

PHÁT HIỆN NGỦ GẬT KHI LÁI XE Ô TÔ DỰA TRÊN KỸ THUẬT HỌC SÂU

DRIVER DROWSINESS DETECTION USING DEEP LEARNING

NGUYỄN NGỌC HOÀNG QUYÊN^{1a}, LÊ HOÀNG AN¹

¹ Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

+ Tác giả liên hệ: ^aEmail: quyennnh@vlute.edu.vn

Nhận bài (Received): 21/03/2023; Phản biện (Reviewed): 28/03/2023; Chấp nhận (Accepted): 02/04/2023

TÓM TẮT

Ngủ gật khi lái xe là một trong những nguyên nhân gây ra tai nạn giao thông phổ biến trên thế giới, kết quả về thiệt hại, thương tật và tính mạng có thể là vĩnh viễn. Trong bài báo này, chúng tôi đề xuất phương pháp phát hiện ngủ gật sử dụng mạng học sâu được phát triển dựa trên mạng InceptionV3 và DenseNet. Chúng tôi tận dụng những ưu điểm của mạng học sâu và tiếp cận học chuyển tiếp để huấn luyện (training) các mạng đề xuất trên tập dữ liệu của chúng tôi. Việc này không những giải quyết vấn đề của hạn chế bộ dữ liệu mà còn đưa ra được kết quả so sánh về thời gian cũng như độ chính xác của các mạng nơ-ron. Kết quả thực nghiệm của phương pháp đề xuất có thể đạt được độ chính xác lên đến 98%.

Từ khóa: Drowsiness detection, DenseNet, Inception-V3, Deep learning

ABSTRACT

Drowsiness while driving is one of the most common causes of traffic accidents around the world, and the consequences caused by such damage, injury and death can be permanent. In this paper, we propose a doze detection method using deep learning network developed based on InceptionV3 and DenseNet networks. We take advantage of deep learning network and forward learning approach to train recommender networks on our dataset. This not only solves the problem of data set limitations, but also gives the comparison results in terms of time as well as the accuracy of neural networks. Experimental results of the proposed method can achieve the accuracy up to 98%.

Keywords: Drowsiness detection, DenseNet, Inception-V3, Deep learning

1. MỞ ĐẦU

1.1. Giới thiệu bài toán

Theo số liệu thống kê của National Highway Traffic Safety Administration (NHTSA) cho biết, số tai nạn giao thông do việc ngủ gật khi lái xe mỗi năm lên đến 100.000 vụ tai nạn do cảnh sát báo cáo và hơn 1.500 người chết với chi phí cho các

vụ tai nạn do lái xe buồn ngủ chiếm khoảng 13% trong tổng số 836 tỷ đô la chi phí xã hội của các vụ va chạm giao thông. Trong năm 2017, 50.000 người đã bị thương trong các vụ tai nạn khi lái xe buồn ngủ và 795 người trong số đó đã thiệt mạng vì lái xe buồn ngủ. Từ năm 2009 đến năm 2013, cảnh sát đã báo cáo 72.000 vụ tai nạn xe cơ giới liên quan đến những người lái xe ngủ gật [4].

Bên cạnh đó theo AAA - Foundation for Traffic Safety cũng cho biết, có hơn 40% tài xế thừa nhận họ đã ngủ gật sau tay lái [3] và có 800 trường hợp tử vong đã xảy ra vào năm 2015 do những người lái xe cảm thấy mệt mỏi sau tay lái [6]. Trong năm 2015, ước tính có khoảng 33.000 vụ tai nạn xe hơi dẫn đến thương tích bao gồm cả những người lái xe buồn ngủ. Con số này chiếm 1,9% tổng số vụ tai nạn thương tích, ước tính có khoảng 90.000 vụ tai nạn (chỉ tính riêng thiệt hại về tài sản, gây tử vong và tài sản) liên quan đến việc lái xe buồn ngủ (1,4% tổng số vụ tai nạn ô tô) [7]. Những số liệu thống kê đáng báo động trên đã chỉ ra sự cần thiết để thực hiện một hệ thống có khả năng theo dõi và cảnh báo tình trạng mệt mỏi, ngủ gật của người lái xe để có thể ngăn chặn những vụ tai nạn giao thông đáng tiếc có thể xảy ra.

