APPLICATION OF MACHINE LEARNING AND THE GEOPOLITICAL RISK INDEX IN FORECASTING THE VOLATILITY OF AGRICULTURAL COMMODITY FUTURES PRICES

Jettanut RODPRASERT[1*] and Isariya SUTTAKULPIBOON[1]

1 Chulalongkorn Business School, Chulalongkorn University, Bangkok, Thailand;
6680063826@cbs.chula.ac.th

ARTICLE HISTORY

Received: 3 November 2025 **Revised:** 17 November 2025 **Published:** 2 December 2025

ABSTRACT

This study examines the influence of the Geopolitical Risk Index (GPR) on agricultural futures price volatility and compares the forecasting accuracy of statistical and machine learning models. Monthly data on corn and soybean futures prices were collected from the Chicago Mercantile Exchange (CME), Brasil Bolsa Balcão (B3), and Dalian Commodity Exchange (DCE) from June 2015 to May 2025. The models evaluated include SARIMAX, GARCHX, and LSTM neural networks. Exogenous variables incorporated are GPR, Geopolitical Threats (GPRT), Geopolitical Acts (GPRA), Country-Specific GPR (GPRC), and trading volume. Model performance is assessed using mean absolute percentage error (MAPE). Results indicate that LSTM models with exogenous variables are most effective at forecasting agricultural futures price volatility. For corn futures, LSTM (lookback = 12) provides the most accurate forecasts. The most effective exogenous variable is GPRC BRAZIL for CME, GPRC USA for B3, and GPRC RUSSIA for DCE. For soybean futures, LSTM (lookback = 6) exhibits the highest accuracy, with GPRA performing best for B3 and GPRC BRAZIL for DCE. Overall, the results demonstrate that integrating geopolitical factors with machine learning techniques effectively improves forecast accuracy of agricultural futures price volatility. This approach can be applied to risk management and hedging strategies in agricultural futures markets.

Keywords: Agricultural Commodity Futures Price Volatility, Geopolitical Risk, Machine Learning

CITATION INFORMATION: Rodprasert, J., & Suttakulpiboon, I. (2025). Application of Machine Learning and the Geopolitical Risk Index in Forecasting the Volatility of Agricultural Commodity Futures Prices. *Procedia of Multidisciplinary Research, 3*(12), 23

การประยุกต์ใช้การเรียนรู้ของเครื่องร่วมกับดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร

เจตณัฐ รอดประเสริฐ[1*] และ อิสริยะ สัตกุลพิบูลย์[1]

1 คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย; 6680063826@cbs.chula.ac.th

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาผลกระทบของดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ (GPR) ต่อความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร และเปรียบเทียบประสิทธิภาพของแบบจำลองทางสถิติและการเรียนรู้ของเครื่องในการพยากรณ์ โดยใช้ข้อมูลรายเดือนของราคาฟิวเจอร์สข้าวโพดและถั่วเหลืองจาก Chicago Mercantile Exchange (CME), Brasil Bolsa Balcão (B3) และ Dalian Commodity Exchange (DCE) ระหว่างมิถุนายน 2558 ถึงพฤษภาคม 2568 แบบจำลองที่ใช้ ได้แก่ SARIMAX, GARCHX และ LSTM โดยมีดัชนี GPR, GPRT, GPRA, GPRC และปริมาณการซื้อขายเป็นตัวแปรภายนอก โดยใช้ MAPE เป็นตัวชี้วัดประสิทธิภาพหลัก

ผลการวิจัยพบว่า แบบจำลอง LSTM ที่รวมตัวแปรภายนอกมีประสิทธิภาพสูงสุด สำหรับฟิวเจอร์สข้าวโพด LSTM (lookback = 12) ให้ผลแม่นยำที่สุด โดยตัวแปรภายนอกที่มีประสิทธิภาพสูงสุดในตลาด CME คือ GPRC BRAZIL, ตลาด B3 คือ GPRC USA และตลาด DCE คือ GPRC RUSSIA ส่วนฟิวเจอร์สถั่วเหลือง LSTM (lookback = 6) แสดงความแม่นยำสูงสุด โดยตลาด B3 มีตัวแปรภายนอกที่ได้ผลดีที่สุดคือ GPRA และตลาด DCE คือ GPRC BRAZIL

ผลการศึกษาแสดงให้เห็นว่า การผสมผสานปัจจัยทางภูมิรัฐศาสตร์เข้ากับเทคนิคการเรียนรู้ของเครื่องสามารถปรับปรุงความแม่นยำในการคาดการณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตรได้อย่างมีประสิทธิภาพ ซึ่งเป็นประโยชน์ต่อการจัดการความเสี่ยงและการวางแผนกลยุทธ์การป้องกันความเสี่ยงในตลาดสินค้าเกษตรล่วงหน้า

คำสำคัญ: ความผันผวนของราคาสินค้าเกษตรล่วงหน้า, ความเสี่ยงทางภูมิรัฐศาสตร์, การเรียนรู้ของเครื่อง

