

FAQ

FOCUSED AND QUICK

Issue 132

August 20, 2018

CREDET SCORING MODEL: เครื่องมือในการประเมินคุณภาพสินเชื่อ

อโนทัย พุทธาริ, จิตรภณ ทรูเจริญพรพานิช,
เพ็ญสิริ บำรุงเชาว์เกษม และ ชินวัฒน์ เทพหัสดิน ณ อยุธยา

บทความนี้เป็นทรัพย์สินของธนาคารแห่งประเทศไทย

การกล่าว คัด หรืออ้างอิง ข้อมูลบางส่วนตามสมควรในบทความนี้

จะต้องกระทำโดยถูกต้อง และอ้างอิงถึงผู้เขียนและธนาคารแห่งประเทศไทย โดยชัดเจน

ข้อคิดเห็นที่ปรากฏในบทความนี้เป็นความเห็นของผู้เขียน
ซึ่งไม่จำเป็นต้องสอดคล้องกับความเห็นของธนาคารแห่งประเทศไทย



“การพัฒนาตัวชี้วัดความเสี่ยงด้านเครดิต นอกจากจะช่วยเพิ่มประสิทธิภาพในการคาดการณ์โอกาสในการผิดนัดชำระหนี้แล้วยังเอื้อต่อการบริหารความเสี่ยงของธนาคารพาณิชย์และแนวทางการตรวจสอบของธนาคารแห่งประเทศไทยที่เน้นกำกับดูแลให้เป็นไปในเชิงรุกมากขึ้น”

*<https://news.efinancialcareers.com/au-en/101486/guest-comment-heres-why-demand-for-risk-professional-will-stay-fairly-strong-over-the-next-six-months>

แนวทางการบริหารความเสี่ยงของสถาบันการเงินและหน่วยงานกำกับดูแลที่เน้นดำเนินการในเชิงรุกมากขึ้นในปัจจุบัน ทำให้เกิดแนวคิดในการสร้างตัวชี้วัดเพื่อนำมาใช้ร่วมกับตัวชี้วัดเดิม เช่น NPL ratio และ Default rate ผู้เขียนจึงได้พัฒนา Credit score เพื่อใช้เป็น Leading indicator ในการติดตามคุณภาพของสินเชื่อ ซึ่งในงานศึกษานี้ใช้ข้อมูลลูกหนี้ธุรกิจที่มียอดหนี้หรือวงเงินเกินกว่า 20 ล้านบาทในการพัฒนา Credit scoring model สำหรับใช้ในการติดตามคุณภาพสินเชื่อ โดย Credit score สามารถแยกแยะลูกหนี้ดี – เสี่ยงออกจากกันได้ค่อนข้างดี สถาบันการเงินและหน่วยงานกำกับดูแลจึงสามารถใช้ Credit score ร่วมกับเครื่องมือบริหารความเสี่ยงอื่นๆ เพื่อจัดการความเสี่ยงได้ก่อนที่จะเกิดเหตุการณ์การผิดนัดชำระหนี้ และเพื่อประกอบการตัดสินใจในการดำเนินนโยบายและกำกับดูแล

บทนำ


รายได้ดอกเบี้ยจากเงินให้สินเชื่อ นับเป็นแหล่งรายได้หลักของธนาคารพาณิชย์ไทย จากข้อมูลผลการดำเนินงานของระบบธนาคารพาณิชย์ไทยในรูปที่ 1 พบว่า ประมาณร้อยละ 56 ของรายได้ทั้งหมดมาจากรายได้ดอกเบี้ยจากเงินให้สินเชื่อ ซึ่งแสดงให้เห็นถึงความสำคัญความสามารถในการชำระหนี้ของผู้กู้ที่มีต่อผลประกอบการของธนาคารพาณิชย์ ดังนั้น การมีเครื่องมือบริหารความเสี่ยงที่เหมาะสมเพื่อใช้ในการติดตามและประเมินความสามารถในการชำระหนี้ของลูกค้ายิ่งเป็นสิ่งสำคัญที่ธนาคารพาณิชย์ในฐานะเจ้าของกิจการต้องให้ความสำคัญ ขณะเดียวกัน ธปท. ในฐานะผู้กำกับดูแลสถาบันการเงินก็จำเป็นต้องใช้เครื่องมือชี้วัดความเสี่ยงในการวิเคราะห์และติดตาม

คุณภาพสินเชื่อของสถาบันการเงินให้สอดคล้องกับเป้าหมายในการรักษาเสถียรภาพระบบสถาบันการเงินไทย

บทความนี้มีวัตถุประสงค์เพื่อสร้างความรู้ความเข้าใจเกี่ยวกับแนวคิดและการประยุกต์ใช้ Credit risk indicator 2 ประเภท ได้แก่ 1) การใช้ Default rate ในการพิจารณาคุณภาพสินเชื่อควบคู่กับ NPL ratio และ 2) การใช้ Credit score เพื่อเป็นเครื่องมือในการติดตามและพยากรณ์ความเสี่ยงที่อาจเกิดขึ้นในอนาคตอันใกล้และการบริหารความเสี่ยงหรือกำกับดูแลเชิงรุก

