



การใช้เทคนิคเอ็นแกรมช่วยในการเพิ่มประสิทธิภาพการตัดสินใจแปลอักษรเบรลล์  
ในกรณีที่มีคำควบกล้ำ สระประสมและอักษรเบรลล์สองเซลล์

**Enhancing Thai Braille Translation with n-gram for Decision Making  
in the Cases of Compound Consonants, Vowels and Characters**

ทศวัฒน์ ชุนหวิทยะธีระ

**Totsawat Chunhawitayatera**

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา  
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์  
มหาวิทยาลัยสงขลานครินทร์

**A Thesis Submitted in Partial Fulfillment of the Requirements for the Degree of  
Master of Engineering in Computer Engineering**

**Prince of Songkla University**

**2555**

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

ชื่อวิทยานิพนธ์            การใช้เทคนิคเอ็นแกรมช่วยในการเพิ่มประสิทธิภาพการตัดสินใจแปล  
อักษรเบรลล์ในกรณีที่มีคำควบกล้ำ สระประสมและอักษรเบรลล์สองเซลล์

ผู้เขียน                    นายทศวัฒน์ ชูณหวิตยะธีระ

สาขาวิชา                 วิศวกรรมคอมพิวเตอร์

---

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

คณะกรรมการสอบ

.....  
(ผู้ช่วยศาสตราจารย์ ดร.พิชญา ตันชัยย์)

.....ประธานกรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.อำนาจ เปาะทอง)

.....กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.พิชญา ตันชัยย์)

.....กรรมการ  
(ดร.เดือนเพ็ญ กชกรจารุงศ์)

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้รับวิทยานิพนธ์ฉบับนี้  
เป็นส่วนหนึ่งของการศึกษา ตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชา  
วิศวกรรมคอมพิวเตอร์

.....  
(ศาสตราจารย์ ดร.อมรรัตน์ พงศ์คารา)

คณบดีบัณฑิตวิทยาลัย

ชื่อวิทยานิพนธ์ การใช้เทคนิคเอ็นแกรมช่วยในการเพิ่มประสิทธิภาพการตัดสินใจแปล  
อักษรเบรลล์ในกรณีที่มีคำควบกล้ำ สระประสมและอักษรเบรลล์สองเซลล์  
ผู้เขียน นายทศวัฒน์ ชุณหวิทยะธีระ  
สาขาวิชา วิศวกรรมคอมพิวเตอร์  
ปีการศึกษา 2554

### บทคัดย่อ

ในปัจจุบันมีการพัฒนาโปรแกรมเพื่อช่วยแปลงข้อความอักษรเบรลล์ภาษาไทยให้เป็นข้อความภาษาไทยเพื่ออำนวยความสะดวกในการสื่อสารระหว่างผู้พิการทางสายตาและคนสายตาปกติ ทั้งนี้เพราะลักษณะการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 มีความแตกต่างจากลักษณะการเขียนภาษาไทยอยู่พอสมควร จึงไม่สามารถใช้วิธีการแปลงโดยอาศัยการเปรียบเทียบแบบตัวอักษรต่อตัวอักษรหรือคำต่อคำได้ ซึ่งโปรแกรมที่ได้มีการพัฒนามาก่อนหน้านี้มักใช้กฎไวยากรณ์ทางภาษาเข้ามากำกับวิธีการแปลง แต่ยังคงประสบปัญหาการแปลงคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ เนื่องจากลักษณะการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 มีลักษณะการเขียนอักษรเรียงติดต่อกันไปจนกระทั่งจบประโยคและใช้การเว้นวรรคเพื่อแบ่งแต่ละประโยคออกจากกัน คำประเภทดังกล่าวมีรูปพ้องกัน จึงสามารถอ่านได้หลายแบบและแต่ละรูปแบบก็มีความหมายที่แตกต่างกันไป จึงทำให้เกิดความกำกวมขึ้นและไม่สามารถเขียนโปรแกรมให้ครอบคลุมทุก ๆ กรณีที่เกิดขึ้นได้

งานวิจัยนี้จึงได้นำเสนอวิธีแก้ไขปัญหาการแปลงข้อความอักษรเบรลล์ภาษาไทยให้เป็นข้อความภาษาไทยเพื่อใช้กับประโยคที่มีคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ โดยใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำก่อนที่จะแปลงให้เป็นภาษาไทยเพื่อลดความกำกวมของภาษาและนำเสนอจำนวนแกรมที่เหมาะสมสำหรับใช้ตัดคำอักษรเบรลล์ภาษาไทย ซึ่งผลการทดลองสรุปว่าสามารถแปลงข้อความได้ถูกต้องมากขึ้นและใช้ปริมาณหน่วยความจำน้อยลง แต่ใช้เวลาแปลงมากกว่าเดิม โดยอยู่ในเกณฑ์ที่ยอมรับได้ และจำนวนแกรมที่เหมาะสมคือ 4-แกรม

คำสำคัญ: อักษรเบรลล์ภาษาไทย, เอ็นแกรมโมเดล, โปรแกรมแปลงข้อความอักษรเบรลล์ภาษาไทยเป็นข้อความภาษาไทย

<b>Thesis Title</b>	Enhancing Thai Braille translation with n-gram for decision making in the cases of compound consonants, vowels and characters
<b>Author</b>	Mr. Totsawat Chunhawitayatera
<b>Major Program</b>	Computer Engineering
<b>Academic Year</b>	2011

## **ABSTRACT**

There have been several developments for Thai Braille to Thai translation for assisting the communication between the visually impaired and the normal sighted. The grammar rules of Thai Braille and Thai are different. So, it is not applicable to use character-to-character or word-to-word translation techniques. Generally, Thai Braille to Thai translation programs apply grammar rules to control the translation process but there are problems about translating compound consonants and vowels, two-cell Braille characters and transliterated words because Thai Braille Grade 1 write characters continuously until the end of the sentence and uses spaces for separating sentences. There are such words that have the same character sequence with other words but have several meanings. This causes ambiguity. Therefore, it is difficult to write a program to cover all conditions.

This Thesis proposes a method to solve Thai Braille to Thai translation problems in the cases that the sentences contain compound consonants, vowels, two-cell Braille characters and transliterated words by using the N-gram model technique to wrap words before being translated into Thai in order to reduce the ambiguity of the language and propose the optimal N-gram number for wrapping Thai Braille words. The new method can improve the correctness of the translation and reduce the memory consumption better than the old method but the new method requires more translation time than the old method. The appropriate N-gram number is 4-gram for the Braille Thai text word wrap.

Keywords: Thai Braille, N-gram model, Thai Braille to Thai translation program

## กิตติกรรมประกาศ

ขอแสดงความขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. พิชญ์ ตันชัยย์ อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก ที่ได้กรุณาอุทิศเวลาให้คำปรึกษา ให้การสนับสนุนการทำวิจัย แนะนำความรู้ในด้านการทำวิจัย เอกสาร ข้อมูลต่างๆเป็นอย่างดี รวมทั้งแนวความคิดและกำลังใจในการแก้ปัญหา ตลอดจนตรวจทานแก้ไขวิทยานิพนธ์ให้ดำเนินไปอย่างสมบูรณ์

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. อำนาจ เปาะทอง ประธานกรรมการสอบวิทยานิพนธ์ที่ได้กรุณาให้คำปรึกษาคำแนะนำ และให้การช่วยเหลือแก้ไขปัญหาในงานวิจัย และตรวจทานวิทยานิพนธ์ให้ดำเนินไปอย่างสมบูรณ์

ขอขอบพระคุณ ดร. เดือนเพ็ญ กชกรจารุงพงศ์ กรรมการสอบวิทยานิพนธ์ที่ได้กรุณาให้คำปรึกษาคำแนะนำ และให้การช่วยเหลือแก้ไขปัญหาในงานวิจัย

ขอขอบคุณ พี่ๆ เพื่อน ๆ และน้องๆ นักศึกษาปริญญาโท ภาควิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยสงขลานครินทร์ โดยเฉพาะกลุ่มงานวิจัยห้อง WIG ประกอบด้วย นางสาวสุภาวดี มากอ้น, นายพิทักษ์ เสวตสุนทร, นายณัฐวุฒิ วิจิตร และนางสาวพรวิภา สร้อยทอง และทุกท่านที่ได้ให้คำแนะนำ คำปรึกษา และกำลังใจที่ดีมาโดยตลอด

ขอขอบพระคุณ คณาจารย์และเจ้าหน้าที่ในภาควิชาวิศวกรรมคอมพิวเตอร์ทุกท่าน ที่ให้ความช่วยเหลือในด้านต่างๆมาโดยตลอด จนกระทั่งงานสำเร็จลุล่วง

สุดท้ายนี้ ข้าพเจ้าขอโน้มราลึกถึงพระคุณของนายอภิชัย ชุณหวิทยะธีระ (บิดา) และนางวารุณี ชุณหวิทยะธีระ (มารดา) บุคคลในครอบครัว ที่ส่งเสริมสนับสนุน ให้คำแนะนำ ให้คำปรึกษา ให้กำลังใจ และทุนทรัพย์แก่ข้าพเจ้าตลอดมาจนกระทั่งทำให้ข้าพเจ้าประสบความสำเร็จ

ทศวัฒน์ ชุณหวิทยะธีระ

## สารบัญ

	หน้า
บทคัดย่อ.....	(3)
ABSTRACT.....	(4)
กิตติกรรมประกาศ.....	(5)
สารบัญ.....	(6)
สารบัญตาราง.....	(10)
สารบัญภาพประกอบ.....	(12)
สัญลักษณ์คำย่อและตัวย่อ.....	(14)
ศัพทานุกรม.....	(15)
บทที่ 1 บทนำ	1
1.1 ความสำคัญ และที่มาของวิทยานิพนธ์.....	1
1.2 วัตถุประสงค์.....	4
1.3 ขอบเขตของการวิจัย.....	4
1.4 ขั้นตอนการวิจัยและวิธีการวิจัย.....	5
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	5
บทที่ 2 ทฤษฎีและหลักการที่เกี่ยวข้อง.....	7
2.1 อักษรเบรลล์.....	7
2.1.1 อักษรเบรลล์ภาษาไทย.....	8
2.1.2 หลักการอ่านเขียนอักษรเบรลล์ภาษาไทยระดับ 1.....	10
2.2 โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file.....	12
2.3 เทคนิคการตัดคำ.....	13
2.3.1 เทคนิคการตัดคำโดยใช้กฎพื้นฐาน.....	14
2.3.2 เทคนิคการตัดคำโดยใช้พจนานุกรม.....	15
2.3.3 เทคนิคการตัดคำโดยใช้คลังข้อมูล.....	17
2.4 คลังข้อมูลภาษา.....	18
2.5 เอ็นแกรมโมเดล.....	21
2.5.1 หลักการทำงานของเอ็นแกรม โมเดล.....	21

## สารบัญ (ต่อ)

	หน้า
2.6 Smoothing Techniques.....	22
2.7 CMU-SLM toolkit.....	24
2.8 โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์.....	25
บทที่ 3 การออกแบบและการพัฒนาระบบ.....	39
3.1 การวิเคราะห์ปัญหาการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยในปัจจุบัน.....	39
3.2 แนวคิดในการแก้ไขปัญหานี้.....	30
3.3 การคัดเลือกประโยคจากคลังข้อมูล BEST และการสร้างไฟล์โมเดล อักษรเบรลล์ภาษาไทย.....	31
3.3.1 การคัดเลือกประโยคที่ต้องการจากคลังข้อมูล BEST.....	32
3.3.2 การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย.....	36
3.4 ภาพรวมของระบบที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้.....	39
3.5 อินพุตและเอาต์พุตของระบบ.....	41
3.6 โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรม เข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้.....	41
3.6.1 ขั้นตอน pre_ngram_generate.....	41
3.6.2 ขั้นตอน generate_ngram_pattern.....	44
3.6.3 ขั้นตอน select_output_pattern.....	48
3.6.4 ขั้นตอน translate_to_thai.....	56
3.7 การประยุกต์เอ็นแกรมโมเดล.....	61
3.8 Smoothing Techniques ที่เลือกใช้.....	66
3.9 รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทย.....	69
บทที่ 4 ผลการทดลอง.....	73
4.1 ด้านความถูกต้องของการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทย.....	73

## สารบัญ (ต่อ)

	หน้า
4.1.1 เครื่องมือที่ใช้ในการทดสอบ.....	73
4.1.2 ภาพรวมการทดสอบด้านความถูกต้องการแปลงอักษรเบรลล์ภาษาไทย ไปเป็นภาษาไทย.....	74
4.1.3 ชุดข้อมูลทดสอบเปรียบเทียบด้านความถูกต้อง.....	75
4.1.4 ผลการทดลองเปรียบเทียบด้านความถูกต้อง.....	77
4.2 ด้านปริมาณการใช้หน่วยความจำในการแปลง.....	79
4.2.1 เครื่องมือที่ใช้ในการทดสอบ.....	79
4.2.2 ภาพรวมการทดสอบปริมาณการใช้หน่วยความจำในการแปลง.....	79
4.2.3 ชุดข้อมูลทดสอบด้านปริมาณการใช้หน่วยความจำ.....	81
4.2.4 ผลการทดลองเปรียบเทียบปริมาณการใช้หน่วยความจำ.....	82
4.3 ระยะเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทย.....	83
4.3.1 เครื่องมือที่ใช้ในการทดสอบ.....	83
4.3.2 ภาพรวมการทดสอบระยะเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทย ไปเป็นภาษาไทย.....	84
4.3.3 ชุดข้อมูลทดสอบเปรียบเทียบด้านเวลาที่ใช้ในการแปลง.....	86
4.3.4 ผลการทดลองเปรียบเทียบด้านเวลาที่ใช้ในการแปลง.....	89
4.4 สรุปผลการทดสอบ.....	92
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	93
5.1 สรุปผลการวิจัย.....	93
5.2 สรุปปัญหา อุปสรรค และสาเหตุข้อผิดพลาดในงานวิจัยนี้.....	94
5.3 ข้อเสนอแนะ.....	97
เอกสารอ้างอิง.....	99
ภาคผนวก.....	103



## สารบัญ (ต่อ)

	หน้า
ภาคผนวก ก. ผลงานตีพิมพ์เผยแพร่จากวิทยานิพนธ์.....	104
ภาคผนวก ข. ตารางผลการทดลอง.....	114
ภาคผนวก ค. รายการคำที่มีความผิดพลาดประเภทต่างๆ.....	121
ภาคผนวก ง. ตารางอักษรเบรลล์ประเภทต่างๆ.....	156
ประวัติผู้เขียน.....	158

## สารบัญตาราง

	หน้า
ตารางที่ 2.1 พยัญชนะภาษาไทยที่มีรูปอักษรเบรลล์แบบ 2 เซลล์.....	8
ตารางที่ 2.2 รูปอักษรเบรลล์ของสระประสม.....	9
ตารางที่ 2.3 สระและเครื่องหมายที่มีรูปอักษรเบรลล์แบบ 2 เซลล์.....	10
ตารางที่ 3.1 อักษรเบรลล์สองเซลล์ที่มีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียว สองตัวที่เขียนติดกัน.....	28
ตารางที่ 3.2 รายละเอียดการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST.....	35
ตารางที่ 3.3 รายละเอียดของตัวแปรในขั้นตอน pre_ngrams_generate.....	42
ตารางที่ 3.4 รายละเอียดของตัวแปรที่ใช้ในขั้นตอน gen_ngram_pattern.....	44
ตารางที่ 3.5 รายละเอียดตัวแปรต่างๆ ที่ใช้ในขั้นตอน select_output_pattern.....	48
ตารางที่ 3.6 ตัวแปรต่างๆ ที่ใช้ในขั้นตอน translate_to_thai.....	58
ตารางที่ 3.7 ตัวแปรต่างๆ ที่ใช้ในฟังก์ชัน load_ngram_word.....	61
ตารางที่ 3.8 ตัวแปรต่างๆ ที่ใช้ในขั้นตอน calculate_smoothing.....	67
ตารางที่ 3.9 ตัวแปรชนิดต่างๆ ที่ใช้ในการสร้างรายการคำ.....	71
ตารางที่ 4.1 รายละเอียดชุดข้อมูลทดสอบด้านความถูกต้อง.....	76
ตารางที่ 4.2 ผลการทดลองเปรียบเทียบความถูกต้องของวิธีการเดิมและวิธีการใหม่.....	77
ตารางที่ 4.3 รายละเอียดชุดข้อมูลทดสอบด้านปริมาณการใช้หน่วยความจำ.....	82
ตารางที่ 4.4 ผลการทดลองปริมาณการใช้หน่วยความจำ.....	83
ตารางที่ 4.5 รายละเอียดประเภทคำควบล้ำ.....	87
ตารางที่ 4.6 รายละเอียดประเภทสระประสม.....	88
ตารางที่ 4.7 รายละเอียดประเภทอักษรเบรลล์สองเซลล์.....	88
ตารางที่ 4.8 รายละเอียดประเภทคำทับศัพท์.....	88
ตารางที่ 4.9 รายละเอียดประเภทข้อความทั่วไป.....	89
ตารางที่ 4.10 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง.....	90
ตารางที่ 1 ผลการทดลองปริมาณการใช้หน่วยความจำ.....	114
ตารางที่ 2 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำควบล้ำ.....	115
ตารางที่ 3 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์สระประสม.....	116

## สารบัญตาราง (ต่อ)

	หน้า
ตารางที่ 4 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภท ไฟล์อักษรเบรลล์สองเซลล์.....	117
ตารางที่ 5 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำทับศัพท์.....	118
ตารางที่ 6 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประโยคทั่วไปของวิธีการเดิม.....	119
ตารางที่ 7 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประโยคทั่วไปของวิธีการใหม่.....	120
ตารางที่ 8 รายการคำที่โปรแกรม Thai2brl แปลงผิดพลาด.....	121
ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทย ที่โปรแกรม SWATH ตัดคำผิดพลาด.....	122
ตารางที่ 10 รายการคำของคลังข้อความ BEST เขียนผิดพลาด.....	154
ตารางที่ 11 อักษรเบรลล์ภาษาไทยแบบ 6 จุด.....	156
ตารางที่ 12 อักษรเบรลล์ภาษาไทยแบบ 8 จุด.....	157

## สารบัญภาพประกอบ

	หน้า
รูปที่ 2.1 การเรียงจุดในอักษรเบรลล์.....	7
รูปที่ 2.2 กราฟเปรียบเทียบจำนวนครั้งที่กดคีย์เมื่อใช้ข้อมูลและจำนวนแกรมต่างๆ.....	20
รูปที่ 3.1 ขนาดของไฟล์ที่มีการใช้คำประเภทต่างๆ เปรียบเทียบับขนาดของไฟล์ทั้งหมด.....	30
รูปที่ 3.2 ภาพรวมวิธีการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST.....	34
รูปที่ 3.3 ตัวอย่างประโยคที่คัดเลือกจากคลังข้อความ BEST.....	36
รูปที่ 3.4 ประโยคที่แปลงให้อยู่ในรูปของอักษรเบรลล์ภาษาไทย.....	36
รูปที่ 3.5 ขั้นตอนการสร้างโมเดลอักษรเบรลล์ภาษาไทย ด้วยชุดเครื่องมือ CMU-SLM toolkit.....	37
รูปที่ 3.6 ตัวอย่างไฟล์โมเดลอักษรเบรลล์ภาษาไทย.....	38
รูปที่ 3.7 ภาพรวมโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย ที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ.....	40
รูปที่ 3.8 ขั้นตอน prepare_ngram_pattern.....	43
รูปที่ 3.9 ขั้นตอน gen_ngram_pattern.....	45
รูปที่ 3.10 การสร้างรูปแบบเอ็นแกรม.....	47
รูปที่ 3.11 ขั้นตอนการทำงานของฟังก์ชัน select_output.....	49
รูปที่ 3.12 ขั้นตอนการทำงานของฟังก์ชัน ngram_to_word.....	51
รูปที่ 3.12a กรณีที่มีการเรียงตัวอักขระเหมือนกันทั้งหมด.....	53
รูปที่ 3.12b กรณีที่มีการเรียงตัวอักขระไม่เหมือนกันทั้งหมด.....	54
รูปที่ 3.13 ขั้นตอนการทำงานของฟังก์ชัน find_ngram.....	55
รูปที่ 3.14 ภาพรวมวิธีการแปลงแบบเทียบคำ.....	57
รูปที่ 3.15 การทำงานของขั้นตอน translate_to_thai.....	59
รูปที่ 3.16 การทำงานของฟังก์ชัน match_brl.....	60
รูปที่ 3.17 ขั้นตอนการทำงานของฟังก์ชัน load_ngram_word.....	62
รูปที่ 3.18 วิธีการจัดเก็บข้อมูลในตัวแปรประเภทต่างๆ.....	65
รูปที่ 3.19 ภาพรวมการทำงานของ Interpolation.....	66

## สารบัญภาพประกอบ (ต่อ)

	หน้า
รูปที่ 3.20 การทำงานของฟังก์ชัน calculate_smoothing.....	68
รูปที่ 3.21 ขั้นตอนการสร้างรายการคำภาษาไทย.....	70
รูปที่ 4.1 ภาพรวมวิธีการเปรียบเทียบด้านความถูกต้อง.....	74
รูปที่ 4.2 ภาพรวมวิธีการทดลองด้านปริมาณการใช้หน่วยความจำ.....	80
รูปที่ 4.3 ภาพรวมวิธีการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง.....	85
รูปที่ 5.1 ขั้นตอนการสร้างรายการคู่คำภาษาไทยและอักษรเบรลล์ภาษาไทย.....	95

## สัญลักษณ์คำย่อและตัวย่อ

ASCII	American Standard Code for Information Interchange
BCC	Braille Computer Code
BEST	Benchmark for Enhancing the Standard of Thai Language processing
BRL	Braille
CMU-SLM	The Carnegie Mellon University Statistical Language Modeling
Chr	Character
G II	Braille grade 2
HLT	Human Language Technology
NECTEC	National Electronics and Computer Technology Center
SWATH	Smart Word Analysis for Thai

## ศัพท์านุกรม

คลังข้อมูลฝึก	Training corpus
ช่องว่าง	Space
ฝึกฝนเอ็นแกรม โมเดล	N-gram model Training
รูปแบบเอ็นแกรม	N-gram pattern
สตริง	String
อาร์เรย์	Array
อักขรเบรลล์	Braille character
เอ็นแกรม โมเดล	N-gram model

# บทที่ 1

## บทนำ

### 1.1 ความสำคัญ และที่มาของวิทยานิพนธ์

ในปัจจุบันมีการพัฒนาโปรแกรมช่วยแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยแบบ File-to-file เพื่อช่วยอำนวยความสะดวกในการสื่อสารระหว่างผู้พิการทางสายตาและคนสายตาปกติ ทั้งนี้เพราะลักษณะการเขียนอักษรเบรลล์ภาษาไทยมีความแตกต่างจากการเขียนภาษาไทยอยู่พอสมควรกล่าวคือ ใช้สัญลักษณ์, ตัวเลขอารบิกและตัวอักษรภาษาอังกฤษเพื่อแทนพยัญชนะ, สระ และวรรณยุกต์ในภาษาไทย (ในที่นี้จะกล่าวถึงเฉพาะการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 ในรูปแบบ Braille Computer Code (BCC) เท่านั้น) เช่น ใช้สัญลักษณ์ “?” เพื่อแทนตัวอักษร “พ”, ใช้ตัวเลขอารบิก “6” เพื่อแทนสระเอา, ใช้ตัวอักษรภาษาอังกฤษ “g” เพื่อแทนตัวอักษรภาษาไทย “ก” เป็นต้น นอกจากนี้ลักษณะการเขียนอักษรเบรลล์ภาษาไทยยังมีการเรียงพยัญชนะ, สระและวรรณยุกต์ที่แตกต่างไปจากลักษณะการเขียนภาษาไทยอีกด้วย ยกตัวอย่างเช่น คำว่า “เพ็ชร์” เมื่อเขียนให้อยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 จะมีการเรียงสระและพยัญชนะเป็น “พ+ล+สระเอีย” และเมื่อเขียนในรูปแบบ BCC จะได้ “?+l+” เป็นต้น (รายละเอียดการเขียนอักษรเบรลล์จะอธิบายในหัวข้อที่ 2.1.2 การเขียนอักษรเบรลล์ภาษาไทยระดับ 1)

นอกจากนี้การแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบ File-to-file ยังคงประสบปัญหาการหาขอบเขตของคำเช่นเดียวกันกับการแปลงภาษาไทยไปเป็นภาษาอังกฤษ ซึ่งปัญหานี้มีสาเหตุมาจากลักษณะการเขียนภาษาไทยที่เขียนอักษรเรียงติดกันไป โดยไม่มีการเว้นวรรคระหว่างคำ แต่จะเว้นวรรคเมื่อเขียนจบประโยคหรือขึ้นย่อหน้าใหม่และคำบางคำในภาษาไทยมีรูปที่พ้องกันทำให้สามารถอ่านได้หลายแบบและความหมายที่ต่างกันไปจึงก่อให้เกิดความกำกวมขึ้น และอักษรเบรลล์ภาษาไทยก็มีลักษณะการเขียนเช่นเดียวกับลักษณะการเขียนของภาษาไทยด้วย จึงทำให้ประสบปัญหาการหาขอบเขตของคำเช่นเดียวกันกับภาษาไทย โดยกระบวนการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบ File-to-file ทั่วไปมักประสบปัญหาในการแปลงคำที่เกี่ยวข้องกับคำควบกล้ำ คำที่มีการใช้สระประสม และคำที่มีการใช้อักษรเบรลล์สองเซลล์ (รายละเอียดการเขียนอักษรเบรลล์สองเซลล์จะอธิบายในหัวข้อที่ 2.1.1 อักษรเบรลล์ภาษาไทย) ซึ่งงานวิจัยเรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” โดยมหาวิทยาลัยสงขลานครินทร์ ได้



นำเสนอโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file [1] แต่ยังคงมีความผิดพลาดในการแปลงที่เกี่ยวกับประเภทของคำที่ได้กล่าวไว้ข้างต้น ตัวอย่างเช่น

การแปลงคำประเภทคำควบกล้ำหรือคำที่มีการใช้สระประสม เช่นคำว่า “\*๕(๔” (เป็นคำว่า “ตากเลี้ยง” ที่เขียนอยู่ในรูปแบบ BCC ระดับ 1) ซึ่งโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม จะแปลงเป็น “ตากเลี้ยง” ทั้งนี้เพราะคำดังกล่าวเมื่อเขียนในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 จะสามารถอ่านได้สองแบบคือ “ตากเลี้ยง” และ “ตากเลี้ยง” ซึ่งโปรแกรมส่วนใหญ่มักถูกกำหนดให้แปลงให้ได้คำที่มีตัวอักษรมากที่สุด หรือเลือกคำที่มีพยางค์ยาวที่สุด จึงดึงอักษร “๕” (“ก”) ไปรวมกับคำ “\*” (“ตา”) ซึ่งเมื่อดึงไปรวมแล้วทำให้เกิดคำว่า “ตาก” ซึ่งมีความหมายในภาษาไทย จึงทำให้แปลงออกมาเป็นคำว่า “ตากเลี้ยง” ซึ่งแม้จะถูกต้องตามหลักการเขียนไวยากรณ์อักษรเบรลล์และแต่ละคำคือ “ตาก” และ “เลี้ยง” ต่างก็มีความหมายในภาษาไทยด้วยกันทั้งคู่ แต่เมื่อนำมารวมกันแล้วกลับทำให้ความหมายโดยรวมผิดไป

การแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์ เช่นคำว่า “?๕๐๕”)” (เป็นคำว่า “พระองค์ทรง” ที่เขียนอยู่ในรูปแบบ BCC ระดับ 1) ซึ่งโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม จะแปลงเป็น “พระองค์ทรง” ทั้งนี้เป็นเพราะโปรแกรมจะไม่ทราบว่าเป็นอักษรเบรลล์สองเซลล์ที่มีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียวสองตัวหรือเป็นอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน โดยในกรณีที่ยกตัวอย่างนี้ ตัวอักษร “๕” เป็นอักษรเบรลล์สองเซลล์ที่มีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน ซึ่งก็คือ “การันต์+ท” จึงทำให้เกิดการแปลงที่ผิดพลาดดังกล่าว

การแก้ไขปัญหาล่าช้านี้ไม่สามารถกระทำได้โดยกำหนดเงื่อนไขเพิ่มเติม หากแต่ต้องพิจารณาความหมายโดยรวมหรือความถี่ในการใช้งาน จากปัญหาดังกล่าวผู้วิจัยจึงมีแนวคิดนำเทคนิคเอ็นแกรมเข้ามาแก้ไขปัญหา แบบจำลองเอ็นแกรม (N-Gram model) [2] เป็นแบบจำลองที่ใช้กระบวนการทางสถิติในการคำนวณหาความถี่หรือค่าความน่าจะเป็นของชุดอักขระ (Character sequence) ที่เกิดขึ้นร่วมกันเป็นคำ หรือค่าความน่าจะเป็นของคำที่เขียนเรียงกัน (Word sequence) ที่เกิดขึ้นร่วมกันเป็นประโยค โดยค่าความถี่หรือค่าความน่าจะเป็นสามารถคำนวณได้จากการนับจำนวนคำที่มีอยู่ในคลังข้อมูลฝึก (Training corpus) [13] ซึ่งแบบจำลองเอ็นแกรมนี้มีงานวิจัยต่างๆ ได้นำมาประยุกต์ เช่น “การระบุคำไทยและคำทับศัพท์ด้วยแบบจำลองเอ็นแกรม” [3] เป็นงานวิจัยที่นำเทคนิคของเอ็นแกรมเข้ามาช่วยระบุชนิดของภาษา, “การตัดคำและกำกับหมวดคำภาษาไทยแบบเบ็ดเสร็จด้วยคอมพิวเตอร์” [4] เป็นงานวิจัยที่นำเทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำภาษาไทย และระบุประเภทของคำ, “การประยุกต์เอ็นแกรมและเวกเตอร์โมเดลสำหรับระบบย่อข้อความภาษาไทย” [5] เป็นงานวิจัยที่นำเทคนิคเอ็นแกรมเข้ามาช่วยในการย่อข้อความภาษาไทย เป็นต้น ซึ่ง

งานวิจัยเหล่านี้เป็นการนำเอาเทคนิคเอ็นแกรมเข้ามาประยุกต์ในด้านประมวลผลทางภาษาไทย ทั้งสิ้น แต่ยังไม่มียานวิจัยใดเลยที่นำเอาเทคนิคเอ็นแกรมเข้ามาประยุกต์กับการประมวลผลอักษรเบรลล์ภาษาไทย นอกจากนี้อักษรเบรลล์ภาษาไทยมีความคล้ายคลึงกันกับภาษาไทยและมีปัญหาการหาขอบเขตคำเช่นเดียวกันกับภาษาไทยอีกด้วย

ดังนั้นผู้วิจัยจึงมีแนวความคิดนำเทคนิคเอ็นแกรมเข้ามาช่วยหาขอบเขตของคำอักษรเบรลล์ภาษาไทย ซึ่งจะทำให้ทราบขอบเขตที่แน่นอนของคำแต่ละคำจึงส่งผลให้การแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยทำได้ง่ายขึ้นและถูกต้องมากยิ่งขึ้น อีกทั้งการนำเทคนิคเอ็นแกรมมาประยุกต์ใช้นี้ ทำให้กระบวนการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยมีความซับซ้อนน้อยลงเมื่อเปรียบเทียบกับกระบวนการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคกฎไวยากรณ์ทางภาษาเข้ามาควบคุมการแปลง โดยให้เอ็นแกรมคำนวณหาความน่าจะเป็นของคำที่เกิดขึ้นร่วมกันเมื่อแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย เพื่อช่วยในการระบุขอบเขตของคำอักษรเบรลล์ภาษาไทยว่าควรแบ่งคำออกมาเป็นรูปแบบไหนจึงจะเหมาะสม และมีความถูกต้องมากที่สุด

วิทยานิพนธ์นี้ จึงมุ่งเน้นวิจัยและพัฒนาเพื่อศึกษาการนำเทคนิคเอ็นแกรมเข้ามาประยุกต์กับการแปลงอักษรเบรลล์ภาษาไทย เพื่อช่วยปรับปรุงกระบวนการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยให้ถูกต้องมากยิ่งขึ้น โดยมีประเด็นที่ศึกษาดังต่อไปนี้

- 1) การนำเทคนิคเอ็นแกรมเข้ามาประยุกต์ใช้ร่วมกับการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทย จะช่วยเพิ่มประสิทธิภาพในการแปลงได้หรือไม่ โดยเปรียบเทียบกับโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” ซึ่งเป็นโปรแกรมที่ได้มีการพัฒนามาก่อนหน้านี้แล้ว
- 2) การหาค่าของจำนวนแกรมที่เหมาะสม เพื่อหาค่าของจำนวนแกรมที่ให้ผลลัพธ์ในการแบ่งคำที่ดีที่สุดโดยเปรียบเทียบระหว่าง 3-แกรม, 4-แกรม และ 5-แกรม โดยใช้วิธีพิจารณาจากความถูกต้องของการแปลง ซึ่งจะต้องถูกต้องตามหลักไวยากรณ์ของอักษรเบรลล์และเมื่อนำไปแปลงให้เป็นภาษาไทยแล้วจะต้องถูกต้องตามหลักไวยากรณ์ของภาษาไทยด้วย และด้านปริมาณการใช้หน่วยความจำในการแปลงและด้านเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยมาประกอบกัน

## 1.2 วัตถุประสงค์

- 1) ศึกษาและพัฒนาการนำเอ็นแกรมเข้ามาช่วยการแบ่งคำอักษรเบรลล์และแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยที่เกี่ยวข้องกับ คำควบกล้ำ, คำที่มีการใช้สระประสม และคำที่มีการใช้อักษรเบรลล์สองเซลล์และคำทับศัพท์
- 2) เพื่อทดสอบและเปรียบเทียบความถูกต้องการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยระหว่างโปรแกรมแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดสินใจด้านการแบ่งคำและการแปลงอักษรเบรลล์ที่ได้เสนอไว้ในวิทยานิพนธ์นี้กับโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมที่ได้มีการพัฒนามาก่อนหน้านี้
- 3) เพื่อศึกษาจำนวนแแกรมที่เหมาะสมสำหรับใช้แบ่งคำอักษรเบรลล์ภาษาไทยโดยพิจารณาเปรียบเทียบจากด้านความถูกต้องของการแปลง, ด้านปริมาณการใช้หน่วยความจำในการแปลงและด้านเวลาที่ใช้ในการแปลง

## 1.3 ขอบเขตของการวิจัย

- 1) ศึกษา วิเคราะห์ ออกแบบและพัฒนาโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดสินใจด้านการแบ่งคำและการแปลงอักษรเบรลล์
- 2) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดสินใจด้านการแบ่งคำและการแปลงอักษรเบรลล์ที่ได้นำเสนอไว้ในวิทยานิพนธ์นี้เน้นในด้านการแก้ไขปัญหาการแปลงอักษรเบรลล์ภาษาไทยที่เกี่ยวข้องกับ การแปลงคำควบกล้ำ, การแปลงคำที่มีการใช้สระประสม, การแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์และการแปลงคำที่มีการใช้คำทับศัพท์
- 3) เปรียบเทียบประสิทธิภาพระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมกับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดสินใจด้านการแบ่งคำและการแปลงอักษรเบรลล์ในด้านความถูกต้องของการแปลง, ด้านปริมาณการใช้หน่วยความจำและด้านเวลาที่ใช้ในการแปลง
- 4) เปรียบเทียบจำนวนแแกรมที่เหมาะสมสำหรับใช้แบ่งคำอักษรเบรลล์ภาษาไทยโดยพิจารณาจากด้านความถูกต้องของการแปลง, ด้านปริมาณการใช้หน่วยความจำในการแปลงและ

ด้านเวลาที่ใช้ในการแปลงและเปรียบเทียบระหว่างจำนวนแกรม 3-แกรม, 4-แกรม และ 5-แกรม

- 5) โปรแกรมที่พัฒนาขึ้นมาี้ครอบคลุมเฉพาะการแปลงอักษรเบรลล์ภาษาไทยระดับ 1

#### 1.4 ขั้นตอนการวิจัยและวิธีการวิจัย

- 1) ศึกษางานวิจัยที่เกี่ยวข้องกับเอ็นแกรมโมเดลและเทคนิคการประมาณค่าความน่าจะเป็น
- 2) ศึกษางานวิจัยที่เกี่ยวข้องกับการประยุกต์เอ็นแกรมโมเดลและเทคนิคการตัดคำ
- 3) ศึกษางานวิจัยที่เกี่ยวข้องกับคลังข้อมูลและเทคนิคการฝึกฝนเอ็นแกรมโมเดล
- 4) ออกแบบและพัฒนา โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ
- 5) ออกแบบและพัฒนาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบวิธีจับคู่คำ หลังจากใช้เทคนิคเอ็นแกรมโมเดลช่วยในการตัดคำอักษรเบรลล์ภาษาไทยแล้ว
- 6) ทดสอบเปรียบเทียบประสิทธิภาพระหว่างโปรแกรมแปลงเบรลล์เป็นแอลทีภาษาไทยแบบ File-to-file เดิม กับ โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ ในด้านความถูกต้องของการแปลง, ด้านปริมาณการใช้หน่วยความจำและด้านเวลาที่ใช้ในการแปลง
- 7) ทดสอบเปรียบเทียบหาจำนวนแกรมที่เหมาะสมของโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ เมื่อใช้จำนวนแกรมเท่ากับ 3-แกรม, 4-แกรม และ 5-แกรม
- 8) ตรวจสอบรายละเอียดความถูกต้องของโปรแกรมที่ได้พัฒนา
- 9) รวบรวมผลการทดสอบ สรุปผล จัดทำวิทยานิพนธ์ฉบับสมบูรณ์

#### 1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ช่วยแก้ไขปัญหาในการแปลงอักษรเบรลล์ภาษาไทยที่เกี่ยวข้องกับการแปลงคำควบล้ำ, การแปลงคำที่มีการใช้สระประสม, การแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์และการแปลงคำที่มีการใช้คำทับศัพท์
- 2) ช่วยแก้ไขปัญหาการหาขอบเขตคำของอักษรเบรลล์ภาษาไทยระดับ 1

ในบทที่ 2 จะกล่าวถึงทฤษฎีและหลักการที่เกี่ยวข้อง ในบทที่ 3 จะกล่าวถึงการออกแบบและพัฒนาระบบ ในบทที่ 4 จะกล่าวถึงผลการทดลอง และในบทที่ 5 จะกล่าวถึงสรุปผลการวิจัยและข้อเสนอแนะ


## บทที่ 2

### ทฤษฎีและหลักการที่เกี่ยวข้อง

ในบทนี้จะนำเสนอทฤษฎีและหลักการที่เกี่ยวข้อง ซึ่งประกอบด้วย อักษรเบรลล์, โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file, เทคนิคการตัดคำ, คลังข้อมูลภาษา, เอ็นแกรม โมเดล, Smoothing Technique, CMU-SLM Toolkit และโปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ (Thai2brl)

#### 2.1 อักษรเบรลล์

หลุยส์ เบรลล์ (Louis Braille) ครูตาบอดชาวฝรั่งเศส ได้ประดิษฐ์อักษรสำหรับคนตาบอด ขึ้นในปี ค.ศ.1834 [29] โดยประกอบด้วยจุดขนาด 6 จุด ใน 1 ช่อง โดยแบ่งเป็น 2 แถวในแนวตั้ง แถวละ 3 จุด ซึ่งสามารถจัดกลุ่มของจุดได้ถึง 63 รูปแบบ และได้แพร่หลายไปทั่วโลก จนมีผู้ดัดแปลงนำไปใช้ในกลุ่มประเทศที่ใช้อักษรโรมันเป็นหลักทั่วยุโรป จากนั้นในปี ค.ศ.1932 ประเทศอังกฤษ และสหรัฐอเมริกา ได้ร่วมมือกันจัดทำมาตรฐานอักษรเบรลล์ภาษาอังกฤษ (English Braille Standard) ขึ้นในปี ค.ศ.1932 ต่อมามีการพัฒนาให้เป็น 8 จุด [35] เพื่อให้สอดคล้องกับรหัสอักษรในระบบคอมพิวเตอร์ โดยเพิ่มจุดสองจุดลงไปในแต่ละคอลัมน์ของอักษรเบรลล์เดิม ดังรูปที่ 2.1



รูปที่ 2.1 การเรียงจุดในอักษรเบรลล์

อักษรเบรลล์ภาษาอังกฤษ ถือว่าเป็นอักษรเบรลล์สากลที่ใช้กันทั่วโลก และแต่ละประเทศนำมาดัดแปลง ปรับปรุงแก้ไข เพื่อนำไปใช้ในประเทศของตนเองเพื่อใช้สื่อสารระหว่างคนตาบอดด้วยกันรวมทั้งประเทศไทยด้วย โดยนอกเหนือจากการเขียนเป็นอักษรแทนพยัญชนะหรือสระในภาษาต่างๆ แล้ว ยังสามารถเขียนแทนสัญลักษณ์ต่างๆ เช่น คณิตศาสตร์, วิทยาศาสตร์, ดนตรี และเครื่องหมายต่างๆ ได้อีกด้วย โดยเรียกการอ่าน-เขียนอักษรเบรลล์แบบปกติว่า “อักษรเบรลล์

ระดับ 1” และเรียกการอ่าน-เขียนอักษรเบรลล์แบบย่อคำว่า “อักษรเบรลล์ระดับ 2” ซึ่งทั้งอักษรเบรลล์ภาษาอังกฤษและอักษรเบรลล์ภาษาไทยก็มีการอ่าน-เขียนในแบบระดับ 2 ด้วย

### 2.1.1 อักษรเบรลล์ภาษาไทย

นางสาวเจนวีฟ คอลฟิลด์ (Miss Gevevive Caulfield) สุภาพสตรีตาบอดชาวอเมริกัน เป็นคนแรกที่นำความรู้เกี่ยวกับอักษรเบรลล์มาเผยแพร่ในประเทศไทย [29] พร้อมกับจัดตั้งโรงเรียนสอนคนตาบอดกรุงเทพขึ้นเมื่อปี พ.ศ.2482 และได้ร่วมกับชาวไทยคนหนึ่งจัดตั้ง มูลนิธิช่วยคนตาบอดแห่งประเทศไทย และกำหนดอักษรเบรลล์ภาษาไทย โดยดัดแปลงมาจากอักษรเบรลล์อังกฤษมาตรฐาน ซึ่งผู้วิจัยได้แสดงรูปแบบอักษรเบรลล์ภาษาไทยไว้ในตารางที่ 11 ในภาคผนวก

อักษรเบรลล์ภาษาไทย ถูกกำหนดโดยการเทียบเสียงเทียบกับอักษรภาษาอังกฤษ เช่น ‘ก’ จะมีรูปแบบอักษรเบรลล์เหมือนอักษร ‘g’ ในภาษาอังกฤษ คือ จุด 1-2-4-5 (g) เป็นต้น และผู้พิการทางสายตาเรียกข้อมูลที่เกี่ยวข้องอยู่ในรูปอักษรรหัสแอสกีภาษาอังกฤษ ที่มีรูปแบบอักษรเบรลล์เหมือนกับข้อความภาษาไทยว่า ข้อมูล “Braille Computer Code”

เนื่องจากอักษรเบรลล์แบบ 6 จุด สามารถแสดงรูปแบบที่แตกต่างกันได้เพียง 63 รูปแบบ ซึ่งไม่เพียงพอที่จะใช้แทนอักษรภาษาไทยได้ทั้งหมด จึงได้มีการกำหนด อักษรเบรลล์แบบสองเซลล์ขึ้น โดยพยัญชนะภาษาไทยซึ่งมีทั้งสิ้น 44 ตัว เมื่อเทียบเสียงเหมือนกันแล้วจะมี 28 เสียง โดยกำหนดให้ พยัญชนะที่ใช้กันมากที่สุดเป็นพยัญชนะพื้นฐาน และกำหนดรูปอักษรเบรลล์เป็นแบบหนึ่งเซลล์ ส่วนพยัญชนะที่มีเสียงเหมือนกันกับพยัญชนะพื้นฐานให้ใช้ อักษรเบรลล์แบบ 2 เซลล์ โดยมีเซลล์หลังเหมือนกับพยัญชนะพื้นฐาน และมีเซลล์หน้าเป็น จุด 6 ( , ) หรือ จุด 3-6 ( - - ) หรือ จุด 3-5-6 ( 0 0 ) ซึ่งผู้วิจัยได้รวบรวมพยัญชนะภาษาไทยที่มีรูปอักษรเบรลล์แบบ 2 เซลล์แสดงไว้ในตารางที่ 2.1

ตารางที่ 2.1 พยัญชนะภาษาไทยที่มีรูปอักษรเบรลล์แบบ 2 เซลล์

เซลล์หน้า	ตัวอักษร
, ( , )	ศ( , s), ข( , u), ฉ( , +), พ( , l), ณ( , n), ฅ( , ), ฉุ( , y), ฉุ( , d), ฉุ( ,  ), ฐ( , t), ก( , ?)
- ( - )	ษ( - s), ค( - u), ฅ( - )
อ ( 0 )	ห( 0 ), ข( 0k)

สระในภาษาไทยกำหนดรูปอักษรเบรลล์ตามเสียงสระ 32 เสียง โดยมีการใช้งานรหัสอักษรสระประสมซึ่งไม่มีในอักษรรหัสแอสกีด้วย โดยผู้วิจัยได้แสดงรูปสระประสมของอักษรเบรลล์ทั้งหมดไว้ในตารางที่ 2.2 ซึ่งจะเห็นได้ว่าการใช้งานสระประสมแบบ 2 เซลล์ด้วย โดยมีการกำหนดอักษรเบรลล์ให้กับสระพื้นฐานทุกตัว และกำหนดให้ใช้อักษรเบรลล์สองเซลล์แทนสระเสียงสั้นที่มีรูปสระเสียงยาว เช่น สระอะ, สระแอะ โดยใช้สระอะต่อท้ายรูปสระเสียงยาว เช่น สระอะ (f a fa) จะเขียนอยู่ในรูปสระอะ (f f) และสระอะ (a a) ต่อกันเป็นต้น

นอกจากพยัญชนะที่มีรูปอักษรเบรลล์แบบ 2 เซลล์แล้ว ยังมีการใช้สระและเครื่องหมายที่ใช้รูปอักษรเบรลล์ 2 เซลล์ด้วย โดยผู้วิจัยได้แสดงเครื่องหมายที่มีรูปอักษรเบรลล์แบบ 2 เซลล์ไว้ในตารางที่ 2.3

ตารางที่ 2.2 รูปอักษรเบรลล์ของสระประสม

สระ	รูปอักษรเบรลล์	Braille Computer Code
อัว	e	e
อัวะ	ea	ea
เอา	6	6
เอีย	(	(
เอือ	q	q
เออ	%	%
อะ	fa	fa (เ-ะ)
แอะ	<a	<a (แ-ะ)
โอะ	ia	ia (โ-ะ)
เอียะ	(a	(a (เอีย-ะ)
เอือะ	qa	qa (เอือ-ะ)
เออะ	%a	%a (เออ-ะ)
เอาะ	oa	oa (อ-ะ)



ตารางที่ 2.3 สระและเครื่องหมายที่มีรูปอักษรเบรลล์แบบ 2 เซลล์

แอสกี	รูปอักษรเบรลล์	Braille Computer Code
ใ	:1	:1 (ใ๓)
ฤ	r1	r1 (ร๓)
ฤา	r1*	r1* (ร๓า)
ล	l1	l1 (ล๓)
ลา	l1*	l1* (ล๓า)
๓	;2	;2
๓ล๓	;1	;1

### 2.1.2 หลักการอ่านเขียนอักษรเบรลล์ภาษาไทยระดับ 1

หลักการอ่าน-เขียนอักษรเบรลล์ภาษาไทยระดับ 1 [33] [34] สามารถสรุปกฎเป็นข้อๆ ได้ดังนี้

ข้อ 1: คำที่ไม่ประกอบด้วยสระประสม วางรูปคำเหมือนกับการเขียนปกติตามหลักภาษาศาสตร์

พยัญชนะต้น+สระ+วรรณยุกต์+ตัวสะกด

เช่น ลีน ➔ ล+อิ+อ+น lb4n lb4n

ข้อ 2: สระต่อไปนี้จะเขียนหลังพยัญชนะเสมอ ได้แก่ อะ, อา, อิ, อี, อือ, อือ, อุ, อู, เอะ, แอะ, โอะ, เอาะ, ออ, อัวะ, อัว, เอียะ, เอีย, เอือะ, เอือ, เอือะ, เออ, อ้า, เอา และเมื่อคำที่ใช้สระเหล่านี้มีรูปวรรณยุกต์ประสมอยู่ด้วยจะต้องเขียนหลังสระ ยกเว้น สระอา กับ สระ ออ ให้เขียนรูปวรรณยุกต์ก่อนสระ

พยัญชนะต้น+สระ+วรรณยุกต์+ตัวสะกด

เช่น เรียน ➔ ร+เอีย+น r(n r(n

ข้อ 3: คำที่เขียนเหมือนกันในรูป สระเอ + สระอา ที่ออกเสียง ได้ทั้งสระอาและสระเอาให้ใช้เป็นสระเอา

พยัญชนะ + สระเอา + วรรณยุกต์

เช่น เผลา ➔ พ+ล+เอา ?l6 ?l6

ข้อ 4: คำที่มีสระ เอ แอ โอ ไอ ในอักษรเบรลล์ให้เขียนเรียงตามปกติเช่นเดียวกับการเขียนภาษาไทย

สระ + พยัญชนะ + ตัวสะกด + วรรณยุกต์

เช่น ไหล่ → ใ + ห + ล + ่ :hl4 :hl4

จากหลักการอ่าน-เขียนอักษรเบรลล์ภาษาไทยระดับ 1 จะเห็นได้ว่าอักษรเบรลล์ และอักษรในรหัสแอสกี ไม่สามารถที่จะเทียบกันได้แบบตัวต่อตัว โดยกรณีที่ไม่สามารถเทียบข้อมูลได้แบบตัวต่อตัวได้แก่

- การใช้อักษรเบรลล์ 2 เซลล์แทนอักษรในรหัสแอสกี 1 ตัว โดยมีการใช้งานอักษรเบรลล์แบบ 2 เซลล์ทั้งพยัญชนะ สระ และเครื่องหมายในภาษาไทย
- การใช้งานอักษรเบรลล์ 1 เซลล์เพื่อแทนอักษรในรหัสแอสกีหลายตัวในการใช้งานสระประสม
- การอ่าน-เขียนคำที่ใช้ สระอะ หรือสระอำ ร่วมกับวรรณยุกต์ มีการเรียงอักษรรหัสแอสกี และอักษรเบรลล์แตกต่างกัน โดยอักษรเบรลล์จะเขียนเป็น พยัญชนะต้น + สระ + วรรณยุกต์ แต่ ในรหัสแอสกี จะเขียนเป็น พยัญชนะต้น + วรรณยุกต์ + สระ เช่น “จ๊ะ” (จ-อ-ะ) เขียนอักษรเบรลล์เป็น “j a 7” (จ-ะ-อ) “คำ” (ค-อ-อำ) เขียนอักษรเบรลล์เป็น “n 4 z” (ค-อำ-อ)
- อักษรเบรลล์มีการใช้สระประสม แต่ไม่มีในอักษรรหัสแอสกี ทำให้มีการเรียงอักษรแตกต่างกัน และเนื่องจากการเขียนข้อความภาษาไทยไม่มีการเว้นวรรคระหว่างคำ จึงทำให้มีความกำกวมเกิดขึ้นว่า คำๆ นั้นจะเป็นคำที่ใช้สระประสมหรือคำหลายคำต่อกันดังนี้
  - คำที่ใช้สระเออและสระเออะที่มีพยัญชนะต้น 1 ตัว เช่นคำว่า “เลอะ” เมื่อเขียนเป็นอักษรเบรลล์จะเขียนเป็นสระประสมได้เป็น “l % a” (“ล-เออะ”) แต่คำว่า “ทะเลอะไร” (“ทะเล”-“อะไร”) ซึ่งพ้องรูปกับคำว่า “ทะเลอะไร” เมื่อเขียนเป็นอักษรเบรลล์จะเขียนเป็น “) a f l o a : r” (“ท-ะ-ล-เออะ-ไร”) ไม่ใช่ “) a l % a : r” (“ท-ะ-ล-เออะ-ไร”)
  - คำที่ใช้พยัญชนะต้น 2 ตัว เช่นคำว่า “เจริญ” เขียนแบบอักษรเบรลล์เป็น “j r % , y” (“จ-ร-เออ-ญ”) ไม่ใช่ “f j r b , y” (“จ-ร-อ-ญ”) คำว่า “เกอช่า” เขียนแบบอักษรเบรลล์เป็น “f g o b + \*” (“ก-อ-อ-ช-า”) ไม่ใช่ “g o % + a” (“ก-อ-เออ-ช-า”) และไม่ใช่ “g % b + \*” (“ก-เออ-อ-ช-า”) คำว่า

“เหมือ” เขียนแบบอักษรเบรลล์เป็น “f )m5o” (“-ท-ม-อ-อ”) ไม่ใช่ “) m๕” (“-ท-ม-เอือ”) เป็นต้น

การเขียนอักษรเบรลล์จะใช้งานสระประสม ซึ่งต่างจากการเขียนในภาษาไทยปกติ และเป็นปัญหาสำคัญในการแปลงข้อมูลระหว่างไทยและเบรลล์ โดยในปัจจุบันมีการใช้งานอักษรเบรลล์ภาษาไทย โดยใช้การอ่าน-เขียนอักษรเบรลล์แบบระดับ 1 แต่ไม่ใช่สระประสมและผู้พิการทางสายตาเรียกการอ่าน-เขียนเช่นนี้อย่างไม่เป็นทางการว่า “อักษรเบรลล์ภาษาไทยระดับ 0”

นอกเหนือจากอักษรเบรลล์แบบ 6 จุด แล้ว ยังได้มีการกำหนดรูปแบบของอักษรเบรลล์ภาษาไทยแบบ 8 จุดขึ้น [35] เพื่อให้ให้สอดคล้องกับระบบคอมพิวเตอร์ทั่วไปด้วย โดยกำหนดให้สามารถเทียบอักษรภาษาไทยแบบปกติและอักษรเบรลล์แบบ 8 จุดได้แบบตัวต่อตัว โดยผู้วิจัยได้แสดงรูปแบบอักษรเบรลล์ภาษาไทยทั้งแบบ 6 จุด และ 8 จุดไว้ในตารางที่ 11-12 ในภาคผนวก ง

## 2.2 โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file ของมหาวิทยาลัยสงขลานครินทร์

โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file [1] ได้นำเสนอไว้ในงานวิจัยเรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” ของมหาวิทยาลัยสงขลานครินทร์ ซึ่งโปรแกรมดังกล่าวทำหน้าที่แปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยในรูปแบบ File-to-file โดยกระบวนการทำงานของโปรแกรมนี้นี้ ได้ใช้วิธีการแปลงแบบใช้กฎไวยากรณ์ทางภาษาของอักษรเบรลล์ภาษาไทยมาควบคุมการแปลง ซึ่งสามารถให้ผลลัพธ์ในการแปลงที่ถูกต้องในระดับหนึ่ง

จากการศึกษางานวิจัยนี้พบว่ายังคงมีปัญหาในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยอยู่ด้วยกัน 2 ประการคือ 1) ปัญหาการแปลงคำควบกล้ำและสระประสม ซึ่งปัญหานี้เกิดจากการต่อคำทำให้เกิดความกำกวมของคำขึ้น เช่น คำว่า “เครือ” เขียนอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 เป็น “urq” ซึ่งก็คือ “ค+ร+เอือ” แต่เนื่องจากคำว่า “rq” หรือ “ร+เอือ” เป็นคำที่มีความหมายว่า “เรือ” ก็เป็นคำที่มีความหมายในภาษาไทยเช่นกัน และอักษรเบรลล์ ‘u’ ซึ่งก็คืออักษร “ค” ในภาษาไทยของว่า “เครือ” อาจจะเป็นตัวควบกล้ำของคำปัจจุบันหรือเป็นตัวสะกดของคำก่อนหน้าก็ได้

และ 2) ปัญหาการแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์ ซึ่งปัญหานี้เกิดจากมีอักษรเบรลล์สองเซลล์บางตัวที่มีรูปพ้องกันกับการเขียนอักษรเบรลล์เซลล์เดียวสองตัวเขียนติดกัน ซึ่งปัญหานี้โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม ยังคงมีการแปลงที่ผิดพลาดอยู่เนื่องจาก การแปลงแบบ File-to-file นั้น โปรแกรมเดิมจะไม่สามารถทราบได้ว่าตรงไหนเป็นอักษรเบรลล์สองเซลล์หนึ่งตัวหรือเป็นอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน ซึ่ง

จะแตกต่างกับกรณีของโปรแกรมการแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด [1] ที่สามารถแก้ไขปัญหาเหล่านี้ได้โดยใช้วิธีให้ผู้ใช้กดคีย์พิเศษก่อนจะป้อนอักษรเบรลล์สองเซลล์และการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบ File-to-file นั้นผู้ใช้จะไม่สามารถโต้ตอบกับโปรแกรมเพื่อระบุว่าตรงไหนเป็นอักษรเบรลล์สองเซลล์ได้ ยกตัวอย่างเช่นคำว่า “พระองค์ทรง” เขียนในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 คือ “{rao}u0r}” ซึ่งก็คือ “พ+ร+ะ+อ+ง+ค+การันต์+ท+ร+ง” โดยอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกันแล้วมีรูปป้องกันกับอักษรเบรลล์สองเซลล์ในที่นี้คือ ‘0+’ ซึ่งก็คืออักษร ‘การันต์+ท’ โดยมีรูปป้องกันกับอักษรเบรลล์สองเซลล์คืออักษร ‘0’ ซึ่งก็คืออักษร ‘ธ’ เมื่อโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมทำการแปลงจะได้เป็นคำว่า “พระองค์ทรง” เพราะโปรแกรมเดิมจะไม่ทราบว่าเป็นอักษรเบรลล์สองเซลล์หนึ่งตัวหรืออักษรเบรลล์เซลล์เดียวสองตัว ดังสาเหตุที่ได้กล่าวไว้ในข้างต้น

ดังนั้นงานวิจัยนี้จึงได้มุ่งเน้นแก้ไขปัญหาดังสองประการที่ได้กล่าวไว้ในข้างต้นโดยใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการแบ่งคำ เพื่อช่วยให้โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยทราบขอบเขตของคำแต่ละคำอย่างชัดเจน ทำให้ไม่มีความกำกวมที่เกิดขึ้นจากการต่อคำและความกำกวมที่เกิดจากการไม่ทราบว่าเป็นอักษรเบรลล์สองเซลล์หนึ่งตัวหรือเป็นอักษรเบรลล์เซลล์เดียวสองตัว

### 2.3 เทคนิคการตัดคำ

เทคนิคการตัดคำ [6] ได้ถูกนำมาใช้ในงานด้านประมวลผลภาษาธรรมชาติ [7] เพื่อให้คอมพิวเตอร์สามารถเข้าใจความหมายของคำในภาษานั้นๆ ได้และเนื่องจากภาษาบางภาษา เช่น ภาษาไทย, ภาษาจีน, ภาษาญี่ปุ่น ภาษาลาว เป็นต้น มีลักษณะการเขียนประโยคที่ประกอบไปด้วยคำย่อยๆ หลายคำเรียงติดกัน โดยไม่มีการเว้นช่องว่างระหว่างคำเหมือนกับภาษาอังกฤษทำให้เกิดปัญหา “การหาขอบเขตของคำ” เมื่อต้องการนำข้อมูลเหล่านั้น ไปประมวลผลด้วยคอมพิวเตอร์ ซึ่งคอมพิวเตอร์ไม่สามารถทราบได้ว่าในประโยคนั้นๆ ประกอบด้วยคำกี่คำ และแต่ละคำประกอบด้วยตัวอักษรอะไรบ้าง จึงจำเป็นต้องตัดคำเสียก่อน ก่อนที่จะนำไปประมวลผลต่อ เพื่อแบ่งขอบเขตของคำแต่ละคำอย่างชัดเจน

