



ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบันเครื่องคอมพิวเตอร์มีบทบาทที่สำคัญไม่ว่าจะเป็นการทำงานประจำวันหรือในการทำงาน และมีแนวโน้มที่จะมีความสำคัญเพิ่มขึ้นเรื่อยๆ โดยเฉพาะการนำข้อมูลข่าวสารที่รวบรวมไว้ในระบบคอมพิวเตอร์มาใช้งานได้อย่างถูกต้องและรวดเร็ว และประหยัดเนื้อที่ในการเก็บกระดาษที่เป็นเอกสารต้นฉบับ จึงมีความพยายามที่จะจัดเก็บข้อมูลข่าวสารต่างๆที่มีให้อยู่ในรูปแบบอิเล็กทรอนิกส์ เพื่อที่จะสามารถนำไปใช้ในระบบคอมพิวเตอร์ได้ เช่น การพิมพ์เอกสารใหม่จากต้นฉบับที่ต้องการ ลงในเครื่องคอมพิวเตอร์แล้วทำการจัดเก็บในฮาร์ดดิสก์ เพื่อการใช้งานในอนาคต แต่การพิมพ์เอกสารใหม่นั้น อาจเกิดข้อผิดพลาดขึ้นได้ ทำให้ข้อมูลข่าวสารนั้นคลาดเคลื่อนจากข้อมูลข่าวสารเดิม และการพิมพ์เอกสารใหม่ยังเสียเวลาและทรัพยากรอย่างมากอีกด้วย จึงมีการพัฒนาเครื่องสแกนเนอร์เพื่อแก้ปัญหาดังกล่าว

การใช้งานเครื่องสแกนเนอร์ เพื่อใช้ในการเก็บรูปภาพและเอกสารต้นฉบับให้อยู่ในรูปแบบอิเล็กทรอนิกส์ ประโยชน์ที่ได้รับก็คือสามารถประหยัดเนื้อที่การเก็บกระดาษที่เป็นเอกสารต้นฉบับ และมีความถูกต้องและรวดเร็วกว่าการพิมพ์เอกสารใหม่ อย่างไรก็ตามการเก็บและแก้ไขเอกสารที่ได้จากเครื่องสแกนเนอร์ยังมีปัญหาอยู่มาก เนื่องจากเอกสารที่ได้มานั้น จะอยู่ในแฟ้มข้อมูลแบบรูปภาพ ซึ่งจะเปลืองเนื้อที่ฮาร์ดดิสก์ในการเก็บข้อมูลมากกว่าแฟ้มข้อมูลแบบตัวอักษร และการแก้ไขหรือการค้นหาข้อความในแฟ้มข้อมูลแบบรูปภาพ จะไม่สามารถใช้โปรแกรมประมวลผลคำทั่วไปได้

ต่อมาได้มีการพัฒนาโปรแกรมโอซีอาร์ (Optical Character Recognition) ขึ้น เพื่อแก้ปัญหาข้างต้นโดยการทำงานของโปรแกรมจะทำการอ่านแฟ้มข้อมูลแบบรูปภาพแล้วแปลงเป็นตัวอักษรเพื่อจัดเก็บเป็นแฟ้มข้อมูลแบบตัวอักษร ทำให้สามารถลดเนื้อที่ฮาร์ดดิสก์ในการเก็บข้อมูล และสามารถแก้ไขหรือค้นหาข้อความได้ด้วยโปรแกรมประมวลผลคำ แต่การใช้โปรแกรมโอซีอาร์ก็ทำให้เกิดปัญหาอื่นตามมา นั่นคือโปรแกรมโอซีอาร์ไม่สามารถแปลงข้อมูลมาได้ถูกต้องครบถ้วนทั้งหมด โดยเฉพาะโปรแกรมโอซีอาร์ภาษาไทยในปัจจุบันยังมีข้อผิดพลาดอยู่มาก ซึ่งยังไม่เหมาะสมที่จะนำแฟ้มข้อมูลเอกสารที่ได้จากโปรแกรมโอซีอาร์ภาษาไทยนั้นมาใช้งานได้ เพราะต้องทำการแก้ไขข้อมูลในแฟ้มข้อมูลเอกสารให้ถูกต้องเสียก่อน ซึ่งทำให้เสียเวลาและทรัพยากรเป็นจำนวนมาก ซึ่งบางครั้งการพิมพ์เอกสารที่ต้องการขึ้นมาใหม่อาจใช้เวลาน้อยกว่า

ในปัจจุบันได้มีงานวิจัยที่มุ่งแก้ไขข้อผิดพลาดของโปรแกรมโอซีอาร์ด้วยวิธีการใหม่ ๆ อยู่เป็นจำนวนมาก ซึ่งโปรแกรมโอซีอาร์ในต่างประเทศได้มีการพัฒนาไปแล้วอย่างมาก เช่นภาษาอังกฤษ ภาษาจีน และ ภาษาญี่ปุ่น ซึ่งในประเทศไทยเองก็ม้งงานวิจัยที่มุ่งแก้ไขข้อผิดพลาดของโปรแกรมโอซีอาร์ภาษาไทยด้วยวิธีการใหม่ ๆ อยู่บ้าง แต่ไม่ได้รับความสนใจเท่าที่ควรในการนำวิธีการใหม่ ๆ เหล่านี้มาพัฒนาให้เป็นโปรแกรมโอซีอาร์ภาษาไทย

