

Transliterated Word Encoding and Retrieval Algorithms for Thai-English Cross-Language Retrieval

Prayut Suwanvisat
Department of Computer Engineering
Chulalongkorn University
Bangkok, Thailand
g40psw@cp.eng.chula.ac.th

Somchai Prasitjutrakul
Department of Computer Engineering
Chulalongkorn University
Bangkok, Thailand
somchaip@chula.ac.th

Abstract: This paper presents transliterated word encoding and retrieval algorithms for Thai-English cross-language retrieval. The encoding is used for Thai-to-English transliterated words and their corresponding Thai words. The encoding algorithm transforms Thai words into a canonical form using romanization rules and transforms English characters to Thai using transliteration rules. The retrieval algorithm searches codes of the query words approximately with codes in the index using a dynamic programming technique. Experimental results showed that the system can achieve both precision and recall as high as 70% simultaneously.

Key words: Transliterated word encoding, Cross-language retrieval

ขั้นตอนวิธีการเข้ารหัสและการค้นคืนคำทับศัพท์ข้ามภาษาไทย-อังกฤษ

ประยูท สุวรรณวิสารท
ภาควิชาวิศวกรรมคอมพิวเตอร์
จุฬาลงกรณ์มหาวิทยาลัย
prayut@cp.eng.chula.ac.th

สมชาย ประสิทธิ์จูตระกูล
ภาควิชาวิศวกรรมคอมพิวเตอร์
จุฬาลงกรณ์มหาวิทยาลัย
somchaip@chula.ac.th

บทคัดย่อ: บทความนำเสนอขั้นตอนวิธีการเข้ารหัสคำทับศัพท์และการค้นคืนสำหรับระบบการค้นคืนข้ามภาษาไทย-อังกฤษ การเข้ารหัสคำนี้ใช้กับกรณีของคำอังกฤษที่ทับศัพท์คำไทย ซึ่งประกอบด้วยขั้นตอนการแปลงรูปคำไทยโดยอาศัยหลักการถ่ายเสียง และการแปลงตัวอักษรอังกฤษเป็นตัวอักษรไทยโดยอาศัยหลักการถอดอักษร ส่วนการค้นคืนนั้นอาศัยการเทียบรหัสคำของข้อความ กับรหัสคำในดัชนีแบบประมาณ โดยใช้เทคนิคกำหนดการพลวัต จากผลการทดลองพบว่าได้ค่าค่าเรียกคืนสูง และค่าแม่นยำประมาณ 70 เปอร์เซ็นต์

คำสำคัญ: การเข้ารหัสคำทับศัพท์, การค้นคืนข้ามภาษา

1. บทนำ

ระบบค้นคืนสารสนเทศเป็นเครื่องมือที่สำคัญอย่างยิ่งในการบริหารสารสนเทศที่มีอยู่จำนวนมากในรูปของสื่ออิเล็กทรอนิกส์ โดยเฉพาะสารสนเทศที่จัดเก็บในเวิร์ดไวด์เว็บและซีดีรอม เนื่องจากสื่อดังกล่าวสามารถจัดเก็บสารสนเทศได้เป็นจำนวนมาก และสามารถเข้าถึงได้ง่ายทั้งจากระยะใกล้และไกล โดยปกติแล้วการวัดประสิทธิผลของระบบค้นคืนสารสนเทศใด ๆ มักจะวัดจากค่าแม่นยำ (Precision) และ ค่าเรียกคืน (Recall) [1] ซึ่ง ค่าแม่นยำ หมายถึงการวัดความสามารถของระบบในการที่จะจัดเอกสารที่ไม่เกี่ยวข้องออกไป ค่าที่ได้จะเป็นอัตราส่วนระหว่างจำนวนของเอกสารที่เกี่ยวข้องที่คืนกลับมา กับจำนวนเอกสารทั้งหมดที่คืนกลับมา ส่วนค่าเรียกคืนหมายถึงการวัดความสามารถของระบบในการคืนเอกสารที่เกี่ยวข้องกลับมา ค่าที่ได้จะเป็นอัตราส่วนระหว่างจำนวนของเอกสารที่เกี่ยวข้องที่คืนกลับมา กับจำนวนทั้งหมดของเอกสารที่เกี่ยวข้อง

ในกรณีที่ผู้ใช้ป้อนคำหลักด้วยภาษาใดภาษาหนึ่ง ในขณะที่คำหลักในเอกสารจัดเก็บด้วยภาษาอื่น ตัวอย่างเช่น ผู้ใช้ต้องการสืบค้นคำว่า *สมชาย* แต่ระบบไม่ได้คืนเอกสารที่มีคำว่า *SOMCHAI* (คำทับศัพท์ที่ตรงกัน) ทำให้ค่าเรียกคืนของระบบค้นคืนสารสนเทศน้อยกว่าที่ควรจะเป็น ถ้าระบบดังกล่าวไม่สนับสนุนการทำงานแบบข้ามภาษา (cross-language retrieval) [2]

