



DỰ BÁO NHU CẦU DU KHÁCH ĐẾN THỪA THIÊN HUẾ DỰA TRÊN MẠNG NƠ-RON NHÂN TẠO

Võ Viết Minh Nhật^{1,*}, Lê Văn Hòa², Nguyễn Thị Thúy Vân², Hoàng Thị Huế²

¹ Cơ quan Đại học Huế, 1 Điện Biên Phủ, Huế, Việt Nam

² Trường Du lịch, Đại học Huế, 22 Lâm Hoàng, Huế, Việt Nam

* Tác giả liên hệ: Võ Viết Minh Nhật <vwmnhat@hueuni.edu.vn>

(Ngày nhận bài: 11-1-2021; Ngày chấp nhận đăng: 19-2-2021)

Tóm tắt. Dự báo chính xác nhu cầu du khách đến tại một điểm đến đóng một vai trò rất quan trọng trong việc tư vấn cho các nhà chính sách để lập kế hoạch và đưa ra các chiến lược liên quan đến đầu tư cơ sở vật chất, nâng cấp hạ tầng và phát triển dịch vụ. Có nhiều cách tiếp cận khác nhau trong dự báo nhu cầu du khách, trong đó dự báo dựa trên dữ liệu chuỗi thời gian đã và đang thu hút được nhiều sự quan tâm nhất do tính chất không có cấu trúc của loại dữ liệu đặc biệt này. Mạng nơ-ron nhân tạo được đánh giá là một phương pháp dự báo đặc biệt phù hợp với loại dữ liệu không có cấu trúc này. Bài báo này nghiên cứu việc sử dụng mạng nơ-ron nhân tạo, bao gồm: MLP, RBF và ELN, để dự báo đối với dữ liệu chuỗi thời gian về du khách đến Thừa Thiên Huế. Các phân tích và so sánh dựa trên mô phỏng chỉ ra rằng mạng RBF cho kết quả dự báo tốt nhất với MSE, RMSE, MAE và MAPE thấp nhất. Kết quả này không chỉ tương đồng với các nghiên cứu trước đây mà còn khẳng định thêm rằng tính năng chuyển đổi không gian từ phi tuyến thành tuyến tính của lớp ẩn đã làm cho RBF trở nên mạnh mẽ đối với loại dữ liệu không có cấu trúc.

Từ khóa: Dự báo nhu cầu du lịch, dữ liệu chuỗi thời gian, mạng nơ-ron nhân tạo, dữ liệu du khách đến Thừa Thiên Huế

Forecasting tourism demand for Thua Thien Hue based on artificial neural networks

Vo Viet Minh Nhat^{1,*}, Le Van Hoa², Nguyen Thi Thuy Van², Hoang Thi Hue²

¹ Hue University, 1 Dien Bien Phu St., Hue, Vietnam

² School of Hospitality and Tourism, Hue University, 22 Lam Hoang St., Hue, Vietnam

* Correspondence to Vo Viet Minh Nhat <vwmnhat@hueuni.edu.vn>

(Received: January 11, 2021; Accepted: February 19, 2021)

Abstract. Accurate tourism demand forecasting for a destination plays a vital role in advising policymakers to plan and devise strategies related to investments in facilities, infrastructure improvements and services development. There are many different approaches in tourism demand forecasting, in which the one based

on time-series data has attracted the most attention due to the unstructured nature of the particular data type. Neural networks have been evaluated as a predictive method specifically suited to this type of unstructured data. This paper examines the usage of neural networks, including MLP, RBF and ELN, to forecast tourism demand using time-series data in Thua Thien Hue. The analysis and comparison based on simulation show that the RBF network gives the best forecast result with the lowest MSE, RMSE, MAE and MAPE. This result is not only consistent with previous studies but also further confirms that the spatial conversion from nonlinear to linear of the hidden layer makes RBF powerful for the non-structural data.

Keywords: Tourism demand forecasting, time-series data, artificial neural networks, tourist arrivals to Thua Thien Hue

1 Đặt vấn đề

Với tác động của quá trình toàn cầu hóa và đời sống con người ngày càng được nâng cao, du lịch đang ngày càng phát triển nhanh chóng. Đối với nhiều vùng miền hay quốc gia, du lịch đóng một vai trò quan trọng và có những đóng góp đáng kể cho sự tăng trưởng GDP (*Gross domestic product*) hay GRDP (*Gross regional domestic product*) của địa phương đó. Du lịch không chỉ thúc đẩy kinh doanh, thương mại và đầu tư vốn mà còn tạo ra nhiều việc làm và khuyến khích tinh thần kinh doanh cho nhiều tầng lớp lao động. Mỗi tỉnh, thành phố, vùng miền hay quốc gia đều luôn muốn biết dữ liệu về du khách đến địa phương mình để có kế hoạch xây dựng, lựa chọn các chiến lược đầu tư và phát triển sản phẩm, dịch vụ phù hợp. Do đó, dự báo tin cậy đóng vai trò rất quan trọng trong quy hoạch du lịch tại mỗi điểm đến.

Dự báo (*forecasting*) về cơ bản là quá trình tổ chức thông tin quá khứ của một hiện tượng để dự đoán tương lai. Trong lĩnh vực du lịch, dự báo nhu cầu du lịch (*tourism demand forecasting*) được thực hiện dựa trên dữ liệu lịch sử về nhu cầu du lịch được thể hiện dưới hình thức chuỗi thời gian (*time series*). Nhu cầu du lịch có thể được đo lường dưới nhiều hình thức khác nhau như số lượng du khách đến/ đi (*tourist arrivals/ departures*), mức chi tiêu/ khoản thu của du lịch (*tourism expenditures/ receipts*), mức xuất khẩu/ nhập khẩu du lịch (*travel exports/ imports*), thời gian lưu trú của du khách (*tourist length of stay*), số đêm nghỉ tại chỗ lưu trú của du khách (*nights spent at tourist accommodation*) v.v. [1]. Do đó, các mô hình dự báo chuỗi thời gian cố gắng xác định xu hướng, độ dốc và chu kỳ (tức thực hiện các phép đo trong các khoảng thời gian liên tiếp) của dữ liệu chuỗi thời gian. Không giống như các phương pháp dựa trên việc quan sát các mẫu ngẫu nhiên, các mô hình dự báo chuỗi thời gian dựa trên các giá trị liên tiếp đại diện cho các phép đo liên tiếp được thực hiện trong các khoảng thời gian cách đều nhau (hàng tháng, hàng quý hoặc hàng năm). Khi một mẫu được thiết lập, các mô hình chuỗi thời gian sẽ tạo ra các dự đoán về giá trị tương lai cho chuỗi thời gian sắp tới.

