



บทที่ 3

วิธีดำเนินการวิจัย

การวิจัยครั้งนี้ต้องการศึกษาเกี่ยวกับการประมาณค่าสัมประสิทธิ์การถดถอยพหุเมื่อความผิดพลาดมีการแจกแจงแบบเบ้และมีการแจกแจงแบบหางยาวกว่าการแจกแจงแบบปกติ ในกรณีที่มีการแจกแจงของความผิดพลาดเป็นแบบหางยาวกว่าการแจกแจงแบบปกติจะศึกษาวิธีการประมาณ 4 วิธี คือวิธีกำลังสองน้อยที่สุด วิธี M-estimator โดยใช้ค่า standard deviation ของ ϵ_i เป็นตัวประมาณสเกล วิธี M-estimator โดยใช้ค่า median absolute deviation เป็นตัวประมาณสเกล และวิธี M-estimator โดยใช้ค่า the modified biweight A-estimator เป็นตัวประมาณสเกล ซึ่งวิธีการประมาณค่าแบบ M-estimator นี้ใช้เกณฑ์ความแกร่งของ Huber เป็นหลัก และพิจารณาการแจกแจงของความผิดพลาดที่มีการแจกแจงแบบปกติปลอมปนและแบบที่ ส่วนกรณีที่มีการแจกแจงความผิดพลาดเป็นแบบเบ้ต้องอาศัยการแปลงค่าที่อยู่ในรูปยกกำลังของ Box และ Cox เพื่อศึกษาวิธีการประมาณค่าสัมประสิทธิ์การถดถอยเชิงเส้นทั้ง 4 วิธี และพิจารณาการแจกแจงของความผิดพลาดที่มีการแจกแจงแบบลอกนอร์มอลแกมมา และไวบูลล์ โดยจะพิจารณาประสิทธิภาพการประมาณค่าสัมประสิทธิ์การถดถอยของทั้ง 4 วิธีด้วยอัตราส่วนผลต่างของค่าเฉลี่ยความผิดพลาดกำลังสอง* และอัตราส่วนผลต่างของความผิดพลาดกำลังสอง** ซึ่งวิธีดำเนินการวิจัยดังกล่าวมีวิธีการและแผนดำเนินงานดังต่อไปนี้

* อัตราส่วนผลต่างค่าเฉลี่ยของความผิดพลาดกำลังสอง (ratio of different average mean square error (RDAMSE)) คือผลต่างของวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองต่ำที่สุดกับวิธีที่เหลืออีก 4 วิธี ทหารด้วยค่าเฉลี่ยความผิดพลาดกำลังสองที่มีค่าต่ำสุด

** อัตราส่วนผลต่างของความผิดพลาดกำลังสอง (ratio of different mean square error (RDMSE)) คือผลต่างของวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองต่ำที่สุดกับวิธีที่เหลืออีก 4 วิธี ทหารด้วยค่าเฉลี่ยความผิดพลาดกำลังสองที่มีค่าต่ำสุด หลังจากนั้นหาผลรวมของการกระทำซ้ำ แล้วหารด้วยจำนวนครั้งของแต่ละวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองต่ำที่สุด

3.1 วิธีมอนติคาร์โล (Monte Carlo method)

เทคนิคการจำลองตัวแบบทางคณิตศาสตร์ที่นิยมใช้วิธีหนึ่ง คือ วิธีมอนติคาร์โล ซึ่งเป็นการจำลองตัวเลขสุ่ม (random number) มาช่วยในการหาค่าตอบของปัญหาที่ต้องการศึกษา โดยการสร้างข้อมูลให้มีสภาพการแจกแจงตามที่ต้องการ ซึ่งขั้นตอนของวิธีมอนติคาร์โลที่ใช้กันอยู่ในปัจจุบันแบ่งเป็น 3 ขั้นตอนดังนี้

3.1.1 การสร้างตัวเลขสุ่ม การใช้ตัวเลขสุ่มเป็นสิ่งสำคัญมากในวิธีมอนติคาร์โล เพราะว่าหลักการของวิธีมอนติคาร์โลนั้นจะใช้ตัวเลขสุ่มมาช่วยในการหาค่าตอบของปัญหาซึ่งลักษณะของตัวเลขสุ่มจะมีการแจกแจงแบบสม่ำเสมอ (uniform distribution) ในช่วง (0,1) สำหรับวิธีสร้างตัวเลขสุ่มนั้นมีผู้เสนอไว้หลายวิธี แต่วิธีหนึ่งที่ดีก็คือ วิธีของไวท์และชมิทท์ (White and Schmidt 1795:421) ที่ได้เสนอไว้กล่าวคือ ลักษณะของตัวเลขสุ่มที่ได้มีการแจกแจงแบบสม่ำเสมอในช่วง (0,1) และเป็นอิสระซึ่งกันและกัน ซึ่งรายละเอียดเสนอไว้ในภาคผนวก ก.

3.1.2 การประยุกต์ปัญหาที่ต้องการศึกษาเพื่อใช้กับตัวเลขสุ่ม ซึ่งขั้นตอนนี้ขึ้นอยู่กับลักษณะของปัญหาที่ต้องการศึกษา บางปัญหาอาจไม่ใช้ตัวเลขสุ่มโดยตรง แต่จะมีขั้นตอนอื่นอีกหลาย ๆ ขั้นตอนซึ่งบางครั้งต้องใช้ตัวเลขสุ่ม

3.1.3 การทดลองกระทำซ้ำ (replication) เมื่อประยุกต์ปัญหาให้ใช้กับตัวเลขสุ่มได้แล้ว ขั้นตอนไปก็คือการทดลองโดยกระบวนการของเลขสุ่ม (random process) มากระทำในลักษณะที่กระทำซ้ำ ๆ กัน เพื่อหาค่าตอบของปัญหาที่ต้องการศึกษา

3.2 แผนค่า เป็นการวิจัย

ในการวิจัยครั้งนี้ได้กำหนดสถานการณ์ต่าง ๆ โดยการสุ่มตัวอย่างจากประชากรที่มีลักษณะการแจกแจงแบบเดียวกัน เช่น ลักษณะการแจกแจงแบบหางยาวกว่าการแจกแจงแบบปกติที่ต้องการศึกษาได้แก่ การแจกแจงแบบปกติปลอมปนและแบบที และลักษณะการแจกแจงแบบเบ้ที่ต้องการศึกษาได้แก่ การแจกแจงแบบลอกนอร์มอล แกมมา และไวบูลล์