1. ตัวชี้วัดคุณภาพสินเชื่อ

ตัวชี้วัดคุณภาพสินเชื่อ หรือตัวชี้วัดความเสี่ยงด้านเครดิต (Credit risk indicator) สามารถแบ่งออกเป็น 2 ประเภท คือ 1) Lagging indicator ซึ่งเป็นตัวชี้วัดจากผลที่เกิดขึ้นแล้วจากเหตุการณ์ในอดีต เช่น สัดส่วนสินเชื่อที่ไม่ก่อให้เกิดรายได้ (Non-performing loan: NPL) และ อัตราการผิดนัดชำระหนี้¹ (Default



rate: DR) เป็นต้น 2) Leading indicator คือ ตัวชี้วัดจากการพยากรณ์แนวโน้มคุณภาพพอร์ตสินเชื่อในอนาคต และเป็นเครื่องมือที่นิยมใช้ในการบริหารความเสี่ยงและกำกับดูแลในเชิงรุก เช่น Credit score² เป็นต้น


1.1 NPL ratio

สินเชื่อที่ไม่ก่อให้เกิดรายได้ (Non-performing loan: NPL) ถือเป็นเครื่องมือหลักสำหรับวิเคราะห์และติดตามคุณภาพสินเชื่อของสถาบันการเงินที่ใช้กันอย่างแพร่หลาย โดยสินเชื่อที่ไม่ก่อให้เกิดรายได้หมายถึง เงินให้สินเชื่อที่ถูกจัดชั้นต่ำกว่ามาตรฐาน จัดชั้นสงสัย จัดชั้นสงสัยจะสูญ และจัดชั้นสูญ³ โดยการติดตามคุณภาพสินเชื่อในเบื้องต้นอาจทำได้โดยการพิจารณาสัดส่วนของสินเชื่อที่ไม่ก่อให้เกิดรายได้ ณ เวลาใดเวลาหนึ่ง ซึ่งคำนวณได้ดังนี้

$$NPL \text{ Ratio} = \frac{NPL_t}{\text{Outstanding loan}_t}$$

$$NPL_t = NPL_{t-1} + \text{New NPL}_t - \text{NPL management}_t$$

อย่างไรก็ตาม NPL ratio อาจไม่สะท้อนให้เห็นถึงคุณภาพของสินเชื่อที่แท้จริง เนื่องจากได้หักผลของยอดสินเชื่อ NPL ที่ได้รับการบริหารจัดการ (NPL management) เช่น การปรับปรุงโครงสร้างหนี้ (Troubled debt restructuring) และการตัดจำหน่ายหนี้สูญ (Write-off) เป็นต้น (รูปที่ 2) ซึ่งปัจจัยเหล่านี้ไม่มีความเกี่ยวข้องความสามารถในการชำระหนี้ของผู้กู้และการเปลี่ยนแปลงของปัจจัยด้านเศรษฐกิจ เป็นต้น ดังนั้น การเปลี่ยนแปลงของ NPL ratio ภายในช่วงระยะเวลาใดเวลาหนึ่ง อาจไม่สะท้อนให้เห็นถึงอัตราการผิดนัดชำระที่เกิดขึ้น ซึ่งอาจส่งผลต่อการวิเคราะห์ความเสี่ยงด้านเครดิต



1.2 Default rate

อัตราการผิดนัดชำระหนี้ หรือ Default rate เป็นการวิเคราะห์คุณภาพสินเชื่อจากการเปลี่ยนแปลงสถานะการจัดชั้นจากลูกหนี้ชั้นดีไปเป็นลูกหนี้ผิดนัดชำระหนี้ภายในช่วงเวลาหนึ่งๆ โดย Default rate สะท้อนให้เห็นถึงคุณภาพสินเชื่อ ณ ช่วงเวลาใดเวลา

¹ Default หมายถึง การที่ลูกหนี้ผิดนัดชำระหนี้หรือชำระล่าช้าอันเป็นเหตุให้เกิดความเสียหายต่อเจ้าหนี้

² Credit score หมายถึง ตัวชี้วัดความน่าจะเป็นในการชำระหนี้โดยใช้วิธีทางสถิติในการประมวลผลข้อมูล

³ รายละเอียดโปรดดูประกาศธนาคารแห่งประเทศไทย ที่ สนส. 5/2559 เรื่อง หลักเกณฑ์การจัดชั้นและการกักเงินสำรองของสถาบันการเงิน


หนึ่ง โดยไม่คำนึงถึงลูกหนี้ผิดนัดชำระในอดีต ซึ่งแตกต่างจาก NPL ratio หรืออาจกล่าวได้ว่าอัตราการผิดนัดชำระหนี้ตอบสนองต่อการเปลี่ยนแปลงของปัจจัยทางเศรษฐกิจได้ดีกว่า NPL Ratio⁴