อักษรเบรลล์ภาษาไทยมีลักษณะการเขียนเช่นเดียวกับภาษาไทยคือ เขียนคำแต่ละคำติดๆ กันเป็นประโยค และเว้นวรรคระหว่างประโยค แต่จะเรียงตัวอักษรนำ ตัวอักษรตาม สระ ตัวสะกด และวรรณยุกต์ที่แตกต่างไปจากภาษาไทย จากความคล้ายคลึงดังกล่าวทำให้ผู้วิจัยมีแนวความคิดว่าหากใช้เทคนิคการตัดคำเข้ามาช่วยแบ่งคำอักษรเบรลล์ภาษาไทย เพื่อให้ทราบขอบเขตของคำที่ชัดเจนแล้ว จะทำให้ไม่เกิดความกำกวมขึ้นอีกต่อไปและทำให้การแปลงอักษร

เบรลล์ภาษาไทยเป็นภาษาไทยทำได้ง่ายขึ้นและถูกต้องมากยิ่งขึ้นอีกด้วย นอกจากนี้ยังไม่มียานวิจัยใดๆ เลยที่นำวิธีการตัดคำมาใช้กับอักษรเบรลล์ภาษาไทย ซึ่งในปัจจุบันมีเพียงงานวิจัยที่เกี่ยวข้องกับการตัดคำภาษาไทยเท่านั้น และจากการศึกษาพบว่าเทคนิคการตัดคำนั้นมีด้วยกันหลายเทคนิค [8][9][10][11] ซึ่งสามารถแบ่งเป็นประเภทต่างๆ ได้ดังนี้ 1) เทคนิคการตัดคำโดยใช้กฎพื้นฐาน 2) เทคนิคการตัดคำโดยใช้พจนานุกรม 3) เทคนิคการตัดคำโดยวิธีเทียบคำที่ยาวที่สุด 4) เทคนิคการตัดคำโดยวิธีตัดคำให้ได้จำนวนคำและคำที่ไม่พบในพจนานุกรมน้อยที่สุด 5) เทคนิคการตัดคำโดยใช้คลังข้อมูล ซึ่งรายละเอียดของแต่ละเทคนิคมีดังต่อไปนี้

### 2.3.1 เทคนิคการตัดคำโดยใช้กฎพื้นฐาน

เทคนิคการตัดคำโดยใช้กฎพื้นฐาน [8] เป็นการตัดคำโดยอาศัยกฎที่ได้ตั้งเอาไว้มาใช้เป็นเกณฑ์ในการแบ่งขอบเขตของคำ โดยกฎที่นำมาใช้นั้นได้นำมาจากหลักไวยากรณ์ภาษาไทย ซึ่งลักษณะของกฎสามารถแบ่งได้เป็น 2 ชนิดคือ กฎการหาขอบเขตหน้า (Front boundary recognition rule) และกฎการหาขอบเขตหลัง (Tail boundary recognition rule) และในแต่ละกฎยังแบ่งออกเป็น 2 กลุ่มย่อยๆ คือ แบ่งตามคุณสมบัติของตัวอักษรโดยกฎที่ได้นี้จะจัดอยู่ในกลุ่มเอ (Group A) และแบ่งตามคุณสมบัติของรูปแบบการใช้สระแต่ละตัว ซึ่งกฎที่ได้นี้จะแบ่งให้อยู่ในกลุ่มบี (Group B) ตัวอย่างกฎกลุ่มเอ เช่น

ตัวอย่างกฎที่ได้จากคุณสมบัติของอักษรในการหาขอบเขตหน้าของพยางค์ เช่น

- กฎ A – 1F : สระต่างๆ เหล่านี้ ะ ิ ี ึ ื ุ ู ็ ๋ ุ ั และวรรณยุกต์ ่ ็ ๊ ั จะต้องมีพยัญชนะอยู่ข้างหน้าอย่างน้อย 1 ตัวอักษรเสมอ
- กฎ A – 2F : สระ เ แ โ โ ส่วนใหญ่จะเป็นตัวอักษรแรกในพยางค์เสมอ ยกเว้นคำบางคำ ตัวอย่างเช่น ขโมย, ทแยง, จเร, สไบ เป็นต้น
- กฎ A – 3F : สระ ใ จะเป็นตัวอักษรแรกของพยางค์เสมอ โดยไม่มีข้อยกเว้น

ตัวอย่างกฎที่ได้จากคุณสมบัติของอักษรในการหาขอบเขตหลังของพยางค์ เช่น

- กฎ A – 1T : พยัญชนะต่อไปนี้ ศ ฌ ญ ฐ ฎ ฏ ฒ พ ฌ จะเป็นตัวสะกดเสมอ ยกเว้นพยางค์ดังต่อไปนี้ ศก ศร ศพ ฐก พศ ญวน ฌรงค์ ศตวรรษ และพยางค์อื่นๆ แต่พยางค์เหล่านั้นสามารถจัดการได้โดยใช้กฎ A – 1F
- กฎ A – 2T : สระ ี จะต้องมีสะกดหนึ่งตัวเสมอ ยกเว้น พยางค์เหล่านี้ “ ี ี ี ”
- กฎ A – 3T : ไม้หันอากาศ ( ั ) จะต้องตามด้วยตัวสะกดอย่างน้อย 1 ตัวอักษรเสมอ



### 2.3.2.1 เทคนิคการตัดคำโดยวิธีเทียบคำที่ยาวที่สุด (Longest Matching)

เทคนิคการตัดคำโดยวิธีเทียบคำที่ยาวที่สุด [9] เป็นการตัดพยางค์ที่นำพจนานุกรมเข้ามาใช้ โดยจะจัดเก็บพยางค์ต่างๆ ไว้ในพจนานุกรม และนำกฎไวยากรณ์ต่างๆ จำนวน 18 กฎเข้ามาช่วยในกรณีที่ไม่พบพยางค์ในพจนานุกรม

หลักการทำงานของวิธีตัดพยางค์ด้วยพจนานุกรมนี้อีกคือ ตรวจสอบสายอักขระ (String) ที่เข้ามาจากซ้ายไปขวากับพยางค์ที่ได้เก็บไว้ในพจนานุกรม ในกรณีที่ตรวจสอบแล้วปรากฏว่าพบพยางค์มากกว่า 1 พยางค์ในพจนานุกรม ให้ทำการเลือกแบ่งพยางค์โดยเลือกพยางค์ที่ยาวที่สุด แล้วทำต่อไปเรื่อยๆ จนจบสายอักขระ แต่ในกรณีที่เลือกพยางค์ที่ยาวที่สุดแล้ว ทำให้เกิดพยางค์ที่ไม่ปรากฏในพจนานุกรมให้ใช้วิธีการย้อนรอย (Back Tracking) กลับไปเลือกพยางค์ที่ยาวรองลงมาแทน

จากการเปรียบเทียบความรวดเร็วในการแบ่งพยางค์กับเทคนิคการแบ่งพยางค์แบบใช้กฎพื้นฐาน ซึ่งสรุปผลได้ว่าเมื่อนำพจนานุกรมเข้ามาใช้ในการแบ่งพยางค์จะสามารถตัดพยางค์ได้รวดเร็วกว่าการใช้กฎ โดยที่ความถูกต้องของการตัดพยางค์นั้นสามารถตัดได้ถูกต้องมากกว่า 99% [9] แต่วิธีการนี้ก็ยังมีข้อเสียคือ ต้องใช้เนื้อที่หน่วยความจำเป็นจำนวนมากในการจัดเก็บรายการคำในพจนานุกรม และความถูกต้องของการแบ่งพยางค์จะขึ้นอยู่กับจำนวนคำที่มีอยู่ในพจนานุกรมและความรวดเร็วในการค้นหารายการคำในพจนานุกรมที่เก็บไว้ในหน่วยความจำ

### 2.3.2.2 เทคนิคการตัดคำโดยวิธีตัดคำให้ได้จำนวนคำและคำที่ไม่พบในพจนานุกรมน้อยที่สุด (Maximal Matching)

เทคนิคการตัดคำโดยวิธีตัดคำให้ได้จำนวนคำและคำที่ไม่พบในพจนานุกรมน้อยที่สุด [10] เป็นเทคนิคที่ลดข้อด้อยของวิธีการตัดคำโดยใช้พจนานุกรม ซึ่งจากการศึกษาวิจัยพบว่าหากประโยคหรือข้อความมีคำที่ไม่อยู่ในพจนานุกรมแล้ว จะทำให้ความถูกต้องในการตัดคำลดลงโดยมาก ซึ่งสาเหตุนี้มาจากการตัดคำโดยอาศัยพจนานุกรมนี้อีกความถูกต้องจะขึ้นอยู่กับจำนวนคำที่มีอยู่ในพจนานุกรม ดังนั้นเทคนิคการตัดคำโดยวิธีตัดคำให้ได้จำนวนคำและคำที่ไม่พบในพจนานุกรมน้อยที่สุดจึงเป็นวิธีแก้ไขข้อด้อยเมื่อไม่มีคำนั้นๆ อยู่ในพจนานุกรม ซึ่งวิธีการตัดคำแบบนี้เป็นการหารูปแบบในการตัดคำทั้งหมดที่สามารถจะเป็นไปได้ เช่น เมื่อมีข้อความว่า "ไปห้ามเหลื" เมื่อใช้วิธีการนี้จะสามารถสร้างรูปแบบในการตัดคำได้ 2 แบบ คือ

1. ไป|ห้าม|เหลื
2. ไป|ห้าม|เหลื

จากนั้นวิธีการนี้จะเลือกข้อความที่แบ่งแล้วมีจำนวนค่าน้อยที่สุดคือ แบบที่ 2 ซึ่งมีจำนวนคำที่ตัดได้ 3 คำ ในขณะที่แบบที่ 1 มี 4 คำ แต่ในกรณีนี้ที่แบ่งคำออกมาแล้วมีจำนวนคำที่เท่ากัน จะใช้เทคนิคการตัดคำแบบยาวที่สุด (Longest Matching) เข้ามาช่วยตัดคำ เช่น ข้อความว่า "ฉันนั่งตากลมที่หน้าบ้าน" เมื่อใช้วิธีการนี้จะสามารถสร้างรูปแบบในการตัดคำได้ 2 แบบ คือ

1. ฉัน|นั่ง|ตาก|ลม|ที่|หน้า|บ้าน
2. ฉัน|นั่ง|ตาก|ลม|ที่หน้า|บ้าน

แต่ทั้ง 2 แบบนี้มีจำนวนคำที่เท่ากัน ในกรณีนี้จึงควรใช้วิธีการตัดคำแบบยาวที่สุด (Longest Matching) เข้ามาช่วยจะทำให้ผลลัพธ์ในการตัดคำประโยคดังกล่าวเป็นแบบที่ 1 เพราะเมื่อเปรียบเทียบจากคำที่ตัดได้ต่างกันนั้น (ตา / ตาก) จะเห็นได้ว่า “ตาก” มีตัวอักษรมากกว่าจึงเลือกแบบที่ 1

### 2.3.3 เทคนิคการตัดคำโดยใช้คลังข้อมูล

เทคนิคการตัดคำโดยใช้คลังข้อมูล [11] เป็นเทคนิคที่นำเอาวิธีการทางสถิติเข้ามาช่วยในการแก้ไขปัญหาความกำกวม โดยใช้ค่าสถิติที่เกิดขึ้นจากลำดับของหน้าที่ของคำแต่ละคำหรือประเภทย่อยของคำแต่ละคำ หรืออาจกล่าวได้ว่าเป็นการนำเอาไวยากรณ์มาใช้งานร่วมกับสถิติเพื่อแก้ปัญหาความกำกวม โดยงานวิจัยนี้ใช้แบบจำลองไตรแกรมและนำเอาค่าสถิติซึ่งพิจารณาจากความต่อเนื่องของหน้าที่ของคำหรือประเภทย่อยของคำ และเลือกเอาประโยคที่มีความน่าจะเป็นสูงที่สุดโดยการหาความน่าจะเป็นของแต่ละประโยคสามารถคำนวณตามสมการที่ 1

$$P(W_i) = \sum_T P(W_i, T_i) \\ = \sum_T \prod_i P(t_i | t_{i-1}, t_{i-2}) \times P(w_i | t_i) \dots \dots \dots (1)$$

จากสมการที่ 1 จะเป็นสูตรสำหรับการคำนวณหาความน่าจะเป็นของแต่ละประโยคที่ตัดได้ โดยใช้วิธีตัดคำให้ได้จำนวนคำและคำที่ไม่พบในพจนานุกรมน้อยที่สุด (Maximal Matching) จากนั้นนำแต่ละรูปแบบของประโยคที่ตัดได้มาคำนวณหาความน่าจะเป็น โดยพิจารณาจากผลรวมความน่าจะเป็นของหน้าที่ของคำ ( $T_i$ ) หรือประเภทย่อยของคำ ( $W_i$ ) ทุกแบบที่เป็นไปได้ของแต่ละประโยค และมีข้อกำหนดว่าความน่าจะเป็นของการเกิดหน้าที่คำหรือประเภทย่อยของคำที่ตำแหน่งปัจจุบันจะขึ้นอยู่กับหน้าที่ของคำ หรือประเภทย่อยของคำสองคำก่อนหน้านั้น ทำให้วิธีการนี้เหมาะสำหรับงานที่ต้องการทราบขอบเขตคำเพียงอย่างเดียวเท่านั้น ซึ่งวิธีนี้สามารถแก้ไขปัญหาความกำกวมได้ดี เนื่องจากมีการพิจารณาถึงหน้าที่ของคำหรือประเภทย่อยของคำเข้ามาประกอบด้วย



อย่างไรก็ตามในกรณีที่ข้อความมีความกำกวมโดยมีหน้าที่ของคำหรือประเภทย่อยของคำเหมือนกัน วิธีการนี้จะไม่สามารถตัดคำได้คั่นและข้อจำกัดอีกประการหนึ่งคือจะต้องเก็บค่าสถิติจากคลังข้อความ โดยที่คลังข้อความที่ดีควรจะนำมาจากเอกสารหลายๆ ประเภท และจะต้องมีขนาดใหญ่พอสมควร

ดังนั้นประสิทธิภาพในการตัดคำแบบนี้จะขึ้นอยู่กับคลังข้อความด้วย ความถูกต้องสูงสุดสำหรับวิธีการนี้คือ 85% และวิธีนี้ยังคงเป็นวิธีการที่นิยมใช้มากที่สุด เนื่องจากความแม่นยำสูงและใช้อัลกอริทึมในการพัฒนาโปรแกรมทำได้ง่ายที่สุด

จากวิธีการตัดคำโดยใช้เทคนิคต่างๆ ที่ได้ศึกษามาพบว่าวิธีการตัดคำโดยใช้คลังข้อมูลสามารถตัดคำได้ถูกต้องมากที่สุดและมีข้อด้อยน้อยที่สุด ดังนั้นในงานวิทยานิพนธ์นี้จึงได้เลือกใช้วิธีการตัดคำโดยใช้คลังข้อมูล ซึ่งจะอยู่ในรูปแบบการตัดคำของอักษรเบรลล์ภาษาไทยระดับ 1

## 2.4 คลังข้อมูลภาษา

คลังข้อมูลภาษา [12] คือ ข้อมูลภาษาเขียนหรือภาษาพูดที่เป็นภาษาที่ใช้จริง ซึ่งถูกรวบรวมขึ้นมาในปริมาณที่มากเพียงพอตามเงื่อนไขที่กำหนดเพื่อให้ได้คลังข้อมูลที่เป็นตัวแทนของภาษาที่ต้องการ คลังข้อมูลภาษาจะถูกนำไปใช้งานในด้านภาษาศาสตร์ การสร้างแบบจำลองภาษา รวมถึงการประมวลผลภาษาธรรมชาติอีกด้วย เช่น นำไปใช้ในการสร้างพจนานุกรม นำข้อมูลด้านสถิติของคำไปสร้างเป็นแบบจำลองเพื่อนำมาใช้ในงานประมวลผลภาษาธรรมชาติด้วยคอมพิวเตอร์

จากการศึกษาพบว่าคลังข้อมูลภาษาสามารถแบ่งได้เป็น 2 ประเภทหลักๆ ด้วยกันคือคลังคำ และคลังข้อความ โดยงานวิจัยในวิทยานิพนธ์นี้จะนำเอาคลังข้อความอักษรเบรลล์ภาษาไทยมาใช้ในการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยเพื่อให้เอ็นแกรมโมเดลคำนวณค่าความน่าจะเป็นของคำที่เกิดขึ้นร่วมกันตามหลักการสร้างไฟล์โมเดลภาษา (การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยจะอธิบายในหัวข้อที่ 3.3.2) แต่ในปัจจุบันยังไม่มีการสร้างคลังข้อความอักษรเบรลล์ภาษาไทย มีเพียงแต่คลังข้อความภาษาไทยเท่านั้น

ดังนั้นในงานวิทยานิพนธ์นี้จึงได้นำเอาคลังข้อความภาษาไทยมาประยุกต์ในการสร้างโมเดลอักษรเบรลล์ภาษาไทย โดยได้เลือกคลังข้อความ BEST [13] ซึ่งเป็นคลังข้อความภาษาไทยนำมาแปลงให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 เสียก่อนจึงจะสามารถนำไปสร้างโมเดลอักษรเบรลล์ภาษาไทยได้

คลังข้อความ BEST เป็นคลังข้อความภาษาไทยที่มีการเก็บรวบรวมคำอย่างเป็นระบบและมีขนาดใหญ่ที่สุดในปัจจุบัน ซึ่งพัฒนาโดยหน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา (Human

Language Technology: HLT) ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (National Electronics and Computer Technology Center: NECTEC) ซึ่งมีรายละเอียดดังนี้

ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติสร้างคลังข้อความภาษาไทยแบบแบ่งคำ “BEST 2009” โดยนำงานเขียนที่มีลักษณะต่างๆ 3 ประเภทมารวบรวมไว้เพื่อให้เป็นตัวแทนของภาษาไทยที่ใช้กันโดยทั่วไปในปัจจุบัน ได้แก่ ข้อความจากหนังสือประเภทนวนิยายในฐานะเป็นตัวแทนของภาษาพูดทั่วไป ข้อความจากเว็บไซต์ [www.midnightuniv.org](http://www.midnightuniv.org) [14] และข้อความจากสารานุกรมสำหรับเยาวชนไทยในฐานะเป็นตัวแทนของภาษาเขียนอย่างเป็นทางการ และข้อความจากหนังสือพิมพ์บนอินเทอร์เน็ตในฐานะเป็นตัวแทนของภาษาข่าว ข้อความในเอกสารต่างๆ เหล่านี้ได้ถูกนำมาวิเคราะห์เพื่อกำหนดขอบเขตของคำ โดยอาศัยหลักการทางภาษาศาสตร์ โดยคำนึงถึงการประมวลผลด้วยคอมพิวเตอร์ร่วมด้วย ทั้งนี้ไม่มีการแก้ไขตัดแปลงเนื้อหาสาระของผลงานต้นฉบับแต่อย่างใด ซึ่งคลังข้อความ BEST มีรายละเอียดดังต่อไปนี้

○ ชื่อไฟล์ : ข้อมูลในคลังข้อความจะกำหนดขึ้นตามประเภทของภาษา ดังนี้

- ภาษาพูดทั่วไปจะเก็บอยู่ในไฟล์ชื่อ novel-000xx.txt
- ภาษาเขียนอย่างเป็นทางการจะเก็บอยู่ในไฟล์ชื่อ encyclopedia-000xx.txt และ miduniv-000xx.txt
- ภาษาข่าวจะเก็บอยู่ในไฟล์ชื่อ news-000xx.txt


○ ขนาด : คลังข้อความมีขนาดประมาณ 5,600,000 คำ โดยนับจากเครื่องหมายกำหนดขอบเขตของคำ “.” ซึ่งคำในที่นี้รวมถึงเครื่องหมายวรรคตอน นิพจน์ระบุนาม (Named-entity) และอักษรย่อด้วย ทั้งนี้จะแบ่งคลังข้อความเป็น 7 ชุด คือชุดฝึกฝน 6 ชุด ประมาณ 5,000,000 คำ และชุดทดสอบ 2 ชุด ประมาณ 600,000 คำ โดยแต่ละชุดมีจำนวนคำดังต่อไปนี้

- ชุดฝึกฝนที่ 1 ประมาณ 500,000 คำ (สร้างขึ้นในเดือน กรกฎาคม 2551)
- ชุดฝึกฝนที่ 2 ประมาณ 500,000 คำ (สร้างขึ้นในเดือน สิงหาคม 2551)
- ชุดฝึกฝนที่ 3 ประมาณ 1,000,000 คำ (สร้างขึ้นในเดือน กันยายน 2551)
- ชุดฝึกฝนที่ 4 ประมาณ 1,000,000 คำ (สร้างขึ้นในเดือน ตุลาคม 2551)
- ชุดฝึกฝนที่ 5 ประมาณ 1,000,000 คำ (สร้างขึ้นในเดือน พฤศจิกายน 2551)
- ชุดฝึกฝนที่ 6 ประมาณ 1,000,000 คำ (สร้างขึ้นในเดือน ธันวาคม 2551)

- ชุดทดสอบชุดที่ 1 ประมาณ 100,000 คำ (สร้างขึ้นในเดือน มกราคม 2552)
  - ชุดทดสอบชุดที่ 2 ประมาณ 500,000 คำ (สร้างขึ้นในเดือน กุมภาพันธ์ 2552)
- Metadata: ไฟล์ข้อมูลทั้งหมดเป็นข้อความล้วนที่ไม่มีการกำกับ metadata เพื่อความสะดวกในการใช้งาน
  - ย่อหน้าและประโยค: ข้อความในไฟล์แบ่งย่อยที่ระดับย่อหน้าตามต้นฉบับเดิม โดยไม่กำกับเครื่องหมายแสดงย่อหน้าและไม่กำกับของเขตของประโยค
  - รหัสอักขระ: UTF-8
  - เครื่องหมายกำหนดขอบเขตคำ: | ในตำแหน่งท้ายของคำ
  - เครื่องหมายกำหนดนิพจน์ระบุนาม (Named-entity) : <NE>...</NE>
  - เครื่องหมายกำหนดอักขรย่อ: <AB>...</AB>
  - เครื่องหมายกำหนดข้อความที่เป็นร้อยกรอง: <POEM>...</POEM>

จากข้อดีต่างๆ ของคลังข้อมูล BEST เช่น ถูกออกแบบมาให้สามารถนำไปใช้ประมวลผลด้วยคอมพิวเตอร์ได้ มีความน่าเชื่อถือในการตัดคำ ได้รับอนุญาตให้สามารถนำไปใช้งานในด้านการศึกษาวิจัยได้ จึงเป็นคลังข้อความที่เหมาะสมที่จะนำมาประยุกต์ใช้งาน ในงานวิจัยนี้

และจากการศึกษางานวิจัยการใช้จำนวนแกรมต่างๆ และขนาดของคลังข้อความในการฝึกฝนเอ็นแกรมโมเดลที่แตกต่างกันเพื่อช่วยในการคาดเดาคำศัพท์ [15] พบว่าเมื่อเพิ่มขนาดของข้อมูลที่ใช้ฝึกฝนเอ็นแกรมโมเดลจะสามารถช่วยลดการกดยเพื่อพิมพ์คำแต่ละคำลงได้ ดังแสดงในรูปที่ 2.2



รูปที่ 2.2 กราฟเปรียบเทียบจำนวนครั้งที่กดคีย์เมื่อใช้ข้อมูลและจำนวนแกรมต่างๆ [15]

Leshner และคณะ [15] ได้ทดลองเพื่อเปรียบเทียบประสิทธิภาพของจำนวนของเอ็นแกรมเมื่อใช้จำนวนแกรมเท่ากับ 1-gram, 2-gram และ 3-gram โดยในแต่ละแกรมใช้ข้อมูลขนาดต่างๆ ตั้งแต่ 100,000 – 3,000,000 คำในการฝึกฝนเอ็นแกรมโมเดล และใช้เอ็นแกรมโมเดลเหล่านี้ร่วมกับโปรแกรมช่วยพิมพ์เพื่อให้เอ็นแกรม โมเดลคาดเดาคำที่จะพิมพ์ โดยผลการทดสอบเปรียบเทียบพบว่าเมื่อใช้ขนาดของข้อมูลในการฝึกฝนเอ็นแกรม โมเดลเพิ่มขึ้นทำให้สามารถคาดเดาคำที่จะพิมพ์ได้ถูกต้องมากยิ่งขึ้น ซึ่งจะช่วยลดจำนวนคำที่ต้องพิมพ์ด้วยตนเองลงได้ และการใช้จำนวนแกรมเท่ากับ 3-gram จะให้ผลลัพธ์ในการคาดเดาคำได้ดีที่สุด

ดังนั้นงานวิจัยนี้จึงนำเอาคลังข้อความ BEST ซึ่งเป็นคลังข้อความที่มีขนาดใหญ่ที่สุดในปัจจุบันมาประยุกต์ใช้งาน แต่จะคัดเลือกเฉพาะประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์เท่านั้น ทั้งนี้เพราะโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม สามารถแปลงประโยคต่างๆ ไปได้ถูกต้องอยู่แล้วและวิทยานิพนธ์นี้ได้มุ่งเน้นที่จะแก้ไขปัญหาที่เกี่ยวข้องกับการแปลงคำควบกล้ำ, สระประสมและอักษรเบรลล์สองเซลล์เท่านั้น และในหัวข้อที่ 3.3.1 จะกล่าวถึงวิธีคัดเลือกประโยคที่ต้องการจากคลังข้อมูล BEST

## 2.5 เอ็นแกรมโมเดล

เอ็นแกรม โมเดล (N-gram model) [2] คือ แบบจำลองที่ใช้คำนวณค่าความน่าจะเป็นของชุดอักขระ (character sequence) ที่เกิดขึ้นร่วมกันเป็นคำ หรือค่าความน่าจะเป็นของคำที่เขียนเรียงกัน (word sequence) ที่เกิดขึ้นร่วมกันเป็นประโยค โดยค่าความน่าจะเป็นของชุดอักขระหรือคำ คำนวณได้จากคลังข้อมูลที่สร้างไว้

Gram คือ หน่วยที่ใช้ในการสร้างแบบจำลองอาจจะเป็นเสียง คำ หรืออักขระก็ได้และแกรมมีได้หลายขนาดแล้วแต่จะกำหนด ตั้งแต่ 1 จนถึง N โดย N เป็นจำนวนนับตั้งแต่ 1, 2, 3 ..., n

### 2.5.1 หลักการทำงานของ N-gram model

เมื่อมีกลุ่มของอักขระที่เขียนเรียงติดกัน ที่เกิดขึ้นร่วมกันเป็นคำ  $S = (c_1 \dots c_n)$  หรือกลุ่มของคำที่เขียนเรียงติดกัน ที่เกิดขึ้นร่วมกันเป็นประโยค  $W = (w_1 \dots w_n)$  ให้ N-gram model คำนวณค่าความน่าจะเป็นของการเกิดชุดของอักขระหรือคำใดๆ ที่เกิดขึ้นร่วมกัน โดยการพิจารณาจากอักขระหรือคำก่อนหน้า ตัวอย่างเช่น

การประมาณค่าด้วย 3- Gram (Probability trigram) คือ การประมาณค่าความน่าจะเป็นของชุดอักขระที่เกิดขึ้นร่วมกันเป็นคำ มีค่าเท่ากับผลคูณของความน่าจะเป็นที่จะพบอักขระ(คำ) ทีละ 3 ตัว(คำ) ติดกันในชุดอักขระนั้น เช่น ประโยค “ฉันกินข้าว” ความน่าจะเป็นที่คำว่า “ฉัน”, “กิน” และ

“ข้าว” เขียนเรียงติดกันแล้วเกิดขึ้นร่วมกันเป็นประโยค = P(ข้าว|กิน,ฉัน) หากเขียนให้อยู่ในรูปทั่วไปจะมีสมการคำนวณค่าความน่าจะเป็นดังสมการที่ 2 และ 3

ค่าความน่าจะเป็นที่จะเกิดคำหรืออักขระ  $x_i$  โดยมีชุดของคำหรือชุดอักขระ  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$  นำหน้า  $= P(x_i | x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n}) \dots \dots \dots (2)$

ซึ่ง  $P(x_i | x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n}) = c(x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}, x_i) / c(x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n}) \dots \dots \dots (3)$

โดยที่  $c(x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}, x_i)$  คือจำนวนครั้งที่เกิด  $x_i$  ร่วมกับ  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$   
 $c(x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n})$  คือจำนวนครั้งที่เกิด  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$  ใน Training Corpus

แต่ในความเป็นจริงแล้วเป็นไปได้ที่จะบรรจุคำทุกๆ คำหรือรูปแบบคำทุกๆ รูปแบบที่เกิดขึ้นลงในคลังข้อมูลฝึกได้ทั้งหมด

ดังนั้นจึงต้องปรับปรุงให้ค่าความน่าจะเป็นแก่คำหรือชุดของอักขระ ที่ไม่มีอยู่ในคลังข้อมูลฝึก ซึ่งเรียกการเพิ่มค่าความน่าจะเป็นให้กับคำที่ไม่พบนี้ว่าการ Smoothing [17] ทั้งนี้เพื่อป้องกันปัญหาการหารด้วยศูนย์ แม้ว่าในความเป็นจริงแล้วจะไม่มีคำนั้นๆ อยู่ก็ตาม

งานวิจัยในวิทยานิพนธ์นี้จะนำแบบจำลองภาษาอักขระเบรลล์ภาษาไทยเข้ามาช่วยในการตัดสินใจเลือกคำที่ได้จากการแปลงอักขระเบรลล์ไปเป็นภาษาไทย โดยใช้วิธีการคำนวณหาค่าความน่าจะเป็นของคำที่เกิดขึ้นร่วมกัน และเนื่องจากหลักไวยากรณ์ของอักขระเบรลล์ จะไม่เหมือนกับหลักไวยากรณ์ของภาษาไทยจึงไม่สามารถนำเอาแบบจำลองเอ็นแกรมของภาษาไทยมาใช้ได้ จึงจำเป็นต้องสร้างแบบจำลองเอ็นแกรมของอักขระเบรลล์ภาษาไทยขึ้นมาใหม่

**2.6 Smoothing Techniques**

Smoothing techniques [17] คือ เทคนิคการประมาณค่าความน่าจะเป็นให้กับคำหรือชุดของคำที่ไม่มีอยู่หรือไม่พบในคลังข้อความ ซึ่งเทคนิคนี้อาศัยวิธีการประมาณค่าทางสถิติในการคำนวณหาค่าความน่าจะเป็นของคำที่ไม่พบในคลังข้อความ และเทคนิคนี้เป็นกระบวนการที่จำเป็นสำหรับงานด้านสถิติ อีกทั้งเป็นการป้องกันปัญหาการหารด้วยศูนย์อีกด้วย นอกจากนี้แล้วจากข้อจำกัดของคลังข้อความที่ไม่สามารถจัดเก็บคำและคู่ของคำทั้งหมดที่เกิดขึ้นจริงไว้ในคลังข้อมูลได้ทั้งหมดทำให้คำบางคำหรือคู่ของคำบางคำอาจไม่มีอยู่ในคลังข้อมูล โดยจะขอยกตัวอย่างสมการการคำนวณค่าความน่าจะเป็นของคำเมื่อใช้จำนวนแกรมเท่ากับ 2 (bigram) ดังสมการที่ 4

$$P(w_2|w_1) = C(w_1w_2)/C(w_1) \dots\dots\dots (4)$$

จากสมการที่ 4 หมายความว่า ค่าความน่าจะเป็นที่คำ  $w_2$  เกิดขึ้นก็ต่อเมื่อมีคำ  $w_1$  เขียนนำหน้า เท่ากับจำนวนคำของ  $w_1w_2$  ซึ่งเขียนเรียงติดกันที่เกิดขึ้นร่วมกันในคลังข้อมูลฝึก ( $C(w_1w_2)$ )หารด้วยจำนวนคำ  $w_1$  ที่พบในคลังข้อมูลฝึก ( $C(w_1)$ )

เมื่อพิจารณาสมการที่ 4 แล้วพบว่าหากคำ  $w_1$  ไม่พบในคลังข้อมูลจะทำให้ค่าของจำนวนคำ  $w_1$  เท่ากับศูนย์ ( $C(w_1) = 0$ ) และเมื่อคำนวณค่าความน่าจะเป็นที่คำ  $w_2$  เกิดขึ้นก็ต่อเมื่อมีคำ  $w_1$  เขียนนำหน้า ( $P(w_2|w_1)$ ) จะทำให้ไม่สามารถคำนวณค่าความน่าจะเป็นได้ ทำให้เกิดปัญหาการหารด้วยศูนย์ [22] หรืออีกกรณีหนึ่งคือคู่ของคำ  $w_1w_2$  ไม่พบในคลังข้อมูลทำให้ค่าของจำนวนคำของ  $w_1w_2$  ซึ่งเขียนเรียงติดกันเท่ากับศูนย์ ( $C(w_1w_2) = 0$ ) และเมื่อคำนวณค่าความน่าจะเป็นที่คำ  $w_2$  เกิดขึ้นก็ต่อเมื่อมีคำ  $w_1$  เขียนนำหน้า ( $P(w_2|w_1)$ ) จะทำให้ได้ค่าความน่าจะเป็นเท่ากับศูนย์ ซึ่งในความเป็นจริงแล้วอาจจะเป็นไปได้ว่ามีโอกาสที่คำ  $w_1$  และ  $w_2$  เกิดขึ้นร่วมกัน ซึ่งกรณีนี้จะให้ผลลัพธ์ในการคำนวณที่ผิดพลาดออกมา

ดังนั้นเพื่อป้องกันปัญหาดังกล่าวจึงได้มีการนำเสนอเทคนิควิธีการที่เรียกว่า smoothing เข้ามาเพื่อป้องกันปัญหาดังกล่าว และจากการศึกษาพบว่าวิธีการ smoothing มีอยู่ด้วยกันหลายวิธี [17] เช่น Baseline Smoothing, Additive Smoothing, Katz Smoothing, Church-Gale Smoothing, Jelinek-Mercer Smoothing และ Novel Smoothing

จากการศึกษาพบว่าการประมาณค่าด้วยวิธี Jelinek-Mercer Smoothing (Interpolation) จะให้ผลลัพธ์ที่ดีที่สุดเมื่อเปรียบเทียบกับวิธีอื่นๆ [17] ซึ่งการทดสอบเปรียบเทียบได้สร้างเอ็นแกรมโมเดล โดยใช้จำนวนแกรมเท่ากับสองแกรม (Bigram) และสามแกรม (Trigram) และใช้คลังข้อมูล TIPSTER, Brown และ Wall Street Journal ในการฝึกฝนเอ็นแกรมโมเดลและแบ่งการฝึกฝนเอ็นแกรมโมเดลออกเป็นสองชุดด้วยกันคือ ชุดแรกฝึกฝนเอ็นแกรมโมเดลด้วยข้อมูลขนาดประมาณ 50,000 ประโยค ชุดที่สองฝึกฝนเอ็นแกรมโมเดลด้วยข้อมูลขนาดประมาณ 10,000,000 ประโยค และวัดค่าความน่าจะเป็นเมื่อใช้เทคนิคการ Smoothing แบบต่างๆ โดยเปรียบเทียบความเบี่ยงเบนจากเส้นฐาน (Difference in test cross-entropy from baseline)

จากผลการทดลองดังกล่าวสามารถสรุปได้ว่าเทคนิคการ Smoothing แบบ Jelinek-Mercer Smoothing (interpolation) จะให้ผลลัพธ์ที่ดีที่สุดเพราะมีความเบี่ยงเบนจากเส้นฐานน้อยที่สุด ซึ่งหมายถึงเทคนิคนี้สามารถประมาณค่าความน่าจะเป็นได้ใกล้เคียงกับค่าความน่าจะเป็นที่คำนวณได้จริงๆ ตามสมการที่ 2 โดยวิธี Jelinek-Mercer Smoothing (Interpolation) มีสมการในการประมาณค่าความน่าจะเป็นดังแสดงในสมการที่ 5

$$P_{\text{interp}}(w_i | w_{i-n+1}^{i-1}) = \lambda_{w_{i-n+1}^{i-1}} P_{\text{ML}}(w_i | w_{i-n+1}^{i-1}) + (1 - \lambda_{w_{i-n+1}^{i-1}}) P_{\text{interp}}(w_i | w_{i-n+2}^{i-1}) \dots \dots \dots (5)$$

$$\text{โดยที่ } P_{\text{ML}}(w_i | w_{i-n+1}^{i-1}) = C(w_{i-n+1}^{i-1} w_i) / C(w_{i-n+1}^{i-1})$$

$$\text{และจากงานวิจัยของ Bahl และคณะ [17] แนะนำให้กำหนดค่าของ } \lambda_{w_{i-n+1}^{i-1}} = \frac{C(w_{i-n+1}^{i-1})}{|W_i : C(w_{i-n+1}^{i-1}) > 0|}$$

ดังนั้นในงานวิจัยที่นำเสนอนี้ได้เลือกใช้เทคนิคการประมาณค่าแบบ Jelinek-Mercer Smoothing (Interpolation) เพื่อใช้คำนวณค่าความน่าจะเป็นให้กับคำหรือคู่ของคำที่เกิดขึ้นร่วมกัน (อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1) ซึ่งไม่ได้ปรากฏอยู่ในคลังข้อมูลและนอกจากนี้แล้วชุดเครื่องมือ CMU-SLM toolkit [21] ที่นำมาใช้ในงานวิจัยนี้มีความสามารถในการคำนวณค่าความน่าจะเป็นโดยใช้เทคนิคการ Smoothing แบบ Jelinek-Mercer Smoothing (Interpolation) อีกด้วย

## 2.7 CMU-SLM Toolkit

ชุดเครื่องมือ CMU-SLM Toolkit [20] เป็นชุดเครื่องมือที่ใช้ในการสร้างโมเดลภาษา (Language model) หรือเรียกว่า “การฝึกฝนเอ็นแกรมโมเดล” โดยชุดเครื่องมือนี้ได้รับการพัฒนาโดยมหาวิทยาลัย Carnegie Mellon โดยในงานวิจัยที่นำเสนอนี้ได้เลือกใช้เครื่องมือ CMU-SLM Toolkit เพื่อช่วยอำนวยความสะดวกในการสร้างโมเดลภาษาของอักษรเบรลล์ภาษาไทยระดับ 1 เนื่องจากมีการใช้งานกันอย่างแพร่หลาย ชุดเครื่องมือนี้มีการเผยแพร่เป็นสาธารณะ มีคู่มืออธิบายการใช้งานชัดเจน ทำให้ใช้งานได้ง่าย และเป็นชุดเครื่องมือที่ครบถ้วนสมบูรณ์ โดยในชุดเครื่องมือนี้จะประกอบด้วยโปรแกรมย่อยจำนวนหลายโปรแกรมด้วยกันเช่น text2wfreq, wfreq2vocab, text2wngram, text2idngram, ngram2mgram, wngram2idngram, idngram2stats, mergeidngram, idngram2lm, binlm2arpa, evallm, interpolate เป็นต้น

สำหรับในวิทยานิพนธ์นี้ได้ใช้เฉพาะ โปรแกรมย่อยบางตัวเท่านั้นในการสร้างโมเดลภาษา ซึ่งมีดังต่อไปนี้

1. โปรแกรม text2wfreq จะทำหน้าที่สร้างรายการคำที่มีอยู่ในไฟล์ที่ผู้ใช้นำมาฝึกฝนเอ็นแกรมโมเดลทั้งหมด พร้อมทั้งนับความถี่ของแต่ละคำ
2. โปรแกรม text2wfreq จะทำหน้าที่สร้างรายการของคำ (Vocabulary) ทั้งหมดที่มีอยู่ในไฟล์ที่ผู้ใช้นำมาฝึกฝนเอ็นแกรมโมเดล

3. โปรแกรม text2idngram ทำหน้าที่สร้างไบนารีไฟล์ที่เก็บว่ามีคำในไฟล์ที่ผู้ใช้นำมาฝึกฝนเอ็นแกรมโมเดล คำๆ นั้นจะสามารถเกิดขึ้นร่วมกับคำใดได้บ้างและไม่สามารถเกิดขึ้นร่วมกับคำใดได้บ้าง โดยเก็บอยู่ในลักษณะเป็นดัชนี (index) ว่าเกิดขึ้นร่วมกับคำอื่นได้หรือไม่ โดยแทนค่าด้วย 1 หากสามารถเกิดขึ้นร่วมกันได้และในกรณีที่ไม่สามารถเกิดขึ้นร่วมกันได้จะแทนค่าด้วย 0
4. โปรแกรม idngram2lm ทำหน้าที่สร้างไฟล์โมเดลภาษา ซึ่งเป็นไฟล์ที่จะนำไปใช้งานต่อไป โดยตัวอย่างไฟล์โมเดลภาษาจะแสดงไว้ในรูปที่ 3.6 ในหัวข้อ 3.3.1 วิธีการฝึกฝนเอ็นแกรมโมเดล

เมื่อใช้โปรแกรมย่อยเหล่านี้แล้วก็จะได้ผลลัพธ์ออกมาเป็นไฟล์โมเดลภาษา ซึ่งขึ้นอยู่กับข้อความที่ผู้ใช้นำมาใช้ในการสร้างโมเดลภาษาว่าเป็นภาษาอะไร จากนั้นผู้วิจัยจะนำเอาไฟล์โมเดลภาษานี้มาใช้กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำตามที่ได้ออกแบบไว้ ซึ่งจะอธิบายใน บทที่ 3 การออกแบบและพัฒนาระบบ

## 2.8 โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ ของมหาวิทยาลัยสงขลานครินทร์

โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ (Thai2brl) [1] ได้นำเสนอไว้ในงานวิจัยเรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” ของมหาวิทยาลัยสงขลานครินทร์ เช่นเดียวกันกับ โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file ที่ได้นำมาเปรียบเทียบประสิทธิภาพกับ โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ โดยโปรแกรมดังกล่าวทำหน้าที่แปลงภาษาไทยไปเป็นอักษรเบรลล์ภาษาไทยในรูปแบบ File-to-file ซึ่งกระบวนการทำงานของโปรแกรมนี้ ได้ใช้วิธีการแปลงแบบใช้กฎไวยากรณ์ทางภาษาของภาษาไทยและอักษรเบรลล์ภาษาไทยเข้ามาควบคุมการแปลง โดยให้ผลลัพธ์ในการแปลงที่ถูกต้องในระดับหนึ่ง

ซึ่งในงานวิจัยนี้ได้้นำโปรแกรมดังกล่าวมาใช้เพื่อแปลงข้อความภาษาไทยให้เป็นข้อความอักษรเบรลล์ภาษาไทยระดับ 1 เพื่อนำไปใช้งานต่อไป โดยได้นำมาใช้ในขั้นตอนต่างๆ ดังนี้

1. ใช้แปลงประโยคภาษาไทยที่ได้คัดเลือกมาจากคลังข้อความ BEST ให้เป็นประโยคอักษรเบรลล์ภาษาไทยระดับ 1 เพื่อนำไปสร้างโมเดลอักษรเบรลล์ภาษาไทยต่อไป



(รายละเอียดการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST จะอธิบายในหัวข้อ 3.3.1 และวิธีการสร้างโมเดลอักษรเบรลล์ภาษาไทยจะอธิบายในหัวข้อ 3.3.2)

2. ใช้แปลงชุดข้อมูลทดสอบให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 เพื่อนำไปทดสอบเปรียบเทียบประสิทธิภาพในด้านต่างๆ ระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file (วิธีการเดิม) กับ โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ (วิธีการใหม่) ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ (รายละเอียดของชุดข้อมูลทดสอบจะอธิบายในหัวข้อ 4.1.3, 4.2.3 และ 4.3.3)
3. ใช้แปลงรายการคำภาษาไทยให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 เพื่อนำไปใช้ในขั้นตอน Translate\_to\_thai เนื่องจากเอ็นแกรมโมเดลไม่สามารถนำไปประยุกต์ด้านการแปลงให้เป็นภาษาไทยได้ จึงต้องมีขั้นตอนดังกล่าวเพื่อทำหน้าที่แปลงประโยคอักษรเบรลล์ภาษาไทยที่ตัดคำแล้วโดยใช้เทคนิคเอ็นแกรมให้อยู่ในรูปแบบของประโยคภาษาไทย และโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file (วิธีการเดิม) ให้เอาท์พุทเป็นประโยคภาษาไทยจึงต้องมีขั้นตอนดังกล่าวเพื่อแปลงให้เอาท์พุทเป็นประโยคภาษาไทยเช่นกัน เพื่อให้สามารถเปรียบเทียบกันได้โดยตรง (รายละเอียดของขั้นตอน Translate\_to\_thai จะอธิบายในหัวข้อ 3.6.4 และรายการคำภาษาไทยและรายการคำอักษรเบรลล์ภาษาไทยจะอธิบายในหัวข้อ 3.9)

แต่ทั้งนี้เนื่องจากโปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ดังกล่าว ยังคงมีการแปลงที่ผิดพลาดอยู่บ้างเนื่องจากการใช้กฎไวยากรณ์ทางภาษาของภาษาไทยและอักษรเบรลล์ภาษาไทยเข้ามาควบคุมการแปลง ซึ่งผู้วิจัยได้พยายามค้นหาคำที่แปลงผิดและแก้ไขให้ถูกต้องให้มากที่สุดเท่าที่จะเป็นไปได้ โดยได้รวบรวมรายการคำดังกล่าวไว้ในตารางที่ 8 ในภาคผนวก ค

## บทที่ 3

### การออกแบบและการพัฒนาระบบ

ในบทนี้จะกล่าวถึงรายละเอียดของปัญหาการแปลงอักษรเบรลล์ภาษาไทยระดับ 1 ไปเป็นภาษาไทย, ขั้นตอนการสร้างไฟล์โมเดลภาษาและเครื่องมือที่ใช้เพื่อนำไปใช้งานร่วมกับโปรแกรมที่ได้นำเสนอและหลักการทำงานของโปรแกรมที่ได้นำเสนอในวิทยานิพนธ์นี้ ซึ่งประกอบไปด้วย 1) การวิเคราะห์ปัญหาการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยในปัจจุบัน 2) แนวคิดในการแก้ไขปัญหในงานวิจัย 3) การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย 4) ภาพรวมของโปรแกรมนำเสนอ 5) อินพุตและเอาต์พุตของโปรแกรมนำเสนอ 6) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ 7) เอ็นแกรมโมเดล 8) Smoothing Techniques และ 9) รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทย

#### 3.1 การวิเคราะห์ปัญหาการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยในปัจจุบัน

ในการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 นั้นมีความคล้ายคลึงกับการเขียนภาษาไทยอยู่มาก เช่น การเขียนคำแต่ละคำติดๆ กันเป็นประโยคและการเว้นวรรคประโยคเป็นช่วงๆ และไม่มี การแบ่งขอบเขตของคำแต่ละคำอย่างชัดเจนเหมือนกับภาษาอังกฤษ แต่ก็มีความแตกต่างกันในด้านของหลักไวยากรณ์อยู่พอสมควรและไม่สามารถแปลโดยเทียบตัวอักษรแบบตัวต่อตัวได้

ดังนั้นจึงจำเป็นต้องอาศัยซอฟต์แวร์แปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยเข้ามาช่วย เพื่อเป็นตัวกลางในการสื่อสารกันระหว่างผู้พิการทางสายตากับคนปกติ ซึ่งซอฟต์แวร์สำหรับการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ได้มีการพัฒนามาก่อนหน้านี้ ได้ใช้หลักการแปลงที่แตกต่างกัน เช่น การแปลงโดยอาศัยการเปรียบเทียบแบบคำต่อคำ การแปลงโดยอาศัยกฎไวยากรณ์ทางภาษา การแปลงโดยอาศัยการเทียบแบบตัวอักษรเบรลล์กับอักษรไทยแบบต่อตัวตามรูปแบบการเขียนภาษาไทยโดยทั่วไปที่เรียกอย่างไม่เป็นทางการว่า “การเขียนอักษรเบรลล์ภาษาไทยระดับ 0” ซึ่งไม่ใช่มาตรฐานในการสื่อสารโดยปกติระหว่างกันของผู้พิการทางสายตา แต่เพื่อให้สื่อสารกับคนสายตาปกติได้

ในการพัฒนาโปรแกรมแปลงอักษรเบรลล์มักใช้การแปลงโดยอาศัยกฎไวยากรณ์ทางภาษา ซึ่งได้รับความนิยมนำมาใช้มากที่สุด เนื่องจากสามารถใช้กฎไวยากรณ์ทางภาษาเป็นเงื่อนไขในการ

เขียนโปรแกรมได้เลยและไม่จำเป็นต้องใช้องค์ประกอบอื่นๆ เช่น ฐานข้อมูลคำ คลังข้อมูลคำ หรือ เครื่องมือพิเศษอื่นๆ

แต่การแปลงโดยใช้กฎไวยากรณ์ทางภาษานั้นมีความซับซ้อนในการเขียนเงื่อนไขการแปลงให้ครอบคลุมกรณีการแปลงทั้งหมดและมักจะมีปัญหาที่เกิดขึ้นจากการต่อคำ เช่น คำว่า “เครือ” เขียนอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 เป็น “urq” ซึ่งก็คือ “ค+ร+เอือ” แต่เนื่องจากคำว่า “rq” หรือ “ร+เอือ” เป็นคำที่มีความหมายว่า “เรือ” ก็เป็นคำที่มีความหมายในภาษาไทยเช่นกัน และอักษรเบรลล์ ‘u’ ซึ่งก็คืออักษร “ค” ในภาษาไทยของว่า “เครือ” อาจจะเป็นตัวควบกล้ำของคำปัจจุบันหรือเป็นตัวสะกดของคำก่อนหน้าก็ได้ เช่นวลีที่ว่า “ไททานิคเรือที่ไม่มีวันจม” (อักษร “ค” เป็นตัวสะกดของคำก่อนหน้า) หรือประโยค “กล้วยเครือนี้ผลมีขนาดใหญ่” (อักษร “ค” เป็นตัวควบกล้ำของคำปัจจุบัน) ซึ่งปัญหาการต่อคำเหล่านี้โดยทั่วไปแล้วจะเกิดขึ้นกับเฉพาะคำควบกล้ำและคำที่มีการใช้สระประสม เพราะอักษรนำของคำๆ นั้นอาจจะเป็นตัวควบกล้ำของคำปัจจุบันหรือเป็นตัวสะกดของคำก่อนหน้าก็ได้ ซึ่งปัจจุบันปัญหานี้ยังคงเป็นสาเหตุหลักที่โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่มีการพัฒนามาก่อนหน้านี้ ยังคงมีการแปลงที่ผิดพลาดอยู่

ปัญหาการแปลงอีกประการหนึ่งที่สำคัญคือ การแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์ ซึ่งปัญหานี้เกิดจากการที่มีอักษรเบรลล์สองเซลล์บางตัวที่มีรูปพ้องกันกับการเขียนอักษรเบรลล์เซลล์เดียวสองตัวติดกัน โดยอักษรเบรลล์สองเซลล์ที่มีปัญหาในการแปลงดังกล่าวแสดงดังตารางที่

3.1

ตารางที่ 3.1 อักษรเบรลล์สองเซลล์ที่มีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน


อักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน	อักษรเบรลล์สองเซลล์
r+1 (ร+๓)	r1 (ฤ)
l+1 (ล+๓)	ll (ฤ)
o+a (อ+สระอะ)	oa (สระเอาะ)
0) (การ์นต์+ท)	0) (ธ)

จากตารางที่ 3.1 อักษรเบรลล์ ‘r1’ ซึ่งก็คืออักษร ‘ฤ’ จะพ้องรูปกับอักษรเบรลล์ ‘r’ (ร) ตามด้วย ‘1’ (๓) และอักษรเบรลล์ ‘ll’ ซึ่งก็คืออักษร ‘ฤ’ จะพ้องรูปกับอักษรเบรลล์ ‘l’ (ล) ตามด้วย ‘1’ (๓) และอักษรเบรลล์ ‘oa’ ซึ่งก็คือ สระเอาะ จะพ้องรูปกับอักษรเบรลล์ ‘o’ (อ) ตามด้วย ‘a’

(สระอะ) และอักษรเบรลล์ ‘0’ ซึ่งก็คืออักษร ‘ธ’ จะพ้องรูปกับอักษรเบรลล์ ‘0’ (การันต์) ตามด้วย ‘)’ (ท)

โดยส่วนมากแล้วจะพบกับปัญหาการแปลงอักษรเบรลล์ ‘0’ (การันต์) ตามด้วย ‘)’ (ท) ที่พ้องรูปกันกับอักษรเบรลล์ ‘0’ (ธ) มากที่สุดเพราะเป็นตัวอักษรที่มีการใช้งานในภาษาไทยหรืออักษรเบรลล์ภาษาไทยมากกว่าตัวอักษรอื่นๆ เช่นคำว่า “พระองค์ทรง” เขียนในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 คือ “?rao}u0)r}” ซึ่งก็คือ “พ+ร+ะ+อ+ง+ค+การันต์+ท+ร+ง” โดยอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกันแล้วมีรูปพ้องกันกับอักษรเบรลล์สองเซลล์ในที่นี้คือ ‘0+)’ ซึ่งก็คืออักษร ‘การันต์+ท’ โดยมีรูปพ้องกันกับอักษรเบรลล์สองเซลล์คืออักษร ‘0’ ซึ่งก็คืออักษร ‘ธ’ ด้วยเหตุนี้ทำให้โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม [1] ไม่สามารถทราบได้ว่าเป็นอักษรเบรลล์สองเซลล์หนึ่งตัวหรือเป็นอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน ซึ่งจะแตกต่างกับกรณีของโปรแกรมการแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด [1] ที่สามารถแก้ไขปัญหาล่านี้ได้โดยใช้วิธีให้ผู้ใช้กดคีย์พิเศษก่อนจะป้อนอักษรเบรลล์สองเซลล์ ซึ่งการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบ File-to-file นั้นผู้ใช้จะไม่สามารถโต้ตอบกับโปรแกรมเพื่อระบุว่าตรงไหนเป็นอักษรเบรลล์สองเซลล์ได้ แม้ว่าปัญหาดังกล่าวอาจสามารถแก้ไขได้ด้วยการแบ่งคำที่เหมาะสมก็ตาม แต่ก็ยังมีคำบางคำที่ไม่สามารถแบ่งได้ เนื่องจากเป็นคำที่เป็นชื่อเฉพาะไม่สามารถแบ่งออกเป็นคำย่อยๆ ได้และจะทำให้ความหมายโดยรวมนั้นผิดไปจากเดิม เช่นคำว่า “นวลจันทร์ทะเล”, “พิมพ์ทอง” เป็นต้น

จากการศึกษาผู้วิจัยได้คัดเลือกประโยคที่ประกอบไปด้วยคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์จากคลังข้อมูล BEST [13] ขนาด 71.8 เมกกะไบต์ (รายละเอียดของคลังข้อมูล BEST และวิธีการคัดเลือกประโยคจากคลังข้อมูล BEST จะอธิบายในหัวข้อที่ 2.4 และ 3.3.1 ตามลำดับ) พบว่าประโยคภาษาไทยที่มีการใช้คำควบกล้ำและสระประสมมีจำนวนประมาณเกือบครึ่งหนึ่งของจำนวนประโยคทั้งหมด และประโยคที่มีการใช้คำอักษรเบรลล์สองเซลล์และคำทับศัพท์มีขนาดประมาณ 1.04 เมกกะไบต์และ 2.72 เมกกะไบต์ตามลำดับดังแสดงในรูปที่ 3.1



รูปที่ 3.1 ขนาดของไฟล์ที่มีการใช้คำประเภทต่างๆ เปรียบเทียบกับขนาดของไฟล์ทั้งหมด

จากรูปที่ 3.1 เห็นได้ว่าในภาษาไทยประกอบด้วยคำควบกล้ำและสระผสมประมาณครึ่งหนึ่งของประโยคทั้งหมด ดังนั้นจึงส่งผลให้การเขียนอักษรเบรลล์ภาษาไทยประกอบด้วยคำประเภทคำควบกล้ำและสระผสมเป็นจำนวนมากเช่นกัน ดังนั้นปัญหาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ได้กล่าวไว้ข้างต้นจึงนับว่าเป็นปัญหาที่สำคัญมากทีเดียว และจำเป็นต้องได้รับการปรับปรุงแก้ไข

### 3.2 แนวคิดในการแก้ไขปัญหในงานวิจัย

จากปัญหาในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ได้กล่าวไว้ในข้างต้น จึงมีแนวคิดที่จะนำเทคนิคเอ็นแกรมโมเดลเข้ามาช่วยในการตัดคำอักษรเบรลล์ภาษาไทยก่อนที่จะแปลงไปเป็นภาษาไทย เพื่อแบ่งขอบเขตแต่ละคำของอักษรเบรลล์ภาษาไทยให้ชัดเจน ทั้งนี้เพื่อเป็นการลดความกำกวมที่จะเกิดขึ้นกับการต่อคำ เช่นเดียวกันกับในกรณีของภาษาไทย

ซึ่งในงานวิจัยที่นำเสนอนี้ได้ใช้เอ็นแกรมโมเดลในการคำนวณหาความน่าจะเป็นที่คำปัจจุบัน ซึ่งอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 จะเกิดขึ้นได้ก็ต่อเมื่อมีคำบางคำที่เป็นรูปแบบเฉพาะ ซึ่งเขียนอยู่ก่อนหน้าคำๆ นี้ ยกตัวอย่างคำในรูปแบบภาษาไทยเพื่อง่ายต่อการทำความเข้าใจ เช่น คำปัจจุบันเป็นคำว่า “เรียน” คำที่เขียนอยู่ก่อนหน้าคำๆ นี้ก็จะมีความเป็นไปได้คือคำว่า “โรง” ตามด้วยคำว่า “เรียน” รวมกันเป็นคำว่า “โรงเรียน”, “นัก” ตามด้วยคำว่า “เรียน” รวมกันเป็นคำว่า “นักเรียน”, “การ” ตามด้วยคำว่า “เรียน” รวมกันเป็นคำว่า “การเรียน” เป็นต้น หรือในทางกลับกัน เมื่อมีส่วนของประโยค เช่น “ฉันไป” ซึ่งคำส่วนใหญ่ที่ตามหลังส่วนของประโยคดังกล่าวก็จะเป็นคำจำพวกสถานที่ เช่น คำว่า “โรงเรียน”, “โรงงาน”, “บ้าน” เป็นต้น ซึ่งมี

ความเป็นไปได้บ้างที่จะเป็นคำประเภทอื่นๆ เช่น คำว่า “กินข้าว”, “เที่ยว” เป็นต้น ซึ่งคำเหล่านี้ก็สามารถพบได้บ้าง แต่จะไม่มีโอกาสพบว่าเป็นคำที่ให้ความหมายขัดแย้งหรือไม่เกี่ยวข้องกับส่วนของประโยคนั้น เช่นคำว่า “เงิน”, “เขี่ย”, “แดง” เป็นต้น

ดังนั้นจึงได้นำเอาหลักการนี้มาประยุกต์ใช้กับอักษรเบรลล์ภาษาไทยระดับ 1 เพราะมีลักษณะบางประการที่เหมือนกับภาษาไทย คือมีการเขียนเป็นคำๆ เรียงติดกันเป็นประโยคและมีการเว้นวรรคระหว่างประโยค เช่นเดียวกับภาษาไทย แต่จะมีความแตกต่างในเรื่องของลำดับการวางอักขระให้เป็นคำขึ้นมาและมีการใช้สัญลักษณ์แทนตัวอักขระที่ไม่เหมือนกับภาษาไทย แต่ก็สามารถใช้หลักการของเอ็นแกรมโมเดลได้เช่นเดียวกับภาษาไทย ซึ่งงานวิจัยที่ได้นำเสนอนี้จะนำไฟล์โมเดลอักษรเบรลล์ภาษาไทยมาเปรียบเทียบเพื่อหาคำถัดไป เช่น พิจารณาจากคำที่เขียนนำหน้าก่อนหน้าคำปัจจุบันจำนวนสองคำ เมื่อใช้จำนวนแกรมเท่ากับ 3-gram เพื่อเปรียบเทียบว่าคำที่ตามหลังนั้นเป็นคำใดได้บ้างและมีค่าความน่าจะเป็นมากน้อยแค่ไหน และมีคำนี้อยู่ในประโยคอินพุตหรือไม่ หากมีจะตัดคำๆ นี้แยกออกมาโดยใช้สัญลักษณ์ <pipe> (ใช้สัญลักษณ์ “<pipe>” ในการแบ่งคำเพื่อไม่ให้ซ้ำกับสัญลักษณ์ “|” ในอักษรเบรลล์ภาษาไทยซึ่งใช้แทนตัวอักษร “ด” ในภาษาไทย) ในการแบ่งขอบเขตของคำแต่ละคำและดำเนินการแบบนี้ไปเรื่อยๆ จนกระทั่งจบประโยคหนึ่งๆ

