

โครงการวิจัยย่อยลำดับที่ 21
เรื่อง ระบบจำแนกแบบหลายตัวโดยกรรมวิธีการเข้ารหัสช่องสัญญาณและฐานหลักdiscriminative
มีแนบเฉพาะที่เสถียร ปีที่ 2

Multiple Classifier Systems using Channel Coding and Invariant Local Discriminant Bases

ผู้รับผิดชอบโครงการ อาจารย์ ดร.วิทยากร อัครศรีวิเศษ
หน่วยวิจัยกรรมวิธีสัญญาณดิจิทัล ภาควิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
E-Mail : widhyakorn.a@chula.ac.th

ระยะเวลาดำเนินการ 12 เดือน (1 กันยายน พ.ศ. 2549 – 31 สิงหาคม พ.ศ. 2550)

บทที่ 1
บทนำ

1.1 ความเป็นมาและเหตุผล

โดยทั่วไป ปัญหาในการรู้จำเป้าหมายอัตโนมัติ (Automatic Target Recognition: ATR) ประกอบด้วย การตรวจจับ (detecting) และการบ่งชี้ (identifying) และการประมาณค่าพารามิเตอร์ของเป้าหมายในภาพอากาศบริเวณ (scene) โดยการใส่เซ็นเซอร์เพียงตัวเดียวหรือหลายตัว โดยที่เราสามารถตั้งสมมติฐานได้ว่าเป้าหมายได้ถูกตรวจจับและตำแหน่งที่ตรวจจับในภาพอากาศบริเวณภาพได้ถูกทราบแล้ว การรู้จำเป้าหมายของเรดาร์แบบช่องเปิดสังเคราะห์ (Synthetic Aperture Radar: SAR) นั้น หมายถึงเป้าหมายได้ถูกจัดกรอปจากภาพอากาศบริเวณของ SAR แล้ว ภาพ SAR นั้นค่อนข้างอ่อนไหวต่อมุมการหมุนของเป้าหมาย เหตุผลที่สำคัญของลักษณะแตกต่าง (variability) อย่างมากมายของแต่ละภาพเป้าหมาย SAR ประกอบด้วย ผลของเงา การที่เป้าหมายมีผลต่อสิ่งแวดล้อม เช่น Clutter การฉาย (projection) ของภาพอากาศบริเวณสามมิติไปบนระนาบ slant รวมทั้งลักษณะแตกต่างของสัญญาณเรดาร์เชิงซ้อนที่เกิดจากการรวมเชิงโคฮีเรนต์ของสัญญาณสะท้อนกลับจากตัวกระจาย (scatter) เมื่อเป้าหมายมีการเคลื่อนที่เป็นระยะห่างสัมพัทธ์ต่ออันดับ (order) ของความยาวคลื่นของสัญญาณส่ง (target speckle)

นอกจากนี้ภาพ SAR ของเป้าหมายที่ได้จากภาพอากาศบริเวณมีมิติขนาดใหญ่ ในขณะที่เดียวกันจำนวนภาพตัวอย่างที่ได้จะมีขนาดน้อย จะเห็นได้ว่าปัญหาในการรู้จำเป้าหมาย

อัตโนมัติเป็นปัญหาในการรู้จำรูปแบบที่ท้าทายเป็นอย่างมาก องค์ความรู้ที่ได้จากการรู้จำเป้าหมายอัตโนมัติสามารถนำมาใช้กับปัญหาการรู้จำรูปแบบต่าง เช่น การรู้จำใบหน้าที่เป็นอยู่ในการป้องกันประเทศ ทั้งในการตรวจสอบหนังสือเดินทาง การเดินทางทางเครื่องบิน และการทำเหมืองข้อมูล (data mining) เป็นต้น

ในทางปฏิบัติเราสามารถสร้างตัวจำแนกเป้าหมายอัตโนมัติให้ทำการตัดสินใจชนิดของเป้าหมายได้หลายวิธี ตัวอย่างเช่น การสร้างตัวจำแนกให้เสถียรต่อการหมุนและลักษณะแตกต่างของเป้าหมาย หรือ โดยการสกัดลักษณะบ่งต่าง (features) ที่มีความเสถียรต่อการหมุนของเป้าหมายในภาพอาณาบริเวณ และสัญญาณรบกวน หรือ การประมาณค่ามุมการหมุนของเป้าหมายในภาพอาณาบริเวณ

การสร้างตัวจำแนกที่กำลังในการแยกแยะเป้าหมายโดยไม่คำนึงถึงมุมการหมุนของเป้าหมายมี ข้อดีคือ เป็นการทำการรู้จำกับพิกเซลดิบ (raw pixel) ของภาพเป้าหมาย จึงไม่มีข้อมูลที่สูญหาย แต่มีข้อเสียที่สำคัญคือ ภาพมีขนาดมิติใหญ่ มีจำนวนภาพในการฝึกฝนน้อย จะทำให้เกิดปัญหาการฝึกฝนเกิน (overtraining) หรือ การจำ (memorizing) หรือ Curse of dimensionality ที่สามารถอธิบายได้โดยทฤษฎี Occam's razor ปัญหาสามารถแก้ไขได้โดยการใช้ระบบตัวจำแนกแบบหลายตัว (multiple classifier systems: MCS) อย่างไรก็ตามการใช้ MCS อาจยังไม่สามารถแก้ปัญหาได้ทั้งหมด เราสามารถเพิ่มประสิทธิภาพในการรู้จำให้เพิ่มขึ้นได้โดยการใช้การสกัดคุณลักษณะที่เสถียรต่อการหมุน

การสกัดคุณลักษณะที่เสถียรต่อการหมุนอาจสามารถแก้ปัญหา curse of dimensionality แต่ในปัจจุบันยังไม่สามารถแก้ปัญหาการรู้จำเป้าหมายอัตโนมัติได้ดีนัก แนวทางเลือกที่ดีอีกทางหนึ่งคือแบ่งการทำงานของระบบจำแนกออกเป็น 2 ส่วนตามแนวความคิด แบ่งแยกและปกครอง (divide and conquer) โดยที่ในส่วนแรกเราจะทำการประมาณมุมการหมุนก่อน และแยกการรู้จำให้ดำเนินการในแต่ละเซกเมนต์ของการหมุน ซึ่งจะช่วยให้ ขอบเขตการตัดสินใจ (boundary decision) มีโครงสร้างที่ง่าย

ไม่ว่าวิธีการรู้จำเป้าหมายอัตโนมัติที่เพิ่มประสิทธิภาพด้วยวิธีการใดๆตามวิธีข้างต้น การรู้จำเป้าหมายอัตโนมัติจำเป็นต้องมีการสกัดคุณลักษณะโดยผลการแปลง (transform) เพื่อให้ได้ระบบพิกัด (coordinate system) ที่เหมาะสมสำหรับการรู้จำ โดยปกติผลการแปลงอาจเป็นไปได้ทั้งแบบเชิงเส้น และไม่เป็นเชิงเส้นที่ใช้ การแปลงเชิงเส้นที่สำคัญ ได้แก่ การวิเคราะห์ส่วนประกอบหลักสำคัญ (Principal Component Analysis: PCA) หนึ่งการแปลง PCA ยังมีข้อเสียเปรียบซึ่งได้มีการแนะนำ การแปลงเชิงเส้น ชนิดอื่น เพื่อเพิ่มประสิทธิภาพการรู้จำ เช่น Linear Discriminant Analysis หรือ Local Discriminant Bases เป็นต้น อย่างไรก็ตามการแปลงที่กล่าวมาข้างต้น เป็นการแปลงที่ไม่ได้ให้ความสนใจต่อโครงสร้าง (structure) ของภาพเป้าหมาย

