

Xây dựng mô hình dự báo phụ tải điện trong thị trường điện trong ngày ứng dụng mạng nơ ron hồi tiếp bộ nhớ ngắn – dài hạn

Nguyễn Hữu Đức^{1*}, Lê Hải Hà², Trần Thị Nhung³

¹Khoa Công nghệ Năng lượng, Trường Đại học Điện lực;

²Công ty TNHH Giải pháp lưới điện thông minh Việt Nam SES;

³Khoa Điện-Điện tử, Trường Đại học Sư phạm Kỹ thuật Nam Định.

*Email: ducnh@epu.edu.vn

Nhận bài: 01/12/2021; Hoàn thiện: 05/8/2022; Chấp nhận đăng: 10/10/2022; Xuất bản: 28/10/2022.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.82.2022.91-97>

TÓM TẮT

Dự báo tải điện đóng một vai trò quan trọng trong việc tham gia thị trường điện. Trong các thị trường điện như thị trường điện ngày trước (dayahead market) và thị trường điện trong ngày (intraday market) thì thị trường điện trong ngày cần dự báo được nhu cầu phụ tải trước 15 phút. Như vậy, bài toán dự báo phụ tải điện trước 15 phút đóng vai trò quan trọng trong việc các đơn vị mua điện khi tham gia vào thị trường điện trong ngày. Do tính không tuyến tính, tính không ổn định theo điều kiện tự nhiên của tải điện trong các hệ thống điện quy mô nhỏ, việc dự báo chính xác vẫn đang là một thách thức. Bài báo này xây dựng mô hình dự báo phụ tải điện ngắn hạn bằng việc dùng mạng nơ ron hồi tiếp bộ nhớ ngắn-dài hạn Long-Short-Term-Memory (LSTM). Kết quả kiểm nghiệm đánh giá mô hình với sai số trong khoảng 1%.

Từ khóa: Dự báo tải điện 15 phút; Thuật toán nơ ron; Bộ nhớ hồi tiếp ngắn – dài hạn; Thị trường điện trong ngày.

1. ĐẶT VẤN ĐỀ

Dự báo phụ tải điện có một vai trò quan trọng trong việc giúp người vận hành hệ thống điện lên kế hoạch sản xuất, truyền tải và phân phối năng lượng điện một cách hiệu quả. Dự báo phụ tải điện chính xác cho phép cải thiện tính an toàn của hệ thống, tối ưu hóa chi phí của hệ thống sản xuất, giảm sự cố của hệ thống truyền tải và phân phối năng lượng. Đối với thị trường điện, dự báo phụ tải điện giúp bên bán và bên mua xác định được giá năng lượng tối ưu cho các giao dịch. Bài toán dự báo phụ tải điện được chia làm 3 loại tùy thuộc vào thời gian dự báo trước: Dự báo phụ tải điện dài hạn; Dự báo phụ tải trung hạn; và Dự báo phụ tải ngắn hạn. Dự báo phụ tải điện ngắn hạn là bài toán dự báo trước phụ tải điện trong thời gian từ 15 phút tới khoảng thời gian theo giờ, và ngày trước [1-2]. Có nhiều nghiên cứu các mô hình dự báo phụ tải điện trong những năm trở lại đây và một vài kỹ thuật được sử dụng trong việc xây dựng mô hình dự báo phụ tải điện. Một kỹ thuật được sử dụng rộng rãi hiện nay cho dự báo tải phụ tải điện ngắn hạn là phương pháp Hồi quy vector (Support Vector Regression -SVR) [3, 4].

