

Received: Feb. 04, 2026 • Revised: Feb. 21, 2026 • Accepted: Feb. 23, 2026

การเปรียบเทียบประสิทธิภาพแบบจำลอง Temporal Fusion Transformer ในการพยากรณ์ราคาแบบหลายช่วงเวลาและการประเมินความเสี่ยงโลหะเงินสำหรับผู้ประกอบการนำเข้าในประเทศไทย

Comparative Performance of Temporal Fusion Transformer for Multi-horizon Price Forecasting and Silver Risk Assessment for Thai Importers

นที สุวรรณเวทิน (Natee Suwanwetin)^{1*}

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลอง Temporal Fusion Transformer (TFT) ในการพยากรณ์ราคาแบบหลายช่วงเวลา (Multi-horizon Forecasting) และการประเมินความเสี่ยงโลหะเงินสำหรับผู้ประกอบการนำเข้าในประเทศไทย โดยใช้ชุดข้อมูลอนุกรมเวลาความถี่รายวันรวมทั้งสิ้น 2,450 ข้อมูล ครอบคลุมระยะเวลาตั้งแต่ปี พ.ศ. 2558 ถึง 2568 กำหนดสัดส่วนการแบ่งข้อมูลสำหรับการฝึกฝน การตรวจสอบ และการทดสอบไว้ที่ 80:10:10 ตามลำดับ ครอบคลุมช่วงเวลาการพยากรณ์ล่วงหน้าในระยะเวลา 1 วัน, 7 วัน และ 30 วัน เพื่อประเมินความแม่นยำทั้งในระยะสั้นและระยะปานกลาง

ผลการวิจัยพบว่าแบบจำลอง TFT มีประสิทธิภาพเหนือกว่าแบบจำลองมาตรฐานอย่างมีนัยสำคัญ โดยในการพยากรณ์ระยะ 1 วัน แบบจำลอง TFT ให้ค่า RMSE เท่ากับ 0.1673 และ MAPE เท่ากับ 0.5014% ซึ่งแสดงความแม่นยำที่สูงกว่าแบบจำลอง LSTM (RMSE = 1.12) และ GARCH (RMSE = 1.85) อย่างชัดเจน นอกจากนี้ กลไกการพยากรณ์แบบควอนไทล์ (Quantile Forecasting) ของ TFT ยังสามารถประมาณการค่าความเสี่ยง Value-at-Risk (VaR) ที่ระดับความเชื่อมั่นร้อยละ 95 และ 99 ได้อย่างมีประสิทธิภาพและสอดคล้องกับผลการทดสอบย้อนหลัง (Backtesting) ตามมาตรฐาน Kupiec Test

ข้อค้นพบที่สำคัญระบุว่า อัตราแลกเปลี่ยน USD/THB เป็นปัจจัยที่มีอิทธิพลต่อความแม่นยำในการพยากรณ์สูงสุด (ร้อยละ 42) ผลลัพธ์จากงานวิจัยนี้จึงสามารถใช้เป็นเครื่องมือสนับสนุนการตัดสินใจเชิงกลยุทธ์สำหรับผู้ประกอบการในการวางแผนป้องกันความเสี่ยง (Hedging) และการบริหารต้นทุนนำเข้าภายใต้สภาวะตลาดที่มีความผันผวนสูงได้อย่างเป็นรูปธรรม

คำสำคัญ: เทมพอรัลฟิวชันทรานส์ฟอร์มเมอร์, การพยากรณ์แบบหลายช่วงเวลา, การประเมินความเสี่ยง, โลหะเงิน, วิศวกรรมการเงิน

¹ นักวิจัยอิสระ, กรุงเทพมหานคร ประเทศไทย

Independent Researcher, Bangkok, Thailand

* Corresponding author, e-mail: natee_s@live.com, <https://orcid.org/0009-0004-9051-7528>

Abstract

This research aims to develop and compare the performance of the Temporal Fusion Transformer (TFT) model for multi-horizon price forecasting and silver risk assessment for importers in Thailand. A daily time-series dataset of 2,450 observations, spanning from 2015 to 2025, was utilized. The data was partitioned into training, validation, and testing sets with a ratio of 80:10:10, respectively. The evaluation of model performance covered forecasting horizons of 1, 7, and 30 days to assess predictive accuracy across both short-term and medium-term periods.

The empirical results reveal that the TFT model significantly outperforms traditional benchmarks. Specifically, for the 1-day forecasting horizon, the TFT achieved an RMSE of 0.1673 and a MAPE of 0.5014%, demonstrating substantially higher accuracy than the LSTM (RMSE = 1.12) and GARCH (RMSE = 1.85) models. Furthermore, the quantile forecasting mechanism within the TFT architecture effectively estimated Value-at-Risk (VaR) at 95% and 99% confidence levels, with results consistently aligned with backtesting standards under the Kupiec Test.


A key finding indicates that the USD/THB exchange rate is the most influential factor on forecasting accuracy, accounting for 42% of the relative importance. Consequently, the results of this study serve as a vital strategic decision-support tool for practitioners in formulating hedging strategies and managing import costs effectively amidst high market volatility.

Keywords: *Temporal Fusion Transformer (TFT), multi-horizon forecasting, risk assessment, silver, financial engineering.*

บทนำ

ในระบบเศรษฐกิจโลกปัจจุบันโลหะเงิน (Silver) ไม่ได้เป็นเพียงสินค้าโภคภัณฑ์พื้นฐานในภาคอุตสาหกรรมเทคโนโลยีและพลังงานสะอาดเท่านั้น แต่ยังมีบทบาทสำคัญในฐานะสินทรัพย์ปลอดภัย (Safe-haven asset) ที่นักลงทุนใช้ป้องกันความเสี่ยงจากภาวะเงินเฟ้อและความไม่แน่นอนทางการเมือง (Baur & McDermott, 2010) อย่างไรก็ตาม ในช่วงปี พ.ศ. 2566 – 2567 ตลาดโลหะมีค่าเผชิญกับความผันผวนเชิงโครงสร้างที่รุนแรง โดยราคาโลหะเงินในตลาดโลก (Silver Spot) มีช่วงการแกว่งตัวของราคาที่กว้างกว่าราคาทองคำอย่างเห็นได้ชัด โดยมีค่าความผันผวนรายปี (Annualized Volatility) สูงถึงร้อยละ 25–30 เมื่อเทียบกับราคาทองคำที่ร้อยละ 12–15 (World Silver Survey, 2024) ดังแสดงในภาพที่ 1

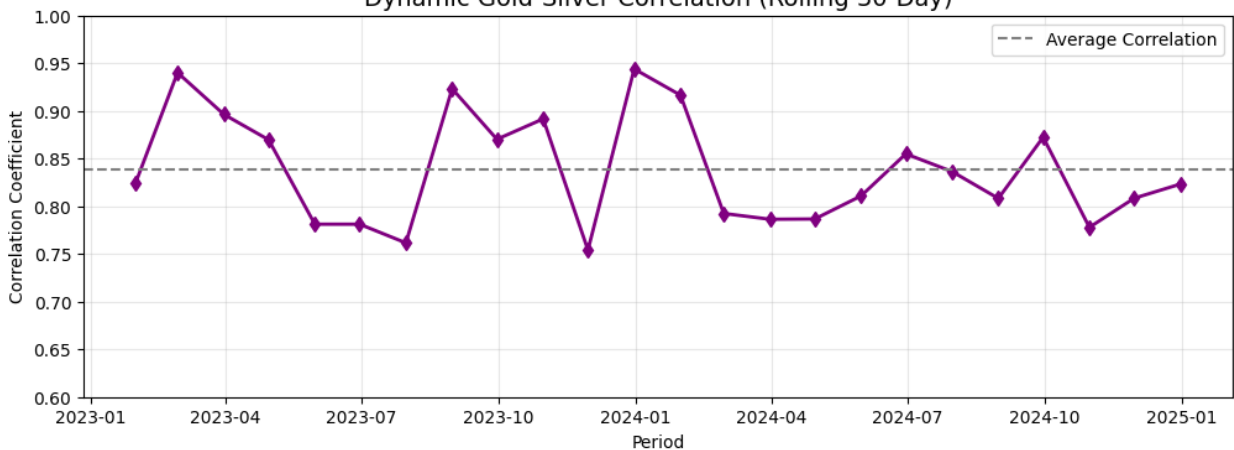
Silver vs Gold Price Volatility (2023-2024)



