

A MACHINE LEARNING FRAMEWORK FOR PREDICTING TREATMENT ADHERENCE IN PARKINSON'S DISEASE: BALANCING PREDICTIVE ROBUSTNESS AND CLINICAL INTERPRETABILITY

Nguyen Thi Dinh^{1*}, Nguyen Thi Mai², Nguyen Ngoc Giang³

¹Faculty of Medicine, Dai Nam University - Phu Luong, Hanoi City, Vietnam

²Faculty of Nursing, Dai Nam University - Phu Luong, Hanoi City, Vietnam

³Phenikaa School of Computing, Phenikaa University - Duong Noi, Hanoi City, Vietnam

Received: 29/04/2026

Revised: 19/06/2026; Accepted: 28/07/2026

ABSTRACT

Background: Medication non-adherence among patients with chronic diseases such as Parkinson's disease (PD) is a major challenge to effective treatment management. Applying Machine Learning (ML) models is a promising approach, but their application in clinical settings is often limited by small sample sizes, imbalanced clinical data, and especially their "black-box" nature.

Objective: This study aims to develop a robust, transparent ML framework to predict treatment adherence in PD patients, providing actionable clinical explanations, especially on a small dataset.

Methods: We analyzed a clinical dataset of 100 patients, which contains demographic, socioeconomic, and clinical features. To evaluate ML models with this small dataset, we utilized a Leave-One-Out Cross Validation (LOOCV) strategy. Additionally, the class imbalance (72% adherent vs. 28% non-adherent) problem was addressed using cost-sensitive learning algorithms. Feature engineering was also applied to resolve multicollinearity. We evaluated performance of Logistic Regression, Random Forest, and Support Vector Machine (SVM) models. Furthermore, Explainable AI (xAI) techniques were used to investigate feature contributions.

Results: The balanced Support Vector Machine (SVM) model achieved the highest overall performance of 85.0% accuracy and a F1-score of 0.746. Feature analysis indicated that medication regimen complexity, age, and disease duration are main indicators in predicting adherence behaviors.

Conclusion: Our proposed framework demonstrates that ML, when coupled with xAI, can reliably forecast treatment adherence even with limited clinical data. This transparent approach provides a foundation for developing robust Clinical Decision Support Systems (CDSS), and helps healthcare professionals to identify high-risk patients early and tailor personalized intervention strategies.

Keywords: Treatment Adherence, Parkinson's Disease, Machine Learning, Leave-One-Out Cross Validation, Explainable AI, Clinical Decision Support System.

*Corresponding author

Email: nguyenthidinh@hmu.edu.vn Phone: (+84) 919103109 DOI: 10.52163/yhc.v67iCD11.6029

KHUNG MÔ HÌNH HỌC MÁY DỰ ĐOÁN TUÂN THỦ ĐIỀU TRỊ TRONG BỆNH PARKINSON: CÂN BẰNG GIỮA HIỆU SUẤT DỰ ĐOÁN VÀ KHẢ NĂNG DIỄN GIẢI LÂM SÀNG

Nguyễn Thị Định^{1*}, Nguyễn Thị Mai², Nguyễn Ngọc Giang³

¹Khoa Y, Đại học Đại Nam - Phú Lương, Tp. Hà Nội, Việt Nam

²Khoa Điều dưỡng, Đại học Đại Nam - Phú Lương, Tp. Hà Nội, Việt Nam

³Trường Tin học Phenikaa, Đại học Phenikaa - Dương Nội, Tp. Hà Nội, Việt Nam

Ngày nhận: 29/04/2026

Ngày sửa: 19/06/2026; Ngày đăng: 28/07/2026

TÓM TẮT

Đặt vấn đề: Việc bệnh nhân mắc các bệnh mạn tính như Parkinson không tuân thủ điều trị là một thách thức y tế lớn. Học máy (ML) có tiềm năng giải quyết vấn đề này, nhưng các mô hình này thường bị hạn chế bởi cỡ mẫu nhỏ, dữ liệu mất cân bằng và tính "hộp đen" thiếu minh bạch.

Mục tiêu: Phát triển một khung mô hình học máy vững chắc, cung cấp các diễn giải lâm sàng có tính thực tiễn cao để dự đoán sự tuân thủ điều trị ở bệnh nhân Parkinson trên tập dữ liệu nhỏ.

