

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของการวิจัย

การวิเคราะห์การถดถอย (Regression analysis) เป็นการศึกษาลักษณะของความสัมพันธ์ระหว่างตัวแปรสองกลุ่ม คือตัวแปรที่ต้องการศึกษา หรือตัวแปรตาม (Dependent variable) กับตัวแปรที่แทนปัจจัยต่าง ๆ ที่มีผลกระทำกับตัวแปรตาม เรียกว่าตัวแปรอิสระ (Independent variable) โดยลักษณะความสัมพันธ์สามารถเขียนในรูปของฟังก์ชัน หรือตัวแบบการถดถอย (Regression model) ตัวแบบการถดถอยนอกจากใช้อธิบายความผันแปรของตัวแปรตามอันเนื่องมาจากการเปลี่ยนแปลงของตัวแปรอิสระแล้ว ยังสามารถใช้พยากรณ์ค่าของตัวแปรตามเมื่อทราบค่าของตัวแปรอิสระในตัวแบบได้อีกด้วย

ในการวิเคราะห์การถดถอยเชิงเส้นนี้ ตัวแปรตามจะต้องเป็นตัวแปรสุ่มนิctต่อเนื่อง และมีการแจกแจงปกติ ส่วนตัวแปรอิสระจะเป็นตัวแปรเชิงปริมาณ หรือเชิงคุณภาพก็ได้ ในกรณีที่ตัวแปรตามเป็นจำนวนนับ หรือความถี่ ซึ่งเป็นตัวแปรไม่ต่อเนื่อง ถ้าใช้การวิเคราะห์การถดถอยเชิงเส้น จะทำให้เกิดปัญหา 2 ประการ คือค่าคาดหวังของตัวแปรตามอาจจะมีค่าน้อยกว่าศูนย์ ซึ่งไม่เป็นไปตามข้อสมมติเบื้องต้นที่ว่า ค่าคาดหวังของจำนวนนับจะต้องมากกว่าหรือเท่ากับศูนย์ และข้อมูลมีความแปรปรวนของค่าคลาดเคลื่อนไม่คงที่ ซึ่งไม่เป็นไปตามข้อสมมติเบื้องต้นที่ว่า ความแปรปรวนของค่าคลาดเคลื่อนคงที่ทุก ๆ ระดับของตัวแปรอิสระ (Gardner et al., 1995)

เป็นที่ทราบว่าตัวแปรตามที่เป็นจำนวนของเหตุการณ์หรือลักษณะที่สนใจ (ซึ่งในวิทยานิพนธ์ฉบับนี้ขอเรียกว่า จำนวนนับ หรือข้อมูลแบบนับ) ที่เกิดขึ้นในช่วงเวลา หรือของเขตที่กำหนดจะมีการแจกแจงปัวซง (Poisson distribution) ดังนั้นความสัมพันธ์ระหว่างตัวแปรตามนี้กับตัวแปรอิสระ จึงสามารถอธิบายได้ด้วยการวิเคราะห์การถดถอยปัวซง (Poisson regression analysis) อย่างไรก็ตามตัวแปรเชิงสุ่มปัวซงมีข้อสมมติเบื้องต้นที่ต้องพิจารณาคือ จำนวนของเหตุการณ์หรือลักษณะที่สนใจที่เกิดขึ้นใน 1 หน่วยเวลา หรือในขอบเขตหนึ่งจะต้องเป็นอิสระกับจำนวนของเหตุการณ์หรือลักษณะที่สนใจที่เกิดขึ้นใน 1 หน่วยเวลาหรือในขอบเขตอื่น และความแปรปรวนมีค่าเท่ากับค่าเฉลี่ย แต่ในทางปฏิบัติข้อสมมติเบื้องต้นเกี่ยวกับการเท่ากันของค่าความแปรปรวนและค่าเฉลี่ยมักไม่เกิดขึ้น ถ้าพบว่าข้อมูลที่เป็นจำนวนนับให้ค่าความแปรปรวนมากกว่า

ค่าเฉลี่ยแสดงว่าเกิดปรากฏการณ์ที่เรียกว่า Overdispersion และเรียกข้อมูลที่เป็นจำนวนนับที่มีลักษณะดังกล่าวว่า Overdispersed counts แต่ถ้าข้อมูลมีค่าความแปรปรวนน้อยกว่าค่าเฉลี่ย จะเกิดลักษณะที่เรียกว่า Underdispersion แต่ในสถานการณ์จริง Underdispersion จะเกิดขึ้นน้อยมาก (McCullagh and Nelder, 1989) ดังนั้นในวิทยานิพนธ์ฉบับนี้เราจะศึกษากระบวนการวิเคราะห์ข้อมูลแบบนับที่มีลักษณะ Overdispersion ท่านนี้

