



Original Article

Forecasting the EUR/USD exchange rate using EEMD in combination with LSTM Algorithm

Tran Thi Tuan Anh*, Nguyen Cong Quoc

University of Economics Ho Chi Minh City

59C, Nguyen Dinh Chieu Street, District 3, Ho Chi Minh City, Vietnam

Received: January 29, 2024

Revised: May 22, 2024; Accepted: June 25, 2024

Abstract: Predicting currency exchange rates, particularly for major currencies such as USD and EUR, poses considerable difficulty owing to the complex nature of financial temporal data. This paper utilizes a combined approach that merges the ensemble empirical mode decomposition (EEMD) technique with the long short-term memory (LSTM) neural network to anticipate the sequence of EUR/USD exchange rates. In this fusion method, the EUR/USD rate is decomposed into several intrinsic mode functions (IMFs), which serve as inputs for the LSTM network to perform predictive analysis. The forecasted exchange rate is derived by aggregating the predicted values of these IMFs. Validation results demonstrate that the EEMD-LSTM combined model significantly outperforms in predicting the closing price of the EUR/USD exchange rate. This finding highlights the potential of the EEMD-LSTM combined algorithm in forecasting other complex financial series.

Keywords: EUR/USD exchange rate, ensemble empirical mode decomposition (EEMD), long short-term memory (LSTM).

* Corresponding author

E-mail address: anhttt@ueh.edu.vn

<https://doi.org/10.57110/jebvn.v3i1.294>

Copyright © 2024 The author(s)

Licensing: This article is published under a CC BY-NC 4.0 license.

Dự báo tỷ giá hối đoái EUR/USD bằng thuật toán kết hợp EEMD-LSTM

Trần Thị Tuấn Anh*, Nguyễn Công Quốc

Đại học Kinh tế Thành phố Hồ Chí Minh

Số 59C, đường Nguyễn Đình Chiểu, Quận 3, Thành phố Hồ Chí Minh, Việt Nam

Nhận ngày 29 tháng 1 năm 2024

Chỉnh sửa ngày 22 tháng 5 năm 2024; Chấp nhận đăng ngày 25 tháng 6 năm 2024

Tóm tắt: Việc dự báo tỷ giá hối đoái, đặc biệt là tỷ giá giữa các tiền tệ quan trọng như USD và EUR thường gặp khó khăn do đặc điểm phức tạp của chuỗi thời gian tài chính. Nghiên cứu này sử dụng mô hình kết hợp giữa phương pháp phân tách các chế độ thực nghiệm tổng hợp (EEMD) và mạng bộ nhớ dài – ngắn hạn (LSTM) để dự báo chuỗi tỷ giá EUR/USD. Trong cách kết hợp này, tỷ giá hối đoái EUR/USD được phân tách thành nhiều hàm chế độ nội tại – đây được xem là thành phần đầu vào của mạng LSTM để thực hiện dự báo. Kết quả dự báo tỷ giá hối đoái được tính toán bằng cách lấy tổng tất cả giá trị dự báo của các hàm chế độ nội tại. Kết quả kiểm định cho thấy thuật toán kết hợp EEMD-LSTM là thuật toán ưu việt trong việc dự báo giá đóng cửa tỷ giá hối đoái EUR/USD. Kết quả này cho thấy tiềm năng ứng dụng thuật toán kết hợp EEMD-LSTM để dự báo các chuỗi tài chính phức tạp khác.

Từ khóa: Tỷ giá hối đoái EUR/USD, EEMD, LSTM.

1. Giới thiệu

Thị trường ngoại hối đóng vai trò rất quan trọng trên thị trường toàn cầu cũng như đối với các quốc gia. Thông qua thị trường ngoại hối, người giao dịch có thể biết được sức mạnh tổng thể về tiền tệ của quốc gia này so với tiền tệ của quốc gia khác (Vykylyuk, Vuković, & Jovanović, 2013). Không giống như thị trường chứng khoán, thị trường ngoại hối là một trong những thị trường phức tạp nhất do mối liên hệ giữa các cặp tiền tệ có thể biến động rất nhiều, biến động thường có dạng phi tuyến tính và khó dự đoán (Bussiere, 2013). Việc dự báo tỷ giá EUR/USD lại càng là một nhiệm vụ khó khăn bởi đây là hai đồng tiền mạnh trong nền kinh tế thế giới (Pérez-Rodríguez, 2006). Xét về khía cạnh kinh tế, tỷ giá EUR/USD chịu ảnh hưởng của nhiều yếu tố kinh tế như tăng trưởng GDP, lạm phát, thị trường lao động và chính sách tiền tệ của cả cộng

đồng chung châu Âu và Hoa Kỳ (Ribeiro, 2016). Các chỉ số kinh tế như lợi suất, bán lẻ, sản lượng công nghiệp và số liệu về việc làm cũng ảnh hưởng đến quyết định giao dịch của các nhà đầu tư (Bukowski & Bukowska, 2017). Ngoài ra, yếu tố chính trị cũng làm cho tỷ giá EUR/USD trở nên khó dự đoán. Bất kỳ một biến động nào trong chính trị của các quốc gia thành viên sử dụng đồng Euro và Hoa Kỳ cũng có thể ảnh hưởng đến tỷ giá EUR/USD (Janetzko, 2014). Thêm vào đó, còn có sự tác động về điều kiện pháp lý, tâm lý nhà đầu tư... Tất cả các yếu tố này cùng nhau tạo ra một môi trường dự báo phức tạp cho tỷ giá EUR/USD, dự báo có thể bị ảnh hưởng bởi những yếu tố không dự đoán được và biến động không lường trước trên thị trường.

Mặc dù khó khăn nhưng việc dự báo tỷ giá EUR/USD thực sự cần thiết và hữu ích cho các quyết định đầu tư của cá nhân, quyết định giao dịch của doanh nghiệp và các chính sách tiền tệ

* Tác giả liên hệ

Địa chỉ email: anhttt@ueh.edu.vn

<https://doi.org/10.57110/jebvn.v3i1.294>

Bản quyền © 2024 (Các) tác giả

Bài báo này được xuất bản theo CC BY-NC 4.0 license.

của chính phủ. Các doanh nghiệp hoạt động quốc tế thường sử dụng USD và EUR trong giao dịch nên phải đối mặt với rủi ro liên quan đến biến động tỷ giá. Dự báo tỷ giá EUR/USD giúp doanh nghiệp tối ưu hóa các chiến lược quản lý rủi ro tài chính, đưa ra quyết định phù hợp về giá cả sản phẩm và tiếp thị quốc tế. Chính phủ cũng quan tâm đến kết quả dự báo tỷ giá EUR/USD để định hình chính sách tài chính và tiền tệ quốc gia. Vì vậy, việc tìm ra thuật toán hữu hiệu để dự báo biến động của tỷ giá EUR/USD được nhiều nhà nghiên cứu quan tâm.

