

드론 영상의 이동 객체 인식을 위한 특징점 매칭 기반 딥러닝 훈련 자료 구축 방법론

강지우¹, 성흥기², 최강혁^{1*}
¹인하대학교 공간정보공학과, ²한국건설기술연구원

Feature Matching based Training Data Construction Method for Moving Object Detection from Drone Images

Ji-Woo Kang¹, Hong Ki Sung², Kang Hyeok Choi^{1*}

¹Department of Geoinformatic Engineering, Inha University

²Dept. of Feature & Smart Construction Research, Korea Institute of Civil Engineering and Building Tech

요약 딥러닝을 활용한 이동 객체 인식은 빠르고 정확한 인식 성능을 기대할 수 있다. 하지만, 딥러닝 기반 객체 인식의 정확도는 훈련 자료의 품질에 큰 영향을 받기에 양질의 훈련 자료를 확보하는 것이 중요하다. 기존의 훈련 자료를 마련하는 방법들은 상당한 비용, 합성 영상의 한계 그리고 초기 훈련 자료 요구와 같은 단점을 지니고 있다. 본 연구에서는 위와 같은 한계점을 극복하고자, 특징점 매칭을 이용해 드론 영상으로부터 차량 객체를 인식하여 초기 훈련 자료를 효율적으로 취득하는 방법론을 제안하고자 한다. 이를 위하여 연속된 드론 영상에서 참조 객체와 다른 영상 간 특징점 매칭을 수행한 후, KAZE, ORB, SIFT 그리고 SURF 알고리즘의 성능을 비교하였다. 다양한 도로 위 상황을 반영하기 위하여 드론과 차량 객체의 움직임으로 인한 객체의 형상 변화에 따라 시나리오를 분류한 후, 시나리오별 참조 객체를 강도에 따라 세분화하여 특징점 매칭 결과를 비교하였다. 실험을 통하여 KAZE 및 SURF 알고리즘이 평균 매칭점 개수 측면에서 우수한 성능을 보였으며, 90% 이상의 평균 정확도를 보였다. 또한, 두 알고리즘은 차량과 드론 간 상대적인 위치 변화와 차량 객체의 강도 변화에 가장 안정적인 성능을 보였다. 이에 본 연구에서는 특징점 매칭 기반 이동 객체의 훈련 자료 취득 방법론을 제시하였으며, 드론 영상으로부터 효율적인 훈련 자료 취득이 가능함을 확인하였다.

Abstract Researchers are studying the use of deep learning to detect moving objects in drone images. The accuracy of the model used depends on the quality of the training data, which highlights the importance of collecting high-quality training data. Methods for collecting training data have disadvantages such as high costs, reliance on synthetic data, and a need for initial training data. Therefore, this study presents a method for obtaining initial training data by matching moving objects in drone images using feature matching. To achieve this objective, we compared the performance of the KAZE, ORB, SIFT, and SURF algorithms by conducting feature matching between reference objects and other images in a series of drone images. In experiments, the KAZE and SURF algorithms performed well in terms of the average number of matching points and showed an average accuracy of over 90%. Additionally, both algorithms consistently outperformed other algorithms in tracking the relative position changes between moving objects and the drone, as well as changes in the intensity of moving objects. The results confirmed that training data can be efficiently obtained from drone images.

Keywords : Training Data, Drone Image, Moving Object, Feature Matching, Object Recognition

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제번호 RS-2022-00143782).

*Corresponding Author : Kang-Hyeok Choi(Inha Univ.)

email: cwsurgy@inha.ac.kr

Received August 21, 2023

Accepted October 6, 2023

Revised September 19, 2023

Published October 31, 2023

1. 서론

차량 및 개인형 이동 장치(PM: Personal Mobility) 등의 이동 객체 정보는 교통, 도시계획, 공공 서비스 및 자율 주행 등 다양한 분야에서 활용될 수 있다[1]. 최근 이러한 정보를 취득하기 위한 영상 속 이동 객체를 인식하는 다양한 관련 연구가 진행되고 있다[2]. 특히 드론 영상은 다음과 같은 다양한 장점을 기반으로 주목을 받고 있다. 먼저, 드론 영상은 위성 또는 항공 영상에 비해 상대적으로 높은 해상도를 가지며, 경제적으로 취득할 수 있다. 다음으로, 드론은 쉬운 조작과 신속한 데이터 수집으로 요구 사항에 빠르게 대응할 수 있으며, 촬영 목적에 따른 촬영 고도, 각도 및 주기 등을 조정하는 것이 상대적으로 용이하다. 마지막으로, 드론 영상은 지상에서 취득된 영상에 비하여 도로에 존재하는 시설물이나 장애물에 의한 영향을 적게 받는다[3].

딥러닝 기반 이동 객체 인식은 대량의 영상을 신속하게 처리할 수 있고 예상 정확도가 높다는 장점이 있어 관련 연구/개발에 대한 수요가 커지고 있다. 이때 딥러닝 모델의 정확도는 훈련 자료의 품질과 양에 큰 영향을 받기 때문에, 양질의 훈련 자료 구축 필요성 또한 증대되고 있다[4]. 드론 영상 기반 객체 인식을 위한 훈련 자료를 구축하는 방법은 실제 데이터 기반 수동 레이블링(labeling), 합성 데이터 생성 및 전이 학습으로 분류된다[4-6].

