

PHÂN LOẠI MẶT ĐƯỜNG SỬ DỤNG MÔ HÌNH HỌC MÁY CÓ GIÁM SÁT TRÊN BỘ DỮ LIỆU CỦA CẢM BIẾN QUÁN TÍNH

ROAD SURFACE CLASSIFICATION USING SUPERVISED MACHINE LEARNING MODEL AND INERTIAL DATA

Ngô Văn Công¹, Trần Đức Nghĩa²,
Nguyễn Đình Nga³, Trần Đức Tân^{4,*}

DOI: <http://doi.org/10.57001/huiv5804.2024.205>

TÓM TẮT

Trong những năm gần đây, với sự phát triển của hạ tầng giao thông và lĩnh vực khoa học công nghệ thì việc nhận diện tình trạng mặt đường đang có nhiều ý nghĩa quan trọng đối với các hệ thống xe tự hành hoặc bài toán dẫn đường tự động. Trong các bài toán phân loại mặt đường thì có các hệ thống sử dụng camera, hệ cảm biến Lidar, tuy nhiên các hệ thống này triển khai thì thường khó thực hiện được phân loại trong thời gian thực, đồng thời cũng tốn kém về mặt chi phí. Chúng tôi nhận thấy sử dụng cảm biến quán tính và các thuật toán học máy sẽ mang lại hiệu năng cao trong thời gian thực và chi phí cho hệ thống cũng thấp hơn nhiều so với các hệ thống khác. Trong bài báo này, chúng tôi đề xuất lựa chọn bộ dữ liệu tối ưu để đánh giá hiệu năng phân loại 3 loại mặt đường là đường nhựa, đường đất và đường đá trên một số mô hình học máy cơ bản trên bộ dữ liệu công khai. Kết quả cho thấy độ chính xác đạt được trên 90% khi phân loại đường nhựa, đường đất, đường đá.

Từ khóa: Học máy, phân loại, cảm biến, mặt đường, giao thông thông minh.

ABSTRACT

Recent advancements in transportation and technology highlight the need for accurate road surface classification in autonomous vehicles and navigation systems. Traditional methods using cameras and Lidar sensors face limitations in real-time performance and cost. Our research suggests that inertial sensors, coupled with machine learning, can achieve over 90% accuracy in real-time classification of asphalt, dirt, and cobblestone surfaces, offering a low-cost and readily available alternative. This paper proposes evaluating the classification performance using fundamental machine learning models on publicly available datasets for these three road surface types.

Keywords: Machine learning, classification, sensor, road surface, ITS.

¹Học viện Khoa học và Công nghệ - VAST

²Viện Công nghệ thông tin (IOIT - VAST)

³Trường Đại học Công nghệ Giao thông Vận tải

⁴Trường Đại học Phenikaa

*Email: tan.tranduc@phenikaa-uni.edu.vn

Ngày nhận bài: 04/5/2024

Ngày nhận bài sửa sau phản biện: 31/5/2024

Ngày chấp nhận đăng: 25/6/2024

1. GIỚI THIỆU

Giám sát tình trạng mặt đường là một vấn đề đầy thách thức trong lĩnh vực giao thông và cơ sở hạ tầng [1, 2]. Để

thực hiện việc này thì các hệ thống giao thông thông minh [3] đã được phát triển, dữ liệu thô được thu thập từ các cảm biến sử dụng trong hạ tầng giao thông [4] và các thành phần tham gia khác, trí tuệ nhân tạo được sử dụng để tạo ra các kịch bản nhằm hỗ trợ đưa ra các quyết định [5-7]. Các dữ liệu này có phạm vi ứng dụng rộng như hệ thống quản lý giao thông, hỗ trợ việc ra quyết định của người tham gia giao thông, hệ thống giao thông công cộng và nhiều hệ thống khác [8, 9]. Để thực hiện các bài toán liên quan đến giám sát tình trạng mặt đường thì có một số phương pháp sử dụng ảnh [10-14], quét LiDAR [15], radar [16, 17] hoặc kết hợp nhiều cảm biến [18]. Tuy nhiên, những công nghệ này thì thường tốn kém về chi phí thiết bị và khó khăn trong tính toán thời gian thực. Một số nghiên cứu liên quan đề xuất phương pháp sử dụng dữ liệu cảm biến quán tính lắp đặt trên xe kết hợp học máy có chi phí rẻ hơn và phù hợp với yêu cầu tính toán thời gian thực [19, 20].

