



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0000658
(43) 공개일자 2024년01월02일

- (51) 국제특허분류(Int. Cl.)
G06V 20/56 (2022.01) G05D 1/02 (2020.01)
G06N 20/00 (2019.01)
- (52) CPC특허분류
G05D 1/0214 (2013.01)
G05D 1/0221 (2013.01)
- (21) 출원번호 10-2023-7044250(분할)
- (22) 출원일자(국제) 2023년01월28일
심사청구일자 없음
- (62) 원출원 특허 10-2021-7026372
원출원일자(국제) 2020년01월28일
심사청구일자 2023년01월11일
- (85) 번역문제출일자 2023년12월21일
- (86) 국제출원번호 PCT/US2020/015383
- (87) 국제공개번호 WO 2020/159968
국제공개일자 2020년08월06일
- (30) 우선권주장
16/265,720 2019년02월01일 미국(US)

- (71) 출원인
테슬라, 인크.
미국 텍사스 78725 오스틴 테슬라 로드 1
- (72) 발명자
엘러스위미, 아쇼크 쿠마르
미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내
바우치, 매튜
미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내
(뒷면에 계속)
- (74) 대리인
특허법인 무한


전체 청구항 수 : 총 1 항

(54) 발명의 명칭 자율 주행을 위한 3차원 특징 예측

(57) 요약

메모리(memory)와 결합한 프로세서(processor)는 차량의 카메라에 의해 캡처된 이미지에 기초하는 이미지 데이터(image data)를 수신(receive)하도록 구성된다. 이미지 데이터는 머신 러닝 특징(machine learning feature)의 3차원 궤적을 예측(predict)하기 위해 훈련된, 훈련된 머신 러닝 모델(trained machine learning model)에 대해 입력의 기초로 사용(use)된다. 머신 러닝 특징의 3차원 궤적(three-dimensional trajectory)은 자동으로 차량을 제어하기 위해 제공(provide)된다.

대표도 - 도2



(52) CPC특허분류

G05D 1/0223 (2013.01)

G05D 1/0231 (2013.01)

G06N 20/00 (2021.08)

G06T 2207/20076 (2013.01)

G06T 2207/20081 (2013.01)

G06T 2207/20084 (2013.01)

(72) 발명자

페인, 크리스토퍼

미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내

카르파티, 앙드레즈

미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내

쉬로프, 드하발

미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내

라마난단, 아르빈드

미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내

하케윌, 제임스 로버트 하워드

미국 캘리포니아 94304 팔로 알토 디어 크릭 로드
3500 테슬라, 인크. 내

명세서

청구범위

청구항 1

시스템에 있어서,
 프로세서를 포함하고,
 상기 프로세서는,
 차량의 카메라에 의해 캡처된 이미지에 기초하는 이미지 데이터를 수신하고,
 머신 러닝 특징의 3차원 궤적을 예측하도록 훈련된, 훈련된 머신 러닝 모델에 대한 입력의 기초로 상기 이미지 데이터를 사용하고,
 차량을 자동으로 제어할 때 상기 머신 러닝 특징의 상기 3차원 궤적을 제공하도록 구성된,
 시스템.

발명의 설명

기술분야

[0001] 본 출원은, 2019년 2월 1일에 출원되고 발명의 명칭이 "자율 주행을 위한 3차원 특징 예측(PREDICTING THREE-DIMENSIONAL FEATURES FOR AUTONOMOUS DRIVING)"인 미국특허출원 제16/265,720호를 우선권주장하고, 이것의 계속출원이며, 상기 미국특허출원의 개시는, 전체적으로 본 출원에 참조로서 포함된다.

배경기술

[0002] 자율 주행(autonomous driving)과 같은 어플리케이션(application)에 사용되는 딥 러닝 시스템(deep learning system)은 머신 러닝 모델(machine learning model)을 훈련함으로써 개발된다. 일반적으로, 딥 러닝 시스템의 성능은 모델을 훈련하는데 사용되는 트레이닝 세트(training set)의 품질에 의해 적어도 부분적으로 제한된다. 여러 경우에서, 상당한 리소스(resource)가 트레이닝 데이터(training data)를 수집(collecting), 큐레이팅(curating) 및 주석 처리(annotating)하는데 투자(invest)된다. 전통적으로, 트레이닝 데이터 세트(training data set)를 큐레이트(curate)하기 위하여, 잠재적 트레이닝 데이터를 검토(reviewing)하고 데이터와 관련된 기능에 적절하게 레이블링(labeling)함으로써, 많은 노력들이 수동으로 수행된다. 정확한 레이블(label)이 있는 트레이닝 세트를 만드는데 요구되는 노력은 상당하고 종종 지루할 수 있다. 더욱이, 머신 러닝 모델을 개선하기 위해 필요한 데이터를 수집하고 정확하게 레이블을 지정하는 것이 종종 어려울 수 있다. 따라서, 정확한 레이블된 특징을 갖는 트레이닝 데이터를 생성하기 위한 프로세스(process)를 개선할 필요가 존재한다.

발명의 내용

[0003] 고도로 정확한 머신 러닝(machine learning) 결과를 생성하기 위한 머신 러닝 트레이닝 기술(machine learning training technique)이 개시(disclose)된다. 차량의 환경(environment of vehicle) 및 차량 작동 매개변수(vehicle operating parameter)를 캡처(capture)하기 위해 차량의 센서(sensor)에 의해 캡처된 데이터를 사용하여, 트레이닝 데이터 세트(training data set)가 생성(create)된다. 예를 들어, 차량에 부착된 센서는 차량이 주행중인 도로 및 주변 환경의 이미지 데이터와 같은 데이터를 캡처한다. 센서 데이터는 차량 차선 경계선(vehicle lane line), 차량 차선(vehicle lane), 다른 차량 교통(other vehicle traffic), 장애물(obstacles), 교통 통제 표지판(traffic control signs) 등을 캡처할 수 있다. 주행 거리 측정(odometry) 및 다른 비슷한 센서는 차량 속도(vehicle speed), 조종(steering), 방향(orientation), 방향(direction) 변경, 위치(location) 변경, 고도(elevation) 변경, 속도(speed) 변경 등과 같은 차량 작동 매개변수를 캡처한다. 캡처된 데이터 세트는 트레이닝 데이터 세트를 생성하기 위해 트레이닝 서버(training server)에 전송된다. 트레이닝 데이터 세트는 고도로 정확한 머신 러닝 결과 생성을 위한 머신 러닝 모델을 훈련하기 위해 사용된다. 일부 실시예에서, 캡처된 데이터의 시계열은 트레이닝 데이터를 생성하기 위해 사용된다. 예를 들어, 그라운드 트루스(ground truth

h)는 시계열 요소들 그룹(group of time series elements)에 기초하여 결정되고 그룹의 단일 요소와 연결(associate)된다. 일례로, 30초와 같은 일정 기간(time period) 동안의 일련의 이미지는, 차량이 이동(travel)하는 일정 기간에 걸쳐서 차량 차선 경계선(vehicle lane line)의 실제 경로를 결정하는데 사용된다. 차량 차선 경계선은 일정 기간 동안 가장 정확한 차량 차선 이미지를 사용하여 결정된다. 차선 경계선의 다른 부분(different portions)(또는 위치)은 시계열의 다른 이미지 데이터에서 식별될 수 있다. 차량이 차선 경계선을 따라 차선을 이동할 때, 차선 경계선의 다른 부분에 대한 더 정확한 데이터가 캡처된다. 일부 예에서, 차선 경계선의 가려진(occluded) 부분은, 예를 들어 차량이 숨겨진 곡선 또는 언덕의 능선을 따라 이동할 때 드러난다. 시계열의 각 이미지로부터 차선 경계선의 가장 정확한 부분은 이미지 데이터의 전체 그룹에 대한 차선 경계선을 식별하는데 사용될 수 있다. 거리(distance)에 있는 차선 경계선의 이미지 데이터(image data)는 일반적으로 차량 근처 차선 경계선의 이미지 데이터보다 덜 상세하다. 차량이 차선을 따라 이동할 때 이미지 데이터의 시계열을 캡처함으로써, 해당 차선의 모든 부분에 대한 정확한 이미지 데이터와 해당 주행 거리 측정 데이터(odometry data)가 수집(collect)된다.

- [0004] 일 실시예에 따른 시스템은, 프로세서, 및 상기 프로세서에 결합되고 상기 프로세서에 명령어를 제공하도록 구성된 메모리를 포함할 수 있다. 상기 프로세서는, 차량의 카메라에 의해 캡처된 이미지에 기초하는 이미지 데이터를 수신하고, 머신 러닝 특징의 3차원 궤적을 예측도록 훈련된, 훈련된 머신 러닝 모델에 대한 입력의 기초로 상기 이미지 데이터 사용하고, 차량을 자동으로 제어할 때 상기 머신 러닝 특징의 상기 3차원 궤적을 제공하도록 구성될 수 있다.
- [0005] 상기 머신 러닝 특징은, 차량 차선 경계선과 연관될 수 있다.
- [0006] 상기 차량 차선 경계선의 상기 3차원 궤적의 부분은, 상기 이미지 데이터에서 가려질 수 있다.
- [0007] 상기 프로세서는, 상기 차량에 의해 점유된 차량 차선을 식별하기 위해, 상기 차량 차선 경계선을 사용하도록 더 구성될 수 있다.
- [0008] 상기 차량 차선은, 주행가능 공간을 식별하기 위해 사용될 수 있다.
- [0009] 상기 식별된 주행가능 공간은, 상기 차량을 상기 차량 차선에 유지하도록 하기 위해 사용될 수 있다.
- [0010] 상기 차량의 상기 카메라는, 전방 카메라, 측방 카메라, 또는 후방 카메라 중 적어도 하나를 포함할 수 있다.
- [0011] 상기 예측된 3차원 궤적은, 복수의 식별된 잠재적인 궤적 중 하나일 수 있다.
- [0012] 상기 예측된 3차원 궤적은, 상기 복수의 식별된 잠재적인 궤적 중 가장 높은 발생 값의 확률을 가질 수 있다.
- [0013] 상기 훈련된 머신 러닝 모델을 훈련하는데 이용되는 트레이닝 데이터는, 시계열 요소들 그룹에서 선택된 시계열 요소를 포함할 수 있다.
- [0014] 상기 트레이닝 데이터는, 상기 시계열 요소들 그룹과 연관된 주행 거리 측정 데이터의 관련 세트를 더 포함할 수 있다.
- [0015] 상기 트레이닝 데이터의 적어도 하나의 부분은, 대응하는 그라운드 트루스에 자동으로 레이블될 수 있다.
- [0016] 상기 차량의 상기 제어는, 상기 차량의 속도 및 조종을 조정하는 것을 포함할 수 있다.
- [0017] 상기 3차원 궤적은, 스플라인에 의해 표현될 수 있다.
- [0018] 상기 3차원 궤적은, 하나 이상의 구분적 다항식에 의해 표현될 수 있다.
- [0019] 상기 머신 러닝 특징은, 제2 차량의 예측된 경로와 연관될 수 있다.
- [0020] 상기 제2 차량의 상기 예측된 경로는, 자동으로 제어되는 상기 차량에 의해 점유되는 차선에 상기 제2 차량이 진입할 가능성이 있는지 여부를 결정하는데 사용될 수 있다.
- [0021] 상기 차량의 상기 제어는, 상기 제2 차량과의 충돌을 피하기 위해, 속도 또는 조종을 조정하는 것을 포함할 수 있다.
- [0022] 일 실시예에 따른 컴퓨터 프로그램 제품은, 비일시적 컴퓨터 판독 가능 저장 매체에 구현되고, 상기 컴퓨터 프로그램 제품은, 차량의 카메라에 의해 캡처된 이미지에 기초하여 이미지 데이터를 수신하고, 차량 차선의 3차원 궤적을 예측도록 훈련된, 훈련된 머신 러닝 모델에 대한 입력의 기초로 상기 이미지 데이터 사용하고, 차량을 자동으로 제어할 때 상기 차량 차선의 상기 3차원 궤적을 제공하도록 구성되는 컴퓨터 명령어를 포함할 수 있다.

다.

[0023] 일 실시예에 따른 방법은, 차량의 카메라에 의해 캡처된 이미지에 기초하여 이미지 데이터를 수신하는 단계; 차량 차선의 3차원 궤적을 예측하도록 훈련된, 훈련된 머신 러닝 모델에 대한 입력의 기초로 상기 이미지 데이터 사용하는 단계; 및 차량을 자동으로 제어할 때 상기 차량 차선의 상기 3차원 궤적을 제공하는 단계를 포함할 수 있다.

도면의 간단한 설명

[0024] 본 발명의 다양한 실시예가 다음의 상세한 설명 및 첨부 도면에 개시되어 있다.

도 1은 자율 주행을 위한 딥 러닝 시스템의 실시예를 도시한 블록도이다.

도 2는 자율 주행을 위한 머신 러닝 모델을 훈련 및 적용하기 위한 프로세스의 실시예를 도시한 흐름도이다.

