

SAR 이미지 분류 성능 향상을 위한 임계값 학습 모듈을 적용한 준지도 학습법

도재준 / 한국항공대학교 컴퓨터비전 연구실

본 논문에서는 준지도 학습법을 사용해 합성 개구 레이더(Synthetic Aperture Radar, SAR) 이미지 데이터 classification을 하는 방법을 제안한다.

데이터 획득과 라벨링이 힘든 SAR 이미지 데이터셋의 단점을 극복하기 위해 본 논문에서는 최신 성능(State Of The Arts, SOTA)을 달성한 준지도 학습법인 FixMatch를 SAR 이미지의 특성에 맞게 적용하며 생긴 변경사항에 대해 서술하고, FixMatch의 한계인 고정된 단일 임계값의 단점을 극복하기 위해 클래스별로 서로 다른 임계값을 학습 과정에서 자연스럽게 학습할 수 있는 새로운 방법인 임계값 학습 모듈을 제안한다.

SAR 이미지는 안테나가 이동하며 레이더파를 쏘고, 물체에 반사되어 되돌아오는 반사파를 연속적으로 수신하고 해상도를 높여 획득하는 이미지 데이터이다. SAR 이미지 데이터는 안테나가 스스로 레이더파를 쏘고 수신하기에 빛이 필요없어 밤낮 관계없이 획득이 가능한 이미지 데이터이다. 또한, 이미지 데이터 획득에 사용하는 레이더파는 가시광선 영역이 아닌 마이크로파 영역의 파장이라 구름 등을 투시할 수 있어 날씨에 관계없이 이미지 데이터를 획득할 수 있다는 장점이 있다.

하지만 눈으로 쉽게 식별이 가능한 광학 이미지 데이터들과는 달리 레이더 이미지 데이터의 특성상 물체 표면에 따라 난반사가 심해 노이즈가 생기거나 광학 이미지에서 생기지 않는 왜곡이 생기는 경우가 많아 사람이 한 눈에 알아보고 분석하기가 쉽지 않다.

본 논문에서는 RGB 이미지 분류 데이터셋에서 SOTA를 달성한 FixMatch를 SAR 이미지 분류에 최적화시켜 사용하였다. FixMatch는 고정된 단일 임계값을 이용해 pseudo labeling을 진행하는데, 이는 데이터셋의 각 클래스별 특징을 무시할 수 있으며, 이는 모델 학습 성능을 저하시키는 원인이 된다. 따라서 클래스별로 서로 다른 임계값을 학습하는 임계값 학습 모듈을 추가하였다.

기존의 FixMatch는 RandAugment 방식을 적용해 strong augmentation을 한다. RandAugment는 이미지를 왜곡시키고 변형시키는 이동, 뒤집기, 비틀기, 색 변환 등의 여러 방법들을 모아놓고 랜덤하게 몇 가지를 선택해 적용을 하는 방식으로 FixMatch가 원래 사용했던 RGB 이미지 데이터셋에는 효과적인 증강 방법이다.

하지만 본 논문에서 사용하는 SAR 이미지 데이터는 RGB 이미지 데이터와는 특성이 다르다.

졸업논문 소개

RGB 이미지 데이터와는 달리 SAR 이미지 데이터는 편광 레이더를 사용하여 이미지 자체에 방향성(orientation) 정보가 포함된다. 그렇기에 좌우로 뒤집을 수는 있어도 상하로 뒤집을 수는 없다. 또한 색이 없는 흑백의 이미지에 가깝기에 색을 바꾸지 못하는 등의 다양한 제약조건들이 있다. 따라서 본 논문에서는 SAR 이미지 데이터들을 증강 시, RandAugment 대신 weak augmentation에 사용되는 resize와 horizontalflip에 추가로 speckle noise를 적용하여 strong augmentation을 사용한다.

Pseudo labeling 단계에서 고정된 단일 임계값을 사용하는 FixMatch의 방식은 학습의 처음부터 끝까지 같은 값의 임계값을 사용한다. 학습이 충분히 되지 않은 모델 학습의 초기 단계에서는 pseudo labeling 과정에 weak augmentation으로 생성된 이미지 데이터들의 예측 결과의 정확도가 대부분 임계값을 넘기에 충분하지 않다. 그래서 학습 초기에는 활용되지 못하고 버려지는 데이

