

DỰ BÁO LƯỢNG BỆNH NHÂN CẤP CỨU HÀNG NGÀY TẠI BỆNH VIỆN: MỘT NGHIÊN CỨU TÌNH HUỐNG

Nguyễn Tấn Phát, Dương Tuấn Anh

Khoa Công Nghệ Thông Tin, Trường Đại Học Ngoại Ngữ - Tin Học TP. HCM

MIT19204@ms.huflit.edu.vn, anhdt@huflit.edu.vn

TÓM TẮT— Mục đích của nghiên cứu này là phân tích hiệu quả của ba mô hình dự báo dùng để dự báo lượng bệnh nhân cấp cứu hàng ngày tại một bệnh viện. Do lượng bệnh nhân cấp cứu hàng ngày tại bệnh viện thường đầy biến động và rất bất định, nên bài toán dự báo trên loại dữ liệu này là một công việc đầy thách thức. Chúng tôi thử nghiệm ba mô hình dự báo chuỗi thời gian khác nhau để dự báo lượng bệnh nhân cấp cứu hàng ngày tại Bệnh viện Đa khoa khu vực Củ Chi, Thành phố Hồ Chí Minh, Việt Nam. Các mô hình dự báo được thử nghiệm trong nghiên cứu này gồm mô hình Holt-Winters, mô hình tự hồi quy tích hợp trung bình di động (ARIMA) có tính mùa và mô hình mạng nơ ron nhân tạo có tính mùa (SANN). Kết quả thực nghiệm trên bộ dữ liệu thực tế cho thấy ba mô hình dự báo nêu trên đều đem lại kết quả dự báo tương đối tốt và mô hình SANN chính là mô hình dự báo tốt nhất. Sai số MAPE của mô hình SANN là 12.74%.

Từ khóa— dự báo, lượng bệnh nhân cấp cứu, mô hình Holt-Winters, ARIMA có tính mùa, ANN có tính mùa.

I. GIỚI THIỆU

Phòng cấp cứu (emergency department) là phòng bận rộn nhất trong bệnh viện. Mục đích chính của phòng này là cung ứng sự chăm sóc khẩn cấp, đúng lúc cho bệnh nhân đang ở tình trạng nguy hiểm. Phòng cấp cứu có thể bị quá tải nếu nguồn nhân lực và cơ sở vật chất của bệnh viện không đáp ứng được yêu cầu thực tế. Do đó, việc dự báo lượng bệnh nhân cấp cứu sẽ đem lại những thông tin hữu ích cho việc hoạch định sử dụng các nguồn tài nguyên của bệnh viện một cách hiệu quả [1]. Dự báo yêu cầu của phòng cấp cứu, dưới hình thức lượng bệnh nhân cấp cứu hàng ngày, đã được thử nghiệm và đánh giá với những phương pháp dự báo chuỗi thời gian khác nhau được dùng để xây dựng mô hình dự báo. Với mục đích này, các dữ liệu quá khứ được biểu diễn dưới dạng *chuỗi thời gian* (time series) được thu thập theo nhịp độ hàng giờ, hàng ngày, hàng tuần hoặc hàng tháng.

Dự báo lượng bệnh nhân cấp cứu được xem là một công tác phức tạp. Các công trình nghiên cứu đi trước của lãnh vực này cho thấy đối với bài toán dự báo này không hề có mô hình dự báo nào là tốt hơn hẳn các mô hình dự báo khác [2]. Nhiều công trình nghiên cứu về bài toán này còn khẳng định rằng dữ liệu lượng bệnh nhân cấp cứu có tính mùa và có chứa đựng những mẫu biến thiên hàng tuần [2].

Các mô hình hiện đang được sử dụng để dự báo lượng bệnh nhân cấp cứu có thể chia làm hai thể loại: các mô hình tuyến tính và các mô hình phi tuyến. Các mô hình tuyến tính thường được sử dụng bao gồm hồi quy tuyến tính (Ekstrom và các cộng sự, 2015 [3]), tự hồi quy tích hợp trung bình di động (ARIMA) (Kadri và các cộng sự, 2014 [4]; Afilal và các cộng sự, 2016 [5]; Rosychuk và các cộng sự, 2016 [6]; Carvalho-Silva và các cộng sự, 2017 [7]; Juang và các cộng sự, 2017 [8]), ARIMA dạng vector (vector ARIMA) (Aboagye-Sarfo và các cộng sự, 2015 [9]), làm trơn hàm mũ (exponential smoothing) (Bergs và các cộng sự, 2014 [10]). Những năm gần đây, các mô hình phi tuyến như hồi quy logistic (Schonwetter và các cộng sự, 2008 [11]), mạng nơ-ron nhân tạo (ANN) (Menke và các cộng sự, 2014 [12]; Pekel và các cộng sự, 2021 [13]), hồi quy vector hỗ trợ (support vector regression) (Zhang và các cộng sự, 2018 [14]), mạng nơ-ron học sâu (Yousefi và các cộng sự, 2019 [15], Harrow và các cộng sự, 2020 [16]) đã được sử dụng để mô hình hóa các biến thiên phi tuyến trên dữ liệu lượng bệnh nhân cấp cứu.