สำหรับวิธีการคำนวณค่าความน่าจะเป็นจะเป็นไปตามหลักของการสร้างเอ็นแกรมโมเดล ซึ่งได้อธิบายไว้ในหัวข้อ 3.3.2 การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย โดยในวิทยานิพนธ์นี้ได้เลือกใช้ชุดเครื่องมือ CMU-SLM Toolkit ในการสร้างไฟล์โมเดลภาษา

### 3.3 การคัดเลือกประโยคจากคลังข้อมูล BEST และการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย

การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยนี้ เป็นการสร้างแบบจำลองทางภาษาของอักษรเบรลล์ภาษาไทยระดับ 1 เพื่อนำไปใช้งานร่วมกับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ โดยการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยหรือการฝึกฝนเอ็นแกรมโมเดล เป็นกระบวนการทางสถิติเพื่อให้เอ็นแกรมโมเดลคำนวณค่าความน่าจะเป็นของคำหนึ่งๆ ว่าสามารถที่จะเกิดขึ้นร่วมกับคำใดได้บ้างด้วยค่าความน่าจะเป็นเท่าใด ซึ่งผู้วิจัยได้แบ่งขั้นตอนการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยออกเป็น 2 ขั้นตอนหลัก คือ 1) ขั้นตอนคัดเลือกประโยคที่ต้องการจากคลังข้อมูล BEST ทั้งนี้เพราะโปรแกรมแปลงเบรลล์เป็นรหัสอสกัภาษาไทยแบบ File-to-file เดิม [1] สามารถแปลงคำต่างๆ ไปได้ถูกต้องอยู่แล้วจึงไม่มีความจำเป็นที่ต้องนำคลังข้อมูล BEST ทั้งหมดมาใช้ในการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย 2) ขั้นตอนการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย ในขั้นตอนนี้

เป็นการสร้างไฟล์แบบจำลองภาษาอักษรเบรลล์ภาษาไทยระดับ 1 โดยใช้ชุดเครื่องมือ CMU-SLM toolkit (รายละเอียดของชุดเครื่องมือ CMU-SLM toolkit จะอธิบายในหัวข้อ 2.7) ซึ่งมีรายละเอียดของขั้นตอนดังกล่าวดังต่อไปนี้

### 3.3.1 การคัดเลือกประโยคจากคลังข้อมูล BEST

ในงานวิจัยที่ได้นำเสนอนี้ได้เลือกใช้คลังข้อความ BEST ซึ่งเป็นคลังข้อความภาษาไทยที่มีขนาดใหญ่ที่สุดในปัจจุบันนำมาประยุกต์ใช้งาน และงานวิจัยนี้ได้มุ่งเน้นการแก้ไขปัญหาเฉพาะการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทย ที่เกี่ยวข้องกับคำควบกล้ำ, สระประสมและอักษรเบรลล์สองเซลล์ของโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิมโดยได้นำเสนอไว้ในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” [1] และโปรแกรมดังกล่าวสามารถแปลงประโยคโดยทั่วไปได้ถูกต้องอยู่แล้ว

ดังนั้นจึงไม่มีความจำเป็นที่จะต้องนำเอาคลังข้อความ BEST ทั้งหมดมาใช้สร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย ผู้วิจัยจึงได้คัดเลือกเอาเฉพาะประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์ และคำทับศัพท์ จากคลังข้อความ BEST เท่านั้น ซึ่งการคัดเลือกประเภทของประโยคดังกล่าวจะประกอบไปด้วย 4 ประเภทดังนี้

- 1) ประโยคที่มีการใช้คำควบกล้ำแบ่งออกเป็น 2 ประเภทด้วยกันคือ
  1. ประโยคที่ประกอบด้วยคำควบกล้ำแท้ ซึ่งจะประกอบด้วยตัวอักษรควบกล้ำ ดังนี้คือ กร, กล, กว, ขร, ขล, ขว, คร, คล, คว, ปร, ปล, พร และ พล
  2. ประโยคที่ประกอบด้วยคำควบกล้ำเทียม ซึ่งจะประกอบด้วยตัวอักษรควบกล้ำ ดังนี้คือ จร, ชร, ตร, ทร, ศรี และ สร
- 2) ประโยคที่ประกอบด้วยสระประสม ประกอบไปด้วยสระประสมดังต่อไปนี้คือ สระอัว, สระอัวะ, สระเออ, สระเออะ, สระเอะ, สระเอา, สระเอาะ, สระเอีย, สระเอียะ, สระเอือ, สระเอือะ และสระโอะ
- 3) ประโยคที่ประกอบด้วยอักษรเบรลล์สองเซลล์ จะคัดเลือกเฉพาะอักษรเบรลล์สองเซลล์ที่มีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน คือ “ช” (พ้องรูปกับอักษรเบรลล์เซลล์เดียว “การันต์+ท”), “ข” (พ้องรูปกับอักษรเบรลล์เซลล์เดียว “การันต์+ข”), “สระเอาะ” (พ้องรูปกับอักษรเบรลล์เซลล์เดียว “อ+สระอะ”), “ฤ” (พ้องรูปกับอักษรเบรลล์เซลล์เดียว “ร+ฤ”), “ฦ” (พ้องรูปกับอักษรเบรลล์เซลล์เดียว “ล+ฦ”)

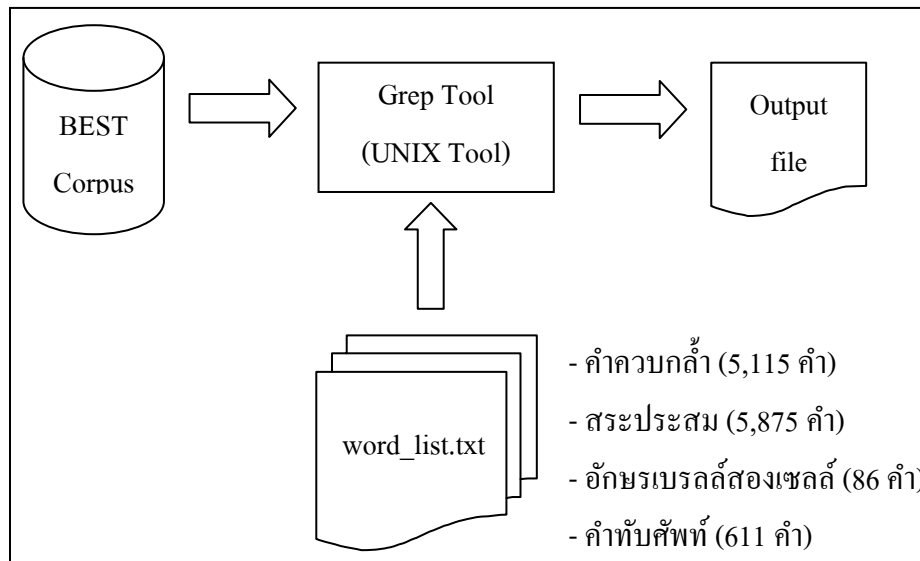
- 4) ประโยคที่ประกอบด้วยคำทับศัพท์ จะคัดเลือกเฉพาะคำทับศัพท์ที่บรรจุไว้ในพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ.2542 [16] เท่านั้น

ในการเลือกประโยคประเภทต่างๆ ดังที่ได้กล่าวไว้ในข้างต้นจากคลังข้อความ BEST ผู้วิจัยเลือกใช้เครื่องมือที่ชื่อว่า grep ซึ่งเป็นยูนิคซ์ทูล (UNIX tool) หรือเครื่องมือหนึ่งที่เป็นโปรแกรมย่อยของระบบปฏิบัติการยูนิคซ์ ที่สามารถคัดเลือกข้อความที่ต้องการได้โดยใช้นิพจน์ (Regular expression) หรือใช้รายการคำ (Word list) ในการค้นหาประโยคที่ตรงกับเงื่อนไขที่ผู้ใช้สร้างไว้

ในงานวิจัยนี้ได้เลือกใช้วิธีคัดเลือกประโยคที่ต้องการโดยใช้รายการคำ เพราะไม่สามารถสร้างนิพจน์ให้ครอบคลุมชนิดของประโยคที่ต้องการคัดเลือกจากคลังข้อความ BEST ได้ทั้งหมด และเนื่องจากปัจจุบันยังไม่มีการรวบรวมรายการคำประเภทคำควบกล้ำ, คำที่มีการใช้สระประสม, คำที่มีการใช้อักษรเบรลล์สองเซลล์และคำทับศัพท์

ดังนั้นผู้วิจัยจึงจำเป็นต้องสร้างรายการคำดังกล่าวด้วยตนเอง ซึ่งรายการคำเหล่านี้ได้นำมาจากพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ.2542 [16] โดยคัดเลือกเฉพาะคำที่เป็นคำควบกล้ำ, คำที่มีการใช้สระประสม, คำที่มีการใช้อักษรเบรลล์สองเซลล์และคำทับศัพท์ และเก็บไว้ในไฟล์ชื่อ word\_list.txt โดยประกอบไปด้วยคำควบกล้ำจำนวน 5,115 คำ, สระประสมจำนวน 5,875 คำ, อักษรเบรลล์สองเซลล์จำนวน 86 คำและคำทับศัพท์จำนวน 611 คำ เมื่อสร้างรายการคำที่ต้องการได้แล้ว ผู้วิจัยจึงนำรายการคำดังกล่าวเป็นเงื่อนไขในการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST โดยใช้โปรแกรมย่อย grep ในการค้นหาประโยคที่ต้องการจากคลังข้อความ BEST และใช้งานบนระบบปฏิบัติการลินุกซ์อูบันตุ (Linux Ubuntu) เวอร์ชัน 9.04 โดยมีภาพรวมการทำงานดังแสดงในรูปที่ 3.2





รูปที่ 3.2 ภาพรวมวิธีการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST

จากภาพรวมวิธีการคัดเลือกประโยคที่ต้องการในรูปที่ 3.2 ผู้วิจัยได้เรียกใช้เครื่องมือ grep โดยใช้คำสั่ง “`grep -f word_list.txt file_name.txt > output_file.txt`” ใน Shell prompt โดยระบุออฟชัน `-f` หมายถึงระบุให้นำรายการคำที่อยู่ในไฟล์ `word_list.txt` คือไฟล์ที่บรรจุรายการคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ที่ผู้วิจัยได้คัดเลือกมาจากพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ.2542 มาใช้ค้นหาประโยคในคลังข้อความ BEST ที่มีการใช้คำเหล่านั้นอยู่ในประโยค โดยไฟล์ชื่อ `file_name.txt` คือไฟล์ในคลังข้อความ BEST และสัญลักษณ์ `>` หมายถึงกำหนดให้โปรแกรมย่อย grep เขียนเอาท์พุทที่ได้ใส่ไว้ในไฟล์ที่ชื่อว่า `output_file.txt` และมีรายละเอียดของผลการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST ดังแสดงในตารางที่ 3.2

ตารางที่ 3.2 รายละเอียดการคัดเลือกประโยคที่ต้องการจากคลังข้อความ BEST

ประเภทของคำ ที่ใช้คัดเลือก ข้อความ	จำนวนคำที่ ใช้คัดเลือก (คำ)	ประเภทข้อความที่คัดเลือกจากคลังข้อความ BEST (คลังข้อความ BEST มีขนาดไฟล์ทั้งหมด 71.8 MB)				รวมทั้งหมดคิด เป็นเปอร์เซ็นต์
		ประเภท บทความ (ขนาด)	ประเภทสารานุกรม ไทยสำหรับเยาวชน (ขนาด)	ประเภทบทความ ข่าว(ขนาด)	ประเภท นวนิยาย (ขนาด)	
คำควบกล้ำ	5,115	7.76 MB	7.50 MB	9.59 MB	7.95 MB	45.68 %
สระประสม	5,875	7.59 MB	7.29 MB	9.31 MB	7.73 MB	44.43 %
อักษรเบรลล์ สองเซลล์	86	97.2 KB	32.6 KB	173 KB	768 KB	1.45 %
คำทับศัพท์	611	529 KB	807 KB	861 KB	589 KB	3.79 %

จากตารางที่ 3.2 เห็นได้ว่าคำควบกล้ำและสระประสมมีการใช้งานในประโยคประเภทต่างๆ ในภาษาไทยมากที่สุดโดยคิดเป็น 45.68 % และ 44.43 % ตามลำดับ ซึ่งมีขนาดประมาณเกือบครึ่งหนึ่งของคลังข้อความ BEST โดยคำควบกล้ำบางคำก็อาจรวมอยู่ในคำที่มีสระประสมและแม้ว่าจะมีการใช้งานอักษรเบรลล์สองเซลล์และคำทับศัพท์น้อยมาก แต่ก็ยังมีจำนวนการใช้งานอยู่พอสมควร จึงทำให้ปัญหาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยดังที่ได้กล่าวไว้แล้ว นับได้ว่าเป็นปัญหาที่มีความสำคัญเช่นกัน

เมื่อได้ไฟล์เอาต์พุตตามที่ต้องการแล้วผู้วิจัยจึงนำไฟล์ทั้งหมดดังกล่าวไปแปลงให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 โดยใช้โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ [1] ซึ่งเป็นโปรแกรมที่มีการพัฒนามาก่อนแล้ว (รายละเอียดของโปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์จะอธิบายในหัวข้อที่ 2.8) เพื่อนำไปสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยต่อไป ซึ่งตัวอย่างประโยคที่ได้คัดเลือกมาจากคลังข้อความ BEST และตัวอย่างประโยคที่ถูกแปลงให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 แสดงในรูปที่ 3.3 และ 3.4 ตามลำดับ

ตัวอย่างประโยคภาษาไทย  
การพัฒนา	วิจัย	รถ	แทรกเตอร์	หลาย	แบบ				
ประกอบ	ด้วย	กระบะ	เมล็ด	พืช	ที่	บรรจุ	อยู่	บน	ตะแกรง
กลายเป็น	ผู้	กระทำ	ความ	ผิด	ฐาน	บุกรุก	อุทยาน	แห่งชาติ	
มีการ	เคลื่อนย้าย	ทรัพยากร	ที่เป็น	วัตถุ	ดิบ	ของ	ระบบ	การ	ผลิต

รูปที่ 3.3 ตัวอย่างประโยคที่คัดเลือกจากคลังข้อความ BEST

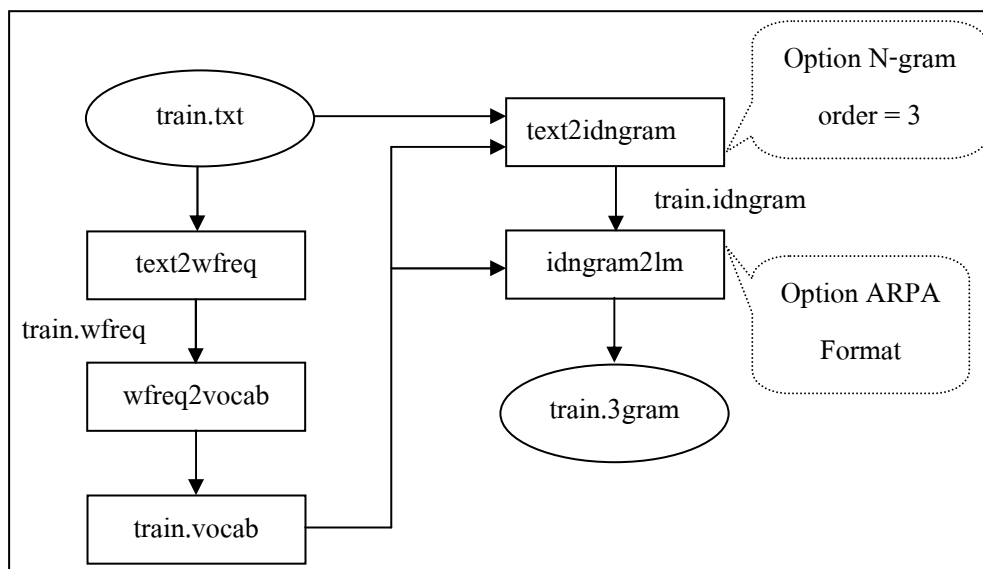
ตัวอย่างประโยคที่แปลงเป็นอักษรเบรลล์ภาษาไทยระดับ 1  
g\*r	?>-)n\*	wbj>y	rt	<rg	%r0	hl\*y	<vv					
&ragov	d4wy	grava	fml'd	?5+	)29	vrrjc	oy39	vn		a<gr}		
gl\*y	f&'n	p34	gra)z	uw\*m	pbd	,t\*n	vcgrcg	oc)y\*n	<h9}	+\*	b	
m2	g\*r	ulq9ny4\*y	)r>?y\*gr	)29	f&'n	w>	tc	dbv	ko}	ravv	g\*r	plb

รูปที่ 3.4 ประโยคที่แปลงให้อยู่ในรูปของอักษรเบรลล์ภาษาไทย

### 3.3.2 การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย

การสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยหรือการฝึกฝนเอ็นแกรมโมเดล [18] คือกระบวนการทางสถิติเพื่อให้เอ็นแกรมโมเดลคำนวณค่าความน่าจะเป็นของคำหนึ่งๆ ว่าสามารถที่จะเกิดขึ้นร่วมกับคำใดได้บ้าง โดยมีขั้นตอนย่อยๆ อยู่หลายขั้นตอนด้วยกัน ซึ่งจะอธิบายโดยใช้แผนภาพในภายหลังและผลที่ได้จากการฝึกฝนเอ็นแกรมโมเดลนี้จะได้เป็นไฟล์นามสกุล .gram และในไฟล์ .gram นี้จะบรรจุค่าความน่าจะเป็นของคำนั้นๆ ว่ามีโอกาสที่จะเกิดขึ้นร่วมกับคำใดได้บ้างด้วยค่าความน่าจะเป็นเท่าไร และบรรจุค่าดัชนีถ่วงน้ำหนัก (Back-off weight) ที่จะนำไปใช้ในกระบวนการ Smoothing อีกด้วย โดยมีการจัดเก็บให้อยู่ในรูปแบบของ ARPA format [19] ซึ่งเป็นรูปแบบไฟล์มาตรฐานของโมเดลภาษา (Language Model) และในงานวิจัยที่นำเสนอนี้ได้เลือกชุดเครื่องมือที่เรียกว่า CMU-SLM toolkit [20] ซึ่งเป็นชุดเครื่องมือที่ช่วยสร้างโมเดลภาษา อีกทั้งชุดเครื่องมือนี้มีการเผยแพร่เป็นสาธารณะ และมีการนำไปใช้งานกันอย่างแพร่หลาย โดยสามารถใช้งานได้ง่าย มีคู่มืออธิบายชัดเจน และเป็นชุดเครื่องมือที่ครบถ้วนสมบูรณ์ (รายละเอียดของชุด

เครื่องมือ CMU-SLM toolkit จะอธิบายในหัวข้อ 2.7) โดยมีขั้นตอนการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยดังแสดงในรูปที่ 3.5



รูปที่ 3.5 ขั้นตอนการสร้างโมเดลอักษรเบรลล์ภาษาไทยด้วยชุดเครื่องมือ CMU-SLM toolkit [18]

จากรูปที่ 3.5 มีขั้นตอนการสร้างโมเดลอักษรเบรลล์ภาษาไทยดังต่อไปนี้

1. สร้างไฟล์ train.wfreq จาก train.txt ด้วยฟังก์ชัน text2wfreq โดยไฟล์ train.wfreq จะเป็นไฟล์ที่เก็บคำที่มีทั้งหมดใน train.txt พร้อมทั้งค่าความถี่ของคำแต่ละคำ
2. สร้างไฟล์ train.vocab จาก train.wfreq ด้วยฟังก์ชัน wfreq2vocab โดยไฟล์ train.vocab จะเป็นรายการของคำ (Vocabulary) ทั้งหมดที่มีอยู่ในไฟล์ train.txt
3. สร้างไฟล์ train.idngram โดยอาศัยไฟล์ train.vocab และไฟล์ train.txt ด้วยฟังก์ชัน text2idngram โดยไฟล์ train.idngram จะเป็น Binary file ที่เก็บ Index ของ N-gram ที่เกิดใน train.txt ซึ่งจะต้องระบุชั้น Order ของ N-gram โดยระบุหลัง option -n เช่น -n 3 คือ กำหนดว่าจะสร้าง N-gram order ที่ N เท่ากับ 3 ซึ่งก็คือ Trigram
4. สร้างไฟล์ train.3gram จาก train.idngram และ train.vocab ด้วยฟังก์ชัน idngram2lm โดยไฟล์ train.3gram จะเป็นรูปแบบไฟล์ N-gram ที่นำไปใช้ ซึ่งถูกจัดเก็บให้อยู่ในรูปแบบของ ARPA format ซึ่งการระบุ Option -arpa จะได้ไฟล์เอาต์พุตในรูปแบบของ

ARPA format และการระบุ Option `-binary` จะได้ไฟล์เอาต์พุตในรูปแบบของ Binary format

เมื่อสร้างโมเดลอักษรเบรลล์ภาษาไทยเสร็จแล้วจะได้ไฟล์นามสกุล `.gram` ซึ่งผู้วิจัยจะนำไฟล์นี้ไปใช้งานต่อไป โดยตัวอย่างของไฟล์โมเดลอักษรเบรลล์ภาษาไทยแสดงในรูปที่ 3.6

ตัวอย่างไฟล์โมเดลอักษรเบรลล์ภาษาไทย (gram=3)

```

\1-grams:
...
-5.1338 !*g1 0.2118
-5.6109 !*ivr!* 0.3348
...
\2-grams:
...
-1.5478 )zn(vr>,tv*1 gra)rw}fg-s|rl<ashgr,n0 0.5339
-1.5478 )zn(vr>,tv*1 sn*mhlw} -0.1462
...
\3-grams:
...
-0.5000 <m9 ;l <n9non
-0.3346 <m9 ?29 n4o}
...

```

รูปที่ 3.6 ตัวอย่างไฟล์โมเดลอักษรเบรลล์ภาษาไทย

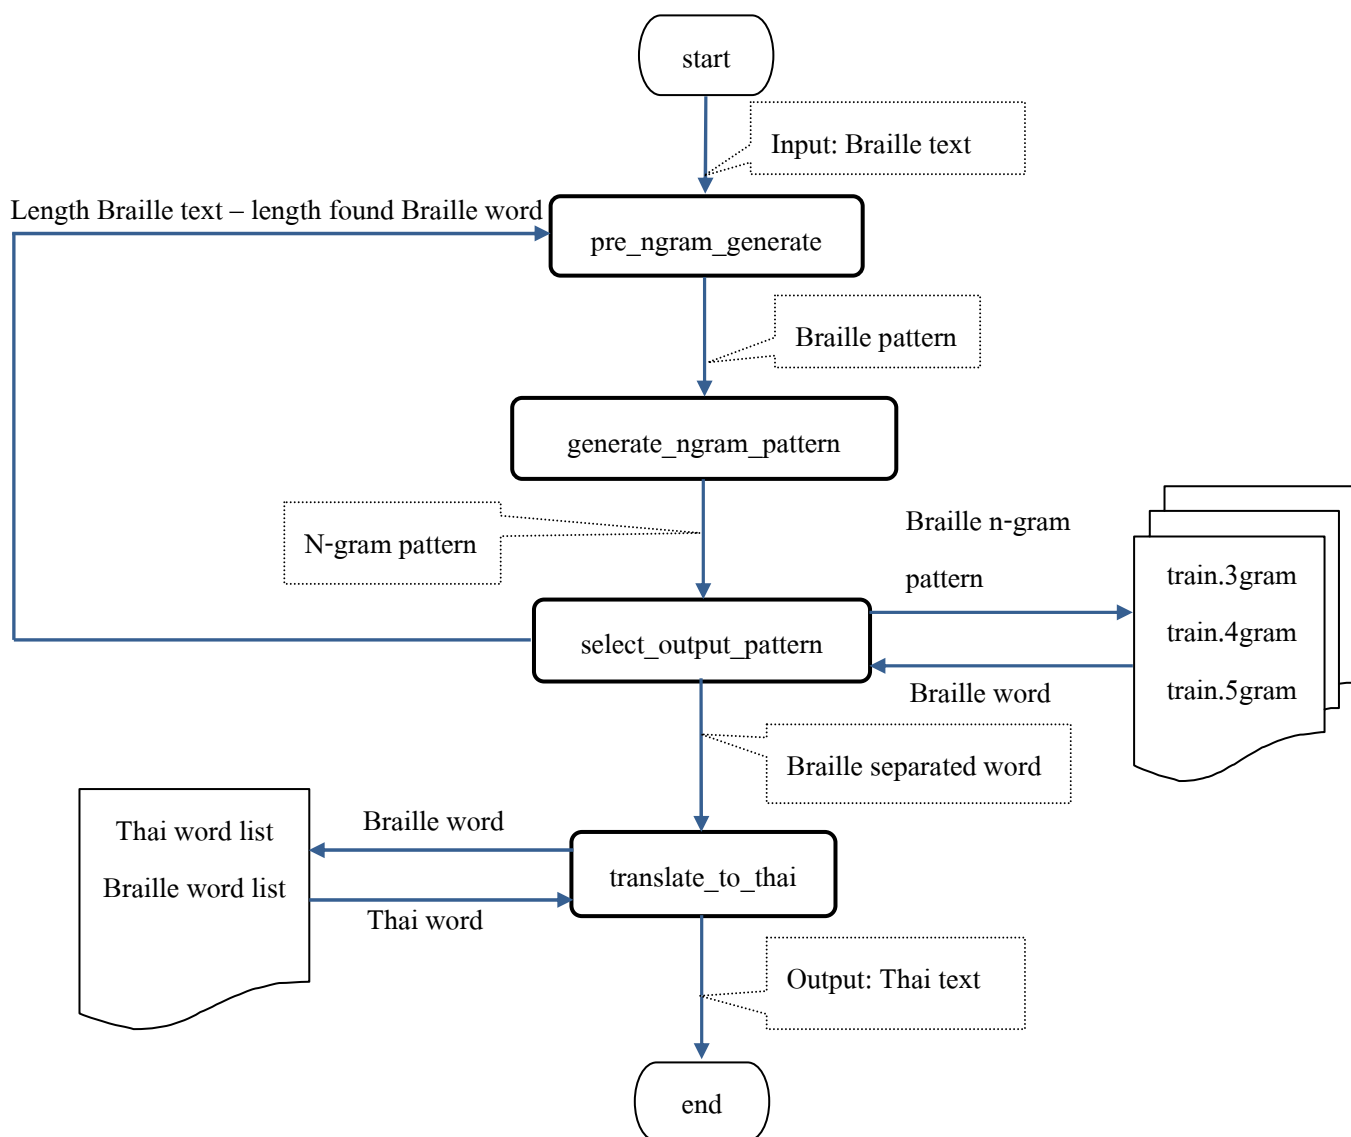
ในรูปที่ 3.6 เป็นตัวอย่างไฟล์โมเดลอักษรเบรลล์ภาษาไทยโดยใช้จำนวนแกรมเท่ากับ 3-แกรม ซึ่งภายในไฟล์จะมีการเรียงลำดับตั้งแต่ 1-gram, 2-gram ไปจนถึง 3-gram และหากในขั้นตอนที่ 3 ในการสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทยถ้าผู้ใช้ได้ระบุตัวเลขจำนวนแกรมเป็น

$n$  แกรม ( $n$  เป็นจำนวนนับ) ภายในไฟล์เอ็นแกรม โมเดลที่ฝึกฝนเสร็จแล้วก็จะมีการเรียงลำดับตั้งแต่ 1-gram, 2-gram ไปเรื่อยๆ จนถึงจำนวนแกรมที่ผู้ใช้ได้กำหนดไว้นั่นเอง และในคอลัมน์ซ้ายสุดจะเป็นค่าความน่าจะเป็นที่พบรูปแบบคำนั้นๆ ซึ่งค่าความน่าจะเป็นนี้จะเห็นได้ว่าติดลบ นั่นก็เพราะค่าความน่าจะเป็นนั้นมีค่าที่น้อยมากๆ เมื่อนำไปคำนวณแล้วจะทำให้มีค่าน้อยมากจนแทบจะเป็นศูนย์ จึงมีการจัดรูปแบบใหม่โดยใช้ลอการิทึมฐานสิบ ( $\log_{10}$ ) จึงทำให้ค่าความน่าจะเป็นติดลบ คอลัมน์ตรงกลาง (เป็นส่วนที่มีตัวอักษรและสัญลักษณ์) เป็นรายการของคำอักษรเบรลล์ภาษาไทยระดับ 1 ที่มีอยู่ในคลังข้อมูลที่ผู้วิจัยได้นำมาสร้างไฟล์โมเดลอักษรเบรลล์ภาษาไทย ซึ่งรายการคำที่แสดงอยู่มีความหมายว่า คำที่อยู่หลังสุดซึ่งแบ่งโดยการเว้นวรรคนั้น จะเกิดขึ้นร่วมกับคำอื่นๆ ที่อยู่ก่อนหน้าด้วยค่าความน่าจะเป็นที่แสดงไว้ในคอลัมน์ซ้ายสุด และในคอลัมน์ขวาสุดที่เป็นตัวเลขเป็นค่าที่แสดงถึงค่าดัชนีถ่วงน้ำหนัก (Back-off weight) คือค่าถ่วงน้ำหนักเมื่อคำหรือชุดของคำไม่มีอยู่หรือไม่พบในคลังข้อความ โดยจะนำค่านี้ไปใช้ในการประมาณค่าความน่าจะเป็นตามหลักวิธีการของ Smoothing ซึ่งค่าดัชนีถ่วงน้ำหนักนี้จะนำไปแทนค่าตัวแปร  $\lambda_{w_{i-n+1}^{i-1}}$  ในสมการที่ 5 แต่จะไม่มีค่าดัชนีถ่วงน้ำหนักในกลุ่มจำนวนแกรมที่ผู้ใช้ได้ระบุไว้ในขั้นตอนที่ 3 (ในที่นี้คือกลุ่มคำที่อยู่ในช่วง 3-gram) นั่นเป็นเพราะว่าหากพบชุดของคำที่เขียนเรียงติดกันที่อยู่ในช่วง 3-gram ก็จะมีค่าความน่าจะเป็นเท่ากับค่าในคอลัมน์ซ้ายสุดนั่นเอง และหากไม่พบจะนำเอาค่าดัชนีถ่วงน้ำหนักในช่วง 2-gram และ 1-gram ไปคำนวณหาค่าความน่าจะเป็น โดยวิธีการของ Smoothing technique ต่อไป

### 3.4 ภาพรวมของระบบที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้

ในวิทยานิพนธ์นี้ได้นำเสนอวิธีการปรับปรุงประสิทธิภาพในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยในรูปแบบ File-to-file โดยนำเทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำอักษรเบรลล์ภาษาไทยเพื่อลดความกำกวมที่เกิดขึ้นจากลักษณะการเขียนของอักษรเบรลล์ภาษาไทยระดับ 1 จากนั้นแปลงให้เป็นภาษาไทยโดยใช้วิธีเทียบแบบคำต่อคำ ซึ่งจำเป็นจะต้องสร้างรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยไว้ล่วงหน้า

ในรูปที่ 3.7 แสดงองค์ประกอบต่างๆ ของระบบที่ได้ออกแบบไว้และลักษณะการเชื่อมต่อกันของฟังก์ชันหลักรวมทั้งการเชื่อมต่อองค์ประกอบอื่นๆ ที่จำเป็นต้องใช้ร่วมในการแปลงอักษรเบรลล์ภาษาไทยระดับ 1 ไปเป็นภาษาไทย



รูปที่ 3.7 ภาพรวมโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย  
ที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ

ในรูปที่ 3.7 เป็นภาพรวมของโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ โดยโปรแกรมนี้รับอินพุตเข้ามาเป็นข้อความที่เขียนอยู่ในรูปอักษรเบรลล์ภาษาไทยระดับ 1 ซึ่งจะแบ่งประโยคออกเป็นส่วนๆ ตามจำนวนแกรมที่ได้กำหนดไว้ (pre\_ngram\_generate) และนำไปสร้างรูปแบบเอ็นแกรม (generate\_ngram\_pattern) จากนั้นนำรูปแบบเอ็นแกรมไปเปรียบเทียบกับไฟล์โมเดลอักษรเบรลล์ภาษาไทยเพื่อตัดคำอักษรเบรลล์ภาษาไทย (select\_output\_pattern) และแปลงให้เป็นประโยค

ภาษาไทย (translate\_to\_thai) โดยวิธีเทียบคำซึ่งใช้งานร่วมกับรายการคำภาษาไทยและรายการคำอักษรเบรลล์ภาษาไทย โดยแต่ละส่วนจะมีการเชื่อมต่อกันดังที่แสดงในรูปที่ 3.7 ซึ่งรายละเอียดการทำงานของแต่ละขั้นตอนต่างๆ จะอธิบายไว้ในหัวข้อที่ 3.6 และในหัวข้อที่ 3.5 จะอธิบายถึงรายละเอียดของอินพุตและเอาต์พุตของโปรแกรมที่น่าเสนอนี้

### 3.5 อินพุตและเอาต์พุตของระบบ

โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้รับอินพุตเป็นไฟล์ข้อความธรรมดา ซึ่งภายในได้บรรจุข้อความที่เขียนให้อยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 โดยการทำงานของโปรแกรมนี้อาจประมวลผลข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ครั้งละ 1 ประโยค โดยจะแบ่งแต่ละประโยคออกจากกันด้วยการเว้นวรรค ทั้งนี้เนื่องมาจากลักษณะไวยากรณ์ของอักษรเบรลล์ภาษาไทยระดับ 1 จะใช้การเว้นวรรคในการแบ่งประโยคออกจากกันเช่นเดียวกันกับการเขียนภาษาไทย เมื่อโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำประมวลผลเสร็จแล้ว จะได้เอาต์พุตเป็นประโยคภาษาไทย และนำประโยคภาษาไทยที่ได้เขียนใส่ในไฟล์เอาต์พุตตามที่ผู้ใช้งานได้ตั้งชื่อไฟล์เอาไว้ ซึ่งจะเป็นไฟล์ข้อความธรรมดา และการทำงานของโปรแกรมจะเป็นเช่นนี้ไปเรื่อยๆ จนกว่าข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ในไฟล์อินพุตจะหมดลง สำหรับวิธีการประมวลผลของโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ได้อธิบายไว้ในหัวข้อที่ 3.6

### 3.6 โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้

ในหัวข้อนี้จะอธิบายถึงขั้นตอนต่างๆ ของโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้รวมถึงชื่อและชนิดของตัวแปรต่างๆ ที่ใช้ในการเก็บข้อมูลและใช้ในการประมวลผล ซึ่งประกอบไปด้วย 4 ขั้นตอนดังนี้

#### 3.6.1 ขั้นตอน pre\_ngrams\_generate

ขั้นตอน pre\_ngram\_generate นี้เป็นขั้นตอนเพื่อเตรียมข้อมูลให้เหมาะสมสำหรับสร้างรูปแบบเอ็นแกรม (N-gram pattern) โดยรับอินพุตเข้ามาเป็นประโยคอักษรเบรลล์ภาษาไทยระดับ 1 และตัดออกเป็นส่วนๆ ตามขนาดจำนวนแกรมที่ได้กำหนดไว้ เช่น หากกำหนดไว้เป็น 4 แกรม



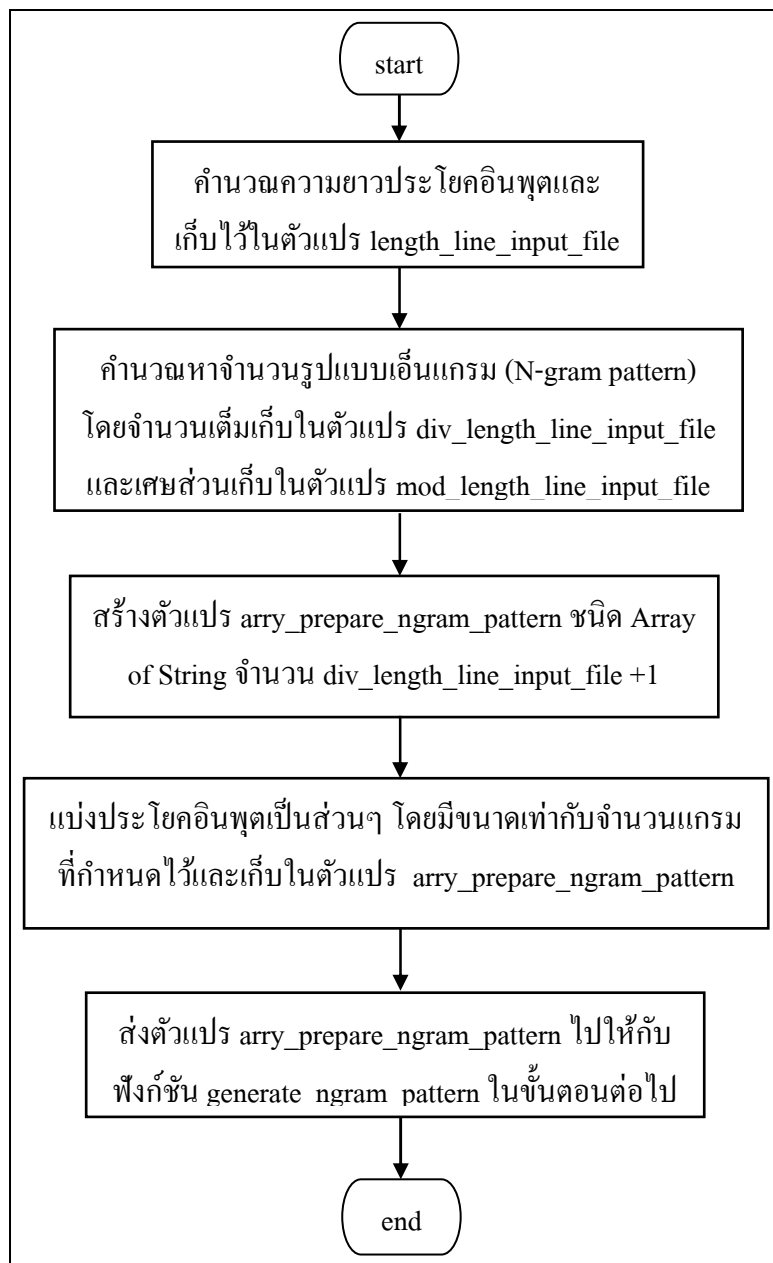
ขั้นตอนนี้จะแบ่งประโยคอินพุตดังกล่าวออกเป็นส่วนๆ และแต่ละส่วนจะมีจำนวนอักขระเท่ากับ 4 อักขระ และแบ่งเช่นนี้ไปเรื่อยๆ จนจบความยาวของประโยค หากประโยคอินพุตเหลือเศษของอักขระอยู่ส่วนสุดท้ายที่แบ่งออกมาก็จะเหลือเท่ากับจำนวนอักขระที่เหลือนั้น

ผู้วิจัย ได้ออกแบบให้ขั้นตอนนี้ให้เป็นฟังก์ชันหนึ่งๆ ซึ่งรับอินพุตเข้ามาครั้งละหนึ่งประโยค โดยอยู่ในรูปแบบของประโยคอักษรเบรลล์ภาษาไทยระดับ 1 และให้อาชีพพุทเป็นอาร์เรย์ของสตริง (Array of string) ที่บรรจุส่วนของประโยคที่ถูกแบ่งออกมาจากประโยคอินพุต ซึ่งมีการประกาศฟังก์ชันเป็น `int prepare_ngram_pattern(string line_input_file)` และมีการกำหนดตัวแปรพร้อมทั้งหน้าที่ดังแสดงในตารางที่ 3.3

ตารางที่ 3.3 รายละเอียดของตัวแปรในขั้นตอน `pre_ngrams_generate`

ชนิดของตัวแปร	ชื่อของตัวแปร	หน้าที่ของตัวแปร
Integer	<code>length_line_input_file</code>	เก็บค่าความยาวของประโยคอินพุต
Integer	<code>index_start</code>	เก็บค่าตำแหน่งเริ่มต้นของรูปแบบเอ็นแกรม
Integer	<code>div_length_line_input_file</code>	เก็บค่าจำนวนเต็มของความยาวประโยคอินพุต
Integer	<code>mod_length_line_input_file</code>	เก็บค่าจำนวนเศษของความยาวประโยคอินพุต
Global Array of String	<code>arry_prepare_ngram_pattern</code>	เก็บรูปแบบเอ็นแกรมที่ได้สร้างไว้ (N-gram pattern)
Global Integer	<code>index_arry_prepare_ngram_pattern</code>	เก็บค่าตำแหน่งของเอ็นแกรมที่ได้สร้างไว้

และผู้วิจัย ได้ออกแบบวิธีการเตรียมข้อมูล โดยมีขั้นตอนการทำงานต่างๆ ดังแสดงในรูปที่ 3.8



รูปที่ 3.8 ขั้นตอน prepare\_ngram\_pattern

จากรูปที่ 3.8 มีรายละเอียดการทำงานต่างๆ ดังต่อไปนี้

1. คำนวณค่าความยาวประโยคอินพุตซึ่งอยู่ในรูปของประโยคอักขรเบรลล์ภาษาไทยระดับ 1 โดยใช้ฟังก์ชัน `length()` และเก็บไว้ในตัวแปร `length_line_input_file`
2. คำนวณจำนวนรูปแบบเอ็นแกรม (N-gram pattern) โดยหาจากนำค่าความยาวประโยคอินพุตที่เก็บไว้ในตัวแปร `length_line_input_file` มาหารด้วยจำนวนแกรมที่ได้กำหนดไว้

โดยหารเอาจำนวนเต็มและเก็บไว้ในตัวแปร `div_length_line_input_file` และหารเอาเศษและเก็บไว้ในตัวแปร `mod_length_line_input_file`

3. สร้างตัวแปร `arry_prepare_ngram_pattern` ชนิด Array of String เพื่อเก็บรูปแบบเอ็นแกรม (N-gram pattern) จำนวน `div_length_line_input_file+1`
4. แบ่งประโยคอินพุตเป็นส่วนๆ โดยแต่ละส่วนมีจำนวนอักขระเท่ากับจำนวนแกรมที่ได้กำหนดไว้และเก็บไว้ในตัวแปร `arry_prepare_ngram_pattern` ที่ได้สร้างเอาไว้ และส่งค่าตัวแปร `arry_prepare_ngram_pattern` ไปให้กับขั้นตอน `generate_ngram_pattern`

### 3.6.2 ขั้นตอน `generate_ngram_pattern`

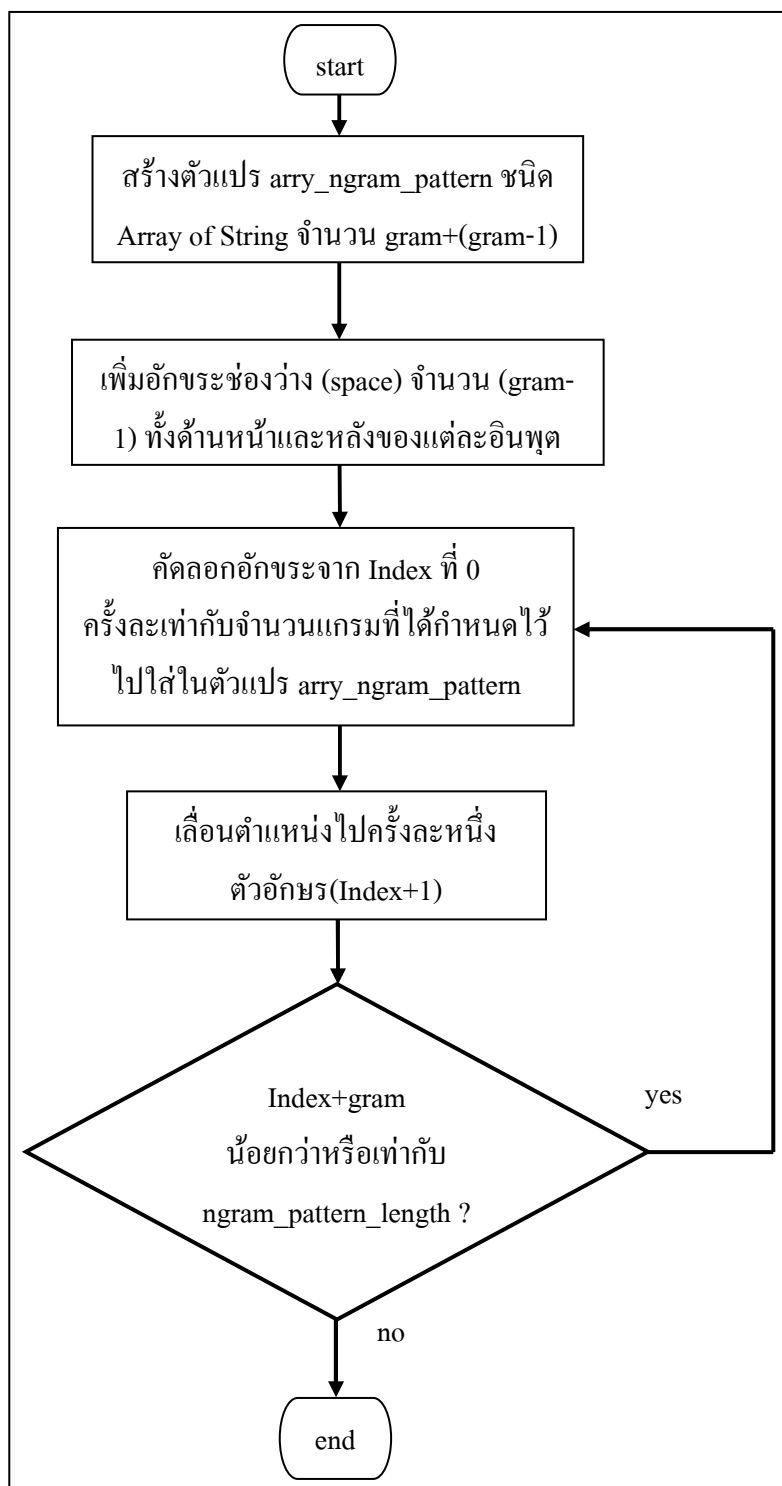
ขั้นตอน `generate_ngram_pattern` นี้เป็นขั้นตอนสร้างรูปแบบเอ็นแกรม (N-gram pattern) เพื่อนำไปเปรียบเทียบกับไฟล์โมเดลอักษรเบรลล์ภาษาไทยซึ่งจะอธิบายในหัวข้อที่ 3.7 เอ็นแกรมโมเดล โดยรับอินพุตเข้ามาเป็นส่วนหนึ่งของประโยคที่ได้จากขั้นตอน `prepare_ngram_pattern` และเพิ่มอักขระช่องว่าง (Space) ทั้งด้านหน้าและด้านหลังจำนวน `gram-1` เพื่อเพิ่มอัตราจับคู่คำโดยขั้นตอนการสร้างรูปแบบเอ็นแกรมได้นำมาจากเว็บไซต์ [ejeepss.wordpress.com](http://ejeepss.wordpress.com) [28] และส่งชุดของรูปแบบเอ็นแกรมที่ได้ไปให้กับขั้นตอน `select_output_pattern` เพื่อเปรียบเทียบกับไฟล์โมเดลอักษรเบรลล์ภาษาไทยและเลือกเอาที่พุดต่อไป

ผู้วิจัยได้ออกแบบให้ขั้นตอนนี้รับอินพุตเข้ามาครั้งละหนึ่งชุดโดยเป็นส่วนประโยคที่ได้จากขั้นตอน `prepare_ngram_pattern` และให้เอาที่พุดเป็นอาร์เรย์ ของสตริง (Array of String) ที่บรรจุชุดรูปแบบเอ็นแกรม (N-gram pattern) ซึ่งมีการประกาศฟังก์ชันเป็น `int gen_ngram_pattern(string ngram_pattern)` และมีการกำหนดตัวแปรพร้อมทั้งหน้าที่ดังแสดงในตารางที่ 3.4

ตารางที่ 3.4 รายละเอียดของตัวแปรที่ใช้ในขั้นตอน `gen_ngram_pattern`

ชนิดของตัวแปร	ชื่อของตัวแปร	หน้าที่ของตัวแปร
Integer	<code>ngram_pattern_length</code>	เก็บค่าความยาวของอินพุต
Global Array of String	<code>arry_ngram_pattern</code>	เก็บชุดรูปแบบของเอ็นแกรม
Global Integer	<code>index_arry_ngram_pattern</code>	เก็บตำแหน่งของชุดรูปแบบเอ็นแกรม

และผู้วิจัยได้ออกแบบวิธีการสร้างรูปแบบเอ็นแกรม (N-gram pattern) โดยมีขั้นตอนการทำงานต่างๆ ดังแสดงในรูปที่ 3.9

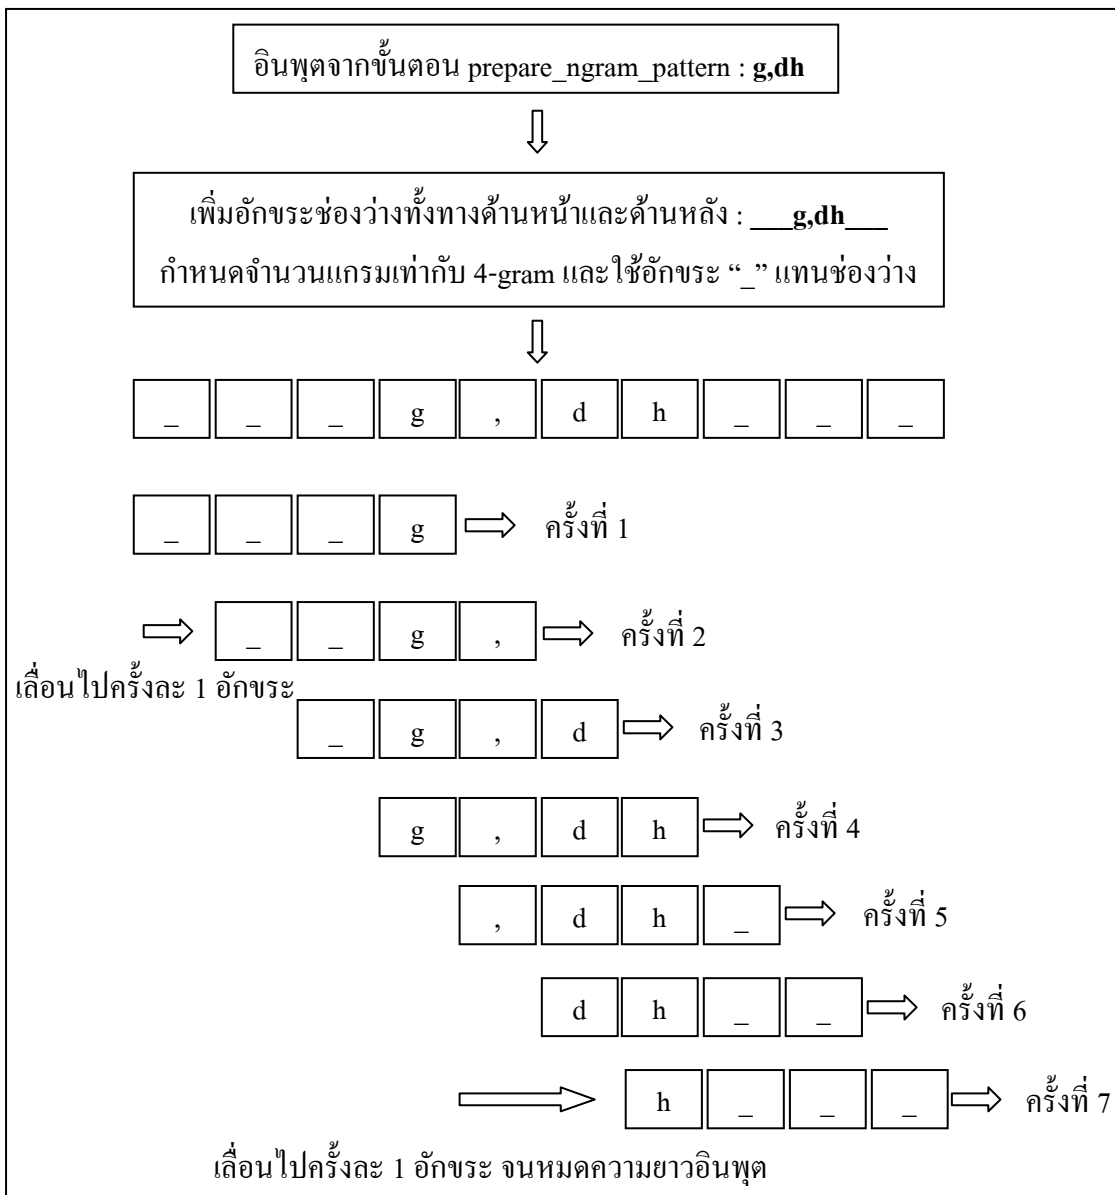


รูปที่ 3.9 ขั้นตอน gen\_ngram\_pattern

จากรูปที่ 3.9 มีรายละเอียดการทำงานต่างๆ ดังต่อไปนี้

1. สร้างตัวแปร `arry_ngram_pattern` ชนิด Array of String จำนวน  $gram+(gram-1)$  ตามที่ได้กำหนดจำนวนแกรมเอาไว้
2. เพิ่มอักขระช่องว่างทั้งทางด้านหน้าและด้านหลังของอินพุตจำนวน  $(gram-1)$  เพื่อเพิ่มอัตราการจับคู่ของคำ ยกตัวอย่างเช่น มีอินพุตเป็น `g,dh` และกำหนดจำนวนแกรมเท่ากับ 4-แกรม จากขั้นตอนนี้จะได้อะไรที่เป็น “`__g,dh__`” (เพื่อให้สังเกตได้ง่ายจะใช้สัญลักษณ์ “`_`” แทนอักขระช่องว่าง)
3. คัดลอกอักขระครึ่งละเท่ากับจำนวนแกรมที่ได้กำหนดไว้ไปในตัวแปร `arry_ngram_pattern` ครึ่งละ 1 ชุดและเลื่อนไปทางด้านขวาครึ่งละ 1 อักขระและคัดลอกอักขระจำนวนครึ่งละเท่ากับจำนวนแกรมที่ได้กำหนดไว้ไปในตัวแปร `arry_ngram_pattern` อีกครั้งจนกว่าจะหมดความยาวของอินพุต
4. ส่งค่าตัวแปร `arry_ngram_pattern` ไปให้กับขั้นตอน `select_output_pattern` ต่อไป

และเพื่อให้ง่ายต่อการทำความเข้าใจผู้วิจัยจึงใช้แผนภาพแสดงขั้นตอนการสร้างรูปแบบเอ็นแกรม ดังแสดงในรูปที่ 3.10



รูปที่ 3.10 การสร้างรูปแบบเอ็นแกรม (N-gram pattern)

ในรูปที่ 3.10 เป็นวิธีการสร้างรูปแบบเอ็นแกรม (N-gram pattern) โดยจะมีลักษณะการทำงานเหมือนกับกล่องที่บรรจุตัวอักษรได้ครั้งละเท่ากับจำนวนแกรมที่ได้กำหนดไว้ ซึ่งในตัวอย่างนี้ได้กำหนดไว้ที่ 4-แกรม โดยกล่องนี้จะคัดลอกอักขระครั้งละ 4 อักขระรวมทั้งอักขระช่องว่างด้วย และเมื่อคัดลอกเสร็จแล้วจะได้เป็น 1 รูปแบบเอ็นแกรมจากนั้นเลื่อนไปด้านขวาครั้งละ 1 อักขระจนจบความยาวของอินพุตก็จะได้รูปแบบเอ็นแกรมทั้งหมดที่เป็นไปได้

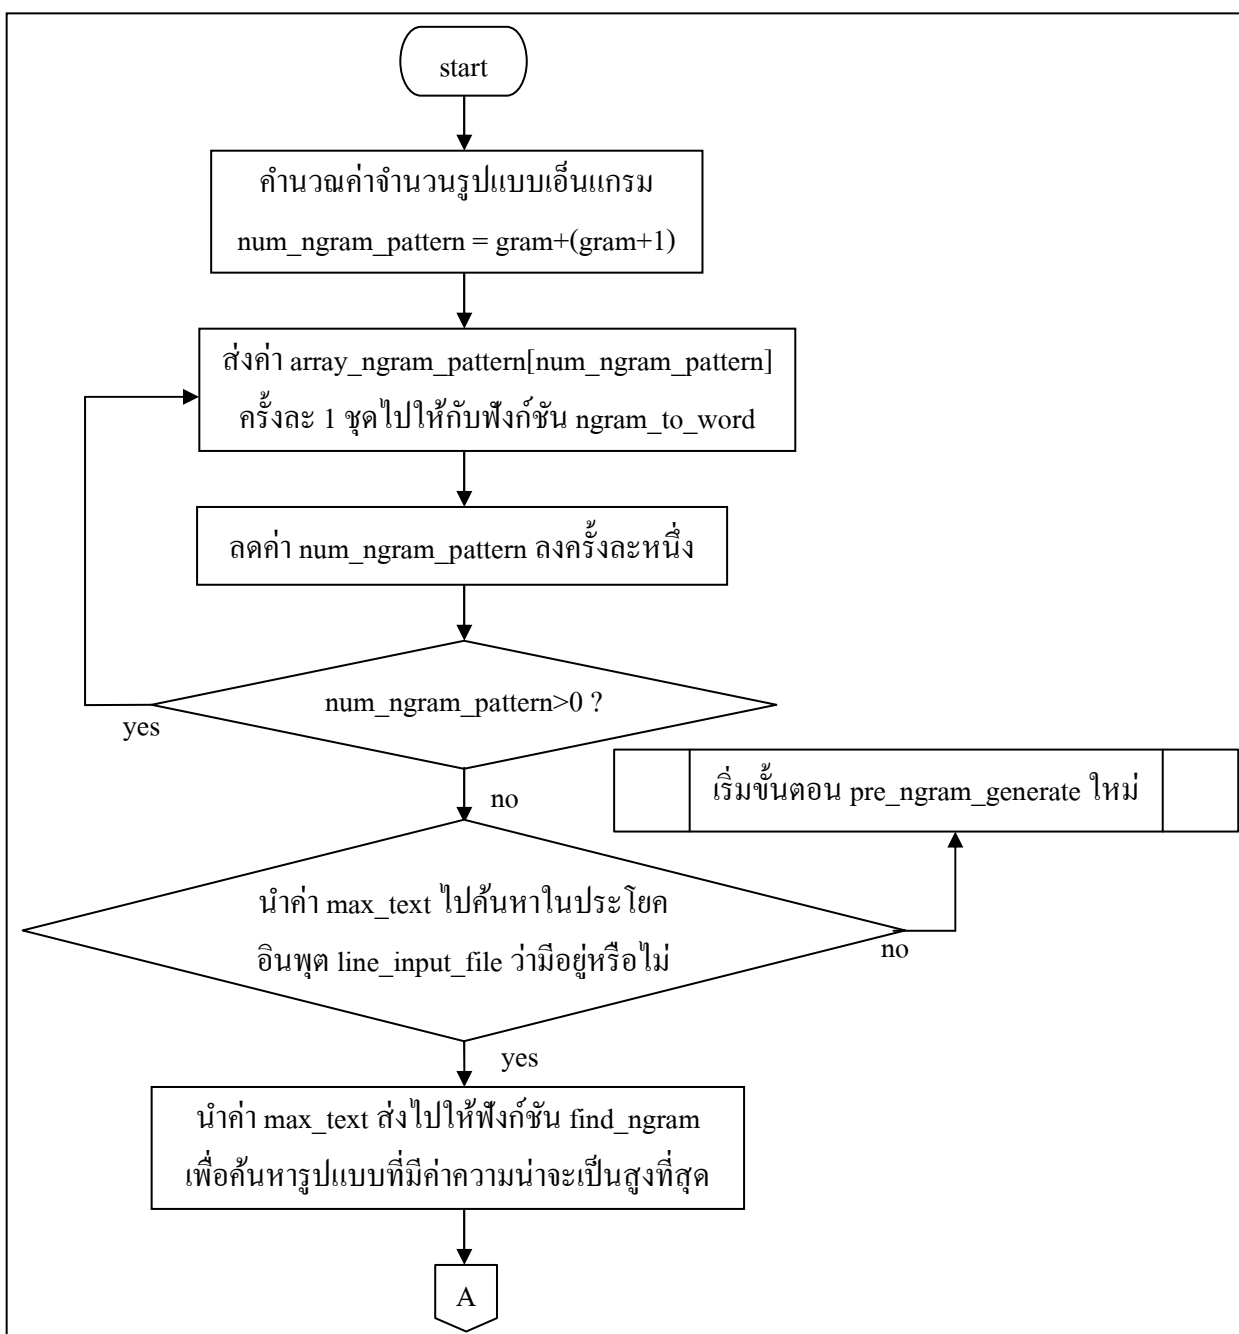
### 3.6.3 ขั้นตอน select\_output\_pattern