Do đặc tính của tải điện là có tính chu kỳ theo thời gian nên nhiều phương pháp dự báo sử dụng dữ liệu lịch sử để dự báo phụ tải điện như phương pháp AR (Autoregressive), MA (Moving Average), ARIMA (Autoregressive Integrated Moving Average) [5-7]. Trong đó, phương pháp ARIMA là một phương pháp thông dụng và phổ biến nhất. Tuy nhiên, các phương pháp này đều giả định là dữ liệu tải điện quá khứ và tải điện tương lai có mối quan hệ tuyến tính với nhau. Điều này có thể dẫn tới sai số lớn trong các trường hợp mối quan hệ là phi tuyến. Các tác giả trong [8] cải tiến phương pháp ARIMA để dự báo phụ tải điện phi tuyến theo mô hình GARCH (Autoregressive Conditional Heteroskedastic). Tuy nhiên, phương pháp này chỉ cho kết quả tốt đối với tập dữ liệu tĩnh [9-10], trong khi dữ liệu tải điện thì có thể là dữ liệu động. Các tồn tại trên được giải quyết với việc ứng dụng mạng nơ ron nhân tạo trong dự báo phụ tải điện. Với sự phát triển của khoa học máy tính, một kỹ thuật khác được sử dụng rất phổ biến là mạng nơ ron nhân tạo [11-13]. Các tài liệu [11, 14-16] trình bày một sự cải tiến ứng dụng mạng nơ ron nhân tạo và Wavelet Neural Networks (WNN) trong dự báo phụ tải điện. Các nhà nghiên cứu tìm

trong dữ liệu lịch sử, một ngày mà có đặc điểm giống nhất với ngày cần dự báo, sau đó áp dụng một bộ lọc cho phụ tải điện của ngày đó (wavelet decomposition).

Các phương pháp trên có một vài tồn tại như một số dữ liệu như dữ liệu nhiệt độ không sẵn có, dữ liệu tải điện tuyến tính và cố định. Các mô hình này có nhược điểm là phức tạp do cần phải xây dựng mô hình cho mỗi bước riêng lẻ. Một vài mô hình chỉ áp dụng cho một tập dữ liệu cụ thể, không có khả năng áp dụng cho bộ dữ liệu khác. Sự đánh giá kết quả đôi khi chỉ dựa trên một tập dữ liệu nhỏ, không phản ánh được độ chính xác tổng thể. Từ các phân tích như trên, bài báo xây dựng mô hình dự báo phụ tải điện ngắn hạn ứng dụng vào thị trường điện trong ngày (intraday ahead) sử dụng kiến trúc mạng nơron nhận tạo hồi tiếp dựa trên bộ nhớ ngắn – dài hạn giúp khắc phục được một số tồn tại trên:


- Mô hình không sử dụng dữ liệu nhiệt độ.
- Mô hình áp dụng cho tất cả các ngày trong tuần, tháng trong năm với bước dự báo 15 phút.
- Mô hình có thể sử dụng cho các bộ dữ liệu phụ tải điện khác nhau (tuyến tính và không tuyến tính, có thể biến thiên).
- Sai số của mô hình được đánh giá với lượng dữ liệu của tất cả các ngày trong tuần.

Cấu trúc bài báo được trình bày như sau: Mục 2 trình bày tổng quan một số phương pháp dự báo phụ tải điện ngắn hạn. Mục 3 trình bày phương pháp dự báo phụ tải điện dựa trên mạng Noron hồi tiếp bộ nhớ ngắn – dài hạn (LSTM). Phương pháp này được sử dụng trong bài báo để xây dựng mô hình dự báo phụ tải điện 15 phút trước khi tham gia thị trường điện trong ngày. Kết quả mô phỏng kiểm chứng được trình bày tại mục 4. Một số kết luận được đưa ra tại mục 5.

2. THUẬT TOÁN DỰ BÁO PHỤ TẢI VỚI MÔ HÌNH MẠNG NORON HỒI TIẾP BỘ NHỚ NGẮN – DÀI HẠN

Xem xét những ưu điểm của LSTM trong dự báo chuỗi thời gian, bài báo này sử dụng lược đồ RNN dựa trên LSTM trong bài báo này để dự báo chuỗi thời gian tải điện. Cho chuỗi thời gian đầu vào $x = \{x_1, x_2, \dots, x_T\}$, LSTM ánh xạ chuỗi thời gian đầu vào thành hai chuỗi thời gian đầu ra $h = \{h_1, h_2, \dots, h_T\}$ và $y = \{y_1, y_2, \dots, y_T\}$ lặp lại bằng cách cập nhật trạng thái của ô nhớ với quy trình sau. Đầu tiên, như trong hình 1, công quên được áp dụng để giúp LSTM quyết định thông tin nào cần loại bỏ khỏi trạng thái ô. Một hàm sigmoid $\sigma(\cdot)$ được sử dụng để tính toán kích hoạt của công quên như:

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + W_{fc}C_{t-1} + b_f) \quad (1)$$



Hình 1. Kiến trúc khối nhớ LSTM.

