



ISSN 1859-3666
E-ISSN 2815-5726

Tạp chí KHOA HỌC THƯƠNG MẠI

TẠP CHÍ CỦA TRƯỜNG ĐẠI HỌC THƯƠNG MẠI



Năm thứ 24 - số 205
9/2025



khoa học thương mại

TẠP CHÍ CỦA TRƯỜNG ĐẠI HỌC THƯƠNG MẠI
ĐẠI HỌC QUỐC GIA HÀ NỘI

TỔNG BIÊN TẬP:

ĐINH VĂN SƠN

PHÓ TỔNG BIÊN TẬP:

THƯ KÝ TÒA SOẠN

TRƯỞNG BAN TRỊ SỰ

NGUYỄN THỊ QUỲNH TRANG

❑ Tòa soạn

Phòng 202 nhà T

Trường Đại học Thương mại

Số 79 đường Hồ Tùng Mậu

Mai Dịch, Cầu Giấy, Hà Nội

❑ Điện thoại: 024.37643219 máy lẻ 2102

❑ Fax: 024.37643228

❑ Email: tckhtm@tmu.edu.vn

❑ Website: tckhtm.tmu.edu.vn

❑ GP hoạt động báo chí:

Số 195/GP-BTTTT ngày 05/6/2023

❑ Chế bản tại: Tòa soạn

Tạp chí Khoa học Thương mại

❑ In tại: Cty TNHH In & TM Hải Nam

❑ Nộp lưu chiếu: 9/2025

HỘI ĐỒNG KHOA HỌC BIÊN TẬP

Đinh Văn Sơn - Đại học Thương mại (Chủ tịch)

Phạm Vũ Luận - Đại học Thương mại (Phó Chủ tịch)

Nguyễn Bách Khoa - Đại học Thương mại (Phó chủ tịch)

Phạm Minh Đạt - Đại học Thương mại (Ủy viên thư ký)

Các ủy viên

- **Vũ Thành Tự Anh** - ĐH Fulbright Việt Nam (Hoa Kỳ)

- **Lê Xuân Bá** - Viện QLKT TW

- **Hervé B. Boismery** - Đại học Reunion (Pháp)

- **H. Eric Boutin** - Đại học Toulon Var (Pháp)

- **Nguyễn Thị Doan** - Hội Khuyến học Việt Nam

- **Haasis Hans** - Đại học Bremenr (Đức)

- **Lê Quốc Hội** - Đại học Kinh tế quốc dân

- **Nguyễn Thị Bích Loan** - Đại học Thương mại

- **Nguyễn Hoàng Long** - Đại học Thương mại

- **Nguyễn Mai** - Chuyên gia kinh tế độc lập

- **Dương Thị Bình Minh** - ĐH Kinh tế Tp Hồ Chí Minh

- **Hee Cheon Moon** - Hội Nghiên cứu TM Hàn Quốc

- **Bùi Xuân Nhàn** - Đại học Thương mại

- **Lương Xuân Quỳ** - Hội Khoa học kinh tế Việt Nam

- **Nguyễn Văn Song** - Học viện Nông nghiệp Việt Nam

- **Nguyễn Thanh Tâm** - Đại học California (Hoa Kỳ)

- **Trương Bá Thanh** - ĐH Kinh tế - Đại học Đà Nẵng

- **Đinh Văn Thành** - Viện Nghiên cứu thương mại

- **Đỗ Minh Thành** - Đại học Thương mại

- **Lê Đình Thắng** - Đại học Québec (Canada)

- **Trần Đình Thiên** - Viện Kinh tế Việt Nam

- **Nguyễn Quang Thuấn** - Viện Hàn lâm KHXH Việt Nam

- **Washio Tomoharu** - ĐH Kwansey Gakuin (Nhật Bản)

- **Lê Như Tuyền** - Grenoble École de Managment (Pháp)

- **Zhang Yujie** - Đại học Tsinghua (Trung Quốc)

KINH TẾ VÀ QUẢN LÝ

- 1. Nguyễn Hoàng** - Ảnh hưởng của chất lượng thể chế đến chi phí logistics cấp tỉnh ở Việt Nam. *Mã số: 205.1TrEM.11* 3

The Impact of Institutional Quality on Provincial Logistics Costs in Vietnam

- 2. Hoàng Hải Hà** - Tác động của niềm tin tới ý định sử dụng dịch vụ công trực tuyến của công dân trên địa bàn thành phố Hà Nội. *Mã số: 205.1GEMg.11* 20

The impact of trust on citizens' intention to use e-government services in Hanoi city

QUẢN TRỊ KINH DOANH

- 3. Nguyễn Văn Nam** - Phát triển nguồn lực tài chính của đơn vị sự nghiệp công lập trong lĩnh vực văn hoá trực thuộc Bộ Văn hoá, Thể thao và Du lịch. *Mã số: 205.2FiBa.21* 33

Developing Financial Resources of Public Service Units in the Cultural Sector under the Ministry of Culture, Sports and Tourism

- 4. Phạm Hùng Cường, Nguyễn Xuân Minh và Tạ Thị Hương** - Tác động của thông tin đánh giá trực tuyến đến quyết định mua hàng tiêu dùng nhanh trên các sàn thương mại điện tử của Gen Z tại Thành phố Hồ Chí Minh. *Mã số: 205.2BMkt.21* 47

The impact of Gen Z's online review information on fast-moving consumer goods purchasing decision on e-commerce platforms in Ho Chi Minh City

- 5. Lê Thị Thu Mai, Lương Châu Giang, Lý Xuân Trà, Cao Hiếu Trang, Nguyễn Mai Linh và Trần Thị Hà Phương** - Vai trò của cảm nhận về mức độ chân thành trong hoạt động trách nhiệm xã hội đối với lòng trung thành với thương hiệu. **Mã số: 205.2BMkt.21**

65

The influence of perceived corporate social responsibility authenticity on brand loyalty

- 6. Bùi Thị Minh Hằng và Nguyễn Thị Thanh Huyền** - Khác biệt giới trong nhận thức về biến đổi khí hậu của nông dân tại tỉnh Bắc Kạn và Tuyên Quang. **Mã số: 205.2DEco.21**

80

Gender Differences in Perception of Climate Change Among Farmers in Bac Kan and Tuyen Quang Provinces

Ý KIẾN TRAO ĐỔI

- 7. Nguyễn Đức Nhuận và Phạm Ngọc Minh Châu** - Thương mại Mỹ - Trung dưới nhiệm kỳ thứ hai của Tổng thống Donald Trump: Triển vọng - Cơ hội và Thách thức. **Mã số: 205.3IIEEM.31**

91

U.S.–China Trade Relation under the Second Presidency of Donald Trump: Prospects, Opportunities, and Challenges

- 8. Hồ Thị Lam, Lê Trương Minh Thư, Hoàng Thùy Dương, Trịnh Thị Ngọc Thuận, Huỳnh Thế Công và Trần Nguyễn Uyển Nhi** - Dự báo lạm phát Việt Nam: Liệu học máy có vượt trội hơn mô hình truyền thống? **Mã số: 205.3OMIs.31**

100

Forecasting Inflation in Vietnam: Can Machine Learning Outperform Traditional Models?

DỰ BÁO LẠM PHÁT VIỆT NAM: LIỆU HỌC MÁY CÓ VƯỢT TRỘI HƠN MÔ HÌNH TRUYỀN THỐNG?

Hồ Thị Lam*

Email: holam@ufm.edu.vn

Lê Trương Minh Thu*

Email: letuongminhthu2004@gmail.com

Hoàng Thùy Dương*

Email: thduonghhh@gmail.com

Trịnh Thị Ngọc Thuận*

Email: ngocthuan06052004@gmail.com

Huỳnh Thế Công*

Email: huynhcong151104@gmail.com

Trần Nguyễn Uyển Nhi*

Email: trannguyennhi76@gmail.com

*Trường Đại học Tài chính - Marketing

Ngày nhận: 08/01/2025

Ngày nhận lại: 01/04/2025

Ngày duyệt đăng: 07/04/2025

Nghiên cứu này nhằm mục tiêu dự báo lạm phát tại Việt Nam bằng cách so sánh hiệu quả của các mô hình truyền thống và trí tuệ nhân tạo. Sử dụng dữ liệu chuỗi thời gian từ năm 2009 đến năm 2023 với 179 quan sát, nghiên cứu áp dụng các mô hình ARIMA, LSTM, ANN và Lasso để đánh giá và so sánh độ chính xác trong dự báo lạm phát. Kết quả cho thấy mô hình Lasso mang lại dự báo chính xác nhất so với các mô hình khác. Điều này cung cấp hàm ý chính sách quan trọng, khi các cơ quan quản lý có thể dựa vào kết quả của mô hình Lasso để nâng cao khả năng dự báo và điều chỉnh chính sách kinh tế kịp thời nhằm đối phó với các biến động lạm phát trong tương lai. Khả năng dự báo chính xác sẽ hỗ trợ việc điều hành chính sách tiền tệ và tài khóa một cách hiệu quả hơn, giúp duy trì ổn định kinh tế vĩ mô. Đồng thời, kết quả nghiên cứu cũng gợi ý rằng việc ứng dụng mô hình trí tuệ nhân tạo vào các bài toán kinh tế có tiềm năng lớn trong việc cải thiện độ chính xác của dự báo, từ đó đóng góp vào việc xây dựng nền kinh tế ổn định và bền vững hơn trong dài hạn.

Từ khóa: Dự báo lạm phát, học sâu, học máy, AI, ANN, ARIMA, Lasso, LSTM.

JEL Classifications: C22, C53, E31, E37.

DOI: 10.54404/JTS.2025.205V.08

1. Giới thiệu

Dự báo lạm phát đóng vai trò quan trọng trong việc hoạch định chính sách kinh tế, quyết định trên thị trường tài chính và chiến lược kinh doanh. Trong bối cảnh kinh tế thay

đổi nhanh chóng, đặc biệt là ở các nước đang phát triển như Việt Nam, dự báo lạm phát chính xác là cần thiết để kiểm soát chính sách tiền tệ, định hướng quyết định tài khóa và đảm bảo sự ổn định kinh tế. Lạm phát có thể

Tác giả liên hệ: holam@ufm.edu.vn

ảnh hưởng trực tiếp đến các quyết định của các chủ thể kinh tế, ảnh hưởng đến sức mua của một quốc gia, lãi suất và tăng trưởng kinh tế tổng thể (Hồ Thị Lam, 2015). Do đó, việc xây dựng các mô hình dự báo tin cậy có thể phản ánh đúng các biến động lạm phát tại Việt Nam là điều quan trọng đối với các nhà hoạch định chính sách và các tổ chức tài chính.

