

Dự báo lạm phát tại Việt Nam bằng mô hình mạng thần kinh nhân tạo

Nguyễn Khắc Hiếu

Trường Đại học Sư phạm Kỹ thuật TP.HCM - ngkhachieu@gmail.com

Nguyễn Thị Anh Vân

Trường Đại học Sư phạm Kỹ thuật TP.HCM - vanngta@hcmute.edu.vn

Ngày nhận: 28/02/2014
Ngày nhận lại: 02/04/2014
Ngày duyệt đăng: 05/08/2014
Mã số: 0214-O-08

Tóm tắt

Lạm phát là vấn đề mà các nhà hoạch định chính sách, các doanh nghiệp và nhà đầu tư đều quan tâm. Có nhiều mô hình dự báo lạm phát, mỗi mô hình đều có ưu và nhược điểm riêng. Bài viết này nhằm so sánh hiệu quả dự báo của mô hình mạng thần kinh nhân tạo (Artificial Neural Network: ANN) và mô hình phân phối độ trễ tự hồi quy (Autoregressive Distributed Lag: ARDL) trong dự báo lạm phát theo tháng tại VN. Kết quả cho thấy, mô hình ANN dự báo trong mẫu tốt hơn mô hình ARDL ở cả 3 tiêu chí R^2 , RMSE và MAE. Đối với dự báo ngoài mẫu, mô hình ANN dự báo tốt hơn ở 2 tiêu chí RMSE và R^2 . Nhìn chung, mô hình ANN dự báo lạm phát tại VN tốt hơn mô hình ARDL.

Abstract

Policy makers, entrepreneurs and investors are all interested in inflation. There are many inflation forecasting models; each one has its own strengths and weaknesses. This paper aims to compare the effectiveness of Artificial Neural Network (ANN) and Auto Regression Distribution Lag (ARDL) models in forecasting monthly inflation rate in Vietnam. The comparison results reveal that ANN model performs better than ARDL in in-sample forecasting for all three criteria R^2 , RMSE and MAE. In out-of-sample forecasting, ANN is better than ARDL in terms of RMSE and R^2 . In general, ANN performs better than ARDL in forecasting inflation of Vietnam.

Từ khóa:

Dự báo, lạm phát, mạng thần kinh nhân tạo, ANN, ARDL

Keywords:

Forecast, inflation, artificial neural network, ANN, ARDL

1. GIỚI THIỆU

Đối với các nước đang phát triển, lạm phát mục tiêu là công cụ hữu ích trong điều hành kinh tế vĩ mô (Mandonca & Souza, 2012). Theo Khan & Senhadji (2001) lạm phát mục tiêu cho các nước phát triển là 1-3%, cho các nước đang phát triển là 11-12%. Còn tại VN, Trần Hoàng Ngân & cộng sự (2013) cho rằng lạm phát mục tiêu hay lạm phát tối ưu nên ở mức 5-7%. Nếu lạm phát cao hơn lạm phát tối ưu sẽ gây ra những tác động tiêu cực như: làm tăng chi phí sản xuất cho các doanh nghiệp, tăng chi phí sử dụng vốn, làm giảm sức mua của người tiêu dùng, đặc biệt là những người sống nhờ vào lương. Ngược lại, nếu lạm phát thấp hay giảm phát xảy ra sẽ làm nền kinh tế trì trệ và không phát triển được.

Chính vì vậy, Nhà nước cần kiểm soát lạm phát sát với lạm phát mục tiêu, một mặt giúp ổn định kinh tế vĩ mô, mặt khác giúp nền kinh tế phát triển. Để kiểm soát lạm phát sát với lạm phát mục tiêu, các nhà làm chính sách cần phải biết được những yếu tố nào tác động đến lạm phát, dự báo được lạm phát trong tương lai, từ đó có những điều chỉnh phù hợp nhằm đạt được mục tiêu đặt ra. Có nhiều mô hình dự báo lạm phát khác nhau, mỗi mô hình có ưu và nhược điểm riêng. Tại VN, đã có nhiều mô hình về dự báo lạm phát của các tác giả như: Phạm Thị Thu Trang (2009), Nguyễn Trọng Hoài (2010), Vũ Sĩ Cường (2011), Sử Đình Thành (2012)... Các công trình này đều sử dụng các mô hình kinh tế lượng để xây dựng mô hình dự báo. Tuy nhiên, việc ứng dụng mô hình ANN vào dự báo lạm phát tại VN vẫn chưa được nghiên cứu nhiều.

Bài viết này nhằm nghiên cứu khả năng ứng dụng của mô hình ANN vào dự báo lạm phát tại VN và so sánh khả năng dự báo của mô hình ANN và mô hình ARDL dựa trên các tiêu chí R^2 , RMSE và MAE.

2. CƠ SỞ LÝ THUYẾT

2.1. Các mô hình dự báo lạm phát

Trong giới hạn của bài viết này tác giả chia các mô hình dự báo lạm phát ra làm hai nhóm: Nhóm các mô hình kinh tế lượng và nhóm các mô hình ANN.

Các mô hình kinh tế lượng:

Trong thực tế, có nhiều mô hình kinh tế lượng được ứng dụng vào dự báo lạm phát đặc biệt là những mô hình chuỗi thời gian như AR, VAR, ARDL, ARIMA... Tại VN, Vũ Sĩ Cường (2011) đã sử dụng mô hình VAR để phân tích lạm phát và khẳng định lạm phát tại VN chịu ảnh hưởng rõ rệt từ chính sách tài khoá. Sử Đình Thành (2012)

đã sử dụng mô hình ARDL để phân tích mối quan hệ giữa lạm phát và thâm hụt ngân sách; từ đó đưa ra những gợi ý chính sách trong điều hành kinh tế vĩ mô. Tại Mỹ, Binner & cộng sự (2006) đã ứng dụng mô hình AR vào dự báo lạm phát và khẳng định dự báo lạm phát bằng mô hình AR không tốt bằng mô hình tự hồi quy Markov (MS-AR). Tại Bangladesh, Faisal (2012) đã ứng dụng mô hình ARIMA để dự báo lạm phát; đồng thời đưa ra những gợi ý chính sách để kiểm soát lạm phát và điều hành kinh tế vĩ mô.

