม จำนวน component (หรือ percentile ในกรณีของการลดมิติแบบ Feature Selection บนพื้นฐานโคสแควร์)

5. สรุปผลงานวิจัย

งานวิจัยนี้มุ่งเน้นไปในด้านการเพิ่มประสิทธิภาพการจำแนกรูปใบหน้าระหว่างชาย-หญิง โดยทางผู้วิจัยจะทำการศึกษาเปรียบเทียบ ระหว่างแต่ละเทคนิคของการลดขนาดมิติของข้อมูลได้แก่ PCA, LDA และ Feature Selection บนพื้นฐานโคสแควร์ โดยรวมไปถึงการศึกษาเปรียบเทียบ ระหว่างแต่ละ kernel ของ SVM ด้วย

จากการทดลองพบว่า การใช้เทคนิคการลดขนาดมิติข้อมูลแบบ PCA โดยใช้ kernel SVM เป็น RBF จะให้ค่าความแม่นยำสูงถึง 0.95 ที่ จำนวน component = 3, 5, 9 และ 15 ซึ่งเป็นค่าที่สูงที่สุดใน การทดลองนี้ เมื่อเปรียบเทียบกับ ความแม่นยำของการจำแนกใบหน้าชาย และ หญิง โดยไม่ได้ใช้เทคนิคอื่นช่วยในขั้นตอนการเตรียมข้อมูล ซึ่งมีความแม่นยำอยู่เพียง 0.85

6.เอกสารอ้างอิง

- [1] ธรรมศักดิ์ เขียรนิเวศน. “การลดขนาดข้อมูลด้วยน้ำหนักความหนาแน่นเพื่อการจัดกลุ่มข้อมูลขนาดใหญ่”, วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ปรการศึกษา 2548.
- [2] พรพล ธรรมรงค์รัตน์, สัตตา ปรีชาวีรกุล, และวิภาดา เวทย์ประสิทธิ์. “การจำแนกประเภทเว็บเพจโดยใช้ค่าความถี่เอกสารและซีฟอर्टเวกเตอร์แมชชีน”, The 12th National Computer Science and Engineering Conference, 2008.
- [3] Ali, W., Shamsuddin, S.M., and Ismail A.S. (2011). “Web Proxy Cache Content Classification based on Support Vector Machine”. *Journal of Artificial Intelligence* 4(1): 100-109.
- [4] Dinh Minh Nhat, V., and Young Lee, S. (2006). “Two dimensional Weighted PCA algorithm for Face Recognition”. *IEEE International Symposium on Computational Intelligence in Robotics and Automation*. Page 219-223.
- [5] Turk, M., and Pentland, A. (1991). “Eigenfaces for recognition”. *Journal of Cognitive Neuroscience*. 3: Page 71-86, from <http://www.sciencedirect.com>
- [6] Tang, F., and Tao, H. (2006) “Fast linear discriminant analysis using binary bases”. *Proceedings of the 18th International Conference on Pattern Recognition (ICPR'06)*, Page 52-55.
- [7] Yang Y. and Pedersen J.O., “A Comparative Study on Feature Selection in Text Categorization,” *Proceedings of The Fourteenth International Conference on Machine Learning (ICML'97)*, Page 412-420.
- [8] Galavotti, L., Sebastiani, F. and Simi, M. (2000) “Feature selection and negative evidence in automated text categorization”, *Proceedings of KDD-00*.
- [9] Cristianini N. and Shawe-Taylor J. (2000) “An Introduction to Support Vector Machines and Other Kernel-based Learning Methods”, U.K. Cambridge University Press.

การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ

SWURES8-104 การศึกษาวิธีการลดมิติเพื่อเพิ่มความเร็วในการจำแนกไบโอเมตริกซ์
THE STUDY OF DIMENSIONALITY REDUCTION METHODS TO SPEED UP BIOMETRIC IDENTIFICATION

รติพร จันทร์กลิ่น¹, กิตติศักดิ์ เกิดประสพ², นิตยา เกิดประสพ³

Ratiporn Chanklan¹, Kittisak Kerdprasop², Nittaya Kerdprasop³

สาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี
School of Computer Engineering, Institute of Engineering, Suranaree University of Technology, Thailand.

Corresponding author, E-mail: arc_angle@hotmail.com

บทคัดย่อ

งานวิจัยนี้มีจุดประสงค์เพื่อศึกษาค่าความถูกต้องในการจำแนกและเวลาที่ได้รับผลกระทบ จากการลดมิติของข้อมูลไบโอเมตริกซ์ เราศึกษาเปรียบเทียบข้อมูลภาพสแกนลายนิ้วมือ ข้อมูลภาพใบหน้า และข้อมูลภาพลายเซ็น การลดมิติได้รับการยอมรับว่าเป็นปัจจัยที่สำคัญเพื่อลดเวลาการทำงานของารรับรู้ภาพ เราจึงศึกษาเทคนิคการลดมิติ 2 เทคนิค คือ การวิเคราะห์องค์ประกอบหลัก (PCA) และการวิเคราะห์การจำแนกเชิงเส้น(LDA) อัลกอริทึมที่ใช้ในการฝึกและจำแนกภาพคือซัพพอร์ตเวกเตอร์แมชชีนโดยใช้สองฟังก์ชันเคอร์เนลที่ต่างกันคือ ฟังก์ชันเชิงเส้นและฟังก์ชันพหุนาม ผลการทดลองแสดงให้เห็นว่าการลดมิติด้วย LDA แล้วใช้ฟังก์ชันเชิงเส้นมีความถูกต้องมากกว่าและใช้เวลาน้อยกว่าไม่ใช้เทคนิคการลดมิติด้วย PCA ซึ่งเทคนิคนี้เหมาะสมกับข้อมูลไบโอเมตริกซ์แบบลักษณะทางกายภาพ เราพบว่าใช้องค์ประกอบ (component) เพียง 1% ของขนาดข้อมูลเดิมก็เพียงพอสำหรับการจำแนกความถูกต้องและทำให้เวลาที่ใช้ในการจำแนกข้อมูลเร็วกว่านำข้อมูลทั้งหมดมาจำแนก

คำสำคัญ : การลดมิติของข้อมูล การจำแนกข้อมูลไบโอเมตริกซ์ ซัพพอร์ตเวกเตอร์แมชชีน การวิเคราะห์องค์ประกอบหลัก การวิเคราะห์การจำแนกเชิงเส้น

Abstract

This research aims at studying the identification accuracy and execution time that are affected by dimensionality reduction of biometric data. We comparatively study the finger scan, face image and handwritten signature data. Dimensionality reduction has long been realized as an important factor to decrease the running time of image recognition. We thus study the two dimensionality reduction techniques: principal component analysis (PCA) and linear discriminant analysis (LDA). The algorithm that has been used to train and identify the images is a support vector machine with two different kernel functions: linear and polynomial functions. Experimental results showed that LDA dimensionality reduction by

การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ

using a linear function is more accurate and takes less time than not use PCA this technique is suitable for physiological biometric data. We found out is that only 1% of original image data dimensions is adequate for the accuracy and speed up identification.

Keywords: dimensionality reduction, biometric identification, support vector machine, principal component analysis, linear discriminant analysis

บทนำ

การลดมิติของข้อมูลเป็นเทคนิคในการเตรียมข้อมูล เป็นการทำให้ข้อมูลตั้งต้นมีขนาดลดลงโดยสูญเสียลักษณะสำคัญของข้อมูลน้อยที่สุดและสูญเสียความถูกต้องของผลลัพธ์น้อยที่สุด ถ้าข้อมูลมีจำนวนมิติหรือตัวแปรมากอาจจะใช้เวลานานในการนำไปประมวลผลและใช้หน่วยความจำค่อนข้างสูง เราจึงเลือกใช้เทคนิคในการลดมิติของข้อมูลที่นิยมใช้ในปัจจุบัน 2 เทคนิค คือ การวิเคราะห์องค์ประกอบหลัก (PCA) และการวิเคราะห์การจำแนกเชิงเส้น (LDA) นำมาช่วยให้สามารถลดการใช้ทรัพยากรต่างๆ เช่น ระยะเวลาในการฝึกฝน การสิ้นเปลืองหน่วยความจำ ให้กับข้อมูล และอาจเพิ่มประสิทธิภาพในการจำแนกข้อมูล ในงานวิจัยนี้ได้เลือกใช้ข้อมูลภาพไบโอเมตริกซ์ 3 ชุด คือ ข้อมูลภาพสแกนลายนิ้วมือ ข้อมูลภาพใบหน้า และข้อมูลภาพลายเซ็น แล้วนำข้อมูลที่ทำการลดมิติแล้วเข้าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ซึ่งเป็นอัลกอริทึมที่ได้รับความนิยมอย่างแพร่หลายในการฝึกและนำมาใช้กันอย่างกว้างขวางในด้านการจำแนกภาพ โดยใช้สองฟังก์ชันเคอร์เนลที่แตกต่างกันคือ ฟังก์ชันเชิงเส้นและฟังก์ชันพหุนาม

จากที่กล่าวมาแล้วนั้นผู้วิจัยจึงได้เสนอเทคนิคการลดมิติข้อมูล เพื่อทำการทดลองโดยมุ่งเน้นการเพิ่มประสิทธิภาพให้มีความถูกต้องดียิ่งขึ้นและเพิ่มความเร็วในกระบวนการจำแนกภาพที่เป็นไบโอเมตริกซ์เพราะเป็นข้อมูลที่มีความซับซ้อน ต้องการความน่าเชื่อถือและการจำแนกต้องแม่นยำ

งานวิจัยและทฤษฎีที่เกี่ยวข้อง

ไบโอเมตริกซ์ (Biometrics) [3] คือการตรวจวัดคุณลักษณะของร่างกายและพฤติกรรมของบุคคล มาใช้ในการระบุตัวบุคคลนั้นๆ แล้วนำคุณลักษณะที่ได้มาเปรียบเทียบกับคุณลักษณะที่บันทึกในฐานข้อมูล เพื่อแยกแยะบุคคลนั้นออกจากบุคคลอื่น ไบโอเมตริกซ์แบ่งออกเป็น 2 ประเภทคือ การใช้ลักษณะทางกายภาพ (Physiological Biometrics) เช่น ลายนิ้วมือ, ใบหน้า, จอตา, ม่านตา ลักษณะทางพฤติกรรม (Behavioural Biometrics) เช่น เสียง, การเดิน, การเซ็นชื่อ ซึ่งในงานวิจัยได้ใช้ภาพที่เป็นไบโอเมตริกซ์ 3 ข้อมูลคือ ข้อมูลภาพสแกนลายนิ้วมือ ข้อมูลภาพใบหน้า และข้อมูลภาพลายเซ็น

