


การตัดคำไทยโดยใช้ดิคชันนารีที่มีโครงสร้างข้อมูลแบบแฮชซิง

THAI WORD SEPARATOR USING HASHING DICTIONARY



สรศักดิ์ ไทยแท้
SORASAK THAITAE



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2541

ISBN 974 - 622 - 303 - 8

เลขที่.....
เลขทะเบียน..... 31664
วัน, เดือน, ปี 21 ธ.ค. 2541

THAI WORD SEPARATOR USING HASHING DICTIONARY

SORASAK THAITAE

A THESIS SUBMITTED IN PARTIAL FULFILMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF SCIENCE PROGRAM IN INFORMATION TECHNOLOGY
SCHOOL OF GRADUATE STUDIES
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

1998

ISBN 974 - 622 - 303 - 8

COPYRIGHT 1998

SCHOOL OF GRADUATE STUDIES

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

หัวข้อวิทยานิพนธ์	การตัดคำไทยโดยใช้ดิคชันนารีที่มีโครงสร้างข้อมูลแบบแฮชซึ่ง
นักศึกษา	นายสรศักดิ์ ไทยแท้
อาจารย์ผู้ควบคุมวิทยานิพนธ์	ผศ.ดร.บุญธีร์ เครือตราฐ
หลักสูตร	วิทยาศาสตร์มหาบัณฑิต
สาขาวิชา	เทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ
พ.ศ.	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหาร ลาดกระบัง 2541

บทคัดย่อ

เนื่องจากตัวอักษรไทยมักจะเขียนติดกันไม่มีตัวอักษรพิเศษขึ้นระหว่างคำดังในภาษาอังกฤษ จึงเป็นการยากที่จะทราบว่าผู้เขียนต้องการจะแบ่งคำอย่างไร หรือ คำใดมีคำที่สะกดผิดอยู่ ทั้งนี้การรู้ขอบเขตของคำโดยอัตโนมัติ จะช่วยให้สามารถตรวจสอบคำสะกดได้ถูกต้องและรวดเร็วขึ้นทั้งสามารถทำ index จากคำในข้อความได้ งานวิจัยนี้ได้นำเสนออัลกอริทึมในการสืบค้นคำศัพท์และพยายามตัดแบ่งคำโดยอัตโนมัติโดยใช้พจนานุกรม (Dictionary) ที่มีโครงสร้างแบบแฮชซึ่ง (Hashing) เป็นตัวช่วยในการตัดคำ รวมทั้งได้ออกแบบอัลกอริทึมแบบ Iterative และโครงสร้างข้อมูล Stack ที่ใช้ในการเก็บตำแหน่งคำในการตัดคำแทนแบบเดิมที่เป็น Recursive รวมทั้งพจนานุกรมที่ใช้แบบ Hashing ทำให้สามารถเพิ่มเติมคำได้ง่ายรวมทั้งสามารถเลือกหาคำคล้ายได้สะดวก งานวิจัยนี้ยังได้ทำการเปรียบเทียบการตัดคำและการตรวจสอบคำผิดกับโปรแกรม Commercial คือ Word 6.0 และ Word 7.0 ของบริษัทไมโครซอฟต์รวมทั้งได้รวบรวม ข้อผิดพลาดของ Word 6.0 และ Word 7.0 มาทำการปรับปรุงอัลกอริทึมในงานวิจัยนี้ งานวิจัยนี้มีข้อดีคือสามารถตัดคำได้ทุกตำแหน่ง ถ้าคำๆนั้นมีในพจนานุกรมซึ่งจะพบคำในประโยคที่ถูกต้องตามพจนานุกรมและยังใช้ความยาวมากที่สุดของคำไทยในพจนานุกรม (25 ตัวอักษร) มาช่วยในการเพิ่มความเร็วในการตัดคำโดยทำการพิจารณาคำที่ละ 25 ตัวอักษร นอกจากนี้ยังเพิ่มเติมโครงสร้างพจนานุกรมนี้ให้มีการหยุดตัดคำที่สั้นกว่า 25 ตัวอักษรเมื่อพบว่าคำๆนั้นไม่มีตัวอักษรต่อในพจนานุกรม แต่มีข้อเสียคือในการค้นหาคำจะช้ากว่าโครงสร้างข้อมูลแบบทรี (Trie)

Thesis Title	Thai Word Separator Using Hashing Dictionary
Student	Mr.Sorasak Thaitae
Thesis Advisor	Assistant Professor Dr.Boontee Kruatrachue
Level of Study	Master of Science program in Information Technology
Degree	Faculty of Information Technology King Mongkut's Institute of Technology Ladkrabang
Year	1998

ABSTRACT

Thai alphabet are written adjacent, without any special alphabet between words. Therefore, it is difficult to separate each word in a line, or to detect any misspelling word. Separate words automatically will help both spelling correction and also document indexing. This research present search algorithm and the new Thai word separator using Hashing dictionary, and design the new separator algorithm using iterative instead of recursive with double stack data structure. We can also make word suggestion to the incorrect word with little modification to the dictionary. Hashing dictionary is also easier to add new words. The new algorithm and dictionary has been compared with softwares Word 6.0 and Word 7.0 of Microsoft in both the running time and correctness. The word separable result is correct as long as the words are in the dictionary. The separable speed has been improved by noticing the max number of character per word in the dictionary is 25. The dictionary also mark ended words so that the separator can stop before 25 characters when the ended words are detected. The speed can be improve with trie structure with trade of new words addition flexibility and word suggestion feature.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลงได้ด้วยดีเพราะได้รับความเมตตาจาก ผศ. ดร. บุญธีร์ เครือตราฐ ที่ได้ให้ความกรุณาตลอดเวลา เพื่อให้คำแนะนำและปรึกษาแนวทางการแก้ปัญหาต่าง ๆ ตลอดจนการทำวิจัยนี้ ผู้วิจัย ขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบคุณ บิดา, มารดา, ญาติ ๆ และ คุณเสวริมศรี สุกรินทร์ ที่ให้กำลังใจในการทำวิจัย ขอขอบคุณ ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) ที่ได้เอื้อเฟื้อรายการคำศัพท์ภาษาไทยฉบับราชบัณฑิตยสถาน พ.ศ. 2525

ขอขอบคุณ คุณฉันทนา อุบลพรรณ บรรณารักษ์ห้องสมุด มหาวิทยาลัยมหิดล ที่ได้จัดเตรียมข้อมูลต่าง ๆ ในงานวิจัย

ขอขอบคุณ คุณภวาลย์ ไกรพิรพรรณ , สิทธิศักดิ์ ทองสุข , วรวิทย์ พูลสวัสดิ์ ที่กรุณาให้คำแนะนำเรื่องการเขียนโปรแกรมภาษา C เพื่อเป็นโปรแกรมที่ใช้ในการทดสอบของงานวิจัยนี้ ขอขอบคุณ คุณเกษรา เวียงวะลัย และคุณอนุรัตน์ บุรณะเรศน์ ที่ได้เอื้อเฟื้ออุปกรณ์ในการทำวิจัย

ขอขอบคุณ เพื่อน ๆ วิทยาการคอมพิวเตอร์ รุ่น 1 และพี่ ๆ ทุกคนในคณะเทคโนโลยีสารสนเทศ ที่ให้กำลังใจและช่วยเหลือในงานวิจัยนี้

ขอขอบคุณพี่บุญช่วย และ พี่ ๆ เจ้าหน้าที่คณะเทคโนโลยีสารสนเทศที่ให้การช่วยเหลือด้านต่าง ๆ

สรศักดิ์ ไทยแท้

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญภาพ.....	VIII
บทที่	
1. บทนำ.....	1
ความเป็นมาของงานวิจัย.....	1
ผลงานที่ผ่านมา.....	1
แนวทางของวิทยานิพนธ์.....	6
วัตถุประสงค์ของงานวิจัย.....	7
โครงสร้างของวิทยานิพนธ์.....	7
2. การค้นหาคำในพจนานุกรมตามโครงสร้างข้อมูลแบบต่างๆ.....	8
โครงสร้างข้อมูลพจนานุกรมอิเล็กทรอนิกส์.....	8
โครงสร้างข้อมูลแบบแฮชซึ่ง.....	12
3. แนวทางการออกแบบพจนานุกรมอิเล็กทรอนิกส์.....	18
ประเภทของพจนานุกรมอิเล็กทรอนิกส์.....	18
ลักษณะคำไทย.....	20
โครงสร้างของพยางค์ในภาษาไทย.....	20
ชนิดของหน่วยคำในภาษาไทย.....	21
การวิเคราะห์ตัวอักษรในภาษาไทย.....	22
การออกแบบพจนานุกรมอิเล็กทรอนิกส์.....	24

สารบัญ (ต่อ)

บทที่	หน้า
โครงสร้างในการเก็บค่าในพจนานุกรมอิเล็กทรอนิกส์	25
ขั้นตอนการออกแบบและการสร้างพจนานุกรมอิเล็กทรอนิกส์	25
ผลของการเก็บโครงสร้างพจนานุกรมแบบแฮชซึ่ง.....	29
อัลกอริทึมในการค้นหาค่า.....	37
การออกแบบโครงสร้างพจนานุกรมในการค้นหาค่าคล้าย.....	39
อัลกอริทึมในการค้นหาค่าคล้าย.....	41
4. การตัดคำโดยใช้พจนานุกรมอิเล็กทรอนิกส์.....	43
การวิเคราะห์โครงสร้างพยางค์คำของภาษาไทยในการตัดคำ.....	44
กฎการตัดคำโดยพิจารณาจากอักษรวิธี.....	45
การวิเคราะห์การตัดแบ่งคำโดยการตรวจสอบจากพจนานุกรม.....	46
ผลงานวิจัยการตัดแบ่งโดยการตรวจสอบจากพจนานุกรม.....	47
หลักการตัดแบ่งคำภาษาไทยโดยใช้โครงสร้างพจนานุกรมแบบแฮชซึ่ง.....	49
การถอยหลังเมื่อพบปัญหาหรือคำที่คลุมเครือ (BackTracking).....	52
อัลกอริทึมในการตัดแบ่งคำภาษาไทย.....	54
การตัดแบ่งคำภาษาไทยเมื่อพบคำผิดในเอกสาร.....	56
5. ผลการทดสอบการตัดแบ่งคำและเปรียบเทียบกับ Microsoft Word.....	57
ข้อมูลที่ใช้ในการทดสอบ.....	57
ผลการทดสอบการตัดคำโดยใช้พจนานุกรมกับ Microsoft Word.....	58
6. บทสรุปและข้อเสนอแนะ.....	65
บทสรุป.....	65
ข้อเสนอแนะ.....	66
บรรณานุกรม.....	67

สารบัญ (ต่อ)

หน้า

ภาคผนวก.....	70
ภาคผนวก ก ตารางแอสกี (ASCII).....	72
ภาคผนวก ข ตารางรายการคำที่ MICROSOFT WORD 6.0 ไม่สามารถตัดแบ่งคำได้.....	74
ตารางรายการคำที่ MICROSOFT WORD 7.0 ไม่สามารถตัดแบ่งคำได้.....	94
ภาคผนวก ค บทความทางวิชาการ.....	111
ประวัติผู้เขียน.....	121

สารบัญตาราง

ตารางที่	หน้า
3.1 แสดงการเกิด Collision.....	30
3.2 แสดงขนาดตัวอักษรที่ประกอบเป็นคำ.....	31
3.3 แสดงการแจกแจงการใช้ตัวอักษรเป็นตัวแรก.....	32
3.4 แสดงการแจกแจงการใช้ตัวอักษรเป็นตัวสุดท้าย.....	33
3.5 แสดงการแจกแจงความถี่ของตัวอักษร.....	34
3.6 แสดงการแจกแจงความถี่ของตัวอักษรที่ใช้มากตามลำดับ.....	35
3.7 แสดงจำนวนคำที่ตัวอักษรประกอบเป็นคำมากที่สุด 10 อันดับ.....	37
5.1 แสดงจำนวนคำที่สามารถตัดแบ่งได้และไม่สามารถตัดแบ่งได้.....	58
5.2 แสดงความเร็วในการตัดคำ.....	59

สารบัญภาพ

ภาพที่	หน้า
1.1 แสดงขั้นตอนการตัดแบ่งค่าและการตรวจสอบตัวสะกด.....	2
1.2 แสดงโครงสร้างพจนานุกรมแบบ Table-Table-Index-Search.....	3
1.3 แสดงโครงสร้างพจนานุกรมแบบ Table-Index-Search.....	4
1.4 แสดงโครงสร้างพจนานุกรมแบบ Tree-Structure.....	4
1.5 แสดงการเก็บค่าแบบ Common Factor.....	5
1.6 แสดงโครงสร้างต้นไม้ในการเก็บค่าแบบ Common Factor.....	5
2.1 แสดงโครงสร้างข้อมูลแบบทรี Trie Structure.....	11
2.2 แสดงการแก้ปัญหาการชนกันโดยวิธี Open Addressing.....	16
2.3 แสดงการแก้ปัญหาการชนกันโดยวิธี Chaining.....	17
3.1 แสดงโครงสร้างการเก็บค่าของพจนานุกรม.....	25
3.2 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชซึ่ง.....	26
3.3 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชซึ่ง.....	28
3.4 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชซึ่ง.....	29
3.5 แสดงวิธีการสร้างพจนานุกรมคำคล้าย.....	40
3.6 แสดงวิธีการค้นหาคำคล้ายในพจนานุกรม.....	41
4.1 แสดงค่าตำแหน่งที่สามารถทำการตัดได้ใน Stack.....	50
4.2 แสดงค่าตำแหน่งที่สามารถทำการตัดได้ใน Stack	51
4.3 แสดงค่าตำแหน่งที่สามารถทำการตัดได้ใน Stack	52
4.4 แสดงขั้นตอนตำแหน่งการตัดคำใน Stack ในการทำ BackTracking.....	53

บทที่ 1

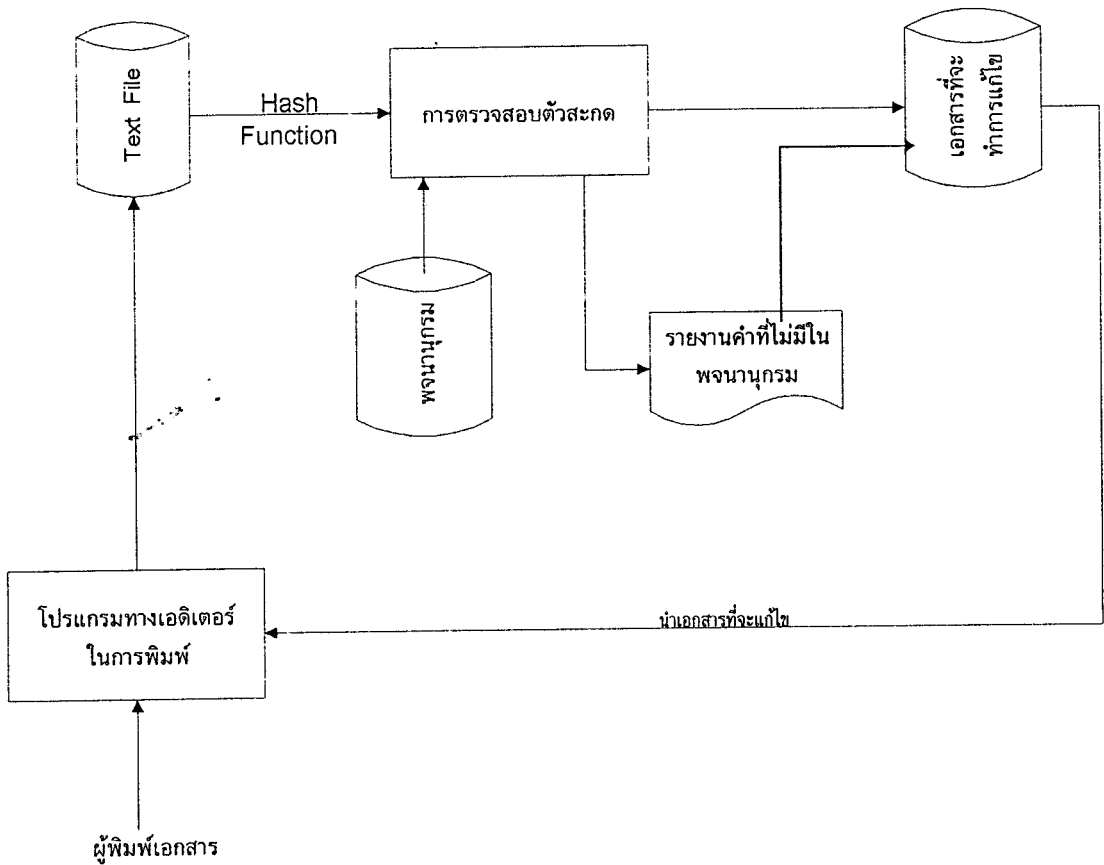
บทนำ

ความเป็นมาของงานวิจัย

ในการพัฒนาการทางด้านคอมพิวเตอร์ เพื่อใช้ในการประมวลผลข้อมูล ได้มีความต้องการมากขึ้น ซึ่งในปัจจุบัน ได้มีการนำเอาคอมพิวเตอร์มาใช้ในการประมวลผลทางด้านภาษามากขึ้น โปรแกรมการตรวจสอบตัวสะกดและการตัดแบ่งพยางค์ ถ้าในภาษาไทยก็เป็นส่วนหนึ่งของการประมวลผลทางด้านภาษา โดยประโยคในภาษาไทยนั้น จะมีการเขียนคำที่ต่อเนื่องติดกัน โดยไม่มีตัวอักษรพิเศษขึ้นระหว่างคำ จนกว่าจะจบประโยค หรือมีการเว้นวรรค หรือ ขึ้นย่อหน้าใหม่ ซึ่งมีความแตกต่างจากคำในประโยคภาษาอังกฤษ ที่มีการแบ่งแยกคำที่ชัดเจน ทำให้เป็นการยากที่จะทำให้ทราบว่าเราควรจะตัดแบ่งคำอย่างไร หรือ มีคำใดที่มีคำสะกดผิดอยู่ในประโยค การทราบขอบเขตของคำในประโยคจึงมีความจำเป็นอย่างยิ่งในการตัดแบ่งคำดังกล่าวอย่างประโยค "เธอมารอกลับบ้าน" เราสามารถทำการตัดแบ่งได้ดังนี้ เธอ * มา * รอ * กลับ * บ้าน หรือ เธอ * มาร * ออก * กลับ * บ้าน หรือ เธอ * มา * รอก * กลับ * บ้าน ซึ่งสามารถแบ่งได้หลายกรณี โดยการตรวจสอบและการตัดแบ่งคำที่มีขึ้นตอน ดังภาพที่ 1.1

ผลงานวิจัยที่ผ่านมา

ผลงานวิจัยในด้านการตัดแบ่งคำภาษาไทยและการสร้างพจนานุกรม อิเล็กทรอนิกส์ ได้มีนักวิจัยผู้มีคุณวุฒิหลายท่านทำการศึกษาค้นคว้าไว้มากมาย ซึ่งจะขอยกตัวอย่างและสรุปวิธีการทำงานพอสังเขป ดังนี้



ภาพที่ 1.1 แสดงขั้นตอนการตัดแบ่งคำ และการตรวจสอบตัวสะกด

1. ผลงานในการสร้างพจนานุกรมภาษาไทย

1.1. ผลงาน วิจัยของ อาจารย์ ยืน ภู่วรรณ และวิวรรณ์ อัมอรมณี เรื่อง "การตรวจสอบตัวสะกดด้วยคอมพิวเตอร์"^[9] ซึ่งได้นำเสนอโครงสร้างพจนานุกรมไว้ 3 แบบ คือ

1.1.1. Table - Table - Linear - Search

โครงสร้างวิธีนี้จะเก็บข้อมูลแบบเรียงต่อกัน

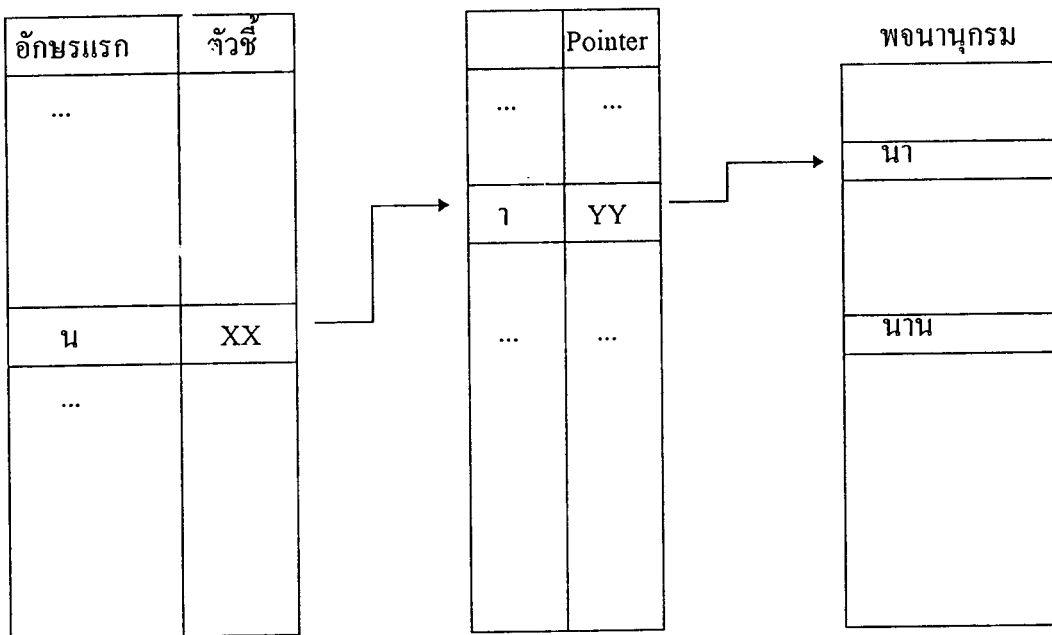
ก _____ 2กา 3กาก 3กาง 6กางกง 3กาง 5กาชาด _____

2กา หมายถึง เลขที่อยู่หน้าคำจะบอกจำนวนตัวอักษรที่ประกอบเป็นคำ

ด้วยวิธีการเรียงพจนานุกรมใช้วิธี Table - Table จะใช้ตารางหน้า 2 ตัวอักษร ดังนั้นโครงสร้างในพจนานุกรมจะลด 2 ตัวอักษรแรก ดังภาพที่ 1.2

ก _____ 01ก 4งก 1จ 3ชาด _____

ถ้าเป็นเลข 0 จะหมายถึงคำ 2 ตัวแรกเป็นคำในพจนานุกรม ตัวอื่นจะบอกความหมายของความยาวของคำในพจนานุกรมไปในตัว โดยลบออกจากสองตัวแรก



ตารางระดับ 1

ตารางระดับ 2

ก-ข แอ โ ไ ใ

จำนวน 49 ตารางๆละ 68 ตัว


ภาพที่ 1.2 แสดงโครงสร้าง พจนานุกรม แบบ Table - Table - Index - Search

1.1.2. Table - Index - Search

โครงสร้างข้อมูลแบบนี้ ยึดหลักการให้ง่ายต่อการลดขนาด โดยเก็บข้อมูลดิคชันนารีมาเรียงติดต่อกัน โดยมีตัวเลขเป็นตัวคั่นระหว่างคำ ดังนี้

_____ 2กา 3กาก 3กาง 6กางก 3กาง 5กาชาด _____

โดยจะเก็บโครงสร้าง ดังภาพที่ 1.3




ภาพที่ 1.3 แสดงโครงสร้างการเก็บพจนานุกรมแบบ Table - Index - Search

ในการค้นหา เช่น ต้องการคำว่า บ้ำง ซึ่งขึ้นต้นด้วยตัว บ การมองตารางระดับ 1 จะบอกได้ว่ากลุ่มอักษรขึ้นต้นด้วยตัว บ อยู่ที่ตำแหน่ง 3800-4150 ดังนั้นเราจะทำ binary search ในตัวชี้ในตารางระดับ 2 ตั้งแต่ 3800-4150 เพื่อหาค่าในพจนานุกรมที่เก็บไว้

1.1.3. Tree Structure

โครงสร้างการเก็บข้อมูลเป็นแบบต้นไม้ (Tree) ดังภาพที่ 1.4



ภาพที่ 1.4 แสดงโครงสร้างการเก็บพจนานุกรม แบบ Tree Structure


1.2. ผลงานวิจัยของ ผศ. ทวีศักดิ์ จันทร์วิทยานุชิต เรื่อง "การตรวจคำผิดในเอกสารภาษาไทย" ^[2] โดยงานวิจัยนี้เก็บโครงสร้างพจนานุกรมแบบต้นไม้ (Tree) โดยมีการนำเสนอวิธีการที่ใช้เลียนแบบ Common Factor ออกมานอกวงเล็บ อย่างพิชคณิต มาทำการจัดเรียงคำในพจนานุกรม ดังภาพที่ 1.5 และ 1.6 คำในพจนานุกรม คือ

สม สมอ สมอง ส้มคร ส้มย สลาดัน สลาย

Common Factor

1. ส(ม มอ มอง ม้คร ม้ย ลาดัน ลาย)
2. ส(ม(\$ อ อ ้คร ้ย) ล (ลาดัน ลาย)
3. ส(ม(\$ อ(\$ ง) ้(คร ย)) ล(ลาดัน ลาย))

ภาพที่ 1.5 แสดงการเก็บคำแบบ Common Factor



ภาพที่ 1.6 แสดงโครงสร้างต้นไม้ในการเก็บแบบ Common Factor

2. ผลงานการตัดแบ่งคำภาษาไทย

2.1. ผลงานวิจัย ของ นายสุรินทร์ จรรยาพรพงษ์ เรื่อง " A Thai Syllable Separation Algorithm " งานวิจัยนี้ได้นำกฎทางอักษรวิธีมาทำการตัดแบ่งคำภาษาไทย โดยมีการกำหนดกฎเกณฑ์ในการตัดแบ่ง 62 ข้อ^[22]

2.2. ผลงานวิจัย ของ อาจารย์ ยืน ภู่วรรณ, สมนึก ศิริโต และสุรศักดิ์ สงวนพงษ์ เรื่อง " การตัดแบ่งพยางค์คำไทยด้วยโครงสร้างข้อมูลแบบต้นไม้ " ผลงานวิจัยได้้นำการพัฒนาปรับปรุงผลงานวิจัย ของ นายสุรินทร์ จรรยาพรพงษ์ มาทำการเก็บกฎการตัดแบ่งคำทั้ง 62 ข้อ เป็นโครงสร้างข้อมูลแบบต้นไม้^[10]

2.3. ผลงานวิจัย ของ อาจารย์ ยืน ภู่วรรณและวิวรรธน์ อัมอรมณ เรื่อง " การแบ่งแยกพยางค์ไทยด้วยดิคชันนารี " เป็นงานวิจัยที่นำเสนอโดยเก็บคำในพจนานุกรม มาทำการเปรียบเทียบกับพจนานุกรม และได้นำเสนอการตัดแบ่งคำที่กำกวม โดยที่มีการย้อนกลับ (Backtrack) ไปตำแหน่งก่อนหน้าเพื่อหาคำที่จะนำมาเปรียบเทียบกับพจนานุกรมต่อ^[8]

2.4. ผลงานวิจัย ของ นายสมนึก ศิริโต เรื่อง " ระบบฐานความรู้เพื่อการวิเคราะห์การแบ่งแยกพยางค์ไทย " ^[13] โดยนำเสนอการพัฒนาโปรแกรมด้วยภาษา Prolog โดยยึดหลักการตัดแบ่งคำที่ใช้กฎของ นายสุรินทร์ จรรยาพรพงษ์

2.5. ผลงานวิจัย ของ อาจารย์ ยืน ภู่วรรณและวิวรรธน์ อัมอรมณ เรื่อง " การตรวจสอบตัวสะกดภาษาไทยด้วยคอมพิวเตอร์ " นำเสนอโดยใช้โครงสร้างข้อมูลที่ท่านอาจารย์ได้ทำการวิจัยมาก่อนหน้า โดยการเก็บข้อมูลคำในพจนานุกรมแบบ Table - Table - Linear - Search^[9]

2.6. ผลงานวิจัย ของ ดร. รัตติกร วรากุลศิริพันธ์และสมศักดิ์ จันวัน เรื่อง " การตัดคำจากประโยคในภาษาไทยด้วยวิธีการเทียบคำที่ยาวที่สุด " โดยนำเสนอการเก็บคำในพจนานุกรมเป็นแบบต้นไม้ (Tree) และนำเสนอการตัดแบ่งคำโดยการคำนวณ Weight ของประโยคที่จะนำมาตัดแบ่ง แล้วทำการเปรียบเทียบกับข้อมูลในพจนานุกรม^[12]

แนวทางของวิทยานิพนธ์

จากผลงานวิจัยการตัดแบ่งคำในภาษาไทย การตรวจสอบตัวสะกด และการสร้างพจนานุกรม อิเล็กทรอนิกส์ ที่ผ่านมา มี 2 แนวทาง คือ วิธีการตรวจสอบตัวสะกด โดยใช้หลักการทางอักษรวิธีและวิธีการตรวจสอบตัวสะกดโดยใช้หลักการเปรียบเทียบกับพจนานุกรม เนื่องจากวิธีการตรวจสอบทางอักษรวิธีนี้ จะสามารถตรวจสอบได้รวดเร็ว แต่ความถูกต้องจะน้อย

เพราะอาจจะพบค่าบางค่าที่เป็นไปตามกฎแต่ไม่มีความหมาย ซึ่งจะพบค่อนข้างมาก ส่วนวิธีการตรวจสอบโดยการเปรียบเทียบกับพจนานุกรมจะมีความถูกต้องสูง แต่ความเร็วจะช้า ส่วนการสร้างพจนานุกรมอิเล็กทรอนิกส์ที่มีการวิจัยที่ผ่านมา จะเป็นการเก็บข้อมูลค่าในพจนานุกรม เป็นแบบโครงสร้างข้อมูลแบบต้นไม้ (Tree) ซึ่งจะมีการปรับปรุงโครงสร้างยาก เมื่อมีการเพิ่มค่าในพจนานุกรม

วิทยานิพนธ์ฉบับนี้ขอนำเสนอการสร้างโครงสร้างการเก็บค่าในพจนานุกรมที่เหมาะสมแก่การตัดคำ โดยมีการเก็บค่าแบบแฮชชิ่ง (Hashing Dictionary) ซึ่งโครงสร้างนี้จะทำให้ค้นหาค่าได้รวดเร็ว และยังสะดวกต่อการปรับปรุงพจนานุกรม เมื่อเกิดค่าใหม่ และยังได้นำเสนอวิธีการตัดแบ่งคำโดยใช้อัลกอริทึมแบบ Hashing มาช่วยในการตัดแบ่งคำและขอบเขตของคำ รวมทั้งทำการปรับปรุงอัลกอริทึมที่เป็นการตัดคำแบบเดิมที่เป็นแบบ Recursive มาเป็นอัลกอริทึมที่เป็นแบบ Iterative แทนซึ่งจะสามารถทำการตรวจสอบได้ทุกตำแหน่งของประโยค โดยมีโครงสร้างข้อมูลแบบ Stack ช่วยในการเก็บตำแหน่ง คำในการตัดแบ่งคำ

วัตถุประสงค์ของงานวิจัย

1. สามารถทำการตัดคำที่พบในพจนานุกรมในประโยคได้รวดเร็ว
2. สามารถเพิ่มเติมค่าได้รวดเร็ว
3. สามารถค้นหาคำคล้ายได้สะดวก เมื่อพบคำที่ผิด
4. ทำการศึกษาข้อผิดพลาดของ Software Word และนำมาปรับปรุงในงานวิจัยนี้ รวมทั้งเปรียบเทียบความเร็วในการตัดคำด้วย
5. ใช้หน่วยความจำอย่างมีประสิทธิภาพ แต่จะเห็นที่ความเร็วเป็นหลัก

โครงสร้างของวิทยานิพนธ์

โครงสร้างของวิทยานิพนธ์ ประกอบด้วย 5 ส่วน คือ บทที่ 2 กล่าวถึง การค้นหาค่าในพจนานุกรมตามโครงสร้างข้อมูลแบบต่างๆ , บทที่ 3 กล่าวถึง แนวทางการออกแบบพจนานุกรมอิเล็กทรอนิกส์ภาษาไทย , บทที่ 4 กล่าวถึง การตัดคำโดยใช้พจนานุกรมอิเล็กทรอนิกส์ภาษาไทย, บทที่ 5 กล่าวถึง ผลการทดสอบการตัดแบ่งคำภาษาไทย และการเปรียบเทียบกับ Word , บทที่ 6 สรุปผลและข้อเสนอแนะ

บทที่ 2

การค้นหาค่าในพจนานุกรมตามโครงสร้างข้อมูลแบบต่างๆ

โครงสร้างข้อมูลสำหรับพจนานุกรมอิเล็กทรอนิกส์

โครงสร้างข้อมูลจะหมายถึงการจัดรูปแบบและระเบียบของข้อมูลให้ทราบถึงขอบเขตซึ่งจะนำมาอยู่ในหน่วยความจำ ดังนั้นการออกแบบโครงสร้างข้อมูลที่ดีจะทำให้เกิดการเอื้ออำนวยต่อการประมวลผลของคอมพิวเตอร์ ดังนี้

- ก. ทำให้การใช้หน่วยความจำมีประสิทธิภาพ
- ข. สามารถนำข้อมูลที่ต้องการใช้มาประมวลผลได้อย่างรวดเร็ว
- ค. สามารถทำการค้นหาค่าได้รวดเร็ว
- ง. สามารถปรับปรุงเพิ่มค่าในพจนานุกรมง่ายและพัฒนาได้อย่างมีประสิทธิภาพ

ในโครงสร้างข้อมูลในการค้นหา (Search) ที่สามารถใช้กับพจนานุกรมอิเล็กทรอนิกส์ได้มีหลายแบบ โดยแต่ละแบบจะมีความแตกต่างกันในเรื่องขนาดและความเร็วในการค้นหา ซึ่งในที่นี้จะขอพูดรายละเอียดของแต่ละโครงสร้างข้อมูลอย่างคร่าวๆ จนถึงโครงสร้างข้อมูลที่ได้นำมาใช้ในงานวิจัยที่เลือกใช้อย่างละเอียดโดยงานวิจัยนี้จะเลือกใช้โครงสร้างข้อมูลแบบแฮชซิง (Hashing)