Trong bài báo này, chúng tôi phân tích hiệu quả của ba mô hình được chọn để dự báo lượng bệnh nhân cấp cứu tại Bệnh viện Đa khoa khu vực Củ Chi. Theo sự khảo sát của chúng tôi, bộ dữ liệu lượng bệnh nhân cấp cứu hàng ngày này là *chuỗi thời gian có tính mùa* (seasonal time series). Tính chất này cũng từng được khẳng định bởi một số công trình đi trước về dự báo lượng bệnh nhân cấp cứu ([2], [6], [7]). Ba đóng góp chính của bài báo này có thể được liệt kê như sau:

- Ba mô hình dự báo: ARIMA có tính mùa, Holt-Winters và ANN có tính mùa (SANN) sẽ được áp dụng vào bài toán dự báo lượng bệnh nhân cấp cứu hàng ngày. Cả ba mô hình này đều thích hợp cho công tác dự báo chuỗi thời gian có tính mùa.
- Tiến trình so sánh sẽ được thực hiện bằng sự phân tích ba mô hình theo một tiêu chí đánh giá chất lượng dự báo thông dụng: độ đo sai số phần trăm tuyệt đối trung bình (Mean Absolute Percentage Error - MAPE).
- Bộ dữ liệu được sử dụng để nghiên cứu là dữ liệu được thu thập từ Bệnh viện Đa khoa khu vực Củ Chi, thuộc huyện Củ Chi, Thành phố Hồ Chí Minh, Việt Nam.

Kết quả thực nghiệm cho thấy trong ba mô hình dự báo được chọn để thử nghiệm thì mô hình ANN có tính mùa (viết tắt là SANN) là mô hình hiệu quả nhất cho công tác dự báo lượng bệnh nhân cấp cứu tại bệnh viện được chọn.

Phần tiếp theo của bài báo được tổ chức như sau. Mục II giới thiệu ba mô hình dự báo sẽ được thử nghiệm và một kỹ thuật liên quan. Mục III mô tả tình huống được nghiên cứu trong công trình này. Mục IV trình bày kết quả thực nghiệm của ba mô hình dự báo với bộ dữ liệu lượng bệnh nhân cấp cứu tại Bệnh viện Củ Chi. Mục VI nêu một vài kết luận và các hướng phát triển của đề tài.

II. CÁC MÔ HÌNH DỰ BÁO VÀ KỸ THUẬT LIÊN QUAN

A. MÔ HÌNH ARIMA CÓ TÍNH MÙA

Mô hình *tự hồi quy tích hợp trung bình di động* (AutoRegressive-Integrated-Moving Average-ARIMA) cung cấp một cách tiếp cận cho dự báo chuỗi thời gian và là một trong những phương pháp được sử dụng phổ biến nhất để dự báo chuỗi thời gian [17]. Các mô hình ARIMA có mục đích mô tả những mối quan hệ tự tương quan (autocorrelation) trong dữ liệu và sử dụng lối ký hiệu sau đây:

$$ARIMA(p, d, q)$$

Với p là bậc (mức độ) của quá trình tự hồi quy (AutoRegression-AR), d là số lần lấy sai phân (I) và q là bậc của quá trình trung bình di động (Moving Average -MA). Để làm cho chuỗi thời gian *có tính dừng* (stationary), tức là loại trừ xu hướng, ta phải lấy sai phân dữ liệu chuỗi thời gian một số lần. Biểu thức toán học cho mô hình ARIMA như sau:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

Với Y_t là giá trị của biến tại thời điểm t , ϕ và θ là thông số mô hình cho các toán hạng tự hồi quy và trung bình di động và e_t là toán hạng thẳng dư biểu diễn những biến động ngẫu nhiên mà thể dự báo [17]. Mặc dù không hề có giới hạn đối với các thông số bậc của mô hình ARIMA, trong thực tế ít khi phải dùng những giá trị của p , d và q lớn hơn 2. Cần chú ý rằng ba giá trị 0,1 hoặc 2, cho các tham số p , d and q , là đủ để biểu diễn một tầm vực chuỗi thời gian rất rộng từ những ngữ cảnh rất khác nhau.

Mô hình ARIMA có thể được mở rộng để có thể mô hình hóa dữ liệu chuỗi thời gian có tính mùa. Mô hình *ARIMA có tính mùa* được thiết lập bằng cách đưa thêm 4 thông số liên quan đến tính mùa vào mô hình như sau:

$$ARIMA(p, d, q)(P, D, Q)^s$$

Với P , D và Q là ba thông số có vai trò tương tự như p , d và q dành cho thành phần mùa trong mô hình và s là chiều dài của mùa.

Mô hình ARIMA này có những đặc tính sau đây: về mặt lý thuyết mô hình thích hợp cho hầu hết các chuỗi thời gian và có thể mô hình hóa các biến động, các tính chất xu hướng, sự tự hồi quy và trung bình di động có tính mùa.

B. MÔ HÌNH HOLT-WINTERS

Làm trơn hàm mũ (exponential smoothing) là một loại mô hình tuyến tính có thể nắm bắt các đặc trưng tuyến tính trong một chuỗi thời gian. Một trong những ý tưởng căn bản của mô hình làm trơn hàm mũ là tạo ra những giá trị tương lai như là những giá trị trung bình có trọng số của những giá trị trong quá khứ theo đó những giá trị quan sát gần đây được đánh trọng số cao hơn những giá trị quan sát rất xa trong quá khứ. Bằng cách hình thành những giá trị dự báo dựa vào những giá trị trung bình có trọng số, chúng ta đang sử dụng một phương pháp "làm trơn" (smoothing). Thuật ngữ "hàm mũ" (exponential) xuất phát từ sự kiện các mô hình làm trơn hàm mũ không chỉ đánh trọng số giảm dần theo thời gian mà còn giảm dần theo kiểu hàm mũ.

