



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2023년10월04일
(11) 등록번호 10-2584850
(24) 등록일자 2023년09월26일

(51) 국제특허분류(Int. Cl.)
G06T 5/00 (2019.01) G06N 20/00 (2019.01)
G06T 5/20 (2006.01) G06T 5/50 (2006.01)
G06T 7/13 (2017.01)
(52) CPC특허분류
G06T 5/001 (2013.01)
G06N 20/00 (2021.08)
(21) 출원번호 10-2021-0178669
(22) 출원일자 2021년12월14일
심사청구일자 2021년12월14일
(65) 공개번호 10-2023-0089904
(43) 공개일자 2023년06월21일
(56) 선행기술조사문헌
Che-Tsung Lin ET AL: "Enhancing Vehicular Safety in Adverse Weather Using Computer Vision Analysis", 2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall), Sept. 2014(2014.09.14.) 1부.*

(73) 특허권자
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
김시호
인천광역시 연수구 송도과학로 85(송도동)
정준교
인천광역시 연수구 하모니로 144
(74) 대리인
특허법인(유한)아이시스

(뒷면에 계속)

전체 청구항 수 : 총 8 항

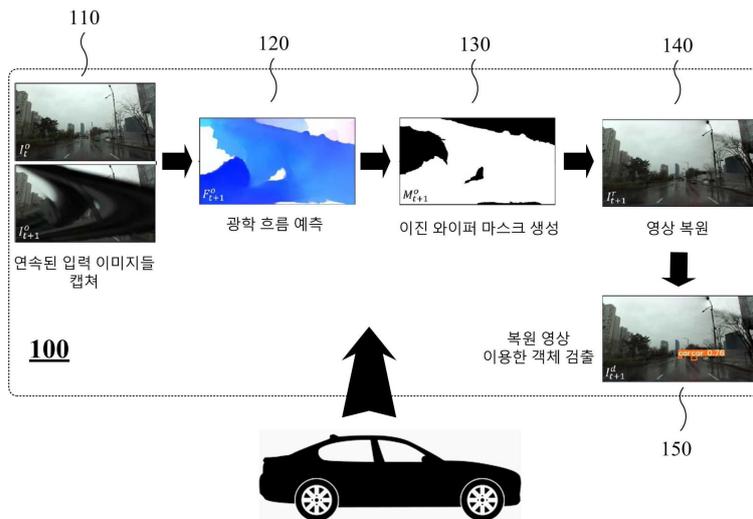
심사관 : 김광식

(54) 발명의 명칭 와이퍼 폐색 영상 복원 방법

(57) 요약

와이퍼 폐색 영상을 복원하는 방법은 영상 처리 장치가 차량 내부 카메라로부터 순차적인 영상들을 입력받는 단계, 상기 영상 처리 장치가 상기 순차적인 영상들을 사전에 학습된 광학 흐름(optical flow) 예측 모델에 입력하여 이진 와이퍼 마스크 및 흐름 데이터를 생성하는 단계 및 상기 영상 처리 장치가 상기 순차적인 영상들 및 복원 대상인 와이퍼 폐색 영역에 대한 상기 흐름 데이터와 상기 흐름 데이터를 이용하여 상기 순차적인 영상들 중 와이퍼 폐색 영역이 있는 타깃 영상을 복원하는 단계를 포함한다.

대표도



(52) CPC특허분류

- G06T 5/20 (2023.01)
- G06T 5/50 (2023.01)
- G06T 7/13 (2017.01)

(56) 선행기술조사문헌

Chen Gao ET AL: "Flow-edge Guided Video Completion", Computer Science_Computer Vision and Pattern Recognition, 3 Sept. 2020(2020.09.03.) 1부.*

Deqing Sun ET AL: "AutoFlow: Learning a Better Training Set for Optical Flow", Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 10093-10102, June 2021(2021.06.19.) 1부.*

Junekyo Jhung ET AL: "Behind-The-Scenes (BTS): Wiper-Occlusion Canceling for Advanced Driver Assistance Systems in Adverse Rain Environments", Sensors 2021, 21(23), 8081, 2 Dec. 2021(2021.12.02.) 1부.*

Zachary Teed ET AL: "RAFT: Recurrent All-Pairs Field Transforms for Optical Flow", Computer Science_Computer Vision and Pattern Recognition, 25 Aug. 2020(2020.08.25.) 1부.*

*는 심사관에 의하여 인용된 문헌

이 발명을 지원한 국가연구개발사업

과제고유번호	1711126158
과제번호	2020-0-00056-002
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원(한국연구재단부설)
연구사업명	정보통신방송연구개발사업
연구과제명	현실 세계에서 변화하는 상황에 따라 지속적으로 자가 개선하는 인공지능 기술 개발
기여율	1/2
과제수행기관명	연세대학교 산학협력단
연구기간	2021.01.01 ~ 2021.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711134394
과제번호	2021-0-01065-001
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원(한국연구재단부설)
연구사업명	정보통신방송연구개발사업
연구과제명	스마트 시티향 라스트마일 자율주행 배달 로봇을 위한 유사 라이더 개발
기여율	1/2
과제수행기관명	뉴빌리티
연구기간	2021.04.01 ~ 2022.03.31

공지예외적용 : 있음

명세서

청구범위

청구항 1

학습장치가 차량 주행 환경에서 캡처한 영상 데이터 세트를 입력받는 단계;

상기 학습장치가 상기 영상 데이터 세트에서 와이퍼가 포함된 복수의 영상들을 이용하여 복수의 와이퍼 이미지 및 상기 복수의 와이퍼 이미지에 대한 흐름 데이터를 추출하는 단계;

상기 학습장치가 공개 영상 데이터 세트 중 임의의 특정 영상에 상기 복수의 와이퍼 이미지 중 임의의 어느 하나를 합성하는 과정을 반복하여 합성 데이터 세트를 생성하는 단계; 및

상기 학습장치가 상기 합성 데이터 세트를 이용하여 와이퍼 이진 마스크를 생성하는 광학 흐름 예측 모델을 학습하는 단계를 포함하는 와이퍼 이진 마스크를 생성하는 광학 흐름 예측 모델 학습 방법.

청구항 2

제1항에 있어서,

상기 학습장치는 상기 복수의 영상들 각각에 대하여 별도의 학습 모델을 이용하여 자동 라벨링으로 유사-정답(pseudo-ground truth)에 해당하는 상기 와이퍼 이미지를 추출하는 와이퍼 이진 마스크를 생성하는 광학 흐름 예측 모델 학습 방법.

청구항 3

제1항에 있어서,

상기 복수의 와이퍼 이미지는 상기 복수의 영상들 각각에 대하여 수제 작업으로 라벨링된 결과인 진성 정답에 해당하는 와이퍼 이진 마스크를 생성하는 광학 흐름 예측 모델 학습 방법.

청구항 4

영상 처리 장치가 차량 내부 카메라로부터 순차적인 영상들을 입력받는 단계;

상기 영상 처리 장치가 상기 순차적인 영상들을 사전에 학습된 광학 흐름(optical flow) 예측 모델에 입력하여 이진 와이퍼 마스크 및 흐름 데이터를 생성하는 단계; 및

상기 영상 처리 장치가 상기 순차적인 영상들 및 복원 대상인 와이퍼 폐색 영역에 대한 상기 흐름 데이터와 상기 흐름 데이터를 이용하여 상기 순차적인 영상들 중 와이퍼 폐색 영역이 있는 타깃 영상을 복원하는 단계를 포함하는 와이퍼 폐색 영상을 복원하는 방법.

청구항 5

제4항에 있어서,

상기 영상 처리 장치는 상기 타깃 영상의 상기 와이퍼 폐색 영역의 주변 영상 정보를 더 이용하여 상기 와이퍼 폐색 영역을 복원하는 와이퍼 폐색 영상을 복원하는 방법.

청구항 6

제4항에 있어서,

상기 영상 처리 장치는 상기 순차적인 영상들 및 복원 대상인 와이퍼 폐색 영역에 대한 상기 흐름 데이터와 상기 흐름 데이터를 영상 복원 모델에 입력하여 상기 와이퍼 폐색 영역을 복원하는 와이퍼 폐색 영상을 복원하는 방법.

청구항 7

제6항에 있어서,

상기 영상 처리 장치는 상기 영상 복원 모델을 이용하여 상기 타깃 영상에서 상기 와이퍼 폐색 영역을 감지하고, 상기 감지한 와이퍼 폐색 영역을 제거하고, 상기 제거된 와이퍼 폐색 영역을 복원하는 와이퍼 폐색 영상을 복원하는 방법.

