(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0086306
(43) 공개일자 2025년06월13일

(51) 국제특허분류(Int. Cl.)
*G01N 21/88* (2006.01) *G01B 11/03* (2006.01)
*G01B 11/14* (2006.01) *G06N 3/08* (2023.01)
*G06T 7/00* (2017.01) *G06T 7/12* (2017.01)
(52) CPC특허분류
*G01N 21/8851* (2013.01)
*G01B 11/03* (2013.01)
(21) 출원번호 10-2023-0175833
(22) 출원일자 2023년12월06일
심사청구일자 2023년12월06일

(71) 출원인
**인하대학교 산학협력단**
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
**김종현**
인천광역시 미추홀구 인하로 100, 인하대학교 1호관 512C(용현동)
(74) 대리인
**양성보**

전체 청구항 수 : 총 8 항

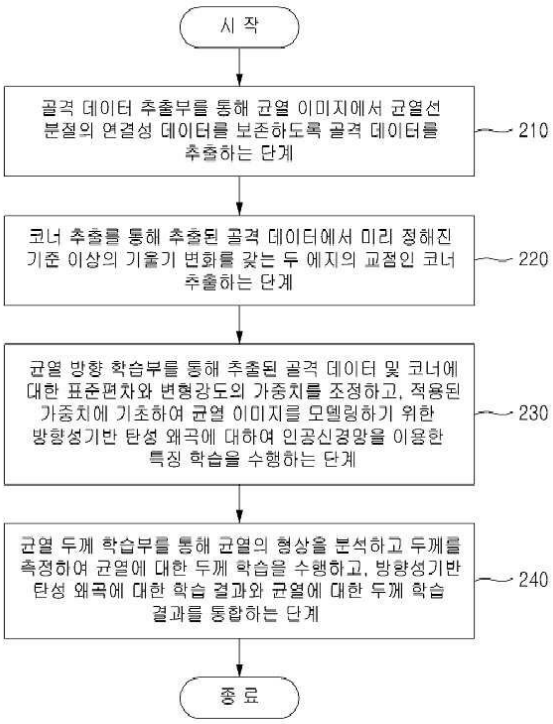
(54) 발명의 명칭 **공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법 및 시스템**

## (57) 요 약

공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법 및 시스템이 제시된다. 본 발명에서 제안하는 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법은 골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이

(뒷면에 계속)

*대 표 도* - 도2



터를 추출하는 단계, 코너 추출부를 통해 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계, 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계 및 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계를 포함한다.

(52) CPC특허분류
***G01B 11/14*** (2021.01)
***G06N 3/08*** (2023.01)
***G06T 7/001*** (2013.01)
***G06T 7/12*** (2017.01)
*G01N 2021/8883* (2013.01)
*G01N 2021/8887* (2013.01)
*G01N 2201/1296* (2013.01)

# 명 세 서

## 청구범위

### 청구항 1

골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 단계;

코너 추출부를 통해 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계;

균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계; 및

균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계

를 포함하는 콘크리트 균열 탐지를 위한 데이터 세트 수집 방법.

### 청구항 2

제1항에 있어서,

상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계는,

코너를 추출하기 위한 두 에지 간의 변화율을 계산하고, 양방향 기울기 변화가 미리 정해진 기준 이상인 위치를 코너로 추출하며,

임의의 픽셀(x, y)을 중심으로 이동시키고, 상기 이동시킨 픽셀(u, v)을 윈도우 내에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 상기 임의의 픽셀(x, y) 위치에서의 가중치를 이용하여 계산하며, 계산 결과가 미리 정해진 기준 이상일 경우 해당 두 에지의 교점을 코너로 결정하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 방법.

### 청구항 3

제1항에 있어서,

상기 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계는,

잔차 기반 CNN을 통해 방향성기반 학습 이미지 및 잔차 이미지를 입력으로 활용하여 업샘플링을 수행하고, 균열 이미지를 모델링하기 위해 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 이미지를 입력으로 사용하여 상기 잔차 기반 CNN을 이용한 특징 학습을 수행하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 방법.

### 청구항 4

제1항에 있어서,

상기 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계는,

상기 균열에 대한 두께 학습을 수행하기 위해 윤곽(contour) 근사를 사용하고, 상기 윤곽 근사는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 식별하여 상기 균열에 대한 두께 학습을 수행함으로써, 상

기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 방법.

**청구항 5**

균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 골격 데이터 추출부;

상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 코너 추출하는 코너 추출부;

상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 균열 방향 학습부; 및

균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 균열 두께 학습부

를 포함하는 콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템.

**청구항 6**

제5항에 있어서,

상기 코너 추출부는,

코너를 추출하기 위한 두 에지 간의 변화율을 계산하고, 양방향 기울기 변화가 미리 정해진 기준 이상인 위치를 코너로 추출하며,

임의의 픽셀(x, y)을 중심으로 이동시키고, 상기 이동시킨 픽셀(u, v)을 윈도우 내에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 상기 임의의 픽셀(x, y) 위치에서의 가중치를 이용하여 계산하며, 계산 결과가 미리 정해진 기준 이상일 경우 해당 두 에지의 교점을 코너로 결정하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템.

**청구항 7**

제5항에 있어서,

상기 균열 방향 학습부는,

잔차 기반 CNN을 통해 방향성기반 학습 이미지 및 잔차 이미지를 입력으로 활용하여 업샘플링을 수행하고, 균열 이미지를 모델링하기 위해 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 이미지를 입력으로 사용하여 상기 잔차 기반 CNN을 이용한 특징 학습을 수행하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템.

**청구항 8**

제5항에 있어서,

상기 균열 두께 학습부는,

상기 균열에 대한 두께 학습을 수행하기 위해 윤곽(contour) 근사를 사용하고, 상기 윤곽 근사는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 식별하여 상기 균열에 대한 두께 학습을 수행함으로써, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는

콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템.

## *발명의 설명*

### *기 술 분 야*

[0001] 본 발명은 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법 및 시

스템에 관한 것이다.

## 배 경 기 술

[0002] 빈번하게 발생하는 건물 붕괴사고를 예방하기 위하여 컴퓨터 과학적 관점에서 수단을 제공하기 위한 기술들이 제안되었다. 작업자가 현장에서 콘크리트 균열을 탐색할 때 위험 상황에 노출될 위험이 있고 시간과 비용이 많이 소요된다. 또한, 균열 발견의 정확도는 작업 중의 시선, 날씨 등의 조건에 의해 제한된다.

[0003] 건축물의 시공에 가장 널리 사용되는 재료인 콘크리트를 사용할 때 발생하는 가장 흔한 문제점 중 하나가 균열이다. 건축물의 노후화에 따라 균열의 수와 크기가 증가하고 이는 구조물의 안전성과 내구성에 악영향을 미치게 되므로, 콘크리트 구조물의 균열을 정기적으로 탐지하고 이에 따른 유지관리 대책을 강구하는 것이 중요하다. 일반적으로 구조물의 균열은 전문 장비를 갖춘 전문가가 현장을 직접 점검하는 방식으로 탐지되지만, 이러한 방식은 많은 노동력과 시간을 필요로 하며, 대규모 아파트가 있는 현장에서는 균열 탐지의 정확도가 떨어져 결국 사람들의 안전에 위협이 될 수 있다.

[0004] 균열을 효율적이고 신뢰성 있게 탐지하고 수동 탐지의 단점을 극복하기 위해 많은 연구들이 이미지 처리 기술을 활용하고 있다. 컴퓨터 비전 분야에서 이미지의 균열 자동 탐지를 위해 이미지 임계, 에지 탐지, wavelet 변환 및 머신 러닝 등 다양한 연구들이 진행되어 오고 있다. 이미지 임계화 방법은 다양한 픽셀 값을 기반으로 픽셀 레벨에서 균열을 분류하여 이미지의 단순화 및 후처리를 용이하게 한다. 에지 탐지 방법은 이미지에 차동 연산자를 적용하여 이미지의 균열을 효율적으로 탐지한다. wavelet 변환의 기본 개념은 이미지 신호와 같은 함수이고, 이 신호를 기반으로 wavelet 함수 또는 기저 함수 집합을 사용하여 균열을 탐지한다. 머신 러닝은 학습 데이터로부터 균열의 특징 벡터를 추출하고 학습을 통해 결과를 추론한다. 비록 이러한 방법들이 있지만 효율적으로 균열을 탐지할 수 있도록 균열의 불균일성, 표면 질감의 다양성, 배경의 복잡성 등을 개선하기 위한 연구가 활발히 진행되고 있다.

[0005] 딥러닝 기법은 심층 비선형 네트워크 구조를 학습하고 추상적 표현을 모델링할 수 있다. 종래기술에서는 CNN을 도로 균열 탐지에 적용한 초기 연구 중 하나인 딥러닝 기반 균열 탐지 기법을 제안하였다. 또한 SVM(Support Vector Machine) 및 부스트 방법과 같은 기존의 머신 러닝 분류기와 비교하여 딥러닝 기법의 효과를 입증하였다. 또 다른 종래기술에서는 포장 균열 탐지 기법의 정확도에 대한 CNN의 깊이와 훈련 및 테스트 데이터 간의 위치 변화의 영향을 연구하였다. 네트워크의 깊이를 증가시키면 정확도가 향상되는 반면, 이미지의 위치를 변경하면 탐지 정확도가 크게 감소하는 것으로 나타났다. 또 다른 종래기술에서는 대규모 도로 손상 데이터셋을 생성하고 각 이미지에서 도로 손상의 위치와 유형을 표시하였다. 이후 딥러닝 기반의 종단 간 객체 탐지 방법을 사용하여 손상 탐지 모델을 훈련하였다. 이러한 방법을 모바일 앱에 적용하여 전문가와 노동력이 부족한 지역에서도 도로 손상을 쉽게 탐지할 수 있도록 하였다.