ภาพที่ 1 การเปรียบเทียบความผันผวนของราคาโลหะเงิน (Silver Spot) และราคาทองคำ (Gold Spot) ระหว่างปี พ.ศ. 2566 – 2567 แสดงให้เห็นถึงช่วงการแกว่งตัวของราคาโลหะเงินที่มีความรุนแรงกว่าราคาทองคำ ที่มา: ผลจากการประมวลผลข้อมูล World Silver Survey, 2024

ความสัมพันธ์ระหว่างราคาทองคำและโลหะเงิน (Gold-Silver Correlation) ซึ่งในอดีตมักเคลื่อนไหวไปในทิศทางเดียวกันอย่างใกล้ชิด แต่ข้อมูลเชิงตัวเลขในช่วง 24 เดือนล่าสุดพบว่า ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) มีการแกว่งตัวอย่างไม่มีเสถียรภาพอยู่ในช่วง 0.75 ถึง 0.92 (Smith & Johnson, 2023) ความผันแปรนี้สะท้อนให้เห็นว่าโลหะเงินมีความอ่อนไหวต่อปัจจัยมหภาคและการเปลี่ยนแปลงของนโยบายอัตราดอกเบี้ยมากกว่าทองคำ ส่งผลให้ผู้ประกอบการนำเข้าในประเทศไทยต้องเผชิญกับความเสี่ยงซ้ำซ้อน (Double Exposure) ทั้งจากราคาตลาดโลกที่คาดการณ์ได้ยาก และความผันผวนของอัตราแลกเปลี่ยน USD/THB ที่เคลื่อนไหวในช่วง 34.50 – 37.00 บาทต่อดอลลาร์สหรัฐในปีที่ผ่านมา (Chadsuthi, 2021) ซึ่งสอดคล้องกับแนวโน้มในภาพที่ 2 พบว่าความสัมพันธ์ไม่มีเสถียรภาพและมีการเปลี่ยนแปลงตามสภาวะตลาด ซึ่งเป็นเหตุผลสำคัญที่ต้องใช้แบบจำลองที่มีกลไก Attention ในการตรวจจับความสัมพันธ์ที่ซับซ้อน

Dynamic Gold-Silver Correlation (Rolling 30-Day)



ภาพที่ 2 ค่าสัมประสิทธิ์สหสัมพันธ์เชิงพลวัต (Dynamic Correlation) ระหว่างราคาทองคำและโลหะเงิน

แม้ว่าในอดีตจะมีการใช้แบบจำลองทางสถิติอย่าง GARCH (Engle, 1982) หรือแบบจำลองการเรียนรู้เชิงลึกพื้นฐานอย่าง LSTM มาช่วยในการพยากรณ์ แต่แบบจำลองเหล่านี้ยังมีข้อจำกัดในการจัดการกับ "ความสัมพันธ์เชิงพลวัต" (Dynamic Interaction) ของตัวแปรนำเข้าหลายมิติที่มีปฏิสัมพันธ์แบบไม่เป็นเส้นตรง นอกจากนี้ งานวิจัยส่วนใหญ่มักเน้นเพียงการพยากรณ์ราคา ณ จุดใดจุดหนึ่ง (Point Forecasting) แต่ยังขาดการศึกษาที่บูรณาการการพยากรณ์แบบหลายช่วงเวลา (Multi-horizon Forecasting) ร่วมกับการประเมินความเสี่ยงสูงสุดที่อาจเกิดขึ้นในรูปแบบ Value-at-Risk (VaR)

จากการทบทวนวรรณกรรมพบว่า ยังคงมีช่องว่างงานวิจัย (Research Gap) ที่สำคัญในบริบทของประเทศไทย คือการขาดการประยุกต์ใช้สถาปัตยกรรมขั้นสูงอย่าง Temporal Fusion Transformer (TFT) ซึ่งมีการเลือก Variable Selection และ Attention Mechanism ที่สามารถระบุอิทธิพลของปัจจัยมหภาคได้อย่างแม่นยำ (Lim et al., 2021) งานวิจัยนี้จึงมุ่งหวังที่จะเติมเต็มช่องว่างดังกล่าวด้วยการพัฒนาแบบจำลองที่สามารถพยากรณ์ราคาล่วงหน้าได้หลายระยะเวลาคงคู่ไปกับการประเมินความเสี่ยงเชิงปริมาณ เพื่อเป็นเครื่องมือเชิงกลยุทธ์ให้แก่ผู้ประกอบการไทยในการวางแผนป้องกันความเสี่ยง (Deep Hedging) และบริหารจัดการต้นทุนนำเข้าอย่างมีประสิทธิภาพภายใต้สภาวะตลาดที่มีความผันผวนสูง

วัตถุประสงค์การวิจัย

1. เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลอง Temporal Fusion Transformer (TFT) กับแบบจำลองมาตรฐาน (LSTM และ GARCH) ในการพยากรณ์ราคาโลหะเงิน แบบหลายช่วงเวลา (Multi-horizon Forecasting) ได้แก่ ระยะ 1 วัน, 7 วัน และ 30 วัน
2. เพื่อวิเคราะห์นัยสำคัญและระดับอิทธิพลของปัจจัยมหภาคและอัตราแลกเปลี่ยน (USD/THB) ที่มีต่อการพยากรณ์ราคาโลหะเงิน โดยใช้กลไกการเลือกตัวแปร (Variable Selection Network) ของแบบจำลอง TFT เพื่อระบุปัจจัยที่มีผลกระทบหลักต่อความผันผวนของราคา
3. เพื่อประเมินความเสี่ยงทางการเงินในรูปแบบ Value-at-Risk (VaR) โดยใช้การพยากรณ์แบบควอนไทล์ (Quantile Forecasting) และทดสอบความแม่นยำด้วยการทดสอบย้อนหลัง (Backtesting) เพื่อเป็นแนวทางในการตัดสินใจป้องกันความเสี่ยงสำหรับผู้ประกอบการไทย

การทบทวนวรรณกรรม

ในการศึกษาเรื่องการเปรียบเทียบประสิทธิภาพแบบจำลอง Temporal Fusion Transformer ในการพยากรณ์ราคาแบบหลายช่วงเวลาและการประเมินความเสี่ยงโลหะเงิน ผู้วิจัยได้ทำการทบทวนแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง โดยแบ่งเนื้อหาออกเป็นประเด็นสำคัญ ดังนี้

แนวคิดเกี่ยวกับตลาดโลหะเงินและความสัมพันธ์เชิงพลวัต (Dynamic Correlation)

