

การคาดคะเนการทุจริตจากงบการเงินโดยใช้แบบจำลองโครงข่ายประสาทเทียม สำหรับการตรวจสอบบัญชี

Fraud Prediction from Financial Statements Using an Artificial Neural Network Model for Auditing

ไพโรจน์ เกตุภักดีกุล^{1*}, พิรัชญา คานะโกะ² และ พัทยา เห็นกลาง³

Pairote Ketpakdeekul^{1*}, Pitachaya Kaneko², and Pattareya Henklang³

^{1,2,3} คณะบริหารธุรกิจ มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร

^{1,2,3} Faculty of Business Administration, Rajamangala University of Technology Phra Nakorn

*Corresponding author, email: pairote.k@mail.rmutk.ac.th

Received: 1 Apr 2024, Revised: 4 May 2024, Accepted: 20 May 2024

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) สำหรับตรวจจับแนวโน้มการทุจริตทางการเงินจากงบการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ด้วยการทบทวนวรรณกรรมและแนวคิดที่เกี่ยวข้องกับทฤษฎีตัวแทน (Agency Theory) ที่มีความสัมพันธ์กับแนวคิดสามเหลี่ยมการทุจริต (Fraud Triangle) และการนำเสนองบการเงินเพื่อตรวจหาการทุจริตด้วย Beneish M-Score ในแบบดั้งเดิมและความก้าวหน้าของเทคโนโลยีโครงข่ายประสาทเทียมที่สอดคล้องกับข้อจำกัดของการตรวจสอบข้อมูลที่จัดเก็บในรูปแบบฐานข้อมูลทำให้ผู้สอบบัญชีใช้เทคโนโลยีช่วยในการตรวจสอบบัญชี ดังนั้น การวิจัยนี้ใช้แบบจำลองโครงข่ายประสาทเทียมในการคาดคะเนการทุจริตจากงบการเงินได้อย่างรวดเร็วและแม่นยำเป็นเครื่องมือหลักในการวิเคราะห์และทำนายแนวโน้มการทุจริต ผลลัพธ์ที่ได้จากการประเมินประสิทธิภาพแบบจำลองที่พัฒนาขึ้นจากข้อมูล 2,001 ชุดข้อมูลมีประสิทธิภาพสูง โดยแบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด (Best Model) มีความแม่นยำโดยรวม ร้อยละ 94.02 และค่าความเชื่อมั่น ร้อยละ 80.41 หลังปรับเทียบ (Calibration) ส่วนผลการวิเคราะห์ Feature Importance ที่มีอิทธิพลในการคาดคะเนสูง คือ อัตราส่วนทุนหมุนเวียน (Current Ratio) ผลลัพธ์ พบว่า แบบจำลองโครงข่ายประสาทเทียมที่พัฒนาขึ้นเป็นเครื่องมือที่มีคุณค่าสำหรับการวางแผนและปรับปรุงกระบวนการตรวจสอบบัญชีที่สามารถคาดคะเนการทุจริตในงบการเงินได้อย่างแม่นยำและน่าเชื่อถือและอาจพัฒนาแบบจำลองโครงข่ายประสาทเทียมเป็นเครื่องมือการตรวจสอบภายในเพิ่มเติมได้

คำสำคัญ: การทุจริต, งบการเงิน, โครงข่ายประสาทเทียม, การตรวจสอบบัญชี

Abstract

This research aims to develop an Artificial Neural Network (ANN) model for detecting financial fraud trends from the financial statements of companies listed on the Stock Exchange of Thailand. By reviewing literature and concepts related to agency theory, which is associated with the fraud triangle concept and the presentation of financial statements, the study seeks to detect fraud using the traditional Beneish M-Score, and advances in artificial neural network technology to overcome the limitations of auditing information stored in database formats, enabling auditors to use technology in auditing. Therefore, this research employs an artificial neural network model to predict fraud quickly and accurately from financial statements as a primary tool for analyzing and predicting fraud trends. The evaluation results of the model developed from 2,001 datasets, demonstrate high efficiency. The best artificial neural network model achieved an overall accuracy of 94.02% and a confidence level of 80.41% after calibration. The analysis of Feature Importance identified the Current Ratio as having a significant influence on prediction. These results indicate that the developed ANN model is a valuable tool for planning and improving the auditing process, capable of accurately and reliably predicting fraud in financial statements. Furthermore, the ANN model may be further developed into an additional internal auditing tool.

Keywords: Fraud, Financial statement, Artificial Neural Network, Auditing

บทนำ

ความรับผิดชอบของผู้สอบบัญชีที่มีต่อการตรวจสอบงบการเงินมีวัตถุประสงค์เพื่อให้ได้ความเชื่อมั่นอย่างสมเหตุสมผลว่างบการเงินโดยรวมปราศจากการแสดงข้อมูลที่ขัดต่อข้อเท็จจริงอันเป็นสาระสำคัญหรือไม่ (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2559) การตรวจสอบการทุจริตเป็นการตรวจสอบข้อเท็จจริงในการปฏิบัติงานสะท้อนออกมาในคุณภาพข้อมูลทางบัญชี (Hribar et al., 2014) และอาศัยคุณภาพของผู้สอบบัญชีในการใช้ความสงสัยเยี่ยงผู้ประกอบวิชาชีพมีความสัมพันธ์ทางตรงกับคุณภาพการตรวจสอบ (Kusumawati & Syamsuddin, 2018) ประสิทธิภาพการทำงาน และคุณลักษณะเฉพาะตัวของผู้สอบบัญชีรับอนุญาต (Suryandari & Yuesti, 2017) และเป้าหมายการตรวจจับทุจริต (Red Flag) (Rahim et al., 2019) ตามแนวคิดสามเหลี่ยม

การทุจริต (Fraud Triangle) ซึ่งเป็นปัจจัยภายในกิจการทั้ง 3 ด้าน คือ โอกาส ข้ออ้าง และแรงกดดัน (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2555ก; Turner et al., 2003) ความรับผิดชอบในการตรวจสอบบัญชีได้รวมไปถึงการป้องกันการทุจริต (Fraud Prevention) ซึ่งส่งผลกระทบต่อความไว้วางใจของนักลงทุน (Yazid & Suryanto, 2017)

