



ศึกษาอัลกอริทึม และเปรียบเทียบผลลัพธ์ ในการทำสร้างแบบจำลอง
ในการทำนายวิกฤตเศรษฐกิจของประเทศสหรัฐอเมริกา โดยใช้ machine learning
Modeling and predicting U.S. recession using machine learning techniques

อภิชา กวินพลาสา¹ และ ธฤตพน อู่สวัสดิ์²

¹ วิทยาศาสตร์มหาบัณฑิต สาขาวิศวกรรมการเงิน คณะวิทยาศาสตร์ มหาวิทยาลัยหอการค้าไทย, apicha.kwinpolasa@gmail.com

² คณะบริหารธุรกิจ มหาวิทยาลัยหอการค้าไทย, thitapon_ous@utcc.ac.th

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษากระบวนการสร้างแบบจำลองโดยใช้เกรเดียนต์บูตติ้ง (Gradient Boosting) รวมถึงทฤษฎีที่เกี่ยวข้อง และทดลองทดลองสร้างแบบจำลองตามงานวิจัย “Modeling and predicting U.S. recessions using machine learning techniques” โดย Spyridon D. Vrontos John Galakis และ Ioannis D. Vrontos เพื่อศึกษาความแตกต่างของแบบจำลองและสามารถนำไปประยุกต์ใช้กับงานอื่นๆ ได้อย่างเหมาะสม ซึ่งงานวิจัยดังกล่าวมีการนำ machine learning ทั้งหมด 18 แบบจำลองมาใช้เปรียบเทียบค่าทางสถิติ ทางผู้ศึกษาได้อาแบบจำลอง Logistic Regression และ Gradient booting มาทำการศึกษาและสร้างแบบจำลองขึ้นมา โดยที่ Logistic Regression เป็นแบบจำลองมาตรฐาน ส่วน Gradient booting เป็นแบบจำลองที่เราสนใจจะศึกษา เนื่องจากมีการประยุกต์ใช้งานหลากหลายมาก แล้วนำทั้งสองมาเปรียบเทียบกัน โดยใช้ค่าทางสถิติเพื่อพิจารณาว่าแบบจำลองใดดีกว่ากัน เริ่มจากใช้ตัวแปรทางเศรษฐกิจและการเงินทั้งหมด 56 ตัวแปรเป็นข้อมูลที่ใช้ทำแบบจำลอง Gradient booting ส่วน Logistic Regression ใช้เพียงตัวแปรเพียง 1 ตัวคือระยะระหว่างอัตราผลตอบแทนระยะสั้นกับระยะยาว กับตัวที่บ่งบอกว่าเป็นสถานะถดถอยอีก 1 ตัวแปร โดยมีการทำกรอบเวลาคาดการณ์ล่วงหน้าเป็น 3 เดือน 6 เดือน และ 12 เดือน เพื่อดูประสิทธิภาพในแต่ละกรอบเวลา

ผลการศึกษา Logistic Regression โดยใช้ในการคาดการณ์ล่วงหน้า 12 เดือน สามารถเป็นเกณฑ์มาตรฐานได้ และสมเหตุสมผลตามงานวิจัยที่อ้างอิง และแบบจำลอง Gradient booting มีประสิทธิภาพดีกว่า Logistic Regression ทุกตัววัดประสิทธิภาพ ถึงแม้ว่าจะมีความแม่นยำที่ใกล้เคียงกัน เนื่องจากข้อมูลที่เป็นสถานะปกติมีถึง 89% และปัญหาเวลาในการประมวลผลค่อนข้างนานพอสมควร ส่วนกรอบเวลาคาดการณ์ล่วงหน้าที่สั้นลงค่ายิ่งแย่ง โดยที่แบบจำลอง Logistic Regression ที่ใช้ในการคาดการณ์ล่วงหน้า 3 เดือน ไม่สามารถคาดการณ์ได้เลย แต่ยังมีข้อสังเกตอยู่หนึ่งประการคือการคาดการณ์ความน่าจะเป็นที่เกิดสถานะถดถอยของ Gradient booting มีค่าใกล้เคียง 0 กับ 1 เท่านั้นจึงไม่เหมาะสำหรับประยุกต์ใช้กับการหาแนวโน้มความน่าจะเป็นหรือการเคลื่อนที่ของความน่าจะเป็น

คำสำคัญ: การเรียนรู้ของเครื่อง, เกรเดียนต์ บูตติ้ง, การถดถอยแบบโลจิสติก



1. บทนำ

machine learning คือการเรียนรู้ของเครื่องจักร ซึ่ง machine learning เป็นเพียงส่วนหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence, AI) ที่ช่วยให้ระบบเทคโนโลยีสารสนเทศ (Information Technology, IT) รู้จักกับรูปแบบพื้นฐานของอัลกอริทึมและชุดข้อมูลต่างๆ เพื่อเป็นการเรียนรู้รูปแบบอัตโนมัติผ่านข้อมูลและประสบการณ์ด้วยตัวเอง ใช้ในการค้นหา แยกแยะ สรุป คาดคะเน คำนวณความน่าจะเป็น และเพื่อพัฒนากระบวนการแก้ไขปัญหาได้อย่างเหมาะสม ด้วยประสิทธิภาพการเรียนรู้ของ machine learning ที่มีมากเช่นนี้ machine learning จึงสามารถนำไปปรับใช้กับการทำธุรกิจได้หลากหลาย

