

CẢI TIẾN MẠNG HỌC SÂU GOOGLINET HỖ TRỢ PHÂN LOẠI BỆNH CAO HUYẾT ÁP TRÊN ẢNH VÕNG MẠC MẮT

Võ Thị Hồng Tuyết, Nguyễn Thanh Bình

Khoa Công Nghệ Thông Tin, Trường Đại học Ngoại ngữ-Tin học TP.HCM

tuyetvth@huflit.edu.vn, binh@huflit.edu.vn

TÓM TẮT— Ảnh võng mạc mắt chứa nhiều thông tin hữu ích. Đặc trưng của ảnh võng mạc mắt được rút trích từ các mô hình học cần được cải thiện và tối ưu giúp quá trình phân loại bệnh được chính xác hơn. Khả năng phân loại càng cao thì quá trình chẩn đoán và điều trị bệnh lý càng thuận lợi. Thách thức trong xử lý ảnh võng mạc là trích xuất đặc trưng quan trọng với các tham số đầu phù hợp với hình thái học tương ứng. Trong nghiên cứu này, chúng tôi đề xuất quá trình cải tiến mạng GoogLeNet dựa vào cơ chế hình thái học waveform để phân loại bệnh cao huyết áp trên ảnh võng mạc mắt. Phương pháp đề xuất gồm hai giai đoạn: tiền xử lý tham số đầu vào cho mô hình học với hình thái học waveform, GoogLeNet chiết xuất đặc trưng với sự cải tiến ở số lượng tầng Inception hỗ trợ chiết xuất đặc trưng sâu. Kết quả được thử nghiệm trên tập dữ liệu STARE với độ chính xác 93.25 %. Quá trình so sánh kết quả phân loại được so sánh với một số phương pháp gần đây và cho kết quả khả quan hơn.

Từ khóa— GoogLeNet, hình thái học waveform, phân lớp bệnh cao huyết áp, ảnh võng mạc mắt.

I. GIỚI THIỆU

Bệnh cao huyết áp với nhiều biến chứng phức tạp đã gây ra nhiều hệ lụy bệnh lý phức tạp. Việc phát hiện sớm căn bệnh này có thể hỗ trợ cho quá trình chẩn đoán và điều trị lâm sàng của các chuyên gia y tế. Ngoài các thiết bị đo, thiết bị thăm khám cụ thể đã áp dụng, việc dựa trên các hình thái bộ phận trong cơ thể bệnh nhân để chẩn đoán bệnh là một trong các yếu tố đáng lưu tâm. Dựa vào võng mạc mắt đánh giá các yếu tố bệnh nhân khoa. Tuy nhiên, các mạch máu này vẫn chứa đựng nhiều thông tin hữu ích. Vì vậy, phát hiện bệnh nhân bị bệnh cao huyết áp dựa trên ảnh võng mạc mắt là một trong các chủ đề được quan tâm trong thị giác máy tính.

Do độ dày của mạch máu võng mạc chỉ từ 3 đến 5 điểm ảnh và liên tục gần nhau trong ảnh, nên việc trích xuất các đặc trưng phải chi tiết và đảm bảo yếu tố hàng xóm gần nhau. Chính vì những yếu tố này, nếu quá trình làm mịn (smoothing) hay cải thiện chất lượng (enhancing) diễn ra với nhiều ngưỡng (threshold)/ bộ lọc (filter) sẽ gây mất thông tin cần thiết. Trong thời gian qua, nhiều phương pháp đã được đề xuất để thực hiện việc này và xoay quanh các chủ đề: cửa sổ trượt, phép biến đổi miền không gian hay có thể bỏ qua giai đoạn làm mịn, thực hiện tiếp tục các mô hình học trích xuất đặc trưng. Bản đồ đặc trưng được trích xuất từ các mô hình học với số lượng tham số đầu vào ổn định, chịu chi phối bởi số tầng, cấu trúc mã hóa - giải mã, đặc trưng học bổ sung, ... Tuy nhiên, nếu lựa chọn sự ổn định của tham số đầu vào, sự can thiệp vào việc bình ổn này cần được quan tâm. Chính vì vậy, các phương pháp tiền xử lý đầu vào ảnh đã được nghiên cứu có thể kể đến như: miền tần số, miền không gian, phép biến đổi và hình thái học. Quá trình này tận dụng kết quả đầu vào được phát triển trong các nghiên cứu gần đây do các kết quả khả quan khi áp dụng mô hình máy học trích xuất đặc trưng. Kiến trúc của các mô hình máy học hoặc học sâu đã được đề xuất và triển khai rộng khắp với nhiều lựa chọn cấu trúc backbone. GoogLeNet với kiến trúc phân tầng Inception và tích chập bộ lọc kết hợp đã mang lại những kết quả khả quan cho bản đồ đặc trưng.