ข้อมูลการอ้างอิง: เจตณัฐ รอดประเสริฐ และ อิสริยะ สัตกุลพิบูลย์. (2568). การประยุกต์ใช้การเรียนรู้ของเครื่องร่วมกับดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร. *Procedia of Multidisciplinary Research, 3*(12), 23

บทนำ

ภาคเกษตรกรรมมีบทบาทสำคัญต่อเศรษฐกิจโลกและความมั่นคงด้านอาหาร แต่ราคาสินค้าเกษตรมักมีความผันผวนสูงมากจากหลายปัจจัย เช่น อุปสงค์-อุปทาน ภูมิอากาศ และโดยเฉพาะอย่างยิ่งคือความตึงเครียดทางการเมืองระหว่างประเทศ ตัวอย่างเช่น ความขัดแย้งระหว่างรัสเซียและยูเครนในปี 2022 ส่งผลให้ราคาฟิวเจอร์สข้าวโพดในตลาด CME เพิ่มขึ้นกว่า 40% ภายในสามเดือน ซึ่งแสดงให้เห็นว่า ความผันผวนที่เกิดขึ้นสามารถสร้างความเสียหายต่อพอร์ตการลงทุนและต้นทุนการผลิตได้อย่างมีนัยสำคัญ

ตลาดซื้อขายล่วงหน้า เช่น CME ในสหรัฐอเมริกา B3 ของบราซิล และ Dalian Commodity Exchange (DCE) ของจีน จึงถูกใช้เป็นกลไกสำคัญสำหรับการบริหารความเสี่ยงด้านราคา ถึงอย่างไรก็ตาม แม้ว่าตลาดดังกล่าวจะสามารถช่วยลดความไม่แน่นอนได้ แต่ความผันผวนของราคาสัญญาฟิวเจอร์สยังมีลักษณะซับซ้อน ทั้งในมิติความเป็นฤดูกาล ความไม่เชิงเส้น และผลของปัจจัยภายนอกที่ทวีความรุนแรงมากขึ้น โดยเฉพาะปัจจัยด้านภูมิรัฐศาสตร์ เช่น การคว่ำบาตรทางเศรษฐกิจ ความขัดแย้งระหว่างประเทศ หรือการเปลี่ยนแปลงความสัมพันธ์ทางการทูต ซึ่งสะท้อนผ่านดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ (Geopolitical Risk Index: GPR)

งานวิจัยที่ผ่านมาให้ความสำคัญกับการพยากรณ์ราคาและความผันผวนของสินค้าโภคภัณฑ์โดยใช้แบบจำลองทางสถิติ เช่น GARCH และ SARIMA รวมถึงเทคนิคการเรียนรู้ของเครื่อง อย่างไรก็ตาม การผสานดัชนี GPR ในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตรยังมีจำนวนจำกัด และขาดการเปรียบเทียบแบบจำลองหลายประเภทในหลายตลาดพร้อมกัน ผู้วิจัยจึงเกิดคำถามว่า “การใช้ความเสี่ยงทางภูมิรัฐศาสตร์ร่วมกับแบบจำลอง LSTM, SARIMAX หรือ GARCHX สามารถเพิ่มประสิทธิภาพในการพยากรณ์ความผันผวนของราคาซื้อขายล่วงหน้าสินค้าเกษตรได้ดีกว่าการใช้ข้อมูลราคาซื้อขายล่วงหน้าสินค้าเกษตรเพียง อย่างเดียวหรือไม่”

จากช่องว่างดังกล่าว งานวิจัยนี้มีวัตถุประสงค์เพื่อ 1) ศึกษาผลกระทบของดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ต่อความผันผวนของราคาฟิวเจอร์สสินค้าเกษตรแต่ละชนิด 2) พัฒนาแบบจำลองการเรียนรู้ของเครื่องที่สามารถประยุกต์ใช้ความเสี่ยงทางภูมิรัฐศาสตร์ในการพยากรณ์ความผันผวนของราคาสินค้าเกษตร และ 3) เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMAX, LSTM และ GARCHX ที่ ใช้ในการพยากรณ์ความผันผวนของราคาสินค้าเกษตร

การทบทวนวรรณกรรม

ตลาดฟิวเจอร์สสินค้าเกษตรมีบทบาทสำคัญในการกำหนดราคาสินค้าและบริหารความเสี่ยงของเกษตรกร นักลงทุน และผู้กำหนดนโยบาย (Lou, 2024) ภายใต้สภาวะที่มีความไม่แน่นอนจากปัจจัยภายนอก เช่น การเปลี่ยนแปลงของสภาพภูมิอากาศและความตึงเครียดทางภูมิรัฐศาสตร์ ตลาดฟิวเจอร์สจึงเป็นกลไกสำคัญในการลดความเสี่ยงและกระจายผลกระทบจากความผันผวนของราคา ตัวอย่างเช่น วิกฤตความขัดแย้งระหว่างรัสเซียและยูเครนในปี 2022 ส่งผลให้ราคาฟิวเจอร์สข้าวโพดเพิ่มขึ้นกว่า 40% ภายในระยะเวลาไม่ถึงสามเดือน เหตุการณ์ดังกล่าวสะท้อนถึงความสำคัญของการคาดการณ์การเปลี่ยนแปลงของราคาเพื่อสนับสนุนการจัดการความเสี่ยงอย่างมีประสิทธิภาพ