Sử dụng mạng nơ-ron nhân tạo (*Artificial Neural Networks - ANN*) để dự báo dữ liệu chuỗi

thời gian đã thu hút nhiều sự quan tâm trong hơn hai thập kỷ qua. Một trong những đặc điểm khiến dự báo dựa trên ANN ngày càng được áp dụng rộng rãi là do ANN đóng vai trò như là phương pháp xấp xỉ hàm phổ quát có khả năng ánh xạ bất kỳ hàm tuyến tính hoặc phi tuyến nào trong các điều kiện nhất định. Trái ngược với các mô hình chuỗi thời gian tuyến tính và cũng do tính linh hoạt của nó, ANN thiếu một quy trình hệ thống tiêu chuẩn để xây dựng mô hình. Việc mô hình hóa ANN chủ yếu vẫn dựa trên kinh nghiệm của từng vấn đề được giải quyết. Do đó, việc có được một ANN tin cậy thường liên quan đến việc lựa chọn một số lượng lớn các tham số thực nghiệm, các yêu cầu xác nhận chéo (*cross-validation*) và phụ thuộc vào dữ liệu.

Trong 10 năm trở lại đây, có khá nhiều nghiên cứu liên quan đến việc ứng dụng các mô hình ANN trong dự báo nhu cầu du lịch dựa trên dữ liệu chuỗi thời gian. Đa số các nghiên cứu này xem xét đối với từng trường hợp dữ liệu cụ thể, như dự báo nhu cầu du lịch đến tại một vùng miền [1, 5, 8, 9] hay tại một quốc gia [6, 10–13, 15, 17], dự báo nhu cầu qua đêm tại các cơ sở lưu trú [12, 14], v.v. Cũng không có khẳng định nào về mô hình ANN tốt nhất cho mọi trường hợp [15]. Trong bài báo này, chúng tôi nghiên cứu mô hình mạng nơ-ron cho việc dự báo nhu cầu du lịch đến điểm đến Thừa Thiên Huế, nhằm đề xuất một hướng tiếp cận mới trong việc dự báo đối với địa phương này. Cũng như đa số các nghiên cứu khác, ba mô hình ANN, gồm mạng perceptron đa lớp (*Multi-layer Perceptron - MLP*), hàm xuyên tâm cơ sở (*Radial Basis Function - RBF*) và mạng hồi quy Elman (*Elman Network - ELN*), được xây dựng, mô hình hoá và thử nghiệm với dữ liệu du khách đến Thừa Thiên Huế trong giai đoạn từ 01/2017 đến 12/2019.

Đóng góp của bài báo bao gồm:

- Mô hình hoá bài toán dự báo dựa trên dữ liệu chuỗi thời gian mà từ đó các mô hình mạng nơ-ron khác nhau có thể được sử dụng để thực hiện dự báo;
- Xây dựng ba mô hình mạng nơ-ron gồm MLP, RBF và ELN để phục vụ cho việc dự báo;
- Xây dựng các kịch bản mô phỏng thử nghiệm khác nhau, trong đó những kiểu véc-tơ đầu vào khác nhau được thử nghiệm, số nơ-ron của lớp ẩn được phân tích và khảo sát. Từ đó chỉ ra được loại mạng nơ-ron phù hợp cho dự báo đối với dữ liệu chuỗi thời gian không có cấu trúc.

Nội dung tiếp theo của bài báo bao gồm 4 mục. Mục 2 tóm lược và đánh giá các nghiên cứu liên quan trong 10 năm trở lại đây, trong đó tập trung vào các mô hình ứng dụng mạng nơ-ron trong dự báo nhu cầu du lịch. Trên cơ sở các phân tích, Mục 3 sẽ mô tả chi tiết các bước xây dựng mạng nơ-ron cho bài toán dự báo nhu cầu du lịch dựa trên chuỗi thời gian, bao gồm: phân tích, chuẩn hóa và chuẩn bị dữ liệu cho việc huấn luyện và xây dựng ba mô hình mạng nơ-ron MLP, RBF và ELN cho dự báo nhu cầu du khách đến tại Thừa Thiên Huế. Các phân tích về độ chính xác dự báo của các mạng nơ-ron được mô tả ở Mục 4. Cuối cùng, kết luận được trình bày trong Mục 5.

2 Các nghiên cứu liên quan

Đã có nhiều nghiên cứu liên quan đến việc xây dựng mô hình và ứng dụng ANN vào dự báo nhu cầu du lịch. Các mô hình ANN được đề xuất có thể là mô hình mạng nơ-ron đơn thuần (như MLP, RBF, ELN, v.v.) hoặc mô hình kết hợp, chẳng hạn như kết hợp giải thuật di truyền với mạng nơ-ron trong việc xác định số nơ-ron ẩn tối ưu [2] hay kết hợp Box-Jenkins với mạng nơ-ron trong việc tính tổng kết quả dự báo thành phần có trọng số [3]. Trong bài báo này chúng tôi chỉ quan tâm đến việc đánh giá các mô hình ANNs đơn thuần khi ứng dụng vào dự báo nhu cầu du lịch. Sau đây là tóm lược các đánh giá về ứng dụng ANN trong dự báo nhu cầu du lịch từ năm 2011 đến nay.

Trong nghiên cứu của mình, Fernandes và cs. [5] đã phân tích khả năng cạnh tranh của điểm đến du lịch dựa trên dự báo nhu cầu du khách đến với sử dụng phương pháp mạng perceptron đa lớp (MLP). Nghiên cứu này tập trung vào dữ liệu về lượng khách qua đêm hàng tháng tại các khách sạn ở hai khu vực miền Bắc và miền Trung của Bồ Đào Nha. Kết quả thực nghiệm chỉ ra rằng mô hình ANN cho độ chính xác dự báo cao. Từ đó các tác giả này cũng khuyến cáo rằng phương pháp ANN nên được sử dụng cho dữ liệu chuỗi thời gian có hành vi phi tuyến.

Nghiên cứu của Lin, Chen và Lee [6] cố gắng xây dựng các mô hình dự báo về lượng du khách đến Đài Loan bằng cách sử dụng phương pháp trung bình trượt kết hợp tự hồi quy (*autoregressive integrated moving average* – ARIMA), ANN và hồi quy đa biến tự thích nghi (*multivariate adaptive regression splines* – MARS). Để đánh giá tính phù hợp của các mô hình được đề xuất, tập dữ liệu về du khách đến Đài Loan hàng tháng được sử dụng. Kết quả phân tích cho thấy ARIMA vượt trội hơn so với ANN và MARS dựa trên sai số trung bình bình phương gốc (*root mean square error* – RMSE), sai số trung bình tuyệt đối (*mean absolute error* – MAD) và sai số phần trăm tuyệt đối trung bình (*mean absolute percent error* – MAPE) trong dự báo nhu cầu du lịch.

Trong nghiên cứu của Teixeira và Fernandes [7], mạng nơ-ron truyền thẳng (*feedforward neural network* – FFNN), mạng nơ-ron truyền phân cấp (*cascade forward neural network* – CFNN) và mạng nơ-ron hồi quy (*recurrent neural network* – RNN) được triển khai và so sánh. Đầu vào của các mô hình ANN là dữ liệu của 12 tháng trước đó và hai đầu vào khác được sử dụng cho năm và tháng. Ba mô hình mạng này cho giá trị MAPE từ 4% đến 6%, trong đó kiến trúc FFNN hoạt động tốt hơn trên cả tập dữ liệu xác thực (*validation*) và tập dữ liệu kiểm tra (*test*) với sai số 4,2%.