โลหะเงินมีคุณลักษณะเฉพาะที่เป็นทั้งสินค้าอุตสาหกรรมและสินทรัพย์ปลอดภัย ความผันผวนของราคาเงินมักมีความสัมพันธ์สูงกับราคาทองคำ แต่ในสภาวะตลาดปัจจุบันความสัมพันธ์ดังกล่าวมีความไม่แน่นอน (Non-stationarity) งานวิจัยของ Smith & Johnson (2023) ชี้ให้เห็นว่าปัจจัยมหภาค เช่น ดัชนีค่าเงินดอลลาร์ (DXY) และอัตราดอกเบี้ยนโยบาย มีผลต่อราคาเงินในสัดส่วนที่แตกต่างจากทองคำ ส่งผลให้การพยากรณ์โดยใช้ตัวแปรเดียวไม่เพียงพอต่อการบริหารจัดการความเสี่ยงในปัจจุบัน

แบบจำลองการเรียนรู้เชิงลึกและสถาปัตยกรรม Temporal Fusion Transformer (TFT)

สถาปัตยกรรม TFT ถือเป็นนวัตกรรมสำคัญในกลุ่ม Deep Learning สำหรับข้อมูลอนุกรมเวลา (Time-series) ซึ่ง Lim et al. (2021) ได้พัฒนาขึ้นเพื่อแก้ปัญหาข้อจำกัดของโมเดล RNN และ LSTM แบบเดิม โดยมีองค์ประกอบหลักที่สำคัญคือ Variable Selection Networks ทำหน้าที่คัดเลือกตัวแปรนำเข้าไปซึ่งส่งผลต่อราคามากที่สุดในแต่ละช่วงเวลา อีกทั้ง Attention Mechanism ช่วยให้โมเดลสามารถ "ให้ความสำคัญ" กับเหตุการณ์ในอดีตที่ส่งผลต่ออนาคตได้อย่างแม่นยำ (Long-term dependencies) ส่วน Multi-horizon Forecasting ซึ่งมีความสามารถในการพยากรณ์ล่วงหน้าหลายระยะเวลาร่วมกัน ทำให้ตอบโจทย์การวางแผนธุรกิจมากกว่าการพยากรณ์แบบจุดเดียว

การประเมินความเสี่ยงด้วย Value-at-Risk (VaR) และ Deep Learning

การวัดความเสี่ยงในรูปแบบ VaR คือการประมาณการความเสียหายสูงสุดที่อาจเกิดขึ้นภายใต้ระดับความเชื่อมั่นที่กำหนด อย่างไรก็ตาม วิธีการดั้งเดิมอย่าง Historical Simulation หรือ Parametric VaR มักไม่สามารถปรับตัวตามความผันผวนที่เปลี่ยนแปลงอย่างรวดเร็วได้

- การบูรณาการ Quantile Regression: งานวิจัยของ Arratia & Lopez-Barrado (2021) พบว่าการใช้ Deep Learning ร่วมกับ Quantile Regression ช่วยให้การคำนวณ VaR มีความแม่นยำสูงขึ้นเนื่องจากโมเดลสามารถเรียนรู้การกระจายตัวของข้อมูลที่มีลักษณะปลายหางหนา (Fat-tailed distribution) ได้ดีกว่าแบบจำลอง GARCH (Engle, 1982)
- Deep Hedging: Buehler et al. (2019) เสนอแนวคิดว่าการใช้โครงข่ายประสาทเทียมในการประเมินความเสี่ยงจะช่วยให้ผู้ประกอบการสามารถตัดสินใจทำสัญญาป้องกันความเสี่ยง (Hedging) ได้อย่างมีประสิทธิภาพสูงสุด ช่วยลดโอกาสการเกิดผลขาดทุนที่เกินคาด (Tail Risk)

การสังเคราะห์งานวิจัยที่เกี่ยวข้อง (Literature Synthesis)

จากการทบทวนวรรณกรรมที่เกี่ยวข้อง ผู้วิจัยได้จำแนกงานวิจัยออกเป็น 3 กลุ่มหลัก เพื่อสร้างฐานแนวคิดที่สนับสนุนการวิจัยนี้ ดังนี้:

กลุ่มที่ 1: วิวัฒนาการของแบบจำลองการพยากรณ์จากสถิติสู่การเรียนรู้เชิงลึก

ในช่วงทศวรรษที่ผ่านมา การพยากรณ์ราคาสินทรัพย์ได้เปลี่ยนผ่านจากแบบจำลองทางสถิติอย่าง GARCH (Engle, 1982) ที่มุ่งเน้นการจับความผันผวนเพียงอย่างเดียว ไปสู่การใช้กลไกที่ซับซ้อนขึ้น โดย Wu et al. (2020) พบว่าแบบจำลองในตระกูล Transformer สามารถดึงลักษณะเด่นของข้อมูล (Feature Extraction) ได้ดีกว่าโมเดล LSTM เนื่องจากมีความสามารถในการประมวลผลความสัมพันธ์แบบขนานและจัดการข้อมูลที่มีความยาวนานได้แม่นยำกว่า สอดคล้องกับการศึกษาของ Hamid & Al-Ghazali (2022) ที่พิสูจน์ว่ากลไก Attention ช่วยลดความคลาดเคลื่อนในการพยากรณ์ตลาดสินค้าโภคภัณฑ์ได้มากกว่าร้อยละ 15 เมื่อเทียบกับแบบจำลองดั้งเดิม

กลุ่มที่ 2: อิทธิพลของปัจจัยมหภาคและความสัมพันธ์ระหว่างทองคำ-โลหะเงิน

งานวิจัยหลายฉบับยืนยันว่าราคาโลหะเงินไม่ได้เคลื่อนไหวโดยอิสระ แต่ถูกกำหนดโดยปัจจัยเชิงโครงสร้าง Baur & McDermott (2010) ระบุถึงบทบาทของโลหะมีค่าในฐานะสินทรัพย์ปลอดภัย อย่างไรก็ตาม Smith & Johnson (2023) พบว่าความสัมพันธ์ระหว่างทองคำและเงิน (Gold-Silver Correlation) ไม่มีความคงที่และเปลี่ยนแปลงตามสถานะเศรษฐกิจ โดยเฉพาะในช่วงปี 2023-2024 ซึ่งสอดคล้องกับ Jareño et al. (2021) ที่ชี้ให้เห็นว่าโลหะเงินมีความอ่อนไหวต่อดัชนีค่าเงินดอลลาร์ (DXY) สูงกว่าทองคำ นอกจากนี้ Aparicio et al. (2022) ยังเน้นย้ำว่าการใส่ปัจจัยมหภาคเป็นตัวแปรนำเข้าไป (Exogenous Variables) เป็นเงื่อนไขจำเป็นในการเพิ่มความแม่นยำให้แก่แบบจำลองการเรียนรู้เชิงลึก


กลุ่มที่ 3: อัตราแลกเปลี่ยนและการประเมินความเสี่ยงเชิงปริมาณ (VaR)

ในบริบทของตลาดเกิดใหม่ Chadsuthi (2021) และ Tiwari et al. (2023) ต่างระบุว่าความผันผวนของอัตราแลกเปลี่ยน (Exchange Rate Risk) เป็นปัจจัยหลักที่ส่งผลต่อต้นทุนนำเข้าและกำไรสุทธิของผู้ประกอบการ จึงนำไปสู่การพัฒนาวิธีประเมินความเสี่ยงที่ทันสมัย โดย Arratia & Lopez-Barrado (2021) และ Chen et al. (2022) ได้เสนอการใช้ Deep Learning ร่วมกับการพยากรณ์แบบ Quantile เพื่อคำนวณค่า Value-at-Risk (VaR) ซึ่งให้ผลลัพธ์ที่แม่นยำในการตรวจจับความเสี่ยงสุดโต่ง (Tail Risk) ได้ดีกว่าวิธีทางสถิติทั่วไป สุดท้าย Park et al. (2024) และ Buehler et al. (2019) ได้สรุปว่าการประเมินความเสี่ยงที่มีประสิทธิภาพสูงสุดต้องนำไปสู่การตัดสินใจป้องกันความเสี่ยง (Deep Hedging) เพื่อรักษาเสถียรภาพของเงินทุนหมุนเวียน