ตลาดฟิวเจอร์สหลักที่สะท้อนกลไกของภูมิภาคต่างๆ ได้แก่ Chicago Mercantile Exchange (CME) ซึ่งเป็นตัวแทนของตลาดพัฒนาแล้ว, B3 (Brasil Bolsa Balcão) ในฐานะตลาดเกิดใหม่ในซีกโลกใต้ และ Dalian Commodity Exchange (DCE) ซึ่งสะท้อนตลาดในประเทศกำลังพัฒนาในทวีปเอเชีย การวิเคราะห์ข้อมูลจากทั้งสามตลาดนี้สามารถให้มุมมองเชิงเปรียบเทียบของพลวัตความผันผวนในระดับโลกและแนวทางการจัดการความเสี่ยงของผู้มีส่วนได้ส่วนเสีย

แบบจำลองที่ได้รับความนิยมในการพยากรณ์ความผันผวนของราคาสินค้าเกษตร ได้แก่ SARIMA/SARIMAX, GARCH/GARCHX และแบบจำลองการเรียนรู้ของเครื่อง เช่น Long Short-Term Memory (LSTM) โดยแบบจำลอง SARIMA/SARIMAX สามารถจับแนวโน้มและฤดูกาลของข้อมูลได้อย่างมีประสิทธิภาพ และ SARIMAX ยังสามารถบูรณาการตัวแปรภายนอก เช่น ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ เพื่ออธิบายผลกระทบจากปัจจัยนอกตลาด ส่วนแบบจำลอง GARCH/GARCHX เหมาะสำหรับข้อมูลที่มีความผันผวนเปลี่ยนแปลงตามเวลา (time-varying volatility)

และสามารถรวมตัวแปรภายนอกเพื่อเพิ่มความแม่นยำในการคาดการณ์ ขณะที่แบบจำลอง LSTM มีศักยภาพในการเรียนรู้รูปแบบที่ซับซ้อนและไม่เชิงเส้นในข้อมูล ทำให้สามารถพยากรณ์ความผันผวนได้ดีกว่าแบบจำลองทางสถิติแบบดั้งเดิม งานวิจัยของ Wang et al. (2023) พบว่า LSTM มีประสิทธิภาพในการจับพลวัตของความผันผวนและความเสี่ยงราคาน้ำมัน ซึ่งมีความเชื่อมโยงกับตลาดสินค้าเกษตร ในด้านปัจจัยภูมิรัฐศาสตร์ พบว่าความขัดแย้งและวิกฤตการณ์ระหว่างประเทศส่งผลต่อความผันผวนของราคาสินค้าเกษตรอย่างมีนัยสำคัญ เช่น ภัยแล้งในซีเรียและสงครามรัสเซีย-ยูเครนที่ทำให้ราคาธัญพืชในตลาดโลกปรับตัวสูงขึ้น (ณัฐวิคม พันธุวงศ์ภักดี, 2021) อย่างไรก็ตาม งานวิจัยส่วนใหญ่ในอดีตยังมีข้อจำกัด ได้แก่ 1) การละเลยปัจจัยภูมิรัฐศาสตร์ในแบบจำลองเชิงปริมาณ 2) การขาดตัวชี้วัดความเสี่ยงทางภูมิรัฐศาสตร์ที่เหมาะสม และ 3) ความยากในการแปลงข้อมูลเชิงคุณภาพทางการเมืองให้อยู่ในรูปแบบที่สามารถใช้ในการเรียนรู้ของเครื่องได้อย่างมีประสิทธิภาพ ดังนั้น การผสานแบบจำลองทางสถิติ (SARIMA และ GARCHX) เข้ากับแบบจำลองการเรียนรู้ของเครื่อง (LSTM) พร้อมตัวแปรภูมิรัฐศาสตร์ เช่น ดัชนี GPR จึงเป็นแนวทางสำคัญในการเพิ่มความแม่นยำของการคาดการณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร การคาดการณ์ที่มีความถูกต้องสูงจะช่วยให้ผู้มีส่วนได้ส่วนเสียสามารถวางแผนการบริหารความเสี่ยง ปรับกลยุทธ์การลงทุน และเลือกเครื่องมืออนุพันธ์ได้เหมาะสมยิ่งขึ้น อีกทั้งยังสามารถพัฒนาเป็นระบบแจ้งเตือนล่วงหน้า (Early Warning System) เพื่อเสริมสร้างเสถียรภาพในตลาดสินค้าเกษตรโลกได้ในระยะยาว

วิธีดำเนินการวิจัย

การศึกษานี้เป็นการวิจัยเชิงปริมาณ (Quantitative Research) ที่มุ่งวิเคราะห์ความสัมพันธ์เชิงสาเหตุระหว่างความเสี่ยงทางภูมิรัฐศาสตร์ (Geopolitical Risk: GPR) กับความผันผวนของราคาสัญญาฟิวเจอร์สสินค้าเกษตร โดยใช้ข้อมูลรายเดือนของ ข้าวโพด (corn) และ ถั่วเหลือง (soybean) ระหว่างเดือนมิถุนายน 2558 ถึงพฤษภาคม 2568 (120 เดือน)