Trong bài báo này, ở phần 2 chúng tôi sẽ xem xét, phân tích lại một số nghiên cứu có liên quan đã công bố; phần 3 là giới thiệu về bộ dữ liệu công khai và các đặc tính quan trọng trong bài toán phân loại mặt đường; ở phần 4 chúng tôi đánh giá hiệu năng của một số mô hình học máy cơ bản đối với bộ dữ liệu công khai.

2. MỘT SỐ NGHIÊN CỨU LIÊN QUAN

Trong nghiên cứu [19], hai thiết bị gắn cảm biến gia tốc được gắn cố định bên trong xe ô tô, một ở trên mặt táp lô của xe, một ở dưới sàn xe để thu thập dữ liệu nhằm phân loại ổ gà và hố ga ở trên đường, các mô hình học máy giám sát cơ bản được sử dụng: Decision Tree (DT), Support Vector Machine (SVM) and k-Nearest Neighbor (kNN), kết quả phân loại cho thấy mô hình SVM đối với trường hợp này là chính xác nhất khi thiết bị đặt trên sàn xe, độ chính xác đạt 97%.

Công bố [20] khác sử dụng một điện thoại thông minh có cảm biến quán tính gắn cố định trong xe, nghiên cứu này tập trung vào xử lý dữ liệu cảm biến và đánh giá hiệu năng của các thuật toán học máy trong phân loại đường bằng phẳng, ổ gà và vết nứt ngang lớn trên đường.

Nghiên cứu [21] xây dựng một phần mềm trên điện thoại thông minh sử dụng cảm biến quán tính và thuật toán học máy C4.5 để phát hiện ổ gà trên đường theo thời gian thực,

kết quả thực nghiệm theo nghiên cứu công bố đạt độ chính xác phát hiện ổ gà trên đường trơn là 98,6%.

Dữ liệu sử dụng từ cảm biến quán tính và GPS gắn trên hệ thống treo của xe [22, 23] đã được sử dụng để đánh giá phân loại mặt đường nhựa và bê tông, mô hình học máy SVM đã được sử dụng với các đặc trưng được lấy trên miền tần số, độ chính xác trung bình của phân loại là 69,4%.

Các kết quả trong [24] sử dụng thuật toán học máy KNN trên bộ dữ liệu của cảm biến gia tốc để phân loại gờ giảm tốc, ổ gà và đường tàu hỏa cắt ngang, bằng cách sử dụng phổ công suất của tín hiệu nhờ biến đổi Fourier nhanh (FFT) kết quả phân loại đạt độ chính xác 95,5% theo báo cáo của tác giả. Các nghiên cứu tương tự cũng đã được thực hiện [25], công bố đưa ra những đặc trưng trên miền thời gian và miền tần số đối với các thuật toán học máy giám sát như cây quyết định, SVM.

Nhóm tác giả [26] đề xuất phát hiện các loại mặt đường như đá cuội và đường bằng phẳng, sử dụng mô hình KNN với 8 đặc trưng từ giá trị gia tốc và góc quay của 3 trục x, y, z. Nghiên cứu [27] cho rằng không có phương pháp chính xác để lựa chọn độ dài của sổ một cách chính xác, do đó cách tiếp cận phổ biến là kiểm tra kết quả thử nghiệm với nhiều cửa sổ khác nhau và lựa chọn độ dài của sổ tối ưu nhất. Bảng 1 trình bày tóm tắt các nghiên cứu đã sử dụng học máy để xác định các bất thường trên mặt đường.

Bảng 1. Một số công bố về phân loại, phát hiện mặt đường

Tác giả	Năm công bố	Phân loại mặt đường	Mô hình	Độ chính xác
Martinelli [19]	2022	Ổ gà Hố ga	SVM	97%
Akanksh Basavaraju [20]	2020	Đường phẳng Ổ gà Vết nứt ngang lớn	Mạng nơ ron	77%
Azza Allouch [21]	2017	Ổ gà	C4.5	98,6%
Wang S, Kodagoda S [22-23]	2018	Nhựa Bê tông	SVM	69,4%
Bustamante-Bello R [24]	2022	Gờ giảm tốc Ổ gà Đường tàu hỏa cắt ngang	KNN	95,5%
Ferjani I [25]	2022	Gờ giảm tốc Ổ gà Đường tàu hỏa cắt ngang	SVM	94%
Julio-Rodríguez [26]	2022	Đường đá cuội Đường bằng phẳng	KNN	99,2%
Menegazzo J. [27]	2021	Đường nhựa Đường đất Đường đá	Mạng nơ ron	93,1%

Qua thông tin trong bảng 1, chúng ta có thể thấy phần lớn các nghiên cứu là liên quan đến việc phân loại các bất thường trên mặt đường như ổ gà, hố ga, gờ giảm tốc. Các nghiên cứu về việc phân loại mặt đường chưa có nhiều công bố.