การทุจริตทางการเงินในองค์กรเป็นปัญหาสำคัญ เช่น กรณีศึกษาของ Enron Corporation ประสบกับการล่มสลายอย่างรวดเร็วในปี ค.ศ. 2001 (พ.ศ. 2544) เนื่องจากการทุจริตถูกการเปิดเผยที่เกิดจากรายการทางการเงินและการบัญชีที่ซับซ้อน การใช้บริษัทหลักทรัพย์ปลอมและการบิดเบือนงบการเงินเพื่อแสดงผลกำไรที่ไม่มีอยู่จริง (Healy & Palepu, 2003; Mubako & O'Donnell, 2018) ซึ่งการทุจริตเหล่านี้มักเกี่ยวข้องกับการบิดเบือนข้อมูลในงบการเงิน การใช้เทคนิคการบัญชีที่ซับซ้อนเพื่อซ่อนหนี้สินหรือผลขาดทุน และการเพิ่มรายได้โดยไม่ชอบด้วยกฎหมายเพื่อหลอกลวงผู้ลงทุนและตลาดหุ้น กรณีตัวอย่างเช่น กรมบังคับคดี (2566) รับกรณีบริษัทสตาร์ค คอร์ปอเรชั่น จำกัด (มหาชน) เป็นคดีพิเศษและได้เชิญผู้สอบบัญชีไปให้ปากคำในฐานะพยาน ดังนั้นบทบาทสำคัญของผู้สอบบัญชีไม่เพียงแต่การทำหน้าที่ตรวจสอบและยืนยันความถูกต้องของข้อมูลในงบการเงินเท่านั้น ผู้สอบบัญชีจึงมีความรับผิดชอบที่สำคัญในการตรวจสอบความถูกต้องของข้อมูลและใช้หลักวิชาชีพที่มีคุณภาพในการประเมินความเสี่ยงจากการทุจริต (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2555ก) เครื่องมือ Beneish M-Score ที่ใช้สูตร 8 ตัวแปรในการคาดคะเนการทุจริตจากข้อมูลในงบการเงิน หากผลการคำนวณที่ได้มีค่ามากกว่า -2.22 จะมีแนวโน้มการทุจริต (Beneish, 1999) ทำให้ผู้สอบบัญชีจำเป็นต้องพัฒนาเครื่องมือและเทคนิคใหม่ที่ทันสมัยในการวิเคราะห์และตรวจสอบข้อมูลทางการเงินที่จัดเก็บในรูปแบบข้อมูลอิเล็กทรอนิกส์ เช่น การใช้เทคโนโลยีโครงข่ายประสาทเทียม (ANN) ร่วมกับเหมืองข้อมูลทางการเงิน (Dashtbayaz & Mohammad, 2015) เป็นส่วนหนึ่งที่จะต้องนำไปร่วมพิจารณาในการกำหนดระดับความเสี่ยงในการตรวจสอบเมื่อผู้สอบบัญชีปฏิบัติงานในขั้นตอนการวางแผน (Dashtbayaz & Mohammad, 2015; Mubako & O'Donnell, 2018) การใช้แบบจำลองโครงข่ายประสาทเทียมเป็นเทคนิคหนึ่งที่สามารถวิเคราะห์และตรวจจับความสัมพันธ์ของข้อมูลทางการเงินที่ซับซ้อนและไม่เชิงเส้นระหว่างตัวแปรได้อย่างมีประสิทธิภาพสูงกว่าเทคนิคทั่วไปอย่าง Logistic Regression หรือ Decision Trees ที่อาจมีข้อจำกัดในการจัดการกับข้อมูลที่มีมิติสูงและความซับซ้อน (Japkowicz, 2001) โดยเฉพาะในการตรวจจับการทุจริตในงบการเงินที่ต้องการความแม่นยำสูงในการจับความผิดปกติ ลดโอกาสของการทำนายผิดพลาดที่อาจเกิดจากการฝึกฝนเกินไป (Overfitting) ซึ่งเป็นปัญหาสำคัญในเทคนิคการวิเคราะห์อื่น (Kak, 1993; Lechner, 2020) และโครงข่ายประสาทเทียมสามารถแสดงความสำคัญของฟีเจอร์ (Feature) เพื่อให้ผู้สอบบัญชีรับอนุญาตนำมาวิเคราะห์และใช้ในการพัฒนาแนวการตรวจสอบและคาดคะเนความเสี่ยงของการทุจริต

ที่ทำงานร่วมกันระหว่างผู้สอบบัญชีและเทคโนโลยีขั้นสูงนี้จะนำไปสู่การพัฒนาวิธีการตรวจสอบที่มีประสิทธิภาพสูงสุด และเป็นการปกป้องผู้ลงทุนและเสริมสร้างความเชื่อมั่นในตลาดทุนได้อย่างมั่นคง (Topor, 2017)

การวิจัยนี้มีความสำคัญในการสร้างเครื่องมือช่วยผู้สอบบัญชีรับอนุญาตในการตรวจสอบบัญชีบนพื้นฐานของการตรวจจับแนวโน้มการทุจริตจากงบการเงินตามมาตรฐานการสอบบัญชี ซึ่งสามารถช่วยลดความเสี่ยงทางการเงินและเสริมสร้างความเชื่อมั่นให้กับผู้มีส่วนได้เสีย

วัตถุประสงค์ของการวิจัย

มุ่งเน้นการศึกษาความสามารถของโครงข่ายประสาทเทียมในการตรวจจับการทุจริตในงบการเงินเพื่อการตรวจสอบบัญชี และพัฒนาแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ที่มีความสามารถทำนายการทุจริตในงบการเงินได้

การทบทวนวรรณกรรม

ด้วยการทบทวนวรรณกรรมและแนวคิดที่เกี่ยวข้องกับทฤษฎีตัวแทน (Agency Theory) ที่มีความสัมพันธ์กับแนวคิดสามเหลี่ยมการทุจริต (Fraud Triangle) ลักษณะเชิงคุณภาพของข้อมูลทางการเงินที่มีประโยชน์ การวัดผลการดำเนินงาน เครื่องมือคำนวณ Beneish M-Score และโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)


1. ทฤษฎีตัวแทน (Agency Theory)

ความสัมพันธ์ระหว่างตัวการ (Principal) และตัวแทน (Agent) ภายใต้สัญญาทางธุรกิจนั้น การประยุกต์ใช้ทฤษฎีตัวแทนเพื่อพรรณนาความสัมพันธ์อันจะเกิดขึ้นระหว่างตัวการ (เจ้าของกิจการ ผู้เป็นเจ้าของส่วนทุน) กับตัวแทน (คณะกรรมการบริษัท) โดยเมื่อทำสัญญาจ้างแล้ว เจ้าของจะมอบอำนาจในการบริหารจัดการทรัพยากรทั้งหมดแก่ผู้บริหารเพื่อการสร้างมูลค่าของกิจการให้อยู่ในระดับที่สูงที่สุด (ศิลปพร ศรีจันเพชร, 2551; Jensen & Meckling, 1976) และมีการควบคุมไม่ให้ตัวแทนดำเนินการที่ไม่เหมาะสม ควบคุมต้นทุนตัวแทนและบริหารความขัดแย้งระหว่างตัวการกับตัวแทน สำหรับผู้สอบบัญชีรับอนุญาตเป็นตัวแทนของผู้ถือหุ้นในฐานะตัวการตามหลักทฤษฎีตัวแทน (Agency Theory) ในการเข้าทำการตรวจสอบงบการเงินของกิจการตามสิ่งที่ผู้บริหารได้ให้การรับรองเกี่ยวกับงบการเงินว่างบการเงินโดยรวมปราศจากการแสดงข้อมูลที่ขัดต่อข้อเท็จจริงอันเป็นสาระสำคัญหรือไม่ ไม่ว่าจะเป็นเกิดจากการทุจริตหรือข้อผิดพลาด ซึ่งช่วยให้ผู้สอบบัญชีสามารถแสดงความเห็นได้ว่า งบการเงินได้จัดทำขึ้นในสาระสำคัญตามแบบทการรายงานทางการเงินที่เกี่ยวข้องหรือไม่ และรายงานต่องบการเงินและสื่อสารให้บุคคลที่เกี่ยวข้องได้รับทราบ (สภาวิชาชีพบัญชี ในพระบรม

ราชูปถัมภ์, 2555) การพิจารณาข้อเท็จจริงโดยเจตนาที่ผู้สอบบัญชีต้องคำนึงถึงมีอยู่ 2 ประเภท คือ 1) การจัดทำรายงานทางการเงินที่ทุจริต และ 2) การใช้สินทรัพย์ในทางที่ไม่เหมาะสม (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2555) การตรวจสอบบัญชียังมีความเสี่ยงที่หลีกเลี่ยงไม่ได้ คือ การแสดงข้อมูลที่ขัดต่อข้อเท็จจริงในงบการเงินที่ไม่อาจตรวจพบ ถึงจะมีการวางแผนและมีการปฏิบัติงานอย่างเหมาะสมตามมาตรฐานการสอบบัญชีแล้วก็ตาม ซึ่งเป็นผลมาจากการทุจริตของผู้บริหารนั้นมากกว่า ความเสี่ยงที่ผู้สอบบัญชีไม่สามารถตรวจพบ

2. แนวคิดสามเหลี่ยมการทุจริต (Fraud Triangle)