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) [1] เป็นวิธีจำแนกกลุ่มข้อมูลโดยใช้ตัวแบ่งแบบเชิงเส้นในการจำแนกข้อมูลออกเป็นสองคลาส ซึ่งซัพพอร์ตเวกเตอร์แมชชีนจะใช้ฟังก์ชันแม핑ฟังก์ชัน (Mapping Function) เพื่อแปลงข้อมูลจากโดเมนเดิมไปยังโดเมนที่เรียกว่า ฟีเจอร์สเปซ (Feature Space) และใช้ฟังก์ชันเคอร์เนล (Kernel Function) ในการวัดความคล้ายกันของข้อมูลในฟีเจอร์สเปซ โดยพยายามสร้างเส้นแบ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตทั้งสองกลุ่มกว้างที่สุด

ในงานวิจัยนี้ใช้เคอร์เนลฟังก์ชัน คือ ฟังก์ชันเชิงเส้น, ฟังก์ชันพหุนาม ในการทดสอบข้อมูลด้วยเทคนิคนี้

การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ

การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis : PCA) ใช้ในการหาความสัมพันธ์ของตัวแปรต่างๆ เหล่านั้น โดยจะสร้างตัวแปรใหม่ซึ่งประกอบขึ้นด้วยความแปรผันหรือความแปรปรวนของตัวแปรเดิม จึงนิยมใช้เพื่อลดขนาดเมตริกซ์ของตัวแปรให้เล็กลงหรือใช้หาความสัมพันธ์ของข้อมูลเป็นวิธีที่ใช้สร้างเมตริกซ์ของความแปรปรวนร่วม(Covariance Matrix) จากข้อมูลภาพ แล้วนำไปใช้ในการสร้างภาพใบหน้าไอเกน (Eigen Faces) มาใช้แทนข้อมูลเวกเตอร์(Eigenvector) โดยมีขั้นตอนการทำงานคือ[4][6]

- 1) แปลงเมตริกซ์ภาพเป็นเมตริกซ์ภาพมาเรียงต่อกันเป็นเวกเตอร์แถว
- 2) คำนวณหาค่าความแปรปรวนร่วมของข้อมูลเมตริกซ์ว่าเรียนซ์(Covariance Matrix) แล้วคำนวณหาไอเกนเวกเตอร์ที่สอดคล้องกันกับค่าไอเกน
- 3) เรียงลำดับไอเกนเวกเตอร์ที่สอดคล้องกับค่าไอเกนจากมากไปน้อยแล้วคัดเอาเฉพาะค่าที่ไม่เท่ากับศูนย์แล้วทำการสกัดเอาลักษณะเด่นของภาพเพื่อนำไปใช้ทำการรู้จำ


การวิเคราะห์จำแนกประเภทเชิงเส้น (Linear Discriminate Analysis : LDA)[2][5]เป็นเทคนิคที่ใช้กันทั่วไปสำหรับการลดมิติและจัดหมวดหมู่ข้อมูล โดยจะพิจารณารักษาจำนวนกลุ่มของข้อมูลให้มากที่สุดแต่ก็จะพยายามหาทิศทางตามกลุ่มข้อมูลเพื่อให้ถูกแยกออกให้ดีที่สุด มันคำนึงถึงการกระจายภายในกลุ่มและกระจายระหว่างกลุ่มนอกจากนี้ยังสามารถจำแนกภาพที่แตกต่างกันอันเนื่องมาจากแหล่งอื่น ๆ เช่น ไฟส่องสว่างและลักษณะการถ่ายภาพ

ขั้นตอนดำเนินงานวิจัย

งานวิจัยนี้ใช้ข้อมูลภาพ 3 ข้อมูล ได้แก่

- ภาพสแกนลายนิ้วมือ จาก <http://fvs.sourceforge.net/download.html> จำนวน 168 ภาพ เป็นภาพลายนิ้วมือทั้งหมด 21 นิ้ว โดยที่ 1 ลายนิ้วมือมี 8 ภาพ มีความละเอียด 80x80 pixels (6400 pixels)
- ภาพใบหน้า จาก <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html> จำนวน 400 ภาพ เป็นภาพใบหน้าบุคคล 40 คน ใบหน้า 1 ใบหน้ามี 10 ภาพ เป็นภาพใบหน้าผู้ชายจำนวน 360ภาพและใบหน้าผู้หญิง 40 ภาพ มีความละเอียด 64x64 pixels (4096 pixels)
- ภาพลายเซ็น จาก <https://sites.google.com/site/hhinganusarapesut/signature/datasets> จำนวน 600 ภาพ เป็นภาพลายเซ็น 30 คน 1 ลายเซ็นมี 20 ภาพ มีความละเอียด 38x144 pixels (5472 pixels)

ในงานวิจัยนี้ต้องการจะออกแบบอัลกอริทึมในการลดมิติข้อมูลให้มีค่าความถูกต้องที่สูง โดยมีขั้นตอนการทำงานดังแสดงในภาพที่ 1



ภาพที่ 1 โครงร่างขั้นตอนการดำเนินงาน

ผลการทดลอง

งานวิจัยนี้ทำการวัดประสิทธิภาพโดยคำนวณค่าความถูกต้อง (accuracy) ในการจำแนกข้อมูลด้วย อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ซึ่งได้ผลการทดลองดังนี้

ชุดข้อมูลภาพสแกนลายนิ้วมือ

- ก่อนใช้เทคนิคลดมิติข้อมูล
 - ฟังก์ชันเชิงเส้นประสิทธิภาพความถูกต้อง 52% ใช้เวลา 0.475 วินาที
 - ฟังก์ชันพหุนามประสิทธิภาพความถูกต้อง 59% ใช้เวลา 0.495 วินาที
- หลังใช้เทคนิคลดมิติข้อมูล
 - LDA ใช้ ฟังก์ชันเชิงเส้น (32 องค์ประกอบ จากทั้งหมด 6400 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 73.8% ใช้เวลา 0.461 วินาที และฟังก์ชันพหุนาม (16 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 47.6% ใช้เวลา 0.467 วินาที
 - PCA ฟังก์ชันเชิงเส้น (8 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 64% ใช้เวลา 0.139 วินาที และฟังก์ชันพหุนาม (1280 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 14% ใช้เวลา 6.471 วินาที


ชุดข้อมูลภาพใบหน้า

- ก่อนใช้เทคนิคลดมิติข้อมูล
 - ฟังก์ชันเชิงเส้นประสิทธิภาพความถูกต้อง 96% ใช้เวลา 1.138 วินาที
 - ฟังก์ชันพหุนามประสิทธิภาพความถูกต้อง 97% ใช้เวลา 2.184 วินาที
- หลังใช้เทคนิคลดมิติข้อมูล
 - LDA ใช้ 41 องค์ประกอบ (จากทั้งหมด 4096 องค์ประกอบ) ฟังก์ชันเชิงเส้นประสิทธิภาพความถูกต้อง 98% ใช้เวลา 0.540 วินาที และฟังก์ชันพหุนามประสิทธิภาพความถูกต้อง 91% ใช้เวลา 0.560 วินาที
 - PCA ฟังก์ชันเชิงเส้น (205 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 96% ใช้เวลา 1.327 วินาที และฟังก์ชันพหุนาม (410 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 98% ใช้เวลา 2.578 วินาที


ชุดข้อมูลภาพลายเซ็น

- ก่อนใช้เทคนิคลดมิติข้อมูล
 - ฟังก์ชันเชิงเส้นประสิทธิภาพความถูกต้อง 94.7% ใช้เวลา 3.600 วินาที
 - ฟังก์ชันพหุนามประสิทธิภาพความถูกต้อง 95.3% ใช้เวลา 3.640 วินาที
 - หลังใช้เทคนิคลดมิติข้อมูล
 - LDA ใช้ 55 องค์ประกอบ (จากทั้งหมด 5472 องค์ประกอบ) ฟังก์ชันเชิงเส้น ประสิทธิภาพความถูกต้อง 86% ใช้เวลา 1.727 วินาที และฟังก์ชันพหุนามประสิทธิภาพความถูกต้อง 84% ใช้เวลา 1.748 วินาที
 - PCA ฟังก์ชันเชิงเส้น (27 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 92.7% ใช้เวลา 0.568 วินาที และฟังก์ชันพหุนาม (557 องค์ประกอบ) ประสิทธิภาพความถูกต้อง 78.7% ใช้เวลา 4.063 วินาที
- จากผลลัพธ์การทดลองข้างต้น เราได้ทำการแสดงผลให้อยู่ในรูปแบบกราฟเพื่อวัดผลข้อมูลที่ใช่และไม่ใช้ เทคนิคลดมิติข้อมูลด้วย การวิเคราะห์องค์ประกอบหลัก (PCA) และการวิเคราะห์การจำแนกเชิงเส้น (LDA)


การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ



(ก) ภาพสแกนลายนิ้วมือ




(ข) ภาพใบหน้า




(ค) ภาพลายเซ็น

ภาพที่ 2 กราฟแสดงค่าความถูกต้องกับจำนวนองค์ประกอบ

จากภาพที่ 2 เป็นกราฟแสดงค่าความถูกต้องที่แนบกันตั้งกับค่าจำนวนองค์ประกอบในแนวแกนนอน จะเห็นว่ากราฟที่ใช้จำนวนองค์ประกอบน้อยๆ ในการจำแนกข้อมูลจะได้ค่าความถูกต้องสูงกว่าหรือเท่ากับการใช้จำนวนองค์ประกอบทั้งหมดของรูปภาพ ภาพสแกนลายนิ้วมือ และภาพใบหน้าการใช้การวิเคราะห์การจำแนกเชิงเส้น (LDA) ร่วมกับซัพพอร์ตเวกเตอร์แมชชีนฟังก์ชันเชิงเส้นให้ค่าความถูกต้องสูงสุด ส่วนภาพลายเซ็นใช้การวิเคราะห์องค์ประกอบหลัก (PCA) ร่วมกับซัพพอร์ตเวกเตอร์แมชชีนฟังก์ชันเชิงเส้นให้ค่าความถูกต้องสูงสุด




