

석사학위논문

임베디드 시스템에서 초분광 이미지
전처리를 위한 효율적인 밴드 선택 기법

2022년

한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

장 두 혁

석사학위논문
지도교수 허준영

임베디드 시스템에서 초분광 이미지 전처리를 위한 효율적인 밴드 선택 기법

Efficient Band Selection for Hyperspectral Image
Preprocessing in Embedded Systems

2021년 12월 일

한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

장 두 혁

석사학위논문
지도교수 허준영

임베디드 시스템에서 초분광 이미지 전처리를 위한 효율적인 밴드 선택 기법

Efficient Band Selection for Hyperspectral Image
Preprocessing in Embedded Systems

위 논문을 공학 석사학위 논문으로 제출함

2021년 12월 일

한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

장 두 혁

장두혁의 공학 석사학위 논문을 인준함

2021년 12월 일

심사위원장 황 호 영 (인)

심 사 위 원 허 준 영 (인)

심 사 위 원 김 진 모 (인)

국 문 초 록

임베디드 시스템에서 초분광 이미지 전처리를 위한 효율적인 밴드 선택 기법

한 성 대 학 교 대 학 원
컴 퓨 터 공 학 과
컴 퓨 터 공 학 전 공
장 두 혁

초분광 이미징 기술은 연속적인 스펙트럼 필터의 결과로 수백 개의 분광 채널(밴드)을 영상정보로 도출하는 기술이다. 원격탐사의 활용 시초로 기존 10개 미만의 스펙트럼 밴드 다분광 센서가 장치 소형화 및 분석 기술 발달에 따라, 현재는 100~200개 정도의 스펙트럼 밴드로 확장되었다. 또한 환경, 국방, 의료, 식품, 머신 비전 등 다양한 분야에 활용되고 있다. 본 연구를 통해 대상 물체에 대한 고유한 분광 반사 특성을 이용하여 화소 구성 비율을 분석하는 분광 혼합분석(Spectral Unmixing) 방식 중 차원 감소(Dimension Reduction) 방식을 사용한다. 차원 감소 방식의 밴드 선택 알고리즘을 개선해 신경망(Neural Network) 인풋으로 모델 학습한다. 학습된 모델을 가지고, 임베디드 시스템(Embedded System)에서 제안 밴드 선택 알고리즘 적용 여부에 따른 전력 소모를 비교하며, 전력 소모를 최소화하는 개선 및 성능 감소 최소화를 목적으로 한다. 특정 정보 추출을 위해, 미가공 데이터를 각 밴드별 최댓값과 최솟값 차이로 이산적인 값을 생성해 부분집합으로 군집화한다. 분류

된 부분집합에서 밴드 선택 알고리즘을 적용한다. 차원 감소 방식은 크게 특징(밴드) 추출과 특징(밴드) 선택으로 나뉘며, 그중에 특징 선택 기법을 적용하여, 파장 범위와 관계없이 데이터 세트에 따른 딥러닝, 머신러닝 분석을 위한 최소 밴드 수와 밴드 선택 알고리즘 적용 소요 시간과 성능을 향상하고자 한다. 이 실험을 통해 기존 밴드 선택 기법보다 약 77~92% 크게 소요 시간을 단축했음에도 불구하고 분류기를 통한 성능 정확도 감소 폭이 적은 의미 있는 결과를 도출하였다. 더 나아가 세그멘테이션(Segmentation) 모델 중 UNet에 제안 알고리즘 적용하고, 사후 학습 양자화 기법(Post-training Quantization)으로 입력 데이터 비트를 변환한다. 모델 첫 인풋 데이터 타입과 Contracting Path에서 Expansive Path으로 인풋으로 들어가는 skip connection의 데이터 타입을 Float64에서 Float16으로 스케일링한다. 결과적으로, 모델 크기를 약 12MB에서 2MB로 경량화하여, 모델 크기 83% 감소와 모델 추론 성능까지 다시 5~6% 올리는 실험을 진행했다. 또한, 본 논문에서 제안한 밴드 선택 알고리즘이 적용된 모델이 픽셀별 밴드에 따른 클래스 분포가 넓을수록 경량화에 따른 성능 향상 정도가 높아지는 것을 확인했다.

【주요어】 밴드 선택, 초분광 이미지 처리, 픽셀 분류, 풀링 연산, 사후 학습 양자화, 경량화

목 차

제 1 장 서 론	1
제 1 절 초분광 이미지 기술 동향	1
제 2 절 연구 내용	3
제 2 장 관련 연구	4
제 1 절 밴드 선택 기법	4
1) 시뮬레이티드 어닐링	4
2) 상호 정보량	6
제 2 절 밴드 추출 기법	7
1) 주성분 분석 기법	7
제 3 절 폴링 연산과 컨볼루션 연산	9
1) 맥스 폴링 연산	9
2) 컨볼루션 연산	11
제 3 장 제안 기법	12
제 1 절 제안 알고리즘	12
제 2 절 모델 설계	13
1) K-최근접 이웃 분류기	13
2) U-Net 모델	15
3) 데이터 세트	18
4) 데이터 세트 분석	19
제 3 절 양자화 기법	20
1) 사후 학습 양자화	21
2) 양자화 인식 훈련	22