Claveria, Monte và Torra [8] so sánh hiệu quả của các ANN khác nhau trong dự báo nhu cầu du lịch. Các tác giả này kiểm tra độ chính xác dự báo của ba loại kiến trúc ANN khác nhau gồm MLP, RBF và ELN. Thực nghiệm được lặp lại với các cấu trúc liên kết có số đầu vào khác nhau đối với 3 loại mạng này. Dữ liệu thực nghiệm là lượng du khách đến Catalonia, Tây Ban Nha từ các quốc gia khác nhau trong khoảng thời gian từ năm 2001 đến 2012. Kết quả thực nghiệm

cho thấy RBF và MLP hoạt động tốt hơn mạng ELN, trong đó là RBF cung cấp dự báo tốt nhất. Kết quả thực nghiệm cũng cho thấy rằng đối với số đầu vào lớn hơn thì kết quả dự báo được cải thiện. Điều này cho thấy tầm quan trọng của việc tăng kích thước đối với dự báo dài hạn.

Trong nghiên cứu của mình, Cogurcu và Kukrer [1] cố gắng xác định phương pháp dự báo mang lại hiệu suất tốt nhất khi so sánh độ chính xác dự báo giữa MLP, RBF và mạng nơ-ron hồi quy tổng quát (*generalized regression neural network* – GRNN) để ước tính nhu cầu du lịch tàu biển hàng tháng đến Izmir, Thổ Nhĩ Kỳ. Nghiên cứu đã sử dụng tổng số lượt du khách tàu biển nước ngoài làm thước đo nhu cầu du lịch tàu biển trong nước và lượng du khách tàu biển hàng tháng đến tại cảng du lịch Izmir trong giai đoạn từ tháng 1/2005 đến 12/2013. Kết quả thực nghiệm cho thấy RBF vượt trội hơn MLP và GRNN về độ chính xác dự báo khi dự báo nhu cầu du lịch tàu biển nội địa hàng tháng đến Izmir trong năm 2014.

Nghiên cứu của Teixeira và Fernandes [9] khảo sát một số kiến trúc khác nhau của MLP với 4, 6, 8 nút ẩn trong dự báo nhu cầu du lịch đến Cape Verde. Dữ liệu chuỗi thời gian được sử dụng đặc biệt khó dự báo do đặc tính không theo mùa vụ của nó. Với số đầu vào là 12 tháng liên tiếp và các kiến trúc với số nút ẩn khác nhau được thử nghiệm, hiệu suất dự báo trong các lần thử nghiệm đã được cải thiện với giá trị MRE = 7,3% và hệ số tương quan Pearson $r = 0,92$.

Melda Akin [10] xem xét các mô hình ARIMA theo mùa vụ (*Seasonal ARIMA* - SARIMA), hồi quy véc-tơ hỗ trợ (*Support Vector Regression* - SVR) và MLP và tối ưu hóa các thông số của chúng trong việc dự báo nhu cầu du khách quốc tế đến Thổ Nhĩ Kỳ. Tác giả đã đề xuất một cách tiếp cận lựa chọn mô hình dự báo đối với từng chuỗi thời gian dựa trên việc so sánh độ chính xác dự báo để chọn cách tiếp cận thích hợp nhất. Từ đó, một mô hình cây quyết định được xây dựng để xác định quy tắc lựa chọn mô hình dự báo.

Constantino, Fernandes và Teixeira [12] sử dụng mô hình mạng nơ-ron nhân tạo để mô hình hóa và dự báo nhu cầu du lịch cho Mozambique trong giai đoạn từ 1/2004 đến 12/2013. Nhu cầu du lịch trong nghiên cứu này là số lượng khách lưu trú qua đêm tại các khách sạn. Một tập các biến độc lập được thử nghiệm như là đầu vào của mô hình, gồm: Chỉ số giá tiêu dùng (*Consumer Price Index* – CPI), tổng sản phẩm quốc nội (*Gross Domestic Product* – GDP) và tỷ giá hối đoái (*Exchange Rates* – ER), của các thị trường du lịch là du khách đến từ Nam Phi, Hoa Kỳ, Bồ Đào Nha và Anh. Một mô hình tốt nhất đã được tìm thấy với MAPE đạt 6,5% và hệ số tương quan Pearson đạt 0,696.

Trong nghiên cứu của Cankurt và Subasi [13], hồi quy đa lớp (*Multi-layer Regression* – MLR), MLP và SVR được sử dụng để thực hiện dự báo nhu cầu du lịch đến Thổ Nhĩ Kỳ. Khác với nghiên cứu của M. Akin [10], nghiên cứu này đề xuất mô hình hồi quy đa lớp MLR với dữ liệu là lượng du khách đến Thổ Nhĩ Kỳ hàng tháng (từ 1/1996 đến 12/2013). Hiệu suất dự báo được so sánh dựa trên sai số tuyệt đối tương đối (RAE) và sai số trung bình bình phương gốc

(RRSE) và cho thấy rằng SVR có hiệu suất tốt nhất, với RAE = 12,34% và RRSE = 14,02%.

Trong nghiên cứu của mình, Koutras, Panagopoulos và Nikas [14] khảo sát và đánh giá các mô hình dự báo tuyến tính và phi tuyến dựa trên ANN về nhu cầu du lịch trong ngành lưu trú. Để dự báo hiệu quả, các phương pháp MLP, SVR và hồi quy tuyến tính (*Linear Regression, LR*) được sử dụng với hai tập dữ liệu thực nghiệm khác nhau. Ưu điểm chính của các mô hình được đề xuất là độ chính xác dự báo và chi phí dự báo thấp. Với dữ liệu lưu trú du lịch được xem xét gồm công suất sử dụng và số lượng khách lưu trú qua đêm tại các khách sạn ở vùng phía Tây Hy Lạp, độ chính xác tương đối của MLP và SVR được so sánh với mô hình LR. Hiệu suất tương đối của MLP và SVR cũng được so sánh với nhau. Thực nghiệm chỉ ra rằng kết hợp của SVR và RBF cho kết quả dự báo tốt hơn các mô hình khác với sai số dự đoán rất nhỏ và ổn định.

Mục đích của Mavrommati và Karakitsiou [15] là nghiên cứu khả năng ứng dụng và hiệu suất của hai mô hình học máy gồm mạng nơ-ron và máy véc-tơ hỗ trợ trong việc dự báo nhu cầu du lịch của Hy Lạp đối với du khách từ các nước không thuộc châu Âu và các nước châu Âu không sử dụng đồng Euro. Dữ liệu chuỗi thời gian được thu thập hàng năm từ năm 1990 đến 2015 được sử dụng. Kết quả thực nghiệm cho thấy rằng các phương pháp học máy không có sự khác biệt đáng kể về hiệu suất. Không có phương pháp nào là tốt nhất cho đối với tất cả các bộ dữ liệu.

