

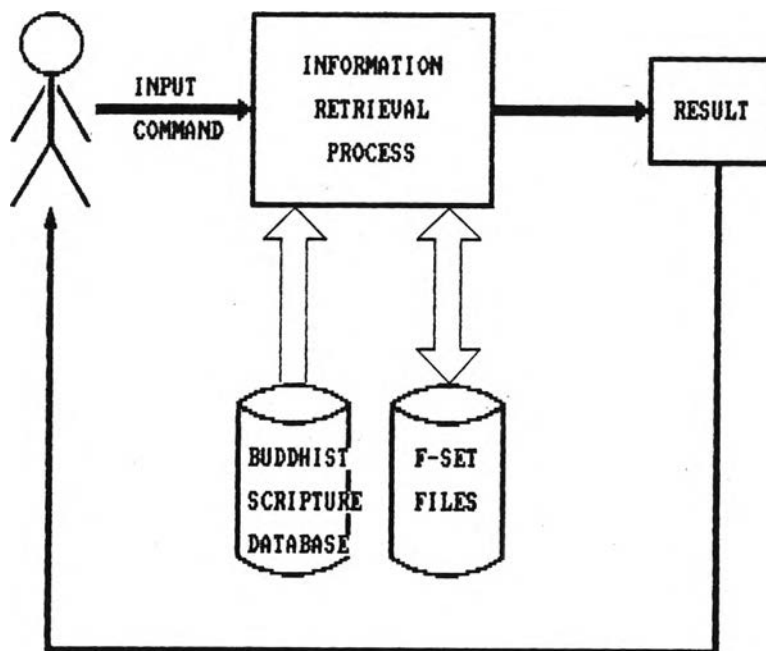


#### บทที่ 4

### การออกแบบระบบสืบค้นสารสนเทศพระไตรปิฎกระบบใหม่

#### 4.1 หลักการของระบบสืบค้นสารสนเทศพระไตรปิฎกระบบใหม่

ระบบสืบค้นสารสนเทศพระไตรปิฎกระบบใหม่ หรือ BUDSIR-III มีหลักการใหญ่ว่า ผู้ใช้เป็นผู้กำหนดทิศทางการค้น โดยผ่านทางคำสั่งค้นที่ป้อนเข้า และขบวนการสืบค้นสารสนเทศจะถูกควบคุมให้ดำเนินการค้นไปตามคำสั่งนั้น โดยมีการดึงข้อมูลต่าง ๆ จากฐานข้อมูลพระไตรปิฎก และกลุ่มแฟ้มข้อมูล F-Set มาใช้งาน เมื่อเสร็จการค้นแต่ละครั้งจะได้ผลลัพธ์แสดงให้แก่ผู้ใช้ทางจอภาพ และมีการเก็บบันทึกสารสนเทศผลลัพธ์เข้าแฟ้มข้อมูล F-Set ไว้ในรูปแบบพิเศษ ส่วนผู้ใช้เมื่อได้รับผลลัพธ์ตอบกลับมา ก็จะใช้ผลลัพธ์นั้น ประกอบการตัดสินใจในการป้อนคำสั่งถัดไป แผนผังข้างล่าง จำลองให้เห็นหลักการของระบบสืบค้นสารสนเทศนี้



รูปที่ 4.1 แผนผังแสดงหลักการของ BUDSIR-III

4.2 โครงสร้างฐานข้อมูล

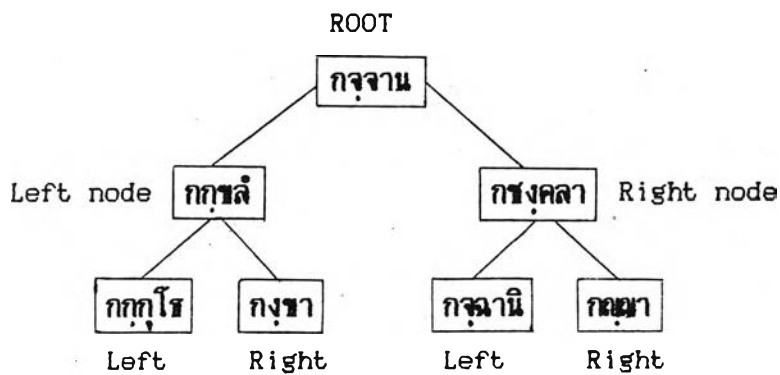
ฐานข้อมูลของ BUDSIR-III ประกอบด้วย ฐานข้อมูลพระไตรปิฎก และ กลุ่มแฟ้มข้อมูล F-Set สำหรับฐานข้อมูลแรก เป็นฐานข้อมูลเดียวกันกับที่ใช้ในบูตเซอรั ส่วนแฟ้มข้อมูล F-Set ได้ออกแบบเพิ่มขึ้นมาในระบบใหม่นี้ เพื่อให้เก็บสารสนเทศผลลัพธ์ที่ได้จากการค้นแต่ละครั้ง ทั้งสองส่วนมีรายละเอียด ดังต่อไปนี้

4.2.1 โครงสร้างฐานข้อมูลพระไตรปิฎก

ฐานข้อมูลพระไตรปิฎก ประกอบด้วยแฟ้มข้อมูล 3 ชนิด ได้แก่ แฟ้มพจนานุกรม แฟ้มข้อมูลย้อนกลับ และแฟ้มข้อมูลพระไตรปิฎก

แฟ้มพจนานุกรม

เก็บข้อมูลคำศัพท์ พร้อมทั้งรายละเอียดเกี่ยวกับคำศัพท์นั้น ข้อมูลเหล่านี้จะถูกแยกเก็บเป็นกลุ่ม ๆ ตามพยัญชนะเริ่มต้นของคำศัพท์ เนื่องจากในภาษาบาลีมีพยัญชนะ 33 ตัว จึงเก็บได้เป็น 33 กลุ่ม การจัดเก็บคำศัพท์ภายในกลุ่ม จะอยู่ในรูปของ โครงสร้างแบบทรี โดยมีตัวชี้โยงระหว่างกัน ซึ่งจะจำลองให้เห็นได้ดังภาพข้างล่างนี้ นอกจากนั้น ยังมี แพ็คเกจ (Dict-Pack) ที่เก็บเฉพาะรายการคำศัพท์แยกมาอีกต่างหาก



— เส้นชี้โยงระหว่างโหนด root-left-right

รูปที่ 4.2 แสดงตัวอย่างการเชื่อมโยงของคำศัพท์ในโครงสร้างแบบทรี

### แฟ้มข้อมูลย้อนกลับ

เก็บข้อมูลจำนวนการปรากฏในแต่ละเล่มของคำค้นที่แต่ละคำ รวมทั้งเก็บข้อมูล **บัญชีการปรากฏ** ได้แก่ ข้อมูลตำแหน่งทุกตำแหน่งของคำค้นที่แต่ละคำ ที่ปรากฏอยู่ในพระไตรปิฎก ข้อมูลตำแหน่ง เป็นรหัสระบุ หน้า/บรรทัด/คำที่ และ แฟ้มเล็ก ซึ่งใช้บ่งชี้ว่าเป็นคำสุดท้ายของบรรทัด หรือ คำสุดท้ายของหน้า ในขบวนการสืบค้นสารสนเทศ โดยเฉพาะการตรวจสอบคำประชิด จำเป็นต้องใช้ข้อมูลส่วนนี้โดยตรง

### แฟ้มข้อมูลพระไตรปิฎก

เก็บข้อมูลพระไตรปิฎกทั้ง 45 เล่ม โดยแยกเป็นเล่ม ๆ ไป ข้อความในพระไตรปิฎกจะถูกจัดเก็บไว้เป็นบล็อก และจัดระเบียบไว้ให้พร้อมที่จะดึงออกไปแสดงทางจอภาพ หรือพิมพ์ออกทางเครื่องพิมพ์ นอกจากนี้ ยังมีไคเรกทอรีประจำแฟ้มข้อมูลพระไตรปิฎก ซึ่งเก็บตัวเลขระบุตำแหน่งเริ่มต้นของข้อความแต่ละหน้าเอาไว้ ดังนั้น เมื่อต้องการดึงข้อความหน้าใด ๆ จากแฟ้มข้อมูลพระไตรปิฎกแล้ว ก็ต้องมาค้นหาตำแหน่งเริ่มต้นของหน้านั้น ๆ ในไคเรกทอรีนี้เสียก่อน

แฟ้มข้อมูลทั้ง 3 ประเภทจะมีตัวชี้เชื่อมโยงระหว่างกัน โดยเริ่มจากแต่ละระเบียบที่เก็บคำค้นที่แต่ละคำในแฟ้มพจนานุกรม จะมีตัวชี้บอกระเบียบเริ่มต้นที่เก็บข้อมูลจำนวนปรากฏและตำแหน่งของคำนั้น ๆ ในแฟ้มข้อมูลย้อนกลับ จากข้อมูลตำแหน่งของคำซึ่งระบุถึง เลขหน้า บรรทัดที่ และคำที่ จะสามารถนำไปค้นหาในไคเรกทอรีประจำแฟ้มข้อมูลพระไตรปิฎกได้ว่า ระเบียบเริ่มต้นของข้อความหน้านั้น อยู่ที่ใดในแฟ้มพระไตรปิฎก จากนั้น ก็สามารถจะเข้าถึงข้อความในพระไตรปิฎกหน้านั้น ๆ ได้ทุกบรรทัด ทุกคำ ข้อความพระไตรปิฎกแต่ละหน้าจะตั้งต้นที่ระเบียบเริ่มต้นของหน้านั้น ไล่ไปตามลำดับจนกระทั่งพบเครื่องหมายจบหน้า

แผนผังในรูปที่ 2.3 ของบทที่ 2 แสดงให้เห็นโครงสร้างทั้งหมดของฐานข้อมูลพระไตรปิฎก และการเชื่อมโยงระหว่างแฟ้มข้อมูลทั้ง 3 ประเภท ดังกล่าว

#### 4.2.2 โครงสร้างกลุ่มแฟ้มข้อมูล F-Set

กลุ่มแฟ้มข้อมูล F-Set ประกอบด้วยแฟ้มไคเรกทอรีของ F-Set 1 แฟ้ม และแฟ้ม F-Set ตั้งแต่ 1 แฟ้มขึ้นไป

#### ที่มาและความหมายของแฟ้มข้อมูล F-Set

จากหลักการค้นของระบบ ต้องเก็บผลลัพธ์การค้นไว้ทุกครั้ง ทั้งนี้เพื่อให้สามารถขยายการค้นออกไปได้กว้างขวางขึ้น เช่น ให้ผู้ใช้สามารถทำการค้นสารสนเทศย่อยลงไป ในกลุ่ม

สารสนเทศผลลัพธ์ขึ้นต้น ซึ่งจะทำให้ได้ผลลัพธ์ที่ตรงเป้าหมายมากยิ่งขึ้น หรือให้ผู้ใช้สามารถรวมเอาผลลัพธ์ของการค้นหลาย ๆ ครั้ง เข้าเป็นสารสนเทศกลุ่มเดียว และตัดส่วนที่ซ้ำกันออกไปด้วยเป็นต้น เพียงความต้องการเท่านั้น ก็จะทำให้เห็นถึงความจำเป็นแล้วว่า ต้องจัดให้มีแฟ้มชั่วคราวที่จะเก็บสารสนเทศผลลัพธ์ของการค้นแต่ละครั้งเอาไว้ และได้ให้ชื่อเรียกแฟ้มประเภทนี้ว่า F-Set

#### แนวทางการออกแบบแฟ้ม F-Set

สิ่งที่ต้องคำนึงถึงในการออกแบบแฟ้ม F-Set มีหลายประการด้วยกัน ดังนี้

๑. ชั้นแรกต้องกำหนดขอบเขตของสารสนเทศเป็นส่วน ๆ โดยที่แต่ละส่วน เมื่อถูกสืบค้นได้เป็นสารสนเทศผลลัพธ์แล้ว จะให้ความหมายที่สอดคล้องกับความต้องการค้นของผู้ใช้ครั้งนั้น ๆ
๒. ข้อมูลในแฟ้ม F-Set ต้องสามารถอ้างอิงถึงกลุ่มสารสนเทศที่เป็นผลลัพธ์ของการค้นนั้น ๆ ได้
๓. ข้อมูลในแฟ้ม F-Set ต้องสามารถนำไปใช้ดำเนินการปฏิบัติการแบบบูล และปฏิบัติการตรวจคำประชิด ในขบวนการสืบค้นสารสนเทศได้
๔. ไม่ควรเก็บผลลัพธ์เป็นข้อความของพระไตรปิฎกโดยตรง เพราะจะซ้ำซ้อนกับที่มีเก็บในฐานข้อมูลพระไตรปิฎกแล้ว
๕. ใช้เนื้อที่การเก็บข้อมูลของแฟ้ม F-Set ให้สิ้นเปลืองน้อยที่สุด

