



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0015182
(43) 공개일자 2025년02월03일

(51) 국제특허분류(Int. Cl.)
G06F 18/241 (2023.01) G06F 17/16 (2006.01)
G06N 3/045 (2023.01) G06N 3/0464 (2023.01)
G06N 3/08 (2023.01) G06V 10/764 (2022.01)
(52) CPC특허분류
G06F 18/241 (2023.01)
G06F 17/16 (2013.01)
(21) 출원번호 10-2023-0096267
(22) 출원일자 2023년07월24일
심사청구일자 2023년07월24일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
이상철
인천광역시 연수구 아트센터대로97번길 76, 1402동 805호(송도동, 송도 더샵 하버뷰 14단지)
정예립
인천광역시 미추홀구 용정공원로83번길 49, 2062호(용현동)
(74) 대리인
양성보


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 계층적 공분산을 이용한 세분화된 데이터 분류 방법 및 시스템

(57) 요약

계층적 공분산을 이용한 세분화된 데이터 분류 방법 및 시스템이 제시된다. 본 발명에서 제안하는 계층적 공분산을 이용한 세분화된 데이터 분류 시스템은 입력 이미지를 블록 단위로 인코딩하는 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부, 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 FCA 모듈 및 상기 FCA 모듈로부터 출력된 각 특징에 대한 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 분류부를 포함한다.

대표도



(52) CPC특허분류

G06N 3/045 (2023.01)

G06N 3/0464 (2023.01)

G06N 3/08 (2023.01)

G06V 10/764 (2023.08)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711192607
과제번호	2021R1A2C2010893
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	중견연구
연구과제명	[Ezbaro] 희소 영상에 특화된 영상 분해-합성을 통한멀티도메인 기반 관심 지표 및
객체 검출 기술 연구	
기 여 율	1/2
과제수행기관명	인하대학교
연구기간	2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	1711179347
과제번호	00155915
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신인재양성(교육운영수익)
연구과제명	[Ezbaro][정부+민간] 인공지능융합혁신인재양성(2차년도)
기 여 율	1/2
과제수행기관명	인하대학교 산학협력단
연구기간	2023.01.01 ~ 2023.12.31

명세서

청구범위

청구항 1

입력 이미지를 블록 단위로 인코딩하는 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부;

상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 FCA 모듈; 및

상기 FCA 모듈로부터 출력된 각 특징에 대한 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 분류부

를 포함하는 데이터 분류 시스템.

청구항 2

제1항에 있어서,

상기 컨볼루션 블록부는,

다단계 특징 정보를 활용하기 위해 계층적 학습을 위한 블록별 백본 네트워크를 이용하는 복수의 컨볼루션 블록을 포함하고, 서로 다른 깊이의 백본에 대한 복수의 중간 특징 맵이 서로 다른 컨볼루션 블록에 입력되는

데이터 분류 시스템.

청구항 3

제1항에 있어서,

상기 FCA 모듈은,

복수의 컨볼루션 블록 각각의 출력 특징 맵을 입력 반도록 복수의 블록이 위치하여 특징 맵의 각 열 또는 행의 요소를 상기 특징 맵의 각 채널 함수의 표현으로 나타내고, 공분산 행렬 그룹의 평균을 각 채널의 최종 관계 디스크립터로 사용하고,

복수의 컨볼루션 블록 각각의 출력 특징 맵을 채널의 수, 특징 맵의 높이와 폭, 특징 맵의 열 벡터, 평균 벡터 및 공분산 행렬을 이용하여 정규화하고, 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 각 특징 맵은 행렬 곱 연산을 거친 후, 다음 컨볼루션 블록의 입력으로 사용되는

데이터 분류 시스템.

청구항 4

제1항에 있어서,

상기 분류부는,

복수의 분류기를 통해 상기 FCA 모듈로부터 출력된 각 특징에 대하여 분류 값을 계산하고, 상기 복수의 분류 값을 연결 함수를 이용하여 융합한 재분류 값을 계산하고,

상기 복수의 분류 값 및 재분류 값 각각에 특징별 분류점수 가중치를 부여하고, 상기 복수의 분류 값 및 재분류 값에 대한 평균으로 최종 분류 값을 출력하는

데이터 분류 시스템.

청구항 5

복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 입력 이미지를 블록 단위로 인코딩하는 단계;

FCA 모듈을 통해 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 필수 특징 맵 채널을 강조하고 특징

맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 단계; 및
 분류부를 통해 상기 FCA 모듈로부터 출력된 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 단계
 를 포함하는 데이터 분류 방법.

청구항 6

제5항에 있어서,
 상기 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 입력 이미지를 블록 단위로 인코딩하는 단계는,
 다단계 특징 정보를 활용하기 위해 계층적 학습을 위한 블록별 백본 네트워크를 이용하는 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 서로 다른 깊이의 백본에 대한 복수의 중간 특징 맵이 서로 다른 컨볼루션 블록에 입력되는
 데이터 분류 방법.

