

# ỨNG DỤNG MẠNG NƠ RON NHÂN TẠO ĐỂ DỰ BÁO LẠM PHÁT: NGHIÊN CỨU TÌNH HUỐNG VIỆT NAM

## APPLICATION OF ARTIFICIAL NEURAL NETWORK TO FORECAST INFLATION: A CASE STUDY OF VIETNAM

Ngày nhận bài: 31/10/2019 Ngày chấp nhận đăng: 04/12/2019 Ngày đăng: 05/08/2020

*Phạm Thị Thanh Xuân, Chu Thị Thanh Trang, Nguyễn Tuấn Duy,  
Bùi Hồng Trang, Nguyễn Thị Bảo Ngọc\**

### Tóm tắt

Bài nghiên cứu này dự báo lạm phát cho Việt Nam bằng việc ứng dụng mạng nơ ron nhân tạo (ANN) với thuật toán lan truyền ngược (back-propagation algorithm). Dữ liệu về lạm phát theo tháng từ năm 2000 đến 2018, được sử dụng trong việc huấn luyện, đánh giá mô hình và dự báo lạm phát. Các phát hiện cho thấy lạm phát thực tế và dự đoán là tương đối gần nhau. Điều này đã góp phần cùng với các nghiên cứu khác trong và ngoài nước khẳng định rằng mô hình ANN sử dụng trong dự báo vĩ mô nói chung và lạm phát nói riêng là hiệu quả và đáng tin cậy.

**Từ khóa:** Mạng lưới mạng nơ ron nhân tạo (ANN), mô hình dự báo, lạm phát.

### Abstract

This study investigates the power of artificial neural network (ANN) with back propagation as forecasting tools for monthly inflation rate for Vietnam. Monthly inflation data from 2000 to 2018 is used for training, validate and forecast. The findings show that the actual and predicted inflation are relatively close to each other. This thus confirms the literature that our proposed ANN model is efficient and reliable. In addition, among considerable factors, money supply appears to be the main determinant in forecasting the inflation rate in Vietnam.

**Keywords:** Artificial neural networks (ANN), forecasting model, Inflation.

### 1. Giới thiệu

Mục tiêu nghiên cứu là vận dụng mạng nơ ron nhân tạo vào việc dự báo một biến số kinh tế vĩ mô quan trọng là lạm phát trong nền kinh tế Việt Nam cho trung, dài hạn. Việc dự báo có vai trò vô cùng quan trọng vì các thông tin có căn cứ tin cậy mà dự báo cung cấp sẽ là cơ sở cho việc hoạch định chính sách và đưa ra các quyết định. Chính vì vậy, nghiên cứu dự báo có sức hút mạnh mẽ không chỉ đối với nhà hoạch định chính sách, các cơ quan chức năng mà ngay cả đối với giới nghiên cứu.

Lịch sử chưa từng ghi nhận một dự báo nào mang lại kết quả chính xác hoàn toàn với thực

tiễn. Trong lĩnh vực kinh tế vĩ mô, chưa từng có công bố một mô hình hay một công cụ nào có khả năng dự báo chính xác diễn biến của nền kinh tế. Mỗi mô hình đều có ưu điểm và hạn chế riêng. Thành thử, nhà nghiên cứu thường chọn một mô hình riêng cho từng bài toán dự báo đồng thời đối sánh kết quả từ nhiều công cụ dự báo nhằm xác định điểm thống nhất.

Trong nhiều mô hình dự báo, nghiên cứu này chọn mô hình mạng nơ ron nhân tạo (ANN) vì nhiều lý do. Trước hết, ANN là một công nghệ tiên tiến, đang được ứng dụng rộng rãi trên thế giới song còn mới mẻ tại Việt Nam. ANN là một kỹ thuật trên nền tảng công nghệ trí tuệ

---

\* Trường Đại học Tài chính - Marketing

nhân tạo (AI). Cấu trúc của ANN và quá trình suy luận của nó có khả năng tự thích ứng linh hoạt (autofit) để đáp ứng với tín hiệu tương quan từ bộ dữ liệu. Dựa trên các công trình thử nghiệm khác nhau, ANN đã được chứng minh về khả năng mang lại kết quả dự đoán có tính chính xác cao. ANN đã được sử dụng rộng rãi để giải quyết các vấn đề phân tích hồi quy phi tuyến. Xét trong phạm vi dự báo kinh tế vĩ mô, mô hình ANN có khả năng dự báo tốc độ tăng trưởng GDP tốt hơn, chính xác hơn các mô hình tuyến tính<sup>1</sup> (Jahn, 2018). Ưu điểm của mô hình ANN là khả năng học và tái tạo được một cách rất linh hoạt các xu hướng vận động của GDP theo thời gian (Jahn, 2018). Khả năng dự báo của ANN đã được chứng minh qua nhiều nghiên cứu thực nghiệm. Ví dụ, ANN được ứng dụng để dự báo tốc độ tăng trưởng GDP của 15 quốc gia công nghiệp hóa, giai đoạn 1996 đến 2016, và dự báo ngoài mẫu đến hết năm 2017 (Jahn, 2018). (Jahn, 2018) khuyến khích các nhà nghiên cứu vận dụng ANN cho việc phân tích các mô hình hồi quy.

Nghiên cứu có những đóng góp nhất định cả về khoa học và thực tiễn. Thứ nhất, đây là một trong số ít những nỗ lực đầu tiên sử dụng mạng lưới mạng nơ ron nhân tạo trong dự báo kinh tế vĩ mô ở Việt Nam. Những kết quả trong nghiên cứu này có thể sử dụng như điểm tham khảo cho các nghiên cứu trong tương lai. Thứ hai, kết quả nghiên cứu có thể được sử dụng trong việc xây dựng các kịch bản phát triển kinh tế cho kế hoạch 5 năm. Vì vậy, điều này có ý nghĩa quan trọng đối với các nhà làm chính sách tại Việt Nam.

Bài viết này được cấu trúc như sau. Ngoài phần mở đầu, phần 2 giới thiệu tổng quan về phương pháp luận ANN. Phần 3 lược khảo một số nghiên cứu tiêu biểu có sử dụng ANN để dự báo lạm phát. Phần 4 trình bày dữ liệu và cấu trúc mạng ANN để dự báo lạm phát Việt Nam. Phần 5 trình bày kết quả dự báo và các kiểm định. Cuối cùng là kết luận.

<sup>1</sup> Jahn (2018) đã so sánh khả năng dự báo của ANN với các mô hình hồi quy dữ liệu bảng và đã chứng minh ANN có kết quả dự báo chính xác hơn, trên dữ liệu của 15 quốc gia công nghiệp hóa.

## 2. Phương pháp luận của ANN

### 2.1. Tổng quan

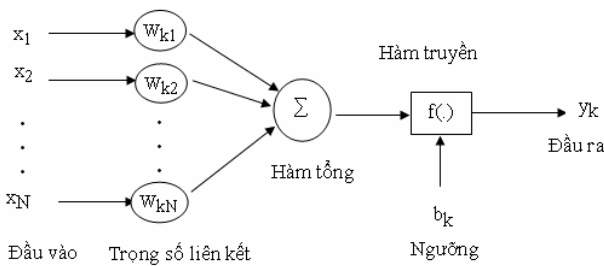
Mạng nơ ron nhân tạo (ANN – Artificial neural network) là một tập hợp các thuật toán phân tích dữ liệu cho phép xác định mối liên hệ toán học phức tạp giữa tập hợp các yếu tố ảnh hưởng (Input) với một biến số hoặc một tập hợp biến số mục tiêu (target). ANN là một ứng dụng trên nền tảng trí tuệ thông minh nhân tạo (Artificial intelligence - AI), cấu trúc của ANN và quá trình học tập, suy luận và tái tạo của nó có khả năng tự thích ứng linh hoạt (autofit) với nhiều loại dữ liệu khác nhau.

