



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2024년10월23일
(11) 등록번호 10-2721266
(24) 등록일자 2024년10월21일

(51) 국제특허분류(Int. Cl.)
G01N 21/88 (2006.01) G01N 21/954 (2006.01)
G06N 3/08 (2023.01) G06Q 50/10 (2012.01)
(52) CPC특허분류
G01N 21/8851 (2013.01)
G01N 21/954 (2013.01)
(21) 출원번호 10-2021-0105228
(22) 출원일자 2021년08월10일
심사청구일자 2021년08월10일
(65) 공개번호 10-2023-0023263
(43) 공개일자 2023년02월17일
(56) 선행기술조사문헌
KR102008973 B1*
KR102018330 B1*
KR1020210056437 A*
KR1020210076883 A*
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
문현준
서울특별시 서대문구 북아현로1가길 20, 101동 1506호(북아현동, e편한세상신촌 1단지)
민경복
서울특별시 서대문구 북아현로 29, 301동 801호(북아현동, 이편한세상신촌)
(뒷면에 계속)
(74) 대리인
송인호, 최관락

전체 청구항 수 : 총 7 항


심사관 : 이창호

(54) 발명의 명칭 딥러닝 기반 하수도 결함 감지 방법 및 그 장치

(57) 요약

딥러닝 기반 하수도 결함 감지 방법 및 그 장치가 개시된다. 딥러닝 기반 하수도 결함 감지 장치는, 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결함 분류 모델을 학습하되, 상이한 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 상기 딥러닝 기반 결함 분류 모델을 학습하는 학습부; 상기 하수도 동영상을 각 프레임 단위로 상기 학습된 딥러닝 기반 결함 분류 모델에 적용하여 결함 영역이 존재하는 결함 프레임들을 분류하는 결함 분류부; 상기 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결함 관련 컨텍스트 정보를 추출하는 텍스트 인식부; 및 상기 결함 프레임들과 상기 결함 관련 컨텍스트 정보를 이용하여 하수도 조사 보고서를 생성하는 보고서 생성부를 포함한다.

대표도 - 도1



(52) CPC특허분류

- G06N 3/08 (2023.01)
- G06Q 50/10 (2015.01)
- G01N 2021/8854 (2013.01)
- G01N 2021/8883 (2013.01)
- G01N 2021/8887 (2013.01)

(72) 발명자

남준영

인천광역시 부평구 부평문화로 138, 이안애비뉴 1
차 801호(부평동)

왕한성

서울특별시 광진구 군자로13길 18-2, 102호(
군자동)

당리민

서울특별시 광진구 동일로52길 11-12, 지하02호(군
자동)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345331679
과제번호	2020R1A6A1A03038540
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	이공학학술연구기반구축(R&D)
연구과제명	자율지능무인비행체연구소
기 여 율	1/1
과제수행기관명	세종대학교 산학협력단
연구기간	2021.03.01 ~ 2022.02.28

공지예외적용 : 있음

명세서

청구범위

청구항 1

트레이닝 데이터 세트를 이용하여 딥러닝 기반 결함 분류 모델을 학습하되, 상이한 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 상기 딥러닝 기반 결함 분류 모델을 학습하는 학습부;

상기 하수도 동영상은 각 프레임 단위로 상기 학습된 딥러닝 기반 결함 분류 모델에 적용하여 결함 영역이 존재하는 결함 프레임들을 분류하는 결함 분류부;

상기 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결함 관련 컨텍스트 정보를 추출하는 텍스트 인식부; 및

상기 결함 프레임들과 상기 결함 관련 컨텍스트 정보를 이용하여 하수도 조사 보고서를 생성하는 보고서 생성부를 포함하되,

상기 하수도 동영상은 각 프레임에 자막 정보가 포함되되,

상기 자막 정보는 조사 시작 캡션, 상기 조사 시작 캡션을 기준으로 각 프레임에 해당하는 하수도 위치까지의 이동 거리, 조사 날짜, 조사 시간, 하수도 유형 및 하수도 식별정보 중 적어도 하나를 포함하며,

상기 텍스트 인식부는, 상기 하수도 동영상 중 일부 프레임에 대해 상기 조사 시작 캡션에 대한 템플릿에 대한 매칭 여부를 수행하되, 매칭되는 프레임 검출시 검출된 프레임 이전의 프레임들은 검사 대상 프레임이 아닌 것으로 판단하여 제거하되,

상기 텍스트 인식부에 의해 상기 하수도 동영상의 각 프레임에 포함된 자막 정보 중 동일한 이동 거리가 인식된 이후 시작 시간 및 종료 시간이 기준 시간을 초과하는 경우, 해당하는 프레임들은 결함이 존재하는 것으로 인식되어 상기 학습된 딥러닝 기반 결함 분류 모델에 입력되어 결함 영역의 존재 여부가 검사되는 것을 특징으로 하는 딥러닝 기반 하수도 결함 감지 장치.

청구항 2

삭제

청구항 3

삭제

청구항 4

삭제

청구항 5

제1 항에 있어서,

상기 결함 분류부는,

상기 딥러닝 기반 결함 분류 모델에서 추출된 특징맵을 이용하여 결함 영역이 강조된 클래스 활성화 맵 및 레이어 활성화 시각화 맵을 생성하되,

상기 클래스 활성화 맵 및 상기 레이어 활성화 시각화 맵은 상기 결함 프레임의 분류 결과 설명에 이용되는 것을 특징으로 하는 딥러닝 기반 하수도 결함 감지 장치.

청구항 6

제1 항에 있어서,

상기 학습부는,

상기 XGBoost(Extream gradient boosting) 기법과 LightGBM(light gradient boosting machine) 기법을 이용하여 상기 딥러닝 기반 결합 분류 모델을 학습하되, 결합 분류 클래스별로 서로 다른 오분류 비용을 할당하여 상기 딥러닝 기반 결합 분류 모델을 학습하는 것을 특징으로 하는 딥러닝 기반 하수도 결합 감지 장치.

청구항 7

(a) 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습하되, 상이한 양상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 상기 딥러닝 기반 결합 분류 모델을 학습하는 단계;

(b) 상기 하수도 동영상은 각 프레임 단위로 상기 학습된 딥러닝 기반 결합 분류 모델에 적용하여 결합 영역이 존재하는 결합 프레임들을 분류하는 단계;

(c) 상기 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 추출하는 단계; 및

(d) 상기 결합 프레임들과 상기 결합 관련 컨텍스트 정보를 이용하여 하수도 조사 보고서를 생성하는 단계를 포함하되,

상기 하수도 동영상은 각 프레임에 자막 정보가 포함되되,

상기 자막 정보는 조사 시작 캡션, 상기 조사 시작 캡션을 기준으로 각 프레임에 해당하는 하수도 위치까지의 이동 거리, 조사 날짜, 조사 시간, 하수도 유형 및 하수도 식별정보 중 적어도 하나를 포함하되,

상기 (c) 단계는,

상기 하수도 동영상에 대한 일부 프레임에 대해 상기 조사 시작 캡션에 대한 템플릿의 매칭 여부를 판단하여 매칭되는 프레임 검출시 검출된 프레임 이전의 프레임들은 검사 대상 프레임이 아닌 것으로 판단하여 제거하며,

상기 (b) 단계는,

상기 하수도 동영상의 각 프레임에 포함된 자막 정보 중 동일한 이동 거리가 인식된 이후 시작 시간 및 종료 시간이 기준 시간을 초과하는 경우, 해당하는 프레임들은 결합이 존재하는 것으로 인식되어 상기 학습된 딥러닝 기반 결합 분류 모델에 입력되어 결합 영역의 존재 여부가 검사되는 것을 특징으로 하는 딥러닝 기반 하수도 결합 감지 방법.

