



Original Article

# Combination of UAV Images and DSM for Land Cover Classification using Convolutional Neural Network

Bui Quang Thanh<sup>1,\*</sup>, Vu Phan Long<sup>2</sup>, Nguyen Xuan Linh<sup>1</sup>, Pham Van Manh<sup>1</sup>

<sup>1</sup>*VNU University of Science, 334 Nguyen Trai, Thanh Xuan, Hanoi, Vietnam*

<sup>2</sup>*Military Mapping Agency, 198 Tran Cung, Hanoi, Vietnam*

Received 26 July 2021

Revised 11 September 2021; Accepted 16 September 2021

**Abstract:** Machine learning applies predominantly to the classification of the satellite images, aerial photo, unmanned aerial vehicle (UAV) data, point clouds with considerable achievements. However, the dynamic and complex structures of land surface prevent accurate land cover segregation through built-in models, and there is a crucial need to investigate novel ones. This study integrates Catboost into a Convolutional neural network for land cover classification from UAV images, with a case study in Hanoi. The combination of these images and Digital surface model to form the input datasets. The results show that the overall accuracy reaches 91,5%, which is relatively higher than other comparing methods. The proposal model can be used as an alternative method for land cover classification.

**Keyword:** UAV, Convolutional neural network, catboost, Hanoi.

\* Corresponding author.

*E-mail address:* [qthanh.bui@gmail.com](mailto:qthanh.bui@gmail.com)

<https://doi.org/10.25073/2588-1094/vnuees.4812>

# Tích hợp DSM và ảnh chụp UAV với mô hình nơ-ron tích chập trong phân loại lớp phủ mặt đất

Bùi Quang Thành<sup>1,\*</sup>, Vũ Phan Long<sup>2</sup>, Nguyễn Xuân Linh<sup>1</sup>, Phạm Văn Mạnh<sup>1</sup>

<sup>1</sup>Trường Đại học Khoa học Tự nhiên, Đại học Quốc gia Hà Nội,  
334 Nguyễn Trãi, Thanh Xuân, Hà Nội, Việt Nam

<sup>2</sup>Cục Bản đồ, Bộ tổng Tham mưu, Ngõ 198 Trần Cung, Hà Nội, Việt Nam

Nhận ngày 26 tháng 7 năm 2021

Chỉnh sửa ngày 11 tháng 9 năm 2021; Chấp nhận đăng ngày 16 tháng 9 năm 2021

**Tóm tắt:** Các phương pháp học máy đã và đang được thử nghiệm với dữ liệu viễn thám đa độ phân giải như ảnh vệ tinh, ảnh hàng không, dữ liệu từ thiết bị bay không người lái (UAV), tập hợp dữ liệu đám mây điểm và đem lại kết quả khả quan. Tuy nhiên, với cấu trúc phức tạp của các loại hình lớp phủ và với đặc điểm nguồn dữ liệu lớn, các mô hình dựng sẵn đôi khi không đạt được độ chính xác mong đợi trong phân loại. Nghiên cứu này tích hợp mạng nơ-ron tích chập và thuật toán Catboost trong phân loại lớp phủ mặt đất từ dữ liệu UAV. Dữ liệu đầu vào của mô hình là ảnh chụp UAV tại Hà Nội, kết hợp với mô hình số bề mặt (DSM). Kết quả cho thấy mô hình đề xuất có độ chính xác phân loại = 91,5%, cao hơn so với các phương pháp phổ biến khác và có thể sử dụng tại các khu vực đô thị khác tại Việt Nam.

**Từ khóa:** UAV, Mạng nơ-ron tích chập, Catboost, Hà Nội.

## 1. Mở đầu

Trong các mô hình học sâu, mạng nơ-ron tích chập (Convolutional neural network - CNN) là phương pháp được sử dụng rộng rãi nhất và đã có nhiều ứng dụng thành công trong nhận dạng khuôn mặt, xử lý ngôn ngữ tự nhiên, phân loại hiện trạng sử dụng đất, xử lý dữ liệu đám mây điểm. Với ưu điểm trong xử lý dữ liệu lớn, CNN vô cùng hữu ích đối với các nghiên cứu có sử dụng dữ liệu viễn thám và các dữ liệu không gian khác. Ví dụ, CNN đã được sử dụng rộng rãi để phân loại dữ liệu ảnh viễn thám có độ phân giải cao [1-3], bao gồm phân loại hiện trạng sử dụng đất, phân loại cảnh quan và xác định đối tượng [2-7], hoặc cho nhận dạng đối tượng từ dữ liệu đám mây điểm [8].