청구항 8

제6항에 있어서,

상기 광학 흐름 예측 모델은

실제 우천 환경의 차량 영상에서 추출한 와이퍼 데이터를 다양한 공개 데이터 세트에 합성하여 마련된 합성 데이터 세트를 이용하여 학습되는 와이퍼 폐색 영상을 복원하는 방법.

발명의 설명

기술 분야

[0001] 이하 설명하는 기술은 와이퍼 폐색 영역 감지 및 와이퍼 폐색 영역을 복원하는 기술에 관한 것이다.

배경 기술

[0002] 종래에 다양한 주행 관련 오픈 데이터 셋이 존재하였으며, 이를 활용한 연구가 있었다. 그러나 종래의 데이터 셋은 대부분 이상적인 날씨 환경에 대한 데이터를 다루고 있다.

[0003] 눈, 안개, 비와 같은 악천후 환경에서 이미지 기반 딥러닝 애플리케이션 성능에 대한 연구는 일부 진행되고 있지만, 실제 비에 대한 효과를 분석하는 연구는 아직 부족하다.

[0004] 실제 비에 의한 영상 왜곡 및 감지 오류에 효과를 고려함에 있어서, 와이퍼 객체를 고려하는 연구 진행되지 않고 있다. 즉, 주행 환경에서 차량 내부에 위치한 카메라를 적용한 영상 인식 등 기능 수행을 방해하는 와이퍼 폐색 영역 감지 및 폐색을 일으키는 와이퍼 제거 방법에 대한 연구는 거의 진행되고 있지 않다.

발명의 내용

해결하려는 과제

[0005] 자율 주행 관련하여 차량에서 촬영되는 이미지를 활용하기 위한 방법과 관련된 연구가 증가하고 있다. 하지만, 차량 내부의 전면 카메라에서 촬영되는 이미지의 경우 와이퍼는 이미지 내에서 큰 폐색 영역을 야기할 수 있다. 이는 이미지 기반 애플리케이션에 실제 외부환경 정보를 가리는 폐색 영역의 입력 데이터로 인한 차량 주행에 관련된 이미지 기반 애플리케이션 성능 저하 및 주행 안전을 위협할 수 있다.

[0006] 자율 주행의 완성도를 높이기 위해서는 우천 환경 주행 중 차량 내부 전방 카메라 이미지에 포착되는 와이퍼를 감지하고 와이퍼에 의한 폐색 구역을 복구하여 깨끗한 이미지 데이터를 생성하기 위한 작업이 필요하다.

[0007] 따라서, 와이퍼 폐색 감지 및 와이퍼 제거 영상 복원을 위한 기계 학습 모델 훈련 방법에 대한 연구가 필요하다.

과제의 해결 수단

[0008] 본 발명의 일 양태에 따른 와이퍼 이진 마스크를 생성하는 광학 흐름 예측 모델 학습 방법은 학습장치가 차량 주행 환경에서 캡처한 영상 데이터 세트를 입력받는 단계, 상기 학습장치가 상기 영상 데이터 세트에서 와이퍼가 포함된 복수의 영상들을 이용하여 복수의 와이퍼 이미지 및 상기 복수의 와이퍼 이미지에 대한 흐름 데이터를 추출하는 단계, 상기 학습장치가 공개 영상 데이터 세트 중 임의의 특정 영상에 상기 복수의 와이퍼 이미지 중 임의의 어느 하나를 합성하는 과정을 반복하여 합성 데이터 세트를 생성하는 단계 및 상기 학습장치가 상기 합성 데이터 세트를 이용하여 광학 흐름 예측 모델을 학습하는 단계를 포함한다.

[0009] 본 발명의 일 양태에 따른 와이퍼 폐색 영상을 복원하는 방법은 영상 처리 장치가 차량 내부 카메라로부터 순차

적인 영상들을 입력받는 단계, 상기 영상 처리 장치가 상기 순차적인 영상들을 사전에 학습된 광학 흐름(optical flow) 예측 모델에 입력하여 이진 와이퍼 마스크 및 흐름 데이터를 생성하는 단계 및 상기 영상 처리 장치가 상기 순차적인 영상들 및 복원 대상인 와이퍼 폐색 영역에 대한 상기 흐름 데이터와 상기 흐름 데이터를 이용하여 상기 순차적인 영상들 중 와이퍼 폐색 영역이 있는 타깃 영상을 복원하는 단계를 포함한다.

발명의 효과

[0010] 이하에서 설명하는 기술은 와이퍼로 인하여 발생한 폐색 영역을 실시간으로 복원하여 와이퍼의 영향이 없는 이미지를 제공한다. 이하 설명하는 기술은 우천시에도 와이퍼 폐색 영역 없는 영상을 이미지 기반 모듈에 제공하여 주행 성능 및 안전 개선을 도모할 뿐만 아니라, 자율주행을 위한 데이터셋 제공 및 다양화에 활용될 수 있다.

도면의 간단한 설명

[0011] 도 1은 우천 환경에서 차량 내부 카메라의 이미지 시퀀스에서 와이퍼의 영향을 나타내는 예시다.
 도 2는 와이퍼 폐색 영상을 복원하여 객체를 검출하는 모델 추론 과정에 대한 예이다.
 도 3은 와이퍼 폐색 영상 복원을 위한 모델 학습 과정과 추론 과정에 대한 예이다.
 도 4는 광학 흐름 예측 모델의 학습 과정에 대한 예이다.
 도 5는 자동 라벨링을 통한 와이퍼 유사-정답 데이터(pseudo-ground truth)를 추출하는 개념도의 예이다.
 도 6은 영상 복원 모델을 이용하여 와이퍼 폐색 영상을 복원하는 과정에 대한 예이다.
 도 7은 광학 흐름 예측 모델영상 복원 모델을 이용하여 이미지 복원 결과 및 효과를 비교하는 예이다.
 도 8은 복원한 영상을 이용한 물체 감지 결과 및 성능 개선 효과를 비교하는 예이다.

발명을 실시하기 위한 구체적인 내용

[0012] 이하 설명하는 기술은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다. 그러나 이는 이하 설명하는 기술을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 이하 설명하는 기술의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0013] 제1, 제2, A, B 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 해당 구성요소들은 상기 용어들에 의해 한정되지는 않으며, 단지 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 이하 설명하는 기술의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. 및/또는 이라는 용어는 복수의 관련된 기재된 항목들의 조합 또는 복수의 관련된 기재된 항목들 중의 어느 항목을 포함한다.

[0014] 본 명세서에서 사용되는 용어에서 단수의 표현은 문맥상 명백하게 다르게 해석되지 않는 한 복수의 표현을 포함하는 것으로 이해되어야 하고, "포함한다" 등의 용어는 설명된 특징, 개수, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함을 의미하는 것이지, 하나 또는 그 이상의 다른 특징들이나 개수, 단계 동작 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 배제하지 않는 것으로 이해되어야 한다.

[0015] 도면에 대한 상세한 설명을 하기에 앞서, 본 명세서에서의 구성부들에 대한 구분은 각 구성부가 담당하는 주기능 별로 구분한 것에 불과함을 명확히 하고자 한다. 즉, 이하에서 설명할 2개 이상의 구성부가 하나의 구성부로 합쳐지거나 또는 하나의 구성부가 보다 세분화된 기능별로 2개 이상으로 분화되어 구비될 수도 있다. 그리고 이하에서 설명할 구성부 각각은 자신이 담당하는 주기능 이외에도 다른 구성부가 담당하는 기능 중 일부 또는 전부의 기능을 추가적으로 수행할 수도 있으며, 구성부 각각이 담당하는 주기능 중 일부 기능이 다른 구성부에 의해 전담되어 수행될 수도 있음은 물론이다.

[0016] 또, 방법 또는 동작 방법을 수행함에 있어서, 상기 방법을 이루는 각 과정들은 문맥상 명백하게 특정 순서를 기재하지 않은 이상 명기된 순서와 다르게 일어날 수 있다. 즉, 각 과정들은 명기된 순서와 동일하게 일어날 수도 있고 실질적으로 동시에 수행될 수도 있으며 반대의 순서대로 수행될 수도 있다.

[0018] 최근 자동차 업계는 카메라를 탑재한 자율주행차 구현에 집중하고 있다. 자율 주행 차량은 인간 운전자와 마찬가지로

가지로 주로 시각적 인식에 의존한다. 비전 기반 딥 러닝 (vision-based deep learning)방법이 상당히 발전함에 따라, ADAS(advanced driver assistance systems)는 영상 데이터를 필수적으로 사용한다. 나아가, 자율 주행 시장을 선도하는 회사 중 하나인 테슬라™(Tesla)의 오토 파일럿(Autopilot)은 레이더 및 라이다(LiDAR) 센서 없이 카메라에 의존하는 시스템을 이용하고 있다.