machine learning จึงกลายเป็นส่วนหนึ่งที่สำคัญมากในหลายแอปพลิเคชันเช่น เครดิตสกอร์ริง (Credit Scoring), การทำนายพลังงานแสงอาทิตย์และลม (Solar and wind energy prediction), การทำนายราคาน้ำมัน (Oil price prediction), การวิเคราะห์ความรู้สึก (Sentiment analysis) ซึ่ง machine learning เหล่านี้มันเป็นส่วนสำคัญที่จะช่วยหาแบบจำลองที่สามารถจัดการกับข้อมูลที่มีความซับซ้อนและจำนวนมากได้อย่างมีประสิทธิภาพ โดยปัจจุบันมีการพัฒนาอัลกอริทึมที่ซับซ้อนมากขึ้นไป เนื่องจากการประมวลผลมีประสิทธิภาพสูงขึ้น ทำให้แบบจำลองที่สร้างมามีประสิทธิภาพดีกว่าอัลกอริทึมเก่าหลายตัว ซึ่งอัลกอริทึมเหล่านี้ใช้เทคนิคการสุ่ม (Randomization techniques) เป็นหลัก ประกอบด้วยการสร้างวิธีแก้ปัญหามากหลายรูปแบบ เช่น แรนดอม ฟอเรส (Random Forest) หรือ เน้นการปรับปรุงกระบวนการ เช่น การบูตตีง (Boosting) ที่จริงแล้วแอปพลิเคชันที่กล่าวมาข้างต้นมีสิ่งๆ ที่เหมือนกันคือ ใช้วิธีการเอนเซมเบิล (Ensemble method)

ทางผู้ศึกษาได้ทำการศึกษาตามงานวิจัย “Modeling and predicting U.S. recessions using machine learning techniques” โดย Spyridon D. Vrontos กับ John Galakis กับ Ioannis D. Vrontos (2019) โดยวิจัยดังกล่าวมีการเปรียบเทียบอัลกอริทึมทั้งหมด 18 ชนิด แบ่งออกเป็น 7 กลุ่ม คือ “1. Logit and Probit models” “2. Penalized Logit models โดยใช้ λ ” “3. Penalized Logit models โดยใช้ $\log(\lambda)$ ” “4. Discriminant analysis models” “5. Bayesian models” “6. Trees and Forests” “7. Boosting”

ผู้ศึกษาจึงเลือกอัลกอริทึม 2 ตัวจากงานวิจัยข้างต้นมาศึกษาคือ “Logistic Regression” และ “Gradient Boosting” โดยที่โลจิสติกส์ รีเกรสชัน (Logistic regression) เป็นตัวเกณฑ์มาตรฐานที่ใช้ในเปรียบเทียบ และเกรเดียนต์บูตตีง (Gradient Boosting) เป็นตัวที่ผู้ศึกษาสนใจศึกษาเพราะว่า ถูกใช้กันอย่างแพร่หลาย เป็นที่นิยมมาก และยังสามารถนำไปประยุกต์ใช้กับการทำงานจริงได้อย่างเหมาะสม

2. วัตถุประสงค์การวิจัย

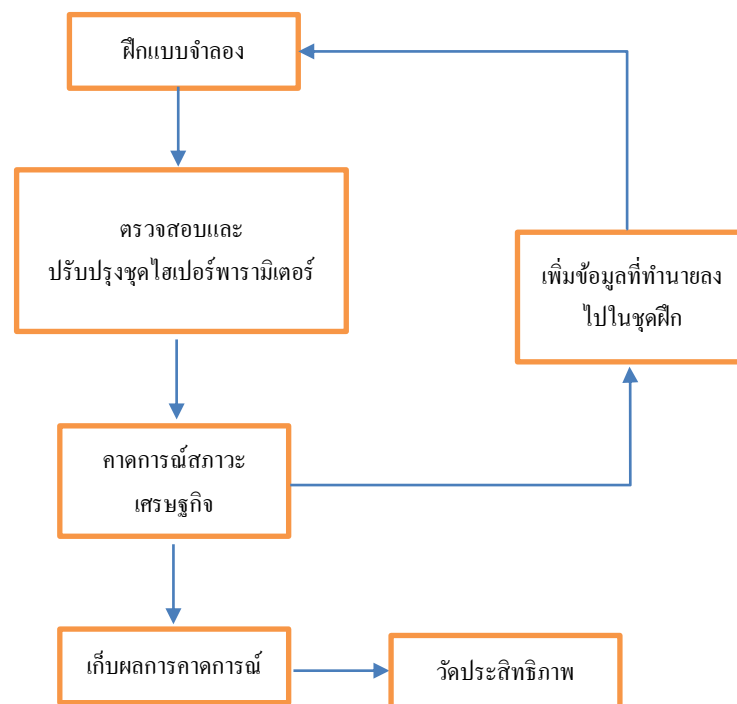
1. เพื่อให้ทราบกระบวนการการสร้างแบบจำลองโดยใช้ เกรเดียนต์บูตตีง (Gradient Boosting) รวมถึงทฤษฎีที่เกี่ยวข้อง
2. เพื่อนำข้อมูลจริงมาทำแบบจำลองทำนายวิกฤตเศรษฐกิจของประเทศสหรัฐอเมริกาตามงานวิจัยที่ศึกษา
3. เพื่อเปรียบเทียบผลลัพธ์ ระหว่าง เกรเดียนต์บูตตีง (Gradient Boosting) กับ โลจิสติกส์ รีเกรสชัน (Logistic regression) โดยใช้ค่าทางสถิติ