ANN xử lý thông tin phỏng theo cách thức xử lý thông tin của các hệ nơ ron sinh học trong não người. Nó được tạo nên từ một số lượng lớn các nơ ron kết nối với nhau thông qua các liên kết có trọng số, tạo thành một thể thống nhất, nhằm xử lý, phân tích một thông tin, một vấn đề. Một mạng nơ ron nhân tạo được cấu trúc cho một ứng dụng cụ thể (nhận dạng mẫu, phân loại dữ liệu,...) thông qua một quá trình huấn luyện-học (training) từ tập các mẫu huấn luyện. Dữ liệu đầu vào (input) sẽ chạy qua toàn bộ mạng nơ ron, sẽ được xử lý, tìm các mối liên hệ và tái tạo lại thành kết quả đầu ra (output). Các output này sẽ được so sánh với các dữ liệu mục tiêu (target) mà hệ thống đã được học trước đó. Nếu còn có sự sai lệch đáng kể giữa output và target, thì quá trình huấn luyện – học tập (training) lặp lại, các trọng số liên kết giữa các nơ ron lại được hiệu chỉnh để đưa ra output khác cải thiện hơn. Quá trình này liên tục lặp lại nhiều lần cho đến khi mang lại độ chệch (bias) bé nhất có thể giữa output và target. Như vậy, về bản chất quá trình huấn luyện - học (training) chính là quá trình hiệu chỉnh trọng số liên kết giữa các nơ ron cho đến khi đạt được một kết quả tối ưu, đó là tái tạo ra output tương tự target và có thể sử dụng để dự báo ngoài mẫu cho target.

### 2.2. Cấu trúc nơ ron nhân tạo<sup>2</sup>

Cấu trúc của một nơ ron nhân tạo tiêu biểu có các thành phần cơ bản như mô tả ở hình dưới.

<sup>2</sup> Nội dung về ANN tham khảo chính từ báo cáo của nhóm nghiên cứu Đại học Công nghệ thuộc Đại học Quốc Gia Hà nội (Đỗ Năng Toàn, et al., 2010).



**Sơ đồ 1. Cấu trúc của nơ ron nhân tạo**

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

Đầu vào cung cấp các tín hiệu vào (*input signals*) của nơ ron, các tín hiệu này thường được đưa vào dưới dạng một vector N chiều.

**Các liên kết:** Mỗi liên kết được thể hiện bởi một trọng số (gọi là trọng số liên kết – *Synaptic weight*). Trọng số liên kết giữa tín hiệu vào thứ j với nơ ron k thường được kí hiệu là  $w_{kj}$ . Thông thường, các trọng số này được khởi tạo một cách ngẫu nhiên ở thời điểm khởi tạo mạng và được cập nhật liên tục trong quá trình huấn luyện mạng.

**Hàm tổng (Summing function):** Thường dùng để tính tổng của tích các đầu vào với trọng số liên kết của nó.

$$\sum_{i=1}^m (w_i x_i) + bias$$

**Ngưỡng** (còn gọi là một độ lệch - *bias*): Ngưỡng này thường được đưa vào như một thành phần của hàm truyền.

**Hàm truyền (Transfer function):** Hàm này được dùng để giới hạn phạm vi đầu ra của mỗi nơ ron. Nó nhận đầu vào là kết quả của hàm tổng và ngưỡng đã cho. Thông thường, phạm vi đầu ra của mỗi nơ ron được giới hạn trong đoạn [0,1] hoặc [-1, 1]. Các hàm truyền rất đa dạng, có thể là các hàm tuyến tính hoặc phi tuyến<sup>3</sup>. Một số hàm truyền thường sử dụng trong các mô hình mạng nơ ron gồm: Symmetrical Hard Limit (*hardlims*), Linear (*purelin*), Saturating Linear (*satlin*) và Log-Sigmoid (*logsig*).

$$f(x) = \begin{cases} 1 & \text{if } \Sigma wx + b \geq 0 \\ 0 & \text{if } \Sigma wx + b < 0 \end{cases}$$

<sup>3</sup> Việc lựa chọn hàm truyền nào là tùy thuộc vào từng bài toán và kinh nghiệm của người thiết kế mạng.

**Đầu ra (output)** Là tín hiệu đầu ra của một nơ ron, với mỗi nơ ron sẽ có tối đa là một đầu ra.

Như vậy tương tự như nơ ron sinh học, nơ ron nhân tạo cũng nhận các tín hiệu đầu vào, xử lý (nhân các tín hiệu này với trọng số liên kết, tính tổng các tích thu được rồi gửi kết quả tới hàm truyền), và tái tạo tín hiệu đầu ra (là kết quả của hàm truyền).

**2.3. Cấu trúc mạng nơ ron nhân tạo**

Một mạng nơ ron có thể gồm 1 hoặc nhiều nơ ron<sup>4</sup>. Mỗi nơ ron là một đơn vị xử lý thông tin, sự liên kết giữa các nơ ron tạo thành cấu trúc mạng. Mặc dù mỗi nơ ron đơn lẻ có thể thực hiện những chức năng xử lý thông tin nhất định, sức mạnh của tính toán nơ ron chủ yếu có được nhờ sự kết hợp các nơ ron trong một kiến trúc thống nhất. Một mạng nơ ron là một mô hình tính toán được xác định qua các tham số: kiểu nơ ron (như là các nút nếu ta coi cả mạng nơ ron là một đồ thị), kiến trúc kết nối (sự tổ chức kết nối giữa các nơ ron) và thuật toán học (thuật toán dùng để học cho mạng). Các nơ ron kết nối với nhau bằng ma trận trọng số. Cách thức kết nối các nơ ron trong mạng xác định cấu trúc (*topology*) của mạng, vì vậy, có nhiều cấu trúc mạng khác nhau.

Cấu trúc tiêu biểu của mạng nơ ron gồm 3 lớp: đầu vào, lớp ẩn và đầu ra

Lớp đầu vào gồm một hay nhiều biến số đầu vào, cung cấp thông tin cho mạng nhân tạo. Đối với dự báo lạm phát và tăng trưởng kinh tế, các biến này có thể là: Tăng trưởng lượng cung tiền thực tế M2, Tỷ giá, tăng trưởng sản xuất công nghiệp... và chính số liệu lịch sử của lạm phát và tăng trưởng kinh tế.

Lớp đầu ra có thể gồm một hay nhiều biến số đầu ra. Trong nghiên cứu này lớp đầu ra có thể là một biến riêng lẻ, hoặc Lạm phát hoặc tăng trưởng GDP hoặc là một tổ hợp biến.

Sự liên kết giữa các yếu tố đầu vào và đầu ra được tính toán qua lớp ẩn trung gian với một hệ thống các hàm truyền và ngưỡng.

Dựa trên tính chất kết nối giữa các nơ ron đầu ra tới các nơ ron đầu vào, mạng được chia thành hai cấu trúc:

<sup>4</sup> Perception là mạng chỉ gồm duy nhất 1 nơ ron.


Kiến trúc truyền thẳng (*feedforward architecture*): là kiểu kiến trúc mạng không có các kết nối ngược trở lại từ các nơ ron đầu ra về các nơ ron đầu vào; mạng không lưu lại các giá trị output trước và các trạng thái kích hoạt của nơ ron. Các mạng nơ ron truyền thẳng cho phép tín hiệu di chuyển theo một đường duy nhất; từ đầu vào tới đầu ra, đầu ra của một tầng bất kì sẽ không ảnh hưởng tới tầng đó. Các mạng kiểu Perceptron là mạng truyền thẳng.