Phương pháp nghiên cứu: Nghiên cứu phân tích dữ liệu của 100 bệnh nhân. Sử dụng chiến lược kiểm chứng chéo loại một (LOOCV) cho dữ liệu nhỏ. Khắc phục vấn đề mất cân bằng lớp (72% tuân thủ, 28% không tuân thủ) bằng thuật toán học có trọng số. Hiệu suất của ba mô hình học máy Logistic Regression (LR), Random Forest (RF), Support Vector Machine (SVM) được đánh giá. Ngoài ra, phương pháp trí tuệ nhân tạo có thể giải thích (xAI) được dùng để đánh giá mức độ đóng góp của từng biến số.

Kết quả: Mô hình SVM cân bằng có hiệu suất tốt nhất: độ chính xác đạt 85,0% và điểm F1 của nhóm không tuân thủ đạt 0,746. Phân tích xAI chỉ ra rằng tần suất dùng thuốc, tuổi tác và thời gian mắc bệnh là ba yếu tố dự báo chính.

Kết luận: Kết quả cho thấy triển vọng ứng dụng ML và xAI trong hỗ trợ dự báo tuân thủ ngay cả khi thiếu hụt dữ liệu, tạo tiền đề cho ứng dụng trong hệ thống hỗ trợ quyết định lâm sàng (CDSS).

Từ khóa: Tuân thủ điều trị, Bệnh Parkinson, Học máy, Kiểm chứng chéo loại một, Trí tuệ nhân tạo có thể giải thích, Hệ thống hỗ trợ quyết định lâm sàng.

1. ĐẶT VẤN ĐỀ

Bệnh Parkinson là một trong những rối loạn thoái hóa thần kinh có tốc độ gia tăng nhanh nhất. Bệnh ảnh hưởng nghiêm trọng đến chức năng vận động và chất lượng cuộc sống của bệnh nhân. Trong quản lý lâm sàng bệnh Parkinson, việc tuân thủ nghiêm ngặt các phác đồ điều trị bằng thuốc được kê đơn đóng vai trò rất quan trọng để kiểm soát các triệu chứng vận động và giảm thiểu các biến chứng nặng nề như dao động vận động và rối loạn vận động. Mặc dù có tầm quan trọng sống còn, tình trạng không tuân thủ dùng thuốc vẫn là một thách thức phổ biến, với tỷ lệ được ghi nhận dao động từ 30% đến hơn 60% trong các cơ sở chăm sóc bệnh mạn tính [1]. Sự không tuân thủ này không chỉ làm giảm hiệu quả điều trị mà còn đẩy nhanh quá trình tiến triển của bệnh và dẫn đến những ca nhập viện có thể phòng ngừa được, từ đó làm gia tăng chi phí chăm sóc y tế [2]. Theo truyền thống, việc đánh giá tuân thủ dùng thuốc chủ yếu dựa vào các bảng câu hỏi tự báo cáo hoặc việc đếm số lượng thuốc. Tuy nhiên, các phương pháp này mang tính chủ quan cao, dễ bị thiên lệch và dễ chịu ảnh hưởng bởi hiệu ứng Hawthorne [3].

Sự ra đời của Học máy (Machine Learning) đã mang lại những khả năng đầy hứa hẹn trong phân tích dự đoán lâm sàng [4]. Tuy nhiên, việc triển khai các mô hình ML vào thực tiễn lâm sàng phải đối mặt với những rào cản đáng kể về mặt phương pháp luận. Việc làm việc với các tập dữ

liệu lâm sàng tất yếu đặt ra thách thức về cỡ mẫu nhỏ. Theo kinh nghiệm của chúng tôi, sự khan hiếm dữ liệu này không chỉ đe dọa khả năng tổng quát hóa của các thuật toán phức tạp mà còn trực tiếp làm tăng nguy cơ xảy ra hiện tượng quá khớp (overfitting) — một rào cản mà chúng tôi chủ động giải quyết trong nghiên cứu này [5]. Hơn nữa, các tập dữ liệu này thường bị mất cân bằng phân lớp, dẫn đến các mô hình bị sai lệch với xu hướng thiên vị nhóm đa số [6]. Có lẽ rào cản lớn nhất đối với việc tích hợp vào lâm sàng là bản chất "hộp đen" của các thuật toán Học máy tiên tiến. Các chuyên gia y tế đòi hỏi những mô hình minh bạch và có thể diễn giải được để xây dựng niềm tin và đưa ra các quyết định sáng suốt [7]. Do đó, việc ứng dụng các mô hình học máy (ML) cùng các kỹ thuật giải thích (xAI) là điều cần thiết để đảm bảo rằng những hiểu biết do AI mang lại phù hợp với y văn đã được công nhận.

