

บทที่ 4

ผลการวิจัยและอภิปรายผล

ในบทนี้จะอธิบายผลการวิจัยและอภิปรายผลที่ได้ดังมีรายละเอียดดังนี้

ผลการวิจัย

1. แบบจำลองที่เหมาะสมของระบบ BN-LVCSR

ผลลัพธ์จากการทดลองขั้นตอนการออกแบบโครงสร้างระบบ BN-LVCSR ในบทที่ 3 จะเป็นผลลัพธ์จากการทดลองที่ถูกต้องเป็นคำตอบของกรรุจ้าเสียงนั้น เป็นลำดับคำที่มีความน่าจะเป็นสูงสุดเมื่อนำมาหาเปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำ จะได้ผลดังนี้

ตารางที่ 4.1
ตารางเปรียบเทียบผลการทดลองในบทที่ 3

ชุดข้อมูล	LOTUS	BN	LOTUS + BN
จำนวนประโยค	20,984	9,115	30,099
จำนวนคำ	390,584	170,219	560,803
จำนวนคำศัพท์	5,412	7,123	9,602
%Correct	64.41%	68.64%	66.95%
%Accuracy	52.97 %	63.56%	61.02%

จากตารางที่ 4.1 จะเห็นว่าระบบต้นแบบมีเปอร์เซ็นต์ความถูกต้อง 64.41% เมื่อนำข้อมูลคลังข้อมูลข่าวภาษาไทย (BN Corpus) มาเพิ่มให้กับข้อมูล LOTUS Corpus จะทำให้เปอร์เซ็นต์ค่าความถูกต้องเพิ่มมากขึ้นเพียง 2.54% แต่เมื่อเปรียบเทียบกับการคลังข้อมูลข่าวภาษาไทยเพียงอย่างเดียวจะให้เปอร์เซ็นต์ค่าความถูกต้องเพิ่มขึ้น 4.23% เพราะข้อมูลของคลังข้อมูลข่าวภาษาไทยมีความใกล้เคียงกับชุดข้อมูลทดสอบ ดังนั้นเปอร์เซ็นต์ความถูกต้องที่ดีที่สุดจะเป็น 68.64% ซึ่งผลลัพธ์ที่ได้นี้ยังไม่เป็นที่น่าพอใจ เปอร์เซ็นต์ความถูกต้องควรจะมีค่ามากกว่า 70% ซึ่งผู้วิจัยจะทำการปรับปรุงระบบต่อไป

1.1 สมมติฐานที่ 1

ในการฝึกฝนแบบจำลองภาษา ผู้วิจัยคิดว่าถ้าทำการเพิ่มข้อมูลสำหรับการฝึกฝนแบบจำลองภาษาให้มากขึ้น จะทำให้ค่าสถิติต่างๆของแบบจำลองครบมากยิ่งขึ้นและระบบจะเรียนรู้คำศัพท์ได้มากขึ้น ซึ่งข้อมูลที่จะนำมาเพิ่มนั้นเป็นข้อมูลประเภทข่าว โดยนำมาจากแหล่งอื่น การที่เพิ่มข้อมูลประเภทข่าวนั้นเป็นเพราะโครงสร้างข้อมูลจะใกล้เคียงกับชุดข้อมูลการทดสอบซึ่งเป็นข้อมูลข่าว อาจจะทำให้ความถูกต้องในการทดสอบมากยิ่งขึ้น

การทดลองของสมมติฐานที่ 1

ข้อมูลข่าวที่นำมาเพิ่มนั้นเป็น คลังข้อมูลข่าวจากหนังสือพิมพ์ไทยรัฐ (Newspaper) ซึ่งได้ข้อมูลนี้เก็บรวบรวมมาจากเน็ตเวก ประกอบด้วย 699,606 ประโยค 10,853,503 คำ และ 70,855 คำศัพท์

สำหรับคลังข้อมูลข่าวภาษาไทย ที่ใช้ฝึกฝนแบบจำลองภาษาันนั้นจะนำเข้าคำที่ไม่มีคำอ่านอยู่ในพจนานุกรมเสียงอ่าน เช่น คำว่า [laugh] ซึ่งเป็นเสียงหัวเราะในข่าว โดยจะนำเข้าเฉพาะคำออกไป จะแทนคลังข้อมูลข่าวภาษาไทย ชุดนี้ว่า BN Full Corpus