การค้นคืนสารสนเทศข้ามภาษา หมายถึงการค้นคืนสารสนเทศ โดยภาษาที่ใช้ในข้อความแตกต่างจากภาษาที่ใช้ในการจัดเก็บเอกสาร การใช้พจนานุกรมสองภาษา (Bilingual Dictionary) ในลักษณะของอรรถาภิธาน (Thesaurus) กับระบบค้นคืนสารสนเทศไม่สามารถแก้ไขปัญหาดังกล่าวได้มากนัก เนื่องจากคำทับศัพท์ส่วนมากมักเป็นคำเฉพาะที่ไม่ปรากฏในพจนานุกรม [3]

มีงานวิจัยต่าง ๆ ที่เกี่ยวข้องกับปัญหาการค้นคืนข้ามภาษาไทย-อังกฤษ คือ [4] ได้นำเสนอขั้นตอนวิธีสำหรับเข้ารหัสคำภาษาอังกฤษ ซึ่งรหัสคำที่ได้จะเป็นกลุ่มของเสียงอ่านที่เป็นไปได้ในภาษาไทย การเข้ารหัสจะอาศัยตารางการกำหนดรหัสและกฎ แต่ในงานวิจัยนั้นไม่ได้แสดงรายละเอียดของตารางการกำหนดรหัส และไม่ได้รายงานผลการทดลอง [5] ได้นำเสนอขั้นตอนวิธีการเข้ารหัสคำสำหรับคำไทยที่ทับศัพท์คำอังกฤษ โดยใช้เทคนิคการเข้ารหัสคำแบบชาวเด็เกซ์

งานวิจัยนี้จะนำเสนอขั้นตอนวิธีการการค้นคืนคำทับศัพท์ข้ามภาษาไทย-อังกฤษ ซึ่งคำทับศัพท์จะเป็นคำภาษาอังกฤษทับศัพท์คำภาษาไทย เช่น *BOONSERMSAP* ทับศัพท์ *บุญเสริมทรัพย์* เป็นต้น การเข้ารหัสประกอบด้วยขั้นตอนการแปลงรูปคำไทยซึ่งอาศัยหลักการถ่ายเสียง และใช้หลักการถอดอักษรเพื่อแปลงตัวอักษรอังกฤษเป็นตัวอักษรไทย จากนั้นนำรหัสคำที่ได้ไปเทียบอักษรแบบประมาณโดยอาศัยเทคนิคกำหนดการพลวัตกับรหัสคำในดัชนี โดยมีการกำหนดเกณฑ์การยอมรับในการเทียบสายอักษร บทความนี้จะนำเสนอขั้นตอนวิธีการเข้ารหัสคำอย่างละเอียดในหัวข้อที่สอง นำเสนอขั้นตอนการค้นคืนในหัวข้อที่สาม หัวข้อที่สี่เสนอวิธีการทดลองประสิทธิผลและผลการทดลอง จากนั้นสรุปเนื้อหาของบทความในหัวข้อที่ห้า

2. ขั้นตอนวิธีการเข้ารหัสคำ

การเข้ารหัสคำมีจุดประสงค์เพื่อแปลงคำไทย และคำอังกฤษที่ทับศัพท์คำไทย ให้อยู่ในรูปแบบรหัสคำรูปแบบเดียวกัน รหัสคำของคำเฉพาะทั้งคำไทย และคำอังกฤษที่ทับศัพท์คำไทยต่างๆในเอกสารจะถูกสร้างขึ้นในขั้นตอนการสร้างดัชนีในระบบการจัดเก็บสารสนเทศ เมื่อผู้ใช้ป้อนข้อความที่เป็นคำเฉพาะคำไทย หรือคำอังกฤษทับศัพท์คำไทย ระบบค้นคืนก็จะสร้างรหัสคำของคำต่างๆในข้อความ เพื่อใช้ค้นหากับรหัสคำที่จัดเก็บไว้ในดัชนี

ขั้นตอนวิธีการเข้ารหัสคำแบ่งออกเป็นสองกระบวนการ คือการแปลงรูปคำไทยโดยอาศัยหลักการถ่ายเสียง และการแปลงตัวอักษรอังกฤษเป็นตัวอักษรไทยโดยอาศัยหลักการถอดอักษร

2.1 การแปลงรูปคำไทย

ขั้นตอนการแปลงรูปคำไทยมีจุดประสงค์หลักเพื่อแปลงคำไทยที่อ่านออกเสียงคล้ายกัน แต่เขียนได้หลายรูปแบบ ให้อยู่ในรูปแบบเดียวกัน เพื่อให้ขั้นตอนการเทียบรหัสกระทำได้ง่ายขึ้น การแปลงรูปประกอบด้วยประกอบด้วยการตัดวรรณยุกต์และไม้ไต่คู้ การเปลี่ยนรูปการสะกด และการแทนที่สระประสมด้วยสัญลักษณ์เสียงสากล

2.1.1 การตัดวรรณยุกต์และไม้ไต่คู้

เนื่องจากในการถอดอักษรไทยเป็นอักษรอังกฤษนั้น จะไม่พิจารณาวรรณยุกต์และไม้ไต่คู้ เช่น *ช้าง* ถอดอักษรเป็น