Để giải quyết những khoảng trống quan trọng này, chúng tôi đề xuất một khung mô hình Học máy vững chắc và minh bạch nhằm dự đoán sự tuân thủ điều trị ở bệnh nhân mắc bệnh Parkinson. Chúng tôi đã phát triển một quy trình có khả năng giải quyết các thách thức về cỡ mẫu nhỏ và mất cân bằng dữ liệu. Dưới đây là ba đóng góp cốt lõi của nghiên cứu này:

1. Đánh giá hiệu quả của các mô hình học máy trên dữ liệu hạn chế: Chúng tôi đã triển khai chiến lược Kiểm

*Tác giả liên hệ

Email: nguyenthidinh@hmu.edu.vn Điện thoại: (+84) 919103109 DOI: 10.52163/yhc.v67iCD11.6029

chứng chéo loại một (Leave-One-Out Cross-Validation - LOOCV) nghiêm ngặt kết hợp với học nhảy cảm với chi phí nhằm ngăn chặn sự rò rỉ dữ liệu (data leakage) và phát hiện tối ưu nhóm thiểu số gồm các bệnh nhân không tuân thủ.

2. Chiến lược xử lý đặc trưng: Chúng tôi đã giải quyết một cách có hệ thống hiện tượng đa cộng tuyến (multicollinearity) giữa các biến số lâm sàng mang tính thời gian (ví dụ: tuổi bệnh nhân, tuổi khởi phát và thời gian mắc bệnh) để bảo toàn tính toàn vẹn của không gian đặc trưng và ngăn ngừa sự biến dạng trọng số trong các mô hình dự báo.

3. Khả năng diễn giải định lượng: Chúng tôi đã tích hợp các kỹ thuật Trí tuệ nhân tạo có thể giải thích (xAI) để giải mã các quá trình ra quyết định của các mô hình học máy. Bằng cách này, chúng tôi cung cấp những thông tin chi tiết, minh bạch và có tính ứng dụng cao, có tiềm năng sử dụng cho các Hệ thống hỗ trợ ra quyết định lâm sàng (CDSS) trong tương lai.

Tóm lại, nghiên cứu này đã chứng minh được các mô hình học máy khi được tinh chỉnh phù hợp và có khả năng diễn giải tốt có thể tạo ra các dự đoán đáng tin cậy về hành vi tuân thủ điều trị, từ đó đặt nền móng cho các can thiệp lâm sàng mang tính chủ động và cá thể hóa.

2. PHƯƠNG PHÁP NGHIÊN CỨU

2.1. Tập dữ liệu

Chúng tôi tiến hành thu thập dữ liệu tại bệnh viện Thanh Nhàn từ tháng 9 năm 2023 đến tháng 7 năm 2024. Tiêu chí lựa chọn đối tượng nghiên cứu là những người bệnh đồng ý tham gia nghiên cứu, có đầy đủ số khám bệnh, được chẩn đoán bệnh Parkinson theo tiêu chuẩn của Hội Rối loạn vận động (Movement Disorder Society – MDS), đang điều trị ngoại trú và sử dụng ít nhất 1 loại thuốc. Chúng tôi loại khỏi nghiên cứu những người bệnh có tình trạng nhận thức bất thường dựa vào thang điểm MoCA (tổng điểm < 22). Về đạo đức nghiên cứu, chúng tôi hoàn toàn tuân thủ các quy định, mọi thông tin đều được mã hóa, bảo mật và chỉ phục vụ cho mục đích nghiên cứu khoa học. Quá trình thu thập số liệu hoàn toàn không can thiệp vào quá trình điều trị và không làm ảnh hưởng đến quyền lợi người bệnh.