Có nhiều phương pháp được sử dụng để dự báo tỷ giá hối đoái và mỗi phương pháp đều có những thế mạnh riêng. Nghiên cứu này sử dụng mô hình dự báo kết hợp giữa thuật toán phân tách EEMD và thuật toán học sâu LSTM. Thuật toán LSTM khá nổi tiếng với việc học các hình mẫu từ một lượng lớn dữ liệu thô mà không cần dựa vào kiến thức trước đó, vì vậy nó trở thành thuật toán có nhiều tiềm năng trong việc dự báo chuỗi thời gian tài chính. Cách kết hợp này sẽ giúp nâng cao độ chính xác của dự báo tỷ giá hối đoái (Wu & Zhu, 2019; Yan & Aasma, 2020).

2. Tổng quan nghiên cứu

Việc nghiên cứu sự biến động và dự báo tỷ hối đoái đã được nhiều nhà nghiên cứu quan tâm. Có nhiều hướng nghiên cứu khác nhau có thể được ứng dụng để thực hiện các dự báo này.

Phổ biến nhất có thể kể đến các phương pháp dựa trên mô hình thống kê như ARIMA (AutoRegressive Integrated Moving Average) hoặc SARIMA (Seasonal ARIMA) để phân tích và dự báo xu hướng, biến động của tỷ giá. Các mô hình thống kê truyền thống phổ biến còn có mô hình hồi quy tuyến tính và phi tuyến tính, trong đó sử dụng các mô hình hồi quy tuyến tính hoặc phi tuyến tính để ánh xạ mối quan hệ giữa các yếu tố kinh tế, tài chính và tỷ giá hối đoái. Khi trí tuệ nhân tạo và học máy ngày càng phát triển thì ngày càng có nhiều thuật toán học máy được ứng dụng trong dự báo các chuỗi thời gian. Trong số đó, mạng nơ-ron hồi quy (RNN - Recurrent Neural Network) và LSTM được nhiều nghiên cứu quan tâm và sử dụng do những ưu điểm vượt trội. Bên cạnh sự phát triển trong mô hình học sâu để dự báo chuỗi thời gian, kỹ thuật phân rã chuỗi thời gian cũng có những

bước phát triển nổi bật. Ngoài những phân rã truyền thống như phân rã xu thế, chu kỳ, mùa vụ thì thuật toán phân tách EEMD cũng được sử dụng rộng rãi. EEMD là một phương pháp phân tách tín hiệu phi tuyến tính, giúp phân tách tín hiệu gốc thành các thành phần IMF (Intrinsic Mode Functions) có thể được phân tích riêng biệt. Việc này giúp loại bỏ nhiễu và giảm độ phức tạp của dữ liệu, tăng khả năng phân tích và dự báo.

Kết hợp EEMD và LSTM cho phép mô hình học hợp lý từ cả tín hiệu gốc và các thành phần IMF đã được phân tách. Điều này giúp cải thiện khả năng dự báo bằng cách tận dụng cả tính phi tuyến tính và khả năng học dài hạn của mạng nơ-ron. Tỷ giá hối đoái thường có động thái phức tạp và chịu ảnh hưởng của nhiều yếu tố khác nhau. Việc sử dụng EEMD để phân tách và loại bỏ nhiễu có thể giúp tạo ra các dữ liệu đầu vào tốt hơn cho mạng LSTM, từ đó cải thiện chất lượng của dự báo. Kết hợp EEMD và LSTM là một phương pháp hiệu quả để dự báo tỷ giá hối đoái bằng cách tận dụng tính linh hoạt của cả hai phương pháp và giảm thiểu nhược điểm của mỗi phương pháp riêng lẻ.

Wu và Zhu (2019) đã kết hợp kỹ thuật EEMD với LSTM để dự đoán giá dầu thô giao ngay của West Texas Middle (WTI). Kết quả thực nghiệm chứng minh mô hình đề xuất vẫn hoạt động tốt khi số lượng kết quả phân rã thay đổi và có triển vọng cho việc dự báo giá dầu thô. Ulina, Purba và Halim (2020) sử dụng kết hợp CEEDAN (cải tiến của EEMD) và thuật toán cải tiến của FA-LSTM để dự báo tỷ giá EUR/USD, AUD/USD, GBP/USD với dữ liệu từ tháng 1/2010 tới tháng 12/2019. Kết quả nghiên cứu cho thấy phương pháp kết hợp đã giải quyết vấn đề tối ưu tham số của mô hình LSTM, kết quả dự báo tốt và tránh được hiện tượng quá khớp thường gặp của các thuật toán máy học. Yan và Aasma (2020) đề xuất một phương pháp dự báo mới dựa trên kết hợp học sâu cho thị trường chứng khoán: CEEMD-PCA-LSTM. Kết quả thực nghiệm của 6 chỉ số chứng khoán đại diện từ 3 loại thị trường cho thấy mô hình đề xuất của các tác giả vượt trội hơn các mô hình chuẩn về độ chính xác dự đoán, tức là sai số kiểm tra thấp hơn và tính đối xứng định hướng cao hơn.

Các kết quả nghiên cứu trước đã cho thấy những ưu thế vượt trội khi kết hợp các thuật toán phân rã và LSTM. Với chuỗi thời gian về tỷ giá

EUR/USD có được, nghiên cứu này sử dụng thuật toán LSTM kết hợp với EEMD để dự báo tỷ giá hối đoái EUR/USD, cụ thể là phân rã chuỗi tỷ giá thành nhiều chuỗi thành phần với tần số khác nhau, sử dụng LSTM dự báo cho từng chuỗi thành phần để tổng hợp lại thành kết quả dự báo cho ban đầu. Để chứng minh tính vượt trội của phương pháp này, nghiên cứu sẽ so sánh kết quả đạt được với phương pháp truyền thống ARIMA.