Gregorić và Baldigara [17] thiết kế một mạng nơ-ron nhân tạo nhằm dự báo số lượng du khách Đức đến Croatia khi xem xét tính chất mùa của dữ liệu thực nghiệm. Sự hiện diện của các yếu tố thời vụ có tác động quyết định nhu cầu du lịch được phân tích. Nghiên cứu dựa trên phân tích thời vụ và phương pháp tiếp cận ANN được sử dụng để xây dựng một mô hình mô tả hành vi của dòng du khách Đức đến Croatia. Các kiến trúc mạng nơ-ron khác nhau được huấn luyện và thử nghiệm; độ chính xác của dự báo và hiệu suất của mô hình được phân tích. Đánh giá hiệu suất mô hình và độ chính xác dự báo đã được kiểm tra bằng cách sử dụng sai số phần trăm tuyệt đối trung bình (MAPE). Kết quả thực nghiệm và phân tích cho thấy rằng giá trị MAPE đạt được là 1,601% cho biết độ chính xác của dự báo mô hình cao.

Tóm lại, các nghiên cứu nêu trên đều cố gắng mô hình hoá bài toán dự báo nhu cầu du lịch dựa trên dữ liệu chuỗi thời gian và xây dựng các mô hình mạng nơ-ron khác nhau để thử nghiệm, đánh giá khả năng dự báo của chúng. Không có một mô hình ANN nào là tốt nhất đối với tất cả các loại dữ liệu. Tùy thuộc vào từng trường hợp cụ thể mà mỗi nghiên cứu chỉ ra mô hình mạng nơ-ron nào là phù hợp nhất. Tuy nhiên, có một tỷ lệ khá lớn các nghiên cứu cho rằng mô hình mạng MLP và RBF khả năng dự báo chính xác khá cao so với các mô hình khác. Khá nhiều nghiên cứu tập trung vào 3 loại mạng MLP, RBF và ELN để đánh giá hiệu quả của chúng trong dự báo du lịch đối với các trường hợp du khách đến tại các địa phương khác nhau. Do đó trong bài viết này, chúng tôi tiếp tục khảo sát hiệu quả dự báo của ba mô hình mạng nơ-ron là MLP, RBF và

ELN trong việc dự báo nhu cầu du khách đến với Thừa Thiên Huế.


3 Mô hình hóa mạng nơ-ron nhân tạo cho dự báo nhu cầu du lịch

3.1 Dữ liệu nhu cầu du lịch được sử dụng

Dữ liệu nhu cầu du lịch được sử dụng trong bài báo này là lượng du khách đến Thừa Thiên Huế trong vòng 3 năm (từ tháng 1/2017 đến 12/2019) được trích xuất từ trang thông tin của Sở Du lịch Thừa Thiên Huế [18]. Thực tế, dữ liệu du lịch của điểm đến này trước năm 2017 (từ năm 1998) cũng đã được thống kê, nhưng chủ yếu theo năm nên không đảm bảo cho việc dự báo theo tháng như được xem xét trong bài báo này. Dựa trên thể hiện trong Hình 1, dữ liệu du khách đến Thừa Thiên Huế không thể hiện tính thời vụ rõ ràng, nên không cần phân tích các yếu tố thời vụ của dữ liệu. Để cài đặt và đánh giá khả năng dự báo, dữ liệu này được chia thành hai phần: dữ liệu huấn luyện và dữ liệu kiểm tra. Tập dữ liệu huấn luyện được dùng trong giai đoạn huấn luyện mạng nơ-ron gồm 24 mẫu tương đương với số liệu du khách đến Thừa Thiên Huế trong vòng 2 năm từ tháng 1/2017 đến tháng 12/2018. Tập dữ liệu kiểm tra được dùng trong giai đoạn kiểm tra để đánh giá về độ chính xác của mạng nơ-ron sau khi huấn luyện, bao gồm 12 mẫu tương đương với 12 tháng còn lại trong tập dữ liệu từ tháng 1/2019 đến tháng 12/2019.

3.2 Chuẩn hóa dữ liệu

Mạng nơ-ron thường phát huy hiệu suất với dữ liệu được chuẩn hóa. Việc sử dụng dữ liệu gốc để huấn luyện mạng nơ-ron có thể làm chậm sự hội tụ. Do đó, dữ liệu cần phải được chuẩn hóa khi bắt đầu mô hình hóa để cải thiện độ chính xác, tốc độ hội tụ và hiệu quả của bước huấn luyện mạng. Trong số các phương pháp chuẩn hóa dữ liệu, phương pháp được sử dụng phổ biến nhất là chia tỷ lệ, có thể được thực hiện để có một phạm vi cụ thể, chẳng hạn như phạm vi giữa -1 và 1 hoặc 0 và 1, cho toàn bộ tập dữ liệu. Ở đây, dữ liệu sẽ được chia tỷ lệ thành phạm vi từ 0 đến 1 trước giai đoạn huấn luyện. Mục đích là tất cả các dữ liệu du khách được chuyển đổi thành



Hình 1. Phân bố dữ liệu du khách đến Thừa Thiên Huế từ tháng 1/2019 đến tháng 12/2019

các giá trị từ 0 đến 1 thông qua việc chia sự khác biệt của giá trị thực tế và giá trị nhỏ nhất cho sự khác biệt của giá trị lớn nhất và nhỏ nhất. Phương trình cho phạm vi tỷ lệ $[0, 1]$ được cho bởi Công thức (1):

$$x_i' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

trong đó, x_i là giá trị thực tế, x_{\min} là giá trị nhỏ nhất, x_{\max} là giá trị lớn nhất trong tập dữ liệu; x_i' là giá trị chuẩn hóa.

3.3 Chuẩn bị dữ liệu cho huấn luyện

Mạng nơ-ron được sử dụng để dự báo xu hướng tương lai của chuỗi thời gian từ các giá trị $x_{t-p+1}, x_{t-p+2}, \dots, x_t$ đến thời điểm hiện tại (thời điểm t). Điều này có nghĩa là giá trị ước tính thu được của x tại thời điểm $t+d$, từ p bước thời gian trở lại từ thời điểm t được tính bằng Công thức (2).

$$x_{t+d} = f(X_t) = f(x_{t-p+1}, x_{t-p+2}, \dots, x_t) \quad (2)$$

trong đó X_t là véc-tơ của p giá trị x bị làm trễ. Thông thường d được đặt bằng 1, nên hàm f sẽ dự báo giá trị tiếp theo của x .

Tiếp theo, các ma trận dữ liệu khác nhau được tạo cho cả dữ liệu huấn luyện và dữ liệu kiểm tra trên cơ sở số bước thời gian làm trễ (p) tương ứng với số đầu vào của mạng nơ-ron và số lượng dự báo (d) tương ứng với số đầu ra của mạng nơ-ron. Hình 2 minh họa cho trường hợp với mạng nơ-ron với 4 đầu vào và một đầu ra. Hình này cho thấy cấu trúc của ma trận dữ liệu với $p = 4$ giá trị vào tương ứng với các mốc thời gian (tháng) và sẽ dự báo giá trị ở mốc thời gian tiếp đó ($d = 1$).

3.4 Tạo tập dữ liệu huấn luyện và kiểm tra

Trong phương pháp dự báo dựa trên ANN, dữ liệu thường được chia thành ba bộ: dữ liệu huấn luyện (*training*), dữ liệu xác nhận (*validation*) và dữ liệu kiểm tra (*test*), để có được một mạng có khả năng khái quát và hoạt động tốt với các trường hợp mới.