1.2. Những nghiên cứu liên quan

HuHe et al. [8] đề xuất sử dụng phương pháp phát hiện ngủ gật bằng cách sử dụng mạng nơ-ron CNN bao gồm hai giai đoạn; giai đoạn thứ nhất tiên hành trích xuất đặc trưng và giai đoạn hai sẽ tiến hành phân loại để nhận dạng trạng thái mắt và miệng. Zuopeng et al [9] đã đề xuất sử dụng phương pháp phát hiện ngủ gật bằng cách sử dụng EM-CNN để phát hiện trạng thái của mắt và miệng dựa trên hình ảnh được trích xuất đặc trưng. Phanikrishna et al [10] đã đề xuất sử dụng phương pháp phát hiện ngủ gật khi lái xe bằng cách sử dụng wavelet packet transform. Wavelet packet transform được trích xuất từ các tín hiệu Điện não đồ (EEG) đơn kênh. Nghiên cứu này mang lại độ chính xác 94,45% khi thực nghiệm. H. Varun Chand and J. Karthikeyan [11], nghiên cứu này đề xuất sử dụng mô hình phân phối đa cấp mới để phát hiện ngủ gật khi lái xe bằng cách sử dụng Mạng thần kinh Convolution (CNN),

sau đó là phân tích cảm xúc. Kết quả hệ thống đạt được mức độ chính xác lên đến 93% dựa trên phân tích thực nghiệm.

1.3. Tổng quan về trạng thái ngủ gật

Giấc ngủ [1] là tình trạng nghỉ ngơi tự nhiên theo chu kỳ của thể xác và tinh thần. Trong tình trạng này người ta thường nhắm mắt và mất ý thức một phần hay hoàn toàn do đó sẽ giảm các vận động và phản ứng đối với các kích thích bên ngoài. Có một thuật ngữ gọi là “Microsleep” [1], nghĩa là một giai đoạn ngủ ngắn và ngoài ý muốn của giấc ngủ, có thể xảy ra bất cứ lúc nào do mệt mỏi hay một sự nỗ lực của ý thức kéo dài nào đó. Microsleep có thể kéo dài trong một vài giây và lúc này não rơi vào trạng thái ngủ nhanh chóng, không kiểm soát được, tình trạng này có thể vô cùng nguy hiểm, đặc biệt là nếu bạn đang lái xe hay trong các tình huống yêu cầu sự chú ý tập trung. Một số dấu hiệu cho thấy bạn đang không tỉnh táo khi lái xe như: ngáp và chớp mắt thường xuyên, khó mở mắt, không thể tập trung, đầu không thể giữ thẳng, lái xe ra khỏi làn đường [1]

1.4. Vai trò của học sâu trong phát hiện và dự đoán

Hiện nay, kỹ thuật học sâu đã và đang được ứng dụng hầu hết trong mọi lĩnh vực với những ưu điểm nổi bật như mang lại độ chính xác cao, có thể được áp dụng với các loại bộ dữ liệu khác nhau, hỗ trợ vấn đề khi dữ liệu không đủ lớn, có khả năng mở rộng về dữ liệu và tính toán. Tận dụng những ưu điểm đó, chúng tôi quyết định áp dụng mạng nơ-ron sâu với Inception-V3 và DenseNet để phát hiện trạng thái ngủ gật khi lái xe.

2. KẾT QUẢ NGHIÊN CỨU

2.1. Mạng nơ-ron trích xuất đặc trưng

2.1.1 InceptionV3

Inception-V3 [2] là kế thừa của Inception-V1 bao gồm 24 triệu tham số. Inception-V3 giải quyết được vấn đề thắt cổ chai (representational bottlenecks). Tức là kích thước của các layers không bị giảm một cách đột ngột. Đồng thời Inception-V3 có một cách tính toán hiệu quả hơn nhờ sử dụng phương pháp nhân tố (factorisation methods). Inception-V3 giúp đẩy nhanh quá trình tính toán; nó sở hữu kiến trúc mạng sâu hơn; ngoài ra, mô hình này đòi hỏi ít thông số hơn và thời gian huấn luyện (training) ngắn hơn.