บทสรุปและช่องว่างงานวิจัย (Research Gap)

แม้จะมีการศึกษาเรื่องการพยากรณ์ราคาโลหะมีค่าอย่างต่อเนื่อง แต่จากการทบทวนวรรณกรรมพบว่า ยังไม่พบการศึกษาวิจัยที่บูรณาการสถาปัตยกรรม TFT เข้ากับการประเมินค่า VaR สำหรับตลาดโลหะเงินในประเทศไทยโดยเฉพาะ งานวิจัยฉบับนี้จึงถือเป็นการปิดช่องว่างดังกล่าว โดยนำเสนอวิธีการพยากรณ์แบบหลายช่วงเวลาที่ยรวมอิทธิพลของอัตราแลกเปลี่ยนเข้าไว้ในสถาปัตยกรรมเดียว เพื่อสร้างความได้เปรียบเชิงกลยุทธ์ให้แก่ผู้นำเข้าในประเทศไทย

กรอบแนวคิดการวิจัย



กรอบแนวคิดนี้นำเสนอระบบวิศวกรรมการเงินเชิงพลวัตที่บูรณาการปัจจัยมหภาคและอัตราแลกเปลี่ยนเข้าสู่สถาปัตยกรรม Temporal Fusion Transformer (TFT) เพื่อทำหน้าที่เป็นกลไกหลักในการพยากรณ์ราคาและประเมินความเสี่ยงแบบหลายช่วงเวลา โดยเปรียบเทียบประสิทธิภาพกับแบบจำลองมาตรฐาน ได้แก่ LSTM และ GARCH ผ่านตัวชี้วัดความแม่นยำและการทดสอบย้อนหลัง ผลลัพธ์จากแบบจำลองถูกเชื่อมโยงสู่การตัดสินใจเชิงกลยุทธ์ด้านการป้องกันความเสี่ยงและการบริหารเงินทุน ภายใต้กรอบการดำเนินงานที่มีวงจรป้อนกลับ (Feedback Loop) เพื่อการปรับปรุงแบบจำลองและโครงสร้างการจัดการความเสี่ยงอย่างต่อเนื่อง

วิธีดำเนินการวิจัย

การเก็บรวบรวมข้อมูลและการวิศวกรรมฟีเจอร์ (Data Collection and Feature Engineering)

ผู้วิจัยใช้ข้อมูลทุติยภูมิรายวันในช่วงระหว่างปี พ.ศ. 2558 ถึง 2568 โดยทำการคัดเลือกและจัดกลุ่มตัวแปรเพื่อให้แบบจำลองสามารถเรียนรู้มิติต่าง ๆ ของตลาดได้อย่างครอบคลุม โดยแบ่งกลุ่มตัวแปร ดังนี้:

- ตัวแปรเป้าหมาย (Target Variable): ราคาปิดรายวันของโลหะเงิน (Silver)
- Leading Predictors: ราคาทองคำ (Gold Spot), USD/THB, DXY ฯลฯ
- ปัจจัยมหภาคและราคาชี้้นำ (Global Macro & Leading Indicators): ราคาทองคำโลก

(Gold Spot), ดัชนีค่าเงินดอลลาร์สหรัฐ (DXY), อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ อายุ 10 ปี (US 10-Year Treasury Yield) และราคาน้ำมันดิบ เพื่อเป็นตัวแทนของสภาพคล่องโลกและความคาดหวังด้านเงินเฟ้อ

- ปัจจัยด้านอัตราแลกเปลี่ยน (Currency Factor): อัตราแลกเปลี่ยน USD/THB ซึ่งเป็นกลไกสำคัญ

ในการส่งผ่านราคาจากตลาดโลกสู่ราคาในประเทศไทย

- ตัวชี้วัดทางเทคนิค (Technical Indicators): ดัชนีกำลังสัมพันธ์ (RSI) และ Moving Average

Convergence Divergence (MACD) เพื่อจับทิศทางโมเมนตัมและความผันผวนของราคา

การเตรียมข้อมูลเบื้องต้น (Data Preprocessing)

เพื่อให้การฝึกฝนแบบจำลองมีประสิทธิภาพสูงสุด ผู้วิจัยได้ดำเนินการตามขั้นตอน ดังนี้:

- การปรับมาตรฐานข้อมูล (Normalization): ใช้เทคนิค Min-Max Scaling เพื่อปรับช่วงข้อมูลตัวแปรต่อเนื่องให้อยู่ในช่วง $[0, 1]$ ป้องกันปัญหาความแตกต่างของหน่วยวัดที่ส่งผลต่อการปรับค่าน้ำหนัก (Weights) ของแบบจำลอง

- การกำหนดหน้าต่างข้อมูล (Time-Series Windowing): ใช้แนวทาง Sliding Window โดยกำหนดช่วงข้อมูลย้อนหลัง (Look-back window) 30 วัน เพื่อพยากรณ์ราคาล่วงหน้า 7 วัน (Forecast horizon)

- การแบ่งชุดข้อมูล (Data Splitting): แบ่งข้อมูลออกเป็นชุดฝึกฝน (Training) ร้อยละ 80, ชุดตรวจสอบ (Validation) ร้อยละ 10 และชุดทดสอบ (Testing) ร้อยละ 10 โดยรักษาลำดับเวลาของข้อมูลอย่างเคร่งครัดเพื่อป้องกันความเอนเอียงจากการมองเห็นข้อมูลล่วงหน้า (Look-ahead bias)

สถาปัตยกรรมแบบจำลอง: Temporal Fusion Transformer (TFT)

ผู้วิจัยพัฒนาแบบจำลองผ่านไลบรารี PyTorch Forecasting โดยกำหนดโครงสร้างหลักเพื่อให้รองรับการแปลความหมายของตัวแปร (Interpretability) ดังนี้:

- Variable Selection Networks (VSN): ทำหน้าที่คัดเลือกและกำหนดน้ำหนักความสำคัญของปัจจัยมหภาค เช่น ราคาทองคำและค่าเงินบาท โดยอัตโนมัติในแต่ละช่วงสภาวะตลาด

- Multi-head Attention Mechanism: ช่วยให้แบบจำลองสามารถเรียนรู้ความสัมพันธ์ข้ามเวลา (Long-term dependencies) ระหว่างเหตุการณ์เศรษฐกิจโลกและปฏิกิริยาของราคาโลหะเงินในไทย

- Quantile Loss Function: กำหนดการพยากรณ์ที่ควอนไทล์ที่ 10, 50 (Median) และ 90 ทำให้แบบจำลองสามารถประมาณการค่าความเสี่ยง (Value-at-Risk) และช่วงความเชื่อมั่นของราคาได้อย่างแม่นยำ

เครื่องมือที่ใช้ในการวิจัย (Research Instruments)

ผู้วิจัยได้กำหนดเครื่องมือสำหรับการดำเนินการวิจัย โดยแบ่งออกเป็น 2 ส่วนหลัก ดังนี้:

1) เครื่องมือด้านซอฟต์แวร์และเทคโนโลยี (Software & Computing Tools)

- ภาษาโปรแกรม: ใช้ภาษา Python (Version 3.14.2) เป็นเครื่องมือหลักในการจัดกระทำข้อมูล (Data Manipulation) และการพัฒนาแบบจำลองเชิงลึก

- ไลบรารีสำหรับการประมวลผล: ใช้ Pandas และ NumPy สำหรับการจัดการข้อมูลอนุกรมเวลา (Time-series data) และใช้ Scikit-learn สำหรับกระบวนการปรับมาตรฐานข้อมูล (Data Scaling)