청구항 7

제5항에 있어서,
 상기 FCA 모듈을 통해 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 필수 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 단계는,
 복수의 컨볼루션 블록 각각의 출력 특징 맵을 입력 반도록 복수의 블록이 위치하여 특징 맵의 각 열 또는 행의 요소를 상기 특징 맵의 각 채널 함수의 표현으로 나타내고, 공분산 행렬 그룹의 평균을 각 채널의 최종 관계 디스크립터로 사용하고,
 복수의 컨볼루션 블록 각각의 출력 특징 맵을 채널의 수, 특징 맵의 높이와 폭, 특징 맵의 열 벡터, 평균 벡터 및 공분산 행렬을 이용하여 정규화하고, 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 각 특징 맵은 행렬 곱 연산을 거친 후, 다음 컨볼루션 블록의 입력으로 사용되는
 데이터 분류 방법.

청구항 8

제5항에 있어서,
 상기 분류부를 통해 상기 FCA 모듈로부터 출력된 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 단계는,
 복수의 분류기를 통해 상기 FCA 모듈로부터 출력된 각 특징에 대하여 분류 값을 계산하고, 상기 복수의 분류 값을 연결 함수를 이용하여 융합한 재분류 값을 계산하고,
 상기 복수의 분류 값 및 재분류 값 각각에 특징별 분류점수 가중치를 부여하고, 상기 복수의 분류 값 및 재분류 값에 대한 평균으로 최종 분류 값을 출력하는
 데이터 분류 방법.

발명의 설명

기술 분야

[0001] 본 발명은 계층적 공분산을 이용한 세분화된 데이터 분류 방법 및 시스템에 관한 것이다.

배경 기술

[0002] 최근 몇 년 동안, FGVC(Fine-Grained Visual Classification)는 컴퓨터 비전에서 가장 흥미롭고 잘 알려진 연구 영역 중 하나였다. FGVC는 운송, 환경 보호, 소매를 포함한 지능적인 분야에서의 다양한 응용으로 인해 많은 관심을 끌었다. 일반적인 이미지 분류와 달리, FGVC는 글로벌 및 로컬 특징에 대한 구별된 외관 세부사항에 초점을 맞추으로써 사소한 세부사항 변경이 있는 하위 클래스에 의존한다. 예를 들어, 새를 단순히 '새'로 분류하

는 대신, 새의 이미지를 새 부리의 패턴의 변화나 머리카락의 작은 부분에 따라 새 종으로 분류될 수 있다. 또한, 차량 이미지는 세부적인 구조적 다양성 또는 설계 요소에 따라 분류할 수 있다. 차량의 미세한 모양과 색상은 유사하다.

[0003] 초기의 세분화된 이미지 분류 방법은 차별적 표현을 학습하기 위해 주석이 있는 대규모 데이터 세트가 필요했다. 일반적으로 강력한 지도 방식으로 심층 신경망을 훈련하려면 다양한 이미지 쌍과 해당 레이블이 필요하다. 그러나 주석이 달린 데이터 세트는 수동 레이블링 비용으로 인해 제한되며, 이는 전문가의 상당한 노력이 필요하다. 따라서, 종래기술에서는 이미지 수준 레이블만 필요로 하는 약한 지도(weak supervision) 방법에 초점을 맞추고 있다. 약한 지도에 의해 학습된 특징은 로컬 및 글로벌 컨텍스트 단서를 결합하여 더 중요한 정보에 초점을 맞출 수 있다.

[0004] FGVC의 핵심은 차별적인 부분을 결정하고 학습하는 것이다. 따라서, 종래기술에서는 주의 맵에 자주 표시되는 두드러진 영역에서 차별적 특성을 추출하는 데 초점을 맞추고 있다. 주의 맵은 로컬 특징의 고유한 특성을 구현하는 데 도움이 될 수 있다. 로컬 특징을 학습하기 위한 성공적인 주의 모델 중 하나는 이미지와 비디오 모두에 대한 분류 및 탐지 작업을 위해 다중 스케일 비전 변환기를 처리하는 것이다. 이 접근 방식은 이미지 분류에서 다중 모드 방법에 비해 상당한 성능을 보여준다. 또한, 반복적인 주의 방법을 사용하여 배경 억제력을 억누르고 전경 포커싱에 초점을 맞추는 종래기술이 제안되었다. 이러한 발전에도 불구하고 주의 방법은 모델 복잡성을 증가시키고 메모리 오버헤드를 유발할 수 있다. 이러한 한계를 극복하기 위해 공분산의 통계적 특성을 활용하는 방법이 제안되었다. 공간 정보만 사용했던 기존 접근 방식과 달리 채널 정보를 활용하여 각 채널 패널 내에서 상황별 의미 정보 스칼라 값의 집계를 방지한다.

선행기술문헌

특허문헌

[0005] (특허문헌 0001) [1] C. Wah, S. Branson, P. Welinder, P. Perona, and S. Belongie, "The caltech UCSD birds-200-2011 dataset," California Inst. Technol., CA, USA, Tech. Rep. CNS-TR-2010-001, 2010.

(특허문헌 0002) [2] J. Krause, M. Stark, J. Deng, and L. Fei-Fei, "3D object representations for fine-grained categorization," in Proc. IEEE Int. Conf. Comput. Vis. Workshops, Dec. 2013, pp. 554-561.

(특허문헌 0003) [3] S. Maji, E. Rahtu, J. Kannala, M. Blaschko, and A. Vedaldi, "Fine-grained visual classification of aircraft," 2013, arXiv:1306.5151.

