

(19) 대한민국특허청(KR)
(12) 공개특허공보(A)(11) 공개번호 10-2024-0163941
(43) 공개일자 2024년11월19일

(51) 국제특허분류(Int. Cl.)

G06Q 50/26 (2024.01) B64U 101/31 (2023.01)
G06N 3/08 (2023.01) G06Q 10/04 (2023.01)
G06V 10/40 (2022.01) G06V 10/82 (2022.01)
G06V 20/52 (2022.01) H04W 4/14 (2018.01)

(52) CPC특허분류

G06Q 50/26 (2024.01)
G06N 3/08 (2023.01)

(21) 출원번호 10-2023-0061167

(22) 출원일자 2023년05월11일

심사청구일자 2023년05월11일

(71) 출원인

인천대학교 산학협력단

인천광역시 연수구 갯벌로 27, 인천대학교 이노베이션센터(송도동)

(72) 발명자

전광길

인천광역시 연수구 해송로 70, 209동 805호(송도동, 송도웰 카운티2단지)

(74) 대리인

특허법인충정


전체 청구항 수 : 총 9 항

(54) 발명의 명칭 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱

(57) 요약

본 발명은 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 및 장치에 관한 것으로, 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하여 높은 고도 또는 지상 근처의 환경조건을 기록하는 단계; 상기 무인 항공기의 비디오 프레임 데이터를 준비하고 특징을 추출하는 단계; 상기 추출된 특징 중에서 최적의 특징을 선택하는 단계; 상기 무인항공기의 과밀 기록을 분석하는 단계; 상기 분석 결과를 토대로 혼잡 여부를 판단하는 단계; 및 과밀이 감지되면 SMS 플랫폼을 통해 최적의 경로를 추천하는 단계;를 포함한다.

대표도 - 도3



(52) CPC특허분류

G06Q 10/047 (2023.01)

G06V 10/40 (2023.08)

G06V 10/82 (2022.01)

G06V 20/53 (2022.01)

H04W 4/14 (2013.01)

B64U 2101/31 (2023.01)

명세서

청구범위

청구항 1

스마트 시티 내부의 인구과밀을 감지하고 안전을 모니터링하기 위한 것으로, 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하여 높은 고도 또는 지상 근처의 환경조건을 기록하는 단계;

상기 무인 항공기의 비디오 프레임 데이터를 준비하고, 특징을 추출하는 단계;

상기 특징을 추출하는 단계에서 추출한 특징 중에서 최적의 특징을 선택하는 단계;

상기 선택된 최적의 특징에 기반하여 과밀 기록을 분석하고, 분석 결과를 토대로 혼잡 여부를 판단하는 단계; 및

상기 판단 단계에서 과밀이 감지되면 SMS 플랫폼을 통해 경로를 추천하는 단계;를 포함하는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 2

제1항에 있어서,

상기 특징을 추출하는 단계에서는, 전이학습(transfer learning)을 수행하는 네트워크의 기저(base)로 수정된 ResNet(Residual Network)구조를 사용할 수 있는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 3

제1항에 있어서,

상기 특징을 선택하는 단계는 자연의 물 순환에서 영감을 받아 데이터의 특징들을 각각 물 분자로 생각하는 물 순환 알고리즘(Water Cycle Algorithm, WCA)을 사용하는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 4

제3항에 있어서,

상기 물 순환 알고리즘은 증발 절차, 압축 및 침전 절차, 물의 로컬화, 지표수 흐름의 생성, 바다로 들어가는 강물의 형성 과정을 모티브로 하는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 5

제3항에 있어서,

상기 물 순환 알고리즘은 상기 특징을 추출하는 단계에서 추출된 특징들로 구성된 입력 값을 넣으면 최적의 특징 값이 선택되는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 6

제3항에 있어서,

상기 물 순환 알고리즘은 미리 정한 종료 조건을 충족하지 못한 때는 (A)단계, (B)단계, (C)단계를 반복하고,

상기 (A)단계는 특징을 선택하는 과정에서 비용함수의 매개변수들과 상기 물 순환 알고리즘의 변수들(N_{sr} , d_{max} , N_{pop} , MAX_{iter})을 초기화하는 단계;

상기 (B)단계는 모든 특징을 사용하여 모델을 학습하고, 각 특징의 중요도를 계산한 이후에 각 특징이 제거될

때 모델의 정확도가 얼마나 감소하는지 측정하는 단계; 및

상기 (C)단계는 가장 중요도가 낮은 특징을 제거하는 단계;를 포함하며,

상기 물 순환 알고리즘의 변수들 중 N_{sr} 은 강(river)의 개수와 하나의 바다(sea)를 합산한 값, d_{max} 은 강과 바다 사이 간격의 최대값, N_{pop} 은 빗방울의 수(initial features), MAX_{iter} 은 반복의 최대 값을 의미하는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 7

제2항에 있어서,

딥 러닝은 비지도, 준지도 및 지도 학습 방법을 결합한, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법.

청구항 8

스마트 시티 내부의 인구과밀을 감지하고 안전을 모니터링하기 위한 것으로, 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하여 높은 고도 또는 지상 근처의 환경조건을 기록하는 데이터 수집부;

상기 무인 항공기의 비디오 프레임 데이터를 준비하고 특징을 추출하는 특징 추출부;

상기 특징 추출부에서 추출한 특징 중에서 최적의 특징을 선택하는 특징 선택부;

상기 선택된 최적의 특징에 기반하여 과밀 기록을 분석하고, 분석 결과를 토대로 혼잡 여부를 판단하여 과밀이 감지되면 SMS 플랫폼을 통해 최적의 경로를 추천하는 SMS 발송부;를 포함하는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 장치.