Mẫu dữ liệu	Giá trị vào				Kết quả ra
1	x_1	x_2	x_3	x_4	x_5
2	x_2	x_3	x_4	x_5	x_6
3	x_3	x_4	x_5	x_6	x_7

n	x_n	x_{n+1}	x_{n+2}	x_{n+3}	x_{n+4}

Hình 2. Cấu trúc ma trận dữ liệu tương ứng với mạng nơ-ron có 4 đầu vào và 1 đầu ra

Trong giai đoạn huấn luyện mạng, trọng số được sửa đổi lặp đi lặp lại trên cơ sở các giá trị vào của tập huấn luyện, nhằm giảm thiểu lỗi (sự khác biệt) giữa kết quả ra thực tế so với mục tiêu mong muốn. Tuy nhiên, nếu quá nhiều thông số hoặc trọng số liên quan đến vấn đề đang xem xét và số lượng dữ liệu huấn luyện có thể dẫn đến hiện tượng quá phù hợp (*overfitting*). Hiện tượng này xảy ra khi mô hình quá phù hợp với các đặc trưng không liên quan có trong dữ liệu đào tạo, thay vì phù hợp với sự (hay hàm) tương quan giữa giá trị vào và kết quả ra, làm mất khả năng khái quát hóa cho các trường hợp mới.

Để tránh vấn đề quá phù hợp, bộ dữ liệu xác nhận được sử dụng để kiểm soát quá trình huấn luyện. Trong quá trình huấn luyện, mạng nơ-ron sửa đổi trọng số trên cơ sở dữ liệu huấn luyện và lỗi mạng được thực hiện với dữ liệu xác nhận. Do đó, có thể xác định chắc chắn các trọng số tối ưu trên cơ sở kiến trúc hoạt động tốt nhất với dữ liệu xác thực. Giá trị của các tham số khác đóng một phần trong việc học mạng cũng có thể được xác định thông qua bộ dữ liệu xác nhận.

Cuối cùng, nếu hiệu quả cuối cùng của hệ thống được xây dựng được đo lường một cách hoàn toàn khách quan, thì lỗi thu được từ dữ liệu xác nhận sẽ không được sử dụng làm cơ sở đo lường vì ở một mức độ nào đó, những dữ liệu này đã tham gia vào quá trình huấn luyện. Tập hợp dữ liệu độc lập thứ ba phải được sử dụng, dữ liệu kiểm tra, cung cấp ước tính sai số của khả năng khái quát hóa.

Không có quy tắc chính xác nào về kích thước tối ưu trong việc phân chia ba tập dữ liệu, mặc dù đa số các nghiên cứu đồng ý rằng tập huấn luyện phải lớn nhất. Trong nghiên cứu này, do dữ liệu khá nhỏ nên dữ liệu chỉ tách thành hai bộ: dữ liệu huấn luyện và dữ liệu kiểm tra. Dữ liệu từ tháng 1/2017 đến tháng 12/2018 được sử dụng làm tập huấn luyện (66,67%) và dữ liệu từ 1/2019 đến 12/2019 được sử dụng làm tập kiểm tra (33,33%).

3.5 Xây dựng mạng nơ-ron cho việc dự báo

Mạng nơ-ron nhân tạo là hệ thống phân tán và song song bao gồm nhiều đơn vị xử lý đơn

giản, được gọi là các nơ-ron. Các đơn vị xử lý này có khả năng tính toán như các hàm toán học, mà trong hầu hết các trường hợp là phi tuyến. Các nơ-ron kết nối với nhau bằng các kết nối một chiều và được sắp xếp thành một hoặc nhiều lớp để tạo thành mạng nơ-ron nhân tạo [19].

Mạng nơ-ron nhân tạo có khả năng học thông qua việc áp dụng một phương pháp huấn luyện. Dựa trên kết quả học được, mạng nơ-ron nhân tạo có khả năng khái quát hóa thông qua việc đề xuất giải pháp cho những trường hợp chưa có đáp án hiện hữu nào. Mạng nơ-ron được sử dụng rộng rãi trong nhiều lĩnh vực khoa học, tính toán kỹ thuật, y học và nhiều lĩnh vực khác [19]. Trong bài báo này, ba mô hình mạng nơ-ron nhân tạo được xem xét: mạng perceptron đa lớp, mạng xuyên tâm cơ sở và mạng hồi quy Elman.

Mạng perceptron đa lớp

Mạng perceptron đa lớp (MLP) gồm một tập các nơ-ron nhân tạo được sắp xếp thành nhiều lớp, mà tín hiệu từ đầu vào được truyền qua mạng qua lần lượt từng lớp. Như được chỉ ra trong Hình 3(a), một mạng MLP 2 lớp với các kết nối một chiều từ lớp vào đến lớp ẩn và từ lớp ẩn đến lớp ra; không có kết nối nào giữa các nơ-ron trong mỗi lớp. MLP được coi là một trong những kiến trúc linh hoạt nhất về khả năng ứng dụng và được sử dụng trong tính toán gần đúng đối với nhiều bài toán khác nhau như nhận dạng mẫu, điều khiển tự động, dự báo dữ liệu chuỗi thời gian, tối ưu hóa v.v. [19].

Quá trình huấn luyện mạng nơ-ron bao gồm việc điều chỉnh liên tục trọng số liên kết giữa các nơ-ron để tìm ra tập trọng số sao cho có thể ánh xạ tốt nhất các sự kiện mong muốn. Phương pháp huấn luyện được biết đến nhiều nhất đối với MLP là tối thiểu hóa gradient, trong đó véc-tơ gradient được tối thiểu hóa bằng cách sử dụng thuật toán lan truyền ngược (*backpropagation*) [19]. Cụ thể, tín hiệu lỗi của nơ-ron j trong lần lặp t được thực hiện bởi Công thức (3):


$$e_j(t) = d_j(t) - y_j(t) \quad (3)$$

trong đó $e_j(t)$ là lỗi, $d_j(t)$ là mục tiêu mong muốn (*target*) và $y_j(t)$ là kết quả hiện thời của mạng.

Sau đó, quy tắc cập nhật trọng số liên kết giữa các nơ-ron được thực hiện bởi Công thức (4):

$$w_{ij}^m(t+1) = w_{ij}^m(t) - \eta \frac{\partial E(t)}{\partial w_{ij}^m(t)} \quad (4)$$

trong đó $w_{ij}^m(t)$ là trọng số liên kết vào i của nơ-ron j của lớp m trong lần lặp t , η là tốc độ huấn luyện và $\partial E(t)$ là đạo hàm riêng của sai số.



Hình 3. Kiến trúc các mạng MLP, RBF và ELM

Thuật toán huấn luyện bao gồm hai giai đoạn. Ban đầu, dữ liệu vào được truyền qua mạng để thu được kết quả ra hiện thời $y_j(t)$ của nó. Giá trị này sau đó được so sánh với mục tiêu mong muốn $d_j(t)$ để tính toán lỗi $e_j(t)$. Trong bước thứ hai, lỗi được truyền ngược lại từ lớp ra đến lớp vào (lan truyền ngược) để phục vụ cho việc điều chỉnh trọng số của các lớp. Bằng cách này, tất cả các trọng số liên kết được điều chỉnh theo quy tắc sửa lỗi đã được giả định, để kết quả ra của mạng trong lần lặp sau gần với mục tiêu mong muốn hơn [19].