Ngoài những mô hình chuỗi thời gian tuyến tính, những mô hình phi tuyến cũng được sử dụng để dự báo lạm phát. Điển hình là Dotsey & cộng sự (2011) đã nghiên cứu khả năng ứng dụng của đường cong Philip trong dự báo lạm phát và khẳng định có thể dự báo lạm phát bằng đường cong này, đặc biệt đối với những nền kinh tế yếu (Weak Economies). Nguyễn Trọng Hoài (2010) đã sử dụng luật Taylor để phân tích lạm phát và đã đưa ra những gợi ý chính sách trong điều hành kinh tế vĩ mô.

Các mô hình ANN:

Bên cạnh những mô hình kinh tế lượng, còn có nhiều công trình nghiên cứu ứng dụng mạng thần kinh nhân tạo trong dự báo lạm phát và đã khẳng định tính ưu việt của mô hình này so với mô hình kinh tế lượng. Moshiri & Cameron (2000) khẳng định trong dài hạn, lạm phát (tại Canada) được dự báo bằng mô hình ANN cho kết quả tốt hơn so với mô hình VAR và ARIMA. Tại Mỹ, Nakamura (2005) cũng sử dụng mô hình ANN để dự báo lạm phát, kết quả cho thấy trong ngắn hạn mô hình ANN dự báo tốt hơn mô hình AR. Ngoài ra, McNelis & McAdam (2005) cũng chứng minh lạm phát có quan hệ phi tuyến với những biến số kinh tế khác, họ đã sử dụng mô hình “Thick Model”, kết hợp nhiều mạng ANN để dự báo lạm phát Mỹ và một số quốc gia châu Âu. Kết quả cho thấy mô hình ANN dự báo không thua kém gì so với mô hình hồi quy tuyến tính. Tiếp theo, Haider & Hanif (2007) cũng ứng dụng mô hình ANN, AR(1) và ARIMA dự báo lạm phát tại Pakistan và khẳng định mô hình ANN dự báo chính xác hơn AR(1) và ARIMA. Duzgun (2010) sử dụng mô hình ANN để dự báo lạm phát tại Thổ Nhĩ Kỳ và kết luận: Mô hình ANN dự báo lạm phát vượt trội hơn so với mô hình ARIMA. Còn tại VN, Lê Đạt Chí (2010) đã ứng dụng mô hình ANN vào dự báo giá chứng khoán tại TP.HCM và nhận xét: Mô hình ANN cho ra kết quả dự báo chính xác hơn mô hình hồi quy tuyến tính truyền thống. Gần đây, Choudhary & Haider (2012) ứng dụng mô hình ANN và AR(1) dự báo lạm phát tại 28 quốc gia thuộc Tổ chức Hợp tác và Phát triển kinh tế (OECD) và khẳng định mô hình ANN giải thích được 45% sự

biến động của lạm phát trong khi mô hình AR(1) chỉ giải thích được 23% sự biến động của lạm phát.

Ngoài những công trình cho thấy tính ưu việt, cũng có những công trình nêu ra những hạn chế của mô hình ANN. Zhang & cộng sự (1998) nhận thấy mô hình ANN chỉ dự báo tốt cho trường hợp phi tuyến còn đối với những mối quan hệ tuyến tính, mô hình ANN dự báo không tốt bằng mô hình hồi quy tuyến tính. Một nghiên cứu khác của Binner & cộng sự (2010) về lạm phát tại nền kinh tế Mỹ kết luận rằng mô hình KRLS dự báo tốt hơn mô hình ANN. Ngoài ra, nghiên cứu của Zhang (2003); Khashei & Bijari (2011) còn phát hiện thêm: Mô hình lai tạo (Hybrid Model) giữa ANN và ARIMA cho ra kết quả dự báo tốt hơn khi sử dụng những mô hình này đơn lẻ.


Tóm lại, có nhiều kết luận khác nhau liên quan đến hiệu quả dự báo của mô hình ANN tùy thuộc vào từng quốc gia và tùy thuộc vào bộ dữ liệu mà nhà nghiên cứu sử dụng. Trong phần tiếp theo, tác giả sẽ trình bày kỹ hơn về ANN và hiệu quả dự báo của nó so với mô hình hồi quy tuyến tính, sử dụng bộ dữ liệu kinh tế vĩ mô của VN.

2.2. Mạng thần kinh nhân tạo và cấu trúc mạng thần kinh nhân tạo

Mạng thần kinh nhân tạo là một mạng gồm các nơon nhân tạo kết hợp với nhau dựa trên đặc tính của mạng thần kinh con người. Mạng thần kinh nhân tạo được McCulloch, W.S. & W. Pitts (1943) giới thiệu đầu tiên vào năm 1943. Sau đó, mô hình này được hoàn thiện bởi những nhà khoa học khác và được ứng dụng nhiều trong lĩnh vực kỹ thuật. Ngày nay, mô hình ANN cũng được ứng dụng nhiều trong kinh doanh và kinh tế đặc biệt là trong dự báo và ra quyết định kinh doanh.

Có hai loại cấu trúc ANN là Mạng truyền thẳng (Feed Forward Networks) và mạng có hồi tiếp (Recurrent Networks). Bài viết này chỉ tập trung nghiên cứu mạng truyền thẳng. Đối với mạng thần kinh truyền thẳng, các nơon nhân tạo được sắp xếp thành các lớp: lớp vào, các lớp ẩn và lớp ra (Hình 1).

Lớp vào sẽ là nơi nhận các tín hiệu đầu vào. Các tín hiệu này có thể là một hằng số, dữ liệu thô hoặc cũng có thể là đầu ra của một mạng nơon khác. Các giá trị này sẽ tác động đến các nơon lớp ẩn thông qua bộ trọng số w_{ij} . Tại lớp ẩn, tín hiệu của lớp vào sẽ được xử lý bằng một hàm kích hoạt (Activate Function), thường là hàm Sigmoid [1] hoặc hàm Tan-hyperbolic [2] sau đó tín hiệu sẽ được truyền qua lớp ra thông qua bộ trọng số w_{jk} .