Cấu trúc mạng phản hồi (*Feedback architecture*): là kiểu kiến trúc mạng có các kết nối từ nơ ron đầu ra tới nơ ron đầu vào. Mạng lưu lại các trạng thái trước đó, và trạng thái tiếp theo không chỉ phụ thuộc vào các tín hiệu đầu vào mà còn phụ thuộc vào các trạng thái trước đó của mạng. Mạng Hopfield thuộc loại này.

Mạng nơ ron nhân tạo có thể có một tầng ẩn (*single hidden layer*) hoặc có nhiều tầng (*multi*

*hidden layer*). Được sử dụng rộng rãi nhất là cấu trúc mạng nhiều tầng truyền thẳng (MLP: Multi Layer Perceptron). Một mạng MLP tổng quát là mạng có  $n$  ( $n \geq 2$ ) tầng (thông thường tầng đầu vào không được tính đến): trong đó gồm một tầng đầu ra (tầng thứ  $n$ ) và  $(n-1)$  tầng ẩn. Mỗi nơ ron thuộc tầng sau liên kết với tất cả các nơ ron thuộc tầng liền trước nó. Đầu ra của nơ ron tầng trước là đầu vào của nơ ron thuộc tầng liền sau nó.

Mạng nơ ron nhiều tầng ẩn cho phép xử lý sâu thông tin, dữ liệu (deep learning), tuy nhiên, nhiều nghiên cứu đã chứng minh rằng chỉ với một lớp ẩn, mạng nơ ron nhân tạo vẫn có thể mô phỏng các hàm phi tuyến rất phức tạp với độ chính xác cao (Cybenko (1989), Hornik et al. (1989) and Zhang et al. (1998), CM (2011). (Demir, et al., 2015)<sup>5</sup>.



Sơ đồ 2. Cấu trúc mạng nơ ron nhiều tầng ẩn (Multi hidden layer)

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


#### 2.4. Quy trình phân tích dữ liệu với ANN

**Chọn biến.** Khi tạo mẫu cần chọn các biến sử dụng trong mô hình. Có 2 vấn đề cần quan tâm:

- Cần tìm hiểu cách biến đổi thông tin, dữ liệu sao cho có lợi cho mạng hơn: thông tin trước khi đưa vào mạng cần được biến đổi ở dạng thích hợp nhất, để mạng đạt được hiệu suất cao nhất.
- Chọn trong số các biến đã được biến đổi biến nào sẽ có lợi cho mạng nhất để đưa vào mô hình. Không phải bất kì thông tin nào về mẫu cũng có lợi cho mạng.

**Chuẩn bị dữ liệu.** Dữ liệu thường được chia thành 3 mẫu con, như sau:

Toàn bộ dữ liệu



<sup>5</sup> Demir và cộng sự (2015) đã so sánh khả năng dự báo của ANN với mô hình hồi quy bội, và đã chứng minh ANN có kết quả dự báo chính xác hơn, trên dữ liệu của Nhật Bản.



Trong đó gồm:

- Mẫu huấn luyện (training set) cung cấp thông tin cho quá trình học của trí tuệ nhân tạo.
- Mẫu kiểm tra (testing set) dùng để kiểm tra mô hình.
- Mẫu xác thực (validation set) dùng để xác thực lại kết quả huấn luyện.

Không có công thức nào cho tỷ lệ giữa các cỡ mẫu. Ở nhiều nghiên cứu, mẫu dữ liệu được chia theo tỷ lệ sau: 70% cho mẫu huấn luyện, 15% cho mẫu kiểm tra và 15% cho mẫu xác thực. Một số nghiên cứu khác sử dụng 100% mẫu cho việc huấn luyện, điều này phù hợp với các dữ liệu có chuỗi thời gian ngắn, nhiều biến động và phù hợp với mục tiêu dự báo ngoài mẫu.

#### **Xác định các tham số cho mạng nơ ron nhân tạo**

- Xác định số nơ ron
- Xác định số tầng ẩn
- Chọn hàm truyền

Không có công thức nào cho vấn đề xác định các tham số cho mạng nơ ron nhân tạo, nó phụ thuộc vào bài toán cụ thể và kinh nghiệm của người thiết kế mạng.

Kết thúc quá trình là bước huấn luyện mạng và khởi tạo trọng số tự động.

### **3. Lược khảo tiền nghiên cứu**

Adnan và Muhammad Nadeem (2007) sử dụng ANN với cấu trúc mạng truyền ngược-đơn biến để so sánh với mô hình truyền thống AR (1), ARIMA dựa trên tiêu chí đánh giá là RMSE. Dữ liệu được sử dụng là tỷ lệ lạm phát hàng tháng so với cùng kỳ năm trước trong giai đoạn 1993 – 2007 để dự báo cho lạm phát trong năm 2008 bằng mô hình mạng truyền thẳng với 12 lớp ẩn, sử dụng thuật toán Levenberg-Marquardt để huấn luyện ANN. Dữ liệu đầu vào được chuẩn hóa để nằm trong đoạn  $[-1;1]$  và sử dụng MATLAB để huấn luyện. Kết quả kiểm định ngoài mẫu của nghiên cứu trên cho thấy, chỉ tiêu RMSE của mô hình mạng phi tuyến thấp hơn rất nhiều so với mô hình AR (1) và mô hình ARIMA. Điều này cho thấy sự cải thiện trong hiệu quả dự báo của mô hình mạng so với

các mô hình truyền thống, tác giả cũng khẳng định ANN làm tốt hơn trong dự báo lạm phát như kết quả nghiên cứu của Emi Nakamura (2005) hay Choudhary và Haider (2008).

Haider and Hanif (2009) đã áp dụng mô hình mạng nơ ron nhân tạo đơn biến để dự báo lạm phát hàng tháng cho Pakistan bằng cách sử dụng phương pháp ANN cho năm 2008, trên cơ sở dữ liệu hàng tháng từ tháng 7 năm 1993 đến tháng 6 năm 2007. Mô hình dự báo tối ưu với 12 lớp ẩn, 12 độ trễ, cũng được huấn luyện bằng cách sử dụng thuật toán Levenberg-Marquardt. Haider và Hanif (2009) cho rằng việc lựa chọn số lượng lớp ẩn phù hợp là một nghệ thuật và điều này cũng khá quan trọng trong việc xây dựng 1 mô hình ANN dự báo tốt. Nếu như Haider và Hanif (2009) chỉ khai thác mô hình đơn biến (univariable) thì Thakur và cộng sự (2015) sử dụng cấu trúc mạng đa biến (multivariable input) trong đó tích hợp thêm 10 biến số vĩ mô có mối quan hệ với lạm phát, gồm: Tăng trưởng kinh tế, tỷ giá, xuất khẩu, lượng cung tiền M1, M2, dự trữ ngoại hối (foreign reserves), nhập khẩu, giá dầu, cán cân thương mại và giá vàng. Ngoài điểm khác biệt trên, nghiên cứu của Tharkur và cộng sự (2015) sử dụng cùng thuật toán Levenberg – Marquardt, cùng cấu trúc mạng “Feed forward back propagation neural network” và phần mềm MATLAB, tương tự Haider và Hanif (2009) để dự báo lạm phát cho India. Mô hình dự báo tối ưu của Tharkur rất khác với Haider và Hanif (2009) trong đó: dữ liệu được chia ngẫu nhiên theo tỷ lệ 0.7; 0.15 và 0.15 lần lượt dùng cho việc huấn luyện, kiểm tra và xác thực; mạng truyền thẳng được tạo với lớp đầu vào có 10 nút đầu vào, bốn lớp ẩn với 25 nơ ron và lớp đầu ra có một nơ ron. Hiệu suất xác nhận tốt nhất với MSE (mean squared error) 0.836 được tìm thấy ở vòng lặp 18 và việc đào tạo tiếp tục cho 6 lần lặp nữa trước khi nó dừng lại. Các đường đồ thị phản ánh kết quả đào tạo, xác nhận và kiểm tra là rất khớp nhau. Lạm phát thực tế và lạm phát dự đoán rất gần nhau, điều này xác định rõ ràng độ tin cậy và hiệu quả của mô hình đề xuất. Tharkur và cộng sự (2016) khuyến nghị rằng mô hình này được thiết kế theo đặc điểm nền kinh tế Ấn Độ, và nó có thể được thực hiện cho bất kỳ quốc gia phát triển hoặc đang phát

triển nào khác. Tuy nhiên, việc lựa chọn các yếu tố ảnh hưởng có thể khác nhau giữa các quốc gia. Ngoài ra, Tharkur và cộng sự (2016) không cung cấp thông tin về có xử lý dữ liệu trước khi đưa vào phân tích.

