

รายงานฉบับสมบูรณ์โครงการวิจัยงบประมาณปี 2546

โครงการวิจัยย่อยลำดับที่ 1 เรื่อง

การพัฒนาการรู้จำลายมือเขียนภาษาไทยแบบออนไลน์

(ชื่อเดิมคือ การพัฒนาการรู้จำลายมือเขียนภาษาไทยแบบออนไลน์บนคอมพิวเตอร์พกพา)

1. ผู้รับผิดชอบโครงการ

รองศาสตราจารย์ ดร.สมชาย จิตะพันธ์กุล
อาจารย์วิทยากร อัครวิเศษ

หัวหน้าโครงการ
นักวิจัย

หมายเหตุ ทางโครงการวิจัยย่อยขอปรับปรุงชื่อโครงการเพื่อให้ครอบคลุมการใช้งานได้กว้างขวางขึ้น ดังเป็นที่ทราบกันแล้วว่า ปัจจุบันนี้มีไม้คูปแบบแท็บเล็ตที่รองรับการป้อนข้อมูลเป็นลายมือเขียนได้แล้ว

2. วัตถุประสงค์ของโครงการ

คอมพิวเตอร์สามารถรู้จำลายมือเขียนภาษาไทยแบบ On-line ได้ ทั้งนี้สำหรับระยะที่ 2 นี้มีวัตถุประสงค์เน้น เพื่อพัฒนาวิธีการรู้จำตัวอักษรแบบลายมือเขียนภาษาไทยแบบออนไลน์ที่เป็นตัวอักษรตัวเดียวที่ได้จากคำในภาษาไทย

3. ขอบเขตหรือเป้าหมายของโครงการ

ศึกษาวิจัย และประยุกต์ใช้ เทคนิคต่างๆกับระบบการรู้จำลายมือเขียนภาษาไทยแบบ On-line เพื่อเพิ่มประสิทธิภาพ โดยที่เป้าหมายเฉพาะระยะที่ 2 คือ


1. สร้างระบบรู้จำลายมือเขียนตัวอักษรภาษาไทยแบบออนไลน์
2. แบ่งตัวอักษรภาษาไทยที่จะรู้จำตามระดับของตัวอักษรออกเป็น 3 กลุ่มดังตารางที่ 1
3. อัตราความถูกต้องเฉลี่ยในแต่ละกลุ่มไม่ต่ำกว่าร้อยละ 90 โดยเก็บตัวอย่างผู้เขียนอิสระจำนวน 62 คน

ระดับของตัวอักษร	ตัวอักษร
ระดับบน	ก ข ค ง จ ฉ ช ซ ฌ ญ ฎ ฏ ฐ ฑ ฒ ด
ระดับกลาง	ต ถ ฐ น บ ป ผ ฝ พ ฟ ภ ม ย ร ล ว ศ ษ ส ห พ อ ฮ ะ า เ ใ โ
ระดับล่าง	า อ

ตารางที่ 1 ตัวอักษรภาษาไทยแบ่งตามระดับ

4. ส่วนงานที่ได้ดำเนินการไปแล้ว

- 4.1 สร้างระบบรู้จำตัวอักษรลายมือเขียนภาษาไทยแบบออนไลน์ด้วยแบบจำลองฮิดเดนมาร์คอฟและฟัซซีโลจิก โดยประกอบด้วยส่วนหลัก 5 ส่วน คือ กระบวนการก่อนหน้า (Preprocessing) การแบ่งส่วนของเส้น (Stroke Segmentation) การสกัดคุณลักษณะสำคัญ (Feature extraction) แบบจำลองฮิดเดนมาร์คอฟ (Hidden Markov Model, HMM) และ ฟัซซีโลจิก (Fuzzy logic) ดังแสดงในรูปที่ 1



รูปที่ 1 แผนภาพการทำงานระบบรู้จำตัวอักษรลายมือเขียนภาษาไทยแบบออนไลน์ด้วยแบบจำลองฮิดเดนมาร์คอฟและฟัซซีโลจิก

4.1.1 กระบวนการก่อนหน้า (Preprocessing)