- [0019] 적응형 순항 제어(ACC: adaptive cruise control), 자동 비상 제동(AEB: automatic emergency braking), 차선 유지 지원(LKA: lane keeping assistance) 및 기타 다양한 기능들이 영상의 객체 감지, 객체 분류, 추적 등과 같은 영상처리 작업을 이용한다.
- [0020] 기상 환경에 따라 차량이 획득하는 영상의 품질이 달라질 수 있다. 예컨대, 우천 환경에서 영상 데이터는 빗줄기, 비 축적, 또는 부착된 빗방울로 인한 품질 저하가 발생할 수 있다.
- [0021] 나아가, 차량은 내부 카메라로 전방 및 후방 영상 등을 캡처하는데, 우천시 와이퍼가 동작하면 카메라가 획득한 영상은 와이퍼로 인한 폐색 영역을 포함하게 된다.
- [0022] 도 1은 우천 환경에서 차량 내부 카메라의 이미지 시퀀스에서 와이퍼의 영향으로 실제 외부 환경이 폐색 영역으로 인해 발생하는 정보 왜곡을 나타내는 예시다.
- [0023] 구체적으로, 도 1(a)에서 정면 차량(빨간색 실선)이 보인다. 도 1(b)에서 와이퍼에 의해 정면 차량이 가려진다. 도 1(c)에서, 와이퍼가 차량(빨간색 점선)을 완전히 가린다. 도 1(d)에서 정면 차량이 다시 가시적으로 보이고, 부착된 빗방울이 제거되었다(파란색 점선). 와이퍼 동작은 와이퍼가 지나가는 영역에 폐색을 만들어 영상에서 객체 검출에 지장을 줄 수 있다. 도 1(c)와 같이, 전방 차량이 완전히 가려진 프레임 경우 비전 기반 인식 애플리케이션은 물체의 존재, 위치, 크기, 또는 종류를 잘못 판단할 수 있다. 이 경우, ADAS는 객체 검출 및 객체 분류에 실패하여 위험한 상황을 초래할 수 있다.
- [0024] 따라서, 자율 주행의 완성도를 높이기 위해서는 우천 환경의 차량 영상에서 발생하는 와이퍼 폐색 영역을 제거하는 기법이 필요하다. 이하 설명하는 기술은 차량의 카메라가 캡처한 영상에서 와이퍼 폐색 영역을 제거하여 영상을 복원하는 기법이다. 이하 차량 영상에서 와이퍼 폐색 영역이 존재하는 영상을 와이퍼 폐색 영상이라고 명명한다.
- [0026] 도 2는 와이퍼 폐색 영상을 복원하여 객체를 검출하는 모델 추론 과정(100)에 대한 예이다. 도 2는 이하 설명한 모델을 이용하여 와이퍼 폐색 영역을 복원하고, 복원한 영상을 이용하여 객체를 검출하는 애플리케이션의 예이다. 전체적인 와이퍼 폐색 영상 복원 과정을 먼저 설명하고자 한다.
- [0027] 와이퍼 폐색 영역을 복원하는 과정은 영상 처리 장치가 수행한다고 가정한다. 도 2는 영상 처리 장치가 와이퍼 폐색 영역을 복원하는 개략적인 과정에 대한 예이다. 영상 처리 장치는 차량 내의 프로세서, 이미지 칩셋, ECU(Electronic Control Unit) 등과 같은 장치로 구현될 수 있다.
- [0028] 제1 단계 (stage 1)에서 영상 생성 장치(카메라)는 두 개의 순차적 입력 이미지(I_t^o , I_{t+1}^o)를 캡처한다(110). 여기서 입력 이미지는 시간 t와 시간 t+1의 이미지와 같이 연속된 이미지일 수 있다. 나아가 입력 이미지는 일정한 시간 간격을 갖는 시간 t의 이미지와 시간 t+n의 이미지일 수도 있다. 도 2에서 시간 t의 이미지 I_t^o 는 정상 이미지이고, 시간 t+1의 이미지 I_{t+1}^o 는 와이퍼 폐색 영역이 있는 이미지이다. 순차적 입력 이미지들은 영상 처리 장치에 입력된다. 여기서 순차적 입력 이미지는 시간 순서에 따른 이미지를 의미하며 반드시 연속된 프레임의 영상은 아닐 수도 있다.
- [0029] 제2 단계 (stage 2)에서, 영상 처리 장치는 I_t^o 및 I_{t+1}^o 를 기준으로 광학 흐름(F_{t+1}^o)을 예측한다(120). 광학 흐름 예측을 위하여 영상 처리 장치는 광학 흐름 예측 모델을 이용할 수 있다. 영상 처리 장치는 광학 흐름을 예측하여 현재 영상에 와이퍼 폐색 영역이 있는지 감지할 수 있다.
- [0030] 제3 단계 (stage 3)에서, 영상 처리 장치는 예측한 광학 흐름을 이용하여 이진 와이퍼 마스크(M_{t+1}^o)를 생성할 수 있다(130).
- [0031] 제4 단계 (stage 4)에서, 영상 처리 장치는 이진 와이퍼 마스크를 이용하여 와이퍼 폐색 영역을 복원한 이미지(I_{t+1}^r)를 생성할 수 있다(140). 영상 처리 장치는 이진 와이퍼 마스크를 이용하여 타깃 영상에서 와이퍼 폐색

영역을 제거할 수 있다. 영상 처리 장치는 현재 영상 I_{t+1}^o 의 와이퍼 폐색 영역을 와이퍼 폐색이 없는 이전 프레임 또는 다른 프레임을 이용하여 복원할 수 있다.

- [0032] 나아가, 영상 처리 장치는 상기 다른 프레임의 영상과 함께, 타겟 영상에서 와이퍼 폐색 영역을 제외한 주변 정보를 더 이용하여 타겟 영상의 와이퍼 폐색 영역을 복원할 수 있다.
- [0033] 이 과정에서 영상 처리 장치는 전통적인 방법으로 현재 영상의 와이퍼 폐색 영역을 정상인 다른 프레임의 영역으로 대체하여 복원할 수 있다. 나아가, 영상 처리 장치는 영상 복원을 위한 별도의 학습 모델을 이용하여 영상을 복원할 수도 있다.
- [0034] 이후, 제5 단계 (stage 5)에서, 영상 처리 장치 또는 별도의 객체 검출 장치에서 복원된 영상을 기준으로 주변 객체를 검출하고, 해당 객체가 구분된 이미지(I_{t+1}^d)를 생성할 수 있다(150).
- [0036] 와이퍼 폐색 영상 복원 과정은 와이퍼 폐색 영상에 대한 이진 와이퍼 마스크를 생성하는 광학 흐름 예측 모델을 학습하는 과정과 학습된 광학 흐름 예측 모델을 이용하여 와이퍼 폐색 영상을 복원하는 추론 수행하는 과정으로 구성된다. 도 3은 와이퍼 폐색 영상 복원을 위한 모델 학습과 추론 과정(200)에 대한 예이다. 도 3은 광학 흐름 예측 모델 학습 과정(210)과 학습된 모델을 이용한 추론 과정(220)으로 구성된다. 도 3에서 이용하는 모델은 음영을 갖는 사각형 블록으로 표현하였다.
- [0037] 학습 과정(210)을 먼저 설명한다. 먼저, 학습을 위한 초기 데이터가 수집되어야 한다. 차량 내부 카메라는 다양한 주행 환경에서 차량 영상을 캡처한다. 차량 영상은 와이퍼가 동작하는 장면을 포함한다. 차량 영상 데이터 세트는 다양한 주행 환경에서의 차량 영상들로 구성된다.
- [0038] 학습 과정은 전술한 영상 처리 장치가 아닌 별도의 학습 장치에서 수행될 수 있다. 학습 장치는 영상 처리 및 모델 학습이 가능한 컴퓨터 장치를 의미한다. 학습 장치는 차량 내부 카메라를 통해 획득한 차량 영상 데이터 세트를 입력받는다(211).
- [0039] 학습 장치는 차량 영상 데이터 세트에서 와이퍼 이미지 및 흐름 데이터를 추출한다(212).
- [0040] 학습 장치는 기존 공개된 영상 데이터 세트에 와이퍼 데이터를 합성한다(213). 이때 학습 장치는 다양한 합성 시나리오에 따라 합성 데이터 세트를 생성할 수 있다. 다양한 합성 시나리오를 이용하여 다양한 합성 데이터를 생성하면 모델의 학습력이 개선될 수 있다.
- [0041] 학습 장치는 합성 데이터 세트를 이용하여 광학 흐름 예측 모델을 학습한다(214). 학습 과정이 종료되면 학습된 광학 흐름 예측 모델이 산출된다. 학습 과정에 대한 상세 내용은 후술한다.
- [0042] 이제 학습된 광학 흐름 예측 모델을 이용한 추론 과정(220)을 설명한다. 추론 과정은 차량에서 수행된다고 가정한다. 차량 내부 카메라는 차량의 영상 데이터를 캡처한다(221). 차량 내부 카메라는 차량의 전면 유리 영상과 같이 와이퍼가 동작하는 영역에 대한 영상을 연속하여 캡처한다. 와이퍼 폐색을 가정하여 전면 유리를 기준으로 설명하였지만, 영상 처리 장치는 와이퍼 폐색이 발생하는 후면 유리뿐만 아니라 매질의 관계없이 와이퍼 폐색이 발생한 영상 데이터에서 동일한 과정을 수행할 수 있다. 또한, 추론은 이미 수집한 영상 데이터셋에 대한 후처리 작업에도 적용될 수 있다.
- [0043] 영상 처리 장치는 시간 흐름에 따른 순차적인 복수의 영상들을 학습된 광학 흐름 예측 모델에 입력한다. 영상 처리 장치는 순차적인 2개의 영상들에 대한 광학 흐름을 예측할 수 있다. 여기서 순차적인 영상은 2개의 연속된 영상들(시간 t 영상 및 시간 t+1 영상)일 수 있다. 나아가, 순차적인 영상은 일정한 시간 간격을 갖는 영상들(①시간 t 영상 및 ② 시간 t+2 영상 또는 시간 t+n)일 수도 있다. 영상 처리 장치는 광학 흐름 예측을 통해 연속된 프레임들 사이에서 픽셀의 변화로 예측할 수 있으며, 와이퍼와 같이 상대적으로 빠른 속도로 이동하는 객체는 픽셀의 변화가 일정한 임계값 이상인 경우로 확인할 수 있다. 광학 흐름 예측 모델은 입력된 영상들을 기준으로 흐름 데이터 및 와이퍼 이진 마스크를 생성한다(222).
- [0044] 영상 처리 장치는 와이퍼 이진 마스크와 카메라가 캡처한 순차적 영상들을 이용하여 와이퍼 폐색 영상을 복원한다. 예컨대, 영상 처리 장치는 순차적 영상들 및 복원 대상 영역의 흐름 및 와이퍼 이진 마스크를 사전에 마련한 영상 복원 모델에 입력하여 와이퍼 폐색 영상을 복원할 수 있다(223).
- [0045] 영상 처리 장치는 복원된 영상을 이용하여 객체를 감지할 수 있다(224). 이후 영상 처리 장치는 검출된 객체에 대한 영상 처리(바운딩 박스 데이터 생성) 또는 검출 객체 정보를 차량의 다른 객체에 전달할 수 있다.