청구항 9

제8항에 있어서,

상기 특징을 추출하는 특징 추출부에서는, 전이학습(transfer learning)을 수행하는 네트워크의 기저(base)로 수정된 ResNet(Residual Network)구조를 사용할 수 있는, 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 장치.

발명의 설명

기술 분야

[0001] 본 발명은 UAV 애플리케이션 및 SMS 플랫폼의 조합으로 혼잡한 상황에서 효과적인 경로를 찾아 인구 과밀을 실시간으로 통제하는 방법 및 장치에 관한 것이다.

배경 기술

[0002] 공공 장소 및 사회에서는 비정상적인 커뮤니티, 폭동 또는 공개 행사로 인해 인구 과밀 현상이 발생할 수 있고, 인구 밀집지역은 감염병을 확산시켜 사회적인 우려를 야기시킨다. 현대 사회에서는 비정상적인 이벤트가 종종 발생하고, 사람들이 혼잡한 공간에서는 예측하기 힘든 행동 양상을 보일 수 있어 과밀 지역에서 사람들을 지속적으로 모니터링 하는 것은 어렵다. 그럼에도 여전히 사회에서의 과밀 감지 시스템은 비정상적인 인구 행동의 출현과 같은 문제를 예방하는 데 중요한 역할을 한다. 오늘날 다양한 카메라가 혼잡한 환경에서 CCTV 카메라와 같은 단순 비디오 감시는 사회에서 사용되고 있다. 하지만 현대 도시의 급속한 도시화 성장으로 인해 토목 인프라, 의료 및 교통과 같은 필수 과제를 고려하여 문제를 해결하기 위해서는 감시를 위한 지능형 접근 방식이 필요하다.

선행기술문헌

특허문헌

[0003] (특허문헌 0001) KR 10-2019-0135672 A

발명의 내용

해결하려는 과제

[0004] 이와 같은 문제점을 해결하기 위하여, 본 발명은 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 및 장치에 관한 것으로, 무인 항공기(Unmanned Aerial Vehicles, UAV)와 소셜모니터링 시스템(Social Monitoring System, SMS)을 도입하여 인구과밀을 감지하고 스마트 시티 내부의 안전을 모니터링하기 위한 방법 및 장치를 제공할 수 있다.

[0005] 드론을 이용하여 환경조건을 기록하고, 과밀 기록을 분석하여 혼잡 여부를 판단하며, 상기 드론의 과밀 기록을 분석하는 과정에서는 전이학습(transfer learning)을 수행하는 네트워크의 기저(base)로 수정된 ResNet(Residual Network)구조를 사용할 수 있으며, 과밀이 감지되면 SMS 플랫폼을 통해 최적의 경로를 추천할 수 있다.

과제의 해결 수단

[0006] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 의한 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법은, 스마트 시티 내부의 인구과밀을 감지하고 안전을 모니터링하기 위한 것으로, 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하여 높은 고도 또는 지상 근처의 환경조건을 기록하는 단계; 상기 무인 항공기의 비디오 프레임 데이터를 준비하고, 특징을 추출하는 단계; 상기 특징을 추출하는 단계에서 추출한 특징 중에서 최적의 특징을 선택하는 단계; 상기 선택된 최적의 특징에 기반하여 과밀 기록을 분석하고, 분석 결과를 토대로 혼잡 여부를 판단하는 단계; 및 상기 판단 단계에서 과밀이 감지되면 SMS 플랫폼을 통해 경로를 추천하는 단계;를 포함할 수 있다.

[0007] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 특징을 추출하는 단계에서는, 전이학습(transfer learning)을 수행하는 네트워크의 기저(base)로 수정된 ResNet(Residual Network)구조를 사용할 수 있다.

[0008] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 특징을 선택하는 단계는 자연의 물 순환에서 영감을 받아 데이터의 특징들을 각각 물 분자로 생각하는 물 순환 알고리즘(Water Cycle Algorithm, WCA)을 사용하는 것을 포함할 수 있다.

[0009] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 물 순환 알고리즘은 증발 절차, 압축 및 침전 절차, 물의 로컬화, 지표수 흐름의 생성, 바다로 들어가는 강물의 형성 과정을 모티브로 할 수 있다.

[0010] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 물 순환 알고리즘은 상기 특징을 추출하는 단계에서 추출된 특징들로 구성된 입력 값을 넣으면 최적의 특징 값이 선택될 수 있다.

[0011] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 물 순환 알고리즘은 미리 정한 종료 조건을 충족하지 못한 때는 (A)단계, (B)단계, (C)단계를 반복하고, 상기 (A)단계는 특징을 선택하는 과정에서 비용함수의 매개변수들과 상기 물 순환 알고리즘의 변수들(N_{sr} , d_{max} , N_{pop} , MAX_{iter})을 초기화하는 단계; 상기 (B)단계는 모든 특징을 사용하여 모델을 학습하고, 각 특징의 중요도를 계산한 이후에 각 특징이 제거될 때 모델의 정확도가 얼마나 감소하는지 측정하는 단계; 및 상기 (C)단계는 가장 중요도가 낮은 특징을 제거하는 단계;를 포함하고, 상기 물 순환 알고리즘의 변수들 중 N_{sr} 은 강(river)의 개수와 하나의 바다(sea)를 합산한 값, d_{max} 는 강과 바다 사이 거리 최대값, N_{pop} 은 빗방울의 수(initial features), MAX_{iter} 는 반복의 최대 값을 의미할 수 있다.

[0012] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 방법 중 상기 특징을 추

출하는 단계에서 딥 러닝은 비지도, 준지도 및 지도 학습 방법을 결합한, 수정된 심층 전이 학습을 사용할 수 있다.