실제 데이터 기반 수동 레이블링 방법은 대표적인 훈련 자료 수집 방법 중 하나로, 실제 드론 영상에서 관심 객체를 식별하고 수동으로 주석을 입력하는 것이다. Z. Xu 등(2018)은 차량과 같은 작은 객체를 인식하기 위하여 낮은 고도에서 촬영한 드론 영상을 수집하고 주석 도구를 이용하여 훈련 자료를 취득하였다[7]. X. Xi 등(2019)은 주차장을 대상으로 드론 영상을 수집하고 직접 주석을 입력하여 훈련 자료를 취득한 후, 차량 객체를 인식하였다[8]. Arora, N. 등(2022)은 YouTube로부터 다양한 조건에서 촬영된 영상을 수집하고 직접 주석을 입력하여 훈련 자료를 구축한 후, 차량 객체를 인식하는 연구를 수행하였다[9].

합성 데이터 기반 방법은 실제계와 유사한 가상 환경을 구축하여 주석이 포함된 훈련 자료를 취득하거나 영상을 조작하여 훈련 자료를 증강하는 방법이다. J. Shen 등(2019)은 생성적 적대 신경망을 기반으로 훈련 자료를 증대하여 보완하고, 무인항공기 영상에서 차량 객체를 인식하였다[10]. K. Konen 등(2021)은 가상 환경 시뮬레이션 도구를 이용하여 합성 데이터를 생성하고 이를 통해 객체

인식 모델의 정확도를 높이는 방법을 제시하였다[11]. B. Kiefer 등(2022)은 DeepGTAV 프레임워크를 사용하여 합성 데이터를 생성하고, 생성한 데이터를 기반으로 객체 인식 모델을 학습하고 정확도를 평가하였다[12].

전이 학습은 사전에 구축된 모델을 이용하여 기존과 다른 환경에서 구축된 훈련 자료를 적용하여 모델의 성능을 향상시키는 방법이다[13]. Walambe R 등(2021)은 이미 학습된 객체 인식 모델을 드론 영상에 적용하여 차량 객체를 인식하였다[14]. Z. Ghasemi Darehnaei 등(2021)은 사전 학습된 CNN 모델 및 다양한 분류기를 활용하여 Faster R-CNN 기반 전이 학습을 수행하고, 다중 차량을 인식하였다[15]. S. Khan 등(2021)은 보행자 신호등을 인식하기 위하여 사전 학습된 MobileNetV2 모델을 전이 학습을 통하여 새로운 데이터 세트에 따라 조정하여 효과적으로 해결하였다[16].

딥러닝 훈련 자료 수집과 관련된 기존의 연구들은 각 연구의 목적에 맞는 합리적인 방법론을 통하여 훈련 자료를 수집하고 딥러닝 모델을 구축한 바 있다. 하지만 기존 연구들에서 사용한 훈련 자료 구축 방법은 다음과 같은 한계를 보인다. 먼저, 수동 레이블링 방법의 경우, 인적 자원과 시간이 많이 소모되어 경제적 비용이 높다. 합성 데이터 생성 방법은 시간, 기상 및 장소 등의 다양한 환경 요소 변화를 반영한 대용량의 훈련 자료 취득에 용이하지만, 여전히 실제 데이터 기반 모델의 성능을 대체할 수 없다[4,12]. 전이 학습의 경우, 기존에 학습된 모델 외에 추가적인 훈련 자료의 구축 없이 모델의 성능을 높일 수 있지만 여전히 초기 훈련 자료가 필요하다는 한계가 있다.

본 연구에서는 위와 같은 한계를 보완하고자, 특징점 매칭을 기반으로 드론 영상으로부터 차량 객체를 인식하여 초기 훈련 자료를 효율적으로 취득하는 방법론을 제안하는 것을 목표로 한다. 이를 위하여 본 연구에서는 드론 영상에서 참조 차량 객체를 획득한 후, 참조 객체와 연속된 영상 간 특징점 매칭을 수행하여 차량을 인식한다. 인식한 차량을 기반으로 훈련 자료를 구축하기 위하여, 훈련 자료에 요구되는 정밀도 및 목적에 따라 최적 알고리즘을 제시하고자 한다.

2. 드론 영상 속 차량 객체의 특징점 매칭

본 연구에서는 드론과 차량 간 상대적인 위치 변화에 따른 차량의 형상 변화를 고려하여 시나리오를 분류한 후, 각 시나리오에서 연속된 드론 영상 세트를 구성하였

다. 연속된 드론 영상 중 한 영상에서 차량 객체를 분리하여 참조 객체로 사용하였으며, 이는 차량의 강도 변화를 고려하기 위하여 차량의 강도 값에 따라 세분화하였다. 이후 특징점 매칭 알고리즘인 KAZE, ORB, SIFT 및 SURF를 이용하여 참조 객체와 다른 영상들 간의 특징점 매칭을 수행하였다.

2.1 특징점 매칭 알고리즘

본 연구에서는 드론의 촬영 각도 및 차량 이동에 따른 연속된 드론 영상 속 차량의 형상 변화에 안정적인 특징점 추출을 위하여 서로 다른 알고리즘의 성능을 비교/분석하였다. 실험에는 상대적으로 영상의 크기 및 회전 변화에 강건한 특징을 지닌 KAZE, ORB, SIFT 및 SURF의 네 가지 알고리즘이 이용되었으며 각 알고리즘은 다음과 같은 특징을 지닌다. 먼저, KAZE 알고리즘은 비선형 확산 필터를 기반으로 영상의 크기, 회전, 블러링(blurring) 및 잡음(noise) 변화에 강건한 특징을 갖는다. ORB 알고리즘은 빠른 속도와 계산의 효율성을 높인 알고리즘으로 영상의 회전 및 크기 변화에 강건한 특징을 갖는다. SIFT 알고리즘은 DoG(difference of gaussian) 영상을 기반으로 영상의 회전, 스케일(scale), 상당한 범위의 2차원 공간상의 왜곡(affine distortion), 잡음(noise) 및 조명 변화에 강건한 특징을 갖는다. 마지막으로, SURF 알고리즘은 기존 SIFT 알고리즘과 유사한 성능을 가지면서 처리 속도를 개선한 알고리즘으로, 영상의 회전, 크기 및 조명 변화에 강건한 특징을 갖는다.