ข้อมูลที่จะนำมาใช้ฝึกฝนแบบจำลองภาษาเพิ่มนั้นจะเปรียบเทียบข้อมูลที่แตกต่างกัน 3 แบบ ได้แก่

1. ข้อมูลของ BN Full Corpus ซึ่งประกอบด้วย 13,044 ประโยค 224,167 คำ 10,314 คำศัพท์ และคำศัพท์ของพจนานุกรมเสียงอ่าน จากคลังข้อมูลข่าวภาษาไทย 38,238 คำศัพท์ (แทนแบบจำลองนี้ด้วย LM1)
2. ข้อมูลของ BN Full Corpus กับ Newspaper ซึ่งประกอบด้วย 574,220 ประโยค 8,778,769 คำ 18,643 คำศัพท์ และคำศัพท์ของพจนานุกรมเสียงอ่านจากคลังข้อมูลข่าวภาษาไทย 38,238 คำศัพท์ (แทนแบบจำลองนี้ด้วย LM2)
3. ข้อมูลของ BN Full Corpus กับ Newspaper ซึ่งประกอบด้วย 679,629 ประโยค 10,514,704 คำ 44,303 คำศัพท์ และคำศัพท์ของพจนานุกรมเสียงอ่านจากคลังข้อมูลข่าวภาษาไทย รวมกับ Newspaper 65,000 คำศัพท์ (แทนแบบจำลองนี้ด้วย LM3)

ผลการทดลองของสมมติฐานที่ 1

ผลลัพธ์จากการทดลองของสมมติฐานที่ 1 จะได้เปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำ ดังนี้

ตารางที่ 4.2

ตารางเปรียบเทียบผลการทดลองของสมมติฐานที่ 1

ชุดข้อมูล	LM1	LM2	LM3
จำนวนประโยชน์	13,044	574,220	679,629
จำนวนคำ	224,167	8,778,769	10,514,704
จำนวนคำศัพท์	10,314	18,643	44,303
จำนวนคำศัพท์ของพจนานุกรม	38,238	38,238	65,000
%Correct	67.80 %	66.53 %	64.83 %
%Accuracy	65.68 %	61.86 %	60.59 %

จากตารางที่ 4.2 แสดงให้เห็นว่าการเพิ่มข้อมูลข่าวที่ใช้ฝึกฝนแบบจำลองภาษาไม่สามารถเพิ่มเปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำได้ สาเหตุเป็นเพราะเมื่อฝึกฝนแบบจำลองภาษาให้รู้คำศัพท์มากขึ้น ทำให้ส่วนของการถอดรหัสคำถูกเกิดทางเลือกของความน่าจะเป็นที่จะเกิดของคำมากขึ้น เมื่อทางเลือกมีมากขึ้นก็จะทำให้เกิดความผิดพลาดมากขึ้น และเนื่องจากชุดข้อมูลการทดลองบนนี้เป็นคำหรือกลุ่มคำสั้นๆ จึงไม่ได้ประโยชน์จากการแบบจำลองภาษามากนัก

จากผลการทดลองของสมมติฐานที่ 1 แสดงให้เห็นว่าการเพิ่มข้อมูลข่าวที่ใช้ในการฝึกฝนแบบจำลองภาษาและคำศัพท์ในพจนานุกรมเสียงอ่านไม่ช่วยเพิ่มเปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำขึ้นได้

1.2 สมมติฐานที่ 2

นำแบบจำลองจากบทที่ 3 มาใช้ในการปรับปุ่ง คือข้อมูลของคลังข้อมูลข่าว 9,115 ประโยค 170,219 คำ 7,123 คำศัพท์ และคำศัพท์ของพจนานุกรมเสียงอ่าน 9,842 คำ จะทำการปรับปุ่งโดยลดคำศัพท์ในพจนานุกรมเสียงอ่าน