ข้อมูลของตัวอักษรแบบออนไลน์ซึ่งใช้ในวิทยานิพนธ์ฉบับนี้ คือ ลำดับของพิกัด (x, y) บนจอภาพมราถุคดิจิทัลโดยอุปกรณ์ป้อนเข้า โดยจะสนใจเฉพาะพิกัดที่อยู่บนเส้นของตัวอักษรและลำดับที่ยกปากกาขึ้นเท่านั้น ไม่รวมถึงพิกัดขณะที่ยกปากกา แรกกดปากกา ฯลฯ โดยใช้ขั้นตอนของ Nair และ Leedham ซึ่งมีขั้นตอนดังต่อไปนี้

- 4.1.1.1 ลบการยกปากกาโดยบังเอิญ
- 4.1.1.2 ทำเส้นให้เรียบ (Smoothing)
- 4.1.1.3 ทำการกรองระยะทางที่สั้น (Minimum Distance Filtering)
- 4.1.1.4 ลบส่วนที่เกิดขึ้นโดยไม่ตั้งใจเวลาลงปากกา หรือยกปากกาขึ้น (Serif Removal)
- 4.1.1.5 ทำนอร์มอลไลซ์ (Normalization)

สำหรับการทำนอร์มอลไลซ์ในภาษาไทยนั้นจะพบตัวอักษรที่มีหางเกินเส้นบรรทัดการขยายขนาดตัวอักษรให้มีความสูงเท่ากันนั้นควรจะสนใจความสูงของตัวอักษรที่ไม่รวมส่วนหางดังนั้นเราจึงหากรอบของตัวอักษรเดี่ยวโดยที่หางจะไม่อยู่ในกรอบเมื่อเราพบว่าตัวอักษรมีโอกาสเป็นหางหรือจุดปลายของตัวอักษรอยู่ด้านบนขวาเราจะพิจารณากรอบด้านบนให้สูงเท่ากับจุดที่สูงที่สุดในส่วนครึ่งด้านซ้ายของตัวอักษรแทนตัวอย่างการหากรอบตัวอักษร

4.1.2 การแบ่งส่วนของเส้น (Stroke Segmentation)

ข้อมูลตัวอักษรที่ได้รับมาจะถูกแบ่งออกเป็นเส้นย่อย (Sub-stroke) โดยจุดที่ใช้แบ่งเส้นรวมออกเป็นเส้นย่อยจะมีลักษณะตามข้อกำหนดข้อใดข้อหนึ่งต่อไปนี้

- เมื่อจุดที่พิจารณาเป็นจุดที่เกิดมุมแหลม จุดที่ n เป็นจุดดังกล่าวเมื่อ

$$|\theta_{n-2} + \theta_{n-1} - \theta_n - \theta_{n+1}| > \theta_T \quad (0.1)$$

เมื่อ θ_T เป็นมุมคงที่ค่าหนึ่ง โดยจากการทดลองพบว่า $\theta_T = \frac{\pi}{3}$ เป็นค่าที่เหมาะสมกับตัวอักษรภาษาไทย

- เมื่อจุดที่พิจารณาเป็นจุดที่มีเส้นสัมผัสทำมุมกับเส้นสัมผัสของจุดเริ่มแรกของเส้นย่อย θ_i เกินค่ามุมที่กำหนดไว้ $\theta_{threshold,t}$
- เมื่อเส้นที่ลากจากจุดแรกของเส้นย่อยถึงจุดที่พิจารณาทำมุม θ_s กับเส้นสัมผัสที่จุดแรกของเส้นย่อยเกินค่ามุมที่กำหนดไว้ $\theta_{threshold,s}$

การแบ่งส่วนของเส้นด้วยกรรมวิธีดังที่กล่าวมาเมื่อทดลองใช้กับตัวอักษรในภาษาไทยพบว่าใช้งานได้ดี

4.1.3 การสกัดคุณลักษณะสำคัญ (Feature Extraction)

หลังจากการแบ่งส่วนของเส้นจะนำแต่ละเส้นมาสกัดคุณลักษณะสำคัญเพื่อนำไปเป็นเวกเตอร์ของคุณลักษณะและนำไปเป็นลำดับที่ไปพิจารณาในแบบจำลองฮิดเดนมาร์คอฟต่อไปในวิทยานิพนธ์นี้ประมาณค่าเส้นย่อยเป็นเส้นตรงเส้นหนึ่งประกอบไปด้วยคุณลักษณะ 5 ชนิด และสามารถอธิบายคุณลักษณะของเส้นย่อย i ได้ดังนี้