Bài báo này đề xuất một phương pháp phân loại bệnh cao huyết áp trên ảnh võng mạc mắt sử dụng hình thái học waveform và cải tiến GoogLeNet. Phương pháp đề xuất gồm hai giai đoạn: tiền xử lý tham số đầu vào mô hình học với hình thái học waveform, và GoogLeNet cải tiến ở số lượng tầng Inception hỗ trợ trích xuất đặc trưng sâu. Bố cục của bài báo này gồm 5 phần: phần 1 giới thiệu tổng quan; các nghiên cứu liên quan đến vấn đề nghiên cứu được trình bày ở phần 2; phương pháp đề xuất phân loại bệnh cao huyết áp trên ảnh võng mạc mắt được nêu ở phần 3; kết quả thực nghiệm và định hướng phát triển trong tương lai được trình bày lần lượt ở phần 4 và 5.

II. CÁC NGHIÊN CỨU LIÊN QUAN

Khả năng trích xuất đặc trưng của các mô hình học được áp dụng nhiều trong bài toán phân loại, với phân loại bệnh cao huyết áp trên ảnh võng mạc mắt không phải là ngoại lệ. Phương pháp phát hiện tự động bệnh cao huyết áp với hệ thống hỗ trợ được triển khai từ 2012 với công trình [1] của Kevin và cộng sự. Quá trình nhận dạng tự động tại nghiên cứu này còn sơ khởi với phép biến đổi Radon với hỗ trợ tính toán đặc trưng bằng ROI (Region of Interest). Công trình [2] tiếp tục phát triển ROI bằng cơ chế cục bộ trung tâm để xác định bản đồ đặc trưng. Vào năm 2019, bài toán phân vùng đã được áp dụng để hỗ trợ phát hiện bệnh cao huyết áp với cơ chế mạng nơ-ron học sâu ngữ nghĩa hình ảnh. Đây cũng chính là một trong những cách thức tận dụng hệ thống mã hóa - giải mã cho quá trình tổng hợp đặc trưng của bài toán phân lớp. Với sự phát triển rộng khắp của mạng lưới

học sâu cho chiết xuất đặc trưng, lần lượt các mạng lưới mới được đề xuất như: ResNet-50 [4], DenseNet [5], hay kết hợp với điều kiện cơ chế phân tích và điều kiện lọc đặc trưng [6, 7]. Nhược điểm của các phương pháp theo định hướng này là việc tối ưu tham số đầu vào cho mô hình học và giới hạn phương pháp tiền xử lý dữ liệu. Bên cạnh đó, các mô hình học với hệ thống mã hóa – giải mã chung thường bao gồm trình tự tương xứng về số lượng block thực hiện ở từng tầng, từng giai đoạn nên đồng nghĩa việc chiết xuất đặc trưng sâu là vấn đề thách thức.


Tiền xử lý hình ảnh đầu vào của các hệ thống phân lớp bao gồm nhiều hình thức: đa cấp độ miền không gian hoặc cải thiện chất lượng điểm ảnh. Tính toán wave đã được đề xuất bởi Nucci và cộng sự [8]. Tại đây quá trình trích xuất đặc trưng hình thái học được thực hiện tự động dựa trên học ground-truth của đối tượng trong ảnh. Đa dạng hóa hình thái với biến đổi waveform cho tín hiệu đầu vào và hỗ trợ phân tích phân lớp tối ưu với support vector machine (SVM) đã được đề xuất tại [9]. Năm 2023, Yang và cộng sự [10] đã tiến hành nghiên cứu máy học áp dụng cho chụp cắt lớp động mạch phổi nhằm đánh giá áp lực này lên bệnh nhân cao huyết áp. Quá trình sử dụng máy học đánh giá đã sử dụng hình dạng, khu vực hình thái của đối tượng cần thiết. Điểm chung của các công trình nghiên cứu này là không biến đổi hình thái mà chỉ tập trung vào việc tái kết nối giữa các khu vực cùng tính chất.