Đầu ra f_t của (1) là một giá trị từ 0 đến 1 tương ứng với trạng thái ô cuối cùng C_{t-1} . Giá trị 0 có nghĩa là quên hoàn toàn trạng thái cuối cùng, trong khi giá trị 1 là viết tắt của việc giữ trạng

thái cuối hoàn toàn. Tiếp theo, chúng ta cần cho LSTM biết thông tin mới nào sẽ được lưu trữ trong trạng thái ô mới. Để bắt đầu, LSTM sử dụng một lớp sigmoid, được đặt tên là lớp cổng đầu vào, trong đó:

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + W_{ic}C_{t-1} + b_i) \quad (2)$$

Phương trình (2) để quyết định những thông tin cần cập nhật. Lớp sigmoid $g(\cdot)$ xây dựng một vectơ U_t để lưu trữ các giá trị ứng viên mới sẽ được thêm vào trạng thái ô mới như phương trình sau:

$$U_t = g(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (3)$$

Sau đó, trạng thái ô cũ C_{t-1} được cập nhật thành trạng thái ô mới C_t với f_t và U_t được ước tính. Cụ thể, trạng thái ô cũ được nhân với f_t để quên thông tin từ trạng thái cuối cùng. Các giá trị ứng cử viên được nhân với lớp cổng đầu vào để quyết định có bao nhiêu thông tin mới được cập nhật lên trạng thái ô mới, điều này dẫn tới phương trình sau:

$$C_t = U_t i_t + C_{t-1} - f_t \quad (4)$$

Một lớp sigmoid khác $\sigma(\cdot)$ sau đó được sử dụng làm cổng đầu ra để lọc và xuất trạng thái ô dưới dạng o_t , trong đó

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + W_{oc}C_{t-1} + b_o) \quad (5)$$

Hơn nữa, một hàm kích hoạt sigmoid đầu ra ô $\ell(\cdot)$ được áp dụng trên trạng thái ô, sau đó được nhân với o_t đầu ra để đưa ra thông tin mong muốn thể hiện bằng phương trình sau:

$$h_t = \sigma_t \ell(C_t) \quad (6)$$

Đối với đầu ra của khối bộ nhớ, một hàm kích hoạt đầu ra $k(\cdot)$ được sử dụng như phương trình sau:

$$y_t = k(W_{yh}h_t + b_y) \quad (7)$$

Trong (1) - (7), các ma trận W_{ix} , W_{fx} , W_{ox} , W_{cx} là các ma trận trọng số đầu vào thích hợp, W_{ih} , W_{fh} , W_{oh} , W_{ch} là các ma trận trọng số lặp lại, W_{yh} đại diện cho ma trận trọng số đầu ra ẩn, W_{ic} , W_{fc} , W_{oc} biểu thị ma trận trọng số của các kết nối lỗ nhìn trộm. Các vectơ b_i , b_f , b_o , b_c , b_y là các vectơ thiên vị tương ứng.

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Dữ liệu phân tích kiểm nghiệm

Để kiểm chứng mô hình đề xuất, dữ liệu dùng để chạy mô hình là dữ liệu tải điện của Italia từ năm 2020 đến 2021 [17]. Dữ liệu được lấy mẫu mỗi 15 phút. Chia bộ dữ liệu thành 2 phần: dữ liệu huấn luyện (tải điện Italia trong năm 2020), dữ liệu kiểm tra (tải điện Italia trong 1 tuần từ ngày 22/02/2021 đến ngày 28/02/2021).

Thuật toán LSTM được áp dụng để dự báo tải điện cho một bước thời gian tiếp theo X_{t+1} , bằng cách sử dụng các bước thời gian trước đó $\{X_{t-d}, X_{t-d+1}, \dots, X_t\}$. Sau đó, mô hình cập nhật giá trị thực tại bước thời gian X_{t+1} để dự đoán cho bước tiếp theo X_{t+2} . Cứ như vậy cho đến bước thời gian cuối cùng trong tập dữ liệu kiểm tra.