ในที่นี้เราจึงสนใจการแปลงระบบพิกัดสามารถสกัดคุณลักษณะที่ให้ความหมายทางโครงสร้างของเป้าหมาย ในที่นี้เราสนใจผลการแปลงที่เกี่ยวกับ PCA โดยการเพิ่มคุณสมบัติทางโครงสร้างให้กับผลการแปลง เช่น ผลการแปลง 2DPCA และกรรมวิธีที่ปรับปรุง

อย่าไรก็ตาม ผลการแปลงที่เรานำมาใช้เพื่อให้ต้านทานต่อการหมุนนั้น มีปัญหาในเชิงปฏิบัติค่อนข้างมาก เช่น ผลการแปลงฟูริเยร์-เมลลิน (Fourier-Mellin) หรือ ผลการแปลงเรดอน (Radon Transform) ซึ่งต้องมีการแปลงระบบพิกัดจาก Euclidian ไปเป็นพิกัดขั้ว ซึ่งจะทำให้มีการแปรปรวนแบบไม่ยูนิฟอร์ม ทำให้ค่าบ่งชี้ที่พิกเซลที่ใกล้ศูนย์กลางเกิดค่าผิดพลาดในการเสถียรต่อการหมุนมากกว่าค่าที่คำนวณได้จากพิกเซลที่อยู่ใกล้ศูนย์กลางของภาพ ทำให้การวิจัยในส่วนของการแปลงเฉพาะที่เสถียรไม่สามารถดำเนินการได้สำเร็จตามเป้าหมาย แต่การศึกษาในส่วนของการเข้ารหัสช่องสัญญาณยังคงสามารถดำเนินการได้ตามเป้าหมาย โดยอาศัยการเข้ารหัสสัญญาณโดยใช้รหัสสุ่ม (random code) ซึ่งดำเนินการกรรมวิธีของ คณาจักรกล ชนิดระเบียบวิธีปริภูมิย่อยสุ่ม (random subspace method)

ในบทที่ 2 เราจะแนะนำระบบจำแนกแบบหลายตัว หรือ คณาจักรกล ที่สร้างบนฐานของการเข้ารหัส ชนิดสุ่ม ในบทที่ 3 เราจะพิจารณาและนำเสนอการแปลงเชิงเส้นที่ให้ความสนใจต่อโครงสร้างของภาพเป้าหมายและแก้ปัญหาเดิมของผลการแปลง PCA โดยเสนอผลการแปลง 2DPCA ชนิดใหม่ การทดสอบการแปลงเชิงเส้นที่นำเสนอขึ้นกับฐานข้อมูลใบหน้าหลายชนิดได้แสดงให้เห็นถึงการปรับปรุงประสิทธิภาพในการรู้จำที่ดีขึ้น และผลการแปลงชนิดนี้สามารถปรับปรุงให้ทำงานร่วมกับการเข้ารหัสแบบส่งซ้ำ ตามกรรมวิธีคณาจักรกล แบบระเบียบวิธีปริภูมิย่อยสุ่ม (random subspace method) ได้ดี บทที่ 4 กล่าวถึงงานที่ได้ทำและที่จะดำเนินต่อไปในอนาคต รวมทั้งสรุป

1.2 วัตถุประสงค์ของโครงการวิจัย

- 1.2.1 เพื่อศึกษาความเป็นไปได้ในการกำหนดระบบจำแนกแบบหลายตัว (multiple classifier systems: MCS) ที่มีนัยทั่วไปบนฐานของการใช้การเข้ารหัสช่องสัญญาณ ฐานหลักดิสคริมิแนนต์เฉพาะที่เสถียร
- 1.2.2 เพื่อศึกษาผลการแปลงเชิงเส้นที่มีประสิทธิภาพกว่า ผลการแปลง PCA และ 2DPCA
- 1.2.3 เพื่อศึกษาความสัมพันธ์ของการขยายระบบจำแนกแบบหลายตัวที่มีนัยทั่วไปกับระบบจำแนกหลายตัวแบบอื่นๆ เพื่อสร้างแบบแผนการรวม (combining scheme) และกลุ่มระบบพิกัด (coordinate system ensemble) ที่มีประสิทธิภาพ

1.3 ขอบเขตของโครงการวิจัย

- 1.3.1 ศึกษาการประยุกต์ใช้การแปลงขั้ว (polar) และ แรดอน (radon transform) สำหรับฐานหลักดิสคริมิแนนต์ เพื่อใช้สร้างระบบพิกัดเสถียรสำหรับระบบจำแนกแบบหลายตัว
- 1.3.2 ทดสอบการประยุกต์ใช้และนัยทั่วไปของผลการแปลงที่มีประสิทธิภาพเช่น 2DPCA หรือผลการแปลงอื่นที่เกี่ยวข้อง โดยการประยุกต์ใช้ร่วมกับระบบรู้จำแบบหลายตัวโดยกรรมวิธีการเข้ารหัสช่องสัญญาณที่มีประสิทธิภาพ
- 1.3.3 เปรียบเทียบระบบจำแนกแบบหลายตัวที่พัฒนาขึ้นเพื่อเปรียบเทียบกับระบบจำแนกแบบหลายตัวที่ทันสมัยอื่นๆ



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 2

ระบบจำแนกแบบหลายตัวโดยวิธีการเข้ารหัสช่องสัญญาณ และฐานหลักdiscriminative แนนต์ เฉพาะที่เสถียรในการประยุกต์ใช้งานในการรู้จำเป้าหมายอัตโนมัติ

Multiple Classifier Systems using Channel Coding and Invariant Local Discriminant Bases for Automatic Target Recognition

2.1. บทนำ

ในรอบหลายปีที่ผ่านมา *คณาจักรกล* (committee machine) หรือ วงหรือชุดของตัวประมาณ ได้พิสูจน์ว่าให้ผลการทำนายที่แม่นยำกว่าใช้ตัวประมาณเพียงตัวเดียว แนวความคิดพื้นฐานของ คณาจักรกล คือการฝึกฝนคณะของตัวจำแนกและรวมการประมาณของตัวประมาณแต่ละตัวเข้าด้วยกัน เพื่อเพิ่มสมรรถนะของนายทั่วไป สมมติฐานหนึ่งของ คณาจักรกล คือ การที่ตัวประมาณแต่ละตัวควรเป็นอิสระต่อกัน ด้วยเหตุผลที่ว่าความผิดพลาดของการประมาณของตัวประมาณแต่ละตัวควรจะไม่มีความสัมพันธ์ (correlation) ต่อกันและกันสูงมากนัก ซึ่งจะทำให้การรวมการประมาณของตัวจำแนกหลายตัวสามารถขจัดความผิดพลาดออกไปได้ดี

ปัจจุบันนี้ นักวิจัยได้มีการนำ คณาจักรกล มาใช้ในงานหลายชนิด เช่น ใช้ในการเฉลี่ยแบบจำลองทั้งชุด (ensemble-averaging model) ที่สร้างด้วยข่ายวงจรประสาทเพื่อใช้ในการวิเคราะห์ทางการเงิน การรู้จำตัวอักษรด้วยการใช้ แบกกิง (bagging) บูสทีง (boosting) และชุดของข่ายวงจรประสาท การใช้ข่ายเกทตั้งในการทำชัด (deblur) และการรู้จำใบหน้า

