



การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคเหมืองข้อมูล

นายพงศธร แป้นไทย

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

วิทยาศาสตรมหาบัณฑิต

สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคเหมืองข้อมูล



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาหลักสูตร

วิทยาศาสตรมหาบัณฑิต

สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ใบรับรองการค้นคว้าอิสระ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

เรื่อง การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิค
เหมืองข้อมูล

โดย นายพงศ์ธร แป้นไทย

ได้รับอนุมัติให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชา
ระบบสารสนเทศเพื่อการจัดการ

คณบดีคณะเทคโนโลยีสารสนเทศและ

นวัตกรรมการดิจิทัล

(ผู้ช่วยศาสตราจารย์ ดร.สุนันทา สดสี)

คณะกรรมการสอบการค้นคว้าอิสระ

ประธาน

(ผู้ช่วยศาสตราจารย์ ดร.เดช ธรรมศิริ)

อาจารย์ที่ปรึกษา

(ผู้ช่วยศาสตราจารย์ ดร.วิชวีวรรณ จิตต์สกุล)

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.มณฑิรา รัตนศิริวงศ์วุฒิ)

ชื่อ : นายพงศ์ธร แป้นไทย
 ชื่อการค้นคว้าอิสระ : การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทย
 จากข้อมูลงบการเงินด้วยเทคนิคเหมืองข้อมูล
 สาขาวิชา : ระบบสารสนเทศเพื่อการจัดการ
 มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
 อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก : ผู้ช่วยศาสตราจารย์ ดร.วัชรวิวัฒน์ จิตต์สกุล
 ปีการศึกษา : 2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทย โดยใช้ข้อมูลงบการเงินเป็นข้อมูลหลัก กลุ่มตัวอย่างประกอบด้วยนิติบุคคลจำนวน 13,218 ราย ซึ่งกำหนดให้นิติบุคคลที่เลิกกิจการในปี พ.ศ. 2567 เป็นกลุ่มเหตุการณ์ และใช้ข้อมูลงบการเงินย้อนหลังในปี พ.ศ. 2565-2566 เป็นตัวแปรอิสระในการสร้างแบบจำลอง อัลกอริทึมที่ใช้ในการศึกษาได้แก่ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน อัลกอริทึมโลจิสติกเรกูแลชันแมชชีน และอัลกอริทึมการเรียนรู้เชิงลึก จากนั้นใช้เทคนิคการเรียนรู้แบบกลุ่ม ทำงานร่วมกันโดยใช้วิธีลงเสียงข้างมาก โดยดำเนินการเตรียม และทำความสะอาดข้อมูล สร้างตัวแปรเชิงการเติบโต และจัดการตัวแปรเชิงหมวดหมู่ให้อยู่ในรูปแบบที่เหมาะสม จากนั้นประเมินประสิทธิภาพด้วยเทคนิค การประเมินความถูกต้องแบบไขว้ โดยใช้ตัวชี้วัด ค่าความถูกต้อง ค่าความแม่นยำ ค่าระลอก และการถ่วงดุล ผลการศึกษาพบว่า อัลกอริทึมโลจิสติกเรกูแลชันแมชชีนให้ประสิทธิภาพสูงที่สุด โดยมีค่าความถูกต้องร้อยละ 94.10 ค่าความแม่นยำ 0.95 ค่าระลอก 0.94 และค่าการถ่วงดุล 0.94 และเมื่อนำแบบจำลองดังกล่าวไปทดสอบกับชุดข้อมูลทดสอบอิสระ (Unseen Data) จำนวน 3,186 รายการ พบว่าแบบจำลองยังคงให้ผลการพยากรณ์ที่มีประสิทธิภาพและความเสถียรสูง โดยมีค่าความถูกต้องร้อยละ 92.90 ค่าความแม่นยำ 0.93 ค่าระลอก 0.93 และค่าการถ่วงดุล 0.93 ผลการวิจัยสะท้อนให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่อง โดยเฉพาะอัลกอริทึมโลจิสติกเรกูแลชันแมชชีน มีศักยภาพในการนำไปประยุกต์ใช้เป็นเครื่องมือสนับสนุนการประเมินความเสี่ยงการเลิกกิจการของนิติบุคคลในประเทศไทยได้อย่างมีประสิทธิภาพ

(การค้นคว้าอิสระมีจำนวนทั้งสิ้น 109 หน้า)

คำสำคัญ : การเลิกกิจการ การเรียนรู้ของเครื่อง ข้อมูลงบการเงิน

อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก

Name : Mr. Pongtorn Panthai

Independent Study Title : Forecasting Corporate Dissolution in Thailand from
Financial Statement Data Using Data Mining Techniques

Major Field : Management Information Systems

King Mongkut's University of Technology North
Bangkok

Independent Study Advisor : Assistant Professor Dr. Watchareewan Jitsakul

Academic Year : 2025

ABSTRACT

This study aims to develop and compare the performance of machine learning models for predicting corporate dissolution in Thailand using financial statement data as the primary source. The sample consists of 13,218 legal entities, of which those that ceased operations in 2024 were classified as the event group. Financial statement data from 2022–2023 were used as independent variables for model construction. The machine learning algorithms employed in this study include Support Vector Machine (SVM), Light Gradient Boosting Machine (LightGBM), and Deep Neural Network (DNN). In addition, ensemble learning was applied using a majority voting approach. The data preparation process involved data cleaning, the construction of growth-related variables, and the transformation of categorical variables into suitable formats. Model performance was evaluated using K-fold cross-validation with Accuracy, Precision, Recall, and F1-score as evaluation metrics. The results indicate that the LightGBM model achieved the highest performance, with an accuracy of 94.10%, precision of 0.95, recall of 0.94, and F1-score of 0.94. Furthermore, when tested on an independent unseen dataset of 3,186 entities, the model maintained high efficiency and stability, achieving an accuracy of 92.90%, precision of 0.93, recall of 0.93, and F1-score of 0.93. The findings suggest that machine learning models, particularly LightGBM, have strong potential for application as an effective decision-support tool for assessing corporate dissolution risk in Thailand.

(Total 109 Pages)

Keywords: Corporate Dissolution, Machine Learning, Financial Statements.

Advisor



กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องด้วยได้รับความกรุณาอย่างสูงจาก ผู้ช่วยศาสตราจารย์ ดร.วัชรวิวัฒน์ จิตต์สกุล อาจารย์ที่ปรึกษาการค้นคว้าอิสระ ที่กรุณาให้ คำปรึกษา แนะนำแนวทางการศึกษาวิจัย ตลอดจนตรวจสอบและแก้ไขข้อบกพร่องต่าง ๆ จนทำให้ การค้นคว้าอิสระฉบับนี้มีความถูกต้องสมบูรณ์ ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.เดช ธรรมศิริ ประธานกรรมการสอบ และ ผู้ช่วยศาสตราจารย์ ดร.มณฑิรา รัตนศิริวงศ์วุฒิ ที่สละเวลาตรวจสอบ ผลงานและให้คำแนะนำเพิ่มเติมอันเป็นประโยชน์อย่างยิ่ง ขอขอบพระคุณคณาจารย์คณะ เทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัลทุกท่าน ที่ได้ถ่ายทอดองค์ความรู้และประสบการณ์จน สำเร็จการศึกษา

ท้ายที่สุดนี้ ผู้วิจัยขอขอบพระคุณครอบครัวที่คอยให้การสนับสนุนและเป็นกำลังใจสำคัญ เสมอมา จนการศึกษาค้นคว้าอิสระฉบับนี้สำเร็จลุล่วง หากมีข้อผิดพลาดประการใด ผู้จัดทำขอน้อม รับคำแนะนำเพื่อนำไปปรับปรุงแก้ไขในโอกาสต่อไป

พงศ์ธร แป้นไทย

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ข
บทคัดย่อภาษาอังกฤษ	ค
กิตติกรรมประกาศ	จ
สารบัญตาราง	ซ
สารบัญภาพ	ฅ
บทที่ 1 บทนำ	
1.1 ความเป็นมาและความสำคัญ	1
1.2 วัตถุประสงค์ของการวิจัย	2
1.3 ขอบเขตของการวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	
2.1 แนวคิดและทฤษฎีเกี่ยวกับความล้มเหลวทางการเงิน (Financial Distress)	5
2.2 เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Techniques)	6
2.3 อัลกอริทึมสำหรับการพยากรณ์	7
2.4 งานวิจัยที่เกี่ยวข้อง	10
บทที่ 3 วิธีดำเนินงานวิจัย	
3.1 การออกแบบกรอบแนวความคิด (Conceptual Framework Design)	25
3.2 การเก็บรวบรวมข้อมูล (Data Collection)	26
3.3 การจัดเตรียมข้อมูล (Data Preprocessing)	28
3.4 การพัฒนา และวัดประสิทธิภาพของแบบจำลอง (Model Development & Evaluation)	29
3.5 การนำแบบจำลองไปใช้งาน (Model Deployment)	32
บทที่ 4 ผลการดำเนินงานวิจัย	
4.1 ผลการเก็บรวบรวมข้อมูล และจัดเตรียมข้อมูล	34
4.2 ผลการพัฒนา และทดสอบประสิทธิภาพของแบบจำลอง	38
4.3 ผลการนำแบบจำลองไปใช้งาน	89
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ	
5.1 สรุปผลการวิจัย	91

สารบัญ (ต่อ)

	หน้า
5.2 การอภิปรายผลการวิจัย	92
5.3 ข้อเสนอแนะ	93
บรรณานุกรม	104
ประวัติผู้จัดทำการค้นคว้าอิสระ	109



สารบัญตาราง

ตารางที่	หน้า
2-1 งานวิจัยที่เกี่ยวข้อง	18
3-1 ค่าพารามิเตอร์สำหรับการทดสอบอัลกอริทึม	30
3-2 ตาราง Confusion Matrix	31
4-1 จำนวนและร้อยละของนิติบุคคลในชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset)	34
4-2 ตัวอย่างชุดข้อมูลสำหรับการพัฒนาแบบจำลองหลังผ่านกระบวนการจัดเตรียมข้อมูล	36
4-3 ค่าพารามิเตอร์ของอัลกอริทึม Support Vector Machine	38
4-4 ค่าพารามิเตอร์ของอัลกอริทึม Light Gradient Boosting Machine	38
4-5 ค่าพารามิเตอร์ของอัลกอริทึม Deep Neural Network	39
4-6 ค่าพารามิเตอร์ของเทคนิค Ensemble Learning	39
4-7 ผลลัพธ์ของอัลกอริทึม Support Vector Machine	40
4-8 ผลลัพธ์ของอัลกอริทึม Light Gradient Boosting Machine	55
4-9 ผลลัพธ์ของอัลกอริทึม Deep Neural Network	83
4-10 ผลลัพธ์ของเทคนิค Ensemble Learning โดยใช้พารามิเตอร์ Vote	87
4-11 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง	88
4-12 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองด้วย Unseen Data	88

สารบัญรูปภาพ

ภาพที่	หน้า
2-1 การค้นหา ไฮเปอร์เพลน (Hyperplane) ที่ดีที่สุด	7
2-2 การสร้างแบบจำลองโครงข่ายประสาทเทียมเชิงลึก (DNN)	9
3-1 กรอบแนวคิดงานวิจัย	25
3-2 Flowchart ขั้นตอนการดำเนินงาน	26
3-3 โครงร่างการออกแบบส่วน User Interface	33
3-4 โครงร่างการแสดงผลการพยากรณ์จากแบบจำลอง	33
4-1 การแสดงผลหน้า Data Input Interface	89
4-2 หน้าจอแสดงผลการพยากรณ์ความเสี่ยงการเลิกกิจการพร้อม ค่าความน่าจะเป็น (Probability)	90



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญ

ในยุคปัจจุบันที่เศรษฐกิจโลกมีความผันผวนสูง และการแข่งขันทางธุรกิจทวีความรุนแรงมากขึ้น การดำเนินธุรกิจของนิติบุคคลต้องเผชิญกับความเสี่ยงหลากหลายด้าน ทั้งจากปัจจัยภายใน เช่น การบริหารจัดการ การเงิน การผลิต และทรัพยากรบุคคล รวมถึงปัจจัยภายนอก เช่น ภาวะเศรษฐกิจโลก การเปลี่ยนแปลงของเทคโนโลยี พฤติกรรมผู้บริโภค และนโยบายของภาครัฐ เป็นต้น ความเสี่ยงเหล่านี้อาจส่งผลกระทบต่อความสามารถในการดำเนินธุรกิจอย่างยั่งยืน และอาจนำไปสู่การเลิกกิจการในที่สุด โดยในปี 2566 สถิติการจดทะเบียนเลิกประกอบกิจการในไทยถือว่าทำสถิติสูงสุดในรอบ 13 ปี อยู่ที่ 23,380 ราย ขณะที่สถานการณ์ในปี 2567 นี้ยังคงต้องติดตามอย่างใกล้ชิดเพราะสถานการณ์ความเสี่ยงที่ธุรกิจกำลังเผชิญยังคงรุนแรงแม้จะเป็นช่วงที่โควิดระบาดได้คลี่คลายไปแล้วก็ตาม [1] การเลิกกิจการของนิติบุคคลไม่เพียงแต่ส่งผลกระทบต่อเจ้าของกิจการเท่านั้น แต่ยังส่งผลกระทบต่อพนักงาน ผู้ถือหุ้น เจ้าหนี้ คู่ค้า และระบบเศรษฐกิจโดยรวม โดยเฉพาะในประเทศไทยที่ภาคธุรกิจขนาดกลาง และขนาดย่อม (SMEs) มีบทบาทสำคัญในการขับเคลื่อนเศรษฐกิจ การที่กิจการต้องปิดตัวลงจำนวนมากอาจส่งผลให้เกิดการว่างงาน การสูญเสียรายได้ของครัวเรือน และการชะลอตัวของระบบเศรษฐกิจในภาพรวม ดังนั้น การสามารถพยากรณ์ความเสี่ยงในการเลิกกิจการได้ล่วงหน้าจึงเป็นสิ่งสำคัญอย่างยิ่ง โดยเฉพาะสำหรับหน่วยงานกำกับดูแล สถาบันการเงิน นักลงทุน และผู้บริหารกิจการ

ข้อมูลทางการเงินถือเป็นแหล่งข้อมูลสำคัญที่สะท้อนถึงสถานะทางการเงิน และผลการดำเนินงานของกิจการในแต่ละช่วงเวลา ตัวชี้วัดทางการเงิน เช่น อัตราส่วนสภาพคล่อง อัตราส่วนหนี้สินต่อทุน และอัตรากำไรสุทธิ สามารถใช้เป็นเครื่องมือในการประเมินความมั่นคงของกิจการได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม การวิเคราะห์ข้อมูลทางการเงินด้วยวิธีการแบบดั้งเดิมอาจไม่สามารถจับความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปรต่าง ๆ ได้อย่างครบถ้วน ซึ่งในบริบทของประเทศไทย การพัฒนาเครื่องมือพยากรณ์ความล้มเหลวทางการเงินได้ก้าวหน้าไปสู่การใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อรับมือกับความซับซ้อนของข้อมูล โดยได้มีการนำเสนอแนวทางการแก้ปัญหาความไม่สมดุลของข้อมูล (Imbalanced Data) [2] ซึ่งเป็นอุปสรรคสำคัญของการพยากรณ์ข้อมูลทางการเงินในไทย ผ่านการใช้เทคนิคการเรียนรู้ของเครื่องร่วมกับการจัดการข้อมูล ผลการศึกษาพบว่าวิธีดังกล่าวสามารถช่วยเพิ่มประสิทธิภาพในการทำนายได้อย่างมีนัยสำคัญ ซึ่ง

สอดคล้องกับความพยายามในการก้าวข้ามข้อจำกัดของแบบจำลองทางสถิติดั้งเดิมอย่าง Altman Z-Score ที่ก่อนหน้านี้ได้มีการศึกษาเปรียบเทียบกับข้อมูลบริษัทในตลาดหลักทรัพย์แห่งประเทศไทย [3] และพบว่าแบบจำลองดังกล่าวเริ่มมีข้อจำกัดเมื่อต้องเผชิญกับสภาพเศรษฐกิจปัจจุบันที่มีความผันผวนสูง การเปลี่ยนผ่านไปสู่การใช้เทคนิคขั้นสูงเหล่านี้จึงเป็นกุญแจสำคัญในการยกระดับความแม่นยำของระบบเตือนภัยล่วงหน้าสำหรับภาคธุรกิจไทย

จากเหตุผลข้างต้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทย โดยใช้ข้อมูลงบการเงินร่วมกับเทคนิคการเรียนรู้ของเครื่อง เพื่อสร้างเครื่องมือประเมินความเสี่ยงที่มีความแม่นยำและเชื่อถือได้ ซึ่งจะเป็นประโยชน์ในการสนับสนุนการตัดสินใจเชิงกลยุทธ์สำหรับผู้มีส่วนได้ส่วนเสียในระบบเศรษฐกิจ

1.2 วัตถุประสงค์ของการวิจัย

- 1.2.1 เพื่อสร้างแบบจำลองการพยากรณ์การเลิกกิจการของนิติบุคคล
- 1.2.2 เพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึมในการพยากรณ์การเลิกกิจการของนิติบุคคล
- 1.2.3 เพื่อนำเสนอข้อมูลการพยากรณ์การเลิกกิจการของนิติบุคคล

1.3 ขอบเขตของการวิจัย

1.3.1 ขอบเขตด้านข้อมูล

งานวิจัยนี้ใช้ข้อมูลทางการเงินของนิติบุคคลที่จดทะเบียนในประเทศไทย ซึ่งอ้างอิงจากข้อมูลงบการเงินที่ยื่นต่อกรมพัฒนาธุรกิจการค้า กระทรวงพาณิชย์ โดยกำหนดให้กลุ่มกิจการที่เลิกดำเนินกิจการในปี พ.ศ. 2567 เป็นกลุ่มเหตุการณ์ (Event) โดยนำข้อมูลงบการเงินย้อนหลัง 2 ปี ได้แก่ ปี พ.ศ. 2565 และปี พ.ศ. 2566 ของกิจการดังกล่าวมาใช้เป็นข้อมูลอิสระในการพัฒนาแบบจำลอง ขณะเดียวกัน กลุ่มกิจการที่ยังดำเนินกิจการอยู่จะใช้ข้อมูลงบการเงินในช่วงเวลาเดียวกัน เพื่อให้การเปรียบเทียบและการวิเคราะห์มีความสอดคล้องกัน สถานะของกิจการถูกจำแนกออกเป็น 2 กลุ่ม ได้แก่ “กิจการที่เลิกดำเนินกิจการ” และ “กิจการที่ยังดำเนินกิจการ” โดยกำหนดสถานะดังกล่าวเป็นตัวแปรตาม (Dependent Variable) สำหรับใช้ในการพัฒนาและประเมินประสิทธิภาพของแบบจำลองการทำนายการเลิกกิจการของธุรกิจ

1.3.2 อัลกอริทึมที่ใช้ในการทำวิจัย ประกอบไปด้วย 4 อัลกอริทึม ได้แก่ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) อัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (Light Gradient Boosting Machine: LightGBM) อัลกอริทึมการเรียนรู้เชิงลึก (Deep

Neural Network: DNN) และเทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning) ทำงานร่วมกัน ด้วยวิธีการลงเสียงข้างมาก (Ensemble Voting)

1.3.3 การประเมินประสิทธิภาพแบบจำลองสำหรับการวิเคราะห์การเลิกกิจการของ นิติบุคคล

1.3.3.1 ค่าความถูกต้อง (Accuracy)

1.3.3.2 ค่าความแม่นยำ (Precision)

1.3.3.3 ค่าระลึก (Recall)

1.3.3.4 ค่าการถ่วงดุล (F1-Score)

1.3.4 นำเสนอผลการพยากรณ์การเลิกกิจการของนิติบุคคลด้วยการแสดงผลผ่านเว็บ แอปพลิเคชัน

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 ได้แบบจำลอง (Model) ที่เหมาะสมสำหรับการพยากรณ์การเลิกกิจการของนิติบุคคล

1.4.2 เพื่อเปรียบเทียบประสิทธิภาพความถูกต้องของอัลกอริทึมสำหรับการพยากรณ์การเลิก กิจการของนิติบุคคล

1.4.3 สามารถนำผลการพยากรณ์การเลิกกิจการของนิติบุคคล เพื่อเป็นแนวทางประกอบการ ตัดสินใจให้กับผู้มีส่วนได้ส่วนเสีย

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การดำเนินงานวิจัยการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้ศึกษาหลักการ ทฤษฎี และงานวิจัยที่เกี่ยวข้องเพื่อเป็นพื้นฐานสำหรับวิเคราะห์ความคิดเห็น ดังนี้

- 2.1 แนวคิดและทฤษฎีเกี่ยวกับความล้มเหลวทางการเงิน (Financial Distress)
- 2.2 เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Techniques)
- 2.3 อัลกอริทึมสำหรับการพยากรณ์
 - 2.3.1 อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)
 - 2.3.2 อัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (Light Gradient Boosting Machine: LightGBM)
 - 2.3.3 อัลกอริทึมการเรียนรู้เชิงลึก (Deep Neural Network: DNN)
 - 2.3.4 เทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning)
- 2.4 งานวิจัยที่เกี่ยวข้อง

2.1 แนวคิดและทฤษฎีเกี่ยวกับความล้มเหลวทางการเงิน (Financial Distress)

ในการศึกษาเกี่ยวกับการพยากรณ์การเลิกกิจการ จำเป็นต้องทำความเข้าใจถึงรากฐานของความล้มเหลวทางการเงิน ซึ่งเป็นสัญญาณเตือนก่อนที่นิติบุคคลจะเข้าสู่กระบวนการเลิกกิจการหรือล้มละลายทางกฎหมาย

2.1.1 นิยามของความล้มเหลวทางการเงินและการเลิกกิจการ

ความล้มเหลวทางการเงิน (Financial Distress) หมายถึง สภาวะที่กิจการประสบปัญหาขาดสภาพคล่อง ไม่สามารถสร้างกระแสเงินสดจากการดำเนินงานได้เพียงพอต่อการชำระหนี้สินเมื่อถึงกำหนด ซึ่งมักสะท้อนผ่านงบการเงินในรูปของการขาดทุนสะสมต่อเนื่อง หรือมีสัดส่วนหนี้สินที่สูงเกินกว่าเกณฑ์ปกติ โดยหากกิจการไม่สามารถปรับโครงสร้างหรือแก้ไขสภาวะดังกล่าวได้ทันท่วงที จะนำไปสู่ผลลัพธ์ในขั้นสุดท้ายคือ "การเลิกกิจการ" (Business Dissolution) ซึ่งในบริบทของประเทศไทย การเลิกกิจการของนิติบุคคลจะครอบคลุมตั้งแต่การที่นายทะเบียนรับจดทะเบียนเลิกกิจการ การถูกขีดชื่อออกจากทะเบียนของกรมพัฒนาธุรกิจการค้า (DBGD) ไปจนถึงการที่กิจการถูกศาลสั่งพิทักษ์ทรัพย์เด็ดขาดและต้องเข้าสู่กระบวนการตามกฎหมายล้มละลาย [3]

2.1.2 วิวัฒนาการของแบบจำลองการพยากรณ์ความล้มเหลวทางการเงิน

วิวัฒนาการของการพยากรณ์ความล้มเหลวทางการเงินเริ่มต้นจากการใช้แบบจำลองทางสถิติ (Statistical Models) โดยอาศัยอัตราส่วนทางการเงินจากงบการเงินเป็นตัวแปรหลัก แบบจำลองที่เป็นรากฐานสำคัญระดับสากล คือแบบจำลอง Altman Z-Score [4] ซึ่งใช้เทคนิคการวิเคราะห์จำแนกประเภทหลายตัวแปร (Multiple Discriminant Analysis: MDA) ในการสร้างสมการเชิงเส้นเพื่อจำแนกกลุ่มบริษัทที่มีความเสี่ยงต่อการล้มละลายออกจากบริษัทที่แข็งแกร่ง ต่อมา แบบจำลอง Ohlson O-Score [5] ได้ถูกพัฒนาขึ้นเพื่อลดข้อจำกัดของ Z-Score โดยประยุกต์ใช้เทคนิคสมการถดถอยโลจิสติก (Logistic Regression) ซึ่งมีจุดเด่น คือสามารถแสดงผลลัพธ์ออกมาในรูปของ "ความน่าจะเป็น" (Probability) ตั้งแต่ 0 ถึง 1 ทำให้ง่ายต่อการตีความ นอกจากนี้ยังมี แบบจำลอง Zmijewski X-Score [6] ที่นำเทคนิค Probit Analysis มาใช้ โดยมุ่งเน้นกลุ่มตัวแปรทางการเงินเพียง 3 ด้านหลัก ได้แก่ อัตราผลตอบแทนต่อสินทรัพย์ (ROA) สัดส่วนหนี้สิน และอัตราส่วนสภาพคล่อง อย่างไรก็ตาม แม้แบบจำลองทางสถิติดั้งเดิมเหล่านี้จะได้รับการยอมรับอย่างกว้างขวาง แต่ล้วนมีข้อจำกัดสำคัญ คือการยึดติดกับ "ข้อสมมติฐานทางสถิติที่เข้มงวด" (เช่น ข้อมูลต้องมีการแจกแจงแบบปกติ) และมักสูญเสียความแม่นยำเมื่อต้องเผชิญกับชุดข้อมูลทางการเงินในยุคปัจจุบันที่มีความซับซ้อน มีมิติข้อมูลขนาดใหญ่ และมีความสัมพันธ์แบบไม่เป็นเส้นตรง (Non-linear) ซึ่งช่องว่างทางวิจัยนี้เองที่เป็นปัจจัยผลักดันให้นักวิจัยในยุคปัจจุบันหันมาประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ที่มีความยืดหยุ่นและให้ประสิทธิภาพสูงกว่ามาใช้ในการพยากรณ์แทน [4,5]

2.2 เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Techniques)

การเรียนรู้ของเครื่อง (Machine Learning: ML) เป็นแขนงหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่มุ่งเน้นการสร้างระบบคอมพิวเตอร์ให้สามารถ "เรียนรู้" และ "ปรับปรุง" ประสิทธิภาพการทำงานได้ด้วยตนเองจากข้อมูล (Data) โดยไม่จำเป็นต้องถูกเขียนโปรแกรมสั่งการไว้อย่างเฉพาะเจาะจงในทุกขั้นตอน (Explicitly Programmed) ซึ่งแตกต่างจากแบบจำลองทางสถิติดั้งเดิมที่ผู้วิจัยต้องเป็นผู้กำหนดสมการหรือความสัมพันธ์ของตัวแปรไว้ล่วงหน้า หลักการสำคัญของ Machine Learning คือการป้อนข้อมูลในอดีต (Historical Data) เข้าสู่ระบบ เพื่อให้อัลกอริทึมทำการค้นหารูปแบบ (Patterns) ความสัมพันธ์ที่ซ่อนอยู่ และสร้างเป็น "แบบจำลอง (Model)" ขึ้นมาสำหรับนำไปใช้ตัดสินใจหรือพยากรณ์ผลลัพธ์ของข้อมูลชุดใหม่ในอนาคต

ในการวิจัยทางการเงินและการพยากรณ์การเลิกกิจการ ปัญหาหลักที่มักพบ คือชุดข้อมูลอัตราส่วนทางการเงินมักมีความซับซ้อน มีมิติของข้อมูลขนาดใหญ่ (High-dimensional Data) และตัวแปรต่าง ๆ มักมีความสัมพันธ์กันแบบไม่เป็นเส้นตรง (Non-linear Relationship) ซึ่งละเมิดข้อตกลงเบื้องต้นของสถิติดั้งเดิม การประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องจึงเข้ามาช่วย


อุดช่องโหว่ดังกล่าว เนื่องจากอัลกอริทึมมีความยืดหยุ่นสูง สามารถจัดการกับข้อมูลที่มีความแปรปรวนหรือข้อมูลที่สูญหาย (Missing Values) ได้ดีกว่า นอกจากนี้ งานวิจัยที่เกี่ยวข้องกับการพยากรณ์สถานะทางการเงิน มักจัดอยู่ในกลุ่มปัญหา การเรียนรู้แบบมีผู้สอน (Supervised Learning) ในลักษณะของการจำแนกประเภท (Classification) ซึ่งเป็นการให้คอมพิวเตอร์เรียนรู้จากชุดข้อมูลที่มีการระบุผลลัพธ์หรือ "คำตอบ (Label)" ไว้แล้วอย่างชัดเจน (เช่น ระบุว่านิติบุคคลนี้ "ดำเนินกิจการอยู่" หรือ "เลิกกิจการ") เพื่อให้แบบจำลองสามารถพยากรณ์สถานะของนิติบุคคลอื่นในอนาคตได้อย่างแม่นยำ [7]

2.3 อัลกอริทึมสำหรับการพยากรณ์

2.3.1 อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน เป็นเทคนิคการเรียนรู้แบบมีผู้สอน (Supervised Learning) ที่ได้รับการยอมรับอย่างกว้างขวางว่ามีประสิทธิภาพสูงในการจัดการกับปัญหาการจำแนกประเภทข้อมูล (Classification) โดยเฉพาะอย่างยิ่งการจำแนกประเภทแบบสองกลุ่ม (Binary Classification) ซึ่งสอดคล้องกับงานวิจัยนี้ที่ต้องการแยกกลุ่มนิติบุคคลที่ "ดำเนินกิจการอยู่" ออกจากกลุ่มที่ "เลิกกิจการ"

หลักการทำงานพื้นฐานของ SVM คือการสร้างหรือค้นหา ระนาบเกิน (Hyperplane) ในปริภูมิที่มีหลายมิติ (N-dimensional Space) ที่สามารถแบ่งแยกข้อมูลทั้งสองกลุ่มออกจากกันได้ดีที่สุด โดยระนาบที่ดีที่สุดนั้น คือระนาบที่สร้าง "ระยะขอบ (Margin)" หรือระยะห่างระหว่างระนาบกับจุดข้อมูลที่อยู่ใกล้ที่สุดของแต่ละกลุ่มให้มีค่ากว้างที่สุด จุดข้อมูลที่อยู่ใกล้กับระนาบนี้มากที่สุด และมีผลโดยตรงต่อการกำหนดตำแหน่งและทิศทางของระนาบจะถูกเรียกว่า "ซัพพอร์ตเวกเตอร์ (Support Vectors)" แสดงดังภาพที่ 2-1



ภาพที่ 2-1 การค้นหา ไฮเปอร์เพลน (Hyperplane) ที่ดีที่สุด
ที่มา : Using Support Vector Machines for Survey Research [8]