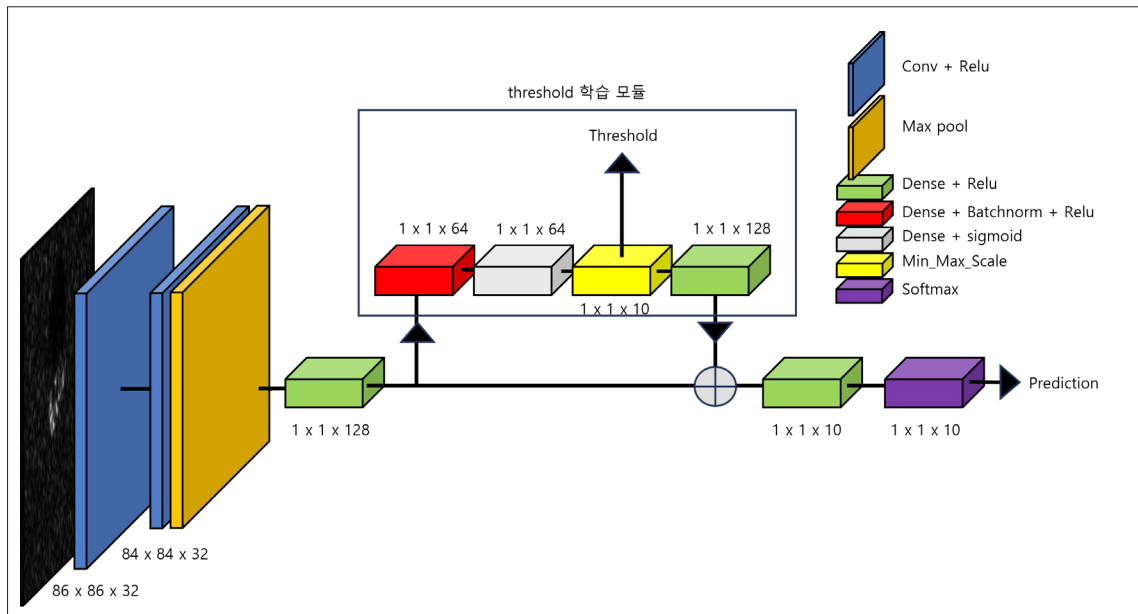
터들이 많을 뿐만 아니라 학습 효율 또한 저하된다. 이러한 한계점을 극복하고자 본 논문에서 임계값 학습 모듈을 제안한다.

임계값 학습 모듈은 학습 모델이 학습 과정에서 데이터들을 학습하며 모델이 class별로 서로 다른 임계값을 학습하여 도출하도록 해주는 모듈로 이러한 문제점을 극복하게 만들어 준다.

임계값 학습 모듈은 ResNet에서 소개된 Residual block처럼 모델의 옆에 붙일 수 있는 모듈의 형태를 취하

<표 1> 임계값 학습 모듈의 구조

Layer	Input Shape	Output Shape
Dense 1	B x 128	B x 64
Batchnorm	B x 64	B x 64
ReLu	B x 64	B x 64
Dense 2	B x 64	B x 10
Sigmoid	B x 10	B x 10
Min_Max_Scale	B x 10	B x 10
Dense 3	B x 10	B x 128
ReLu	B x 128	B x 128



<그림 1> 임계값 학습 모듈을 적용한 전체 네트워크

고 있다. 임계값 학습 모듈의 구조를 <표 1>에서 볼 수 있다. <표 1>에서 B는 batch의 수이다.

임계값 학습 모듈에서 Min_max_scale Layer는 임계값 학습 모듈의 핵심이다. 임계값 학습 모듈에서 Sigmoid를 통과한 feature는 min_max_scale layer를 통과하여 임계값이 된다. 임계값은 Dense 3 layer를 거쳐 feature가 되어 본래의 학습 모델에 합쳐져 임계값을 학습하는데 영향을 끼친다. Sigmoid를 통과한 output은 모든 값을 최소값과 최대값 사이로 정규화를 시켜 임계값을 얻을 수 있다. 본 논문에서는 최소값을 0.8로 최대값을 1로 두었다. 임계값 학습 모듈은 <그림 1>에서 확인할 수 있다.

기존의 RGB 데이터셋을 대상으로 하는 FixMatch는 wide ResNet-28-2 모델을 backbone으로 사용하였다. 하지만 우리가 실험에 사용한 MSTAR 데이터셋을 학습하기에 wide ResNet-28-2 모델은 너무 크고 무거운 모델이라 C.Coman이 제시한 모델을 backbone으로 사용한다. <표 2>에서 backbone의 구조를 확인할 수 있다.