#### การออกแบบโครงสร้างข้อมูลในแฟ้ม F-Set

เนื่องจากเนื้อความในพระไตรปิฎกแต่ละเล่มจะถูกแบ่งไว้เป็นข้อ ๆ แต่ละข้อมีหมายเลขข้อนำหน้าข้อความ เลขข้อจะเริ่มตั้งแต่ (1) เรียงไปตามลำดับ แต่เดิม การค้นหาข้อความที่ต้องการ และการอ้างอิงข้อความตอนใดในพระไตรปิฎกฉบับพิมพ์นั้น มักมีการใช้หมายเลขข้อเหล่านี้เป็นตัวอ้างอิง ซึ่งจะเป็นที่เข้าใจตรงกันในหมู่ผู้ศึกษาพระไตรปิฎก

ดังนั้น ข้อมูลใน F-Set ควรจะอ้างอิงถึงสารสนเทศผลลัพธ์เป็นข้อ ๆ ไป และเพื่อไม่ให้เก็บสารสนเทศผลลัพธ์แต่ละข้อไปซ้ำซ้อนกับในฐานข้อมูลพระไตรปิฎก จึงออกแบบให้เก็บกลุ่มหมายเลขข้อของสารสนเทศผลลัพธ์ไว้แทน ซึ่งนับว่ามีความเหมาะสม เนื่องจากหมายเลขข้อเหล่านี้ ไม่มีการซ้ำซ้อนกัน (unique) สามารถบ่งชี้ว่าเป็นสารสนเทศข้อใดได้โดยไม่สับสน การเก็บข้อมูลเป็นหมายเลขข้อนี้ เป็นลักษณะของแฟ้มข้อมูลย้อนกลับ จึงทำให้สามารถดำเนินการปฏิบัติการแบบบูลบนแฟ้ม F-Set ได้ และเพื่อให้สามารถดำเนินการปฏิบัติการตรวจคำประชิด บนแฟ้ม F-Set ได้ ก็จำเป็นต้องเก็บข้อมูลตำแหน่งคำลงไปด้วย และจากหลักการที่ว่า F-Set เป็นข้อมูลผลลัพธ์ที่ได้จากการสืบค้นสารสนเทศแต่ละครั้ง ในการค้นจะต้องมีการกำหนดคำค้นต่าง ๆ ไว้ในคำสั่งค้น ดังนั้น แทนที่จะเก็บเพียงหมายเลขข้อของสารสนเทศที่ปรากฏคำค้นเหล่านั้นไว้ จึงได้เก็บตำแหน่งคำของคำค้นเหล่านั้นลงไปด้วย ซึ่งจากฐานข้อมูลพระไตรปิฎก จะสามารถดึงข้อมูลตำแหน่งคำของ

ทุกคำค้นที่เป็น เลขหน้า/เลขบรรทัด/เลขที่คำในบรรทัด มาได้ และนำมาเก็บเพิ่มในแฟ้ม F-Set ดังนั้น ข้อมูลในแฟ้ม F-Set จะเก็บรวบรวมข้อมูล เลขข้อ/เลขหน้า/เลขบรรทัด/เลขที่คำ ซึ่งจะ สามารถอ้างอิงสารสนเทศผลลัพธ์ทุกข้อและยังบอกละเอียดไปถึงตำแหน่งของคำค้นด้วย การเก็บ เป็นข้อมูลตัวเลขนี้จะทำให้สิ้นเปลืองเนื้อที่เก็บน้อยกว่า เมื่อเทียบกับการเก็บตัวสารสนเทศตรง ๆ

การเรียกชื่อแฟ้ม F-Set จะมีการกำหนดหมายเลขให้แก่แฟ้ม F-Set ที่ถูกสร้างขึ้นมาใหม่ ในทันที เรียกว่า **หมายเลขเซก** หมายเลขนี้จะยูนิต ดังนั้น จะในการอ้างอิงแฟ้ม F-Set แฟ้มใด ก็ให้ใช้หมายเลขเซกนี้ โดยเติมเครื่องหมาย "#" ไว้ข้างหน้าด้วยทุกครั้ง เช่น #1, #2 เป็นต้น ทั้งนี้เพื่อให้เห็นว่า มีความหมายแตกต่างจากตัวเลขธรรมดา คือเป็นหมายเลขเซก ในการ กำหนดหมายเลขเซกให้แก่ F-Set แฟ้มใหม่นั้น จะเริ่มตั้งแต่หมายเลข 1 เป็นต้นไป และได้ใช้ เนื้อที่ในหน่วยความจำสำหรับเก็บค่าตัวเลขล่าสุด ที่ถูกกำหนดให้แก่ F-Set ไปแล้ว

ในรูปที่ 4.3 ได้แสดงให้เห็นถึงโครงสร้างของกลุ่มแฟ้มข้อมูล F-Set

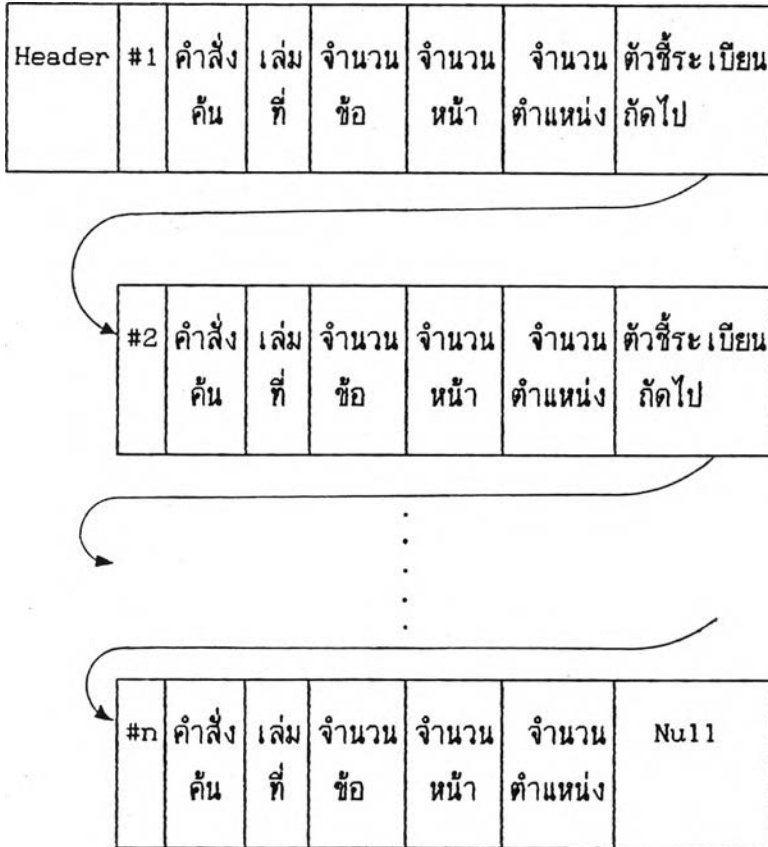
#### แฟ้มไคเรกทอรีของ F-Set

เนื่องจากแฟ้ม F-Set แต่ละแฟ้ม เกิดขึ้นจากการค้นสารสนเทศแต่ละครั้ง โดยมี คำสั่งค้นต่าง ๆ กัน ซึ่งโดยทั่วไปแล้ว ผู้ใช้ย่อมต้องการทราบถึงที่มาของสารสนเทศผลลัพธ์เหล่านั้น ที่ถูกเก็บไว้ในแฟ้ม F-Set ต่าง ๆ ในรูปแบบพิเศษ และนับเป็นเรื่องที่ยุ่งยากมากที่จะให้ผู้ใช้งาน จำไว้เอง จึงจัดให้มีแฟ้มไคเรกทอรีของ F-Set สำหรับเก็บคำสั่งค้นแต่ละครั้ง รวมทั้งปริมาณของ สารสนเทศผลลัพธ์แต่ละครั้งว่า มีกี่ข้อ กี่หน้า และจำนวนคำค้นมีพบอยู่ที่หมดกี่ตำแหน่ง ข้อมูลแต่ละ ระเบียบในแฟ้มไคเรกทอรี จะเก็บข้อมูลเกี่ยวกับแฟ้ม F-Set แต่ละแฟ้ม ระเบียบข้อมูลในแฟ้ม ไคเรกทอรีจะโยงต่อกันเป็นลักษณะของ **รายการเชื่อมโยง (Linked List)** แบบทิศทางเดียว และได้ใช้เนื้อที่ในหน่วยความจำสำหรับเก็บตัวชี้ระเบียบแรก และตัวชี้ระเบียบสุดท้าย ไว้ด้วย

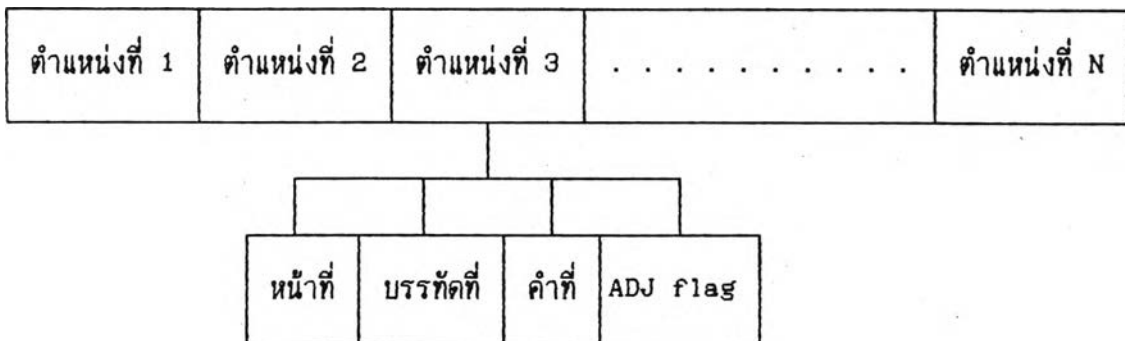
#### การเพิ่ม-ลบ F-Set ในฐานข้อมูล

ในการเพิ่มแฟ้ม F-Set แฟ้มใหม่เข้าในฐานข้อมูล จะมีการเพิ่มค่าตัวเลขนับหมายเลข เซกขึ้น 1 แล้วใช้ค่านั้น กำหนดหมายเลขเซกให้แก่ F-Set แฟ้มใหม่ พร้อมกับบันทึกข้อมูล หมายเลขเซก คำสั่งค้น จำนวนข้อ จำนวนหน้า จำนวนตำแหน่งคำ ของสารสนเทศผลลัพธ์นั้น เข้าเป็นระเบียบใหม่ในแฟ้มไคเรกทอรีของ F-Set ด้วย โดยจะเพิ่มเข้าทางตอนท้ายของ **รายการเชื่อมโยง (Linked List)** เท่านั้น เนื่องจากมีตัวชี้บอกระเบียบสุดท้ายไว้ จึงสามารถ เก็บลงในระเบียบถัดไปได้ และในการนี้ จะต้องมีการเปลี่ยนค่าตัวชี้ระเบียบสุดท้าย ให้ชี้มายัง ระเบียบใหม่ และกำหนดตัวชี้ของระเบียบก่อนหน้า ซึ่งเดิมมีค่าเป็น Null อยู่ ให้เก็บตำแหน่งของ ระเบียบใหม่นี้ไว้แทน แล้วกำหนดให้ตัวชี้ของระเบียบใหม่เป็น Null ดังภาพจำลองในรูปที่ 4.4

**แผนผังโครงสร้างของ F-Set**




**แผนผัง F-Set**




รูปที่ 4.3 แสดงโครงสร้างของกลุ่มแฟ้มข้อมูล F-Set และข้อมูลที่เก็บ

ลักษณะแฟ้มไดเรกทอรีของ F-Set ที่มีข้อมูลอยู่ 2 ระเบียบ



การเพิ่มระเบียบใหม่เข้าในแฟ้มไดเรกทอรีของ F-Set




รูปที่ 4.4 แสดงการเพิ่มระเบียบเข้าไดเรกทอรี เมื่อมี F-Set แฟ้มใหม่เพิ่มเข้าในฐานข้อมูล