Để ứng dụng mô hình làm trơn hàm mũ, có ba dạng của mô hình này mà được áp dụng rộng rãi cho những chuỗi thời gian khác nhau [18]. Làm trơn hàm mũ đơn giản (Simple exponential smoothing) (loại I) được dùng khi chuỗi thời gian không có xu hướng và không có tính mùa. Giả sử chúng ta có chuỗi thời gian Y_t , đo đạc tại những thời điểm $t = 1, \dots, T$. Mô hình làm trơn hàm mũ đơn giản được định nghĩa bằng công thức đệ quy như sau:

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha) \hat{Y}_t \quad (1)$$

Với \hat{Y}_{t+1} là giá trị dự báo tại thời điểm $t+1$, α là *hằng số làm trơn* (smoothing constant), Y_t : giá trị dữ liệu thực sự tại thời điểm t , \hat{Y}_t : giá trị dự báo tại thời điểm t .

Khi có tồn tại xu hướng (trend) trong chuỗi thời gian, mô hình hàm mũ Holt (loại II) có thể được dùng. Phương pháp Holt đòi hỏi ước lượng độ dốc (slope) hiện hành và biên độ (level) hiện hành, do đó phương pháp dùng hai

hằng số làm trơn cho mỗi công thức ước lượng. Hai hằng số làm trơn này giúp tính giá trị ước lượng của biên độ và độ dốc mà biến đổi theo thời gian khi có những quan sát mới được đưa vào. Ba phương trình của phương pháp Holt như sau:

$$\hat{Y}_{t+p} = L_t + pT_t \tag{2}$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \tag{3}$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \tag{4}$$

Với \hat{Y}_{t+p} : giá trị dự báo tại p thời đoạn sau thời điểm t , L_t : giá trị ước lượng của biên độ tại thời điểm hiện hành, T_t : giá trị ước lượng của độ dốc tại thời điểm hiện hành, α : hằng số làm trơn cho biên độ ($0 < \alpha < 1$) và β : hằng số làm trơn cho độ dốc, tức xu hướng ($0 < \beta < 1$).

Trong phương trình (3), biên độ hiện hành (L_t) được tính bằng cách lấy trung bình có đánh trọng số của hai giá trị ước lượng: một ước lượng là giá trị quan sát hiện hành (Y_t) và giá trị ước lượng thứ hai là bằng tổng giá trị xu hướng trước đó một thời đoạn (T_{t-1}) với giá trị biên độ ước lượng trước đó một thời đoạn (L_{t-1}). Phương trình (2) cho thấy giá trị dự báo p thời đoạn về phía tương lai (\hat{Y}_{t+p}) được tính bằng cách lấy giá trị ước lượng xu hướng hiện hành (T_t) nhân với số thời đoạn hướng về tương lai để dự báo (p) và tích số này cộng với giá trị ước lượng của biên độ hiện hành (L_t).

Holt-Winters là một phương pháp làm trơn hàm mũ dùng để dự báo chuỗi thời gian có thể hiện cả tính xu hướng và tính mùa (loại III). Phương pháp này có hai phiên bản: Holt-Winters dạng nhân (multiplicative Holt-Winters) và Holt-Winters dạng cộng (additive Holt-Winters). Bốn phương trình trong lược đồ đệ quy của phương pháp Holt-Winters dạng nhân như sau:

$$\hat{Y}_{t+p} = (L_t + pT_t) S_{t-s+p} \tag{5}$$

$$L_t = \alpha Y_t / S_{t-s} + (1 - \alpha)(L_{t-1} + T_{t-1}) \tag{6}$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \tag{7}$$

$$S_t = \gamma Y_t / L_t + (1 - \gamma)S_{t-s} \tag{8}$$

Với \hat{Y}_{t+p} : giá trị dự báo tại p thời đoạn sau thời điểm t , L_t : giá trị ước lượng của biên độ tại thời điểm hiện hành, T_t : giá trị ước lượng của xu hướng tại thời điểm hiện hành, S_t : giá trị ước lượng của thành phần mùa, α : hằng số làm trơn cho biên độ ($0 < \alpha < 1$), β : hằng số làm trơn cho xu hướng ($0 < \beta < 1$), γ : hằng số làm trơn để ước lượng tính mùa ($0 < \gamma < 1$) và s : độ dài mùa.

Nếu γ bằng 0, nghĩa là không có thành phần mùa trong chuỗi thời gian và phương pháp Holt-Winters trở thành phương pháp Holt. Nếu cả γ và β bằng 0, mô hình trở thành phương pháp làm trơn hàm mũ đơn giản. Như vậy phương pháp Holt-Winters là mô hình tổng quát nhất trong ba mô hình làm trơn hàm mũ.

Trong phiên bản nhân của phương pháp Holt-Winters, ước lượng tính mùa được thực hiện bằng *chỉ số mùa* (seasonal index) và được tính bằng phương trình Eq. (8). Phương trình (8) cho thấy thành phần mùa hiện hành, S_t , bằng γ nhân với chỉ số mùa được ước lượng bằng đại lượng Y_t/L_t cộng với $(1 - \gamma)$ nhân thành phần mùa tại thời điểm trước đó S_{t-s} .

