

SỬ DỤNG MẠNG NƠ-RON NHÂN TẠO DỰ BÁO MỨC NƯỚC SÔNG CHỊU ẢNH HƯỞNG CỦA THỦY TRIỀU

Hồ Việt Tuấn

Công ty TNHH Framgia Việt Nam

Hồ Việt Hùng

Trường Đại học Thủy Lợi

Tóm tắt: Mạng nơ-ron hồi quy (Recurrent Neural Network - RNN) được sử dụng rộng rãi trong nhiều lĩnh vực khác nhau, trong đó có thủy lợi. Các mô hình RNN được ứng dụng để dự báo mực nước sông, lưu lượng đến hồ chứa... Trong bài báo này, các tác giả đã thiết lập một mô hình Long Short-Term Memory network (LSTM), một dạng đặc biệt của RNN, để dự báo mực nước ở hạ lưu cống - âu thuyền Cầu Cát thuộc hệ thống thủy lợi Bắc Hưng Hải. Dữ liệu đầu vào của mô hình chỉ là mực nước ở hạ lưu cống Cầu Cát trong quá khứ, kết quả dự báo là mực nước ở đó cho 6 giờ, 12 giờ, 18 giờ và 24 giờ trong tương lai. Mô hình mà các tác giả đề xuất cho kết quả có độ chính xác cao và ổn định, hệ số Nash dao động từ 95.3% đến 91.6% tương ứng với các trường hợp dự báo. Vì vậy, có thể ứng dụng mô hình này để dự báo mực nước tại các cống vùng triều, giúp cho việc vận hành cống an toàn, hiệu quả.

Từ khóa: Mạng nơ-ron hồi quy (RNN), LSTM, dự báo mực nước, âu thuyền Cầu Cát.

Summary: Recurrent Neural Network (RNN) is widely used in many different fields, including irrigation. RNN models have been applied to forecast river water levels, reservoir's inflow... In this paper, the authors developed a Long Short-Term Memory Network model (LSTM), a special type of RNN, to predict water levels downstream of Cau Cat Culvert in the Bac Hung Hai irrigation system. The input data of the model are just the water levels downstream of Cau Cat Culvert in the past, the predicted result is the water level there for 6 hours, 12 hours, 18 hours and 24 hours of lead-time in the future. The model proposed by the authors provides results with high accuracy and stability, with Nash coefficients ranging from 95.3% to 91.6% corresponding to the predicted cases. Therefore, it is possible to use this model to forecast the water level in the tidal sluice, helping to operate the culvert safely and effectively.

Key words: Recurrent Neural Network (RNN), LSTM, forecast river water levels, Cau Cat Culvert.

1. GIỚI THIỆU CHUNG

Trí tuệ nhân tạo (Artificial Intelligence - AI) ngày càng được ứng dụng rộng rãi trong nhiều lĩnh vực khác nhau của đời sống. AI có thể được áp dụng trong ngành Thủy lợi để dự báo mực nước hoặc lưu lượng dòng chảy trong sông nhằm cảnh báo lũ, góp phần giảm nhẹ và phòng ngừa tác hại của lũ lụt, hoặc dự báo mực nước

ở các cống tưới tiêu kết hợp nhằm giúp cho quy trình vận hành cống phù hợp và hiệu quả. Nhằm giúp độc giả hiểu rõ hơn các ứng dụng của AI trong lĩnh vực tài nguyên nước, bài báo này trình bày một mô hình áp dụng mạng nơ-ron nhân tạo (Artificial Neural Network - ANN) để dự báo mực nước sông vùng chịu ảnh hưởng của thủy triều.

Ngày nhận bài: 11/10/2018

Ngày thông qua phản biện: 30/11/2018

Ngày duyệt đăng: 05/12/2018

Từ trước đến nay, các mô hình thủy lực được áp dụng rộng rãi ở Việt Nam cũng như trên thế giới để tính toán dòng chảy trong sông vùng chịu ảnh hưởng của thủy triều, phục vụ cho công tác quy hoạch phòng chống lũ lụt hay hạn hán, xâm nhập mặn. Tuy nhiên, các mô hình này thường yêu cầu một lượng lớn các dữ liệu đầu vào như địa hình, lượng mưa, các lưu lượng chảy qua cống lấy nước hay thoát nước... Các thông số của mô hình phải được hiệu chỉnh và kiểm định dựa trên nhiều tài liệu thực đo, do đó không dễ dàng lựa chọn các thông số phù hợp. Trong trường hợp không có đủ tài liệu địa hình, địa mạo và tùy theo nhu cầu thực tế, mô hình mạng nơ-ron nhân tạo (ANN) có thể được áp dụng để dự báo các yếu tố thủy văn, thủy lực của dòng chảy. Các mô hình ANN dựa trên mối quan hệ giữa các dữ liệu đầu vào và đầu ra để học các quy luật trong quá khứ từ đó đưa ra các dự báo trong tương lai.