3. Phương pháp nghiên cứu

3.1. Dữ liệu

Bộ dữ liệu về tỷ giá hối đoái EUR/USD của nghiên cứu được thu thập từ Yahoo! Finance. Tỷ giá hối đoái EUR/USD được thu thập theo ngày trong khoảng thời gian 20 năm, tính từ tháng 12/2003 đến tháng 2/2023, bao gồm 4.985 quan sát. Số quan sát này được chia thành 4.487 quan sát (90% bộ dữ liệu ban đầu) từ ngày 01/12/2003 tới 19/03/2023 để phục vụ cho việc đào tạo và 499 quan sát (10% bộ dữ liệu ban đầu) từ ngày 22/03/2021 tới 16/02/2023 để phục vụ cho việc kiểm tra. Với số quan sát ở tập dữ liệu huấn luyện là 4.487, đây được xem là dữ liệu đủ lớn để thực hiện việc huấn luyện.

3.2. Phương pháp xử lý số liệu

a. Thuật toán phân tách EMD và EEMD

Phương pháp phân tách EMD là một trong những phương pháp phân tách được sử dụng khá phổ biến. Phương pháp phân tách EMD có thể được áp dụng trên các chuỗi thời gian phi tuyến tính và không dừng (Huang, 1998). Phương pháp EMD phân tách chuỗi thời gian thành một số nhỏ hoặc hữu hạn các hàm chức năng nội tại (IMF) cùng với phần dư mà khi cộng tất cả các hàm chức năng nội tại với phần dư này lại tạo được một chuỗi như chuỗi gốc ban đầu. Việc phân tách này chỉ dựa trên chính các đặc điểm của chuỗi thời gian đó. Thứ nhất, thuật toán phân tách xác định tất cả các điểm cực trị cục bộ trong chuỗi thời gian và kế đến tạo thành các đường biên trên và dưới tương ứng như một đường spline bậc 3 bằng phương pháp nội suy. Thứ hai, giá trị trung bình của các đường biên trên và dưới được đem ra khỏi chuỗi thời gian và chuỗi được đem ra đó

tạo thành một hàm IMF cục bộ. Phương pháp phân tách EMD là một quá trình bao gồm nhiều bước như sau:

Bước 1: Xác định các điểm cực trị có thể có dữ liệu chuỗi thời gian ban đầu $x^{(t)}$, bao gồm cả giá trị lớn nhất và giá trị nhỏ nhất

Bước 2: Tạo ra cận trên nổi các điểm cực đại cục bộ lại thành $e_{max}^{(t)}$ và cận dưới của các điểm cực tiểu cục bộ lại thành $e_{min}^{(t)}$ bằng các đường spline bậc 3.

Bước 3: Tính giá trị trung bình $m_1^{(t)}$ của $e_{max}^{(t)}$ và $e_{min}^{(t)}$.

$$m_1^{(t)} = \frac{e_{max}^{(t)} + e_{min}^{(t)}}{2}$$

Bước 4: Hàm nội tại đầu tiên được suy ra từ phương trình sau:

$$h_1^{(t)} = x^{(t)} - m_1^{(t)}$$

Bước 5: Kiểm tra $h_1^{(t)}$ trong quá trình thực hiện thuật toán phân tách liệu có thỏa mãn 2 điều kiện không. Nếu có, $h_1^{(t)}$ được xem là hàm chức năng nội tại thứ nhất và phần dư được xác định bởi phương trình sau sẽ được thay thế làm chuỗi gốc tiếp theo $x^{(t)}$:

$$r_1^{(t)} = x^{(t)} - h_1^{(t)}$$

Nếu 2 điều kiện trên không thỏa mãn thì $h_1^{(t)}$ sẽ được thay thế làm chuỗi gốc ban đầu.

Bước 6: Tiếp tục lặp lại các bước trên. Quá trình sàng lọc sẽ dừng khi phần dư sau khi được phân tách là một hàm đơn điệu hay là một hằng số hoặc là một hàm với duy nhất một điểm cực trị yếu không có đủ khả năng để trích xuất thành các hàm chức năng nội tại.

Cuối cùng, kết quả sau khi phân tách bằng phương pháp EMD đối với chuỗi dữ liệu ban đầu $x(t)$:

$$x^{(t)} = \sum_{i=1}^N h_i^{(t)} + R_N^{(t)}$$

Trong đó: $h_i^{(t)}$, $i = 1, 2, 3... N$, là các hàm chức năng nội tại có thể có và $x^{(t)}$ là chuỗi ban đầu; $R_N^{(t)}$ là chuỗi phần dư.

EEMD khắc phục nhược điểm của phương pháp phân tách EMD khi chúng có thể giải quyết hiện tượng pha trộn phương thức (mode mixing). Hiện tượng pha trộn phương thức xảy ra khi có 2 hay nhiều tín hiệu bị trộn lẫn vào nhau. Có thể có 2 trường hợp pha trộn có thể xảy ra: một là, tín hiệu của các chức năng khác nhau xuất hiện

trong cùng một hàm chức năng nội tại IMF; hai là các tín hiệu của cùng một hàm chức năng nội tại được phân tán thành các hàm chức năng nội tại IMF khác nhau.

Ý tưởng cải tiến chính của EEMD là sử dụng tính chất giá trị trung bình của nhiều trắng bằng 0. Bằng cách phân bổ nhiều trắng một cách đồng đều nhiều lần vào chuỗi ban đầu trong quá trình phân tách, nhiều trong tín hiệu được che đi bởi nhiễu nhân tạo được thêm vào nhiều lần để có được khoảng giá trị chính xác hơn. Đồng thời, các kết quả phân tách được thực hiện bằng cách lấy giá trị trung bình. Quá trình lấy trung bình được thực hiện càng nhiều lần thì nhiễu được đưa vào quá trình phân tách càng ít.

Thiết lập chuỗi tín hiệu ban đầu thành n chuỗi khác nhau để tiến hành thêm nhiều trắng $w_n^{(t)}$ tương ứng vào chính chuỗi ban đầu $x^{(t)}$.

$$x_n^{(t)} = x^{(t)} + w_n^{(t)}$$

Sau đó tiến hành phân tách EMD cho chuỗi $x_n^{(t)}$.

