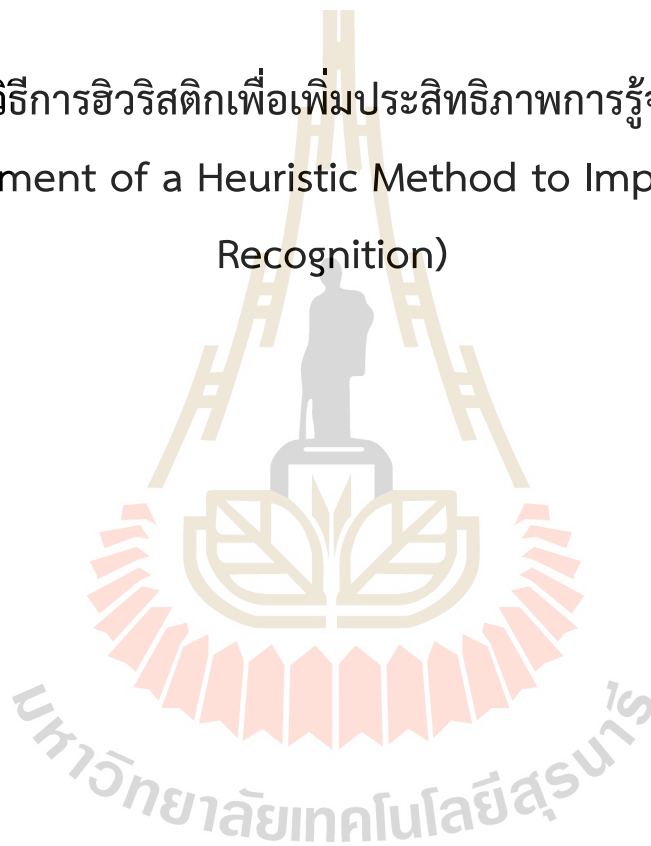




รายงานการวิจัย

การพัฒนาวิธีการฮิวริสติกเพื่อเพิ่มประสิทธิภาพการรู้จำลายมือชื่อ
(The Development of a Heuristic Method to Improve Signature
Recognition)



ได้รับทุนอุดหนุนการวิจัยจาก
มหาวิทยาลัยเทคโนโลยีสุรนารี

ผลงานวิจัยเป็นความรับผิดชอบของหัวหน้าโครงการวิจัยแต่เพียงผู้เดียว



รายงานการวิจัย

การพัฒนาวิธีการฮิวริสติกเพื่อเพิ่มประสิทธิภาพการรู้จำลายมือชื่อ (The Development of a Heuristic Method to Improve Signature Recognition)

ผู้วิจัย

หัวหน้าโครงการ

รองศาสตราจารย์ ดร.กิตติศักดิ์ เกิดประสพ

ผู้วิจัยร่วม

รองศาสตราจารย์ ดร.นิตยา เกิดประสพ

สาขาวิชาวิศวกรรมคอมพิวเตอร์

สำนักวิชาวิศวกรรมศาสตร์

ได้รับทุนอุดหนุนการวิจัยจากมหาวิทยาลัยเทคโนโลยีสุรนารี ปีงบประมาณ พ.ศ. 2560 และ 2561

ผลงานวิจัยเป็นความรับผิดชอบของหัวหน้าโครงการวิจัยแต่เพียงผู้เดียว

กุมภาพันธ์ 2563

กิตติกรรมประกาศ

คณะผู้วิจัยขอขอบคุณมหาวิทยาลัยเทคโนโลยีสุรนารี และสำนักงานคณะกรรมการวิจัยแห่งชาติ ที่สนับสนุนโครงการวิจัยนี้ด้วยการจัดสรรงบประมาณให้ในปีงบประมาณ พ.ศ.2560 และ ปีงบประมาณ พ.ศ. 2561 รวมถึงขอขอบคุณผู้ทรงคุณวุฒิทั้งภายนอกและภายในมหาวิทยาลัย ที่ได้เสียสละเวลาทำหน้าที่ตรวจข้อเสนอโครงการวิจัยและตรวจร่างรายงานการวิจัยฉบับสมบูรณ์ ข้อเสนอแนะจากผู้ทรงคุณวุฒิทุกท่านเป็นประโยชน์อย่างมากต่อคณะผู้วิจัยในการปรับปรุงการออกแบบ และขั้นตอนการดำเนินงานของโครงการวิจัย งานวิจัยนี้สำเร็จได้อย่างดีด้วยการมีส่วนร่วมจากนักศึกษาทั้งในระดับปริญญาโทบัณฑิตและปริญญาตรีบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ ที่ได้ทำหน้าที่เป็นผู้ช่วยวิจัยในโครงการวิจัยนี้



บทคัดย่อภาษาไทย

การรู้จำลายมือชื่อเป็นการประยุกต์ใช้เทคนิคการรู้จำแบบและการเรียนรู้เชิงสถิติของเครื่องเพื่อช่วยในงานไบโอเมตริกซ์ ซึ่งหมายถึงวิธีการอัตโนมัติที่ใช้ในการจดจำและระบุตัวบุคคลด้วยลักษณะทางกายภาพหรือพฤติกรรมที่เป็นลักษณะเฉพาะของแต่ละบุคคล ลักษณะเฉพาะทางกายภาพอาจจะเปลี่ยนนิ้วมือ โครงสร้างใบหน้า รูปแบบม่านตา หรืออื่น ๆ ลักษณะเฉพาะทางพฤติกรรมได้แก่ลายมือชื่อ จังหวะการพิมพ์ รูปแบบการเดิน หรือพฤติกรรมในลักษณะอื่น ๆ การจำแนกบุคคลด้วยข้อมูลไบโอเมตริกซ์เชิงพฤติกรรมมีข้อดีที่ไม่ต้องมีการสัมผัสทางกายภาพ แต่ปัญหาที่สำคัญคือมีความแม่นยำในการจำแนกต่ำ การนำเทคโนโลยีไบโอเมตริกซ์เชิงพฤติกรรมไปใช้งานจริงจึงยังจำกัด และจำเป็นต้องใช้ไบโอเมตริกซ์หลายประเภทประกอบกัน เช่น ใช้การสแกนลายนิ้วมือและลายม่านตาร่วมกับลายมือชื่อ ไบโอเมตริกซ์ที่ใช้งานส่วนใหญ่จึงมักจะเป็นลักษณะเฉพาะทางสรีรวิทยา ผู้วิจัยจึงมีแนวคิดในการศึกษาและพัฒนาไบโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางพฤติกรรมให้มีประสิทธิภาพการจดจำและระบุตัวบุคคลได้แม่นยำมากขึ้น ไบโอเมตริกซ์ที่ศึกษาในงานวิจัยนี้เน้นที่ลายมือชื่อ เนื่องจากเป็นไบโอเมตริกซ์เชิงพฤติกรรมที่ใช้งานกันมากแต่มักจะอยู่ในรูปแบบเอกสาร การพัฒนาการรู้จำลายมือชื่อในลักษณะอิเล็กทรอนิกส์จะช่วยพัฒนาการทำธุรกรรมรวมถึงนิติกรรมต่าง ๆ ที่กระทำผ่านระบบดิจิทัลให้มีความถูกต้องและเชื่อถือได้มากขึ้น การพัฒนางานวิจัยนี้ใช้วิธีการเพิ่มความแม่นยำในการรู้จำลายมือชื่อด้วยเทคนิคการเรียนรู้เชิงสถิติและการเรียนรู้เชิงฮิวริสติก โดยเทคนิคฮิวริสติกในงานวิจัยนี้เป็นการเพิ่มน้ำหนักให้กับพิกเซลของภาพลายมือชื่อที่แสดงลักษณะเด่นของลายมือชื่อนั้น ๆ ผลการทดลองพบว่าฮิวริสติกที่ใช้สามารถเพิ่มประสิทธิภาพการรู้จำให้มีความแม่นยำมากขึ้น

บทคัดย่อภาษาอังกฤษ

Signature recognition is the application of pattern recognition and statistical machine learning techniques to assist biometrics, which is the automated method to recognize an individual from his/her physical or behavioral characteristics. Physical characteristics can be either a fingerprint, face structure, iris pattern, or others. Behavioral characteristics include signature, typing stroke, walking pattern, and other specific behaviors. The advantage of behavioral biometrics is that there is no need for physical contact. However, the major disadvantage is that recognition accuracy of behavioral biometrics is still lower than the physical ones. Therefore, its real-life application is limited and needs a combination of many types of biometrics such as finger and iris scan to be accompanied with signature. The practical biometric systems are mostly based on physical characteristics. We are thus interested in improving the behavioral based biometrics, especially the handwritten signature, to be more accurate in its recognition rate. This interest is from the widely use of signature in paper form as a main method to recognize an individual. The increase in recognition accuracy of handwritten signature in electronic form is considered a great beneficial toward digital banking and other legislative actions. To improve handwritten signature recognition, we apply a heuristic that assign more weight in some pixel areas of the signature picture that can help differentiate on signature from the others. The experimental results reveal that this heuristics can actually improve the recognition rate.

สารบัญ

	หน้า
กิตติกรรมประกาศ	ก
บทคัดย่อภาษาไทย	ข
บทคัดย่อภาษาอังกฤษ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญภาพ	ช
บทที่ 1 บทนำ	
1.1 ความสำคัญและที่มาของปัญหาการวิจัย	1
1.2 วัตถุประสงค์ของโครงการวิจัย	2
1.3 ขอบเขตของการวิจัย	2
1.4 ประโยชน์ที่ได้รับ	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	
2.1 ระบบไบโอเมตริกซ์	4
2.2 งานวิจัยที่เกี่ยวข้อง	6
บทที่ 3 การออกแบบและพัฒนาไบโอเมตริกซ์เพื่อรู้จำลายมือชื่อ	
3.1 กรอบแนวคิดของงานวิจัย	9
3.2 ขั้นตอนการดำเนินงานวิจัย	10
3.2.1 ขั้นตอนการเก็บข้อมูลและการสร้างไฟล์ภาพ	11
3.2.2 ขั้นตอนการแปลงภาพเป็นข้อมูลทางตัวเลข	11
3.2.3 ขั้นตอนการทดสอบเปรียบเทียบอัลกอริทึม	13
3.2.4 ขั้นตอนการเพิ่มประสิทธิภาพการรู้จำด้วยเทคนิคการปรับปรุงภาพ	13
3.2.5 ขั้นตอนการเพิ่มประสิทธิภาพการรู้จำด้วยเทคนิคฮิวริสติก	14
บทที่ 4 การทดสอบประสิทธิภาพการรู้จำลายมือชื่อ	
4.1 ข้อมูลที่ใช้ในการทดสอบ	16
4.2 ผลการทดสอบความแม่นยำในการรู้จำลายมือชื่อ	16
4.2.1 ผลการทดสอบประสิทธิภาพของอัลกอริทึมการรู้จำด้วยภาพต้นฉบับ	17
4.2.2 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคการปรับปรุงภาพ	18
4.2.3 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคฮิวริสติก	20
4.2.4 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคการปรับปรุงภาพ และเทคนิคฮิวริสติก	21

สารบัญ(ต่อ)

	หน้า
4.3 การทดสอบประสิทธิภาพด้านเวลา	22
4.4 อภิปรายผล	23
บทที่ 5 บทสรุป	
5.1 สรุปผลการวิจัย	25
5.2 ข้อจำกัดและข้อเสนอแนะ	28
บรรณานุกรม	29
ภาคผนวก ผลผลิตของงานวิจัย	32
ภาคผนวก ก บทความวิจัยตีพิมพ์ในวารสารและเอกสารสืบเนื่องจากการประชุมวิชาการ	33
1. A. Hirunyanakul, S. Bunrit, N. Kerdprasop, K. Kerdprasop (2019). Deep learning technique for improving the recognition of handwritten signature. <i>International Journal of Information and Electronic Engineering</i> , vol. 9, no. 4, December, pp. 72-78. (indexing: INSPEC, ISSN: 2010-3719)	
2. A. Hirunyanakul, K. Chaiyakhan, R. Chanklan, K. Kerdprasop, N. Kerdprasop (2015). A new efficient method to improve handwritten signature recognition. <i>Proceedings of the 3rd International Conference on Industrial Application Engineering 2015 (ICIAE2015)</i> , Kitakyushu, Japan, 28-31 March, pp.561-568.	
3. N. Kerdprasop, R. Chanklan, A. Hirunyanakul, K. Kerdprasop (2014). An empirical study of dimensionality reduction methods for biometric recognition. <i>Proceedings of the 7th International Conference on Security Technology (SecTech 2014)</i> , Hainan, China, 20-23 December, pp.26-29.	
ภาคผนวก ข ลิขสิทธิ์โปรแกรม	53
โปรแกรมรู้จำภาพลายมือชื่อ (Handwritten signature image recognition program)	
ประวัติผู้วิจัย	56

สารบัญตาราง

	หน้า
ตารางที่ 4.1 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อของอัลกอริทึมการรู้จำ แบบต่าง ๆ	17
ตารางที่ 4.2 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคการ ปรับปรุงภาพ	19
ตารางที่ 4.3 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคฮิวริสติก	20
ตารางที่ 4.4 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคปรับปรุงภาพ ร่วมกับเทคนิคฮิวริสติก	21



สารบัญภาพ

	หน้า
รูปที่ 2.1 ส่วนประกอบหลักของระบบไปโอเมตริกซ์	6
รูปที่ 3.1 กรอบแนวคิดของการเพิ่มความแม่นยำในการรู้จำลักษณะเฉพาะทางพฤติกรรม ด้วยฮิวริสติก	10
รูปที่ 3.2 ตัวอย่างภาพลายมือชื่อที่ปรับให้เป็นสีขาว-ดำและทำให้มีขนาดเท่ากัน	11
รูปที่ 3.3 ตัวอย่างภาพลายมือชื่อที่อยู่ในรูปของตาราง และค่าความเข้มถูกแทนที่ด้วย ตัวเลข 0 – 255	12
รูปที่ 3.4 ตัวอย่างการแปลงไฟล์ภาพให้เป็นข้อมูลตัวเลขตามความเข้มสีด้วยไพธอน	12
รูปที่ 3.5 ตัวอย่างการเพิ่มข้อมูลความเข้มสูงในแต่ละลายมือชื่อ	14
รูปที่ 3.6 การเพิ่มข้อมูลที่มีความเข้มสูงในแต่ละลายมือชื่อตามลำดับจาก 20% ไปจนถึง 100%	15
รูปที่ 4.1 ตัวอย่างข้อมูลภาพลายมือชื่อ	16
รูปที่ 4.2 กราฟแสดงความสัมพันธ์ของจำนวน k กับค่าความแม่นยำของอัลกอริทึม เคเนียร์สเนเบอร์	18
รูปที่ 4.3 กราฟแสดงความสัมพันธ์ระหว่างความแม่นยำในการรู้จำและเวลาที่ใช้ในการสร้าง โมเดลเมื่อเปลี่ยนแปลงเปอร์เซ็นต์ของการเพิ่มข้อมูลในเทคนิคฮิวริสติก	22
รูปที่ 4.4 กราฟแสดงการเปรียบเทียบความแม่นยำการรู้จำภาพลายมือชื่อ	24
รูปที่ 5.1 แผนภาพสรุปขั้นตอนการดำเนินงานวิจัย	26
รูปที่ 5.2 แผนภาพสรุปผลการทดสอบประสิทธิภาพการรู้จำลายมือชื่อ	28

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของปัญหาการวิจัย

การรู้จำลายมือชื่อเป็นการประยุกต์ใช้เทคนิคการรู้จำแบบและการเรียนรู้เชิงสถิติของเครื่อง เพื่อช่วยในงานไบโอเมตริกซ์ คำว่าไบโอเมตริกซ์ (หรือชีวมิติ, ชีวมาตร) หมายถึง คือวิธีการอัตโนมัติที่ใช้ในการจดจำและระบุตัวบุคคลด้วยลักษณะทางกายภาพ ชีวภาพ ชีวเคมี หรือพฤติกรรมที่เป็นลักษณะเฉพาะของแต่ละบุคคล ลักษณะเฉพาะนี้อาจจะเป็นลายนิ้วมือ ภาพใบหน้า ลายเซ็น รูปแบบม่านตา รูปแบบดีเอ็นเอ หรือลักษณะเฉพาะในรูปแบบอื่น ๆ ลักษณะเฉพาะบุคคลที่สามารถนำมาใช้ในการยืนยันและระบุตัวบุคคล จะต้องมีคุณสมบัติพื้นฐาน 4 ประการต่อไปนี้ (Jain et al., 2004; Delac and Grgic, 2004)

- ความเป็นสากล (universality) บุคคลทุกคนจะต้องมีอวัยวะหรือมีลักษณะเฉพาะนั้น ๆ
- ความแตกต่าง (distinctiveness) ลักษณะเฉพาะนั้นจะต้องแตกต่างกันในแต่ละบุคคล
- ความคงทน (permanence) ลักษณะเฉพาะนั้นควรจะปรากฏอยู่อย่างถาวร หรืออย่างน้อยต้องไม่เปลี่ยนแปลงภายในช่วงระยะเวลาสั้น ๆ
- สามารถเก็บรวบรวมได้ (collectability) ข้อมูลที่เป็นลักษณะเฉพาะนั้นต้องสามารถเก็บตัวอย่าง บันทึก และแปลงเป็นข้อมูลในเชิงปริมาณได้

ลักษณะประจำตัวที่มีความจำเพาะและแตกต่างกันในแต่ละบุคคลจะเรียกว่า *ลักษณะเฉพาะ* (traits or characteristics) ลักษณะเฉพาะที่สามารถนำมาใช้ในงานไบโอเมตริกซ์สำหรับการยืนยันและระบุตัวบุคคลมีได้ไม่จำกัด (Unar et al., 2014) ในจำนวนที่มีได้มากมายนั้น นักวิจัยนิยมจำแนกประเภทไบโอเมตริกซ์ตามลักษณะเฉพาะได้เป็น 2 ประเภท คือ ไบโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางสรีรวิทยา (physiological biometrics) และไบโอเมตริกซ์ที่ใช้ลักษณะเฉพาะทางพฤติกรรม (behavioral biometrics)

ปัญหาที่สำคัญประการหนึ่งของระบบไบโอเมตริกซ์ คือความแม่นยำในการจำแนกบุคคลด้วยข้อมูลไบโอเมตริกซ์บางประเภท เช่นภาพใบหน้า ลายเซ็น จะมีความแม่นยำในการจำแนกต่ำ (de Luis-Garcia et al., 2003; Delac and Grgic, 2004) การนำเทคโนโลยีไบโอเมตริกซ์ไปใช้งานจริงจึงยังจำกัด และจำเป็นต้องใช้ไบโอเมตริกซ์หลายประเภทประกอบกับข้อมูลเอกสาร เช่น ใช้การสแกน

ลายนิ้วมือและลายม่านตา ร่วมกับลายมือชื่อในเอกสาร ไบโอมेटริกซ์ที่ใช้งานส่วนใหญ่จะเป็นลักษณะเฉพาะทางสรีรวิทยา

ผู้วิจัยจึงมีแนวคิดในการศึกษาและพัฒนาไบโอมेटริกซ์ที่ใช้ลักษณะเฉพาะทางพฤติกรรมให้มีประสิทธิภาพสูงขึ้น ไบโอมेटริกซ์ที่ศึกษาในงานวิจัยนี้เน้นเฉพาะลายมือชื่อ เนื่องจากเป็นไบโอมेटริกซ์เชิงพฤติกรรมที่ใช้กันมากแต่มักจะถูกจัดอยู่ในรูปแบบเอกสาร การพัฒนาการรู้จำลายมือชื่อในลักษณะอิเล็กทรอนิกส์จึงคาดว่าจะช่วยพัฒนาการทำธุรกรรมและนิติกรรมต่าง ๆ ผ่านระบบดิจิทัลให้มีความถูกต้องและเชื่อถือได้มากขึ้น

การพัฒนางานวิจัยนี้ใช้วิธีการเพิ่มความแม่นยำในการรู้จำลายมือชื่อ ด้วยเทคนิคการเรียนรู้เชิงสถิติ (statistical-based learning) และการเรียนรู้เชิงฮิวริสติก (heuristic-based learning) นอกจากการเพิ่มประสิทธิภาพการรู้จำให้มีความแม่นยำมากขึ้นแล้ว งานวิจัยนี้ยังคำนึงถึงประสิทธิภาพในด้านเวลาที่ใช้ในการประมวลผลโดยจะพยายามลดเวลาในกระบวนการรู้จำ การลดเวลาประมวลผลนี้จะเป็นแนวทางสำคัญในการประยุกต์ใช้เทคโนโลยีไบโอมेटริกซ์ด้านพฤติกรรมกับอุปกรณ์อัจฉริยะต่าง ๆ (smart devices) ได้อย่างแพร่หลายในอนาคต

1.2 วัตถุประสงค์ของโครงการวิจัย

- พัฒนาเทคนิคในการเพิ่มประสิทธิภาพการรู้จำของระบบไบโอมेटริกซ์เชิงพฤติกรรม ด้วยเทคนิคการเรียนรู้ของเครื่อง (machine learning) ในสองวิธีการหลักคือ วิธีการเรียนรู้เชิงสถิติ (statistical-based learning) และวิธีการเรียนรู้เชิงฮิวริสติก (heuristic-based learning)
- ศึกษาค้นคว้าเชิงทฤษฎี และออกแบบแนวทางลดเวลาในการประมวลผลของระบบไบโอมेटริกซ์ ด้วยการวิเคราะห์และคัดเลือกเฉพาะลักษณะประจำหรือฟีเจอร์ (feature selection) ที่จำเป็นต่ออัลกอริทึมรู้จำ รวมถึงการสกัดฟีเจอร์ (feature extraction) ที่ต้องมีการแปลงมิติของข้อมูล

1.3 ขอบเขตของการวิจัย

- การออกแบบอัลกอริทึมการรู้จำของระบบไบโอมेटริกซ์ จะใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (support vector machine) เป็นพื้นฐานในการพัฒนาเนื่องจากเป็นอัลกอริทึมที่มักจะให้ผลการจำแนกที่มีความแม่นยำสูงในข้อมูลภาพ และในการประเมินประสิทธิภาพจะใช้วิธีวัดความแม่นยำและเวลาในการประมวลผลเปรียบเทียบกับอัลกอริทึมต่าง ๆ ที่นิยมใช้ในงานวิจัยด้านไบโอมेटริกซ์ได้แก่

อัลกอริทึมโครงข่ายประสาท (neural network) อัลกอริทึมการเรียนรู้แบบเบย์ส์ (Bayes learning) และอัลกอริทึมเพื่อนบ้านใกล้ที่สุด (nearest neighbors)