Tại Việt Nam, nghiên cứu của Nguyễn Khắc Hiếu và Nguyễn Thị Vân Anh (2014) đã 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. Nghiên cứu so sánh hiệu quả dự báo của mô hình mạng nơ ron 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 Việt Nam. Kết quả cho thấy, mô hình ANN dự báo trong mẫu tốt hơn mô hình ARDL ở cả 3 tiêu chí R<sup>2</sup>, RMSE và MAE. Đối với dự báo ngoài mẫu, mô hình ANN dự báo tốt hơn ở 2 tiêu chí RMSE và R<sup>2</sup>. Nhìn chung, mô hình ANN dự báo lạm phát tại Việt Nam tốt hơn mô hình ARDL. Kết quả phân tích của mô hình ANN và mô hình ARDL cho thấy có các yếu tố sau tác động đến lạm phát: yếu tố tâm lý, yếu tố mùa vụ, giá dầu, lượng cung tiền và lãi suất.

Bên cạnh đó nghiên cứu của Lê Đạt Chí (2011) trường Đại học kinh tế Thành phố Hồ Chí Minh, trong luận văn tiến sĩ với đề tài “Ứng dụng mô hình mạng nơ ron nhân tạo trong dự báo kinh tế - Trường hợp thị trường chứng khoán Việt Nam”: thực hiện dự báo giá chứng khoán trên thị trường chứng khoán Việt Nam, cụ thể là VNINDEX bằng cách tìm ra cấu trúc mạng ANN phù hợp nhất. Sử dụng quy trình 8 bước của 5 nhà nghiên cứu: Deboerk, Master, Blum và Nelson và Illingworth bằng phần mềm Neural solution 5.0.

Với dữ liệu biến đầu vào bao gồm: lạm phát, tỷ giá, lãi suất, sản lượng công nghiệp, cán cân thương mại, lượng cung tiền M2, tăng trưởng tín dụng để dự báo VN Index.

Với 104 quan sát, được chia theo tỷ lệ 70%-20%-10% dùng để huấn luyện mạng. Mô hình ba lớp: đầu vào là các biến vĩ mô, 1 lớp ẩn và

1 lớp đầu ra là kết quả Vnindex. Sử dụng thuật toán Levenberg – Marquardt (LM) và tiêu chuẩn MSE, Rsquare để xác nhận về độ phù hợp của mô hình. Và đưa ra được kết luận về cấu trúc ANN tuyến tính cho kết quả dự báo tốt hơn mô hình tuyến tính truyền thống. Ngoài ra, tác giả còn xây dựng mô hình mạng ANN phi tuyến khi khảo sát các biến tài chính, bằng mô hình MLN 9-3-1, 9-4-1, 9-5-1, 9-6-1. Cũng đưa đến kết luận ANN cho kết quả dự báo tốt hơn. Hay mô hình mạng truyền thẳng đa lớp MLF 4-4-1, 4-3-2-1, 4-4-3-1, CNN 4-3-1 sau một quá trình “thử và sai” cũng đem đến kết luận mạng ANN phù hợp nhất với dữ liệu và biến số đang khảo sát của luận án.

Những nghiên cứu trên cho thấy mô hình mạng nơ ron nhân tạo có thể được sử dụng rộng rãi như một công cụ lập kế hoạch để dự báo tỷ lệ lạm phát. Việc tạo ra một mô hình dự báo phù hợp thì cần chú ý tới việc lựa chọn biến đầu vào, mã hóa biến sau đó chọn số lớp ẩn, chia dữ liệu để huấn luyện và kiểm tra, chọn tiêu chí đánh giá phù hợp, số vòng lặp vừa đủ, tránh tốn nhiều thời gian, ngoài ra còn tránh hiện tượng overfitting. Tất cả các khâu trên đều khác biệt theo quốc gia và từng giai đoạn, nên có thể nói việc xây dựng mô hình dự báo ANN là một “nghệ thuật”. Nguyên tắc chính của mạng nơ ron phân tích tìm tín hiệu tương quan của các dữ liệu đầu vào với đầu ra, không tính đến mối quan hệ nhân quả giữa chúng. Đó vừa là điểm mạnh cũng là điểm hạn chế của ANN. Là điểm hạn chế bởi vì, giữa các biến số kinh tế vĩ mô, bên cạnh mối tương quan, còn có mối quan hệ nhân quả sâu sắc. Nếu như phần lớn các mô hình hồi quy đều hướng đến khai thác cấu trúc nhân quả từ dữ liệu thì ANN lại chỉ quan tâm đến các tín hiệu tương quan. Ngược lại, vì không bị gán bất kỳ mối quan hệ nhân quả nào trong các biến đầu vào đầu ra trong quá trình phân tích dữ liệu, giống như các mô hình hồi quy khác, ANN linh hoạt hơn rất nhiều trong việc lấy tín hiệu tương quan từ bộ dữ liệu đầu vào, đầu ra. So với các mô hình phân tích dữ liệu theo chuỗi thời gian, mô hình ANN không áp đặt bất kỳ hạn chế nào đối với các biến đầu vào. Ví dụ: đối với các mô hình có cùng họ với mô hình Vector autoregression (VAR, SVAR, ARDL), các biến đầu vào buộc phải dừng, thậm chí dừng cùng

bậc (ngoại trừ ARDL), với mô hình hồi quy, các biến đầu vào phải có phân phối chuẩn hóa. Hơn nữa, việc dự báo trung dài hạn (trên 5 năm) đối với các biến số vĩ mô như GDP và Lạm phát là rất khó, đặc biệt hạn chế đối với các mô hình hồi quy tích hợp nhiều biến số có quan hệ nhân quả với nhau. Trong các mô hình dự báo với chỉ một chuỗi dữ liệu đầu vào thì ANN có nhiều ưu điểm hơn hẳn trong phạm vi dự báo ngoài mẫu trung dài hạn (so với các mô hình dự báo họ ARIMA, ARCH/GARCH). Chính vì vậy, mặc dù ANN không phải là giải pháp phù hợp cho tất cả mọi vấn đề nhưng là lựa chọn đặc biệt khi phải xử lý các dữ liệu phức tạp, hoặc các mối quan hệ phi tuyến tính<sup>6</sup> giữa các biến đầu vào, đầu ra hoặc các chuỗi thời gian liên tục thay đổi xu hướng.