도 3은 요소들의 시계열을 사용하여 트레이닝 데이터를 생성하기 위한 프로세스의 실시예를 도시한 흐름도이다.

도 4는 자율 주행을 위한 머신 러닝 모델을 훈련 및 적용하기 위한 프로세스의 실시예를 도시한 흐름도이다.

도 5는 차량 센서로부터 캡처된 이미지의 일 예를 나타내는 도면이다.

도 6은 차선의 3차원 궤적을 예측하여 차량 센서로부터 캡처된 이미지의 일 예를 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0025] 본 발명은, 프로세스에 연결된 메모리(memory)에 의하여 저장 및/또는 제공되는 명령어(instructions)를 실행(execute)하도록 구성(configure)된 프로세서와 같은 프로세서(processor), 프로세스(process), 장치(apparatus), 시스템(system), 물질의 구성(composition of matter), 및/또는 컴퓨터 판독가능 저장 매체(computer readable storage medium)에 구현된(embodied) 컴퓨터 프로그램 제품을 포함하는 다양한 방법으로 구현될 수 있다. 본 명세서에서, 이러한 구현, 또는 본 발명이 취할 수 있는 임의의 다른 형태는, 기술로 지칭될 수 있다. 일반적으로, 개시된 프로세스(process)의 단계의 순서는 본 발명의 범위 내에서 변경(alter)될 수 있다. 특별한 언급이 없는 한, 작업을 수행하도록 구성된 것으로 설명된 프로세서나 메모리와 같은 구성요소는 주어진 시간에 작업을 수행하도록 임시로 구성된 일반 구성요소 또는 작업을 수행하도록 제조된 특정 구성요소로 구현될 수 있다. 본 명세서에 사용된 바와 같이, 용어 '프로세서'는 하나 이상의 장치(devices), 회로(circuits), 및/또는 컴퓨터 프로그램 명령어와 같은 데이터를 처리하도록 구성된 처리 코어(processing core)를 지칭(refer)한다.

[0026] 본 발명의 하나 이상의 실시예에 대한 상세한 설명이 본 발명의 원리를 예시하는 첨부 도면과 함께 아래에 제공된다. 본 발명은 이러한 실시예와 관련하여 설명되지만, 본 발명은 임의의 실시예에 제한되지 않는다. 본 발명의 범위는 청구범위에 의해서만 제한되고 본 발명은 수많은 대안, 수정 및 등가물을 포함한다. 본 발명의 완전한 이해를 제공하기 위해 다수의 특정 세부사항이 설명에 기재되어 있다. 이러한 세부사항은 예시의 목적으로 제공되며 본 발명은 이러한 특정 세부사항의 일부 또는 전부 없이 청구범위에 따라 실시될 수 있다. 명확성을 기하기 위해, 본 발명과 관련된 기술 분야에서 알려진 기술 자료는 본 발명이 불필요하게 모호하게 되는 일이 없도록 상세히 설명하지 않았다.

[0027] 고도로 정확한 머신 러닝(machine learning) 결과를 생성하기 위한 머신 러닝 트레이닝 기술(machine learning training technique)이 개시(disclose)된다. 차량의 환경(environment of vehicle) 및 차량 작동 매개변수(vehicle operating parameter)를 캡처(capture)하기 위해 차량의 센서(sensor)에 의해 캡처된 데이터를 사용하여, 트레이닝 데이터 세트(training data set)가 생성(create)된다. 예를 들어, 차량에 부착된 센서는 차량이 주행중인 도로 및 주변 환경의 이미지 데이터와 같은 데이터를 캡처한다. 센서 데이터는 차량 차선 경계선(vehicle lane line), 차량 차선(vehicle lane), 다른 차량 교통(other vehicle traffic), 장애물(obstacles), 교통 통제 표지판(traffic control signs) 등을 캡처할 수 있다. 주행 거리 측정(odometry) 및 다른 비슷한 센서는 차량 속도(vehicle speed), 조종(steering), 방향(orientation), 방향(direction) 변경, 위치(location) 변경, 고도(elevation) 변경, 속도(speed) 변경 등과 같은 차량 작동 매개변수를 캡처한다. 캡처된 데이터 세트는 트레이닝 데이터 세트를 생성하기 위해 트레이닝 서버(training server)에 전송된다. 트레이닝 데이터 세트는 고도로 정확한 머신 러닝 결과 생성을 위한 머신 러닝 모델을 훈련하기 위해 사용된다. 일부 실시예에서, 캡처된 데이터의 시계열은 트레이닝 데이터를 생성하기 위해 사용된다. 예를 들어, 그라운드 트루스(ground truth)는 시계열 요소들 그룹(group of time series elements)에 기초하여 결정되고 그룹의 단일 요소와 연결

(associate)된다. 일례로, 30초와 같은 일정 기간 동안의 일련의 이미지는, 차량이 이동(travel)하는 일정 기간에 걸쳐서 차량 차선 경계선(vehicle lane line)의 실제 경로를 결정하는데 사용된다. 차량 차선 경계선은 일정 기간 동안 가장 정확한 차량 차선 이미지를 사용하여 결정된다. 차선 경계선의 다른 부분(different portions) (또는 위치)은 시계열의 다른 이미지 데이터에서 식별될 수 있다. 차량이 차선 경계선을 따라 차선을 이동할 때, 차선 경계선의 다른 부분에 대한 더 정확한 데이터가 캡처된다. 일부 예에서, 차선 경계선의 가려진(occluded) 부분은, 예를 들어 차량이 숨겨진 곡선 또는 언덕의 능선을 따라 이동할 때 드러난다. 시계열의 각 이미지로부터 차선 경계선의 가장 정확한 부분은 이미지 데이터의 전체 그룹에 대한 차선 경계선을 식별하는데 사용될 수 있다. 거리(distance)에 있는 차선 경계선의 이미지 데이터(image data)는 일반적으로 차량 근처 차선 경계선의 이미지 데이터보다 덜 상세하다. 차량이 차선을 따라 이동할 때 이미지 데이터의 시계열을 캡처함으로써, 해당 차선의 모든 부분에 대한 정확한 이미지 데이터와 해당 주행 거리 측정 데이터(odometry data)가 수집(collect)된다.

[0028] 일부 실시예에서, 차선 경계선과 같은 특징의 3차원 표현(three-dimensional representation)은, 그라운드 트루스(ground truth)에 대응하는 시계열 요소들 그룹으로부터 생성된다. 그런 다음 이 그라운드 트루스는, 캡처된 이미지 데이터 그룹의 단일 이미지 프레임과 같은 시계열 요소들(time series elements)의 부분집합(subset)과 연관(associate)된다. 예를 들어, 이미지 그룹의 첫번째 이미지(first image)는 3차원 공간에서 표현되는 차선 경계선에 대한 그라운드 트루스와 연관(associate)된다. 그라운드 트루스가 이미지 그룹에 기초하여 결정되지만, 선택된 첫번째 프레임과 그라운드 트루스는 트레이닝 데이터를 생성하는데 사용된다. 예를 들어, 단일 이미지만을 사용하여 차량 차선의 3차원 표현을 예측하기 위해 트레이닝 데이터가 생성된다. 일부 실시예들에서, 시계열 요소들 그룹에 속하는 요소들의 그룹 또는 임의의 요소는 그라운드 트루스와 연관되고, 트레이닝 데이터를 생성하기 위해 사용된다. 예를 들어, 트레이닝 데이터 생성을 위해 전체 비디오 시퀀스(sequence)에 그라운드 트루스가 적용될 수 있다. 다른 실시예로, 시계열 요소들 그룹의 중간 요소 또는 마지막 요소는 그라운드 트루스와 연관되고 트레이닝 데이터를 생성하는데 사용된다.

[0029] 다양한 실시예에서, 선택된 이미지 및 그라운드 트루스는 차선 경계선(lane line), 이웃 차량(neighboring vehicle)을 포함하는 차량에 대한 경로 예측, 물체의 깊이 거리(depth distances of objects), 교통 통제 표지판(traffic control sign) 등과 같은 다른 특징에 적용될 수 있다. 예를 들어, 인접 차선에 있는 차량의 일련의 이미지는 해당 차량의 경로를 예측하기 위해 사용된다. 이미지의 시계열과 인접 차량에 의해 취해(take)진 실제 경로를 사용하여, 차량의 경로를 예측하기 위해 그룹의 단일 이미지와 취해진 실제 경로는 트레이닝 데이터로 사용될 수 있다. 이 정보는 인접 차량이 자율 주행 차량(autonomous vehicle)의 경로에 끼어들 것(cut into)인지 여부를 예측하는데 사용될 수 있다. 예를 들어, 경로 예측은 인접 차량이 자율 주행 차량 앞에서 합류(merge)할 것인지 여부를 예측할 수 있다. 자율 주행 차량은 충돌 가능성을 최소화하기 위해 제어(control)될 수 있다. 예를 들어, 자율 주행 차량은 충돌(collisions)을 막기 위해 속도를 줄이고, 충돌을 막기 위해 차량의 속도(speed) 및/또는 조종(steering)을 조정하고, 자율 주행 차량의 인접 차량(adjacent vehicle) 및/또는 탑승자(occupants)에게 경고를 시작(initiate)하고, 및/또는 차선을 변경(change)하는 등을 할 수 있다. 다양한 실시예에서, 차량 경로 예측을 포함하는 경로 예측을 정확하게 추론하는 능력은 자율 주행 차량의 안전성을 상당히 개선(improve)시킨다.

[0030] 일부 실시예에서, 훈련된 머신 러닝 모델(machine learning model)은 차선 경계선을 포함하는 자율 주행을 위한 하나 이상의 특징의 3차원 표현을 예측하기 위해 사용될 수 있다. 예를 들어, 차선 경계선의 이미지 분할(segmenting)에 의한 이미지 데이터에서 2차원 차선 경계선을 식별(identify)하는 대신, 요소들의 시계열과 시계열에 해당하는 주행 거리 측정 데이터를 사용하여 3차원 표현이 생성(generate)된다. 3차원 표현은 고도(elevation)의 변화를 포함하는데, 이는, 차선 경계선 감지의 정확성과 해당 차선 감지 및 식별된 주행가능 경로의 정확도를 대단히 향상시킨다. 일부 실시예에서, 차선 경계선은 하나 이상의 스플라인(spline) 또는 다른 매개변수화(parameterized)된 표현의 형태를 사용하여 표현(represent)된다. 차선 경계선을 표현하기 위한 구분적 다항식(piecewise polynomial)의 사용은 3차원 물체를 평가하는데 필요한 전산 리소스(computational resource)를 대단히 감소(reduce)시킨다. 이러한 전산 리소스 감소는 표현의 정확성을 크게 희생(sacrifice)하지 않으면서 처리 속도와 효율성의 개선에 대응(correspond)한다. 다양한 실시예에서, 특히 차선 경계선의 곡선을 포함하는, 차선 경계선은 구분적 다항식, 3차원 포인트의 세트(set of three-dimensional point), 또는 다른 적절한 표현을 사용하여 표현될 수 있다. 예를 들어, 구분적 다항식은 센서 데이터(sensor data)를 사용하여 시간이 지남에 따라 캡처된 요소들의 그룹에서 식별된 매우 정확한 차선 경계선의 섹션(section)을 사용하여 실제 차선 경계선을 보간한다(interpolate).

[0031] 일부 실시예에서, 센서 데이터가 수신된다. 센서 데이터는 이미지(비디오 및/또는 스틸 이미지(still image)와 같은), 레이더(radar), 오디오(audio), 라이더(lidar), 관성(inertia), 주행 거리 측정(odometry), 위치(location), 및/또는 다른 형태의 센서 데이터를 포함할 수 있다. 센서 데이터는 시계열 요소들 그룹을 포함한다. 예를 들어, 시계열 요소들 그룹은 일정 기간동안 차량의 센서 카메라로부터 캡처된 이미지의 그룹을 포함할 수 있다. 일부 실시예에서, 트레이닝 데이터세트(training dataset)는 시계열 요소들 그룹 내 복수의 시계열 요소들에 기초하여 시계열 요소들 그룹 내 적어도 하나의 선택된 시계열 요소에 대응하는 그라운드 트루스(ground truth)를 결정하는 것을 포함하여 결정된다. 예를 들어, 그라운드 트루스는 그룹의 이전 및/또는 후속 시계열 요소들을 포함하는 시계열 요소들 그룹의 각 요소의 가장 관련성이 높은 부분을 조사하여(examine) 결정된다. 일부 시나리오(scenario)에서, 이전 및/또는 후속 시계열 요소들만이, 처음에는 곡선 주변에서 사라지고 시계열의 나중 요소들(later elements)에만 나타나는 차량 차선 경계선과 같은, 앞선 시계열 요소들(earlier times series elements)에 없는 데이터를 포함한다. 결정된 그라운드 트루스는 차량 차선 경계선의 3차원 표현, 차량에 대한 예측된 경로, 또는 다른 유사한 예측일 수 있다. 시계열 요소들 그룹의 요소는 선택되어지고 그라운드 트루스와 연관되어진다. 선택된 요소와 그라운드 트루스는 트레이닝 데이터세트의 일부이다. 일부 실시예에서, 프로세서는 트레이닝 데이터세트를 사용하여 머신 러닝 모델을 훈련하기 위해 사용된다. 예를 들어, 트레이닝 데이터세트는 차량의 자율 주행(self-driving) 또는 운전자 보조 작동(driver-assisted operation)에 사용되는 특징(features)을 추론(infer)하기 위한 머신 러닝 모델을 훈련하는 데 사용된다. 훈련된 머신 러닝 모델을 사용하여, 신경망(neural network)은 차량 차선, 주행가능 공간(drivable space), 물체(예: 보행자(pedestrians), 정지 차량(stationary vehicles), 이동 차량(moving vehicles) 등), 기상(예: 비, 우박, 안개 등), 교통 통제 물체(예: 신호등(traffic lights), 교통 표지판(traffic signs), 거리 표지판(street signs) 등), 교통 패턴(traffic pattern) 등과 같은 자율 주행과 관련된 특징(features)을 추론할 수 있다.