청구항 8

삭제

청구항 9

삭제

청구항 10

삭제

청구항 11

제7 항에 있어서,

상기 (b) 단계는,

상기 딥러닝 기반 결합 분류 모델에서 추출된 특징맵을 이용하여 결합 영역이 강조된 클래스 활성화 맵 및 레이

어 활성화 시각화 맵을 생성하되,

상기 클래스 활성화 맵 및 상기 레이어 활성화 시각화 맵은 상기 결합 프레임의 분류 결과 설명에 이용되는 것을 특징으로 하는 딥러닝 기반 하수도 결합 감지 방법.

청구항 12

제7 항에 있어서,

상기 (a) 단계는,

XGBoost(Extream gradient boosting) 기법과 LightGBM(light gradient boosting machine) 기법을 이용하여 상기 딥러닝 기반 결합 분류 모델을 학습하되, 결합 분류 클래스별로 서로 다른 오분류 비용을 할당하여 상기 딥러닝 기반 결합 분류 모델을 학습하는 것을 특징으로 하는 딥러닝 기반 하수도 결합 감지 방법.

청구항 13

제7 항에 따른 방법을 수행하기 위한 프로그램 코드를 기록한 컴퓨터로 판독 가능한 기록매체.

발명의 설명

기술 분야

[0001] 본 발명은 딥러닝 기반 하수도 결합 감지 방법 및 그 장치에 관한 것이다.

배경 기술

[0003] 하수관로와 같은 콘크리트 구조물에는 건설 시간, 비용, 유지보수 비용 등 많은 인력, 비용, 시간이 필요하다. 하수관을 적절하게 관리하지 않는다면 수질 문제, 오수, 빗물 등의 문제로 심각한 인명피해를 초래할 수 있다. 이런 문제가 발생하지 않기 위해 하수관로의 관리는 중요하다.

[0004] 이전의 하수관 관리는 검사관이 직접 하수관을 살펴 검사하거나 CCTV 영상을 수동으로 결합을 관찰하고 하수관로의 상태의 심각성에 따라 유지 보수하는 방식을 사용하였다. 이 방식은 검사관의 경험 부족이나 피로로 인해 실수가 발생할 수 있다.

[0005] 그러나 최근에는 로봇과 스캐너 장치를 활용하여 하수관로 검사 및 유지보수에 사용되어 비용도 절감하고 검사의 효율성을 높이고 있다. 로봇에 의해 기록된 CCTV 영상은 비위생적 환경이나 사람이 접근할 수 없는 환경을 모니터링하기 효과적이다. 수집된 CCTV 영상은 방대한 양이기 때문에 딥러닝(Deep Learning)을 이용한 결합 자동 인식 시스템 구현이 중요하다.

발명의 내용

해결하려는 과제

[0007] 본 발명은 딥러닝 기반 하수도 결합 감지 방법 및 그 장치를 제공하기 위한 것이다.

[0008] 본 발명은 로봇에 의해 촬영된 영상을 기반으로 하수도내 결합을 인식하여 자동으로 보고서를 생성할 수 있는 딥러닝 기반 하수도 결합 감지 방법 및 그 장치를 제공하기 위한 것이다.

과제의 해결 수단

[0010] 본 발명의 일 측면에 따르면, 딥러닝 기반 하수도 결합 감지 장치가 제공된다.

[0011] 본 발명의 일 실시예에 따르면, 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습하되, 상기한 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 상기 딥러닝 기반 결합 분류 모델을 학습하는 학습부; 상기 하수도 동영상을 각 프레임 단위로 상기 학습된 딥러닝 기반 결합 분류 모델에 적용하여 결합 영

역이 존재하는 결합 프레임들을 분류하는 결합 분류부; 상기 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 추출하는 텍스트 인식부; 및 상기 결합 프레임들과 상기 결합 관련 컨텍스트 정보를 이용하여 하수도 조사 보고서를 생성하는 보고서 생성부를 포함하는 딥러닝 기반 하수도 결합 감지 장치가 제공될 수 있다.

- [0012] 상기 하수도 동영상은 각 프레임에 자막 정보가 포함되되, 상기 자막 정보는 조사 시작 캡션, 상기 조사 시작 캡션을 기준으로 각 프레임에 해당하는 하수도 위치까지의 이동 거리, 조사 날짜, 조사 시간, 하수도 유형 및 하수도 식별정보 중 적어도 하나를 포함할 수 있다.
- [0013] 상기 텍스트 인식부는, 상기 하수도 동영상 중 일부 프레임에 대해 특정 템플릿에 대한 매칭 여부를 수행하되, 매칭되는 프레임 검출시 검출된 프레임 이전의 프레임들은 검사 대상 프레임이 아닌 것으로 판단하여 제거할 수 있다.
- [0014] 상기 텍스트 인식부에 의해 상기 하수도 동영상의 각 프레임에 포함된 자막 정보 중 이동 거리가 인식된 이후 시작 시간 및 종료 시간이 기준 시간을 초과하는 경우, 해당하는 프레임들은 결합이 존재하는 것으로 인식되어 상기 학습된 딥러닝 기반 결합 분류 모델에 입력되어 결합 영역의 존재 여부가 검사될 수 있다.
- [0015] 상기 결합 분류부는, 상기 딥러닝 기반 결합 분류 모델에서 추출된 특징맵을 이용하여 결합 영역이 강조된 클래스 활성화 맵 및 레이어 활성화 시각화 맵을 생성하되, 상기 클래스 활성화 맵 및 상기 레이어 활성화 시각화 맵은 상기 결합 프레임의 분류 결과 설명에 이용될 수 있다.
- [0016] 상기 학습부는, 상기 XGBoost(Extream gradient boosting) 기법과 LightGBM(light gradient boosting machine) 기법을 이용하여 상기 딥러닝 기반 결합 분류 모델을 학습하되, 결합 분류 클래스별로 서로 다른 오분류 비용을 할당하여 상기 딥러닝 기반 결합 분류 모델을 학습할 수 있다.
- [0018] 본 발명의 다른 측면에 따르면, 딥러닝 기반 하수도 결합 감지 방법이 제공된다.
- [0019] 본 발명의 일 실시예에 따르면, (a) 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습하되, 상이한 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 상기 딥러닝 기반 결합 분류 모델을 학습하는 단계; (b) 상기 하수도 동영상을 각 프레임 단위로 상기 학습된 딥러닝 기반 결합 분류 모델에 적용하여 결합 영역이 존재하는 결합 프레임들을 분류하는 단계; (c) 상기 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 추출하는 단계; 및 (d) 상기 결합 프레임들과 상기 결합 관련 컨텍스트 정보를 이용하여 하수도 조사 보고서를 생성하는 단계를 포함하는 딥러닝 기반 하수도 결합 감지 방법이 제공될 수 있다.