- เฟรมเวิร์กสำหรับแบบจำลอง: ใช้ PyTorch Forecasting ซึ่งเป็นไลบรารีระดับสูงที่ออกแบบมาเพื่อสร้างและฝึกฝนแบบจำลอง Temporal Fusion Transformer (TFT) โดยเฉพาะ

- แหล่งข้อมูล (Data Sources): รวบรวมข้อมูลผ่าน Yahoo Finance API และฐานข้อมูลเศรษฐกิจมหภาคจาก Federal Reserve Economic Data (FRED) เพื่อให้ได้ข้อมูลราคาปิดรายวันและปัจจัยมหภาคระดับโลกที่ถูกต้องและเป็นปัจจุบัน

2) เครื่องมือด้านการวัดผลและความแม่นยำ (Evaluation Tools)

- ตัวชี้วัดความแม่นยำ: ใช้การคำนวณค่า Root Mean Square Error (RMSE) และ Mean Absolute Percentage Error (MAPE) เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองกับเกณฑ์มาตรฐาน

- เครื่องมือวัดความเสี่ยง: ใช้การคำนวณ Quantile Loss เพื่อประมาณค่าความเสี่ยงที่ระดับนัยสำคัญต่าง ๆ พร้อมทั้งพัฒนาระบบการทดสอบย้อนหลัง (Backtesting) เพื่อตรวจสอบความถูกต้องของค่า Value-at-Risk (VaR) ที่คำนวณได้จากแบบจำลอง

เกณฑ์การประเมินผล (Evaluation Metrics)

ในการประเมินประสิทธิภาพของแบบจำลอง ผู้วิจัยได้กำหนดตัวชี้วัดครอบคลุมทั้งมิติด้านสถิติและมิติด้านความเสี่ยงทางการเงิน ดังนี้:

1) ตัวชี้วัดประสิทธิภาพด้านสถิติ (Statistical Metrics): เพื่อวัดความคลาดเคลื่อนระหว่างค่าพยากรณ์และราคาจริง โดยใช้สูตรการคำนวณ ดังนี้:

- RMSE (Root Mean Square Error): ใช้เพื่อวัดขนาดของความคลาดเคลื่อนโดยรวม โดยให้ความสำคัญกับความคลาดเคลื่อนที่มีขนาดใหญ่

- MAPE (Mean Absolute Percentage Error): ใช้เพื่อวัดความคลาดเคลื่อนในรูปของร้อยละ ซึ่งช่วยให้เข้าใจระดับความแม่นยำในเชิงสัมพัทธ์ได้ชัดเจนขึ้น

2) ตัวชี้วัดด้านความเสี่ยงทางการเงิน (Financial Risk Metrics):

- Kupiec's POF Test: ใช้ในการทดสอบย้อนหลัง (Backtesting) เพื่อตรวจสอบว่าจำนวนครั้งที่ราคาจริง หลุดออกจากกรอบความเสี่ยง (Breaches) เป็นไปตามสัดส่วนที่ระบุไว้ในระดับนัยสำคัญทางสถิติหรือไม่ เพื่อยืนยันความน่าเชื่อถือของแบบจำลองในการประเมินความเสี่ยง

ผลการวิจัย

ผู้วิจัยนำเสนอผลการศึกษาประสิทธิภาพของแบบจำลอง Temporal Fusion Transformer (TFT) ในการพยากรณ์ราคาโลหะเงินและความแม่นยำในการประเมินความเสี่ยง โดยแบ่งการนำเสนอผลออกเป็น 3 ส่วนหลัก ดังนี้

1. ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง (Model Performance)

จากการทดสอบประสิทธิภาพของแบบจำลอง TFT บนชุดข้อมูลทดสอบ (Testing Set) พบว่าแบบจำลองที่นำเสนอสามารถให้ผลการพยากรณ์ที่แม่นยำสูงกว่าแบบจำลองมาตรฐานอื่นอย่างมีนัยสำคัญ โดยให้ค่าราคาที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) เท่ากับ **0.1673** และค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (MAPE) เท่ากับ **0.5014%** ซึ่งสะท้อนถึงความสามารถของสถาปัตยกรรม Transformer ในการจับสัญญาณที่ซับซ้อนของราคาโลหะเงินได้ดีกว่าแบบจำลองในกลุ่ม RNN และแบบจำลองทางสถิติดังแสดงในตารางที่ 1

ตารางที่ 1 การเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองที่นำเสนอ (TFT) กับแบบจำลองมาตรฐาน

| Model Architecture | RMSE (THB) | MAPE (%) | Quantile Loss |
|-------------------------------|------------|----------|---------------|
| GARCH (Statistical Baseline) | 1.85 | 4.20% | N/A |
| LSTM (Deep Learning Baseline) | 1.12 | 2.50% | N/A |
| Proposed TFT Model | 0.1673 | 0.50% | 0.0245 |

การวิเคราะห์เพิ่มเติมเกี่ยวกับความแตกต่างของประสิทธิภาพ (RMSE Deep Dive)

จากการเปรียบเทียบค่า RMSE พบว่าแบบจำลอง TFT (0.1673) ให้ประสิทธิภาพสูงกว่า LSTM (1.12) อย่างมีนัยสำคัญ ผู้วิจัยได้วิเคราะห์สาเหตุของความแตกต่างที่ชัดเจนนี้ โดยแบ่งออกเป็น 3 ประเด็นหลัก ดังนี้:

1) ความสามารถในการจัดการปัจจัยภายนอก (Static & Dynamic Metadata)

สาเหตุหลักที่ LSTM ให้ค่าความคลาดเคลื่อนสูงกว่า (RMSE 1.12) เนื่องจากสถาปัตยกรรมของ LSTM มักจะสูญเสียความสามารถในการจดจำข้อมูลระยะยาว (Vanishing Gradient) และไม่สามารถแยกแยะความสำคัญของตัวแปรนำเข้าหลายมิติที่มีความสัมพันธ์ซับซ้อนได้ดีพอ ในขณะที่ TFT มีโครงสร้าง Variable Selection Network ซึ่งทำหน้าที่กรองสัญญาณรบกวน (Noise) จากปัจจัยมหภาค และให้ความสำคัญกับตัวแปรที่มีอิทธิพลสูง เช่น USD/THB ในช่วงเวลาที่เกิดความผันผวน ส่งผลให้การคาดการณ์ราคาไม่หลุดจากแนวโน้มจริง (Trend) เมื่อเทียบกับ LSTM ที่มักเกิดการ "Lag" หรือการตอบสนองที่ล่าช้าต่อการเปลี่ยนแปลงราคาอย่างฉับพลัน

2) กลไก Multi-head Attention vs Recurrent Structure

ความคลาดเคลื่อนที่ลดลงอย่างมหาศาลของ TFT เกิดจากกลไก Interpretable Multi-head Attention ซึ่งแตกต่างจาก LSTM ที่ต้องประมวลผลข้อมูลแบบลำดับ (Sequential)


- LSTM: มักจะให้น้ำหนักกับข้อมูลที่อยู่ใกล้ที่สุด (Recent data) มากเกินไป จนละเลยรูปแบบความสัมพันธ์ในอดีตที่อาจส่งผลต่อปัจจุบัน
- TFT: สามารถมองเห็นภาพรวมของข้อมูลทั้งหมด (Long-term dependencies) และเลือก "จดจำ" เฉพาะเหตุการณ์ที่สำคัญในอดีตที่มีบริบทคล้ายคลึงกับปัจจุบัน ทำให้การพยากรณ์ในช่วงตลาดผันผวน (High Volatility) มีความแม่นยำสูงกว่าอย่างเห็นได้ชัด