Trên thế giới, các mô hình ANN đã được sử dụng để dự báo lũ từ năm 1990. Sau đó, các nhà khoa học đã áp dụng và cải tiến các thuật toán trong mô hình ANN nhằm tăng độ chính xác trong dự báo (Lê Xuân Hiền, Hồ Việt Hùng, 2018) [1]. Asaad Y. Shamseldin (2010) [5] đã khai thác sử dụng mạng nơ-ron nhân tạo để dự báo lưu lượng dòng chảy sông Nile xanh ở Sudan. Trong nghiên cứu này, tác giả đã sử dụng giá trị lưu lượng dòng chảy trung bình ngày của sông Nile xanh đo tại Eldeim gần biên giới Sudan - Ethiopia và dữ liệu lượng mưa trung bình ngày trong khu vực cho giai đoạn bốn năm 1992-1995 để dự báo. Chen, J.F. và nnk (2014) [6] đã sử dụng thuật toán Cuckoo Search để dự báo lưu lượng dòng chảy đến hồ Hòa Bình, Việt Nam. Ngoài ra, có thể kể đến các nghiên cứu ở trong nước như: Trương Xuân Nam, Nguyễn Thanh Tùng (2016) đã sử dụng phương pháp Học sâu để dự báo lưu lượng nước đến hồ Hòa Bình [4]. Trong nghiên cứu này, các tác giả đã sử dụng dữ liệu đầu vào là lưu lượng mùa kiệt từ năm 1964 đến 2002 với bước thời gian quan trắc 10 ngày và đưa ra dự báo lưu

lượng dòng chảy cho 10 ngày sau đó. Lê Xuân Hiền, Hồ Việt Hùng (2018) đã ứng dụng mô hình bộ nhớ gần xa, Long Short-Term Memory (LSTM) để dự báo mực nước tại các trạm thủy văn ở Hải Phòng, khu vực bị ảnh hưởng của thủy triều. Các tác giả đã sử dụng dữ liệu là mực nước giờ để dự báo mực nước trong tương lai từ 1 giờ đến 5 giờ, tại trạm Quang Phục và Cửa Cấm [1]. Hồ Việt Hùng và nnk (2018) đã xây dựng một mô hình toán dựa trên mạng nơ-ron hồi quy (Recurrent Neural Network - RNN), một dạng ứng dụng chuyên sâu của mô hình ANN, để dự báo lưu lượng lũ sông Đà tại Lai Châu trước 1 ngày [2] và dự báo lưu lượng dòng chảy sông Hồng tại trạm Sơn Tây trước 1 ngày, 2 ngày và 3 ngày [3]. Mô hình mà các tác giả đề xuất không đòi hỏi các dữ liệu về địa hình và thảm phủ bề mặt lưu vực sông, chỉ cần các dữ liệu về lưu lượng dòng chảy. Lê Xuân Hiền và nnk (2018) đã sử dụng mô hình LSTM để dự báo lưu lượng nước về hồ Hòa Bình trước 6 giờ, 12 giờ và 18 giờ [7]. Những nghiên cứu kể trên cho thấy rằng, các mô hình dự báo dòng chảy dựa trên ANN ngày càng phổ biến và có thể ứng dụng rộng rãi trong ngành Thủy lợi.

Trong bài báo này, các tác giả xây dựng một mô hình mạng nơ-ron hồi quy (RNN) để dự báo mực nước ở hạ lưu cống – âu thuyền Cầu Cát thuộc hệ thống thủy lợi Bắc Hưng Hải, với 4 trường hợp dự báo: 6 giờ, 12 giờ, 18 giờ và 24 giờ.