Chúng tôi đã xây dựng được bộ dữ liệu lâm sàng gồm 100 bệnh nhân. Không gian đặc trưng bao gồm các đặc điểm nhân khẩu học (ví dụ: tuổi, giới tính, nghề nghiệp), các yếu tố kinh tế - xã hội (ví dụ: mức thu nhập) và các chỉ số lâm sàng chuyên sâu (ví dụ: phân loại UPDRS, tần suất dùng thuốc, và thời gian mắc bệnh). Biến mục tiêu là sự tuân thủ điều trị được chia thành hai phân lớp: "tuân thủ" (chiếm 72% tập dữ liệu) và "không tuân thủ" (28%).

Để đảm bảo tính toàn vẹn của không gian đặc trưng và tối ưu hóa hiệu suất của các thuật toán học máy, chúng tôi đã sử dụng các kỹ thuật tiền xử lý sau: Để loại bỏ hiện tượng đa cộng tuyến, biến "Tuổi khởi phát" đã được loại bỏ một cách có hệ thống khỏi không gian đặc trưng; Các danh mục nghề nghiệp được gộp lại thành các nhóm vĩ mô lớn hơn (ví dụ: người làm công ăn lương, lao động tự do, đã nghỉ hưu). Việc phân nhóm theo ngữ nghĩa này giúp bảo toàn lượng thông tin cốt lõi trong khi vẫn giảm thiểu được số chiều dữ liệu. Tiếp theo, chúng tôi sử dụng kỹ thuật mã hóa one-hot (one-hot encoding) để mã hóa các biến phân loại; Chúng tôi cũng chuẩn hóa các biến số học về dạng (giá trị trung bình = 0, phương sai = 1) để triệt tiêu tác động của sự khác biệt về các đơn vị đo lường.

Vì tập dữ liệu chỉ có 100 mẫu, chúng tôi đã sử dụng phương pháp Kiểm chứng chéo loại một (LOOCV) để đánh giá hiệu quả các mô hình ML. Cách tiếp cận này đảm bảo rằng các thuật toán được tiếp xúc với lượng dữ

liệu huấn luyện lớn nhất có thể trong mỗi vòng lặp, đồng thời ngăn ngừa hiện tượng rò rỉ dữ liệu giữa tập huấn luyện và tập kiểm tra [5, 8].

2.2. Các mô hình học máy

Vấn đề mất cân bằng phân lớp (tỷ lệ 2,5:1 giữa nhóm bệnh nhân tuân thủ và không tuân thủ) là một thách thức phân loại đáng kể, thường làm cho các mô hình dự báo bị thiên lệch về phía nhóm đa số. Do đó, chúng tôi đã áp dụng mô hình học máy có trọng số cho các lớp (cost-sensitive learning), trong đó các trọng số phân lớp được tự động điều chỉnh tỷ lệ nghịch với tần suất xuất hiện của chúng trong dữ liệu huấn luyện [6]. Ba thuật toán học máy đã được sử dụng để đánh giá và so sánh hiệu suất:

1. Hồi quy Logistic (Logistic Regression): Đóng vai trò là mô hình tuyến tính cơ sở, được biết đến với độ vững và khả năng tổng quát hóa tốt trên các tập dữ liệu nhỏ [9].

2. Rừng ngẫu nhiên (Random Forest): Một phương pháp học tập hợp (ensemble learning) sử dụng các cây quyết định, mang lại hiệu quả cao trong việc nắm bắt các mối quan hệ phi tuyến tính [4]. Máy học véc-tơ hỗ trợ (Support Vector Machine - SVM): Được triển khai với nhân tuyến tính (linear kernel) để ánh xạ các ranh giới quyết định trong không gian đa chiều [10].

Hiệu suất dự đoán tổng thể được định lượng bằng Độ chính xác (Accuracy) và Điểm số F1 (F1-Score) - một chỉ số cung cấp cái nhìn đánh giá tốt hơn đối với các mô hình học máy trên những tập dữ liệu bị mất cân bằng.

2.3. Khung Trí tuệ nhân tạo có thể giải thích (xAI) đảm bảo tính minh bạch trong lâm sàng

Để vượt qua những hạn chế mang tính "hộp đen" của các thuật toán học máy tiên tiến, chúng tôi đã tích hợp một khung Trí tuệ nhân tạo có thể giải thích (xAI) sử dụng công cụ SHAP (SHapley Additive exPlanations) [11]. SHAP tính toán mức độ đóng góp biên (marginal contribution) của từng đặc trưng vào dự đoán cuối cùng của mô hình, cung cấp một thước đo hợp nhất về mặt toán học để đánh giá mức độ quan trọng của đặc trưng.