발명의 내용

해결하려는 과제

[0006] 본 발명이 이루고자 하는 기술적 과제는 패턴 인식을 위해 공분산 행렬 분석을 세분화된 분류를 위한 주의 모델에 통합하는 방법 및 시스템을 제공하는데 있다. 본 발명의 실시예에 따른 FCA(Feature map Covariance Attention) 모듈은 공분산의 통계적 특성을 이용하여 구축되고, 분류 작업에 채널 공분산 주의를 이용하여 주의 모듈의 가치치와 관련된 계산 오버헤드를 효과적으로 줄이고자 한다.

과제의 해결 수단

[0007] 일 측면에 있어서, 본 발명에서 제안하는 계층적 공분산을 이용한 세분화된 데이터 분류 시스템은 입력 이미지를 블록 단위로 인코딩하는 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부, 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 FCA 모듈 및 상기 FCA 모듈로부터 출력된 각 특징에 대한 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 분류부를 포함한다.

[0008] 상기 컨볼루션 블록부는 다단계 특징 정보를 활용하기 위해 계층적 학습을 위한 블록별 백본 네트워크를 이용하는 복수의 컨볼루션 블록을 포함하고, 서로 다른 깊이의 백본에 대한 복수의 중간 특징 맵이 서로 다른 컨볼루션 블록에 입력된다.

[0009] 상기 FCA 모듈은 복수의 컨볼루션 블록 각각의 출력 특징 맵을 입력 받도록 복수의 블록이 위치하여 특징 맵의

각 열 또는 행의 요소를 상기 특징 맵의 각 채널 함수의 표현으로 나타내고, 공분산 행렬 그룹의 평균을 각 채널의 최종 관계 디스크립터로 사용하고, 복수의 컨볼루션 블록 각각의 출력 특징 맵을 채널의 수, 특징 맵의 높이와 폭, 특징 맵의 열 벡터, 평균 벡터 및 공분산 행렬을 이용하여 정규화하고, 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 각 특징 맵은 행렬 곱 연산을 거친 후, 다음 컨볼루션 블록의 입력으로 사용된다.

[0010] 상기 분류부는 복수의 분류기를 통해 상기 FCA 모듈로부터 출력된 각 특징에 대하여 분류 값을 계산하고, 상기 복수의 분류 값을 연결 함수를 이용하여 융합한 재분류 값을 계산하고, 상기 복수의 분류 값 및 재분류 값 각각에 특징별 분류점수 가중치를 부여하고, 상기 복수의 분류 값 및 재분류 값에 대한 평균으로 최종 분류 값을 출력한다.

[0011] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 계층적 공분산을 이용한 세분화된 데이터 분류 방법은 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 입력 이미지를 블록 단위로 인코딩하는 단계, FCA 모듈을 통해 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 필수 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 단계 및 분류부를 통해 상기 FCA 모듈로부터 출력된 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 단계를 포함한다.

발명의 효과

[0012] 본 발명의 실시예들에 따르면 계층적 공분산을 이용한 세분화된 데이터 분류 방법 및 시스템을 통해 분류 작업에 채널 공분산 주의를 이용하여 주의 모듈의 가중치와 관련된 계산 오버헤드를 효과적으로 줄일 수 있다. 또한, FCA 모듈은 추가 주석 정보 없이 이미지의 공간적 특징에 초점을 맞추고, 다양한 규모로 집중된 특징 맵에 대하여 보다 세분화된 특징을 얻을 수 있으므로 블록 단위의 각 특징 피라미드에 계층적으로 적용할 수 있다.

도면의 간단한 설명

[0013] 도 1은 본 발명의 일 실시예에 따른 세분화된 분류가 어려운 이미지의 예시를 나타내는 도면이다.
 도 2는 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 시스템의 구성을 나타내는 도면이다.
 도 3은 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 방법을 설명하기 위한 흐름도이다.
 도 4는 본 발명의 일 실시예에 따른 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 알고리즘이다.
 도 5는 본 발명의 일 실시예에 따른 공분산 행렬을 사용하는 작업인 PCA에서 PC 수에 따른 이미지를 나타내는 도면이다.
 도 6은 본 발명의 일 실시예에 따른 FCA 모듈의 구성을 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0014] FGVC(Fine-Grained Visual Classification)는 항공 및 동물 품종 분류와 같은 다양한 영역에서 응용되고 있고, 이는 주로 FGVC의 기준이 상당히 작은 범위 또는 미묘한 패턴 차이에 따라 다르기 때문이다. 심층 컨볼루션 신경망에서 특징 맵 사이의 공분산은 차별적 영역을 자동으로 학습하기 위한 특징 선택에 긍정적인 영향을 미친다. 본 발명에서는 공분산 특성을 사용하는 주의 모듈을 삽입하여 세분화된 분류 모델을 위한 방법을 제안한다. 구체적으로, 본 발명에서는 기존 분류 모델을 구성하는 컨볼루션 블록 사이의 특징 맵을 추출하기 위한 특징 맵 주의(Feature map Covariance Attention; FCA) 모듈을 제안한다. 그런 다음 FCA 모듈은 해당하는 공분산 행렬 값을 채널에 적용하여 돌출 영역에 초점을 맞춘다. 본 발명에서는 다양한 규모 표현에 초점을 맞추어 계층적 방식으로 세분화된 분류의 필요성을 보여준다. 또한 제안된 각 전략이 분류 성능에 어떻게 영향을 미치는지 보여주기 위해 두 가지 절제 연구를 구현했다. 본 발명의 실시예에 따른 실험은 주로 세분화된 분류 작업에 사용되는 CUB-200-2011, Stanford Cars 및 FGVC-Aircraft의 세 가지 데이터 세트에 대해 수행된다. 본 발명의 실시예에 따른 방법은 최첨단 모델을 0.4%, 1.1%, 1.4% 차이로 능가한다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