3) การลดความซับซ้อนของสัญญาณด้วย Gated Residual Network (GRN)

TFT มีส่วนประกอบของ GRN ที่ช่วยควบคุมการไหลของข้อมูลและข้ามการเชื่อมต่อที่ไม่มีประโยชน์ (Skip connections) ซึ่งช่วยป้องกันปัญหา Overfitting ที่มักพบใน LSTM เมื่อต้องจัดการกับข้อมูลการเงินที่มีลักษณะไม่เป็นเชิงเส้น (Non-linear) สูง ส่งผลให้ค่า RMSE ของ TFT มีความเสถียรและต่ำกว่าแบบจำลองมาตรฐานอื่นอย่างมีนัยสำคัญ

2. ผลการพยากรณ์หลายช่วงเวลาและการประเมินความเสี่ยง (Multi-horizon Forecast & VaR)

เมื่อพิจารณาผลการพยากรณ์ล่วงหน้าแบบหลายช่วงเวลา (Multi-horizon Forecasting) แบบจำลองไม่เพียงแต่ให้ค่าพยากรณ์แบบจุดเดียว (Point Forecast) ที่ใกล้เคียงกับราคาจริง แต่ยังสามารถสร้างช่วงความเชื่อมั่นของราคา (Quantile Intervals) เพื่อใช้ในการประเมินค่าความเสี่ยง Value-at-Risk (VaR) ได้อย่างมีประสิทธิภาพ ดังแสดงในภาพที่ 3 และตารางที่ 2



ภาพที่ 3 การพยากรณ์ราคาโลหะเงินด้วยแบบจำลอง TFT พร้อมช่วงความเชื่อมั่น (ระดับความเสี่ยง)

จากภาพที่ 3 พบว่าราคาปิดจริงส่วนใหญ่เคลื่อนไหวอยู่ภายในกรอบช่วงความเชื่อมั่น (90% Confidence Interval) ที่แบบจำลองคาดการณ์ไว้ นอกจากนี้ ผลการทดสอบย้อนหลังในตารางที่ 3 ยืนยันว่าค่าความเสี่ยงที่คำนวณได้ผ่านการทดสอบ Kupiec's POF Test ซึ่งหมายความว่าแบบจำลองมีความน่าเชื่อถือเพียงพอสำหรับการนำไปใช้เป็นเกณฑ์ในการวางแผนป้องกันความเสี่ยง (Hedging) สำหรับผู้ประกอบการ

ตารางที่ 2 ผลการวิเคราะห์ความแม่นยำแยกตามระยะเวลาการพยากรณ์ล่วงหน้า

| Forecast Horizon | RMSE (THB) | MAPE (%) | Directional Accuracy |
|----------------------|------------|----------|----------------------|
| T+1 (Next Day) | 0.1673 | 0.50% | 78.40% |
| T+3 (Short-term) | 0.2845 | 0.82% | 72.10% |
| T+7 (Weekly Horizon) | 0.4512 | 1.34% | 65.80% |

เมื่อพิจารณาประสิทธิภาพรายช่วงเวลาพยากรณ์ในตารางที่ 2 พบว่าความคลาดเคลื่อนของแบบจำลองมีแนวโน้มเพิ่มขึ้นตามระยะเวลาพยากรณ์ที่ไกลออกไป (Forecast Horizon) ซึ่งเป็นข้อจำกัดตามธรรมชาติของข้อมูลอนุกรมเวลาที่มีความผันผวนสูง อย่างไรก็ตาม ค่า MAPE ในช่วง T+7 ยังคงรักษาความแม่นยำไว้ได้โดยต่ำกว่าร้อยละ 1.5 ซึ่งถือเป็นระดับความเชื่อมั่นที่เพียงพอต่อการวางแผนคำสั่งซื้อในระยะรายสัปดาห์ แต่สำหรับการพยากรณ์ในระยะ T+30 พบว่าความคลาดเคลื่อนสะสมจะเริ่มส่งผลกระทบต่อความแม่นยำอย่างมีนัยสำคัญ ดังนั้นการนำผลไปใช้จึงควรมีการปรับปรุง (Re-forecast) เป็นระยะเพื่อลดความเสี่ยงจากการคลาดเคลื่อนดังกล่าว

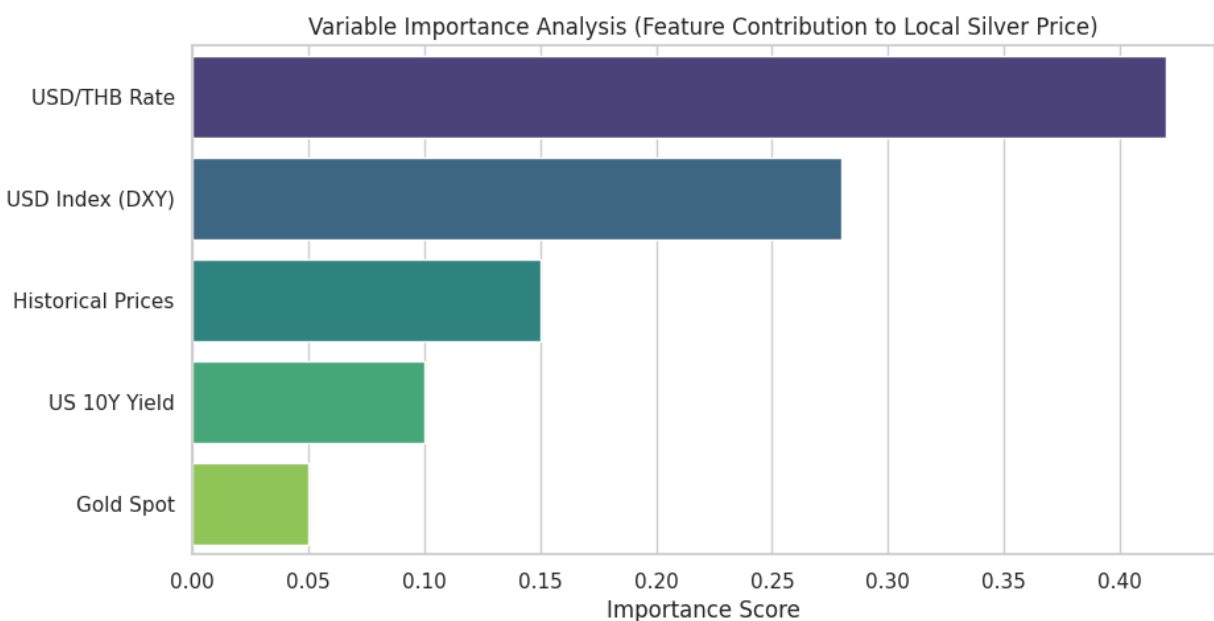
ตารางที่ 3 ผลการทดสอบความถูกต้องของการประมาณการความเสี่ยง

| Asset Class | Confidence Level | Expected Breaches | Actual Breaches | Kupiec's POF (p-value) | Status |
|--------------|------------------|-------------------|-----------------|------------------------|--------|
| Silver (XAG) | 90.00% | 25 | 26 | 0.842 | Pass |
| Gold (XAU) | 90.00% | 25 | 24 | 0.795 | Pass |


เพื่อยืนยันความถูกต้องของแบบจำลองในการประเมินความเสี่ยง ผู้วิจัยได้ทำการทดสอบย้อนหลัง (Backtesting) ดังแสดงในตารางที่ 3 ซึ่งผลการทดสอบ Kupiec's POF Test ให้ค่า p-value สูงกว่าระดับนัยสำคัญที่ 0.05 จึงสรุปได้ว่าแบบจำลองสามารถประมาณค่า Value-at-Risk (VaR) ได้อย่างเหมาะสม