Biến đổi hình thái học đối tượng còn có thể dựa vào các yếu tố: tổng diện tích khu vực, biên độ, thời gian (tùy loại tín hiệu số) hoặc đặc trưng hình thái. Các yếu tố này đã được đề xuất tại [11 – 13]. Bên cạnh đó, kết hợp giữa học sâu và đặc trưng hình thái tín hiệu đã được áp dụng để tính toán giảm tải tâm thất trái theo dạng bài toán phân lớp [12] và hình thái biểu hiện gen [13]. Nhìn chung, các đặc trưng hình thái học được sử dụng như yếu tố tiền xử lý cho hình ảnh đầu vào của các hệ thống phân lớp hay phát hiện đối tượng sẽ sử dụng đi kèm mô hình học sâu hoặc cải thiện đầu vào cho học sâu [14-17]. Quá trình học đặc trưng trải qua kết cấu nhiều tầng xử lý của học sâu và các cơ chế tối ưu bản đồ đặc trưng bằng thuyết ngữ nghĩa phân đoạn hoặc xác suất tính toán.

Dựa vào các nghiên cứu có liên quan đã liệt kê ở trên, kết quả liên đới và kết hợp giữa hình thái học cùng các mô hình học sâu đã trở thành xu thế và tất yếu trong các hệ thống phân lớp hay phát hiện bất thường trên ảnh tự nhiên và y khoa.

III. PHƯƠNG PHÁP ĐỀ XUẤT PHÂN LOẠI BỆNH CAO HUYẾT ÁP

Như đã trình bày ở phần 1, nghiên cứu này đề xuất phương pháp phân loại bệnh cao huyết áp dựa trên hình thái học waveform và cải tiến mô hình GoogLeNet. Các giai đoạn của phương pháp đề xuất được mô tả như hình 1 dưới đây.



Hình 1. Phương pháp đề xuất phân loại bệnh cao huyết áp

Như đã mô tả, phương pháp đề xuất bao gồm hai giai đoạn:

- Giai đoạn 1: tiền xử lý với hình thái học waveform cải thiện chất lượng tham số đầu vào cho giai đoạn sau. Quá trình này tập trung vào hình gọn sóng theo biên waveform và tái sử dụng cho quá trình làm mịn.
- Giai đoạn 2: cải tiến tầng Inception trong kiến trúc mô hình GoogLeNet. Kết quả tầng cuối cùng là xác suất dự đoán softmax nhằm lựa chọn kết quả phân loại.

A. HÌNH THÁI HỌC WAVEFORM

Hình thái học waveform là trạng thái của hình thái dạng sóng của tín hiệu. Hình thái này liên quan đến khu vực đối tượng, biên độ khoảng cách giữa các điểm ảnh. Với hình thái học cơ bản sẽ bao gồm các yếu tố:

- Giãn nở (Dilation).
- Xói mòn (Erosion).
- Mở thực thi (Opening performs).
- Đóng thực thi (Closing performs).
- Tính toán khác biệt (TopHat calculates).
- Tính toán watershed (Watershed calculates).

