

2022년 지질자원 데이터 활용 및 인공지능 경진대회 최종 제안서

TerraSAR-X 영상 및 modified U-Net을 이용한 홍수 변화 탐지

유진우, 윤영웅, 이어루

1. 문제정의

(1) 연구 배경 및 필요성

- 화석연료의 지속적인 사용으로 매년마다 대기 중 이산화탄소 농도는 증가하고 있으며, 이로 인한영향은 지구온난화 및 기후 변화 등으로 나타남 (그림1)

Global Temperature and Carbon Dioxide




그림 1 전지구 이산화탄소 농도 변화 및 전지구 기온 편차(Karl et al. 2009)

- 전 세계적으로 기후가 바뀌어 감으로써 엘니뇨, 라니냐와 같은 현상이 발생하며, 이러한

현상에 의하여 비정상적으로 강우 현상이 특정 지역에 집중되어 큰 홍수를 유발함(Kiem et al., 2003)




그림 2 년도별 세계적인 홍수 발생 횟수 (출처 : EM-DAT 2014)

- 10년간 재해 피해 중 홍수와 관련된 호우 및 태풍에 의한 평균 피해액은 연간 약 3203억 원으로, 전체 재해 평균 피해액의 88.3%를 차지 할 만큼 높은 인명 및 재산 피해가 발생되며(행정안전부, 2018), 계속적으로 증가하는 추세를 보임.(Moel and Aerts, 2011)
- 홍수에 대한 피해를 방지하고 복구하기 위해서 침수 피해지역을 신속하게 파악하는 것은 매우 중요한 사안임
- 이러한 홍수 침수 피해지역을 파악하기 위하여 넓은 범위를 효과적으로 관측할 수 있는 위성영상을 활용
- 실제 위성 영상을 통해 기름 유출, 화산 분화, 지반 침하와 같은 인재 및 자연재해를 효과적으로 관측 및 분석하고 있음.(Baek et al., 2020, Jo et al., 2018, Jung et al., 2007)
- 위성 영상은 광학 위성 영상, 레이더 위성 영상등의 다양한 종류의 위성이 존재
- 광학 위성 영상의 경우 태양의 가시광선을 통해 영상화를 하기 때문에 기후 및 시간대의 영향을 많이 받아 취득할 수 있는 영상의 수가 한정적임. 특히, 홍수 관측의 측면으로 볼 때, 광학 영상의 경우 비가 온 뒤에는 구름의 영향으로 인해 사용할 수 있는 영상이 한정적이며, 저녁 시간대에 경우 영상을 취득할 수가 없음
- 반면 레이더 위성 영상은 높은 투과율을 가지는 마이크로파를 직접 쏘는 능동형 센서를 이용하기 때문에 시간이나 기상 조건에 상관없이 영상을 취득할 수 있어, 광학 위성의 단

점을 보완할 수 있어 홍수 관측에 있어 레이더 위성 영상이 효과적임 (Schumann et al., 2011)

- 최근에는 위성 영상들과 딥러닝 기법을 결합하여 재난 재해 관측 관련 연구가 증가하고 있으며, 이러한 연구들은 기존의 알고리즘을 상회하는 성능을 보여줌(Stanislav et al., 2020)
- 딥러닝 기법 중 segmentation 기법은 이미지 내에 있는 물체들을 의미 있는 단위로 분할해 주기 때문에 홍수의 발생 지역과 미발생 지역의 면적을 파악하는데 적합.
- U-Net은 인코더와 디코더를 활용하여 context 인식과 localization 사이에 발생하는 trade-off를 해결한 모델로 segmentation의 대표적인 기법임(Ronneberger et al., 2015)
- U-Net의 Encoder는 각 입력 영상의 특성맵을 추출하는 역할을 하고 있으며, 이 특성맵은 딥러닝의 역전파 과정 및 학습 결과에 영향을 줌
- 기존 U-Net의 경우에는 단일의 인코더만을 가지고 있어 단일 크기의 convolution 연산만을 진행함
- 레이더 위성 영상은 영상화 과정에서 여러 산란체의 후방산란 값을 한 픽셀 안에 따로 표현할 수 없기 때문에 speckle noise가 발생하게 됨
- Speckle noise는 multiplicative noise 및 레일리분포의 특성을 나타내어, 레이더 영상 화질을 저하시키므로 특징 추출 등과 같은 컴퓨터 비전 분야의 성능을 저하시키는 요인으로 이를 단일 크기의 컨볼루션 연산을 통해서 필터링하게 된다면, 노이즈가 낀 영상에서 충분한 양질을 가지는 특성맵을 추출하지 못할 것임.
- 또한, 기존 SAR 영상과 딥러닝을 활용한 홍수 면적 탐지의 경우 각 영상에 대한 수계 영역과 비수계 영역을 탐지한 후, 추가적인 연산을 통해 홍수가 발생한 면적을 도출해냄.
- 따라서 본 모델 개발 연구에서는 위의 한계점을 보완하기 위해 다중 인코더의 구조를 사용하여 다양한 크기의 convolution 연산을 진행하여 다양한 크기의 추출맵을 추출하고, 홍수 전후의 영상을 활용하여 홍수가 발생된 지역을 직접적으로 도출해내는 모델을 제작하고자 함.

2. 데이터 개요

(1) 연구 지역

- 그림3은 연구지역으로 미국의 미시시피강 유역으로 자체 길이가 3,767km로 미국에서 두번째로 긴 강으로 길이에 비해서 강의 높낮이 차가 적으며, 물의 흐름도 완만하고 수량도 많음.

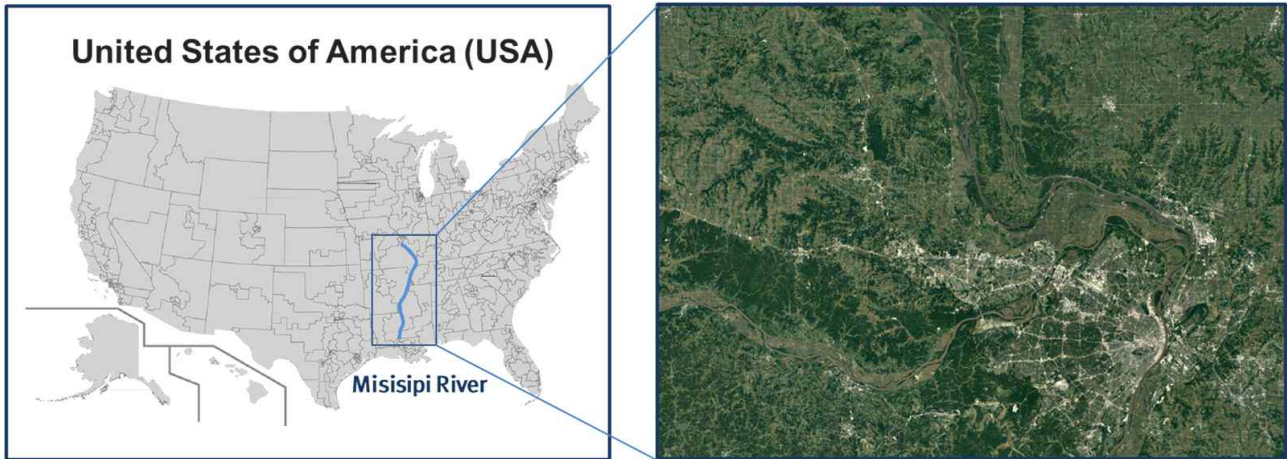


그림 3 연구지역

- 계절에 따라 수량의 증감이 현저하며 큰 홍수를 자주 일으키는 지역으로 미국의 주요농업지대 및 납 광산과 석유 정제 시설이 위치해 홍수 발생 시 미국 뿐 아니라 국제 경제에 영향을 줌.