โดยปกติโครงสร้างของ คณาจักรกล นั้นสามารถแบ่งตามโครงสร้างออกได้เป็น 2 แบบ คือ แบบสถิต (static) และ แบบจลน์ (dynamic) ในทำนองเดียวกัน คณาจักรกล ก็สามารถแบ่งตามกระบวนการเล็งเลศออกได้เป็น 2 แบบ คือ การครอบคลุมที่เหมาะสมที่สุด (coverage optimization) และ การทำนายที่เหมาะสมที่สุด (prediction optimization)

2.1.1. คณาจักรกลแบ่งตามโครงสร้าง

2.1.1.1. โครงสร้างแบบสถิต

เป็นกระบวนการสร้าง คณาจักรกล ที่เกิดจากการใช้ ตัวจำแนกต่างชนิด หรือ การเข้าถึงตัวสกัดคุณลักษณะ (feature) ที่แตกต่างกันของตัวจำแนกชนิดเดียวกัน หรือ การฝึกฝนตัวจำแนกชนิดเดียวกันด้วยชุดฝึกฝนที่ต่างกัน (different training set) การฝึกฝนตัวจำแนกที่มีการป้อนสัญญาณรบกวนให้แต่ละตัวจำแนก

ตัวอย่างของ คณาจักรกล ที่มีโครงสร้างแบบสถิตนี้ได้แก่ การสร้างข่ายวงจรประสาทที่มีค่าเริ่มต้นของค่าถ่วงน้ำหนักที่ต่างกัน (different

initialization weights) การทำการสุ่มซ้ำ (resampling) ชุดฝึกฝน เทคนิคนี้ถูกเรียกอีกอย่างหนึ่งว่า **แบกกิ่ง (Bagging)** และเทคนิคการสุ่มซ้ำทางสถิติโดยที่ตัวอย่าง (sample) แต่ละตัวของชุดฝึกฝนที่ถูกเลือกมาใช้ในการฝึกตัวจำแนกในปัจจุบัน จะขึ้นอยู่กับสมรรถนะของตัวจำแนกที่ถูกสร้างขึ้นก่อนหน้านี้ เทคนิคนี้ถูกเรียกอีกอย่างหนึ่งว่า **บูสท์ทิง (Boosting)**

2.1.1.2. โครงสร้างแบบจลน์

เป็นกระบวนการสร้าง คณาจักรกล ที่เกี่ยวข้องโดยตรงกับอินพุท ในกระบวนการรวม (combining) เทคนิคของการสร้างตัวจำแนกแบบหลายตัวนี้ รู้จักกันดีในอีกชื่อหนึ่ง คือ การรวมผสมผู้เชี่ยวชาญ (mixture of experts) โดยที่เอาท์พุทของตัวจำแนกตัวหนึ่งตัวใดจะถูกส่งผ่านโดยข่ายเกทตึง ที่จริงเกทตึงจะเป็นตัวตัดสินว่าผู้เชี่ยวชาญตัวใดที่เกี่ยวข้องกับชุดย่อย (subsets) ที่แตกต่างกันของปริภูมิอินพุท (input space) ในที่นี้ผู้เชี่ยวชาญและข่ายเกทตึงอาจเป็นข่ายวงจรประสาทก็ได้

2.1.2. คณาจักรกลแบ่งตามกระบวนการเล็งเลิศ

คณาจักรกล ที่จริงประกอบด้วย ชุดของตัวจำแนก และ กระบวนการในการรวบรวมการตัดสินใจของกลุ่มของตัวจำแนก โดยปกติ คณาจักรกลที่ได้รับความนิยม จะมีลักษณะแบบขนานซึ่งสามารถแบ่งออกได้ เป็น 2 แบบ คือ

1. ให้มีการรวบรวมการทำนายที่มีการกำหนดไว้ก่อน แต่เน้นที่การสร้างตัวจำแนกให้มีความหลากหลายเพื่อให้ผลของการจำแนกมีความถูกต้องแม่นยำที่สุด
2. ออกแบบและสร้างตัวจำแนกจำนวนหนึ่ง แต่เน้นที่การรวมการตัดสินใจของชุดของตัวจำแนก

2.1.2.1. การครอบคลุมที่เหมาะสมที่สุด (coverage optimization)

คณาจักรกล แบบที่ 1 ที่กล่าวถึงก่อนหน้านี้ สามารถเรียกอีกชื่อหนึ่งว่า **วิธีการครอบคลุมที่เหมาะสมที่สุด (coverage optimization method)** ซึ่งกรรมวิธีย่อยต่างๆ ที่อยู่ในการแบ่งแยกแบบนี้ ได้แสดงไว้ในตารางที่ 1 ดังต่อไปนี้

2.1.2.2. การทำนายที่เหมาะสมที่สุด (prediction optimization)

คณาจักรกล แบบที่ 2 ที่กล่าวถึงก่อนหน้านี้ สามารถเรียกอีกชื่อหนึ่งว่า *วิธีการทำนายที่เหมาะสมที่สุด* (prediction optimization method) ซึ่งกรรมวิธีย่อยต่างๆ ที่อยู่ในการแบ่งแยกแบบนี้ ได้แสดงไว้ในตารางที่ 2 ดังต่อไปนี้

ในงานวิจัยปีที่ 1 เน้นวิธีแบบขนานตามรูปแบบของวิธีการครอบคลุมที่เหมาะสมที่สุด โดยผสม คณาจักรกล จำนวน 3 แบบ เพื่อสร้าง คณาจักรกลแบบใหม่ คณาจักรกล สามแบบ ที่นำมาพิจารณา ได้แก่ วิธี Adaboost วิธีรหัสแก้ไขผิดพลาดเอชท์พุด และ วิธีที่ใช้ชุดการฝึกฝนหลายชุด (multiple training sets) นอกจากนั้นเรายังสนใจ คณาจักรกล ตามกรรมวิธีการเข้ารหัสต่อกัน

ในงานวิจัยในปีที่ 2 นี้ เราได้ศึกษากรรมวิธีที่มีประสิทธิภาพมากกว่างานวิจัยในปีที่ 1 คือ การสร้างคณาจักรกล ตามกรรมวิธีการเข้ารหัสช่องสัญญาณแบบส่งซ้ำ (โดยการปรับปรุง ระเบียบวิธีปริภูมิสุ่ม (random subspace method: RSA)) ซึ่งสามารถทำงานร่วมกับผลการแปลง 2DPCA ได้อย่างมีประสิทธิภาพ โดยกรรมวิธีที่เราได้พัฒนาในงานวิจัยนี้ เรียกว่า 2DRSA

ตาราง 1 วิธี coverage optimization

Method	Training mechanism for introducing complementariness	Physical level
noise injection	inject noise to the training set	input
stacking	train classifiers by nonoverlapping subsamples of training set	input distribution \mathcal{D}
bagging	resample the training set by bootstrap replicates	input distribution \mathcal{D}
boosting	resample the training set by weights evolving with accuracy	input distribution \mathcal{D}
random subspace	project training set to random chosen subspaces	input representation
stochastic discrimination	generate random kernels to measure coverage of training set	classifier
perturbation	vary initial conditions or parameters of training process	classifier
error correction output coding	force training on partial decision boundaries	output
multiple feature sets	train classifiers using different feature subsets	input representation

ตาราง 2 วิธี prediction optimization

Trainable	binary or one of N decisions	ranked lists of classes	continuous prob. estimates or belief scores
No	majority	order statistics	sum, product rules
Yes	weighted vote	logistic regression	Bayes rules