- ข้อมูลไบโอเมตริกซ์จะใช้ข้อมูลลักษณะเฉพาะทางพฤติกรรมที่เป็นภาพที่ได้จากการสแกนลายมือชื่อบนกระดาษ โดยจะยังไม่พิจารณาการใช้อุปกรณ์พิเศษช่วยในการบันทึกลายมือชื่อและเชื่อมต่อโดยตรงกับระบบคอมพิวเตอร์ การใช้อุปกรณ์ช่วยจะพิจารณาเป็นเฟสต่อไปของงานวิจัย

1.4 ประโยชน์ที่ได้รับ

งานวิจัยนี้ได้รับประโยชน์จากการดำเนินงานโครงการ ในหลายด้านได้แก่

- (1) งานวิจัยนี้เป็นการศึกษา ค้นคว้า ออกแบบ และพัฒนาขั้นตอนวิธีการ ทั้งในเชิงทฤษฎีและเชิงประจักษ์เพื่อให้ได้องค์ความรู้ใหม่ในด้านการเพิ่มประสิทธิภาพการรู้จำข้อมูลไบโอเมตริกซ์ โดยจะเน้นที่ไบโอเมตริกซ์เชิงพฤติกรรมด้วยการรู้จำลายมือชื่อ ประโยชน์ที่ได้รับโดยตรงคือเทคนิคและอัลกอริทึมใหม่ที่สามารถเผยแพร่ผลงานที่เป็นความก้าวหน้าใหม่ต่อที่ประชุมวิชาการระดับนานาชาติได้จำนวน 2 บทความ และตีพิมพ์ผลงานในวารสารวิชาการระดับนานาชาติได้ 1 บทความ
- (2) การดำเนินงานวิจัยในส่วนที่เป็นการวิจัยเชิงประจักษ์ ที่จะต้องมีการเก็บรวบรวมข้อมูลและทำการทดลองกับข้อมูลเหล่านั้น จะต้องใช้ผู้ช่วยวิจัยที่เป็นนักศึกษาระดับปริญญาโทและเอก ในสาขาวิชาวิศวกรรมคอมพิวเตอร์ โครงการวิจัยนี้จึงมีประโยชน์ในการพัฒนานักวิจัยรุ่นใหม่ให้สามารถทำงานวิจัยในระดับสูงได้
- (3) การพัฒนาอัลกอริทึมให้สามารถใช้งานได้ในลักษณะของโปรแกรมต้นแบบหรือ prototype ทำให้ได้โปรแกรมต้นแบบที่สามารถจดลิสลิตีได้จำนวน 1 โปรแกรม ได้แก่ โปรแกรมรู้จำภาพลายมือชื่อ (handwritten signature image recognition program) ลิขสิทธิ์เลขที่ ว1. 5362 ออกให้ ณ วันที่ 8 เมษายน 2558

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 ระบบไบโอเมตริกซ์

การรู้จำข้อมูลไบโอเมตริกซ์สามารถจำแนกตามวัตถุประสงค์การใช้งานได้เป็น 2 ประเภทคือ การรู้จำเพื่อยืนยันตัวตนบุคคล (verification or authentication) และการรู้จำเพื่อระบุตัวบุคคล (identification) การรู้จำทั้งสองประเภทนิยามโจทย์ปัญหาและลักษณะการทำงานของระบบไบโอเมตริกซ์ได้ดังต่อไปนี้ (Jain et al., 2004)

การรู้จำเพื่อยืนยันตัวตนบุคคล (verification/authentication)

กำหนดให้ X_Q เป็นเวกเตอร์ลักษณะประจำของข้อมูลไบโอเมตริกซ์ (biometric feature vector) และ I เป็นรหัสประจำตัวที่บุคคลนั้นใช้ยืนยันตนเอง (claimed identity) เมื่อกำหนดให้ (X_Q, I) เป็นข้อมูลรับเข้าของระบบไบโอเมตริกซ์ ระบบจะประมวลผลเพื่อตัดสินใจว่าเจ้าของข้อมูล (X_Q, I) เป็นคลาส C_1 หรือคลาส C_2 โดยคลาส C_1 หมายถึง บุคคลนั้นเป็นเจ้าของที่แท้จริงของทั้งลักษณะเฉพาะและรหัสประจำตัว ส่วนคลาส C_2 หมายถึง บุคคลนั้นเป็นผู้ปลอมแปลงเนื่องจากลักษณะเฉพาะบุคคลไม่ตรงกับรหัสประจำตัวที่ใช้อ้างอิง โดยเกณฑ์การตัดสินใจประเมินจากฟังก์ชัน S

$$(X_Q, I) \in C_1 \quad \text{ถ้า } S(X_Q, X_I) \geq t$$

$$(X_Q, I) \in C_2 \quad \text{ถ้า } S(X_Q, X_I) < t$$

โดยที่ S คือ ฟังก์ชันวัดความคล้ายคลึงระหว่างเวกเตอร์ของลักษณะเฉพาะบุคคล X_Q ที่เป็น

ข้อมูลรับเข้า และลักษณะเฉพาะบุคคล X_I ที่บันทึกไว้ในฐานข้อมูล

X_I คือ ข้อมูลไบโอเมตริกซ์ของบุคคลที่มีรหัสประจำตัว I และข้อมูลนั้นถูกบันทึกไว้เป็น

แม่แบบในฐานข้อมูลก่อนหน้ากระบวนการรู้จำเพื่อยืนยันตัวตนบุคคล

t คือ ค่าคงที่ที่กำหนดไว้ล่วงหน้า (threshold)

การรู้จำเพื่อยืนยันตัวตนบุคคลจึงเป็นการรายงานผลการตรวจสอบไบโอเมตริกซ์ของบุคคลว่าตรงกับรหัสประจำตัวที่บุคคลนั้นใช้อ้างอิงหรือไม่ ผลการตรวจสอบจะเป็น ใช่/ไม่ใช่ (accept/reject)

การรู้จำเพื่อระบุตัวบุคคล (identification)

กำหนดให้ X_Q เป็นเวกเตอร์ลักษณะประจำของข้อมูลไบโอเมตริกซ์ (biometric feature vector) และเป็นข้อมูลรับเข้าเพียงอย่างเดียวของระบบไบโอเมตริกซ์ ระบบจะทำหน้าที่ค้นหารหัสประจำตัวบุคคล I_K โดย K มีค่าตั้งแต่ 1 ถึง $N+1$ รหัสประจำตัว I_1 ถึง I_N เป็นรหัสประจำตัวบุคคลจำนวน N คนที่ลงทะเบียนไว้กับระบบ ส่วนรหัส I_{N+1} เป็นรหัสพิเศษหมายถึงบุคคลนั้นไม่มีข้อมูลบันทึกไว้ในฐานข้อมูล เมื่อกำหนดข้อมูลเข้าเป็น X_Q ระบบจะประมวลผลเพื่อค้นหารหัสประจำตัวบุคคลตามเกณฑ์ต่อไปนี้

$$X_Q \in I_K \text{ ถ้า } \max_k \{S(X_Q, X_{I_k})\} \geq t, K = 1, \dots, N$$

$$X_Q \in I_{N+1} \text{ ถ้า } \max_k \{S(X_Q, X_{I_k})\} < t$$

โดยที่ X_{I_k} คือ ข้อมูลไบโอเมตริกซ์ของบุคคลที่มีรหัสประจำตัว I_k และ $K = 1, \dots, N$

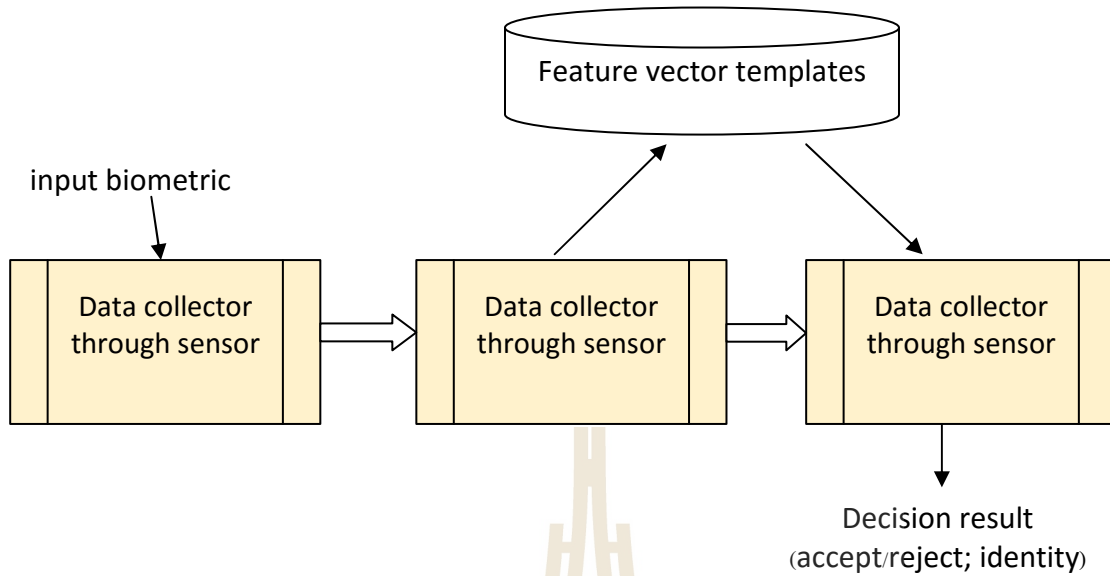
การรู้จำเพื่อระบุตัวบุคคล จึงเป็นการใช้ข้อมูลไบโอเมตริกซ์เพื่อค้นหาจากฐานข้อมูลว่าข้อมูลไบโอเมตริกซ์นั้นเป็นของบุคคลใด ในกระบวนการค้นหาจึงใช้เวลานานกว่าการรู้จำเพื่อยืนยันตัวบุคคล ระบบไบโอเมตริกซ์ไม่ว่าจะเพื่อยืนยันตัวบุคคล หรือเพื่อค้นหาและระบุตัวบุคคล จะมีส่วนประกอบหลักเหมือนกัน คือ

(๑) มีอุปกรณ์สำหรับอ่านข้อมูลลักษณะเฉพาะบุคคล (sensor device) พร้อมโมดูลในการแปลงข้อมูลให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้

(๒) โมดูลคัดเลือกลักษณะประจำ (attribute/feature) ที่จำเป็นต้องใช้ในการรู้จำพร้อมทั้งทำหน้าที่บันทึกข้อมูลลักษณะประจำของแต่ละบุคคลลงฐานข้อมูล ข้อมูลจะได้รับการคัดเลือกและแปลงรูปแบบ เรียกข้อมูลนี้ว่า แม่แบบในลักษณะพีเจอร์เวกเตอร์ (feature vector template)

(๓) โมดูลในการจับคู่แบบและตัดสินใจ (pattern matching and decision making) ทำหน้าที่คำนวณความคล้ายของรูปแบบลักษณะเฉพาะในแม่แบบ เทียบกับลักษณะเฉพาะบุคคลที่เป็นข้อมูลเข้า ณ ขณะนั้นของระบบ และตัดสินใจตามเกณฑ์ที่ตั้งไว้เพื่อแสดงผลการตัดสินใจเป็นการยืนยัน/ปฏิเสธบุคคล (accept/reject) หรือแสดงผลเป็นการระบุตัวบุคคล (identity) ตามแต่วัตถุประสงค์การใช้งานระบบ

ในช่วงลงทะเบียนข้อมูลไบโอเมตริกซ์จะใช้โมดูลที่ ๑ และ ๒ ในช่วงตรวจสอบข้อมูลเพื่อยืนยันบุคคลหรือเพื่อระบุบุคคลจะใช้ส่วนประกอบทั้งสามส่วน ส่วนประกอบเหล่านี้แสดงเป็นแผนภาพได้ดังรูปที่ 2.1



รูปที่ 2.1 ส่วนประกอบหลักของระบบไบโอเมตริกซ์

2.2 งานวิจัยที่เกี่ยวข้อง

ในปัจจุบันเทคโนโลยีไบโอเมตริกซ์ได้ถูกนำไปใช้จริงในหลายหน่วยงานของหลาย ๆ ประเทศ ด้วยวัตถุประสงค์หลักคือเพื่อยืนยันตัวตนบุคคล เช่น การตรวจคนเข้าเมือง การควบคุมการเข้าออกอาคาร การลงเวลาเข้าทำงาน การยืนยันตัวตนเพื่อการทำธุรกรรมหรือธุรกิจพาณิชย์ อิเล็กทรอนิกส์ และงานด้านอื่น ๆ อีกมาก ข้อดีของไบโอเมตริกซ์เมื่อเปรียบเทียบกับการรักษาความปลอดภัยแบบเดิม เช่น การใช้บัตรประจำตัว โทเค็น หรือ รหัสผ่าน ที่เห็นได้ชัดเจนคือข้อมูลไบโอเมตริกซ์ปลอมแปลงได้ยากกว่า และสะดวกสำหรับผู้ที่ไม่ต้องมีภาระในการพกพาอุปกรณ์หรือจดจำรหัส แต่ข้อด้อยของเทคโนโลยีนี้คือความแม่นยำของระบบอัตโนมัติในการรู้จำข้อมูลไบโอเมตริกซ์บางประเภทยังคงค่อนข้างต่ำ โดยเฉพาะไบโอเมตริกซ์ทางพฤติกรรม นอกจากนี้ลักษณะเฉพาะบางอย่างเก็บตัวอย่างได้ยาก และยังไม่เป็นที่ยอมรับของประชาชนโดยทั่วไป (Boukhonine et al., 2005; Yampolskiy and Govindaraju, 2008; Bailador et al., 2011; Radhika et al., 2011; Galbally et al., 2012)

แนวทางหลักของการปรับปรุงระบบไบโอเมตริกซ์ให้มีความน่าเชื่อถือ สามารถนำไปสู่การใช้งานจริงได้กว้างขวางขึ้นและได้รับการยอมรับจากผู้ใช้งานมากขึ้น คือ การพัฒนาและปรับปรุงความน่าเชื่อถือของระบบในด้านต่าง ๆ ได้แก่เพิ่มความแม่นยำในการรู้จำ เพิ่มความปลอดภัยในการใช้งาน และการเก็บรักษาข้อมูลของผู้ใช้ เพิ่มประสิทธิภาพของระบบในด้านความเร็วในการประมวลผล และพัฒนาฟังก์ชันของระบบให้ใช้งานได้ง่าย (Jain et al., 2004; Giot et al., 2013) แนวทางที่เป็น

วัตถุประสงค์หลักของโครงการวิจัยนี้คือด้านความแม่นยำในการรู้จำ และการลดเวลาในการประมวลผล

ในประเด็นการเพิ่มความแม่นยำของระบบไบโอเมตริกซ์ นักวิจัยจำนวนมากได้เสนอแนวทางพัฒนาระบบที่ใช้ลักษณะเฉพาะบุคคลมากกว่าหนึ่งลักษณะ เพื่อใช้ประกอบการรู้จำและตัดสินใจยืนยันตัวบุคคล เรียกระบบลักษณะนี้ว่า ระบบไบโอเมตริกซ์แบบหลายภาวะ (multi-modal biometric system) การพัฒนาระบบดังกล่าวจะต้องมีขั้นตอนการรวม (fusion) ข้อมูลหรือสารสนเทศ ซึ่งจะเกิดขึ้นได้ในหลายระดับ (Singh et al., 2007; Liao and Isa, 2011; Benaliouche and Touahria, 2014) ได้แก่ (๑) ในระดับข้อมูลจากอุปกรณ์รับรู้ เป็นการรวมข้อมูลจากหลายลักษณะเฉพาะ เช่น ใช้ลักษณะเฉพาะจากม่านตาร่วมกับลายนิ้วมือ (๒) ในระดับข้อมูลลักษณะประจำหรือพีเจอร์ เป็นการรวมพีเจอร์ที่คัดเลือกแล้วจากหลายลักษณะเฉพาะ (๓) ในระดับสารสนเทศระหว่างประมวลผล ใช้การรวมคะแนนของฟังก์ชันวัดความคล้ายคลึงที่คำนวณจากแต่ละลักษณะเฉพาะ (๔) ในระดับสารสนเทศหลังประมวลผล เป็นขั้นตัดสินใจโดยอาจจะใช้การโหวตผลตามผลลัพธ์ส่วนใหญ่ จากการพิจารณาลักษณะเฉพาะแต่ละลักษณะเพื่อตัดสินว่าผู้ใช้นั้นเป็นตัวจริงหรือบุคคลแอบอ้าง

งานวิจัยของ Gonzalez-Rodriguez และคณะ (2005) ได้นำเสนอเทคนิคจากพื้นฐานทฤษฎีของเบย์ส์สำหรับประมวลผลลายนิ้วมือ ใบหน้า และลายเซ็น เพื่อประกอบการตัดสินใจในศาล โดยการรวมสารสนเทศเกิดขึ้นในระดับการตัดสินใจ งานวิจัยของ Jing และคณะ (2007) ใช้ลักษณะเฉพาะที่เป็นใบหน้าและลายพิมพ์ฝ่ามือ โดยรวมข้อมูลในระดับพิกเซลของภาพ ทีมวิจัยของ Fahmy (2008) รวมถึงทีมวิจัยของ Liao และ Isa (2011) ศึกษาลักษณะเฉพาะที่เป็นม่านตาและลายนิ้วมือ จากนั้นรวมสารสนเทศที่เป็นคะแนนจากฟังก์ชันวัดความคล้ายคลึง โดยใช้ซอฟต์แวร์แมชชีนเป็นเครื่องมือ ทีมวิจัยของ Gawande (2013) ใช้ลักษณะเฉพาะที่เป็นม่านตาร่วมกับลายนิ้วมือและจำแนกด้วยซอฟต์แวร์แมชชีนเช่นเดียวกัน แต่การรวมข้อมูลเกิดขึ้นในระดับพีเจอร์ เช่นเดียวกับทีมของ Benaliouche และ Touahria (2014) ที่ใช้ข้อมูลม่านตาร่วมกับลายนิ้วมือ แต่รวมสารสนเทศที่เป็นคะแนนจากฟังก์ชันวัดความคล้ายคลึง และในขั้นตัดสินใจของระบบไบโอเมตริกซ์แบบหลายภาวะ ใช้การรวมคะแนนด้วยตรรกศาสตร์คลุมเครือ งานของ Yang และคณะ (2013) พิจารณาระบบไบโอเมตริกซ์แบบหลายภาวะด้วยวัตถุประสงค์ที่แตกต่างออกไป โดยทีมวิจัยของ Yang เสนอแนวคิดว่ารระบบไบโอเมตริกซ์ควรมีความปลอดภัยในระดับสูง จึงเสนอแนวทางการใช้ลายเซ็นเป็นลักษณะเฉพาะทางพฤติกรรม เพื่อคัดกรองและยืนยันบุคคลก่อนเข้าใช้ระบบไบโอเมตริกซ์

ในประเด็นการลดเวลาการประมวลผลของระบบไบโอเมตริกซ์ นักวิจัยส่วนใหญ่เห็นพ้องกับแนวทางการลดมิติของข้อมูล (Mazanec et al., 2008; Fatahi et al., 2013; Sodhi and Lal,

2013) โดยทั่วไปการลดมิติของข้อมูลจะใช้วิธีการคัดเลือกฟีเจอร์ (feature selection) และการสกัดฟีเจอร์ (feature extraction)

การคัดเลือกฟีเจอร์เป็นการวิเคราะห์ข้อมูลเป็นรายฟีเจอร์หรือรายแอททริบิวต์ ด้วยเทคนิคการวิเคราะห์ในรูปแบบต่าง ๆ เพื่อคัดเลือกไว้เฉพาะฟีเจอร์ที่มีความสำคัญต่อการจำแนกหรือการรู้จำข้อมูล ข้อมูลที่ผ่านการคัดเลือกมักจะไม่เปลี่ยนรูปแบบของฟีเจอร์ เพียงแต่มีจำนวนฟีเจอร์ที่ลดลง เทคนิคนี้นิยมใช้ในงานวิจัยสาขาการทำเหมืองข้อมูล (data mining) และสาขาการเรียนรู้ของเครื่อง (machine learning)

การสกัดฟีเจอร์เพื่อคัดแยกไว้เฉพาะแอททริบิวต์หรือฟีเจอร์ที่จำเป็นต่อการรู้จำ เป็นเทคนิคที่นิยมใช้ในงานวิจัยสาขาการรู้จำแบบ (pattern recognition) เทคนิคนี้แตกต่างจากการคัดเลือกฟีเจอร์ตรงที่มีการเปลี่ยนรูปแบบข้อมูล (data transformation) ก่อนการคัดเลือกฟีเจอร์ การเปลี่ยนรูปแบบข้อมูลอาจจะเป็นการแปลงมิติข้อมูลไปสู่มิติที่มีความซับซ้อนน้อยลงและจำแนกข้อมูลได้ชัดเจนมากขึ้น (Martinez and Kak, 2001) วิธีการแปลงมิติที่นิยมใช้ในงานรู้จำคือ การวิเคราะห์องค์ประกอบหลัก (principal component analysis, PCA) และ การวิเคราะห์ดิสคริมิแนนต์เชิงเส้น (linear discriminant analysis, LDA) เทคนิค PCA และ LDA เป็นเทคนิคเชิงสถิติที่มักใช้ในระบบไบโอเมตริกซ์ (Mazanec et al., 2008; Fatahi et al., 2013, Rodriguez-Lujan et al., 2013; Sodhi and Lal, 2013)

ในการดำเนินงานโครงการวิจัยนี้ ผู้วิจัยมีเป้าหมายที่จะศึกษาวิธีการเพิ่มประสิทธิภาพการรู้จำของระบบไบโอเมตริกซ์ในสองประเด็นคือ ประเด็นของการลดเวลาการประมวลผล และ ประเด็นของการเพิ่มความแม่นยำในการรู้จำข้อมูลไบโอเมตริกซ์ การลดเวลาการประมวลผลจะใช้แนวทางลดมิติข้อมูลด้วยวิธีการสกัดฟีเจอร์ และในประเด็นของการเพิ่มความแม่นยำของการรู้จำข้อมูลไบโอเมตริกซ์ โดยจะใช้อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเป็นพื้นฐานของการพัฒนา เนื่องจากซัพพอร์ตเวกเตอร์แมชชีนมักจะให้ประสิทธิภาพการจำแนกที่แม่นยำกว่าอัลกอริทึมแบบอื่น ถ้าหากปรับใช้ฟังก์ชันแก่นหรือเคอร์เนลได้อย่างเหมาะสมกับลักษณะข้อมูล