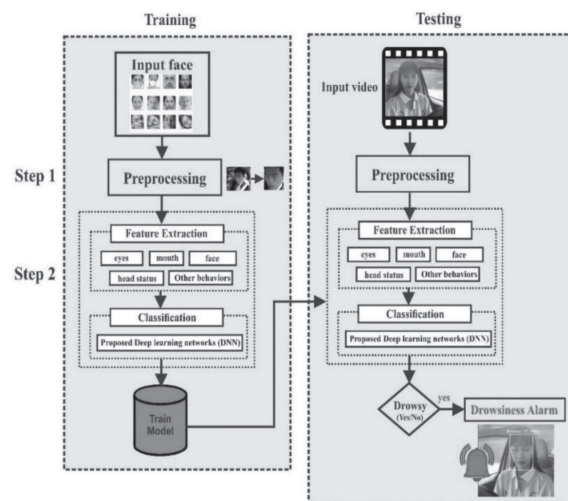
2.2.2 DenseNet

DenseNet [5] sẽ khác so với ResNet, các đầu ra của từng phép ánh xạ có cùng kích thước dài và rộng sẽ được concatenate với nhau thành một khối theo chiều sâu. Sau đó để giảm chiều dữ liệu chúng ta áp dụng tầng chuyển tiếp (transition layer). Tầng này là kết hợp của một layer tích chập giúp giảm độ sâu và một max pooling giúp giảm kích thước dài và rộng. Về độ chính xác, DenseNet training ít hơn một nửa tham số nhưng có độ chính xác cao hơn so với ResNet50 trên bộ dữ liệu ImageNet. Bên cạnh đó, việc xử lý overfitting trên DenseNet rất hiệu quả; DenseNet đồng thời cũng áp dụng BatchNormalization trước khi thực hiện tích chập ở các tầng chuyển tiếp nên giảm được vanishing gradient. Mô tả tầng của kiến trúc mạng

2.2. Phương pháp đề xuất

Trong phần này, khuôn mặt sẽ được phát hiện bằng việc sử dụng SSD và ResNet-10, sau đó được chuyển đến các mạng để phát hiện trạng thái ngủ gật.

Chúng tôi phát triển các mô hình mạng dựa trên mô hình của InceptionV3, DenseNet bằng cách thực hiện các cải tiến trong một số lớp để thích ứng cho việc phát hiện ngủ gật. Trong phương pháp này, việc phát hiện ngủ gật sử dụng mạng nơ-ron sâu (DNN) bao gồm hai giai đoạn là training và testing. Trong giai đoạn thứ nhất, chúng tôi huấn luyện (training) các mô hình bằng cách huấn luyện (training) dựa trên tập dữ liệu đã được xử lý trước đó. Trong giai đoạn thứ hai, chúng tôi đánh giá các mô hình mạng với tập dữ liệu testing để phát hiện ngủ gật:



Hình 1. Các giai đoạn trong quá trình xây dựng hệ thống.

2.2.1. Pha huấn luyện

a. Tiền xử lý

Trong bước tiền xử lý, chúng tôi tiến hành trích xuất frames từ các video có liên quan đến trạng thái ngủ gật khi lái xe, sau đó chúng tôi thực hiện việc phát hiện khuôn mặt từ tập dữ liệu hình ảnh bằng cách sử dụng mạng SSD (Single Shot MultiBox Detector) với ResNet-10 và chuẩn hóa chúng thành kích thước 224x224 để tạo tập dữ liệu huấn luyện (training).