3. การดำเนินการวิจัย

ขั้นตอนการดำเนินงาน

1. รวบรวมข้อมูลทางเศรษฐกิจและการเงินจาก Federal Reserve Bank of St. Louis' FRED ทั้งหมด 59 ตัวแปร และตัวชี้วัดเศรษฐกิจถอดยี่ได้มาจาก National Bureau of Economic Research's Business Cycle Dating Committee chronology of U.S. business cycles
2. ปรับข้อมูลให้เป็น leading ตามกรอบเวลาที่ศึกษาคือ 3 เดือน 6 เดือน และ 12 เดือน
3. แยกข้อมูลเป็นสามกลุ่ม คือ กลุ่มแรก จำนวน 216 ข้อมูล ใช้สำหรับการฝึกแบบจำลอง กลุ่มที่สอง จำนวน 36 ข้อมูล ใช้ในการตรวจสอบและปรับค่า ชุดไฮเปอร์พารามิเตอร์ และกลุ่มที่สาม จำนวน 252 ข้อมูล ใช้ในการทำนายเพื่อวัดผล
4. ฝึกแบบจำลองและทำนายแบบ walk forward คือ ข้อมูลเก่าเมื่อถูกทำนายเสร็จจะถูกนำไปฝึกใหม่เพื่อรวมเหตุการณ์ใหม่ๆที่เกิดขึ้น มีขั้นตอนเป็นไปตามรูปที่ 1



รูปที่ 1 ขั้นตอนการฝึกแบบจำลองและทำนายผลแบบ walk forward

5. เมื่อเก็บผลการคาดการณ์ทุกช่วงเวลาเรียบร้อยแล้ว นำผลที่ได้มาทำการวัดประสิทธิภาพโดยใช้ ค่าทางสถิติคือ ความแม่นยำ พื้นที่ใต้เส้นโค้ง อาโอซี ความไว ความจำเพาะ คะแนนเอฟ1
6. เมื่อได้ตัววัดประสิทธิภาพของทั้ง 2 แบบจำลองแล้วนำมาเปรียบเทียบ และสรุปผล



โดยแบบจำลอง เกรเดียนต์ บูตติ้ง (Gradient boosting) ที่ใช้มีแนวคิดและทฤษฎีดังนี้

Friedman (2001, 2002) ได้พัฒนากรอบงานสำหรับการสร้างเทคนิคการบูตติ้งใหม่โดยอ้างอิงจากหนังสือ the statistical principles of additive modeling and maximum likelihood (Friedman et al., 2000) โดยเฉพาะอย่างยิ่ง Friedman (2001) ได้นำเสนอวิธีการทั่วไปสำหรับการประมาณค่าหรือการประมาณฟังก์ชัน $F(x_{t-h})$ โดยการจับคู่ตัวแปรทำนายที่ล่าช้า x_{t-h} กับตัวแปรตาม โดยอ้างอิงการออฟติไมเซชันเชิงตัวเลข (numerical optimization) ในขอบเขตพื้นที่ฟังก์ชัน (function space) ซึ่งฟังก์ชัน $F(x_{t-h})$ สามารถแสดงได้ในรูปแบบของ forward stagewise additive modeling และ application of steepest-descent minimization

อัลกอริทึมการเคลื่อนลงตามความชัน (Gradient Descent Algorithm) ถูกพัฒนามาเพื่อปรับแต่งแบบจำลอง โดยใช้เกณฑ์ความเหมาะสมที่แตกต่างกัน แนวคิดหลักของอัลกอริทึมนี้คือการสร้างแบบจำลองขึ้นมาแล้วปรับปรุงตามลำดับไปเรื่อยๆ โดยจากการเรียนรู้และปรับค่าของแบบจำลองที่อ่อนแอให้เหมาะสมกับค่าความผิดพลาดเทียม (pseudo-residuals) ปัจจุบัน ในการวนซ้ำแต่ละรอบตามลำดับ

จุดสนใจหลักของการวิเคราะห์พื้นฐานคือการสร้างแบบจำลองและการทำนายค่าความน่าจะเป็นของภาวะถดถอย y_t โดยใช้ตัวแปรทำนาย x_{t-h}

สมมุติว่าแต่ละ $y_t = 1$ คือสถานะถดถอย เป็นผลลัพธ์ของตัวแปรสุ่มแบบแบร์นูลลี ด้วยความน่าจะเป็นที่จะเกิดสถานะถดถอย p_t ปริมาณที่สนใจคือ log-odds แทนด้วย $\lambda(x_{t-h})$ โดยที่ $\lambda(x_{t-h}) = \ln\left(\frac{p_t}{1-p_t}\right)$ ซึ่งเป็นฟังก์ชันของชุดตัวแปรทำนาย x_{t-h} ภายใต้กรอบของการเคลื่อนลงตามความชัน (Gradient Descent Algorithm) $\lambda(x_{t-h})$ คือฟังก์ชัน $F(x_{t-h})$ ซึ่งสามารถอธิบายดังสมการที่ 1

$$\lambda(x_{t-h}) = F(x_{t-h}) = \sum_{l=1}^L g_l(x_{t-h}, \eta) \quad (1)$$

โดยที่ฟังก์ชัน g_l ขึ้นอยู่กับพื้นฐานอัลกอริทึมต่างๆ เช่น ต้นไม้ตัดสินใจ (Decision tree) เป็นต้น และ η_l คือเวกเตอร์ของพารามิเตอร์ที่จะใช้ในการประมาณค่า สำหรับต้นไม้ตัดสินใจคือค่าที่แยกชุดข้อมูลในแต่ละโหนดจนไปถึงโหนดสุดท้ายหรือใบ