ในวิทยานิพนธ์ฉบับนี้จะมุ่งเน้นในการออกแบบและพัฒนาโปรแกรมโอซีอาร์ภาษาไทย โดยนำเอางานวิจัยที่มีอยู่มาเป็นส่วนประกอบในโปรแกรม เพื่อเป็นการนำเอาวิธีการใหม่ ๆ ในงานวิจัยเหล่านี้มาใช้ในการแก้ปัญหาจริงให้เห็นเป็นรูปธรรม

งานวิจัยและทฤษฎีที่เกี่ยวข้อง

แบบจำลองของโปรแกรมโอซีอาร์ ที่ใช้กันอยู่ทั่วไปมี 3 ขั้นตอน (จุฬารัตน์ [1]) ดังนี้

Pre-Processing → OCR Processing → Post-Processing

รูปที่ 1.1 แสดงแบบจำลองของโปรแกรมโอซีอาร์

1. ขั้นตอนเตรียมประมวลผล (Pre-Processing) จะเป็นขั้นตอนที่ทำการปรับลักษณะและคุณสมบัติต่างๆของรูปภาพเอกสารให้เหมาะสมกับขั้นตอนประมวลผลการรู้จำ โดยวิธีการในขั้นตอนนี้มักจะใช้วิธีทางการประมวลผลรูปภาพ (Image Processing)
 - ข้อมูลนำเข้า : รูปภาพของเอกสาร (Document Image) ที่ได้จากการสแกนหรือเพิ่มข้อมูลรูปภาพที่ได้ทำการสแกนเก็บไว้แล้ว
 - ข้อมูลส่งออก : รูปภาพของเอกสารที่เหมาะสมจะนำไปใช้ในขั้นตอนประมวลผลการรู้จำ
2. ขั้นตอนประมวลผลการรู้จำ (OCR Processing) เป็นขั้นตอนที่ทำการอ่านตัวอักษรหรือการรู้จำตัวอักษรโดยแบ่งได้เป็นขั้นตอนหลักๆ 2 ขั้นตอน คือ
 1. การตัดแยกตัวอักษร (Character Segmentation)
 2. การรู้จำตัวอักษร (Character Recognition)
 ซึ่งขั้นตอนประมวลผลการรู้จำนี้ถือเป็นขั้นตอนหลักของโปรแกรมโอซีอาร์
 - ข้อมูลนำเข้า : รูปภาพของเอกสารที่ได้จากขั้นตอนเตรียมประมวลผล
 - ข้อมูลส่งออก : ลำดับของรหัสตัวอักษร (Text Stream)

3. ขั้นตอนหลังประมวลผล (Post-Processing) เป็นขั้นตอนที่ช่วยในการปรับปรุงผลลัพธ์ที่ได้จากขั้นตอนประมวลผลการรู้จำ ซึ่งวิธีการที่นำมาใช้ในขั้นตอนนี้ก็คือการแก้คำที่สะกดผิด (Spelling Corrector)
- ข้อมูลนำเข้า : ลำดับของรหัสตัวอักษร หรือ เพิ่มข้อมูลที่เก็บลำดับของรหัสตัวอักษรที่ได้จากขั้นตอนประมวลผลการรู้จำ
 - ข้อมูลส่งออก : เพิ่มข้อมูลที่เก็บลำดับของรหัสตัวอักษรที่ได้รับการแก้ไขคำที่สะกดให้ถูกต้องแล้ว

วิธีการที่ใช้ในขั้นตอนเตรียมประมวลผล

จากแบบจำลองของโปรแกรมไอซีอาร์ ขั้นตอนเตรียมประมวลผลนอกจากจะใช้ในการปรับลักษณะและคุณสมบัติต่างๆของรูปภาพเอกสารให้เหมาะสมกับขั้นตอนประมวลผลการรู้จำแล้วยังมีส่วนช่วยในการตัดแยกตัวอักษรและการรู้จำตัวอักษรมีความถูกต้องมากยิ่งขึ้น โดยใช้วิธีการประมวลผลรูปภาพ ซึ่งบางวิธีสามารถทำได้เองด้วยเครื่องคอมพิวเตอร์ แต่บางวิธีจำเป็นต้องใช้มนุษย์เป็นผู้พิจารณา ขั้นตอนเตรียมประมวลผลโดยส่วนใหญ่จะประกอบด้วยวิธีการดังนี้