1. โครงสร้างข้อมูลแบบลำดับ (Sequential List) เป็นเทคนิคที่มีการค้นหาค่าที่ง่ายที่สุด ซึ่งในการเก็บค่าไม่จำเป็นต้องมีการเรียงลำดับค่าในพจนานุกรม โดยการอ่านค่าจากพจนานุกรมแล้วทำการเปรียบเทียบค่านั้นว่าตรงกับค่าที่ต้องการหาหรือไม่ โดยทำการไล่ทีละ 1 ค่าจนกว่าจะพบค่าที่ต้องการหา เวลาที่ใช้ในการค้นหาอย่างช้า (worst case) ของอัลกอริทึมเป็น $O(n)$ ^[24] อัลกอริทึมของ Sequential Search

```

SU1 : [เริ่มต้น]      i = 0;
SU2 : [จบหรือไม่]     IF i >= n
                       { break; }           ( ไม่พบ )
SU3 : [เปรียบเทียบ]  IF KEY = LIST[i]
                       { break; }           ( พบ )
SU4 : [Loop]          i = i + 1;
                       ไป Step SU2;

```

โดยที่ LIST เป็น อะเรย์ที่เก็บค่าในพจนานุกรม
n เป็น จำนวนค่าทั้งหมดในพจนานุกรม
KEY เป็น ค่าที่ต้องการค้นหา

2. โครงสร้างข้อมูลแบบเรียงลำดับ (Sorted List) จะเป็นโครงสร้างที่มีการค้นหาเหมือน Sequential Search โดยมีการเรียงลำดับค่าในพจนานุกรมมาแล้ว
อัลกอริทึมของ Sorted List

```

SO1 : [เริ่มต้น]      i = 0;
SO2 : [จบหรือไม่]     IF i >= n
                       { break; }           ( ไม่พบ )
SO3 : [เปรียบเทียบ]  IF KEY = LIST[i]
                       { break; }           ( พบ )
SO4 :                 IF KEY < LIST[i]
                       { break; }           ( ไม่พบ )
SO5 : [Loop]          i = i + 1;
                       ไป Step SO2;

```

3. โครงสร้างข้อมูลแบบดรรชนี (Indexed List) เป็นการเพิ่มความเร็วให้กับ
โครงสร้างข้อมูลแบบลำดับ โดยจะมีการออกแบบเป็น 2 ส่วน ส่วนแรกจะเก็บตัวอักษรแรก
ของแต่ละค่าในพจนานุกรม ซึ่งจะมีตัวชี้ (Index) ค่าในพจนานุกรม ส่วนที่สองจะเก็บค่าทั้งหมด
ในพจนานุกรม และทำการค้นหาค่าที่ต้องการจากการพิจารณาตัวอักษรแรกของค่าที่ต้องการ

การหาค่าก่อน เพื่อเปรียบเทียบกับส่วนแรกที่เก็บก่อน เมื่อพบจะทราบขอบเขตค่าที่ต้องการหาและทำการเปรียบเทียบต่อในส่วนที่สอง ทำให้จะไม่เสียเวลาเหมือนการค้นหาแบบ Sequential Search ซึ่งสามารถศึกษาโครงสร้างแบบนี้ได้จากผลงานวิจัยเรื่อง “ การตรวจสอบตัวสะกดด้วยคอมพิวเตอร์ ” ของอาจารย์ ยืน ภู่วรวรรณและวิวรรธน์ อิ่มอารมณ^[9]

4. โครงสร้างข้อมูลแบบเรียงลำดับที่มีการค้นหาแบบทวิภาค^[24] (Binary Search) การค้นหาแบบนี้จะเป็นการแก้ไขข้อเสียของการค้นหาแบบซีควเอนเชียล เพราะถ้าหากค่าที่ต้องการค้นหาพบอยู่หลังสุดจะต้องเสียเวลาค้นหานาน แต่การค้นหาแบบทวิภาคนี้จะมีการเรียงค่าอยู่แล้ว วิธีการค้นหาจะแบ่งค่าในพจนานุกรมเป็น 2 ส่วน แล้วนำค่าที่พบในตรงกลางมาเปรียบเทียบกับค่าที่ต้องการค้นหา ถ้าค่าที่อยู่ตรงกลางในพจนานุกรมมีค่ามากกว่าแสดงว่าค่าที่ต้องการจะอยู่ก่อนค่ากลางนี้ จากนั้นนำค่าทั้งหมดของครึ่งแรกมาแบ่งเป็น 2 ส่วน นำค่าตรงกลางการแบ่งมาเปรียบเทียบ ทำเช่นนี้ไปเรื่อยๆจนกว่าจะพบค่าที่ต้องการหรือไม่สามารถหาค่านั้นได้ เวลาที่ใช้ในการค้นหาของอัลกอริทึมเป็น $O(\log n)$

อัลกอริทึมของการค้นหาแบบทวิภาค (Binary Search)


B1	: [เริ่มต้น]	lower = 0; upper = n-1;	
B2	: [จบหรือไม่]	IF upper < lower	
		{ break; }	(ไม่พบ)
B3	: [ค่ากลาง]	i = $\lfloor (lower + upper) / 2 \rfloor$;	
B4	: [เปรียบเทียบ]	IF KEY = LIST[i]	
		{ break; }	(พบ)
B5	: [เลื่อนค่า]	IF KEY < LIST[i]	
		{ upper = i-1; }	
		ELSE	
		{ lower = i+1; }	
B6	: [Loop]	ไป Step B2	

5. โครงสร้างข้อมูลแบบต้นไม้ (Tree Structure) เป็นโครงสร้างที่มีระดับ (Hierarchical Structure) ซึ่งจะเก็บค่าในพจนานุกรมเป็น node โดยมีการเรียงลำดับค่าของค่าต่างๆเป็นระดับชั้น (Level) ในการประยุกต์ใช้กับการเก็บค่าในพจนานุกรมทั้งหมดจะพบปัญหา

ทำให้ได้มีการออกแบบโครงสร้างข้อมูลแบบทรี (Trie Structure) ซึ่งเป็นพื้นฐานมาจากโครงสร้างข้อมูลแบบต้นไม้ โดยมีการเก็บคำแต่ละคำเป็น node ของตัวอักษรที่ประกอบกันเป็นคำ ซึ่งจะมีการเชื่อมโยงกันกับตัวอักษรถัดไปของคำ ซึ่งการเก็บอักษรของ node จะมีการเก็บแบบ multiarray ดังภาพที่ 2.1 จะทำให้มีการค้นหาที่รวดเร็วกว่าการเก็บโครงสร้างแบบต้นไม้ เวลาที่ใช้ในการค้นหาของอัลกอริทึมเป็น $O(\log n)$ ^[24]

ตัวอย่างการเก็บคำในโครงสร้างข้อมูลแบบทรี

คำว่า กา, การ, การก, การณ์, ...



ภาพที่ 2.1 แสดงโครงสร้างข้อมูลแบบทรี (Trie Structure)

โครงสร้างข้อมูลแบบแฮชชิง (Hashing)

เป็นวิธีการค้นหาที่รวดเร็วซึ่งมีเวลาที่ใช้ในการค้นหาของอัลกอริทึมเป็น $O(n)$ ^[24] โดยวิธีแฮชชิงนี้เป็นเทคนิคในการสร้างตารางโดยที่มีค่าคีย์มาช่วยในการค้นหาข้อมูล ซึ่งทำได้ง่ายและรวดเร็ว การแฮชชิงจะใช้วิธีการเปลี่ยนค่าของข้อมูลเป็นค่าของแอดเดรสโดยอาศัยฟังก์ชัน ที่เรียกว่า "แฮชชิงฟังก์ชัน" (Hashing Function หรือ Key - to - Address Transformation) ดังนั้นการกระจายของข้อมูลจะขึ้นกับการเลือกใช้ฟังก์ชันที่เหมาะสม แต่ในบางครั้งการแปลงค่าของข้อมูลจะมีค่าแอดเดรสออกมาตรงกัน ซึ่งเรียกว่า "การชนกัน" (Collision) ส่วนประกอบที่สำคัญของโครงสร้างข้อมูลแฮชชิง คือ

1. Hash Table
2. Hash Function

การสร้างฟังก์ชันแฮชชิง

1. Modular Division

$$H(x) = x \text{ mod } M$$

โดยที่ x เป็นค่าของข้อมูล

M เป็นขนาดของ Table (prime number)

2. Polynomial Addressing

ถ้ามีค่าของข้อมูลเป็นตัวอักษรในคำที่มีความยาว L ของคำ วิธีการนี้จะสามารถทำงานได้อย่างมีประสิทธิภาพ โดยมีการคำนวณตาม ASCII ของตัวอักษร

ซึ่งจะเขียนเป็นสูตรทั่วไปได้ ดังนี้

$$H(x) = \text{base}^{(L-1)} * x_1 + \text{base}^{(L-2)} * x_2 + \dots + x_L$$

L - ความยาวของคำ

base - เป็นค่าตัวอักษรทั้งหมดในตาราง ASCII

เช่น การ

$$H(x) = \text{base}^{2*'}ก' + \text{base}^{1*'}า' + 'ร'$$

โดยจากสูตรทั่วไปของ Polynomial นี้สามารถเขียนเป็นโครงสร้างได้ดังนี้

$$h = x_i;$$

For (I=2; I <= L; I++)

$$\{ h_i = (h * \text{base} + x_i) \bmod \text{Size} ; \}$$

size - ขนาดของ Table Hashing (Prime Number)

3. Multiplication

$$H(x) = \text{floor}(\text{Size} * (k * x - \text{floor}(k * x)))$$

โดยที่ k เป็นค่า $0 < k < 1$

Size เป็นขนาด Table

การแก้ปัญหาคอลลิชัน^[3] (Collision)

จากการใช้แฮชซึ่งฟังก์ชัน จะพบการชนกันของข้อมูลอยู่บ้าง ทำให้เกิดปัญหาในการค้นหาข้อมูล ซึ่งจะมีการแก้ไขดังนี้

1. Open - Addressing
2. Chaining

วิธีการ Open - Addressing (ภาพที่ 2.2)

1. Linear Probing เป็นวิธีที่ง่ายที่สุด คือ ถ้าพบว่ามี การชนกันของข้อมูลเกิดขึ้นให้บวกค่าคงที่เข้ากับ $H(x)$

$$H(x) = H(x) + C$$

อัลกอริทึมของ Linear Probing มีดังนี้

```

HI1 : [ ค่าเริ่มต้น ]      loc = H(KEY);
HI2 : [ การตรวจสอบ ]      IF ( HLIST [ loc ] == EMPTY )
                            THEN HLIST[loc] = KEY ; (เก็บค่า)
                              ไปที่ HI1;
HI3 : [ การเลื่อน ]        loc = loc + 1;
                              IF ( loc == M )
                                THEN loc = 0;
HI4 : [ Loop ]            ไปยังขั้น HI2 ;
  
```

โดยที่	loc	เป็นค่าตำแหน่งการ Hash
	H(KEY)	Hashing Function
	KEY	ข้อมูล
	HLIST	อะเรย์ในการเก็บค่า
	M	ขนาด Table

2. Random Probing

$$H_{i+1}(x) = (H_i(x) + C) \bmod M$$

อัลกอริทึมของ Random Probing มีดังนี้

1. คำนวณค่าเริ่มต้น
2. ถ้าค่าเริ่มต้นที่คำนวณได้เป็นค่าแอดเดรสที่ยังว่างให้ใส่ค่าลงไปแอดเดรสแล้วออก

จากโพรซีเจอร์นี้

3. ทำซ้ำถึงข้อ 5 จนกว่าจะพบแอดเดรสว่าง
4. คำนวณหาแอดเดรสที่ว่างจากสูตร Random Probing
5. ถ้าทุกแอดเดรสถูกตรวจสอบแล้วว่าไม่ว่างให้เขียน Overflow ออกจากโพรซีเจอร์
6. ใส่ค่าในแอดเดรสนี้ แล้วออกจากโพรซีเจอร์

3. Double Hashing เป็นการใช้ฟังก์ชัน 2 ฟังก์ชัน โดยมีฟังก์ชันหนึ่งเป็นฟังก์ชันอิสระ และอีกฟังก์ชันจะเป็นการเลือกจากค่า Random Probing

ตัวอย่างเช่น สมมติว่ามีฟังก์ชัน H_1 ที่ $H_1(x_1) = H_1(x_2) = i$ เมื่อ $x_1 \neq x_2$ และถ้ามีฟังก์ชัน G_1 ที่ $G_1(x_1) \neq G_1(x_2)$ เมื่อ $x_1 \neq x_2$ เราจะใช้ $G_1(x_1)$ หรือ $G_1(x_2)$ เป็นค่าพารามิเตอร์ c (ค่าคงที่) เมื่อนำไปใช้กับวิธี random probing จะได้ค่าที่แตกต่างกันเมื่อ H_1 และ G_1 ต่างก็เป็นอิสระกัน

ถ้าให้ $H_1(x) = x \text{ MOD } m$ และ $G_1(x) = (x \text{ MOD } (m-2)) + 1$ เมื่อ x เป็นค่าคีย์ และ m เป็นขนาดตาราง ถ้า $x = 75$ และ $m = 11$ จะได้ $H_1(75) = 9$ และ $G_1(75) = 4$

เมื่อนำมาประยุกต์ใช้กับ random probing โดยใช้สูตร

$$H_{i+1}(x) = (H_i(x) + c) \text{ MOD } 11$$

เมื่อ $i = 1$ จะได้ $H_1(75) = 9$ และ $c = G_1(75) = 4$

เมื่อค่า $i = 1, 2, 3, \dots$ จะได้ผลลัพธ์ของ $H_i(75)$ ดังนี้

$$9, 2, 6, 10, 3, 7, 0, 4, 8, 1, 5$$

และสมมติว่ามีคีย์ถัดไปเป็น 42

$$H_1(42) = 9 \text{ (ค่าเดียวกับ } H_1(75) \text{ แต่ } G_1(42) = 7 = c)$$

เมื่อใช้วิธี random probing

$$H_{i+1}(x) = (H_i(x) + c) \text{ MOD } 11$$

แทนค่าเริ่มต้น เมื่อ $i = 1$ จะได้ $H_1 = 9$ และ $c = 7$

เมื่อค่า $i = 1, 2, 3, \dots$ จะได้ผลลัพธ์ของ $H_i(42)$ ดังนี้

$$9, 5, 1, 8, 4, 0, 7, 3, 10, 6, 2$$

จะเห็นว่าถ้าเกิดการชนกัน $H_1(75) = H_1(42) = 9$ ถ้าใช้วิธีนี้จะได้ค่าที่แตกต่างกัน

วิธีการ Chaining (ภาพที่ 2.3)

เป็นวิธีที่นิยมกันมาก โดยมีลิงค์ลิสต์มาช่วย ซึ่งจะแบ่งการ Chaining เป็น 2 ส่วน คือ ส่วนแรกจะมีขนาดคงที่ โดยจะเป็นลักษณะของอะเรย์ ส่วนที่สองจะเป็นพอยน์เตอร์ในการชี้ค่าที่มีแอดเดรสเดียวกันกับค่าของแอดเดรสข้อมูลแรก ซึ่งในงานวิจัยนี้ใช้วิธีนี้ในการแก้ไขปัญหาการชนกันของข้อมูล

ตัวอย่างการแก้ปัญหาการชนกันของค่า

ชาติ, นักร, ป็ชชุน, ยอก, เลียบเคียง, ทรนง, สบู่, นิบาค

การคำนวณแฮชผ่านฟังก์ชันแฮชซึ่ง

$$H_{i+1} = ((H_i * 67) + X_{i+1}) \text{ mod } 32761$$

H - ค่า Hashing

X - Ascii ของตัวอักษรถัดไปในค่า

คำนวณรอบตามตัวอักษรที่ประกอบเป็นค่าจะพบว่า

คำว่า	ชาติ	มีแฮชเป็น	1
คำว่า	นักร, เลียบเคียง	มีแฮชเป็น	2
คำว่า	ป็ชชุน, สบู่	มีแฮชเป็น	11
คำว่า	ทรนง, นิบาค, ยอก	มีแฮชเป็น	26

ค่าแฮช


จำนวน Prob

1	ชาติ		1
2	นักร		1
3	เลียบเคียง		2
...			
11	ป็ชชุน		1
12	สบู่		2
...			
26	ทรนง		1
27	นิบาค		2
28	ยอก		3
...			

ภาพที่ 2.2 การแก้ปัญหาการชนกันโดยวิธี Open Addressing

ค่าแอดเดรส

ค่าในพจนานุกรม



ภาพที่ 2.3 แสดงการแก้ปัญหาการชนกันโดยวิธี Chaining

บทที่ 3

แนวทางการออกแบบพจนานุกรมอิเล็กทรอนิกส์

พจนานุกรมอิเล็กทรอนิกส์ เป็นแหล่งข้อมูลในด้านภาษาศาสตร์ ที่จำเป็นสำหรับการประมวลผลภาษาธรรมชาติ ^[7] พจนานุกรมที่จัดเก็บลงในคอมพิวเตอร์ จึงมีบทบาทที่สำคัญเพิ่มมากขึ้น ในงานประมวลผลดังนั้นการเก็บพจนานุกรมอิเล็กทรอนิกส์ จึงมีบทบาทเป็นอย่างมาก ในการค้นหา คำ ส่วนรายละเอียดของพจนานุกรมก็จะแตกต่างกันออกไปตามแต่การใช้งานต่าง ๆ

ประเภทของพจนานุกรมอิเล็กทรอนิกส์ อาจแบ่งเป็น

1. ประเภทผู้ใช้งาน

- 1.1. พจนานุกรมอเนกประสงค์ (General Dictionary) เช่น พจนานุกรมฉบับราชบัณฑิตยสถาน พจนานุกรมนักเรียน
- 1.2. พจนานุกรมศัพท์เทคนิค (Technical Dictionary) เก็บข้อมูลคำศัพท์เฉพาะสาขา เช่น ทางการแพทย์, วิศวกรรม, คอมพิวเตอร์
- 1.3. พจนานุกรมเล็กชิคอน (User Specific Lexicon) เก็บข้อมูลศัพท์เฉพาะงานใดงานหนึ่งโดยเฉพาะ เช่น พจนานุกรมสำหรับงานแปลภาษา

2. ตามคู่ภาษา (Classify by Language Pairs)

- 2.1. พจนานุกรมที่มีคู่ภาษาเพียงภาษาเดียว (Mono - Lingual Dictionary) เช่น พจนานุกรมฉบับราชบัณฑิตยสถาน พจนานุกรมของลองแมน
- 2.2 พจนานุกรมที่มีคู่ภาษา 2 ภาษา (Bilingual Dictionary) เช่น พจนานุกรมไทย - อังกฤษ

2.3. พจนานุกรมที่มีคู่ภาษามากกว่า 2 ภาษา (Multilingual Dictionary)

3. เนื้อหาของข้อมูลที่บันทึก

3.1. พจนานุกรม (Dictionary)

3.2. เล็กซีคอน (Lexicon)

3.3. พจนานุกรมคำพ้อง (Thesaurus)

3.4. สารานุกรม (Encyclopedia)

4. ตามกลุ่มผู้ใช้

4.1. พจนานุกรมสำหรับมนุษย์ (Dictionary for Human)

4.2. พจนานุกรมสำหรับเครื่องใช้ (Dictionary for Computer)

รายละเอียดข้อมูลในพจนานุกรมอิเล็กทรอนิกส์

พจนานุกรมอิเล็กทรอนิกส์มีมากมายหลายประเภทขึ้นอยู่กับวัตถุประสงค์ของผู้ใช้งานเพราะฉะนั้นเนื้อหาในการเก็บรายละเอียดก็จะแตกต่างกันไป ดังนั้นหากว่ามีพจนานุกรมอิเล็กทรอนิกส์ที่สามารถเก็บรายละเอียดข้อมูลทุกอย่างที่สามารถนำไปใช้งานหลายๆด้านก็จะทำให้พจนานุกรมนั้นมีประสิทธิภาพในการใช้งานสูง สำหรับรายละเอียดที่สามารถเก็บในพจนานุกรมอิเล็กทรอนิกส์ได้ เราอาจจะแบ่งเป็นการเก็บของ

ก. คำหรือหน่วยคำ

ข. ข้อมูลระดับคำ และการแบ่งแยกคำและพยางค์

ค. ข้อมูลเกี่ยวกับการผันของคำ

ง. รายละเอียดเกี่ยวกับการผันของคำ

จ. การออกเสียง

ฉ. ชนิดของคำ

ช. ความถี่ที่ใช้และความสำคัญของคำ

ซ. ข้อมูลเกี่ยวกับลักษณะของคำ

ฅ. โครงสร้างของไวยากรณ์

ญ. คำพ้องความหมาย

ฎ. การเชื่อมโยงในคำ และ ไวยากรณ์

ฯลฯ

รายละเอียดของพจนานุกรมอิเล็กทรอนิกส์ที่กล่าวมาในตอนต้นนี้ เราอาจจะมีแบ่งรายละเอียดในการเก็บได้อีกมาก ขึ้นอยู่กับการใช้งานที่จำเป็นในทางการประมวลผลข้อมูลด้านภาษาศาสตร์

ลักษณะของคำไทย^[14]

คำในภาษาไทยนั้นมีการแบ่งเป็น 2 ประเภท คือ

ก. คำโดด หมายถึง คำเดี่ยวที่มีความหมายในตัวเอง เช่น ยืน เดิน วิ่ง

ข. คำประสม หมายถึง คำที่เกิดจากการนำคำโดดมารวมกันแล้วเกิดคำใหม่ที่มีความหมาย เช่น เรือใบ น้ำตก

นอกจากนี้การแบ่งคำในภาษาไทยยังแตกต่างจากการแบ่งคำในภาษาอังกฤษ เนื่องจากวิธีการเขียนประโยคภาษาไทยนั้นเขียนติดต่อกันโดยไม่มีช่องว่างดังการเขียนประโยคในภาษาอังกฤษ ซึ่งมีการเขียนที่มีช่องว่างระหว่างคำ ทำให้ไม่สามารถทราบถึงตำแหน่งสิ้นสุดคำในประโยคภาษาไทยที่แน่นอน เพราะฉะนั้นการเลือกโครงสร้างข้อมูลสำหรับการเก็บพจนานุกรมและวิธีปฏิบัติการจะต้องนำลักษณะคำไทยและการแบ่งคำมาเป็นหลักการพิจารณาด้วย

โครงสร้างของพยางค์ในภาษาไทย

คำไทยส่วนใหญ่จะเป็นคำพยางค์เดี่ยว (Monosyllable) แต่จะมีบางคำที่มีหลายพยางค์ เราสามารถแบ่งโครงสร้างพยางค์ของภาษาไทยได้ 3 กลุ่ม คือ

1. โครงสร้างของคำพยางค์เดี่ยว จะแบ่งเป็น 2 ลักษณะ

ว

1.1) พ (พ) ส พ เช่น จน, เป็น, กรุง ฯลฯ

ว

1.2) พ (พ) ส:(พ) เช่น อย่า, ปลา, ก้าว

โดยที่ พ ----- พยัญชนะ
 (พ) ----- พยัญชนะควบกล้ำ อาจจะมีหรือไม่มีก็ได้
 ส ----- สระเสียงสั้น
 ส : ----- สระเสียงยาว
 ว ----- วรรณยุกต์

2. โครงสร้างของคำสองพยางค์ จะเป็นการประสมของคำพยางค์เดียว จะมีรูปแบบ 2 ลักษณะ คือ

- 2.1. พวกที่มีพยางค์แรกเป็นสระเสียงสั้น ได้แก่ สนั่น, สะกิด, กะพริบ ฯลฯ
- 2.2. พวกที่มีพยางค์แรกเป็นสระเสียงยาวหรือมีตัวสะกด ได้แก่ กากี, มานพ, กันดาร, วันที ฯลฯ

3. โครงสร้างของคำสามพยางค์ขึ้นไป มักจะเป็นคำประสมหรือคำที่ยืมมาจากภาษาอื่น ได้แก่ ไวโอลิน, วิทยาลัย

ชนิดของหน่วยคำในภาษาไทย แบ่งเป็น 2 ชนิด

1. หน่วยคำอิสระ (Free morpheme) คือ หน่วยคำที่ปรากฏได้ตามลำพังในประโยค หรือปรากฏร่วมกับหน่วยคำอื่นบางหน่วยที่ไม่อาจปรากฏได้ตามลำพัง

ตัวอย่าง เช่น ตาย

1. แมวตายแล้ว
2. เราไม่กลัวแม้แต่ความตาย

จะเห็นว่าคำว่า "ตาย" ในประโยคที่ 1 จะสามารถอยู่ได้ตามลำพัง ส่วนประโยคที่ 2 จะต้องมีการประสมคำระหว่าง "ความ" กับ "ตาย"

2. หน่วยคำไม่อิสระ (Bound morpheme) คือ หน่วยคำที่ปรากฏตามลำพังไม่ได้ในประโยค จะแบ่งเป็น 5 ประเภท

2.1 หน่วยหน้าศัพท์ (prefix) คือ หน่วยคำไม่อิสระที่เกิดหน้าหน่วยคำอื่นเสมอ

การออกแบบพจนานุกรมอิเล็กทรอนิกส์ภาษาไทย

แนวทางการออกแบบโครงสร้างข้อมูลสำหรับการจัดเก็บพจนานุกรมอิเล็กทรอนิกส์ภาษาไทยในวิทยานิพนธ์นี้ ได้พิจารณาจากวิธีการค้นหาคำศัพท์จากพจนานุกรมลักษณะคำไทย และโครงสร้างของภาษาไทย โดยโครงสร้างข้อมูลนี้จะเป็นโครงสร้างข้อมูลแบบแฮชซิง (Hashing) โดยมีการค้นหาคำศัพท์ เป็นแบบแฮชซิงด้วย ซึ่งโครงสร้างข้อมูลแฮชซิง เป็นโครงสร้างที่รวดเร็วต่อการสืบค้นหาคำ และสะดวกต่อการเพิ่มเติมคำศัพท์ใหม่ ๆ ในพจนานุกรมอิเล็กทรอนิกส์ ซึ่งโครงสร้างข้อมูลแบบแฮชซิง มักจะพบการชนกัน (Collision) ของข้อมูล ถ้ามีฟังก์ชันแฮชซิงที่ไม่ดีในงานวิจัยได้นำฟังก์ชันแฮชซิง แบบ Polynomial Addressing มาทำการคำนวณโดยใช้ฟังก์ชันของ Horner ช่วยในการคำนวณ โดยงานวิจัยนี้จะทำการแก้ไขปัญหาการชนกันของข้อมูลด้วยวิธีการของ Chaining

วิธีการปฏิบัติการกับข้อมูล แบ่งเป็น 2 ประเภท

1. การปฏิบัติการแบบพลวัต (Dynamic Method) เป็นวิธีการเก็บข้อมูลในรูปตารางที่มีการเปลี่ยนแปลงได้ เช่น ต้นไม้แบบทวิภาค (Binary Tree) ต้นไม้แบบบีพลัส (B^+ - Tree) โครงสร้างข้อมูลแบบทรี (Trie)
2. การปฏิบัติการแบบสถิต (Static Method) เป็นวิธีการจัดเก็บข้อมูลที่ไม่มีการเปลี่ยนแปลง หรือ ตารางตายตัว เช่น การหาแฮชซิงแบบสมบูรณ์ (Perfect Hashing) ทรีแบบลดขนาด (Compressed Trie)

วิธีการปฏิบัติการกับโครงสร้างข้อมูลทั้ง 2 แบบ มีข้อดีและข้อเสียที่แตกต่างกันโดยข้อดีแบบพลวัต คือ โครงสร้างข้อมูลมีการเปลี่ยนแปลงในขณะที่มีการปรับเปลี่ยนของข้อมูล ส่วนข้อดีของแบบสถิต คือ โครงสร้างมีขนาดเล็กและสามารถค้นหาได้รวดเร็ว สำหรับวิทยานิพนธ์นี้ได้นำข้อดีทั้ง 2 มาผสมปรับปรุงเพื่อจะเก็บคำในพจนานุกรมต่อไป

โครงสร้างในการเก็บค่าในพจนานุกรมอิเล็กทรอนิกส์

การเก็บโครงสร้างข้อมูลแบบแฮชซึ่งนี้ จะแบ่งเป็น 2 ส่วน คือ

1. ส่วนเก็บ Index จะเก็บค่าที่คำนวณแฮช
2. ส่วนเก็บค่าในพจนานุกรม โดยส่วนนี้จะมีโครงสร้างดังภาพที่ 3.1 จะแบ่งเป็น
 - 2.1 คำศัพท์
 - 2.2 ตัวชี้ Address ในการ Link เมื่อพบว่ามีความแฮชในการ hash เดียวกัน
 - 2.3 ตัวบ่งบอกการมีค่าต่อ (Continue Search)

ค่า	Pointer	Continue
การ	-1	-1

ภาพที่ 3.1 โครงสร้างการเก็บค่าของพจนานุกรม

ขั้นตอนการออกแบบและการสร้างพจนานุกรมอิเล็กทรอนิกส์

ขั้นที่ 1 จะนำคำทั้งหมดในพจนานุกรม มาเก็บไว้ในโครงสร้างภาพที่ 3.1 จะได้โครงสร้างก่อนที่จะนำมาคำนวณผ่าน Hashing Function ดังภาพที่ 3.2 โดยที่ค่าเริ่มต้นของการเก็บโครงสร้างจะมีค่าเท่ากับ -1

	Index		Dictionary	Pointer	Continue
0	-1	0	ก	-1	-1
1	-1	1	กก	-1	-1
	.		.		
	.		.		
	.		.		

ภาพที่ 3.2 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชซิง (Hashing Structure)

ขั้นที่ 2 นำค่าในพจนานุกรมมาทำการคำนวณผ่าน hashing function ทีละค่าในพจนานุกรม โดยวิธีการ Polynomial Addressing ซึ่งใช้หลักการของ Horner เป็นตัวช่วยในการคำนวณ ซึ่งจะขอยกตัวอย่างการคำนวณ ดังนี้ โดยมีฟังก์ชันที่ใช้

$$h_{i+1} = [(h_i * \text{base}) + X_{i+1}] \% \text{size}$$

ซึ่งจะคำนวณตามจำนวนตัวอักษรที่ประกอบในคำนั้น

โดยที่ h แทน ค่าแอดเดรสที่คำนวณได้ ค่าเริ่มต้นค่าเท่ากับ 0

base แทน จำนวนทั้งหมดของรหัส ASCII ซึ่งตัวอักษรทั้งหมดมี 256 ตัว

X แทน ค่ารหัส ASCII (ภาคผนวก ก) ของตัวอักษรในคำ

size แทน ขนาดของตาราง Hashing ซึ่งจะต้องเป็น prime number

ในวิทยานิพนธ์ นี้จะให้ค่าเท่ากับ 32761

ตัวอย่าง คำว่า " ก "

$$X_0 = "ก" = 161$$

$$X_1 = "๕" = 231$$

$$\text{รอบที่ 1} \quad h = ((0 * 256) + 161) \% 32761 = 161$$

$$\text{รอบที่ 2} \quad h = ((161 * 256) + 231) \% 32761 = 8686$$

ดังนั้น คำว่า " ก " จะมีค่าแอดเดรส เท่ากับ 8686

ขั้นที่ 3 เมื่อได้ค่าแอดเดรสของคำแล้ว จะทำการเปลี่ยนค่าในตาราง Index ดังภาพที่ 3.3 โดยการตรวจสอบก่อนว่าค่าในตาราง Index เป็นค่าที่เท่ากับ -1 หรือไม่ ถ้าเท่ากับ -1 ก็ให้ทำการเปลี่ยนค่าได้ แต่ถ้าไม่เท่ากับ -1 ก็ให้นำการค้นหาไปยังส่วนที่เป็นแอดเดรสของคำในตารางดรรชนี (Index) เพื่อให้หาค่าที่เป็นค่าในพจนานุกรมที่มีค่าแอดเดรสของคำสุดท้ายที่มีค่าเป็น -1 ของโครงสร้างดังภาพที่ 3.1 ซึ่งค่านั้นจะต้องเท่า -1 ถ้าไม่เท่ากับ -1 ให้ทำการค้นหาต่อไปเรื่อยๆ จนกว่าค่าจะเท่ากับ -1 จึงเปลี่ยนค่าในฟิลด์นั้น ให้เป็นค่าแอดเดรสของคำใหม่

ขั้นที่ 4 จะทำการคำนวณในขั้นตอนที่ 2-3 จนกว่าค่าในพจนานุกรมจะหมด โดยค่าฟิลด์ที่ 3 จากภาพที่ 3.1 จะเปลี่ยนค่าเป็น 1 เมื่อพบว่ามีการคำนวณนั้นมีตัวอักษรต่อจากคำๆ นั้น ซึ่งจะแสดงให้เห็นดังภาพที่ 3.4 โดยคำว่า " กา " จะมีค่า " การ " ซึ่งเป็นตัวที่มีอักษรต่อจากคำว่า " กา " โดยจะเปลี่ยนค่าฟิลด์ของ Continue เป็นค่าเท่ากับ 1 (มีตัวต่อ)

Index		Dictionary	Pointer	Continue
0	-1	กั	-1	-1
1	-1	กิก	-1	-1
	.	.		
	.	.		
	.	.		
8686	0	.		
	.			
	.			
	.			

ภาพที่ 3.3 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชซิง (Hashing Structure)

Index	Dictionary	Pointer	Continue
0	กี	-1	-1
	.		
	.		
	.		
8616	กา	-1	1
	.		
	.		
	.		
8686	การ	7589	-1
	.		
	.		
	.		
23481	กัน	-1	-1
	.		
	.		
	.		