[0006] 또 다른 종래기술에서는 종단간 탐지 모델을 구축하여 교량의 균열을 자동으로 탐지하였다. 깊이별 분리 가능한 컨볼루션을 사용하면 파라미터의 수를 효과적으로 줄일 수 있음을 입증하였다. 또 다른 종래기술에서는 탐지 정확도를 훼손하지 않고 속도를 향상시키기 위해 YOLOv3-Lite 방법을 제안하였다. 또 다른 종래기술에서는 CNN을 이용하여 표면 투과 이미지를 자동으로 탐지하고 측정하여 숨겨진 균열을 3D로 재구성함으로써 저비용으로 손상을 효율적으로 탐지할 수 있는 방법을 제안하였다. 또 다른 종래기술에서는 픽셀 레벨에서 균열을 탐지하기 위해 FCN(Fully Convolutional Network)을 기반으로 하는 기술을 제안하였다. FCN은 다양한 스케일의 물체를 탐지할 수 있는 업샘플링 및 다운샘플링 계층으로 구성되어 있으며, 균열 탐지의 정확도는 97.96%로 측정되었다. 또 다른 종래기술에서는 전이 학습을 이용하여 VGG16을 개선하고 콘크리트 교량의 표면 결함에 대한 정확한 분류를 모델링하였다. 또 다른 종래기술에서는 균열 탐지의 정확도를 향상시키기 위해 Faster R-CNN, R-FCN 및 FPN 기반 Faster RCNN에 영역 기반 변형 모듈을 추가하였다. 앞서 언급한 바와 같이 대부분의 연구에서는 균열 탐지의 정확도를 향상시키기 위해 다양한 전이 학습 기법을 사용하여 콘크리트의 표면 균열 탐지를 모델링하였다. 전이 학습을 사용하면 모델 훈련이 더 쉽고 빨라지지만 이것이 네트워크 아키텍처의 특징이다. 균열 데이터에 대한 전처리나 데이터 증강 방법에는 이점이 없다.

## 선행기술문헌

### 비특허문헌

[0007] (비특허문헌 0001) [1] Kenney, Charles S and Zuliani, Marco and Manjunath, BS, "An axiomatic approach to corner detection," IEEE Computer Society Conference on Computer Vision and Pattern Recognition

(CVPR'05), vol. 1, pp. 191- 197, 2005.

## 발명의 내용

### 해결하려는 과제

[0008] 본 발명이 이루고자 하는 기술적 과제는 균열 탐지의 정확도 향상을 목표로 신경망을 이용하여 방향과 두께를 기준으로 콘크리트 균열 데이터를 효율적으로 증강하기 위해 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법 및 시스템을 제공하는데 있다. 본 발명에서는 전이 학습을 사용하는 한계를 고려하여 균열 데이터 증강을 위한 새로운 네트워크 훈련 모델을 제안한다.

### 과제의 해결 수단

[0009] 일 측면에 있어서, 본 발명에서 제안하는 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 방법은 골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 단계, 코너 추출부를 통해 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계, 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계 및 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계를 포함한다.

[0010] 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계는 코너를 추출하기 위한 두 에지 간의 변화율을 계산하고, 양방향 기울기 변화가 미리 정해진 기준 이상인 위치를 코너로 추출하며, 임의의 픽셀(x, y)을 중심으로 이동시키고, 상기 이동시킨 픽셀(u, v)을 윈도우 내에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 상기 임의의 픽셀(x, y) 위치에서의 가중치를 이용하여 계산하며, 계산 결과가 미리 정해진 기준 이상일 경우 해당 두 에지의 교점을 코너로 결정한다.

[0011] 상기 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계는 잔차 기반 CNN을 통해 방향성기반 학습 이미지 및 잔차 이미지를 입력으로 활용하여 업샘플링을 수행하고, 균열 이미지를 모델링하기 위해 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 이미지를 입력으로 사용하여 상기 잔차 기반 CNN을 이용한 특징 학습을 수행한다.

[0012] 상기 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계는 상기 균열에 대한 두께 학습을 수행하기 위해 윤곽(contour) 근사를 사용하고, 상기 윤곽 근사는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 식별하여 상기 균열에 대한 두께 학습을 수행함으로써, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합한다.

[0013] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 시스템은 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 골격 데이터 추출부, 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 코너 추출하는 코너 추출부, 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 균열 방향 학습부 및 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 균열 두께 학습부를 포함한다.

### 발명의 효과

[0014] 본 발명의 실시예들에 따르면 균열의 방향과 두께를 학습하는 것을 기반으로 하는 데이터 증강 기법을 사용함으로써 데이터셋 수집의 어려움을 효율적으로 해결하며, 이는 비용 효율적이고 시간 효율적이다. 또한 균열의 존재를 기반으로 쿼드트리를 구축하여 균열 데이터를 적응적으로 처리하는 방법을 제안함으로써 효율성을 향상시

킬 수 있다. 정확도의 향상 정도를 확인하기 위해 다양한 장면(scenes)에 균열 탐지 알고리즘을 적용한 실험을 수행하였으며, IoU(Intersection over union) 정확도로 측정하였을 때 모든 장면에서 정확도가 향상되었다.

## 도면의 간단한 설명

[0015] 도 1은 본 발명의 일 실시예에 따른 데이터 증강 후의 이미지를 나타내는 예시도이다.

도 2는 본 발명의 일 실시예에 따른 콘크리트 균열 탐지를 위한 데이터 세트 수집 방법을 설명하기 위한 예시도이다.

도 3은 본 발명의 일 실시예에 따른 콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템의 구성을 나타내는 도면이다.

도 4는 본 발명의 일 실시예에 따른 균열 이미지에서 추출된 골격을 나타내는 도면이다.

도 5는 본 발명의 일 실시예에 따른 골격과 코너 세트가 있는 균열 벡터를 나타내는 도면이다.

도 6은 본 발명의 일 실시예에 따른 균열 방향의 방향 기반 탄성 왜곡을 설명하기 위한 도면이다.

도 7은 본 발명의 일 실시예에 따른 균열 데이터 증강에 대해 설명하기 위한 도면이다.

도 8은 본 발명의 일 실시예에 따른 CNN을 통한 균열 생성 과정을 설명하기 위한 도면이다.

도 9는 본 발명의 일 실시예에 따른 잔차 기반 CNN의 아키텍처를 나타내는 도면이다.

도 10은 본 발명의 일 실시예에 따른 윤곽 근사를 설명하기 위한 도면이다.

도 11은 본 발명의 일 실시예에 따른 윤곽 정보를 기반으로 추출된 균열의 두께를 이용하는 CNN의 아키텍처를 나타내는 도면이다.

도 12는 본 발명의 일 실시예에 따른 쿼드트리 구축 과정을 설명하기 위한 도면이다.

도 13은 본 발명의 일 실시예에 따른 밀도의 유무에 따라 FD와 ED로 분류하는 과정을 설명하기 위한 도면이다.

도 14는 본 발명의 일 실시예에 따른 경로 상태 값을 포함하는 쿼드트리 생성 과정을 설명하기 위한 도면이다.

도 15는 본 발명의 일 실시예에 따른 균열 패치 수집을 위한 쿼드트리 노드의 예시를 나타내는 도면이다.

## 발명을 실시하기 위한 구체적인 내용

[0016] 본 발명에서는 콘크리트 균열이 포함된 이미지의 데이터 세트를 효율적으로 얻기 위해 컨볼루션 신경망(CNN 또는 ConvNet) 훈련을 기반으로 한 데이터 증강 기법을 제안한다. 콘크리트 균열은 보통 표준화된 형태가 없고 복잡한 패턴을 가지고 있어 이미지를 얻기 어려우며, 데이터 확보 시 위험한 상황에 노출될 위험이 있다. 따라서 본 발명에서는 균열의 방향과 두께를 학습하는 것을 기반으로 하는 데이터 증강 기법을 사용함으로써 데이터셋 수집의 어려움을 효율적으로 해결하며, 이는 비용 효율적이고 시간 효율적이다. 또한 효율성을 향상시키기 위해 균열의 존재를 기반으로 쿼드트리를 구축하여 균열 데이터를 적응적으로 처리하는 방법을 제안한다. 정확도의 향상 정도를 확인하기 위해 다양한 장면(scenes)에 균열 탐지 알고리즘을 적용한 실험을 수행하였으며, IoU(Intersection over union) 정확도로 측정하였을 때 모든 장면에서 정확도가 향상되었다. 균열 데이터를 증강하지 않고 알고리즘을 수행하였을 때 오탐지율은 약 25%로 나타났다. 반면에 제안하는 방법을 사용하여 데이터를 증강하였을 때 오탐지율은 3%로 크게 감소하였다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0018] 본 발명의 실시예에 따른 균열 탐지 네트워크에 있어서, 불균일한 조명, 얼룩진 영역, 흐림, 노이즈 등과 같은 문제를 처리하는 것은 이미지 기반 균열 탐지 연구에서 매우 중요하다. 균열을 탐지하는 한 가지 방법은 균열이 주변보다 일반적으로 어둡다고 가정하는 반복 클리핑 방법과 같이 노이즈와 균열을 명확하게 구분하는 특징을 정의하는 것이다. 종래기술에서는 균열 이미지를 분할하기 위해 NDHM(Neighboring Difference Histogram) 방법을 제안하였다. 그러나 이 방법은 시험 이미지에서 그림자와 같은 어두운 영역이 많을 때 오작동할 수 있다. 균열 탐지의 정확성과 완성도를 향상시키기 위해 균열 영역의 콘트라스트를 향상시키기 위해 wavelet 변환 기반 방법이 제안되었다. 그러나 wavelet의 이방성 특성 때문에 그것들은 종종 높은 곡률로 또는 낮은 연속성으로 균열을 처리하지 못한다. 보다 강력한 노이즈 감소 능력으로 NDH를 확장하기 위해 FoSA(F* seed-growing 접근법)

방법이 제안되었다. CrackTree 방법은 균열에 드리워진 그림자를 제거하기 위해 설계되었지만 계산하는 데 오랜 시간이 걸린다. 밝기와 연결성을 모두 고려하는 CTA(Conditional Texture Anisotropy) 및 FFA(Free-Form Anisotropy)과 같이 이미지의 이방성을 측정하는 접근법은 균열 탐지에서 좋은 결과를 보여주었다. 그러나 그것들은 종종 에지 영역에 민감하고 노이즈를 초래할 수 있다. saliency을 사용하여 이러한 문제를 해결하기 위한 방법이 제안되었다.

[0019] 또 다른 종래기술에서는 LBP(Local binary pattern) 방법을 사용하여 로컬 특징을 통해 양호한 균열 탐지 결과를 얻었으나 각 이미지에 대한 파라미터 조정이 필요하다. 또 다른 종래기술에서는 콘크리트 터널 표면의 균열을 탐지하기 위해 BTH(Black Top-Hat) 변환 및 임계값 분할 방법을 제안하였으나 조명이 고르지 않을 경우 이 방법은 잘 작동하지 않는다. 최근 균열의 공간 분포, 강도, 기하학적 특징 등 다중 데이터를 고려하기 위해 집합 영역(Region of Aggregation; ROA)을 모델링하고 균열 영역을 확장하기 위해 ROB(Region of Belief)를 모델링하였다. 이 방법은 얇은 형태의 균열에 대해 좋은 결과를 생성한다.