Mạng RBF

Không giống như MLP, mạng cơ sở xuyên tâm (*Radial Basis Function*–RBF) chỉ có hai lớp: một lớp ẩn và một lớp ra. Như mô tả trong Hình 3(b), kiến trúc mạng RBF là tương tự với mạng MLP 2 lớp, nhưng với sự khác biệt về chức năng của các nơ-ron lớp ẩn. Các hàm kích hoạt của lớp ẩn đều dựa trên tính chất xuyên tâm [19], trong đó mỗi nơ-ron ẩn sẽ xác định tâm của những dữ liệu vào tương tự (phân bố gần nhau trong không gian vào). Một trong những hàm kích hoạt được sử dụng nhiều nhất cho nơ-ron lớp ẩn là hàm Gaussian như trong Công thức (5):

$$\varphi(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (5)$$

trong đó x là giá trị mẫu vào, c là tâm của Gaussian và σ^2 phương sai (bán kính) của nó.

Việc huấn luyện RBFs được thực hiện trong hai giai đoạn. Đầu tiên, trọng số của lớp ẩn được tính toán bằng cách xác định các tâm dựa trên phân bố của tập dữ liệu vào. Các dữ liệu có phân bố “gần nhau” được xem thuộc về một cụm mà tâm của cụm đó sẽ được tính toán dựa trên một hàm cơ sở xuyên tâm như Công thức (5). Tiếp đó, trọng số của lớp ra được điều chỉnh theo cách huấn luyện có giám sát tương tự như mạng MLP [19].

Mạng ELN

Mạng Elman (ELN) là một kiến trúc đệ quy dựa trên mạng MLP do J.L. Elman đề xuất [20]. Mạng ELN chia lớp vào thành hai phần: phần đầu tiên bao gồm các đầu vào thông thường của mạng và phần thứ hai, có tên gọi là đơn vị ngữ cảnh, bao gồm các đầu ra của lớp ẩn được đưa trở lại thành đầu vào (đệ quy), như được mô tả trong Hình 3(c). Vì các đơn vị ngữ cảnh của mạng ELN được xem là đầu vào, nên chúng cũng có trọng số liên kết và có thể được điều chỉnh bằng thuật toán lan truyền ngược theo thời gian. Trong đa số cài đặt, phiên bản lan truyền ngược được cắt lát theo thời gian tạo thành từng khoảng trễ. Quá trình huấn luyện mạng Elman tương tự với mạng MLP và việc điều chỉnh trọng số sẽ dừng khi “sự biến thiên trọng số” của mạng trở nên ổn định [19].

3.6 Phương thức đánh giá kết quả dự báo

Có khá nhiều phương thức đánh giá độ chính xác của các mô hình dự báo. Cũng như đa số các nghiên cứu đã được phân tích trong Mục 2, bốn phương thức dự báo sau thường được sử dụng:

Sai số bình phương trung bình (*mean squared error* - MSE): Nó đo độ lệch bình phương trung bình của các giá trị dự báo. MSE nhấn mạnh rằng tổng sai số dự báo trên thực tế bị ảnh hưởng nhiều bởi sai số lớn riêng lẻ, nhưng không cung cấp bất kỳ ý tưởng nào về hướng của lỗi tổng thể [21]. MSE được xác định bởi Công thức (6).

$$MSE = \frac{1}{P} \sum_{t=1}^P (y_t - \hat{y}_t)^2 \quad (6)$$

Sai số tuyệt đối trung bình (*mean absolute error* - MAE): Nó đo độ lệch tuyệt đối trung bình của các giá trị dự báo so với giá trị ban đầu. MAE cho thấy mức độ của lỗi tổng thể xảy ra do dự báo, nhưng cũng không cung cấp bất kỳ ý tưởng nào về hướng của các lỗi [21]. Phương trình của phương thức này được chỉ ra trong Công thức (7).

$$MAE = \frac{1}{P} \sum_{t=1}^P |y_t - \hat{y}_t| \quad (7)$$

Sai số phần trăm tuyệt đối trung bình (*mean absolute percentage error* - MAPE): Phương thức này không phụ thuộc vào quy mô đo lường nên nó trở thành một lựa chọn phổ biến trong các bài toán dự báo, đặc biệt là dựa trên mạng nơ-ron [21]. Nó được định nghĩa bởi Công thức (8):

$$MAPE = \frac{1}{p} \sum_{t=1}^p \frac{|y_t - \hat{y}_t|}{|y_t|} \times 100 \quad (8)$$

Căn bậc hai của phương sai bình phương trung bình (*root mean square error* - RMSE): Nó được định nghĩa là độ lệch chuẩn của các sai số giữa giá trị mục tiêu và giá trị dự đoán [21]. RMSE đơn giản là căn bậc hai của MSE do đó nó được tính bằng Công thức (9).

$$RMSE = \sqrt{\frac{1}{p} \sum_{t=1}^p (y_t - \hat{y}_t)^2} \quad (9)$$

4 Mô phỏng và phân tích kết quả

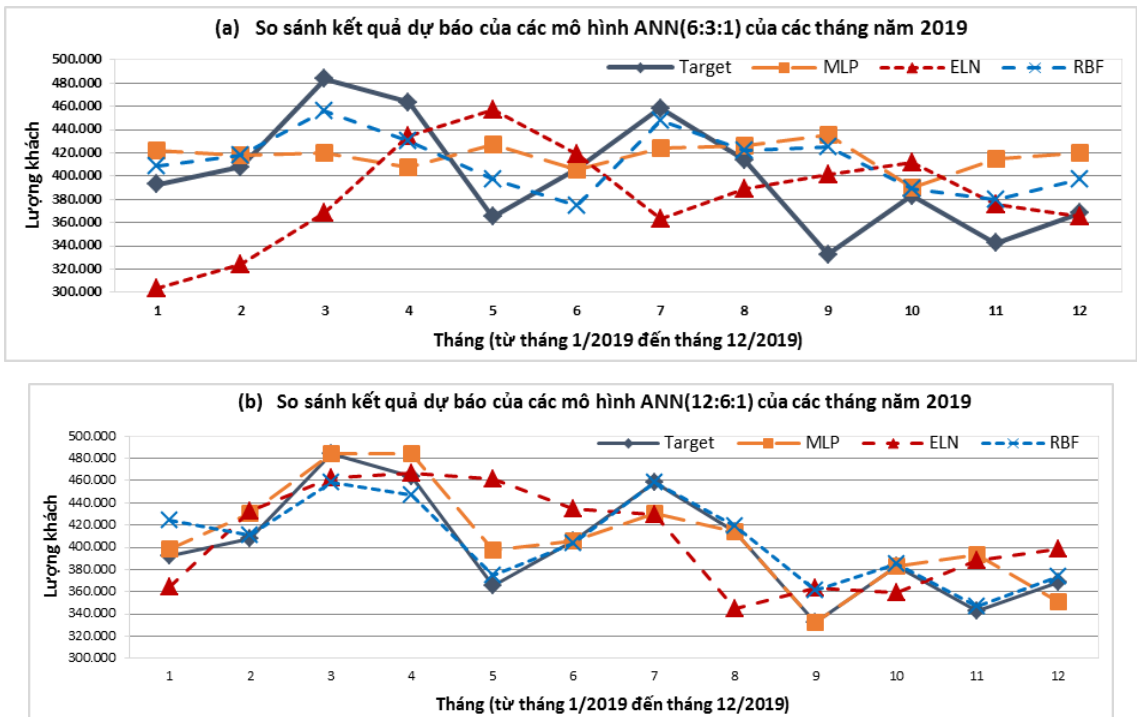
Chúng tôi sử dụng Matlab phiên bản 2010b để tiến hành mô phỏng 3 mô hình mạng nơ-ron MLP, RBF và ELN, với dữ liệu là lượng du khách hàng tháng đến Thừa Thiên Huế (từ tháng 1/2017 đến tháng 12/2019). Dữ liệu này được trích xuất từ trang thông tin điện tử của Sở du lịch Thừa Thiên Huế [18]. Các cài đặt được thực hiện trên máy tính PC với cấu hình 2.4 GHz Intel Core 2 CPU, 2G RAM.