Trong dự báo kinh tế truyền thống, các mô hình tuyến tính như Auto-Regressive Integrated Moving Average (ARIMA) đã được sử dụng rộng rãi nhờ tính đơn giản và dễ hiểu. Mô hình ARIMA hoạt động trên giả định rằng các giá trị quá khứ và sai số có thể dự báo xu hướng tương lai, khiến nó trở thành lựa chọn phổ biến cho dữ liệu chuỗi thời gian (Box & Jenkins, 1976). Tuy nhiên, ARIMA thường bị giới hạn trong việc nắm bắt các yếu tố phi tuyến và các mối quan hệ phức tạp trong dữ liệu, điều ngày càng được công nhận là quan trọng để dự báo chính xác trong các nền kinh tế hiện đại (Cheng và cộng sự, 2015).

Sự xuất hiện của trí tuệ nhân tạo, cụ thể là các kỹ thuật học máy (machine learning - ML) và học sâu (deep learning - DL) tiên tiến đã mở ra những khả năng mới nhằm cải thiện độ chính xác của dự báo lạm phát. Các mô hình học máy, chẳng hạn như Mạng Nơ-ron Nhân tạo (Artificial Neural Networks - ANN) và các mô hình học sâu, đặc biệt là mô hình trí nhớ ngắn - dài hạn (Long Short-Term Memory - LSTM), có tiềm năng vượt qua giới hạn của các mô hình tuyến tính truyền thống bằng cách học từ các tập dữ liệu lớn và nắm bắt các mẫu phức tạp hơn (Zhang và cộng sự, 1998). ANN, được lấy cảm hứng từ mạng nơ-ron của não người, có khả năng mô hình hóa các mối quan hệ phi tuyến giữa đầu vào và đầu ra (Sako và cộng sự, 2022). LSTM, một loại mạng nơ-ron hồi quy (Recurrent Neural Network - RNN), đặc biệt phù hợp với dự báo chuỗi thời gian do khả năng ghi nhớ các trạng thái trước đó qua các chuỗi dài, từ đó nắm bắt được các phụ thuộc thời gian hiệu quả hơn so với các mô hình truyền thống (Hochreiter & Schmidhuber, 1997; Lim & Zohren, 2021).

Ngoài ra, các kỹ thuật điều chuẩn như Lasso (Least Absolute Shrinkage and Selection Operator) cũng thu hút sự chú ý nhờ khả năng xử lý hiện tượng quá khớp (overfitting) trong dữ liệu nhiều chiều. Lasso thực hiện việc lựa chọn biến và điều chuẩn, cho

phép tạo ra các mô hình tiết kiệm biến số hơn, qua đó cải thiện khả năng khái quát hóa trên dữ liệu chưa được nhìn thấy (Tibshirani, 1996). Nhiều nghiên cứu gần đây đã chỉ ra rằng việc sử dụng Lasso có thể giảm thiểu độ phức tạp của mô hình mà không làm suy giảm hiệu suất dự báo, đặc biệt trong các bài toán kinh tế với dữ liệu chuỗi thời gian và biến động lớn (Tao & Zhang, 2016; Zou, 2006). Bằng cách tích hợp Lasso vào dự báo lạm phát, tác giả tìm cách kiểm tra xem liệu nó có thể nâng cao hiệu suất của mô hình thông qua việc giảm độ phức tạp trong khi vẫn duy trì độ chính xác hay không.

Dự báo những thay đổi tiềm ẩn trong môi trường tài chính và kinh tế, giúp các cơ quan quản lý tài chính phát hiện sớm những nguy cơ đe dọa sự ổn định của hệ thống tài chính cụ thể là lạm phát, từ đó đưa ra các biện pháp phòng ngừa thích hợp giúp giảm thiểu rủi ro cho nền kinh tế và định hướng đầu tư, tránh được những cú sốc kinh tế bất ngờ và hỗ trợ ổn định kinh tế vĩ mô và phát triển kinh tế bền vững. Trong khi có nhiều mô hình khác nhau được phát triển, mục tiêu của nghiên cứu này là tập trung so sánh hiệu quả của các mô hình khác nhau (ARIMA, ANN, LSTM và Lasso) trong dự báo lạm phát ở Việt Nam. Khi nền kinh tế Việt Nam ngày càng hội nhập vào thị trường toàn cầu, việc dự báo lạm phát trở nên đặc biệt thách thức do những cú sốc bên ngoài, sự biến động giá cả toàn cầu và quá trình chuyển đổi của quốc gia này sang một nền kinh tế thị trường. Việc áp dụng các phương pháp truyền thống và hiện đại sẽ cung cấp cái nhìn sâu sắc về điểm mạnh và hạn chế của chúng trong bối cảnh Việt Nam, từ đó giúp các nhà hoạch định chính sách hay các nhà đầu tư lựa chọn mô hình phù hợp nhất với nhu cầu của mình để dự báo lạm phát trong tương lai.

Trong các phần tiếp theo, nhóm tác giả sẽ thực hiện xem xét các nghiên cứu hiện có về các mô hình dự báo lạm phát, đồng thời cùng thảo luận về các phương pháp so sánh các kỹ thuật này cũng như trình bày kết quả phân tích của nhóm tác giả dựa trên dữ liệu lạm phát của Việt Nam. Cuối cùng, nghiên cứu này sẽ xác định những phương pháp nào đưa ra dự báo chính xác và đáng tin cậy nhất, đặc biệt tập trung vào cách các mô hình xử lý sự phức tạp và các yếu tố đặc thù của lạm phát Việt Nam.

2. Tổng quan nghiên cứu

2.1. Các nghiên cứu dự báo lạm phát sử dụng mô hình truyền thống

Trong bối cảnh biến động lớn của nền kinh tế toàn cầu, việc dự báo lạm phát đã trở thành một công cụ hữu ích trong điều hành kinh tế vĩ mô (de Mendonça & de Guimarães e Souza, 2012). Trên thế giới đã có rất nhiều mô hình truyền thống được ứng dụng để dự báo lạm phát. ARIMA (Autoregressive Integrated Moving Average) là mô hình dự báo truyền thống được biết đến với khả năng nắm bắt các đặc điểm quan trọng của lạm phát trong thời gian ngắn (Enders & Siklos, 2001). Tuy nhiên, các nghiên cứu dự báo lạm phát bằng mô hình ARIMA đã chứng minh ARIMA không thể xử lý tốt các chuỗi thời gian có xu hướng hoặc thay đổi cấu trúc, dẫn đến độ chính xác thấp trong dự báo dài hạn. Điều này gợi ý rằng, ARIMA có thể hữu ích trong ngắn hạn, nhưng hiệu suất của nó có thể suy giảm đáng kể trong bối cảnh biến động kinh tế. Nghiên cứu của (Box & Jenkins, 1976) đặt nền tảng cho mô hình ARIMA trong phân tích chuỗi thời gian, trở thành công cụ phổ biến trong dự báo kinh tế và lạm phát. Tiếp nối nghiên cứu này, (Junttila, 2001) áp dụng ARIMA vào dự báo lạm phát ở nền kinh tế Phần Lan, cho thấy độ chính xác cao của phương pháp này trong ngắn hạn, mặc dù nó có hạn chế khi áp dụng cho các dự báo dài hạn. Nghiên cứu của (Akbulut, 2022) tại Thổ Nhĩ Kỳ so sánh mô hình ARIMA với các phương pháp học máy, kết luận rằng ARIMA mang lại dự báo ổn định nhưng kém linh hoạt hơn so với các mô hình hiện đại khi sử dụng cho các giai đoạn dài. Nghiên cứu của (Salam và cộng sự, 2007) cũng nhận mạnh rằng ARIMA phù hợp với các dự báo ngắn hạn tại Pakistan, mặc dù việc kết hợp với các mô hình biến động có thể cải thiện độ chính xác trong dài hạn.

Trong dự báo lạm phát, việc hiểu rõ mối quan hệ giữa các biến số kinh tế là rất quan trọng. Các mô hình truyền thống như ARIMA thường chỉ tập trung vào một biến duy nhất, trong khi mô hình VAR (Vector Autoregression) đã mở rộng khả năng dự báo lạm phát bằng cách xem xét mối quan hệ tương tác giữa nhiều yếu tố kinh tế. Mô hình VAR có thể cải thiện độ chính xác trong dự báo khi các yếu tố kinh tế không hoạt động

độc lập (Sims, 1980). Các nghiên cứu sử dụng mô hình VAR để dự báo lạm phát đã đóng góp quan trọng vào việc phân tích mối quan hệ động giữa các biến kinh tế vĩ mô và lạm phát. Blanchard & Quah (1989) mở rộng VAR bằng cách áp dụng phương pháp phân rã để phân biệt giữa các cú sốc cung và cầu, cho phép nghiên cứu tác động của các biến động kinh tế đối với lạm phát. Trong nghiên cứu tại Mỹ, (Stock & Watson, 2003) sử dụng VAR để phân tích và dự báo lạm phát, cho thấy rằng mô hình này có độ chính xác cao trong việc nắm bắt các chu kỳ kinh tế và dự báo ngắn hạn. Cũng tại các nền kinh tế mới nổi, nghiên cứu của Canova (1995) cho thấy VAR là công cụ hiệu quả để dự báo lạm phát, giúp phân tích tác động của các yếu tố như cung tiền, lãi suất và tỷ giá hối đoái. Bernanke & Kuttner (2005) ứng dụng VAR vào phân tích chính sách tiền tệ, nhấn mạnh rằng mô hình này có khả năng dự báo lạm phát và đánh giá tác động của chính sách một cách chính xác trong các nền kinh tế phát triển và mới nổi. Nhìn chung, các nghiên cứu này cho thấy VAR là một công cụ linh hoạt và mạnh mẽ trong dự báo lạm phát, đặc biệt là khi có sự tương tác phức tạp giữa các yếu tố kinh tế vĩ mô.