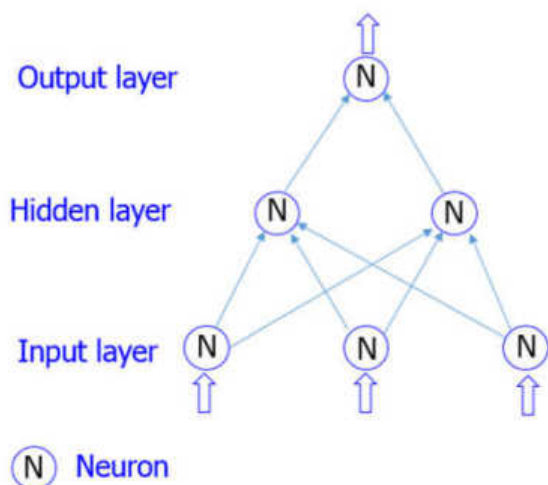
2. PHƯƠNG PHÁP NGHIÊN CỨU VÀ DỮ LIỆU ĐẦU VÀO

2.1. Mạng nơ-ron hồi quy (RNN) và mạng LSTM

Mạng nơ-ron nhân tạo được mô phỏng dựa trên hoạt động của hệ thống thần kinh động vật, là mô hình xử lý thông tin nhờ một lượng lớn các nơ-ron được gắn kết với nhau. Cấu trúc cơ bản của một ANN gồm 3 thành phần, được gọi là: lớp dữ liệu đầu vào (Input layer), lớp ẩn (Hidden layer) và lớp dữ liệu đầu ra (Output layer) như Hình 1 [3]. Một ANN có thể có một

hoặc nhiều lớp ẩn, phụ thuộc vào kích thước của tập dữ liệu đầu vào và yêu cầu về độ chính xác của kết quả dự báo.

Mạng nơ-ron hồi quy (RNN) khác với mạng ANN truyền thống là: nó chứa các vòng lặp bên trong, cho phép thông tin có thể lưu lại được. Long Short-Term Memory networks (LSTM)

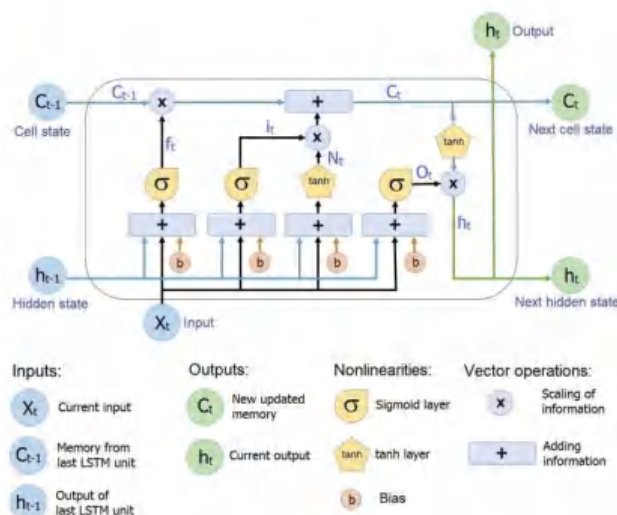


Hình 1: Cấu trúc của một ANN [3]

Mạng LSTM có kiến trúc dạng chuỗi gồm các mô đun lặp đi lặp lại, nó không chỉ có 1 tầng nơ-ron như RNN chuẩn mà có tới 4 tầng tương tác với nhau một cách đặc biệt (Hình 2) [1]. Mỗi mô đun LSTM gồm có trạng thái tế bào (cell state) và các cổng (gate). Trạng thái tế bào chạy xuyên suốt qua tất cả các mô đun giúp thông tin được truyền đạt dễ dàng, còn cổng là nơi sàng lọc thông tin đi qua nó, có 3 cổng và 4 tầng trong một mô đun LSTM. Đầu tiên là tầng của cổng quên f_t (forget gate layer), nó sẽ quyết định thông tin nào cần bỏ đi từ trạng thái tế bào. Đầu vào của tầng này là h_{t-1} (giá trị đầu ra tại thời điểm $t-1$) và x_t (dữ liệu đầu vào, hiện tại); đầu ra của nó là f_t , một số trong khoảng từ 0 đến 1 cho mỗi số trong trạng thái tế bào C_{t-1} .