Để nâng cao độ chính xác phân loại, nhiều nghiên cứu đã tích hợp tư liệu ảnh với một số dữ liệu bổ trợ khác như mô hình số địa hình (DTM), mô hình số bề mặt (DSM), dữ liệu từ đám mây điểm [9, 10]. Các dữ liệu bổ trợ đó thường được trộn (fusion) với ảnh chụp vệ tinh (các băng phổ) hoặc ảnh UAV (ảnh tổ hợp màu 3 kênh đỏ, xanh lục, xanh lam). Trong đó dữ liệu DTM, DSM cung cấp thêm nhiều thông tin về độ cao từ đó có thêm suy luận chính xác về loại đối tượng trong mối tương quan với các đối tượng xung quanh [1]. Với cấu trúc phức tạp của các loại hình lớp phủ và với đặc điểm nguồn dữ liệu lớn, các mô hình dựng sẵn đôi khi không đạt được độ chính xác mong đợi trong phân loại, do đó việc nghiên cứu các mô hình mới, thuật toán mới là cần thiết.

\* Tác giả liên hệ.

Địa chỉ email: qthanh.bui@gmail.com

<https://doi.org/10.25073/2588-1094/vnuees.4812>

Nghiên cứu này đề xuất tích hợp mô hình CNN trong đó tích hợp thuật toán Catboost thay thế cho lớp phân loại (dense layer) để nâng cao độ chính xác phân loại ảnh. Ảnh chụp từ thiết bị bay không người lái, kết hợp với mô hình số bề mặt (được xây dựng tự động từ khối ảnh chụp bằng phần mềm Pix4D mapper) được tích hợp để thành lập bộ dữ liệu đầu vào cho mô hình. Kết quả phân loại được so sánh với các phương pháp phổ biến khác đã được sử dụng với nguồn dữ liệu đầu vào tương tự.

## 2. Dữ liệu và phương pháp

### 2.1. Dữ liệu

Dữ liệu thử nghiệm tại khu vực Thượng Đình, Hà Nội được bay chụp vào ngày 8/5/2017 với thiết bị bay IDJ Phantom 3, Camera FC6310, tiêu cự 9 mm, độ cao bay chụp khoảng 191 m, dao động tùy từng tấm ảnh. Dải bay chụp được thiết kế với độ phủ ngang, dọc đảm bảo các điểm ảnh cùng tên xuất hiện trên nhiều tấm ảnh. Các tấm ảnh được lưu trữ trong khuôn dạng tệp jpg, với các thông số bay chụp của từng tấm ảnh. Khu vực bay chụp có tổng diện tích 0,627 km<sup>2</sup>. Tổng cộng 515 tấm ảnh jpg với các thông số như tọa độ tâm chụp, độ cao bay chụp, độ phân giải không gian trung bình 2,64 cm được lưu trữ. Thêm vào đó, 4 điểm khống chế mặt đất được sử dụng nhằm căn chỉnh toàn bộ khối ảnh về hệ tọa độ được sử dụng, và 2 điểm được sử dụng để kiểm tra, đánh giá độ chính xác.

### 2.2. Phương pháp

#### *Tiền xử lý ảnh, thành lập DSM*


Quá trình tiền xử lý ảnh được thực hiện bằng phần mềm Pix4D mapper. Phần mềm này cho phép tự động lấy thông tin từ các ảnh chụp và ghép thành khối ảnh dựa trên các điểm ảnh. Thông qua 3 bước xử lý chính như: khởi tạo khối ảnh với các thông số về định hướng tấm ảnh, xác định điểm ảnh cùng tên (tie-points), tạo đám mây điểm (point cloud), tạo bình đồ ảnh (orthophoto) và thành lập DSM. Sau quá trình khởi tạo, xác định các thông số camera, phần mềm tự động