- [0016] 도 1은 본 발명의 일 실시예에 따른 세분화된 분류가 어려운 이미지의 예시를 나타내는 도면이다.
- [0017] 본 발명에서는 패턴 인식을 위해 공분산 행렬 분석을 세분화된 분류를 위한 주의 모듈에 통합한다. 제안하는 방법은 분류 작업에 채널 공분산 주의를 사용하고, 주의 모듈의 가중치와 관련된 계산 오버헤드를 효과적으로 줄일 수 있다.
- [0018] 본 발명의 실시예에 따른 FCA(Feature map Covariance Attention) 모듈은 공분산의 통계적 특성을 사용하여 구축된다. FCA 모듈은 도 1과 같이 추가 주석 정보(예를 들어, 경계 상자/구성 요소 주석) 없이 이미지의 공간적 특징에 초점을 맞출 수 있다. 또한 이 모듈은 다양한 규모로 집종된 특징 맵에 대하여 보다 세분화된 특징을 얻을 수 있으므로 블록 단위의 각 특징 피라미드에 계층적으로 적용할 수 있다. CUB-200-2011(CUB)[1], Stanford Cars(CAR)[2], FGVC-Aircraft(AIR)[3]의 세 가지 데이터 세트에 대해 세분화된 분류를 수행했으며 최첨단(State-of-the-Art; SOTA) 방법과 비교하여 높은 성능을 달성했다.
- [0019] 본 발명의 실시예에 따르면, 특징 맵 채널 간의 공분산 통계를 기반으로 주의 기술을 적용하는 FCA(Feature map Covariance Attention) 모듈을 제안하며, 작은 특징에 대한 중요한 채널에만 집중한다. 또한, 특징 피라미드를 활용하여 분류를 진행하는 네트워크를 제안하고, 구체적으로 규모 다양성 측면에서 견고하게 만드는 블록 단위 방법을 제안한다.
- [0021] 본 발명의 실시예에 따르면, 차별적 특징을 발견하는 것은 세분화된 이미지 분류에서 필수적인 과제이다. 컨볼루션 신경망(CNN)은 분류, 인식 및 분할과 같은 컴퓨터 비전 작업에 주로 사용된다. 그러나 FT-VGG 및 B-CNN와 같은 방법은 섬세한 집중이 없기 때문에 미묘한 차별적 특징 표현을 포착하는 데 강력하지 않다. 종래기술에서는 다양한 풀링 기법으로 입력 데이터를 전처리하는 특징 인코딩 방법에 초점을 맞추었다. 종래기술에서 로컬 쌍별 특징 상호 작용을 캡처하는 두 개의 스트림 CNN으로 구성된 이중 선형 CNN 모델 B-CNN이 제안되었다. 한편, 또 다른 종래기술에서 콤팩트하고 명시적인 특징 매핑을 사용하여 특징의 교차 상호 작용을 캡처하는 커널 풀링 방법이 제안되었다. 반면에 또 다른 종래기술에서는 다중 교차 계층 특징을 융합하기 위해 계층적 이중 선 풀링을 도입했다. 그럼에도 불구하고 이러한 방법의 성능은 여전히 개선되어야 하며 추가 계획이 여전히 필요하다.
- [0022] 최근 추가 정보나 경계 상자 주석 없이 학습 분류를 위한 준지도 방식이 등장했다. 종래기술에서 특징과 다른 네트워크 계층 간의 관계를 활용하여 다단계 세분성을 형성할 것을 제안했다. 또 다른 종래기술에서 모델 다양성을 향상시키고 위치 증거를 동적으로 정렬하기 전에 시각적 콘텐츠 정보에 통합하기 위해 Kullback-Leibler 발산 기반 제약 조건을 학습한다. 한편, 또 다른 종래기술에서는 자세 집약적 특징 정규화를 통해 차별적 특징을 촉진하기 위해 적응형 그래프 일치 알고리즘으로 로컬 차별적 영역을 산출하는 상호 채널 손실(MC-Loss)로 훈련된 채널별 주의 접근 방식을 구현함으로써 한 걸음 더 나아갔다. 뿐만 아니라 특징 맵의 스케일 피라미드를 활용하여 이미지 스케일의 견고성을 달성한다. 그러한 이유로, 본 발명의 실시예에서는 모델 견고성을 향상시키기 위해 스케일 발산을 위해 네트워크의 계층 구조를 모델에 사용한다.
- [0023] 주의 기술은 분류에서 중요한 역할을 한다. 인간 시각의 중요한 특징은 인간이 전체 장면을 동시에 처리하려고 시도하지 않는다는 점이다. 인간의 경우 시각 시스템은 부분 속성에 초점을 맞추고 선택적으로 투영에 초점을 맞춘다. 최근 종래기술들은 이러한 개념을 기반으로 더 나은 시각적 구조를 포착하기 위한 집중적인 기술을 개발하려고 시도했다. 종래기술에서 다양한 규모의 차별적 영역을 반복적으로 학습하는 반복 주의 네트워크인 RA-CNN과 공간적으로 상관된 채널을 클러스터링하여 더 다양한 로컬 부분을 생성하는 다중 주의 컨볼루션 신경망인 MA-CNN과 같은 차별적 영역을 캡처하기 위한 주의 모듈을 사용했다. 종래기술에서 세분화된 시각적 세부 사항을 캡처하는 선택적 희소 샘플링 네트워크(SSN)가 제안되었다. 또한 FT-VGG는 차별적 패치의 필터 뱅크를 학습하여 중간 수준의 표현 학습을 향상시키며, 또 다른 종래기술에서는 대부분의 정보 영역을 현지화하기 위한 자체 지도 네트워크를 제안했다. 이러한 네트워크는 여러 각도에서 특징 맵을 분석하는 동안 노이즈가 많은 입력에 대해 개선되고 강력하지만, 작업 오버헤드로 인해 속도가 느려진다.
- [0024] 공분산 행렬 분석은 패턴 인식, 컴퓨터 비전, 신호 처리에서 일반적으로 사용된다. 가장 잘 알려진 애플리케이션 기술 중 하나는 특징 추출 및 데이터 표현 기술인 주성분 분석(Principal Component Analysis; PCA)이다. PCA 기반 이미지 표현 및 인식 방법에서 특징 행렬은 공분산 행렬을 평가하기 위해 벡터로 변환된다. 여기서 고유 벡터는 이미지의 주요 구성 요소를 추출하기 위해 계산되며, 이는 샘플 수와 특징 차원이 모두 높은 경우 일