C. MÔ HÌNH ANN CÓ TÍNH MÙA (SANN)


Trong nghiên cứu này, một trong những mô hình *mạng nơ ron nhân tạo* (ANN) thông dụng, mạng truyền thẳng một tầng ẩn được dùng để dự báo chuỗi thời gian. Mô hình này được biểu diễn bằng một mạng gồm ba tầng chứa các đơn vị xử lý nối với nhau bằng những đường nối không có chu trình (acyclic link). Hình 1 minh họa cấu trúc của ANN ba tầng.

Về tổng quát, mô hình có thể được huấn luyện bằng những quan sát trong quá khứ của một chuỗi thời gian để nắm bắt những đặc tính phi tuyến của chuỗi thời gian đó. Các thông số của mô hình (trọng số của các đường nối và độ lệch của các nút) sẽ được cập nhật theo kiểu lặp nhiều lần bởi một quá trình cực tiểu hóa các sai số dự báo. Với công tác dự báo chuỗi thời gian, dựa vào quá trình tính toán trước đó, mối liên hệ giữa giá trị đầu ra (y_t) và giá trị đầu vào ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) được biểu diễn bằng công thức toán học sau đây để dự báo chuỗi thời gian.

$$y_t = a_0 + \sum_{j=1}^q a_j f(w_{0j} + \sum_{i=1}^p w_{ij}y_{t-i}) + e_t \tag{9}$$

Với a_j ($j = 0, 1, 2, \dots, q$) là độ lệch (bias) tại đơn vị thứ j của tầng ẩn, và w_{ij} ($i = 0, 1, 2, \dots, p; j = 0, 1, 2, \dots, q$) là các trọng số đường nối giữa các tầng của mạng ANN, $f(\cdot)$ là hàm truyền (transfer function) tại tầng ẩn, thí dụ như hàm sigmod $f(x) = 1/(1 + \exp(-x))$, p là số nút ở tầng nhập và q là số nút ở tầng ẩn. Thực tế, mô hình ANN với công

thức (9) thực hiện một ánh xạ phi tuyến từ những quan sát trong quá khứ $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ thành một trị dự báo trong tương lai (y_t) , tức là:



Hình 1. Mạng ANN ba tầng với N nơ ron tầng nhập, H nơ ron tầng ẩn và M đơn vị đầu ra

$$y_t = \varphi(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + e_t \tag{10}$$

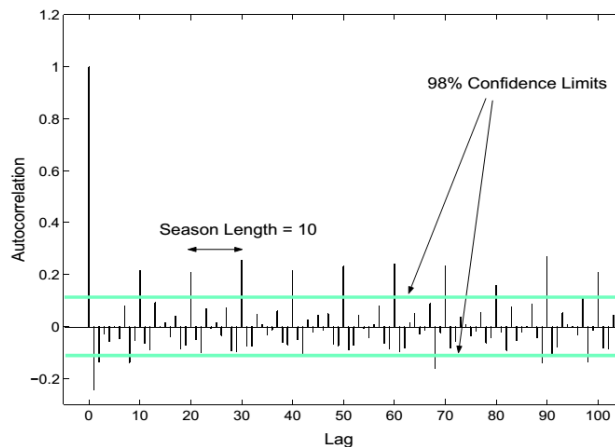
Với w là vector chứa tất cả các thông số của mạng, φ là hàm xấp xỉ được xác định bởi cấu trúc mạng và các trọng số của các đường nối và e_t là sai số dự báo tại thời điểm t .

Việc sử dụng ANN để dự báo chuỗi thời gian hàm ý rằng số đơn vị tầng nhập gắn liền với số giá trị trong quá khứ mà đủ để nhận dạng ra diễn tiến của các bước tương lai. Về số lượng nút ở tầng nhập, vẫn chưa có lý thuyết nào giúp xác định được số nút này một cách thích hợp. Nhưng trong công trình [19], Hamzaçebi khuyến nghị rằng số nút ở tầng nhập nên bằng với độ dài mùa s để dự báo tốt hơn đối với chuỗi thời gian có tính mùa, thí dụ, 12 đối với dữ liệu hàng tháng có độ dài mùa là 12 tháng, là 4 đối với dữ liệu hàng quý có độ dài mùa là 4 quý. Hamzaçebi đặt tên mô hình ANN đặc biệt này là ANN có tính mùa (Seasonal ANN), viết tắt là SANN. Trong bài báo [19], Hamzaçebi đã so sánh hiệu quả của SANN với mô hình ARIMA có tính mùa trên bốn bộ dữ liệu chuỗi thời gian mẫu và tìm thấy SANN đem lại hiệu quả dự báo tốt hơn mô hình ARIMA có tính mùa trên đa số của bốn bộ dữ liệu này. Kết luận quan trọng rút ra từ công trình [19] là SANN có thể dự báo thành công chuỗi thời gian có tính mùa mà không cần phải khử thành phần mùa ra khỏi chuỗi thời gian trong một bước tiền xử lý.