xác định các điểm ảnh cùng tên (key points) để khớp ảnh. Các điểm khống chế mặt đất được sử dụng sau đó để căn chỉnh toàn bộ khối ảnh. Các điểm khống chế mặt đất được đo trong hệ tọa độ VN2000, múi 3°, và được chuyển về hệ tọa độ WGS84-UTM múi 48 cùng với tọa độ được thiết lập trên UAV. Nghiên cứu này tập trung vào xây dựng thuật toán phân loại ảnh, do đó việc chuyển đổi dữ liệu sang hệ tọa độ quốc tế sẽ thuận tiện hơn trong việc so sánh với các mô hình đã được xây dựng từ trước trên thế giới và tại Việt Nam.

#### *Mô hình Convolutional Neural Network kết hợp với Catboost*

Hiện tại các mô hình học sâu dựa trên cấu trúc mạng nơ-ron tích chập có thể được sử dụng cho nhiều mục đích khác nhau như: tách lọc mây từ chuỗi ảnh đa phổ, tách lọc mây từ ảnh đơn, nâng độ phân giải ảnh, phân loại lớp phủ dựa trên cấp trúc mạng U-net, cấu trúc Generative Adversarial Network (GAN). Đây là các công công đoạn nhằm tăng độ chính xác trong phân loại ảnh. Trong nghiên cứu này, mô hình tích hợp thuật toán phân loại Catboost được tích hợp với mô hình CNN, trong đó lớp cuối cùng của CNN được thay thế bởi Catboost, nhằm nâng cao độ chính xác phân loại. Cấu trúc của CNN bao gồm 2 lớp tích chập, kết hợp với hàm kích hoạt ReLU cùng với Dropout (để hạn chế over-fitting). Dữ liệu đầu ra tiếp tục được biến đổi (flatted) trước khi đưa vào lớp Fully Connected Layer. Lớp cuối cùng này sau đó sẽ được thay thế bởi Catboost. Trong đó, Catboost là một thuật toán phân loại dựa trên cây quyết định. Thuật toán đang được sử dụng rộng rãi trong cộng đồng nghiên cứu ứng dụng học máy. Thuật toán này có thể mạnh trong phân loại dữ liệu dạng bảng (tabulated data), và xử lý tốt nhóm dữ liệu phân nhóm (categorical data).

Mô hình CNN với các cấu trúc mới sẽ được thực hiện sử dụng nền tảng TensorFlow và thư viện Keras. TensorFlow là một nền tảng mã nguồn mở được phát triển bởi Google với mục đích xử lý các bài toán học sâu và rất mạnh mẽ trong việc xây dựng cấu trúc cho các bộ dữ liệu cũng như làm việc với các mảng đa chiều (hay còn gọi là Tensor) – một đơn vị cơ bản trong việc xây dựng các mạng nơ-ron.



Hình 1. Mô hình tích hợp CNN và Catboost trong phân loại ảnh.

Bảng 1. Thông số mô hình CNN và số lượng tham số mô hình

Các lớp (Layers)	Cấu trúc (Output Shape)	Tham số (Param #)
conv2d_6 (Conv2D)	(None, 9, 9, 8)	296
batch_normalization_6	(Batch (None, 9, 9, 8)	32
leaky_re_lu_6 (LeakyReLU)	(None, 9, 9, 8)	0
conv2d_7 (Conv2D)	(None, 9, 9, 8)	584
batch_normalization_7	(Batch (None, 9, 9, 8)	32
leaky_re_lu_7 (LeakyReLU)	(None, 9, 9, 8)	0
max_pooling2d_3	(MaxPooling2 (None, 4, 4, 8)	0
dropout_5 (Dropout)	(None, 4, 4, 8)	0
conv2d_8 (Conv2D)	(None, 4, 4, 16)	3216
batch_normalization_8	(Batch (None, 4, 4, 16)	64
leaky_re_lu_8 (LeakyReLU)	(None, 4, 4, 16)	0
max_pooling2d_4	(MaxPooling2 (None, 2, 2, 16)	0
dropout_6 (Dropout)	(None, 2, 2, 16)	0
flatten_1 (Flatten)	(None, 64)	0
my_dense (Dense)	(None, 32)	2080
dropout_7 (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 32)	1056
dropout_8 (Dropout)	(None, 32)	0
visualized_layer (Dense)	(None, 5)	165
Tổng tham số (Total params): 7525		
Tham số huấn luyện (Trainable params): 7461		
Tham số không huấn luyện (Non-trainable params): 64		