สำหรับการแจกแจงแบบปกติปลอมปนจะกำหนด เปอร์เซนต์การปลอมปน เป็น 5 10

20 และ 30 ส่วนสเกลแพกเคอร์มี 3 ระดับคือ 5 10 และ 15 ซึ่งถ้ามีสเกลแพกเคอร์สูงจะทำให้เกิดค่าผิดปกติสูง สามารถแสดงรายละเอียดได้ในตารางที่ 3.1

ตารางที่ 3.1 แสดงค่าสเกลแพกเคอร์และ เปอร์เซนต์การปลอมปนทั้งหมดที่ใช้ในการวิจัย

C \ P	5	10	20	30
5	(5,5)	(5,10)	(5,20)	(5,30)
10	(10,5)	(10,10)	(10,20)	(10,30)
15	(15,5)	(15,10)	(15,20)	(15,30)

สำหรับการแจกแจงแบบที่จะสนใจศึกษา เมื่อระดับความเป็นอิสระ (DF) = 4 และ 8 โดยเมื่อระดับความเป็นอิสระน้อยจะทำให้เกิดหางหนาและยาวกว่าแบบปกติมากขึ้น

สำหรับการแจกแจงแบบลอกนอร์มอลสนใจศึกษาเมื่อค่า $\mu = 0$, $\sigma^2 = 1$ ซึ่งเป็นค่าเฉลี่ยและค่าความแปรปรวนของการแจกแจงแบบปกติ

สำหรับการแจกแจงแบบแกมมาจะพิจารณาเมื่อ $\beta = 5, 10$ และ 150 , $\alpha = 1$ และ 2 โดยมีประสิทธิภาพความแปรปรวนเป็น 100% และ 70% ตามลำดับ

สำหรับการแจกแจงแบบไวบูลล์จะพิจารณาเมื่อ $\beta = 5, 10$ และ 150 , $\alpha = 1$ และ 2 โดยมีประสิทธิภาพความแปรปรวนเป็น 100% และ 52% ตามลำดับ

ขนาดตัวอย่างที่ใช้สำหรับการแจกแจงของความผิดพลาดแบบปกติปลอมปน ลอกนอร์มอล แกมมา และไวบูลล์ เมื่อมีจำนวนตัวแปรอิสระ $m = 3$ จะใช้ขนาดตัวอย่าง $n = 20$ และเมื่อมีจำนวนตัวแปรอิสระ $m = 5, 10$ จะใช้ขนาดตัวอย่าง $n = 50, 100$ และ 150 ตามลำดับ ส่วนการแจกแจงของความคลาดเคลื่อนแบบที่ จะใช้ขนาดตัวอย่าง $n = 20$ และมีจำนวนตัวแปรอิสระ $m = 3, 5$ และ 10 ตามลำดับเท่านั้น

3.3 ขั้นตอนของการดำเนินงานวิจัย

การวิจัยนี้สนใจศึกษาการประมาณค่าสัมประสิทธิ์การถดถอยพหุ เมื่อค่าประมาณสเกล เปลี่ยนไป ในที่นี้พิจารณา เมื่อความผิดพลาดของข้อมูลมีการแจกแจงแบบหางยาวกว่าการแจกแจงแบบปกติ และแบบเบ้ โดยการสร้างโปรแกรมหลักจำนวน 2 โปรแกรม สำหรับการแจกแจงที่มีหางยาวกว่าการแจกแจงแบบปกติ และการแจกแจงแบบเบ้ ด้วยภาษาฟอร์แทรน IV กับเครื่อง IBM 370/3031 ซึ่งแต่ละโปรแกรมมีขั้นตอนในการดำเนินงานดังนี้

3.3.1 กำหนดลักษณะการแจกแจงของความผิดพลาด (II) ขนาดตัวอย่างและจำนวนตัวแปรอิสระ เพื่อนำไปสร้างตัวแปรตาม (y)

3.3.2 การสร้างข้อมูล คือตัวแปรตาม (y) และตัวแปรอิสระ (X) เมื่อการแจกแจงของความผิดพลาดเป็นแบบหางยาวกว่าการแจกแจงปกติ ตัวแปรตาม (y) สร้างจากตัวแปรอิสระ (X) ซึ่งเป็นค่าคงที่ และค่าความผิดพลาดมีลักษณะการแจกแจงตามที่ต้องการศึกษา โดยให้ตัวแปรตามมีความสัมพันธ์เชิงเส้นตรงกับตัวแปรอิสระ ส่วนกรณีที่มีการแจกแจงของความผิดพลาดเป็นแบบเบ้ ตัวแปรตาม (y) สร้างให้มีลักษณะการแจกแจงตามที่ต้องการศึกษาโดยไม่เป็นฟังก์ชันเชิงเส้นตรงกับตัวแปรอิสระ (X) และค่าความคลาดเคลื่อน

3.3.3 ทดสอบความเหมาะสมของตัวแปรอิสระ (y) โดยทดสอบความเป็นอิสระซึ่งกันและกันหรือไม่ เรียกว่าการทดสอบ Multicollinearity

3.3.4 การประมาณค่าสัมประสิทธิ์การถดถอยพหุเชิงเส้น เมื่อความผิดพลาดมีการแจกแจงแบบหางยาวกว่าการแจกแจงแบบปกติ โดยใช้วิธีกำลังสองน้อยที่สุด วิธี M-estimator เมื่อใช้ standard deviation ของ ϵ_i เป็นตัวประมาณสเกล (scale estimator) วิธี M-estimator เมื่อใช้ median absolute deviation (MAD) เป็น ตัวประมาณสเกล และวิธี M-estimator เมื่อใช้ the modified biweight A-estimator ที่ $C = 9$ และ 10 เป็นตัวประมาณสเกล ในที่นี้ใช้เกณฑ์ความแกร่งของ Huber