- **การแปลงระดับความเข้มสีของรูปภาพจากหลายระดับเป็นสองระดับ (Binarization)** เนื่องจากการสแกนรูปภาพนั้น ผู้สแกนสามารถกำหนดจำนวนระดับความเข้มสีของรูปภาพได้ เช่น 256, 16, 4 หรือ 2 ระดับ แต่การแปลงระดับความเข้มสีของรูปภาพนั้นขึ้นอยู่กับว่าขั้นตอนไอซีอาร์โปรแกรมซึ่งนั้นต้องการรูปภาพที่มีจำนวนระดับความเข้มสีเป็นเท่าไร โดยส่วนใหญ่จะใช้รูปที่มีจำนวนระดับความเข้มสี 2 ระดับคือ ขาว และดำ
- **การลดจุดภาพรบกวน (Noise Reduction)** จุดภาพรบกวน เป็นจุดภาพที่เราไม่ต้องการซึ่งเกิดขึ้นในขั้นตอนการสแกนภาพหรืออาจเกิดจากต้นฉบับที่เป็นเอกสารมีจุดปรากฏอยู่ ดังรูปที่ 1.2

ก ก

รูปที่ 1.2 แสดงจุดภาพรบกวนที่ปรากฏในภาพอาจทำให้เกิดความผิดพลาดขึ้นได้

จุดภาพรบกวนมีผลทำให้รูปตัวอักษรเพี้ยนไปจากเดิมและจะทำให้การรู้จำผิดพลาดด้วย จึงมีความจำเป็นจะต้องลดจุดภาพรบกวนเพื่อให้ได้รูปภาพที่ใกล้เคียงตามความเป็นจริง

- **การหมุนภาพ (Rotation)** บางครั้งรูปภาพที่ได้จากการสแกนเอกสารนั้นไม่ตรง อาจเป็นเพราะการสแกนเอียงหรือต้นฉบับเอียง ซึ่งจะทำให้ขั้นตอนประมวลผลการรู้จำนั้น

มีความผิดพลาดเกิดขึ้นได้ จึงต้องทำการหมุนภาพให้กลับมาตรงตามที่ต้องการ ในปัจจุบันมีการนำวิธีการทางสถิติที่เกี่ยวข้องกับการประมาณค่าความเอียงของเอกสาร เพื่อทำการหมุนภาพเอกสารเองด้วยเครื่องคอมพิวเตอร์ เช่น การหาองศาความเอียง โดยใช้สมการถดถอย (ยุทพงษ์ และ กฤษณะ [2]) แต่ในบางครั้งการกำหนดองศาความเอียงของเอกสารโดยผู้ใช้นั้น ได้ผลลัพธ์ที่ดีและง่ายกว่ามาก และหลังจากที่ได้ค่าองศาความเอียงของเอกสารแล้วก็จะทำการหมุนภาพตามค่าความเอียงที่ได้ต่อไป

- **การกลับภาพ (Flipping, Reflection)** เป็นวิธีการกลับภาพให้อยู่ในลักษณะที่ต้องการ ดังรูปที่ 1.3 เป็นการกลับภาพในแนวนอน (Flip Horizontal) และ แนวตั้ง (Flip Vertical) ตามลำดับ

ก ก ย

รูปที่ 1.3 แสดงการกลับภาพในแนวนอนและการกลับภาพในแนวตั้งตามลำดับ

- **การกลับสีของจุดภาพ (Inversion)** เป็นการกลับสีของจุดภาพโดยจะแทนจุดสีดำด้วยสีขาว และแทนจุดสีขาวด้วยสีดำตามรูปที่ 1.4

ก

ก

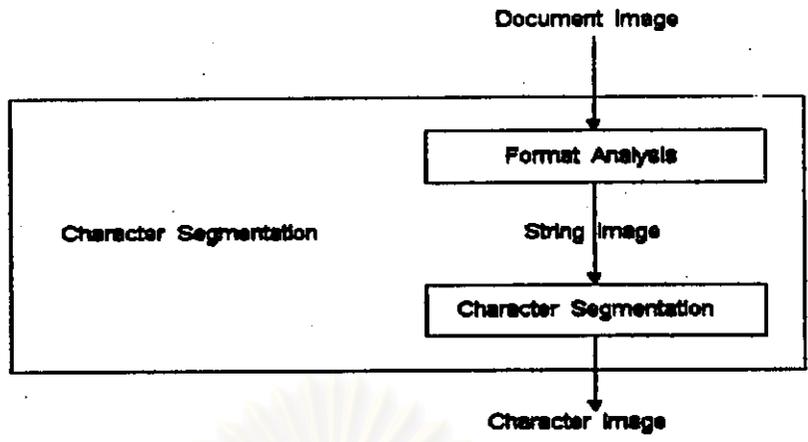
รูปที่ 1.4 แสดงการกลับสีของจุดภาพ

รูปภาพของเอกสารที่จะนำมาใช้ในโปรแกรมโอซีอาร์ จะต้องนำมาพิจารณาก่อนว่า ลักษณะของรูปนั้นยังไม่เหมาะสมกับขั้นตอนประมวลผลการรู้จำอย่างไร จึงจะนำวิธีการต่างๆ ในขั้นตอนเตรียมประมวลผลที่เกี่ยวข้องเหล่านี้ มาใช้ปรับลักษณะให้เหมาะสมต่อไป