[0013] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 장치는 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하여 높은 고도 또는 지상 근처의 환경조건을 기록하는 데이터 수집부; 상기 무인 항공기의 비디오 프레임 데이터를 준비하고 특징을 추출하는 특징 추출부; 상기 특징 추출부에서 추출한 특징 중에서 최적의 특징을 선택하는 특징 선택부; 상기 선택된 최적의 특징에 기반하여 과밀 기록을 분석하고, 분석 결과를 토대로 혼잡 여부를 판단하여 과밀이 감지되면 SMS 플랫폼을 통해 최적의 경로를 추천하는 SMS 발송부;를 포함할 수 있다.

[0014] 본 발명의 일 실시예에 딥러닝 기반의 COVID-19 감염도시의 과밀화 시각화 스마트 센싱 장치 중 특징 추출부에서는, 전이학습(transfer learning)을 수행하는 네트워크의 기저(base)로 수정된 ResNet 구조를 사용할 수 있다.

발명의 효과

[0015] 공공 장소 및 사회에서의 인구 과밀은 감염병 확산 등 사회적 우려가 있음에도 불구하고 이벤트에 대한 예측가능성이 낮기 때문에 CCTV로 모니터링을 수행하는 것은 한계가 있다. 본 발명에서는 수정된 ResNet을 활용하여 과밀 분석을 자동화하고, UAV 애플리케이션 및 SMS 플랫폼의 조합으로 혼잡한 상황에서 효과적인 경로를 찾아 인구 과밀을 실시간으로 통제하여 COVID-19 등 도심 내 감염병 증가를 방지하는데 기여한다.

도면의 간단한 설명

[0016] 도 1은 본 발명의 일 실시 예에 따른 과밀화 감지를 위한 스마트 시각적 센싱 기술 장치의 구성을 나타내는 도면이다.

도 2는 본 발명의 일 실시 예에 따라 UAV와 SMS 간의 관계를 나타낸 도면이다.

도 3은 본 발명의 일 실시 예에 따른 과밀화 감지를 위한 스마트 시각적 센싱 기술 방법을 설명하는 순서도이다.

도 4는 과밀화 감지를 위한 스마트 시각적 센싱을 위하여, 특징 추출 단계에서 제안하는 수정된 ResNet 구조를 나타낸 도면이다.

도 5는 과밀화 감지를 위한 스마트 시각적 센싱을 위하여, 두 데이터베이스 UCSD 및 UMN의 샘플 프레임을 나타낸 도면이다.

도 6은 과밀화 감지를 위한 스마트 시각적 센싱을 위하여, UMN 데이터 세트에 대한 과밀 인식을 위한 혼동 행렬을 나타낸 도면이다.

도 7은 과밀화 감지를 위한 스마트 시각적 센싱을 위하여, UCSD 데이터 세트에서 과밀 인식에 대한 혼동 행렬을 나타낸 도면이다.

도 8은 과밀화 감지를 위한 스마트 시각적 센싱을 위하여, ROC 곡선이 두 데이터 세트에 대한 이상 행동 탐지에서 제안된 모델의 높은 AUC 비율을 보여주는 것을 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0017] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람직한 실시예들로부터 더욱 명백해질 것이다. 이때, 각각의 도면에서 동일한 구성요소는 가능한 동일한 부호로 나타낸다. 또한, 이미 공지된 기능 및/또는 구성에 대한 상세한 설명은 생략한다.

[0018] 이하에 개시된 내용은, 다양한 실시 예에 따른 동작을 이해하는데 필요한 부분을 중점적으로 설명하며, 그 설명의 요지를 흐릴 수 있는 요소들에 대한 설명은 생략한다. 또한 도면의 일부 구성요소는 과장되거나 생략되거나 또는 개략적으로 도시될 수 있다. 각 구성요소의 크기는 실제 크기를 전적으로 반영하는 것이 아니며, 따라서 각각의 도면에 그려진 구성요소들의 상대적인 크기나 간격에 의해 여기에 기재되는 내용들이 제한되는 것은 아니다.

[0019] 본 발명의 실시예들을 설명함에 있어서, 본 발명과 관련된 공지기술에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하기로 한다. 그리고, 후술되는 용어들은

본 발명에서의 기능을 고려하여 정의된 용어들로서 이는 사용자, 운용자의 의도 또는 관례 등에 따라 달라질 수 있다. 그러므로 그 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다. 상세한 설명에서 사용되는 용어는 단지 본 발명의 실시 예들을 기술하기 위한 것이며, 결코 제한적이지는 안 된다. 명확하게 달리 사용되지 않는 한, 단수 형태의 표현은 복수 형태의 의미를 포함한다. 본 설명에서, "포함" 또는 "구비"와 같은 표현은 어떤 특성들, 숫자들, 단계들, 동작들, 요소들, 이들의 일부 또는 조합을 가리키기 위한 것이며, 기술된 것 이외에 하나 또는 그 이상의 다른 특성, 숫자, 단계, 동작, 요소, 이들의 일부 또는 조합의 존재 또는 가능성을 배제하도록 해석되어서는 안 된다.