3.3.5 การประมาณค่าสัมประสิทธิ์การถดถอยพหุเชิงเส้น เมื่อความผิดพลาดมีการแจกแจงแบบเบ้จะอาศัยการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox แล้วประมาณค่าสัมประสิทธิ์การถดถอยพหุเชิงเส้นโดยใช้วิธีกำลังสองน้อยที่สุด วิธี M-estimator เมื่อใช้ standard deviation ของ ϵ_i เป็นตัวประมาณสเกล (scale estimator) วิธี M-estimator เมื่อใช้ median absolute deviation (MAD) เป็นตัวประมาณสเกล และวิธี M-estimator

เมื่อใช้ the modified biweight A-estimator ที่ $C = 9$ และ 10 เป็นตัวประมาณสเกล
 ในที่นี้ใช้เกณฑ์ความแกร่งของ Huber

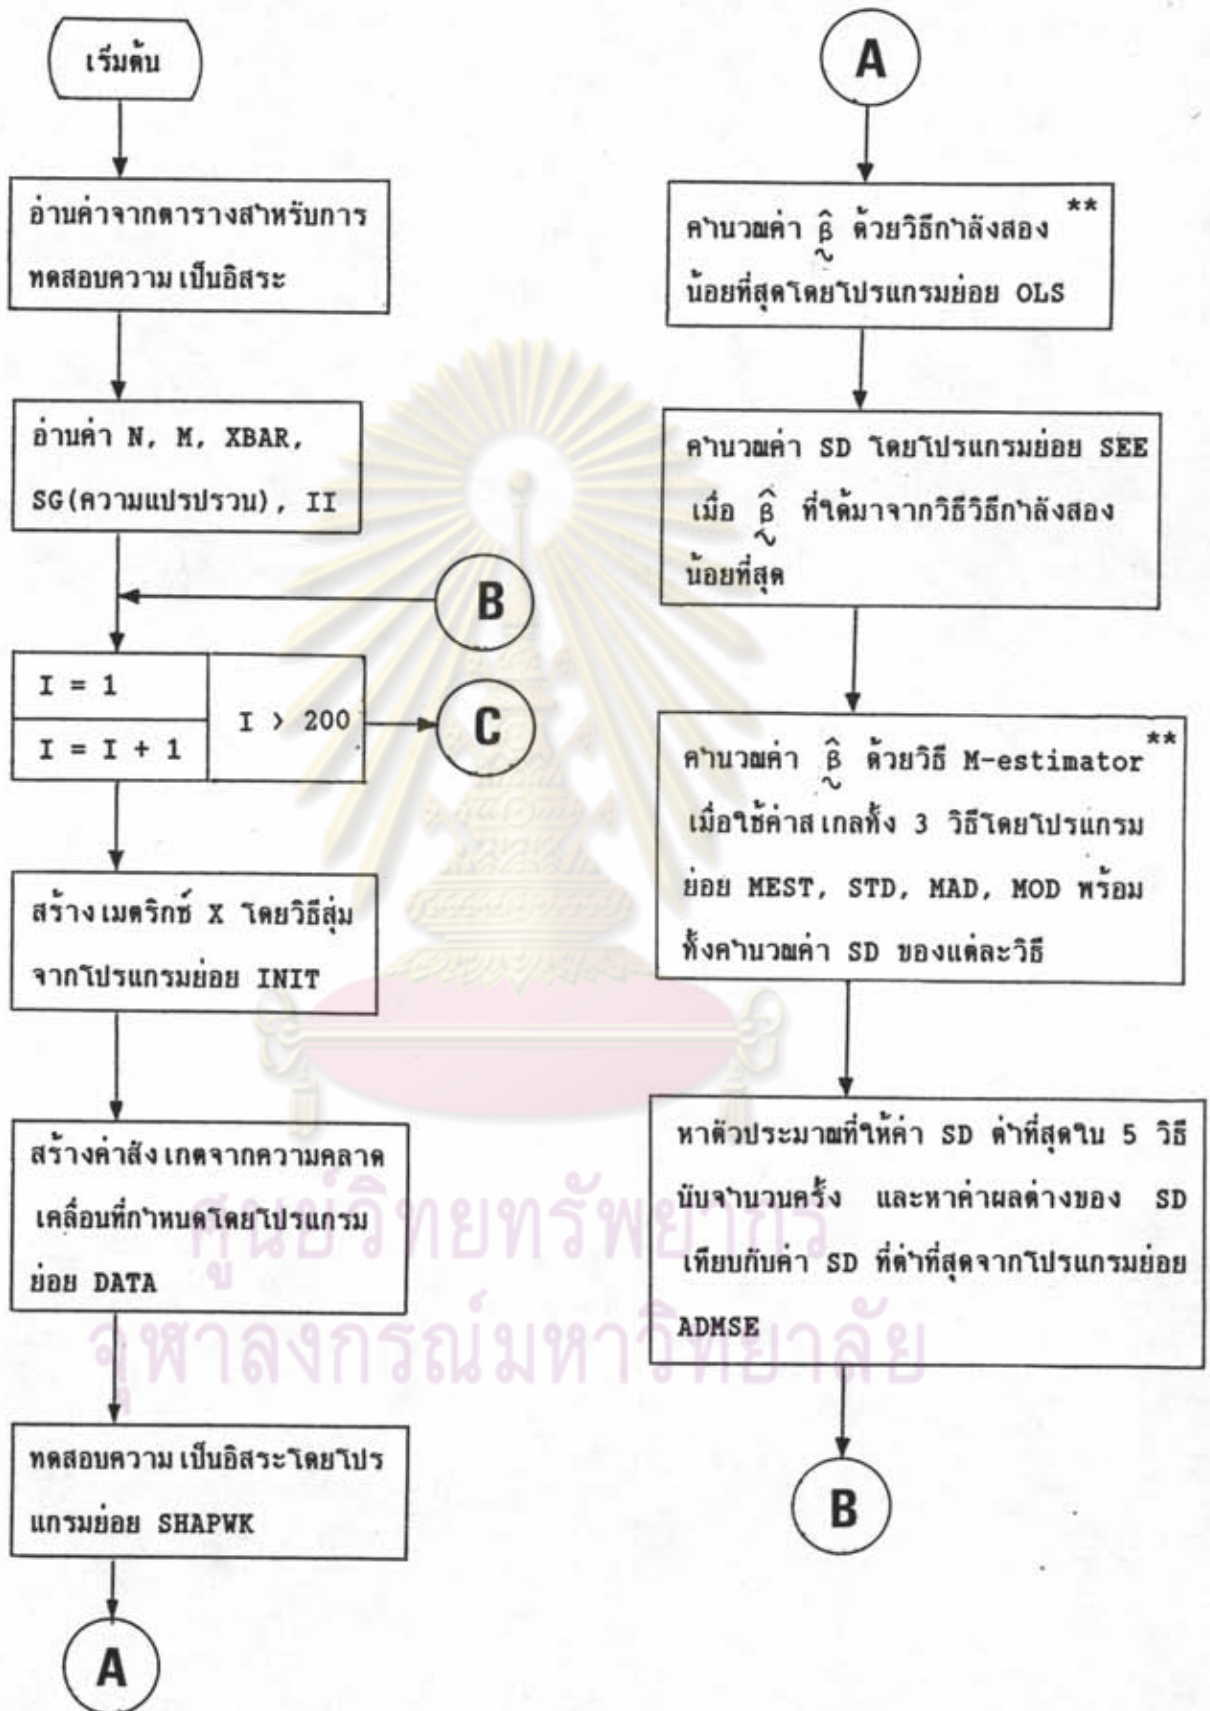
3.3.6 คำนวณหาค่าความผิดพลาดกำลังสองของการประมาณค่าสัมประสิทธิ์การถดถอย
 (mean square error) อัตราส่วนผลต่างของความผิดพลาดกำลังสองของการประมาณค่า
 สัมประสิทธิ์การถดถอย โดยเทียบกับวิธีที่ให้ค่าความผิดพลาดกำลังสองต่ำที่สุด, ค่าความแปรปรวน
 ของผลต่างความผิดพลาดกำลังสอง ค่าเฉลี่ยของความผิดพลาดกำลังสอง (AMSE) ค่าความ
 แปรปรวนของค่าเฉลี่ยความผิดพลาดกำลังสอง (STD) และอัตราส่วนผลต่างค่าเฉลี่ยของความ
 ผิดพลาดกำลังสอง โดยเทียบกับวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองต่ำที่สุด (DIFF) ของตัว
 ประมาณทั้ง 4 วิธี