วิธีการที่ใช้ในขั้นตอนประมวลผลการรู้จำ

จากแบบจำลองของโปรแกรมโอซีอาร์ ขั้นตอนการรู้จำตัวอักษรแบ่งออกเป็น 2 ขั้นตอน คือ

1. **การตัดแยกตัวอักษร (Character Segmentation)** เป็นขั้นตอนที่ใช้แยกรูปของตัวอักษรออกจากรูปของเอกสารเพื่อส่งให้กับขั้นตอนที่ 2 ต่อไป ในงานวิจัยของ Casey and Lecolinet [3] มีแบบจำลองของการตัดแยกตัวอักษรตามรูปที่ 1.5



รูปที่ 1.5 แสดงแบบจำลองของการตัดแยกตัวอักษร

ซึ่งในงานวิจัยของ Casey and Lecolinet [3] สามารถแบ่งการตัดแยกตัวอักษรออกได้เป็น 3 รูปแบบ คือ

- **Dissection** เป็นรูปแบบที่นิยมใช้ โดยเน้นการพิจารณารูปร่างของตัวอักษร (character-like) คือ ตัวอักษรแต่ละตัวจะต้องสามารถหาขอบเขตได้ชัดเจน และจะได้รูปของตัวอักษรตามขอบเขตนั้น ตามรูปที่ 1.6



รูปที่ 1.6 แสดงรูปที่ได้จากการตัดแยกตัวอักษรแบบ Dissection

- **Recognition-based** เป็นรูปแบบที่ตรงข้ามกับ Dissection โดยจะไม่เน้นที่การพิจารณารูปร่างของตัวอักษร แต่จะคำนึงถึงความเป็นไปได้ในการรู้จำตัวอักษรนั้น ซึ่งรูปแบบนี้จะรวมขั้นตอนการแยกตัวอักษรกับขั้นตอนการรู้จำตัวอักษรเข้าด้วยกัน เพราะการแยกตัวอักษรต้องใช้ความรู้จากขั้นตอนในการรู้จำมาช่วยในการพิจารณาว่าควรจะต้องแยกตัวอักษรที่ใด ดังรูปที่ 1.7

Input Pattern	Windowed Input	Matching Prototype 1	Residue	Matching Prototype 2
กม	ก	ก	ม	
	ก	ก	ม	
	ก	ก	ม	
	ก	ก	ม	
	ม	ม	ก	ก

รูปที่ 1.7 แสดงการแยกตัวอักษรโดยใช้ความรู้จากขั้นตอนการรู้จำตัวอักษร

ซึ่งการพิจารณาว่าควรแยกตัวอักษรที่ใดอาจใช้ความรู้ทางวากยสัมพันธ์ (syntactic) และ อรรถศาสตร์ (semantics) มาร่วมพิจารณาด้วย

- **Holistic** เป็นรูปแบบที่จะพิจารณาถึงความเป็นไปได้ในการรู้จำคำหึ่งคำ ซึ่งเป็น การหลีกเลี่ยงปัญหาที่จะพบในขั้นตอนการรู้จำตัวอักษร แต่รูปแบบ Holistic หาก จะใช้ในงานเอกสารที่มีคำอยู่มากจะต้องใช้ความรู้จากพจนานุกรม (Lexicon) ขนาดใหญ่ จึงนิยมใช้ในงานบางประเภทที่มีคำไม่มาก

จากแบบจำลองของการตัดแยกตัวอักษร (รูปที่ 1.5) จะพบว่าข้อมูลนำเข้าคือรูปภาพของ เอกสาร (Document Image) และจะผ่านขั้นตอนย่อยอีก 2 ขั้นตอน คือ

1. **Format Analysis** เป็นขั้นตอนในการวิเคราะห์โครงสร้างของเอกสาร เช่น ส่วนใด ควรจะเป็นบรรทัดเดียวกัน ส่วนใดเป็นย่อหน้า เป็นต้น แล้วส่งผลลัพธ์ที่เป็นรูป ของบรรทัด (String Image) ไปยังขั้นตอนต่อไป วิธีการที่ใช้ เช่น การตรวจสอบค่า Histogram ของภาพในแนวนอน เพื่อหาพื้นที่ที่มีความน่าจะเป็นสูงที่จะเป็นช่องว่างระหว่างบรรทัด
2. **Character Segmentation** เป็นขั้นตอนที่ทำการแยกรูปตัวอักษร (Character Image) ออกจากรูปภาพของบรรทัดที่ได้จากขั้นตอน Format Analysis มักใช้วิธี การล้อมกรอบตัวอักษร (Bounding Box Analysis) เพื่อกำหนดขอบเขตของตัว อักษรแต่ละตัว