반적으로 높은 메모리 비용으로 이어진다. 이러한 문제를 극복하기 위해 종래기술에서 상황별 정보를 분석할 수 있는 로컬 및 글로벌 신호에 의존하는 방법을 제안했다. 본 발명에서는 컨텍스트 정보를 활용하여 행렬을 이용하는 채널 주의를 수행함으로써, 세분화된 분류를 위해 집중해야 하는 특징 맵의 채널을 식별한다.

- [0026] 도 2는 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 시스템의 구성을 나타내는 도면이다.
- [0027] 본 발명의 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 시스템은 주의 모듈이 있는 세 개의 컨볼루션 블록과 네 개의 분류기로 구성된 모델을 제안한다. 계층적 방식으로 각 특징 맵 스케일에 주의를 기울이기 위해 입력 이미지를 블록 단위로 집중적으로 인코딩하고 분류한다. 최종 분류 출력은 세 가지 분류기의 융합에서 얻은 재분류 값을 포함하여 네 가지 분류 값의 평균이다.
- [0028] 본 발명의 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 시스템은 컨볼루션 블록부(210), FCA 모듈(220) 및 분류부(230)를 포함한다.
- [0029] 본 발명의 실시예에 따른 컨볼루션 블록부(210)는 입력 이미지(211)를 블록 단위로 인코딩하는 복수의 컨볼루션 블록을 포함한다.
- [0030] 본 발명의 실시예에 따른 컨볼루션 블록부(210)는 다단계 특징 정보를 활용하기 위해 계층적 학습을 위한 블록별 백본 네트워크를 이용하는 복수의 컨볼루션 블록을 포함하고, 서로 다른 깊이의 백본에 대한 복수의 중간 특징 맵이 서로 다른 컨볼루션 블록(BLOCK1, BLOCK2, BLOCK3)에 입력된다.
- [0031] 본 발명의 실시예에 따른 FCA 모듈(220)은 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시킨다.
- [0032] 본 발명의 실시예에 따른 FCA 모듈(220)은 복수의 컨볼루션 블록 각각의 출력 특징 맵을 입력 받도록 복수의 블록(FCA1, FCA2, FCA3)이 위치하여 특징 맵의 각 열 또는 행의 요소를 상기 특징 맵의 각 채널 함수의 표현으로 나타내고, 공분산 행렬 그룹의 평균을 각 채널의 최종 관계 디스크립터로 사용한다.
- [0033] 본 발명의 실시예에 따른 FCA 모듈(220)은 복수의 컨볼루션 블록 각각의 출력 특징 맵을 채널의 수, 특징 맵의 높이와 폭, 특징 맵의 열 벡터, 평균 벡터 및 공분산 행렬을 이용하여 정규화하고, 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 각 특징 맵은 행렬 곱 연산을 거친 후, 다음 컨볼루션 블록의 입력으로 사용된다.
- [0034] 본 발명의 실시예에 따른 분류부(230)는 상기 FCA 모듈로부터 출력된 각 특징에 대한 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력한다.
- [0035] 본 발명의 실시예에 따른 분류부(230)는 복수의 분류기를 통해 상기 FCA 모듈로부터 출력된 각 특징에 대하여 분류 값을 계산하고, 상기 복수의 분류 값을 연결 함수를 이용하여 융합한 재분류 값을 계산한다.
- [0036] 본 발명의 실시예에 따른 분류부(230)는 상기 복수의 분류 값 및 재분류 값 각각에 특징별 분류점수 가중치를 부여하고, 상기 복수의 분류 값 및 재분류 값에 대한 평균으로 최종 분류 값을 출력한다.
- [0038] 도 3은 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 방법을 설명하기 위한 흐름도이다.
- [0039] 본 발명의 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 방법은 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 입력 이미지를 블록 단위로 인코딩하는 단계(310), FCA 모듈을 통해 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 필수 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시키는 단계(320) 및 분류부를 통해 상기 FCA 모듈로부터 출력된 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력하는 단계(330)를 포함한다.
- [0040] 단계(310)에서, 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 입력 이미지를 블록 단위로 인코딩한다.
- [0041] 본 발명의 실시예에 따르면, 다단계 특징 정보를 활용하기 위해 계층적 학습을 위한 블록별 백본 네트워크를 이용하는 복수의 컨볼루션 블록을 포함하는 컨볼루션 블록부를 통해 서로 다른 깊이의 백본에 대한 복수의 중간

특징 맵이 서로 다른 컨볼루션 블록에 입력된다.