(ก) ภาพสแกนลายนิ้วมือ



(ข) ภาพใบหน้า

การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ



(ค) ภาพลายเซ็น

ภาพที่ 3 กราฟแสดงเวลาในการจำแนกกับจำนวนองค์ประกอบ

จากภาพที่ 3 เป็นกราฟแสดงค่าเวลาในแนวนอนตั้งกับค่าจำนวนองค์ประกอบ ถ้าดูที่การวิเคราะห์องค์ประกอบหลัก (PCA) จะเห็นว่าเวลาที่ใช้ในการจำแนกจะมีค่ามากถ้าจำนวนองค์ประกอบของภาพมาก แต่ถ้าดูการใช้การวิเคราะห์การจำแนกเชิงเส้น (LDA) จะเห็นว่าเวลาที่ใช้จะมีค่ามากถ้าจำนวนองค์ประกอบของภาพจำนวนน้อยๆ

สรุปผลงานวิจัย

งานวิจัยนี้นำเสนอการใช้เทคนิคลดมิติข้อมูลกับข้อมูลไบโอเมตริกซ์เพื่อลดเวลาและเพิ่มประสิทธิภาพในการจำแนกข้อมูล โดยใช้ข้อมูล 3 ชุดได้แก่ ชุดข้อมูลภาพสแกนลายนิ้วมือ ภาพใบหน้า และภาพลายเซ็น โดยใช้เทคนิคลดมิติข้อมูลที่นิยมใช้ 2 เทคนิค คือ การวิเคราะห์องค์ประกอบหลัก (PCA) และการวิเคราะห์การจำแนกเชิงเส้น (LDA) ผลการทดลองโดยการเปรียบเทียบประสิทธิภาพความถูกต้องด้วยอัลกอริทึมที่ใช้ในการจำแนกข้อมูลภาพคืออัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนโดยใช้เคอร์เนลฟังก์ชัน 2 เคอร์เนล ได้แก่ ฟังก์ชันเชิงเส้น และฟังก์ชันพหุนาม โดยเปรียบเทียบค่าความถูกต้องและเวลาในการจำแนกข้อมูลก่อนและหลังการใช้เทคนิคการลดมิติข้อมูล ผลการทดลองปรากฏว่าชุดข้อมูลภาพสแกนลายนิ้วมือใช้เทคนิคลดมิติข้อมูลด้วยเทคนิคการวิเคราะห์การจำแนกเชิงเส้นด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลฟังก์ชันเชิงเส้นได้ค่าความถูกต้องเพิ่มขึ้นจาก 52% เป็น 73.8% และภาพใบหน้าใช้เทคนิคลดมิติข้อมูลด้วยเทคนิคการวิเคราะห์การจำแนกเชิงเส้นด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลฟังก์ชันเชิงเส้นซึ่งมีค่าความถูกต้องเพิ่มขึ้นจาก 96% เป็น 98% ส่วนภาพลายเซ็นใช้การวิเคราะห์องค์ประกอบหลักร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลฟังก์ชันเชิงเส้นได้ค่าความถูกต้องลดลงจากเดิม 95% เป็น 92% จากผลการทดลองสามารถสรุปได้ว่าการใช้เทคนิคลดมิติข้อมูลสามารถทำให้ประสิทธิภาพดีและใช้เวลาน้อยกว่าไม่ใช้เทคนิคการลดมิติ และพบว่าใช้องค์ประกอบเพียง 1% จากองค์ประกอบทั้งหมดก็เพียงพอที่จะนำไปจำแนกข้อมูลได้โดยสามารถลดเวลาและประสิทธิภาพลดลงน้อยเมื่อเทียบกับไม่ใช้เทคนิคการลดมิติ การใช้เทคนิคลดมิติข้อมูลด้วยเทคนิคการวิเคราะห์การจำแนกเชิงเส้นด้วยเคอร์เนลฟังก์ชันเชิงเส้นจะจำแนกข้อมูลมีประสิทธิภาพดีขึ้นและใช้เวลาน้อยโดยจะเหมาะกับข้อมูลที่มีลักษณะเด่นชัดและมีรูปแบบแน่นอน

การประชุมวิชาการ "มศว วิจัย" ครั้งที่ 8
26-27 พฤศจิกายน 2557 มหาวิทยาลัยศรีนครินทรวิโรฒ

อ้างอิง

- [1] Ali, W., Shamsuddin, S.M., and Ismail A.S. (2011). "Web Proxy Cache Content Classification based on Support Vector Machine". *Journal of Artificial Intelligence* 4(1): 100-109.
- [2] Balakrishnama, S., and Ganapathiraju, A. (1998). *Linear discriminant analysis: a brief tutorial*. Mississippi State (MS): Institute for Signal and information Processing, Mississippi State University.
- [3] Delac, K., and Grgic, M. 2004."A Survey of Biometric Recognition Methods. " *In Proceedings of the 46th International Symposium on Electronics in Marine*, pp.184-193.
- [4] Vo Dinh, M. N., and Sung,Y. L. (2005). Two dimensional Weighted PCA algorithm for Face Recognition. In *Proceedings of the IEEE International Symposium on Computational Intelligence in Robotics and Automation*. pp. 219-223.
- [5] Tang, F., and Tao, H. (2006). Fast linear discriminant analysis using binary bases. In *Proceedings of the 18th international conference on pattern recognition (ICPR'06)*, V.2. pp. 219-223.
- [6] Turk, M., and Pentland, A. (1991). Eigenfaces for recognition. *Journal of Cognitive Neuroscience*. 3(1): 71-86.

มหาวิทยาลัยเทคโนโลยีสุรนารี

Fingerprint Recognition with Edge Detection and Dimensionality Reduction Techniques.

Ratiporn Chanklan*, Kedkarn Chaiyakhan, Anusara Hirunyanakul, Kittisak Kerdprasop, Nittaya Kerdprasop

Data Engineering Research Unit, School of Computer Engineering, Suranaree University of Technology,
Nakhon Ratchasima 30000

*Corresponding Author: arc_angle@hotmail.com

Abstract

In present an implementing fingerprint has been used widely. Such as fingerprint scanners first used your phones, used fingerprint scanner to save working hours. But the performance for implementing fingerprint also mistake. We assume that the fingerprint images to edge detection of the image to make the image more clearly, and may cause performance image recognition to better. We thus study the four edges detection: sobel, prewitt, robert and canny. For faster classification we apply two dimensionality reduction techniques: principal component analysis and linear discriminant analysis. Then, we identify biometrics with the algorithm support vector machine using kernel function linear. Experimental results showed that pre-processing fingerprint images using canny edge detection with principal component analysis the rate increased accuracy and highest from 64.3% to 88% and using canny edge detection with linear discriminant analysis the rate increased accuracy and highest from 73.8% to 88%

Keywords: fingerprint, edge detection, support vector machine, principal component analysis, linear discriminant analysis

1. Introduction

The combination of biological, medical and computer technology together by using the unique features of each person used to identify the person. And bring unique features to compare the unique features that have been recorded in the database for identify them from others. The system is called system identification biotechnology or biometric. The physical characteristics of the people do not change over time but the physical behavioral may have

changed. Thus identify the person by physical characteristics are reliable more than physical behavioral. In present fingerprint identification used to access devices such as cell phones is popular. The biometric system is not security enough, because the accuracy can't be a hundred percent. In the past, many researchers proposed edge detection techniques used to enhance the recognition. Improved performance the recognition by the application of wavelet transform with prewitt edge detection⁽¹⁾. Have taken edge detection used with gray level watershed approach makes fast data classification and better performance⁽²⁾. Edge detection is important to recognize the fingerprint. It influences on the image extraction and affects the matching of images. The algorithm should be chosen according to the characteristics of the image is detected to be implemented perfectly⁽³⁾.

We thus propose edges detection, which is important in image processing and widely used to enhance recognition. We uses fingerprint images in the experiment. However, fingerprint images each individuals will look very similar it making classification difficult. First, we should be separation element of image. The element is maintaining characteristics of fingerprint. We used separation element of image by finding four edges detection method: sobel, prewitt, robert and canny. Because it make a fingerprint images look clear. And we apply two dimensionality reduction techniques: principal component analysis and linear discriminant analysis. Dimensionality reduction is making a classification less time and save a memory. Then dimensionality reduction image data into the algorithm that is used in the classification. We identify by support vector machine with linear kernel and compared the performance of each model.

2. Theories

2.1 Edge detection

Edge detection⁽⁴⁾ is to find line around the object in the image. When we know line around the object, we can calculate the area (size) or recognition type of the object. However, finding correct image edge detection perfect not an easy task. In particular, finding edge of image with low quality or uneven light is even harder. Edges can be detected by the difference of light intensity from one point to another point. If there is much difference of light intensity, the edges can be outlined clearly. If the difference of light intensity is low the edges are not clear. Edge detection techniques can be divided into two main groups: Gradient method and Laplacian method.

In this study, we use four gradient methods: sobel edge detection, prewitt edge detection, robert edge detection, and canny edge detection.

2.1.1 Sobel edge detection

Sobel⁽⁴⁾ is used to find change of colors in image between object and background. The gradient value in each band is calculated by convolution image with filter of size 3X3. The result applying Sobel edge detection is show in Fig. 1.




Fig. 1. Demonstration of Sobel edge detection

2.1.2 Prewitt edge detection

Prewitt⁽⁴⁾ performs edge detection by calculating gradient vector of each point on the original image. The higher gray level intensity shows border between object and background. Gradient is calculate by filter of size 3X3. Example of Prewitt edge detection is show in Fig. 2.



Fig. 2. Illustration of Prewitt edge detection

2.1.3 Robert edge detection

Robert⁽⁴⁾ edge detection technique is similar to the Sobel edge detection. But use filter at smaller size of 2X2. Example of applying the Robert edge detection techniques is show in Fig. 3.



Fig. 3. Robert edge detection from samples image

2.1.4 Canny edge detection

Canny⁽⁴⁾ edge detection applies adjustments to smooth image with Gaussian filter to remove noise in the image. It makes a better edge finding. Then calculate magnitude size and orientation of gradient. The next step is to use non-maxima suppression with Gradient magnitude to make the edges thinner. Finally use double thresholding algorithm to identify edge pixels and connect consecutive edges. Demonstration of Canny edge detection to the sample image is shown in Fig. 4.



Fig. 4. Example of applying Canny edge detection

2.2 Dimensionality Reduction

Dimensionality reduction is an action to replace original data with a new set of compact data. It reduces memory usage and uses less time for classification. Classification or recognition over a set of compact data should produce the same result as or equivalent classifying the original data.

In this study, we use two dimensionality reduction techniques: principal component analysis and linear discriminant analysis.

