



บทที่ 2

## การเรียงลำดับข้อมูล

### 2.1 การเรียงลำดับข้อมูลโดยคอมพิวเตอร์

การเรียงลำดับข้อมูลโดยคอมพิวเตอร์ คือ วิธีการนำเอาข้อมูลมาเรียงต่อกันตามค่าคีย์ของข้อมูลอันหนึ่ง จากค่าน้อยไปค่ามาก หรือ จากค่ามากไปค่าน้อย ข้อมูลจะถูกจัดเรียงลำดับตามค่าของคีย์ข้อมูล ซึ่งถ้าค่าของคีย์ข้อมูลเป็นค่าตัวเลข การเรียงลำดับเรียงตามค่าตัวเลขของคีย์ ส่วนคีย์ที่เป็นชุดตัวอักษร การเรียงลำดับเรียงตามค่าลำดับตัวอักษร (Collating Sequence) ที่เครื่องคอมพิวเตอร์นั้นใช้

การเรียงลำดับข้อมูล แบ่งเป็น 2 ประเภท คือ

1. การเรียงลำดับภายใน (Internal Sorting) เป็นการเรียงลำดับซึ่งข้อมูลทั้งหมดสามารถใส่ลงในหน่วยความจำหลักได้ทั้งหมด การทำงานเกิดขึ้นในหน่วยความจำหลักซึ่งสามารถทำการ Random Access ข้อมูลได้

2. การเรียงลำดับภายนอก (External Sorting) เป็นการเรียงลำดับข้อมูลขนาดใหญ่ซึ่งข้อมูลทั้งหมด ไม่สามารถใส่ลงในหน่วยความจำได้ ต้องเก็บอยู่ในหน่วยความจำสำรองบางส่วน เช่น จานแม่เหล็ก เทปแม่เหล็ก

อัลกอริทึม (Algorithm) ของวิธีการเรียงลำดับข้อมูล ได้มีการพัฒนามาช้านาน ซึ่งก็มีหลายวิธี โดยผู้ต้องการใช้ สามารถเลือกวิธีการทำงาน และนำไปพัฒนาใช้งาน เทคนิควิธีการเรียงลำดับข้อมูลที่ยอมรับใช้กัน เช่น การเรียงลำดับแบบลอยตัว (Bubble Sort), อินเซชันซอร์ต (Insertion Sort), ควิกซอร์ต (Quicksort), เชลลซอร์ต (Shellsort), ฮีปซอร์ต (Heapsort) แต่ละอัลกอริทึมการเรียงลำดับข้อมูลมีประสิทธิภาพแตกต่างกัน ประสิทธิภาพของการเรียงลำดับก็คือจำนวนเวลาที่ใช้ในการทำงานของอัลกอริทึม (Actual Execution Time of Algorithm) การออกแบบของอัลกอริทึมการเรียงลำดับข้อมูลมีวัตถุประสงค์หลักใหญ่คือเพื่อลดการแลกเปลี่ยนข้อมูล ลดการเคลื่อนย้ายข้อมูล เพราะการสลับตำแหน่งที่อยู่ข้อมูลใช้เวลาในการทำงานมาก

หลักในการพิจารณาเพื่อเลือกวิธีการเรียงลำดับข้อมูลที่จะใช้

1. เวลาที่จะใช้ในการพัฒนาโปรแกรมมาใช้งาน (Programming Time)
2. เวลาที่ใช้ในการทำงานของโปรแกรม (Execution Time of the Program)
3. ขนาดของหน่วยความจำหลัก และหน่วยความจำสำรองที่โปรแกรมต้องการใช้ (Memory and Auxiliary Space Need)

พบว่าในบางครั้งนั้น ความพยายามที่จะปรับปรุงประสิทธิภาพของวิธีการเรียงลำดับ จะทำให้โปรแกรมมีความซับซ้อนมากขึ้น (Complexity) และการใช้ตัวแปรมากขึ้น ทำให้ต้องใช้หน่วยความจำในการประมวลผลมากขึ้นเกิดความสิ้นเปลือง (Overhead) มากขึ้นแก่ซอฟต์แวร์ เพราะต้องนำคำสั่งมาและประมวลผลคำสั่งของโปรแกรมที่มีขนาดใหญ่ขึ้น ซึ่งถ้าหากว่า ระบบที่ใช้ (Machine Environment) อนุญาตให้ได้สำหรับขนาดหน่วยความจำที่เพิ่มขึ้นแล้ว การเพิ่มความซับซ้อนของโปรแกรมนั้นทำให้สามารถเพิ่มประสิทธิภาพได้ ก็นับได้ว่าเป็นการแลกเปลี่ยนที่มีค่า (Worth Trade Off)