발명의 효과

- [0021] 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 감지 방법 및 그 장치를 제공함으로써, 본 발명은 로봇에 의해 촬영된 영상을 기반으로 하수도내 결합을 인식하여 자동으로 보고서를 생성할 수 있는 이점이 있다.

도면의 간단한 설명

- [0023] 도 1은 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 감지 시스템을 개략적으로 도시한 도면.
- 도 2 및 도 3은 본 발명의 일 실시예에 따른 결합 데이터 세트를 설명하기 위해 도시한 도면.
- 도 4는 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델의 학습 과정을 설명하기 위해 도시한 도면.
- 도 5는 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델의 상세 구조를 도시한 도면.
- 도 6은 본 발명의 일 실시예에 따른 결합 분류 과정을 설명하기 위해 도시한 도면.
- 도 7 및 도 8은 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델에서의 분류 결과 설명을 위한 시각화를 설명하기 위해 도시한 도면.
- 도 9는 본 발명의 일 실시예에 따른 각 프레임에 포함된 자막 정보를 예시한 도면.
- 도 10은 본 발명의 일 실시예에 따른 텍스트 인식부의 상세 구조를 도시한 도면.
- 도 11은 본 발명의 일 실시예에 따른 로봇이 7초 동안 조사하기 위해 정지했을때 결합이 있는 하수도의 샘플 이미지를 예시한 도면.

- 도 12는 본 발명의 일 실시예에 따른 결함 검사를 위한 의사 코드의 일 예를 예시한 도면.
- 도 13은 본 발명의 일 실시예에 따른 보고서 템플릿의 일 예를 도시한 도면.
- 도 14는 본 발명의 일 실시예에 따른 하수도 조사 결과에 따른 보고서를 예시한 도면.
- 도 15는 본 발명의 일 실시예에 따른 딥러닝 기반 결함 분류 모델의 훈련 및 검증 프로세스의 정확성과 손실을 나타낸 도면.
- 도 16은 본 발명의 일 실시예에 따른 테스트 세트의 균열 분류에 대한 혼동 매트릭스를 예시한 도면.
- 도 17은 종래와 본 발명의 일 실시예에 따른 결함 분류 결과를 비교한 결과를 도시한 도면.
- 도 18은 서로 다른 균형 비율에서 균열 원주 (CC:crack circumferential) 이미지 및 비 균열 이미지(NC:non-crack images) 수를 나타낸 도면.
- 도 19는 불균형 데이터 세트에 대한 네 가지 방법의 ACU 비교한 도면.
- 도 20은 수동으로 생성된 보고서와 본 발명의 일 실시예에 따라 생성된 보고서의 자동 균열 분류 및 위치 인식 결과를 비교한 결과를 나타낸 도면.
- 도 21은 수동으로 생성된 보고서와 본 발명의 일 실시예에 따라 생성된 보고서의 감지된 균열 수를 비교한 결과를 나타낸 도면.
- 도 22는 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결함 검사 방법을 나타낸 순서도.
- 도 23은 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결함 감지를 위한 아키텍처를 예시한 도면.

발명을 실시하기 위한 구체적인 내용

- [0024] 본 명세서에서 사용되는 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "구성된다" 또는 "포함한다" 등의 용어는 명세서상에 기재된 여러 구성 요소들, 또는 여러 단계들을 반드시 모두 포함하는 것으로 해석되지 않아야 하며, 그 중 일부 구성 요소들 또는 일부 단계들은 포함되지 않을 수도 있고, 또는 추가적인 구성 요소 또는 단계들을 더 포함할 수 있는 것으로 해석되어야 한다. 또한, 명세서에 기재된 "...부", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어와 소프트웨어의 결합으로 구현될 수 있다.
- [0025] 이하, 첨부된 도면들을 참조하여 본 발명의 실시예를 상세히 설명한다.
- [0027] 도 1은 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결함 감지 시스템을 개략적으로 도시한 도면이고, 도 2 및 도 3은 본 발명의 일 실시예에 따른 결함 데이터 세트를 설명하기 위해 도시한 도면이고, 도 4는 본 발명의 일 실시예에 따른 딥러닝 기반 결함 분류 모델의 학습 과정을 설명하기 위해 도시한 도면이며, 도 5는 본 발명의 일 실시예에 따른 딥러닝 기반 결함 분류 모델의 상세 구조를 도시한 도면이고, 도 6은 본 발명의 일 실시예에 따른 결함 분류 과정을 설명하기 위해 도시한 도면이며, 도 7 및 도 8은 본 발명의 일 실시예에 따른 딥러닝 기반 결함 분류 모델에서의 분류 결과 설명을 위한 시각화를 설명하기 위해 도시한 도면이고, 도 9는 본 발명의 일 실시예에 따른 각 프레임에 포함된 자막 정보를 예시한 도면이며, 도 10은 본 발명의 일 실시예에 따른 텍스트 인식부의 상세 구조를 도시한 도면이고, 도 11은 본 발명의 일 실시예에 따른 로봇이 7초 동안 조사하기 위해 정지했을 때 결합이 있는 하수도의 샘플 이미지를 예시한 도면이고, 도 12는 본 발명의 일 실시예에 따른 결함 검사를 위한 의사 코드의 일 예를 예시한 도면이고, 도 13은 본 발명의 일 실시예에 따른 보고서 템플릿의 일 예를 도시한 도면이며, 도 14는 본 발명의 일 실시예에 따른 하수도 조사 결과에 따른 보고서를 예시한 도면이고, 도 15는 본 발명의 일 실시예에 따른 딥러닝 기반 결함 분류 모델의 훈련 및 검증 프로세스의 정확성과 손실을 나타낸 도면이며, 도 16은 본 발명의 일 실시예에 따른 테스트 세트의 균열 분류에 대한 혼동 매트릭스를 예시한 도면이고, 도 17은 종래와 본 발명의 일 실시예에 따른 결함 분류 결과를 비교한 결과를 도시한 도면이며, 도 18은 서로 다른 균형 비율에서 균열 원주 (CC:crack circumferential) 이미지 및 비 균열 이미지 (NC:non-crack images) 수를 나타낸 도면이고, 도 19는 불균형 데이터 세트에 대한 네 가지 방법의 ACU 비교한 도면이고, 도 20은 수동으로 생성된 보고서와 본 발명의 일 실시예에 따라 생성된 보고서의 자동 균열 분류 및 위치 인식 결과를 비교한 결과이며, 도 21은 수동으로 생성된 보고서와 본 발명의 일 실시예에 따라 생성된 보고서의 감지된 균열 수를 비교한 결과를 나타낸 도면이다.
- [0028] 도 1을 참조하면, 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결함 감지 장치(100)은 결함 데이터셋 생성

부(110), 학습부(115), 결합 분류부(120), 텍스트 인식부(125), 보고서 생성부(130), 메모리(135) 및 프로세서(140)를 포함하여 구성된다.