ส่วนการลบแฟ้ม F-Set แฟ้มใดแฟ้มหนึ่งออกจากฐานข้อมูล ก็ต้องลบระเบียบข้อมูลในแฟ้มไดเรกทอรี ที่เก็บข้อมูลเกี่ยวกับ F-Set นั้น ๆ ออกไป 1 ระเบียบ โดยการเปลี่ยนตัวชี้ของระเบียบก่อนหน้า หรืออาจเป็นตัวชี้ระเบียบแรกของ รายการเชื่อมโยง นั้น (ถ้าระเบียบที่จะลบออกเป็นระเบียบแรก) ให้ชี้ไปยังระเบียบถัดไปแทน แต่ถ้าระเบียบที่จะลบออกเป็นระเบียบสุดท้ายของ Link-List ก็จะต้องกำหนดตัวชี้ของระเบียบก่อนหน้าให้เป็น Null แทน ดังในรูปที่ 4.5 เป็นภาพจำลองของการลบข้อมูลในไดเรกทอรีของ F-Set ออก 1 ระเบียบ เมื่อมีการลบแฟ้ม F-Set ออกจากฐานข้อมูล 1 แฟ้ม


#### ข้อจำกัดเกี่ยวกับ F-Set

จำนวนแฟ้ม F-Set ที่จะเก็บบันทึกไว้ได้ ถูกจำกัดด้วยปริมาณเนื้อที่ว่างในงานแม่เหล็ก ว่ามีสำรองไว้มากเพียงใด


การลบข้อมูลระเบียบแรกออกจากแฟ้มไดเรกทอรีของ F-Set




การลบข้อมูลระเบียบกลาง ๆ ออกจากแฟ้มไดเรกทอรีของ F-Set



การลบข้อมูลระเบียบท้ายออกจากแฟ้มไดเรกทอรีของ F-Set



การลบข้อมูลที่เหลือเพียงระเบียบเดียวออกจากแฟ้มไดเรกทอรีของ F-Set



รูปที่ 4.5 แสดงการลบระเบียบของไดเรกทอรี เมื่อ F-Set ถูกลบออกจากฐานข้อมูล 1 แฟ้ม



### 4.3 โครงสร้างขบวนการสืบค้นสารสนเทศระยะไตรปิฎกในระบบใหม่

#### 4.3.1 ปฏิบัติการแบบบูล

ความหมายของปฏิบัติการแบบบูล AND, OR, NOT เมื่อนำมาใช้ในทางปฏิบัติ จะใช้ปฏิบัติการของเซต ได้แก่ อินเตอร์เซกชัน ยูเนียน และ ดิฟเฟอเรนซ์ ตามลำดับ โดยมอง F-Set เป็นเซต ๆ หนึ่ง ที่มีสมาชิกเป็นหมายเลขข้อต่าง ๆ และในการกำหนดปฏิบัติการแบบบูลไว้ในคำสั่งคั้นั้น จะใช้สัญลักษณ์แทน ดังนี้

ชนิดของปฏิบัติการ	สัญลักษณ์ที่ใช้
AND	&
OR	+
NOT	-

ดังนั้น เมื่อต้องการใช้ปฏิบัติการแบบบูลกระทำบน F-Set 2 เซต จะระบุในคำสั่งได้ ดังตัวอย่าง

#1 & #2 หมายถึง F-Set หมายเลข 1 AND F-Set หมายเลข 2

#1 + #2 หมายถึง F-Set หมายเลข 1 OR F-Set หมายเลข 2

#1 - #2 หมายถึง F-Set หมายเลข 1 NOT F-Set หมายเลข 2

#### ความหมายของ #1 & #2 ในทางปฏิบัติ

หมายความว่า F-Set หมายเลข 1 อินเตอร์เซกกับ F-Set หมายเลข 2 โดยมองว่า F-Set ทั้งสองเป็นเซตของหมายเลขข้อของสารสนเทศผลลัพธ์ ที่ได้จากการสืบค้นสารสนเทศครั้งที่ 1 และครั้งที่ 2 ตามลำดับ

ดังนั้น #1 & #2 จะได้ผลเป็นหมายเลขข้อกลุ่มหนึ่ง ที่พบว่าเป็นสมาชิกอยู่ในทั้งสองเซต และกลุ่มของหมายเลขข้อนี้ รวมทั้งข้อมูลตำแหน่งคำที่อยู่ในข้อเหล่านี้ จะถูกเก็บบันทึกไว้ใน F-Set ใหม่ รูปที่ 4.6 แสดงผังงานการดำเนินการปฏิบัติการ AND ระหว่างเซต #21 และเซต #22 ผลลัพธ์ (ถ้ามี) จะถูกเก็บไว้ในเซต #23

#### ความหมายของ #1 + #2 ในทางปฏิบัติ

หมายความว่า F-Set หมายเลข 1 ยูเนียนกับ F-Set หมายเลข 2 โดยที่ F-Set ทั้งสองเป็นเซตของหมายเลขข้อของสารสนเทศผลลัพธ์ ที่ได้จากการสืบค้นสารสนเทศครั้งที่ 1 และครั้งที่ 2 ตามลำดับ

ดังนั้น #1 + #2 จะได้ผลเป็นหมายเลขชื่อกลุ่มหนึ่ง ที่พบว่าเป็นสมาชิกอยู่ในเซต #1 หรือ #2 หรืออาจเป็นสมาชิกอยู่ในทั้งสองเซตก็ได้ และกลุ่มของหมายเลขชื่อนี้ รวมทั้งข้อมูลตำแหน่งคำที่อยู่ภายในชื่อนี้ จะถูกเก็บบันทึกไว้ใน F-Set ใหม่ รูปที่ 4.7 แสดงผังงานการดำเนินปฏิบัติการ OR ระหว่างเซต #21 และเซต #22 ผลลัพธ์จะถูกเก็บไว้ในเซต #23

#### ความหมายของ #1 - #2 ในทางปฏิบัติ

หมายความว่า F-Set หมายเลข 1 ทำเซตคิฟเฟอเรนซ์ด้วย F-Set หมายเลข 2 โดยที่ F-Set ทั้งสองเป็นเซตของหมายเลขชื่อของสารสนเทศผลลัพธ์ ที่ได้จากการสืบค้นสารสนเทศครั้งที่ 1 และครั้งที่ 2 ตามลำดับ

ดังนั้น #1 - #2 จะได้ผลเป็นหมายเลขชื่อกลุ่มหนึ่ง ที่พบว่าเป็นสมาชิกอยู่ในเซต #1 แต่ไม่ได้เป็นสมาชิกอยู่ในเซต #2 และกลุ่มของหมายเลขชื่อนี้ รวมทั้งข้อมูลตำแหน่งคำที่อยู่ภายในชื่อนี้ จะถูกเก็บบันทึกไว้ใน F-Set ใหม่ รูปที่ 4.8 แสดงผังงานการดำเนินปฏิบัติการ NOT ระหว่างเซต #21 และเซต #22 ผลลัพธ์(ถ้ามี) จะถูกเก็บไว้ในเซต #23

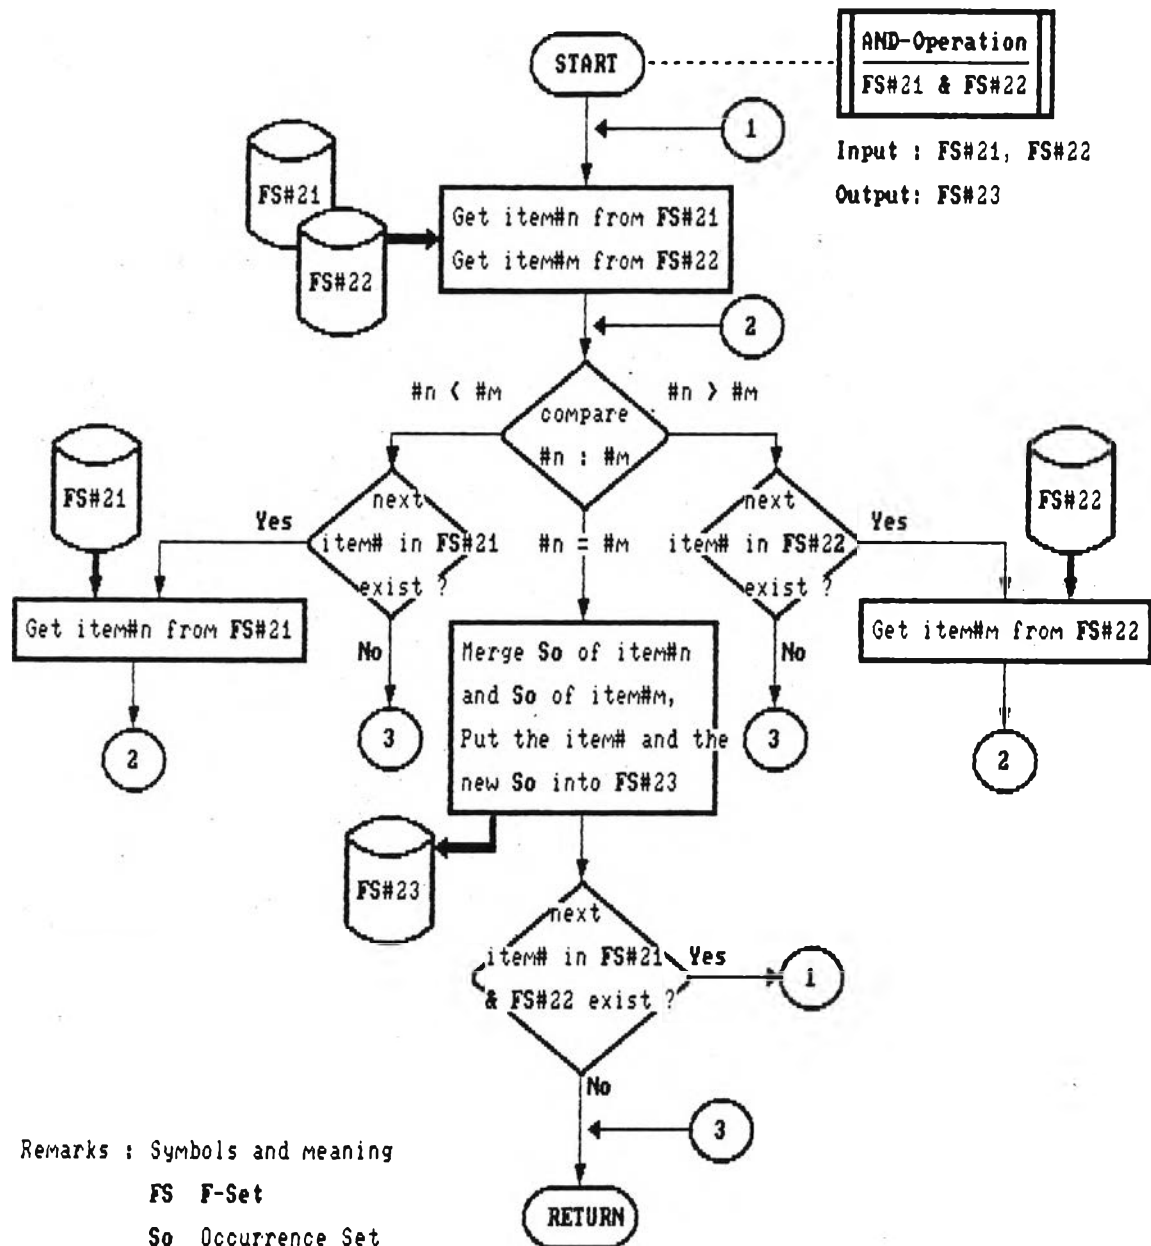
#### 4.3.2 ปฏิบัติการประชิด

ความหมายของปฏิบัติการประชิด หรือ ADJ มีความหมายดังทราบกันแล้วว่า จะตรวจหาตำแหน่งของคำ 2 คำ ว่ามีที่ปรากฏอยู่ในตำแหน่งถัดกันไปบ้างหรือไม่ เมื่อนำมาใช้กระทำบน F-Set ในขบวนการสืบค้นสารสนเทศของ BUDSIR-III นี้ จะดำเนินการโดย มอง F-Set เป็นกลุ่มของตำแหน่งคำ ซึ่งจะระบุตำแหน่งแต่ละตำแหน่งเป็น เลขชื่อ/เลขหน้า/เลขบรรทัด/เลขที่คำในบรรทัด ดังนั้น จึงสามารถนำข้อมูลตำแหน่งคำนี้ มาใช้พิจารณาคำประชิด ในระหว่าง F-Set 2 เซตได้ โดยกำหนดให้ใช้สัญลักษณ์ "@" สำหรับแทนปฏิบัติการประชิด เมื่อต้องการระบุไว้ในคำสั่งค้น ตัวอย่างเช่น