D. CÁCH ƯỚC LƯỢNG ĐỘ DÀI MÙA CHO CHUỖI THỜI GIAN CÓ TÍNH MÙA

Để kiểm tra có sự hiện diện của tính mùa cũng như ước lượng độ dài mùa trên một chuỗi thời gian, chúng ta phải xem xét các vị trí ứng với các độ trễ (lag numbers) của những hệ số tương quan (correlation values) trên biểu đồ hàm tự tương quan (Auto-correlation Function - ACF). Ý tưởng chính là chúng ta tính những khoảng cách Δd giữa những vị trí kế tiếp nhau của các giá trị có tần số cao trong biểu đồ ACF. Nếu có nhiều lần xuất hiện với cùng khoảng cách, khoảng cách Δd xuất hiện thường xuyên nhất sẽ được chọn làm độ dài mùa, dựa vào nguyên tắc đa số.

Phương pháp ước lượng độ dài mùa mà dựa vào biểu đồ ACF nêu trên được đề xuất bởi Ngoc Tran năm 2003 [20]. Phương pháp này bao gồm các bước sau:



Hình 2. Phát hiện độ dài mùa dựa vào biểu đồ ACF

- Thực hiện tính sai phân trên chuỗi thời gian.
- Tính và vẽ biểu đồ ACF cho chuỗi thời gian đã lấy sai phân.
- Lập đường bao với *phạm vi độ tin cậy* (confidence limit) 95% hay 98%.
- Xác định những vị trí có tần số xuất hiện cao.
- Tính khoảng cách giữa những vị trí kế tiếp của những điểm tần số cao.

Khoảng cách xuất hiện thường xuyên nhất sẽ được chọn là độ dài mùa. Hình 2 minh họa một thí dụ về một biểu đồ ACF với phạm vi độ tin cậy 98%. Chúng ta chọn các vị trí nằm ngoài đường bao với phạm vi độ tin cậy 98% và có được 14 vị trí đầu tiên của những điểm tần số cao, như được nêu trong Bảng 1.


Bảng 1. Thí dụ về các khoảng cách của những điểm tần số cao

Vị trí tần số cao	0	1	2	8	10	20	30	40	50	60	68	70	80	90
Khoảng cách		1	1	6	2	10	10	10	10	10	8	2	10	10

Sau khi tính khoảng cách giữa các vị trí kế tiếp của những điểm tần số cao, chúng ta có được 13 khoảng cách trong đó có 7 lần xuất hiện của khoảng cách với độ dài 10, 2 lần xuất hiện của khoảng cách với độ dài 2, 1 lần xuất hiện của khoảng cách với độ dài 6 và 1 lần xuất hiện của khoảng cách với độ dài 8. Như vậy, khoảng cách với độ dài 10 có số lần xuất hiện cao nhất và 10 sẽ được chọn như là độ dài mùa trong thí dụ này.

III. TÌNH HUỐNG NGHIÊN CỨU

Dữ liệu được dùng trong nghiên cứu này là từ Phòng cấp cứu của Bệnh viện Đa khoa khu vực Củ Chi, Thành phố Hồ Chí Minh thu thập hàng ngày từ ngày 01 tháng 01 năm 2018 đến 31 tháng 12 năm 2020 với tổng số 75511 bệnh nhân. Như vậy có tất cả 1095 giá trị quan sát trên chuỗi thời gian. Giá trị trung bình của lượng bệnh nhân cấp cứu hàng ngày là 68, giá trị tối thiểu là 7 và giá trị tối đa là 122. Hình 3 minh họa đường biểu diễn của lượng bệnh nhân cấp cứu hàng ngày trong 3 năm từ năm 2018 đến năm 2020. Từ Hình 3 bằng trực quan, chúng ta có thể cảm nhận được tính không dừng (nonstationary) của chuỗi dữ liệu. Một chuỗi thời gian có tính không dừng khi giá trị trung bình và độ lệch chuẩn không cố định mà biến thiên khi thời gian thay đổi.




Hình 3. Đường biểu diễn lượng bệnh nhân cấp cứu hàng ngày từ ngày 1 tháng 1 năm 2018 đến 31 tháng 12 năm 2020.


Bệnh viện Đa khoa khu vực Củ Chi là bệnh viện hạng 2 trực thuộc Sở Y tế Thành Phố Hồ Chí Minh. Huyện Củ Chi nằm ở vị trí cửa ngõ, tiếp giáp với các tỉnh Tây Ninh, Long An và Bình Dương và là nơi có nhiều khu công nghiệp với qui mô công nhân lớn.

Hình 4 trình bày đường biểu diễn lượng bệnh nhân cấp cứu hàng ngày trong một tháng từ ngày 01 tháng 01 năm 2018 đến ngày 30 tháng 1 năm 2018. Từ Hình 3 và Hình 4 chúng ta có thể thấy lượng bệnh nhân cấp cứu hàng ngày biến thiên rất lớn, có khác biệt nhiều vào dịp cuối tuần và những ngày nghỉ lễ. Ngoài ra, sự biến thiên có tính mùa được nhận diện với thời đoạn là một tuần lễ.

Để phát hiện tính mùa của bộ dữ liệu này, chúng tôi áp dụng phương pháp đã được mô tả ở Tiểu mục II.D và đã phát hiện chuỗi thời gian này có tính mùa với độ dài mùa là 7. Biểu đồ ACF mà trên đó chúng tôi xác định được độ dài mùa cũng được trình bày ở Hình 5. Chúng tôi xây dựng được biểu đồ ACF cho chuỗi thời gian này với sự hỗ trợ của phần mềm R.