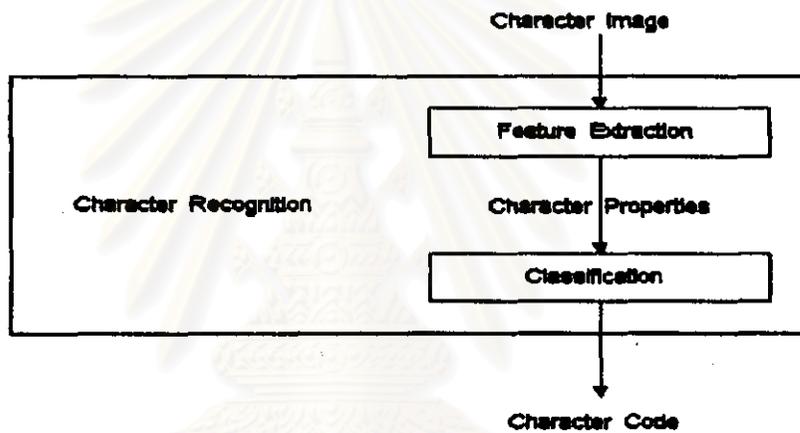
การตัดแยกตัวอักษรโดยเฉพาะตัวอักษรภาษาไทยนั้นจะใช้รูปแบบ Dissection เนื่องจาก เหมาะสมกับลักษณะของตัวอักษรและคำในภาษาไทยมากกว่า แต่เนื่องจากตัวอักษรภาษาไทย นั้นมีหลายระดับและมักเกิดการชนกันของตัวอักษร ดังนั้นจึงเกิดปัญหาในการกำหนดขอบเขตที่ แน่นหนาขึ้น จึงมีงานวิจัยที่เกี่ยวข้องกับการตัดแยกตัวอักษรภาษาไทย เช่น

Premchaiswadi et al. [4] เสนอการตัดแยกตัวอักษรพิมพ์ภาษาไทยที่ติดกันในแนวนอน และแนวตั้ง โดยอาศัยโครงสร้างหลายระดับ (Multi-Level Structure) ของประโยคในภาษาไทย และ Distinctive Features ของตัวอักษรภาษาไทย เพื่อแบ่งระดับของตัวอักษรและใช้ในการ พิจารณาประเภทของการติดกันของตัวอักษร ซึ่งการตัดแยกตัวอักษรจะขึ้นอยู่กับประเภทของการ ติดกันของตัวอักษร

จรรยา และ บุญธีร์ [5] นำเสนอวิธีการแยกตัวอักษรภาษาไทยที่ติดกันโดยวิธี Shortest Path เพื่อมุ่งสร้างระบบการแยกตัวอักษรพิมพ์ภาษาไทย ที่มีลักษณะการติดในแนวนอน และมี จำนวนการติดของตัวอักษร 2 ตัว โดยใช้วิธี Shortest Path ทางตรง และทางเฉียง

Panich et al. [6] เสนอวิธี Segmentation of Connected Character using Distinctive Features of Thai Characters in Thai Character Recognition System โดยแบ่งตัวอักษรไทย ออกเป็นกลุ่มต่างๆ 6 กลุ่มตามระดับของตัวอักษรที่ปรากฏ และแบ่งลักษณะของการติดกันของตัว อักษรทั้ง 6 กลุ่มนั้น ออกเป็น 10 กลุ่ม และได้เสนอวิธีการหาการติดกันของตัวอักษรว่าเกิดขึ้นใน ลักษณะของกลุ่มใด และวิธีการตัดแยกตัวอักษรที่ติดกันนั้น

2. การรู้จำตัวอักษร (Character Recognition) เป็นขั้นตอนที่รู้จำตัวอักษรโดยใช้รูป ของตัวอักษรที่ได้รับจากขั้นตอนการตัดแยกตัวอักษร เพื่อให้ได้รหัสของตัวอักษร ใน งานวิจัยของ Casey and Lecolinet [3] มีแบบจำลองของการรู้จำตัวอักษร ตามรูปที่ 1.8



รูปที่ 1.8 แสดงแบบจำลองของการรู้จำตัวอักษร

จากแบบจำลองของการรู้จำตัวอักษรในรูปที่ 1.8 จะพบว่าข้อมูลนำเข้าคือรูปภาพของตัว อักษร (Character Image) ซึ่งได้รับมาจากการตัดแยกตัวอักษร และจะผ่านขั้นตอนย่อยอีก 2 ขั้น ตอน คือ

1. Feature Extraction เป็นขั้นตอนย่อยที่ใช้ในการแยกลักษณะสำคัญของตัวอักษร เพื่อให้ได้คุณสมบัติเฉพาะของตัวอักษรนั้น (Character Properties)
2. Classification เป็นขั้นตอนที่นำเอาคุณสมบัติเฉพาะของตัวอักษรมาทำการ พิจารณาและแยกแยะตัวอักษรออกตามประเภทและได้ผลลัพธ์คือรหัสของตัว อักษร (Character Code)