ทั้งนี้ อัตราการผิดนัดชำระหนี้ (Default rate) สามารถคำนวณได้ดังนี้

$$\text{Default rate}_t = \frac{\text{No. of default}_t}{\text{No. of total borrowers}_{t-1}}$$

$$\text{Exposure weighted default rate}_t = \frac{\text{Outstanding defaulted loan}_t}{\text{Outstanding loan}_{t-1}}$$

รูปที่ 3 แสดงข้อมูล NPL ratio เทียบกับ Default rate ของสินเชื่อลูกหนี้ธุรกิจที่มียอดหนี้หรือวงเงินเกินกว่า 20 ล้านบาท จะสังเกตได้ว่า ในช่วงปี 2552 อัตราการผิดนัดชำระอยู่ที่ระดับร้อยละ 3 ถึง 4 ถึงแม้ว่า NPL ratio ในช่วงเวลาดังกล่าวจะลดลงอย่างต่อเนื่องก็ตาม



ที่มา: ธนาคารแห่งประเทศไทยและคำนวณโดยผู้เขียน

นอกจาก Default rate จะสามารถสะท้อนคุณภาพสินเชื่อภายในช่วงเวลาหนึ่งๆ แล้ว Default rate ยังมีความยืดหยุ่นกว่า NPL ratio เนื่องจากสามารถปรับเปลี่ยนนิยามของการผิดนัดชำระให้สอดคล้องกับสถานการณ์และลักษณะเฉพาะของสินเชื่อต่างประเภทกันได้ เช่น กำหนดให้ลูกหนี้ที่เข้ารับการปรับปรุงโครงสร้างหนี้ (Troubled debt restructuring: TDR) เป็นลูกหนี้ผิดนัดชำระ เป็นต้น

แม้ว่า NPL ratio และ Default rate จะเป็นตัวชี้วัดที่มีประสิทธิภาพ สามารถใช้เป็นเครื่องมือในการติดตามคุณภาพสินเชื่อของสถาบันการเงิน แต่ตัวชี้วัดทั้ง 2 ตัวดังกล่าวเป็น Lagging indicator เนื่องจากจะสามารถรับรู้ว่าคุณภาพสินเชื่อนั้นแย่ลงได้ก็ต่อเมื่อเหตุการณ์ผิดนัดชำระนั้นเกิดขึ้นแล้ว ซึ่งอาจไม่เพียงพอต่อการบริหารความเสี่ยงหรือการกำกับดูแลเชิงรุกที่ต้องอาศัยการคาดการณ์หรือพยากรณ์ความเสี่ยงเพื่อให้สามารถจัดการกับความเสี่ยงได้ก่อนที่จะเกิดเหตุ

1.3 Credit scoring

Credit scoring คือ แบบจำลองที่ใช้กระบวนการทางสถิติในการจัดการข้อมูลเพื่อกำหนดเป็นค่าคะแนน Credit score ซึ่งใช้เป็นตัวชี้วัดความน่าจะเป็นในการชำระหนี้คืน โดย Credit score ถูกนำมาใช้อย่างแพร่หลายในการพิจารณาคำขอสินเชื่อเนื่องจากคุณภาพของผู้กู้ส่งผลโดยตรงต่อความสามารถในการทำกำไรและความมั่นคงของสถาบันการเงิน การคัดกรองและพิจารณาคำขอกู้ยืมจึงถือเป็นขั้นตอนสำคัญในการป้องกันความเสี่ยงด้านเครดิต⁵

ปัจจุบันสถาบันการเงินได้จัดทำ Credit score โดยนำข้อมูลทางการเงินและข้อมูลอื่นๆ ที่เกี่ยวข้องกับความน่าเชื่อถือของผู้กู้มาประเมินและมีการกำหนดค่าคะแนนขั้นต่ำ (Threshold) ที่ชัดเจนในการตัดสินใจให้กู้ ซึ่งเป็นวิธีการที่ช่วยลดความแตกต่างในการพิจารณาอนุมัติสินเชื่อและเพิ่มประสิทธิภาพในขั้นตอนการประเมินความเสี่ยงด้านเครดิตเมื่อเทียบกับการใช้ดุลยพินิจของเจ้าหน้าที่สินเชื่ออย่างในอดีต นอกจากนี้ Credit score ยังสามารถใช้เป็น Leading indicator เพื่อติดตามคุณภาพและความสามารถในการชำระหนี้ของลูกหนี้ก่อนที่จะเกิดการผิดนัดชำระหนี้ได้

⁴ Serwa (2014)

⁵ Abdou and Pointon (2011)

2. การจัดทำแบบจำลอง Credit scoring

2.1 Data

ในบทความนี้กำหนดให้ตัวแปรตาม (Dependent variable) คือ ลูกหนี้ที่ถูกรายงานหนี้จากรายการหนึ่งจัดชั้นเป็นลูกหนี้ผิดนัดชำระ (NPL) ภายในช่วง 1 ปีข้างหน้า โดยใช้ฐานข้อมูลสินเชื่อภาคธุรกิจรายตัวที่มียอดหนี้หรือวงเงินเกินกว่า 20 ล้านบาท