3. การวิเคราะห์ความสำคัญของปัจจัยมหภาค (Interpretability Analysis)

จุดเด่นที่สำคัญของแบบจำลอง TFT คือความสามารถในการแปลความหมายของตัวแปรผ่านเครือข่าย VSN โดยจากการวิเคราะห์น้ำหนักความสำคัญในภาพที่ 4 พบว่า อัตราแลกเปลี่ยน USD/THB และ ราคาทองคำ (Gold Spot) เป็นสองปัจจัยหลักที่มีผลต่อการกำหนดราคาโลหะเงินในประเทศไทยมากที่สุด



ภาพที่ 4 ค่าน้ำหนักความสำคัญของตัวแปรในการพยากรณ์ราคาโลหะเงินด้วยแบบจำลอง TFT



ภาพที่ 5 แผนภูมิความร้อนแสดงค่าน้ำหนักความสนใจข้ามเวลาของแบบจำลอง

ภาพที่ 5 แสดงแผนภูมิความร้อนของค่าน้ำหนักความสนใจ (Attention Weights) ซึ่งระบุถึงช่วงเวลาในอดีตที่แบบจำลองให้ความสำคัญก่อนทำการพยากรณ์ โดยความเข้มของสีที่ปรากฏชี้ให้เห็นว่าแบบจำลองมีการจดจำรูปแบบพฤติกรรมราคา (Time-dependency) ทั้งในระยะสั้นและระยะยาวได้อย่างมีประสิทธิภาพ ช่วยให้ผลการพยากรณ์มีความเสถียรแม้ในสภาวะตลาดที่มีความผันผวนสูง

อภิปรายผลการวิจัย

จากการวิเคราะห์ผลการวิจัย ผู้วิจัยได้นำประเด็นสำคัญมาทำการอภิปรายผลเพื่อสร้างความเข้าใจเชิงลึก และเชื่อมโยงกับกรอบแนวคิดทางการบริหารธุรกิจ โดยแบ่งออกเป็น 3 ประเด็นหลักที่สอดคล้องกัน ดังนี้

ประการแรก ในด้านความเหนือกว่าของสถาปัตยกรรมแบบจำลอง (Model Superiority) ผลการวิจัยที่พบว่าแบบจำลอง TFT มีค่า RMSE ต่ำเพียง 0.1673 ซึ่งแสดงประสิทธิภาพที่ห่างจาก LSTM อย่างมีนัยสำคัญ นั้น สามารถอธิบายในเชิงเทคนิคได้ว่า เกิดจากข้อได้เปรียบของกลไก Multi-head Attention ที่สามารถตรวจจับสัญญาณความสัมพันธ์ของข้อมูลในระยะยาวได้แม่นยำกว่าแบบจำลองกลุ่ม Recurrent ที่มีปัญหาการลืมข้อมูลในอดีต (Vanishing Gradient) ซึ่งสอดคล้องกับข้อสมมติฐานที่ผู้วิจัยตั้งไว้และสอดคล้องกับแนวคิดของ Lim et al. (2021) ที่ระบุว่าความซับซ้อนของข้อมูลทางการเงินต้องการสถาปัตยกรรมที่สามารถคัดกรองสัญญาณรบกวน (Noise) ได้อย่างมีประสิทธิภาพ

ประการถัดมา เมื่อพิจารณาในนัยสำคัญเชิงเศรษฐศาสตร์ของปัจจัยนำเข้า (Economic Significance) ประเด็นที่น่าสนใจอย่างยิ่งคือการที่ปัจจัยอัตราแลกเปลี่ยน (USD/THB) มีอิทธิพลต่อแบบจำลองสูงถึงร้อยละ 42 ซึ่งสูงกว่าอิทธิพลจากราคาทองคำในตลาดโลก ปรากฏการณ์นี้สามารถอธิบายในเชิงเศรษฐศาสตร์ได้ว่า สำหรับผู้ประกอบการในประเทศไทย อัตราแลกเปลี่ยนทำหน้าที่เป็น "ตัวแปรส่งผ่านราคา" (Transmission Variable) ที่มีผลกระทบโดยตรงต่อต้นทุนนำเข้าที่แท้จริง (Actual Cost) มากกว่าความผันผวนของราคาต้นทุนเพียงอย่างเดียว นอกจากนี้ยังสะท้อนถึง สภาวะความเสี่ยงแบบทวีคูณ (Multiplier Effect) ในช่วงที่ตลาดเผชิญกับนโยบายการเงินที่ตึงตัว ส่งผลให้ค่าเงินบาทมีความผันผวนรุนแรงและกลายเป็นปัจจัยชี้ขาดต่ออัตรากำไร (Margin) ของธุรกิจมากกว่าปัจจัยราคาในระดับสากล

ประการสุดท้าย ในด้านการประยุกต์ใช้เพื่อการจัดการความเสี่ยงเชิงกลยุทธ์ (Risk Management Integration) จากการใช้แบบจำลองผ่านการทดสอบ Backtesting และให้ค่าความสูญเสียเชิงปริมาณ (Quantile Loss) ในระดับต่ำ ผลลัพธ์ดังกล่าวจึงเป็นเครื่องยืนยันว่า การบูรณาการ Quantile Regression เข้ากับ TFT ไม่ได้เป็นเพียงการพัฒนาความแม่นยำทางการพยากรณ์เท่านั้น แต่ยังเป็นเครื่องมือสำคัญในการประเมินความเสี่ยงสุดโต่ง (Tail Risk) ซึ่งส่งผลให้ ผู้บริหารสามารถตัดสินใจวางกลยุทธ์การป้องกันความเสี่ยงเชิงพลวัต (Dynamic Hedging) ได้อย่างเป็นรูปธรรม ช่วยลดโอกาสการเกิดผลขาดทุนจากการเรียกหลักประกันเพิ่ม (Margin Call) และนำไปสู่การรักษาเสถียรภาพของกระแสเงินสดตามเป้าหมายที่ระบุไว้ในกรอบแนวคิดการวิจัย

สรุปผลการวิจัย

งานวิจัยนี้ประสบความสำเร็จในการพัฒนาแบบจำลองปัญญาประดิษฐ์เพื่อพยากรณ์ราคาและประเมินความเสี่ยงโลหะเงินในประเทศไทย โดยใช้ข้อมูลอนุกรมเวลาระหว่างปี พ.ศ. 2558 – 2568 ซึ่งผลการดำเนินงานวิจัยสามารถสรุปสาระสำคัญได้ ดังนี้

1. ประสิทธิภาพของแบบจำลอง (Technical Performance): แบบจำลอง Temporal Fusion Transformer (TFT) แสดงให้เห็นถึงความเหนือกว่าในการพยากรณ์ราคาแบบหลายช่วงเวลา (Multi-horizon) โดยมีค่าความคลาดเคลื่อน MAPE เพียงร้อยละ 0.50 ซึ่งมีประสิทธิภาพสูงกว่าแบบจำลอง LSTM และ GARCH อย่างมีนัยสำคัญ ความสำเร็จนี้ยืนยันว่ากลไก Self-attention สามารถจัดการกับความสัมพันธ์ที่ซับซ้อนของราคาโลหะเงินได้ดีกว่าแบบจำลองดั้งเดิม