2.2.1 Principal Component Analysis (PCA)

PCA^(5,6) is the technique of multivariate data analysis without segmenting variables. It is commonly used to reduce size of the matrix of variables to smaller size appropriate for the further analysis of data. PCA will create a new variable, which is made up of variable or the variance of a combination of original variables. Finding relations among image normally uses the matrix of covariance from image data to build an Eigen faces instead of the vector (Eigenvector).

2.2.2 Linear Discriminant Analysis (LDA)

LDA⁽⁷⁾ is a technique used for supervised learning. It is commonly used for dimensionality reduction over data variables and also for classifying data. It uses a function to project data onto a subspace in such a way that data coming from different classes are well separated, and data from the same class are formed closer together to allow easy classification. It considers a distribution within group and distribution between the groups. LDA can identify picture that are affected by factors such as lights and shooting characteristics.

2.3 Support Vector Machine (SVM)

SVM^(8,9) is a process of selecting the optimal model for inducing the patterns. Support vector machine is popular in pattern recognition and data classification. Support vector machines for classification use optimal hyperplane in classifying data. Hyperplanes can be created in various ways. But there will be the one optimal hyperplane that can maintain the greatest distance between two groups. The optimal hyperplane can be found by locating the support vector that is used as representative of the entire data set. This support vector is used to divide the data by taking a plane that can separate the two datagroups as much as

possible. Then find a plane with maximum margin and assume that plane a suitable one for classification.

We assume a set of n data points, $(x_1, y_1), \dots, (x_n, y_n)$ when $x \in R^m, y \in \{-1, 1\}$. When m is dimension, x is data input, and y is class -1 or +1. Creating a plane to split data can be calculated using Equations 1 and 2.

$$(w * x_1) + b > 0 \text{ where } y_i = +1 \quad (1)$$

$$(w * x_2) + b < 0 \text{ where } y_i = -1 \quad (2)$$

These equations classify data into either a class +1 or -1, depending on the data attribute value, weight(w), and bias(b). Example of creating a hyperplane to gain a maximum margin is shown in Fig. 5.




Fig. 5. Optimal hyperplane for classification

3. Research Process

This research used Fingerprint data set from <http://fvs.sourceforge.net/download.html>. It contains 168 fingerprint images of all 21 fingers; 1 finger has 8 images with a resolution of 80x80 pixels (6400 pixels).

In this study edges detection and dimensionality reduction have been applied to improve accuracy and to speed up the recognition. The process of experimentation is shown in Figure 6.

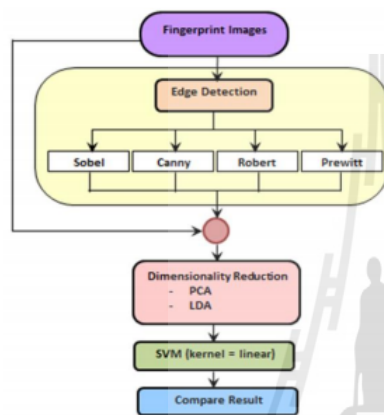



Fig. 6. The process of fingerprint recognition.


The first step of our comparative study is the application of 4 edges detection methods: sobel, prewitt, robert and canny. The implementation uses matlab program and python language with spyder editor to convert images data to array. Color in each pixel is convert to array 1 dimensional array. Then we apply dimensionality reduction techniques. In the last step, we use support vector machine algorithm to classify image data.

4. Experimental Results


This research measures the performance of the model by comparing the accuracy of the data classification with support vector machine algorithm. The experimental results before and after applying the edges detection techniques are shown in table 1, 2 and 3. Examples of fingerprint images obtained from each edge detection technique are illustrated in Fig. 7.




(a) Original fingerprint image




(b) Fingerprint image after applying sobel edge detection




(c) Fingerprint image after applying canny edge detection.



(c) Fingerprint image after applying canny edge detection.



(d) Fingerprint image after applying robert edge detection.



(e) Fingerprint image after applying prewitt edge detection.

Fig. 7. Fingerprint image samples.

4.1 Fingerprint Recognition Accuracy of Non-edge versus Edges Detection

We split data into two datasets: training data containing 126 images and test data consisting of 42 images. Then perform classification using support vector machine algorithm with linear kernel. The classification accuracy is 52.4%. This is the base line for comparison because it is the classification performance of the original image data. After applying edges detection: sobel, canny, and perwitt the classification accuracy increase.

Table 1. Before applying Dimensionality Reduction

edge detection	accuracy
Sobel	85.7 %
Camy	71.4 %
Robert	38.1 %
Prewitt	52.4 %
Non- edge	52.4 %

4.2 Recognition Accuracy of Full Feature Fingerprint versus Dimensionality Reduction

Table 2. Before applying edge detection

Dimension reduce	component	accuracy
LDA	32	73.80%
PCA	8	64.30%

When we use dimensionality reduction techniques, the classification accuracy increase significantly. LDA can increase accuracy from 52.4% to 73.80% and PCA increases accuracy from 52.4% to 64.30%.

4.3 Accuracy Improvement with Edge Detection and Dimensionality Reduction


Table 3. After applying LDA with edge detection

edge detection	component	accuracy
Sobel	32	88%
Camy	32	71.4%
Robert	16	40.5%
Prewitt	32	45.2%


Table 4. After applying PCA with edge detection

edge detection	component	accuracy
Sobel	7	88%
Canny	10	83.3%
Robert	6	52.5%
Prewitt	16	71.4%

We have shown results before and after edge detection with two dimensionality reduction technique: principal component analysis (PCA) and linear discriminant analysis (LDA), as a graph in Fig. 8.



(a) This graph shows the accuracy with the components by edges detection and LDA.



(b) This graph shows the accuracy with the components by edges detection and PCA.

Fig. 8. Graph shows all results.

Fig. 8 is a graph showing the accuracy in accordance with the number of components. We are interested in the most accuracy model by comparing between edge detection method and non-edge detection method. Non-edges detected LDA + SVM gives the most accurate model at 73.8%. After using sobel edge detection + LDA + SVM, model's accuracy increases to 88%. Non-edge detected + PCA + SVM has the highest accuracy at 64.3%. After using sobel edge detection + PCA + SVM the accuracy increase to 88%. The accuracy is increased after applying edge detection because the fingerprint images can be noticed clearly. It can be seen from examples in Fig. 7 that the sobel edge detection technique converts prominent ridges into gray scale that can facilitate the classification algorithm.

4 Conclusions

The fingerprint recognition technology is widely used in many real-life applications such as the access to mobile devices, border control, entering building, and so on. Adopting fingerprints for identification and authentication is, however, still inaccurate. We propose in this paper the improvement of fingerprint image recognition through the use of edge detection and dimensionality reduction techniques. We use four edge detection methods: sobel, prewitt, robert, and canny. We apply dimensionality reduction techniques to help faster identification using two techniques: principal component analysis and linear discriminant analysis. Then classify fingerprint image with support vector machine using linear kernel. In a series of experimentation, we use fingerprint images of size fingerprint image size 80x80 pixels (6400 components). The dataset contains of 168 images obtained from 21 people. The experimental results showed that LDA + SVM gave a classification model that has the highest accuracy at 73.8%. After using sobel edge detection + LDA + SVM the increased accuracy to 88%. And PCA + SVM, model has the highest accuracy 64.3% after using sobel edge detection + PCA + SVM model accuracy increased to 88%. The results can be summarized as sobel edge detection when used in conjunction with dimensional reduction technique: principal component analysis or linear discriminant analysis, the recognition of fingerprint image can be significantly enhanced.

References

- (1) Zhou Weina, Han Jun, Zeng Xiaoyang and Yan Weiwei : "Fingerprint verification based on wavelet and edge detection", 9th International Conference on Electronic Measurement & Instruments, Vol 3, pp. 1001-1004, 2009
- (2) G.Sambasiva Rao, C. NagaRaju, Dr.L.S.S. Reddy and Dr.E.V. Prasad : "A Novel Fingerprints Identification System Based on The Edge Detection", Journal of Computer Science and Network Security, Vol. 8, No.12, pp. 394-397, 2008
- (3) Wei Cui, Guoliang Wu, Rongjin Hua and HaoYang: "The research of edge detection algorithm for Fingerprint images", Automation Congress (WAC 2008), Vol. 1, pp. 1-5, 2008
- (4) Gonzalez, R. C., and Woods, R. E : "Digital Image Processing", Addison-Wesley, 1992
- (5) Dinh Minh Nhat, V., and Young Lee, S: "Two dimensional Weighted PCA algorithm for Face Recognition", IEEE International Symposium on Computational Intelligence in Robotics and Automation, pp. 219-223, 2006
- (6) Turk, M., and Pentland, A: "Eigenfaces for recognition", Journal of Cognitive Neuroscience. Vol. 3, pp. 71-86, 1991
- (7) Balakrishnama, S., and Ganapathiraju, A: "Linear discriminant analysis: a brief tutorial", Mississippi State (MS): Institute for Signal and information Processing, Mississippi State University, 1998
- (8) Pornpon Thamrongrat, Ladda Preechaweeraikul and Wipada Wetpasit: "Web Page Classification Using Document Frequency and Support Vector Machine", The 12th National Computer Science and Engineering Conference, 2008.
- (9) Ali, W., Shamsuddin, S.M., and Ismail A.S: "Web Proxy Cache Content Classification based on Support Vector Machine", Journal of Artificial Intelligence, Vol. 4, No.1, pp. 100-109, 2011

Traffic Sign Classification using Support Vector Machine and Image Segmentation

Kedkarn Chaiyakhan*, Anusara Hirunyanakul, Ratiporn Chanklan,
Kittisak Kerdprasop, Nittaya Kerdprasop

Data Engineering Research Unit, School of Computer Engineering, Institute of Engineering,
Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand.
Rajamangala University of Technology Isan, Nakhon Ratchasima 30000, Thailand.

*Corresponding Author: kedkarn@hotmail.com

Abstract

Traffic sign classification system is a part of driving assistance system that automatically alerts and instructs the driver about the meaning of traffic signs. In this paper, we proposed the idea for classifying automatically each type of traffic signs. The proposed method has been tested with a publicly available dataset: German Traffic Sign Recognition Benchmark (GTSRB). We use 360 images for testing by grouping traffic signs into 12 groups and images are taken by short distance from camera. In the first stage of our method, we have to separate particular traffic sign from background using color analysis, edge detection, and region of interest (ROI). In the process of ROI, we use Hough Transform algorithm to detect the different shapes of circle, square, and triangle. After we obtained edge images and images from ROI, in the subsequent stage we use 75% of images for training and 25% of images for testing using support vector machine classification algorithm. From ROI image we use feature extraction to get normal direction from edge image and also use support vector machine (SVM) to classify and compare results between ROI and ROI with normal direction feature. In our experimental results, using ROI and SVM can improve the efficiency of classification which has the accuracy 73%, ROI with normal direction feature and SVM can improve the efficiency of classification which has the accuracy 88.60%, when compare with the original involved background 67.80%. The improvement from SVM is about 5% and 20.8% respectively.