## 2.2 อัลกอริทึมการเรียงลำดับข้อมูลควิกซอร์ต

ควิกซอร์ต เป็น อัลกอริทึมการเรียงลำดับข้อมูลภายในที่มีประสิทธิภาพและเป็นที่ยอมรับกันมากที่สุด อัลกอริทึมควิกซอร์ต คิดค้นโดย C.A.R Hoare ในปี ค.ศ. 1961

ควิกซอร์ต เป็นเทคนิคการเรียงลำดับที่ได้รับการยอมรับว่ามีประสิทธิภาพ เพราะใช้เวลาการทำงานน้อย และใช้เนื้อที่หน่วยความจำในการประมวลผลน้อย

ลักษณะการทำงานของควิกซอร์ต เป็นวิธีการเรียงลำดับข้อมูลที่อาศัยหลักของการแบ่งส่วนข้อมูล (Partition-Exchange Sort) คือในตอนแรกการแบ่งส่วนข้อมูลจะทำให้ชุดลำดับของข้อมูลทั้งหมด ถูกแบ่งออกเป็น 2 ส่วน โดยที่ค่าคีย์ทั้งหมดที่อยู่ในส่วนแรกมีค่าคีย์ข้อมูลน้อยกว่าคีย์ทั้งหมดที่อยู่ในส่วนที่สอง ซึ่งจำนวนคีย์ในแต่ละส่วนไม่จำเป็นต้องเท่ากันต่อไป แต่แต่ละส่วนจะถูกแบ่งออกไปเรื่อยๆ โดยใช้วิธีการเดียวกัน จนกระทั่งค่าคีย์ทั้งหมดได้ถูกเรียงลำดับแล้ว แต่ละขั้นตอนของวิธีการดำเนินงาน จุดประสงค์คือ เพื่อที่จะวางข้อมูลที่เลือกขึ้นมาในแต่ละขั้นตอนลงในตำแหน่งที่แท้จริงของมัน (คือตำแหน่งที่ข้อมูลจะอยู่เมื่อได้เรียงลำดับเรียบร้อยแล้ว) ซึ่งข้อมูลที่อยู่ก่อนหน้าจะมีคีย์ข้อมูลน้อยกว่า และข้อมูลที่อยู่ตามหลังจะมีค่าคีย์ข้อมูลมากกว่า การทำงานนี้เรียกว่า การแบ่งส่วนข้อมูล (Partition) การแบ่งส่วนนี้จะทำซ้ำกันเรื่อยๆ กับชุดข้อมูลย่อยเรื่อยๆ จนกระทั่ง ข้อมูลทั้งหมดถูกวางอยู่ในตำแหน่งที่แท้จริงของมันแล้ว การแบ่งส่วนออก

เป็น 2 ส่วนนี้ช่วยให้การเรียงลำดับเร็วขึ้น เนื่องจากโดยเฉลี่ยแล้วจำนวนคีย์ในแต่ละส่วนที่ได้หลังจากการแบ่งส่วนแล้วจะลดลงครึ่งหนึ่ง ทำให้จำนวนครั้งของการเปรียบเทียบลดลงครึ่งหนึ่งด้วย



- k : ตำแหน่ง เริ่มต้นของแต่ละส่วน
- m : ตำแหน่ง สิ้นสุดท้ายของแต่ละส่วน
- j : ตำแหน่ง ของคีย์ที่แบ่งส่วนข้อมูลออกเป็น 2 ส่วน

รูปที่ 2.1 แสดงการแบ่งส่วนข้อมูล

ข้อเสียของอัลกอริทึมควิกซอร์ตในการนำไปใช้งาน ซึ่งก็นับว่ามีความสำคัญต่อการนำข้อมูลที่ได้เรียงลำดับแล้วไปใช้งาน คือ การทำงานของอัลกอริทึมควิกซอร์ตเป็นประเภท ไม่เสถียรภาพ (Unstable) กล่าวคือ โดยทั่วไปแล้วข้อมูลที่ทำการเรียงลำดับ ถ้าข้อมูลมีค่าคีย์ข้อมูลเท่ากัน