Hình 1. Cấu trúc mạng thần kinh nhân tạo truyền thẳng một lớp ẩn

Nguồn: Phạm Hữu Đức Dục (2009)

Tương tự các mô hình hồi quy tuyến tính, mô hình ANN xác lập mối quan hệ giữa một tập hợp các biến đầu vào X_i ($i = \overline{1, m}$) với một hoặc nhiều biến đầu ra Y_k ($k = \overline{1, n}$) dựa vào dữ liệu trong quá khứ. Điều khác biệt là sự tồn tại của các “lớp ẩn” (Hidden Layer), các lớp này liên kết giữa lớp vào và lớp ra của mạng nơron. Chính các lớp ẩn này đã giúp cho mô hình mạng thần kinh có khả năng mô phỏng mối tương quan phi tuyến tốt hơn so với mô hình truyền thống.

Mục tiêu của mô hình ANN là tính toán và dự báo giá trị của biến đầu ra với một tập hợp các thông tin của biến đầu vào được cho trước. Mô hình ANN sẽ được “huấn luyện” để có thể “học” từ những thông tin quá khứ. Từ đó, mạng có thể đưa ra kết quả dự báo dựa trên những gì đã được học. Quá trình này sẽ được tiến hành bằng các thuật toán huấn luyện mạng, phổ biến là thuật toán lan truyền ngược (Back-Propagation Algorithm) và thuật toán di truyền (Genetic Algorithm).

2.3. Ước lượng các hệ số của mô hình ANN bằng thuật toán lan truyền ngược

Để tính toán tín hiệu đầu ra theo tín hiệu vào, cần phải có hàm kích hoạt ở các lớp ẩn. Có hai hàm kích hoạt thường được sử dụng đó là hàm Sigmoid và hàm Tan-Hyperbolic. Đối với ANN một lớp ẩn, ứng với tín hiệu đầu vào là X_i và bộ trọng số w_{ij} , ta có tín hiệu ra tại nơron H_j là:

$$H_j = f\left(\sum_{i=1}^n X_i w_{ij}\right) \quad (1)$$

Sau khi có được tín hiệu ra ở các lớp ẩn. Giá trị $\hat{Y}_k$ (ước lượng) sẽ được tính như sau [3]:

$$\hat{Y}_k = f\left(\sum_{j=1}^q H_j * w_{jk}\right) = f\left(\sum_{j=1}^q f\left(\sum_{i=1}^n X_i w_{ij}\right) * w_{jk}\right) \quad (2)$$

Ứng với một quan sát thứ t ($t = \overline{1, T}$), tín hiệu đầu ra của mạng được ký hiệu là $\hat{Y}_{k,t}$, tín hiệu thực tế được ký hiệu là $Y_{k,t}$, độ lệch giữa $\hat{Y}_{k,t}$ và $Y_{k,t}$ được gọi là sai số. Ước lượng các tham số mô hình là tìm bộ trọng số w_{ij} và w_{jk} sao cho tổng bình phương các sai số này là bé nhất. Hay là tìm giá trị bé nhất của hàm mục tiêu $E(w)$ sau đây:

$$E(w) = \frac{1}{2} \sum_{t=1}^T \sum_{k=1}^n (Y_{k,t} - \hat{Y}_{k,t})^2 \quad (3)$$

Vì hàm $E(w)$ là một hàm phi tuyến theo w nên không thể tìm bộ trọng số w giống như cách tìm các hệ số β trong phương trình hồi quy tuyến tính (OLS). Do đó, tác giả tính toán bộ trọng số w này bằng một thuật toán được gọi là thuật toán lan truyền ngược sai số.

Thuật toán lan truyền ngược sai số

Thuật toán lan truyền ngược sai số là một thuật toán phức tạp. Theo Sarle (1994), để sử dụng được mạng thần kinh nhân tạo, không nhất thiết phải nắm được thuật toán lan truyền ngược sai số. Ý tưởng cơ bản của thuật toán này là khi w thay đổi thì $E(w)$ sẽ thay đổi và ứng một hàm $E(w)$ sẽ có một tập giá trị của các trọng số w mà làm cho hàm $E(w)$ đạt giá trị cực tiểu.

Để ước lượng các trọng số w bằng thuật toán lan truyền ngược sai số, đầu tiên ta gán cho mạng một bộ trọng số w ban đầu, từ bộ trọng số này ta tính toán được giá trị hàm $E(w)$. Sau đó ta sẽ điều chỉnh trọng số w sao cho bộ trọng số mới làm cho hàm $E(w)$ bé hơn. Phương pháp này được gọi là phương pháp hạ Gradient (Phạm Hữu Đức Dục, 2009). Giá trị điều chỉnh là:

$$\Delta w = w^{new} - w^{old} = -\eta \partial E / \partial w \quad (4)$$

Quá trình tìm bộ trọng số thích hợp cho mạng còn được gọi là quá trình học. Hằng số η còn được gọi là hằng số học. Quá trình học sẽ được lặp đi lặp lại cho đến khi Δw gần bằng 0 (nhỏ hơn một mức sai số cho trước) hoặc điều kiện dừng học được kích hoạt. Điều kiện dừng học được thiết lập nhằm tránh tình trạng học quá (Over-Fitting).

3. DỮ LIỆU NGHIÊN CỨU VÀ PHƯƠNG PHÁP NGHIÊN CỨU

3.1. Dữ liệu nghiên cứu

Các số liệu nghiên cứu sẽ được thu thập theo tháng từ năm 2001 đến 2012, tổng cộng có 144 quan sát. Trong đó, 132 quan sát đầu tiên sẽ được sử dụng để thiết lập mô hình, 12 quan sát cuối cùng sẽ được sử dụng để kiểm tra dự báo ngoài mẫu.

Lạm phát IF(%) được thu thập từ Tổng cục Thống kê (GSO) tính theo chỉ số giá tiêu dùng CPI.

Thay đổi cung tiền của tháng sau so với tháng trước DM2 (%) được thu thập từ Quỹ Tiền tệ Quốc tế (IMF).

Lãi suất cho vay R (%) được thu thập từ Quỹ Tiền tệ Quốc tế (IMF).

Thay đổi giá dầu DOIL (%) là thay đổi giá dầu của tháng sau so với tháng trước. DOIL được thu thập từ Ngân hàng Thế giới (WB).