#### 4. Dữ liệu và cấu trúc ANN dự báo lạm phát Việt Nam

Dữ liệu sử dụng để dự báo lạm phát là chuỗi số phân trăm thay đổi của CPI kỳ này so với cùng kỳ năm trước<sup>7</sup>, trong thời gian từ 2000 đến 2018, số liệu theo năm. Dữ liệu của các biến trong mô hình được trích từ nguồn dữ liệu IFS-IMF, DOT-IMF, UN Trade Statistic, Thomson Reuters DataStream and General Statistics Office of Vietnam (GSO).

Riêng cơ sở dữ liệu về tỷ giá hối đoái thực hàng tháng (REER) và tỷ giá danh nghĩa hàng tháng (NEER) của Việt Nam là không có sẵn nên tác giả tự tính dựa trên trọng số là giá trị thương mại của Việt Nam với 19 quốc gia đối tác hàng đầu với Việt Nam, gồm Nhật Bản, Đức, Pháp, Anh, Hà Lan, Nga, Thụy Sĩ, Ý, Bỉ, Hoa Kỳ, Hàn Quốc, Trung Quốc, Singapore, Malaysia, Thái Lan, Indonesia, Hồng Kông, Ấn Độ và Philippines. Tổng giao dịch của 19 quốc gia này với Việt Nam đạt tới 75% tổng giao dịch đối ngoại của Việt Nam trong 5 năm qua (cập nhật đến tháng 3 năm 2015). Các trọng số được tính bằng cách sử dụng dữ liệu giao dịch từ DOT - IMF và được cố định trong giai đoạn 2010-2015.

Quá trình xây dựng mô hình ANN được thực hiện như sau:

#### Bước 1: Lựa chọn các biến đầu vào

Theo các nghiên cứu trước đó (Apergis 2004; Caputo & Magendzo 2011; Dhakal et al. 1994; Font & Grau 2012) cùng với đặc tính của thị trường Việt Nam và tính khả dụng của dữ liệu, nghiên cứu này xem xét các biến số sau: tốc độ tăng trưởng hàng tháng của tiền (M2), tốc độ tăng trưởng tín dụng trong nước hàng tháng (CREDIT), tốc độ tăng trưởng tỷ giá hối đoái thực hàng tháng (REER), tốc độ tăng trưởng hàng tháng chỉ số sản xuất công nghiệp (IIP) và tốc độ tăng trưởng tỷ giá danh nghĩa hàng tháng (NEER).

Mô hình sẽ tính dự báo giá trị chuỗi  $y(t)$  dựa trên các giá trị trong quá khứ  $d$  của chuỗi  $x(t)$ . Theo đó, khi chỉ tiêu  $R$  càng cao thì khả năng dự đoán của mô hình càng tốt.

**Bảng 1. Kết quả kiểm tra các biến**

| Variables | R-total | R-validation |
|-----------|---------|--------------|
| M2        | 0.753   | 0.542        |
| CREDIT    | 0.747   | 0.460        |
| REER      | 0.433   | 0.357        |
| IIP       | 0.460   | 0.200        |
| NEER      | 0.350   | 0.001        |


*Ghi chú: M2 Tỷ lệ tăng trưởng lượng cung tiền thực tế theo tháng; CREDIT tỷ lệ tăng trưởng tín dụng nội địa theo tháng; REER tỷ lệ tăng trưởng tỷ giá hiệu lực thực theo tháng; IP Tỷ lệ tăng trưởng sản xuất công nghiệp theo tháng; NEER tỷ lệ tăng trưởng tỷ giá hiệu lực danh nghĩa theo tháng.*

*Nguồn: Phân tích của nhóm tác giả*

Dữ liệu được hiển thị ở bảng trên cho thấy, M2 có hệ số R-validation cao nhất. Ngoài ra, Hình 1 cho thấy mối tương quan chéo cao giữa M2 và lạm phát. Do đó, M2 được chọn để dự báo lạm phát Việt Nam.

<sup>6</sup> Ước lượng các mối quan hệ phi tuyến luôn là hạn chế của các mô hình hồi quy không trên nền tảng ANN.

<sup>7</sup> Tên đầy đủ của chuỗi số trong dữ liệu IMF là: Prices, Consumer Price Index, All items, Percentage change, Corresponding period previous year, Percent.



**Hình 1. Tốc độ tăng trưởng lượng cung tiền thực tế (M2) và tỷ lệ lạm phát (INF)**

*Nguồn: Phân tích của nhóm tác giả*

Bước 2: Việc lựa chọn mẫu huấn luyện và kiểm tra

Sau khi biến đầu vào được chọn một cách thích hợp, các mẫu thử nghiệm và huấn luyện được xác định. Trong nghiên cứu của chúng tôi, các vectơ đầu vào và vectơ đầu ra sẽ được chia ngẫu nhiên thành ba bộ bằng cách sử dụng các tham số chia như sau: (1) 65% kích thước mẫu sẽ được sử dụng cho huấn luyện; (2) 20% kích thước mẫu sẽ được sử dụng để xác nhận và ngừng đào tạo trước khi bị hiện tượng overfitting; (3) 15% kích thước mẫu cuối cùng sẽ được sử dụng như một kiểm tra.

Bước 3: Lựa chọn độ trễ

Xác định độ trễ là 1 bước quan trọng bởi trong việc dự báo chuỗi thời gian vì nó chưa đựng thông tin quan trọng về cấu trúc tự tương quan trong dữ liệu. Bảng 2 chỉ ra rằng độ trễ của 17 và 15 là tối ưu với tiêu chí AIC và LR. Tuy nhiên, kết quả của mối tương quan chéo giữa INF và M2 cho thấy số độ trễ là 16 là tối ưu. Do đó, số độ trễ 16 được chọn cho mô hình của chúng tôi.

**Bảng 2. Kết quả kiểm tra độ trễ**

| Lags | LR      | AIC   |
|------|---------|-------|
| 0    |         | 4.288 |
| 1    | 105.570 | 3.772 |
| 2    | 13.312  | 3.744 |
| 3    | 8.304   | 3.742 |
| 4    | 1.554   | 3.777 |
| 5    | 5.299   | 3.791 |
| 6    | 13.831  | 3.760 |
| 7    | 9.842   | 3.750 |
| 8    | 2.007   | 3.782 |
| 9    | 6.717   | 3.789 |
| 10   | 1.082   | 3.825 |
| 11   | 12.675  | 3.801 |
| 12   | 48.126  | 3.588 |
| 13   | 33.725  | 3.452 |
| 14   | 5.729   | 3.464 |
| 15   | 14.257  | 3.431 |
| 16   | 7.870   | 3.432 |
| 17   | 9.463   | 3.424 |
| 18   | 6.821   | 3.430 |
| 19   | 2.592   | 3.459 |
| 20   | 5.242   | 3.474 |

*Nguồn: Ước tính dựa trên tính toán của tác giả*

Bước 4: Lựa chọn số lớp ẩn

Theo nghiên cứu của Cybenko (1989), Hornik, Stinchcombe và White (1989), Zhang, Patuwo và Hu (1998), mô hình ANN của chúng tôi được cấu trúc với một số lớp ẩn đủ để ANN ước tính bất kỳ hàm phi tuyến tính phức tạp nào với độ chính xác mong muốn. Chúng tôi được xây dựng ANN với 32 số nút lớp ẩn do các lý do sau: (1) mạng có số nút ẩn bằng với số nút đầu vào cho thấy kết quả dự báo tốt hơn trong một số nghiên cứu (Chakraborty et al. 1992; Sharda & Patil 1992). Trong trường hợp của chúng tôi, đó là  $16 * 2 = 32$  nút (2) bằng cách chạy thử nghiệm (thử và thử), số nút ẩn của 32 cho kết quả tốt nhất.