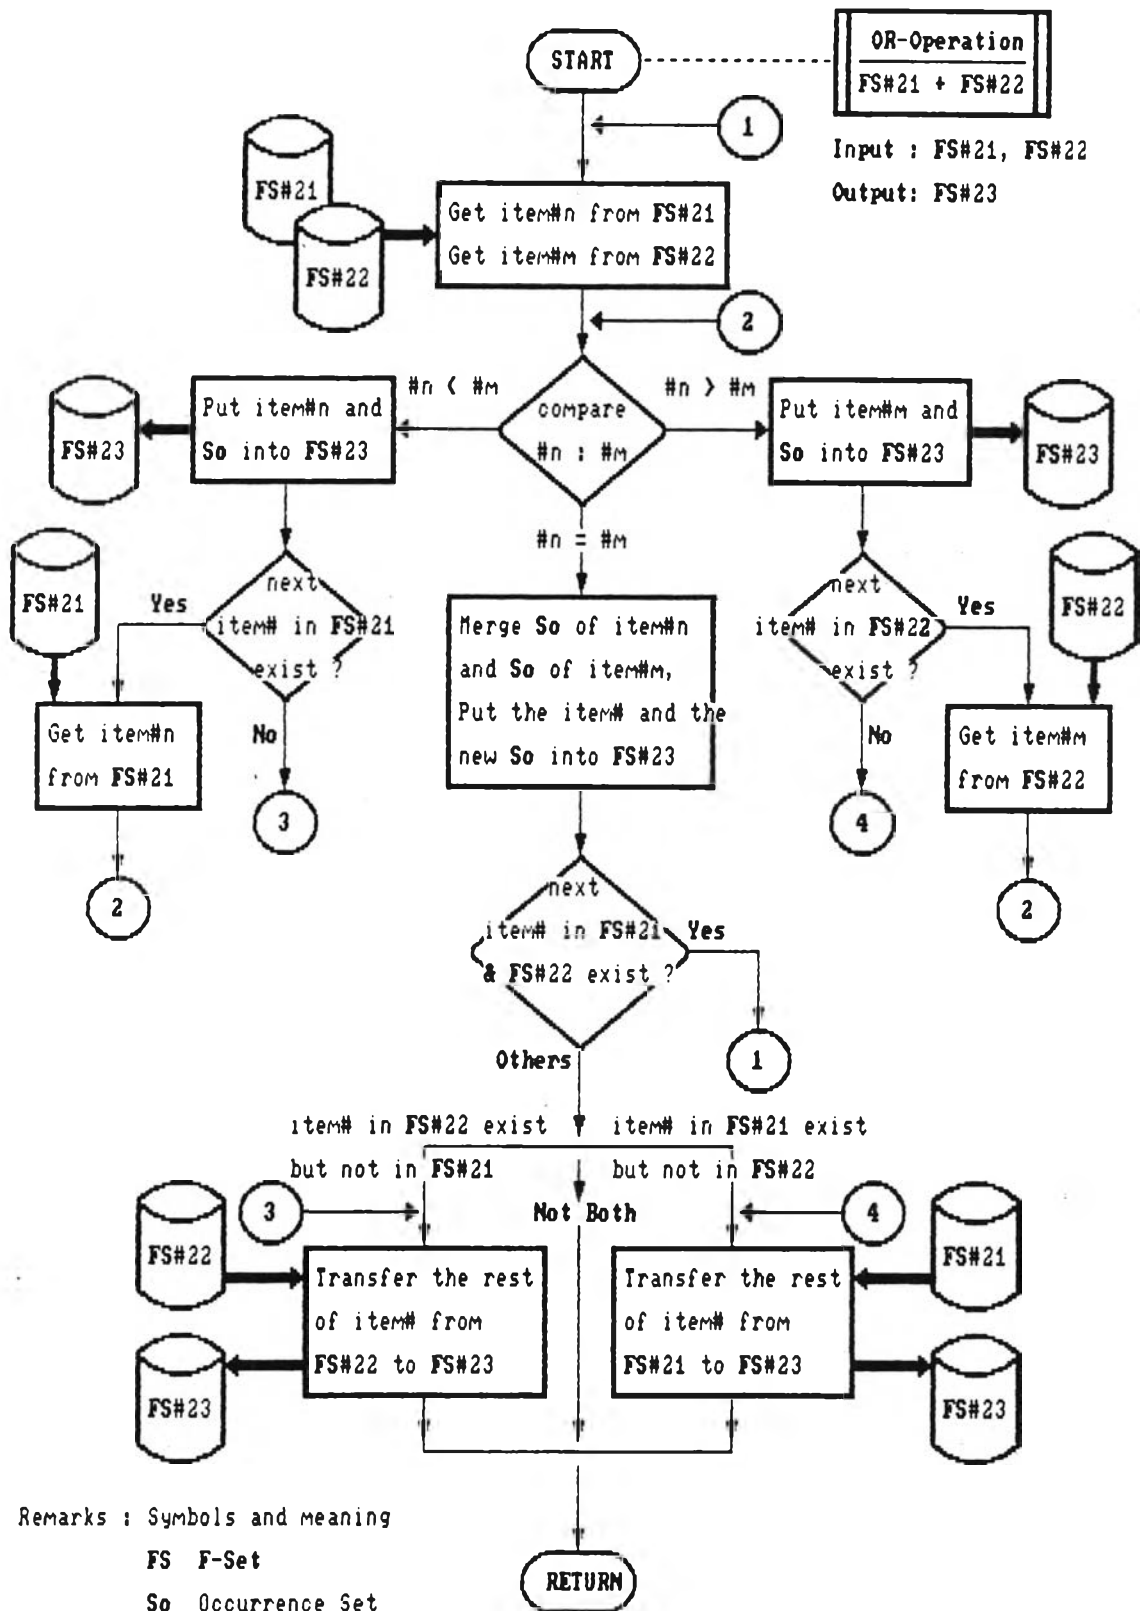
#1 @ #2 หมายถึง F-Set หมายเลข 1 กระทำ ADJ กับ F-Set หมายเลข 2

#### ความหมายของ #1 @ #2 ในทางปฏิบัติ

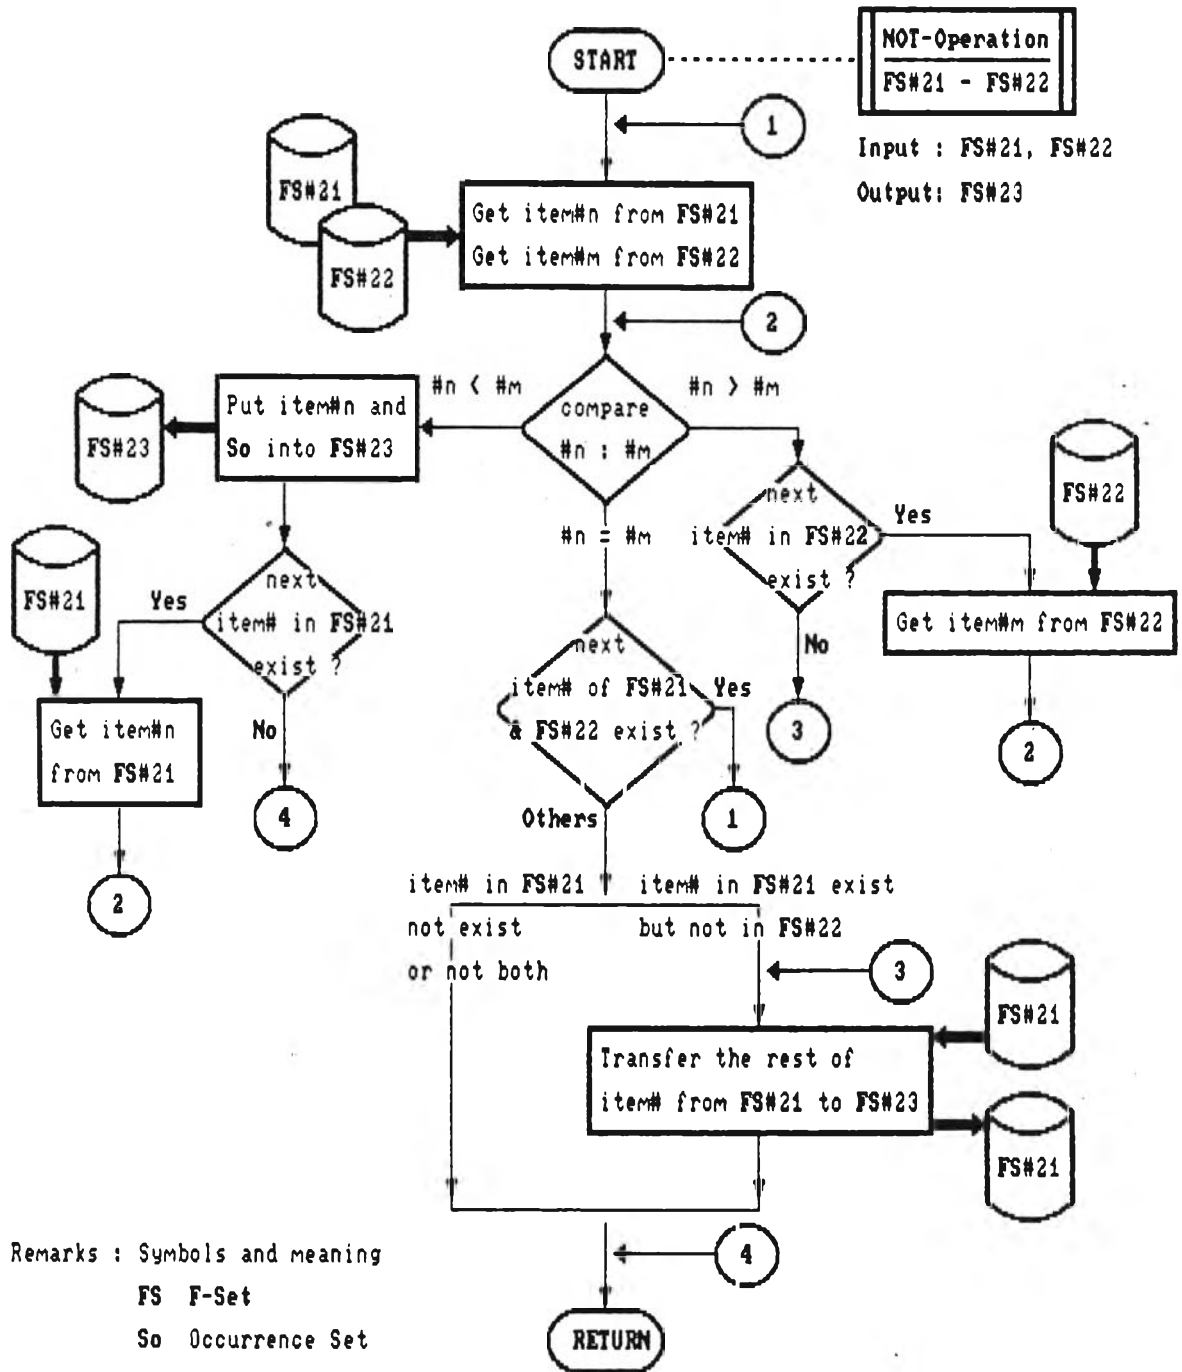
เมื่อมอง F-Set เป็นเซตของข้อมูลตำแหน่งคำ ที่ได้มาจากการสืบค้นสารสนเทศขั้นต้น ซึ่งข้อมูลตำแหน่งเหล่านี้เป็นบอกถึงตำแหน่งของคำต่างที่ใช้ระบุไว้ในคำสั่งค้น ในการดำเนินปฏิบัติการ ADJ ระบบจะไม่จำเป็นต้องรู้ว่า ใน F-Set ทั้งสองเก็บตำแหน่งของคำใดบ้าง แต่จะพิจารณาแต่ละตำแหน่งของทั้งสองเซตว่า ตำแหน่งเหล่านั้น อยู่ใน ข้อ/หน้าใด บรรทัดใด และคำที่เท่าไรของบรรทัด