CHANG ดังนั้นวรรณยุกต์ และไม้ไต่คู้ จะถูกตัดทิ้งจากคำไทย

2.1.2 การเปลี่ยนรูปการสะกด

การเปลี่ยนรูปการสะกดอาศัยหลักทางภาษาศาสตร์ [6] และข้อมูลทางสถิติ [7] เพื่อเปลี่ยนรูปแบบการสะกดของคำไทยที่เขียนได้หลายรูปแบบให้เหมือนกัน แบ่งเป็นกรณีต่าง ๆ ดังนี้

- รร ทำการเปลี่ยน รร เป็น ัน ในกรณีที่ไม่มีตัวสะกดตามหลัง เช่น จรรยา บรรจบ ครรรจ์ เป็นต้น และ เป็น ัน ในกรณีที่ไม่มีตัวสะกดตามหลัง เช่น ธรรม พรรณ กรรม เป็นต้น
- สระ ใ- ใ- และ ใ-ย ทำการเปลี่ยนสระดังกล่าวทั้งหมดเป็น -ัย
- สระ ำ และ ำ ทำการเปลี่ยนสระ ำ เป็น ำ
- การันต์และอักษรควบการันต์ ทำการตัดอักษรและอักษรควบที่มีตัวการันต์กำกับออก เนื่องจากการถอดอักษรโดยปกติจะไม่ถอดอักษรที่มีการันต์กำกับ เช่น สิทธิ์ ถอดเป็น SITH พันธุ์ ถอดเป็น PHAN เป็นต้น

2.1.3 การแทนที่สระประสมด้วยสัญลักษณ์เสียงสากล

การแทนที่สระประสมด้วยสัญลักษณ์เสียงสากลมีจุดประสงค์เพื่อแปลงทำให้คำไทยที่มีการใช้สระประสมและสระเดี่ยวที่ใช้อักษรตั้งแต่สองตัวขึ้นไปให้อยู่รูปแบบที่ง่ายต่อการประมวลผล และลดจำนวนอักขระที่ต้องเปรียบเทียบซึ่งขั้นตอนนี้จะใช้สัญลักษณ์เสียงสากล [8] แทนเสียงสระดังกล่าวโดยจะวางสัญลักษณ์เสียงสากลไว้หลังพยัญชนะต้นเพื่อให้มีรูปแบบเหมือนกับผลลัพธ์ที่ได้จากการถอดอักษรคำอังกฤษทับศัพท์คำไทย การใช้สัญลักษณ์เสียงสากลแทนที่สระมีดังนี้

- ใช้สัญลักษณ์เสียง e แทนสระ เ-ะ เช่น เละ เปลี่ยนเป็น le
- ใช้สัญลักษณ์เสียง x แทนสระ แ-ะ แ-ะ เช่น แกะ แหะ เปลี่ยนเป็น gx หลx ตามลำดับ
- ใช้สัญลักษณ์เสียง q แทนสระ เ-ิ เ-ิ เช่น เกิด เษขญ เปลี่ยนเป็น gqd ผชขญ ตามลำดับ
- ใช้สัญลักษณ์เสียง l แทนสระ เ-ีย เ-ีย เ-ีย และ เ-ีย เช่น เสียง เกรียน เปลี่ยนเป็น slg กวln ตามลำดับ

- ใช้สัญลักษณ์เสียง U แทนสระ เ-ื่อ เ-ื่อ เ-ื่อ เ-ื่อ และ ัว เช่น เรือง เกลือ ผัวะ และ ัว เปลี่ยนเป็น r Uง glU ผU และ wU ตามลำดับ
- ใช้สัญลักษณ์เสียง @ แทนสระ เ-า เ-า เ-าะ และ เ-าะ เช่น เภา เพรา เภาะ และ เฉพาะ เปลี่ยนเป็น g@ พร@ ง@ และ ฉพ@ ตามลำดับ

2.2 การถอดอักษรคำอังกฤษทับศัพท์คำไทย

ในกรณีที่ข้อความเป็นคำอังกฤษทับศัพท์คำไทย จะทำการถอดอักษรอังกฤษเป็นไทย การถอดอักษรที่นำเสนอในที่นี้เป็นการเปลี่ยนพยัญชนะอังกฤษเป็นพยัญชนะไทย ส่วนสระอังกฤษจะใช้หลักเกณฑ์การแทนที่สระประสมด้วยสัญลักษณ์เสียงสากลคือจะถอดสระอังกฤษเป็นสระไทย แต่ถ้าสระไทยนั้นเป็นสระที่ใช้อักษรตั้งแต่สองตัวขึ้นไปจะใช้สัญลักษณ์เสียงสากล แทนเสียงสระดังกล่าว

หลักเกณฑ์ในการถอดอักษรในส่วนพยัญชนะ (ดูตารางที่ 1) จะใช้หลักการเทียบตัวอักษรโรมัน-ไทยของ ISO [9] โดยได้ดัดแปลงบางส่วนเพื่อให้สมบูรณ์ยิ่งขึ้น เช่น ถอด DH เป็น ท และ ถอด BH เป็น พ เนื่องจากการเขียนแบบบาลีสันสกฤต ซึ่งยังมีใช้กันอยู่มากในปัจจุบัน [10]

อังกฤษ	ไทย	
B	บ	
BH	พ	*
C	ช	*
CH	ช (ฉ ฉ)	
CK	ก	*
D	ด (ฎ)	
DH	ท	*
F	ฟ (ฝ)	
G	ก	*
H	ห (ฮ)	
J	จ	*
K	ก	
KH	ข (ข ค ค ฅ)	
L	ล (ภ พ)	
M	ม	