Mô hình ARCH (Autoregressive Conditional Heteroskedasticity) đã được phát triển để cải thiện khả năng dự đoán trong các tình huống có biến động mạnh. Khả năng này trở nên đặc biệt cần thiết trong bối cảnh lạm phát, khi mà những biến động tài chính có thể gây ra những tác động sâu rộng đến nền kinh tế. Mô hình ARCH cho thấy khả năng mô phỏng biến động tài chính tốt hơn so với các mô hình như ARIMA (Engle, 1982). Các nghiên cứu sử dụng mô hình ARCH/GARCH trong dự báo lạm phát đã đóng góp nhiều vào việc hiểu rõ hơn về biến động và tính bất ổn định trong lạm phát. Engle (1982) là người đầu tiên giới thiệu mô hình ARCH nhằm phân tích sự thay đổi trong phương sai của sai số qua các thời điểm, mở đầu cho việc ứng dụng rộng rãi của mô hình này trong phân tích biến động lạm phát. (Bollerslev, 1986) sau đó phát triển mô hình GARCH (Generalized ARCH), cho phép phân tích sự biến động lâu dài, đáp ứng tốt hơn yêu cầu dự báo ở các giai đoạn dài. Nghiên cứu của (Brunner & Hess, 1993) sử dụng mô hình GARCH để phân tích lạm phát tại Mỹ, chứng minh rằng sự biến động

của lạm phát có tính dài hạn và mô hình GARCH có khả năng nắm bắt các đặc điểm biến động này một cách hiệu quả. Trong bối cảnh các thị trường mới nổi, nghiên cứu của (Qasim và cộng sự, 2021) sử dụng mô hình GARCH để dự báo lạm phát ở Pakistan, cho thấy rằng GARCH có khả năng dự báo chính xác hơn so với các mô hình tuyến tính truyền thống nhờ vào việc xử lý được tính không ổn định của dữ liệu kinh tế. Những nghiên cứu này khẳng định tính ưu việt của ARCH/GARCH trong dự báo lạm phát khi các biến động không ổn định đóng vai trò quan trọng trong việc hiểu và dự đoán xu hướng lạm phát.

Tổng quan, các mô hình dự báo truyền thống, bao gồm ARIMA, VAR và ARCH/GARCH, mặc dù cung cấp những công cụ hữu ích trong việc dự đoán lạm phát, nhưng vẫn tồn tại những hạn chế nhất định. Đầu tiên, các mô hình này thường phụ thuộc vào dữ liệu lịch sử, khiến cho khả năng phản ứng với các cú sốc kinh tế hoặc biến động bất ngờ trở nên hạn chế. Chúng thường không đủ linh hoạt để xử lý các yếu tố ngoại sinh, như chính sách tiền tệ, sự thay đổi trong điều kiện thị trường, hoặc các sự kiện bất ngờ khác có thể ảnh hưởng lớn đến lạm phát. Hơn nữa, tính phức tạp của các mối quan hệ giữa các biến kinh tế có thể dẫn đến việc các mô hình này khó xác định chính xác các mối quan hệ nhân quả và đưa ra dự báo tin cậy trong bối cảnh không ổn định. Cuối cùng, sự phụ thuộc vào các giả định về tính ổn định và cấu trúc của mô hình có thể làm giảm độ chính xác của các dự báo, đặc biệt trong những thời kỳ biến động mạnh của nền kinh tế. Do đó, mặc dù có giá trị trong nhiều tình huống, các mô hình dự báo truyền thống cần được cải tiến hoặc kết hợp với các phương pháp hiện đại hơn để tăng cường độ chính xác và khả năng thích ứng trong việc dự đoán lạm phát.

2.2. Các nghiên cứu dự báo lạm phát sử dụng AI - các mô hình học máy và học sâu

Mô hình học máy (ML) và học sâu (DL) đóng vai trò quan trọng trong việc dự báo và kiểm soát lạm phát bằng cách phân tích các mối quan hệ phức tạp giữa các yếu tố kinh tế. Điển hình như ANN và LSTM có thể vượt qua giới hạn của mô hình tuyến tính truyền thống bằng cách học từ dữ liệu lớn và nắm bắt các mẫu phức tạp (Zhang và cộng sự, 1998).

Stock & Watson (1999) là một trong những nghiên cứu tiên phong xử lý dự báo lạm phát ở Hoa Kỳ bằng cách sử dụng các phương pháp mạng nơ-ron (NN). Họ so sánh các dự báo ở các mốc thời gian một, sáu và mười hai tháng đối với chuỗi thời gian kinh tế hàng tháng của Hoa Kỳ. Kết quả chỉ ra rằng hầu hết các phương pháp phi tuyến tính, bao gồm phương pháp ANN, đều đưa ra dự báo tệ hơn các phương pháp AR tuyến tính (Stock & Watson, 1999). Nakamura (2005), trong một nghiên cứu sau đó, đã dự báo lạm phát mới của Hoa Kỳ bằng cách sử dụng phương pháp mạng nơ-ron. Tác giả sử dụng GDPdeflator làm chỉ báo lạm phát. Các mạng nơ-ron hoạt động tốt hơn các mô hình tự hồi quy đơn biến như các mô hình AR với các đường cơ sở khác nhau (Nakamura, 2005). Hussain và cộng sự (2022) đã áp dụng mô hình ANN và ARIMA để dự báo lạm phát ở Pakistan và chứng minh rằng ANN không chỉ cải thiện khả năng dự đoán mà còn có khả năng xử lý dữ liệu không ổn định một cách hiệu quả. Almosova & Andresen (2019) chỉ ra rằng mạng nơ-ron nhân tạo (ANN) cho kết quả tốt hơn so với các mô hình AR tuyến tính và bước đi ngẫu nhiên, đồng thời mô hình này không chỉ cải thiện độ chính xác dự báo mà còn có khả năng nắm bắt các mối quan hệ phi tuyến tính trong dữ liệu kinh tế. Nghiên cứu của (Haider & Hanif, 2007) cũng xác nhận tính hiệu quả của mô hình ANN trong việc dự báo lạm phát ở Pakistan, cho thấy rằng các mô hình học máy có thể cung cấp những dự báo chính xác hơn nhờ vào khả năng xử lý và phân tích dữ liệu lớn. Medeiros và cộng sự (2021) cũng lưu ý tương tự về hiệu suất vượt trội của các mô hình ML so với các chuẩn mực đơn biến để dự báo lạm phát tại Hoa Kỳ, chẳng hạn như bước đi ngẫu nhiên và AR (Medeiros và cộng sự, 2021). Họ thấy rằng hiệu suất sử dụng các phương pháp ML có thể tốt hơn tới 30% về mặt lỗi bình phương trung bình. Họ cũng đặc biệt chú ý đến mô hình rừng ngẫu nhiên (Random Forest) phi tuyến tính, cung cấp kết quả chính xác hơn các thuật toán ML khác như Lasso, Lasso thích ứng và hồi quy Ridge. Barkan và cộng sự (2023) cải thiện dự báo của Hoa Kỳ bằng cách sử dụng các chỉ số phân tách tạo nên CPI. Họ sử dụng các mô hình AR và VAR làm chuẩn mực chuỗi thời gian và kiểm tra hiệu suất của các

mô hình ML như KNN và các phương pháp tiếp cận mạng nơ-ron. Kết quả chứng minh tính ưu việt của mô hình mạng nơ-ron, đặc biệt là ở các cấp độ thấp của hệ thống phân cấp CPI (Barkan và cộng sự, 2023). Những nghiên cứu này không chỉ khẳng định khả năng của các mô hình học máy trong dự báo lạm phát mà còn mở ra hướng đi mới trong việc áp dụng các công nghệ tiên tiến trong phân tích kinh tế.

Mô hình DL sử dụng mạng nơ-ron với nhiều lớp, cho phép nó học từ những dữ liệu phức tạp và biến đổi theo thời gian. Điều này giúp mô hình nắm bắt các mối quan hệ phi tuyến tính giữa các yếu tố kinh tế như giá cả, lãi suất và biến động thị trường. Nghiên cứu dự báo lạm phát bằng các mô hình học sâu, đặc biệt là LSTM và các kiến trúc học sâu khác, đã ngày càng thu hút sự quan tâm trong cộng đồng nghiên cứu. Một nghiên cứu nổi bật của Zhang và cộng sự (2022) đã áp dụng mô hình LSTM để dự đoán GDP ở Trung Quốc, cho thấy rằng LSTM có khả năng xử lý dữ liệu chuỗi thời gian và nắm bắt được các mối quan hệ phi tuyến tính, từ đó cải thiện độ chính xác dự báo so với các phương pháp truyền thống. Tương tự, Siami-Namini và cộng sự (2018) và Ülke và cộng sự (2018) đã so sánh thực nghiệm các kỹ thuật học máy với các phương pháp truyền thống để dự báo lạm phát trong bối cảnh các yếu tố kinh tế vĩ mô phức tạp và chứng minh rằng mô hình này có thể thích ứng tốt với biến động kinh tế và cung cấp những dự báo chính xác hơn. Lê Thị Thanh Xuân và cộng sự (2021) cũng đã chứng minh rằng mô hình LSTM có khả năng dự báo ưu việt hơn so với mô hình ANN để dự báo lạm phát hàng tháng tại Việt Nam.

Mặc dù các mô hình học máy và học sâu đã mang lại những tiến bộ đáng kể trong việc dự báo lạm phát, nhưng chúng cũng gặp phải một số hạn chế, đặc biệt là trong việc xử lý dữ liệu có độ phức tạp cao. Những mô hình này có thể dễ bị quá khớp khi dữ liệu không đủ đại diện, dẫn đến hiệu suất kém trong các tình huống thực tế. Kỹ thuật điều chuẩn Lasso giúp giảm quá khớp, chọn biến và cải thiện khả năng khái quát hóa (Tibshirani, 1996). Nhiều nghiên cứu chỉ ra rằng Lasso giảm độ phức tạp mà vẫn giữ hiệu suất, đặc biệt trong dự báo kinh tế với dữ liệu chuỗi thời gian biến động (Tao & Zhang, 2016; Zou, 2006). Do

đó, việc tích hợp Lasso vào dự báo lạm phát kiểm tra khả năng cải thiện hiệu suất thông qua việc giảm độ phức tạp mà vẫn duy trì độ chính xác. Nghiên cứu dự báo lạm phát bằng mô hình Lasso đã được áp dụng trong nhiều bối cảnh và cho thấy hiệu quả trong việc lựa chọn biến và tối ưu hóa dự báo. Medeiros và cộng sự (2016) sử dụng hồi quy Lasso để dự báo lạm phát ở Brazil. Họ cũng sử dụng các mô hình tự hồi quy tuyến tính và mô hình nhân tố dựa trên các thành phần chính làm thông số kỹ thuật chuẩn. Kết quả của họ chỉ ra rằng kết quả Lasso chính xác hơn thông số kỹ thuật chuẩn trong dự báo ngắn hạn. Lasso giúp loại bỏ các biến không cần thiết, từ đó nâng cao độ chính xác của dự báo so với các mô hình hồi quy truyền thống. Baybuza (2018) cũng thu được những phát hiện tương tự đối với dự báo lạm phát của Nga. Tác giả so sánh dự báo lạm phát của Nga theo các phương pháp chuỗi thời gian khác nhau với kết quả của các thuật toán ML như hồi quy Lasso và Ridge, mô hình lưới đàn hồi và mô hình rừng ngẫu nhiên và cho thấy các phương pháp ML có thể cải thiện chất lượng dự báo lạm phát của Nga so với các mô hình chuỗi thời gian đơn biến (Baybuza, 2018). Özgür & Akkoç (2022) cố gắng dự báo lạm phát ở Thổ Nhĩ Kỳ bằng các kỹ thuật ML và so sánh kết quả của chúng với một số mô hình chuẩn chuỗi thời gian. Các thuật toán mà họ sử dụng là Ridge regression, Lasso regression và các thuật toán elastic net. Họ tuyên bố rằng các phương pháp co rút như Lasso và các thuật toán elastic net hoạt động tốt hơn các phương pháp kinh tế lượng thông thường (Özgür & Akkoç, 2022). Những nghiên cứu này cho thấy mô hình Lasso là một công cụ hữu ích trong việc dự báo lạm phát, nhận mạnh vai trò của nó trong việc chọn lọc biến và cải thiện độ chính xác dự báo.