การทดลองของสมมติฐานที่ 2

จากการที่ผู้วิจัยได้สังเกตผลลัพธ์ที่ได้จากการทดสอบหัวสนับน้ำคำที่ได้มานั้นมักจะเป็นคำสั้นๆ ที่ไม่มีความหมาย ไม่น่าจะเป็นคำสำคัญได้ โดยความน่าจะเป็นของการที่จะเกิดคำสั้นๆ เหล่านั้นมีมากกว่าคำสำคัญ ดังนั้นผู้วิจัยจึงลองลดคำศัพท์ในพจนานุกรมเสียงอ่าน โดยคำที่เข้าออกจากพจนานุกรมเสียงอ่านนี้จะเป็นคำหยุด (Stop word list) ซึ่งก็คือ คำสั้นๆ ที่ไม่มีความหมาย ไม่น่าจะนำมาเป็นคำสำคัญได้ เช่น คำเชื่อมและคำบุพบทต่างๆ (การ, ความ, ก็, จึง ฯลฯ) คำหยุดที่จะตัดออกจากพจนานุกรมเสียงอ่านนั้นมี 125 คำศัพท์ ดังนั้นพจนานุกรมเสียงอ่านที่ใช้ในการทดสอบหัวสรุปมีคำศัพท์ 9,717 คำ

ข้อมูลที่จะนำมาใช้ฝึกฝนแบบจำลองภาษาของสมมติฐานที่ 2 คือ ข้อมูลของคลังข้อมูลข่าวภาษาไทยซึ่งประกอบด้วย 9,115 ประโยค 170,219 คำ 7,123 คำศัพท์ และคำศัพท์ของพจนานุกรมเสียงอ่าน 9,717 คำ

ผลการทดลองของสมมติฐานที่ 2

การทดลองจากสมมติฐานที่ 2 แบบจำลองที่ปรับปุ่งโดยลดคำศัพท์ในพจนานุกรมเสียงอ่านแล้วจะได้ค่าเบอร์เซ็นต์ความถูกต้องเท่ากับ 78.32% และเบอร์เซ็นต์ความแม่นยำเท่ากับ 74.34% ดังแสดงในตารางที่ 4.3

ตารางที่ 4.3
ตารางเปรียบเทียบผลการทดลองของสมมติฐานที่ 2

ชุดข้อมูล	แบบจำลองที่เหมาะสม
จำนวนประโยค	9,115
จำนวนคำ	170,219
จำนวนคำศัพท์	7,123
จำนวนคำศัพท์ของพจนานุกรม	9,717
%Correct	78.32 %
%Accuracy	74.34 %

ซึ่งค่า เปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำ 78.32%, 74.34% เป็นผลที่ผู้วิจัยยอมรับได้ดังนั้น จึงนำแบบจำลองนี้ซึ่งเป็นแบบจำลองที่ดีที่สุดนำไปใช้งานในการค้นหาคำสำคัญต่อไป

2. ขั้นตอนการค้นหาโดยใช้คำสำคัญ

โครงสร้างของลักษณะคำในภาษาไทยนั้น จะไม่มีการแยกคำ ทำให้วิธีการแยกคำเป็นสิ่งที่จำเป็น เพื่อช่วยในการค้นหาคำสำคัญ ใน การค้นหาคำสำคัญในภาษาไทยนั้นนอกจากต้องการการแยกคำแล้ว ยังต้องตัดคำหยุดออกไปก่อนที่จะค้นหาคำสำคัญด้วย ซึ่งในงานวิทยานิพนธ์นี้ ผลลัพธ์ที่ได้จากการถอดรหัสนั้นได้มีการตัดคำหยุดออกไปแล้ว ดังนั้นผลลัพธ์ที่ได้จากการถอดรหัสนั้นสามารถนำไปใช้สำหรับการค้นหาคำสำคัญได้เลย

เนื่องจากขั้นตอนจากระบบ BN-LVCRS นั้นไม่ได้ให้ความถูกต้อง 100% ดังนั้นการค้นหาคำสำคัญจะพบปัญหาว่า การค้นหาคำสำคัญทั้งคำนั้น ถ้าการถอดรหัสออกมาได้ถูกต้องทั้งคำจะสามารถค้นหาคำสำคัญและแสดงประโยคของมาได้ แต่ถ้าการถอดรหัสออกมาไม่ถูกต้องทุกคำ ผลลัพธ์จากการค้นหาอาจจะไม่แสดงประโยคใดออกมาก ทำให้ผลลัพธ์ที่ได้นั้นผิดพลาดได้ ดังนั้น การใช้คำสำคัญ 10 คำ จากวิธีการ N-best โดย N=10 ใน การค้นหายอมให้ผลลัพธ์ดีกว่าใช้คำสำคัญ 1 คำ และคำสำคัญทั้งคำนั้นอาจจะไม่ได้ถูกต้องทั้งหมด ดังนั้นการใช้คำสำคัญอย่าง (Sub Keyword) มาช่วยนั้นการค้นหาด้วยนั้น จะทำให้ประสิทธิภาพในการค้นหาข้อมูลเพิ่มมากขึ้น ซึ่งคำสำคัญอยู่นั้นได้มาจาก การแยกคำจากคำสำคัญ