อังกฤษ	ไทย	
N	น (ณ)	
NG	ง	
P	ป	
PH	พ (ผ ภ)	
Q	ค	*
R	ร (ฤ)	
S	ส (ซ ส ษ)	
T	ต (ฏ)	
TH	ท (ฐ ท ฒ ถ ฑ)	
V	ว	
W	ว	
X	ก	*
Y	ย (ญ)	
Z	ซ	*

* ส่วนที่ปรับเปลี่ยนและเพิ่มเติมจากแบบของ ISO ตารางที่ 1 การถอดอักษรพยัญชนะอังกฤษเป็นไทย

ส่วนหลักเกณฑ์ในการถอดอักษรในส่วนสระอังกฤษเป็นสระไทยนั้น ผู้วิจัยพบว่ามีปัญหาอย่างมากในการถอด

อักษร คือ หนึ่งหน่วยอักษรโรมันสามารถถอดได้เป็นหลายหน่วยอักษรไทยเช่น A ถอดอักษรเป็น เ-ะ -ะ -า และ O ถอดอักษรเป็น -อ -โ เป็นต้น และหลายหน่วยอักษรโรมันสามารถถอดเป็นหนึ่งหน่วยอักษรไทยได้ เช่น U หรือ OO ถอดเป็น -ุ เป็นต้น และจากการศึกษาของผู้วิจัยพบว่ามีความหลากหลายในการใช้อักษรโรมันแทนอักษรไทย เช่น คำว่า พร มีการเขียนเป็น *Phorn Phon Porn Pon* เป็นต้น (การใช้ *om* เป็นความนิยมใช้ซึ่งไม่ถูกต้องตามหลักภาษาที่ราชบัณฑิตยสถานกำหนด) ดังนั้นในงานวิจัยนี้จึงได้พยายามยึดหลักการถอดอักษรของราชบัณฑิตยสถาน [11] และ การใช้อักษรโรมันแทนอักษรไทยของจันทร์เพ็ญ โวหารสุนทร [12] (ได้จากการสำรวจความนิยมในการใช้อักษรโรมันแทนอักษรไทย) เป็นต้นแบบและเพิ่มเติมบางส่วนจากการศึกษาของผู้วิจัยที่มีผู้นิยมใช้เข้าไปดังตารางที่ 2

อังกฤษ	ถอดอักษรเป็น	หมายเหตุ
A	ะ	
AA	า	*
AE	x (แ-ะ แ-)	
AI	ัย	
AO	@ (เ-า)	
AIU	I (เ-ีย)	*
ARN	าน	*
ART	าท	*
E	เ (เ-ะ เ-)	
EE	-ี	*
EO	แ-ว	
ER	q (เ-อ เ-) หลัง R ต้องไม่เป็นสระ	
EU	-ึ	
I	-ิ	
IA	I (เ-ียะ เ-ีย)	
IE	I (เ-ียะ เ-ีย)	*
O	อ (-อ)	
OE	q (เ-อ เ-)	
OI	อย	
OO	-ุ	
ORN	ร (-อน)	*
U	-ุ (-ึ -ุ -ู)	
UA	U (เ-ือะ เ-ือ -ัวะ -ัว)	
UE	-ึ	

* ส่วนที่เพิ่มเติมจากแบบของราชบัณฑิตยสถาน

ตารางที่ 2 การถอดอักษรสระอังกฤษเป็นไทย

หมายเหตุ ถ้าตัวอักษรแรกของคำเป็นสระได้แก่ A E I O และ U ให้ถอด A เป็น อ ถอด E เป็น เ (สระ เ- กับ อ) ถอด I เป็น อ (อ กับสระ -ิ) ถอด O เป็น โ (สระ -โ กับ

อ) และถอด U เป็น อุ (อ กับสระ -ุ) และถ้าตัวอักษรถัดไปเป็นสระอีกให้นำอักษรตัวแรกไปรวมด้วยในการถอดอักษรโดยเทียบตามตารางที่ 2

3. ขั้นตอนการค้นคืน

รหัสคำที่ได้ของคู่คำไทยและคำอังกฤษทับศัพท์คำไทยนั้นอาจไม่ตรงกันทุกตัวอักษร แต่จะมีลักษณะคล้ายกัน ทั้งนี้เนื่องจากหลักการทับศัพท์ที่ใช้กันในปัจจุบันมีหลายรูปแบบ การเปรียบเทียบรหัสคำแบบเปรียบเทียบตัวต่อตัวในรหัสให้ตรงกัน จะได้ความแม่นยำของการค้นคืนที่สูง แต่ค่าเรียกคืนจะต่ำมาก เพื่อสร้างความสมดุลของระบบการค้นคืน เพื่อให้ได้ค่าแม่นยำและค่าเรียกคืนที่ดีทั้งคู่ การค้นคืนรหัสคำจะอาศัยสองเทคนิคคือ การแยกเทียบส่วนพยัญชนะและส่วนสระ และการเทียบรหัสคำแบบประมาณ

