

การเปรียบเทียบตัวแบบความถดถอยโลจิสติกแบบสถิติและแบบพลวัต



นางสาววรุณี มุริกา

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาสถิติ ภาควิชาสถิติ

คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2551

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

A COMPARISON BETWEEN A STATIC LOGISTIC REGRESSION MODEL AND
A DYNAMIC LOGISTIC REGRESSION MODEL

Miss Warunee Muriga

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Statistics Program in Statistics

Department of Statistics

Faculty of Commerce and Accountancy

Chulalongkorn University

Academic Year 2008

Copyright of Chulalongkorn University

511616

หัวข้อวิทยานิพนธ์

การเปรียบเทียบตัวแบบความถดถอยโลจิสติกแบบสถิติ
และแบบพลวัต

โดย

นางสาววรุณี มุริกา


สาขาวิชา

สถิติ

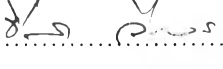
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

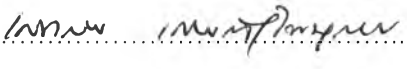
ผู้ช่วยศาสตราจารย์ ดร. เสกสรร เกียรติสุโขทัย


คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้
วิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาโทบริหาร
ศาสตรบัณฑิต

 คณบดีคณะพาณิชยศาสตร์และการบัญชี
(รองศาสตราจารย์ ดร. อรรณพ ต้นละม้าย)


คณะกรรมการสอบวิทยานิพนธ์

 ประธานกรรมการ
(รองศาสตราจารย์ ดร. ชีระพร วีระถาวร)

 อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร. เสกสรร เกียรติสุโขทัย)

 กรรมการภายนอกมหาวิทยาลัย
(ดร. ไอวาท สุนันท์)

 กรรมการ
(รองศาสตราจารย์ ดร. สุธล ดุงศ์วัฒนา)

 กรรมการ
(รองศาสตราจารย์ ดร. กัลยา วานิชย์บัญชา)

วรุณี มุริกา : การเปรียบเทียบตัวแบบความถดถอยโลจิสติกแบบสถิตย์และแบบพลวัต.
(A Comparison between A Static Logistic Regression Model and A Dynamic Logistic
Regression Model) อ. ที่ปรึกษาวิทยานิพนธ์หลัก : ผศ. ดร. เสกสรร เกียรติสุไพบูลย์,
78 หน้า.

วิทยานิพนธ์ฉบับนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของการพยากรณ์ระหว่าง
ตัวแบบถดถอยโลจิสติกแบบสถิตย์ (Static model) และตัวแบบพลวัต (Dynamic model) โดยวิธีการ
วิเคราะห์แบบสถิตย์จะพิจารณาช่วงเวลาเป็นเพียงหนึ่งช่วงเวลาเท่านั้น แต่วิธีการวิเคราะห์แบบพลวัต
จะทำการแบ่งช่วงเวลาออกเป็นหลายช่วงเวลาย่อยและพิจารณาข้อมูลของแต่ละหน่วยตัวอย่างในแต่ละ
ช่วงเวลานั้น ซึ่งเป็นลักษณะของ Hazard model ในกรณีที่เป็นแบบไม่ต่อเนื่อง และทำการศึกษาด้วย
ข้อมูล 2 ประเภท ได้แก่ ข้อมูลจำลองและข้อมูลจริง โดยข้อมูลจำลองอยู่ภายใต้เงื่อนไขว่า จำนวนตัว
แปรอิสระที่ใช้ในแต่ละตัวแบบเท่ากับ 3 ตัวแปร (X_1, X_2, X_3) เมื่อ X_1 มีการแจกแจงแบบปกติด้วย
 $\mu = 0$ และ $\sigma^2 = 1$ X_2 มีการแจกแจงแบบเบอร์นูลลีด้วย $p = 1/2$ และ X_3 เป็นตัวแปรที่มีค่า
เปลี่ยนแปลงไปตามเวลาและมาจากการแจกแจงแบบเอกซโพเนนเชียลด้วยพารามิเตอร์ $\lambda = 1/36$ แบ่ง
ช่วงเวลาออกเป็น 24 ช่วง ขนาดตัวอย่างที่ใช้เท่ากับ 10,000 และกระทำซ้ำจำนวน 1,000 ครั้ง และข้อมูล
จริงเป็นข้อมูลทุติยภูมิเกี่ยวกับการเช่าซื้อสินค้าชนิดหนึ่ง โดยเหตุการณ์ที่สนใจคือการเกิดหนี้ NPL
(Non Performing Loan) ใช้ตัวแปรอิสระจำนวน 3 ตัวแปร พิจารณาข้อมูลของลูกค้าในช่วงเวลา 1 ปี
โดยแบ่งออกเป็น 4 ช่วงๆ ละ 3 เดือน และใช้ขนาดตัวอย่างเท่ากับ 10,000 เกณฑ์ที่ใช้ในการเปรียบเทียบ
คือ วัดประสิทธิภาพของการพยากรณ์ระหว่างตัวแบบทั้งสองด้วยโค้ง ROC ผลการศึกษาสรุปดังนี้