Hình 4. Đường biểu diễn lượng bệnh nhân cấp cứu hàng ngày trong một tháng từ ngày 01 tháng 01. 2018 đến ngày 30 tháng 01. 2018



Hình 5. Độ dài mùa của bộ dữ liệu và biểu đồ ACF tương ứng

IV. KẾT QUẢ THỰC NGHIỆM

Như đã đề cập ở Mục II, mô hình ARIMA có tính mùa, mô hình Holt-Winters và mô hình SANN được hiện thực và thử nghiệm trong công trình này. Chúng tôi hiện thực cả ba mô hình bằng ngôn ngữ R. R là một ngôn ngữ và môi trường lập trình cho những tính toán xác suất, đồ họa và cung cấp nhiều công cụ phân tích dữ liệu chuỗi thời gian [21]. Lưu ý, chỉ dự báo một bước (one-step ahead forecasting) được thực hiện trong nghiên cứu này.

A. TIÊU CHÍ ĐÁNH GIÁ ĐỘ CHÍNH XÁC DỰ BÁO

Trong nghiên cứu này, sai số phần trăm tuyệt đối trung bình (mean absolute percentage error - MAPE) được dùng làm tiêu chí đánh giá. Sai số MAPE được định nghĩa như sau:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t} \tag{11}$$

với n là số điểm dữ liệu của chuỗi thời gian, y_t giá trị thực sự tại thời điểm t và \hat{y}_t là giá trị dự báo tại thời điểm t .

Sai số MAPE là một độ đo tương đối. MAPE là một giá trị thống kê bất biến đối với biên độ của chuỗi thời gian mà biểu diễn sai số như là một trị phần trăm (percentage). Mô hình sẽ đạt độ chính xác dự báo càng cao khi MAPE càng tiến gần đến 0%.

B. XÁC ĐỊNH THÔNG SỐ CHO CÁC MÔ HÌNH


Việc xác định những giá trị thông số tốt nhất cho mô hình ARIMA được thực hiện bằng cách phân tích biểu đồ hàm tự tương quan (autocorrelation function - ACF) và biểu đồ hàm tự tương quan riêng phần (partial autocorrelation function - PACF). Với sự hỗ trợ của hàm AUTO.ARIMA() trong phần mềm R, chúng tôi xác định được mô hình thích hợp nhất cho tập huấn luyện của dữ liệu lượng bệnh nhân cấp cứu là (1,0,1)(1,0,0)[7]. Cũng sự hỗ trợ của phần mềm R, chúng tôi xác định được ba thông số α , β và γ cho mô hình Holt-Winters đối với dữ liệu lượng bệnh nhân cấp cứu. Giá trị thấp của α ($=0.11922$) cho thấy bộ dữ liệu có tính ngẫu nhiên

(randomness) khá cao, giá trị rất thấp của β ($= 0.00225$) cho thấy xu hướng (tăng hay giảm) của bộ dữ liệu không đáng kể và giá trị trung bình của γ ($= 0.06$) cho thấy bộ dữ liệu này thực sự có tính mùa. Với cả ba mô hình, chiều dài mùa được gán giá trị 7 như đã nêu ở Mục III. Số đơn vị ở tầng nhập của mạng SANN cũng được gán giá trị 7. Số đơn vị ở tầng ẩn của SANN được xác định thông qua nhiều lần thực nghiệm. Các giá trị thông số thích hợp nhất cho cả ba mô hình được trình bày ở Bảng 2. Kiến trúc của mạng nơ ron SANN được minh họa ở Hình 6.

Chuỗi thời gian lượng bệnh nhân cấp cứu hàng ngày được chia làm hai phần: phần huấn luyện và phần kiểm thử. Chúng tôi sử dụng 80% điểm dữ liệu đầu tiên trong chuỗi thời gian cho phần huấn luyện và 20% còn lại cho phần kiểm thử. Các mô hình dự báo được kiểm thử trên phần kiểm thử và tính ra độ đo hiệu quả dự báo.

Bảng 2. Các thông số cho ba mô hình dự báo

Mô hình	Các thông số
ARIMA có tính mùa	(1,0,1)(1,0,0)[7]
Holt-Winters	α : 0.119221, β : 0.002250993, γ : 0.06212727 Chiều dài mùa: 7
SANN	7-7-1 Chiều dài mùa: 7



Hình 6. Kiến trúc của mạng SANN

C. KẾT QUẢ THỰC NGHIỆM

Kết quả thực nghiệm được trình bày ở Bảng 3. Các sai số dự báo MAPE của ba mô hình dự báo được ghi ở cột 2 của Bảng 3.

Từ kết quả thực nghiệm, chúng ta có thể thấy hiệu quả dự báo của cả ba mô hình đều tương đối tốt và sai số dự báo của SANN là thấp nhất. Sai số MAPE của SANN là 12.74 %. Điều đó cho thấy mô hình SANN là mô hình tốt nhất trong số ba mô hình để chọn để dự báo lượng bệnh nhân cấp cứu hàng ngày tại bệnh viện. Lý do chính của điều này là mô hình SANN với khả năng có thể nắm bắt các thành phần tuyến tính và các thành phần phi tuyến trên chuỗi thời gian đã tạo ra một hiệu ứng kết hợp và do đó cải tiến được hiệu quả dự báo. Phát hiện này nhấn mạnh giá trị hữu ích của việc sử dụng mạng nơ ron SANN để dự báo lượng bệnh nhân cấp cứu tại bệnh viện.