3. MÔ TẢ DỮ LIỆU

Trong bài báo này chúng tôi sử dụng bộ dữ liệu công khai [28], dữ liệu với tần số lấy mẫu là 100Hz thu được từ các cảm biến MPU-9250 và GPS. Bối cảnh được sử dụng để thu thập dữ liệu này là trên 3 loại xe khác nhau, 3 lái xe khác nhau và chạy trên 3 loại mặt đường khác nhau: đường đất, đường đá và đường nhựa bằng phẳng. Bảng dưới đây trình bày chi tiết về cách thu thập dữ liệu [28].

Bảng 2. Mô tả về bộ dữ liệu

Mẫu dữ liệu	Loại xe	Lái xe	Kịch bản chạy xe	Độ dài
PVS 1	Volkswagen Saveiro	Lái xe 1	Kịch bản 1	13,81km
PVS 2	Volkswagen Saveiro	Lái xe 1	Kịch bản 2	11,62km
PVS 3	Volkswagen Saveiro	Lái xe 1	Kịch bản 3	10,72km
PVS 4	Fiat Bravo	Lái xe 2	Kịch bản 1	13,81km
PVS 5	Fiat Bravo	Lái xe 2	Kịch bản 2	11,63km
PVS 6	Fiat Bravo	Lái xe 2	Kịch bản 3	10,73km
PVS 7	Fiat Palio	Lái xe 3	Kịch bản 1	13,78km
PVS 8	Fiat Palio	Lái xe 3	Kịch bản 2	11,63km
PVS 9	Fiat Palio	Lái xe 3	Kịch bản 3	10,74km

Các đặc trưng từ giá trị gia tốc, góc quay của 3 trục x, y, z và tốc độ được sử dụng trong bài báo này. Chúng tôi tạo ra các tệp dữ liệu từ bộ dữ liệu công khai mà ở đó dữ liệu được gắn các nhãn tương ứng là đường đất, đường đá và đường nhựa trơn. Hình 1 mô tả về 3 kịch bản chạy xe và hình 2 là ảnh chụp về 3 loại mặt đường [28].



Hình 1. Ba kịch bản chạy xe [28]



Hình 2. Ảnh chụp của 3 loại mặt đường [28]

Số lượng mẫu dữ liệu được thể hiện như bảng 3 [28].

Bảng 3. Số lượng mẫu dữ liệu

Kịch bản	Tệp dữ liệu	Số lượng mẫu			Tổng số mẫu	Độ dài quãng đường (km)			Tổng (km)
		Đường đất	Đường đá	Đường nhựa		Đường đất	Đường đá	Đường nhựa	
1	PVS1	25,868	61,659	56,509	144036	1,59	3,53	8,7	13,81
	PVS4	23,903	57,670	50,919	132,492	1,58	3,51	8,72	13,81
	PVS7	23,778	54,224	50,546	128,548	1,59	3,49	8,69	13,78

2	PVS2	44,618	20,737	59,330	124,684	2,17	1,39	8,07	11,62
	PVS5	60,539	18,143	55,195	133,877	2,16	1,38	8,09	11,63
	PVS8	44,939	18,825	59,854	123,618	2,16	1,37	8,09	11,63
3	PVS3	28,659	26,143	51,014	105,816	1,66	1,66	7,4	10,72
	PVS6	23,888	31,641	40,750	96,279	1,38	1,93	7,43	10,73
	PVS9	23,153	25,182	43,220	91,555	1,67	1,66	7,42	10,74
Tổng số		299,345 (27,69%)	314,224 (29,07%)	467,337 (43,24%)		15,96	19,92	72,61	

Nhóm tác giả [27] nhận định bộ dữ liệu họ tạo có một sự mất cân bằng nhẹ về dữ liệu giữa các nhãn [29], và tác giả cho rằng việc này thường được xử lý giống như một mô hình phân loại thông thường [30], không cần thiết áp dụng các phương pháp xử lý vấn đề cân bằng dữ liệu trong trường hợp này. Chúng tôi nhận thấy rằng trong số lượng mẫu thu được thì có 1 phần là mẫu thu được khi xe không di chuyển, do vậy cùng quãng đường như trong bảng 3 nhưng số mẫu dữ liệu thu được khi xe di chuyển là sẽ ít hơn, chúng ta coi các mẫu dữ liệu từ cảm biến quán tính khi vận tốc bằng 0 là nhiễu và loại trừ nó ra khỏi bộ dữ liệu áp dụng vào các mô hình học máy trong bài báo này, bảng 4 dưới đây mô tả số lượng mẫu sau khi đã lọc nhiễu.