การเทียบรหัสคำแบบประมาณนั้นอาศัยการคำนวณค่าความแตกต่าง (distance) ของรหัสคำด้วยเทคนิคระยะแก้ไขเสียงอ่านสั้นที่สุด (Minimum Phonetic Edit Distance) [13] โดยแยกหาค่าความแตกต่างของส่วนพยัญชนะ และส่วนสระของรหัสคำ จากนั้นนำค่าความแตกต่างของรหัสคำที่ได้มาทดสอบกับเงื่อนไขในการเปรียบเทียบ ถ้าผ่านการทดสอบจะสรุปได้ว่ารหัสคำทั้งสองรหัสนี้เป็นรหัสที่มาจากคำหลักที่ตรงกันในอีกภาษา

3.1 การคำนวณหาค่าความแตกต่างของรหัสคำ

การคำนวณหาค่าความแตกต่างของรหัสคำจะได้มาจากการคำนวณหาต้นทุนน้อยที่สุดในการแก้ไขอักขระ (ประกอบด้วยการลบการเพิ่มและการแทนที่อักขระ) ให้รหัสคำทั้งสองเหมือนกัน ซึ่งจะพิจารณาความแตกต่างกันทางเสียงของอักขระแทนรูปของอักขระ โดยใช้กลุ่มอักขระของชาวตะวันตกช่วยในการกำหนดกลุ่มเสียงที่คล้ายกัน โดยผู้วิจัยได้ทำการปรับเปลี่ยนการกำหนดต้นทุนในการแก้ไขอักขระของขั้นตอนวิธีระยะแก้ไขเสียงอ่านสั้นที่สุด [13] เพื่อความเหมาะสมเมื่อใช้กับคำในภาษาไทยโดยมีแนวคิดดังนี้

- กำหนดต้นทุนต่อการแก้ไขอักขระให้มี 4 ระดับ คือ C_1 , C_2 , C_3 และ C_4 โดยกำหนดให้ $C_1=0$ $C_2=1$ $C_3=4$ และ $C_4=7$
- กำหนดต้นทุนในการแก้ไขแต่ละอักขระให้มีค่าไม่เท่ากันได้
- อนุญาตให้มีการแทนที่อักขระแบบหนึ่งอักขระต่อสองอักขระ เช่น การแทนที่ ทร ด้วย ช เป็นต้น

การคำนวณค่าความแตกต่างอาศัยเทคนิคกำหนดการพลวัต (dynamic programming) จากสมการเวียนเกิด $Edit(P_j, W_k)$ ดังนี้

$$Edit(P_0, W_0) = 0$$

$$Edit(P_j, W_0) = Edit(P_{j-1}, W_0) + D(p_{j-1}, p_j)$$

$$Edit(P_0, W_k) = Edit(P_0, W_{k-1}) + D(w_{k-1}, w_k)$$

$$Edit(P_j, W_k) = \min\{ Edit(P_{j-1}, W_k) + D(p_{j-1}, w_j), \\ Edit(P_j, W_{k-1}) + D(p_j, w_k), \\ Edit(P_{j-1}, W_{k-1}) + R(p_{j-1}p_j, w_k) \}$$

โดยที่ $P_j = p_1 p_2 p_3 \dots p_j$ เป็นสายอักขระต้นแบบ มีความยาว j ตัวอักษร

$W_k = w_1 w_2 w_3 \dots w_k$ เป็นสายอักขระเป้าหมาย มีความยาว k ตัวอักษร

$p_{j-1}p_j$ เป็นสองอักขระใด ๆ ที่มีตำแหน่งติดกัน

$D(p_j, w_k)$ มีค่าเท่ากับ $\min(DELADD[p_j], REPLACE[p_{j-1}p_j, w_k])$

$R(p_{j-1}p_j, w_k)$ มีค่าเท่ากับ $\min(REPLACE[p_j, w_k], REPLACE[p_{j-1}p_j, w_k])$

$REPLACE[p_{j-1}p_j, w_k]$ หมายถึงตารางค้นหาต้นทุนในการแทนที่อักขระ $p_{j-1}p_j$ ด้วยอักขระ w_k

$DELADD[p_j]$ หมายถึงตารางค้นหาต้นทุนในการลบเพิ่มอักขระ p_j

การกำหนดต้นทุนในการแทนที่อักขระ (ตาราง $REPLACE[p_j, w_k]$ สำหรับการแทนที่อักขระ p_j ด้วยอักขระ w_k) มีหลักการดังนี้

- พยัญชนะไทยมี 44 รูป แยกความแตกต่างทางเสียงได้ 21 เสียง [8] กำหนดต้นทุนเท่ากับ C_1 เช่น การแทนที่ญ ด้วย ย มีต้นทุนเท่ากับ C_1 เป็นต้น
- อักขระที่ไม่สามารถแยกความแตกต่างในการถอดอักษร กำหนดต้นทุนเท่ากับ C_2 ได้แก่ อักษร K ถอดเป็น ก หรือ ค อักษร T ถอดเป็น ต หรือ ท อักษร P ถอดเป็น ป หรือ พ อักษร CH ถอดเป็น จ หรือ ช อักษร E ถอดเป็น - หรือ - และ อักษร U ถอดเป็น - หรือ -
- การถอดอักษรสำหรับสระเสียงสั้นกับสระเสียงยาว ที่ไม่สามารถแยกความแตกต่างทางเสียงในภาษาอังกฤษ กำหนดต้นทุนในการแทนที่อักขระเท่ากับ C_1 เช่น อักษร A ถอดอักษรเป็น -ะ หรือ -า อักษร I ถอดอักษรเป็น -ิ หรือ -ี เป็นต้น
- มาตราของอักขระไทย จะเลือกบางอักขระมาเป็นตัวแทนมาตรา ดังตารางที่ 3 โดยจะกำหนดต้นทุนในการ