ภาพที่ 3.4 แสดงการเก็บค่าของโครงสร้างข้อมูลแบบแฮชชิ่ง (Hashing Structure)

ผลของการเก็บโครงสร้างพจนานุกรมแบบ Hashing

จากการเก็บโครงสร้างพจนานุกรม Hashing นี้ จะพบว่ามีกรณีชนกัน (Collision) ของคำ ในการคำนวณ คำจากคำทั้งหมดในพจนานุกรม 32,381 คำ พบว่าค่าแฮชที่ชนกันมากที่สุดมีจำนวน 6 Collision จำนวน 3 คำ

โดยจะมีค่าเฉลี่ยในการค้นหาคำในพจนานุกรมเท่ากับ 0.50 คำต่อครั้ง ดังตารางที่ 3.1 โดยให้วิธานิพนธ์ นี้จะทำการหาผลที่เกี่ยวกับการใช้พจนานุกรม โดยแบ่งเป็นขนาดของคำในพจนานุกรม สถิติเกี่ยวกับการใช้ของตัวอักษรที่ประกอบขึ้นเป็นคำ และพร้อมทั้งทำการเขียนโปรแกรมเก็บค่าสถิติอื่น ๆ ที่เกี่ยวข้องกัพจนานุกรมด้วย

ตารางที่ 3.1 จำนวนการเกิด Collision

จำนวน Collision	จำนวนคำ	เปอร์เซ็นต์ในพจนานุกรม
ไม่มี Collision	20540	63.43
1 Collision	8484	26.20
2 Collision	2566	7.92
3 Collision	635	1.96
4 Collision	134	0.41
5 Collision	19	0.07
6 Collision	3	0.01
รวม	32381	
ค่าเฉลี่ย	0.50	

ตารางที่ 3.2 ตารางแสดงขนาดตัวอักษรที่ประกอบเป็นคำ

ขนาดของคำ	จำนวนคำ	เปอร์เซ็นต์ %	ขนาดของคำ	จำนวนคำ	เปอร์เซ็นต์ %
1	1	0.003	20	38	0.117
2	471	1.455	21	41	0.127
3	2522	7.789	22	18	0.056
4	4031	12.449	23	10	0.031
5	4890	15.101	24	10	0.031
6	5597	17.285	25	9	0.028
7	4660	14.391	26	8	0.025
8	3408	10.525	27	11	0.033
9	2177	6.723	28	3	0.009
10	1489	4.598	29	2	0.006
11	934	2.884	30	1	0.003
12	695	2.146	31	2	0.006
13	426	1.316	32	3	0.009
14	336	1.038	33	2	0.006
15	215	0.664	34	2	0.006
16	150	0.463	35	1	0.003
17	90	0.278	36	1	0.003
18	77	0.238	37	0	0
19	49	0.151	38	1	0.003

ตารางที่ 3.3 แสดงการแจกแจงการใช้ตัวอักษรเป็นตัวแรก

ก	= 2735	ป	= 1691	๙	= 0
ข	= 902	ผ	= 432	๙๑	= 0
ฃ	= 0	ฝ	= 134	๙๒	= 0
ค	= 964	พ	= 1139	๙๓	= 0
ค	= 0	ฟ	= 139	๙๔	= 0
ฅ	= 19	ภ	= 334	๙๕	= 3706
ง	= 122	ม	= 1123	๙๖	= 1043
จ	= 820	ย	= 494	๙๗	= 1023
ฉ	= 180	ร	= 944	๙๘	= 178
ช	= 681	ฤ	= 46	๙๙	= 606
ช	= 199	ล	= 910	๐	= 0
จ	= 4	ฬ	= 6	๑	= 0
ญ	= 13	ว	= 904	๑๑	= 0
ฎ	= 1	ศ	= 318	๑๒	= 0
ฎ	= 0	ษ	= 10	๑๓	= 0
ฐ	= 20	ส	= 2080	๑๔	= 0
ฑ	= 4	ห	= 1329	๑๕	= 0
ฒ	= 0	ท	= 0	๑๖	= 0
ณ	= 2	อ	= 1951		
ด	= 455	ฮ	= 61		
ด	= 1307	๑	= 1		
ถ	= 318	๒	= 0		
ท	= 986	๓	= 0		
ธ	= 239	๔	= 0		
น	= 954	๕	= 0		
บ	= 854	๖	= 0		

ตารางที่ 3.4 แสดงการแจกแจงการใช้ตัวอักษรเป็นตัวสุดท้าย

ก	= 2022	น	= 3535	๙	= 0
ข	= 69	บ	= 897	๑	= 2581
ฅ	= 0	ป	= 159	๑	= 430
ค	= 198	ผ	= 7	๑	= 516
ค	= 0	ฝ	= 1	๑	= 1055
ฅ	= 33	พ	= 249	๑	= 7
ง	= 3527	ฟ	= 75	๑	= 0
จ	= 326	ภ	= 40	๑	= 273
ฉ	= 7	ม	= 1819	๑	= 293
ช	= 180	ย	= 1881	๑	= 0
ช	= 20	ร	= 1422	๑	= 0
ฅ	= 2	ฤ	= 3	๑	= 0
ฅ	= 166	ล	= 703	๑	= 0
ฅ	= 10	ฅ	= 0	๑	= 0
ฅ	= 39	ว	= 1058	๑	= 4
ฅ	= 52	ศ	= 238	๑	= 116
๗	= 17	ษ	= 140	๑	= 2
ฅ	= 14	ส	= 302	๑	= 546
ฅ	= 225	ท	= 58	๑	= 468
ค	= 1411	พ	= 16	๑	= 13
ค	= 560	อ	= 863	๑	= 40
ฅ	= 83	ฮ	= 4	๑	= 1958
๗	= 265	๗	= 1		
๗	= 84	๗	= 1298		

ตารางที่ 3.5 การแจกแจงความถี่ของตัวอักษร

ก	= 11052	น	= 11369	เ	= 7950
ข	= 2557	บ	= 4237	ว	= 14858
ฃ	= 0	ป	= 3944	๑	= 1679
ค	= 3430	ผ	= 944	๒	= 6481
ฅ	= 0	ฝ	= 297	๓	= 4562
ฉ	= 177	พ	= 3464	๔	= 623
ง	= 7600	ฟ	= 466	๕	= 1837
จ	= 2879	ภ	= 1082	๖	= 4075
ฉ	= 545	ม	= 7946	๗	= 2032
ช	= 2446	ย	= 7098	๘	= 8006
ฌ	= 618	ร	= 12825	๙	= 2484
ฎ	= 43	ฤ	= 314	๐	= 2122
ญ	= 831	ล	= 6517	๑	= 652
ฎ	= 133	ฬ	= 6	๒	= 1468
ฏ	= 216	ว	= 6172	๓	= 22
ฐ	= 298	ศ	= 1330	๔	= 130
ฑ	= 229	ษ	= 928	๕	= 822
ฒ	= 59	ส	= 5470	๖	= 5431
ณ	= 1226	ห	= 4880	๗	= 6430
ด	= 4934	ฬ	= 104	๘	= 228
ต	= 5626	อ	= 8791	๙	= 204
ถ	= 1007	ฮ	= 176	๐	= 2206
ท	= 3930	๑	= 2		
ธ	= 1202	๒	= 5445		

ตารางที่ 3.6 การแจกแจงความถี่ของตัวอักษรที่ใช้มากตามลำดับ

พยัญชนะ

ที่	ตัวอักษร	จำนวน	ที่	ตัวอักษร	จำนวน
1	ร	12825	23	ณ	1226
2	น	11369	24	ธ	1202
3	ก	11052	25	ภ	1082
4	อ	8791	26	ถ	1007
5	ม	7946	27	ผ	944
6	ง	7600	28	ษ	928
7	ย	7098	29	ญ	831
8	ล	6517	30	ช	618
9	ว	6172	31	ฉ	545
10	ต	5626	32	ฟ	466
11	ส	5470	33	ฐ	298
12	ด	4934	34	ฝ	297
13	ห	4880	35	ฑ	229
14	บ	4237	36	ฎ	216
15	ป	3944	37	ฒ	177
16	ท	3930	38	ฮ	176
17	พ	3464	39	ฎ	133
18	ค	3430	40	ฬ	104
19	จ	2879	41	ฒ	59
20	ข	2557	42	ณ	43
21	ช	2446	43	ญ	0
22	ศ	1330	44	ต	0

สระ

ที่	ตัวอักษร	จำนวน	ที่	ตัวอักษร	จำนวน
1	า	14858	10	๒	2032
2	๑	8006	11	๒๓	1837
3	๑๒	7950	12	๒๑	1679
4	๒๒	6481	13	๒	1468
5	๑๑	5445	14	๒๔	623
6	๒๓	4562	15	๒	652
7	๒๑	4075	16	๓	314
8	๒	2484	17	๓	6
9	๒	2122			

วรรณยุกต์และตัวอักษรอื่นๆ

ที่	ตัวอักษร	จำนวน	ที่	ตัวอักษร	จำนวน
1	๒๑	6430	5	๒๑	228
2	๒๑	5431	6	๒๑	204
3	๒๑	2206	7	๓	130
4	๒๓	822	8	๒	22

ตารางที่ 3.7 ตารางแสดงจำนวนคำที่ตัวอักษรประกอบเป็นคำมากที่สุด 10 อันดับ

ลำดับ	ขนาดตัวอักษร	ลำดับ	ขนาดตัวอักษร
1	6 ตัวอักษร	6	3 ตัวอักษร
2	5 ตัวอักษร	7	9 ตัวอักษร
3	7 ตัวอักษร	8	10 ตัวอักษร
4	4 ตัวอักษร	9	11 ตัวอักษร
5	8 ตัวอักษร	10	12 ตัวอักษร

อัลกอริทึมในการค้นหา

การค้นหาจากโครงสร้างข้อมูลแบบ Hashing นั้น จะเป็นการตรวจสอบว่าคำที่ต้องการค้นหาในโครงสร้างพจนานุกรมแฮชซึ่งหรือไม่มี ซึ่งมีขั้นตอนการค้นหา ดังนี้

1. นำคำที่ต้องการค้นหาทำการคำนวณผ่าน Hashing Function
2. เมื่อได้ค่าแฮชแล้วให้นำค่าแฮชนั้นมาพิจารณาในส่วนของ Index Table ก่อน เมื่อได้ตำแหน่งของคำจาก Index Table ให้มาพิจารณาที่ Dictionary Table โดยดูจากตำแหน่งใน Index Table
3. เมื่อพิจารณาคำที่ได้จากตำแหน่งของ Dictionary Table นำคำมาทำการเปรียบเทียบกับคำที่ต้องการค้นหา เมื่อพบคำนั้นก็หยุดค้นหา และเมื่อไม่ใช่คำที่ต้องการค้นหาก็จะทำการพิจารณาในฟิลด์ที่ 2 ของโครงสร้างพจนานุกรมในภาพที่ 3.1 ว่ามี Link (พิจารณาจากค่า -1) ต่อหรือไม่ ถ้าไม่มี Link ต่อก็ทำการหยุดค้นหา เพราะคำที่ต้องการไม่พบในพจนานุกรม แต่ถ้ามี Link (ไม่เท่ากับ -1) ต่อก็ให้ทำการเปรียบเทียบคำต่อไปกับคำที่ต้องการค้นหา จนกว่าจะพบหรือสิ้นสุด Link (เป็น -1 หรือ ไม่) ที่เชื่อมต่อ

ตัวอย่างแสดงขั้นตอนในการค้นหา

สมมติว่าต้องการทราบว่า คำว่า " การ " เก็บไว้ในพจนานุกรมอิเล็กทรอนิกส์จัดเก็บไว้ในโครงสร้างข้อมูลแบบ Hashing หรือไม่ รายละเอียดมีดังนี้

1. นับจำนวนตัวอักษรของคำที่จะค้นหา

$$\text{" การ " } = 3$$

2. ทำการคำนวณค่า Address โดยทำการคำนวณตามรอบที่ประกอบเป็นคำ

$$\text{รอบที่ 1 : } h = ((0 * 256) + 161 (\text{" ก "})) \% 32761 = 161$$

$$\text{รอบที่ 2 : } h = ((161 * 256) + 210 (\text{" า "})) \% 32761 = 8665$$

$$\text{รอบที่ 3 : } h = ((8665 * 256) + 195 (\text{" ร "})) \% 32761 = 23448$$

3. นำค่าแอดเดรสที่คำนวณได้ มาพิจารณาใน Index Table เพื่อดูตำแหน่งของคำในพจนานุกรมในภาพที่ 3.4 ซึ่งจะได้ตำแหน่งคำที่ 130 ในพจนานุกรม นำค่านั้นมาทำการเปรียบเทียบทีละตัวอักษร จะพบว่าคำว่า " การ " พบในพจนานุกรม

อัลกอริทึม ในการค้นหา

```

SH 1 : [ นับความยาวของคำ ]          len = strlen ( KEY ) ;
SH 2 : [ คำนวณค่า Hash ]            For ( i=0 , i <= len , i++ )
                                     { h ( KEY ) = [ ( h * 256 ) + Xi+1 ] \% 32761 ; }
SH 3 : [ check if found             If ( INDEX [ h ] == -1 )
      ใน Index ]                     { break ; }          ( ไม่พบ )
                                     If ( INDEX [ h ] != -1 )
                                     { loc = INDEX [ h ] ; } ( พบว่ามีคำแต่
                                                                อาจจะใช่หรือไม่ )
SH 4 : [ check if found ]           If ( DICTIONARY [ loc ] == KEY )
                                     { break ; }          ( พบคำที่ต้องการหา )
                                     If ( DICTIONARY [ loc ] != KEY )
                                     { loc = DICTIONARYPOINTER [ loc ] ; }
SH 5 : [ Loop ]                     Go to SH 4

```

- โดยที่
- len = เป็นจำนวนตัวอักษรที่ประกอบกันเป็นคำ
 - strlen = เป็นฟังก์ชันนับความยาวของคำ ในภาษา C
 - h (Key) = ค่าแฮชที่คำนวณของคำ
 - INDEX = ตารางของคำ Index ในการชี้ไปยังตำแหน่งใน DICTIONARY
 - DICTIONARY = ตารางในการเก็บคำในพจนานุกรม แบ่งเป็น 3 ส่วน
 1. ส่วนคำ (DICTIONARYDATA)
 2. ส่วนตัวชี้ (DICTIONARYPOINTER)
 3. ส่วนตัวต่อจากคำ (DICTIONARYCONTINUE)
 - loc = ตำแหน่งของคำ
 - KEY = คำที่ต้องการหา
 - X = ค่าของตัวอักษรในตาราง ASCII

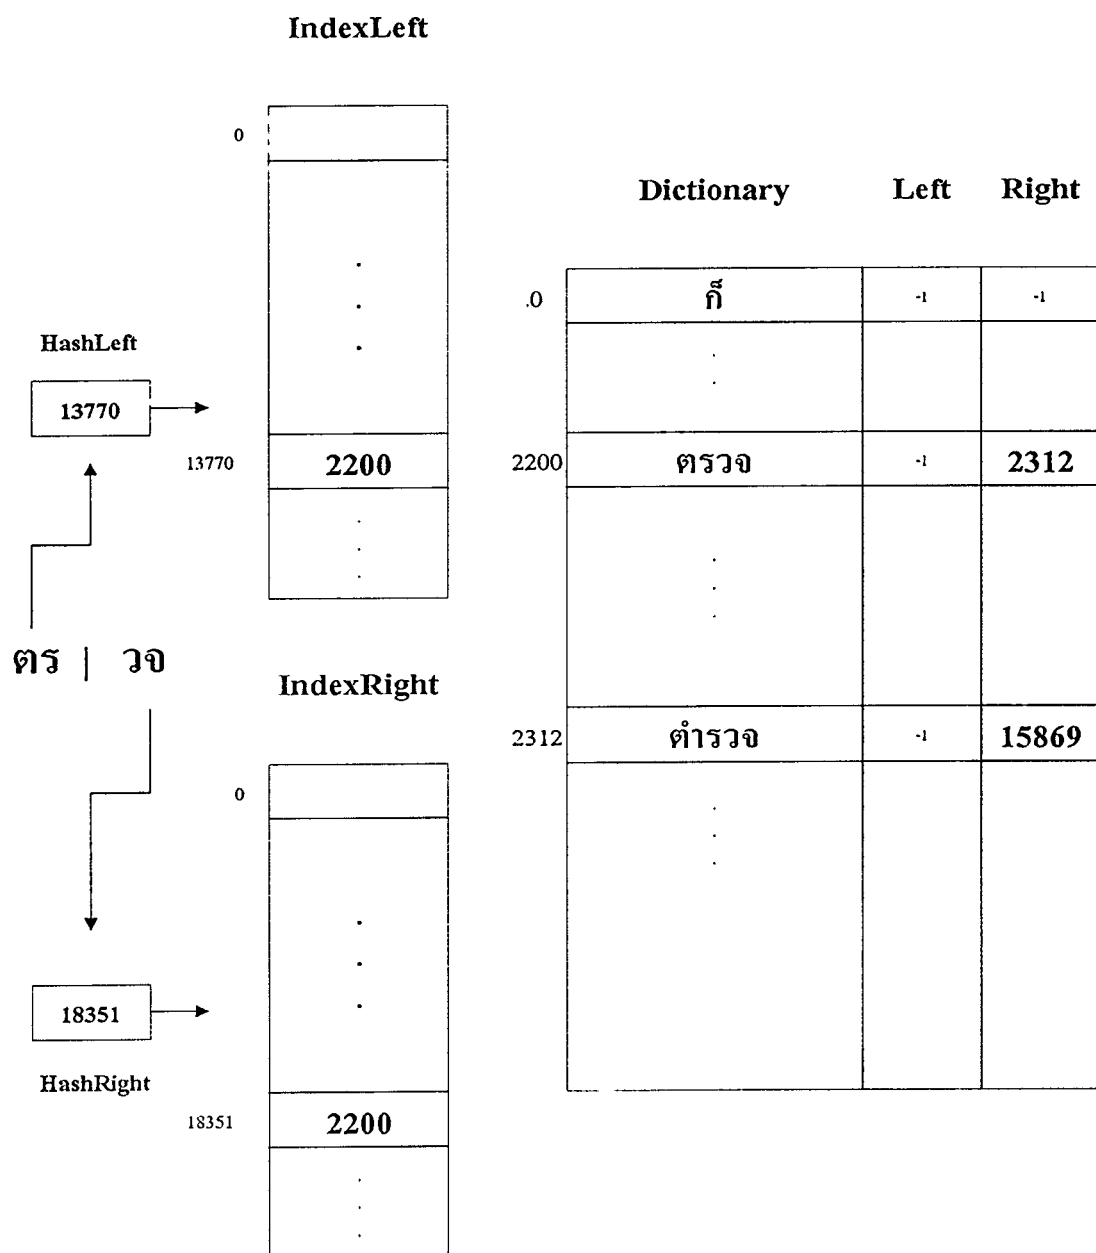
การออกแบบโครงสร้างพจนานุกรมในการค้นหาคำคล้าย

ในการออกแบบการเก็บคำในพจนานุกรมนั้นมีความสำคัญ แต่ในการเก็บโครงสร้างของพจนานุกรมในการหาคำคล้ายก็มีคำสำคัญมากเหมือนกัน เมื่อในการค้นหาไม่สามารถค้นหาคำที่ต้องการได้ ก็ควรจะมีคำที่คล้ายกับคำที่ต้องการหาขึ้นมาให้ผู้ใช้ได้ดู เพราะคำที่ต้องการค้นหานั้นอาจจะมีการพิมพ์ที่ผิดพลาดเกิดขึ้น โดยโครงสร้างการเก็บจะแตกต่างกับโครงสร้างพจนานุกรมแบบ Hashing เดิมเล็กน้อย ซึ่งโครงสร้างใหม่นี้จะเก็บตาราง Index ของแฮช เป็น 2 ส่วนคือ ส่วนทางขวาและส่วนทางซ้าย โดยมีขั้นตอนการสร้างดังนี้

1. นำคำในพจนานุกรมมาทำการคำนวณผ่าน Hash Function ทีละคำ โดยที่นับความยาวของตัวอักษรในคำ แล้วทำการแบ่งครึ่งคำนับมาคำนวณทีละครึ่ง (ถ้ามีจำนวนตัวเป็นคี่จะแบ่งเป็นทางซ้ายมากกว่าทางขวา) มาคำนวณ
2. เมื่อได้ค่าแฮชของครึ่งคำทางซ้ายจะนำมาใส่ในตาราง Index Left ซึ่งเป็น Index ทางซ้าย และค่าแฮชทางขวาของคำ จะไปใส่ค่าในตาราง Index Right ซึ่งเป็น Index ทางขวา
3. เมื่อพบค่าแฮชที่เหมือนกันจะทำการสร้าง Link เชื่อมโยงกับที่ส่วนทางซ้ายของโครงสร้างคำที่มีแฮชเดียวกัน

ตัวอย่างการสร้างพจนานุกรมคำคล้าย

สมมติมี คำว่า "ตรวจ"

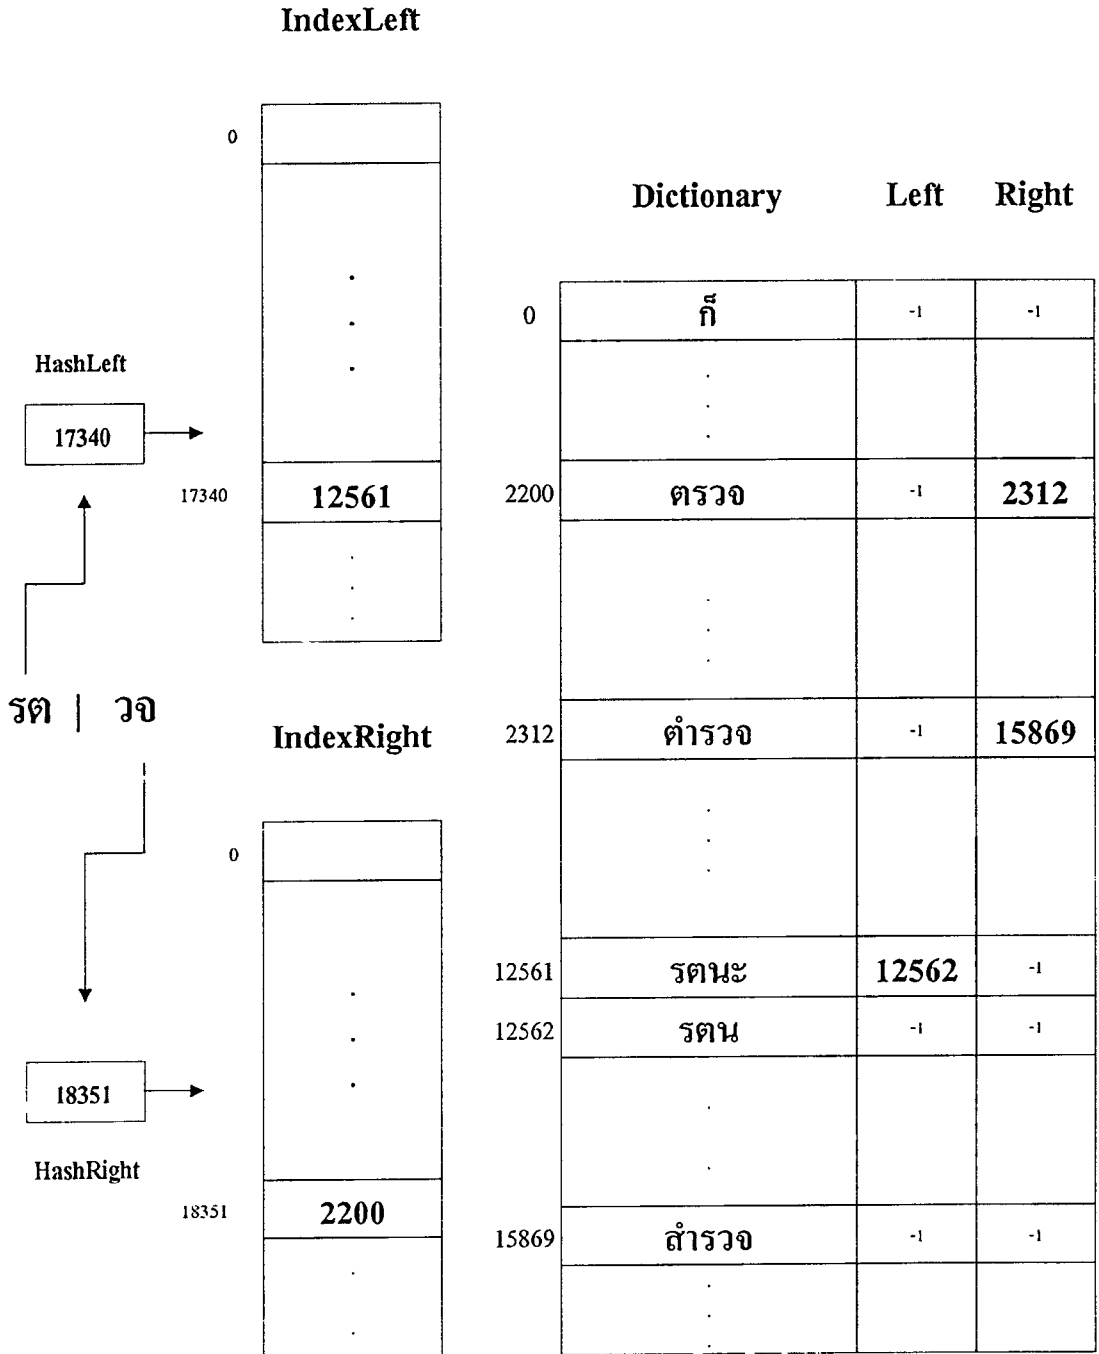


ภาพที่ 3.5 รูปแสดงวิธีการสร้างพจนานุกรมคำคล้าย

จากภาพที่ 3.5 การสร้างพจนานุกรมเลขซึ่งหาคำคล้ายทำโดยการนำคำมาแบ่งครึ่งสร้างดรชนีคำทางซ้ายและดรชนีคำทางขวา ซึ่งจากตัวอย่างจะนำคำว่า ตรวจ มาแบ่งครึ่งสร้างดรชนีคำว่า ตร เป็นดรชนีทางซ้าย และสร้างคำว่า วจ เป็นดรชนีคำทางขวาเพื่อใช้ค้นหาต่อไป

อัลกอริทึมในการค้นหาคำคล้ายในพจนานุกรม

วิธีการหาคำคล้ายจะใช้ก็ต่อเมื่อพบว่ามีคำที่ไม่พบในพจนานุกรมเกิดขึ้น โดยเราจะแบ่งคำที่ต้องการหาเป็น 2 ส่วน เพื่อหาคำคล้าย ทั้งจากคำที่คล้ายกับในส่วนซ้าย และคำที่คล้ายกันใน ส่วนขวาของคำที่ต้องการหา ดังตัวอย่างดังภาพที่ 3.6 เช่น คำว่า "รดจ "



ภาพที่ 3.6 แสดงวิธีการค้นหาคำคล้ายในพจนานุกรม

จากภาพที่ 3.6 จะได้คำที่คล้ายกับคำว่า " รตวง " จะมีคำว่า รตนะ , รตน , ตรวง ,
ตำรวจ, สำรวจ เพื่อให้สามารถทำการแก้ไขต่อไป

บทที่ 4

การตัดคำโดยใช้พจนานุกรมอิเล็กทรอนิกส์ภาษาไทย

ในบทนี้จะกล่าวถึงการตัดแบ่งคำของภาษาไทย โดยมีวิธีการตัดแบ่งคำได้ 2 แบบ โดยแต่ละวิธีจะมีข้อดีและข้อเสียที่ต่างกัน โดยจะกล่าวถึงวิธีการตัดคำทั้ง 2 แบบ พร้อมทั้งนำพจนานุกรมอิเล็กทรอนิกส์ภาษาไทยที่ได้ทำการออกแบบได้มาช่วยในการตัดแบ่งด้วย ซึ่งการตัดแบ่งคำภาษาไทยจะมีวิธีดังนี้

1. การตรวจสอบทางอักษรวิธี จะทำการตรวจสอบการสะกดคำโดยการตรวจสอบพยัญชนะ, สระ, วรรณยุกต์, การันต์ ว่าอยู่ในตำแหน่งที่ควรจะเป็นหรือไม่ในลำดับของคำและกฎต่าง ๆ เช่น

พยัญชนะ - ฅ ค ไม่ใช่แล้วจึงไม่ควรปรากฏในคำ

- ฉ ญ ฎ ฒ ณ พ ไม่ปรากฏเป็นอักษรต้นของคำ
นอกจากมีพวกสระนำมาก่อน ยกเว้น ณ เพียงคำเดียว

ฯลฯ

สระ - สระหน้าจะต้องตามด้วยพยัญชนะเสมอ

- สระหลังจะต้องมีพยัญชนะหรือวรรณยุกต์นำหน้าเท่านั้น

ฯลฯ

วรรณยุกต์ - ต้องตามด้วยตัวสะกดหรือสระหลังเท่านั้น

- เป็นอักษรแรกของคำไม่ได้

ฯลฯ

การันต์ - ต้องอยู่ท้ายสุดของคำเท่านั้น ยกเว้นคำที่มาจากภาษาอังกฤษ

- ต้องตามหลังพยัญชนะบางตัวหรือสระอิ เท่านั้น

ฯลฯ

ข้อดีของวิธีการตรวจสอบทางอักษรวิธี จะเป็นไปอย่างรวดเร็ว เนื่องจากการตรวจสอบกฎที่ตั้งเอาไว้แล้ว ทำการเปรียบเทียบมีจำนวนน้อยครั้งกว่าการตรวจสอบคำในพจนานุกรมเนื่องจากฐานข้อมูลที่จะต้องใช้ในวิธีการนี้ คือ กฎต่าง ๆ ในการตรวจสอบ ย่อมจะมีน้อยกว่าจำนวนคำทั้งหมดในฐานข้อมูลพจนานุกรม แต่มีข้อเสียคือ ความแม่นยำในการตรวจสอบจะน้อย เนื่องจากจะพบคำที่ผิดแต่เป็นไปตามกฎ เช่น งาม วอล เป็นต้น นอกจากนี้ในการปฏิบัติจะทำได้ยาก

2. การตรวจสอบกับพจนานุกรม คือ นำคำไปเปรียบเทียบกับคำในพจนานุกรมว่าพบหรือไม่ ข้อดี จะมีความแม่นยำสูง จึงแน่ใจว่าคำที่ผ่านการตรวจสอบทุกคำมีความหมายแน่นอน นอกจากนี้การปฏิบัติยังทำได้ง่าย แต่ความเร็วในการตรวจสอบจะช้า เพราะต้องเปรียบเทียบกับคำในพจนานุกรม นอกจากนี้ยังไม่สามารถตรวจสอบคำที่ไม่มีในพจนานุกรมได้

การวิเคราะห์โครงสร้างพยางค์ของคำภาษาไทย ^{(4),(14)}

การวิเคราะห์คำภาษาไทยโดยทั่วไป จะพบว่าจะมีอยู่ 7 รูปแบบ คือ

$$1) C(C) \overset{(T)}{V}(S(S))$$

$$5) VC(C) \overset{(T)}{V}(S(S))$$

$$2) C(C) \overset{(T)}{V}(S(S))$$

$$6) VC(C) \overset{(T)}{V}(S(S))$$

$$3) C(C) \overset{(T)}{V}(S(S))$$

$$7) VC(C) \overset{(T)}{V}(S(S))$$

$$4) VC(C) \overset{(T)}{V}(S(S))$$

โดยที่	C	-	พยัญชนะ
	V	-	สระ
	T	-	วรรณยุกต์
	S	-	ตัวสะกด
	()	-	อาจจะมีหรือไม่มี

การวิเคราะห์การแบ่งพยางค์ไทยแบบอักษรวิธี

- 1) การจัดแบ่งกลุ่มของพยางค์ไทย
 - 1.1) กลุ่มตายตัว เช่น สระ ๕ จะไม่มีรูปแบบ $C\text{๕}$ และ $C\text{๕}SS$
 - 1.2) กลุ่มที่คลุมเครือ เช่น สระ ๖ จะพบรูปแบบ $C\text{๖}$, $C\text{๖}S$ และ $C\text{๖}SS$ ซึ่งจะไม่สามารถทำการแบ่งพยางค์ได้ทันที
- 2) การกำหนดขอบเขตของคำ มีหลักเกณฑ์ ดังนี้
 - 2.1) พิจารณาขอบเขตคำ ที่เป็นตามหลักอักษรวิธี ยกเว้นคำที่คลุมเครือ
 - 2.2) พิจารณาโดยใช้ขอบเขตของการเป็นตัวหน้าและตัวสุดท้ายของคำ
 - 2.3) ทำการ mark คำที่ไม่อยู่ในหลักเกณฑ์ เพื่อพิจารณาทีหลัง

กฎการตัดคำโดยพิจารณาจากอักษรวิธี ^[22]

1. กฎของการตัดแบ่งขอบเขตพยางค์ตัวหน้า
 - 1.1) สระ ๑ ๖ ๕ ๖ ๕ ๕ ๕ ๕ ๖ ๑ ๖ และวรรณยุกต์ ๕ ๕ ๕ ๕ ๕ จะต้องมีพยัญชนะนำอย่างน้อย 1 ตัว
 - 1.2) สระ ๕ ๖ ๖ ๖ จะต้องมีพยัญชนะนำตามหลัง ยกเว้นคำบางคำ เช่น ขโมย
 - 1.3) สระ ๖ จะมีพยัญชนะตามเสมอ
 - 1.4) ฉ ผ ฝ ฮ เป็นตัวนำหน้าเสมอ ยกเว้นมีสระ ๕ ๖ ๖ ๖ มาก่อน
 - 1.5) ห ส่วนมากจะเป็นตัวนำของคำ ยกเว้น สห มหา คหบดี มหกรรม
 - 1.6) ข้อ 1.1 อาจจะมีพยัญชนะมากกว่า 1 ตัว
2. กฎการตัดแบ่งพยางค์ตัวหลัง
 - 2.1) ศ ฌ ญ ษ ฐ ฎ ฏ ฒ พ ฒ ส่วนมากเป็นตัวสะกด ยกเว้น ศก สร สพ ษก ญวน
 - 2.2) ๕ จะพบตัวสะกดเสมอ ยกเว้น ร์, หี, ฮี
 - 2.3) ไม้หันอากาศ จะมีตัวสะกด 1 ตัว
 - 2.4) ๑ ๖ และ ๕ จะเป็นตัวสุดท้ายของพยางค์
 - 2.5) ๕ มักพบเป็นตัวสุดท้ายของคำ ยกเว้น คำจากภาษาอังกฤษ
 - 2.6) วรรณยุกต์ที่อยู่ระหว่าง 2 พยัญชนะ ไม่มีสระจะต้องการสะกดแน่นอน

ลักษณะที่พบในการตรวจสอบการสะกดคำและการแยกคำมี 5 ลักษณะ ดังนี้

1. คำที่ถูกต้อง และ mark จุดแยกคำได้ เช่น

แปลง่าย เมื่อตรวจสอบถึงคำว่า แปล จะเห็นว่าพบในพจนานุกรม และยังมีคำอื่นอีกที่เป็นไปได้ เช่น แปลง แปร แปล ดังนั้นจึงต้องนำการ mark ไว้ก่อนที่จุดแยกคำ ที่หลัง " ป " และทำการเปรียบเทียบต่อ จะพบว่า แปล ก็เป็นจุดที่สามารถแยกคำได้ ก็ทำการ mark ที่หลัง " ล " ต่อ