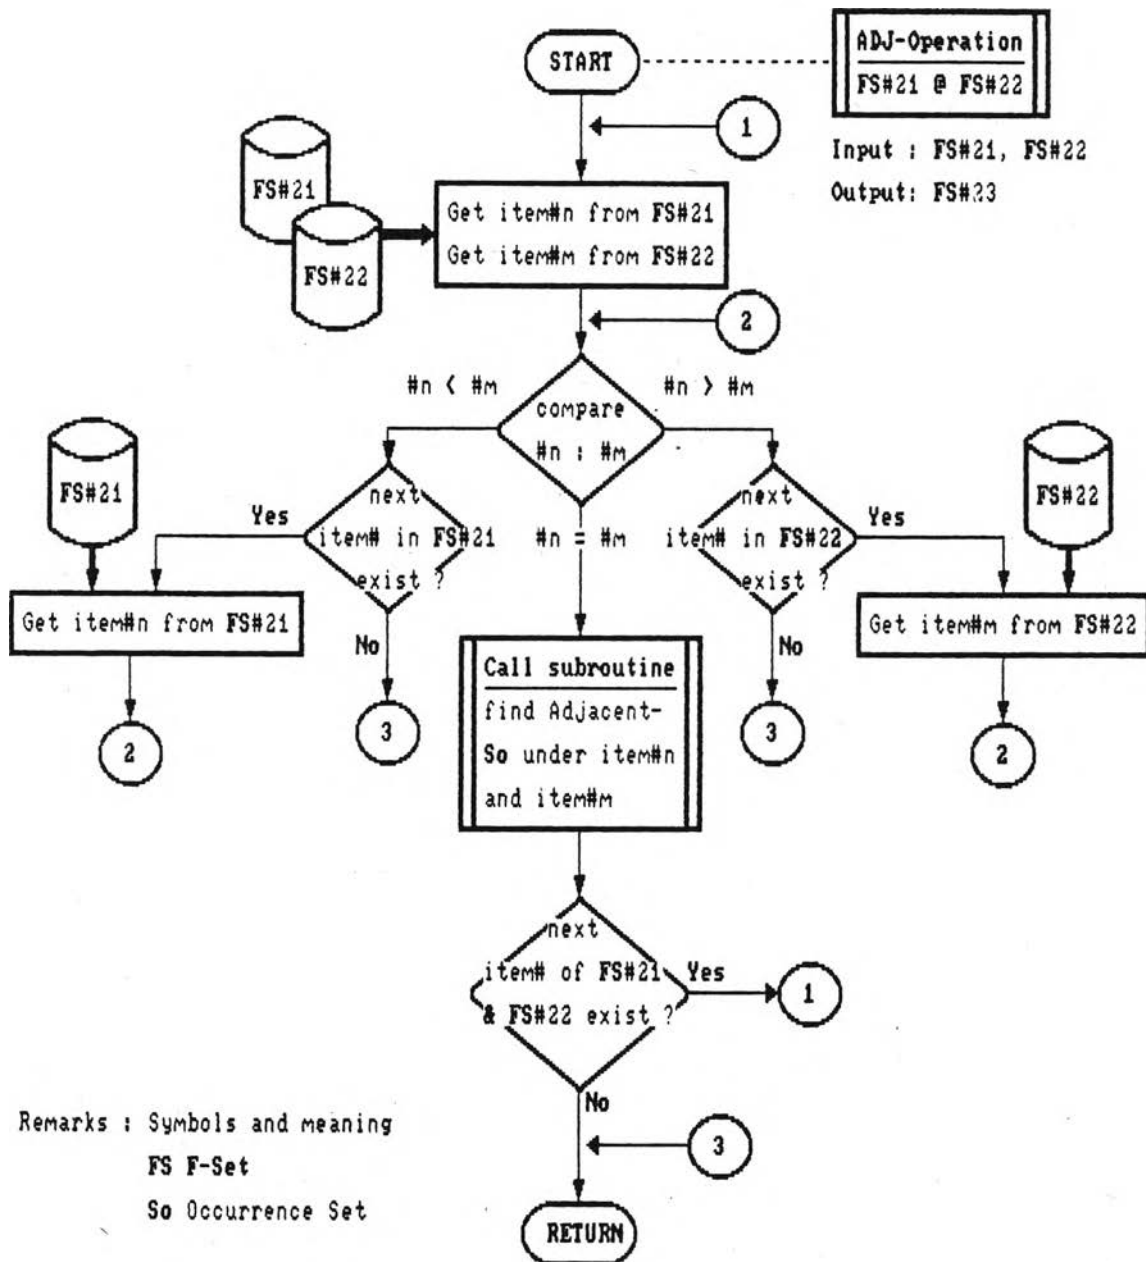
รูปที่ 4.6 แสดงผังงานการดำเนินการ AND ระหว่างเซต #21 และเซต #22



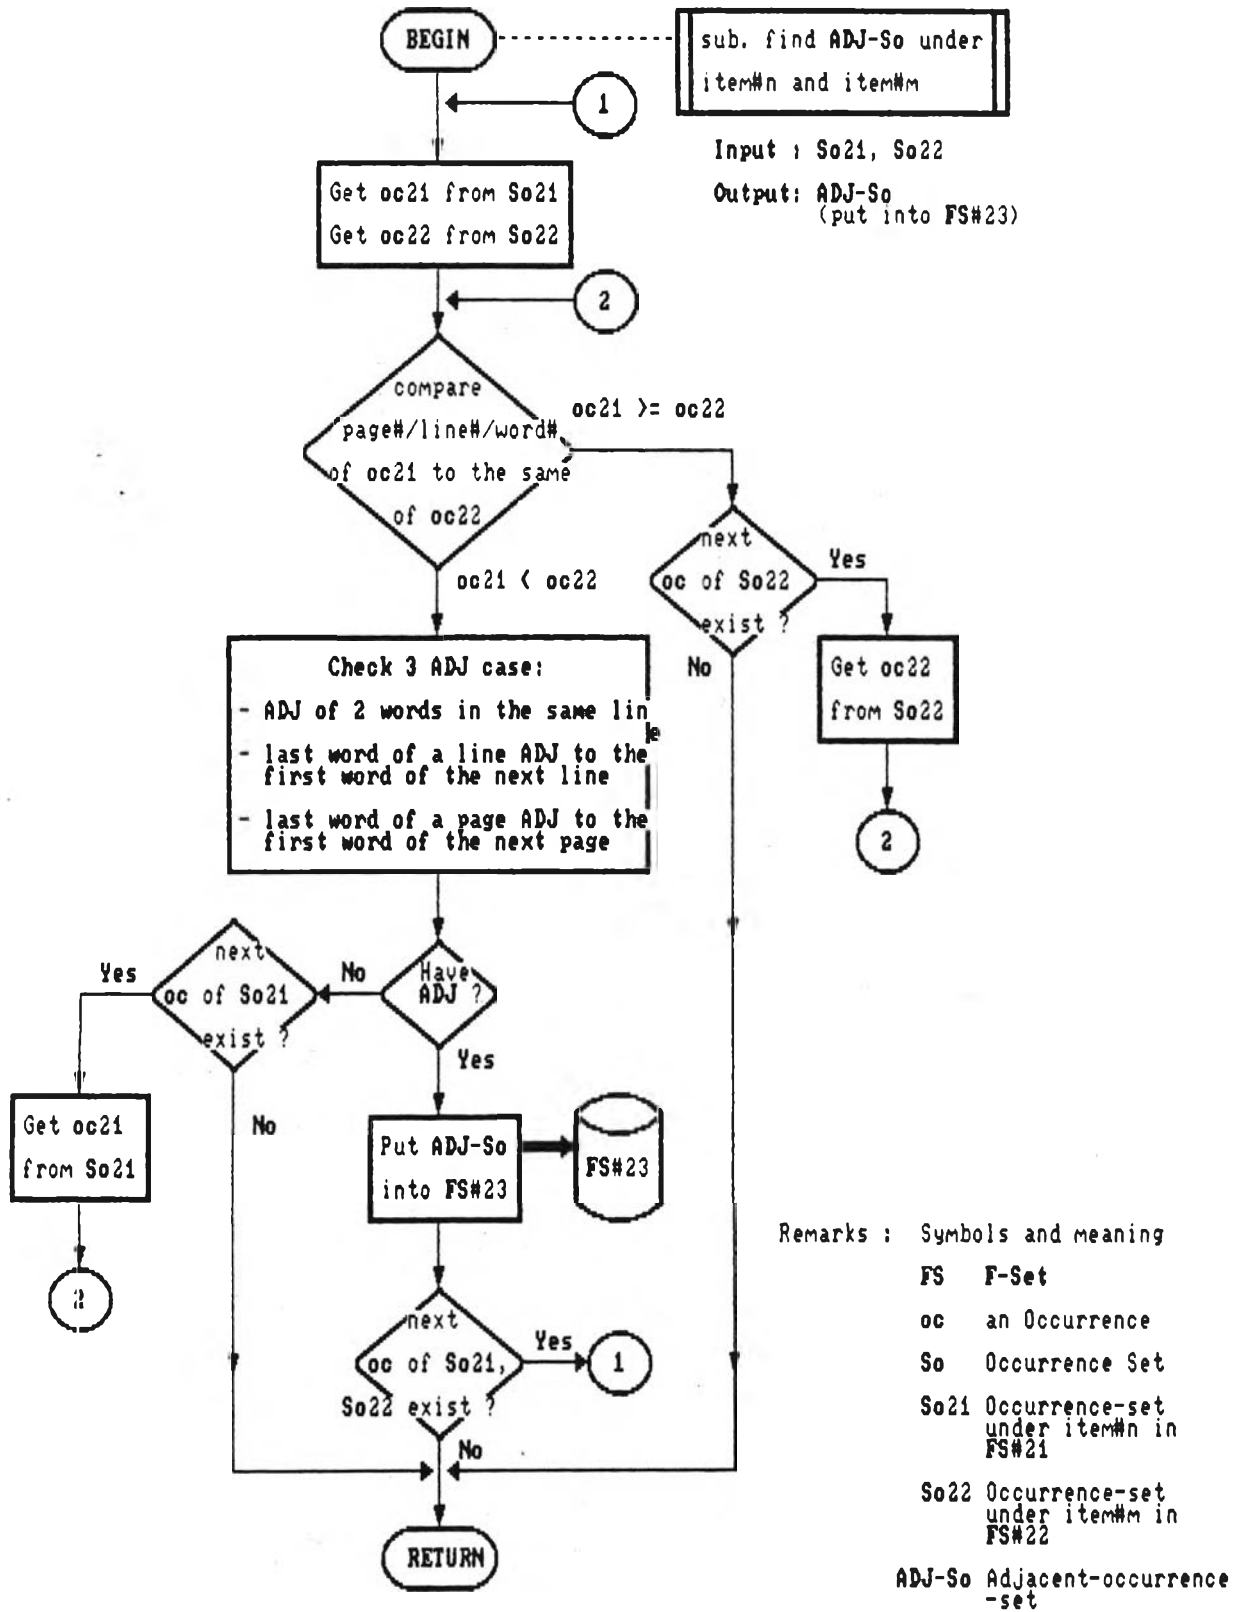
รูปที่ 4.7 แสดงผังงานการดำเนินการปฏิบัติการ OR ระหว่างเซต #21 และเซต #22



รูปที่ 4.8 แสดงผังงานการดำเนินการปฏิบัติการ NOT ระหว่างเซต #21 และเซต #22



รูปที่ 4.9/1 แสดงผังงานการดำเนินการ ADJ ระหว่างเซต #21 และเซต #22



รูปที่ 4.9/2 แสดงผังงานการดำเนินปฏิบัติการ ADJ ระหว่างเซต #21 และเซต #22

ดังนั้น #1 และ #2 จะได้ผลเป็นกลุ่มของหมายเลขข้อ ที่มีคำประชิดกันปรากฏอยู่ในข้อเหล่านั้น หมายเลขข้อกลุ่มนี้ จะถูกบันทึกเก็บไว้ในแฟ้มข้อมูล F-Set แฟ้มใหม่ พร้อมทั้งตำแหน่งของคำประชิดในหัวข้อเหล่านั้น จะถูกเก็บลงไปด้วย โดยจะใส่แฟล็กกำกับไว้ทุกตำแหน่งในกลุ่มของตำแหน่งที่ประชิดกันภายในข้อหนึ่ง ๆ และที่ตำแหน่งสุดท้ายของกลุ่ม จะใช้แฟล็กที่แตกต่างออกไป เพื่อบอกว่า เป็นตำแหน่งสุดท้ายของกลุ่มตำแหน่งที่ประชิดกันในข้อนั้น ๆ ในรูปที่ 4.9 ได้แสดงผังงานของการดำเนินการปฏิบัติกร ADJ ระหว่างเซต #21 และเซต #22 ผลลัพธ์ (ถ้ามี) จะถูกเก็บไว้ในเซต #23