ในบริบทของการวิเคราะห์ข้อมูลทางการเงิน ซึ่งตัวแปรอัตราส่วนทางการเงินต่างๆ มักมีความสัมพันธ์ที่ซับซ้อนและไม่สามารถแบ่งแยกด้วยเส้นตรงหรือระนาบเชิงเส้นได้ (Non-linearly Separable) จุดเด่นที่สำคัญที่สุดของ SVM คือการประยุกต์ใช้เทคนิคที่เรียกว่า "เคอร์เนลทริก (Kernel Trick)" เทคนิคนี้จะทำการแปลงรูปข้อมูล (Map) จากมิติเดิมให้ไปสู่มิติที่สูงขึ้น เพื่อให้สามารถค้นหาระนาบเกินที่แบ่งแยกข้อมูลได้ชัดเจนยิ่งขึ้น โดยเคอร์เนลฟังก์ชันที่ได้รับความนิยมในงานวิจัยด้านการพยากรณ์ความล้มเหลวทางการเงิน ได้แก่ Radial Basis Function (RBF) และ Polynomial Kernel นอกจากนี้ ยังมีข้อได้เปรียบสำคัญของ SVM คือเป็นเทคนิคที่มีประสิทธิภาพโดดเด่นในการแก้ปัญหาการจำแนกประเภทแบบทวิภาค (Binary Classification) โดยเฉพาะอย่างยิ่งความสามารถในการจัดการกับชุดข้อมูลที่มีตัวแปรอิสระจำนวนมาก (High-dimensional Predictors) ได้เป็นอย่างดี แม้ว่าชุดข้อมูลนั้นจะมีจำนวนตัวอย่างที่จำกัด ซึ่งช่วยให้อัลกอริทึมมีความทนทานต่อข้อมูลที่มีความคลาดเคลื่อน (Robustness to Noise) และลดปัญหาการเรียนรู้ที่จำเพาะกับชุดข้อมูลฝึกสอนมากเกินไป (Overfitting) ได้อย่างมีประสิทธิภาพ [8]


2.3.2 อัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (Light Gradient Boosting Machine: LightGBM)

เป็นเทคนิคการเรียนรู้ของเครื่องในกลุ่มแกรเดียนท์บูสติง (Gradient Boosting Framework) ซึ่งมีรากฐานมาจากการทำงานร่วมกันของต้นไม้ตัดสินใจ (Decision Tree) แบบเอนเซมเบิล (Ensemble Learning) อัลกอริทึมนี้ถูกออกแบบมาเพื่อแก้ปัญหาข้อจำกัดด้านความเร็วและหน่วยความจำของเทคนิคบูสติงแบบดั้งเดิม ทำให้เหมาะสมอย่างยิ่งสำหรับการวิเคราะห์ชุดข้อมูลขนาดใหญ่ (Large-scale Data) ที่มีตัวแปรหรือมิติของข้อมูลจำนวนมาก เช่น ข้อมูลอัตราส่วนทางการเงินจากงบการเงินของนิติบุคคล

จุดเด่นที่สำคัญที่สุดของ LightGBM ซึ่งแตกต่างจากอัลกอริทึมต้นไม้ตัดสินใจทั่วไปหรือ XGBoost คือ การใช้กลยุทธ์ การขยายกิ่งแบบมุ่งเน้นใบ (Leaf-wise Tree Growth) แทนการขยายกิ่งแบบระดับชั้น (Level-wise) ซึ่งช่วยลดค่าความคลาดเคลื่อนได้ลึกกว่าและเพิ่มความแม่นยำให้กับแบบจำลองได้ดีกว่าภายใต้ข้อจำกัดของจำนวนโหนดที่เท่ากัน นอกจากนี้ LightGBM ยังประยุกต์ใช้เทคนิคเชิงนวัตกรรมสองประการ ได้แก่ 1) Gradient-based One-Side Sampling (GOSS) ที่ช่วยลดจำนวนข้อมูลที่ใช้ในการคำนวณลงโดยเลือกพิจารณาเฉพาะกลุ่มข้อมูลที่มีความคลาดเคลื่อนสูง (Large Gradients) และ 2) Exclusive Feature Bundling (EFB) ที่ช่วยรวบรวมตัวแปรที่ไม่ซ้อนทับกันเข้าด้วยกันเพื่อลดมิติของข้อมูล [9] ผลลัพธ์ที่ได้ คือ อัลกอริทึมที่มีความรวดเร็วในการฝึกสอน (Training Speed) สูงมาก ใช้ทรัพยากรเครื่องน้อย และมีความทนทานต่อข้อมูลที่ขาดหาย (Missing Values) ซึ่งเป็นธรรมชาติของข้อมูลงบการเงินได้อย่างมีประสิทธิภาพ จึงทำให้ LightGBM กลายเป็นหนึ่งในอัลกอริทึมที่ได้รับความนิยมและให้ผลลัพธ์ระดับ State-of-the-art ในงานวิจัยด้านการพยากรณ์ความล้มเหลวทางการเงินในยุคปัจจุบัน [10]

2.3.3 อัลกอริทึมการเรียนรู้เชิงลึก (Deep Neural Network: DNN)

อัลกอริทึมการเรียนรู้เชิงลึก เป็นสถาปัตยกรรมขั้นสูงของโครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) ที่ถูกออกแบบมาเพื่อจำลองกระบวนการเรียนรู้และประมวลผลของระบบประสาทในสมองมนุษย์ โครงสร้างพื้นฐานของ DNN ประกอบด้วยชั้นของโหนดประมวลผล (Nodes หรือ Neurons) จำนวนหลายชั้นเรียงซ้อนกัน แสดงดังภาพที่ 2-2 ซึ่งประกอบด้วยชั้นรับข้อมูลเข้า (Input Layer) ที่ในบริบทของงานวิจัยนี้คือตัวแปรอัตราส่วนทางการเงินต่างๆ ชั้นซ่อน (Hidden Layers) จำนวนหลายชั้น (ซึ่งเป็นที่มาของคำว่า "เชิงลึก" หรือ Deep) ที่ทำหน้าที่สกัดคุณลักษณะ (Feature Extraction) และค้นหารูปแบบความสัมพันธ์ และสุดท้ายคือชั้นส่งออกข้อมูล (Output Layer) ที่แสดงผลลัพธ์ความน่าจะเป็นของสถานะนิติบุคคล เช่น ดำเนินกิจการอยู่ หรือ เลิกกิจการ



ภาพที่ 2-2 การสร้างแบบจำลองโครงข่ายประสาทเทียมเชิงลึก (DNN)

กลไกสำคัญของอัลกอริทึมนี้ คือ ความสามารถในการเรียนรู้ความสัมพันธ์แบบไม่เป็นเส้นตรง (Non-linear Relationships) ระดับสูง และสามารถจัดการกับข้อมูลที่มีปฏิสัมพันธ์ระหว่างตัวแปรทางการเงิน (Feature Interactions) ที่ซับซ้อนได้อย่างอัตโนมัติ ผ่านกระบวนการปรับปรุงค่าน้ำหนัก (Weights) และค่าความเอนเอียง (Biases) ซ้ำๆ ด้วยอัลกอริทึมการแพร่ย้อนกลับ (Backpropagation) เพื่อลดค่าความคลาดเคลื่อนให้เหลือน้อยที่สุด [11] อย่างไรก็ตาม แม้ว่า DNN จะมีศักยภาพในการให้ความแม่นยำที่สูงมาก แต่ก็มีบทบาทสำคัญในการนำมาใช้งานในสายการเงินและการประเมินความเสี่ยง ได้แก่ ลักษณะการทำงานที่เป็น "กล่องดำ (Black-box)" ซึ่งหมายความว่าผู้วิจัยไม่สามารถอธิบายเหตุผลเบื้องหลังหรือน้ำหนักความสำคัญของแต่ละตัวแปรที่นำไปสู่ผลลัพธ์การตัดสินใจ (Interpretability) ได้อย่างชัดเจนเหมือนกับโมเดลกลุ่มต้นไม้ตัดสินใจ นอกจากนี้ DNN ยังต้องการชุดข้อมูลขนาดใหญ่ในการฝึกสอนเพื่อป้องกันปัญหาการจำข้อมูลมากเกินไป (Overfitting) รวมทั้งใช้ทรัพยากรและระยะเวลาในการประมวลผลที่ค่อนข้างสูง

2.3.4 เทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning)

เทคนิคการเรียนรู้แบบกลุ่ม เป็นกระบวนทัศน์ (Paradigm) ทางการเรียนรู้ของเครื่องที่ไม่ได้พึ่งพาการประมวลผลจากแบบจำลองเพียงตัวเดียว แต่ใช้หลักการสร้างและผสมผสานแบบจำลองย่อย (Base Learners หรือ Weak Learners) จำนวนหลายตัวเข้าด้วยกัน เพื่อนำผลลัพธ์ที่ได้จากแต่ละแบบจำลองมาผ่านกระบวนการรวบรวมคำตอบ เช่น การลงคะแนนเสียงข้างมาก (Majority Voting) สำหรับปัญหาการจำแนกประเภท หรือการหาค่าเฉลี่ย (Averaging) ในการตัดสินใจขั้นสุดท้าย

หลักการสำคัญของเทคนิคนี้ถูกออกแบบมาเพื่อแก้ไขข้อจำกัดของแบบจำลองเดี่ยว โดยมุ่งเน้นที่การลดความแปรปรวน (Variance) ลดความเอนเอียง (Bias) และเพิ่มความทนทานต่อ

ปัญหาการเรียนรู้ที่จำเพาะกับชุดข้อมูลฝึกสอนมากเกินไป (Overfitting) [12] สำหรับการประยุกต์ใช้ในการพยากรณ์การเลิกกิจการหรือความล้มเหลวทางการเงินนั้น ข้อมูลอัตราส่วนทางการเงินจากการเงินมักมีลักษณะที่ซับซ้อน มีจุดข้อมูลรบกวน (Noise) ข้อมูลสูญหาย (Missing Values) และมีปัญหาความไม่สมดุลของคลาสข้อมูล (Imbalanced Data) สูงมาก เทคนิคการเรียนรู้แบบกลุ่มจึงได้รับการพิสูจน์ผ่านงานวิจัยจำนวนมากว่า สามารถยกระดับความแม่นยำ (Accuracy) เสถียรภาพ (Stability) และประสิทธิภาพในการจำแนกประเภทนิติบุคคลที่มีความเสี่ยงได้อย่างมีนัยสำคัญ และมักให้ผลลัพธ์ที่เหนือกว่าการใช้อัลกอริทึมเดี่ยว (Single Classifiers) อย่างเห็นได้ชัด [13]

2.4 งานวิจัยที่เกี่ยวข้อง

ผู้วิจัยทำการศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง โดยศึกษาทฤษฎี กระบวนการ เอกสารทางวิชาการ และงานวิจัยที่เกี่ยวข้อง เพื่อนำมาประยุกต์ใช้ในการพัฒนาแบบจำลอง ดังนี้

ณิชา [14] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์ความเสี่ยงในการล้มละลายของบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ด้วยตัวชี้วัดทางบัญชี และตัวชี้วัด Systemic Risk โดยศึกษาความสัมพันธ์ของตัวชี้วัดทางบัญชี และตัวชี้วัด Systemic Risk ต่อความเสี่ยงในการล้มละลายของบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย และพัฒนาแบบจำลองที่สามารถพยากรณ์ความเสี่ยงในการล้มละลายของบริษัทจดทะเบียนฯ ซึ่งใช้เทคนิคการวิเคราะห์ความถดถอยโลจิสติก โดยใช้ข้อมูลบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย จำนวน 297 บริษัท ตั้งแต่ช่วงเวลาปี พ.ศ. 2535 ถึงปี พ.ศ. 2562 ผลการศึกษาพบว่า ตัวชี้วัด Systemic Risk และตัวชี้วัดทางบัญชีสามารถอธิบายการล้มละลายของบริษัทจดทะเบียนฯ ได้ โดยตัวแปรอิสระจากกลุ่มตัวชี้วัด 2 ด้าน สามารถนำมาพัฒนาเป็นแบบจำลองที่ใช้ในการพยากรณ์ความเสี่ยงในการล้มละลายของบริษัทจดทะเบียนฯ เพื่อใช้เป็นข้อมูลเบื้องต้นในการลงทุน รวมถึงผู้บริหารบริษัทสามารถนำข้อมูลมาใช้ในการตัดสินใจ หรือปรับกลยุทธ์และรับมือกับความเสี่ยงที่เกิดขึ้น และสามารถแก้ไขได้ทัน่วงทีก่อนที่จะประสบภาวะล้มละลาย

มัทนีย์ [15] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์ความล้มเหลวทางการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย เพื่อสร้างแบบจำลองสำหรับพยากรณ์ความล้มเหลวทางการเงินของบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ระหว่างปี พ.ศ. 2554-2564 จำนวน 506 บริษัท แบ่งเป็นกลุ่มบริษัทที่อยู่ในหมวดพื้นฟูกิจการจำนวน 34 บริษัท และกลุ่มบริษัทที่ไม่อยู่ในหมวดที่อยู่ระหว่างฟื้นการดำเนินงานจำนวน 472 บริษัท โดยใช้เทคนิคการวิเคราะห์ถดถอยโลจิสติก (Logistic Regression) ผลการศึกษา คือตัวแปรอิสระที่มีความสามารถในการพยากรณ์ความล้มเหลวทางการเงินของบริษัทในตลาดหลักทรัพย์แห่งประเทศไทย จากทั้งหมดจำนวน

19 ตัวแปร พบว่ามีเพียง 4 ตัวแปรที่สามารถระบุได้อย่างมีนัยสำคัญ ได้แก่ อัตราส่วนทุนหมุนเวียนต่อสินทรัพย์รวม อัตราส่วนเงินสดต่อสินทรัพย์รวม อัตราส่วนการหมุนเวียนของสินทรัพย์ และอัตราส่วนหนี้สินต่อส่วนของผู้ถือหุ้น และเมื่อนำแบบจำลองมาทดสอบประสิทธิภาพในการพยากรณ์โอกาสที่บริษัทจะประสบภาวะล้มเหลวทางการเงิน พบว่า แบบจำลองสามารถทำนายโอกาสที่บริษัทจะประสบภาวะความล้มเหลวทางการเงินโดยรวมได้ถูกต้องถึงร้อยละ 90.67

พิรุณพร [16] ได้ทำการศึกษาวิจัย เรื่อง การสร้างแบบจำลองในการพยากรณ์ผลการดำเนินงานจากข้อมูลในงบการเงินของบริษัทในตลาดหลักทรัพย์กรณีศึกษา กลุ่มอุตสาหกรรมเกษตรและกลุ่มอุตสาหกรรมอาหาร เพื่อสร้างแบบจำลองสำหรับพยากรณ์ผลการดำเนินงานของธุรกิจโดยการศึกษาเปรียบเทียบสภาพคล่อง ฐานะทางการเงิน และปัจจัยด้านการบริหาร ของบริษัทฯ โดยใช้เทคนิคการทำเหมืองข้อมูล (Data Mining) และเปรียบเทียบวิธีการสร้างแบบจำลองด้วยวิธีต่าง ๆ ข้อมูลที่นำมาใช้ในการศึกษาเป็นข้อมูลของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย กลุ่มอุตสาหกรรมเกษตร และกลุ่มอุตสาหกรรมอาหารตั้งแต่ปี พ.ศ. 2542 – 2561 จากการศึกษาพบว่าวิธีที่ดีที่สุด ที่ใช้ในการสร้างแบบจำลองเพื่อพยากรณ์ผลการดำเนินงานของกิจการ ได้แก่ วิธี Deep Learning เมื่อนำข้อมูลชุดทดสอบมาทดสอบในแบบจำลองที่สร้างโดยวิธี Deep Learning พบว่าผลการทดสอบ มีความแม่นยำร้อยละ 94.7 อย่างไรก็ตามแบบจำลองอาจไม่สามารถใช้ในการพยากรณ์ได้กับอุตสาหกรรมอื่นที่มีรูปแบบการดำเนินงานที่แตกต่างกัน

อรุณา [17] ได้ทำการศึกษาวิจัย เรื่อง แบบจำลองการพยากรณ์ภาวะล้มละลายของวิสาหกิจขนาดกลาง และขนาดย่อมในประเทศไทย เพื่อพัฒนาแบบจำลองโดยใช้ข้อมูลของวิสาหกิจขนาดกลางและขนาดย่อม ที่มีภาวะล้มละลาย และไม่ล้มละลาย ที่เข้าลักษณะตามนิยามของวิสาหกิจขนาดกลาง และขนาดย่อม พ.ศ.2562 โดยใช้ข้อมูลทั้งหมด 3 ปี ตั้งแต่ปี พ.ศ. 2560 ถึง พ.ศ. 2562 มีจำนวน ตัวอย่างทั้งหมดจำนวน 96 บริษัทประกอบด้วยกิจการที่ล้มละลาย 48 บริษัท และกิจการที่ไม่ล้มละลาย 48 บริษัท ผลการศึกษาพบว่าตัวแปรสำคัญที่สามารถพยากรณ์ภาวะล้มละลายล่วงหน้า 1 ปีก่อนกิจการจะล้มละลายได้อย่างมีนัยสำคัญ คืออัตราการหมุนของสินทรัพย์ถาวร อัตรากำไรจากการดำเนินงาน อัตราผลตอบแทนผู้ถือหุ้น และอายุของกิจการ ความแม่นยำในการพยากรณ์เท่ากับ 77.08%

สกุลกาญจน์ และนุรีย์ [18] ได้ทำการศึกษาวิจัย เรื่อง การเรียนรู้ของเครื่องเพื่อการทำนายการผิดนัดชำระของลูกหนี้บัตรเครดิต ด้วยข้อมูลรายการธุรกรรมทั้งหมด 1,048,575 แถว และข้อมูลลูกค้า จำนวน 438,557 แถว โดยสร้างแบบจำลองเพื่อแบ่งกลุ่มลูกค้าที่มีความสามารถในการชำระหนี้บัตรเครดิต เป็น 2 ประเภท คือกลุ่มลูกค้าปกติ และกลุ่มลูกค้าผิดนัดชำระ โดยใช้การเรียนรู้ของเครื่อง แบบมีผู้สอน (Supervised Learning) ประเภท Classification ประกอบด้วยอัลกอริทึม 3 วิธี ได้แก่ Logistic Regression, Random Forest และ Catboost เพื่อหาแบบจำลองที่มีประสิทธิภาพ

มากที่สุดในการจัดกลุ่มลูกหนี้ ผลการศึกษาพบว่าโมเดล XGBoost ให้ค่าความถูกต้อง (Accuracy) สูงสุดที่ 98% เมื่อใช้จำนวนต้นไม้ เท่ากับ 15 และอัตราการเรียนรู้ที่ 0.1 ขณะที่โมเดล CatBoost ให้ค่าความถูกต้องรองลงมาที่ 97% โดยใช้จำนวนต้นไม้เพียง 7 ต้น ภายใต้ค่าอัตราการเรียนรู้เดียวกัน ส่วนโมเดล Logistic Regression ซึ่งเป็นโมเดลเชิงเส้นแบบพื้นฐาน ให้ค่าความถูกต้องเพียง 62% แสดงให้เห็นถึงข้อจำกัดในการจัดการกับข้อมูลที่มีความซับซ้อนสูง

ชญาณิช ขจิตพรณ และรัชกฤษ [19] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์การเกิดพายุฝนฟ้าคะนองระยะปัจจุบัน ด้วยเทคนิคการเรียนรู้ของเครื่องกรณีศึกษาสนามบินภาคเหนือของประเทศไทย เพื่อพัฒนาแบบจำลองการพยากรณ์การเกิดพายุฝนฟ้าคะนองระยะปัจจุบัน และประเมินประสิทธิภาพของแบบจำลองดังกล่าวในการพยากรณ์ล่วงหน้า 1 และ 2 ชั่วโมง สำหรับสนามบินในพื้นที่ภาคเหนือของประเทศไทย ข้อมูลที่ใช้ในการวิจัยประกอบด้วยข่าวอากาศการบินรายชั่วโมงจากสนามบิน 9 แห่งในภาคเหนือ ซึ่งจัดเก็บโดยกรมอุตุนิยมวิทยา ระหว่างปี พ.ศ. 2558 ถึง 2565 รวมทั้งสิ้น 364,382 ชุดข้อมูล โดยสร้างแบบจำลองการพยากรณ์ ด้วยอัลกอริทึมมาตรฐาน เช่น Naive Bayes, Decision Tree และ Neural Networks รวมถึงอัลกอริทึมแบบกลุ่ม (Ensemble Learning) ได้แก่ Bagging, AdaBoost และ Random Forest พร้อมทั้งปรับสมดุลของข้อมูลด้วยเทคนิค SMOTE (Synthetic Minority Over-sampling Technique) และประเมินผลด้วยวิธี 10-Fold Cross Validation ผลการวิจัยพบว่า สำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง แบบจำลองที่ให้ผลลัพธ์ดีที่สุด คือ Random Forest โดยมีค่า F-measure เท่ากับ 76.45% และค่า AUC เท่ากับ 0.888 ส่วนการพยากรณ์ล่วงหน้า 2 ชั่วโมง แบบจำลองที่มีประสิทธิภาพสูงสุด คือ Neural Networks ร่วมกับ Bagging โดยมีค่า F-measure เท่ากับ 30.62% และค่า AUC เท่ากับ 0.746 ผลลัพธ์เหล่านี้สะท้อนให้เห็นถึงศักยภาพของเทคนิคการเรียนรู้ของเครื่องในการพยากรณ์พายุฝนฟ้าคะนองในบริบทของข้อมูลจริงจากสนามบินในประเทศไทย

ปภากร และอนิรุทธิ์ [20] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์ยอดขายไก่เนื้อด้วยเทคนิคการเรียนรู้ของเครื่อง กรณีศึกษาผู้ประกอบการรายย่อยใน อำเภอหล่มสัก จังหวัดเพชรบูรณ์ โดยการรวบรวมข้อมูลยอดขายไก่เนื้อ ตั้งแต่เดือนพฤษภาคม พ.ศ.2566 ถึง เดือนกุมภาพันธ์ พ.ศ. 2567 จากผู้ประกอบการรายย่อยธุรกิจไก่เนื้อในอำเภอหล่มสัก จังหวัดเพชรบูรณ์ และนำมาพัฒนาโมเดลด้วยเทคนิคการเรียนรู้ด้วยเครื่องประกอบด้วย 3 อัลกอริทึม ได้แก่ เทคนิคโครงข่ายประสาทเทียม (Neural Network) เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines) และ เทคนิคป่าสุ่ม (Random Forest) และพัฒนาโมเดลด้วยเทคนิคอนุกรมเวลา 2 เทคนิค ได้แก่ เทคนิค Holt-Winters Exponential Smoothing และ เทคนิค Auto Regressive Integrated Moving Average (ARIMA) จากนั้นทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง ผลการวิจัยพบว่าเทคนิคที่ดีที่สุดของเทคนิคการเรียนรู้ของเครื่อง คือ เทคนิคป่าสุ่ม (Random Forest) ซึ่งให้ค่าอัตราการ

พยากรณ์ผิดพลาด (Error rate) น้อยที่สุด และผลการวิจัยพบว่าเทคนิคที่ดีที่สุดของเทคนิคอนุกรมเวลา คือเทคนิค ARIMA ซึ่งให้ค่าอัตราการพยากรณ์ผิดพลาด (Error rate) น้อยที่สุด

โชติมา [21] ได้ทำการศึกษาวิจัย เรื่อง การพัฒนาแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องเพื่อพยากรณ์พื้นที่ในประเทศไทยที่มีความเสี่ยงได้รับผลกระทบจากการเกิดดินโคลนถล่ม เพื่อหาตัวแปรหรือปัจจัยที่มีความสำคัญ และเหมาะสมสำหรับการพยากรณ์พื้นที่ที่มีความเสี่ยงที่จะได้รับผลกระทบจากการเกิดดินโคลนถล่ม โดยในการพัฒนาแบบจำลองนั้นเทคนิคการเรียนรู้ของเครื่องมาประยุกต์ใช้ และพัฒนาเครื่องมือที่แสดงข้อมูลพื้นที่ที่มีความเสี่ยง ผู้วิจัยใช้เทคนิคไคสแควร์ (Chi-Square) ในการคัดเลือกคุณลักษณะของข้อมูลเพื่อให้การพัฒนาแบบจำลองได้ผลลัพธ์มีประสิทธิภาพได้ตัวแปรทั้งหมด 27 ตัวแปร ที่มีค่าน้ำหนักมากกว่าหรือเท่ากับ 10 ซึ่งผลจากการประเมินแบบจำลองให้ค่า Recall อยู่ที่ 70.97% และ Accuracy อยู่ที่ 64.70%

นันทุฒิ ศรันย์ และเดชรัฐสินป์ [22] ได้ทำการศึกษาวิจัย เรื่อง การพัฒนาโมเดลพยากรณ์สำหรับปริมาณการรับส่งข้อมูลอินเทอร์เน็ตโดยใช้เทคนิคโครงข่ายประสาทเทียม โดยผู้วิจัยใช้ข้อมูลปริมาณการรับส่งข้อมูลอินเทอร์เน็ตจากบริษัทโทรคมนาคมแห่งชาติ จำกัด (มหาชน) ระหว่างเดือนมกราคม ถึง ธันวาคม พ.ศ. 2564 รวมทั้งสิ้น 12 ชุดข้อมูล ซึ่งแบ่งออกเป็นชุดฝึกสอน และชุดทดสอบ ในอัตราส่วน 70:30 สำหรับการสร้างโมเดลใช้โครงข่ายประสาทเทียมแบบเพอร์เซ็ปตรอนหลายชั้น (Multilayer Perceptron) ที่มีการแพร่แบบย้อนกลับ (Backpropagation) โดยใช้อัลกอริธึม Levenberg-Marquardt ในการปรับค่าน้ำหนัก และไบแอส พร้อมทั้งทดลองจำนวนโหนดในชั้นซ่อนที่แตกต่างกันเพื่อหาค่าที่เหมาะสมที่สุด ผลการวิจัยพบว่า โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเป็นรูปแบบที่เหมาะสมสำหรับการพยากรณ์ปริมาณการรับส่งข้อมูลอินเทอร์เน็ต โดยโมเดลที่มีจำนวนโหนดในชั้นซ่อนเท่ากับ 2 เท่าของจำนวนข้อมูลนำเข้า ($2n$) ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่าเฉลี่ยร้อยละความผิดพลาดสัมบูรณ์ (MAPE) ต่ำที่สุดที่ 3.01% เมื่อเปรียบเทียบกับโมเดลแบบ $1n$, $3n$, $4n$ และ $5n$ ซึ่งมีค่า MAPE เท่ากับ 3.59%, 4.02%, 4.08% และ 5.95% ตามลำดับ

Zhao, Ouenniche, and Smedt [23] ได้ทำการศึกษาวิจัย เรื่อง A Complex Network Analysis Approach to Bankruptcy Prediction Using Company Relational Information-Based Drivers โดยงานวิจัยนี้นำเสนอแนวทางใหม่ในการพยากรณ์การล้มละลายของกิจการ โดยประยุกต์ใช้การวิเคราะห์โครงข่ายเชิงซ้อน (Complex Network Analysis) แทนการใช้เฉพาะตัวชี้วัดทางการเงินหรือการเรียนรู้ด้วยเครื่องแบบดั้งเดิม ผู้วิจัยได้จำลองหาความสัมพันธ์ระหว่างบริษัทต่าง ๆ ให้อยู่ในรูปแบบเครือข่าย โดยให้แต่ละบริษัทเป็นโหนด และเชื่อมโยงกันผ่านความสัมพันธ์ด้านการเงิน จากการวิเคราะห์โครงสร้างของเครือข่าย เช่น ค่า Centrality และการตรวจจับกลุ่มในเครือข่าย พบว่าตัวชี้วัดจากโครงข่ายสามารถสะท้อนความเสี่ยงในการล้มละลายได้อย่างมีนัยสำคัญ ผลการทดลองชี้ว่าเมื่อรวมตัวชี้วัดจากเครือข่ายเข้ากับโมเดลดั้งเดิม จะช่วยเพิ่มความ

แม่นยำในการพยากรณ์อย่างชัดเจน งานวิจัยนี้จึงมีศักยภาพในการประยุกต์ใช้จริงทั้งในภาคการเงินและเชิงนโยบาย

Zhao, Y. et al. [24] ได้ทำการศึกษาวิจัย เรื่อง Combining Intra-Risk and Contagion Risk for Enterprise Bankruptcy Prediction Using Graph Neural Networks ผู้วิจัยนำเสนอวิธีการใหม่ในการพยากรณ์ความเสี่ยงการล้มละลายของธุรกิจขนาดกลาง และขนาดย่อม (SMEs) โดยใช้การวิเคราะห์ความเสี่ยงภายในองค์กร (Intra-Risk) ร่วมกับความเสี่ยงลุกลามจากกิจการที่เกี่ยวข้องกัน (Contagion Risk) ผ่านโมเดล Graph Neural Networks (GNNs) ในโครงข่ายความรู้ของกิจการ (Enterprise Knowledge Graph) โดยออกแบบระบบที่มี 2 ส่วนหลัก ได้แก่ ตัวเข้ารหัสความเสี่ยงภายในองค์กร โดยใช้ข้อมูลทางธุรกิจพื้นฐาน และประวัติคดีความ และระบบวิเคราะห์ผลกระทบจากบริษัทที่เกี่ยวข้อง โดยใช้ทั้งโครงข่ายไฮเปอร์กราฟ (Hyper-GNNs) และโครงข่ายกราฟแบบเฮเทอโรจีเนียส (Heter-GNNs) เพื่อเรียนรู้ผลกระทบจากความสัมพันธ์ต่าง ๆ เช่น อุตสาหกรรมเดียวกัน หรือมีผู้มีส่วนได้เสียร่วมกัน จากนั้นสร้างโมเดลแบบรวมที่สามารถคาดการณ์การล้มละลายได้อย่างแม่นยำยิ่งขึ้น งานวิจัยยังได้พัฒนา และเปิดเผยชุดข้อมูล SMEsD ซึ่งรวบรวมข้อมูลจากหลายแหล่งในโลกจริง และได้แสดงให้เห็นว่าโมเดลที่เสนอมีประสิทธิภาพเหนือกว่าโมเดลเดิมหลายตัวอย่างมีนัยสำคัญ ทั้งในด้านความแม่นยำ ค่า F1-score และ AUC

Malakauskas and Lakstutiene [25] ได้ทำการศึกษาวิจัย เรื่อง Financial Distress Prediction for Small and Medium Enterprises Using Machine Learning Techniques งานวิจัยนี้มุ่งพัฒนาแบบจำลองเพื่อคาดการณ์ภาวะการเงินย่ำแย่ (Financial Distress) ของธุรกิจขนาดกลาง และขนาดย่อม (SMEs) โดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ได้แก่ การถดถอยโลจิสติก (Logistic Regression) เครือข่ายประสาทเทียม (Artificial Neural Networks) และป่าการตัดสินใจแบบสุ่ม (Random Forests) ด้วยข้อมูลจาก SMEs กว่า 12,000 ราย พร้อมตัวแปรทางการเงินแบบมาตรฐาน และตัวแปรเพิ่มเติม เช่น ประวัติการค้างชำระ การเปลี่ยนแปลงในยอดขาย และอายุของบริษัท เพื่อเพิ่มความแม่นยำของโมเดล ผลการทดลองแสดงให้เห็นว่าโมเดลที่ใช้ Random Forests พร้อมตัวแปรด้านเวลาให้ความแม่นยำสูงที่สุด โดยสามารถแยกแยะบริษัทที่มีแนวโน้มประสบปัญหาทางการเงินได้ดีกว่าโมเดลอื่น ขณะที่ Neural Networks ทำนายผลดีที่สุดเมื่อใช้เฉพาะตัวแปรดั้งเดิมเพียงปีเดียว