Hai tiêu chí đánh giá được sử dụng là RMSE (root mean square error) và MAPE (mean absolute percentage error) giữa giá trị thực tế và giá trị dự báo.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |L_{pred}(i) - L_{true}(i)|} \quad (8)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{L_{pred}(i) - L_{true}(i)}{L_{true}(i)} \right| \quad (9)$$


Trong đó: N số lượng step trong bộ dữ liệu Test.

$L_{pred}(i)$ tải điện dự báo tại step thứ i.

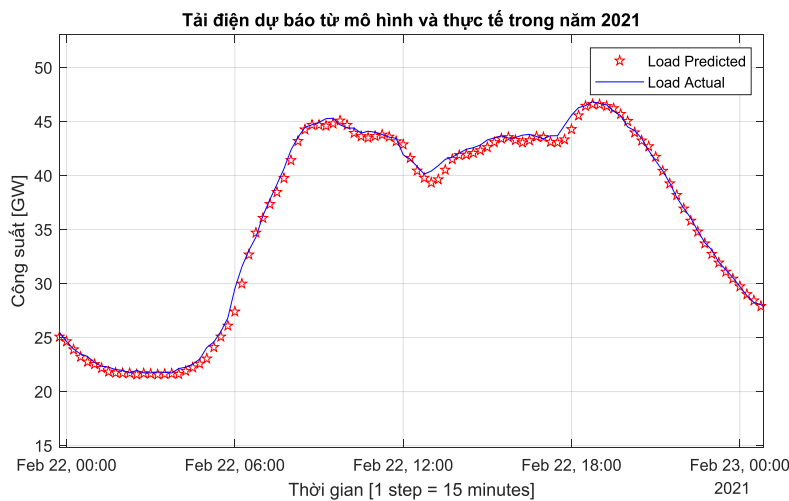
$L_{true}(i)$ tải điện thực tế tại step thứ i

3.2. Kết quả mô phỏng kiểm chứng


Mô hình được xây dựng trên phần mềm Matlab. Các kết quả mô phỏng kiểm chứng mô hình đề xuất so sánh với dữ liệu tải điện thực tế các ngày trong 1 tuần được thể hiện từ hình 2 đến hình 11. Hình 2 cho ta kết quả dự báo của mô hình trong một tuần từ ngày 22/2/2021 đến ngày 28/2/2021. Đường màu xanh là dữ liệu tải thực tế và đường màu đỏ là kết quả dự báo của mô hình theo từng 15 phút. Hình 3 thể hiện kết quả dự báo của mô hình và dữ liệu thực tế vào ngày thứ 2 đầu tuần (ngày 22/02/2021). Ta có thể thấy rằng sai số lớn nhất tập trung vào thời điểm 12h30 đến 13h30 và khung giờ từ 17h00 đến 18h00 trong ngày. Kết quả dự báo ngày chủ nhật được thể hiện trên hình 4. Sai số mô hình dự báo các ngày trong tuần được thể hiện hình 5, hình 6.




Hình 2. Biểu đồ so sánh giữa giá trị tải điện dự báo từ mô hình và tải điện thực tế trong 1 tuần từ 22/2 đến 28/2 năm 2021.



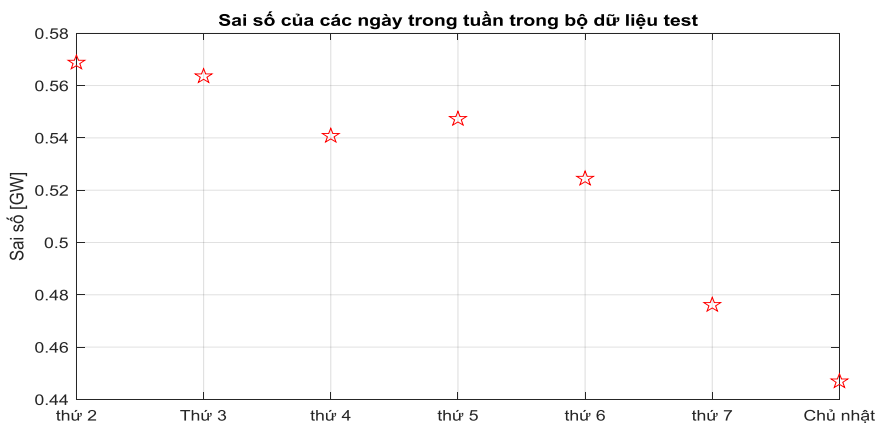
Hình 3. Biểu đồ so sánh giữa giá trị tải điện dự báo từ mô hình và tải điện thực tế thứ 2 ngày 22/2/2021.