2.2 연구 데이터

본 연구에서는 일산 킨텍스(KINTEX) 및 대화역 인근에서 촬영된 드론 영상을 사용하였다. 대상지에는 직선 도로, 교차로 및 주차장 등이 포함되어 있으며, 대상지 속 이동 객체에는 자동차, 초소형 자동차 및 원동기장치자전거 등이 포함된다. 이 중 자동차 객체를 대상으로 실험을 수행하였다. 영상에서 이동 객체들은 정지 또는 이동하는 상황을 고르게 확인할 수 있으며, 이동하는 차량은 직진하거나 교차로에서 회전하는 상황을 확인할 수 있다.

드론 영상 속 차량 객체는 차량 상태 및 드론과 상대적인 위치 관계에 따라 형상이 달라질 수 있다[17]. 따라서 본 연구에서는 차량 객체와 드론 간 상대적인 위치와 방향에 따라 Table 1과 같이 실험 데이터를 분류하였다. 먼저, 차량 객체의 상태에 따라 정지한 차량과 이동 중인 차량으로 구분한 후, 차량과 드론의 진행 방향에 따라 나란한 경우와 수직에 가까운 경우로 세분화하였다. Case

A의 경우, 정지한 차량이 드론의 진행 방향과 나란히 놓인 상황으로, 상대적으로 차량의 짧은 변보다 긴 변에서 형상 변화가 크게 나타난다[18]. Case B의 경우, 정지한 차량이 드론의 진행 방향과 수직에 가깝게 놓인 상황으로, 상대적으로 차량의 긴 변보다 짧은 변에서 형상 변화가 크게 나타난다. Case C의 경우, 이동 중인 차량이 드론의 진행 방향과 나란히 놓인 상황으로, 드론과 차량이 함께 이동하여 상대적으로 형상 변화가 크지 않다. Case D의 경우, 이동 중인 차량이 드론의 진행 방향과 수직에 가깝게 진행하는 상황으로, 회전으로 인해 상대적으로 형상 변화가 가장 크게 나타난다.

Table 1. Classification of experimental data based on the spatial relationship between drone and vehicles.

Case	Vehicle state	The direction of the drone and the vehicle
A	stopped	parallel
B	stopped	Almost perpendicular
C	moving	parallel
D	moving	Almost perpendicular

본 연구에서는 객체의 밝기 값에 따른 특징점 매칭 및 객체 인식 성능을 비교 분석하기 위하여 차량 객체의 강도(intensity)를 기준으로 차량을 3단계로 분류하였다. 차량 객체의 밝기, 즉 강도 값은 특징점 매칭에 큰 영향을 미칠 수 있다[18]. 따라서 참조 객체를 객체 픽셀(pixel)의 평균 강도 값을 이용하여 Table 2와 같이 3단계로 분류하였다. Table 2에서 I1은 상대적으로 밝은 값을 갖는 차량 객체이며, I2는 상대적으로 중간값을 갖는 차량 객체이다. 또한 I3은 상대적으로 어두운 값을 갖는 차량 객체이다.

Table 2. Classification of Intensity

Case	Intensity	Range of values
I1 (Intensity 1)	White	150 \leq
I2 (Intensity 2)	Gray	90 \leq
I3 (Intensity 3)	Black	60 \leq

본 연구에서는 차량 객체와 드론의 상대적인 위치 관계에 따라 구분한 각 시나리오의 참조 영상에서 강도별 객체를 분리한 후, 참조 객체와 연속된 드론 영상 간 특징점 매칭을 수행하였다. Fig. 1에서 각 시나리오에 해당하는 연속된 드론 영상 세트와 참조 영상을 확인할 수 있다.

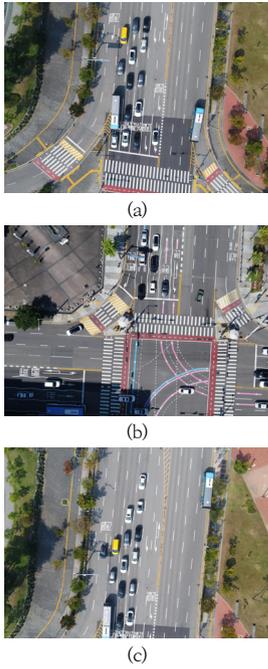


Fig. 1. Drone images for case A
 Images of stationary vehicles captured sequentially in parallel to their direction (Case A). A series of images in the order of (b), (a), and (c) with (a) as the reference image.