3.3.7 สรุปผลในรูปแบบของตาราง

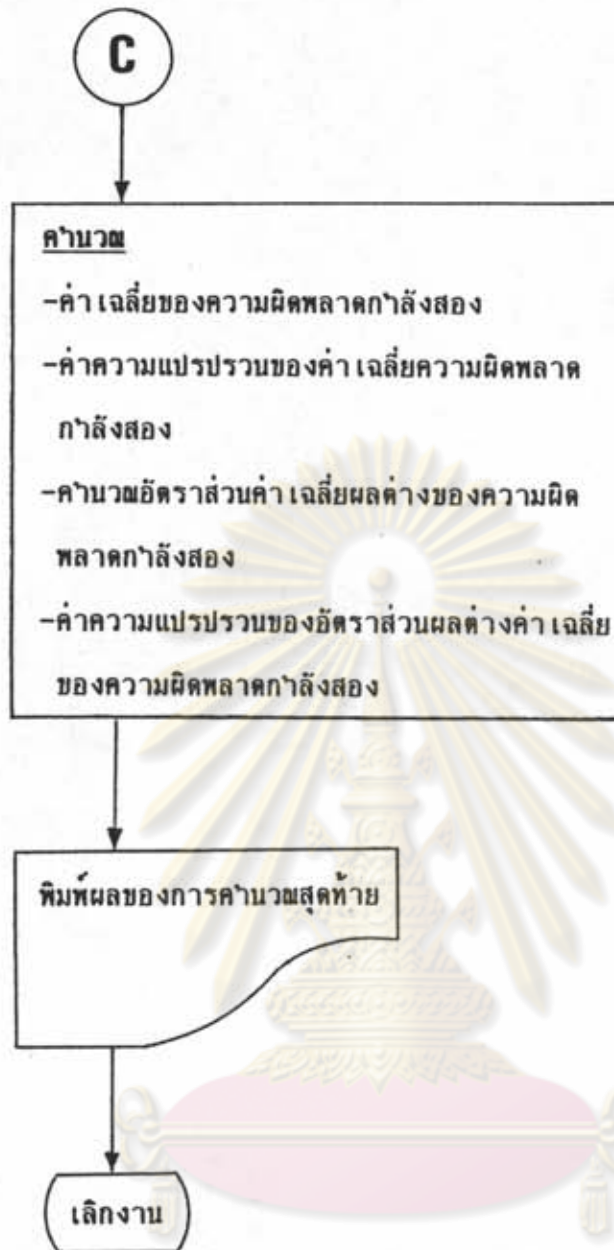
3.4 ผังงานวิธีคำนวณการวิจัย

ขั้นตอนในการคำนวณงานสามารถแสดงเป็นผังงานได้ ดังรูปที่ 3.1 ส่วนรายละเอียด
 ของโปรแกรมแสดงไว้ในภาคผนวก ค. และความหมายของสัญลักษณ์ที่ใช้ในผังงานมีดังนี้

II	รูปแบบของการแจกแจงของความผิดพลาด
N	จำนวนค่าสังเกต
M	จำนวนพารามิเตอร์
IC	สเกลแฟคเตอร์
P	เปอร์เซ็นต์การปลอมปน
AMSE	ค่าเฉลี่ยของความผิดพลาดกำลังสอง
STD	ค่าเฉลี่ยของความแปรปรวนของความผิดพลาดกำลังสอง
ARDIF	ผลต่างของค่าเฉลี่ยของความผิดพลาดกำลังสอง เมื่อเทียบกับค่าเฉลี่ย ของความผิดพลาดกำลังสอง



** กรณีที่ค่าความผิดพลาดมีการแจกแจงแบบ เบ้จะต้องทำการแปลงข้อมูลที่อยู่ในรูปยกกำลังของ Box และ Cox ก่อนการประมาณค่าทุกวิธี



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

จากรูปที่ 3.1 สามารถแยกอธิบายแต่ละขั้นตอนได้ดังนี้

3.4.1 เริ่มต้นระบบโดยการอ่านค่าจากตารางสำหรับการทดสอบความเป็นอิสระได้แก่ ตารางค่าสัมประสิทธิ์การทดสอบของ Shapiro และ Wilk และตาราง percentage point ของการทดสอบ Shapiro และ Wilk ทั้งนี้พิจารณาขนาดของตัวอย่างค่าสังเกต $n = 20, 50, 100$ และ 150 ซึ่งรายละเอียดแสดงไว้ในภาคผนวก ข.