Keywords: image classification, support vector machine, hough transform, feature extraction, ROI.

1. Introduction

Image segmentation is the important process to subdivide an image into several regions. It is an important topic in computer vision and image processing. The result of segmentation is objects that are separated from background. The separated objects can decrease processing time and processing steps. Nowadays image segmentation has been widely used in several kinds of applications such as industrial images, geography and traffic safety. In this paper, we propose the experiment results of classification for several kinds of traffic signs by performing segmentation using image processing technique and classifying with support vector machine.

Traffic sign was designed for human to recognize and interpret the meaning of the abstract sign which using uncomplicated shape, character and symbol. The development of traffic sign recognition has been used for automatic driven vehicle or warning system for driver. Then it is an interesting task to make the computer identify, distinguish, and recognize the traffic sign correctly.

Color space is primarily used to obtain image information and detection. The Hue-Saturation-Value^(1,2) (HSV) color space has been the most popular one as it based on human color perception. In addition it is considered largely invariant to illumination changes and also used to classify traffic sign by color separation. Many researchers use Red-Green-Blue (RGB) color space⁽³⁾ to get image information and then convert it to a gray scale image to find edge contour of traffic sign region. However RGB is not a good representation with color separated between

objects and background. Thus, the conversion of RGB to gray scale image is required and then uses gray scale image to find contour edge. The contour edge can describe the shape properties of object and finally the position of object can be derived.

Currently, there are many researches in traffic sign segmentation and recognition that using several algorithms. Amplitude segmentation methods is the simplest method to separate the region of traffic sign using a proper threshold value, but the result is not good since the intensity of image and background are similar. Boundary detection method⁽⁴⁾ is rather be popular and get good efficiency result of image segmentation is edge detection. This method takes quite a long time in processing, because after obtaining edge contour, the next step is to find the arbitrary shape in image.













2. Related Work

Many methodologies and researches have been proposed for traffic sign classification system. Sekanian et al.⁽⁵⁾ proposed the detection of Norwegian speed limit signs. They design for 3 steps. Color classification using HSV color space, position detection of speed limit sign using template matching, and speed limit number recognition using neural network. Liu et al.⁽⁶⁾ proposed vision-based stop sign detection and recognition systems for intelligent vehicle based on HSV color space, size analysis, and ratio of traffic sign. They used neural network technique in recognition process. Huda et al.⁽⁷⁾ proposed real-time detection and recognition of Indian traffic signs using matlab. They also used gaussian filter and median filter to remove noise in image and used YCbCr color space in segmentation process. In the next step they used feature extraction before classification and recognition using multi-layer perceptron neural network method. Another method has also been proposed by Surinwarangkoon et al.⁽⁸⁾ based on thresholding. They use RGB color space in segmentation process. They also use feature selection before classification process in traffic sign recognition system in poor condition.

3. Characteristics of Traffic Sign

Since traffic signs provide important information for driver about caution and hazard, their color and shape are chosen by traffic authorities to make them easy to understand by humans. In this paper, we selected traffic signs from German Traffic Sign Recognition Benchmark

Table 1. Different categories of traffic signs from GTSRB.

Traffic Sign Types	Image	Traffic Sign Types	Image
Speed limit (30 km/h)		Speed limit (120 km/h)	
Speed limit (50 km/h)		No overtaking	
Speed limit (60 km/h)		No overtaking by lorries	
Speed limit (70 km/h)		Right of way at the next crossroads	
Speed limit (80 km/h)		Priority road	
Speed limit (100 km/h)		Give way	

(GTSRB). The dataset used in our experiment contains 360 images, which are separated into 12 categories. There are mainly 3 shapes of traffic signs in our experiment such as circle, square, and triangle. Short distance photos were taken in shady, normal and bright light conditions by camera for every image. The size of the traffic signs were normalized to 80 X 80 pixels for size testing of signs. Different category of traffic signs from GTSRB are shown in Table 1.

4. Materials and Methods

4.1 Canny Edge Detection

In this paper we use canny edge detection to compute gradient direction of image. Canny edge detection enhances the image using smoothing process by Gaussian filter to blur image for eliminating noises in image. Then compute the gradient magnitude and gradient orientation using first-order derivative. Next step is to use non-maxima suppression and gradient magnitude to find thinnest contour. The last step is to use double thresholding algorithm to specify contour pixels and make the contour continuously.

Noise reduction is the first step using Gaussian filter.




Fig. 1. Normal direction of edge pixel.

Given that $I[i,j]$ is the image which require edge contour, $G[i,j, \sigma]$ is Gaussian smoothing filter, and σ is the variable to control the distribution of smoothing. The smoothing process is as follows:

$$S[i,j] = G[i,j,\sigma] * I[i,j] \quad (1)$$

When smooth the image with noise reduction, the next step is to take the $S[i,j]$ image to compute x, y partial derivatives $P[i,j]$ and $Q[i,j]$ respectively

$$P[i,j] \approx (S[i,j+1] - S[i,j] + S[i+1,j+1] - S[i+1,j])/2 \quad (2)$$

$$Q[i,j] \approx (S[i,j] - S[i+1,j] + S[i,j+1] - S[i+1,j+1])/2 \quad (3)$$

In the final step $P[i,j]$ and $Q[i,j]$ can be compute by converting rectangular coordinates to polar coordinates to find the size and direction of gradient.

$$M[i,j] = \sqrt{P[i,j]^2 + Q[i,j]^2} \quad (4)$$

$$\theta[i,j] = \arctan(Q[i,j], P[i,j]) \quad (5)$$

Thus the normal direction of edge pixel can be compute in the process of Canny edge detection. These normal direction values are the feature extraction that has been used in image segmentation by support vector machine. Normal direction on each edge pixel shown in Fig.1.

4.2 Region of Interest (ROI)

Region of Interest is the method to crop the specific region of object in the image by eliminating background. ROI can be obtained by using binary edge contour image to find the position of circle, triangle, and square in image. The Hough transform is the algorithm to find the position of object. Since this paper uses 3 shapes of traffic sign, thus 2 methods of Hough transform algorithm were used to find sign position: Hough transform for circle detection and Hough transform for line detection to detect triangle and square.

(a) Hough transform for circle detection

Circle detection using Hough transform is the method




Fig. 2. Coordinate of circle and line.

for circle detection in image. Every edge pixel in binary image was substituted in geometric circle equation called Hough space to obtain a center of circle and radius in an image using maximum vote value of X_c, Y_c , and r .

$$X_c = x + r \cos \theta \quad (6)$$

$$Y_c = y + r \sin \theta \quad (7)$$

Where X_c and Y_c are the possible center point of circle (range of X_c is 1 to image width, Y_c is 1 to image height), x and y are edge pixel coordinate, r is radius of circle (range of r is 1 to half diagonal distance of image), and θ is possible angle when measure along x coordinate (0-360 degrees) as shown in Fig. 2.

(b) Hough transform for line detection

Line detection using Hough transform is the method for line detection in image. Every edge pixel in binary image was substituted in geometric line equation called Hough space to derive the maximum vote of each line. If there are 3 maximum votes and 3 intersection in Hough space the object is triangle. Likewise, if there are 4 maximum votes and 4 intersection in Hough space the objects is square.

$$d = x \cos \theta + y \sin \theta \quad (8)$$

Where d is distance from the origin point when perpendicular measuring from specific line, θ is possible angle (0-360 degrees) of line when dragging from origin point to perpendicular with line along x coordinate, x and y are coordinates of edge pixel as shown in Fig. 2.

4.3 Support Vector Machine (SVM)

In this section we introduce some basic concepts of SVM and different types of kernel function.

(a) Overview of SVM

Support vector machine is supervised machine learning algorithm used for classification and regression problems by generating the optimal separation hyperplane in a multi-dimensional space. The basic idea




Fig. 3. Optimal hyperplane with maximum margin.

of SVM is to find the optimal hyperplane to separate datasets. Two parallel hyperplanes are constructed on each side of the hyperplane that separate the data. The separating hyperplane is the hyperplane that maximizes the distance between the two parallel hyperplanes. An assumption is made that the larger of margin or distance between these parallel hyperplanes, the better of classification as shown in Fig. 3.

We consider 2 datasets of the form

$$D = \{(x_1, y_1), \dots, (x_l, y_l)\}, x_i \in R^m, y_i \in \{-1, 1\} \quad (9)$$

Where l denote the amount of dataset, i denote the sequence of data, m is number of dimensions, and y is classification result consisting of +1 and -1 to denote each group of dataset after separation process.

If the training data are linearly separable, we consider the dataset by specifying x_1 to be data of x_i and value is positive. Likewise x_2 is data of x_i and value is negative. This can be written as

$$\begin{aligned} (w * x_1) + b &> 0 \text{ where } y_i = +1 \\ (w * x_2) + b &< 0 \text{ where } y_i = -1 \end{aligned} \quad (10)$$

Where w denotes weight of vector, x_1 is positive data vector, x_2 is negative data vector, and b denotes bias value.

(b) Kernel Function of SVM

Training vectors can be represented in a higher dimensional space. There are many kernel functions available in SVM. So how to select an optimal kernel function is also a research problem. However, for general purpose, there are some popular kernel functions:

- Linear kernel:

$$K(x_i, x_j) = x_i^T x_j \quad (11)$$

- Polynomial kernel:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \quad \gamma > 0 \quad (12)$$

- RBF kernel:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0 \quad (13)$$

- Sigmoid kernel:

$$K(x_i, x_j) = \tanh \gamma x_i^T x_j + r \quad (14)$$

Here, γ , r and d are kernel function parameters.

5. Proposed Work

A framework of proposed work for segmentation and classification of traffic sign is shown in Fig. 4. The main stages of our implementation are: image pre-processing using edge detection, image pre-processing using Hough transform to get region of interest (ROI), and classification process using support vector machine with different kinds of kernel functions.

