

# การพัฒนาโครงสร้างข้อมูลพจนานุกรมไทยด้วยทรีแอดวู



นาย อภิชิต พิทยรัตน์โสภณ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

ภาควิชาวิศวกรรมคอมพิวเตอร์

บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย

พ.ศ. 2537

ISBN 974-584-532-9

ลิขสิทธิ์ของบัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย

I16923911

**THAI DICTIONARY DATA STRUCTURE  
DEVELOPMENT USING DOUBLE ARRAY TRIE**

**Mr. Apichit Pittayaratsopon**

A Thesis Submitted in Partial Fulfillment of the Requirement

for the Degree of Master of Science

Department of Computer Engineering

Graduate School

Chulalongkorn University


1994

ISBN 974-584-532-9


หัวข้อวิทยานิพนธ์    การพัฒนาโครงสร้างข้อมูลพจนานุกรมไทยด้วยทรีแอดแวลู  
โดย                            นาย อภิชาติ พิทยรัตน์โสภณ  
ภาควิชา                        วิศวกรรมคอมพิวเตอร์  
อาจารย์ที่ปรึกษา            อาจารย์ ดร. ชรรยง เต็งอำนาจ  
อาจารย์ที่ปรึกษาร่วม      อาจารย์ วิรัช ศรีเลิศล้ำวาณิช




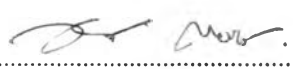
บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

  
..... คณบดีบัณฑิตวิทยาลัย  
( ศาสตราจารย์ ดร. ถาวร วัชรากัญ )

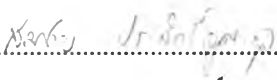
คณะกรรมการสอบวิทยานิพนธ์

  
..... ประธานกรรมการ  
( รองศาสตราจารย์ สมชาย ทานอง )

  
..... กรรมการ  
( อาจารย์ ดร. ชรรยง เต็งอำนาจ )

  
..... กรรมการ  
( อาจารย์ วิรัช ศรีเลิศล้ำวาณิช )

  
..... กรรมการ  
( อาจารย์ จารุมাত্র ปันทอง )

  
..... กรรมการ  
( อาจารย์ ดร. สมชาย ประสิทธิ์จิตรระกุล )

พิมพ์จัดฉบับแปลด้วยอักษรไทยในกรอบสี่เหลี่ยมที่พิมพ์แยกเล่มเดียว



อภิชาติ พิทยรัตน์โสภณ : การพัฒนาโครงสร้างข้อมูลพจนานุกรมไทยด้วยทรีแวกู (THAI  
DICTIONARY DATA STRUCTURE DEVELOPMENT USING DOUBLE ARRAY TRIE)

อ.ที่ปรึกษา : อ.ดร. ยรรยง เต็งอำนวยการ, อ.ที่ปรึกษาร่วม : อ. วิรัช ศรีเลิศล้ำวาณิช,  
53 หน้า, ISBN 974-584-532-9

การวิจัยครั้งนี้มีจุดมุ่งหมายเพื่อสร้างและพัฒนาโครงสร้างข้อมูลของระบบจัดการฐานข้อมูล  
พจนานุกรมภาษาไทยที่มีลักษณะจลน์ สามารถเพิ่มลบคำได้ตลอดโดยไม่ต้องสร้างพจนานุกรมทั้งหมดใหม่  
เพื่อใช้ในโครงการแปลภาษาด้วยคอมพิวเตอร์ โดยให้มีประสิทธิภาพในการสืบค้นเพิ่มลบคำศัพท์ ทั้งใน  
ด้านความเร็ว ความยืดหยุ่น รวมถึงการประหยัดหน่วยความจำ ด้วยทรีแวกู

มีการใช้โครงสร้างข้อมูลต่างๆ เพื่อเก็บพจนานุกรม รวมทั้งโครงสร้างข้อมูลทรีแวกูที่เข้ากันได้ดี  
กับลักษณะของคำไทย แต่โครงสร้างทั้งหมดล้วนมีลักษณะสถิตย์ คือไม่สามารถเพิ่มลบคำได้ในทันที ต้องแก้ไข  
เพิ่มลบคำนั้นในชุดของคำศัพท์ก่อน แล้วจึงสร้างพจนานุกรมทั้งหมดขึ้นมาใหม่ แต่เมื่อใช้โครงสร้างข้อมูล  
ทรีแวกูซึ่งมีลักษณะจลน์แล้วสามารถลบจุดบกพร่องนี้ได้

จากผลการทดสอบพบว่าทรีแวกูเหมาะที่จะใช้เป็นโครงสร้างข้อมูลสำหรับฐานข้อมูลพจนานุกรม  
ภาษาไทยที่จำเป็นต้องมีการแก้ไขเพิ่มลบคำอยู่ตลอด เพราะว่ามีความสามารถในการเพิ่มลบคำได้  
มีประสิทธิภาพการใช้เนื้อที่หน่วยความจำที่ดี และมีเวลาที่ใช้ในการเพิ่มลบคำที่ดี

ภาควิชา.....วิภาษวิธี.....  
สาขาวิชา.....วิทยาศาสตร์คอมพิวเตอร์.....  
ปีการศึกษา.....2536.....

ลายมือชื่อนิติ.....  
ลายมือชื่ออาจารย์ที่ปรึกษา.....  
ลายมือชื่ออาจารย์ที่ปรึกษาร่วม.....