- [0042] 단계(320)에서, 상기 FCA 모듈을 통해 상기 인코딩된 입력 이미지의 각 특징 맵 스케일에 대하여 필수 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 이용하여 관련 없는 정보를 감소시킨다.
- [0043] 본 발명의 실시예에 따르면, 복수의 컨볼루션 블록 각각의 출력 특징 맵을 입력 받도록 복수의 블록이 위치하여 특징 맵의 각 열 또는 행의 요소를 상기 특징 맵의 각 채널 함수의 표현으로 나타내고, 공분산 행렬 그룹의 평균을 각 채널의 최종 관계 디스크립터로 사용한다.
- [0044] 본 발명의 실시예에 따르면, 복수의 컨볼루션 블록 각각의 출력 특징 맵을 채널의 수, 특징 맵의 높이와 폭, 특징 맵의 열 벡터, 평균 벡터 및 공분산 행렬을 이용하여 정규화하고, 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 각 특징 맵은 행렬 곱 연산을 거친 후, 다음 컨볼루션 블록의 입력으로 사용된다.
- [0045] 단계(330)에서, 상기 분류부를 통해 상기 FCA 모듈로부터 출력된 복수의 분류 값 및 상기 복수의 분류 값을 융합하여 얻은 재분류 값에 대한 평균으로 최종 분류 값을 출력한다.
- [0046] 본 발명의 실시예에 따르면, 복수의 분류기를 통해 상기 FCA 모듈로부터 출력된 각 특징에 대하여 분류 값을 계산하고, 상기 복수의 분류 값을 연결 함수를 이용하여 융합한 재분류 값을 계산한다.
- [0047] 본 발명의 실시예에 따르면, 상기 복수의 분류 값 및 재분류 값 각각에 특징별 분류점수 가중치를 부여하고, 상기 복수의 분류 값 및 재분류 값에 대한 평균으로 최종 분류 값을 출력한다.
- [0049] 도 4는 본 발명의 일 실시예에 따른 본 발명의 일 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 알고리즘이다.
- [0050] 본 발명의 실시예에 따른 계층적 공분산을 이용한 세분화된 데이터 분류 과정을 도 5 및 도 6을 참조하여 더욱 상세히 설명한다.
- [0052] 도 5는 본 발명의 일 실시예에 따른 공분산 행렬을 사용하는 작업인 PCA에서 PC 수에 따른 이미지를 나타내는 도면이다.
- [0053] 도 5(a)는 새 이미지고, 도 5(b)는 차 이미지를 예시로서 나타낸다. 본 발명의 실시예에 따르면, 30대 이상의 PC에서 충분히 구별할 수 있었다. 공분산 행렬을 사용하여 이러한 중요한 기능을 알 수 있음을 확인할 수 있다.
- [0054] 공분산 주위에 있어서, 종래기술에서는 공분산 행렬의 두 가지 특성을 식별했다.
- [0055] 첫째, 공분산 행렬은 전역 데이터 분포를 시뮬레이션한다. 데이터는 종종 PCA(도 5) 및 데이터를 압축적으로 나타내는 선형 판별 분석과 같이 고유값 분해의 최상의 기초를 찾기 위해 공분산 행렬을 사용하여 표현된다. 종래 기술에 따르면, 공분산 행렬을 고차원 데이터에 시간이 많이 걸리는 고유값 분해를 활용하는 대신 글로벌 분포 정보로 데이터를 정규화하기 위한 투영 행렬로 직접 활용할 수 있다. 이에 따라 분류 작업에서 공분산 행렬을 활용하여 빛 계산으로 필수 정보를 쉽게 추출할 수 있다.
- [0056] 이중 통계량은 공동 분포에 대한 정보를 인코딩할 수 있다. 다양한 물리적 의미와 단위를 갖는 특징 벡터 요소를 사용하여 공분산 행렬은 데이터 종속성을 효율적으로 모델링할 수 있다. 픽셀 강도, 위치, 1차 및 2차 도함수와 같은 다양한 통계 사이의 의존성은 전통적인 공분산 디스크립터(descriptor)를 사용하여 표현된다. 본 발명은 전통적인 핸드 크래프트 기능을 버리는 대신 공분산 행렬을 사용하여 잘 알려진 딥 러닝 프레임워크에 통합할 수 있다.
- [0057] 공분산 행렬은 딥 러닝에서 글로벌 및 로컬 의존성을 가진 특징 맵을 모델링하는 새로운 주의 모듈로 사용될 수 있다. 또한 핸드 크래프트 특성은 이질성(heterogeneity)의 두 번째 속성을 기반으로 학습된 기능과 성공적으로 통합될 수 있다. 본 발명의 실시예에 따르면, 공분산 행렬을 가진 주의 모듈이 분할 작업에서 잘 수행될 뿐만 아니라 FGVC에서 고유한 특징을 효과적으로 추출할 수 있음을 보여준다.
- [0059] 도 6은 본 발명의 일 실시예에 따른 FCA 모듈의 구성을 나타내는 도면이다.
- [0060] 본 발명의 실시예에 따르면, 필수 특징 맵 채널을 강조하고 특징 맵의 공분산 행렬을 사용하여 관련 없는 정보