- [0047] 기술한 바와 같이, 영상 처리 장치는 우천 환경의 주행 차량 이미지에서 와이퍼를 실시간 감지하기 위해 광학 흐름 기법을 사용한다. 광학 흐름은 연속된 두 이미지 간 동일한 픽셀의 변화 차이를 벡터 (vector)로 나타낸다. 영상 처리 장치는 다른 객체에 비해 상대적으로 빠르게 움직이는 와이퍼를 감지하기 위해 광학 흐름을 활용할 수 있다. 광학 흐름 예측 모델은 대표적으로 RAFT 모델이 있다. 연구자는 RAFT 모델을 사용하여 모델을 구축하였다. 물론, 광학 흐름 예측은 다른 모델을 사용하여 예측될 수도 있다.
- [0048] RAFT 모델을 간략하게 설명한다. 광학 흐름 예측 모델은 특징 인코더(feature encoder) 및 컨텍스트 인코더(context encoder)를 포함한다. 특징 인코더는 시간 t와 시간 t+1의 프레임을 각각 입력받아 특징을 추출하는 계층들을 포함한다. 이후 상호연관(correlation) 계층은 각 프레임의 특징들을 입력받아 모든 특징 벡터 쌍들에 대한 내적 연산을 하여 4D 상호연관 볼륨(correlation volume)을 생성한다. 컨텍스트 인코더는 시간 t의 프레임을 입력받아 영상에 존재하는 객체에 대한 정보를 산출한다. 이후 GRU는 반복적으로 앞서 구한 흐름(flow), 현재 특징 벡터 정보 및 컨텍스트 정보를 입력받아 광학 흐름을 갱신하여 산출한다.
- [0049] 광학 흐름 예측 모델은 사전에 학습되어야 한다. 학습 데이터 세트는 와이퍼 폐색 영상으로 구성되어야 하는데, 관련된 연구가 없었기 때문에 공개된 와이퍼 폐색 영상은 많지 않았다. 이에 연구자는 차량 환경의 영상을 수집하고, 영상의 다양성 부가를 위하여 종전 공개 데이터 세트에 와이퍼 데이터를 합성하는 방식으로 학습 데이터 세트를 구축하였다. 학습 과정은 전술한 영상 처리 장치가 아닌 별도의 학습 장치에서 수행될 수 있다. 학습 장치는 영상 처리 및 모델 학습이 가능한 컴퓨터 장치를 의미한다.
- [0050] 도 4는 광학 흐름 예측 모델의 학습 과정(300)에 대한 예이다. 연구자(개발자)는 우천 환경에서 차량 주행 영상을 수집한다(310). 수집한 영상은 우천 환경에서 와이퍼가 동작하는 장면을 포함한다. 연구자는 다양한 환경에서 우천시 주행하는 차량의 영상을 수집할 수 있다.
- [0051] 학습장치는 수집한 차량 주행 영상을 입력받는다. 학습장치는 수집한 차량 주행 영상에서 와이퍼 데이터를 추출할 수 있다(320). 학습장치는 소위 자동 라벨링(auto-labeling)을 이용하여 영상에서 와이퍼 영상 및 흐름 데이터를 추출할 수 있다. 연구자도 자동 라벨링을 이용하여 와이퍼 데이터를 추출하였다. 한편, 자동 라벨링이 아닌 수작업으로 와이퍼 데이터가 추출될 수도 있다. 이 경우 학습장치는 수작업으로 추출된 와이퍼 데이터를 이용하면 된다.
- [0052] 학습장치는 종전 광학 흐름 데이터 세트에 와이퍼 데이터를 합성하여 합성 데이터를 생성한다(330). 생성된 합성 데이터가 최종적인 학습 데이터가 된다. 종전 광학 흐름 데이터 세트는 모델 학습을 위해 공개된 데이터 세트일 수 있다. 학습장치는 추출한 와이퍼 영상 및 흐름 데이터를 다양한 조합으로 샘플링할 수 있다. 학습장치는 샘플링한 와이퍼 영상 및 흐름 데이터를 종전 광학 데이터 세트에 합성할 수 있다.
- [0053] 학습장치는 마련된 학습 데이터를 이용하여 광학 흐름 예측 모델을 학습시킨다(340).
- [0054] 도 4는 다양한 시나리오에 따라 와이퍼 영상을 샘플링하여 가상의 학습 데이터를 이용한 예이다. 이에 반하여, 광학 흐름 추출이 가능한 대량의 와이퍼 폐색 영상이 구비된 경우, 학습 장치는 가상의 데이터를 이용하지 않고 진성 데이터를 이용하여 광학 흐름 예측 모델을 학습할 수도 있다.
- [0056] 도 5는 자동 라벨링을 통한 와이퍼 유사-정답 데이터 (pseudo-ground truth)를 추출하는 개념도의 예이다.
- [0057] 자동 라벨링(auto-labeling)은 별도의 딥 러닝 기반 광학 흐름 모델이 사용될 수 있다. 예를 들어, 학습장치는 딥러닝 기반 광학 흐름 모델을 사용하여 입력 이미지 데이터에 대한 추론을 수행하여 라벨링을 할 수 있다.
- [0058] 자동 라벨링을 위해, 광학 흐름 임계 값을 이용한 하이패스 필터(High-pass filter with optical flow magnitude threshold)의 개념이 사용될 수 있다. 예를 들어, 학습장치는 이미지의 광학 흐름 크기를 임계 값으로 필터링하여, 와이퍼 객체에 해당되는 픽셀을 추출할 수 있다. 자동 라벨링은 수작업을 통한 주석(annotation) 보다 효율적으로, 다량의 데이터를 빠르게 생성할 수 있다.
- [0059] 학습장치는 최종적으로 추출한 결과물을 유사-정답으로 분류하고, 광학 흐름 데이터 세트에 합성하여 광학 흐름 예측 모델을 위한 정답 데이터로 활용할 수 있다.
- [0061] 영상 처리 장치는 다양한 방법론 중 어느 하나를 이용하여 와이퍼 폐색 영상을 복원할 수 있다. 예컨대, 영상 처리 장치가 일반적인 영상 처리 기법을 이용하여 와이퍼 폐색 영상을 복원하는 과정을 설명한다. 영상 처리 장치는 와이퍼 폐색 영역이 있는 시간 t+1 타깃 영상을 시간 t의 참조 영상을 이용하여 복원한다고 가정한다. 영상 처리 장치는 생성한 이진 와이퍼 마스크를 이용하여 와이퍼 폐색 영역이 있는 타깃 영상에서 와이퍼 폐색 영역을 제거할 수 있다. 이후 영상 처리 장치는 타깃 영상의 와이퍼 폐색 영역을 다른 프레임의 영상의 정보를 이