- พิกัดตามแนวนอนของจุดศูนย์กลางของเส้นย่อย (x_c) หาได้จาก

$$x_c(i) = \frac{1}{N} \sum_{n=1}^N x(i) \quad (0.2)$$

โดย $x(i)$ คือ พิกัดตามแนวนอนของจุดที่ i ของเส้นย่อย และ N จำนวนจุดทั้งหมดบนเส้นย่อยนั้น

- พิกัดตามแนวตั้งของจุดศูนย์กลางของเส้นย่อย (y_c) หาได้จาก

$$y_c(i) = \frac{1}{N} \sum_{n=1}^N y(i) \quad (0.3)$$

โดย $y(i)$ คือ พิกัดตามแนวตั้งของจุดที่ i ของเส้นย่อย และ N จำนวนจุดทั้งหมดบนเส้นย่อยนั้น

- มุมของเส้นที่ลากจากจุดต้นไปถึงจุดปลายของเส้นย่อยเมื่อเทียบกับเส้นแนวนอน ($\theta_v(i)$)

- มุมระหว่างเส้นย่อยที่พิจารณากับเส้นย่อยก่อนหน้า ($\theta_{re}(i)$)
- ความยาวของเส้นตรงที่ลากจากจุดแรกถึงจุดสุดท้ายของเส้นย่อยนั้น ($L(i)$)

4.1.4 แบบจำลองฮิดเดนมาร์คอฟ (Hidden Markov Model, HMM)

หลังจากสกัดคุณลักษณะสำคัญแล้วจะได้เวกเตอร์ลักษณะ (Feature vector) ซึ่งมี 2 มิติมิติแรกคือจำนวนคุณลักษณะในหัวข้อ 4.1.3 ซึ่งในที่นี้จะมีขนาดเท่ากับ 5 เท่ากันหมดทุกๆตัวอักษร ส่วนมิติที่สองมีขนาดเท่ากับจำนวนเส้นย่อยทั้งหมดในตัวอักษรนั้น ซึ่งแต่ละตัวอักษรจะมีจำนวนเส้นย่อยไม่เท่ากัน จากนั้นป้อนเวกเตอร์ลักษณะของตัวอักษรตัวที่ i ที่จะใช้ในการฝึกฝนทั้งหมดให้แบบจำลองฮิดเดนมาร์คอฟมาเพื่อทำการฝึกฝนหาพารามิเตอร์ของแบบจำลองของตัวอักษรที่ i (λ_i) หลังจากฝึกฝนครบทุกชนิดตัวอักษรเราจะได้แบบจำลองฮิดเดนมาร์คอฟจำนวนเท่ากับจำนวนชนิดตัวอักษรทั้งหมด

ในกรณีที่มี K ชนิดมีการตัดสินใจชนิดของลำดับการสังเกต \bar{O} ต้องหาค่าความน่าจะเป็นภายหลัง $P(\bar{O} | \lambda_i)$ ของทุกๆแบบจำลอง ดังนั้นข้อมูลออกของแบบจำลองฮิดเดนมาร์คอฟคือความน่าจะเป็นภายหลังของทุกๆแบบจำลอง, $P(\bar{O} | \lambda_1), P(\bar{O} | \lambda_2), \dots, P(\bar{O} | \lambda_i), \dots, P(\bar{O} | \lambda_K)$ และเราจะตัดสินใจว่า \bar{O} เป็นตัวอักษรชนิดที่ i ถ้า $P(\bar{O} | \lambda_i)$ มีค่ามากที่สุดดังสมการ

$$i = \arg \max_{1 \leq i \leq K} P(\bar{O} | \lambda_i) \quad (0.4)$$

สำหรับในที่นี้จะไม่ตัดสินใจด้วยกระบวนการดังที่กล่าวมาโดยทันที เนื่องจากคำตอบที่ได้จากแบบจำลองฮิดเดนมาร์คอฟมีการตัดสินใจผิดพลาดเป็นตัวอักษรที่มีลักษณะคล้ายกันค่อนข้างมาก ดังนั้นจึงนำเอาค่าพารามิเตอร์ของแบบจำลอง และ $P(\bar{O} | \lambda_i)$ ไปเพื่อสร้างฟังก์ชันทางฟัซซีโลจิกต่อไป