Alanis, Chava and Shah [26] ได้ทำการศึกษาวิจัย เรื่อง Benchmarking Machine Learning Models to Predict Corporate Bankruptcy งานวิจัยนี้ประเมินประสิทธิภาพของอัลกอริธึมการเรียนรู้ของเครื่อง (Machine Learning) 8 รูปแบบในการทำนายการล้มละลายของบริษัทมหาชนในสหรัฐอเมริกา โดยใช้ข้อมูลย้อนหลังตั้งแต่ปี 1969 ถึง 2019 รวมกว่า 131,000 ชุดข้อมูล และกรณีล้มละลาย 2,585 กรณี จากการทดลองแบบทำนายล่วงหน้าหนึ่งปี (one-year-

ahead forecasts) พบว่า โมเดล Gradient Boosted Trees (เช่น XGBoost และ LightGBM) มีความแม่นยำสูงที่สุด โดยเฉพาะ XGBoost ที่ให้ค่า AUC สูงถึง 0.92 ตัวแปรสำคัญที่มีผลต่อการทำนายมากที่สุด ได้แก่ ผลตอบแทนจากหุ้นส่วนเกิน (Excess Return) ความเสี่ยงเฉพาะบริษัท (Idiosyncratic Risk) และ ขนาดบริษัทเทียบกับตลาด (Relative Size) ในทางตรงกันข้าม ตัวแปรจากข้อมูลมหภาค (Macroeconomic Variables) และข้อความจากรายงานประจำปี เช่น ความรู้สึกเชิงบวก-ลบ หรือระดับความไม่แน่นอน ไม่ได้เพิ่มประสิทธิภาพของโมเดลอย่างมีนัยสำคัญ

Kim and Yoon [27] ได้ทำการศึกษาวิจัย เรื่อง Corporate Bankruptcy Prediction with Domain-Adapted BERT งานวิจัยนี้นำเสนอวิธีการทำนายการล้มละลายของบริษัทโดยใช้โมเดลภาษา BERT จุดเด่นของงานนี้ คือการใช้เทคนิควิเคราะห์ความรู้สึก (Sentiment Analysis) จากข้อความในส่วน Management Discussion and Analysis (MD&A) ของแบบฟอร์ม 10-K ซึ่งเป็นส่วนที่ผู้บริหารแสดงความเห็นเกี่ยวกับอนาคตของกิจการ เมื่อนำโมเดลที่ได้ไปประเมินร่วมกับโมเดลทำนาย เช่น Logistic Hazard Model, SVM และ k-Nearest Neighbors พบว่า โมเดลที่ใช้ BERT แบบปรับโดเมนให้ผลการทำนายความเสี่ยงการล้มละลายได้แม่นยำที่สุด โดยมี Accuracy สูงถึง 91.56% ในการแยกแยะบริษัทที่มีแนวโน้มล้มละลายภายใน 12 เดือน งานวิจัยนี้จึงแสดงให้เห็นว่าการวิเคราะห์ข้อความแบบเจาะจงบริบทด้วย BERT สามารถเพิ่มความแม่นยำในการทำนายวิกฤตการเงินได้อย่างมีนัยสำคัญ

Iparraguirre-Villanueva and Cabanillas-Carbonell [28] ได้ทำการศึกษาวิจัย เรื่อง Predicting Business Bankruptcy: A Comparative Analysis With Machine Learning Models งานวิจัยนี้มุ่งวิเคราะห์เปรียบเทียบความแม่นยำของอัลกอริทึม การเรียนรู้ของเครื่อง (Machine Learning) จำนวน 16 แบบ ในการพยากรณ์การล้มละลายของธุรกิจ โดยใช้ชุดข้อมูลจากบริษัท 6,819 แห่ง ซึ่งประกอบด้วยตัวแปรทางการเงิน และเศรษฐกิจมหภาครวม 96 ตัวแปร ขั้นตอนการวิเคราะห์ประกอบด้วยการทำความสะอาดข้อมูล วิเคราะห์เชิงสำรวจ การคัดเลือกตัวแปร การฝึกโมเดล และประเมินผลด้วยค่าความแม่นยำ (Accuracy), ความไว (Recall), ค่าความแม่นยำเฉพาะ (Precision), F1-score และค่า ROC-AUC ผลการศึกษาแสดงให้เห็นว่า อัลกอริทึมแบบ Stacking Classifier (SCC) ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่าความแม่นยำ Recall และ F1-score เท่ากันที่ 97.63% ตามมาด้วย Randomized Search CV และ Decision Tree ที่มีความแม่นยำเกิน 97% เช่นกัน ขณะที่โมเดลอย่าง PAC และ Bernoulli NB มีประสิทธิภาพต่ำกว่า 90% แม้ยังอยู่ในระดับที่ใช้งานได้

Hamdi, Mestiri and Arbi [29] ได้ทำการศึกษาวิจัย เรื่อง Artificial Intelligence Techniques for Bankruptcy Prediction of Tunisian Companies: An Application of Machine Learning and Deep Learning-Based Models งานวิจัยนี้ศึกษาการทำนายการ

ล้มละลายของบริษัทในประเทศตุนีเซีย โดยเปรียบเทียบประสิทธิภาพของโมเดลทางสถิติ การเรียนรู้ของเครื่อง และ Deep Learning รวมทั้งหมด 6 รูปแบบ ได้แก่ Linear Discriminant Analysis, Logistic Regression, Decision Trees, Support Vector Machine (SVM), Random Forest และ Deep Neural Network โดยใช้ข้อมูลทางการเงิน 25 ตัวแปร จากบริษัทตุนีเซีย 732 แห่ง ในช่วงปี 2011–2017 ผลการทดลองพบว่าโมเดล Deep Neural Network ให้ผลแม่นยำสูงสุด (Accuracy 93.6%, F1-score 0.964, AUC 0.888) การศึกษานี้ชี้ว่า Deep Neural Network เป็นเครื่องมือที่มีศักยภาพสูงในการคัดกรองบริษัทที่เสี่ยงล้มละลาย และสามารถช่วยผู้ให้กู้หรือสถาบันการเงินตัดสินใจเชิงกลยุทธ์ได้อย่างมีประสิทธิภาพ พร้อมเสนอแนวทางในอนาคต เช่น การผสานโมเดล (Hybrid) และการใช้ข้อมูลไม่ใช่เชิงตัวเลขเพื่อเพิ่มความแม่นยำในการทำนาย

Kuiziniene, D. et al. [30] ได้ทำการศึกษาวิจัย เรื่อง Systematic Review of Financial Distress Identification using Artificial Intelligence Methods โดยการศึกษานี้เป็นการทบทวนงานวิจัยจำนวน 232 ชิ้นที่เกี่ยวข้องกับการใช้เทคนิคปัญญาประดิษฐ์ (AI) สำหรับการระบุภาวะความเสี่ยงทางการเงินของกิจการ เช่น การล้มละลายหรือการผิดนัดชำระหนี้ โดยใช้แนวทาง PRISMA ในการคัดเลือกบทความ งานวิจัยนี้วิเคราะห์ประเด็นสำคัญต่าง ๆ เช่น ความไม่สมดุลของข้อมูล การลดมิติข้อมูลทางการเงิน ขั้นตอนการเตรียมข้อมูล ตัวชี้วัดที่ไม่ใช่ข้อมูลทางการเงิน วิธีการเรียนรู้ของเครื่องที่ใช้บ่อย รวมถึงตัวชี้วัดประสิทธิภาพของโมเดล ผลการศึกษพบว่า การจัดการกับข้อมูลที่ไม่สมดุลและการลดมิติข้อมูลเป็นขั้นตอนสำคัญในการเตรียมข้อมูล และยังเผยให้เห็นถึงแนวทางการวิจัยใหม่ ๆ ที่ยังไม่ถูกสำรวจอย่างลึกซึ้งในปัจจุบัน

Vásquez-Serpa, L. et al. [31] ได้ทำการศึกษาวิจัย เรื่อง Challenges of Artificial Intelligence for the Prevention and Identification of Bankruptcy Risk in Financial Institutions: A Systematic Review งานวิจัยนี้เป็นการทบทวนอย่างเป็นระบบเกี่ยวกับการใช้เทคโนโลยีปัญญาประดิษฐ์ (AI) เพื่อทำนาย และป้องกันความเสี่ยงการล้มละลายของสถาบันการเงิน โดยวิเคราะห์ทั้งเทคนิคดั้งเดิม (เช่น Logistic Regression, Decision Tree) และเทคนิคสมัยใหม่ เช่น XGBoost, LSTM และโมเดลแบบ Hybrid โดยใช้กรอบการวิเคราะห์ PRISMA และ PICOC ผลการศึกษาแสดงว่าเทคนิค AI สมัยใหม่สามารถให้ความแม่นยำสูงถึง 99% ในบางกรณี แต่ก็มีข้อจำกัด เช่น ความต้องการข้อมูลจำนวนมาก และทรัพยากรคอมพิวเตอร์สูง งานวิจัยยังระบุปัจจัยสำคัญที่ใช้ในการพยากรณ์ เช่น อัตราส่วนหนี้สิน, ROA, ROE และการวิเคราะห์ข้อความจากแหล่งข้อมูลภายนอก (NLP, Sentiment Analysis) รวมถึงเทคนิคยอดนิยมอย่าง SMOTE ที่ใช้แก้ปัญหาชุดข้อมูลไม่สมดุล นอกจากนี้ยังเสนอแนวทางอนาคต เช่น การผสานข้อมูลเชิงคุณภาพ และการใช้เทคนิคเรียนรู้ต่อเนื่อง เพื่อเพิ่มความแม่นยำ และความสามารถในการปรับตัวของโมเดลในสถานการณ์จริง

Noh [32] ได้ทำการศึกษาวิจัย เรื่อง Comparing the Performance of Corporate Bankruptcy Prediction Models Based on Imbalanced Financial Data งานวิจัยนี้ศึกษาเปรียบเทียบประสิทธิภาพของโมเดลพยากรณ์การล้มละลายของกิจการภายใต้ปัญหาข้อมูลไม่สมดุล (Imbalanced Financial Data) โดยใช้ข้อมูลจาก 1,020 บริษัทจดทะเบียนในตลาดหลักทรัพย์เกาหลี (KOSPI และ KOSDAQ) ช่วงปี 2012–2021 ซึ่งมีเพียง 20 บริษัทที่ล้มละลาย ผู้วิจัยจึงนำเสนอวิธีการสุ่มตัวอย่างข้อมูลบริษัทที่ไม่ล้มละลายแบบใหม่ รวมถึงเทคนิค Approximate Entropy เพื่อคัดเลือกบริษัทที่ “เสถียร” มาใช้เป็นตัวแทนในการฝึกโมเดล นอกจากนี้ยังเสนอวิธีตั้งค่าเกณฑ์จำแนก (Optimal Threshold) โดยอิงจากคะแนนความผิดปกติ (Anomaly Score) เพื่อเพิ่มค่า AUC ให้แม่นยำยิ่งขึ้น งานวิจัยเปรียบเทียบโมเดล LSTM, Logistic Regression, k-NN, Decision Tree และ Random Forest โดยพบว่า Random Forest และ k-NN มีประสิทธิภาพสูงสุดในการจำแนกบริษัทที่ไม่ล้มละลาย ขณะที่ Decision Tree ทำได้ดีที่สุดในแง่ของการทำนายบริษัทที่ล้มละลาย ทั้งนี้ผลการทดลองยืนยันว่า การเลือกกลุ่มตัวอย่างอย่างเหมาะสม และการตั้ง Threshold ตามค่าคะแนนความผิดปกติ ช่วยเพิ่มประสิทธิภาพของโมเดลได้ดีกว่าการใช้ข้อมูลทั้งหมดแบบไม่ปรับสมดุล

ธัญญ์วี และคณะ [33] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์-ความแม่นยำ เพื่อวิเคราะห์ประมาณการยอดขายสินค้าขายปลีก กรณีศึกษา Walmart โดยงานวิจัยนี้แนะนำการพยากรณ์ยอดขายล่วงหน้า 28 วันของสินค้าปลีกในห้าง Walmart โดยใช้เทคนิค Deep Learning เพื่อช่วยในการบริหารจัดการคลังสินค้าให้สอดคล้องกับความต้องการซื้อที่แตกต่างกันในแต่ละสาขา และแต่ละหมวดสินค้า งานวิจัยได้ทดลองใช้โมเดลหลายแบบในการพยากรณ์ เช่น KNN Regression, Random Forest, Linear Regression, Logistic Regression, SVM และ LightGBM โดยประเมินผลลัพธ์จากค่า RMSE (Root Mean Square Error) พบว่า LightGBM ให้ผลแม่นยำที่สุด (RMSE = 1.997) และใช้เวลาฝึกน้อยที่สุด จึงสรุปได้ว่า LightGBM เหมาะสมที่สุดสำหรับการพยากรณ์ยอดขายราย SKU ในแต่ละสาขาของ Walmart

ปวิศ และพิศิษฐ์ [34] ได้ทำการศึกษาวิจัย เรื่อง การพยากรณ์ระยะเวลาการเดินทางด้วยวิธีการเรียนรู้ของเครื่องโดยใช้ข้อมูลจากพาหนะ และโทรศัพท์มือถือในจังหวัดกรุงเทพมหานคร งานวิจัยนี้แนะนำการพัฒนาต้นแบบการพยากรณ์ระยะเวลาการเดินทางของรถแท็กซี่ในเขตกรุงเทพมหานคร โดยใช้เทคนิคการเรียนรู้ของเครื่องกับข้อมูลพิกัดจาก iTic รวมกว่า 4.8 ล้านรายการ ผลการทดลองเปรียบเทียบอัลกอริทึมหลายประเภท พบว่า XGBoost ให้ประสิทธิภาพดีที่สุด ด้วยค่า RMSE เท่ากับ 163.3069 และใช้เวลาในการฝึกเพียง 14.51 วินาที ขณะที่ LightGBM และ CatBoost ก็แสดงผลลัพธ์ที่ใกล้เคียง และมีศักยภาพในการพัฒนาต่อยอดเช่นกัน

ตารางที่ 2-1 สรุปงานวิจัยที่เกี่ยวข้อง

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
การพยากรณ์ความเสี่ยงในการล้มละลายของบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ด้วยตัวชี้วัดทางบัญชี และตัวชี้วัด Systemic Risk [14]	2564	1. ตัวชี้วัดทางบัญชี 2. ตัวชี้วัด Systemic Risk 3. Logistic Regression	ผลการศึกษาพบว่า ตัวแปรจากกลุ่มตัวชี้วัดทั้งสองด้านสามารถใช้ในการพยากรณ์ความเสี่ยงในการล้มละลายได้ โดยเฉพาะตัวชี้วัด Systemic Risk มีความสามารถในการอธิบายความเสี่ยงได้อย่างมีนัยสำคัญ โดยแบบจำลองที่รวมทั้งตัวชี้วัดด้านบัญชี และ Systemic Risk ให้ผลการพยากรณ์ที่แม่นยำที่สุด
การพยากรณ์ความล้มเหลวทางการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย [15]	2565	1. Logistic Regression	แบบจำลองสามารถพยากรณ์ความล้มเหลวทางการเงินได้แม่นยำถึง 90.67% โดยพบว่า 4 ตัวแปรที่มีนัยสำคัญ ได้แก่ อัตราส่วนทุนหมุนเวียนต่อสินทรัพย์รวม (NWCTA), อัตราส่วนเงินสดต่อสินทรัพย์รวม (CTA), การหมุนเวียนของสินทรัพย์ (TAT) และอัตราส่วนหนี้สินต่อส่วนของผู้ถือหุ้น (DE) แสดงให้เห็นถึงความสำคัญของข้อมูลทางการเงินในการประเมินความเสี่ยงของกิจการในอนาคต

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
การสร้างแบบจำลองในการพยากรณ์ผลการดำเนินงานจากข้อมูลในงบการเงินของบริษัทในตลาดหลักทรัพย์ กรณีศึกษา กลุ่มอุตสาหกรรมเกษตร และกลุ่มอุตสาหกรรมอาหาร [16]	2563	1. Decision Tree 2. Deep Learning (Artificial Neural Network (ANN)) 3. Regression Analysis	โมเดล ANN ให้ความแม่นยำสูงที่สุดในการพยากรณ์ผลการดำเนินงานของกิจการในกลุ่มอุตสาหกรรมเกษตร และอาหาร รองลงมาคือ Decision Tree และ Regression ตามลำดับ ตัวแปรทางการเงินที่สำคัญ ได้แก่ อัตราส่วนกำไรสุทธิ และรายได้จากการขาย ซึ่งมีอิทธิพลสูงต่อผลการดำเนินงานของบริษัท
แบบจำลองการพยากรณ์ภาวะล้มละลายของวิสาหกิจขนาดกลางและขนาดย่อมในประเทศไทย [17]	2565	1. Logistic Regression 2. Multivariate Discriminant Analysis	ตัวแปรสำคัญที่สามารถพยากรณ์ภาวะล้มละลายล่วงหน้า 1 ปี ก่อนกิจการจะล้มละลายได้อย่างมีนัยสำคัญ คือ อัตราการหมุนของสินทรัพย์ถาวร อัตรากำไรจากการดำเนินงาน อัตราผลตอบแทนผู้ถือหุ้น และ อายุของกิจการ ความแม่นยำในการพยากรณ์เท่ากับ 77.08%
การเรียนรู้ของเครื่องเพื่อการทำนายการผิดนัดชำระของลูกหนี้บัตรเครดิต [18]	2565	1. Logistic Regression 2. Extreme Gradient Boosting (XGBoost) 3. CatBoost	แบบจำลองที่ดีที่สุดคือ XGBoost และ CatBoost ซึ่งสามารถแยกแยะกลุ่มลูกค้าปกติ และลูกค้าที่มีแนวโน้มผิดนัดชำระได้อย่างแม่นยำ เหมาะสมต่อการนำไปใช้ในระบบประเมินความเสี่ยงด้านสินเชื่อของสถาบันการเงิน

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
การพยากรณ์การเกิดพายุฝนฟ้าคะนองระยะปัจจุบัน ด้วยเทคนิคการเรียนรู้ของเครื่องกรณีศึกษาสนามบินภาคเหนือของประเทศไทย [19]	2567	1. Random Forest 2. Neural Network 3. Decision Tree 4. Naïve Bayes 5. Bagging 6. AdaBoost	สำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง แบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุด คือ Random Forest โดยมีค่า F-measure เท่ากับ 76.45% และค่า AUC เท่ากับ 0.888 ส่วนการพยากรณ์ล่วงหน้า 2 ชั่วโมง แบบจำลองที่มีประสิทธิภาพสูงสุด คือ Neural Networks ร่วมกับ Bagging โดยมีค่า F-measure เท่ากับ 30.62% และค่า AUC เท่ากับ 0.746
การพยากรณ์ยอดขายไก่เนื้อด้วยเทคนิคการเรียนรู้ของเครื่องกรณีศึกษาผู้ประกอบการรายย่อยใน อำเภอหล่มสัก จังหวัดเพชรบูรณ์ [20]	2567	1. Neural Network 2. Support Vector Machine 3. Random Forest 4. ARIMA 5. Holt-Winters Exponential Smoothing	Random Forest และ ARIMA ให้ผลพยากรณ์แม่นยำสูงสุด โดยมีค่าความคลาดเคลื่อน (RMSE) ต่ำกว่าวิธีอื่นอย่างมีนัยสำคัญ ทั้งสองวิธีสามารถสะท้อนแนวโน้มยอดขายได้ดี และเหมาะกับการวางแผนการผลิตสำหรับผู้ประกอบการรายย่อย ทั้งนี้ Random Forest เหมาะกับข้อมูลที่มีปัจจัยแปรผันจำนวนมาก ส่วน ARIMA เหมาะกับข้อมูลที่มีรูปแบบแนวโน้มชัดเจน

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
การพัฒนาแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องเพื่อพยากรณ์พื้นที่ในประเทศไทยที่มีความเสี่ยงได้รับผลกระทบจากการเกิดดินโคลนถล่ม [21]	2564	1. Chi-Square Feature Selection 2. Artificial Neural Network	โมเดล ANN สามารถจำแนกพื้นที่เสี่ยงดินโคลนถล่มได้อย่างมีประสิทธิภาพ (Recall = 70.97%, Accuracy = 64.70%) ซึ่งอยู่ในระดับที่น่าพึงพอใจ และมีศักยภาพพร้อมนำไปประยุกต์ใช้ในระบบเฝ้าระวังและเตือนภัยระดับพื้นที่ได้จริง
การพัฒนาโมเดลพยากรณ์สำหรับปริมาณการรับส่งข้อมูลอินเทอร์เน็ตโดยใช้เทคนิคโครงข่ายประสาทเทียม [22]	2565	1. เทคนิค Artificial Neural Network (ANN) แบบ Multilayer Perceptron + Levenberg-Marquardt Algorithm	โมเดล ANN (โหนดซ่อน 2n) พยากรณ์การใช้อินเทอร์เน็ตรายวันได้แม่นยำที่สุด (MAPE = 3.01%) สามารถนำไปประยุกต์ใช้วางแผนและบริหารทรัพยากรเครือข่ายองค์กรได้อย่างมีประสิทธิภาพ
A Complex Network Analysis Approach to Bankruptcy Prediction Using Company Relational Information-based Drivers [23]	2567	1. Complex Network Analysis (การวิเคราะห์โครงข่ายเชิงซ้อน) 2. Support Vector Machine (SVM) 3. Random Forest (RF) 4. Gradient Boosting Machine (GBM)	การเพิ่มคุณลักษณะจากการวิเคราะห์เครือข่ายลงในโมเดล ML ช่วยเพิ่มประสิทธิภาพในการพยากรณ์การล้มละลายได้อย่างชัดเจน โดยเฉพาะโมเดล GBM ที่ได้ค่าความแม่นยำสูงสุดเมื่อรวมตัวแปรจาก Network เข้าด้วยกัน งานวิจัยชี้ว่าความสัมพันธ์ระหว่างบริษัทในระบบเศรษฐกิจมีผลต่อความเสี่ยงล้มละลาย และสามารถนำมาใช้เพิ่มศักยภาพในการตรวจจับความเสี่ยงทางการเงินได้จริง

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
Combining Intra-Risk and Contagion Risk for Enterprise Bankruptcy Prediction Using Graph Neural Networks [24]	2565	1. Graph Neural Networks (GNNs) 2. Hypergraph Neural Networks (Hyper-GNNs) 3. Heterogeneous Graph Neural Networks (Heter-GNNs)	โมเดล Hyper-GNN (ผสานข้อมูล Intra-Risk และ Contagion Risk) ให้ความแม่นยำสูงสุด (AUC และ F1-score) การใช้ข้อมูลโครงสร้างเครือข่ายร่วมกับข้อมูลการเงินช่วยยกระดับการพยากรณ์ล้มละลายให้แม่นยำยิ่งขึ้น เหมาะสำหรับสร้างระบบเตือนภัยล่วงหน้าระดับอุตสาหกรรมหรือประเทศ
Financial Distress Prediction for Small and Medium Enterprises Using Machine Learning Techniques [25]	2564	1. Logistic Regression 2. Neural Networks 3. Random Forest	Random Forest ให้ผลแม่นยำที่สุดโดยเฉพาะเมื่อใช้ตัวแปรแบบหลายช่วงเวลา แสดงให้เห็นว่าข้อมูลตามช่วงเวลาช่วยเพิ่มความแม่นยำของโมเดลได้มาก ขณะที่ Neural Networks ทำนายผลได้ดีที่สุดเมื่อใช้เฉพาะตัวแปรเพียงปีเดียว
Benchmarking Machine Learning Models to Predict Corporate Bankruptcy [26]	2565	1. Extreme Gradient Boosting (XGBoost) 2. Light Gradient Boosting Machine (LightGBM) 3. Logistic Regression 4. Random Forest 5. Support Vector Machine (SVM)	โมเดลที่ให้ประสิทธิภาพสูงสุดคือ Extreme Gradient Boosting (XGBoost) ซึ่งให้ค่า Accuracy, F1-score และ ROC-AUC สูงที่สุดในเกือบทุกกรณี รองลงมาคือ Random Forest และ Gradient Boosting ผลการวิจัยยืนยันว่าการเลือกเทคนิค Machine Learning ที่เหมาะสมมีผลอย่างมากต่อความแม่นยำของการพยากรณ์การล้มละลาย

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
Corporate Bankruptcy Prediction with Domain-Adapted BERT [27]	2564	1. Domain-adapted BERT + Sentiment Analysis	ใช้ข้อความจากรายงาน MD&A วิเคราะห์ด้วย BERT ทำให้แยกแยะบริษัทที่มีแนวโน้มล้มละลายได้แม่นยำกว่า Logistic และ SVM โดยมี Accuracy สูงถึง 91.56%
Predicting Business Bankruptcy: A Comparative Analysis with Machine Learning Models [28]	2567	การเรียนรู้ของเครื่อง (Machine Learning) จำนวน 16 อัลกอริทึม	โมเดลที่ให้ผลดีที่สุดคือ Stacking Classifier ซึ่งให้ความแม่นยำสูงถึง 97.63% รองลงมาคือ RandomizedSearchCV และ Decision Tree ขณะที่บางโมเดลให้ผลแม่นยำต่ำกว่า 90% อย่างชัดเจน งานวิจัยยืนยันว่า Machine Learning สามารถใช้เป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์ความเสี่ยงการล้มละลายของธุรกิจ
Artificial Intelligence Techniques for Bankruptcy Prediction of Tunisian Companies: An Application of Machine Learning and Deep Learning-Based Models [29]	2567	1. Deep Neural Networks (DNN) 2. Random Forest 3. Logistic Regression 4. Support Vector Machine 5. Decision Tree 6. Linear Discriminant Analysis (LDA)	ผลการวิจัยพบว่า Deep Neural Network (DNN) ให้ความแม่นยำสูงสุดที่ 93.6% และมี F1-score กับ AUC สูงที่สุด รองลงมาคือ Random Forest และ Logistic Regression แสดงให้เห็นว่าเทคนิค Deep Learning มีประสิทธิภาพสูงในการพยากรณ์การล้มละลายของบริษัทในบริบทของประเทศตูนิเซีย

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
Systematic Review of Financial Distress Identification using Artificial Intelligence Methods [30]	2565	1. Systematic Literature Review using PRISMA framework	จากการทบทวน 232 งานวิจัย พบประเด็นสำคัญ ได้แก่ การจัดการข้อมูลไม่สมดุล การลดมิติ และการคัดเลือกคุณลักษณะ ซึ่งเป็นหัวใจสำคัญของการใช้ AI ในด้านนี้
Challenges of Artificial Intelligence for the Prevention and Identification of Bankruptcy Risk in Financial Institutions: A Systematic Review [31]	2568	1. Systematic Review + Analysis of AI Techniques including Logistic Regression	ผลการศึกษาพบว่าโมเดล AI สมัยใหม่ เช่น LSTM และ XGBoost มีความแม่นยำสูงในการทำนายความเสี่ยง โดยบางกรณีให้ผลแม่นยำเกิน 99% ซึ่งเหนือกว่าวิธีดั้งเดิมที่ใช้เพียงอัตราส่วนทางการเงิน อย่างไรก็ตาม โมเดลเหล่านี้ต้องการข้อมูลจำนวนมาก และทรัพยากรคอมพิวเตอร์สูง จึงอาจไม่เหมาะกับสถาบันที่มีข้อจำกัดด้านเทคโนโลยี
Comparing the Performance of Corporate Bankruptcy Prediction Models Based on Imbalanced Financial Data [32]	2566	1. Long Short-Term Memory (LSTM) 2. k-Nearest Neighbors (k-NN) 3. Logistic Regression 4. Decision Tree 5. Random Forest	ผลการทดลองพบว่า Random Forest และ k-NN ให้ผลลัพธ์ที่ดีที่สุดในกลุ่มข้อมูลขนาดเล็ก โดยเฉพาะเมื่อใช้วิธีเลือกตัวอย่างจาก Entropy ต่ำ และการใช้ Threshold ที่เหมาะสมช่วยเพิ่มความแม่นยำของโมเดลได้อย่างมีนัยสำคัญ แม้ในกรณีที่ใช้ข้อมูลทั้งหมดที่ไม่สมดุล

ตารางที่ 2-1 (ต่อ)

งานวิจัย	ปี	เทคนิค	ผลการวิจัย
การพยากรณ์-ความแม่นยำ เพื่อวิเคราะห์ประมาณการยอดขายสินค้าขายปลีกกรณีศึกษา Walmart [33]	2566	1. KNN Regression 2. Random Forest 3. Linear Regression 4. Logistic Regression 5. SVM 6. LightGBM	ผลลัพธ์จากค่า RMSE (Root Mean Square Error) พบว่า LightGBM ให้ผลแม่นยำที่สุด (RMSE = 1.997) และใช้เวลาฝึกน้อยที่สุด จึงสรุปได้ว่า LightGBM เหมาะสมที่สุดสำหรับการพยากรณ์ยอดขายราย SKU ในแต่ละสาขาของ Walmart เพื่อสนับสนุนการตัดสินใจด้านการจัดการสต็อกอย่างมีประสิทธิภาพ
การพยากรณ์ระยะเวลาการเดินทางด้วยวิธีการเรียนรู้ของเครื่องโดยใช้ข้อมูลจากพาหนะ และโทรศัพท์มือถือในจังหวัดกรุงเทพมหานคร [34]	2565	1. XGBoost 2. LightGBM 3. CatBoost	ผลการทดลองเปรียบเทียบอัลกอริทึมหลายประเภทพบว่า XGBoost ให้ประสิทธิภาพดีที่สุด ด้วยค่า RMSE เท่ากับ 163.3069 และใช้เวลาในการฝึกเพียง 14.51 วินาที ขณะที่ LightGBM และ CatBoost ก็ให้ผลลัพธ์ที่ใกล้เคียง และมีศักยภาพในการพัฒนาต่อเช่นกัน

จากตารางที่ 2-1 ทฤษฎี เอกสารทางวิชาการ และงานวิจัยที่เกี่ยวข้องที่ผู้วิจัยได้ศึกษามาข้างต้น พบว่าการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ในการวิเคราะห์ และพยากรณ์ข้อมูลจากชุดข้อมูลขนาดใหญ่ได้รับความนิยมเพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะในการวิเคราะห์ข้อมูลทางการเงินซึ่งมีความซับซ้อน และสัมพันธ์กับความเสี่ยงของธุรกิจ งานวิจัยหลายชิ้นได้นำเสนอการใช้อัลกอริทึมเหมือนข้อมูลที่มีประสิทธิภาพ เช่น LightGBM, Support Vector Machine (SVM), Deep Neural Network (DNN) และ Ensemble Learning เพื่อวิเคราะห์รูปแบบของข้อมูล และคาดการณ์ผลลัพธ์ได้อย่างแม่นยำ ด้วยเหตุนี้ ผู้วิจัยจึงมีแนวคิดในการนำอัลกอริทึมดังกล่าวมา