So sánh bảng 4 và bảng 3 chúng ta có thể thấy số lượng mẫu dữ liệu có sự thay đổi để cân bằng hơn ở dữ liệu tại các nhãn, đối với dữ liệu có nhãn đường đất và đường đá đã tăng lên xấp xỉ 30% và dữ liệu có nhãn là đường nhựa đã giảm từ 43,24% xuống còn 40,0%.

Bảng 4. Số lượng mẫu sau lọc nhiễu

Kịch bản	Tập dữ liệu	Số lượng mẫu			Tổng số mẫu
		Đường đất	Đường đá	Đường nhựa	
1	PVS 1	25,668	60,759	43,973	130400
	PVS 4	23,903	56,371	45,728	126,002
	PVS 7	23,778	53,524	43,798	121,100
2	PVS 2	44,618	20,737	54,047	119,402
	PVS 5	60,539	18,143	49,519	128,201
	PVS 8	44,939	18,825	53,437	117,201
3	PVS 3	28,559	26,143	41,398	96,100
	PVS 6	23,888	31,641	35,771	91,300
	PVS 9	23,153	24,783	38,966	86,902
Tổng số		299,045 (29,4%)	310,926 (30,6%)	406,637 (40,0%)	

Trong bài báo này, chúng tôi tiến hành đánh giá hiệu năng phân loại của một số mô hình học máy cơ bản (cây quyết định; KNN; Rừng Ngẫu nhiên; Gradient-boosting) trên các bộ dữ liệu huấn luyện và kiểm tra như sau:

Thử nghiệm 1: Bộ dữ liệu này được lựa chọn để mô hình học máy có đủ các dữ liệu từ loại xe; người lái xe; kịch bản chạy xe; tỷ lệ giữa tập huấn luyện và kiểm tra ở thử nghiệm này khoảng 7:3:

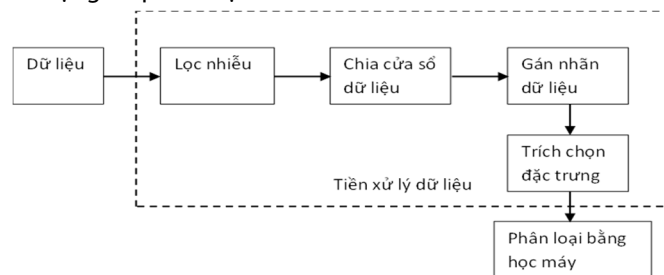
- Tập dữ liệu huấn luyện: được tạo ra từ các tập PVS 1; PVS 2; PVS 4; PVS 6; PVS 8; PVS 9.

- Tập dữ liệu kiểm tra: được tạo ra từ các tập PVS 3; PVS 5; PVS 7.

Thử nghiệm 2: Chúng tôi lựa chọn bộ dữ liệu thử nghiệm phân loại mà chỉ lấy trên 1 loại xe do 1 lái xe chạy để loại bỏ các yếu tố ảnh hưởng từ đặc tính của xe như độ nặng, độ giảm sóc của xe và đặc tính của lái xe. Tập dữ liệu được lựa chọn là PVS 1; PVS 2; PVS 3 với tỷ lệ phân chia tập huấn luyện và kiểm tra cũng là 6.5:3.5 để tương đương với tỷ lệ ở thử nghiệm 1.

4. HIỆU NĂNG PHÂN LOẠI

Các mô hình học máy có giám sát (C4.5; KNN; Rừng Ngẫu nhiên; Gradient-boosting) được thực nghiệm trong bài báo này đều được lập trình bằng ngôn ngữ Python 3, sử dụng thư viện scikit-learn trên nền tảng Google Collaboratory. Các mô hình được thực hiện trên bộ dữ liệu sau khi chúng tôi đã lọc bỏ các giá trị của cảm biến quán tính khi xe không di chuyển. Đối với mỗi mô hình chúng tôi sẽ thay đổi các giá trị tham số về cửa sổ dữ liệu là 100; 200; 300; 400; 500 để tính toán độ chính xác. Hình 3 mô tả về phương pháp và kỹ thuật sử dụng để phân loại.