แหล่งข้อมูลและตัวแปรที่ใช้

ข้อมูลประกอบด้วย 3 กลุ่มหลัก ได้แก่

1) ราคาสัญญาซื้อขายล่วงหน้า จากตลาด CME (สหรัฐฯ), B3 (บราซิล) และ DCE (จีน) โดยใช้ราคาปิดรายเดือนจาก Bloomberg

2) ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ (Geopolitical Risk Indices) จากงานวิจัย Caldara et al. (2022) ได้แก่ GPR, GPRT, GPRA และ GPRC ของประเทศสหรัฐอเมริกา รัสเซีย ยูเครน จีน และบราซิล

3) ปริมาณการซื้อขาย (Trading Volume) ของสัญญาฟิวเจอร์สจาก Bloomberg

ตัวแปรตาม (Dependent Variable) คือ ค่าความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร*, อัตราการเปลี่ยนแปลงของราคาสัญญาซื้อขายล่วงหน้า**

ตัวแปรภายนอก (Exogenous Variables) ได้แก่ ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ และปริมาณการซื้อขาย ทั้งในรูปค่าระดับ (level) และ ผลตอบแทนแบบลอการิทึม (log return%) เพื่อสะท้อนการเปลี่ยนแปลงเชิงพลวัตของปัจจัยภูมิรัฐศาสตร์และสภาพคล่องตลาด โดยผู้วิจัยได้ทดสอบการใช้ตัวแปรภายนอก 2 รูปแบบนี้ทั้งแบบทีละตัวแปร (Single-variable) และแบบรวมทุกตัวแปร (Full model) เพื่อเปรียบเทียบประสิทธิภาพของการพยากรณ์ในแต่ละแบบจำลอง

การเตรียมข้อมูล (Data Preparation)

ข้อมูลได้รับการปรับให้อยู่ในรูปแบบที่เหมาะสมกับการวิเคราะห์อนุกรมเวลา ดังนี้:

1) Data Cleaning: ตรวจสอบและจัดการค่าที่สูญหาย (missing values) และค่าผิดปกติ (outliers) ด้วย Bollinger Bands

2) Data Transformation:

- แปลงราคาสัญญาซื้อขายล่วงหน้าเป็น Monthly Log Return% เพื่อใช้สร้างค่าความผันผวน

- แปลงค่าดัชนี GPR และปริมาณการซื้อขายให้อยู่ในรูป log return% เช่นกัน เพื่อสะท้อนการเปลี่ยนแปลงเชิงอัตราส่วนของความเสี่ยงภูมิรัฐศาสตร์ในแต่ละเดือน
- ทำ Normalization ให้ข้อมูลอยู่ในรูปแบบเดียวกันก่อนนำเข้าสู่แบบจำลอง

$$Monthly\ Log\ Returns\% = log\left(\frac{Price_t}{Price_{t-1}}\right) * 100$$

หมายเหตุ การแปลงข้อมูลเป็น Monthly Log Return% จะทำให้ข้อมูลหายไป 1 ข้อมูล คือ ลดลงจาก 120 ข้อมูล เป็น 119 ข้อมูล

3) Volatility Construction: ทดสอบ ARCH Effect ด้วย Ljung-Box Test และสร้างค่าความผันผวนโดยใช้แบบจำลอง GARCH ที่ให้ค่า AIC ต่ำที่สุด

ตารางที่ 1 แบบจำลองที่ใช้ในการสร้างค่าความผันผวนของแต่ละฟิวเจอร์ส

ฟิวเจอร์ส	แบบจำลอง	รูปแบบการแจกแจง
CME CORN	EGARCH (1,1)	Normal Distribution
CME SOYBEAN	EGARCH (1,1)	Normal Distribution
B3 CORN	EGARCH (1,1)	Normal Distribution
B3 SOYBEAN	EGARCH (1,1)	Normal Distribution
DCE CORN	EGARCH (1,1)	Normal Distribution
DCE SOYBEAN	EGARCH (1,1)	Student's t-Distribution

* หลังจากสร้างค่าความผันผวนด้วยแบบจำลองในตารางที่ 1 แล้ว ผู้วิจัยนำค่าความผันผวนที่ได้ มาใช้เป็นตัวแปรตามเพื่อใช้ในการพยากรณ์ด้วยแบบจำลอง SARIMAX และ LSTM

** สำหรับแบบจำลอง GARCHX ผู้วิจัยใช้อัตราการเปลี่ยนแปลงของราคาสัญญาซื้อขายล่วงหน้า มาใช้เป็นตัวแปรตาม

แบบจำลองที่ใช้ (Model Specification)

แบบจำลองหลักที่ใช้ในการเปรียบเทียบ ได้แก่:

1) SARIMAX: ใช้สำหรับการพยากรณ์เชิงเส้น โดยเพิ่มตัวแปรภายนอกทั้งในรูป level และ log return% เพื่อทดสอบผลเชิงพลวัต

2) LSTM: ใช้โครงข่ายประสาทเทียมแบบลำดับเวลา (Sequential LSTM) พร้อมข้อมูลย้อนหลัง (lookback = 6, 12 เดือน) และตัวแปรภายนอกทั้งสองรูปแบบ เพื่อเปรียบเทียบประสิทธิภาพ