를 줄이는 FCA 모듈을 제안한다. 각 채널 특징 맵의 모든 컨텍스트 의미 정보가 대략적인 스칼라 값으로 집계되는 종래기술의 주의 모듈과 달리, 본 발명의 실시예에 따른 FCA 모듈은 특징 맵의 각 열 또는 행의 요소를 각 채널 함수의 표현으로 간주된다. 그런 다음 공분산 행렬 그룹의 평균이 각 채널의 최종 관계 디스크립터로 사용된다. FCA 모듈은 이 채널 공분산을 사용하며 전체 모델 구조에 위치한다.

[0061] 도 5는 본 발명의 실시예에 따른 FCA 모듈의 특정 과정을 도시한다. 각 블록의 출력 특징 맵은 $X \in \mathbb{R}^{C \times HW}$ 로 표시된다. 여기서 C는 채널의 수, H와 W는 각각 특징 맵의 높이와 폭이다. 그런 다음 X는 다음과 같이 정규화된다:

$$\Sigma_C = \frac{1}{HW} (X - \mu \cdot O^T) (X - \mu \cdot O^T)^T \in \mathbb{R}^{C \times C} \quad (1)$$

[0063] 여기서 $O \in \mathbb{R}^{HW}$ 는 하나의 열 벡터이고 μ 및 Σ_C 는 각각 평균 벡터 및 공분산 행렬이다. 그런 다음 역행렬을 특징 맵의 행 및 열 크기로 곱하여 $C \times C$ 형태로 생성한다:

$$X_i^{att} = \Sigma_C \odot X_i, i \in \{1, 2, 3\} \quad (2)$$

[0065] 마지막으로, 각 특징 맵은 식(2)에 나타난 바와 같이 공분산 행렬에 주의를 기울이는 데 초점을 맞추기 위해 행렬 곱 연산을 거친다. 여기서 X_i 는 i번째 블록의 마지막 층에 있는 특징 맵이고, $\odot$ 는 내적이며, X_i^{att} 는 주의를 가지는 특징 맵이다. 그런 다음 X_i^{att} 는 다음 컨볼루션 블록의 입력으로 사용된다.

[0066] 채널 공분산 주의 행렬은 채널 간 관계가 있는 컨볼루션 연산 대신 특징 맵에 직접 적용됨에 유의한다. 채널 공분산 주의 모듈은 공분산 행렬을 사용하여 채널 함수 간의 의존성을 모델링하여 보다 일관된 의미 정보를 얻을 수 있다.

[0067] 본 발명의 실시예에 따른 이미지 분류를 위한 일반 커리큘럼 지도(General curriculum supervision)는 얇은 서브 네트워크(shallow sub-networks)와 결합된 레이블 평활화 기반의 쉬운 지도 신호를 채택하여 적용되었다. 거칠고 세분화된(Rough and Fine) 지도는 얇은 서브 네트워크로 심층 네트워크에 대한 규모 민감도를 보완하는 학습 방법의 차별적 기능을 장려한다. 서로 다른 깊이의 백본에 대한 여러 중간 특징 맵이 서로 다른 컨볼루션 블록에 공급되기 때문에, 본 발명에서는 다단계 특징 정보를 최대한 활용하기 위해 계층적 학습을 위한 블록별 방식으로 백본 네트워크(예를 들어, VGG 및 ResNet)를 사용한다. 이러한 개념을 활용하여 각 블록의 특징 맵에 초점을 맞추고 이러한 특징을 사용하여 분류 작업을 수행하기 위해 세 개의 블록을 사용한다. 프론트 엔드(front end)의 블록에서 추출된 특징 맵에는 거시적 특징이 포함되어 있으며, 리어 엔드(rear end)에서 추출된 특징 맵에는 미시적 특징이 포함되어 있다. 이러한 방식으로 표현의 견고성을 강조하여 글로벌 및 로컬 특징을 모두 가져온다.

[0068] 앙상블 학습의 안정적인 일반화 성능을 위해 일반적인 교차 엔트로피 손실인 L_{ce} 보다 평활화 계수가 하나 더 필요한 평활 교차 엔트로피 손실인 L_{sce} 를 제안한다.

$$L_{sce} (y^{(s)}, y, \alpha^{(s)}) = L_{ce} (y^{(s)}, y_{\alpha^{(s)}}) \quad (3)$$

[0070] 여기서 s는 컨볼루션 블록의 지수이고 α 는 0과 1 사이의 평활화 계수를 나타낸다. 지도 레이블 $y^{(s)}$ 와 원할 대상 코드가 가까워질수록 복잡한 네트워크 아키텍처로 인해 관련 서브 네트워크는 더 정확한 예측을 생성할 것이다. 일반적으로 서브 네트워크가 깊을수록 더 복잡한 예시에서 매핑 특징을 학습할 수 있다.

