

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 เทคนิคการค้นหาลำดับข้อมูลบนฐานข้อมูลเชิงสัมพันธ์

การค้นคืนสารสนเทศเป็นเทคโนโลยีที่ใช้ในการเพิ่มประสิทธิภาพการทำงานของระบบค้นหาลำดับข้อมูล และจัดลำดับความสำคัญหรือความน่าจะเป็นของข้อมูลที่ใช้ต้องการตามค่าน้ำหนักที่คำนวณได้จากมากไปหาน้อย โดยเดิมทีการค้นคืนสารสนเทศจะใช้ได้กับเอกสารประเภทข้อความ (Text) เท่านั้น แต่ปัจจุบันนี้ ถ้ากล่าวถึงการค้นคืนสารสนเทศอาจจะหมายความรวมถึงเอกสารที่อยู่บนเครือข่ายอินเทอร์เน็ต หรือเอกสารประเภทอื่นๆ ด้วย เช่น รูปภาพ เสียง วิดีโอ เป็นต้น


ในปัจจุบันเทคนิคการค้นหาลำดับข้อมูลบนฐานข้อมูลเชิงสัมพันธ์โดยเรียงลำดับความสำคัญของข้อมูลจากมากไปหาน้อย จะนำเอาคำหลัก (Keyword) ที่ต้องการค้นหาไปเปรียบเทียบกับ Pattern ข้อมูลที่ได้จัดเตรียมไว้ แล้วนำผลลัพธ์ที่ได้จากการค้นหามาจัดลำดับความสำคัญหรือความน่าจะเป็นของข้อมูลที่ใช้ต้องการ ซึ่งสามารถคำนวณได้จากสูตรดังต่อไปนี้

$$W_{ij} = IDF_i * TF_{ij}$$

$$IDF_i = \log_2(n / DF_i)$$

โดยที่

- W_{ij} คือ ค่าน้ำหนักของแต่ละคำที่ค้นหาเจอ
- TF_{ij} คือ จำนวนความถี่ของแต่ละคำ ที่ค้นหาเจอในแต่ละ Term
- DF_i คือ จำนวนความถี่ของคำทั้งหมดที่ปรากฏในทุกๆ เอกสาร
- IDF_i คือ ค่าที่ได้จากการคำนวณ Log ฐานสองของจำนวนคำทั้งหมดที่ค้นพบหารด้วยจำนวนความถี่ของคำทั้งหมดที่ปรากฏในทุกๆ เอกสาร
- n คือ จำนวนคำทั้งหมดที่ปรากฏในทุกๆ Term รวมกัน



ภาพ 2.1 แสดงหลักการทำงานของเทคนิคการค้นคืนสารสนเทศ

(อ้างอิงจาก : <http://web.missouri.edu/~heink/7301-fs2004/info retrieval/irmodel.html>)

จากภาพ 2.1 สามารถอธิบายหลักการทำงานของเทคนิคการค้นหาลำดับข้อมูลบนฐานข้อมูลเชิงสัมพันธ์ ได้ตามขั้นตอนการทำงาน ดังต่อไปนี้

- Formulate Query คือกระบวนการรับ Keyword ที่ผู้ใช้งานต้องการค้นหา
- System Transforms Query คือกระบวนการประมวลผล Keyword ที่ได้รับจากผู้ใช้งาน
- ตัดคำที่ไม่มีความหมายออก เช่น a, an, the เป็นต้น
- แยก Keyword ที่รับเข้ามาออกเป็นคำๆ
- Matching Process คือกระบวนการนำคำที่ได้จากกระบวนการ System Transforms Query ไปเปรียบเทียบกับคำต่างๆ ที่อยู่ในเอกสารในฐานข้อมูล หากเอกสารใดๆ มีคำที่มีความหมายตรงกับคำที่นำไปเปรียบเทียบให้ Return เอกสารนั้นออกมา
- Results List คือกระบวนการจัดลำดับความสำคัญหรือความน่าจะเป็นของเอกสารที่ผู้ใช้งานต้องการ
- Relevance Determination คือกระบวนการแสดงผลข้อมูลต่างๆ ที่ผ่านการประมวลผลให้ผู้ใช้งาน