3.2. Phương pháp nghiên cứu

Bài viết sử dụng phương pháp định lượng trong dự báo cụ thể là ứng dụng mô hình ANN và mô ARDL vào dự báo lạm phát theo tháng tại VN.


Xây dựng mô hình ANN

Để xây dựng cấu trúc mạng ANN, ta cần thực hiện 3 bước chính sau đây:

Bước 1: Xác định các biến đầu vào và đầu ra của mô hình

Để xây dựng mạng ANN cần phải tìm được các biến đầu vào và đầu ra thích hợp cho mô hình. Dữ liệu đầu vào là các biến chuỗi thời gian do đó phải tìm ra độ trễ thích hợp. Tang & Fishwick (1993) đề xuất sử dụng bằng phương pháp Box-Jenkins để tìm độ trễ thích hợp. Tuy nhiên, phương pháp này không thực sự tốt vì các độ trễ trong thành phần AR chỉ thích hợp với mối liên hệ tuyến tính còn mô hình ANN là mô hình mô phỏng quan hệ phi tuyến. Sharda & Patil (1992) đề xuất sử dụng 12 độ trễ cho dữ liệu theo tháng và 4 độ trễ cho dữ liệu theo quý. Bài viết này sử dụng cách tiếp cận của Sharda & Patil (1992) cho các độ trễ của biến độc lập. Tất cả 12 độ trễ của các biến độc lập sẽ được đưa vào mô hình, sau khi chạy thử mô hình, những biến ít có ý nghĩa

sẽ bị loại khỏi mô hình. Kết quả cuối cùng, tác giả còn giữ lại những biến sau đây cho mô hình dự báo.



Hình 2. Mô hình mạng thần kinh nhân tạo dự báo lạm phát [4]

Nguồn: Phân tích của tác giả

Bước 2: Chuẩn hoá dữ liệu đầu vào, đầu ra và chọn hàm kích hoạt

Do dữ liệu lạm phát có giá trị âm, nên hàm kích hoạt trong trường hợp này được sử dụng là hàm Tan-hyperbolic và dữ liệu được chuẩn hoá theo phân phối chuẩn.

Bước 3: Xây dựng và lựa chọn cấu trúc mạng

Khi xây dựng cấu trúc mạng ANN ta sẽ gặp phải câu hỏi: Đây là cấu trúc tối ưu của mạng ANN đối với một bộ dữ liệu đã cho? Hiện nay, các nhà nghiên cứu vẫn chưa đưa ra được phương pháp xác định cấu trúc tối ưu của mạng ANN. Quá trình xây dựng cấu trúc mạng là quá trình thử và sai (Try and Error). Nhiều mô hình mạng được đưa ra bằng cách thay đổi số nơron trong mỗi lớp ẩn và số lớp ẩn trong mô hình. Sau đó, ta sẽ dùng bộ dữ liệu để huấn luyện mạng. Mô hình nào cho kết quả dự báo tốt nhất sẽ là hình được lựa chọn.

Xây dựng mô hình phân phối độ trễ tự hồi quy (ARDL)

Phần này áp dụng cách tiếp cận của Tinbergen (1949) trong xây dựng mô hình ARDL. Trước tiên, để tránh hiện tượng hồi quy giả tạo, tác giả sẽ kiểm định tính dừng của tất cả các biến được đưa vào mô hình. Kế đến, để tìm được những biến độc lập tác động có ý nghĩa đối với lạm phát, tác giả đưa lần lượt từng độ trễ (từ nhỏ đến lớn) vào mô hình, quá trình sẽ được dừng lại khi các độ trễ mới đưa thêm vào không có ý nghĩa thống kê. Mô hình ARDL(p,q) đưa vào ước lượng có dạng như sau:

$$IF_t = \alpha_0 + \sum_{i=1}^p \alpha_i * IF_{t-i} + \sum_{j=0}^q \beta_j * DM2_{t-j} + \sum_{j=0}^q \gamma_j * DOIL_{t-j} + \sum_{j=0}^q \delta_j * R_{t-j} + \sum_{k=1}^{11} \rho_k * D_k$$

Trong đó, D_k là biến Dummy đại diện cho sự khác biệt về lạm phát của 12 tháng trong năm.

4. KẾT QUẢ NGHIÊN CỨU

4.1. Thống kê mô tả dữ liệu

Dữ liệu tác giả đưa vào phân tích có 4 biến chính, đó là: Lạm phát (IF), thay đổi cung tiền (DM2), thay đổi giá dầu thế giới (DOIL) và lãi suất cho vay (R). Bảng 1 thể hiện giá trị thống kê mô tả của các biến trên.

Bảng 1. Thống kê mô tả các biến số

	IF	DM2	DOIL	R
Trung bình	0,0071	0,0196	0,0131	11,689
Trung vị	0,0049	0,0185	0,0254	11,175
Lớn nhất	0,0390	0,0853	0,1898	20,250
Nhỏ nhất	-0,0085	-0,0176	-0,2679	8,4600
Độ lệch chuẩn	0,0090	0,0174	0,0811	2,7759
Số quan sát	144	144	144	144

Nguồn: Tính toán của nhóm tác giả

4.2. Kết quả ước lượng các mô hình

Mô hình mạng thần kinh nhân tạo:

Như đã phân tích, việc xây dựng mạng ANN được tác giả tiếp cận theo phương pháp của Sharda & Patil (1992). Kết quả cuối cùng, 10 biến sau được chọn làm biến đầu vào cho mô hình ANN:

IF_{t-1} , IF_{t-12} , $DOIL$, $DOIL_{t-1}$, $DOIL_{t-6}$, R_t , R_{t-2} , $M2_{t-1}$, $M2_{t-3}$, và Month

Hàm kích hoạt được sử dụng là hàm Tan-hyperbolic và dữ liệu được chuẩn hoá theo phân phối chuẩn. Quá trình xây dựng các lớp ẩn cho mạng ANN là một quá trình thử và sai. Ta sẽ thay đổi số lớp ẩn và số nơron trong mỗi lớp ẩn. Để tìm ra mô hình ANN tốt nhất, tác giả lựa chọn 7 mô hình sau đây để đưa vào phân tích:

Bảng 2. Ký hiệu các mô hình ANN

Số biến vào	Số nơron trong lớp ẩn 1	Số nơron trong lớp ẩn 2	Số biến ra	Ký hiệu
10	5		1	ANN-10-5-1
10	4		1	ANN-10-4-1
10	3		1	ANN-10-3-1
10	7	4	1	ANN-10-7-4-1
10	7	3	1	ANN-10-7-3-1
10	5	3	1	ANN-10-5-3-1
10	5	2	1	ANN-10-5-2-1

Nguồn: Đề xuất của tác giả

Việc huấn luyện mạng được thực hiện bằng phần mềm SPSS, dữ liệu bao gồm 132 quan sát (2001M01-2011M12), trong đó 70% được sử dụng cho tập huấn luyện và 30% được sử dụng cho tập xác nhận. Quá trình phân chia này được thực hiện một cách ngẫu nhiên. Sau khi quá trình huấn luyện mạng kết thúc, ứng với mỗi một mạng ANN ta sẽ có được một bộ trọng số của mô hình. Ứng với 7 mạng ANN ta có 7 bộ trọng số khác nhau. Sau đây là chi tiết bộ trọng số của mô hình ANN-10-5-2-1 (mô hình được chọn làm đại diện cho nhóm mô hình ANN).

Bảng 3. Các trọng số ước lượng của mô hình ANN-10-5-2-1

Các biến vào		Các biến ra					
		Lớp ẩn 1					Đầu ra
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	IF
Lớp vào	(Bias)	-0,018	1,079	0,006	0,215	0,344	
	[month=1]	-0,087	0,636	0,237	0,121	0,566	
	[month=2]	-0,701	0,747	-0,750	0,673	-0,064	
	[month=3]	0,875	-0,875	0,159	-0,347	-0,653	
	[month=4]	0,082	0,237	0,058	-0,182	-0,456	
	[month=5]	0,260	0,825	0,345	-0,414	0,018	
	[month=6]	0,363	0,079	0,503	-0,201	0,252	
	[month=7]	0,230	-0,299	0,766	-0,397	0,057	
	[month=8]	-0,112	-0,583	-0,354	-0,365	0,154	
	[month=9]	-0,567	0,202	0,405	-0,181	-0,116	
	[month=10]	-0,165	-0,012	0,343	0,580	-0,323	
	[month=11]	-0,578	-0,423	0,168	-0,163	-0,250	
	[month=12]	-0,470	0,448	-0,508	-0,026	-0,413	
	IF1	-0,234	-0,552	-0,474	0,483	0,796	
	DOIL	0,376	0,770	-0,163	-0,276	0,496	
	DOIL1	-0,076	0,068	0,228	-0,417	0,577	
	R	0,071	0,510	-0,209	0,640	0,517	
	DM23	0,137	0,132	-0,810	-0,199	0,476	
	DM21	0,335	0,867	-0,140	-0,278	0,217	
	IF12	0,575	-0,248	-0,254	0,865	0,830	

	DOIL6	-0,053	0,591	-0,310	0,120	-0,571	
	R2	0,709	-0,145	-0,398	0,759	0,126	
Lớp ẩn 1	(Bias)				0,074	0,881	
	H(1:1)				-0,092	0,983	
	H(1:2)				-0,231	-0,830	
	H(1:3)				0,948	0,367	
	H(1:4)				-1,261	-0,790	
	H(1:5)				0,111	-0,767	
Lớp ẩn 2	(Bias)					0,521	
	H(2:1)					0,423	
	H(2:2)					-1,907	

Nguồn: Phân tích của nhóm tác giả

Sau khi có được bộ trọng số của các mô hình ANN tác giả sử dụng phương trình (3) để tính toán các giá trị dự báo. Sau khi có kết quả dự báo tác giả so sánh hiệu quả dự báo trong mẫu và ngoài mẫu của các mô hình ANN dự trên các tiêu chí R^2 , RMSE và MAE. Bảng 4 thể hiện chi tiết hiệu quả dự báo của các mô hình ANN.

Bảng 4. So sánh kết quả dự báo giữa các mô hình ANN


Mô hình	Dự báo trong mẫu			Dự báo ngoài mẫu		
	R^2	RMSE	MAE	R^2	RMSE	MAE
ANN-10-5-1	70,6%	0,00508	0,00357	45,8%	0,00539	0,00358
ANN-10-4-1	69,8%	0,00509	0,00358	27,4%	0,00670	0,00450
ANN-10-3-1	80,0%	0,00416	0,00320	40,3%	0,00532	0,00408
ANN-10-7-4-1	73,4%	0,00478	0,00353	49,0%	0,00511	0,00390
ANN-10-7-3-1	71,7%	0,00492	0,00358	48,4%	0,00571	0,00466
ANN-10-5-3-1	79,5%	0,00421	0,00308	39,3%	0,00557	0,00410

ANN-10-5-2-1	80,6%	0,00410	0,00287	75,0%	0,00565	0,00414
--------------	-------	---------	---------	-------	---------	---------

Nguồn: Tính toán của tác giả

Kết quả trên cho thấy đối với dự báo trong mẫu, mô hình ANN-10-5-2-1 cho kết quả tốt nhất. Trong khi dự báo ngoài mẫu lại có sự phân tán. Mô hình ANN-10-5-2-1 cho kết quả R^2 tốt nhất, mô hình ANN-10-7-4-1 cho RMSE tốt nhất còn mô hình ANN-10-5-1 cho kết quả MAE tốt nhất. Nhìn chung, mô hình ANN với 2 lớp ẩn cho kết quả dự báo tốt hơn mô hình ANN 1 lớp ẩn cả trong mẫu lẫn ngoài mẫu. Kết quả cuối cùng, tác giả lựa chọn mô hình ANN-10-5-2-1 là mô hình ANN cho việc dự báo lạm phát theo tháng tại VN.

Ngoài việc tính toán giá trị dự báo, mô hình ANN còn phân tích cho ta biết được biến nào có mức độ quan trọng lớn nhất trong dự báo hay biến nào giải thích được nhiều nhất cho sự biến thiên của kết quả đầu ra. Phân tích mức độ quan trọng của các biến cho mô hình ANN-10-5-2-1 được thể hiện ở Hình 3. Từ kết quả phân tích này ta thấy độ trễ bậc 1 của lạm phát ($IF1=IF_{t-1}$) có mức độ quan trọng nhất. Kế đến là yếu tố mùa vụ (Month). Tiếp theo là giá dầu ($DOIL1=DOIL_{t-1}$, $DOIL6=DOIL_{t-6}$), lãi suất và cung tiền.