- [0020] 또한, 제1, 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되는 것은 아니며, 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다.
- [0021] 이하에서는, 첨부된 도면들을 참조하여 본 발명의 바람직한 실시형태를 상세히 설명하기로 한다.
- [0022] 본 발명의 과밀화 감지를 위한 스마트 시각적 센싱의 흐름도는 도 3에 나와 있다.
- [0023] 본 발명의 과밀화 감지를 위한 스마트 시각적 센싱 방법에는 다음과 같은 주요 단계가 있다. 데이터 수집 단계(단계 S310); 비디오 프레임들 준비하는 단계(단계 S312); 특징을 추출 단계(단계 S320); 특징 선택 단계(단계 S322); 혼잡 여부 판단 단계(단계 S330) 및 과밀 감지 SMS 발송 단계(단계 S340)를 포함하는 것을 특징으로 한다.
- [0024] 도 1은 본 발명의 일 실시 예에 따른 과밀화 감지를 위한 스마트 시각적 센싱 장치의 구성을 나타내는 도면이다.
- [0025] 도 1을 참조하면, 본 발명의 일 실시 예에 따른 과밀화 감지 장치(100)는 데이터 수집부(110), 특징 추출부(120), 특징 선택부(130) 및 SMS 발송부(140)를 포함할 수 있다. 도 1에 도시된 구성요소들은 과밀화 감지 장치를 구현하는데 있어서 필수적인 것은 아니어서, 본 명세서 상에서 설명되는 과밀화 감지 장치는 위에서 열거된 구성요소들 보다 많거나 또는 적은 구성요소들을 가질 수 있다.
- [0026] 도 3을 참조하면, 단계 S310에서, 데이터 수집부(110)는 무인 항공기가 높은 고도 또는 지상 근처의 환경조건을 기록하기 위한 학습 데이터를 수집할 수 있다.
- [0027] 단계 S312에서, 상기 무인 항공기의 비디오 프레임 데이터를 준비할 수 있다.
- [0028] 단계 S320에서, 특징 추출부(120)에서 상기 비디오에서 사람들의 밀도를 조사하기 위한 특징을 추출할 수 있다.
- [0029] 단계 S322에서, 특징 선택부(130)에서 추출한 특징 중에서 최적의 특징을 선택할 수 있다.
- [0030] 단계 S330에서, 무인항공기의 과밀 기록을 분석하고, 분석 결과를 토대로 혼잡 여부를 판단할 수 있다.
- [0031] 단계 S340에서, SMS 발송부(140)는 혼잡한 상황에서 효과적인 경로를 찾아 인구 과밀을 실시간으로 통제하여 COVID-19 등 도심 내 감염병 증가를 방지할 수 있다.
- [0032] 도 3을 참조하면, 데이터 수집 단계(S310)에서, 데이터 수집부(110)는 무인 항공기(Unmanned Aerial Vehicles, UAV)를 이용하고, 높은 고도 또는 지상 근처의 환경조건을 기록하기 위한 학습 데이터를 수집할 수 있다. 여기서, 학습 데이터는 인구 밀집 지역의 이미지를 포함할 수 있다.
- [0033] 도 2의 왼쪽 부분에서는 무인항공기 UAV가 과밀 기록을 감지하고 있는 과정을 보여준다.
- [0034] UAV 카메라에 충전기, 배터리, 컨트롤러 및 지상 모니터링 시스템은 안정화와 함께 포함되어 있다. UAV의 하나로써 Octocopter에는 GPS 및 고도 컨트롤러가 장착되어 있다. 200m 반경 내에서 그 범위는 300m일 수 있다. UAV 밑면에 있는 고화질 카메라는 점진적인 프레임으로 비디오를 캡처할 수 있다. 또한 Sprint Mobile 네트워크와 UAV 지상국의 광대역 네트워크를 사용하여 캡처한 비디오를 클라우드 플랫폼에 SMS로 업로드할 수 있다. 통신 채널 및 프로토콜을 사용하여 사용자 또는 데이터 처리 센터는 정보를 수신할 수 있다. 적절한 데이터 전송 프로토콜은 데이터 낭비를 최소화하면서 실시간 데이터 전송을 향상시킬 수 있다.
- [0036] 도 3을 참조하면, 특징 추출단계(S320)에서, 특징 추출부(120)는 무인 항공기 UAV의 비디오 프레임 데이터를 준비하는 단계(S312)를 거쳐 이미지의 주요 특징을 추출할 수 있다.

[0037] 도 4는 특징 추출 단계(S320)에서 전이학습(transfer learning)을 수행하기 위한 네트워크의 기저(base)로 사용되는 수정된 ResNet(Residual Network)구조를 나타낸다.

[0038] 추출된 특징을 기반으로, 수정된 ResNet 아키텍처를 사용하여 과밀 장면 프레임들을 평가할 수 있다. 수정된 ResNet 모델은 의사 결정 구조의 견고성을 크게 향상시킨다.

[0039] 수정된 ResNet 아키텍처는 e2e(end-to-end) 모델보다 레이어 수가 적기 때문에 정확한 탐지를 유지하면서 더 빠른 탐지 프로세스를 제공할 수 있다.

[0040] ResNet은 과밀 장면에서 특징을 추출하는데 도움이 될 수 있다. 두개의 추가적인 레이어를 덧붙임으로써, 향상된 표면 특성을 얻을 수 있다. 컨볼루션 결과는 다음과 같은 방정식일 수 있다.

수학식 1

$$x_j^\ell = f \left(\sum_{i \in M_j} x_j^{\ell-1} * k_{ij}^\ell + b_j^\ell \right)$$

[0041]

[0042] ℓ 은 ℓ 레이어를 나타내고, k_{ij}^ℓ 은 컨볼루션 커널을 의미한다.

[0043] b_j 는 바이어스를 나타내고, M_j 은 입력 매핑의 모음을 의미한다.

[0044] 또한 sigmoidal 함수는 (x, y) 위치에서의 j th 특징의 매핑에서 예시되며, i_{th}, v_{ij}^{xy} 의 계층은 다음과 같이 설명된다.

수학식 2

$$v_{ij}^{xy} = \text{sig} \left(b_{ij} + \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} w_{ij}^{xy} v_{(i-1)}^{(x+p)(y+q)} \right)$$

[0045]

[0047] 추가적으로 Q_j 와 P_i 는 kernel의 너비와 높이를 나타내고, w_{ij}^{pq} 는 kernel의 가중치를 의미한다.