용하여 복원할 수 있다. 타깃 영상의 와이퍼 폐색 영역을 복원하는데 참조가 되는 영상을 참조 영상이라고 명명한다. 예컨대, 영상 처리 장치는 시간 t 의 참조 영상에서 시간 $t+1$ 타깃 영상의 와이퍼 폐색 영역과 동일한 영역을 추출하고, 타깃 영상의 와이퍼 폐색 영역을 대체할 수 있다. 또는, 영상 처리 장치는 $t+1$ 시간과 가장 가까우며 와이퍼 폐색 영역이 없는 영상을 참조 영상으로 이용할 수 있다. 예컨대, 영상 처리 장치는 $t+2$ 시간의 영상을 참조 영상으로 이용할 수도 있다. 나아가 영상 처리 장치는 타깃 영상에서 와이퍼 폐색 영역을 제외한 주변 영상 정보를 더 이용하여 와이퍼 폐색 영역을 복원할 수도 있다. 이때 타깃 영상에서 와이퍼 폐색 영역과 주변 영역에 일정한 경계가 생길 수 있는데, 영상 처리 장치는 보간과 같은 영상 처리 기술을 이용하여 영상을 보정할 수 있다.

[0062] 연구자는 이진 마스크와 광학 흐름을 예측할 수 있는 연속된 영상들을 입력받아 이진 마스크 영역을 복원하는 별도의 신경망 모델을 이용하였다. 와이퍼 폐색 영상을 복원하는 모델은 영상 복원 모델이라고 명명한다.

[0063] 도 6은 영상 복원 모델을 이용하여 와이퍼 폐색 영상을 복원하는 과정에 대한 예이다.

[0064] 먼저, 전술한 광학 흐름 예측 모델을 이용하여 이진 와이퍼 마스크가 생성되었다고 전제한다. 광학 흐름 예측 모델은 광학 흐름이 설정한 임계값을 넘지 못하면 모든 값이 0(검정)인 마스크를 생성하고, 광학 흐름이 설정한 임계값을 초과하는 경우 모든 값이 1(흰색)인 마스크를 생성할 수 있다. 여기서 임계값은 와이퍼 동작을 식별할 수 있는 적절한 값이 사용될 수 있다. 나아가, 임계값은 와이퍼의 속도에 따라 적응적으로 결정될 수도 있다. 영상 복원 모델은 마스크가 흰색인 경우에만 해당 영역을 복원 대상으로 삼아 복원할 수 있다.

[0065] 영상 처리 장치는 시간 흐름 순서에 따라 순차적인 영상들을 입력받는다. 순차적인 영상들 중 일부는 와이퍼 폐색 영역이 없는 영상 A이고 이 영상을 영상 복원을 위한 참조 영상으로 이용될 수 있다. 또한, 순차적인 영상들 중 일부는 와이퍼 폐색 영역이 있는 타깃 영상 B이다. B는 와이퍼 폐색 영역이 있어 객체 감지가 어려운 상태이다.

[0066] 영상 처리 장치는 순차적인 영상들 A 및 B를 전술한 광학 흐름 예측 모델에 입력하여 이진 와이퍼 마스크 C 및 흐름 데이터를 생성할 수 있다.

[0067] 영상 처리 장치는 참조 영상 A, 타깃 영상 B 및 이진 와이퍼 마스크 C를 영상 복원 모델에 입력하여 와이퍼 폐색 영상 B를 복원할 수 있다. 이때 영상 복원 모델은 이진 와이퍼 마스크를 이용하여 복원 대상 영상에서 해당 영역을 제거한다. 이후 영상 복원 모델은 제거된 영역을 참조 영상을 참고하여 복원하게 된다.

[0068] 영상 복원 모델은 다양한 모델 중 어느 하나가 활용될 수도 있다. 연구자는 종전 연구된 FGVC(flow-based video completion application) 모델(Gao, C.; Saraf, A.; Huang, J.B.; Kopf, J. Flow-edge guided video completion. European Conference on Computer Vision. Springer, 2020, pp. 713-29.) 이용하였다. FGVC 모델은 RAFT를 이용하여 광학 흐름을 추정하고, 영상 복원에 복원 영역에 대한 이진 마스크를 필요로 한다.

[0070] 이하 연구자가 구축한 광학 흐름 예측 모델 및 영상 복원 모델을 이용하여 와이퍼 폐색 영상을 복원한 결과를 설명한다. 아래 표 1은 연구자가 구축한 광학 흐름 예측 모델에 대한 학습 정보를 나타낸다.

표 1

Schedule	Dataset	#Iterations	Batch size	Crop size	Learning rate	Weight decay
1	FlyingChairs	100k	12	386 × 496	0.0004	0.0001
2	FlyingThings3D	100k	6	400 × 720	0.000125	0.0001
3	SintelWipers	100k	6	368 × 768	0.000125	0.00001

[0071]

[0073] 광학 흐름 예측 모델에서는 벡터 크기 임계값을 25.0로 설정하였다. 다만, 전술한 바와 같이 해당 모델에 대한 임계값은 실험을 통하여 결정될 수도 있다.

[0074] 본 발명의 몇몇 실시예에 따른 광학 흐름 예측 모델을 정량적으로 평가하기 위해 SSIM(Structural similarity Index Measure) 및 Binary Classification(BC)이 사용될 수 있다. 예를 들어, 본 발명의 몇몇 실시예에 따른 광학 흐름 예측 모델에서 (1) 바이너리 와이퍼 마스크 감지(WMD)의 픽셀 단위 일치 정확도 및 이미지 유사성 및 (2) 와이퍼 장면 감지(WSD)의 정확도가 평가될 수 있다.

[0075] 한편, 하나의 객체 클래스가 전체 집합의 17.1%(8,472,972픽셀)를 차지하기 때문에 데이터가 불균형하다고 볼 수 있다. 따라서, 이진 분류의 F1 점수는 객관적인 지표로 간주될 수 있다. 참 양성(TP, true positive), 거짓

음성(FN, false negative) 및 거짓 양성(FP, false positive)으로 계산된 재현율 및 정밀도의 조화 평균이기 때문이다.

[0076] F1 점수는 아래의 식 (1)에 따라 계산될 수 있다.

$$Precision = \frac{TP}{TP + FP}, Recall = \frac{TP}{TP + FN}, F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (1)$$

[0078] 이하에서 본 발명의 몇몇 실시예에 따른 와이퍼 폐색 감지 및 와이퍼 제거 이미지 복원 방법에 대한 정량적 평가에 대해 설명한다.

[0079] 표 2는 모델 측면에서 SSIM 및 이진 분류(와이퍼 마스크 및 장면 감지)에 대한 측정 결과를 나타낸다. 표 2에서 BTS는 전술한 광학 흐름 예측 모델을 나타낸다. BTS(Behind-the-scenes)는 연구자가 구축한 모델을 명명한 것이다.

표 2

Model	Dataset	Wiper Mask Detection (WMD)					Wiper Scene Detection (WSD)		
		SSIM		Binary Classification			Binary Classification		
		Average	Std. Dev.	Precision	Recall	F1 score	Precision	Recall	F1 score
raft-chairs	C	0.833	0.112	63.4	13.7	22.5	74.5	25.6	38.1
raft-things	C+T	0.937	0.087	88.3	76.9	82.2	76.8	85.0	80.7
raft-sintel	C+T+S	0.934	0.094	92.8	71.6	80.8	73.6	84.7	78.8
raft-kitti	C+T+S/K	0.884	0.079	75.7	53.7	62.8	68.9	73.0	70.9
BTS	C+T+Sw	0.962	0.027	87.6	96.0	91.6	87.4	89.2	88.3
BTS-kitti	C+T+Sw/K	0.890	0.075	68.8	79.4	72.5	85.8	84.1	84.9

Datasets: FlyingChairs (C), FlyingThings3D (T), Sintel (S), KITTI (K), SintelWipers (Sw)

[0080]

[0081] 표 2를 참조하면, 본 발명의 몇몇 실시예에 따른 광학 흐름 예측 모델은, 초당 15프레임을 생성하는 과정에서, SSIM 및 이진 분류 평가 모두에 대해 다른 모델들 보다 높은 성능을 갖는다는 것을 볼 수 있다.