Hình 3. Mức độ quan trọng các biến độc lập của mô hình ANN-10-5-2-1

Nguồn: Phân tích của tác giả

Để làm rõ hiệu quả dự báo của mô hình ANN, ta sẽ so sánh hiệu quả dự báo của mô hình ANN so với một mô hình kinh tế lượng. Để có được kết quả so sánh, trước tiên tác giả thiết lập mô hình ARDL.

Mô hình ARDL

Dữ liệu thu thập được là dữ liệu dạng chuỗi thời gian. Do đó, để tránh hiện tượng hồi quy giả tạo, tác giả kiểm tra tính dừng của các biến số trên.

Bảng 5. Kiểm định tính dừng của các biến

Biến số	Kiểm định ADF	
	Level	1 st difference
IF	-6,357***	
DM2	-10,337***	
DOIL	-8,901***	
R	-3,175**	-6,275***

Ghi chú: Dấu ** và *** cho biết kết quả có ý nghĩa thống kê ở mức 5% và 1%

Nguồn: Tính toán của tác giả

Trong trường hợp này phương pháp nghiệm riêng đơn vị ADF cho giá trị $I(0)$ được thực hiện. Kết quả kiểm định được tóm tắt trong Bảng 5. Dựa vào kết quả trên, có thể kết luận tất cả các chuỗi chúng ta khảo sát đều dừng bậc 0 ở mức ý nghĩa 5%. Do đó, ta có thể thực hiện hồi quy dựa trên các biến này mà không sợ bị hồi quy giả tạo.

Để đưa yếu tố mùa vụ hay yếu tố tháng vào mô hình, tác giả sử dụng 11 biến Dummy từ D1 đến D11 để mã hoá cho 12 trạng thái ứng với 12 tháng trong năm. Dữ liệu được sử dụng để xây dựng mô hình hồi quy là từ 2001M01 đến 2011M12. Kết quả hồi quy biến IF theo các biến khác như Bảng 6.

**Bảng 6. Kết quả hồi quy
(Biến phụ thuộc IF_t)**

Biến	Hệ số	Độ lệch chuẩn	Thống kê t	Xác suất
C	-0,005865	0,003919	-1,496493	0,1376
IF_{t-1}	0,506398	0,087954	5,757506	0,0000
$DM2_{t-3}$	0,087811	0,037348	2,351167	0,0206
$DM2_{t-12}$	0,087857	0,041991	2,092249	0,0389
$DOIL_t$	0,027193	0,007532	3,610404	0,0005
$DOIL_{t-1}$	0,013087	0,007434	1,760424	0,0813
R_t	0,000619	0,000249	2,486905	0,0145
D1	0,002107	0,002646	0,796184	0,4278
D2	0,010894	0,003223	3,379829	0,0010
D3	-0,016524	0,003353	-4,928667	0,0000
D4	-0,001994	0,002971	-0,671171	0,5036
D5	0,001331	0,002893	0,460166	0,6464
D6	-0,004676	0,002836	-1,648729	0,1023
D7	-0,003924	0,002991	-1,311734	0,1926
D8	-0,002855	0,002898	-0,985427	0,3267
D9	-0,002350	0,002849	-0,824689	0,4115
D10	-0,003460	0,002826	-1,224343	0,2236
D11	-0,001048	0,002811	-0,372794	0,7101
R^2	0,681665	Giá trị F		12,84807
R^2 hiệu chỉnh	0,628609	Sig (F)		0,000000
Trị số DW	2,363510			

Nguồn: Tính toán của tác giả

Kết quả trên cho thấy tất cả các biến IF_{t-1} , $DM2_{t-3}$, $DM2_{t-12}$, $DOil_t$, Oil_{t-1} và R_t đều có tác động dương lên lạm phát và đều có ý nghĩa thống kê ở mức dưới 5%. Để biết yếu tố tháng (biến Dummy) có ảnh hưởng đến lạm phát không, ta thực hiện kiểm định Wald. Kết quả kiểm định cho thấy yếu tố tháng có ảnh hưởng đến lạm phát với $Sig. = 0,000$.

4.3. So sánh kết quả dự báo của mô hình ANN và mô hình ARDL

Như đã phân tích kết quả ước lượng các mô hình, mô hình ANN-10-5-2-1 được lựa chọn làm mô hình mạng thần kinh nhân tạo cho dự báo lạm phát. Trong phần này, tác giả sẽ so sánh hiệu quả dự báo của mô hình ANN-10-5-2-1 và mô hình ARDL dựa vào các tiêu chí RMSE, MAE và R^2 cả trong mẫu và ngoài mẫu.

Kết quả dự báo của mô hình ANN-10-5-2-1 về mặt lý thuyết sẽ được tính toán từ bộ trọng số ở Bảng 3 theo phương trình (3). Còn về mặt thực tiễn, giá trị dự báo này sẽ được phần mềm SPSS tính toán ra sau khi ta có bộ trọng số bằng cách chọn chức năng lưu giá trị dự báo (Save Predicted Value) trong khi ta thực hiện việc huấn luyện mạng.


Giá trị dự báo của mô hình ARDL được tính toán từ bảng trọng số hồi quy ở Bảng 6. Sau khi có được các giá trị dự báo, ta sẽ tính toán các giá trị RMSE, MAE và R^2 . Kết quả so sánh hiệu quả dự báo của 2 mô hình được thể hiện trong Bảng 7.