Hình 3. Phương pháp thực hiện phân loại

Trong hình 3, dữ liệu [28] được sử dụng để áp dụng vào các mô hình học máy, các bước tiền xử lý được áp dụng như lọc nhiễu bằng cách loại bỏ các dữ liệu của cảm biến khi vận tốc bằng 0, sau đó dữ liệu được phân chia thành các cửa sổ có độ dài khác nhau, các dữ liệu được chia thành tập huấn luyện và kiểm tra sẽ được gán nhãn tương ứng đối với các loại mặt đường. Bộ trích chọn đặc trưng được áp dụng trước khi thực hiện phân loại bởi các mô hình học máy, ở bài báo này chúng tôi áp dụng các đặc trưng cơ bản trên miền thời gian như: trung bình, độ lệch chuẩn, RMS, phương sai.

Mô hình cây quyết định C4.5: là một thuật toán quyết định cây (decision tree) được phát triển bởi Ross Quinlan vào những năm 1990. C4.5 là phiên bản cải tiến của thuật toán ID3 (Iterative Dichotomiser 3) và là một trong những thuật toán quyết định cây phổ biến nhất trong lĩnh vực học máy [31]. C4.5 bắt đầu bằng việc xây dựng cây quyết định từ gốc (root) bằng cách chọn thuộc tính tốt nhất để chia dữ liệu thành các tập con (subsets) sao cho mỗi tập con chứa các mẫu có tính đồng nhất nhất có thể.

Mô hình Rừng Ngẫu nhiên (Random Forest): là một thuật toán học máy dựa trên việc xây dựng nhiều cây quyết định (decision trees) và kết hợp kết quả từ các cây để tạo ra một dự đoán cuối cùng [32].

Bảng 5 dưới đây thể hiện độ chính xác của mô hình trên các cửa sổ dữ liệu khác nhau trên 2 thử nghiệm nêu tại mục 3.

Bảng 5. Độ chính xác của C4.5

Mô hình Cây quyết định					
Bộ dữ liệu thử nghiệm	Độ dài cửa sổ				
	100	200	300	400	500
Thử nghiệm 1	73,3 %	69,4 %	71,8 %	72,2 %	65,0 %
Thử nghiệm 2	79,6 %	75,5 %	76,6 %	81,5 %	78,5 %
Mô hình Rừng Ngẫu nhiên					
Bộ dữ liệu thử nghiệm	Độ dài cửa sổ				
	100	200	300	400	500
Thử nghiệm 1	67,0 %	70,2 %	70,5 %	70,8 %	71,0 %
Thử nghiệm 2	82,3 %	82,2 %	83,2 %	78,2 %	83,2 %

Mô hình K lân cận: KNN bao gồm một kỹ thuật phân loại dựa trên các số liệu tương tự giữa dữ liệu để nhận dạng mẫu. Bằng cách này, đối với một dữ liệu mới, khoảng cách giữa dữ liệu và mỗi dữ liệu huấn luyện được tính toán, xác định k lân cận gần nhất. Lớp dữ liệu mới được định nghĩa là lớp phổ biến nhất trong số k lân cận của nó [33]. Trong nghiên cứu [27], nhóm tác giả đã thử nghiệm trên đối với mô hình KNN có kết quả tốt nhất tại cửa sổ dữ liệu 200, tại các lân cận 1, 2, 5, 10, 50. Bảng 6, 7 thể hiện độ chính xác của mô hình trên các độ dài cửa sổ khác nhau.

Bảng 6. Độ chính xác KNN áp dụng trên dữ liệu của thử nghiệm 1

Lân cận	Độ dài cửa sổ				
	100	200	300	400	500
1	92,2%	80,3%	90,5%	81,3%	79,5%
2	75,7%	70,3%	75,2%	71,7%	68,9%
5	76,7%	74,9%	77,6%	76,7%	76,0%
10	70,8%	71,2%	71,2%	72,1%	70,7%
20	69,5%	68,4%	69,1%	70,3%	69,3%
50	67,0%	66,0%	67,9%	67,7%	66,9%