งานวิจัยเกี่ยวกับการรู้จำตัวอักษรภาษาไทย เช่น

สุพันธ์ [7] นำเสนอวิธีการรู้จำตัวอักษรลายมือเขียนภาษาไทยโดยการนำหัวของตัวอักษรมาพิจารณาเพื่อทำการจำแนกกลุ่มของตัวอักษรออกเป็นกลุ่มย่อยๆ โดยให้ตัวอักษรที่มีหัวอยู่ในบริเวณเดียวกันอยู่กลุ่มเดียวกัน จากนั้นก็จะพิจารณาเปรียบเทียบตัวอักษรที่อยู่ในกลุ่มของตนเองแตกต่างกันไป ทั้งนี้ขึ้นกับลักษณะเด่นของตัวอักษรที่อยู่ในกลุ่มนั้นๆ ซึ่งทำให้กลุ่มของตัวอักษรที่ต้องเปรียบเทียบมีจำนวนลดลง ทำให้เปรียบเทียบได้อย่างรวดเร็ว

พิพัฒน์ และ มณฑา [8] นำเสนอวิธีการรู้จำตัวอักษรไทยหลายรูปแบบโดยใช้วิธีการไดนามิกโปรแกรมมิ่ง โดยการพิจารณาเส้นแสดงขอบของอักขระโดยนำรหัสทิศทางแบบลูกโซ่ของฟรีแมน กับความแตกต่างของทิศทางของเส้นแสดงขอบอักขระมาใช้ในการตัดแบ่งเส้นแสดงขอบของอักขระออกเป็นส่วนโค้งเว้าและส่วนโค้งนูน เพื่อนำไปใช้ในการเปรียบเทียบแบบไดนามิกโปรแกรมมิ่ง โดยการคำนวณค่าความคล้ายคลึง (Similarity) ของส่วนโค้งเว้าและส่วนโค้งนูนที่ได้กับส่วนโค้งเว้าและส่วนโค้งนูนของตัวอักขระต้นแบบ

สนธยา [9] นำเสนอเรื่องการศึกษาการรู้จำตัวอักษรพิมพ์ภาษาไทยโดยวิธีจีนแทกติก (King Sun Fu [10]) ซึ่งเป็นการศึกษาโครงสร้างของตัวอักษรโดยการเปลี่ยนแปลงเส้นแสดงขอบของตัวอักษรให้อยู่ในรูปรหัสทิศทางแบบลูกโซ่ของฟรีแมน และเปลี่ยนรหัสลูกโซ่เป็นรหัสเวกเตอร์เส้นตรงและวงกลม เพื่อนำมาจัดเก็บเป็นรูปของประโยคที่ประกอบด้วยพรีมิทีฟ (Primitive) ในลักษณะของโครงสร้างแบบต้นไม้ และอาศัยวิธีการวิเคราะห์ประโยคที่ได้จากการเปลี่ยนเส้นแสดงขอบของตัวอักษรเปรียบเทียบกับประโยคของอักขระต้นแบบ โดยเลือกเปรียบเทียบเฉพาะตัวอักษรต้นแบบที่มีหัวของตัวอักษรอยู่ในบริเวณเดียวกันกับหัวของตัวอักษรที่ต้องการรู้จำ และเปรียบเทียบเฉพาะตัวอักษรที่เป็นตัวอักษรอยู่ในระดับเดียวกันเท่านั้น (โดยการระบุเส้นบอกระดับ) สำหรับตัวอักษรที่แตกต่างกันไม่มากจะถูกนำไปเปรียบเทียบทางฟีเจอร์ (feature) อีกครั้งหนึ่งโดยการเก็บลักษณะพิเศษของแต่ละตัวอักษรไว้ หากผลการรู้จำในขั้นต้นไม่อยู่ในเกณฑ์ที่ยอมรับได้ เวกเตอร์ของตัวอักษรจะถูกนำมา ปรับปรุงเพื่อตัดส่วนเกินออก หรือเชื่อมเวกเตอร์ที่อยู่ใกล้เคียงกันเข้าด้วยกันแล้วจึงนำมาทำการรู้จำ โดยวิธีเดิมอีกจนกว่าผลการรู้จำจะอยู่ในเกณฑ์ที่ยอมรับได้หรือไม่สามารถทำการปรับปรุงเวกเตอร์ได้อีก

เดชา [11] นำเสนอเรื่องการรู้จำตัวอักษรพิมพ์ภาษาไทยโดยใช้เทคนิคแบบพีชชีโลจิก และวิธีจีนแทกติก โดยทำการปรับปรุงวิธีการจีนแทกติกของ สนธยา [9] โดยการนำเทคนิคแบบพีชชีโลจิกเข้ามาใช้เมื่อการใช้วิธีการทางจีนแทกติกไม่สามารถรู้จำตัวอักษร รวมทั้งปรับปรุงวิธีการทำตัวอักษรให้บาง (Pavlidis [12]) โดยการใช้วิธีทำตัวอักษรให้บางแบบเอสพีทีเอ (SPTA, Save Point Thinning Algorithm)