แทนที่อักขระตัวแทนมาตรากับอักขระที่อยู่ในมาตราเดียวกันเท่ากับ C_3 ซึ่งวิธีนี้จะทำให้ความแตกต่างของเสียงมีได้มากกว่าวิธีจัดกลุ่มแบบชาวตะวันตกซึ่งภาษาไทยที่รวมอักขระต่าง ๆ ที่อยู่มาตราเดียวกันเข้าเป็นกลุ่มเสียงเดียวกัน [14] เช่น คำว่า สาร กับ ชาญ วิธีที่น่าเสนอสามารถบอกได้ว่า ส-ช และ ร-ญ ต่างกันสิ้นเชิงเนื่องจากทั้ง ส และ ช มีความสัมพันธ์กับ ค หรือ ด (มาตราค) แต่ ส และ ช ไม่มีความสัมพันธ์กันเอง แต่ถ้าเป็นวิธีชาวตะวันตกจะบอกว่าอักษร ส และ ช มีความสัมพันธ์กันเนื่องจากอยู่ในมาตราค และ อักษร ร และ ญ มีความสัมพันธ์กันเนื่องจากอยู่ในมาตราณ

มาตรา	ตัวอักษร	ตัวแทน
กก	ก ข ค ฅ	ก
กค	ค ต ถ ท ธ ฎ ฏ ฐ ฒ จ ช ษ ส ซ	ค ต
กง	ง	ง
กน	น ณ ญ ล พ ร	น
กบ	บ ป พ ภ ฟ	บ
กม	ม	ม

ตารางที่ 3 อักขระแทนมาตราต่าง ๆ

- กำหนดต้นทุนในการแทนที่อักขระแบบหนึ่งอักขระต่อสองอักขระเท่ากัน เนื่องจากมีการอ่านออกเสียงเหมือนกัน โดยแบ่งเป็นกรณีต่าง ๆ ดังนี้
 1. อักษรควบไม่แท้ มี 5 ตัว [6] ดังนี้ ทร-ช, จร-จ, สร-ส, ศร-ศ และ ชร-ช
 2. อักษรนำเสียงสนธิ มี 9 ตัว [6] ดังนี้ อย, หย, หง, หร, หญ, หล, หน, หว และ หม
 3. อักษรควบที่เป็นตัวสะกด [6] เช่น กร-จักร, คร-สมัคร, ตร-จิตร, ทร-สมุทร, ปร-กอป, รค-ชลมารค, รด-สามารถ และ หม-พรม
- นอกจากนั้นจะกำหนดต้นทุนในการแทนที่เท่ากับ C_4 (ซึ่งมีค่ามากที่สุด)

การกำหนดต้นทุนในการลบเพิ่มอักขระ (ตาราง $DELADD[a]$) สามารถแบ่งเป็นกรณีต่าง ๆ ดังนี้

- สระที่มีการแปลงรูป ได้แก่ -ะ -โ- และ -อ ซึ่งจะไม่ปรากฏในหน่วยอักษรของคำไทย แต่จะปรากฏในคำอังกฤษทับศัพท์ภาษาไทย ทำให้หน่วยอักษรที่ได้จากถอดอักษรไม่ตรงกันกับคำไทย เช่น Thavee-ทวี พร-Phon และ นก-Nok เป็นต้น ดังนั้นจะกำหนดต้นทุนในการเพิ่มหรือลบอักขระกลุ่มนี้เท่ากับ C_2

- พยัญชนะที่เป็นส่วนประกอบของสระประสม ได้แก่ อ ย และ ว เช่น เอ-อ เอ-ย และ -ว เป็นต้น ซึ่งมักจะเกิดความผิดพลาดได้ง่ายในการถ่ายอักษร เช่น คำว่า *Chuan* (ชวน) การถอดอักษรจะได้ เขียน ซึ่งไม่ได้ อักษร ว ดังนั้นจะกำหนดต้นทุนในการเพิ่มหรือลบ อักษรกลุ่มนี้เท่ากับ C_2
- การทับศัพท์ที่ไม่ตรงตามประกาศของราชบัณฑิตยสถาน เช่น คำว่า *ธรรม-Thama* จิตร-*Chitara* และ *รัตน-Ratana* เป็นต้น จากการทับศัพท์แบบนี้ทำให้เวลาถอดอักษรแล้ว จะได้สระ -ะ หรือ -า เกิน ดังนั้นจะกำหนดต้นทุนในการเพิ่มหรือลบอักษรกลุ่มนี้เท่ากับ C_2
- นอกจากนี้จะกำหนดต้นทุนในการลบเพิ่มเท่ากับ C_4 (ซึ่งมีมากที่สุด)