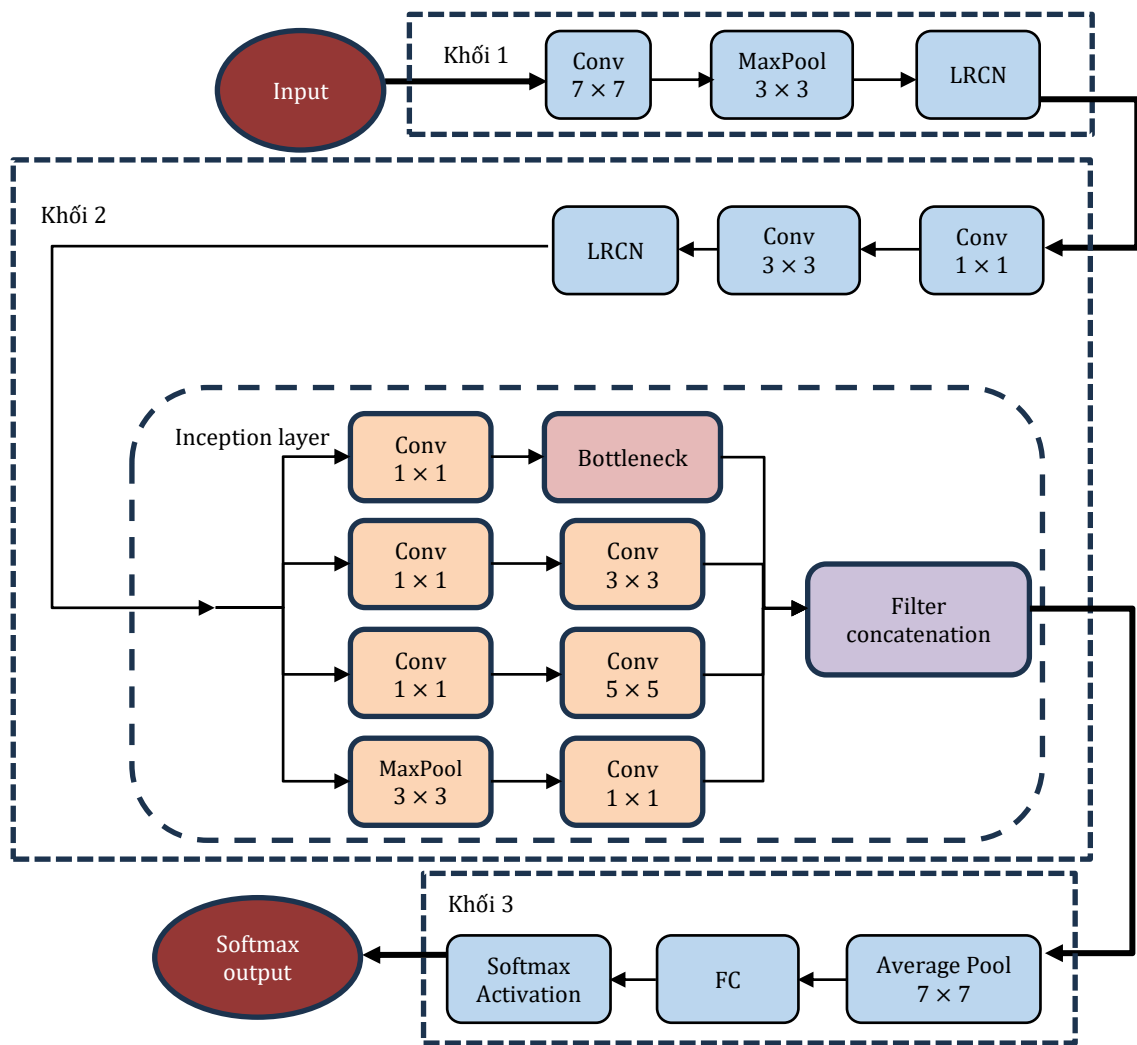
Quá trình tính toán từng giai đoạn hay tổng hợp quy trình đều dựa vào cơ chế thuần đặc trưng của giãn nở và xói mòn trên nền tảng đóng/ mở khu vực được lựa chọn. Đối với ảnh võng mạc mắt, hình thái sóng còn được ghi nhận theo kết hợp với phản ứng cảm quang khi chụp và độ nhạy sáng. Các giá trị độ gãy trong quá trình phục vụ hồi độ nhạy sáng có hình nón và thường được tẩy trắng. Đây chính là các yếu tố quan trọng để xác định hình thái

gọn sóng và cải thiện chất lượng tham số đầu vào cho giai đoạn liền sau. Hình thái sóng waveform trong phương pháp đề xuất được áp dụng như sau:

- Tính toán điểm nổi bật trên toàn cục ảnh.
- Chọn lựa số điểm nổi bật trung tâm (số cụm hình thái) bằng tính chất gom cụm k-means. Lựa chọn số cụm tùy theo từng khu vực sau khi đã xói mòn và giãn nở.
- Tính toán đường cơ sở giữa mỗi điểm ảnh với điểm trung tâm của cụm gần nhất. Quá trình này được tính theo khoảng cách Euclidean.
- Trên mỗi điểm ảnh p, tính khoảng cách với các điểm hàng xóm trong khu vực cửa sổ 3×3 . Điểm q nào gần với p hơn sẽ hợp với p 1 góc sao cho p và q là 2 tia tạo ra được từ điểm trung tâm cụm của p.
- Nếu góc hợp thành có độ lớn hơn 30° sẽ được gộp chung khu vực gom cụm và cập nhật giá trị mới bằng giá trị điểm p ban đầu. Ngược lại sẽ loại khỏi khu vực gom cụm hiện tại.

Việc tính toán này đã hỗ trợ cho hình thái gần giữa các điểm ảnh trong ảnh võng mạc mắt được tăng cường tính liên đới gần hơn so với trước đây. Trở thành tiền đề tốt cho mô hình học chiết xuất đặc trưng.

B. PHÂN LOẠI BỆNH CAO HUYẾT ÁP VỚI GOOGLNET ĐƯỢC CẢI TIẾN



Hình 2. Quá trình cải tiến GoogLeNet.