2. คำที่ถูกต้อง และแยกคำได้ เช่น

แปลง่าย เมื่อตรวจสอบถึง แปลง จะเห็นว่าพบคำในพจนานุกรม และไม่มีคำอื่นที่เป็นไปได้ ดังนั้น จะทำการแยกคำที่หลัง " ง " ทันที แต่อาจจะผิด เมื่อเปรียบเทียบคำต่อไป

3. คำที่ไม่ถูกต้อง แต่สามารถย้อนกลับได้ เช่น

แปลง่าย เมื่อตัดคำที่หลัง " ง " ไปแล้ว ก็จะเริ่มตรวจสอบคำต่อไป โดยเริ่มจาก แต่พบว่าไม่มีคำที่ขึ้นต้นด้วย ' ในพจนานุกรม ก็ตรวจสอบว่ามีการ mark ไว้ก่อนหน้าหรือไม่ ถ้ามีการ mark จะย้อนกลับไป mark ก่อนหน้า แล้วตรวจสอบใหม่ โดยเริ่มจากตัวอักษร " ง " เปรียบเทียบกับคำในพจนานุกรมต่อ

4. คำที่ถูกต้อง แต่ไม่สามารถ mark หรือแยกคำได้ เช่น

ตลาด เมื่อตรวจสอบถึงตัว ตล จะพบว่า เป็นส่วนของคำที่มีในพจนานุกรมเท่านั้น จึงไม่สามารถทำการ mark หรือ แยกคำได้ ต้องดำเนินการตรวจสอบตัวอักษรถัดไปก่อน


5. คำที่ไม่ถูกต้อง และไม่สามารถย้อนกลับได้ เช่น

นมมีเล็บ เมื่อตรวจสอบถึงตัวสุดท้าย คือ " ป " จะพบว่า เป็นคำที่ไม่มีในพจนานุกรม และไม่ได้เป็นส่วนหนึ่งของคำ เมื่อตรวจสอบการ mark ของคำก่อนหน้า คือ มี ก็ไม่พบการ mark จุดแยกคำ ดังนั้น จึงไม่สามารถย้อนกลับได้ ดังนั้น คำว่า เล็บ จึงเป็นคำผิด


ผลงานวิจัยการตัดแบ่งคำไทยโดยการตรวจสอบกับพจนานุกรมที่ผ่านมา

1. ผลงานวิจัยของ อาจารย์ยี่น ภู่วรรณและวิวรรณ อิมอารมณี เรื่อง " การแบ่งแยก พยางค์ไทยด้วยดิถีชนารี " ^[8] ได้นำเสนอการตัดแบ่งคำ ดังนี้

ประโยค " ผลของการวิจัยนี้... "



ในการตัดคำจะเริ่มที่ "ผ" จะชี้ในหมวด "ผ" ของพจนานุกรมและนำตัวถัดไปคือ "ล" มาทำการเปรียบเทียบจะพบคำว่า "ผล" และเมื่อนำตัวอักษรถัดไปมาเปรียบเทียบคือ "ข" พบว่า "ผลข" ไม่พบในพจนานุกรม โปรแกรมจะทราบขอบเขตของคำทันที และจะนำตัวอักษร "ข" มาเริ่มเปรียบเทียบกับพจนานุกรมใหม่ พร้อมทั้งได้นำเสนอวิธีการตัดคำที่คลุมเครือด้วยวิธีการย้อนกลับ (Backtracking) ดังนี้ ประโยค " โคนมหนองโพ "



ในการตัดแบ่งคำพบว่า " โค " มีในพจนานุกรม และเมื่อหาคำต่อไปพบว่า " โคน " มีในพจนานุกรมทำให้มีโอกาสในการตัดคำและเป็นคำที่ยาวที่สุด และเมื่อค้นหาต่อไปพบว่า " โคนม " ไม่มีในพจนานุกรมจะทำการตัดคำ โคน / ม ก่อน(ซึ่งไม่ถูกต้อง) แต่เมื่อค้นหา " มหน " จะพบว่าไม่มีในพจนานุกรม ทำให้ควรมีการย้อนกลับไปตำแหน่งก่อนหน้าที่สามารถตัดคำได้ โดยถือว่า โค / นมหน แล้วทำการตรวจสอบ " นมหน " ต่อจะพบว่าตัดแบ่งได้เป็น นม / หน

2. ผลงานวิจัยของ ดร. รัตติกร วรากุลศิริพันธ์และสมศักดิ์ จันวัน เรื่อง " การตัดคำจากประโยคในภาษาไทยด้วยวิธีการเทียบคำที่ยาวที่สุด " ^[12] โดยนำแนวทางของอาจารย์ยืน ภู่วรรณในการตัดคำที่ยาวที่สุดมาช่วยในการออกแบบ วิธีการตัดคำมีดังนี้ เช่น ประโยค " ถิ่นกินข้าว " ในการตัดแบ่งจะทำการหา ASCII ตัวแรกของประโยคคือ " ถ " (169) และหา Weight ของประโยคโดยการนำค่า ASCII ของตัวอักษรแรกรวมกับตัวอักษรถัดไป คือ " ถ " (169) + " ิ่น " (209) = " ถิ่น " (378) แล้วทำการเปรียบเทียบโดยใช้ตัวอักษร 2 ตัวอักษรแรกของประโยคเพื่อชี้ไปในพจนานุกรมของคำที่ขึ้นต้นด้วยตัวอักษร 2 ตัวนั้น จากนั้นก็เริ่มเปรียบเทียบจากคำที่ยาวที่สุดก่อน คือ คำว่า " ถิ่นกินข้าว " ถ้าไม่พบในพจนานุกรมก็จะหาคำว่า " ถิ่นกินข้า " จนกว่าจะพบคำในพจนานุกรม ในที่นี้จะเท่ากับ 3 ตัวอักษร (ถิ่น) แล้วทำการหาค่า ASCII 2 ตัวอักษรถัดไปแล้วทำการเปรียบเทียบกับพจนานุกรม จนถึงที่สุดประโยค


หลักการตัดแบ่งคำภาษาไทยในวิทยานิพนธ์โดยใช้โครงสร้างพจนานุกรมแบบแฮชชิง

ในการตัดแบ่งพยางค์จากพจนานุกรมนี้จะใช้หลักการเปรียบเทียบคำจากพจนานุกรมที่มีอยู่ในหน่วยความจำ โดยในวิทยานิพนธ์ฉบับนี้ ได้นำแนวทางการตัดคำของอาจารย์ยืน ภู่วรรณตามหลักการแบบ Backtracking มาทำการออกแบบและนำเสนอวิธีการตัดคำโดยใช้โครงสร้างในการตัดคำอีกแบบหนึ่ง ซึ่งจะได้นำเสนอโครงสร้างข้อมูลแบบ Stack เข้ามาช่วยในการตัดแบ่งคำภาษาไทยด้วย ซึ่งจะทำให้มีการทำงานของการทำงานของการตัดแบ่งคำเป็นแบบ Iterative ซึ่งแตกต่างกับการตัดคำที่เป็นแบบ Recursive เดิม วิธีการนี้จะนำตัวอักษรมาทำการคำนวณผ่าน Hashing Function (เดียวกับโครงสร้างพจนานุกรมที่ได้ออกแบบไว้ในบทที่ 3) ทีละตัวอักษร แล้วนำมาเปรียบเทียบกับคำในโครงสร้างพจนานุกรม แบบแฮชชิง ที่ได้ออกแบบไว้ว่าพบหรือไม่พบคำ ๆ นั้น ถ้าพบจะเก็บตำแหน่งของตัวอักษรนั้นไว้ใน Stack ตัวที่ 1 และทำการค้นหาต่อจนกว่าจะพบคำที่ยาวที่สุดในการตัดแบ่งคำได้ในแต่ละรอบ ซึ่งจะนำตำแหน่งของตัวอักษรที่ยาวที่สุดในแต่ละรอบมาเก็บไว้ใน Stack ตัวที่ 2 แล้วนำตัวอักษรถัดไปต่อจากตำแหน่งที่ยาวที่สุดมาทำการคำนวณต่อ

จนกว่าจะถึงที่สุดของประโยคหรือสิ้นสุดบรรทัดของประโยคนั้น ๆ หรือพบว่าคำที่กำลังเปรียบเทียบในพจนานุกรมนั้นไม่มีตัวต่อตามโครงสร้างพจนานุกรมภาพที่ 3.1 (word.continue) จากหลักการตัดแบ่งคำนี้จะขอยกตัวอย่างเพื่อให้รายละเอียดได้ชัดเจนขึ้น

เช่น	ตำแหน่ง	1	2	3	4	5	6	7	8	9	10
	ตัวอักษร	ก	า	ร	ค	ร	ว	จ	ส	อ	บ

รอบที่ 1 จะนำตัวอักษร "ก" มาทำการคำนวณผ่าน Hashing Function ก่อน เมื่อเปรียบเทียบคำกับโครงสร้างพจนานุกรม ถ้าไม่พบจะนำตัวอักษรถัดไป คือ "า" มาทำการคำนวณต่อ และเปรียบเทียบ ซึ่งพบว่าคำว่า "กา" มีในพจนานุกรมทำการในตำแหน่งใน Stack ตัวที่ 1 ดังภาพที่ 4.1 และทำการนำตัวอักษรถัดไปคือ "ร" มาทำการคำนวณต่อ พบว่า คำว่า "การ" มีในพจนานุกรม ใส่ตำแหน่งใน Stack ตัวที่ 1 และนำตัวอักษรถัดไปมาคำนวณต่อ จนจบประโยค พบว่า "การ" เป็นคำที่ยาวที่สุดในรอบที่ 1 ใส่ตำแหน่งที่ยาวที่สุดใน Stack ตัวที่ 2 ดังภาพที่ 4.1



Stack ตัวที่ 1
ตำแหน่งที่ตัดได้

Stack ตัวที่ 2
ตำแหน่งที่ยาวที่สุด

ภาพที่ 4.1 แสดงค่าตำแหน่งที่สามารถทำการตัดได้

รอบที่ 2 นำตัวอักษรที่อยู่ในตำแหน่งที่ยาวที่สุด มาทำการคำนวณต่อ โดยตัวอักษรที่นำมาคือ "ค" แล้วเปรียบเทียบค่าในพจนานุกรม และนำตัวอักษรถัดไป ทำคำนวณต่อไปเรื่อย ๆ ซึ่งจะพบว่าค่าที่ยาวที่สุดในรอบนี้ คือ "ตรวจ" ซึ่งไม่มีตำแหน่งที่ตัดได้ก่อนหน้า จึงนำค่ามาใส่ Stack ทั้ง 2 ตัว ดังภาพที่ 4.2

7	(ตรวจ)
3	(การ)
2	(กา)

7	(ตรวจ)
3	(การ)

Stack ตัวที่ 1
ตำแหน่งที่ตัดได้

Stack ตัวที่ 2
ตำแหน่งที่ยาวที่สุด

ภาพที่ 4.2 แสดงค่าตำแหน่งที่สามารถตัดค่าได้

รอบที่ 3 นำตัวอักษรถัดไปในรอบที่ 2 มาคำนวณต่อ โดยนำ "ส" มาคำนวณเปรียบเทียบค่าในพจนานุกรม ซึ่งจะพบว่า มีคำว่า "สอ" สามารถตัดค่าได้ และคำว่า "สอบ" ตัดค่าได้ ก็จะนำค่าตำแหน่งไปใส่ใน Stack ตัวที่ 1 และค่าที่ยาวที่สุดใน Stack ตัวที่ 2 ดังภาพที่ 4.3

10	(สอบ)	
9	(สอ)	
7	(ตรวจ)	
3	(การ)	
2	(กา)	

10	(สอบ)	
7	(ตรวจ)	
3	(การ)	

Stack ตัวที่ 1
ตำแหน่งที่ตัดได้

Stack ตัวที่ 2
ตำแหน่งที่ยาวที่สุด

ภาพที่ 4.3 แสดงค่าตำแหน่งที่สามารถตัดคำได้


การถอยหลังเมื่อพบปัญหาหรือคำที่คลุมเครือ (Back Tracking)

ในการค้นหาคำในพจนานุกรมเพื่อนำมาตัดแบ่งคำ อาจจะมีปัญหาในการตัดแบ่งคำบางคำ ซึ่งในงานวิจัยนี้ได้นำวิธีการ Back Tracking มาใช้เพื่อใช้ ตัดสินการตัดแบ่งคำ เพื่อให้ได้คำที่ถูกต้องมากที่สุด ดังตัวอย่าง

ตำแหน่ง	1	2	3	4	5	6	7	8	9
ตัวอักษร	ก	า	ร	ก	ร	ะ	จ	า	ย

ในการทำงานจะมีขั้นตอนดังนี้ คือ เริ่มต้นจะหาคำที่ยาวที่สุดก่อน ในที่นี้ จะได้คำว่า " การก " และทำการเก็บในแต่ละตัวใน Stack ตัวที่ 1 ว่ามีคำใดที่สั้นกว่าคำว่า " การก " และพบในพจนานุกรม คือคำว่า กา, การ จากนั้นในรอบต่อไปจะนำตัวอักษรถัดจากคำว่า การก มาตัดแบ่งคำต่อ จะได้คำว่า " ระ " และนำตัวอักษรถัดไปมาตัดแบ่งต่อ จะได้คำว่า " จา " แล้วนำตัวอักษรถัดไปมาตัดแบ่ง ในที่นี้จะเหลือ " ย " ตัวเดียว ซึ่งไม่สามารถตัดแบ่งได้ จึงต้องทำการ Back Track ไปยังตำแหน่งก่อนหน้า จนกว่าจะทำการ Back track หหมดตำแหน่งก่อนหน้าใน Stack ตัวที่ 1 หรือ Back track จนกว่าจะพบคำที่ตัดได้ในประโยคต่อ โดยจะมีขั้นตอนการทำงานดังภาพที่ 4.4

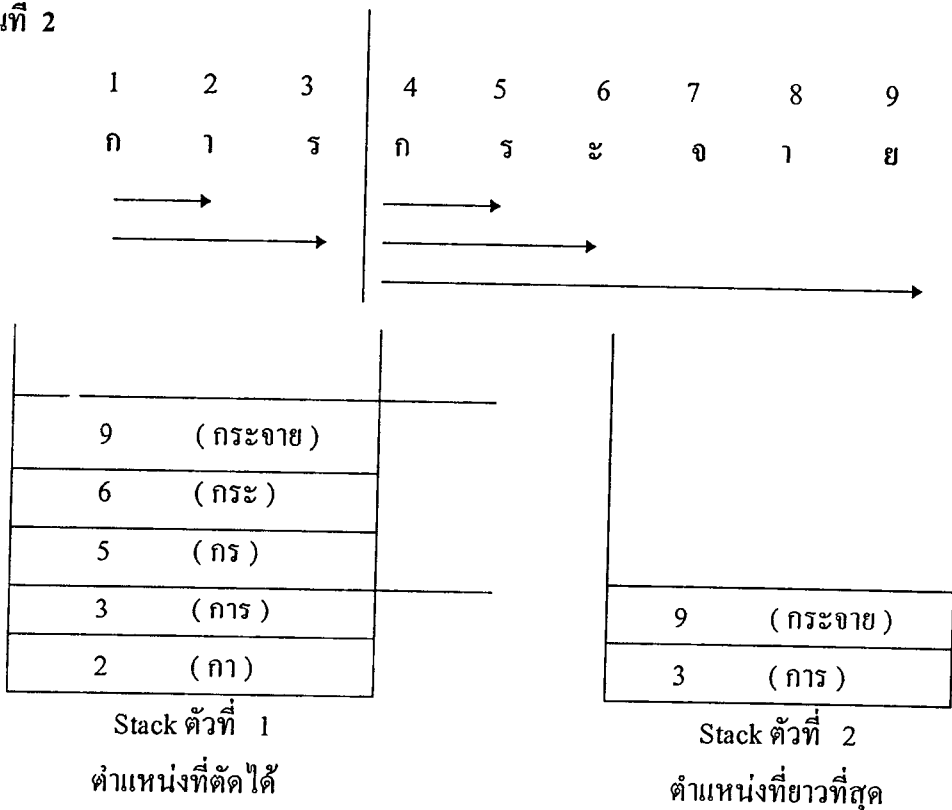
ขั้นตอนที่ 1



Stack ตัวที่ 1
ตำแหน่งที่ตัดได้

Stack ตัวที่ 2
ตำแหน่งที่ยาวที่สุด

ขั้นตอนที่ 2



Stack ตัวที่ 1
ตำแหน่งที่ตัดได้

Stack ตัวที่ 2
ตำแหน่งที่ยาวที่สุด

ภาพที่ 4.4 แสดงขั้นตอนตำแหน่งการตัดคำใน Stack ในการ Back Tracking

อัลกอริทึมการตัดแบ่งคำภาษาไทย

```

pos = 0 ; count = 0 ;
While ( text [ pos ] != ตัวหยุดประโยค ) ----- จะตรวจสอบการสิ้นสุดประโยค
{ For ( h = maxposition = 0; q = pos; q <= count; q++ ) ----- loop ตรวจสอบคำหยุด
    เมื่อ count = 25 หรือไม่พบตัวต่อ
    { p = text [ q ]; ----- p จะเป็นตัวชี้ตำแหน่งตัวอักษร
      hash = Horner ( h, p ); ----- คำนวณการ hashing
      word = Dict ( hash, text, pos, q, found ); ----- จะส่งตำแหน่งที่สามารถ
        ตัดได้ ถ้าสามารถตัดได้ จะให้
        found = 1 เพื่อจะเก็บตำแหน่งที่
        ยาวที่สุดต่อไป
      h = hash; ----- ส่งค่ากลับมาคำนวณต่อ
      If ( found )
        { Pushstack1 ( q ); ----- เก็บตำแหน่งที่ตัดได้ใน Stack ตัวที่ 1
          maxposition = q; ----- เก็บตำแหน่งที่ยาวที่สุด
          If ( word.continue == -1 ) ----- ตรวจสอบตัวอักษรที่มีต่อจากคำ
            { break; }
          } ----- If Loop
        } ----- For Loop
      If ( maxposition != 0 ) ----- พบตำแหน่งที่ยาวที่สุด
        { Pushstack2 ( maxposition ) ----- เก็บตำแหน่งที่ยาวที่สุดใน Stack ตัวที่ 2
          pos = maxposition ; ----- ให้ตำแหน่งที่จะคำนวณต่อหลังจากที่
            ตัดคำได้
          }
        Else { pos = Popstack ( ); } ----- ให้ตำแหน่ง Back Track
          กลับไปก่อนหน้าเมื่อพบคำกำกวม
      } // จบ while loop

```

หมายเหตุ ตัวหยุดประโยค คือ ตัวที่ขึ้นประโยคใหม่ ($\backslash n$) หรือ ตัวที่เป็น Space (' ')

โดยที่	pos , q	-----	ตำแหน่งของตัวอักษรในประโยค
	count	-----	จำนวนตัวอักษรที่จะตรวจสอบในประโยค (25 ตัวอักษร)
	text	-----	array เก็บตัวอักษรในประโยค
	p	-----	ตัวชี้ตัวอักษร
	hash	-----	ค่าแฮชของคำ
	found	-----	ตรวจสอบว่าพบคำที่สามารถตัดได้ในประโยค
	maxposition	-----	ตำแหน่งของตัวอักษรที่ยาวที่สุดที่ตัดได้
	h	-----	ค่า hashing เพื่อส่งค่ากลับไปคำนวณต่อ
	word.continue	-----	สำหรับตรวจสอบตัวอักษรที่ต่อจากคำที่เปรียบเทียบ
	Horner	-----	Hashing Function
	Dict	-----	เป็น function เปรียบเทียบคำในพจนานุกรม
	Pushstack1	-----	เป็น function ในการใส่ตำแหน่งที่สามารถตัดได้
	Pushstack2	-----	เป็น function ในการใส่ตำแหน่งที่ยาวที่สุดที่สามารถตัดได้
	PopStack	-----	เป็น function Backtrack เพื่อจะได้คำที่ถูกตัดมากที่สุด

หมายเหตุ ในการ PopStack จะมีการตรวจคำที่ตัดก่อนหน้าว่ามีการตัดมากกว่า 1 ครั้งในแต่ละรอบ (ตรวจสอบใน Stack ตัวที่ 1) หรือไม่ ถ้าไม่ จะทำการ Popstack ตำแหน่งใน Stack ตัวที่ 1 ไปจนกว่าจะพบการตัดตำแหน่งของคำก่อนหน้ามากกว่า 1 ครั้ง เพื่อนำตำแหน่งนั้นมาทำการเปรียบเทียบกับพจนานุกรมต่อไป โดยการตัดคำรอบใหม่ จะทำการตรวจสอบตำแหน่งที่ตัดได้กับตำแหน่งใน Stack ตัวที่ 2 ถ้าพบว่าสามารถตัดคำได้มากกว่าในรอบก่อน จะทำการเปลี่ยนตำแหน่งใน Stack ตัวที่ 2 เพื่อจะได้คำที่ยาวที่สุดในการตัดคำ

จากอัลกอริทึมการตัดคำจะต้องทำการค้นหาคำในพจนานุกรมก่อน ดังนั้นค่าเฉลี่ยในการค้นหาจะเท่ากับผลคูณของค่าเฉลี่ยในการค้นหาที่เกิด Collision (ตารางที่ 3.1) กับค่าเฉลี่ยของจำนวนตัวอักษรที่ประกอบเป็นคำ (ตารางที่ 3.2) ซึ่งจะได้ค่าเป็น $1*n + 0.5*6.76$ โดย n เป็นจำนวนตัวอักษรที่เปรียบเทียบ ซึ่งค่ามากที่สุดในการค้นหา (worst case) เท่ากับ $1*n + 5*6.76$ และค่าน้อยที่สุดในการค้นหา (best case) เท่ากับ $1*n$

บทที่ 5

ผลการทดสอบการตัดแบ่งคำและเปรียบเทียบกับ Microsoft Word

ในการวิเคราะห์การทำงานของโปรแกรมการตัดคำภาษาไทยโดยใช้พจนานุกรมที่มีโครงสร้างแฮชซึ่งในวิทยานิพนธ์ จะพบว่ามีความสามารถในการตัดแบ่งคำได้อย่างถูกต้องและรวดเร็วกว่าโปรแกรม Commercial Microsoft Word

ข้อมูลที่ใช้ในการทดสอบ

คำศัพท์ที่ใช้สำหรับการสร้างพจนานุกรมอิเล็กทรอนิกส์ภาษาไทย เป็นคำศัพท์พจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2525 ซึ่งมีรายการคำทั้งหมด 32,381 คำนำมาสร้างพจนานุกรมโดยมีการสร้าง Index ในรายการคำ เพื่อใช้ในการตรวจสอบการตัดคำภาษาไทย ซึ่งผู้วิจัยได้พบว่ารายการคำในพจนานุกรมของ Microsoft Word (ดังตารางรายการคำในภาคผนวก ข) มีจำนวนรายการคำน้อยกว่ารายการคำในวิทยานิพนธ์ โดยผู้วิจัยได้ทำการทดสอบการตัดคำในประโยคเดียวกัน ที่มีรายการคำเหมือนกันทั้งในงานวิจัยและ Microsoft Word ก็จะพบข้อผิดพลาดของ Microsoft Word ในการตัดคำ และในการตัดคำของ Microsoft Word ยังพบคำที่ถูกต้องตามพจนานุกรม แต่ Microsoft Word ตรวจสอบเป็นคำผิด เช่น คำว่า อุตสาหกรรม, แม่ย่า, เศรษฐกิจ เป็นต้น ดังผลการทดสอบในตารางที่ 5.1

ตารางที่ 5.1 แสดงจำนวนคำจากพจนานุกรมราชบัณฑิตยสถานที่ไม่พบในพจนานุกรมของ Microsoft Word

โปรแกรม	จำนวนคำทั้งหมด	คำที่ตรวจสอบ			
		ถูก	% ที่ ถูก	ผิด	% ที่ผิด
Word 6.0	32,381	30,090	92.92	2,291	7.08
Word 7.0	32,381	31,374	96.89	1,007	3.11

การทดสอบการตัดคำโดยใช้พจนานุกรมอิเล็กทรอนิกส์ภาษาไทยกับ Microsoft Word

การทดสอบการตัดคำในงานวิจัยกับ Microsoft Word จะสามารถแบ่งการเปรียบเทียบได้ดังนี้

- ก) ความเร็วในการตัดคำ
- ข) ความถูกต้องในการตัดคำ
- ค) การค้นหาคำคล้ายเมื่อพบคำผิดในเอกสาร

ก) ความเร็วในการตัดคำ

จากการที่ได้ทำการวัดความเร็วในการตรวจสอบเอกสารชนิดเดียวกัน(เอกสารที่ตรวจสอบคือบทคัดย่อภาษาไทยในวิทยานิพนธ์ฉบับนี้ ซึ่งทำการคัดลอกจนได้จำนวนหน้าตามที่ต้องการทดสอบ) ระหว่าง Microsoft Word กับโปรแกรมของงานวิจัยจะได้ผลดังตารางที่ 5.2

ตารางที่ 5.2 ตารางแสดงความเร็วในการตรวจสอบเป็นวินาที (บน Pentium 90 MHz)

จำนวนหน้า จำนวนบรรทัด Software	5 145	10 288	20 575	50 1436	100 2868	200 5736
Word 6.0	3	4	9	20	38	75
โปรแกรม Spell Check 1	2	3	6	14	28	55
โปรแกรม Spell Check 2	1	2	4	7	13	26
โปรแกรม Spell Check 3	1	2	4	9	17	35
โปรแกรม Spell Check 4	0.90	1.50	2.72	6.17	11.82	23.20
โปรแกรม Spell Check 5	0.81	1.28	2.28	5.25	10.14	19.92

จากตารางที่ 5.2

โปรแกรม Spell Check 1	-	พิจารณาตรวจสอบจนถึงสุดประโยค
โปรแกรม Spell Check 2	-	พิจารณาตรวจสอบทีละ 15 ตัวอักษรของประโยค
โปรแกรม Spell Check 3	-	พิจารณาตรวจสอบทีละ 25 ตัวอักษรของประโยค
โปรแกรม Spell Check 4	-	ทำการเปลี่ยนโครงสร้างในการ PopStack โดยพิจารณาจำนวนรอบที่สามารถตัดได้ในแต่ละรอบ ถ้าในรอบมีตำแหน่งที่สามารถตัดได้เพียง 1 ครั้ง ให้ทำการ PopStack ต่อไปอีก
โปรแกรม Spell Check 5	-	โครงสร้างพจนานุกรมเพิ่มฟิลด์แสดงตัวอักษรที่มีตัวต่อของคำที่พิจารณา(ดังภาพที่ 3.1)และพิจารณาตรวจสอบไป 25 ตัวอักษรของประโยค

หมายเหตุ การทดสอบกับ Microsoft Word 7.0 ไม่สามารถตรวจสอบได้เพราะโปรแกรมไม่มีการตอบสนองในการ Spell Checking

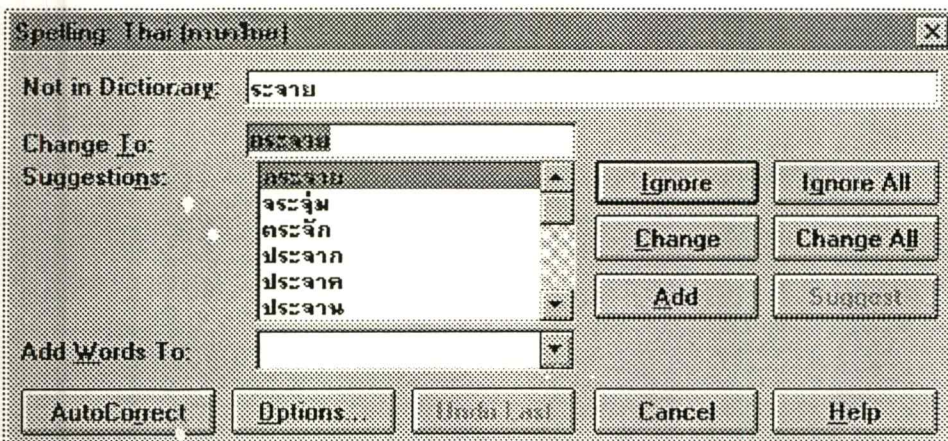
ข) ความถูกต้องในการตัดคำ

Input การกระจาย

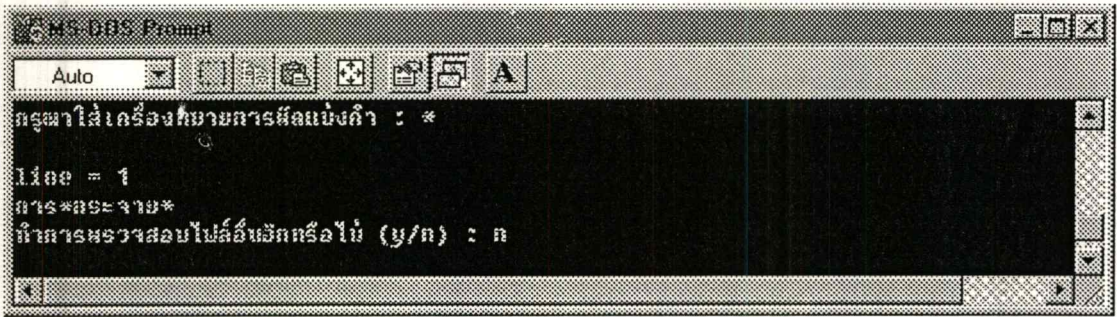
Output

Word

การก **กระจาย**



งานวิจัย

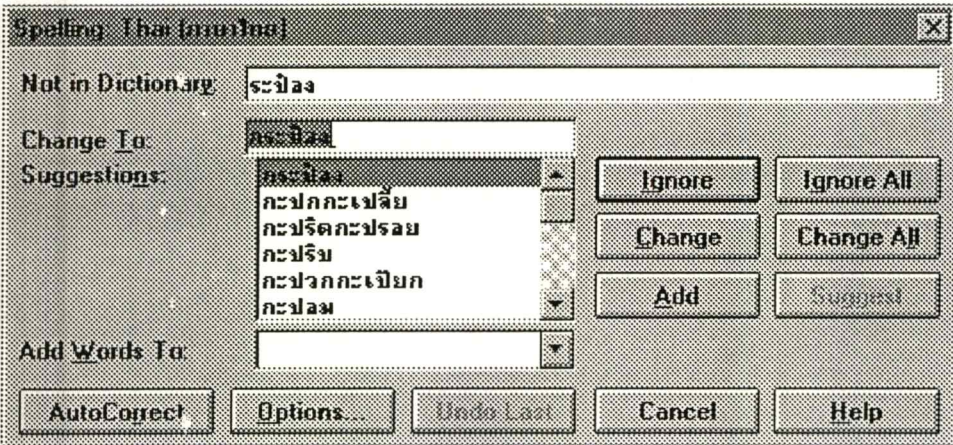


Input ปลากะบอง

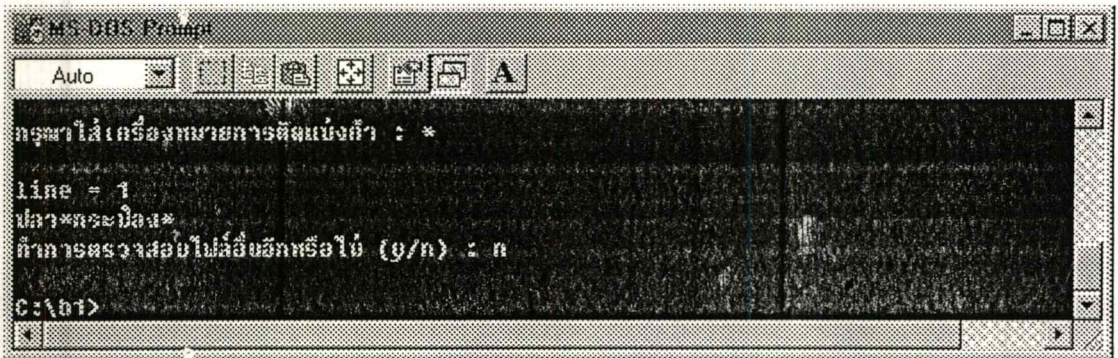
Output

Word

ปลากะ**บอง**



งานวิจัย



ตัวอย่างประโยคที่ Microsoft Word ตัดแบ่งคำผิด

ตัวอย่างประโยค	Word 6.0	Word 7.0
ผู้นำเข้าจะเข้มงวดมาก	ผู้นำเข้าจะเข้ มงวด มาก	ผู้นำเข้าจะเข้ มงวด มาก
ปลาทูนากะป๋อง	ปลาทูนาก ระป๋อง	ปลาทูนาก ระป๋อง
ขอปริจาคหนังสือ	ขอป ริจาค หนังสือ	ขอป ริจาค หนังสือ
การกระจาย	การก กระจาย	การก กระจาย
มาบปริจาค	มาบ ริจาค	มาบ ริจาค
ปลากะป๋อง	ปลาก ระป๋อง	ปลาก ระป๋อง
จะมอหงหาสมาชิก	จะมอหงหาส มาชิก	จะมอหงหาส มาชิก
จะจ้ำงาน	จะจ้ำ ้งงาน	จะจ้ำ ้งงาน

จากตัวอย่างประโยคที่แสดงให้เห็นการตัดคำระหว่าง Microsoft Word กับงานวิจัย จะพบว่าการทำงานของ Microsoft Word จะตัดคำผิดซึ่งคำในประโยคเหล่านั้นเป็นคำที่ถูกต้องตามพจนานุกรม โดยถ้านำคำจากประโยคข้างต้นมาทำการแยกเป็นคำๆจะพบว่าในส่วนของ Microsoft Word ก็จะสามารถตัดแบ่งคำได้ถูกต้อง


ค) การค้นหาคำคล้ายเมื่อพบคำผิดในเอกสาร

ในการค้นหาคำคล้ายในงานวิจัยจะหาจากการนำเอาขอบเขตคำที่ผิดมาหาในพจนานุกรมโดยทำการแบ่งครึ่งความยาวของขอบเขตคำผิด จะหาคำคล้ายโดยการนำคำที่แบ่งครึ่งของคำที่ผิดมาทำการค้นหาทั้งสองด้านของคำ (รายละเอียดในบทที่ 3) แต่ใน Microsoft Word จะใช้วิธีการค้นหาโดยการนำคำที่ผิดมาพิจารณาตัวอักษรเป็นคู่ แล้วทำการค้นหาคำในพจนานุกรม