ส่วนตัวแปรต้น (Independent variables) ที่ใช้ในการจัดทำ Credit score ประกอบด้วยตัวแปร 3 กลุ่ม ได้แก่ 1) ข้อมูลทั่วไปของลูกหนี้ 2) อัตราส่วนทางการเงิน (Financial ratio) และ 3) ลักษณะสินเชื่อจากฐานข้อมูลสินเชื่อภาคธุรกิจรายตัว (Loan characteristics) ที่มียอดหนี้หรือวงเงินเกินกว่า 20 ล้านบาท รายละเอียดตามตารางที่ 1 โดยตัวแปรที่ใช้ในการทดสอบมีทั้งสิ้น 139 ตัวแปรครอบคลุมข้อมูลรายเดือนตั้งแต่ปี 2549 – 2559

ตารางที่ 1 รายละเอียดตัวแปรที่ใช้ในการทำ Credit score	
กลุ่มตัวแปร	รายละเอียด
1. ข้อมูลทั่วไปของลูกหนี้	ขนาดธุรกิจ ระยะเวลาในการประกอบธุรกิจ และประเภทอุตสาหกรรม เป็นต้น
2. อัตราส่วนทางการเงิน (Financial ratio)	คำนวณจากข้อมูลงบการเงินที่จัดเก็บโดยกรมพัฒนาธุรกิจการค้า กระทรวงพาณิชย์ เช่น เครื่องชี้ด้านสภาพคล่อง ความสามารถในการทำกำไร และความสามารถในการชำระหนี้ เป็นต้น
3. ลักษณะสินเชื่อจากฐานข้อมูลสินเชื่อภาคธุรกิจรายตัว (Loan characteristics) มี ยอดหนี้หรือวงเงินเกินกว่า 20 ล้านบาท	อัตราการใช้เงิน (Utilization rate) สถานะการจัดชั้นของลูกหนี้ และประเภทหลักประกัน เป็นต้น

ทั้งนี้ ตัวแปรที่ใช้ในการสะท้อนความเสี่ยงประกอบไปด้วยตัวแปรเชิงปริมาณ (Quantitative data) และตัวแปรเชิงคุณภาพ (Qualitative data) บทความนี้จะนำ Weight of Evidence⁶ (WoE) มาใช้เพื่อจัดการแทนค่าข้อมูลเพื่อให้ค่าตัวแปรให้มี Monotonic relationship โดยแสดงในรูป Log Odds⁷ ซึ่งคำนวณได้ดังนี้

$$WoE_i = \ln \left(\frac{\%Distr\ Bad_i}{\%Distr\ Good_i} \right)$$

โดย %Distr Bad_i คือ สัดส่วนของลูกหนี้เสียที่อยู่ในกลุ่ม i ต่อลูกหนี้เสียทั้งหมด และ %Distr Good_i คือ สัดส่วนของลูกหนี้ดีที่อยู่ในกลุ่ม i ต่อลูกหนี้ดีทั้งหมด

2.2 Methodology

โดยทั่วไป เทคนิคที่ใช้ในการพัฒนา Credit scoring model ประกอบไปด้วย 2 เทคนิคหลัก ได้แก่ 1) Traditional statistical method เช่น Discriminant analysis, Probit analysis และ Logistic regression และ 2) Advanced statistical method เช่น Neural networks และ Genetic programming

ในบทความนี้ใช้ Pooled logistic regression เนื่องจากเป็นเทคนิคที่ไม่ซับซ้อนและนิยมใช้กันอย่างแพร่หลายในการพัฒนา Credit scoring model เพื่อใช้ในการทำนายโอกาสหรือความน่าจะเป็นที่จะเกิดเหตุการณ์ใดเหตุการณ์หนึ่งที่สนใจ ซึ่งในที่นี้หมายถึงการที่ลูกหนี้ถูกจัดชั้นเป็น NPL โดยแบ่งข้อมูลออกเป็น 2 ชุด คือ 1) ข้อมูลช่วง 2549 – 2556 สำหรับใช้ในการพัฒนาแบบจำลอง (Training data) และ 2) ข้อมูลช่วง 2557 – 2559 สำหรับใช้ในการทดสอบ (Test data) Logistic regression model

⁶ Weight of Evidence (WoE) คือ การให้น้ำหนักของข้อมูล เพื่อให้เกิดความสัมพันธ์สูงสุดระหว่างตัวแปรต้นที่ได้รับการแปลงค่าให้อยู่ในรูป WoE และตัวแปรตาม โดยจะทำให้

ความสัมพันธ์ของตัวแปรทั้ง 2 เป็นไปในทางเดียวกัน (Monotonic)