Bảng 3. Kết quả sai số dự báo của ba mô hình

Mô hình	Sai số dự báo MAPE
ARIMA có tính mùa	13.31109
Holt-Winters	12.84018
SANN	12.74151

Hiệu quả dự báo của ba mô hình được xếp thứ tự như sau: SANN tốt hơn Holt-Winters và Holt-Winters tốt hơn ARIMA có tính mùa.

Ghi chú: Nếu độc giả có yêu cầu sử dụng bộ dữ liệu trong công trình này để nghiên cứu, độc giả có thể liên hệ với một trong hai tác giả của bài báo này.

V. KẾT LUẬN

Nghiên cứu này cho thấy lượng bệnh nhân cấp cứu hàng ngày được đặc trưng hóa bằng những biến thiên có tính mùa và mẫu biến thiên hàng tuần. Ngoài ra, nghiên cứu này cho thấy các mô hình dự báo mà có thể xử lý chuỗi thời gian có tính mùa đều có thể được dùng để dự báo lượng bệnh nhân cấp cứu tại bệnh viện. Độ chính xác dự báo tùy thuộc vào mô hình dự báo được sử dụng. Trong phần thực nghiệm với bộ dữ liệu lượng bệnh nhân cấp cứu tại Bệnh viện Đa khoa khu vực Củ Chi, chúng tôi đánh giá so sánh ba mô hình dự báo và rút ra kết luận: mô hình mạng nơ-ron SANN đem lại chất lượng dự báo tốt nhất so với mô hình ARIMA có tính mùa và mô hình Holt Winters. Ngoài ra, mô hình Holt-Winters dự báo tốt hơn ARIMA có tính mùa.

Tuy nhiên, nghiên cứu này chỉ mới thực hiện việc dự báo một bước (one step ahead forecasting) tức là tầm dự báo chỉ là một ngày, như vậy những tầm dự báo khác cũng cần được thực nghiệm để xác nhận tính hiệu quả của ba mô hình dự báo nêu trên với những tầm dự báo khác nhau này. Ngoài ra, ba mô hình dự báo nêu trên cũng cần được thực nghiệm thêm với các bộ dữ liệu lượng bệnh nhân cấp cứu tại một số bệnh viện khác để có thể khẳng định hơn nữa tính hiệu quả của ba mô hình đối với bài toán dự báo đầy thách thức này. Ba là, chúng tôi dự định cải tiến hơn nữa ba mô hình dự báo nêu trên bằng cách áp dụng chiến lược *phát hiện và khử bất thường* (anomaly detection and repair) trước khi tiến hành dự báo vì bộ dữ liệu lượng bệnh nhân cấp cứu có thể chứa các mẫu bất thường và điều này thường làm suy giảm hiệu quả dự báo [22, 23].

VI. TÀI LIỆU THAM KHẢO

- [1] M. Gul and E. Celik. An exhaustive review and analysis on applications of statistical forecasting in hospital emergency departments. *Heal. Syst.*, **9**: 4: 263–284, 2020.
- [2] R. Calegari, F. S. Fogliatto, F. R. Lucini, J. Neyeloff, R. S. Kuchenbecker, and B. D. Schaan. Forecasting Daily Volume and Acuity of Patients in the Emergency Department. *Comput. Math. Methods Med.*, **2016**, 2016.
- [3] A. Ekström, L. Kurland, N. Farrokhnia, M. Castrén, M. Nordberg. Forecasting emergency department visits using Internet data. *Ann Emerg Med*, **65**: 4: 436–442, 2015.
- [4] F. Kadri, F. Harrou, S. Chaabane, and C. Tahon. Time series modelling and forecasting of emergency department overcrowding. *J. Med. Syst.*, **38**: 9, 2014.
- [5] M. Afilal, F. Yalaoui, F. Dugardin, L. Amodeo, D. Laplanche, and P. Blua. Forecasting the Emergency Department Patients Flow. *J. Med. Syst.*, **40**: 7, 2016.
- [6] R. J. Rosychuk, E. Youngson, and B. H. Rowe. Presentations to emergency departments for COPD: A time series analysis. *Canadian Respiratory Journal*, **2016**: 1-9, 2016.
- [7] M. Carvalho-Silva, M. T. T. Monteiro, F. de Sá-Soares, and S. Dória-Nóbrega. Assessment of forecasting models for patients arrival at Emergency Department. *Oper. Res. Heal. Care*, **18**: 112–118, 2018.
- [8] W-C. Juang, S-J. Huang, F-D. Huang, P. W. Cheng and S. R. Wann. Application of time series analysis in modelling and forecasting emergency department visits in a medical centre in Southern Taiwan. *BMJ Open*, **7**: 11, 2017.
- [9] P. Aboagye-Sarfo, Q. Mai, F.M. Sanfilippo, D. B. Preen, L.M. Stewart, D. M. Fatovich. A comparison of multivariate and univariate time series approaches to modelling and forecasting emergency department demand in Western Australia. *J Biomed Inform*, **57**: 62–73, 2015.
- [10] J. Bergs, P. Heerinx, S. Verelst. Knowing what to expect, forecasting monthly emergency department visits: a time-series analysis. *Int Emerg Nurs*, **22**: 2: 112–115, 2013.
- [11] R. S. Schonwetter, L. D. Clark, S. A. Leedy, M. J. Quinn, M. Azer and S. Kim. Predicting emergency room visits and hospitalizations among hospice patients with cardiac disease. *Journal of Palliative Medicine*, **11**: 8 : 1142–1150, 2008.
- [12] N. B. Menke, N. Caputo, R. Fraser, J. Haber, C. Shields and M. N. Menke. A retrospective analysis of the utility of an artificial neural network to predict ED volume. *The American Journal of Emergency Medicine*, **32**: 6: 614–617, 2004.
- [13] E. Pekel, M. Gul, E. Celik and S. Yousefi. Metaheuristic Approaches Integrated with ANN in Forecasting Emergency Department Visits. *Mathematical Problems in Engineering*, **2021**, 14 pages, 2021.
- [14] Y. Zhang, L. Luo, J. Yang, D. Liu, R. Kong, and Y. Feng. A hybrid ARIMA-SVR approach for forecasting emergency patient flow. *J. Ambient Intell. Humaniz. Comput.*, **10**: 8: 3315–3323, 2019.