[0071] 본 발명의 실시예에 따른 분류부는 4개의 분류기를 사용하는데, $clfi \in \{1, 2, 3, 4\}$ 는 도 2에서 CLF로 표시된다. 각 블록 뒤에 글로벌 최대 풀링 층을 배치하여 이미지 표현을 얻고 다음과 같이 $clfi$ 에 입력한다:

$$f_i = clfi(X_i), i \in \{1, 2, 3\} \quad (4)$$

[0073] 여기서 $clfi$ 는 더 나은 분류 목적을 위한 컨볼루션 블록이고 $\oplus$ 는 연결 함수이다. 각 $clfi$ 는 두 개의 다층 퍼셉

트론과 ELU를 활성화 함수로 하는 두 개의 배치 정규화 함수로 구성된다. 세 가지 분류 성능이 생성될 때, clf_4 는 마지막 분류에 사용되며 다음과 같은 세 가지 특징이 연결된다.

$$f_4 = clf_4(X_1 \oplus X_2 \oplus X_3) \quad (5)$$

그런 다음 각 분류 결과에 가중치를 부여하여 최종 분류 점수를 계산한다. $\lambda_1, \lambda_2, \lambda_3$ 및 λ_4 는 다음과 같이 블록 특성별 분류점수 가중치를 0.7, 0.8, 0.9, 1.0으로 지정하였다.

$$f_{final} = \lambda_1 f_1 + \lambda_2 f_2 + \lambda_3 f_3 + \lambda_4 f_4 \quad (6)$$

기존 작업 후 더 높은 성능을 달성하기 위해 기존 작업에서 제안된 그래프 기반 로컬리제이션 방법을 적용한다. 이 방법은 패치 단위로 주의가 필요한 부분을 잘라냄으로써 대조 손실 함수를 이용한다. 그래프에서 각 패치를 노드로 삽입하면 패치의 속성을 기준으로 순서를 다시 정렬한다. 무작위로 주의를 입력하는 모델에 비해 이 방법을 사용할 때 보다 안정적인 주의를 적용할 수 있다.

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.

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(embodiment)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.


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.

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.


[0083] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

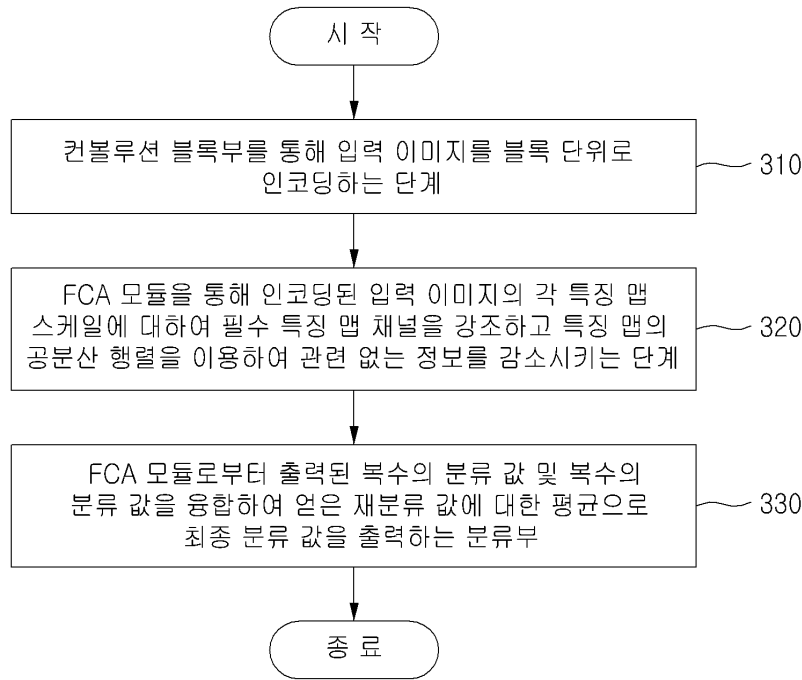
도면1



도면2



도면3



도면4

Algorithm 1 The Procedure of Our Method

Input: $Block_1, Block_2, Block_3 \in \mathbb{N}$, where $\mathbb{N}$ is the backbone network.


Output: f_{final}

```

1: for  $i = 1, 2, 3$  do
2:   if  $i = 1$  then  $X_0 = Img$ 
3:   end if
4:    $X_i \leftarrow Block_i(X_{i-1})$   $\triangleright$  Feature map extraction
5:    $\Sigma_C \leftarrow \frac{1}{HW} (X - \mu \cdot O^T) (X - \mu \cdot O^T)^T \in \mathbb{R}^{C \times C}$   $\triangleright$  Calculate covariance matrix
6:    $X_i^{att} \leftarrow \Sigma_C \odot X_i$   $\triangleright$  Give channel attention
7: end for
8: for  $i = 1, 2, 3$  do
9:    $f_i \leftarrow clf_i(X_i)$   $\triangleright$  Classify feature map
10: end for
11:  $f_4 \leftarrow clf_4(X_1 \oplus X_2 \oplus X_3)$   $\triangleright$  Concatenate outputs
12:  $f_{final} \leftarrow w\text{-avg}(f_1, f_2, f_3, f_4)$   $\triangleright$  Weight-average outputs

```

도면5



도면6