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

là một dạng đặc biệt của RNN nhằm giải quyết các bài toán có sự phụ thuộc dài hạn (long-term dependency). LSTM xuất hiện lần đầu tiên vào năm 1997, sau đó đã được cải tiến và phổ biến rộng rãi. Nhiều mô hình dự báo đã cho kết quả tốt khi sử dụng LSTM vì nó có khả năng học được các phụ thuộc xa và ghi nhớ thông tin trong một khoảng thời gian dài [2].



Hình 2: Cấu trúc của một mô đun LSTM [1]

Trong đó: σ là hàm sigmoid, W_f và b_f lần lượt là trọng số và tham số của tầng cổng quên.

Hai tầng tiếp theo sẽ quyết định thông tin lưu vào trạng thái tế bào và cập nhật giá trị cho trạng thái này, đó là tầng cổng vào i_t (input gate layer) và một tầng tanh N_t (tanh layer).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$N_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

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

Trong đó: C_{t-1} và C_t là trạng thái tế bào lần lượt ở thời điểm $t-1$ và t ; W_i và b_i lần lượt là trọng số và tham số của tầng cổng vào. W_C và b_C là trọng số và tham số của trạng thái tế bào; \tanh là hàm hyperbolic tangens.

Cuối cùng là tầng công ra o_t (output gate), giá trị đầu ra (h_t) sẽ được quyết định bởi trạng thái tế bào muốn xuất ra.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Trong đó: W_o và b_o lần lượt là trọng số và tham số của tầng công ra.

Trong nghiên cứu này, thư viện phần mềm mã nguồn mở TensorFlow của Google, các thư viện Numpy, Pandas, Keras cùng với ngôn ngữ lập trình Python 3.6 đã được sử dụng để thiết lập một mô hình LSTM.

2.2. Phương pháp đánh giá

Để đánh giá mức độ chính xác của kết quả mô hình, các tác giả sử dụng hai trị số, đó là RMSE (Root Mean Squared Error – sai số căn quân phương) và NSE (Nash Sutcliffe Efficiency – hệ số Nash), được tính toán bằng các công thức (7) và (8) [1].

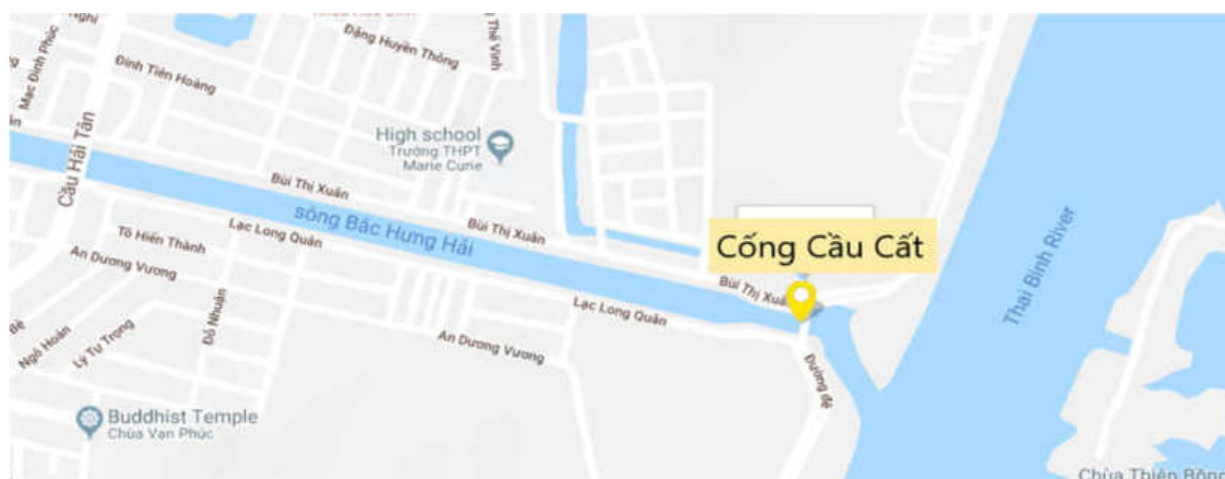
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (7)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (8)$$

Trong đó: O_i , \bar{O}_i và P_i lần lượt là giá trị thực đo, giá trị thực đo trung bình và giá trị dự báo của mẫu thứ i . Mô hình dự báo có độ chính xác cao khi giá trị của RMSE nhỏ và NSE lớn.