Sau khi trải qua giai đoạn tiền xử lý với waveform, kết quả đầu ra ở giai đoạn 1 sẽ thành đầu vào cho mô hình GoogLeNet cải tiến ở giai đoạn 2. Kiến trúc của một mô hình GoogLeNet truyền thống bao gồm 3 khối như hình 2, bao gồm:

- Khối 1: 1 tầng Convolutional (stride = 2), 1 tầng MaxPooling (stride = 2) và 1 tầng tích chập tái sử dụng dài hạn (Long-Term Recurrent Convolutional Network – LRCN).

- Khối 2: 1 tầng Convolutional (1 kernel), 1 tầng Convolutional (strike = 1) và 1 tầng LRCN, tầng Inception.
- Khối 3: 1 tầng Average Pool (1 kernel), 1 tầng Fully Connected (FC) và 1 tầng softmax activation.

Kiến trúc của tầng Inception sẽ bao gồm 4 thành phần tính song song nhau:

- Thành phần 1: 1 tầng Convolution (1×1)
- Thành phần 2: 1 tầng Convolution (1×1) và 1 tầng Convolution (3×3)
- Thành phần 3: 1 tầng Convolution (1×1) và 1 tầng Convolution (5×5)
- Thành phần 4: 1 tầng MaxPooling (3×3) và 1 tầng Convolution (1×1)
- Kết nối Filter Concatenation.

Khi cải tiến tầng Inception, phương pháp đề xuất áp dụng cơ chế Bottleneck cho thành phần 1 của tầng này. Cụ thể chi tiết toàn bộ kiến trúc GoogLeNet cải tiến như hình 2. Với Bottleneck, quá trình thực hiện bao gồm:


- 1 tầng batch normalization: giữ kích thước của bản đồ đặc trưng ở tầng trước đó.
- 1 tầng batch normalization: huấn luyện với kích cỡ 64×16 và giữ padding.
- Nối kết bản đồ đặc trưng cho bước filter concatenation liền sau.

Bottleneck được sử dụng nhằm mục đích tăng cường đặc trưng trích xuất sâu trên cùng kích cỡ của bản đồ đầu vào. Quá trình tối ưu sâu này hữu ích với mô hình trên hình ảnh võng mạc mắt. Lý do đến từ độ dày mỏng và độ liên kết gần giữa các điểm ảnh trên loại hình ảnh này. Vốn dĩ bệnh nhân cao huyết áp sẽ gặp khó khăn ở dữ liệu đầu vào so với mô hình học sâu. Việc lựa chọn tái tạo tại tầng Inception còn là tăng cường cho tầng lọc kết hợp ở cuối khối 2 của GoogLeNet.


IV. THÍ NGHIỆM VÀ ĐÁNH GIÁ KẾT QUẢ

A. TẬP DỮ LIỆU

Tập dữ liệu STARE (STructured Analysis of the Retina) [18], được mở rộng gồm 402 ảnh võng mạc mắt có kích thước 605×700 và chuẩn 24 bit trên 1 điểm ảnh màu RGB. Trong đó, có 26 ảnh là của bệnh nhân bị cao huyết áp và số còn lại là không có dấu hiệu bệnh cao huyết áp (có thể rơi vào loại bệnh khác).



(a) Hình ảnh võng mạc mắt của bệnh nhân không bị cao huyết áp



(b) Hình ảnh võng mạc mắt của bệnh nhân bị cao huyết áp

Hình 3. Một số hình ảnh trong tập dữ liệu STARE [18]

Bảng 1. Các tham số để tăng dữ liệu cho tập dữ liệu STARE

| Loại biến đổi | Mô tả |
|---------------------------|---|
| Xoay (rotation) | Xoay ngẫu nhiên giữa $(-10, 10)$ |
| Cắt (clipping) | Cắt ngẫu nhiên trong các góc $(-10, 10)$ |
| Lật (flipping) | Lật ngang (horizontal) và dọc (vertical) |
| Dịch chuyển (translation) | Dịch chuyển ngẫu nhiên trong phạm vi -5% đến 5% số lượng điểm ảnh |

Hình 3 trình bày một số hình ảnh trong tập STARE [18]. Toàn bộ hình ảnh được thực hiện thay đổi kích thước 512×512 , biến đổi xoay và cắt để đa dạng hóa tập dữ liệu mẫu thành 1000 ảnh phục vụ cho thực nghiệm. Các phép biến đổi xoay quanh các tính chất như bảng 1.