Đối với các hàm chế độ nội tại có được từ phương pháp phân tách EMD cho từng chuỗi ban đầu $x_n^{(t)}$, ta tiến hành lấy giá trị trung bình của tất cả các hàm chế độ nội tại này lại thì sẽ được một hàm chế độ nội tại chính thức.

$$imf(t) = \frac{1}{N} \sum_{n=1}^N imf_n(t)$$

EEMD có thể phân tách dữ liệu tín hiệu gốc thành tổ hợp tuyến tính của một số hữu hạn các hàm IMF, với tần suất cao đến thấp và mỗi thành phần IMF của quá trình phân tách chứa các tín hiệu đặc trưng cục bộ của tín hiệu gốc ở các bước thời gian khác nhau. Nhìn chung, về mặt thống kê, phương pháp EEMD giúp khử nhiễu được tốt hơn cũng như tránh tình trạng pha trộn phương thức như EMD.

b. Phương pháp LSTM

Khi giải quyết các vấn đề liên quan đến dữ liệu chuỗi phi tuyến phức tạp, chẳng hạn như nhận dạng giọng nói, xử lý hình ảnh, dự báo chuỗi giá chứng khoán... thì việc ứng dụng mạng thần kinh truyền thống chưa mang lại hiệu quả tích cực. Một trong những giải pháp đó là dùng Recurrent Neural Networks (RNNs). Lý do là vì RNNs có thể trích xuất các hình mẫu hoặc các quy luật từ dữ liệu lịch sử và sử dụng các quy luật này để dự đoán chuỗi thời gian trong tương

lai. Phương pháp RNN tiêu chuẩn này có cấu trúc mô-đun lặp lại khá đơn giản.

LSTM là một biến thể ưu việt hơn được phát triển dựa trên kiến trúc RNN và được sử dụng để giải quyết nhược điểm của RNN. LSTM kiểm soát việc bổ sung hoặc xóa thông tin trạng thái của các ô thông qua một mô-đun bao gồm cơ chế chọn cổng. Hình 1 cho thấy các cấu thành bên trong của một khối LSTM. Hệ thống của LSTM bao gồm một tập hợp các mạng con được kết nối thường xuyên, được gọi là các khối bộ nhớ. Ý tưởng đằng sau khối bộ nhớ là duy trì trạng thái thông tin của nó theo thời gian và điều chỉnh luồng thông tin được gọi là các đơn vị cổng phi tuyến tính. Hình 1 cũng thể hiện kiến trúc của một khối LSTM, bao gồm các cổng, tín hiệu đầu vào $x^{(t)}$, đầu ra $y^{(t)}$, các chức năng kích hoạt và đường kết nối thông tin (Gers & Schmidhuber 2000). Đầu ra của khối này được kết nối liên tục với đầu vào của khối sau hay sự liên kết liên tục giữa các cổng và ngược lại.

Các thành phần của LSTM, với N khối xử lý và M tham số đầu vào, gồm có:

Block input: Khối này có chức năng nhận thông tin đầu vào, kết hợp đầu vào $x^{(t)}$ hiện tại và đầu ra của LSTM trước đó là $y^{(t-1)}$ đó được biểu diễn như sau:

$$z^{(t)} = g(W_z x^{(t)} + R_z y^{(t-1)} + b_z)$$

Trong đó W_z và R_z lần lượt là tỷ trọng ứng với $x^{(t)}$ và $y^{(t-1)}$, b_z đại diện cho véc-tơ phần dư có trọng số. Quá trình này được thể hiện bằng phương trình sau:

$$i^{(t)} = \sigma(W_i x^{(t)} + R_i y^{(t-1)} + p_i \odot c^{(t-1)} + b_i)$$

Trong đó \odot biểu thị tích của vô hướng của vector; W_i , R_i và p_i tương ứng là các tham số của $x^{(t)}$, $y^{(t-1)}$ và $c^{(t-1)}$; còn b_i là phần chênh lệch. Các lớp LSTM trước đã xác định được những thông tin được nắm giữ tại $c^{(t)}$. Điều này bao gồm việc lựa chọn các giá trị $z^{(t)}$ có khả năng được thêm vào các trạng thái ô và các giá trị kích hoạt $i^{(t)}$ của các cổng đầu vào.

Forget gate: LSTM xác định được thông tin nào sẽ bị xóa khỏi trạng thái ô trước đó $c^{(t-1)}$ tại cổng này. Các giá trị kích hoạt $f^{(t)}$ của các cổng quên tại t được tính toán dựa trên đầu vào hiện tại $x^{(t)}$, đầu ra $y^{(t-1)}$, và trạng thái $c^{(t-1)}$; cùng với các kết nối thông tin và các thành phần sai số b_f của các cổng quên theo phương trình sau:

$$f^{(t)} = \sigma(W_f x^{(t)} + R_f y^{(t-1)} + p_f \odot c^{(t-1)} + b_f)$$

Trong đó W_f , R_f và p_f lần lượt là trọng số của $x^{(t)}$, $y^{(t-1)}$ và $c^{(t-1)}$, và b_f được coi là véc-tơ có trọng số của các thành phần sai số.

Cell: Thành phần này giúp tính toán giá trị ô, kết hợp đầu vào $z^{(t)}$, cổng đầu vào $i^{(t)}$ và các giá trị cổng quên $f^{(t)}$ với giá trị ô trước đó.

$$c^{(t)} = z^{(t)} \odot i^{(t)} + c^{(t-1)} \odot f^{(t)}$$

Output gate: Thành phần này thực hiện xác định giá trị $o^{(t)}$ để chuẩn bị cho bước cuối cùng tính toán giá trị đầu ra bằng việc kết hợp thành phần đầu vào hiện tại $x^{(t)}$, giá trị $y^{(t-1)}$ và giá trị ô $c^{(t-1)}$ trong lần lặp cuối cùng.