Mô hình hồi quy phi tuyến sau đây được hình thành:

$$y_t = f(y_{t-1}, \dots, y_{t-d}, x_{t-1}, \dots, x_{t-d}) \quad (1)$$

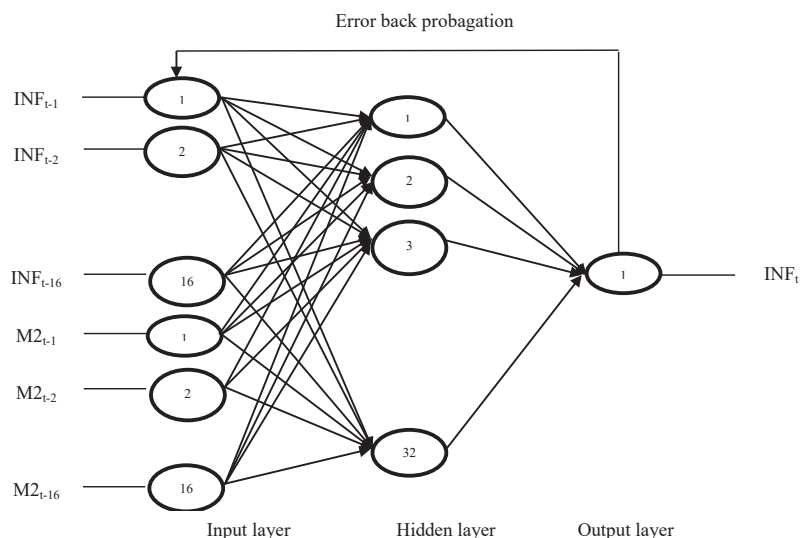


Với  $y$  là chuỗi thời gian mục tiêu của tốc độ tăng trưởng hàng tháng lạm phát (INF)

$x$  là biến chuỗi thời gian ngoại sinh - tốc độ tăng trưởng lượng cung tiền hàng tháng (M2)

$d$  là số độ trễ 16 như được xác định như trên

Mạng chuyển tiếp được tạo ra với 16 nút đầu vào cho mỗi biến, 2 lớp ẩn với hai nút cho mỗi và 1 nút đầu ra. Cấu trúc ANN của mô hình đề xuất trong nghiên cứu này được minh họa trong Hình 2.




**Hình 2. Mô hình đa chuỗi đề xuất**

*Nguồn: Phân tích của nhóm tác giả*

### 5. Kết quả

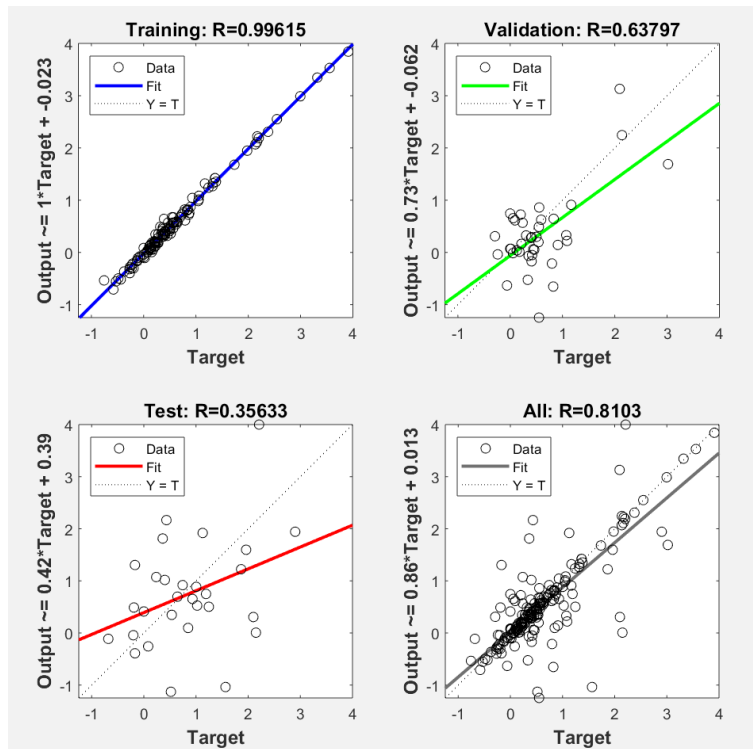
Mô hình được đề xuất sử dụng thuật toán Levenberg-Marquest, kết quả đào tạo được mô tả trong hình 3, các đường cong đào tạo, xác nhận và kiểm tra là tương tự nhau. Hiệu suất xác nhận tốt nhất với chỉ số sai số bình phương trung bình (MSE) là 0,403 được tìm thấy ở epoch 2 và việc đào tạo tiếp tục cho năm lần lặp nữa trước khi nó dừng lại. Quan trọng hơn, hiệu suất đào tạo ghi nhận không hiện tượng overfitting.



**Hình 3: Kết quả huấn luyện mạng ANN**

*Nguồn: Phân tích của nhóm tác giả*

Bước tiếp theo của việc xác thực mạng ANN bao gồm tạo biểu đồ hồi quy cho biết mối quan hệ giữa kết quả đầu ra của mạng (tỷ lệ lạm phát quan sát được từ ANN) và các mục tiêu (tỷ lệ lạm phát dự đoán) trong đào tạo, xác nhận, kiểm tra và toàn bộ dữ liệu. Theo lý thuyết, kết quả đầu ra mạng và các mục tiêu sẽ hoàn toàn bằng nhau nếu việc đào tạo là hoàn hảo. Tuy nhiên, mối quan hệ này hiếm khi xảy ra trong thực tế. Như trong hình 4, ba trục tương ứng thể hiện dữ liệu huấn luyện, xác nhận và thử nghiệm. Đường nét đứt trong mỗi trục biểu thị kết quả tối ưu có nghĩa là đầu ra bằng với mục tiêu. Trong khi đó, đường liền nét thể hiện đường hồi quy tuyến tính phù hợp nhất giữa đầu ra và mục tiêu. Ngoài ra, giá trị R cho thấy mối quan hệ giữa đầu ra và mục tiêu. Theo đó,  $R = 1$  đề xuất mối quan hệ tuyến tính chính xác giữa đầu ra và mục tiêu trong khi R gần bằng 0, cho rằng không có mối quan hệ tuyến tính giữa chúng (Thakur, Bhattacharyya & Mondal 2016). Thuật toán được chấm dứt theo thủ tục dừng sớm.




**Hình 4. Đào tạo mô hình hồi quy**

*Nguồn: Phân tích của nhóm tác giả*

Hình 4 cho thấy: mẫu đào tạo cho thấy đầu ra mạng và mục tiêu gần như giống hệt nhau vì giá trị R gần bằng 1. Điều này cho thấy mô hình đề xuất là đáng tin cậy và hiệu quả.

Hơn nữa, chúng tôi tiếp tục thực hiện tự động sửa lỗi mô hình như được trình bày trong hình 5. Điều này cũng cung cấp kiểm tra chéo về hiệu suất mạng. Ngoại trừ độ trễ bằng 0, thì tự tương quan nằm trong quanh 0 với độ tin cậy 95%. Nói cách khác, mô hình ANN của chúng tôi là phù hợp.