2.2. การเข้ารหัสของสัญญาณแบบส่งซ้ำและระเบียบวิธีปริภูมิแบบสุ่ม

ระเบียบวิธีปริภูมิแบบสุ่ม (random subspace method: RSM) เป็นระเบียบวิธีหนึ่งที่ใช้ในระบบจำแนกแบบหลายตัว (multiple classifier systems: MCS) ซึ่งสามารถสร้างตัวจำแนกได้หลายตัวโดยการสุ่มเลือกพิกัด หรือ ปริภูมิจำนวนหนึ่งจากปริภูมิที่มีอยู่ทั้งหมด เช่น เราสามารถสุ่มเลือกจำนวนปริภูมิ เพียง 10 เปรอร์เซ็นต์ ของปริภูมิทั้งหมดของตัวบ่งต่าง (feature) เมื่อเราทำการสุ่มแบบส่งคืนในแต่ละครั้งเราจะได้ตัวจำแนกหนึ่งตัว ซึ่งได้การตัดสินใจของตัวจำแนกแต่ละตัวเป็นตัวแปรสุ่ม (random variable) ที่มีผลของการตัดสินใจกระจายแบบอิสระและเหมือนกัน (independent and identically distribution: iid) จากนั้นเราจะนำตัวจำแนกแต่ละตัวที่สร้างจากการสุ่มปริภูมิของ ตัวบ่งต่าง มาทำการลงคะแนน (vote) ในการลงคะแนนเราอาจสามารถพิจารณาว่าเสมือนเป็นการส่งสัญญาณที่มีลักษณะเหมือนกันไปในช่องสัญญาณที่ต่างความถี่กัน โดยมีลดคาบของบิตข้อมูลให้มีค่าน้อยลง อย่างไรก็ตามการลงคะแนนจะทำให้การตัดสินใจบิตข้อมูลมีความถูกต้องมากขึ้น การส่งสัญญาณในช่องสัญญาณในลักษณะนี้สามารถเปรียบได้กับการเข้ารหัสของสัญญาณแบบส่งซ้ำ (repetition code) ดังนั้นการใช้ RSM กับการจำแนกใบหน้าและเป้าหมายอัตโนมัติ จึงเป็นการศึกษาวิจัยการสร้าง คนาจักรกล โดยอาศัยการเข้ารหัสของสัญญาณแบบหนึ่ง โดยในที่นี้เป็นการเข้ารหัสสัญญาณแบบส่งซ้ำนั่นเอง ในบทต่อไปจะกล่าวถึงผลการแปลงแบบ 2DPCA และส่วนขยาย รวมถึงการประยุกต์ใช้ ระเบียบวิธี RSM เพื่อพัฒนาระเบียบวิธีใหม่ที่เรียกว่า (two-dimensional random subspace analysis: 2DRSA)

จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 3

การรู้จำใบหน้าและเป้าหมายอัตโนมัติโดยวิธีการวิเคราะห์ส่วนประกอบमुखสำคัญแบบ สองมิติและส่วนขยาย

Face and Automatic Target Recognitions using Two-Dimensional Principal Component Analysis and Its variants

3.1. บทนำ

การวิเคราะห์ส่วนประกอบमुखสำคัญ (principal component analysis: PCA) เกี่ยวข้องกับสถิติอันดับที่สองของภาพอินพุท และการหาการพรรณนา (reconstruction) ที่มีค่าเหมาะสมที่สุดโดยการหาค่าผิดพลาดของการพรรณนาที่น้อยที่สุดตามกระบวนการหาค่ากำลังสองต่ำสุด (least square) ค่าเวกเตอร์เจาะจง (eigenvector) ที่คำนวณจากเมตริกซ์โควาเรียนซ์ของใบหน้า ก็คือ ค่าเจาะจงใบหน้า นั่นเอง ขนาดมิติของปริภูมิคุณลักษณะของใบหน้า (face feature space) สามารถลดให้มีขนาดเล็กลงได้โดยเลือก ไอเกนเวกเตอร์ เฉพาะที่มี ค่าเจาะจง (eigenvalue) มากที่สุด

เมื่อเราสามารถสร้างปริภูมิของใบหน้าได้แล้ว ใบหน้าของภาพที่จะถูกทดสอบจะถูกฉาย (projection) ไปบนปริภูมิใบหน้าเพื่อให้ได้เวกเตอร์คุณลักษณะซึ่งก็คือ ค่าสัมประสิทธิ์ของการพรรณนา (representation coefficients) ของปริภูมิใบหน้า ตัวจำแนกสามารถตัดสินใจเลือกคลาสของภาพอินพุท โดยเปรียบเทียบคะแนนความเหมือน (similarity score) ระหว่าง เวกเตอร์คุณลักษณะ ของภาพทดสอบ กับ ค่า เวกเตอร์คุณลักษณะ PCA ของแต่ละบุคคลที่อยู่ในฐานข้อมูล

ปัญหาหนึ่งของการประยุกต์ใช้ PCA ในการสกัดตัวบ่งต่าง เกิดจากการประมาณค่าที่ไม่แม่นยำของเมตริกซ์โควาเรียนซ์ ที่มีมิติขนาดใหญ่และมีจำนวนตัวอย่างน้อย เช่น ในการประยุกต์การรู้จำใบหน้า หรือ ที่รู้จักกันในชื่อ ว่า ขนาดจำนวนตัวอย่างน้อย (small sample size: SSS) หรือ คำสาปของมิติ (curse of dimensionality) ปัญหาหนึ่งที่สำคัญที่ทำให้การประมาณค่าเมตริกซ์โควาเรียนซ์ได้ไม่แม่นยำนั้น เกิดจากการใช้ sample mean มาแทนค่าเฉลี่ยที่แท้จริงปัญหาดังกล่าวนี้สามารถบรรเทาให้น้อยลงโดยอาศัยคุณสมบัติของใบหน้าที่มีความสัมพันธ์ค่อนข้างมากในบริเวณพิกเซลที่อยู่ใกล้เคียงกัน ด้วยเหตุนี้เราสามารถนิยามให้พิกเซลที่อยู่ใกล้เคียงกันสามารถร่วมใช้ เวกเตอร์เฉพาะ (eigenvector) ร่วมกันได้

3.2. การวิเคราะห์ส่วนประกอบमुखสำคัญแบบสองมิติ

เป็นที่ทราบกันดีแล้วว่า การสกัดคุณลักษณะที่ใช้ในการรู้จำภาพในด้านต่างๆ นั้นมีเทคนิคที่น่าสนใจได้แก่ Principal Component Analysis (PCA) มีการใช้กันอย่างแพร่ภาพในงานการรู้จำใบหน้าและเป้าหมายอัตโนมัติ (Face and Automatic Target Recognitions) ปัจจุบันมีการเสนอเทคนิค Two-Dimensional Principal Component Analysis (2DPCA) ซึ่งพัฒนามนหลักการของ PCA ซึ่งสามารถแก้ปัญหาดังกล่าวได้ โดยนิยาม เมตริกซ์ความแปรปรวนร่วมเกี่ยวขึ้นมาใหม่โดยไม่ต้องมีการแปลงรูปภาพจากสองมิติซึ่งเป็นเมตริกซ์ไปเป็นเวกเตอร์หนึ่งมิติ ทำให้เมตริกซ์ความแปรปรวนร่วมเกี่ยว (covariance matrix) ที่ได้มีขนาดเล็กลงและเต็ม ในที่นี้เราสามารถเรียก ปริภูมีย่อยของใบหน้า ที่สกัดด้วยวิธี 2DPCA อีกอย่างหนึ่งว่า “Principal Component Vector”