(2) 데이터

- 연구 데이터는 2008년 7월 미시시피강 범람에 의한 침수 지역을 탐지하기 위해 홍수 발생 전 후의 TerraSAR-X 위성 영상 두 장을 활용
- 2008년 7월 4일의 영상은 홍수가 발생 직후의 영상이며, 15일의 영상은 홍수가 발생한 이후, 물이 빠진 후의 영상
- 그림4에서 노란색 부분이 모델의 train과 test에 활용된 지역으로 두 시기의 영상을 시간 순 및 시간 역순으로 활용하여 수계에서 비수계 및 비수계에서 수계로 변한 지역에 대해 학습

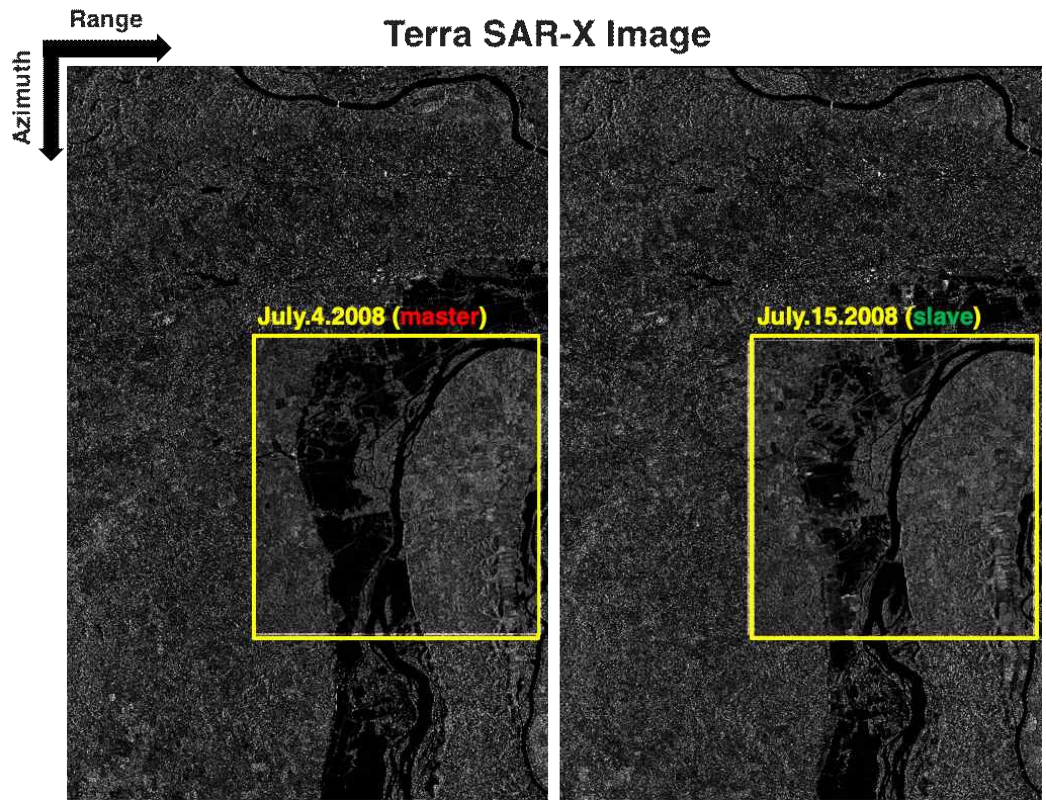


그림 4 레이더 영상 원본 데이터

표 1 데이터 상세 정보

Date	Mode	Pass Direction	Polarization	Incidence Angle
2008.07.04	Stripmap	Ascending	VV	44.5027deg
2008.07.15	Stripmap	Ascending	VV	44.5052deg

- 표1은 학습데이터의 메타데이터를 보여줌

3. 방법론

- 그림5는 TerraSAR-X 영상 및 modified U-Net을 이용한 홍수 변화 탐지모델 분석의 모식도를 나타냄

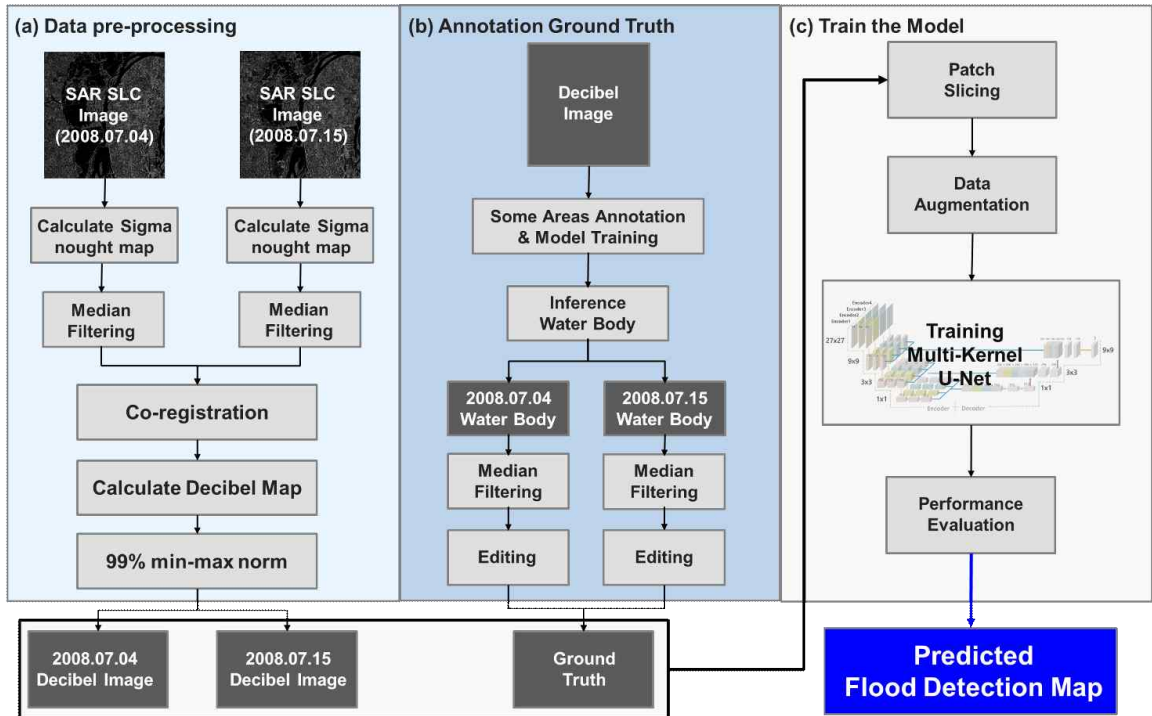


그림 5 데이터 전처리 모식도

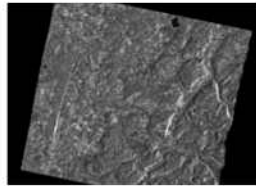
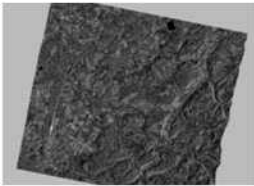
- 분석방법은 크게 3파트로 데이터 전처리, 정답값 라벨 제작, 모델 학습 및 결과 분석의 파트로 나눌 수 있음.

a) 딥러닝 모델 학습을 위한 미시시피강 홍수기간 중 두 시기의 TerraSAR-X 데이터 전처리

- TerraSAR-X Data을 이용하여 시그마넛 영상을 제작 (그림6)
- 시그마넛 영상은 SAR 안테나로부터 방사된 에너지가 지상 산란체에 의해서 반사되는 특성을 가리키는 후방산란계수값으로 영상의 픽셀 값에서 지구의 물리적인 특성 값으로 변환 해준 영상
- 센서의 영상 획득 기하나 입사각 및 빔 조향등에 상관관계가 적어 서로 다른 센서에서 얻어진 값의 상호 비교가 가능하며, 지상표적 탐지, 토지피복분류, 토양수분 예측, 작황 파악 및 해상풍산출 등에 활용

$$\sigma^0 = (k_s \cdot |DN|^2 - NEBN) \cdot \sin\theta_{loc}$$

k_s : calibration and processor scaling factor
DN : Digital Number
NEBN : Noise Equivalent Beta Naught
 θ_{loc} : Local Incidence Angle

Raw Data
Sigma Naught

그림 6 시그마넛 영상 수식

- 생성된 시그마넛 영상 내에는 스펙클 노이즈가 포함.
- Speckle noise는 multiplicative noise 및 레일리분포의 특성을 나타내어, SAR 영상 화질을 저하시키는 요인 중의 하나로, 노이즈가 심하게 포함되어 있을 시 모델의 예측 성능을 저하시킴
- Speckle noise의 영향을 줄이기 위해 임펄스성 잡음을 제거하는데 효과적인 메디안 필터를 3x3의 크기로 적용
- 위성 레이더의 특성 상, 같은 지역에 대해 촬영한다 해도 촬영 궤도와 같은 환경에 따라 두 시기의 영상이 위치의 차이가 존재
- 두 시기의 위성 영상 간의 위치의 차이가 존재할 경우, 이는 모델의 학습 성능을 떨어뜨릴 수 있음
- 영상의 쌍이 동일한 위치에 놓이게 하기 위해 영상 정합(co-registration)을 진행(Zou et al., 2019) (그림7)
- 위성레이더 자료가 갖고 있는 지표 특성에 대한 반사 신호인강도 정보의 상관 계수를 이용하는 cross-correlation 방법을 사용(chae, 2016)
- SLC 영상 내 모든 가로 및 세로 방향 픽셀의 상관성을 SLC 영상 쌍 전체에 대해 커널을 이동시키면 계산하는 intensity cross correlation 방법을 사용하여, 두 SLC 영상간의 변위를 추정하고, 이를 이용하여 정합(chae, 2016)