2.2 International Components for Uni-Code (ICU) (อ้างอิงจาก : <http://site.icu-project.org>)

ICU คือเทคโนโลยีที่นำมาใช้ในการแยกคำต่างๆ ออกจากกันโดยรับอินพุต (Input) เป็นข้อความ เทคโนโลยีดังกล่าวได้มีการใช้งานอย่างแพร่หลาย อาทิ เช่น ผลิตภัณฑ์ของ Google, Apple, Apache, IBM เป็นต้น ซึ่งในปัจจุบันเทคโนโลยี ICU ได้กลายเป็นเทคโนโลยีพื้นฐานของโปรแกรมภาษา C, C++ และ Java โดยพัฒนาภายใต้มาตรฐานของ Open Source License

2.2.1 หลักการทำงานของ ICU


- 2.2.1.1 กำหนดข้อความที่เราต้องการแยกคำออก ในเทคโนโลยี ICU เราสามารถกำหนดบทความได้โดยไม่จำกัดความยาวของบทความ แต่ไม่ควรใช้บทความที่มีความยาวมากเกินไป เช่น บทความที่มีความยาวหลายๆ หน้ากระดาษ A4 หรือหนังสือทั้งเล่ม เป็นต้น เพราะจะทำให้เสียเวลาในการประมวลผลค่อนข้างมาก
- 2.2.1.2 กำหนดรูปแบบของภาษาที่ต้องการใช้แยกคำ เช่น US, TH เป็นต้น
- 2.2.1.3 กำหนดสัญลักษณ์ที่ใช้แบ่งคำ เช่น , - เป็นต้น
- 2.2.1.4 การเข้ารหัส เทคโนโลยี ICU จะนำเอาบทความที่รับเข้ามาไปเข้ารหัสให้อยู่ในรูปแบบยูนิโคด (Uni-Code) แล้วนำไปเปรียบเทียบกับข้อมูลที่เก็บไว้ในตารางเปรียบเทียบคำของ ICU ซึ่งปัจจุบันตารางที่ใช้ในการเปรียบเทียบข้อมูลของ ICU ที่นิยมใช้งานและมีความแม่นยำที่สุด จะเป็นเทคโนโลยี ICU ที่ถูกพัฒนาโดยบริษัท IBM
- 2.2.1.5 ประมวลผลข้อมูลที่รับเข้ามา โดยจะได้เอาที่พหุเป็นคำต่างๆ ที่ถูกค้นด้วยเครื่องเครื่องหมายที่เรากำหนด

2.2.2 ขอบเขตความสามารถของเทคโนโลยี ICU

- 2.2.2.1 ภาษาที่สามารถใช้เทคโนโลยี ICU ได้ จำต้องเป็นภาษาที่อยู่ภายใต้มาตรฐานของรูปแบบยูนิโคด (Uni-Code) เท่านั้น
- 2.2.2.2 ภาษาที่เทคโนโลยี ICU รองรับจะต้องเป็นภาษาที่เป็นไปตามอนุสัญญาและมาตรฐานของภูมิภาคหรือประเทศเท่านั้น
- 2.2.2.3 การจัดรูปแบบของวันที่ และรูปแบบอัตราเงินจะเป็นไปตามข้อมูลพื้นที่ของภาษาที่เลือกใช้งาน
- 2.2.2.4 การคำนวณวันที่และเวลาจะขึ้นอยู่กับรูปแบบปฏิทินของภาษาที่เลือก ในกรณีที่ไม่มีรูปแบบของปฏิทินตามรูปแบบภาษาที่เลือก หรือไม่ได้กำหนดรูปแบบปฏิทิน ICU จะเลือกใช้ปฏิทินในรูปแบบคริสต์ศักราชอัตโนมัติ

2.3 ระบบฐานข้อมูลเชิงสัมพันธ์ (Relational Database)

ระบบฐานข้อมูลเชิงสัมพันธ์เป็นฐานข้อมูลที่ใช้โมเดลเชิงสัมพันธ์ (Relational Database Model) คือ ภายในระบบฐานข้อมูลจะประกอบด้วย ตาราง (Relation) ในแต่ละตารางแบ่งออกเป็น 2 ส่วนคือ แถว (Tuple) และคอลัมน์ (Attribute) โดยแต่ละคอลัมน์ ก็จะมีชนิดข้อมูล (Data type) และคีย์ (Key) เป็นตัวกำหนดรูปแบบของข้อมูลที่จะเก็บข้อมูล หลักการทำงานของระบบฐานข้อมูลเชิงสัมพันธ์ จะอาศัยหลักการทางคณิตศาสตร์ในเรื่องของ Set เพื่อใช้สำหรับการบริหารจัดการข้อมูลต่างๆ ที่อยู่ภายใต้ฐานข้อมูลเชิงสัมพันธ์