3) GARCHX: แบบจำลองความแปรปรวนแบบมีเงื่อนไขที่เพิ่มตัวแปรภายนอกในสมการความผันผวน เพื่อประเมินผลของ GPR และปริมาณการซื้อขายต่อการเปลี่ยนแปลงของความผันผวน

ตารางที่ 2 แสดงการตั้งค่าพารามิเตอร์ของแบบจำลอง

ฟิวเจอร์ส	**SARIMAX**	**GARCHX / Distribution**	**LSTM**
CME CORN	SARIMA(1,0,3)$(0,1,1)_{12}$	EGARCH(1,1), Normal Distribution	Lookback = 6,12 LSTM Units = 64 Dropout = 0.2 Optimizer = ADAM Loss Function = MSE Epochs = 30
CME SOYBEAN	SARIMA(0,0,1)$(0,1,1)_{12}$	EGARCH(1,1), Normal Distribution	
B3 CORN	SARIMA(1,0,0)$(1,1,0)_{12}$	EGARCH(1,1), Normal Distribution	

ฟิวเจอร์ส	SARIMAX	GARCHX / Distribution	LSTM
B3 SOYBEAN	SARIMA(0,1,3)(1,1,1)$_{12}$	EGARCH(1,1), Normal Distribution	Batch Size = 16 Validation Split = 0.2 Early Stopping Patience = 5 Scaler = MinMaxScaler (0-1)
DCE CORN	SARIMA(0,1,1)(1,0,1)$_{12}$	EGARCH(1,1), Normal Distribution	
DCE SOYBEAN	SARIMA(0,1,2)(1,1,1)$_{12}$	EGARCH(1,1), Student's t-Distribution	

การประเมินผล (Model Evaluation)

ประสิทธิภาพของแต่ละแบบจำลองถูกประเมินด้วย

- Root Mean Square Error (RMSE)
- Mean Absolute Error (MAE)
- Mean Absolute Percentage Error (MAPE)

พร้อมเปรียบเทียบค่าความคลาดเคลื่อนระหว่างแบบจำลองที่ใช้ตัวแปรภายนอกในรูป ระดับ (level) กับแบบ log return% เพื่อระบุรูปแบบของตัวแปรที่ส่งผลต่อความแม่นยำมากที่สุด

ขั้นตอนการวิเคราะห์โดยสรุป

แบบจำลอง SARIMAX, แบบจำลอง LSTM

1) ทดสอบความนิ่งข้อมูล ด้วยวิธี ADF Test (เฉพาะแบบจำลอง SARIMAX)
2) กำหนดค่าพารามิเตอร์ของแบบจำลอง
3) ทำการแบ่งข้อมูลโดยจัดสรรให้ Training Data คิดเป็น 80% และ Testing Data คิดเป็น 20%
- ชุดฝึกฝน: ข้อมูลจากกรกฎาคม พ.ศ.2558 ถึงพฤษภาคม พ.ศ.2566 (95 เดือน)
- ชุดทดสอบ: ข้อมูลจากมิถุนายน พ.ศ.2566 ถึงพฤษภาคม พ.ศ.2568 (24 เดือน)

4) ฟิตข้อมูลด้วยแบบจำลอง
5) ทำการพยากรณ์ และประเมินประสิทธิภาพแบบจำลองด้วย RMSE, MAE, และ MAPE

สำหรับแบบจำลอง GARCHX

1) ทำการแบ่งข้อมูลอัตราการเปลี่ยนแปลงของราคาสัญญาซื้อขายล่วงหน้า ที่ได้จากการเตรียมข้อมูล โดยจัดสรรให้ Training Data คิดเป็น 80% และ Testing Data คิดเป็น 20%
- ชุดฝึกฝน: ข้อมูลจากกรกฎาคม พ.ศ.2558 ถึงพฤษภาคม พ.ศ.2566 (95 เดือน)
- ชุดทดสอบ: ข้อมูลจากมิถุนายน พ.ศ.2566 ถึงพฤษภาคม พ.ศ.2568 (24 เดือน)

2) กำหนดค่าพารามิเตอร์ของแบบจำลอง
โดยใช้แบบจำลองเดียวกันกับแบบจำลอง GARCH ในตารางที่ 1
3) ฟิตข้อมูลด้วยแบบจำลอง
4) ทำการพยากรณ์ และประเมินประสิทธิภาพแบบจำลองด้วย RMSE, MAE, และ MAPE

ผลการวิจัย

ตารางที่ 3 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองพยากรณ์ความผันผวนราคาฟิวเจอร์สข้าวโพดและถั่วเหลืองในตลาด CME, B3 และ DCE