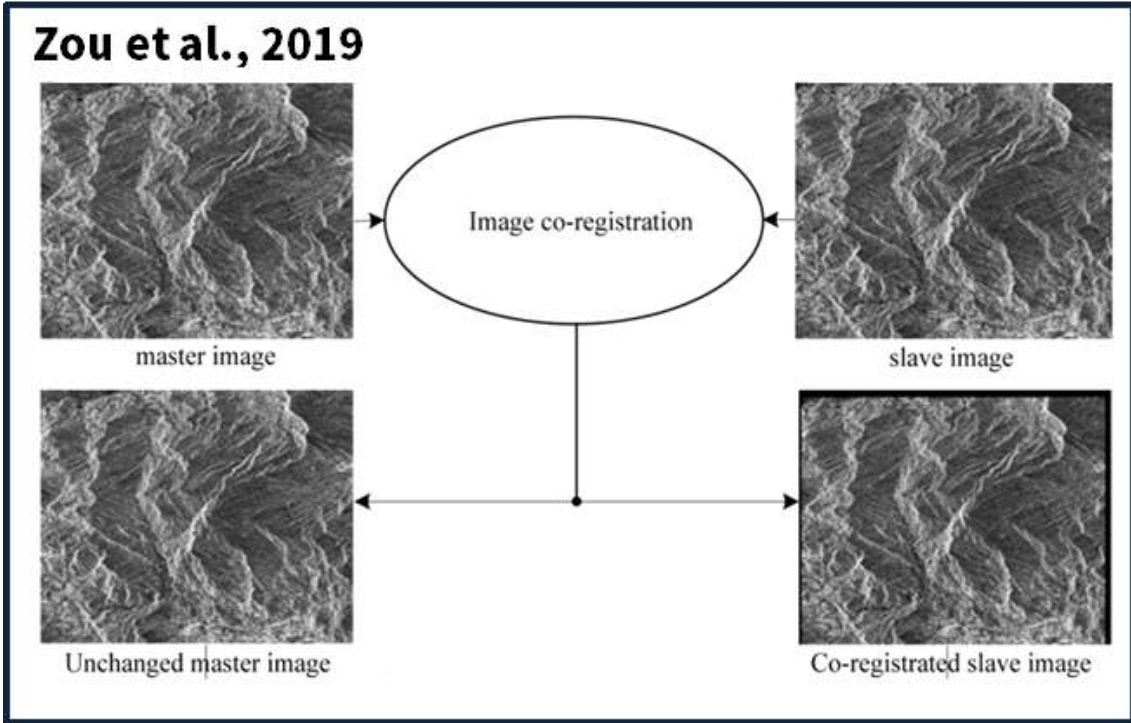


그림 7 Co-registration 방법

- 영상 정합을 진행한 후, Intensity 영상의 값의 단위를 Decibel로 변환한 영상을 생성
- Decibel 영상은 강도영상과 마찬가지로 많은 스펙클노이즈가 포함되어 있으나 값의 범위가 줄어들기 때문에, 더 안정적인 학습 진행 가능
- 그 후 전처리 데이터의 이상치 값 제거 및 영상 정규화를 위해 99% min-max normalization 처리

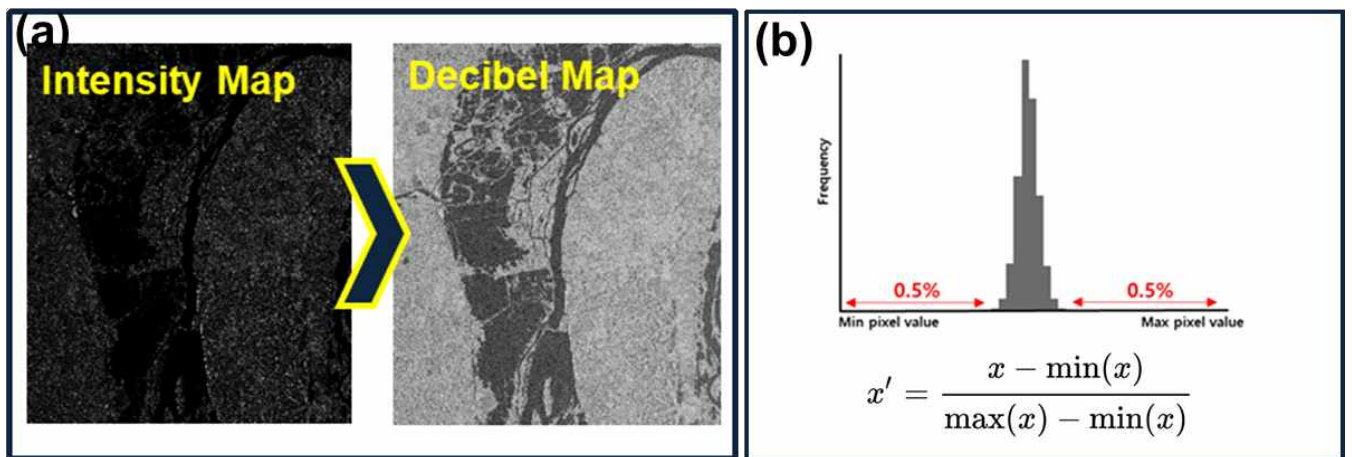


그림 8 Decibel 영상 전환(a), 99% min-max 정규화(b)

b) 전처리한 데이터를 배경으로 모델의 정답값 제작

- 모델의 학습을 위해 수계 영역과 비수계영역 어노테이션 실시



그림 9 어노테이션 방법

- 어노테이션 진행을 효율적으로 진행하기 위해 일부 지역에 대해 어노테이션을 진행하고, 이를 통해 수계와 비수계를 찾는 간단한 ANN모델을 제작
- 제작한 모델에 입력자료를 적용하여 예측된 수계 비수계영역 데이터를 획득 (그림10)

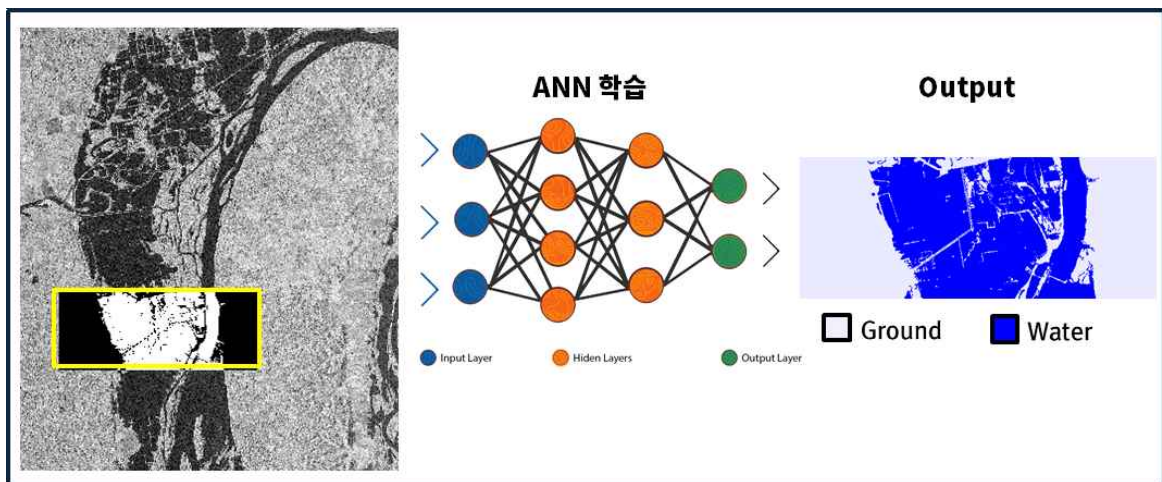


그림 10 ANN 학습 모식도

- 예측된 수계 비수계영역 데이터는 스펙클노이즈로 인해 오분류된 픽셀들이 포함
- 최종적인 수계, 비수계 영역 라벨링을 위해 중앙값 필터링을 적용하여 포함되어 있는 한 두 픽셀의 적은 영역의 오분류된 픽셀을 제거
- 그 후, 그림자나 다른 영향으로 인해 오분류가 된 픽셀들을 Decibel map과 원본 자료를

확인해가며 직접 수정

- 이렇게 제작된 master 영상과 slave영상에 대한 수계, 비수계 map을 시간 순(master to slave), 시간의 역순(slave to master)으로 차분하여 땅에서 땅(Ground to Ground), 물에서 물(Water to Water), 물에서 땅(Water to Ground), 땅에서 물(Ground to Water)의 변화를 나타내주는 최종 라벨 제작 (그림11)
- 이를 통해 홍수 전후의 영상으로 바로 홍수 발생 면적을 탐지하는 모델을 제작 가능