บทที่ 3

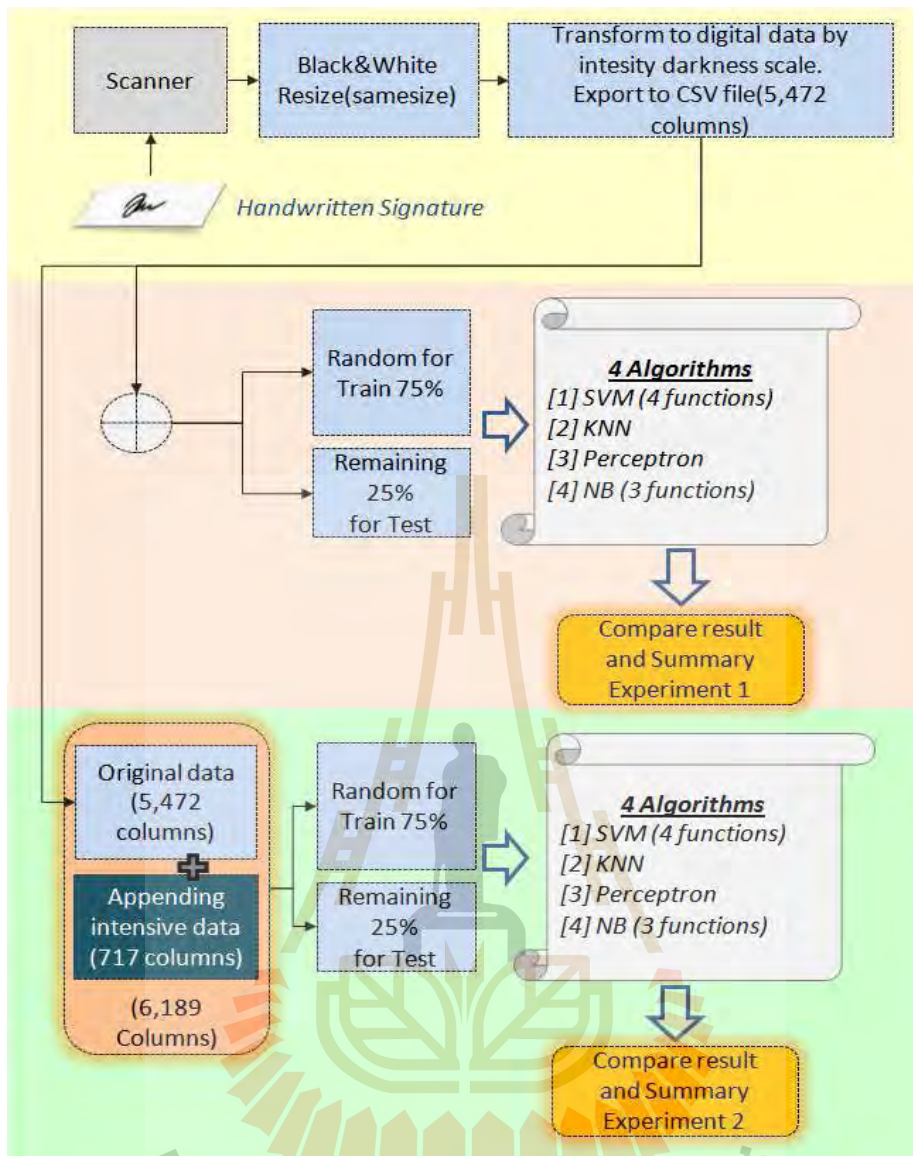
การออกแบบและพัฒนาไบโอเมตริกซ์เพื่อรู้จำลายมือชื่อ

3.1 กรอบแนวคิดของงานวิจัย

โครงการวิจัยนี้มีวัตถุประสงค์ที่จะพัฒนาเทคนิคเพิ่มประสิทธิภาพการรู้จำไบโอเมตริกซ์ได้ทั้งสองลักษณะคือการรู้จำเพื่อยืนยันตัวบุคคลและการรู้จำเพื่อระบุตัวบุคคล โดยในระยะแรกของโครงการจะเน้นที่การรู้จำเพื่อระบุตัวบุคคล เนื่องจากเป็นงานที่ใช้เวลามากกว่าการรู้จำเพื่อยืนยันตัวบุคคล จึงมีความจำเป็นที่จะต้องได้รับการพัฒนาแนวทางเพิ่มความเร็วในการประมวลผล

การเพิ่มความเร็วในการประมวลผลจะใช้แนวทางเชิงสถิติเพื่อลดมิติข้อมูล ด้วยการลดจำนวนลักษณะประจำ (attributes / features / variables) ที่จะต้องใช้ในการคำนวณของฟังก์ชันวัดความคล้ายคลึง ในเบื้องต้นผู้วิจัยจะพิจารณาใช้เทคนิค PCA (principal component analysis) และ LDA (linear discriminant analysis) เพื่อศึกษาเปรียบเทียบประสิทธิภาพในด้านการลดเวลาในการประมวลผลของอัลกอริทึมรู้จำ

การเพิ่มความแม่นยำในการยืนยันและระบุตัวบุคคล โดยเฉพาะในกรณีข้อมูลไบโอเมตริกซ์ที่เป็นลักษณะเฉพาะทางพฤติกรรมที่เป็นภาพลายมือชื่อและระบบไบโอเมตริกซ์มักจะมีความแม่นยำในการรู้จำต่ำ ผู้วิจัยจะใช้วิธีเชิงฮิวริสติกช่วยเพิ่มความแม่นยำ โดยกรอบแนวคิดของการวิจัยแสดงได้ดังรูปที่ 3.1



รูปที่ 3.1 กรอบแนวคิดของการเพิ่มความแม่นยำในการรู้จำลักษณะเฉพาะทางพฤติกรรมด้วยฮิวริสติก

3.2 ขั้นตอนการดำเนินงานวิจัย

จากกรอบแนวคิดหลัก สามารถจำแนกการดำเนินงานออกเป็นขั้นตอนต่าง ๆ ได้ดังนี้

- 1) การเก็บข้อมูลลายมือชื่อและการแปลงภาพลายมือชื่อให้เป็นไฟล์ภาพ
- 2) การแปลงข้อมูลภาพลายมือชื่อให้เป็นข้อมูลทางตัวเลข
- 3) การทดสอบเปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึม
- 4) การเพิ่มประสิทธิภาพการรู้จำโดยการใช้เทคนิคการปรับปรุงภาพ ด้วยการหา

ขอบภาพและการทำขอบภาพให้บางลง

5) การเพิ่มประสิทธิภาพการรู้จำโดยการใช้เทคนิคฮิวริสติก ด้วยการเพิ่มชุดข้อมูลที่มีความเข้มสูง

3.2.1 ขั้นตอนการเก็บข้อมูลและการสร้างไฟล์ภาพ

ขั้นตอนนี้จะเป็นการเก็บรวบรวมข้อมูลและการแปลงข้อมูล โดยได้ทำการเก็บรวบรวมข้อมูลจริงจากนักศึกษาชั้นปีที่สี่ จำนวน 30 คน โดยแต่ละคนเขียนลายมือชื่อคนละ 20 ครั้งโดยให้เขียนในคราวแรก 10 ครั้งจากนั้นเว้นระยะไป 14 วันแล้วจึงให้เขียนลายมือชื่ออีก 10 ครั้งเพื่อเป็นการยืนยันว่าใช้ลายมือชื่อในชีวิตประจำวันจริงและเป็นการรองรับความแปรปรวนของลายมือชื่อตามสภาพแวดล้อมด้านระยะเวลา ดังนั้นจำนวนลายมือชื่อที่ใช้ในงานวิจัยนี้จะมีทั้งหมด 600 ลายมือชื่อ

รายละเอียดเชิงเทคนิคของขั้นตอนนี้ประกอบด้วย การนำภาพลายมือชื่อที่ได้ทั้งหมดมาผ่านเครื่องสแกน FUJI XEROX รุ่น ApeosPort-IV5070 เพื่อทำเป็นไฟล์รูปภาพ จากนั้นปรับแต่งสีให้เป็นลักษณะขาวดำ และปรับขนาดรูปภาพลายมือชื่อให้มีขนาดเท่ากันทุกภาพ โดยแต่ละภาพกว้าง 144 พิกเซลและสูง 38 พิกเซลดังตัวอย่างในรูปที่ 3.2




รูปที่ 3.2 ตัวอย่างภาพลายมือชื่อที่ปรับให้เป็นสีขาว-ดำและทำให้มีขนาดเท่ากัน

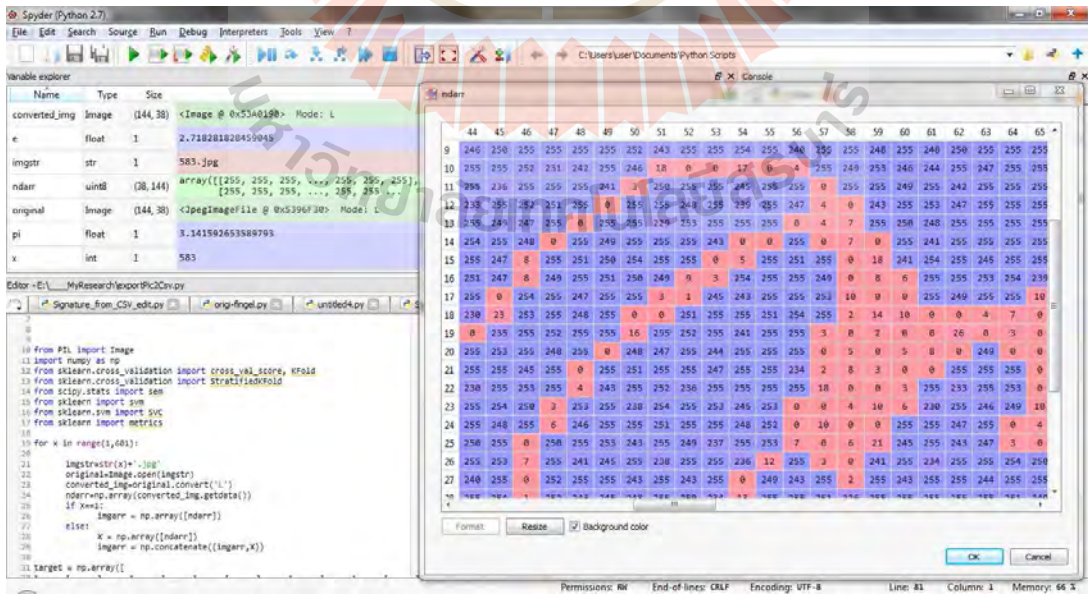
3.2.2 ขั้นตอนการแปลงภาพเป็นข้อมูลทางตัวเลข

ในขั้นตอนนี้ใช้โปรแกรมไพธอนประมวลผล เพื่อแปลงภาพลายมือชื่อให้เป็นรูปแบบตารางที่มีขนาด 144 คอลัมน์และ 38 แถว จากนั้นแทนที่ค่าความเข้มสีลงไปในทุกช่องของตารางนั้น ค่าความเข้มสีแสดงอยู่ในลักษณะตัวเลข มีค่าระหว่าง 0 ถึง 255 โดยที่ 0 คือ ค่าระดับความเข้มสูงที่สุด (สีดำ) และตัวเลข 255 คือความเข้มต่ำสุด (สีขาว) ดังตัวอย่างในรูปที่ 3.3

จากนั้นจัดเรียงข้อมูลตัวเลขของไฟล์ภาพแต่ละลายมือชื่อ ให้อยู่ในรูปของแถวลำดับ 1 มิติ โดยที่ลายมือชื่อหนึ่งรูปจะมีค่าข้อมูล 5,472 คอลัมน์ แสดงตัวอย่างได้ดังรูปที่ 3.4



รูปที่ 3.3 ตัวอย่างภาพลายมือชื่อที่อยู่ในรูปของตาราง และค่าความเข้มถูกแทนที่ด้วยตัวเลข 0 – 255



รูปที่ 3.4 ตัวอย่างการแปลงไฟล์ภาพให้เป็นข้อมูลตัวเลขตามความเข้มสีด้วยไพธอน

3.2.3 ขั้นตอนการทดสอบเปรียบเทียบอัลกอริทึม

การทำงานในขั้นตอนนี้ประกอบด้วย

- 1) นำข้อมูลในรูปแบบแถวลำดับ 1 มิติ แปลงให้เป็นไฟล์ csv
- 2) แบ่งข้อมูลเป็นสองส่วน โดย 75% ของข้อมูลทำหน้าที่เป็นข้อมูลเพื่อการฝึก (training data) และส่วนที่เหลือ 25% ทำหน้าที่เป็นข้อมูลเพื่อการทดสอบ (test data)
- 3) นำข้อมูลเพื่อการฝึกไปใช้กับอัลกอริทึม 4 อัลกอริทึม คือ perceptron, support vector machine (ใช้คอร์เนลฟังก์ชันที่แตกต่างกัน 4 ชนิด ได้แก่ ฟังก์ชันเชิงเส้นฟังก์ชันพหุนามฟังก์ชันเรเดียลเบสิส และฟังก์ชันซิกมอยด์), naive Bayes (ใช้ลักษณะการกระจายของข้อมูลที่แตกต่างกัน 3 ประเภท ได้แก่ เกาเซียน มัลติโนเมียล และเบอร์นูลลี) และ k-nearest neighbors ($k = 1, 2, \dots, 20$) เพื่อสร้างโมเดลการเรียนรู้จำ และทดสอบความแม่นยำของโมเดลด้วยข้อมูลทดสอบ
- 4) เปรียบเทียบประสิทธิภาพอัลกอริทึมเพื่อคัดเลือกโมเดลที่มีความแม่นยำมากที่สุดไปใช้ในขั้นตอนต่อไป

3.2.4 ขั้นตอนการเพิ่มประสิทธิภาพการเรียนรู้จำด้วยเทคนิคการปรับปรุงภาพ

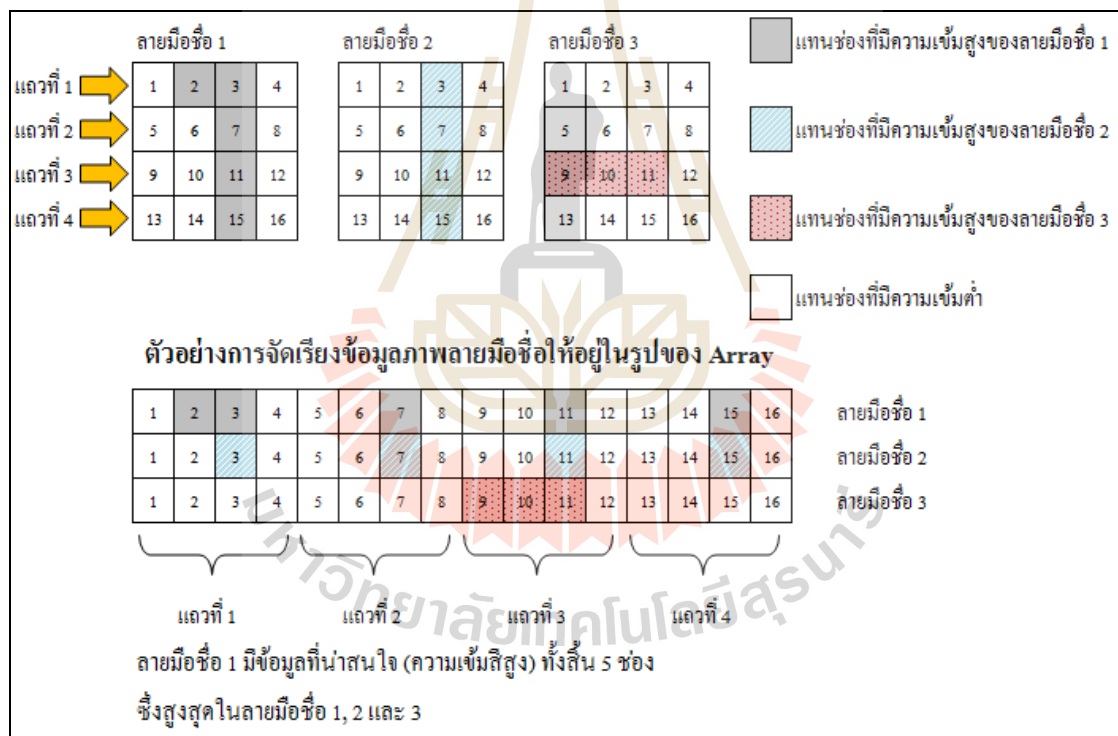
การดำเนินงานในขั้นตอนนี้เป็นการปรับปรุงไฟล์ภาพให้มีความคมชัดยิ่งขึ้นด้วยเทคนิคการปรับปรุงภาพ จากนั้นจึงคัดเลือกเทคนิคที่เหมาะสมที่สุดมาใช้ในขั้นตอนต่อไปของการพัฒนาโมเดลการเรียนรู้จำ รายละเอียดการทำงานในขั้นตอนนี้ประกอบด้วย

- 1) ปรับปรุงภาพด้วยเทคนิคการหาขอบภาพและทำขอบภาพให้บางลงด้วย 5 เทคนิค คือ Sobel edge detection, Canny edge detection, Robert edge detection, Prewitt edge detection, thinning
- 2) นำไฟล์ภาพที่ได้รับการปรับปรุงแล้วมาแปลงให้อยู่ในรูปของตารางตัวเลขตามความเข้มสี จากนั้นแปลงข้อมูลตัวเลขให้เป็นชุดข้อมูลแถวลำดับ
- 3) ทดสอบประสิทธิภาพเทคนิคการปรับปรุงภาพแต่ละแบบด้วยอัลกอริทึมการเรียนรู้ 4 อัลกอริทึม
- 4) คัดเลือกไฟล์รูปภาพที่ได้จากเทคนิคการปรับปรุงรูปภาพ โดยตัดสินใจเลือกจากการนำไปเปรียบเทียบกับค่าที่สูงที่สุดของชุดข้อมูลดั้งเดิม (ผลลัพธ์ที่ดีที่สุดจากขั้นตอนที่ 3.2.3 ขั้นตอนการทดสอบเปรียบเทียบอัลกอริทึม) โดยภาพที่ได้จากเทคนิคเหล่านั้นจะถูกนำไปใช้ในขั้นตอนถัดไป

3.2.5 ขั้นตอนการเพิ่มประสิทธิภาพการรู้จำด้วยเทคนิคฮิวริสติก

ขั้นตอนนี้เป็นการเพิ่มประสิทธิภาพโมเดลการรู้จำด้วยการพัฒนาฮิวริสติกที่เหมาะสม โดยจะมุ่งเน้นไปที่การนำข้อมูลมาใช้งานให้เกิดประโยชน์สูงสุด ข้อสมมุติฐานเบื้องต้นของการจำแนกภาพลายมือชื่อเพื่อระบุและยืนยันตัวตนของเจ้าของลายมือชื่อได้อย่างแม่นยำคือจะต้องสามารถจดจำลักษณะเด่นของแต่ละลายมือชื่อ ในงานวิจัยนี้มุ่งความสนใจไปที่บริเวณข้อมูลที่มีความเข้มสีสูง ซึ่งหมายถึงจุดเด่นที่สุดของแต่ละลายมือชื่อ ในขณะที่บริเวณข้อมูลที่มีความเข้มสีต่ำแสดงถึงที่ว่างระหว่างเส้นของตัวลายมือชื่อซึ่งไม่มีส่วนช่วยในการจำแนกและจดจำลายมือชื่อทำให้สามารถลดความสำคัญของข้อมูลในบริเวณนี้ได้

ตัวอย่างการเพิ่มข้อมูลที่มีความเข้มสีสูงซึ่งเป็นบริเวณที่คาดว่าจะสามารถช่วยเพิ่มความแม่นยำในการรู้จำลายมือชื่อของแต่ละบุคคล แสดงได้ดังรูปที่ 3.5

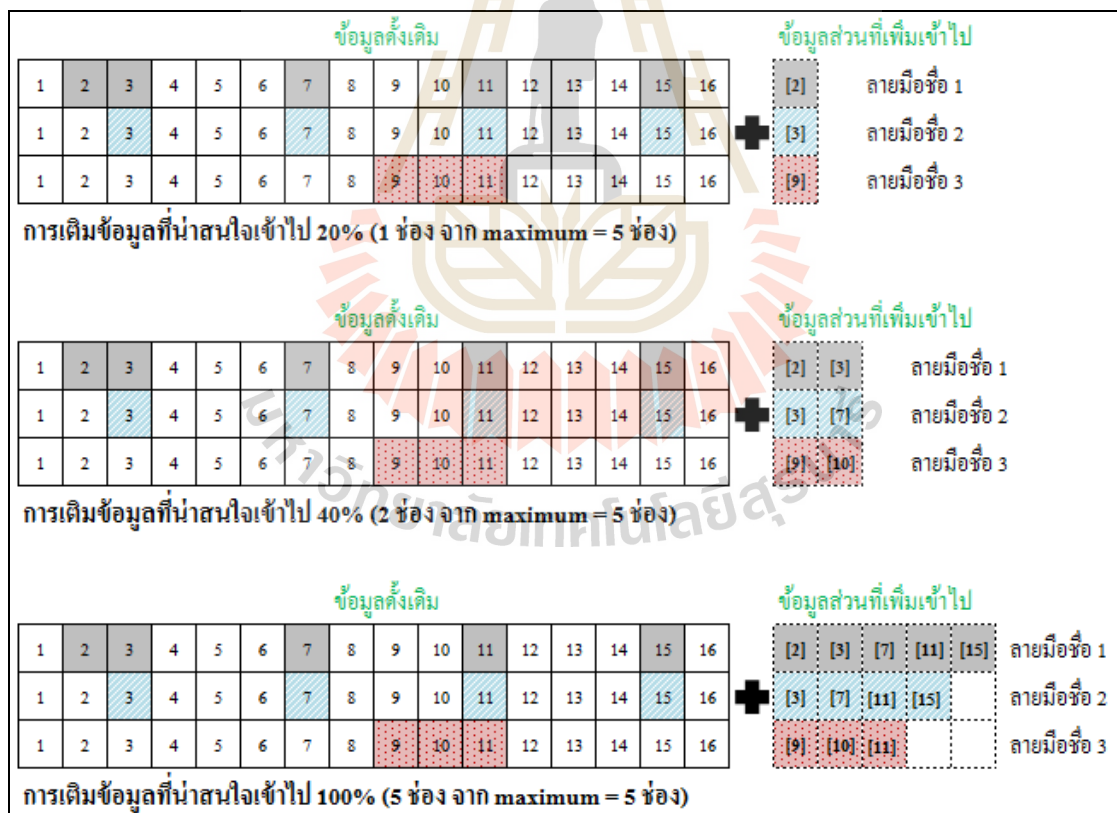


รูปที่ 3.5 ตัวอย่างการเพิ่มข้อมูลความเข้มสูงในแต่ละลายมือชื่อ

รูปที่ 3.5 แสดงการแปลงภาพลายมือชื่อในลักษณะของข้อมูลแถวลำดับ โดยตัวอย่างเป็นภาพลายมือชื่อขนาด 4x4 ทั้งสามภาพถูกนำมาจัดเรียงให้อยู่ในรูปของแถวลำดับขนาด 16 คอลัมน์ ซึ่งจากชุดข้อมูลตัวอย่างนี้ จะเห็นได้ว่าลายมือชื่อที่ 1 มีจำนวนข้อมูลที่มีความเข้มสีสูง