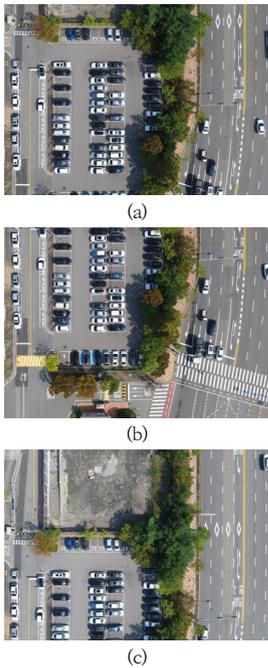
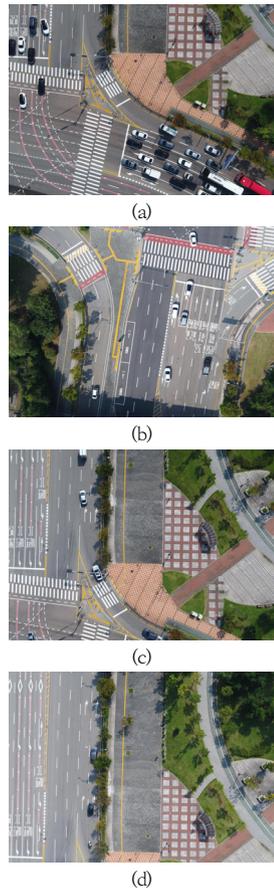


Fig. 2. Drone images for case B
 Images of stationary vehicles captured sequentially in perpendicular to their direction (Case B). A series of images in the order of (b), (a), and (c) with (a) as the reference image.



Fig. 3. Drone images for case C
 Images of moving vehicles captured sequentially in parallel to their direction (Case C). A series of images in the order of (a), and (b) with (a) as the reference image.



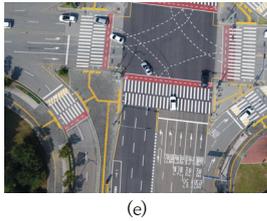


Fig. 4. Drone images for case D
 Images of moving vehicles captured sequentially in perpendicular to their direction (Case D). A series of images in the order of (a), (b), and (c) with (a) as the reference image. Also, a series of images in the order of (d), and (e) with (d) as the reference image.

2.3 알고리즘 성능 평가 기준

본 연구에서는 각 시나리오에서 강도별 객체 영상과 수행한 특징점 매칭 결과를 정상 매칭점 수와 매칭 정확도에 따라 평가하였다. 정상 매칭점 수는 정상으로 판별된 매칭점의 개수이다. 본 연구는 초기 훈련 자료 취득을 목표로 하여 훈련 자료 구축에 요구되는 인식 정밀도에 따라 정상 판별 기준을 Table 3과 같이 구분하였다. Table 3에서 Level 1의 경우, 도로 위 차량을 인식하고 구분하는 정밀도를 요구하는 단계로 차량으로 매칭된 경우, 정상으로 판별하였다. 차량 객체로 구성된 훈련 자료를 구축하고자 하는 목적에 사용될 수 있으며, 상대적으로 높은 정확도를 기대할 수 있다. Level 2의 경우, 서로 유사한 크기 및 강도를 갖는 차량을 구분하는 정밀도를 요구하는 단계로 차량의 크기 및 강도가 유사한 차량 객체로 매칭된 경우, 정상으로 판별하였다. 크기와 강도가 유사한 차량 객체로 구성된 훈련 자료를 구축하고자 하는 목적에 활용될 수 있으며, 동일 차량을 인식하는 Level 3보다 상대적으로 높은 정확도를 기대할 수 있다. Level 3의 경우, 동일 차량을 인식할 수 있는 정밀도를 요구하는 단계로 동일 차량으로 매칭된 경우, 정상으로 판별하였다. 차량 객체 추적 및 감시 등과 같은 동일 차량으로 구성된 훈련 자료를 구축하고자 하는 상황에 활용될 수 있다.

Table 3. Classification of Intensity

Level	Correct point
L1 (Level 1)	Vehicle
L2 (Level 2)	Similar Vehicle with Intensity and Size
L3 (Level 3)	Same Vehicle

매칭 정확도는 정상 판별 기준에 따라 도출된 정상 매

칭점 개수를 전체 매칭점 개수로 나눈 후, 백분율로 표기한 것이다. 지상에서 촬영한 차량 영상에 비해 공중에서 촬영한 차량 영상은 확인할 수 있는 특징이 제한적이므로, 드론 영상 속 추출되는 특징점 개수는 상대적으로 적다. 매칭 정확도는 분모인 전체 매칭점 수에 따라 민감하게 변화하므로 정상 매칭점 수와 함께 알고리즘 성능을 분석하였다. 또한, 전체 매칭점 수가 2개 이하인 경우, 신뢰도가 낮다고 판단하여 매칭 정확도 분석에서 제외하였다.

3. 드론 영상과 차량 객체 간 특징점 매칭 결과

3.1 차량 객체와 드론의 위치 변화에 따른 결과

드론과 차량 객체 간의 상대적인 위치가 변화하는 경우, KAZE 알고리즘이 상대적으로 가장 안정적인 결과를 보였다. KAZE 알고리즘은 모든 시나리오에서 80% 이상 매칭 정확도를 유지하고 있으며, 다른 알고리즘보다 정상 매칭점 수가 많은 것을 확인할 수 있다. 차량과 드론 간 상대적 위치 변화에 따른 특징점 매칭 결과는 Table 4에 나와 있다.

먼저, KAZE 알고리즘은 Case A에서 L1, L2 및 L3에서 10개의 정상 매칭점 수와 100%의 높은 정확도를 보였다. Case B에서는 8개의 정상 매칭점 수를 보이며, 양호한 성능을 유지하고 있다. 상대적으로 형상 변화가 적은 Case C에서 12~14개로 정상 매칭점 수가 가장 많은 것을 확인할 수 있다. 동일 차량을 인식하는 L3에서는 정상 매칭점 수가 12개로 줄어, 매칭 정확도는 상대적으로 다소 낮아졌음을 알 수 있다. 상대적으로 형상 변화가 크게 나타나는 Case D에서는 정상 매칭점 수가 5개로 줄어든 것을 확인할 수 있다. 매칭점 수는 줄었으나, 매칭 정확도는 L1에서 100%, L2와 L3에서 80% 정확도로 양호한 수준을 유지하고 있다.