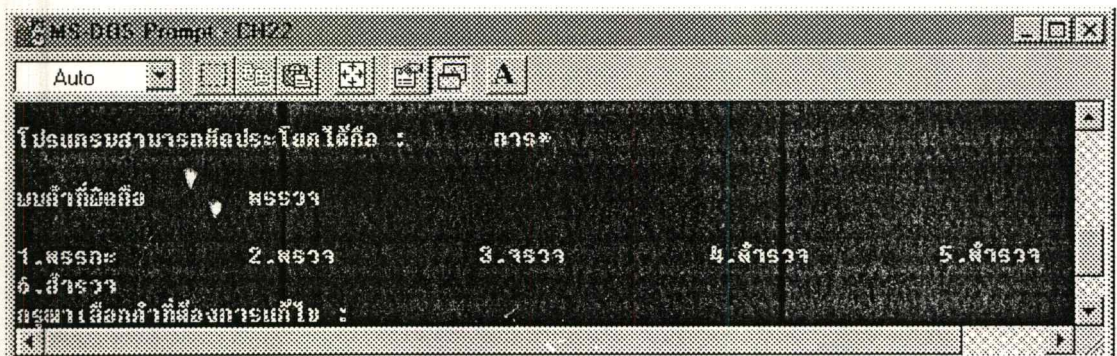
ตัวอย่างการค้นหาคำคล้าย

ประโยค " การตรรวจวบ "

Word



งานวิจัย



จากการทดลองจะพบว่าการใช้พจนานุกรมอิเล็กทรอนิกส์ฉบับราชบัณฑิตยสถาน จะมีความถูกต้องสูง สามารถทำการตรวจสอบได้รวดเร็ว และยังมีการค้นหาคำคล้ายได้ใกล้เคียงกับคำที่ผิดในเอกสารมาก ซึ่งเป็นข้อที่ได้เปรียบของการตัดคำภาษาไทยเมื่อทำการเปรียบเทียบกับโปรแกรม Microsoft Word ที่ได้นำเสนอในวิทยานิพนธ์นี้

บทที่ 6

บทสรุปและข้อเสนอแนะ

บทสรุป

ในการวิจัยทางด้านภาษาศาสตร์ ได้ มีนักวิจัยหลายท่านให้ความสนใจและมีการพัฒนาต่อเนื่องกันเรื่อยๆมา โดยการตัดแบ่งคำภาษาไทยนี้เป็นส่วนหนึ่งของงานทางด้านภาษาศาสตร์ ซึ่งในวิทยานิพนธ์นี้ได้นำเสนออัลกอริทึมในการสืบค้นคำศัพท์ที่มีโครงสร้างข้อมูลแบบแฮชซิง (Hashing) มาทำการเก็บคำในพจนานุกรมและยังใช้อัลกอริทึมแฮชซิงนี้มาทำการตัดแบ่งคำภาษาไทย โดยความสามารถในการตัดคำจะให้ผลลัพธ์เป็นคำศัพท์ที่ยาวที่สุดที่พบในพจนานุกรม และสามารถตัดคำได้ทุกคำที่ปรากฏเป็นคำศัพท์ในพจนานุกรม ในด้านความเร็วในการตรวจสอบเอกสารจะมีความเร็วกว่าโปรแกรม Microsoft Word

โครงสร้างข้อมูลสำหรับการเก็บพจนานุกรมอิเล็กทรอนิกส์ภาษาไทยที่พัฒนาขึ้นมาโดยใช้โครงสร้างข้อมูลแบบแฮชซิงนี้ จะมีประสิทธิภาพที่ดีในด้านของการเพิ่มเติมคำศัพท์ใหม่ สามารถสร้าง Index ของคำได้ง่าย และยังสามารถค้นหาคำคล้ายได้สะดวกรวดเร็ว โดยในการตัดคำในวิทยานิพนธ์นี้ได้ทำการออกแบบอัลกอริทึมที่เป็นแบบลักษณะ Iterative และใช้โครงสร้างข้อมูลแบบ Stack ในการเก็บตำแหน่งคำที่ตัดได้แทนอัลกอริทึมแบบ Recursive ซึ่งเป็นแบบเดิมที่ได้มีผู้ทำการวิจัยมาแล้วซึ่งจะทำให้การตัดคำจะมีการตรวจสอบคำได้ทุกตำแหน่งก่อนทำการตัดคำ

ข้อเสนอแนะ

วิทยานิพนธ์นี้ได้ทำการสร้างพจนานุกรมอิเล็กทรอนิกส์ที่บรรจุคำ 32,381 คำ ในทางปฏิบัติการกับคำในพจนานุกรม จะต้องเก็บคำทั้งหมดในหน่วยความจำ ถ้าจำนวนคำที่จะเกิดขึ้นต่อไปมีจำนวนมากขึ้น จะทำให้หน่วยความจำที่มีอยู่จำกัดไม่สามารถรองรับข้อมูลทั้งหมดได้ แต่ถ้ามีการปรับปรุงการจัดการหน่วยความจำกับจำนวนคำในพจนานุกรม ให้ใช้งานได้อย่างมีประสิทธิภาพโดยไม่ทำให้ประสิทธิภาพทางด้านอื่นๆลดลง จะทำให้การตรวจสอบการตัดคำภาษาไทยกับพจนานุกรมทำงานได้ดีมากขึ้น

สำหรับอัลกอริทึมที่ใช้ในการตัดแบ่งคำที่พัฒนาในวิทยานิพนธ์นี้ จะใช้อัลกอริทึมที่เปรียบเทียบกับพจนานุกรมเท่านั้น ถ้าต้องการให้อัลกอริทึมในการตัดคำมีประสิทธิภาพสมบูรณ์มากขึ้นควรจะนำกฎในการตรวจสอบคำในภาษาไทยมาผสมผสานกับการเปรียบเทียบคำในพจนานุกรม จะทำให้มีความถูกต้องในการตัดแบ่งคำมากขึ้น และจะทำให้งานทางด้านภาษาศาสตร์มีประโยชน์มากขึ้นในการนำไปใช้ต่อไป

บรรณานุกรม

1. " พจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2525 " จาก CD-ROM พจนานุกรมฉบับราชบัณฑิตยสถาน, ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC).
2. ทวีศักดิ์ จันทร์วิทยานูชิต " การตรวจสอบคำผิดในเอกสารภาษาไทย " โครงการวิจัยและพัฒนาอิเล็กทรอนิกส์และคอมพิวเตอร์, เล่มที่ 2, ینگประมาณ 2533.
3. ประกาศิต ชาติบุรุษ และอาทิตย์ จิตต์จุพานนท์ โครงสร้างข้อมูลและอัลกอริทึม สำนักพิมพ์ ซีเอ็ด, 2521.
4. ปรีชา ทิชนพงษ์ ลักษณะภาษาไทย สำนักพิมพ์โอเดียนสโตร์, 2528.
5. มนตรี พจนารถลาวัฒน์ การเขียนโปรแกรมคอมพิวเตอร์ด้วยเทอร์โบซี สำนักพิมพ์ ซีเอ็ด, 2521.
6. ยืน ภู่วรรณ " เทคนิคพัฒนาการภาษาไทยบนเครื่องไมโครคอมพิวเตอร์ " วารสารไมโครคอมพิวเตอร์, ฉบับที่ 3, 2528-2529.
7. ยืน ภู่วรรณ และชัยขงศ์ วงศ์ชัยวัฒน์ การประมวลผลภาษาธรรมชาติ (Natural Language Processing) สถาบันเทคโนโลยีพระจอมเกล้าธนบุรี.
8. ยืน ภู่วรรณ และวิวรรณ อิ่มอารมณ " การแบ่งแยกพยางค์ไทยด้วยดิคชันนารี " รายงานการประชุมทางวิชาการ วิศวกรรมไฟฟ้า สถาบันอุดมศึกษาแห่งประเทศไทย, ครั้งที่ 9, ธันวาคม 2529.
9. ยืน ภู่วรรณ และวิวรรณ อิ่มอารมณ " การตรวจสอบตัวสะกดด้วยคอมพิวเตอร์ " รายงานการประชุมทางวิชาการ วิศวกรรมไฟฟ้า สถาบันอุดมศึกษาแห่งประเทศไทย, ครั้งที่ 10, พฤศจิกายน 2530.
10. ยืน ภู่วรรณ, สมนึก คีรีโตและ สุรศักดิ์ สงวนพงษ์ " การตัดพยางค์คำไทยด้วยโครงสร้างข้อมูลแบบต้นไม้ ", รายงานการประชุมวิชาการ ทางวิศวกรรมไฟฟ้า 8 สถาบันอุดมศึกษา ครั้งที่ 8, ธันวาคม 2528.
11. ยืน ภู่วรรณ และเสรี เสวตเสริม " การพัฒนาอัลกอริทึม สำหรับประมวลผลตัวอักษรไทย ", วิศวกรรมสาร ปีที่ 37, เล่มที่ 3, มิถุนายน 2527.

12. รัตติกร วรากุลศิริพันธ์และ สมศักดิ์ จันวัน " การตัดคำจากประโยคในภาษาไทยด้วยวิธีการเทียบคำที่ยาวที่สุด " Paper On Natural Language Processing, 2530-2537.
13. สมนึก คีรีโต " ระบบฐานความรู้เพื่อการวิเคราะห์การแบ่งแยกพยางค์ไทย " รายงานการประชุมทางวิชาการวิศวกรรมไฟฟ้า สถาบันอุดมศึกษาแห่งประเทศไทย ครั้งที่ 9 , ธันวาคม 2529.
14. อนันต์ อ่วมศาสตร์และ เนาวรัตน์ อ่วมศาสตร์ ลักษณะภาษาไทย, สำนักพิมพ์ไทยวัฒนาพานิช , 2519.
15. Collins, William J. Data Structures An Object-Oriented Approach. Addison-Wesley Publishing 1992.
16. Gonnet, G.H. and R. Baeza-Yates. Handbook Of Algorithms And Data Structures in Pascal and C. 2nd.ed, Addison-Weseley, 1991.
17. Hoch, Rainer and Thomas Kiceinger. " On Virtual Partitioning of Large Dictionaries for Contextual Post - Processing to Improve Character Recognition. " IEEE Conference 1993, pp. 226-231.
18. Kernighan, Brian W. and Dennis M. Ritchie. The C Programming Language. 2nd.ed. Prentice Hall, 1988.
19. Lewis, Harry R. and Larry Denenberg. Data Structures & Their Algorithms. HarperCollins Publisher, 1991.
20. Peterson, James L. " Computer Programs for Detecting and Corrceting Spelling Errors." Communication of the ACM , No. 12 (December 1980) , Vol. 23, pp. 676-687.
21. Peterson, James L. " A Note On Undetected Typing Errors. " Communication of the ACM, No. 7 (July 1986), Vol. 29, pp. 633-637.
22. S. Charnyapornpong. A Thai Syallable Separation Algorithm. AIT Thesis, Faculty of Engineer, No. CA-83-10, 1983.
23. Schurmann, Jurgen. " A Multifont Word Recognition System for Postal Address Reading. " IEEE Transaction on Computers, No. 8 (August 1978), Vol. c - 27, pp. 721-732 .

24. Tenenbaum, Aaron M. and Moshe J. Angenstein. Data Structures Using Pascal. Prentice-Hall Inc. 1986.
25. Tremblay, Jean-Paul. and Paul G.Sorenson. An Introduction to Data Structures with Applications. 2nd.ed, McGRAW-HILL , 1984.
26. Turner, Lawrence E. Jr. Data Structures From Recipes To C. Wm.C.Brown, 1994.
27. Weiss, Mark Allen. Data Structures And Algorithm Analysis. Benjamin Cummings Publishing, 1992.

ภาคผนวก

ภาคผนวก ก

ตารางค่ารหัส ASCII

View by:		Decimal		Name: nbspace		Unicode: 00A0									
				Key: a0160		Dec: 160									
						Hex: A0									
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47
	!	"	#	\$	%	&	'	()	*	+	,	-	.	/
48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63
0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79
@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95
P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
96	97	98	99	100	101	102	103	104	105	106	107	108	109	110	111
`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
112	113	114	115	116	117	118	119	120	121	122	123	124	125	126	127
p	q	r	s	t	u	v	w	x	y	z	{		}	~	
128	129	130	131	132	133	134	135	136	137	138	139	140	141	142	143
		...	ı	ş	ç	+	ı	ı	ı	ı	ı	ı			
144	145	146	147	148	149	150	151	152	153	154	155	156	157	158	159
	•	ˆ	˜	˘	˙	˚	˛	˜	˜	˜	˜	˜			˜
160	161	162	163	164	165	166	167	168	169	170	171	172	173	174	175
	ก	ข	ฃ	ค	ฅ	ฉ	ง	ฉ	ง	ช	ฉ	ช	ซ	ฌ	ญ
176	177	178	179	180	181	182	183	184	185	186	187	188	189	190	191
๑	๒	๓	๔	๕	๖	๗	๘	๙	๐	๑	๒	๓	๔	๕	๖
192	193	194	195	196	197	198	199	200	201	202	203	204	205	206	207
๗	๘	๙	๐	๑	๒	๓	๔	๕	๖	๗	๘	๙	๐	๑	๒
208	209	210	211	212	213	214	215	216	217	218	219	220	221	222	223
๓	๔	๕	๖	๗	๘	๙									๓
224	225	226	227	228	229	230	231	232	233	234	235	236	237	238	239
๔	๕	๖	๗	๘	๙	๐	๑	๒	๓	๔	๕	๖	๗	๘	๙
240	241	242	243	244	245	246	247	248	249	250	251	252	253	254	255
๐	๑	๒	๓	๔	๕	๖	๗	๘	๙	—	—			๐	

ภาคผนวก ข

ตารางรายการคำที่ MICROSOFT WORD 6.0 ไม่สามารถตัดแบ่งคำได้

กฎบัตรสหประชาชาติ	กระโถนถาญี	กล็องจูลทรรศน์	กากขยาถ
กฎยุทธวินัย	กระถั้น	กล็องตุค	กากฉีก
กบพูด	กระแทกกระถั้น	กล็องโทรทรรศน์	กาญจน
กปนก	กระแท้ม	กลับตาลปัตร	กามราถ
กรณีย	กระปุกหลุก	กลุ่มอกกลุ่มใจ	กายพันรน์
กรรมกรรม	กระเปาะเหลาะ	กษัตราธิราช	การิตการก
กรรมการณีย	กระเปี้ย	กษัตริยชาติ	การิตวางก
กรรมชรูป	กระแป้	กษีรามพู	กาลโยค
กรรมชวาท	กระผลาม	กะควน	กาฟปักษี
กรรมวาทจาจารย์	กระเพียด	กะมง	กาพวาท
กรรมสัมปาทิก	กระแมม	กะส้าหอย	กำริบเสิบสาน
กรรมมาธิการ	กระยาคชวาง	กัณฐ	กินหู้
กระจิง	กระยาสังวาง	กัณฐชะ	กั
กระจิม	กระลาพิน	กัณฐัส	กัณ
กระโจมอก	กระเขมสานต์	กัณฐัสวี	กัณวิทยา
กระเลง	กระเหมา	กัณห	กัณกัถ
กระโฆกโฆกฮาก	กระอ่วน	กัณหธรรม	กุกกุก
กระซ้อ	กระอ๊กกระอ่วน	กัณหปักษ	กุกกอร
กระชกกระช	กรัณท	กัปปีย	กุกกาการ
กระช	กริตย	กัปปียการก	กุกมก
กระเช่ากระช	กริยวิเศษณานู-	กัปปียกัณท์	กุกมการ
กระดิง	ประโยค	กัปปียโวหาร	กุกมกัณท
กระเดียม	กรุณาทฤคฺณ	กัมป	กุกมกัณทยักษ
กระเดะกระแต่	กฤค	กัมปน	กุกมารลพิทา
กระดิง	กฤคตติกา	กัมปนาการ	กุกลาต็อก
กระเดียม	กฤคตย	กัมปนาท	กุกโลบาย
	กฤษฏาณชเลศ	กัถยาน	กุกกาการ

แก้งพัง	ข้าวปุ้น	คต	คัมภีร์
เกรงอกเกรงใจ	ข้าวเภา	คมน	คัมภีร์ภาพ
เกลือเบสติก	ข้าวฮาง	ครรรไล	ค่ายเขาวชน
เกลือยูเรต	จิค	ครอบครองปร-	คาราคาก่า
เกสี	จีกะไล่โท้	ปักษ์	ค่านูณ
เกษตรและสห-	จีเข็บ	คร้าครอะ	คิง
กรณ์	จีทุค	คริสตัง	คิถาน
แกงบวด	จีปะตี้ว	คริสเตียน	คิถานปัจจัย
แก๊ส	จีแย	ครั้นครีก	คิถานเกดัช
แก๊สไขเเนา	จีเหร์	ครุฑพ่าห์	คูนนุม
แก๊สเฉื่อย	ชั้นพลับพลา	คลอแคล	คุษ
แก๊สน้ำตา	ขุนพัฒน์	คล้อแคล์	คุษฐาน
โกกิล	บุย	คล่องแคล่ว	คุษประเทศ
โกญจ	บุยไผ่	คลอโรฟิลล์	คุษรหัสย์
โกญจนาท	บุยอินทรีย์	คลับคล้ายคลับ	คูปร์ปักษ์
โกร์นเกร็น	บู	คลา	เคมีอนินทรีย์
ขมิงทัง	เขม	คลายเคล่ง	เคร่งครัด
ขรรค	เขมรไทโรโยค	ควินสิริกิต์	เครดิทฟองซิเอร์
ขลั่ง	เขื่อม	คห	เคท
ขลึง	แขยงแขงขน	คหกรรมศาสตร์	เคทศาสตร์
ขลุกขลັก	ไ้ขัทรพิช	คหบดี	เคทเศรษฐศาสตร์
ขลุกขลิก	คช	คหปตานี	เคทสถาน
ขวายขวน	คชกรรม	คัคน	เคอย
ขันจ	คชนาม	คันถ	เค็ดตาด็อก
ขันจาสกร	คชลักษณะ	คันถฐระ	แคลเซียมคาร์ไบด์
ขันจาสีมา	คชศาสตร์	คันธมาทน์	แคลเซียมไซคลา-
ขัตติย	คชสาร	คันบวย	เมต
ขัตติยมานะ	คชสีห์	คับอกคับใจ	ฆ้องหุ่ย
ข้าวโกบ	คณ	คัพภ	งกเงิน
ข้าวบิณฑ์	คณบดี	คัพภสาลี	งงววย

ง่วงงุน	จรม	จันทรุปราคา	จูลชีวัน
งอมแงม	จரிய	จับยี่กี	จูลชีวิน
งาล้ว	จริยธรรม	จั่ว	จูลพรรคนัน
งูสวัด	จริยวัตร	จาด	จูลวรรค
เงินคาวน	จริยศาสตร์	จาดุทสี่	จูลศักราช
เงินสเตอร์ลิง	จริยศึกษา	จาดูร	จูลดาว
โงนแงน	จองคช	จาดูรงค	จูลินทรีย์
จตุ	จะกรัจจะกราจ	จาดูรงคสันนิบาต	เจคีย
จตุกาลธาตุ	จ๊ะเอ๋	จาดูรราชการ	เจคียถาน
จตุตถ	จักรพรรดิ	จำนวนจินตภาพ	เจคียสถาน
จตุทิพยคันธา	จักรวรรดิ	จำนวนตรรกยะ	เจदनารมณ
จตุบาท	จักรวรรดินิยม	จำนวนอตรรกยะ	เจคีย
จตุบริษัฏ	จักรवाद	จิตต	เจริญสมณธรรม
จตุปัจจย	จันท	จิตตภาวนา	เจ้าขุนมูลนาย
จตุปารีสุทธิศีล	จันทวาทา	จิตตวิสุทธิ	เจ้าเซ็นเดินตำบุด
จตุร	จัตวาทัณฑ์	จิตตานุปัสสนา	เจ้าประคูน
จตุรคุณ	จัตูร	จิตรปทา	เจ้าสัว
จตุรงคนายก	จัตูรพักตร์	จินต	เจีย
จตุรงคประดับ	จัตูร मुख	จินตกวี	เจ็อย
จตุรงคยมก	จัตูรมุข	จินตนาการ	เจ็อยแจ้ว
จตุรถ	จันทนา	จินตภาพ	แจ่ง
จตุรพักตร์	จันทร	จिर	แจ้น
จตุรพิช	จันทรกลา	จिरกาล	แจบ
จตุรพิชพร	จันทรกานต์	จิริฐิติกาล	แจ่ม
จตุร मुख	จันทรคติ	จุฑาธิปไตย	แจ่มแจ้ง
จตุรภูมิ	จันทรคราส	จุฑุทธศาสตร์	แจ่มใส
จตุรยุค	จันทรพิมพ์	จุฑสมสุรทิน	แจ้วแห้ว
จตุลึงคบาท	จันทรมณฑล	จุล	ฉกษัตริย์
จตุโลกบาล	จันทรวงค์	จุลกฐิน	ฉกามาพจร
จรรณขันธ์	จันทรเสขร	จุลชีพ	ฉกามาพจร

ฉง	ช้อ	โซเดียมไซคลา-	ดุลยภาพ
ฉทวาร	ชอุม	เมต	คูคู
ฉทานศาลา	ชัค	โซเดียมไฮโดร-	คูรี
ฉพีสติม	ชังฉ	เจนกฐาเมต	เด็กเมื่อวานขึ้น
ฉสก	ชังฉวิหาร	โซเดียมไฮโดร-	เคโซ
ฉันท	ช่างฟิต	เจนซัลเฟต	เคโซชัย
ฉันทลักษณะ	ชาต	โซรมศาสตร์ารูช	เคโซพล
ฉันทวิลาศ	ชาตรูป	ฉาปน	คคะแต่
ฉันทศาสตร์	ชาตสระ	ฉาปนกิจ	คกขุย
ฉินท	ชาวเล	ฉาปนสถาน	คกใต้เถรเทวทัต
ฉินทฤกษ์	ชีรณคคิ	ญาณทัสนะ	คจ
ฉุ กฉิน	ชีว	ฐานกรรม	คจปัญจก
ฉุ กะหุก	ชีวเคมี	ฐาปน	กรรมฐาน
ฉเใจ	ชีวประวัติ	ทังส	คจสาร
ฉยเมย	ชีวโลก	ทาก	คคิย
ฉลิมพระ	ชีววิทยา	คนุช	คณุมัธยา
ฉนมพรรษา	ชุนห	คอกค้ว	คัมโคล้ง
ฉ่องฉ่าง	ชุนหปักษ์	คะหมัง	คัมเปอะ
ชค	ชุนฉ	คังรือ	คโมนุท
ชงฉ	ชุนฉปักษ์	คามพ	ครมคยอม
ชนม	เชษฐ	คามพวรรณ	ครรก
ชนมพรรษา	เชษฐะ	คิเปรสชัน	ครรกศาสตร์
ชนินทร์	โชติค	ค็อกคิใจ	ครัง
ชเนตคิ	โชโหว	คุ่ม	ครังค
ชมฉัว	ชอกแซก	คูริย	ครังควชิราวคิ
ชมพูนุท	ช่องแซง	คูริยางค	คธาไปรษณียากร
ชลธารก	ชับชาบ	คูริยางคศาสตร์	คร์กัณสวาด
ชลธิศ	ชิมชาบ	คูริยางคศิลป์	คร์ฉินทลามกา
ชลธิ	เชลล์ทุคิยภูมิ	คูลย	คร์ชีชาต
ชว	โซเดียมซัลเฟต	คูลยพินิจ	คร์ชีพิยรส

ตรีทิวรสว	ติ	ถึงแก่มรณภาพ	ทรงสนาการ
ตรีเทวตรีคันธา	ติก	ถึงแก่อสัญกรรม	พระราช
ตรีปีตผล	ติงส	ถือน้ำพระ	ทรงลักษณ์
ตรีภูว	ติงสติม	พิพัฒน์-สัตยา	ทรัพย์
ตรีมธูร	ตีคตื้อ	ถู	ทรัพย์สิทธิ
ตรีโลจน์	ตุ้ตะ	ถู	ทฤษ
ตรีโลก	ตุ้บต๊	ถูปรหุคคค	ทลบบ
ตรีวาคผล	ตุรงค	ถู	ทวัดคังสาการ
ตรีสุรผล	ตุล	เถย	ทวาทสม
ตรีเสมหผล	ตุหรดตุหระ	เถยจิต	ทวาทตี
ตรีงศ	เต็มอก	เถยเจตนา	ทวابر
ตฤตีย	เต็มอกเต็มใจ	เถยสังวาส	ทวิช
ตฤ	เตนแก๊ต	เถลไถล	ทวิชงค์
ต่อนัดต่อเนง	เต้าหู้	ไถย	ทวิป
ตอม่อ	แตรพินฟาร์	ทนต	ทศเบญจกุก
ตะเกียงแก๊ต	แตรวงโยธวาทิต	ทนตกาษฐ์	ทศพิชราชธรรม
ตะพีดตะพื่อ	ไตรกิสยา	ทร	ทศม
ตะหลุง	ไตรตรีงษ์	ทรกรรม	ทองคำเปลว
ตั้งอกตั้งใจ	ไตรยางค์	ทรงข้าวบิณฑ์	ทองเค
ตัศตวศาสตร์	ไตรวัฏ	ทรงมณฑ์	ทองชมพูนุท
ตันอกตันใจ	ไตรสรณาคมน์	ทรชน	ทองบรอนซ์
ตาไก่อ	ถนัถนั	ทรชาติ	ทองสักโก
ตามพ	ถมถัด	ทรทัง	ทองฮัสตคคค
ตามพหัตถี	ถมถ	ทรชีก	ทอดหุ่ย
ตายขุย	ถวัดถวัน	ทรพล	ทักษ
ตาลปีตร	ถ้วคร้า	ทรพิษ	ทักษ
ตาลปีตรบั้งเพลึง	ถ่านไค้ก	ทรพี	ทักษกรรม
ตาลปีตรถาญี	ถ่านไฟแซ็ก	ทรภิกษ์	ทักษมาต
ตาลปีตรถาญี	ถิร	ทรยศ	ทักษนิคม
ตาลอ	ถิน	ทรยุค	ทักษวิทยา

ทัศนสถาน	ทิวชม	เทวนิยม	ธรรมนุญการปก-
ทัต	ทุกข	เทวภาวะ	ครองราชอาณา-
ทันต	ทุกขนิโรธ	เทวรูป	จักร
ทันตชะ	ทุกขลาภ	เทวโลก	ธรรมะธัมโม
ทันตแพทย์	ทุกขเวทนา	เทววาจิกะ	ธรรมากิมุข
ทัศน	ทุกขสมุทัย	เทววิทยา	ธราชิปตี
ทัศนคติ	ทุกขารมณ	เทวสถาน	ธราชิป
ทัศนวิสัย	ทุกขีย	เทห์	ธเรษตรีศวรร
ทัศนศาสตร์	ทฐ	เทห์ฟากฟ้า	ธัญดัจ
ทัศนศึกษา	ทฐกัณดาร	เทียรชม	ธาดุโภภ
ทัศนีย์	ทฐคม	เทียรชมชาติ	ธานินทร์
ทัศนีย์ภาพ	ทฐชน	เทียรชมราตร	ธราชิคุณ
ทาร	ทฐชาติ	เท็กซีมิเตอร์	ธีร
ทิจากร	ทฐพล	โทรทรรรศน์	ธีรภาพ
ทิจฐ	ทฐภิกษ	โทรมคัตตราวุธ	ธีรราช
ทิจพย	ทฐลักษณ	โทษกรรม	ธุดงค
ทิจพยจักษุ	ทฐฐ	โทษารมณ	ธุดงควัตร
ทิจพยจักษุญาณ	ทฐ	โทส	ธุดงคสมาทาน
ทิจพยญาณ	ทฐ	ธงพระครุฑพ่าห์	ธุม
ทิจพยเนตร	เทพย	ธงเยวราชน้อย	ธุมเกตุ
ทิจพยพยาน	เทพยเจ้า	ธงเยวราชใหญ่	ธุมชาด
ทิจพยมานุษ	เทพยดา	ธนาณัติ	ธุมเพลิง
ทิจพยรส	เทพนทร์	ธนิษฐะ	ธุมมา
ทิจพยไศรศร	เทตฐเรียม	ธนุร	ธุร
ทิวส	เทว	ธนุรमारค	ธุรการ
ทิวชม	เทวทัณท์	ธนุรเวท	ธูว
ทิวชมชาติ	เทวทูต	ธรณิศวร	ธูวดารา
ทิวชมนิกาย	เทวธรรม	ธรรมกถีก	ธูวภาค
ทิวชมสระ	เทวธิดา	ธรรมนุญ	ธูวมณฑล
ทิวชมาย	เทวนาครี		ธูวชัยฎี

รูปถ่าย	นฤคัม	นพทวาร	นิตย
นข	นฤคย	นพนิค	นิตยทาน
นขทวารณ์	นฤคยั	นพนิยาย	นิตยภัค
นขลัษิต	นฤคยศาลา	นพปฏล	นิตยสาร
นขเลขา	นฤคยศาสตร์	นพพฐ	นิตยกรณ
นขา	นฤคยสถาน	นพมุข	นิตยารมณ
นค	นฤเทพ	นพรัตน์	นิตยฆ
นค	นฤนาท	นพโลหะ	นิตยพัท
นคจร	นฤบตี	นพวิธ	นิตยพัทกุศล
นคดล	นฤบาล	นพอรหาคิณ	นิตยนิค
นคณทล	นฤเบศ	นพอรหาคิณ	นิตยโฆษ
นควิถี	นฤป	นคเลง	นิตย
นคสุท	นฤปนีติ	นคษัตรเนมิ	นิตยบาล
นคสินธุ์	นฤปเวศม์	นคษัตรปาฐก	นิตยันตร
นคบกอกพรอง	นฤปัดนี	นคษัตรโยค	นิตยาคี
นค	นฤพาน	นคสรราช	นิตย
นค	นฤมล	นคันท	นิตย
นคเทพ	นฤมาณ	นคันทปักษี	นิตยจร
นคนาถ	นฤมิต	นคเวษ	นิตย
นคนายก	นค	นคสังวัจจร	นคกระโจมอก
นคบดี	นค	นคคินทร์	นคนัง
นคบาล	นคกภูมิ	นคภุช	นค
นคพยัคฆ์	นคกรรม	นคไรช	นคาวรัตน์
นคราช	นคกรรมิก	นคากิไรช	นคั่นนัค
นคเศรษฐี	นคการ	นค้ำพระพิพัฒน์-	นคั่นแพน
นคสิงห์	นคกิจ	นคตัชยา	นคั่นหน้าอก
นคสีห์	นคครหะ	นคคิมสทกรณ	นค
นค	นคคณ	นคคิมอุตสาหกรรณ	นคคสุกติก
นคคหิต	นคคระหะ	นคค	นคคัวร์ดา
นคโฆษ	นคคชาต	นคคหกรรณ	นคคภษณ

บทกวี	บำเรอเชอภักดี	เบญจกูด	ปโยชรา
บทเรศ	บิณฑ	เบญจคัพย์	ปโยนิธิ
บทวเรศ	บิณฑบาท	เบญจม	ปโยราตี
บมิ	บิตุจลา	เบญจมสุรทิน	ปร
บร	บุบบิบ	เบญจโลหกะ	ปรตย์กษ
บรรทการ	บุปผ	เบญจวรรณ	ปรนัย
บรรทการกรรม	บุปผชาติ	เบญจวรรณห้าสี	ปรปักษ์
บรรพตคีลา	บุปผวิกิต	เบญจางค	ปรม
บรอนซ์	บุพเปตพลี	เบญจางค	ปรโลก
บราร	บุพพ	ประดิษฐ์	ปรวาทิ
บริษัทเครตติ-	บุพพษาณ	เบอะบะ	ประกายพริก
ฟองซิเอร์	บุพพสาพะ	แบะอก	ประกบประหม
บแรง	บุพวิทท์	โบกขร	ประโคนธรรม
บแรงภักษ์	บุรพผลคูนี	โบกขรพรรษ	ประจักษ์
บอกหนังสือ-	บุราณทุดิยิกา	โบททสัมา	ประจักษ์นิยม
สังฆราช	บุษบ	ปฎิ	ประเจ็ดประเจ็ด
บอง	บุษบราค	ปฎิการ	ประชาติปไตย
บเอ	บุษบวรช	ปฎิคิด	ประชาติบาล
บัญญัติไตรยางค์	บุษบัน	ปฎิญาตากลว่า-	ประดักประเดิด
บัญญัติพฤค	บุษบาบัน	ด้วยสิทธิมนุษย-	ประดี
บัณเฑาะก์	บุษป	ชน	ประดิษฐ์
บัดแมลง	บุษยะ	ปฐมโพธิกาล	ประดิษฐ์กรรม
บาทนิกต	บุหงาประหงัน	ปฐมสุรทิน	ประเด็ยวประด้าว
บาทภัก	บุหงามลาชอ	ปฐมษาณ	ประทุษฤจิต
บาทรช	บุชเนีย	ปนเป	ประทุษฤจิต
บานเบียง	บุชเนียสถาน	ปปัญจ	ประมุท
บานโกชน	บุรณ	ปปัญจธรรม	ประดัยवाद
บานโยทก	บุรณภาพ	ปโย	ประสัยท
บารร์รด	บุรณมี	ปโยชนม์	ปรารค์ปรา
บ้ำระห้ำ	บุรพษาณ	ปโยชร	ปริณามัคติ