[0032] 일부 실시예에서, 시스템은 프로세서 및 프로세서에 결합된(coupled) 메모리를 포함한다. 프로세서는 차량의 카메라에 의하여 캡처된 이미지에 기초한 이미지 데이터를 수신(receive)하기 위해 구성(configure)된다. 예를 들어, 차량에 부착된 카메라 센서는 차량 환경(vehicle's environment)의 이미지(image)를 캡처한다. 카메라는 전방 카메라(forward facing camera), 기둥 카메라(pillar camera), 또는 다른 적절히 위치한 카메라일 수 있다. 카메라에서 캡처된 이미지 데이터는 차량의 GPU 또는 AI 프로세서와 같은 프로세서를 사용하여 처리(process)된다. 일부 실시예에서, 이미지 데이터는 차량 차선의 3차원 궤적(three-dimensional trajectory)을 예측하기 위해 훈련된, 훈련된 머신 러닝 모델(trained machine learning model)에 대한 입력의 기초로 사용된다. 예를 들어, 이미지 데이터는 차량 차선을 예측(predict)하도록 훈련된 신경망에 대한 입력으로 사용된다. 머신 러닝 모델은 감지된 차선에 대한 3차원 궤적을 추론한다. 이미지를 2차원(two-dimensional) 이미지의 차선(lane)과 비차선 세그먼트(non-lane segment)로 분할(segmenting)하는 대신, 3차원 표현이 추론된다. 일부 실시예에서, 3차원 표현은 스플라인(spline), 파라메트릭 곡선(parametric curve), 또는 3차원으로 곡선을 설명할 수 있는 다른 표현이다. 일부 실시예에서, 차량 차선의 3차원 궤적은 차량을 자동으로 제어할 때 제공(provide)된다. 예를 들어, 3차원 궤적은 차선 경계선을 결정하고 해당하는 주행가능한 공간을 결정하는데 사용된다.

[0033] 도 1은 자율 주행을 위한 딥 러닝 시스템(deep learning system)의 실시예를 도시하는 블록도이다. 딥 러닝 시스템은 자율 주행(autonomous driving)을 위한 머신 러닝 모델 훈련을 위한 데이터 수집 및 처리뿐만 아니라 차량의 자율 주행(self-driving) 및/또는 운전자 보조 작동(driver-assisted operation)을 위해 함께 사용될 수 있는 다른 구성요소를 포함한다. 다양한 실시예에서, 딥러닝 시스템은 차량에 설치(install)된다. 차량의 데이터는 차량 또는 다른 유사한 차량의 자율 주행 특징을 훈련하고 개선하는데 사용될 수 있다.

[0034] 도시된 예에서, 딥 러닝 시스템(100)은 센서(sensors)(101), 이미지 전처리 프로세서(image pre-processor)(103), 딥 러닝 네트워크(deep learning network)(105), 인공지능(artificial intelligence(AI)) 프로세서(107), 차량 제어 모듈(vehicle control module)(109), 및 네트워크 인터페이스(network interface)(111)를 포함하는 딥 러닝 네트워크(deep learning network)이다. 다양한 실시예에서, 상이한 구성 요소들이 통신 가능하게(communicatively) 연결된다. 예를 들어, 센서(101)의 센서 데이터는 이미지 전처리 프로세서(103)에 공급(feed)된다. 이미지 전처리 프로세서(103)의 처리된 센서 데이터는 AI 프로세서(107)에서 구동되는 딥 러닝 네트워크(105)에 공급된다. AI 프로세서(107)에서 구동되는 딥 러닝 네트워크(105)의 출력은 차량 제어 모듈(109)에 공급된다. 다양한 실시예에서, 차량 제어 모듈(109)은 차량에 연결되고, 차량의 속도, 제동, 및/또는 조종 등과 같은 차량의 작동을 제어한다. 다양한 실시예에서, 센서 데이터 및/또는 머신 러닝 결과는 네트워크 인터페이스(111)를 통해 원격 서버(remote server)로 전송(send)될 수 있다. 예를 들어, 센서 데이터는 성능(performance), 편안함(comfort), 및/또는 차량의 안전(safety)을 개선하기 위하여 트레이닝 데이터를

수집할 수 있도록 네트워크 인터페이스(111)를 통해 원격 서버로 전송(transmit)될 수 있다. 다양한 실시예에서, 네트워크 인터페이스(111)는 여러 이유 중에서도 원격 서버와 통신하고(communicate), 전화를 걸고, 텍스트 메시지(text message)를 송신(send) 및/또는 수신(receive)하고, 차량의 작동에 기초한 센서 데이터를 송신(transmit)하기 위해 사용된다. 일부 실시예에서, 딥 러닝 시스템(100)은 적절하게 추가된 또는 더 적은 구성요소(components)를 포함할 수 있다. 예를 들어, 일부 실시예에서, 이미지 전처리 프로세서(103)는 선택적 구성요소이다. 다른 예로서, 일부 실시예에서, 후처리 구성요소(post-processing component)(미도시)는 출력이 차량 제어 모듈(109)에 제공되기 전에 딥 러닝 네트워크(105)의 출력에 대한 후처리를 수행하는데 사용된다.

[0035]

일부 실시예에서, 센서(101)는 하나 이상의 센서를 포함한다. 다양한 실시예에서, 센서(101)는 차량의 상이한 위치에서 차량에 부착(affix)될 수 있고/있거나 하나 이상의 상이한 방향으로 배향(orient)될 수 있다. 예를 들어, 센서(101)는 전면(front), 측면(side), 후면(rear), 및/또는 지붕(roof) 등에 전방(forward-facing), 후방(rear-facing), 측방(side-facing) 등의 방향으로 부착될 수 있다. 일부 실시예에서, 센서(101)는 하이 다이내믹 레인지 카메라(high dynamic range camera)와 같은 이미지 센서(image sensor)일 수 있다. 일부 실시예에서, 센서(101)는 비시각적 센서(non-visual sensors)를 포함한다. 일부 실시예에서, 센서(101)는, 다른 것들 중에서도, 레이더(radar), 오디오(audio), 라이더(LiDAR), 관성(inertia), 주행 거리 측정(odometry), 위치(location), 및/또는 초음파 센서(ultrasonic sensors) 데이터를 포함한다. 일부 실시예에서, 센서(101)는 차량 제어 모듈(109)과 함께 차량에 장착(mount)되지 않는다. 예를 들어, 센서(101)는 이웃 차량(neighboring vehicle)에 장착 및/또는 도로 또는 환경에 부착될 수 있으며, 센서 데이터를 캡처하기 위하여 딥 러닝 시스템의 일부로 포함될 수 있다. 일부 실시예에서, 센서(101)는 차량이 이동(travel)하고 있는 노면(road surface)을 캡처하는 하나 이상의 카메라를 포함한다. 예를 들어, 하나 이상의 전방(front-facing) 및/또는 기둥 카메라(pillar camera)는 차량이 이동하고 있는 차선의 차선 표시(lane markings)를 캡처한다. 다른 예로서, 카메라는 차량이 이동하는 차선으로 진입(cut into)을 시도하는 차량을 포함하는 이웃 차량을 캡처한다. 추가 센서는 차량 궤적과 관련된 정보를 포함하는 주행 거리 측정, 위치, 및/또는 차량 제어 정보를 캡처한다. 센서(101)는 스틸 이미지 및/또는 비디오 모두를 캡처할 수 있는 센서를 포함할 수 있다. 데이터는 일정 시간 기간(period of time) 동안 캡처된 데이터의 시퀀스(sequence)와 같이 일정 시간 기간 동안 캡처될 수 있다. 예를 들어, 차선 표시의 이미지는 15초 또는 다른 적절한 기간 동안 차량 주행 거리 측정 데이터와 함께 캡처될 수 있다. 일부 실시예에서, 센서(101)는 차량의 위치 및/또는 위치의 변화를 결정하기 위한 글로벌 포지션 시스템(global position system(GPS)) 센서와 같은 위치 센서를 포함한다.

[0036]

일부 실시예에서, 이미지 전처리 프로세서(103)는 센서(101)의 센서 데이터를 전처리(pre-process)하는 데 사용된다. 예를 들어, 이미지 전처리 프로세서(103)는 센서 데이터를 전처리하고, 센서 데이터를 하나 이상의 구성요소로 분할(split)하고, 및/또는 하나 이상의 구성요소를 후처리(post-process)하는 데 사용될 수 있다. 일부 실시예에서, 이미지 전처리 프로세서(103)는 그래픽처리장치(graphics processing unit(GPU)), 중앙처리장치(central processing unit(CPU)), 이미지 신호 프로세서(image signal processor), 또는 전문화된 이미지 프로세서(specialized image processor)이다. 다양한 실시예에서, 이미지 전처리 프로세서(103)는 하이 다이내믹 레인지 데이터(high dynamic range data)를 처리하기 위한 톤-매핑 프로세서(tone-mapper processor)이다. 일부 실시예에서, 이미지 전처리 프로세서(103)는 인공 지능(AI) 프로세서(107)의 일부로 구현된다. 예를 들어, 이미지 전처리 프로세서(103)는 AI 프로세서(107)의 구성일 수 있다. 일부 실시예에서, 이미지 전처리 프로세서(103)는 이미지를 정규화(normalize)하거나 이미지를 변환(transform)하기 위해 사용될 수 있다. 예를 들어, 어안 렌즈(fisheye lens)로 캡처된 이미지는 뒤틀릴(warp) 수 있고, 이미지 전처리 프로세서(103)는 뒤틀림(warping)을 제거(remove)하거나 수정(modify)하는 데 사용될 수 있다. 일부 실시예에서, 노이즈(noise), 왜곡(distortion), 및/또는 흐릿함(blurriness)는 전처리 단계를 통해 제거되거나 감소(reduce)된다. 다양한 실시예에서, 이미지는 머신 러닝 분석의 결과를 개선하기 위해 조정(adjust)되거나 정규화 된다. 예를 들어, 이미지의 화이트 밸런스(white balance)는, 다른 것들 중에서도, 일광(daylight), 화창함(sunny), 흐림(cloudy), 황혼(dusk), 일출(sunrise), 일몰(sunset), 야간 조건(night conditions)과 같은 상이한 조명 작동 조건을 고려하여 조정(adjust)된다.

[0037]

일부 실시예에서, 딥 러닝 네트워크(105)는 차선 마커(lane markers), 차선(lane), 주행가능 공간(drivable space), 장애물(obstacles), 및/또는 잠재적인 차량 경로(potential vehicle paths) 등을 결정하기 위한 주행 환경을 분석하는 것을 포함하는 차량 제어 매개변수를 결정하는데 사용되는 딥 러닝 네트워크이다. 예를 들어, 딥 러닝 네트워크(105)는 센서 데이터와 같은 입력에 대해 훈련(train)되고 그 출력이 차량 제어 모듈(109)에 제공되는 컨볼루션 신경망(convolutional neural network(CNN))과 같은 인공 신경망일 수 있다. 일례로, 출력은 적어도 차선 마커의 3차원 표현을 포함할 수 있다. 다른 예로서, 출력은 차량의 차선으로 합류(merge)할 가

능성이 있는 적어도 잠재적인 차량(potential vehicle)을 포함할 수 있다. 일부 실시예에서, 딥 러닝 네트워크(105)는 적어도 센서 데이터를 입력으로서 수신한다. 추가 입력에는 차량 주변 환경을 설명하는 장면 데이터(scene data) 및/또는 차량의 작동 특성과 같은 차량 사양(specifications)이 포함될 수 있다. 장면 데이터는 비(raining), 젖은 도로(wet roads), 눈(snowing), 진흙(muddy), 고밀도 교통(high density traffic), 고속도로(highway), 도시(urban), 스쿨 존(school zone) 등과 같은 차량 주변의 환경을 설명하는 장면 태그(scene tags)를 포함할 수 있다. 일부 실시예에서, 딥 러닝 네트워크(105)의 출력은 차량의 차량 차선의 3차원 궤적이다. 일부 실시예에서, 딥 러닝 네트워크(105)의 출력은 진입하는 잠재적인 차량이다. 예를 들어, 딥 러닝 네트워크(105)는 차량 앞의 차선으로 진입할 가능성이 있는 이웃 차량을 식별한다.