	Model	Exog	RMSE	MAE	MAPE (%)
	LSTM with X: Model4_lb=12	GPRC BRA	0.2539	0.2096	3.2422
CME	LSTM with X: Model9_2_lb=6	Volume Return	0.2609	0.2296	3.5488
Corn	GARCHX Model3_2	GPRA Return	0.4695	0.3647	5.3836
	SARIMAX Model9_2	Volume Return	0.6206	0.4738	7.2564
	LSTM Model_lb=6	-	0.8115	0.5668	10.1616
CME	LSTM with X: Model2_lb=12	GPRT	0.9097	0.6356	11.3420
Soybean	SARIMAX Model6	GPRC RUS	1.1327	0.8391	13.4708
	GARCHX Model10_2	Full Model Return	1.3817	1.0510	16.3642
	LSTM with X: Model8_lb=12	GPRC USA	0.6723	0.5147	6.4676
B3	LSTM with X: Model10_lb=6	Full Model	0.7390	0.5588	6.8382
Corn	GARCHX Model9_2	Volume Return	0.9584	0.7204	8.5138
	SARIMAX Model10_2	Full Model Return	0.9070	0.7208	8.6356
	LSTM with X: Model3_lb=6	GPRA	0.5207	0.4089	11.2458
B3	LSTM with X: Model3_lb=12	GPRA	0.5626	0.4577	13.4138
Soybean	SARIMAX Model10	Full Model	0.6286	0.5168	13.6155
	GARCHX Model5_2	GPRC CHN Return	0.7016	0.6347	15.5056
	LSTM with X: Model6_lb=12	GPRC RUS	0.2337	0.1987	5.8277
DCE	LSTM with X: Model10_lb=6	Full Model	0.3155	0.2555	6.7238
Corn	GARCHX Model5_2	GPRC CHN Return	0.5013	0.3764	9.2722
	SARIMAX Model1	GPR	0.5241	0.4017	10.0854
	LSTM with X: Model4_lb=6	GPRC BRA	0.3862	0.3130	6.6178
DCE	LSTM with X: Model1_lb=12	GPR	0.4923	0.4060	8.5346
Soybean	GARCHX Model6_2	GPRC RUS Return	0.6014	0.4903	9.4686
	SARIMAX Model8	GPRC USA	0.7178	0.5381	12.9567

จากตารางที่ 3 พบว่า ประสิทธิภาพของแบบจำลองทางสถิติ และ แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร มีความแตกต่างกันไปตามลักษณะเฉพาะของฟิวเจอร์สและตลาดซื้อขาย ทั้งนี้ เพื่อให้สามารถประเมินความเหมาะสมของแบบจำลองได้อย่างชัดเจน ผู้วิจัยจึงได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMAX, LSTM, และ GARCHX โดยจำแนกตามฟิวเจอร์สแต่ละชนิด ดังนี้

1) CME CORN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สข้าวโพด พบว่าแบบจำลอง LSTM (Lookback = 12) ที่ใช้ตัวแปร GPRC BRA เป็นตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งใน

เกณฑ์ RMSE, MAE และ MAPE สะท้อนให้เห็นว่าแบบจำลองเชิงลึกสามารถเรียนรู้ลักษณะความผันผวนของข้อมูลที่มีความซับซ้อนและมีความสัมพันธ์เชิงเวลาได้ดีกว่าแบบจำลองเชิงเส้น

2) CME SOYBEAN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สถั่วเหลือง พบว่าแบบจำลอง LSTM (Lookback = 6) ที่ไม่ใช้ตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งในเกณฑ์ MAE และ MAPE ทั้งนี้เป็นไปตามคุณลักษณะของ LSTM ที่สามารถเรียนรู้ลำดับเชิงเวลาได้ดี โดยการใช้ข้อมูลย้อนหลังที่ยาวขึ้นช่วยให้โมเดลสามารถจับโครงสร้างเชิงพลวัตของความผันผวนในตลาดฟิวเจอร์สได้
อย่างมีประสิทธิภาพ

3) B3 CORN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สข้าวโพด พบว่าแบบจำลอง LSTM (Lookback = 12) ที่ใช้ตัวแปร GPRC USA เป็นตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งในเกณฑ์ RMSE, MAE และ MAPE สะท้อนให้เห็นว่าตลาดข้าวโพดของบราซิลได้รับอิทธิพลจากสถานการณ์ทางเศรษฐกิจและเหตุการณ์ทางภูมิรัฐศาสตร์ของสหรัฐอเมริกา ซึ่งเป็นประเทศคู่ค้าหลักและผู้ผลิตข้าวโพดรายใหญ่ของโลก ดังนั้นการใช้ตัวแปร GPRC USA จึงช่วยเพิ่มความสามารถในการอธิบายความผันผวนของราคาฟิวเจอร์สได้ดีกว่าแบบจำลองที่ไม่ใช้ตัวแปรภายนอก

4) B3 SOYBEAN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สถั่วเหลือง พบว่าแบบจำลอง LSTM (Lookback = 6) ที่ใช้ตัวแปร GPRA เป็นตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งในเกณฑ์ RMSE, MAE และ MAPE ทั้งนี้เป็นไปตามคุณลักษณะของ LSTM ที่สามารถเรียนรู้ลำดับเชิงเวลาได้ดี โดยการใช้ข้อมูลย้อนหลังที่ยาวขึ้นช่วยให้โมเดลสามารถจับโครงสร้างเชิงพลวัตของความผันผวนในตลาดฟิวเจอร์สได้อย่างมีประสิทธิภาพมากขึ้น