2.3. Các nghiên cứu dự báo lạm phát tại Việt Nam

Nghiên cứu dự báo lạm phát ở Việt Nam đã thu hút nhiều sự quan tâm từ các nhà nghiên cứu trong và ngoài nước, với nhiều phương pháp khác nhau được áp dụng. Một nghiên cứu của Vương (2011) đã sử dụng mô hình ARIMA để dự đoán lạm phát tại Việt Nam, kết quả cho thấy mô hình này có thể nắm bắt được các xu hướng ngắn hạn của chỉ số giá tiêu dùng, mặc dù vẫn còn hạn chế

trong việc phản ứng với các cú sốc kinh tế. Nguyễn Khắc Hiếu và Nguyễn Thị Anh Vân (2015) chứng minh mô hình mạng thần kinh nhân tạo (ANN) vượt trội hơn mô hình ARDL trong việc dự báo lạm phát tại Việt Nam, đồng thời chỉ ra rằng nhiều yếu tố như tâm lý người tiêu dùng, giá dầu, cung tiền và lãi suất có ảnh hưởng đến lạm phát, từ đó khẳng định ANN là công cụ hiệu quả cho các nhà hoạch định chính sách và nhà đầu tư trong việc dự báo các biến số kinh tế. Ngoài ra, nghiên cứu của Phước Tran & Anh Hoang Le (2024) đã cung cấp so sánh về độ chính xác dự đoán giữa các thuật toán học máy (KNN và perceptron nhiều lớp (MLP) và các mô hình dự báo truyền thống như VAR và LASSO. Kết quả thực nghiệm cho thấy, các mô hình dự báo lạm phát theo mô hình MLP là chính xác nhất vì nó có thể mô tả các mối quan hệ phi tuyến tính giữa các biến trong mô hình và lập bản đồ trực quan. Những nghiên cứu này không chỉ đóng góp vào kho tàng tri thức về dự báo lạm phát ở Việt Nam mà còn chỉ ra những thách thức và cơ hội trong việc áp dụng các phương pháp hiện đại.

3. Phương pháp nghiên cứu

3.1. Dữ liệu

Để dự báo lạm phát Việt Nam, dựa theo các nghiên cứu trước đây, chúng tôi bao gồm các biến nghiên cứu sau: “Lãi suất bình quân liên ngân hàng” (IIR), “Cung tiền” (M2), “Chỉ số sản xuất công nghiệp” (IIP), “Tỷ giá” (ER), “Tín dụng trong nước” (CREDIT) và “Sự thay đổi chỉ số giá tiêu dùng so với tháng trước” để đo lường Lạm phát của Việt Nam (LP).

Việc lựa chọn các biến số trong mô hình dự báo lạm phát tại Việt Nam dựa trên cơ sở lý thuyết kinh tế và thực tiễn nghiên cứu trước đây. Những biến này đã được chứng minh là có ảnh hưởng đáng kể đến lạm phát trong các mô hình dự báo và phân tích kinh tế vĩ mô. Thứ nhất, lãi suất bình quân liên ngân hàng được sử dụng để đại diện cho chính sách tiền tệ và chi phí vốn trong nền kinh tế. Lãi suất ảnh hưởng trực tiếp đến chi phí vay mượn, tiêu dùng và đầu tư, từ đó tác động đến giá cả hàng hóa và dịch vụ. Thứ hai, cung tiền là một trong những yếu tố quan trọng ảnh hưởng đến lạm phát theo lý thuyết số lượng tiền tệ. Khi lượng tiền trong nền kinh tế tăng, nhu cầu tiêu dùng và đầu tư cũng gia tăng, có thể tạo áp lực lên giá cả. M2 bao gồm tiền mặt lưu thông và

tiền gửi, là thước đo quan trọng của cung tiền. Thứ ba, chỉ số sản xuất công nghiệp được sử dụng để đại diện cho hoạt động kinh tế thực, phản ánh mức độ sản xuất và cung ứng hàng hóa trong nền kinh tế. Khi sản xuất gia tăng, nguồn cung hàng hóa dồi dào hơn có thể giúp kiềm chế lạm phát, trong khi sự suy giảm sản xuất có thể gây ra tình trạng thiếu hụt, đẩy giá cả lên cao. Thứ tư, tỷ giá hối đoái đóng vai trò quan trọng trong việc tác động đến giá cả hàng hóa nhập khẩu và cạnh tranh quốc tế. Khi đồng VND mất giá, chi phí nhập khẩu tăng lên, làm gia tăng lạm phát thông qua kênh giá cả hàng hóa nhập khẩu. Lý thuyết và thực nghiệm đều chỉ ra rằng tỷ giá có tác động đáng kể đến lạm phát ở các nền kinh tế mở như Việt Nam. Các nghiên cứu thực nghiệm cho thấy sự mất giá của VND có thể làm gia tăng lạm phát, đặc biệt là trong bối cảnh nền kinh tế phụ thuộc nhiều vào nhập khẩu nguyên liệu. Cuối cùng, tín dụng trong nước phản ánh mức độ cho vay của hệ thống ngân hàng đối với nền kinh tế. Tín dụng tăng cao có thể thúc đẩy tiêu dùng và đầu tư, từ đó gây áp lực lên giá cả và làm gia tăng lạm phát.

Dữ liệu được thu thập liên tục và xuyên suốt hàng tháng từ năm 2009 đến 2023. Dữ liệu được thu thập từ cơ sở dữ liệu của World Bank, IMF và Tổng cục thống kê.


Hình 1 minh họa diễn biến lạm phát của Việt Nam trong giai đoạn nghiên cứu. Trong đó, lạm phát cao diễn ra trong giai đoạn 2009-2012 do tác động của cuộc khủng hoảng tài chính toàn cầu năm 2008. Tuy nhiên, nhờ những chính sách kiểm soát của Chính phủ, lạm phát đã duy trì ở mức ổn định dưới 5% trong giai đoạn từ 2013 đến nay.

3.2. Mô hình dự báo

3.2.1. Mô hình ARIMA

ARIMA (Autoregressive Integrated Moving Average) là một mô hình thống kê phổ biến, là phiên bản nâng cao hơn của ARMA kết hợp các quy trình AR và MA để tạo thành một mô hình tổng hợp. ARIMA được xây dựng với 3 thành phần chính: tự hồi quy (AR), tính dừng của chuỗi (I) và trung bình trượt (MA), được ký hiệu bởi ARIMA(p,d,q), trong đó:

- p là bậc của phân tự hồi quy (AR - Autoregressive),
- d là số lần vi phân cần thiết để biến chuỗi thời gian thành chuỗi dừng (Integrated),



(Nguồn: Tác giả)

Hình 1: Diễn biến lạm phát Việt Nam theo thời gian từ năm 2009 đến năm 2023

- q là bậc của phân trung bình trượt (MA - Moving Average).

Phương trình tổng quát của mô hình ARIMA có dạng:

$$Y_t = a_0 + \sum_{i=1}^p a_i Y_{t-i} + \sum_{i=1}^q \beta_i \varepsilon_{t-i} + \varepsilon_t \quad (1)$$

Trong đó: Y_t là giá trị của biến dự báo tại thời điểm t , ε_t là nhiễu ngẫu nhiên tại thời điểm t , a_0 là hằng số, a_i là hệ số của phân tự hồi quy và β_i là hệ số của phân trung bình trượt.

Để áp dụng mô hình ARIMA trong dự báo lạm phát, các bước sau đây được thực hiện:

Bước 1: Thu thập và Chuẩn bị Dữ liệu

Dữ liệu chuỗi thời gian về các yếu tố ảnh hưởng đến lạm phát (như tỷ lệ lạm phát được đo lường bởi sự thay đổi chỉ số giá tiêu dùng so với kỳ trước, cung tiền, GDP, lãi suất, tín dụng...) được thu thập từ các nguồn đáng tin cậy bao gồm WB, IMF, Tổng cục thống kê. Dữ liệu sau đó được kiểm tra và điền khuyết các giá trị còn thiếu, loại bỏ ngoại lai để đảm bảo dữ liệu ổn định cho nghiên cứu. Dữ liệu sau đó được chia thành tập huấn luyện và tập kiểm tra theo tỷ lệ 80:20.

Bước 2: Kiểm tra tính dừng của chuỗi thời gian

Trước tiên, chuỗi thời gian của tỷ lệ lạm phát (LP) và các biến giải thích được kiểm tra tính dừng bằng các kiểm định Augmented Dickey-Fuller (ADF) và Phillips-Perron (PP). Nếu chuỗi không dừng, sai phân sẽ được áp dụng để biến chuỗi thành chuỗi dừng.

Bước 3: Xác định bậc của mô hình ARIMA

Dựa vào biểu đồ tự tương quan (ACF) và tự tương quan từng phần (PACF), các giá trị thích hợp cho p , d , và q được ước lượng. ACF và PACF giúp xác định cấu trúc bậc của mô hình bằng cách quan sát sự suy giảm của các hệ số tự tương quan qua các độ trễ. Nhóm tác giả xác định giá trị tối đa của p , d và q lần lượt là 5, 1 và 5.

Bước 4: Ước lượng tham số và xây dựng mô hình

Mô hình ARIMA với các bậc tối đã xác định được ước lượng thông qua phương pháp bình phương nhỏ nhất (OLS). Sau đó, tiêu chí AIC (Akaike Information Criterion) và thời gian huấn luyện mô hình được sử dụng để đánh giá và chọn mô hình tối ưu. Mô hình ARIMA tốt nhất là ARIMA (1,1,1) với AICmin = 333.127 và thời gian huấn luyện tối thiểu là 12,140 giây.

Bước 5: Kiểm định mô hình

Để kiểm tra tính phù hợp của mô hình, kiểm định Ljung-Box và phân tích phần dư được thực hiện nhằm xác nhận rằng phần dư không còn tính tự tương quan, đảm bảo rằng mô hình đã mô tả đầy đủ các đặc tính của chuỗi thời gian.

Bước 6: Dự báo và đánh giá

Với mô hình ARIMA đã tối ưu, dự báo được thực hiện cho các giai đoạn tiếp theo. Độ chính xác của mô hình dự báo được đánh giá bằng cách so sánh giá trị dự báo với giá trị thực tế.