ขั้นตอน select\_output\_pattern ทำหน้าที่เปรียบเทียบรูปแบบเอ็นแกรม (N-gram pattern) ที่สร้างมาจากขั้นตอน generate\_ngram\_pattern เพื่อค้นหาคำอักษรเบรลล์ภาษาไทยระดับ 1 ที่มีความคล้ายคลึงกันกับรูปแบบเอ็นแกรมดังกล่าวและค้นหาว่ารูปแบบเอ็นแกรมใดในไฟล์โมเดลอักษรเบรลล์ภาษาไทยจะมีค่าความน่าจะเป็นสูงที่สุด โดยเลือกคำอักษรเบรลล์ภาษาไทยระดับ 1 เป็นเอาท์พุทและแบ่งแต่ละคำออกจากกันด้วยสัญลักษณ์ <pipe> (ใช้สัญลักษณ์ “<pipe>” เพื่อไม่ให้ซ้ำกับสัญลักษณ์ “|” ในอักษรเบรลล์ภาษาไทยที่ใช้แทนตัวอักษร “ด” ในภาษาไทย) เพื่อลดความกำวมของรูปแบบการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 และแปลงให้เป็นประโยคภาษาไทยโดยขั้นตอน translate\_to\_thai อีกครั้ง โดยมีการประกาศฟังก์ชันเป็น void select\_output(string dictionary[],int number\_dictionary\_index,string array\_ngram\_pattern[],int index\_array\_ngram\_pattern) และมีรายละเอียดของตัวแปรและหน้าที่ต่างๆ ของแต่ละตัวแปรดังแสดงในตารางที่ 3.5

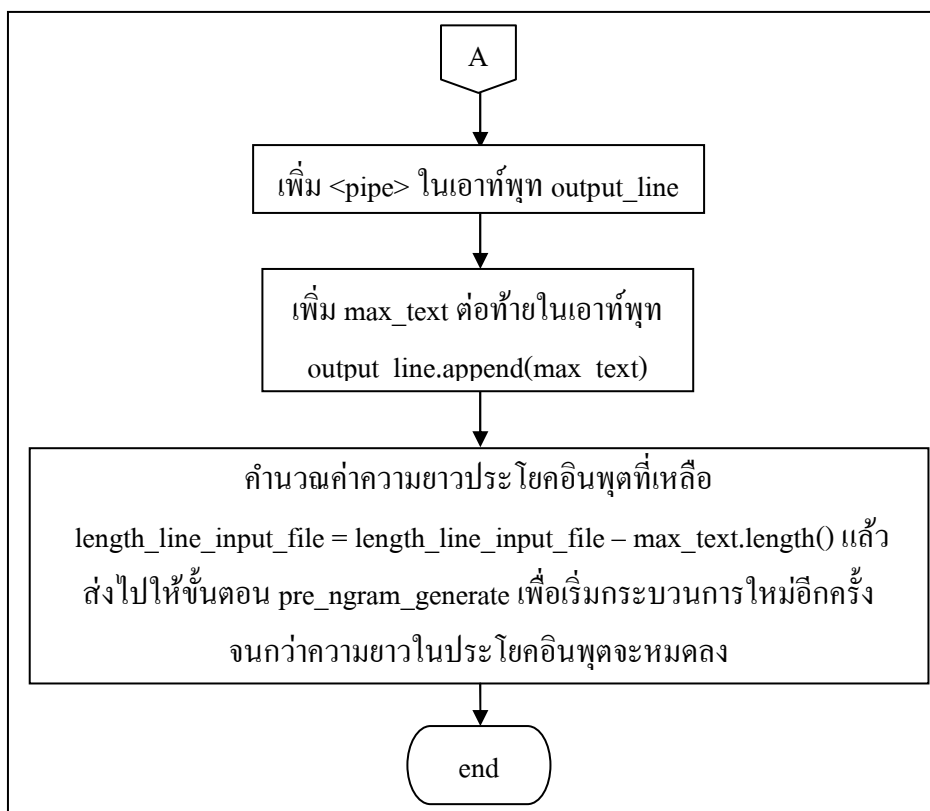
ตารางที่ 3.5 รายละเอียดตัวแปรต่างๆ ที่ใช้ในขั้นตอน select\_output\_pattern

ชนิดของตัวแปร	ชื่อของตัวแปร	หน้าที่ของตัวแปร
Global Integer	max_score	เก็บคะแนนที่มากที่สุด
Global String	max_text	เก็บคำอักษรเบรลล์ที่มีคะแนนมากที่สุด
Global String	max_pattern	เก็บรูปแบบเอ็นแกรมที่ได้คะแนนมากที่สุด
Global Integer	max_text_index	เก็บ index คำอักษรเบรลล์ที่มีคะแนนมากที่สุด
Integer	ngram_pattern_length	เก็บความยาวของรูปแบบเอ็นแกรม
Integer	dictionary_length	เก็บความยาวของคำในรายการคำอักษรเบรลล์ภาษาไทย
Integer	score	เก็บค่าคะแนนของแต่ละคำในปัจจุบัน
Integer	num_ngram_pattern	เก็บจำนวนรูปแบบของเอ็นแกรม
Array of String	array_ngram_pattern	เก็บรูปแบบของเอ็นแกรม
Global String	line_input_file	เก็บประโยคอินพุต
Global String	output_line	เก็บประโยคเอาท์พุท
Global Integer	length_line_input_file	เก็บค่าความยาวของประโยคอินพุต
Global Array of String	word_list_brl	เก็บรายการคำอักษรเบรลล์ภาษาไทย
Global Integer	index_word_list_brl	เก็บ index ของรายการคำอักษรเบรลล์ภาษาไทย
Global Float	max_prob	เก็บค่าความน่าจะเป็นที่มากที่สุด
Float	current_prob	เก็บค่าความน่าจะเป็นของแต่ละคำในปัจจุบัน

ผู้วิจัยได้ออกแบบวิธีการสร้างเอาต์พุทโดยอาศัยข้อมูลต่างๆ จากฟังก์ชันอื่นๆ ซึ่งได้แบ่งฟังก์ชันออกเป็น 3 ฟังก์ชันหลักคือ 1) ฟังก์ชัน select\_output ทำหน้าที่สร้างเอาต์พุทซึ่งเป็นประโยคอักษรเบรลล์ภาษาไทยระดับ 1 ที่แบ่งคำแล้วโดยอาศัยข้อมูลจากฟังก์ชัน ngram\_to\_word และฟังก์ชัน find\_ngram เพื่อใช้ประกอบในการตัดสินใจตัดคำ 2) ฟังก์ชัน ngram\_to\_word ทำหน้าที่คำนวณคะแนนเพื่อเปรียบเทียบรูปแบบเอ็นแกรมว่าคล้ายคลึงกับคำใดมากที่สุด และ 3) ฟังก์ชัน find\_ngram ทำหน้าที่ค้นหารูปแบบของคำในไฟล์โมเดลอักษรเบรลล์ภาษาไทยว่ารูปแบบคำใดมีความน่าจะเป็นสูงที่สุด โดยมีขั้นตอนการทำงานต่างๆ ดังแสดงในรูปที่ 3.11-3.13 ตามลำดับ







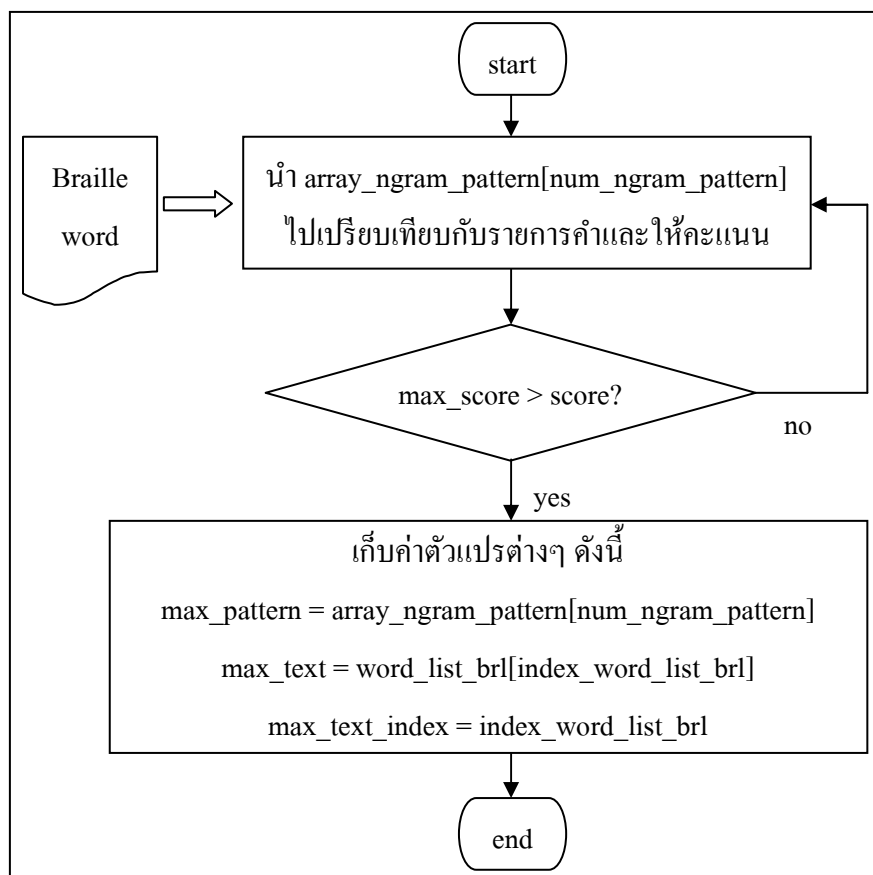
รูปที่ 3.11 ขั้นตอนการทำงานของฟังก์ชัน select\_output

จากรูปที่ 3.11 แสดงขั้นตอนการทำงานของฟังก์ชัน select\_output ซึ่งมีลำดับการทำงานดังนี้

1. ค้นหาจำนวนรูปแบบของเอ็นแกรมจาก  $gram+(gram-1)$  ตามที่ได้กำหนดจำนวนแกรมเอาไว้แล้ว
2. ส่งรูปแบบเอ็นแกรมแต่ละรูปแบบที่เก็บไว้ในตัวแปร array\_ngram\_pattern [num\_ngram\_pattern] ไปให้กับฟังก์ชัน ngram\_to\_word
3. ทำซ้ำขั้นตอนที่ 1 และ 2 จนกระทั่งครบรูปแบบเอ็นแกรมทั้งหมดซึ่งจะได้คำที่มีความคล้ายคลึงกับรูปแบบเอ็นแกรมมากที่สุดซึ่งเก็บไว้ในตัวแปร max\_text
4. ตรวจสอบว่าคำอักษรเบรลล์ภาษาไทยที่เลือกมานั้นพบในประโยคอินพุตหรือไม่ หากไม่พบให้กลับไปเริ่มขั้นตอน pre\_ngram\_generate ใหม่เพื่อสร้างชุดรูปแบบเอ็นแกรมใหม่ และหากพบว่ามีคำนั้นมีอยู่ในประโยคอินพุตให้ส่งค่าๆ นั้นไปให้กับฟังก์ชัน find\_ngram
5. เมื่อส่งค่า max\_text ซึ่งเป็นคำอักษรเบรลล์ภาษาไทยระดับ 1 ที่เลือกจากวิธีเปรียบเทียบความคล้ายคลึงไปให้กับฟังก์ชัน find\_ngram เพื่อค้นหารูปแบบของคำๆ นั้นว่าเกิดขึ้น

ร่วมกับคำๆ ใดได้บ้างและมีค่าความน่าจะเป็นเท่าไร โดยเมื่อผ่านฟังก์ชันนี้แล้วก็จะได้รูปแบบคำที่ใช้ฝึกฝนเอ็นแกรมโมเดลที่มีค่าความน่าจะเป็นสูงที่สุด

6. เพิ่มสัญลักษณ์ “<pipe>” เพื่อเป็นสัญลักษณ์ในการแบ่งคำแต่ละคำออกจากกันลงในประโยคเอาท์พุทซึ่งเก็บไว้ในตัวแปร `output_line`
7. เพิ่มคำที่เลือกมาโดยอาศัยข้อมูลจากฟังก์ชัน `ngram_to_word` และฟังก์ชัน `find_ngram` ซึ่งเก็บไว้ในตัวแปร `max_text` ลงในประโยคเอาท์พุท
8. คำนวณค่าความยาวประโยคอินพุทที่เหลือหลังจากแบ่งคำปัจจุบันเสร็จแล้วกลับไปให้กับขั้นตอน `pre_ngram_generate` เพื่อเริ่มกระบวนการใหม่
9. ทำซ้ำตั้งแต่ขั้นตอน `pre_ngram_generate` จนถึงขั้นตอน `select_output` จนกว่าความยาวของประโยคอินพุทที่เก็บไว้ในตัวแปร `length_line_input_file` จะหมดลง

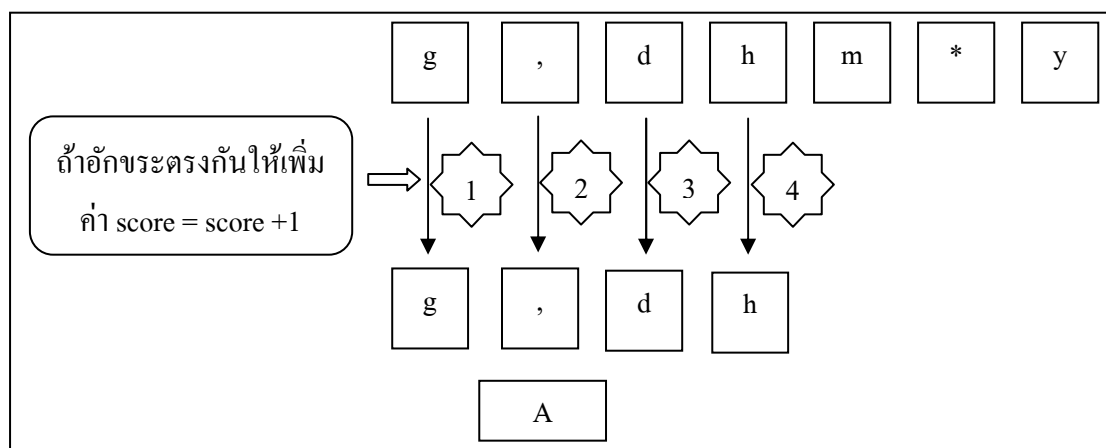


รูปที่ 3.12 ขั้นตอนการทำงานของฟังก์ชัน `ngram_to_word`

ผู้วิจัยได้ออกแบบฟังก์ชัน `ngram_to_word` เพื่อทำหน้าที่เปลี่ยนจากรูปแบบเอ็นแกรม (N-gram pattern) ให้ไปเป็นคำอักษรเบรลล์ภาษาไทยระดับ 1 โดยใช้หลักการของ Pattern Matching และการให้คะแนนความคล้ายคลึง ทั้งนี้เพราะต้องการนำคำอักษรเบรลล์ภาษาไทยดังกล่าวไปค้นหาในรูปแบบของคำในไฟล์โมเดลอักษรเบรลล์ภาษาไทยที่บ่งบอกว่าคำอักษรเบรลล์คำใดสามารถเกิดรวมกันกับคำใดได้บ้างและแต่ละรูปแบบมีค่าความน่าจะเป็นเท่าไร ซึ่งวิธีการทำงานของฟังก์ชัน `ngram_to_word` มีรายละเอียดดังนี้

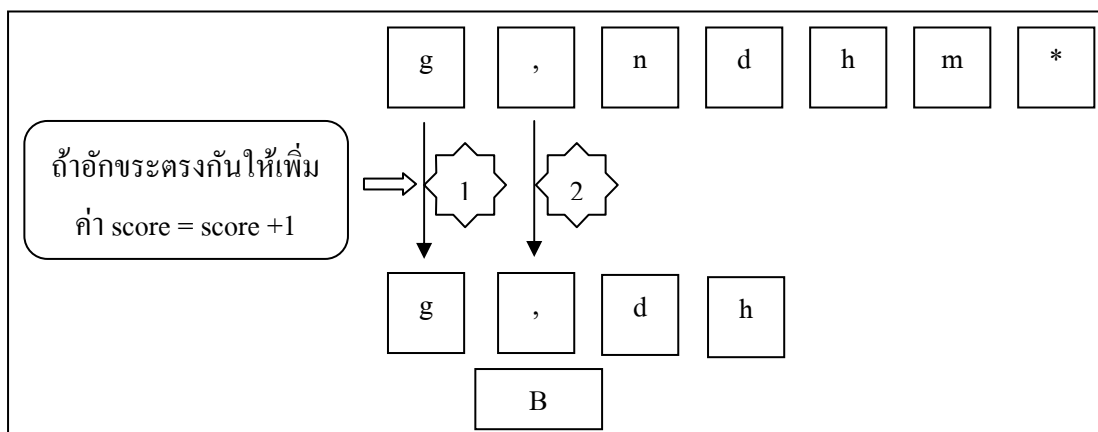
1. นำแต่ละรูปแบบเอ็นแกรม (N-gram pattern) ไปเปรียบเทียบกับรายการคำอักษรเบรลล์ภาษาไทยที่ได้สร้างเอาไว้แล้ว โดยใช้หลักการเช่นเดียวกันกับ Pattern Matching แต่อักขระตัวแรกของรูปแบบเอ็นแกรมจะต้องตรงกันกับอักขระตัวแรกของรายการคำอักษรเบรลล์ภาษาไทยเท่านั้น
2. ให้คะแนนแต่ละรูปแบบเอ็นแกรมโดยหากอักขระตัวแรกตรงกันกับรายการคำอักษรเบรลล์ภาษาไทยก็ให้คะแนน 1 คะแนนและหากตัวถัดๆ ไปตรงกันอีกก็เพิ่มคะแนนเช่นนี้ไปเรื่อยๆ จนหมดความยาวรูปแบบเอ็นแกรมและอักขระของรูปแบบเอ็นแกรมและอักขระของรายการคำอักษรเบรลล์ภาษาไทยที่เหมือนกันต้องมีลักษณะเรียงติดกันไปตลอดไม่มีอักขระอื่นๆ ที่ไม่ตรงกันมาคั่นกลาง
3. หากรูปแบบเอ็นแกรมใดมีค่าคะแนนมากกว่าค่าคะแนนมากที่สุด (`max_score`) ให้เก็บค่าต่างๆ ดังนี้
  - เก็บค่ารูปแบบเอ็นแกรมที่มีคะแนนมากที่สุดไว้ในตัวแปร `max_pattern`
  - เก็บค่าคะแนนมากที่สุดไว้ในตัวแปร `max_score`
  - เก็บคำอักษรเบรลล์ภาษาไทยที่มีความคล้ายคลึงกับรูปแบบเอ็นแกรมมากที่สุดไว้ในตัวแปร `max_text`
  - เก็บค่า Index ของคำอักษรเบรลล์ภาษาไทยที่มีความคล้ายคลึงกับรูปแบบเอ็นแกรมมากที่สุดไว้ในตัวแปร `max_text_index`
4. ทำซ้ำจนกว่าจะครบรูปแบบเอ็นแกรมทั้งหมด

และเพื่อให้ง่ายต่อการทำความเข้าใจผู้วิจัยจึงใช้กรณีตัวอย่างในรูปที่ 3.12a และ 3.12b อธิบายวิธีการคิดคะแนนความคล้ายคลึงกันระหว่างรูปแบบเอ็นแกรมและรายการคำอักษรเบรลล์ ภาษาไทยระดับ 1 ดังต่อไปนี้



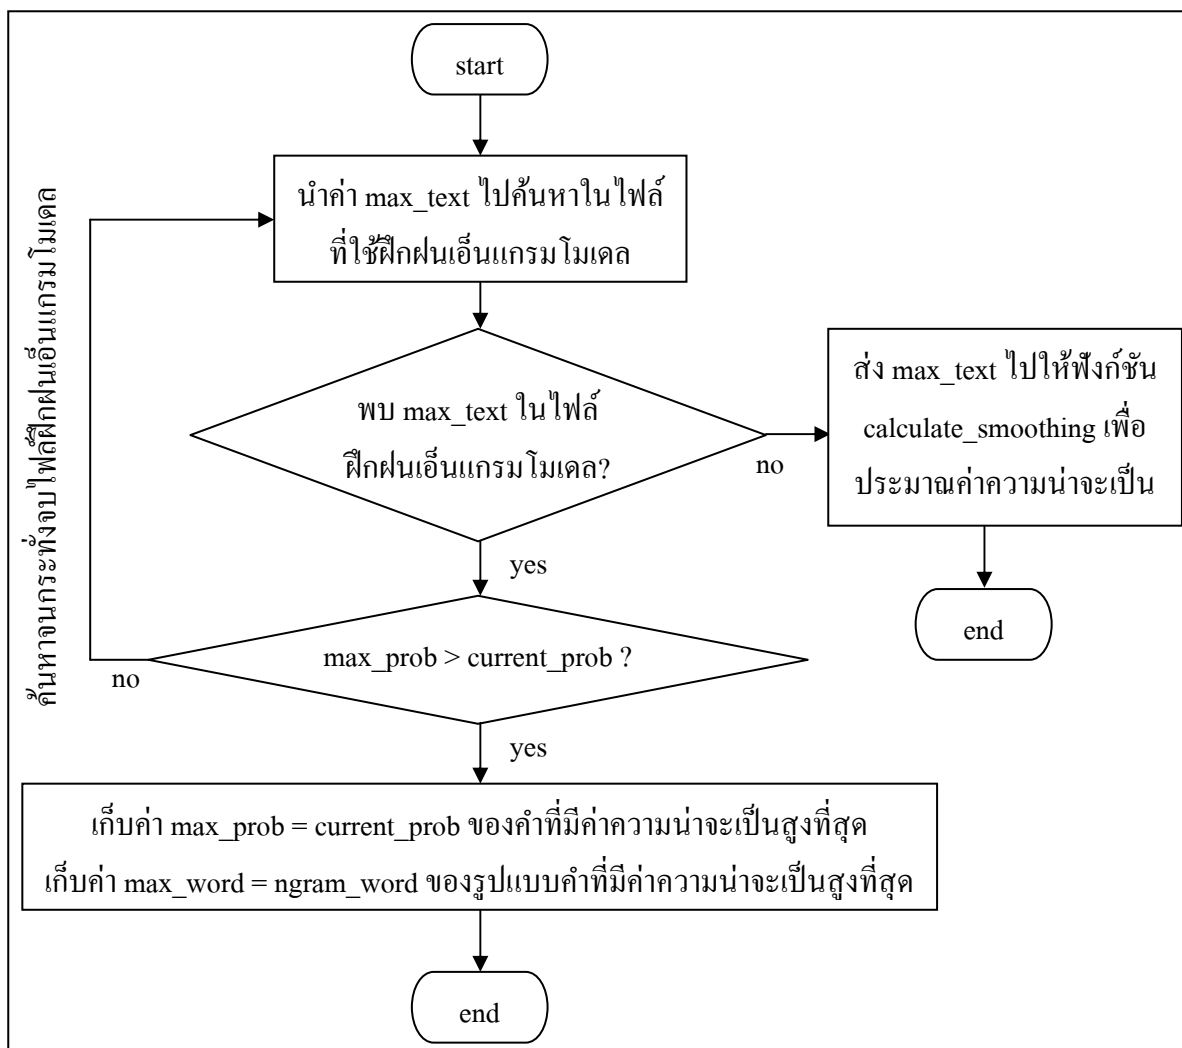
รูปที่ 3.12a กรณีที่มีการเรียงตัวอักขระเหมือนกันทั้งหมด

ในกรณีรูปที่ 3.12a นี้เป็นกรณีที่มีการเรียงอักขระของรูปแบบเอ็นแกรมและการเรียงอักขระของคำอักษรเบรลล์ภาษาไทยระดับ 1 ที่ได้สร้างเอาไว้แล้วเหมือนกันจนกระทั่งหมดความยาวของรูปแบบเอ็นแกรม ซึ่งจะคิดคะแนนตามจำนวนลักษณะการเรียงอักขระที่เหมือนกันและต่อเนื่องกันไปเรื่อยๆ กล่าวคือ เมื่ออักขระของรูปแบบเอ็นแกรมตำแหน่งแรกคือตัวอักขระ “g” ตรงกันกับอักขระตัวแรกของคำอักษรเบรลล์ภาษาไทยซึ่งเป็นตัวอักขระ “g” เช่นเดียวกันก็จะให้คะแนน 1 คะแนนและเก็บค่าคะแนนไว้ในตัวแปร score และอักขระตัวถัดไปซึ่งเป็นตัวอักขระ “,” ตรงกันอีกก็จะเพิ่มคะแนนอีก 1 คะแนนรวมเป็น 2 คะแนนและทำเช่นนี้ไปเรื่อยๆ จนกว่าจะพบอักขระที่เรียงไม่เหมือนกันจึงหยุดการเพิ่มคะแนน



รูปที่ 3.12b กรณีที่มีการเรียงตัวอักขระไม่เหมือนกันทั้งหมด

ในกรณีรูปที่ 3.12b นี้การเรียงตัวอักขระระหว่างรูปแบบเอ็นแกรมและคำอักษรเบรลล์ภาษาไทยเหมือนกันบางส่วน กล่าวคือตัวอักขระตัวแรกของรูปแบบเอ็นแกรมเป็นตัวอักษร “g” เช่นเดียวกันจึงให้คะแนนเพิ่ม 1 คะแนนและตัวอักขระตัวที่ 2 เป็นตัวอักษร “,” เช่นเดียวกันอีกก็เพิ่มคะแนนให้อีก 1 คะแนนรวมเป็น 2 คะแนนและตัวอักขระตัวที่ 3 ของรูปแบบเอ็นแกรมเป็นตัว “d” แต่ตัวอักขระตัวถัดไปของคำอักษรเบรลล์ภาษาไทยเป็นตัว “n” ซึ่งไม่ตรงกันจึงหยุดการเพิ่มคะแนนเพียงเท่านี้แม้ว่าตัวอักขระที่ 4 และ 5 ของคำอักษรเบรลล์ภาษาไทยจะตรงกันกับตัวอักษรที่เหลือของรูปแบบเอ็นแกรมก็ตาม



รูปที่ 3.13 ขั้นตอนการทำงานของฟังก์ชัน find\_ngram

จากรูปที่ 3.13 แสดงขั้นตอนการทำงานของฟังก์ชัน find\_ngram ซึ่งมีรายละเอียดดังต่อไปนี้

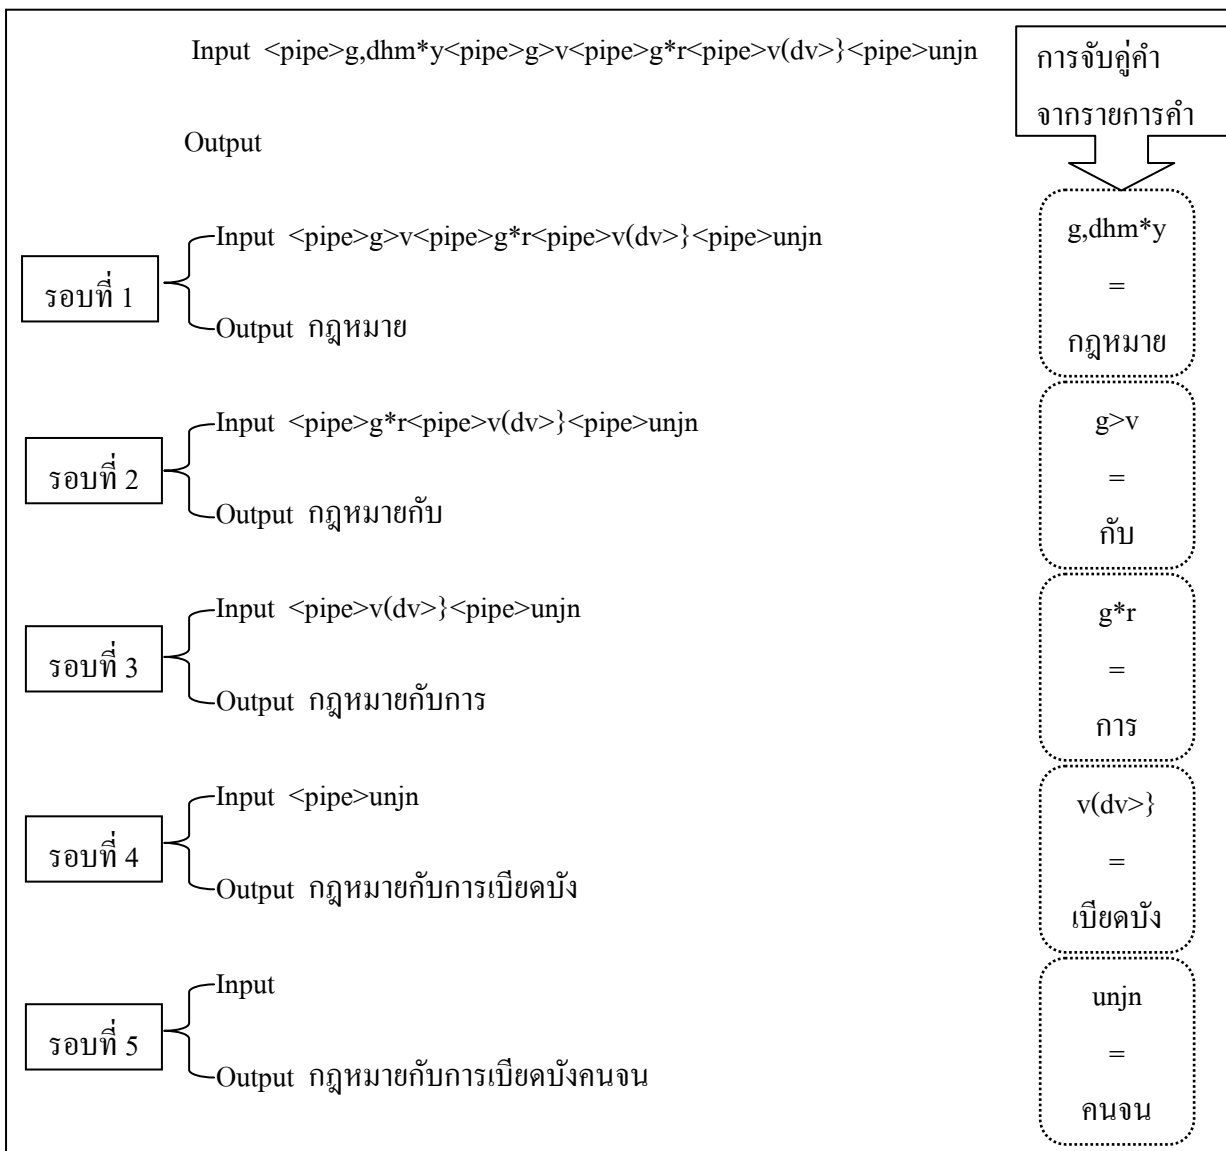
1. นำค่าที่เก็บไว้ในตัวแปร max\_text ไปค้นหาในรายการคำโมเดลอักขรเบรลล์ภาษาไทยซึ่งเก็บไว้ในตัวแปร array\_ngram\_word\_list (รายละเอียดของรายการโมเดลอักขรเบรลล์ภาษาไทยจะอธิบายในหัวข้อที่ 3.7 เอ็นแกรมโมเดล)
2. หากพบค่า max\_text ให้เก็บค่าความน่าจะเป็นของรูปแบบคำๆ นั้นในตัวแปร current\_prob หากไม่พบให้ส่งค่า max\_text ไปให้กับฟังก์ชัน calculate\_smoothing เพื่อประมาณค่าความน่าจะเป็นของรูปแบบคำๆ นั้น จากนั้นจึงจบการทำงาน (รายละเอียดของการประมาณค่าความน่าจะเป็นจะอธิบายในหัวข้อที่ 3.8 Smoothing Techniques)

3. คำนวณกระทั่งหาค่าโมเดลอักขรเบรลล์ภาษาไทยเพื่อค้นหารูปแบบของคำที่มีค่าความน่าจะเป็นสูงที่สุดโดยเก็บไว้ในตัวแปร `max_prob`
4. เก็บค่าความน่าจะเป็นที่สูงที่สุดของรูปแบบคำไว้ในตัวแปร `max_prob` และเก็บรูปแบบคำที่มีค่าความน่าจะเป็นสูงที่สุดในตัวแปร `max_word`
5. ส่งค่า `max_prob` และ `max_word` กลับไปให้ฟังก์ชัน `select_output` เพื่อประกอบการตัดสินใจแบ่งคำต่อไป

#### 3.6.4 ขั้นตอน `translate_to_thai`

ในขั้นตอน `translate_to_thai` นี้ทำหน้าที่แปลงจากประโยคอักขรเบรลล์ที่ได้ตัดคำแล้วให้อยู่ในรูปของประโยคภาษาไทย โดยใช้งานร่วมกับ รายการคำอักขรเบรลล์ภาษาไทยและรายการคำภาษาไทย ซึ่งจะอธิบายรายละเอียดในหัวข้อที่ 3.9 รายการคำอักขรเบรลล์ภาษาไทยและรายการคำภาษาไทย

ซึ่งวิธีการแปลงประโยคอักขรเบรลล์ภาษาไทยระดับ 1 ที่ได้ตัดคำไว้แล้วไปเป็นประโยคภาษาไทย จะใช้วิธีเทียบคำคือ แทนที่คำอักขรเบรลล์ภาษาไทยระดับ 1 ด้วยคำในภาษาไทยที่ตรงกัน โดยค้นหารายการของคำที่ตรงกันจากรายการคำอักขรเบรลล์ภาษาไทยและรายการคำภาษาไทย ที่ได้สร้างไว้ก่อนแล้ว ดังแสดงในรูปที่ 3.14



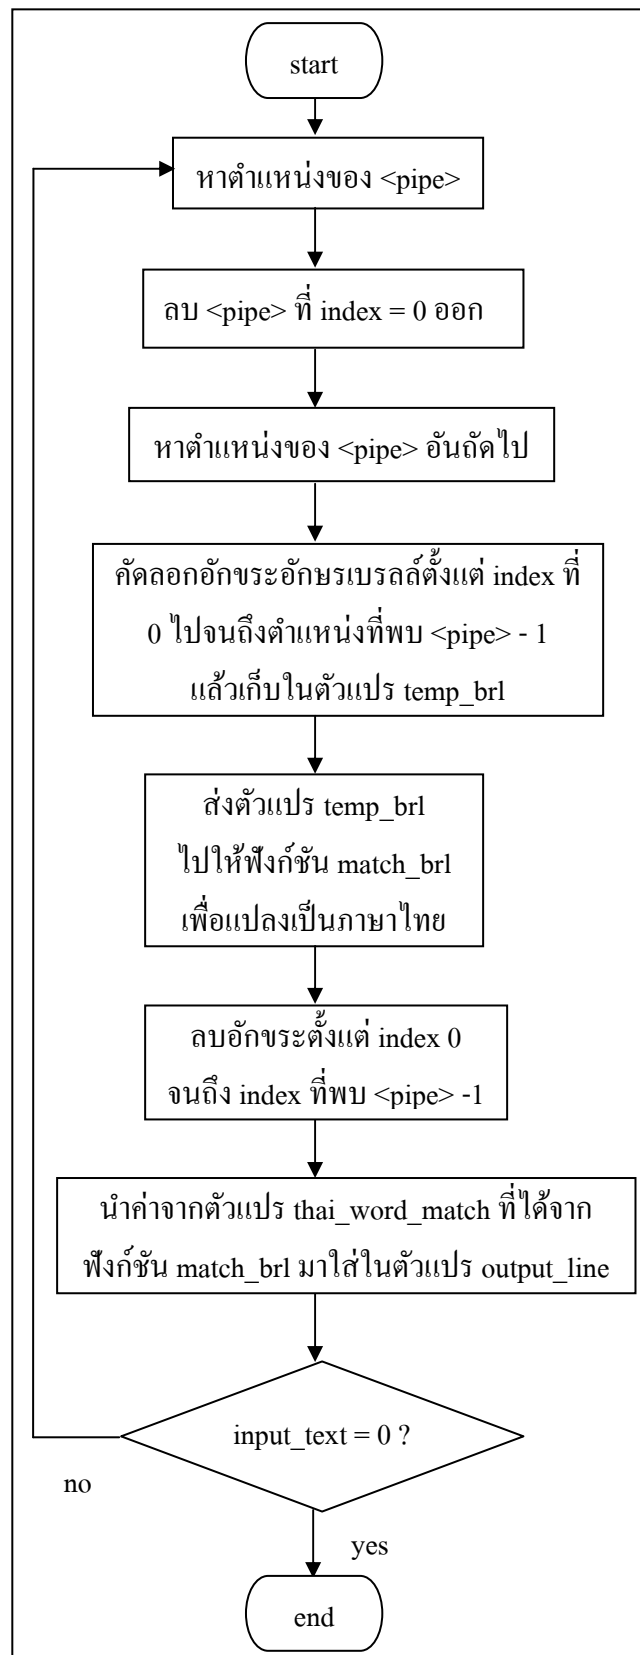
รูปที่ 3.14 ภาพรวมวิธีการแปลงแบบเทียบคำ

ในวิธีการแปลงแบบเทียบคำนี้ผู้วิจัยได้ออกแบบฟังก์ชันหลักที่ชื่อว่า `mapping_translate` เพื่อทำหน้าที่ในการแปลงแบบเทียบคำ ซึ่งมีการประกาศฟังก์ชันเป็น `string mapping_translate (string text)` โดยมีการรับ Parameter เป็นตัวแปรชนิด `String` คือประโยคอักษรเบรลล์ภาษาไทย ระดับ 1 ที่ได้แบ่งคำไว้เรียบร้อยแล้วนั่นเอง และมีการคืนค่าเป็นชนิด `String` เช่นกันคือประโยคภาษาไทย โดยฟังก์ชัน `mapping_translate` มีรายละเอียดของตัวแปรชนิดต่างๆ ที่ใช้งานร่วมกันดังแสดงในตารางที่ 3.6 และมีขั้นตอนการทำงานดังแสดงในรูปที่ 3.15 และ 3.16 โดยในรูปที่ 3.15 เป็นฟังก์ชันหลักและรูปที่ 3.16 เป็นฟังก์ชัน `match_br` ซึ่งทำหน้าที่ค้นหาคำอักษรเบรลล์ภาษาไทย

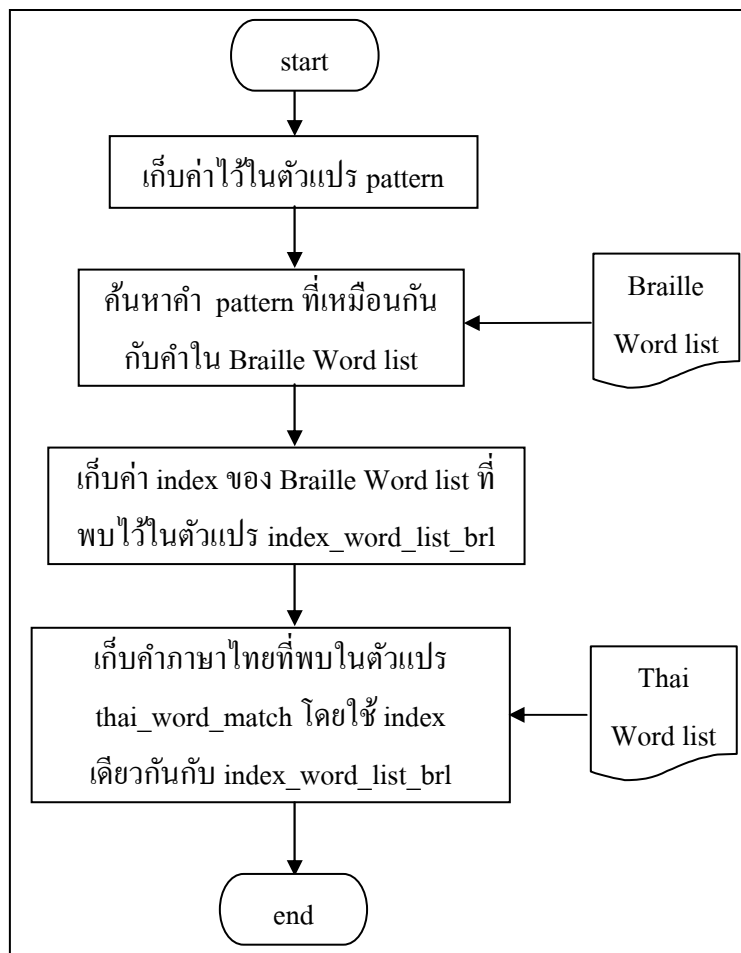


ตารางที่ 3.6 ตัวแปรต่างๆ ที่ใช้ในขั้นตอน translate\_to\_thai

ชื่อของตัวแปร	ชนิดของตัวแปร	หน้าที่ของตัวแปร
text	String	เก็บประโยคอักษรเบรลล์ภาษาไทยระดับ 1 ที่ตัดคำเรียบร้อยแล้ว
length_text	Integer	เก็บค่าดั้งเดิมความยาวของประโยคอักษรเบรลล์ภาษาไทยระดับ 1 ที่ตัดคำเรียบร้อยแล้ว
temp_length_text	Integer	เก็บค่าความยาวปัจจุบันของประโยคอักษรเบรลล์ภาษาไทยระดับ 1 ที่กำลังแปลงให้เป็นประโยคภาษาไทย
length_match_brl	Integer	เก็บค่าความยาวของคำอักษรเบรลล์ภาษาไทยปัจจุบันที่นำไปแปลงให้เป็นคำภาษาไทย
length_word_copy	Integer	เก็บค่าความยาวทั้งหมดของคำอักษรเบรลล์ภาษาไทยที่แปลงไปเป็นคำภาษาไทยแล้ว
start_index_copy	Integer	เก็บค่าตำแหน่งอักขระอักษรเบรลล์ภาษาไทยที่จะนำไปแปลงเป็นคำภาษาไทย
output_line	String	เก็บประโยคภาษาไทยที่แปลงมาจากประโยคอักษรเบรลล์ภาษาไทย
temp_brl	String	เก็บอักษรเบรลล์ภาษาไทยและส่งไปที่ฟังก์ชัน match_brl แปลงเป็นภาษาไทย
thai_word_match	Global String	เก็บคำภาษาไทยที่ค้นหาในรายการคำแล้วตรงกันกับคำอักษรเบรลล์ภาษาไทยที่ได้ส่งไปแปลง



รูปที่ 3.15 การทำงานของขั้นตอน translate\_to\_thai



รูปที่ 3.16 การทำงานของฟังก์ชัน match\_brl

จากรูปที่ 3.15 และ 3.16 มีรายละเอียดการทำงานต่างๆ ดังต่อไปนี้

1. หาดำแหน่งของสัญลักษณ์ <pipe> จากประโยคอินพุต
2. ลบสัญลักษณ์ <pipe> ที่ตำแหน่งเริ่มต้นออก
3. หาดำแหน่งของสัญลักษณ์ <pipe> อันถัดไป
4. คัดลอกอักขระอักษรเบรลล์ที่แบ่งคำเสร็จแล้วตั้งแต่ตำแหน่งเริ่มต้นจนถึงตำแหน่งที่พบ <pipe> - 1 อันถัดไปและส่งให้กับฟังก์ชัน match\_brl เพื่อค้นหาคำภาษาไทยที่ตรงกัน
5. นำคำภาษาไทยที่ค้นหาพบจากฟังก์ชัน match\_brl ไปใส่ในตัวแปร output\_line
6. ลบอักขระอักษรเบรลล์ตั้งแต่ตำแหน่งแรกจนถึงตำแหน่งที่พบ <pipe> - 1
7. ทำซ้ำตั้งแต่ข้อ 1-6 จนกว่าประโยคอินพุตจะหมดลง

### 3.7 การประยุกต์เอ็นแกรมโมเดล

เทคนิคเอ็นแกรม โมเดลเป็นเทคนิคทางด้านสถิติที่ใช้สร้าง โมเดลภาษาและคำนวณหาค่าความน่าจะเป็นที่ค่าๆ หนึ่งสามารถเกิดร่วมกับค่าๆ ใดได้บ้างด้วยค่าความน่าจะเป็นเท่าไร (รายละเอียดด้านทฤษฎีได้อธิบายไว้ในหัวข้อที่ 2.5 เอ็นแกรมโมเดล) ซึ่งในงานวิจัยนี้ได้นำเทคนิคดังกล่าวมาประยุกต์ใช้ตัดคำอักษรเบรลล์ภาษาไทยก่อนที่จะแปลงไปเป็นภาษาไทยเพื่อลดความกำกวมอันเนื่องมาจากลักษณะไวยากรณ์การเขียนของอักษรเบรลล์ภาษาไทยระดับ 1 ที่เขียนคำแต่ละคำติดกันต่อเนื่องกันไปและใช้การเว้นวรรคเพื่อแบ่งแต่ละประโยคออกจากกันแต่จะมีการเรียงอักษรนำ อักษรตาม สระ วรรณยุกต์และตัวสะกดที่แตกต่างไปจากลักษณะไวยากรณ์ของภาษาไทย โดยวิธีการไฟล์โมเดลอักษรเบรลล์ภาษาไทยหรือการฝึกฝนเอ็นแกรมโมเดลได้อธิบายไว้ในหัวข้อที่ 3.3.2 และรายละเอียดของเครื่องมือที่ใช้ได้อธิบายไว้ในหัวข้อที่ 2.7 CMU-SLM toolkit

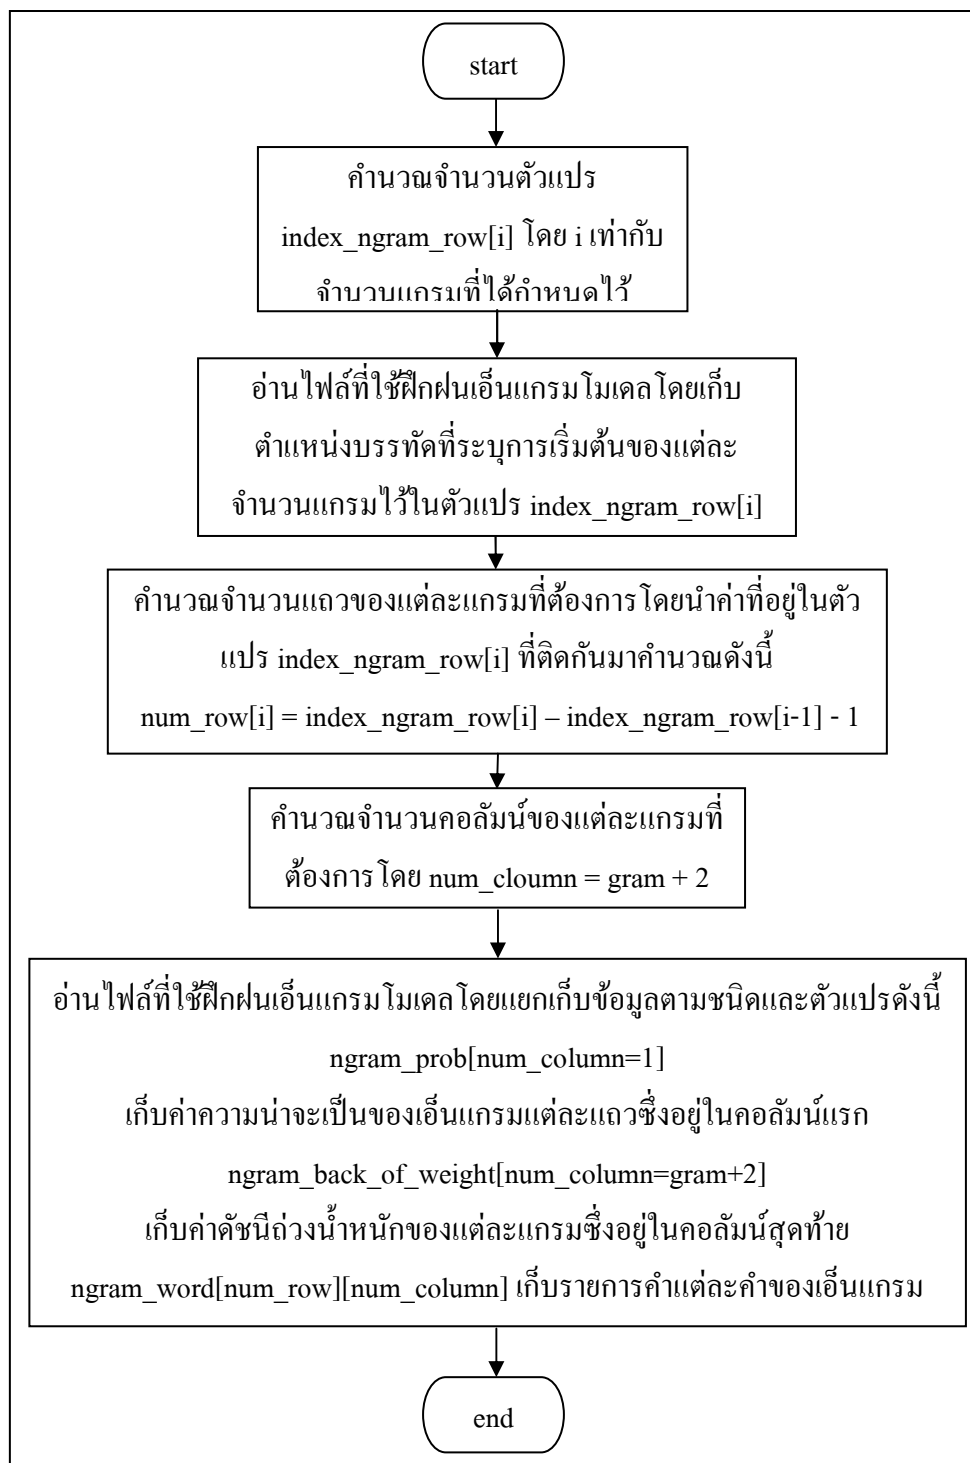
โดยในหัวข้อนี้จะกล่าวถึงวิธีการจัดเตรียมข้อมูลดังกล่าวและจัดเก็บไว้ในหน่วยความจำหลักและการนำไปใช้งาน ซึ่งผู้วิจัยได้ออกแบบฟังก์ชันชื่อว่า `load_ngram_word` ซึ่งจะทำหน้าที่อ่านไฟล์ที่ฝึกฝนเอ็นแกรม โมเดลและประมวลผลเพื่อแยกชนิดของข้อมูลและเก็บข้อมูลดังกล่าวไว้ในหน่วยความจำหลัก โดยมีการประกาศฟังก์ชันเป็น `void load_ngram_word()` โดยมีรายละเอียดของตัวแปรต่างๆ ที่ใช้ในฟังก์ชันนี้ดังแสดงในตารางที่ 3.7

ตารางที่ 3.7 ตัวแปรต่างๆ ที่ใช้ในฟังก์ชัน `load_ngram_word`

ชื่อของตัวแปร	ชนิดของตัวแปร	หน้าที่ของตัวแปร
<code>index_ngram_row</code>	Array of Integer	เก็บตำแหน่งบรรทัดของแต่ละแกรม
<code>num_row</code>	Array of Integer	เก็บจำนวนแถวของแต่ละแกรม
<code>num_column</code>	Array of Integer	เก็บจำนวนคอลัมน์ของแต่ละแกรม
<code>row</code>	Global Integer	เก็บ index ของแถว
<code>column</code>	Global Integer	เก็บ index ของคอลัมน์
<code>ngram_word</code>	Global 2D Array of String	เก็บรายการคำของเอ็นแกรม
<code>ngram_prob</code>	Global Double	เก็บค่าความน่าจะเป็นของเอ็นแกรม
<code>ngram_back_of_weight</code>	Global Double	เก็บค่าดัชนีถ่วงน้ำหนักของเอ็นแกรม

ผู้วิจัยได้ออกแบบการทำงานของฟังก์ชัน `load_ngram_word` เป็น 2 ช่วง ดังนี้ 1) อ่านข้อมูลในไฟล์ฝึกฝนเอ็นแกรม โมเดลเพื่อคำนวณจำนวนแถวและคอลัมน์ของแต่ละแกรมเพื่อจองขนาดของตัวแปรที่ใช้เก็บข้อมูลดังกล่าวได้ถูกต้อง 2) อ่านข้อมูลดังกล่าวและจัดเก็บไว้ในตัวแปรแต่ละ

ประเภทตามที่ได้ออกแบบไว้ โดยฟังก์ชัน `load_ngram_word` มีขั้นตอนการทำงานดังแสดงในรูปที่ 3.17



รูปที่ 3.17 ขั้นตอนการทำงานของฟังก์ชัน `load_ngram_word`

จากรูปที่ 3.17 มีรายละเอียดขั้นตอนการทำงานต่างๆ ดังต่อไปนี้

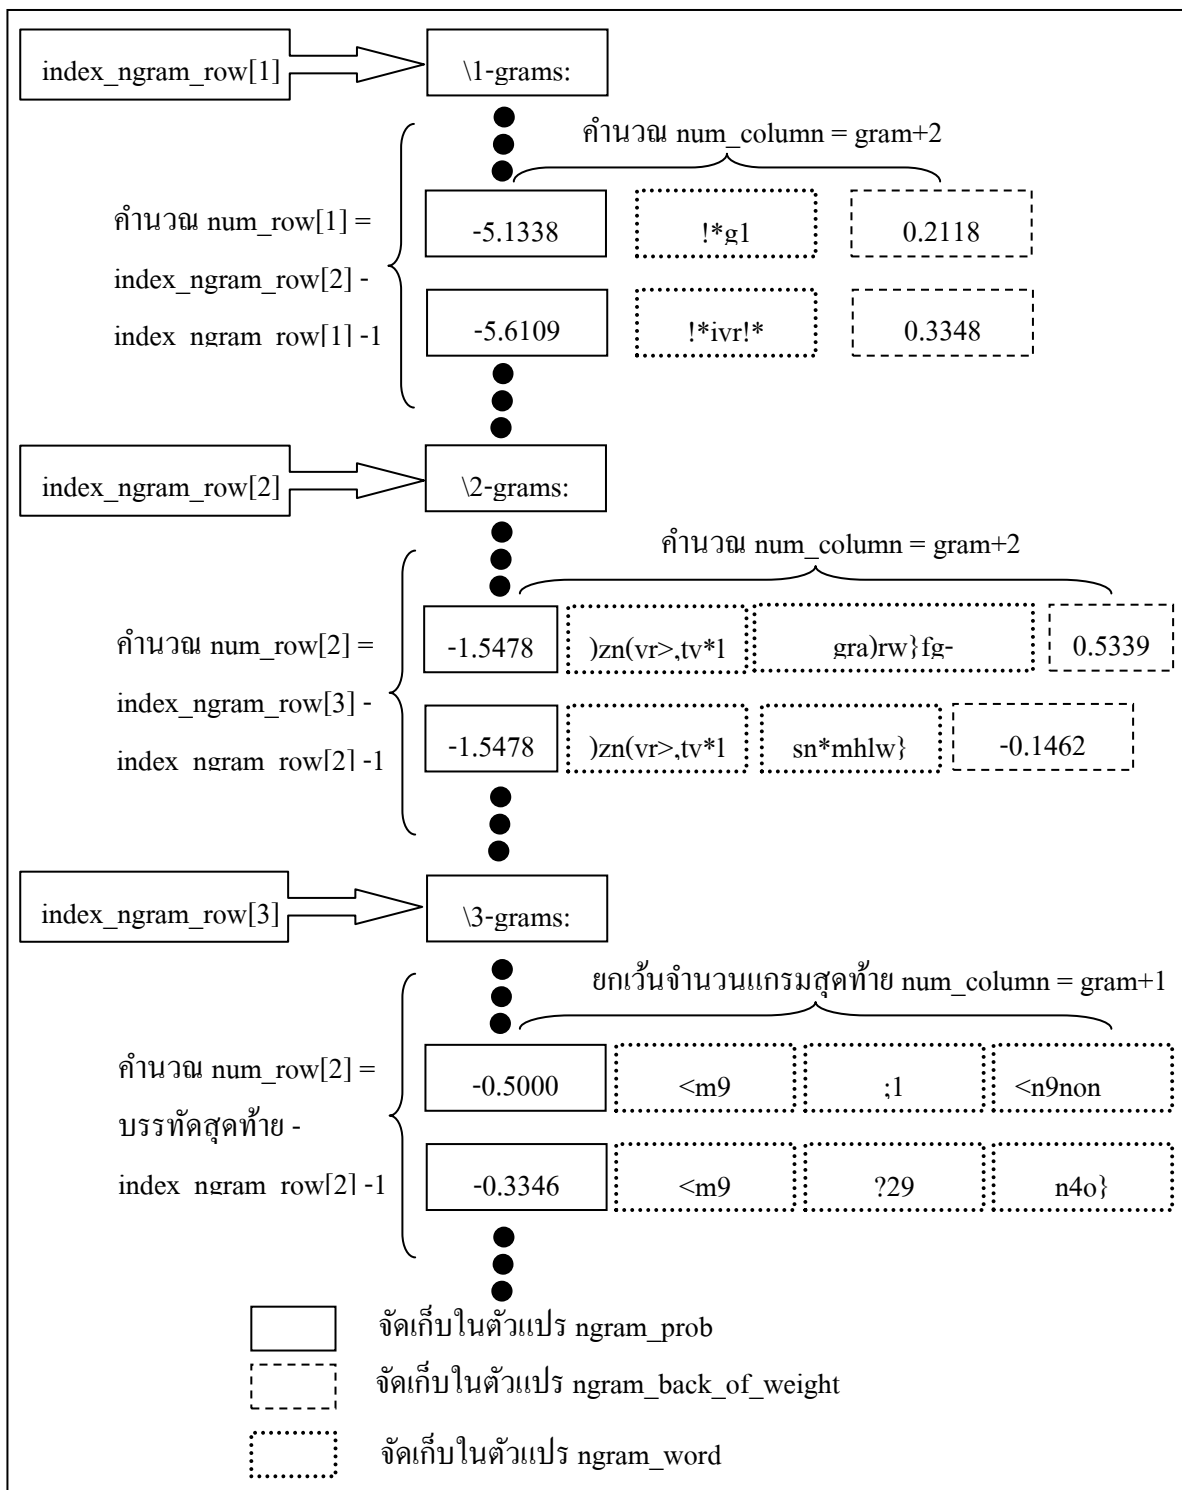
1. คำนวณจำนวนตัวแปรที่ใช้เก็บตำแหน่งเริ่มต้นของแต่ละแกรมซึ่งมีจำนวนเท่ากับขนาดของจำนวนแกรมที่ได้กำหนดไว้ กล่าวคือ หากกำหนดขนาดแกรมไว้ที่ 3-แกรม ก็ต้องกำหนดจำนวนตัวแปร `index_ngram_row[gram]` ให้มีจำนวนเท่ากับ 3 ชุดด้วยเพื่อที่จะเก็บตำแหน่งเริ่มต้นของแกรมคือ 1-gram, 2-gram และ 3-gram ว่าอยู่ที่บรรทัดไหนบ้าง เป็นต้น
2. อ่านไฟล์โมเดลอักษรเบรลล์ภาษาไทยโดยเก็บตำแหน่งเริ่มต้นของแต่ละแกรมไว้ในตัวแปร `index_ngram_row[gram]` โดยสามารถตรวจสอบได้จากการเปรียบเทียบค่า กล่าวคือ ตำแหน่งเริ่มต้นของ 1-แกรม จะมีค่าเท่ากับเป็น `\1-grams:` และตำแหน่งเริ่มต้นของ 2-แกรม จะมีค่าเท่ากับเป็น `\2-grams:` เป็นลักษณะเช่นนี้ไปเรื่อยๆ จนกระทั่งครบตามจำนวนแกรมที่ได้กำหนดไว้ ซึ่งจะช่วยให้ทราบได้ว่าตำแหน่งเริ่มต้นของแต่ละแกรมอยู่ที่บรรทัดไหนบ้าง และเก็บตำแหน่งบรรทัดเหล่านั้นไว้ในตัวแปร `index_ngram_row[gram]`
3. คำนวณจำนวนแถวของแต่ละแกรมที่ต้องการ โดยจัดเก็บไว้ในตัวแปร `num_row[i]` ซึ่งคำนวณได้จาก  $num\_row[i] = index\_ngram\_row[i] - index\_ngram\_row[i-1] - 1$  ซึ่งจะได้จำนวนแถวที่ต้องการเพื่อจัดเก็บรูปแบบเอ็นแกรมของแต่ละขนาดแกรมตั้งแต่ 1-แกรม ไปจนถึงขนาดแกรมที่ได้กำหนดไว้
4. คำนวณจำนวนคอลัมน์ของแต่ละรูปแบบเอ็นแกรมที่ต้องการ โดยจัดเก็บไว้ในตัวแปร `num_column[i]` ซึ่งคำนวณได้จาก  $num\_column[i] = gram + 2$  คือในแต่ละแกรมจะมีคอลัมน์ที่เพิ่มขึ้นมาสำหรับจัดเก็บค่าความน่าจะเป็นของแต่ละรูปแบบเอ็นแกรมและค่าดัชนีถ่วงน้ำหนักของแต่ละรูปแบบเอ็นแกรม (ตามที่ได้แสดงไว้ในรูปที่ 3.18) ยกเว้นจำนวนแกรมสุดท้ายตามที่ได้กำหนดไว้ซึ่งในตัวอย่างนี้ได้กำหนดขนาดของแกรมเท่ากับ 3-แกรม โดยจำนวนแกรมสุดท้ายที่ได้กำหนดไว้ก็คือจำนวนแกรมที่ 3-แกรม ซึ่งจะมีเพิ่มขึ้นมาอีกเพียง 1 คอลัมน์เท่านั้นสำหรับจัดเก็บค่าความน่าจะเป็นของแต่ละรูปแบบเอ็นแกรม
5. อ่านไฟล์โมเดลอักษรเบรลล์ภาษาไทยโดยแยกจัดเก็บข้อมูลชนิดต่างๆ ลงในตัวแปรแต่ละตัวแปรตามที่ได้กำหนดไว้ กล่าวคือ
  - 5.1. เก็บค่าความน่าจะเป็นของแต่ละรูปแบบเอ็นแกรมแต่ละแถวซึ่งอยู่ในคอลัมน์แรกเสมอไว้ในตัวแปร `ngram_prob[num_column=1]`