ขั้นตอนของอัลกอริทึม Gradient Boosting สามารถเขียนได้ดังนี้

1. เริ่มต้นด้วย $F_0(x_{t-h}) = 0$ และตั้งค่า learning rate $\varepsilon > 0$ ซึ่งค่านี้สามารถควบคุมอัตราการบูตติ้งให้พอดีหรือมากเกินไปได้

2. สำหรับ $l = 1, \dots, L$

2.1. กำหนดค่าความผิดพลาดเทียม (pseudo-residuals) เช่น negative gradient ของฟังก์ชันสูญเสีย (Loss function) ถูกมิไนมิเซอร์ (minimized) ที่ความพอดีปัจจุบันในแต่ละจุดของข้อมูลที่ใช้ฝึก สามารถเขียนเป็นสมการได้ดังนี้

$$R_t = - \frac{\partial L(Y_t, F(X_{t-h}))}{\partial F(X_{t-h})} \Big|_{F(X_{t-h}) = \hat{F}_{l-1}(X_{t-h})} \quad (2)$$

2.2. ประมาณค่า negative gradient โดยใช้ความลึกของต้นไม้ตัดสินใจ (d) และแก้ไขปัญหาตามวิธีออฟติไมเซชัน (Optimization) สามารถเขียนสมการได้ดังนี้



$$\text{minimize}_\gamma = \sum_{t=1}^T (R_t - g(X_{t-h}; \gamma))^2 \quad (3)$$

2.3. ปรับปรุง $\hat{F}_l(X_{t-h})$ เป็นไปตามสมการนี้

$$\hat{F}_l(X_{t-h}) = \hat{F}_{l-1}(X_{t-h}) + \hat{g}_l(X_{t-h}) \quad (4)$$

$$\text{เมื่อ } \hat{g}_l(X_{t-h}) = \epsilon g(x_{t-h}; \eta)$$

2.4. ส่งกลับค่าในลำดับถัดไปที่ $\hat{F}_l(X_{t-h}), l = 1, \dots, L$

4. ผลการศึกษา

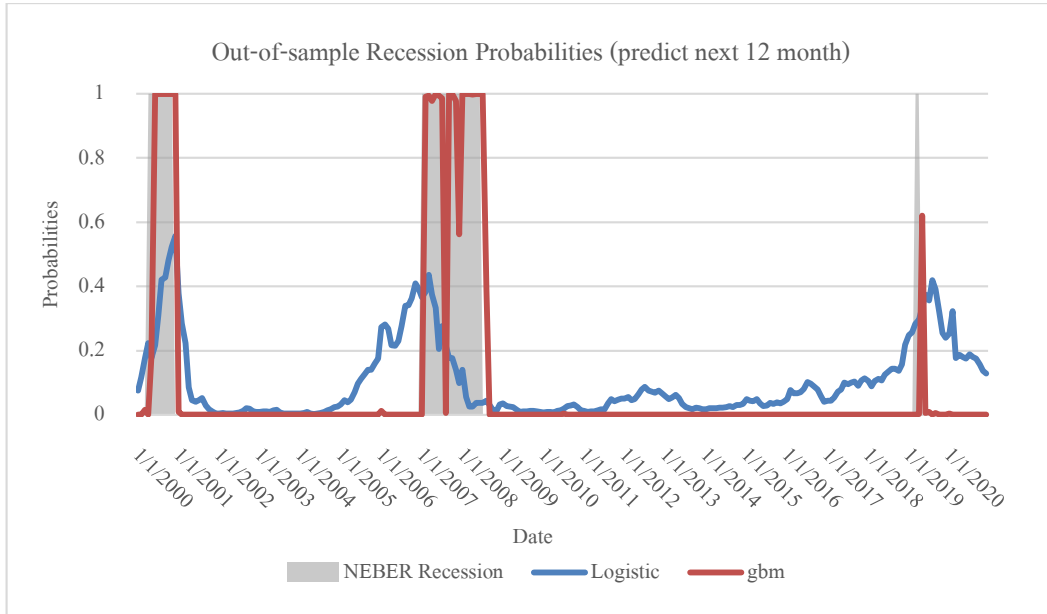
1. ผลการศึกษาเปรียบเทียบของแบบจำลองคาดการณ์ล่วงหน้า 12 เดือน

ความแม่นยำในการทำนายของแบบจำลองการถดถอยโลจิสติกโดยใช้ term space อย่างเดียวมีผลลัพธ์เป็นไปตามตารางที่ 1 โดยมีค่า พื้นที่ใต้กราฟของเส้นโค้ง อาโอซี (Area under the ROC Curve; AUC) เท่ากับ 82% หรือค่าความแม่นยำ (Accuracy) เท่ากับ 87% เส้นอัตราผลตอบแทนทำหน้าที่ได้ค่อนข้างดีในการให้สัญญาณเตือนล่วงหน้าที่สุดคล้องกันกับสภาวะถดถอยที่เกิดขึ้นในช่วงปี ค.ศ. 2000 – 2021 โดยทั่วไปผลลัพธ์จะค่อนข้างคล้ายคลึงกันกับแบบจำลอง Probit ซึ่งอ้างอิงมาจากงานวิจัยล่าสุดของ Liu และ Moench (2016)