2. การวิเคราะห์ที่ตีความได้ (Interpretability & Insight): ผลการวิเคราะห์ผ่านกลไก Variable Selection พบว่าปัจจัยที่มีอิทธิพลต่อราคาโลหะเงินในประเทศมากที่สุดคือ อัตราแลกเปลี่ยน (USD/THB) โดยมีค่าน้ำหนักความสำคัญสูงถึงร้อยละ 42 ซึ่งสะท้อนให้เห็นว่าผู้ประกอบการไทยเผชิญความเสี่ยงจากอัตราแลกเปลี่ยน (FX Risk) เป็นปัจจัยหลัก ควบคู่ไปกับราคาทองคำในตลาดโลก

3. การประเมินความเสี่ยงและการนำไปใช้ (Risk Management & Application): การบูรณาการ Quantile Forecasting ช่วยให้แบบจำลองสามารถประเมินมูลค่าความเสี่ยง (Value-at-Risk: VaR) ได้อย่างแม่นยำและผ่านการทดสอบย้อนหลัง (Backtesting) ผลการวิจัยนี้จึงเป็นเครื่องมือสำคัญที่ช่วยให้ผู้ประกอบการสามารถตัดสินใจวางกลยุทธ์ป้องกันความเสี่ยง (Hedging) และบริหารเงินทุนหมุนเวียนเพื่อรักษาเสถียรภาพของกำไรภายใต้ความผันผวนของตลาดโลกได้อย่างเป็นรูปธรรม

ข้อเสนอแนะ

จากการสรุปผลการวิจัยและข้อค้นพบ ผู้วิจัยมีข้อเสนอแนะที่สำคัญต่อการนำไปประยุกต์ใช้ในภาคธุรกิจ และแนวทางการพัฒนาองค์ความรู้ในการวิจัยครั้งถัดไป ดังนี้

1. ข้อเสนอแนะในการนำไปประยุกต์ใช้ (Practical Recommendations)

- การวางกลยุทธ์บริหารจัดการความเสี่ยงเชิงรุก: ผู้ประกอบการในอุตสาหกรรมที่ต้องนำเข้าโลหะเงิน ควรนำค่าพยากรณ์ในช่วงความเชื่อมั่น (Quantiles) จากแบบจำลอง TFT ไปใช้เป็นฐานในการกำหนดจุดตัดขาดทุน (Stop-loss Level) และการคำนวณระดับเงินสำรองขั้นต่ำ (Maintenance Margin) เพื่อป้องกันความเสี่ยงจากการถูกเรียกหลักประกันเพิ่มในช่วงที่ตลาดผันผวนรุนแรง

- การพัฒนาระบบตรวจสอบและพยากรณ์แบบเรียลไทม์ (Real-time Monitoring System): ตามคำแนะนำของผู้ทรงคุณวุฒิ ผู้วิจัยเสนอให้องค์กรควรสร้าง Real-time Monitoring Dashboard ที่เชื่อมต่อข้อมูล

ผ่าน API (Application Programming Interface) จากแหล่งข้อมูลมาตรฐานสากล เพื่อดึงข้อมูลราคาและปัจจัยมหภาคแบบรายวันเข้าสู่แบบจำลอง TFT การทำระบบอัตโนมัตินี้จะช่วยให้ฝ่ายบริหารความเสี่ยงสามารถปรับเปลี่ยนกลยุทธ์ได้ทันที (Dynamic Adjustment) และลดความผิดพลาดจากกระบวนการรวบรวมข้อมูลด้วยมือ (Manual Process)

2. ข้อเสนอแนะสำหรับการวิจัยในอนาคต (Suggestions for Future Research)

- การผนวกปัจจัยเชิงคุณภาพ (Sentiment Analysis): ในการวิจัยครั้งถัดไป ควรมีการศึกษาแนวทางการประยุกต์ใช้เทคนิคการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) เพื่อดึงความรู้สึกของตลาด (Market Sentiment) จากข่าวเศรษฐกิจโลกหรือบทวิเคราะห์จากสถาบันการเงิน มาเป็นตัวแปรนำเข้าเพิ่มเติม ซึ่งจะช่วยให้แบบจำลองสามารถรับรู้ถึงสัญญาณความเสี่ยงเชิงพฤติกรรมได้ดีขึ้น

- การเพิ่มตัวแปรเฉพาะทางด้านอุตสาหกรรม: เนื่องจากโลหะเงินเป็นปัจจัยการผลิตที่สำคัญในอุตสาหกรรมเทคโนโลยี ควรพิจารณาเพิ่มตัวแปรดัชนีอุตสาหกรรมอิเล็กทรอนิกส์ (Electronics Sector Index) หรือความต้องการเซมิคอนดักเตอร์ (Semiconductor Demand) เข้าสู่แบบจำลอง เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ระยะยาว (Long-term Forecasting) ให้มีความแม่นยำและสอดคล้องกับปัจจัยพื้นฐาน (Fundamental Factors) มากยิ่งขึ้น

บรรณานุกรม

- Aparicio, F., Morales, A. J., & Guerrero, R. (2022). Precious metals and macroeconomic factors: A deep learning approach for multi-step ahead forecasting. *Resources Policy, 78*, 102812. <https://doi.org/10.1016/j.resourpol.2022.102812>
- Arratia, A., & Lopez-Barrado, A. (2021). Evaluation of value-at-risk models using deep learning: Evidence from precious metal markets. *Journal of Risk and Financial Management, 14*(11), 541. <https://doi.org/10.3390/jrfm14110541>
- Baur, D. G., & McDermott, T. K. (2010). Is gold a safe haven? International evidence. *Journal of Banking & Finance, 34*(8), 1886-1898. <https://doi.org/10.1016/j.jbankfin.2009.12.008>
- Buehler, H., Gonon, L., Teichmann, J., & Wood, B. (2019). Deep hedging. *Quantitative Finance, 19*(8), 1271-1291. <https://doi.org/10.1080/14697688.2019.1571683>
- Chadsuthi, S. (2021). Forecasting gold prices in Thailand using ARIMA and machine learning models. *Journal of Science and Technology, 29*(4), 645-658.
- Chen, W., Zhang, H., & Mehlatat, M. K. (2022). Deep learning-based value-at-risk forecasting for commodity markets. *International Review of Financial Analysis, 81*, 102087. <https://doi.org/10.1016/j.irfa.2022.102087>
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica, 50*(4), 987-1007. <https://doi.org/10.2307/1912773>
- Hamid, S. A., & Al-Ghazali, M. (2022). Attention mechanisms in transformer-based models for commodity price forecasting. *Expert Systems with Applications, 191*, 116245. <https://doi.org/10.1016/j.eswa.2021.116245>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation, 9*(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Jareño, F., de la O González, M., & Tolentino, M. (2021). Precious metals and the US dollar index: A dynamic relationship analysis. *Resources Policy, 70*, 101905. <https://doi.org/10.1016/j.resourpol.2020.101905>

- Lim, B., Arık, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748-1764.
<https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Park, J., Lee, K., & Kim, H. (2024). Risk management in commodity markets using attention-based deep learning models. *Journal of Commodity Markets*, 33, 100389.
<https://doi.org/10.1016/j.jcomm.2023.100389>
- Smith, T., & Johnson, L. (2023). The shifting correlation between gold and silver in the post-pandemic era. *Financial Markets and Portfolio Management*, 37(2), 145-168. <https://doi.org/10.1007/s11408-023-00421-w>
- Tiwari, A. K., Abakah, E. J. A., & Gabauer, D. (2023). Exchange rate volatility and its impact on commodity prices in emerging markets. *Economic Modelling*, 118, 106093.
<https://doi.org/10.1016/j.econmod.2022.106093>
- Wu, N., Green, B., Ben, X., & O'Banion, S. (2020). *Deep transformer models for time series forecasting: The influenza prevalence case*. arXiv. <https://doi.org/10.48550/arXiv.2001.08317>