- 5.2. เก็บค่าดัชนีถ่วงน้ำหนักของแต่ละรูปแบบเอ็นแกรมในแต่ละแถวซึ่งจะอยู่ที่คอลัมน์สุดท้ายเสมอ ไว้ในตัวแปร `ngram_back_of_weight[num_column=gram+2]` ยกเว้นจำนวนแกรมสุดท้ายที่ไม่มีค่าดัชนีถ่วงน้ำหนัก
- 5.3. เก็บรายการค่าของแต่ละเอ็นแกรมในตัวแปร `ngram_word[num_row][num_column]` โดยแบ่งตามแถวและคอลัมน์ตามที่ได้ออกแบบไว้
6. จบการของฟังก์ชันนี้โดยออกแบบให้ฟังก์ชันเริ่มต้นการทำงานพร้อมกับการเริ่มโปรแกรมหลัก

และเพื่อเป็นการง่ายต่อการทำความเข้าใจผู้วิจัยจึงใช้แผนภาพเพื่ออธิบายการจัดเก็บข้อมูลจากไฟล์โมเดลอักษรเบรลล์ภาษาไทยลงในตัวแปรประเภทต่างๆ ดังแสดงในรูปที่ 3.18 โดยสมมุติว่ากำหนดจำนวนแกรมไว้เป็น 3-แกรม

โดยมีการแบ่งการจัดเก็บข้อมูลชนิดต่างๆ ในตัวแปรประเภทต่างๆ ดังต่อไปนี้

- เก็บลำดับที่บรรทัดของตำแหน่งเริ่มต้นของแต่ละแกรมไว้ในตัวแปร `index_ngram_row[i]` โดยใช้วิธีค้นหาจากการเปรียบเทียบคำคือ ตำแหน่งเริ่มต้นของแต่ละแกรมจะมีลักษณะเป็น \1-grams:, \2-grams: เป็นเช่นนี้ไปเรื่อยๆ จนกระทั่งถึงจำนวนแกรมที่ได้กำหนดไว้
- เก็บค่าความน่าจะเป็นของแต่ละรูปแบบเอ็นแกรมไว้ในตัวแปร `ngram_prob` ซึ่งจะอยู่ในคอลัมน์แรกของแต่ละแถวที่ไม่ใช่แถวของตำแหน่งเริ่มต้นของแต่ละแกรม ซึ่งจากรูปที่ 3.18 คือค่าตัวเลขที่แสดงอยู่ในกรอบลักษณะ
- เก็บค่าดัชนีถ่วงน้ำหนัก (Back-off weight) ของแต่ละรูปแบบเอ็นแกรมไว้ในตัวแปร `ngram_back_of_weight` ซึ่งจะอยู่คอลัมน์ท้ายสุดของแต่ละแถวเสมอ ยกเว้นจำนวนแกรมสุดท้ายจะไม่มีค่าดัชนีถ่วงน้ำหนัก ซึ่งจากรูปที่ 3.18 คือค่าตัวเลขที่แสดงอยู่ในกรอบลักษณะ
- เก็บค่าคำของแต่ละรูปแบบเอ็นแกรมซึ่งเป็นคำแต่ละคำที่เขียนอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 โดยเก็บไว้ในตัวแปร `ngram_word[row][column]` ตามตำแหน่งของแถวและคอลัมน์ที่ได้กำหนดไว้ ซึ่งจากรูปที่ 3.18 คือตัวอักษรเบรลล์ที่แสดงอยู่ในกรอบลักษณะ



รูปที่ 3.18 วิธีการจัดเก็บข้อมูลในตัวแปรประเภทต่างๆ

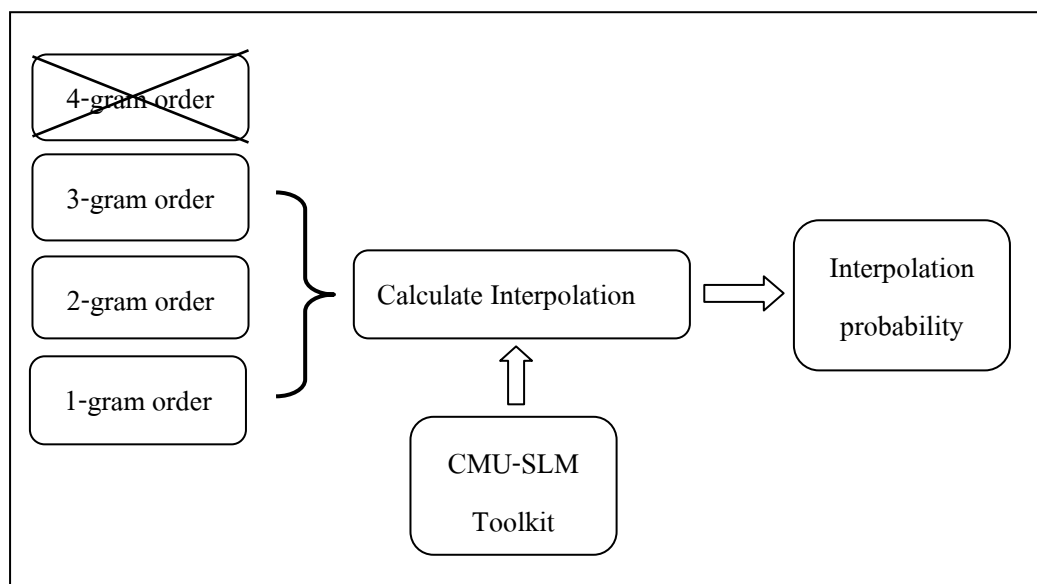


### 3.8 Smoothing Techniques ที่เลือกใช้

เทคนิค Smoothing Technique ที่เลือกใช้ในวิทยานิพนธ์นี้ใช้วิธีการของ Jelinek-Mercer Smoothing (Interpolation) ในการประมาณค่าความน่าจะเป็น ซึ่งวิธีการแบบ Interpolation คือการนำเอาค่าความน่าจะเป็นของจำนวนแกรมอื่นๆ มาคำนวณร่วมกันเพื่อประมาณค่าความน่าจะเป็น โดยมีสมการคำนวณค่าความน่าจะเป็นดังสมการที่ 5

$$P_{\text{interp}}(w_i | w_{i-n+1}^{i-1}) = \lambda_{w_{i-n+1}^{i-1}} P_{\text{ML}}(w_i | w_{i-n+1}^{i-1}) + (1 - \lambda_{w_{i-n+1}^{i-1}}) P_{\text{interp}}(w_i | w_{i-n+2}^{i-1}) \dots (5)$$

และเพื่อให้ง่ายต่อการทำความเข้าใจผู้วิจัยจึงใช้แผนภาพในการอธิบายดังแสดงในรูปที่ 3.19



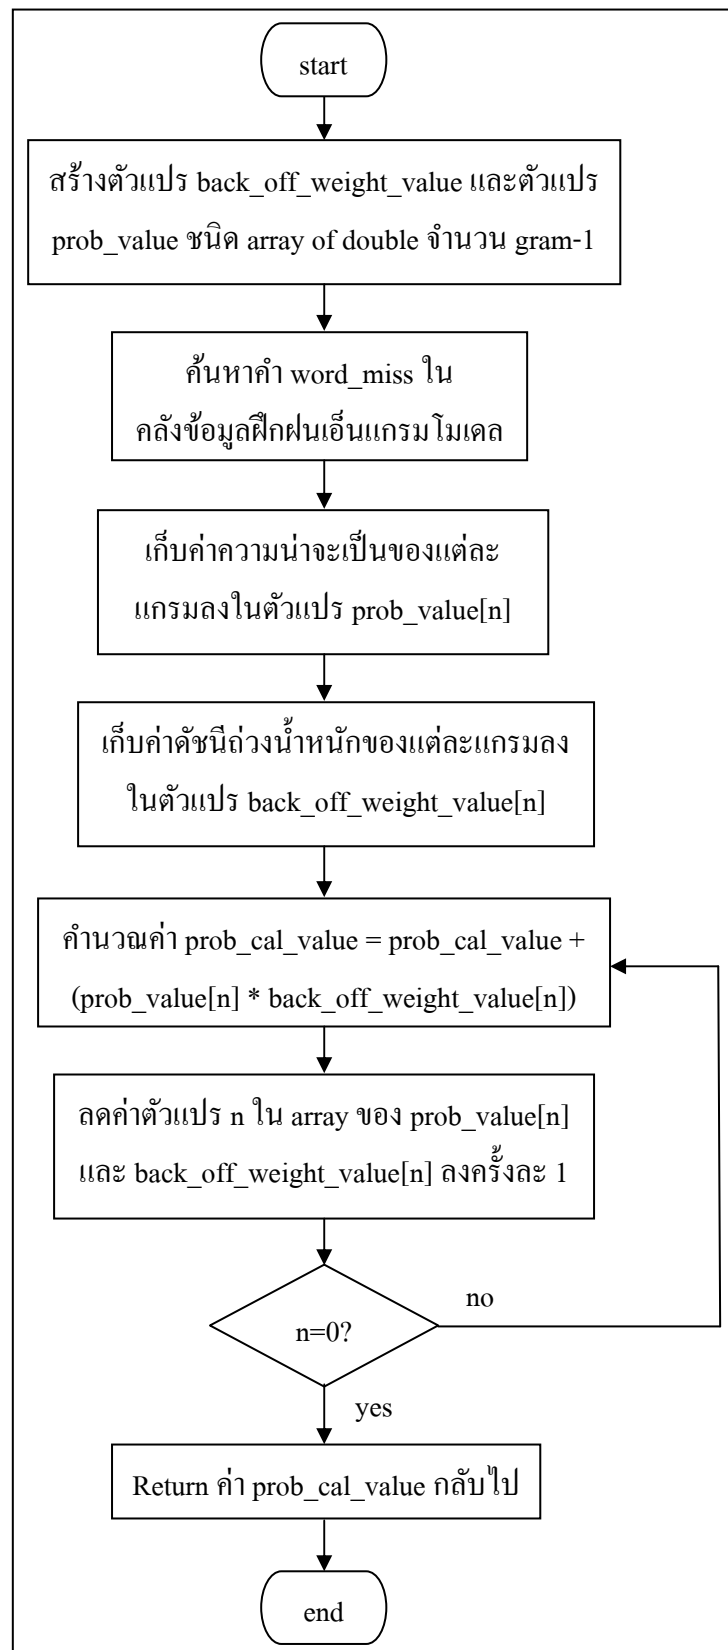
รูปที่ 3.19 ภาพรวมการทำงานของ Interpolation

จากรูปที่ 3.19 สมมติว่ากำหนดการฝึกฝนเอ็นแกรม โมเดลด้วยจำนวนแกรมเท่ากับ 4-แกรม และในคลังข้อมูลฝึกไม่พบคำที่ต้องการเมื่อค้นหาที่จำนวนแกรมเท่ากับ 4-แกรม ดังนั้นจึงใช้วิธีการประมาณค่าความน่าจะเป็นแบบ Interpolation โดยใช้ชุดเครื่องมือ CMU-SLM Toolkit ประมาณค่าความน่าจะเป็นโดยใช้จำนวนแกรมที่ถัดไปเรื่อยๆ จนถึง 1-แกรมมาคำนวณร่วมกัน กล่าวคือค่าความน่าจะเป็นที่ได้จากการประมาณค่าของคำที่ไม่พบในจำนวนแกรมเท่ากับ 4-แกรม มีค่าเท่ากับ ค่า Back-off weight ของ 3-แกรมคูณด้วยค่าความน่าจะเป็นของจำนวนแกรม 3-แกรม บวกด้วย ค่า Back-off weight ของ 2-แกรมคูณด้วยค่าความน่าจะเป็นของจำนวนแกรม 2-แกรม บวกด้วย ค่า Back-off weight ของ 1-แกรมคูณด้วยค่าความน่าจะเป็นของจำนวนแกรม 1-แกรม

และในวิทยานิพนธ์นี้ผู้วิจัยได้สร้างฟังก์ชัน `calculate_smoothing` เพื่อประมาณค่าความน่าจะเป็นในกรณีที่ไม่พบคำหรือชุดของคำในคลังข้อมูลฝึก โดยมีการประกาศฟังก์ชันเป็น `double calculate_smooth (string word)` โดยมีการรับพารามิเตอร์ (Parameter) เป็นตัวแปรชนิด String คือ คำอักษรเบรลล์ภาษาไทยระดับ 1 ที่ไม่พบในคลังข้อมูลฝึกและมีการคืนค่าเป็นชนิด Double คือค่าความน่าจะเป็นที่ได้จากการประมาณค่าโดยฟังก์ชัน `calculate_smoothing` และมีรายละเอียดของตัวแปรชนิดต่างๆ ที่ใช้งานร่วมกันดังแสดงในตารางที่ 3.8 และมีขั้นตอนการทำงานแสดงในรูปที่ 3.20

ตารางที่ 3.8 ตัวแปรต่างๆ ที่ใช้ในขั้นตอน `calculate_smoothing`

ชนิดของตัวแปร	ชื่อของตัวแปร	หน้าที่ของตัวแปร
Double	<code>prob_cal_value</code>	เก็บค่าความน่าจะเป็นที่ได้จากการประมาณค่า
String	<code>word_miss</code>	เก็บค่าของคำที่ไม่พบในคลังข้อมูลฝึก
Array of Double	<code>back_off_weight_value</code>	เก็บค่าดัชนีถ่วงน้ำหนักของแต่ละจำนวนแกรม
Array of Double	<code>prob_value</code>	เก็บค่าความน่าจะเป็นของแต่ละจำนวนแกรม



รูปที่ 3.20 การทำงานของฟังก์ชัน calculate\_smoothing

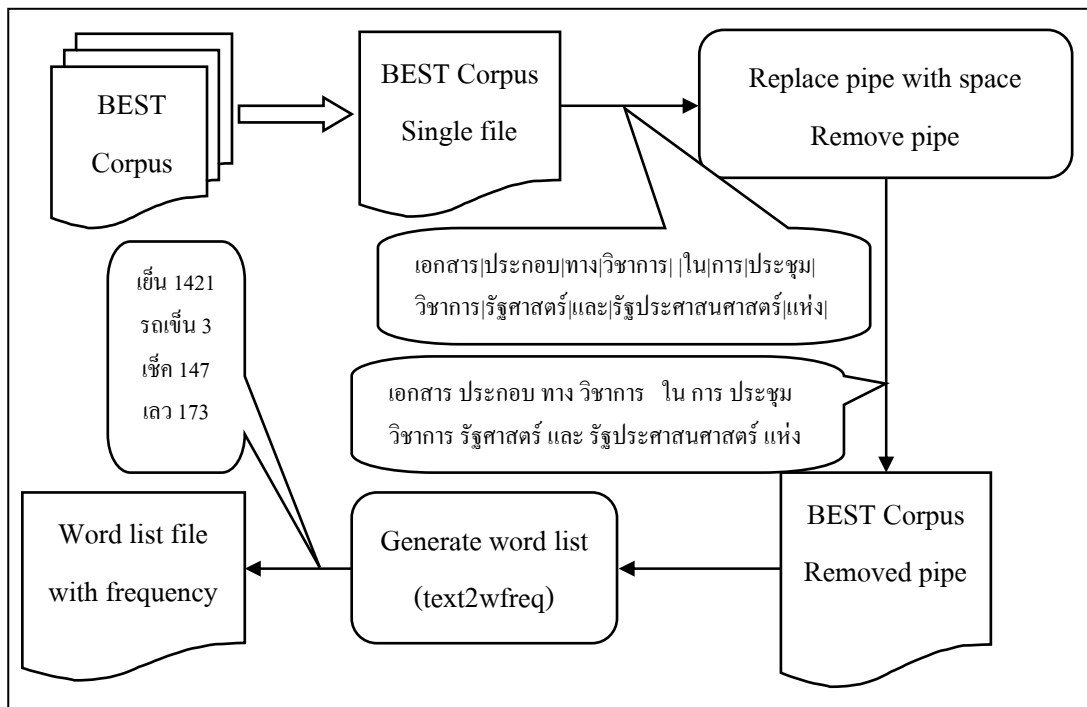
จากรูปที่ 3.20 มีรายละเอียดการทำงานต่างๆ ดังต่อไปนี้

1. สร้างตัวแปร `back_off_weight_value` และ `prob_value` ชนิด Array of Double จำนวน `gram-1` ตามที่ได้กำหนดไว้
2. ค้นหารูปแบบคำที่ไม่พบในคลังข้อมูลฝึกในขนาดแกรมที่ `gram-1`, `gram-2` ไปเรื่อยๆ จนถึงขนาด `1-gram`
3. เก็บค่าดัชนีถ่วงน้ำหนัก (Back-off weight) ของแต่ละแกรมลงในตัวแปร `back_off_weight_value[n]` และเก็บค่าความน่าจะเป็นของแต่ละแกรมลงในตัวแปร `prob_value[n]`
4. คำนวณค่าความน่าจะเป็นแบบ Interpolation โดยนำผลรวมของค่าดัชนีถ่วงน้ำหนัก (Back-off weight) ของแต่ละแกรมคูณด้วยค่าความน่าจะเป็นของแต่ละแกรมและเก็บไว้ในตัวแปร `prob_cal_value` และส่งคืนค่าความน่าจะเป็นแบบ Interpolation กลับคืนไปให้คำสั่งที่เรียกใช้ฟังก์ชันนี้

### 3.9 รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทย

รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยที่ผู้วิจัยได้จัดเตรียมขึ้นมานี้จะนำไปใช้ในขั้นตอน `Translate_to_Thai` และเนื่องจากเอ็นแกรมโมเดลนั้นสามารถนำไปใช้ในด้านการหาขอบเขตของคำเท่านั้น ไม่สามารถนำไปใช้แปลงอักษรเบรลล์ภาษาไทยให้เป็นภาษาไทยได้ นอกจากนี้ผู้วิจัยต้องการเปรียบเทียบประสิทธิภาพระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file [1] เดิม กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ ซึ่งโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมนั้นจะให้เอาท์พุทเป็นข้อความภาษาไทยทำให้จำเป็นต้องมีขั้นตอน `Translate_to_Thai` เพิ่มเติมเข้ามาเพื่อแปลงให้เอาท์พุทเป็นข้อความภาษาไทยเหมือนกันเพื่อเปรียบเทียบกันได้โดยตรง

ดังนั้นผู้วิจัยจึงออกแบบให้การแปลงจากอักษรเบรลล์ภาษาไทยเป็นภาษาไทยใช้วิธีการแบบเทียบเป็นคำต่อคำ เช่น เมื่อตัดคำอักษรเบรลล์ภาษาไทยได้เป็นคำว่า “g,dhm\*y” ซึ่งตรงกันกับคำว่า “กฎหมาย” ในภาษาไทย เมื่อใช้วิธีเทียบเป็นคำต่อคำก็จะแทนที่คำ “g,dhm\*y” ด้วยคำว่า “กฎหมาย” ลงไปแทนในตำแหน่งเดียวกันของข้อความ ซึ่งเมื่อใช้วิธีการนี้แล้วทำให้จำเป็นต้องสร้างทั้งรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยขึ้นมาเพื่อที่จะนำไปใช้กับวิธีการเทียบเป็นคำต่อคำ โดยขั้นตอนการสร้างรายการคำภาษาไทยแสดงไว้ในรูปที่ 3.21



รูปที่ 3.21 ขั้นตอนการสร้างรายการคำภาษาไทย

จากรูปที่ 3.21 มีรายละเอียดวิธีการสร้างรายการคำภาษาไทยเพื่อนำไปใช้ในขั้นตอน Translate\_to\_Thai ดังต่อไปนี้

1. นำไฟล์คลังข้อความ BEST ทั้งหมดรวมเข้าเป็นไฟล์ๆ เดียวกัน เพื่อความสะดวกต่อการนำไปใช้งานและเพื่อใช้ในขั้นตอนการสร้างรายการคำ (Generate word list)
2. เนื่องจากข้อจำกัดของโปรแกรม text2wfreq ที่อยู่ในชุดเครื่องมือ CMU-SLM toolkit ไม่สามารถประมวลผลภาษาไทยได้โดยตรง ทำให้ต้องมีการดัดแปลงเครื่องหมายคั่นระหว่างคำเป็นช่องว่าง (Space) แทนเพื่อให้เหมือนกับการเขียนคำในภาษาอังกฤษที่ใช้ช่องว่างเป็นตัวบ่งบอกขอบเขตของคำ ดังนั้นผู้วิจัยจึงได้แทนที่เครื่องหมายคั่นระหว่างคำ (“|”) ที่ใช้ในคลังข้อความ BEST ด้วยช่องว่างแทน
3. สร้างรายการคำโดยเรียกใช้โปรแกรม text2wfreq ด้วยคำสั่ง “text2wfreq -hash 1000000 <input.text> output.wfreq” โดย text2wfreq เป็นโปรแกรมที่ใช้สร้างรายการคำและออฟชั่น -hash 1000000 หมายถึงให้ของพื้นที่หน่วยความจำไว้สำหรับการสร้าง

Hash-table เพื่อใช้ในการจัดเก็บรายการคำ ถัดไปจะเป็นชื่อของไฟล์อินพุตและชื่อของไฟล์เอาต์พุตตามลำดับ โดยนามสกุลของไฟล์เอาต์พุตจะเป็น \*.wfreq ซึ่งก็คือรายการความถี่ของคำนั่นเอง

เมื่อได้รายการคำภาษาไทยเรียบร้อยแล้วจึงนำรายการคำดังกล่าวไปแปลงให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 โดยใช้โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ [1] (รายละเอียดของโปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์จะอธิบายในหัวข้อ 2.8) ซึ่งให้อเอาต์พุตเป็นข้อความที่อยู่ในรูปแบบอักษรเบรลล์ภาษาไทย โดยใช้คำสั่ง `Thai2brl <[Input file] >[OutputFile] -g 1` ใน Shell prompt โดยโปรแกรม Thai2brl เป็นโปรแกรมที่ทำหน้าที่แปลงจากภาษาไทยเป็นอักษรเบรลล์ภาษาไทย และถัดไปเป็นชื่ออินพุตไฟล์และเอาต์พุตไฟล์ตามลำดับ และออฟชั่น `-g 1` หมายถึงระบุให้อเอาต์พุตอยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1

เมื่อสร้างทั้งรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยแล้ว จึงนำไปใช้งานในโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ได้ออกแบบไว้ต่อไป โดยผู้วิจัยได้ออกแบบให้จัดเก็บรายการคำดังกล่าวไว้ในหน่วยความจำ โดยมีรายละเอียดต่างๆ ดังแสดงในตารางที่ 3.9 ดังนี้

ตารางที่ 3.9 ตัวแปรชนิดต่างๆ ที่ใช้ในการสร้างรายการคำ

รายละเอียด/ประเภทรายการคำ	รายการคำอักษรเบรลล์ภาษาไทย	รายการคำภาษาไทย
ชื่อฟังก์ชันที่ใช้โหลดข้อมูล	<code>void load_braille_word_list()</code>	<code>void load_word_list()</code>
ประเภทข้อมูลที่ใช้จัดเก็บ	global array of string	global array of string
ชื่อข้อมูลที่ใช้จัดเก็บ	<code>word_list_brl[]</code>	<code>word_list[]</code>
ประเภทข้อมูลที่จัดเก็บดัชนี	global integer	global integer
ชื่อข้อมูลที่ใช้จัดเก็บดัชนี	<code>index_word_list_brl</code>	<code>index_word_list</code>
เรียกใช้งานฟังก์ชันเมื่อ	เริ่มโปรแกรมหลัก	เริ่มโปรแกรมหลัก

ในตารางที่ 3.9 จะเห็นได้ว่าลักษณะของฟังก์ชันและข้อมูลที่ใช้จัดเก็บรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยนั้นจะคล้ายคลึงกัน แต่จะแตกต่างกันเพียงแค่ลักษณะข้อมูลที่ถูกจัดเก็บไว้ในหน่วยความจำเท่านั้น ซึ่งก็คือเป็นรายการคำอักษรเบรลล์ภาษาไทยกับรายการคำภาษาไทยเท่านั้นที่แตกต่างกัน

รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยนี้ผู้วิจัยได้ออกแบบให้มีฟังก์ชันสำหรับจัดเก็บรายการคำดังกล่าวไว้ให้อยู่ในหน่วยความจำหลัก โดยมีฟังก์ชันชื่อว่า `load_braille_word_list` และ `load_word_list` ทำหน้าที่โหลดรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยไปไว้ในหน่วยความจำหลัก ทั้งนี้เพื่อความสะดวกรวดเร็วในการเรียกใช้เมื่อตัดคำอักษรเบรลล์ภาษาไทยในแต่ละประโยคเสร็จสิ้น และทั้งสองฟังก์ชันนี้จะเรียกใช้เมื่อมีการเริ่มโปรแกรมหลักเหมือนกัน

ในบทความต่อไปจะกล่าวถึงผลการทดลองโดยเป็นการเปรียบเทียบประสิทธิภาพด้านความถูกต้องของการแปลงอักษรเบรลล์ภาษาไทยระดับ 1 ไปเป็นภาษาไทย, ด้านปริมาณการใช้หน่วยความจำในระหว่างการแปลงและด้านเวลาที่ใช้ในการแปลง ระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file (วิธีการเดิม) กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ (วิธีการใหม่) ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้

## บทที่ 4

### ผลการทดลอง

ในบทนี้ได้นำเสนอผลการทดลองที่ได้ออกแบบไว้ ซึ่งสอดคล้องกันกับวัตถุประสงค์ของวิทยานิพนธ์ที่ได้นำเสนอ โดยมี 3 ประการด้วยกันคือ 1) ศึกษาและพัฒนาการนำเทคนิคเอ็นแกรมเข้ามาช่วยแบ่งคำอักษรเบรลล์ภาษาไทยและแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยที่เกี่ยวข้องกับคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ 2) เปรียบเทียบประสิทธิภาพในด้านความถูกต้อง, ปริมาณการใช้หน่วยความจำและเวลาที่ใช้ในการแปลงระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file (วิธีการเดิม) กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ (วิธีการใหม่) 3) จำนวนแรมที่เหมาะสมสำหรับตัดคำอักษรเบรลล์ภาษาไทยระดับ 1 ทั้งด้านความถูกต้อง, ปริมาณการใช้หน่วยความจำและระยะเวลาที่ใช้ในการแปลง

ผู้วิจัยได้ออกแบบการทดลองทั้งหมดเป็น 3 ด้านเพื่อให้สอดคล้องกันกับจุดประสงค์ดังกล่าวข้างต้น ซึ่งประกอบไปด้วย 1) ด้านความถูกต้องของการแปลง 2) ด้านปริมาณการใช้หน่วยความจำในการแปลง และ 3) ด้านระยะเวลาที่ใช้ในการแปลง โดยในแต่ละด้านมีรายละเอียดดังนี้

#### 4.1 ด้านความถูกต้องของการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย

##### 4.1.1 เครื่องมือที่ใช้ในการทดสอบ

- 1) โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file [1]
- 2) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ
- 3) ชุดข้อมูลทดสอบในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 (รายละเอียดของชุดข้อมูลทดสอบจะอธิบายในหัวข้อ 4.1.3)
- 4) เครื่องคอมพิวเตอร์ติดตั้งระบบปฏิบัติการ Linux Ubuntu version 9.04 1 เครื่อง  
ติดตั้ง CPU Intel รุ่น Core2Quad (Q9400) ความเร็ว 2.66 GHz ติดตั้งหน่วยความจำที่ใช้งานได้ 3.25 GB

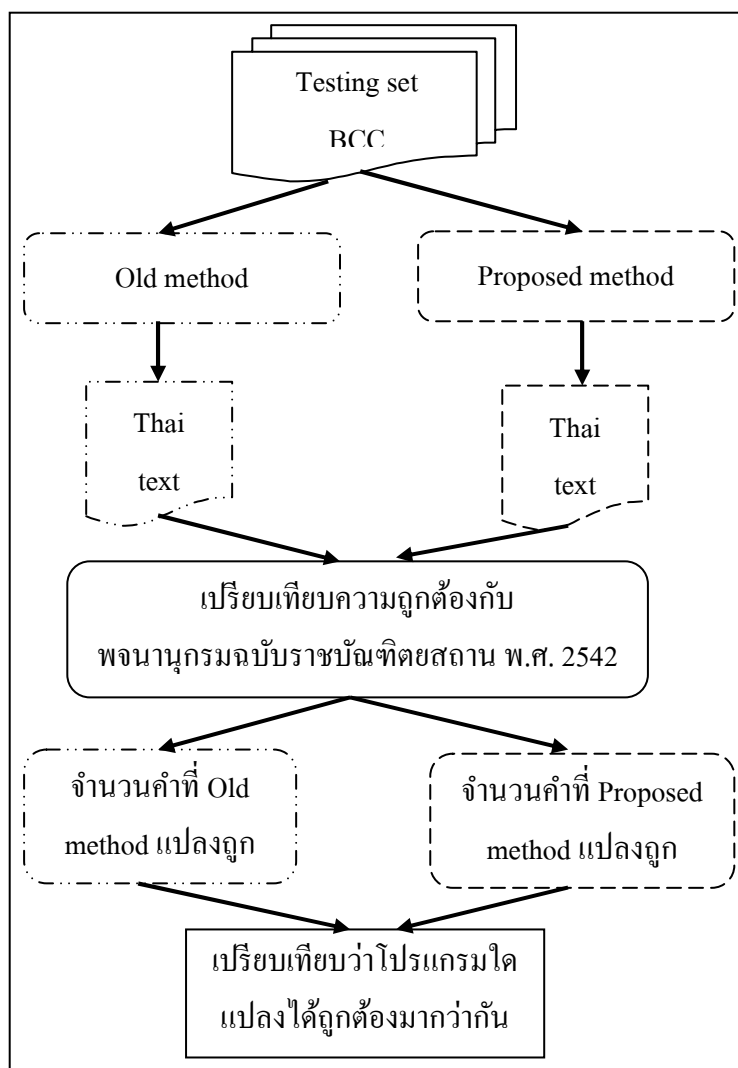


5) C/C++ compiler

6) Gedit Text editor

#### 4.1.2 ภาพรวมการทดสอบด้านความถูกต้องการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย

ผู้วิจัยได้ออกแบบวิธีการทดสอบเปรียบเทียบความถูกต้องการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่าง โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file กับ โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์นี้ โดยได้ใช้แผนภาพเพื่ออธิบายซึ่งง่ายต่อการทำความเข้าใจ โดยภาพรวมวิธีการทดสอบด้านความถูกต้องแสดงในรูปที่ 4.1



รูปที่ 4.1 ภาพรวมวิธีการเปรียบเทียบด้านความถูกต้อง

จากรูปที่ 4.1 มีขั้นตอนวิธีการทดสอบเปรียบเทียบด้านความถูกต้องดังต่อไปนี้

- 1) นำชุดข้อมูลทดสอบ (Testing set) ซึ่งเป็นชุดของไฟล์ข้อความประโยคอักษรเบรลล์ภาษาไทยระดับ 1 โดยแบ่งแยกย่อยออกเป็น 4 ประเภทได้แก่
  - 1.1. ประโยคที่มีการใช้คำควบกล้ำ
  - 1.2. ประโยคที่มีการใช้สระประสม
  - 1.3. ประโยคที่มีการใช้อักษรเบรลล์สองเซลล์
  - 1.4. ประโยคที่มีการใช้คำทับศัพท์

โดยรายละเอียดของชุดข้อมูลทดสอบจะกล่าวในหัวข้อที่ 4.1.3 จากนั้นให้โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file และ โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ แปลงจากข้อความอักษรเบรลล์ภาษาไทยเป็นภาษาไทย
- 2) เมื่อโปรแกรมทั้งสองแปลงเสร็จแล้วก็จะได้ประโยคภาษาไทย จากนั้นจึงนำประโยคดังกล่าวไปเปรียบเทียบกับพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. 2542 เพื่อตรวจสอบความถูกต้อง
- 3) นับจำนวนประโยคที่โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file แปลงถูกต้องและนับจำนวนประโยคที่โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ แปลงถูกต้อง
- 4) เปรียบเทียบว่าโปรแกรมไหนสามารถแปลงข้อความได้ถูกต้องมากกว่ากัน

#### 4.1.3 ชุดข้อมูลทดสอบเปรียบเทียบด้านความถูกต้อง

ชุดข้อมูลทดสอบนี้ผู้วิจัยได้ออกแบบให้ครอบคลุมและสอดคล้องกันกับจุดประสงค์ของงานวิจัยนี้มากที่สุด โดยแบ่งออกเป็น 4 ประเภทด้วยกันคือ

1. ประโยคที่มีการใช้คำควบกล้ำ
2. ประโยคที่มีการใช้สระประสม
3. ประโยคที่มีการใช้อักษรเบรลล์สองเซลล์
4. ประโยคที่มีการใช้คำทับศัพท์

และเพื่อให้ชุดข้อมูลทดสอบดังกล่าวสอดคล้องกันกับประเภทภาษาเขียน ผู้วิจัยจึงได้นำเอาวิธีการรวบรวมข้อความแบบคลังข้อความ BEST [14] มาใช้กับชุดข้อมูลทดสอบนี้ด้วย โดยในแต่ละประเภทจะมีลักษณะการเขียนประโยคทั้ง 3 รูปแบบภาษาคือ

- 1) รูปแบบภาษาเขียนแบบเป็นทางการ โดยรวบรวมจากประโยคในหนังสือสารานุกรมไทยสำหรับเยาวชน, หนังสือเรียนวิชาภาษาไทยและหนังสือเรียนวิชาสังคมศึกษา
- 2) รูปแบบภาษาเขียนแบบไม่เป็นทางการ โดยรวบรวมจากประโยคในนวนิยายทั่วไปและบทความละครจากหนังสือพิมพ์
- 3) รูปแบบภาษาข่าว โดยรวบรวมจากบทความหนังสือพิมพ์ในอินเทอร์เน็ต

โดยรายละเอียดของชุดข้อมูลทดสอบสรุปได้ดังแสดงในตารางที่ 4.1

ตารางที่ 4.1 รายละเอียดชุดข้อมูลทดสอบด้านความถูกต้อง

ประเภทไฟล์	คำควบกล้ำ	สระประสม	เบรลล์สองเซลล์	คำทับศัพท์
ขนาดไฟล์ (KB)	9,923	9,700	315	820
ค่าเฉลี่ยจำนวนอักขระต่อบรรทัด	42.96	44.35	35.82	43.44
จำนวนคำเฉพาะ	231,115	219,022	8,713	18,881
จำนวนคำทั้งหมด	2,324,072	2,273,127	85,010	190,609
จำนวนคำเฉพาะคิดเป็นเปอร์เซ็นต์ของจำนวนคำทั้งหมด	9.94	9.64	10.25	9.91

ชุดข้อมูลทดสอบเหล่านี้เป็นประโยคภาษาไทยที่มีการใช้คำเฉพาะคือ คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ บรรจุอยู่ในแต่ละประโยค ซึ่งแต่ละประโยคนั้นอาจจะมีคำเฉพาะเหล่านี้มากกว่าหนึ่งคำก็ได้แต่อย่างน้อยทุกๆ ประโยคจะต้องมีคำเฉพาะเหล่านี้อย่างน้อยหนึ่งคำ จากนั้นผู้วิจัยได้ใช้โปรแกรมแปลงภาษาไทยเป็นอักษรเบรลล์ [1] (Thai2brl) ซึ่ง

เป็นโปรแกรมที่ทำหน้าที่แปลงภาษาไทยไปเป็นอักษรเบรลล์ระดับ 1 ซึ่งได้มีผู้พัฒนามาก่อนแล้ว เพื่อแปลงให้ชุดข้อมูลทดสอบดังกล่าวอยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 จากนั้นจึงนำชุดข้อมูลทดสอบดังกล่าวให้โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file และโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ แปลงซึ่งจะได้ผลลัพธ์ออกมาเป็นประโยคภาษาไทย และนำไปเปรียบเทียบความถูกต้องกับชุดข้อมูลทดสอบซึ่งเป็นประโยคภาษาไทยต้นฉบับ เพื่อตรวจสอบความถูกต้องและหาข้อผิดพลาดต่อไป

#### 4.1.4 ผลการทดลองเปรียบเทียบด้านความถูกต้อง

ผลการทดลองเปรียบเทียบการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 3-แกรม, 4-แกรมและ 5-แกรม ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ พบว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 4-แกรมและ 5-แกรม สามารถช่วยเพิ่มความถูกต้องในการแปลงประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ ได้มากที่สุด โดยผลการทดลองสามารถสรุปได้ดังตารางที่ 4.2

ตารางที่ 4.2 ผลการทดลองเปรียบเทียบความถูกต้องของวิธีการเดิมและวิธีการใหม่

ประเภทข้อมูล	ประเภทของประโยค			
	คำควบกล้ำ	สระประสม	อักษรเบรลล์ สองเซลล์	คำทับศัพท์
จำนวนประโยคทั้งหมด	231,115	219,022	8,713	18,881
จำนวนประโยคที่วิธีการเดิม แปลงถูกต้อง	183,562	172,340	4,995	14,003
อัตราการแปลงถูกต้อง ของวิธีการเดิม (%)	79.42%	78.69%	57.33%	74.16%

ตารางที่ 4.2 ผลการทดลองเปรียบเทียบความถูกต้องของวิธีการเดิมและวิธีการใหม่ (ต่อ)

ประเภทข้อมูล	ประเภทของประโยค			
	คำควบกล้ำ	สระประสม	อักษรเบรลล์ สองเซลล์	คำทับศัพท์
จำนวนประโยคที่วิธีการใหม่ ขนาด 3-แกรมแปลงถูกต้อง	204,979	194,817	8,098	16,829
อัตราการแปลงถูกต้องของวิธีการใหม่ ขนาด 3-gram (%)	88.69%	88.95%	92.94%	89.13%
จำนวนประโยคที่วิธีการใหม่ ขนาด 4-แกรมแปลงถูกต้อง	215,768	205,071	8,525	17,715
อัตราการแปลงถูกต้องของวิธีการใหม่ ขนาด 4-gram (%)	93.36%	93.63%	97.84%	93.82%
จำนวนประโยคที่วิธีการใหม่ ขนาด 5-แกรมแปลงถูกต้อง	215,768	205,071	8,525	17,715
อัตราการแปลงถูกต้องของวิธีการใหม่ ขนาด 5-gram (%)	93.36%	93.63%	97.84%	93.82%
วิธีการเดิม: โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file				
วิธีการใหม่: โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ				

จากการทดลองเปรียบเทียบความถูกต้องของการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยพบว่าเทคนิคเอ็นแกรมที่นำมาใช้ในการตัดคำอักษรเบรลล์ภาษาไทยก่อนที่จะแปลงไปเป็นภาษาไทย จำนวนแกรมที่เหมาะสมคือ 4-แกรม เนื่องจากเมื่อใช้จำนวนแกรมเท่ากับ 4-แกรมสามารถช่วยลดปัญหาความกำกวมของการเขียนอักษรเบรลล์ภาษาไทยได้เป็นอย่างดี และสามารถแปลงได้ถูกต้องในระดับที่มากกว่า 93 เปอร์เซ็นต์ในทุกประเภทของประโยคเมื่อเปรียบเทียบกับโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิมที่ใช้เทคนิคการเขียน

กฎไวยากรณ์ทางภาษาเข้ามาจำกัดการแปลง ซึ่งไม่ครอบคลุมลักษณะรูปแบบการเขียนอักขรเบรลล์ภาษาไทยทั้งหมดได้ และมีอัตราความถูกต้องในการแปลงต่ำกว่า หากใช้จำนวนแกรมเป็น 3-แกรม อัตราความถูกต้องในการแปลงจะลดลง หากใช้จำนวนแกรมเป็น 5-แกรมอัตราความถูกต้องในการแปลงจะไม่เพิ่มขึ้น และใช้เวลาในการประมวลผลมากกว่าการใช้จำนวนแกรมเป็น 4-แกรม

ดังนั้นสรุปได้ว่าการนำเทคนิคเอ็นแกรมเข้ามาช่วยตัดคำอักขรเบรลล์ภาษาไทยก่อนที่จะแปลงไปเป็นภาษาไทยสามารถลดความกำกวมของภาษาลงไปได้ ซึ่งทำให้โปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยทราบขอบเขตที่ชัดเจนของคำแต่ละคำ และแปลงได้ถูกต้องมากยิ่งขึ้น และจำนวนแกรมที่เหมาะสมคือ 4-แกรม

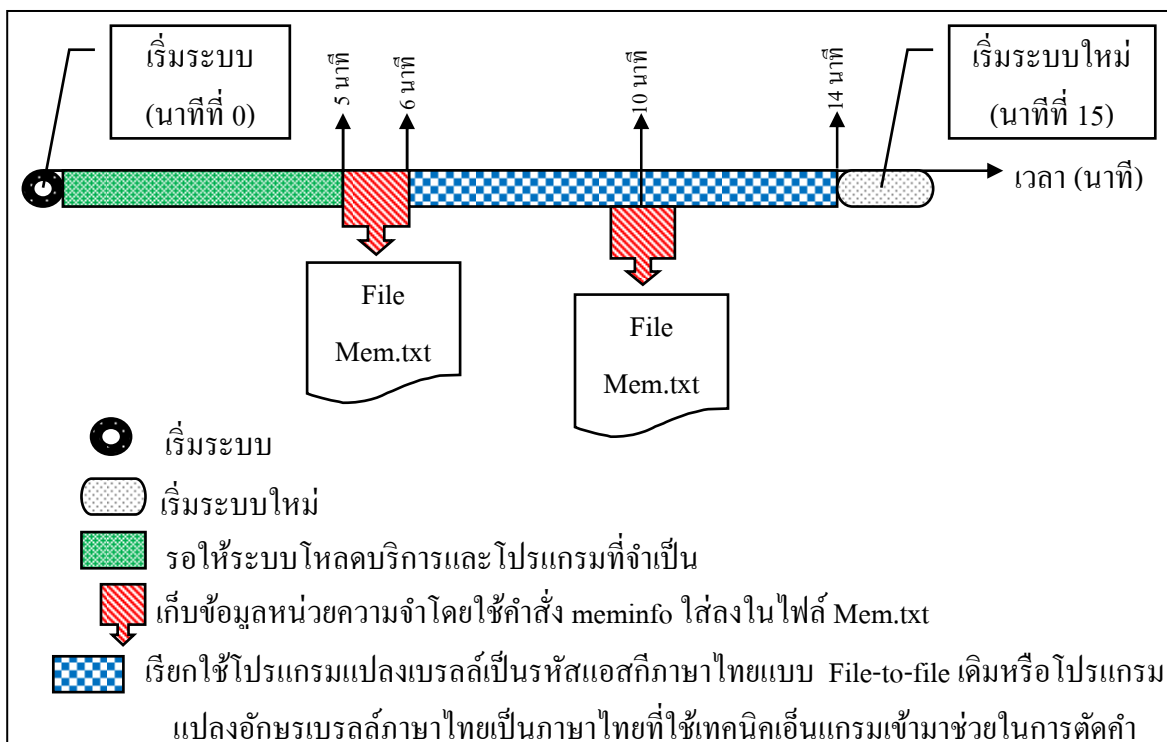
#### 4.2 ด้านปริมาณการใช้หน่วยความจำในการแปลง

##### 4.2.1 เครื่องมือที่ใช้ในการทดสอบ

- 1) โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file
- 2) โปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ
- 3) ชุดข้อมูลทดสอบในรูปแบบอักขรเบรลล์ภาษาไทยระดับ 1 (รายละเอียดของชุดข้อมูลทดสอบจะอธิบายในหัวข้อ 4.2.3)
- 4) เครื่องคอมพิวเตอร์ติดตั้งระบบปฏิบัติการ Linux Ubuntu version 9.04 1 เครื่อง  
ติดตั้ง CPU Intel รุ่น Core2Quad (Q9400) ความเร็ว 2.66 GHz ติดตั้งหน่วย  
หน่วยความจำที่ใช้งานได้ 3.25 GB
- 5) C/C++ compiler
- 6) Gedit Text editor

##### 4.2.2 ภาพรวมการทดสอบปริมาณการใช้หน่วยความจำในการแปลง

ผู้วิจัยได้ออกแบบวิธีการทดสอบเปรียบเทียบปริมาณการใช้หน่วยความจำในการแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ โดยภาพรวมวิธีการทดลองด้านปริมาณการใช้หน่วยความจำแสดงในรูปที่ 4.2



รูปที่ 4.2 ภาพรวมวิธีการทดลองด้านปริมาณการใช้หน่วยความจำ

จากรูปที่ 4.2 ผู้วิจัยได้แสดงภาพรวมวิธีการทดลองวัดปริมาณการใช้หน่วยความจำของโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม และโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ซึ่งมีขั้นตอนดังต่อไปนี้

- 1) เริ่มระบบเครื่องคอมพิวเตอร์ที่ติดตั้งระบบปฏิบัติการ Linux Ubuntu เวอร์ชัน 9.04
- 2) รอให้ระบบปฏิบัติการเรียกใช้งานบริการที่จำเป็นและโปรแกรมอื่นๆ ให้เสร็จสิ้นก่อน โดยต้องการให้มีผลกระทบกับการทดลองด้านปริมาณการใช้หน่วยความจำของโปรแกรมแปลงให้น้อยที่สุด โดยรอเป็นระยะเวลา 5 นาที
- 3) หลังจากรอเป็นระยะเวลา 5 นาทีแล้ว ผู้วิจัยได้ใช้คำสั่ง `cat /proc/meminfo >> mem.txt` ใน Terminal ซึ่งเป็นคำสั่งให้แสดงข้อมูลเกี่ยวกับหน่วยความจำของระบบออกมาและเก็บข้อมูลดังกล่าวไว้ในไฟล์ข้อความที่ชื่อว่า mem.txt โดยผู้วิจัยจะใช้ข้อมูลเฉพาะปริมาณหน่วยความจำที่ว่าง MemFree : โดยเปรียบเทียบปริมาณหน่วยความจำที่ว่าง

ก่อนเรียกใช้งานโปรแกรมแปลงและระหว่างโปรแกรมแปลงกำลังทำงาน โดยผลต่างของปริมาณหน่วยความจำที่ว่างก็คือหน่วยความจำที่โปรแกรมแปลงต้องใช้นั่นเอง

- 4) ในนาทีที่ 6 ผู้วิจัยเรียกใช้โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม หรือโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เพื่อให้แปลงข้อความจากอักษรเบรลล์ภาษาไทยเป็นภาษาไทย โดยใช้ชุดข้อมูลทดสอบที่ได้เตรียมเอาไว้ ซึ่งรายละเอียดของชุดข้อมูลทดสอบจะกล่าวในหัวข้อที่ 4.2.3
- 5) ในนาทีที่ 10 ผู้วิจัยได้ใช้คำสั่ง `cat /proc/meminfo >> mem.txt` ใน Terminal อีกครั้งเพื่อวัดปริมาณการใช้หน่วยความจำในขณะที่โปรแกรมแปลงกำลังทำงาน
- 6) ในนาทีที่ 15 หรือเมื่อโปรแกรมแปลงทำงานเสร็จสิ้นแล้วผู้วิจัยจะเริ่มระบบปฏิบัติการใหม่อีกครั้ง (Restart) เพื่อเริ่มการทดลองใหม่อีกครั้งและเป็นการป้องกันปัญหาการคืนหน่วยความจำให้แก่ระบบและผลกระทบอื่นๆ จากบริการและโปรแกรมอื่นๆ ที่ระบบปฏิบัติการเรียกขึ้นมาใช้งาน
- 7) ทำการทดลองซ้ำแต่ละโปรแกรมทั้งหมด 10 ครั้ง และในแต่ละครั้งเมื่อทดลองเสร็จสิ้นจะเริ่มเครื่องคอมพิวเตอร์ใหม่ทุกครั้ง

ซึ่งในการทดลองเปรียบเทียบปริมาณการใช้หน่วยความจำนี้ เพื่อต้องการเปรียบเทียบว่าโปรแกรมใดเหมาะสมที่จะนำไปใช้บนอุปกรณ์คอมพิวเตอร์แบบพกพาสำหรับผู้พิการทางสายตา เช่น Braille Note [1] มากกว่ากัน ทั้งนี้เพราะอุปกรณ์ Braille Note นั้นมีทรัพยากรที่จำกัดทั้งในด้านความเร็วของหน่วยประมวลผลกลางและปริมาณหน่วยความจำหลัก

#### 4.2.3 ชุดข้อมูลทดสอบด้านปริมาณการใช้หน่วยความจำ

ชุดข้อมูลสำหรับทดสอบเปรียบเทียบปริมาณการใช้หน่วยความจำนี้ ผู้วิจัยได้นำชุดข้อมูลทดสอบนี้มาจากการชุดข้อมูลทดสอบเปรียบเทียบความถูกต้อง แต่พบว่าไฟล์ที่บรรจุประโยคที่มีการใช้อักษรเบรลล์สองเซลล์และคำทับศัพท์มีจำนวนค่าน้อยมาก และโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file แปลงได้รวดเร็วมากจนไม่สามารถเรียกใช้คำสั่ง `cat /proc/meminfo >> mem.txt` ใน Terminal เพื่อเก็บข้อมูลปริมาณการใช้หน่วยความจำได้ทัน จึงไม่สามารถวัดปริมาณการใช้หน่วยความจำเมื่อใช้ไฟล์ประเภทดังกล่าวทดสอบ ทำให้ในการทดลองนี้



ใช้เฉพาะไฟล์ที่บรรจุประโยคที่มีการใช้คำควบกล้ำและสระประสมเท่านั้น โดยสามารถสรุปได้ดังตารางที่ 4.3

ตารางที่ 4.3 รายละเอียดชุดข้อมูลทดสอบด้านปริมาณการใช้หน่วยความจำ

ประเภทไฟล์	คำควบกล้ำ	สระประสม
ขนาดไฟล์ (KB)	9,923	9,700
ค่าเฉลี่ยจำนวนอักขระต่อบรรทัด	42.96	44.35
จำนวนคำเฉพาะ	231,115	219,022
จำนวนคำเฉพาะคิดเป็นเปอร์เซ็นต์ของจำนวนทั้งหมด	51.34	48.66

#### 4.2.4 ผลการทดลองเปรียบเทียบปริมาณการใช้หน่วยความจำ

ผลการทดลองเปรียบเทียบปริมาณการใช้หน่วยความจำในการแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำเมื่อใช้จำนวนแกรมเท่ากับ 3-แกรม, 4-แกรม และ 5-แกรม ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ โดยทดลองซ้ำทั้งหมด 10 ครั้งและหาค่าเฉลี่ย พบว่าโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำใช้ปริมาณหน่วยความจำน้อยกว่าโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file มาก ซึ่งมีผลการทดลองดังแสดงในตารางที่ 4.4 และผลการทดลองด้านปริมาณการใช้หน่วยความจำในการแปลงทั้งหมดจะแสดงไว้ในตารางที่ 1 ในภาคผนวก ข

ตารางที่ 4.4 ผลการทดลองปริมาณการใช้หน่วยความจำ

ครั้งที่	วิธีการเดิม		วิธีการใหม่					
			3-แกรม		4-แกรม		5-แกรม	
	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)
เฉลี่ย	178.9	178.9	8.19	8.21	8.89	8.9	8.79	8.81
SD.	0.1729	0.2424	0.1524	0.1197	0.1449	0.2108	0.1197	0.0994
Max	179.2	179.3	8.5	8.4	9.2	9.3	9	9
Min	178.7	178.6	8	8	8.7	8.7	8.6	8.7

จากผลการทดลองเปรียบเทียบด้านปริมาณการใช้หน่วยความจำระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 3-แกรม, 4-แกรม และ 5-แกรม จะเห็นได้ว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำมีปริมาณการใช้หน่วยความจำเฉลี่ยแล้วอยู่ในช่วงระหว่างประมาณ 8.19-8.9 MB ซึ่งน้อยกว่าโปรแกรมเดิมมากประมาณ 20 เท่า ทั้งนี้เนื่องจากโปรแกรมเดิมได้ใช้ลักษณะการทำงานแบบรีเคอร์ซีฟ (Recursive) ซึ่งใช้ปริมาณหน่วยความจำมากแตกต่างจากโปรแกรมที่นำเสนอในที่นี้ที่ใช้ลักษณะการทำงานแบบวนรอบ (For loop) เพื่อค้นหารูปแบบเอ็นแกรม (N-gram pattern) ที่คล้ายคลึงกัน

ดังนั้นจึงสรุปได้ว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ มีความเหมาะสมกับการนำไปใช้บนอุปกรณ์ Braille note [32] ที่มีทรัพยากรจำกัดมากกว่าโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม โดยเฉพาะอย่างยิ่งหน่วยความจำ

#### 4.3 ระยะเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย

##### 4.3.1 เครื่องมือที่ใช้ในการทดสอบ

- 1) โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file
- 2) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ

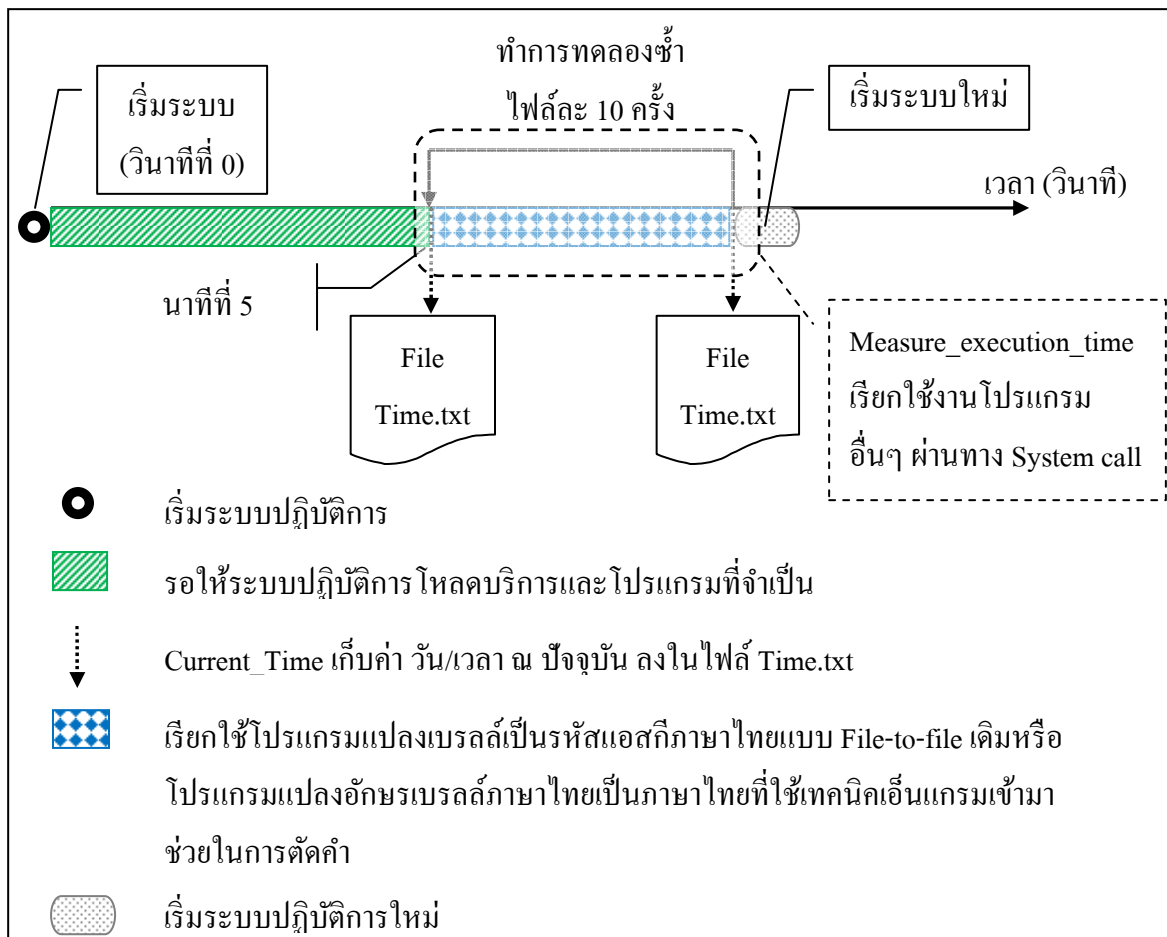
- 3) ชุดข้อมูลทดสอบในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 (รายละเอียดของชุดข้อมูลทดสอบจะอธิบายในหัวข้อ 4.2.3)
- 4) เครื่องคอมพิวเตอร์ติดตั้งระบบปฏิบัติการ Linux Ubuntu version 9.04 1 เครื่อง  
ติดตั้ง CPU Intel รุ่น Core2Quad (Q9400) ความเร็ว 2.66 GHz ติดตั้งหน่วย  
หน่วยความจำที่ใช้งานได้ 3.25 GB
- 5) C/C++ compiler
- 6) Gedit Text editor

#### 4.3.2 ภาพรวมการทดสอบระยะเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย

ผู้วิจัยได้ออกแบบวิธีการทดสอบเปรียบเทียบความรวดเร็วในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ โดยใช้วิธีสร้างโปรแกรมที่ชื่อว่า `measure_execution_time` เพื่อทำหน้าที่เรียกใช้งานโปรแกรมแปลงเหล่านี้ผ่านทาง การเรียกผ่านระบบ (System call) เนื่องจากผู้วิจัยต้องการให้โปรแกรมอื่นๆ มีการทำงานที่ต่อเนื่องกันไปตลอด ทั้งการจับเวลาและการแปลงข้อความอักษรเบรลล์ภาษาไทยเป็นภาษาไทย โดยมีลำดับการเรียกใช้งานโปรแกรมอื่นๆ ดังนี้