- [0029] 결합 데이터셋 생성부(110)는 하수도에서 촬영된 영상을 프레임 단위로 추출한 후 결합 유형별 클래스 샘플 이미지로 생성하기 위한 수단이다.
- [0030] 예를 들어, 결합 유형은 도 2에 도시된 바와 같이, 8개 클래스로 분류될 수 있다.
- [0031] 보다 상세히 설명하면, 하수도에서 촬영된 영상에서 모든 프레임을 추출한 후 수동으로 조사하여 도 2에 도시된 바와 같이, 8가지 결합 유형의 하수 결합을 포함하는 결합 데이터 세트를 생성할 수 있다.
- [0032] 이와 같이, 기본적인 결합 데이터 세트가 생성되면, 결합 데이터셋 생성부(110)는 증강 기술(예를 들어, 수평 뒤집기, 기울기 범위, 확대 및 축소 범위)을 적용하여 결합 데이터를 확장할 수 있다. 예를 들어, 각 결합 클래스별 데이터 증강 기술 적용 전후의 이미지 수는 도 3에 도시된 바와 같다.
- [0033] 학습부(115)는 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습하기 위한 수단이다. 트레이닝 데이터 세트는 결합 데이터셋 생성부(110)에서 생성된 결합 데이터 세트를 포함할 수 있다. 물론, 트레이닝 세트는 결합 데이터 세트 이외에도 정상적인 하수도 영상에 대한 데이터 세트를 포함할 수도 있다.
- [0034] 학습부(115)는 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습함에 있어, 서로 상이한 복수의 학습 기법을 기반으로 딥러닝 기반 결합 분류 모델을 학습할 수 있다.
- [0035] 도 4에는 딥러닝 기반 결합 분류 모델의 학습 과정이 예시되어 있다. 도 4에서 보여지는 바와 같이, 학습부(115)는 앙상블 기반 학습 기법과 비용 민감 기반 학습 기법을 사용하여 결합 분류 모델을 학습시킬 수 있다.
- [0036] 하수도를 촬영한 영상 중 결합 영역을 포함하는 영상보다는 결합이 없는 이미지의 수가 상대적으로 매우 많다. 즉, 딥러닝 기반 결합 분류 모델을 적절하게 학습하기 위한 결합 영역을 포함하는 영상은 매우 적을 수밖에 없으며, 이로 인해, 불균형 데이터 문제(IDP: imbalanced data problem)가 발생하게 된다. 따라서, 본 발명의 일 실시예에 따른 학습부(115)는 앙상블 기반 기법(Ensemble learning)과 비용 민감 학습 기법(cost-sensitive learning)을 적용하여 딥러닝 기반 결합 분류 모델을 학습시켜 불균형 데이터 문제를 해결할 수 있다.
- [0037] 우선, 앙상블 기반 학습 기법에 대해 간략하게 설명하기로 한다. 배깅(Bagging)과 부스팅(boosting)은 앙상블 기반 학습에 사용되는 두가지 주요 기술이다. 배깅 접근 방식은 원래 데이터 세트에서 무작위로 대체하여 여러 개의 새로운 훈련 하위 집합을 생성한다. 부스팅 방법은 초기 학습자가 데이터에 간단한 모델을 적용한 다음 데이터에서 오류를 조사하는 방식으로 연속적으로 훈련된다. 부스팅 방법은 다음 트리가 적합하면 모든 단계에서 이전 학습자의 정확성을 높이는 것이 목적이다.
- [0038] 배깅 기법은 단일 모델의 성능이 낮을 때 오류가 줄기 때문에 본 발명의 일 실시예에서는 상이한 복수의 부스팅 기법을 적용하여 결합 분류 모델을 학습하는 것을 가정하기로 한다.
- [0039] 예를 들어, 학습부(115)는 서로 상이한 복수의 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 딥러닝 기반 결합 분류 모델을 학습시킬 수 있다. 즉, 학습부(115)는 XGBoost(Extream gradient boosting) 기법과 LightGBM(light gradient boosting machine) 기법을 적용하여 딥러닝 기반 결합 분류 모델을 학습시킬 수 있다. XGBoost 기법과 LightGBM 기법은 최상의 트리를 얻기 위해 트리를 성장시킬 때 왼쪽 방향 성장 전략을 구현하고 Gradient Boosting 트리 접근 방식에 남아 있는 문제인 정보 손실 가능성을 방지할 수 있다.
- [0040] 또한, LightGBM이 GOSS(Gradient-based One-Side Sample) 메소드 호출을 적용하여 데이터 인스턴스를 분석하고 줄여 적절한 분할값을 알아내며, XGBoost는 가장 적절한 분할을 추정하기 위해 사전 정렬 기반 및 히스토그램 기반 알고리즘을 이용할 수 있다.
- [0041] 반복 t에서 XGBoost의 목적함수는 수학적 1과 같이 정의될 수 있다.

수학적 1

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i + f_t(x_i)) + ohm(f_t)$$

[0042]

[0043] 여기서, $l(\cdot)$ 은 실제 값 y_i 과 예측된 \hat{y}_i 의 차이를 추정하는 손실 함수를 나타낸다. 회귀 문제의 경우, $l(\cdot)$ 은 일반적으로 평균 제곱근 오차(RMSE: root mean square error)인 반면 분류 문제의 경우 로그 손실(logloss 또는 mlogloss)이다. ohm 은 XGBoost가 학습된 가중치를 평활화하여 과적합을 제어하는데 이용되는 정규화 매개 변수를 나타낸다. 정규화 값은 샘플 수와 샘플의 예측 임계값에 따라 할당될 수 있다.

[0044] LightGBM은 XGBoost의 통합 학습 방법을 사용하여 결합 분석 모델의 학습 시간을 줄일 수 있다. LightGBM은 XGBoost(반복 스캔 데이터)에 남아 있는 문제를 대처하기 위해 GOSS(gradient-based one-side sampling) 및 EFB(exclusive feature bundling)을 적용할 수 있다.

[0045] GOSS 알고리즘을 적용하여 정보 획득 계산에 도움이 되지 않는 더 작은 기율기로 일부 데이터를 제거하여 계산 복잡성을 줄일 수 있다. 또한, EFB 알고리즘을 적용하여 서로 독립적이지 않은 기능을 융합하고, 바인딩하여 기능 수를 줄일 수 있다.

[0046] 또한, LightGBM 알고리즘은 히스토그램 기반 알고리즘, weighted quantile sketch 알고리즘 및 최대 깊이에 제한이 있는 leaf-wise 방식을 적용하여 수렴 속도를 가속화하여 대규모 데이터 세트 처리에 적합한 이점이 있다.

[0047] 또한, 학습부(115)는 딥러닝 기반 결합 분류 모델 학습시, 결합 분류 클래스별로 서로 상이한 오분류 비용을 할당하여 학습시킬 수 있다.

[0048] 오분류 비용은 비용 매트릭스를 통해 적용될 수 있다. 예를 들어, 비용 행렬 $cm_{c_1c_2}$ 은 관찰을 클래스 c_1 에서 클래스 c_2 로 분류하는데 드는 평균 비용을 나타낸다. 행렬에서 모든 대각선 요소(정확한 분류)는 다음과 같다. 입력 x 에 대한 출력 O_i 을 결정하기 위한 위험 R은 수학적 식 2와 같이 나타낼 수 있다.