⁷ Odds หมายถึง สัดส่วนของโอกาสที่จะเกิดเหตุการณ์ต่อโอกาสที่จะไม่เกิดเหตุการณ์นั้น

$$\ln\left(\frac{\text{prob}(\text{default})}{1-\text{prob}(\text{default})}\right)_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_n x_{in} + \varepsilon_i$$

x_i คือ Weight of Evidence ของตัวแปรที่คาดว่าจะส่งผลต่อการเกิดเหตุการณ์

ทั้งนี้ ค่า $\ln\left(\frac{\text{prob}(\text{default})}{1-\text{prob}(\text{default})}\right)$ หรืออัตราส่วน Odds ที่ได้จาก Logistic regression model จะถูกแปลงให้เป็นคะแนน (Credit score) เพื่อความสะดวกในการสื่อสารและใช้งาน (ภาคผนวก 1 การแปลงค่า PD เป็นคะแนน)

3. ผลการศึกษา

จากการวิเคราะห์ด้วย Logistic regression model พบว่า ตัวแปรที่มีนัยสำคัญในการพยากรณ์การผิดนัดชำระหนี้มี 2 กลุ่ม รวมทั้งสิ้น 8 ตัวแปร ดังนี้

1) ข้อมูลทั่วไปของลูกค้า ได้แก่

Sector ประเภทอุตสาหกรรมของลูกค้าที่ระบุไว้ในงบการเงิน⁸

Size ขนาดธุรกิจตามนิยามกระทรวงอุตสาหกรรม ได้แก่ เล็ก กลาง และใหญ่

2) ลักษณะสินเชื่อ (Loan characteristics) จากฐานข้อมูลสินเชื่อภาคธุรกิจ ได้แก่

UR อัตราการใช้จ่ายเงินสินเชื่อรวม

ΔUR_{3mma} อัตราเปลี่ยนแปลงเฉลี่ยของอัตราการใช้จ่ายเงินสินเชื่อ 3 เดือนล่าสุด

OD_{3mma} ค่าเฉลี่ย 3 เดือนของอัตราการใช้จ่ายเงินเบิกเกินบัญชี

Month จำนวนเดือนที่ยอดคงค้างของ Term loan ไม่ลดลง

Class สถานะจัดชั้นที่แย่ที่สุดใน 6 เดือนที่ผ่านมา⁹

TDR dummy ลูกหนี้เคยมีการปรับโครงสร้างหนี้ในช่วง 1 ปีที่ผ่านมา

ผลการศึกษาโดยใช้ Logistic regression model (ตารางที่ 2) พบว่า สถานะการจัดชั้นมีผลต่อโอกาสในการผิดนัดชำระหนี้มากที่สุด โดยลูกหนี้ที่เคยถูกจัดชั้นเป็น NPL ใน 6 เดือนที่ผ่านมา จะมีโอกาสในการผิดนัดชำระหนี้มากกว่าลูกหนี้กลุ่มอื่น เช่นเดียวกับกลุ่มลูกหนี้ที่เคยมีการปรับโครงสร้างหนี้ในช่วง 1 ปีที่ผ่านมาและกลุ่มลูกหนี้ที่มีการใช้วงเงินเบิกเกินบัญชีก็จะมีโอกาสในการผิดนัดชำระหนี้สูงขึ้นด้วย

ตารางที่ 2 ผลการศึกษา Logistic model

Variables	Coefficient	Standard Error
<i>UR</i>	0.3453***	0.00567
<i>ΔUR_{3mma}</i>	0.1591***	0.00943
<i>OD_{3mma}</i>	0.4810***	0.00511
<i>Month</i>	0.3073***	0.00589
<i>Class</i>	0.5492***	0.00383
<i>TDR</i>	0.5009***	0.00442
<i>Sector</i>	Yes	-
<i>Size</i>	Yes	-
No. of Observations = 1,743,030		
McFadden R ² = 0.2921		
*** Represent 1% significant level		

ที่มา: คำนวณโดยผู้เขียน

ทั้งนี้ ประเภทอุตสาหกรรมและขนาดธุรกิจมีผลต่อโอกาสในการผิดนัดชำระหนี้ โดยอุตสาหกรรมที่ใช้งานมากมีโอกาสนในการผิดนัดชำระหนี้สูงกว่า

⁸ ประเภทอุตสาหกรรม หมายถึง อุตสาหกรรม 23 ประเภท ได้แก่ 1) เกษตร ป่าไม้ ประมง 2) เหมืองแร่ ถ่านหิน 3) อาหาร เครื่องดื่ม ยาสูบ 4) สิ่งทอ 5) ไม้ กระดาษ เฟอร์นิเจอร์ 6) เคมีภัณฑ์ 7) เหล็กและปิโตรเลียม 8) อิเล็กทรอนิกส์ 9) รถยนต์ 10) เครื่องจักร 11) สาธารณูปโภค 12) ก่อสร้าง 13) พาณิชยกรรม 14) ขนส่ง 15) สื่อสาร 16) กิจกรรมทางการเงิน 17) อสังหาริมทรัพย์


18) การศึกษา 19) สุขภาพ 20) บริการที่พัก 21) บริการอื่นๆ 22) ธุรกิจส่วนตัว 23) ราชการ