ต่อมาคือแบบจำลองที่สนใจคือ Gradient Boosting มีความแม่นยำในการคาดการณ์สูงมากโดยที่ประสิทธิภาพเป็นไปตามตารางที่ 1 โดยมีค่าดังนี้ พื้นที่ใต้กราฟของเส้นโค้ง อาโอซี (Area under the ROC Curve; AUC) เท่ากับ 96% หรือค่าความแม่นยำ (Accuracy) เท่ากับ 96% และในส่วนรูปที่ 2 แสดงให้เห็นความน่าจะเป็นในการสภาวะถดถอยและช่วงเวลาที่เกิดสภาวะถดถอยจริง ของช่วง out-of-sample และ รูปที่ 3 แสดงให้กราฟของเส้นโค้ง อาโอซี ของแต่ละแบบจำลอง ซึ่งทั้งหมดนี้เป็นการเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 2 โดยใช้ช่วงเวลาคาดการณ์ล่วงหน้า 12 เดือน

ตารางที่ 1 แสดงผลประสิทธิภาพของแบบจำลองโดยใช้ช่วงเวลาคาดการณ์ล่วงหน้า 12 เดือน

Model	Logistic Regression	Gradient Boosting
พื้นที่ใต้กราฟของเส้นโค้ง อาโอซี (Area under the ROC Curve; AUC)	0.82	0.96
ค่าความผิดพลาดต่ำสุดของการแยกประเภท (Minimum Classification Error; MCE)	0.13	0.04
ค่าความแม่นยำ (Accuracy)	0.87	0.96
สัมประสิทธิ์แคปป์ของโคเฮน (Cohen's kappa)	0.31	0.79
ความไว (Sensitivity)	0.36	0.79
ความจำเพาะ (Specificity)	0.36	0.79
ความเที่ยงตรง (Precision)	0.42	0.85
คะแนน เอฟวัน (F1 Score)	0.38	0.81
Balanced accuracy	0.88	0.64



รูปที่ 2 ความน่าของการเกิดสภาวะถดถอยของแต่ละแบบจำลอง และ ช่วงที่เกิดสภาวะถดถอยจริงจาก NEBER Recession โดยใช้ในการคาดการณ์ล่วงหน้า 12 เดือน



รูปที่ 3 กราฟของเส้นโค้ง อาโอซี ของแต่ละแบบจำลอง โดยใช้ในการคาดการณ์ล่วงหน้า 12 เดือน