[0082] 예를 들어, 평균 SSIM 0.962 및 표준편차 0.027라는 결과에 비추어 보면, 휘도, 대비, 및 구조와 관련하여, 전체 결과는 정답(ground truth)과 유사하다는 것을 볼 수 있다.

[0083] 또한, 가장 높은 조화 평균 F1 점수는 모델이 정밀도(precision)와 재현율(recall)에서 균형을 이루는 정도를 나타낼 수 있다.

[0084] 표 3은 원본 광학 흐름 데이터 세트에 대한 끝점 오류(EPE, end-point-error)의 실험 결과를 나타낸다.

표 3

Model	Sintel (train)		KITTI 2015 (train)	
	Clean	Final	F1-epe	F1-all
raft-chairs	2.24	4.51	9.85	37.6
raft-things	1.46	2.78	5.00	17.4
raft-sintel	0.75	1.22	1.21	5.6
raft-kitti	4.55	6.15	0.63	1.5
BTS	0.93	1.49	4.37	13.5
BTS-kitti	5.41	6.68	0.67	1.7

[0085]

[0086] 표 3을 참조하면, 본 발명에 따른 모델은 raft-kitti와 동일한 훈련 일정을 기반으로 KITTI 데이터 세트에 의해서 미세 조정됨으로써, raft-kitti에 비해 크게 향상된 미세 조정 결과를 갖는다는 것을 알 수 있다.

[0087] Raft-chairs는 최악의 점수를 받았고 도메인 불일치를 극복하지 못한 것을 볼 수 있다. 이는, 해당 모델이 대상 개체와 다른 비현실적이고 꾸준한 움직이는 합성 개체로 훈련되었기 때문이다. 반면에, 더 복잡하고 다양한 3D 개체로 훈련된 raft-things는 실제 영역에 적응하여 +10.4%p SSIM, +59.7%p F1-WMD 및 +42.6%p F1-WSD와 같이 크게 개선된 성능을 갖는 것을 볼 수 있다.

- [0088] raft-sintel은 합성 데이터의 동적이고, 다양하고, 순차적인 프레임으로 더 많이 훈련되었지만 성능이 저하된 것을 볼 수 있다. 반면에, KITTI 기반으로 주행환경에 의해 미세 조정된 모델은 F1-WMD가 -18%p 된 성능을 갖는 것을 볼 수 있다.
- [0089] 그러나, Sintel을 미세 조정을 위해 생성된 합성 데이터 세트로 대체함으로써, SintelWiper는 Raft-관련 모델과 비교하여 +10.8% F1-WMD 및 +7.6% F1-WSD의 성능을 갖는 것을 볼 수 있다. 따라서, SintelWiper는 본 발명에 따른 모델을 훨씬 더 정확하고 균형 있게 만들었다는 것을 볼 수 있다.
- [0090] 본 발명에 따른 광학 흐름 예측 모델은, WMD와 WSD의 기억력을 크게 향상시켜 더 높은 F1 점수를 달성한 것을 볼 수 있다. 다시 말하면, BTS는 다른 모델이 놓친 와이퍼의 픽셀, 특히 종료 상태의 와이퍼를 감지할 수 있고, 이와 같은 유리한 효과는 정성적 결과로 볼 수 있다.
- [0091] 또한, 원본 데이터 세트와 관련하여, 광학 흐름 예측 모델의 광학 흐름 추정 EPE 오류는 +0.27% 미만인 것을 볼 수 있다. 이는, 즉 영상 복원 모델은 허용 가능한 EPE 오류를 갖는다는 것을 볼 수 있다.
- [0092] 이와 같이, 본 발명에 따른 광학 흐름 예측 모델은 광학 흐름과 와이퍼 데이터 세트를 생성하는데 적합하다는 것을 볼 수 있다.
- [0093] 표 4는 다양한 데이터 합성 시나리오로 미세 조정된 RAFT-들의 결과를 나타낸다.

표 4

Proportion	Method	Wiper Mask Detection (WMD)					Wiper Scene Detection (WSD)		
		SSIM		Binary Classification			Binary Classification		
		Average	Std. Dev.	Precision	Recall	F1	Precision	Recall	F1
Partial	Orig. Sintel	0.934	0.094	92.8	71.6	80.8	73.6	84.7	78.8
	Single seq.	0.922	0.095	93.4	62.9	75.2	71.8	76.5	74.1
	Single end.	0.938	0.070	92.4	74.1	82.2	95.2	76.0	84.5
Complete	Sequential	0.953	0.045	0.886	87.7	88.1	90.8	80.1	85.1
	Random	0.956	0.032	0.879	90.5	89.2	91.3	82.6	86.7
	Rand. Seq.	0.962	0.027	0.876	96.0	91.6	87.4	89.2	88.3

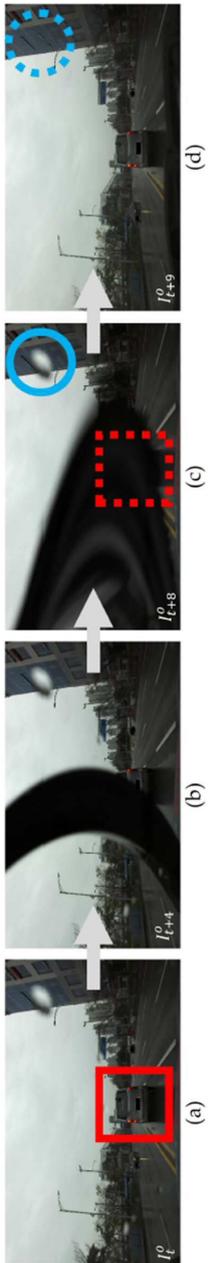
Reference model: raft-sintel (original Sintel), raft-things + synthesized Sintel with scenarios

- [0094] 표 4를 참조하면, 시작, 반환, 및 종료 상태의 조합을 사용한 데이터 합성과 관련된, 다양한 샘플링 시나리오에 의한 영향이 설명된다.
- [0095] 예를 들어, 합성의 부분 비율과 합성의 완전한 비율을 비교함으로써, 더 많은 데이터가 본 발명에 따른 모델의 성능을 향상시킨 것을 볼 수 있다.
- [0096] 또한, 단일 시퀀스는 원본 데이터에 아무것도 적용하지 않는 것에 비해 성능을 악화시키는 효과를 갖는다는 것을 볼 수 있다.
- [0097] 표 4의 결과에 따르면, 순차 프레임 샘플링은 일반적으로 88.1% F1-WMD의 균형 정밀도를 유지하고, 재현율을 향상시키는 데 도움이 된다는 것을 볼 수 있다.
- [0098] 무작위 샘플링은 F1-WMD가 +1.1%p 더 높은 점수를 얻기 위해 약간 더 많은 와이퍼 픽셀을 예측했다는 것을 볼 수 있다.
- [0099] 따라서, 본 발명의 몇몇 실시예에 따른 광학 흐름 예측 모델은 순차 및 무작위 샘플링 조합을 활용하여 0.926 SSIM, 91.6% F1-WMD 및 88.3% F1-WSD와 같은 최상의 성능을 갖는다는 것을 볼 수 있다.
- [0100] 도 7은 광학 흐름 예측 모델영상 복원 모델을 이용하여 이미지 복원 결과 및 효과를 비교하는 예이다. 도 7(a)는 원본 이미지를 나타낸다. 도 7(b)는 raft-thing으로 만든 마스크로 복원된 결과를 나타낸다. 도 7(c)는 raft-things와 와이퍼 폐색 복원 모델 사이의 비교 결과를 나타낸다. 도 7(d)는 본 발명의 몇몇 실시예에 따른 와이퍼 폐색 복원 모델로 만든 마스크로 복원한 결과를 나타낸다.
- [0101] 도 7은 마스크 정확도의 중요성을 보여준다. 예를 들어, 도 8(c)에서 파란색 박스로 표시된 왜곡된 건물(제1 행 및 제2 행), 반사된 물체(제3 행), 및 흐릿한 차량 바퀴(제4 행)와 같은 복원된 영역을 보았을 때, 마스크 정확도의 중요성을 알 수 있다.