สำหรับข้อมูลจำลอง พบว่า ในทุกกรณีของการทดลองตัวแบบถดถอยโลจิสติกแบบพลวัต
มีพื้นที่ใต้โค้ง ROC มากกว่าตัวแบบสถิตย์อย่างมีนัยสำคัญทางสถิติที่ระดับนัยสำคัญ 0.05 สำหรับข้อมูล
จริง พบว่า ทั้งสองตัวแบบมีพื้นที่ใต้โค้ง ROC ใกล้เคียงกัน ซึ่งตัวแบบพลวัตมีพื้นที่ใต้โค้งมากกว่า
เล็กน้อย แต่เราไม่สามารถสรุปได้ว่าตัวแบบพลวัตมีพื้นที่ใต้โค้ง ROC มากกว่าตัวแบบสถิตย์ที่ระดับ
นัยสำคัญ 0.05

ภาควิชา.....สถิติ.....
สาขาวิชา.....สถิติ.....
ปีการศึกษา.....2551.....

ลายมือชื่อนิสิต.....*วรุณี มุริกา*.....
ลายมือชื่อ อ. ที่ปรึกษาวิทยานิพนธ์หลัก.....*เสกสรร เกียรติสุไพบูลย์*.....

4982223026 : MAJOR STATISTICS

KEY WORD : HAZARD FUNCTION/ LOGISTIC REGRESSION MODEL/ CREDIT SCORING MODEL/ ROC CURVE.

WARUNEE MURIGA : A COMPARISON BETWEEN A STATIC LOGISTIC REGRESSION MODEL AND A DYNAMIC LOGISTIC REGRESSION MODEL.

THESIS PRINCIPAL ADVISOR : ASST. PROF. SEKSAN KAITSUPAIBUL, Ph.D.,
78 pp.

The objective of this research is to compare the prediction power between two logistic regression models: static model and dynamic model. A static model considers only one period of explanatory variable values for each sample unit. A dynamic model, or a hazard model, divides time into several periods and consider data of explanatory variables in several periods for each sample unit. We consider a discrete time hazard model for the dynamic model. We perform the comparisons on two types of data: simulated data and real data .The simulated data are generated by R program using Monte Carlo Simulation techniques. The model assumes 3 independent variables, X_1, X_2, X_3 , where X_1 has normal distribution with mean 0 and variance 1, X_2 has bernoulli distribution with probability of success 1/2 and X_3 has exponential distribution with parameter 1/36 . The simulation is divided into 24 periods with sample size equal to 10,000 and the simulation is repeated for 1,000 times. The real data is a secondary data from a credit activity. The interested event of dependent variable is non performing loan (NPL) of customers. The number of independent variables is equal to 3, and the sample size equals 10,000. The data considered for each customer is within one-year period divided into four 3-months long subperiods. The criteria employed for the comparison is the area under ROC curve for a prediction purpose. The conclusions of this study are as follows.