다음으로, SURF 알고리즘은 두 번째로 많은 정상 매칭점 수를 갖는다. Case A, B 그리고 Case C에서 각 5~7개의 정상 매칭점 수를 보인다. 매칭 정확도는 Case A와 Case C에서 100%의 높은 정확도를 보이며, Case B에서는 83%의 상대적으로 낮은 정확도를 확인할 수 있다. KAZE 알고리즘은 정상 매칭점 수가 Case C, A 그리고 Case B 순으로 줄어들면서 시나리오에 따른 변화가 나타나는 반면 SURF 알고리즘은 시나리오 간 변화가 두드러지지 않는다.

Table 4. Feature matching results of relative position variation between vehicle objects and drones

Case	Algorithm	Total Matched Point	Level		
			L1	L2	L3
Case A	KAZE	10	10	10	10
	ORB	0	0	0	0
	SIFT	4	3	3	3
	SURF	7	7	7	7
Case B	KAZE	8	7	7	7
	ORB	0	0	0	0
	SIFT	4	3	3	3
	SURF	6	5	5	5
Case C	KAZE	15	14	14	12
	ORB	1	1	1	1
	SIFT	2	2	2	2
	SURF	7	7	7	7
Case D	KAZE	5	5	4	4
	ORB	0	0	0	0
	SIFT	1	1	1	1
	SURF	4	4	4	3

Case	Algorithm	Total Matched Point	Level		
			L1	L2	L3
Case A	KAZE	10	100%	100%	100%
	ORB	0	-	-	-
	SIFT	4	75%	75%	75%
	SURF	7	100%	100%	100%
Case B	KAZE	8	88%	88%	88%
	ORB	0	-	-	-
	SIFT	4	75%	75%	75%
	SURF	6	83%	83%	83%
Case C	KAZE	15	93%	93%	80%
	ORB	1	-	-	-
	SIFT	2	-	-	-
	SURF	7	100%	100%	100%
Case D	KAZE	5	100%	80%	80%
	ORB	0	-	-	-
	SIFT	1	-	-	-
	SURF	4	100%	100%	75%

SIFT 알고리즘은 각 시나리오에서 1~4개 사이의 정상 매칭점 수를 보이며 상대적으로 저조한 성능을 보였다. 매칭점 수는 적으나, L1, L2 및 L3 단계에서 모두 동일한 매칭 정확도를 유지하며, 상대적으로 차량이 아닌 차선 및 그림자나 유사한 차량으로 오매칭이 적은 것을 알 수 있다. 마지막으로, ORB 알고리즘은 모든 시나리오에서 0개의 특징점을 매칭하면서 상대적으로 가장 저조한 성능을 보였다.

따라서 드론 영상 속 차량의 상태에 따라 차량의 형상이 변화하는 상황에서 KAZE 알고리즘이 상대적으로 높은 매칭 정확도와 많은 정상 매칭점 수를 보이며 안정적인 결과를 보였다. SURF 알고리즘은 KAZE 알고리즘에 비하여 정상 매칭점 수는 적지만, 상대적으로 차량 객체와 드론의 위치 관계에 따른 영향을 덜 받는 것을 확인할 수 있다. KAZE와 SURF 알고리즘 모두 L1, L2에서 매칭 정확도를 유지하다가 L3에서 감소하였다. 동일 차량을

추적하고자 하는 상황에서 Level에 따른 변화가 적었던 SIFT 알고리즘이 매칭 정확도 측면에서 성능을 기대해볼 수 있다. 또한, 드론을 이용하여 차량 객체를 촬영할 때, 이동 중인 차량과 나란한 방향으로 진행하며 촬영하는 것이 가장 높은 정확도와 많은 매칭점 수를 보였다.

3.2 차량의 강도에 따른 결과

차량 객체의 강도가 변화하는 경우, KAZE 알고리즘이 강도별 객체에서 가장 많은 정상 매칭점 수를 보이며 상대적으로 안정적인 결과를 보였다. 또한 모든 특징점 매칭 알고리즘은 차량의 강도 값이 낮아짐에 따라 정상 매칭점 수가 상대적으로 크게 줄어드는 것을 확인할 수 있다.

KAZE 알고리즘은 상대적으로 높은 강도 값을 갖는 I1 객체에서 15~16개의 정상 매칭점 수와 평균 91%의

높은 정확도를 보이고 있다. 강도 값이 낮아진 I2 객체에서는 정상 매칭점 수가 7개로 크게 감소한 것을 확인할 수 있다. 어두운 I3 객체는 3개의 정상 매칭점 수를 보이며, 다른 알고리즘에 비하여 가장 양호한 성능을 보이고 있다.

SURF 알고리즘도 마찬가지로, I1 객체에서 12~14개의 정상 매칭점 수와 평균 93%의 높은 정확도를 보였으나, I2 객체에서 정상 매칭점 수가 4개로, 어두운 I3 객체에서는 0개로 감소한 것을 확인할 수 있다. SIFT 알고리즘은 I1 객체에서는 6개의 정상 매칭점 수와 100%의 높은 정확도로 양호한 성능을 보였지만, I2 및 I3 객체에서 정상 매칭점 수가 1~2개로 감소하는 것을 확인할 수 있다. 마지막으로 ORB 알고리즘은 가장 저조한 성능을 보이고 있다.