เปรียบเทียบประสิทธิภาพในการพยากรณ์สถานะการเลิกกิจการของนิติบุคคลในประเทศไทย โดยใช้
ตัวชี้วัดทางการเงินที่ได้จากงบการเงิน และเลือกใช้อัลกอริทึมที่ให้ผลดีที่สุดในการพัฒนาแบบจำลอง
เพื่อแสดงผลการพยากรณ์ต่อไป



บทที่ 3


วิธีดำเนินงานวิจัย

การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้ทำการศึกษาค้นคว้า ทฤษฎี แนวคิด และงานวิจัยที่เกี่ยวข้องต่าง ๆ เพื่อนำมาประยุกต์ใช้ในงานวิจัย โดยมีรายละเอียด และขั้นตอนดังต่อไปนี้

- 3.1 ขั้นตอนการกำหนดกรอบแนวคิด (Conceptual Framework Design)
- 3.2 การเก็บรวบรวมข้อมูล (Data Collection)
- 3.3 การจัดเตรียมข้อมูล (Data Preprocessing)
- 3.4 การพัฒนา และวัดประสิทธิภาพแบบจำลอง (Model Development & Evaluation)
- 3.5 การนำแบบจำลองไปใช้งาน (Model Deployment)


3.1 การออกแบบกรอบแนวความคิด (Conceptual Framework Design)

ผู้วิจัยได้ศึกษาค้นคว้างานวิจัยที่เกี่ยวข้องกับการพัฒนาแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) และนำมาประยุกต์ใช้กับงานวิจัยนี้ โดยมีกระบวนการดำเนินงานแสดงดังภาพที่ 3-1




ภาพที่ 3-1 กรอบแนวคิดงานวิจัย

จากภาพที่ 3-1 งานวิจัยนี้นำเสนอกรอบแนวคิดการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงิน โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง กระบวนการวิจัยแบ่งออกเป็น 3 ส่วนหลัก คือการเก็บรวบรวมข้อมูลและจัดเตรียมข้อมูล การพัฒนา และวัดประสิทธิภาพแบบจำลอง และการนำแบบจำลองไปใช้งาน เริ่มจากขั้นตอนการจัดเตรียมข้อมูล ผู้วิจัยได้นำข้อมูลที่รวบรวมได้มาผ่านกระบวนการทำความสะอาดข้อมูล จัดการกับค่าที่สูญหาย (Missing Values) และปัญหาความไม่สมดุลของคลาสข้อมูล (Imbalanced Data) เพื่อให้ได้ชุดข้อมูลที่มีความสมบูรณ์ จากนั้นดำเนินการแบ่งชุดข้อมูลออกเป็น 2 ส่วนหลัก ได้แก่ ชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset) และ ชุดข้อมูลทดสอบอิสระ (Unseen Dataset) สำหรับขั้นตอนการพัฒนาแบบจำลอง ได้นำชุดข้อมูลส่วนแรกมาใช้ร่วมกับเทคนิคการตรวจสอบความถูกต้องข้ามกลุ่ม (Cross-Validation) มาใช้ในการเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึม ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM), อัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (Light Gradient Boosting Machine: LightGBM) และโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network: DNN) รวมไปถึงการทดสอบประยุกต์ใช้เทคนิคการรวมแบบจำลอง (Ensemble Voting) โดยพิจารณาประสิทธิภาพของแบบจำลองสำหรับการพยากรณ์สถานะกิจการจากค่าความแม่นยำ (Precision) ค่าระลึก (Recall) ค่าการถ่วงดุล (F1-score) และค่าความถูกต้อง (Accuracy) ท้ายที่สุดจะดำเนินการคัดเลือกอัลกอริทึมที่ดีที่สุด (Best Algorithm) เพื่อนำไปสร้างเป็นแบบจำลองขั้นสุดท้าย (Final Model) และประยุกต์ใช้งานต่อไป โดยมีขั้นตอนการดำเนินงาน แสดงดังภาพที่ 3-2



ภาพที่ 3-2 Flowchart ขั้นตอนการดำเนินงาน



ภาพที่ 3-2 Flowchart ขั้นตอนการดำเนินงาน (ต่อ)

3.2 การเก็บรวบรวมข้อมูล (Data Collection)

การศึกษานี้เป็นการวิจัยเชิงปริมาณ (Quantitative Research) โดยอาศัยข้อมูลทุติยภูมิ (Secondary Data) จากฐานข้อมูลงบการเงินของกรมพัฒนาธุรกิจการค้า (Department of Business Development: DBD) กระทรวงพาณิชย์ ในขั้นตอนการคัดเลือกข้อมูล ผู้วิจัยได้กำหนดสัดส่วนของกลุ่มตัวอย่างให้มีความสมดุลตั้งแต่กระบวนการรวบรวมข้อมูล โดยไม่ได้ใช้วิธีการทางสถิติหรืออัลกอริทึมเพื่อสร้างข้อมูลจำลองในการปรับสมดุล (Data Balancing Techniques) ในภายหลัง ผู้วิจัยดำเนินการโดยเริ่มต้นจากข้อจำกัดของจำนวนประชากรกลุ่มเป้าหมาย คือคัดกรองนิติบุคคลที่มีสถานะ "เลิกกิจการ" ในปี พ.ศ. 2567 และมีข้อมูลงบการเงินย้อนหลัง 2 ปีครบถ้วน ซึ่งรวบรวมได้จำนวนทั้งสิ้น 6,609 ราย จากนั้นจึงทำการคัดเลือกนิติบุคคลที่มีสถานะ "ดำเนินกิจการ" ในปี พ.ศ. 2567 ที่มีข้อมูลงบการเงินย้อนหลังครบถ้วนเช่นเดียวกัน มาในจำนวนที่เท่ากันคือ 6,609 ราย ด้วยวิธีการสุ่มตัวอย่าง (Random Sampling) จากประชากรทั้งหมด 10,647 ราย

กระบวนการดังกล่าวทำให้ได้กลุ่มตัวอย่างสำหรับการวิเคราะห์รวมทั้งสิ้น 13,218 รายการ ในสัดส่วนที่เท่ากัน ซึ่งช่วยป้องกันปัญหาความลำเอียงของแบบจำลอง (Model Bias) ที่มักเกิดจากชุดข้อมูลที่ไม่สมดุล (Imbalanced Data) ได้อย่างมีประสิทธิภาพ ทั้งนี้ เพื่อให้เป็นไปตามหลักจริยธรรมการวิจัยและพระราชบัญญัติคุ้มครองข้อมูลส่วนบุคคล (PDPA) ผู้วิจัยได้ดำเนินการปกปิดข้อมูล

สามารถระบุตัวตนของนิติบุคคลได้ (Data Anonymization) เช่น ชื่อบริษัท และเลขทะเบียนนิติบุคคล ก่อนนำเข้าสู่กระบวนการวิเคราะห์

3.2.1 ลักษณะของข้อมูลและตัวแปรที่ใช้ในการศึกษา

ชุดข้อมูลที่ใช้ในการวิจัยประกอบด้วยตัวแปร (Features) จำนวน 32 ตัวแปร ซึ่งรวบรวมจากข้อมูลย้อนหลังในรอบปีบัญชี พ.ศ. 2565 – 2566 โดยครอบคลุมมิติข้อมูลที่สำคัญ ได้แก่

- ข้อมูลลักษณะการดำเนินกิจการ (Business Characteristics)
- ข้อมูลรายการในงบการเงิน (Financial Statements)
- ข้อมูลอัตราส่วนทางการเงิน (Financial Ratios)
- ความเห็นของผู้สอบบัญชี (Auditor's Opinion)
- สถานภาพการดำเนินกิจการ (Operating Status)

3.2.2 การกำหนดตัวแปรเป้าหมาย (Target Variable)

เนื่องจากงานวิจัยนี้ประยุกต์ใช้อัลกอริทึมในกลุ่มการจำแนกประเภท (Classification) ผู้วิจัยจึงได้กำหนดตัวแปรเป้าหมายสำหรับการ จำแนกกลุ่มข้อมูลแบบสองกลุ่ม (Binary Classification) เพื่อพยากรณ์สถานะของนิติบุคคลในปี พ.ศ. 2567 โดยแบ่งออกเป็น 2 กลุ่ม ดังนี้

- คลาส 0 (Class 0): กลุ่มนิติบุคคลที่ "ยังดำเนินกิจการ" (Majority Class)
- คลาส 1 (Class 1): กลุ่มนิติบุคคลที่ "เลิกกิจการ" ซึ่งกำหนดให้เป็นกลุ่มเหตุการณ์ที่ผู้วิจัยให้ความสนใจ (Event Group / Minority Class)

3.2.3 การนำเข้าและสำรวจข้อมูลเบื้องต้น (Exploratory Data Analysis)

ผู้วิจัยดำเนินการนำเข้าชุดข้อมูล (Data Loading) ด้วยภาษาไพทอน (Python) ผ่านไลบรารี Pandas เพื่อจัดเก็บข้อมูลในรูปแบบตาราง (DataFrame) จากนั้นจึงทำการสำรวจข้อมูลเบื้องต้น (Exploratory Data Analysis) โดยตรวจสอบมิติของข้อมูลซึ่งประกอบด้วยข้อมูลจำนวน 13,218 รายการ และตัวแปรจำนวน 32 ตัวแปร รวมถึงตรวจสอบชนิดของตัวแปร (Data Types) และค่าสูญหาย เพื่อทำความเข้าใจโครงสร้างและคุณภาพของข้อมูล ก่อนนำไปสู่กระบวนการเตรียมข้อมูล (Data Preprocessing) ในลำดับถัดไป

3.3 การจัดเตรียมข้อมูล (Data Preprocessing)

การจัดเตรียมข้อมูลเป็นขั้นตอนที่มีความสำคัญอย่างยิ่งในการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง เพื่อให้ชุดข้อมูลมีความสมบูรณ์ ลดความซ้ำซ้อน และอยู่ในรูปแบบที่เหมาะสมต่อการประมวลผลของอัลกอริทึม ในขั้นตอนนี้ ผู้วิจัยได้ทำการคัดเลือกตัวแปร (Feature Selection) โดยอ้างอิงจากการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง ซึ่งนำไปสู่การคัดกรองตัวแปรตั้งต้นจาก

ทั้งหมด 32 ตัวแปร ให้คงเหลือเพียง 16 ตัวแปรที่มีนัยสำคัญต่อการพยากรณ์ความล้มเหลวทางการเงิน โดยผู้วิจัยได้ดำเนินการจัดเตรียมข้อมูลผ่านกระบวนการต่าง ๆ ดังนี้

3.3.1 การคัดเลือกตัวแปร (Feature Selection)

เพื่อเพิ่มประสิทธิภาพของแบบจำลอง ลดระยะเวลาในการประมวลผล และป้องกันปัญหาความซ้ำซ้อนของข้อมูล ผู้วิจัยได้ทำการคัดเลือกเฉพาะตัวแปรที่มีนัยสำคัญเชิงทฤษฎีด้านความเสี่ยงเครดิต และการล้มละลาย โดยแบ่งกลุ่มตัวแปรออกเป็น 2 ส่วนหลัก ได้แก่

3.3.1.1 ตัวแปรพื้นฐานของนิติบุคคล: ได้แก่ จำนวนปีที่ดำเนินกิจการ (สะท้อนเสถียรภาพ) ประเภทนิติบุคคล (สะท้อนโครงสร้างทางกฎหมาย) หมวดหมู่อุตสาหกรรม (TSIC) และภูมิภาคที่ตั้งกิจการ

3.3.1.2 ตัวแปรเชิงระดับ (Level Features) จากงบการเงินปี พ.ศ. 2566 เลือกใช้ข้อมูลปีล่าสุดเพื่อสะท้อนสถานะปัจจุบันของธุรกิจ ประกอบด้วย รวมสินทรัพย์ รวมหนี้สิน รวมรายได้ กำไร(ขาดทุน)สุทธิ และอัตราผลตอบแทนผู้ถือหุ้น ทั้งนี้ ผู้วิจัยได้พิจารณาตัดตัวแปรงบการเงินปี พ.ศ. 2565 ในรูปแบบเชิงระดับออกจากการนำเข้าแบบจำลอง เพื่อลดปัญหามภาวะร่วมเชิงเส้นพหุคูณ (Multicollinearity)

3.3.2 การสร้างตัวแปรเชิงพลวัตและอัตราส่วนทางการเงิน (Feature Engineering)

เพื่อให้แบบจำลองสามารถเรียนรู้แนวโน้มการเปลี่ยนแปลงทางการเงินและโครงสร้างทุนของธุรกิจ ผู้วิจัยได้ดำเนินการสร้างตัวแปรใหม่ ดังนี้

3.3.2.1 ตัวแปรเชิงการเติบโต (Growth Features) คำนวณจากการเปรียบเทียบค่าระหว่างปี พ.ศ. 2565 และ 2566 เพื่อสะท้อนการเติบโตหรือถดถอยของกิจการ ได้แก่ อัตราการเติบโตของสินทรัพย์ (Asset Growth) หนี้สิน (Debt Growth) รายได้ (Revenue Growth) และกำไรสุทธิ (Profit Growth) โดยกำหนดสมการการคำนวณดังสมการที่ 3-1

$$\text{Growth} = \frac{X_{66} - X_{65}}{|X_{65}|} \quad (3-1)$$

โดยกำหนดให้ผลลัพธ์เป็นค่าว่าง (NaN) ในกรณีที่ค่าฐานในปี 2565 เท่ากับศูนย์ เพื่อหลีกเลี่ยงข้อผิดพลาดทางคณิตศาสตร์

3.3.2.2 ตัวแปรอัตราส่วนทางการเงิน (Ratio Features) สร้างเพิ่มเติมจากข้อมูลปี พ.ศ. 2566 เพื่อสะท้อนสภาพคล่องและความสามารถในการทำกำไร ได้แก่ อัตราส่วนหนี้สินต่อสินทรัพย์ (Debt Ratio) และอัตรากำไรสุทธิ (Profit Margin)

3.3.3 การจัดการตัวแปรเชิงหมวดหมู่ (Categorical Encoding)

สำหรับตัวแปรเชิงหมวดหมู่ (Categorical Data) เช่น ประเภทนิติบุคคล หมวดหมู่อุตสาหกรรม (TSIC) และความเห็นของผู้สอบบัญชี ผู้วิจัยได้แปลงชนิดข้อมูล (Data Type) และใช้เทคนิคการเข้ารหัสตัวแปร (Label Encoding) เพื่อแปลงค่าข้อความให้เป็นรหัสตัวเลข (เช่น "บริษัทจำกัด" กำหนดค่าเป็น 0 "ห้างหุ้นส่วนจำกัด" กำหนดค่าเป็น 1 โดยได้จัดทำพจนานุกรมข้อมูล (Data Dictionary) เพื่อใช้สำหรับการตีความผลลัพธ์ในภายหลัง

3.3.4 การจัดการค่าที่สูญหาย (Missing Values Handling)

ในขั้นตอนการทำความสะอาดข้อมูล ผู้วิจัยได้แปลงข้อมูลให้อยู่ในรูปแบบตัวเลข และกำหนดให้ข้อมูลที่ไม่สามารถระบุค่าได้หรือเกิดจากการหารด้วยศูนย์เป็นค่าว่าง (NaN) อย่างชัดเจน อย่างไรก็ตาม กลยุทธ์ในการจัดการค่าว่าง (Imputation) จะถูกปรับใช้ให้เหมาะสมกับข้อกำหนดของแต่ละอัลกอริทึมในขั้นตอนการฝึกสอนแบบจำลอง โดยอัลกอริทึม LightGBM มีกลไกภายในที่สามารถจัดการกับข้อมูลที่ขาดหายไปโดยตรง ในขณะที่อัลกอริทึม SVM และ DNN ผู้วิจัยจะดำเนินการเติมค่าที่ขาดหาย (เช่น การใช้ค่าเฉลี่ย หรือค่ามัธยฐาน) ร่วมกับการปรับสเกลข้อมูล (Data Scaling) ภายในกระบวนการสร้างแบบจำลอง (Pipeline) ต่อไป

3.4 การพัฒนา และวัดประสิทธิภาพของแบบจำลอง (Model Development & Evaluation)

ในขั้นตอนการพัฒนาแบบจำลอง ผู้วิจัยได้นำชุดข้อมูลที่ผ่านการจัดเตรียม และทำความสะอาดแล้ว มาเข้าสู่กระบวนการเรียนรู้และทดสอบประสิทธิภาพ โดยมีรายละเอียดขั้นตอนดังต่อไปนี้

3.4.1 การแบ่งชุดข้อมูล (Split Data)

ก่อนเข้าสู่กระบวนการฝึกสอนแบบจำลอง ผู้วิจัยได้ดำเนินการแบ่งชุดข้อมูลที่ผ่านการทำความสะอาดแล้วทั้งหมดออกเป็น 2 ส่วนหลักอย่างเป็นระบบ ได้แก่

3.4.1.1 ชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset): เป็นชุดข้อมูลส่วนใหญ่ที่ถูกสุ่มคัดเลือกและจัดสัดส่วนของคลาสข้อมูลเป้าหมาย (สถานะนิติบุคคล) ให้มีความสมดุลอย่างสมบูรณ์แบบ (Perfectly Balanced) เพื่อป้องกันปัญหาความเอนเอียง (Bias) ของแบบจำลอง โดยข้อมูลชุดนี้จะถูกนำไปใช้ในขั้นตอนการฝึกสอนและปรับแต่งพารามิเตอร์

3.4.1.2 ชุดข้อมูลทดสอบอิสระ (Unseen Dataset) เป็นชุดข้อมูลส่วนที่เหลือซึ่งจะถูกแยกเก็บไว้โดยเด็ดขาด (Data Leakage Prevention) และไม่ถูกนำมารวมในกระบวนการฝึกสอนใดๆ เพื่อใช้เป็นตัวแทนของข้อมูลใหม่ในสถานการณ์จริง สำหรับการทดสอบประสิทธิภาพของแบบจำลองขั้นสุดท้าย

สำหรับกระบวนการฝึกสอนบนชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (ส่วนที่ 1) ผู้วิจัยได้ประยุกต์ใช้เทคนิค K-Fold Cross-validation โดยชุดข้อมูลจะถูกแบ่งออกเป็นสับย่อยที่มีขนาด

เท่าๆ กันจำนวน K ส่วน ในแต่ละรอบของการทดสอบ แบบจำลองจะใช้ข้อมูล K-1 ส่วนเป็นชุดฝึกสอน (Training Set) และใช้ข้อมูล 1 ส่วนที่เหลือเป็นชุดทดสอบ (Validation Set) สลับกันไปจนครบ เพื่อให้ผลการประเมินประสิทธิภาพในขั้นตอนการพัฒนามีความน่าเชื่อถือสูงสุด

3.4.2 การสร้างแบบจำลองและการปรับแต่งพารามิเตอร์ (Model Development and Hyperparameter Tuning)

ผู้วิจัยดำเนินการสร้างแบบจำลองการจำแนกประเภท (Classification Models) โดยเลือกใช้ อัลกอริทึมการเรียนรู้ของเครื่องประสิทธิภาพสูงจำนวน 3 อัลกอริทึม ได้แก่ SVM, LightGBM และ DNN เพื่อให้แบบจำลองแต่ละตัวสามารถทำงานได้อย่างมีประสิทธิภาพสูงสุดและเหมาะสมกับบริบทของชุดข้อมูล ผู้วิจัยได้ดำเนินการปรับแต่งค่าพารามิเตอร์ (Hyperparameter Tuning) ของแต่ละอัลกอริทึม โดยรายละเอียดช่วงของค่าพารามิเตอร์ แสดงดังตารางที่ 3-1

ตารางที่ 3-1 ค่าพารามิเตอร์สำหรับการทดสอบอัลกอริทึม

Algorithm	Parameter
Support Vector Machine	kernels type, C, gamma
Light Gradient Boosting Machine	num_leaves, min_child_samples, max_depth, learning_rate, n_estimators, feature_fraction, reg_lambda
Deep Neural Network	hidden_units, dropout_rates, learning_rate, batch_size, epochs, activation, use_bn, l2

3.4.3 การประยุกต์ใช้เทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning)

หลังจากได้แบบจำลองเดี่ยว (Base Models) ที่ผ่านการปรับแต่งพารามิเตอร์เรียบร้อยแล้ว ผู้วิจัยได้นำแนวคิดการเรียนรู้แบบกลุ่ม (Ensemble Learning) มาประยุกต์ใช้เพื่อยกระดับประสิทธิภาพในการพยากรณ์ โดยเลือกใช้เทคนิค การลงคะแนนเสียงแบบยืดหยุ่น (Soft Voting Classifier) กระบวนการนี้จะทำการรวบรวม "ค่าความน่าจะเป็น (Prediction Probabilities)" ที่ได้จากการพยากรณ์ของแบบจำลอง SVM, LightGBM และ DNN นำมาคำนวณหาค่าเฉลี่ยแบบถ่วงน้ำหนัก (Weighted Average Probability) เพื่อใช้เป็นเกณฑ์ในการตัดสินใจจำแนกสถานะขั้นสุดท้ายของนิติบุคคล วิธีการนี้ช่วยให้แบบจำลองมีความละเอียดอ่อนต่อข้อมูลความเสี่ยง (Sensitivity) สูงขึ้น และสามารถลดทอนข้อผิดพลาดที่อาจเกิดจากการพยากรณ์ที่ผิดพลาดของ

แบบจำลองใดแบบจำลองหนึ่ง (Single Model Error) ได้อย่างมีประสิทธิภาพ ส่งผลให้ผลลัพธ์การพยากรณ์มีเสถียรภาพและมีความน่าเชื่อถือสูงสุดสำหรับการนำไปประยุกต์ใช้งานจริง

3.4.4 การวัดประสิทธิภาพแบบจำลอง (Model Evaluation Metrics)

ในการเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละอัลกอริทึม ผู้วิจัยประเมินผลลัพธ์ผ่านตาราง Confusion Matrix ที่จะทำให้เข้าใจผลลัพธ์ของแต่ละแบบจำลองได้ละเอียดมากขึ้น โดยประเมินว่าแบบจำลองทำงานได้ดีหรือไม่ในแต่ละคลาส ซึ่งใช้ในการประเมินประสิทธิภาพแบบจำลอง ได้แก่ ค่าความถูกต้อง ค่าความแม่นยำ ค่าระลอก และการถ่วงดุล แสดงดังตารางที่ 3-2

ตารางที่ 3-2 ตาราง Confusion Matrix

Actual / Predicted Class		Predicted Class	
		Class 1	Class 2
Actual Class	Class 1	x_{11}	x_{12}
	Class 2	x_{21}	x_{22}

สำหรับการคำนวณค่าต่าง ๆ ประกอบด้วย ค่าผลรวมของ False Positive (TFN), ค่าผลรวมของ False Positive (TFP), ค่าผลรวมของ True Negative (TTN) และผลรวมของ True Positive (TP) สามารถคำนวณได้จากสมการที่ 3-2 ถึง 3-5 ตามลำดับ

$$TFN_i = \sum_{j=1}^n x_{ij} \quad (3-2)$$

$$TFP_i = \sum_{j=1}^n x_{ji} \quad (3-3)$$

$$TTN_i = \sum_{j=1}^n \sum_{k=1}^n x_{jk} \quad (3-4)$$

$$TTP_{all} = \sum_{j=1}^n x_{jj} \quad (3-5)$$

โดยที่ i คือ คลาสที่กำลังพิจารณา

j คือ คลาสที่แบบจำลองทำนาย

k คือ คลาสที่เป็นจริง

สำหรับการคำนวณค่าต่าง ๆ เพื่อใช้ประเมินแบบจำลองประกอบด้วย ค่าความถูกต้อง (Accuracy : A), ค่าความแม่นยำ (Precision : P_i), ค่าระลึก (Recall : R_i) และค่าการถ่วงดุล (F1-Score : F) สามารถคำนวณได้จากสมการที่ 3-6 ถึง 3-9 ตามลำดับ

$$A = \frac{TTP_{all}}{\text{Total Number of testing Entries}} \quad (3-6)$$

$$P_i = \frac{TTP_{all}}{TP_{all} + TFP_i} \quad (3-7)$$

$$R_i = \frac{TTP_{all}}{TTP_{all} + TFN_i} \quad (3-8)$$

$$F = \frac{2P_i \times R_i}{P_i + R_i} \quad (3-9)$$

โดยที่ i คือคลาสที่กำลังพิจารณา

3.5 การนำแบบจำลองไปใช้งาน (Model Deployment)

การนำแบบจำลองไปประยุกต์ใช้งานจริง (Deployment) เป็นขั้นตอนสุดท้ายของงานวิจัย เพื่อให้ผู้ปฏิบัติงานและหน่วยงานที่เกี่ยวข้องสามารถนำผลลัพธ์ไปใช้ประโยชน์ในการประเมินความเสี่ยงได้อย่างเป็นรูปธรรมและเกิดประสิทธิภาพสูงสุด ผู้วิจัยได้ดำเนินการออกแบบและพัฒนาระบบการพยากรณ์ตามขั้นตอนดังต่อไปนี้

3.5.1 การบันทึกแบบจำลองขั้นสุดท้าย (Final Model Exporting)


เมื่อเสร็จสิ้นกระบวนการประเมินและเปรียบเทียบประสิทธิภาพ ผู้วิจัยได้คัดเลือกแบบจำลองที่ให้ผลลัพธ์ความแม่นยำสูงสุด มาเป็นแบบจำลองขั้นสุดท้าย จากนั้นจึงดำเนินการบันทึกแบบจำลองเก็บไว้ในรูปแบบไฟล์นามสกุล .pkl (Pickle file) กระบวนการนี้เปรียบเสมือนการบันทึก "ชุดความรู้" และ "เงื่อนไขการตัดสินใจ" ทั้งหมดที่แบบจำลองได้เรียนรู้มาอย่างสมบูรณ์ เพื่อให้สามารถนำไฟล์ดังกล่าวไปติดตั้งบนระบบและพร้อมสำหรับการพยากรณ์ข้อมูลชุดใหม่ได้ทันที โดยไม่จำเป็นต้องเริ่มต้นกระบวนการฝึกสอนข้อมูลใหม่อีกครั้ง

3.5.2 การพัฒนาเว็บแอปพลิเคชัน และการให้บริการผ่านระบบคลาวด์ (Web Application Development and Cloud Deployment)


เพื่อให้ผู้ปฏิบัติงานสามารถเข้าถึงและใช้งานแบบจำลองได้อย่างสะดวก ผู้วิจัยได้นำไฟล์แบบจำลองขั้นสุดท้ายมาพัฒนาต่อยอดเป็นเว็บแอปพลิเคชัน (Web Application) โดยเลือกใช้

แพลตฟอร์มไฟร์เบสสตูดิโอ (Firebase Studio) ซึ่งเป็นระบบคลาวด์ที่มีเสถียรภาพสูงในการบริหารจัดการทั้งระบบแบบเบ็ดเสร็จ (End-to-End) ทั้งในส่วนของการให้บริการหน้าเว็บไซต์ (Hosting) และการประมวลผล


ผู้วิจัยได้ออกแบบส่วนติดต่อผู้ใช้งาน (User Interface: UI) ให้รองรับการกรอกข้อมูลรายการทางบัญชีและอัตราส่วนทางการเงินของนิติบุคคล เมื่อผู้ใช้งานกดยืนยัน ข้อมูลจะถูกส่งไปประมวลผลผ่านแบบจำลอง ที่ทำงานอยู่บนระบบคลาวด์ และส่งคืนผลลัพธ์การพยากรณ์สถานะของนิติบุคคล (ดำเนินกิจการอยู่ หรือ มีความเสี่ยงเลิกกิจการ) พร้อมแสดงค่าความน่าจะเป็น (Probability) กลับมาแสดงผลบนหน้าจอได้อย่างทันที (Real-time Inference) การนำแบบจำลองขึ้นระบบในลักษณะนี้ ทำให้องค์กรมีเครื่องมือสนับสนุนการตัดสินใจ (Decision Support System) ที่พร้อมใช้งานจริงสำหรับการประเมินความเสี่ยงด้านสินเชื่อได้อย่างรวดเร็วและมีประสิทธิภาพ แสดงดังภาพที่ 3-3 และภาพที่ 3-4



ภาพที่ 3-3 แสดงโครงร่างการออกแบบส่วน User Interface



ภาพที่ 3-4 แสดงโครงสร้างการแสดงผลการพยากรณ์จากแบบจำลอง



บทที่ 4

ผลการดำเนินงานวิจัย

ผลการดำเนินงานวิจัยการพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง มีรายละเอียดดังต่อไปนี้

- 4.1 ผลการเก็บรวบรวม และจัดเตรียมข้อมูล
- 4.2 ผลการพัฒนา และทดสอบประสิทธิภาพของแบบจำลอง
- 4.3 ผลการนำแบบจำลองไปใช้งาน

4.1 ผลการเก็บรวบรวมข้อมูล

จากการเก็บรวบรวมข้อมูลทุติยภูมิ (Secondary Data) ของนิติบุคคลในประเทศไทย ครอบคลุมระยะเวลาบัญชี พ.ศ. 2565 - 2566 ผู้วิจัยได้รับชุดข้อมูลตั้งต้น (Raw Data) จำนวนทั้งสิ้น 13,218 รายการ จากนั้นนำมาผ่านกระบวนการจัดเตรียมข้อมูล (Data Preprocessing) ตามระเบียบวิธีวิจัยที่กำหนดไว้ในบทที่ 3 ซึ่งประกอบด้วยกระบวนการทำความสะอาดข้อมูล การจัดการค่าที่ขาดหาย การสร้างตัวแปรเชิงพลวัตและอัตราส่วนทางการเงิน (Feature Engineering) และการเข้ารหัสตัวแปรเชิงหมวดหมู่ (Label Encoding) จนได้ตัวแปรอิสระที่พร้อมใช้งานจำนวน 16 ตัวแปร และตัวแปรเป้าหมาย (Target Variable) 1 ตัวแปร เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลองและป้องกันปัญหาความเอนเอียง (Bias) ผู้วิจัยได้ดำเนินการสุ่มคัดเลือกและแบ่งข้อมูล (Data Splitting) ออกเป็น 2 ส่วนหลัก ได้แก่

4.1.1 ชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset): จำนวน 10,000 รายการ โดยผู้วิจัยได้ทำการจัดสัดส่วนของคลาสข้อมูลเป้าหมายให้มีความสมดุลอย่างสมบูรณ์แบบ (Perfectly Balanced Data) เพื่อนำเข้าสู่กระบวนการฝึกสอนอัลกอริทึม ดังแสดงสัดส่วนในตารางที่ 4-1