5.1 Image Pre-processing using Canny Edge Detection

In Canny edge detection process; the first step is to decrease the dimensions of color space by converting color image to gray scale image to the remaining of only 256 colors, since much color is not necessary to find edge. Then the Canny edge is detected from gray scale image, as shown in Fig. 5

5.2 Image Pre-processing using Region of Interest

In the process to finding region of interest (ROI) by eliminating background, there are two main steps to detect region of traffic sign: convert color image to gray scale image and edge detection using canny edge detection, because it can remove noise from image by blurring to improve the quality of edge image. After that, the edge image is then sent to Hough transform to detect circle, triangle, and square. So, we can obtain the region of interest of traffic sign and then in the final step, region of interest has been sent to classification process using support vector machine as shown in Fig. 6.

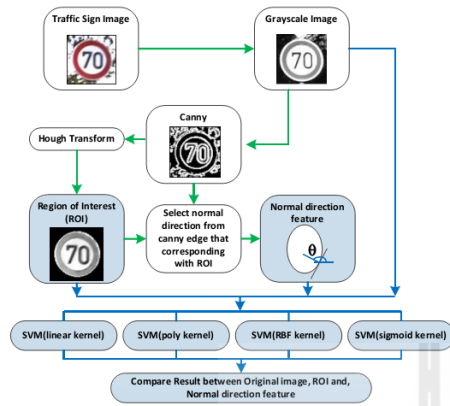


Fig. 4. A framework of proposed work.



Fig. 5. Canny edge image.

5.3 Feature Extraction

After we obtained the edge image we also obtained the normal direction feature. The normal direction of gradient or normal vectors are derived from the line that drags to touch every edge pixel from edge image which we call tangent vector, and then draw the perpendicular line with tangent vector. We will get the normal direction degree when measure angle along x axis. The normal direction in every edge pixels are the feature that will use in SVM classification process. Because normal direction feature can represents the shape and curve of object in degree of angles (0-360). Normal direction feature is shown is Fig.7.

5.4 SVM Classification

In SVM training process, we have 3 models for training images including original images that are converted to gray scale, ROI and, ROI with normal direction feature. All 3




Fig. 6. Find ROI using Hough transform.




Fig. 7. Normal direction feature on every edge pixel.

models were trained from 270 images. In classification evaluation process, 90 images were used for testing. These tested images had been performed with image processing steps the same as those in the training process. Finally, we use 4 kernels functions (Linear, Polynomial, Sigmoid, and RBF) in SVM classification process.

6. Experimental Results

In this paper, we use 360 images from 12 categories and 3 different shapes such as circle, triangle, and square.

We use Matlab for pre-processing images and Python 2.7 use for the classification process. SVM is the efficiency method that has been widely used for classification and we also use 4 kernel functions in classification process as shown the experimental results in Table 2.

Linear kernel function gives rather high accuracy when

compared with other kernel functions. The accuracy rates are ranging between 67.80% - 88.60%. But original image gives low accuracy.

Polynomial kernel function obtains medium accuracy between 46.70% - 54.50%. Original image gives low accuracy for this kernel function.

RBF and sigmoid kernel function get very low accuracy in all methods of pre-processing image. The accuracy rates are between 4.40% - 28.70%.

The accuracy of classification when using ROI with linear kernel function is 73% and the accuracy of classification when using ROI with normal direction feature is 88.60%. The results of Polynomial, RBF and Sigmoid kernel functions are rather low as shown in Table 2.

In Table 2, we found that the classification accuracy of linear kernel function with region of interest (ROI) and region of interest with normal direction feature techniques is rather good on 3 methods of image pre-processing. Accuracy of original image is 67.80%, ROI 73% and, ROI with normal direction feature 88.60%. A comparative graph of classification accuracy using image pre-processing techniques with 4 kernel functions is shown in Fig. 8.

7. Conclusions

Traffic signs classification using support Vector machine and image segmentation is the main contribution presented in this paper. The image segmentation algorithm namely region of interest (ROI) and region of interest (ROI) with normal direction feature using SVM linear kernel function is quite efficient for classification. It can improve the accuracy of classification from 67.80% to 73% and 88.60%; the increase is about 5% and 20.8%. This increase is due to the fact that ROI will crop image only the region of traffic signs and eliminate the unnecessary background. We also use feature extraction with normal direction and bring the results to compare with ROI and original image. The accuracy of original image when used in classification process is not good. We found that the classification result using original image get low accuracy because original image consists of noisy background. On the other hand, ROI and ROI with normal direction feature are the gray scale image which has possible 256 intensity values, and we crop the specific region of traffic sign and also eliminate noisy background from image. Hence, ROI and ROI with normal direction feature when using with SVM linear kernel function already shows good accuracy in terms of segmentation and classification.

Table 2. Classification results for each method.

SVM	Original		ROI		Normal direction	
	Accuracy		Accuracy		Accuracy	
	Train	Test	Train	Test	Train	Test
Linear	1.000	0.678	1.000	0.730	1.000	0.886
poly	1.000	0.467	1.000	0.511	0.958	0.545
RBF	1.000	0.067	1.000	0.067	1.000	0.365
Sigmoid	0.960	0.044	0.096	0.044	0.0975	0.287




Fig. 8. Accuracy of classification using image.

In future work, we will mainly focus on improving the efficiency of the traffic sign segmentation and classification in order to use other information in image such as texture feature and morphological features. We will also apply feature extraction and feature selection before classification process to improve accuracy and reduce misclassification data.

Acknowledgment

Financial assistance for Kedkam Chaiyakhan has been provided by a scholarship from Rajamangala University of Technology Isan, Nakhorn Ratchasima, Thailand.

References

- (1) G. Piccioli, E. De Micheli, P. Parodi, and M. Campani : "A robust method for road sign detection and recognition", *Image and Vision Computing*, Vol. 14, No. 1, pp. 209-223, 1996
- (2) X. W. Gao, L. Podladchikova, D. Shaposhnikov, K. Hong, and N. Shevtsova : "Recognition of traffic signs based on their colour and shape features extracted

- using human vision models”, Journal of Visual Communication and Image Representation, Vol. 17, pp. 675-685, 2006
- (3) A. de la Escalera, L. E. Moreno, M. A. Salichs, and J. M. Armingol : “Road traffic sign detection and classification”, IEEE Transactions on Industrial Electronics, Vol. 44, pp. 848-859, 1997
 - (4) T. Surinwarangkoon, S. Nitsuwat, and E. J. Moore : “Traffic sign recognition by color filtering and particle swarm optimization”, 4th International Conference on Computer Research and Development, pp. 55-59, 2012
 - (5) L. Sekanina, and J. Torrensen : “Detection of Norwegian Speed Limit Signs”, In Proc. Of the 16th European Simulation Multiconference, pp. 337-340, 2002
 - (6) X. Lui, and B. Ran : “Vision-based Stop Sign Detection and Recognition System for Intelligent Vehicle”, Journal of the Transportation Research Board, Vol. 1748, pp. 161-166, 2001
 - (7) H. Dean, and Jabir : “Real Time Detection and Recognition of Indian Traffic Signs using Matlab”, International Journal of Scientific & Engineering Research, Vol. 4, pp. 684-690, 2013
 - (8) T. Surinwarangkoon, S. Nitsuwat, and E. J. Moore : “Traffic Sign Recognition System for Roadside Images in Poor Condition”, International Journal of Machine Learning and Computing, Vol. 3(1), pp. 121-126, 2013



A New Efficient Method to Improve Handwritten Signature Recognition

Anusara Hirunyanakul*, Kedkam Chaiyakhan, Ratiporn Chanklan, Kittisak Kerdprasop, Nittaya Kerdprasop

Data Engineering Research Unit, School of Computer Engineering, Institute of Engineering,
Suranaree University of Technology, NakhonRatchasima 30000,Thailand.

*Corresponding author: Anusara.cpe8@gmail.com

Abstract

In this research we demonstrate the improvement for handwritten recognition using edge detection technique and our novel technique of adding intensive data. We collect totally 600 signatures from 30 people. Then we transform the hand written signatures images to be image file and resize to 144 x 38 pixels along the width and the height, respectively. Every pixel is encoded its intensity value from 0 to 255. The value 0 is the highest intensity (black) and 255 is white. Next, we use 4 different algorithms: Support Vector Machine (with linear, polynomial, radial basis, and sigmoid kernel functions), k-Nearest Neighbors, Perceptron, and Naïve Bayes (using Gaussian, multinomial, and Bernoulli density functions). From the experiment result, SVM with polynomial kernel function shows the highest accuracy (95.33%). Then we use 4 techniques of edge detection: Sobel, Prewitt, Robert, Canny and Thinning technique. With Sobel edge detection technique, we found that the accuracy is gained to 96% (higher than the highest of original data). We also observe that Sobel technique can improve the accuracy of k-NN with a significant level (from 78.67% to 91.33%). Moreover, we try to append the high intensity color data. And by this technique, we notice significant improvement of k-NN accuracy up to 96%. In SVM with linear function, after applying our technique the accuracy is improved to 98.00% which is the highest accuracy of this research.

Keywords: image recognition, handwritten signature, support vector machine, k-nearest neighbor, naïve Bayes

1. Introduction

The use of biometric in authentication or individual identification receives much attention in the current. It provides convenience of not having to carry identification

documents, which reduces the problem of document falsification. The signature is external identity which is widely used for identifying individual. Signature of a person is distinct and it is hardly to be forged or counterfeited.

Vargas et al.⁽¹⁾ reviewed the handwritten signatures focusing on the grey-scale measurement and co-occurrence matrix technique and local binary pattern base on MCYT-75 and GPDS-100 databases. The result was that the EER (Equal Error Rate) = 16.27%.

Guerbai et al.⁽²⁾ proposed the powerful use of OC-SVM for handwritten signature verification. The result from the experiment was 5-7% AER (Average Error Rate) in CEDAR dataset, whereas 15 - 17% AER in GPDS dataset.

Frias-Martinez et al.⁽³⁾ demonstrated the handwritten recognition based on the Support Vector Machine (SVM) and compared to a traditional classification technique like Multi-Layer Perceptron (MLP). The experimental results showed that SVM could provide up to 71% accuracy rate, which is better than the MLP technique.

Zheng et al.⁽⁴⁾ conducted edges and gradients detection, which was an innovative method for finding clearer edges. They used Least Squares Support Vector Machine (LS-SVM) with radial basis kernel function and Sobel and Canny edge detection. The outcome revealed that these techniques were even more effective than applying only a single machine learning technique.

Most researches on signature recognition often focused on a comparative study to find algorithms suitable for the signature recognition. However, we often encounter problems of a similar signature of different individuals or slightly different signatures of the same individual. Due to various environmental conditions, the accuracy of signature identification turns derogated. We have realized the importance of pre-processing. It is the importance step that can affect the accuracy rate. This paper proposes a

technique to enhance the signature recognition by focusing the improvement of signature images. The signature images will be improved by edge detection technique and thinning edge technique. In addition, we propose a novel concept, which is never seen in any previous signature recognition researches; that is, to append the interesting area of image dataset. And in this case is high intensity color data.