ประเภทของการทุจริตที่ ACFE (2021) ได้นำเสนอไว้มี 3 ประเภทหลัก คือ 1. ยักยอกทรัพย์ (Asset Misappropriation) 2. การคอร์รัปชัน (Corruption) และ 3. การทุจริตรายงานทางการเงิน (Financial Statement Fraud) ไม่ว่าการทุจริตในประเภทใดก็ตาม การทุจริตจะเกิดจากองค์ประกอบ 3 ด้าน คือ 1. แรงกดดัน (Pressure) 2. โอกาส (Opportunity) และ 3. การหาเหตุผลอันสมควร (Rationalization) ทำให้เรียกว่า สามเหลี่ยมการทุจริต (Fraud Triangle) การทุจริตอาจจะเกิดขึ้นหากมีองค์ประกอบครบ แสดงดังรูปที่ 1



รูปที่ 1 สามเหลี่ยมการทุจริต (Fraud Triangle) (ACFE, 2021)

ผลการสำรวจการทุจริต (ฉ้อโกง) ในระดับนานาชาติมีแนวโน้มเพิ่มมากขึ้น และเป็นการทุจริตจากงบการเงินมากเป็นอันดับ 2 (ACFE, 2020; Pricewaterhousecoopers, 2020) จึงเป็นเหตุผลที่ผู้สอบบัญชีรับอนุญาต (CPA) ต้องทำความเข้าใจธุรกิจ เพื่อเป็นตัวแทนของผู้ถือหุ้นในการตรวจสอบความถูกต้อง ครบถ้วน ของงบการเงินว่าแสดงข้อมูลที่ขัดต่อข้อเท็จจริงอันเป็นสาระสำคัญหรือไม่ และการตรวจสอบการทุจริตเป็นอีกหนึ่งสิ่งที่จะต้องปฏิบัติในการตรวจสอบตามมาตรฐานการสอบบัญชีที่รับรองทั่วไป

3. ลักษณะเชิงคุณภาพของข้อมูลทางการเงินที่มีประโยชน์

กรอบแนวคิดสำหรับการรายงานทางการเงินให้แนวคิดไว้ว่า ข้อมูลการเงินจะมีประโยชน์ก็ต่อเมื่อข้อมูลนั้นเกี่ยวข้องกับการตัดสินใจและเป็นตัวแทนอันเที่ยงธรรมถึงสิ่งที่ตั้งใจจะสื่อ กล่าวคือ ลักษณะเชิงคุณภาพพื้นฐานของข้อมูลการเงิน และประโยชน์จะเพิ่มขึ้นหากมีลักษณะเชิงคุณภาพเสริม ได้แก่ การเปรียบเทียบกันได้ การพิสูจน์ยืนยันได้ ความทันเวลา ความเข้าใจได้ แต่ข้อจำกัดด้านต้นทุนต่อการรายงานทางการเงินที่มีประโยชน์นั้นพิจารณาจากต้นทุนที่เสียไปกับผลประโยชน์ของการรายงานข้อมูลนั้น (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2563) งบการเงินจัดทำขึ้นเพื่อวัตถุประสงค์ในการให้ข้อมูลเกี่ยวกับสินทรัพย์ หนี้สิน ส่วนของเจ้าของ รายได้ และค่าใช้จ่ายของกิจการที่เสนอรายงาน ข้อมูลดังกล่าวปรากฏในงบแสดงฐานะการเงิน งบกำไรขาดทุนเบ็ดเสร็จ งบแสดงการเปลี่ยนแปลงส่วนของผู้ถือหุ้น และงบกระแสเงินสด ซึ่งมีประโยชน์ต่อผู้ใช้งบการเงินในการประเมินความเป็นไปได้สำหรับกระแสเงินสดรับสุทธิในอนาคต และการประเมินหน้าที่และความรับผิดชอบของฝ่ายบริหารต่อทรัพยากรเชิงเศรษฐกิจของกิจการที่เสนอรายงาน (สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์, 2563)

4. การวัดผลการดำเนินงาน (Business Performance)

การวิเคราะห์อัตราส่วน (Ratio Analysis) จากข้อมูลในงบการเงินที่เป็นตัวเลข ได้แก่ งบแสดงฐานะการเงิน งบกำไรขาดทุนเบ็ดเสร็จ งบแสดงการเปลี่ยนแปลงส่วนของผู้ถือหุ้น และงบกระแสเงินสด นำมาคำนวณเพื่อวัดผลการดำเนินงานแบ่งออกเป็น 4 กลุ่ม ได้แก่ 1. อัตราส่วนสภาพคล่อง (Liquidity Ratios) 2. อัตราส่วนประสิทธิภาพในการดำเนินงาน (Activity Ratios) 3. อัตราส่วนโครงสร้างเงินทุนและความสามารถในการชำระหนี้ (Leveraged Ratios) และ 4. อัตราส่วนความสามารถในการทำกำไรและผลตอบแทนจากการลงทุน (Profitability Ratio) งานวิจัยนี้มุ่งเน้นตอบสนองอัตราส่วนทางการเงินที่คำนวณจากข้อมูลในงบการเงินเป็นพื้นฐานเป็นหลัก ผู้สอบบัญชีรับอนุญาตใช้อัตราส่วนทางการเงินเพื่อหาแนวโน้มการทุจริตเพื่อประเมินและนำไปวางแผนการตรวจสอบงบการเงิน เพื่อตรวจสอบงบการเงินและแสดงความเห็นต่องบการเงินว่าถูกต้องตามที่ควรตามหลักการบัญชีที่รับรองทั่วไป และไม่มีข้อมูลที่ขัดต่อข้อเท็จจริงอันเป็นสาระสำคัญ

5. เครื่องมือตรวจจบบการทุจริต M-Score

ตัวแบบจำลอง Beneish M-Score มีตัวแปรทั้งหมด 8 ตัวแปร พิจารณาการบิดเบือนตัวเลขในงบการเงินว่าเป็นผลมาจากการจัดการรายได้หรือมาจากโครงสร้างอื่นนั้น การเก็บข้อมูลจากงบการเงิน ได้แก่ 1. ดัชนีลูกหนี้ต่อยอดขาย (Days Sales in Receivables Index: DSRI) 2. ดัชนีอัตรากำไรขั้นต้น (Gross Margin Index: GMI) 3. ดัชนีคุณภาพของสินทรัพย์ (Asset Quality Index: AQI) 4. ดัชนีการเติบโตของยอดขาย (Sales Growth Index: SGI) 5. ดัชนีค่าเสื่อมราคา (Depreciation Index: DEPI) 6. ดัชนีค่าใช้จ่ายในการขายและบริหาร (Sales, General and Administrative

Expenses Index: SGAI) 7. อัตราส่วนเงินทุนหมุนเวียนคงค้างต่อสินทรัพย์รวม (Total Accrual to Total Assets: TATA) 8. ดัชนีความสามารถในการชำระหนี้ (Leverage Index: LVGI) (พรรณนิภา รอดวรรณะ, 2564; Beneish, 1999; Beneish & Vorst, 2020) สูตรในการคำนวณดังนี้

$$M = - 4.84 + 0.920 \cdot \text{DSRI} + 0.528 \cdot \text{GMI} + 0.404 \cdot \text{AQI} + 0.892 \cdot \text{SGI} \\ + 0.115 \cdot \text{DEPI} - 0.172 \cdot \text{SGAI} + 4.679 \cdot \text{TATA} - 0.327 \cdot \text{LVGI}$$

6. โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

ปัญญาประดิษฐ์เป็นการทำให้เครื่องจักรทำงานเลียนแบบมนุษย์ (Artificial Intelligence) ด้วยการทำให้เครื่องจักรเรียนรู้ (Machine Learning) ได้อย่างสมองมนุษย์มากขึ้น การเรียนรู้ของเครื่องเชิงลึก (Deep Learning) มีเรียนรู้อยู่ 4 รูปแบบ คือ 1. แบบมีการสอนหรือมีการฝึกฝน (Supervised) 2. แบบมีการสอนหรือไม่มีการฝึกฝน (Unsupervised) 3. แบบกึ่งมีผู้สอนหรือกึ่งมีการฝึกฝน (Semi-supervised) และ 4. แบบเสริมแรง (Reinforcement) การเรียนรู้ของเครื่องแบบไม่ซับซ้อน คือ มีโครงสร้างของโครงข่ายเป็นชั้นนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นผลลัพธ์ (Output Layer) อย่างละ 1 ชั้น แต่เมื่อมีชั้นซ่อนเพิ่มขึ้นเราจะเรียกว่าเป็นการเรียนรู้ของเครื่องเชิงลึก (Deep Learning) ซึ่งชั้นซ่อนมีได้ไม่จำกัดจำนวนขึ้นอยู่กับผู้พัฒนาแบบจำลอง กำหนดให้เหมาะสม สำหรับโครงข่ายป้อนไปข้างหน้าเชิงลึก (Deep feedforward network) หรือเรียกอีกอย่างว่า โครงข่ายแบบหลายชั้น (Multilayer Perceptron: MLP) มีนักวิจัยจำนวนมากใช้ในการวิจัยเชิงเปรียบเทียบประสิทธิภาพระหว่างโครงข่ายประสาทเทียมกับเทคนิคอื่น

7. งานวิจัยที่เกี่ยวข้อง

การตรวจสอบบัญชีมีขึ้นเพื่อยืนยันความถูกต้องของงบการเงินภายใต้มาตรฐานการรายงานทางการเงิน ซึ่งผู้สอบบัญชีมีบทบาทสำคัญในการทำหน้าที่เป็นตัวแทนของผู้ถือหุ้นเพื่อตรวจสอบงบการเงินที่ผู้บริหารรับรอง (Jensen & Meckling, 1976) และตรวจสอบว่าไม่มีการทุจริตหรือข้อผิดพลาดอย่างมีนัยสำคัญ โดยต้องปฏิบัติตามกฎหมายและมาตรฐานการสอบบัญชีที่กำหนดไว้ ทั้งนี้ผู้สอบบัญชีต้องพิจารณาในมุมมองของการเงินตามที่งานวิจัยของ ผัสย์ศุภา หลงทอง และนิมมวล วิเศษสรรพ (2562) ได้แสดงถึงการใช้อัตราส่วนทางการเงินเพื่อการตรวจสอบความมีเสถียรภาพทางการเงิน ประสิทธิภาพ โครงสร้างทุน และความสามารถในการทำกำไร ซึ่งมีการใช้ข้อมูลทางการเงินเป็นหลักในการคำนวณ การตรวจสอบดังกล่าวอาจพบการทุจริต จากการศึกษาโดย ACFE (2020; 2021) และ Pricewaterhousecoopers (2020) ได้ระบุว่า การยกยอกทรัพย์สินเป็นประเภทที่พบมากที่สุดของการทุจริต และในประเทศไทย การทุจริตด้านการบัญชีและงบการเงิน

อยู่ในอันดับสาม การวิจัยโดย Nawaiseh et al. (2020) ได้แสดงถึงการใช้โครงข่ายประสาทเทียมแบบ Feedforward และ Backpropagation เพื่อประเมินความเห็นของผู้สอบบัญชี ซึ่งได้ผลลัพธ์ที่แม่นยำและมีอัตราความผิดพลาดต่ำ นอกจากนี้ Omar et al. (2017) ได้เสนอการใช้แบบจำลอง Beneish M-Score ในการวิเคราะห์แนวโน้มการทุจริตจากข้อมูลงบการเงินผ่านโครงข่ายประสาทเทียม โดยผลการวิจัยแสดงให้เห็นว่าโครงข่ายประสาทเทียมสามารถเรียนรู้และทำนายการทุจริตได้เป็นอย่างดี

สมมติฐาน

สมมติฐานหลัก (H_0)


โครงข่ายประสาทเทียมสามารถเรียนรู้และคาดคะเนข้อมูลทุจริตจากงบการเงินได้

สมมติฐานรอง (H_1)

โครงข่ายประสาทเทียมไม่สามารถเรียนรู้และคาดคะเนข้อมูลทุจริตจากงบการเงินได้

กรอบแนวคิดการวิจัย

การคาดคะเนการทุจริตจากงบการเงินโดยใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการตรวจสอบบัญชี มุ่งเน้นศึกษาข้อมูลในอดีตที่เป็นข้อมูลทางการเงิน เช่น ยอดคงเหลือในบัญชี เพื่อคำนวณค่า M-Score และนำค่าดังกล่าวเป็นปัจจัยกับช่วงงบการเงินนั้นมีแนวโน้มการทุจริตหรือไม่มีการทุจริต ในอีกด้านหนึ่งจะนำยอดคงเหลือในบัญชีไปหาอัตราส่วนทางการเงิน และนำองค์ประกอบในการคำนวณ M-Score กับอัตราส่วนทางการเงินใช้เป็นข้อมูลนำเข้า (Feature) เพื่อฝึกฝนและทดสอบโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ให้มีความแม่นยำและน่าเชื่อถือเพื่อสรุปสมมติฐานการวิจัยที่ว่า “โครงข่ายประสาทเทียมสามารถเรียนรู้และคาดคะเนข้อมูลทุจริตจากงบการเงินได้ (H_0)” และทราบตัวแปรที่สำคัญในการประมวลผลเพื่อให้ผู้สอบบัญชีรับอนุญาตนำตัวแปรดังกล่าวไปใช้เพื่อการตรวจสอบบัญชีต่อไป กรอบแนวคิดการวิจัยปรากฏตามรูปที่ 2



รูปที่ 2 กรอบแนวคิดการวิจัย

วิธีดำเนินการวิจัย

งานวิจัยนี้ใช้ระเบียบวิธีวิจัยเชิงเอกสาร (Documentary Research) วิธีการดำเนินการมีดังนี้

1. ศึกษาทฤษฎีและเอกสารงานวิจัยที่เกี่ยวข้องกับการทุจริตทางการเงินที่เกี่ยวข้องกับข้อมูลในงบการเงินที่ระบุถึงปัจจัยในการตรวจสอบการทุจริตหรือล้มละลายด้วยโครงข่ายประสาทเทียม

2. รวบรวมข้อมูลจากงบการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย

2.1 ประชากร คือ ข้อมูลจากงบการเงินที่แสดงไว้ในรายงานประจำปี (Annual Report) ของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย (SET) ที่เผยแพร่ต่อสาธารณะ และคงสถานะเป็นบริษัทจดทะเบียน ณ วันที่ 31 สิงหาคม 2565 ทั้งนี้ไม่รวมกลุ่มอุตสาหกรรมบริการการเงินกองทุนรวมและทรัสต์มีทั้งสิ้น 547 บริษัท มีประชากรที่ใช้ในการวิจัย 3,282 ชุดข้อมูล

2.2 กลุ่มตัวอย่าง คือ ชุดข้อมูลที่จัดเก็บจากกลุ่มประชากรจำนวน 3,039 ชุดข้อมูล คิดเป็นร้อยละ 92.60 ของประชากร

3. นำข้อมูล 3,039 ชุดข้อมูลที่รวบรวมได้มาวิเคราะห์การแจกแจงของข้อมูลเพื่อคัดกรองข้อมูลที่มีความผิดปกติ Outliner ที่ระดับ 4.5 จนเหลือ 2,001 ชุดข้อมูลสำหรับการฝึกฝนและทดสอบแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

4. นำเสนอผลโดยใช้โปรแกรม Python บน Google Colab ที่มีผลการวิเคราะห์เชิงพรรณนา การวิเคราะห์เชิงอนุมาน และผลการทดสอบและประเมินประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียม

ผลการวิจัย

ประสิทธิภาพในการทำงานของโครงข่ายประสาทเทียม เมทริกซ์การประเมินประสิทธิภาพ และการประเมินความสามารถแบบจำลอง