3.2.2. Mô hình ANN

Mạng nơ-ron nhân tạo (ANN) là một thuật toán được thiết kế dựa trên cấu trúc và chức năng của não bộ con người. Chúng gồm các “nơ-ron” liên kết với nhau để xử lý và truyền tải thông tin. Mỗi nơ-ron sẽ nhận được dữ liệu đầu vào từ các nơ-ron khác, sau đó nó sẽ áp dụng một hàm toán học lên các dữ liệu này để tạo ra kết quả đầu ra. Và kết quả này sẽ được gửi đến các nơ-ron khác trong lớp kế tiếp. Để thực hiện các nhiệm vụ dự báo, kiến trúc Multilayer Perceptron (MLP) đã được thi hành. MLP là một mạng truyền thẳng có giám sát, gồm ba lớp: lớp đầu vào, lớp ẩn và lớp đầu ra.

Lớp đầu vào của một mạng nơ-ron bao gồm một hoặc nhiều biến số đầu vào, cung cấp thông tin cần thiết cho quá trình xử lý. Trong việc dự đoán lạm phát, các biến này có thể bao gồm: tăng trưởng thực tế của tỷ giá hối đoái, lượng cung tiền M2, chỉ số sản xuất công nghiệp... cùng với các số liệu lịch sử liên quan đến lạm phát. Lớp đầu ra có thể bao gồm một hoặc nhiều biến số đầu ra; trong nghiên cứu này, lớp đầu ra được xác định là tỷ lệ lạm phát (LP). Mối quan hệ giữa các yếu tố đầu vào và đầu ra được tính toán thông qua các lớp ẩn trung gian, sử dụng một hệ thống các hàm kích hoạt và ngưỡng.

Trong đó, có hai hàm kích hoạt được sử dụng phổ biến trong mạng nơ-ron nhân tạo là hàm sigmoid (PT. 1) và hàm ReLU (PT. 2)


trong các mạng neuron nhân tạo. Hàm này nhận đầu vào với bất kỳ giá trị thực nào và trả về đầu ra nằm trong khoảng (0,1). Với tính chất này, hàm sigmoid thường được dùng để chuyển đổi giá trị thực thành xác suất. Khi đầu vào là một giá trị âm lớn, đầu ra của hàm sigmoid tiến dần về 0; ngược lại, với đầu vào là giá trị dương lớn, đầu ra sẽ tiến gần đến 1. Nếu đầu vào bằng 0, giá trị hàm sigmoid sẽ là 0,5. Do đó, giá trị đầu vào bằng 0 thường được coi là ranh giới cho bài toán phân loại nhị phân. Tuy nhiên, một nhược điểm của hàm sigmoid là dễ bị bão hòa khi giá trị đầu vào trở nên quá lớn hoặc quá nhỏ, dẫn đến đạo hàm gần như bị triệt tiêu, làm giảm tốc độ tính toán và gây khó khăn cho việc lan truyền ngược. Nghiên cứu gần đây cho thấy, hàm kích hoạt ReLU có khả năng khắc phục vấn đề triệt tiêu đạo hàm, giúp tăng tốc độ tính toán và cải thiện hiệu suất mô hình, vì đầu ra của hàm ReLU vẫn là giá trị dương khi đầu vào lớn hơn 0.

Quy trình dự báo bằng ANN được tiến hành như sau:

Bước 1: Chuẩn bị dữ liệu

Dữ liệu đã được làm sạch trước khi áp dụng ARIMA tiếp tục được chuẩn hóa bằng phương pháp MinMax nhằm giúp tăng độ chính xác và tốc độ hội tụ của mô hình của các mô hình học máy và học sâu.

Nhóm tác giả sử dụng quy trình chuẩn hóa MinMax, theo đó, các biến được đưa về một khoảng giá trị nhất định, thường là từ 0 đến 1



(Nguồn: *Neural Networks in Finance gaining predictive edge in the market* của Paul D. Mc Nelis)

Hình 2: Cấu trúc ANN

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$R(x) = \max(0, x) \quad (3)$$

Hàm sigmoid là một hàm kích hoạt phi tuyến tính, thường được sử dụng rộng rãi

hoặc từ -1 đến 1. Công thức chuẩn hóa MinMax được định nghĩa như sau:

$$x_{i,norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (4)$$

Trong đó:

Ý KIẾN TRAO ĐỔI

x_i là giá trị gốc của dữ liệu cần chuẩn hóa, $x_{\max}$ và $x_{\min}$ lần lượt là giá trị lớn nhất và nhỏ nhất trong tập dữ liệu,

$x_{i, \text{norm}}$ là giá trị đã được chuẩn hóa.

Sau đó, dữ liệu ban đầu được chia thành tập huấn luyện và tập kiểm tra theo tỷ lệ 80:20.

Bước 2: Xây dựng và huấn luyện mô hình ANN

Trong nghiên cứu của nhóm tác giả, mô hình ANN được xây dựng bao gồm hai tầng ẩn với số lượng nơ ron lần lượt là 64 và 32. Lý do chọn hai tầng ẩn là để đảm bảo mô hình có đủ khả năng học được các đặc trưng phức tạp của dữ liệu mà không bị quá phức tạp, tránh hiện tượng quá khớp (overfitting). Số lượng nơ ron giảm dần từ 64 xuống 32 nhằm giúp mô hình tổng quát hóa tốt hơn, thay vì giữ nguyên hoặc tăng số lượng nơ ron có thể làm tăng độ phức tạp không cần thiết. Hàm kích hoạt ReLU (Rectified Linear Unit) được sử dụng để đảm bảo tính phi tuyến trong các tầng ẩn, giúp mạng học được các mối quan hệ phi tuyến giữa các biến đầu vào và đầu ra. Tầng đầu ra của mô hình có một nơ ron duy nhất, được thiết kế để dự báo giá trị lạm phát (LP) liên tục và không sử dụng hàm kích hoạt nhằm đảm bảo đầu ra là một giá trị thực. Thuật toán tối ưu Adam được sử dụng trong quá trình huấn luyện để tự động điều chỉnh tốc độ học, giúp cải thiện hiệu quả hội tụ và tối ưu hóa các tham số trong mô hình. Adam có tốc độ học mặc định là 0.001, giúp ổn định quá trình học. Mô hình được huấn luyện trong 50 epoch với kích thước lô (batch size) là 32, đảm bảo tính ổn định và độ bao quát của quá trình huấn luyện. Tổng số trọng số trong mô hình là 5,249 tham số, bao gồm 3,136 trọng số trong tầng đầu tiên, 2,080 trọng số tầng thứ hai và 33 trọng số tầng đầu ra. Cuối cùng, hàm mất mát

mean squared error được chọn cho bài toán hồi quy này, nhằm tối thiểu hóa sai số bình phương trung bình giữa giá trị dự báo và giá trị lạm phát thực tế, giúp mô hình đạt được độ chính xác tốt hơn trong dự báo lạm phát.

Bước 3: Đánh giá và hiệu chỉnh mô hình

Nhóm tác giả sử dụng chỉ số RMSE để đánh giá độ chính xác của mô hình dự báo trên tập kiểm tra. Sau đó, nhóm tác giả thực hiện tối ưu hóa siêu tham số (hyperparameter tuning) để tìm cấu hình tốt nhất của mô hình ANN.


Sau khi đạt được mô hình tối ưu, sử dụng mô hình ANN để dự báo lạm phát cho các thời kỳ tương lai dựa trên dữ liệu đầu vào mới.

3.2.3. Mô hình LSTM

Mô hình LSTM là một loại chương trình máy tính dùng để phân tích những dữ liệu có xu hướng dài hạn. Là một bản hoàn thiện hơn của mô hình Mạng thần kinh hồi quy (RNN-Recurrent Neural Network), nó đã khắc phục được vấn đề biến mất độ dốc và phụ thuộc xa của mô hình RNN. Mô hình LSTM có cấu trúc dạng chuỗi các nút mạng giống như RNN nhưng lại phức tạp hơn. Nó gồm 4 tầng tương tác với nhau một cách đặc biệt là: Cell state, Forget gate, Input gate và Output gate.

Điểm đặc biệt của mô hình LSTM nằm ở chỗ trạng thái ô C (Cell state) là nơi lưu trữ các trọng số dài hạn của mô hình. Cổng quên (Forget gate) sẽ lọc những thông tin bị bỏ quên từ trạng thái trước như thông tin được lấy từ đầu vào tại thời điểm t , các thông số trạng thái ô C và trạng thái ẩn (hidden state) h_{t-1} . Các thông tin trên sẽ được xử lý qua hàm kích hoạt sigmoid σ , $\tanh$ và các phép toán véc-tơ, đưa về giá trị (0,1).

$$f_t = \sigma(U_f \times x_t + W_f \times h_{t-1} + b_f) \quad (5)$$



(Nguồn: Nhóm tác giả)

Hình 3: Mô tả mô hình LSTM

Kết quả đầu ra là trạng thái ô C và trạng thái ẩn h tại thời điểm t, chúng sẽ được lưu trữ và sử dụng ở nút mạng t + 1 tiếp theo. Một véc tơ C_t mới được hàm kích hoạt *tanh* tạo ra có giá trị (-1;1) để thêm vào trạng thái.

$$i_t = \sigma(U_i \times x_t + W_i \times h_{t-1} + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(U_c \times x_t + W_c \times h_t + b_c) \quad (7)$$

Sau đó, các thông tin $f_t * C_{t-1}$ bị bỏ qua ở ô trước đó sẽ được cập nhật vào ô mới C_t (cell state) rồi tiếp tục được cập nhật ở đầu ra $i_t * C_t$.

$$C_t = \sigma(f_t \times C_{t-1} + i_t \times \tilde{C}_t) \quad (8)$$

Bằng cách sử dụng giá trị trả về của hàm kích hoạt sigmoid σ , các thông tin đầu ra của trạng thái hiện tại được xác định ở công output, từ đó quyết định được số lượng thông tin trạng thái sẽ xuất. Kết quả được xuất thành đầu ra cho trạng thái ẩn (hidden state).

$$o_t = \sigma(U_o \times x_t + W_o \times h_{t-1} + b_o) \quad (9)$$

$$h_t = \tanh(C_t) \times o_t \quad (10)$$

Từ nguyên lý hoạt động trên, mô hình LSTM thích hợp hơn để phân tích dữ liệu là chuỗi thời gian hay dự báo chuỗi thời gian trong dài hạn. Vì LSTM có khả năng truy vấn được thông tin từ một tập hợp thông tin lớn hơn.