- 1) เรียกใช้งานโปรแกรมเก็บค่า วัน/เวลา ณ ปัจจุบัน (`Current_Time`) ครั้งแรก (ก่อนแปลง) แล้วเก็บค่าลงในไฟล์ `Time.txt` โดยโปรแกรม `Current_Time` เป็นโปรแกรมที่ผู้วิจัยสร้างขึ้นมา เพื่อเรียกใช้คำสั่ง `date` ผ่านทางการเรียกผ่านระบบซึ่งแสดงค่า วัน/เวลา ณ ปัจจุบันของระบบปฏิบัติการออกมา
- 2) เรียกใช้โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file หรือโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เพื่อแปลงชุดข้อมูลทดสอบจากอักษรเบรลล์ภาษาไทยเป็นภาษาไทย
- 3) เรียกใช้งานโปรแกรมเก็บค่า วัน/เวลา ณ ปัจจุบัน ครั้งที่สอง (หลังแปลง) แล้วเก็บค่าลงในไฟล์ `Time.txt`

โดยผลต่างเวลาคั้งแรกและคั้งที่สองก็คือเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยไปเป็นภาษาไทยของโปรแกรมแปลงนั่นเอง โดยมีภาพรวมวิธีการการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง ดังแสดงในรูปที่ 4.3



รูปที่ 4.3 ภาพรวมวิธีการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง

จากรูปที่ 4.3 ผู้วิจัยได้แสดงภาพรวมวิธีการทดลองวัดเวลาในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยของโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file และโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ซึ่งมีขั้นตอนดังต่อไปนี้

1. เริ่มระบบเครื่องคอมพิวเตอร์ที่ติดตั้งระบบปฏิบัติการ Linux Ubuntu เวอร์ชัน 9.04
2. รอให้ระบบปฏิบัติการเรียกใช้งานบริการที่จำเป็นและโปรแกรมอื่นๆ ให้เสร็จสิ้นก่อน โดยต้องการให้มีผลกระทบกับการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงของ

โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยให้น้อยที่สุด โดยรอเป็นระยะเวลา 300 วินาที (5 นาที)

3. หลังจากรอเป็นระยะเวลา 300 วินาทีแล้ว ผู้วิจัยได้เรียกใช้โปรแกรม `measure_execution_time` ที่ได้สร้างขึ้นมาก่อนหน้านี้แล้ว เพื่อเริ่มกระบวนการจับเวลาในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยของโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม หรือโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ โดยในแต่ละไฟล์จะทดลองจับเวลาทั้งหมด 10 ครั้ง
4. หลังจากจับเวลาในการแปลงของแต่ละไฟล์เสร็จแล้วผู้วิจัยจะเริ่มระบบปฏิบัติการใหม่อีกครั้ง เพื่อเริ่มการทดลองจับเวลากับไฟล์อื่นๆ โดยใช้ชุดข้อมูลทดสอบที่ได้เตรียมเอาไว้ ซึ่งรายละเอียดของชุดข้อมูลทดสอบจะกล่าวในหัวข้อที่ 4.3.3

ซึ่งในการทดลองเปรียบเทียบความรวดเร็วในการแปลงนี้ เพื่อต้องการเปรียบเทียบว่าโปรแกรมใดสามารถแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้รวดเร็วกว่ากัน

#### 4.3.3 ชุดข้อมูลทดสอบเปรียบเทียบด้านเวลาที่ใช้ในการแปลง

ชุดข้อมูลทดสอบเปรียบเทียบเวลาที่ใช้ในการแปลงนี้ผู้วิจัยได้ออกแบบให้สอดคล้องกันกับลักษณะไฟล์ที่ผู้ใช้นิยมนำมาใช้งานในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย โดยมีขนาดประมาณ 10 KB (ประมาณ 10 หน้า) โดยเป็นไฟล์ข้อความล้วน และเขียนอยู่ในรูปของอักษรเบรลล์ภาษาไทยระดับ 1 รวมทั้งมีการใช้สัญลักษณ์ต่างๆ ในการเขียนด้วยเช่น เครื่องหมายอัญประกาศ, นขลิขิต, ปรศนี เป็นต้น โดยแบ่งออกเป็น 5 ประเภทด้วยกันคือ

1. ประโยคที่มีการใช้คำควบกล้ำ จำนวน 5 ไฟล์
2. ประโยคที่มีการใช้สระประสม จำนวน 5 ไฟล์
3. ประโยคที่มีการใช้อักษรเบรลล์สองเซลล์ จำนวน 5 ไฟล์
4. ประโยคที่มีการใช้คำทับศัพท์ จำนวน 5 ไฟล์
5. ประโยคทั่วไป จำนวน 10 ไฟล์

โดยประเภทประโยคทั่วไป เป็นการรวบรวมเอาประโยคที่มีการใช้คำควบกล้ำ, อักษรเบรลล์สองเซลล์, สระประสมและคำทับศัพท์เข้าไว้ด้วยกัน และเพื่อให้ชุดข้อมูลทดสอบดังกล่าว

ใกล้เคียงกันกับประโยคที่ผู้ใช้งานได้ใช้งานจริงและสอดคล้องกันกับประเภทของภาษาเขียน ผู้วิจัยจึงได้นำเอาวิธีการรวบรวมข้อความแบบคลังข้อความ BEST [14] มาใช้ในชุดข้อมูลทดสอบนี้ด้วย โดยในแต่ละประเภทจะประกอบไปด้วยลักษณะการเขียนทั้ง 3 รูปแบบภาษาคือ

1. รูปแบบภาษาเขียนแบบเป็นทางการ นำมาจากประโยคในหนังสือสารานุกรมไทยสำหรับเยาวชน, หนังสือเรียนวิชาภาษาไทยและหนังสือเรียนวิชาสังคมศึกษา
2. รูปแบบภาษาเขียนแบบไม่เป็นทางการ นำมาจากประโยคในนวนิยายทั่วไปและบทความละครจากหนังสือพิมพ์
3. รูปแบบภาษาข่าว นำมาจากบทความหนังสือพิมพ์ในอินเทอร์เน็ต

ซึ่งในแต่ละประเภททั้ง 5 ประเภทที่นำมาทดสอบเปรียบเทียบเวลาที่ใช้ในการแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยใน โดยในแต่ละไฟล์จะมีลักษณะการเขียนทั้ง 3 รูปแบบดังกล่าว เพื่อให้ชุดข้อมูลทดสอบดังกล่าวมีความใกล้เคียงกันกับลักษณะการเขียนที่ผู้ใช้ได้ใช้งานจริงมากที่สุดเท่าที่จะเป็นไปได้ โดยรายละเอียดของชุดข้อมูลทดสอบเปรียบเทียบเวลาที่ใช้ในการแปลงสามารถสรุปได้ดังแสดงในตารางที่ 4.5 – 4.9

ตารางที่ 4.5 รายละเอียดประเภทคำควบกล้ำ

ประเภทคำควบกล้ำ					
ไฟล์ที่	1	2	3	4	5
จำนวนบรรทัด	198	205	200	178	182
ขนาด(KB)	9.76	10	10	9.83	9.95
ค่าเฉลี่ยจำนวนตัวอักษรต่อบรรทัด	49.53	48.97	50.33	55.6	54.99
จำนวนคำควบกล้ำ	198	205	200	178	182

ตารางที่ 4.6 รายละเอียดประเภทสระประสม

ประเภทสระประสม					
ไฟล์ที่	1	2	3	4	5
จำนวนบรรทัด	197	197	191	202	198
ขนาด(KB)	9.86	9.64	9.17	9.19	9.76
ค่าเฉลี่ยจำนวน ตัวอักษรต่อบรรทัด	50.26	49.11	48.18	45.62	49.52
จำนวนคำสระประสม	197	197	191	202	198

ตารางที่ 4.7 รายละเอียดประเภทอักษรเบรลล์สองเซลล์

ประเภทอักษรเบรลล์สองเซลล์					
ไฟล์ที่	1	2	3	4	5
จำนวนบรรทัด	211	211	245	214	217
ขนาด(KB)	9.14	9.17	9.6	9.92	9.87
ค่าเฉลี่ยจำนวน ตัวอักษรต่อบรรทัด	43.39	43.54	39.16	46.51	45.59
จำนวนคำอักษรเบรลล์สองเซลล์	211	211	245	214	217

ตารางที่ 4.8 รายละเอียดประเภทคำทับศัพท์

ประเภทคำทับศัพท์					
ไฟล์ที่	1	2	3	4	5
จำนวนบรรทัด	193	191	186	196	185
ขนาด(KB)	9.98	9.68	9.96	10	9.19
ค่าเฉลี่ยจำนวน ตัวอักษรต่อบรรทัด	51.98	50.9	53.88	51.26	49.9
จำนวนคำทับศัพท์	193	191	186	196	185

ตารางที่ 4.9 รายละเอียดประเภทข้อความทั่วไป

ประเภทประโยคทั่วไป										
ไฟล์ที่	1	2	3	4	5	6	7	8	9	10
ขนาด (KB)	9.92	9.97	9.98	9.91	9.96	10.00	10.00	10.00	9.95	9.98
จำนวนบรรทัด	198	224	214	201	214	219	218	214	221	195
จำนวนคำเฉพาะ	198	224	214	201	214	219	218	214	221	195
ค่าเฉลี่ยจำนวน ตัวอักษรต่อบรรทัด	50.33	44.61	46.79	49.53	46.68	45.91	46.05	46.98	45.11	51.45

#### 4.3.4 ผลการทดลองเปรียบเทียบด้านเวลาที่ใช้ในการแปลง

ผลการทดลองเปรียบเทียบเปรียบเทียบเวลาที่ใช้ในการแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 4-แกรม ซึ่งเป็นจำนวนแกรมที่มีความเหมาะสมมากที่สุดในการตัดคำอักขรเบรลล์ภาษาไทย เนื่องจากผลการทดลองด้านความถูกต้องในการแปลงในหัวข้อ 4.1.4 เมื่อจำนวนแกรมเท่ากับ 4-แกรม ก็สามารถให้ผลการแปลงที่มีความถูกต้องมากที่สุดแล้วโดยไม่จำเป็นที่จะต้องใช้น้ำหนักแกรมที่มากขึ้นแต่อย่างใด และผลการทดลองด้านปริมาณการใช้หน่วยความจำในหัวข้อ 4.2.4 เมื่อใช้จำนวนแกรมเท่ากับ 4-แกรม ก็มีการใช้ปริมาณหน่วยความจำที่ใกล้เคียงกันกับจำนวนแกรมเท่ากับ 5-แกรม ดังนั้นในการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงจึงใช้จำนวนแกรมเท่ากับ 4-แกรมเท่านั้นในการเปรียบเทียบกับโปรแกรมเดิม

โดยผลการทดลองพบว่าโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 4-แกรม ใช้เวลาในการแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่มากกว่าโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม อยู่พอสมควร โดยผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงอักขรเบรลล์ภาษาไทยไปเป็นภาษาไทยระหว่างโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักขรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ แสดงในตารางที่ 4.10 และผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงทั้งหมดจะแสดงไว้ในตารางที่ 2-7 ในภาคผนวก ข



ตารางที่ 4.10 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง

ประเภทประโยค	วิธีการเดิม	วิธีการใหม่
คำควบกล้ำ (ค่าเฉลี่ยเวลา : วินาที)	0.5786	158.28
S.D.	0.141248	9.012554
Max	0.76	176
Min	0.41	148
Average file size (KB)	9.908	9.908
สระประสม (ค่าเฉลี่ยเวลา : วินาที)	0.59	158.12
S.D.	0.077249	19.88502
Max	0.74	196
Min	0.51	140
Average file size (KB)	9.524	9.524
เบรลล์สองเซล์ (ค่าเฉลี่ยเวลา : วินาที)	0.634	171.58
S.D.	0.10218	9.731267
Max	0.78	187
Min	0.53	160
Average file size (KB)	9.54	9.54

ตารางที่ 4.10 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลง (ต่อ)

ประเภทประโยค	วิธีการเดิม	วิธีการใหม่
คำทับศัพท์ (ค่าเฉลี่ยเวลา : วินาที)	0.5356	159.6
S.D.	0.065781	8.111468
Max	0.65	172
Min	0.41	146
Average file size (KB)	9.762	9.762
ทั่วไป (ค่าเฉลี่ยเวลา : วินาที)	0.5476	160.1
S.D.	0.009653	5.418822
Max	0.56	168
Min	0.53	150
Average file size (KB)	9.967	9.967

จากการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย พบว่าโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม สามารถแปลงได้รวดเร็วกว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ เมื่อใช้จำนวนแกรมเท่ากับ 4-แกรม เนื่องจากโปรแกรมเดิมใช้เทคนิคการแปลงแบบใช้กฎไวยากรณ์ทางภาษาเข้ามาควบคุมการแปลงร่วมกับวิธีการเขียนโปรแกรมแบบรีเคอร์ซีฟ (Recursive) ซึ่งแตกต่างจากวิธีที่นำเอาเทคนิคเอ็นแกรมเข้ามาช่วยตัดคำอักษรเบรลล์ภาษาไทย

ก่อนที่จะแปลงเป็นภาษาไทยและใช้วิธีการเขียนโปรแกรมแบบวนรอบ เพื่อค้นหารูปแบบเอ็นแกรม (N-gram pattern) ที่คล้ายคลึงกัน ทำให้โปรแกรมที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้สามารถแปลงได้ช้ากว่าโปรแกรมเดิม

อย่างไรก็ตามโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ ใช้เวลาในการแปลงข้อความอักษรเบรลล์ภาษาไทยเป็นภาษาไทย อยู่ในเกณฑ์ที่สามารถยอมรับได้ คือใช้เวลาประมาณไม่เกิน 3 นาที ในการแปลงเอกสารข้อความประมาณ 10 หน้า และให้ผลการแปลงที่ถูกต้องมากกว่าโปรแกรมเดิมเป็นอย่างมาก

#### 4.4 สรุปผลการทดสอบ

การทดลองเปรียบเทียบประสิทธิภาพด้านความถูกต้องในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทย, การเปรียบเทียบด้านปริมาณการใช้หน่วยความจำและการเปรียบเทียบเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยระหว่างโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้กับโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file พบว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำมีประสิทธิภาพที่ดีกว่าด้านความถูกต้องในการแปลงและด้านปริมาณการใช้หน่วยความจำ แต่ใช้เวลาในการแปลงมากกว่าโปรแกรมเดิมมาก จึงเหมาะสำหรับนำไปใช้แปลงเอกสารทั่วไปที่ไม่ได้มีความยาวมากนักและไม่เหมาะที่จะนำไปใช้แปลงไฟล์ที่มีขนาดใหญ่มาก ซึ่งทำให้ใช้เวลาแปลงนานเกินไป ในบทความต่อไปจะกล่าวถึงการสรุปผลการวิจัย, ปัญหาและอุปสรรคที่พบและข้อเสนอแนะต่างๆ ที่ควรปรับปรุงในงานวิจัยนี้

## บทที่ 5

### สรุปผลการวิจัยและข้อเสนอแนะ

#### 5.1 สรุปผลการวิจัย

วิทยานิพนธ์นี้มุ่งเน้นการแก้ไขปัญหาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่เกี่ยวข้องกับปัญหาการแปลงประโยคที่มีการใช้คำควบกล้ำ สระประสม อักษรเบรลล์สองเซลล์และคำทับศัพท์ ซึ่งเป็นปัญหาที่พบในการทำงานของโปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file เดิม โดยใช้เทคนิคเอ็นแกรมโมเดลประยุกต์ในการตัดคำอักษรเบรลล์ภาษาไทยก่อนที่จะแปลงไปเป็นภาษาไทยเพื่อลดความกำกวมของลักษณะการเขียนอักษรเบรลล์ภาษาไทย โดยผลการวิจัยสามารถกล่าวโดยสรุปได้ดังต่อไปนี้

- 1) การนำเทคนิคเอ็นแกรม โมเดลเข้ามาช่วยในการตัดคำอักษรเบรลล์ภาษาไทยสามารถช่วยลดความกำกวมของลักษณะการเขียนอักษรเบรลล์ภาษาไทยระดับ 1 ได้เป็นอย่างดี โดยเทคนิคนี้จะช่วยหาขอบเขตของคำแต่ละคำ ทำให้โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ สามารถแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้อย่างถูกต้องมากยิ่งขึ้น โดยสามารถแปลงประโยคอักษรเบรลล์ภาษาไทยระดับ 1 ที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ที่ได้ถูกต้องมากกว่า 93 เปอร์เซ็นต์ทุกประเภท
- 2) จากการทดลองทั้งด้านความถูกต้องในการแปลง ด้านปริมาณการใช้หน่วยความจำและเปรียบเทียบเวลาที่ใช้ในการแปลง สามารถสรุปได้ว่าเมื่อใช้จำนวนแกรม 4-แกรม มีความเหมาะสมที่สุดในการนำไปใช้งานการตัดคำอักษรเบรลล์ภาษาไทยระดับ 1 เนื่องจากเมื่อใช้จำนวนแกรม 4-แกรม สามารถแปลงได้ถูกต้องมากกว่าจำนวนแกรม 3-แกรม และใช้เวลาแปลงน้อยกว่าเมื่อใช้จำนวนแกรม 5-แกรม และจากการเปรียบเทียบปริมาณการใช้หน่วยความจำพบว่าใกล้เคียงกันกับจำนวนแกรม 3-แกรม และ 5-แกรม

## 5.2 สรุปปัญหา อุปสรรค และสาเหตุข้อผิดพลาดในงานวิจัยนี้

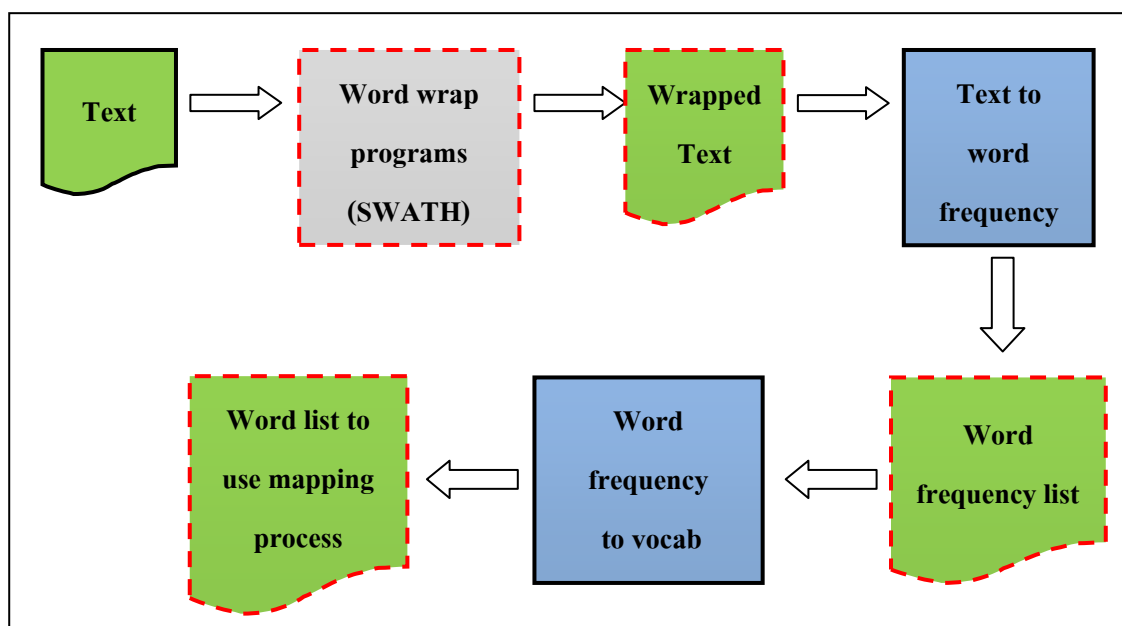
### 1) คลังข้อความสำหรับฝึกฝนเอ็นแกรมโมเดล

ในการสร้างเอ็นแกรมโมเดลนั้นจำเป็นต้องมีคลังข้อมูลหรือคลังข้อความสำหรับฝึกฝนเอ็นแกรมโมเดลให้สามารถสร้าง N-gram pattern ที่บ่งบอกลักษณะการเรียงกันของคำที่เกิดขึ้นเป็นประโยคหรือลักษณะการเรียงของอักขระที่เกิดขึ้นเป็นคำ ด้วยค่าความน่าจะเป็นหนึ่งๆ ของแต่ละภาษานั้นๆ ซึ่งในปัจจุบันนี้ไม่มีคลังข้อความใดเลยที่เขียนอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 ที่จะนำมาใช้ฝึกฝนเอ็นแกรมโมเดลได้โดยตรง จึงจำเป็นต้องประยุกต์จากคลังข้อความภาษาไทยแทน โดยได้ใช้คลังข้อความ BEST

โดยผู้วิจัยได้พบว่ายังคงมีคำบางคำในคลังข้อความนี้เขียนผิดอยู่ก่อนแล้วและผู้วิจัยได้พยายามค้นหาและแก้ไขคำที่เขียนผิดเหล่านี้ให้ถูกต้อง โดยผู้วิจัยได้พยายามแก้ไขให้ถูกต้องและครอบคลุมมากที่สุดเท่าที่จะเป็นไปได้แต่อาจจะไม่ครอบคลุมคำทั้งหมดที่มีอยู่เนื่องจากคลังข้อความ BEST นั้นมีขนาดใหญ่มาก (รายละเอียดของคลังข้อความ BEST กล่าวไว้ในหัวข้อที่ 2.3.3 ) โดยผู้วิจัยได้รวบรวมรายการคำที่คลังข้อความ BEST เขียนผิดพลาดอยู่ก่อนแล้วในตารางที่ 10 ในภาคผนวก ก

### 2) โปรแกรมตัดคำและรายการคู่คำภาษาไทยกับคำอักษรเบรลล์ภาษาไทย

ในงานวิจัยนี้ผู้วิจัยได้นำโปรแกรมตัดคำ SWATH [29] มาใช้ในขั้นตอนการสร้างรายการคู่คำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยเพื่อนำไปใช้ในขั้นตอน Translate\_to\_thai เนื่องจากเทคนิคเอ็นแกรมโมเดลสามารถตัดคำอักษรเบรลล์ภาษาไทยได้แต่ไม่สามารถแปลงอักษรเบรลล์ภาษาไทยให้เป็นภาษาไทยได้ จึงต้องใช้วิธีการแปลงแบบจับคู่คำ ซึ่งจำเป็นต้องสร้างรายการคำที่ใช้ในการจับคู่คำขึ้นมาก่อน โดยผู้วิจัยได้ออกแบบวิธีการสร้างรายการคำดังกล่าวดังแสดงในรูปที่ 5.1



รูปที่ 5.1 ขั้นตอนการสร้างรายการคำภาษาไทยและอักษรเบรลล์ภาษาไทย

จากรูปที่ 5.1 ผู้วิจัยได้ใช้โปรแกรมตัดคำ SWATH แบ่งคำเพื่อนำไปสร้างรายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยต่อไป แต่เนื่องจากโปรแกรมตัดคำ SWATH ยังคงมีความผิดพลาดในการตัดคำอยู่ โดยมีความถูกต้องในการตัดคำที่ 99 เปอร์เซ็นต์ [29] ทำให้ประโยคที่ตัดคำเรียบร้อยแล้ว (Wrapped Text ในรูปที่ 5.1) มีคำบางคำที่ตัดคำผิดพลาดรวมอยู่ด้วย ดังนั้นเมื่อนำไปใช้ในขั้นตอนถัดไปจึงก่อให้เกิดความผิดพลาดตามมา และทำให้รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยผิดพลาดไปด้วย

ดังนั้นผู้วิจัยจึงได้พยายามค้นหาและแก้ไขรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยดังกล่าว ให้ถูกต้องมากที่สุดโดยใช้วิธีเปรียบเทียบกับพจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ.2542 [16] และผู้วิจัยได้รวบรวมรายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาดในตารางที่ 9 ในภาคผนวก ก โดยได้ตัดรายการคำดังกล่าวออกไปจากรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยที่ได้สร้างไว้

### 3) โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ (Thai2brl)

ผู้วิจัยได้นำโปรแกรม Thai2brl [1] มาใช้ในงานวิจัยนี้ในขั้นตอนต่างๆ ที่ต้องแปลงข้อความจากภาษาไทยให้เป็นอักษรเบรลล์ภาษาไทยระดับ 1 เช่น การสร้างคลังข้อความในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 สำหรับฝึกฝนเอ็นแกรมโมเดล,

การสร้างรายการคู่คำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยสำหรับขั้นตอน Translate\_to\_thai อย่างไรก็ตามโปรแกรมนี้ยังคงมีความผิดพลาดในการแปลงจากภาษาไทยไปเป็นอักษรเบรลล์ภาษาไทยและชุดข้อมูลทดสอบต่างๆ ที่นำเสนอในบทที่ 4 ทำให้ข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ที่แปลงได้มีการแปลงที่ผิดพลาดรวมอยู่ด้วย จึงเป็นสาเหตุให้โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ มีการทำงานที่ผิดพลาดไปด้วย

โดยผู้วิจัยได้พยายามค้นหาคำที่แปลงผิดและแก้ไขในส่วนที่พบให้มากที่สุดเท่าที่จะเป็นไปได้ แต่อาจจะไม่ใช่ทั้งหมดที่โปรแกรม Thai2brl แปลงผิดพลาด จึงทำให้ข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ที่แปลงได้ยังคงมีความผิดพลาดรวมอยู่ด้วย และหากไม่สามารถแก้ไขคำผิดได้ ก็จะตัดคำนั้นออกไปจากฐานข้อมูล โดยผู้วิจัยได้รวบรวมคำที่โปรแกรม Thai2brl แปลงผิดพลาดและได้แก้ไขไปแล้วในตารางที่ 8 ในภาคผนวก ก

- 4) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ที่ได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้

เนื่องจากโปรแกรมที่ผู้วิจัยได้ออกแบบไว้นี้ ได้ใช้เทคนิคเอ็นแกรมโมเดลเข้ามาช่วยในการตัดคำ โดยอ้างอิงจากค่าความน่าจะเป็นของคำที่เขียนเรียงติดกันที่เกิดขึ้นร่วมกันเป็นประโยคในคลังข้อมูลฝึก ซึ่งเอ็นแกรมโมเดลนี้เป็นลักษณะการตัดคำโดยใช้ค่าสถิติของคำเข้ามาเป็นเกณฑ์ตัดสิน ซึ่งบางครั้งก็มีความผิดพลาดในการตัดคำเกิดขึ้นได้ โดยเฉพาะประโยคที่มีการใช้ชื่อเฉพาะ (ชื่อบุคคล, ชื่อสถานที่, ชื่อสิ่งของ) ซึ่งในความเป็นจริงคำที่เป็นชื่อเฉพาะเหล่านี้จะสามารถพบได้น้อยกว่าคำทั่วไปมากจึงทำให้มีค่าทางสถิติที่น้อยกว่าคำทั่วไป จึงเป็นสาเหตุให้โปรแกรมที่พัฒนาขึ้นมาตัดคำผิดพลาดนั่นเอง ยกตัวอย่างเช่น ประโยค “คุณอาร์มจะไปไหนคะ” ซึ่งโดยทั่วไปแล้วค่าความน่าจะเป็นที่คำว่า “คุณ” เขียนนำหน้าแล้วตามด้วยคำว่า “อา” จะมีมากกว่าคำว่า “คุณ” เขียนนำหน้าแล้วตามด้วยคำว่า “อาร์ม” เสมอ ดังนั้นโปรแกรมจึงเลือกตัดคำให้เป็น “คุณอา” แทนที่จะเป็น “คุณอาร์ม” เป็นต้น

### 5.3 ข้อเสนอแนะ

- 1) โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำ ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์ฉบับนี้ ยังคงทำงานได้ซ้ำเมื่อเปรียบเทียบกับโปรแกรมเดิมและไม่เหมาะสมที่จะนำไปใช้แปลงไฟล์ข้อความขนาดใหญ่ จึงควรนำไปใช้ร่วมกับโปรแกรมอื่นๆ เพื่อให้แปลงข้อความเฉพาะประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์
- 2) รายการคำที่นำมาจากพจนานุกรมฉบับราชบัณฑิตยสถานที่ใช้คัดเลือกประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์จากคลังข้อความ BEST เพื่อนำไปสร้างโมเดลอักษรเบรลล์ภาษาไทยในหัวข้อที่ 3.3.1 ควรใช้พจนานุกรมฉบับราชบัณฑิตยสถานที่ปรับปรุงล่าสุดให้เป็นปัจจุบันเพื่อเพิ่มความถูกต้องของรายการคำดังกล่าวและครอบคลุมรายการคำให้มากที่สุดเท่าที่จะเป็นไปได้ ซึ่งจะทำให้ไฟล์โมเดลภาษาที่สร้างขึ้นครอบคลุมรูปแบบคำต่างๆ มากขึ้นและจะมีความถูกต้องในการเลือกคำมากขึ้นเช่นกัน
- 3) คลังข้อความที่นำมาใช้ฝึกฝนเอ็นแกรมโมเดล ควรมีความถูกต้อง 100 เปอร์เซ็นต์และเป็นไปตามกฎไวยากรณ์ภาษาของอักษรเบรลล์ภาษาไทยระดับ 1 แต่ทั้งนี้เนื่องจากในวิจัยนี้ ไม่มีคลังข้อความใดเลยที่เขียนอยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 ดังนั้นผู้วิจัยจึงต้องนำเอาคลังข้อความ BEST ซึ่งเป็นคลังข้อความภาษาไทย นำมาแปลงให้อยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 โดยใช้โปรแกรม Thai2brl [1] ในการแปลง ซึ่งยังคงมีความผิดพลาดในการแปลงอยู่ ซึ่งส่งผลให้เอ็นแกรมโมเดลที่สร้างขึ้นมานั้นมีข้อมูลที่ผิดพลาดรวมอยู่ด้วยและส่งผลกระทบต่อความถูกต้องของการตัดคำอักษรเบรลล์ภาษาไทย

ดังนั้นจึงควรมีการสร้างคลังข้อความอักษรเบรลล์ภาษาไทยที่มีความถูกต้องครบถ้วนสมบูรณ์เพื่อใช้ในการฝึกฝนเอ็นแกรมโมเดล ซึ่งจำเป็นต้องมีผู้เชี่ยวชาญในการเขียนอักษรเบรลล์ระดับ 1 เพื่อตรวจสอบแก้ไขข้อมูลดังกล่าวให้เป็นไปตามกฎไวยากรณ์ของอักษรเบรลล์ และต้องใช้เวลาในการรวบรวมข้อความประเภทต่างๆ



ให้ครบถ้วนเพื่อเป็นตัวแทนของประเภทภาษาเขียนแบบต่างๆ เพื่อสร้างเป็นคลังข้อความอักษรเบรลล์ภาษาไทย

- 4) คลังข้อความที่นำมาใช้ฝึกฝนเอ็นแกรมโมเดลควรมีการปรับปรุงให้มีขนาดที่กะทัดรัดมากขึ้นโดยใช้เทคนิค N-gram Weighting Technique [30] ซึ่งสามารถลดขนาดของคลังข้อมูลที่นำมาฝึกฝนเอ็นแกรมโมเดลลงได้และสามารถลดอัตราความผิดพลาดที่เกิดจากการเขียนคำที่ผิด (Word error rate) ลงได้ 1.2 เปอร์เซ็นต์ โดยจะส่งผลให้ใช้ปริมาณหน่วยความจำน้อยลงและสามารถทำงานได้รวดเร็วมากขึ้นเนื่องจากเอ็นแกรมโมเดลมีขนาดที่เล็กลงนั่นเอง
- 5) รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยที่ใช้ในขั้นตอน Translate\_to\_Thai ควรมีการปรับปรุงให้มีความถูกต้องทุกๆ คำ เนื่องจากจะส่งผลต่อการเทียบคำจากอักษรเบรลล์ภาษาไทยไปเป็นคำภาษาไทยทำให้เกิดความผิดพลาดได้ ซึ่งสาเหตุนี้เกิดขึ้นจากผู้วิจัยได้ใช้โปรแกรมตัดคำภาษาไทย (SWATH) ซึ่งยังคงมีความผิดพลาดในการตัดคำอยู่บ้าง (SWATH มีความถูกต้องอยู่ในระดับที่ 99 เปอร์เซ็นต์) นำมาใช้ตัดคำประโยคภาษาไทยเพื่อนำไปสร้างเป็นรายการคำภาษาไทยและใช้โปรแกรมแปลงภาษาไทยไปเป็นอักษรเบรลล์ระดับ 1 (โปรแกรม Thai2brl) จึงทำให้มีความผิดพลาดดังกล่าวเกิดขึ้น

ดังนั้นจึงควรตรวจสอบรายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยให้ถูกต้องทุกๆ คำ โดยผู้ที่มีความรู้ความเชี่ยวชาญในการเขียนภาษาไทยและอักษรเบรลล์ภาษาไทยระดับ 1 และควรเพิ่มคู่ของคำอื่นๆ ที่อาจจะไม่พบในรายการคู่คำดังกล่าว เพื่อให้สามารถครอบคลุมการแปลงได้มากยิ่งขึ้น

## เอกสารอ้างอิง

- [1] วรพล ทินกรสูติบุตร, “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด,” วิทยานิพนธ์มหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์, 2551.
- [2] หน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “Principle of N-gram model,” *หลักการทํางานของเอ็นแกรมโมเดล*, 19-July-2009. [Online]. Available: [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_content&view=article&id=66&Itemid=92&lang=en](http://www.hlt.nectec.or.th/speech/index.php?option=com_content&view=article&id=66&Itemid=92&lang=en). [Accessed: 29-Feb-2012].
- [3] อัครพล เอกวงศอนันต์, “การระบุคำไทยและคำทับศัพท์ด้วยแบบจำลองเอ็นแกรม,” วิทยานิพนธ์มหาบัณฑิต สาขาวิชาภาษาศาสตร์ ภาควิชาภาษาศาสตร์ คณะอักษรศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2548.
- [4] นัฐวุฒิ ไชยเจริญ, “การตัดคำและกำกับหมวดคำภาษาไทยแบบเบ็ดเสร็จด้วยคอมพิวเตอร์,” วิทยานิพนธ์มหาบัณฑิต สาขาวิชาภาษาศาสตร์ ภาควิชาภาษาศาสตร์ คณะอักษรศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2544.
- [5] วีรยา อมรพงษ์กุล, อัยฎาภรณ์ พิมพ์สมบูรณ์, จันทิมา พลพินิจ, และอุมาภรณ์ สายแสงจันทร์, “การประยุกต์เอ็นแกรมและเว็ทเตอร์โมเดลสำหรับระบบย่อข้อความภาษาไทย,” *Proceedings of Thailand Conference of Computer Science (ThCSC)*, pp. 48-54, Bangkok, Thailand, ธันวาคม พ.ศ. 2547.
- [6] สารานุกรมไทยสำหรับเยาวชนโดยพระราชประสงค์ในสมเด็จพระเจ้าอยู่หัว, “Thai Word Segmentation,” *โปรแกรมตัดคำภาษาไทย*, 5-Nov-1983. [Online]. Available: <http://kanchanapisek.or.th/kp6/New/sub/book/book.php?book=25&chap=7&page=t25-7-infodetail05.html>. [Accessed: 15-Jan-2012].
- [7] Thai Computational Linguistics Laboratory, “Natural language processing,” *การประมวลผลภาษาธรรมชาติ*, 14-Nov-2002. [Online]. Available: <http://www.tcllab.org>. [Accessed: 15-Jan-2012].
- [8] ดวงแก้ว สวามีภักดิ์, “การประยุกต์ใช้เครื่องมือพัฒนา การประมวลผลภาษาภายใต้ระบบยูนิคซ์เพื่อสร้างซอฟต์แวร์วิเคราะห์ไวยากรณ์ภาษาไทย,” *สถาบันไทยคดีศึกษา มหาวิทยาลัยธรรมศาสตร์*, 2531.

- [9] ยืน ภู่วรรณ และ วิวรรณ อิ่มอารมณ์, “การแบ่งพยางค์ไทยด้วยดิคชันนารี,” รายงานการประชุมวิชาการวิศวกรรมไฟฟ้า ครั้งที่ 9, 2529.
- [10] สัมพันธ์ ธีรธรรมย์, “การแบ่งคำไทยด้วยพจนานุกรม,” โครงการวิศวกรรม ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2534.
- [11] ไพศาล เจริญพรสวัสดิ์, “การตัดคำโดยใช้คุณลักษณะ,” วิทยานิพนธ์มหาบัณฑิต สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2541.
- [12] คณะอักษรศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, “คลังข้อมูลภาษา,” *คลังข้อมูลภาษา*, 31-Aug-2008. [Online]. Available: <http://ling.arts.chula.ac.th/TNC/>. [Accessed: 15-Jan-2012].
- [13] หน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “BEST corpus,” *คลังข้อความ BEST*, 19-July-2009. [Online]. Available: [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_jumi&fileid=14&Itemid=121&lang=en](http://www.hlt.nectec.or.th/speech/index.php?option=com_jumi&fileid=14&Itemid=121&lang=en). [Accessed: 15-Jan-2012].
- [14] นิธิ เอียวศรีวงศ์และคณะ, “Midnight University,” *มหาวิทยาลัยเที่ยงคืน*, Sep-1997. [Online]. Available: <http://www.midnightuniv.org>. [Accessed: 15-Jan-2012].
- [15] G. W. Leshner, B. J. Moulton, D. J. Higginbotham, “Effect of N-gram order and training text size on word prediction,” In Proceedings of the Rehabilitation Engineering and Assistive Technology Society of North America (RESNA), pp. 52-54, 1999.
- [16] ราชบัณฑิตยสถาน, “The Royal Institute,” *พจนานุกรมฉบับราชบัณฑิตยสถาน*, 31-Mar-1933. [Online]. Available: <http://www.royin.go.th/th/home/>. [Accessed: 15-Jan-2012].
- [17] Stanley F. Chen และ Joshua Goodman, “An Empirical Study of Smoothing Techniques for Language Modeling,” Proceedings of the 34<sup>th</sup> annual meeting on Association for Computational Linguistics, pp. 310-318, 1996.
- [18] หน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “Training N-gram model,” *การฝึกฝนเอ็นแกรมโมเดลด้วยชุดเครื่องมือ CMU-SLM toolkit*, 17-Jan-2012. [Online]. Available: [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_content&view=article&id=70&Itemid=94](http://www.hlt.nectec.or.th/speech/index.php?option=com_content&view=article&id=70&Itemid=94). [Accessed: 4-Feb-2012].

- [19] Doug Paul (MIT Lincoln Labs for research) และ U.S. Department of Defense Advanced Research Project Agency (ARPA), “ARPA format,” *ARPA format*, 2004. [Online]. Available: <http://www.speech.sri.com/projects/srilm/manpages/ngram-format.5.html>. [Accessed: 15-Jan-2012].
- [20] P.R. Clarkson และ R. Rosenfeld Cambridge University, “CMU-SLM toolkit,” *CMU-SLM toolkit*, June-1999. [Online]. Available: <http://www.speech.cs.cmu.edu/SLM/toolkit.html>. [Accessed: 15-Jan-2012].
- [21] Pisit Thai Natural Language Processing Lab, “โครงสร้างพจนานุกรมแบบทรี,” *ReoCities*, Aug-1998. [Online]. Available: <http://reocities.com/ResearchTriangle/thinktank/5593/Trie/trie.htm>. [Accessed: 15-Jan-2012].
- [22] The Math Forum (Drexel University), “Division by zero,” *ปัญหาการหารด้วยศูนย์*, Jan-1994. [Online]. Available: <http://mathforum.org/dr.math/faq/faq.divideby0.html>. [Accessed: 4-Feb-2012].
- [23] หน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “การสร้างโมเดลภาษาด้วย CMU-SLM toolkit,” *การสร้างโมเดลภาษาคู่ด้วยชุดเครื่องมือ CMU-SLM toolkit*, 17-Jan-2012. [Online]. Available: [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_content&view=article&id=70&Itemid=94](http://www.hlt.nectec.or.th/speech/index.php?option=com_content&view=article&id=70&Itemid=94). [Accessed: 4-Feb-2012].
- [24] Krisda Khankasikam และ Nuttanart Muansuwan, “Thai Word Segmentation a Lexical Semantic Approach,” The 10<sup>th</sup> Machine Translation Summit (MT Summit X), September 12-16, Phuket, Thailand, p. 331, 2005.
- [25] Hitoshi Isahara Kansai Advanced Research Center และศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “ORCHID corpus,” *คลังข้อความ ORCHID*, Oct-1999. [Online]. Available: <http://www.hlt.nectec.or.th/orchid/> [Accessed: 15-Jan-2012].
- [26] กิตติชน แม่นสมุทร, “การตัดคำแบบเอ็นแกรม,” *สร้าง Search Engine กัน*, 20-Jun-2007. [Online]. Available: <http://ejeepss.wordpress.com/2007/06/20/สร้าง-search-engine-กันใหม่/>. [Accessed: 15-Jan-2012].
- [27] หน่วยปฏิบัติการวิจัยวิทยาการมนุษยภาษา ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ, “โปรแกรมตัดคำ SWATH,” *Thai word segmentation*, 28-Jul-

2005. [Online]. Available: <http://www.hlt.nectec.or.th/products/swath.php>. [Accessed: 15-Jan-2012].
- [28] B.P. Hsu and J.R. Glass, “N-gram Weighting: Reducing Training Data Mismatch in Cross-Domain Language Model Estimation,” In Proceedings of Empirical Methods in Natural Language Processing (EMNLP), 2008, pp. 829-838, 2008.
- [29] สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน, “ประวัติอักษรเบรลล์,” *อักษรเบรลล์*, Oct-2008. [Online]. Available: [http://school.obec.go.th/speced4/speced4/load/Borsure/4History of braille.pdf](http://school.obec.go.th/speced4/speced4/load/Borsure/4History%20of%20braille.pdf). [Accessed: 6-Feb-2012].
- [30] BANA member, “American English Braille,” Braille formats, 1996. [Online]. Available: <http://www.brl.org/formats/index.html>. [Accessed: 6-Feb-2012].
- [31] Eitan Gurari, “North American Braille Computer Code,” *North American Braille Computer Code Formats*, 3-Sep-2010. [Online]. Available: <http://www.dotlessbraille.org/index.html>. [Accessed: 6-Feb-2012].
- [32] BrailleNote Users members, “BrailleNote,” *BrailleNote*, 18-Feb-2012. [Online]. Available: <http://www.brailnoteusers.info>. [Accessed: 3-Mar-2012].
- [33] สมทรง พันธุ์สุวรรณ , “การอ่าน เขียน พิมพ์ อักษรเบรลล์,” พิมพ์ครั้งที่ 1 หจก. จงเจริญการพิมพ์ พ.ศ. 2538.
- [34] กมลวรรณ อินอร่าม, “การเรียนรู้อักษรเบรลล์,” คณะครุศาสตร์ มหาวิทยาลัยราชภัฏสวนคูสิต, ISBN 974-223-404-3, 2547.
- [35] The Braille Authority of North America (BANA), “Unified 8 dot Braille Code,” *Unified 8 dot Braille Code*, Dec-2010. [Online]. Available: <http://www.brailleauthority.org>. [Accessed: 4-Mar-2012].

## ภาคผนวก

**ภาคผนวก ก : ผลงานที่ได้รับการตีพิมพ์เผยแพร่**

ทศวัฒน์ ชูณหวิตยะธีระ และพิชญา ตันชัยย์, “การใช้เอ็นแกรมช่วยในการตัดสินใจแปลอักษรเบรลล์ที่ใช้คำควบกล้ำ สระประสม และอักษรเบรลล์สองเซลล์,” ในการประชุมวิชาการเสนอผลงานวิจัย มหาวิทยาลัยพายัพ พ.ศ. 2555, เชียงใหม่, ประเทศไทย, 17 กุมภาพันธ์ 2555, รางวัลผลงานวิจัยดีเด่น (Best Paper Award) กลุ่มสาขาวิทยาศาสตร์เทคโนโลยี

ชื่อเรื่อง การใช้เอ็นแกรมช่วยในการตัดสินใจแปลอักษรเบรลล์ที่ใช้คำควบกล้ำ สระประสม

และอักษรเบรลล์สองเซลล์

## Enhancing Thai Braille translation with n-gram for decision making in the cases of compound consonants, vowels and characters

ชื่อคณะผู้วิจัย นายทศวัฒน์ ชุนหวิตยะธีระ และ ผศ.ดร. พิชญา ตันฑายย์

**Mr. Totsawat Chunhawitayatera and Asst. Prof. Dr. Pichaya Tandayya**

หน่วยงานต้นสังกัด ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์

### บทคัดย่อ

การแปลงข้อความรหัสอักษรเบรลล์ภาษาไทยให้เป็นข้อความรหัสแอสกีภาษาไทยในปัจจุบัน มักใช้กฎไวยากรณ์ทางภาษาเข้ามากำกับวิธีการแปลง แต่ยังคงประสบปัญหาการแปลงคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ เนื่องจากไวยากรณ์ที่แตกต่างกันและความไม่แน่นอนในการใช้ภาษา จึงไม่สามารถเขียนโปรแกรมให้ครอบคลุมทุกๆ กรณีที่เกิดขึ้นได้ งานวิจัยนี้ได้นำเสนอวิธีแก้ไขปัญหการแปลงข้อความรหัสอักษรเบรลล์ภาษาไทยให้เป็นข้อความรหัสแอสกีภาษาไทยเพื่อใช้กับประโยคที่มีคำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์และคำทับศัพท์ โดยใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำก่อนที่จะแปลงให้เป็นภาษาไทยเพื่อลดความกำกวมของภาษาและนำเสนอจำนวนแกรมที่เหมาะสมสำหรับใช้ตัดคำอักษรเบรลล์ภาษาไทย ซึ่งผลการทดลองสรุปว่าสามารถแปลงข้อความได้ถูกต้องมากขึ้นและใช้ปริมาณหน่วยความจำน้อยลง แต่ใช้เวลาแปลงมากกว่าเดิม โดยอยู่ในเกณฑ์ที่ยอมรับได้ และจำนวนแกรมที่เหมาะสมคือ 4 แกรม

คำสำคัญ : อักษรเบรลล์ภาษาไทย, เอ็นแกรมโมเดล, โปรแกรมแปลงข้อความรหัสอักษรเบรลล์ภาษาไทยเป็นรหัสแอสกีภาษาไทย

### ABSTRACT

In the present, the Braille Thai to Thai translation applies grammar rules to control the translation process but there are problems about translating compound consonants and vowels, two-cell Braille characters and transliterated words. The causes are too many grammar rules and the ambiguity of the language. Therefore, it is difficult to write a program to cover all conditions. This paper proposes a method to solve Braille Thai to Thai translation problems in the cases that the sentences contain compound consonants, vowels, two-cell Braille characters and transliterated words by using the N-gram model technique to wrap words before being translated into Thai in order to reduce the ambiguity of the language and propose the optimal N-gram number for wrapping Braille Thai words. The new method can improve the translation correctness and reduce the memory consumption better than the old method but the new method requires more translation time than the old method. The appropriate N-gram number is 4-gram for the Braille Thai text word wrap.

Key Words: Thai Braille, N-gram model, Braille to Thai translation program



## บทนำ

ในประเทศไทยได้มีการพัฒนาโปรแกรมช่วยแปลงรหัสอักษรเบรลล์ภาษาไทยเป็นรหัสแอสกีภาษาไทยแบบ File-to-file มาอย่างต่อเนื่อง แต่โปรแกรมเหล่านั้นยังคงประสบปัญหาการแปลงคำที่เกี่ยวข้องกับคำควบกล้ำ, คำที่มีการใช้สระประสม, คำที่มีการใช้อักษรเบรลล์สองเซลล์และคำทับศัพท์ ซึ่งในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” วรพล ทินกรสูตินุตร (2551) โดยมหาวิทยาลัยสงขลานครินทร์ ได้นำเสนอโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file ซึ่งโปรแกรมนี้เป็นโปรแกรมแปลงข้อความรหัสอักษรเบรลล์ภาษาไทยเป็นข้อความรหัสแอสกีภาษาไทยแบบ File-to-file ซึ่งยังคงมีความผิดพลาดในการแปลงคำประเภทดังกล่าว

ในบทความนี้ได้เสนอวิธีแก้ไขปัญหาดังกล่าวโดยนำเทคนิคเอ็นแกรมเข้ามาช่วยในการหาขอบเขตของคำอักษรเบรลล์ภาษาไทย ซึ่งจะช่วยให้ทราบขอบเขตที่แน่นอนของคำแต่ละคำ จึงส่งผลให้การแปลงเบรลล์ภาษาไทยเป็นแอสกีภาษาไทยทำได้ง่ายขึ้นและถูกต้องมากยิ่งขึ้น อีกทั้งการนำเทคนิคเอ็นแกรมมาประยุกต์ใช้นี้ทำให้กระบวนการแปลงเบรลล์ภาษาไทยเป็นแอสกีภาษาไทยมีความซับซ้อนน้อยลง เมื่อเปรียบเทียบกับแปลงเบรลล์ภาษาไทยเป็นแอสกีภาษาไทยที่ใช้เทคนิคกฎไวยากรณ์ทางภาษา โดยให้เอ็นแกรมคำนวณหาค่าความน่าจะเป็นของอักขระที่เขียนเรียงติดกัน (Character sequence) ที่เกิดขึ้นร่วมกันเป็นคำอักษรเบรลล์ภาษาไทย เพื่อช่วยในการระบุขอบเขตของคำอักษรเบรลล์ภาษาไทยว่าควรแบ่งคำออกมาเป็นรูปแบบอย่างไรจึงจะเหมาะสม และเพิ่มความถูกต้องในการแปลง

## วัตถุประสงค์ของงานวิจัย

งานวิจัยนี้มุ่งเน้นวิจัยและพัฒนาเพื่อศึกษานำเทคนิคเอ็นแกรม เข้ามาประยุกต์ใช้กับการแปลงอักษรเบรลล์ภาษาไทย เพื่อช่วยปรับปรุงกระบวนการแปลง

รหัสอักษรเบรลล์ภาษาไทยไปเป็นรหัสแอสกีภาษาไทยให้ถูกต้องมากยิ่งขึ้น โดยมีประเด็นที่ศึกษาดังต่อไปนี้

- 1) นำเทคนิคเอ็นแกรมเข้ามาประยุกต์ใช้ร่วมกับการแปลงเบรลล์ภาษาไทยเป็นแอสกีภาษาไทย จะช่วยเพิ่มความถูกต้องในการแปลงได้หรือไม่ โดยเปรียบเทียบกับโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด”
- 2) หากค่าของจำนวนแกรมที่เหมาะสม เพื่อหาค่าของจำนวนแกรมที่ให้ผลลัพธ์ในการแบ่งคำที่ดีที่สุดโดยเปรียบเทียบระหว่าง 3-แกรม, 4-แกรม และ 5-แกรม โดยใช้วิธีพิจารณาจากความถูกต้องของการแบ่งคำอักษรเบรลล์ภาษาไทยระดับ 1 ซึ่งจะต้องถูกต้องตามหลักไวยากรณ์ของอักษรเบรลล์ภาษาไทยและเมื่อนำไปแปลงให้เป็นภาษาไทยแล้วจะต้องถูกต้องตามหลักไวยากรณ์ของภาษาไทยด้วย

บทความนี้ นำเทคนิคเอ็นแกรมมาตัดคำอักษรเบรลล์ภาษาไทยและแปลงให้เป็นภาษาไทยโดยใช้วิธีจับคู่คำ และเสนอจำนวนแกรมที่เหมาะสมในการตัดคำอักษรเบรลล์ภาษาไทย

## ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยและเทคโนโลยีต่างๆ ที่เกี่ยวข้อง ซึ่งได้นำมาใช้ในการวิจัยนี้โดยประกอบไปด้วย 1) โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม 2) เทคนิคการตัดคำ 3) เอ็นแกรม โมเดล 4) Smoothing Technique 5) คลังข้อมูลภาษา และ 6) CMU-SLM Toolkit

1. โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม

โปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file ได้นำเสนอไว้ในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” วรพล ทินกรสูตินุตร (2551) ของมหาวิทยาลัยสงขลานครินทร์ ซึ่งโปรแกรมดังกล่าวทำหน้าที่แปลงเบรลล์ภาษาไทยเป็นรหัสแอสกีภาษาไทยในรูปแบบ File-to-file โดยกระบวนการทำงานของโปรแกรมนี้ ใช้กฎไวยากรณ์ทาง

ภาษาของอักษรเบรลล์ภาษาไทยมาควบคุมการแปลง ซึ่งให้ผลลัพธ์ในการแปลงถูกต้องระดับหนึ่ง

จากการศึกษางานวิจัยนี้พบว่ายังคงมีปัญหาในการแปลงเบรลล์ภาษาไทยเป็นแอสกีภาษาไทยอยู่ด้วยกัน 2 ประการคือ 1) ปัญหาการแปลงคำควบกล้ำและสระประสม ซึ่งปัญหานี้เกิดจากการตัดคำในประโยคอักษรเบรลล์ภาษาไทยที่มีความกำกวม ทำให้โปรแกรมดังกล่าวไม่สามารถแยกแยะได้ว่าอักขระของคำควบกล้ำที่เขียนนั้นเป็นอักขระตัวสะกดของคำๆ หน้าหรือเป็นอักขระอักษรนำของคำๆ หลัง 2) ปัญหาการแปลงคำที่มีการใช้อักษรเบรลล์สองเซลล์ ซึ่งปัญหานี้เกิดจากมีอักษรเบรลล์สองเซลล์บางตัวมีรูปพ้องกันกับอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน ทำให้โปรแกรมดังกล่าวไม่สามารถทราบได้ว่าอักขระเหล่านี้ควรเป็นอักษรเบรลล์สองเซลล์หนึ่งตัว หรือเป็นอักษรเบรลล์เซลล์เดียวสองตัวที่เขียนติดกัน

## 2. เทคนิคการตัดคำ

เทคนิคการตัดคำ ใช้ในการหาขอบเขตของคำในงานด้านประมวลผลภาษาธรรมชาติ เพื่อให้คอมพิวเตอร์สามารถเข้าใจความหมายของคำในภาษานั้นๆ ได้และเนื่องจากภาษาบางภาษา เช่น ภาษาไทย ภาษาจีน ภาษาญี่ปุ่น ภาษาลาว เป็นต้น มีลักษณะการเขียนประโยคที่ประกอบไปด้วยคำย่อยๆ หลายคำเรียงติดกัน โดยไม่มีการเว้นช่องว่างระหว่างคำเหมือนกับภาษาอังกฤษทำให้เกิดปัญหา “ขอบเขตของคำ” เมื่อนำข้อมูลเหล่านั้นไปประมวลผลด้วยคอมพิวเตอร์ ทำให้คอมพิวเตอร์ไม่สามารถทราบได้ว่าในประโยคนั้นๆ ประกอบด้วยคำกี่คำ และแต่ละคำประกอบด้วยตัวอักษรอะไรบ้าง จึงจำเป็นต้องตัดคำเสียก่อน ก่อนที่จะนำไปประมวลผลต่อ เพื่อแบ่งขอบเขตของคำแต่ละคำอย่างชัดเจน

อักษรเบรลล์ภาษาไทยมีลักษณะการเขียนเช่นเดียวกับภาษาไทยคือ เขียนคำแต่ละคำติดๆ กันเป็นประโยคและเว้นวรรคระหว่างประโยค แต่ละเรียงตัวอักษรนำ ตัวอักษรตาม สระ ตัวสะกด และวรรณยุกต์ที่แตกต่างไปจากภาษาไทย

ดังนั้นหากใช้เทคนิคการตัดคำเข้ามาช่วยตัดคำอักษรเบรลล์ภาษาไทย เพื่อให้ทราบขอบเขตของคำที่ชัดเจน และลดความกำกวม ทำให้การแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยทำได้ง่ายขึ้นและถูกต้องมากยิ่งขึ้นอีกด้วย นอกจากนี้ยังไม่มียานวิจัยใดๆ เลยที่จะนำวิธีการตัดคำมาใช้กับอักษรเบรลล์ภาษาไทย ซึ่งในปัจจุบันมีเพียงงานวิจัยที่เกี่ยวข้องกับการตัดคำภาษาไทยเท่านั้น

ในปัจจุบันพบว่าเทคนิคการตัดคำโดยใช้คลังข้อมูลมีความถูกต้องแม่นยำมากที่สุด และเทคนิคการตัดคำโดยใช้เอ็นแกรมโมเดลเป็นเทคนิคการตัดคำโดยใช้คลังข้อมูลที่นิยมใช้ในปัจจุบันมากที่สุด

## 3. เอ็นแกรมโมเดล (N-gram model)

เอ็นแกรมโมเดล (N-gram model) คือ แบบจำลองที่ใช้คำนวณค่าความน่าจะเป็นของชุดอักขระ (character sequence) ที่เกิดขึ้นร่วมกันเป็นคำ หรือค่าความน่าจะเป็นของคำที่เขียนเรียงกัน (word sequence) ที่เกิดขึ้นร่วมกันเป็นประโยค โดยค่าความน่าจะเป็นของชุดอักขระหรือคำสามารถคำนวณได้จากคลังข้อมูลฝึกที่สร้างไว้

แกรม (Gram) คือ หน่วยที่ใช้ในการสร้างแบบจำลองอาจจะเป็นเสียง คำ หรืออักขระก็ได้และแกรมมีได้หลายขนาดแล้วแต่จะกำหนดตั้งแต่ 1 จนถึง N โดย N เป็นจำนวนนับตั้งแต่ 1, 2, 3 ..., n

หลักการทำงานของเอ็นแกรมอาศัยหลักความเป็นจริงที่ว่าเมื่อมีการเขียนอักขระใดๆ หรือคำใดๆ เรียงติดกันเพื่อสร้างเป็นคำหรือเป็นประโยค แต่ละอักขระหรือคำที่เขียนนั้น จะมีความสัมพันธ์กับอักขระหรือคำที่เขียนไว้ก่อนหน้าด้วยค่าความน่าจะเป็นค่าหนึ่ง ตัวอย่างเช่น มีคำ 3 คำคือ “ข้าว” “กิน” และ “ฉัน” เมื่อนำมาเขียนเรียงกันเพื่อสร้างเป็นประโยค จะสามารถเรียงได้หลายรูปแบบ คือ “ข้าว+กิน+ฉัน” “กิน+ฉัน+ข้าว” “ฉัน+กิน+ข้าว” เป็นต้น แต่รูปแบบ “ฉัน+กิน+ข้าว” จะสามารถพบได้มากที่สุดหรืออีกนัยหนึ่งก็คือรูปแบบนี้มีค่าความน่าจะเป็นสูงที่สุดนั่นเอง แต่ทั้งนี้เทคนิคแบบเอ็นแกรมเป็นการคำนวณในเชิงสถิติเท่านั้นและไม่ได้

นำเอาเรื่องของกฎไวยากรณ์ภาษาเข้ามาเกี่ยวข้องด้วย โดยค่าความน่าจะเป็นที่มีสมการคำนวณดังนี้  
 ค่าความน่าจะเป็นที่จะเกิดคำหรืออักขระ  $x_i$  โดยมีชุดของคำหรือชุดอักขระ  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$  นำหน้า  
 $= P(x_i | x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n})$   
 ซึ่ง  $P(x_i | x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n}) = c(x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}, x_i) / c(x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n})$   
 โดยที่  $c(x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}, x_i)$  คือจำนวนครั้งในคลังข้อมูลฝึกที่เกิด  $x_i$  ร่วมกับ  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$   
 $c(x_{i-1}, x_{i-2}, x_{i-3}, \dots, x_{i-n})$  คือจำนวนครั้งที่เกิด  $x_{i-n}, \dots, x_{i-3}, x_{i-2}, x_{i-1}$  ในคลังข้อมูลฝึก