3.4.2 อ่านค่าขนาดตัวอย่าง (N) จำนวนตัวแปรอิสระ (M) ค่าเฉลี่ย (\bar{X}) ค่าความแปรปรวน (SG) ของการแจกแจงแบบปกติ และลักษณะการแจกแจงของประชากร (II)

3.4.3 สร้างเมตริกซ์ X ที่มีการแจกแจงแบบปกติมีขนาด $n \times m$ โดยวิธีสุ่มพร้อมทั้งสร้างเมตริกซ์ $(XX)^{-1}$ จากโปรแกรมย่อย INIT

3.4.4 สร้างค่าสังเกตจากความคลาดเคลื่อนที่กำหนดตาม II จากโปรแกรมย่อย DATA ได้แก่

3.4.4.1 การแจกแจงปกติ ฟังก์ชันที่ใช้ในการแจกแจงแบบปกติจะใช้วิธีของ Box และ Muller (1958) ซึ่งเป็นวิธีที่สร้างการแจกแจงแบบปกติที่มีค่าเฉลี่ยเป็น μ และความแปรปรวนเป็น σ^2 โดย DMEAN และ $(SIGMA)^2$ คือค่าเฉลี่ยและความแปรปรวนที่กำหนดสำหรับรายละเอียดแสดงไว้ในภาคผนวก ก. การใช้ฟังก์ชันนี้ใช้คำสั่ง NORMAL(DMEAN, SIGMA) ผลลัพธ์คือ NORMAL ที่มีค่าเฉลี่ยและความแปรปรวนที่กำหนด

3.4.4.2 การแจกแจงแบบปกติปลอมปน สร้างโดยการใช้วิธีการแปลงข้อมูลมาจากการแจกแจงแบบปกติที่ได้มาจาก NORMAL(DMEAN, SIGMA) ด้วยความน่าจะเป็น $(1-P)$ เมื่อ DMEAN SIGMA และ P เป็นค่าเฉลี่ย ความแปรปรวนและเปอร์เซ็นต์การปลอมปน และได้มาจาก NORMAL(DMEAN, SG2) ด้วยความน่าจะเป็น P เมื่อ SG2 เป็นผลคูณของ IC กับ SIGMA IC เป็นสเกลแฟกเตอร์สำหรับความแปรปรวนโดยที่รายละเอียดแสดงไว้ในภาคผนวก ก.

3.4.4.3 การแจกแจงแบบที ฟังก์ชันที่ใช้คือ TDIST(NDF, DMEAN, SIGMA) โดยที่ผลลัพธ์คือค่าของ TDIST มีระดับความเป็นอิสระเป็น NDF ซึ่งสร้างจากสัดส่วนของการแจกแจงแบบปกติ และการแจกแจงแบบไคสแควร์มีระดับความเป็นอิสระเป็น NDF ค่าเฉลี่ยและความแปรปรวนของการแจกแจงแบบปกติเป็น DMEAN และ SIGMA สำหรับรายละเอียดแสดงไว้ในภาค

หมวด ก.

3.4.4.4 การแจกแจงแบบลอการิธึม หาได้จากการหา exponential ของฟังก์ชัน NORMAL(DMEAN,SIGMA) เมื่อ DMEAN และ SIGMA เป็นค่าเฉลี่ยและความแปรปรวนของการแจกแจงแบบปกติสำหรับรายละเอียดแสดงไว้ในภาคผนวก ก.

3.4.4.5 การแจกแจงแบบแกมมา ฟังก์ชันที่ใช้คือ GAMMA1(ALPHA1,BETA1) ฟังก์ชันนี้สร้างโดยวิธี reproductive property ซึ่งรายละเอียดแสดงไว้ในภาคผนวก ก. ฟังก์ชัน GAMMA1 จะกำหนดค่า ALPHA1 และ BETA1 เพื่อให้ได้ค่าเฉลี่ยและความแปรปรวนตามที่ต้องการ ผลลัพธ์คือค่า GAMMA1 จะมีการแจกแจงแบบแกมมามีค่าเฉลี่ยเป็น $BETA1 \times ALPHA1$ และความแปรปรวนเป็น $BETA1^2 \times ALPHA1$

3.4.4.6 การแจกแจงแบบไวบูลล์ ฟังก์ชันที่ใช้คือ WEIBUL(ALPHA1,BETA1) ฟังก์ชันนี้สร้างโดยวิธี inverse transformation ซึ่งรายละเอียดแสดงไว้ในภาคผนวก ก. ฟังก์ชัน WEIBUL จะกำหนดค่า ALPHA1 และ BETA1 เพื่อให้ได้ค่าเฉลี่ยและความแปรปรวนตามที่ต้องการ ผลลัพธ์คือ ค่า WEIBUL จะมีการแจกแจงแบบไวบูลล์มีค่าเฉลี่ยเป็น $BETA1 \times (1-1/ALPHA1)$ และความแปรปรวนเป็น $BETA1^2 \times [\Gamma(1+2/ALPHA1) - \Gamma^2(1+1/ALPHA1)]$

หลังจากนั้นกำหนดค่าสังเกต y ให้มีความสัมพันธ์เชิงเส้นโดยพิจารณาการแจกแจงของค่าผิดพลาด ดังนี้

3.4.4.7 เมื่อการแจกแจงของค่าผิดพลาดเป็นแบบหางยาวกว่าการแจกแจงแบบปกติ

ในการวิจัยครั้งนี้จะสร้างตัวแปรอิสระ X ซึ่งมีค่าคงที่ก่อน แล้วจึงสร้างตัวแปร y ที่มีความสัมพันธ์เชิงเส้นกับ X ให้มีลักษณะการแจกแจงตามความผิดพลาดที่กำหนด II และตามรูปแบบของความสัมพันธ์คือ $y = X\beta + \epsilon$ เมื่อ β เป็นค่าพารามิเตอร์ที่ถูกกำหนดขึ้นมา และ ϵ เป็นความผิดพลาดที่มีการแจกแจงเป็นแบบต่างๆดังที่กล่าวแล้วใน 3.4.4.1 ถึง 3.4.4.3 สำหรับการสร้าง y นั้นจะเริ่มจากการกำหนดจำนวนตัวแปรอิสระ และขนาดตัวอย่างที่ต้องการศึกษา พารามิเตอร์ β ค่าเฉลี่ย ค่าความแปรปรวน และลักษณะการแจกแจงของค่าผิดพลาด