จากการศึกษาละเอียดวิธี 2DPCA เราสามารถจำแนก ส่วนขยายของ 2DPCA ออกได้เป็น

1. row-based 2DPCA
2. column-based 2DPCA
3. row-based diagonal 2DPCA
4. column-based diagonal 2DPCA

อนึ่งความสัมพันธ์ของ PCA กับ 2DPCA สามารถพิจารณาได้ดังต่อไปนี้ ให้ C และ G เป็นเมตริกซ์โควาเรียนซ์ของ PCA และ 2DPCA ตามลำดับ โดยที่

$$C = \frac{1}{N} \sum (x - \mu)(x - \mu)^T$$

x is the vectorized data with the size $mn \times 1$

และ

$$G = \frac{1}{N} \sum (X - \bar{X})^T (X - \bar{X})$$

X is the image with the size $m \times n$

อนึ่ง G เป็นเมตริกซ์โควาเรียนซ์ของ row-based 2DPCA ในขณะที่เดียวกัน หากให้ H เป็นเมตริกซ์โควาเรียนซ์ของ column-based 2DPCA เราจะเห็นได้ว่าเราสามารถหาความสัมพันธ์ของเมตริกซ์โควาเรียนซ์ระหว่าง PCA กับ 2DPCA ได้ดังนี้

$$\mathbf{G} = \frac{1}{N} \sum (\mathbf{X} - \bar{\mathbf{X}})^T (\mathbf{X} - \bar{\mathbf{X}})$$

Row-based 2DPCA
(Left computation)

$$\mathbf{H} = \frac{1}{N} \sum (\mathbf{X} - \bar{\mathbf{X}})(\mathbf{X} - \bar{\mathbf{X}})^T$$

Column-based 2DPCA
(Left computation)

Relation Equation between 1D and 2D covariance matrix

$$\mathbf{G}(i, j) = \sum_{k=1}^M \mathbf{C}(M(i-1) + k, M(j-1) + k)$$

เพื่อเป็นการง่ายในการอธิบาย เราสามารถพิจารณาได้จากตัวอย่างดังต่อไปนี้ โดยสมมติ
อย่างง่ายสูญเสียหน่วยสำคัญ ได้ว่า เรามีตัวอย่างในการเรียนรู้เพียงหนึ่งตัวอย่าง สำหรับหลาย
ตัวอย่างก็สามารถขยายได้โดยไม่มีข้อผิดพลาด

% โปรแกรม MATLAB แสดงการคำนวณ PCA, 2DPCA (row), 2DPCA (column), และ การรวมวีธีแปรผัน

>> syms a1 a2 a3 a4 a5 a6 a7 a8 a9 b1 b2 b3 b4 b5 b6 b7 b8 b9

>> A=[a1 a2 a3;a4 a5 a6;a7 a8 a9]

A =

[a1, a2, a3]

[a4, a5, a6]

[a7, a8, a9]

>> C=A(:)*A(:)' % conventional PCA

C =

[a1^2, a1*a4, a1*a7, a1*a2, a1*a5, a1*a8, a1*a3, a1*a6, a1*a9]

[a1*a4, a4^2, a4*a7, a4*a2, a4*a5, a4*a8, a4*a3, a4*a6, a4*a9]

[a1*a7, a4*a7, a7^2, a7*a2, a7*a5, a7*a8, a7*a3, a7*a6, a7*a9]

[a1*a2, a4*a2, a7*a2, a2^2, a2*a5, a2*a8, a2*a3, a2*a6, a2*a9]

[a1*a5, a4*a5, a7*a5, a2*a5, a5^2, a5*a8, a5*a3, a5*a6, a5*a9]

[a1*a8, a4*a8, a7*a8, a2*a8, a5*a8, a8^2, a8*a3, a8*a6, a8*a9]

[a1*a3, a4*a3, a7*a3, a2*a3, a5*a3, a8*a3, a3^2, a3*a6, a3*a9]

[a1*a6, a4*a6, a7*a6, a2*a6, a5*a6, a8*a6, a3*a6, a6^2, a6*a9]

[a1*a9, a4*a9, a7*a9, a2*a9, a5*a9, a8*a9, a3*a9, a6*a9, a9^2]

>> G1=A.*A % row-based 2DPCA

G1 =

[a1^2+a4^2+a7^2, a1*a2+a4*a5+a7*a8, a1*a3+a4*a6+a7*a9]

[a1*a2+a4*a5+a7*a8, a2^2+a5^2+a8^2, a2*a3+a5*a6+a8*a9]

[a1*a3+a4*a6+a7*a9, a2*a3+a5*a6+a8*a9, a3^2+a6^2+a9^2]

>> G2=A*A.' % column-based 2DPCA

G2 =

[a1^2+a2^2+a3^2, a1*a4+a2*a5+a3*a6, a1*a7+a2*a8+a3*a9]

[a1*a4+a2*a5+a3*a6, a4^2+a5^2+a6^2, a4*a7+a5*a8+a6*a9]

[a1*a7+a2*a8+a3*a9, a4*a7+a5*a8+a6*a9, a7^2+a8^2+a9^2]

>> DiagA = % construct diagonal matrix A.

[a1, a2, a3]

```

[a5, a6, a4]
[a9, a7, a8]

>> G3 = DiagA.*DiagA           % row-based diagonal PCA
G3 =
[ a1^2+a5^2+a9^2, a1*a2+a5*a6+a7*a9, a1*a3+a4*a5+a8*a9]
[ a1*a2+a5*a6+a7*a9, a2^2+a6^2+a7^2, a2*a3+a4*a6+a7*a8]
[ a1*a3+a4*a5+a8*a9, a2*a3+a4*a6+a7*a8, a3^2+a4^2+a8^2]

>> G4 = DiagA*DiagA.'         % column-based diagonal PCA
[ a1^2+a2^2+a3^2, a1*a5+a2*a6+a4*a3, a1*a9+a7*a2+a8*a3]
[ a1*a5+a2*a6+a4*a3, a4^2+a5^2+a6^2, a5*a9+a7*a6+a4*a8]
[ a1*a9+a7*a2+a8*a3, a5*a9+a7*a6+a4*a8, a7^2+a8^2+a9^2]