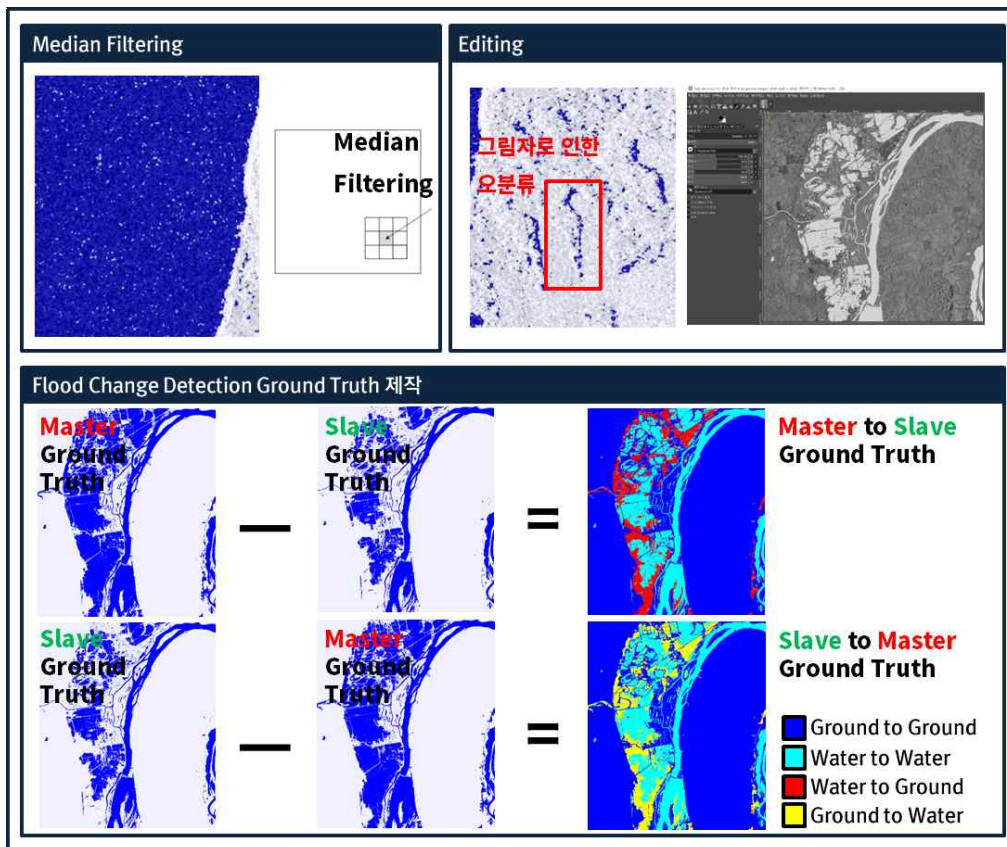


그림 11 최종 정답값 제작

c) 모델 제작 및 학습

- 앞서 제작한 데이터를 모델의 입력자료로 활용해주기 위해서는 영상을 128 * 128 크기의 패치로 영역이 서로 겹치지 않도록 자름
- 제작한 13528장의 패치를 서로 겹치지 않게 train 8000장, test 5528장으로 나눔
- 모델의 과적합을 방지하고 새로운 데이터에 대한 강건한 모델을 제작하기 위해 학습 데

이더 증강(Data Augmentation) 진행

- 데이터 증강은 Affine Transform, Random Rotation한 데이터를 활용
- 데이터 증강의 결과 학습 dataset의 양을 2배로 늘림

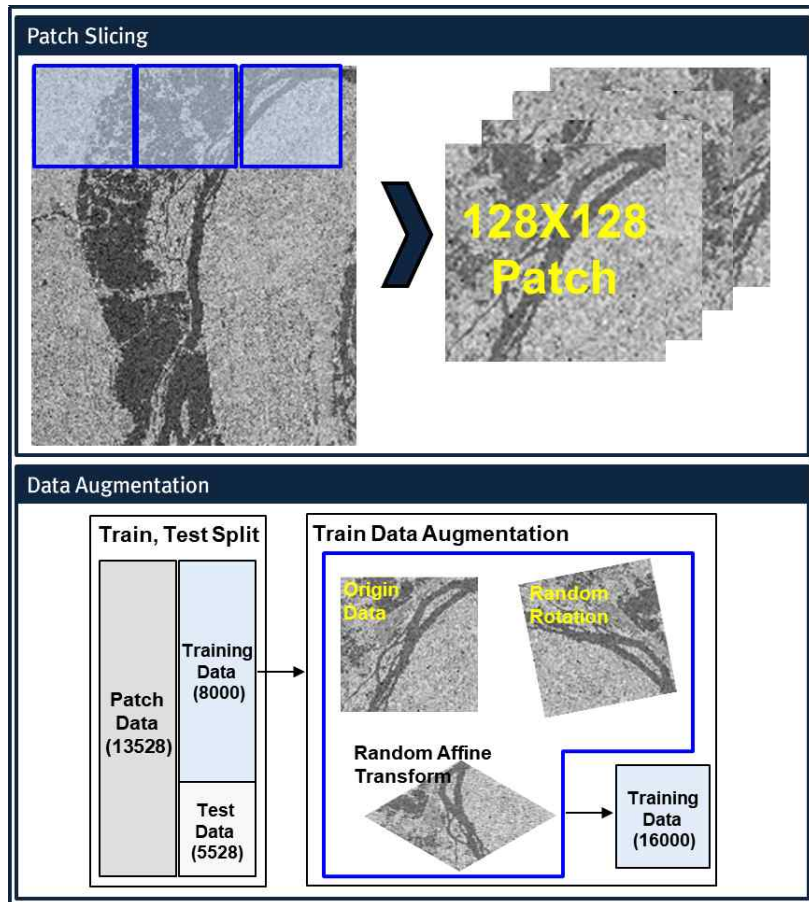


그림 12 데이터 패치 Slicing 및 학습 데이터 증강

- 아래 그림 13는 본 연구에서 사용된 모델과 모델 학습에 사용된 hyperparameter를 나타냄
- 모델 학습 환경은 UBUNTU 서버에서 pytorch 환경에서 진행
- 모델의 입력 자료는 SAR 영상 패치[128, 128, 2], 출력 값은 홍수 발생 변화 탐지 면적 [128, 128]으로 나타남
- 기존 U-Net은 단일 인코더를 사용하기 때문에 단일 크기의 Convolution 연산만 진행
- 반면, 본 연구에 사용된 모델은 3by 3, 5 by 5, 3by 3 dilated의 커널 크기를 가지는 3가지의 인코더를 사용하여 충분한 양과 질의 특성 맵을 추출

- 이를 Concatenate 하여 디코더로 전달하여 세밀한 localization이 가능한 모델 도출
- 모델의 튜닝에 사용된 Hyperparameter는 optimizer는 Nadam, learning rate는 0.001에서 0.0001로 감소되게 하였고, 손실함수는 Categorical Crossentropy, Batch Size는 50, Epochs는 1000을 사용

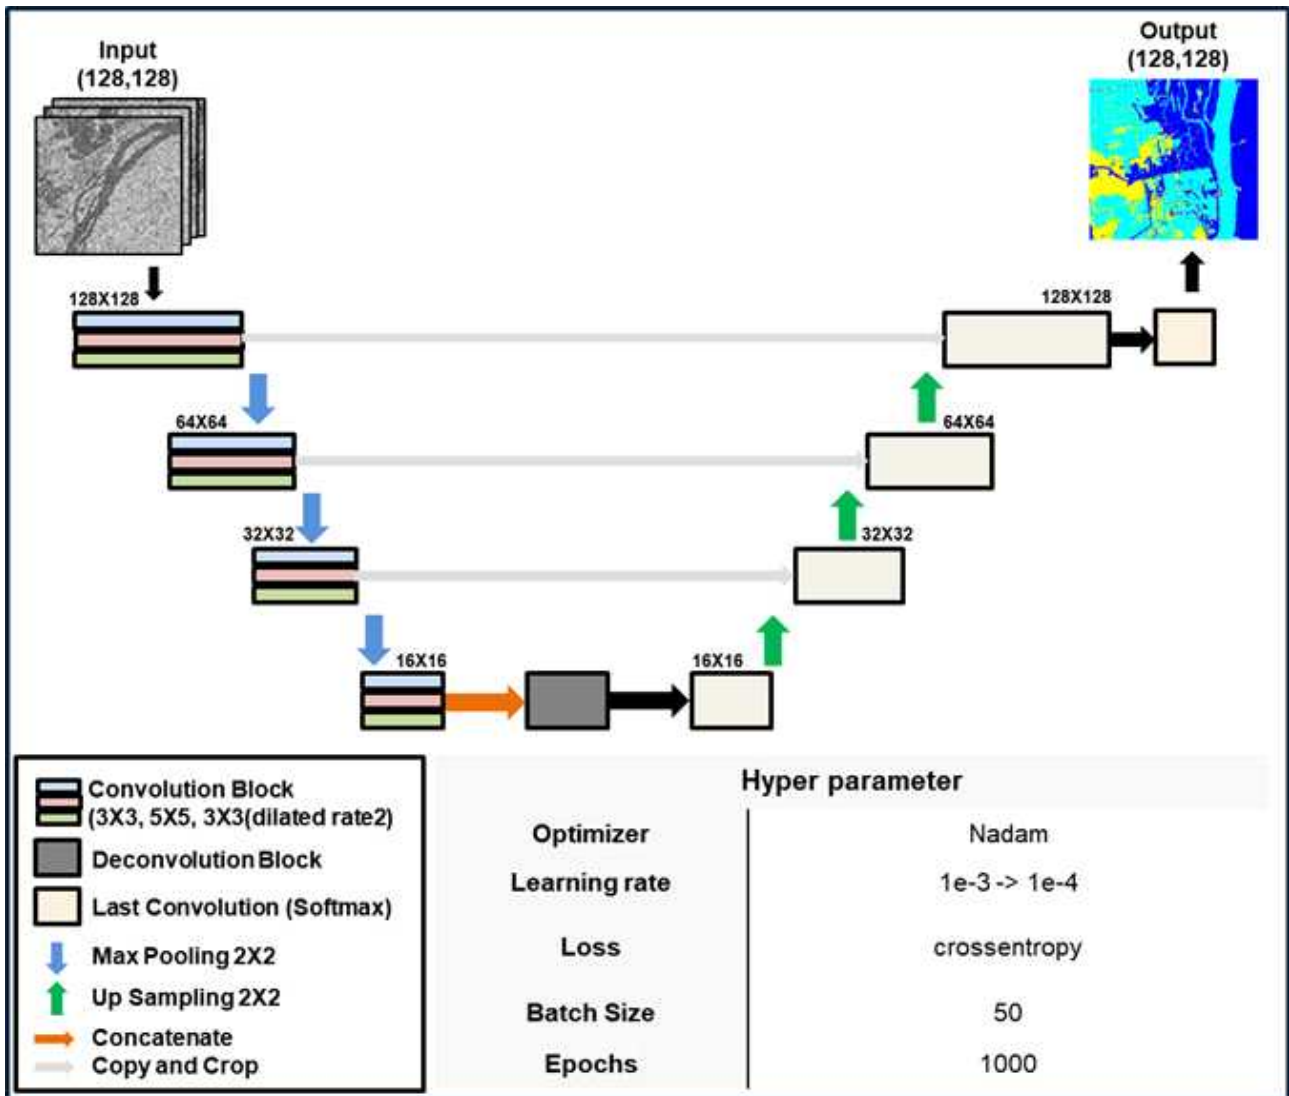


그림 13 Modified U-Net

d) 모델 성능 평가 및 결과 분석

- 학습 되어진 모델의 결과는 신중히 평가 및 분석 되어야 하므로 학습에 활용되지 않은 Test data를 활용하여 모델의 성능을 정량적으로 평가 (그림 14)
- Test data를 predict 하여 confusion matrix를 제작
- Confusion matrix를 통해 Precision, Recall, PR_curve 및 F1-score를 도출

- Precision은 학습된 모델에 의해 정답값으로 분류된 것 중 실제의 정답값 비율을 나타냄
- Recall은 실제 정답값 중 학습된 모델에 의해 정답값으로 분류된 비율
- PR Curve는 알고리즘 파라미터 조정에 대한 Precision 및 Recall값의 변화를 나타내는 그래프로 그래프 하단 면적을 통해 계산된 Average Precision 값을 통해 모델의 성능을 평가 그리고 F1 score는 Class 수가 불균형 할 때 더 정확한 모델 성능을 평가할 수 있음

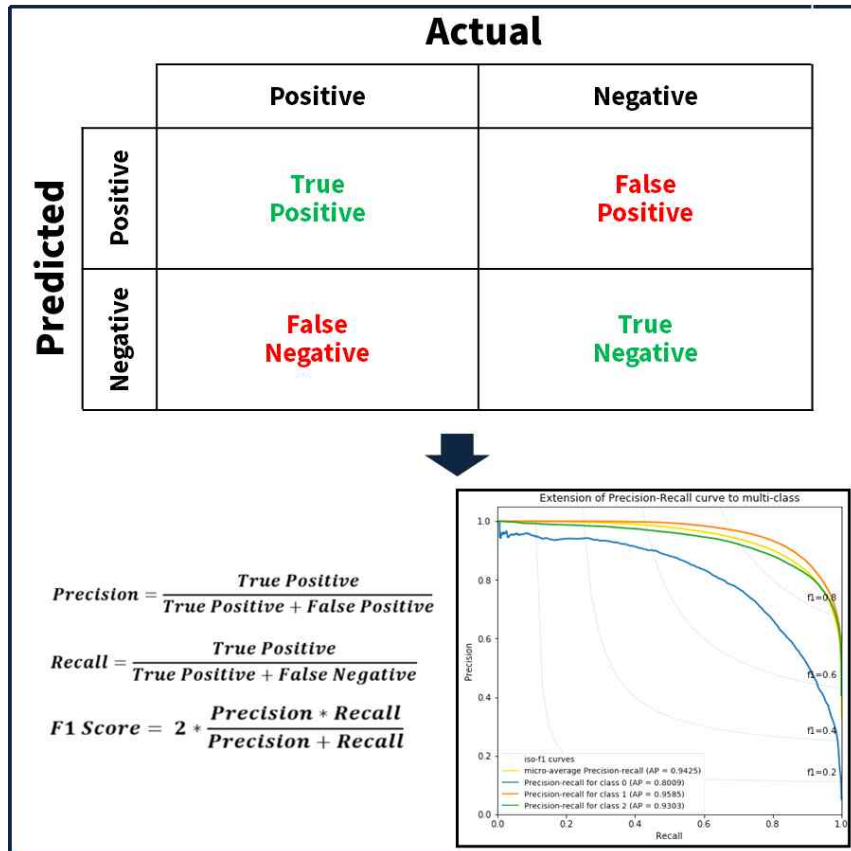


그림 14 정량적 성능 지표

4. 연구 결과

(1) 입력데이터 제작

- 그림15는 두 시기의 원본데이터 전처리를 통해 정규화된 Decibel 영상을 보여줌




그림 15 Raw 데이터(a,b) 와 최종 전처리 데이터(c,d)

- Decibel 영상과 원본 영상을 비교 했을 때, 값의 범위를 줄이고 표준화 함으로써 수계 영역과 비수계 영역에 대한 구분이 육안으로도 쉽게 구분 가능하며 이는 모델 학습하는데 있어서도 매우 효과적임

(2) 정답값 제작

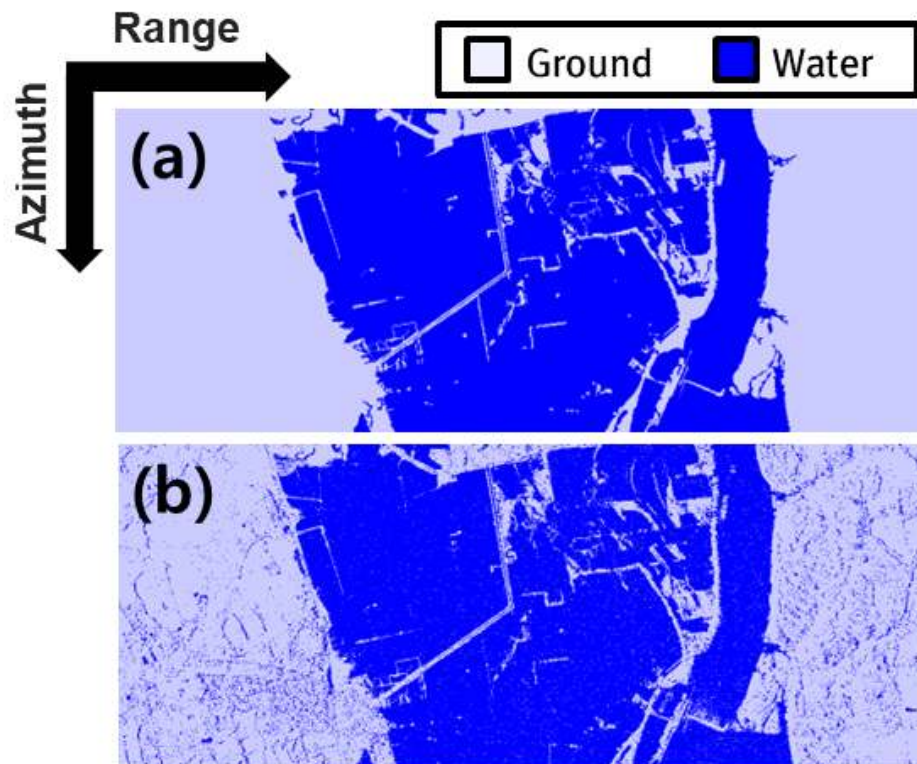


그림 16 정답값 영상 비교

- 그림16-(a) 직접 손으로 수계 및 비수계 영역을 어노테이션 한 영상이고 (b)는 ANN 모델을 통해 예측된 수계와 비수계 영역.
- 직접 어노테이션한 영역과 모델을 통해 예측된 영역의 큰 차이는 없으며 모델의 정확도는 94.7% 보임. 그러나 그림자와 Spckle noise로 인해 오분류된 픽셀들이 존재




그림 17 최종 수계 및 비수계 영역 : 홍수 발생 직후 시기의 모델을 활용한 1차 결과(a), 육안검수 후의 최종 결과(c); 홍수 발생 시간이 지난 이후 시기의 모델을 활용한 1차 결과(b), 육안검수 후의 최종 결과(d)

- 학습된 ANN 모델을 활용하여 전체 영상의 결과를 1차적으로 도출하였으며 2차적으로 오분류된 픽셀들을 육안검수를 통해 수정하여 최종 정답값(수계 및 비수계 영역)을 제작

(3) 모델 성능 평가 및 Inference 결과 비교 분석

- 앞서 학습된 모델을 Precision, Recall, PR_curve 그리고 F1-score를 통해 성능 평가

표 2 정량적 성능 평가 결과

Value	Ground to Ground	Water to Water	Ground to Water	Water to Ground	Total
Precision	0.986	0.995	0.934	0.917	0.958
Recall	0.997	0.947	0.929	0.962	0.959
F1-score	0.992	0.970	0.931	0.939	0.958
Accuracy	0.982				

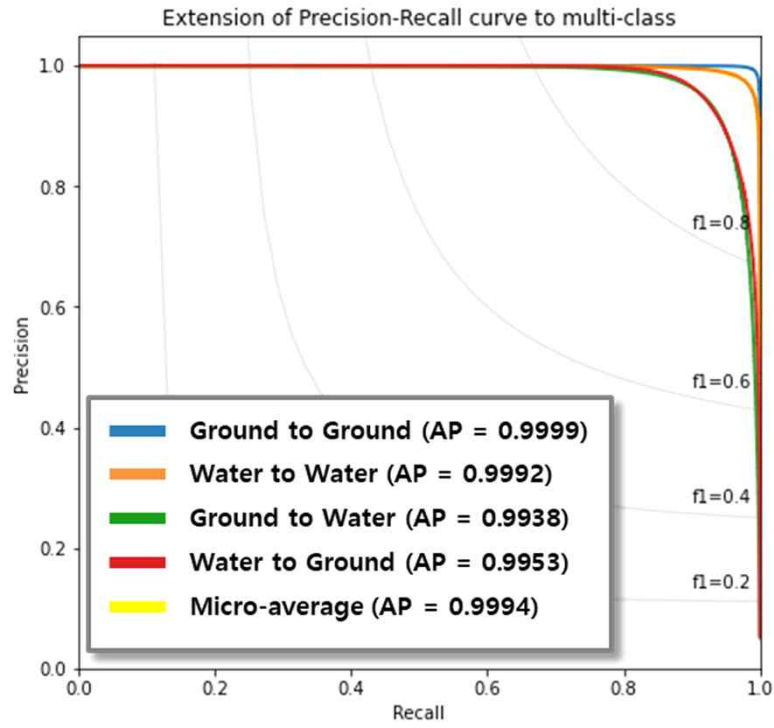


그림 18 모델의 PR_curve 결과

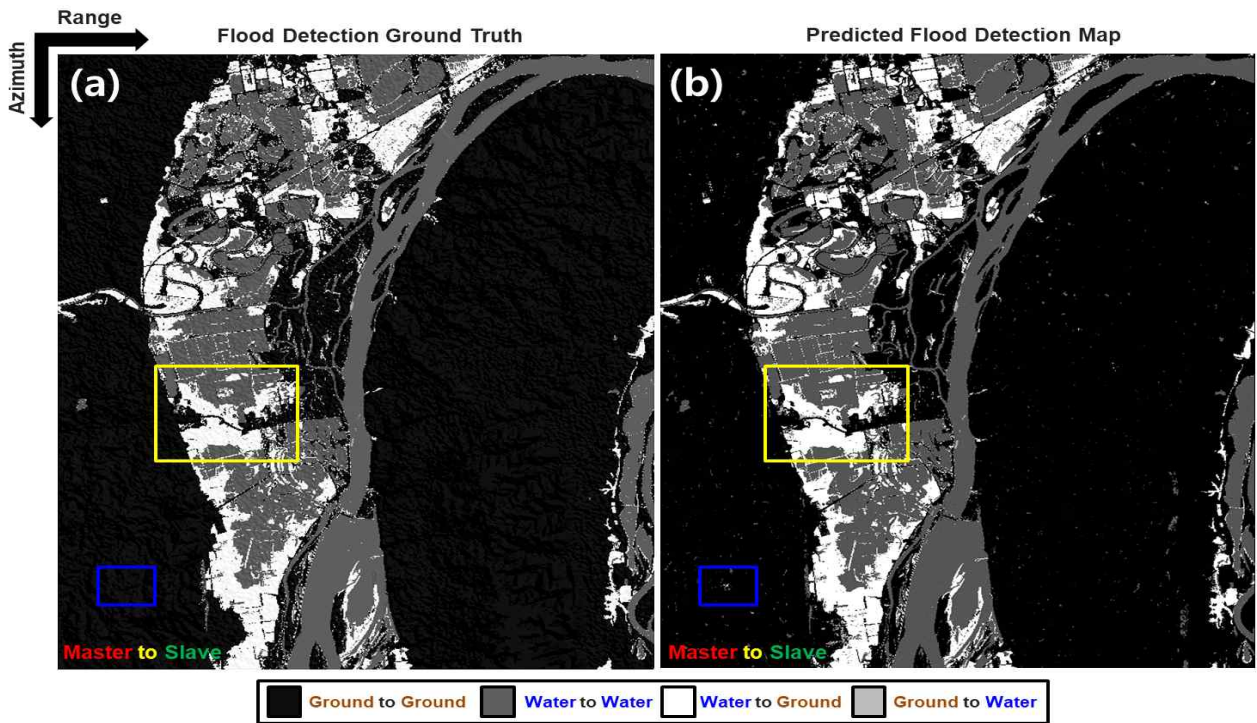


그림 19 시간 순 Inference 결과 비교 정답값(a), 모델 예측값(b)

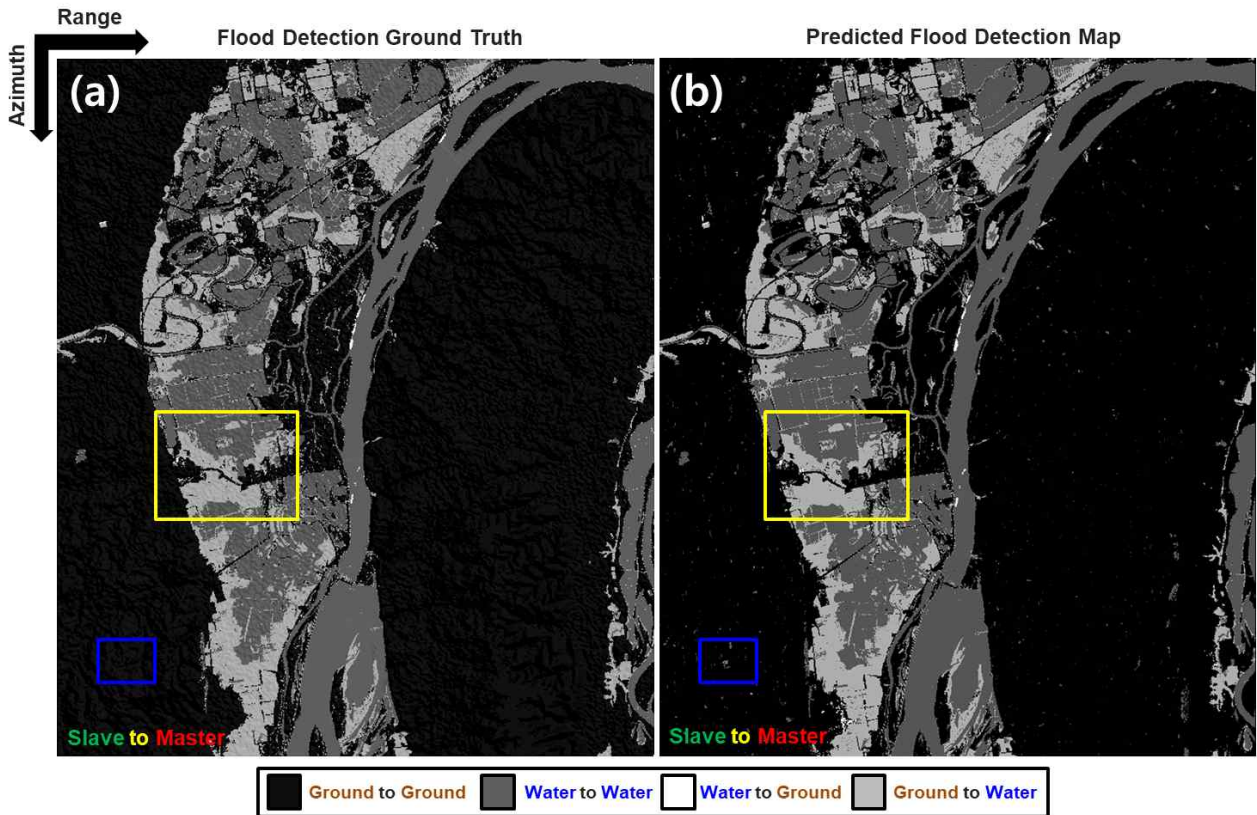


그림 20 시간 역순 Inference 결과 비교 정답값(a), 모델 예측값(b)

- 그림19-a는 시간 순(Master to Slave)으로 정답값 영상을 차분하여 제작한 영상이고, 그림19-b는 시간순으로 모델을 학습하여 수계에서 비수계를 탐지한 결과로 매우 유사한 경향을 보이지만 파란색 영역에 대해 오분류가 된 것을 확인
- 그림20-a는 시간 역순(Slave to Master)으로 정답값 영상을 차분하여 제작한 영상이고, 그림20-b는 시간 역순으로 모델을 학습하여 비수계에서 수계를 탐지한 결과 또한 매우 유사한 경향을 보이지만 파란색 영역에 대해 오분류가 된 것을 확인
- 그림21, 그림22은 시간역순(Slave to Master)으로 차분한 결과로써, 노란색 영역 및 파란색 영역을 확인해보면 자세히 확인 할 수 있음

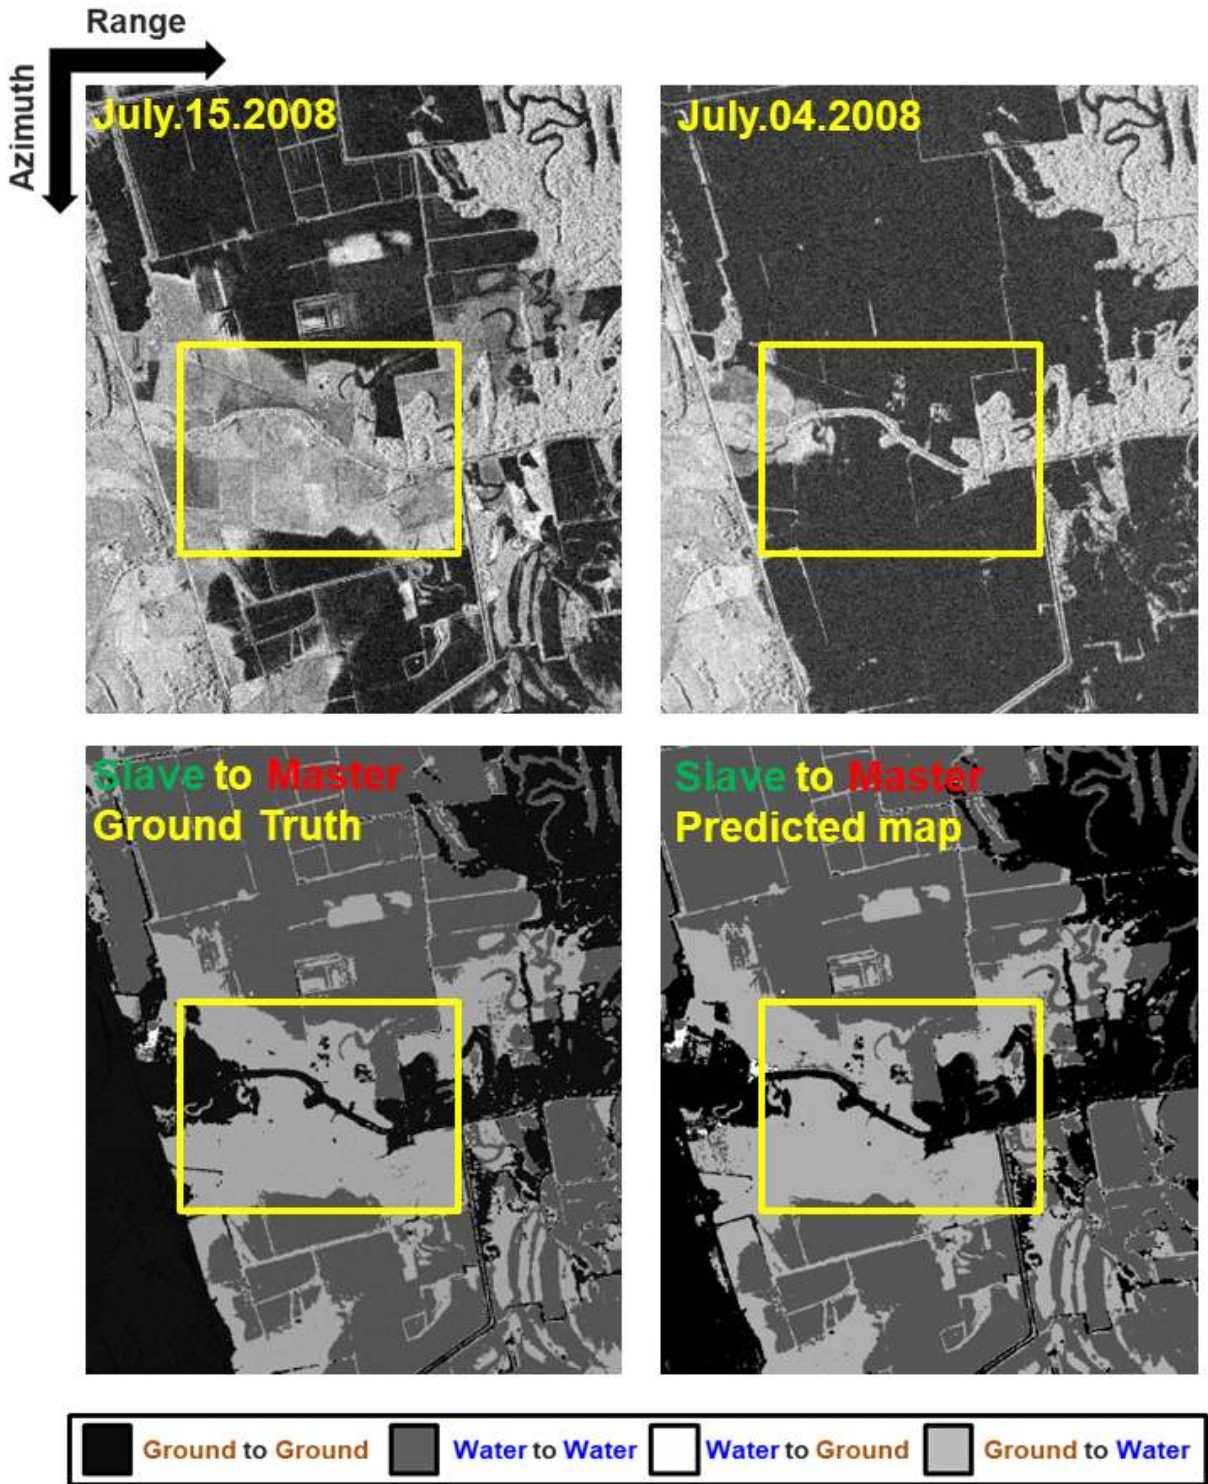


그림 21 두 시기의 위성 영상과 Ground truth 및 예측 결과 상세 분석(1)




그림 22 두 시기의 위성 영상과 Ground truth 및 예측 결과 상세 분석(2)

(4) 새로운 지역 선정 및 Inference 결과

- 추가적으로 Train 및 Test 데이터로 활용되지 않은 새로운 지역을 추가적으로 학습된 모델을 통해 Inference 실시
- 그림23의 파란색 영역은 새로운 지역을 나타냄

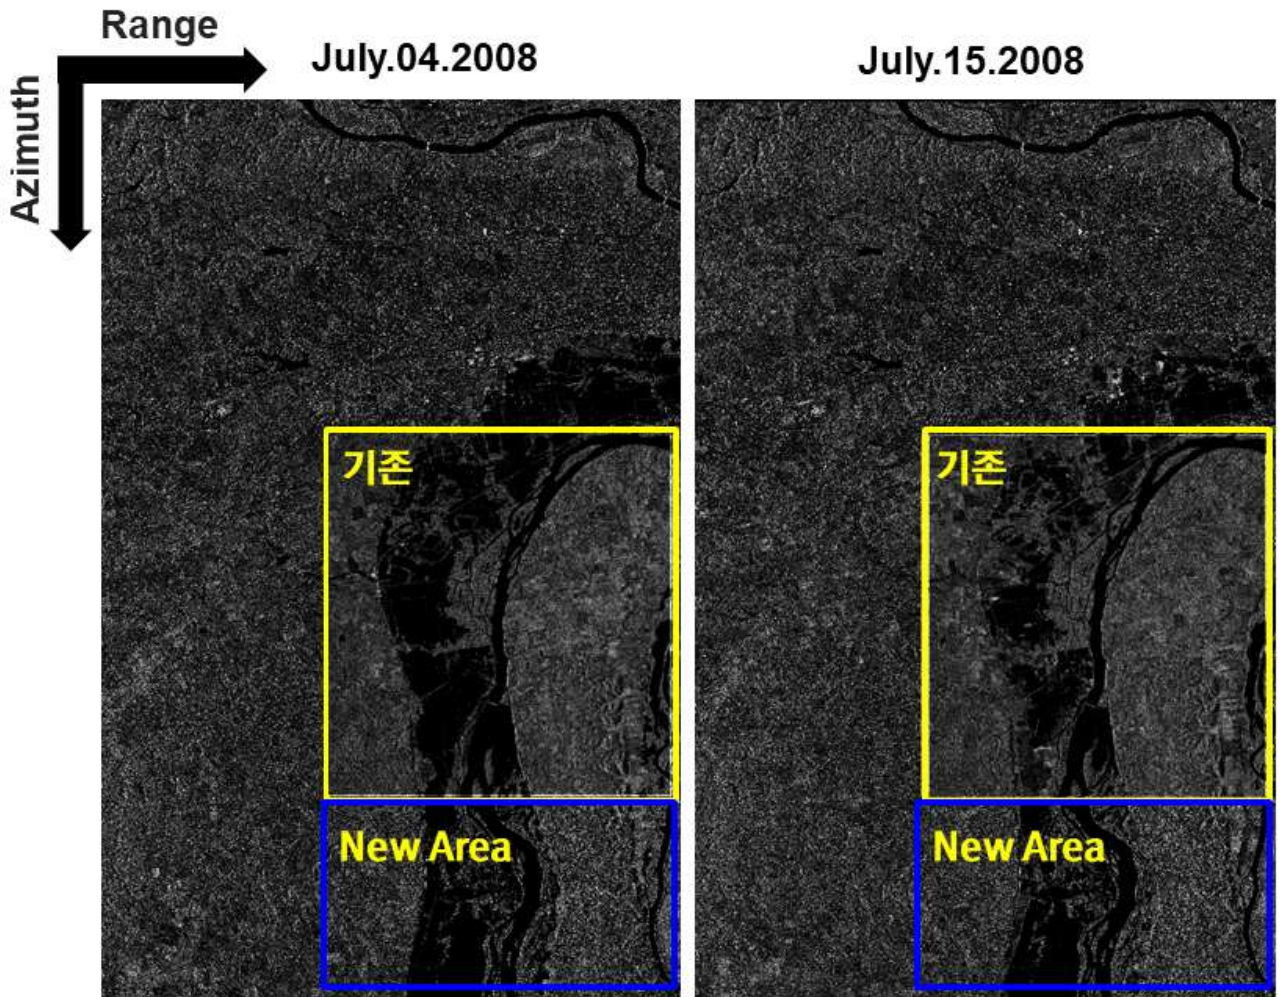


그림 23 기존 지역외의 새로운 지역

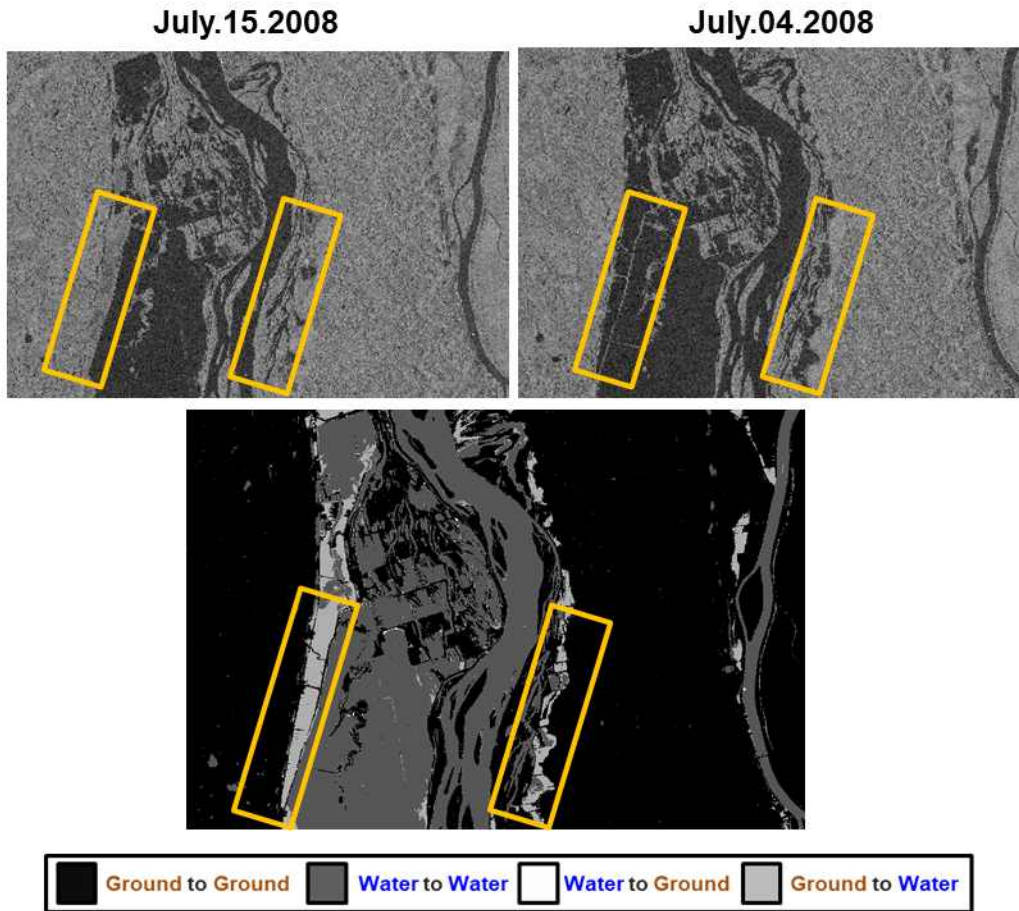


그림 24 새로운 지역에서의 추론 결과 및 분석

- 새로운 지역에 대한 예측 결과는 주황색 영역을 통해 확인 가능 (그림24)
- 학습 및 테스트에 사용된 이외의 지역에서도 홍수의 변화 탐지 면적이 잘 나타남

5. 활용방안 및 추후계획

- 해당 모델의 결과를 통해 빠른 홍수 피해 지역을 신속히 탐지 하여 인명 및 재산 피해를 최소화
- 추후 연구에서는 노이즈의 영향을 더 최소화할 수 있는 모델 구조를 도출해내고자 함
- 추가적인 시계열 자료를 활용하여 정량적으로 홍수가 자주 발생하는 지역 특정 및 해당 지역에 대한 홍수저감시설(하수관거 및 빗물저류시설) 설치 등 수해 예방 가이드라인 제시함으로써 절대적인 홍수 피해 저감에 기여
- 또한, KOMPSAT-5 와 같은 국내 위성 영상을 통해 홍수 변화 탐지 모델을 제작할 예정

이며 국내 위성 자산의 활용도를 높힐 수 있음

- 추후 연구에서는 위성 영상 및 학습의 결과물로 나온 홍수 변화 탐지 map과 빗물 저류 시설의 위치 및 홍수 관련 GIS 데이터를 추가적으로 활용하여 홍수 취약성도를 제작하고자 함

6. 참고문헌

- Baek, W.-K., Jung, H.-S., Kim, D., 2020, Oil Spill Detection of Kerch Strait in November 2007 from Dual-Polarized TerraSAR-X Image Using Artificial and Convolutional Neural Network Regression Models , Journal of Coastal Research, SI102, 137-144.
- Chae sung ho (2016). 지표변위 정밀 관측을 위한 위성레이더 오프셋트래킹 기법 향상. 서울시립대학교.
- EM-DAT, 2014. The OFDA/CRED International Disaster Database [online]. Available from: www.emdat.be/ [Accessed 1 Feb 2015].
- de MOEL, H., & Aerts, J. C. J. H. (2011). Effect of uncertainty in land use, damage models and inundation depth on flood damage estimates. Natural Hazards, 58(1), 407-425.
- Jo, M., Osmanoglu, B., & Jung, H. S. (2018). Detecting surface changes triggered by recent volcanic activities at Kīlauea, Hawai'i, by using the SAR Interferometric technique: Preliminary report. Korean Journal of Remote Sensing, 34(6_4), 1545-1553.
- Jung, H. C., Kim, S. W., Jung, H. S., Min, K. D., & Won, J. S. (2007). Satellite observation of coal mining subsidence by persistent scatterer analysis. Engineering Geology, 92(1-2), 1-13.
- Karl, T. R., Melillo, J. M., Peterson, T. C., & Hassol, S. J. (Eds.). (2009). Global climate change impacts in the United States. Cambridge University Press.
- Kiem, A. S., Franks, S. W., & Kuczera, G. (2003). Multi-decadal variability of flood

risk. *Geophysical Research Letters*, 30(2).

- Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234–241). Springer, Cham.
- Schumann, G.J.-P., Neal, J.C., Mason, D.C., and Bates, P.D. (2011), The accuracy of sequential aerial photography and SAR data for observing urban flood dynamics a case study of the UK summer 2007 floods, *Remote Sensing of Environment*, Vol. 115, No. 10, pp. 2536–2546.
- Zou, W., Li, Y., Li, Z., & Ding, X. (2009). Improvement of the accuracy of InSAR image co-registration based on tie points—a review. *Sensors*, 9(02), 1259–1281.
- 행정안전부, 2018, 「2018 재해연보」, 행정안전부