[0038] 일부 실시예에서, 인공 지능(AI) 프로세서(107)는 딥 러닝 네트워크(105)를 구동(run)하기 위한 하드웨어 프로세서(hardware processor)이다. 일부 실시예에서, AI 프로세서(107)는 센서 데이터에 대해 컨벌루션 신경망(CNN)을 사용하여 추론을 수행하기 위한 전문화된 AI 프로세서이다. AI 프로세서(107)는 센서 데이터의 비트 맵스(bit depth)를 위해 최적화될 수 있다. 일부 실시예에서, AI 프로세서(107)는, 다른 것들 중에서도, 컨벌루션(convolution), 내적(dot-product), 벡터(vector), 및/또는 행렬 연산(matrix operations)을 포함하는 신경망 연산(operations)과 같은 딥 러닝 연산(operations)을 위해 최적화된다. 일부 실시예에서, AI 프로세서(107)는 그래픽처리장치(GPU)를 사용하여 구현된다. 다양한 실시예에서, AI 프로세서(107)는 메모리에 결합된다. 메모리는, 실행 시 AI 프로세서가 수신된 입력 센서 데이터에 대하여 딥 러닝 분석(deep learning analysis)을 수행하고 자율 주행에 사용되기 위한 머신 러닝 결과(machine learning result)를 결정하도록 하는 명령어를 AI 프로세서에 제공하도록 구성된다. 일부 실시예에서, AI 프로세서는 데이터를 트레이닝 데이터로 이용 가능하게 만들기 위한 준비로 센서 데이터를 처리하는데 사용된다.

[0039] 일부 실시예에서, 차량 제어 모듈(109)은 인공 지능(AI) 프로세서(107)의 출력을 처리(process)하고 차량 제어 작동으로 변환(translate)하는 데 이용(utilize)된다. 일부 실시예에서, 차량 제어 모듈(109)은 자율 주행을 위한 차량 제어에 이용된다. 일부 실시예에서, 차량 제어 모듈(109)은 차량의 속도(speed), 가속도(acceleration), 조종(steering), 제동(braking) 등을 조정(adjust)할 수 있다. 예를 들어, 일부 실시예에서, 차량 제어 모듈(109)은 차선 내에서 차량의 위치를 유지(maintain)하고, 차량을 다른 차선으로 합치고(merge), 차량의 속도 및 차량을 합치는 것을 고려한 차선 포지셔닝(positioning) 등 차량을 제어하는데 사용된다.

[0040] 일부 실시예에서, 차량 제어 모듈(109)은 브레이크 등(brake light), 방향 지시등(turns signal), 헤드라이트(headlight) 등과 같은 차량 조명을 제어하는데 사용된다. 일부 실시예에서, 차량 제어 모듈(109)은 차량 사운드 시스템(sound system), 오디오 경고(audio alert) 재생, 마이크(microphone) 활성화, 경적(horn) 활성화 등과 같은 차량 오디오 상태(audio condition)를 제어하는 데 사용된다. 일부 실시예에서, 차량 제어 모듈(109)은 운전자 및/또는 승객에게 잠재적인 충돌 또는 의도한 목적지의 접근과 같은 운전 이벤트(driving event)를 알리는 경고 시스템(warning system)을 포함하는 알림 시스템(notification system)을 제어하는데 사용된다. 일부 실시예에서, 차량 제어 모듈(109)은 차량의 센서(101)와 같은 센서를 조정하는데 사용된다. 예를 들어, 차량 제어 모듈(109)은 방향(orientation) 수정, 출력 해상도(resolution) 및/또는 형식 유형(format type) 변경, 캡처 속도(capture rate) 증가 또는 감소, 캡처된 동적 범위 조정, 카메라의 초점(focus) 조정, 센서 활성화 및/또는 비활성화 등과 같은 하나 이상의 센서의 매개변수를 변경하는데 사용될 수 있다. 일부 실시예에서, 차량 제어 모듈(109)은 필터의 주파수 범위(frequency range) 수정, 특징(feature) 및/또는 에지 감지 매개변수(edge detection parameter) 조정, 채널(channel) 및 비트 맵스(bit depth) 조정 등과 같은 이미지 전처리 프로세서(103)의 매개변수를 변경하는데 사용될 수 있다. 다양한 실시예에서, 차량 제어 모듈(109)은 차량의 자율 주행(self-driving) 및/또는 운전자 보조 제어(driver-assisted control)를 구현하는데 사용된다. 일부 실시예에서, 차량 제어 모듈(109)은 메모리와 결합한 프로세서를 사용하여 구현된다. 일부 실시예에서, 차량 제어 모듈(109)은 특정 용도용 집적 회로(application-specific integrated circuit)(ASIC), 설계가능 논리 소자(programmable logic device)(PLD), 또는 다른 적절한 처리 하드웨어를 사용하여 구현된다.

[0041] 일부 실시예에서, 네트워크 인터페이스(111)는 음성 데이터(voice data)를 포함하는 데이터를 전송 및/또는 수신하기 위한 통신 인터페이스(communication interface)이다. 다양한 실시예에서, 네트워크 인터페이스(111)는, 연결하고 음성 통화(voice call)를 할 수 있도록 하기 위하여, 문자 메시지(text message)를 송신(send) 및/또는 수신(receive)하기 위하여, 센서 데이터를 전송(transmit)하기 위하여, 업데이트(update)된 머신 러닝 모델을 포함하는 딥 러닝 네트워크에 대한 업데이트(update) 수신하기 위하여, 기상 조건(weather condition) 및 예보(forecast)를 포함하는 환경 조건(environmental condition), 교통 상황(traffic condition) 등을 검색(retrieve)하기 위하여, 원격 서버와 인터페이싱(interfacing)하기 위한 셀룰러(cellular) 또는 무선 인터페이

스(wireless interface)를 포함한다. 예를 들어, 네트워크 인터페이스(111)는 센서(101), 이미지 전처리 프로세서(103), 딥 러닝 네트워크(105), AI 프로세서(107), 및/또는 차량 제어 모듈(109)에 대한 명령어 및/또는 작동 매개변수에 대한 업데이트를 수신하는데 사용될 수 있다. 딥 러닝 네트워크(105)의 머신 러닝 모델 네트워크 인터페이스(111)를 사용하여 업데이트될 수 있다. 다른 예로서, 네트워크 인터페이스(111)는 센서(101)의 펌웨어(firmware) 및/또는 이미지 처리 매개변수와 같은 이미지 전처리 프로세서(103)의 작동 매개변수(operating parameters)를 업데이트 하는데 사용될 수 있다. 또 다른 실시예로서, 네트워크 인터페이스(111)은 머신 러닝 모델을 훈련하기 위해 잠재적인 트레이닝 데이터를 원격 서버로 전송하는데 사용될 수 있다.

[0042] 도 2는 자율 주행을 위한 머신 러닝 모델을 훈련 및 적용하기 위한 프로세스(process)의 실시예를 도시하는 흐름도이다. 예를 들어, 센서 및 주행 거리 측정 데이터를 포함하는 입력 데이터는 머신 러닝 모델을 훈련하기 위한 트레이닝 데이터를 생성하기 위하여 수신되고 처리된다. 일부 실시예에서, 센서 데이터는 자율 주행 시스템을 통해 캡처된 이미지 데이터와 대응(correspond)한다. 일부 실시예에서, 센서 데이터는 사용자가 수동으로 자율 주행을 해제(disengaging)하는 것과 같은 특정 사용 케이스(use case)에 기초하여 캡처된 센서 데이터에 대응한다. 일부 실시예에서, 프로세스는 도 1의 딥 러닝 시스템(100)을 위한 머신 러닝 모델을 생성하고 배치(deploy)하기 위해 사용된다.

[0043] (201)에서, 트레이닝 데이터가 준비된다. 일부 실시예에서, 이미지 데이터와 주행 거리 측정 데이터를 포함하는 센서 데이터는 트레이닝 데이터 세트(training data set)를 생성하기 위해 수신된다. 센서 데이터는 하나 이상의 카메라로부터 스틸 이미지 및/또는 비디오를 포함할 수 있다. 레이더, 라이다, 초음파 등과 같은 추가 센서는 관련된 센서 데이터를 제공하기 위해 사용될 수 있다. 다양한 실시예에서, 센서 데이터는 센서 데이터의 특징을 식별하는 것을 돕기 위해서 대응하는 주행 거리 측정 데이터와 짝(pair)을 이룬다. 예를 들어, 위치 및 위치의 변화 데이터는 차선 경계선, 교통 제어 신호, 물체 등과 같은 센서 데이터에서 관련 특징의 위치를 식별하는데 사용될 수 있다. 일부 실시예에서, 센서 데이터는 요소들의 시계열이고, 그라운드 트루스를 결정하는데 사용된다. 그룹의 그라운드 트루스는 이미지 데이터의 첫번째 프레임(first frame)과 같은 시계열의 부분집합(subset)과 연결(associate)된다. 시계열의 선택된 요소 및 그라운드 트루스는 트레이닝 데이터를 준비하는데 사용된다. 일부 실시예에서, 트레이닝 데이터는 차선 경계선(lane line), 차량 경로(vehicle path), 교통 패턴(traffic pattern)등 과 같은 센서 데이터로부터 특징만을 식별하도록 머신 러닝 모델을 훈련하기 위해서 준비된다. 준비된 트레이닝 데이터는 훈련, 검증(validation), 테스트(testing)를 위한 데이터를 포함할 수 있다. 다양한 실시예에서, 센서 데이터는 상이한 형식(format) 일수 있다. 예를 들어, 센서 데이터는 스틸 이미지, 비디오, 오디오 등 일수 있다. 주행 거리 측정 데이터는 적용된 가속도, 적용된 제동, 적용된 조종, 차량 위치(vehicle location), 차량 방향(vehicle orientation), 차량 위치의 변화, 차량 방향의 변화 등과 같은 차량 작동 매개변수를 포함할 수 있다. 다양한 실시예에서, 트레이닝 데이터는 트레이닝 데이터 세트를 생성하기 위해서 큐레이트(curate) 되고 주석이 달린다(annotate). 일부 실시예에서, 트레이닝 데이터의 준비의 일부는 인간 큐레이터(curator)에 의해서 수행될 수 있다. 다양한 실시예에서, 트레이닝 데이터의 일부는 차량으로부터 캡처된 데이터로부터 자동으로 생성되고, 탄탄한(robust) 트레이닝 데이터 세트를 구축(build)하기 위해서 필요한 노력 및 시간을 크게 줄인다. 일부 실시예에서, 데이터의 형식은 배치된(deployed) 딥 러닝 어플리케이션(application)에서 사용되는 머신 러닝 모델과 호환 가능하다. 다양한 실시예에서, 트레이닝 데이터는 훈련된 모델의 정확도를 시험하기 위한 검증 데이터를 포함한다.

[0044] (203)에서, 머신 러닝 모델은 훈련된다. 예를 들어, 머신 러닝 모델은 (201)에서 준비된 데이터를 사용하여 훈련된다. 일부 실시예에서, 모델은 컨벌루션 신경망(CNN)과 같은 신경망이다. 다양한 실시예에서, 모델은 다수의 중간 계층(intermediate layer)를 포함한다. 다양한 실시예에서, 신경망은 다수의 컨벌루션(convolution) 및 풀링 계층(pooling layer)을 포함하는 다수의 계층을 포함할 수 있다. 일부 실시예에서, 트레이닝 모델은 수신된 센서 데이터로부터 생성된 검증 데이터 세트를 사용하여 검증된다. 다양한 실시예에서, 머신 러닝 모델은 단일 입력 이미지로부터 특징의 3차원 표현을 예측하도록 훈련된다. 예를 들어, 차선 경계선의 3차원 표현은 카메라로부터 캡처된 이미지로부터 추론될 수 있다. 다른 예로서, 차량이 합류를 시도할 것인지 여부를 포함하는 예측된 이웃 차량의 경로는 카메라로부터 캡처된 이미지로부터 예측된다.

[0045] (205)에서, 훈련된 머신 러닝 모델이 배치된다. 예를 들어, 훈련된 머신 러닝 모델은 도 1의 딥 러닝 네트워크(105)와 같은 딥 러닝 네트워크에 대한 업데이트로서 차량에 설치(install)된다. 일부 실시예에서, 오버 디 에어(over-the-air) 업데이트는 새로 훈련된 머신 러닝 모델을 설치하는데 사용된다. 일부 실시예에서, 업데이트는 와이파이(WiFi) 또는 셀룰러 네트워크와 같은 무선 네트워크를 사용하여 전송된 펌웨어 업데이트(firmware update)이다. 일부 실시예에서, 새로운 머신 러닝 모델은 차량이 서비스(service)될 때 설치될 수 있다.