ปรีย	ปัจฉิมคาม	ปานทัศน์	ปุรพชาต
ปรียรณ	ปัจฉิมตชนบท	ปานนาส	ปุษยะ
ปรียวาท	ปัจฉิมตประเทศ	ปานภูต	ปุสสะ
ปรียวาทิ	ปัจจุส	ปานวินาส	ปุชนีย
ปริเวณ	ปัจจุสกาล	ปานसार	ปุธิปุยา
ปฐิตปฐิต	ปัจจุสมัย	ปานิมุกต์	เปกข์
ปลวังค	ปัจเจกโพธิ	ปานีย	เป็ดก่า
ปลาม้า	ปัจโจสกาล	ปาป	เปต
ปวัตน	ปัจยการ	ปาปมุต	เปตพลี
ปวัตนาการ	ปัจญ	ปาร	เปตวิสัย
ปลันน	ปัจญจณี	ปารคู	เปตอง
ปลันนาการ	ปัจญจม	ปาเส็งเคริง	เปรมปรา
ปลัษห	ปัจญจวัคคีย์	ปาหุไณย	เปทว
ปลัษหการ	ปัจญจสาขา	ปาหุไณยบุคคล	เปศลมรัย
ปลัษหาวหาร	ปัจญญาส	ปิงค	เป็ดอก
ปะวะหลิม	ปัจณรส	ปิงคหัตถิ	เป็ยะ
ปักข	ปัจณรสม	ปีตามหะ	แปรปรวน
ปักขคณนา	ปัจณรสมสูตริน	ปีตามหัยกา	แป๊ะ
ปักขพิฬาร	ปักทม	ปีตามหัยชิกา	โปกขร
ปักษ	ปักทมปาณิ	ปีโตรเลียม	โปกขรพรรษ
ปักษกษัย	ปักทมราค	ปิย	โป้งไย้ง
ปักษคณนา	ปักทมราช	ปีหลัน	โปฐบพ
ปักษคม	ปีนจุหรีจ	ปีมะไว้	โปฐปทมาส
ปักษธร	ปาฏิหาริย์	ปุนัพพสุ	โปรงเปรง
ปักษเภท	ปาฐ	ปุพพ	ไปรษณีย
ปักษวาหน	ปาฐก	ปุพพผลคฺณี	ไปรษณียนิเทศ
ปักษานดร	ปาฐกถา	ปุพพะภัททะ	ไปรษณียบรรณ
ปักษาวสาน	ปาณ	ปุม	ไปรษณียบัตร
ปักษ	ปาณก	ปุมป่า	ไปรษณียภณท์
ปัจฉิมต	ปาณกชาติ	ปุรพผลคฺณี	ไปรษณียวัตถุ

ไปรษณียากร	โศภณัฐพะพะ	พฤษ	พิมพ
ผมซึ่งเกิด	โศย	พฤษชาติ	พิมพากรณ
ผมบ็อบ	โศอน	พฤษทล	พิริย
ผรณ	ฝรั่งเศส	พฤษเทวดา	พิริยพฤษ
ผรส	พงศ	พฤษราช	พิริยโยธา
ผรสวาท	พงศกร	พฤษศาสตร์	พิลีกก็กือ
ผลคุณ	พงศธร	พฤษ	พิลีกฟิลัน
ผลคุณี	พจน	พฤษมา	พ็เบ้ม
ผลคุณีบูรพมาส	พญาพชาติ	พฤษมาจารย์	พ็ร
ผลับ	พณิข	พลว	พฤษมามกะ
ผลิก	พณิขย์	พล้งงานจณ	พฤษศาสนิกชน
ผลิกสิขรี	พณขันท์	พลับพลา	พุ่มข้าวบิณฑ์
ผลิกศิลา	พย์กพยิด	พอ โคนิยม	พื่อเจ้อ
ผลุนผลัน	พย์คฆ	พักตร	แพทย
ผลุปผลัป	พยุห	พัฒน	แพทยศาสตร์
ผสมผส	พยุหบาตร	พัทร	โพธิ
ผัสส	พยุหบาตรา	พัทรสีมา	โพธิญาณ
ผากแผ้ง	พยุหยาตรา	พันธ	โพธิบัลลังก์
ผาลคุณ	พยุหโยธา	พันธกรณ	โพธิปักขิยธรรม
ผิน	พยุหเสนา	พันธบัตร	โพธิสมภาร
ผินหลังให้	พยุหแสนยา	พันธมิตร	โพธิสัตว์
ผืด	พยุหแสนยากร	พันธวรรษ	โพนแพน
ผูกพัทรสีมา	พรรคกลิน	พ่าห์	โพยกัวน
ผเน	พรมจรรย์	พิจิก	ไปปัก
ผเนธรรม	พรมจารณ	พิดย	ไปรสาณท์
ผยิบผยาบ	พริ้อมพรัก	พิดิ	พอดแพด
ผล่อไหล	พฤษทัย	พิตย	พิดเพียด
ผือกโทป่าด	พฤษญาษ	พิตยาการ	พะอะพะ
โศภณัฐพ	พฤษหารณย์	พิตพัฒน	พะพะ
โศภณัฐพธรรม	พฤษหารันย์	พิตพิภณฑสถาน	ไฟแฉ็ก

ภย	ภูกตเศษ	มรุร	มฤคศิรัศ
ภราตร	ภุญช	มรุรตรัย	ม้วนค้วน
ภราตรภาพ	ภุชเรศวร	มรุรพจน์	มหรณพ
ภราตฤ	ภุเนตุ	มรุลีห	มหัจฉริย
ภราตฤภาพ	ภุเบนทร์	มนท	มหันต
ภวังค	ภุเบศ	มนทกานติ	มหันตโทษ
ภวังคจิต	ภุเบศวร	มนัสคาป	มหิป
ภักต	ภุป	มनुย	มอมแมม
ภักตฤคฤตย์	ภุมินทร์	มनुยชาติ	ม่อห้อม
ภักษ	ภุมิบริมาณ	มनुยเทพ	มะม่วงหิมพานต์
ภักษการ	ภุมิศาสตร์	มनुยธรรม	มะตัง
ภังค	เศรษฐกิจ	มनुยโลก	มัด
ภันฑ	ภุมีศวร	มनुยศาสตร์	มัดนายก
ภันฑกรรม	ภุรโลก	มनुยสัมพันธ์	มังคละ
ภาคเศษ	ภุว	มनुยอวกาศ	มังส
ภานีย	ภุวดล	มโนนฤต	มังสวัตติ
ภาระติคพันใน-	ภุวนัตตรัย	มโนภินิเวศ	มัด
อสังหาริมทรัพย์	ภุวนาด	มยุร	มัดม
ภาว	ภุวเนตร	มยุรคติ	มัดมันติก
ภาวศุทธิ	ภุวไนย	มยุรฉัตร	มัดมันติกสมัย
ภาวะรูกเนิน	ภุษณ	มยุรอาสน์	มัดมิม
ภิกษุ	ภุษณพาส	มรณ	มัดมิมนิกาย
ภิน	เภสัชพฤษ- ศาสตร์	มรณกรรม	มัดมิมบุรุษ
ภินชาติ	ศาสตร์	มรณธรรม	มัดมิมประเทศ
ภินท	เภสัชอุตสาห- กรรม	มรณบัตร	มัดมิมภูมิ
ภินทน	กรรม	มรณภัย	มัดมิมยาม
ภินวรรณ	โกชน	มรณภาพ	มัดมิมวัย
ภีรูก	มณีราค	มรณันติก	มัดมิมวัตติ
ภีรูกชาติ	มต	มฤคศิร	มัดม
ภูกต	มรุป	มฤคศิรมาส	มัดมทาน

มันทนศิลป์	มูตั้ง	มุกันด	เขาวราช
มัธย	มูพท	มุกันตวาด	เขาวเรศ
มัธฐาน	เมรย	มูทช	เขาวลักษณะ
มัวชั่ว	แม่่น	มูทชการ	เขิ่นเขื่อ
มาคสิร	แม่่นข่า	มูทชนาธิการ	โยกเขก
มาฆ	แมลงวันสเปน	มูทชกัณฑ์	โยค
มาฆบุชา	โมกข	มูทชกภูมิ	โยคจักฆ
มานทะเลสุน	โมกขบริสุทธี	มูทชโยธา	โยคนิทรา
มานุษย	โมกษ	มูทชวิธี	โย่งแย่ง
มานุษยวิทยา	โมฆ	มูทชวินัย	โยธ
มิกสิร	โมฆกรรม	มูทชศาสตร์	โยธวาทิต
มิฉากัมมันตะ	โมฆีย	มูทชหัตถิ	โยพนมัท
มิณช	โมฆียกรรม	มูทชโรปกรณ์	รคเร็วว
มิต	โมร	มูพ	รงค
มิตภาณี	โมห	มูพดี	รงควัตถุ
มิม	ไมกัธรัฐพส	มูพยง	รถจุกเงิน
มิศรค	ไม้พัฒนาฆาต	มูพเขาว์	รมณีย
มิส	ชคิกังค์	มูว	รวนเร
มีพท	ชมกปาฏิหาริย์	มูวชน	รโหด
มุขบารู	ชว	มูวราช	รังสร้าง
มุขย	ชวา	มูวราชา	รังสีคอสมิก
มุขยประโยค	ช้ง	เข็บอก	รัชด
มุตกิด	ชัคเขียด	เขกยูย	รัชด
มูทชากิเชก	ชันตร	เขกยูยน้อย	รัฐธรรมนุญ
มูบมิบ	ชันตรกรรม	เขกยูยลิกา	รัฐประศาสนนัย
มูรชากิเชก	ชางมะตอย	เขาว	รัฐประศาสน-
มูฮัมมัด	ชاپนมัด	เขาวชน	ศาสตร์
มูค	ชามโยค	เขาวนะ	รัฐประศาสนโน-
มูรช	ชิมนาสติก	เขาวมาลย์	บาย
มูละ	ชี่	เขาวยอด	รัตน

รัตนโกสินทร์	ลหุก	ภาสาย	จักฎี
รัตนดรัย	ทองธรรม์	วงศ	วังมรรค
รัตนบัลลังก์	ลักษณะ	วงศกร	วัชร
รัตนสิงหาสน์	ลักษณะนาม	วชิร	วัชรธาตุมณฑล
รัมก	ลักษณะอาการ	วชิรปาณี	วัชรปาณี
รัมณีย	ลักษณะณ์	วชิรหัตถ์	วัชรยาน
รัต	ลักษณะ	วณ	วัชรอาสน์
รัตสระ	ลักษณะ	วณบัตร	วัฏ
ราชกิจจานุเบกษา	ลายสื่อ	วณพันธน์	วัฏจักร
ราชภัฏ	ลิต	วต	วัฏทุกข์
ราชมัต	ลุ่มคุ่น	วทานีย	วัฏสงสาร
ราชโยค	ลุ่มโดง	วธ	วัฒน
ราชวโรงการ	ลูกรมโหด	วธก	วัฒนธรรม
ราชหัตถเลข	เลขาริการ	วร	วันทย
ราชองครักษ์	เล่นพิเรนทร์	วรคณุ	วันทยหัตถ์
ร้ายกาจ	เลป	วรท	วัส
รุกข	เลปกร	วรทาน	วัสคณนา
รุกขชาติ	เลอะเทอะ	วรมหาวิหาร	ว้าก
รุกขมูล	เลอะเทอะ	ววรรณ	วากจิริพัศตร์
รุกขมุติกษุดงค์	เล็กเล็ก	ววรรณกรรม	วากย
เรียบวูธ	เลือดในอก	ววรรณคดี	วากยสัมพันธ์
เรื้อยเจื้อย	เลื้อยเจื้อย	ววรรณยุกต์	วาด
แรงงานและ-	โลกเชษฐ	ววรรณยุกต์	วาดปานะ
สวัสดิการสังคม	โลกาภิวัตน์	ววรรณศิลป์	วาดกัย
ฤทัย	โลกุตระ	วรรษา	ว่าแต่เขาอิเหนา-
ฤทัย	โลท	วรวิหาร	เป็นเอง
ฤทัยแปลงสาร	โลทกุมภี	วสันต	วาทย
ฤทัยผสมแล้ว	ไล่เลีย	วสันตวิมุวัด	วาทยกร
ฤทัยเลียขลิง	ภา	วัคควัท	วานชื่น
ลขุโกชน์	ภาษา	วัจ	วาลธิ

วิกข์มกณะ	วีรชน	คัสตรศาสตร์	ศิษย์
วิกข์ติ	วีรบุรุษ	ศากย	สีต
วิกข์ติการก	วุ่นเป็นจุดกฐิน	ศากยเกตุ	สีตกาล
วิกข์กาลโกชน	เวนคีนอสังหาริม-	ศากยพุทธ	ศึกษาธิการ
วังระแบง	ทรัพย์	ศากยมุนี	ศึกษานิมิตส์
วิทช	เวม็ดิก	सानต	สุกร
วิทชฐานะ	เวียง	सानตรส	สุกรวรรณ
วิทชาคาร	ศตปที	सानติก	สุกถ
วิทชศาสตร์ชีว-	ศตสังวัตสร	ศापมุกดี	สุกถปักษ์
ภาพ	ศระวะณ	ศาลคตีเล็กและ-	สุก
วินช	ศราทช	เขาวชน	สุกกร
วีร	ศราทชพรด	ศาลเขาวชนและ-	สุกเคราะห์
วีโรฒ	ศศ	ครอบคร้ว	สุกนิมิต
วีโรชน	ศศชร	ศาสตร์	สุกมัสตุ
วิลช	ศศพินท์	ศาสน	สุกมาตรา
วีโลววรรณ	ศศลักษณ์	ศาสนจักร	สุกมาส
วีวรรณ	ศศิขันธ์	ศาสนีย	สุกกร
วีวัฒน์	ศักย	ศิริ	สุกอักษร
วีวาท	ศักยภาพ	ศิริประภา	สุกถ
วิศาช	ศักกร	ศิลป์	สุนช
วิศาชบุชชา	ศักกรภพน์	ศิลป์กร	สุนชพ่าห์
วิเศษณ	ศักพท	ศิลป์กรรม	สุนชภาพ
วิเศษณการก	ศักพทมูลวิทช	ศิลป์การ	สุนชเขาวชน
วิศช	ศักถ	ศิลป์กิจ	สุนชวาท
วิศาช	ศักถกรรม	ศิลป์วิทช	เศรษฐ
วิศาชบุชชา	ศักถแพทช	ศิลป์ศาสตร์	เศรษฐกิจ
วิศามานชนาม	ศักถศาสตร์	ศิว	เศรษฐศาสตร์
วีต	ศักตร	ศิวโมกข์	เศจ
วีร	ศักตรกรรม	ศิวถึงค์	โสภศักถ
วีรกรรม	ศักตรการ	ศิวเวท	ชมายุมแบลง

สกฎ	สมุหเทศาภิบาล	สวามิภักดิ์	สังค
สกฎการ	สมุหนาม	สห	สังคญาติ
สกลมหาสังฆ	สมุหนายก	สหกรณ์	สังฆ
ปริณายก	สมุหประธาน	สหการ	สังฆกรรม
สงสารวิภู	สมุหพระกลาโหม	สหจร	สังฆการี
สคัมภ์	สรณ	สหชาติ	สังฆเถระ
สควิร	สรณคมนตรี	สหชาติ	สังฆทาน
สควิร	สรณศรัย	สหธรรม	สังฆนายก
สคิร	สรณาคมนตรี	สหธรรมิก	สังฆปาโมกข์
สนุกเกอร์	สรีร	สหบาน	สังฆภัก
สภาว	สรีรภิก	สหประชาชาติ	สังฆเภท
สภาวการณ	สรีรธาตุ	สหพันธ์	สังฆมณฑล
สมณ	สรีรวิทยา	สหพันธรัฐ	สังฆมนตรี
สมณบริหาร	สรีรศาสตร์	สหภาพ	สังฆมราช
สมณโฆหาร	สลบไสล	สหภาพแรงงาน	สังฆสภา
สมณศักดิ์	สลา	สหศึกษา	สังฆาธิการ
สมณสารูป	สว	สหัส	สังฆ
สมณศาสน	สวกรรม	สหัสธารา	สังฆกร
สมณะ	สวการย	สหัสันยน์	สังฆการ
สมเด็จพระสังฆ-	สวณีย	สหัสเนตร	สังฆชาติ
ราช	สวภาพ	สหัสรังสี	สังฆชาติญาณ
สมถ	สวรรค	สหัสสะ	สังฆตาท
สมถยานิก	สวรรคค	สอนหนังสือ-	สังฆ
สมถวิปัสสนา	สวรรคคปตี	สังฆมราช	สังฆ
สมบัตินักเลง	สววรรค้อยในอก-	สะบักสะบอม	สังฆวาร
สมปฤาดี	นรกอยู่ในใจ	สะบัดสะบั้ง	สังฆ
สมฤาดี	สวราชย	สังฆ	สังฆพรต
สมิติ	สวัสติการ	สังฆกร	สังฆวาที
สมุห	สวัสติ	สังฆค	สังฆ
สมุหกลาโหม	สวามินี	สังฆคธรรม	สังฆบาล

สัตว์แพทย์	สากษิน	สีฆ	สุริยเคราะห์
สัตว์โลก	สากษย	สีต	สุริยมณฑล
สัตว์วิทยา	สากิย	สีห	สุป
สัตว์ชาติ	สากิยบุตร	สีหนาท	สุรย
สันถว	สากิยมุณี	สีหบัญญัติ	สุรยกานต์
สันถวไมตรี	สีง	สีหราช	สุรยคราส
สันติภูิก	สาฎิก	สุคนธ	เสกข
สับปลี	सान	สุคนธรส	เสกขบุคคล
สัปด	สาธย	สุญญ	เสข
สัปดปรณ	สามนต	สุทฐ	เสขบุคคล
สัปดประกรณ	สามนตราช	สุธาโกชน	เส็งเคร็ง
สัปดสดก	สามานย	สุนทรีย	เสต
สัปด	สามานยนาม	สุพรรณภาษน	เสนห
สัปดศก	สารบบ	สุภ	เสนาธิการ
สัปบุริส	สารบบ	สุ่มเสียง	เสนาธิปด
สัมพัจฉร	สารัตถ	สุร	เสนาพยุห
สัมพัจฉรฉินท์	สาราณีย	สุรคต	เสนาพยุห
สัมพันธ	สาราณียธรรม	สุรเชษฐ	เสถ
สัมพันธภาพ	สาหัตถ	สุรบถ	เสถบรรพต
สัมพันธมิตร	สาหัตถิก	สุรภาพ	เสารภย์
สัมพันธไมตรี	สำนึ่ง	สุรโลก	เสาว
สัมพาหะ	สีขานล	สุรสีหนาท	เสาวคันท์
สัมพุทฐ	สิงห	สุรเสียง	เสาวธาร
สัมมากัมมันตะ	สิงหนาท	สุริย	เสาวภา
สัมฤทธิ	สิงหบัญญัติ	สุริยกันต์	เสาวภาคย์
สัมฤทธิศก	สิงหราช	สุริยกานต์	เสาวภาพ
สัลลาป	สิงหลก	สุริยการ	เสาวรภย์
สัลเลข	สีญจ	สุริยกาล	เสาวลักษณะ
สัสต	สีทฐ	สุริยคติ	เสือบอง
สัสตทสิฐิ	สีร	สุริยคราส	แสนย

โศดทัศนวัสดุ	หรัศว	หิม	อกเต่า
โศดทัศนอุปกรณ์	หรัศวมูรดี	หิมพาน	อกแตก
โสภ	หฤทัย	หิมพานต์	อกทะเล
หงส	หฤทัยกัปน์	หิมวัต	อกนิษฐ์
หงสคติ	หฤทัยกัมป	หิมวันต์	อกเมือง
หงสบาท	หฤทัยปรีช	หิมวา	อกรวบ
หงสรถ	หฤทัยพันธน์	หิมवाद	อกโรย
หงสราข	หลงไหล	หิมวาน	อกเลา
ห้งาเหงอะ	หลาท	หิมवास	อกหัก
หญ้ายายเภา	หลีบ	หิมเวศ	อกบปีย
หทย	หลู่หลี่	หิรัณย	อกบปียวัตถุ
หน้องแหหนึ่ง	หว่าง	หิรัณยการ	อกบปียโหวหาร
หนอนตายหยาก	หสน	หิรัณยเกษตร	อคาร
หน้าอก	หอมเตียม	หิรัณยรัศมี	องค
หมักหมม	หักอก	หีน	องค์การสห-
หมากฮอส	หักอกหักใจ	หีนยาน	ประชาชาติ
หม้า	หังส	หิงส	องคชาติ
หม้าดับ	หัดถ	หีนหรรษ์	องครักษ์
หมุบหมิบ	หัดถกรรม	หือรือโหด	องควิการ
หมูหย็อง	หัดถการ	หุด	องควิเกษป
หย	หัดถกิจ	หุดโกวิท	องควิทยา
หยอกเอิน	หัดถบาส	หู่หี่	องล
หย็อง	หัดถพันธ	เหมันต	อจिर
หย็องกรอด	หัดถศิลป์	เหมาะเหม็ง	อคุลย
หย็องแห็ย	หัดถศีกษา	แห็ย	อพระ
หย็อมแห็ย	หัดถจารย์	ไหหล่า	อริก
หย็อย	หัดถาภรณ์	อก	อริกมาส
หยิกหย็อง	ห้วหน้าว	อกไก่	อริกวาร
หรรณ	ห้วอก	อคราก	อริกสุรทิน
หรรษ	ห้ส	อกตั้ง	อริปไตย

อน	อภิณฑ	อเสกข	อัญญ
อนงค	อมต	อเสกขบุคคล	อัญญิตถีย
อนงคเลข	อมตบพ	อเสข	อัญญเศียรถีย
อนงคเลขา	อย	อเสขะ	อัญญมณี
อนร	อยน	อ่อนอกอ่อนใจ	อัญญมัญญ
อนรการ	อรทัย	อ้อมอก	อัญญ
อนัตถ	อรรถถกถาจารย์	อ้อยส้อย	อัญม
อนันต	อรหันต	อะครีนาลีน	อัญพัท
อนันตร	อรหันตฆาต	อะคักอะเคีย	อัญญิมิญชะ
อนาภูล	อรัญญิก	อะคักอะเคือ	อัญ
อนารย	อรัญญาต	อะคักอะเค้	อัญจันทร
อนารยชน	อริย	อักขร	อัญมภาค
อนารยธรรม	อริยทรัพย์	อักขรวิธี	อัญมณฑล
อนีก	อริยบุคคล	อักขรวิบัติ	อัญมมาต
อนีกพรรษณะ	อริยผล	อักขนิพาท	อัญมรัตติ
อนีกทศนะ	อริยมรรค	อักขนิโหดร	อัญ
อนุตร	อริยสัง	อักข	อัญ
อนุรักษ	อวิญญาณก	อักขรชยา	อัญ
อนุรักษนิยม	อวิญญาณกทรัพย์	อักขรมหาเสนาบดี	อัญ
อนุราช	อวิโรธน์	อักขรมเหสี	อัญ
อนุราชะ	อสังหาริม	อักขรราชทูต	อัญ
อนอกอนันตัง	อสังหาริมทรัพย์	อักขรมณฑทูต	อัญ
อปจายน	อสัง	อังส	อัญ
อปจายนธรรม	อสังกรรม	อังสกุญ	อัญ
อปจายนมัย	อสังกน	อังสริย	อัญ
อปร	อสังกนพงศ	อังสริยบุคคล	อัญ
อปรภาค	อสังกนวงศ	อังสริยภาพ	อัญ
อปรัณชาติ	อสิเลสะ	อังสริยลักษณะ	อัญ
อปาน	อสุร	อังสริยลักษณะ	อัญ
อภิขนาธิปไตย	อสุรกาย	อังสรัตติก	อัญ

อันตกาล	อัสวยุช	อารยชน	อินทริยญาณ
อันตกิริยา	อัมภู	อารยชาติ	อินทริยสังวร
อันตคุณ	อัมภูกัณฑ์	อารยธรรม	อิมอกอิมใจ
อันตคุ	อัมภูมณฑล	อารยประเทศ	อิสร
อันตชาติ	อัมภูมณฑล	อารัมภ	อิสรภาพ
อันตลิกษะ	อัส	อารัมภกถา	อิสริย
อันตัน	อัสตงคต	อารัมภบท	อิสริยศ
อันติม	อัสตร	อาวัล	อี
อันติมสัง	อัสมุขี	อาวาห	อีหน้องอีแห่ง
อันตเวาสีก	อัสสนี	อาศिर	อีเหละเขละขละ
อันธ	อาคันตุก	อาศिरพจน์	อีงอล
อันธการ	อาคันตุกภัต	อาศिरพาท	อุคห
อันธพาล	อาคันตุกวัตร	อาศिरพิช	อุคหนิमित
อันโยนย	อาจริย	อาศिरวงนะ	อุณห
อันวย	อาจริยวัตร	อาศिरวาท	อุตตรผลคูนี
อัป	อาจริยวาท	อาศिरวิษ	อุตตรภัทรบท
อัปเปหิ	อาชีว	อาศิรพิช	อุตตรอาษาฒ
อัปภันตร	อาชีวศึกษา	อาศิรวิษ	อุตตรสาพาหะ
อัมพ	อาทิตย	อาสาพห	อุตตะภัททะ
อัมพวัน	อาทิตยมณฑล	อาสาพหบุชา	อุตร
อัมพวา	อาทิตยวาร	อิฏฐ	อุตรกुरु
อัมพูช	อาเนาปานัสสติ	อิทธิปาฏิหาริย์	อุตรกुरु
อัมพูจีนี	อาปนกะ	อินทร	อุตรนิกาย
อัมพูท	อ้ายเจียว	อินทรธนู	อุตรผลคูนี
อัสถุรอาณ	อายุร	อินทรวงศ	อุตรภัทรบท
อัสว	อายุรแพทย์	อินทรวิเชียร	อุตริมนุสธรรม
อัสวโกวิท	อายุรเวช	อินทรศักดิ์	อุตสาห
อัสวมุข	อายุรเวท	อินทรายุช	อุตสาหกรรม
อัสวมุขี	อายุรศาสตร์	อินทริย	อุตสาหกรรมศิลป์
อัสวเมธ	อารย	อินทริยโคจร	อุท

อุทบาตร	เอมโອ	ไฮโครเจนเพอร์-
อุทบาน	เออนະ	ออกไซด์
อุทพินท์	เอื้อเรื้อเอื้อเตื้อ	
อุบอิบ	เอาอกเอาใจ	
อุปปาติก	แอนติเงิน	
อุปสัมปทาเปกซ์	แอนติบอดี	
อุปสัมปทาเปกซ์	แอนติอิเล็กตรอน	
อุปีชฌาย	โอม	
อุปีชฌายวัตร	โอมชกล	
อุปีทว	โอมสงสาร	
อุปาน	โอด	
อุย	โอร	
อุยหน้า	โอยฐ	
อุยหน้า	โอยฐชะ	
อุร	โอยฐภัย	
อุรค	โอห์มมิเตอร์	
อุรเคนทร์	ไธ	
อุถปนนะ	ไอศูริย	
อุษณ	ไอศูริยสมบัติ	
อุษณกร	ฮวบฮาบ	
อุษณกาล	ฮะฮ้าย	
อุษณรัศมี	ฮัจญ์	
อุษณรุจี	ฮัจญะฮ์	
อุษณินัย	ฮัจญี	
อุษาโยค	ฮีดฮีด	
อุย	ฮือ	
เอกภักดี	ฮุขเลฮุข	
เอกส	ฮู้	
เอกอัครราชทูต	เฮ็ด	
เอกอัครสมณทูต	แฮก	

ตารางรายการคำที่ MICROSOFT WORD 7.0 ไม่สามารถตัดแบ่งคำได้

กฎบัตรสหประ-	กระเป๋	กะควน	กุมภการ
ชาชาติ	กระเป๋	กะมง	กุมภันชา
กฎยุทธวินัย	กระผลาม	กัณฐ	กุมภันชาชัยกษ
กบฑุด	กระเพียด	กัณฐชะ	กุมารลพิดา
กปณก	กระเมม	กัณฐศ	กุศโลบาย
กรณีย	กระยากขวาง	กัณฐศว์	กฏาการ
กรรมการณิ	กระยาตั้งวาง	กัณห	แก้งฟัง
กรรมชรูป	กระลาพิน	กัณหธรรม	เกลือเบสิก
กรรมสัมปาทิก	กระเขมสานต์	กัณหปักษ์	เกลือยูเรต
กรรมาธิการ	กระเหมา	กัมป	เกสี
กระจิ่ง	กระอ่วน	กัมปน	เกษตรและ-
กระจิม	กระอ๊กกระอ่วน	กัมปนาการ	สหกรณ์
กระเฉง	กรัณชา	กัลยาม	แกงบวด
กระโหกโหกฮาก	กริตย	กากขยาก	โกกิล
กระชิกกระชี่	กริยาวิเศษณานุ	กาญจน	โกญจ
กระชี่	ประโยชน์	กามราด	โกรันเกรัน
กระเข้ากระชี่	กรุณาทฤคุณ	การิตการก	ขมิ่งทิ่ง
กระคิ่ง	กฤต	การิตวางก	ขรรค
กระเดียม	กฤตติกา	กาลโยค	ขตั้ง
กระแตะกระแต่	กฤตย	กาพวาด	ขตั้ง
กระคิ่ง	กฤษฏาญชเลศ	กำเรบเสิบสาน	ขลุกขลัก
กระเดียม	กล้องจุลทรรศน์	กินหู้	ขลุกขลิก
กระโถนฤาษี	กล้องตุค	กึ	ขวายขวน
กระหั้น	กล้องโทรทรรศน์	กึ๊กกือ	ชันชา
กระแทกกระหั้น	กลับตาลปัตร	กุกกุก	ชันชาสกร
กระแท้ม	กษัตราธิราช	กุกกुर	ขัดตีย
กระปุกหลุก	กษัตริยชาติ	กฏาการ	ขัดตียมานะ
กระปาะเหลาะ	กษีรามพู	กุมภ	ข้าวโกย

ข้าวบิณฑ์	คต	คิลาน	จตุรงคยมก
ข้าวปั้น	คมน	คิลานปัจฉิม	จตุรพิธ
ข้าวเภา	ครรไล	คูนนุม	จตุรพิธพร
ข้าวฮาง	ครอบครอง-	คุษห	จตุลึงคบาท
ชิด	ปรปักษ์	คุษฐาน	จรรยาขันฑ์
ชี่กะไล้ไ้	คร่ำครอะ	คุษประเทศ	จริม
ชี่เจ็บ	คริตเตียน	คุษหรัศย์	จரிய
ชี่ทุค	ครันครีก	คูปริภักย์	จริยธรรม
ชี่ปะตี้ว	คลอกแคล	เคมีอนินทรีย์	จริยวัตร
ชี่แย	คล้อแคล้	เคร่งครัด	จริยศาสตร์
ชี่เห่	คล็องแคล้ว	เครคิดฟองซิเออร์	จริยศึกษา
ชันพลับพลา	คลับคล้ายคลับ	เคห	จงคช
ชุนพัฒน	คลายเคล่ง	เคหศาสตร์	จะกรัจจะกราจ
ชุย	ควินสิริกิต์	เคหเศรษฐศาสตร์	จ๊ะเอ๋
ชุยไผ่	คห	เคอย	จักรวาท
ชุยอินทรีย์	คหกรรมศาสตร์	เค็ดตาลีอก	จันฉา
ชู	คหปตานี	แคลเซียมคาร์ไบด์	จันฉวาตา
เชม	คัคน	ฆ้องหุ่ย	จัตวาพันฑ์
เชมรไพรโยค	คันถ	งกเงิน	จัตูร
เชื่อม	คันถรุระ	งงววย	จัตูรพักตร์
เขยงแขงขน	คันธมาพน	ง่วงงุน	จัตูรภูช
ไ้ใช้ทรพิษ	คันบวย	งอมแงม	จัตูรมุข
คช	คัพภ	งาล้ว	จันทนา
คชกรรม	คัพภสาลี	งูสวัด	จันทร
คชนาม	คัมภีร	เงินสเตอร์ลิง	จันทรมณฑล
คชลักษณะ	คัมภีรภาพ	โงนงน	จันทรวงศ
คชศาสตร์	ค้ายเขวชน	จตุตถ	จันทรูปราคา
คชสาร	คาราคาก่า	จตุทิพยคันธา	จั่ว
คชสีห์	ค่านูณ	จตุรงคนายก	จาก
คณ	คิง	จตุรงคประดับ	จากุทลี

จาดูร	เจ้าประคูน	ชลธิศ	โซเดียม-
จาดูรงค	เจ้าแก้ว	ชว	ไฮโดรเจน-
จาดูรงคสันนิบาต	เจีย	ชอ้อ	กฏาเมต
จาดูรราชการ	เจ็ย	ชอ้อม	โซเดียม-
จำนวนจินตภาพ	เจ็ยแจ้ว	ซัก	ไฮโดรเจนซัลเฟต
จำนวนตรรกยะ	แจ่ง	ซังฆ	โซรมัสตราวุธ
จำนวนอตรรกยะ	แจ้น	ซังฆวิหาร	ฉापน
จิตต	แจบ	ชาติ	ฉापนกิจ
จิตตภาวนา	แจ่ม	ชาติรูป	ฉापนสถาน
จิตตวิสุทธิ	แจ่มแจ้ง	ชาติสระ	ญาณทัสนะ
จิตตานุปัสสนา	แจ่มใส	ชาวเล	ฐานกรณ์
จิตรปทา	แจ้วแหว	ชีร์ณัคคิ	ฐापน
จินต	ฉพีสติม	ชี้ว	ทังส
จินตกวี	ฉสก	ชี้วเคมี	คนุช
จินตภาพ	ฉัน ท	ชี้วประวัติ	ดอกคิ้ว
จิร	ฉัน ทลัษณ์	ชี้ววิทยา	คังรือ
จิรกาล	ฉัน ทวิลาต	ชุนห	คามพ
จุฑาธิปไตย	ฉัน ทศาสตร์	ชุษณ	คามพวรรณ
จุดยุทธศาสตร์	ฉิน ท	เชษฐ	คุ่ม
จุทสมสุรทิน	ฉิน ทฤกษ์	เชษฐะ	คุรีย
จุลทรรศน์	ฉุก ฉิน	โชติก	คุรียางค
จุลินทรีย์	ฉุก ละหุก	โซโหว	คุรียางคศาสตร์
เจติย	เฉไฉ	ชอกแซก	คุรียางคศิลป์
เจติยสถาน	เฉยเมย	ช่องแซ่ง	คุรี
เจติยสถาน	โฉ่งฉ่าง	ซับซาบ	เด็กเมือวานซืน
เจตนารมณ์	ชงฆ	ซิมซาบ	แคะแค้
เจติย	ชนม	โซเดียมซัลเฟต	ตกขุย
เจริญสมณธรรม	ชเนตตี	โซเดียม-	ตกใต้เกรเทวทัต
เจ้าขุนมูลนาย	ชมชัว	โซคลาเมต	ตจ
เจ้าเซ็นตันต้าบุด	ชลธารก		