[0020] 일반적으로 데이터 증강은 학습 기반 연구에 사용되는 데이터의 양을 증가시키기 위해 원본 데이터에 다양한 변환을 적용하는 기법이다. 데이터 증강은 일반적으로 훈련 단계에서 사용되지만 테스트 단계에서 사용될 수도 있는데, 이를 TTA(Test-Time augmentation)라고 한다. 이 방법은 하나의 테스트 이미지를 여러 이미지로 증강하고 이에 대한 추론을 수행한다. 이 프로세스에서 생성된 출력은 이후 앙상블된다. 이 기술은 Kaggle과 같은 대회에서 일반적으로 사용된다.

[0021] 본 발명의 실시예에 따른 이미지 조작 기반 접근법에 있어서, 픽셀 레벨 변환 기법과 공간 레벨 변환 기법이 있는데, 픽셀 레벨 변환은 이미지에 블러, 지터, 노이즈 등을 적용하여 픽셀 레벨로 변환하는 기법으로, 픽셀 레벨 변환에는 가우시안 블러, 모션 블러, 밝기 지터, 콘트라스트 지터, 채도 지터, ISO 노이즈, JPEG 압축 등 다양한 기법이 사용되고 있으며, 공간 레벨 변환은 이미지 공간을 변환하는 기법이다. 공간적 차원의 변환은 이미지 공간을 변형시키는 기법으로, 대표적인 방법으로는 플립과 회전이 있으며, 이미지의 일부를 잘라내는 크로핑도 많이 사용되고 있다.

[0022] 종래기술에서는 중첩되지 않는 슬라이딩 윈도우 내에서 특징값을 랜덤하게 셔플링하는 기법을 제안하였다. 이 방법을 적용하면 성능이 향상되지만 윈도우의 크기에 따라 성능이 크게 영향을 받는다. 또 다른 종래기술에서는 훈련 집합에서 두 개의 이미지를 랜덤하게 선택하여 224×224 크기로 랜덤하게 잘라낸 후 랜덤 수평 플립을 적용하는 방법을 제안하였다. 얻어진 두 개의 패치를 평균화하여 혼합 패치를 생성한다. 두 개의 이미지는 혼합되지만 하나의 레이블만 사용되므로 정확도가 저하될 수 있다. 또 다른 종래기술에서는 단순 평균 혼합 접근 방식에서 벗어나 두 이미지를 혼합하는 개선된 방법을 제안하였다. 대신 프로세스를 향상시키기 위해 8개의 새로운 혼합 방법을 도입하였다. 또 다른 종래기술에서는 0에서 1 사이의 람다 값을 갖는 가중 선형 보간을 사용하여 두 이미지를 보간하는 기법을 제안하였다. 이 방법은 간단하지만 모델의 일반화 성능을 향상시키고 손상된 레이블의 기억을 방지하며 모델을 적대적인 예에 더 민감하게 만들 수 있다.

[0023] 또 다른 종래기술에서는 4개의 이미지에서 랜덤하게 잘라낸 패치를 결합하여 하나의 이미지를 생성하는 RICAP(Random image cropping patching) 기법을 제안하였다. 또한, Mixup 기법과 유사하게 패치의 면적 비율을 기반으로 4개의 이미지의 레이블을 혼합하여 훈련을 위한 소프트 레이블을 생성하였다. 그러나 크로핑 프로세스에서 이미지의 주요 영역이 아닌 배경을 잘라낸 경우 잘못된 레이블이 할당될 수 있다. 또 다른 종래기술에서는 입력 이미지 레이블 대신 숨겨진 표현 또는 특징 맵 레벨에서 Mixup을 처리하는 방법을 제안하였다. 이 방법을 사용하면 결정 경계를 매끄럽게 할 수 있을 뿐만 아니라 Mixup의 장점도 보존할 수 있다. 또 다른 종래기술에서는 이미지를 혼합하는 이전에 언급한 방법과 달리 이미지 영역을 지우는 것을 포함하는 접근법을 선택하였다. 이 방법은 입력 이미지에 랜덤 크기의 경계 상자를 만들고 이를 훈련에 사용하기 전에 랜덤 노이즈, ImageNet 평균값, 0, 255 또는 다른 값으로 채우는 것을 포함한다.

[0024] 또 다른 종래기술에서는 이미지를 그리드로 분할하고 훈련 중에 각 반복마다 패치를 무작위로 지우는 방법을 제안하였다. 이 접근법은 네트워크가 객체의 특정 부분에만 집중하는 것이 아니라 이미지의 다양한 부분을 고려할 수 있도록 하여 보다 포괄적인 예측을 가능하게 한다. 또 다른 종래기술에서는 Mixup과 Cutout 기술을 결합한 CutMix라고 불리는 방법을 제안하였다. 이 기법은 이미지에서 상자 영역을 선택하여 지운 다음 다른 이미지에서 추출된 패치로 빈 영역을 채우는 것을 포함한다. 레이블은 패치의 면적에 비례하여 혼합된다. 또 다른 종래기술에서는 Augmix라고 불리는 방법을 제안했는데, 이 방법은 다중 증강 기술을 이미지에 직렬 또는 병렬로 적용한 다음 원래 이미지와 혼합한다. 이 방법은 주로 일반적인 테스트 정확도를 향상시키는 것이 아니라 견고성을 측정하도록 설계된 ImageNet-C 및 ImageNet-P와 같은 데이터셋에서 성능을 향상시키기 위해 제안되었다. CutMix의

패치를 자르고 붙이는 과정에서 발생하는 강한 에지 문제를 완화하기 위해 종래기술에서는 경계 영역을 매끄럽게 하여 보다 점진적인 전환을 만드는 SmoothMix라고 하는 방법을 제안하였다. 또 다른 종래기술에서는 이미지의 saliency를 유지하면서 이미지를 블렌딩하는 PuzzzleMix라고 하는 방법을 제안하였다. 이 접근법은 원본 이미지의 현저한 영역을 유지하는 동시에 혼합 출력을 생성하는 것을 목표로 한다. 이는 각 이미지에서 로컬 통계의 보존을 가능하게 하며 기존 혼합 기술에 비해 더 나은 일반화 성능을 보여준다. 또한 적대적 공격에 대한 견고성을 강화한다.

[0026] 도 1은 본 발명의 일 실시예에 따른 데이터 증강 후의 이미지를 나타내는 예시도이다.

[0027] 본 발명의 실시예에 따른 균열 탐지를 위한 데이터셋 및 데이터 증강에 있어서, 종래기술에 따라 수집된 데이터셋은 균열 탐지 연구에 널리 사용된다. 데이터셋은 중국 랴오닝성 다롄시에 있는 교량의 주탑과 앵커룸 표면에서 스마트폰을 사용하여 촬영된 이미지로 구성되어 있다. 원본 이미지의 해상도는 4160x3120이지만 256x256 해상도의 더 작은 이미지로 수동으로 분할하여 균열이 있는 이미지와 균열이 없는 이미지로 분류하였다. SDNET2018 데이터셋은 균열이 있는 이미지와 균열이 없는 이미지를 모두 포함한 콘크리트 교량의 이미지를 제공한다. 인공 신경망 모델의 성능은 훈련 데이터셋의 크기와 관련이 있다. 그러나 실제 균열 이미지의 크고 다양한 데이터셋을 얻는 것은 어려울 수 있다. 충분한 양의 실제 데이터를 수집하기 어려운 영역에서 실제 균열 이미지의 제한된 가용성을 보완하기 위해 종종 데이터 증강과 같은 기술을 사용한다. 데이터 증강 기술은 합성 생성된 데이터로 인위적으로 확장함으로써 과적합과 같은 작은 훈련 데이터셋의 한계를 효과적으로 해결할 수 있다.

[0028] 간단한 데이터 증강 기법 중 하나는 TensorFlow 2.0에서 제공하는 ImageDataGenerator 인터페이스를 사용하는 것으로, 이 인터페이스는 공간 수준의 변환을 기반으로 모델링된다. 이미지 플립, 회전, 시프트 및 기타 변환과 같은 작업을 적용함으로써 데이터 샘플 수를 효과적으로 늘릴 수 있다. 그러나 도 1에 도시된 바와 같이, 대부분이 단순 선형 변환이기 때문에 균열 패턴의 다양성을 나타내기에 충분하지 않을 수 있다. 도 1(a)는 원본 이미지, 도 1(b)는 수평 뒤집기, 도 1(c)는 회전, 도 1(d)는 수평 이동된 데이터 증강 후의 이미지를 각각 나타낸다.

[0029] 본 발명의 실시예에 따르면, 균열 패턴 추출을 위한 CNN과 균열의 형상 변형을 위한 탄성 왜곡을 활용한다. 균열은 표준화된 형상을 가지고 있지 않고 주변 환경에 따라 달라질 수 있기 때문에 실제 균열 데이터의 특성을 고려한 메타 데이터를 생성하기 위해서는 균열의 특성을 훈련하고 학습하는 것이 필요하다. 이하, 균열의 방향과 두께를 활용한 학습 기반의 데이터 증강 방법에 대하여 설명한다.

[0031] 도 2는 본 발명의 일 실시예에 따른 콘크리트 균열 탐지를 위한 데이터 세트 수집 방법을 설명하기 위한 예시도이다.

[0032] 본 발명의 실시예에 따른 콘크리트 균열 탐지를 위한 데이터 세트 수집 방법은 골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 단계(210), 코너 추출부를 통해 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출하는 단계(220), 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계(230) 및 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합하는 단계(240)를 포함한다.

[0033] 단계(210)에서, 골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출한다.

[0034] 단계(220)에서, 코너 추출부를 통해 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출한다.

[0035] 본 발명의 실시예에 따르면, 코너를 추출하기 위한 두 에지 간의 변화율을 계산하고, 양방향 기울기 변화가 미리 정해진 기준 이상인 위치를 코너로 추출한다.