3. KẾT QUẢ

3.1. Hiệu suất dự đoán

Bảng 1. Hiệu suất dự báo của các mô hình theo phương pháp Kiểm chứng chéo loại một (LOOCV)

Mô hình	Độ chính xác (%)	F1-score
Baseline-Random	48.0	0.381
Baseline-Mode	72.0	0.000
Hồi quy Logistic	84.0	0.724
Rừng ngẫu nhiên	84.0	0.704
SVM	85.0	0.746

Với chiến lược học nhảy cảm với chi phí được thực hiện thông qua việc cân bằng trọng số phân lớp và dưới khung Kiểm chứng chéo loại một (LOOCV), các mô hình đã đạt được các mức hiệu suất như trình bày trong Bảng 1:

- Hồi quy Logistic đạt Độ chính xác tổng thể là 84,0% và Điểm số F1 của nhóm "không tuân thủ" là 0,724.

- Rừng ngẫu nhiên đạt Độ chính xác tương đương là 84,0% nhưng có Điểm số F1 của nhóm "không tuân thủ" thấp hơn, ở mức 0,704.

- Máy học véc-tơ hỗ trợ (SVM - Nhân tuyến tính) là mô hình hoạt động tốt nhất với Độ chính xác tổng thể đạt 85,0% và Điểm số F1 của nhóm "không tuân thủ" là 0,746.

Để chứng minh các mô hình học máy thực sự học được quy luật phân loại thay vì phụ thuộc vào sự mất cân bằng của dữ liệu (với 72% nhân thuộc về lớp "tuân thủ"), chúng tôi đối chiếu hiệu năng với hai mô hình cơ sở: Baseline-Random (dự đoán ngẫu nhiên) và Baseline-Mode (luôn dự đoán nhân đa số). Các kết quả đạt được cho thấy sự vượt trội có ý nghĩa của các mô hình đề xuất so với ngưỡng accuracy 72% của mô hình Baseline-Mode.

3.2. Phân tích các yếu tố nguy cơ lâm sàng


Như thể hiện trong Hình 3.1, các giá trị SHAP (SHapley Additive exPlanations) được trích xuất từ mô hình SVM cho thấy các yếu tố dự báo quan trọng nhất đối với hành vi tuân thủ điều trị ở bệnh nhân Parkinson:

- Tần suất dùng thuốc (DosingFrequency): Đây là đặc trưng dự báo quan trọng nhất. Tần suất dùng thuốc cao hơn (được thể hiện bằng các điểm màu đỏ ở bên trái) tác động tiêu cực đến đầu ra của mô hình, làm giảm giá trị dự đoán (giảm khả năng dự đoán không tuân thủ). Ngược lại, tần suất dùng thuốc thấp hơn (các điểm màu xanh lam ở bên phải) làm tăng đáng kể giá trị của kết quả dự đoán (tăng khả năng dự đoán không tuân thủ).

- Tuổi tác (Age): Đặc trưng này cho thấy mối tương quan thuận mạnh mẽ với đầu ra của mô hình. Những người lớn tuổi hơn (các điểm màu đỏ) tập trung chủ yếu ở phía dương của trục giá trị SHAP, chỉ ra rằng độ tuổi càng cao thì càng thúc đẩy kết quả dự đoán theo chiều hướng tăng lên.

- Thời gian mắc bệnh (DiseaseDuration): Chúng ta có thể thấy mối quan hệ nghịch biến của yếu tố này với đầu ra. Thời gian mắc bệnh ngắn hơn (các điểm màu xanh lam) có xu hướng làm tăng dự đoán của mô hình, trong khi thời gian mắc bệnh dài hơn (các điểm màu đỏ) làm giảm dự đoán.

Kết quả này cho thấy các dự đoán của mô hình chủ yếu bị chi phối bởi "Tần suất dùng thuốc", tuổi tác của bệnh nhân và thời gian mắc bệnh.