For simulated data, in most simulation runs, the area under ROC curve from the dynamic model is greater than the area under ROC curve of the static model at significance level of 0.05. Therefore the dynamic model performs better than the static model. For the real data set, the area under ROC curve from the dynamic model is only slightly more than that of the static model, but not significant at significance level of 0.05. Therefore, we cannot conclude that the dynamic model performs better than the static model.

Department : Statistics

Student's signature : *Warunee Muriga*

Field of study : Statistics

Principal Advisor's signature : *၂၀၀၈ ၂၀၀၈*

Academic year : 2008

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จได้ด้วยดีจากความอนุเคราะห์ของบุคคลหลายฝ่ายด้วยกัน ผู้วิจัยขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.เสกสรร เกียรติสุไพบูลย์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่กรุณาใช้เวลาให้คำแนะนำ ปรึกษา ตลอดจนแก้ไขข้อบกพร่องต่างๆ จนกระทั่งวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี

ผู้วิจัยขอกราบขอบพระคุณ รองศาสตราจารย์ ดร. ชีระพร วีระถาวร รองศาสตราจารย์ ดร. สุปถ ดุรงค์วัฒนา รองศาสตราจารย์ ดร. กัลยา วานิชย์บัญชา และ ดร. โอวาท สุนันท์ ในฐานะประธานกรรมการและกรรมการสอบวิทยานิพนธ์ ที่กรุณาตรวจแก้ไขข้อคิด และแนะแนวทางที่ทำให้วิทยานิพนธ์ฉบับนี้สมบูรณ์ยิ่งขึ้น ทั้งนี้ผู้วิจัยขอกราบขอบพระคุณคณาจารย์ประจำภาควิชาสถิติ ที่ให้โอกาสทางการศึกษา และประสิทธิประสาทความรู้ให้แก่ผู้วิจัยจนกระทั่งสำเร็จการศึกษา

ท้ายนี้ผู้วิจัยใคร่ขอกราบขอบพระคุณ บิดา มารดา ซึ่งให้การสนับสนุน และเพื่อนๆ ที่ให้กำลังใจแก่ผู้วิจัยเสมอมาจนกระทั่งสำเร็จการศึกษา

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฅ
สารบัญภาพ.....	ฐ
บทที่ 1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
วัตถุประสงค์ของการวิจัย.....	2
สมมติฐานของการวิจัย.....	2
ขอบเขตของการวิจัย.....	3
ข้อตกลงเบื้องต้น.....	3
คำจำกัดความที่ใช้ในการวิจัย.....	4
เกณฑ์การตัดสินใจ.....	7
ประโยชน์ที่คาดว่าจะได้รับ.....	8
บทที่ 2 ทฤษฎีและสถิติที่เกี่ยวข้อง.....	9
ข้อสมมติทั่วไปของตัวแบบถดถอยโลจิสติก.....	9
การประมาณค่าพารามิเตอร์ด้วยวิธีภาวน่าจะเป็นสูงสุด.....	11
การวิเคราะห์ความถดถอย โลจิสติกแบบสถิตย์.....	12
การวิเคราะห์ความถดถอย โลจิสติกแบบพลวัต.....	13
Survival function หรือ ฟังก์ชันการอยู่รอด.....	14
Hazard function หรือ ฟังก์ชันอัตราภาวะภัย.....	14
บทที่ 3 วิธีดำเนินการวิจัย.....	16
แผนการดำเนินการวิจัย.....	16
ขั้นตอนการดำเนินงาน.....	18