*Xây dựng bộ dữ liệu huấn luyện mô hình*

Để chuẩn bị dữ liệu cho quá trình phân loại ảnh bằng CNN, tổng cộng 1000 mẫu kiểm chứng thực địa được lựa chọn ngẫu nhiên (đảm bảo các loại hình lớp phủ có số lượng mẫu đáp ứng yêu cầu làm đại diện cho cả khu vực) trên toàn bộ khu vực nghiên cứu. Kích thước mẫu giao 9 x 9 pixels, tổng cộng 81000 pixels (1000 mẫu x 81 pixels). Mỗi mẫu được gán thủ công 1 loại hình lớp phủ (Đất trồng, Nhà, Thảm cỏ, Cây, Đường, Bề mặt bê tông, Mặt nước). Quá trình gán nhãn được thực hiện dựa trên giải đoán ảnh (vì ảnh UAV được chụp với độ phân giải không gian lớn, nên có thể nhận diện chính xác được từng đối tượng mẫu ảnh).


**3. Kết quả và thảo luận**

*3.1. Nắn chỉnh khối ảnh và thành lập DSM*

Trong nghiên cứu này, 6 điểm không chế (trong đó có 2 điểm dùng để kiểm tra) được sử dụng nhằm nắn chỉnh toàn bộ khối ảnh (Hình 2). Trong đó thể hiện khối ảnh gốc (xanh lá cây - green) và khối ảnh sau khi nắn chỉnh sử dụng điểm không chế (Màu xanh da trời – blue).

Bảng 2 cung cấp thông tin sai số của điểm không chế và điểm kiểm tra về các giá trị (X, Y và độ cao). Sai số mặt phẳng nằm trong giới hạn cho phép để thành lập bản đồ tỷ lệ 1:2000, trong đó RMSE về mặt phẳng nhỏ hơn 2 cm [11] (Bảng 2), do đó có thể tiếp tục thực hiện ghép

ảnh, nắn ảnh trực giao và tạo DSM (Hình 3). DSM sau đó được ghép với ảnh RGB thu thập từ UAV để tạo ra dữ liệu đầu vào cho mô hình CNN gồm 4 băng phổ (R, G, B và DSM).



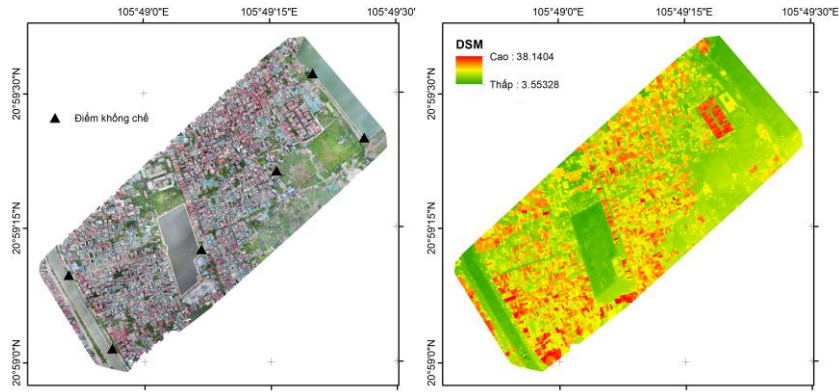
Hình 2. Khối ảnh sau khi được nắn chỉnh dựa vào điểm không chế mặt đất.