Quy trình dự báo lạm phát với LSTM như sau:

Bước 1: Chuẩn bị dữ liệu

Dữ liệu chuỗi thời gian của các biến đầu vào như tỷ lệ lạm phát (LP), cung tiền, GDP, lãi suất và tín dụng được thu thập và làm sạch. Dữ liệu này sau đó được chuẩn hóa để giảm thiểu ảnh hưởng của các giá trị lớn, tăng độ ổn định cho mô hình LSTM. Nhóm tác giả sử dụng quy trình chuẩn hoá MinMax tương tự phương pháp ANN ở trên.

Dữ liệu sau đó được chia thành hai tập: tập huấn luyện và tập kiểm tra, theo tỷ lệ 80:20. Tập huấn luyện được sử dụng để học các mẫu, trong khi tập kiểm tra giúp đánh giá hiệu suất của mô hình.

Bước 2: Xây dựng và huấn luyện mô hình LSTM

Coi mỗi giá trị của bộ dữ liệu là một bước thời gian và sử dụng 12 bước thời gian để xây dựng các lớp của mô hình LSTM. Mô hình LSTM được xây dựng với các tầng LSTM nối tiếp với 02 tầng dày (dense layers) chứa 50

neuron và hàm kích hoạt ReLU để cân bằng giữa khả năng ghi nhớ các chuỗi dữ liệu dài và tránh quá tải tính toán. Số lượng đơn vị LSTM, số tầng và các tham số như batch size và số epoch được điều chỉnh thông qua quá trình tối ưu hóa để tăng độ chính xác. Batch size của mô hình bằng 32 và số epoch bằng 50. Lớp đầu ra là Dense với một neuron để dự đoán giá trị đầu ra.

Hàm mất mát Mean Squared Error (MSE) và thuật toán tối ưu hóa Adam được sử dụng để cập nhật trọng số và giảm thiểu sai số dự báo. Tổng cộng, mô hình có 11.051 tham số có thể điều chỉnh.

Bước 3: Dự báo và đánh giá kết quả

Sau khi huấn luyện, mô hình LSTM được sử dụng để dự báo lạm phát trên tập kiểm tra. Độ chính xác của dự báo được đánh giá qua chỉ số như RMSE (Root Mean Squared Error), giúp xác định khả năng dự báo của mô hình trên dữ liệu thực tế.

3.2.4. Mô hình Lasso (Least Absolute Shrinkage and Selection Operator)

Toán tử chọn lọc và co ngót tuyệt đối tối thiểu hay còn gọi là mô hình hồi quy Lasso, là hình thức chính quy hóa cho các mô hình hồi quy tuyến tính. Lasso là một kỹ thuật hồi quy lựa chọn biến chủ động, hoạt động trên nguyên tắc áp dụng hàm phạt (penalty function), trong quá trình tối ưu hóa các quan sát, tự động loại các biến không có nghĩa dự báo ra khỏi mô hình bằng cách đưa hệ số hồi quy của các biến đó về 0.

Lasso đã cải thiện mô hình hồi quy bình phương nhỏ nhất thông thường (OLS) thông qua việc loại bỏ tổng giá trị tuyệt đối của các hệ số nhỏ hơn một hằng số. Hồi quy Lasso phát triển từ việc xem xét N quan sát của biến phụ thuộc y_i và p biến giải thích $x_i = (x_{i1}, \dots, x_{ip})$. Trong đó, x_i và y_i tương ứng thuộc R^p và R . Kết quả của biến phụ thuộc dựa trên các biến giải thích sẽ được dự đoán bằng cách sử dụng mô hình hồi quy tuyến tính sau:

$$f(x) = \beta_0 + \sum_{j=1}^p x_{ij} \beta_j \quad (11)$$

Ước lượng OLS với cặp (β_0, β) dựa trên việc tối thiểu hóa bình phương sai số:

$$\begin{aligned} \underset{\beta_0, \beta}{\text{minimize}} \left\{ \frac{1}{N} \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 \right\} \\ = \frac{1}{N} \|y - \beta_0 \mathbf{1} - X\beta\|^2 \quad (12) \end{aligned}$$

Ý KIẾN TRAO ĐỔI

Việc sửa đổi mô hình OLS thành mô hình hồi quy Lasso được thực hiện:

$$\underset{\beta_0, \beta}{\text{minimize}} \left\{ \frac{1}{N} \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p \beta_j \right\} \\ = \frac{1}{N} \|y - \beta_0 \mathbf{1} - X\beta\|^2 + \lambda \|\beta\| \quad (13)$$

Việc chọn giá trị tối ưu của Lambda (λ) là vấn đề chính trong mô hình hồi quy Lasso. Lambda (λ) là một tham số chính sử dụng xác thực chéo để xác định. Lasso là một kỹ thuật thường được áp dụng trong học máy để xử lý dữ liệu chiều cao, nhờ vào khả năng tự động lựa chọn tính năng. Phương pháp này thực hiện điều này bằng cách thêm một điều khoản phạt vào tổng bình phương sai số (RSS), được nhân với tham số điều chỉnh (λ). Tham số chính quy hóa này quyết định mức độ chính quy hóa được áp dụng. Khi giá trị của λ lớn hơn, mức phạt cũng tăng lên, dẫn đến việc nhiều hệ số bị thu hẹp, nhiều giá trị về số 0 hơn. Hệ quả là, một số tính năng có thể bị giảm tầm quan trọng hoặc bị loại bỏ hoàn toàn khỏi mô hình, từ đó thực hiện lựa chọn tính năng tự động một cách hiệu quả. Sử dụng mô hình Lasso giúp phát hiện và chọn lọc các yếu tố kinh tế chính có ảnh hưởng đến lạm phát, từ đó cung cấp cho các nhà hoạch định chính sách cơ sở dựa trên dữ liệu cho việc xây dựng các biện pháp kiểm soát lạm phát một cách hiệu quả và kịp thời. Do đó, phương pháp dự báo bằng Lasso không chỉ giúp cải thiện độ chính xác của dự báo mà còn hỗ trợ phân tích các yếu tố quyết định lạm phát, giúp tối ưu hóa các chính sách kinh tế phù hợp.

Quy trình dự báo lạm phát với Lasso được thực hiện như sau:

Bước 1: Chuẩn bị dữ liệu

Dữ liệu chuỗi thời gian của các biến đầu vào (bao gồm Tỷ lệ lạm phát, cung tiền, GDP, tín dụng, v.v.) được thu thập và làm sạch để đảm bảo tính đồng nhất và chất lượng. Chuỗi thời gian này bao gồm các biến liên quan đến lạm phát và các yếu tố kinh tế khác.

Bước 2: Phân chia tập dữ liệu

Tập dữ liệu được chia thành hai phần: tập huấn luyện (training set) và tập kiểm tra (test set) trong tỷ lệ 80:20. Tập huấn luyện được sử dụng để ước lượng các tham số mô hình, trong khi tập kiểm tra giúp đánh giá độ chính xác của mô hình.

Bước 3: Điều chỉnh tham số λ

Tham số λ trong Lasso điều khiển mức độ thu gọn. Giá trị tối ưu của λ được xác định bằng phương pháp cross-validation (k-fold cross-validation), giúp tránh hiện tượng quá khớp và đảm bảo mô hình đạt độ chính xác cao nhất. Giá trị λ được lựa chọn là 0.1.

Bước 4: Ước lượng mô hình Lasso

Mô hình Lasso hồi quy được ước lượng bằng cách sử dụng các biến độc lập từ tập huấn luyện, sau đó điều chỉnh hệ số của từng biến sao cho hàm mất mát đạt giá trị tối thiểu. Các biến không quan trọng sẽ bị loại bỏ khi hệ số của chúng bị thu nhỏ về 0, giúp mô hình trở nên đơn giản và tập trung vào các yếu tố ảnh hưởng mạnh nhất đến lạm phát.

Bước 5: Dự báo và đánh giá

Với mô hình Lasso tối ưu, dự báo lạm phát được thực hiện trên tập kiểm tra. Độ chính xác của dự báo được đánh giá bằng chỉ số sai số MSE (Mean Squared Error) và hệ số xác định R^2 để xác định khả năng dự báo của mô hình.

3.3. Một số chỉ số đánh giá chất lượng dự báo

3.3.1. Sai số bình phương trung bình - MSE (Mean Squared Error)

MSE đo lường mức độ sai lệch trung bình giữa giá trị dự báo và giá trị thực tế, thông qua việc tính trung bình của bình phương sai số.

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (14)$$

Chỉ số MSE càng nhỏ thì mô hình dự báo càng chính xác, vì sai lệch giữa giá trị dự báo và thực tế nhỏ hơn.

3.3.2. Căn bậc hai của sai số bình phương trung bình - RMSE (Root Mean Squared Error)

RMSE là căn bậc hai của MSE và được sử dụng để đo độ chính xác của mô hình dự báo theo cùng đơn vị với biến dự báo. Công thức tính:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (15)$$

RMSE dễ hiểu hơn MSE do kết quả nằm trên cùng thang đo với dữ liệu gốc. RMSE càng nhỏ thì dự báo càng chính xác.

3.3.3. Hệ số xác định - R^2 (R-squared)

R^2 cho biết tỷ lệ biến động của giá trị thực tế được giải thích bởi mô hình dự báo. Công thức tính:

$$R^2 = 1 - \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (16)$$

Trong đó, Y_t là giá trị thực tế, $\hat{Y}_t$ là giá trị mà mô hình dự báo (dựa trên các biến độc lập) và $\bar{Y}_t$ là giá trị trung bình của biến mục tiêu trong tập dữ liệu.

Giá trị R^2 nằm trong khoảng từ 0 đến 1. Khi R^2 gần 1, mô hình có khả năng giải thích cao hơn về biến động của dữ liệu, tức là mô hình dự báo tốt hơn.

4. Kết quả và đánh giá

4.1. Kết quả dự báo theo mô hình ARIMA

Hình 4 thể hiện các giá trị dự báo theo xu hướng so với các giá trị thực tế bằng mô hình ARIMA. Mặc dù mô hình ARIMA được lựa chọn phù hợp cho dữ liệu huấn luyện, dự báo lam phát trên tập test vẫn cho thấy sự chênh lệch đáng kể so với giá trị thực tế. Điều này có thể xuất phát từ một số lý do chính. Đầu tiên, ARIMA là mô hình tuyến tính, giả định rằng các mẫu quan hệ trong dữ liệu ổn định theo thời gian. Tuy nhiên, tỷ lệ lam phát thường chịu ảnh hưởng của các yếu tố phi tuyến và các cú sốc ngắn hạn, chẳng hạn như biến động giá năng lượng hoặc thay đổi chính sách, mà ARIMA khó có thể nắm bắt đầy đủ. Thêm vào đó, lam phát dễ bị biến động bởi các yếu tố thời vụ và những thay đổi cung - cầu, làm giảm độ chính xác khi dự báo ngắn hạn. ARIMA còn phụ thuộc chủ yếu vào dữ liệu quá khứ và không tính đến các yếu tố ngoại sinh, chẳng hạn như chính sách tiền tệ hoặc tình hình kinh tế toàn cầu, vốn tác động mạnh đến lam phát và có thể dẫn đến sai lệch lớn khi thị trường có biến động mạnh. Những hạn chế này cho thấy rằng, tính chính xác trong dự báo lam phát ở Việt Nam bởi mô hình truyền thống là thấp và khó có thể áp dụng trên thực tế, do đó, để dự báo lam phát hiệu quả trong bối cảnh kinh tế có biến động,

cần kết hợp với các mô hình phi tuyến hoặc mô hình học sâu như ANN hoặc LSTM để cải thiện độ chính xác.