수학적 식 2

$$R(o_i | x) = \sum_i cm_{c_1c_2} P(v_j | x)$$

[0049]

[0050] 방정식을 통해 클래스 i 를 선택할 확률은 미리 결정된 오분류 비용에 따라 달라지며, 사후 확률(posterior probabilities)은 x 의 실측값에 대한 불확실성을 결정할 수 있다. 비용에 민감한 학습의 목표는 최소 위험 R로 클래스 v_j 를 생성하여 오분류 비용을 최소화하는 것이다.

[0051] 종래와 달리, 본 발명의 일 실시예에서는 결합 분류 모델 학습시, 모든 결합 분류 클래스에 대해 서로 다른 오분류 비용을 할당하여 학습할 수 있다.

[0052] 상술한 바와 같이, 학습부(115)에 의해 딥러닝 기반 결합 분류 모델에 대한 학습이 완료된 이후, 결합 분류부(120)는 학습된 딥러닝 기반 결합 분류 모델을 이용하여 하수도 촬영 동영상상 각 프레임 단위로 분석하여 결합 영역이 포함된 결합 프레임(영상)들을 분류할 수 있다.

[0053] 도 5에는 딥러닝 기반 결합 분류 모델의 상세 구조가 도시되어 있다.

[0054] 도 5에 도시된 바와 같이, 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델은 VGG19 아키텍처 기반 모델이며, 244 x 244 x 3 크기의 컬러 이미지를 입력받을 수 있다. 입력 영상은 크기가 3 x 3인 필터를 포함하는

16개의 컨볼루션 레이어를 통과할 수 있다. 스트라이드 및 공간 패딩(stride and spatial padding)은 각각 3 x 3 컨볼루션 레이어에 대해 모두 픽셀 1로 설정될 수 있다. 일부 컨볼루션 레이어 후단에 2 x 2 크기의 총 5개의 최대 풀링(max-pooling)이 부착되며, 스트라이드(stride)는 2로 설정될 수 있다.

- [0055] 일련의 컨볼루션 레이어 다음에는 3개의 완전 연결 레이어가 위치될 수 있다. 두개의 완전 연결 레이어는 각각 4096개의 뉴런을 포함하고 있으며, 마지막 완전 연결 계층의 출력 뉴런 수는 8개 클래스 수에 맞게 1000개에서 8개로 감소될 수 있다.
- [0056] 딥러닝 기반 결합 분류 모델은 하수도를 촬영한 영상을 입력받은 후 컨볼루션 연산을 통해 특징맵을 생성한 후 이를 이용하여 결합 영역을 포함하는 결합 프레임을 결합 분류 클래스별로 분류할 수 있다.
- [0057] 도 6에는 결합 분류부(120)의 결합 프레임(영상) 분류에 대한 상세 과정이 도시되어 있다. 도 6을 참조하여 결합 분류부(120)에서 결합 프레임(영상)을 분류하는 과정에 대해 보다 상세히 설명하기로 한다.
- [0058] 도 6에 도시된 바와 같이, 결합 분류부(120)는 하수도 동영상의 각 프레임 단위로 추출한 후, 추출한 프레임을 학습된 딥러닝 기반 결합 분류 모델에 입력한다. 이에 따라, 학습된 딥러닝 기반 결합 분류 모델은 하수도 동영상을 각 프레임 단위로 분석하여 결합 분류 과정을 수행함으로써 결합 영역이 존재하는 프레임(결합 프레임이라 칭하기로 함)을 분류할 수 있다.
- [0059] 결합 분류부(120)는 딥러닝 기반 결합 분류 모델에서 분류된 결합 프레임에 대해 결합 부위 특징에 따른 후처리 과정을 통해 최종 결합 부위를 추출한 후 결합 데이터 세트에 저장하며, 이는 딥러닝 기반 결합 분류 모델의 학습에 재 이용될 수 있다.
- [0060] 또한, 결합 분류부(120)는 딥러닝 기반 결합 분류 모델의 각 컨볼루션 레이어에서 추출되는 특징맵을 이용하여 클래스 활성화 맵(CAM: class activation map) 또는 레이어 활성화 시각화 맵을 생성할 수 있다.
- [0061] 각각에 대해 간략하게 설명하기로 한다.
- [0062] 클래스 활성화 맵은 딥러닝 기반 결합 분류 모델의 마지막 컨볼루션 레이어에서 획득된 특징맵(feature map)을 이용하여 생성될 수 있다. 즉, 클래스 활성화 맵은 딥러닝 기반 결합 분류 모델의 최종 컨볼루션 레이어에서 획득되는 특징맵을 글로벌 평균 풀링(GAP: global average pooling)한 후 그 결과값을 소프트 맥스(softmax)에 넣어 확률값을 얻는 결과이다.
- [0063] 즉, 클래스 활성화 맵은 소프트 맥스에서 획득된 클래스별 가중치를 최종 컨볼루션 레이어의 특징맵에 다시 투영하여 결합 클래스 분류에 영향을 미치는 중요한 부분(결합 영역)을 강조할 수 있다. 이로 인해, 딥러닝 기반 결합 분류 모델에서 특정 프레임을 특정 결합 분류 클래스로 분류하는 이유 설명에 이용될 수 있다.
- [0064] 도 7에는 딥러닝 기반 결합 분류 모델에서 분류된 결합 프레임과 해당 딥러닝 기반 결합 분류 모델이 해당 프레임을 결합 프레임으로 분류한 이유를 설명하는 클래스 활성화 맵이 예시되어 있다.
- [0065] 도 7에서 보여지는 바와 같이, 학습된 딥러닝 기반 결합 분류 모델이 특정 결합 클래스의 결합 영역이 클래스 활성화 맵에서 정확하게 강조 표시됨을 알 수 있다. 따라서, 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델이 결합 클래스에 따른 결합 영역을 정확하게 탐지하여 분류하는 것을 알 수 있다.
- [0066] 레이어 활성화 시각화 맵은 컨볼루션 레이어가 필터(특징맵)를 통해 영상의 중요한 특징을 추출하는 방법을 시각화할 수 있다. 즉, 딥러닝 기반 결합 분류 모델의 중간 활성화를 시각화하여 해당 딥러닝 기반 결합 모델이 여러 컨볼루션 레이어를 통해 프레임에서 모양, 엣지 및 색상과 같은 특정 추상 기능을 학습하는 방법을 시각화할 수 있다. 중간 활성화는 특정 컨볼루션 레이어의 특징 맵을 시각화할 수 있다. 각 특징 맵은 서로 다른 유형의 특징 맞춤이므로 이를 표현하는 가장 적절한 접근 방식은 특징맵의 콘텐츠를 2D 이미지로 별도 표시하는 것이다. 도 8에는 입력 이미지에 대한 첫 번째 및 마지막 컨볼루션 레이어에 대한 중간 활성화 시각화를 예시한 도면이다.
- [0067] 첫 번째 컨볼루션 레이어의 중간 활성화는 입력 프레임의 전체 모양을 유지하는 것을 알 수 있다. 입력 프레임의 바깥쪽 테두리에 초점을 맞추고 입력 프레임의 정보 대부분이 유지되는 것을 알 수 있다. 그러나, 단일 테두리, 모서리, 색상 및 각도와 같은 더 추상적인 특징은 딥러닝 기반 결합 분류 모델이 더 깊어지면서 학습되는 것을 알 수 있다. 따라서, 레이어 활성화 시각화 기법은 시각적으로 해석하기에는 다소 어렵다.
- [0068] 텍스트 인식부(125)는 하수도 동영상의 각 프레임에 포함된 자막 정보를 텍스트로 인식하여 결합 관련 컨텍스트 정보를 생성하기 위한 수단이다.

