

## บทที่ 2

### แนวคิด ทฤษฎีและเอกสารที่เกี่ยวข้อง

ในการค้นคว้าอิสระเรื่อง “การพัฒนาฐานข้อมูล เพื่อจัดทำ สารสนเทศสนับสนุนการตัดสินใจของผู้บริหารด้านเทคนิค พื้นที่ภาคเหนือตอนบน บริษัท ทีทีแอนด์ที จำกัด (มหาชน) ” ผู้ค้นคว้าได้ศึกษาจากเอกสารและงานวิจัยที่เกี่ยวข้อง ซึ่งสรุปสาระสำคัญได้ดังนี้

#### 2.1 การคัดแยกข้อมูล

Raymond J. Mooney (2009) ได้อธิบายในเอกสารการสอนไว้ว่า Information Extraction (IE) หมายถึงกระบวนการในการสกัดสารสนเทศ ออกจากเอกสารที่เราสนใจ ตัวอย่างเช่น หากเราอ่านหนังสือพิมพ์ 1 เล่ม เราคงเลือกอ่านเฉพาะคอลัมน์ที่สนใจ และในคอลัมน์ที่เราสนใจนั้น อาจยาวมาก ซึ่งหลายท่านอาจจะอ่านเฉพาะย่อหน้า หรือจุดที่สนใจเท่านั้น ดังนั้น หากเราจะทำอย่างไรให้คอมพิวเตอร์เข้าใจและสกัดเฉพาะสารสนเทศ ที่เราสนใจ เราอาจต้องใช้เทคนิค หรือ Algorithm ที่จะทำให้คอมพิวเตอร์เข้าใจเนื้อหาข้อเอกสารข้อความ และสกัดเอาสิ่งที่เราสนใจออกมา

หลักการของ IE นั้น ที่เพื่อสกัดสารสนเทศ หรือข้อมูลที่เราสนใจ ออกจากเอกสารประเภทตัวอักษร ทั้งในเอกสารที่มีรูปแบบมีโครงสร้างบางส่วน (Semi-structure) และเอกสารที่ไม่มีโครงสร้าง (Unstructured) โดยทำการแปลงเอกสารที่ได้กล่าวมาแล้ว ไปสู่ฐานข้อมูลที่มีโครงสร้าง ตัวอย่างงานด้านต่าง ๆ ที่นำ IE ไปใช้ดังนี้

- 1) Newspaper articles หาสารสนเทศที่สนใจ จากหนังสือพิมพ์โดยอัตโนมัติ
- 2) Web pages หาสารสนเทศที่สนใจจาก WebPage ตัวอย่างเช่น Google Bot เป็นต้น
- 3) Newsgroup messages หาสารสนเทศจากข้อความในกลุ่ม เช่น สกัดหาข้อมูลจาก Mail เพื่อหาข้อมูลที่สนใจ
- 4) Classified ads หาสารสนเทศเฉพาะโฆษณาที่สนใจจากโฆษณาทั้งหมด

ตัวอย่างเช่น CIA และ NSA ใช้ IE ในการสกัดหาแนวโน้ม หรือการส่งสัญญาณ จากตัวอักษรผ่านทางหนังสือพิมพ์ทุกฉบับ เว็บไซต์ที่ต้องสงสัย หรือเอกสารอื่น ๆ เพื่อหาแนวโน้มการโจมตีจากผู้ก่อการร้าย เป็นต้น

การ Extraction เอกสาร HTML นั้น อาจเรียกอีกอย่างหนึ่ง ได้ว่า Web Extraction ซึ่งส่วนใหญ่จะเป็นการสกัดสารสนเทศจากเอกสาร HTML (Semi-structured) หรืออาจเรียกได้ว่า wrapper หรือ screen scraping

Website ที่จะถูกสกัดสารสนเทศได้นั้น จะต้องมี Template ที่ชัดเจน เช่น HTML จะใช้เทคนิค regular expression pattern ในการสกัดเอกสาร เช่น

Amazon list price:

Pre-filler pattern: “<b>List Price:</b> <span class=listprice>”

Filler pattern: “\$d+(.d{2})?b”