การจัดข้อมูลสำหรับการวิเคราะห์แบบสถิติและแบบพลวัต.....	19
การคำนวณความน่าจะเป็นของเหตุการณ์ของหน่วยตัวอย่าง (\hat{p}_i) สำหรับตัวแบบ พลวัต.....	20
บทที่ 4 ผลการวิเคราะห์ข้อมูล.....	22
สำหรับการแบ่งช่วงเวลาเป็น 12 ช่วงเวลาย่อย.....	23
กรณีที่ 1.....	23
กรณีที่ 2.....	26
กรณีที่ 3.....	29
สำหรับการแบ่งช่วงเวลาเป็น 24 ช่วงเวลาย่อย.....	32
กรณีที่ 4.....	32
กรณีที่ 5.....	35
กรณีที่ 6.....	38
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ.....	41
สรุปผลการวิจัย.....	41
อภิปรายผลการวิจัย.....	44
ข้อเสนอแนะ.....	45
รายการอ้างอิง.....	46
ภาคผนวก.....	48
ประวัติผู้เขียนวิทยานิพนธ์.....	78

สารบัญตาราง

ณ

ตารางที่	หน้า
4.1 แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพหุวัตน์ในการทดลอง 1 ครั้ง สำหรับกรณีที่ 1.....	23
4.2 แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 1.....	24
4.3 แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 1.....	25
4.4 แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพหุวัตน์ในการทดลอง 1 ครั้ง สำหรับกรณีที่ 2.....	26
4.5 แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 2.....	26
4.6 แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 2.....	27
4.7 แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพหุวัตน์ในการทดลอง 1 ครั้ง สำหรับกรณีที่ 3.....	29
4.8 แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 3.....	29
4.9 แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 3.....	30
4.10 แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพหุวัตน์ในการทดลอง 1 ครั้ง สำหรับกรณีที่ 4.....	32
4.11 แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 4.....	33
4.12 แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 4.....	33
4.13 แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพหุวัตน์ในการทดลอง 1 ครั้ง สำหรับกรณีที่ 5.....	35
4.14 แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 5.....	35
4.15 แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 5.....	36

4.16	แสดงตัวอย่างค่าสัมประสิทธิ์ความถดถอยของการประมาณของตัวแบบสถิติ และตัวแบบพลวัตในการทดลอง 1 ครั้ง สำหรับกรณีที่ 6.....	38
4.17	แสดงพิสัยของค่าสถิติ R^2 ของตัวแบบทั้งสอง จากการจำลอง 1,000 ครั้ง กรณีที่ 6.....	38
4.18	แสดงพื้นที่ใต้โค้ง ROC ของตัวแบบทั้งสองและสถิติทดสอบความแตกต่างของ พื้นที่ใต้โค้ง ROC กรณีที่ 6.....	39
5.1	สรุปค่าสถิติ R^2 ของตัวแบบสถิติและตัวแบบพลวัตในการศึกษาทั้ง 6 กรณี.....	41
5.2	สรุปพื้นที่ใต้โค้ง ROC และผลการเปรียบเทียบของตัวแบบสถิติและตัวแบบพลวัต ในการศึกษาทั้ง 6 กรณี.....	42
5.3	เปรียบเทียบค่าพารามิเตอร์และค่าสัมประสิทธิ์ความถดถอยของการประมาณในตัวแบบ สถิติและพลวัต สำหรับข้อมูลจำลองทั้ง 6 กรณี.....	43

รูปภาพ	หน้า
1.1 ตัวอย่างเส้นโค้งและพื้นที่ใต้โค้ง ROC.....	5
3.1 การจัดข้อมูลสำหรับการวิเคราะห์แบบสถิตยและแบบพลวัต.....	19
3.2 การคำนวณความน่าจะเป็นของเหตุการณ์ของหน่วยตัวอย่าง (\hat{p}) สำหรับตัวแบบ พลวัต.....	20
4.1 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 1	25
4.2 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 2	28
4.3 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 3	31
4.4 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 4	34
4.5 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 5	37
4.6 แสดงตัวอย่างโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตในการทดลอง 1 ครั้ง กรณีที่ 6	40
A แสดงโค้ง ROC ของตัวแบบสถิตยและตัวแบบพลวัตสำหรับข้อมูลจริง	62