## C216583 : MAJOR COMPUTER SCIENCE

KEY WORD: DATA STRUCTURE / DICTIONARY / THAI LANGUAGE / DOUBLE ARRAY TRIE  
APICHT PITTAYARATSOPON : THAI DICTIONARY DATA STRUCTURE USING  
DOUBLE ARRAY TRIE. THESIS ADVISOR : YANYONG TENGAMNUAY, Ph.D.,  
THESIS CO-ADVISOR : VIRACH SORNLERLTLAMVANICH. 53 pp. ISBN  
974-584-532-9

This research has objective to create and develop data structure of Thai dictionary database management system which has dynamic characteristic and will be used in machine translation project. Insertion and deletion of words can be done as often as needed without creating new whole dictionary. The development uses Double Array Trie for efficiencies of insert and delete time, flexibility, and memory use.

There are various data structures used to develop dictionary, including trie data structure which matches Thai word characteristic. But all are static - words cannot be inserted or deleted immediately, but words are initially inserted or deleted in set of words and then new dictionary is recreated. When using dynamic Double Array Trie data structure, above problem can be solved.

From result of testing, Double Array Trie is suitable to be used as data structure of Thai dictionary database which is necessary to have words edited as often as needed. Because Double Array Trie has ability of insertion and deletion, efficiency in memory using, and fast insert and delete time.

ภาควิชา.....  
สาขาวิชา.....  
ปีการศึกษา.....

ลายมือชื่อนิสิต.....  
ลายมือชื่ออาจารย์ที่ปรึกษา.....  
ลายมือชื่ออาจารย์ที่ปรึกษาร่วม.....



## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยความช่วยเหลือจากบุคคลหลายท่าน ผู้เขียนขอขอบพระคุณอาจารย์ ดร. ยรรยง เต็งอำนวยสำหรับคำแนะนำปรึกษา ขอขอบพระคุณอาจารย์ วิรัช ศรีเลิศ-ล้ำวณิช อาจารย์ ดร. สุรพันธ์ เมฆนาวิน และบุคลากรห้องปฏิบัติการวิจัยภาษาและวิทยาการความรู้ ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติสำหรับข้อมูล เครื่องมือ และสถานที่ และขอขอบคุณเพื่อนพี่น้องสำหรับคำแนะนำต่างๆ

ทำนี้ ผู้เขียนขอขอบพระคุณบิดามารดาที่เฝ้ากำลังใจเสมอมาจนสำเร็จการศึกษา



## สารบัญ

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญภาพ.....	ญ
บทนำ.....	1
- ความสำคัญ และความเป็นมาของปัญหา.....	1
- โครงสร้างข้อมูล.....	2
- โครงสร้างทรี.....	3
- วัตถุประสงค์ของการวิจัย.....	7
- ขอบเขตของการวิจัย.....	7
- วิธีดำเนินการวิจัย.....	8
- ประโยชน์ที่คาดว่าจะได้รับ.....	8
โครงสร้างข้อมูลทรีแฉก.....	10
- การเปรียบเทียบ (Pattern Matching) ของทรีแฉก.....	10
- การปรับปรุงทรีแฉก.....	13
- เงื่อนไขเพิ่มเติมของทรีแฉก.....	13
- การสืบค้นคีย์.....	15
- การเพิ่มคีย์.....	17
- การลบคีย์.....	23
การออกแบบโครงสร้างข้อมูลทรีแฉก.....	25
- โครงสร้างข้อมูลของอาร์เรย์คู่ (BASE และ CHECK).....	25
- โครงสร้างเพิ่มข้อมูลของอาร์เรย์คู่ (BASE และ CHECK).....	26

- โครงสร้างเพิ่มข้อมูลของ TAIL.....	27
- ค่าคงที่ที่ใช้ในโปรแกรม.....	27
- โครงสร้างข้อมูลที่ใช้ในโปรแกรม.....	29
- ฟังก์ชันการจัดการโครงสร้างข้อมูลทรีแอดวู.....	31
- โปรแกรมอรรถประโยชน์.....	33
การทดสอบ.....	35
- โครงสร้างข้อมูลทรีอัดแน่นแบบจลน์.....	35
- ผลการทดสอบ.....	36
- สรุปผล.....	37
บทสรุปและข้อเสนอแนะ.....	40
- บทสรุป.....	40
- ข้อเสนอแนะ.....	41
เอกสารอ้างอิง.....	42
ประวัติผู้เขียน.....	43



## สารบัญตาราง

ตารางที่ 4.1 ผลการทดสอบกับค่าประเภทต่างๆ.....	39
---	----

## สารบัญรูป

รูปที่ 1.1 คำภาษาอังกฤษที่ใช้บ่อย 31 คำ.....	3
รูปที่ 1.2 ทริโยงของคำอังกฤษที่ใช้บ่อย .....	4
รูปที่ 1.3 ทริยครรชนิของคำอังกฤษที่ใช้บ่อย .....	4
รูปที่ 1.4 ทริยอัดแน่นของคำอังกฤษที่ใช้บ่อย.....	5
รูปที่ 2.1 เครื่องเปรียบเทียบ (Pattern Matching Machine) ของ K1.....	11
รูปที่ 2.2 โครงสร้างข้อมูลทริยของ K1 .....	12
รูปที่ 2.3 โครงสร้างข้อมูลทริยแถวคู่.....	12
รูปที่ 2.4 ฟังก์ชัน goto ของ K'.....	13
รูปที่ 2.5 ทริยแถวคู่ของ K' .....	16
รูปที่ 2.6 ขั้นตอนการเพิ่มคีย์ .....	21
รูปที่ 3.1 แสดง BASE และ TAIL ที่ปรับปรุงแล้ว.....	26
รูปที่ 3.2 แสดง BASE และ CHECK ที่เก็บเป็นแฟ้มข้อมูล .....	26
รูปที่ 3.3 แสดง TAIL ที่เก็บเป็นแฟ้มข้อมูล .....	27