แต่ปัญหาที่มักจะเกิดขึ้นนี้คือ ภาษาของเอกสารนั้นๆ หากเป็นภาษา English จะมีข้อดี คือ คำเต่าلةจะถูกแบ่งด้วยช่องว่าง (Space) แต่สำหรับภาษาไทยนั้นเป็นเรื่องยาก เนื่องจากเป็นภาษาที่เขียนติดๆ กันจึงทำให้ต้องใช้หลักการ NLP (Natural Language Processing) เข้ามาช่วย ตัวอย่างเช่นคำว่า ตากลม (ตา-กลม) กับ ตากลม (ตา-ก-ล-ม) นั้น เป็นเรื่องยากที่จะให้คอมพิวเตอร์เข้าใจ จึงต้องใช้หลักการทาง NLP เข้ามาช่วย อาจใช้ n-Grams หรือการคุณค่าไกล์เคียงจาก Corpus หรือใช้เทคนิค Dictionary ฯลฯ เพื่อให้สามารถสกัดเป็นคำภาษาไทยได้อย่างถูกต้องและถูกความหมาย


## 2.2 คลังข้อมูล

Han, Jiawei. and Kamber, Micheline. (2001) ได้อธิบายว่า คลังข้อมูล หมายถึงฐานข้อมูลเชิงสัมพันธ์ที่ถูกออกแบบให้เก็บข้อมูลการจัดการ และมีคุณสมบัติต่างๆ เพื่อใช้สำหรับช่วยสนับสนุนการตัดสินใจ โดยคลังข้อมูลมีคุณลักษณะที่ต่างจากฐานข้อมูลเชิงปฏิบัติการ เช่น หน้าที่และการจัดเก็บที่แบ่งแยกกันอย่างชัดเจน ดังนี้

- 1) Subject-Oriented เป็นการมองข้อมูลที่มุ่งเน้นประเด็นสำคัญๆ ของข้อมูล เช่น ข้อมูลลูกค้า ข้อมูลสินค้า ข้อมูลการขาย มากกว่าการที่จะมุ่งเน้นในงานที่มีการประมวลผลแบบวันต่อวัน คลังข้อมูลจะมุ่งเน้นในเรื่องของโครงสร้างสำหรับการวิเคราะห์ เพื่อสนับสนุนการตัดสินใจ
- 2) การรวมรวมข้อมูล เป็นการรวมรวมข้อมูลจากหลายแหล่ง ข้อมูลที่แตกต่างกัน เช่น ฐานข้อมูลเชิงสัมพันธ์ เท็กซ์ไฟล์ และออนไลน์ทรานเซกชันเรคอร์ด เป็นต้น โดยอาศัย

เทคนิคการรวบรวม และทำให้ข้อมูลสมบูรณ์ เพื่อให้ได้โครงสร้างข้อมูลมีความมั่นคง น่าเชื่อถือ เพื่อสามารถนำไปใช้ในการสนับสนุนการตัดสินใจ ได้

- 3) Time-Variant ข้อมูลที่จัดเก็บในคลังข้อมูลเป็นสารสนเทศที่ได้จากการเก็บข้อมูลที่สำคัญของโครงสร้างคลังข้อมูล ทั้งในส่วนที่แสดงนัย และแสดงอย่างชัดเจน
- 4) Nonvolatile เป็นการพิจารณาแหล่งจัดเก็บคลังข้อมูล ที่จัดเก็บแยกจากฐานข้อมูล ทราบเชิงชั้น ซึ่งการแยกแหล่งจัดเก็บนี้มีผลทำให้คลังข้อมูลไม่จำเป็นต้องมีการประมวลผล ทราบเชิงชั้นทุกครั้ง ที่มีการเรียกคืนมา และข้อมูลมีลักษณะอ่อนไหว อย่างเดียว โดยจะมีกระบวนการที่สำคัญคือ การอ่านข้อมูลเข้าสู่หน่วยความจำ และการเข้าถึงข้อมูลในหน่วยความจำ



รูป 2.1 แสดงสถาปัตยกรรมคลังข้อมูล

ที่มา: Han, Jiawei. and Kamber, Micheline. (2001 : Figure 2.12)