$$o^{(t)} = \sigma(W_o x^{(t)} + R_o y^{(t-1)} + p_o \odot c^{(t-1)} + b_o)$$

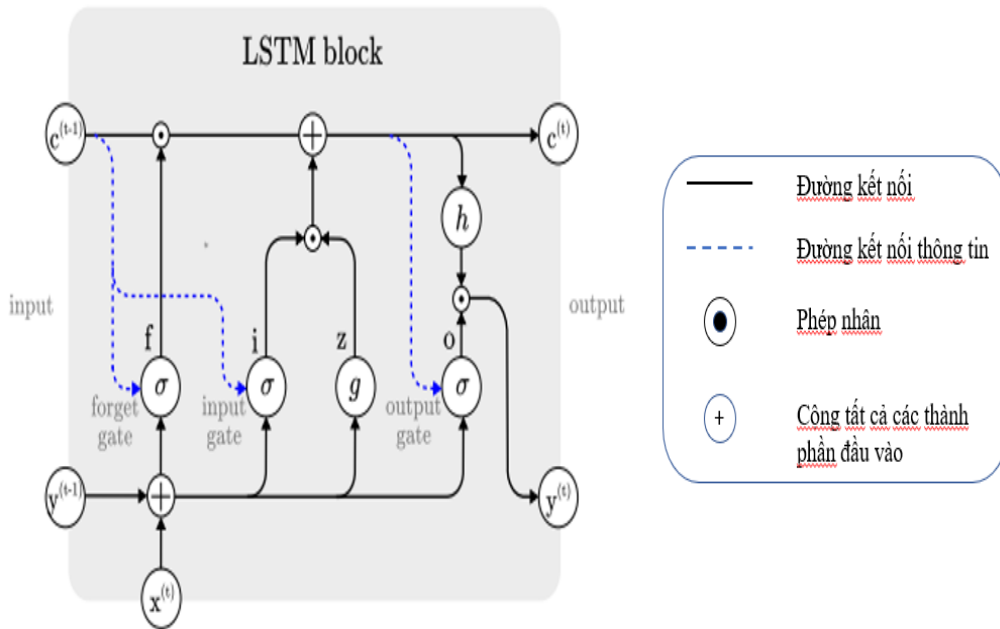
Trong đó W_o , R_o và p_o lần lượt là trọng số của $x^{(t)}$, $y^{(t-1)}$, $c^{(t-1)}$ và b_o chứa các sai khớp.

Block output: Bước cuối cùng là tính toán đầu ra khỏi, kết hợp giá trị ô hiện tại $c^{(t)}$ với giá trị cổng đầu ra hiện tại như phương trình sau:

$$y^{(t)} = g(c^{(t)}) \odot o^{(t)}$$

Ở những bước trên, σ , g và h là các hàm kích hoạt phi tuyến tính.

Với cách thức thực hiện như trên, nghiên cứu này sẽ thực hiện phân rã chuỗi tỷ giá thành nhiều chuỗi thành phần nội tại bằng EEMD, sau đó sử dụng LSTM dự báo cho từng chuỗi IMF và cuối cùng là tổng hợp những dự báo thành phần IMF này lại thành kết quả dự báo cho chuỗi ban đầu.



Hình 1: Cơ chế hoạt động của LSTM
 Nguồn: Van Houtd, Mosquera, & Nápoles (2020).