따라서 차량 객체의 강도 값이 감소함에 따라 정상 매

Table 5. Feature matching results of vehicle intensity variation

Intensity	Algorithm	Total Matched Point	Level		
			L1	L2	L3
I1	KAZE	17	16	16	15
	ORB	1	1	1	1
	SIFT	6	6	6	5
	SURF	14	14	13	12
I2	KAZE	7	7	7	7
	ORB	0	0	0	0
	SIFT	2	1	1	1
	SURF	4	4	4	4
I3	KAZE	4	3	3	3
	ORB	0	0	0	0
	SIFT	1	1	1	1
	SURF	0	0	0	0

Intensity	Algorithm	Total Matched Point	Level		
			L1	L2	L3
I1	KAZE	17	94%	94%	88%
	ORB	1	-	-	-
	SIFT	6	100%	100%	83%
	SURF	14	100%	93%	86%
I2	KAZE	7	100%	100%	100%
	ORB	0	-	-	-
	SIFT	2	-	-	-
	SURF	4	100%	100%	100%
I3	KAZE	4	75%	75%	75%
	ORB	0	-	-	-
	SIFT	1	-	-	-
	SURF	0	-	-	-

칭점 수도 감소하였으나, KAZE 알고리즘이 어두운 객체에서도 정상 매칭점 수를 유지하며 가장 안정적인 결과를 보였다. SURF 알고리즘도 적절한 정상 매칭점 수와 높은 정확도로 양호한 결과를 보였다. 어두운 차량 객체의 경우, 정상 매칭점 수가 상대적으로 크게 감소하며, KAZE 알고리즘을 제외한 ORB, SIFT 및 SURF 알고리즘은 0~1개로 저조한 성능을 보였다.

3.3 종합 결과

드론 영상과 차량 객체 간 특징점 매칭에서 드론과 차량 간 상대적인 위치 변화를 고려하는 경우, KAZE 및 SURF 알고리즘을 사용하는 것이 적합하다고 판단하였다. 차량의 강도에 따른 변화를 고려하는 경우, KAZE 알고리즘을 사용하는 것이 적합하다고 판단하였다. 차량의 강도가 드론과 차량의 상대적인 위치 변화보다 특징점 매칭 정확도에 미치는 영향이 상대적으로 크게 나타났다.

요구되는 인식 정밀도에 따른 최적 특징점 매칭 알고리즘은 다음과 같다. 차량을 인식하고자 하는 경우(L1), KAZE와 SURF 알고리즘이 평균 90% 이상 정확도를 유지하고 있어 가장 적합하다고 판단하였다. 강도 및 크기 유사 차량을 인식하고자 하는 경우(L2), 마찬가지로 KAZE와 SURF 알고리즘은 대부분 90% 이상 정확도를 보이고 있어 가장 적합하다고 판단하였다. 동일 차량 객체를 추적하고자 하는 경우(L3), 오매칭으로 인하여 정확도가 낮아져, KAZE와 SURF 알고리즘을 함께 사용하는 것이 적합하다고 판단하였다. KAZE 알고리즘의 경우, 정상 매칭점 수가 많지만 주로 흰 차선 또는 주변 교통 시설물로 오매칭도 상대적으로 자주 나타난다. 매칭 정확도 측면에서는 상대적으로 오매칭이 적은 SURF 알고리즘을 고려할 수 있다.

Fig. 5는 Case A에서 I1 객체를 매칭한 결과이다. 특징점 매칭을 이용하여 인식한 차량을 기반으로 영상 분류 딥러닝 모델인 SAM(SAM: Segment Anything Model)을 통하여 Fig. 6과 같이 차량 객체를 추출할 수 있다. 매칭된 특징점을 중심으로 주변 영상을 획득한 뒤, SAM을 통하여 폴리곤(polygon)형 객체만 추출한 것이다. 이를 통하여 요구되는 인식 정밀도에 따라 원하는 차량 객체를 훈련 자료로 효율적으로 취득할 수 있다.

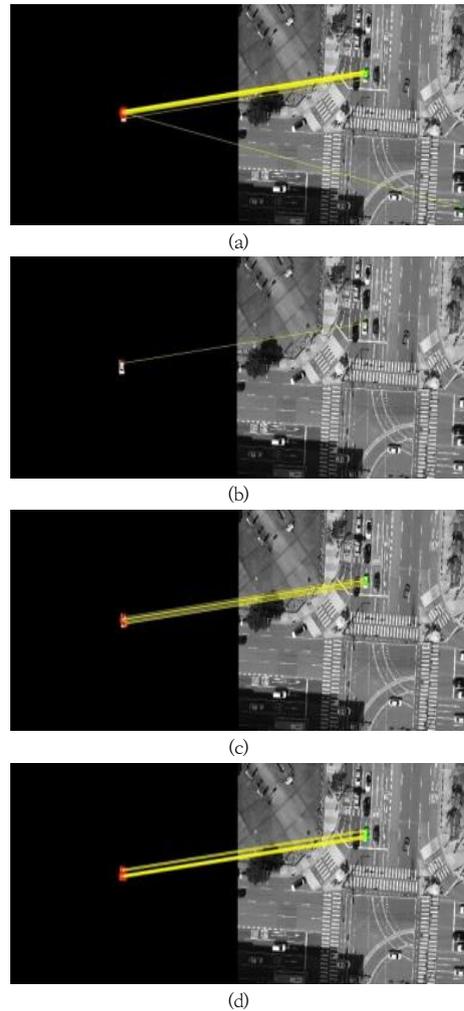


Fig. 5. Example of Feature matching Result (Case A-I1)
(a) KAZE (b) ORB (c) SIFT (d) SURF