[0036] 본 발명의 실시예에 따르면, 임의의 픽셀(x, y)을 중심으로 이동시키고, 상기 이동시킨 픽셀(u, v)을 윈도우 내

에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 상기 임의의 픽셀(x, y) 위치에서의 가중치를 이용하여 계산하며, 계산 결과가 미리 정해진 기준 이상일 경우 해당 두 에지의 교점을 코너로 결정한다.

[0037] 단계(230)에서, 균열 방향 학습부를 통해 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행한다.

[0038] 본 발명의 실시예에 따르면, 잔차 기반 CNN을 통해 방향성기반 학습 이미지 및 잔차 이미지를 입력으로 활용하여 업샘플링을 수행하고, 균열 이미지를 모델링하기 위해 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 이미지를 입력으로 사용하여 상기 잔차 기반 CNN을 이용한 특징 학습을 수행한다.

[0039] 단계(240)에서, 균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합한다.

[0040] 본 발명의 실시예에 따르면, 상기 균열에 대한 두께 학습을 수행하기 위해 윤곽(contour) 근사를 사용하고, 상기 윤곽 근사는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 식별하여 상기 균열에 대한 두께 학습을 수행함으로써, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합한다.

[0042] 도 3은 본 발명의 일 실시예에 따른 콘크리트 균열 탐지를 위한 데이터 세트 수집 시스템의 구성을 나타내는 도면이다.

[0043] 본 실시예에 따른 데이터 세트 수집 시스템(300)은 프로세서(310), 버스(320), 네트워크 인터페이스(330), 메모리(340) 및 데이터베이스(350)를 포함할 수 있다. 메모리(340)는 운영체제(341) 및 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 루틴(342)을 포함할 수 있다. 프로세서(310)는 골격 데이터 추출부(311), 코너 추출부(312), 균열 방향 학습부(313) 및 균열 두께 학습부(314)를 포함할 수 있다. 다른 실시예들에서 데이터 세트 수집 시스템(300)은 도 3의 구성요소들보다 더 많은 구성요소들을 포함할 수도 있다. 그러나, 대부분의 종래기술적 구성요소들을 명확하게 도시할 필요성은 없다. 예를 들어, 데이터 세트 수집 시스템(300)은 디스플레이나 트랜시버(transceiver)와 같은 다른 구성요소들을 포함할 수도 있다.

[0044] 메모리(340)는 컴퓨터에서 판독 가능한 기록 매체로서, RAM(random access memory), ROM(read only memory) 및 디스크 드라이브와 같은 비소멸성 대용량 기록장치(permanent mass storage device)를 포함할 수 있다. 또한, 메모리(340)에는 운영체제(341)와 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집 루틴(342)을 위한 프로그램 코드가 저장될 수 있다. 이러한 소프트웨어 구성요소들은 드라이브 메커니즘(drive mechanism, 미도시)을 이용하여 메모리(340)와는 별도의 컴퓨터에서 판독 가능한 기록 매체로부터 로딩될 수 있다. 이러한 별도의 컴퓨터에서 판독 가능한 기록 매체는 플로피 드라이브, 디스크, 테이프, DVD/CD-ROM 드라이브, 메모리 카드 등의 컴퓨터에서 판독 가능한 기록 매체(미도시)를 포함할 수 있다. 다른 실시예에서 소프트웨어 구성요소들은 컴퓨터에서 판독 가능한 기록 매체가 아닌 네트워크 인터페이스(330)를 통해 메모리(340)에 로딩될 수도 있다.

[0045] 버스(320)는 데이터 세트 수집 시스템(300)의 구성요소들간의 통신 및 데이터 전송을 가능하게 할 수 있다. 버스(320)는 고속 시리얼 버스(high-speed serial bus), 병렬 버스(parallel bus), SAN(Storage Area Network) 및/또는 다른 적절한 통신 기술을 이용하여 구성될 수 있다.

[0046] 네트워크 인터페이스(330)는 데이터 세트 수집 시스템(300)을 컴퓨터 네트워크에 연결하기 위한 컴퓨터 하드웨어 구성요소일 수 있다. 네트워크 인터페이스(330)는 데이터 세트 수집 시스템(300)을 무선 또는 유선 커넥션을 통해 컴퓨터 네트워크에 연결시킬 수 있다.

[0047] 데이터베이스(350)는 공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 효율적인 데이터 세트 수집을 위해 필요한 모든 정보를 저장 및 유지하는 역할을 할 수 있다. 도 3에서는 데이터 세트 수집 시스템(300)의 내부에 데이터베이스(350)를 구축하여 포함하는 것으로 도시하고 있으나, 이에 한정되는 것은 아니며 시스템 구현 방식이나 환경 등에 따라 생략될 수 있고 혹은 전체 또는 일부의 데이터베이스가 별개의 다른 시스템 상에 구축된 외부 데이터베이스로서 존재하는 것 또한 가능하다.

[0048] 프로세서(310)는 기본적인 산술, 로직 및 데이터 세트 수집 시스템(300)의 입출력 연산을 수행함으로써, 컴퓨터 프로그램의 명령을 처리하도록 구성될 수 있다. 명령은 메모리(340) 또는 네트워크 인터페이스(330)에 의해,

그리고 버스(320)를 통해 프로세서(310)로 제공될 수 있다. 프로세서(310)는 골격 데이터 추출부(311), 코너 추출부(312), 균열 방향 학습부(313) 및 균열 두께 학습부(314)를 위한 프로그램 코드를 실행하도록 구성될 수 있다. 이러한 프로그램 코드는 메모리(340)와 같은 기록 장치에 저장될 수 있다.

[0049] 골격 데이터 추출부(311), 코너 추출부(312), 균열 방향 학습부(313) 및 균열 두께 학습부(314)는 도 2의 단계들(210~240)을 수행하기 위해 구성될 수 있다.

[0050] 데이터 세트 수집 시스템(300)은 골격 데이터 추출부(311), 코너 추출부(312), 균열 방향 학습부(313) 및 균열 두께 학습부(314)를 포함할 수 있다.

[0051] 본 발명의 실시예에 따른 골격 데이터 추출부(311)는 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출한다.

[0052] 본 발명의 실시예에 따른 코너 추출부(312)는 상기 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너를 추출한다.

[0053] 본 발명의 실시예에 따른 코너 추출부(312)는 코너를 추출하기 위한 두 에지 간의 변화율을 계산하고, 양방향 기울기 변화가 미리 정해진 기준 이상인 위치를 코너로 추출한다.

[0054] 본 발명의 실시예에 따른 코너 추출부(312)는 임의의 픽셀(x, y)을 중심으로 이동시키고, 상기 이동시킨 픽셀(u, v)을 윈도우 내에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 상기 임의의 픽셀(x, y) 위치에서의 가중치를 이용하여 계산하며, 계산 결과가 미리 정해진 기준 이상일 경우 해당 두 에지의 교점을 코너로 결정한다.

[0055] 본 발명의 실시예에 따른 균열 방향 학습부(313)는 상기 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 상기 적용된 가중치에 기초하여 상기 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행한다.

[0056] 본 발명의 실시예에 따른 균열 방향 학습부(313)는 잔차 기반 CNN을 통해 방향성기반 학습 이미지 및 잔차 이미지를 입력으로 활용하여 업샘플링을 수행하고, 균열 이미지를 모델링하기 위해 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 이미지를 입력으로 사용하여 상기 잔차 기반 CNN을 이용한 특징 학습을 수행한다.

[0057] 본 발명의 실시예에 따른 균열 두께 학습부(314)는 균열의 형상을 분석하고 두께를 측정하여 상기 균열에 대한 두께 학습을 수행하고, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합한다.

[0058] 본 발명의 실시예에 따른 균열 두께 학습부(314)는 상기 균열에 대한 두께 학습을 수행하기 위해 윤곽(contour) 근사를 사용하고, 상기 윤곽 근사는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 식별하여 상기 균열에 대한 두께 학습을 수행함으로써, 상기 방향성기반 탄성 왜곡에 대한 학습 결과와 상기 균열에 대한 두께 학습 결과를 통합한다.

[0060] 도 4는 본 발명의 일 실시예에 따른 균열 이미지에서 추출된 골격을 나타내는 도면이다.

[0061] 본 발명의 실시예에 따른 균열 이미지, 다시 말해 균열 데이터에서 골격을 추출하는 방법에 대하여 설명한다. 도 4(a)는 입력되는 균열 이미지를 나타내고, 도 4(b)는 추출된 골격을 나타내는 도면이다.

[0062] 실제 균열 데이터를 조사한 결과 균열이 존재하는 영역은 크기가 매우 작음을 알 수 있었다. 따라서, 도 4(b)와 같이 균열선 분절에 데이터 변환을 적용할 때 균열이 불규칙적으로 조각나는 경향이 있다. 균열선 분절의 연결성 정보를 보존하기 위해 본 발명에서는 먼저 균열 이미지에서 골격을 추출한다. 이를 위해 본 발명에서는 균열선 분절을 픽셀 기반 표현에서 얇은 벡터 기반 표현으로 변환하기 위해 골격화 프로세스를 적용한다.

[0064] 도 5는 본 발명의 일 실시예에 따른 골격과 코너 세트가 있는 균열 벡터를 나타내는 도면이다.

[0065] 본 발명의 실시예에 따른 균열 데이터에서 기울기 변화가 큰 두 에지의 교점인 코너를 탐지하는 방법을 설명한다. 본 발명에서는 Harris 코너 탐지 방법을 개선한 Shi-Tomasi 코너 탐지 기법을 활용한다. 이 기법은 에지 간의 변화율을 계산하고 양방향 기울기 변화가 큰 위치를 코너로 간주한다. 한 개의 픽셀을 중심으로 이동시키고 x축의 u 픽셀과 y축의 v 픽셀을 윈도우 내에서 이동시켜 마스크 윈도우 내 픽셀값 차이의 제곱합을 계산한다.

식(1)에서 W(x, y)는 위치(x, y)에서의 가중치를 나타내고 I(x, y)는 원래 위치의 픽셀값을 나타내고 I(x + u, y + v)는 이동된 위치의 픽셀값을 나타낸다.

[0066] $$E(u,v) = \sum_{x,y} W(x,y)\,[I(x+u, y+v) - I(x,y)]^2 \quad (1)$$

[0067] 위의 식에 테일러 확장을 적용하면 식(2)가 산출된다.