Hình 1. Biểu đồ SHAP của mô hình SVM

4. BÀN LUẬN

Trong nghiên cứu này, chúng tôi đề xuất một khung mô hình Học máy vững chắc và minh bạch để dự đoán sự tuân thủ điều trị ở bệnh nhân mắc bệnh Parkinson. Các phát hiện của chúng tôi chứng minh rằng việc kết hợp các mô hình ML với Trí tuệ nhân tạo có thể giải thích (xAI) không chỉ cải thiện độ chính xác của dự báo mà còn cung

cấp những hiểu biết lâm sàng mang tính thực tiễn cho các chuyên gia y tế.

4.1. Hiệu suất của các mô hình

Với một tập dữ liệu lâm sàng gồm 100 bệnh nhân, bằng cách sử dụng chiến lược Kiểm chứng chéo loại một (LOOCV), chúng tôi đã tối đa hóa dữ liệu huấn luyện trong mỗi vòng lặp đồng thời ngăn chặn hiện tượng rò rỉ dữ liệu (data leakage) giữa tập huấn luyện và tập kiểm tra. Đồng thời, với mô hình học nhạy cảm với chi phí (cost-sensitive learning), chúng tôi đã đạt được điểm số F1 ở mức chấp nhận được trong việc phát hiện phân lớp thiểu số (bệnh nhân không tuân thủ).

Trong số các thuật toán, Máy học véc-tơ hỗ trợ (SVM) với nhân tuyến tính đạt được hiệu suất tổng thể cao nhất, với độ chính xác đạt 85,0% và điểm số F1 là 0,746. Hiệu suất vượt trội này của mô hình SVM bắt nguồn từ khả năng ánh xạ các ranh giới quyết định trong không gian đa chiều của nó.

4.2. Diễn giải các yếu tố lâm sàng thông qua xAI

Một trong những đóng góp cốt lõi của nghiên cứu này là việc tích hợp khung mô hình SHAP (SHapley Additive exPlanations) để giải mã bản chất "hộp đen" của các thuật toán ML. Phân tích SHAP được trích xuất từ mô hình SVM cho thấy hành vi điều trị và nhân khẩu học của bệnh nhân là những yếu tố thúc đẩy chính cho các dự đoán của mô hình.


- Tần suất dùng thuốc (Dosing Frequency): Nổi lên như một đặc trưng dự báo quan trọng nhất. Tần suất dùng thuốc cao hơn tác động tiêu cực đến đầu ra của mô hình, làm giảm xác suất dự đoán không tuân thủ điều trị, trong khi tần suất dùng thuốc thấp hơn làm tăng xác suất dự đoán không tuân thủ điều trị. Phát hiện này gợi ý rằng một phác đồ điều trị có tần suất cao có thể giúp bệnh nhân thiết lập một thói quen dùng thuốc hàng ngày nghiêm ngặt hơn. Ngoài ra, những bệnh nhân cần dùng thuốc thường xuyên thường gặp phải các triệu chứng rõ rệt hơn hoặc nhận được sự giám sát chặt chẽ hơn từ người chăm sóc, cả hai điều này đều có thể đóng vai trò như những lời nhắc nhở liên tục và từ đó làm tăng khả năng tuân thủ tổng thể.

- Tuổi tác (Age): Cho thấy mối tương quan thuận mạnh mẽ với đầu ra của mô hình. Tuổi càng cao càng đẩy kết quả dự đoán lên trên, cho thấy khả năng không tuân thủ cao hơn. Quan sát lâm sàng này có thể do một vài thách thức liên quan đến tuổi tác. Bệnh nhân lớn tuổi thường gặp phải tình trạng suy giảm nhận thức hoặc suy giảm trí nhớ, khiến họ khó tuân thủ nghiêm ngặt lịch trình dùng thuốc. Họ cũng có nhiều khả năng gặp phải tình trạng đa dược (polypharmacy - sử dụng đồng thời nhiều loại thuốc cho các bệnh đồng mắc khác nhau) và các hạn chế về thể chất (như khó nuốt hoặc khó mở lọ thuốc), tất cả những điều này có thể làm tăng đáng kể sự nhầm lẫn và nguy cơ bỏ lỡ liều.