เช่น ข้อมูลตัวที่ i และ ตัวที่ j มีคีย์ข้อมูลเท่ากัน คือ

$$\text{key}(i) = \text{key}(j)$$

โดย i และ j เป็น ลำดับของข้อมูล ถ้าก่อนการเรียงลำดับข้อมูล ค่า i น้อยกว่าค่า j เมื่อเรียงลำดับข้อมูลจะได้ ข้อมูลตัวที่ i มาก่อน ข้อมูลตัวที่ j การเรียงลำดับที่ให้ผลดังนี้ เป็นการเรียงลำดับที่เสถียรภาพ (Stable) แต่การทำงานของอัลกอริทึมควิกซอร์ต โดยการเปรียบเทียบข้อมูล จะเปรียบเทียบข้อมูลในตำแหน่งที่อยู่ห่างไกลกัน คือ จากตอนปลายทั้งสองด้านของชุดลำดับ ทำให้ผลการเรียงลำดับข้อมูล เป็นไปได้ที่เกิด ไม่เสถียรภาพของข้อมูล ซึ่งไม่สามารถรักษาลำดับเดิมของข้อมูลที่มีค่าคีย์ข้อมูลเท่ากัน



ความเสถียรภาพของข้อมูลนับว่ามีความจำเป็น ถ้าลำดับของข้อมูลก่อนการเรียงลำดับมีความสำคัญในการใช้งาน

### 2.3 การสำรวจผลงานทางวิชาการ

การพัฒนาปรับปรุงอัลกอริทึมการเรียงลำดับด้วย ควิกซอร์ต ให้มีประสิทธิภาพสูง ได้มีแนวความคิด ตลอดจนผลงานวิชาการ ดังนี้

Motzkin<sup>3</sup> เสนอว่า ข้อเสียเปรียบอย่างหนึ่งของควิกซอร์ต คือการทำงานกับข้อมูลที่อยู่ในลำดับข้างแล้ว (Partially Sorted) โดยการเลือกตัวกำหนดการแบ่งส่วนข้อมูล จะทำให้เกิดเป็นลักษณะการทำงานที่เป็นกรณีร้ายแรง (Worst Case Situation) และได้เสนอว่า คีย์ที่ควบคุมการแบ่งส่วนควรได้จากค่าเฉลี่ย (Mean) จะทำให้ ลักษณะลำดับของคีย์ ไม่มีผลต่อประสิทธิภาพการทำงานของอัลกอริทึมได้ แต่กรณีร้ายแรง (Worst Case) สามารถเกิดได้เมื่อการกระจายของค่าคีย์ภายหลังการเรียงลำดับแล้ว มีลักษณะดังนี้

$$k_{j-1} < \sum_{i=1}^j k_i \leq k_j$$

กล่าวคือ ค่าของคีย์ทั้งหมดก่อนตัวที่  $j$  มีค่าอยู่ระหว่างค่าของคีย์ตัวที่  $j-1$  และ คีย์ตัวที่  $j$  หรืออีกนัยหนึ่งคือ ค่าเฉลี่ยของคีย์ทั้งหมดก่อนคีย์ตัวที่  $j$  มีค่าอยู่ระหว่างค่าคีย์ตัวที่  $j-1$  และ ค่าคีย์ตัวที่  $j$  ตัวอย่างเช่น ข้อมูล 2 3 6 10 12 23 120 จะเห็นว่าค่าเฉลี่ยของข้อมูลทั้งหมดนั้นคือ 25 ทำให้การใช้ค่าเฉลี่ยของข้อมูลเป็นตัวกำหนดการแบ่งส่วนนั้นทำให้เกิดกรณีร้ายแรงขึ้นได้เช่นกัน

Motzkin<sup>4</sup> ได้เสนอว่า ในการแบ่งส่วนข้อมูล โดยการอ่านข้อมูลไปในทิศทางเดียวกัน แทนการอ่านข้อมูลสลับกันของปลายทั้งสองด้านของข้อมูล เพื่อให้เกิดเสถียรภาพของข้อมูล

Cook และ Do Jin Kim<sup>5</sup> ได้ศึกษาเปรียบเทียบการทำงานของอัลกอริทึม การเรียงลำดับข้อมูล อินเซกชันซอร์ต, เซลซอร์ต, สเตรท เมจ ซอร์ต (Straight Merge Sort), ควิกซอร์ต และ ฮีปซอร์ต กับ ข้อมูลที่มีการเรียงลำดับในอัตราส่วนต่างๆ พบว่าโดยการใช้ อินเซกชันซอร์ต ร่วมกับ ควิกซอร์ต จะทำให้เกิดประสิทธิภาพการทำงานดีขึ้น

<sup>3</sup>Motzkin, D., "Meansort," Commun ACM 23, 11(Nov 1980) : 250-251.

<sup>4</sup>Motzkin, D., "A stable Quicksort," Softw. Pract. Exper. 11 (June 1981) : 607-611.