อภิญา [13] นำเสนอเรื่องการใช้การโปรแกรมตรรกะเชิงอุปนัยในการรู้จำตัวอักษรพิมพ์ภาษาไทย โดยนำการเรียนรู้โดยการอุปนัยโดยใช้การโปรแกรมตรรกะเชิงอุปนัย (Inductive Logic Programming, ILP) หรือ ไอ แอล พี โดยใช้ความรู้ส่วนหลัง (background knowledge) ในการสร้างสมมติฐานใหม่ทีละจุดคล้อยกับตัวอย่างที่ได้รับ ซึ่งเทคนิคขั้นต้นจะเป็นการพิจารณาโครงสร้างของตัวอักษรโดยทำการเปลี่ยนขอบของตัวอักษรเป็นรหัสทิศทางแบบลูกโซ่ของพรีแมน ทำการเปลี่ยนรหัสทิศทางแบบลูกโซ่ของพรีแมนเป็นเวกเตอร์เส้นตรง และเวกเตอร์วงกลม แล้วทำการเปลี่ยนเวกเตอร์เป็นหน่วยสร้างพื้นฐาน นำการโปรแกรมตรรกะเชิงอุปนัยมาทำการเรียนรู้ลักษณะของหน่วยสร้างพื้นฐานที่ได้จากตัวอักษรต้นแบบ เช่น ระดับของตัว อักษรขนาดของตัวอักษร ลักษณะส่วนหัวของตัวอักษร ลักษณะส่วนปลายของตัวอักษร เป็นต้น

อนเนต [14] นำเสนอเรื่องการใช้การรู้จำตัวอักษรพิมพ์ภาษาไทยโดยใช้เทคนิคด้านการวิเคราะห์ตัวประกอบสำคัญและนิเวรอลเนตเวิร์ก ซึ่งใช้วิธีการแปลงแบบเค-แอล (Karthunen Loeve Transform) เป็นขั้นตอนที่ใช้ในการวิเคราะห์ตัวประกอบสำคัญ ซึ่งจะทำการแปลงข้อมูลภาพให้กลายเป็นข้อมูลเวกเตอร์ ซึ่งลักษณะของตัวอักษรต่างๆในภาพนั้นจะมีข้อมูลเวกเตอร์ที่บ่งบอกถึงลักษณะสำคัญและคุณสมบัติเฉพาะของตัวอักษรที่แตกต่างกัน และใช้นิเวรอลเนตเวิร์กแบบแบคพรอพาเกชัน เป็นขั้นตอนที่นำเอาเวกเตอร์ของตัวอักษรที่ได้ มาทำการพิจารณาและแยกแยะตัวอักษร ในวิทยานิพนธ์ฉบับนี้จะใช้วิธีการของอนเนต [14] เป็นหลักในขั้นตอนการรู้จำ

วิธีการที่ใช้ในขั้นตอนหลังประมวลผล

ผลลัพธ์ที่ได้จากขั้นตอนประมวลผลการรู้จำนั้น อาจไม่ถูกต้องซึ่งจะต้องนำมาแก้ไขก่อนนำไปใช้งานจริง วิธีที่นิยมใช้กันโดยทั่วไปก็คือใช้โปรแกรมตรวจและแก้ไขคำที่สะกดผิด (Spell Corrector) ซึ่งโปรแกรมตรวจและแก้ไขคำที่สะกดผิดโดยทั่วไปจะใช้วิธีค้นหาคำศัพท์ในพจนานุกรมเท่านั้น แต่วิธีการแก้ไขคำผิดที่น่าเสนอโดย อนันต์ลดา และ ชลวิษ [15] จะพิจารณาถึงความถูกต้องด้านภาษาศาสตร์และความผิดพลาดที่มักเกิดขึ้นจากโปรแกรมโอซีอาร์ ร่วมกันในการแก้ไขด้วย โดยใช้ค่าสถิติของไตรแกรมของประเภทของคำ (Part of speech Tri-gram), ค่าความน่าจะเป็นของคำเมื่อรู้ประเภทของคำ (probability of word given part of speech), ค่าสถิติของความผิดพลาดที่เกิดขึ้นจากโปรแกรมโอซีอาร์ และ ค่าสถิติของไตรแกรมของตัวอักษร (Character Tri-gram) เพื่อให้ในการตรวจสอบคำผิดรวมถึงการเลือกคำที่เหมาะสมที่สุดที่จะนำมาใช้แทนคำผิดในประโยค และใช้ระยะแก้ไขแบบเคลื่อนที่ (Dynamic Edit Distance) เพื่อความเหมาะสมในการแก้ไขคำที่มีความสั้นยาวแตกต่างกัน

วัตถุประสงค์

เพื่อออกแบบและพัฒนาโปรแกรมไอซีอาร์ภาษาไทย โดยพัฒนาวิธีการที่ใช้ในขั้นตอนเตรียมประมวลผลและวิธีการตัดแยกตัวอักษร และประยุกต์วิธีการแยกลักษณะสำคัญของตัวอักษร (เค-แอล ทรานส์ฟอร์ม), วิธีการแยกแยะตัวอักษร (นิวรอลเน็ตเวิร์กแบบแมคพรอพาเกชัน) และวิธีการแก้ไขคำที่สะกดผิด (ไตรแกรมของประเภทของคำ) เพื่อให้สามารถทำงานร่วมกับส่วนอื่นๆในโปรแกรม