- Thời gian mắc bệnh (Disease Duration): Thể hiện mối quan hệ nghịch biến với đầu ra của mô hình. Thời gian mắc bệnh dài hơn sẽ đẩy kết quả dự đoán xuống dưới, cho thấy xác suất không tuân thủ thấp hơn (tức là tuân thủ tốt hơn), trong khi thời gian mắc bệnh ngắn hơn làm tăng dự đoán về sự không tuân thủ. Phát hiện này phản ánh thực tế lâm sàng rằng những bệnh nhân sống chung với bệnh Parkinson trong một thời gian dài thường đã tích hợp lịch trình dùng thuốc phức tạp của họ thành các thói quen hàng ngày ăn sâu vào đời sống. Hơn nữa, khi bệnh tiến triển qua nhiều năm, bệnh nhân nhận thức rất rõ rệt về các dao động vận động tức thì và nghiêm trọng (chẳng hạn như các giai đoạn "tắt" [off periods] hoặc hiện tượng đông cứng [freezing]) xảy ra do bỏ lỡ liều thuốc, buộc họ phải tuân thủ nghiêm ngặt phác đồ để được kê đơn để duy trì khả năng vận động và chất lượng cuộc sống.

Về mặt lâm sàng, những phát hiện này thách thức các giả định thông thường và nhấn mạnh rằng tuổi tác là một yếu tố dễ bị tổn thương cốt lõi. Các nhà cung cấp dịch vụ y tế nên ưu tiên hỗ trợ cá thể hóa, chẳng hạn như sự tham gia của người chăm sóc, các công cụ hỗ trợ trí nhớ và quản lý thuốc có hỗ trợ, đặc biệt dành riêng cho các bệnh nhân lớn tuổi. Trong khi đó, họ có thể tận dụng các thói quen đã được thiết lập và kiến thức kinh nghiệm của những bệnh nhân lâu năm để duy trì tỷ lệ tuân thủ cao.

Trong Hình 2, với phân tích SHAP, chúng ta có thể thấy chi tiết ảnh hưởng của từng đặc trưng trong việc dự đoán một bệnh nhân không tuân thủ.



Hình 2. Diễn giải lâm sàng cho CDSS (Đối với bệnh nhân không tuân thủ)

4.3. Ý nghĩa thực tiễn và Hạn chế của nghiên cứu

Cách tiếp cận ML minh bạch này đặt nền móng vững chắc cho việc phát triển các Hệ thống Hỗ trợ Ra quyết định Lâm sàng (CDSS) mạnh mẽ. Bằng cách hiểu được quy trình ra quyết định của các mô hình tối ưu, các chuyên gia y tế có thể xây dựng niềm tin và đưa ra các quyết định sáng suốt. Điều này cho phép nhận diện sớm những bệnh nhân có nguy cơ cao và điều chỉnh các chiến lược can thiệp cá thể hóa chẳng hạn như hợp nhất các phác đồ dùng thuốc để giảm tần suất liều lượng.

Tuy nhiên, nghiên cứu này vẫn tồn tại một số hạn chế. Bất chấp việc áp dụng các chiến lược kiểm chứng nghiêm ngặt và học nhạy cảm với chi phí, cỡ mẫu nhỏ về bản chất đã giới hạn khả năng tổng quát hóa rộng hơn của các thuật toán phức tạp. Trong tương lai, chúng tôi sẽ tập trung vào việc kiểm chứng khung mô hình này bằng cách sử dụng các tập dữ liệu đa trung tâm lớn hơn và kết hợp các biến số lâm sàng theo chiều dọc (longitudinal clinical variables) để theo dõi và dự đoán một cách toàn diện các thay đổi động trong sự tuân thủ điều trị của bệnh nhân Parkinson.

5. KẾT LUẬN

Chúng tôi đã phát triển và kiểm chứng thành công một khung mô hình Học máy vững chắc và minh bạch nhằm dự đoán sự tuân thủ điều trị ở bệnh nhân mắc bệnh Parkinson. Bằng cách triển khai chiến lược Kiểm chứng chéo loại một (LOOCV) và mô hình học nhạy cảm với chi phí, chúng tôi đã giải quyết hiệu quả các thách thức phổ biến về cỡ mẫu nhỏ và dữ liệu lâm sàng mất cân bằng. Trong số các thuật toán được đánh giá, mô hình Máy học véc-tơ hỗ trợ (SVM) đạt hiệu suất cao nhất, với độ chính xác tổng thể là 85,0% và điểm số F1 cho dự đoán không tuân thủ là 0,746.