<표 2> Backbone의 구조

Layer	Input shape	Kernel	Output shape
Conv2D 1	88 x 88 x 1	3 x 3	86 x 86 x 32
Conv2D 2	86 x 86 x 32	3 x 3	84 x 84 x 32
MaxPool	84 x 84 x 32	2 x 2	42 x 42 x 32
Dropout	42 x 42 x 32	0.25	42 x 42 x 32
Flatten	42 x 42 x 32	1	56448
Dense 1	56448	1	128
Dropout	128	0.25	128
Dense 2	128	1	10

본 논문에서 제시한 준지도 학습법을 실험하기 위해 사용한 SAR 이미지 데이터셋은 MSTAR 데이터셋이다. MSTAR 데이터셋은 탱크, 장갑차, 트럭과 불도저 등을 포함한 10여 개의 클래스(BMP-2, BRDM-2, BTR-60, BTR-70, T-62, T-72, 2S1, ZSU-234, ZIL-131, D7)로 이루어져 있다. MSTAR 데이터셋은 구하기 힘든 SAR 이미지

classification 분야에서 흔히 쓰이는 데이터셋으로 전체 학습 데이터는 3671장이고, 테스트 데이터는 3203장이다.

성능 비교 실험에 사용한 데이터는 전체 학습 데이터 3671장의 20%와 50%만을 사용하고 input 이미지 데이터의 크기를 88 x 88, 44 x 44로 resize하여 결과 비교를 하였다. 비교한 결과는 <표 3>과 <표 4>에서 확인할 수 있다.

비교한 결과의 Baseline은 backbone만을 사용하여 지도 학습을 사용한 결과이고, FixMatch는 임계값 학습 모듈을 적용하지 않은 결과이다. 마지막으로 FixMatch + Ths는 임계값 학습 모듈이 적용된 FixMatch이다.

본 논문에서는 RGB 이미지에서 SOTA를 달성한 FixMatch를 SAR 이미지 데이터에 맞게 적용한 후, 클래스별로 서로 다른 임계값을 모델 학습 과정에서 얻을 수 있도록 구성한 SAR 이미지 classification 준지도 학습법에 대해 서술하였다. SAR 이미지 데이터의 특성을 반영하지 못하는 기존의 FixMatch를 SAR 이미지 특성을 반영하도록 speckle noise를 사용하도록 strong augmentation 방식을 바꾸고 backbone을 바꿔 1차적으로 성능이 향상되는 것을 확인하였다. 하지만 FixMatch는 고정된 단일 임계값을 사용한다는 한계가 있어 한계 극복을 위해 학습 과정에서 모델이 자연스럽게 클래스별로 서로 다른 임계값을 학습하는 임계값 학습 모듈이라는 개념을 제시하여 성능이 올라가는 것을 확인하였다.

임계값 학습 모듈을 추가하는 경우, 학습을 하는 과정에서 학습 모델이 임계값을 학습하여 클래스별로 서로 다른 임계값을 얻어 좀 더 유연한 학습이 가능하도록 해 클래스 간의 데이터 불균형을 해결하고 학습 효율을 해결하였다.

기존에도 고정된 단일 임계값이 가져오는 한계를 극복하고자 학습 과정에 임계값이 계속 변하거나 클래스별로 서로 다른 임계값을 가지도록 하는 연구들은 존재하였다. 다만 그 연구들은 수식을 사전에 정의하여 임계값을 계산

졸업논문 소개

하는 수동적인 방법들이었다.

임계값 학습 모듈은 수동적인 방식이 아닌 학습 과정에서 모델이 능동적으로 임계값을 학습하는 새로운 방법이다.

본 논문에서 제시한 임계값 학습 모듈의 한계는 SAR 이미지 데이터셋에만 치중되었다는 점과 C.Coman의 모델에만 적용을 하였다는 점이다. 이를 개선하기 위해 다른 backbone 모델로 SAR 이미지 데이터셋인 MSTAR 데이터셋뿐만 아니라 RGB 이미지 데이터셋인 CIFAR-10이나 STL-10 같은 데이터셋으로도 연구를 진행할 수 있을 것이다.

본 논문의 연구를 SAR 이미지 데이터셋이 아닌 다른 데이터셋으로도 확장하여 연구를 진행한다면 학습 과정에

들어오는 데이터에 따라 클래스별로 서로 다른 임계값을 얻는 유연한 새로운 방법을 발견할 수 있을 것이다.

<표 3> 88 x 88의 실험 결과

비교군 \ Accuracy	20%	50%
Baseline	83.51%	91.99%
FixMatch	87.23%	94.05%
FixMatch + Ths	88.14%	94.86%

<표 4> 44 x 44의 실험 결과

비교군 \ Accuracy	20%	50%
Baseline	83.82%	91.22%
FixMatch	84.39%	92.26%
FixMatch + Ths	86.13%	92.47%



도 재 준

- 2022년 2월 : 한국항공대학교 소프트웨어학과 학사
- 2024년 2월 : 한국항공대학교 인공지능학과 석사
- 주관심분야 : 컴퓨터비전, 인공지능