*3.2. Phân loại lớp phủ mặt đất*

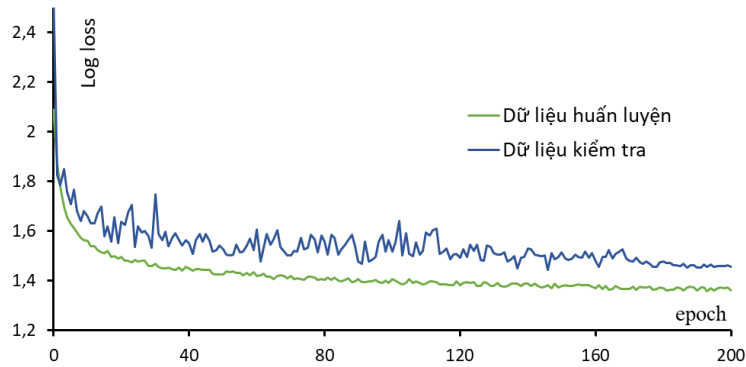
Mẫu thực địa được sử dụng để huấn luyện mô hình CNN-Catboost, cụ thể 80% được sử dụng để huấn luyện, hiệu chỉnh mô hình và 20% dùng để đánh giá độ chính xác mô hình. Các tham số của mô hình CNN được xác định như sau (hàm kích hoạt = ReLU và Softmax, thuật toán tối ưu = Adam, kích thước mỗi mảnh = 9 x 9, và tỷ lệ dropout = 0.15). Mô hình được học 200 lần (epoch), với kích thước gói đầu vào (batch size) là 64, hàm tối ưu (loss function) được sử dụng là *categorical\_logloss* (do đây là bài toán phân loại nhiều lớp đầu ra – multiple classification). Hình 4 thể hiện sự thay đổi của giá trị log-loss sau 200 lần lặp của mô hình CNN-Catboost.

Bảng 2. Điểm không chế mặt đất, điểm kiểm tra và sai số nắn chỉnh

TT	X	Y	Độ cao (H)	Loại điểm	Sai số X	Sai số Y	Sai số H
1	584451,890	2321623,210	6,512	KC	-0,0141	-0,0110	0,0214
2	584601,590	2321370,949	6,397	KC	0,0230	-0,0230	-0,0290
3	585466,351	2322094,702	5,300	KC	0,0230	0,0190	-0,0260
4	585289,306	2322315,152	5,073	KC	-0,0170	0,0212	0,0310
Mean [m]					0,0037	0,0016	-0,0007
RMS Error [m]					0,0193	0,0190	0,0271
5	584907,451	2321711,471	6,078	KT	-0,0190	-0,0210	0,0579
6	585165,601	2321981,898	6,778	KT	0,0179	0,0180	0,0014
Mean [m]					-0,0006	-0,0015	0,0296
RMS Error [m]					0,0185	0,0195	0,0283



Hình 3. Bình đồ ảnh và mô hình số bề mặt (DSM).



Hình 4. Thay đổi của hàm mục tiêu sau 200 epoch, từ mô hình CNN-Catboost với tập dữ liệu bao gồm ảnh R,G, B từ UAV và DSM.


Mô hình được thử nghiệm trên 2 gói dữ liệu (1) bao gồm cả DSM, tương đương 4 lớp R,G,B và DSM (2) không bao gồm DSM, dữ liệu chỉ có 3 lớp R,G, và B từ ảnh chụp UAV. Dựa trên thông số đánh giá từ Bảng 3, có thể nhận thấy mô hình đề xuất cùng với dữ liệu tích hợp giữa

ảnh chụp UAV và DSM có độ chính xác cao nhất, trong đó DSM bổ sung thông tin và nâng cao chất lượng phân loại ảnh. Mô hình CNN-Catboost cho độ chính xác tổng thể cao nhất (OA = 91,5%), và mô hình này được sử dụng để phân loại lớp phủ cho khu vực nghiên cứu (Hình 5)

Bảng 3. Sai số mô hình trong tương quan với các mô hình dùng để so sánh

Chỉ số đánh giá	Các mô hình được thử nghiệm			
	CNN-Catboost	CNN với dense layer	CNN-Catboost	CNN với dense layer
	Không có DSM	Không có DSM	Có DSM	Có DSM
Giá trị Loss	1,5873	1,6087	1,4569	1,5374
Độ chính xác tổng thể (OA) %	88,4	87,6	91,5	89,8