B. THỰC NGHIỆM

Quá trình thực nghiệm trên tập STARE [18] được áp dụng theo từng giai đoạn của phương pháp đề xuất. Kết quả được thực thi và so sánh với phương pháp GoogLeNet truyền thống [17], ResNet-50 [4] và AI semantic [3]. Môi

trường thực thi có môi trường tương đồng về tham số và kích cỡ đầu vào. Kết quả thực nghiệm được đánh giá bằng độ chính xác (Accuracy) của kết quả phân lớp bệnh nhân cao huyết áp trên ảnh võng mạc mắt được nêu cụ thể ở bảng 2. Giá trị độ đo chính xác theo công thức dưới đây:

$$ACC = \frac{TP+TN}{TP+FN+TN+FP} \quad (1)$$

Trong đó:

- True Positive (TP): số lượng kết quả phân loại đúng lớp so với dữ liệu mẫu.
- True Negative (TN): số lượng kết quả không thuộc về nhóm đúng (ground-truth), kết quả phân loại là kết quả không thuộc lớp (phân lớp khác so với TP) nhưng trong dữ liệu mẫu lại thuộc.
- False Positive (FP): số lượng kết quả thuộc phân lớp nhưng không đúng với thực tế (ground-truth), kết quả thuộc phân lớp nhưng không đúng trong dữ liệu mẫu.
- False Negative (FN): số lượng kết quả không thuộc phân lớp nhưng không đúng với thực tế (ground-truth), kết quả phân loại không thuộc lớp và không thuộc cả trong dữ liệu mẫu.

Khi đánh giá, ACC càng cao cho thấy phương pháp đang thử nghiệm cho kết quả phân loại càng chính xác.

Bảng 2. Độ chính xác trung bình của phương pháp đề xuất và một số phương pháp khác khi thực nghiệm trên tập STARE

| Phương pháp thực nghiệm | Độ chính xác (tập STARE gốc) | Độ chính xác (tập STARE đã được biến đổi tăng dữ liệu) |
|-----------------------------|------------------------------|--|
| GoogLeNet truyền thống [17] | 91.17% | 90.33% |
| ResNet-50 [4] | 90.08% | 89.92% |
| AI semantic [3] | 89.66% | 88.35% |
| Phương pháp đề xuất | 94.68% | 93.25% |

Để kiểm chứng sự thích hợp giữa waveform và ngưỡng lọc để tạo mịn cho đầu vào GoogLeNet cải tiến, chúng tôi đã tiến hành thực nghiệm với một số ngưỡng phổ biến: Gaussian, Bayesian với Waveform. Hình ảnh được đánh giá bằng giá trị độ chính xác của toàn bộ tập dữ liệu STARE đã được biến đổi tăng dữ liệu tương ứng với từng ngưỡng này. Các giá trị cụ thể được thể hiện ở bảng 3 dưới đây.

Bảng 3. Độ chính xác trung bình giữa các ngưỡng lọc và waveform trên tập STARE

| Phương pháp thực nghiệm | Độ chính xác (tập STARE gốc) | Độ chính xác (tập STARE đã được biến đổi tăng dữ liệu) |
|-------------------------------|------------------------------|--|
| Gaussian + GoogLeNet cải tiến | 92.89% | 92.13% |
| Bayesian + GoogLeNet cải tiến | 90.77% | 89.04% |
| Waveform + GoogLeNet cải tiến | 94.68% | 93.25% |

Dựa trên các kết quả so sánh trên, chúng tôi nhận thấy hình thái học waveform phù hợp với sự cải tiến của GoogLeNet. Từ việc cải thiện tham số đầu vào, quá trình cải tiến tăng Inception bằng Bottleneck đã mang lại kết quả khả thi vì tối ưu được bản đồ đặc trưng cho quá trình phân lớp bệnh cao huyết áp trên ảnh võng mạc mắt. Quá trình chiết xuất đặc trưng sâu đã phù hợp với cơ chế Bottleneck do độ dày và độ liên kết yếu giữa các điểm ảnh võng mạc cần sự kết nối sâu ở tầng tính toán đặc trưng.