4.1.2 ชุดข้อมูลทดสอบอิสระ (Unseen Dataset): จำนวน 3,218 รายการ ถูกแยกเก็บไว้โดยไม่นำมารวมในกระบวนการฝึกสอนแบบจำลอง เพื่อใช้เป็นตัวแทนของข้อมูลจริงในการประเมินประสิทธิภาพขั้นสุดท้าย

ตารางที่ 4-1 จำนวนและร้อยละของนิติบุคคลในชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset)

สถานภาพการดำเนินการ (Target Variable)	จำนวน (ราย)	ร้อยละ (%)
คลาส 0 (Class 0): ไม่อยู่ในกลุ่มเลิกกิจการ	5,000	50.00
คลาส 1 (Class 1): เลิกกิจการ (กลุ่มเหตุการณ์)	5,000	50.00
รวมชุดข้อมูลสำหรับการพัฒนาแบบจำลอง	10,000	100.00

จากตารางที่ 4-1 พบว่า ชุดข้อมูลสำหรับการพัฒนาแบบจำลองประกอบด้วยนิติบุคคลที่ยังดำเนินการอยู่ (คลาส 0) และนิติบุคคลที่เลิกกิจการ (คลาส 1) ในสัดส่วนที่เท่ากัน คือ 50:50 ซึ่งเป็นสัดส่วนในอุดมคติสำหรับการจำแนกประเภทข้อมูลทางการเงิน เพื่อให้เห็นภาพโครงสร้างของชุดข้อมูลขั้นสุดท้าย (Final Dataset) ที่พร้อมนำเข้าสู่กระบวนการเรียนรู้ของเครื่อง ผู้วิจัยได้สุ่มดึงตัวอย่างข้อมูลจำนวน 20 รายการ (จากชุดข้อมูล 10,000 รายการ) ดังแสดงในตารางที่ 4-2 ทั้งนี้ ตัวแปรเชิงหมวดหมู่ทั้งหมดได้ถูกแปลงให้อยู่ในรูปแบบรหัสตัวเลข (Numerical Codes) เป็นที่เรียบร้อยแล้ว โดยอ้างอิงจากพจนานุกรมข้อมูล (Categorical Data Dictionary) ยกตัวอย่างเช่น ประเภทนิติบุคคล กำหนดให้ 0 = บริษัทจำกัด, 2 = ห้างหุ้นส่วนจำกัด และ ความเห็นผู้สอบบัญชี กำหนดให้ 0 = มีเงื่อนไข, 1 = ไม่มีข้อมูล, 2 = ไม่มีเงื่อนไข เป็นต้น

ตารางที่ 4-2 ตัวอย่างชุดข้อมูลสำหรับการพัฒนาแบบจำลองหลังผ่านกระบวนการจัดเตรียมข้อมูล

อายุกิจการ (ปี)	สินทรัพย์ (บาท)	หนี้สิน (บาท)	รายได้ (บาท)	กำไรสุทธิ (บาท)	ROE(%)	Growth สินทรัพย์	Growth หนี้สิน	Growth รายได้	Growth กำไร	Debt Ratio	Profit Margin	รหัสนิติบุคคล	รหัสTSIC	รหัสภาค	รหัสผู้สอบฯ	Target
7	10,755,562	4,541,806	14,575,137	1,704,695	27.43	0.15	-0.07	0.45	36.15	0.42	0.12	0	5	3	2	0
14	26,303,266	40,139,281	2,067,266	-2,087,904	-15.09	-0.03	0.03	0.29	0.28	1.53	-1.01	0	11	0	2	0
7	2,134,844	2,397,032	11,563,197	347,491	-132.54	-0.35	-0.39	0.45	1.39	1.12	0.03	0	8	6	0	0
12	13,676,717	15,190,977	6,480,315	1,032,391	-68.18	0.02	-0.05	0.23	-0.35	1.11	0.16	0	11	3	2	0
65	72,104,026	43,220,547	41,054,630	678,275	2.35	-0.13	-0.21	-0.22	-0.81	0.60	0.02	2	6	6	2	0
21	5,419,958	1,665,366	14,245,274	-356,964	-9.51	0.10	1.07	0.03	-2.09	0.31	-0.03	0	5	0	2	0
5	5,818,730	854,382	8,508,681	868,664	17.50	0.29	1.05	0.19	0.07	0.15	0.10	0	13	0	2	0
17	29,293,605	6,809,086	21,109,150	1,346,728	5.99	0.35	12.64	-0.36	-0.46	0.23	0.06	0	6	0	2	0
10	4,245,947	255,536	6,599,004	-1,320,666	-33.10	-0.24	-0.15	0.53	-14.16	0.06	-0.20	0	8	6	2	0
6	1,337,620	229,849	38,846,870	221,041	19.95	0.24	0.20	-0.46	0.56	0.17	0.01	0	6	0	2	0
10	247,695	201,838	531,968	123,246	268.76	1.54	0.15	0.08	0.17	0.81	0.23	0	16	6	2	1
11	3,011,875	8,000	0	-8,000	-0.27	0.00	0.00	2.50	0.19	0.00	-114.0	0	6	2	2	1
10	1,298,822	5,544	2,836	-1,664	-0.13	0.00	0.00	0.00	0.16	0.00	-0.59	2	6	3	1	1

ตารางที่ 4-2 (ต่อ)

อายุกิจการ (ปี)	สินทรัพย์ (บาท)	หนี้สิน (บาท)	รายได้ (บาท)	กำไรสุทธิ (บาท)	ROE(%)	Growth สินทรัพย์	Growth หนี้สิน	Growth รายได้	Growth กำไร	Debt Ratio	Profit Margin	รหัสนิติบุคคล	รหัสTSIC	รหัสภาค	รหัสผู้สอบฯ	Target
27	390,352	387,284	1,008,828	153,532	5004.06	-0.54	-0.61	84.05	1.15	0.99	0.15	2	5	0	1	1
11	123,613	657,606	3,445,001	-29,830	-5.59	-0.67	-0.25	-0.12	0.83	5.32	-0.01	0	6	0	2	1
27	4,733,230	9,874	80,000	-354,489	-7.51	-0.07	0.10	-0.33	-0.31	0.00	-4.43	0	12	0	2	1
6	53,118	10,000	61	-10,140	-23.52	-0.47	-0.78	0.20	0.04	0.19	-16.50	2	11	0	1	1
5	1,265,604	6,240	12,000	5,921	0.47	0.00	-0.22	-0.97	1.09	0.00	0.49	0	6	6	2	1
10	1,757,094	40,000	28,000	24,000	1.40	0.02	0.11	0.00	0.00	0.02	0.86	2	9	4	1	1
4	1,544,278	169,699	6,008	-314,112	-22.85	-0.17	0.00	0.59	-35.00	0.11	-52.28	0	3	0	2	1

จากตารางที่ 4.2 พบข้อสังเกตเบื้องต้นว่า กลุ่มนิติบุคคลที่เลิกกิจการ (คลาส 1) มักมีอัตราส่วนหนี้สิน (Debt Ratio) ที่สูงกว่า และมีอัตรากำไร (Profit Margin) รวมถึงอัตราการเติบโต (Growth) ที่ติดลบอย่างชัดเจนเมื่อเทียบกับกลุ่มที่ยังดำเนินกิจการ (คลาส 0) ซึ่งสะท้อนถึงปัญหาความเสี่ยงทางการเงิน ทั้งนี้ ชุดข้อมูลดังกล่าวทั้ง 10,000 รายการ ได้ผ่านการทำความสะอาดและแปลงเป็นรูปแบบตัวเลข (Numerical Format) อย่างสมบูรณ์ ซึ่งมีโครงสร้างที่พร้อมสำหรับการนำเข้าสู่กระบวนการฝึกสอนและเปรียบเทียบประสิทธิภาพของแบบจำลองในหัวข้อถัดไป

4.2 ผลการพัฒนา และทดสอบประสิทธิภาพของแบบจำลอง

หลังจากที่ผู้วิจัยได้นำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) มาประยุกต์ใช้ในการพยากรณ์ความเสี่ยงการเลิกกิจการของนิติบุคคล โดยประกอบด้วยแบบจำลอง 3 รูปแบบ ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) อัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (Light Gradient Boosting Machine: LightGBM) และโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network: DNN) รวมไปถึงการประยุกต์ใช้เทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning) ด้วยวิธีการลงคะแนนเสียงแบบยึดหยุ่น (Soft Voting) มาใช้ในการพัฒนาและประเมินประสิทธิภาพแบบจำลอง ในการปรับแต่งแบบจำลอง (Hyperparameter Tuning) ผู้วิจัยได้ดำเนินการกำหนดค่าพารามิเตอร์แบบคงที่และกำหนดขอบเขตของพารามิเตอร์แบบปรับแต่งได้ เพื่อค้นหาชุดพารามิเตอร์ที่ให้ประสิทธิภาพสูงสุด (Best Parameters) สำหรับแต่ละอัลกอริทึม โดยใช้เทคนิคการตรวจสอบความถูกต้องข้ามกลุ่มแบบ K-Fold (K-Fold Cross-validation) บนชุดข้อมูลสำหรับการพัฒนาแบบจำลองจำนวน 10,000 รายการ ทั้งนี้การเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละรูปแบบ จะถูกพิจารณาจากตัวชี้วัดผลทางสถิติ 4 ประการ ได้แก่ ค่าความถูกต้อง (Accuracy: A) ค่าความแม่นยำ (Precision: P) ค่าระลึก (Recall: R) และค่าการถ่วงดุล (F1-Score: F) โดยมีรายละเอียดดังนี้

4.2.1 การกำหนดพารามิเตอร์ ที่ใช้ในการทดสอบอัลกอริทึม แสดงดังตารางที่ 4-3 ถึง 4-6

ตารางที่ 4-3 ค่าพารามิเตอร์ของอัลกอริทึม Support Vector Machine

Algorithm	Parameter	Value
SVM	Kernel type	poly, rbf , linear, sigmoid
	C	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1
	Gamma	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1

จากตารางที่ 4-3 แสดงค่าพารามิเตอร์ของอัลกอริทึม SVM จำนวน 3 พารามิเตอร์ ได้แก่ พารามิเตอร์ Kernel type เท่ากับ poly, rbf , linear, sigmoid พารามิเตอร์ C เท่ากับ 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1 และพารามิเตอร์ Gamma เท่ากับ 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1

ตารางที่ 4-4 ค่าพารามิเตอร์ของอัลกอริทึม Light Gradient Boosting Machine

Algorithm	Parameter	Value
LightGBM	num_leaves	15, 31, 63
	min_child_samples	10, 20, 40
	max_depth	-1, 8
	learning_rate	0.05, 0.1
	n_estimators	100, 200, 300
	feature_fraction	0.8, 1.0
	reg_lambda	0.0, 0.1

จากตารางที่ 4-4 แสดงค่าพารามิเตอร์ของอัลกอริทึม LightGBM จำนวน 7 พารามิเตอร์ ได้แก่ พารามิเตอร์ num_leaves เท่ากับ 15, 31, 63 พารามิเตอร์ min_child_samples เท่ากับ 10, 20, 40 พารามิเตอร์ max_depth เท่ากับ -1, 8 พารามิเตอร์ learning_rate เท่ากับ 0.05, 0.1 พารามิเตอร์ n_estimators เท่ากับ 100, 200, 300 พารามิเตอร์ feature_fraction เท่ากับ 0.8, 1.0 และพารามิเตอร์ reg_lambda เท่ากับ 0.0, 0.1

ตารางที่ 4-5 ค่าพารามิเตอร์ของอัลกอริทึม Deep Neural Network

Algorithm	Parameter	Value
DNN	hidden_units	128, 64, 32
	dropout_rates	0.1, 0.1, 0.1; 0.3, 0.3, 0.2
	learning_rate	1e-3, 5e-4, 3e-4
	batch_size	256, 512
	epochs	100
	activation	ReLU
	use_bn	True
	l2	0.0, 1e-5, 1e-4

จากตารางที่ 4-5 แสดงค่าพารามิเตอร์ของอัลกอริทึม DNN จำนวน 8 พารามิเตอร์ ได้แก่ พารามิเตอร์ hidden_units เท่ากับ 128, 64, 32 พารามิเตอร์ dropout_rates เท่ากับ 0.1, 0.1, 0.1; 0.3, 0.3, 0.2 พารามิเตอร์ learning_rate เท่ากับ 1e-3, 5e-4, 3e-4 พารามิเตอร์ batch_size

เท่ากับ 256, 512 พารามิเตอร์ epochs เท่ากับ 100 พารามิเตอร์ activation เท่ากับ ReLU พารามิเตอร์ use_bn เท่ากับ True และพารามิเตอร์ l2 เท่ากับ 0.0, $1e-5$, $1e-4$

ตารางที่ 4-6 ค่าพารามิเตอร์ของเทคนิค Ensemble

Algorithm	Parameter
Ensemble Learning	Soft Voting

จากตาราง 4-6 กำหนดค่าพารามิเตอร์ของเทคนิค Ensemble Learning จำนวน 1 พารามิเตอร์ ได้แก่ พารามิเตอร์ Soft Voting

4.2.2 ผลลัพธ์การทดสอบประสิทธิภาพพิจารณาด้วยค่าความถูกต้อง ค่าความแม่นยำ ค่าระลึก และค่าการถ่วงดุล โดยปรับค่าพารามิเตอร์ของแต่ละอัลกอริทึมให้ได้ประสิทธิภาพที่ดีที่สุด แสดงดังตารางที่ 4-7 ถึง 4-9

ตารางที่ 4-7 ผลลัพธ์ของอัลกอริทึม Support Vector Machine

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
linear	0.1	0.1	69.02	0.74	0.59	0.66
linear	0.1	0.2	69.02	0.74	0.59	0.66
linear	0.1	0.3	69.02	0.74	0.59	0.66
linear	0.1	0.4	69.02	0.74	0.59	0.66
linear	0.1	0.5	69.02	0.74	0.59	0.66
linear	0.1	0.6	69.02	0.74	0.59	0.66
linear	0.1	0.7	69.02	0.74	0.59	0.66
linear	0.1	0.8	69.02	0.74	0.59	0.66
linear	0.1	0.9	69.02	0.74	0.59	0.66
linear	0.1	1	69.02	0.74	0.59	0.66
poly	0.1	0.1	64.46	0.97	0.30	0.46
poly	0.1	0.2	65.35	0.94	0.33	0.49
poly	0.1	0.3	66.36	0.90	0.37	0.52
poly	0.1	0.4	68.17	0.87	0.43	0.57
poly	0.1	0.5	71.99	0.85	0.54	0.66
poly	0.1	0.6	73.60	0.82	0.61	0.70
poly	0.1	0.7	74.27	0.81	0.63	0.71
poly	0.1	0.8	74.93	0.81	0.65	0.72
poly	0.1	0.9	75.39	0.81	0.66	0.73
poly	0.1	1	75.67	0.81	0.67	0.73
rbf	0.1	0.1	72.53	0.76	0.67	0.71
rbf	0.1	0.2	72.52	0.77	0.64	0.70
rbf	0.1	0.3	72.89	0.78	0.64	0.70
rbf	0.1	0.4	72.88	0.78	0.64	0.70

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
rbf	0.1	0.5	72.98	0.78	0.64	0.70
rbf	0.1	0.6	73.16	0.79	0.64	0.70
rbf	0.1	0.7	73.13	0.79	0.63	0.70
rbf	0.1	0.8	73.11	0.79	0.63	0.70
rbf	0.1	0.9	73.05	0.79	0.63	0.70
rbf	0.1	1	72.96	0.79	0.63	0.70
sigmoid	0.1	0.1	62.40	0.69	0.45	0.54
sigmoid	0.1	0.2	57.25	0.58	0.53	0.55
sigmoid	0.1	0.3	57.19	0.57	0.57	0.57
sigmoid	0.1	0.4	55.72	0.56	0.56	0.56
sigmoid	0.1	0.5	55.08	0.55	0.55	0.55
sigmoid	0.1	0.6	53.87	0.54	0.54	0.54
sigmoid	0.1	0.7	53.34	0.53	0.54	0.53
sigmoid	0.1	0.8	52.94	0.53	0.53	0.53
sigmoid	0.1	0.9	53.36	0.53	0.53	0.53
sigmoid	0.1	1	53.94	0.54	0.54	0.54
linear	0.2	0.1	70.16	0.74	0.63	0.68
linear	0.2	0.2	70.16	0.74	0.63	0.68
linear	0.2	0.3	70.16	0.74	0.63	0.68
linear	0.2	0.4	70.16	0.74	0.63	0.68
linear	0.2	0.5	70.16	0.74	0.63	0.68
linear	0.2	0.6	70.16	0.74	0.63	0.68
linear	0.2	0.7	70.16	0.74	0.63	0.68
linear	0.2	0.8	70.16	0.74	0.63	0.68
linear	0.2	0.9	70.16	0.74	0.63	0.68
linear	0.2	1	70.16	0.74	0.63	0.68
poly	0.2	0.1	64.99	0.96	0.31	0.47

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
poly	0.2	0.2	65.67	0.91	0.35	0.50
poly	0.2	0.3	67.68	0.88	0.41	0.56
poly	0.2	0.4	72.10	0.85	0.54	0.66
poly	0.2	0.5	73.85	0.81	0.62	0.70
poly	0.2	0.6	74.69	0.81	0.64	0.72
poly	0.2	0.7	75.29	0.81	0.66	0.73
poly	0.2	0.8	75.64	0.81	0.67	0.73
poly	0.2	0.9	75.88	0.81	0.67	0.74
poly	0.2	1	76.11	0.81	0.68	0.74
rbf	0.2	0.1	72.89	0.76	0.66	0.71
rbf	0.2	0.2	73.17	0.78	0.64	0.71
rbf	0.2	0.3	73.26	0.78	0.65	0.71
rbf	0.2	0.4	73.33	0.78	0.65	0.71
rbf	0.2	0.5	73.24	0.78	0.64	0.71
rbf	0.2	0.6	73.34	0.79	0.64	0.70
rbf	0.2	0.7	73.30	0.79	0.63	0.70
rbf	0.2	0.8	73.43	0.80	0.63	0.70
rbf	0.2	0.9	73.46	0.80	0.63	0.70
rbf	0.2	1	73.35	0.80	0.63	0.70
sigmoid	0.2	0.1	63.68	0.65	0.61	0.63
sigmoid	0.2	0.2	56.28	0.56	0.55	0.56
sigmoid	0.2	0.3	56.93	0.57	0.57	0.57
sigmoid	0.2	0.4	56.39	0.56	0.57	0.57
sigmoid	0.2	0.5	55.61	0.56	0.56	0.56
sigmoid	0.2	0.6	53.66	0.54	0.54	0.54
sigmoid	0.2	0.7	53.13	0.53	0.53	0.53
sigmoid	0.2	0.8	52.94	0.53	0.53	0.53

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
sigmoid	0.2	0.9	53.40	0.53	0.53	0.53
sigmoid	0.2	1	53.86	0.54	0.54	0.54
linear	0.3	0.1	70.99	0.73	0.66	0.69
linear	0.3	0.2	70.99	0.73	0.66	0.69
linear	0.3	0.3	70.99	0.73	0.66	0.69
linear	0.3	0.4	70.99	0.73	0.66	0.69
linear	0.3	0.5	70.99	0.73	0.66	0.69
linear	0.3	0.6	70.99	0.73	0.66	0.69
linear	0.3	0.7	70.99	0.73	0.66	0.69
linear	0.3	0.8	70.99	0.73	0.66	0.69
linear	0.3	0.9	70.99	0.73	0.66	0.69
linear	0.3	1	70.99	0.73	0.66	0.69
poly	0.3	0.1	65.00	0.95	0.32	0.47
poly	0.3	0.2	66.15	0.90	0.36	0.52
poly	0.3	0.3	69.48	0.87	0.46	0.60
poly	0.3	0.4	73.16	0.82	0.60	0.69
poly	0.3	0.5	74.49	0.81	0.64	0.71
poly	0.3	0.6	75.30	0.81	0.66	0.73
poly	0.3	0.7	75.64	0.81	0.67	0.73
poly	0.3	0.8	75.93	0.81	0.67	0.74
poly	0.3	0.9	76.25	0.82	0.68	0.74
poly	0.3	1	76.51	0.82	0.68	0.74
rbf	0.3	0.1	73.00	0.77	0.66	0.71
rbf	0.3	0.2	73.40	0.78	0.65	0.71
rbf	0.3	0.3	73.56	0.78	0.65	0.71
rbf	0.3	0.4	73.54	0.79	0.65	0.71
rbf	0.3	0.5	73.52	0.79	0.64	0.71

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
rbf	0.3	0.6	73.68	0.79	0.64	0.71
rbf	0.3	0.7	73.57	0.80	0.63	0.71
rbf	0.3	0.8	73.58	0.80	0.63	0.71
rbf	0.3	0.9	73.62	0.80	0.63	0.70
rbf	0.3	1	73.65	0.80	0.63	0.70
sigmoid	0.3	0.1	59.16	0.62	0.49	0.54
sigmoid	0.3	0.2	55.85	0.56	0.55	0.55
sigmoid	0.3	0.3	56.89	0.57	0.57	0.57
sigmoid	0.3	0.4	56.34	0.56	0.57	0.56
sigmoid	0.3	0.5	55.44	0.55	0.56	0.56
sigmoid	0.3	0.6	53.68	0.54	0.54	0.54
sigmoid	0.3	0.7	53.10	0.53	0.53	0.53
sigmoid	0.3	0.8	52.89	0.53	0.53	0.53
sigmoid	0.3	0.9	53.39	0.53	0.53	0.53
sigmoid	0.3	1	53.97	0.54	0.54	0.54
linear	0.4	0.1	71.22	0.73	0.68	0.70
linear	0.4	0.2	71.22	0.73	0.68	0.70
linear	0.4	0.3	71.22	0.73	0.68	0.70
linear	0.4	0.4	71.22	0.73	0.68	0.70
linear	0.4	0.5	71.22	0.73	0.68	0.70
linear	0.4	0.6	71.22	0.73	0.68	0.70
linear	0.4	0.7	71.22	0.73	0.68	0.70
linear	0.4	0.8	71.22	0.73	0.68	0.70
linear	0.4	0.9	71.22	0.73	0.68	0.70
linear	0.4	1	71.22	0.73	0.68	0.70
poly	0.4	0.1	65.05	0.95	0.32	0.48
poly	0.4	0.2	66.59	0.90	0.38	0.53

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
poly	0.4	0.3	71.40	0.86	0.51	0.64
poly	0.4	0.4	73.86	0.81	0.62	0.70
poly	0.4	0.5	74.93	0.81	0.65	0.72
poly	0.4	0.6	75.50	0.81	0.67	0.73
poly	0.4	0.7	75.84	0.81	0.67	0.74
poly	0.4	0.8	76.14	0.81	0.68	0.74
poly	0.4	0.9	76.52	0.82	0.68	0.74
poly	0.4	1	76.81	0.82	0.69	0.75
rbf	0.4	0.1	72.99	0.77	0.66	0.71
rbf	0.4	0.2	73.70	0.78	0.65	0.71
rbf	0.4	0.3	73.76	0.79	0.65	0.71
rbf	0.4	0.4	73.71	0.79	0.65	0.71
rbf	0.4	0.5	73.83	0.79	0.64	0.71
rbf	0.4	0.6	73.80	0.80	0.64	0.71
rbf	0.4	0.7	73.86	0.80	0.64	0.71
rbf	0.4	0.8	73.87	0.80	0.64	0.71
rbf	0.4	0.9	73.87	0.80	0.63	0.71
rbf	0.4	1	73.73	0.80	0.63	0.71
sigmoid	0.4	0.1	58.46	0.60	0.50	0.55
sigmoid	0.4	0.2	55.72	0.56	0.55	0.55
sigmoid	0.4	0.3	56.83	0.57	0.57	0.57
sigmoid	0.4	0.4	56.40	0.56	0.57	0.57
sigmoid	0.4	0.5	55.35	0.55	0.56	0.55
sigmoid	0.4	0.6	53.65	0.54	0.54	0.54
sigmoid	0.4	0.7	53.10	0.53	0.53	0.53
sigmoid	0.4	0.8	52.93	0.53	0.53	0.53
sigmoid	0.4	0.9	53.34	0.53	0.53	0.53

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
sigmoid	0.4	1	54.33	0.54	0.54	0.54
linear	0.5	0.1	71.69	0.73	0.69	0.71
linear	0.5	0.2	71.69	0.73	0.69	0.71
linear	0.5	0.3	71.69	0.73	0.69	0.71
linear	0.5	0.4	71.69	0.73	0.69	0.71
linear	0.5	0.5	71.69	0.73	0.69	0.71
linear	0.5	0.6	71.69	0.73	0.69	0.71
linear	0.5	0.7	71.69	0.73	0.69	0.71
linear	0.5	0.8	71.69	0.73	0.69	0.71
linear	0.5	0.9	71.69	0.73	0.69	0.71
linear	0.5	1	71.69	0.73	0.69	0.71
poly	0.5	0.1	65.15	0.95	0.32	0.48
poly	0.5	0.2	67.05	0.89	0.39	0.54
poly	0.5	0.3	72.25	0.84	0.55	0.66
poly	0.5	0.4	74.17	0.81	0.63	0.71
poly	0.5	0.5	75.21	0.81	0.66	0.73
poly	0.5	0.6	75.66	0.81	0.67	0.73
poly	0.5	0.7	76.02	0.81	0.68	0.74
poly	0.5	0.8	76.44	0.82	0.68	0.74
poly	0.5	0.9	76.63	0.82	0.69	0.75
poly	0.5	1	77.25	0.82	0.70	0.75
rbf	0.5	0.1	73.24	0.77	0.66	0.71
rbf	0.5	0.2	73.87	0.78	0.66	0.72
rbf	0.5	0.3	73.90	0.79	0.66	0.72
rbf	0.5	0.4	73.88	0.79	0.65	0.71
rbf	0.5	0.5	73.88	0.79	0.64	0.71
rbf	0.5	0.6	73.95	0.80	0.64	0.71

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
rbf	0.5	0.7	73.96	0.80	0.64	0.71
rbf	0.5	0.8	74.05	0.80	0.64	0.71
rbf	0.5	0.9	74.03	0.80	0.64	0.71
rbf	0.5	1	73.90	0.80	0.63	0.71
sigmoid	0.5	0.1	58.08	0.59	0.51	0.55
sigmoid	0.5	0.2	55.71	0.56	0.55	0.55
sigmoid	0.5	0.3	56.80	0.57	0.57	0.57
sigmoid	0.5	0.4	56.37	0.56	0.57	0.57
sigmoid	0.5	0.5	55.35	0.55	0.56	0.55
sigmoid	0.5	0.6	53.63	0.54	0.54	0.54
sigmoid	0.5	0.7	53.06	0.53	0.53	0.53
sigmoid	0.5	0.8	52.91	0.53	0.53	0.53
sigmoid	0.5	0.9	53.31	0.53	0.53	0.53
sigmoid	0.5	1	53.92	0.54	0.54	0.54
linear	0.6	0.1	72.05	0.73	0.71	0.72
linear	0.6	0.2	72.05	0.73	0.71	0.72
linear	0.6	0.3	72.05	0.73	0.71	0.72
linear	0.6	0.4	72.05	0.73	0.71	0.72
linear	0.6	0.5	72.05	0.73	0.71	0.72
linear	0.6	0.6	72.05	0.73	0.71	0.72
linear	0.6	0.7	72.05	0.73	0.71	0.72
linear	0.6	0.8	72.05	0.73	0.71	0.72
linear	0.6	0.9	72.05	0.73	0.71	0.72
linear	0.6	1	72.05	0.73	0.71	0.72
poly	0.6	0.1	65.10	0.94	0.32	0.48
poly	0.6	0.2	67.35	0.88	0.40	0.55
poly	0.6	0.3	72.94	0.83	0.58	0.68

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
poly	0.6	0.4	74.48	0.81	0.64	0.71
poly	0.6	0.5	75.39	0.81	0.66	0.73
poly	0.6	0.6	75.80	0.81	0.67	0.73
poly	0.6	0.7	76.16	0.82	0.68	0.74
poly	0.6	0.8	76.50	0.82	0.68	0.74
poly	0.6	0.9	76.93	0.82	0.69	0.75
poly	0.6	1	77.47	0.82	0.70	0.76
rbf	0.6	0.1	73.43	0.78	0.66	0.71
rbf	0.6	0.2	74.09	0.79	0.66	0.72
rbf	0.6	0.3	74.12	0.79	0.66	0.72
rbf	0.6	0.4	74.17	0.79	0.65	0.72
rbf	0.6	0.5	74.10	0.80	0.65	0.71
rbf	0.6	0.6	74.00	0.80	0.64	0.71
rbf	0.6	0.7	74.15	0.80	0.64	0.71
rbf	0.6	0.8	74.14	0.80	0.64	0.71
rbf	0.6	0.9	74.20	0.80	0.64	0.71
rbf	0.6	1	74.08	0.80	0.64	0.71
sigmoid	0.6	0.1	57.73	0.59	0.52	0.55
sigmoid	0.6	0.2	55.75	0.56	0.55	0.56
sigmoid	0.6	0.3	56.76	0.57	0.57	0.57
sigmoid	0.6	0.4	56.39	0.56	0.57	0.57
sigmoid	0.6	0.5	55.36	0.55	0.56	0.56
sigmoid	0.6	0.6	53.62	0.54	0.54	0.54
sigmoid	0.6	0.7	53.24	0.53	0.53	0.53
sigmoid	0.6	0.8	52.87	0.53	0.53	0.53
sigmoid	0.6	0.9	52.63	0.53	0.53	0.53
sigmoid	0.6	1	54.93	0.55	0.55	0.55

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
linear	0.7	0.1	72.18	0.72	0.72	0.72
linear	0.7	0.2	72.18	0.72	0.72	0.72
linear	0.7	0.3	72.18	0.72	0.72	0.72
linear	0.7	0.4	72.18	0.72	0.72	0.72
linear	0.7	0.5	72.18	0.72	0.72	0.72
linear	0.7	0.6	72.18	0.72	0.72	0.72
linear	0.7	0.7	72.18	0.72	0.72	0.72
linear	0.7	0.8	72.18	0.72	0.72	0.72
linear	0.7	0.9	72.18	0.72	0.72	0.72
linear	0.7	1	72.18	0.72	0.72	0.72
poly	0.7	0.1	65.26	0.94	0.33	0.48
poly	0.7	0.2	67.74	0.88	0.41	0.56
poly	0.7	0.3	73.17	0.82	0.59	0.69
poly	0.7	0.4	74.70	0.81	0.65	0.72
poly	0.7	0.5	75.51	0.81	0.66	0.73
poly	0.7	0.6	75.91	0.81	0.67	0.74
poly	0.7	0.7	76.39	0.82	0.68	0.74
poly	0.7	0.8	76.61	0.82	0.69	0.75
poly	0.7	0.9	77.27	0.82	0.70	0.75
poly	0.7	1	77.65	0.82	0.71	0.76
rbf	0.7	0.1	73.56	0.78	0.66	0.71
rbf	0.7	0.2	74.17	0.79	0.67	0.72
rbf	0.7	0.3	74.12	0.79	0.66	0.72
rbf	0.7	0.4	74.18	0.79	0.66	0.72
rbf	0.7	0.5	74.26	0.80	0.65	0.72
rbf	0.7	0.6	74.20	0.80	0.65	0.71
rbf	0.7	0.7	74.30	0.80	0.64	0.71