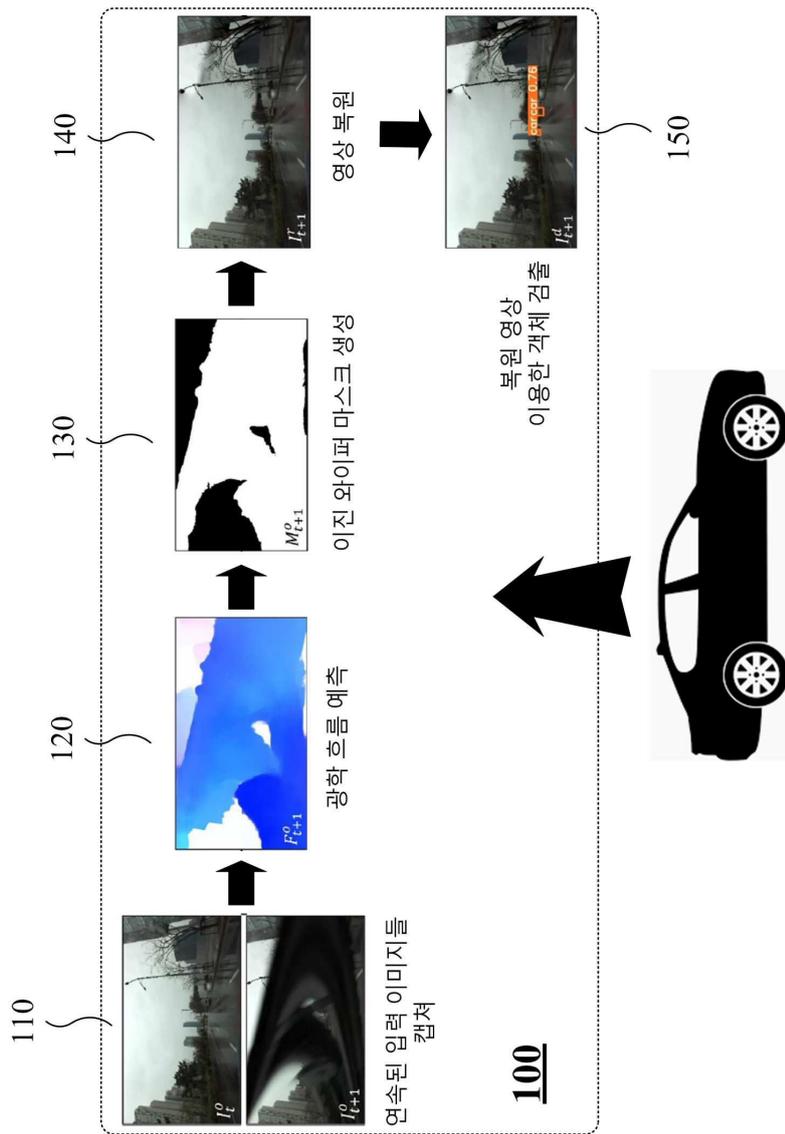
- [0104] 도 7에서는, raft-things 및 와이퍼 폐색 복원 모델로부터 생성된 이진 마스크를 사용하여, 복원할 대상 영역을 할당하는 정확한 이진 마스크의 효율성이 비교되었다.
- [0105] 도 7에서, 와이퍼는 장면에서 차량, 교통 표지판, 및 도로 특징과 같은 물체의 의미 있는 픽셀을 가린 것을 볼 수 있다.
- [0106] raft-things을 활용한 이미지 복원 결과는 인공물(artifacts)을 포함한다는 것을 볼 수 있다. 반면에, 본 발명의 몇몇 실시예에 따른 와이퍼 폐색 복원 모델을 활용한 이미지 복원 결과는 인공물을 포함하지 않고 원본 이미지와 유사한 것을 볼 수 있다.
- [0107] 이와 같이, 본 발명의 몇몇 실시예에 따른 와이퍼 폐색 복원 모델은 건물 벽 및 표지판의 복원을 위해 정확한 타겟 마스크를 할당하여, 미러링 및 흐릿한 차량 바퀴와 같은 인공물이 생성되는 것을 방지할 수 있다. 따라서, 본 발명의 몇몇 실시예에 따른 광학 흐름 예측 모델에 따르면 선명한 복원 결과를 생성하여, 정확한 지역 정보를 안내할 수 있다.
- [0108] 나아가, 본 발명의 와이퍼 광학 흐름 예측 모델을 이용한 이미지 복원 방법에 따르면, 썸 뒤에 있었던 차량 및 도로 특징과 같은 객체를 시각화함으로써, 와이퍼 폐색 영역이 있는 모든 이미지를 사용할 수 있다. 이 경우, 복원된 이미지는 물체 감지와 같은 ADAS 작업을 위한 입력 데이터로 사용될 수 있다.
- [0110] 이하에서는, 본 발명의 몇몇 실시예에 따른 물체 감지 (objection detection) 방법에 대해 설명한다.
- [0111] 도 8은 복원한 영상을 이용한 물체 감지 결과 및 성능 개선 효과를 비교하는 예이다. 도 8(a)는 원본 이미지 시퀀스를 나타낸다. 도 8(b)는 이미지 복원 전 물체 감지 결과를 나타낸다. 도 8(c)는 결과 비교 결과를 나타낸다. 도 8(d)는 이미지 복원 후 물체 감지 결과를 나타낸다. 도 8에서 와이퍼는 정면 물체를 자르거나 가리려, 잘못된 물체 감지 결과를 야기시킬 수 있다. 연구자는 FGVC와 와이퍼 폐색 복원 모델에서 생성된 복원 이미지를 사용하여, YOLOv4를 테스트가 수행하였다. 도 8(b)를 참조하면, 네트워크는 와이퍼를 사용하여 원본 이미지로 잘리거나 가려진 차량을 감지하는데 어려움을 겪을 수 있다. 잘린 객체는 신뢰도가 낮거나 두 개 이상의 경계 상자에 예측될 수 있다. 그러나 가려진 객체는 감지할 기회가 없을 수 있다. 경계 상자는 개체의 신뢰도, 위치, 크기, 수, 및 존재에 관한 핵심 정보를 제공하기 때문에, 잘못된 탐지 결과는 ADAS의 부정확한 결정을 야기시키고, 따라서 안전이 위협될 수 있다. 그러나, 도 8(d)를 참조하면, 와이퍼 폐색이 복원된 영상은 잘리고 가려진 물체가 정확하게 감지된 것을 볼 수 있다. 결과적으로 와이퍼 폐색 영상 복원은 ACC, AEB와 같은 횡방향 및 종방향 제어를 향상시킬 수 있다.
- [0113] 또한, 상술한 바와 같은 광학 흐름 예측 모델 학습 방법 및 와이퍼 폐색 영역 영상 복원 방법은 컴퓨터에서 실행될 수 있는 실행 가능한 알고리즘을 포함하는 프로그램(또는 어플리케이션)으로 구현될 수 있다. 상기 프로그램은 일시적 또는 비 일시적 판독 가능 매체(non-transitory computer readable medium)에 저장되어 제공될 수 있다.
- [0114] 비 일시적 판독 가능 매체란 레지스터, 캐시, 메모리 등과 같이 짧은 순간 동안 데이터를 저장하는 매체가 아니라 반영구적으로 데이터를 저장하며, 기기에 의해 판독(reading)이 가능한 매체를 의미한다. 구체적으로는, 상술한 다양한 어플리케이션 또는 프로그램들은 CD, DVD, 하드 디스크, 블루레이 디스크, USB, 메모리카드, ROM (read-only memory), PROM (programmable read only memory), EPROM(Erasable PROM, EPROM) 또는 EEPROM(Electrically EPROM) 또는 플래시 메모리 등과 같은 비일시적 판독 가능 매체에 저장되어 제공될 수 있다.
- [0115] 일시적 판독 가능 매체는 스태틱 램(Static RAM, SRAM), 다이내믹 램(Dynamic RAM, DRAM), 싱크로너스 디램(Synchronous DRAM, SDRAM), 2배속 SDRAM(Double Data Rate SDRAM, DDR SDRAM), 증강형 SDRAM(Enhanced SDRAM, ESDRAM), 동기화 DRAM(Synclink DRAM, SLDRAM) 및 직접 램버스 램(Direct Rambus RAM, DRRAM) 과 같은 다양한 RAM을 의미한다.
- [0116] 본 실시예 및 본 명세서에 첨부된 도면은 전술한 기술에 포함되는 기술적 사상의 일부를 명확하게 나타내고 있는 것에 불과하며, 전술한 기술의 명세서 및 도면에 포함된 기술적 사상의 범위 내에서 당업자가 용이하게 유추할 수 있는 변형 예와 구체적인 실시예는 모두 전술한 기술의 권리범위에 포함되는 것이 자명하다고 할 것이다.