Bảng 7. So sánh hiệu quả dự báo của mô hình ANN-10-5-2-1 và ARDL

Mô hình	Dự báo trong mẫu			Dự báo ngoài mẫu		
	R^2	RMSE	MAE	R^2	RMSE	MAE
ANN-10-5-2-1	80,6%	0,00410	0,00287	75,0%	0,00565	0,00414
ARDL	68,2%	0,00521	0,00355	32,7%	0,00618	0,00377

Nguồn: Tính toán của tác giả

Kết quả trên cho thấy đối với dự báo trong mẫu, mô hình ANN dự báo vượt trội hơn so với mô hình ARDL trên tất cả các tiêu chí (R^2 lớn hơn, RMSE nhỏ hơn và MAE nhỏ hơn). Đối với dự báo ngoài mẫu, mô hình ANN dự báo tốt hơn ở hai tiêu chí R^2 và RMSE nhưng không tốt hơn ở tiêu chí MAE. Hình 4 thể hiện cụ thể hơn hiệu quả dự báo ngoài mẫu của mô hình ANN-10-5-2-1 và mô hình ARDL.



Hình 4. Kết quả dự báo ngoài mẫu

Nguồn: Phân tích của nhóm tác giả

5. KẾT LUẬN VÀ MỘT SỐ GỢI Ý CHÍNH SÁCH

5.1. Kết luận

Bài viết nghiên cứu các yếu tố tác động đến lạm phát và sử dụng mô hình ANN, mô hình ARDL để dự báo lạm phát theo tháng tại VN. Kết quả phân tích của mô hình ANN và mô hình ARDL cho thấy có các yếu tố sau tác động đến lạm phát: Tâm lí, mùa vụ, giá dầu, cung tiền và lãi suất.

Đối với mô hình ANN, tác giả sử dụng cấu trúc mạng truyền thẳng với 1 và 2 lớp ẩn, hàm kích hoạt là hàm Tan-hyperbolic, dữ liệu đầu vào và đầu ra được chuẩn hoá theo phân phối chuẩn. So sánh kết quả dự báo giữa các mô hình ANN cho thấy mô hình ANN với 2 lớp ẩn cho kết quả dự báo tốt hơn mô hình ANN 1 lớp ẩn. Kết quả dự báo tốt nhất đối với lạm phát là mô hình ANN-10-5-2-1.

Đối với mô hình ARDL, kết quả phân tích hồi quy chỉ ra lãi suất tăng có tác động tức thời làm cho lạm phát tăng. Kế đến, giá dầu tăng có tác động làm cho lạm phát tăng tức thời và tăng kéo dài thêm một tháng nữa. Tiếp theo là yếu tố tâm lí, yếu tố này có

tác động dương đối với lạm phát với độ trễ là 1 tháng. Cuối cùng, khi cung tiền tăng lạm phát sẽ tăng với độ trễ là 3 và 12 tháng.

So sánh kết quả dự báo trong mẫu của mô hình ANN và ARDL, mô hình ANN dự báo tốt hơn mô hình ARDL ở tất cả 3 tiêu chí R^2 , RMSE và MAE. Đối với dự báo ngoài mẫu, mô hình ANN chỉ dự báo tốt hơn ở hai tiêu chí R^2 và RMSE. Nhìn chung, mô hình ANN dự báo lạm phát tốt hơn mô hình ARDL.

5.2 Một số gợi ý chính sách

Kết quả nghiên cứu cho thấy mô hình ANN dự báo tốt hơn mô hình ARDL. Tuy thuật toán để tính ra các trọng số của mô hình ANN tương đối phức tạp nhưng để ứng dụng mô hình ANN vào dự báo ta không nhất thiết phải nắm kĩ những thuật toán trên (Sarle, 1994). Do đó, mô hình ANN là một lựa chọn tốt cho các nhà hoạch định chính sách, các doanh nghiệp và các nhà đầu tư nếu họ muốn dự báo những biến số kinh tế nói chung và dự báo lạm phát nói riêng.

Từ phân tích kết quả dự báo của mô hình ANN và ARDL ta thấy yếu tố quan trọng nhất tác động đến lạm phát theo tháng là yếu tố tâm lí, kết quả này tương đồng với nghiên cứu của Phạm Thị Thu Trang (2009) cho rằng yếu tố tâm lí có tác động đến lạm phát với độ trễ là 1 tháng. Vì vậy để kiềm chế lạm phát trong ngắn hạn, các nhà hoạch định chính sách cần ổn định được yếu tố tâm lí của người dân. Tuy nhiên, đây là một việc làm rất khó, vì VN đã có lạm phát tương đối cao trong nhiều năm qua. Người dân sẽ kì vọng lạm phát trong tương lai tương tự như lạm phát trong quá khứ. Để giảm được yếu tố tâm lí này, trước tiên Nhà nước cần phải giảm lạm phát trong hiện tại. Theo Mankiw (2009), một nền kinh tế muốn cắt giảm lạm phát phải trải qua một giai đoạn thất nghiệp lớn, hay là phải có sự đánh đổi giữa việc tăng trưởng và giảm lạm phát. Do đó, các nhà hoạch định chính sách cần cân nhắc sự đánh đổi giữa hai yếu tố này trong việc kiềm chế lạm phát.

Cũng từ kết quả phân tích mô hình ANN, yếu tố quan trọng tiếp theo mà Nhà nước có thể can thiệp để kiềm chế lạm phát đó là yếu tố mùa vụ hay là việc lên xuống có chu kì của lạm phát. Tại VN, giá cả của hàng hoá và dịch vụ thường tăng cao vào những dịp lễ tết. Nhà nước có thể hạn chế điều này thông qua các chương trình bình ổn giá trước tết và kiểm tra việc tăng giá bất hợp lí của các doanh nghiệp, các nhà phân phối và các nhà bán lẻ sau tết.

Cuối cùng, kết quả nghiên cứu cũng cho thấy cung tiền và lãi suất là hai yếu tố có tác động đến lạm phát. Các nhà hoạch định chính sách có thể can thiệp vào lãi suất

hoặc cung tiền nhằm kiềm chế lạm phát. Tuy nhiên, hai biến số này có mối liên hệ qua lại lẫn nhau, do đó các nhà hoạch định chính sách cần phối hợp giữa chính sách tài khoá và tiền tệ nhằm đạt hiệu quả hơn trong việc kiềm chế lạm phát tại VN (Nguyễn Trọng Hoài, 2010).