⁹ สถานะจัดชั้น ประกอบด้วย 1) ลูกหนี้จัดชั้นปกติ (ระยะเวลาค้างชำระน้อยกว่า 1 เดือน) 2) ลูกหนี้จัดชั้นกล่าวถึงเป็นพิเศษ (ระยะเวลาค้างชำระมากกว่า 1 เดือน แต่ไม่เกิน 3 เดือน) และ 3) ลูกหนี้ NPL (ระยะเวลาค้างชำระมากกว่า 3 เดือน)

อุตสาหกรรมที่ใช้เทคโนโลยีในการผลิต ส่วนธุรกิจขนาดเล็กมีโอกาสในการผิมนัดชำระหนี้สูงกว่าธุรกิจขนาดใหญ่


อย่างไรก็ตาม เป็นที่น่าสังเกตว่าอัตราส่วนทางการเงินที่ได้จากข้อมูลงบการเงินของลูกค้า ไม่ได้ถูกเลือกให้อยู่ในแบบจำลอง Credit score ซึ่งมีสาเหตุมาจากความถี่ของข้อมูลที่เป็นรายปี ขณะที่ตัวแปรอื่นมีความถี่เป็นรายเดือน

นอกจากนี้ เมื่อนำอัตราส่วน Odds ที่ได้จาก Logistic regression ข้างต้นมาสร้าง Credit score พบว่า การกระจายตัวของ Credit score ของกลุ่มลูกหนี้ที่ได้รับการจัดชั้นปกติจะมีคะแนนที่สูงกว่ากลุ่มลูกหนี้ที่ได้รับการจัดชั้นเป็นสถานะอื่น (รูปที่ 4)



ทั้งนี้ จากการทดสอบด้วยข้อมูลช่วงปี 2557 ถึง 2558 โดยมี Test data ทั้งสิ้น 558,368 รายการ พบว่า ค่าสัมประสิทธิ์ GINI อยู่ที่ 0.763 (รูปที่ 5) ซึ่งสะท้อนว่าแบบจำลองมีความสามารถในการแบ่งแยกลูกหนี้ดีและเสียออกจากกันได้ค่อนข้างดี โดยทั่วไปค่าสัมประสิทธิ์ GINI ที่สามารถยอมรับได้จะอยู่ระหว่าง 0.65 – 0.80 ทั้งนี้ ค่าสัมประสิทธิ์ GINI ยิ่งสูงสะท้อน Discriminatory power ที่สูง (ภาคผนวก 2 ค่าสัมประสิทธิ์ GINI)

รูปที่ 5 Measure of Performance: Gini Coefficient



ที่มา: คำนวณโดยผู้เขียน

4. การนำไปใช้

การนำ Credit score ไปใช้เพื่อเป็นเครื่องมือในการติดตามคุณภาพลูกหนี้จะต้องกำหนดค่า Threshold¹⁰ เพื่อใช้ในการแยกแยะลูกหนี้ออกเป็น 2 กลุ่ม คือ 1) ลูกหนี้ดี (Good account) ซึ่งเป็นกลุ่มลูกหนี้ที่สามารถชำระหนี้ตามเวลาที่กำหนด และ 2) ลูกหนี้เสีย (Bad account) ซึ่งเป็นกลุ่มลูกหนี้ที่ไม่สามารถชำระหนี้ตามเวลาที่กำหนด โดยนิยามของ Bad account สามารถปรับให้สอดคล้องกับสถานการณ์และลักษณะเฉพาะของสินเชื่อแต่ละประเภทได้¹¹ ทั้งนี้ การกำหนดค่า Threshold ที่สูงเกินไปจะก่อให้เกิดต้นทุนเพิ่มขึ้นในการติดตามสถานะลูกหนี้ (Type I error) ขณะที่การกำหนดค่า Threshold ที่ต่ำเกินไป จะส่งผลให้สูญเสียโอกาสในการติดตามลูกหนี้บางรายที่มีโอกาสเป็นลูกหนี้เสีย (Type II error)

จากการทดลองกำหนดค่า Threshold พบว่า การกำหนดค่า Threshold เพิ่มขึ้นจาก 600 เป็น 650 คะแนน ส่งผลให้เกิด Type I error เพิ่มขึ้นจากร้อยละ 1.1 เป็นร้อยละ 2.4 ซึ่งหมายถึงต้นทุนเสียเปล่าที่เพิ่มขึ้นจากการติดตามลูกหนี้ดี (หรือเรียกว่า False positive) 8,490 บัญชี ขณะที่ Type II error ลดลง

¹⁰ ค่าสถิติที่ใช้ในการวัดประสิทธิภาพของค่า Threshold ในการแบ่งแยกลูกหนี้ดีและเสียออกจากกันมีหลายวิธี เช่น Accuracy ratio (AR), Kolmogorov-Smirnov test (KS), Area under the receiver operating characteristics

curve (AUROC), Population stability index (PSI), Characteristics analysis เป็นต้น

¹¹ Avery et al. (1996)

จากร้อยละ 73.2 เป็นร้อยละ 58.6 ซึ่งหมายถึงประโยชน์ที่ได้รับจากการติดตามลูกหนี้เสีย (หรือเรียกว่า True positive) ได้เพิ่มอีก 2,036 บัญชี (ตารางที่ 3)