- [0046] (207)에서, 센서 데이터는 수신된다. 예를 들어, 센서 데이터는 차량의 하나 이상의 센서로부터 캡처된다. 일부 실시예에서, 센서들은 도 1의 센서(101)이다. 센서는 바람막이 창(windshield) 뒤에 장착된 어안 카메라(fisheye camera), 기둥에 장착된 전방 또는 측면 카메라, 후방 카메라 등과 같은 이미지 센서를 포함할 수 있다. 다양한 실시예에서, 센서 데이터는 상기 형식이거나 (203)에서 훈련된 머신 러닝 모델이 입력으로 이용하는 형식으로 변환(convert)된다. 예를 들어, 센서 데이터는 가공되지 않은(raw) 또는 처리된(processed) 이미지 데이터이다. 일부 실시예에서, 데이터는 초음파 센서, 레이더, 라이더 센서, 마이크, 또는 다른 적절한 기술로부터 캡처된 데이터이다. 일부 실시예에서, 센서데이터는 전처리 단계 동안 도 1의 이미지 전처리 프로세서(103)와 같은 이미지 전처리 프로세서를 사용하여 전처리 된다. 예를 들어, 이미지는 왜곡, 노이즈 등을 제거하기 위해 정규화 될 수 있다.
- [0047] (209)에서, 훈련된 머신 러닝 모델인 적용된다. 예를 들어, (203)에서 훈련된 머신 러닝 모델은 (207)에서 수신된 센서 데이터에 적용된다. 일부 실시예에서, 모델의 적용은 도 1의 딥 러닝 네트워크(105)와 같은 딥 러닝 네트워크를 사용하는 도 1의 AI 프로세서(107)와 같은 AI 프로세서에 의해서 수행된다. 다양한 실시예에서, 훈련된 머신 러닝 모델을 적용함으로써, 차선 경계선과 같은 특징의 3차원 표현 이 식별 및/또는 예측된다. 예를 들어, 차량이 이동하는 차선의 차선 경계선을 나타내는 두개의 스플라인(spline)이 추론(infer)된다. 다른 예로, 예측된 이웃 차량의 경로는 현재의 차선으로 이웃 차량이 진입할 가능성이 있는지 여부를 포함하여 추론된다. 다양한 실시예에서, 차량(vehicles), 장애물(obstacles), 차선(lanes), 교통 통제 표지판(traffic control signals), 지도 특징(map features), 물체 거리(object distance), 속도 제한(speed limit), 주행가능 공간(drivable space) 등은 머신 러닝 모델을 적용하여 식별된다. 일부 실시예에서, 특징들은 3차원으로 식별된다.
- [0048] (211)에서, 자율 주행 차량이 제어된다. 예를 들어, 하나 이상의 자율 주행 특징은 차량의 다양한 측면에 의해서 구현된다. 예시에는 조종, 속도, 가속도, 및/또는 차량의 제동 제어, 차선에서 차량의 위치 유지, 다른 차량 및/또는 장애물에 대한 차량의 위치 유지, 탑승자에게 알림 또는 경고 제공 등을 포함할 수 있다. (209)에서 수행된 분석에 기초하여, 차량의 조종 또는 속도는 두 차선 경계선사이에서 차량을 유지하기 위해서 제어된다. 예를 들어, 왼쪽과 오른쪽 차선 경계선은 예측되고 대응하는 차량 차선 및 주행가능 공간이 식별된다. 다양한 실시예에서, 도1의 차량 제어 모듈(109)와 같은 차량 제어 모듈은 차량을 제어한다.
- [0049] 도 3은 요소들의 시계열(time series of elements)을 사용하여 트레이닝 데이터를 생성하기 위한 프로세스의 실시예를 도시하는 흐름도이다. 예를 들어, 센서 및 주행 거리 측정 데이터로 구성된 요소들의 시계열은 차량으로부터 수집되고 트레이닝 데이터를 자동으로 생성하는데 사용된다. 다양한 실시예에서, 도3의 프로세스는 대응하는 그라운드 트루스와 함께 자동으로 트레이닝 데이터를 레이블(label)하기 위해 사용된다. 시계열에 대응하는 결과(outcome)는 시계열의 요소와 연관(associate)된다. 결과와 선택된 요소는 미래의 결과를 예측하는데 사용하는 트레이닝 데이터로 포장(package)된다. 다양한 실시예에서, 센서와 관련 데이터는 도 1의 딥 러닝 시스템을 사용하여 캡처된다. 예를 들어, 다양한 실시예에서, 센서 데이터는 도 1의 센서(들)(101)로부터 캡처된다. 일부 실시예에서, 도 3의 프로세스는 도 2의 (201)에서 수행된다. 일부 실시예에서, 도3의 프로세스는 기존의 예측(existing predictions)이 정확하지 않거나 개선될 수 있는 경우 자동으로 데이터를 수집하도록 수행된다. 예를 들어, 예측은 차량이 자율 주행 차량의 경로로 진입할 것인지 여부를 결정하기 위해 자율 주행 차량에 의해 만들어진다. 일정 기간을 기다리고 캡처된 센서 데이터를 분석한 후에, 예측이 맞았는지(correct) 틀렸는지(incorrect) 결정(determination)이 만들어질 수 있다. 일부 실시예에서, 예측이 개선될 수 있다는 결정이 만들어진다. 막상 예측이 틀리거나 개선될 수 있는 경우, 도 3의 프로세스는 머신 러닝 모델을 향상하기 위한 예시의 큐레이티드 세트(curated set)를 생성하기 위해서 예측과 관련된 데이터를 적용할 수 있다.
- [0050] (301)에서, 시계열의 요소들이 수신된다. 다양한 실시예에서, 요소들은 차량에서 캡처되고 트레이닝 서버(training server)에 전송된 이미지 데이터와 같은 센서 데이터이다. 센서 데이터는 요소들의 시계열을 생성하기 위해서 일정 시간 기간 동안 캡처된다. 다양한 실시예에서, 요소들은 요소들의 순서(ordering)를 유지(maintain)하기 위한 타임스탬프(timestamps)이다. 요소들이 시계열을 통해 진행(progress)됨에 따라, 시계열의 추가 이벤트들은, 시계열의 앞선 요소(earlier element)에서 결과를 예측하는 데 도움이 되도록 사용된다. 예를 들어, 시계열은 합류 신호를 보내고, 가속하고, 근처 차선 경계선에 가깝게 위치를 지정하는 인접한 차선의 차량을 캡처할 수 있다. 전체 시계열을 사용하여, 결과는 차량이 공유 차선(shared lane)으로 합류했는지 결정(determine)하도록 사용될 수 있다. 이 결과는 시계열의 초기 이미지 중 하나와 같은 시계열의 선택된 요소에 기초하여 차량이 합류할 것인지를 예측하는데 사용될 수 있다. 다른 예시로, 시계열은 차선 경계선의 곡선(curve)를 캡처한다. 시계열은 시계열의 단일 요소에서만 분명하지 않은 차선의 다양한 차선의 딥(dips), 밴드(bends), 마루(crests) 등을 캡처한다. 다양한 실시예에서, 요소들은 머신 러닝 모델이 입력으로 사용하는 형식

의 센서 데이터이다. 예를 들어, 센서 데이터는 가공되지 않은(raw) 또는 처리된 이미지 데이터이다. 일부 실시예에서, 데이터는 초음파 센서, 레이더, 라이다 센서, 또는 다른 적절한 기술로부터 캡처된 데이터이다.

[0051] 다양한 실시예에서, 시계열은 타임스탬프를 시계열의 각 요소와 연관시킴으로써 구성(organize)된다. 예를 들어, 타임스탬프는 적어도 시계열의 첫번째 요소와 연관(associate)된다. 타임스탬프는 주행 거리 측정 데이터와 같은 관련 데이터로 시계열 요소들을 보정(calibrate)하기 위해 사용될 수 있다. 다양한 실시예에서, 시계열의 길이는 10초, 30초 또는 다른 적절한 길이와 같은 고정된 시간의 길이일 수 있다. 시간의 길이는 설정할 수 있다(configurable). 다양한 실시예에서, 시계열은 차량의 평균 속도(average speed)와 같은 차량의 속도에 기초할 수 있다. 예를 들어, 더 느린 속도에서는, 더 긴 거리의 주행 동안 데이터를 캡처하기 위하여, 동일한 속도로 더 짧은 시간 길이를 사용하는 것보다 시계열(time series)을 위한 시간의 길이가 증가될 수 있다. 일부 실시예에서, 시계열에서 요소들의 수는 설정할 수 있다(configurable). 예를 들어, 요소들의 수는 이동한 거리에 기초할 수 있다. 예를 들어, 고정된 일정 기간동안 빠르게 이동하는 차량은 느리게 이동하는 차량보다 시계열에서 더 많은 요소들을 포함한다. 추가 요소들은 캡처된 환경(environment)의 정확도(fidelity)를 높이고(increase) 예측된 머신 러닝 결과의 정확성을 개선할 수 있다. 다양한 실시예에서, 요소들의 수는 센서가 캡처하는 캡처하는 초당 프레임 조정에 의하여 및/또는 불필요한 중간 프레임을 폐기(discard)함에 의하여 조정된다.

[0052] (303)에서, 시계열의 요소들과 관련된 데이터가 수신된다. 다양한 실시예에서, 관련 데이터는 (301)에서 수신된 요소들과 함께 트레이닝 서버에서 수신된다. 일부 실시예에서, 관련 데이터는 차량의 주행 거리 측정 데이터이다. 위치, 방향, 위치의 변화, 방향의 변화, 및/또는 다른 관련된 차량 데이터를 사용하여 시계열의 요소들에서 식별된 특징의 위치상의 데이터는 레이블(label)된다. 예를 들어, 차선 경계선은 차선 경계선의 요소들의 시계열을 조사하여 매우 정확한 위치와 함께 레이블 될 수 있다. 일반적으로 차량 카메라와 가장 가까운 차선 경계선은 정확하고 차량의 위치와 밀접한 관련이 있다. 이에 반해, 차량으로부터 가장 멀리 떨어진 차선의 XYZ 위치는 결정(determine)하기 어렵다. 차선 경계선의 먼 부분은 가려지거나(occluded)(예: 굽은 곳(bend) 또는 언덕 뒤) 및/또는 정확하게 캡처하기 어려울 수 있다(예: 거리 또는 조명 등으로 인해). 요소들과 관련된 데이터는 높은 정확도(accuracy)로 식별된 시계열에서 식별된 특징의 일부를 레이블하기 위해 사용된다. 다양한 실시예에서, 임계값(threshold value)은 관련 데이터와 식별된 특징의 일부(차선 경계선의 일부와 같은)를 연관(associate)시킬지 여부를 결정하기 위해 사용될 수 있다. 예를 들어, 높은 확실성(certainty)으로 식별된 차선 경계선의 일부(차량 근처 부분과 같은)는 관련 데이터와 연관(associate)되는 반면에 임계값 미만(below)의 높은 확실성으로 식별된 차선 경계선의 일부(차량으로부터 먼 부분과 같은)는 요소의 관련 데이터와 연관(associate)되지 않는다. 대신에, 후속 요소(subsequent element)와 같은, 더 높은 확실성을 가진 시계열의 또 다른 요소와 이와 관련된 데이터가 사용된다. 일부 실시예에서, 관련 데이터는 도 1의 딥 러닝 네트워크(105)의 출력과 같은 신경망의 출력(output)이다. 일부 실시예에서, 관련 데이터는 도 1의 차량 제어 모듈(109)과 같은 차량 제어 모듈의 출력이다. 관련 데이터는 속도, 가속도, 가속도의 변화, 조종, 조종의 변화, 제동, 제동의 변화 등과 같은 차량 작동 파라미터(vehicle operating parameters)를 포함할 수 있다. 일부 실시예에서, 관련 데이터는 장애물과 같은 물체의 거리를 추정하기 위한 레이더 데이터이다.

[0053] 일부 실시예에서, 시계열의 요소들과 관련된 데이터는 지도 데이터(map data)를 포함한다. 예를 들어, 도로 및/또는 위성 수준 지도 데이터와 같은 오프라인 데이터(offline data)는 (303)에서 수신된다. 지도 데이터는 도로(roads), 차량 차선(vehicle lanes), 교차로(intersections), 속도 제한(speed limits), 스쿨존(school zone) 등과 같은 특징을 식별하는데 사용된다. 예를 들어, 지도 데이터는 차량 차선의 경로를 설명(describe)할 수 있다. 다른 예로, 지도 데이터는 지도의 다른 도로와 연관된(associated) 속도 제한을 설명할 수 있다.

[0054] 다양한 실시예에서, 시계열의 요소들 관련된 데이터는 타임스탬프와 관련 데이터를 연관시킴으로써 구성(organize)된다. 시계열 요소들 및 관련 데이터로부터 대응하는 타임스탬프는 두 데이터 세트를 동기화(synchronize)하기 위해 사용될 수 있다. 일부 실시예에서, 데이터는 캡처 시간(capture time)에서 동기화된다. 예를 들어, 시계열의 각 요소가 캡처되면, 대응하는 관련 데이터의 세트는 캡처되고 시계열 요소와 저장(save)된다. 다양한 실시예에서, 관련 데이터의 일정 기간은 설정될 수 있고/거나 요소들의 시계열의 일정 기간과 일치(match)한다. 일부 실시예에서, 관련 데이터는 시계열 요소들과 같은 속도(rate)로 샘플링(sample)된다.