<sup>5</sup>Cook, C. R., and Do Jin Kim., "Best sorting algorithm for Nearly sorted lists," Commun ACM 26, 4(April 1983) : 620-624.

Baer และ Yi-Bing Lin<sup>๑</sup> เสนอโครงสร้างข้อมูลโคดเวิร์ดเพื่อใช้ในอัลกอริทึมควิกซอร์ต ดังนี้

จากแนวความคิดของโคดเวิร์ด เป็นค่าข้อมูลใหม่ที่ได้จากการนำคีย์ข้อมูลเดิมมาปรับเปลี่ยน โดยค่าข้อมูลใหม่มีคุณสมบัติใช้เปรียบเทียบได้เช่นเดียวกับคีย์ข้อมูลเดิม ในการใช้ค่าข้อมูลใหม่หรือค่าโคดเวิร์ดนี้เปรียบเทียบข้อมูลแทนคีย์ เพื่อการแบ่งส่วนข้อมูลสามารถจัดข้อมูลออกเป็น 4 กลุ่มแทน 2 กลุ่ม คือ กลุ่ม S1, S2, S3 และ S4 โดย คีย์ข้อมูลในกลุ่ม S1 และ S2 จะเป็นข้อมูลที่มีคีย์น้อยกว่าคีย์ของตัวกำหนดการแบ่งส่วน และคีย์ข้อมูลในกลุ่ม S3 และ S4 จะเป็นข้อมูลที่มีคีย์มากกว่าคีย์ของตัวกำหนดการแบ่งส่วน

โดยการทำงานของอัลกอริทึมควิกซอร์ต ของ Baer และ Yi-Bing Lin ทำตามลักษณะการทำงานเดิมของอัลกอริทึมควิกซอร์ต แต่ใช้ค่าโคดเวิร์ดในการเปรียบเทียบแทนการใช้คีย์ข้อมูล โดยแบ่งการทำงานออกเป็น 2 ขั้นตอน ขั้นตอนแรกแบ่งข้อมูลทั้งหมดเป็น 2 ส่วน คือ ชุดลำดับบน (T1) และชุดลำดับล่าง (T2) ซึ่ง T1 ประกอบด้วยสมาชิกของ S1 และ S2 ส่วน T2 ประกอบด้วยสมาชิกของ S3 และ S4 โดยแต่ละสมาชิกจะถูกทำเครื่องหมายเพื่อแสดงถึงกลุ่มย่อยที่ตนเองเป็นสมาชิกจริง ๆ การทำงานในขั้นตอนแรกนี้เป็นลักษณะของอัลกอริทึมควิกซอร์ตแบบเดิมที่แบ่งข้อมูลออกเป็น 2 ส่วน ในขั้นตอนที่สอง T1 และ T2 จะต้องถูกอ่านทั้งหมดอีกครั้ง เพื่อกระจายเป็น S1, S2 และ S3, S4 ตามลำดับ โดยการพิจารณาจากขนาดของข้อมูลในแต่ละกลุ่มย่อย ถ้าขนาดของ S1 (S3) และ S2 (S4) มีขนาดเท่า ๆ กันแล้ว ให้กระจาย T1 และ T2 เรียกว่าการทำไฟร์-เว พาทิชันนิ่ง (Four-Way Partitioning) หรือการแบ่ง 4 ส่วน แต่ถ้าขนาดของ S1 (S3) ต่างจาก S2 (S4) มาก การอ่านข้อมูลอีกครั้งรอบเพื่อกระจาย T1, T2 ไม่เป็นประโยชน์เท่าที่ควร ให้ใช้ T1 และ T2 เป็นข้อมูลเข้าในรอบถัดไปแทน เป็นการทำทู-เว พาทิชันนิ่ง (Two-Way Partitioning) หรือการแบ่ง 2 ส่วน หรือทำเป็น ทรี-เว พาทิชันนิ่ง (Three-Way Partitioning) การแบ่ง 3 ส่วน ประกอบด้วยกลุ่มข้อมูล S1, S2 และ T2 หรือ กลุ่มข้อมูล T1, S3 และ S4 ในขั้นตอนที่ 2 ทำงานเพื่อพิจารณาการแบ่งข้อมูลต่อให้เป็นข้อมูลกลุ่มย่อย ซึ่งเป็นการแบ่งตามเครื่องหมายที่ให้ไว้ในขั้นตอนแรก

<sup>๑</sup>Baer J. L. , and Yi-Bing Lin, "Improving Quicksort Performance with a Codeword Data Structure," IEEE Trans on Software Engineering 15 ,5(May 1989) : 622-631.