1. ประสิทธิภาพในการทำงานของโครงข่ายประสาทเทียม

1.1 โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ของแบบจำลอง

แบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด (Best Model) ที่มีความแม่นยำโดยรวมร้อยละ 94.02 และความน่าเชื่อถือ ร้อยละ 80.41 หลังจากปรับเทียบ และแบบจำลองนี้เป็นการเรียนรู้เชิงลึก (Deep Learning) มีจำนวนชั้นนำเข้า 1 ชั้น 23 นิวรอน และชั้นซ่อน 2 ชั้น ที่มี 12 นิวรอน ในชั้นซ่อนที่ 1 และ 9 นิวรอน ในชั้นซ่อนที่ 2 และชั้นผลลัพธ์ 1 ชั้น 1 นิวรอน และมีการทำปรับเทียบ (Calibration) ด้วยค่า “bias” และ “weight” เพื่อให้แบบจำลองมีประสิทธิภาพและเหมาะสมที่สุดยิ่งขึ้น ด้วยการลดความเบี่ยงเบนของความผิดพลาด (ช่วยเพิ่มความเที่ยงตรง) และเพิ่มความสามารถในการทำนายที่แม่นยำ เพื่อให้เหมาะสมกับข้อมูลการทุจริตจริงในสถานการณ์การตรวจสอบบัญชี

1.2 การวิเคราะห์ความเคลื่อนไหวของการฝึกฝน


กราฟที่นำเสนอแสดงให้เห็นถึงการเปลี่ยนแปลงของค่าความสูญเสีย (Loss) และค่าความแม่นยำโดยรวม (Accuracy) ตลอดจนการฝึกฝนตามจำนวนรอบการเรียนรู้ (Epochs) ตามรูปที่ 3 พบว่า ค่าความสูญเสีย (Log Loss) มีแนวโน้มคงที่หลังจากผ่านรอบการเรียนรู้ที่ 20 เป็นต้นไป และค่าความแม่นยำโดยรวม (Accuracy) กับค่าความสูญเสียมีความสมดุลที่รอบการเรียนรู้ที่ 92



รูปที่ 3 ความสัมพันธ์ระหว่างค่าความสูญเสียและค่าความแม่นยำโดยรวมแต่ละรอบการฝึกฝน

1.3 วิเคราะห์การแจกแจงข้อมูลด้วยฮิสโตแกรม (Histogram)

โครงข่ายประสาทเทียมในชั้นผลลัพธ์ (Output Layer) มีการวิเคราะห์การกระจายตัวของ “bias” และ “weight” ในชั้นผลลัพธ์ ตามรูปที่ 4 พบว่า ค่า “bias” แสดงการกระจายตัว หมายถึง การปรับตัวของชั้นผลลัพธ์ที่เฉพาะเจาะจง ส่วน “weight” มีการกระจายตัวที่สะท้อนถึงการปรับตัวที่เข้มข้นและมีความเสถียรในการทำนายผลลัพธ์ที่แม่นยำ



รูปที่ 4 การวิเคราะห์การกระจายตัวของค่า “bias” และค่า “weight” ชั้นซ่อน Output Layer

2. เมตริกซ์การประเมินประสิทธิภาพ (Performance Metrix)

ค่าความแม่นยำโดยรวมเพียงอย่างเดียวยังไม่เพียงพอที่จะสรุปประสิทธิภาพของโครงข่ายประสาทเทียม ดังนั้น Confusion Matrix สามารถให้มุมมองครอบคลุมเกี่ยวกับความสามารถในการทำนายของแบบจำลอง โดยจะแบ่งออกเป็น 4 ส่วน คือ 1) ข้อมูลที่จำแนกถูกต้องในคลาสบวก 2) ข้อมูลที่จำแนกถูกต้องในคลาสลบ 3) ข้อผิดพลาดในการจำแนกคลาสบวก และ 4) ข้อผิดพลาดในการจำแนกคลาสลบ ปรากฏผลดังนี้

ผลลัพธ์การฝึกฝนและทดสอบ	แบบจำลอง	
	ที่ดีที่สุด	เปรียบเทียบ
ข้อมูลที่จำแนกถูกต้องในคลาสบวก (True Positive: TP)	83 ครั้ง	82 ครั้ง
ข้อมูลที่จำแนกถูกต้องในคลาสลบ (True Negative: TN)	106 ครั้ง	103 ครั้ง
ข้อผิดพลาดในการจำแนกคลาสบวก (False Positive: FP)	9 ครั้ง	12 ครั้ง
ข้อผิดพลาดในการจำแนกคลาสลบ (False Negative: FN)	3 ครั้ง	4 ครั้ง

ข้อมูลข้างต้นนำมาใส่ใน Confusion Matrix ตามรูปที่ 5 จะทำให้เกิดความชัดเจนก่อนการนำไปใช้

Confusion Matrix of Test Accuracy Evaluation

		Predicted Values	
		Negative (Class 0)	Positive (Class 1)
Actual Values	Negative (Class 0)	True Negative (TN) Type I Error	False Positive (FP)
	Positive (Class 1)	False Negative (FN) Type II Error	True Positive (TP)

รูปที่ 5 Confusion Matrix จาก Best Model

จากข้อมูลผลลัพธ์การฝึกและทดสอบดังกล่าวข้างต้นสามารถนำมาคำนวณเพื่อประเมินประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมได้ตาม

จากตารางที่ 1 มีเมตริกซ์สำหรับการประเมินประสิทธิภาพ 4 ด้าน คือ 1. ความแม่นยำและเที่ยงตรง 2. ความสมดุล 3. ความน่าเชื่อถือ และ 4. ความน่าจะเป็น โดยการวิเคราะห์ผลเหล่านี้จะช่วยสนับสนุนค่าความแม่นยำโดยรวมของแบบจำลองว่ามีประสิทธิภาพในลำดับต่อไป

ตารางที่ 1 เมทริกซ์ประเมินประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียม

การประเมิน	เมทริกซ์	การเปรียบเทียบ		ผลแตกต่าง	สูตรการคำนวณ
		ก่อน	หลัง		
ความแม่นยำ	Accuracy	0.9402	0.9203	-0.0199	$\frac{TP + TN}{Total}$
	Precision	0.9021	0.8723	-0.0298	$\frac{TP}{TP + FP}$
	Recall (sensitivity)	0.9651	0.9534	-0.0117	$\frac{TP}{TP + FN}$
	Specificity	0.9217	0.8956	-0.0261	$\frac{TN}{TN + FP}$
ความสมดุล	F1-score	0.9325	0.9111	-0.0214	$2 \times \frac{Precision \times Recall}{Precision + Recall}$
	macro average	0.9400	0.9200	-0.0200	$\frac{F1 - Score(0) + F1 - Score(1)}{2}$
ความน่าเชื่อถือ	positive_pred_value: PPV	0.9021	0.8723	-0.0298	$\frac{TP}{TP + FP}$
	negative_pred_value: NPV	0.9724	0.9626	-0.0098	$\frac{TN}{TN + FN}$
ความน่าจะเป็น	positive_lik_ratio: LR+	12.3320	9.1375	-3.1945	$\frac{Recall}{1 - Specificity}$
	negative_lik_ratio: LR-	0.0378	0.0519	+0.0141	$\frac{1 - Recall}{Specificity}$

2.1 ความแม่นยำและความเที่ยงตรง

การทดสอบความสามารถของแบบจำลองในการทำนายข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน เป็นการประเมินประสิทธิภาพที่แสดงในค่าของความแม่นยำโดยรวม (Accuracy), ความแม่นยำในการจำแนก (Precision), อัตราการตรวจจับที่ถูกต้อง (Recall (Sensitivity)), และความจำเพาะ (Specificity) ตามตารางที่ 1 พบว่า การปรับค่าแบบจำลองทำให้ความแม่นยำโดยรวมลดลงเล็กน้อย อย่างไรก็ตาม การลดลงของค่าความจำเพาะ (Specificity) และความแม่นยำในการจำแนก (Precision) แสดงให้เห็นว่าการปรับค่าอาจส่งผลให้แบบจำลองมีการทำนายข้อผิดพลาดในการจำแนกคลาสิก (False Positive: FP) มากขึ้น ซึ่งควรพิจารณาการปรับแต่งเพิ่มเติมเพื่อลดผลกระทบ