ตารางที่ 4.4
ตัวอย่างของคำสำคัญและคำสำคัญที่ได้จากการ 10-best

คำสำคัญ	กระบวนการ พานิชย์	ประกาศ	ประกาศ ไฟ
1-best	กระบวนการ พานิชย์	ลักษณะ	ประกาศ ราย
2-best	กระบวนการ พานิชย์	รับทราบ	ประกาศ ร้าย
3-best	กระบวนการ ผ่าน	รับรอง	ประกาศ ไว้
4-best	ประท้วง พานิชย์	รั้ดเกล้า	ประกาศ ตาย
5-best	กระบวนการ ร้าน	ประกาศ	ร่างกาย ราย
6-best	กระบวนการ พันเอก	ปรับ ออก	ประกาศ ไว้
7-best	ครับ ผู้ พานิชย์	ปรับ แรก	ประกาศ นาย
8-best	กระบวนการ คน	กลับ แรก	ร่างกาย ร้าย
9-best	รับรู้ พานิชย์	ปรับ รอบ	ร่างกาย ไว้
10-best	กระบวนการ ค้าน	กลับ รอบ	ประกาศ ไว้

ตารางที่ 4.4 แสดงตัวอย่างของคำสำคัญและคำสำคัญที่ได้จากการ 10-best โดยคำว่า “กระบวนการ พานิชย์” จะพบได้ใน 1-best คำว่า “ประกาศ” จะพบได้ใน 5-best และคำว่า “ประกาศ ไฟ” จะไม่พบใน N-best ใด แต่จะมีคำว่า “ประกาศ” ซึ่งเป็นคำสำคัญอยู่ที่สูงต้องดังนั้นจะทำการพัฒนาแอพพลิเคชันตามโครงสร้างที่ได้ออกแบบไว้ เพื่อให้สะดวกต่อการใช้งานโดยระบบ BN-LVCRS จะได้ผลลัพธ์เป็น 10 คำสำคัญ ซึ่งในแต่ละคำสำคัญจะมีกุญแจของคำสำคัญอยู่ที่ได้มีการจัดลำดับความสำคัญโดยใช้ความถี่

ภาพที่ 4.3
ผลลัพธ์จากการค้นหาคำสำคัญว่า “ประกาย ไฟ”

The screenshot shows a web browser interface with the URL <http://localhost/index.php>. The main content area displays a table titled 'Your list:' under the heading 'Keyword: ประกาย ไฟ'. The table has two columns: 'Keyword' and 'Content'. The 'Content' column contains several lines of Thai text, each preceded by a small blue icon. The text includes various phrases related to light, such as 'แสงสว่าง', 'ไฟฟ้า', and 'ไฟฟ้า'.