[0068] $$E(u,v) \cong \sum_{x,y} [I(x,y) + uI_x + vI_y - I(x,y)]^2 \quad (2)$$

[0069] 식(3)은 식(2)를 행렬 형태로 재배열한 최종식으로, 행렬의 고유값이 일정 임계값 이상이면 이를 코너로 간주한다. 이 과정은 SVD(Singular Value Decomposition) 기법을 이용하여 계산된다.

[0070] $$E(u,v) \cong [u,v] \left( \sum_{x,y} W(x,y) \begin{bmatrix} I^2x & I_xI_y \\ I_xI_y & I^2y \end{bmatrix} \right) \begin{bmatrix} u \\ v \end{bmatrix} \quad (3)$$

[0071] 사용자가 최대 코너 개수, 기울기 변화 임계값, 코너 간 최소 거리를 지정하면 N개의 코너가 추출된다.

[0072] 도 5(a)는 골격과 코너 세트가 있는 균열 벡터를 나타내며, 도 5(a)는 입력 데이터, 도 5(b)는 골격 추출, 도 5(c)는 코너 추출, 도 5(d)는 코너를 연결하여 생성된 코너 방향을 각각 나타낸다.

[0073] 도 5(d)는 탐지된 코너를 선분으로 연결한 결과이다. 이 데이터는 방향 기반의 증강 기법에 활용될 것이다. 도 4는 단절된 세그먼트 없이 균열 골격의 안정적인 추출을 보여주며, 도 4와 비교했을 때 명확하다.

[0075] 도 6은 본 발명의 일 실시예에 따른 균열 방향의 방향 기반 탄성 왜곡을 설명하기 위한 도면이다.

[0076] 본 발명의 실시예에 따른 미시적 관점과 거시적 관점 모두에서 모델링한 방향기반 탄성왜곡 기법에 대해 설명한다. 미시적 수준에서는 표준편차 σ과 변형강도 α의 가중치를 조정하여 균열에 대한 변형을 계산한다.

[0077] 도 4(a)는 입력 데이터를 나타내고, 도 4(b)는 앞서 언급한 것처럼 추출된 코너를 연결하여 형성한 선분 중 하나를 확대한 것이다. 도 4(b)에서 볼 수 있듯이 이는 적용된 가중치를 바탕으로 변형 정도를 쉽게 관찰할 수 있게 해준다. 도 4(c)는 균열을 나타내는 선분에 방향 기반 탄성왜곡을 적용한 결과를 보여주고 있다. 거시적 관점에서 탄성 왜곡은 균열의 표면 형상을 변형시키기 위해 회전각과 affine 변환의 가중치를 조정하는 것을 포함한다.

[0079] 도 7은 본 발명의 일 실시예에 따른 균열 데이터 증강에 대해 설명하기 위한 도면이다.

[0080] 도 7은 방향성 기반 세그먼트를 이용하여 마이크로 매크로 탄성 왜곡을 적용한 결과를 나타낸 것이다. 이러한 방향성에 대한 제어가 어려웠던 기존의 픽셀 기반 데이터 증강 기법과 달리, 본 발명에서는 단순한 직선 균열이 아닌 보다 다양한 변화로 균열의 방향을 포착할 수 있다. 물론 무작위성을 도입하는 것이 이 문제를 일시적으로 완화시킬 수는 있지만, 무작위화에 기반한 변환은 원래의 균열 패턴 및 특성의 손실로 이어질 수 있다.

[0082] 도 8은 본 발명의 일 실시예에 따른 CNN을 통한 균열 생성 과정을 설명하기 위한 도면이다.

[0083] 본 발명의 실시예에 따른 방향 기반 데이터 증강 기법을 훈련하여 균열 데이터를 효과적으로 모델링할 수 있는 CNN 기반 네트워크를 제안한다. 훈련을 위해 본 발명의 실시예에서는 500개의 골격화 균열 이미지와 400개의 선분 이미지를 활용하였다. 또한 방향 기반 데이터 증강 기법을 이용하여 추가적인 훈련 데이터를 수집하였다. 본 발명의 실시예에서는 실제 균열과 유사한 패턴을 얻기 위해 획득한 균열 이미지를 기반으로 특징 학습 프로세스를 설명한다. 골격화 기법을 통해 획득한 균열 이미지를 이용하여 네트워크를 훈련할 때 특징이 복잡하여 학습 프로세스 중 수렴 문제가 발생하기도 하였다. 그러나 균열에서 코너를 추출하고 이를 선분과 연결하여 얻은 방향 데이터를 활용하여 이 문제를 해결하였다.

[0084] 도 8(a)는 균열 이미지에서 추출된 뼈대 데이터를 나타내고, 도 8(b)는 CNN 훈련을 통해 생성된 결과를 표시하여 실제 균열과 매우 유사한 패턴을 보여준다. 탄성 왜곡의 가중치가 큰 경우 원래 균열의 특성을 충분히 보존하지 못하는 노이즈를 발생시킬 수 있다. 그러나 본 발명의 실시예에 따른 방법은 이러한 문제를 완화시켰다.

[0086] 도 9는 본 발명의 일 실시예에 따른 잔차 기반 CNN의 아키텍처를 나타내는 도면이다.

[0087] 본 발명의 실시예에 따른 실험에 사용된 잔차 기반 CNN의 아키텍처는 방향 기반 학습 이미지, 26개의 계층으로 구성된 네트워크, 3개의 업샘플링 단계, 잔차 이미지를 입력으로 활용하여 네트워크 훈련 과정 중 최적의 결과를 얻을 수 있다. 업샘플링 단계의 수가 증가함에 따라 결과가 개선되었으며 잔차 이미지를 사용하여 3채널 훈련에서 색상과 관련된 문제를 해결하였다. 마지막으로 균열 패턴의 세부 사항을 고려한 결과를 얻기 위해 방향성기반 탄성 왜곡 데이터를 입력으로 사용하고 이 데이터를 사용하여 네트워크를 훈련하여 결과를 얻었다. 그러나 이 접근법은 균열의 방향만을 고려할 뿐 균열의 두께를 고려하지 않아 훈련 시 균열 두께의 변화를 충분히 포착하지 못할 수 있다. 따라서 본 발명의 실시예에서는 균열 두께 학습 방법을 통합하도록 프레임워크를 확장하였다.

[0089] 도 10은 본 발명의 일 실시예에 따른 윤곽 근사를 설명하기 위한 도면이다.

[0090] 본 발명의 실시예에서는 균열의 형상을 분석하고 두께를 측정하기 위해 윤곽(contour) 근사를 활용한다. contour는 동일한 색상 또는 픽셀 값을 가지는 영역에 의해 형성되는 경계를 말한다. 이는 물체의 윤곽선이나 형상을 식별하는 데 일반적으로 사용된다. 본 발명에서는 OpenCV 라이브러리에 내장되어 있는 Douglas-Peucker 알고리즘을 사용하였다. 도 10(a)는 입력 데이터, 도 10(b)는 윤곽$\varepsilon$ ≥0.005인 이미지, 도 10 (c)는 $\varepsilon$=0.005인 윤곽 이미지를 각각 나타낸다.

[0091] 도 10(b)의 결과를 얻기 위해, contour 근사에 대한 파라미터 $\varepsilon$를 0.005로 설정하였다. 이 값은 경험적으로 결정되며 타이트한 contour를 얻기 위해 일반적으로 사용된다. $\varepsilon$ 값이 작으면 원래의 contour와 매우 유사한 결과가 도출되지만, $\varepsilon$ 값이 크면 원래의 contour와 차이가 발생할 수 있다.

[0093] 도 11은 본 발명의 일 실시예에 따른 윤곽 정보를 기반으로 추출된 균열의 두께를 이용하는 CNN의 아키텍처를 나타내는 도면이다.

[0094] 본 발명에서 추출한 최종 데이터는 방향성만을 고려한 기존의 실험 결과와 비교하여 두께 측면에서 보다 상세한 특징을 포착하였다. 도 11은 윤곽 정보를 기반으로 추출된 균열의 두께를 이용하여 훈련한 인공 신경망을 나타낸 것이다. 네트워크 모델은 앞서 설명한 접근법을 따르며, 입력 데이터는 균열의 두께와 방향 정보로 구성되어 있다.

[0096] 도 12는 본 발명의 일 실시예에 따른 쿼드트리 구축 과정을 설명하기 위한 도면이다.

[0097] 본 발명의 실시예에 따른 쿼드트리는 각 내부 노드가 4개의 자식(children)을 가지는 트리 데이터 구조이며, 각 노드에 중요한 데이터가 존재하는 것을 기반으로 적응적으로 세분화된다. 용도에 따라 정보 측면에서 "관심 최소 단위"는 일반적으로 쿼드트리의 리프(leaf) 셀에 저장된다.

[0099] 도 13은 본 발명의 일 실시예에 따른 밀도의 유무에 따라 FD와 ED로 분류하는 과정을 설명하기 위한 도면이다.

[0100] 본 발명의 실시예에서는 전체 데이터 세트에 비해 균열이 전체 공간에서 차지하는 비중이 작기 때문에 데이터의 크기를 줄이기 위해 쿼드트리를 사용한다.

[0101] 도 13을 참조하면, 밀도 유무에 따른 FD(Full Density)와 ED(Empty Density)로 분류한다. 도 13(a)는 입력 데이터, 도 13(b)는 패치 분할, 도 13(c)는 FD(적색) 및 ED(기타)를 각각 나타낸다.

[0102] 본 발명의 실시예에서는 균열을 화이트 영역으로 나타내는 이진 데이터를 입력으로 사용한다(도 13(a) 참조).

도 13(b) 및 도 13(c)와 같이, 쿼드트리 세분화를 위한 기준으로 균열 영역을 기준으로 공간을 분할한다. 쿼드트리를 이용하여 균열 데이터를 분할하는 이유는 픽셀 정보를 얻기 위해서가 아니라 공간 도메인에서 의미 있는 정보를 추출하기 위해서이다. 네트워크 훈련은 쿼드트리의 리프(leaf) 노드로 표현되는 이미지 패치를 이용하여 수행하며, $C_p$로 표현된다. 쿼드트리를 구성하기 위해 사용되는 가장 낮은 레벨의 노드는 앞에서 설명한 방법을 사용하여 생성되며, 노드는 위쪽으로 병합되어 트리 구조를 형성한다.

[0104] 도 14는 본 발명의 일 실시예에 따른 경로 상태 값을 포함하는 쿼드트리 생성 과정을 설명하기 위한 도면이다.