[0069] 하수도 동영상의 각 프레임에는 도 9에 도시된 바와 같이, 자막 정보들일 포함할 수 있다. 각 프레임에 포함되는 자막 정보는 동영상에서 조사 시작을 알리는 캡션 정보, 조사 날짜, 조사 시간, 하수도 유형, 하수도 직경, 이동 거리, 하수도 식별정보 중 적어도 하나를 포함할 수 있다. 여기서, 이동 거리는 조사 시작 시점부터 로봇이 이동한 이동 거리를 나타낼 수 있다.

[0070] 도 10에는 텍스트 인식부(125)의 상세 구조가 도시되어 있다. 도 10을 참조하여 텍스트 인식부(125)의 상세 구조에 대해 보다 상세히 설명하기로 한다.

[0071] 도 10에 도시된 바와 같이, 텍스트 인식부(125)는 프레임 통합부(1010), 전처리부(1020), 텍스트 감지 및 인식부(1030)를 포함할 수 있다.

[0072] 텍스트 인식부(125)가 하수도 동영상에 대한 자막 인식을 수행하기 전에, 로봇이 CCTV 영상을 하수관에 넣기 전에 녹화를 시작하는 경우, 도 9에 도시된 바와 같이, "조사 시작" 템플릿을 감지하여 템플릿 매칭 방식을 적용하여 하수도 외부의 프레임을 제거할 수 있다.

[0073] 템플릿 매칭 기법에 대해 간략하게 설명하기로 한다. 템플릿 매칭은 템플릿 이미지와 유사한 이미지 영역을 검색하는 방법이다. 템플릿 매칭은 수학적 3과 같은 상관 계수를 도출하여 템플릿 이미지와 원본 이미지와의 유사성을 판단할 수 있다.

수학식 3

$$\eta(x', y') = \frac{\sum_{i=1}^M \sum_{j=1}^N \{x'(i, j) \cdot y'(i, j)\}}{\sqrt{\sum_{i=1}^M \sum_{j=1}^N \{x'(i, j)\}^2} \sqrt{\sum_{i=1}^M \sum_{j=1}^N \{y'(i, j)\}^2}} \in [0, 1]$$

[0074]

[0075] 여기서, I는 P x Q 크기의 원본 이미지를 나타내며, T는 M x N 크기의 템플릿을 나타낸다. 또한,

$\eta(x', y')$ 는 레퍼런스 이미지와 원본 이미지 $\mathcal{C}(x', y')$ 간의 상호 상관에 해당하는 분수의 피제수를 나타낸다. 따라서, 템플릿 매칭을 통해 원본 이미지 스팟에 대한 요약이 수행될 수 있다.

$x' = 0..w - 1, y' = 0..h - 1.$

[0076] 원본 이미지와 템플릿의 일치 정도가 미리 정의된 임계값보다 크면 템플릿이 일치하는 것으로 간주될 수 있다. 템플릿 매칭 기법은 변형 불변하며, 이미지의 크기와 템플릿에 민감하다. 따라서, 템플릿의 텍스트 크기가 원본 이미지의 텍스트 크기보다 작거나 크면 템플릿 매칭되지 않을 가능성이 있다. 따라서, 본 발명의 일 실시예에서는 이미지 스케일링 변경에 대해서도 템플릿 매칭 기법 적용이 가능하도록 하기 위해 다중 스케일링 접근 방식을 적용할 수 있다. 즉, 원본 이미지의 크기를 다양한 크기로 스케일링하고, 스케일링된 원본 이미지에 대해 템플릿 매칭을 수행하여 상관 계수가 가장 높은 매칭을 추적하여 가장 중요한 상관 계수가 있는 일치 항목을 선택하여 일치된 영역으로 간주할 수 있다.

[0077] 즉, 도 9에 예시된 바와 같은 "조사 시작" 템플릿이 한 프레임에서 감지된 다음 해당 프레임 이전 프레임들을 삭제할 수 있다. 반면, "조사 시작" 템플릿이 감지되지 않는 경우, 모든 프레임에 대해 자막 인식 작업을 수행할 수도 있다.

[0078] 프레임 통합부(1010)는 하수도 동영상의 연속된 프레임들(예를 들어, 30 프레임)을 통합하여 평균 이미지를 계산하여 대비를 높이고 배경을 단순화하기 위해 다중 프레임 통합 과정을 수행할 수 있다.

[0079] 예를 들어, 프레임 통합부(1010)는 수학식 4와 같이 연속된 프레임들을 통합하여 평균 이미지를 출력할 수 있다.

수학식 4

$$\text{Average Image}_i(x, y) = \text{avg}_{j \in C_i}(p_j(x, y))$$

[0080]

[0081]

[0082]

[0083]

[0084]

[0085]

[0086]

[0087]

[0088]

[0089]

[0090]

[0091]

[0092]

[0093]

[0094]

여기서, $p_j(x, y)$ 는 프레임 j의 (x,y) 위치에 있는 픽셀값을 나타낸다.

이와 같이, 프레임 통합부(1010)에 의해 연속된 프레임들을 통합한 평균 이미지가 출력되면, 전처리부(1020)는 노이즈를 줄이기 위해 블러링(blurring), 히스토그램 이퀄라이저(histogram equalizer), 형태학적 연산(morphological operation)과 같은 이미지 전처리 과정을 수행한다.

전처리부(1020)는 프레임 통합부(1010)에서 출력된 이미지에 대해 전처리 과정을 수행한 후 에지를 검출하여 텍스트 감지 및 인식부(1030)로 출력할 수 있다.

텍스트 감지 및 인식부(1030)는 전처리부(1020)에서 출력된 에지 정보를 기반으로 자막 정보를 텍스트로 감지하여 인식하여 결합 관련 컨텍스트 정보를 생성할 수 있다. 텍스트 감지 및 인식부(1030)는 전처리부(1020)의 결과를 기초로 텍스트 지역화 및 검증을 통해 자막 정보를 감지하고 노이즈를 감소시키며 오정보를 제거한 후 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 생성할 수 있다.

예를 들어, 텍스트 감지 및 인식부(1030)는 결합 발생 위치를 알 수 있도록 이동 거리, 하수도 유형 등을 인식하여 결합 관련 컨텍스트 정보로 생성할 수 있다.

텍스트 감지 및 인식부(1030)는 OCR 엔진을 이용하여 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 생성할 수도 있다.

또한, 하수도 조사를 위해 로봇이 하수도 내부로 이동하도록 제어하는 동안 카메라를 통해 하수도 이상이 확인되면, 해당 위치에서 로봇을 정지시키고, 도11에 도시된 바와 같이 로봇에 장착된 카메라를 활용하여 360도 각도에서 균열을 검사하도록 할 수 있다. 도 11의 1110은 이동 거리로 변경되지 않음을 알 수 있다. 즉, 로봇이 작동 중 동작이 멈춰도 "이동 거리" 정보는 정확하게 동일하게 유지되는 것을 알 수 있다. 따라서, 텍스트 인식부(125)에 의해 이동 거리를 인식한 후 시작 시간 및 종료 시간이 3000ms(3s) 이상이면 균열이 있는 것으로 간주할 수 있다. 이에 대한 의사 코드는 도 12에 도시된 바와 같다.