[0048] 바이어스 매핑 함수는 상대적으로 각 b_{ij} 와 $\text{sig}(\cdot)$ 이다.

[0049] 스토캐스틱 인테그레이션 레이어를 사용할 수 있다. 추가적으로, 위 레이어는 과적합을 방지하는 장점이 있다. CNN 모델에서 바이어스와 가중치를 결정할 때는 DTL 아키텍처는 다음 방정식을 고려하여 업데이트를 할 수 있다.

수학식 3

$$\Delta W_l(t+1) = -\frac{x\lambda}{r}W_l - \frac{x}{n}\frac{\partial C}{\partial W_l} + m\Delta W_l(t)$$

$$\Delta B_l(t+1) = -\frac{x}{n}\frac{\partial C}{\partial B_l} + m\Delta B_l(t).$$

[0050]

[0051]

비용 함수, 업데이트 단계, 모멘텀, 총 훈련 샘플 수, 학습 속도, 정규화 매개변수, 레이어 번호, 바이어스 및 가중치는 각각 C, t, m, n, x, l, B 및 W로 표시된다. 랜덤 풀링은 과적합 문제를 방지하는 데 도움이 되며 과밀이 있는 입력 프레임에서 픽셀 패색 감지를 개선한다.

[0052]

따라서 p 확률은 각 j 영역에 대해 다음 방정식에 따라 평가된다.

수학식 4

$$p_i = \alpha_i \left(\sum_{k \in R_j} \alpha_k \right)^{-1}$$

[0053]

[0054]

여기서 R_j^i 는 속성 C의 매핑에서 끌어당기는 영역 j이고, i는 그 안에 있는 각 요소의 인덱스이다.

수학식 5

$$\alpha_{p,q}^{l,k} = \text{Random} \left(\alpha_{m,n}^{l-1,k} u(i,j) \right)_{(m,n,i,j) \in p}$$

[0055]

[0056]

Random(.) 함수는 u(i, j)를 가중치 창 함수로 사용하여 k번째 특징 매핑 및 ℓ 번째 레이어의 공간 좌표 p 및 q에서 각 뉴런의 활성화를 계산하는 데 사용된다.

[0057]

여기서 $\alpha_{p,q}^{l,k}$ 는 컨볼루션 신경망의 수렴을 가속화하는 활성화 함수의 출력이다.

[0058]

제안된 ResNet은 이 경우 3×3 VGG 아키텍처를 기반으로 한다. 잔차 블록은 출력 채널 수가 같은 두 개의 3×3 컨볼루션 레이어로 구성될 수 있다.

[0059]

각 컨볼루션 레이어 후에 정규화된 배치 레이어와 ReLU 활성화 함수가 적용될 수 있다. 입력을 추가한 후 ReLU의 최종 활성화 전에 두 번째 컨볼루션 계산이 수행된다. 결과적으로 더 많은 수의 채널이 필요할 수 있다. 입력을 변경하고 추가를 수행하려면 $a1 \times 1$ 컨볼루션 레이어가 필요하다. 또한 ResNet의 처음 두 계층은 GoogleNet을 기반으로 한다. 64개의 출력 채널과 스트라이드가 2인 7×7 컨볼루션 레이어 다음에는 스트라이드가 2인 최대 3×3 수집 레이어가 필요하다. 컨볼루션 레이어의 출력은 완전히 연결된 계층을 만든다.

[0061]

특징 선택 단계(S322)는 자연의 물 순환에서 영감을 받은 물 순환 알고리즘(WCA)을 사용할 수 있다.

[0062]

이 알고리즘에는 다음과 같은 다섯 가지 주요 부분이 있다. 1) 증발 공정; 2) 압축 및 침전 공정; 3) 물의 국지

화; 4) 지표수 흐름의 생성; 5) 바다로 들어가는 강물의 형성하는 과정을 포함할 수 있다.

구덩이와 표면 수증기는 최고 품질의 글로벌 기능을 찾는 가장 효과적인 접근 방식으로 간주된다. 각 구덩이의 용량은 다양하다. 용량은 깊이에 따라 결정된다. 기본적으로 모든 피트의 용량은 최적화를 위한 각 루프 반복에서 다음과 같이 설명된다.

수학식 6

$$C_i = (|f_i - f_{\text{Min}}|) \times \text{Const} \times (|f_{\text{Min}} - f_{\text{Max}}|)^{-1}$$

이 방정식에서 f_i 의 값은 i 번째 피트의 값과 같고 Const는 상수 값으로 간주된다. 또한 f_{min} 과 f_{max} 는 각각 피트에 대해 생성된 최소값과 최대값으로 가정한다. Const의 값도 피트의 최대 용량을 기준으로 목적 함수에 따라 표시된다. 또한 C_i 는 작은 구덩이에서 떨어지는 빗방울의 수로 큰 구덩이로 들어가는 구덩이의 용량으로, 이 경우 한 피트의 빗방울이 용량을 초과하면 한 피트의 용량이 다른 피트로 이전된다. 구덩이 i 는 용량이 더 큰 기존 구덩이 중에서 무작위로 선택된다. 우선 순위는 구덩이의 용량이 클수록 선택 가능성이 높아진다. 문제에 대한 답의 검색 공간이 벡터 D 인 경우, 물방울 모집단 중에서 각 물방울 i 의 속도와 위치를 표현한다.

$$X_i = (X_{i1}, X_{i2}, \dots, X_{iD}), V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$$

Algorithm 1: Feature Selection Using the WCA Algorithm.