#### 4.3.3 การกำหนดลำดับก่อนหลังของการดำเนินการปฏิบัติกร

เมื่อกำหนดให้สามารถเติมตัวปฏิบัติกร หลายตัวไว้ในคำสั่งค้นได้ ก็จำเป็นจะต้องกำหนดหลักเกณฑ์ไว้ให้เป็นที่เข้าใจตรงกันระหว่างผู้ใช้ กับระบบว่า ปฏิบัติกรใด จะถูกดำเนินการก่อนหลังอย่างไรบ้าง สำหรับใน BUDSIR-III จะกำหนดลำดับก่อนหลังของการดำเนินการปฏิบัติกรต่าง ๆ จากลำดับแรกไปลำดับสุดท้าย ดังนี้

ADJ

AND, NOT

OR

สำหรับตัวปฏิบัติกรที่มีคีย์เท่ากัน หรือเป็นตัวปฏิบัติกรเดียวกัน ก็ให้ถือว่า จะมีลำดับของการดำเนินการปฏิบัติกรจากซ้ายไปขวา นอกจากนั้น ยังอนุญาตให้ใช้วงเล็บ สำหรับเปลี่ยนกฎเกณฑ์จากที่กำหนดลำดับไว้ดังกล่าวได้ โดยระบบจะพิจารณาดำเนินการในส่วนที่อยู่ภายในวงเล็บเป็นลำดับแรกสุด และกรณีที่มีวงเล็บซ้อนกันหลายชั้น ก็จะเริ่มทำจากวงเล็บชั้นในสุดออกมาทีละชั้น การใช้งานวงเล็บต้องใส่วงเล็บเปิด และวงเล็บปิดให้ถูกต้อง มิฉะนั้น จะถือว่าผิดรูปแบบการบอคำสั่งค้น และจะยกเลิกการค้นทันที

#### 4.3.4 ขบวนการสืบค้นสารสนเทศพระไตรปิฎก

ในขบวนการสืบค้นสารสนเทศของ BUDSIR-III จำเป็นต้องกำหนดแนวทางของการดำเนินขั้นตอนที่สำคัญ ๆ ดังต่อไปนี้ คือ

- การแปลย่อคำคำสั่งค้น (search formula interpretation)
- การค้นหาคำในโครงสร้างแบบทรี ของแฟ้มพจนานุกรม
- การค้นหาส่วนของคำ หรือ partial word (ประเภทที่ 1) ในแฟ้มพจนานุกรม ด้วยวิธีการของ คอนท-มอริส-แพรท สตรีงแมชชีน
- การค้นหาส่วนของคำ หรือ partial word (ประเภทที่ 2) ในแฟ้มพจนานุกรม ด้วย



วิธีการของ คอนท-มอริส-แพรท สตรีงแมชชีน (ปรับปรุงใหม่)  
สำหรับรายละเอียดของแต่ละขั้นตอนนั้น ก็จะอธิบายเป็นลำดับต่อไป

### การแปลงย้อยคำสั่ง

เนื่องจากคำสั่งคนที่ผู้ใช้ป้อนเข้ามาจะอยู่ในรูปของ **สัญกรณ์แบบเติมกลาง** (infix notation) คือ ป้อนตัวปฏิบัติการไว้ระหว่างคำค้นหรือหมายเลขเซต 2 ตัว ซึ่งเป็นรูปแบบที่ผู้ใช้เข้าใจง่าย แต่เมื่อมองในแง่ของการประมวลผล จะมีความยุ่งยากในการที่ต้องกวาดดูคำสั่งนั้น ๆ กลับไปกลับมา เพื่อจะประมวลผลไปได้ตามลำดับที่ถูกต้อง

ด้วยเหตุนี้ จึงต้องเปลี่ยนคำสั่งที่ผู้ใช้ป้อนเข้ามานั้น ให้อยู่ในรูปของ **สัญกรณ์แบบเติมท้าย** (suffix notation) (Tremblay 1981: 457-472) ทั้งนี้ เป็นการตรวจสอบไปต่ว่า คำสั่งที่ป้อนเข้ามานั้น มีความผิดพลาดทางวากยสัมพันธ์ (syntax error) หรือไม่ และคำสั่งคนที่แปลงรูปแล้วนี้ จะมีการเรียงลำดับของตัวปฏิบัติการที่ต้องทำก่อนหลัง จากซ้ายไปขวา ซึ่งพร้อมที่จะถูกนำไปประมวลผลขั้นตอนต่อไป

ตัวอย่างเช่น	( <b>อานนท</b> + <b>อานนโท</b> ) & <b>อายุสมา</b>	เป็นสัญกรณ์แบบเติมกลาง
และจะได้ว่า	<b>อายุสมา อานนท อานนโท + &amp;</b>	เป็นสัญกรณ์แบบเติมท้าย

ในขั้นตอนประมวลผลถัดไป ก็จะเป็นการแปลคำสั่ง โดยจะต้องใช้ **ตัวเรียงทับซ้อน** (stack) สำหรับเป็นที่เก็บข้อมูลชั่วคราวด้วย ส่วนการประมวลผลจะมีขั้นตอนย่อย ๆ ดังนี้

ก. ดึงข้อมูลจากคำสั่งคนมา 1 โทเคน (token)

ข. พิจารณาโทเคนนั้นว่าเป็น ตัวปฏิบัติการ (operator) หรือ ตัวถูกปฏิบัติการ (operand)

- ถ้าเป็นตัวถูกปฏิบัติการ จะพิจารณาว่าเป็น **คำศัพท์** หรือเป็น **หมายเลขเซต** ของ F-Set

-: ถ้าเป็นหมายเลขเซต (#n) จะถูกตรวจสอบว่ามีอยู่จริงหรือไม่ แล้วจึงนำไปฝากเก็บไว้ใน ตัวเรียงทับซ้อน จากนั้นไปทำข้อ จ.

-: ถ้าเป็นคำศัพท์ จะใช้คำนั้นค้นหาสารสนเทศจากแฟ้มพระไตรปิฎก แล้วสร้างเป็นแฟ้ม F-Set ชั่วคราว (ซึ่งจะยังไม่ได้รับหมายเลข และลงทะเบียในแฟ้มใดเรกทอรีของ F-Set) แล้วเก็บชื่อแฟ้มชั่วคราวนี้ไว้ใน ตัวเรียงทับซ้อน จากนั้นไปทำข้อ จ.

- ถ้าเป็นตัวปฏิบัติการจะดึง ตัวถูกปฏิบัติการที่ฝากเก็บไว้ใน ตัวเรียงทับซ้อน ออกมา 2 ตัว แล้วไปทำข้อ ค.

ค. พิจารณาว่า ตัวปฏิบัติการเป็น AND, OR, NOT หรือ ADJ แล้วนำตัวถูกปฏิบัติการ 2 ตัวนั้นไปดำเนินการตามขั้นตอนของปฏิบัติการนั้น ๆ จนเสร็จ แล้วไปทำข้อ ง.

ง. นำผลลัพธ์ที่ได้จากการดำเนินการไปฝากเก็บไว้ใน ตัวเรียงทับซ้อน แล้วไปทำข้อ จ.

- จ. พิจารณาว่า ยังมีโทเคนถัดไปในคำสิ่งคั่นหรือไม่
- ถ้ายังมี ให้กลับไปทำข้อ ก.
  - ถ้าไม่มี ให้ดึงผลลัพธ์จาก ตัวเรียงกับซ้อน ออกมาเป็นผลลัพธ์สุดท้าย ซึ่งจะถูกนำไปแสดงแก่ผู้ใช้ต่อไป

#### การค้นคำในโครงสร้างแบบทรี ของแฟ้มพจนานุกรม


เนื่องจากแฟ้มพจนานุกรม แยกเก็บคำศัพท์ไว้เป็นกลุ่ม ๆ ตามพยัญชนะตัวแรกของคำศัพท์ที่เหมือนกัน แล้วภายในกลุ่มจะเก็บคำศัพท์ไว้ในโครงสร้างแบบทรี ลักษณะของเทอมที่จะนำมาใช้ค้นหาคำศัพท์ในแฟ้มพจนานุกรมได้โดยตรง มี 3 รูปแบบ ได้แก่

- คำศัพท์เดี่ยว เช่น อานนท ปญญา สงฺขาร
- ส่วนของคำเติมท้ายด้วย \* เช่น วิญญาณ\* สงฺสรา\*
- ส่วนของคำเติมท้ายด้วย ? เช่น สงฺสรา??? ชมวิ????

ส่วนขั้นตอนการค้นคำ มีดังต่อไปนี้

- ก. เริ่มแรกจะนำส่วนของคำไม่รวม \* หรือ ? มาพิจารณาก่อนว่า พยัญชนะตัวแรกของเทอมนั้น ตรงกับกลุ่มคำศัพท์ใดในแฟ้มพจนานุกรม ซึ่งในกรณีนี้อักษรตัวแรกของเทอมเป็นสระ "เ" หรือ "โ" ก็จะข้ามไปดูลักษณะถัดไปที่เป็นพยัญชนะ ต่อไปจะใช้ส่วนของคำนั้น ไล่ค้นหาคำศัพท์ที่เหมือนกันในโครงสร้างแบบทรี
- ข. ใช้ส่วนของคำนั้น เทียบเคียงกับคำศัพท์ที่เป็นส่วนยอด (root) ถ้าตรงกันให้ไปทำข้อ ฉ. แต่ถ้าไม่ตรงกันให้ไปทำข้อ ค.
- ค. พิจารณาว่า ส่วนของคำมีค่าน้อยกว่า หรือมากกว่าส่วนยอดนั้น
- ถ้ามีค่าน้อยกว่าส่วนยอด ให้ไล่ลงไปทางโนนดซ้าย (left node) ของส่วนยอดนั้น
  - ถ้ามีค่ามากกว่าส่วนยอด ให้ไล่ลงไปทางโนนดขวา (right node) ของส่วนยอดนั้น
- และพิจารณาว่า มีโนนดซ้ายหรือขวาในระดับถัดไป ตามต้องการหรือไม่
- : ถ้าไม่มีโนนดระดับถัดไปทางด้านที่จะไล่ลงนั้น แสดงว่า ไม่มีคำที่ค้นหา ให้ไปทำข้อ ฉ.
  - : ถ้ายังมีโนนดระดับถัดไป ก็ให้มองโนนดนั้นเป็นส่วนยอดอีก แล้วย้อนกลับไปทำข้อ ข.
- ง. เมื่อได้คำศัพท์ที่ตรงกันแล้ว ต้องดูความถูกต้องอีกครั้ง โดยดูว่า เทอมที่ใช้ค้นเป็น คำเต็ม หรือ ส่วนของคำที่มี ?, \* เติมท้ายอยู่
- ถ้าเทอมใช้ค้นเป็น คำเต็ม แสดงว่า ได้คำศัพท์ที่ตรงกันทั้งคำแล้ว ให้ไปทำข้อ ฉ.
  - ถ้าเป็นส่วนของคำที่มี "\*" เติมท้าย แสดงว่า คำศัพท์ที่พบนั้น เป็น 1 คำที่อยู่ในข่ายความ ต้องการ เพราะขึ้นต้นเหมือนส่วนของคำที่ใช้ค้น แล้วไปทำข้อ จ.