Hinde and Demetrio (1998) ได้อธิบายถึงสาเหตุที่เป็นไปได้ที่ทำให้เกิด Overdispersion ในจำนวนนับ ดังนี้

1) การจัดตัวอย่างแบบเกากรคุ่ม (Cluster sampling) จะแบ่งประชากรออกเป็นกลุ่มย่อย ๆ โดยที่ในแต่ละกลุ่มย่อยจะมีคุณลักษณะคล้ายกัน และภายในกลุ่มเดียวกันจะมีคุณลักษณะที่แตกต่างกัน ถ้าการแบ่งกลุ่มไม่เหมาะสม อาจทำให้เกิดความผันแปรระหว่างกลุ่มซึ่งทำให้เกิดความแปรปรวนมาก

2) จำนวนนับที่เกิดขึ้นใน 1 หน่วยเวลา หรือในขอบเขตหนึ่งไม่เป็นอิสระกับจำนวนของเหตุการณ์หรือลักษณะที่สนใจที่เกิดขึ้นใน 1 หน่วยเวลาหรือในขอบเขตอื่น ทำให้เกิดความผันแปรระหว่างตัวแปรตาม

3) การรวมกลุ่มระหว่างระดับของตัวแปร ทำให้เกิดการแยกแจงแบบผสม (Compound distributions)

Hinde and Demetrio (1998) ได้กล่าวถึงผลเสียที่จะเกิดขึ้นในกรณีที่เราไม่จำ Overdispersion มาพิจารณาในการวิเคราะห์ข้อมูล คือ

1) สมประสิทธิ์ของการทดสอบปัจจัยมีค่าคาดเคลื่อนมาตรฐาน (Standard error) ต่ำกว่าความเป็นจริง ทำให้ตัดสินใจเลือกตัวแปรอิสระเข้าตัวแปรไม่ถูกต้อง

2) ส่งผลให้การเปลี่ยนของค่า Deviance ที่เกี่ยวข้องกับการนำตัวแปรอิสระเข้าหรือออกจากตัวแบบมีค่ามากเกินไป อาจทำให้เลือกตัวแบบที่มีความซับซ้อนมากเกินไป

นักสถิติหลายท่านได้เสนอตัวแบบสำหรับประมาณค่า Overdispersion ในกรณีทดสอบปัจจัย Poortema (1999) ได้รวบรวมไว้ แต่ไม่ได้เสนอวิธีการหาค่าประมาณ หรือวิธีการอนุมานเชิงสถิติ (ทดสอบสมมติฐาน และการประมาณค่าแบบช่วง) ของพารามิเตอร์ที่เกี่ยวข้องอย่างไรก็ตามตัวแบบเชิงพารามิตริกที่นิยมใช้มากก็คือ ตัวแบบการทดสอบทวินามแบบลบ (Negative Binomial Regression Model: NB)

การแยกแจงทวินามแบบลบมีหลักฐานแบบตามลักษณะของความสัมพันธ์ระหว่างค่าเฉลี่ย และความแปรปรวน แต่รูปแบบที่นิยมกันทั่ว ๆ ไปมากที่สุดสำหรับวิเคราะห์ข้อมูลดังกล่าว ได้แก่ ตัวแบบทวินามแบบลบที่มีความแปรปรวนเป็นฟังก์ชันเชิงเส้นของค่าเฉลี่ย (Linear mean –

variance Negative Binomial model) หรือเรียกย่อ ๆ ว่า ตัวแบบ NB1 และตัวแบบทวินามแบบลบที่มีความแปรปรวนเป็นฟังก์ชันพหุนามกำลังสองของค่าเฉลี่ย (Quadratic mean – variance Negative Binomial model) หรือตัวแบบทวินามแบบลบที่มีความแปรปรวนเป็นฟังก์ชันกำลังสองค่าเฉลี่ย และเรียกย่อ ๆ ว่า ตัวแบบ NB2 ในวิทยานิพนธ์ฉบับนี้จะเน้นศึกษากระบวนการวิเคราะห์ข้อมูลทวินามแบบลบที่มีความแปรปรวนเป็นฟังก์ชันกำลังสองค่าเฉลี่ยเท่านั้น