Hình 4. Biểu đồ so sánh giữa giá trị tài điện dự báo từ mô hình và tài điện thực tế chủ nhật ngày 22/2/2021.



Hình 5. Biểu đồ so sánh giữa giá trị tài điện dự báo từ mô hình và tài điện thực tế trong 1 tuần từ 22/2 đến 28/2 năm 2021.



Hình 6. Biểu đồ so sánh giữa giá trị tài điện dự báo từ mô hình và tài điện thực tế trong 1 tuần từ 22/2 đến 28/2 năm 2021.

Kết quả chạy mô hình được tóm tắt trên bảng 1. Bảng 1 cho ta thấy, giá trị sai số của kết quả dự báo của mô hình trên số liệu 1 tuần kiểm chứng. Giá trị sai số RMSE là 0,52% và giá trị sai số MAPE là 1,13%.

Bảng 1. Sai số của tải điện dự báo của mô hình với bộ dữ liệu 1 tuần kiểm chứng.

Sai số (%)	Giá trị
RMSE	0.52
MAPE	1.13%

Bảng 2 tóm tắt sai số RMSE và MAPE các ngày trong tuần. Ta thấy, ngày chủ nhật có sai số RMSE thấp nhất và ngày thứ 2 là có sai số RMSE lớn nhất. Đối với sai số MAPE thì ngày thứ 6 có sai số thấp nhất là 1,07% và ngày thứ 2 có sai số lớn nhất là 1,24%.

Bảng 2. Sai số của tải điện dự báo các ngày trong tuần với bộ dữ liệu kiểm chứng.

Sai số (%)	Thứ 2	Thứ 3	Thứ 4	Thứ 5	Thứ 6	Thứ 7	CN
RMSE	0.57	0.56	0.54	0.55	0.52	0.48	0.45
MAPE	1.24	1.12	1.08	1.08	1.07	1.15	1.20

4. KẾT LUẬN

Bài báo đề xuất và xây dựng mô hình dự báo phụ tải điện trước 15 phút trong thị trường điện trong ngày. Mô hình sử dụng mạng nơron hồi tiếp bộ nhớ ngắn – dài hạn (Long-short-term memory LSTM). Ưu điểm của mô hình là đơn giản không yêu cầu các dữ liệu như nhiệt độ, độ ẩm,... Như vậy, mô hình có thể ứng dụng trong trường hợp dự báo phụ tải điện mà các dữ liệu về nhiệt độ, độ ẩm không sẵn có. Đặc tính tải điện của một ngày trong lịch sử được thu thập và đưa vào mô hình để từ đó dự báo được phụ tải điện trước 15 phút. Kết quả kiểm chứng mô hình với bộ dữ liệu tải điện trong 1 tuần của Italia cho sai số nằm trong khoảng 1%. Ngoài ra, mô hình dự báo này có thể tích hợp vào phần mềm quản lý điện năng của nhà máy, tòa nhà (PMS) để đưa ra các dự báo tiêu thụ điện cho các giờ tới.