Keyword	Content
ประกาย ไฟ	แสงสว่าง แสง ช่วง หน้า ว่า บันเทิง ตະ คลิป วิดีโอ ทำ บิ๊ก กับ ดารา อีก อย่างอื่น เป็น กะ ลุกนั่งท่องเที่ยว
ประกาย ไฟ	เมื่อ ไม่ หลุก ล่าสุด ก่อ เหตุ ว่า ตัด คลีป ที่ บีบคลาน เป็น ราย ที่ สอง ใน เดือน
ประกาย ไฟ	สอง รัง ประเพณี ว่า พระอาทิตย์ เหลือ สามอาทิตย์ ไม่ น้อย กว่า ส่อง ร่อง คน ดู ล่าสุด มาก ตาม ราย กาก
ประกาย ไฟ	ไฟ เด่น ฉะ ต้อง ชาวบ้าน ให้ ใจ ลืมหายใจ ลืมหายใจ ต้อง
ประกาย ไฟ	ฟ้า ประ缥缈 ให้ ลืมหายใจ นั่น เป็น ญี่ปุ่น สังออก คลอกไม้ ราย ใหญ่ เป็น อันดับ ส่อง วง คาก แมเมอร์เมดท์ เดย ดี ตะ
ประกาย ไฟ	ฟ้า เจ็บน้ำที่ ให้ มี การ ลัก ขับ ให้ แล้ว หนึ่ง ราย
ประกาย ไฟ	แสง บิบาก น้ำ ผ้า หมา ไป ใน ชีวี น้ำ ห่วง จาก ที่ ปลาย ไฟ ทำ สำเร็จ เสน่ห์ คง รัก รุ่มเรื่อง อนุพัฒ บันร่วง ต่อ ที่ ใจ หาย ให้ ดี กัน กลุ่ม นี้
ประกาย ไฟ	ล่าสุด หน้า ทุก ผู้คน มอง ศูนย์ เชือด ลึก อึก หัน หนึ่ง ราย
ประกาย ไฟ	สอง รัง ประเพณี ว่า พระอาทิตย์ เหลือ สามอาทิตย์ ไม่ น้อย กว่า ส่อง ร่อง คน ดู ล่าสุด มาก ตาม ราย กาก

จากภาพที่ 4.3 การค้นหาคำสำคัญว่า “ประกาย ไฟ” จะไม่พบในคำสำคัญทั้ง 10 คำ ดังนั้นจะใช้คำสำคัญย่อymาช่วยในการค้นหา โดยจัดลำดับความถี่ของคำสำคัญย่อymาตามคำสำคัญทั้ง 10 คำ จะแสดงดังตารางที่ 4.5

ตารางที่ 4.5

ตารางแสดงความถี่ของคำสำคัญย่อymาตามคำสำคัญว่า “ประกาย ไฟ” ทั้ง 10 คำ

คำสำคัญย่อyma	ความถี่
ประกาย	7
ร่างกาย	3
ไฟ	2
ร้าย	2
ราย	2
ไว	1
ใต้	1
หาย	1
ตาย	1

ภาพที่ 4.4
ผลลัพธ์จากการจัดลำดับตามความถี่ของคำสำคัญอย่าง

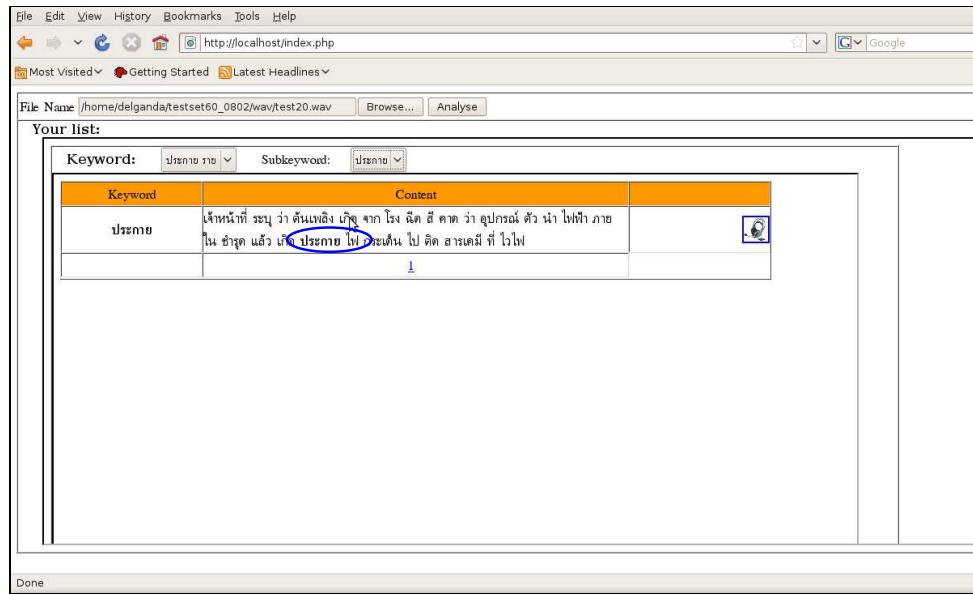
The screenshot shows a web browser window with the URL <http://localhost/index.php>. The page title is "Getting Started". The main content area is titled "Your list:" and contains a table with two columns: "Keyword" and "Content". The "Keyword" column lists various Thai phrases, and the "Content" column lists the frequency of each phrase. The most frequent phrase is "ประจำ ราย เดือน ใน หลัก ล่าสุด ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้" (Frequency: 10). Other entries include "ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้" (Frequency: 9), "ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้" (Frequency: 8), and so on.