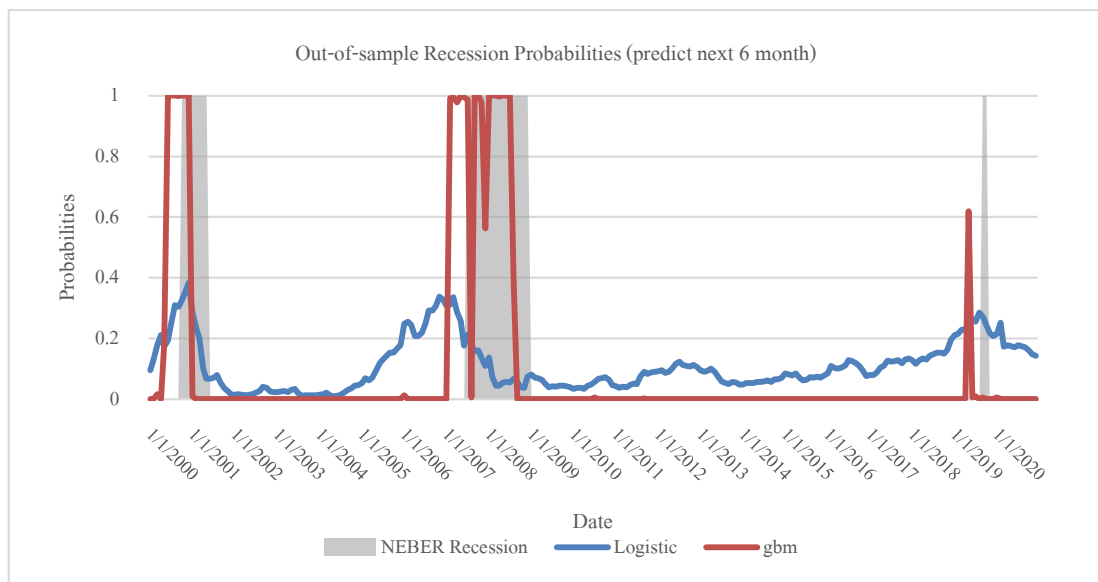


2. ผลการศึกษาเปรียบเทียบของแบบจำลองคาดการณ์ล่วงหน้า 6 เดือน

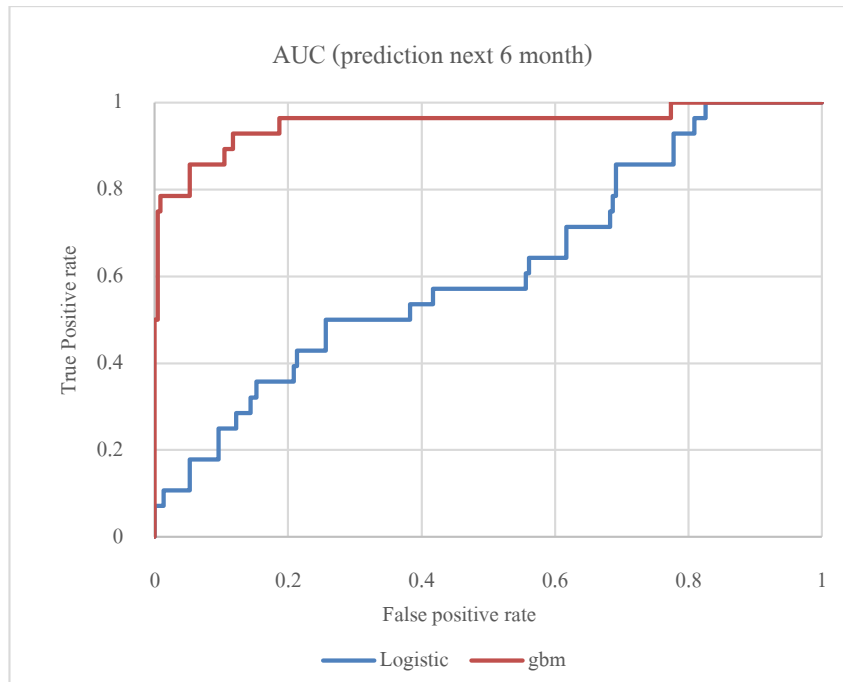
จากตารางที่ 2 พบว่าแบบจำลอง logistic แม้ว่าความแม่นยำใกล้เคียงการคาดการณ์ล่วงหน้า 12 เดือน เมื่อพิจารณา AUC มีค่าเท่ากับ 62% ซึ่งมีค่าน้อยลงมากเมื่อเทียบกับการคาดการณ์ล่วงหน้า 12 เดือนบ่งบอกว่าแบบจำลองนี้ทำนายได้แย่ง sensitivity ลดลง และ specificity เพิ่มขึ้นจึงบอกได้เป็นนัยว่าแบบจำลองนี้ False negative สูงขึ้น ในส่วนของแบบจำลอง gbm มีความแตกต่างกันเล็กน้อย แต่ก็ลดลง เมื่อเราไปรูปภาพที่ 4 แสดงให้เห็นความน่าจะเป็นในการสภาวะถดถอยและช่วงเวลาที่เกิดสภาวะถดถอยจริง ของช่วง out-of-sample ของการคาดการณ์ล่วงหน้า 6 เดือน จะพบว่า จุดที่ทำนายว่าเกิดสภาวะถดถอยเกิดก่อน เหตุการณ์ที่เกิดขึ้นจริง ผลจึงไปตามรูปภาพที่ 5 แสดงให้กราฟของเส้นโค้ง อาไอซี ของแต่ละ แบบจำลองของการคาดการณ์ล่วงหน้า 6 เดือน จึงสรุปได้ว่าความสามารถในการทำนายลดลงอย่างมาก ผลลัพธ์เป็นไปตามตารางที่ 2

ตารางที่ 2 แสดงผลประสิทธิภาพของแบบจำลอง โดยใช้ช่วงเวลาคาดการณ์ล่วงหน้า 6 เดือน

Metrics	Mode	Logistic Regression	Gradient Boosting
พื้นที่ใต้กราฟของเส้นโค้ง อาไอซี (Area under the ROC Curve; AUC)		0.62	0.95
ค่าความผิดพลาดต่ำสุดของการแยกประเภท (Minimum Classification Error; MCE)		0.13	0.04
ค่าความแม่นยำ (Accuracy)		0.87	0.96
สัมประสิทธิ์แคปปาของโคเฮน (Cohen's kappa)		0.09	0.79
ความไว (Sensitivity)		0.96	0.98
ความจำเพาะ (Specificity)		0.10	0.78
ความเที่ยงตรง (Precision)		0.27	0.85
คะแนน เอฟวัน (F1 Score)		0.15	0.81
Balanced accuracy		0.53	0.88



รูปที่ 4 ความน่าจะเป็นของการเกิดสภาวะถดถอยของแต่ละแบบจำลอง และ ช่วงที่เกิดสภาวะถดถอยจริงจาก NEBER Recession โดยใช้ในการคาดการณ์ล่วงหน้า 6 เดือน



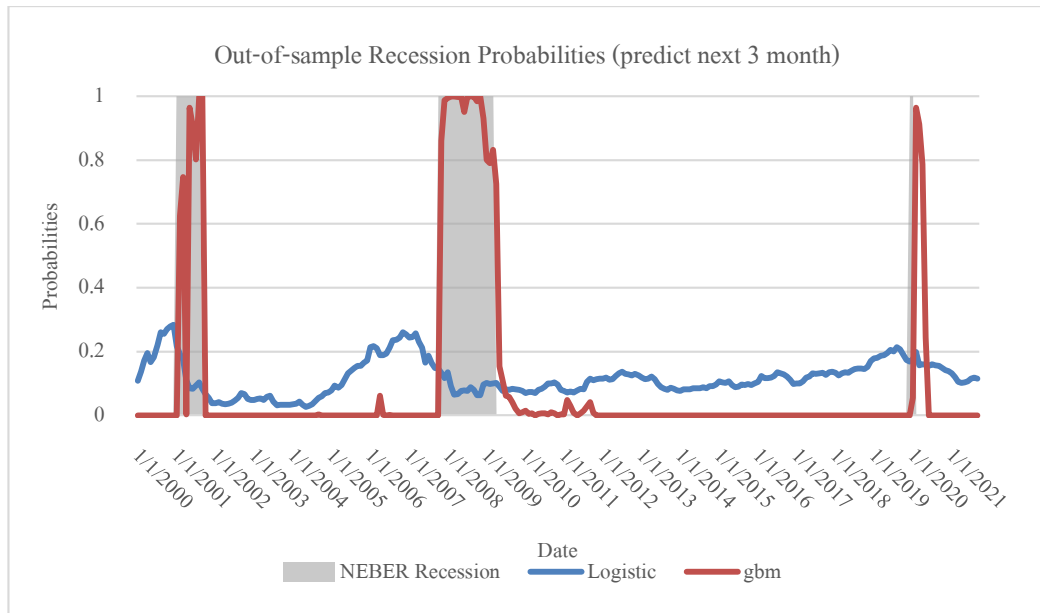
รูปที่ 5 กราฟของเส้นโค้ง อีโอซี ของแต่ละแบบจำลอง โดยใช้ในการคาดการณ์ล่วงหน้า 6 เดือน