Bảng 7. Độ chính xác KNN áp dụng trên dữ liệu của thử nghiệm 2

Lân cận	Độ dài cửa sổ				
	100	200	300	400	500
1	76,4%	71,7%	76,8%	77,8%	76,5%
2	75,3%	74,4%	77,1%	73,1%	75,2%
5	76,6%	74,4%	76,6%	76,8%	76,9%
10	77,3%	74,6%	75,6%	76,8%	78,2%
20	76,5%	75,3%	77,1%	76,2%	78,6%
50	74,8%	74,2%	76,1%	77,5%	76,4%

4.4. Mô hình Gradient-boosting

Bảng 8. Độ chính xác Gradient-boosting

Bộ dữ liệu thử nghiệm	Độ dài cửa sổ				
	100	200	300	400	500
Thử nghiệm 1	85,0%	84,4%	90,2%	85,3 %	86,7%
Thử nghiệm 2	86,6%	87,4%	88,4%	85,9 %	89,9%

Gradient-boosting là một kỹ thuật học máy mạnh mẽ được sử dụng cho cả bài toán phân loại và hồi quy. Nó là một

phương pháp tập hợp (ensemble method) mà kết hợp các mô hình yếu thành một mô hình mạnh hơn thông qua việc xây dựng các cây quyết định (decision trees) tuần tự [34]. Độ chính xác của mô hình như bảng 8.

5. PHÂN TÍCH KẾT QUẢ

Quan sát kết quả trong các bảng 5, 6, 7, 8 chúng ta có thể thấy các mô hình học máy Cây quyết định và Rừng Ngẫu nhiên có độ chính xác thấp hơn các mô hình KNN và Gradient-boosting. Mô hình Cây quyết định và Rừng Ngẫu nhiên trong bộ dữ liệu của thử nghiệm 1 có độ chính xác trung bình khoảng 70%, thấp hơn kết quả khi chạy trên bộ dữ liệu của thử nghiệm 2, độ chính xác đạt được khoảng 82%.

So sánh kết quả của mô hình KNN trên bộ dữ liệu của thử nghiệm 1 đối với kết quả của nhóm tác giả [27] đã công bố, kết quả của chúng tôi cao hơn khi độ chính xác trung bình đạt được khoảng 85%, công bố [27] cho kết quả trung bình đạt khoảng 75%.

Kết quả khi thử nghiệm trên mô hình Gradient-boosting có độ chính xác cao nhất, trung bình khoảng 87% khi chạy trên cả 2 bộ dữ liệu thử nghiệm 1 và thử nghiệm 2. Mô hình Gradient-boosting cũng cho thấy kết quả là ổn định nhất khi sự thay đổi giữa các kết quả chỉ rơi vào khoảng 4%. Ba mô hình còn lại cũng cho thấy sự ổn định của các kết quả khi thực hiện trên bộ dữ liệu của thử nghiệm 2.

6. KẾT LUẬN

Với sự phát triển của giao thông thông minh, một số ứng dụng đã trở nên phổ biến hàng ngày (hệ thống định vị dẫn đường, xe tự hành). Những hệ thống được sử dụng trong hệ thống giao thông thông minh cần có nhiều nguồn dữ liệu khác nhau để đưa ra các quyết định một cách chính xác nhất, một trong số đó thì thông tin về trạng thái mặt đường là cũng quan trọng để đưa ra các quyết định bởi người lái xe hoặc máy tính.

Nghiên cứu [27] đã công bố một số kết quả về phân loại 3 mặt đường gồm: đường nhựa phẳng, đường đất, đường đá sử dụng các phương pháp học máy trên bộ dữ liệu [28] mà họ đã công khai. Kết quả của Menegazzo, J và cộng sự [27] khi thực hiện phân loại bằng mô hình KNN đạt trung bình khoảng 75%. Trong bài báo này, chúng tôi đề xuất áp dụng một bộ lọc trong bước tiền xử lý dữ liệu trước khi thực hiện phân loại bằng mô hình học máy, thực nghiệm cho thấy kết quả phân loại mặt đường bằng mô hình KNN sau khi xử lý dữ liệu đã cải thiện độ chính xác đáng kể, độ chính xác trung bình đạt 85%.