Bằng cách tích hợp Trí tuệ nhân tạo có thể giải thích (XAI) thông qua khung mô hình SHAP, chúng tôi đã xác định tần suất dùng thuốc, tuổi tác và thời gian mắc bệnh là những yếu tố dự báo quan trọng nhất đối với hành vi tuân thủ điều trị. Các kết quả này nhấn mạnh rằng tần suất dùng thuốc và các yếu tố nhân khẩu học là những chỉ báo mang tính quyết định đối với sự tuân thủ hơn là giai đoạn lâm sàng thực tế của bệnh.

Tóm lại, khung mô hình được đề xuất chứng minh rằng Học máy khi được kết hợp với khả năng diễn giải cho thấy tiềm năng bước đầu trong ứng dụng vào bài toán dự đoán tuân thủ điều trị của bệnh nhân Parkinson trên bộ dữ liệu nhỏ. Nghiên cứu này đặt nền móng cho việc phát triển các Hệ thống Hỗ trợ Ra quyết định Lâm sàng (CDSS) trong tương lai, cho phép các chuyên gia y tế nhận diện sớm những bệnh nhân có nguy cơ cao và tùy biến các chiến lược can thiệp cá thể hóa nhằm tối ưu hóa kết quả điều trị trong quản lý bệnh Parkinson. Tuy nhiên với kết quả sơ bộ của nghiên cứu, chúng tôi nhận thấy vẫn cần thiết phải làm thêm nhiều thí nghiệm trên các bộ dữ liệu khác, và xây dựng một bộ dữ liệu độc lập để có thể đánh giá chính xác khả năng áp dụng vào thực tế của phương pháp này.

TÀI LIỆU THAM KHẢO

- [1] Malek N and Grosset DG. Medication Adherence in Patients with Parkinson's Disease. CNS Drugs 2015 Jan; 29:47–53. DOI: 10.1007/s40263-014-0220-0
- [2] Brown MT and Bussell JK. Medication Adherence: WHO Cares? Mayo Clinic Proceedings 2011 Apr; 86:304–14. DOI: 10.4065/mcp.2010.0575
- [3] McCambridge J, Witton J and Elbourne DR. Systematic review of the Hawthorne effect: new concepts are needed to study research participation effects. Journal of Clinical Epidemiology 2014; 67:267–77. DOI: 10.1016/j.jclinepi.2013.08.015
- [4] Lo-Ciganic WH, Donohue JM, Thorpe JM, Perera S, Thorpe CT, Marcum ZA and Gellad WF. Using Machine Learning to Examine Medication Adherence Thresholds and Risk of Hospitalization. Medical Care 2015 Aug; 53:720–8. DOI: 10.1097/MLR.0000000000000394
- [5] Vabalas A, Gowen E, Poliakoff E and Casson AJ. Machine Learning Algorithm Validation with a Limited Sample Size. PLOS ONE 2019 Nov; 14. DOI: 10.1371/journal.pone.0224365
- [6] Haibo He and Garcia E. Learning from Imbalanced Data. IEEE Transactions on Knowledge and Data Engineering 2009 Sep; 21:1263–84. DOI: 10.1109/TKDE.2008.239
- [7] Amann J, Blasimme A, Vayena E, Frey D and Madai VI. Explainability for Artificial Intelligence in Healthcare: A Multidisciplinary Perspective. BMC Medical Informatics and Decision Making 2020 Dec; 20:310. DOI: 10.1186/s12911-020-01332-6
- [8] Bates S, Hastie T and Tibshirani R. Cross-Validation: What Does It Estimate and How Well Does It Do It? Journal of the American Statistical Association 2024 Apr; 119:1434–45. DOI: 10.1080/01621459.2023.2197686
- [9] Cox DR. The regression analysis of binary sequences. Journal of the Royal Statistical Society: Series B (Methodological) 1958; 20:215–32
- [10] Cortes C and Vapnik V. Support-vector networks. Machine learning 1995; 20:273–97. DOI: 10.1007/BF00994018
- [11] Lundberg S and Lee SI. A Unified Approach to Interpreting Model Predictions. 2017. DOI: 10.48550/ARXIV.1705.07874