[0105] 본 발명의 실시예에 따라 생성된 노드를 쿼드트리에 결합하기 전에 각 노드의 밀도 값을 임계값과 비교하여 노드 내에 균열이 존재하는지 여부를 판단한다. 이 비교에 따라 노드는 FD 또는 ED 상태로 분류된다(도 14(a) 참조). 최하위 레벨의 노드는 자체적으로 분류된 상태 값을 가지며 상위 레벨의 노드의 상태 값은 하위 노드의 상태 값을 결합하여 결정된다(도 14(b) 참조). 트리의 각 노드는 상태 값, 밀도 데이터 및 이와 연관된 키 값을 가지고 있고 키는 노드의 위치 및 트리의 깊이를 나타내는 X 및 Y 좌표를 포함하고 있으며 네트워크 프로세스가 완료된 후 깊이 및 위치를 사용하여 결과를 결합한다. 상태는 FD, ED 또는 MIX로 표시되며 본 발명에서는 각 패치의 밀도를 최하위 레벨의 노드에 대한 데이터로 사용한다(도 14(a) 참조). 최하위 레벨의 노드의 깊이는 아래의 식(4)를 사용하여 계산된다.

[0106]
$$d = log_2\left(\frac{D_{width}}{N_{width}}\right) \quad (4)$$

[0107] 여기서 d는 현재 노드의 깊이를 나타내고, $D_{width}$와 $N_{width}$는 각각 전체 입력 데이터의 폭과 현재 노드의 폭을 나타낸다. 부모 노드는 4개의 자식 노드로부터 위쪽 방향으로 생성된다. 부모 노드의 데이터는 자식 노드들로부터의 데이터의 합이다. 1만큼 깊이가 감소하고, 자식 노드들을 병합할 때 위치가 결정된다. 마지막으로, 자식 노드들의 상태를 집계하여 부모 노드의 상태 값을 결정한다. 모든 자식 노드들이 동일한 상태 값을 가지면, 그 값은 부모 노드에 할당된다. 자식 노드들이 FD와 ED 상태를 모두 가지면, 부모 노드의 상태 값은 MIX로 할당된다.

[0109] 도 15는 본 발명의 일 실시예에 따른 균열 패치 수집을 위한 쿼드트리 노드의 예시를 나타내는 도면이다.

[0110] 본 발명의 실시예에 따르면, 모든 자식 노드가 동일한 상태 값을 가지는 경우 부모 노드는 해당 값을 저장하고 자식 노드는 제거된다. 상태가 ED인 노드는 균열이 없음을 나타내므로 네트워크 훈련이 필요하지 않다. FD의 경우 네트워크 훈련을 한꺼번에 적용하는 대신 본 발명의 실시예에서는 필요한 데이터가 포함된 자식 노드에 선택적으로 적용하여 보다 효율적인 접근법을 따른다. 이 프로세스를 루트(root) 노드에 도달할 때까지 반복하여 모든 노드에 대해 상태 값이 할당된 쿼드트리를 구성한다. 트리가 완료되면 FD 노드의 데이터와 키 값을 수집하고(도 15 참조), 이 데이터셋을 네트워크 훈련에 사용한다. 본 발명의 실시예에 따른 실험 결과는 전체적으로 약 37.5%의 데이터를 압축할 수 있어 메모리 효율성이 향상됨을 보여주었다.

[0112] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0113] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의

조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

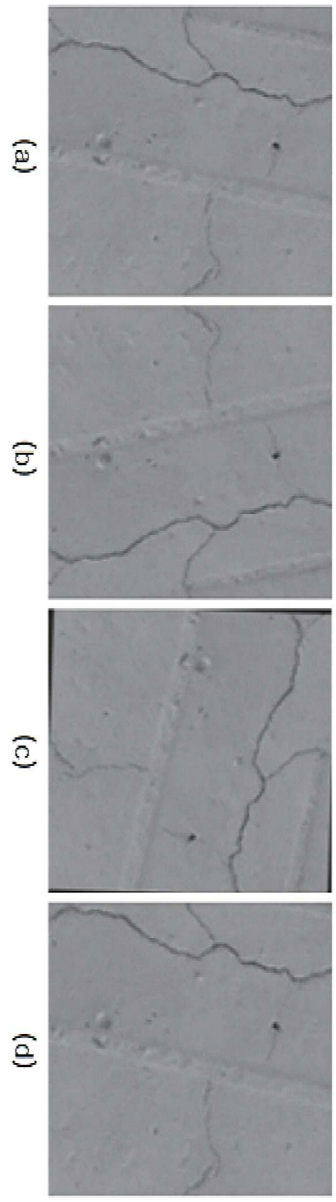
[0114] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic 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.

[0115] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

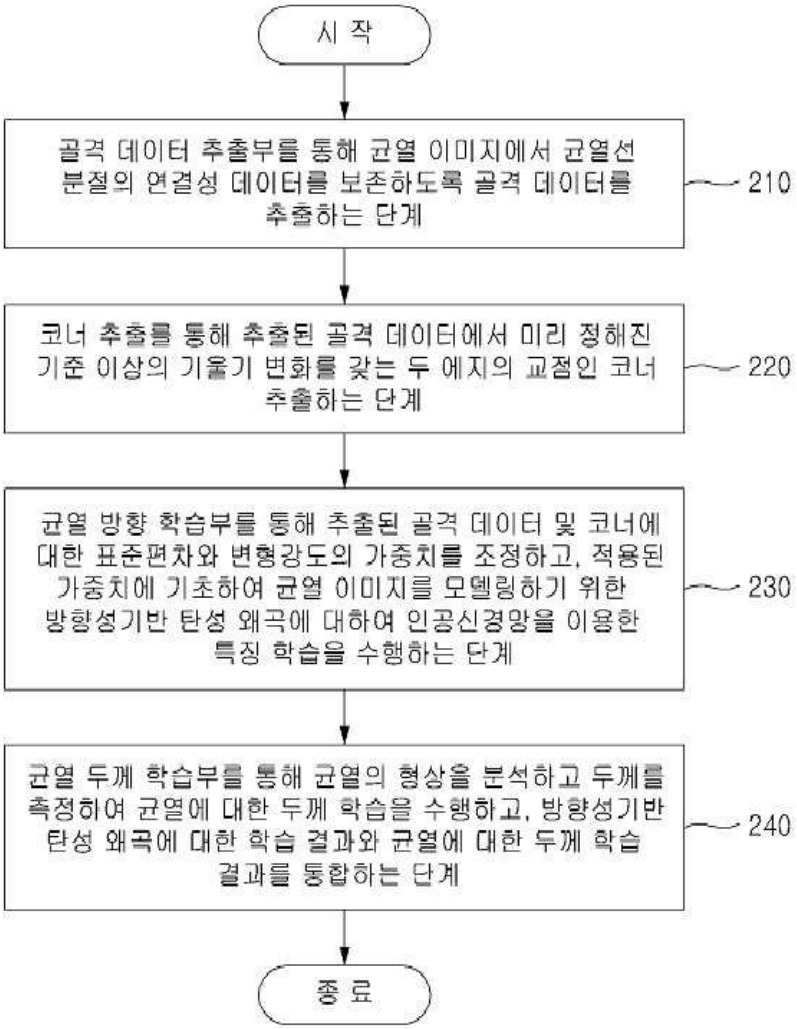
[0116] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

## 도면

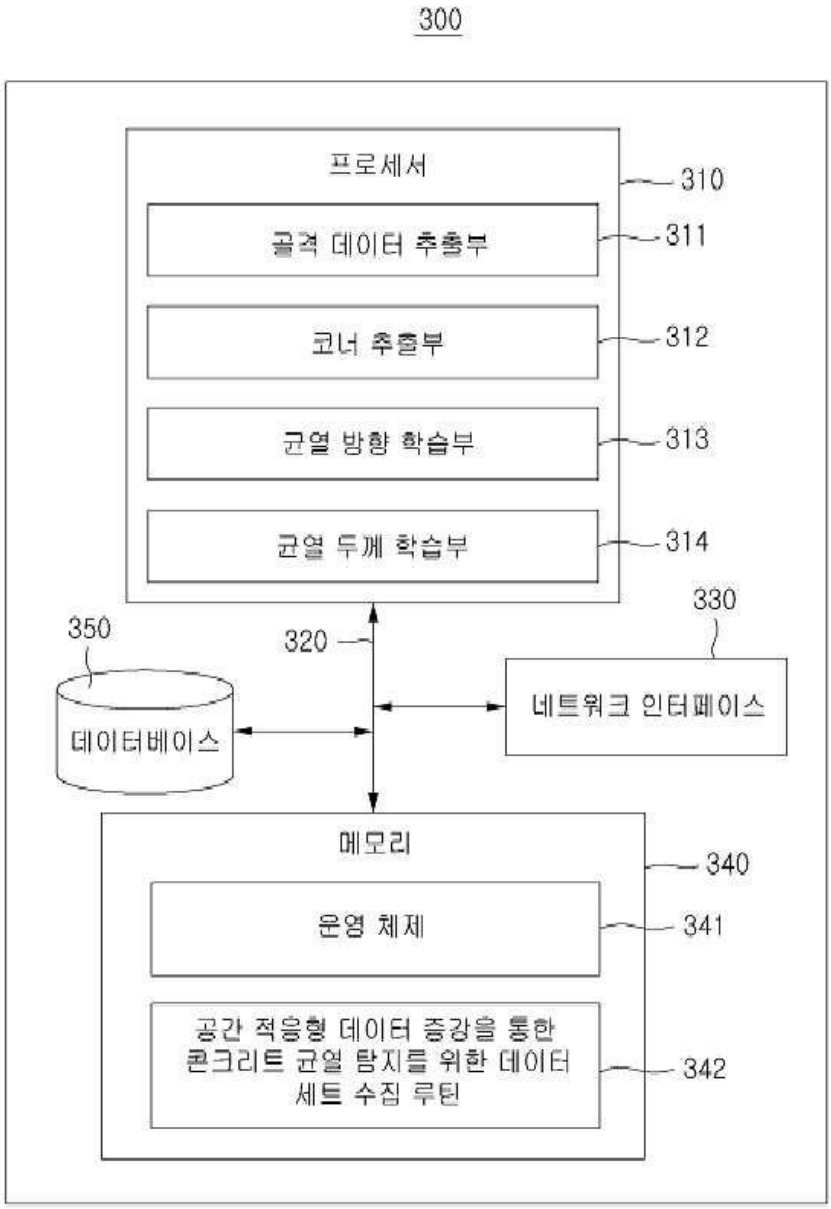
### 도면1



도면2


시 작
골격 데이터 추출부를 통해 균열 이미지에서 균열선 분절의 연결성 데이터를 보존하도록 골격 데이터를 추출하는 단계
210
코너 추출를 통해 추출된 골격 데이터에서 미리 정해진 기준 이상의 기울기 변화를 갖는 두 에지의 교점인 코너 추출하는 단계
220
균열 방향 학습부를 통해 추출된 골격 데이터 및 코너에 대한 표준편차와 변형강도의 가중치를 조정하고, 적용된 가중치에 기초하여 균열 이미지를 모델링하기 위한 방향성기반 탄성 왜곡에 대하여 인공신경망을 이용한 특징 학습을 수행하는 단계
230
균열 두께 학습부를 통해 균열의 형상을 분석하고 두께를 측정하여 균열에 대한 두께 학습을 수행하고, 방향성기반 탄성 왜곡에 대한 학습 결과와 균열에 대한 두께 학습 결과를 통합하는 단계
240
종 료