2.3. Dữ liệu đầu vào của mô hình

Mô hình LSTM được xây dựng để dự báo mực nước ở hạ lưu cống – âu thuyền Cầu Cát, nối sông Bắc Hưng Hải với sông Thái Bình (Hình 3). Đây là một trong các cống chính của hệ thống thủy lợi Bắc Hưng Hải, cống – âu thuyền kết hợp lấy nước hoặc tiêu nước ra sông Thái Bình, có hệ thống đo mực nước 6 giờ một lần, vào lúc 1h, 7h, 13h, 19h. Cống có 1 cửa với kích thước B x H= 6.0 x 6.45 m; Cao trình đáy cống là -1.50 m [8].



Hình 3: Vị trí cống Cầu Cát trong sơ đồ hệ thống Bắc Hưng Hải

Dữ liệu đầu vào của mô hình là mực nước hạ lưu cống Cầu Cát, phía sông Thái Bình, 6 giờ đo một lần, từ 01h ngày 01/01/2000 đến 19h ngày 10/11/2018 (27559 số liệu). Tập dữ liệu này được chia thành 3 phần. Phần thứ nhất là chuỗi số liệu được đo đạc trong 18 năm (26059

số liệu) từ 01h ngày 01/01/2000 đến 19h ngày 31/10/2017 dùng để hiệu chỉnh (training) mô hình và lựa chọn các thông số tốt nhất cho mô hình LSTM. Phần thứ hai là chuỗi số liệu thực đo trong 1 năm (1460 số liệu), từ 01h ngày 01/11/2017 đến 19h ngày 31/10/2018, dùng để

kiểm định (test) các thông số mô hình. Phần thứ ba là các số liệu thực đo trong 10 ngày đầu tháng 11/2018 dùng để dự báo thử mực nước hạ lưu công Cầu Cát và so sánh kết quả dự báo với mực nước thực đo tại công này.

2.4. Thiết kế mô hình

Mô hình LSTM được xây dựng để dự báo mực nước lần lượt cho từng trường hợp: 6 giờ, 12 giờ, 18 giờ và 24 giờ. Với mỗi trường hợp, các thông số của mô hình có thể được điều chỉnh bằng cách thử dần cho đến khi đạt kết quả tốt nhất. Mô hình cũng được lập trình để tự động tính các trị số của RMSE và NSE theo công thức (7) và (8). Sau quá trình hiệu chỉnh và kiểm định, các thông số phù hợp nhất của mô hình cho mỗi trường hợp đã được lựa chọn để phục vụ việc dự báo. Dữ liệu đầu vào của mô hình LSTM là mực nước thực đo trong 12 bước thời gian gần nhất (từ $t-11$, $t-10$,... đến $t-0$), tức trong 72 giờ gần nhất trước thời điểm t , để dự báo cho 6 giờ, 12 giờ, 18 giờ hoặc 24 giờ trong tương lai sau thời điểm t (tức $t+1$, $t+2$, $t+3$, $t+4$). Chiều dài chuỗi là 12 bước thời gian (time step) vì 72 giờ gần nhất tác động tới kết quả dự báo nhiều nhất, các số liệu trong quá khứ xa hơn chỉ bổ sung thêm thông tin. Số lượng mô đun (LSTM cells) cũng được lựa chọn dựa trên kết quả tính thử dần của từng trường hợp, với 42 hoặc 43 mô đun, NSE có trị số cao nhất. Để tránh hiện tượng quá khớp với thực đo (Over

fitting) trong quá trình hiệu chỉnh mô hình, kỹ thuật dừng lại sớm (Early stopping) đã được sử dụng. Do đó, số lần lặp (Epoch) là do mô hình tự động chọn và nó tự dừng tính toán khi có kết quả tốt. Như vậy, các thông số cũng như cấu trúc của mô hình được chọn thông qua quá trình thử dần và được đánh giá dựa trên các trị số RMSE và NSE.