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
rbf	0.7	0.8	74.34	0.80	0.64	0.72
rbf	0.7	0.9	74.25	0.80	0.64	0.71
rbf	0.7	1	74.14	0.80	0.64	0.71
sigmoid	0.7	0.1	57.34	0.58	0.52	0.55
sigmoid	0.7	0.2	55.73	0.56	0.55	0.56
sigmoid	0.7	0.3	55.74	0.56	0.56	0.56
sigmoid	0.7	0.4	56.34	0.56	0.57	0.57
sigmoid	0.7	0.5	55.37	0.55	0.56	0.55
sigmoid	0.7	0.6	53.62	0.54	0.54	0.54
sigmoid	0.7	0.7	53.20	0.53	0.53	0.53
sigmoid	0.7	0.8	52.87	0.53	0.53	0.53
sigmoid	0.7	0.9	52.63	0.53	0.53	0.53
sigmoid	0.7	1	54.91	0.55	0.55	0.55
linear	0.8	0.1	72.59	0.72	0.73	0.73
linear	0.8	0.2	72.59	0.72	0.73	0.73
linear	0.8	0.3	72.59	0.72	0.73	0.73
linear	0.8	0.4	72.59	0.72	0.73	0.73
linear	0.8	0.5	72.59	0.72	0.73	0.73
linear	0.8	0.6	72.59	0.72	0.73	0.73
linear	0.8	0.7	72.59	0.72	0.73	0.73
linear	0.8	0.8	72.59	0.72	0.73	0.73
linear	0.8	0.9	72.59	0.72	0.73	0.73
linear	0.8	1	72.59	0.72	0.73	0.73
poly	0.8	0.1	65.35	0.94	0.33	0.49
poly	0.8	0.2	68.17	0.87	0.43	0.57
poly	0.8	0.3	73.60	0.82	0.61	0.70
poly	0.8	0.4	74.93	0.81	0.65	0.72

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
poly	0.8	0.5	75.67	0.81	0.67	0.73
poly	0.8	0.6	76.01	0.81	0.68	0.74
poly	0.8	0.7	76.47	0.82	0.68	0.74
poly	0.8	0.8	76.82	0.82	0.69	0.75
poly	0.8	0.9	77.42	0.82	0.70	0.76
poly	0.8	1	77.84	0.82	0.71	0.76
rbf	0.8	0.1	73.66	0.78	0.66	0.71
rbf	0.8	0.2	74.19	0.79	0.67	0.72
rbf	0.8	0.3	74.27	0.79	0.66	0.72
rbf	0.8	0.4	74.39	0.79	0.66	0.72
rbf	0.8	0.5	74.42	0.80	0.65	0.72
rbf	0.8	0.6	74.46	0.80	0.65	0.72
rbf	0.8	0.7	74.53	0.81	0.65	0.72
rbf	0.8	0.8	74.36	0.80	0.65	0.72
rbf	0.8	0.9	74.33	0.80	0.64	0.71
rbf	0.8	1	74.24	0.80	0.64	0.71
sigmoid	0.8	0.1	57.33	0.58	0.54	0.56
sigmoid	0.8	0.2	55.62	0.56	0.55	0.56
sigmoid	0.8	0.3	56.73	0.57	0.57	0.57
sigmoid	0.8	0.4	56.32	0.56	0.57	0.57
sigmoid	0.8	0.5	55.38	0.55	0.56	0.56
sigmoid	0.8	0.6	53.61	0.54	0.54	0.54
sigmoid	0.8	0.7	53.21	0.53	0.53	0.53
sigmoid	0.8	0.8	52.83	0.53	0.53	0.53
sigmoid	0.8	0.9	53.28	0.53	0.53	0.53
sigmoid	0.8	1	56.42	0.56	0.57	0.56
linear	0.9	0.1	72.69	0.72	0.74	0.73

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
linear	0.9	0.2	72.69	0.72	0.74	0.73
linear	0.9	0.3	72.69	0.72	0.74	0.73
linear	0.9	0.4	72.69	0.72	0.74	0.73
linear	0.9	0.5	72.69	0.72	0.74	0.73
linear	0.9	0.6	72.69	0.72	0.74	0.73
linear	0.9	0.7	72.69	0.72	0.74	0.73
linear	0.9	0.8	72.69	0.72	0.74	0.73
linear	0.9	0.9	72.69	0.72	0.74	0.73
linear	0.9	1	72.69	0.72	0.74	0.73
poly	0.9	0.1	65.36	0.93	0.33	0.49
poly	0.9	0.2	68.83	0.88	0.44	0.58
poly	0.9	0.3	73.76	0.81	0.62	0.70
poly	0.9	0.4	75.08	0.81	0.66	0.73
poly	0.9	0.5	75.61	0.81	0.67	0.73
poly	0.9	0.6	76.09	0.81	0.68	0.74
poly	0.9	0.7	76.51	0.82	0.68	0.74
poly	0.9	0.8	77.05	0.82	0.70	0.75
poly	0.9	0.9	77.64	0.82	0.71	0.76
poly	0.9	1	78.03	0.82	0.72	0.77
rbf	0.9	0.1	73.79	0.78	0.66	0.71
rbf	0.9	0.2	74.37	0.79	0.67	0.72
rbf	0.9	0.3	74.42	0.79	0.66	0.72
rbf	0.9	0.4	74.59	0.80	0.66	0.72
rbf	0.9	0.5	74.48	0.80	0.66	0.72
rbf	0.9	0.6	74.62	0.80	0.65	0.72
rbf	0.9	0.7	74.58	0.81	0.65	0.72
rbf	0.9	0.8	74.45	0.80	0.65	0.72

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
rbf	0.9	0.9	74.41	0.81	0.64	0.72
rbf	0.9	1	74.42	0.81	0.64	0.72
sigmoid	0.9	0.1	57.31	0.58	0.54	0.56
sigmoid	0.9	0.2	55.56	0.56	0.55	0.56
sigmoid	0.9	0.3	56.77	0.57	0.57	0.57
sigmoid	0.9	0.4	56.29	0.56	0.57	0.56
sigmoid	0.9	0.5	55.38	0.55	0.56	0.56
sigmoid	0.9	0.6	53.62	0.54	0.54	0.54
sigmoid	0.9	0.7	53.20	0.53	0.53	0.53
sigmoid	0.9	0.8	52.84	0.53	0.53	0.53
sigmoid	0.9	0.9	53.26	0.53	0.53	0.53
sigmoid	0.9	1	56.38	0.56	0.57	0.56
linear	1	0.1	72.92	0.72	0.75	0.73
linear	1	0.2	72.92	0.72	0.75	0.73
linear	1	0.3	72.92	0.72	0.75	0.73
linear	1	0.4	72.92	0.72	0.75	0.73
linear	1	0.5	72.92	0.72	0.75	0.73
linear	1	0.6	72.92	0.72	0.75	0.73
linear	1	0.7	72.92	0.72	0.75	0.73
linear	1	0.8	72.92	0.72	0.75	0.73
linear	1	0.9	72.92	0.72	0.75	0.73
linear	1	1	72.92	0.72	0.75	0.73
poly	1	0.1	65.43	0.93	0.33	0.49
poly	1	0.2	69.39	0.87	0.46	0.60
poly	1	0.3	73.98	0.81	0.62	0.70
poly	1	0.4	75.25	0.81	0.66	0.73
poly	1	0.5	75.75	0.81	0.67	0.73

ตารางที่ 4-7 (ต่อ)

Parameter			Performance			
Kernel	C	Gamma	Accuracy(%)	Precision	Recall	F1
poly	1	0.6	76.24	0.82	0.68	0.74
poly	1	0.7	76.59	0.82	0.69	0.75
poly	1	0.8	77.26	0.82	0.70	0.75
poly	1	0.9	77.71	0.82	0.71	0.76
poly	1	1	78.06	0.82	0.72	0.77
rbf	1	0.1	73.92	0.79	0.66	0.72
rbf	1	0.2	74.37	0.79	0.67	0.72
rbf	1	0.3	74.55	0.79	0.66	0.72
rbf	1	0.4	74.66	0.80	0.66	0.72
rbf	1	0.5	74.65	0.80	0.66	0.72
rbf	1	0.6	74.62	0.80	0.66	0.72
rbf	1	0.7	74.65	0.80	0.65	0.72
rbf	1	0.8	74.55	0.81	0.65	0.72
rbf	1	0.9	74.43	0.81	0.64	0.72
rbf	1	1	74.42	0.81	0.64	0.72
sigmoid	1	0.1	57.15	0.58	0.54	0.56
sigmoid	1	0.2	55.51	0.56	0.55	0.55
sigmoid	1	0.3	56.78	0.57	0.57	0.57
sigmoid	1	0.4	56.32	0.56	0.57	0.56
sigmoid	1	0.5	55.37	0.55	0.56	0.56
sigmoid	1	0.6	53.74	0.54	0.54	0.54
sigmoid	1	0.7	53.17	0.53	0.53	0.53
sigmoid	1	0.8	52.83	0.53	0.53	0.53
sigmoid	1	0.9	53.26	0.53	0.53	0.53
sigmoid	1	1	55.29	0.55	0.55	0.55

จากตาราง 4-7 พบว่าค่าพารามิเตอร์ของ Support Vector Machine ที่ให้ประสิทธิภาพดีที่สุด คือพารามิเตอร์ Kernels เท่ากับ poly พารามิเตอร์ C เท่ากับ 1 และพารามิเตอร์ Gamma เท่ากับ 1 โดยให้ค่าความถูกต้องเท่ากับร้อยละ 78.1 ค่าความแม่นยำเท่ากับ 0.82 ค่าระลึกเท่ากับ 0.72 และค่าการถ่วงดุลเท่ากับ 0.77 ตามลำดับ



ตารางที่ 4-8 ผลลัพธ์ของอัลกอริทึม Light Gradient Boosting Machine

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	-1	0.05	100	0.8	0	93.85	0.96	0.92	0.94
15	10	-1	0.05	100	0.8	0.1	93.91	0.96	0.92	0.94
31	10	-1	0.05	100	0.8	0	93.79	0.95	0.92	0.94
31	10	-1	0.05	100	0.8	0.1	93.83	0.96	0.92	0.94
63	10	-1	0.05	100	0.8	0	93.76	0.95	0.92	0.94
63	10	-1	0.05	100	0.8	0.1	93.79	0.95	0.92	0.94
15	10	-1	0.05	200	0.8	0	93.98	0.96	0.92	0.94
15	10	-1	0.05	200	0.8	0.1	93.99	0.96	0.92	0.94
31	10	-1	0.05	200	0.8	0	93.99	0.95	0.92	0.94
31	10	-1	0.05	200	0.8	0.1	93.94	0.96	0.92	0.94
63	10	-1	0.05	200	0.8	0	93.98	0.96	0.92	0.94
63	10	-1	0.05	200	0.8	0.1	93.90	0.96	0.92	0.94
<u>15</u>	<u>10</u>	<u>-1</u>	<u>0.05</u>	<u>300</u>	<u>0.8</u>	<u>0</u>	<u>94.12</u>	<u>0.96</u>	<u>0.92</u>	<u>0.94</u>
15	10	-1	0.05	300	0.8	0.1	94.08	0.96	0.92	0.94
31	10	-1	0.05	300	0.8	0	94.02	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	10	-1	0.05	300	0.8	0.1	93.91	0.95	0.92	0.94
63	10	-1	0.05	300	0.8	0	93.93	0.96	0.92	0.94
63	10	-1	0.05	300	0.8	0.1	93.82	0.95	0.92	0.94
15	20	-1	0.05	100	0.8	0	93.77	0.96	0.92	0.94
15	20	-1	0.05	100	0.8	0.1	93.71	0.95	0.92	0.94
31	20	-1	0.05	100	0.8	0	93.80	0.95	0.92	0.94
31	20	-1	0.05	100	0.8	0.1	93.80	0.96	0.92	0.94
63	20	-1	0.05	100	0.8	0	93.79	0.95	0.92	0.94
63	20	-1	0.05	100	0.8	0.1	93.81	0.95	0.92	0.94
15	20	-1	0.05	200	0.8	0	93.89	0.96	0.92	0.94
15	20	-1	0.05	200	0.8	0.1	93.88	0.96	0.92	0.94
31	20	-1	0.05	200	0.8	0	93.93	0.95	0.92	0.94
31	20	-1	0.05	200	0.8	0.1	93.89	0.95	0.92	0.94
63	20	-1	0.05	200	0.8	0	93.98	0.96	0.92	0.94
63	20	-1	0.05	200	0.8	0.1	93.80	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	20	-1	0.05	300	0.8	0	93.76	0.95	0.92	0.94
15	20	-1	0.05	300	0.8	0.1	93.85	0.96	0.92	0.94
31	20	-1	0.05	300	0.8	0	93.97	0.96	0.92	0.94
31	20	-1	0.05	300	0.8	0.1	93.86	0.96	0.92	0.94
63	20	-1	0.05	300	0.8	0	93.89	0.96	0.92	0.94
63	20	-1	0.05	300	0.8	0.1	93.91	0.95	0.92	0.94
15	40	-1	0.05	100	0.8	0	93.88	0.96	0.92	0.94
15	40	-1	0.05	100	0.8	0.1	93.88	0.96	0.92	0.94
31	40	-1	0.05	100	0.8	0	93.88	0.96	0.92	0.94
31	40	-1	0.05	100	0.8	0.1	93.92	0.95	0.92	0.94
63	40	-1	0.05	100	0.8	0	93.79	0.95	0.92	0.94
63	40	-1	0.05	100	0.8	0.1	93.85	0.95	0.92	0.94
15	40	-1	0.05	200	0.8	0	94.01	0.96	0.92	0.94
15	40	-1	0.05	200	0.8	0.1	93.98	0.96	0.92	0.94
31	40	-1	0.05	200	0.8	0	93.84	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	40	-1	0.05	200	0.8	0.1	93.81	0.95	0.92	0.94
63	40	-1	0.05	200	0.8	0	93.89	0.96	0.92	0.94
63	40	-1	0.05	200	0.8	0.1	93.88	0.96	0.92	0.94
15	40	-1	0.05	300	0.8	0	93.92	0.95	0.92	0.94
15	40	-1	0.05	300	0.8	0.1	93.95	0.96	0.92	0.94
31	40	-1	0.05	300	0.8	0	93.84	0.95	0.92	0.94
31	40	-1	0.05	300	0.8	0.1	93.83	0.95	0.92	0.94
63	40	-1	0.05	300	0.8	0	93.89	0.95	0.92	0.94
63	40	-1	0.05	300	0.8	0.1	93.84	0.96	0.92	0.94
15	10	8	0.05	100	0.8	0	93.81	0.96	0.92	0.94
15	10	8	0.05	100	0.8	0.1	93.89	0.96	0.92	0.94
31	10	8	0.05	100	0.8	0	93.75	0.95	0.92	0.94
31	10	8	0.05	100	0.8	0.1	93.85	0.96	0.92	0.94
63	10	8	0.05	100	0.8	0	93.84	0.96	0.92	0.94
63	10	8	0.05	100	0.8	0.1	93.81	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	8	0.05	200	0.8	0	93.95	0.96	0.92	0.94
15	10	8	0.05	200	0.8	0.1	94.03	0.96	0.92	0.94
31	10	8	0.05	200	0.8	0	93.90	0.95	0.92	0.94
31	10	8	0.05	200	0.8	0.1	93.89	0.95	0.92	0.94
63	10	8	0.05	200	0.8	0	93.89	0.95	0.92	0.94
63	10	8	0.05	200	0.8	0.1	93.94	0.95	0.92	0.94
15	10	8	0.05	300	0.8	0	94.00	0.96	0.92	0.94
15	10	8	0.05	300	0.8	0.1	93.94	0.96	0.92	0.94
31	10	8	0.05	300	0.8	0	93.94	0.95	0.92	0.94
31	10	8	0.05	300	0.8	0.1	93.91	0.95	0.92	0.94
63	10	8	0.05	300	0.8	0	93.75	0.95	0.92	0.94
63	10	8	0.05	300	0.8	0.1	93.84	0.95	0.92	0.94
15	20	8	0.05	100	0.8	0	93.70	0.95	0.92	0.94
15	20	8	0.05	100	0.8	0.1	93.74	0.95	0.92	0.94
31	20	8	0.05	100	0.8	0	93.90	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	20	8	0.05	100	0.8	0.1	93.85	0.96	0.92	0.94
63	20	8	0.05	100	0.8	0	93.90	0.96	0.92	0.94
63	20	8	0.05	100	0.8	0.1	93.88	0.96	0.92	0.94
15	20	8	0.05	200	0.8	0	93.96	0.96	0.92	0.94
15	20	8	0.05	200	0.8	0.1	93.96	0.96	0.92	0.94
31	20	8	0.05	200	0.8	0	93.92	0.95	0.92	0.94
31	20	8	0.05	200	0.8	0.1	94.00	0.95	0.92	0.94
63	20	8	0.05	200	0.8	0	93.89	0.95	0.92	0.94
63	20	8	0.05	200	0.8	0.1	93.95	0.95	0.92	0.94
15	20	8	0.05	300	0.8	0	93.96	0.96	0.92	0.94
15	20	8	0.05	300	0.8	0.1	93.93	0.95	0.92	0.94
31	20	8	0.05	300	0.8	0	93.91	0.95	0.92	0.94
31	20	8	0.05	300	0.8	0.1	93.95	0.95	0.92	0.94
63	20	8	0.05	300	0.8	0	93.86	0.95	0.92	0.94
63	20	8	0.05	300	0.8	0.1	93.91	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	40	8	0.05	100	0.8	0	93.83	0.96	0.92	0.94
15	40	8	0.05	100	0.8	0.1	93.82	0.95	0.92	0.94
31	40	8	0.05	100	0.8	0	93.87	0.96	0.92	0.94
31	40	8	0.05	100	0.8	0.1	93.83	0.96	0.92	0.94
63	40	8	0.05	100	0.8	0	93.87	0.96	0.92	0.94
63	40	8	0.05	100	0.8	0.1	93.88	0.96	0.92	0.94
15	40	8	0.05	200	0.8	0	94.02	0.96	0.92	0.94
15	40	8	0.05	200	0.8	0.1	93.95	0.95	0.92	0.94
31	40	8	0.05	200	0.8	0	93.93	0.95	0.92	0.94
31	40	8	0.05	200	0.8	0.1	93.94	0.96	0.92	0.94
63	40	8	0.05	200	0.8	0	93.87	0.95	0.92	0.94
63	40	8	0.05	200	0.8	0.1	93.94	0.95	0.92	0.94
15	40	8	0.05	300	0.8	0	94.04	0.96	0.92	0.94
15	40	8	0.05	300	0.8	0.1	93.96	0.95	0.92	0.94
31	40	8	0.05	300	0.8	0	93.85	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	40	8	0.05	300	0.8	0.1	93.67	0.95	0.92	0.94
63	40	8	0.05	300	0.8	0	93.72	0.95	0.92	0.94
63	40	8	0.05	300	0.8	0.1	93.88	0.95	0.92	0.94
15	10	-1	0.1	100	0.8	0	93.96	0.96	0.92	0.94
15	10	-1	0.1	100	0.8	0.1	94.02	0.96	0.92	0.94
31	10	-1	0.1	100	0.8	0	93.72	0.95	0.92	0.94
31	10	-1	0.1	100	0.8	0.1	93.96	0.95	0.92	0.94
63	10	-1	0.1	100	0.8	0	93.94	0.96	0.92	0.94
63	10	-1	0.1	100	0.8	0.1	93.84	0.95	0.92	0.94
15	10	-1	0.1	200	0.8	0	93.92	0.95	0.92	0.94
15	10	-1	0.1	200	0.8	0.1	93.87	0.95	0.92	0.94
31	10	-1	0.1	200	0.8	0	93.84	0.95	0.92	0.94
31	10	-1	0.1	200	0.8	0.1	93.87	0.95	0.92	0.94
63	10	-1	0.1	200	0.8	0	93.98	0.96	0.92	0.94
63	10	-1	0.1	200	0.8	0.1	93.74	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	-1	0.1	300	0.8	0	93.86	0.95	0.92	0.94
15	10	-1	0.1	300	0.8	0.1	93.86	0.95	0.92	0.94
31	10	-1	0.1	300	0.8	0	93.79	0.95	0.92	0.94
31	10	-1	0.1	300	0.8	0.1	93.88	0.95	0.92	0.94
63	10	-1	0.1	300	0.8	0	93.98	0.96	0.92	0.94
63	10	-1	0.1	300	0.8	0.1	93.79	0.95	0.92	0.94
15	20	-1	0.1	100	0.8	0	94.01	0.96	0.92	0.94
15	20	-1	0.1	100	0.8	0.1	93.90	0.96	0.92	0.94
31	20	-1	0.1	100	0.8	0	93.96	0.96	0.92	0.94
31	20	-1	0.1	100	0.8	0.1	93.94	0.95	0.92	0.94
63	20	-1	0.1	100	0.8	0	93.88	0.95	0.92	0.94
63	20	-1	0.1	100	0.8	0.1	93.72	0.95	0.92	0.94
15	20	-1	0.1	200	0.8	0	94.01	0.96	0.92	0.94
15	20	-1	0.1	200	0.8	0.1	93.80	0.95	0.92	0.94
31	20	-1	0.1	200	0.8	0	93.91	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	20	-1	0.1	200	0.8	0.1	93.84	0.95	0.92	0.94
63	20	-1	0.1	200	0.8	0	94.00	0.96	0.92	0.94
63	20	-1	0.1	200	0.8	0.1	93.85	0.96	0.92	0.94
15	20	-1	0.1	300	0.8	0	93.92	0.95	0.92	0.94
15	20	-1	0.1	300	0.8	0.1	93.80	0.95	0.92	0.94
31	20	-1	0.1	300	0.8	0	93.83	0.95	0.92	0.94
31	20	-1	0.1	300	0.8	0.1	93.90	0.95	0.92	0.94
63	20	-1	0.1	300	0.8	0	93.91	0.96	0.92	0.94
63	20	-1	0.1	300	0.8	0.1	93.94	0.96	0.92	0.94
15	40	-1	0.1	100	0.8	0	93.99	0.96	0.92	0.94
15	40	-1	0.1	100	0.8	0.1	93.88	0.95	0.92	0.94
31	40	-1	0.1	100	0.8	0	93.87	0.95	0.92	0.94
31	40	-1	0.1	100	0.8	0.1	93.89	0.95	0.92	0.94
63	40	-1	0.1	100	0.8	0	93.78	0.95	0.92	0.94
63	40	-1	0.1	100	0.8	0.1	93.92	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	40	-1	0.1	200	0.8	0	93.81	0.95	0.92	0.94
15	40	-1	0.1	200	0.8	0.1	93.96	0.96	0.92	0.94
31	40	-1	0.1	200	0.8	0	93.73	0.95	0.92	0.94
31	40	-1	0.1	200	0.8	0.1	93.76	0.95	0.92	0.94
63	40	-1	0.1	200	0.8	0	93.85	0.95	0.92	0.94
63	40	-1	0.1	200	0.8	0.1	93.90	0.96	0.92	0.94
15	40	-1	0.1	300	0.8	0	93.86	0.95	0.92	0.94
15	40	-1	0.1	300	0.8	0.1	93.82	0.95	0.92	0.94
31	40	-1	0.1	300	0.8	0	93.67	0.95	0.92	0.94
31	40	-1	0.1	300	0.8	0.1	93.82	0.95	0.92	0.94
63	40	-1	0.1	300	0.8	0	93.84	0.95	0.92	0.94
63	40	-1	0.1	300	0.8	0.1	93.94	0.96	0.92	0.94
15	10	8	0.1	100	0.8	0	93.88	0.96	0.92	0.94
15	10	8	0.1	100	0.8	0.1	93.95	0.96	0.92	0.94
31	10	8	0.1	100	0.8	0	93.87	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	10	8	0.1	100	0.8	0.1	93.80	0.95	0.92	0.94
63	10	8	0.1	100	0.8	0	93.94	0.95	0.92	0.94
63	10	8	0.1	100	0.8	0.1	93.91	0.95	0.92	0.94
15	10	8	0.1	200	0.8	0	93.80	0.95	0.92	0.94
15	10	8	0.1	200	0.8	0.1	93.82	0.95	0.92	0.94
31	10	8	0.1	200	0.8	0	93.82	0.95	0.92	0.94
31	10	8	0.1	200	0.8	0.1	93.77	0.95	0.92	0.94
63	10	8	0.1	200	0.8	0	93.83	0.95	0.92	0.94
63	10	8	0.1	200	0.8	0.1	93.85	0.95	0.92	0.94
15	10	8	0.1	300	0.8	0	93.80	0.95	0.92	0.94
15	10	8	0.1	300	0.8	0.1	93.68	0.95	0.92	0.94
31	10	8	0.1	300	0.8	0	93.86	0.95	0.92	0.94
31	10	8	0.1	300	0.8	0.1	93.82	0.95	0.92	0.94
63	10	8	0.1	300	0.8	0	93.72	0.95	0.92	0.94
63	10	8	0.1	300	0.8	0.1	93.98	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	20	8	0.1	100	0.8	0	94.02	0.96	0.92	0.94
15	20	8	0.1	100	0.8	0.1	94.06	0.96	0.92	0.94
31	20	8	0.1	100	0.8	0	93.85	0.95	0.92	0.94
31	20	8	0.1	100	0.8	0.1	93.94	0.95	0.92	0.94
63	20	8	0.1	100	0.8	0	93.83	0.95	0.92	0.94
63	20	8	0.1	100	0.8	0.1	93.87	0.95	0.92	0.94
15	20	8	0.1	200	0.8	0	93.90	0.95	0.92	0.94
15	20	8	0.1	200	0.8	0.1	93.99	0.95	0.92	0.94
31	20	8	0.1	200	0.8	0	93.89	0.95	0.92	0.94
31	20	8	0.1	200	0.8	0.1	93.87	0.95	0.92	0.94
63	20	8	0.1	200	0.8	0	93.87	0.95	0.92	0.94
63	20	8	0.1	200	0.8	0.1	93.86	0.95	0.92	0.94
15	20	8	0.1	300	0.8	0	93.71	0.95	0.92	0.94
15	20	8	0.1	300	0.8	0.1	93.91	0.95	0.92	0.94
31	20	8	0.1	300	0.8	0	93.90	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	20	8	0.1	300	0.8	0.1	93.85	0.95	0.92	0.94
63	20	8	0.1	300	0.8	0	93.87	0.95	0.92	0.94
63	20	8	0.1	300	0.8	0.1	93.75	0.95	0.92	0.94
15	40	8	0.1	100	0.8	0	94.03	0.96	0.92	0.94
15	40	8	0.1	100	0.8	0.1	93.91	0.95	0.92	0.94
31	40	8	0.1	100	0.8	0	93.86	0.95	0.92	0.94
31	40	8	0.1	100	0.8	0.1	93.87	0.95	0.92	0.94
63	40	8	0.1	100	0.8	0	93.92	0.95	0.92	0.94
63	40	8	0.1	100	0.8	0.1	93.79	0.95	0.92	0.94
15	40	8	0.1	200	0.8	0	93.93	0.95	0.92	0.94
15	40	8	0.1	200	0.8	0.1	93.90	0.95	0.92	0.94
31	40	8	0.1	200	0.8	0	93.87	0.95	0.92	0.94
31	40	8	0.1	200	0.8	0.1	93.79	0.95	0.92	0.94
63	40	8	0.1	200	0.8	0	93.78	0.95	0.92	0.94
63	40	8	0.1	200	0.8	0.1	93.86	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	40	8	0.1	300	0.8	0	93.94	0.95	0.92	0.94
15	40	8	0.1	300	0.8	0.1	93.89	0.95	0.92	0.94
31	40	8	0.1	300	0.8	0	93.78	0.95	0.92	0.94
31	40	8	0.1	300	0.8	0.1	93.80	0.95	0.92	0.94
63	40	8	0.1	300	0.8	0	93.72	0.95	0.92	0.94
63	40	8	0.1	300	0.8	0.1	93.78	0.95	0.92	0.94
15	10	-1	0.05	100	1	0	93.83	0.96	0.92	0.94
15	10	-1	0.05	100	1	0.1	93.78	0.96	0.92	0.94
31	10	-1	0.05	100	1	0	93.72	0.95	0.92	0.94
31	10	-1	0.05	100	1	0.1	93.75	0.95	0.92	0.94
63	10	-1	0.05	100	1	0	93.79	0.95	0.92	0.94
63	10	-1	0.05	100	1	0.1	93.85	0.96	0.92	0.94
15	10	-1	0.05	200	1	0	93.87	0.96	0.92	0.94
15	10	-1	0.05	200	1	0.1	93.81	0.95	0.92	0.94
31	10	-1	0.05	200	1	0	93.89	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	10	-1	0.05	200	1	0.1	93.74	0.95	0.92	0.94
63	10	-1	0.05	200	1	0	93.93	0.96	0.92	0.94
63	10	-1	0.05	200	1	0.1	93.95	0.96	0.92	0.94
15	10	-1	0.05	300	1	0	93.82	0.95	0.92	0.94
15	10	-1	0.05	300	1	0.1	93.78	0.95	0.92	0.94
31	10	-1	0.05	300	1	0	93.80	0.95	0.92	0.94
31	10	-1	0.05	300	1	0.1	93.81	0.95	0.92	0.94
63	10	-1	0.05	300	1	0	93.94	0.96	0.92	0.94
63	10	-1	0.05	300	1	0.1	93.91	0.96	0.92	0.94
15	20	-1	0.05	100	1	0	93.74	0.96	0.92	0.94
15	20	-1	0.05	100	1	0.1	93.72	0.95	0.92	0.94
31	20	-1	0.05	100	1	0	93.80	0.96	0.92	0.94
31	20	-1	0.05	100	1	0.1	93.83	0.96	0.92	0.94
63	20	-1	0.05	100	1	0	93.74	0.95	0.92	0.94
63	20	-1	0.05	100	1	0.1	93.85	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	20	-1	0.05	200	1	0	93.82	0.95	0.92	0.94
15	20	-1	0.05	200	1	0.1	93.88	0.96	0.92	0.94
31	20	-1	0.05	200	1	0	93.82	0.96	0.92	0.94
31	20	-1	0.05	200	1	0.1	93.85	0.95	0.92	0.94
63	20	-1	0.05	200	1	0	93.74	0.95	0.92	0.94
63	20	-1	0.05	200	1	0.1	93.87	0.96	0.92	0.94
15	20	-1	0.05	300	1	0	93.77	0.95	0.92	0.94
15	20	-1	0.05	300	1	0.1	93.87	0.95	0.92	0.94
31	20	-1	0.05	300	1	0	93.80	0.96	0.92	0.94
31	20	-1	0.05	300	1	0.1	93.73	0.95	0.92	0.94
63	20	-1	0.05	300	1	0	93.73	0.95	0.92	0.94
63	20	-1	0.05	300	1	0.1	93.74	0.95	0.92	0.94
15	40	-1	0.05	100	1	0	93.76	0.96	0.92	0.94
15	40	-1	0.05	100	1	0.1	93.76	0.95	0.92	0.94
31	40	-1	0.05	100	1	0	93.77	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	40	-1	0.05	100	1	0.1	93.76	0.95	0.92	0.94
63	40	-1	0.05	100	1	0	93.74	0.95	0.92	0.94
63	40	-1	0.05	100	1	0.1	93.93	0.96	0.92	0.94
15	40	-1	0.05	200	1	0	93.83	0.95	0.92	0.94
15	40	-1	0.05	200	1	0.1	93.86	0.95	0.92	0.94
31	40	-1	0.05	200	1	0	93.89	0.96	0.92	0.94
31	40	-1	0.05	200	1	0.1	93.68	0.95	0.92	0.94
63	40	-1	0.05	200	1	0	93.76	0.95	0.92	0.94
63	40	-1	0.05	200	1	0.1	93.85	0.95	0.92	0.94
15	40	-1	0.05	300	1	0	93.76	0.95	0.92	0.94
15	40	-1	0.05	300	1	0.1	93.86	0.95	0.92	0.94
31	40	-1	0.05	300	1	0	93.82	0.95	0.92	0.94
31	40	-1	0.05	300	1	0.1	93.66	0.95	0.92	0.94
63	40	-1	0.05	300	1	0	93.79	0.95	0.92	0.94
63	40	-1	0.05	300	1	0.1	93.78	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	8	0.05	100	1	0	93.85	0.96	0.92	0.94
15	10	8	0.05	100	1	0.1	93.77	0.96	0.92	0.94
31	10	8	0.05	100	1	0	93.74	0.95	0.92	0.94
31	10	8	0.05	100	1	0.1	93.79	0.96	0.92	0.94
63	10	8	0.05	100	1	0	93.73	0.95	0.92	0.94
63	10	8	0.05	100	1	0.1	93.82	0.96	0.92	0.94
15	10	8	0.05	200	1	0	93.91	0.96	0.92	0.94
15	10	8	0.05	200	1	0.1	93.93	0.96	0.92	0.94
31	10	8	0.05	200	1	0	93.84	0.95	0.92	0.94
31	10	8	0.05	200	1	0.1	93.88	0.95	0.92	0.94
63	10	8	0.05	200	1	0	93.82	0.95	0.92	0.94
63	10	8	0.05	200	1	0.1	93.83	0.95	0.92	0.94
15	10	8	0.05	300	1	0	93.81	0.95	0.92	0.94
15	10	8	0.05	300	1	0.1	93.86	0.95	0.92	0.94
31	10	8	0.05	300	1	0	93.74	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	10	8	0.05	300	1	0.1	93.95	0.95	0.92	0.94
63	10	8	0.05	300	1	0	93.89	0.95	0.92	0.94
63	10	8	0.05	300	1	0.1	93.85	0.95	0.92	0.94
15	20	8	0.05	100	1	0	93.75	0.96	0.92	0.94
15	20	8	0.05	100	1	0.1	93.77	0.96	0.92	0.94
31	20	8	0.05	100	1	0	93.79	0.96	0.92	0.94
31	20	8	0.05	100	1	0.1	93.71	0.95	0.92	0.94
63	20	8	0.05	100	1	0	93.79	0.95	0.92	0.94
63	20	8	0.05	100	1	0.1	93.93	0.96	0.92	0.94
15	20	8	0.05	200	1	0	93.91	0.96	0.92	0.94
15	20	8	0.05	200	1	0.1	93.88	0.96	0.92	0.94
31	20	8	0.05	200	1	0	93.95	0.95	0.92	0.94
31	20	8	0.05	200	1	0.1	93.80	0.95	0.92	0.94
63	20	8	0.05	200	1	0	93.89	0.95	0.92	0.94
63	20	8	0.05	200	1	0.1	94.03	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	20	8	0.05	300	1	0	93.78	0.95	0.92	0.94
15	20	8	0.05	300	1	0.1	93.93	0.96	0.92	0.94
31	20	8	0.05	300	1	0	93.84	0.95	0.92	0.94
31	20	8	0.05	300	1	0.1	93.78	0.95	0.92	0.94
63	20	8	0.05	300	1	0	93.91	0.95	0.92	0.94
63	20	8	0.05	300	1	0.1	93.96	0.95	0.92	0.94
15	40	8	0.05	100	1	0	93.78	0.96	0.92	0.94
15	40	8	0.05	100	1	0.1	93.82	0.96	0.92	0.94
31	40	8	0.05	100	1	0	93.79	0.96	0.92	0.94
31	40	8	0.05	100	1	0.1	93.77	0.96	0.92	0.94
63	40	8	0.05	100	1	0	93.81	0.96	0.92	0.94
63	40	8	0.05	100	1	0.1	93.69	0.95	0.92	0.94
15	40	8	0.05	200	1	0	93.81	0.95	0.92	0.94
15	40	8	0.05	200	1	0.1	93.81	0.95	0.92	0.94
31	40	8	0.05	200	1	0	93.93	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	40	8	0.05	200	1	0.1	93.89	0.96	0.92	0.94
63	40	8	0.05	200	1	0	93.81	0.95	0.92	0.94
63	40	8	0.05	200	1	0.1	93.99	0.95	0.92	0.94
15	40	8	0.05	300	1	0	93.82	0.96	0.92	0.94
15	40	8	0.05	300	1	0.1	93.85	0.95	0.92	0.94
31	40	8	0.05	300	1	0	93.94	0.95	0.92	0.94
31	40	8	0.05	300	1	0.1	93.90	0.95	0.92	0.94
63	40	8	0.05	300	1	0	93.90	0.95	0.92	0.94
63	40	8	0.05	300	1	0.1	93.85	0.95	0.92	0.94
15	10	-1	0.1	100	1	0	93.82	0.95	0.92	0.94
15	10	-1	0.1	100	1	0.1	93.84	0.95	0.92	0.94
31	10	-1	0.1	100	1	0	93.72	0.95	0.92	0.94
31	10	-1	0.1	100	1	0.1	93.81	0.95	0.92	0.94
63	10	-1	0.1	100	1	0	93.90	0.96	0.92	0.94
63	10	-1	0.1	100	1	0.1	93.89	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	-1	0.1	200	1	0	93.83	0.95	0.92	0.94
15	10	-1	0.1	200	1	0.1	93.78	0.95	0.92	0.94
31	10	-1	0.1	200	1	0	93.72	0.95	0.92	0.94
31	10	-1	0.1	200	1	0.1	93.68	0.95	0.92	0.94
63	10	-1	0.1	200	1	0	94.04	0.96	0.92	0.94
63	10	-1	0.1	200	1	0.1	93.89	0.96	0.92	0.94
15	10	-1	0.1	300	1	0	93.69	0.95	0.92	0.94
15	10	-1	0.1	300	1	0.1	93.70	0.95	0.92	0.94
31	10	-1	0.1	300	1	0	93.72	0.95	0.92	0.94
31	10	-1	0.1	300	1	0.1	93.67	0.95	0.92	0.94
63	10	-1	0.1	300	1	0	93.90	0.96	0.92	0.94
63	10	-1	0.1	300	1	0.1	93.97	0.96	0.92	0.94
15	20	-1	0.1	100	1	0	93.96	0.96	0.92	0.94
15	20	-1	0.1	100	1	0.1	93.93	0.95	0.92	0.94
31	20	-1	0.1	100	1	0	93.75	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	20	-1	0.1	100	1	0.1	93.79	0.95	0.92	0.94
63	20	-1	0.1	100	1	0	93.82	0.95	0.92	0.94
63	20	-1	0.1	100	1	0.1	93.85	0.96	0.92	0.94
15	20	-1	0.1	200	1	0	93.84	0.95	0.92	0.94
15	20	-1	0.1	200	1	0.1	93.93	0.95	0.92	0.94
31	20	-1	0.1	200	1	0	93.64	0.95	0.92	0.94
31	20	-1	0.1	200	1	0.1	93.80	0.95	0.92	0.94
63	20	-1	0.1	200	1	0	93.90	0.96	0.92	0.94
63	20	-1	0.1	200	1	0.1	93.83	0.96	0.92	0.94
15	20	-1	0.1	300	1	0	93.65	0.95	0.92	0.94
15	20	-1	0.1	300	1	0.1	93.90	0.95	0.92	0.94
31	20	-1	0.1	300	1	0	93.79	0.95	0.92	0.94
31	20	-1	0.1	300	1	0.1	93.79	0.95	0.92	0.94
63	20	-1	0.1	300	1	0	93.96	0.96	0.92	0.94
63	20	-1	0.1	300	1	0.1	93.78	0.96	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	40	-1	0.1	100	1	0	93.71	0.95	0.92	0.94
15	40	-1	0.1	100	1	0.1	93.87	0.96	0.92	0.94
31	40	-1	0.1	100	1	0	93.85	0.95	0.92	0.94
31	40	-1	0.1	100	1	0.1	93.85	0.95	0.92	0.94
63	40	-1	0.1	100	1	0	93.69	0.95	0.92	0.94
63	40	-1	0.1	100	1	0.1	93.84	0.95	0.92	0.94
15	40	-1	0.1	200	1	0	93.79	0.95	0.92	0.94
15	40	-1	0.1	200	1	0.1	93.81	0.95	0.92	0.94
31	40	-1	0.1	200	1	0	93.81	0.95	0.92	0.94
31	40	-1	0.1	200	1	0.1	93.77	0.95	0.92	0.94
63	40	-1	0.1	200	1	0	93.82	0.95	0.92	0.94
63	40	-1	0.1	200	1	0.1	93.79	0.95	0.92	0.94
15	40	-1	0.1	300	1	0	93.73	0.95	0.92	0.94
15	40	-1	0.1	300	1	0.1	93.79	0.95	0.92	0.94
31	40	-1	0.1	300	1	0	93.79	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	40	-1	0.1	300	1	0.1	93.68	0.95	0.92	0.94
63	40	-1	0.1	300	1	0	93.80	0.95	0.92	0.94
63	40	-1	0.1	300	1	0.1	93.80	0.95	0.92	0.94
15	10	8	0.1	100	1	0	93.88	0.95	0.92	0.94
15	10	8	0.1	100	1	0.1	93.79	0.95	0.92	0.94
31	10	8	0.1	100	1	0	93.90	0.95	0.92	0.94
31	10	8	0.1	100	1	0.1	93.80	0.95	0.92	0.94
63	10	8	0.1	100	1	0	93.96	0.95	0.92	0.94
63	10	8	0.1	100	1	0.1	93.94	0.95	0.92	0.94
15	10	8	0.1	200	1	0	93.82	0.95	0.92	0.94
15	10	8	0.1	200	1	0.1	93.75	0.95	0.92	0.94
31	10	8	0.1	200	1	0	93.88	0.95	0.92	0.94
31	10	8	0.1	200	1	0.1	93.88	0.95	0.92	0.94
63	10	8	0.1	200	1	0	93.84	0.95	0.92	0.94
63	10	8	0.1	200	1	0.1	93.79	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	10	8	0.1	300	1	0	93.61	0.95	0.92	0.94
15	10	8	0.1	300	1	0.1	93.79	0.95	0.92	0.94
31	10	8	0.1	300	1	0	93.73	0.95	0.92	0.94
31	10	8	0.1	300	1	0.1	93.85	0.95	0.92	0.94
63	10	8	0.1	300	1	0	93.73	0.95	0.92	0.94
63	10	8	0.1	300	1	0.1	93.72	0.95	0.92	0.94
15	20	8	0.1	100	1	0	93.96	0.96	0.92	0.94
15	20	8	0.1	100	1	0.1	93.94	0.96	0.92	0.94
31	20	8	0.1	100	1	0	93.80	0.95	0.92	0.94
31	20	8	0.1	100	1	0.1	93.80	0.95	0.92	0.94
63	20	8	0.1	100	1	0	93.81	0.95	0.92	0.94
63	20	8	0.1	100	1	0.1	93.89	0.96	0.92	0.94
15	20	8	0.1	200	1	0	93.77	0.95	0.92	0.94
15	20	8	0.1	200	1	0.1	93.90	0.96	0.92	0.94
31	20	8	0.1	200	1	0	93.82	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
31	20	8	0.1	200	1	0.1	93.73	0.95	0.92	0.94
63	20	8	0.1	200	1	0	93.83	0.95	0.92	0.94
63	20	8	0.1	200	1	0.1	93.84	0.95	0.92	0.94
15	20	8	0.1	300	1	0	93.74	0.95	0.92	0.94
15	20	8	0.1	300	1	0.1	93.86	0.95	0.92	0.94
31	20	8	0.1	300	1	0	93.81	0.95	0.92	0.94
31	20	8	0.1	300	1	0.1	93.83	0.95	0.92	0.94
63	20	8	0.1	300	1	0	93.71	0.95	0.92	0.94
63	20	8	0.1	300	1	0.1	93.83	0.95	0.92	0.94
15	40	8	0.1	100	1	0	93.89	0.95	0.92	0.94
15	40	8	0.1	100	1	0.1	93.77	0.95	0.92	0.94
31	40	8	0.1	100	1	0	93.92	0.95	0.92	0.94
31	40	8	0.1	100	1	0.1	93.83	0.95	0.92	0.94
63	40	8	0.1	100	1	0	93.88	0.96	0.92	0.94
63	40	8	0.1	100	1	0.1	93.85	0.95	0.92	0.94