도면

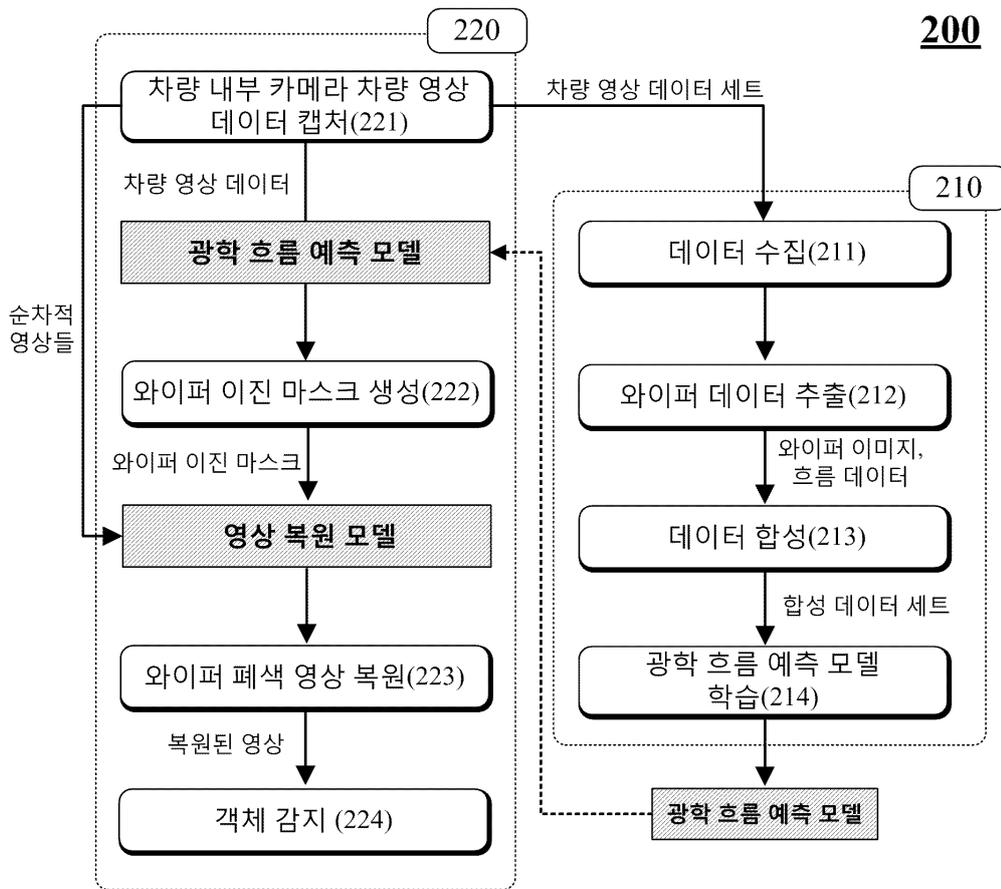
도면1



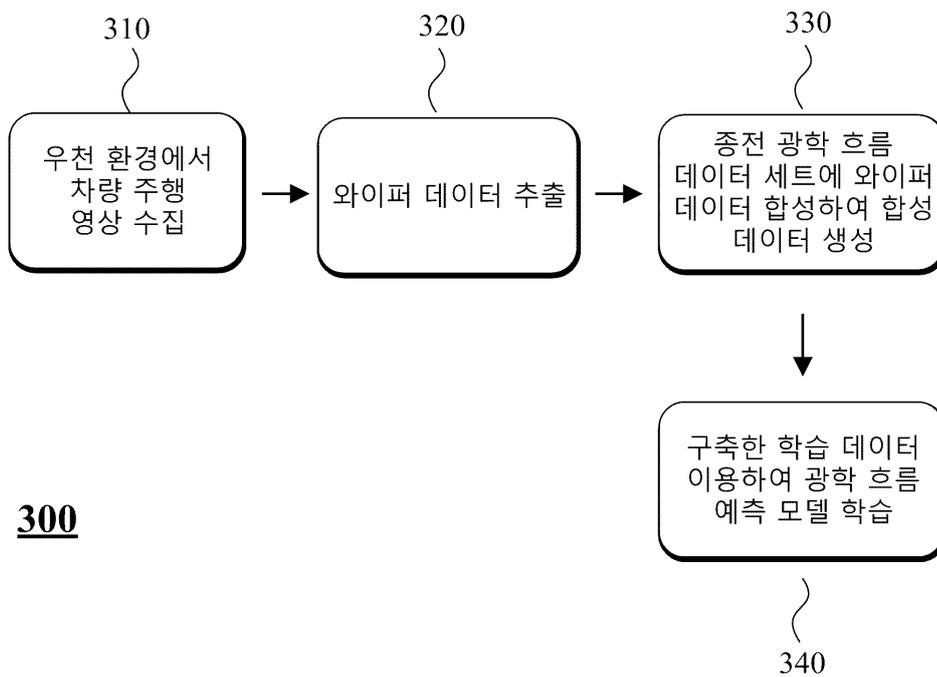
도면2



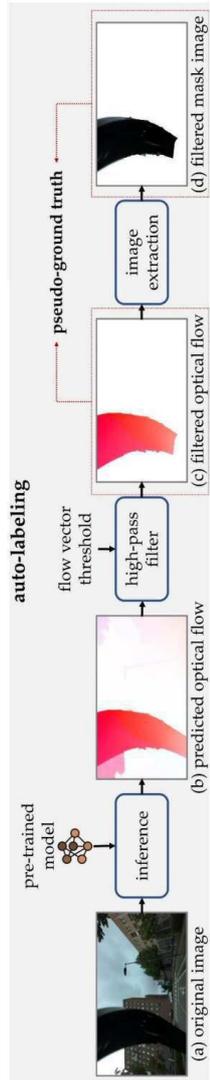
도면3



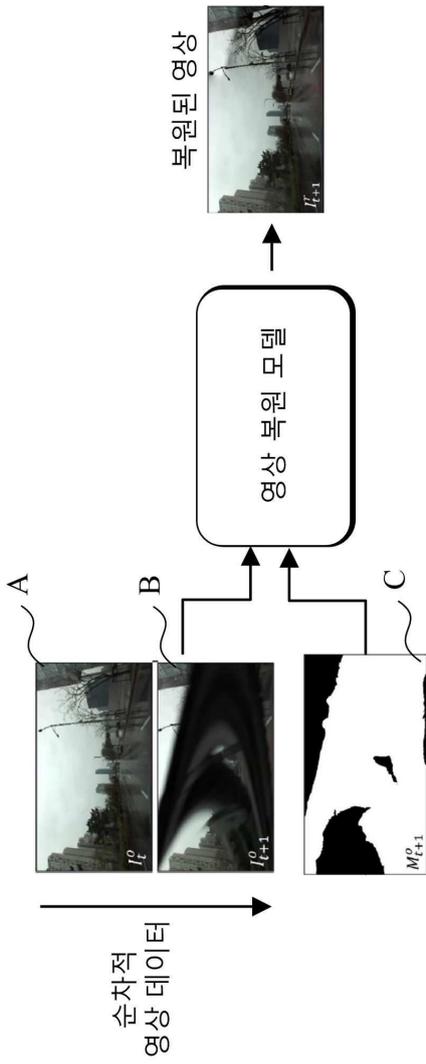
도면4



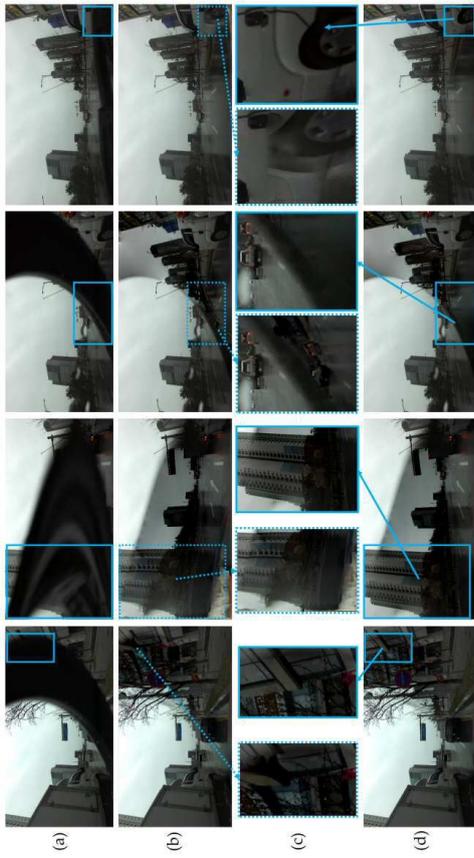
도면5



도면6



도면7



도면8