4. Smoothing Techniques

Smoothing techniques สำหรับงานวิจัยทางด้านโมเดลภาษาคือ เทคนิคประมาณค่าความน่าจะเป็นให้กับคำหรือชุดของคำที่ไม่พบในคลังข้อมูลฝึก ซึ่งเทคนิคนี้อาศัยวิธีการประมาณค่าทางสถิติในการคำนวณหาค่าความน่าจะเป็นของคำที่ไม่พบในคลังข้อความ และเทคนิคนี้เป็นกระบวนการที่จำเป็นสำหรับงานด้านสถิติ อีกทั้งเป็นการป้องกันปัญหาการหารด้วยศูนย์อีกด้วย และจากข้อจำกัดของคลังข้อความที่ไม่สามารถจัดเก็บคำและคู่ของคำทั้งหมดที่เกิดขึ้นจริงไว้ในคลังข้อมูลได้ทั้งหมด ทำให้คำบางคำหรือคู่ของคำบางคำอาจจะไม่มีอยู่ในคลังข้อมูล จากการศึกษาเปรียบเทียบเทคนิควิธีประมาณค่าความน่าจะเป็น Smoothing techniques ของ Stanley F. Chen และ Joshua Goodman (1996) พบว่าเทคนิคของ Jelinek และ Mercer Smoothing (Interpolation) จะให้ผลลัพธ์ที่ดีที่สุดเมื่อเปรียบเทียบกับวิธีอื่นๆ โดยมีสมการคำนวณประมาณค่าความน่าจะเป็นดังนี้

$$P_{\text{interp}}(w_i | w_{i-n+1}^{i-1}) = \lambda_{w_{i-n+1}} P_{\text{ML}}(w_i | w_{i-n+1}^{i-1}) + (1 - \lambda_{w_{i-n+1}}) P_{\text{interp}}(w_i | w_{i-n+2}^{i-1})$$

โดยค่าความน่าจะเป็นของ Interpolation เท่ากับค่าถ่วงน้ำหนัก (Back-off weight) คูณด้วยค่าความน่าจะเป็นของจำนวนแกรมที่ n-1

$$\text{โดยที่ } P_{\text{ML}}(w_i | w_{i-n+1}^{i-1}) = C(w_{i-n+1}^{i-1} w_i) / C(w_{i-n+1}^{i-1})$$

คือ ค่าความน่าจะเป็นของจำนวนแกรมที่ n-1 ซึ่งหาได้จากจำนวนคำที่  $w_i$  เกิดขึ้นร่วมกับ  $w_{i-n+1}^{i-1}$  หารด้วยจำนวนคำของ  $w_{i-n+1}^{i-1}$  ที่พบในคลังข้อมูลฝึก และ  $\lambda_{w_{i-n+1}} = \frac{C(w_{i-n+1}^{i-1})}{|W_i : C(w_{i-n+1}^{i-1}) > 0|}$

คือค่าถ่วงน้ำหนัก (Back-off weight) เท่ากับจำนวนคำของ  $w_{i-n+1}^{i-1}$  ที่พบในคลังข้อมูลฝึกหารด้วยค่าสัมบูรณ์ของจำนวนคำ  $w_i$  ต่อจำนวนคำของ  $w_{i-n+1}^{i-1}$

5. คลังข้อมูลภาษา

คลังข้อมูลภาษา คือ ข้อมูลภาษาเขียนหรือภาษาพูดที่เป็นภาษาที่ใช้จริง ซึ่งรวบรวมขึ้นมาในปริมาณที่มากเพียงพอตามเงื่อนไขที่กำหนดเพื่อให้ได้คลังข้อมูลที่เป็นตัวแทนของภาษาที่ต้องการ คลังข้อมูลภาษานำไปใช้งานในด้านภาษาศาสตร์ การสร้างแบบจำลองภาษารวมถึงการประมวลผลภาษาธรรมชาติอีกด้วย เช่น นำไปใช้สร้างพจนานุกรม นำข้อมูลด้านสถิติของคำไปสร้างเป็นแบบจำลองเพื่อนำมาใช้ในงานประมวลผลภาษาธรรมชาติด้วยคอมพิวเตอร์

ในงานวิจัยนี้ได้นำคลังข้อความภาษาไทยมาประยุกต์ใช้งานในการฝึกฝนเอ็นแกรมโมเดล โดยได้เลือกคลังข้อความ BEST ซึ่งเป็นคลังข้อความภาษาไทยและได้คัดเลือกเฉพาะประโยคที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซตล์และคำทับศัพท์เท่านั้น ทั้งนี้เพราะโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมสามารถแปลงประโยคต่างๆ ไปได้ถูกต้องอยู่แล้วและต้องนำคลังข้อความมาแปลงให้อยู่ในรูปแบบของอักษรเบรลล์ภาษาไทยระดับ 1 เสียก่อน จึงจะสามารถนำไปฝึกฝนเอ็นแกรมโมเดลได้ โดยในที่นี้จะใช้โปรแกรมแปลงภาษาไทยเป็นอักษรเบรลล์ (Thai2brl) ซึ่งได้นำเสนอไว้ในวิทยานิพนธ์เรื่อง “การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด” วรพล ทินกรสูตินุตร (2551) ของมหาวิทยาลัยสงขลานครินทร์

คลังข้อความ BEST เป็นคลังข้อความภาษาไทยที่มีการเก็บรวบรวมคำอย่างเป็นระบบและมีขนาดใหญ่ที่สุดในปัจจุบัน ซึ่งพัฒนาโดยหน่วย

ปฏิบัติการวิจัยวิทยาการมนุษยภาษา (HLT) ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) โดยคัดเลือกข้อความจากงานเขียนลักษณะต่าง ๆ 3 ประเภทคือ 1) ข้อความจากหนังสือประเภทนวนิยายในฐานะเป็นตัวแทนของภาษาพูดทั่วไป 2) ข้อความจากเว็บไซต์ www.midnightuniv.org และข้อความจากสารานุกรมสำหรับเยาวชนไทยในฐานะเป็นตัวแทนของภาษาเขียนอย่างเป็นทางการ 3) ข้อความจากหนังสือพิมพ์บนอินเทอร์เน็ตในฐานะเป็นตัวแทนของภาษาข่าว

6. CMU-SLM Toolkit

ชุดเครื่องมือ CMU-SLM Toolkit เป็นชุดเครื่องมือที่ใช้ในการสร้างโมเดลภาษา (Language model) ซึ่งชุดเครื่องมือนี้ได้รับการพัฒนาโดยมหาวิทยาลัย Carnegie Mellon โดยในงานวิจัยนี้ได้เลือกใช้ชุดเครื่องมือ CMU-SLM Toolkit เพื่อช่วยอำนวยความสะดวกในการสร้างโมเดลภาษาของอักษรเบรลล์ภาษาไทยระดับ 1 เนื่องจากชุดเครื่องมือนี้มีการใช้งานกันอย่างแพร่หลายและมีเทคนิคการ Smoothing แบบ Interpolation ชุดเครื่องมือนี้มีการเผยแพร่เป็นสาธารณะ มีคู่มืออธิบายการใช้งานชัดเจน ทำให้ใช้งานได้ง่ายและเป็นชุดเครื่องมือที่ครบถ้วนสมบูรณ์ โดยในชุดเครื่องมือนี้จะประกอบด้วยโปรแกรมย่อยจำนวนหลายโปรแกรมด้วยกัน เช่น text2 wfreq, wfreq2vocab, text2wngram, text2idngram, idngram2lm, interpolate เป็นต้น

อุปกรณ์และวิธีวิจัย

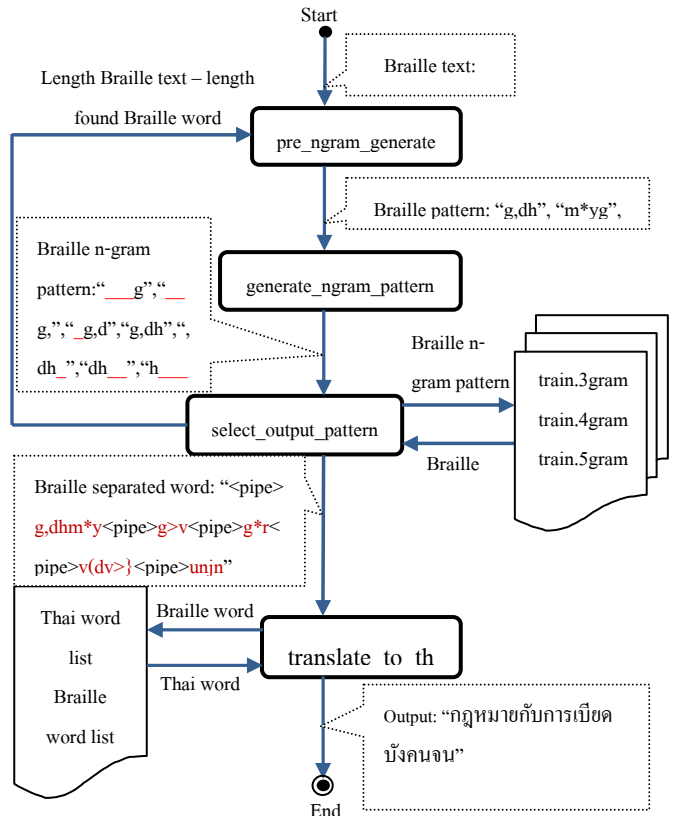
เครื่องมือที่ใช้ในการวิจัยประกอบด้วย

- CMU-SLM toolkit
- คลังข้อความ BEST
- โปรแกรมแปลงภาษาไทยเป็นอักษรเบรลล์ภาษาไทย
- ชุดข้อมูลสำหรับทดสอบ
- พัฒนาโปรแกรมโดยใช้ภาษา C/C++

ภาพรวมของระบบ

ในบทความนี้ได้นำเสนอวิธีการปรับปรุงประสิทธิภาพในการแปลงอักษรเบรลล์ภาษาไทยเป็น

ภาษาไทยในรูปแบบ File-to-file โดยนำเทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำอักษรเบรลล์ภาษาไทย เพื่อลดความกำกวมที่เกิดขึ้นจากลักษณะการเขียนของอักษรเบรลล์ภาษาไทยระดับ 1 หลังจากนั้นจะแปลงให้เป็นภาษาไทยโดยใช้วิธีเทียบแบบคำต่อคำ ซึ่งจำเป็นต้องสร้างรายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยไว้ล่วงหน้า ในภาพที่ 1 แสดงภาพรวมของระบบที่ได้ออกแบบไว้



ภาพที่ 1 ภาพรวมโปรแกรม

ภาพที่ 1 แสดงองค์ประกอบต่างๆของระบบที่ได้ออกแบบไว้และลักษณะการเชื่อมต่อกันของฟังก์ชันหลักรวมทั้งการเชื่อมต่อองค์ประกอบอื่นๆ ที่จำเป็นต้องใช้ร่วมในการแปลงอักษรเบรลล์ภาษาไทยระดับ 1 ให้เป็นภาษาไทย ซึ่งประกอบไปด้วยส่วนต่างๆ ทั้งหมด 6 ส่วนด้วยกันคือ

- 1) ขั้นตอน pre\_ngram\_generate
- 2) ขั้นตอน generate\_ngram\_pattern
- 3) ขั้นตอน select\_output\_pattern
- 4) ไฟล์ฝึกฝนเอ็นแกรมโมเดล
- 5) ขั้นตอน translate\_to\_thai

6) รายการคำภาษาไทยและรายการคำอักษรเบรลล์ภาษาไทย

โดยอินพุต/เอาต์พุตและรายละเอียดแต่ละส่วนมีดังนี้  
อินพุตและเอาต์พุตของระบบ

โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยแบบ File-to-file ที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอไว้ในบทความนี้จะรับอินพุตเป็นไฟล์ข้อความธรรมดา ซึ่งภายในได้บรรจุข้อความที่เขียนให้อยู่ในรูปแบบอักษรเบรลล์ภาษาไทยระดับ 1 โดยการทำงานของโปรแกรมนี้จะประมวลผลข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ครั้งละ 1 ประโยคโดยแบ่งแต่ละประโยคออกจากกันด้วยการเว้นวรรค เช่นเดียวกันกับการเขียนภาษาไทย เมื่อโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ได้นำเสนอนี้ประมวลผลเสร็จแล้ว จะได้เอาต์พุตเป็นประโยคภาษาไทยและนำประโยคภาษาไทยที่ได้นั้นเขียนใส่ในไฟล์เอาต์พุตตามที่ผู้ใช้งานโปรแกรมนี้ได้ตั้งชื่อไฟล์เอาไว้ ซึ่งเป็นไฟล์ข้อความภาษาไทยธรรมดา และการทำงานของโปรแกรมก็จะเป็นเช่นนี้ไปเรื่อยๆ จนกว่าข้อความอักษรเบรลล์ภาษาไทยระดับ 1 ในไฟล์อินพุตจะหมดลง

#### 1. ขั้นตอน pre\_ngram\_generate

ขั้นตอนนี้รับอินพุตเป็นข้อความอักษรเบรลล์ภาษาไทยและแบ่งออกเป็นแต่ละประโยคโดยใช้การเว้นวรรค จากนั้นตัดประโยคที่รับมาเป็นส่วนๆ ตามขนาดของจำนวนแกรมที่ได้กำหนดไว้ เพื่อเพิ่มอัตราการจับคู่คำของแต่ละอักขระให้มากขึ้น และให้อาต์พุตเป็นชุดของอักขระอักษรเบรลล์ภาษาไทยโดยแต่ละชุดมีความยาวเท่ากับจำนวนแกรมที่ได้กำหนดไว้

#### 2. ขั้นตอน generate\_ngram\_pattern

ขั้นตอนนี้รับอินพุตเป็นชุดของอักขระอักษรเบรลล์ภาษาไทยจากขั้นตอน pre\_ngram\_generate และนำมาสร้างรูปแบบเอ็นแกรม (n-gram pattern) โดยอ้างอิงกระบวนการสร้างรูปแบบเอ็นแกรมจากเว็บไซต์ <http://www.hlt.nectec.or.th> เพื่อนำไปใช้ค้นหาเปรียบเทียบรูปแบบของคำที่เขียนเรียงติดกันตาม

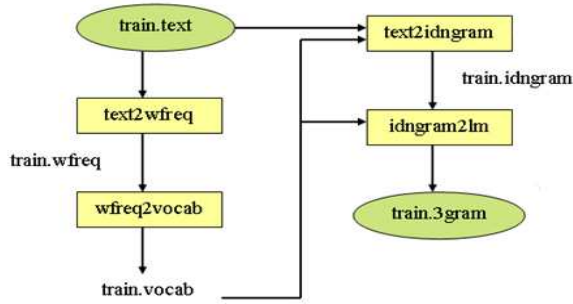
หลักการของเอ็นแกรมโมเดลในขั้นตอนต่อไป โดยให้อาต์พุตเป็นชุดของรูปแบบ n-gram pattern

#### 3. ขั้นตอน select\_output\_pattern

ขั้นตอนนี้รับอินพุตเป็นชุดรูปแบบของ n-gram pattern จากนั้นเปรียบเทียบแต่ละ pattern กับไฟล์ฝึกฝนเอ็นแกรมโมเดลโดยพิจารณาว่า pattern นั้นๆ ใกล้เคียงกับคำใดมากที่สุดและ pattern รูปแบบไหนมีค่าความน่าจะเป็นสูงที่สุด และหากมี pattern นั้นปรากฏอยู่ในประโยคก็เลือกเอา pattern นั้นเป็นคำเอาต์พุต หากไม่มีก็จะเลือกเอาคำที่มีความคล้ายคลึงกับ pattern นั้นมากที่สุดมาแทน แต่จะต้องมี pattern นั้นปรากฏอยู่ในประโยคด้วย จากนั้นใส่เครื่องหมาย “<pipe>” เพื่อเป็นสัญลักษณ์ในการแบ่งคำแต่ละคำออกจากกัน และส่งค่าความยาวของประโยคที่เหลือกลับไปให้ขั้นตอน pre\_ngram\_generate เพื่อสร้างชุดของอักขระใหม่และทำแบบนี้วนไปเรื่อยๆ จนกว่าจะจบประโยค เมื่อจบขั้นตอนนี้แล้วจะให้เอาต์พุตเป็นประโยคอักษรเบรลล์ที่มีการแบ่งคำแต่ละคำออกจากกัน โดยใช้เครื่องหมาย “<pipe>” คั่นคำแต่ละคำ

#### 4. ไฟล์ฝึกฝนเอ็นแกรมโมเดล

ไฟล์ที่ใช้ฝึกฝนเอ็นแกรมโมเดลนี้ สร้างขึ้นจากการใช้ชุดเครื่องมือ CMU-SLM toolkit โดยในการทดลองได้ใช้ขนาดของจำนวนแกรมเท่ากับ 3-gram, 4-gram และ 5-gram เพื่อเปรียบเทียบว่าจำนวนแกรมเท่าใดจึงจะให้ผลลัพธ์ที่ดีที่สุด ซึ่งวิธีการฝึกฝนเอ็นแกรมโมเดล (Training N-gram model) คือ กระบวนการทางสถิติเพื่อให้เอ็นแกรมโมเดลคำนวณค่าความน่าจะเป็นของคำหนึ่งๆ ว่าสามารถเกิดขึ้นร่วมกับคำใดได้บ้าง โดยขั้นตอนการฝึกฝนเอ็นแกรมโมเดลอ้างอิงมาจากเว็บไซต์ [www.hlt.nectec.or.th](http://www.hlt.nectec.or.th) ดังแสดงในภาพที่ 2



ภาพที่ 2 การฝึกฝนเอ็นแกรม โมเดล

โดยการฝึกฝนเอ็นแกรม โมเดลจะได้เป็นไฟล์นามสกุล .gram และในไฟล์ .gram นี้จะบรรจุค่าความน่าจะเป็นของคำนั้นๆ ว่ามีโอกาสที่จะเกิดขึ้นร่วมกับคำใดได้บ้างด้วยค่าความน่าจะเป็นเท่าไร และบรรจุค่าถ่วงน้ำหนัก (Back-off weight) ที่จะนำไปใช้ในกระบวนการ smoothing อีกด้วย ซึ่งมีการจัดเก็บให้อยู่ในรูปแบบของ ARPA format ซึ่งเป็นรูปแบบไฟล์มาตรฐานของโมเดลภาษา (Language Model)

#### 5. ขั้นตอน translate\_to\_thai

ขั้นตอนนี้เป็นขั้นตอนแปลงข้อความอักษรเบรลล์ภาษาไทยที่ได้ตัดคำแล้วโดยใช้สัญลักษณ์ “<pipe>” คั่นระหว่างคำ แปลงให้เป็นภาษาไทย โดยใช้เทคนิควิธีการจับคู่คำ ซึ่งอาศัยรายการคู่คำอักษรเบรลล์ภาษาไทยและภาษาไทยที่สร้างไว้ก่อนหน้านี้แล้ว โดยแทนที่คำอักษรเบรลล์ภาษาไทยแต่ละคำด้วยคำภาษาไทยที่ได้จับคู่เอาไว้และลบเครื่องหมาย “<pipe>” ออก ซึ่งผลลัพธ์ท้ายสุดก็จะได้ข้อความภาษาไทยเพื่อนำไปเปรียบเทียบประสิทธิภาพกับโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม

#### 6. รายการคู่คำอักษรเบรลล์ภาษาไทยและภาษาไทย

รายการคำอักษรเบรลล์ภาษาไทยและรายการคำภาษาไทยที่จัดเตรียมขึ้นมาจะนำไปใช้ในขั้นตอน Translate\_to\_Thai เพราะเอ็นแกรมโมเดลนั้นมีความสามารถเฉพาะการหาขอบเขตของคำเท่านั้น ไม่สามารถใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้ นอกจากนี้ต้องการเปรียบเทียบประสิทธิภาพระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกี

ภาษาไทยแบบ File-to-file เดิม กับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอขึ้น ซึ่งโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม นั้นให้เอาท์พุทเป็นข้อความภาษาไทย ทำให้จำเป็นต้องมีขั้นตอน Translate\_to\_Thai เพิ่มเติมเข้ามาเพื่อให้เอาท์พุทเป็นข้อความภาษาไทยเหมือนกันเพื่อที่จะเปรียบเทียบกันได้โดยตรง

ดังนั้นจึงได้ออกแบบการแปลงจากอักษรเบรลล์ภาษาไทยเป็นภาษาไทยโดยใช้วิธีเทียบคำต่อคำหลังจากที่ใช้เทคนิคเอ็นแกรมในการตัดคำแล้ว ตัวอย่างเช่น เมื่อตัดคำอักษรเบรลล์ภาษาไทยได้เป็นคำว่า “g,dhm\*y” ซึ่งตรงกันกับคำว่า “กฎหมาย” ในภาษาไทย เมื่อใช้วิธีเทียบคำต่อคำก็จะแทนที่คำ “g,dhm\*y” ด้วยคำว่า “กฎหมาย” ลงไปแทนในตำแหน่งเดียวกันของข้อความ ทำให้ไฟล์เอาท์พุทเป็นข้อความภาษาไทย


#### ผลการทดสอบเปรียบเทียบประสิทธิภาพ

ในการทดสอบเปรียบเทียบประสิทธิภาพระหว่างโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมกับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำที่ได้นำเสนอขึ้น จะทดสอบเปรียบเทียบทั้งหมด 3 ด้านด้วยกันคือ 1) ความถูกต้องของการแปลง 2) ปริมาณการใช้หน่วยความจำ และ 3) เวลาที่ใช้ในการแปลง ซึ่งมีรายละเอียดดังนี้

##### 1) ด้านความถูกต้องของการแปลง

ในการทดสอบด้านความถูกต้องของการแปลงข้อความอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้ใช้ชุดข้อมูลทดสอบซึ่งแบ่งเป็น 4 ชุดด้วยกันคือ ชุดที่ 1) ข้อความที่ใช้อักษรเบรลล์สองเซลล์ จำนวน 8,713 บรรทัด ชุดที่ 2) ข้อความที่ใช้คำควบกล้ำ จำนวน 231,115 บรรทัด ชุดที่ 3) ข้อความที่ใช้สระประสม จำนวน 219,022 บรรทัด ชุดที่ 4) ข้อความที่ใช้คำทับศัพท์ จำนวน 18,881 บรรทัด โดยแต่ละบรรทัดจะมี 1 ประโยค และในแต่ละประโยคจะบรรจุคำประเภทนั้นๆ อย่างน้อย 1 คำ

โดยชุดข้อมูลทดสอบแต่ละชุดจะมีลักษณะการใช้ภาษาเขียนแบบต่างๆ แบ่งเป็น 3 ประเภทคือ 1) ภาษาเขียนแบบเป็นทางการ 2) ภาษาเขียนแบบไม่เป็นทางการและ 3) ภาษาข่าว ทั้งนี้เพื่อต้องการให้ข้อมูลทดสอบมีลักษณะใกล้เคียงกับการเขียนโดยทั่วไปมากที่สุด โดยอ้างอิงจากโครงสร้างการจัดเก็บข้อความของคลังข้อความ BEST และผลการทดลองแสดงในภาพที่ 3




ภาพที่ 3 ผลการเปรียบเทียบความถูกต้อง

โดยผลการทดลองพบว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดคำสามารถแปลงข้อความที่มีการใช้คำควบกล้ำ, สระประสม, อักษรเบรลล์สองเซลล์ และคำทับศัพท์ ได้ถูกต้องมากกว่าโปรแกรมเดิมคิดเป็น 13.94%, 14.94%, 40.51% และ 19.66% ตามลำดับเมื่อใช้จำนวนแกรมเท่ากับ 4-gram

2) ด้านปริมาณการใช้หน่วยความจำ ในการทดสอบด้านปริมาณการใช้หน่วยความจำจะเริ่มวัดปริมาณหน่วยความจำที่โปรแกรมต้องใช้ตั้งแต่เริ่มเรียกใช้งานโปรแกรมจนกระทั่งโปรแกรมสิ้นสุดการทำงาน โดยใช้ชุดข้อมูลทดสอบเช่นเดียวกันกับวิธีการวัดความถูกต้องของการแปลง และวัดทั้งหมด 10 ครั้ง และหาค่าเฉลี่ยปริมาณการใช้หน่วยความจำของโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิมกับโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัด


คำ โดยแบ่งเป็น เมื่อใช้จำนวนแกรมเท่ากับ 3-gram, 4-gram และ 5-gram ซึ่งผลที่ได้แสดงในภาพที่ 4



ภาพที่ 4 ผลเปรียบเทียบปริมาณการใช้หน่วยความจำ

โดยผลการทดลองพบว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดคำมีปริมาณการใช้หน่วยความจำน้อยกว่าโปรแกรมเดิมคิดเป็น 21.81 เท่า ซึ่งเหมาะสมต่อการนำไปใช้บนอุปกรณ์ Braille note ซึ่งมีทรัพยากรที่จำกัด

3) ด้านเวลาที่ใช้ในการแปลง ในด้านเวลาที่ใช้ในการแปลงจะใช้วิธีจับเวลาตั้งแต่เรียกใช้โปรแกรมจนกระทั่งโปรแกรมสิ้นสุดการทำงาน โดยไฟล์ที่นำมาทดสอบจะแบ่งออกเป็น 5 ประเภทคือ 1) ประโยคที่ใช้คำควบกล้ำ 2) ประโยคที่ใช้อักษรเบรลล์สองเซลล์ 3) ประโยคที่ใช้สระประสม 4) ประโยคที่ใช้คำทับศัพท์ และ 5) ประเภทประโยคทั่วไป ซึ่งแต่ละประเภทจะใช้ไฟล์ทั้งหมด 5 ไฟล์และประเภทประโยคทั่วไปใช้ทั้งหมด 10 ไฟล์โดยมีขนาดประมาณ 10 KB (ประมาณ 220 บรรทัด) โดยแต่ละบรรทัดจะมี 1 ประโยคและในแต่ละประโยคมีคำประเภคนั้นๆ อย่างน้อย 1 คำ และทดสอบทั้งหมด 10 ครั้งและหาค่าเฉลี่ย ทั้งนี้เพื่อต้องการให้ใกล้เคียงกับการนำโปรแกรมไปใช้งานจริงมากที่สุด ซึ่งผลที่ได้แสดงในภาพที่ 5



ภาพที่ 5 ผลการเปรียบเทียบเวลาที่ใช้ในการแปลง

โดยผลการทดลองพบว่าโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยตัดคำใช้เวลาในการแปลงมากกว่าโปรแกรมเดิมคิดเป็น 272.71 เท่า จึงเหมาะในการใช้แก้ปัญหาเฉพาะจุดร่วมกับโปรแกรมแปลงตัวอื่น

#### ผลการวิจัยและการอภิปรายผล

จากการพัฒนาโปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมเข้ามาช่วยในการตัดคำเพื่อแก้ไขปัญหาของโปรแกรมแปลงเบรลล์เป็นแอสกีภาษาไทยแบบ File-to-file เดิม โดยสามารถแก้ไขปัญหาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้เป็นอย่างดี และใช้ปริมาณหน่วยความจำน้อยกว่าโปรแกรมเดิมมากซึ่งใช้กฎไวยากรณ์ทางภาษาเข้ามาควบคุมการแปลง จึงมีความเหมาะสมมากกว่าในการนำไปใช้ในอุปกรณ์ Braille Note ที่มีทรัพยากรอยู่อย่างจำกัด

อย่างไรก็ตามการใช้งานโปรแกรมที่ได้พัฒนาขึ้นมาใหม่นี้ก็มีข้อด้อย คือเวลาที่ใช้ในการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยใช้เวลาแปลงที่มากกว่าโปรแกรมเดิมมาก ทำให้โปรแกรมนี้เหมาะกับการใช้แปลงไฟล์ที่มีขนาดไม่ใหญ่มาก ซึ่งผู้ใช้งานสามารถยอมรับได้ แต่หากเป็นไฟล์ที่มีขนาดใหญ่จะใช้เวลาแปลงนาน จึงนับว่าเป็นข้อด้อยของโปรแกรมนี้ที่ควรนำไปปรับปรุงให้ดีกว่าเดิม

## สรุป

บทความนี้เสนอการนำเทคนิคเอ็นแกรมโมเดลมาประยุกต์ใช้ตัดคำอักษรเบรลล์ภาษาไทยเพื่อลดความกำกวมของภาษาก่อนที่จะแปลงไปเป็นภาษาไทย ซึ่งวิธีการนี้สามารถช่วยแก้ปัญหาการแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยได้เป็นอย่างดี โดยเฉพาะปัญหาที่เกี่ยวข้องกับการแปลงคำควบกล้ำ คำที่มีการใช้สระประสม อักษรเบรลล์สองเซลล์และคำทับศัพท์ และจำนวนแกรมที่เหมาะสมสำหรับใช้ตัดคำอักษรเบรลล์ภาษาไทยคือ 4 แกรม

#### ข้อเสนอแนะ

การนำเทคนิคเอ็นแกรมเข้ามาช่วยตัดคำอักษรเบรลล์ภาษาไทยก่อนที่จะแปลงให้เป็นภาษาไทยสามารถช่วยลดความกำกวมของคำได้เป็นอย่างดี แต่ยังคงมีประเด็นเรื่องเวลาที่ใช้ในการแปลงที่ทำให้ช้ากว่าโปรแกรมเดิมมาก ซึ่งไม่เหมาะสมในการนำไปใช้แปลงไฟล์ขนาดใหญ่ทั้งหมด แต่ควรใช้งานร่วมกับวิธีการอื่นๆ เพื่อเพิ่มความถูกต้องในการแปลงคำควบกล้ำ คำที่มีการใช้สระประสม อักษรเบรลล์สองเซลล์และคำทับศัพท์

#### เอกสารอ้างอิง

- วรพล ทินกรสูติบุตร. (2551). การแปลงเบรลล์และแอสกีภาษาไทยแบบทันทีทันใด. วิทยานิพนธ์มหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์
- Stanley F. Chen and Joshua Goodman. (1996). An Empirical Study of Smoothing Techniques for Language Modeling, Aiken Computational Laboratory Harvard University.
- N-gram. (2011). Retrieved September 5, 2011, from <http://en.wikipedia.org/wiki/N-gram>
- BEST Corpus. (2011). Retrieved September 5, 2011, from <http://thailang.nectec.or.th/2009/index.php>
- Philip Clarkson. (2011). CMU-SLM language model toolkit. Retrieved



- September 26, 2011, from <http://mi.eng.cam.ac.uk/~prc14/toolkit.html>
- Training N-gram model. (2011). Retrieved September 5, 2011, from [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_content&view=article&id=70&Itemid=94](http://www.hlt.nectec.or.th/speech/index.php?option=com_content&view=article&id=70&Itemid=94)
- Word wrap. (2011). Retrieved September 5, 2011, from [http://en.wikipedia.org/wiki/Word\\_wrap](http://en.wikipedia.org/wiki/Word_wrap)
- Language model. (2011). Retrieved September 5, 2011, from [http://www.hlt.nectec.or.th/speech/index.php?option=com\\_content&view=article&id=70&Itemid=94](http://www.hlt.nectec.or.th/speech/index.php?option=com_content&view=article&id=70&Itemid=94)

## ภาคผนวก ข : ตารางผลการทดลอง

ตารางที่ 1 ผลการทดลองปริมาณการใช้หน่วยความจำ

ครั้งที่	วิธีการเดิม		วิธีการใหม่					
			3-แกรม		4-แกรม		5-แกรม	
	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)	ค่าความกล้า (MB)	สระประสม (MB)
1	179	178.9	8.2	8.2	8.9	8.9	8.8	8.8
2	178.8	179.2	8.2	8.3	8.8	9.3	8.9	8.9
3	179.1	178.6	8	8.4	8.7	8.7	8.7	8.7
4	178.7	178.8	8.5	8	8.8	8.9	8.6	8.8
5	178.9	178.9	8.2	8.1	9.2	8.8	8.8	8.8
6	178.7	178.7	8.1	8.2	9	9.2	8.8	8.7
7	179.2	179.1	8.3	8.1	8.9	9	8.7	9
8	178.9	179.3	8	8.3	8.8	8.7	8.7	8.7
9	178.7	178.8	8.3	8.2	8.8	8.7	8.9	8.8
10	178.9	178.6	8.1	8.3	9	8.8	9	8.9
เฉลี่ย	178.9	178.9	8.19	8.21	8.89	8.9	8.79	8.81
SD.	0.1729	0.2424	0.1524	0.1197	0.1449	0.2108	0.1197	0.0994
Max	179.2	179.3	8.5	8.4	9.2	9.3	9	9
Min	178.7	178.6	8	8	8.7	8.7	8.6	8.7

ตารางที่ 2 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำควบล้ำ

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำควบล้ำ (เวลา : วินาที)									
	วิธีการเดิม					วิธีการใหม่				
	ไฟล์ที่					ไฟล์ที่				
	1	2	3	4	5	1	2	3	4	5
1	0.55	0.75	0.74	0.44	0.43	149	174	160	155	150
2	0.54	0.74	0.73	0.43	0.42	148	173	162	156	152
3	0.53	0.73	0.72	0.42	0.41	150	174	161	156	152
4	0.53	0.73	0.73	0.43	0.42	149	174	161	156	152
5	0.56	0.76	0.75	0.45	0.44	148	175	160	156	152
6	0.54	0.74	0.73	0.43	0.42	149	175	160	155	152
7	0.56	0.76	0.75	0.45	0.44	149	176	161	156	152
8	0.54	0.74	0.73	0.43	0.42	148	174	160	157	153
9	0.55	0.75	0.74	0.44	0.43	150	174	161	156	152
10	0.56	0.76	0.75	0.45	0.44	149	173	161	155	151
เฉลี่ย	0.546	0.746	0.737	0.437	0.427	148.9	174.2	160.7	155.8	151.8
SD.	0.0117	0.0117	0.0106	0.0106	0.0106	0.7379	0.9189	0.6749	0.6325	0.7888
Max	0.56	0.76	0.75	0.45	0.44	150	176	162	157	153
Min	0.53	0.73	0.72	0.42	0.41	148	173	160	155	150
จำนวนบรรทัด	198	205	200	178	182	198	205	200	178	182
Size(KB)	9.76	10	10	9.83	9.95	9.76	10	10	9.83	9.95

ตารางที่ 3 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์สระประสม

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์สระประสม (เวลา : วินาที)									
	วิธีการเดิม					วิธีการใหม่				
	ไฟล์ที่					ไฟล์ที่				
	1	2	3	4	5	1	2	3	4	5
1	0.55	0.54	0.53	0.73	0.63	158	155	142	194	140
2	0.54	0.53	0.52	0.72	0.62	158	155	142	195	141
3	0.54	0.53	0.52	0.72	0.62	158	155	142	196	140
4	0.53	0.52	0.51	0.71	0.61	159	155	142	195	140
5	0.56	0.55	0.54	0.74	0.64	158	155	142	194	141
6	0.53	0.52	0.51	0.71	0.61	159	155	141	195	141
7	0.54	0.53	0.52	0.72	0.62	158	155	143	195	140
8	0.55	0.54	0.53	0.73	0.63	159	155	142	195	140
9	0.56	0.55	0.54	0.74	0.64	158	154	142	195	141
10	0.54	0.53	0.52	0.72	0.62	158	156	142	195	140
เฉลี่ย	0.544	0.534	0.524	0.724	0.624	158.3	155	142	194.9	140.4
SD.	0.0107	0.0107	0.0107	0.0107	0.0107	0.4830	0.4714	0.4714	0.5676	0.5164
Max	0.56	0.55	0.54	0.74	0.64	159	156	143	196	141
Min	0.53	0.52	0.51	0.71	0.61	158	154	141	194	140
จำนวน บรรทัด	197	197	191	202	198	197	197	191	202	198
Size(KB)	9.86	9.64	9.17	9.19	9.76	9.86	9.64	9.17	9.19	9.76

ตารางที่ 4 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์อักษรเบรลล์สองเซลล์

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์อักษรเบรลล์สองเซลล์ (เวลา : วินาที)									
	วิธีการเดิม					วิธีการใหม่				
	ไฟล์ที่					ไฟล์ที่				
	1	2	3	4	5	1	2	3	4	5
1	0.55	0.56	0.57	0.77	0.76	161	162	168	184	182
2	0.53	0.54	0.55	0.75	0.74	160	164	170	184	182
3	0.56	0.57	0.58	0.78	0.77	160	162	170	184	180
4	0.54	0.55	0.56	0.76	0.75	161	162	168	185	182
5	0.53	0.54	0.55	0.75	0.74	160	163	169	184	178
6	0.55	0.56	0.57	0.77	0.76	163	162	168	184	181
7	0.54	0.55	0.56	0.76	0.75	162	163	169	185	181
8	0.55	0.56	0.57	0.77	0.76	160	164	169	184	182
9	0.53	0.54	0.55	0.75	0.74	161	163	167	184	187
10	0.54	0.55	0.56	0.76	0.75	160	164	168	184	179
เฉลี่ย	0.542	0.552	0.562	0.762	0.752	160.8	162.9	168.6	184.2	181.4
SD.	0.0103	0.0103	0.0103	0.0103	0.0103	1.0328	0.8756	0.9661	0.4216	2.4129
Max	0.56	0.57	0.58	0.78	0.77	163	164	170	185	187
Min	0.53	0.54	0.55	0.75	0.74	160	162	167	184	178
จำนวนบรรทัด	211	211	245	214	217	211	211	245	214	217
Size(KB)	9.14	9.17	9.6	9.92	9.87	9.14	9.17	9.6	9.92	9.87

ตารางที่ 5 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำทับศัพท์

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทไฟล์คำทับศัพท์ (เวลา : วินาที)									
	วิธีการเดิม					วิธีการใหม่				
	ไฟล์ที่					ไฟล์ที่				
	1	2	3	4	5	1	2	3	4	5
1	0.53	0.52	0.51	0.61	0.41	163	160	159	171	146
2	0.56	0.55	0.54	0.64	0.44	161	160	157	172	147
3	0.55	0.54	0.53	0.63	0.43	162	160	157	171	147
4	0.54	0.53	0.52	0.62	0.42	163	161	157	172	146
5	0.56	0.55	0.54	0.64	0.44	162	160	157	172	148
6	0.56	0.56	0.55	0.65	0.45	162	160	158	171	146
7	0.56	0.56	0.55	0.65	0.45	163	161	157	170	146
8	0.55	0.54	0.53	0.63	0.43	161	161	157	172	148
9	0.53	0.52	0.51	0.61	0.41	162	161	158	171	146
10	0.54	0.53	0.52	0.62	0.42	162	161	157	172	146
เฉลี่ย	0.548	0.54	0.53	0.63	0.43	162.1	160.5	157.4	171.4	146.6
SD.	0.0123	0.0149	0.0149	0.0149	0.0149	0.7379	0.5270	0.6992	0.6992	0.8433
Max	0.56	0.56	0.55	0.65	0.45	163	161	159	172	148
Min	0.53	0.52	0.51	0.61	0.41	161	160	157	170	146
จำนวนบรรทัด	193	191	186	196	185	193	191	186	196	185
Size(KB)	9.98	9.68	9.96	10	9.19	9.98	9.68	9.96	10	9.19

ตารางที่ 6 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประโยคทั่วไปของวิธีการเดิม

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทประโยคทั่วไป (เวลา : วินาที)									
	โปรแกรมแปลงเบรลล์เป็นรหัสแอสกีภาษาไทยแบบ File-to-file (วิธีการเดิม)									
	ไฟล์ที่									
	1	2	3	4	5	6	7	8	9	10
1	0.54	0.55	0.55	0.56	0.55	0.54	0.54	0.55	0.56	0.56
2	0.54	0.55	0.54	0.55	0.54	0.55	0.55	0.54	0.55	0.54
3	0.53	0.56	0.54	0.54	0.56	0.55	0.54	0.54	0.54	0.53
4	0.56	0.53	0.53	0.56	0.55	0.56	0.54	0.56	0.56	0.55
5	0.54	0.54	0.54	0.55	0.54	0.54	0.56	0.55	0.53	0.56
6	0.56	0.56	0.56	0.56	0.54	0.55	0.56	0.56	0.54	0.56
7	0.55	0.56	0.54	0.56	0.56	0.54	0.55	0.55	0.55	0.53
8	0.54	0.54	0.53	0.55	0.55	0.55	0.54	0.55	0.56	0.54
9	0.53	0.56	0.56	0.54	0.54	0.54	0.55	0.54	0.55	0.55
10	0.54	0.55	0.56	0.55	0.54	0.56	0.55	0.56	0.53	0.54
เฉลี่ย	0.543	0.55	0.545	0.552	0.547	0.548	0.548	0.55	0.547	0.546
SD.	0.0106	0.0105	0.0118	0.0079	0.0082	0.0079	0.0079	0.0082	0.0116	0.0117
Max	0.56	0.56	0.56	0.56	0.56	0.56	0.56	0.56	0.56	0.56
Min	0.53	0.53	0.53	0.54	0.54	0.54	0.54	0.54	0.53	0.53
จำนวนบรรทัด	198	224	214	201	214	219	218	214	221	195
Size(KB)	9.92	9.97	9.98	9.91	9.96	10.00	10.00	10.00	9.95	9.98

ตารางที่ 7 ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประโยคทั่วไปของวิธีการใหม่

ครั้งที่	ผลการทดลองเปรียบเทียบเวลาที่ใช้ในการแปลงประเภทประโยคทั่วไป (เวลา : วินาที)									
	โปรแกรมแปลงอักษรเบรลล์ภาษาไทยเป็นภาษาไทยที่ใช้เทคนิคเอ็นแกรมในการตัดคำ(วิธีการใหม่)									
	ไฟล์ที่									
	1	2	3	4	5	6	7	8	9	10
1	155	159	163	162	153	159	151	167	165	166
2	156	159	162	162	153	159	151	168	166	167
3	156	159	163	162	154	159	150	168	166	165
4	156	161	162	161	154	159	150	166	167	167
5	155	159	162	163	153	159	150	167	166	165
6	155	159	162	162	154	159	150	167	166	165
7	156	159	164	161	154	160	150	168	166	166
8	155	160	162	162	153	159	150	166	165	167
9	156	159	163	163	154	158	150	167	166	165
10	155	160	162	161	154	160	150	166	166	166
เฉลี่ย	155.5	159.4	162.5	161.9	153.6	159.1	150.2	167	165.9	165.9
SD.	0.5270	0.6992	0.7071	0.7379	0.5164	0.5676	0.4216	0.8165	0.5676	0.8756
Max	156	161	164	163	154	160	151	168	167	167
Min	155	159	162	161	153	158	150	166	165	165
จำนวนบรรทัด	198	224	214	201	214	219	218	214	221	195
Size(KB)	9.92	9.97	9.98	9.91	9.96	10.00	10.00	10.00	9.95	9.98



ภาคผนวก ค : รายการคำที่มีความผิดพลาดประเภทต่างๆ

ตารางที่ 8 รายการคำที่โปรแกรม Thai2brl แปลงผิดพลาด

คำไทย	Thai2brl แปลงผิด	ที่ถูกต้องควรเป็น
	เบรลล์ไทยระดับ 1	เบรลล์ไทยระดับ 1
ข้างเป็ออกมา	k4*}&%4ogm*	k4*}f&4oogm*
มาทำอะไร	m*)%a:r	m*f)oa:r
เกลี่ยกันไป	f/l29yg>n:&	/l(9yg>n:&
ไถ่เกลี่ย	:gl9fgl29y	:gl9gl(9y
กระเป๋้าเป็อย่าง	gra&68&%4y9*}	gra%68f&4oy9*}
เกลี่ยดิน	fgl29ydbn	gl(9dbn
ปนเป็อยู่	&n&%y39	&nf&oy39
ลั้งเลอยู่	l>}l%y39	l>}floy39
อ่อนเพ็ลี่ย	o9onf?l2y	o9on?l(
เกลี่ย	fgl29y	gl(9y
ร่อนเร็อยู่	r9omr%9y39	r9onfr9oy39
ทะเลอยู่ไหน	)al%y39:hn	)afaoy39:hn
ลั้งเคราะห์	s>}ur*ah0	s>}uroah0
เพ็ลี่ยกาย	f?l2yg*y	?l(g*y
คำว่า	u*w9*	uzw9*
โอ้เอ็อยู่	io4o%4y39	io4fo4oy39
เมื่อ	fm59o	mq9
คะเนอยู่	uan%y39	uafnoy39
จะเข็อยู่	jak%y39	jafk4oy39
เต็อยาก	l%4y*g	f 4oy*g
กะลัมกะเหล็ลี่ย	galb4myafh129y	galb4mgahl(9
กลอเคล็ลี่ย	uloful2y	uloul(
ระเหยอยู่	rahy%y39	rah%yoy39

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ก.....-:.....ง	g.....-c.....}	พกลม	?glm	รีโน	r2in
สังเคราะห์แสง	s>}ur*ah0<s}	ชะมบ	+amv	วิกว	wb,?w
กฏกกรโทธิณี	g, cggirhbn2	ฐึฐ	r340)	รียก	r2yg
ใจจรคใจจ่อ	:ljjrd:ljj9o	คร่ำ	r9z	รึรา	r2r*
เพราะฉนั้น	?roa/n>4n	กันธ	u>n0)	ไฮเด	:=fd
แม่ม่าย	ffm9m9*y	ตริว	rbw	กึ๊ก	g37g
กรรมการก	grrmg*rg	วิศย	wbsy	รึ้ง	r{4}
แหยแฝ่น	<hy<fx9n	ถมะ	t*ma	แหวด	<hwd
เข้าเกีย	k64g(	เมรย	fmry	รึ้น	r54n
กรชนกจ	gr0)ngbj	เมลก	fmlg	ช่อย	+9oy
เร้าโลม	r64ilm	บแรง	v<r}	มูพท	m3,lh
บ้านเป่า	v4*n&6	ปฤษฐ	&r1-s,t	ไฮ้ส	:=4s
พัฒนากร	?>-)n*gr	ปล่ง	&19}	โทนะ	ihna
ไหวพวิบ	:hw?wbv	เมहन	fmhn	โหม่	ihm9
เบอร์นี่	v%r0n2	พชระ	?+ra	จ้าน	j4*n
นั้่นเนอ	n>4nn%	ถ้าว	t9*w	ชอว์	+ow0
ประกาศก	&rag*,sg	จ้าว	j9*w	ฝ่อ.	xo.
วันจักร	w>nj>gr	สารท	s*r)	จรส	jrs
ปากไปล์	&*g:&19	พญาน	?,y*,n	ปร-	&r-
ชูเมือง	+3mq}	เม้า	m64	ก้าม	gzm
ไอ้ดโท	io7di)4	เรขา	frk*	ปรด	&rd
ซองแมว	!o}<mw	โชมย	ikmy	รชะ	r+a
เบอร์น	v%r0n	เมาะ	moa	รณ	r,n0
จิดสัน	j>ds>n	โชน	ikln	ปาป	&*&
เสียดกล	s(gl	โชมม	ik-sm	อาด	o*d
ไชยยาฟ	:!yy*\$	วู้ง	wc4}	แจะ	j<a
ประสาร	&ras*r	เมิด	m%l	วฤก	wrlg
โสเหล่	isfh19	พณิข	?,nb+	ปรม	&rm
ละเมิน	lam%n	ถึ้ง	tb9}	มบธ	mv0)
กับแก	g>v<g4	เร่ม	fr9m	วศค	w,su

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ลูกล่า	l3gI9*	พูน	?34n	พีร	?2r
ปัญญาส	&>,y,y*s	เมื่อ	mq	มมข	mmk
ข้าวกะ	k4*wga	พนจร	?njr	ร้น	r4n
เป็นไฟ	f&'n:\$	ซังข	+>},u	รנד	rnd
เหลื่อม	hlqm	ปลาก	&l*g	คาธ	u*0)
ว่ายดา	w9*y *	เราะ	roa	รบศ	rvs
เค็กชา	fd'g+*	เวตร	fwlr	รปก	r&,&?
วิชาธร	wb+*0)r	บอดอ	vo o	ทอย	)oy
วิหตุต	wb)yc	ถึง	t{}9	วหา	wh*
เดินหน	d%nhn	ธรม	0)rm	วอค	wou
มาเรีย	m*r(	พนาย	?n*y	ขุน	,kcn
กรี้ดก	gr27dg	ธอโร	0)oir	มรณ	mr,n
โดได้	idid4	บ้อม	v4om	เขา	,k6
มีเรีย	m2r(	บ้อม	v8om	ปาร์	&*r
น้ำตาย	n4z *y	ซังก	0)>}g	โตก	ilg
เผ่าไท	p69:)	แครต	<ur	คคน	uun
โสคน้ำ	i,sgn4z	เวย์	fwy0	วอด	wol
บรรดาก	vrrd*g	เวรา	fwr*	ขอนแก่น	kon
เกลือก	glqg	เพชร	f? r	คฤห	ur h
อ้อมสม	oc4msm	ปลาด	&l*	น้ท	n>,) )
เคลิบ	ul%v	กูรม	g3rm	คล-	ul-
เยียน	y(n	ซัปน	+>&n	นััน	n>n
เยียบ	y(v	เพรา	?r6	รพา	r?*
ทาบทา	)*v)*	กูวา	g3w*	อาม	o*m
เจ็ย	fj7yc	เวลี	fwsb	โตย	ily
เจรีด	fjr'd	เวहन	fwhn	gur	gur
เยียว	y(w	พยาล	?y*1	กลี	gl2
หนัน	hn>9n	ไขมา	:km*	คงธ	u}0)
หน้า	hn>4*	ซ็อน	k4on	มदन	mln
ทาร์พี	)*r?2	แคละ	ul<a	สูด	,s3l

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เลห์ล	fuh0l	แคแล	<u<l	ระยะ	rya
กุเทพ	gcf)?	ธารณ	0)*r,n	จลา	jl*
พัวนา	pen*	ไข้ว	:k4w	ขาด	+*d
แยแส	<y9<s	พรพล	?r?l	ฝี่	x29
เวี่ยน	fwy0n	เวีย	w(	ฝีก	x2g
เวหาส	fwh*s	ไขษย	:k-sy	คาม	u*m
เว็ก	w%4g	ถุ้ง	tc4}	ไต่	:l 9
เวียก	w(g	ถือก	l37g	มวก	mwg
กุมท	gcmc)	ธินะ	0)b,na	แท้	<h4
เพอญ	f?ob,y	แวดี	<wd2	นิ้ว	ne
กทรรป	g)rr&	แวดร	<w r	ซาซ	!*
เคียร	u(r	ปลีก	&l2g	มสด	msd
หมดพก	hmd?g	ซึ้น	,k{4n	ยัญ	-s>,
จะกุ	jfagc	ซ้อย	k4oy	ยซ่า	-s>,)
จะคะ	jfada	ก้าบ	u4*v	ยัณ	-s>,n
กูรุง	gcrcl}	คคนะ	uuna	ยัษ	-s>-s
เคือ	uq4	ธีโอ	0)2io	แะ	<-a
แคแกล	<u<gl	ขอลอ	kolo	โะ	i-a
กูร	gcrcl	ธูมา	0)cm*	จිර	jbr
โวการ	iwg*r	จิตด	jb	คณน	u,nn
โวทาน	iw)*n	ไวโพ	:wi?	รสก	rsg
กูเรา	gcr6	ชากา	+*g*	แม่	<m7
ก้นขบ	g4nkv	เพิ่ม	?%m	สกก	sg,
ไวคอม	:wuom	ชาคร	+*ur	ซาร	+*r
พื้ว	p24w0	ปวาพ	&w*,l	กรรา	gr*
ทำนูล	)zn3l	ธนู	f0)nc	ปีบ	&2v
แพทยา	<?)y*	คงที	u})2	ไหน	:lhn
กูเวร	gcfwr	ปสาท	&s*)	กัว	ge
แพรมน	<?rmn	ปสาน	&s*n	ปีป	&2&
แคบิต	<uvbd	โธวน	i0)wn	ไหม	:lhm

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ศตปที	,s&)2	เพื่อ	?q	ซัซ	k>+
รงก์	r}gc0	อจลา	o]l*	โรษ	ir-s
รจเลข	rjflk	ปหาร	&h*r	ไหว	:lhw
ทำให้	)z:h4	อจิริ	o]br	ชาด	+*1
คลี่ป	ulb7&	ดยุก	dycg	ปีฟ	&2,l
นายดุ	n*ydc	ดยุก	dycu	สขะ	ska
โพรติ	i?rdb	แก่น	fg9n	สขา	sk*
กูชิน	g3!bn	แพทย	<?)y	สชิ	skb
เผนิก	fpmbg	แม่	<m9f	ถกถ	tgl
เผลี้จ	fpl'j	ศยนะ	,syna	กกก	ggg
เผลี้ด	fpl'd	อพระ	o)ra	กรร	grr
กูดกบ	g3dgv	ศยาม	,sy*m	รอน	ron
นายติ	n*y]b	พรอก	?rog	ก้า	g7*
รมณีย	rm,n2y	ศรัท	,sr>)	ปู่ฎ	&c,
เผลิด	fplbd	อริป	o0)b&	ฤช	r]c
ทิพยา	)b?y*	ชะยง	kay}	ฤตุ	r]c
รมิดา	rmbd*	ป้อย	&4oy	ฉน้ำ	/nz
เผอิด	fpopl	พรอด	?rod	ฉบบ	/vv
เผ็ง	p%9}	ชะยม	kaym	ฤษภ	r]s,?
เผ็ง	p%4}	ศรภาพ	,sr*?	รอม	rom
เผียน	p(n	อนงค	on}u	กกพ	gg?
ไพเรอ	:?r%	อนยะ	onya	หตะ	h]a
ศวศุร	,sw,scr	กั่ว	ge9	หทย	h]y
ศวสัน	,sw>sn	อนัม	on>m	ฉบ้ำ	/vz
นายทร	n*y)r	ทนอด	)nod	ฉมบ	/mv
ไพสาง	:?,s*k	แม้ง	<m4}	หนง	hn}
ศอกก้า	,soggz	ฉินต	jbn	กกถ	gg]l
บาววน	v*&wn	กัษณ	g>-s,n	เกถ	fg]l
คลุ้ม	ulc4m	อนีก	on{g	ฉมา	/m*
หย้อย	hy'oy	เกร์	fg9	ฉม่า	/mz

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
หิ้ว	hy4*w	อนุช	onc+	ลกร	lgr
บ่าลง	v9*1}	ปีกข	&>gk	ปุ่ร	&cr
บาลอก	v*log	ปีกข	&>g-s	ลขข	lkk
บาลาน	v*1*n	กาคำ	g*uz	ลคร	lur
กระลา	gral*	อนุส	oncs	สัญ	s9,y
บาสมา	v*sm*	สลัด	,sl>t	ลฆุ	l,uc
หรั้ว	hr>sw	ไพโค	:?iu	สดก	sdg
รโหด	rihu	สำหา	szh*	กกะ	gga
กูดกู	g3d,?3	สัวส์	,sw>s	สदन	sdn
ทีแท้	)2<4	ศศธร	,s,s0)r	ถ่ง	19}
กระลำ	gralz	ทรรป	)rr&	นัร	n2r
กมลเศ	gmfl,s	ตะกู	ag3	สคำ	sdz
หลงจิ	hl}jb	ตะแก	a<g	สดี	sd2
หลงตา	hl} *	บajak	v*jg	สดี	s 0
กระลี	gral2	ทรวด	)rwd	สดก	slg
หลงลม	hl}lm	ทรहन	)rhn	สदन	sln
ดักษณ	>g-s,n	ทรหุ	)rh3	ก่ง	g9}
ฝนฟ้า	xnx4*	ปัญญา	&>,yj	ก่ง	g4}
พื้ตวา	\$> w*	กาชี	g*!b	ชิน	!bn
เซราะ	flr*a	ศัพท	,s>?)	สต่อ	slo
ฝรั้ง	xr>4}	ศัลก	,s>lg	นุง	nc}
กูรมะ	g3rma	บาทบ	v*)v	ชิม	!bm
กูวัง	g3w>}	เกลศ	fgl,s	ฉศก	/,sg
กระวี	graw2	ศากย	,s*gy	ล่น	19n
กรณีย	gr,n2y	ศากุก	,s*,dg	พฤต	?r1-)
รอบคี	rovu2	ศานต	,s*n	พฤต	?r1
ทีโรส	)2irs	ช่าว	+9*w	ชิต	!bl
กรบูร	grv3r	ทราก	)r*g	มหู	mh3
บินมะ	vbnma	ศพร	,s*?r	ลบบ	lvm
คว้าว	uw9*w	ศารท	,s*r)	ลปก	l&g

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
บินยา	vbny*	อปยศ	o&y,s	ลปน	l&n
บิลญา	vbl,y*	ตะบม	avm	ตาด	*d
บิลบี	vblv2	คาเล	u*fl	กนา	g/*
บิศาจ	vb,s*j	กำว	u9*w	นัฐ	/>,t
กระสน	grasn	ทรม	)rcm	โคด	iul
กระสบ	grasv	ทรู้	)r39	คุบ	ucv
หล็อก	hl'og	ทรูท	)r3)	สถน	stn
ศิกษก	,sbg-sg	ก้าน	g7*n	สถล	stl
หล่อน	hl'on	ทลบม	)lvm	คุป	uc&
ร่อยๆ	r9oyl	ทลท	)lb)	ลัว	l4w
ศิเฆา	,sbk6	กานน	g*n	ตาน	*n
ที่สุด	)2scd	กตุ้	gl39	กอย	goy
พินฟู	\$5n\$3	ท่วย	)9wy	ชปท	0)&)
กระสะ	grasa	ท้วย	)4wy	ชพน	0)?n
ฟูล	\$cd3l	ทวยะ	)wya	พะ	?fa
ระจี้	ra}29	แมลบ	<mlv	ชรณ	0)r,n
กอมจญ	gopj,y	ท้วย	)w>y	สาด	s*
ทุกข์	)cgk	โครส	iurs	วาก	w*g
ขึ้นง	k{4n}	ทวิช	)wb+	ตาบ	*v
หลาหล	hl*hl	โครำ	iurz	จุน	jcn
เกิน	fg7n	ตะละ	ala	ลวย	lwy
หลิ่ง	h1b9}	ขานู	k*,nc	จະะ	jaa
บือชา	v5o!*	เกศว	fg,sw	ชีท	l2)
คิลปี	,sbl&2	นกกก	nghg	กาฐ	g*,t
บือโค	v5oid	ดอมอ	do,uo	โคส	ius
บือแน	v5o<n	ด้อง	d4o}	กอส	gos
ฝัจก	x2j>g	สิ่ง	s29}	เกษ	fg-s
ศุทธิ	,sc)0)b	โคดค	iuld	กฏี	g, b
ศุณัก	,scn>g	สีตล	s2 l	ไคร	:ur
ศุยริ	,sc-sbr	ก้วย	g8wy	ถนป	tn&

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ระหวย	rahwy	อ่ยง	oy9}	พ.ศ	?,s
เกยลา	fgyl*	อ่ยส	oy>s	คว-	uw-
ระแอน	ra<on	กาบ	g*v3	ถน้ำ	tnz
รักษา	r>gk*	ศาสก	,s*sg	ดอ	loo
เกยร	fgy3r	ดอป	do&o	โมน	im,u
รักดป	r>gd&	สีมา	s2m*	ถม	tmo
กะลอก	ga/od	ฟ้าม	\$9*m	ถลน	tln
เกรี่บ	fgr'v	อ่ย	oyc9	ถลม	tlm
เกรี่ม	fgr'm	ทหระ	)hra	น้ย	<n4
ตัวโค	eiu	ก่ว	gw4*	พกา	?g*
กะซี่	gal29	ศาสน	,s*sn	พงศ	?,s
รังเก	r>}fg	สีสะ	s2sa	res	res
โซลซา	i!l+*	สีสา	s2s*	คูถ	u3t
กะดัด	gad>d	โมน	imjn	บิจู	vb,t
ทูเรน	)3frn	กามท	g*m)	ฆาญ	,u*,
กะดอก	galog	ปาคี	&*g2	วาร	w*r
บุตร	vc r0	สิ่ง	s59}	ฆาต	,u*
กะตำ	gal9*	ป้าง	&9*}	ฆาน	,u*n
เสกฐี	f,sg,t2	โมริ	imrb	ตาล	*1
เศรษฐ	f,sr-s,t	โมโร	imir	ชช	!c+
ญญ่าย	,y,y9*y	ข่าม	k9*m	ไกร	:gr
ดางค์	*}u0	โมนก	im-sg	แพศ	<?s
บุทกล	vc)ul	โมนน	im-s,n	ดาว	*w
โคโรค	iuiru	ซี้ต	+24	ไม	:1m4
ขุนลู	kcnl3	เกิน	fg>n	กีด	g'
กะตุค	ga cd	กวาน	gw*n	พชร	?+r
เสวาล	f,sw*1	ปาทป	&*)&	ทาย	)*-s
แจ๊ค	<j7uf	จูน	j3r,n	วาว	w*,l
กะตุก	gal3g	อวจร	owjr	โนน	inn
บุรณะ	vcr,na	งจิด	}}bd	ควา	uw*



ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
โศรตร	i,sr r	สีตล	,s2 l	โนม	inm
เกลิง	fg b}	ค้วย	dey	บีด	v2
หัวตำ	he z	ค้าง	d4*}	วิง	wb}
กะถั่ว	gate	สูงก	sc}g	ดาฟ	*,l
ฐาสุก	,t*scg	สูงะ	scja	ศรณ	s0)n
กะทัง	ga)>}	กาโย	g*iy	กถา	gt*
สกขรา	sgkr*	สุจิ	scjb	พฐู	?0)3
กะทุน	ga)cn	การก	g*rg	ฐู่	0)c0
ณอกุณ	,nouc,n	สุญญ	sc,y,y	ถัน	l>n
ภารยา	,?*ry*	ศุณี	,scnb	งอด	}od
เทรีย	)r(	นพศก	n?,sg	ขาบ	k*v
รันชะ	r>n0)a	นภจร	n,?jr	กทม	g)m
ฆอชนี	,uo+n2	ศุนย	,s3ny	เคก	fug
รากษส	r*g-ss	อเสข	ofsk	ขขว	kkw
สงเขป	s}f-s&	ลกลา	lgl*	ฐูว	0)cw
กะนุด	gavcd	ลกการ	lg*r	อนธ	on0)
คามิน	*mbn	ลกจ	lgcj	ถัก	l>?
โฆยจน	ij-sjn	ลกช	luc,)	งอย	}oy
โฆเซ	i,uf!9	ลกพ	luc,l	อนล	onl
คอสอง	uoso}	คัตว	> w	ถัก	l>l
หายยา	h*yy*	ออกเ	oogf	ถั่ว	</9
เบรีย	vr(	คีน	ub9n	พญู	?v3
หิงสา	h{s*	นมผา	nmp*	พพร	??0)
จทวาร	/)w*r	จ้อม	}4om	ถั่ว	</w
จัน	/n>4n	คิมห	ubmh	อนำ	onz
มจวัน	m,uw>n	ปาย	&9*y	ลาช	l*+
ราปิก	r*&2g	ดาโบ	d*iv	ลาญ	l*,y
พญา	?,y*y*	นมาช	nm*!	บงก	v}g
รายวา	r*yw*	นยนะ	nyna	พลว	?lw
มฉกร	m,n,)br	นยนา	nyn*	มับ	m>v

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
พจนกรก	?njrg	คามพ	d*m?	म्म	m>m
ละถี่	/a/29	บบอ	v*vo	มัย	m>y
กรัณฑท	gr>,n,)	กษีร	g-s2r	พลอ	?lo
ละด้า	/a 4*	ลพุช	l?c+	พร-	?r-
แบน โจ	<vnij	บาบี	v*v2	ยกน	ygn
ละนอง	/ano}	ป้าว	&4*w	กนน	gnn
เหมื่อ	fhm4o	ป้าว	&7*w	ขลพ	k/?
เหมอะ	fhmoa	นฤดม	nrldm	พรบ	?rv
เหมื่อ	hmq	นฤตย	nr y	ยขว	ykw
นายร.	n*yr.	ดาลุ	d*lc	ฟอจ	\$oj
ริควน	rbdwn	บาพก	v*?g	ยลร	y/r
เหริน	fhrbn	บ้าย	v8*y	ชงฆ	+},u
มนทึร	mn)br	ทอรา	)or*	ยธษ	y0)-s
มนุชย	mnc-sy	ไฟ้า	:\$4*	ยมก	ymg
สธ.ถี่	s0).g'	ด้าว	d9*w	ยมด	yml
สธุสะ	s0)csa	ง้าน	}9*n	ยวน	ywn
นัยยา	/>yy*	ง้าน	}4*n	ยวา	yw*
โทบิน	i)vbn	ทะทา	)a)*	ขนด	knd
รื่อ	r59o}	ลมาด	lm*d	ลาด	l*l
คากัน	u*g>n	ลลนา	lln*	ร่า	r9*
มรขวด	mrkwd	ลลาฎ	ll*,	ร่า	r4*
สนเดก	snfdg	ทะนน	)ann	ลาศ	l*s
ณิมคก	/bmu}	fund	fund	ขนน	knn
กะแหะ	gah<a	ยมท.	ym).	มาฆ	m*,u
สนาดก	sn*dg	ลวณะ	lw,na	สพท	s?)
มรีจ	mr2jb	ลวณะ	lwna	ขาด	k*l
กะอด	gaobd	ลว่ม	l9wm	โปป	i&&
ใบล้า	:lvs>j	ล้วย	l4wy	คร-	r-
แหร์น	<hr9n	เจมะ	fjma	ชนม	+nm
แหร์ว	<hr4w	ช้อย	y4o}	นาด	n*d

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
รู้ดี	r3d24	ทะแย	)a<y	ถึร	tbr
ตำหระ	zhra	คึน	u54n	มาด	m*d
ครธาน	dr0)*n	ก่อง	g9o}	อปร	o&r
มลิน	mlb4n	ภฤดก	,?r1dg	นาท	n*)
มลิน	ml59n	ดาอี	d*o2	ขอบ	yov
มวกผา	mwgp*	ค้ำกถ	dzgl	มาด	m*
แห้ว	<hw4}	เศรฐ	f,sr,t	ชู้	+39
แห้ว	<hw4n	ลอนิ	lonb	คึน	d2n
สนุ่น	snc9n	อะแจ	oa<j	คึป	d2&
เขยอะ	fkyoa	ค้ำดง	dzd}	กว-	gw-
มสารก	ms*rg	งายู	}*y3	งาย	}*y
มหัคฆ	mh>u,u	ลอมแม	lo<m	พล้า	?lz
คถภาค	dl,?*u	ล่อย	l9oy	อกว	o,?w
รูสึก	r3s{g	เศลษ	f,sl-s	คอก	uou
กริตย	grb y	นหาน	nh*n	หญ	hyc
ค้ำตา	u9* *	ค้ำนู	dz n3	มาท	m*)
ป้งมา	&8}m*	นหุด	nhc	มาน	m*n
เขยตร	fk-s r	บ้ำรู	vzr3	ชูป	+3v
มหาพน	mh*?n	เศจ	,s6j	หญ	hy3
คไวท์	d:w)0	ตาขอ	*ko	หรณ	hr,n
โง้งๆ	i}9}1	คณิน	u,nbn	จึน	}bn
ปฎิรพ	&, br?	ค้ำบด	dzv1	จึม	}bm
คึกถ	2g*g	ลถกถ	lagl	อร	ocr
พร่อย	?r9oy	ยัษฐ	-s>-s,t	ชมบ	+mv
ปตานี	& *n2	โยทศ	i-s,},s	ปล-	&l-
ปถม้ง	&tm>}	ทะไล	)a:l	จึน	}{n
ปปัญจ	&&>,yj	ค้ำวี	dzr2	ไปย	:&y
เรือก	rqg	ลมะ	lam*	คึก	bg
ปมเป่า	&m&6	ค้ำรู	dzr3	มาบ	m*v
เกียง	g{}	สุรย	s3ry	อมถ	om

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เกิด	g(d	ละมู	lamc	เซ้	f+9
เกียน	g(n	เสกข	fsgk	งุย	}cy
ชนะมี	+nam2	เสีง	fs'}	มาย	m*y
ดอนพล	don?l	ทักษ	)>g-s	ยัญ	y>,y
ประกล	&ragl	เงีน	f}'n	กวม	gwm
ตีกเค	{gfu	ละไม	la:m	ทีก	)2g
กั้นไค	g>n:d	ปีพก	&2,lg	กึ่ง	g{}
มหิมา	mhbm*	ปีพา	&2,l*	คู้	uc9
มหิยี่	mhb-s2	ชษณ	+c-s,n	กวย	gwy
ประจัญ	&raj,y	อ้งส	o>}s	ผกก	pgg
ดักคน	d>gdn	ยัชน	y>+n	พสก	?sg
มิโหษช	mih-s0)	เสนง	fsn}	พสน	?sn
ดักษก	d>g-sg	ยัจู	y>,tb	พสุ	?sc
ดักษณ	d>g-s,n	ย่น	y>9n	อยน	oyn
กรรดิ	grrdb	ภาณก	,?*,ng	ย้า	y4*
ประชน	&ra+n	เสนห	fsnh	กวะ	gwa
คูนกู	cng3	อัฐม	o>,tm	ยาค	y*u
ประชา	&ra+*	อ้นช	o>,n,)	ผคม	pum
กั้นยา	g>ny*	คารร	*0)r	ผงม	p}m
กั้นลง	g>nl}	ด่าน	9*n	ผงร	p}r
กรรทบ	grr)v	เสบย	fsvy	อยู	oy3
แกงไค	<g}:d	กร้อ	gr4o	จะ	jfa
ตุงค	cr}u	เกีย	g(	วีท	w2)
ตุลข่า	clkz	สงกร	s}gr	ทีน	)2n
จแจ้น	j<j4n	อัทธ	o>)0)	วีร	w2r
ประณค	&ra,n	ลัคิน	l>un	กวา	gw*
ประณม	&ra,nm	สงคม	s}um	ยาด	y*d
ชรแรง	+r<r}	สงคร	s}ur	ทีบ	)2v
ประคง	&rad}	ลั้ง	l>9}	ผญา	p,y*
ประคน	&radn	สงคอ	s}uo	คุด	dcd

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
อกเลา	ogl6	อันด	o>n	ผทม	p)m
ขระงม	+ra}m	ยาดร	y* r	ยาน	y*n
ขระงำ	+ra}z	ลัญญ	l>,y/	เอช	fo+
เตงกู	f }g3	ลัญ	l>,tb	แซต	<
ประดี	&radb	คนทา	un)*	กุง	gc}
ขระมด	+ramd	ลัดดา	l>d*	ลี้	l29
ขระลอ	+ralo	ภาสา	,?*s*	อรช	or+
ชันวา	0)>nw*	เสาว	s6w	ลี้	l24
กัปนก	g>&ng	อันธ	o>n0)	อรณ	or,n
ขระลู	+ralc	คนธ	un0)0	ลี้ช	l2+
มะคูก	mad3g	สณจ	s,n,0	แซท	< )
มะแตก	ma< g	กิงส	,?b}s	แซน	< n
สมบัก	sm&>g	ทันต	)>n	เอด	fod
สมมุส	smpcs	เลียบ	s%v	พอน	?on
ประดี	&ra b	สคูป	sd3&	ขบถ	kvt
มะแน	ma<n9	สดอล	s ol	ยาบ	y*v
ธารณะ	0)*r,na	ลาขา	l*k*	กปณ	g&,n
ธารณา	0)*r,n*	จิ่ง	kb9}	วู้	w39
มะป็น	ma&bn	ตามพ	*m?	วู้	w37
มะผาบ	map*v	สติก	s bg	มาศ	m*,s
มะฟ้อ	max9o	อัมพ	o>m?	คุด	dcl
ธารธร	0)*r0)r	ลาขา	l*+*	มาศ	m*s
สมมติ	smm b	ลาชี	l*+b	กฤษ	grl+
กัมดี	g>md2	เปตา	f& *	กฤด	grld
มะพุด	ma?3d	ทัปน	)>&n	เว้	fw8
มะแพน	ma<?n	นะแส	na<s	เวก	fwg
มะแพน	ma<\$n	ล่าน	l9*n	เซส	f+s
มะเมอ	mam%	ทัสน	)>,sn	กพง	g?}
สี่มลม	s4mlm	นักร	n>gr	แพต	<\$
กัมปน	g>m&n	ดีผา	d2p*	กมง	gm}

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ริคุณ	0)buc,n	ดีพร	d2?r	พรณ	pr,n
ประทะ	&ra)a	ดาขอ	*yo	เซา	+6
องคุด	o}ucl	ถ้าย	l4*y	กมจ	gmj
เดริย	r(	ดียว	d2yw	ผล-	pl-
ประท่า	&ra)z	ดียว	d2y*	ผลก	plg
รุคดก	0)cd}u	ทัพท	)>,lh	ผลง	pl}
มะวาร	maw*r	จีณะ	k2,na	อโล	oil
จยุดิ	jyc b	คมน	umn0	อวก	owg
ฐระะ	0)craa	กรัก	gr>g	กฤษ	gc,n
ประเท	&raf)	ตาลอ	*lo	ลุด	lc
คำชุม	uz+cm	ท้าง	)4*}	อวท	ow)
มักตา	m>g *	ข้าว	y4*w	ลูท	lc)
ดาวเน	d*wfn	โง้น	i}4n	แถล	<tl
ควาบส	d*wvs	ลาญ	l*y3	เวย	fwy
มั่งก	m>}g}	ตาดู	*lc	ผลอ	plo
จรมุก	jrm3g	ลาร	*r*	มิต	mb
มั่งกุ	m>}gc	ครั่ง	ur9}	กล-	gl-
จรรจา	jrrj*	ลาดส	l*ls	อสก	os,?
คำตัก	uz >g	ก้าส	g7*s	นขา	nk*
อนวัช	onw>+	ดาวา	*w*	ที่	)59
เขียะ	k(a	ลาวก	l*wg	มิน	mbn
จรวัก	jrw>g	แก้ง	<g4}	เบท	fv)
ค่านาน	dzn*,n	แก้ง	<g}	ลู้	l34
ค่านว	uznwr	กราง	gr*}	ท่ง	)9}
จระทก	jra)g	เกรว	f,?rw	ปลู	&l3
จระนำ	jranz	นันท	n>n)	อเส	ofs
อนุญาต	onc,y*	แสนย	< sny	ขมม	kmm
เขื่อน	kqn	แสนย	<svg	อ้อ	o7o
คำรวจ	dzrwj	แสนย	<syg	กลธ	gl0)
มันตา	m>n *	แสนย	<sy}	หาว	hww

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
มันนง	m>nng	แสอก	<sog	ทธิ	)0)b
คำหนี	dzhnb	แสอง	<so}	ทนต์	)n
แกรั้ง	<gr4}	ครุค	dcru	ไ้	:!14
คำปุ่น	uz&cn	โศดม	isdm	ทนม	)nm
ดิแชะ	db!<a	บุปผ	vc&p	รู่	r29
พระใบ	?ra:lv	กราด	gr*l	กยร	gyr
ชื้อ	+o54o	ยี่	y29n	แวก	<wg
แกรั่ม	<gr4m	อาจ	o*jj	ตฤณ	r1,n
คินหู	dbnh3	บุพพ	vc??	กรก	grg
คินอะ	dbnoa	กำชำ	gz+z	สิร	sbr
ชะต้ำ	+a 4*	กำชำ	gz!z	คปค	u&u
มากชู	m*g+3	ครั้น	ur>n	ย่ำ	yz*
คำสมอ	uzsmo	มกรว	mgr*	ตฤท	r1)
มากธิ	m*u0)2	คูอา	dco*	ภรด	,?r
มังสะ	m*}sa	บุยอ	vcyo	ตฤป	r1&
คำแสด	uz<sd	ยี่	y{4m	รีฟ	r2\$
คิอาช	dbo*!	บุรพ	vcr?	มี	m29
ชะเลย	+afly	คูกร	d3gr	มี	m24
มาซา	m*!6	แกแน	<g<n	หสน	hsn
ชะวก	+aw*g	เปสล	f&,sl	มี	m2f
คำแหง	uz<h}	เปสล	f&sl	แวก	<w\$
อปการ	o&g*r	ยี่	y54m	สี่	s29
สรบับ	srv>v	นาคร	n*ur	รีส	r2s
อปมาน	o&m*n	หงอด	h}od	แ่ง	<}&8
คี่น	d2/>n	อาชี	o*!b	ยี่	yb,t
ไ้ระ	i 7ra	บุษย	vc-sy	สี่	s2,u
สรลอด	srlod	อาณา	o*,n*	ยี่	ybn
อกินห	o,?b,nh	คูรา	d3r*	ทมก	)mg
สรลอน	srlon	สี่	lb4m	รีง	r{}
จอกช	jo}u+	นาคู	n*u3	ทมน	)mn

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เชื่อม	kqm	สถาพ	st*?	ทมบ	)mv
มานุษ	m*nc-s	สถาด	st*l	สีด	s2d
กัศมล	g>,sml	คูอา	d3o*	ภฤศ	,?r1,s
มาฟูส	m*\$3s	มคาย	md*y	หอง	ho}
อมตบท	om v)	คูเอ	d3fo	สีด	s2
ได้ไฟ	: 4:\$	อาเด	o*fd	ทมอ	)mo
คีหีน	d2hbn	อาตม	o* m	ยิป	ybv
น้ำยู	n4*yc	ยูน	yc9n	ตลบ	lv
จอดคค	joddd	ยูน	yc4n	โว	iw9
ประศม	&ra,sm	ยubl	ycvl	ปสพ	&s?
ประศุ	&ra,sc	อานก	o*ng	สมา	sm*
ประศก	&rasg	พริด	?r>d	ทยา	)y*
สลิ่ง	slb4}	อานะ	o*na	กัก	,?>g
กร่อม	gr9om	หญิป	h,ybv	ไว้	:lw4
ดิ่งสะ	d{}sa	พริบ	?r>v	ไเว	:wf
อขาลา	oy*1*	อาน้ำ	o*nz	ทร-	)r-
กลไกล	gl:gl	ยววา	ycw*	ปสุ	&sc
คิลาน	ubl*n	กริว	grbw	คมข	um+
ควี่	ub4w9	ท้าว	)9*w	มีน	m2n
มารษา	m*r-s*	ยูกา	y3u*	ป้อ	&7o
แจมพง	<km?}	ยู้ด	y34d	กสท	gs)
ม้ารำ	m4*rz	ลู่ก	lc9g	คมน	umn
กาจขม	g*j+m	ตำแบ	z<v	กสิ	gsb
ครีย	dcrby	มณญ	mnc,y	ซีด	y2d
นกเกร	ngfgr	นูละ	v3la	แซ้	<k4
สวภาพ	sw,?*?	อ้าม	o9*m	ฌอง	,+o}
มวาว	m*w*r	ลู่้ง	lc4}	สีห	s2h
น้ำชน	n4z+n	น้ำว	n4*w	จิต	kb
สว้าน	sw4*n	อายต	o*y	ฌอน	,+on
จขาบ	jak*v	โชตค	i+ g	คร-	ur-



ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
อวลอบ	owlov	อายน	o*yn	มีก	m{g
อวอล	owlol	แก่	<gl9	แดง	fd}
มาแอะ	m*o<a	ยูษะ	y3-sa	ทรรท	)r)
ลวงค์	lw}u0	เยซุ	fy!c	รุษ	rcy
อเสกข	ofs-gk	เค็จ	fd'j	รุศ	r-cs
ลวิตร	lwb r	ครี	ur24	ญื่อ	,y4o
กลเหย	glfhy	กรีก	ur2u	ทุพ	)c?
แกะกะ	g<aga	แปทุ	<&)3	รู้	r39
มิดล	mbdlo	มมาก	mm*g	ลุม	l3m
ถนนคก	tnn g	มยุง	myc}	รุจ	r3j
มิถุน	m-btcn	แปริ	<&r8	สี่	s5o
นโคทร	niu)r	มยุง	my3k	ครม	urm
นงพงา	n}?)*	คำรุ	zrc	กือ	g7o
โกญจน	ig,yjn	สนธิ	snb0)	ขยด	kyd
มิลลิ	mbllb	สนุข	snck	ศกฏ	,sg,
นนตรา	nn r*	สนุต	snc	ศกถ	,sgl
โกฐสอ	ig,tso	สนุน	sncn	ขยม	kym
สอปูน	so&3n	โชรม	i+rm	จัม	j>m
สอยไร	soy:r	สบกก	svgg	รุศ	r3
กล้อม	gl4om	ก้ามา	gzm*	ปอด	&ol
ละคอน	lauon	สบทบ	sv)v	ศจี	,sj2
ละจิด	la}bd	พฤกษ	?r1g-s	ศดก	,sdg
ละโบม	laivm	นาพี	n*,12	คอด	uol
มีคณา	m2u,n*	ก้ารอ	gzro	ศดก	,sg
สะตือ	sa 5o	หนาง	hn*}	ขยล	kyl
สะทอน	sa)on	แกแผล	<g<1	ญาน	,y*n
มีแชม	m2<!m	แก้ว	<gw9	รุช	r30)
สะนิง	sanb}	มริจ	mr-bj	รุณ	r3n
ละลอก	lalog	เยิง	y%}	ศนิ	,snb
ละวาง	law*}	เยิด	y%d	เดช	fd0)

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ละเวง	lafw}	เย็น	y%n	ศพล	,s?l
คุณจี	uc,nj2	เย็บ	y%v	ศมน	,smn
อะจิ้น	oaj2n	เยิม	y%m	ญีบ	,ybv
ละเหย	lafhy	หนาน	hn*n	เลน	fl,n
โกรญจ	igr,yj	เยี่ย	y(	เลด	fld
กัณฑ์	gl>n)	กำรู่	gZR3	แอม	<om
มีศุข	m2,sck	ติงส	b}s	ศรภ	,sr,?
ละแอน	la<on	กริช	gr2-s	ญี่	,y29
นิกษา	nbG-s*	มลโค	mliu	กอก	gog
ลักษะ	l>gka	สพาบ	s?*v	เลท	fl)
ลักขี	l>gk2	อาศุ	o*,sc	ทุส	)cs
นิกอฮ	nbgo=	มลัน	ml9n	ญี	, ,tb
ลักกา	l>g,?*	ดิชี	b!2	จ้ำ	j7*
นิกะห	nbGah	กริ่ง	gr{}	สมี่	sm2
ลักษะ	l>g-sa	เยื่อ	yq	พาก	?*g
นพปฎล	n?&,dl	หนาย	hn*y	หัง	h>}
ลันเต	l>nfl	มลก	mlwg	ยุด	yed
สังขต	s>}k	มลัก	ml>g	ยุด	yc
มือสี	m5os2	ทำงน	)z}n	รุม	r3m
ลัพท์	l>?0)0	มล้ำ	ml4*	พาง	?*}
ลัพท์	l>?0)b	มลาก	ml*g	เคห	fuh
ลักข์	l>,?y0	กรุก	grcg	กรบ	grv
ลัษคต	l>yu	มลาน	ml*n	ตวน	wn
ลากษา	l*g-s*	มลว	ml*w	ภาม	,?*m
มุขลค	mckld	มลิน	mlbn	เลพ	fl?
ลางที	l*})2	อาห	o*hr	ตว	ww
คุณดม	uc,ndm	โป๊ป	i&7&	ดุม	cm
ลางด	l*}*d	หนี่	hn29	โอ	io7
เด็ค	d%4g	จมรี	jmr2	พาด	?*
เด็ค	d%9d	อ้านด	oznd	พาท	?*)

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เด็ด	d%4d	มสาร	ms*r	ยุพ	yc?
อัครา	o>d0)*	เจ็ด	j%d	เทก	f)g
เดิน	d%9n	มหัส	mh>l	คอส	uos
เดิน	d%4n	เงิน	j%n	เรข	frk
มุกิน	mc)bn	เด้า	d69	พาธ	?*0)
อัครา	o>)0)*	จรวน	jrvn	แบ้	<v4
นิทาน	nb)*,u	ซงค้ำ	!}dz	พาน	?*n
ลาพูช	l*?c+	โปสก	i&sg	สุน	sc,n
ลาพา	l*?6	ติดถ	b t	เลศ	fls
นิธาน	nb0)*n	ตีป่า	b&*	เลห	flh
อันตร	o>n r	ทำไม	)z:l m	สยง	sy}
นินนะ	nbna	สภาค	s,*u	สยด	syd
มูธา	mcr0)*	จรรม	jrrm	เทค	f)u
มุลุด	mc c	ติมิ	bmb	มุน	mcn
พระหา	?rah*	หม่อ	hm9o	กลศ	gl,s
อันเต	o>n f	ไขไฟ	:ly:?	สยา	sy*
คุณถม	uc,ntm	ซ้วย	l4wy	พาม	?*m
อันทุ	o>n)c	ติลก	blg	ยู่	y39
มูหุด	mchc	ครูด	ur3d	ยู่	y34
อันวย	o>nwy	เลกี	flg2	สรก	srg
มูธา	m3r0)*	ไปถ้	:&l9	สรณ	sr,n
มูรัค	m3r>u	จรวจ	jrwj	สรบ	srv
เค้ม	d%9m	จรอก	jrog	เคะ	ufa
เค้ม	d%4m	ซอแซ	!o<!	สรพ	sr?
นวลภูถ	nw&,dl	สภาว	s,*w	มุส	mcs
นวลฐู	nw?0)3	เล็น	fl'n	เคา	u6
ลาหู่	l*h39	หมอย	hmoy	สรม	srm
เค็ย	d(4	ผณิน	p,nbn	โออร	ior
เค็ยง	d{}	จราส	jr*s	คระ	ura
ล่ำซำ	l9z!z	เล็ย	fl9y	ศลก	,sl,?

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เด็ด	d(d	หม่า	hm9*	ศวา	,sw*
ลำเทง	lzf}	หม่า	hm4*	เทท	f))
สั้นถว	s>ntw	ทิพย	)b?y	ศศะ	,s,sa
ซ้ำใจ	+9z:l j	แจตร	<jr	เทน	f)n
คุณฐ	uc,n0)3	เล็ว	fl'w	ศศิ	,s,sb
ชำนาญ	+znrr	เลว	flw}	ตู้	37
นวาระ	nw*ra	เขดา	fkd*	ขร-	kr-
เคื่อ	dq9	เล็	fls0	ศศิ	,s,s2
นหาดก	nh*dg	คลวง	ulw}	ศศา	,ss*
นหารุ	nh*rc	กล้อ	ul4o	ณัฐ	,n>,t
ลำพัน	lz?>n	อิกอ	obgo	พาส	?*s
นพการ	n,lg*r	ทิพา	)b?*	ทฤณ	)r1,u
คุณน	uc,nnn	เลหะ	flha	พาท	?*h
สัปปิ	s>&&b	จริม	jrbm	ณิก	,nbg
สัมมนา	s>mn*	แจรก	<jrg	ศีต	p2
แดงงา	<dg}*	แจรง	<jr}	ศุก	sc,?
ลิกขา	lbgk*	อิชท	ob+)	นฤป	nr1&
การจร	g*rjr	ตีระ	2ra	ชอย	+oy
อัสดม	o>sdm	แบ้ง	<v4}	เต้	f 9
ปสันน	&s>nn	นิกร	nbgr	นวก	nwg
ปสัยห	&s>yh	หนี่	hn24	โชค	i+d
กล้าย	gl4*y	จริว	jrbw	เตง	f }
ปหังส	&h>}s	ทิวส	)bws	ขล-	kl-
คุณนุ	uc,nnc	l"ll	l"ll	ขลป	klv
มูลฟู	m3l\$3	นิกห	nbuh	จาบ	j*v
สัยน์	s>yn0	พรศุ	prsc	ศาน	,s*,n
การเต	g*rfl	หมื่น	hm5n	ศาด	,s*
คุณบท	uc,nv)	ก้อม	g4om	ขลม	klm
สาภิข	s*gby	โจรา	ijr*	ปฎิ	&>,
นิษฐา	nb-s,t*	โจละ	ijla	ศุข	scy

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
นิยาม	nb-s*)	ทิ้ง	)24}	สุร	scr
ปอทม.	&o)m.	รชนิ	r+nb	ศاپ	,s*&
นิสาท	nbs*)	รชนิ	r+n2	กาศ	g*,s
ปอพาน	&o?*n	โกญจ	ig,yj	ผู้	pc4
ปอมท.	&om).	ก้อย	g'oy	ผูก	pcg
ถะกัถ	tag>d	ผลิก	plbg	โบน	ivn
ถะโกน	taign	มหิป	mhb&	ไอน	:on
ปะกัถ	&ag>}	ผลิน	plbn	กุศ	gcs
ถะถับ	tat>v	มหิช	mhb-s	ขลา	kl*
คุณปก	uc,n&g	รดยา	rty*	แลง	<l}
อาจมน	o*jmn	ผลือ	pl5o	กัถ	u>}
ถึพหา	l2,lh*	รบายู	rv*,y	โซพ	i+?
ถัมกั	t>m,?0	กอรี	gor2	แลบ	<l v
จัตุร	j> cr	โดมร	idmr	จึร	k2r
นอนนก	nonng	และ	flfa	แลป	<l&
ปะบุก	&avcg	แล่ง	<l9}	ตอย	oy
ปะป็น	&a&9n	จ้อง	j9o}	จั่ง	j9}
กลัถ	glb9}	ม่อน	m9on	จั่ง	j8}
ปะโยค	&aiyu	อิคู	obl3	หาด	h*d
เมนกา	fmng*	สมมต	smm	บเอ	vfo
น็อง	n59o}	ซัน	!>4n	แค้	<u4
โดอาส	ido*s	กรูณ	grc,n	เทด	f l
สามสบ	s*msv	ม็อม	m'om	ขว-	kw-
นุซอส	n3=os	โดรณ	idr,n	ขวง	kw}
กลัถ	glb4m	หยอน	hyon	ห่าน	h*n
คุ่นๆ	lc9n1	สมรด	smerd	เทว	f)w
ลุฟตี	lc\$ 2	หยัก	hy>g	สุว	scw
จึตัน	+2 4n	หยั่ง	hy>}	ไซ	:+9
เมาริ	m6ir	และะ	l<aa	ญู	g3,
นนะจึต	na,ybs	หยัด	hy>d	นพป	n,l&

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ดูลาย	lcl*y	แล้ว	<le	น้อ	n4o
กลิ้ง	gl{4}	หยัน	hy>n	ไซย	:+y
นักตะ	n>gla	หยับ	hy>v	กูด	g3d
เมียร	m(r	ผอวด	powd	ครำ	urz
เมื่อ	fm29o	ผอุน	po3n	ต๊ะ	la7
เนเมธ	fnfm0)	หยาง	hy*}	น้ำ	n9z
ปัญญา	&>,yjg	พลวก	?lwg	จี้	k{4
เนยทา	fn-s*)	หยาน	hy*n	เมก	fmg
ถ้ำชา	t4z+*	ที่รฆ	)2r,u	ฮอก	=og
อามลก	o*mlg	หยาว	hy*w	ทศม	),sm
สารทา	s*r)*	คุ่มพ	cm?	ฮอง	=o}
คุณพี	uc,n?2	หยุง	hyc}	ก้ำ	g9z
อาชาน	o*y*n	หยุน	hycn	เกา	,?6
อายุธ	o*yc0)	หยุย	hycy	ฮอบ	=ov
อายุร	o*ycr	หรรบๆ	hrv1	ทศา	),s*
อายุษ	o*yc-s	จ้อม	j9om	ปัว	&e
บัตนี	&> n2	หรับ	hr>v	หาส	h*s
นังธร	n>}0)r	นียด	nby	ทศา	)s*
สารูป	s*r3&	เขตร	fk r	เฟน	fpn
ซุนดู	+cnd3	โกรง	igr}	ม.ค	m.u
นันทา	n>n *	หรรน	hrcn	ทอก	)og
อวาท	o*w*h	ชาคา	!*u*	บัก	v>,
อวุด	o*wc	โกรด	igrd	ฮัท	=>)
นันทิ	n>n)b	ช่าง	!9*}	ฮัพ	=>\$
นันทา	n>nl*	หฤทย	hr1)y	โลล	ill
เลขผา	flkp*	กรูม	gr3m	โลห	ilh
เลขยะ	flkya	กลอบ	ulov	ฮาม	=*m
อาชาม	o*-s*-)	กะชะ	ga+a	ชุก	!9g
ขมหิน	kmhbn	นึรา	nbr*	ช้น	!4n
คุณยู	uc,nyc	ไลโป	:li&	ช่ม	!9m

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
คุณรจ	uc,nrj	โกรม	igrm	ชม.	!m.
กาวาง	g*w*}	จ้อย	j9oy	ฮาว	=*w
เลททุ	fl,)},c	รศนา	r,sn*	und	und
เลณทุ	fl,n,)},c	กะดง	gad}	โยด	iyd
เลดงา	fld}*	อุกห	ocuh	โยด	iy
อาสูร	o*s3r	ทุกข	)cgk	โยธ	iy0)
เลคัม	fld>m	อุณห	oc,nh	พิร	?br
กระดะ	gradc	จอแสด	jo<s	ปฎูล	&,dl
ถูลดะ	tclla	โกลง	igl}	วจน	wk/
เลนจง	flnj}	ไจ้จ	:j4l	จัน	j4n
กาสาว	g*s*w	ทุกฎ	)cg,	แดส	<ds
เลปกร	fl&gr	โกลฟ	igl\$	โยส	iys
นาคจู	n*uj3	ทุกร	)cgr	ไต้	id4
เลยย	flyyy	สมิป	sm2&	กลา	gl*
เลขญ	fl-s, c	สมිර	sm2r	หุก	h3g
ขยัน	ky>4n	ฝ้าย	p9*y	มกร	mgr
ซุมซม	+cm+m	ฝ้าย	p4*y	ไย	:y9
เล็ก	l%9g	คล้า	ul4*	มกส	mgs
เล็ก	l%9d	คลาก	ul*g	วงศ	w},s
เล็ก	l%9,s	คลาด	ul*u	สูธ	=30)
คุณศก	uc,n,sg	ฟ้าว	p9*w	เฮก	f=g
แถมพก	<tm?g	มะฮ	ma=0	ซอน	!on
ป้านง	&4*n}	ผิดก	pbdg	เทห	f)h
เมื่อบ	mqv	ฉมัน	/m>n	เฮด	f=d
เลียม	l(m	ร้อย	r9oy	ขอก	kog
ป้านนุ	&*nnc	หลาบ	hl*v	จับ	j4v
บงบอก	v}vog	วยาม	wy*m	เมศ	fm,s
เลียว	l(w	มังส	m>}s	เมษ	fm-s
เลือก	fl2og	สร้าง	sr9}	คัว	ue
ขวยใจ	kwy:lj	นืด	n24d	นอม	nom

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ก้านัด	gzn>d	สรวบ	srvv	เมห	fmh
ทกล้ำ	)gl4*	นาโง	n*i}	เมอ	m%
ทอดอย	)dtoy	สรฎ	sr,?3	คีว	,sbw
ชูเซ่	+3f!9	นีน	n24n	ค้ำ	u7*
ชูร่า	+3r9*	ชำชะ	!z=a	กุน	g3n
ชูว์	+34w0	ปลพี	&t?2	กูป	g3v
ทยาลู	)y*lc	ฉลาย	/!*y	คนย	dny
กระใด	gra:ld	สรตน	srln	แกด	<gl
ข้วน	kw>4n	สรตม	srlm	วจน	wjn
บรทาร	vr)*r	ฉล็ก	/!2g	วจา	wj*
จามปา	j*m&*	นาฎก	n*,lg	โดล	idl
ขว้าว	kw4*w	วรุถ	wr3t	ปารู	&*,t
ทรทึง	)r){}	พอดา	?o *	วชะ	w+a
ทรธิก	)r0){g	วฤษภ	wr1-s,?	ปาน	&*,n
จาร์.	j9*r.	วฤษด	wr1-sl	ได้	:ld4
โลงอก	il}og	นาฎย	n*,ly	วฤษะ	w, a
ปิงคด	&b}ul	วสลิ	wsl2	ไค้	:d9
ปิจดี	&bjd2	หวั	hwe	วตธ	w 0)
ทรสาย	)rs*y	มัธย	m>0)y	จรก	jrg
ทรสุม	)rscm	พ้อม	?4om	สุน	,scn
โลลูป	illc&	สริต	srbl	วธก	w0)g
ทรหวด	)rhwl	สรีร	sr2r	มตก	m g
ทรหึง	)rh){}	นัว	n54w	สุภ	,sc,?
ทรเหล	)rfhl	จะไร	ja:r	มตะ	m a
โลห้ซ	ilh>+	หวม	hwcm	ปณต	&,n
นางทิ	n*})b	ทุน	)cm	บ้ำ	v7*
ไลโซล	:li!l	อูว์	o3w0	วนา	wn*
ทรอึง	)ro){}	สลวน	slwn	พีท	?2)
ขอแกว	ko<gw	คลึง	ulb}	มรุ	m0)c
ทรพย	)r>?y	คลิด	ulbd	วยง	wy}



ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ไลปิด	:l&bd	ปรวด	&rwd	แกว	<gw
ลำบอก	szvog	เอกม	fogm	ป็น	&'n
จ้อ.	j9*o.	เอกส	fogs	วรท	wr)
พ้อธร	?9o0)r	มัลก	m>lg	เก้	fg9
เข็ง	+%9}	ทุษฐ	)c-s,t	มนท	mn)
เข็ง	+%4}	กล่น	gl9n	เพ	fp
จ่างย	jz}*y	เน่ง	fn9}	อช	ok
จ่าทับ	jz)>v	ระมา	ram*	นช	ny
แม-มี้	<m-m4	กลบท	glv)	ภว	,?w
แมร์ก	<mr0g	กั้ง	g4}}	อฆ	o,u
แมร์จ	<m9rj	กะทำ	ga z	ลธ	lo
กำหนก	gzhng	ฉันท	/>n)	นร	nr
เข็ด	+%9d	ม้าน	m>*n	วช	wk
บราลี	vr* 2	ทุษก	)3-sg	วู	w3
อีคว	o2uwb	คุ่น	uc9n	าล	al
ทฤษฏี	)r1-s,d>	เขลง	fk }	ชค	+u
วภูมะ	w, cma	กล่ม	gl9m	หท	hh
วทุฒน	w,)-)n	เขละ	fk a	แซ	<!
พลอิ่ง	)lo{ }	พะอง	?ao}	สว	,sw
จ่าบ่ม	jzv9m	ระลง	ral}	ปบ	&v
เข็ด	+%9l	เขชม	fk-sm	บช	vy
เข็ย	+(4	มาแก	m*<g	สผ	sp
วนจรก	wnjrg	พักร	?>gr	สศ	,s,s
จ่าบับ	jzv>v	น่าย	n9*y	อย	oy
ป็นยา	&5ny*	กลมก	glm,?	ชช	++
คดรวย	udrwy	ฉาทน	/*)n	ตะ	a
บริรม	vrbrm	มาจา	m*j*	ผอ	po
จ่ายาม	jzy*m	คลุป	ulcv	ศห	,sh
จ่าราญ	jzr*,y	ไกรพ	:gr?	f.	f.
พัญจก	?>,yjg	กชกร	g+gr	มค	mu

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
อุจจุ	ocj/c	เที่ยง	f)4}	หย	hy
เชื่อม	+qm	สวยม	swym	มจน	m,u
วังษา	w>}+*	มาดา	m*d*	ปร	&r
กระทด	gra)d	กดละ	glla	ศส	,s=
สือดี	s5od2	เพ็ด	f)4d	มง	m}
วิญจก	w>,yjg	กสี่ว	gl4w	กข	gk
คุดชู	ucd!3	เอฟ)	fo\$)	เซ	f+
คุปติ	uc& b	มาตร	m* r	กค	gu
โซโหว	i+ihw	คยห	ucyh	เล	fl
ขะแถก	ka<!g	เนาะ	noa	ชท	+)
ตักโต	7gi	มาตฤ	m* r1	คี	u2
เปรอง	&r%}	มาดา	m* *	นฤ	nr1
ครวัก	urw>g	สว่า	sw9*	พด	?d
กว้าง	gw9*}	เผื่อ	pq	บษ	v-s
ตกว่า	gw9*	ฉินท	/bn)	มจ	mj
ดกหมก	ghmg	หั้น	h>4n	โม	im
พ่าห์	?9*h0	ควอช	uwo+	กม	gm
ต่งุ่น	}c9n	ม้าน	m4*n	ดิ	di
คูเบค	u3fvu	กะปู้	ga&3	ริ	rb
ตจสาร	js*r	นึ่งขง	/2y}	คย	uy
พ่าพวก	?z?wg	มานี้	m*n2	พะ	pa
พิกโต	?bgi	ควาก	uw*g	คร	ur
พีกัล	?bg7l	มาปก	m*&g	พ่า	?z
นางสุ	n*}sc	มาภา	m*,?*	สฬ	sh
ยมท.)	ym).)	ม้าย	m4*y	แพ	<p
ยรรยง	yrry}	กสือ	gl4o	ลิ	lb
ขวกสา	ywgs*	ขจอก	kjog	ทส	)s
ชลาโว	!l*iw	รัชด	r>+d	วจ	wj
ต้นกล	4ngl	แต้ว	< 4w	ไก	:g
ย้องๆ	y4o}l	เฉลว	f/lw	กจ	gj

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
บดกพ	vr1}u?	ขจาว	kj*w	ถด	td
เป็ศัศ	f&,s>s	ขจย	kjcy	ถน	tn
พิตรก	?bdrq	ชี้อ	!2:o	ล๑	l;2
พิดาน	?bd*n	ขเจา	kj6	วณ	w,n
พิโดร	?bidr	ขณะเ	k,naf	กณ	u,n
เป็สูญ	f&sc,y	โต่ง	i 9}	ช๑	+a
คระหน	urahn	มารค	m*ru	วต	w
กินดา	gbn *	ค.ปง	.&}	ระ	ra
ทะนุก	)ancg	แน่ว	<n9w	อช	o+
วัทน	w>)n0	โตฏก	i ,dg	วธ	w0)
วัที่	w>)29	ขตอย	k oy	เม	fm
วันทน	w>n)n	เทวอ	f wo	ทก	)g
วันทย	w>n)y	โผอน	ipon	มต	m
วันท	w>n)b	มาระ	m*ra	แระ	<r
สุหฤท	schr1)	มารู	m*r3	มท	m)
สุหลง	sch }	กี้ดี	g'd4	ทต	)d
สุหัท	sch>)	ส่อน	s9on	ทท	))
สุโหลง	sc:h}	กะแม	ga<m	เก	fu
สุกษม	s3g-sm	กะยุ	gayc	ยู	y3
วันฟู	w>n\$3	กคชา	gd+*	ทน	)n
ทะลอก	)alog	มาถ่า	m*lz	ตจ	j
ยันตร	y>n r	มาถ	m*fl	พ	?c
จันแส	j2n<s	โนว	inw0	ไม	:m
กวาน	gw9*n	พานร	?*nr	สก	=g
วัปะ	w>&&a	มาสก	m*sg	ดี	{
คั้ง	4n>}	เค็ง	fu4}	สง	=}
บอนนา	vonn*	เกจณ	fuj/	สด	=d
เป็ดส	&%ds	มาห	m*h0	เท	fh
วัรว	wer0	ไตบา	: v*	ท	)c
ยัยฎ	y>-s, b	ขนอง	kno}	ชง	!}

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เสฐฐี	fs, ,t2	แฉละ	</la	พะ	?a
เฮ้าฟ	o67\$	มาพก	m*,lg	นพ	n,l
ก้วัว	gw4*w	คหัฐ	uh>,t	วก	w,?
วากรา	w*gr*	ขนาท	kn*g	ตต	
ขากส์	y*gs0	ขนาง	kn*}	ชู	!3
วางตา	w*} *	มิกา	mbu*	โศ	i,s
ยจนก	y*jng	มิตี	mbu2	ตท	)
ยจนา	y*jn*	มั้ง	mb4}	แต	<
ยไจน	y*:/n	เค้ป	fu4&	โร	ir
ยตนา	y* n*	หามะ	h*ma	ตล	l
วากล	w*j*1	ชคตี	+ud2	รณ	r,n
บอเลา	vol6	เทห์	f h0	บะ	va
บอวม	vow0m	มิญช	mb,y+	ฟู	\$c
กินนี	gbnn2	เคี้ย	fu4y	ชล	!l
ยานยา	y*ny*	มิดะ	mbda	ทพ	)?
บะด้ร	vad>r	กถัง	gl>}	รุ	rc
คยุดิ	yc b	ชुरอ	!3ro	เค	fd
เสริช	sr%+	กุกๆ	gcl	ษฐ	-s,t
เสริด	sr%d	ชฎิล	+,dbl	ษน	-sn
ทะเวณ	)afwn	หาวี	h*rb	ษม	-sm
กระทอ	gra o	เคย	fuy3	อน	on
ยายจี	y*yj2	มิตี	mb 2	โศ	is
เสวตร	fsw r	หาสก	h*sg	จิ	jb
พิหาร	?bh*r	พิขา	?bk*	ทม	)m
พิฟาร	?b,l*r	พั้ง	?b9}	ฐ	0)0
ตรมवल	rmwl	พิจย	?bjy	ตี	l2
วายิบ	w*ybv	ร้มก	r>mg	ดู	du
นาที	n*)29	พิจล	?bjl	นข	nk
ข้บชอ	k>v!o	แอลก	<olg	ทม	hm
ตรลอค	rlod	บงสุ	v}sc	รท	r)

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ตรลาด	rl*d	พิชย	?b+y	นค	nu
จับพล	k>v?l	หีรอ	hbro	สะ	sa
วาลธิ	w*10)b	หีตา	h2 *	ไค	:lu
เครีด	fur'd	หึ่งส	h{s	ทร	)r
เครีน	fur'n	โอโซ	ioi!	รพ	r?
นานก	n*fng	เขาอ	k6o	ขย	ky
ตระกล	ragl	รางๆ	r*}1	จึ	!b
ยายยู	y*yyc	กทลี	g)l2	จญ	j.y
วิกจะ	wbgja	ถงาด	t}*d	วล	wl
เคร่า	ur69	เผื่อ	xq	ป้า	&z
ยายวี	y*yw2	มีด	m24d	ผก	pg
ยายคี	y*y,sb	บโตน	vi)n	ปี	&b
วิกัย	wbg>y	พิฑู	?b0)c	ฐู	0)3
วิการ	wbg*r	มีนา	m2n*	วว	ww
พีธม	?290)m	ขบวร	kvwr	ทจ	0)j
เสียน	s(n	ขบูร	kv3r	ทช	0)+
ตระดก	radg	กล้า	gl9*	วษ	w-s
กินลี	gbnl2	กุนิ	gc,nb	ธน	0)n
ตระไน	ra:n	กุนี	gc,n2	ชุ	+c
ตระบก	ravg	โอษฐ	io-s,t	ขข	kk
ทังวล	)>}wl	กุดา	gcd*	ดร	dr
ชะอ็ด	!ao>d	ขมวน	kmwn	ขง	k}
โอทีส	io)2s	กนลา	gnl*	ชย	+y
โอไร	io4i0)	มีพห	m2,lh	ไส	:s
โปรโส	i&ris	วาบา	w*v*	สก	sg
วิจิน	wbjbn	เชื้อ	kq	อิ	=b
ย้ายาม	zyz*m	วามน	w*mn	วอ	wo
โอลอฟ	iolo\$	วามะ	w*ma	มร	mr
กระทุ	grac	มีด	m54d	อห	oh
ทัดทา	)>d)*	กุ่มก	gcm,?	ฉน	,un

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ยี่จู่	yb, ta	มีน	m59n	ฝ่า	pz
จุ่มที	jcm)2	มือ	m59o	ห้	h4
บัพชา	v>?+*	วาโย	w*iy	ฤณ	r1,n
ไปสาง	:&,s*j	วารณ	w*r,n	นง	n}
จุมพฏ	jcm?,	กะแอ	ga<o	หง	h}
ตริงค	r>}u	พิมพ	?bm?	ฤต	r1
ยิสต์	ybs 0	กลาด	gl*d	นฐ	n,t
บัลดพ	v>  ?	เขิล	!%l	นท	n)
จุมพล	jcm?l	ขยอง	kyo}	กี	g2
ซัลมา	!>lm*	ไอนุ	:onc	นน	nn
ทััพพะ	)>??a	กังก	g>}g	wo	wo
พื่อ	?29oo	ค้อย	u4oy	ถึ	t2
ชาญอด	!*yol	กบฑู	gv)3	นี	n2
ซ้าตา	!4* *	สตัย	s> y	นบ	nv
แสนิง	<snb}	มุขย	mcky	ลี้	l'
ผเคิน	pd%n	คอร้	uor0	ลก	lg
กระนง	grang	มุกร	mcur	ตวร	r
วิฑูร	wb)3r	ว่าา	w9**	มุ	mc
ยุกติ	ycglb	ขยาบ	ky*v	สภ	su
ชานน	!*fnn	สัตว	s> w	กน	gn
จูคัง	j3d>}	ร้าด	r7*d	วั	w>
จูคิท	j3db)	กुरร	gcrr	คท	h
พุงจง	?c}j}	ราตวร	r* r	สุ	sc
พุงคอ	?c}do	แซ้ง	< 4}	ปง	&}
จูเทศ	j3f),s	ราโท	r*i)	ฎิ	, b
กึ่งบ	g28}v	มูจน	mcjn	สท	sl
ซาเยด	!*fyd	มูญช	mc,y+	กท	uh
หงสรถ	h}srt	มูทค	mc)u	ฐุม	,tm
ผรุพก	prc?g	ตถตา	t *	ศข	,sk
ครูลพ	ur3!?	มูทา	mc)*	ศณ	,s/

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
หงอคง	h}od1	กบี่	gv29	ศช	,s+
ผลคูณ	plucn	มุก	mc)c	ศญ	,s,d
วิโชค	wbiyu	ตณญ	ng3	ศฐ	,s,t
หุ่ย	h}c9y	มุณี	mcnb	ศต	,s
หงข.,	hj+.,	ก้งส	g>}s	แย	<y
บางสุ	v*}sc	ไทกร	:)gr	แ-	<-
กระบา	grav*	สเลบ	=flv	ชู	k3
ตริงศ	r{}s	มุ่ม	mc9m	ดู	l3
เจตีย	fjd2y	มุ่ม	mc4m	บค	vu
ผลิ่ง	pl{9}	ชลวร	+lwr	บง	v}
ตฤตีย	r 2y	กโบร	givr	โ-	i-
วิวระ	wbwra	คอริ	uorb	กั	g4
บาเซด	v*fl	พิทค	?bhu	จู	j3
บาเซะ	v*!fa	กโบล	givl	ศม	,sm
หตุผล	h cpl	กปณก	g&,ng	ศย	,sy
วิวห	wbw*h	กปณา	g&,n*	สุ	p3
บาดรี	v*dr2	มูรช	mcr+	ลฐ	l,t
บาแดง	v*<d}	ขลิ่ง	kl4}	อป	o&
วิษณ	wb-s*,n	แซ่ว	<!9w	ยง	y}
วิศฤต	wbsr	มูกู	mc13	เต	f
กุกุน	gckcn	แจ่น	<k9n	บจ	vj
บาทรช	v*)r+	ขลวน	klwn	บฉ	v/
เจโทร	fji)r	มุสะ	mcsa	ศฐ	s,t
เขกยู	fy,?cy	ราแม	r*<m	สว	sw
ชิงเย	!b}fy	ขลาย	kl*y	ฟง	\$}
ชิงห์	!b}h0	แจนะ	<kna	ยม	ym
ผะออบ	paov	ขลิ่ง	kl{}	ฉง	/}
วิกลี	w2gl2	กปอ.	g&o.	บฎ	v,
เขวาน	y6wn	มุดอ	m3do	กึ	gc
เคลิ่น	ful'n	รายา	r*y*	แซ	<+

ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
เคลื่อน	ful4n	แกละ	<kla	สด	s
เคล้า	ul69	มูรธ	m3r0)	โฑ	i,)
ชินตา	!bn *	โซเซ	ifly	ยล	yl
เคลิก	ul%g	โซรม	!irm	ชว	+w
วีแวว	w2<ww	ราสี	r*s2	ยว	yw
รื้อน	r5on	ฮารี	=*r2	บต	v
กุกา	g3, *	ราหุ	r*hc	ลพ	l?
กั้น.	g>n.	คะได	ua:d	พข	?k
โหมะ	ihma	ฮาว	=*fw	ตุ	tc
รุกข	rcgk	คะนน	uann	ปุ	&c
ขวาด	kw*d	ตมูก	m3g	กศ	gs
ฐักัด	,tg>d	โซโห	i!ih	ภ7	,?#g
กูด	g34d	ดยาค	y*u	ยห	yh
ถั่ง	t>9}	กัณห	g>,nh	เน	fn
ขวาว	kw*w	ถนััน	tn>n	ภค	,?u
ขษณะ	k-s,na	ถนิม	tnbm	ถม	/m
ขษัย	k-s>y	สัสต	s>s	ทล	)l
ขษีร	k-s2r	ตริณี	r,n2	นภ	n,?
สามล	s*ml	ถลาก	tl*g	มู	m3
ถัทธ	t>)0)	คะมู	uam3	งะ	}a
กमार	gm*r	คะยา	uay*	ถบ	tv
รุจา	rcj*	ตรบป	rlv	ภฐ	,?,t
ขสมก	ksmg	ธตริฐ	0) r,t	ภต	,?
กมุท	gmc)	ตริลา	rl*	ดล	dl
ชชะชะ	+a+a	จากร	j*gr	ภภ	,?,?
ช้อก	k4og	วินย	wbny	ม่	m9
พื่น	?59n	กัคน	u>un	ด้	d4
ครับ	r>v	เคอย	u%y	บธ	v0)
ธนุร	0)ncr	ส้าง	s4*}	ภย	,?y
ไหม่	:hm9	ริปุ	rb&c	ภร	,?r



ตารางที่ 9 รายการคำภาษาไทยกับคำอักษรเบรลล์ภาษาไทยที่โปรแกรม SWATH ตัดคำผิดพลาด (ต่อ)

ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
รุ่ม	rc9m	ริปู	rb&3	ถล	tl
พื่อ	?59o	ตรวจ	rwd	วิ	wb
ส้าย	s4*y	ตรวจ	rwy	รู้	r9
รุรุ	rcrc	แหวน	<hnw	พจ	?j
ไให้ว	:h4w	ตรอน	ron	บบ	vv
รุหะ	rcha	แหระ	hr<a	บพ	v?
จั่งส	,)>}s	มื่อ	,+'o}		
คั่นถ	u>nt	ถ่อน	t9on		

ตารางที่ 10 รายการคำของคลังข้อความ BEST เขียนผิดพลาด

คลังข้อความ BEST เขียนผิด		ที่ถูกต้องควรเป็น	
ภาษาไทย	เบรลล์ไทยระดับ 1	ภาษาไทย	เบรลล์ไทยระดับ 1
ทรงสี่เหลี่ยม	)r}s2hl(9m	ทรงสี่เหลี่ยม	)r}s29hl(9m
คดอบ	ulov	ครอบ	urov
กิ่งผ่าน	g{}p9*n	กิ่งผ่าน	g{9}p9*n
ไว้ใน	:lw4:ln	ไว้ใน	:w4:ln
สัญญาณ	s>,y,y*n	สัญญาณ	s>,y,y*,n
ไฟฟ้า	:\$4*	ไฟฟ้า	:\$S4*
ตรงที่	r})2	ตรงที่	r})29
พื้นที่	?59n)2	พื้นที่	?54n)29
เลือก	fl2og	เลือก	lqg
ก็พาน	g'?*n	ก็พาล	g'?*1
เจรจาพาที	fjrgj'?*)29	เจรจาพาที	fjrgj'?*)2
ไม่มี	:m9m29	ไม่มี	:m9m2
ก.	g.	ก็	g'
นาที่	n*)29	นาที่	n*)2
ผู้ชาย	pc4+*y	ผู้ชาย	p34+*y
แซ่	<!9	แซ่ด	<!9d
ที่มี	)2m2	ที่มี	)29m2
ก็	g4	ก็	g'
เมื่อ	fm29o	เมื่อ	mq9
ได้	:ld4	ได้	:d4
กิน	u54n	กิน	u5n
ดิดีที่	d2d2)29	ดิดีที่	d2d2)2
เหมือ	fhm5o	เหมื่อน	hmqn
มัน	m>*n	มัน	m>n
ก้า	g7*	กัับ	g>v
สังเคราะห์	s>}ur*ah0	สังเคราะห์	s>}uroah0
ตั่ง	4n>}	ตั้น	4n
สักที่	s>g)29	สักคนที่	s>gun)29
กือ	g7o	ก็	g'

ตารางที่ 10 รายการคำของคลังข้อความ BEST เขียนผิดพลาด (ต่อ)

คลังข้อความ BEST เขียนผิด		ที่ถูกต้องควรเป็น	
ห้องแล็บ	h4o}<l v	ห้องแล็ป	h4o}<l'&
ผู้	pc4	ผู้	p34
ประสมัย	&rasm>y	ประชุมสมัย	&ra+cmsm>y
ไป	:&7	ไป	:&
ลูกบาศร	l3gv* r	ลูกบาศก์	l3gv*,sg0
ชีวิตอยู่	+2wb y39	ชีวิตอยู่	+2wb oy39
ผ่าร้อน	p9*wr4on	ร้อนผ่า	r4onp9*w
ชอกช้ำกำทรวง	+og+z4gz9)rw}	ชอกช้ำระกำทรวง	+og+z4ragz)rw}
มากิน	m*g%n	มากัด	m*g%d
ไว้	:lw4	ไว้	:w4
น้ำมันก๊าส	nz4m>ng7*s	น้ำมันก๊าด	nz4m>ng7*d
อยู่	y39	อยู่	oy39
รักที่มี	r>g)2m2	รักที่มี	r>g)29m2
ขอมัน	kom>n	ของมัน	ko}m>n
รู้สี่สา	r34s2s*	รู้สี่กรู้สา	r34s{gr34s*
โทร	i)r	โทรศัพท์	i)r,s>?)0
มีดู	m2d3	มาดู	m*d3

ภาคผนวก ง : ตารางอักษรเบรลล์ประเภทต่างๆ

ตารางที่ 11 อักษรเบรลล์ภาษาไทยแบบ 6 จุด

ก	ข	ฃ	ค	ค	ฅ	ง	จ	ฉ
G	K	Ok	U	-u	,u	]	J	/
ช	ซ	ฅ	ญ	ฎ	ฎ	ฐ	ฑ	ฒ
+	!	,+	,y	,d	,	,t	,)	-)
ณ	ด	ต	ถ	ท	ธ	น	บ	ป
,n	D		T	)	0)	N	V	&
พ	ฝ	พ	ฟ	ภ	ม	ย	ร	ล
P	X	?	\$	,?	M	Y	R	L
ว	ศ	ษ	ส	ห	ฬ	อ	ฮ	
W	,s	-s	S	H	,l	O	=	
อะ	อา	อิ	อี	อึ	อึ	อุ	อู	
A	*	B	2	[	5	C	3	
เอะ	เอ	แอะ	แอ	โอะ	โ	เออะ	ออ	
Fa	f	<t	<	ia	i	Oa	O	
เออะ	เออ	เอ็อะ	เอ็ย	เอ็อะ	เอ็อ	อัวะ	อัว	
%a	%	(a	(	Qa	Q	Ea	E	
อำ	ไอ	ไอ	เอา	ฤ	ฤ	ฤา	ฤา	
Z	:	:1	6	R1	L1	R1*	L1*	
อ๋	อ๊	อึ	อ้	อ๋	อ๋	๑		
9	4	7	8	>	0	1		



## ประวัติผู้เขียน

ชื่อ สกุล นายทศวัฒน์ ชุณหวิทยะธีระ  
 รหัสประจำตัวนักศึกษา 5010120025  
 วุฒิการศึกษา

วุฒิ	ชื่อสถาบัน	ปีที่สำเร็จการศึกษา
วิศวกรรมศาสตรบัณฑิต (วิศวกรรมคอมพิวเตอร์)	มหาวิทยาลัยสงขลานครินทร์	2550

## ทุนการศึกษา (ที่ได้รับในระหว่างการศึกษา)

ทุนผู้ช่วยสอน ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัย-  
สงขลานครินทร์

## การตีพิมพ์เผยแพร่ผลงาน

ทศวัฒน์ ชุณหวิทยะธีระ และ ผศ.ดร. พิชญ์ ดันฑัยย์, “การใช้เอ็นแกรมช่วยในการ  
ตัดสินใจแปลอักษรเบรลล์ที่ใช้คำควบกล้ำ สระประสม และอักษรเบรลล์สองเซลล์,” ใน  
การประชุมวิชาการเสนอผลงานวิจัย มหาวิทยาลัยพายัพ พ.ศ. 2555, เชียงใหม่, ประเทศไทย  
, 17 กุมภาพันธ์ 2555, รางวัลผลงานวิจัยดีเด่น (Best Paper Award) กลุ่มสาขาวิทยาศาสตร์  
เทคโนโลยี.