3.2 เกณฑ์การเทียบรหัสคำแบบประมาณ

รหัสคำสอง P_m และ W_n ใด ๆ ที่มีค่าความแตกต่างผ่านเกณฑ์ที่แสดงข้างล่างนี้ ทั้งส่วนพยัญชนะ และส่วนสระของรหัส จะถือว่าเป็นรหัสคำของคำที่ตรงกันระหว่างภาษาไทย กับภาษาอังกฤษทับศัพท์ภาษาไทย

$$\text{Edit}(P_m, W_n) \leq \alpha \times \text{Max}(m, n) \times C_4$$

$\text{Max}(m, n) \times C_4$ หมายถึงต้นทุนมากที่สุดที่ใช้ในการแก้ไขอักษร คือแก้ไขทุกอักษรของ W_n ให้เป็น P_m ในขณะที่ α นี้เป็นพารามิเตอร์ของระบบที่ผู้ใช้สามารถกำหนดได้ ซึ่งจะส่งผลต่อค่าแม่นยำและค่าเรียกคืนของระบบ α มีค่าระหว่าง 0 ถึง 1 ซึ่งจะเป็นตัวกำหนดเกณฑ์การยอมรับความเหมือนกันของรหัสคำแบบประมาณ โดยที่ 0 หมายถึงรหัสคำทั้งสองต้องเหมือนกันทุกประการจึงจะยอมรับ ในขณะที่ 1 หมายถึงการยอมรับทุก ๆ คู่รหัสคำไม่ว่าจะแตกต่างเท่าใดก็ตาม

ตัวอย่าง ต้องการทดสอบว่า “*ชูลิตติยวงศ์*” และ “*CHULERTTIYAWONG*” เป็นคำทับศัพท์ที่ตรงกันในภาษาไทย-อังกฤษหรือไม่ โดยจะเริ่มต้นจากการเข้ารหัสคำ การคำนวณหาค่าความแตกต่าง และนำค่าความแตกต่างที่ได้ไปทดสอบกับเงื่อนไขเพื่อสรุปว่าเป็นคำทับศัพท์ที่ตรงกันในภาษาไทย-อังกฤษหรือไม่ กำหนดให้ $\alpha = 0.15$

การเข้ารหัสคำ

- *CHULERTTIYAWONG* → “ชูลิตติยวง”

- *ชูลิตติยวงศ์* → *ชูลิตติยวง* → “ชูลิตติยวง”

การค้นคืน

ส่วนพยัญชนะ

$$\text{Edit}(\text{“ชลดตยวง”, “ชลดตยวง”}) = 5$$

$$0.15 \times \text{Max}(8, 7) \times 7 = 8.4$$

$$\text{ผ่านเกณฑ์: } 5 \leq 8.4$$

ส่วนสระ

$$\text{Edit}(\text{“ุ, ิ”}, \text{“ุ, ิ”}) = 1$$

$$0.15 \times \text{Max}(4, 3) \times 7 = 4.2$$

$$\text{ผ่านเกณฑ์: } 1 \leq 4.2$$


จากตัวอย่างพบว่าผ่านเกณฑ์ทั้งส่วนพยัญชนะ และส่วนสระ สรุปได้ว่าทั้งสองคำเป็นคำทับศัพท์ที่ตรงกันในภาษาไทย-อังกฤษ

4. ผลการทดลอง

ผู้วิจัยได้ทำการทดลองขั้นตอนวิธีที่ได้นำเสนอ โดยใช้ชื่อและชื่อสกุลทั้งภาษาไทยและภาษาอังกฤษที่ตรงกันของนิติปีการศึกษา 2541 ระดับปริญญาโทบัณฑิต จุฬาลงกรณ์มหาวิทยาลัย จำนวน 5,000 คู่ เป็นตัวอย่างข้อมูลในการทดลอง โดยนำคำศัพท์ทั้งหมดไปทำการเข้ารหัสด้วยขั้นตอนวิธีที่นำเสนอ และจัดเก็บคำศัพท์และรหัสคำในฐานข้อมูล หลังจากนั้นนำคำทั้งหมด 10,000 คำ ไปค้นคืนที่ละคำจากฐานข้อมูล ด้วยขั้นตอนวิธีการค้นคืนที่ได้นำเสนอ เพื่อทำการคำนวณค่าแม่นยำ และค่าเรียกคืน โดยตั้ง α ให้มีค่าในระดับต่าง ๆ เพื่อหาความสัมพันธ์ระหว่าง α กับประสิทธิภาพของการค้นคืน ได้ผลดังแสดงในรูปที่ 1

จากรูปที่ 1 แสดงให้เห็นว่าค่าแม่นยำของระบบค้นคืนสูงประมาณ 94 เปอร์เซ็นต์ และจะลดค่าลงอย่างต่อเนื่องเมื่อค่าของ α เพิ่มขึ้น ส่วนพฤติกรรมของค่าเรียกคืนจะเริ่มต้นประมาณ 17 เปอร์เซ็นต์และจะเพิ่มค่าขึ้นเมื่อค่า α เพิ่มขึ้น ประสิทธิภาพของการค้นคืนที่ได้จากการทดลองพบว่าสอดคล้องกับพฤติกรรมโดยปกติของค่าแม่นยำและค่าเรียกคืนในระบบค้นคืนใด ๆ คือแนวโน้มของค่าแม่นยำและค่าเรียกคืนจะตรงข้ามกัน