ตารางที่ 4-8 (ต่อ)

Parameters							Performance			
num_ leaves	min_child _samples	max_ depth	learning_ rate	n_ estimators	feature_ fraction	reg_ lambda	Accuracy (%)	Precision	Recall	F1
15	40	8	0.1	200	1	0	93.80	0.95	0.92	0.94
15	40	8	0.1	200	1	0.1	93.78	0.95	0.92	0.94
31	40	8	0.1	200	1	0	93.70	0.95	0.92	0.94
31	40	8	0.1	200	1	0.1	93.85	0.95	0.92	0.94
63	40	8	0.1	200	1	0	93.73	0.95	0.92	0.94
63	40	8	0.1	200	1	0.1	93.82	0.95	0.92	0.94
15	40	8	0.1	300	1	0	93.76	0.95	0.92	0.94
15	40	8	0.1	300	1	0.1	93.77	0.95	0.92	0.94
31	40	8	0.1	300	1	0	93.69	0.95	0.92	0.94
31	40	8	0.1	300	1	0.1	93.73	0.95	0.92	0.94
63	40	8	0.1	300	1	0	93.72	0.95	0.92	0.94
63	40	8	0.1	300	1	0.1	93.74	0.95	0.92	0.94

จากตาราง 4-8 พบว่าค่าพารามิเตอร์ของ Light Gradient Boosting Machine ที่ให้ประสิทธิภาพดีที่สุด คือพารามิเตอร์ num_leaves เท่ากับ 15 พารามิเตอร์ min_child_samples เท่ากับ 10 พารามิเตอร์ max_depth เท่ากับ -1 พารามิเตอร์ learning_rate เท่ากับ 0.05 พารามิเตอร์ n_estimators

เท่ากับ 300 พารามิเตอร์ feature_fraction เท่ากับ 0.8 และพารามิเตอร์ reg_lambda เท่ากับ 0 โดยให้ค่าความถูกต้องเท่ากับร้อยละ 94.1 ค่าความแม่นยำ เท่ากับ 0.957 ค่าระลึกเท่ากับ 0.92 และค่าการถ่วงดุลเท่ากับ 0.94 ตามลำดับ



ตารางที่ 4-9 ผลลัพธ์ของอัลกอริทึม Deep Neural Network

Parameter					Performance			
hidden_ units	dropout _rates	learning_ rate	batch_ size	l2	Accuracy (%)	Precision	Recall	F1
[64, 32]	[0.1, 0.1]	0.001	256	0	80.02	0.88	0.70	0.76
[64, 32]	[0.1, 0.1]	0.001	256	1.00E-05	80.10	0.88	0.69	0.77
[64, 32]	[0.1, 0.1]	0.001	256	0.0001	80.12	0.88	0.70	0.77
[64, 32]	[0.1, 0.1]	0.001	512	0	77.37	0.86	0.68	0.75
[64, 32]	[0.1, 0.1]	0.001	512	1.00E-05	80.50	0.89	0.70	0.77
[64, 32]	[0.1, 0.1]	0.001	512	0.0001	73.17	0.82	0.60	0.69
[64, 32]	[0.1, 0.1]	0.0005	256	0	83.13	0.90	0.75	0.80
[64, 32]	[0.1, 0.1]	0.0005	256	1.00E-05	77.41	0.85	0.68	0.74
[64, 32]	[0.1, 0.1]	0.0005	256	0.0001	83.93	0.89	0.78	0.82
[64, 32]	[0.1, 0.1]	0.0005	512	0	78.16	0.88	0.66	0.74
[64, 32]	[0.1, 0.1]	0.0005	512	1.00E-05	77.19	0.86	0.65	0.73
[64, 32]	[0.1, 0.1]	0.0005	512	0.0001	76.26	0.84	0.65	0.73
[64, 32]	[0.1, 0.1]	0.0003	256	0	83.99	0.83	0.86	0.84
[64, 32]	[0.1, 0.1]	0.0003	256	1.00E-05	78.99	0.89	0.67	0.74
[64, 32]	[0.1, 0.1]	0.0003	256	0.0001	79.01	0.90	0.66	0.74
[64, 32]	[0.1, 0.1]	0.0003	512	0	74.27	0.83	0.61	0.70
[64, 32]	[0.1, 0.1]	0.0003	512	1.00E-05	77.22	0.84	0.68	0.75
[64, 32]	[0.1, 0.1]	0.0003	512	0.0001	76.96	0.81	0.70	0.75
[64, 32]	[0.2, 0.2]	0.001	256	0	79.72	0.87	0.70	0.77
[64, 32]	[0.2, 0.2]	0.001	256	1.00E-05	79.92	0.88	0.69	0.77
[64, 32]	[0.2, 0.2]	0.001	256	0.0001	83.34	0.90	0.75	0.80
[64, 32]	[0.2, 0.2]	0.001	512	0	75.26	0.86	0.61	0.71
[64, 32]	[0.2, 0.2]	0.001	512	1.00E-05	74.13	0.88	0.57	0.68
[64, 32]	[0.2, 0.2]	0.001	512	0.0001	74.65	0.84	0.61	0.71
[64, 32]	[0.2, 0.2]	0.0005	256	0	83.91	0.87	0.79	0.83
[64, 32]	[0.2, 0.2]	0.0005	256	1.00E-05	77.81	0.86	0.66	0.74
[64, 32]	[0.2, 0.2]	0.0005	256	0.0001	81.64	0.85	0.78	0.81

ตารางที่ 4-9 (ต่อ)

Parameter					Performance			
hidden_ units	dropout _rates	learning_ rate	batch_ size	l2	Accuracy (%)	Precision	Recall	F1
[64, 32]	[0.2, 0.2]	0.0005	512	0	77.42	0.84	0.67	0.74
[64, 32]	[0.2, 0.2]	0.0005	512	1.00E-05	72.81	0.80	0.63	0.70
[64, 32]	[0.2, 0.2]	0.0005	512	0.0001	76.78	0.87	0.64	0.72
[64, 32]	[0.2, 0.2]	0.0003	256	0	79.32	0.86	0.71	0.76
[64, 32]	[0.2, 0.2]	0.0003	256	1.00E-05	84.48	0.85	0.84	0.84
[64, 32]	[0.2, 0.2]	0.0003	256	0.0001	77.28	0.81	0.72	0.75
[64, 32]	[0.2, 0.2]	0.0003	512	0	73.66	0.83	0.60	0.70
[64, 32]	[0.2, 0.2]	0.0003	512	1.00E-05	73.06	0.79	0.71	0.73
[64, 32]	[0.2, 0.2]	0.0003	512	0.0001	74.18	0.84	0.60	0.70
[128, 64]	[0.1, 0.1]	0.001	256	0	83.04	0.87	0.77	0.81
[128, 64]	[0.1, 0.1]	0.001	256	1.00E-05	78.16	0.86	0.67	0.75
[128, 64]	[0.1, 0.1]	0.001	256	0.0001	74.71	0.85	0.61	0.70
[128, 64]	[0.1, 0.1]	0.001	512	0	75.84	0.84	0.64	0.73
[128, 64]	[0.1, 0.1]	0.001	512	1.00E-05	73.42	0.78	0.68	0.72
[128, 64]	[0.1, 0.1]	0.001	512	0.0001	75.63	0.85	0.63	0.71
[128, 64]	[0.1, 0.1]	0.0005	256	0	75.94	0.77	0.81	0.77
[128, 64]	[0.1, 0.1]	0.0005	256	1.00E-05	81.82	0.87	0.75	0.80
[128, 64]	[0.1, 0.1]	0.0005	256	0.0001	82.57	0.89	0.75	0.80
[128, 64]	[0.1, 0.1]	0.0005	512	0	76.89	0.84	0.67	0.74
[128, 64]	[0.1, 0.1]	0.0005	512	1.00E-05	75.02	0.87	0.59	0.70
[128, 64]	[0.1, 0.1]	0.0005	512	0.0001	75.30	0.84	0.62	0.71
[128, 64]	[0.1, 0.1]	0.0003	256	0	79.78	0.90	0.67	0.76
[128, 64]	[0.1, 0.1]	0.0003	256	1.00E-05	87.09	0.84	0.92	0.88
[128, 64]	[0.1, 0.1]	0.0003	256	0.0001	79.32	0.79	0.83	0.80
[128, 64]	[0.1, 0.1]	0.0003	512	0	78.48	0.82	0.75	0.78
[128, 64]	[0.1, 0.1]	0.0003	512	1.00E-05	73.68	0.76	0.70	0.73

ตารางที่ 4-9 (ต่อ)

Parameter					Performance			
hidden_ units	dropout _rates	learning_ rate	batch_ size	l2	Accuracy (%)	Precision	Recall	F1
[128, 64]	[0.1, 0.1]	0.0003	512	0.0001	76.61	0.80	0.76	0.76
[128, 64]	[0.2, 0.2]	0.001	256	0	80.11	0.86	0.71	0.78
[128, 64]	[0.2, 0.2]	0.001	256	1.00E-05	80.97	0.89	0.71	0.78
[128, 64]	[0.2, 0.2]	0.001	256	0.0001	80.84	0.85	0.74	0.79
[128, 64]	[0.2, 0.2]	0.001	512	0	72.55	0.84	0.56	0.67
[128, 64]	[0.2, 0.2]	0.001	512	1.00E-05	76.02	0.85	0.63	0.72
[128, 64]	[0.2, 0.2]	0.001	512	0.0001	73.24	0.79	0.66	0.71
[128, 64]	[0.2, 0.2]	0.0005	256	0	80.98	0.88	0.71	0.78
[128, 64]	[0.2, 0.2]	0.0005	256	1.00E-05	86.04	0.91	0.81	0.84
[128, 64]	[0.2, 0.2]	0.0005	256	0.0001	80.27	0.91	0.67	0.76
[128, 64]	[0.2, 0.2]	0.0005	512	0	75.01	0.81	0.70	0.73
[128, 64]	[0.2, 0.2]	0.0005	512	1.00E-05	72.70	0.80	0.61	0.69
[128, 64]	[0.2, 0.2]	0.0005	512	0.0001	72.36	0.82	0.58	0.68
[128, 64]	[0.2, 0.2]	0.0003	256	0	85.52	0.88	0.83	0.84
[128, 64]	[0.2, 0.2]	0.0003	256	1.00E-05	87.23	0.89	0.85	0.87
[128, 64]	[0.2, 0.2]	0.0003	256	0.0001	77.14	0.90	0.61	0.72
[128, 64]	[0.2, 0.2]	0.0003	512	0	73.70	0.83	0.60	0.68
[128, 64]	[0.2, 0.2]	0.0003	512	1.00E-05	77.97	0.82	0.71	0.75
[128, 64]	[0.2, 0.2]	0.0003	512	0.0001	74.78	0.79	0.70	0.73
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	256	0	76.13	0.87	0.61	0.71
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	256	1.00E-05	81.64	0.83	0.79	0.81
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	256	0.0001	81.06	0.88	0.72	0.78
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	512	0	78.18	0.86	0.67	0.75
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	512	1.00E-05	75.90	0.83	0.66	0.72

ตารางที่ 4-9 (ต่อ)

Parameter					Performance			
hidden_ units	dropout _rates	learning_ rate	batch_ size	l2	Accuracy (%)	Precision	Recall	F1
[128, 64, 32]	[0.1, 0.1, 0.1]	0.001	512	0.0001	75.19	0.84	0.63	0.72
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	256	0	82.55	0.88	0.75	0.81
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	256	1.00E-05	78.77	0.85	0.70	0.76
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	256	0.0001	81.55	0.88	0.73	0.78
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	512	0	78.32	0.90	0.64	0.74
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	512	1.00E-05	75.12	0.86	0.60	0.71
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0005	512	0.0001	80.58	0.87	0.71	0.78
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	256	0	82.46	0.89	0.75	0.80
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	256	1.00E-05	85.08	0.87	0.84	0.85
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	256	0.0001	83.10	0.90	0.74	0.81
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	512	0	73.34	0.78	0.70	0.72
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	512	1.00E-05	75.59	0.84	0.63	0.71
[128, 64, 32]	[0.1, 0.1, 0.1]	0.0003	512	0.0001	74.43	0.86	0.59	0.70
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	256	0	75.54	0.91	0.57	0.69
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	256	1.00E-05	78.13	0.88	0.66	0.74
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	256	0.0001	78.93	0.90	0.66	0.74

ตารางที่ 4-9 (ต่อ)

Parameter					Performance			
hidden_ units	dropout _rates	learning_ rate	batch_ size	l2	Accuracy (%)	Precision	Recall	F1
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	512	0	74.41	0.88	0.57	0.69
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	512	1.00E-05	74.33	0.84	0.61	0.70
[128, 64, 32]	[0.3, 0.3, 0.2]	0.001	512	0.0001	73.88	0.84	0.59	0.69
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	256	0	85.96	0.88	0.83	0.85
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	256	1.00E-05	80.41	0.91	0.67	0.76
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	256	0.0001	79.88	0.89	0.68	0.76
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	512	0	74.64	0.86	0.59	0.70
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	512	1.00E-05	76.46	0.90	0.60	0.71
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0005	512	0.0001	77.55	0.87	0.64	0.73
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	256	0	76.07	0.84	0.65	0.73
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	256	1.00E-05	76.37	0.85	0.64	0.72
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	256	0.0001	79.58	0.89	0.67	0.76
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	512	0	72.56	0.83	0.57	0.68
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	512	1.00E-05	76.81	0.83	0.68	0.74
[128, 64, 32]	[0.3, 0.3, 0.2]	0.0003	512	0.0001	75.82	0.84	0.63	0.72

จากตาราง 4-9 พบว่าค่าพารามิเตอร์ของ Deep Neural Network ที่ให้ประสิทธิภาพดีที่สุดคือพารามิเตอร์ hidden_units เท่ากับ 128, 64 พารามิเตอร์ dropout_rates เท่ากับ 0.1, 0.1

พารามิเตอร์ learning_rate เท่ากับ 0.003 พารามิเตอร์ batch_size เท่ากับ 256 พารามิเตอร์ และ พารามิเตอร์ l2 เท่ากับ 0.00001 โดยให้ค่าความถูกต้องเท่ากับร้อยละ 87.1 ค่าความแม่นยำเท่ากับ 0.84 ค่าระลึกเท่ากับ 0.92 และค่าการถ่วงดุลเท่ากับ 0.88 ตามลำดับ

ตารางที่ 4-10 ผลลัพธ์ของเทคนิค Ensemble Learning โดยใช้พารามิเตอร์ Vote

Algorithm	Performance			
	Accuracy (%)	Precision	Recall	F1
SVM, LightGBM, DNN	93.10	0.93	0.93	0.93

จากตาราง 4-10 พบว่าเทคนิค Ensemble ของแบบจำลองจำนวน 3 อัลกอริทึมได้แก่ SVM, LightGBM และ DNN ให้ประสิทธิภาพดีที่สุด โดยให้ค่าความถูกต้องเท่ากับร้อยละ 93.1 ค่าความแม่นยำเท่ากับ 0.93 ค่าระลึกเท่ากับ 0.93 และค่าการถ่วงดุลเท่ากับ 0.93 ตามลำดับ

ตารางที่ 4-11 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง

Algorithm	Performance			
	Accuracy (%)	Precision	Recall	F1
SVM	78.06	0.82	0.72	0.77
LightGBM	94.12	0.96	0.92	0.94
DNN	87.09	0.84	0.92	0.88
Ensemble Voting	93.10	0.93	0.93	0.93

จากตารางที่ 4-11 เมื่อได้ผลลัพธ์ของ 3 แบบจำลอง ผู้วิจัยทำการเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลอง พบว่าแบบจำลอง LightGBM ให้ประสิทธิภาพในการทำนายผลดีที่สุดด้วยค่าความถูกต้องร้อยละ 94.1 ค่าความแม่นยำ 0.96 ค่าระลึก 0.92 และค่าการถ่วงดุล 0.94 ตามลำดับ จากนั้นได้ทำการทดสอบประสิทธิภาพแบบจำลองทั้ง 4 แบบจำลองด้วย Unseen Data จำนวน 3,186 รายการ

ตารางที่ 4-12 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองด้วย Unseen Data

Algorithm	Performance			
	Accuracy (%)	Precision	Recall	F1
SVM	76.71	0.80	0.72	0.76
LightGBM	<u>92.90</u>	<u>0.93</u>	<u>0.93</u>	<u>0.93</u>
DNN	65.25	0.62	0.82	0.70
Ensemble Voting	92.71	0.93	0.93	0.93

จากตารางที่ 4-12 ผลการทดสอบด้วย Unseen Data จำนวน 3,186 รายการ พบว่าแบบจำลอง LightGBM ให้ประสิทธิภาพในการทำนายผลดีที่สุดด้วยค่าความถูกต้องร้อยละ 92.90 ค่าความแม่นยำ 0.93 ค่าระลึก 0.93 และค่าการถ่วงดุล 0.93