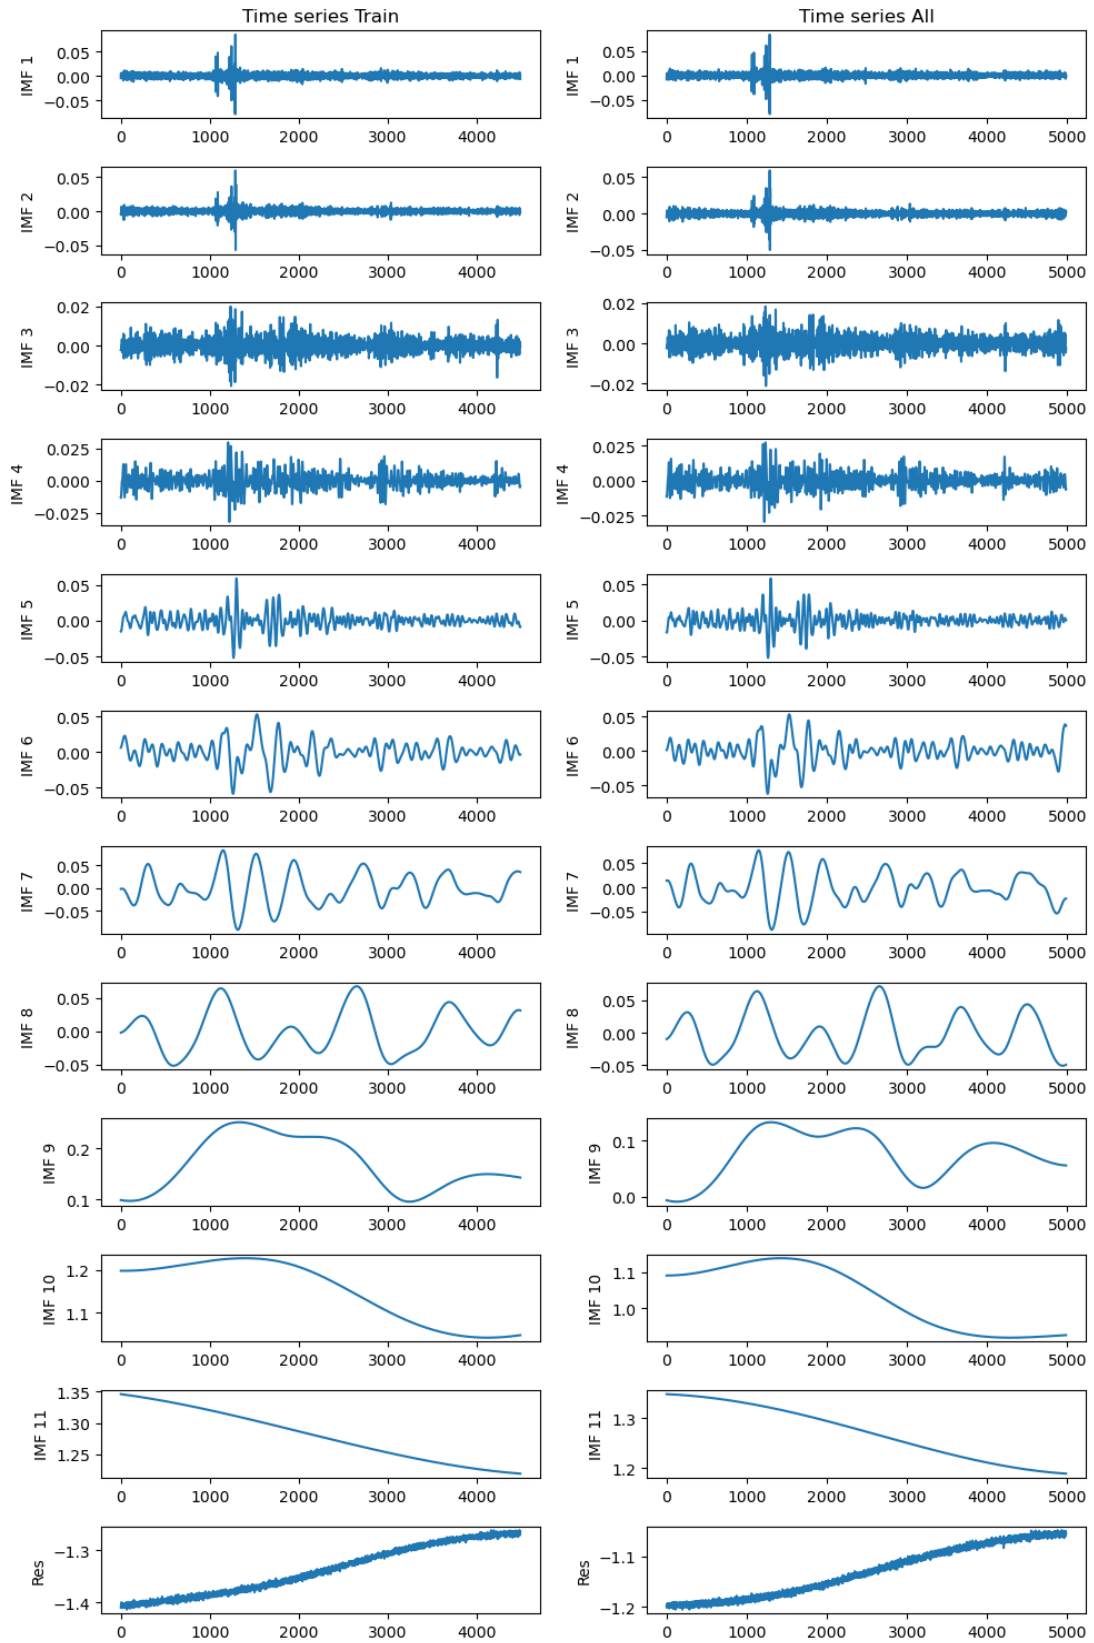
4. Kết quả nghiên cứu và thảo luận

4.1. Thống kê mô tả dữ liệu

Nghiên cứu sử dụng dữ liệu giá đóng cửa của tỷ giá hối đoái EUR/USD từ năm 2003 đến năm 2023 được trích xuất từ gói Yahoo! Finance bằng ngôn ngữ lập trình Python.

Bảng 1 thực hiện thống kê mô tả trên tổng cộng 4.985 quan sát với giá trị trung bình là 1,123 và độ lệch chuẩn 0,125. Bên cạnh đó, giá trị nhỏ nhất của chuỗi tỷ giá hối đoái EUR/USD

là 0,959 và giá trị lớn nhất là 1,598. Ngoài ra, tứ phân vị dưới của bộ dữ liệu trên là 1,134 và tứ phân vị trên là 1,334. Kết quả kiểm định tính dừng bằng kiểm định ADF và kiểm định Phillips-Perron cũng cho thấy chuỗi tỷ giá EUR/USD là chuỗi liên kết bậc nhất. Các kỹ thuật thông thường sẽ phân tích chuỗi sai phân để tránh hồi quy giả mạo. Tuy nhiên, việc lấy sai phân có thể làm mất thông tin dài hạn của chuỗi. Trong khi đó, thuật toán EEMD kết hợp LSTM không cần thực hiện lấy sai phân, thể hiện tính ưu việt của phương pháp kết hợp này.



Hình 2: Kết quả phân tách chuỗi tỷ giá EUR/USD theo phương pháp phân tách EEMD
 Nguồn: Nhóm tác giả.

Bảng 1: Thống kê mô tả giá đóng cửa của tỷ giá hối đoái EUR/USD

Đại lượng	Tỷ giá EUR/USD hàng ngày
Số quan sát	4.985
Trung bình	1,243
Độ lệch chuẩn	0,125
Giá trị nhỏ nhất	0,960
Phân vị 0,25	1,134
Phân vị 0,5	1,232
Phân vị 0,75	1,335
Giá trị lớn nhất	1,599
Kiểm định ADF	
Chuỗi gốc	-2,376
Chuỗi sai phân	-65,575***
Kiểm định Phillips-Perron	
Chuỗi gốc	-2,086
Chuỗi sai phân	-66,224***

Nguồn: Nhóm tác giả.

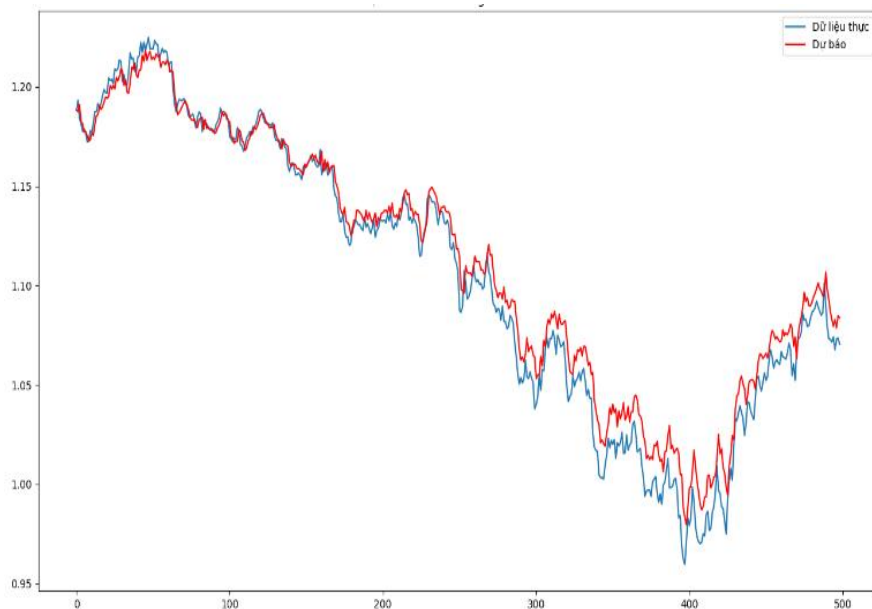
4.2.. Kết quả nghiên cứu

a. Phân tách bằng EEMD

Nghiên cứu thực hiện phân tách EEMD cho toàn bộ dữ liệu. Hình 2 thể hiện kết quả phân tách, bao gồm 11 chuỗi nội tại IMFs và 1 chuỗi phần dư.

b. Dự báo bằng thuật toán LSTM

Hình 3 thể hiện kết quả sau khi chạy LSTM cho các chuỗi có được từ thuật toán phân tách EEMD. Sau khi chạy LSTM, nhóm tác giả có được kết quả dự báo của từng chuỗi IMF. Kế đến, tiến hành cộng tất cả chuỗi dự báo của IMF lại sẽ được một chuỗi dự báo tỷ giá hối đoái EUR/USD. Sau đó, hiệu chỉnh kết quả dự báo của chuỗi tỷ giá hối đoái EUR/USD và được kết quả như Hình 3. Có thể thấy chuyển động của chuỗi dự báo dường như khá sát với chuỗi kiểm thử của tỷ giá hối đoái EUR/USD.