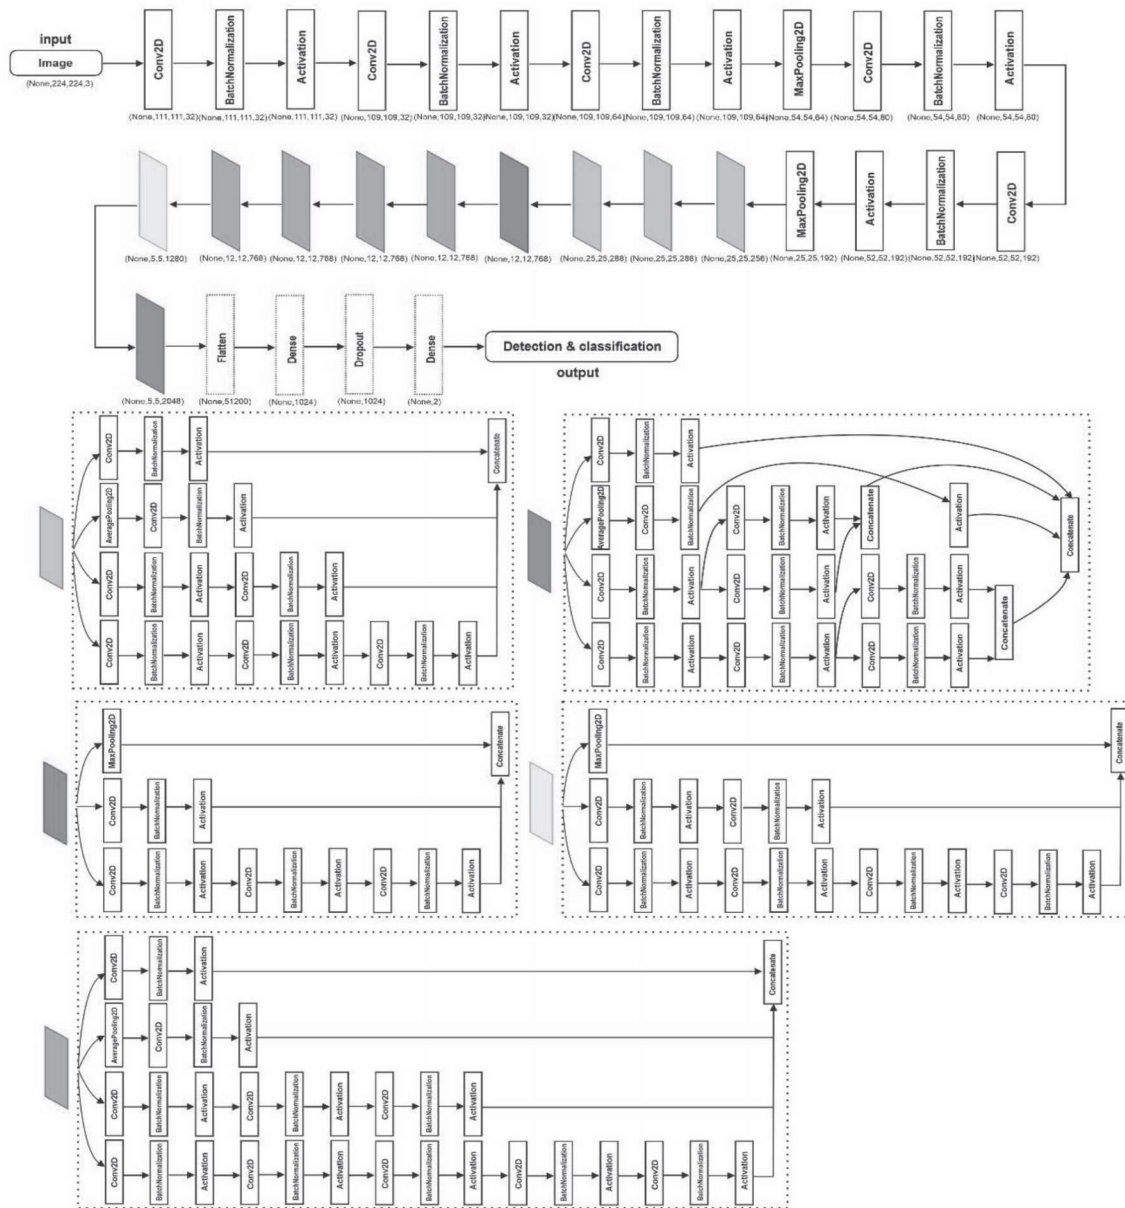
b. Trích xuất đặc trưng và huấn luyện (training)

Để trích xuất các đặc trưng và huấn

luyện, tập dữ liệu huấn luyện (training) sẽ được chuyển qua mạng nơ-ron học sâu (DNN); đồng thời, dựa vào những ưu điểm của mạng nơ-ron được đề cập trong Phần 2.1, chúng tôi phát triển các mạng nơ-ron để phát hiện ngủ gật dựa trên InceptionV3 và DenseNet bằng cách cải tiến một số lớp của chúng để điều chỉnh khả năng phát hiện buồn ngủ.

Mô hình 1: Với những ưu điểm nổi bật được đề cập ở phần 2.1, chúng tôi quyết


định xây dựng mạng nơ-ron cho việc phát hiện ngủ gật dựa trên việc phát triển mạng InceptionV3 đã được huấn luyện (training) trước đó. Chúng tôi áp dụng việc học chuyển giao từ mô hình InceptionV3 đã được dựng trước đó và thêm vào một số lớp cho mô hình mạng đề xuất như Flatten, Relu (Dense), Dropout, Sigmoid (Dense); các lớp thêm vào được biểu diễn qua các đường nét đứt màu đỏ và mô hình đề xuất được thể hiện trong hình 2.



Hình 2. Mô hình 1: Kiến trúc mạng đề xuất được phát triển từ InceptionV3

Mô hình 2: Với những ưu điểm nổi bật như việc training ít hơn một nửa tham số nhưng vẫn mang lại độ chính xác cao; việc xử lý overfitting hiệu quả (được đề cập trong phần 2.1), chúng tôi chọn mạng DenseNet để phát triển cũng như xây dựng mạng nơ-ron cho dự đoán trạng thái ngủ gật

bằng việc áp dụng việc học chuyển giao từ mô hình DenseNet đã được xây dựng trước đó và thêm vào một số lớp cho mạng đề xuất bao gồm Flatten, Relu (Dense), Dropout, Sigmoid (Dense); các lớp thêm vào được biểu diễn qua các đường nét đứt màu đỏ và mô hình đề xuất được thể hiện trong hình 3.