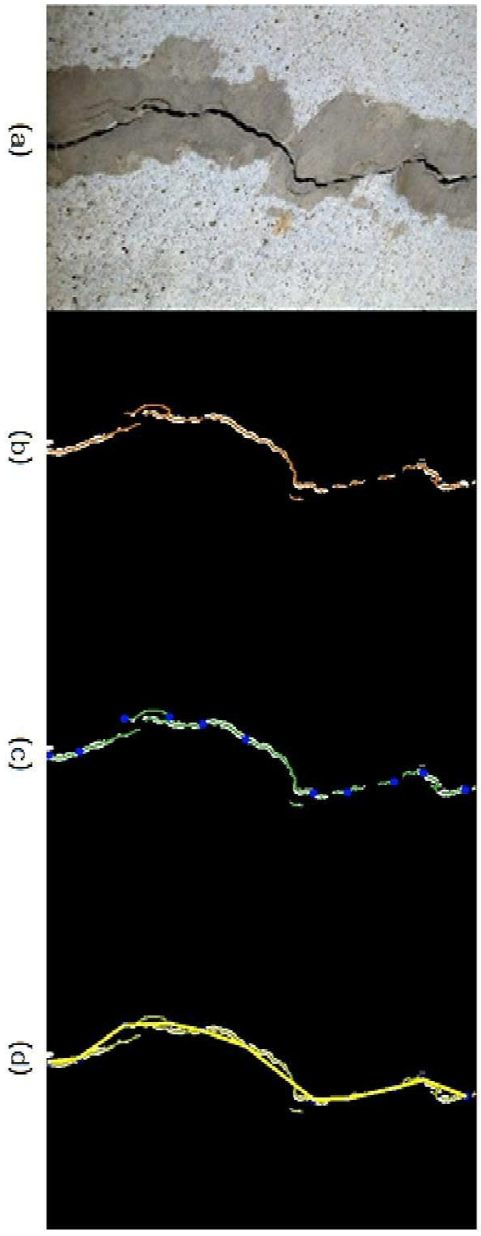
도면3


300
프로세서
310
골격 데이터 추출부
311
코너 추출부
312
균열 방향 학습부
313
균열 두께 학습부
314
320
330
350
데이터베이스
네트워크 인터페이스
메모리
340
운영 체제
341
공간 적응형 데이터 증강을 통한 콘크리트 균열 탐지를 위한 데이터 세트 수집 루틴
342