- ถ้าเป็นส่วนของคำที่มี "?" เติมท้าย ต้องมานับจำนวนอักษรข้างท้ายของคำค้นที่ ถัดจากส่วนที่ตรงกับเทอมค่านั้น ว่ามีกี่ตัว ถ้ามีจำนวนอักษรไม่เกินจำนวน "?" ที่เติมท้ายเทอมใช้ค้น ก็จะได้ว่า คำค้นที่ค้นนั้น เป็น 1 คำที่อยู่ในข่ายความต้องการ แล้วไปทำข้อ จ.
- จ. หาคำค้นที่อื่น ๆ ที่อยู่ในข่ายความต้องการ โดยไล่ตามตัวชี้บอกคำค้นที่มีค่าน้อยกว่า กับตัวชี้บอกคำค้นที่มีค่ามากกว่า และพิจารณาคำค้นที่นั้น ๆ ว่ามีคุณสมบัติตามต้องการหรือไม่ ด้วยวิธีนี้ ก็จะได้กลุ่มของคำค้นทั้งหมดที่ค้นหา แล้วไปทำข้อ ฉ.
- ฉ. บอกผลการค้นแก่ผู้ใช้ว่า ค้นหาพบหรือไม่ และสิ้นสุดการค้นคำ



- เส้นชี้อยู่ระหว่างโหนด root-left-right
- - - ทิศทางไล่หาคำตามค่าแอลเกิ ใช้สำหรับกรณีค้นด้วยส่วนของคำ


รูปที่ 4.10 แสดงภาพจำลองวิธีการไล่ค้นหาคำค้นที่ในโครงสร้างแบบทรี

#### การค้นหาส่วนของคำ (ประเภท 1) ในแฟ้มพจนานุกรมโดยวิธีค้นหา-มอริส-แพท

รูปแบบของ ส่วนของคำ (ประเภท 1) ได้แก่ กลุ่มตัวอักษรที่มี "\*" นำหน้า และอาจจะมี "\*" หรือ "?" เติมไว้ท้ายเทอมที่ใช้ค้นได้ด้วย ตัวอย่างเช่น \*กุมาร \*กุมาร\* \*กุมาร?? เป็นต้น

การค้นหาส่วนของคำรูปแบบนี้ จะทำการค้นจากแฟ้มดิกแพค (Dict-Pack) ของพจนานุกรม เมื่อพบคำค้นหรือกลุ่มคำค้นที่อยู่ในข่ายความต้องการแล้ว ก็สามารถไปค้นข้อมูลรายละเอียดเกี่ยวกับคำค้นที่นั้น ๆ จากในฐานข้อมูลพระไตรปิฎกได้เช่นเดียวกัน

วิธีการที่นำมาใช้สำหรับค้นหาส่วนของคำ (ประเภท 1) เรียกว่า **วิธีเทียบกลุ่มตัวอักษรของคнут-มอริส-แพรท** (Knuth-Morris-Pratt string-matching) (Baase 1978: 175-183) ซึ่งมีหลักการที่แตกต่างจากการเทียบเคียงกลุ่มตัวอักษรแบบธรรมดา คือ แทนที่จะนำอักษรที่จะค้นหา ไปเทียบเคียงกับอักษรในคำค้นท์ของพจนานุกรม กลับนำกลุ่มอักษรนั้น มาสร้างผังงานตรวจสอบอักษร ที่ประกอบด้วยขั้นตอนย่อย ๆ ชุดหนึ่ง แล้วนำคำค้นท์จากแฟ้มดิกแพค มาผ่านขั้นตอนการตรวจตามผังงานดังกล่าวแทน ซึ่งก็จะได้ผลลัพธ์ออกมาว่า พบกลุ่มอักษรที่ค้นหา ในคำค้นท์นั้นหรือไม่ ตัวอย่างเช่น ต้องการค้น \*กฤษณา\* จะได้ผังงานของคнут-มอริส-แพรท เป็นดังนี้



รูปที่ 4.11 แสดงแผนผังของคнут-มอริส-แพรท สร้างจากกลุ่มอักษร "กฤษณา"

ความหมายของสัญลักษณ์ต่าง ๆ ในแผนผัง มีดังนี้

- (a) วงกลมที่มีตัวอักษรบรรจุอยู่ คือ จุดตรวจสอบอักษรแต่ละจุดของผังงาน โดยเปรียบเทียบอักษรที่ดึงมาจากคำค้นท์ว่า ตรงกับอักษรที่บรรจุอยู่ในวงกลมหรือไม่
- (\*) วงกลมที่มี "\*" บรรจุอยู่ คือ จุดสิ้นสุดการตรวจ ถ้าการตรวจดำเนินผ่านทุกขั้นตอนไปถึงจุดนี้ แสดงว่า พบกลุ่มอักษรที่ต้องการในคำค้นท์ที่นำมาตรวจ
- $\xrightarrow{s}$  ลูกศรที่มีอักษร s กำกับ คือ success link หมายถึง ตัวชี้บอกทิศทางที่จะไปเมื่อการเปรียบเทียบอักษรที่จุดตรวจนั้น ๆ สำเร็จ คือ เปรียบเทียบแล้วอักษรตรงกัน
- $\xrightarrow{f}$  ลูกศรที่มีอักษร f กำกับ คือ failure link หมายถึง ตัวชี้บอกทิศทางที่จะไปเมื่อการเปรียบเทียบอักษรที่จุดตรวจนั้น ๆ ล้มเหลว คือ เปรียบเทียบแล้วอักษรไม่ตรงกัน

การสร้างผังงานของคнут-มอริส-แพรท มีขั้นตอนดังนี้

- ก. กำหนดจุดตรวจสอบในผังงาน โดยใช้อักษรแต่ละตัวของกลุ่มอักษรต้นแบบ และให้หมายเลขประจำจุดตรวจเหล่านั้น เริ่มตั้งแต่เลข 1 เป็นต้นไป ส่วนจุดเริ่มต้นสำหรับดึงอักษรถัด

ไปจากคำที่จะตรวจ ก็กำหนดให้เป็น หมายเลข ๐

ข. สร้างตัวชี้ FLINK (failure link) ของแต่ละจุดตรวจ สำหรับบอกตำแหน่งที่จะไป เมื่อการเปรียบเทียบอักษรที่จุดนั้น ๆ ให้ผลล้มเหลว การบอกตำแหน่งจะใช้เป็นตัวเลข ตามที่กำหนดไว้ในข้อ ก. ซึ่งการกำหนดค่าให้แก่ FLINK แต่ละตัว มีหลักการ ดังนี้คือ

- กำหนดให้ FLINK ของจุดที่ 1 เป็นตำแหน่งที่ ๐ คือ


$$FLINK(1) = 0$$

- กำหนดให้ FLINK ของจุดอื่น ๆ คือจุดที่  $i$  เป็นตำแหน่ง  $j$


$$FLINK(i) = j$$

โดยที่  $j < i$  และมีกลุ่มอักษรย่อยที่จุดเริ่มต้นจำนวน  $j-1$  ตัว ที่เหมือนกันตัวต่อตัว กับกลุ่มอักษรย่อยจำนวน  $j-1$  ตัว ที่นำหน้าอักษรตำแหน่งที่  $i$  ในที่นี้  $j$  ต้องเป็น จำนวนเต็มใหญ่ที่สุด ที่เป็นไปได้ตามข้อกำหนดทั้งสอง (ดังแสดงในรูปที่ 4.13)

แต่ ถ้าไม่มีโหมด  $j$  ที่เป็นไปตามเงื่อนไขดังกล่าว ให้กำหนด  $FLINK(i) = 1$



หรืออาจอยู่ในอีกรูปแบบหนึ่ง ดังนี้



รูปที่ 4.12 แสดงการกำหนดค่า FLINK ในกรณีที่มีกลุ่มอักษรย่อยซ้ำกันภายใน

การใช้ผังงานของคนหมู่มาก-มอริส-แพททรวางหาส่วนของคำประเภท 1 ในคำค้นท์

- ก. ดึงอักษรมา 1 ตัว จากคำค้นท์ที่นำมาตรวจหา ส่วนของคำ แล้วไปที่จุดตรวจถัดไป
- ข. เปรียบเทียบอักษรจากคำค้นท์ กับอักษรที่จุดตรวจว่าตรงกันหรือไม่
- ถ้าตรงกัน ให้ไปทำข้อ ค.
  - ถ้าไม่ตรงกัน ให้ย้ายจุดไปตามที่ระบุไว้ใน FLINK ของจุดนั้น แล้วพิจารณาว่าจุดที่ย้ายมานี้เป็น 0 หรือไม่
    - : ถ้าเป็นตำแหน่ง 0 ให้ไปทำข้อ ง.
    - : ถ้าไม่เป็นตำแหน่ง 0 ให้ใช้อักษรเดิมแล้วไปทำข้อ ข.
- ค. ถึงจุดสิ้นสุดแล้วหรือไม่
- ถ้ายังไม่ถึงจุดสิ้นสุด ให้ไปทำข้อ ง.
  - ถ้าถึงจุดสิ้นสุดแล้ว ก็จบการตรวจแบบ success end
- ง. ตรวจดูว่า ยังมีอักษรถัดไปในคำค้นท์หรือไม่
- ถ้ามี ให้ไปทำข้อ ก.
  - ถ้าไม่มีอักษรให้ดึงแล้ว ก็จบการตรวจแบบ failure end

การค้นหาส่วนของคำ (ประเภท 2) ในผังพจนานุกรมโดยวิธีคนหมู่มาก-มอริส-แพทท(ปรับปรุงใหม่)


รูปแบบของ ส่วนของคำหรือกลุ่มอักษร (ประเภท 2) ได้แก่ ส่วนของคำที่มี "?" แทรกอยู่ในกลุ่มอักษร และอาจมี "\*" นำหน้า หรือมี "\*", "?" เดิมไว้ท้ายเทอมที่ใช้ค้นได้ ด้วย ตัวอย่างเช่น โววาท \*โววา\* \*โววา?ท?? เป็นต้น

การค้นหาในกลุ่มอักษรรูปแบบนี้ จะทำการค้นจากผังมดิกแพคของพจนานุกรม เช่นเดียวกับประเภทแรก และเมื่อพบคำค้นท์ หรือกลุ่มคำค้นท์ที่อยู่ในข่ายความต้องการแล้ว จะสามารถไปค้นข้อมูลรายละเอียดเกี่ยวกับคำค้นท์นั้น ๆ จากในฐานข้อมูลพระไตรปิฎกได้เช่นเดียวกัน

วิธีการที่นำมาใช้สำหรับค้นหาในกลุ่มอักษร (ประเภท 2) เรียกว่า วิธีเทียบเคียงกลุ่มอักษร KMP แบบปรับปรุง ซึ่งมีหลักการคล้ายคลึงกับที่ใช้ในประเภท 1 คือ นำกลุ่มอักษรนั้น มาสร้างผังงานตรวจสอบอักษร ที่ประกอบด้วยขั้นตอนย่อย ๆ ชุดหนึ่ง แล้วนำคำค้นท์ที่จะตรวจหาในกลุ่มอักษรที่ค้น มาผ่านขั้นตอนการตรวจตามผังงานดังกล่าว

ส่วนที่แตกต่างจากวิธีการของประเภท 1 ก็คือ จะมีการสร้าง FLINK ไว้สองชุด เฉพาะของจุดตรวจที่ i ซึ่งอยู่ถัดจาก "?" (คือจุดตรวจที่ i-1 และที่จุดนี้จะยอมรับอักษรทุกตัว) เนื่องจากไม่อาจคาดเดาได้ว่า หน้าตำแหน่ง i จะมีกลุ่มอักษรย่อยซ้ำกันหรือไม่ คำ FLINK(i) คำแรกใช้สำหรับกรณีมีอักษรซ้ำ ส่วนอีกคำคือ FLINK(i)=1 ซึ่งใช้ในกรณีไม่มีอักษรซ้ำ จากนั้นในการตรวจคำค้นท์ เมื่อผ่านจุดตรวจ "?" มาแล้ว ตัวอักษรได้ถูกกำหนดลงไปที่จุดตรวจนั้น

และเมื่อนั้น จึงจะสามารถเลือกได้ว่า FLINK(i) เป็นค่าใด ด้วยเหตุนี้ ในการตรวจอักษร ถ้ามีการย้อนกลับไปตั้งต้นที่จุดตรวจที่ 1 ใหม่ ก็จะทำให้ FLINK(i) ต้องมีการพิจารณาค่าใหม่ทุกครั้งไป หลังจากสิ้นการตรวจคำค้นแต่ละคำ ก็จะได้ผลลัพธ์ออกมาตามต้องการว่า พบกลุ่มอักษรที่ค้นหา ในคำค้นที่นั้นหรือไม่ ตัวอย่างเช่น ต้องการค้น \*กุก?มา\* จะได้ผังงานของ KMP แบบปรับปรุง เป็นดังนี้



รูปที่ 4.13 แสดงแผนผังของ KMP แบบปรับปรุง ที่สร้างจากกลุ่มอักษร "กุก?มา"