4.1.5 ฟัซซีโลจิก (Fuzzy Logic)

ข้อมูลออกจากแบบจำลองฮิดเดนมาร์คอฟ และลักษณะบ่งความต่างจะนำมาวัดเพื่อให้ได้ตัวแปรฟัซซีด้วยฟังก์ชันความเป็นสมาชิกที่เหมาะสม หลังจากนั้นก็นำตัวแปรเหล่านี้มาทดสอบกับกฎทางฟัซซีในการตัดสินใจขั้นสุดท้าย โดยฟังก์ชันความเป็นสมาชิกฟัซซี (Fuzzy Membership Function) ที่ใช้วัดปริมาณต่างๆ ได้จากการประมาณค่าของฟังก์ชันความหนาแน่นของปริมาณนั้นที่คำนวณมาจากชุดข้อมูลตัวอย่าง โดยลักษณะบ่งความต่างที่ใช้เป็นเกณฑ์วัดมีดังต่อไปนี้


- อัตราส่วนความกว้างต่อความสูง
- หัวตัวอักษร
- ตำแหน่งจุดต้นและจุดปลายของตัวอักษร
- รอยหยัก
- ตำแหน่งจุดตัด
- จำนวนขีดด้านท้าย

4.1.6 ผลการทดสอบระบบรู้จำ


โดยจะเปรียบเทียบระบบรู้จำที่กล่าวมากับระบบรู้จำที่ใช้แบบจำลองฮิดเดนมาร์คอฟแบบพื้นฐาน โดยนำไปทดสอบกับชุดข้อมูลตัวอักษรของกลุ่มผู้เขียนอิสระได้ผลดังแสดงในรูปที่ 2-4



รูปที่ 2 แผนภูมิเปรียบเทียบอัตราการเรียนรู้จำตัวอักษรระดับกลาง (ก-น)



รูปที่ 3 แผนภูมิเปรียบเทียบอัตราการเรียนรู้จำตัวอักษรระดับกลาง (ป-เ)




รูปที่ 4 แผนภูมิเปรียบเทียบอัตราการเรียนรู้จำตัวอักษรระดับบน

โดยอัตราการเรียนรู้เฉลี่ยของของตัวอักษรระดับล่างเท่ากับร้อยละ 96.84 โดยสรุปรวมได้ดังตารางที่ 2

ชุดข้อมูล	อัตราการเรียนรู้จำตัวอักษรระดับต่างๆ (ร้อยละ)		
	ระดับบน	ระดับกลาง	ระดับล่าง
ผู้เขียนที่ใช้ในการฝึกฝนระบบ	94.32	95.66	100.00
ผู้เขียนอิสระ	90.96	93.27	96.84

ตารางที่ 2 อัตราการเรียนรู้เฉลี่ยของระบบรู้จำตัวอักษรภาษาไทยด้วยแบบจำลองฮิดเดนมาร์คอฟและพีชชีโลจิก

4.2 เสนอระบบรู้จำขึ้นใหม่โดยนำ Classifier 2 ประเภทมาใช้ร่วมกัน คือ ประเภท generative อันได้แก่ Hidden Markov Models (HMMs) และ ประเภท discriminative อันได้แก่ Support Vector Machines (SVMs) โดยนำ posterior probability ที่ได้จาก HMMs มา map เป็น feature ของ SVMs โดยใช้วิธี Score space mapping โดยมีลักษณะระบบดังรูปที่ 5




รูปที่ 5 แผนผังแนวคิดระบบรู้จำตัวอักษร

เนื่องจาก SVMs เป็น Binary Classifier แต่ในงานรู้จำตัวอักษรนั้นเป็น Multi classification ดังนั้นเราจึงต้องนำเทคนิคอื่น คือ Max win algorithm เพื่อทำให้ใช้งานได้กับงานด้าน Multiclass โดยกระบวนการก่อนหน้าและการสกัดคุณลักษณะอาศัยตามหัวข้อ 4.1.1 ถึง 4.1.3