2.2 ค่าความสมดุล

การวิเคราะห์ค่าความสมดุลที่ได้จากตารางที่ 1 พบว่า มีการลดลงของค่า F1-score และ Macro Average สะท้อนถึงการลดลงของความสมดุลระหว่าง ความแม่นยำในการจำแนก (Precision) และอัตราการตรวจจับที่ถูกต้อง (Recall) หลังจากการปรับเทียบ (Calibration) แสดงให้

เห็นว่าการปรับปรุงอาจทำให้ความสามารถในการจำแนกข้อมูลที่แม่นยำลดลง การปรับปรุงแบบจำลองอาจต้องการการปรับแต่งเพิ่มเติมเพื่อรักษาความสมดุลของการทำนายระหว่างคลาส

2.3 ค่าความน่าเชื่อถือ

การวิเคราะห์ค่าความน่าเชื่อถือที่ได้จาก ตารางที่ 1 พบว่า การลดลงของ Positive Pred Value: PPV และ Negative Pred Value: NPV หลังจากการปรับเทียบ (Calibration) บ่งบอกถึงการลดลงของความน่าเชื่อถือของการทำนาย Positive และ Negative ตามลำดับ ซึ่งหมายความว่า การปรับค่าอาจทำให้แบบจำลองมีความแม่นยำโดยรวมน้อยลงในการแยกแยะระหว่างคลาสที่แท้จริงและคลาสที่ถูกทำนาย การปรับปรุงแบบจำลองควรพิจารณาวิธีการเพื่อเพิ่มความน่าเชื่อถือของการทำนายให้สูงขึ้น

2.4 อัตราส่วนความน่าจะเป็น

การวิเคราะห์ค่าความน่าเชื่อถือที่ได้จากตารางที่ 1 พบว่า ค่า Positive Likelihood Ratio (LR+) ที่ลดลงและค่า Negative Likelihood Ratio (LR-) ที่เพิ่มขึ้นหลังจากการปรับเทียบ (Calibration) สะท้อนถึงการเปลี่ยนแปลงของความน่าจะเป็นในการทำนายการเกิดขึ้นของคลาส Positive เมื่อเทียบกับคลาส Negative. ค่า LR+ ที่ลดลงแสดงว่าความน่าจะเป็นของการทำนายเป็น Positive เมื่อเป็นจริง คือ Positive นั้นลดลง ความเปลี่ยนแปลงเหล่านี้บ่งบอกถึงการปรับแต่งที่อาจส่งผลกระทบต่อความสามารถในการทำนายของแบบจำลอง

3. การประเมินความสามารถแบบจำลอง


การประเมินความสามารถของแบบจำลองนั้นใช้ความสามารถในการเรียนรู้ (Learning Curve), พื้นที่ใต้โค้ง (AUC), ค่า Log Loss, ค่า Brier Score และการเปรียบเทียบประสิทธิภาพการจำแนกประเภทก่อนและหลังการปรับเทียบ

3.1 การประเมินความสามารถในการเรียนรู้ของแบบจำลอง (Learning Curve)


การวิเคราะห์ด้วยกราฟเส้นการเรียนรู้ก่อนและหลังการปรับเทียบมีความแตกต่างกันเล็กน้อย โดยสมรรถนะของแบบจำลองในชุดการฝึกฝนลดลงเล็กน้อยและเริ่มเข้าใกล้สมรรถนะในชุดการตรวจสอบมากขึ้น อันเป็นสัญญาณที่ดีที่แสดงว่าการปรับเทียบได้ช่วยลดปัญหาการฝึกฝนแบบจำลองมากเกินไปและทำให้แบบจำลองมีความทนทานและเชื่อถือได้มากขึ้นตามรูปที่ 6

3.2 การประเมินประสิทธิภาพแบบจำลองด้วย ROC Curve และ AUC

Area Under the Curve: AUC วัดพื้นที่ใต้เส้นโค้งลักษณะการทำงานของตัวรับ (ROC) ใช้วัดภาพรวมของประสิทธิภาพของแบบจำลองในเกณฑ์การจำแนกประเภททั้งหมด โดยที่ AUC เข้าใกล้ 1 หมายถึง แบบจำลองที่เกือบสมบูรณ์แบบ ผลการวิจัยพบพื้นที่ใต้โค้งตามรูปที่ 7



รูปที่ 6 กราฟเส้นการเรียนรู้ของแบบจำลองหลังปรับเทียบแบบจำลอง



รูปที่ 7 ประสิทธิภาพของ AUC หลังการปรับเทียบแบบจำลอง

จากรูปที่ 7 พบว่า หลังจากการปรับเทียบ (Calibration) ประสิทธิภาพของแบบจำลอง ยังคงแสดงประสิทธิภาพที่สูงมากอยู่ ถึงแม้จะลดลงจากก่อนการปรับเทียบที่ร้อยละ 0.98 เป็นหลังการปรับเทียบที่ร้อยละ 0.97 ซึ่งไม่มีการเปลี่ยนแปลงมากนักจากก่อนการปรับเทียบ สิ่งนี้ชี้ให้เห็นว่าการปรับเทียบไม่ได้ทำให้คุณสมบัติของแบบจำลองในการจำแนกข้อมูลผิดเพี้ยนไป แต่ยังคงรักษาความแม่นยำในการจำแนกในระดับสูงไว้ได้

3.3 การประเมินความแม่นยำของแบบจำลองด้วย Log Loss

ในการประเมินประสิทธิภาพของแบบจำลองการจำแนกประเภท (Classification) ด้วยค่า Log Loss (Binary Cross-entropy) พบว่า แบบจำลองแสดงประสิทธิภาพที่สูง โดยค่า Train Log Loss, Tuning Loss, และ Test Loss (จาก Best Model) ปรากฏค่า 0.17098133, 0.21084249 และ 0.16472299 ซึ่งสะท้อนถึงประสิทธิภาพที่ยอมรับในความแม่นยำของแบบจำลองในการทำนายข้อมูลทดสอบได้ดี เพราะมีค่าต่ำหรือเข้าใกล้ 0

3.4 ความน่าเชื่อถือของความน่าจะเป็นที่แบบจำลองด้วย Brier Score

การประเมินความน่าเชื่อถือด้วยค่า Brier Score พบว่า การประเมินการปรับเทียบของแบบจำลองอยู่ที่ 0.068108 ในขณะที่ค่า Brier Score จากการทดสอบแบบจำลองอยู่ที่ 0.070437 ซึ่งมีความใกล้เคียงกันอย่างมากทำให้เกิดข้อบ่งชี้ว่าแบบจำลองมีความสม่ำเสมอและเชื่อมั่นในการทำนายผลลัพธ์เมื่อประยุกต์ใช้กับข้อมูลที่ไม่คุ้นเคยหรือไม่เคยเห็นมาก่อน ซึ่งรับรองความพร้อมของแบบจำลองสำหรับการประยุกต์ใช้ในสถานการณ์ต่าง ๆ ได้อย่างมั่นคงและน่าเชื่อถือ

4. การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance)

การวิเคราะห์ความสำคัญของตัวแปรที่โครงข่ายประสาทเทียมใช้ในการฝึกฝน โดยมีการเรียงลำดับจากความสำคัญมาไปหาความสำคัญน้อย ดังปรากฏในตารางที่ 2

ตารางที่ 2 5 ลำดับแรกของตัวแปรสำคัญที่ใช้ในการฝึกฝน

No.	Feature	Score
1	CR	0.3852
2	CA_TA	0.3054
3	DSRI	0.1958
4	GMI	0.1263
5	SGI	0.1119