Đã có một số nghiên cứu thuật toán tích hợp (ensemble), ví dụ như [12-14] trong đó khẳng định khả năng nâng cao độ chính xác trong phân loại lớp phủ mặt đất. Bên cạnh đó, mô hình học sâu được sử dụng rộng rãi trong phân tích ảnh nói chung và ảnh viễn thám nói riêng (nhận diện đối tượng, phân loại lớp phủ, phân mảnh đối tượng, trộn ảnh) với dữ liệu đầu vào có độ phân giải cao. Nghiên cứu gần nhất của [15] sử dụng mô hình CNN với thuật toán gradient boosting đã thử nghiệm độ chính xác phân loại theo định hướng đối tượng (segmented image objects) từ ảnh SPOT 7. Bài báo này đánh giá khả năng phân loại của mô hình tích hợp tương tự như nghiên cứu của [15] và dữ liệu được xây dựng từ ảnh UAV tương tự như trong công trình [9], thử nghiệm tại khu vực Thượng Đình, thành phố Hà Nội. Độ chính xác phân loại tổng thể đạt (91,5%) và cao hơn so với các phương pháp dùng để so sánh đối với cùng tập dữ liệu. Nhìn chung, khi so sánh với nhiều nghiên cứu tại các khu vực khác nhau [16, 17], độ chính xác của mô hình CNN-Catboost đạt được là khả quan, và có thể được sử dụng trong các nghiên cứu tiếp theo.



Hình 5. Kết quả phân loại tại khu vực nghiên cứu với dữ liệu tích hợp từ ảnh chụp UAV và DSM.

## Kết luận

Nghiên cứu này tích hợp thuật toán phân loại Catboost cùng với mô hình mạng nơ-ron tích

chập nhằm nâng cao độ chính xác phân loại lớp phủ mặt đất từ dữ liệu ảnh UAV. Dựa trên kết quả thử nghiệm, việc sử dụng mô hình tích hợp CNN-Catboost và với sự bổ sung DSM trong dữ liệu đầu vào cho độ chính xác tổng thể = 91,5%, cao hơn so với các mô hình được sử dụng để so sánh. Mô hình đề xuất có thể được sử dụng như lựa chọn khác trong nâng cao độ chính xác phân loại từ ảnh vệ tinh độ phân giải cao, ảnh UAV. Việc thử nghiệm các thuật toán mới hay tích hợp các lớp dữ liệu gia tăng từ nguồn tư liệu ảnh chụp UAV là cần thiết và đang là xu hướng nghiên cứu hiện nay.

## Lời cảm ơn

Nghiên cứu này được tài trợ bởi Quỹ Phát triển Khoa học và Công nghệ Quốc gia (NAFOSTED) trong đề tài mã số 105.99-2020.09

## Tài liệu tham khảo

- [1] D. Marcos, M. Volpi, B. Kellenberger, D. Tuia, Land Cover Mapping at Very High Resolution with Rotation Equivariant Cnns: Towards Small yet Accurate Models, *ISPRS Journal of Photogrammetry and Remote Sensing* Vol. 145, 2018, pp. 96-107, <https://doi.org/10.1016/j.isprsjprs.2018.01.021>.
- [2] H. Wang, Y. Wang, Q. Zhang, S. Xiang, C. Pan, Gated Convolutional Neural Network for Semantic Segmentation in High-Resolution Images, *Remote Sensing* Vol. 9, No. 5, 2017, 10.3390/rs9050446.
- [3] W. Zhou, S. Newsam, C. Li, Z. Shao, Learning Low Dimensional Convolutional Neural Networks for High-Resolution Remote Sensing Image Retrieval, *Remote Sensing* Vol. 9, No. 5, 2017, <https://doi.org/10.3390/rs9050489>.
- [4] S. Srivastava, J. E. V. Muñoz, D. Tuia, Understanding Urban Landuse from the above and Ground Perspectives: A Deep Learning, Multimodal Solution, *Remote Sensing of Environment* Vol. 228, 2019, pp. 129-143, <https://doi.org/10.1016/j.rse.2019.04.014>.
- [5] G. Scarpa, M. Gargiulo, A. Mazza, R. Gaetano, A Cnn-Based Fusion Method for Feature Extraction from Sentinel Data, *Remote Sensing* Vol. 10, No. 2, 2018, <https://doi.org/10.3390/rs10020236>.