Input: consists of the extracted features from the modified ResNet structure

Output: the best selected features (f_s)

```

1  While stopping criterion not met, Do
2      Initialize the parameters of  $cost_{\text{function}}$  in feature selection
3      Initialize the parameters of WCA ( $N_{sr}, d_{\text{max}}, N_{\text{pop}}, \text{MaxIter}$ )
4      For each raindrop of optimization model Do
5          Select the random subset of features
6          Sort the features based on min-to-max order
7          Evaluate the cost function by seeking the  $G_{\text{opt}}(f_k)$ 
8          If the  $new_{\text{value}}$  is better than  $old_{\text{values}}$ , Then
9              Replace positions of river with a stream
10             Replace position of river with the sea
11             If the evaporation happen, Then
12                 The raining is happening
13                 Increase  $d_{\text{max}}$  and discover filled pits
14             End if
15         End if
16     End for
17     Find  $G_{\text{opt}}$  (Global answer) or best subset ( $f_s$ )
18     For each raindrop of WCA, Do
19         Update the  $V_i$  and  $X_i$ 
20     End For
21 End While

```

여기서 V_i 와 X_i 는 각 물방울의 현재 속도와 위치를 나타낸다. 또한 X_{select} 는 현재 물이 흐르는 구덩이보다 용량이 더 큰 구덩이의 현재 위치를 보여준다.

수학식 7

$$V_i(t+1) = V_i(t) + \text{Rand}(X_{\text{select}}(t) - X_i(t))$$

$$X_i(t+1) = X_i(t) + V_i(t+1).$$

[0069]

[0070] WCA를 사용하여 ResNet 모델에서 추출한 특징 벡터에서 특징을 선택할 수 있다.

[0071] WCA 알고리즘에서 바다의 수는 강과 바다의 위치 차이에 의해 결정되며 빗방울의 반복과 초기 빗방울 개체수는 상대적으로 각 5개, 10개, 100개로 가정할 수 있다. 데이터 세트는 시작점을 제공하고 세 가지 다른 위치에서 11개의 비디오 프레임을 포함할 수 있다.

[0072] 다음 순서는 알고리즘1을 따른 것으로 가장 적합한 특징을 선택하기 위함이다.

[0073] 혼잡 여부를 판단하는 단계(S330)에서는 서포트 벡터 머신을 사용할 수 있다.

[0074] 하나의 학습 데이터 세트가 제공되고 각 입력에 D 속성이 포함되어 있는 경우(즉, D 차원 공간에 따라 다름) 각 포인트에 Y 일치 값이 있다고 가정하면 입력과 출력을 연결하는 함수는 다음과 같이 찾을 수 있다.

수학식 8

$$f(x, w) = b + w^T x$$

[0075]

[0076] 함수 f는 다음 방정식에서 w와 b의 값이 사용자가 값을 변경할 수 있는 상수 매개변수인 C에 대해 f를 최소화하도록 요구한다. 이 매개변수를 사용하여 ϵ 의 부재로 인한 페널티 가중치의 변화와 균형을 달성하는 동시에 식별 마진을 증가시키려고 한다. 따라서 함수 L_ϵ 은 다음 방정식에 따라 도입된다.

수학식 9

$$R(C) = \frac{C}{l} \sum_{i=1}^l L_\epsilon(y_i, f_i(x, w)) + 0.5 \|w\|^2$$

[0077]

$$|y - f(x, w)|_\epsilon = \begin{cases} 0 & |y - f(x, w)| \leq \epsilon \\ |y - f(x, w)| - \epsilon & \text{otherwise} \end{cases}$$

[0078]

[0079] 따라서 다음 방정식의 최대 값이 필요하다.

수학식 10

$$L_P(a_i, a_i^*) = -\frac{1}{2} \sum_{j=1}^l (a_i - a_i^*)(a_j - a_j^*) x_i^T x_j$$

$$- \epsilon \sum_{i=1}^l (a_i + a_i^*) + \sum_{i=1}^l (a_i - a_i^*) y_i.$$

[0080]

[0081] SVM 함수(f)는 커널 함수를 사용하여 앞서 언급한 방정식을 풀어서 형성할 수 있다.

[0082] 표 1은 과밀 인식에서 제안된 구조의 특이성, 정확성 및 민감도를 나타낸다.

표 1

The Video Frames (Density)	Specificity	Accuracy	Sensitivity
UMN (Low)	0.9981	0.9964	0.9911
UMN (High)	0.9878	0.9908	0.9917
UCSD -ped1 (Low)	0.9913	0.9875	0.9843
UCSD -ped2 (Low)	0.8591	0.8561	0.8436
UCSD -ped1 (High)	0.9821	0.9840	0.9872
UCSD -ped2 (High)	0.8444	0.8431	0.8408

[0083]

[0084] 표 1은 각 프레임에 대한 탐지 모델의 정확도, 민감도 및 특이도뿐만 아니라 거짓 양성 및 거짓 음성 값을 나타낼 수 있다.

[0085] 도 5는 제안된 방법을 두 데이터베이스의 비디오 프레임 집합에 적용하여 과밀을 탐지한 결과를 보여준다. 두 데이터 세트 모두 일반 프레임과 과밀을 나타내는 프레임을 포함한다.

[0086] 도 5는 두 데이터베이스 UCSD 및 UMN의 샘플 프레임을 나타낸다. 제안된 모델은 빨간색과 녹색으로 많은 프레임에서 과밀의 존재를 감지할 수 있다. 녹색 상자는 과밀하지 않음을 의미하고, 빨간색 상자는 프레임셋의 인구 과밀을 보여준다.

[0087] 도 5에서 알고리즘에 의한 과밀의 징후를 보여주는 프레임 위에 빨간색 상자가 그려져 있다. 프레임은 과밀하지 않은 녹색 상자에 나타난다.