ตารางที่ 3 Prediction Performance of 697,671 accounts				
	Score	600	650	700
PD		28.6%	16.7%	9.1%
Type I error		1.1%	2.4%	4.9%
no. of good accounts	reference	8,490	17,301	
Type II error		73.2%	58.6%	43.8%
no. of bad accounts	reference	2,036	2,078	
Accuracy		97.4%	96.5%	94.3%
Sensitivity		26.8%	41.4%	56.2%
Specificity		98.9%	97.6%	95.1%

ที่มา: คำนวณโดยผู้เขียน

หากเพิ่มค่า Threshold เพิ่มขึ้นจาก 650 เป็น 700 คะแนน จะมีต้นทุนเสียเปล่าที่เพิ่มขึ้นจากการติดตามลูกหนี้ดีอีก 17,301 บัญชี ขณะที่ได้รับประโยชน์จากการติดตามลูกหนี้เสียได้เพิ่มขึ้นเพียง 2,078 บัญชี (ภาพผนวก 2 Confusion matrix) ดังนั้นการกำหนดค่า Threshold จะต้องคำนึงถึงต้นทุนเทียบกับประโยชน์ที่จะได้รับ (Trade-off) ให้สอดคล้องกับระดับความเสี่ยงที่ยอมรับได้ (Risk appetite)

นอกจากนี้ เมื่อพิจารณาค่าสถิติอื่นๆ พบว่าแบบจำลองที่ใช้ในงานศึกษานี้มีความแม่นยำค่อนข้างสูง ดูจากค่า Accuracy ที่สูงกว่าร้อยละ 90 โดยความแม่นยำที่เกิดขึ้นนี้เป็นผลมาจากการที่แบบจำลองมีความสามารถทำนายลูกหนี้ดีได้ถูกต้อง (Specificity) มากกว่าที่จะทำนายลูกหนี้เสีย (Sensitivity) ซึ่งส่วนหนึ่งเป็นผลมาจากปัจจัยเฉพาะที่แตกต่างกันในลูกหนี้แต่ละราย เช่น ประเภทและขนาดของธุรกิจ ดังนั้นในการกำหนดค่า Threshold อาจต้องคำนึงถึงประเภทและขนาดของธุรกิจด้วย

5. บทสรุป

การจัดทำแบบจำลอง Credit score เพื่อใช้ในการแยกแยะลูกหนี้ดี-เสีย และคาดการณ์แนวโน้มการผิดนัดชำระหนี้ภายใน 1 ปี ข้างหน้าจะช่วยเพิ่มประสิทธิภาพและพัฒนาแนวทางการบริหารความเสี่ยงของสถาบันการเงินให้เอื้อต่อแนวทางการตรวจสอบของธนาคารแห่งประเทศไทยที่เน้นกำกับดูแลเป็นไปในเชิงรุกมากขึ้น

อย่างไรก็ตาม สิ่งสำคัญที่ต้องคำนึงถึงเมื่อมีการใช้ Credit score คือ 1) เกณฑ์การกำหนดคะแนนที่ใช้คัดกรองลูกหนี้ที่มีคุณภาพต่ำจะต้องคำนึงถึงต้นทุนเทียบกับประโยชน์ที่จะได้รับ (Trade-off) เพื่อให้สอดคล้องกับระดับความเสี่ยงที่ยอมรับได้ (Risk appetite) และ 2) การติดตามประสิทธิภาพรวมถึงการ Calibrate และปรับปรุงแบบจำลองอย่างต่อเนื่อง เพื่อให้แบบจำลองสามารถสะท้อนความเสี่ยงลูกหนี้ได้อย่างแม่นยำมากขึ้น

ภาคผนวก 1 การแปลงค่า PD เป็นคะแนน

- 1) กำหนดคะแนนที่เป็นค่ากลาง (Center Score) โดยค่ากลางนี้จะหมายถึงอัตราส่วน Odds ที่ 1:1 เช่น กำหนดค่ากลางเท่ากับ 500 คะแนนสำหรับโอกาสในการเกิดเหตุการณ์ Good กับ Bad เท่ากัน
- 2) กำหนดค่าการเปลี่ยนแปลงของคะแนนที่ทำให้อัตราส่วน Odds เปลี่ยนแปลงไป 2 เท่า (Points to Double Odds: PDO) เช่น กำหนดให้ PDO เพิ่มขึ้น 50 คะแนน เมื่ออัตราส่วน Odds ของ Good กับ Bad เปลี่ยนจาก 1:1 เป็น 2:1
- 3) คำนวณคะแนนได้ดังนี้

$$Score = Center\ score + \ln Odds * factor$$

where Center score = 500 and

$$factor = PDO / \log(1/2)$$

ตารางที่ 1 ตัวอย่างการคำนวณคะแนน			
Score	Odds	Good rate	Bad rate
350	1:8	11%	89%
400	1:4	20%	80%
450	1:2	33%	67%
500 (Center score)	1:1	50%	50%
550	2:1	67%	33%
600	4:1	80%	20%
650	8:1	89%	11%