- [6] C. Tuna, G. Unal, E. Sertel, Single-Frame Super Resolution of Remote-Sensing Images by Convolutional Neural Networks, *International Journal of Remote Sensing* Vol. 39, No. 8, 2018, pp. 2463-2479, <https://doi.org/10.1080/01431161.2018.1425561>
- [7] G. Tsagkatakis, A. Aidini, K. Fotiadou, M. Giannopoulos, A. Pentari, P. Tsakalides, Survey of Deep-Learning Approaches for Remote Sensing Observation Enhancement, *Sensors*, Vol. 19, No. 18, 2019, <https://doi.org/10.3390/s19183929>.
- [8] X. Hu, and Y. Yuan, Deep-Learning-Based Classification for Dtm Extraction from Als Point Cloud, *Remote Sensing* Vol. 8, No. 9, 2016, <https://doi.org/10.3390/rs8090730>.
- [9] H. A. H. A. Najjar, B. Kalantar, B. Pradhan, V. Saeidi, A. A. Halin, N. Ueda, and S. Mansor, Land Cover Classification from Fused Dsm and Uav Images Using Convolutional Neural Networks, *Remote Sensing* Vol. 11, No. 12, 2019, <https://doi.org/10.3390/rs11121461>.
- [10] F. Jahan, J. Zhou, M. Awrangjeb, Y. Gao, Fusion of Hyperspectral and Lidar Data Using Discriminant Correlation Analysis for Land Cover Classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* Vol. 11, No. 10, 2018, pp. 3905-3917, <https://doi.org/10.1109/JSTARS.2018.2868142>.
- [11] B. N. Quy, P. T. Anh, D. A. Quan, P. V. Hiep, T. T. Kien, H. X. Tu, N. D. Dong, N. D. Duc, N. V. Hung, Research on Application of Unmanned Aerial Vehicles (Uavs) in Cadastral Mapping of Arable Land, *Journal of Mining and Earth Sciences*, Vol. 61, No. 5, 2020, pp. 43-53, (in Vietnamese), [https://doi.org/10.46326/jmes.2020.61\(5\).05](https://doi.org/10.46326/jmes.2020.61(5).05).
- [12] S. Rahman, M. Irfan, M. Raza, K. Moyeezullah Ghori, S. Yaqoob, M. Awais, Performance Analysis of Boosting Classifiers in Recognizing Activities of Daily Living, *International Journal of Environmental Research and Public Health*, Vol. 17, No. 3, 2020, <https://doi.org/10.3390/ijerph17031082>.
- [13] H. Liu, P. Gong, J. Wang, N. Clinton, Y. Bai, S. Liang, Annual Dynamics of Global Land Cover and Its Long-Term Changes from 1982 to 2015, *Earth Syst. Sci. Data* Vol. 12, No. 2, 2020, pp. 1217-1243, <https://doi.org/10.5194/essd-12-1217-2020>
- [14] M. R. Machado, S. Karray, I. T. D. Sousa, Lightgbm: An Effective Decision Tree Gradient Boosting Method to Predict Customer Loyalty in the Finance Industry, pp. 1111-1116.
- [15] B. Q. Thanh, T. Y. Chou, T. V. Hoang, Y. M. Fang, C. Y. Mu, P. H. Huang, P. V. Dong, N. Q. Huy, D. T. Anh, P. V. Manh, and M. E. Meadows, Gradient Boosting Machine and Object-Based Cnn for Land Cover Classification, *Remote Sensing* Vol. 13, No. 14, 2021, <https://doi.org/10.3390/rs13142709>.
- [16] S. E. Jozdani, B. A. Johnson, D. Chen, Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification, *Remote Sensing*, Vol. 11, No. 14, 2019, <https://doi.org/10.3390/rs11141713>.
- [17] M. J. Jun, A Comparison of a Gradient Boosting Decision Tree, Random Forests, and Artificial Neural Networks to Model Urban Land Use Changes: The Case of the Seoul Metropolitan Area, *International Journal of Geographical Information Science* 2021, pp. 1-19, <https://doi.org/10.1080/13658816.2021.1887490>.