[0088] 도 6은 UMN 데이터 세트에 대한 과밀 인식을 위한 혼동 행렬을 나타낸다. 평균 정확도는 97.91%이고 다양성은 $\pm 2.74\%$ 이다.

[0089] 도 7은 UCSD 데이터 세트에서 과밀 인식에 대한 혼동 행렬을 나타낸다. 평균 정확도는 85.70%이고 다양성은 $\pm 3.11\%$ 이다.

[0090] 도 6 및 도 7에서는 응답의 다양성 정도를 설명하기 위해 UMN 및 UCSD 데이터 세트에서의 테스트 데이터 무작위 10개 폴드를 제시한다.

[0091] 각 폴드의 평균값들은 혼동 행렬로 표시된다.

[0092] 도 6 및 도 7은 정상(Nor) 및 과밀(OvCro) 클래스를 사용하여 과밀을 감지하는 제안된 모델의 기능을 보여준다.

[0093] 혼동 행렬 대표값은 각 폴드의 평균 값을 표시하는 데 사용된다.

[0094] 도 8은 ROC 곡선은 두 데이터 세트에 대한 이상 행동 탐지에서 제안된 모델의 높은 AUC 비율을 나타낸다.

[0095] 도 8에서는 수정된 ResNet 구조를 기반으로, 다양한 군중 장면 설정에 대한 ROC(Receiver Operating Characteristic) 곡선의 곡선 아래 영역(AUC)이 상당히 개선된 것을 확인할 수 있다.

[0096] 과밀화로 인해 많은 수의 비디오 프레임을 기반으로 하는 ROC에 따르면 VGG19, DensNet 및 ResNet을 포함한 다른 특징 추출 방법과 성능을 비교할 수 있다. 수정된 ResNet 구조를 사용할 때 모든 경우에 만족스러운 AUC를 생성할 수 있다.

[0098] 표 2에서는 수정된 ResNet 방법을 VGG, DenseNet 및 일반 ResNet과 같은 유사한 방법과 비교한 것으로 제안 모델의 속도 속성을 나타낸다.

표 2

Method	Overcrowding with low density (UMN)			Overcrowding with high density (UMN)			Overcrowding with low density (UCSD)			Overcrowding with high density (UCSD)		
	APT (ms)	Acc (%)	AUC (%)	APT (ms)	Acc (%)	AUC (%)	APT (ms)	Acc (%)	AUC (%)	APT (ms)	Acc (%)	AUC (%)
VGG (e2e)	126.1	96.87	95.11	217.5	95.28	94.71	192.4	89.73	88.20	302.8	88.08	87.66
DenseNet (e2e)	301.2	97.37	96.76	389.7	96.49	95.83	298.1	90.83	88.45	450.3	89.25	87.71
ResNet (e2e)	210.4	97.51	96.31	309.2	96.34	95.15	221.8	90.54	89.84	387.9	88.14	86.02
Modified ResNet (e2e)	165.1	98.86	98.03	234.5	97.84	97.44	178.3	92.43	91.72	277.8	90.18	89.9
VGG (ME)	102.7	97.44	96.22	108.1	96.31	95.20	167.1	90.39	89.44	241.3	88.89	86.11
DenseNet (ME)	198.7	97.98	96.11	283.9	97.76	96.49	244.7	91.18	90.09	376.5	88.61	87.12
ResNet (ME)	145.1	98.83	97.28	223.1	97.33	96.12	178.1	92.73	92.38	267.9	89.17	87.56
Modified ResNet (ME)	117.3	99.63	98.64	198.9	98.24	98.13	143.9	94.66	93.1	216.4	93.31	92.5

[0099]

[0100]

정확도(ACC) 및 곡선 아래 면적(AUC)이 추정될 수 있다. 실험 프레임워크를 실시간 알고리즘으로 적용하여 각 프레임의 평균 처리 시간(밀리초)을 계산할 수 있다. 유사한 특징을 식별하고 분류하기 위해 제안하는 방법을 다른 방법과 비교할 수 있다. 인구 밀도가 높거나 낮은 프레임을 포함하여 다양한 비디오 프레임이 고려된다.

[0101]

실시간 방법을 검증하기 위해 훈련된 네트워크에 프레임 세트를 적용하여 응답 시간을 추정할 수 있다. 밀리초 단위의 시간 표준은 APT이다. 실시간 응답의 가장 일반적인 측정 단위는 밀리초(ms)와 마이크로초(μs)이다.

[0102]

네트워크 컴퓨팅은 실시간 처리 문제를 크게 줄일 수 있다. 실시간 시스템은 SMS로 정보를 보낼 때 데이터 전달에 중요한 문제이다.

[0103]

표 2는 서로 다른 과밀 조건에서 APT, 정확도(ACC) 및 AUC라는 용어를 표시한다. 다양한 조건에서 우리 알고리즘은 과밀을 결정하는 데 평균 170ms이다. 샘플 데이터 세트는 각각 117ms 및 143ms의 실시간 응답을 경험한다.

[0104]

프레임을 변경하면 APT 값이 거의 동일하다. 인구 밀도의 이러한 변화로 인해 제안된 방법을 추적하는 데 시간이 더 오래 걸릴 수 있다.

[0105]

e2e 구조와 모델 엔지니어링 간의 비교, 즉 딥 러닝 구조, 기능 선택 및 분류에 의한 기능 추출은 기능 선택이 처리 시간과 계산 복잡성을 줄일 수 있음을 보여준다.

[0107]

표 3은 정확성(ACC)과 복잡도(CC)를 비디오 이미지의 과밀 측정을 위한 기반으로 사용하여 제안된 방법에서 얻은 결과를 유사한 접근 방식의 결과와 비교한 것을 나타낸다.