보고서 생성부(130)는 결합 프레임들과 결합 관련 컨텍스트 정보를 이용하여 하수도 조사 결과에 따른 보고서를 생성하기 위한 수단이다.

예를 들어, 보고서 생성부(130)는 도 13에 도시된 바와 같이 보고서 템플릿을 이용하여 보고서를 생성할 수 있다. 보고서 템플릿은 도 13에서 보여지는 바와 같이, 하수도 전체 길이를 나타내는 템플릿이 포함되며, 결합 프레임이 검출된 위치를 기준으로 검출된 결합 프레임(이미지)와 결합 관련 컨텍스트 정보를 포함하여 보고서가 생성될 수 있다.

도 14에는 본 발명의 일 실시예에 따른 하수도 검사 보고서의 일 예가 도시되어 있다.

도 15는 본 발명의 일 실시예에 따른 정확도 및 손실 측면에서 훈련과 검증 결과를 도시한 도면이다. 증가된 데이터 세트에서 클래스당 7000개의 이미지로 전체 56,000개의 이미지가 무작위로 선택하였다. 데이터 세트를 두 부분으로 분리한 후 훈련 데이터 세트에 90%을 할당하고, 나머지 10%를 이용하여 검증을 수행하였다. 훈련 데이터 세트는 훈련 서버 세트와 검증 서버 세트의 두가지 서버 세트로 더 나뉠 수 있다.

처음에는 학습률을 0.001로 설정하고 검증 오차에 따라 천천히 0.0001로 최소화하였으며, 에포크 50회, 배치 크기 64로 학습되었으며 전체 학습 시간은 1시간 10분동안 지속하였다.

도 17에 도시된 바와 같이, 종래의 두가지 딥러닝 기반 결합 분류 모델과 비교한 결과, 본 발명의 일 실시예에 따른 딥러닝 기반 결합 분류 모델이 97.6%의 정확도로 매우 정확하게 결합을 분류하는 것을 알 수 있다.

도 18은 서로 다른 균형 비율에서 균열 원주(CC:crack circumferential) 이미지 및 비 균열 이미지(NC:non-crack images) 수를 나타낸 것으로, 데이터 불균형 실험을 수행하기 위해 두가지 클래스(균열 원주 및 비균열)

을 선택하였다. 두 클래스의 원본 이미지(본 이미지 (균열 원주 : 2380 및 비 균열 : 13,934)를 기반으로 균형 (1 : 1)에서 심각한 불균형 (1 : 100)까지 다양한 데이터 비율이 도 18에 도시된 바와 같다.

- [0095] 도 19는 데이터 불균형 데이터 세트에 대한 네가 방법의 ACU를 비교한 결과이다.
- [0096] 비용에 민감한 학습 방법을 사용하여 모델을 학습하기 전에 서로 다른 클래스 간의 데이터 비율을 사용하여 각 클래스에 해당하는 가중치를 설정하였다. 마이너 클래스에 속하는 모든 이미지는 다수 클래스에서 n개의 이미지로 간주 된다. 결과적으로 모델은 불균형 클래스와 균형 클래스를 균등하게 처리해야 한다. 반면 앙상블 학습 기반 접근 방식은 특징 추출 및 앙상블 학습을 포함하여 두 가지 주요 부분을 포함한다. 특징 추출 부분에서는 최종 소프트 맥스 분류기를 제거하여 결합 분류 모델을 특징 추출기로 전환하였다. 그런 다음 첫 번째 부분에서 추출된 4096개의 특징 벡터를 사용하여 두 번째 부분의 XGBoost/LightGBM 분류기를 학습시킨다. 도 18는 다양한 데이터 비율에 대한 결합 분류 모델(SD 모델), 비용에 민감한 학습 기반 모델(CS_SD), XGBoost SD 모델(XGB_SD) 및 LightGBM SD 모델(LGB_SD)을 포함한 4가지 모델의 AUC 값을 보여준다. AUC 값은 균열 둘레 등급(CC)에 속하는 이미지 수가 비 균열 이미지(NC) 수에 비해 작다(CC/NC=1/100, 1/10, 1/9, 1/8, 1/7, 1/6, 1/5, 1/4, 1/3, 1/2, 1/1).
- [0097] 데이터 비율이 1/1 및 1/2 인 경우 4개 모델의 AUC 값 간에 약간의 차이가 있다. 그러나 원래 SD 모델의 AUC 값은 불균형 데이터가 더 심각해지면 크게 감소하고 균형 계수가 1/100일때 0.67에 도달한다. 또한 결합 분류 모델(SD 모델)을 기반으로 한 세 가지 접근 방식은 심하게 불균형 데이터에서도 데이터 불균형 문제를 효과적으로 처리할 수 있음을 알 수 있다. 데이터 비율이 1/100일 때 XGB_SD 모델은 가장 높은 AUC값 0.94, LGB_SD는 약간 낮은 AUC값 0.92, CS_SD는 최저 AUC 값 0.82를 얻는다. 전반적으로 LGB_SD 및 XGB_SD는 CS_SD 모델 및 원래 SD 모델과 비교하여 다양한 데이터 비율 설정에서 AUC 값 측면에서 더 강력한 성능을 보여준다. 또한 불균형 비율이 높아질 경우 대부분 LGB_SD 모델의 AUC 값이 XGB_SD 모델 보다 좋은 성능을 갖는다.
- [0098] 도 20은 자동 균열 분류 및 위치 인식 결과를 기존 보고서와 본 발명의 보고서 자료를 비교한 결과이다. 대부분의 결합과 일치하지만 하나만 잘못 분류되었다(측면 돌출은 파이프 손상으로 잘못 분류됨). 위치 형식은 텍스트 인식 모듈에서 인식하는 거리와 다르다. 처음 세 자리는 미터를 나타내며 마지막 두 자리는 센티미터 단위로 더 많은 추출 위치를 나타내기 때문이다.
- [0099] 도 21는 종래의 수동으로 생성된 보고서와 본 발명의 일 실시예에 따라 생성된 보고서의 분류 성능을 비교한 결과이다. 전체적으로 매뉴얼 보고서에서 감지된 83개 크랙 중 12개 동영상에서 85개 크랙이 자동으로 추출된 반면, 본 발명의 일 실시예에 따른 시스템은 81개 크랙을 정확하게 분류했다. 12개의 동영상에 기록된 전체 분류 정확도는 95.3% (81/85)이다.
- [0100] 다시, 도 1을 참조하여, 메모리(135)는 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 검사 방법을 수행하기 위해 필요한 다양한 명령어들을 저장한다.
- [0101] 프로세서(140)는 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 검사 장치(100)의 내부 구성 요소들(예를 들어, 결합 데이터셋 생성부(110), 학습부(115), 결합 분류부(120), 텍스트 인식부(125), 보고서 생성부(130), 메모리(135) 등)을 제어하기 위한 수단이다.
- [0103] 도 22는 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 검사 방법을 나타낸 순서도이고, 도 23은 본 발명의 일 실시예에 따른 딥러닝 기반 하수도 결합 감지를 위한 아키텍처를 예시한 도면이다.
- [0104] 단계 2210에서 딥러닝 기반 하수도 결합 검사 장치(100)는 트레이닝 데이터 세트를 이용하여 딥러닝 기반 결합 분류 모델을 학습한다. 이때, 딥러닝 기반 하수도 결합 검사 장치(100)는 상이한 앙상블 기반 학습 기법과 비용 민감 학습 기법을 적용하여 딥러닝 기반 결합 분류 모델을 학습할 수 있다.
- [0105] 딥러닝 기반 결합 분류 모델을 학습하는 방법에 대해서는 전술한 바와 동일하므로 상세한 설명은 생략하기로 한다.
- [0106] 단계 2215에서 딥러닝 기반 하수도 결합 검사 장치(100)는 하수도 동영상을 각 프레임 단위로 학습된 딥러닝 기반 결합 분류 모델에 적용하여 결합 영역이 존재하는 결합 프레임들을 분류한다.
- [0107] 단계 2220에서 딥러닝 기반 하수도 결합 검사 장치(100)는 하수도 동영상의 각 프레임에 포함된 자막 정보를 인식하여 결합 관련 컨텍스트 정보를 추출한다.
- [0108] 단계 2225에서 딥러닝 기반 하수도 결합 검사 장치(100)는 결합 프레임들과 결합 관련 컨텍스트 정보를 이용하