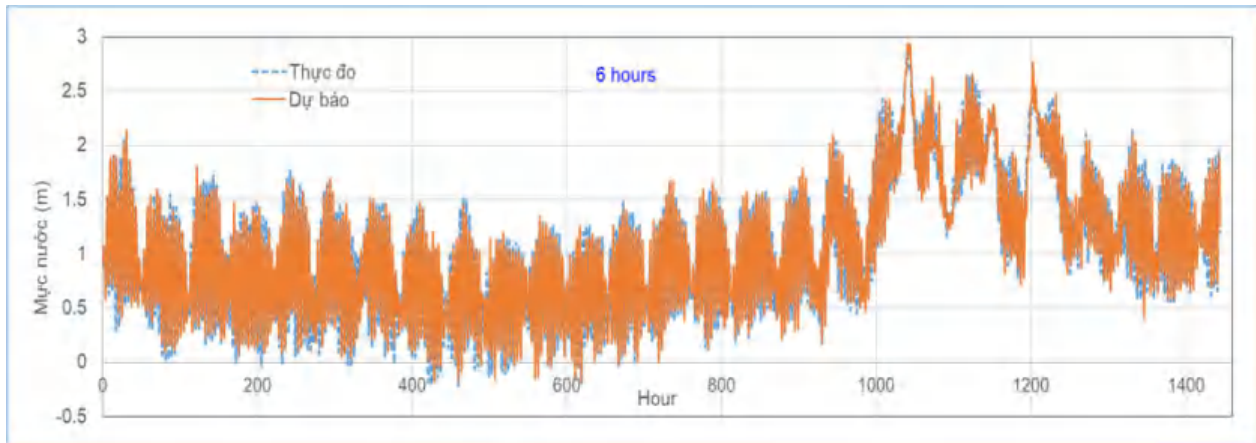
3. KẾT QUẢ NGHIÊN CỨU

3.1. Kết quả kiểm định mô hình


Sử dụng cấu trúc mô hình đã được lựa chọn như trên, các tác giả tiến hành kiểm định mô hình cho tất cả 4 trường hợp, với thời gian dự báo là 6 giờ, 12 giờ, 18 giờ và 24 giờ, bằng cách so sánh kết quả dự báo với số liệu thực đo mực nước tại hạ lưu công Cầu Cát trong thời gian 1 năm, từ ngày 01/11/2017 đến ngày 31/10/2018. Kết quả kiểm định mô hình được thể hiện trên các đồ thị từ Hình 4 đến Hình 8 và Bảng 1. Có thể thấy rằng, kết quả kiểm định có độ chính xác cao, hệ số NSE dao động từ 95.3% đến 91.6%. Khi có lũ trên sông Thái Bình, đỉnh lũ kết hợp với đỉnh triều làm mực nước dâng cao nhưng mô hình vẫn dự báo đúng thời gian xuất hiện đỉnh lũ. Tuy nhiên, mực nước dự báo chân triều có xu hướng cao hơn thực đo khi dự báo 12 giờ và xa hơn. Dự báo 6 giờ cho kết quả tốt nhất với sai số RMSE chỉ có 13cm. Khi dự báo xa hơn cho tương lai, độ chính xác (hệ số NSE) giảm xuống.