4.2.1 Support Vector Machines

4.2.1.1 ซัพพอร์ตเวกเตอร์แมชชีนแบบไม่เชิงเส้น ในงานบางประเภทมีลักษณะไม่เป็นเชิงเส้นจึงไม่สามารถใช้ไฮเปอร์เพลนมาจำแนกประเภทได้ดังรูปที่ 6



รูปที่ 6 โครงสร้างข้อมูลแบบไม่เป็นเชิงเส้น

วิธีประยุกต์ใช้ซัพพอร์ตเวกเตอร์แมชชีนกับกรณีไม่เป็นเชิงเส้นนี้ทำได้โดยการส่ง (Map) จาก ปริภูมิขาเข้า (Input space) ไปสู่ ปริภูมิลักษณะ (Feature space) โดยผ่านฟังก์ชัน $\Phi(\vec{x})$ ดังรูปที่ 7



รูปที่ 7 การส่งปริภูมิขาเข้า (ซ้าย) ไปสู่ ปริภูมิลักษณะ (ขวา)

จากรูปเป็นตัวอย่างของการส่งจาก

Input Space: $\vec{x} = (x_1, x_2)$ (2 คุณลักษณะ)

Feature Space: $\Phi(\vec{x}) = (x_1^2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2, \sqrt{2}x_1x_2, 1)$ (6 คุณลักษณะ)

หลังจากส่งไปสู่ปริภูมิลักษณะแล้วเราสามารถหาไฮเปอร์เพลนมาจำแนกประเภทได้

4.2.1.2 **เคอร์เนล (Kernels)** เนื่องจากมีจำนวนของคุณลักษณะ (Attribute) มากมายจากโพลีโนเมียลดีกรี p บน N คุณลักษณะในปริภูมิเข้าเป็น $O(N^p)$ คุณลักษณะในปริภูมิลักษณะ

Kernel functions:
$$K(\bar{x}_i, \bar{x}_j) = \Phi(\bar{x}_i) \cdot \Phi(\bar{x}_j) \tag{0.5}$$

จาก $\Phi(\bar{x}) = (x_1^2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2, \sqrt{2}x_1x_2, 1)$ เราสามารถหาฟังก์ชันเคอร์เนลได้เป็น

$$K(\bar{x}_i, \bar{x}_j) = \Phi(\bar{x}_i) \cdot \Phi(\bar{x}_j) = [\bar{x}_i \cdot \bar{x}_j + 1]^2 \tag{0.6}$$

เราปรับปรุงใหม่โดยใช้ฟังก์ชันเคอร์เนลได้ดังนี้

Dual Optimal Problem: Maximize
$$L(\bar{\alpha}) = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(\bar{x}_i, \bar{x}_j) \tag{0.7}$$

Subject to
$$\sum_i \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, l$$

Hyperplane:
$$h(\bar{x}) = \text{sign} \left[\sum_{x_i \in SV} \alpha_i y_i K(\bar{x}_i, \bar{x}_j) + b \right] \tag{0.8}$$

ฟังก์ชันเคอร์เนลมีหลากหลายขึ้นกับการใช้งาน เช่น

Linear:
$$K(\bar{x}_i, \bar{x}_j) = \bar{x}_i \cdot \bar{x}_j \tag{0.9}$$

Polynomial:
$$K(\bar{x}_i, \bar{x}_j) = [\bar{x}_i \cdot \bar{x}_j + 1]^d \tag{0.10}$$

Radial Basis Function (RBF):
$$K(\bar{x}_i, \bar{x}_j) = \exp(-\|\bar{x}_i - \bar{x}_j\|^2 / (2\sigma^2)) \tag{0.11}$$

Sigmoid:
$$K(\bar{x}_i, \bar{x}_j) = \tanh[\gamma(\bar{x}_i - \bar{x}_j) + c] \tag{0.12}$$

4.2.2 ปริภูมิคะแนน (Score-spaces)

ปริภูมิคะแนน คือ ปริภูมิที่ลำดับเวกเตอร์การสังเกต (Observation vectors) ใดๆ สามารถถูกส่ง (Map) มาเป็นคะแนน (Score) ซึ่งคะแนนที่ได้จะเป็นข้อมูลขาเข้าของตัวจำแนกประเภท (Classifier) ต่อไป เหตุผลที่ทำให้ปริภูมิคะแนนมีประโยชน์และน่าสนใจคือ