여 하수도 조사 보고서를 생성한다.

[0109] 단계 2210 내지 단계 2225의 각 단계에 대한 상세한 설명은 도 1 내지 도 21을 참조하여 설명한 바와 동일하므로 중복되는 설명은 생략하기로 한다.

[0111] 본 발명의 실시 예에 따른 장치 및 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 컴퓨터 판독 가능 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 분야 통상의 기술자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media) 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0112] 상술한 하드웨어 장치는 본 발명의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.


[0113] 이제까지 본 발명에 대하여 그 실시 예들을 중심으로 살펴보았다. 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 변형된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 그러므로 개시된 실시 예들은 한정적인 관점이 아니라 설명적인 관점에서 고려되어야 한다. 본 발명의 범위는 전술한 설명이 아니라 특허청구범위에 나타나 있으며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명에 포함된 것으로 해석되어야 할 것이다.

부호의 설명


- [0115] 100: 딥러닝 기반 하수도 결함 감지 장치
- 110: 결함 데이터셋 생성부
- 115: 학습부
- 120: 결함 분류부
- 125: 텍스트 인식부
- 130: 보고서 생성부
- 135: 메모리
- 140: 프로세서

도면

도면1




도면2




도면3

Class	No. images	After augmentation
Crack circumferential	2380	7142
Debris silty	4036	12,108
Joint faulty	5397	16,193
Joint open	3174	9524
Lateral protruding	3754	11,264
Surface damage	2542	7628
Pipe broken	3169	9507
Non-crack	13,934	41,804
Total	38,386	115,170


도면4




도면5




도면6




도면7




도면8




도면9



도면10



도면11



도면12


Algorithm 1. Defects detection

```


1: For frame  $x$  in extracted frames X do
2:   current_distance = recognize_distance( $x$ )
3:   time = get_time( $x$ )
4:   If current_distance is NULL then
5:     start_time = time
6:     end_time = start_time
7:     add current_distance, start_time, stop_time to the temp_array
8:   Else
9:     stop_time = time
10:    update stop_time in the temp_array
11:  End If
12:  If (current_distance is different than (select current_distance from
temp_array)) and ((stop_time - start_time) > 3000) then
13:    extract all the frames that have the current distance information
14:    current_distance = NULL, temp_array = NULL
15:  End If
16: End For

```


도면13



도면14



도면15



도면16

Class [↕]	CC [↕]	DS [↕]	JF [↕]	JO [↕]	LP [↕]	SD [↕]	PB [↕]	NON [↕]	ACC (%) [↕]
CC [↕]	666 [↕]	0 [↕]	0 [↕]	7 [↕]	0 [↕]	15 [↕]	6 [↕]	6 [↕]	95.1 [↕]
DS [↕]	0 [↕]	684 [↕]	3 [↕]	5 [↕]	2 [↕]	0 [↕]	1 [↕]	5 [↕]	97.7 [↕]
JF [↕]	11 [↕]	1 [↕]	658 [↕]	23 [↕]	0 [↕]	0 [↕]	5 [↕]	2 [↕]	94 [↕]
JO [↕]	5 [↕]	3 [↕]	8 [↕]	674 [↕]	0 [↕]	2 [↕]	0 [↕]	8 [↕]	96.2 [↕]
LP [↕]	0 [↕]	11 [↕]	8 [↕]	2 [↕]	673 [↕]	3 [↕]	2 [↕]	1 [↕]	96.1 [↕]
SD [↕]	17 [↕]	0 [↕]	25 [↕]	0 [↕]	1 [↕]	652 [↕]	0 [↕]	5 [↕]	93.1 [↕]
PB [↕]	4 [↕]	13 [↕]	0 [↕]	3 [↕]	0 [↕]	1 [↕]	677 [↕]	2 [↕]	96.7 [↕]
NON [↕]	5 [↕]	3 [↕]	6 [↕]	3 [↕]	0 [↕]	2 [↕]	1 [↕]	680 [↕]	97.1 [↕]


도면17

Model [↕]	Input size [↕]	Number of convolutional layers [↕]	Testing time/image [↕]	Accuracy (%) [↕]
SD [↕]	(224, 224, 3) [↕]	19 [↕]	0.15 [↕]	97.6 [↕]
Kumar et al. [25] [↕]	(256, 256, 3) [↕]	2 [↕]	0.057 [↕]	85.4 [↕]
Perez et al. [14] [↕]	(224, 224, 3) [↕]	13 [↕]	0.094 [↕]	95.2 [↕]

도면18

↕	Image ratio between crack circumferential and non-crack classes [↕]										
	1:1 [↕]	1:2 [↕]	1:3 [↕]	1:4 [↕]	1:5 [↕]	1:6 [↕]	1:7 [↕]	1:8 [↕]	1:9 [↕]	1:10 [↕]	1:100 [↕]
CC [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	1000 [↕]	130 [↕]
NC [↕]	1000 [↕]	2000 [↕]	3000 [↕]	4000 [↕]	5000 [↕]	6000 [↕]	7000 [↕]	8000 [↕]	9000 [↕]	10000 [↕]	13000 [↕]


도면19



도면20

#	Crack type		Location	
	Ground truth	Prediction	Ground truth	Prediction
1	Joint faulty	Joint faulty	2.47m	2m
2	Joint faulty	Joint faulty	10.51m	10m
3	Joint faulty	Joint faulty	14.44m	14m
4	Lateral protruding	Lateral protruding	15.63m	15m
5	Lateral protruding	Lateral protruding	24.02m	24m
6	Lateral protruding	Lateral protruding	26.78m	26m
7	Joint open	Joint open	30.38m	30m
8	Lateral protruding	Pipe broken	41.97m	41m
10	Joint faulty	Joint faulty	42.50m	42m
11	Surface damage	Surface damage	43.61m	43m

도면21



도면22