### สถาปัตยกรรมของคลังข้อมูล ดังแสดงในรูป 2.1 แบ่งเป็น 3 ชั้นคือ

- 1) ชั้นล่าง (Bottom Tier) เป็นเซิร์ฟเวอร์คลังข้อมูล ที่ส่วนใหญ่จะเป็นระบบฐานข้อมูลเชิงสัมพันธ์ ข้อมูลของคลังข้อมูลได้มามาจากฐานข้อมูลปฏิบัติการ (Operational Database) และแหล่งข้อมูลภายนอกผ่านโปรแกรมเกตเวย์ (Gateways) สนับสนุนการทำงานของระบบ การจัดการฐานข้อมูล และอนุญาตให้เครื่องลูกข่าย (Client) ทำการประมวลผลคำสั่งเอกสาร SQL ในฝั่งเซิร์ฟเวอร์ ตัวอย่างโปรแกรมเกตเวย์ เช่น ODBC (Open Database Connection) OLE-DB (Open Linking and Embedding for Database) และ JDBC (Java Database Connection) เป็นต้น
- 2) ชั้นกลาง (Middle Tier) เป็นโอลเดลเพซิร์ฟเวอร์ ที่มีการประยุกต์ใช้ โอลเดลเพซิสัมพันธ์ ซึ่งเป็นส่วนขยายของ Relational DBMS โดยเชื่อมการทำงานของโครงสร้างข้อมูลหลายมิติ กับการทำงานของความสัมพันธ์มาตรฐาน
- 3) ชั้นบน (Top Tier) เป็นเครื่องไคลเอนท์ ที่ประกอบด้วยเครื่องมือสำหรับคำานวณ รายงาน วิเคราะห์ รวมถึงเครื่องมือทางค้าตัวใบหนึ่น

### โครงสร้างของคลังข้อมูล

Reed Jacobson (2000) ได้กล่าวว่าโครงสร้างของคลังข้อมูลประกอบด้วย 2 โครงสร้างที่สำคัญคือ

- 1) ตารางหลัก (Fact Table) เป็นตารางในคลังข้อมูลเชิงสัมพันธ์ที่เก็บค่า รายละเอียดต่างๆ ประกอบด้วยคีย์คอลัมน์ทำหน้าที่เป็นคีย์หลัก และค่าหน่วยวัด (Measure) หรือ ข้อเท็จจริง (Fact) โดยจะจัดเก็บรายละเอียดระดับล่างสุดเท่านั้น ดังตาราง 2.1

ตาราง 2.1 แสดงตัวอย่างโครงร่างแนวคิดของตารางหลักการขาย

State	Product	Month	Units	Dollars
WA	Colony Cranberry Muffins	January	3	7.95
WA	Sphinx Bagels	January	4	7.32
OR	Colony Cranberry Muffins	January	3	7.95
OR	Sphinx Bagels	January	4	7.32
WA	Colony Cranberry Muffins	February	16	42.40

ตาราง 2.2 แสดงตัวอย่าง โครงสร้างแท็บจิงของตารางหลักการขาย

STATE_ID	PROD_ID	Month	Sales Units	Sales Dollars
1	589	1/1/1998	3	7.95
1	1218	1/1/1998	4	7.32
2	589	1/1/1998	3	7.95
2	1218	1/1/1998	4	7.32
1	589	2/1/1998	16	42.40

จากตัวอย่าง โครงสร้างแนวคิดของตารางหลักการขายประกอบด้วย 5 คอลัมน์ที่เก็บ State, Product, Month, Units และ Dollars ตามลำดับ โดยที่สามคอลัมน์แรกประกอบด้วย State, Product และ Month เป็นคีย์คอลัมน์ ส่วนอีกสองคอลัมน์คือ Units และ Dollars เป็นค่าหน่วยวัด ซึ่งปกติการจัดเก็บข้อมูลจริงจะมีรูปแบบดังตาราง 2.2 ที่แสดงตัวอย่าง โครงสร้างแท็บจิงของตารางหลักการขาย คือจัดเก็บค่าคีย์เป็นตัวเลขเพื่อความรวดเร็วและลดขนาดของฐานข้อมูล

- 2) ตาราง ไดเมนชัน (Dimension Table) เป็นตารางในคลังข้อมูลเชิงสัมพันธ์ที่ประกอบด้วย แคลวแต่ละแคลวสำหรับสมាជิกของ ไดเมนชัน ซึ่งมีความเกี่ยวข้องกับลำดับขั้นความสัมพันธ์ ในคลังข้อมูล คีย์คอลัมน์ของตาราง ไดเมนชันจะต้องประกอบด้วยค่าเฉพาะสำหรับ แต่ละ สมាជิกของ ไดเมนชัน เรียกว่าคีย์หลัก ทำหน้าที่เชื่อมต่อ กันระหว่างตารางหลักและตาราง ไดเมนชัน ดังตาราง 2.3