ภาพ 2.2 แสดงส่วนประกอบของฐานข้อมูลเชิงสัมพันธ์

2.4 ภาษา SQL (Structured Query Language)

SQL เป็นภาษามาตรฐานที่ใช้ติดต่อกับระบบฐานข้อมูลเชิงสัมพันธ์ (Relational Database Management System) หรือ RDBMS ซึ่ง ANSI ได้ประกาศออกมาอย่างเป็นทางการ ดังนั้น ผู้ที่ทำงานกับฐานข้อมูลในปัจจุบันจำเป็นต้องรู้ เนื่องจากระบบฐานข้อมูลที่มีอยู่ในปัจจุบันเกือบทั้งหมดเป็นระบบฐานข้อมูลแบบ RDBMS SQL สามารถแบ่งคำสั่งออกเป็น 4 กลุ่ม คือ

- 2.4.1 Data Manipulate (DML) เป็นคำสั่งจัดการข้อมูล ได้แก่ Insert, Update, Delete, Rollback, Commit
- 2.4.2 Data Definition (DDL) เป็นคำสั่งจัดการกับไฟล์ในฐานข้อมูล ได้แก่ Create, Alter, Drop
- 2.4.3 Query เป็นคำสั่งการเรียกดูข้อมูล คือ Select
- 2.4.4 Data Control เป็นคำสั่งจัดการความปลอดภัย

2.5 การค้นหาข้อมูลใน RDBMS โดยทั่วไป

การค้นหาข้อมูลบนฐานข้อมูล RDBMS จะกระทำผ่านภาษา SQL (Structured Query Language) โดยใช้คำสั่งในกลุ่มของ Query เป็นคำสั่งการเรียกดูข้อมูล คือ Select

- 2.5.1 Like เป็นคำหลักที่ใช้สำหรับการระบุเงื่อนไขการเลือกข้อมูลในตาราง (Relation) โดยทำการค้นหาข้อความที่ระบุภายในคอลัมน์ (Attribute) ที่กำหนด

SELECT Attribute FROM Relation WHERE LIKE Attribute '%Keyword%'

โดยภายใต้คำสั่ง Like เราสามารถกำหนดรูปแบบสัญลักษณ์ที่ใช้แทนตัวอักษรต่างๆ นอกเหนือจากที่ผู้ใช้กำหนดได้ คือ

- 2.5.1.1 % ใช้แทนอักขระตัวอะไรก็ได้และมีกี่ตัวก็ได้

- 2.5.1.2 _ ใช้แทนตัวอักษรหนึ่งตัวตัวอะไรก็ได้

แต่ปัญหาหลักในการค้นหาข้อมูลแบบนี้คือ RDBMS จะ คืนค่า(Return) ทั้งหมดที่ค้นหาเจอออกมา โดยไม่ได้คำนึงถึงระดับความสำคัญของข้อมูลที่ใช้ต้องการ

2.5.2 Full Text Search

Full Text Search คือเทคโนโลยีที่ใช้ในการค้นหาข้อมูลในระบบฐานข้อมูลเชิงสัมพันธ์อีกเทคโนโลยีหนึ่ง ที่ถูกพัฒนามาเพื่อใช้ในการค้นหาข้อมูลเพื่อตอบสนองความต้องการของผู้ใช้ข้อมูล แต่เทคโนโลยีนี้ไม่ได้มีอยู่ในระบบฐานข้อมูลเชิงสัมพันธ์ทุกระบบ จะมีบางระบบฐานข้อมูลเท่านั้นที่สามารถใช้เทคโนโลยีนี้ได้ เช่น Oracle, MSSQL MySQL เป็นต้น

แต่ปัจจุบันเทคโนโลยีเหล่านี้ยังมีปัญหาด้านการใช้งานอยู่ คือใช้ระยะเวลาในการประมวลผลข้อมูลค่อนข้างนาน ราคาสูง และเทคโนโลยีนี้ก็ยังไม่ได้เป็นมาตรฐานของระบบฐานข้อมูลเชิงสัมพันธ์ ทำให้รูปแบบการใช้งาน Full Text Search ของฐานข้อมูลเชิงสัมพันธ์แต่ละผลิตภัณฑ์ก็มีรูปแบบในการใช้งานที่แตกต่างกัน ทำให้ยากต่อการจะศึกษา และนำมาใช้งานจริง