Bảng 1: Thông số mô hình và kết quả kiểm định cho 4 trường hợp

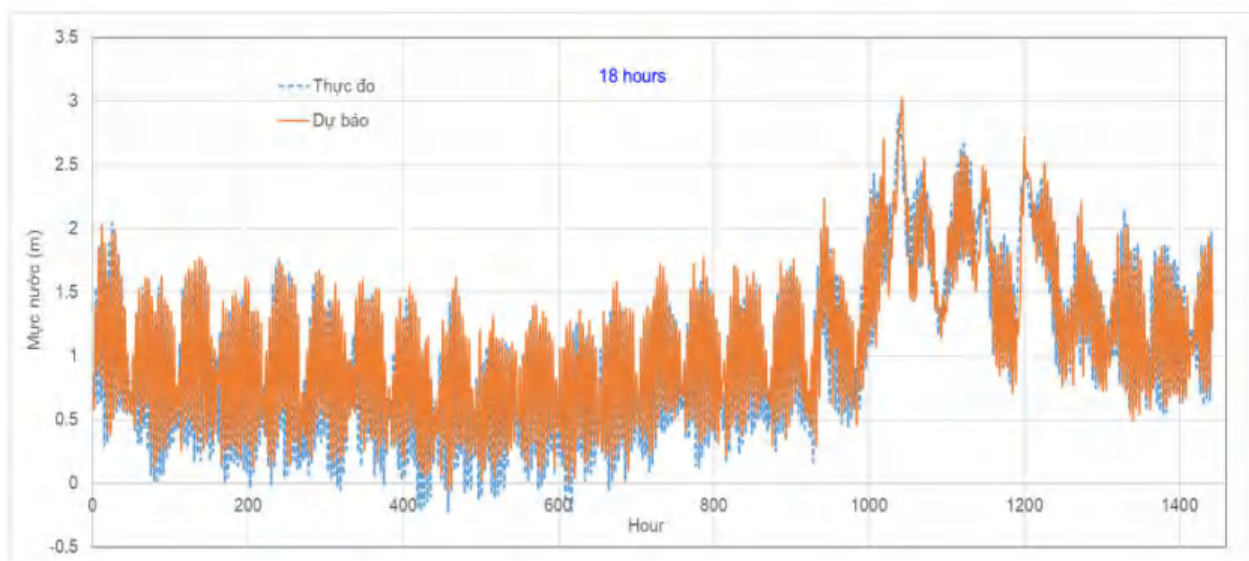
Dự báo (h)	Chiều dài chuỗi (số)	Số trạm đo MN	LSTM cells	Số lần lặp	RMSE (m)	NSE (%)
6	12	1	42	1200	0.131	95.3%
12	12	1	43	940	0.174	91.7%
18	12	1	42	1349	0.171	92.0%
24	12	1	43	1281	0.176	91.6%




Hình 4: So sánh số liệu thực đo với mực nước dự báo 6 giờ




Hình 5: So sánh số liệu thực đo với mực nước dự báo 12 giờ



Hình 6: So sánh số liệu thực đo với mực nước dự báo 18 giờ



Hình 7: So sánh số liệu thực đo với mực nước dự báo 24 giờ



Hình 8: So sánh mực nước thực đo với dự báo 6 giờ (trái) và 24 giờ (phải)

Sau quá trình hiệu chỉnh và kiểm định, các thông số của mô hình đã được chọn cho từng trường hợp. Sau đó, tất cả các số liệu của phần 1 và phần 2 trong tập dữ liệu đầu vào đã được tập hợp để hoàn thành (Finalize) 4 mô hình dự báo. Các mô hình này được ghi lại thành 4 files dưới định dạng *.h5 phục vụ việc dự báo.

3.1. Kết quả dự báo mực nước trong tương lai gần

Để tiến hành dự báo thử nghiệm cho từng trường hợp, chúng tôi cho chạy các file định dạng *.h5 trong môi trường Python 3.6 sử dụng TensorFlow backend, keras, numpy, pandas, sklearn.

Phần dữ liệu thứ ba gồm 5 ngày, từ ngày 01/11/2018 đến 05/11/2018 đã được sử dụng, trong đó: 72 giờ của 4 ngày đầu được dùng như dữ liệu đầu vào của mô hình để đưa ra kết quả dự báo mực nước, 24 giờ của ngày cuối cùng được dùng để đánh giá kết quả dự báo. Đây là tập dữ liệu độc lập và chưa được sử dụng trước đây nhằm đảm bảo tính khách quan của kết quả dự báo. Kết quả dự báo được so sánh với số liệu thực đo trong ngày 4/11 và ngày 5/11/2018. Các thông số mô hình và kết quả dự báo mực nước ở hạ lưu cống Cầu Cát với 4 trường hợp khác nhau được thể hiện trong Bảng 2.

Có thể thấy rằng, chênh lệch giữa kết quả dự báo và thực đo là nhỏ, từ 1cm đến 13cm. Lúc 19h ngày 4/11/2018 xuất hiện đỉnh triều nên sai số dự báo lên tới 13cm (8.5%), mặc dù chỉ dự báo 6 giờ. Dự báo xa nhất, 24 giờ, cũng có sai số 13cm (11.2%), đây là sai số lớn nhất. Vào các thời điểm còn lại sai số nhỏ hơn (1cm

và 3cm). Rõ ràng việc đo mực nước 6 giờ một lần cũng ảnh hưởng đến kết quả dự báo. Nếu mực nước được đo 3 giờ một lần, hoặc mỗi 2 giờ thì kết quả dự báo sẽ tốt hơn, độ chính xác sẽ tăng lên, vì đây là vùng chịu ảnh hưởng của thủy triều, mực nước thay đổi nhanh theo từng giờ.