จากผลการทดลองพบว่าขั้นตอนวิธีการเข้ารหัสคำทับศัพท์เพื่อการค้นคืนข้ามภาษาไทย-อังกฤษจะเกิดประสิทธิภาพสูงสุดคือค่าแม่นยำเท่ากับ 69 เปอร์เซ็นต์และค่าเรียกคืนเท่ากับ 73 เปอร์เซ็นต์ เมื่อกำหนดค่าแอลฟาเท่ากับ 0.15



รูปที่ 1 ความสัมพันธ์ระหว่างค่า α กับประสิทธิผลการค้นคืน

5. สรุป

บทความนี้ได้นำเสนอขั้นตอนวิธีการเข้ารหัสคำทับศัพท์และการค้นคืนเพื่อการค้นคืนข้ามภาษาไทย-อังกฤษ การเข้ารหัสนี้ใช้กับกรณีของคำอังกฤษที่ทับศัพท์คำไทย ซึ่งประกอบด้วยขั้นตอนการแปลงรูปคำไทยซึ่งอาศัยหลักการถ่ายเสียง และใช้หลักการถอดอักษรเพื่อแปลงตัวอักษรอังกฤษเป็นตัวอักษรไทย ขั้นตอนการค้นคืนนั้นจะเข้ารหัสคำของคำในข้อความ เพื่อนำได้ไปเทียบรหัสแบบประมาณกับรหัสคำต่างๆ ในดัชนี โดยอาศัยเทคนิคกำหนดการพลวัตรหัสคำได้ผ่านเกณฑ์การยอมรับในการเทียบสายอักษรที่กำหนดไว้ ก็ถือว่าเป็นคำทับศัพท์ที่ตรงกันของอีกภาษาหนึ่ง ผลการทดลองแสดงให้เห็นว่าขั้นตอนวิธีที่ได้นำเสนอนี้ให้ประสิทธิผลของการค้นคืนที่มีค่าเรียกคืนและค่าแม่นยำประมาณ 70 เปอร์เซนต์

เอกสารอ้างอิง

- [1] W. Frakes, "Introduction to Information Storage and Retrieval System", *Information Retrieval : Data Structure & Algorithm*, W.B. Frakes and R. Baeza-Yates ed., Prentice Hall, 1992.
- [2] D. Oard and B. Dorr, "A Survey of Multilingual Text Retrieval", *Technical Report UMIACS-TR-96-19 CD-TR-3615*, University of Maryland, College Park, April 1996.
- [3] K. Knight and J. Graehl, "Machine Transliteration", *Annual Meeting of the*

Association for Computational Linguistics (ACL-97/EACL-97).

- [4] S. Ongroongruang, R. Prongsirivattana, and V. Jantarasukree, "English to Thai Word Retrieval Using Sound Index", *Proc 2nd SNLP'95*, Bangkok Thailand, Aug. 2-4, 1995, pp. 4 7-413.
- [5] P. Suwanvisat and S. Prasitjutrakul, "Thai-English Cross-Language Transliterated Word Retrieval using Soundex Technique", *Proc. of the National Computer Science and Engineering Conference 1998*, Bangkok Thailand, Aug. 19-21, 1998.
- [6] กำชัย ทองหล่อ, "หลักภาษาไทย", พิมพ์ครั้งที่ 10, กรุงเทพมหานคร : อมรการพิมพ์, 2540.
- [7] S. Sethaputra, "Thaisoft So Sethaputra Dictionary Version 1.5" [Computer Software], Bangkok : Thaisoft Co.,Ltd, 1996.
- [8] ประจักษ์ ประภาพิตยการ และคณะ, "รู้จักภาษาไทย", พิมพ์ครั้งที่ 1, กรุงเทพมหานคร : โอเดียนบุ๊กส์, 2519.
- [9] International Organization for Standardization, "Information and Documentation – Transliteration of Thai", *Draft International Standard ISO/DIS 11940*, 1996.
- [10] พยงค์ ทิมเจริญ, "การเขียนชื่อภาษาไทยด้วยอักษรโรมัน", วารสารแผนที่ ปีที่ 27 ฉบับที่ 2 (ตุลาคม-ธันวาคม 2527) : 61-74.
- [11] ราชบัณฑิตยสถาน, "ประกาศราชบัณฑิตยสถาน เรื่องการถอดอักษรไทยเป็นโรมัน", 2482.
- [12] จันทรเพ็ญ โวหารสุนทร, "การศึกษาการใช้อักษรโรมันแทนอักษรไทย", ปรินูญานิพนธ์, คณะอักษรศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร, 2530.
- [13] J. Zobel and P. Dart, "Phonetic String Matching: Lessons from Information Retrieval", *Proceedings of the 19th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, Zurich, Switzerland, 1996, pp. 166-172.
- [14] นิลเนตร อรุณวงศ์ ณ อยุธยา, "การเปลี่ยนอักขระของคำในภาษาไทย โดยใช้หลักการของชาวเด็คซ์", ปรินูญานิพนธ์, คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2534.