표 3

Author	Model	Acc	CC
Singh <i>et al.</i> [10]	Aggregation of ensembles	95.25%	High
Chu <i>et al.</i> [23]	SCG-SF	90.9%	Middle
Li <i>et al.</i> [24]	ST-CaAE	95.5%	Middle
Zhou <i>et al.</i> [25]	AnomalyNet	94.4%	High
Our proposed model	mResNet (ME)	96.55%	Middle

[0108]

[0109]

지금까지 UAV와 SMS 플랫폼의 조합을 통해 과밀을 감지할 수 있는 방법은 제안되지 않았다. 표 3에서는 제안한 방법과 비교하여 얼마나 잘 수행되는지 확인할 수 있다.

[0110]

일부 방법은 과도한 빛, 대기 오염 및 강우로 인해 인구 이동 또는 환경 변화를 감지하는 데 제대로 작동하지 않음을 나타낸다.

[0112]

UAV 및 SMS는 COVID-19의 급속한 확산을 방지하기 위해 이벤트 모니터링 및 인구 분산과 같은 다양한 애플리케이션에 점점 더 많이 배치되고 있다.

[0113]

본 발명은 깊이 수정된 ResNet 구조를 사용하여 추론된 패턴을 학습하여 성능을 개선하는 SMS를 유지하기 위해 UAV가 사용되었다. 이들은 과밀 분석을 자동화하는 데 사용된다. 자동화된 모델을 기반으로 다양한 장소의 과밀

화를 최소화하도록 설계되어 소셜 컴퓨팅을 통해 이상 발생에 효과적으로 대응하는 기술을 개발했다. 혼잡한 상황에서 효과적인 경로를 찾기 위해 빠른 알고리즘을 기반으로 한 UAV와 SMS를 사용하여 인구 행동에서 수집된 정보를 처리할 수 있다.

[0114] 제안된 개선된 ResNet 모델은 의사 결정 프레임워크의 견고성을 크게 향상시킨다. 제안된 접근 방식은 과밀을 처리할 수 있을 만큼 견고하여 SMS가 최적의 경로를 추천하고 COVID-19의 증가를 방지할 수 있다.


[0115] 제안된 모델을 스마트 시티에 배치하고 구현함으로써 여러 사회 시스템 목적을 충족할 수 있다.

부호의 설명


[0118] 100: 과밀화 감지 장치 110: 데이터 수집부
120: 특징 추출부 130: 특징 선택부
140: SMS 발송부

도면


도면1




도면2



도면3



도면4



도면5



도면6

UMN dataset (fold 1)		UMN dataset (fold 2)		UMN dataset (fold 3)		UMN dataset (fold 4)		UMN dataset (fold 5)			
Nor	99.89% (1994)	0.11% (2)	Nor	99.64% (1990)	0.35% (7)	Nor	99.44% (1986)	0.55% (11)	Nor	99.63% (1990)	0.36% (7)
OvCro	5.76% (90)	94.24% (1471)	OvCro	3.84% (60)	96.15% (1501)	OvCro	5.00% (78)	95.00% (1483)	OvCro	3.26% (51)	96.73% (1510)
Nor		OvCro	Nor		OvCro	Nor		OvCro	Nor		OvCro
UMN dataset (fold 6)		UMN dataset (fold 7)		UMN dataset (fold 8)		UMN dataset (fold 9)		UMN dataset (fold 10)			
Nor	99.18% (1981)	0.81% (16)	Nor	99.24% (1982)	0.75% (15)	Nor	98.94% (1976)	1.05% (21)	Nor	98.74% (1972)	1.25% (15)
OvCro	5.95% (93)	94.04% (1468)	OvCro	6.34% (99)	93.65% (1462)	OvCro	5.38% (84)	94.61% (1477)	OvCro	5.12% (80)	94.87% (1481)
Nor		OvCro	Nor		OvCro	Nor		OvCro	Nor		OvCro

도면7

UCSD dataset (fold 1)		UCSD dataset (fold 2)		UCSD dataset (fold 3)		UCSD dataset (fold 4)		UCSD dataset (fold 5)	
Nor	84.05% (1681)	Nor	84.45% (1689)	Nor	85.60% (1712)	Nor	85.05% (1701)	Nor	84.50% (1690)
OvCro	15.95% (319)	OvCro	15.55% (311)	OvCro	14.40% (288)	OvCro	14.95% (299)	OvCro	15.50% (310)
Nor	21.45% (429)	Nor	20.40% (408)	Nor	19.35% (387)	Nor	19.15% (383)	Nor	18.70% (374)
OvCro	78.55% (1571)	OvCro	79.60% (1592)	OvCro	80.65% (1613)	OvCro	80.85% (1617)	OvCro	81.30% (1626)
UCSD dataset (fold 6)		UCSD dataset (fold 7)		UCSD dataset (fold 8)		UCSD dataset (fold 9)		UCSD dataset (fold 10)	
Nor	83.80% (1676)	Nor	84.20% (1684)	Nor	85.15% (1703)	Nor	84.60% (1692)	Nor	84.40% (1688)
OvCro	16.20% (324)	OvCro	15.80% (316)	OvCro	14.85% (297)	OvCro	15.40% (308)	OvCro	15.61% (312)
Nor	19.85% (397)	Nor	19.60% (392)	Nor	20.45% (409)	Nor	19.40% (388)	Nor	19.60% (392)
OvCro	80.15% (1603)	OvCro	80.40% (1608)	OvCro	79.55% (1591)	OvCro	80.60% (1612)	OvCro	80.40% (1608)

도면8