Hình 3: Đồ thị thể hiện kết quả dự báo của mô hình kết hợp EEMD-LSTM

Nguồn: Nhóm tác giả.

4.3. So sánh với các mô hình ARIMA tiêu chuẩn

Để kiểm tra liệu mô hình dự báo kết hợp EEMD-LSTM mà nghiên cứu đề xuất có hiệu

quả hay không, nhóm tác giả tiến hành so sánh với kết quả dự báo đến từ mô hình ARIMA (0,1,2) và mô hình dự báo kết hợp ARIMA (0,1,2)-GARCH (1,1). Độ trễ của ARIMA được

xác định dựa trên phương pháp Box-Jenkins thông qua việc kiểm định tính dừng, biểu đồ ACF và biểu đồ PACF của chuỗi tỷ giá sau khi đã biến đổi thành chuỗi dừng. Bảng 2 cho thấy

kết quả so sánh giữa mô hình mà nghiên cứu đề xuất là EEMD-LSTM và hai mô hình tiêu chuẩn là ARIMA và ARIMA-GARCH bằng các thông số sai số thống kê MSE, MAE, MAPE.

Bảng 2: Bảng kết quả so sánh giữa EEMD-LSTM với các mô hình thống kê truyền thống

	MSE	MAE	MAPE
EEMD-LSTM	0,000134 (*)	0,009031 (*)	0,851964 (*)
ARIMA (0,1,2)	0,01274	0,09088	8,65093
ARIMA (0,1,2)- GARCH (1,1)	0,01649	0,107551	10,1626

Ghi chú: (*) Kết quả có tiêu chí đánh giá mức độ sai số tốt nhất.

Nguồn: Nhóm tác giả tính toán.

Kết quả Bảng 2 cho thấy mô hình mà nghiên cứu đề xuất EEMD-LSTM vượt trội hơn hẳn mô hình tiêu chuẩn ARIMA và ARIMA-GARCH. EEMD-LSTM có kết quả của 3 tiêu chí đánh giá, bao gồm MSE, MAE, MAPE là nhỏ nhất, điều này hàm ý rằng mô hình kết hợp EEMD-LSTM mà nghiên cứu thực sự dự báo tốt đối với tỷ giá hối đoái EUR/USD so với hai mô hình tiêu chuẩn còn lại. Mặc dù là mô hình kết hợp giữa ARIMA và GARCH có cải tiến trên phần dư của mô hình ARIMA nhưng sự kết hợp hai mô hình truyền thống này chưa thực sự mang đến tính hiệu quả như mô hình ARIMA đơn lẻ.

Với việc so sánh ba tiêu chí kiểm định sai số thống kê cũng cho thấy sự hiệu quả của mô hình kết hợp giữa phương pháp phân tách EEMD và thuật toán học sâu LSTM trong việc dự báo tỷ giá hối đoái EUR/USD. Các phương pháp thống kê truyền thống như ARIMA hay ARIMA-GARCH thường phải xem xét tính dừng và tính tuyến tính trong dữ liệu, không thực sự phù hợp với những dữ liệu có biểu hiện phi tuyến như giá tài sản tài chính hoặc tỷ giá hối đoái. Ngược lại, phương pháp EEMD-LSTM, cũng như các phương pháp kết hợp khác, có khả năng xử lý tốt tính phi tuyến thông qua sự phân rã EEMD cũng như thông qua lớp mạng nơ-ron nhân tạo của LSTM. Kết quả của việc kết hợp EEMD-LSTM đã được chứng minh hiệu quả trong nhiều nghiên cứu trước đó khi cho rằng các mô hình dự báo đơn lẻ hoặc truyền thống có độ chính xác trung bình thấp hơn 70% (Shen, Chao, & Zhao,

2015; Yao & Tan, 2000; Zhang, 2018), trong khi các mô hình dự báo kết hợp hay các phương pháp dự báo tiên tiến cho thấy kết quả dự báo trung bình lớn hơn 70% (Bao, Yue, & Rao, 2017; Galeshchuk, Mukherjee, & Management, 2017; Huang, Nakamori, & Wang, 2005; Özorhan, Toroslu, & Şehitoğlu, 2017). Các nghiên cứu này đưa ra những quan điểm củng cố cho mô hình kết hợp EEMD-LSTM phù hợp để dự báo tỷ giá hối đoái EUR/USD. Mô hình kết hợp này có những ưu điểm như sau:

(1) Thuật toán phân tách EEMD có thể cho thấy bản chất chuyển động của dữ liệu chuỗi thời gian đang được phân tách.

(2) Thuật toán phân tách EEMD giải quyết được tình trạng pha trộn phương thức xuất hiện trong phương pháp phân tách EMD.

(3) Mạng thần kinh học sâu LSTM có các công cụ thay đổi cơ chế thông tin dựa trên kiến trúc cơ bản của RNN, do đó mô hình đề xuất có thể học được các dữ liệu dài hơn mà không xảy ra tình trạng biến mất độ dốc.

5. Kết luận và gợi ý chính sách

Trong nghiên cứu này, nhóm tác giả đã đề xuất mô hình kết hợp giữa thuật toán phân tách EEMD và mạng thần kinh học sâu LSTM để dự báo xu hướng của tỷ giá hối đoái EUR/USD. Các bước chính trong mô hình này được thực hiện như sau:

(1) Tỷ giá hối đoái EUR/USD được phân tách thành nhiều hàm chế độ nội tại và một phần dư bằng phương pháp phân tách EEMD.

(2) Các hàm chế độ nội tại và phần dư được xem là thành phần đầu vào của mạng thần kinh học sâu LSTM để thực hiện dự báo.