(จุดสำคัญของลายมือชื่อ) เป็นจำนวนช่องทั้งทั้งสิ้น 5 ช่อง (ลายมือชื่อที่ 2 มี 4 ช่อง และลายมือชื่อที่ 3 มี 3 ช่อง) โดยจำนวนช่อง เท่ากับ 5 ช่องในที่นี่จะถูกนำไปอ้างอิงในขั้นตอนย่อยต่อไป

แนวคิดในขั้นตอนนี้ยังได้ให้ความสนใจเกี่ยวกับเวลาที่ใช้ในการสร้างโมเดลการรู้จำ เนื่องจากการเพิ่มข้อมูลอาจจะทำให้ช่วงการสร้างโมเดลใช้เวลามากขึ้น จึงปรับการเพิ่มข้อมูลคราวละไม่มากเพื่อสังเกตการใช้เวลาในขั้นตอนการสร้างโมเดล โดยในขั้นตอนนี้จะทำการเพิ่มข้อมูลบริเวณที่มีความเข้มสูงทีละ 20% จากนั้นจะทำการบันทึกผลการทดลอง เพื่อนำไปเปรียบเทียบกับความแม่นยำของข้อมูลเดิมที่ภาพลายมือชื่อไม่ได้ถูกปรับปรุงด้วยเทคนิคฮิสโตแกรมนี้ ซึ่งหากได้ความแม่นยำที่มากขึ้น จะกระทำการเพิ่มข้อมูลบริเวณที่เป็นจุดเด่นของภาพต่อไปจนกว่าความแม่นยำจะคงที่ หรือ จนกว่าจะข้อมูลที่เพิ่มเข้าไปจะครบ 100% ดังตัวอย่างที่แสดงดังรูปที่ 3.6 จากตัวอย่างจะเห็นว่าข้อมูลภาพลายมือชื่อที่อยู่ในรูปของชุดข้อมูลแถวลำดับทั้ง 3 ลายมือชื่อ จะถูกเพิ่มชุดข้อมูลที่มีความเข้มสีสูงลงไป (ในภาพจะเรียกว่า ข้อมูลที่น่าสนใจ) โดยแสดงตัวอย่างทั้งในระดับเพิ่มเข้าไป 20% (เพิ่ม 1 ช่อง จาก maximum = 5 ช่อง) เพิ่ม 40% (เพิ่ม 2 ช่อง จาก maximum = 5 ช่อง) และเพิ่ม 100% (เพิ่ม 5 ช่อง จาก maximum = 5 ช่อง)



รูปที่ 3.6 การเพิ่มข้อมูลที่มีความเข้มสูงในแต่ละลายมือชื่อตามลำดับจาก 20% ไปจนถึง 100%

บทที่ 4

การทดสอบประสิทธิภาพการรู้จำลายมือชื่อ

วัตถุประสงค์หลักของโครงการวิจัยนี้คือพัฒนาแนวทางที่จะช่วยเพิ่มความแม่นยำในการรู้จำภาพลายมือชื่อ เทคนิคในการเพิ่มความแม่นยำใช้การปรับปรุงภาพและการใช้ฮิวริสติกด้วยการเพิ่มข้อมูลเฉพาะส่วนที่เป็นลักษณะเด่นของภาพ ในการสร้างโมเดลเพื่อการรู้จำใช้เทคนิคการเรียนรู้เชิงสถิติได้แก่ นาอ็ฟเบย์ส์และซัพพอร์ตเวกเตอร์แมชชีน รวมถึงทดสอบกับเทคนิคการเรียนรู้ของเครื่องในแบบอื่น ๆ ได้แก่เพอร์เซ็ปตรอนและเคเนียเรสเนเบอร์ ข้อมูลที่ใช้ในการทดสอบอธิบายในหัวข้อ 4.1 ผลการทดสอบนำเสนอในหัวข้อ 4.2 ผลการทดสอบประสิทธิภาพด้านเวลาแสดงในหัวข้อ 4.3 และการอภิปรายผลปรากฏในหัวข้อ 4.4

4.1 ข้อมูลที่ใช้ในการทดสอบ

ข้อมูลภาพลายมือชื่อของบุคคลจำนวน 30 คน รวมทั้งหมด 600 ภาพที่ใช้ในงานวิจัยนี้อยู่ในเว็บไซต์ <https://sites.google.com/site/nhinganusaracpesut/signature/datasets> ภาพลายมือชื่อทั้งหมดรวบรวมโดยทีมผู้ช่วยวิจัย โดยแต่ละภาพลายมือชื่อมีขนาด 38x144 พิกเซลเท่ากันทั้งหมด ดังแสดงตัวอย่างได้ดังรูปที่ 4.1



รูปที่ 4.1 ตัวอย่างข้อมูลภาพลายมือชื่อ

4.2 ผลการทดสอบความแม่นยำในการรู้จำลายมือชื่อ

กระบวนการทดสอบความแม่นยำในการรู้จำลายมือชื่อ จะแบ่งการทดสอบออกเป็น 4 ส่วน ประกอบด้วย 1) การทดสอบประสิทธิภาพของอัลกอริทึมการรู้จำโดยใช้ภาพต้นฉบับที่ไม่มีการปรับปรุงภาพ 2) การทดสอบความแม่นยำในการรู้จำลายมือชื่อกับภาพที่ผ่านเทคนิคการปรับปรุงภาพแบบต่าง ๆ 3) การทดสอบความแม่นยำในการรู้จำลายมือชื่อกับภาพที่ได้รับการปรับปรุงด้วยเทคนิค

อีวีริสติก และ 4) การทดสอบความแม่นยำในการรู้จำลายมือชื่อกับภาพที่ได้รับการปรับปรุงด้วยเทคนิคการปรับปรุงภาพรวมกับการใช้อีวีริสติก

4.2.1 ผลการทดสอบประสิทธิภาพของอัลกอริทึมการรู้จำด้วยภาพต้นฉบับ


การทดสอบในขั้นตอนนี้เป็นการเปรียบเทียบประสิทธิภาพความแม่นยำในการจำแนกเพื่อรู้จำภาพลายมือชื่อของอัลกอริทึมทั้ง 4 อัลกอริทึมได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (ใช้เคอร์เนลฟังก์ชันสี่ชนิดคือ ฟังก์ชันเชิงเส้น ฟังก์ชันพหุนาม ฟังก์ชันเรเดียลเบสิส และฟังก์ชันซิกมอยด์) เพอร์เซปตรอน นาอ์ฟเบย์ (ใช้ฟังก์ชันการกระจายข้อมูลสามชนิดคือ เกาเซียน มัลติโนเมียล และเบอร์นูลลี) และเคเนียร์เสนเบอร์ ในกรณีของอัลกอริทึมเคเนียร์เสนเบอร์จะทำการทดลองด้วยค่า $k = 1, 2, 3, \dots, 20$ เพื่อหาค่า k ที่ให้ค่าความแม่นยำที่สูงที่สุดเพื่อพิจารณาเลือกโมเดลที่ดีที่สุดสำหรับนำไปใช้ในขั้นตอนนี้

ผลการทดลองแสดงดังตารางที่ 4.1 การทดสอบประสิทธิภาพของอัลกอริทึมที่ใช้ในการรู้จำ ปรากฏผลว่าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนมีความแม่นยำในการรู้จำสูงที่สุดอยู่ที่ 95.33% ด้วยการใช้เคอร์เนลฟังก์ชันพหุนาม รองลงมาจะเป็นอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่ใช้เคอร์เนลฟังก์ชันเชิงเส้นให้ค่าความแม่นยำที่ 94.67% อัลกอริทึมอื่น ๆ จะให้ค่าความแม่นยำที่ต่ำลง เช่น มัลติโนเมียลนาอ์ฟเบย์อยู่ที่ 82.67% เพอร์เซปตรอน 68.67%

ตารางที่ 4.1 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อของอัลกอริทึมการรู้จำแบบต่าง ๆ

Algorithms	Functions	Accuracy	
		Training data	Test data
Perceptron	Linear	1.000	0.687
SVM	Linear	1.000	0.947
	Poly	1.000	0.953
	RBF	1.000	0.007
	Sigmoid	0.042	0.007
Naive Bayes	Gaussian	1.000	0.567
	Multinomial	0.973	0.827
	Bernoulli	0.042	0.007
k-NN	k=1	1.000	0.847
	k=2	0.953	0.833
	k=3	0.927	0.787

ในกรณีของอัลกอริทึมเคเนียร์เซนเบอร์ สังเกตได้ว่าค่า k มีความสัมพันธ์แบบแปรผกผันกับค่าความแม่นยำในการรู้จำ โดยความแม่นยำจะมีค่ามากที่สุดเมื่อ $k=1$ (อยู่ที่ 84.7%) และน้อยที่สุด 38.7% เมื่อ $k = 20$ ดังจะเห็นได้จากรูปที่ 4.2








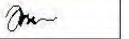
รูปที่ 4.2 กราฟแสดงความสัมพันธ์ของจำนวน k กับค่าความแม่นยำของอัลกอริทึมเคเนียร์เซนเบอร์

4.2.2 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคการปรับปรุงภาพ

เมื่อนำภาพถ่ายมือชื่อมาปรับปรุงคุณภาพของภาพด้วยเทคนิคการหาขอบภาพและการทำขอบภาพให้บางลง จากนั้นนำภาพที่ปรับปรุงแล้วไปสร้างโมเดลด้วยอัลกอริทึมการรู้จำ ผลลัพธ์ปรากฏดังตารางที่ 4.2 จากผลลัพธ์พบว่าอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่ใช้ฟังก์ชันเชิงเส้นเป็นเคอร์เนล ให้ค่าความแม่นยำสูงขึ้นด้วยเทคนิคการตรวจหาขอบภาพแบบโซเบล โดยให้ค่าความแม่นยำที่ 96.00% ซึ่งเป็นค่าที่สูงกว่าค่าความแม่นยำสูงสุดของการรู้จำกับภาพในชุดข้อมูลดั้งเดิม

จากผลการทดลองในตารางที่ 4.2 จะเห็นได้ว่าด้วยเทคนิคการตรวจหาขอบแบบโซเบลนั้น อัลกอริทึมเคเนียร์เซนเบอร์มีค่าความแม่นยำสูงขึ้นเมื่อ $k = 1, 2$ และ 3 โดยเฉพาะอย่างยิ่งที่ค่า $k = 1$ นั้น มีความแม่นยำสูงถึง 95.33% ซึ่งเทียบเท่ากับค่าความแม่นยำสูงสุดของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่เรียนรู้จากชุดข้อมูลดั้งเดิมที่ยังไม่ผ่านกระบวนการปรับปรุงภาพ

ตารางที่ 4.2 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคการปรับปรุงภาพ

Algorithm	Function	Original Data		Sobel Edge		Canny Edge		Robert Edge		Prewitt Edge		Thining	
													
		Accuracy		Accuracy		Accuracy		Accuracy		Accuracy		Accuracy	
		Training data	Test data	Test data	GAP from Original	Test data	GAP from Original	Test data	GAP from Original	Test data	GAP from Original	Test data	GAP from Original
Perceptron	linear	1.000	68.67%	86.67%	18.00%	64.00%	-4.67%	72.00%	3.33%	65.33%	-3.34%	45.33%	-23.34%
SVM	linear	1.000	94.67%	96.00%	1.33%	83.33%	-11.34%	89.33%	-5.34%	82.00%	-12.67%	86.00%	-8.67%
	poly	1.000	95.33%	94.00%	-1.33%	2.00%	-93.33%	14.67%	-80.66%	2.00%	-93.33%	88.67%	-6.66%
	rbf	1.000	0.67%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%
	sigmoid	0.042	0.67%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%	0.67%	0.00%
Naive Bayes	gaussian	1.000	56.67%	20.67%	-36.00%	65.33%	-8.66%	72.00%	15.33%	65.33%	8.66%	71.33%	14.66%
	multinomial	0.973	82.67%	89.33%	6.66%	85.33%	2.66%	86.67%	4.00%	87.33%	4.66%	75.33%	-7.34%
	bernoulli	0.042	0.67%	17.33%	16.66%	67.33%	66.66%	72.00%	71.33%	68.67%	68.00%	0.67%	0.00%
k-NN	k = 1	1.000	84.67%	95.33%	10.66%	9.33%	-75.34%	40.00%	-44.67%	12.67%	-72.00%	25.33%	-59.34%
	k = 2	0.953	83.33%	94.00%	10.67%	9.33%	-74.00%	37.33%	-46.00%	14.00%	-69.33%	20.67%	-62.66%
	k = 3	0.927	78.67%	91.33%	12.66%	6.00%	-72.67%	28.00%	-50.67%	8.00%	-70.67%	9.33%	-69.34%

ในส่วนของความแม่นยำที่ได้จากเทคนิคการหาขอบภาพนั้น จะมีความแม่นยำในการทำนายค่อนข้างน้อย ตัวอย่างเช่นเทคนิคการตรวจหาขอบภาพแบบแค่นี้ จะมีความแม่นยำสูงสุดอยู่ที่ 85.33% เมื่อเรียนรู้ด้วยอัลกอริทึมนาอิว์เบย์ที่ใช้ฟังก์ชันการกระจายข้อมูลแบบมัลติโนเมียล ซึ่งนับว่ายังน้อยกว่าค่าความแม่นยำสูงสุดของชุดข้อมูลดั้งเดิมถึง 12% และด้วยเทคนิคการหาขอบภาพแบบอื่น ๆ ที่เหลือ ไม่ว่าจะเป็นการตรวจหาขอบภาพแบบโรเบิร์ต การตรวจหาขอบภาพแบบพรีวิตต์ และการทำขอบภาพบางนั้นจะให้ค่าความแม่นยำที่ต่ำ โดยทั้งหมดมีค่าความแม่นยำต่ำกว่า 90% ไม่ว่าจะใช้อัลกอริทึมใดในการสร้างโมเดลการรู้จำ

จากการทดลองนี้แสดงให้เห็นว่า การใช้เทคนิคการตรวจหาขอบภาพแบบโซเบลนั้นเป็นเพียงเทคนิคเดียวที่ให้ผลลัพธ์การรู้จำภาพลายมือชื่อที่สูงกว่าค่าความแม่นยำสูงสุดของชุดข้อมูลดั้งเดิม ผู้วิจัยจึงนำเฉพาะภาพลายมือชื่อที่ผ่านการทำขอบภาพแบบโซเบล เพื่อเข้าสู่กระบวนการพัฒนาประสิทธิภาพโมเดลการรู้จำในขั้นตอนสุดท้าย

4.2.3 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคฮิวริสติก

เทคนิคฮิวริสติกที่ใช้ในการปรับปรุงภาพลายมือชื่อของงานวิจัยนี้ ใช้วิธีการเพิ่มข้อมูลในส่วนของภาพที่มีความเข้มสีสูงที่ถือเป็นจุดเด่นของภาพลายมือชื่อ ผลการทดสอบความแม่นยำในการรู้จำภาพที่ผ่านเทคนิคฮิวริสติกนี้แสดงดังตารางที่ 4.3

ผลการทดสอบปรากฏว่าการเพิ่มชุดข้อมูลที่มีความเข้มสีสูงเข้าไปนั้นช่วยให้ความแม่นยำสูงขึ้นในอัลกอริทึมส่วนใหญ่ เช่น อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนจะเพิ่มขึ้นประมาณ 2.1% โดยมีค่าความแม่นยำสูงสุดที่ 97.33% ด้วยการใช้เคอร์เนลฟังก์ชันพหุนาม นอกจากนั้นยังพบอีกว่า อัลกอริทึมเคเนียร์เสนเบอร์เป็นอีกอัลกอริทึมที่ให้ค่าความแม่นยำที่สูงที่สุดเช่นเดียวกันที่ 97.33% เมื่อใช้ค่า $k = 1$ โดยมีความแม่นยำสูงขึ้นถึง 14.95% เมื่อเปรียบเทียบกับข้อมูลชุดดั้งเดิม โดยถือว่าเป็นการเพิ่มขึ้นอย่างมีนัยสำคัญ และเมื่อพิจารณาที่ $k = 2$ และ 3 นั้นจะพบว่ามีความแม่นยำเพิ่มขึ้นเช่นกันจาก 83.3% เป็น 97.3% และจาก 78.7% เป็น 93.3% ตามลำดับ

ตารางที่ 4.3 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคฮิวริสติก

Algorithm	Function	Traditional Method		Intensive Data Method		Improvement
		(5,472 columns)		(5,472+717 columns)		
		Accuracy		Accuracy		
		Training data	Test data	Training data	Test data	
Perceptron	linear	1.000	0.687	1.000	0.693	0.96%
SVM	linear	1.000	0.947	1.000	0.967	2.11%
	poly	1.000	0.953	1.000	0.973	2.10%
	rbf	1.000	0.007	1.000	0.007	0.00%
	sigmoid	0.042	0.007	0.042	0.007	0.00%
Naive Bayes	gaussian	1.000	0.567	1.000	0.567	0.00%
	multinomial	0.973	0.827	0.987	0.893	8.06%
	bernoulli	0.042	0.007	0.042	0.007	0.00%
k-NN	k = 1	1.000	0.847	1.000	0.973	14.95%
	k = 2	0.953	0.833	0.982	0.953	14.40%
	k = 3	0.927	0.787	0.980	0.933	18.63%

4.2.4 ผลการทดสอบประสิทธิภาพการรู้จำด้วยภาพที่ผ่านเทคนิคการปรับปรุงภาพและเทคนิคฮิวริสติก

จากผลการทดลองในขั้นตอนก่อนหน้าแสดงให้เห็นถึงผลลัพธ์ที่ดีที่สุดในการรู้จำภาพลายมือซึ่งอยู่ที่ระดับความแม่นยำ 97.3% โดยพบว่าการใช้ภาพลายมือชื่อที่ผ่านการหาขอบภาพแบบโซเบล และด้วยเทคนิคการเพิ่มชุดข้อมูลความเข้มสูงเข้าไปนั้นทำให้ค่าความแม่นยำสูงขึ้นอย่างมีนัยสำคัญ เมื่อนำทั้งเทคนิคการปรับปรุงภาพและเทคนิคฮิวริสติกมาใช้ร่วมกัน (Sobel Edge + Additional Intensive Data Method) ได้ผลลัพธ์ดังตารางที่ 4.4 จากการใช้เทคนิคการปรับปรุงภาพร่วมกับเทคนิคฮิวริสติก พบว่ามีสองอัลกอริทึมที่ให้ความแม่นยำสูงถึง 98% ได้แก่ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่ใช้เคอร์เนลเป็นฟังก์ชันเชิงเส้น และอัลกอริทึมเคเนียร์เรนเนเบอร์ เมื่อค่า $k = 1$

การเพิ่มประสิทธิภาพโมเดลการรู้จำด้วยการนำทั้งสองเทคนิคมาผสมผสานกัน ทำให้อัลกอริทึมส่วนใหญ่มีค่าความแม่นยำสูงขึ้น มีเพียงอัลกอริทึมนาอิวเบย์ที่ใช้ฟังก์ชันการกระจายข้อมูลแบบเกาส์เซียนเท่านั้นที่ให้ความแม่นยำที่ลดลงจาก 56.67% เหลือเพียง 21.33%

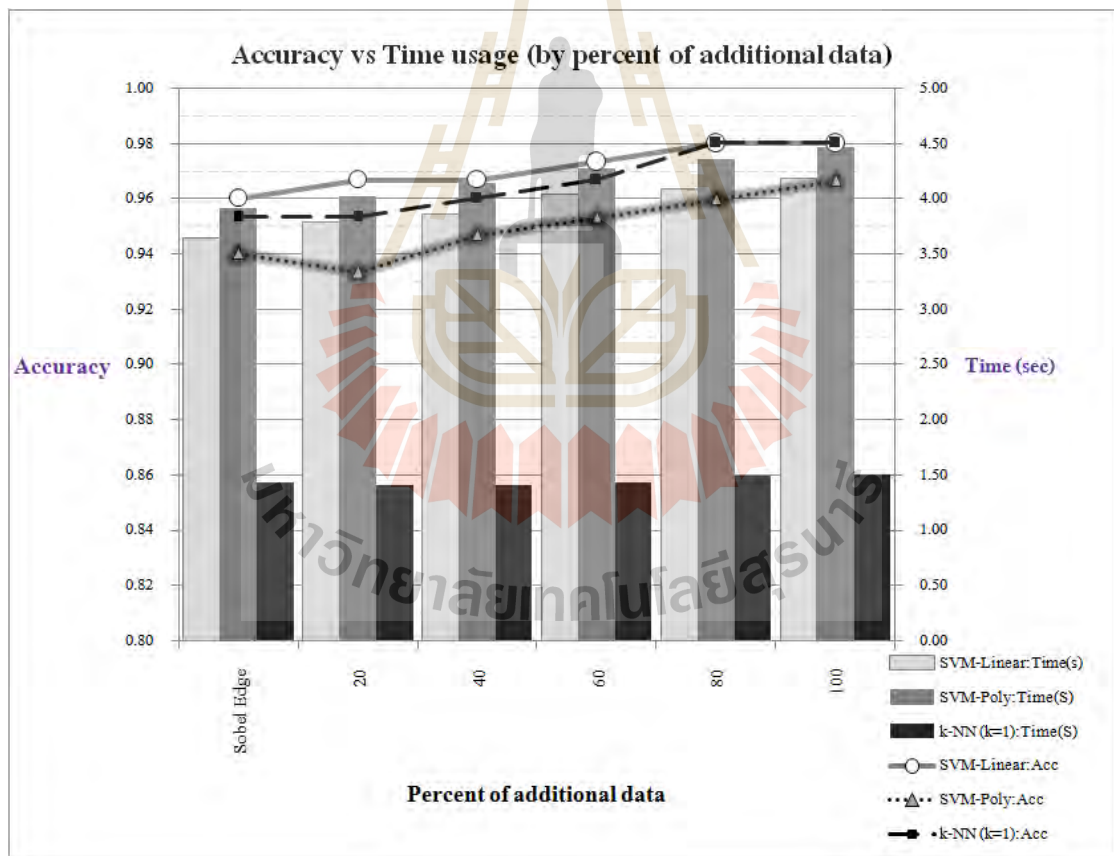
ตารางที่ 4.4 ผลการทดสอบความแม่นยำในการรู้จำภาพลายมือชื่อที่ผ่านเทคนิคปรับปรุงภาพร่วมกับเทคนิคฮิวริสติก