การใช้ผังงานของ KMP แบบปรับปรุงใหม่ ในการตรวจหาส่วนของคำประเภท 2 ในคำค้นที่

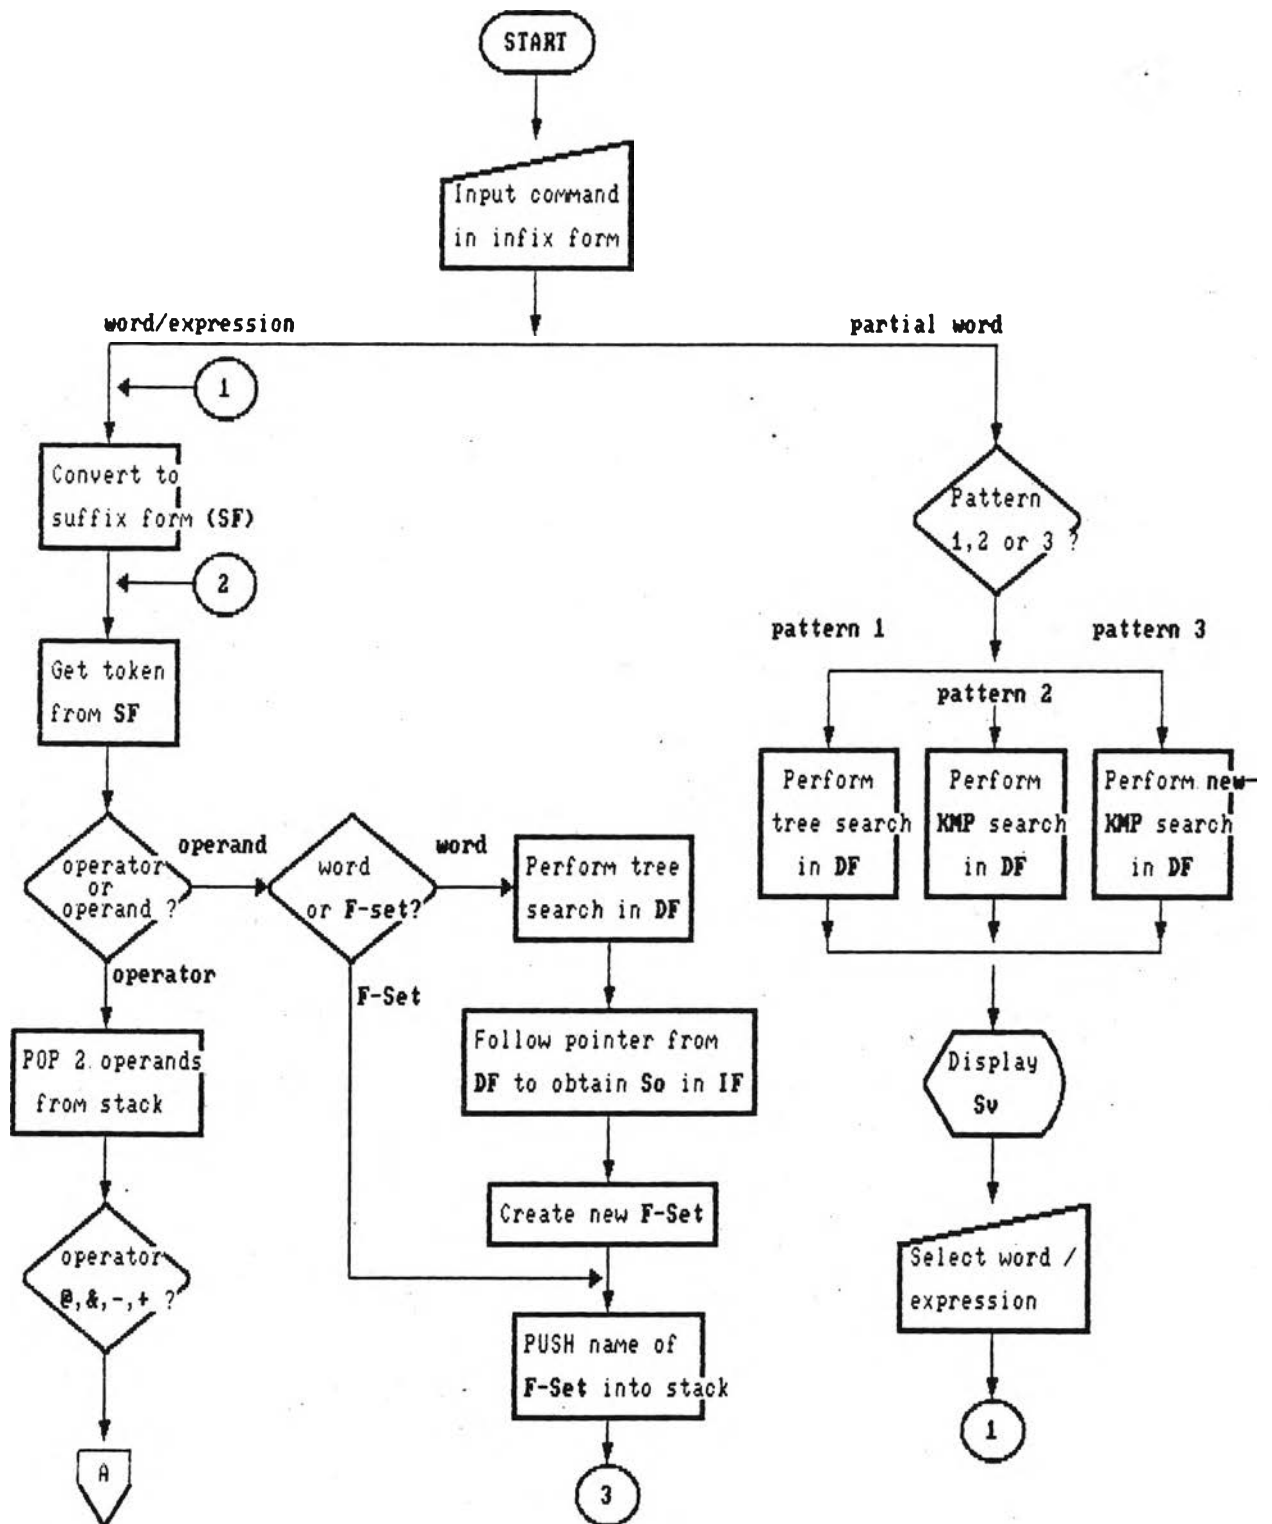
- ก. ตั้งอักษรมา 1 ตัว จากคำค้นที่นำมาตรวจหา ส่วนของคำ แล้วไปที่จุดตรวจถัดไป
- ข. ถ้าจุดตรวจนั้นเป็น "?" ให้ถือว่าผ่านการตรวจที่จุดนั้น แล้วพิจารณาอักษรที่นำมาตรวจว่า เป็นตัวที่จะทำให้เกิดอักษรซ้ำภายในกลุ่มอักษรต้นแบบ ได้หรือไม่
  - ถ้าจะเกิดอักษรซ้ำ ให้กำหนดค่า FLINK ของจุดตรวจถัดไปตามที่เตรียมไว้
  - ถ้าไม่เกิดอักษรซ้ำ ให้กำหนดค่า FLINK ของจุดตรวจถัดไปเป็น 1
 จากนั้น ไปทำข้อ จ.
- ค. เปรียบเทียบอักษรจากคำค้นที่ กับอักษรประจำจุดตรวจว่าตรงกันหรือไม่
  - ถ้าตรงกัน ให้ไปทำข้อ ง.
  - ถ้าไม่ตรงกัน ให้ย้ายจุดไปตามที่ระบุไว้ใน FLINK ของจุดนั้น แล้วพิจารณาว่าจุดที่ย้ายมานี้เป็น 0 หรือไม่
    - : ถ้าเป็นตำแหน่ง 0 ให้ไปทำข้อ จ.
    - : ถ้าไม่เป็นตำแหน่ง 0 ให้ใช้อักษรเดิมแล้วไปทำข้อ ค.

- ง. ถึงจุดสิ้นสุดแล้วหรือไม่
  - ถ้ายังไม่ถึงจุดสิ้นสุด ให้ไปทำข้อ จ.
  - ถ้าถึงจุดสิ้นสุดแล้ว ก็จบการตรวจแบบ success end
- จ. ตรวจสอบว่า ยังมีอักษรถัดไปในคำค้นหรือไม่
  - ถ้ามี ให้ไปทำข้อ ก.
  - ถ้าไม่มีอักษรให้ดึงแล้ว ก็จบการตรวจแบบ failure end

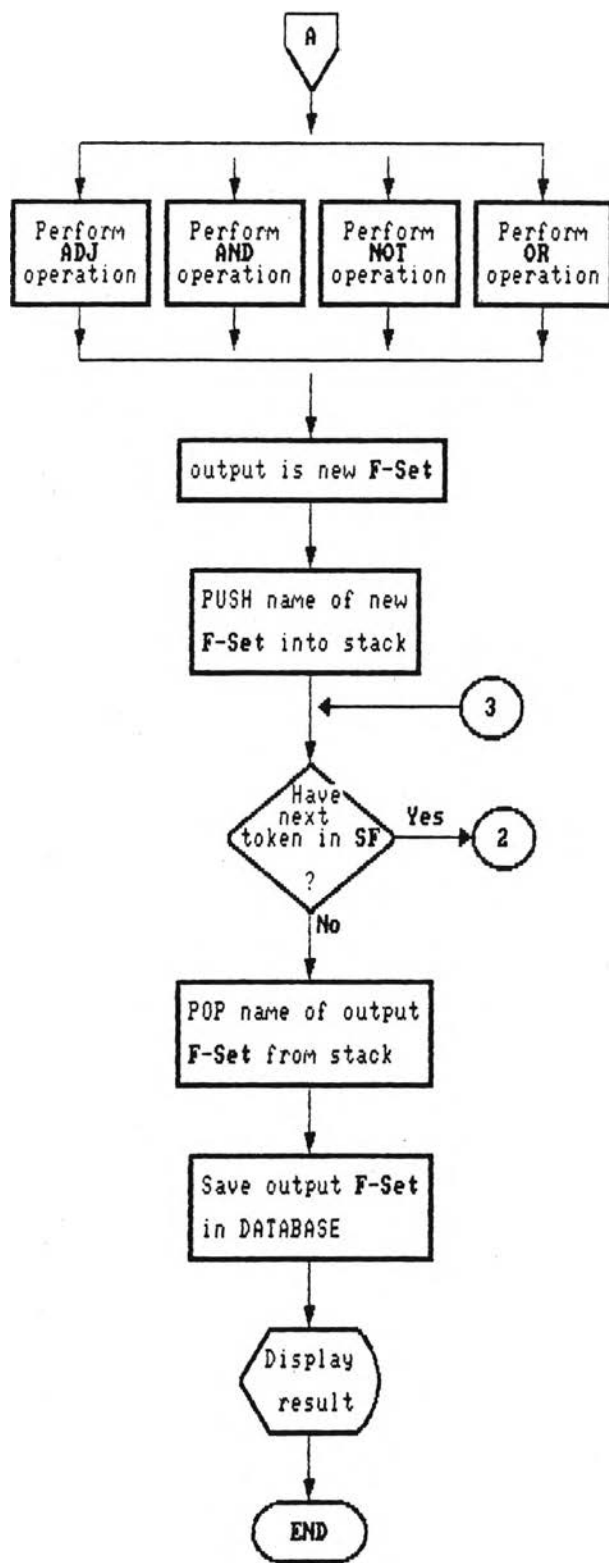
ผังงานของขบวนการสืบค้นสารสนเทศของ BUDSIR-111

ขั้นตอนต่าง ๆ ที่กล่าวมาข้างต้น จะถูกนำมาประกอบกันเข้าเป็นขบวนการสืบค้นสารสนเทศพระไตรปิฎกระบบใหม่ ดังแสดงในรูปที่ 4.14





รูปที่ 4.14/1 แสดงผังงานของขบวนการสับคั่นสารสนเทศพระไตรปิฎก ในระบบใหม่



Remarks : Symbols and meaning  
**SF** Suffix form  
**DF** Dictionary File  
**IF** Inverted File  
**Sv** Vocabulary Set  
**So** Occurrence Set  
**v** Vocabulary  
**p** Phrase

รูปที่ 4.14/2 แสดงผังงานของขบวนการสืบค้นสารสนเทศพระไตรปิฎก ในระบบใหม่