4.2. Kết quả dự báo theo mô hình ANN


Với các thông số được thiết lập tối ưu như được trình bày ở phần phương pháp, nhóm tác giả thực hiện dự báo giá trị tỷ lệ lam phát bằng cách sử dụng mô hình ANN. Sau khi dự đoán được giá trị của tập huấn luyện và tập kiểm tra, nhóm tác giả đã chuyển đổi các dự đoán này về dạng gốc để so sánh với giá trị thực tế. Kết quả dự đoán cho tập huấn luyện và tập kiểm tra đã được tính toán và sẵn sàng để đánh giá mô hình.

Nhóm tác giả sử dụng chỉ số RMSE (Root Mean Squared Error) để đánh giá độ chính xác của mô hình trên tập huấn luyện. Giá trị RMSE được báo cáo là 0,8513, cho thấy mô hình có độ chính xác tốt trên tập huấn luyện.

Để hình dung rõ hơn về hiệu suất của mô hình, chúng ta sẽ vẽ biểu đồ so sánh giữa giá thực tế và giá dự đoán của mô hình trên tập kiểm tra. Mặc dù bám sát xu hướng thực tế, đường dự đoán có dao động nhiều hơn so với đường giá trị thực tế, đặc biệt là ở những giai đoạn biến động mạnh của lam phát. Đồng thời khoảng cách giữa giá trị dự đoán và giá trị thực tế khá lớn. Điều này cho thấy mô hình chưa đủ ổn định để đưa ra dự báo chính xác và đáng tin cậy.


4.3. Kết quả dự báo theo mô hình LSTM

Mô hình LSTM được xây dựng với hai lớp LSTM, mỗi lớp chứa 50 nơ-ron và hàm kích hoạt ReLU. Lớp đầu ra là Dense với một nơ-ron để dự đoán giá trị đầu ra. Mô hình được biên dịch với trình tối ưu hóa Adam và hàm lỗi là mean squared error để giảm thiểu sai số trong quá trình huấn luyện. Tổng cộng, mô hình có 11.051 tham số có thể điều chỉnh.



(Nguồn: Nhóm tác giả)

Hình 4. So sánh kết quả dự báo và thực tế trên tập kiểm tra



(Nguồn: Nhóm tác giả)


Hình 5: So sánh giá trị thực tế và giá trị dự báo bằng ANN

Quá trình huấn luyện mô hình được thực hiện trong 50 epoch, với kích thước batch là 32. Kết quả huấn luyện cho thấy giá trị loss của tập huấn luyện và tập kiểm tra giảm dần qua từng epoch, với loss trên tập huấn luyện bắt đầu từ 0.1243 và giảm xuống 0.0035 ở epoch cuối cùng, trong khi val loss trên tập kiểm tra cũng giảm từ 0.0143 xuống còn 0.00099. Sự giảm đồng bộ của cả hai giá trị loss cho thấy mô hình học tốt mà không gặp phải hiện tượng overfitting đáng kể.

Cuối cùng, để kiểm tra tình trạng quá khớp (overfitting), biểu đồ mất mát (loss) đã được vẽ ra. Trong hình 6, đường màu cam thể hiện độ mất mát trong tập huấn luyện và đường màu xanh giảm nhanh chóng và ổn định cho thấy độ mất mát trong tập huấn luyện. Hình 6 cũng cho thấy đường loss trên tập huấn luyện và tập kiểm tra có xu hướng hội tụ, chứng tỏ mô hình đã đạt được độ chính xác tốt trong dự đoán mà không bị quá khớp. Tổng quan mô hình vẫn đang cải thiện trên tập dữ liệu xác thực và đang dự báo tốt từ dữ liệu huấn luyện.


Điều này cũng được kiểm chứng với giá trị RMSE. RMSE được tính toán để đánh giá hiệu suất của mô hình trên tập huấn luyện và kiểm tra. $\text{Train_rmse} = 1.4214$ và $\text{Test_rmse} = 0.7551$. Kết quả cho thấy mô hình có khả năng dự đoán tốt trên tập kiểm tra với sai số thấp hơn so với tập huấn luyện. Điều này có thể chỉ ra rằng mô hình có khả năng tổng quát tốt và không bị quá khớp.

Hình 7 trực quan hoá giá trị dự báo và giá trị thực tế của mô hình LSTM. Việc trực quan hóa kết quả giúp dễ dàng so sánh và đánh giá hiệu suất dự đoán của mô hình một cách trực quan. Ở hình 7, đường màu xanh hiện thị giá trị thực tế, trong khi đường màu cam thể hiện dự báo của mô hình. Kích thước của dữ liệu thử nghiệm nằm trong khoảng từ 145 đến 180, phạm vi giá trị từ 1.0 đến 5.0. Theo biểu đồ, có những khoảng thời gian mà đường dự báo và đường thực tế có sự chênh lệch rõ rệt tại một số thời điểm như 165-170, đường dự đoán không theo kịp sự gia tăng của giá thực tế, cho thấy rằng mô hình có độ chính xác chưa cao.



(Nguồn: Nhóm tác giả)

Hình 6: Biểu đồ mất mát bởi mô hình LSTM



(Nguồn: Nhóm tác giả)

Hình 7: So sánh giá trị thực tế và giá trị dự báo bằng LSTM

4.4. Kết quả dự báo theo mô hình Lasso

Mô hình Lasso được thiết lập tối ưu với λ bằng 0.1. Kết quả cho thấy MSE được tính là 6.3928, cho biết mức độ sai lệch bình quân của các dự đoán so với giá trị thực tế và hệ số xác định là 0.7153, cho thấy rằng khoảng 71.53% biến thiên của giá trị thực tế có thể được giải thích bởi mô hình hồi quy LASSO. Mặc dù score không gần giá trị 1, nhưng 0.715 vẫn được coi là phù hợp trong nhiều ứng dụng thực tế, đặc biệt trong các lĩnh vực mà có nhiều yếu tố không thể đo lường và ảnh hưởng đến tỷ lệ lạm phát (tâm lý người tiêu dùng, chính sách chính phủ, ...). Đây là một chỉ số tích cực cho thấy mô hình có khả năng giải thích một phần lớn biến động của lạm phát.


Hình 8 trực quan hoá giá trị dự báo từ mô hình Lasso và giá trị thực tế của lạm phát.

Đường dự đoán của Lasso theo dõi khá sát với đường giá trị thực tế, cho thấy mô hình đã nắm bắt được xu hướng chính trong dữ liệu tỷ lệ lạm phát ở Việt Nam.

5. Kết luận

Bài nghiên cứu đã sử dụng các mô hình ARIMA, ANN, LSTM và Lasso để dự báo lạm phát hàng tháng của Việt Nam. Kết quả nghiên cứu cho thấy mô hình Lasso là phương pháp dự báo lạm phát hiệu quả nhất trong bối cảnh Việt Nam, mang lại dự báo sát với xu hướng thực tế hơn so với các mô hình truyền thống như ARIMA, ANN và LSTM.

Điều này mở ra nhiều ứng dụng quan trọng trong thực tiễn, đặc biệt đối với Chính phủ và doanh nghiệp trong việc ra quyết định dựa trên dữ liệu. Thứ nhất, mô hình Lasso có thể trở thành công cụ hỗ trợ quan trọng trong việc thiết lập chính sách tiền tệ và điều hành kinh tế



(Nguồn: Tác giả)

Hình 8: So sánh giá trị lạm phát thực tế và giá trị dự báo bằng Lasso

vĩ mô. Nhờ khả năng chọn lọc biến quan trọng và loại bỏ nhiễu, mô hình giúp xác định rõ hơn các yếu tố tác động đến lạm phát, hỗ trợ Chính phủ nâng cao khả năng ứng phó với các biến động kinh tế, tạo điều kiện cho việc điều chỉnh chính sách một cách linh hoạt và kịp thời, đảm bảo sự ổn định và phát triển bền vững trong bối cảnh thị trường luôn thay đổi. Dự báo lạm phát trung và dài hạn giúp Ngân hàng Nhà nước và các cơ quan hoạch định chính sách có thể điều chỉnh chính sách tiền tệ một cách chủ động, giảm thiểu tình trạng nổi lũng hoặc thất thoát quá mức. Việc nhận diện xu hướng lạm phát thông qua các yếu tố như tín dụng trong nước, lãi suất liên ngân hàng và cung tiền sẽ giúp Chính phủ đưa ra quyết định hợp lý về điều tiết thanh khoản và kiểm soát tăng trưởng tín dụng. Thứ hai, mô hình Lasso có thể hỗ trợ trong việc điều hành tỷ giá và kiểm soát giá cả, đặc biệt trong bối cảnh Việt Nam là nền kinh tế mở, chịu nhiều tác động từ biến động ngoại hối. Việc dự báo tác động của tỷ giá hối đoái lên lạm phát sẽ giúp Ngân hàng Nhà nước chủ động có biện pháp can thiệp nhằm ổn định thị trường ngoại hối, tránh gây ra những cú sốc về giá. Thứ ba, mô hình có thể đóng vai trò quan trọng trong việc quản lý rủi ro kinh tế, cung cấp cảnh báo sớm về nguy cơ lạm phát vượt tầm kiểm soát. Khi xuất hiện những cú sốc kinh tế như giá dầu tăng hoặc bất ổn thị trường tài chính, mô hình sẽ hỗ trợ Chính phủ đánh giá mức độ ảnh hưởng và đề xuất các giải pháp ứng phó kịp thời nhằm giảm thiểu tác động tiêu cực. Tuy nhiên, kết quả dự báo của mô hình Lasso vẫn chịu ảnh hưởng từ các yếu tố bất ổn của nền kinh tế trong giai đoạn dịch bệnh, khiến cho độ chính xác chưa đạt mức tối ưu. Do đó, để tăng cường hiệu quả ứng dụng, cần tiếp tục mở rộng tập dữ liệu, thử nghiệm thêm các biến số mới và điều chỉnh tham số của mô hình nhằm cải thiện độ chính xác.