3. ผลการศึกษาเปรียบเทียบของแบบจำลองคาดการณ์ล่วงหน้า 3 เดือน

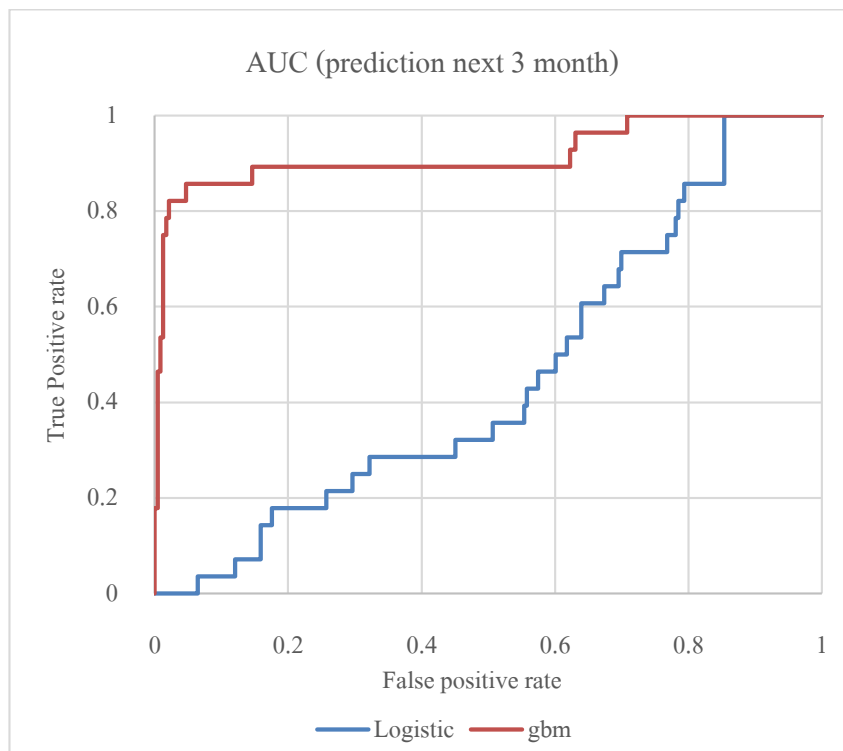
จากตารางที่ 3 พบว่าแบบจำลอง logistic ไม่สามารถคาดการณ์ได้โดย สามารถดูได้จาก AUC ที่ต่ำกว่า 50% และค่าความไวเท่ากับ 0 และ ความจำเพาะเท่ากับ 1 ซึ่งบอกได้ว่า แบบจำลองนี้ 100% คาดการณ์ เป็นสภาวะปกติทั้งหมด ทำให้การคาดการณ์ผิดพลาดทั้งหมด และที่ความแม่นยำเท่ากับ 89% เพราะว่า ชุดข้อมูลเป็นแบบไม่สมดุลกัน คือ มีสภาวะปกติประมาณ 89% สภาวะถดถอย 11% ความแม่นยำจึงเป็น 89% ในส่วน gbm เมื่อเทียบกับ คาดการณ์ล่วงหน้า 6 เดือน กับ 12 เดือน พบว่ามีค่าน้อยกว่าอยู่ประมาณ 4 – 5 % มีค่าเท่ากับ 91% ส่วนค่าความไว 82% บ่งบอกว่าแบบจำลองนี้คาดได้ถูกช่วงเวลาค่อนข้างสูง เมื่อดูรูปที่ 6 จะเห็นว่าเป็นตามทีกล่าวมาข้างต้น และ ประสิทธิภาพของแบบจำลองแต่ละแบบโดยใช้ในการคาดการณ์ระยะสั้นคือ 3 เดือน ผลลัพธ์เป็นไปตามตารางที่ 3

ตารางที่ 3 แสดงผลประสิทธิภาพของแบบจำลอง โดยใช้ช่วงเวลาคาดการณ์ล่วงหน้า 3 เดือน

Metrics	Model	
	Logistic Regression	Gradient Boosting
พื้นที่ใต้กราฟของเส้นโค้ง อีโอซี (Area under the ROC Curve; AUC)	0.45	0.91
ค่าความผิดพลาดต่ำสุดของการแยกประเภท (Minimum Classification Error; MCE)	0.10	0.03
ค่าความแม่นยำ (Accuracy)	0.89	0.96
สัมประสิทธิ์แคปปาของโคเฮน (Cohen's kappa)	0	0.79
ความไว (Sensitivity)	0	0.82
ความจำเพาะ (Specificity)	1	0.97
ความเที่ยงตรง (Precision)	0	0.82
คะแนน เอฟวัน (F1 Score)	0	0.82
Balanced accuracy	0	0.90



รูปที่ 6 ความน่าของการเกิดสภาวะถดถอยของแต่ละแบบจำลอง และ ช่วงที่เกิดสภาวะถดถอยจริงจาก NEBER Recession โดยใช้ในการคาดการณ์ล่วงหน้า 3 เดือน



รูปที่ 7 กราฟของเส้นโค้ง อาโอซี ของแต่ละแบบจำลอง โดยใช้ในการคาดการณ์ล่วงหน้า 3 เดือน