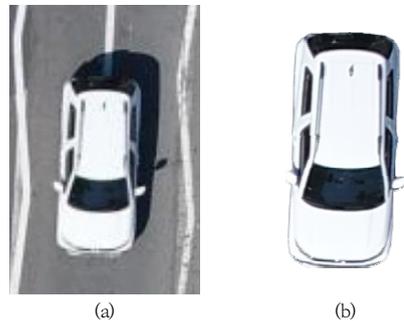


Fig. 6. Example of vehicle object extraction using feature matching results for training data
(a) cropped image of the detected vehicle using the feature matching (b) extracted polygon type objects using SAM

4. 결론

본 연구에서는 드론 영상 속 이동 객체 훈련 자료를 효율적으로 취득하기 위하여 특징점 매칭을 통한 객체 인식을 수행하였다. 드론과 차량 객체 간의 상대적인 위치 변화와 차량의 강도에 따른 시나리오를 구성한 후, 시나리오별 서로 다른 네 가지 특징점 매칭 알고리즘의 성능을 비교/분석하였다.

도로, 교차로 및 여러 이동 객체 등이 포함된 지역을 촬영한 드론 영상 속 차량을 인식하는 실험에서 KAZE 및 SURF 알고리즘이 드론과 차량 객체 간 상대적인 위치 변화와 차량의 강도 변화에 상대적으로 일관된 성능을 보였다. 훈련 자료의 요구되는 목적에 따라 차량을 인식하는 경우, KAZE 및 SURF 알고리즘이 적절한 평균 매칭점 개수와 90% 이상의 평균 정확도를 보였다. 유사한 크기 및 강도 값을 갖는 차량을 인식하는 경우, KAZE 및 SURF 알고리즘 모두 90% 이상의 평균 정확도를 유지하였다. 동일 차량을 인식하고자 하는 경우, KAZE 알고리즘은 매칭점 개수 측면에서 우수한 결과를 보였으며, SURF 알고리즘은 평균 정확도 측면에서 90% 이상을 유지하였다. 이에 본 연구에서는 특징점 매칭을 이용하여 차량 객체 영상을 획득하고, 이를 기반으로 영상 분류 딥러닝 모델에 적용하여 효율적인 훈련 자료 취득 방안의 효용성을 확인하였다.

향후 본 연구 내용을 바탕으로 다음과 같은 추가적인 연구가 필요하다. 먼저, 다양한 고도에서 촬영한 영상을 이용해 특징점 매칭을 수행할 필요가 있다. 드론 영상은 촬영 고도가 높아질수록 영상 속 차량 객체가 작아져 얻을 수 있는 특징 정보가 매우 제한적이다. 다음으로, 드론 영상 속 차량 객체는 차량의 강도 외에 주변 시설물의 그림자로 인해 영향을 받을 수 있다. 일반적인 상황에서 정확한 객체 인식을 위해서 그림자로 인한 강도 값의 변화도 고려할 필요가 있다. 마지막으로, 경사촬영 드론 영상을 통한 연구를 수행할 필요가 있다. 경사촬영 영상은 정사촬영(Nadir) 영상보다 드론과 이동 객체 간 상대적인 위치 변화에 따른 시각적 왜곡이 크게 나타난다. 이에 따른 특징점 매칭 결과의 변화를 살펴볼 필요가 있다.

References

[1] Butilă EV, Boboc RG, "Urban Traffic Monitoring and Analysis Using Unmanned Aerial Vehicles (UAVs): A

Systematic Literature Review", *Remote Sensing*, Vol.14, No.3, p.620, Jan. 2022.

DOI: <https://doi.org/10.3390/rs14030620>

[2] T. Moranduzzo and F. Melgani, "A SIFT-SVM method for detecting cars in UAV images", *2012 IEEE International Geoscience and Remote Sensing Symposium*, Munich, Germany, pp.6868-6871, Jul. 2012.
DOI: <https://dx.doi.org/10.1109/IGARSS.2012.6352585>

[3] Du, R., Peng, Z., and Lu, Q, "Comparison of SMS Calculation Methods Based on NGSIM Data for UAV Detection", *2012 4th International Conference on Intelligent Human-Machine Systems and Cybernetics*, IEEE, Nanchang, China, Vol.2, pp.112-115, Aug. 2012.
DOI: <https://dx.doi.org/10.1109/IHMSC.2012.123>

[4] Srivastava S., Narayan S., Mittal S, "A survey of deep learning techniques for vehicle detection from UAV images", *Journal of Systems Architecture*, Vol.117, Aug. 2021.
DOI: <https://doi.org/10.1016/j.sysarc.2021.102152>

[5] Mittal P., Singh R., Sharma A, "Deep learning-based object detection in low-altitude UAV datasets: A survey", *Image and Vision Computing*, Vol.104, Dec. 2020.
DOI: <https://doi.org/10.1016/j.imavis.2020.104046>

[6] A. Bouguettaya, H. Zarzour, A. Kechida and A. M. Taberkit, "Vehicle Detection From UAV Imagery With Deep Learning: A Review" in *IEEE Transactions on Neural Networks and Learning Systems*, Vol.33, No.11, pp. 6047-6067, Nov. 2022.
DOI: <https://doi.org/10.1109/TNNLS.2021.3080276>