คงปีญจก-	ดาโก่ง	ดู	ทวาทสม
กรรมฐาน	ตามพ	ดูปรหบุคคล	ทว่าทสี่
คงสาร	ตามพหัดถี	ดู	ทวabr
คัมโคถิ่ง	คayชย	เดย	ทวix
คัมเปอะ	คาลปีตร	เดยจิต	ทศเบญจกดู
ครมตรอม	คาลปีตรบังเพลิง	เดยเจตนา	ทศพิชราชธรรม
ครรก	คาลปีตรฤยี่	เดยสังวาส	ทศม
ครรกศาสตร์	คาลอ	เดถไลถ	ทอถคำเปลว
ครังค	คิก	ไถย	ทอถเค
ครังควชิราวดี	คิงส	ทนต	ทอถอัสถคคต
ครไปรษณียากร	คิงสคิม	ทร	ทอถหุ่ย
ครีกันสวาท	คืดค้อ	ทรกรรม	ทักษ
ครินทลามกา	คู้ตะ	ทรข้าวบิณท์	ทักษ
ครีชาต	คู้บคู้บ	ทรมันท์	ทักษกรรม
ครีทพิยรส	คुरुจค	ทรชน	ทักษฆาต
ครีทรวธา	คูล	ทรชาติ	ทักษนิคม
ครีเทวตรีคันธา	คุหรัคคุหเร </td <td>ทรชีก</td> <td>ทักษทวทยา</td>	ทรชีก	ทักษทวทยา
ครีปีคผล	คเรพินฟาร์	ทรพล	ทักษทสถาน
ครีมรุ	คเรวงโยชวาทิต	ทรพิช	ทัก
ครีโลจน	ไครคิกษา	ทรภิกษ	ทัก
ครีโลกก	ถนคถน	ทรยศ	ทักคชะ
ครีวาคผล	ถมถีถ	ทรยुक	ทักคแพทย์
ครีสุรผล	ถมถ	ทรรคณาการ	ทัก
ครีเสมหผล	ถวัดถวัน	ทรรราช	ทัก
คฤถีย	ถ้วครว้า	ทรลักษณ	ทัก
คฤ	ถ่านไฟแซ็ก	ทรพิย	ทัก
ค่อนันคต่อเนง	ถิร	ทรพิยสิทธิ	ทัก
ค่อมอ	ถิน	ทฤจ	ทัก
คะพีคคะพีอ	ถิงแก่มรณภาพ	ทลบบม	ทาร
คะหลุง	ถิงแก่อัสถกรรม	ทวัดคิงสภาการ	ทิกษากร

ทิว	เทวทูต	ชราธิป	นรนาชก
ทิพย	เทวธรรม	ชเรศตรีศวร	นรบดี
ทิพยญาณ	เทวธิดา	ชญ์คัจ	นรบาล
ทิพยเนตร	เทวนาครี	ชาตุโขภ	นรพย์คณ์
ทิพยพยาน	เทวนิยม	ชานินทร์	นรราช
ทิพขมานุษ	เทวภาวะ	ชาราริคุณ	นรเศรษฐ์
ทิพขรต	เทवरูป	ชุดงค	นรสิงห์
ทิพขโสรต	เทวโลก	ชุดงควัตร	นรสีห์
ทิวส	เทววาจิกะ	ชุดงคสมาทาน	นฤ
ทิม	เทววิทยา	ชุม	นฤคหิต
ทิมนิกาย	เทวสถาน	ชุมเกตุ	นฤโฆษ
ทิมสระ	เทห์	ชุมชาล	นฤดม
ทิม	เทห์ฟากฟ้า	ชุมเพลิง	นฤตย
ทุกข	โทรทรรสน์	ชุม่า	นฤตยศาลา
ทุกขนิโรธ	โทรมคัสตราวุธ	ชुर	นฤตยศาสตร์
ทุกขลภ	โทษกรณ	ชुरการ	นฤตยสถาน
ทุกขสมุทัย	โทส	ชูว	นฤเทพ
ทุกขารมณ	ชงเขาวราชน้อย	ชูวคารา	นฤนาท
ทुर	ชงเขาวราชใหญ่	ชูวภาค	นฤเบศ
ทุรคม	ชนิษฐะ	ชูวมณฑล	นฤป
ทุริกษ	ชนุร	ชูวชัยฎี	นฤปนีติ
ทุษฐ	ชนุรมารค	ชูปฤายี	นฤปเวศม์
ทุส	ชรรวมถัก	นขา	นฤปัดนี
ทูร	ชรรมนูญ	นภ	นฤมถ
เทพย	ชรรมนูญการ-	นภมณฑล	นว
เทพยเจ้า	ปภครองราช-	นภศูต	นวก
เทพยดา	อาณจักร	นย	นวกภูมิ
เทพนทร์	ชรรมะรัมโม	นร	นวกกรรม
เทว	ชรรมาภิมุข	นรเทพ	นวกกรรมิก
เทวทัศน์	ชราธิปดี	นรนาถ	นวกการ

นวกิจ	นิตยทาน	บรรพการกรรม	บุรพผลคูนี
นวครหะ	นิตยภัต	บรรพตคีลา	บุราณพุตติยิกา
นวกุณ	นิตติกรรม	บราร	บุษบ
นวเคราะห์	นิตถารมณ	บริษัทเครตติ	บุษบราต
นทวาร	นิตาฆ	ฟองชีเอร	บุษบวรรัช
นพนิต	นิตพัท	บแรง	บุษบัน
นพนียาย	นิตพัทกุศล	บแรงภักษ	บุษป
นพปฏ	นิตยานิก	บอง	บุษยะ
นวมุข	นิตรย	บเอ	บุษนีย
นวลโหะ	นิตรบาล	บัฐยาพฤต	บุษนียสถาน
นวลวิธ	นิตรันตร	บัตแมล่ง	บุรพษาต
นวลอรหาคุณ	นิตาพิ	บาทนิกต	เบญจกุล
นวลรหาคุณ	นิตก	บาทภัก	เบญจคัพย์
นักเลง	นิต	บาทรช	เบญจม
นักษัตร์เนมิ	นิตจร	บานเบียง	เบญจมสุรทิน
นักษัตร์โยค	นุงนัง	บานโกชน	เบญจโหทะ
นักสราช	เนา	บานีโยทก	เบญจจรรณ
นันท	เนารัตน์	บารเรต	เบญจจรรณห้าสี
นันทปิกษี	แนนนันต์	บ่าระห้า	เบญจางค
นัวเนีย	แนนแพน	บ่าเรอเซอภักดี	เบญจางค
นาคสังวัจจร	บงก	บิณฑ	ประดิษฐ์
นาคินท	บงสุกุลิก	บิตุจฉา	เบอะบะ
นาฎย	บตีวรดา	บุบบิบ	โบกขร
นามไธย	บทภาชน	บุปผ	โบกขรพรรษ
นามาภไธย	บทภาชนีย	บุปผชาติ	ไบพัทฐีมา
นิตมสทกรรม	บทเรศ	บุปผวิกติ	ปฎิ
นิตมอุตสาหกรรม	บทวเรศ	บุพพ	ปฎิการ
นิกท	บมิ	บุพพษาต	ปฎิคหิต
นิกทกรรม	บร	บุพพสาพหะ	
นิตย	บรรพาร	บุพพิเทห์	

ปฏิกูญาสาทลว่า-	ประคิษฐกรรม	ปิกษร	ปานวินาศ
คัวยสิททธิมนุชย-	ประเค็ยวประคัว	ปิกษเกท	ปานิมุกคั
ชน	ประทุษฎุจิด	ปิกษวาหน	ปานีย
ปฐุมโพธิกาล	ประทุษฐุจิด	ปิกษานคร	ปาป
ปฐุมสุรทิน	ประลัยวาท	ปิกษาวสาน	ปาปมุต
ปฐุมษาณ	ประลัยท	ปิจจันต	ปาร
ปนเป	ปรางคัปรา	ปิจจันตคาม	ปารคุ
ปปีญจ	ปรีณามัคคิ	ปิจจันตชนบท	ปาเต็งเครีง
ปปีญจธรรม	ปรีย	ปิจจันตประเทศ	ปาหุไณย
ปโย	ปรียรณ	ปิจจุต	ปิงค
ปโยชนม	ปรียวาท	ปิจจุตกาล	ปิงคหัตถิ
ปโยธร	ปรีเวณ	ปิจเจกโพธิ	ปิตามหัยกา
ปโยธรา	ปรีฎัคปรีฎัค	ปิจโจตกาล	ปิตามหัยยิกา
ปโยนิริ	ปลวงค	ปิจยาการ	ปีหลัน
ปโยราคิ	ปลาม้า	ปิจญ	ปีมะโว
ปร	ปวัตน	ปิจญจณี	ปุนัพพสุ
ปรคยัคษ	ปวัตนาการ	ปิจญจม	ปุนพ
ปรนัย	ปลันน	ปิจญจวัคคิย	ปุนพผลคุนี
ปรปิกษ	ปลันนาการ	ปิจญจสาขา	ปุนพพะภัททะ
ปรม	ปลัยท	ปิจญญาส	ปุม
ปรโลก	ปลัยทาการ	ปิจนรต	ปุมป้า
ปรวาทิ	ปลัยทาอาหาร	ปิจนรสม	ปุนพผลคุนี
ประคอบประหงม	ปะวะหลิม	ปิจนรสมสุรทิน	ปุนพษาณ
ประคินทรรรพ	ปิกข	ปัทมราค	ปุนยยะ
ประจกษ	ปิกขคณนา	ปาฐ	ปุตตะ
ประจกษนิชม	ปิกขพิพาร	ปาน	ปุนชเนย
ประเจดประเจ้อ	ปิกข	ปานก	ปุนชปุย้า
ประคักประคิต	ปิกขกษย	ปานทันค	เปกข
ประคิ	ปิกขคณนา	ปานนาส	เป็ดก้า
ประคิษฐ	ปิกขคม	ปานภูต	เปต

เปตวิสัย	ผลุบผลับ	พยุหแสนยา	พิชยาการ
เปตอง	ผลสมผลเส	พยุหแสนยากร	พิพิชภัณฑสถาน
เปรมปรา	ผัดส	พรรคกลิน	พิมพ
เปลว	ผากแผ้ง	พร้อมพรั๊ก	พิมพากรณ์
เปศลมรัย	ผาดคุน	พระทัย	พิริย
เป็ยะ	ผิน	พระฤาษี	พิริยพณฑท์
แปรปรวน	ผินหลังให้	พระหารณย์	พิริยโยธา
โปกขร	ผืด	พระหารณย์	พิล็กก็๊กก็้อ
โปกขรพรรษ	ผูกพัทธสีมา	พฤกษ	พิล็กฟิลัน
โป้งโย้ง	ผน	พฤกษชาติ	พีเบ้ม
โปฐบท	ผนธรรม	พฤกษทล	พีร
โปฐบทมาส	ผียบผยาบ	พฤกษเทวดา	พุททมามกะ
โปรงเปรง	ผลอไผล	พฤกษราช	พุททศาสนิกชน
ไปรษณีย	เผือกโทป้าด	พฤกษศาสตร์	พุ่มข้าวบิณฑ์
ไปรษณียนิเทศ	โศฎฐัพ	พฤฒ	เพื่อเจ้อ
ไปรษณียบรรณ	โศฎฐัพธรรม	พฤฒาจารย์	แพทย
ไปรษณียบัตร	โศฎฐัพพะ	พลว	แพทยศาสตร์
ไปรษณียภัณฑท์	โผย	พล้งงานจณน์	โพธิ
ไปรษณียวัตถุ	โผอน	พลับพลา	โพธิปักขิยธรรม
ไปรษณียากร	ฝรั่งเสศ	พักตร	โพธิสมภาร
ผมชิงเกิด	พงศ	พัฒน	โพนแพน
ผรณ	พจน	พัทธ	ไฟป้อก
ผรุส	พญาพชาติ	พัทธสีมา	ไพธราณท์
ผลคูนี	พยักพยิด	พันธ	ฟอดแฟด
ผลคูนีบูรพมาส	พยัคคม	พันธกรณิ	ฟัดเฟียด
ผลับ	พยุห	พันธบัตร	เฟอะพะ
ผลิก	พยุหบาตร	พันธมิตร	เฟอะพะ
ผลิกศิขรี	พยุหบาตรา	พิจิก	ไฟแจ๊ก
ผลิกศิลา	พยุหยาตรา	พิถย	ภย
ผลุนผลัน	พยุหโยธา	พิทย	ภราดร

ภราดรภาพ	ภูวนัตตริย์	มรณันติก	มัชฌิมาน
ภราตฤ	ภูวไนย	มฤคศิร	มัวชั่ว
ภราตฤภาพ	เภสัชพฤกษ-	มฤคศิรมาส	มาคสิร
ภวังค	ศาสตร์	มฤคสิริต	มาฆ
ภักต	เภสัช-	ม้วนตัวน	มานทะเลน
ภักตฤกฤตย์	อุตสาหกรรม	มหัจฉริย	มานุษย
ภักษ	โภชน	มหันต	มานุษยวิทยา
ภักษการ	มณีราค	มหิป	มิกสิร
ภังค	มต	มอมแมม	มิฉนากัมมันตะ
ภันฑ	มรูป	ม่อห้อม	มิณูช
ภันฑาครรภ	มธูร	มะม่วงหิมพานต์	มิต
ภาคเสธ	มธูรตรีย	มัต	มิตภาณี
ภาว	มธูรพจน์	มังส	มิม
ภาวศุทธิ	มธูลีห์	มังสวิริติ	มิศรภ
ภาวะชุกเณิน	มนท	มัจ	มิต
ภิน	มนทกานติ	มัจฉ	มีพห
ภินท	มนัสตป	มัจฉันติก	มุขบาฐ
ภินทน	มนุษย	มัจฉันติกสมัย	มุตกิด
ภีรูก	มนุษยสัมพันธ	มัจฉิม	มุบมิบ
ภูกต	มโนนุกูล	มัจฉิมนิกาย	มูธาภิเชก
ภูกตเสช	มโนภินิเวศ	มัจฉิมบุรุษ	มุขัมมัด
ภุณูช	มยุร	มัจฉิมประเทศ	มูก
ภุชเรศวร	มยุรคติ	มัจฉิมภุมิ	มูรช
ภุเนตุ	มยุรฉัตร	มัจฉิมยาม	มูละ
ภุเบนทร์	มยุรอาสน์	มัจฉิมวัย	มูตั้ง
ภุเบศ	มรณ	มัจฉวิริติ	มูพห
ภุเบศวรร	มรณกรรม	มัจฉา	เมรย
ภุป	มรณธรรม	มัจฉาน	แมน
ภุมิบริมาณ	มรณบัตร	มัจฉานศิลป์	แมนย่า
ภูรโลก	มรณภาพ	มัชย	แมลงวันสเปน

โมกษ	ยุทธวินัย	รกเรื้อย	รุกข
โมกษบริสุทธ	ยุทธศาสตร์	รงค์	รุกขชาติ
โมกษ	ยุทธหัตถี	รงค์วัตถุ	รุกขมูล
โมฆ	ยุพ	รถนุกเงิน	รุกขมุสิกขุดงค์
โมฆกรรม	ยุพยง	รมณีย	เรียบวฐ
โมฆี	ยุพเยาว์	รวนเร	เรือยเจื้อย
โมฆีกรรม	ยุว	รโหคต	แรงงานและ-
โมร	ยุวชน	รังสร้าง	สวัสดิการสังคม
โมห	ยุวราช	รังสีคอสมิก	ฤทัย
ไม้กัฏฐพส	ยุวราชา	รัชต	ฤษี
ไม้ทัณฑฆาต	เขภุย	รัชต	ฤษีแปลงสาร
ขติภังค์	เขภุยนัย	รัฐธรรมนูญ	ฤษีผสมแล้ว
ขว	เขภุยลิกา	รัฐประศาสนนัย	ฤษีเลี้ยงลิง
ข้ง	เขาว	รัฐประศาสน-	ลขุโภชน
ขัคเคียด	เขาวชน	ศาสตร์	ลหุก
ขันตร	เขาวนะ	รัฐประศาสน-	ลองธรรม
ขันตรกรรม	เขาวมาลย์	บาย	ลักษณะ
ขางมะคอบ	เขาวยอด	รัตน	ลักษณะนาม
ขापนมัต	เขาวราช	รัตนโกสินทร์	ลักษณะการ
ขามโยค	เขาวเรศ	รัตนบัลลังก์	ลักษณะ
ขี้	เขาวลักษณะ	รัตนสิงหาสน์	ลักษณะ
ขุคันด	เขิ่นเขื่อ	รัมก	ลายสื่อ
ขุคันตวาด	โยกเขก	รัมณีย	ถุ่นตุ้น
ขุทธ	โยค	รัต	ถุ่นโตง
ขุทธการ	โยคจักขุ	ราชกิจจานุเบกษา	ถุคมโหด
ขุทธนาธิการ	โยคนิทรา	ราชภัฏ	ถ่นพิเรนทร์
ขุทธภันท์	โย่งเข่ง	ราชโยค	เลป
ขุทธภูมิ	โยธ	ราชวโรงการ	เลอะเทอะ
ขุทธโยธา	โยธวาพิต	ราชหัตถเลขา	เละเทะ
ขุทธวิธี	โยพนมัท	ราชองครักษ์	เล็กเล็ก

เลื้อยเจื้อย	วัดคู่วัท	วาลธิ	ศราทพรต
โลกาภิวัตน์	วัง	วิกาลโภชน	ศศ
โลห	วังกุฎี	วังระแบง	ศศธร
โลหกุมภี	วังมรรค	วิทย์	ศศพินทุ์
ไล่เลีย	วัชร	วิทย์ฐานะ	ศศลักษณ์
ภา	วัชรธาตุมณฑล	วิทยาการ	ศศิขันธ์
ภาษา	วัชรปาลี	วิทยาศาสตร์-	ศักย
ภาสาย	วัชรยาน	ชีวภาพ	ศักยภาพ
วงศ	วัชรอาสน์	วินย	ศักร
วชิร	วิภู	วิร	ศักรภพณ์
วชิรปาลี	วิภูจักร	วิโรจน์	ศัพท
วชิรหัตถ์	วิภูทุกข์	วิลย	ศัพทมูลวิทยา
วณ	วิฒน	วิไลวรรณ	ศัลย
วณบัตร	วิฒนธรรม	วิวิฒน	ศัลยกรรม
วณพันธ์	วันทย	วิวาท	ศัลยแพทย์
วต	วันทยหัตถ์	วิสาข	ศัลยศาสตร์
วทานิย	วัส	วิสาขบูชา	ศัสตร
วธ	วัสคณนา	วิเศษณ	ศัสตรกรรม
วธก	ว้าก	วิเศษณการก	ศัสตรการ
วร	วากจिरพัศตร์	วิสย	ศัสตรศาสตร์
วรคณู	วากย	วิสาข	ศากย
วรท	วากยสัมพันธ์	วิสาขบูชา	ศากยเกตุ
วรทาน	วาท	วิสามานยนาม	ศากยพุทธ
วรมหาวิหาร	วาทปานะ	วีต	ศากยมนี
ววรรณ	วาทภัย	เวมัตติก	ศานต
ววรรณคดี	ว่าแต่เขาอิเหนา-	เวียง	ศานตรส
ววรรณยุค	เป็นเอง	ศตปที	ศานติก
วรวิหาร	วาทย	ศตตั้งวัดสร	ศำปมุกดี
วสันต	วาทยกร	สระวน	ศาลคดีเด็กและ-
วสันตวิษุวัต	วานขึ้น	ศราทธ	เยาวชน

ศาลเยาวชนและ-	ศุภมัสดุ	สมถ	สวัสดิการ
ครอบครัว	ศุภมาตรา	สมถยานิก	สวัสดิ
ศาสตร์	ศุกร	สมถวิปัสสนา	สวามินี
ศาสน	ศุภอักษร	สมบัตินักเลง	สห
ศาสนจักร	ศุลก	สมปฤดี	สหกรณ์
ศาสนีย	สุนย	สมฤดี	สหการ
ศิร	สุนยภาพ	สมุห	สหชาติ
ศิรประภา	สุนย์เยาวชน	สมุหกลาโหม	สหธรรม
ศิลป์	สุนยวาท	สมุหเทศาภิบาล	สหธรรมิก
ศิลป์กร	เศรษฐ	สมุหนาม	สหบาน
ศิลป์กรรม	เศรษฐศาสตร์	สมุหนายก	สหประชาชาติ
ศิลป์การ	เสาจ	สมุหประธาน	สหพันธ์
ศิลป์กิจ	ขมายุมแปลง	สมุหพระกลาโหม	สหพันธรัฐ
ศิลป์วิทยา	สกฎ	สรณ	สหภาพ
ศิลป์ศาสตร์	สกฎการ	สรณคมน์	สหภาพแรงงาน
สิว	สกลมหาสังฆ	สรณตรีข	สหศึกษา
สิวโมกษ์	ปริณายก	สรිර	สหัส
สิวสิ่งค์	ตงสารวัฏ	สรිරกิจ	สหัสธารา
สิวเวท	สตั้มก	สรිරธาตุ	สหัสเนตร
ศิษย์	สถวีร	สรිරวิทยา	สะบักสะบอม
สีต	สถวีร	สรිරศาสตร์	สะบัดสะบั้ง
สีตกาล	สนุกเกอร์	สลบไสล	สังข
ศึกษาธิการ	สภาวะ	สลาจ	สังขกร
ศึกษานิเทศก์	สภาวะการณ	สว	สังขต
ศุกร	สมณ	สวกรรม	สังขตธรรม
ศุกรวรรณ	สมณบริจาร	สวการย์	สังค
ศุกถ	สมณโวหาร	สวณีย	สังคญาติ
ศุก	สมณศักดิ์	สวภาพ	สังฆ
ศุกเคราะห์	สมณสารูป	สวรรค	สังฆกรรม
ศุภนิมิต	สมณศาสน	สวราชย์	สังฆการี

สังฆเถระ	สัปตสดก	สารบบ	สุ้มเสียง
สังฆนายก	สัปต	สารบบ	สุร
สังฆเภท	สัปปริส	สารัตถ	สุรคต
สังฆมณฑล	สัมพัจฉร	สาราณีย	สุรบถ
สังฆมนตรี	สัมพัจฉรนิ นท์	สาราณียธรรม	สุรภาพ
สังฆสภา	สัมพันธ	สาหัตถ	สุรโลก
สังฆาธิการ	สัมพันธภาพ	สาหัตถิก	สุรสีหนาท
สังฆ	สัมพันธมิตร	สำนัง	สุรเสียง
สังฆกร	สัมพันธไมตรี	สีขานล	สุริย
สังฆการ	สัมพาหะ	สิงห	สุริยกันต์
สังฆชาติ	สัมพุทธ	สิงหนาท	สุริยกานต์
สังฆชาติญาณ	สัมฤทธิ	สิงหบัญชร	สุริยการ
สังฆดาห	สัมฤทธิศก	สิงหราช	สุริยกาล
สังฆ	สังคาล	สิงหลก	สุริยคติ
สังฆวาร	สังคเลข	สิงญจ	สุริยคราส
สังคย	สังคต	สิงท	สุริยเคราะห์
สังคยพรต	สังคตทฐิ	สิร	สุริยมณฑล
สังค	สากษิน	สีม	สุป
สังค	สากษย	สีด	สุรย
สังคแพทย์	สากษิ	สีห	สุรยกันต์
สังคโลก	สากษิบุตร	สีหนาท	สุรยคราส
สังควิทยา	สากษิมุณี	สีหบัญชร	เสกข
สังคธาธิก	สัง	สีหราช	เสกขบุคคล
สังค	สาฎิก	สุคนธ	เสข
สังค	สาณ	สุคนธรส	เสขบุคคล
สังคทฐิก	สาธย	สุญญ	เส็งเคร็ง
สังคปลี	สามนต	สุท	เสด
สังค	สามนตราช	สุนทรีย	เสนห
สังคปกรณ	สามานย	สุพรรณภาษณ์	เสนาธิการ
สังคประการณ	สามานยนาม	สุภ	เสนาธิปัด

เสนาายุทธ์	หุมหมิบ	หัตถาภรณ์	อคาร
เสนาายุทธ์	หุมห้อย	หั่วหน้าว	องค
เสล	หย	หัสต	องค์การสห
เสลบรรพต	หยอกเอิน	หิม	ประชาชาติ
เสารภย์	ห้อย	หิมพาน	องคชาติ
เสาว	ห้อยกรอด	หิมพานต์	องครักษ์
เสาวคันธ์	ห้อยอมแหยม	หิมวัต	องควิการ
เสาวธาร	ห้อย	หิมวันต์	องควิเกษป
เสาวภา	หยิกห้อย	หิมวา	องควิทยา
เสาวภาพ	หรรณ	หิมวาด	องค
เสาวรภย์	หรรษ	หิมวาน	อจिर
เสือบอง	หรัสว	หิมवास	อคูลย
แสนย	หรัสวมูรติ	หิมเวศ	อพระ
โสดทัศนวัตดุ	หฤทัย	หิรัณย	อริก
โสดทัศนอุปกรณ	หฤทัยกัปน์	หิรัณยเกศ	อริกวาร
โสก	หฤทัยกัมป	หิรัณยรัศมี	อริกสุรทิน
หงส	หฤทัยปรีย์	หีน	อน
หงสคคิ	หฤทัยพันธน์	หีนยาน	อนงค
หงสบาท	หลงไหล	หิงส	อนงคเลข
หงสรถ	หลับ	หีนหรรษ์	อนงคเลขา
หงสราช	หลู่หลี้	หือรือโหด	อนธ
หง่าเหงอะ	หว่าง	หุด	อนัตถ
หญ่ายายเภา	หสน	หุดโกวิท	อนันต
หทย	หอมเตียม	หู่หู่	อนันตร
หน้องแหหนึ่ง	หังส	เหมันต	อนากูล
หนอนตายหยาก	หัตถการ	เหมาะเหม็ง	อนารย
หมักหมม	หัตถกิจ	แหยม	อนารยชน
หมากฮอส	หัตถบาท	อกับปีย	อนารยธรรม
หม้า	หัตถพันธ	อกับปียวัตตุ	อนีก
หม้าดับ	หัตถศึกษา	อกับปียโวหาร	อนีกทรสนะ

อนีกัทชนะ	อตัณฺฏกรรม	อัญฺเคียรถีย์	อันติม
อนุตร	อัสมกฺิน	อัญฺมณิ	อันติมสัจ
อนุรักษ	อัสมกฺินพงศ์	อัญฺมัญ	อันเตวาทิก
อนุรักษนิยม	อัสมกฺินวงศ์	อัญฺฐ	อันธ
อนุราร	อติเตสะ	อัญฺฐม	อันโยนย
อนุราระ	อเสกข	อัญฺฐผล	อันวย
อนกอนันดัจ	อเสกขบุคคล	อัญฺฐิมิณฺุชะ	อัป
อปจายน	อเสข	อัญฺฐ	อัปเปหิ
อปจายนธรรม	อเสขะ	อัญฺฐจันทร	อัปภันตร
อปจายนมัย	อ้อยส้อย	อัญฺฐมณฑล	อัมพ
อปฺร	อะครินาสิณ	อัญฺฐมาต	อัมพวัน
อปฺรภาค	อะคักอะเต็ย	อัญฺฐรัตติ	อัมพวา
อปฺรรัณชาติ	อะคักอะเต็อ	อัญฺฐนฯ	อัสวมุขี
อปฺราน	อะคักอะเต็	อัญฺฐนฯโกต	อัสวมธ
อภิขนาธิปไตย	อักขร	อัญฺฐนฯชะ	อัสวยุช
อภิณฺห	อักขรววิธี	อัญฺฐ	อัญฺฐ
อมต	อักขรววิธี	อัญฺฐชีวประวัติ	อัญฺฐกณิน ท์
อมตบพ	อัญฺคินิพาท	อัญฺฐนัย	อัญฺฐมกค
อย	อัญฺคินิโทต	อัญฺฐภาพ	อัญฺฐมกค
อรทัย	อัญฺครสมณฑุต	อัญฺฐวินิบาดกรรม	อัญฺฐ
อรรตถาจารย์	อัญฺงศ	อัญฺฐหิต	อัญฺฐคกค
อรหันต	อัญฺงศกฺุญ	อัญฺฐเหตุ	อัญฺฐมุขี
อรหันตฆาต	อัญฺงศริย	อัญฺฐท	อัญฺฐสณี
อริย	อัญฺงศริยบุคคล	อัญฺฐทคค	อาคันตฺก
อริยผล	อัญฺงศริยภาพ	อัญฺฐทคฺุ	อาคันตฺกภัก
อวิญฺญาณก	อัญฺงศริยลักษณะ	อัญฺฐนต	อาคันตฺกวัตร
อวิญฺญาณกรัพฺย	อัญฺงศริยลักษณะ	อัญฺฐนตกริยา	อาจริย
อวิโรธน	อัญฺงศนตติก	อัญฺฐนตคฺุ	อาจริยวาท
อสังหาริม	อัญฺญ	อัญฺฐนตลิกชะ	อาชีว
อตัณฺุ	อัญฺญตติถีย์	อัญฺฐนตัน	อาชีวศึกษา

อาทิตย์	อิฏฐ	อุตรภัทรบท	เอกภักดี
อาทิตย์ยมนาฬ : อาทิตย์วาร	อินทร	อุตริมนุสธรรม	เอกส
อานาปานัสสติ	อินทรธนู	อุตสาห	เอกอัครสมณฑุต
อ้ายเจี๊ว	อินทรวงศ์	อุตสาหกรรม	เอมโอช
อายุร	อินทรวีเชียร	อุตสาหกรรมศิลป์	เออนะ
อายุรแพทย์	อินทรสักดิ์	อุท	เอ้อเรือเอ้อเต๋อ
อายุรเวช	อินทรีย	อุทบาตร	แอนตือเอี๊ยกตรอน
อายุรศาสตร์	อินทรียโคจร	อุทบาน	โอฆ
อารย	อินทรียญาณ	อุทพินท์	โอฆชล
อารยชน	อินทรียสังวร	อุบอิบ	ไอ้ด
อารยชาติ	อิสร	อุปปาติก	โอร
อารยธรรม	อิสรภาพ	อุปสัมปทาเปกซ์	โอยฐ
อารยประเทศ	อิสริย	อุปสัมปทาเปกซ์	โอยฐภัย
อาร์มก	อิสริยศ	อุปัชฌาย	ไ้อ
อาร์มกถา	อีหน้องอีหนั่ง	อุปัชฌายวัตร	ไ้อศุริย
อาร์มกบท	อีเหละเหละขละ	อุปีทว	ไ้อศุริยสมบัติ
อาวัล	อีงอด	อุปาน	ฮวบฮาบ
อาวาท	อุคห	อุ้ย	ฮะฮ้าย
อาศิร	อุคหนิมิต	อุยหน้า	ฮัจญ์
อาศิรพจน์	อุณห	อุ้ยหน้า	ฮัจญะฮ์
อาศิรพาท	อุตตรผลคูนี	อุร	ฮัจญี
อาศิรพิช	อุตตรภัทรบท	อุรค	ฮีดฮัด
อาศิรวจนะ	อุตตรอาษาณ	อุรเคนทร์	ฮี้ย
อาศิรวาท	อุตตราสาพะนะ	อุษณ	ฮุยเลฮุย
อาศิรวิช	อุตตะภัททะ	อุษณกร	ฮู้
อาศิรพิช	อุตร	อุษณกาล	เฮ็ด
อาศิรวิช	อุตรกรู	อุษณรัศมี	แฮก
อาสาพห	อุตรกรู	อุษณรุจี	
อาสาพหบูชา	อุตรนิกาย	อุษาโยค	
	อุตรผลคูนี	อุย	

ภาคผนวก ก

การตัดพยางค์คำไทย

โดยโครงสร้างข้อมูลแบบสแตกและดิกชันนารีแบบแฮชซิง

Thai Word Separator using Double Stack with Hashing Dictionary

สรศักดิ์ ไทยแท้

บุญธีร์ เครือตราชู

นักศึกษาปริญญาโท คณะเทคโนโลยีสารสนเทศ

อาจารย์ประจำภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

บทคัดย่อ

เนื่องจากตัวอักษรไทยมักจะเขียนติดกันไม่มีตัวอักษรพิเศษขึ้นระหว่างคำดังในภาษาอังกฤษ จึงเป็นการยากที่จะทราบว่าผู้เขียนต้องการจะแบ่งคำอย่างไร หรือ คำใดมีคำที่สะกดผิดอยู่ ทั้งนี้การรู้ขอบเขตของคำโดยอัตโนมัติ จะช่วยให้สามารถตรวจสอบคำสะกดได้ถูกต้องและรวดเร็วขึ้นทั้งสามารถทำ index จากคำในข้อความได้ งานวิจัยนี้ พยายามตัดแบ่งคำโดยอัตโนมัติโดยใช้พจนานุกรม (Dictionary) แบบแฮชซิง (Hashing) เป็นตัวช่วยในการตัดคำ รวมทั้งได้ออกแบบ Algorithm แบบ Loop และโครงสร้างข้อมูล Stack ที่ใช้ในการเก็บตำแหน่งคำในการตัดคำแทนแบบเดิมที่เป็น Recursive รวมทั้งพจนานุกรมที่ใช้แบบ Hash ทำให้สามารถเพิ่มเติมคำได้ง่ายรวมทั้งสามารถเลือกหาคำคล้ายได้สะดวก งานวิจัยนี้ยังได้ทำการเปรียบเทียบการตัดคำและการตรวจสอบคำผิดกับ Software คือ Word 6.0 และ Word 7.0 รวมทั้งได้รวบรวม ข้อผิดพลาดของ Word 6.0 และ Word 7.0 มาทำการปรับปรุง Algorithm ในงานวิจัยนี้

Abstract

Thai alphabets are written adjacent, without any special alphabet between words. Therefore, it is difficult to separate each word in a line, or to detect any misspelling word. Separate words automatically will help both spelling correction and also document indexing. This research present the new Thai word separator using Hashing dictionary, and design the new separator algorithm using Loop instead of Recursive with double stack data structure. We can also make word suggestion to the incorrect word with little modification to the dictionary. Hashing dictionary is also easier to add new words. The new algorithm and dictionary has been compared with standard softwares Word 6.0 and Word 7.0 in both the running time and correctness.