รวมทั้งค่าคงที่ X แล้วจึงสร้าง y ตามรูปแบบดังกล่าว

3.4.4.8 เมื่อการแจกแจงของค่าผิดพลาดเป็นแบบเบ้

ในการวิจัยครั้งนี้จะสร้างตัวแปรอิสระ X ซึ่งมีค่าคงที่ก่อน แล้วจึงสร้างตัวแปร y ให้มีการแจกแจงแบบเบ้ตาม 3.4.4.4 ถึง 3.4.4.6 แล้วอาศัยการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox เพื่อสร้างตัวแปร $y^{(\lambda)}$ ที่มีความสัมพันธ์เชิงเส้นกับ X ตามรูปแบบของความสัมพันธ์คือ $y^{(\lambda)} = X\beta + \epsilon$ เมื่อ β เป็นค่าพารามิเตอร์ที่ถูกกำหนดขึ้นมา λ เป็นค่าพารามิเตอร์ของการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox และ ϵ เป็นความผิดพลาดที่มีการแจกแจงเป็นแบบสมมาตรเชิงเส้นและเป็นแบบปกติโดยประมาณ

3.4.5 การทดสอบความเหมาะสมของตัวแปรอิสระ X โดยทดสอบความเป็นอิสระซึ่งกันและกัน เนื่องจากถ้าตัวแปรอิสระเกิด multicollinearity จะทำให้การประมาณค่าสัมประสิทธิ์การถดถอยหาค่าด้วยวิธีกำลังสองน้อยที่สุด และวิธี M-estimator ลดประสิทธิภาพลง (Mongomery (ค.ศ.1982 หน้า 364-381) Mason และ Gunst (ค.ศ.1985 หน้า 401-407)) และผลของการที่ตัวแปรอิสระมีความสัมพันธ์กันหรือเกิด multicollinearity จะทำให้เมตริกซ์ X เกือบจะเป็น singular matrix นั่นคือ determinant มีค่าน้อยและ inverse มีค่าสูงซึ่งจะทำให้ความแปรปรวนของสมการถดถอยมีค่าสูง และมีผลทำให้ยอมรับ H_0 บ่อยครั้งดังนั้นการสรุปความสัมพันธ์ของ y และ X อาจเกิดความผิดพลาดได้

การทดสอบว่าเกิด multicollinearity หรือไม่อาจทำการทดสอบสมมติฐานดังนี้

สมมติฐานของการทดสอบ H_0 : ไม่เกิด multicollinearity

เทียบกับ H_a : เกิด multicollinearity

ณ. ระดับสำคัญ $\alpha = 0.05$ และ 0.01

$$\text{ตัวสถิติทดสอบ } F = \frac{(m-2) R_1^2 / (m-2)}{(n-m+1) (s-R_1^2) / (n-m+1)} \quad (\text{ไม่รวม intercept})$$

โดยที่ R_1^2 เป็นสหสัมพันธ์ (correlation) ของ Regression ที่ X_1 บน X ($j \neq i$) ;

$$i, j = 1, \dots, m$$

ขอบเขตวิกฤต F จะหาได้จากตาราง \mathcal{F} . ระดับนัยสำคัญ 0.05 และ 0.01

การตัดสินใจ จะปฏิเสธ H_0 เมื่อ F (คำนวณ) $>$ F (ตาราง)

3.4.6 การประมาณค่าสัมประสิทธิ์การถดถอยพหุด้วยวิธีกำลังสองน้อยที่สุด

3.4.6.1 เมื่อความผิดพลาดมีการแจกแจงเป็นแบบหางยาวกว่าการแจกแจงแบบปกติ โปรแกรมย่อยที่ใช้ในการประมาณค่าสัมประสิทธิ์การถดถอยคือ OLS(B) โดยที่ B เป็นเวกเตอร์ของสัมประสิทธิ์การถดถอยพหุ ซึ่งเมทริกซ์ของ X จะใช้ร่วมกับโปรแกรมหลัก เมทริกซ์ X ประกอบด้วยตัวแปรอิสระ M ตัวและตัวแปรตาม 1 ตัว N คือจำนวนข้อมูล และโปรแกรมย่อย OLS(B) จะประกอบด้วยโปรแกรมย่อยอีกดังนี้

ก) โปรแกรมย่อยสำหรับหาเมทริกซ์ผกผัน (inverse matrix) คือโปรแกรม INVS(M,A) เมื่อ M เป็นขนาดของเมทริกซ์ผกผันที่ต้องการหาและ A เป็นเมทริกซ์ผกผันที่ต้องการ

ข) โปรแกรมย่อยสำหรับประมาณค่าผิดพลาด คือโปรแกรม YRESID (X,N,M,YHAT,YRES,B) โดยที่ X เป็นเมทริกซ์ของตัวแปรอิสระและตัวแปรตาม N คือจำนวนข้อมูล M คือจำนวนตัวแปรอิสระ YHAT คือค่าประมาณ \hat{e}_i YRES คือค่าผิดพลาด และ B คือสัมประสิทธิ์การถดถอยพหุ

3.4.6.2 เมื่อการแจกแจงของค่าผิดพลาดมีการแจกแจงแบบเบ้ จะอาศัยการแปลงที่อยู่ในรูปแบบ Box และ Cox โดยโปรแกรมย่อย BOXCOX(B,FL1) ซึ่ง B คือค่าสัมประสิทธิ์การถดถอยพหุ FL1 คือ λ ซึ่งเป็นค่าประมาณ λ ที่อยู่ในรูปยกกำลังของ Box และ Cox โดยมีขั้นตอนการทำงานดังนี้