Hình 3. Mô hình 2: Kiến trúc mạng đề xuất được phát triển từ DenseNet

2.2.2. Kết quả huấn luyện (training) và thực nghiệm

Để tiến hành thực nghiệm cho mô hình đề xuất, chúng tôi thực hiện hai kịch bản với các tham số huấn luyện như sau:

a. Các kịch bản áp dụng

Bảng 1. Các kịch bản được đề xuất và các tham số huấn luyện

Scenario	Technique of Feature Extraction and Prediction	Batch size	Epoch	Learning rate
1	Adaptive deep neural network developed from InceptionV3	250	30	1e-4
2	Adaptive deep neural network developed from DenseNet	250	30	1e-4

b. Môi trường cài đặt và mô tả tập dữ liệu

1. Môi trường cài đặt

Để so sánh và đánh giá, chúng tôi thực hiện phương pháp đề xuất trên các mô hình InceptionV3 và DenseNet trong cùng một môi trường Visual Studio Code với Windows 10, cấu hình RAM 8GB và dùng GPU Nvidia Geforce. Thư viện hỗ trợ huấn

luyện (training) mô hình mạng sử dụng là Tensorflow phiên bản 2.2.

2. Mô tả tập dữ liệu

Tập dữ liệu được chúng tôi tự xây dựng bao gồm 3425 hình ảnh về trạng thái buồn ngủ, 4388 hình ảnh về trạng thái không buồn ngủ được trích xuất và thu thập từ dữ liệu của Bing Search API, Kaggle, RMFD

và iStock, sau đó được chia theo tỷ lệ 80% (tức là 6250) hình ảnh được sử dụng cho huấn luyện (training) và 20% (tức là 1563) hình ảnh cho thử nghiệm. Việc sử dụng tập dữ liệu hình ảnh làm dữ liệu đầu vào của mô hình sẽ giúp cho thời gian huấn luyện

(training) thực hiện nhanh hơn ở những môi trường cài đặt hạn chế so với tập dữ liệu video mà vẫn đảm bảo có đầy đủ ngữ cảnh mà video mang lại. Chi tiết tập dữ liệu được mô tả trong bảng 2.

Bảng 2. Mô tả tập dữ liệu

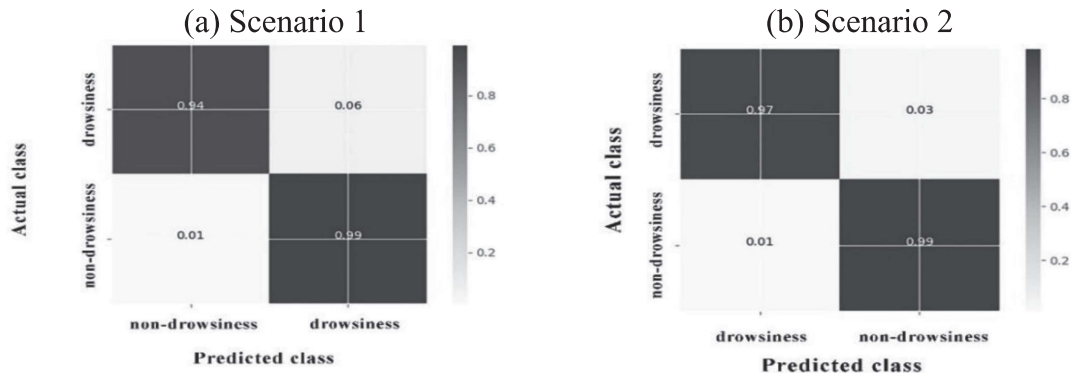
Status	Number	Num face	Type	Size
Drowsiness	3425	3425	Image	230 MB
Non-drowsiness	4388	4388	Image	66.1 MB
Both	33	13729	Video	1760 MB

c. Các kết quả thu được

1. Metrics of Precision

Chúng tôi xác định các giá trị precision, recall và accuracy được xác định bởi confusion matrix [12]. Hình 4 cho thấy confusion matrix cho các kịch bản. Trong kịch bản 1, giá trị TP (true positive) và TN (true negative) của việc dự đoán trạng thái