- [15] M. Yousefi, M. Yousefi, M. Fathi and S. Fogliatto. Patient visit forecasting in an emergency department using a deep neural network approach. *Kybernetes*, **49**: 9, 2335-2348, 2019.
- [16] F. Harrou, A. Dairi, F. Kadri, Y. Sun. Forecasting emergency department overcrowding: A deep learning framework. *Chaos, Solitons and Fractals*, **139**, 2020.
- [17] J. E. Hanke, W. Wichern. *Business Forecasting- 9th Edition*, Pearson New International Edition, 510 ps, 2014.
- [18] P. Goodwin. The Holt-Winters Approach to Exponential Smoothing: 50 Years Old and Going Strong, *Foresight*, pp. 30-33, 2010.
- [19] C. Hamzaçebi. Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*, **178**: 4550-4559, 2008.
- [20] N. Ngoc Tran, *Automatic ARIMA time series modeling and forecasting for adaptive Input/Output prefetching*. Ph.D. Thesis, Department of Computer Science, University of Illinois, Urbana, Illinois, 2002.
- [21] The R project for Statistical Computing at <http://www.r-project.org/>
- [22] H. T. T. Thuy, D. T. Anh and V. T. N. Chau. Anomaly repair-based approach to improve time series forecasting. *Intelligent Data Analysis*, **26**: 2: 277-294, 2022.
- [23] K. Kadri, F. Harrou, S. Chaabane, Y. Sun, C. Tahon. Seasonal ARMA-based SPC charts for anomaly detection: Application to emergency department systems. *Neurocomputing*, **173**: 2002-2114, 2016.

FORECASTING DAILY PATIENT ARRIVALS IN THE EMERGENCY DEPARTMENT: A CASE STUDY

Nguyen Tan Phat, Duong Tuan Anh

ABSTRACT— The goal of this study is to analyze the performance of three forecasting models in predicting daily patient arrivals in the emergency department (ED). Due to the fact that emergency patient flow is highly uncertain and dynamic, this forecasting problem is a challenging task. We tested different time series models to forecast ED daily patient arrivals at General Hospital of Cu Chi Area in Ho Chi Minh city, Vietnam. Forecasting models tested in this work are seasonal multiplicative Holt-Winters (HW), autoregressive integrated moving average (ARIMA) and seasonal artificial neural network (SANN). The experimental results show that all the three models bring out acceptable predictive accuracy and SANN is the best model for forecasting emergency patient arrivals in the selected hospital. The MAPE of SANN model is 12.74 %.

Keywords— forecasting, emergency patient arrivals, Holt-Winters, seasonal ARIMA, seasonal ANN.



Nguyễn Tấn Phát tốt nghiệp cử nhân công nghệ thông tin tại Trường Đại Học Mở Tp. Hồ Chí Minh năm 2006 và tốt nghiệp thạc sĩ ngành Công nghệ thông tin tại Trường Đại học Ngoại ngữ-Tin học Tp. Hồ Chí Minh năm 2022. Anh là chuyên viên công tác tại Phòng Công nghệ thông tin của Bệnh viện Đa khoa khu vực Củ Chi từ 2007 đến nay. Lĩnh vực nghiên cứu chính của anh là dự báo chuỗi thời gian.



Dương Tuấn Anh tốt nghiệp tiến sĩ ngành Khoa học máy tính tại Học viện Công nghệ Á Châu (Asian Institute of Technology), Bangkok, Thái Lan năm 1998 và đó cũng là nơi mà ông tốt nghiệp thạc sĩ với cùng chuyên ngành. Ông là Phó giáo sư tại khoa Khoa học và Kỹ thuật máy tính, Trường Đại học Bách Khoa, ĐHQG Tp. Hồ Chí Minh từ năm 2007. Hiện nay, ông là giảng viên khoa Công nghệ thông tin, Trường Đại học Ngoại ngữ-Tin học Tp. Hồ Chí Minh. Lĩnh vực nghiên cứu chính của ông là metaheuristics, học máy và khai phá dữ liệu chuỗi thời gian. Ông là đồng tác giả của trên 100 bài báo khoa học.