V. KẾT LUẬN VÀ HƯỚNG NGHIÊN CỨU MỞ RỘNG

Phân loại bệnh cao huyết áp rất cần thiết cho y học hiện đại. Nghiên cứu này đã đề xuất một phương pháp hỗ trợ phân loại bệnh cao huyết áp dựa trên ảnh võng mạc mắt nhờ vào hình thái học waveform và cải tiến GoogLeNet để trích xuất đặc trưng sâu. Từ đó, bản đồ đặc trưng góp phần xác định đâu là các mạch máu võng mạc của bệnh nhân bị cao huyết áp. Phương pháp đề xuất đã được thực nghiệm trên tập STARE [18] và so sánh với các phương pháp: GoogLeNet truyền thống [17], ResNet-50 [4] và AI semantic [3]. Kết quả đã cho thấy tính khả thi của sự kết hợp hình thái học waveform và mô hình học sâu GoogLeNet trong bài toán phân lớp này. Tuy nhiên, trong tương lai cần tiến hành đa dạng hóa yếu tố hình thái học cho bản đồ đặc trưng sâu và thử nghiệm trên nhiều tập dữ liệu khác để mô hình được học chuẩn xác hơn. Bên cạnh đó, nghiên cứu cải thiện số tầng cho mô hình học sâu dựa trên trạng thái và hình thái cũng là vấn đề cần được lưu tâm nhằm giảm thiểu thời gian huấn luyện mà vẫn tận dụng tốt các tham số dữ liệu đầu vào.

VI. LỜI CẢM ƠN

Nghiên cứu được tài trợ bởi Trường Đại học Ngoại ngữ-Tin học Thành phố Hồ Chí Minh trong khuôn khổ Đề tài mã số H2023-07.

VII. TÀI LIỆU THAM KHẢO

- [1] Kevin Noronha, Navya K.T, K Prabhakar Nayak (2012), Support system for the automated detection of hypertensive retinopathy using fundus images, *Proceedings of ICEDSP'12*, MIT, Manipal, pp. 1 – 5.
- [2] S. Irshad and M. U. Akram (2014), Classification of retinal vessels into arteries and veins for detection of hypertensive retinopathy, *2014 Cairo International Biomedical Engineering Conference (CIBEC)*, Giza, Egypt, pp. 133-136.
- [3] Arsalan M, Owais M, Mahmood T, Cho SW, Park KR (2019), Aiding the Diagnosis of Diabetic and Hypertensive Retinopathy Using Artificial Intelligence-Based Semantic Segmentation, *Journal of Clinical Medicine*, Vol. 8, No. 9, Issue. 1446.
- [4] Viraj Jiwane, Anubhav DattaGupta, Arunkumar Chauhan and Vidya Patil (2021), Detecting diabetic retinopathy using deep learning technique with Resnet-50, *ICDSMLA 2020, Lecture notes in Electrical Engineering*, Springer, Vol. 783, pp. 45 – 55.
- [5] Abbas Q, Qureshi I, Ibrahim MEA (2021), An automatic detection and classification system of five stages for hypertensive retinopathy using semantic and instance segmentation in densenet architecture, *Sensors*, vol. 21, no. 20, issue. 6936.
- [6] Muhammad Arsalan, Adnan Haider, Young Won Lee, Kang Ryoung Park (2022), Detecting retinal vasculature as a key biomarker for deep Learning-based intelligent screening and analysis of diabetic and hypertensive retinopathy, *Expert Systems with Applications*, Vol. 200, Issue. 117009.
- [7] Nagpal D, Alsubaie N, Soufiene BO, Alqahtani MS, Abbas M, Almohiy HM (2023), Automatic Detection of Diabetic Hypertensive Retinopathy in Fundus Images Using Transfer Learning, *Applied Sciences*, Vol. 13, No. 8, Issue. 4695.
- [8] Nucci CG, De Bonis P, Mangiola A, Santini P, Sciandrone M, Risi A, Anile C. (2016), Intracranial pressure wave morphological classification: automated analysis and clinical validation, *Acta Neurochir (Wien)*, Vol. 158, No. 3, Issue. 581-8, discussion 588.
- [9] Li, H., An, Z., Zuo, S. et al (2022), Classification of electrocardiogram signals with waveform morphological analysis and support vector machines, *Medical & Biological Engineering & Computing*, Vol. 60, pp. 109–119.
- [10] Zhang N, Zhao X, Li J, Huang L, Li H, Feng H, Garcia MA, Cao Y, Sun Z, Chai S. (2023), Machine Learning Based on Computed Tomography Pulmonary Angiography in Evaluating Pulmonary Artery Pressure in Patients with Pulmonary Hypertension, *Journal of Clinical Medicine*, Vol. 12, No. 4, Issue. 1297.
- [11] H. Yang and Z. Wei (2020), Arrhythmia Recognition and Classification Using Combined Parametric and Visual Pattern Features of ECG Morphology, in *IEEE Access*, Vol. 8, pp. 47103-47117.
- [12] Jacobs JP. (2022), Hypoplastic Left Ventricle: Definition, Morphology, and Classification of the Cardiac Phenotypes, *World Journal for Pediatric and Congenital Heart Surgery*, Vol. 13, No. 5, pp. 615-619.
- [13] Jillian Goetz et al (2022), Unified classification of mouse retinal ganglion cells using function, morphology and gene expression, *Cell reports, Open Access*, Vol. 40, No. 2, Issue. 111040.
- [14] Zhang L, Yuan M, An Z, Zhao X, Wu H, Li H, et al. (2020), Prediction of hypertension, hyperglycemia and dyslipidemia from retinal fundus photographs via deep learning: A cross-sectional study of chronic diseases in central China, *PLoS ONE*, Vol. 15, No. 5, Issue. e0233166.
- [15] Panagiotis I Georgianos, Rajiv Agarwal (2021), Hypertension in Chronic Kidney Disease (CKD): Diagnosis, Classification, and Therapeutic Targets, *American Journal of Hypertension*, Vol. 34, No. 4, pp. 318–326.
- [16] D. Nagpal, S. N. Panda and M. Malarvel (2021), Hypertensive Retinopathy Screening through Fundus Images-A Review, *2021 6th International Conference on Inventive Computation Technologies (ICICT)*, Coimbatore, India, pp. 924-929.
- [17] A. Sekhar, S. Biswas, R. Hazra, A. K. Sunaniya, A. Mukherjee and L. Yang (2022), Brain Tumor Classification Using Fine-Tuned GoogLeNet Features and Machine Learning Algorithms: IoMT Enabled CAD System, in *IEEE Journal of Biomedical and Health Informatics*, Vol. 26, No. 3, pp. 983-991.
- [18] Michael Goldbaum, M.D. (2004), The STARE Project, Structured analysis of the Retina, <https://cecas.clemson.edu/~ahoover/stare/diagnoses/all-mg-codes.txt>, Accessed date June, 18, 2024.