ขอบเขตของวิทยานิพนธ์

ออกแบบและพัฒนาโปรแกรมไอซีอาร์ภาษาไทย โดยมีความสามารถดังนี้

1. โปรแกรมจะทำงานภายใต้ระบบปฏิบัติการ Microsoft Windows บนเครื่องคอมพิวเตอร์ที่มีข้อกำหนดขั้นต่ำคือ ใช้หน่วยประมวลผลกลางรุ่น Pentium 233 MMX มีหน่วยความจำ 64 เมกกะไบต์ขึ้นไปและเนื้อที่ฮาร์ดดิสก์ที่เพียงพอต่อการทำงานของโปรแกรม
2. สามารถดำเนินการในขั้นตอนเตรียมประมวลผลได้
3. สามารถดำเนินการในขั้นตอนประมวลผลรู้จำได้ ด้วยวิธีการแยกลักษณะสำคัญของตัวอักษร (เค-แอล ทรานส์ฟอร์ม), วิธีการแยกแยะตัวอักษร (นิวรอลเน็ตเวิร์กแบบแมคพรอพาเกชัน)
4. สามารถดำเนินการในขั้นตอนหลังประมวลผลได้ ด้วยวิธีการไตรแกรมของประเภทของคำ
5. สามารถรับข้อมูลภาพเอกสารจากเครื่องสแกนเนอร์ผ่านทางโปรแกรมไอซีอาร์ภาษาไทยได้โดยตรง
6. สามารถเปิดแฟ้มข้อมูลภาพที่ได้ทำการสแกนเก็บไว้ มาทำการประมวลผลรู้จำได้
7. สามารถเก็บแฟ้มข้อมูลตัวอักษรที่ได้จากการประมวลผลรู้จำ เพื่อนำไปใช้งานในโปรแกรมประมวลผลคำทั่วไปได้
8. แฟ้มข้อมูลรูปภาพเอกสารที่จะใช้ในการทดสอบจะต้องมีลักษณะดังนี้
 - แฟ้มข้อมูลรูปภาพเอกสารจะต้องมีสีขาว-ดำ จัดเก็บแบบ BMP
 - ตัวอักษรที่ปรากฏในเอกสารคือ ตัวอักษรพิมพ์ภาษาไทยและภาษาอังกฤษ ตัวเลข พิมพ์ไทยและอาราบิก แบบ AngsanaUPC, BrowalliaUPC, CordiaUPC, DilleniaUPC, EucrosiaUPC และ FreesiaUPC

- ขนาดของตัวอักษรที่จะใช้ทดสอบคือขนาด 14, 16, 18, 20, 22, 24, 28 และ 36 โดยที่ขนาดของตัวอักษรในเอกสารจะต้องมีขนาดเท่ากันทั้งเอกสาร
- รูปแบบของตัวอักษรจะต้องไม่มีรูปแบบเอียง, รูปแบบหนา หรือขีดเส้นใต้

ขั้นตอนการทำวิทยานิพนธ์

1. ศึกษาโปรแกรมโอซีอาร์ภาษาไทย
2. ศึกษางานวิจัยที่เกี่ยวข้องกับการทำงานของโปรแกรมโอซีอาร์ภาษาไทย
3. ออกแบบขั้นตอนการทำงานของโปรแกรมโอซีอาร์ภาษาไทย
4. พัฒนาฐานความรู้ที่เหมาะสมในการรู้จำตัวอักษรที่ใช้กับโปรแกรมโอซีอาร์ภาษาไทย
5. พัฒนาโปรแกรมโอซีอาร์ภาษาไทยตามที่ได้ทำการออกแบบไว้
6. ทดสอบโปรแกรมโอซีอาร์ภาษาไทย และเปรียบเทียบผลกับโปรแกรมโอซีอาร์ภาษาไทยอื่นๆ
7. สรุปผลการทำงาน

ประโยชน์ที่คาดว่าจะได้รับ

1. ได้โปรแกรมโอซีอาร์ภาษาไทยใหม่ที่ใช่วิธีการแยกลักษณะสำคัญของตัวอักษร (เค-แอลทรานส์ฟอร์ม), วิธีการแยกแยะตัวอักษร (นิวรอลเน็ตเวิร์กแบบแบคพรอพากะชัน) และวิธีการแก้ไขคำที่สะกดผิด (ไดรแกรมของประเภทของคำ)
2. สามารถนำโปรแกรมโอซีอาร์ภาษาไทยที่ได้ ไปใช้ในการจัดเก็บข้อมูลจากเอกสารให้อยู่ในแฟ้มข้อมูลแบบรหัสตัวอักษรของระบบคอมพิวเตอร์
3. ได้ฐานความรู้ในการรู้จำตัวอักษรและการแก้ไขคำสะกดผิด ที่เหมาะสมกับโปรแกรมโอซีอาร์ภาษาไทย
4. สามารถนำวิธีการที่ได้จากวิทยานิพนธ์นี้ไปประยุกต์ใช้กับงานอื่นๆได้