5) DCE CORN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สข้าวโพด พบว่าแบบจำลอง LSTM (Lookback = 12) ที่ใช้ตัวแปร GPRC RUS เป็นตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งในเกณฑ์ RMSE, MAE และ MAPE สะท้อนว่าตลาดข้าวโพดของจีนมีความอ่อนไหวต่อความไม่แน่นอนทางภูมิรัฐศาสตร์ที่เกี่ยวข้องกับรัสเซีย โดยเฉพาะประเด็นด้านพลังงานและความมั่นคงทางอาหาร ซึ่งส่งผลต่อราคาวัตถุดิบในตลาดโลกและส่งต่อมายังตลาดจีนในลักษณะ lagged effect

6) DCE SOYBEAN

จากผลการศึกษาประสิทธิภาพของแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สถั่วเหลือง พบว่าแบบจำลอง LSTM (Lookback = 6) ที่ใช้ตัวแปร GPRC BRA เป็นตัวแปรภายนอก มีประสิทธิภาพในการพยากรณ์สูงสุดเมื่อเทียบกับแบบจำลองอื่น โดยให้ค่าความคลาดเคลื่อนต่ำสุดทั้งในเกณฑ์ RMSE, MAE และ MAPE ทั้งนี้เป็นไปตามคุณลักษณะของ LSTM ที่สามารถเรียนรู้ลำดับเชิงเวลาได้ดี โดยการใช้ข้อมูลย้อนหลังที่ยาวขึ้นช่วยให้โมเดลสามารถจับโครงสร้างเชิงพลวัตของความผันผวนในตลาดฟิวเจอร์สได้อย่างมีประสิทธิภาพมากขึ้น

โดยสรุปแล้ว แบบจำลอง LSTM มีประสิทธิภาพสูงสุดในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตรในทุกตลาดและทุกฟิวเจอร์ส เมื่อเทียบกับแบบจำลองเชิงเส้นอย่าง SARIMAX และ GARCHX ทั้งนี้ ในกลุ่ม ฟิวเจอร์สข้าวโพด แบบจำลองที่สามารถพยากรณ์ได้อย่างแม่นยำที่สุดคือ LSTM ที่มีค่า Lookback = 12 ขณะที่ในกลุ่ม ฟิวเจอร์สถั่วเหลือง แบบจำลองที่ให้ผลการพยากรณ์แม่นยำที่สุดคือ LSTM ที่มีค่า Lookback = 6 ซึ่งเหมาะสมกับลักษณะของข้อมูลที่มีการเปลี่ยนแปลงถี่และตอบสนองต่อปัจจัยภายนอกในระยะสั้นมากกว่า

สรุปและอภิปรายผลการวิจัย

จากการศึกษาการประยุกต์ใช้การเรียนรู้ของเครื่องร่วมกับดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ ในการพยากรณ์ความผันผวนของราคาฟิวเจอร์สสินค้าเกษตร ได้แก่ ข้าวโพดและถั่วเหลือง ในตลาด CME, B3 และ DCE พบว่า แบบจำลอง SARIMAX มีความสามารถในการอธิบายโครงสร้างเวลาและฤดูกาลของข้อมูลราคาฟิวเจอร์สได้ดี โดยเฉพาะเมื่อรวมตัวแปรดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ เข้ามาในแบบจำลอง ผลลัพธ์สอดคล้องกับงานวิจัยของ Khadka and Chi (2024) ที่พบว่าแบบจำลองเชิงสถิติอย่าง SARIMA สามารถสะท้อนผลกระทบของเหตุการณ์ทางภูมิรัฐศาสตร์ต่อราคาสินค้าเกษตรได้อย่างมีประสิทธิภาพ โดยเฉพาะในช่วงที่ตลาดมีความผันผวนสูง สำหรับแบบจำลอง LSTM ซึ่งเป็นแบบจำลองเชิงลึกที่สามารถเรียนรู้ลำดับข้อมูลในอดีตและความสัมพันธ์แบบไม่เชิงเส้น ผลการวิจัยแสดงให้เห็นว่าการประยุกต์ใช้ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ร่วมกับแบบจำลอง LSTM สามารถเพิ่มประสิทธิภาพในการพยากรณ์ความผันผวนในตลาดที่มีความไม่แน่นอนสูง เช่น ตลาด DCE ของจีน ซึ่งสอดคล้องกับงานวิจัยของ Chen et al. (2021) และ Gu and Li (2024) ที่ยืนยันว่าแบบจำลอง LSTM สามารถประมวลความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปรเศรษฐกิจมหภาคกับราคาสินค้าเกษตรได้ดีกว่าแบบจำลองเชิงเส้นแบบดั้งเดิม ในขณะที่แบบจำลอง GARCHX สามารถอธิบายการเปลี่ยนแปลงของความแปรปรวนตามเวลาได้อย่างมีนัยสำคัญ ซึ่งผลการวิจัยสอดคล้องกับ Dai et al. (2024) ที่ระบุว่า แบบจำลอง GARCHX และ GJR-GARCH-MIDAS สามารถสะท้อนผลกระทบของ GPR ต่อความผันผวนในตลาดสินค้าเกษตรระหว่างประเทศได้อย่างชัดเจน