- ปริภูมิคะแนนถูกกำหนดให้ใช้กับแบบจำลองความน่าจะเป็นแบบ Generative เพราะฉะนั้นจึงเหมาะกับวิธีการแบบโดยนัย (Implicit method) เช่น โครงข่ายประสาทเทียม
- สามารถรวมเอาข้อดีของตัวจำแนกประเภทแบบจำลองแบบ Generative กับตัวจำแนกประเภทที่ถูกฝึกแบบ Discriminative
- เนื่องจากข้อดีของแบบจำลองแบบ Generative ที่รองรับมิติที่หลากหลายของลำดับเวกเตอร์การสังเกตได้ ทำให้ปริภูมิคะแนนสามารถส่งลำดับเวกเตอร์การสังเกตที่มีมิติหลากหลาย ไปเป็น

เวกเตอร์ที่มีมิติคงที่ได้ จึงเหมาะกับตัวจำแนกประเภทแบบสถิต เช่น ซัพพอร์ตเวกเตอร์แมชชีน ที่ถูกนำไปใช้กับงานการจำแนกประเภทแบบจลน์ ดังเช่น งานด้านการรู้เสียงพูด หรือ ตัวอักษร

- ความสามารถที่โดดเด่นในการจำแนกประเภทของตัวจำแนกประเภทที่ถูกฝึกแบบ Discriminative เช่น ซัพพอร์ตเวกเตอร์แมชชีน ในงานการจำแนกประเภทแบบสถิตเพราะจะทำการหาขอบเขตของชนิด (Class boundaries) โดยตรงโดยไม่ต้องผ่านขั้นตอนในการจำลองความหนาแน่นของข้อมูล

พิจารณาลำดับการสังเกต \bar{O} และ เซตของแบบจำลองความน่าจะเป็นแบบ Generative ที่เป็นไปได้ของ \bar{O} , $P = \{P_k(\bar{O}|\bar{\theta}_k)\}$ เมื่อ k คือ ตัวชี้สำหรับแต่ละแบบจำลองในเซต P และ $\bar{\theta}_k$ คือ เวกเตอร์พารามิเตอร์ของสมาชิกตัวที่ k ที่ประมาณจากแบบจำลองแบบ Generative และให้ $\bar{\Theta}_k$ คือ เวกเตอร์พารามิเตอร์แท้จริงของสมาชิกตัวที่ k ที่สร้างจากแบบจำลองแบบ Generative ที่ถูกต้อง ในหลายกรณีที่เราไม่สามารถหา $\bar{\Theta}_k$ ได้เราจึงจำเป็นต้องทำการประมาณค่า $\bar{\Theta}_k$ โดยใช้อนุกรมเทเลอร์ (Taylor series) และเนื่องจากค่าความน่าจะเป็นในเซต P มีค่าน้อยมากเราจึงนิยมใช้ค่า $\ln P$ แทนดังนั้น

$$\begin{aligned} \ln P_k(\bar{O}|\bar{\Theta}_k) &= \ln P_k(\bar{O}|\bar{\theta}_k) + (\bar{\Theta}_k - \bar{\theta}_k)^T \nabla_{\bar{\theta}_k} \ln P_k(\bar{O}|\bar{\theta}_k) \\ &+ \frac{1}{2} (\bar{\Theta}_k - \bar{\theta}_k)^T \left[\nabla_{\bar{\theta}_k}^2 \ln P_k(\bar{O}|\bar{\theta}_k) \right] (\bar{\Theta}_k - \bar{\theta}_k) + \dots \end{aligned} \quad (0.13)$$

หากเรากำหนดให้พจน์ที่มีดีกรีมากกว่า 2 ให้อยู่ในเทอม $\Psi\left((\bar{\Theta}_k - \bar{\theta}_k)^{n+1}\right)$ ดังนั้น

$$\begin{aligned} \ln P_k(\bar{O}|\bar{\Theta}_k) &= \ln P_k(\bar{O}|\bar{\theta}_k) + (\bar{\Theta}_k - \bar{\theta}_k)^T \nabla_{\bar{\theta}_k} \ln P_k(\bar{O}|\bar{\theta}_k) \\ &+ \frac{1}{2} (\bar{\Theta}_k - \bar{\theta}_k)^T \left[\nabla_{\bar{\theta}_k}^2 \ln P_k(\bar{O}|\bar{\theta}_k) \right] (\bar{\Theta}_k - \bar{\theta}_k) \\ &+ \Psi\left((\bar{\Theta}_k - \bar{\theta}_k)^{n+1}\right) \\ &= \bar{w}_{lik(k)}^T \varphi^{lik(i)}(\bar{O}) + \Psi\left((\bar{\Theta}_k - \bar{\theta}_k)^{n+1}\right) \end{aligned} \quad (0.14)$$