Algorithm	Function	Original		Sobel Edge		Sobel Edge + Additional Intensive Data Method	
		Accuracy		Accuracy		Accuracy	
		Train	Test	Test	Improvement from original	Test	Improvement from original
Perceptron	linear	100%	68.67%	86.67%	26.21%	88.67%	29.12%
SVM	linear	100%	94.67%	96.00%	1.40%	98.00%	3.52%
	poly	100%	95.33%	94.00%	-1.40%	96.67%	1.41%
	rbf	100%	0.67%	0.67%	0.00%	0.67%	0.00%
	sigmoid	4.22%	0.67%	0.67%	0.00%	0.67%	0.00%
Naive Bayes	gaussian	100.0%	56.67%	20.67%	-63.53%	21.33%	-62.36%
	multinomial	97.33%	82.67%	89.33%	8.06%	92.67%	12.10%
	bernoulli	4.22%	0.67%	17.33%	2486.57%	18.00%	2586.57%
k-NN	k = 1	100.00%	84.67%	95.33%	12.59%	98.00%	15.74%
	k = 2	95.33%	83.33%	94.00%	12.80%	95.33%	14.40%
	k = 3	92.67%	78.67%	91.33%	16.09%	96.00%	22.03%

4.3 การทดสอบประสิทธิภาพด้านเวลา

จากผลการทดสอบในขั้นตอนก่อนหน้าพบว่าเทคนิคฮิวริสติกสามารถเพิ่มความแม่นยำในการรู้จำภาพลายมือชื่อ ในขั้นตอนนี้จึงได้ทดลองหาความสัมพันธ์ระหว่างความแม่นยำ และเวลาที่ใช้ในการสร้างโมเดลการรู้จำ โดยจะทำการเพิ่มข้อมูลบริเวณที่มีความเข้มสูงที่เป็นตัวแทนจุดเด่นของลักษณะลายมือชื่อของแต่ละบุคคล โดยเพิ่มข้อมูลที่ละ 20% จากจำนวนข้อมูลที่มีความเข้มสูงทั้งหมด

จากการสำรวจข้อมูลทั้ง 600 ภาพพบว่าจำนวนข้อมูลความเข้มสูงที่สูงที่สุดจากข้อมูลทั้งหมด คือ 717 คอลัมน์ซึ่งจะสามารถเห็นได้จากกราฟในรูปที่ 4.3 ว่าความแม่นยำในการทำนายของแต่ละโมเดลนั้นจะมีค่าสูงขึ้นตามลำดับ โดยจะมีค่าสูงที่สุดเมื่อเพิ่มข้อมูลที่ความเข้มสูงเข้าไปที่ 100% ในขณะที่เวลาที่เพิ่มขึ้นมาจากการเพิ่มชุดข้อมูลเข้าไบนั้นจะเพิ่มขึ้นเพียงแค่น้อย โดยในอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนจะเพิ่มขึ้น 0.5 วินาที และอัลกอริทึมเคเนียร์เนสเนเบอร์จะเพิ่มเพียง 0.08 วินาที



รูปที่ 4.3 กราฟแสดงความสัมพันธ์ระหว่างความแม่นยำในการรู้จำและเวลาที่ใช้ในการสร้างโมเดลเมื่อเปลี่ยนแปลงเปอร์เซ็นต์ของการเพิ่มข้อมูลในเทคนิคฮิวริสติก

4.4 อภิปรายผล

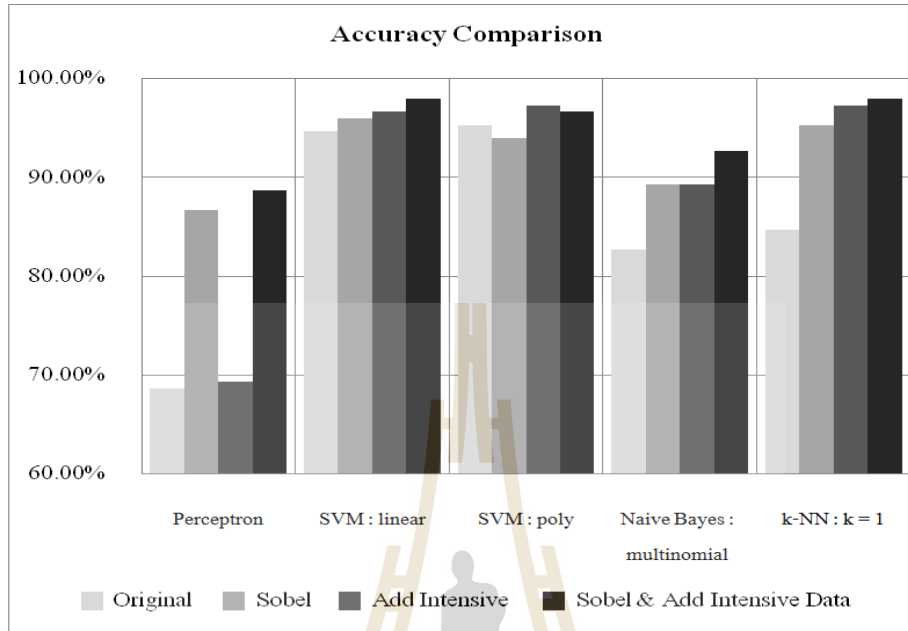
จากข้อมูลตั้งต้นที่เป็นภาพลายมือชื่อทั้งสิ้น 600ภาพ จากผู้เข้าร่วม 30 คน และผลการทดลองที่ได้นำเสนอมาข้างต้นนั้น สามารถสรุปและวิเคราะห์ผลการเปรียบเทียบประสิทธิภาพได้ดังต่อไปนี้

1) กรณีที่ไม่มีการปรับปรุงใด ๆ กับภาพลายมือชื่อ (Original Data) การรู้จำภาพด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนที่ใช้ฟังก์ชันพหุนามเป็นเคอร์เนล ให้ความแม่นยำในการรู้จำลายมือชื่อสูงที่สุดที่ 95.33% ซึ่งผลการทดลองนี้สอดคล้องกับงานวิจัยด้านการรู้จำลายมือชื่อส่วนใหญ่ที่ระบุว่าซัพพอร์ตเวกเตอร์แมชชีนเป็นอัลกอริทึมที่ให้ค่าความแม่นยำสูงสุด หรือสูงอยู่ในอันดับต้น ๆ โดยค่าความแม่นยำที่ 95.33% นี้จะถูกใช้เป็นค่าความแม่นยำพื้นฐานสำหรับเปรียบเทียบกับเทคนิคในขั้นตอนต่อ ๆ ไป นอกจากนี้ข้อสังเกตอีกประการจากการทดลองในขั้นตอนนี้พบว่าอัลกอริทึมเคเนียร์เสนเบอร์ให้ค่าความแม่นยำที่มีลักษณะการแปรผันแบบผกผันกับค่า k อย่างมีนัยสำคัญ

2) การปรับปรุงภาพด้วยเทคนิคการหาขอบภาพและการทำขอบให้บางลง เมื่อนำภาพที่ผ่านการปรับปรุงแล้วไปผ่านกระบวนการรู้จำพบว่าวิธีการตรวจหาขอบภาพแบบโซเบลนั้นเป็นวิธีที่ให้ค่าความแม่นยำที่ดีที่สุด คือ 96.00% และเป็นเพียงวิธีเดียวที่มีค่าความแม่นยำสูงกว่าค่าความแม่นยำสูงสุดของข้อมูลชุดเดิม การได้ค่าความแม่นยำที่สูงขึ้นคาดว่าเกิดจากการที่การตรวจหาขอบภาพแบบโซเบลนั้นทำให้ขอบของตัวลายมือชื่อมีความหนามากขึ้น จึงทำให้มีข้อมูลที่นำมาใช้ในการสร้างโมเดลการรู้จำมากขึ้น ซึ่งจะสอดคล้องกับผลลัพธ์ที่ได้จากเทคนิคการทำขอบภาพให้บางลง ซึ่งความแม่นยำที่ได้มานั้นลดลงในเกือบทุกอัลกอริทึม

3) การปรับปรุงภาพด้วยเทคนิคอิวิริสติกที่ใช้วิธีการเพิ่มชุดข้อมูลที่มีความเข้มสูง (Additional Intensive Data Method) โดยการเพิ่มชุดข้อมูลที่มีค่าความเข้มสีค่อนข้างมากเพิ่มเข้าไปต่อท้ายกับชุดข้อมูลเดิม กล่าวคือสนใจระดับความเข้มสีที่อยู่ระหว่าง 0 ถึง 200 เท่านั้น จากนั้นนำข้อมูลใหม่ที่ผ่านการคัดกรองแล้วเข้าไปต่อท้ายจากชุดข้อมูลแถวลำดับเดิมอีก 717 คอลัมน์ รวมกับของเดิม 5,472 คอลัมน์ ทำให้ขยายขนาดข้อมูลเป็นทั้งสิ้น 6,189 คอลัมน์ โดยภาพลายมือชื่อที่นำมาใช้นั้นจะเป็นภาพลายมือชื่อที่ได้จากการใช้เทคนิคการตรวจหาขอบภาพแบบโซเบลเข้าช่วยก่อนแล้ว ซึ่งผลการทดลองจากวิธีการใหม่นี้พบว่า อัลกอริทึมเพอร์เซปตรอนเป็นอัลกอริทึมที่แสดงการเพิ่มขึ้นของค่าความแม่นยำมากที่สุด โดยเพิ่มจาก 68.67% เป็น 88.67% ซึ่งเพิ่มจากเดิม 20% ทั้งนี้เป็นเพราะค่าความแม่นยำเดิมนั้นต่ำมาก จึงสามารถเห็นการเพิ่มขึ้นของความแม่นยำได้อย่างชัดเจน ในส่วนของค่าการรู้จำที่สูงที่สุดในงานวิจัยชิ้นนี้นี้อยู่ที่ 98% ซึ่งมาจากสองอัลกอริทึม ได้แก่ อัลกอริทึมเคเนียร์เสนเบอร์ ที่ค่า $k=1$ มีค่าความแม่นยำเพิ่มขึ้นจาก 84.67% เป็น 98.00% ซึ่งเพิ่มขึ้นถึง 13.33% อีกอัลกอริทึมหนึ่งที่ให้ค่าความแม่นยำสูงทัดเทียมกันคือ ซัพพอร์ตเวกเตอร์แมชชีนที่ใช้เคอร์เนลเป็นฟังก์ชันเชิงเส้น ซึ่งเป็นอัลกอริทึมที่ให้ค่าความแม่นยำที่สูงตั้งแต่เดิมอยู่แล้ว

ผลสรุปของการเปรียบเทียบค่าความแม่นยำในการรู้จำภาพลายมือชื่อแสดงเป็นภาพกราฟได้ดังรูปที่ 4.4



รูปที่ 4.4 กราฟแสดงการเปรียบเทียบความแม่นยำการรู้จำภาพลายมือชื่อ

ในส่วนของเวลาที่ใช้ในการสร้างโมเดลนั้นพบว่าจะเพิ่มขึ้นเพียงเล็กน้อยเมื่อเทียบกับความแม่นยำที่สูงขึ้น จึงถือได้ว่าเป็นการแลกเปลี่ยนระหว่างเวลากับความแม่นยำที่คุ้มค่า ตัวอย่างเช่นอัลกอริทึมเคเนียร์เซนเบอร์จะมีความแม่นยำสูงขึ้น 3% โดยใช้เวลาเพิ่มขึ้นเพียง 0.08 วินาที

บทที่ 5

บทสรุป

5.1 สรุปผลการวิจัย

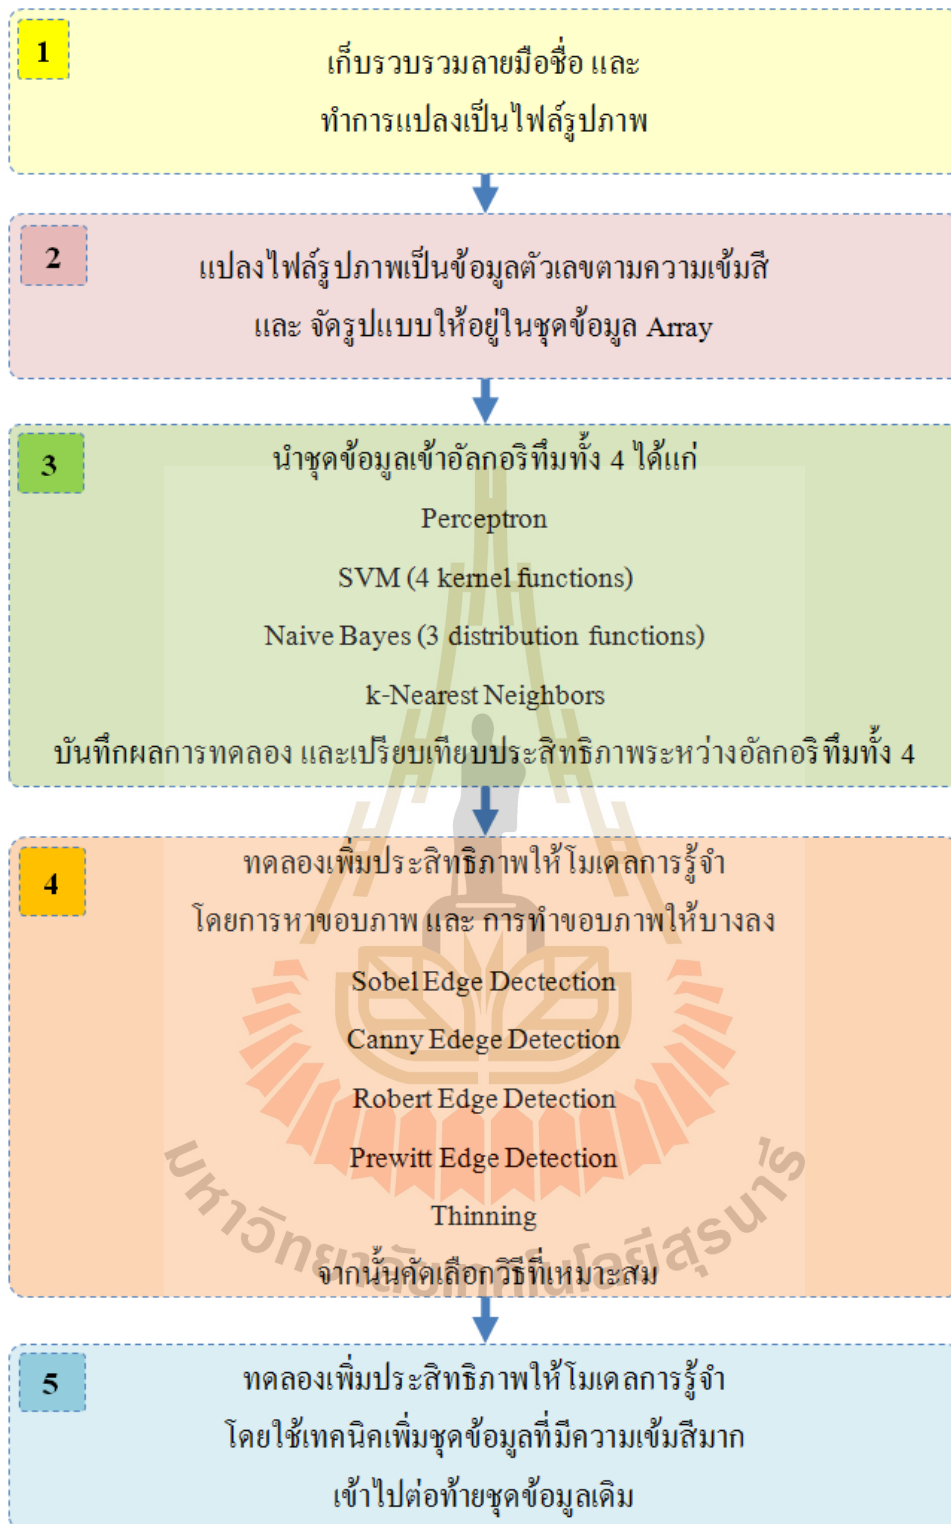
งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแนวทางในการเพิ่มประสิทธิภาพระบบไปโอเมตริกซ์สำหรับระบุตัวตนจากพฤติกรรมของบุคคล โดยลักษณะพฤติกรรมของบุคคลในงานวิจัยนี้เน้นเฉพาะลายมือชื่อ แนวทางการเพิ่มประสิทธิภาพในด้านความแม่นยำของการรู้จำใช้วิธีการปรับปรุงภาพร่วมกับเทคนิคฮิวริสติกที่เป็นการเพิ่มข้อมูลที่มีความเข้มสูง เนื่องจากสันนิษฐานว่าจุดของภาพลายมือชื่อที่มีความเข้มสูงจะเป็นจุดที่สามารถแยกความแตกต่างของลายมือชื่อแต่ละบุคคลได้ดี

ในส่วนการรู้จำภาพลายมือชื่อที่ผ่านกระบวนการปรับปรุงภาพและการใช้เทคนิคฮิวริสติกมาแล้ว จะใช้อัลกอริทึมการรู้จำ 4 อัลกอริทึมได้แก่ perceptron, support vector machine, naive Bayes และ k-nearest neighbors การคัดเลือกอัลกอริทึมใช้วิธีการศึกษาเปรียบเทียบประสิทธิภาพของโมเดลที่ได้จากอัลกอริทึมการรู้จำทั้ง 4 อัลกอริทึม เพื่อคัดเลือกอัลกอริทึมการรู้จำที่ให้ความแม่นยำสูงที่สุด

ขั้นตอนการดำเนินงานหลักของโครงการวิจัยนี้แบ่งออกเป็น 5 ขั้นตอนย่อยได้แก่

- 1) ขั้นตอนการเก็บข้อมูลลายมือชื่อและการแปลงภาพลายมือชื่อให้เป็นไฟล์ภาพ
- 2) ขั้นตอนการแปลงข้อมูลภาพลายมือชื่อให้เป็นข้อมูลทางตัวเลขเพื่อให้สามารถประมวลผลในขั้นตอนต่อไปได้
- 3) ขั้นตอนการทดสอบเปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึมเพื่อคัดเลือกอัลกอริทึมที่ให้ความแม่นยำในการรู้จำที่สูงที่สุด
- 4) ขั้นตอนการเพิ่มประสิทธิภาพการรู้จำโดยการใช้เทคนิคการหาขอบภาพและการทำขอบภาพให้บางลง
- 5) ขั้นตอนการเพิ่มประสิทธิภาพการรู้จำโดยการใช้เทคนิคฮิวริสติก ด้วยการเพิ่มชุดข้อมูลที่มีความเข้มสูง

ขั้นตอนเหล่านี้สรุปเป็นแผนภาพได้ดังรูปที่ 5.1

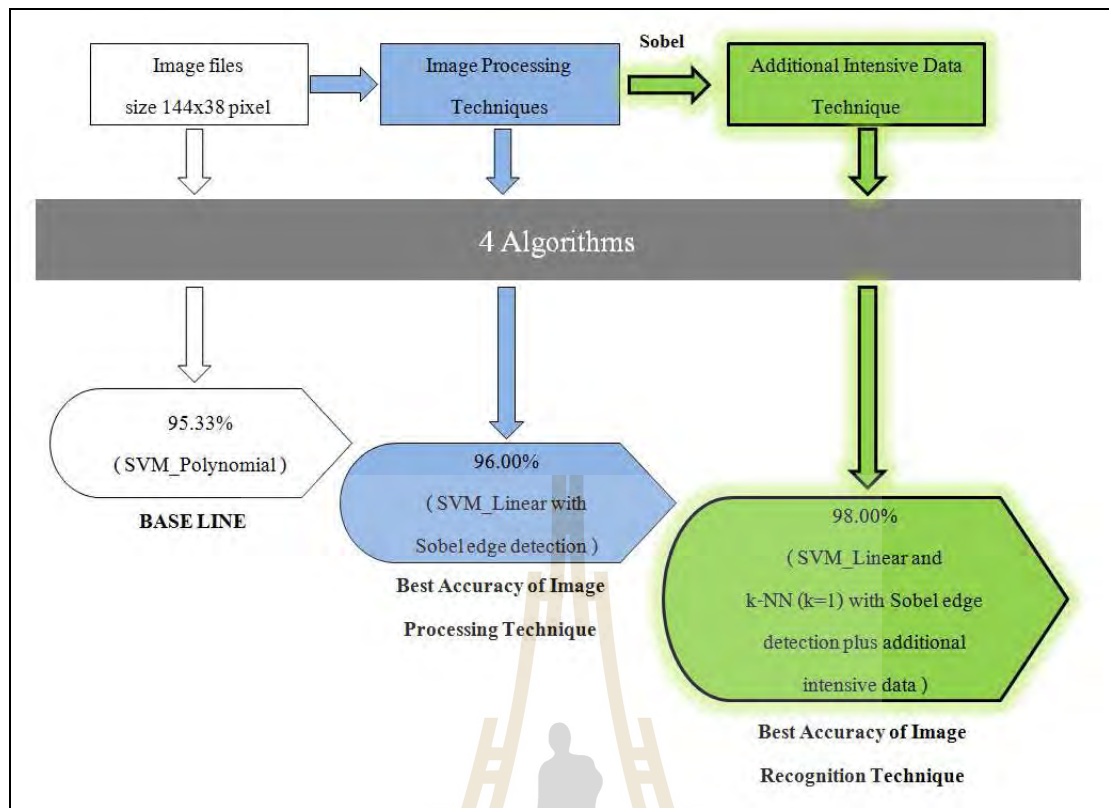


รูปที่ 5.1 แผนภาพสรุปขั้นตอนการดำเนินงานวิจัย

จากผลการทดลองทดสอบประสิทธิภาพการรู้จำลายมือชื่อด้วยวิธีการใช้ภาพถ่ายมือชื่อดั้งเดิมที่ยังไม่ผ่านกระบวนการปรับปรุงภาพและการใช้ฮิวริสติก พบว่าอัลกอริทึมซอฟต์แวร์แมชชีนที่ใช้ฟังก์ชันพหุนามเป็นเคอร์เนล ให้ค่าความแม่นยำสูงสุดที่ 95.33% และนอกจากนั้นยังสังเกตเห็นได้อีกว่าอัลกอริทึมเคเนียร์เรสเนเบอร์ในการทดลองนี้ให้ค่าความแม่นยำที่มีความสัมพันธ์กับค่า k อย่างมีนัยสำคัญโดยความสัมพันธ์ที่ได้มีลักษณะการแปรผันแบบผกผัน นั่นคือ k ที่มีค่าน้อยจะให้ความแม่นยำในการรู้จำลายมือชื่อสูงกว่า k ที่มีค่ามาก