เมื่อเปรียบเทียบแบบจำลองโดยรวม พบว่า LSTM มีความแม่นยำในการพยากรณ์สูงสุด ในขณะที่ SARIMAX ให้ผลดีในตลาดที่มีรูปแบบฤดูกาลชัดเจน และ GARCHX เด่นในการจับความผันผวนแบบเฉียบพลันที่เกิดจากข่าวสารทางภูมิรัฐศาสตร์

ข้อเสนอแนะในการนำผลการวิจัยไปใช้

1) การบริหารความเสี่ยงด้านราคา: ผู้ประกอบการเกษตรกรรมและนักลงทุนควรใช้ ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ โดยเฉพาะจากประเทศผู้ผลิต มาประกอบการตัดสินใจในการทำ สัญญาซื้อขายล่วงหน้า (Hedging Strategy) เพื่อบริหารจัดการความผันผวนของราคาฟิวเจอร์สสินค้าเกษตรอย่างมีประสิทธิภาพ

2) การพัฒนาระบบเตือนภัยและระบบสนับสนุนการตัดสินใจ: ควรนำผลการวิจัยไปใช้ในการพัฒนา ระบบเตือนภัยล่วงหน้า (Early Warning System) และ ระบบสนับสนุนการตัดสินใจ (Decision Support System) โดยอาศัยแบบจำลองการเรียนรู้ของเครื่องที่ตอบสนองต่อการเปลี่ยนแปลงของดัชนีความเสี่ยงฯ เพื่อให้นักวิเคราะห์และผู้มีส่วนได้ส่วนเสียสามารถเตรียมรับมือกับความไม่แน่นอนของตลาดได้อย่างทันท่วงทีและมีข้อมูลสนับสนุนการตัดสินใจ

ข้อเสนอแนะในการทำวิจัยครั้งถัดไป

1) งานวิจัยครั้งถัดไปควรขยายขอบเขตไปยังฟิวเจอร์สสินค้าเกษตรอื่นๆ เช่น ข้าวสาลี น้ำตาล กาแฟ โกโก้ หรือยางพารา และพิจารณาเพิ่มตัวแปรด้านเศรษฐกิจมหภาค เช่น ดัชนีราคาผู้บริโภค (CPI) อัตราแลกเปลี่ยน และราคาน้ำมัน รวมถึงตัวแปรด้านภูมิอากาศ เช่น ปริมาณน้ำฝน เพื่อให้การวิเคราะห์ความผันผวนของราคามีความครอบคลุมและสมบูรณ์ยิ่งขึ้น

2) การวิจัยในอนาคตควรเพิ่มการเปรียบเทียบกับแบบจำลองที่ซับซ้อนกว่า เช่น แบบจำลอง Transformer หรือ Bidirectional LSTM เพื่อเพิ่มความสามารถในการทดสอบประสิทธิภาพของอัลกอริทึมที่แตกต่างกันในการพยากรณ์ความผันผวน

3) ในการวิจัยครั้งนี้ใช้ข้อมูลแบบรายเดือน ซึ่งอาจไม่สามารถสะท้อนข้อมูลที่เป็นปัจจุบัน การวิจัยในครั้งถัดไปอาจใช้ข้อมูลแบบรายวัน เพื่อเพิ่มความแม่นยำในการพยากรณ์

เอกสารอ้างอิง

Chen, S., Han, X., Shen, Y., & Ye, C. (2021). [Retracted] Application of Improved LSTM Algorithm in Macroeconomic Forecasting. *Computational Intelligence and Neuroscience, 2021*(1), 4471044.

Dai, Y. S., Dai, P. F., & Zhou, W. X. (2024). The impact of geopolitical risk on the international agricultural market: Empirical analysis based on the GJR-GARCH-MIDAS model. *arXiv preprint arXiv:2404.01641*.

Gu, S., & Li, M. (2024). Forecasting corn futures prices using the LSTM model. Financial Economics Research, 1(1), 1-16.

Khadka, R., & Chi, Y. N. (2024). Forecasting the Global Price of Corn: Unveiling Insights with SARIMA Modelling Amidst Geopolitical Events and Market Dynamics. *American Journal of Applied Statistics and Economics, 3*, 124-135.

Lou, C. (2024). Analysis of the Guiding Role of Futures Markets in Agricultural Development. Advances in Economics, *Management and Political Sciences, 92*, 330-335.

Wang, Z., French, N., James, T., Schillaci, C., Chan, F., Feng, M., & Lipani, A. (2023). Climate and environmental data contribute to the prediction of grain commodity prices using deep learning. *Journal of Sustainable Agriculture and Environment, 2*(3), 251-265.

ณัฐวิคม พันธุวงศ์ภักดี. (2021). *SDG Insights | ความท้าทายด้านความมั่นคง: ผลกระทบทางภูมิรัฐศาสตร์ของการเปลี่ยนแปลงสภาพภูมิอากาศ*. สืบค้นจาก https://www.sdgmove.com/2021/07/29/sdg-insights-climate-change-to-changes-in-geopolitics/.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.

Copyright: © 2025 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).