ถ้า $n \rightarrow \infty$ เทอม $\bar{w}_{lik(k)}^T \varphi^{lik(i)}(\bar{O})$ จะประมาณค่าจริงของ $\ln P_k(\bar{O}|\bar{\Theta}_k)$ ได้ใกล้เคียงที่สุด โดย $\varphi^{lik(i)}(\bar{O})$ คือ คะแนน (Score) ภายในปริภูมิคะแนนที่มีมิติอนันต์ซึ่งเกิดจากการหาอนุพันธ์อันดับที่อนันต์ในการประมาณค่าพารามิเตอร์ และ $\bar{w}_{lik(k)}$ คือเวกเตอร์น้ำหนักซึ่งถูกประมาณขึ้น

พิจารณาลำดับการสังเกต \bar{O} ที่ถูกส่งไปยังปริภูมิคะแนนจะเรียกว่าคะแนน (Score), $\varphi_{\bar{F}}^f(\bar{O})$ โดย


$$\varphi_{\bar{F}}^f(\bar{O}) = \varphi_{\bar{F}}^f\left(\{P_k(\bar{O}|\bar{\theta}_k)\}\right) \quad (0.15)$$

โดย $f(\{P_k(\bar{O}|\bar{\theta}_k)\})$ คือ Score-argument และเป็นฟังก์ชันของสมาชิกของ P

φ_F คือ ตัวส่งคะแนน (Score-mapping)

\hat{F} คือ ตัวดำเนินการคะแนน (Score-operator)

4.2.3 การทดลองกับพยัญชนะและสระระดับกลางจากชุดข้อมูลกลุ่มผู้เขียนอิสระได้ผลดังรูปที่ 8



รูปที่ 8 อัตราการรู้จำของระบบรู้จำที่เสนอเปรียบเทียบกับแบบ HMMs

จากผลที่ได้พบว่าผลรวมยังไม่ดีกว่าแบบ HMMs แต่มีค่าใกล้เคียงกันเนื่องจากพารามิเตอร์ต่างๆ และกระบวนการบางอย่างยังไม่เหมาะสมกับลักษณะข้อมูล เช่น จำนวนสถานะของแบบจำลองฮิดเดนมาร์คอฟ จำนวนส่วนผสมแบบเกาส์ ลักษณะของคุณลักษณะ การเลือกกลุ่มชนิดสับสน ฯลฯ ซึ่งต้องมีการปรับปรุงต่อไป

5. ส่วนที่จะดำเนินการต่อไป

- 5.1 ค้นหาและแก้ไขข้อผิดพลาดในโปรแกรมของระบบรู้จำที่เสนอในหัวข้อ 4.2
- 5.2 ปรับปรุงระบบที่เสนอในหัวข้อ 4.2 ให้มีอัตราการรู้จำเกินกว่าร้อยละ 90 โดยการเลือก Sub-score space และ ปรับปรุง feature ของ HMMs ใหม่
- 5.3 เขียนสรุปในลักษณะรายงานเป็นรูปเล่ม และ paper

6. ผลผลิตและหรือความสัมฤทธิ์ผลของงานที่ได้ดำเนินการไปแล้ว

- 6.1 บทความเรื่อง Language-based Hand-printed Characters Recognition: A Novel Method Using Spatial and Temporal Informative Features ซึ่งได้ไปทำเสนอที่งาน NNSP 2003 ณ ประเทศฝรั่งเศส
- 6.2 บทความเรื่อง ON-LINE THAI HANDWRITTEN CHARACTER RECOGNITION USING HIDDEN MARKOV MODEL AND FUZZY LOGIC ซึ่งได้ไปทำเสนอที่งาน NNSP 2003 ณ ประเทศฝรั่งเศส