จากตารางที่ 2 พบว่า Feature ที่ชื่อ Current Ratio: CR มีค่า 0.3852 มาเป็นลำดับที่ 1 แสดงถึงความสำคัญในการจัดการสินทรัพย์หมุนเวียนให้เหมาะสมต่อการทำนาย ส่วนตัวแปรในลำดับรองลงมาคือ Current Assets to Total Assets: CA_TA มีค่า 0.3054 แสดงถึงความสำคัญของสินทรัพย์หมุนเวียนที่มีสัดส่วนสูงเมื่อเทียบกับสินทรัพย์รวม

อภิปรายผลการวิจัย

การวิจัยนี้ได้พัฒนาและทดสอบแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) ซึ่งเน้นย้ำถึงความสามารถในการตรวจจับและทำนายการทุจริตทางการเงินในงบการเงินของบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย โดยมีความแม่นยำสูงส่งผลให้เห็นศักยภาพของการใช้เทคโนโลยีนี้ในการสนับสนุนกระบวนการตรวจสอบทางการเงินและการตรวจจับการทุจริตได้อย่างมีประสิทธิภาพ (Bao et al., 2017; Jiang, 2021)

การเชื่อมโยงผลลัพธ์จากการวิจัยนี้กับงานวิจัยอื่น เช่น การศึกษาของ Beneish (1999) ที่พัฒนาตัวชี้วัดการทุจริต M-Score และงานวิจัยโดย Caouette et al. (1968) เกี่ยวกับการใช้การวิเคราะห์แบบจำแนกเพื่อคาดการณ์การล้มละลาย และได้รับการสนับสนุนจากผลงานของ Anderson & McNeill (1992) เน้นย้ำถึงความสำคัญของการใช้เทคนิคการวิเคราะห์ข้อมูลและโครงข่ายประสาทเทียมเพื่อเพิ่มประสิทธิภาพในกระบวนการตรวจสอบบัญชีและการตรวจจับการทุจริต

การวิเคราะห์ผลลัพธ์และการประเมินความแม่นยำของแบบจำลอง ANN ในการวิจัยนี้ไม่เพียงแสดงถึงความเป็นไปได้ในการประยุกต์ใช้แบบจำลองในสถานการณ์จริงเท่านั้น แต่ยังเปิดโอกาสให้เห็นถึงความเป็นไปได้ในการปรับปรุงกระบวนการตรวจสอบทางการเงินเพื่อเพิ่มความโปร่งใสและความน่าเชื่อถือของข้อมูลทางการเงิน รวมถึงการใช้ข้อมูลสาธารณะในการพยากรณ์ความล้มเหลวทางการเงินการเชื่อมโยงกับงานวิจัยของ พรพนนิภา รอดวรรณะ (2564) ที่สำรวจการใช้ Forensic Analytics ในการตรวจสอบการทุจริตทางบัญชีการใช้เทคโนโลยีและเทคนิควิเคราะห์ข้อมูลสมัยใหม่ เช่น ANN สามารถเพิ่มความสามารถในการตรวจจับและทำนายการทุจริตทางการเงินได้อย่างมีประสิทธิภาพ ช่วยให้กระบวนการตรวจสอบมีความน่าเชื่อถือและช่วยเสริมสร้างความมั่นใจให้กับผู้ถือหุ้นและผู้ลงทุนในตลาดทุน (Kim & Upneja, 2014)

สรุปผลการวิจัย

ในการวิจัยนี้มุ่งเน้นไปที่การพัฒนา ทดสอบ ประเมินประสิทธิภาพ และประเมินความน่าเชื่อถือของโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เพื่อตรวจจับแนวโน้มการทุจริตทางการเงินจากข้อมูลงบการเงินของบริษัทจำกัดมหาชนที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย โครงข่ายประสาทเทียมได้รับการออกแบบเพื่อวิเคราะห์และจำแนกพฤติกรรมที่ผิดปกติซึ่งอาจบ่งบอกถึงแนวโน้มการทุจริตจากข้อมูลทางการเงินได้

ผลการทดสอบแบบจำลองโครงข่ายประสาทเทียมด้วยชุดข้อมูลทางการเงินที่มีความซับซ้อนสามารถสรุปได้ว่า แบบจำลองที่พัฒนาขึ้นมีความแม่นยำ ร้อยละ 94.02 และความน่าเชื่อถือ ร้อยละ 80.41 ซึ่งถือว่าอยู่ในระดับที่สูง อันเกิดจากการปรับเทียบ (Calibration) ทำให้เกิดความเชื่อมั่นว่า

แบบจำลองสามารถทำนายข้อมูลใหม่ที่มาพร้อมกับลักษณะที่แตกต่างออกไปได้ดียิ่งขึ้น การทดสอบโดยใช้ ROC Curve และ AUC แสดงให้เห็นว่า แบบจำลองสามารถจัดการกับการทำนายข้อมูลที่เป็นบวก (มีแนวโน้มการทุจริต) และข้อมูลที่เป็นลบ (ไม่มีแนวโน้มการทุจริต) ได้อย่างมีประสิทธิภาพ ส่วน Confusion Matrix ที่ใช้วิเคราะห์แบบจำลองให้ข้อมูลที่สำคัญเกี่ยวกับความแม่นยำโดยรวม (Accuracy) ร้อยละ 94.02 ความแม่นยำในการจำแนก (Precision) ร้อยละ 87.23 และอัตราการตรวจจับที่ถูกต้อง (Recall) ร้อยละ 95.34 ซึ่งเป็นผลลัพธ์ที่สะท้อนให้เห็นถึงศักยภาพของการทำงานของโครงข่ายประสาทเทียมในด้านการตรวจจับการทุจริตทางการเงินได้อย่างมีประสิทธิภาพ การเปลี่ยนแปลงเหล่านี้แสดงถึงการทำงานของแบบจำลองหลังการปรับเทียบที่ทำให้การทำนายเป็นไปอย่างมีความแม่นยำ เสถียรและมีอัตราความผิดพลาด (Brier Score) ที่ลดลงทำให้แบบจำลองทำนายมีความน่าเชื่อถือมากขึ้น และทำให้ทราบถึงตัวแปร (Feature) ที่สำคัญในการเรียนรู้ของโครงข่ายประสาทเทียม คือ Current Ratio: CR ซึ่งบ่งชี้ไปถึงกลุ่มรายการสินทรัพย์หมุนเวียน หนี้สินหมุนเวียน และสินทรัพย์รวมที่ต้องให้ความสนใจเป็นพิเศษในการนำไปใช้ในการตรวจสอบบัญชี

ผลลัพธ์จากการวิจัยนี้ยืนยันถึงศักยภาพและความสำคัญของการใช้เทคโนโลยีโครงข่ายประสาทเทียม (ANN) ในการต่อสู้กับปัญหาการทุจริตทางการเงิน และเปิดทางสู่การศึกษาและการพัฒนาเพื่อเพิ่มความแม่นยำและประสิทธิภาพในการตรวจจับการทุจริตทางการเงินในอุตสาหกรรมอื่น

ข้อเสนอแนะ

แม้ว่าผลการวิจัยจะแสดงถึงความสำเร็จของโครงข่ายประสาทเทียมในการตรวจจับแนวโน้มการทุจริตทางการเงิน แต่ยังมีข้อจำกัดบางประการที่ควรพิจารณา รวมถึงความต้องการข้อมูลทางการเงินที่ครบถ้วนและมีคุณภาพสูงเพื่อการฝึกฝนและทดสอบแบบจำลองที่มีประสิทธิภาพในอนาคต การวิจัยควรมุ่งเน้นไปที่การพัฒนาโครงข่ายประสาทเทียมที่สามารถจัดการกับข้อมูลที่มีความหลากหลายและไม่สมบูรณ์ได้ดียิ่งขึ้น รวมถึงการสำรวจเทคนิคการเรียนรู้เชิงลึกอื่น ๆ ที่อาจช่วยเพิ่มประสิทธิภาพในการตรวจจับการทุจริตทางการเงิน และทำงานวิจัยบูรณาการข้ามสาขาวิชา เช่น การเงิน การบัญชี หลักสถิติและวิทยาการคอมพิวเตอร์ จะเพิ่มโอกาสในการค้นพบวิธีการใหม่ที่มีประสิทธิภาพสูงในการป้องกันและตรวจจับการทุจริตทางการเงิน