Điều kiện hội tụ đối với quá trình huấn luyện được kết hợp dựa trên mỗi bình phương trung bình MSE và ngưỡng số vòng lặp tối đa. Trong các cài đặt này, MSE và ngưỡng số vòng lặp tối đa được thiết lập lần lượt là 0,005 và 10.000 vòng lặp. Thực tế, khó có thể thiết lập chính xác được các ngưỡng này mà hầu hết là dựa trên kinh nghiệm, với nhiều lần chạy thử khác nhau để xác định giá trị ngưỡng phù hợp nhất. Chúng tôi chọn ngưỡng MSE khá nhỏ nhằm kiểm tra độ chính xác dự báo của các mạng nơ-ron, nhưng cũng khống chế số vòng lặp như là điều kiện dừng để phòng trường hợp các mạng không thể hội tụ được với giá trị ngưỡng MSE này. Hơn nữa, do dữ liệu huấn luyện có kích thước khá nhỏ và đã được chuẩn hóa về khoảng [0, 1], nên thiết lập giá trị ngưỡng nhỏ đối với MSE và ngưỡng vòng huấn luyện như trên là cần thiết.

Có 2 kiến trúc mạng nơ-ron được thử nghiệm cho mỗi loại mạng MLP, RBF và ELN gồm (6:3:1) và (12:6:1), tức là các kiến trúc có 6 (hoặc 12) đầu vào, 3 (hoặc 6) nơ-ron ẩn và 1 nơ-ron ra. Như vậy sẽ có hai loại ma trận dữ liệu huấn luyện khác nhau được xây dựng, như mô tả trong Hình 4. Thực tế các kiến trúc mạng khác nhau cũng có thể được thử nghiệm, nhưng đối với dữ liệu nhu cầu du lịch thì việc chọn số điểm lấy giá trị đầu vào là 6 hay 12 tháng liên tục là hợp lý vì tính mùa vụ của nhu cầu du lịch luôn tồn tại, mặc dù đối với dữ liệu du khách đến Thừa Thiên Huế không thể hiện rõ ràng (Hình 1).

Mẫu dữ liệu	Giá trị vào					Kết quả ra	Mẫu dữ liệu	Giá trị vào					Kết quả ra
1	X_1	X_2	X_6		X_7	1	X_1	X_2	X_{12}		X_{13}
2	X_2	X_3	X_7		X_8	2	X_2	X_3	X_{13}		X_{14}
3	X_3	X_4	X_8		X_9	3	X_3	X_4	X_{14}		X_{15}
.....	
n	X_n	X_{n+1}	X_{n+6}		X_{n+7}	n	X_n	X_{n+1}	X_{n+11}		X_{n+12}

Hình 4. Ma trận dữ liệu cho các kiến trúc mạng no-ron (6:3:1) và (12:6:1)



Hình 5. So sánh kết quả dự báo của MLP, ELN và RBF với giá trị thực tế (Target) trong 2 kiến trúc (6:3:1) và (12:6:1)

Kết quả dự báo về lượng du khách đối với dữ liệu kiểm tra của các mạng no-ron MLP, RBF và ELN là được chỉ ra trong Hình 5(a) và Hình 5(b), tương ứng với 2 kiến trúc mạng no-ron khác nhau là (6:3:1) và (12:3:1). Rõ ràng, kết quả dự báo của mạng RBF là tiệm cận khá gần với lượng du khách đến thực tế (Target), đối với cả hai kiến trúc (6:3:1) và (12:6:1), trong đó kiến trúc (12:6:1) cho kết quả dự báo là sát với giá trị thực tế nhất. Điều này cũng thể hiện ở các giá trị của MSE, RMSE, MAE và MAPE cho thấy rằng RBF đạt được các giá trị tương ứng thấp nhất, đặc biệt với kiến trúc (12:6:1), như được chỉ ra trong Bảng 1.

Bảng 1. So sánh lỗi dự báo của MLP, ELN và RBF trong 2 kiến trúc (6:3:1) và (12:6:1)

	MLP		ELN		RBF	
	(6:3:1)	(12:6:1)	(6:3:1)	(12:6:1)	(6:3:1)	(12:6:1)
MSE	2,65E+09	4,72E+08	4,50E+09	1,84E+09	1,28E+09	2,40E+08
RMSE	51.444,96	21.724,35	67.103,98	42.850,08	35.753,80	15.483,36
MAE	41.797,55	14.737,44	56.329,20	35.878,55	27.997,36	11.110,80
MAPE	10,88	3,82	13,93	9,31	7,40	2,81

Kết quả dự báo này là phù hợp với các kết quả của các nghiên cứu trước đây [1, 8] trong đó mạng RBF thường cho giá trị dự báo chính xác nhất, đặc biệt đối với các dữ liệu chuỗi thời gian phi tuyến và không có tính mùa vụ rõ ràng. Thực tế, như đã được phân tích trong [19], vai trò của các nơ-ron ẩn trong mạng RBF là thực hiện chuyển dữ liệu từ không gian phi tuyến ban đầu về không gian tuyến tính mà ở đó có thể phân tách tuyến tính các dữ liệu này. Đây là một tính năng rất đặc biệt của mạng RBF giúp cho nó giải được các bài toán phi tuyến tính một cách hiệu quả như dự báo dữ liệu chuỗi thời gian. Đối với mạng ELN, kết quả dự báo kém đã chỉ ra rằng cấu trúc liên kết phản hồi của mạng Elman không thể nắm bắt các đặc điểm cụ thể của dữ liệu chuỗi thời gian.