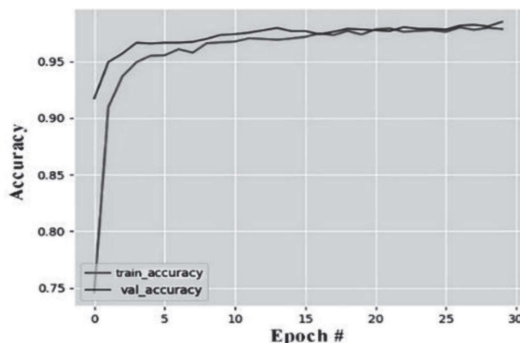
buồn ngủ và không buồn ngủ lần lượt là 94% và 99%. Trong kịch bản 2, giá trị TP (true positive) và TN (true negative) của việc dự đoán trạng thái buồn ngủ và không buồn ngủ lần lượt là 97% và 99%. Độ chính xác của các mạng sau quá trình huấn luyện (training) ở cả 2 kịch bản lần lượt là 97% và 98% trên tập dữ liệu đề xuất.



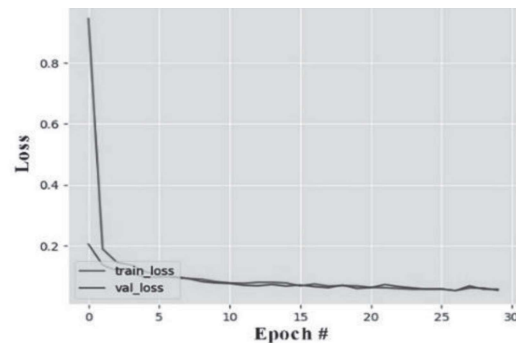
Hình 4. Confusion matrix của các kịch bản

2. Độ đo Loss và Accuracy

(a) Scenario 1: Accuracy




(b) Scenario 2: Loss_value



Hình 5. Biểu đồ độ đo Accuracy and Loss trong quá trình huấn luyện (training) của kịch bản 1

Đối với kịch bản 1, Hình 5 cho thấy kết quả Loss và Accuracy của kịch bản 1 sau 30 bước huấn luyện (training) (epochs) với learning_rate là $1e-4$. Quan sát hình 5a) ta thấy rằng, giá trị train_accuracy lúc này là 96% và giá trị val_accuracy ở mức 97%, ta cũng xác định được accuracy trung bình

trong kịch bản này là 96.5%. Vì vậy, kịch bản 1 có xu hướng học hiệu quả. Quan sát hình 5b) biểu diễn giá trị train_Loss và val_Loss của quá trình huấn luyện (training). Giá trị train_Loss và val_Loss ở kịch bản 1 đều ở mức xấp xỉ 0.06.




Hình 6. Biểu đồ độ đo Accuracy and Loss trong quá trình huấn luyện (training) của kịch bản 2

Đối với kịch bản 2, Hình 6 cho thấy kết quả Loss và Accuracy của kịch bản 2 sau 30 bước huấn luyện (training) (epochs) với learning_rate là $1e-4$. Hình 6a) biểu diễn giá trị train_accuracy lúc này là 97% và giá trị val_accuracy ở mức 98%, ta có giá trị accuracy trung bình là 97.5%, cao hơn so với kịch bản 1,2 và 3, điều này cho thấy mô hình đang có xu hướng học và hoạt động hiệu quả. Hình 6b) biểu diễn giá trị train_Loss và val_Loss của quá trình huấn luyện (training). Từ số bước huấn luyện 20 trở đi, train_Loss và val_Loss có giá trị lần lượt là 0.1 và 0.06.

43 phút, điều này là hiển nhiên trong lĩnh vực học sâu, khi một mô hình mang lại độ chính xác tốt hơn thì phải trả giá cho thời gian huấn luyện (training) lâu hơn.

2. Thời gian huấn luyện (training)

Hình 7 biểu diễn thời gian huấn luyện (training) của các kịch bản. Thời gian huấn luyện (training) cho kịch bản 1 là 3 tiếng 50 phút và kịch bản 2 là 4 tiếng 33 phút. Có thể thấy rằng kịch bản 2 cho kết quả huấn luyện (training) lâu hơn kịch bản 1 là