2. Related Theorems and Algorithms

2.1 Pattern Recognition

The pattern recognition⁽⁵⁾ is the study about object classification with respect to "Feature" of each "Class." The method can be applied to various fields, for example, the individual identification using biological data, e.g. fingerprint, face, iris, DNA, or even a signature, as well as the recognition of documents, e.g. pattern recognition of spam mail.

Issues related to pattern recognition and classification have been of great interest at present. As a result, technology and various advanced tools have been developed to be applied. The classification often requires knowledge of various branches, e.g. data mining, artificial neural network, machine learning, data improvement processes such as image-data improvement by edge detection.

2.2 Image Edge Detection

The image edge detection⁽⁶⁾ is used to detect lines showing around the shape of an object by cutting away any other details, e.g. color or streaked. The image used to represent the shape of the object is represented as a "Binary Image." Edge detection can be done in a variety of ways with similar principles; that is, to find the difference of color between the "Gray Scale" of one point and the other point. If the light intensity is very different, the edges will be clearer; however, if the color difference is less, the edges can be vague. The edge detection can be applied in computer vision, e.g. boundary separation between object and background or object recognition etc.

2.2.1 Sobel Edge Detection

Sobel edge detection⁽⁶⁾ is the edge detection method by using the 2 filters with the size 3 x 3 called "Sx" and "Sy" to separate objects and background. The gradient values of each band will be computed and create the filters. Example of Sx and Sy filter are in figure 1.

$$\begin{array}{|c|c|c|} \hline -1 & 0 & 1 \\ \hline -2 & 0 & 2 \\ \hline -1 & 0 & 1 \\ \hline \end{array} S_x \qquad \begin{array}{|c|c|c|} \hline 1 & 2 & 1 \\ \hline 0 & 0 & 0 \\ \hline -1 & -2 & -1 \\ \hline \end{array} S_y$$

Fig.1.Sobelfilter.

The calculation of sobel gradient value is shown in equation 1.

$$Sobel\ gradient = \sqrt{(S_x^2 + S_y^2)}(1)$$

2.2.2 Prewitt Edge Detection

Prewitt edge detection⁽⁶⁾ is detection technique using the same concept as the Sobel edge detection. The differential is the value in the filters that shown in figure 2.

$$\begin{array}{|c|c|c|} \hline -1 & 0 & 1 \\ \hline -1 & 0 & 1 \\ \hline -1 & 0 & 1 \\ \hline \end{array} h_x \qquad \begin{array}{|c|c|c|} \hline -1 & -1 & -1 \\ \hline 0 & 0 & 0 \\ \hline 1 & 1 & 1 \\ \hline \end{array} h_y$$

Fig.2.Prewitt filter.

Prewitt gradient can be calculated as shown in equation 2.

$$Prewitt\ gradient = \sqrt{(h_x^2 + h_y^2)}(2)$$

2.2.3 Robert Edge Detection

Robert edge detection⁽⁶⁾ is a technique using 2x2 size filters called "Gx" and "Gy". The concept of this edge detection is to calculate the gradient of an image which is summarized from the differences between diagonally adjacent pixels. The filter of Robert edge detection is shown in figure 3.

$$\begin{array}{|c|c|} \hline 1 & 0 \\ \hline 0 & -1 \\ \hline \end{array} G_x \qquad \begin{array}{|c|c|} \hline 0 & 1 \\ \hline -1 & 0 \\ \hline \end{array} G_y$$

Fig. 3.Robert filter.

Robert gradient can be calculated as shown in equation 3.

$$G(F(i,j)) = |f(i+1,j+1) - f(i,j)| + |f(i+1,j) - f(i,j+1)| \quad (3)$$

2.2.4 Canny Edge Detection

The first step of Canny edge detection⁽⁶⁾ is to eliminate noise. Noise can be removed by using Gaussian Filter to clear the speckles and smooth the edge of image. In the second step, a gradient operator will be applied to achieve the gradient's intensity and direction. Then, The non-maximum suppression is used for thinning the images' edge by determining if the pixel is a better candidate than its neighbors. The final step is using double thresholding algorithm to specify contour pixels and make the edge continuous.

The calculation of Gaussian Filter which is applied in Canny edge detection can be explained by equation 4.

$$S[i, j] = G[i, j, \sigma] * I[i, j] \quad (4)$$

where $S[i, j]$ is image after filtered,

$I[i, j]$ is image for finding edge detection,

$G[i, j, \sigma]$ is Gaussian filter, and

σ is a variable to control the distribution of smoothing the image.

The image $S[i, j]$ is used in equation 5 and 6 to find the x, y partial derivatives $P[i, j]$ and $Q[i, j]$. The size and direction gradient are explained in equations 7 and 8, respectively.

$$P[i, j] \approx (S[i, j + 1] - S[i, j] + S[i + 1, j + 1] - S[i + 1, j]) / 2 \quad (5)$$

$$Q[i, j] \approx (S[i, j] - S[i + 1, j] + S[i, j + 1] - S[i + 1, j + 1]) / 2 \quad (6)$$

$$M[i, j] = \sqrt{P[i, j]^2 + Q[i, j]^2} \quad (7)$$

$$\theta[i, j] = \arctan(Q[i, j] / P[i, j]) \quad (8)$$

2.3 Thinning Edge

The edge thinning⁽⁶⁾ is an important preparation process (pre-processing) that is widely used to slenderize image with thick edges, which is produced from the edge detection. This is to remove the excessively thick edge pixels. Usually, excessively thick edge slenderizing is used in character recognition and signature recognition to eventually generate thinnest edge lines with only one pixel.

The thinning edge operation can be done by using P1 and P2 filters. The first step in doing that is to use the P1 filter; using the 3x3 template to scan the image data and then decide whether or not the pixels around the edges can be deleted. If the pixels can be deleted, mark them but do not delete them yet. After scanning throughout the image, delete the marked pixels. In the final step, P2 filter is used as when using the P1 filter. After deleting the marked pixels, repeat these steps until no more image data can be deleted.

2.4 Perceptron

Perceptron^(7,8) is one of the most popular algorithms used in classification. This algorithm is based on basic linear function model to classify the data with centroid as representative population. The linear function model mechanism is to create a line connecting the centroid of two groups and then create a perpendicular line to break the groups apart. Perceptron employs this method of linear function model as an initiative separation line. After that, the algorithm will check for the misclassified data point. If a fault exists, the counterbalance to weight of that data point to achieve the accurate classification, or to achieve classification with least erroneous data.

Another advantage of the Perceptron is that we can tune the learning rate to determine for the algorithm's accuracy. If learning rate is too small value, the weighting in erroneous data will be also small and we will see gradual changes of the separation line. On the other hand, if the learning rate is too high in value, it will result in too aggressive changes that will affect other data and that data must be classified many times. This can be explained by figure 4, where η is the learning rate values.




Fig. 4. The difference between 3 cases of learning rate in Perceptron algorithm⁽⁸⁾

2.5 Support Vector Machine

Support Vector Machine^(7,10) or SVM is an algorithm based on a linear function model, which is developed from the Perceptron algorithm. It is a way to increase flexibility of classification to acquire large margin as much as possible. The concept of this algorithm is to place the data onto feature space and draw lines connecting the edges of each group. And then, the algorithm uses these data points on the edge to represent groups. The nearest data points of each group are called "support vector". Then data separation lines of both groups are created to classify the data with the largest margins as possible, that shown in figure 5. In some cases, this algorithm can allow for misclassification to achieve the larger margin by using slack variable.




Fig. 5. The support vectors and classification in SVM algorithm

Another advantage of the Support Vector Machine is that the processing time is less than Perceptron algorithm because Support Vector Machine does not require all the data points to be calculated. In addition, the Support Vector Machine provides various kind of functions, called kernel, to fit a specific type of data distribution. These kernel functions include linear, polynomial, radial basis, and sigmoid.

2.6 Naïve Bayes

Naive Bayes^(7,8,11) is an algorithm that uses the Bayes theorem to assist in classification. It is based on the assumption that the attributes of the sample are independent. The algorithm is suitable for the set of large sample. The modeling is in the form of conditional probability. The advantage of this method of learning is that we can use the data and "Prior knowledge" to help in learning. This algorithm gives good performance when compare with the other algorithms. In terms of the calculation, the principles of probability will be used and will be based on the theory of Bayes.

2.7 k-Nearest Neighbors

k-Nearest Neighbors^(7,11) or k-NN is a popular classification algorithm in the field of pattern recognition. The concept of this algorithm is classifying the new data base on the k closest training examples. And the class of new data will be assigned by the majority class label of the k closest training data.




Fig. 6. The example of k-NN algorithm when $k=1$, 2 and 3

Figure 6 shows the classification of k-Nearest Neighbors with the different k values. Results will vary depending on the number of the closest k, for example when $k=1$ for the incoming data (represented by x) will be classified as (-). When $k=2$, the incoming data can be classified as either (-) or (+). When $k=3$, the incoming data will be classified as (+).

The objectives of this research are:

- 1) To study and compare the effectiveness of hand-written signature recognition models from 4 learning algorithms: Perceptron, SVM, Naïve Bayes, and k-NN.
- 2) To improve the accuracy of hand-written signature recognition model by using image improvement and by addition of high intensity data.

3. Research Framework

This research consists of 6 stages (and diagrammatically shown in figure 7) as follows:

1) Collecting 600 signatures from 30 university students who use the hand-written signature in daily life and turn to images file by scanning device. We adjust the image's color to black and white. Then, equalize their size. The raw data of all hand-written signature image files are stored at the main author's website:

<https://sites.google.com/site/nhinganusarapesut/signature/datasets>

2) Using of edge detection technique and thinning edges to sharpen signature images.

3) Converting the data into a numeric table in accordance with color intensity, and then converting the numeric table to the array data.

4) Input the array data to the 4 learning algorithms to recognize correct owner of each signature. Studying and

comparing the performances and drawing the initial conclusions.

5) Adding each image data with high intensity area appending to the original image and choosing edge detection technique that gives highest accuracy in the image improvement process (the experimental results show that the Sobel edge detection technique gives highest precision).

6) Comparing the learning accuracy of models that are created from a training data set annotated with high intensity area. Then observe results and draw the conclusions.