ที่มา: คำนวณโดยผู้เขียน

ภาคผนวก 2 ค่าสถิติที่ใช้ในการทดสอบประสิทธิภาพของค่า Threshold

- 1) ค่าสัมประสิทธิ์ GINI เป็นค่าสถิติที่ใช้ในการทดสอบประสิทธิภาพของค่า Threshold ในการแบ่งแยกลูกหนี้ดีและเสียออกจากกัน (Discriminatory power) โดยหากค่าสัมประสิทธิ์ GINI เท่ากับ 0 หมายถึงประสิทธิภาพในการแบ่งแยกลูกหนี้ดีและเสียต่ำ ซึ่งสามารถคำนวณได้ดังนี้ (รูปที่ 1)

$$\text{Gini Coefficient} = \frac{\text{Area A}}{\text{Area A} + \text{Area B}}$$

รูปที่ 1 Cumulative Bad Account by Credit Score



ที่มา: Kraus A., and Kuchenhoff H. (2013), Credit scoring and the optimization concerning area under the curve, credit score and credit control XIII, August.

2) Confusion matrix

ตารางที่ 2 Confusion Matrix		
	Actual	
Predicted	Default	Not default
Default	True positive (TP)	False positive (FP)
Not default	False Negative (FN)	True Negative (TN)

$$\text{Type I error} = \frac{FP}{FP + TN}$$

$$\text{Type II error} = \frac{FN}{TP + FN}$$

$$\text{Accuracy} = \frac{(TP + TN)}{TP + FP + FN + TN}$$

$$\text{Sensitivity} = \frac{TP}{TP + FN}$$

$$\text{Specificity} = \frac{TN}{TN + FP}$$

References:

- Abdou, H.A., and Pointon, J. (2011), Credit scoring, statistical techniques and evaluation criteria: a review of the literature. *Intelligent System in Accounting, Finance & Management*, 18(2-3): 59-88.
- Avery, R.B., Bostic, R.W., Calem, P.S., and Canner, G.B. 1996. Credit risk, credit scoring, and the performance of home mortgages. *Federal Reserve Bulletin* 82: 621-48.
- Bhardwaj, G., and Sengupta, R. (2015), Credit scoring and loan default, Federal Reserve Bank of Kansas City Research Working Papers, RWP 15-02 February.
- Dobromiř, S. Using non-performing loan rates to compute loan default rates: evidence from European banking sectors, *Econometric Research in Finance* vol 1: 46-65.
- Einav, L., Jenkins, M., and Levin, J. (2013), The impact of credit scoring on consumer lending, *RAND Journal of Economics*, vol 44: 249-274
- Kraus, A., and Kuchenhoff, H. (2013), Credit scoring and the optimization concerning area under the curve. *Credit Score and Credit Control XIII*, August.
- Limsombunchai, V., Gan, C., and Lee, M. (2005), An analysis of credit scoring for agricultural loans in Thailand, *American Journal of Applied Sciences*, 2(8): 1198-1205.
- Marquez, J. (2008), An introduction to credit scoring for small and medium size enterprises, *Journal of Microfinance Risk Management*, 1-47.
- Skantzios, N. and Castelein, N. (2016), Credit scoring case study in data analytics, Deloitte.
- Verstraeten, G., and Van den Poel, D. (2003), Quantifying credit-scoring performance, *Transactions on Information and Communications Technologies*, vol 9: 317-326.

ผู้เขียนขอขอบคุณ คุณรณดล นุ่มนนท์ และ คุณศุภรัตน์ วรรณิ์ ที่ช่วยสนับสนุนให้บทความนี้สำเร็จลุล่วงไปด้วยดี และขอขอบคุณ ดร. เสาวณี จันทะพงษ์ และ ดร. ศุภโชค ถาวรไกรวงศ์ ที่ช่วยเป็นที่ปรึกษาและให้คำแนะนำรวมทั้งข้อคิดเห็นที่เป็นประโยชน์ต่อการจัดทำบทความนี้

Contact authors:

อโนทัย พุทธาริ
ผู้เชี่ยวชาญอาวุโส
ด้านตรวจสอบแบบจำลอง
ฝ่ายประเมินความเสี่ยงและ
แบบจำลองสถาบันการเงิน
สายกำกับสถาบันการเงิน
anotai@bot.or.th



จิตรภณ หุริเจริญพรพานิช
ผู้ช่วยผู้อำนวยการ
ฝ่ายประเมินความเสี่ยงและ
แบบจำลองสถาบันการเงิน
สายกำกับสถาบันการเงิน
Chittrah@bot.or.th



เพ็ญสิริ บำรุงเชาว์เกษม
ผู้ตรวจสอบอาวุโส
ฝ่ายประเมินความเสี่ยงและ
แบบจำลองสถาบันการเงิน
สายกำกับสถาบันการเงิน
Pensirib@bot.or.th



ชินวัฒน์ เทพหัสดิน ณ อยุธยา
ผู้วิเคราะห์อาวุโส
กลุ่มงานดาต้าอานาไลติกส์
ChinnawD@bot.or.th