Hình 7. Biểu đồ biểu diễn thời gian huấn luyện (training) của các kịch bản



3. Kết quả kiểm thử

Các độ đo về độ chính xác và thời gian

Việc thực nghiệm để kiểm tra được thực hiện trên tổng số 33 người khác nhau từ các video bao gồm trạng thái ngủ gật và không ngủ gật. Hình 8 cho thấy kết quả của độ chính xác trung bình và thời gian dự đoán trung bình khi phát hiện người lái xe rơi

vào trạng thái ngủ gật. Độ chính xác trung bình của kịch bản 1 là 97.5% và kịch bản 2 là 97.8%. Có thể thấy, kịch bản 2 vượt trội hơn kịch bản 1 về độ chính xác. Bên cạnh đó, thời gian dự đoán trung bình của các kịch bản lần lượt là 5.7 phút cho kịch bản 1 và kịch bản 2 là 5.9 phút; điều này cho

thấy, kịch bản 1 cho kết quả dự đoán nhanh hơn tuy nhiên việc dự đoán quá nhanh sẽ dễ đưa ra kết quả nhầm lẫn giữa việc chớp mắt và việc mắt rơi vào trạng thái ngủ gật; ngược lại việc kết hợp tất cả các dấu hiệu để đưa ra kết quả dự đoán chính xác sẽ cần nhiều thời gian hơn.



a) Độ chính xác trung bình khi phát hiện ngủ gật b) Thời gian dự đoán trung bình khi phát hiện ngủ gật

Hình 8. Biểu đồ biểu diễn độ chính xác và thời gian dự đoán trung bình qua các kịch bản

Một số kết quả kiểm thử

Bảng 3 cho thấy các kết quả thử nghiệm của các kịch bản. Trường hợp A, quan sát 2 kịch bản ta thấy được cả 2 kịch bản đều cho kết quả đúng nhưng kịch bản 1 cho kết quả dự đoán thấp hơn so với các kịch bản 2. Trường hợp B, lúc này người lái đã rơi vào trạng thái ngủ gật, việc dự đoán của 2 kịch bản đều đúng, đặc biệt kịch bản 2 cho kết quả dự đoán lên đến 98.90%. Trường hợp C, người lái xe lúc này đang đeo kính, khẩu

trang và ở trường hợp không buồn ngủ thì cả 2 kịch bản đều cho kết quả đúng, tuy nhiên kịch bản 2 chỉ có 91.55% trong khi kịch bản 2 có độ chính xác 99.76%. Trường hợp D, khi người lái xe rơi vào trạng thái ngủ gật (kết hợp đeo kính và khẩu trang) thì kịch bản 2 có kết quả dự đoán cao nhất với 97.16%. Quan sát kết quả ở bảng 2 cho thấy, kịch bản 2 cho kết quả tối ưu hơn so với kịch bản còn lại.

Bảng 3. Ảnh kết quả của từng kịch bản

Kịch bản	A	B	C	D
1				
2				

4. So sánh và thảo luận

Bảng 4. So sánh độ chính xác của các phương pháp phát hiện ngủ gật

Tác giả	Phương pháp	Độ chính xác
HuHe et al. [8]	A Real-time Driver Fatigue Detection Method Based on Two-Stage Convolutional Neural Network	93.83%
Zuopeng et al. [9]	Driver Fatigue Detection Based on Convolutional Neural Networks Using EM-CNN	93.623%
H. Varun Chand, J. Karthikeyan [10]	CNN Based Driver Drowsiness Detection System Using Emotion Analysis	93%
The proposed method with scenario 1	Deep learning network developed from Inception V3.	97%
The proposed method with scenario 2	Deep learning network developed from DenseNet	98%

Ở đây, chúng tôi đề xuất hệ thống phát hiện ngủ gật khi lái xe bằng cách sử dụng kỹ thuật Deep Learning. Qua kết quả huấn luyện (training) và thực nghiệm (bảng 3), kết quả huấn luyện (training) ở các kịch bản 1 và 2 có độ chính xác huấn luyện lần lượt là 97% và 98% trên tập dữ liệu đề xuất của chúng tôi. Thêm vào đó, các mô hình mạng đề xuất cũng là những bộ trích xuất đặc trưng rất tốt, vì chúng có thể nắm bắt các đặc điểm liên quan của trạng thái ngủ gật từ người lái thông qua hình ảnh hoặc video. Thay vì tập trung vào vùng mắt và vùng miệng như các công trình trước đây [8], [9], [10] thì các mạng thần kinh học sâu được đề xuất phân tích tất cả hoạt động của người lái xe để tìm hiểu các đặc điểm của việc ngủ gật như đầu không thể giữ thẳng, ngáp, chớp mắt liên tục để dự đoán buồn ngủ. Ngoài ra, chúng tôi tận dụng những ưu điểm của việc học chuyển giao điều này giúp giải quyết vấn đề về tập dữ liệu học nhỏ, thời gian huấn luyện (training) nhanh và giữ lợi thế của mạng học sâu. Phương pháp đề xuất của chúng tôi đều có thể phát hiện và đem lại kết quả chính xác tình trạng ngủ gật của người lái xe trong trường hợp

đeo khẩu trang, đeo khẩu trang kết hợp đeo kính (bảng 3), trong khi một số phương pháp chưa cung cấp độ chính xác trong trường hợp này. Bên cạnh đó, phương pháp đề xuất của chúng tôi có thể cung cấp một số ưu điểm cũng như độ chính xác trong việc lựa chọn mô hình có thể đáp ứng việc triển khai thực tế hệ thống phát hiện ngủ gật trong tương lai.