TÀI LIỆU THAM KHẢO

- [1]. P. Shinde and M. Amelin, "A Literature Review of Intraday Electricity Markets and Prices", 2019 IEEE Milan PowerTech, pp. 1-6, (2019), doi: 10.1109/PTC.2019.8810752.
- [2]. A. Khan and M. Rizwan, "ANN and ANFIS Based Approach for Very Short Term Load Forecasting: A Step Towards Smart Energy Management System," 2021 8th International Conference on Signal Processing and Integrated Networks (SPIN), (2021).
- [3]. H. Aoyang, Z. Shengqi, J. Xuehui and Z. Zhisheng, "Short-term Load Forecasting Model Based on RBF Neural Network Optimized by Artificial Bee Colony Algorithm," 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE), (2021).
- [4]. M. Bashari and A. Rahimi-Kian, "Forecasting Electric Load by Aggregating Meteorological and History-based Deep Learning Modules," 2020 IEEE Power & Energy Society General Meeting (PESGM), (2020).
- [5]. M. Kumar and R. Krishan, "Non-Linear Auto-Regressive Modeling based Day-ahead BESS Dispatch Strategy for Distribution Transformer Overload Management," 2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE), (2021).
- [6]. M. Khashei and M. Bijari, "A novel hybridization of artificial neural networks and arima models for time series forecasting," Applied Soft Computing, vol. 11, no. 2, pp. 2664–2675, (2011).

- [7]. K.-Y. Chen and C.-H. Wang, "A hybrid sarima and support vector machines in forecasting the production values of the machinery industry in taiwan," Expert Systems with Applications, vol. 32, no. 1, pp. 254–264, (2007).
- [8]. C.-L. Hor, S. J. Watson, and S. Majithia, "Daily load forecasting and maximum demand estimation using arima and garch," in Probabilistic Methods Applied to Power Systems, 2006. PMAPS 2006. IEEE international Conf. pp. 1–6, (2006).
- [9]. K. M. Kam, "Stationary and non-stationary time series prediction using state space model and pattern-based approach". The University of Texas at Arlington, (2014).
- [10]. M. Lineesh, K. Minu, and C. J. John, "Analysis of nonstationary nonlinear economic time series of gold price: A comparative study," in International Mathematical Forum, vol. 5, no. 34. Citeseer, pp. 1673–1683, (2010).
- [11]. YanyingLi, JinxingChe, YoulongYang, "Subsampled support vector regression ensemble for short term electric load forecasting", Energy Volume 164, Pages 160-170, (2018).
- [12]. A. Navot, L. Shpigelman, N.Tishby, E.Vaadia, "Nearest Neighbor Based Feature Selection for Regression and its Application to Neural Activity", Advances in Neural Information Processing Systems 18 [Neural Information Processing Systems, NIPS 2005, December 5-8], (2005).
- [13]. H. S. Hippert, C. E. Pedreira and R. C. Souza, "Neural Networks for ShortTerm Load Forecasting: a Review and Evaluation", IEEE Transactions on Power Systems, vol. 16, no. 1, pp. 44-55, (2001).
- [14]. Kunjin Chen, Kunlong Chen, Qin Wang, Ziyu He, Jun Hu, Jinliang He, "Short-Term Load Forecasting With Deep Residual Networks", IEEE Transactions on Smart Grid, Volume: 10, Issue: 4, (2019).
- [15]. P. Mandal, T. Senjyu, N. Urasaki and T. Funabashi, "A neural network based several-hour-ahead electric load forecasting using similar days approach", Elec. Power and Energy Systems, vol. 28, pp. 367-373, (2006).
- [16]. Ying Chen, Peter B. Luh, Che Guan, Yige Zhao, Laurent D. Michel, Matthew A. Coolbeth, Peter B. Friedland, "Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks", IEEE Transactions on Power Systems, Volume: 25, Issue: 1, (2010).
- [17]. <https://www.terna.it/en/electric-system/transparency-report/total-load>.

ABSTRACT

Electrical load forecasting in intraday markets using neural network based on long-short term memory

Load forecasting plays an important role for buyers participating into electricity markets. Buyers need to be able to forecast load demand 15 minutes in advance for participating in the intraday market. Thus, the problem of predicting the electricity load 15 minutes in advance plays a vital role in participating into the intraday market. Due to the non-linearity and instability under natural conditions of electrical loads in small-scale power systems, accurate forecasting is still a challenge. This paper investigates the use of Long-Short-Term-Memory (LSTM) short-term memory structure based on feedback neural network structure to predict the electricity load 15 minutes in advance.

Keywords: Time series; Intraday electricity market; Recurrent neural network (RNN); Long-short-term-memory (LSTM).