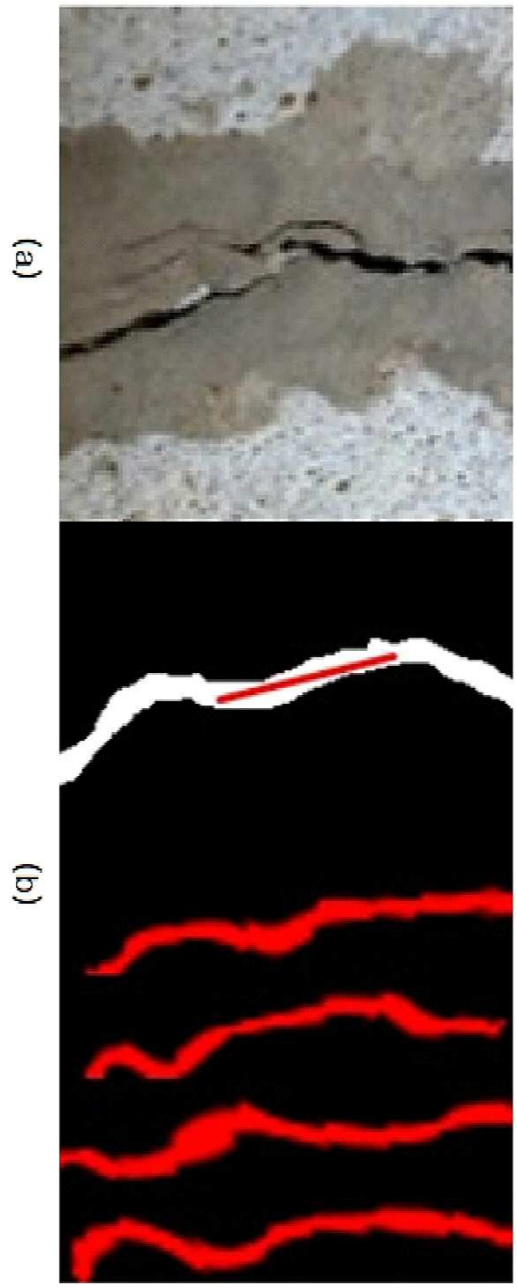
도면4



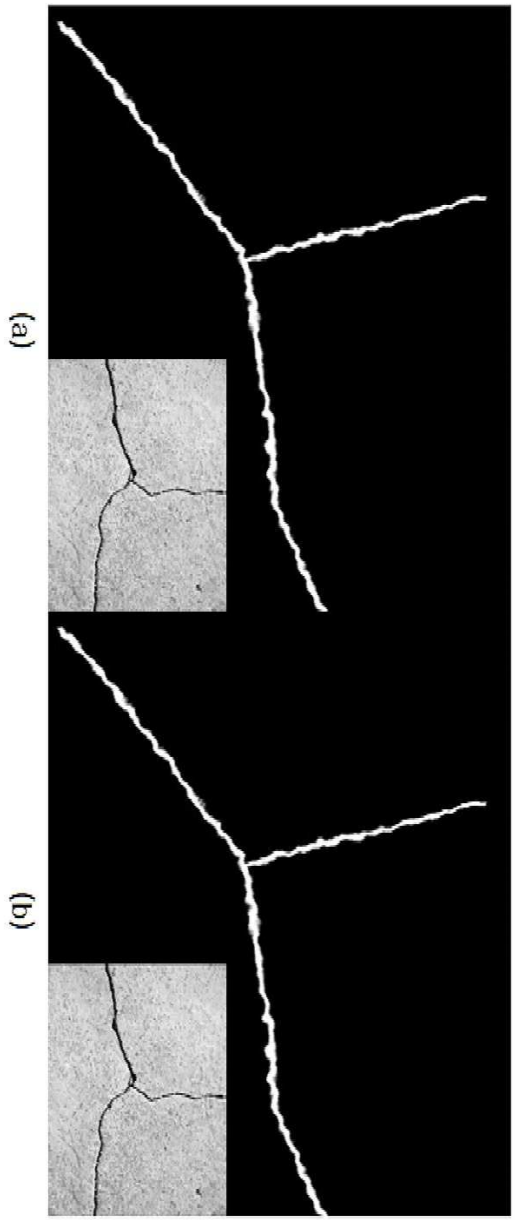
도면5



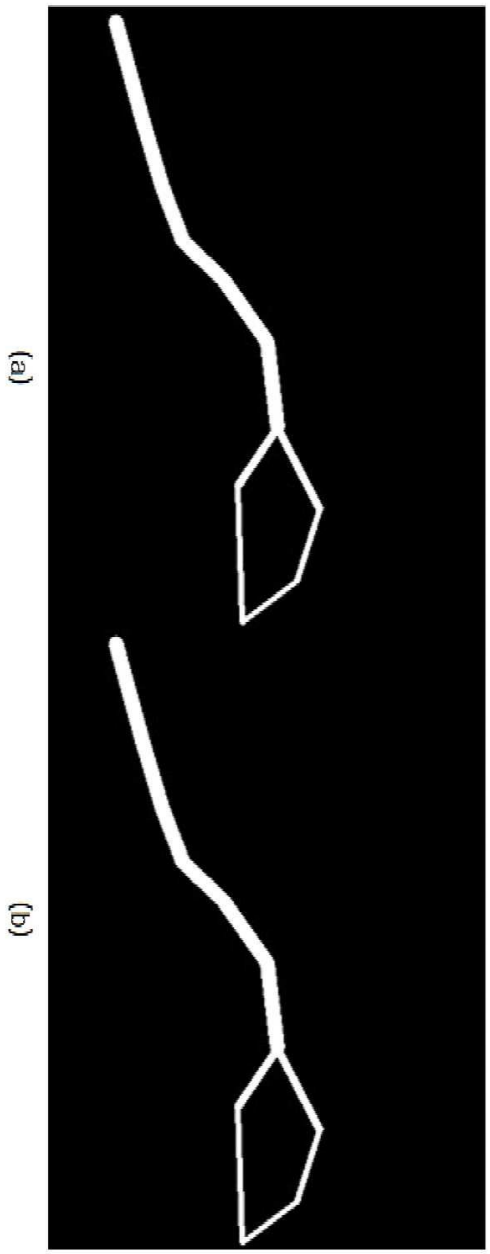
도면6



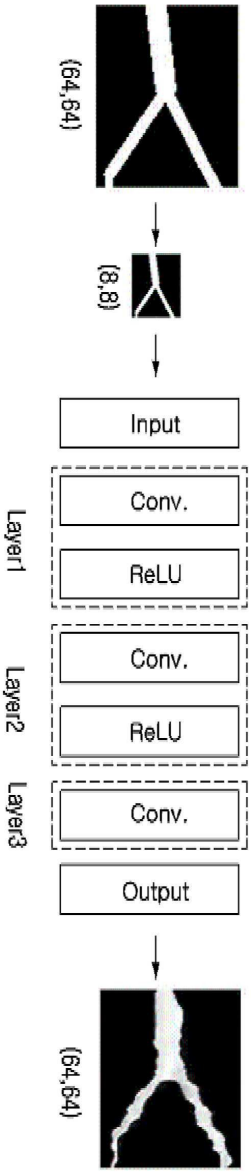
도면7



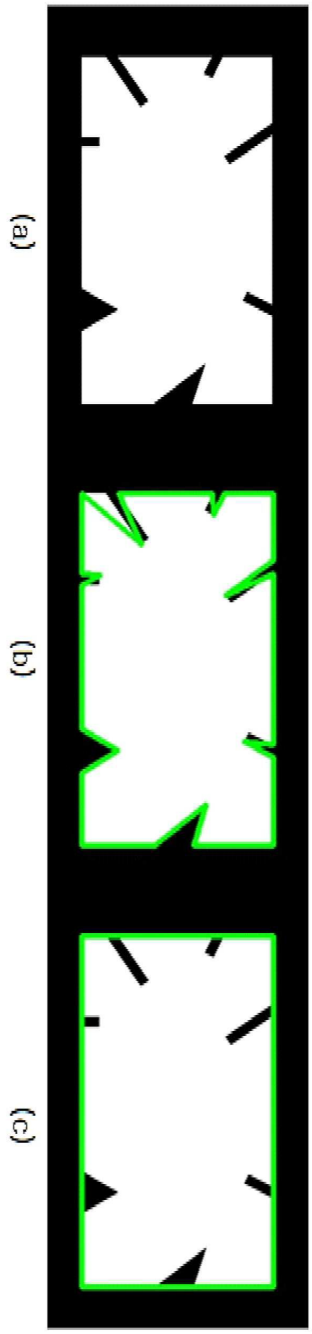
도면8



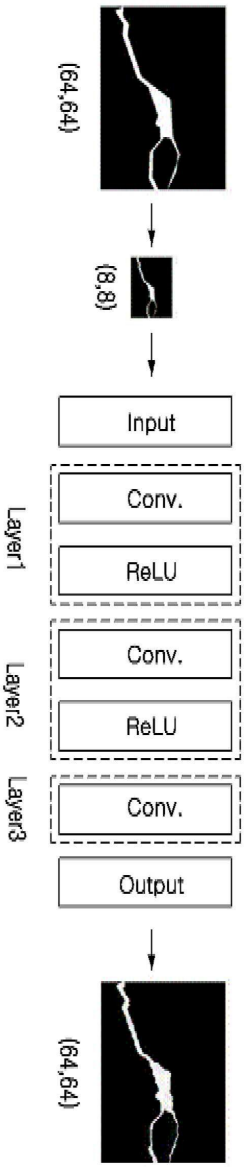
도면9


(64,64)
(8,8)
Input
Layer1
Conv.
ReLU
Layer2
Conv.
ReLU
Layer3
Conv.
Output
(64,64)

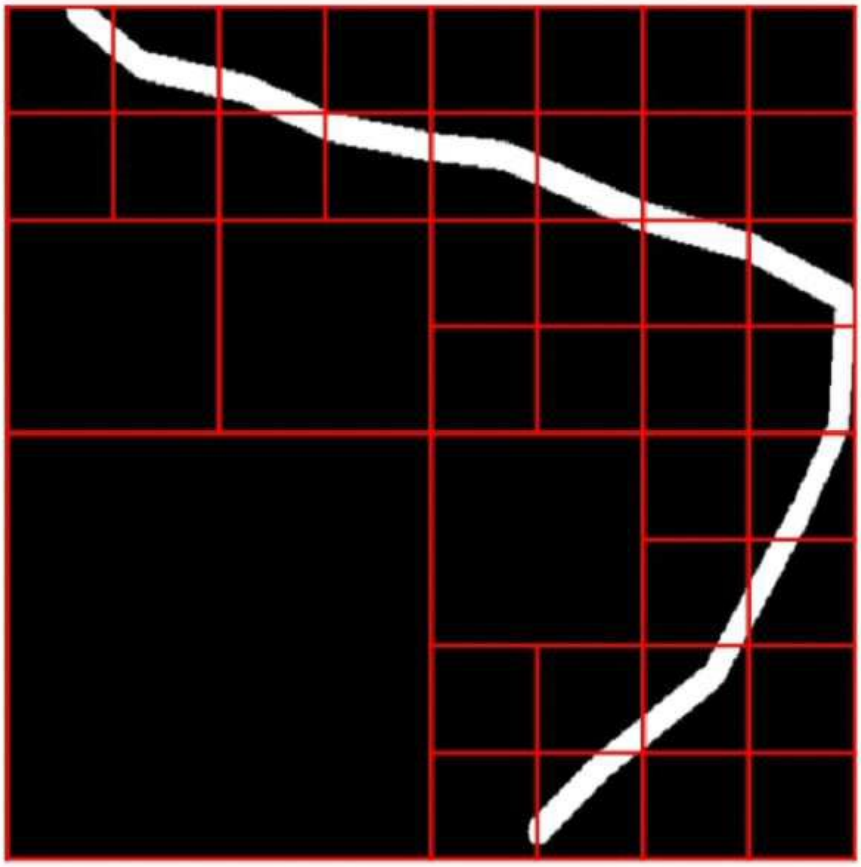
도면10



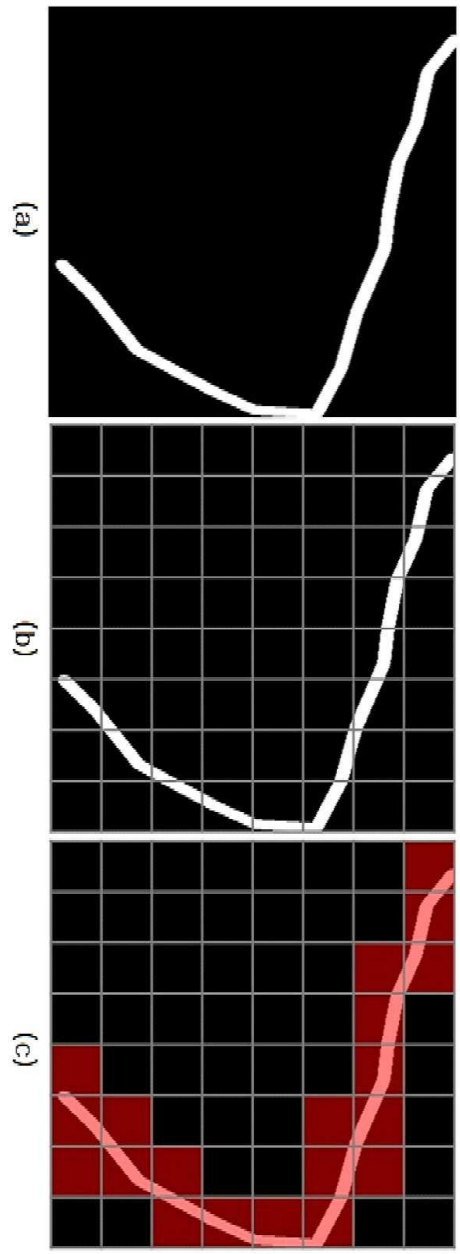
도면11


(64,64)
(8,8)
Input
Layer1
Conv.
ReLU
Layer2
Conv.
ReLU
Layer3
Conv.
Output
(64,64)

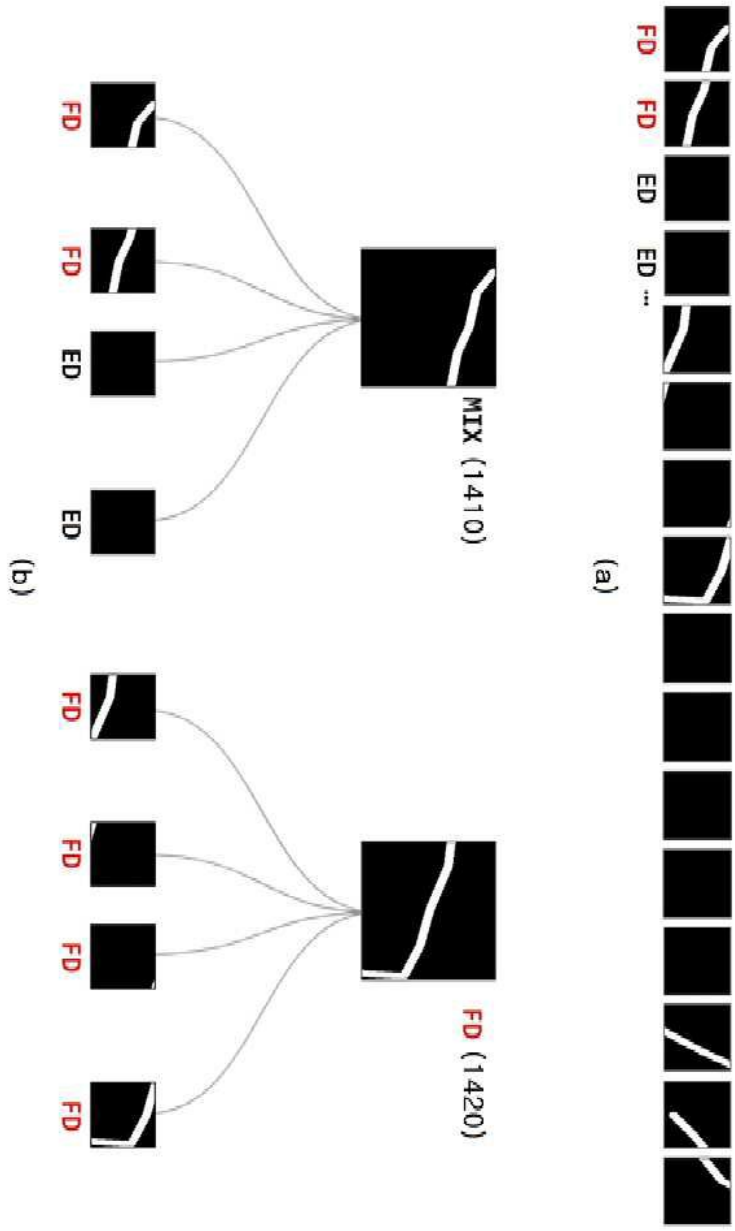
도면12



도면13



도면14



도면15