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

ขั้นตอน	ความหมาย
1	คำนวณค่าเฉลี่ยเรขาคณิต (geometric mean(G)) ของเวกเตอร์ y โดย y_i มีค่ามากกว่า 0 แล้วคำนวณค่า $y_1 = y/G$
2	กำหนดค่าเริ่มต้น ST ค่าสุดท้าย FIN เป็นขอบเขตในการหาค่า λ หรือ FL1 โดยใช้เทคนิคของการหา λ ที่มีค่าผลบวกกำลังสองของค่าผิดพลาด หรือที่มีค่า $\hat{\sigma}_e^2 \lambda$ ต่ำสุด รายละเอียดแสดงในภาคผนวก ข. ซึ่ง SSE2 แทน $\hat{\sigma}_e^2 \lambda$ ที่มีค่าต่ำสุดซึ่งใช้ในการประมาณค่า FL1 และ B

3.4.7 การหาค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error (MSE)) โดยโปรแกรมย่อย SEE(B,SE) เมื่อ B ที่เข้ามาจากวิธีกำลังสองน้อยที่สุดโดยการหาผลรวมของ MSE ของ $\hat{\beta}_i$ ที่ได้จากการประมาณเทียบกับ β ของประชากรทุกค่าของ β_i ; $i = 1, \dots, M$ แล้วหารด้วย M

$$\text{MSE ของวิธีกำลังสองน้อยที่สุด} = \frac{\sum_i^M (\hat{\beta}_i(\text{OLS}) - \hat{\beta}_i)^2}{M}$$

เมื่อ $\hat{\beta}_i(\text{OLS})$ เป็น $\hat{\beta}_i$ ของวิธีกำลังสองน้อยที่สุด

3.4.8 การประมาณค่าสัมประสิทธิ์การถดถอยพหุด้วยวิธี M-estimator โดยใช้ค่าประมาณสเกลทั้ง 3 วิธี โปรแกรมที่เรียกใช้คือ MEST ซึ่งพิจารณาตามการแจกแจงของค่าผิดพลาดดังนี้

3.4.8.1 เมื่อความผิดพลาดเป็นแบบหางยาวกว่าการแจกแจงแบบปกติ จะเรียกโปรแกรมย่อยในการประมาณค่าสัมประสิทธิ์การถดถอยแยกวิธีตามการประมาณค่าสเกลดังนี้

n) โปรแกรมย่อย BAR(B1,BMBAR,SIGMA) เมื่อ BMBAR คือค่า $\hat{\beta}_i$ ที่ได้จากการประมาณค่าโดยวิธี M-estimator เมื่อใช้ the standard deviation of location เป็นค่าประมาณสเกล และใช้เกณฑ์ความแกร่งของ Huber ที่ $b = 2$



ข) โปรแกรมย่อย MAD(B1,BMMAD,SIGMA) เมื่อ BMMAD คือค่า $\hat{\beta}$ ที่ได้จากการประมาณค่าโดยวิธี M-estimator เมื่อใช้ median absolute deviation เป็นค่าประมาณสเกล และใช้เกณฑ์ความแกร่งของ Huber เมื่อ $b = 2$ และ SIGMA คือค่าประมาณสเกล

ค) โปรแกรมย่อย MMOD(BMMAD,KCC,SIGMA1,BMMOD,SIGMA) เมื่อ BMMOD คือค่า $\hat{\beta}$ ที่ได้จากการประมาณค่าโดยวิธี M-estimator เมื่อใช้ the modified biweight A-estimator เป็นค่าประมาณสเกล และใช้เกณฑ์ความแกร่งของ Huber เมื่อ $b = 2$ SIGMA คือค่าประมาณสเกลที่ได้จากวิธี MAD BMMAD คือค่าสัมประสิทธิ์การถดถอยที่ได้จากวิธี MAD SIGMA1 คือค่าประมาณสเกลของวิธี MMOD และ KCC คือค่าคงที่ $C = 9$ หรือ 10

3.4.8.2 เมื่อความผิดพลาดเป็นแบบเบ้ จะอาศัยการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox และประมาณค่าสัมประสิทธิ์การถดถอยพหุโดยใช้โปรแกรมย่อยตามลำดับดังนี้

ก) การประมาณค่าสัมประสิทธิ์การถดถอยพหุ โดยวิธี M-estimator ที่ใช้ค่า standard deviation of location เป็นตัวประมาณสเกล จากเทคนิคการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox โปรแกรมย่อยที่เรียกใช้คือ BOXC1(B,FL1,SIGMA) ซึ่ง B เป็นค่าสัมประสิทธิ์ของการถดถอยพหุ FL1 คือ λ ซึ่งเป็นค่าประมาณที่อยู่ในรูปยกกำลังของ Box และ Cox สำหรับโปรแกรมย่อย BOXC1(B,FL1,SIGMA) นี้ใช้ค่าตอบที่ได้จากโปรแกรม BOXCOX(B,FL1) ในการประมาณสัมประสิทธิ์การถดถอยพหุ และ λ ซึ่งเป็นค่าประมาณของการแปลง

ข) การประมาณค่าสัมประสิทธิ์การถดถอยพหุ โดยวิธี M-estimator ที่ใช้ค่า median absolute deviation เป็นตัวประมาณสเกล จากเทคนิคการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox โปรแกรมย่อยที่เรียกใช้คือ BOXC2(B,FL1,SIGMA) สำหรับโปรแกรมย่อย BOXC2(B,FL1,SIGMA) นี้ประมวลผลในท่านองเดียวกับโปรแกรม BOXC1 (B,FL1,SIGMA) และใช้ค่าตอบที่ได้จากโปรแกรม BOXCOX(B,FL1) ในการประมาณสัมประสิทธิ์การถด-

ถอยพหุ และ λ ซึ่งเป็นค่าประมาณของการแปลง

ค) การประมาณค่าสัมประสิทธิ์การถดถอยพหุ โดยวิธี M-estimator ที่ใช้ค่า the modified biweight A-estimator เป็นตัวประมาณสเกล จากเทคนิคการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox โปรแกรมย่อยที่เรียกใช้คือ BOXC3 (B, FL1, SIGMA) สำหรับโปรแกรมย่อย BOXC3 (B, FL1, SIGMA) นี้ประมวลผลในทำนองเดียวกับโปรแกรม BOXC1 (B, FL1, SIGMA) และ BOXC2 (B, FL1, SIGMA) และใช้ค่าตอบที่ได้จากโปรแกรม BOXCOX (B, FL1) ในการประมาณสัมประสิทธิ์การถดถอยพหุ และ λ ซึ่งเป็นค่าประมาณของการแปลง