```

รูปที่ 1 1D covariance matrix (conventional PCA), row-based 2D covariance matrix and its variations.

```

>> corrG1 =
[ a1*a4+a4*a7+a7*a2, a4*a2+a7*a5+a2*a8, a4*a3+a7*a6+a2*a9]
[ a1*a5+a4*a8+a7*a3, a2*a5+a5*a8+a8*a3, a5*a3+a8*a6+a3*a9]
[ a1*a6+a4*a9+a1*a7, a2*a6+a5*a9+a1*a8, a3*a6+a6*a9+a1*a9]

>> B1 =
[ a4, a5, a6]
[ a7, a8, a9]
[ a2, a3, a1]

>> corrG2 =
[ a1*a7+a4*a2+a7*a5, a7*a2+a2*a5+a5*a8, a7*a3+a2*a6+a5*a9]
[ a1*a8+a4*a3+a7*a6, a2*a8+a5*a3+a8*a6, a8*a3+a3*a6+a6*a9]
[ a1*a9+a1*a4+a4*a7, a2*a9+a1*a5+a4*a8, a3*a9+a1*a6+a4*a9]

>> B2 =
[ a7, a8, a9]
[ a2, a3, a1]
[ a5, a6, a4]

>> corrG3 =
[ a1*a2+a4*a5+a7*a8, a2^2+a5^2+a8^2, a2*a3+a5*a6+a8*a9]
[ a1*a3+a4*a6+a7*a9, a2*a3+a5*a6+a8*a9, a3^2+a6^2+a9^2]
[ a1^2+a4^2+a7^2, a1*a2+a4*a5+a7*a8, a1*a3+a4*a6+a7*a9]

>> B3 =
[ a2, a3, a1]
[ a5, a6, a4]
[ a8, a9, a7]

>> corrG4 =
[ a1*a5+a4*a8+a7*a3, a2*a5+a5*a8+a8*a3, a5*a3+a8*a6+a3*a9]
[ a1*a6+a4*a9+a1*a7, a2*a6+a5*a9+a1*a8, a3*a6+a6*a9+a1*a9]
[ a1*a4+a4*a7+a7*a2, a4*a2+a7*a5+a2*a8, a4*a3+a7*a6+a2*a9]

>> B4 =
[ a5, a6, a4]
[ a8, a9, a7]
[ a3, a1, a2]

>> corrG5 =
[ a1*a8+a4*a3+a7*a6, a2*a8+a5*a3+a8*a6, a8*a3+a3*a6+a6*a9]
[ a1*a9+a1*a4+a4*a7, a2*a9+a1*a5+a4*a8, a3*a9+a1*a6+a4*a9]
[ a1*a7+a4*a2+a7*a5, a7*a2+a2*a5+a5*a8, a7*a3+a2*a6+a5*a9]

>> B5 =
[ a8, a9, a7]
[ a3, a1, a2]
[ a6, a4, a5]

>> corrG6 =
[ a1*a3+a4*a6+a7*a9, a2*a3+a5*a6+a8*a9, a3^2+a6^2+a9^2]
[ a1^2+a4^2+a7^2, a1*a2+a4*a5+a7*a8, a1*a3+a4*a6+a7*a9]
[ a1*a2+a4*a5+a7*a8, a2^2+a5^2+a8^2, a2*a3+a5*a6+a8*a9]

>> B6 =
[ a3, a1, a2]
[ a6, a4, a5]
[ a9, a7, a8]

>> corrG7 =
[ a1*a6+a4*a9+a1*a7, a2*a6+a5*a9+a1*a8, a3*a6+a6*a9+a1*a9]
[ a1*a4+a4*a7+a7*a2, a4*a2+a7*a5+a2*a8, a4*a3+a7*a6+a2*a9]
[ a1*a5+a4*a8+a7*a3, a2*a5+a5*a8+a8*a3, a5*a3+a8*a6+a3*a9]

>> B7 =
[ a6, a4, a5]
[ a9, a7, a8]
[ a1, a2, a3]

```

>> corrG8 =	>> B8 =
[a1*a9+a1*a4+a4*a7, a2*a9+a1*a5+a4*a8, a3*a9+a1*a6+a4*a9]	[a9, a7, a8]
[a1*a7+a4*a2+a7*a5, a7*a2+a2*a5+a5*a8, a7*a3+a2*a6+a5*a9]	[a1, a2, a3]
[a1*a8+a4*a3+a7*a6, a2*a8+a5*a3+a8*a6, a8*a3+a3*a6+a6*a9]	[a4, a5, a6]

รูปที่ 2 2D cross-covariance matrices and its corresponding transformed matrices.

จากผลการวิเคราะห์ข้างต้น จะเห็นได้ว่าทางคณะวิจัยสามารถค้นพบแนวทางซึ่งยังไม่มีการค้นพบมาก่อน แต่เนื่องจากทางผู้วิจัยยังไม่ได้ผลการทดลองจึงขอเพียงเกริ่นนำ ระเบียบวิธีใหม่ที่ค้นพบแต่เพียงเล็กน้อย จากผลข้างต้นคณะผู้วิจัยพบว่าเราสามารถพัฒนา นัยทั่วไปของ 2DPCA ได้โดยอาศัยความสัมพันธ์เมตริกซ์โควาเรียนซ์ระหว่าง PCA กับ 2DPCA ซึ่งในที่นี้เราเรียกใหม่ว่า การวิเคราะห์สหสัมพันธ์ภาพ (image cross-covariance analysis: ICCA) ซึ่งมีสมการความสัมพันธ์ระหว่างเมตริกซ์โควาเรียนซ์ระหว่าง PCA กับ ICCA ดังนี้

$$G_L(i, j) = \sum_{k=1}^M C(m(M(i-1)+k), M(j-1)+k)$$

3.3. ผลการทดลอง

การทดลองการรู้จำใบหน้าที่ดำเนินการทดลองในโครงการนี้มีเพื่อวัตถุประสงค์เพื่อเทียบเคียงผลและประยุกต์ใช้ ในที่นี้เราทำการทดสอบกับฐานข้อมูลใบหน้า Yale AR และ ORL โดยทำการทดสอบ 2 ส่วน คือ การหาส่วนประกอบमुखสำคัญสองมิติที่มีการเลื่อน หรือ ICCA และ 2DPCA ที่มีการทำงานร่วมกับ RSM โดยมีรายละเอียดดังนี้

3.3.1. การวิเคราะห์สหสัมพันธ์ภาพ

รูปที่ 3-6 แสดงผลการเปรียบเทียบ ICCA ที่มีการเลื่อนของฐานข้อมูลภาพ Yale และ ORL ตามลำดับ โดยที่เมื่อไม่มีการเลื่อนเลยจะเป็นผลการแปลง 2DPCA นั่นเอง จะเห็นได้ว่ามีค่า shift บางค่าที่ทำให้ผลของการรู้จำสูงกว่า 2DPCA




Fig. 6. Recognition accuracy on the Yale database.




Fig. 7. Recognition accuracy on the ORL database.





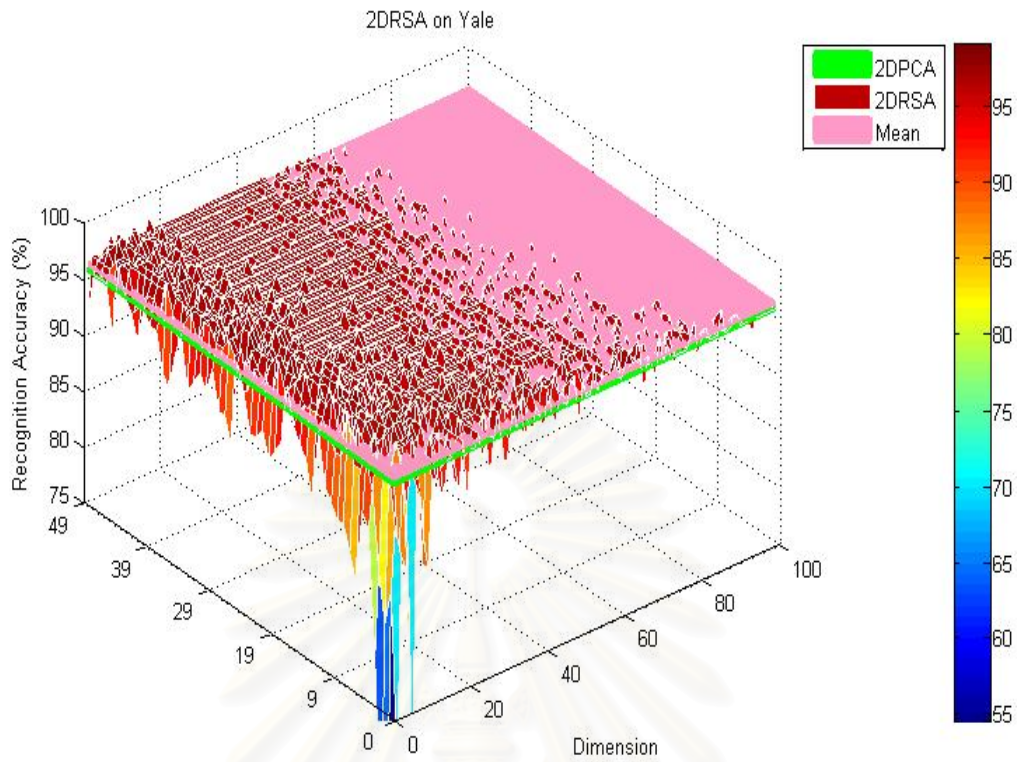
Fig. 5 The shifted images of the best recognition accuracy on the Yale database.