เมื่อใช้เทคนิคการปรับปรุงภาพด้วยการหาขอบภาพและการทำภาพให้บางลง จากผลการทดลองจะเห็นได้ว่าวิธีการตรวจหาขอบภาพแบบโซเบลนั้นเป็นวิธีที่ให้ค่าความแม่นยำที่ดีที่สุด คือ 96% และเป็นเพียงวิธีปรับปรุงภาพวิธีเดียวที่ให้ค่าความแม่นยำในการรู้จำลายมือชื่อสูงขึ้นกว่าค่าความแม่นยำสูงสุดของข้อมูลชุดเดิมที่ไม่ต้องใช้เทคนิคการปรับปรุงภาพ โดยการรู้จำที่ดีที่สุดได้มาจากอัลกอริทึมซอฟต์แวร์แมชชีนที่ใช้ฟังก์ชันเชิงเส้นเป็นเคอร์เนล ส่วนในกรณีของการรู้จำด้วยอัลกอริทึมเคเนียร์เรสเนเบอร์นั้นได้ค่าความแม่นยำเท่ากับค่าสูงสุดของชุดข้อมูลเดิมที่ 95.33% โดยอัลกอริทึมส่วนใหญ่จะให้ค่าความแม่นยำสูงขึ้นเมื่อภาพถ่ายมือชื่อถูกปรับปรุงด้วยเทคนิคการตรวจหาขอบภาพแบบโซเบล

การพัฒนาแนวทางการเพิ่มประสิทธิภาพของระบบไบโอเมตริกซ์เชิงพฤติกรรมในขั้นตอนสุดท้ายเป็นการใช้ฮิวริสติกด้วยเทคนิคการเพิ่มชุดข้อมูลที่มีความเข้มสูง จากผลการทดลองพบว่าอัลกอริทึมเพอร์เซปตรอนเป็นอัลกอริทึมที่มีค่าความแม่นยำในการรู้จำลายมือชื่อเพิ่มขึ้นมากที่สุดโดยเพิ่มจาก 68.67% เป็น 88.67% ซึ่งเพิ่มจากเดิม 20% ในส่วนของค่าความแม่นยำที่สูงที่สุดในการรู้จำลายมือชื่ออยู่ที่ 98% โดยมาจากสองอัลกอริทึม ได้แก่ อัลกอริทึมเคเนียร์เรสเนเบอร์ ที่ค่า $k=1$ และซอฟต์แวร์แมชชีนที่ใช้ฟังก์ชันเชิงเส้นเป็นเคอร์เนล โดยผลการทดสอบเหล่านี้สรุปได้ดังภาพที่ 5.2



รูปที่ 5.2 แผนภาพสรุปผลการทดสอบประสิทธิภาพการรู้จำลายมือชื่อ

5.2 ข้อจำกัดและข้อเสนอแนะ

ข้อมูลที่ใช้ในงานวิจัยนี้รวบรวมจากกลุ่มของนักศึกษาที่มีอายุอยู่ในช่วง 20-23 ปีซึ่งเป็นกลุ่มตัวอย่างเพียงช่วงวัยเดียว ในอนาคตอาจจะสามารถเพิ่มจำนวนของคนเข้าร่วมงานวิจัยให้มากขึ้น โดยอาจเพิ่มกลุ่มของเด็กวัยรุ่น คนวัยทำงาน และคนวัยเกษียณ เพื่อให้ครอบคลุมกลุ่มตัวอย่างมากขึ้น รวมถึงเพิ่มกลุ่มอาชีพให้หลากหลายมากขึ้นซึ่งจะสามารถแสดงถึงความสามารถของไบโอเมตริกซ์เชิงพฤติกรรมว่ามีประสิทธิภาพด้านความแม่นยำ เพียงพอที่จะรองรับการใช้งานกับกลุ่มบุคคลทุกกลุ่มและหลากหลายอาชีพ

งานวิจัยชิ้นนี้มีลักษณะการทำงานแบบออฟไลน์ ซึ่งหากมีการพัฒนาไปเป็นการใช้งานแบบออนไลน์จะทำให้เกิดความสะดวกต่อการใช้งาน และเหมาะสมกับการใช้งานในยุคปัจจุบันมากยิ่งขึ้น

เนื่องจากเทคนิคการปรับปรุงรูปภาพในยุคปัจจุบันนั้นมีหลากหลายเทคนิค และมีการพัฒนาไปอย่างรวดเร็ว ข้อเสนอแนะสำหรับการพัฒนางานวิจัยในอนาคตจึงเป็นการประยุกต์เทคนิคการปรับปรุงรูปภาพแบบอื่นที่อาจจะให้ผลลัพธ์ที่ดียิ่งขึ้น รวมถึงอาจพิจารณาใช้เทคนิคการเรียนรู้ในยุคใหม่ เช่น การเรียนรู้เชิงลึก ที่คาดว่าจะอาจให้ความแม่นยำในการรู้จำภาพลายมือชื่อได้ดีขึ้น

บรรณานุกรม

- G. Bailador, C. Sanchez-Avila, J. Guerra-Casanova, and A. de Santos Sierra, "Analysis of pattern recognition techniques for in-air signature biometrics," *Pattern Recognition*, vol. 44, pp. 2468-2478, 2011.
- H. Benaliouche and M. Touahria, "Comparative study of multimodal biometric recognition by fusion of iris and fingerprint," *The Scientific World Journal*, article 829369, pp. 1-13, 2014.
- S. Boukhonine, V. Krotov, and B. Rupert, "Future security approaches and biometrics," *Communications of the Association for Information Systems*, vol. 16, article 48, 2005.
- K. Delac and M. Grgic, "A survey of biometric recognition methods," *Proceedings of the 46th International Symposium Electronics in Marines, Zadar, Croatia*, pp. 184-193, 2004.
- R. de Luis-Garcia, C. Alberola-Lopez, O. Aghzout, and J. Ruiz-Alzola, "Biometric identification systems," *Signal Processing*, vol. 83, pp. 2539-2557, 2003.
- M. Fahmy, A. Atiya, and R. Elfouly, "Biometric fusion using enhanced SVM classification," *Proceedings of the International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, Harbin, China, pp. 1043-1048, 2008.
- S. Fatahi, E. Zadkhosh, and A. Chalechale, "Face recognition with linear discriminant analysis and neural networks," *Proceedings of the First Iranian Conference on Pattern Recognition and Image Analysis*, Birjand, Iran, pp. 1-4, 2013.
- J. Galbally, R. Plamondon, J. Fierrez, and J. Ortega-Garcia, "Synthetic on-line signature generation. Part I: methodology and algorithms," *Pattern Recognition*, vol. 45, pp. 2610-2621, 2012.
- U. Gawande, M. Zaveri, and A. Kapur, "A novel algorithm for feature level fusion using SVM classifier for multibiometrics-based person identification," *Applied*

- Computational Intelligence and Soft Computing*, article 515918, pp. 1-11, 2013.
- R. Giot, M. El-Abed, and C. Rosenberger, "Fast computation of the performance evaluation of biometric systems: application to multibiometrics," *Future Generation Computer Systems*, vol. 29, pp. 788-799, 2013.
- J. Gonzalez-Rodriguez, J. Fierrez-Aguilar, D. Ramos-Castro, and J. Ortega-Garcia, "Bayesian analysis of fingerprint, face and signature evidences with automatic biometric systems," *Forensic Science International*, vol. 155, pp. 126-140, 2005.
- A. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 4-20, 2004.
- X. Jing, Y. Yao, D. Zhang, J. Yang, and M. Li, "Face and palmprint pixel level fusion and kernel DCV-RBF classifier for small sample biometric recognition," *Pattern Recognition*, vol. 40, pp. 3209-3224, 2007.
- H. Liao and D. Isa, "Feature selection for support vector machine-based face-iris multimodal biometric system," *Expert Systems with Applications*, vol. 38, pp. 11105-11111, 2011.
- A. Martinez and A. Kak, "PCA versus LDA," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, no. 2, pp. 228-233, 2001.
- J. Mazanec, M. Melisek, M. Oravec, and J. Pavlovicova, "Support vector machines, PCA, and LDA in face recognition," *Journal of Electrical Engineering*, vol. 59, no. 4, pp. 203-209, 2008.
- K. Radhika, M. Venkatesha, and G. Sekhar, "An approach for on-line signature authentication using Zernike moments," *Pattern Recognition Letters*, vol. 32, pp. 749-760, 2011.
- J. Ramirez-Cortes, P. Gomez-Gil, V. Alarcon-Aquino, D. Baez-Lopez, and R. Enriquez-Caldera, "A biometric system based on neural networks and SVM using

- morphological feature extraction from hand-shape images,” *Informatica*, vol. 22, no. 2, pp. 225-240, 2011.
- I. Rodriguez-Lujan, G. Bailador, C. Sanchez-Avila, A. Herrero, and G. Vidal-de-Miguel, “Analysis of pattern recognition and dimensionality reduction techniques for odor biometrics,” *Knowledge-Based systems*, vol. 52, pp. 279-289, 2013.
- R. Singh, M. Vatsa, and A. Noore, “Intelligent biometric information fusion using support vector machine,” *Soft Computing in Image Processing*, vol. 210, pp. 325-349, 2007.
- K. Sodhi and M. Lal, “Face recognition using PCA, LDA and various distance classifiers,” *Journal of Global Research in Computer Science*, vol. 4, no. 3, pp. 30-35, 2013.
- J. Unar, W. Seng, and A. Abbasi, “A review of biometric technology along with trends and prospects,” *Pattern Recognition*, vol. 47, pp. 2673-2688, 2014.
- R. Yampolskiy and V. Govindaraju, “Behavioural biometrics: a survey and classification,” *International Journal of Biometrics*, vol. 1, no. 1, pp. 81-112, 2008.
- K. Yang, E. Du, and Z. Zhou, “Consent biometrics,” *Neurocomputing*, vol. 100, pp. 153-162, 2013.

ภาคผนวก

ผลผลิตของงานวิจัย



ภาคผนวก ก

บทความวิจัยตีพิมพ์ในวารสารและเอกสารสืบเนื่องจากการประชุมวิชาการ

1. A. Hirunyanakul, S. Bunrit, N. Kerdprasop, K. Kerdprasop (2019). Deep learning technique for improving the recognition of handwritten signature. *International Journal of Information and Electronic Engineering*, vol. 9, no. 4, December, pp. 72-78. (indexing: INSPEC, ISSN: 2010-3719)
2. A. Hirunyanakul, K. Chaiyakhan, R. Chanklan, K. Kerdprasop, N. Kerdprasop (2015). A new efficient method to improve handwritten signature recognition. *Proceedings of the 3rd International Conference on Industrial Application Engineering 2015 (ICIAE2015)*, Kitakyushu, Japan, 28-31 March, pp.561-568.
3. N. Kerdprasop, R. Chanklan, A. Hirunyanakul, K. Kerdprasop (2014). An empirical study of dimensionality reduction methods for biometric recognition. *Proceedings of the 7th International Conference on Security Technology (SecTech 2014)*, Hainan, China, 20-23 December, pp.26-29.

มหาวิทยาลัยเทคโนโลยีสุรนารี

Deep Learning Technique for Improving the Recognition of Handwritten Signature

Anusara Hirunyanakul, Supaporn Bunrit, Nittaya Kerdprasop, and Kittisak Kerdprasop

Abstract—Handwritten signature recognition is a biometric task used extensively in our daily life. The efficacy of such system is important and challenging in that the recognition accuracy still has room for improvement. In this paper, we propose the use of Deep Convolutional Neural Networks (DCNN), which is a deep learning technique, to improve accuracy of handwritten signature recognition. We apply DCNN in two difference strategies for signature recognition: 1) transfer learning using leveraged features from a pre-trained model on a larger dataset, and 2) create CNN model from scratch. Our studied dataset consists of 600 pictures of handwritten signatures collected from 30 people. In order to evaluate the effectiveness of the proposed method, the accuracy is compared with the results obtained from various machine learning methods. The comparison reveals very satisfied recognition results in the sense that the two proposed strategies achieve 100% of the recognition rate. To compare the two strategies in terms of training time, the strategy of creating DCNN model from scratch shows much lower training time than the transfer learning strategy.

Index Terms—Deep learning, deep convolutional neural networks, handwritten signature recognition, transfer learning.

I. INTRODUCTION

Handwritten signature is a task of machine learning with the main aim to verify or identify individuals by recognizing the pattern in their signature. The recognition task is thus recognizing the specific behavior when a person signs his/her signature. Such recognition system is therefore categorized as behavioral biometric system.

Biometric is different from other identification systems such as key/object possession system which requires a keycard or smartcard, or information-based system that asks for secret information like password or pin code. The strong point of biometric is that it is easy to use and convenient in practice. The convenience comes from the free of worry to remember password/pin code or to carry any keycard, identification card (ID) or badge. People are absolutely saved from hassle of having to frequently change passwords, key cards, or badges. The problems of forgetting passwords and the losing of ID cards are very annoying in traditional verification system. Moreover, each personal signature is distinct and the security is high because of the difficulty to

be forged or counterfeited. When compared to other high reliable biometric system like iris recognition or retinal recognition, handwritten signature recognition can be compromised with the advantages of economical technology, quick verification time, low intrusive level, and high social acceptability.

However, the drawback of handwritten signature recognition system is its recognition rate that still be in a middle range when compared to other biometric systems. Many researchers are thus pay attention to improve the accuracy by applying many image processing techniques or a hybrid of machine learning methods. In this work, we propose a deep learning technique based on two strategies: transfer learning and learning from scratch.

The literature review on the advance of handwritten signature recognition and preliminaries of biometrics, pattern recognition and deep learning techniques are presented in Section II. Our proposed recognition method based on deep convolutional neural networks (DCNN) is explained in Section III. The results of performance evaluation are shown in Section IV. We finally conclude our work in Section.

II. LITERATURE REVIEW AND THEORY

A. Related Work

Recently, researchers had investigated a wide range of techniques to improve the accuracy of handwritten signature recognition. The data-intensive technique proposed by Hirunyanakul *et al.* [1] converted signature data from image file into numeric table in accordance with color intensity of gray scale with 256 level from 0 (black color) – 255 (white color). Then, numeric table was transformed to be array data and fed the array data into the pre-modeling step. At the pre-modeling step, image quality has been enhanced by applying Sobel edge detection technique. Data in high intensity area were then assigned more weight than those in less important area such as the white background. At the modeling step, support vector machine (SVM) with several types of kernel functions, multi-layer perceptron, and k-nearest neighbors (kNN) with different number of neighbors were applied to build models for signature recognition. SVM with linear kernel and k-NN with k=1 are the two most accurate modeling methods.

The work of Vagas *et al.* [2] improved signature recognition rate by focusing on the grey-scale and co-occurrence matrix technique with local binary pattern based on the MCYT-75 and GPDS-100 databases. The result of the equal error rate (EER) in such work is 16.27%. Guerbai *et al.* [3] proposed one-class SVM for handwritten signature verification. The result from the experiment was

Manuscript received November 7, 2019; revised December 16, 2019.

A. Hirunyanakul, S. Bunrit, and K. Kerdprasop are with the School of Computer Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand (e-mail: Anusara.hi@gmail.com, nittaya@sut.ac.th).

N. Kerdprasop is with the School of Computer Engineering and Data and Knowledge Engineering Research Unit, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand (e-mail: kerdpras@sut.ac.th).

5-7% average error rate (AER) in recognizing signatures available in the CEDAR dataset.

The aforementioned works were based recognition performance on current machine learning techniques such as SVM. In the age of big data [4], state-of-the-art technique called deep learning is gaining dramatic interest from researchers in various fields. Deep convolutional neural network (DCNN) is a kind of deep learning developed from artificial neural network. DCNN has been claimed [5] a powerful technique for general image recognition. We are thus interested in applying DCNN for a specific task of handwritten signature recognition.

Our DCNN-based signature recognition method is structured to be composed of two learning strategies, which are transfer learning using parameters available from existing deep learning network architecture (also called a pre-trained strategy), and learning from scratch in which we create new deep learning network architecture from our own design. For the pre-trained strategy, we employ the two existing models: AlexNet and VGG16. AlexNet was invented by Alex Krizhevsky and teammates and has big impact in machine learning and image recognition communities [6]-[10]. VGGNet is a new architecture of deep learning developed by Simonyan and Zisserman and widely adopted by many researchers [11]-[14]. VGGNet consists of 16 layers in its deep network with 138 million parameters and can classify objects as much as 1,000 categories. We are thus interested in comparing performance of VGGNet and AlexNet in recognition the biometric.

B. Biometrics

Biometrics is a part of pattern recognition [15]-[17]. It is a technical term for individual identification or verification using features extracted from either human's physical or behavior. Biometric systems have one of the two modes of operation: verification and identification. For the verification mode, after the user sends a signature or information of biometrics to the biometric system, the system checks the identity of the user via PIN, Login name, or others. The system will recognize and verify the requested user as 1:1 (one-to-one) data. The applications of this kind of biometrics always found in E-Commerce, access control, or mobile devices access control.

For the identification mode, the biometric system tries to recognize the sender or the requested biometric information through the comparison against the registered dataset. The operation of this mode is 1:N (one-to-N). The recognition of this system will be automatically compared without the identification request (like login name, login id).

Biometric system is more complex than traditional identification system such as object possession system or information-based system. However, it is traded off with simplicity, efficiency, and social acceptability. Password or information-based system is the simplest system but it is vulnerable to attack from electronic theft.

The object possession system such as smartcard, key card or identification documents is very useful and easy to use. However, it can be easily lost, stolen or forgotten at somewhere. Even though the system is integrated with cryptography methods, it makes the system more expensive

to implement. On the contrary, the biometric system is very difficult to falsify, since it is encrypted by the complicated mathematic operations. It is considerably less falsifiable than the manual recognition. Another benefit of biometrics is that the information is unique for each individual and tolerate to the time variations.

C. Pattern Recognition, Intelligence, and Deep Learning

The pattern recognition [16] is the field of study closely relate to artificial intelligence (AI) and machine learning. It involves object classification with respect to "feature" of each "class". Pattern recognition can be applied to various fields. For example, the individual identification using physical biometrics such as face, fingerprint, iris, DNA, and behavioral biometrics such as signature. The classification technique in pattern recognition requires knowledge of various branches, e.g. data mining, neural network, machine learning, and data improvement processes such as image enhancement.

Pattern recognition can be considered a sub-field of AI that has been defined by John McCarthy as "the science and engineering of making intelligent machines that have the ability to achieve goals like humans do" [17]-[19]. Broadly speaking, AI is human intelligence exhibited by machines. Currently, we can group AI into two separated tasks, which are Artificial General Intelligence (AGI) and Artificial Narrow Intelligence (ANI). AGI is the intelligence of a machine that could successfully perform any intelligent task that a human being can. It is a primary goal of AI research. For ANI, it focused on one narrow task. Almost all existing systems that claim to use AI are likely operating as a narrow AI because they focused on a specific problem. The examples are spamming e-mail classification system, face recognition, and a well-known board game AI "AlphaGo".

Machine learning is defined as another large sub-field of AI [16], [20]. It is a field concerning how to make computers being able to learn without being explicitly programmed. Therefore, machine learning is an approach to achieve AI. This is exactly how humans learn as well. When kids learn to identify objects/person, we do not tell them an algorithm/procedure to identify the features. We just simply show them multiple examples of that object and then our human brain automatically identifies the features and learns to identify that object. This is indeed what a machine-learning model does.

In terms of learning method and technique, machine learning can be divided into two groups: supervised and unsupervised learning. For supervised learning, the computer or machine is presented with example inputs and their real outputs, which can be seen as guiding solutions. The goal of learning is to create a general rule that can correctly relate inputs to outputs [21]. Examples of supervised learning are perceptron, SVM, naïve Bayes. In case of unsupervised learning, there is no need for guiding solutions. The learning objective is it find common structures or patterns in the training data. Examples of unsupervised learning are association mining and clustering.

Deep learning is a new kind of machine learning method that makes its learning via data representations. It is opposed to task-specific algorithms in that its learning can be both

supervised or unsupervised [22]-[24]. One of the most prominent deep learning architecture is deep neural networks. It has been successfully applied to many fields including speech recognition, natural language processing, biometrics, board game programs, and image recognition. For image recognition applications, they can produce results comparably to human experts [25]-[27]. The use of deep learning for handwritten recognition are investigated and researched in textual form of different languages [28]-[32].

Deep neural network can recognize raw images through a numerous of connected network layers. Each layer processes and computes the information sent from the previous stacked layer. This layer-by-layer processing runs until the output layer has been reached. The result from a network is a class label. The most applicable deep neural network is convolutional neural network.

D. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) is a learning method inspired by biological processes. It is believed that the main computation element of living creatures is neuron. The connected network of neurons forms the basis of all the decisions made based on the information gathered. CNN is a feed-forward network with three key mechanisms: local receptive fields, weight sharing, and sub-sampling [33]. The network is trained like a normal neural network using back-propagation algorithm. The common architecture of a CNN is structured by four main layers [34].

1) *Convolutional layer*: This layer has main function for applying a filter mask. The filter is applied on a specified area of the image. The area that has been filtered is called the receptive field. The operation of this layer involves computing the weighted summation of the values covered by the receptive field using the weights of the filter mask. Then, the weighted summation is added with a bias and passes through an activation function. Once this value is computed, receptive field moves on the feature map by a number of strides to cover new area for computation of next value using the same filter mask. The purpose of filter mask is to learn basic pattern of object in the image. The weights of filter mask are shared across a feature map in the model [7]-[9].

2) *ReLU layer (rectified linear units layer)*: This layer is placed immediately after the convolutional layer. It aims at applying the nonlinearity to the system because during convolutional layers, just linear operation is used. The transfer functions like sigmoid and tanh that are preferred in the past do not used in CNN. It instead uses ReLU or Rectified Linear Unit transfer function. ReLU is claimed to improve the network in both accuracy and training times [35]. It also mitigates the gradient problem issue. The ReLU applies function in equation 1 to all input values.

$$f(x) = \max(0, x) \quad (1)$$

According to equation 1, the ReLU layer changes all negative values into zero value. This layer increases the nonlinear properties of the model.

3) *Pooling layers*: The pooling layer is preferred to say as a down-sampling layer. There are many layer options. However, the most popular one is max-pooling. The algorithm of max-pooling applies on input volume and

outputs the maximum value in every sub region that filter mask move around. Example is demonstrated in Fig. 1.




Fig. 1. Example of Max-pooling with filter mask = 2x2 and Stride = 2.

The proposal of this layer is to reduce the spatial dimension of the input volumes, which are not as important as other features. Another proposal of this layer is to prevent a problem of over fitting [12].

4) *Dropout layers*: To avoid the over fitting problem, the dropout layer is applied to contain the switching function that randomly selects neurons during each iteration of the model training stage. It can prevent the neurons to learn features of which relevant only when a different neuron is present [12], [36].

5) *Fully connected layers*: This is the traditional layer of neural network model in which each neuron is connected to every output from previous layer. This layer integrates all features learned from previous layers across the image to identify the larger patterns. The last layer of fully connected layer is to classify the images [37].

There are numerous architectures using the concept of CNN. The prominent ones include AlexNet [38], GoogleNet [39], VGGNet [7], and ResNet [40]. These architectures are the inspiration for many research works to use them to solve variety of problems. The applications of these CNN architectures are in two main strategies: transfer learning [41], and create new CNN from scratch [42]. We adopt both strategies in our research work. The details of these strategies are in the next section.