[0055] (305)에서, 시계열에 대한 그라운드 트루스가 결정된다. 다양한 실시예에서, 시계열은 머신 러닝 특징(machine learning feature)과 연관된(associated) 그라운드 트루스를 결정하기 위해서 분석(analyze)된다. 예를 들어, 차선 경계선은 해당 차선 경계선에 대한 그라운드 트루스에 대응하는 시계열에서 식별된다. 다른 예로, 이동 물체(차량, 보행자(pedestrian), 자전거 타는 사람(biker), 동물(animal) 등과 같은)의 경로에 대한 그라운드 트

루스는 시계열에서 감지(detect)된 이동 물체에 대해 식별된 경로이다. 일부 실시예에서, 움직이는 차량이 시계열에 걸쳐 자율 주행 차량의 차선으로 진입하는 경우, 움직이는 차량은 진입(cut-in)하는 차량으로 주석이 달린다. 일부 실시예에서, 그라운드 트루스는 3차원 궤적(three-dimensional trajectory)과 같은 3차원 표현으로 표현된다. 예를 들어, 차선과 연관된(associated) 그라운드 트루스는 3차원 매개변수화 된(parameterized) 스플라인(spline) 또는 곡선(curve)으로 표현될 수 있다. 다른 예로서, 감지된 차량에 대한 예측된 경로는 3차원 궤적으로 결정되고 표현된다. 예측된 경로는 차량이 점유된(occupied) 공간에 합류(merge)할 것인지 여부를 결정하는데 사용될 수 있다. 다양한 실시예에서, 요소들의 시계열을 조사하는 것만으로도 그라운드 트루스가 결정될 수 있다. 예를 들어, 시계열의 부분집합(subset)만을 분석하면 가려진 일부 차선 경계선이 가려진(occlude) 채로 남겨질 수 있다. 요소들의 시계열에 걸친 분석을 확장(expand)하면, 차량 차선의 가려진 부분이 드러난다(reveal). 더욱이, 시계열의 끝 쪽에 있는 캡처된 데이터는 더 멀리 떨어진 차선 경계선의 세부사항을 더 정확하게 (예를 들어, 더 높은 신뢰도(fidelity)로) 캡처한다. 추가로, 관련 데이터는 가까운 거리에서(거리 및 시간 모두) 캡처된 데이터를 기초로 하기 때문에 관련 데이터는 또한 더 정확하다. 다양한 실시예에서, 동시적인 로컬라이제이션(simultaneous localization)과 매핑 기술(mapping techniques)은, 물체(object)의 서로 다른 부분들을 고도(elevation)를 포함하는 정확한 3차원 위치로 매핑하기 위하여, 요소들의 시계열 중 서로 다른 요소들(different elements)에서 식별된, 차선 경계선과 같은, 감지된 물체의 서로 다른 부분(different portions)에 적용된다. 매핑된(mapped) 3차원 위치 세트는 시계열에 걸쳐 캡처된 차선 경계선의 부분(segment)과 같은 물체의 그라운드 트루스를 표현한다. 일부 실시예에서, 로컬라이제이션 과 매핑 기술은 정확한 포인트의 세트(set of precise point), 예를 들어 차량 차선 경계선을 따라 다른 포인트에 대응하는 포인트의 세트(set of points)를 생성(result)한다. 포인트의 세트는 스플라인(spline) 또는 파라메트릭 곡선(parametric curve)과 같은 더 효율적인 형식으로 전환(convert)될 수 있다. 일부 실시예에서, 그라운드 트루스는 차선 경계선, 주행가능 공간, 교통 통제, 차량 등과 같은 물체를 3차원으로 감지(detect)하기위해서 결정된다(determine).

[0056] 일부 실시예에서, 그라운드 트루스는 의미론적 레이블(semantic labels)을 예측하기위해서 결정된다. 예를 들어, 감지된 차량은 좌측 차선 또는 우측 차선에 있는 것으로 레이블(label) 될 수 있다. 일부 실시예에서, 감지된 차량은 사각지대(blind spot)에 있는, 양보해야 하는 차량으로, 또는 다른 적절한 의미론적 레이블로서 레이블 될 수 있다. 일부 실시예에서, 차량은 결정된 그라운드 트루스에 기초한 지도의 도로 또는 차선에 배치(assign)된다. 추가적인 예시에서, 결정된 그라운드 트루스는 신호등(traffic light), 차선, 주행가능 공간, 또는 다른 자율 주행을 돕는(assist) 특징을 레이블하기 위해서 사용될 수 있다.

[0057] 일부 실시예에서, 관련 데이터는 감지된 물체의 깊이(depth)(또는 거리) 데이터이다. 요소들의 시계열에서 식별된 물체와 거리 데이터를 연결함으로써(associating), 머신 러닝 모델은 관련 거리 데이터를 감지된 물체의 그라운드 트루스로 사용하여 물체 거리를 추정하도록 훈련될 수 있다. 일부 실시예에서, 거리는 장애물, 장벽(barrier), 이동 차량, 정지 차량, 교통 통제 표지판, 보행자 등과 같은 감지된 물체에 대한 것이다.

[0058] (307)에서, 트레이닝 데이터가 포장(package)된다. 예를 들어, 시계열의 요소는 선택되고 (305)에서 결정된 그라운드 트루스와 연관(associate)된다. 다양한 실시예에서, 선택된 요소는 시계열의 초기 요소이다. 선택된 요소는 머신 러닝 모델에 입력된(input) 센서 데이터(sensor data)를 나타내고(represent) 그라운드 트루스는 예측된 결과를 표현한다. 다양한 실시예에서, 트레이닝 데이터는 트레이닝 데이터로서 포장(package)되고 준비(prepare)된다. 일부 실시예에서, 트레이닝 데이터는 훈련, 검증, 및 테스트 데이터(testing data)로 포장된다. 결정된 그라운드 트루스 및 시계열의 선택된 요소에 기초하여, 트레이닝 데이터는 머신 러닝 모델이 차선 경계선, 차량의 예측 경로, 속도 제한, 차량 진입(vehicle cut-ins), 물체 거리, 및/또는 주행가능 공간, 자율 주행을 위한 다른 유용한 기능을 식별하도록 훈련(train)하기 위해 포장(package)될 수 있다. 포장된 트레이닝 데이터는 이제 머신 러닝 모델을 훈련하기 위해서 사용 가능하다.

[0059] 도 4는 자율 주행을 위한 머신 러닝 모델을 훈련 및 적용하기 위한 프로세스의 실시예를 도시한 흐름도이다. 일부 실시예에서, 도 4의 프로세스는 자율 주행을 위한 머신 러닝모델을 훈련하기 위한 센서 및 주행 거리 측정 데이터를 수집(collect)하고 유지(retain)하기 위해 이용된다. 일부 실시예에서, 도 4의 프로세스는 자율 주행 제어가 활성화(enable)되었는지 여부와 관계없이 자율 주행이 가능한 차량에서 구현(implement)된다. 예를 들어, 센서 및 주행 거리 측정 데이터는 자율 주행이 해제(disengage)된 직후 순간, 차량이 인간 운전자에게 의해 운전되어지는 동안 및/또는 차량이 자율 주행 되는 동안에 수집(collect)될 수 있다. 일부 실시예에서, 도 4에 설명된 기술은 도 1의 딥 러닝 시스템을 사용하여 구현(implement)될 수 있다. 일부 실시예에서, 도 4의 프로세스의 부분은 자율 주행을 위한 머신 러닝 모델을 적용하는 프로세스의 부분으로서 도 2의 (207), (209), 및/또는 (211)에서 수행된다.

- [0060] (401)에서, 센서 데이터가 수신된다. 예를 들어, 센서가 장착된(equipped) 차량은 센서 데이터를 캡처하고 차량에서 구동(run)되는 신경망에 센서 데이터를 제공한다. 일부 실시예에서, 센서 데이터는 비전 데이터(vision data), 초음파 데이터(ultrasonic data), 라이다 데이터(LiDaR data), 또는 다른 적절한 센서 데이터일 수 있다. 예를 들어, 이미지는 하이 다이내믹 레인지(high dynamic range) 전방 카메라(forward-facing camera)로부터 캡처된다. 다른 예로서, 초음파 데이터는 측방 초음파 센서로부터 캡처된다. 일부 실시예에서, 차량은 데이터를 캡처하기 위한 다수의 센서들과 부착(affix)된다. 예를 들어, 일부 실시예에서, 8개의 서라운드 카메라(surround camera)가 차량에 부착되고 250미터까지의 범위로 차량 주변의 360도의 시인성(visibility)을 제공(provide)한다. 일부 실시예에서, 카메라 센서는 와이드 전방 카메라(wide forward camera), 내로우 전방 카메라(narrow forward camera), 후방 카메라(rear view camera), 전방을 바라보는 측방 카메라(forward looking camera), 및 또는 후방을 바라보는 측방 카메라(rearward looking side camera)를 포함한다. 일부 실시예에서, 초음파 및/또는 레이더 센서는 주변 세부사항을 캡처하는데 사용된다. 예를 들어, 12개의 초음파 센서는 단단한(hard) 물체와 부드러운(soft) 물체 모두를 감지(detect)하기 위해서 차량에 부착될 수 있다. 일부 실시예에서, 전방 레이더(forward-facing radar)는 주변 환경의 데이터를 캡처하기 위해 이용(utilize)된다. 다양한 실시예에서, 레이더 센서는 폭우(heavy rain), 안개(fog), 먼지(dust), 및 다른 차량에도 불구하고 주변 세부사항을 캡처할 수 있다. 다양한 센서는 차량 주변 환경을 캡처하는데 사용되고, 캡처된 데이터는 딥 러닝 분석을 위해 제공된다.
- [0061] 일부 실시예에서, 센서 데이터는 차량의 위치, 방향, 위치의 변경, 및/또는 방향의 변경 등을 포함하는 주행 거리 측정 데이터를 포함한다. 예를 들어, 위치 데이터는 캡처되고 동일한 시간 프레임의 동안에 캡처된 다른 센서 데이터와 연결(associate)된다. 일례로, 이미지 데이터가 캡처될 때 캡처된 위치 데이터는 이미지 데이터와 위치 정보를 연결(associate)하는데 사용된다.
- [0062] (403)에서, 센서 데이터는 전처리된다(pre-processed). 일부 실시예에서, 하나 이상의 전처리 패스(pre-processing passes)가 센서 데이터에 대해 수행(perform)된다. 예를 들어, 데이터는 노이즈(noise) 제거, 정렬(alignment) 문제 및/또는 흐림(blurring) 수정 등을 위해서 전처리 될 수 있다. 일부 실시예에서, 하나 이상의 다른 필터링 패스(filtering passes)가 데이터에 대해 수행된다. 예를 들어, 센서 데이터의 상이한 구성요소를 분리하기 위해 하이패스 필터(high-pass filter)는 데이터에 대해서 수행될 수 있고 로우패스 필터(low-pass filter)는 데이터에 대해서 수행될 수 있다. 다양한 실시예에서, (403)에서 수행되는 전처리 단계는 선택적이며/이거나 신경망에 통합(incorporate)될 수 있다.
- [0063] (405)에서, 센서 데이터의 딥 러닝 분석(deep learning analysis)이 시작(initiate)된다. 일부 실시예에서, 딥 러닝 분석은 (403)에서 선택적으로 전처리된 센서 데이터에 대해서 수행된다. 다양한 실시예에서, 딥 러닝 분석은 컨벌루션 신경망(CNN)과 같은 신경망을 사용하여 수행된다. 다양한 실시예에서, 머신 러닝 모델은 도 2의 프로세스(process)를 사용하여 오프라인(off-line)으로 훈련되고 센서 데이터에 대한 추론(inference)을 수행하기 위해 차량에 배치(deploy)된다. 예를 들어, 모델은 도로 차선 경계선(road lane lines), 장애물, 보행자, 이동 차량, 주차된 차량, 주행가능 공간 등을 적절하게 식별하도록 훈련될 수 있다. 일부 실시예에서, 차선 경계선에 대한 다수의 궤적(trajectories)들이 식별된다. 예를 들어, 차선 경계선에 대한 여러 잠재적인 궤적(potential trajectories)들은 감지(detect)되고 각 궤적은 대응하는 발생의 확률(probability of occurring)을 갖는다. 일부 실시예에서, 예측된 차선 경계선은 가장 높은 발생의 확률 및/또는 가장 높은 연관된 신뢰 값(confidence value)을 갖는 차선 경계선이다. 일부 실시예에서, 딥 러닝 분석으로부터 예측된 차선 경계선 최소 신뢰 임계값(confidence threshold value)을 초과하는 것을 요구한다. 다양한 실시예에서, 신경망은 하나 이상의 중간 계층(intermediate layer)을 포함하는 다수의 계층(layer)을 포함한다. 다양한 실시예에서, 센서 데이터 및/또는 딥 러닝 분석의 결과는 트레이닝 데이터의 자동 생성을 위하여 유지(retain)되고 (411)에서 전송(transmit)된다.
- [0064] 다양한 실시예에서, 딥 러닝 분석은 추가적인 특징을 예측하기위해서 사용된다. 예측된 특징은 자율 주행을 보조(assist)하기위해 사용될 수 있다. 예를 들어, 감지된 차량은 차선 또는 도로에 할당(assign)될 수 있다. 다른 예로서, 감지된 차량은 사각지대(blind spot)에 있을지, 양보(yield)해야 하는 차량이 될지, 좌측 인접한 차선에 있는 차량이 될지, 우측 인접한 차선에 있는 차량이 될지, 또는 다른 적절한 속성을 갖는지 결정될 수 있다. 마찬가지로, 딥 러닝 분석은 신호등, 주행가능 공간, 보행자, 장애물, 또는 운전을 위한 다른 적절한 특징을 식별할 수 있다.
- [0065] (407)에서, 딥 러닝 분석의 결과가 차량 제어에 제공된다. 예를 들어, 결과는 자율 주행을 위해 차량을 제어 및/또는 자율 주행 기능(functionality) 구현하기 위해서 차량 제어 모듈에 제공된다. 일부 실시예에서, (405)에서 딥 러닝 분석의 결과는 하나 이상의 상이한 머신 러닝 모델을 사용하여 하나 이상의 추가적인 딥 러닝 패스