Fig. 6 The shifted images of the best recognition accuracy on the ORL database.

ในส่วนที่สองเราได้ทำการทดลอง 2DPCA ร่วมกับ RSM โดยไดกราฟผลการรู้จำดังแสดง ในรูปสองรูปข้างนี้ จะเห็นได้ว่าเมื่อใช้จำนวนมิติสุ่มที่มีขนาดเพียง 10 เเปอร์เซ็นต์ของมิติทั้งหมดของตัวบ่งต่าง ผลการรู้จำมีโอกาสสูงมากที่จะดีกว่า 2DPCA ดั้งเดิม ซึ่งในขณะนี้กำลังคำนวณผลการทดลองโดยละเอียดในอีกชั้นหนึ่ง

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



บทที่ 4 สรุปและงานต่อไป

4.1. สรุป

โครงการนี้นำเสนอการรู้จำเป้าหมายอัตโนมัติและรู้จำใบหน้าและเป้าหมายอัตโนมัติ แต่เนื่องจากแนวความคิดยังอยู่ในขั้นต้น จึงทำการทดลองกับใบหน้าเพียงอย่างเดียวก่อน โดยได้นำเสนอเทคนิคการจำแนกด้วยคณาจักรกลแบบเข้ารหัสช่องสัญญาณส่งซ้ำ โดยอาศัยระเบียบวิธีปริภูมิย่อยแบบสุ่ม นอกจากนี้ได้มีการศึกษาเพิ่มเติมเทคนิคที่ใช้ในการรู้จำใบหน้าซึ่งพัฒนาปรับปรุงจาก 2DPCA ที่เรียกว่า ICCA อย่างไรก็ตาม แนวความคิดนี้ยังอยู่ในขั้นต้น แต่ผลการทดลองได้แสดงให้เห็นว่าเมื่อพัฒนาต่อไปจะมีผลของการรู้จำดีขึ้นไปได้อีก นอกจากนี้ยังได้เริ่มต้นศึกษาปริภูมิย่อยความละเอียดสูงยิ่งยวด ที่สามารถหาค่าสัมประสิทธิ์ความละเอียดสูงยิ่งยวดจาก ชุดของค่าสัมประสิทธิ์ความละเอียดต่ำ ที่มีความซับซ้อนในการคำนวณต่ำกว่าการคำนวณค่าสัมประสิทธิ์จากภาพความละเอียดสูงยิ่งยวด

4.2. ส่วนงานที่ได้ดำเนินการไปแล้ว

1. พัฒนาระบบจำแนกแบบหลายตัวบนฐานการเข้ารหัสแบบส่งซ้ำ (repetition code) ซึ่งอ้างอิงตามระเบียบวิธีปริภูมิย่อยแบบสุ่ม
2. ศึกษาการวิเคราะห์ส่วนประกอบหลักแบบสองปริภูมิ (two dimension principal component analysis: 2DPCA) (เมทริกซ์) ซึ่งต่างจากวิธีเดิมที่เป็นคลาสปริภูมิเดียว (เวกเตอร์) ในขณะนี้ได้ศึกษาพบว่าในทางปฏิบัติ 2DPCA มีการประมาณค่า เมทริกซ์โคแวนเรียนต์ (covariance matrix) ที่แม่นยำกว่า PCA เดิม
3. ศึกษาการขยายตัวของวิเคราะห์ส่วนประกอบหลักแบบสองปริภูมิ (Generalized 2DPCA)
4. ศึกษาการจำแนกที่เหมาะสมกับผลการแปลง 2DPCA ที่เรียกว่า 2DRSA
5. ศึกษาปริภูมิย่อยความละเอียดสูงยิ่งยวด ที่สามารถหาค่าสัมประสิทธิ์ความละเอียดสูงยิ่งยวดจาก ชุดของค่าสัมประสิทธิ์ความละเอียดต่ำ ที่มีความซับซ้อนในการคำนวณต่ำกว่าการคำนวณค่าสัมประสิทธิ์จากภาพความละเอียดสูงยิ่งยวด

4.3. ส่วนงานต่อไป

1. ศึกษาการผนวกใช้ 2DRSA ร่วมกับ ICCA
2. พัฒนาวิธี 2DPCA แบบหลายระดับความละเอียด (multiresolution) ที่มีอ้างอิงกับ 2DPCA และการเข้ารหัสแบบ zero-embedded tree
3. พัฒนาเทคนิค 2DPCA กับ ระเบียบวิธีความละเอียดสูงยิ่งยวด รวมถึงระเบียบวิธี 2DRSA กับ ICCA เพื่อพัฒนาทฤษฎีการรู้จำที่มีประสิทธิภาพ มีขั้นตอนในการคำนวณต่ำ และการสกัดตัวบ่งชี้ที่ดี

4.4. ผลผลิตและหรือความสัมฤทธิ์ผลของงานที่ได้ดำเนินการไปแล้ว

1. บทความทางวิชาการนานาชาติเรื่อง Image Cross-Covariance Analysis for Face Recognition ซึ่งได้รับการตอบรับให้ไปนำเสนอที่งานประชุม 2007 IEEE TENCON ณ เมืองไทเป ประเทศสาธารณรัฐไต้หวัน วันที่ 30 ตุลาคม - 2 พฤศจิกายน พ.ศ. 2550
2. บทความทางวิชาการนานาชาติเรื่อง Decision Combination of Multiple Classifier Systems for Multiresolution Face Recognition ซึ่งได้รับการตอบรับให้ไปนำเสนอที่งานประชุม ECTI-CON 2007 เชียงราย วันที่ 9-12 พฤษภาคม พ.ศ. 2550

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

เอกสารอ้างอิง

- 1) T. Dietterich, "Machine learning research: Four current directions," *AI Magazine*, vol.18, no.4, pp.97--136, 1997.
- 2) A. Sharkey, *Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems*, Springer Verlag, 1999.
- 3) R. Neal, "Probabilistic inference using Markov chain Monte Carlo methods," Tech. Rep., Dept. of Computer Science, University of Toronto, Tech. Rep. CRG-TR-93-1, 1993.
- 4) Y. Freund and R. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of Computer and System Sciences*, 1995.
- 5) T. Dietterich and G. Bakiri, "Error-correcting output codes: A general method for improving multiclass inductive learning programs," *Proc. of the Ninth AAAI*, pp.572--577, 1991.
- 6) T. Ho, "The random subspace method for constructing decision forests," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol.20, no.8, pp.832--844, 1998.
- 7) C. Nikunj and K. Tumer, "Input decimation ensembles: Decorrelation through dimensionality reduction," in *Lecture Notes in Computer Science*, ed. J. Kittler and F. Roli, *Multiple Classifier Systems*, vol.2096, pp.238--247, Springer-Verlag, Berlin Heidelberg New York, 2001.
- 8) R. Nock, "Inducing interpretable voting classifiers without trading accuracy for simplicity: Theoretical results, approximation algorithm, and experiments," *Journal of Artificial Intelligent Research*, pp.138--170, 2002.
- 9) R. Coifman and N. Saito, "Constructions of local orthonormal bases for classification and regression," *C. R. Acad. Sci. Paris*, vol.319 S'erie I, pp. 191--196, 1994.
- 10) R. Coifman and M. Mickerhauser, "Entropy-based algorithm for best basis selection," *IEEE Trans. Inform. Theory*, vol.38, no.2, pp.713--718, 1992.