Keyword	Content
ประจำ ราย เดือน ใน หลัก ล่าสุด ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	10
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	9
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	8
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	7
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	6
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	5
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	4
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	3
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	2
ประจำ ราย เดือน ที่ ให้ เก็บ ไว้ สำหรับ วัน นี้	1

คำสำคัญที่ต้องการค้นหาคือคำว่า “ประจำ ไฟ” ดังนั้นจะลองเลือกคำว่า “ประจำ” ซึ่งจะแสดงผลลัพธ์ดังนี้

ภาพที่ 4.5

ผลลัพธ์จากการเลือกคำสำคัญอย่างว่า “ประกาย”



Keyword	Content
ประกาย	เสียงน้ำที่สะบัดเมื่อตื้อจากในร่องน้ำ มีเสียงกระซิบกระซ่อน ดังเช่นเสียงกระซิบกระซ่อนที่มนต์เสน่ห์ต้องการฟัง
	1

ผลลัพธ์ที่ได้จากการเลือกคำสำคัญอย่างว่า “ประกาย” จะค้นหาข้อมูลประโยชน์ขึ้นมา มีคำว่า “ประกาย ไฟ” ซึ่งตรงกับสิ่งที่เราต้องการค้นหา

อภิปรายผลการทดลอง

จากผลการทดลองทั้งหมดที่ทำมาจะเห็นได้ว่าระบบของ BN-LVCSR แบบจำลองที่ดีที่สุดคือ แบบจำลองในสมมติฐานที่ 2 ได้เปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำ 78.32%, 74.34% ซึ่งให้ผลลัพธ์ที่ดีกว่างานวิจัยในด้านนี้ที่ผ่านมา ทั้งนี้เปอร์เซ็นต์ความถูกต้อง 78.32% อาจมาจาก การที่ใช้วิธี 10-best และการตัดคำหยุดออกจากพจนานุกรมเสียงอ่าน ซึ่งช่วยให้ความถูกต้องมากขึ้น การเพิ่มข้อมูลข่าวสำหรับการฝึกฝนแบบจำลองภาษาให้เรียนรู้คำศัพท์มากขึ้น ไม่ได้ช่วยให้เปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำเพิ่มขึ้น แต่ทำให้เปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำลดลงอีกด้วย เพราะเมื่อมีคำศัพท์มากขึ้นก็จะทำให้เกิดความผิดพลาดมากขึ้นด้วย ส่วน 22.68% ที่มีความผิดพลาดนั้นอาจจะเกิดจากชุดข้อมูลที่ใช้ในการทดสอบนั้นเป็นเพียงคำลีสันๆ และมีขนาดเล็ก ทำให้คำศัพท์ที่ใช้ในการทดสอบมีจำนวนน้อย ดังนั้นถ้าเพิ่มชุดข้อมูลทดสอบให้มีขนาดใหญ่ขึ้น คำศัพท์มากขึ้น และลักษณะการพูดให้เป็นประโยชน์ อาจจะทำให้มีเปอร์เซ็นต์ความถูกต้องและเปอร์เซ็นต์ความแม่นยำเพิ่มมากขึ้นได้

ในส่วนของการค้นหาคำสำคัญนั้น จะมีการใช้คำสำคัญอย่างมากซ่อนอยู่ในการค้นหาคำสำคัญเพื่อให้ตรงกับความต้องการของผู้ใช้มากที่สุด โดยคำสำคัญอยู่นั้นจะเรียงลำดับตามความถี่ของเกิดคำ ถ้าความถี่ของคำสำคัญอยู่มากอาจจะสันนิษฐานได้ว่าคำสำคัญที่ต้องการค้นหานั้น มีคำสำคัญอยู่ที่มีความถี่สูงสุดเป็นองค์ประกอบก็ได้ ดังนั้นการใช้คำสำคัญอย่างมากซ่อนอยู่ในการค้นหาคำสำคัญนั้นจะช่วยเพิ่มประสิทธิภาพในการค้นหามากยิ่งขึ้น