Kiến trúc (12:6:1) cho kết quả dự báo tốt hơn kiến trúc (6:3:1) cũng cho thấy rằng dự báo dựa trên chuỗi thời gian phụ thuộc vào việc xác định kích thước điểm lấy thông tin để tìm ra quy luật của dữ liệu. Mặc dù dữ liệu du khách đến Thừa Thiên Huế không thể hiện tính mùa vụ rõ ràng, tuy nhiên xu hướng tăng, giảm du khách vẫn thường tuân theo quy luật hàng năm hơn là hàng quý hay nửa năm. Việc tăng số điểm nhận dữ liệu theo năm rõ ràng giúp cho kiến trúc (12:6:1) học được quy luật biến thiên của chuỗi thời gian về nhu cầu du khách tốt hơn và do đó cho kết quả dự báo gần sát với giá trị thực tế. Do vậy, việc tăng kích thước dữ liệu huấn luyện sẽ làm tăng độ chính xác của các mô hình dự báo này.

5 Kết luận

Bài báo đã thành công trong việc mô hình hoá và xây dựng mạng nơ-ron trong việc dự báo nhu cầu du khách đến Thừa Thiên Huế. Với dữ liệu có dạng chuỗi thời gian, ba mô hình mạng nơ-ron MLP, ELN và RBF đã được phân tích và triển khai. Việc chuẩn hóa và chuẩn bị dữ liệu cũng đã được mô tả chi tiết; hai kiến trúc mạng nơ-ron (6:3:1) và (12:6:1) là được xem xét. Kết quả cài đặt và phân tích đã chỉ ra rằng mạng RBF có khả năng dự báo chính xác nhất, thể hiện ở các mức độ lỗi thấp nhất của MSE, RMSE, MAE và MAPE. Thực tế, đã có nhiều nghiên cứu ứng dụng mạng nơ-ron trong dự báo nhu cầu du lịch, nhưng mỗi loại mạng nơ-ron thì phát huy hiệu quả đối với từng dữ liệu cụ thể và không có mạng nơ-ron nào là hiệu quả nhất trong mọi trường hợp.

Mặc dù dữ liệu được sử dụng trong bài báo có kích thước khá nhỏ nhưng giá trị MAPE thu được là khá bé, dưới 10% [22], cho thấy độ chính xác khá cao của các mạng nơ-ron trong dự báo dữ liệu chuỗi thời gian.

Tài liệu tham khảo

1. M. Cuhadar, I. Cogurcu, and C. Kukrer (2014), Modelling and Forecasting Cruise Tourism Demand to Izmir by Different Artificial Neural Network Architectures, *International Journal of Business and Social Research*, 4(3), 12–28, doi: 10.18533/ijbsr.v4i3.431.
2. H.-C. Huang and C.- I Hou (2017), Tourism Demand Forecasting Model Using Neural Network, *Int. J. Comput. Sci. Inf. Technol.*, 9(2), 19–29, doi: 10.5121/ijcsit.2017.9202.
3. M. E. Nor, A. I. M. Nurul, and M. S. Rusiman (2018), A Hybrid Approach on Tourism Demand Forecasting, *J. Phys. Conf. Ser.*, 995(1), doi: 10.1088/1742-6596/995/1/012034.
4. Y. Yu, Y. Wang, S. Gao, and Z. Tang (2017), Statistical Modeling and Prediction for Tourism Economy Using Dendritic Neural Network, *Comput. Intell. Neurosci.*, 1–9, doi: 10.1155/2017/7436948.
5. P. O. Fernandes, J. P. Teixeira, J. M. Ferreira, and S. G. Azevedo (2011), Forecasting Tourism Demand with Artificial Neural Networks, *Tour. Manag. Stud.*, 2009–2011.
6. C. J. Lin, H. F. Chen, and T. S. Lee (2011), Forecasting Tourism Demand Using Time Series, Artificial Neural Networks and Multivariate Adaptive Regression Splines: Evidence from Taiwan, *Int. J. Bus. Adm.*, 2(2), doi: 10.5430/ijba.v2n2p14.
7. J. P. Teixeira and P. O. Fernandes (2014), *Forecasting of a Non-Seasonal Tourism Time Series with ANN*, in 1st International Work-Conference on Time Series (ITISE), 1–11.
8. O. Claveria, E. Monte, and S. Torra (2013), Tourism Demand Forecasting with Different Neural Networks Models, *SSRN Electron. J.*, doi: 10.2139/ssrn.2507362.
9. J. P. Teixeira and P. O. Fernandes, (2014), *Forecasting of a Non-Seasonal Tourism Time Series with ANN*, in International work-conference on Time Series – ETISE 2014, 1–11.
10. M. Akin, A novel approach to model selection in tourism demand modeling (2015), *Tour. Manag.*, 48, 64–72, doi: 10.1016/j.tourman.2014.11.004.
11. O. Claveria, E. Monte, and S. Torra (2015), Tourism Demand Forecasting with Neural Network Models: Different Ways of Treating Information, *Int. J. Tour. Res.*, 17(5), 492–500, doi: 10.1002/jtr.2016.
12. H. A. Constantino, P. O. Fernandes, and J. P. Teixeira (2016), Tourism demand modelling and forecasting with artificial neural network models: The Mozambique case study, *Tékhne*, 14(2), 113–124, doi: 10.1016/j.tekhne.2016.04.006.

13. S. Cankurt and A. Subasi (2016), Tourism demand modelling and forecasting using data mining techniques in multivariate time series: a case study in Turkey, *Turkish J. Electr. Eng. Comput. Sci.*, 24, 3388–3404, doi: 10.3906/elk-1311-134.
14. A. Koutras, A. Panagopoulos, and I. A. Nikas (2017), Forecasting Tourism Demand Using Linear and Nonlinear Prediction Models, *Acad. Tur. Innov. Journa*, 9(1), 85–98.
15. A. Mavrommati and A. Karakitsiou (2018), Machine learning methods in tourism demand forecasting: some evidence from Greece, *MIBES Trans.*, 11(1), 92–105.
16. E. S. Silva, H. Hassani, S. Heravi, and X. Huang (2019), Forecasting tourism demand with denoised neural networks, *Ann. Tour. Res.*, 74, no. October 2018, 134–154, doi: 10.1016/j.annals.2018.11.006.
17. M. Gregorić and T. Baldigara (2020), Artificial neural networks in modelling seasonal tourism demand – case study of Croatia, *Zb. Veleučilišta u Rijeci*, 8(1), 19–39, doi: 10.31784/zvr.8.1.2.
18. <https://sdl.thuathienhue.gov.vn/> (accessed at 14:00 March 20, 2020).
19. A. Shrestha and A. Mahmood (2019), Review of Deep Learning Algorithms and Architectures, in *IEEE Access*, 7, pp. 53040-53065, doi: 10.1109/ACCESS.2019.2912200.
20. Elman (1990), J.L. Finding structure in time, *Cogn. Sci.*, 14, 179–211.
21. C. Hamzacebi (2008), Improving artificial neural networks' performance in seasonal time series forecasting, *Information Sciences*, 178, 4550–4559.
22. R.K. Klimberg, G.P. Sillup, K.J. Boyle and V. Tavva (2010), Forecasting performance measures – what are their practical meaning?, *Advances in Business and Management Forecasting*, 7, 137–147, Emerald Group Publishing Limited, Bingley.