(deep learning pass)를 통해서 전달(pass)된다. 예를 들어, 차선 경계선에 대한 예측된 경로는 차량 차선을 결정하는데 사용될 수 있고 결정된 차량 차선은 주행가능 공간을 결정하는데 사용될 수 있다. 주행가능 공간은 차량에 대한 경로를 결정하는데 사용된다. 유사하게, 일부 실시예에서, 예측된 차량 진입이 감지된다. 차량의 결정된 경로는 잠재적인 충돌(potential collisions)을 피하기(avoid) 위해 예측된 진입(cut-in)을 고려(account)한다. 일부 실시예에서, 딥 러닝의 다양한 출력은 차량의 예측된 경로, 식별된 장애물, 속도 제한을 포함하는 식별된 교통 통제 표지판 등을 포함하는 자율 주행을 위한 차량 환경(vehicle's environment)의 3차원 표현을 구성(construct)하는데 사용된다. 일부 실시예에서, 차량 제어 모듈은 결정된 경로를 따라 차량을 제어하기 위해 결정된 결과를 이용(utilize)한다. 일부 실시예에서, 차량 제어 모듈은 도 1의 차량 제어 모듈(109)이다.

[0066] (409)에서, 차량이 제어(control)된다. 일부 실시예에서, 자율 주행이 활성화(activate)된 차량은 도 1의 차량 제어 모듈(109)와 같은 차량 제어 모듈을 사용하여 제어된다. 차량 제어는, 예를 들어 차량의 주변 환경을 고려(consideration)하여 적절한 속도로 차선에 차량을 유지(maintain)하기 위해 속도 및/또는 차량의 조종을 조절(modulate)할 수 있다. 일부 실시예에서, 결과는 이웃 차량이 동일 차선으로 합류(merge)할 것을 예상하여 차량을 조정(adjust)하는데 사용된다. 다양한 실시예에서, 딥 러닝 분석의 결과를 사용하여, 차량 제어 모듈은, 예를 들어 결정된 경로를 따라서 적절한 속도로 차량을 작동하기 위해 적절한 방식(manner)을 결정한다. 다양한 실시예에서, 속도의 변화, 제동의 적용, 조종의 조정 등과 같은 차량 제어의 결과는 트레이닝 데이터의 자동 생성을 위해서 유지(retain)되고 사용(use)된다. 다양한 실시예에서, 차량 제어 매개변수들(vehicle control parameters)은 트레이닝 데이터의 자동 생성을 위해서 유지되고 (411)에서 전송(transmit)된다.

[0067] (411)에서, 센서 및 관련 데이터가 전송된다. 예를 들어, (405)에서 딥 러닝 분석의 결과 및/또는 (409)에서 사용된 차량 제어 매개변수와 함께 (401)에서 수신된 센서 데이터는 트레이닝 데이터의 자동 생성을 위해 컴퓨터 서버(computer server)에 전송된다. 일부 실시예에서, 데이터는 데이터의 시계열이고 다양한 수집된(gathered) 데이터는 컴퓨터 서버에 의하여 함께 연관(associate)된다. 예를 들어, 주행 거리 측정 데이터는 그라운드 트루스를 생성하기 위한 캡처된 이미지 데이터와 연관된다. 다양한 실시예에서, 수집된(collected) 데이터는, 예를 들어 와이파이(WiFi) 또는 셀룰러 연결(cellular connection)을 통하여, 차량으로부터 트레이닝 데이터 센터(training data center)로 무선으로 전송(transmit)된다. 다양한 실시예에서, 메타데이터(metadata)는 센서 데이터와 함께 전송된다. 예를 들어, 메타데이터는 하루 중 시간(time of day), 타임스탬프(timestamp), 위치, 차량의 타입(type of vehicle), 차량 제어 및/또는 속도, 가속도, 제동, 자율 주행이 활성화되었는지 여부, 조종 각도(steering angle), 주행 거리 측정 데이터 등과 같은 작동 매개변수를 포함할 수 있다. 추가 메타데이터는 마지막 이전 센서 데이터가 전송 되고부터 시간, 차량 타입(vehicle type), 기상 조건(weather conditions), 도로 조건(road conditions) 등을 포함한다. 일부 실시예에서, 전송된 데이터는, 예를 들어 차량의 고유 식별자(unique identifiers)를 제거하여 익명화(anonymize)된다. 또 다른 예로, 유사한 차량 모델의 데이터는 개별 사용자와 그들의 그들 차량 사용이 식별되는 것을 방지(prevent)하기 위해서 병합(merge)된다.

[0068] 일부 실시예에서, 데이터는 트리거(trigger)에 대한 응답으로만 전송(transmit)된다. 예를 들어, 일부 실시예에서, 부정확 예측은 딥 러닝 네트워크의 예측을 향상하기 위한 큐레이트된(curated) 예시의 세트를 생성하기 위해서 데이터를 자동으로 수집하기 위한 센서 및 관련 데이터의 전송을 촉발(trigger)한다. 예를 들어, 차량이 합류(merge)를 시도하는지 여부와 관련된 (405)에서 수행된 예측은 예측을 실제로 관찰된 결과와 비교함으로써 부정확한 것으로 결정된다. 잘못된 예측과 관련된 센서 및 센서 데이터를 포함하는 데이터는 트레이닝 데이터를 자동으로 생성하기 위해서 전송되고 사용된다. 일부 실시예에서, 트리거는 급 커브(sharp curves), 도로의 분기점(forks in the roads), 차선 병합(lane merges), 급 정지(sudden stops), 또는 추가 트레이닝 데이터가 도움이 되고 수집(gather)하기 어려울 수 있는 다른 적절한 시나리오와 같은 특정 시나리오를 식별하는데 사용될 수 있다. 예를 들어, 트리거는 자율 주행 특성(autonomous driving features)의 갑작스러운 비활성화(deactivation) 또는 해제(disengagement)를 기초로 할 수 있다. 또 다른 예로, 속도의 변화 또는 가속도의 변화와 같은 차량 작동 속성(vehicle operating properties)은 트리거의 기초를 형성할 수 있다. 일부 실시예에서, 특정 임계(threshold) 미만의 정확도를 갖는 예측은 센서 및 관련 데이터의 전송을 촉발(trigger)시킨다. 예를 들어, 어떤 시나리오에서, 예측은 불린-정확(Boolean correct) 또는 불린-부정확(Boolean incorrect) 결과를 갖지 않을 수 있으며, 대신에 예측의 정확도 값(accuracy value)을 결정함으로써 평가된다.

[0069] 다양한 실시예에서, 센서 및 관련 데이터는 일정 시간 기간에 걸쳐서 캡처되고 데이터의 전체 시계열은 함께 전송된다. 일정 기간은 차량의 속도, 이동한 거리(distance traveled), 속도의 변화 등과 같은 하나 이상의 요소(factors)로 구성 및/또는 기초로 할 수 있다. 일부 실시예에서, 캡처된 센서 및/또는 관련 데이터의 샘플링 속

도(sampling rate)는 설정할 수 있다(configurable). 예를 들어, 샘플링 속도는 고속에서(higher speed), 급정지(sudden braking) 동안, 급 가속(sudden acceleration) 동안, 급하게 조종하는(hard steering) 동안, 또는 추가적인 정확도(fidelity)를 필요로 하는 다른 적절한 시나리오에서 증가(increase)한다.

[0070] 도 5는 차량 센서로부터 캡처된 이미지의 일 예시를 도시한 도면이다. 도시된 예에서, 도 5의 이미지는 두 차선 경계선 사이 차선을 이동중인 차량으로부터 캡처된 이미지 데이터(image data)(500)를 포함한다. 이미지 데이터(500)를 캡처하는데 사용되는 차량 및 센서의 위치는 레이블 (A)로 표현(represent)된다. 이미지 데이터(500)은 센서 데이터이며 주행도중 차량의 전방 카메라와 같은 카메라 센서로부터 캡처될 수 있다. 이미지 데이터(500)은 차선 경계선의 일부(501 및 511)를 캡처한다. 차선 경계선(501 및 511)은 차선 경계선 (501 및 511)이 수평선(horizon)에 접근(approach)함에 따라 오른쪽으로 곡선을 이룬다(curve). 도시된 예에서, 차선 경계선(501 및 511)은 가시적(visible)이다, 그러나 카메라 센서의 위치에서 멀어지는 방향으로 곡선을 이루면서 감지하기가 점점 더 어려워진다. 차선 경계선(501 및 511)의 상단에 그려진 흰색 선은 어떤 추가 입력 없이 이미지 데이터(500)으로부터 차선 경계선(501 및 511)의 감지가능한(detectable) 부분(portion)을 근사화(approximate)한다. 일부 실시예에서, 차선 경계선(501 및 511)의 감지된 부분은 이미지 데이터(500)를 분할(segmenting)함으로써 감지(detect)될 수 있다.

[0071] 일부 실시예에서, 레이블 (A), (B) 및 (C)는 도로 상의 상이한 위치 및 시계열의 상이한 시간에 대응한다. 레이블 (A)는 시간 및 이미지 데이터(500)가 캡처된 시간에서 차량의 위치에 대응(correspond)한다. 레이블 (B)는 레이블 (A)의 위치의 앞 도로상의 위치와 레이블 (A)의 시간 이후의 시간에 대응한다. 유사하게, 레이블 (C)는 레이블 (B)의 위치의 앞 도로상의 위치와 레이블 (B)의 시간 이후의 시간에 대응한다. 차량이 이동(travel)하면서, 레이블 (A), (B) 및 (C)의 위치를 통과하고(레이블 (A)에서 레이블(C)로) 이동하는 동안에 센서의 시계열과 관련 데이터를 캡처한다. 시계열은 레이블 (A), (B) 및 (C) 위치(및 시간)에서 캡처된 요소들을 포함한다. 레이블 (A)는 시계열의 첫번째 요소에 대응(correspond)하고, 레이블 (B)는 시계열의 중간 요소에 대응하며, 레이블 (C)는 시계열의 중간(또는 잠재적으로 마지막) 요소에 대응한다. 각 레이블에서, 레이블의 위치에서 차량의 주행 거리 측정 데이터(odometry data)와 같은 추가 데이터가 캡처된다. 시계열의 길이에 의존하여, 추가적이거나 더 적은 데이터가 캡처된다. 일부 실시예에서, 타임스탬프(timestamp)는 시계열의 각 요소와 연관(associate)된다.

[0072] 일부 실시예에서, 차선 경계선(501 및 511)에 대한 그라운드 트루스(미도시)가 결정된다. 예를 들어, 본 명세서에 개시된 프로세스(process)를 사용하여, 차선 경계선(501 및 511)의 위치는 요소들의 시계열의 다른 요소들로부터 차선 경계선(501 및 511)의 다른 부분(different portion)을 식별(identify)함으로써 식별된다. 도시된 예에서, 부분(portions)(503 및 513)은 레이블 (A)의 시간 및 위치에서 취해진(take) 이미지 데이터(500) 및 관련 데이터(주행 거리 측정 데이터와 같은)를 사용하여 식별된다. 부분(505 및 515)는 레이블 (B)의 시간 및 위치에서 취해진 이미지 데이터(미도시) 및 관련 데이터(주행 거리 측정 데이터와 같은)를 사용하여 식별된다. 부분(507 및 517)은 레이블 (C)의 시간 및 위치에서 취해진 이미지 데이터(미도시) 및 관련 데이터(주행 거리 측정 데이터와 같은)를 사용하여 식별된다. 요소들의 시계열을 분석함으로써, 차선 경계선(501 및 511)의 다른 부분의 위치는 식별되고 그라운드 트루스는 상이한 식별된 부분을 결합함으로써 결정될 수 있다. 일부 실시예에서, 부분은 차량 차선의 각 부분을 따라 포인트(point)로 식별된다. 도시된 예에서, 각 차량 차선의 3개의 부분만이 프로세스(process)를 설명(explain)하기 위해 강조표시(highlight)되었다(차선 경계선(501)에 대한 부분(503), (505), 및 (507) 그리고 차선 경계선(511)에 대한 부분(513), (515), 및 (517)), 그러나 추가 부분은 높은 해상도(resolution) 및/또는 더 높은 정확도(accuracy)로 차선 경계선의 위치를 결정(determine)하기 위해서 시계열에 걸쳐서 캡처될 수 있다.