- 11) N. Saito, Local Feature Extraction and Its Applications Using a Library of Bases, Ph.D. thesis, Dept. of Mathematics, Yale University, 1994.
- 12) J. O'Sullivan, M. DeVore, V. Kedia, and M. Miller, "SAR ATR performance using a conditionally Gaussian model," IEEE Trans. Aerospace and Electronic Systems, vol.37, no.1, pp.91--108, 2001.
- 13) C. Nilabul, O. Pham, R. Mersereau, M. Smith, and M. Clements, "Hidden Markov modeling for SAR automatic target recognition," ICASSP, pp.1061-1064, May 1998.
- 14) A.Y. Ng and M. Jordan, "On discriminative vs. generative classifiers: A comparison of logistic regression and naive Bayes," Advances in Neural Information Processing Systems, Cambridge, MIT Press, 2002.
- 15) Q. Zhao, D. Xu, and J. Principe, "Pose estimation for SAR automatic target recognition, Image Understanding Workshop '98, Pacific Grove, Canada, pp.827--831, 1998.
- 16) Q. Zhao and J. Principe, "Support vector machines for synthetic aperture radar automatic target recognition," Automatic target recognition IX, SPIE Conf., Orlando, FL, pp.101--107, 1999.
- 17) Q. Zhao, J.C. Principe, V. Brennan, D. Xu, and Z. Wang, "Synthetic aperture radar automatic target recognition with three strategies of learning and representation," Optical Engr., special issue on ATR, vol.39, no.5, pp.1230--1244, 2000.
- 18) E.P. Simoncelli, W.T. Freeman and D. Heeger, "Shiftable multiscale transforms," IEEE Trans. Inform. Theory, vol.38, no.2, pp.587--607, March 1992.
- 19) C.M. Pun and M.C. Lee, "Log-polar wavelet energy signatures for rotation and scale invariant texture classification," IEEE Trans. Pattern Anal. and Machine Intell., vol.25, no.5, pp.590--603, May 2003.
- 20) P.C. Teo, Theory and Applications of Steerable Functions, Ph.D. thesis, Stanford University, March 1998.
- 21) J. Wood, "Invariant pattern recognition: A review," Pattern Recognition, vol.29, no.1, pp.1--17, 1996.

- 22) E.P. Simoncelli, W.T. Freeman and D. Heeger, "Symmetries and discriminability in feedforward network architecture," IEEE Trans. Inform. Theory, vol.38, no.2, pp.816--826, March 1992.
- 23) O.K. Al-Shaykh and J.K. Doherty, "Invariant image analysis based on radon transform and SVD," IEEE Trans. Circuits and Systems, vol.43, no.2, pp.123--133, February 1996.
- 24) H.J. Dohse and A. Jain, "Object classification and registration by radon transform based invariants," Proc. of Int. Conf. on Acoustics, Speech, and Signal Processing, pp.225--228, April 1987.
- 25) E. Tapia, J. Gonzalez, and J. Villena, "A generalized class of boosting algorithms based on recursive decoding models," in Lecture Notes in Computer Science, ed. T. Windeatt and F. Roli, Multiple Classifier Systems, vol.2096, Springer-Verlag, Berlin Heidelberg New York, 2001.
- 26) S. Hashem, "Optimal linear combinations of neural networks," Neural Networks, vol.10, no.4, pp.599--614, 1997.
- 27) L. Sirovich and M. Kirby, "Low-dimensional procedure for characterization of human faces," J. Optical Soc. Am., vol.4, pp.519-524, 1987.
- 28) M. Turk and A. Pentland, "Eigenfaces for recognition," J. of Cognitive Neuroscience, vol.3, no.1, pp.71-86, 1991.
- 29) P.N. Belhumeur, J.P. Hespanha, and D.J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection," IEEE Trans. Pattern Anal. and Mach. Intell., vol.19, pp.711-720, July 1997.
- 30) W. Zhao, R. Chellappa, and A. Krishnaswamy, "Discriminant analysis of principle components for face recognition," Japan, IEEE 3rd Inter. Conf. on Automatic Face and Gesture Recognition, 1998.
- 31) W. Zhao, R. Chellappa, and N. Nandhakumar, "Empirical performance analysis of linear discriminant classifiers," CVPR, pp.164-171, IEEE Computer Society, 1998.
- 32) K. Fukunaga, Introduction to Statistical Pattern Recognition, second ed., Academic Press, 1990.

- 33) L. Chen, H. Liao, M. Ko, J. Lin, and G. Yu, A new LDA based face recognition system which can solve the small sample size problem," Pattern Recognition, vol.33, no.10, pp.1713-1726, 2000.
- 34) J. Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, Regularized discriminant analysis for the small sample size problem in face recognition," Pattern Recogn. Lett., vol.24, no.16, pp.3079-3087, 2003.
- 35) R. Huang, Q. Liu, H. Lu, and S. Ma, Solving the small sample size problem of LDA," Pattern Recognition, vol.3, pp.29-32, 2002.
- 36) J. Yang, D. Zhang, A.F. Frangi, and J. yu Yang, Two-dimensional PCA: A new approach to appearance-based face representation and recognition," IEEE Trans. Pattern Anal. and Mach. Intell., vol.26, pp.131{137, Jan. 2004.
- 37) J. Ye, R. Janardan, and Q. Li, Two-dimensional linear discriminant analysis," in Advances in Neural Information Processing Systems 17, ed. L.K. Saul, Y. Weiss, and L. Bottou, pp.1569{1576, MIT Press, Cambridge, MA, 2005.
- 38) J. Yang and J.Y. Yang, From image vector to matrix: A straightforward image projection technique IMPCA vs. PCA," Pattern Recognition, vol.35, no.9, pp.1997-1999, 2002.
- 39) Yale, The Yale face database," 1997. Available from <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>.
- 40) ORL, The ORL face database at the AT&T (Olivetti) research laboratory," 1992. Available from <http://www.cl.cam.ac.uk/Research/DTG/attarchive/facedatabase.html>.
- 41) D. Zhang and Z.H. Zhou, $(2D)^2$ PCA: 2-directional 2-dimensional PCA for efficient face representation and recognition," Neurocomputing, 2005.
- 42) H. Kong, X. Li, L. Wang, E.K. Teoh, J.G. Wang, and R. Venkateswarlu, Generalized 2D principal component analysis," IEEE International Joint Conference on Neural Networks (IJCNN), 2005.
- 43) S. Shan, W. Gao, and D. Zhao, Face recognition based on face-specific subspace," International Journal of Imaging Systems and Technology, vol.13