Bảng 2: Thông số mô hình và kết quả dự báo thử nghiệm

Ngày, Tháng, Năm	Giờ	Dự báo (h)	Chiều dài chuỗi SL (số)	LSTM cells	Số lần lặp	MN thực đo (m)	MN dự báo (m)	Chênh lệch (m)	Sai số (%)
4-Nov-2018	19:00	6	12	42	4000	1.53	1.40	-0.13	-8.5
5-Nov-2018	1:00	12	12	43	2135	0.96	0.93	-0.03	-3.1
5-Nov-2018	7:00	18	12	42	2657	0.67	0.68	0.01	1.5
5-Nov-2018	13:00	24	12	43	2628	1.16	1.29	0.13	11.2

4. KẾT LUẬN

Trong bài báo này, các tác giả đã trình bày phương pháp nghiên cứu để xây dựng một mô hình LSTM và sử dụng nó để dự báo mực nước ở hạ lưu cống Cầu Cát thuộc hệ thống thủy lợi Bắc Hưng Hải. Dữ liệu đầu vào chỉ là mực nước ở hạ lưu cống Cầu Cát trong quá khứ, từ ngày 01/01/2000 đến ngày 31/10/2018. Kết quả dự báo là mực nước tại cống này sau thời

điểm kể trên 6 giờ, 12 giờ, 18 giờ và 24 giờ. Sản phẩm của nghiên cứu này là 4 files, người sử dụng có thể chạy các file này để dự báo mực nước ở hạ lưu cống Cầu Cát cho 6 giờ, 12 giờ, 18 giờ và 24 giờ tương lai, sau khi nhập các số liệu mực nước của 72 giờ trước đó. Mô hình mà các tác giả đề xuất cho kết quả có độ chính xác cao và ổn định, nó có thể dự báo mực nước tại các cống vùng triều, giúp cho việc quản lý, vận hành cống an toàn, hiệu quả.

TÀI LIỆU THAM KHẢO

- [1] Lê Xuân Hiền, Hồ Việt Hùng (2018). “Ứng dụng mạng Long Short-Term Memory (LSTM) để dự báo mực nước tại trạm Quang Phục và Cửa Cấm, Hải Phòng, Việt Nam”. Tạp chí Thủy lợi và môi trường số 62 (tháng 9/2018), Đại học Thủy lợi.
- [2] Hồ Việt Hùng, Lê Xuân Hiền, Giha Lee (2018). “xây dựng mô hình mạng nơ-ron hồi quy dựa trên phần mềm mã nguồn mở để dự báo lưu lượng dòng chảy”. Tuyển tập Hội nghị Khoa học thường niên năm 2018, Đại học Thủy lợi.
- [3] Hồ Việt Hùng, Lê Xuân Hiền, Giha Lee (2018). “Ứng dụng mạng thần kinh nhân tạo dự báo lưu lượng dòng chảy sông Hồng tại Sơn Tây dựa trên dữ liệu ở thượng lưu”. Hội nghị Khoa học thường niên năm 2018, Hội Cơ học Thủy khí.

- [4] Trương Xuân Nam, Nguyễn Thanh Tùng (2016). “Deep learning: Ứng dụng cho dự báo lưu lượng nước đến hồ chứa Hòa Bình”. Tuyển tập Hội nghị Khoa học thường niên năm 2016, Đại học Thủy lợi.
- [5] Asaad Y. Shamseldin (2010). “Artificial neural network model for river flow forecasting in a developing country”. Journal of Hydroinformatics, 12.1.
- [6] Chen, J.F., Hsieh, H.N., and Do, Q.H. (2014). “Forecasting Hoabinh Reservoir’s Incoming Flow: An Application of Neural Networks with the Cuckoo Search Algorithm”. Information. 5, 570-586.
- [7] Le, X.H., Ho, V.H., Lee, G.H., and Jung, S.H. (2018) “A Deep Neural Network Application for Forecasting the Inflow into the Hoabinh Reservoir in Vietnam”. Proceeding of International Symposium on Lowland Technology.
- [8] Website: <http://bachunghai.com/default.aspx?user=0&pro=qlct-xemthongsokythuat>