[0073] 다양한 실시예에서, 센서의 위치에서 가장 가까운 차선 경계선(501 및 511)을 캡처하는 이미지 데이터에서 부분의 위치(locations of portions)는 높은 정확도의 정도로 결정된다. 예를 들어, 부분(503 및 513)의 위치는 레이블 (A)의 이미지 데이터(500) 및 관련 데이터(주행 거리 측정 데이터와 같은)를 사용하여 높은 정확도의 정도로 식별된다. 부분(505 및 515)의 위치는 레이블 (B)의 이미지 및 관련 데이터를 사용하여 높은 정확도의 정도로 식별된다. 부분(507 및 517)의 위치는 레이블 (C)의 이미지 데이터 및 관련 데이터를 사용하여 높은 정확도의 정도로 식별된다. 요소들의 시계열을 이용함으로써, 시계열에 의해 캡처된 차선 경계선(501 및 511)의 다양한 부분의 위치는 3차원의 높은 정확도의 정도로 식별될 수 있고 차선 경계선(501 및 511)의 그라운드 트루스를 위한 기초로 사용될 수 있다. 다양한 실시예에서, 결정된 그라운드 트루스(ground truth)는 이미지 데이터(500)와 같은 시계열의 선택된 요소와 연관된다. 그라운드 트루스 및 선택된 요소는 차선 경계선을 예측하기 위한 트레이닝 데이터 생성에 사용될 수 있다. 일부 실시예에서, 트레이닝 데이터는 인간 레이블링(human labeling)

없이 자동으로 생성된다. 트레이닝 데이터는 이미지 데이터(500)과 같은 캡처된 데이터로부터 차선 경계선의 3차원 궤적을 예측하기위해서 머신 러닝 모델을 훈련하는데 사용될 수 있다.

[0074] 도 6은 차선 경계선의 3차원 궤적을 예측하여 차량 센서로부터 캡처한 이미지의 예를 도시한 도면이다. 도시된 예에서, 도 6의 이미지는 두 차선 경계선 사이의 차선을 이동하는 차량으로부터 캡처된 이미지 데이터(600)을 포함한다. 이미지 데이터(600)을 캡처하기 위하여 사용된 차량 및 센서의 위치는 레이블 (A)로 표현된다. 일부 실시예에서, 레이블 (A)는 도 5의 레이블 (A)와 동일한 위치에 대응한다. 이미지 데이터(600)은 센서 데이터(sensor data)이고 주행중인 차량의 전방 카메라와 같은 카메라 센서(camera sensor)로부터 캡처될 수 있다. 이미지 데이터(600)은 차선 경계선(601 및 611)의 부분을 캡처한다. 차선 경계선(601 및 611)은 차선 경계선(601 및 611)이 수평선에 접근함에 따라서 오른쪽으로 곡선을 이룬다(curve). 도시된 예에서, 차선 경계선(601 및 611)은 가시적이다, 그러나 카메라 센서의 위치로부터 멀어지는 방향으로 곡선을 이루고 거리에서 멀리 떨어질수록 감지하기 점점 어려워진다. 차선 경계선(601 및 611)에 그려진 빨간색 선은 차선 경계선(601 및 611)의 예측된 3차원 궤적이다. 본 명세서에 개시된 프로세스를 사용하여, 3차원 궤적은 훈련된 머신 러닝 모델에 대한 입력으로서 이미지 데이터(600)를 사용하여 예측된다. 일부 실시예에서, 예측된 3차원 궤적은 3차원 매개변수화 스플라인(three-dimensional parameterized spline) 또는 다른 표현의 매개변수화 형식으로 표현(represent)된다.

[0075] 도시된 예에서, 차선 경계선(601 및 611)의 부분(portions)(621)은 멀리 떨어져 있는 차선 경계선(601 및 611)의 일부(part)이다. 차선 경계선(601 및 611)의 부분(621)의 3차원 위치(즉, 경도(longitude), 위도(latitude), 및 고도(altitude))는 본 명세서에 개시된 프로세스를 사용하여 높은 정확도의 정도로 결정되고 차선 경계선(601 및 611)의 예측된 3차원 궤적에 포함된다. 훈련된 머신 러닝 모델을 사용하여, 차선 경계선(601 및 611)의 3차원 궤적은 차선 경계선(601 및 611)의 부분(621)의 위치에서 위치 데이터(location data)를 요구(require)하지 않으면서 이미지 데이터(600)를 사용하여 예측될 수 있다. 도시된 예에서, 이미지 데이터(600)은 레이블 (A)의 위치 및 시간에서 캡처된다.

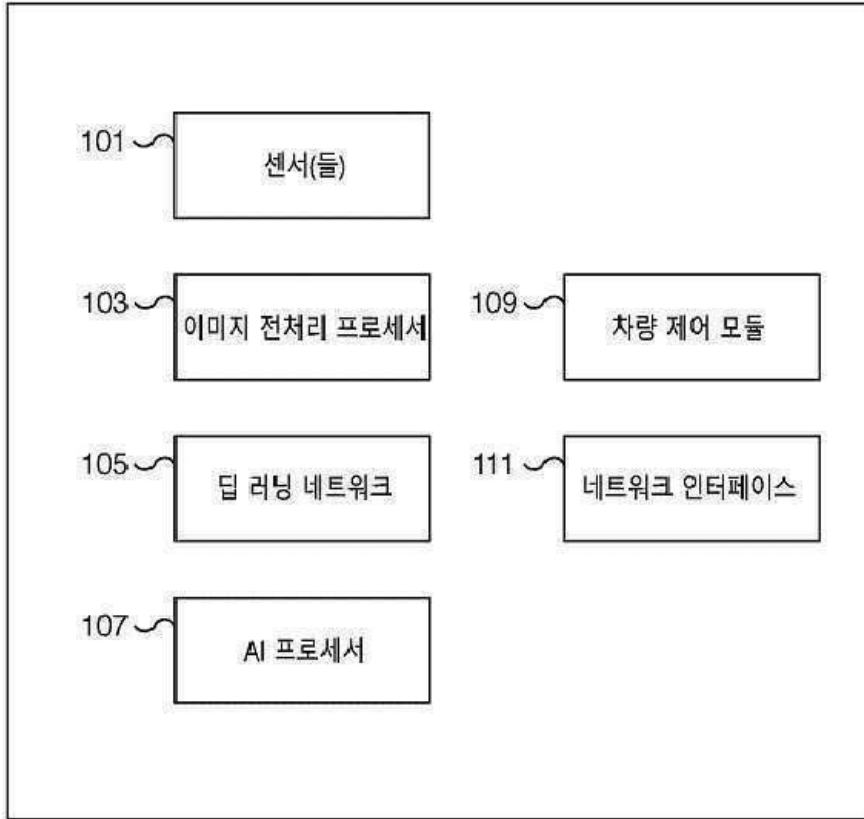
[0076] 일부 실시예에서, 도 6의 레이블 (A)는 도 5의 레이블 (A)에 대응하고 차선 경계선(601 및 611)의 예측된 3차원 궤적은 훈련된 머신 러닝 모델에 대한 입력으로서 이미지 데이터(600)만을 사용하여 결정된다. 도 5의 레이블 (A), (B), 및 (C)의 위치에서 취한(take) 요소들을 포함하는 시계열의 관련 데이터 및 이미지를 사용하여 결정된 그라운드 트루스를 사용하여 머신 러닝 모델을 훈련함으로써, 차선 경계선(601 및 611)의 3차원 궤적은, 부분(621)과 같은 먼 곳에 있는 차선 경계선의 부분(portion)도 높은 정확도의 정도로 예측된다. 이미지 데이터(600)와 도 5의 이미지 데이터(500)가 연관되어 있더라도, 궤적(trajectories)의 예측은 트레이닝 데이터에 포함될 이미지 데이터(600)을 요구하지(require) 않는다. 충분한 트레이닝 데이터의 훈련을 통해, 차선 경계선은 새로이 접하는(counter) 시나리오(scenario)에서도 예측될 수 있다. 다양한 실시예에서, 차선 경계선(601 및 611)의 예측된 3차원 궤적은 감지(detect)된 차선 경계선 내에서 차량의 위치를 유지(maintain)하기 위해 및/또는 예측 차선 경계선의 감지된 차선을 따라서 차량이 자율적으로 항행(navigate)하기 위해 사용된다. 차선 경계선을 3차원으로 예측함으로써, 항행(navigation)의 성능(performance), 안전성(safely) 및 정확성(accuracy)이 대단히 개선된다.

[0077] 전술한 실시예가 이해를 명료하게 하기 위한 목적으로 일부 상세하게 설명되었지만, 발명은 제공된 상세설명에 의해 제한되지 않는다. 본 발명을 구현하기 위한 다수의 대안적인 방법이 있다. 본 명세서에 개시된 실시예는 예시적이며 제한적이지 않다.

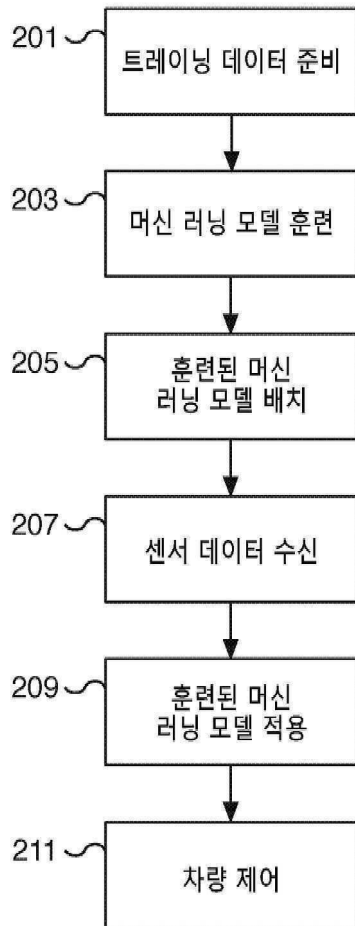
도면

도면1

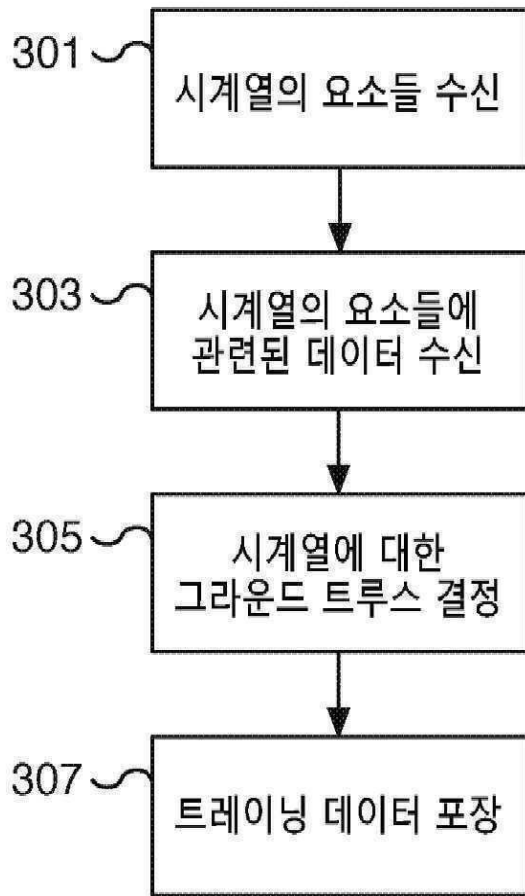
100



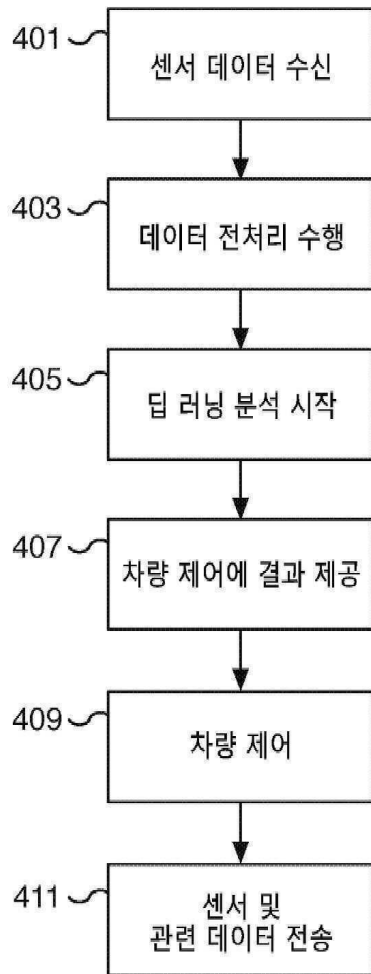
도면2




도면3



도면4



도면5



도면6