เอกสารอ้างอิง

กรมบังคับคดี. (2566). *DSI แฉลงความคืบหน้ากรณีหุ้น STARK (คดีพิเศษที่ 57/2566)*.

https://www.dsi.go.th/th/Detail/e34fb66360cc0cc2186_a1951f5aab66f

- ผัลย์ศุภา หลงทอง และ นิ่มนวล วิเศษสรรพ. (2562). ความสัมพันธ์ระหว่างความเสี่ยงที่เป็นระบบและอัตราส่วนทางการเงิน กรณีบริษัทจดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย SET 100. *The Rangsit Graduate Research Conference: RGRC*, กรุงเทพมหานคร.
- พรรณนิภา รอดวรรณะ. (2564). ระบบ Forensic Analytics ขั้นพื้นฐานในการตรวจสอบการทุจริตของงบการเงิน: กรณีศึกษาบริษัทในตลาดหลักทรัพย์แห่งประเทศไทย. *วารสารสภาวิชาชีพบัญชี*, 3(8), 4-21.
- ศิลปพร ศรีจันเพชร. (2551). ทฤษฎีบรรษัทภิบาล. *วารสารบริหารธุรกิจ มหาวิทยาลัยธรรมศาสตร์*, 31(120), 1-4.
- สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์. (2555ก). ความรับผิดชอบของผู้สอบบัญชีเกี่ยวกับการพิจารณาการทุจริตในการตรวจสอบงบการเงิน (มาตรฐานการสอบบัญชี รหัส 240). https://acpro-std.tf.ac.or.th/test_std/uploads/files/TSA/2564_TSA240.pdf
- สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์. (2555ข). วัตถุประสงค์โดยรวมของผู้สอบบัญชีรับอนุญาตและการปฏิบัติงานตรวจสอบตามมาตรฐานการสอบบัญชี (มาตรฐานการสอบบัญชี รหัส 200). https://acpro-std.tf.ac.or.th/test_std/uploads/files/TSA/2564_TSA200.pdf
- สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์. (2559). การแสดงความเห็นและการรายงานต่องบการเงิน (มาตรฐานการสอบบัญชี รหัส 700 (ปรับปรุง)). [https://acpro-std.tf.ac.or.th/test_std/uploads/files/TSA/2564_TSA700\(Revised\).pdf](https://acpro-std.tf.ac.or.th/test_std/uploads/files/TSA/2564_TSA700(Revised).pdf)
- สภาวิชาชีพบัญชี ในพระบรมราชูปถัมภ์. (2563). กรอบแนวคิดสำหรับการรายงานทางการเงิน (ประกาศสภาวิชาชีพบัญชี ที่ 48/2563). https://eservice.tf.ac.or.th/get_file/index.php?file=Frame%20work_03.10.66.pdf
- ACFE. (2020). *Report to the nations: 2020 global study on occupational fraud and abuse*. <https://www.acfe.com/report-to-the-nations/2020/>
- ACFE. (2021). *Fraud triangle*. <https://www.acfe.com/fraud-triangle.aspx%C2%A0>
- Anderson, D., & McNeill, G. (1992). *Artificial neural networks technology*. https://www.academia.edu/download/33786328/Artificial_Neural_Networks_Technology.pdf
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PloS one*, 12(7), e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Beneish, M. D. (1999). The detection of earnings manipulation. *Financial Analysts Journal*, 55(5), 24-36.
- Beneish, M. D., & Vorst, P. (2020). The cost of fraud prediction errors. SSRN 3529662.

- Caouette, J. B., Altman, E. I., Narayanan, P., & Altman, Z. (1968). 1.6 Z-score estimated for non-manufacturers & emerging markets. *Altman Z-Score*, 189(1).
- Dashtbayaz, M. L., & Mohammad, S. (2015). Data search and discovery process for financial statement fraud. *Research Journal of Finance and Accounting*, 6(3), 75-80.
- Healy, P. M., & Palepu, K. G. (2003). The fall of Enron. *Journal of Economic Perspectives*, 17(2), 3-26. <https://doi.org/10.1257/089533003765888403>
- Hribar, P., Kravet, T., & Wilson, R. (2014). A new measure of accounting quality. *Review of Accounting Studies*, 19(1), 506-538. <https://doi.org/10.1007/s11142-013-9253-8>
- Japkowicz, N. (2001). Supervised versus unsupervised binary-learning by feedforward neural networks. *Machine Learning*, 42, 97-122.
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of financial economics*, 3(4), 305-360.
- Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184, 115537. <https://doi.org/10.1016/j.eswa.2021.115537>
- Kak, S. (1993). On training feedforward neural networks. *Pramana*, 40(1), 35-42. <https://doi.org/10.1007/BF02898040>
- Kim, S., & Upneja, A. (2014). Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models. *Economic Modelling*, 36, 354-362. <https://doi.org/10.1016/j.econmod.2013.10.005>
- Kusumawati, A., & Syamsuddin, S. (2018). The effect of auditor quality to professional skepticism and its relationship to audit quality. *International Journal of Law and Management*, 60(4), 998-1008. <https://doi.org/10.1108/IJLMA-03-2017-0062>
- Lechner, M. (2020). Learning representations for binary-classification without backpropagation. In *8th International Conference on Learning Representations* (pp 1-17). Virtual; Addis Ababa, Ethiopia: ICLR.
- Mubako, G., & O' Donnell, E. (2018). Effect of fraud risk assessments on auditor skepticism: Unintended consequences on evidence evaluation. *International Journal of Auditing*, 22(1), 55-64. <https://doi.org/10.1111/ijau.12104>

- Nawaiseh, A. K., Abbod, M. F., & Itagaki, T. (2020). Financial statement audit using support vector machines, artificial neural networks and K-nearest neighbor: An empirical study of UK and Ireland. *International Journal of Simulation Systems, Science & Technology*, 21(2), 1-6. <https://doi.org/10.5013/IJSSST.a.21.02.07>
- Omar, N., Johari, Z. A., & Smith, M. (2017). Predicting fraudulent financial reporting using artificial neural network. *Journal of Financial Crime*, 24(2), 362-387. <https://doi.org/10.1108/JFC-11-2015-0061>
- Pricewaterhousecoopers. (2020). *Staying on top of a never-ending war*. <https://www.pwc.com/th/en/consulting/forensic/economic-crime-and-fraud-in-thailand.html>
- Rahim, S., Muslim, M., & Amin, A. (2019). Red flag and auditor experience toward criminal detection through professional skepticism. *Jurnal Akuntans*, 23(1), 47-62. <https://doi.org/10.24912/ja.v23i1.459>
- Suryandari, N., & Yuesti, A. (2017). Professional scepticism and auditors ability to detect fraud based on workload and characteristics of auditors. *Scientific Research Journal (SCIRJ)*, 5(9), 109-115.
- Topor, D. I. (2017). The auditor's responsibility for finding errors and fraud from financial situations: Case study. *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 7(1), 342-352. <https://doi.org/10.6007/IJARAFMS/v7-i1/2862>
- Turner, J. L., Mock, T. J., & Srivastava, R. P. (2003). *An analysis of the fraud triangle*. https://www.researchgate.net/publication/237777981_An_Analysis_of_the_Fraud_Triangle
- Yazid, H., & Suryanto, T. (2017). IFRS, professional auditor skepticism, conflict agency to prevention of fraud and investor confidence level. *International Journal of Economic Perspectives*, 11(1), 250-259.