Nghiên cứu này chúng tôi cũng đã đề xuất thực hiện phân loại trên bộ dữ liệu mà ở đó các đặc trưng bị tác động bởi các yếu tố tác động đến dữ liệu để gán nhãn như loại xe, áp suất lốp, người lái xe. Tuy kết quả thực hiện trên các mô hình học máy ở bài báo này cho thấy có cải thiện hơn nhưng không quá nhiều, chúng tôi nhận thấy một phần nguyên nhân có thể gây ra bởi bộ dữ liệu này khi tổng hợp từ [28] thì số lượng dữ liệu sử dụng không đủ lớn và chưa cân bằng cho mỗi loại mặt đường. Trong thời gian tới, nhóm tác giả dự kiến sẽ thu thập một bộ dữ liệu đủ lớn và áp dụng một số

phương pháp để nâng cao hiệu năng của cảm biến quán tính [35-36] kết hợp với một mô hình học máy đơn giản để có thể áp dụng phân loại thời gian thực trên các thiết bị nhúng có hiệu năng thấp mà vẫn đạt được độ chính xác cao.

TÀI LIỆU THAM KHẢO

- [1]. R. Bishop, "A survey of intelligent vehicle applications worldwide," in *Proc. IEEE Intell. Vehicles Symp.*, 2000, 25-30.
- [2]. J. Eriksson, L. Girod, B. T. Hull, R. Newton, S. Madden, H. Balakrishnan, "The pothole patrol: Using a mobile sensor network for road surface monitoring," in *Proc. 6th Int. Conf. Mobile Syst., Appl., Services*, 29-39, 2008.
- [3]. *Intelligent Transportation Systems*. <http://www.its.dot.gov/>.
- [4]. Ha L. M., Tan T. D., Long N. T., Duc N. D., Thuy N. P. "Errors determination of the MEMS IMU," *Journal of Science VNUH*, 6, 12, 2007.
- [5]. Machin M, Sanguesa JA, Garrido P, Martinez FJ, "On the use of artificial intelligence techniques in intelligent transportation systems," In *2018 IEEE wireless communications and networking conference workshops (WCNCW)*, pp 332-337, 2018.
- [6]. Mathew TV, *Transportation systems engineering: Intrusive technologies*, 2014. https://nptel.ac.in/courses/105101008/downloads/cete_09.pdf.
- [7]. Mathew TV, *Transportation systems engineering: Non-intrusive technologies*, 2014. https://nptel.ac.in/courses/105101008/downloads/cete_10.pdf.
- [8]. Singh B, Gupta A, "Recent trends in intelligent transportation systems: a review," *J Transp Lit* 9:30-34, 2015.
- [9]. Tran D. T., Luu, M. H., Nguyen T. L., Nguyen D. D., Nguyen P. T., "Land-vehicle mems INS/GPS positioning during GPS signal blockage periods," *Journal of Science, Vietnam National University, Hanoi*, 23(4), 243-251, 2007.
- [10]. R. Medina, J. Gómez-García-Bermejo, J. E. Zalama, "Automated visual inspection of road surface cracks," in *Proc. Int. Symp. Automat. Robot. Construct. (ISARC)*, 2010, 14-20.
- [11]. R. A. Ferguson, et al., *Road pavement deterioration inspection system*. Google Patents 6615648 B1, Sep. 9, 2003.
- [12]. Y. Huang, B. Xu, "Automatic inspection of pavement cracking distress," *J. Electron. Imag.*, 15, 1, 2006, Art. no. 013017.
- [13]. E. Salari, G. Bao, "Automated pavement distress inspection based on 2D and 3D information," in *Proc. IEEE Int. Conf. Electro/Inf. Technol.*, 1-4, 2011.
- [14]. S. Varadharajan, S. Jose, K. Sharma, L. Wander, C. Mertz, "Vision for road inspection," in *Proc. IEEE Winter Conf. Appl. Comput. Vis.*, 115-122, 2014.
- [15]. Pothole Marker and More APK, Mountain View, CA, USA, Google Play, 2017.
- [16]. Roadscanners, *Roadscanners*. 1998. [Online]. Available: <http://www.roadscanners.fi>
- [17]. M. R. Mahmoudzadeh, J. B. Got, S. Lambot, C. Grégoire, "Road inspection using full-wave inversion of far-field ground-penetrating radar data," in *Proc. 7th Int. Workshop Adv. Ground Penetrating Radar*, 1-6, 2013.
- [18]. S. J. Yu, S. R. Sukumar, A. F. Koschan, D. L. Page, M. A. Abidi, "3D reconstruction of road surfaces using an integrated multi-sensory approach," *Opt. Lasers Eng.*, 45, 7, 808-818, 2007.