Ngoài những kết quả đã đạt được, bài viết cũng còn một số hạn chế. Có những biến tác động đến lạm phát như GDP, thâm thụt ngân sách nhưng tác giả không đưa những yếu tố này vào mô hình dự báo được vì dữ liệu về các biến này chỉ có theo quý hoặc theo năm. Những yếu tố khác tác động đến giá cả từ phía cung như thiên tai, lũ lụt (một vấn đề rất phổ biến tại VN) nhưng chưa được nghiên cứu. Tác giả hy vọng những nghiên cứu tiếp theo sẽ làm rõ hơn về vấn đề này■

Chú thích

[1] $f(x) = 1/(1+e^{-x})$

[2] $f(x) = (e^x - e^{-x})/(e^x + e^{-x})$

[3] $f(x)$ là hàm kích hoạt

[4] IFt-1: là giá trị lạm phát có độ trễ 1 tháng

Biến Month là biến mã hoá giá trị của 12 tháng trong năm đại diện cho yếu tố mùa vụ của lạm phát.

Tài liệu tham khảo

- Binner, J. M., Elger, C. T., Nilsson, B., & Tepper, J. A. (2006), "Predictable Non-Linearities in U.S. Inflation", *Economic Letter*, 93, 323-328.
- Binner, J. M., Tino, P., Tepper, J., Anderson, R., Jones, B., & Kendall, G. (2010), "Does Money Matter in Inflation Forecasting?", *Physica A: Statistical Mechanics and its Applications*, 4793-4808.
- Choudhary, M. A., & Haider, A. (2012), "Neural Network Models for Inflation Forecasting: An Appraisal", *Applied Economics, Taylor & Francis Journals*, 44(20), 2631-2635.
- Dotsey, M., Fujita, S., & Stark, T. (2011), *Do Phillips Curves Conditionally Help to Forecast Inflation?*, Federal Reserve Bank of Philadelphia, Working Paper, 11-40.
- Duzgun, R. (2010), "Generalized Regression Neural Networks for Inflation Forecasting", *International Research Journal of Finance and Economics*, 51, 59.
- Faisal, F. (2012), "Forecasting Bangladesh's Inflation Using Time Series ARIMA Models", *World Review of Business Research*, 2(3), 100-117.

- Haider, A., & Hanif, M. N. (2007), "Inflation Forecasting in Pakistan using Artificial Neural Networks", *Pakistan Economic and Social Review*, 123-138.
- Khan, M. S., & Senhadji, A. S. (2001), *Threshold Effects in the Relationship Between Inflation and Growth*, 48, IMF Staff paper.
- Khashei, M., & Bijari, M. (2011), "A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Timeseries Forecasting", *Applied Soft Computing*, 2664-2675.
- Lê Đạt Chí (2011), *Ứng dụng mô hình mạng thần kinh nhân tạo trong dự báo kinh tế - Trường hợp thị trường chứng khoán VN*, Luận án tiến sĩ, Trường Đại học Kinh tế TP.HCM.
- Mandonca, H. F., & Souza, G. J. (2012), "Is Inflation Targeting a Good Remedy to Control Inflation?", *Journal of Development Economics*, 178-191.
- Mankiw, N. G. (2009), *Principles of Macroeconomics*, Cengage learning, Australia.
- McCulloch, W. S., & Pitts, W. (1943), "A Logical Calculus of Ideas Immanent in Nervous Activity", *Bulletin of Mathematical Biophysics*, 115-133.
- McNelis, P., & McAdam, P. (2005), "Forecasting Inflation with Thick Model and Neural Network", *Economic Modelling*, 848-867.
- Moshiri, S., & Cameron, N. (2000), Neural Network Versus Econometric Models in Forecasting Inflation, *Journal of Forecasting*, 19(3), 201-217.
- Nakamura, E. (2005), "Inflation Forecasting Using a Neural Network", *Economics Letters*.
- Nguyễn Trọng Hoài & Nguyễn Hoài Bảo (2010), "Khả năng của chính sách tiền tệ trong việc khắc phục lạm phát cao dài hạn: Phân tích dựa trên luật Taylor cho tình huống VN", Tạp chí *Phát triển kinh tế* (242).
- Phạm Hữu Đức Dục (2009), *Mạng nơron và ứng dụng trong điều khiển tự động*, 42-52, NXB Khoa học kỹ thuật, Hà Nội.
- Phạm Thị Thu Trang (2009), "Các yếu tố tác động tới lạm phát tại VN - Phân tích chuỗi thời gian phi tuyến", Tạp chí *Kinh tế và Dự báo*, (12).
- Sharda, R., & Patil, R. B. (1992), "Connectionist Approach to Time Series Prediction: An Empirical Test", *Journal of Intelligent Manufacturing*, 317-323.
- Sarle, W. S. (1994), "Neural Networks and Statistical Models", *Proceeds of the Nineteenth Annual SAS Users Group International Conference*.
- Sử Đình Thành (2012), "Thâm hụt ngân sách và lạm phát: Minh chứng thực nghiệm ở VN", Tạp chí *Phát triển kinh tế*, 259.
- Tang, Z. & Fishwick, P. A. (1993), "Feedforward Neural Nets as Models for Time Series Forecasting", *ORSA Journal on Computing*, 374-385.
- Tinbergen, J. (1949), "Long term Foreign Trade Elasticities", *Metroeconomica*, 1(3), 174-185.

- Trần Hoàng Ngân, Vũ Thị Lệ Giang, & Hoàng Hải Yến (2013), “Mối quan hệ giữa lạm phát và tăng trưởng kinh tế tại VN thời gian qua”, Tạp chí *Phát triển kinh tế*, 276, 2-10.
- Vũ Sĩ Cường (2011), “Tác động của chính sách tài khóa và tiền tệ đến lạm phát: Mô hình lí thuyết và thực tiễn ở VN”, Tạp chí *Phát triển kinh tế*, 247.
- Warren, S. S. (1994), “Neural Networks and Statistical Models”, *Proceeds of the Nineteenth Annual SAS Users Group International Conference*, April 1994.
- Yao, J., Tan, C. L., & Poh, H. L. (1999), “Neural Network for Technical Analysis A Study on KLCI”, *International Journal of Theoretical and Applied Finance*, 2(2).
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998), “Forecasting with Artificial Neural Networks: The State of the Art”, *International Journal of Forecasting*, 14(1), 35-62.
- Zhang, G. P. (2003), “Time Series Forecasting using a Hybrid ARIMA and Neural Network Model”, *Neurocomputing*, 50, 159-175.