III. MATERIAL AND METHOD

This section presents material and method used in our work. It consists of research framework, research workflow, and strategies of network creation. Details of our dataset and computation resource are also presented in this section.

A. Research Framework

The main idea of our research is graphically shown in Fig. 2. Based on the objective of improving the accuracy rate of handwritten signature recognition using state-of-the-art learning method, we design our research to contain deep learning-based technique as a core function. As a result, two strategies of DCNN “Transfer Learning” and “Training from scratch” are used in this work to build up the network model. For performance evaluation, we compare the recognition accuracy and training time of DCNN and machine learning techniques.

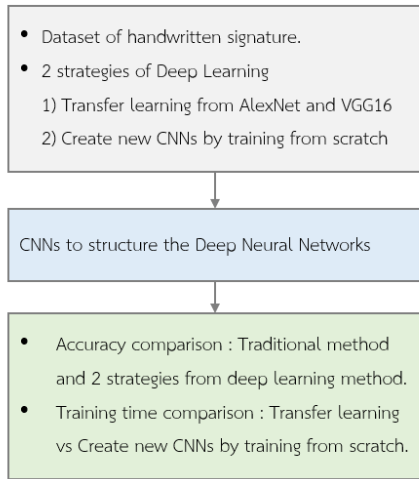


Fig. 2. Research framework.

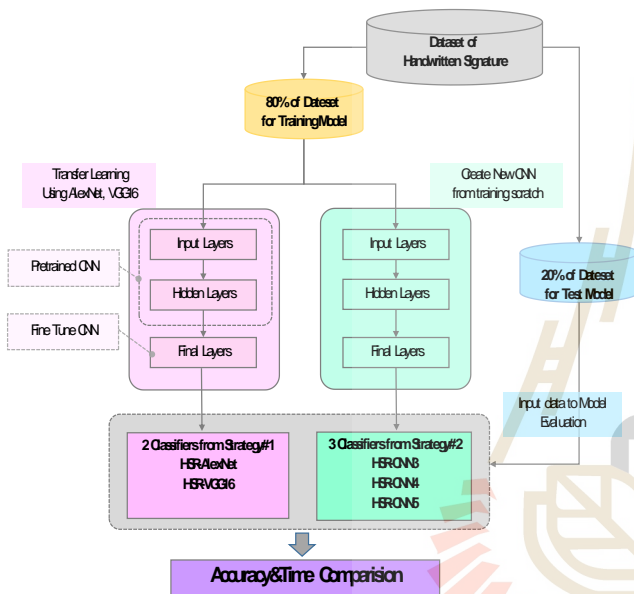


Fig. 3. Research workflow diagram.

B. Research Workflow

The flow chart shown in Fig. 3 demonstrates our research steps. Starting by using the dataset of handwritten signatures [1], which is publicly available at <https://sites.google.com/site/nhinganusaracpesut/signature/datasets>. Firstly, we separate dataset into two parts. The first part, 80% of data, is for training model and the rest 20% is for testing model performance. The training set is fed into both strategies. The strategy 1 is called “Transfer Learning” that applied the pre-train DCNN based on the AlexNet and VGG16 architectures. The strategy 2 is named “Training from scratch” in which all weights of the DCNN are learned solely from our dataset.

In strategy 1 that we use the classifiers from transfer learning technique of AlexNet and VGG16, we call them as HSR-AlexNet and HSR-VGG16, respectively. HSR is the acronym for handwritten signature recognition. In strategy 2, we design three classifiers from different architectures of DCNN, and we call these classifiers as HSR-CNN3, HSR-CNN4, and HSR-CNN5. The differences among these three classifiers are the number of convolutional layers.

C. Strategies of DCNN in This Research

1) *Transfer learning from pre-train of big dataset:* Transfer learning using AlexNet and VGG16 is the strategy that we fine-tune the pre-trained models of AlexNet and VGG16 to best suit our current dataset. AlexNet is a well-known architecture that are pre-trained from numerous images (more than 1 million images), where the output classes or object categories are 1,000 classes. AlexNet is claimed its success in classification for wide range of applications. VGGNet is a popular deep learning like AlexNet, but the number of layers in VGGNet is deeper. In this work, we use VGG16, which consists of 16 layers (There are only 8 layers for AlexNet). VGGNet is attractive word wide because of its uniform architecture. In this experiment, we use the pre-trained network of AlexNet and VGG16 as a starting point to learn the new task of our dataset. On the key parameters of a fine-tuning task, we tune the model with varying number of Epoch (10, 20, and 50). Other parameters are shown in Table I. Such parameters are back propagation learning algorithm that we use SGDM (stochastic gradient descent with momentum), set mini batch size to 10, set the initial learning rate to 0.0001, the validation frequency (VF) equals 30, and the validation patience is “Inf”.

TABLE I: KEY PARAMETER SET UP IN “TRANSFER LEARNING” BY USING ALEXNET AND VGG16

Parameter Name	Value
Learning Algorithm	SGDM
Mini Batch Size	10
Initial Learning Rate	0.0001
Validation Frequency	30
Validation Patience	Inf
Max Epochs	10, 20, 50

2) *Create new CNN from scratch:* The starting point of this strategy is different from the transfer learning scheme. To create new CNN from scratch, we need a model to learn our new training dataset. That means model from this method is purely influenced from our dataset with no overwhelming by millions of data as the scheme pre-trained by AlexNet or VGG16. On creating the suitable CNN architecture, we tune the number of convolutional layers in order to investigate the effective trend in terms of accuracy and training time. The requirements of input image size between each technique are not the same. Pre-trained AlexNet require 227x227 pixels, VGG16 require 224x224 pixels. By creating new CNN from scratch, we can use the original size of image, which is 38x144 pixels. Table II shows detail of the two strategies for comparison.

TABLE II: DETAIL COMPARISON OF “TRANSFER LEARNING” AND “CREATE NEW CNN FROM SCRATCH”

Transfer learning	Create New CNN from scratch
Start with the pre-train of AlexNet, VGG16	Start with new learn from our dataset
# Convolution Layers : 5 layers for AlexNet 13 layers for VGG16	# Convolution Layers : 3 for HSR-CNN3 4 for HSR-CNN4 5 for HSR-CNN5
Image size: 227x227 pixels (AlexNet) 224x224 pixels (VGG16)	Image size: 38x144 pixels

D. Dataset of This Research

We experiment on 600 signature images collected from 30 individuals. Original size of images in a dataset is 38x144 pixels. However, for a strategy “Transfer learning by Using AlexNet”, we need to feed pictures with the exact size of 277x277 pixels. But for the strategy “Transfer learning by Using VGG16”, the image size must be 224x224 pixels. As a result, we need to firstly resize each image into the acceptable size of both AlexNet and VGG16. Fig. 4 shows four examples of the resized handwritten signature pictures. Each example shows the original 38x144 size, the 224x224 size for VGG16, and the 277x277 size for AlexNet.

Our experiments run by program MATLAB R2018a on a personal computer with CPU Intel Core i5-7300HQ (2.50 – 3.50 GHz) 4 Cores/4 Threads, GPU NVIDIA GeForce GTX 1050 (4GB GDDR5), HDD 1 TB 5400 RPM, and RAM 8 GB with DDR 4.




Fig. 4. Examples of the resized handwritten signature picture.

IV. EXPERIMENTAL RESULTS

This section explains experiments and experimental results. The key point is the comparison of performances between 2 strategies of deep learning techniques: “Transfer learning by using AlexNet and VGG16” and “Create new CNN from scratch”. Accuracy and training time comparison of “Transfer learning by using AlexNet and VGG16” are shown in Table III and the comparative results of “Create new CNN from scratch” are illustrated in Table IV. Both deep learning techniques provide higher accuracy when compared to traditional machine learning methods as shown in Table V.

From the results demonstrated in Table III, it can be seen that HSR-AlexNet is able to achieve highest accuracy at 100% when Max Epochs = 50 with 312 seconds of training time (the example of training progress result is shown is Fig. 5). On the contrary, the HSR-VGG16 can reach 100% accuracy at earlier iteration since Max Epochs = 20. However, the training time of VGG16 is quite long at 2,012 seconds, as compared to 312 seconds used by the AlexNet.

From Table IV that shows the results obtained from the “Create new CNN from scratch” strategy, the highest accuracy is reached when Max Epochs equal 50. HSR-CNN3 can reach its highest accuracy at 94.17% with training time of 90 seconds. HSR-CNN4 can reach a better accuracy at 98.33% using 104 seconds of training time, whereas HSR-CNN5 is the best model with the highest accuracy of 99.17%. The tradeoff is that HSR-CNN5 uses the longest training time at 115 seconds. It can be noticed from the results that, at the same value of Max Epochs (i.e., 50), the greater number of convolutional layers, the higher accuracy.

TABLE III: ACCURACY AND TRAINING TIME COMPARISON BETWEEN HSR-ALEXNET AND HSR-VGG16 FROM STRATEGY “TRANSFER LEARNING BY USING ALEXNET AND VGG16”

Deep learning technique	Max Epochs	Accuracy	Time (sec)
HSR-AlexNet (Transfer Learning from AlexNet)	10	89.17	63
	20	98.33	136
	50	100.00	312
HSR-VGG16 (Transfer Learning from VGG16)	10	93.33	460
	20	100.00	2012
	50	100.00	2283

TABLE IV: ACCURACY AND TRAINING TIME COMPARISON BETWEEN HSR-CNN3 HSR-CNN4 AND HSR-CNN5 FROM STRATEGY “CREATE NEW CNN FROM SCRATCH”

Deep learning technique	Max Epochs	Accuracy	Time (sec)
HSR-CNN3 (3 Convolutional Layers)	10	92.50	18
	20	93.33	37
	50	94.17	90
HSR-CNN4 (4 Convolutional Layers)	10	95.00	20
	20	97.50	43
	50	98.33	104
HSR-CNN5 (5 Convolutional Layers)	10	94.17	24
	20	97.50	48
	50	99.17	115

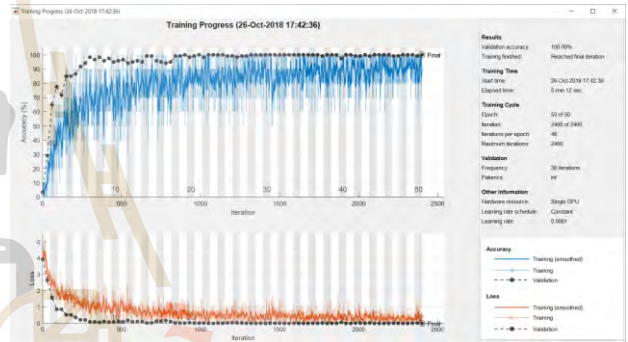


Fig. 5. Training progress from modeling of HSR-AlexNet when Max Epochs = 50.

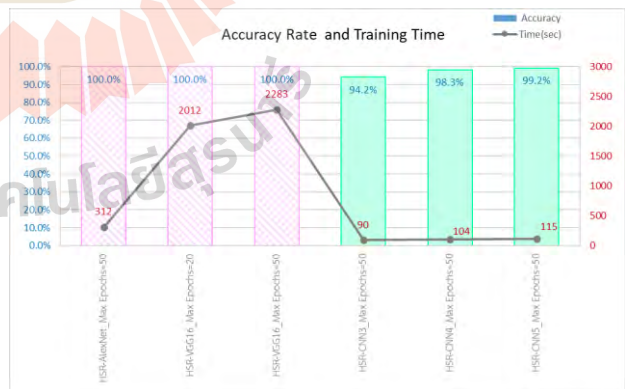


Fig. 6. Accuracy and Training time comparison of deep learning models from both strategies of “Training by using AlexNet and VGG16” and “Create new CNN from Scratch”.

TABLE V: ACCURACY COMPARISON BETWEEN DEEP LEARNING AND TRADITIONAL MACHINE LEARNING

Method	Model	Highest Accuracy
Deep Learning	HSR-AlexNet	100.00
	HSR-VGG16	100.00
	HSR-CNN5	99.17
Traditional Machine Learning	SVM + Sobel Edge + Additional Intensive Data	98.00
	k-NN + Sobel Edge + Additional Intensive Data	98.00

A bar chart in Fig. 6 compares the accuracy and the training time from the best model with the highest accuracy in each strategy. We can see that the accuracies of transfer learning technique (diagonal stripes bar chart) are higher than the create new CNN from scratch (solid colored bar chart). But the trade-off in terms of increasing training time can also be observed (solid line). Especially for VGG16, the training time usage is more than 10 times higher than the create new CNN from scratch strategy (2,012 seconds and 2,883 seconds compared to 115 seconds).

Table V presents a comparison in terms of accuracy to recognize handwritten signature between deep learning models and the machine learning models. The machine learning algorithms are SVM and k-NN plus the image enhancement with Sobel edge detection technique and data intensive weighting. We found that all models from deep learning with both “Transfer learning by using AlexNet and VGG16” strategy and “Create new CNN from scratch” scheme perform better than the methods based on traditional machine learning algorithms. The maximum accuracy of the traditional machine learning is 98.0%, whereas the minimum of deep learning (learning from scratch scheme) is 99.17%. At maximum performance of a pre-trained deep learning, the accuracy is as high as 100%. In detail comparison of each model, HSR-AlexNet, HSR-VGG16, and HSR-CNN5 are more accurate than traditional machine learning by 2%, 2% and 1.17%, respectively.

V. CONCLUSION

In this research, we study the problem of offline-handwritten signature recognition with the main focus to improve recognition performance by applying the novel technique of deep learning. We use two strategies of deep learning, that are 1) transfer learning from pre-trained model of AlexNet and VGG16, and 2) create new CNN from scratch. We demonstrate through experimentation that our proposed method using deep learning technique can improve the accuracy rate of handwritten signature recognition. We also do the comparison in terms of the training time of both strategies of deep learning. Our dataset of this research is collected from users who use their handwritten signature in daily life. This kind of data can guarantee that our method can practically be applied in the real-world scenario.

In part of the performance comparison from transfer learning technique, both HSR-AlexNet and HSR-VGG16 are able to achieve the perfect accuracy at 100% of recognition rate. Moreover, we can observe that HSR-VGG16 achieve an accuracy 100% with the lower number of Max Epochs (HSR-VGG16 achieve 100% at max epoch = 20, while HSR-AlexNet archive at max epoch = 50). Such results also relate to the training time that each model uses. HSR-VGG16 always takes longer time than HSR-AlexNet. The reason is that the architecture of VGG16 has more layers and more number of parameters than the AlexNet architecture. According to the “creating new CNN from scratch” strategy, the models can provide maximum accuracy at 99.17% (with HSR-CNN5 architecture using max epoch =50). The accuracy is a bit lower than transfer learning technique but compromising by significant shorter training time. Moreover,

we observe that when increase the number of convolutional layers, we will get higher accuracy result.

Finally, when we compare both strategies of deep learning to the traditional machine methods, it is clearly to conclude that deep learning method can help improving the performance of handwritten signature recognition.

In this research, we perform handwritten signature recognition with offline version. The limitation is that the number of sample size is only 600 signatures. For more robustness of the research result, we plan to include more samples in our dataset in the future. Another research direction that we plan to perform is the extension of current task to cover online handwritten signature verification.


ACKNOWLEDGMENT

This research work has been supported by grants from the National Research Council of Thailand (NRCT). Data and Knowledge Engineering Research Unit has been fully supported by a research grant from Suranaree University of Technology.

REFERENCES

- [1] A. Hirunyanakul, K. Chaiyakhon, R. Chanklan, K. Kerdprasop, and N. Kerdprasop, “A new efficient method to improve handwritten signature recognition,” in *Proceedings of The 3rd International Conference on Industrial Application Engineering 2015*, March 2015, pp. 561–568.
- [2] J. F. Vargas, M. A. Ferrer, C. M. Travieso, and J. B. Alonso, “Off-line signature verification based on grey level information using texture features,” *Pattern Recognition*, vol. 44, no. 2, pp. 375–385, 2011.
- [3] Y. Guerbai, Y. Chibani, and B. Hadjadji, “The effective use of the one-class SVM classifier for handwritten signature verification based on writer-independent parameters,” *Pattern Recognition*, vol. 48, no. 1, pp. 103–113, 2015.
- [4] D. Gershgorin. (July 2017). The data that transformed AI research - and possibly the world. *Quartz*. [Online]. Available: <https://qz.com/1034972/>
- [5] J. Donahue *et al.*, “DeCAF: A deep convolutional activation feature for generic visual recognition,” in *Proc. the 31st International Conference on Machine Learning*, PMLR, vol. 32, no. 1, 2014, pp. 647–655.
- [6] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep Learning*, vol. 1, MIT Press, Cambridge, 2016.
- [7] J. Gu *et al.*, “Recent advances in convolutional neural networks,” *arXiv Prepr. arXiv1512.07108*, 2015.
- [8] C. Szegedy *et al.*, “Going deeper with convolutions,” in *Proc. the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 1–9.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Advances in Neural Information Processing Systems*, 2012, pp. 1097–1105.
- [10] J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and L. Fei-Fei, “Imagenet: A large-scale hierarchical image database,” in *Proc. the IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 248–255.
- [11] O. Russakovsky *et al.*, “Imagenet large scale visual recognition challenge,” *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252, 2015.
- [12] A. Krizhevsky and G. Hinton, “Learning multiple layers of features from tiny images,” *Technical Report TR-2009*, University of Toronto, Canada, 2009.
- [13] L. Wang, S. Guo, W. Huang, and Y. Qiao, “Places205-vggnet models for scene recognition,” *arXiv Prepr. arXiv1508.01667*, 2015.
- [14] J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic segmentation,” in *Proc. the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 3431–3440.
- [15] J. A. Unar, W. C. Seng, and A. Abbasi, “A review of biometric technology along with trends and prospects,” *Pattern Recognition*, vol. 47, no. 8, pp. 2673–2688, 2014.
- [16] N. M. Nasrabadi. (2007). Pattern recognition and machine learning. *Journal of Electronic Imaging*. [Online]. 16(4), article 49901, Available: <https://doi.org/10.1117/1.2819119>


- [17] S. M. Weiss and I. Kapouleas, "An empirical comparison of pattern recognition, neural nets, and machine learning classification methods," in *Proc. the 11th International Joint Conference on Artificial Intelligence*, 1989, pp. 781–787.
- [18] A. K. Jain, R. P. W. Duin, and J. Mao, "Statistical pattern recognition: A review," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 1, pp. 4–37, 2000.
- [19] T. J. M. Bench-Capon and P. E. Dunne, "Argumentation in artificial intelligence," *Artificial Intelligence*, vol. 171, no. 10–15, pp. 619–641, 2007.
- [20] S. B. Kotsiantis, I. Zaharakis, and P. Pintelas, "Supervised machine learning: A review of classification techniques," in *Proc. the 2007 Conference on Emerging Artificial Intelligence Applications in Computer Engineering: Real World AI Systems with Applications in eHealth, HCI, Information Retrieval and Pervasive Technologies*, 2007, pp. 3–24.
- [21] Y. Anzai, *Pattern Recognition and Machine Learning*. Morgan Kaufmann, 2012.
- [22] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 8, pp. 1798–1828, 2013.
- [23] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, 2015.
- [24] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, p. 436, 2015.
- [25] D. Ciresan, U. Meier, and J. Schmidhuber, "Multi-column deep neural networks for image classification," *arXiv Prepr. arXiv1202.2745*, 2012.
- [26] J. Russell. (2017). Google's AlphaGo AI wins three-match series against the world's best Go player. *Techcrunch*, [Online]. Available: <https://techcrunch.com/2017/05/24/alphago-beats-planets-best-human-go-player-ke-jie/?renderMode=ie11>
- [27] R. Rendall *et al.*, "Image-based manufacturing analytics: Improving the accuracy of an industrial pellet classification system using deep neural networks," *Chemometrics and Intelligent Laboratory Systems*, vol. 180, pp. 26–35, 2018.
- [28] D. C. Ciresan, U. Meier, L. M. Gambardella, and J. Schmidhuber, "Convolutional neural network committees for handwritten character classification," in *Proc. 2011 International Conference on Document Analysis and Recognition*, 2011, pp. 1135–1139.
- [29] L.-L. Ma and J. Wu, "A Tibetan component representation learning method for online handwritten Tibetan character recognition," in *Proc. 14th International Conference on Frontiers in Handwriting Recognition*, 2014, pp. 317–322.
- [30] P. Vijayaraghavan and M. Sra. (2014). Handwritten Tamil recognition using a convolutional neural network. MIT Media Lab. [Online]. Available: https://web.media.mit.edu/~sra/tamil_cnn.pdf
- [31] K. Mehrotra, S. Jetley, A. Deshmukh, and S. Belhe, "Unconstrained handwritten devanagari character recognition using convolutional neural networks," in *Proc. the 4th International Workshop on Multilingual OCR*, 2013, p. 15.
- [32] D. Ciregan, U. Meier, and J. Schmidhuber, "Multi-column deep neural networks for image classification," in *Proc. the 2012 IEEE Conference on Computer Vision and Pattern Recognition*, 2012.
- [33] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," in *Proc. the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [34] C. Boufekar, A. Kerboua, and M. Batouche, "Investigation on deep learning for off-line handwritten Arabic character recognition," *Cognitive Systems Research*, vol. 50, pp. 180–195, 2018.
- [35] V. Nair and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," in *Proc. the 27th International Conference on Machine Learning*, 2010, pp. 807–814.
- [36] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," *arXiv Prepr. arXiv1207.0580*, 2012.
- [37] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [38] A. A. Almisreb, N. Jamil, and N. M. Din, "Utilizing AlexNet deep transfer learning for ear recognition," in *Proc. the 4th International Conference on Information Retrieval and Knowledge Management*, 2018, pp. 1–5.
- [39] Z. Zhong, L. Jin, and Z. Xie, "High performance offline handwritten Chinese character recognition using GoogleNet and directional feature maps," in *Proc. the 13th International Conference on Document Analysis and Recognition*, 2015, pp. 846–850.
- [40] Z. Lu, X. Jiang, and A. C. Kot, "Deep coupled ResNet for low-resolution face recognition," *IEEE Signal Processing Letters*, vol. 25, no. 4, pp. 526–530, 2018.
- [41] D. Han, Q. Liu, and W. Fan, "A new image classification method using CNN transfer learning and web data augmentation," *Expert System Applications*, vol. 95, pp. 43–56, 2018.
- [42] N. Tajbakhsh *et al.*, "Convolutional neural networks for medical image analysis: Full training or fine tuning?" *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1299–1312, 2016.



A. Hirunyanakul is a Ph.D. student in School of Computer Engineering, Suranaree University of Technology (SUT), Thailand. She received her B.E. and M.E. in computer engineering from Suranaree University of Technology, Thailand, in 2006 and 2014. Her research of interest includes data mining, machine learning, and artificial intelligence.