- [19]. Martinelli A., Meocci M., Dolfi M., Branzi V., Morosi S., Argenti F., Berzi L., Consumi T., "Road Surface Anomaly Assessment Using Low-Cost Accelerometers: A Machine Learning Approach," *Sensors* 22, 3788, 2002. <https://doi.org/10.3390/s22103788>.
- [20]. Akanksh Basavaraju, Jing Du, Fujie Zhou, Jim Ji, "A Machine Learning Approach to Road Surface Anomaly Assessment Using Smartphone Sensors," *IEEE Sensors Journal*, 20, 5, 2020.
- [21]. Azza Allouch, Anis Koubaa, Tarek Abbes, Adel Ammar, "RoadSense: Smartphone Application to Estimate Road Conditions Using Accelerometer and Gyroscope," in *IEEE Sensors Journal*, 17. doi: 10.1109/JSEN.2017.2702739
- [22]. Wang S, Kodagoda S, Shi L, Dai X, "Two-stage road terrain identification approach for land vehicles using feature-based and markov random field algorithm," *IEEE Intell Syst* 33(1):29-39, 2018.
- [23]. Wang S, Kodagoda S, Shi L, Wang H, "Road-terrain classification for land vehicles: employing an acceleration-based approach," *EEE Veh Technol Mag* 12(3):34-41, 2017
- [24]. Bustamante-Bello R., García-Barba A., Arce-Saenz L.A., Curiel-Ramirez L.A., Izquierdo-Reyes J., Ramirez-Mendoza R.A., "Visualizing Street Pavement Anomalies through Fog Computing V2I Networks and Machine Learning," *Sensors*, 22, 456.
- [25]. Ferjani I., Alsaif S.A., "How to get best predictions for road monitoring using machine learning techniques," *PeerJ Comput. Sci.* 8, e941, 2022.
- [26]. Julio-Rodríguez J.d.C., Rojas-Ruiz C.A., Santana-Díaz A., "Bustamante-Bello, M.R.; Ramirez-Mendoza, R.A. Environment Classification Using Machine Learning Methods for Eco-Driving Strategies in Intelligent Vehicles," *Appl. Sci.*, 12, 5578, 2022.
- [27]. Menegazzo J., Von Wangenheim A., "Road surface type classification based on inertial sensors and machine learning," *Computing*, 103, 2143-2170, 2021.
- [28]. J. Menegazzo, A. Von Wangenheim, "Multi-Contextual and Multi-Aspect Analysis for Road Surface Type Classification Through Inertial Sensors and Deep Learning," *2020 X Brazilian Symposium on Computing Systems Engineering (SBESC)*, Florianopolis, 1-8, 2020. doi: 10.1109/SBESC51047.2020.9277846.
- [29]. Fernández A, García S, Galar M, Prati RC, Krawczyk B, Herrera F, "Learning from imbalanced data sets," Springer, Berlin, 2018.
- [30]. Brownlee J, "Imbalanced classification with python: better metrics, balance skewed classes, cost-sensitive learning," *Machine Learning Mastery*, 2020 <https://books.google.com.br/books?id=jaXJDwAAQBAJ>
- [31]. J. R. Quinlan, *C4.5: Programs for Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993.
- [32]. Breiman L., "Random Forests," *Machine Learning* 45, 5-32, 2001. <https://doi.org/10.1023/A:1010933404324>.
- [33]. Khandelwal R, *K-nearest neighbors (KNN)*. 2018. <https://medium.com/datadriveninvestor/k-nearestneighbors-knn-7b4bd0128da7>
- [34]. Natekin A, Knoll A., "Gradient boosting machines, a tutorial," *Front Neurorobot*, 4:7-21, 2013. doi: 10.3389/fnbot.2013.00021. PMID: 24409142; PMCID: PMC3885826.
- [35]. Tran D. T., Luu M. H., Nguyen T. L., Nguyen P. T., Huynh, H. T., "Performance improvement of MEMS-based sensor applying in inertial navigation systems," *Posts, Telematics & Information Technology Journal*, 2, 19-24, 2007.
- [36]. Tan T. D., Ha L. M., Long N. T., Tue H. H., Thuy N. P., "Novel MEMS INS/GPS integration scheme using parallel Kalman filters," In *2008 IEEE/SICE International Symposium on System Integration* (pp. 72-76), 2008. IEEE.

AUTHORS INFORMATION

Ngo Van Cong¹, Tran Duc Nghia², Nguyen Dinh Nga³, Tran Duc Tan⁴

¹Graduate University of Sciences and Technology - VAST, Vietnam

²Institute of Information Technology (IOIT - VAST), Vietnam

³University of Transport Technology, Vietnam

⁴Phenikaa University, Vietnam