Cuối cùng, không chỉ hữu ích đối với Chính phủ, mô hình Lasso còn có thể hỗ trợ doanh nghiệp, đặc biệt là trong các lĩnh vực tài chính, bất động sản và sản xuất, bằng cách cung cấp các dự báo chính xác hơn về lạm phát để tối ưu hóa chiến lược kinh doanh. Dự báo lạm phát chính xác giúp doanh nghiệp hoạch định chiến lược giá cả, điều chỉnh mức giá sản phẩm phù hợp với xu hướng lạm phát nhằm đảm bảo lợi nhuận và sức cạnh tranh trên thị trường. Điều này đặc biệt quan trọng

đối với các doanh nghiệp trong lĩnh vực hàng tiêu dùng nhanh và sản xuất công nghiệp, nơi biến động giá cả nguyên vật liệu có thể ảnh hưởng đáng kể đến chi phí sản xuất. Bên cạnh đó, việc dự báo xu hướng lãi suất và cung tiền sẽ giúp doanh nghiệp quản lý tài chính và đầu tư hiệu quả hơn. Các doanh nghiệp có thể dựa vào dự báo lạm phát để điều chỉnh chiến lược vay vốn, tối ưu hóa chi phí tài chính và đưa ra quyết định đầu tư vào các tài sản có lợi suất cao hơn trong môi trường lãi suất biến động. Ngoài ra, các công ty bán lẻ và sản xuất cũng có thể sử dụng mô hình để dự báo nhu cầu thị trường, giúp điều chỉnh sản lượng sản xuất, tối ưu hóa chuỗi cung ứng và kiểm soát hàng tồn kho một cách hiệu quả hơn. Nhờ đó, doanh nghiệp có thể tăng cường khả năng cạnh tranh, giảm thiểu rủi ro tài chính và đảm bảo sự ổn định trong hoạt động kinh doanh.

Mặc dù mô hình Lasso đã cho thấy tính ưu việt trong việc dự báo lạm phát, nghiên cứu cũng đề xuất các nghiên cứu trong tương lai có thể kết hợp Lasso với các mô hình phi tuyến như LSTM và ANN để tận dụng lợi thế của cả hai phương pháp. Mô hình Lasso giúp chọn lọc các biến quan trọng, giảm nhiễu và cung cấp mô hình tuyến tính ổn định, trong khi LSTM và ANN có khả năng học các quan hệ phi tuyến, giúp nhận diện các xu hướng phức tạp trong dữ liệu kinh tế. Việc kết hợp các mô hình này có thể giúp nâng cao độ chính xác và tính linh hoạt của dự báo, đặc biệt trong các giai đoạn kinh tế có biến động mạnh. ♦

Tài liệu tham khảo:

- Akbulut, H. (2022). Forecasting inflation in Turkey: A comparison of time-series and machine learning models. *Economic Journal of Emerging Markets*, 55-71. <https://doi.org/10.20885/ejem.vol14.iss1.art5>.
- Barkan, O., Benchimol, J., Caspi, I., Cohen, E., Hammer, A., & Koenigstein, N. (2023). Forecasting CPI inflation components with Hierarchical Recurrent Neural Networks. *International Journal of Forecasting*, 39(3), 1145-1162. <https://doi.org/10.1016/j.ijforecast.2022.04.009>.
- Baybuza, I. (2018). Inflation Forecasting Using Machine Learning Methods. *Russian Journal of Money and Finance*, 42-59. <https://doi.org/10.31477/rjmf.201804.42>.

- Bernanke, B. S., & Kuttner, K. N. (2005). What explains the stock market's reaction to Federal Reserve policy? *Journal of Finance*, 60, 1221-1257.
- Blanchard, O., & Quah, D. (1989). The Dynamic Effects of Aggregate Demand and Supply Disturbances. *The American Economic Review*, 79(4), 655-673.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control* (Revised Edition). Holden Day.
- Brunner, A. D., & Hess, G. D. (1993). Are Higher Levels of Inflation Less Predictable? A State-Dependent Conditional Heteroscedasticity Approach. *Journal of Business & Economic Statistics*, 11(2), 187-197. <https://doi.org/10.1080/07350015.1993.10509947>
- Canova, F. (1995). Vector Autoregressive Models: Specification Estimation, Inference, and Forecasting. In M. H. Pesaran & M. R. Wickens (Eds.), *Handbook of Applied Econometrics: Macroeconomics* (pp. 73-138). Blackwell.
- Cheng, C., Sa-Ngasoongsong, A., Beyca, O., Le, T., Yang, H., Kong, Z. (James), & Bukkapatnam, S. T. S. (2015). Time series forecasting for nonlinear and non-stationary processes: a review and comparative study. *IIE Transactions*, 47(10), 1053-1071. <https://doi.org/10.1080/0740817X.2014.999180>
- de Mendonça, H. F., & de Guimarães e Souza, G. J. (2012). Is inflation targeting a good remedy to control inflation? *Journal of Development Economics*, 98(2), 178-191. <https://doi.org/10.1016/j.jdevec.2011.06.011>
- Enders, W., & Siklos, P. L. (2001). Cointegration and Threshold Adjustment. *Journal of Business & Economic Statistics*, 19(2), 166-176. <https://doi.org/10.1198/073500101316970395>
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987. <https://doi.org/10.2307/1912773>
- Haider, A., & Hanif, M. N. (2007). *Inflation Forecasting in Pakistan using Artificial Neural Networks* (14645; MPRA Paper).
- 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>
- Hussain, L., Ghufran, B., & Ditta, A. (2022). Forecasting Inflation, Exchange Rate, and GDP using ANN and ARIMA Models: Evidence from Pakistan. *Sustainable Business and Society in Emerging Economies*, 4(1), 25-32. <https://doi.org/10.26710/sbsee.v4i1.2147>
- Junttila, J. (2001). Structural breaks, ARIMA model and Finnish inflation forecasts. *International Journal of Forecasting*, 17(2), 203-230. [https://doi.org/10.1016/S0169-2070\(00\)00080-7](https://doi.org/10.1016/S0169-2070(00)00080-7)
- Lam, H. T. (2015). Hiệu ứng ngưỡng trong môi quan hệ giữa tăng trưởng và lạm phát. *Kinh tế và Phát triển*, 217, 29-37.
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, A., & Zilberman, E. (2021). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business & Economic Statistics*, 39(1), 98-119. <https://doi.org/10.1080/07350015.2019.1637745>
- Medeiros, M. C., Vasconcelos, G., & Freitas, E. (2016). Forecasting Brazilian Inflation with High-Dimensional Models. *Brazilian Review of Econometrics*, 36(2), 223-254. <https://doi.org/10.12660/bre.v99n992016.52273>
- Nakamura, E. (2005). Inflation forecasting using a neural network. *Economics Letters*, 86(3), 373-378. <https://doi.org/10.1016/j.econlet.2004.09.003>
- Özgür, Ö., & Akkoç, U. (2022). Inflation forecasting in an emerging economy: selecting variables with machine learning algorithms. *International Journal of Emerging Markets*, 17(8), 1889-1908. <https://doi.org/10.1108/IJOEM-05-2020-0577>
- Phuoc Tran, & Anh Hoang Le. (2024). Application of machine learning methods in forecasting economic growth and inflation of Vietnam. *Electronic Journal of Applied Statistical Analysis*, 17(1), 191-205.

- Qasim, T. B., Ali, H., Malik, N., & Liaquat, M. (2021). Forecasting Inflation Applying ARIMA Model with GARCH Innovation: The Case of Pakistan. *Journal of Accounting and Finance in Emerging Economies*, 7(2), 313-324. <https://doi.org/10.26710/jafee.v7i2.1681>.
- Sako, K., Mpinda, B. N., & Rodrigues, P. C. (2022). Neural Networks for Financial Time Series Forecasting. *Entropy*, 24(5), 657. <https://doi.org/10.3390/e24050657>.
- Salam, M. A., Salam, S., & Feridun, M. (2007). *Application of ARIMA Models for Forecasting Inflation in Pakistan* (1; Economic Analysis Working Papers).
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 1394-1401. <https://doi.org/10.1109/ICMLA.2018.00227>.
- Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 48(1), 1. <https://doi.org/10.2307/1912017>.
- Stock, J. H., & Watson, M. W. (2003). Forecasting Output and Inflation: The Role of Asset Prices. *Journal of Economic Literature*, 41(3), 788-829.
- Stock, J., & Watson, M. (1999). *Forecasting Inflation*. <https://doi.org/10.3386/w7023>.
- Tao, X., & Zhang, H. (2016). Prediction of Rural Residents' Consumption Expenditure Based on Lasso and Adaptive Lasso Methods. *Open Journal of Statistics*, 06(06), 1166-1173. <https://doi.org/10.4236/ojs.2016.66094>.
- Thị Thanh Xuân, P., Thị Thanh Trang, C., Tuấn Duy, N., Hồng Trang, B., & Thị Bảo Ngọc, N. (2021). Ứng dụng mạng nơ ron nhận tạo để dự báo lạm phát: nghiên cứu tình huống Việt Nam. *Tạp Chí Nghiên Cứu Tài Chính - Marketing*, 58, 54-66. <https://doi.org/10.52932/jfm.vi58.83>.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of Royal Statistical Society, B*(58), 267-288.
- Ülke, V., Sahin, A., & Subasi, A. (2018). A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA. *Neural Computing and Applications*, 30(5), 1519-1527. <https://doi.org/10.1007/s00521-016-2766-x>.
- VUONG, M.-G. (2011). Forecasting Vietnam's Inflation in the Short Term by using ARIMA Models. *Vietnam Securities Review*, 152, 42-44.
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks: *International Journal of Forecasting*, 14(1), 35-62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7).
- Zhang, J., Wen, J., & Yang, Z. (2022). China's GDP forecasting using Long Short Term Memory Recurrent Neural Network and Hidden Markov Model. *PLOS ONE*, 17(6), e0269529. <https://doi.org/10.1371/journal.pone.0269529>.
- Zou, H. (2006). The Adaptive Lasso and Its Oracle Properties. *Journal of the American Statistical Association*, 101(476), 1418-1429. <https://doi.org/10.1198/016214506000000735>.

Summary

This study aims to forecast inflation in Vietnam by comparing the performance of traditional models and artificial intelligence techniques. Using time series data from 2009 to 2023 with 179 observations, the study employs ARIMA, LSTM, ANN, and Lasso models to evaluate and compare their forecasting accuracy. The results reveal that the Lasso model provides the most accurate forecasts among the models considered. This finding has important policy implications, as regulatory agencies can rely on the Lasso model to enhance forecasting capabilities and adjust economic policies in a timely manner to cope with future inflation fluctuations. Accurate forecasting can support more effective monetary and fiscal policy management, thereby contributing to macroeconomic stability. Furthermore, the study highlights the promising potential of applying artificial intelligence models to economic problems, as they can significantly improve forecasting precision and support the development of a more stable and sustainable economy in the long run.