2.6 ตัวอย่างการใช้งานเทคโนโลยีบนฐานข้อมูล MSSQL ของ Microsoft

2.6.1 Contains

```
SELECT Attribute FROM Relation WHERE CONTAINS(Attribute, N'Keyword')
```

การค้นหาข้อมูลโดยใช้คำสั่ง Contains จะป้อนคำหลัก (Keyword) ที่ต้องการค้นหาเป็นคำๆ เท่านั้น ไม่สามารถป้อนเป็นข้อความได้ และรูปแบบการค้นหาข้อมูลของคำสั่ง Contains ระบบฐานข้อมูลจะค้นหาเฉพาะคำที่มีความหมายตรงกับคำหลัก (Keyword) เท่านั้น ตัวอย่างเช่น ต้องการหาคำว่า Song แต่ในฐานข้อมูลไม่มีข้อมูลคำว่า Song แต่มีคำว่า Songs ผลลัพธ์ที่ได้ คือ **ไม่พบข้อมูลที่ต้องการค้นหา** แต่หากต้องการให้ค้นหาข้อมูลโดยพิจารณาคำที่มีความหมายใกล้เคียงคำหลัก (Keyword) ด้วย ให้ใช้คำสั่ง **FORMSOF** ช่วยในการค้นหา ตัวอย่างเช่น

```
SELECT Attribute FROM Relation
WHERE CONTAINS(Attribute, N' FORMSOF (INFLECTIONAL, Keyword) ');
```

2.6.2 Freetext

```
SELECT Attribute FROM Relation WHERE FREETEXT(Attribute, N'Keyword');
```

การค้นหาข้อมูลโดยใช้คำสั่ง Freetext จะมีรูปแบบในการค้นหาข้อมูลที่คล้ายๆ กับ คำสั่ง Contains แต่สามารถป้อนคำหลัก (Keyword) เป็นข้อความได้

2.6.3 Containstable

```

SELECT Attribute
FROM Relation
INNER JOIN CONTAINSTABLE(Relation, Attribute 'Keyword') AS KEY_TBL
ON Relation. Attribute = KEY_TBL.[KEY]

```

การค้นหาข้อมูลโดยใช้คำสั่ง Containstable จะมีรูปแบบในการค้นหาข้อมูลที่คล้ายๆ กับ คำสั่ง Contains แต่ในคำสั่ง Containstable จะมีการทำจัดลำดับความสำคัญของข้อมูล (Ranking) ที่ค้นหาพบด้วย โดยจะเรียงลำดับความสำคัญของข้อมูลตามคอลัมน์ (Attribute) ที่ถูกกำหนดให้เป็น KEY_TBL

2.7 งานวิจัยที่เกี่ยวข้อง

สิทธิโชค ปัญญาอุษชัย และตีพณินุชิตประสิทธิ์ชัย (2552) ศึกษาเรื่อง ระบบการค้นคืนสารสนเทศโดยใช้เทคนิค N-Gram มีวัตถุประสงค์ในการศึกษา เพื่อพัฒนาระบบการค้นคืนสารสนเทศโดยใช้เทคนิค N-Gram เพื่อให้ได้ข้อมูลสารสนเทศที่ตรงตามความต้องการของผู้ใช้งาน และได้ทำการประเมินประสิทธิภาพการให้ค่าความแม่นยำ Precision และค่าความถูกต้อง Recall ในการค้นคืน โดยผล ได้จากการประเมินประสิทธิภาพของระบบ พบว่ามีค่าเฉลี่ยรวมอยู่ในระดับดี และระบบสามารถนำไปใช้งานได้จริง

วิไลพร เลิศมหาเกียรติ (2553) ศึกษาเรื่อง การค้นคืนสารสนเทศแบบสหความสัมพันธ์ตามหมวดหมู่ระบบทศนิยมดิวอี้ โดยวัตถุประสงค์เพื่อศึกษา วิเคราะห์ข้อมูลแบบสหความสัมพันธ์และพัฒนาระบบขั้นตอนวิธีการค้นคืนสารสนเทศแบบสหความสัมพันธ์ ภายใต้กรอบความรู้การจัดการหมวดหมู่ระบบทศนิยมดิวอี้แบบสหความสัมพันธ์ (DDC-MR) โดยวิเคราะห์ความสัมพันธ์ของคำสำคัญในเอกสาร และคำค้นของผู้ใช้กับกรอบความรู้ระบบทศนิยมดิวอี้ คำนวณน้ำหนักและหาสัดส่วนความสัมพันธ์ของเนื้อหาในแต่ละหมวด เพื่อนำมาแสดงเป็นสัดส่วนของความสัมพันธ์สำหรับใช้เปรียบเทียบความคล้ายคลึงระหว่างคำสำคัญในเอกสาร และในส่วนคำค้นของผู้ใช้ ซึ่งการนำเทคนิคการวิเคราะห์หมวดหมู่แบบสหความสัมพันธ์ จะทำให้สามารถนำเสนอเอกสารที่มีรูปแบบสหความสัมพันธ์ของเนื้อหาที่ตรงกัน หรือมีความคล้ายคลึงกับรูปแบบสหความสัมพันธ์ของคำค้นของผู้ใช้ และสามารถใช้คำค้นในภาษาใด ภาษาหนึ่ง เพื่อค้นหาเอกสารจากฐานข้อมูลสากลที่มีการ

จัดหมวดหมู่ตามระบบทศนิยมคิวอี้ได้ และได้มีการทดสอบโดยมีค่าความแม่นยำ (Precision) เท่ากับ 0.74

นิพนธ์ เจริญกิจการ (2544) ได้นำเสนองานวิจัยระบบการค้นคืนเอกสารภาษาไทยด้วยเทคนิคขั้นสูง ระยะที่ 2 โดยมีวัตถุประสงค์เพื่อศึกษาฐานสารสนเทศภาษาไทย และคุณสมบัติต่างๆ ของฐานสารสนเทศไทยและวิธีการค้นคืนภาษาไทยด้วยเทคนิคขั้นสูง การวิจัยนี้จะเน้นไปที่การค้นคืนในแบบแนวความคิด เทคนิคที่ได้รับการยอมรับอย่างกว้าง ขวางเช่น vector space และ latent semantic indexing เป็นต้น

นพดล หมื่นโพ (2548) ได้ศึกษาเรื่องการเพิ่มประสิทธิภาพระบบค้นคืนข้อมูลสารสนเทศภาษาไทยด้วยนามวลีผันแปรและออนโทโลยี มีวัตถุประสงค์ในการศึกษา เพื่อศึกษาลักษณะและปัญหาในการวิเคราะห์โครงสร้างนามวลีภาษาไทยและการใช้คำอ้างอิงในภาษาไทย และพัฒนาเทคนิคเพื่อเพิ่มประสิทธิภาพการหาตัวแทนเอกสารและขยายคำค้นสำหรับระบบค้นคืนข้อมูลสารสนเทศที่เหมาะสมกับเอกสารภาษาไทย ที่มีความถูกต้องสูงและนำไปใช้ได้อย่างมีประสิทธิภาพ จากการศึกษานี้พบว่า การใช้นามวลีผันแปรร่วมกับนิพจน์ระบุนามเป็นตัวแทนเอกสารและใช้คำกับนิพจน์ระบุนามและนามวลีร่วมกับคำที่ได้จากการขยายคำค้นเป็นตัวแทนคำค้น ทำให้ประสิทธิภาพของระบบค้นคืนเอกสารดีขึ้น ค่าความถูกต้อง สูงขึ้นเฉลี่ย 103%

พงษ์ปัญญา จงจักรพันธ์ (2542) ได้ศึกษาเรื่องระบบค้นคืนข้อมูลสารสนเทศโดยใช้ภาษาธรรมชาติ มีวัตถุประสงค์ในการศึกษา เพื่อพัฒนาระบบค้นคืนสารสนเทศโดยใช้ภาษาธรรมชาติ โดยระบบจะทำการวิเคราะห์และแปลงคำร้องของผู้ใช้ด้วยวิธีการเก็บรวบรวมข้อมูลแบบ non-deterministic top-down โดยใช้รูปแบบไวยากรณ์เป็นตัวช่วยในการค้นหาความหมายร่วมกับพจนานุกรมฐานความรู้ และใช้ mSQL เป็นฐานข้อมูลในการศึกษาครั้งนี้