[7] Z. Xu, H. Shi, N. Li, C. Xiang and H. Zhou, "Vehicle Detection Under UAV Based on Optimal Dense YOLO Method", *2018 5th International Conference on Systems and Informatics (ICSAI)*, Nanjing, China, pp.407-411, Nov. 2018.
DOI: <https://doi.org/10.1109/ICSAI.2018.8599403>

[8] X. Xi, Z. Yu, Z. Zhan, Y. Yin and C. Tian, "Multi-Task Cost-Sensitive-Convolutional Neural Network for Car Detection", in *IEEE Access*, Vol.7, pp.98061-98068, Jul. 2019.
DOI: <https://doi.org/10.1109/ACCESS.2019.2927866>

[9] Arora, N., Kumar, Y., Karkra, R, and Kumar M., "Automatic vehicle detection system in different environment conditions using fast R-CNN", *Multimedia Tools and Applications* 81, pp.18715-18735, March. 2022.
DOI: <https://doi.org/10.1007/s11042-022-12347-8>

[10] J. Shen, N. Liu, H. Sun and H. Zhou, "Vehicle Detection in Aerial Images Based on Lightweight Deep Convolutional Network and Generative Adversarial Network", in *IEEE Access*, Vol.7, pp. 148119-148130, Oct. 2019.
DOI: <https://doi.org/10.1109/ACCESS.2019.2947143>

[11] K. Konen and T. Hecking, "Increased Robustness of Object Detection on Aerial Image Datasets using Simulated Imagery", *2021 IEEE Fourth International Conference on Artificial Intelligence and Knowledge*

Engineering (AIKE), Laguna Hills, CA, USA, pp. 1-8, Dec. 2021.

DOI: <https://doi.org/10.1109/AIKE52691.2021.00007>

- [12] B. Kiefer, D. Ott and A. Zell, "Leveraging Synthetic Data in Object Detection on Unmanned Aerial Vehicles", *2022 26th International Conference on Pattern Recognition (ICPR)*, Montreal, QC, Canada, pp.3564-3571, Aug. 2022.
DOI: <https://doi.org/10.1109/ICPR56361.2022.9956710>
- [13] Al-Qubaydhi N, Alenezi A, Alanazi T, Senyor A, Alanezi N, Alotaibi B, Alotaibi M, Razaque A, Abdelhamid AA, Alotaibi A, "Detection of Unauthorized Unmanned Aerial Vehicles Using YOLOv5 and Transfer Learning", *Electronics*, Vol.11, No.17, p.2669, Aug. 2022.
DOI: <https://doi.org/10.3390/electronics11172669>
- [14] Walambe R, Marathe A, Kotecha K, "Multiscale Object Detection from Drone Imagery Using Ensemble Transfer Learning", *Drones 2021*, Vol.5, No.3, p.66, Jul. 2021.
DOI: <https://doi.org/10.3390/drones5030066>
- [15] Z. Ghasemi Darehnaei, M. Shokouhifar, H. Yazdanjouei and S. M. J. Rastegar Fatemi, "Si-EDTL: Swarm intelligence ensemble deep transfer learning for multiple vehicle detection in UAV images", *Concurrency and Computation: Practice and Experience*, Vol.34, No.5, pp.e6726, Feb. 2022.
DOI: <https://doi.org/10.1002/cpe.6726>
- [16] S. Khan, Y. Teng and J. Cui, "Pedestrian Traffic Lights Classification Using Transfer Learning in Smart City Application", *2021 13th International Conference on Communication Software and Networks (ICCSN)*, Chongqing, China, pp. 352-356, Jun. 2021.
DOI: <https://doi.org/10.1109/ICCSN52437.2021.9463615>
- [17] L. Wang, F. Chen, H. Yin, "Detecting and tracking vehicles in traffic by unmanned aerial vehicles", *Automation in Construction*, Vol.72, No.3, pp.294-308, Dec. 2016.
DOI: <https://doi.org/10.1016/i.autcon.2016.05.008>
- [18] Tao Zhao and R. Nevatia, "Car detection in low resolution aerial image", *Proceedings Eighth IEEE International Conference on Computer Vision (ICCV)*, Vancouver, BC, Canada, Vol.1, pp.710-717.
DOI: <https://doi.org/10.1109/ICCV.2001.937593>

강 지 우(Ji-Woo Kang)

[준회원]



- 2020년 2월 ~ 현재 : 인하대학교 공간정보공학과 (학사)

<관심분야>

공간정보, 스마트도시

성 흥 기(Hong Ki Sung)

[정회원]



- 2012년 2월 : 경희대학교 사회기반시스템공학과 (공학사)
- 2014년 2월 : 경희대학교 사회기반시스템공학과 (공학석사)
- 2023년 2월 : 경희대학교 사회기반시스템공학과 (공학박사)
- 2014년 9월 ~ 현재 : 한국건설기술연구원 전임연구원

<관심분야>

토목공학, 구조공학, 공간정보

최 강 혁(Kang Hyeok Choi)

[정회원]



- 2018년 8월 : 서울대학교 건설환경공학부 (공학박사)
- 2019년 2월 ~ 2019년 12월 : 명지대학교 연구교수
- 2020년 1월 ~ 2020년 11월 : Purdue University, Post Doc.
- 2021년 1월 ~ 2022년 8월 : 한국건설기술연구원, Post Doc.
- 2022년 9월 ~ 현재 : 인하대학교 공간정보공학과 조교수

<관심분야>

공간정보, 디지털트윈, 3D 모델링