3. KẾT LUẬN

Trong bài báo này, chúng tôi đề xuất phương pháp với bốn kịch bản cho hệ thống phát hiện ngủ gật khi lái xe sử dụng các kỹ thuật Deep Learning, chúng tôi thiết kế hai mạng nơ-ron sâu thích ứng được phát triển dựa trên mạng InceptionV3 và DenseNet lần lượt cho các kịch bản 1 và 2. Phương pháp này sẽ tiến hành phân tích các dấu hiệu ngủ gật của người lái xe và tìm hiểu tất cả các đặc điểm của trạng thái ngủ gật. Bên cạnh đó, phương pháp đề xuất của chúng tôi còn cung cấp độ chính xác trong trường hợp đeo khẩu trang kết hợp đeo kính, trong khi đó những nghiên cứu trước đó chưa cung cấp và độ chính xác mang lại sau khi huấn luyện (training) lên

đến là 98%. Kết quả thực nghiệm cho thấy phương pháp này có tính khả thi và thích ứng với sự phát triển của các ứng dụng cho hệ thống cảnh báo ngủ gật. Nghiên cứu này giúp chúng ta có thể ngăn ngừa tai nạn ô tô đáng tiếc do ngủ gật gây ra.

TÀI LIỆU THAM KHẢO

- [1] Kingman, P.S.; Jesse, B.; Forrest, C.; Kate, G.; James, K.; Roger, K.; Anne, T.M.; Sharon, L.M.; Allan, I.P.; Susan, R (1999). Drowsy driving and automobile crashes. In Ncsdr/nhtsa Expert Panel on Driver Fatigue and Sleepiness; National Highway Traffic Safety Administration: Rockville, MD, USA.
- [2] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, Zbigniew Wojna (2015). Rethinking the Inception Architecture for Computer Vision. IEEE
- [3] American Automobile Association Foundation for Traffic Safety (2010). Asleep at the wheel: the prevalence and impact of drowsy driving.
- [4] National Highway Traffic Safety Administration (2017). Traffic Safety Facts.
- [5] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger (2018). Densely Connected Convolutional Networks. IEEE.
- [6] National Highway Traffic Safety Administration. (2021). Drowsy Driving.
- [7] National Sleep Foundation. Drowsy Driving. 2021.
- [8] HuHe, XiaoyongZhang, FuJiang, ChenglongWang, YingzeYang, WeirongLiu, JunPeng (2020). A Real-time Driver Fatigue Detection Method Based on Two-Stage Convolutional Neural Network. IFAC-PapersOnLine Volume 53, Issue 2, 2020.
- [9] Zhao, Z.; Zhou, N.; Zhang, L.; Yan, H.; Xu, Y.; Zhang, Z (2020). Driver Fatigue Detection Based on Convolutional Neural Networks Using EM-CNN. Hindawi.
- [10] V. Phanikrishna and S. Chinara (2021). "Automatic classification methods for detecting drowsiness using wavelet packet transform extracted time-domain features from single-channel EEG signal," Journal of Neuroscience Methods, vol. 347, no. 3, pp. 108927.
- [11] H. Varun Chand and J. Karthikeyan (2021). CNN Based Driver Drowsiness Detection System Using Emotion Analysis. Springer.
- [12] Feras A (2020). Batarseh and Ruixin Yang. Data Democracy.
- [13] Thái Thị Hoà Vân (2017). Nghiên cứu tình trạng buồn ngủ của người lái xe dựa trên nhận dạng cử chỉ khuôn mặt. Đại học Đà Nẵng.
- [14] Nguyễn Duy Linh, Trần Công Trung (2019). Tìm hiểu một số hệ thống cảnh báo lái xe ngủ gật và đề xuất phương pháp xây dựng ứng dụng với thư viện mã nguồn mở OpenCv. Tạp chí thông tin khoa học và công nghệ Quảng Bình – Số 4/2019
- [15] Trương Quốc Định và Nguyễn Đăng Quang (2015). Hệ thống phát hiện tình trạng ngủ gật của lái xe. Tạp chí Khoa học Trường Đại học Cần Thơ.