ง) โปรแกรมย่อยสำหรับการคำนวณค่าผลบวกกำลังสองของค่าผิดพลาด โปรแกรมที่เรียกใช้คือ SUMBAR (FLX, SSE, K, SIGMA) SUMMAD (FLX, SSE, K, SIGMA) และ SUMMOD (FLX, SSE, K, BMMAD, SIGMA1, KCC, SIGMA) โดยที่ FLX เป็นค่า λ ที่ต้องการใช้ ในการแปลงข้อมูล y ให้อยู่ในรูปตัวแบบเชิงเส้นดังนี้

$$(3.4.8.2.1) \quad \underset{\sim}{y}(\lambda) = X\underset{\sim}{\beta} + \underset{\sim}{\varepsilon}$$

SSE คือ $\sigma_{\varepsilon}^2 | \lambda$ ที่คำนวณได้จากตัวแบบเชิงเส้นนี้ K เป็นค่าใช้สำหรับบอกตำแหน่งของ SSE ว่าเป็นค่าของจุดเริ่มต้น ค่ากลาง หรือค่าสุดท้ายในโปรแกรมที่เรียกใช้คือ BOXCOX BOXC1 BOXC2 และ BOXC3 SIGMA เป็นค่าประมาณสเกลของการประมาณสเกลในแต่ละวิธี

ค) โปรแกรมย่อยสำหรับการแปลงข้อมูลโดยเทคนิคการแปลงที่อยู่ในรูปยกกำลังของ Box และ Cox โปรแกรมย่อยที่ใช้คือ BCOX (FL1) ซึ่ง FL1 คือค่า λ สำหรับการแปลงข้อมูลหรือ y_1 ให้อยู่ในรูปตัวแบบเชิงเส้น (3.4.8.2.1) โดยที่ y_1 ใช้ข้อมูลร่วมกับโปรแกรมที่เรียกใช้คือ SUMBAR SUMMAD หรือ SUMMOD และผลลัพธ์จะถูกแทนเมตริกซ์ X ในแนวตั้งที่ M2 เพื่อใช้ในการประมาณสัมประสิทธิ์การถดถอยพหุต่อไป

หลังจากการประมาณค่าสัมประสิทธิ์การถดถอยพหุแล้ว ขั้นตอนต่อไปคือการหาค่าเฉลี่ยความผิดพลาดกำลังสองของการประมาณค่าสัมประสิทธิ์การถดถอยพหุด้วยวิธี BAR MAD และ MOD ที่ C = 9 และ 10 โดยการหาผลรวมของ MSE ของ $\hat{\beta}_i$ ที่ได้จากการประมาณเทียบกับ β ของประชากรทุกค่าของ β_i ; $i = 1, \dots, M$ แล้วหารด้วย M

$$\text{MSE ของวิธี BAR} = \frac{\sum_i^M (\hat{\beta}_{i(\text{BAR})} - \beta_i)^2}{M}$$

เมื่อ $\hat{\beta}_{i(\text{BAR})}$ เป็น $\hat{\beta}_i$ ของวิธี M-estimator ที่ใช้ standard deviation of location เป็นตัวประมาณสเกล

$$\text{MSE ของวิธี MAD} = \frac{\sum_i^M (\hat{\beta}_{i(\text{MAD})} - \beta_i)^2}{M}$$

เมื่อ $\hat{\beta}_{i(\text{MAD})}$ เป็น $\hat{\beta}_i$ ของวิธี M-estimator ที่ใช้ median absolute deviation เป็นตัวประมาณสเกล

$$\text{MSE ของวิธี MOD} = \frac{\sum_i^M (\hat{\beta}_{i(\text{MOD})} - \beta_i)^2}{M}$$

เมื่อ $\hat{\beta}_{i(\text{MOD})}$ เป็น $\hat{\beta}_i$ ของวิธี M-estimator ที่ใช้ modified biweight A-estimator ที่ $C = 9$ และ 10 เป็นตัวประมาณสเกล

3.4.9 หาค่าอัตราส่วนผลต่างความผิดพลาดกำลังสอง (Ratio of Different Mean Square Error (RDMSE)) จากวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองน้อยที่สุดมีค่าต่ำสุด กับวิธีที่เหลืออีก 4 วิธี หลังจากนั้นหาผลรวมของการกระทำซ้ำ แล้วหารด้วยจำนวนครั้งของแต่ละวิธีที่ให้ค่า MSE ต่ำที่สุด

$$\text{RDMSE} = \frac{\sum \left[\frac{\text{MSE}_{\text{nom}} - \text{MSE}_{\text{min}}}{\text{MSE}_{\text{min}}} \right] \times 100}{\text{TIMES}}$$

เมื่อ MSE_{min} แทนวิธีที่ให้ค่า MSE ต่ำที่สุด
 MSE_{nom} แทนวิธีที่ให้ค่า MSE โดยทั่วไปที่ไม่ใช่ค่าต่ำที่สุด
 TIMES คือจำนวนครั้งของแต่ละวิธีที่ให้ค่า MSE ต่ำที่สุด

3.4.10 กลับไปกระทำซ้ำจากข้อ 3.4.3 ถึง 3.4.9 จนกระทั่งครบ 200 ครั้งแล้ว

หาค่าอัตราส่วนผลต่างค่าเฉลี่ยความผิดพลาดกำลังสอง (Ratio of Different Average Mean Square Error (RDAMSE)) จากวิธีที่ให้ค่าเฉลี่ยความผิดพลาดกำลังสองน้อยที่สุดมีค่าต่ำสุดกับวิธีที่เหลืออีก 4 วิธี

$$RDMSE = (AMSE_{nom} - AMSE_{min}) / AMSE_{min}$$

เมื่อ $AMSE_{min}$ แทนวิธีที่ให้ค่า AMSE ต่ำที่สุด

$AMSE_{nom}$ แทนวิธีที่ให้ค่า AMSE โดยทั่วไปที่ไม่ใช่ค่าต่ำที่สุด

3.4.11 พิมพ์รายงานผลการคำนวณสุดท้ายและจบการทำงาน



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย