



딥 러닝과 데이터 결합에 의한 싱크홀 트래킹

노승환*¹, 남 부 호아이** , 최복길***, 뉴엔 만 등*²

Sinkhole Tracking by Deep Learning and Data Association

Soonghwan Ro*¹, Nam Vu Hoai** , Bokgil Choi***, and Nguyen Manh Dung*²

이 논문은 2018년 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입 (2018R1D1A1B07049146), 본 논문에서 학습과 테스트에 사용된 싱크홀 비디오는 계명대학교 고병철교수에게서 지원 받았음.

요 약

최근 자주 발생하는 싱크 홀(sinkhole)을 정확하게 발견하고 추적하는 것은 사람 및 재산 피해를 예방하기 위해서 매우 중요하다. 그 동안 싱크 홀을 검출하기 위한 방안들이 많이 제안되었지만 지하 깊은 곳에서 발생하는 싱크 홀에 대한 검출은 완전히 해결되지 않고 있다. 또한 실시간으로 싱크 홀을 감지하고 실시간으로 경고를 발생하는 시스템은 아직 안정화되지 않은 상태이다. 본 연구는 딥 러닝과 데이터 결합에 의해 싱크 홀을 실시간으로 검출하기 위한 연구이며, 제안하는 알고리즘은 크게 바이너리 분할(binary segmentation), 싱크 홀 분류(sinkhole classification) 및 싱크 홀 추적(sinkhole tracking)의 세 가지 주요 부분으로 구성된다. 실험 결과 싱크 홀이 실시간으로 데이터 세트에서 추적 될 수 있음을 보여주었다. 따라서 본 연구에서 제안된 시스템은 싱크 홀을 탐지하기 위해서 실제로 적용될 수 있음을 보여준다.

Abstract

Accurate tracking of the sinkholes that are appearing frequently now is an important method of protecting human and property damage. Although many sinkhole detection systems have been proposed, it is still far from completely solved especially in-depth area. Furthermore, detection of sinkhole algorithms experienced the problem of unstable result that makes the system difficult to fire a warning in real-time. In this paper, we proposed a method of sinkhole tracking by deep learning and data association, that takes advantage of the recent development of CNN transfer learning. Our system consists of three main parts which are binary segmentation, sinkhole classification, and sinkhole tracking. The experiment results show that the sinkhole can be tracked in real-time on the dataset. These achievements have proven that the proposed system is able to apply to the practical application.

Keywords

sinkhole tracking, CNN transfer learning, data association, Hungarian Algorithm, Otsu algorithm

* 공주대학교 정보통신공학부
- ORCID¹: <http://orcid.org/0000-0001-6091-796X>
- ORCID²: <http://orcid.org/0000-0001-6165-4137>

** Department of Computer Science, Faculty of Information Technology, PTIT
- ORCID: <http://orcid.org/0000-0001-5290-2258>

*** 공주대학교 전기공학부
- ORCID: <http://orcid.org/0000-0003-1750-1568>

• Received: Apr. 02, 2019, Revised: May 20, 2019, Accepted: May 23, 2019
• Corresponding Author: Ro Soong Hwan
Dept. of Radio Science Engineering, Kongju University, 1223-24 Cheonandae-ro, Chungnam, 31080, Republic of Korea.
Tel.: +82-41-521-9197, Email: rosh@kongju.ac.kr

1. 서 론

싱크 홀은 지표면의 일부가 붕괴된 형태로 지반이 함몰되거나 구멍이 만들어진 것이다. 자연적으로 발생하는 싱크 홀 대부분은 카르스트 프로세스에 의해 발생한다[1]. 그러나 최근 지하 탐사 기술이 발달하면서 다양한 원인에 의해서 싱크 홀이 발생하는 것이 발견되고 있으며, 그 가운데 네 가지 주요 발생 원인은 용해(Dissolution), 표면 침하(Cover-subsidence), 표면붕괴(Cover-collapse) 및 인공적인 원인에 의한 것으로 알려져 있다. 이러한 원인 중 도시 지역의 건설 활동이 많아짐에 따라 사람에 의해 유발된 싱크 홀이 급속히 증가하고 있다. 이와 같이 사람에 의해 발생하는 싱크 홀은 인명 피해뿐만 아니라 심각한 경제적 손실을 주기 때문에 이러한 손실을 막기 위해서 사전에 탐지되어야 하는 많은 재난중의 하나이다. 경우에 따라 싱크 홀은 폐기물을 처리 할 장소로 사용되기도 하였으며, 그 결과 지하수가 오염되어 심각한 문제를 발생시켰다. 따라서 싱크 홀을 조기에 발견하는 것은 삶의 질을 향상시키기 위해서 정부와 사회단체가 해야 하는 매우 심각한 문제이며, 특히 거주 지역에서 발생하는 싱크 홀을 조기에 발견하는 것은 매우 중요하다.

이와 같이 싱크 홀은 인간의 삶의 질, 그리고 경제에 크게 영향을 미치지 않지만 싱크 홀 추적하고 관리하는 방법에 대한 연구는 크게 진행되지 않았다. 싱크 홀을 식별하는 가장 일반적인 방법은 싱크 홀이 나타나는 영역에서 드릴을 사용하여 탐사하는 것이다. 그러나 이와 같은 방법은 매우 비효율적이며, 시설을 파괴하고 싱크 홀을 악화시킬 위험이 있다 [2]. 싱크 홀을 확인하는 또 다른 방법은 콘 침투 탐사 검사(CPT, Cone Penetrometer Test)를 사용하는 것이다. CPT는 토양의 지질 공학적 성질을 규명하고 지질층을 표현하기 위해 활용되며, 이 CPT 방법에 의해서 전반적으로 싱크 홀일 확률이 결정된다. CPT는 비교적 신속하고 간단하게 싱크 홀을 탐지할 수 있으나 접촉식 검사방법으로 인해 싱크 홀을 악화시킬 수 있다.

현재 GPR(Ground Penetrating Radar)은 싱크 홀을 탐지할 때 가장 일반적으로 사용되는 방법이다. GPR은 지상에서 지하로 레이더 신호를 보내고 수

신 신호를 분석한다. 그러나 이 방법의 단점은 지하층에 존재하는 매우 다른 조건에 의해 신호가 분산될 수 있다는 것이다. GPR 방법과 유사하게 지진파를 이용하여 특정 지역에 싱크 홀이 나타날 확률을 분석하는데 사용될 수 있다[3]. 이 외에도 특정지역에 싱크 홀이 명백하게 없다는 것을 확인하기 위해서 ERT(Electrical Resistivity Tomography)와 DPSH(Dynamic Penetration Super Highway) 등의 방법이 사용된다[3].

대형 싱크 홀을 감시하고 추정하기 위해서는 지상 기반 간섭계 합성 개구 레이더(Ground-based Interferometric Synthetic Aperture Radar)가 활용된다. 일반적으로 이런 종류의 시스템은 넓은 지역을 관찰하기 위해 높은 위치에 설치된다. 그러나 이 방법의 한계는 설치 위치가 감시 결과에 영향을 미칠 수 있다는 것이다.

공수 레이저 스캐닝 기술(Airborne Laser Scanning Technology)[4]은 공중 레이저 스캐닝 데이터를 사용하여 싱크 홀 위험을 감지 기술로써, 일반적으로 표면 및 물체에 대한 상세한 3D 정보를 수집하는 방법으로 활용된다. 3D 데이터에는 일반적으로 지형 내에 포함되는 표면 형상 및 싱크 홀에 대한 정보가 포함되어 있지만, 싱크 홀은 주변 환경과 크게 다른 모양을 형성하지 않는다. 따라서 이 방법으로 싱크 홀을 탐지하는 것은 쉽지 않다. 공수 레이저(Airborne Laser) 방법은 일반적인 사진으로는 구분할 수 없는 초목, 토양 색상 및 표면 온도를 사용하여 침하 지역을 나타낼 수 있다. 그러나 데이터를 수집하기 위해서는 시간과 비용이 많이 들며, 또한 주변 환경에 의해 결과가 많은 영향을 받는다.

최근에 많은 양의 학습 데이터를 사용할 수 있고, 고성능 GPU이 개발됨에 따라 싱크홀과 같은 유사한 집단의 객체를 탐지하기 위한 기술을 향상시킬 수 있는 다양한 딥러닝 기반 방법이 제안되었다. RCNN(Regional based CNN)은 S. Ren[5]에 의해 빠른 처리를 위해서 제안되었지만 실시간 시스템에서 구현하기에는 충분히 빠르지 않다. YOLO(You Only Look Once) framework[6]에서는 실시간 성능을 얻기 위해 region proposal을 regression 문제로 공식화했다. YOLO의 고유한 기능은 객체 감지의 개별 구성 요소를 단일 컨볼루션 네트워크로 통합하여 여러 경

계 상자(Regions)와 해당 상자에 대한 클래스 확률을 동시에 예측한다는 것이다. 그러나 여전히 YOLO 프레임 워크의 정확성은 처리된 이미지에 나타나는 작은 객체의 영향을 받기 때문에 싱크홀을 탐지하는데 고속 RCNN과 YOLO를 적용하는 것은 어렵다. 싱크홀을 탐지하는데 있어 필요한 것은 실시간으로 처리하는 것이며, 또한 싱크홀 이미지는 먼 거리에서 캡처되므로 어떤 싱크홀들은 작게 나타날 수가 있다.

싱크홀을 탐지하기 위해 설명한 앞의 방법과는 달리 열 영상(Thermal Imagery)은 싱크홀 영역의 표면 온도가 주변 영역의 표면 온도와 크게 다르다는 사실을 사용한다. 공수 레이저 방식의 고비용을 줄이기 위해 [7]는 넓은 영역을 감시하기 위해 원적외선(FIR) 카메라를 장착한 무인 항공기를 사용한다. 또한 이 방법에서는 시간의 경과에 따른 온도 차이를 관찰함으로써 싱크홀을 기록하기 위한 최적의 시간을 알아냈다. 그리고 녹화된 영상에서 싱크홀 영역의 후보를 적응 이진화 방법(Adaptive Binarization)을 사용하여 분할하였다. 그 다음 경량 컨볼루션 신경망(Light CNN)[8]과 BRF(Boosted Random Forest)를 사용하여 잠재적인 싱크홀을 실

제의 싱크홀로 분류한다. 그러나 열화상 카메라로 싱크홀을 감지하는 방법은 조기에 싱크홀에 대한 경고 메시지를 줄 수 있지만, 열화상 카메라의 출력 이미지에 노이즈가 포함되어 있어 결과가 안정적이지 않다. 또한 싱크홀의 정확한 위치를 추적하여 경고를 할 수 없다.

본 논문에서는 [7]에서 제공되는 데이터 세트를 사용하여 싱크홀의 조기 발견 및 경고를 하는 자동 싱크홀 추적 시스템을 소개한다. 데이터 세트는 드론에 탑재된 열화상 카메라에서 수집된 데이터를 사용한다. 본 논문에서 제안된 시스템은 크게 세 부분으로 구성된다. 우선, 이진 영상에서 후보 싱크홀 영역을 추출한 후, 싱크홀 후보를 실제 싱크홀로 분류하기 위해 CNN 전달 학습(Transfer Learning)을 적용한다. 마지막으로 싱크홀을 추적(Sinkhole Tracking)하기 위해서 데이터 연결(Data Association) 방법이 구현된다.

본 논문의 나머지 부분은 다음과 같이 구성된다. 2 장에서는 제안된 알고리즘과 시스템에 대해 설명한다. 3 장에서는 실험 결과를 보여주며, 4 장에서는 추후 연구내용과 결과에 대한 검토를 한다.

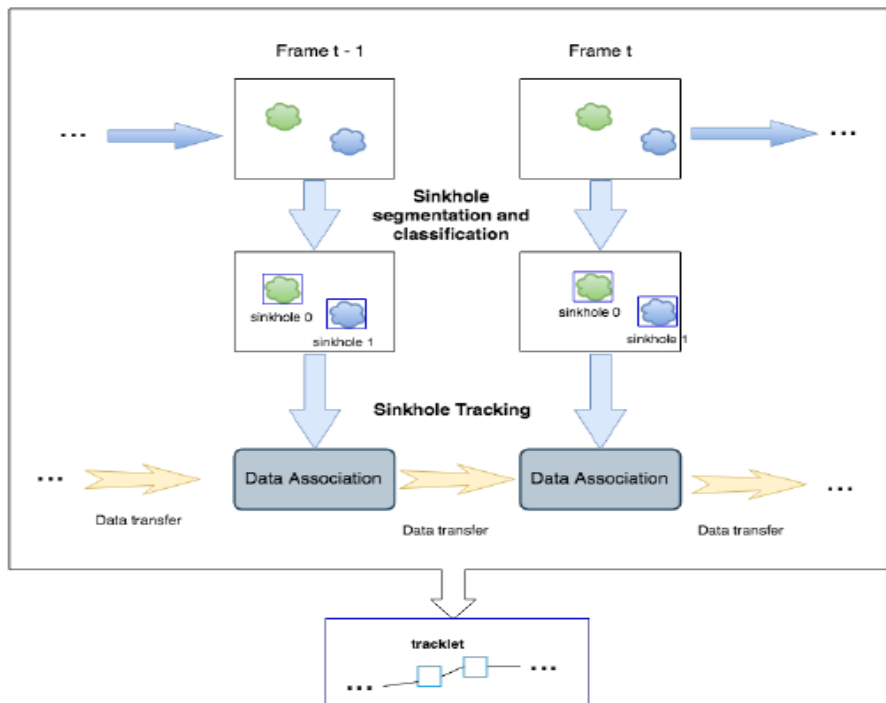


그림 1. 제안된 방안의 흐름도
Fig. 1. Flowchart of proposed method

II. 제안된 방법

본 논문에서 제안된 방안은 그림 1과 같이 후보 싱크 홀 분할(Candidate Sinkhole Segmentation), 싱크 홀 분류(Sinkhole Classification) 그리고 싱크 홀 추적(Sinkhole Tracking)의 세 단계로 구성되어 있다. 제안된 방안의 첫 번째 단계인 싱크 홀 분류는 온도 편차에 의한 이진 분류(Binary Segmentation)하는 것이다. 이 단계에서는 열화상 이미지를 수신한 후 주어진 비디오 프레임에서 후보 싱크 홀 위치를 출력한다. 이진 분할은 싱크 홀 위치의 온도가 주변 지역의 온도보다 낮다는 현상에 의해 이루어진다. 두 번째 단계는 후보 싱크 홀을 실제 싱크 홀로 분류하기 위해 전송 학습(Transfer Learning) 방법을 사용하는 싱크 홀 분류기이다.

마지막 단계인 실시간 싱크 홀 추적에서는 데이터 연관 문제를 처리하기 위해 헝가리언 알고리즘(Hungarian Algorithm)[9]을 사용하며, 싱크 홀 분류기에서 수집된 데이터는 현재 프레임 및 이전 프레임의 데이터 분포를 기반으로 온라인으로 트랙릿(Tracklet)에 할당된다. 또한, 분류 단계에서 불안정한 결과를 출력할 수 있는 문제점은 본 연구에서 개발된 방향 투표 기법(Direction Voting Technique)으로 해결할 수 있다.

2.1 후보 싱크 홀 분할

영화상 카메라 영상의 회색 음영 이미지는 첫 번째 단계의 입력이다. 분할(Segmentation) 알고리즘은 열 영상에서 차가운 영역을 찾아 후보 싱크 홀을 감지한다. 이를 위하여, 주변 환경이 싱크 홀보다 어두운 회색을 가질 수 있기 때문에 이중 임계(Dual-thresholding) 방법을 적용한다. 이중 임계 프로세스는 다음과 같다. I 는 입력 이미지이고, (x, y) 는 특정 픽셀의 위치이며, T_l 과 T_h 는 임계값을 나타낸다.

$$I(x, y) = \begin{cases} 0, & \text{if } I(x, y) \leq T_l \text{ or } I(x, y) \geq T_h \\ 255, & \text{if } T_l \leq I(x, y) \leq T_h \end{cases} \quad (1)$$

T_l 는 Otsu 알고리즘을 적용하여 정하였다[11]. 데

이터 세트에 대해서 적용한 결과 $T_h = T_l + 20$ 에서 최상의 성능을 제공한다는 것을 알 수 있었다.

2진 세그먼테이션 단계 후에도 2진 이미지에 여전히 잡음이 남아 있으며, 세그먼트된 영역의 가장자리 잡음을 제거하기 위해 개방(Opening), 폐쇄(Closing), 팽창(Dilate), 침식(Erode)과 같은 형태학적 동작(Morphological Operation)이 적용된다.


형태학적 잡음 제거 후, 나무, 건물, 자동차와 같은 싱크 홀과 유사한 형태를 것들을 제거하기 위해 연결 요소 분석(Connected Component Analysis)를 적용한다. 세그먼트된 이미지에서 흰색 픽셀의 각 블록은 휴리스틱 필터(Heuristic Filter)를 통과하는 연결된 구성 요소로 간주된다. CC_i 는 이미지에서 i 번째 연결 구성요소이며, w_i 는 CC_i 의 넓이, h_i 는 CC_i 의 높이, 그리고 s_i 는 CC_i 의 영역으로써 i 번째 연결 구성요소의 흰색 픽셀 수이다. 휴리스틱 필터의 알고리즘은 Algorithm 1에서 설명되며, 그리고 플리커 에너지 분류[10]는 세그먼트된 이미지에서 노이즈를 제거하기 위해서 고려된다.

Algorithm 1 Cell Examination

```

procedure
while  $CC_i \in$  Connected Component Set do
  if  $w_i$  or  $h_i \leq t_1$  then
    remove  $CC_i$ 
  if  $w_i$  or  $h_i \geq t_2$  then
    remove  $CC_i$ 
  if  $\frac{w_i}{h_i} \leq t_3$  then
    remove  $CC_i$ 
  if  $\frac{w_i}{h_i} \geq t_4$  then
    remove  $CC_i$ 
  if shape of  $CC_i$  is not convex hull then
    remove  $CC_i$ 
  if  $s_i \leq t_5$  then
    remove  $CC_i$ 
  if  $s_i \geq t_6$  then
    remove  $CC_i$ 
  if the variance of pixel value in  $i^{th}$ 
  connected component is larger than
   $t_7$  then
    remove  $CC_i$ 
end

```



(a) 열화상 이미지 (b) 이진 분류 영상
 (a) Thermal image (b) Binary segmented image

그림 2. 이진 분류 결과
 Fig. 2. Binary segmented result

휴리스틱 필터에서 사용된 임계 값들은 경험적으로 선택된다. 선택된 임계 값들은 $(t_1, t_2, t_3, t_4, t_5, t_6, t_7) = (5, 100, 0, 2, 5, 75, 1000, 15)$ 이다. 그림 2의 (a)는 열화상 이미지를 보여주며, (b)는 이진 분류 결과 이진 영상을 보여준다.

2.2 CNN 전달 학습에 의한 싱크 홀 분류

최근 컴퓨터 기술의 발달로, 딥 러닝은 이미지를 분류하는데 가장 향상된 성능을 보여주었다. 본 논문에서는 실제 싱크 홀과 다른 물체를 구분하기 위해 CNN 분류기를 구현하였다. CNN 전달 학습을 이용한 영상 분류는 훈련(Training)과 예측(Prediction)의 두 단계로 구성된다. 훈련 단계에서 CNN 모델은 해당 유형으로 레이블이 지정된 알려진 데이터 이미지 세트를 사용하여 학습된다. 모델이 학습되면 새 이미지의 객체 유형을 예측하는 데 사용된다.

CNN 모델을 학습하기 위해서는 엄청난 수의 매개 변수 때문에 큰 데이터 집합과 많은 양의 계산량, 그리고 성능이 뛰어난 컴퓨터가 필요하다. 따라

서 데이터 세트가 부족하면 CNN을 학습시키는데 많은 어려움이 있다. 대신 사전에 훈련된 모델을 원래 데이터 집합에 속하지 않는 범주에서 작업하도록 전송될 수 있다. 본 논문에서는 CNN 싱크 홀 분류 모델을 학습하기 위해 전달 학습 방법을 사용하였다.

Alexnet[12]이 LSVRC2012 유형 분류 컨테스트에서 성공을 거둔 이후에 ResNet(Residual Network)은 최근 컴퓨터 비전과 딥 러닝에서 가장 효율적으로 사용되는 훈련된 모델이다[13]. ResNet 모델은 수백만 개의 이미지와 1000개의 객체 유형이 포함된 Image Net Dataset[14]에서 학습되었다. ResNet에는 다양한 버전이 있으며, 본 논문에서는 ResNet-50을 선택했다. ResNet-50은 49개의 컨벌루션 레이어(Convolution Layer), 1개의 완전 연결된 레이어(Fully Connected Layer) 및 1000 개의 객체 유형에 대한 각 이미지의 분류 점수를 계산하는 1개의 분류 레이어(Classification Layer)를 포함한다. 싱크 홀 영역을 분류하기 위해 최종 레이어를 싱크 홀과 싱크 홀이 아닌 두 가지 객체 유형 만 있는 새 레이어로 대체했다. 이 레이어는 데이터 집합에서 역 전파 미세 조정 접근 방식(Back-propagation Fine-tune Approach)을 사용하여 처음부터 훈련되어진다.

비디오 프레임에서 싱크 홀 이미지 분류하기 위해 CNN을 훈련시키기 위해서는 훈련을 위한 하나의 데이터 세트와 평가를 위한 또 다른 데이터 세트를 준비해야 한다. 본 논문에서 교육을 위한 데이터 세트 7000개의 싱크 홀 이미지와 7000개의 싱크 홀이 아닌 이미지가 있으며, 평가 데이터 세트는 각 클래스에 대해서 1000개의 이미지가 있다.




그림 3. 싱크홀 데이터 세트와 싱크홀이 아닌 데이터 세트 이미지
 Fig. 3. Images from sinkhole dataset and non-sinkhole dataset

전달 학습 방식을 사용하여 CNN을 훈련 할 때, 사전에 훈련된 CNN의 가중치가 상대적으로 좋았기 때문에 초기에 작은 학습 율을 사용했으며 빨리 수렴할 필요가 없었다. 최적화 프로세스는 최대 50,000 반복 실행되었으며, 훈련 된 CNN 분류기의 결과 정확도는 99% 이상이었다. 그림 3은 학습에 사용된 싱크홀과 싱크홀이 아닌 열화상 영상이며, 윗줄의 영상은 싱크홀 영상을 보여주며, 아랫줄은 싱크홀이 아닌 영상을 보여준다.

2.3 HA 알고리즘에 의한 싱크 홀 추적

싱크 홀을 CNN 분류기에서 감지하고 인식한 후, 추적의 문제는 싱크 홀을 연속 프레임의 개체 궤도인 각 트랙릿(Tracklets)에 할당하는 것이다. 이 문제를 해결하기 위해 데이터 결합을 위해 헝가리언 알고리즘(HA, Hungarian Algorithm)을 구현했다. 데이터 결합을 위한 방법에는 NNDA(Nearest Neighbor Data Association), PDA(Probabilistic Data Association), JPDA(Joint Probabilistic Data Association) 및 FDA(Fuzzy Data Association) 등 많은 알고리즘이 있으며 [15], 본 논문에서는 이미지에 많은 싱크홀이 있는 것이 아니기 때문에 헝가리언 알고리즘을 사용하였다.

비디오 프레임에서 싱크 홀이 N개 발견되었다고 가정 할 때 문제는 싱크 홀이 속한 트랙 렛을 식별하는 방법이다. 또한 s_{ij} 를 i 번째 싱크 홀과 j 번째 트랙 렛의 데이터 분포사이의 점수라고 하자. 스코어는 트랙렛에서의 싱크 홀 이미지와 검출 된 싱크 홀의 이미지 사이의 상관관계(Correlation)를 사용하여 계산된다. 상관 점수가 높으면 싱크 홀이 각 트랙 렛에 속할 확률이 높다는 것을 의미한다.

HA를 사용하여 문제를 풀기 위해 거리 $d_{i,j} = \frac{1}{s_{i,j}}$ 을 얻을 것이다. 그리고 x_{ij} 는 i 번째 싱크 홀과 j 번째 트랙 렛의 관계를 정의한다. 즉 i 번째 싱크 홀이 j 번째 트랙 렛의 일부인 경우에만 $x_{ij} = 1$, 그렇지 않으면 $x_{ij} = 0$ 이다. 따라서 $\sum_{j=1}^N x_{ij} = 1$ 이거나 하나의 검출 된 싱크 홀은 단지 하나의 트랙

세트에 속하며, 여기서 $i = \overline{1, N}$, 그리고 N 은 트랙 렛의 수이다. HA는 이런 종류의 최적화 문제를 해결하는 방법입니다. 그것은 식 (2)에서 전체 비용 함수를 최소화한다.

$$d = \sum_{i=1}^N \sum_{j=1}^N d_{ij} x_{ij} \quad (2)$$

할당 문제(Assignment Problem)의 거리 행렬은 식 (3)과 같이 주어진다.

$$\begin{bmatrix} d_{11} & d_{12} & d_{13} & \dots & d_{1N} \\ d_{21} & d_{22} & d_{23} & \dots & d_{2N} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ d_{N1} & d_{N2} & d_{N3} & \dots & d_{NN} \end{bmatrix} \quad (3)$$

첫 번째 단계에서 HA는 각 싱크 홀과 트랙 렛 사이의 최소 거리를 찾은 다음 각각의 최소 무게로 모든 가중치 d_{ij} 를 뺀다.

$$d_{ij} = d_{ij} - \min\{d_{ij}\}, j = \overline{1, N} \quad (4)$$

마찬가지로 HA는 거리 매트릭스의 동일한 열에 있는 모든 항목에서 각 열의 최소 거리를 뺀다.

$$d_{ij} = d_{ij} - \min\{d_{ij}\}, i = \overline{1, N} \quad (5)$$

이 단계 후에 거리 매트릭스 D에는 0 값이 포함된다. 세 번째 단계에서, n 을 최소한 한 개 이상의 0을 포함하는 수평/수직 라인이라고 할 때, $n=N$ 이면, 거리 매트릭스 D의 0값을 기반으로 할당 x_{ij} 를 만들 수 있다. 그렇지 않으면, 세 번째 단계의 조건이 충족 될 때까지 두 번째, 세 번째 단계를 반복해야 한다.

수집 한 데이터 세트는 드론에서 캡처 한 비디오이다. 따라서 싱크 홀과 다른 물체는 고정되어 있고 카메라가 움직이기 때문에 비디오가 안정적이지 않다. 경우에 따라서 분할 및 분류 단계에서 이미지의 실제 싱크 홀을 감지하지 못하는 경우가 있다. 이

경우 이전 프레임의 이전 싱크 홀 위치를 작은 변환 거리로 사용하여 현재 프레임에 배치한다. 변환 거리는 이전 프레임 및 현재 프레임의 다른 싱크 홀 변환을 기반으로 계산된다. 이 변환 보정은 비디오 프레임의 모든 싱크 홀이 같은 방향으로 움직인다는 가정 하에 수행되었다. 이 접근법은 시스템이 감지 및 인식 과정에서 싱크 홀이 누락 된 문제를 해결하는데 도움이 된다.

III. 실험 결과

본 논문에서는 실시간 싱크 홀을 효율적으로 수행하기 위해 Intel Core i7, GPU : GTX 1070, Ram : 16Gb의 하드웨어를 사용하였다. 제안 된 싱크 홀 추적 시스템을 평가하기 위해 무인 항공기에서 캡처 한 수집 된 비디오가 사용되었다. 먼저 입력 비디오를 학습용 데이터 세트와 테스트용 데이터 세트로 세분화 한 후에 성능을 평가하기 위해 식 (6), (7)을 사용하여 평균 탐지 정확도(AP, Average detection Precision)와 평균 재현(AR, Average Recall)을 추정하였다.

$$AP = \frac{TP}{TP + FP} \quad (6)$$

$$AR = \frac{TP}{TP + FN} \quad (7)$$

TP : True Positive, FP : False Positive,

FN : False Negative

중첩 임계 값(Overlapping Threshold)에 의해서 검출 된 싱크 홀이 FP 인지 또는 TP 인지를 알 수 있다. FP는 실제 싱크 홀의 중첩 임계값 이하로 중첩되는 모든 테스트 데이터를 테스트함으로써 결정되며, TP는 실제 싱크홀의 중첩 임계값 이상으로 중첩되는 모든 테스트 데이터를 테스트함으로써 결정된다.

표 1에 제안된 방법의 AR과 AP를 보여준다. 중첩 임계 값이 증가하면 제안 된 방법의 AP와 AR 점수가 감소한다는 것을 알 수 있다. 일반적으로 문헌에서 추적 방법의 성능을 평가하기 위해서 중첩 임계 값을 0.5로 사용한다.

표 1. 정확도 평가

Table 1. Accuracy evaluation

Overlapping Threshold	Average Recall	Average detection Precision
0.3	93.2%	94.1%
0.4	92.0%	92.4%
0.5	88.7%	89.0%
0.6	86.6%	87.4%

IV. 결론

본 논문에서는 실시간 싱크 홀 추적을 효율적으로 수행하기 위해 CNN 객체 분류기와 HA 데이터 연관성을 결합한 접근 방식을 제안했다. 실험 결과 제안 된 방법은 중첩 임계 값 0.5에서 각각 AP와 AR에 대해 89%와 88.7%를 달성하였다. 그러나 본 논문에서 제안 된 방법은 입력 비디오가 안정적이지 않을 때 분할 단계에서 잠재 싱크 홀 후보를 감지하지 못하는 경우가 있으며, 또한, 훈련 세트에서 입력 잠재 후보가 누락 된 경우 분류기 성능이 좋지 않은 경우도 있다. 그러나 이러한 단점에도 불구하고 제안 된 방법은 적외선 카메라를 이용한 싱크 홀 검색과 같은 실용적인 분야에 유용하게 사용될 수 있음을 보여준다. 추후 연구 과제로는 현재 싱크 홀에 대한 데이터 세트가 부족하기 때문에 많은 데이터 세트를 확보를 하는 방법에 대한 연구를 진행할 예정이다.

References

- [1] E. Intriери, G. Gigli, M. Nocentini, L. Lombardi, F. Mugnai, F. Fidolini, and N. Casagli, "Sinkhole monitoring and early warning: an experimental and successful GB- InSAR application", *Geomorphology*, Vol. 241, pp. 304-314, Jul. 2015.
- [2] T. L. Dobecki and S. B. Upchurch, "Geophysical applications to detect sinkholes and ground subsidence", *Leading Edge*, Vol. 25, No. 3, pp. 336-341, Mar. 2006.
- [3] A. Billi, L. D. Filippis, P. P. Poncia, P. Sella, and C. Faccenn, "Hidden sinkholes and karst

cavities in the travertine plateau of a highly-populated geothermal seismic territory (Tivoli, central Italy)", *Geomorphology*, Vol. 255, pp. 63-80, Feb. 2016.

[4] D. Bloomquist, R. Shrestha, and C. Slatton, "Early sinkhole detection and verification using airborne laser and infrared technologies", Final report BC-354-54, Department of Civil and Coastal Engineering, University of Florida, 2005.

[5] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards realtime object detection with region proposal networks", *Proc. Advances in Neural Information Processing Systems*, pp. 91-99, Jan. 2016.

[6] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection", *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 779-788, 2016.

[7] Lee, Eun Ju, Sang Young Shin, Byoung Chul Ko, and Chunho Chang, "Early sinkhole detection using a drone-based thermal camera and image processing", *Infrared Physics and Technology*, Vol. 78, pp. 223-232, Sep. 2016.

[8] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D., "Backpropagation applied to handwritten zip code recognition", *Neural computation*, Vol. 1, No. 4, pp. 541-551, Dec. 1989.

[9] Munkres J, "Algorithms for assignment and transportation problems", *Journal of the Society for Industrial and Applied Mathematics*, Vol. 5, No. 1, pp. 32-38, Mar. 1957.

[10] Nguyen Manh Dung and Soonghwan Ro, "Algorithm for Fire Detection using a Camera Surveillance System", *Proceedings of the International Conference on Image and Graphics Processing(ICIGP 2018)*, pp. 38-42, Feb. 2018.

[11] Nobuyuki Otsu, "A threshold selection method from gray-level histograms", *IEEE transactions on systems, man, and cybernetics*, Vol. SMC-9, No.

1, pp. 62-66, Jan. 1979.

[12] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton, "Imagenet classification with deep convolutional neural networks", *Proceedings of the Advances in neural information processing systems*, pp. 1097-1105, Dec. 2012.

[13] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun, "Deep residual learning for image recognition", *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, Jun. 2016.

[14] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei, "Imagenet : A large-scale hierarchical image database", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248-255, Jun. 2009.

[15] Wanli Xu, Shuo Bao, and Zhun Liu, "Data Association Algorithm Overview and Performance Evaluation", *Proceedings of the International Industrial Information and Computer Engineering Conference*, pp. 262-265, Mar. 2015.

저자소개

노 승 환 (Soonghwan Ro)



1987년 : 고려대학교 전자공학과 (공학사)
 1989년 : 고려대학교 전자공학과 (공학석사)
 1993년 : 고려대학교 전자공학과 (공학박사)
 2003년 : 영국버밍엄 대학교

초빙연구원

1994 ~ 현재 : 국립 공주대학교 정보통신공학부 교수
 관심분야 : 5G이동통신, 임베디드시스템, 열화상 영상처리

남 부 호아이 (Nam Vu Hoai)



2013년 : Honio University of
Science and Technology,
Department of Electronics and
Technology(공학사)
2015년 : 전남대학교 컴퓨터공학과
(공학석사)
2017 ~ 현재 : Lecturer, Posts and
Telecommunications of Technology, Ha Noi, Vietnam
관심분야 : 영상처리, 머신러닝, 적외선 영상처리

최 복 길 (Bokgil Choi)



1979년 2월 : 고려대학교 전기
공학과 졸업(공학사)
1983년 8월 : 고려대학교 전기
공학과 석사(공학석사)
1990년 8월 : 고려대학교
전기공학과 박사(공학박사)
1992년 3월 ~ 현재 : 공주대학교

교수
관심분야 : 반도체 센서, 에너지 하베스팅

뉴엔 만 등 (Nguyen Manh Dung)



2005년 7월 : Hanoi Univ. of
Science and Tech. Dept. of
Electronic and Tele-
communication(공학사)
2009년 2월 : 공주대학교
정보통신과(공학석사)
2017년 3월 ~ 현재 : 공주대학교

정보통신과 박사과정
관심분야 : 영상처리, 임베디드 시스템