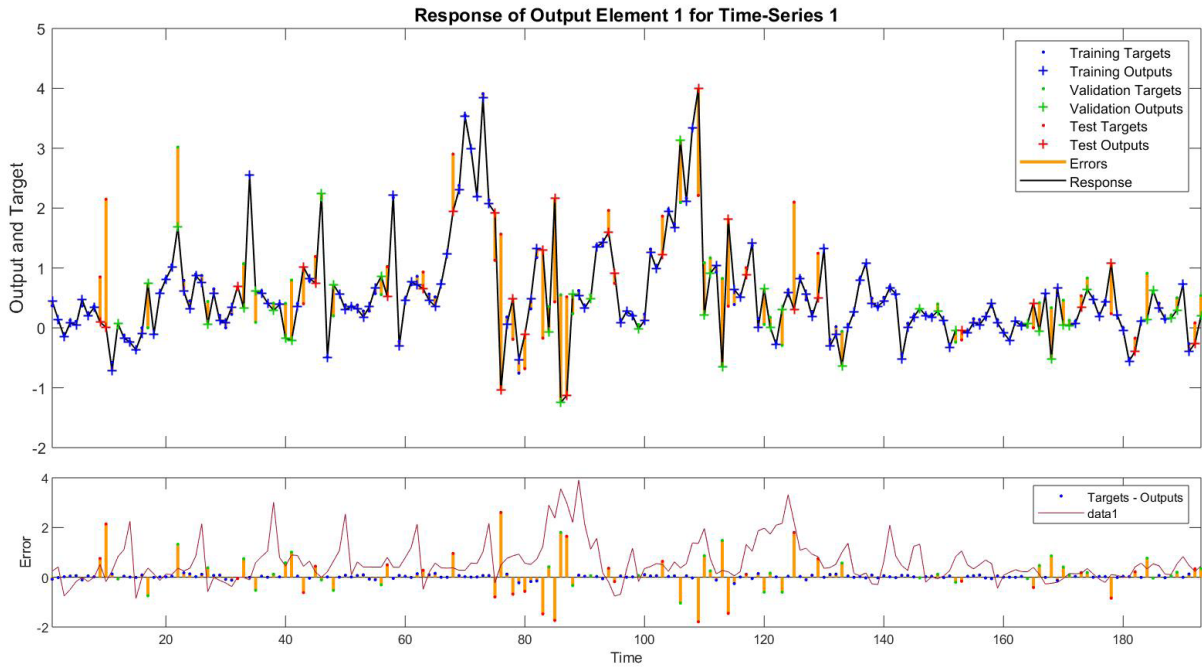


**Hình 5. Tự tương quan của mô hình đề xuất**

*Nguồn: Phân tích của nhóm tác giả*

Hình 6 trình bày kết quả của đầu ra, mục tiêu và sai lệch của chuỗi thời gian. Theo đó, các điểm thời gian đã được chọn để đào tạo, kiểm tra và xác nhận có thể được xác định. Điều quan trọng cần lưu ý là những điểm này được chọn ngẫu nhiên trong bước đầu tiên. Khi dữ liệu được cập nhật, mô hình ANN được đề xuất có thể tự động khớp với tập dữ liệu mới. Đó là một trong những thế mạnh của việc sử dụng các mô hình ANN.

Phần dưới của hình 6 biểu thị độ lệch của một số điểm dự đoán. Các điểm này nằm ở các điểm 80-90 và 110-130 tương ứng với hai cú sốc tài chính (cuộc khủng hoảng tài chính toàn cầu 2008-2009 và cuộc khủng hoảng nợ châu Âu 2011-2014) - sự gia tăng bất thường của lạm phát Việt Nam. Có thể thấy, trong thời kỳ các cú sốc tài chính, xu hướng của các sai lệch dự báo là tương đối cao so với toàn bộ cỡ mẫu. Tuy nhiên, những sai lệch này không nghiêm trọng vì có khoảng dưới 20 điểm lỗi trên 200 quan sát.




**Hình 6. Kết quả đầu ra của mô hình ANN**

*Nguồn: Phân tích của nhóm tác giả*

Hình 7 trình bày mô hình dự báo xuất phát từ các bước trên. Lạm phát dự báo được thực hiện cho toàn bộ mẫu mà không xác định mẫu nào đang thử nghiệm, xác nhận và đào tạo. Có thể

thấy, chuỗi quan sát (đường màu xanh) và chuỗi dự đoán (màu đỏ) rất gần nhau. Do đó, điều này chứng tỏ rằng mô hình đề xuất là chính xác, hiệu quả và có thể áp dụng.



**Hình 7. Tỷ lệ lạm phát theo dự đoán và quan sát tại Việt Nam**

*Nguồn: Phân tích của nhóm tác giả*

Dữ liệu trong Bảng 3 thể hiện thêm về tính toán lạm phát thực tế và dự đoán trong nhiều tháng từ tháng 1 năm 2017 đến tháng 5 năm 2018 hoàn toàn bằng với lạm phát dự đoán trong cùng

tháng được lấy từ mô hình đề xuất của chúng tôi. Vậy nên độ tin cậy và hiệu quả của mô hình đề xuất của chúng tôi được xác nhận.

**Bảng 3. Lạm phát thực tế và dự đoán từ tháng 1 năm 2017 đến tháng 5 năm 2018**

| Time (Month/Day/Year) | Observed inflation | Predicted inflation |
|-----------------------|--------------------|---------------------|
| 1/1/2017              | 0.458              | -0.239              |
| 2/1/2017              | 0.237              | 0.237               |
| 3/1/2017              | 0.208              | 0.208               |
| 4/1/2017              | 0.000              | 0.000               |
| 5/1/2017              | -0.529             | 0.008               |
| 6/1/2017              | -0.171             | -0.775              |
| 7/1/2017              | 0.114              | 0.276               |
| 8/1/2017              | 0.912              | 0.912               |
| 9/1/2017              | 0.593              | 1.626               |
| 10/1/2017             | 0.412              | 0.412               |
| 11/1/2017             | 0.131              | 0.131               |
| 12/1/2017             | 0.214              | 0.214               |
| 1/1/2018              | 0.502              | 0.502               |
| 2/1/2018              | 0.730              | 0.729               |
| 3/1/2018              | -0.266             | 0.836               |
| 4/1/2018              | 0.083              | 0.083               |
| 5/1/2018              | 0.542              | 0.542               |

*Nguồn: Ước tính dựa trên tính toán của tác giả*

### 6. Kết luận

Lạm phát là một trong số ít các biến số vĩ mô quan trọng nhất ở phạm vi quốc gia. Việc phân tích hành vi, diễn biến của nó trở thành nền tảng cho mọi nền kinh tế và cho các quyết định khác nhau ở cả cấp độ Chính phủ lẫn tư nhân. Tuy nhiên, sự phức tạp trong sự vận động của các nhân tố tác động bên trong bên ngoài lạm phát khiến việc dự báo biến số này luôn là một thách thức lớn. Chính vì vậy, rất nhiều mô hình đã được phát triển trong sự nỗ lực không ngừng nhằm cải thiện tính chính xác.

Dự báo trên nền tảng mạng nơ ron nhân tạo (artificial neural network - ANN) là một điểm quan trọng trong sự phát triển của các mô hình dự báo. Mặc dù việc sử dụng ANN trong lĩnh vực kinh tế vẫn còn ở giai đoạn khởi động so với các lĩnh vực khác, nhưng tính ưu việt của nó đã sớm được chứng minh. Moshiri và Cameron (2000) đã khẳng định khả năng dự báo lạm phát của mô hình ANN (back propagation neural network) không thua kém các mô hình kinh tế