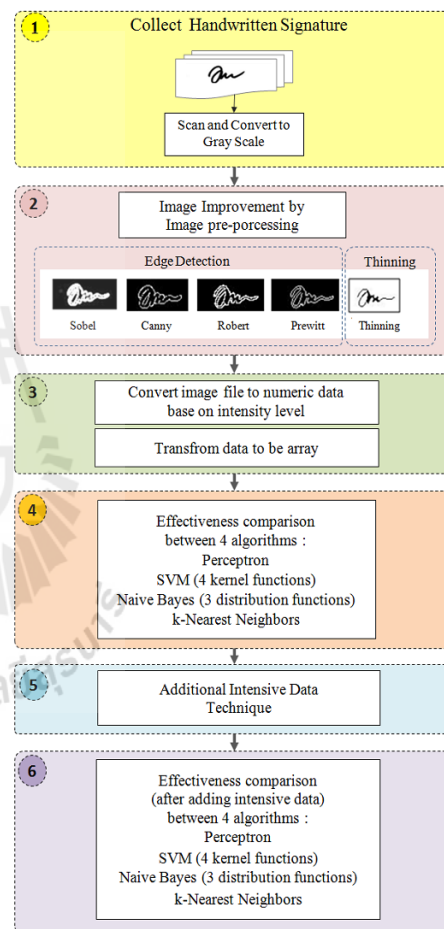


Fig. 7. Research framework

4. Experimental Results

With all 600 signatures from 30 individuals, we use Python 2.7 Language on Editor Spyder to predict the results of signature recognition.

The image improvement at the second step of our proposed framework yields the results as shown in figure 8.

From table 1, the four algorithms used in this study include Perceptron algorithm, Support Vector Machine algorithm (Linear Function, Polynomial Function, Radial

Basis Function, and Sigmoid Function), Naive Bayes algorithm (Gaussian Function, Multinomial Function, and Bernoulli Function), and k-Nearest Neighbors algorithm. These algorithms are used in comparative test. The results obtained indicate that, in using the original image files, the SVM-Polynomial Function provides the highest accuracy of 95.33% and we see 94.67% by SVM-Linear Function. The Naive Bayes algorithm with Multinomial Function gives 82.67% of accuracy, and the k-Nearest Neighbors algorithm gives 78.67% of accuracy.



Fig. 8. Example images after applying edge detection and thinning techniques to signature images of three persons

Table 1. Experimental results of signature recognition with image improvement techniques

Algorithm	Function	Original	Sobel	Prewitt	Robert	Canny	Thinning
Perceptron	linear	68.67%	86.67%	65.33%	72.00%	64.00%	45.33%
SVM	linear	94.67%	96.00%	82.00%	89.33%	83.33%	86.00%
	poly	95.33%	94.00%	2.00%	14.67%	2.00%	88.67%
	rbf	0.67%	0.67%	0.67%	0.67%	0.67%	0.67%
	sigmoid	0.67%	0.67%	0.67%	0.67%	0.67%	0.67%
Naive Bayes	gaussian	56.67%	20.67%	65.33%	72.00%	65.33%	71.33%
	multinomial	82.67%	89.33%	87.33%	86.67%	85.33%	75.33%
	bernoulli	0.67%	17.33%	68.67%	72.00%	67.33%	0.67%
kNN	k = 3	78.67%	91.33%	8.00%	28.00%	6.00%	9.33%

Table 2. Experimental results when using additional intensive data technique

Algorithm	Function	Original		Sobel Edge		Sobel Edge + Additional Intensive Data Method	
		Accuracy		Accuracy		Accuracy	
		Train	Test	Train	Test	Train	Test
Perceptron	linear	100%	68.67%	100%	86.67%	100%	88.67%
SVM	linear	100%	94.67%	100%	96.00%	100%	98.00%
	poly	100%	95.33%	100%	94.00%	100%	96.67%
	rbf	100%	0.67%	100%	0.67%	100%	0.67%
	sigmoid	4.22%	0.67%	4.22%	0.67%	4.22%	0.67%
Naive Bayes	gaussian	100.0%	56.67%	99.56%	20.67%	99.56%	21.33%
	multinomial	97.33%	82.67%	94.00%	89.33%	99.73%	92.67%
	bernoulli	4.22%	0.67%	49.78%	17.33%	48.44%	18.00%
kNN	k = 3	92.67%	78.67%	98.22%	91.33%	99.11%	96.00%

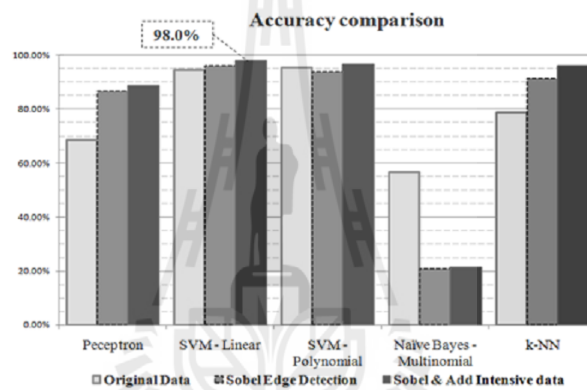


Fig. 9. Accuracy comparisons of original signature image data recognition, recognition from Sobel edge detected data, and recognition from both Sobel and additional intensive data techniques

The accuracy improvement of learning algorithms after using image processing with edge detection technique and thinning reveal that k-Nearest Neighbors algorithm's accuracy is increased by 12.66%; that is, from 78.67% to 91.33% with the use of Sobel edge detection technique. This increment is very significant. The accuracy of SVM-Linear Function is increased by applying the Sobel edge detection technique as well and the improved accuracy is 96.00%. Sobel edge detection is the best image processing technique applied prior to the signature recognition with learning algorithms.

Table 2 shows the results of using the additional intensive data technique with Sobel edge detection: SVM-Linear Function provides the accuracy of 98.00%,

which is the highest accuracy in this research. Moreover, we also found that the k-Nearest Neighbors algorithm provides higher accuracy by using the additional intensive data; that is the accuracy increases from 91.33% to 96.00% (which is higher than the maximum value of the original data).

The accuracy comparisons of signature image recognition without any other techniques, recognition with edge detection technique, and recognition with both edge detection and our additional intensive data techniques are shown in figure 9. It can be noticed that the combination of Sobel edge detection technique and our novel proposed additional intensive data technique yields the highest recognition rate at 98%.

5. Conclusions

We study the problem of handwritten signature recognition with the main objective of devising techniques to improve recognition accuracy rate. According to the signatures collected from hand-written users for this research, the SVM-Linear Function is the most suitable learning algorithm for modeling the signature recognition with the edge detection technique applied for image improvement and the additional intensive data technique newly proposed for accuracy improvement. This combination of edge detection and additional intensive data techniques provides the accuracy rate of up to 98.00%. For the technique of image improvement, the researchers note that we have possibility to achieve higher accuracy if we study more advanced techniques of image processing.

Acknowledgment

This research has been supported by grant from the National Research Council of Thailand (NRCT) and Suranaree University of Technology through the funding of research unit.

References

- (1) Vargas J.F., Ferrer M.A, Travieso C.M. and Alonso J.B.: "Off-line signature verification based on grey level information using texture features", *Pattern Recognition*, Vol.44, pp.375–385, 2011
- (2) Guerbai Y., Chibani Y., and Hadjadji B.: "The effective use of the one-class SVM classifier for handwritten signature verification based on writer-independent parameters", *Pattern Recognition*, Vol. 48, pp. 103-113, 2014
- (3) Frias-Martinez E., Sanchez A., and Velez J.: "Support vector machines versus multi-layer perceptrons for efficient off-line signature recognition", *Engineering Applications of Artificial Intelligence*, Vol. 19, No. 6, pp.693-704, 2006
- (4) Zheng S., Liu J., and Tian J. W.: "A new efficient SVM-based edge detection method", *Pattern Recognition Letters*, Vol. 25, pp. 1143-1154, 2004
- (5) Dougherty G.: "Pattern Recognition and Classification: An Introduction", Springer, 2012
- (6) Gonzalez R. C., and Woods R. E. : "Digital Image Processing", Prentice Hall, 2001
- (7) Theodoridis S., Pikrakis A., Koutroumbas K., and Cavouras D.: "An Introduction to Pattern Recognition: A MATLAB Approach", Academic Press, 2010
- (8) Flach P.: "Machine Learning: The Art and Science of Algorithms That Make Sense of Data", Cambridge University Press, 2012
- (9) Cristianini N., and Shawe-Taylor J.: "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", Cambridge University Press, 2000
- (10) Garreta R., and Moncecchi G.: "Learning scikit-learn: Machine Learning in Python", Packt Publishing, 2013
- (11) Aci M., Inan C., and Avci M.: "A hybrid classification method of k nearest neighbor, Bayesian methods and genetic algorithm", *Expert Systems with Applications* Vol. 37, pp. 5061–5067, 2010

ประวัติผู้เขียน

นางสาวรติพร จันทร์กลิ่น เกิดเมื่อวันที่ 30 มีนาคม พ.ศ. 2533 ที่ อำเภอเมือง จังหวัด เพชรบูรณ์ เริ่มเข้าศึกษาระดับชั้นอนุบาล 1 ถึงชั้นมัธยมศึกษาปีที่ 3 ที่โรงเรียนเซนต์โยเซฟศรี- เพชรบูรณ์ อำเภอเมือง จังหวัดเพชรบูรณ์ จากนั้นได้เข้าศึกษาต่อในระดับมัธยมศึกษาตอนปลาย ที่ โรงเรียนเพชรพิทยาคม อำเภอเมือง จังหวัดเพชรบูรณ์ ปีการศึกษา 2553 ได้เข้าศึกษาต่อระดับปริญญาตรีในสาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยี สุรนารี และสำเร็จการศึกษาเมื่อปี พ.ศ. 2556 ภายหลังสำเร็จการศึกษาในระดับปริญญาตรี ได้เข้า ศึกษาในระดับปริญญาโท สาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัย เทคโนโลยีสุรนารี ในปี 2556

ในระหว่างการศึกษาได้รับความอนุเคราะห์อย่างยิ่งจากอาจารย์ประจำวิชา Formal Methods and Computability, Knowledge Discovery and Data Mining ได้รับความไว้วางใจให้เป็น ผู้ช่วยสอน และได้รับความไว้วางใจให้เป็นผู้ช่วยสอนปฏิบัติการจากอาจารย์ประจำวิชา Object- Oriented Technology และ Software Engineering และได้รับการตีพิมพ์เผยแพร่บทความวิชาการซึ่ง รายละเอียดสามารถดูได้ที่ภาคผนวก ค