(3) Việc dự báo tỷ giá hối đoái được thực hiện bằng cách lấy tổng tất cả giá trị dự báo của các hàm chế độ nội tại cùng với phần dư. Sau đó, giá trị dự báo này được hiệu chỉnh cho ra kết quả cuối cùng nhằm phục vụ cho việc phân tích so sánh.

Sau khi có được kết quả dự báo tỷ giá hối đoái EUR/USD, nghiên cứu tiến hành so sánh với hai mô hình dự báo truyền thống là ARIMA(0,1,2) và mô hình kết hợp ARIMA(0,1,2)-GARCH(1,1). Kết quả thực nghiệm cho thấy mô hình dự báo được đề xuất là EEMD-LSTM hiệu quả hơn so với hai mô hình còn lại. Trong nghiên cứu này, mô hình được đề xuất EEMD-LSTM đã giải quyết tốt vấn đề dự báo tỷ giá hối đoái EUR/USD nhằm nắm bắt các rủi ro về tỷ giá có thể xảy ra trong tương lai, đặc biệt trong thương mại quốc tế. Ngoài ra, mô hình EEMD-LSTM còn được ứng dụng để giải quyết các vấn đề liên quan đến dữ liệu chuỗi thời gian phi tuyến tính và không dừng. Cụ thể, mô hình kết hợp này có thể được dùng để dự báo khả năng xảy ra động đất, dự báo giá năng lượng và các vấn đề liên quan đến quyết định tài chính, dự báo rủi ro khi đầu tư và đặc biệt là các mô hình hồi quy chuỗi thời gian trong tài chính. Trong những nghiên cứu mở rộng tiếp theo, các nhà ứng dụng có thể bổ sung thêm các yếu tố vĩ mô vào mô hình nghiên cứu nhằm phù hợp với các lý thuyết kinh tế và tăng thêm độ chính xác cho dự báo.

Tài liệu tham khảo

- Bukowski, S. I., & Bukowska, J. E. (2017). Financial and fiscal crises, prices and EUR/USD rate of exchange. *International Journal of Business and Economic Sciences Applied Research (IJESAR)*, 10(3). <http://doi.org/10.25103/ijesar.103.05>
- Bussiere, M. (2013). Exchange rate pass-through to trade prices: The role of nonlinearities and asymmetries. *Oxford Bulletin of Economics and Statistics*, 75(5), 731-758. <http://doi.org/10.1111/j.1468-0084.2012.00711.x>
- Chen, Z., Yuan, C., Wu, H., Zhang, L., Li, K., Xue, X., & Wu, L. (2022). An improved method based on EEMD-LSTM to predict missing measured data of structural sensors. *Applied Sciences*, 12(18), 9027. <https://doi.org/10.3390/app12189027>
- Dobrovolny, M., Soukal, I., Lim, K. C., Selamat, A., & Krejcar, O. (2020). Forecasting of FOREX price trend using recurrent neural network-long short-term memory. Conference: Hradec Economic Days 2020. <http://doi.org/10.36689/uhk/hed/2020-01-011>
- Galeshchuk, S., & Mukherjee, S. (2017). Deep networks for predicting direction of change in foreign exchange rates. *Intelligent Systems in Accounting, Finance and Management*, 24(4), 100-110. <http://doi.org/10.1002/isaf.1404>
- Huang, N. E. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, physical and engineering sciences*. <https://doi.org/10.1098/rspa.1998.0193>
- Huang, W., Nakamori, Y., & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*, 32(10), 2513-2522. <https://doi.org/10.1016/j.cor.2004.03.016>
- Janetzko, D. (2014). Using Twitter to model the EUR/USD exchange rate. arXiv preprint arXiv:1402.1624. <https://doi.org/10.48550/arXiv.1402.1624>
- Özorhan, M. O., Toroslu, İ. H., & Şehitoğlu, O. T. (2017). A strength-biased prediction model for forecasting exchange rates using support vector machines and genetic algorithms. *Soft Computing*, 21, 6653-6671. <https://doi.org/10.1007/s00500-016-2216-9>
- Pérez-Rodríguez, J. V. (2006). The Euro and other major currencies floating against the U.S. dollar. *Atlantic Economic Journal*, 34, 367-384. <https://doi.org/10.1007/s11293-006-9042-x>
- Qu, Y., & Zhao, X. (2019). Application of LSTM neural network in forecasting foreign exchange price. *Paper presented at the Journal of Physics: Conference Series*. <http://doi.org/10.1088/1742-6596/1237/4/042036>
- Ribeiro, G. A. M. (2016). Macroeconomic determinants of international currencies. Master's thesis.
- Shen, F., Chao, J., & Zhao, J. (2015). Forecasting exchange rate using deep belief networks and conjugate gradient method. *Neurocomputing*, 167,

- 243-253.
<https://doi.org/10.1016/j.neucom.2015.04.071>
- Ulina, M., Purba, R., & Halim, A. (2020). Foreign exchange prediction using CEEMDAN and improved FA-LSTM. The 2020 Fifth International Conference on Informatics and Computing (ICIC). <https://doi.org/10.1109/ICIC50835.2020.9288615>
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53, 5929-5955. <https://doi.org/10.1007/s10462-020-09838-1>
- Vukovic, D., & VYKLYUK, V. (2013). Forex prediction with neural network: usd/eur currency pair. *Actual Problems of Economics*, 10, 251-261.
- Wu, Y. X., Wu, Q. B., & Zhu, J. Q. (2019). Improved EEMD-based crude oil price forecasting using LSTM networks. *Physica A: Statistical Mechanics and its Applications*, 516, 114-124. <https://doi.org/10.1016/j.physa.2018.09.120>
- Yan, B., & Aasma, M. (2020). A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM. *Expert systems with Applications*, 159, 113609.8, 71206-71218. <https://doi.org/10.1016/j.eswa.2020.113609>
- Yao, J., & Tan, C. L. (2000). A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing*, 34(1-4), 79-98. [https://doi.org/10.1016/S0925-2312\(00\)00300-3](https://doi.org/10.1016/S0925-2312(00)00300-3)
- Zhang, B. (2018, July). Foreign exchange rates forecasting with an EMD-LSTM neural networks model. *Journal of Physics: Conference Series*, 1053(1), p. 012005. <http://doi.org/10.1088/1742-6596/1053/1/012005>