1. บทนำ

ในปัจจุบันได้มีการใช้งานเวิร์ดโปรเซสซิ่งภาษาไทยกันอย่างแพร่หลาย โปรแกรมการตัดคำและการตรวจสอบตัวสะกดในงานเอกสารจึงมีความจำเป็นอย่างมาก จึงได้มีผู้วิจัยผลิตผลงานออกมามากมายอย่างต่อเนื่อง ซึ่งในแต่ละผลงานจะมีจุดมุ่งหมายให้การตรวจสอบคำสะกดหรือการตัดคำที่มีความถูกต้องมากที่สุดในเวลาที่สุดเร็ว และยังสามารถค้นหาคำคล้ายคำที่คิดได้อย่างถูกต้อง

2. หลักการและลักษณะของภาษาไทย

จากหลักการของพจนานุกรมสามารถแบ่งอักษรไทยได้ 3 กลุ่ม ดังนี้

- กลุ่มที่ 1 ได้แก่ กลุ่มวรรณยุกต์ ประกอบด้วย ไม้ยมก ไม้เอก ไม้โท ไม้ตรี ไม้จัตวา ไม้ไต่คู้ การันต์
- กลุ่มที่ 2 ได้แก่ กลุ่มสระ ประกอบด้วย อะ อา อิ อี อึ อือ อ่า อุ ู เอ แอ ไอ โอ โอ ไม้หันอากาศ
- กลุ่มที่ 3 ได้แก่ กลุ่มพยัญชนะทั้ง 44 ตัว

ในการเขียนประโยคในภาษาไทยนั้นจะเป็นการเขียนที่คิดกันตามลำดับ การแบ่งคำจะไม่มีกฎเกณฑ์ที่แน่นอนในการตัดแบ่งคำเหมือนในภาษาอังกฤษ โดยการแบ่งคำจะขึ้นอยู่กับแต่ละคนที่ต้องการจะสื่อความหมาย ดังนั้นการที่จะทำให้คอมพิวเตอร์ทราบถึงการตรวจสอบคำนั้น คอมพิวเตอร์จะต้องทราบถึงจุดสิ้นสุดของคำเสียก่อน แต่มีในบางประโยคที่มีคำที่กำกวมยากต่อการตัดแบ่งคำ เช่น

เธอมารอกลับบ้าน

ในการตัดแบ่งคำนั้นจะสามารถทำได้เพียงการตรวจสอบว่าคำนั้นมีในพจนานุกรมหรือไม่ โดยจะสามารถแบ่งคำได้ดังนี้

เธอ * มา * รอ * กลับ * บ้าน

เธอ * มาร * ออก * ลับ * บ้าน

เธอ * มา * รอก * ลับ * บ้าน

ซึ่งจะเห็นว่า "มารอกลับ" สามารถตัดแบ่งได้หลายกรณี

2.1 สรุปผลงานวิจัยเกี่ยวกับการแบ่งแยกคำในภาษาไทย

สามารถแบ่งได้ 2 แนวทาง

1. การตรวจสอบทางอักษรวิธี จะทำการตรวจสอบการสะกดคำโดยการตรวจสอบพยัญชนะ^[5], สระ, วรรณยุกต์, การันต์ ว่าเป็นไปตามหลักภาษา“หรือไม่ เช่น พยัญชนะ - ฉ ญ ฎ ฒ ณ พ ไม่ปรากฏเป็นอักษรต้นของคำนอกจากจะมีพวกสระนำหน้ามาก่อน ยกเว้น ฉ สระ - สระหลัง (า, ะ เป็นต้น) จะต้องมีพยัญชนะหรือวรรณยุกต์นำหน้าเท่านั้น

- สระหน้า (เ, แ, โ, ใ, ไ เป็นต้น) จะต้องตามด้วยพยัญชนะ

วรรณยุกต์ - เป็นอักษรแรกไม่ได้

- ต้องตามด้วยตัวสะกดหรือสระหลัง

การันต์ - ต้องเป็นตัวสุดท้ายของคำเสมอ ยกเว้นคำที่มาจากภาษาอื่น

ข้อดีของการตรวจสอบทางอักษรวิธีคือสามารถตรวจสอบได้อย่างรวดเร็ว แต่มีข้อเสีย ในความแม่นยำ ถูกต้อง ของการตรวจสอบจะน้อย เพราะอาจจะพบคำที่คิดแต่เป็นไปตามกฎ

2. การตรวจสอบกับพจนานุกรม จะเป็นการนำคำในประโยคมาเปรียบเทียบกับคำในพจนานุกรม โดยการตรวจวิธีนี้ได้มีการจัดเก็บคำในพจนานุกรมได้ 3 แบบ^[7,8] คือ

1. แบบ Table-Table-Linear-Search

2. แบบ Table-Index-Search

3. แบบ Tree Structure^[6]

ซึ่งมีข้อดี คือ มีความแม่นยำ ถูกต้องสูงแต่ ความเร็วในการประมวลผลจะช้ากว่าแบบแรก

ลักษณะของคำที่เกิดในงานเอกสาร^[1,2]

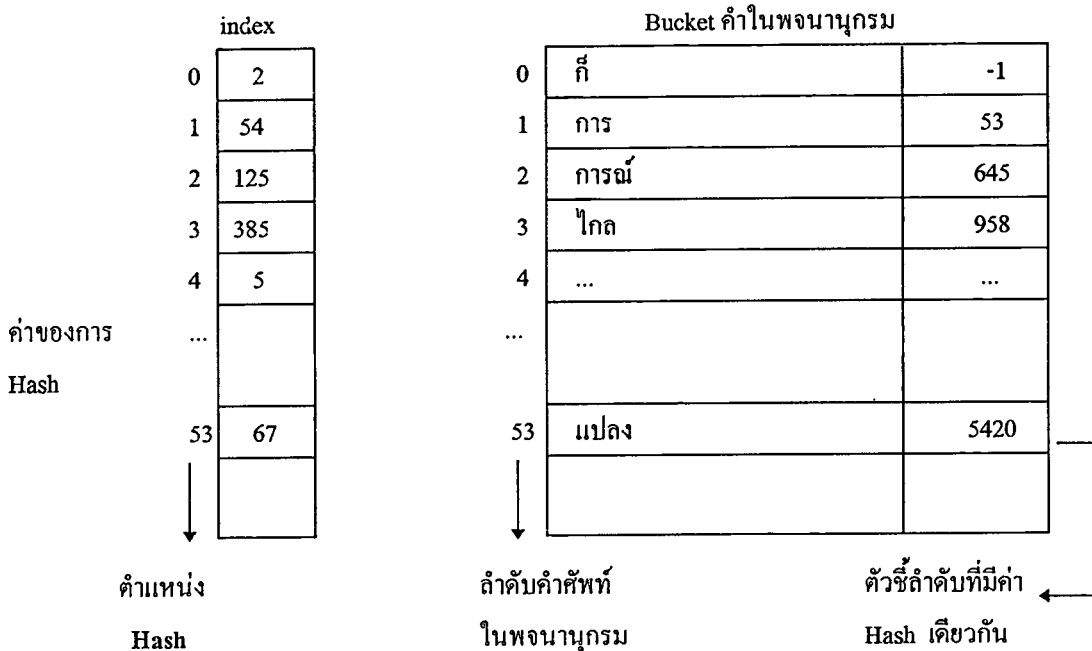
1. การพิมพ์เกิน เช่น การตรวจสอบตัวสะกด
2. การพิมพ์ผิด เช่น การตรวจสอบตัวสะกด
3. การพิมพ์ขาด เช่น การตรวจสอบตัวสะกด
4. การพิมพ์ที่มีการสลับที่ระหว่างตัวอักษรที่ถูกในคำ เช่น การตรวจสอบตัวสะกด

2.2 โครงสร้างข้อมูลในพจนานุกรม

ในงานวิจัยนี้ได้ทำการเก็บคำในพจนานุกรมโดยการที่นำคำในพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2525 แต่ละคำมาทำการคำนวณผ่านค่าของ Hash Function เพื่อ

จะได้้นำค่า Address มาทำการเก็บเป็นโครงสร้าง^(3,4) ดัง

รูปที่ 1



รูปที่ 1 โครงสร้างพจนานุกรมแบบ Hashing

ซึ่งมีข้อดี คือ สามารถค้นหาคำได้อย่างรวดเร็ว สามารถเพิ่มเติมคำใหม่ในพจนานุกรมได้ง่าย แต่มักจะมีการชนกันของ Address ซึ่งจะขึ้นกับค่าของ Hash Function

3. การทดลองและผลงานที่ได้จากงานวิจัย

ผลของการเก็บโครงสร้างของพจนานุกรมแบบ Hashing

การเก็บโครงสร้างของพจนานุกรมแบบ Hashing นั้นจะพบว่ามี การชนกันของ address ในการคำนวณผ่าน Hash Function ดังนี้ จากจำนวนค่าทั้งหมดในพจนานุกรม = 32381 คำ พบค่าที่เกิด collision มากที่สุด 6 collision มี 3 คำโดยจะมีค่าเฉลี่ยของการเกิด collision ในพจนานุกรม 1.50 คำต่อครั้ง

ตารางที่ 1 จำนวนการเกิด Collision ของพจนานุกรม

จำนวน Collision	จำนวนคำ
ไม่มี Collision	20540
1 Collision	8484
2 Collision	2566
3 Collision	635
4 Collision	134
5 Collision	19
6 Collision	3
รวม	32,381
ค่าเฉลี่ย	0.50

ตารางที่ 2 ตารางแสดงข้อมูลในพจนานุกรม

ข้อมูล	
จำนวนไบต์ของพจนานุกรม	283,903
จำนวนค่าทั้งหมด	32,381
ค่าเฉลี่ยจำนวนตัวอักษรต่อคำ	6.76

ตารางที่ 3 ตารางแสดงการแจกแจงความถี่ตัวอักษรในพจนานุกรม

ขนาด ของคำ	จำนวน คำ	เปอร์เซ็นต์ %	ขนาด ของคำ	จำนวน คำ	เปอร์เซ็นต์ %	ขนาด ของคำ	จำนวน คำ	เปอร์เซ็นต์ %
1	1	0.003	14	336	1.038	27	11	0.033
2	471	1.455	15	215	0.664	28	3	0.009
3	2522	7.789	16	150	0.463	29	2	0.006
4	4031	12.449	17	90	0.278	30	1	0.003
5	4890	15.101	18	77	0.238	31	2	0.006
6	5597	17.285	19	49	0.151	32	3	0.009
7	4660	14.391	20	38	0.117	33	2	0.006
8	3408	10.525	21	41	0.127	34	2	0.006
9	2177	6.723	22	18	0.056	35	1	0.003
10	1489	4.598	23	10	0.031	36	1	0.003
11	934	2.884	24	10	0.031	37	0	0
12	695	2.146	25	9	0.028	38	1	0.003
13	426	1.316	26	8	0.025	39	0	0

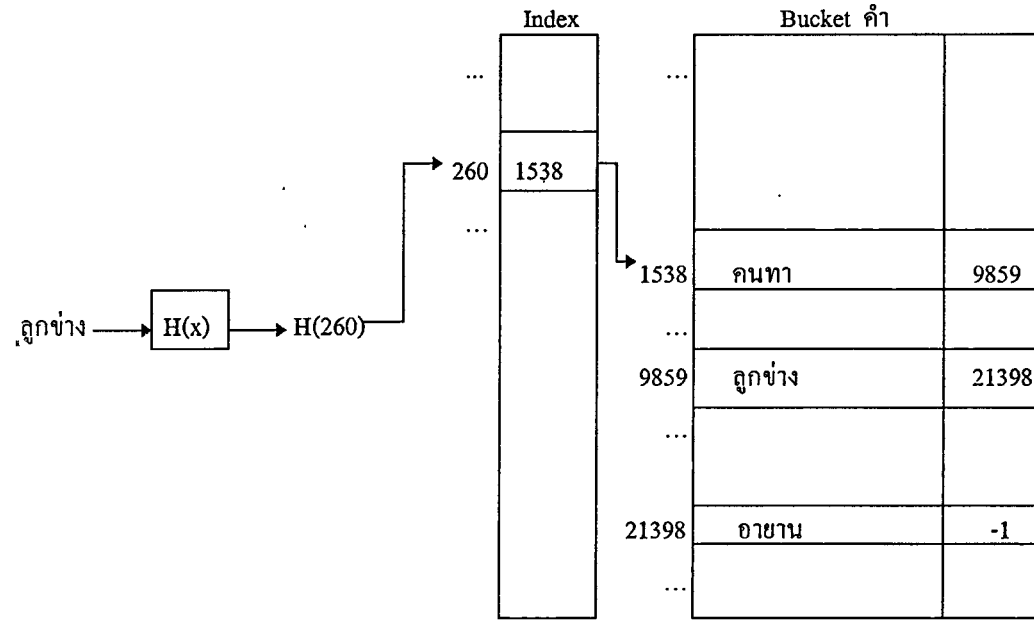
ตารางที่ 4 การแจกแจงความถี่ของตัวอักษรที่พบของคำในพจนานุกรม

ก	=11052	ท	= 229	ม	= 7946	๕	= 7950	๙	= 822
ข	= 2557	ฑ	= 59	ย	= 7098	๖	= 14858	'	= 5431
ฃ	= 0	ฒ	= 1226	ร	= 12825	๗	= 1679	๙	= 6430
ค	= 3430	ด	= 4934	ฤ	= 314	๘	= 6481	๙	= 228
ฅ	= 0	ต	= 5626	ล	= 6517	๙	= 4562		
ฆ	= 177	ถ	= 1007	ฬ	= 6	๙	= 623		
ง	= 7600	ท	= 3930	ว	= 6172	๙	= 1837		
จ	= 2879	ธ	= 1202	ศ	= 1330	๙	= 4075		
ฉ	= 545	น	=11369	ษ	= 928	๙	= 2032		
ช	= 2446	บ	= 4237	ส	= 5470	๙	= 8006		
ฌ	= 618	ป	= 3944	ห	= 4880	๙	= 2484		
ฉ	= 43	ผ	= 944	พ	= 104	๙	= 2122		
ญ	= 831	ฝ	= 297	อ	= 8791	๙	= 652		
ฎ	= 133	พ	= 3464	ฮ	= 176	๙	= 1468		
ฏ	= 216	ฟ	= 466	๑	= 2	๙	= 22		
ฐ	= 298	ภ	= 1082	๒	= 5445	๙	= 130		

วิธีการค้นหาในพจนานุกรมที่มีโครงสร้างแบบ Hashing

ในการค้นหาแบบ Hashing Search เป็นการค้นหาที่มีความรวดเร็ว ทำให้มีประสิทธิภาพในการค้นหาเป็น $O(n)$ โดย n เป็นจำนวนคำในพจนานุกรม สำหรับพจนานุกรมภาษาไทยจะมีประสิทธิภาพของการค้นหาที่ขึ้นอยู่กับจำนวนของตัวอักษรของคำที่ประกอบเป็นประโยค โดยในการเก็บพจนานุกรมแบบ Hashing นี้ จะทำให้มีค่าเฉลี่ยในการค้นหาอยู่ที่ ผลคูณของค่าเฉลี่ยของการค้นหา (collision) กับค่าเฉลี่ยของจำนวนตัวอักษร

ที่ประกอบเป็นหนึ่งคำ ในที่นี้ คือ $1.5 \times 6.76 = 10.14$ ตัวอักษร ดังนั้นในการเปรียบเทียบจะทำการเปรียบเทียบประมาณ 11 ตัวอักษร หรือมีการค้นหาประมาณ 2 ครั้ง ในลิงก์ต่อการค้นหาในหนึ่งคำของภาษาไทย ดังตัวอย่างเช่นจะทำการค้นหาคำว่า “ ลูกช่าง “ จะนำค่านั้นมาทำการคำนวณผ่าน Hashing Function เพื่อจะได้ตำแหน่ง address ของค่านั้น ในที่นี้ค่า hash สุดการคำนวณเท่ากับ 260 ซึ่งจะนำไปค้นหาในโครงสร้างพจนานุกรมแบบ Hashing ดังรูปที่ 2



รูปที่ 2 รูปแสดงวิธีการค้นหาในพจนานุกรมแบบ Hashing

ขั้นตอนการตัดแบ่งคำโดยใช้ข้อมูลจากพจนานุกรม

ในการตัดแบ่งพยางค์จากพจนานุกรมนี้จะใช้หลักการเปรียบเทียบกับพจนานุกรมที่มีอยู่ในหน่วยความจำ เช่น มีประโยคตัวอย่างดังนี้


1 2 3 4 5 6 7 8 9 10

ก ร ต ร ว จ ส อ บ

ในการพิจารณาในการตัดแบ่งคำในภาษาไทย จะนำตัวอักษรของคำมาทีละตัว มาทำการคำนวณผ่าน Hash Function เพื่อทำการเปรียบเทียบกับโครงสร้างของพจนานุกรม ว่าพบคำหรือไม่พบในพจนานุกรม ถ้าพบจะนำค่าตำแหน่งของตัวอักษรมาเก็บใน Stack ตัวที่ 1 และ

เมื่อพบตำแหน่งที่ยาวที่สุดในการตัดคำในแต่ละรอบจะนำมาเก็บไว้ใน Stack ตัวที่ 2 แล้วเริ่มต้นคำใหม่ เริ่มจากตำแหน่งของคำที่ยาวที่สุดทำงานสิ้นสุดบรรทัด ดังตัวอย่างคือการนำเอาตัวอักษรแรก คือ ก มาทำการคำนวณผ่าน Hash Function เพื่อเปรียบเทียบโครงสร้างข้อมูลในพจนานุกรมที่เก็บแบบ Hashing ว่าพบหรือไม่ ถ้าพบจะทำการใส่ค่าตำแหน่งตัวอักษรใน Stack ตัวที่ 1 และถ้าไม่พบจะทำการนำตัวอักษรต่อไป คือ ำ มาทำการคำนวณต่อจากตัวอักษรก่อนหน้า แล้วนำมาเปรียบเทียบกับพจนานุกรมว่าพบหรือไม่ จะทำเช่นนี้จนกว่าจะสิ้นสุด

บรรทัด และเมื่อได้คำที่ยาวที่สุดจะทำการเก็บตำแหน่งไว้ ใน Stack ตัวที่ 2 เพื่อให้ทราบถึงตำแหน่งที่ตัดคำดังรูปที่ 3



10	(สอบ)
9	(สอ)
7	(ตรวจ)
3	(การ)
2	(กา)

10	(สอบ)
7	(ตรวจ)
3	(การ)

ค่าใน Stack ตัวที่ 1

จะเก็บตำแหน่งที่สามารถตัดได้

ค่าใน Stack ตัวที่ 2

จะเก็บตำแหน่งที่ตัดยาวที่สุดได้

รูปที่ 3 รูปแสดงค่าตำแหน่งที่สามารถทำการตัดแบ่งคำได้

การถอยหลังเมื่อพบปัญหา (Back Tracking)

ในการค้นหาคำในพจนานุกรมเพื่อนำมาตัดแบ่งคำ อาจจะมีปัญหาในการตัดแบ่งคำบางคำ ซึ่งในงานวิจัยนี้ได้นำวิธีการ Back Tracking มาใช้เพื่อใช้ตัดสินใจการตัดแบ่งคำ เพื่อให้ได้คำที่ถูกต้องมากที่สุด ดังตัวอย่าง


1 2 3 4 5 6 7 8 9

การกระจาย

ในการทำงานจะมี ขั้นตอนดังนี้ คือ เริ่มต้นจะหาคำที่ยาวที่สุดก่อน ในที่นี้จะได้คำว่า “การก” และจะทำการเก็บตำแหน่งในแต่ละตัวใน stack ตัวที่ 1 ว่ามีค่าที่สั้นกว่าอะไรบ้าง คือคำว่า ก, กร จากนั้นในรอบต่อ

มานำตัวอักษรถัดจากคำว่า การก มาตัดแบ่งต่อจะได้คำเดียวคือ “ระ” และนำตัวอักษรที่ต่อจาก ระ มาตัดแบ่งต่อจะได้คำว่า จา แล้วนำตัวอักษรถัดมาตัดแบ่งโดยในที่นี้จะมีตัวอักษร ย เหลือเพียงตัวเดียว ซึ่งไม่สามารถตัดแบ่งได้คือ จึงทำการ Back Track ไปยังตำแหน่งก่อนหน้า รวมทั้งทำการเก็บตำแหน่งของคำที่ยาวที่สุดในการตัดแบ่งคำไว้ด้วย โดยไปยังที่ตัวอักษร จ (ตำแหน่งที่ 7) แล้วทำการคำนวณผ่าน Hash Function ถ้าพบคำในพจนานุกรมจะทำการเก็บค่าใน Stack ทั้ง 2 ตัวใหม่ โดยการ Back Track จะทำไปจนกว่าค่าที่ Back Track ใน Stack ตัวที่ 1 จะหมด ซึ่งจะมีขั้นตอนการทำงานดังนี้

ขั้นตอนที่ 1




8 (จา)
6 (ระ)
4 (การก)
3 (การ)
2 (กา)

ค่าใน Stack ตัวที่ 1
จะเก็บตำแหน่งที่สามารถตัดได้

8 (จา)
6 (ระ)
4 (การก)

ค่าใน Stack ตัวที่ 2
จะเก็บตำแหน่งที่ตัดยาวที่สุดได้

ขั้นตอนที่ 2



8 (กระจาย)
6 (กระ)
3 (การ)
2 (กา)

ค่าใน Stack ตัวที่ 1
จะเก็บตำแหน่งที่สามารถตัดได้

8 (กระจาย)
3 (การ)


ค่าใน Stack ตัวที่ 2
จะเก็บตำแหน่งที่ตัดยาวที่สุดได้

รูปที่ 4 รูปแสดงขั้นตอนตำแหน่งการตัดคำใน Stack ในการ Back Tracking

การหาขอบเขตของคำที่ไม่พบในพจนานุกรม

ในการตัดแบ่งคำเปรียบเทียบกับพจนานุกรม เมื่อทำการ Back Track จนไปถึงที่ตัวอักษรต้นบรรทัด โปรแกรมจะทำการหาขอบเขตของคำที่ไม่พบในพจนานุกรม โดยจะทำการเก็บค่าตำแหน่งที่ทำการตัดไปแล้วมากที่สุดเป็นตำแหน่งเริ่มต้นของคำที่ผิด แล้วทำการ

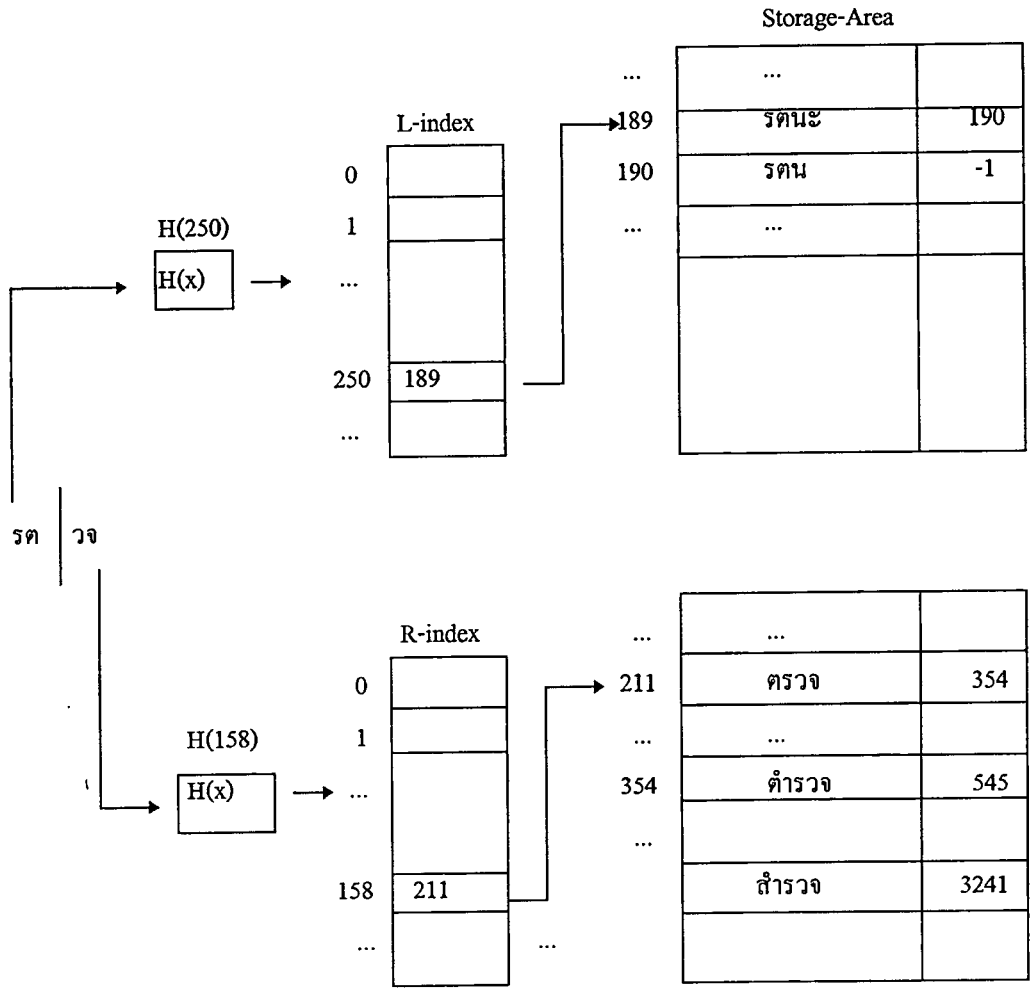
Skip ตัวอักษรไปที่ละตัว เพื่อนำตัวอักษรตัวถัดไปมาทำการคำในพจนานุกรม เมื่อพบว่าจากตำแหน่งที่คำนวณใหม่สามารถทำการตัดแบ่งคำได้เมื่อเปรียบเทียบกับพจนานุกรม ได้มากกว่าหรือเท่ากับสองคำที่พบในพจนานุกรม โปรแกรมจะนำตำแหน่งนั้นมาเป็นจุดสิ้นสุดคำที่ผิด เพื่อทำการแก้ไขต่อไป ดังตัวอย่างต่อไปนี้



วิธีการค้นหาคำคล้ายเมื่อพบคำที่ไม่มีในพจนานุกรม

จากวิธีการหาขอบเขตของคำที่ไม่มีพบในพจนานุกรม ทำให้ได้คำที่ไม่มีพบในพจนานุกรมและทราบถึงจำนวนตัวอักษรที่ประกอบในคำที่ผิดนั้น โดยการค้นหาคำคล้ายจะทำได้ด้วยการนำจำนวนตัวอักษรที่ผิดในคำ

นั้นมาทำการแบ่งครึ่งทั้งทางซ้ายและทางขวา แล้วนำตัวอักษรที่ได้ทำการแบ่งมาคำนวณผ่านค่า Hashing Function ทั้งซ้ายและขวา เพื่อจะค้นหารายการคำที่น่าจะเป็นมาทำการแก้ไขต่อไป เช่นจากตัวอย่างข้างต้น จะได้คำว่า "ตรวจ" เป็นคำผิด ดังรูปที่ 5



หมายเหตุ ตัวอักษร “ สระอ้อ “ ในภาษาไทยจะถือว่าเป็น 1 ตัวอักษรในคำของภาษาไทย
รูปที่ 5 รูปแสดงวิธีการค้นหาคำคล้ายในพจนานุกรม

จากการค้นหาคำคล้ายจะพบว่าคำว่า "ตรวจ" จะมีคำที่คล้ายกัน คือ คำว่า ตรวจ, ตรวจ, ตรวจ, ตรวจ, ตรวจ เป็นต้น ทำให้สามารถเลือกคำที่ถูกต้องตามพจนานุกรมในการแก้ไขคำที่ผิด

การเปรียบเทียบความสามารถของ Word กับผลงานที่ทำการวิจัย

ในประโยคภาษาไทยที่ นำมาตรวจสอบกับ Software มาตรฐานของ Word ยังพบข้อผิดพลาดในการแบ่งแยกคำอยู่ ทั้งๆที่คำในประโยคนั้นๆเป็นคำที่ถูกต้อง และมีอยู่ในพจนานุกรมดังตัวอย่างนี้

ตารางที่ 5 ตารางแสดงตัวอย่างประโยคที่ Word ตัดแบ่งคำผิด

ตัวอย่างประโยค	Word 6.0	Word 7.0
การกระจาย มาบริจาค ปลากระป๋อง จมองหาสมาชิก	การกระจาย มาบริจาค ปลากระป๋อง จมองหาสมาชิก	การกระจาย มาบริจาค ปลากระป๋อง จมองหาสมาชิก

จากตารางจะพบว่าคำที่ Word ตัดคตินั้นเป็นคำที่เขียนถูกต้องตามพจนานุกรม เช่น ปลากระป๋อง ถ้าทำการแยกจากกันเป็น ปลา กับ กระป๋อง ใน Word จะทำถูก แต่ถ้าเขียนติดกันเป็น ปลากระป๋อง Word จะบอกว่าผิดดังตารางที่ 5 และคำที่ประกบกันเป็นประโยคเมื่อทำการแยกเป็นคำจะพบว่าการตัดแบ่งคำใน Word สามารถตัด

แบ่งได้ถูกต้อง นอกจากนี้ยังพบว่าคำบางคำที่ Word ไม่สามารถตัดแบ่งได้แต่คำๆนั้นเมื่อตรวจสอบในพจนานุกรมพบว่า เป็นคำที่ถูกต้อง ตัวอย่างเช่น คำว่า เศรษฐกิจ, แม่นยำ, อุตสาหกรรม เป็นต้น ในผลงานที่ได้ทำการวิจัยยังทำการเปรียบเทียบความเร็วในการตัดแบ่งคำระหว่าง Word กับ ผลงานที่ได้ทำการวิจัย ดังตารางที่ 6

ตารางที่ 6 แสดงการเปรียบเทียบความเร็วในการตัดแบ่งคำ (sec)

จำนวนหน้า Software จำนวนบรรทัด	5	10	20	50	100	200
Word 6.0	3	4	9	20	38	75
โปรแกรม Spell Check (พิจารณาจนสุดบรรทัด)	2	3	6	14	28	55
โปรแกรม Spell Check (พิจารณา 15 ตัวอักษร)	1	2	4	7	13	26
โปรแกรม Spell Check (พิจารณา 25 ตัวอักษร)	1	2	4	9	17	35

หมายเหตุ การทดสอบความเร็วในการตัดแบ่งใน Word 7.0 ไม่สามารถตรวจสอบได้เพราะถ้าเอกสารมีจำนวนตัวอักษรมากๆ การทำงานของ Word 7.0 จะไม่มีการตอบสนอง (Not Respond)

4. สรุปและวิจารณ์ผล

จากการใช้ Hashing Algorithm ในการตัดแบ่งแยกคำในภาษาไทย และการใช้โครงสร้างแบบ Hashing ในการเก็บคำในพจนานุกรม ทำให้ประสิทธิภาพของการ

ตรวจสอบการตัดแบ่งคำในภาษาไทย ทำงานได้อย่างรวดเร็วกว่าการใช้ Software มาตรฐาน Word มาทำการตัดแบ่งคำ มีความถูกต้อง มีความแม่นยำในการตัดแบ่งแยกคำสูง ง่ายต่อการพัฒนาและเมื่อพบคำที่ผิดในเอกสาร โครงสร้างที่จัดเก็บนี้จะช่วยค้นหาคำที่คล้ายกับคำที่ผิดได้อย่าง

รวดเร็ว และยังสามารถเพิ่มคำใหม่ที่จะเกิดขึ้นต่อไปในอนาคตได้อย่างง่ายดาย

กิตติกรรมประกาศ

เอกสารอ้างอิง

- [1] James L. Peterson , " Computer Programs for Detecting and Corrceting Spelling Errors" , Communication of the ACM , Vol . 23 , No 12 , December 1980.
- [2] James L. Peterson , " A Note On Undetected Typing Errors " ,Communication of the ACM , Vol 29 , No 7 , July 1986 .
- [3] Jurgen Schurmann , " A Multifont Word Recognition System for Postal Address Reading " , IEEE Transaction on Computers , Vol c - 27 , No 8 , August 1978 .
- [4] Rainer Hoch and Thomas Kiceinger , " On Virtual Partitioning of Large Dictionaries for Contextual Post - Processing to Improve Character Recognition" , IEEE. Conference 1993 .
- [5] S. Chamyapompong , " A Thai Syallable Separation Algorithm" , AIT Thesis No. CA-83-10.
- [6] ยืน ภู่วรวรรณ , สมนึก คีรีโต และ สุรศักดิ์ สงวนพงษ์ "การตัดพยางค์คำไทยด้วยโครงสร้างข้อมูลแบบ

ผู้วิจัยและพัฒนาต้องขอขอบพระคุณอย่างสูงต่อศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) ที่ได้เอื้อเฟื้อไฟล์รายการคำของข้อมูลในพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2525

ตันไม้" , รายงานการประชุมวิชาการ ทางวิศวกรรมไฟฟ้า 8 สถาบันอุดมศึกษา ครั้งที่ 8 , ธันวาคม 2528.

[7] ยืน ภู่วรวรรณ และ วิวรรณ อิมอรณณ์ , " การแบ่งแยกพยางค์ไทยด้วยดิกชันนารี " , รายงานการประชุมทางวิชาการ วิศวกรรมไฟฟ้า สถาบันอุดมศึกษาแห่งประเทศไทย ครั้งที่ 9 , ธันวาคม 2529 .

[8] ยืน ภู่วรวรรณ และ วิวรรณ อิมอรณณ์ , " การตรวจสอบตัวสะกดด้วยคอมพิวเตอร์ " , รายงานการประชุมวิชาการวิศวกรรมไฟฟ้า ครั้งที่ 10 , พฤศจิกายน 2530.

[9] ผศ.ดร. เสรี เสวตเศรณี และ รศ. ยืน ภู่วรวรรณ , " การพัฒนาอัลกอริทึม สำหรับประมวลผลตัวอักษรไทย " , วิศวกรรมสาร ปีที่ 37 เล่มที่ 3 , มิถุนายน 2527 .

[10] " พจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2525 " , ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC).

[11] ยืน ภู่วรวรรณ และ ชัยยศ วงศ์ชัยสุวรรณ , " การประมวลผลภาษาธรรมชาติ (Natural Language Processing) " , สถาบันเทคโนโลยีพระจอมเกล้าธนบุรี.

[12] ติม ตันติยาสวัสดิกุล , " มาแบ่งคำภาษาไทยให้ดีขึ้นเถิด " , คอมพิวเตอร์ ปีที่ 16 ฉบับที่ 84 มีนาคม - เมษายน 2532.

ประวัติผู้เขียน

ชื่อผู้เขียน

นาย สรศักดิ์ ไทยแท้

วัน เดือน ปีเกิด

30 กรกฎาคม พ.ศ. 2516

สถานที่เกิด

กรุงเทพมหานคร

วุฒิการศึกษาระดับปริญญาตรี

วท. บ. (เอกคณิตศาสตร์)

สถานที่สำเร็จการศึกษา

คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ประสานมิตร

ปีที่สำเร็จการศึกษา

ปีการศึกษา 2538