ผลการทดสอบดังกล่าวยืนยันในเชิงประจักษ์ว่า แบบจำลอง LightGBM ที่ผ่านการปรับแต่งพารามิเตอร์ มีความสามารถในการเรียนรู้รูปแบบความสัมพันธ์เชิงลึกของข้อมูลทางการเงินได้อย่างมีประสิทธิภาพ อีกทั้งยังมีความทนทานต่อภาวะการเรียนรู้เกินพอดี (Overfitting) ทำให้สามารถนำไปใช้พยากรณ์ข้อมูลชุดใหม่ในสถานการณ์จริงได้อย่างมีประสิทธิภาพ และมีความน่าเชื่อถือสูง ด้วยเหตุนี้ ผู้วิจัยจึงพิจารณาคัดเลือก LightGBM ให้เป็นแบบจำลองขั้นสุดท้าย (Final Model) โดยดำเนินการบันทึกสถานะชุดความรู้ของแบบจำลอง (Model Serialization) เพื่อนำไปประยุกต์ใช้งานจริง (Model Deployment) ในรูปแบบของระบบเตือนภัยล่วงหน้าบนเครือข่ายอินเทอร์เน็ต ซึ่งจะช่วยให้ผู้ปฏิบัติงานสามารถนำไปใช้เป็นเครื่องมือสนับสนุนการตัดสินใจได้อย่างเป็นรูปธรรม โดยผู้วิจัยจะได้นำเสนอผลการพัฒนาระบบเว็บแอปพลิเคชัน (Web Application) ในหัวข้อถัดไป

4.3 ผลการนำแบบจำลองไปใช้งาน

หลังจากดำเนินการพัฒนา และเลือกแบบจำลองที่เหมาะสมสำหรับพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้คัดเลือกแบบจำลองอัลกอริทึมโลทกราเดียนบูตติ้งแมชชีน (LightGBM) ซึ่งเป็นแบบจำลองที่มีประสิทธิภาพสูงสุด มาทำการบันทึกสถานะ (Model Serialization) ให้อยู่ในรูปแบบไฟล์ .pkl และนำไปพัฒนาต่อยอดบูรณาการเข้ากับระบบเว็บแอปพลิเคชัน (Web Application) เพื่อให้บริการในรูปแบบของระบบเตือนภัยล่วงหน้า (Early Warning System) สำหรับการประเมินความเสี่ยงนิติบุคคล ผู้วิจัยได้เลือกใช้แพลตฟอร์มไฟร์เบสสตูดิโอ (Firebase Studio) ในการบริหารจัดการระบบฐานข้อมูลและการ

ให้บริการประมวลผลบนระบบคลาวด์ (Cloud Hosting) โดยผลการพัฒนาระบบสามารถแบ่งส่วนการทำงานหลักออกเป็น 2 ส่วน ดังนี้


4.3.1 ส่วนการนำเข้าข้อมูล (Data Input Interface)

ระบบถูกออกแบบให้มีส่วนติดต่อผู้ใช้งาน (User Interface: UI) ที่ใช้งานง่ายและตรงไปตรงมา ผู้ใช้งานระบบ (เช่น เจ้าหน้าที่วิเคราะห์สินเชื่อ หรือผู้บริหารความเสี่ยง) สามารถกรอกข้อมูลตัวเลขทางการเงินที่สำคัญของนิติบุคคลที่ต้องการตรวจสอบลงในแบบฟอร์มบนหน้าเว็บไซต์ เช่น ข้อมูลสินทรัพย์รวม หนี้สินรวม รายได้รวม และข้อมูลอัตราส่วนทางการเงินต่างๆ เมื่อผู้ใช้งานกดยืนยันข้อมูลจะถูกส่งผ่านระบบคลาวด์เพื่อนำไปแปลงสภาพ (Data Transformation) ให้อยู่ในรูปแบบที่แบบจำลองรองรับ แสดงตามภาพที่ 4-1

ภาพที่ 4-1 การแสดงผลหน้า Data Input Interface

4.3.2 ส่วนการประมวลผลและแสดงผลลัพธ์ (Real-time Inference and Output Interface)

เมื่อระบบคลาวด์ได้รับข้อมูล จะทำการส่งต่อข้อมูลไปยังแบบจำลอง LightGBM ที่ฝังตัวอยู่ เพื่อทำการพยากรณ์สถานะของกิจการอย่างทันที (Real-time) จากนั้นระบบจะส่งคืนผลลัพธ์กลับมาแสดงผลบนหน้าจอของผู้ใช้งาน โดยผลลัพธ์จะแสดงสถานะการพยากรณ์ออกเป็น 2 ระดับ ได้แก่ "ดำเนินการกิจการอยู่" หรือ "มีความเสี่ยงเลิกกิจการ" พร้อมทั้งแสดงค่าความน่าจะเป็น (Probability Score) เป็นเปอร์เซ็นต์ เพื่อให้ผู้ปฏิบัติงานสามารถรับทราบระดับความรุนแรงของความเสี่ยง และนำไปใช้ประกอบการตัดสินใจเชิงกลยุทธ์ได้อย่างมีประสิทธิภาพ ดังแสดงในภาพที่ 4-2



ภาพที่ 4-2 หน้าจอแสดงผลการพยากรณ์ความเสี่ยงการเลิกกิจการพร้อมค่าความน่าจะเป็น (Probability)

ภาพรวมของผลการดำเนินงานวิจัยในบทนี้ แสดงให้เห็นถึงความสำเร็จในการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อพยากรณ์ความเสี่ยงการเลิกกิจการของนิติบุคคลในประเทศไทยได้อย่างเป็นรูปธรรม โดยเริ่มต้นจากการจัดเตรียมชุดข้อมูลงบการเงินและอัตราส่วนทางการเงินจำนวน 13,218 รายการ ให้มีความสมบูรณ์และลดความเอนเอียงของคลาสข้อมูล (Balanced Data) เพื่อนำเข้าสู่กระบวนการฝึกสอนแบบจำลอง จากการทดสอบและเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึมต่างๆ พบหลักฐานเชิงประจักษ์ว่า แบบจำลองอัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (LightGBM) เป็นแบบจำลองที่มีศักยภาพสูงสุด ทั้งในขั้นตอนการแบ่งข้อมูลด้วยเทคนิค Cross-Validation และการทดสอบกับชุดข้อมูลอิสระที่แบบจำลองไม่เคยพบเห็นมาก่อน (Unseen Dataset) โดยสามารถให้ผลลัพธ์การพยากรณ์ที่แม่นยำและเอาชนะแบบจำลอง SVM, DNN รวมถึงเทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Soft Voting) ได้อย่างมีนัยสำคัญ

ท้ายที่สุด ผู้วิจัยได้นำแบบจำลอง LightGBM ขั้นสุดท้าย ไปบูรณาการร่วมกับแพลตฟอร์มไฟร์เบสสตูดิโอ (Firebase Studio) เพื่อพัฒนาดำเนินการเป็นระบบเว็บแอปพลิเคชันเตือนภัยล่วงหน้า (Early Warning System) ที่ประมวลผลได้แบบเรียลไทม์ ซึ่งผลลัพธ์ทั้งหมดนี้บรรจุตามวัตถุประสงค์ของการวิจัยที่ได้กำหนดไว้ทุกประการ ทั้งนี้ ผู้วิจัยจะนำข้อค้นพบที่ได้ไปทำการสรุปผล อภิปรายผลเชิงลึกเปรียบเทียบกับงานวิจัยในอดีต และนำเสนอข้อเสนอแนะสำหรับการนำไปใช้ประโยชน์ต่อไป

บทที่ 5

สรุปผล อภิปรายผล และข้อเสนอแนะ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทยจากข้อมูลงบการเงิน การดำเนินงานวิจัยครอบคลุมกระบวนการเก็บรวบรวมข้อมูล การจัดเตรียมข้อมูล การพัฒนา และประเมินประสิทธิภาพแบบจำลอง และการนำแบบจำลองไปใช้งานจริง ในบทนี้จะนำเสนอข้อมูล 3 ส่วน ดังนี้

- 5.1 สรุปผลการวิจัย
- 5.2 การอภิปรายผลการวิจัย
- 5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การวิจัยเรื่องการพยากรณ์ความเสี่ยงการเลิกกิจการของนิติบุคคลในประเทศไทยด้วยเทคนิคการเรียนรู้ของเครื่อง สามารถสรุปผลการดำเนินงานตามขั้นตอนหลักได้ดังนี้

5.1.1 สรุปผลการเก็บรวบรวมและจัดเตรียมข้อมูล

จากการรวบรวมข้อมูลทุติยภูมิของนิติบุคคลจากฐานข้อมูลกรมพัฒนาธุรกิจการค้า ครอบคลุมข้อมูลงบการเงินในปี พ.ศ. 2565 – 2566 เพื่อพยากรณ์สถานะกิจการในปี พ.ศ. 2567 ผู้วิจัยได้รับชุดข้อมูลตั้งต้นจำนวน 13,218 รายการ โดยได้นำมาผ่านกระบวนการทำความสะอาด จัดการค่าที่ขาดหาย และสร้างตัวแปรเชิงพลวัต (Feature Engineering) เช่น อัตราการเติบโตของสินทรัพย์ หนี้สิน รายได้ และกำไร รวมถึงการแปลงชนิดข้อมูลตัวแปรเชิงหมวดหมู่ให้อยู่ในรูปแบบรหัสตัวเลข เพื่อให้แบบจำลองเรียนรู้ได้อย่างมีประสิทธิภาพ ผู้วิจัยได้แบ่งชุดข้อมูลออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลสำหรับการพัฒนาแบบจำลอง (Modeling Dataset) จำนวน 10,000 รายการ และชุดข้อมูลทดสอบอิสระ (Unseen Dataset) จำนวน 3,218 รายการ โดยจัดสัดส่วนของตัวแปรเป้าหมาย (นิติบุคคลที่ยังดำเนินกิจการ และนิติบุคคลที่เลิกกิจการ) ให้มีความสมดุลอย่างสมบูรณ์แบบ (Perfectly Balanced Data) ที่สัดส่วน 50:50 ซึ่งจากการสำรวจข้อมูลเบื้องต้นพบว่า กลุ่มนิติบุคคลที่เลิกกิจการมักแสดงสัญญาณความเสี่ยงผ่านอัตราส่วนหนี้สินที่สูง และมีอัตรากำไรสุทธิรวมถึงการเติบโตของรายได้ที่ติดลบอย่างเด่นชัด

5.1.2 สรุปผลการพัฒนาและเปรียบเทียบประสิทธิภาพแบบจำลอง

ผู้วิจัยได้นำชุดข้อมูลสำหรับการพัฒนาแบบจำลองไปเข้าสู่กระบวนการเรียนรู้และปรับแต่งพารามิเตอร์ (Hyperparameter Tuning) ผ่านเทคนิคการตรวจสอบความถูกต้องข้ามกลุ่มแบบ

K-Fold (K-Fold Cross-Validation) โดยเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง 3 อัลกอริทึม ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (SVM) อัลกอริทึมโลทกราดิเอนบูตติ้งแมชชีน (LightGBM) และ โครงข่ายประสาทเทียมเชิงลึก (DNN) รวมไปถึงการประยุกต์ใช้เทคนิคการเรียนรู้แบบกลุ่มด้วยการลงคะแนนเสียงแบบยืดหยุ่น (Ensemble Soft Voting) ผลการประเมินประสิทธิภาพชี้ให้เห็นอย่างชัดเจนว่า แบบจำลอง LightGBM มีประสิทธิภาพในการพยากรณ์สูงสุดในทุกตัวชี้วัด โดยมีค่าความถูกต้อง (Accuracy) สูงถึงร้อยละ 94.10 ค่าความแม่นยำ (Precision) 0.96 ค่าระลึก (Recall) 0.92 และการถ่วงดุล (F1-Score) 0.94 ซึ่งสามารถเอาชนะแบบจำลอง Ensemble (ความถูกต้องร้อยละ 93.10) แบบจำลอง DNN (ร้อยละ 87.10) และแบบจำลอง SVM (ร้อยละ 78.10) ได้อย่างมีนัยสำคัญ นอกจากนี้ เมื่อนำแบบจำลอง LightGBM ไปประเมินความแม่นยำขั้นสุดท้ายกับชุดข้อมูลทดสอบอิสระ (Unseen Dataset) แบบจำลองยังคงรักษามาตรฐานความแม่นยำได้อย่างยอดเยี่ยม โดยให้ค่าความถูกต้องถึงร้อยละ 92.90 และค่าการถ่วงดุล 0.93 ซึ่งพิสูจน์ให้เห็นว่าแบบจำลองมีเสถียรภาพและไม่เกิดภาวะการเรียนรู้เกินพอดี (Overfitting)

5.1.3 สรุปผลการนำแบบจำลองไปประยุกต์ใช้งาน

จากผลการทดสอบเชิงประจักษ์ ผู้วิจัยได้คัดเลือกแบบจำลอง LightGBM เป็นแบบจำลองขั้นสุดท้าย (Final Model) และทำการบันทึกสถานะชุดความรู้ของแบบจำลอง (Model Serialization) เพื่อนำไปพัฒนาเป็นระบบเว็บแอปพลิเคชันเตือนภัยล่วงหน้า (Early Warning System) ผ่านแพลตฟอร์มไฟร์เบสสตูดิโอ (Firebase Studio) ซึ่งระบบดังกล่าวสามารถรับข้อมูลตัวเลขทางการเงินจากผู้ใช้งาน ไปประมวลผลบนระบบคลาวด์ และส่งคืนผลลัพธ์การพยากรณ์สถานะความเสี่ยงของกิจการ พร้อมแสดงค่าความน่าจะเป็น (Probability Score) ได้แบบเรียลไทม์ ถือเป็นการตอบสนองต่อวัตถุประสงค์การวิจัยในการสร้างเครื่องมือสนับสนุนการตัดสินใจที่สามารถนำไปปฏิบัติงานได้จริงอย่างสมบูรณ์

5.2 การอภิปรายผลการวิจัย

จากสรุปผลการวิจัยข้างต้น ผู้วิจัยสามารถนำประเด็นค้นพบที่สำคัญมาอภิปรายผลโดยเชื่อมโยงกับแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้องได้ดังนี้

5.2.1 ประสิทธิภาพของแบบจำลองในการพยากรณ์ความเสี่ยงทางการเงิน

ผลการวิจัยพบว่าแบบจำลองอัลกอริทึมโลทกราดิเอนบูตติ้งแมชชีน (LightGBM) ให้ประสิทธิภาพสูงสุดด้วยค่าความถูกต้องร้อยละ 94.10 ซึ่งสูงกว่าแบบจำลองพื้นฐานอย่าง SVM และ DNN อย่างมีนัยสำคัญ ประเด็นนี้สามารถอธิบายได้ว่า เนื่องจาก LightGBM เป็นอัลกอริทึมกลุ่ม Tree-based ที่ใช้วิธีการ Gradient Boosting ซึ่งมีความโดดเด่นในการจัดการกับข้อมูลโครงสร้างตาราง (Tabular Data) และสามารถจับความสัมพันธ์ที่ซับซ้อนของตัวแปรทางการเงินได้ดีกว่า

แบบจำลองเชิงเส้น ซึ่งผลลัพธ์นี้ สอดคล้องกับงานวิจัยของ Iparraguirre-Villanueva และ Cabanillas-Carbonell [29] ที่ระบุว่าอัลกอริทึมในกลุ่ม Boosting ให้ประสิทธิภาพความแม่นยำสูงสุดในการพยากรณ์การล้มละลายของธุรกิจ และยัง สอดคล้องกับข้อค้นพบของ Alanis และคณะ [9] ที่ทำการประเมินเปรียบเทียบ (Benchmarking) และยืนยันว่าแบบจำลองกลุ่ม Ensemble มีความเหมาะสมอย่างยิ่งกับชุดข้อมูลที่มีความไม่สมดุลและมีความซับซ้อนสูงเช่นข้อมูลงบการเงิน

5.2.2 ความสำคัญของตัวแปรอัตราส่วนทางการเงินและอัตราการเติบโต

จากการที่ผู้วิจัยสร้างตัวแปรเชิงพลวัต เช่น อัตราการเติบโตของสินทรัพย์ (Asset Growth) และหนี้สิน (Debt Growth) พบว่าตัวแปรเหล่านี้ส่งผลบวกต่อความแม่นยำของแบบจำลองเป็นอย่างมาก อภิปรายได้ว่าตัวแปรเหล่านี้ไม่ได้สะท้อนเพียงแค่สถานะปัจจุบัน แต่สะท้อนถึง ทิศทางของกิจการข้ามปี ซึ่งเป็นสัญญาณเตือนภัย (Early Warning Signals) ที่ชัดเจนกว่าข้อมูลปีเดียว ประเด็นนี้ สอดคล้องกับงานวิจัยของ Hamdi และคณะ [30] ที่เน้นย้ำว่าการใช้อัตราส่วนทางการเงินร่วมกับเทคนิคปัญญาประดิษฐ์ เป็นปัจจัยขับเคลื่อนหลักที่ช่วยให้แบบจำลองแยกแยะบริษัทที่มีความเสี่ยงได้อย่างแม่นยำ และยัง สอดคล้องกับแนวคิดของ Zhao และคณะ [24] ที่ให้ความสำคัญกับการใช้ข้อมูลเชิงลึกมาเป็นตัวขับเคลื่อน (Drivers) ในการวิเคราะห์โครงข่ายความเสี่ยงขององค์กร

5.3 ข้อเสนอแนะ

จากการศึกษาและข้อค้นพบที่ได้จากการวิจัย ผู้วิจัยมีข้อเสนอแนะที่สำคัญทั้งในด้านการนำไปใช้ประโยชน์และด้านการศึกษาต่อยอดในอนาคต ดังนี้

5.3.1 ข้อเสนอแนะในการนำไปใช้ประโยชน์

5.3.1.1 หน่วยงานภาครัฐและผู้กำกับดูแล กรมพัฒนาธุรกิจการค้าหรือหน่วยงานที่เกี่ยวข้อง สามารถนำแนวทางและแบบจำลองอัลกอริทึมไลต์กราเดียนบูตติ้งแมชชีน (LightGBM) ที่พัฒนาขึ้น ไปประยุกต์ใช้เป็นระบบเตือนภัยล่วงหน้า (Early Warning System) เพื่อคัดกรองและเฝ้าระวังกลุ่มนิติบุคคลที่มีสัญญาณบ่งชี้ความเสี่ยงทางการเงิน ซึ่งจะช่วยให้ภาครัฐสามารถวางแผนรับมือหรือออกมาตรการช่วยเหลือธุรกิจได้อย่างทันห่วงที่

5.3.1.2 สถาบันการเงินและภาคธุรกิจ ธนาคารหรือสถาบันการเงินสามารถนำเว็บแอปพลิเคชันที่พัฒนาขึ้นไปใช้เป็นเครื่องมือเสริมในการประเมินความเสี่ยงด้านสินเชื่อ (Credit Risk Assessment) ร่วมกับการพิจารณาแบบดั้งเดิม โดยเฉพาะการใช้ตัวแปรอัตราการเติบโต (Growth) มาเป็นดัชนีชี้วัดความสามารถในการดำเนินกิจการอย่างต่อเนื่อง

5.3.1.3 ผู้ประกอบการ นิติบุคคลขนาดกลางและขนาดย่อม (SMEs) สามารถใช้ระบบนี้ในการประเมินสภาพทางการเงินของตนเอง (Self-Assessment) เพื่อเปรียบเทียบกับเกณฑ์

มาตรฐานในอุตสาหกรรมและเตรียมความพร้อมในการปรับปรุงโครงสร้างงบการเงินให้มีความมั่นคงยิ่งขึ้น

5.3.2 ข้อเสนอแนะในการวิจัยครั้งต่อไป

5.3.2.1 การขยายขอบเขตข้อมูล: ในการศึกษาครั้งต่อไป ควรมีการพิจารณาเพิ่มตัวแปรที่ไม่ใช่ตัวเลขทางการเงิน (Non-financial Data) เช่น ประสิทธิภาพของคณะกรรมการบริหารสถานที่ตั้งกิจการ หรือข้อมูลปัจจัยภายนอกอย่างดัชนีเศรษฐกิจมหภาค เพื่อให้แบบจำลองมีความครอบคลุมและแม่นยำในมิติที่หลากหลายมากขึ้น

5.3.1.2 การศึกษาข้อมูลเชิงเวลา (Time-series Analysis): ควรเพิ่มระยะเวลาในการเก็บรวบรวมข้อมูลย้อนหลังให้มากกว่า 2 รอบปีบัญชี เพื่อศึกษาพฤติกรรมและรูปแบบความเสี่ยงในระยะยาว (Long-term Trend) ซึ่งจะช่วยทำให้แบบจำลองสามารถแยกแยะระหว่างวิกฤตชั่วคราวและสัญญาณการเลิกกิจการที่แท้จริงได้ดีขึ้น

5.3.1.3 การประยุกต์ใช้เทคนิคที่ทันสมัย: ควรทดสอบการนำเทคนิคการอธิบายแบบจำลอง (Explainable AI: XAI) เช่น SHAP หรือ LIME มาใช้ร่วมกับแบบจำลอง LightGBM เพื่ออธิบายว่าปัจจัยใดที่มีอิทธิพลต่อผลการพยากรณ์มากที่สุดในแต่ละกรณี ซึ่งจะช่วยสร้างความเชื่อมั่นให้กับผู้ใช้งานในแง่ของความโปร่งใสของปัญญาประดิษฐ์

บรรณานุกรม

- 1 กองบรรณาธิการ SPOTLIGHT. (2024, December 24). ยอดจดทะเบียนเลิกธุรกิจใกล้แตะ 2 หมื่นราย ก่อนและหลังโควิดเป็นอย่างไร?. กองบรรณาธิการ SPOTLIGHT. [สืบค้นวันที่ 19 พฤษภาคม 2568]. เข้าถึงได้จาก <https://www.amarintv.com/spotlight/economy/502969>
- 2 พชร พลายพิชิต. (2567). การทำนายความล้มเหลวทางการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ด้วยการเรียนรู้ของเครื่องที่มีการจัดการข้อมูลที่ไม่สมดุล ร่วมกับการคัดเลือกตัวแปร. [สารนิพนธ์วิทยาศาสตร์มหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์].
- 3 อินทัต โกศลวิตร เคียงขวัญ อักษรวงศ์ และวิดา ลีวนานนท์ชัย. (2563). การพยากรณ์ความล้มเหลวทางการเงินของบริษัทในตลาดหลักทรัพย์แห่งประเทศไทย. วารสารบริหารศาสตรมหาวิทยาลัยอุบลราชธานี, 10(2), 41-56.
- 4 Alaka, HA., et al., (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. Expert Systems with Applications, 94, 164-184.
- 5 Lawrence, J. R., Pongsatat, S., and Lawrence, H. (2015). The Use Of Ohlson's O-Score For Bankruptcy Prediction In Thailand. The Journal of Applied Business Research, 31(6), 2069-2078.
- 6 Cunha, A. M. (2024). An accuracy test of Altman and Zmijewski accounting-based bankruptcy models. Qeios. <https://doi.org/10.32388/GRY2NL.2>
- 7 Mullainathan, S., and Spiess, J., (2017). Machine Learning: An Applied Econometric Approach. Journal of Economic Perspectives, 31(2), 87-106. <https://doi.org/10.1257/jep.31.2.87>
- 8 Kirchner, A., & Signorino, C. S. (2018). Using support vector machines for survey research. Survey Practice, 11(1). <https://doi.org/10.29115/SP-2018-0001>.
- 9 Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems, 30, 3146-3154.

- 10 Matsumaru, M., and Katagiri, H. (2025). A Two-Stage Machine Learning Approach to Bankruptcy Prediction: From Comprehensive Modeling to Feature Selection for Noise Reduction. *Preprints.org*. [https://doi: 10.20944/preprints202510.2374.v1](https://doi.org/10.20944/preprints202510.2374.v1)
- 11 LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*. <https://doi.org/10.1038/nature14539>
- 12 Opitz, D., & Maclin, R. (1999). Popular ensemble methods: An empirical study. *Journal of Artificial Intelligence Research*. <https://doi.org/10.1613/jair.614>
- 13 Pisula, T. (2020). An ensemble classifier-based scoring model for predicting bankruptcy of Polish companies in the Podkarpackie Voivodeship. *Journal of Risk and Financial Management*. <https://doi.org/10.3390/jrfm13020037>
- 14 ณิช อังตระกูล. (2564). การพยากรณ์ความเสี่ยงในการล้มละลายของบริษัทที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ด้วยตัวชี้วัดทางบัญชี และตัวชี้วัด Systemic Risk. [สารนิพนธ์การจัดการมหาบัณฑิต, มหาวิทยาลัยมหิดล].
- 15 มัทนีย์ รวีอินทร์. (2565). การพยากรณ์ความล้มเหลวทางการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย. [การค้นคว้าอิสระวิทยาศาสตรมหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์].
- 16 พิรุณพร ไพฑูรย์เจริญลาภ. (2563). การสร้างแบบจำลองในการพยากรณ์ผลการดำเนินงานจากข้อมูลในงบการเงินของบริษัทในตลาดหลักทรัพย์กรณีศึกษา กลุ่มอุตสาหกรรมเกษตรและกลุ่มอุตสาหกรรมอาหาร. [การค้นคว้าอิสระบริหารธุรกิจมหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์].
- 17 อรญา ใจสมัคร. (2565). แบบจำลองการพยากรณ์ภาวะล้มละลายของวิสาหกิจขนาดกลางและขนาดย่อมในประเทศไทย. [การค้นคว้าอิสระวิทยาศาสตรมหาบัณฑิต, มหาวิทยาลัยเชียงใหม่].
- 18 สกฤตกาญจน์ ทองคำ และนุรีย์ วิวัฒน์วัฒนา. (2565). การเรียนรู้ของเครื่องเพื่อการทำนายการผิดนัดชำระของลูกหนี้ บัตรเครดิต. 2022 2nd Proceeding of the Data Science Conference. [วิทยาศาสตรมหาบัณฑิต, มหาวิทยาลัยศรีนครินทรวิโรฒ].
- 19 ชญานิษฐ์ เมืองสง, ขจิตพรณ กฤตพลวิมาน และรัชกฤษ ชนพัฒน์. (2567). การพยากรณ์การเกิดพายุฝนฟ้าคะนองระยะปัจจุบัน ด้วยเทคนิคการเรียนรู้ของเครื่องกรณีศึกษาสนามบินภาคเหนือของประเทศไทย. *วารสารวิชาการมหาวิทยาลัยอีสเทิร์นเอเซีย ฉบับวิทยาศาสตร์และเทคโนโลยี*, 18(2), 59-77.

- 20 ปภากร ศรีวงศ์ชัย และอนิรุทธิ์ อัสวสกุลสร. (2567). การพยากรณ์ยอดขายไก่เนื้อด้วยเทคนิคการเรียนรู้ของเครื่อง. Journal of MCU Ubon Review, 9(2), 594-600.
- 21 โชติมา ดีพัฒน์. (2564). การพัฒนาแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องเพื่อพยากรณ์พื้นที่ในประเทศไทยที่มีความเสี่ยงได้รับผลกระทบจากการเกิดดินโคลนถล่ม. [สารนิพนธ์วิศวกรรมศาสตรมหาบัณฑิต, มหาวิทยาลัยธุรกิจบัณฑิต].
- 22 นัทวุฒิ ชันชกรสิกรรม, ศรัณย์ นาคณอม และเตชคุศลีนป์ เพียชัย. (2565). การพัฒนาโมเดลพยากรณ์สำหรับปริมาณการรับส่งข้อมูลอินเทอร์เน็ตโดยใช้เทคนิคโครงข่ายประสาทเทียม. Journal of Science and Technology, Sukhothai Thammathirat Open University, 2(2), 32-44.
- 23 Zhao, J., Ouenniche, J. and De Smedt, J. (2004). A complex network analysis approach to bankruptcy prediction using company relational information-based drivers. Knowledge-Based Systems. <https://doi.org/10.1016/j.knosys.2024.112234>
- 24 Zhao, Y., et al. (2022). Combining Intra-Risk and Contagion Risk for Enterprise Bankruptcy Prediction Using Graph Neural Networks. arXiv. <https://doi.org/10.48550/arXiv.2202.03874.pdf>
- 25 Malakauskas, A. and Lakstutiene, A. (2021). Financial Distress Prediction for Small and Medium Enterprises Using Machine Learning Techniques. Inzinerine Ekonomika-Engineering Economics, 2021, 32(1), 4–14.
- 26 Alanis, E., Chava, S., & Shah, A. (2022). Benchmarking machine learning models to predict corporate bankruptcy. arXiv. <https://doi.org/10.48550/arXiv.2212.12051>
- 27 Kim, A. G., & Yoon, S. (2021). Corporate Bankruptcy Prediction with Domain-Adapted BERT. arXiv. <https://doi.org/10.48550/arXiv.2110.13459>
- 28 Iparraguirre-Villanueva, O., & Cabanillas-Carbonell, M. (2024). Predicting business bankruptcy: A comparative analysis with machine learning models. Journal of Open Innovation: Technology, Market, and Complexity. <https://doi.org/10.1016/j.joitmc.2024.100375>

- 29 Hamdi, M., Mestiri, S., & Arbi, A. (2024). Artificial intelligence techniques for bankruptcy prediction of Tunisian companies: An application of machine learning and deep learning-based models. Journal of Risk and Financial Management. <https://doi.org/10.3390/jrfm17040132>
- 30 Kuiziniene, D., et al. (2022). Systematic Review of Financial Distress Identification using Artificial Intelligence Methods. Applied Artificial Intelligence, 36(1), 3526-3571. <https://doi.org/10.1080/08839514.2022.2138124>
- 31 Vásquez-Serpa, L., et al. (2025). Challenges of Artificial Intelligence for the Prevention and Identification of Bankruptcy Risk in Financial Institutions: A Systematic Review. Journal of Risk and Financial Management, 18(26). <https://doi.org/10.3390/jrfm18010026>
- 32 Noh, S. (2023). Comparing the Performance of Corporate Bankruptcy Prediction Models Based on Imbalanced Financial Data. Sustainability. <https://doi.org/10.3390/su15064794>.
- 33 ธัญญ์วี ขวรัตน์รังษี และคณะ. (2566). การพยากรณ์-ความแม่นยำ เพื่อวิเคราะห์ประมาณการยอดขายสินค้าขายปลีก กรณีศึกษา Walmart. การประชุมวิชาการระดับชาติและระดับนานาชาติ เบญจมิตรวิชาการ ครั้งที่ 13. กรุงเทพมหานคร: มหาวิทยาลัยกรุงเทพสุพรรณภูมิ.
- 34 ปวีศ เวชวรรณกิจกุล และพิศิษฐ์ จารุมณีโรจน์. (2565). การพยากรณ์ระยะเวลาการเดินทางด้วยวิธีการเรียนรู้ของเครื่อง โดยใช้ข้อมูลจากพาหนะ และโทรศัพท์มือถือในจังหวัดกรุงเทพมหานคร. Thai Journal of Operations Research: TJOR, 10(2), 54-62.



ประวัติผู้เขียน

ชื่อ	พงศ์ธร แป้นไทย
ชื่อการค้นคว้าอิสระ	การพยากรณ์การเลิกกิจการของนิติบุคคลในประเทศไทย จากข้อมูลงบการเงินด้วยเทคนิคการเรียนรู้ของเครื่อง
สาขาวิชา	ระบบสารสนเทศเพื่อการจัดการ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ประวัติ	ปริญญาตรี วิทยาศาสตร์บัณฑิต สาขาเศรษฐศาสตร์เกษตร มหาวิทยาลัยเกษตรศาสตร์