IMPROVING GOOGLNET FOR HYPERTENSION CLASSIFICATION BASED ON RETINAL VESSEL IMAGES

Vo Thi Hong Tuyen, Nguyen Thanh Binh

ABSTRACT— Retinal vessel images contain a wide range of information that is a manifestation of the disease. Features of these images extracted from learning models need to be improved and optimized to help the disease classification process be more accurate. The higher the classification ability, the easier the diagnosis and treatment of the disease. The challenge is to extract deep features based on retinal images with initial parameters consistent with the corresponding morphology. In this paper, we propose an improvement process of GoogLeNet based on the waveform morphology mechanism to classify hypertension on retinal images. The proposed method includes two stages: preprocessing input parameters for the learning model with waveform morphology, GoogLeNet feature extraction with improvements in the number of Inception layers supporting deep feature extraction. The results were tested on the STARE dataset with an accuracy of 93.25 %. The classification results are compared with some recent methods and show more positive results.

Keyword— GoogLeNet, waveform morphology, hypertension classification, retinal vessel image.



ThS. Võ Thị Hồng Tuyết

(<https://orcid.org/0000-0002-9153-2883>) tốt nghiệp Cử nhân ngành Sư phạm Tin học tại Trường Đại học Sư phạm TP.HCM vào năm 2011 và Thạc sĩ Kỹ thuật chuyên ngành Khoa học máy tính tại Trường Đại học Bách Khoa –

ĐH Quốc Gia TP.HCM vào năm 2015. Từ 2019 đến nay, cô là nghiên cứu sinh ngành Khoa học máy tính tại Khoa Khoa học và Kỹ thuật máy tính của Trường Đại học Bách Khoa – ĐH Quốc Gia TP.HCM. Hiện nay, cô là giảng viên bộ môn Khoa học máy tính, Khoa Công nghệ thông tin Trường Đại học Ngoại Ngữ-Tin học TP.HCM. Lĩnh vực nghiên cứu chính: thị giác máy tính, xử lý ảnh và nhận dạng.



PGS.TS Nguyễn Thanh Bình

(<https://orcid.org/0000-0003-0136-874X>) nhận bằng Kỹ Sư tại Trường Đại học Bách khoa-ĐH Quốc gia TP.HCM năm 2000, và nhận bằng Thạc sĩ và Tiến sĩ ngành Khoa học máy tính từ Đại học Allahabad-Ấn Độ vào năm 2005 và 2011. Hiện nay,

anh là Phó Giáo sư ngành Công nghệ thông tin tại Trường Đại học Ngoại ngữ-Tin Học TP.HCM. Lĩnh vực nghiên cứu: nhận dạng, xử lý ảnh, hệ thống thông tin đa phương tiện, hệ thống hỗ trợ quyết định và dữ liệu chuỗi thời gian.