5. สรุปผลการศึกษา

จากการศึกษาอัลกอริทึม Gradient Booting เพื่อสร้างแบบจำลองทำนายวิกฤต เศรษฐกิจของประเทศสหรัฐอเมริกาเปรียบเทียบกับประสิทธิภาพอัลกอริทึม Logistic Regression ที่ใช้เป็นเกณฑ์มาตรฐานสำหรับอ้างอิง ผลของการศึกษาครั้งนี้สามารถสรุปได้ดังนี้

ประการแรก แบบจำลอง Logistic Regression ของเส้นอัตราผลตอบแทน (term space) โดยคาดการณ์ล่วงหน้า 12 เดือน ให้ผลสอดคล้องกับสมมุติฐานและหลักฐานยืนยัน ความสามารถในการทำนายที่เดือนล่วงหน้าของสถานะถดถอยของเศรษฐกิจสหรัฐฯ ดังนั้นจึงเป็นทางเลือกที่มีเหตุผลในการเลือกแบบจำลองนี้เป็นเกณฑ์มาตรฐานหรือแบบจำลองอ้างอิง

ประการที่สองข้อสรุปที่สำคัญที่สุดคือ การนำ machine learning อย่าง Gradient Booting มาใช้ดูเหมือนจะเป็นก้าวที่ชัดเจนสำหรับการคาดการณ์สถานะเศรษฐกิจถดถอยของสหรัฐฯ เมื่อเทียบกับเทคนิคทางเศรษฐมิติหลักอย่าง Logistic Regression การสร้างการคาดการณ์จาก machine learning นี้ ช่วยปรับปรุงประสิทธิภาพ ความสามารถในการคาดการณ์และความแม่นยำ ในทุกตัวชี้วัด ไม่ว่าจะเป็น พื้นที่ใต้เส้นโค้ง ROC ความแม่นยำ ความไว และคะแนนเอฟ 1 ในทุกขอบเขตการพยากรณ์อย่างมีนัยสำคัญ

ประการสุดท้ายความแม่นยำของแบบจำลองแต่ละแบบมีความแตกต่างกันระดับหนึ่ง เพราะความแม่นยำของแบบจำลองไม่สอดคล้องกันระหว่างกรอบระยะเวลา อย่างไรก็ตาม เทคนิคบางอย่างแสดงประสิทธิภาพสัมพัทธ์ที่สอดคล้องกันมากขึ้น

6. ข้อเสนอแนะ

จากการสังเกตพบว่า Gradient booting ไม่เหมาะสำหรับทำนายความน่าจะเป็นเพราะตามทฤษฎีแล้วเป็น greedy algorithm ทำให้พบความน่าจะเป็นที่ได้รับออกมา เกือบเท่า 0 หรือ 1 เท่านั้น ไม่สามารถดูแนวโน้มได้ จึงสรุปได้ว่าน่าจะเหมาะสำหรับแก้ไขปัญหาที่ต้องการ 0 กับ 1 เท่านั้น เช่น นำไปประยุกต์ใช้กับการทำการตลาด ค้นหา กลุ่มเป้าหมายว่าจะซื้อของหรือไม่ซื้อของ เพื่อให้เกิดประสิทธิภาพสูงที่สุดในการทำโฆษณา

จากการเปรียบเทียบข้างต้น พบว่า Gradient booting มีประสิทธิภาพที่สูงกว่า logistic regression มาก ดังนั้นแล้วเมื่อโจทย์เหมาะสมทั้งสองอัลกอริทึมควรเลือก Gradient booting มากกว่าเพราะมีการพัฒนาปรับปรุงให้ดีขึ้นและลดจุดด้อยต่างๆที่มีในต้นไม้ตัดใจ เช่น การลด overfitting ของต้นไม้ และ เพิ่มประสิทธิภาพในการทำนายในแง่ ความแม่นยำ และพื้นที่ใต้เส้นโค้ง ROC

แบบจำลองที่ใช้ในการศึกษามีแค่ 2 ตัว ควรขยายไปศึกษาแบบจำลองอื่นๆเพิ่มเติม เช่น Bayesian, Random Fores, LASSO ที่ผลของการทดลองออกมาเป็นเส้นแนวโน้มความน่าจะเป็นคล้ายๆ Logistic Regression อ้างอิงผลจากบทความที่ศึกษา Spyridon D. Vrontos John Galakis และ Ioannis D. Vrontos (2019) เพื่อประยุกต์ใช้กับโจทย์ที่ต้องการเส้นแนวโน้มของความน่าจะเป็น



เอกสารอ้างอิง

- Berge, T. J., & Jorda, O. (2011). Evaluating the classification of economic activity into recessions and expansions. *American Economic Journal: Macroeconomics*, 3(2), 246–277.
- Chauvet, M., & Hamilton, J. D. (2006). Dating business cycle turning points. In C. Milas, P. Rothman, D. van Dijk, & D. E. Wildasin (Eds.), *Nonlinear time series analysis of business cycles: Contributions to economic analysis*, vol. 276 (pp. 1–54)
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232.
- Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367–378.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *Review of Financial Studies*, 33, 2223–2273.
- Liu, W., & Moench, E. (2016). What predicts US recessions?. *International Journal of Forecasting*, 32, 1138–1150.
- Ng, S. (2014). Boosting recessions. *Canadian Journal of Economics*, 47(1), 1–34.
- Spyridon D. Vrontos a, John Galakis b, Ioannis D. Vrontos c (2019) Modeling and predicting U.S. recessions using machine learning techniques