lượng truyền thống và thậm chí tốt hơn trong một số trường hợp. Nakamura (2005) đánh giá tính hữu ích của mạng neuron nhân tạo bằng việc dự báo lạm phát ngoài mẫu trên dữ liệu của Mỹ. Kết quả cho thấy trong ngắn hạn (1 hoặc 2 quý) ANN vượt trội hơn hẳn so với các mô hình tự hồi quy. Sự đơn giản trong cấu trúc của ANN và quy trình ước lượng chuyên biệt chính là hai nhân tố vai trò quan trọng quyết định tính dự báo chính xác của ANN. Khả năng dự báo tốt của ANN tiếp tục được chứng minh qua nghiên cứu của Binner, Bissoondeeal, Elger, Gazely, and Mullineux (2005), trong đó vận dụng nhiều mô hình để dự báo lạm phát và đã xác định mô hình mang lại kết quả tối ưu là ANN. Theo các tác giả, các mô hình dự báo tuyến tính (ARIMA và VAR) không giải quyết được các mối quan hệ phi tuyến tồn tại trong dữ liệu lạm phát. Trong khi đó ANN – đại diện tiêu biểu cho các mô hình phi tuyến – hoàn toàn khắc phục được hạn chế đó, có thể cung cấp các dự báo trong mẫu lẫn ngoài mẫu tốt với độ chính xác cao hơn rõ rệt. Các mô hình tuyến tính chỉ đơn giản là một tập hợp con của các mô hình ANN mà thôi. Sai số dự báo lạm phát trong trường hợp Pakistan của ANN thấp nhất và cách biệt so với AR(1) và ARIMA (Haider & Hanif, 2009). Thử nghiệm sức mạnh dự báo lạm phát theo tháng của ANN, Choudhary and Haider (2012) đã lần lượt vận dụng ANN trên dữ liệu của 28 quốc gia trong khối OECD. Nhiều phiên bản ANN đã được khai thác. Kết quả khẳng định ANN hoàn toàn là công cụ tin cậy để dự báo lạm phát. Các dự báo ngoài mẫu, ngắn hạn của ANN có độ chính xác cao, với tỷ lệ dự báo đúng đạt 45% trong số 28 quốc gia trong mẫu. Trong khi đó, các mô hình AR1 chỉ đạt tỷ lệ chính xác là 23% mà thôi.

Trên nền tảng đó, nghiên cứu này chọn sử dụng mô hình mạng nơ ron nhân tạo (ANN) để dự báo tỷ lệ lạm phát ở Việt Nam. Kết quả dự báo của của nghiên cứu này có độ chính xác tương đối cao, vì vậy, một lần nữa khẳng định sự lựa chọn ANN vào dự báo lạm phát Việt Nam và phù hợp. Trên cơ sở đó, nghiên cứu khuyến nghị việc vận dụng ANN để dự báo, để cung cấp những thông tin, số liệu quan trọng trong việc xây dựng các kịch bản kinh tế cho giai đoạn 5 năm, tầm nhìn đến 10 năm của Việt



Nam. Ngoài ra, kết quả nghiên cứu cũng góp phần bổ sung thêm vào hệ thống minh chứng khoa học về tính hiệu quả của ANN trong dự báo biến số kinh tế vĩ mô này.

Bên cạnh kết quả nêu trên, nghiên cứu cũng đặt ra nhiều vấn đề cần lưu ý và tiếp tục nghiên cứu trong tương lai. Dự báo lạm phát là một công việc khó khăn và để có kết quả tốt đòi hỏi phải sử dụng cân bằng các mô hình khác nhau, khai thác hiệu quả các biến số và đòi hỏi một lượng lớn dữ liệu có chất lượng. Đồng thời, lý thuyết kinh tế luôn đóng một vai trò quan trọng trong việc lựa chọn biên, thiết lập cấu trúc các mô hình dự báo. Tính chính xác của dự báo được tăng lên đáng kể nếu có sự phối hợp chặt chẽ giữa lý thuyết kinh tế, mô hình thực nghiệm

một cách phù hợp với tính chất dữ liệu. Xuyên suốt lịch sử phát triển của các mô hình dự báo, mạng nơ ron nhân tạo hiện có thể xem là công cụ dự báo cho phép tích hợp được các yếu tố nêu trên. Hơn thế nữa, ANN đã và đang phát triển thành một hệ thống gồm nhiều mô hình dự báo tiên tiến, tích hợp với các mô hình khác tạo thành 1 hệ các mô hình dự báo lai (hybrid model<sup>8</sup>) có thể được sử dụng để dự báo, phân loại, thiết lập v.v. phục vụ cho nhiều mục đích và có khả năng tìm ra giải pháp thích hợp cho nhiều vấn đề dự báo khác nhau. Việc khai thác các mô hình hybrid đó sẽ là bước phát triển tiếp theo cho nghiên cứu này.

---

<sup>8</sup> Ví dụ: Mô hình ANN kết hợp ARIMA

## Tài liệu tham khảo

### Tiếng Việt

Lê Đạt Chí, 2011, ‘Ứng dụng mô hình mạng nơ ron nhân tạo trong dự báo kinh tế Trường hợp thị trường chứng khoán Việt Nam’, *Luận án tiến sĩ*, Đại học Kinh tế Thành phố Hồ Chí Minh.

Nguyễn Khắc Hiếu và Nguyễn Thị Vân Anh, 2014, ‘Dự báo lạm phát tại Việt Nam bằng mô hình mạng nơ ron nhân tạo’, *Tạp chí Phát triển Kinh tế*, vol. 286

### Tiếng Anh

Adnan Haider & Muhammad Nadeem Hanif, 2007, ‘Inflation Forecasting in Pakistan using Artificial Neural Networks’, *MPRA Paper No.* 14645.

Apergis, N 2004, ‘Inflation, output growth, volatility and causality: evidence from panel data and the G7 countries’, *Economics Letters*, vol. 83, no. 2, pp. 185-191.

Caputo, R & Magendzo, I 2011, ‘Do exchange rate regimes matter for inflation and exchange rate dynamics? The case of Central America’, *Journal of Latin American Studies*, vol. 43, no. 2, pp. 327-354.

Chakraborty, K, Mehrotra, K, Mohan, CK & Ranka, S 1992, ‘Forecasting the behavior of multivariate time series using neural networks’, *Neural Networks*, vol. 5, no. 6, pp. 961-970.

Choudhary, M. A., & Haider, A. (2012). Neural network models for inflation forecasting: an appraisal. *Applied Economics*, 44(20), 2631-2635. doi: 10.1080/00036846.2011.566190

Cybenko, G 1989, ‘Approximation by superpositions of a sigmoidal function’, *Mathematics of Control, Signals and Systems*, vol. 2, no. 4, pp. 303-314.

Dhakal, D, Kandil, M, Sharma, SC & Trescott, PB 1994, ‘Determinants of the Inflation rate in the United States: A VAR Investigation’, *The Quarterly Review of Economics and Finance*, vol. 34, no. 1, pp. 95-112.

Font, B & Grau, AJ 2012, ‘Exchange rate and inflation risk premia in the EMU’, *Quantitative Finance*, vol. 12, no. 6, pp. 907-931.

Haider, A & Hanif, MN 2009, ‘Inflation forecasting in Pakistan using artificial neural networks’, *Pakistan Economic and Social Review*, vol. 47, no. 1, pp. 123-138.

Hornik, K, Stinchcombe, M & White, H 1989, ‘Multilayer feedforward networks are universal approximators’, *Neural Networks*, vol. 2, no. 5, pp. 359-366.

Nakamura, E. (2005). Inflation forecasting using a neural network. *Economics Letters*, 86(3), 373-378. doi: <https://doi.org/10.1016/j.econlet.2004.09.003>

Sharda, R & Patil, RB 1992, ‘Connectionist approach to time series prediction: an empirical test’, *Journal of Intelligent Manufacturing*, vol. 3, no. 5, pp. 317-323.

Thakur, GSM, Bhattacharyya, R & Mondal, SS 2016, ‘Artificial neural network based model for forecasting of inflation in India’, *Fuzzy Information and Engineering*, vol. 8, no. 1, pp. 87-100.

Zhang, G, Patuwo, BE & Hu, MY 1998, ‘Forecasting with artificial neural networks:: The state of the art’, *International Journal of Forecasting*, vol. 14, no. 1, pp. 35-62.