S. Bunrit is a lecturer with Computer Engineering School, SUT. She received her bachelor degree in science (mathematics) from Kasetsart University, Thailand, in 1997, master degree in science (computer science) from Chulalongkorn University, Thailand, in 2001. Her research of interest includes artificial neural network, deep learning, machine learning, digital image processing, computer vision, and time series analysis.



N. Kerdprasop is an associate professor and the head of Data Engineering Research Unit, School of Computer Engineering, Suranaree University of Technology (SUT), Thailand. She received her B.S. in radiation techniques from Mahidol University, Thailand, in 1985, M.S. in computer science from the Prince of Songkla University, Thailand, in 1991 and Ph.D. in computer science from Nova Southeastern University, U.S.A., in 1999. Her research of interest

includes data mining, artificial intelligence, logic and constraint programming.



K. Kerdprasop is an associate professor at the School of Computer Engineering, the chair of the school, and the head of Knowledge Engineering Research Unit, SUT. He received his bachelor degree in mathematics from Srinakarinwirot University, Thailand, in 1986, MS in computer science from the Prince of Songkla University, Thailand, in 1991 and Ph.D. in computer science from Nova Southeastern University, U.S.A.,

in 1999. His current research includes machine learning and artificial intelligences.

A New Efficient Method to Improve Handwritten Signature Recognition

AnusaraHirunyanakul*, KedkarnChaiyakhan, RatipornChanklan, KittisakKerdprasop, NittayaKerdprasop

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 edgetechnique. 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 imagedataset. 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.

-1	0	1
-2	0	2
-1	0	1

$$S_x$$

1	2	1
0	0	0
-1	-2	-1

$$S_y$$

Fig.1.Sobel filter.

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.

-1	0	1
-1	0	1
-1	0	1

$$h_x$$

-1	-1	-1
0	0	0
1	1	1

$$h_y$$

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.

1	0
0	-1

$$G_x$$

0	1
-1	0

$$G_y$$

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 eliminated 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 doublethresholding 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 explain 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.

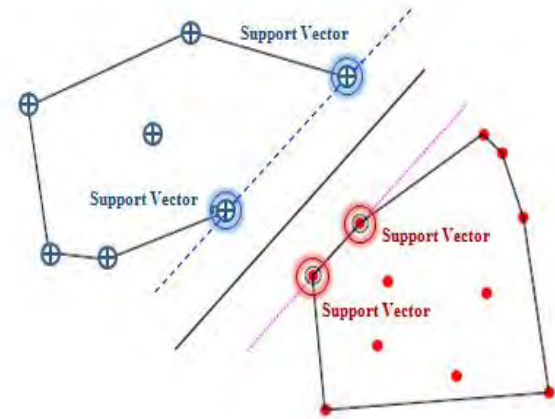


Fig. 5. The support vectors and classification in SVM algorithm

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/nhinganusaracpesut/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.

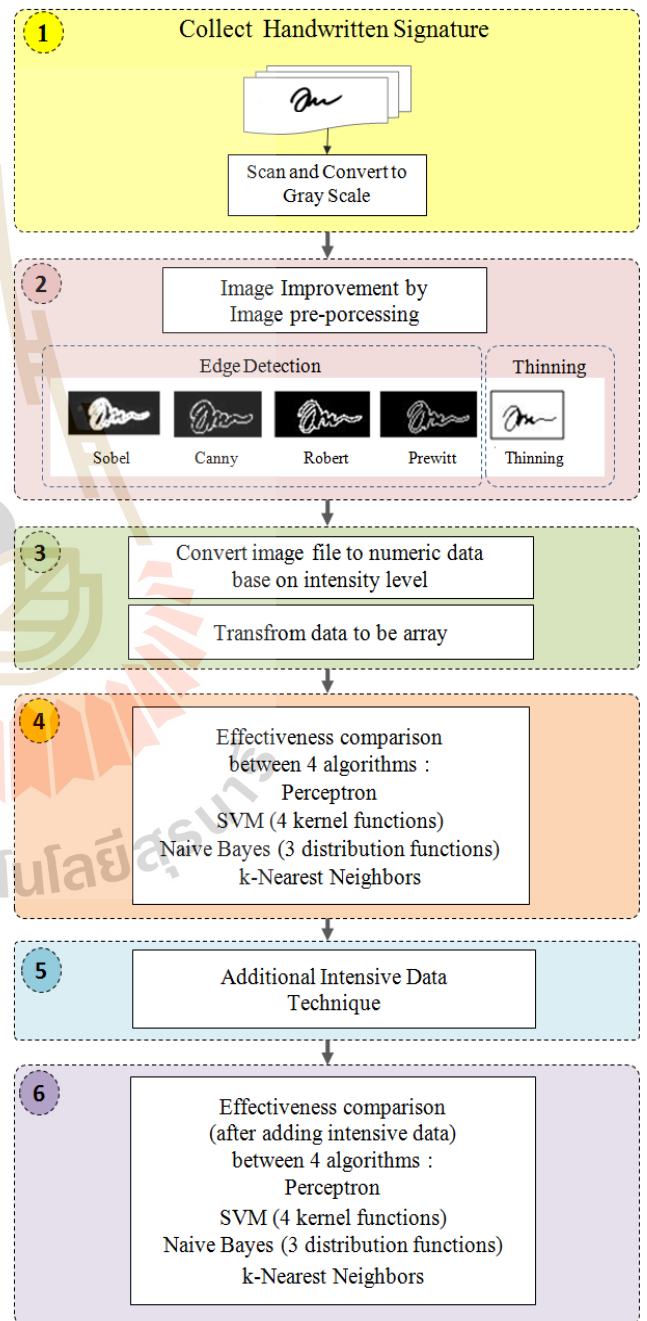


Fig. 7. Research framework

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 Hadjadj 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

An Empirical Study of Dimensionality Reduction Methods for Biometric Recognition

Nittaya Kerdprasop, Ratiporn Chanklan, Anusara Hirunyanakul, Kittisak Kerdprasop
Data Engineering and Knowledge Engineering Research Units,
School of Computer Engineering, Suranaree University of Technology, Thailand
e-mail: nittaya@sut.ac.th

Abstract—This research aims at studying the recognition accuracy and execution time that are affected by different dimensionality reduction methods applied to the biometric image data. We comparatively study the fingerprint, face images, and handwritten signature data that are pre-processed with the two statistical based dimensionality reduction methods: principal component analysis (PCA) and linear discriminant analysis (LDA). The algorithm that has been used to train and recognize the images is support vector machine with linear and polynomial kernel functions. Experimental results showed that the application of LDA dimensionality reduction method before recognizing the image patterns with a linear kernel function of SVM is more accurate and takes less time than the recognition that did not use dimensionality reduction. LDA is a suitable technique for physiological biometrics, whereas PCA is appropriate for the behavioral biometrics. We also found out that only 1% of transformed dimensions is adequate for the accurate recognition of biometric image patterns.

Keywords—dimensionality reduction; PCA; LDA; biometric recognition

I. INTRODUCTION

The term *biometrics* refers to the automatic recognition method for identifying and authenticating people based on the measurable characteristics and distinctive features of humans [4]. The measurement can be either physical, biological, behavioral, or a mixture of characteristics. Commonly used physiological biometrics are fingerprint, face image, hand geometry, vascular configuration of retina, iris pattern, and DNA [2], [8]. Unlike physiological biometrics that are based on body characteristics, behavioral biometrics are mostly based on muscle control and movement such as signature, keystroke, gait, and voice [1].

Biometric technologies have been commonly used for two main purposes: authentication and identification. Authentication (or verification) based on biometrics aims at verifying if the individual is the same person as the claimed identity, whereas biometric identification attempts to determine identity of an unknown individual. Biometric authentication requires a one-to-one matching of the biometric identifier against the stored biometrics (called templates), while identification is a one-to-many matching of an identity against the whole database [4]. Biometric identification thus takes more time than the authentication process.

Major issues concerning the practicality of biometric systems are reliability in terms of accuracy and security, efficiency in terms of speed and the ease of use, and acceptability from users [3], [4]. To increase recognition speed of a biometric system, many researchers have agreed upon the dimensionality approaches [5], [6], [7]. To reduce dimensions of the input feature space, feature selection and feature extraction are two practical techniques adopted by numerous recognition systems. Given the original set of input features, feature selection techniques choose a subset of most relevant features, but feature extraction techniques transform data into a lower dimensional space before the selection of discriminative features.

In this work, we are interested in reducing the matching time of authentication and identification processes at the preliminary stage of feature extraction and selection. We perform a comparative study of applying the principal component analysis (PCA) and the linear discriminant analysis (LDA) as feature extraction technique to reduce the dimensions of the biometric images. We compare the performance of PCA and LDA on both the physiological biometrics, using fingerprint and face images, and the behavioral biometrics using signature images. The recognition algorithm used in our work is support vector machine (SVM) with two different kinds of kernel: linear and polynomial kernel functions.

II. A STUDY FRAMEWORK

To perform a comparative study of statistical based dimensionality reduction methods over physiological and behavioral biometric images, we use three kinds of biometric traits: fingerprint, face, and signature (shown in Figure 1). Scanned images of fingerprint biometric are from <http://fvs.sourceforge.net/download.html>. This data set contains 168 fingerprint images of 21 different fingers. Each finger has 8 images. Resolution of the image is 80×80 pixels, thus comprising total features of 6400 pixels.

Face images are another set of physiological biometric data used in this study. This data set, formerly known as ORL database, is freely available for download at <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>. It contains 400

images of 40 people; 36 of them are male and 4 are female. Each person had been taken 10 images at different time with variety in details and face expressions. Resolution of each image is 64×64 pixels, comprising 4096 total pixels.

Behavioral biometrics used in this study is signature images collected by our research group. We asked 30 undergraduate students to sign on the paper 20 times. Then we scanned the images and cropped each image to be equal size of 38×144 pixels (4096 pixels in total). Our signature data set contains 600 signature images. The examples shown in Figure 1(c) are signatures of three different students.

The flow of our work (presented in Figure 2) can be explained as follows. In the data preparation phase, we convert images into the data array form. This format is required by the python program used in our analysis.

We then apply the PCA and LDA dimensionality reduction techniques. The transformed data are split into training set (around 75%) and test set (the rest 25%). During the recognition phase, the training data set is used to train the SVM classifier.

III. EXPERIMENTAL RESULTS

In this comparative study, we evaluate the recognition performance of two different kernels: linear and polynomial kernel functions. The test data set has been applied to test the SVM classification model for its accuracy. Evaluation metric used in our comparative study is the classification accuracy (or the recognition rate). We also compare the dimensionality reduction and training time of each technique.

The accuracy (or recognition rates) and running time of fingerprint, face, and signature images are illustrated in Figure 3. The time and accuracy are obtained from four different combinations of dimensionality reduction methods and kernel functions. These combinations are: (1) LDA with linear SVM, (2) LDA with polynomial SVM, (3) PCA with linear SVM, and (4) PCA with polynomial SVM.

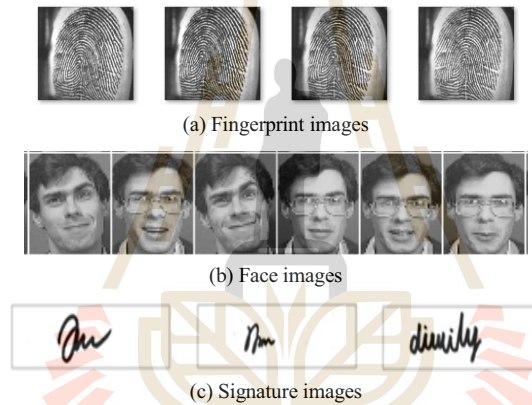


Figure 1. Examples of images used in our comparative study.

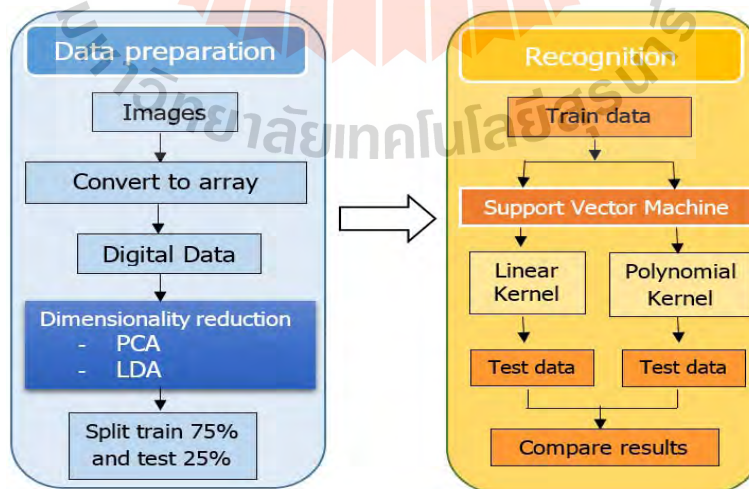





Figure 2. A framework of dimensionality reduction method comparison.



(a) Fingerprint images



(b) Face images



(c) Signature images

Figure 3. Recognition rate (left) and running time (right) comparisons of different combinations in dimensionality reduction techniques (PCA/LDA) in the data preparation phase and kernel functions (linear/polynomial) of support vector machine in the recognition phase.

IV. CONCLUSION

In this work, we propose that pattern matching to verify or identify biometric identity against the stored templates can be done faster and consumes less computational resources through the reduced feature vectors. We thus present comparative study results of the two statistical based dimensionality techniques applied over the physiological and behavioral biometric data. We applied the PCA and LDA to reduce the features of fingerprint, face images, and signature data. Pattern recognition algorithm used in our study is SVM with linear and polynomial kernel functions.

The study results revealed that only a very small number of features (around 1%) was sufficient for accurate recognition over fingerprint, face, and signature images. We also found that LDA is an appropriate technique to be applied to the physiological biometrics such as fingerprint and face images. For behavioral biometrics such as signatures that are varied from individual to individual, PCA gives a better result in terms of accuracy. We are interested in this characteristic of PCA and plan to further investigate its characteristic on other behavioral biometrics.

ACKNOWLEDGMENT

This work has been supported by grants from the National Research Council of Thailand (NRCT) and Suranaree University of Technology.

REFERENCES

- [1] G. Bailador, C. Sanchez-Avila, J. Guerra-Casanova, and A. de Santos Sierra, "Analysis of pattern recognition techniques for in-air signature biometrics," *Pattern Recognition*, vol. 44, pp. 2468–2478, October–November 2011.
- [2] K. Delac and M. Grgic, "A survey of biometric recognition methods," *Proc. 46th Int. Symp. Electronics in Marines, Croatia*, pp. 184–193, 2004.
- [3] R. Giot, M. El-Abed, and C. Rosenberger, "Fast computation of the performance evaluation of biometric systems: application to multibiometrics," *Future Generation Computer Systems*, vol. 29, pp. 788–799, 2013.
- [4] A. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 4–20, 2004.
- [5] A. Martinez and A. Kak, "PCA versus LDA," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, no. 2, pp. 228–233, 2001.
- [6] J. Mazanec, M. Melisek, M. Oravec, and J. Pavlovicova, "Support vector machines, PCA, and LDA in face recognition," *Journal of Electrical Engineering*, vol. 59, no. 4, pp. 203–209, 2008.
- [7] K. Sodhi and M. Lal, "Face recognition using PCA, LDA and various distance classifiers," *Journal of Global Research in Computer Science*, vol. 4, no. 3, pp. 30–35, 2013.
- [8] J. Unar, W. Seng, and A. Abbasi, "A review of biometric technology along with trends and prospects," *Pattern Recognition*, vol. 47, pp. 2673–2688, 2014.



ภาคผนวก ข

ลิขสิทธิ์โปรแกรม

โปรแกรมรู้จำภาพถ่ายลายมือชื่อ

(Handwritten signature image recognition program)



ชื่อภาษาไทย	โปรแกรมรู้จำภาพลายมือชื่อ
ชื่อภาษาอังกฤษ	Handwritten signature image recognition program
ทะเบียนข้อมูลเลขที่	ว1. 5362
ให้ไว้ ณ วันที่	8 เมษายน พ.ศ. 2558
คำอธิบายโปรแกรมโดยย่อ	<p>โปรแกรมรู้จำภาพลายมือชื่อนี้พัฒนาด้วยภาษาไพธอน (Python) และแมทแล็บ (MATLAB) โดยได้มีการนำเสนอเทคนิคใหม่เพื่อการเพิ่มประสิทธิภาพในการรู้จำภาพลายมือชื่อ แหล่งข้อมูลลายมือชื่อเป็นภาพลายเซ็นจากการเก็บข้อมูลจริง จำนวนทั้งสิ้น 600 ภาพ จากบุคคลทั้งหมด 30 คน โดยแต่ละลายมือชื่อจะถูกแปลงเป็นไฟล์ภาพและทำให้มีขนาด 38x144 พิกเซลเท่ากันทั้งหมด จากนั้นทุก ๆ พิกเซลในแต่ละภาพจะถูกแปลงค่าเป็นค่าความเข้มจาก 0 ถึง 255 โดย 0 คือค่าความเข้มที่มากที่สุด หรือสีดำ ส่วนค่า 255 หมายถึงสีขาว ภาพลายมือชื่อเหล่านี้จะถูกนำไปฝึกการรู้จำด้วยอัลกอริทึม 4 แบบ ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (ด้วยเคอร์เนลฟังก์ชันเชิงเส้น พหุนาม เรเดียลเบสิส และ ซิกมอยด์) เคเนียร์สเนเบอร์ เพอร์เซปตรอน และนาอีฟเบย์ (ด้วยฟังก์ชันการกระจายข้อมูลแบบ เกาเซียน มัลติโนเมียล และ เบอร์นูลลี)</p> <p>จากนั้นจะใช้เทคนิคการประมวลผลภาพเข้ามาช่วยเพิ่มความแม่นยำในการรู้จำ เทคนิคที่ใช้ได้แก่วิธีการตรวจหาขอบภาพทั้ง 4 แบบคือ โซเบลพรีวิต โรเบิร์ต และแคนนี่ รวมถึงการทำขอบภาพให้บาง จากนั้นผู้พัฒนาได้เพิ่มเทคนิคใหม่ ด้วยการเพิ่มข้อมูลที่มีค่าความเข้มสีระดับสูงเข้าไปต่อท้ายชุดข้อมูลเดิม เป็นขั้นตอนต่อจากการทำขอบแบบโซเบล และด้วยวิธีการเพิ่มข้อมูลนี้เองทำให้ค่าความแม่นยำของอัลกอริทึมส่วนใหญ่สูงขึ้นโดยเฉพาะอย่างยิ่งอัลกอริทึมเคเนียร์สเนเบอร์ เมื่อ $k=1$ และ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนเคอร์เนลฟังก์ชันเชิงเส้น</p>


 รลช.01 ทะเบียนข้อมูลเลขที่ ว1. 5362

**หนังสือรับรองการแจ้งข้อมูล
ลิขสิทธิ์**
ออกให้เพื่อแสดงว่า
มหาวิทยาลัยเทคโนโลยีสุรนารี

ได้แจ้งข้อมูลลิขสิทธิ์ ประเภทงาน **วรรณกรรม**
 ลักษณะงาน **โปรแกรมคอมพิวเตอร์**
 ชื่อผลงาน **โปรแกรมรู้จำภาพลายมือชื่อ**
 วัตถุประสงค์ **ทรัพย์สินทางปัญญา** ตามคำขอแจ้งข้อมูลลิขสิทธิ์ เลขที่ **322087**
 เมื่อวันที่ **1 เดือน เมษายน พ.ศ. 2558**

ให้ไว้ ณ วันที่ 8 เดือน เมษายน พ.ศ. 2558

ลงชื่อ.....
 นางสาวศิริวรรณ นพรัถ
 นักวิชาการพาณิชย์ปฏิบัติการ
 ปฏิบัติราชการแทนผู้อำนวยการสำนักลิขสิทธิ์

หมายเหตุ 1. เอกสารนี้มีได้รับรองความเป็นเจ้าของลิขสิทธิ์
 2. การเปลี่ยนแปลงรายการข้างต้น ให้ดูด้านหลัง

ประวัติผู้วิจัย

รองศาสตราจารย์ ดร.กิตติศักดิ์ เกิดประสพ สำเร็จการศึกษาในระดับปริญญาเอกสาขา Computer Science จาก Nova Southeastern University เมือง Fort Lauderdale รัฐฟลอริดา สหรัฐอเมริกา เมื่อปีพุทธศักราช 2542 (ค.ศ. 1999) ด้วยทุนการศึกษาของทบวงมหาวิทยาลัย (หรือชื่อใหม่ในปัจจุบันคือ กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม) หลังสำเร็จการศึกษาได้ปฏิบัติงานในตำแหน่งอาจารย์ ประจำสาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชา วิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ปัจจุบันดำรงตำแหน่งหัวหน้าหน่วยวิจัยวิศวกรรม ความรู้ เน้นการวิจัยเกี่ยวกับการพัฒนาระบบเหมืองข้อมูลประสิทธิภาพสูง การประยุกต์เหมืองข้อมูล กับงานวิศวกรรม และการวิเคราะห์ข้อมูลเชิงสถิติ รวมถึงการวิจัยพื้นฐานเกี่ยวกับเทคนิคการวิเคราะห์ ข้อมูลโดยวิธีอัตโนมัติ โดยมีผลงานวิจัยในด้านฐานข้อมูล การวิเคราะห์ข้อมูล การทำเหมืองข้อมูล และการค้นหาความรู้ ตีพิมพ์ในวารสารวิชาการและเอกสารการประชุมวิชาการทั้งระดับชาติและ นานาชาติจำนวนมากกว่า 300 เรื่อง

รองศาสตราจารย์ ดร.นิตยา เกิดประสพ สำเร็จการศึกษาในระดับปริญญาเอกสาขา Computer Science จาก Nova Southeastern University เมือง Fort Lauderdale รัฐฟลอริดา สหรัฐอเมริกา เมื่อปีพุทธศักราช 2542 (ค.ศ. 1999) ด้วยทุนการศึกษาของกระทรวงวิทยาศาสตร์ และเทคโนโลยี (หรือชื่อใหม่ในปัจจุบันคือ กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม) หลังสำเร็จการศึกษาได้ปฏิบัติราชการในตำแหน่งอาจารย์ ประจำสาขาคอมพิวเตอร์ ภาควิชา คณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ต่อมาในปีพุทธศักราช 2543 ได้มา ปฏิบัติงานในตำแหน่งอาจารย์ประจำสาขาวิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จนถึงปัจจุบัน งานวิจัยที่ทำในขณะนี้คือการประยุกต์เทคโนโลยีเหมืองข้อมูลกับงานด้านการแพทย์ การสาธารณสุขและสิ่งแวดล้อม รวมถึงการพัฒนาเทคนิคเพื่อเพิ่มความสามารถในการจัดการความรู้ ของระบบเหมืองข้อมูล