1.2 วัตถุประสงค์

1. เพื่อศึกษาแนวคิดเชิงทฤษฎีของการวิเคราะห์ข้อมูล NB2
2. เพื่อศึกษาระบวนการของ การวิเคราะห์ข้อมูล NB2
3. เพื่อศึกษาการประยุกต์ใช้ตัวแบบ NB2
4. เพื่อศึกษารูปแบบ และคุณสมบัติของ Robust variance ของตัวประมาณค่าพารามิเตอร์ของตัวแบบ NB2

1.3 ขอบเขตและวิธีการดำเนินการวิจัย

1. ศึกษาคุณลักษณะ รวมรวมทฤษฎีบท ตลอดจนคุณสมบัติต่าง ๆ ที่สำคัญที่เกี่ยวข้องกับตัวแบบเชิงเส้นว่างทั่วไป (Generalized Linear Models: glms) และการวิเคราะห์การถดถอย NB2 เช่น การหาตัวประมาณค่าพารามิเตอร์ด้วยวิธีความ prawne ที่สูงสุด (Maximum Likelihood Method) โดยใช้ วิธีนิวตัน – رافสัน (Newton – Raphson) การเลือกตัวแบบ (Model Selection) โดยใช้ Akaike Information Criteria และการวินิจฉัยตัวแบบ (Model Diagnostics) โดยใช้ Half normal plot with simulated envelope
2. ศึกษาแบบทดสอบเพื่อเปรียบเทียบระหว่างการถดถอยปั่นป่วน กับการถดถอย NB2 ได้แก่ Wald test, Likelihood ratio test และ Score tests และตรวจสอบคุณสมบัติ Score test ที่เสนอโดย Dean (1992) และโดย Wang – Shu Lu (1997) โดยใช้ Simulation study
3. พัฒนาสูตรของ Robust variance ของค่าประมาณสัมประสิทธิ์ตัวทำนายเชิงเส้น (Linear predictor coefficient Estimates) ของ NB2 และศึกษาคุณสมบัติของ Robust variance ที่ได้โดยใช้ Simulation study

1.4 ระยะเวลาการดำเนินงาน

กันยายน พ.ศ.2548 – พฤษภาคม พ.ศ.2550

ตารางที่ 1.1 แผนการดำเนินการวิจัย

ขั้นตอนการดำเนินงาน	ระยะเวลาดำเนินการวิจัย																											
	พ.ศ.2548				พ.ศ.2549												พ.ศ.2550											
	9	10	11	12	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3	4	5							
1. เลือกหัวข้อวิทยานิพนธ์	●	●																										
2. ทบทวนวรรณกรรม	●	●	●	●	●																							
3. จัดทำโครงสร้างวิทยานิพนธ์						●	●	●																				
4. เสนอโครงสร้างวิทยานิพนธ์								●																				
5. เตรียมเครื่องมือ NB2 fit								●	●																			
6. เรียนชุดคำสั่งของ Half normal pot with simulated envelope ของ Poisson และ NB2								●	●	●	●	●																
8. ศึกษาคุณสมบัติ Score test ที่เสนอโดย Dean (1992) และ Wang – Shu Lu (1997) โดยใช้ Simulation study													●	●	●	●												
9. เรียนสูตรในการคำนวณ Robust variance ของ NB2													●	●	●													
10. ศึกษาเปรียบเทียบ Robust variance กับ Asymptotic variance โดย Simulation study														●	●	●	●											
11. เตรียมต้นฉบับวิทยานิพนธ์																		●	●	●					●			
12. สอบวิทยานิพนธ์																									●			
13. แก้ไขและส่งรายงานวิทยานิพนธ์ฉบับสมบูรณ์																								●	●			

1.5 ประโยชน์ที่คาดว่าจะได้รับ

- เข้าใจถึงแนวคิด ทฤษฎี และการประยุกต์ใช้ตัวแบบ NB2
- เป็นแนวทางศึกษา และใช้เป็นเอกสารอ้างอิงสำหรับนักศึกษา และผู้สนใจที่จะศึกษาเกี่ยวกับคุณลักษณะต่าง ๆ ของตัวแบบ NB2
- ทำให้ทราบถึงกระบวนการที่จะดำเนินการศึกษาวิจัย
- เสนอ Robust variance ของตัวแบบ NB2 แก้วรรณกรรมที่เกี่ยวกับการวิเคราะห์ข้อมูลจำนวนนับ