ตาราง 2.3 แสดงตัวอย่าง โครงสร้างแนวคิดของตาราง ไดเมนชันสินค้า

PROD_ID	Product Name	Subcategory
589	Colony Cranberry Muffins	Muffins
592	Colony Cranberry Muffins	Muffins
1218	Sphinx Bagels	Bagels

จากตัวอย่าง โครงสร้างแนวคิดของตาราง ไดเมนชันสินค้าประกอบด้วย 3 คอลัมน์ที่เก็บ PROD\_ID, Product Name, Subcategory ตามลำดับ โดยที่คอลัมน์ PROD\_ID ทำหน้าที่เป็นคีย์หลัก ของตาราง ไดเมนชันสินค้า และมีความสัมพันธ์กับ โครงสร้างแนวคิดแท็บจิงของตารางหลักการขาย

แบบหนึ่งต่ออีก (One-to-Many Relationship) คือคอลัมน์นึงจะถูกเรียกว่า คีย์ภายนอก (Foreign Key)


### 2.3 คิวบ์ข้อมูล

Han, Jiawei, and Kamber, Micheline. (2001) ได้อธิบายว่า คิวบ์ข้อมูล เป็นโมเดลที่แสดงมุมมองของข้อมูลได้ในหลายมิติ สร้างตามหลักตรรกวิทยา หรือตามเหตุผลที่จำยอมให้แอพพลิเคชัน โภคเงยน์เรียกรับค่าต่างๆ ได้ถ้าค่านั้นถูกสรุปรวมไว้ในคิวเบล็ว โดยที่คิวจะมีลักษณะคล้ายตารางหลัก ประกอบด้วยคอลัมน์สำหรับแต่ละคีย์หลักของ โภคเงยน์ชัน คอลัมน์สำหรับค่าหน่วยวัด และการรวมค่าสมาชิกที่อาจเป็นไปได้เฉพาะสมาชิกในระดับล่างสุดของแต่ละ โภคเงยน์ชันเท่านั้น นอกจากนี้ คิวบ์ข้อมูลยังประกอบด้วยสมาชิก ต่างๆ จากทุกระดับของ โภคเงยน์ชันด้วย

### 2.4 เครื่องร่างของมัลติโภคเงยน์ชันนอล


คลังข้อมูลใช้แบบจำลองมัลติโภคเงยน์ชันนอลสำหรับออกแบบความสัมพันธ์ของคลังข้อมูล เพื่อให้ข้อมูลอยู่ในรูปแบบที่เหมาะสมสำหรับประมวลผล โภคเงยน์ ประกอบด้วย 3 เครื่องร่างดังต่อไปนี้

- 1) เครื่องร่างดาว (Star Schema) เป็นแบบจำลองพื้นฐานของคลังข้อมูล ประกอบด้วย ตารางหลัก และตาราง โภคเงยน์ โดยที่ตาราง โภคเงยน์ที่เชื่อมโยงกับตารางหลักมีลักษณะคล้ายดาว ดังรูป 2.2




รูป 2.2 แสดงเครื่องร่างดาวของคลังข้อมูลการขาย

- 2) เคาร่างเกล็ดหิมะ (Snowflake Schema) เป็นแบบจำลองคลังข้อมูลที่ต่างไปจากเคาร่างดาวเนื่องจากตารางไดเมนชันบางตารางจะถูกน้อมัลไวซ์ (Normalized) เพื่อลดความซ้ำซ้อนและประหยัดพื้นที่จัดเก็บข้อมูล ทำให้มีตารางเพิ่มขึ้น แต่จำเป็นต้องมีการรวมตารางในภายหลังทำให้เสียเวลาในการประมวลผลเพิ่มขึ้น ดังรูป 2.3



รูป 2.3 แสดงเคาร่างเกล็ดหิมะของคลังข้อมูลการขาย

- 3) เคาร่างกลุ่มดาว (Fact Constellation Schema) เป็นแบบจำลองคลังข้อมูลที่มี ตารางหลักมากกว่า 1 ตาราง และมีการใช้ตารางไดเมนชันร่วมกัน ซึ่งเคาร่างนี้อาจประกอบด้วยหลายๆ เคาร่างดาว ดังรูป 2.4



รูป 2.4 แสดงเคาร่างกลุ่มดาวของคลังข้อมูลการขาย และการขนส่ง