제 4 장 실 험	24
제 1 절 실험환경	24
제 2 절 제안 알고리즘 결과	
1) 제안 알고리즘 결과	26
제 3 절 K-최근접 이웃 분류기 평가	27
1) K-최근접 이웃 분류기 평가	27
제 4 절 세그멘테이션 딥러닝 모델 성능평가 & 양자화 적용비교	29
1) 알고리즘 미적용 밴드에 대한 U-Net 모델 성능평가	29
2) 제안 기법 적용된 밴드에 U-Net 모델 성능평가	30
3) 사후 양자화 기법 세그멘테이션 딥러닝 모델 변환 적용	31
제 5 장 결 론	34
참 고 문 헌	36
ABSTRACT	40

표 목 차

[표 1-1] 초분광 이미지 사용 대역	2
[표 4-1] 딥러닝 구성 기준	24
[표 4-2] 세그멘테이션 패치된 데이터 세트 구성	25
[표 4-3] 데이터세트 구성	25
[표 4-4] 제안 알고리즘 결과	26
[표 4-5] Pavia Centre 데이터 라벨별 성능 스코어	28
[표 4-6] 밴드 선택 알고리즘 적용 유무에 따른 사후 훈련 양자화 적용에 따른 모델 크기 경량화 비교	33

그림 목 차

[그림 2-1] 시뮬레이티드 어닐링.	6
[그림 2-2] 주성분 분석 기법 2차원 데이터 예시.	9
[그림 2-3] 주성분 분석 기법으로 PC1(좌)과 PC2(우)에 대한 예시.	10
[그림 2-4] 풀링 연산 계산 과정 예시.	11
[그림 3-1] 전처리 과정으로 적용되는 밴드 선택 알고리즘.	12
[그림 3-2] 밴드 선택 알고리즘 적용 방식.	13
[그림 3-3] 유클리드 거리 시각화.	14
[그림 3-4] 맨해튼 거리 시각화.	15
[그림 3-5] K-NN알고리즘 순서(좌) > 우).	15
[그림 3-6] U-Net Contracting Path와 Expansive Path 구조.	17
[그림 3-7] Indian Pines, Pavia Centre 의 Groud Truth.	18
[그림 3-8] 밴드에 따른 픽셀별 클래스 그래프(IP 와 PC).	19
[그림 3-9] 부동 소수점에서 고정소수점으로 변환.	20
[그림 3-10] Quantization term image.	21
[그림 3-11] 밴드 선택 알고리즘 적용 &사후 훈련 양자화 방식 적용 흐름.	23
[그림 3-12] uint8 VGG16모델 누적 전력 및 추론 시간 분석.	23
[그림 3-13] float32 VGG16 모델 누적 전력 및 추론 시간 분석.	24
[그림 4-1] 밴드 선택 알고리즘 적용 시간 비교.	26
[그림 4-2] 밴드 선택 알고리즘과 기존 휴리스틱 알고리즘 및 밴드 선택 미 적용 분류기 성능 비교.	27
[그림 4-3] 밴드 선택 알고리즘 및 밴드 선택 미적용 분류기 예측 결과. ·	28
[그림 4-4] 밴드 선택 알고리즘 미적용 분류기 성능과 손실 그래프(IP). ·	29
[그림 4-5] 밴드 선택 알고리즘 미적용 분류기 성능 과 손실 그래프(PC). 30	30
[그림 4-6] 밴드 선택 알고리즘 적용 분류기 성능과 손실 그래프(IP).	31
[그림 4-7] 밴드 선택 알고리즘 적용 분류기 성능 과 손실 그래프(PC). ·	31
[그림 4-8] 밴드 선택 알고리즘 적용 여부에 따른 사후 훈련 양자화 적용에 따른 성능 비교.	32

수 식 목 차

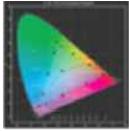
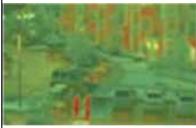
[수식 2-1] 시뮬레이티드 어닐링 함수 수식.	4
[수식 2-2] 변수 X 의 엔트로피 수식.	6
[수식 2-3] 상호 정보량 수식.	7
[수식 2-4] 상호 정보량과 엔트로피의 관계.	7
[수식 2-5] 풀링 연산 출력 크기 수식.	10
[수식 3-1] 유클리드 거리 수식.	14
[수식 3-2] 맨해튼 거리 수식.	14
[수식 3-3] pixel-Wise Softmax 함수 & Cross-Entropy Loss함수.	16

제 1 장 서론

제 1 절 초분광 이미지 기술 동향

초분광 이미지 처리는 공간 정보에 분광 기술을 통해 전자기파의 스펙트럼에 따른 영상정보를 초분광 큐브 형태로 구성하여 대상체의 상태, 특징 분광 정보를 나타내는 기술이다(김거식, 2021). 초분광 이미지 처리 기술이 원격탐사의 활용 시초로 10개 미만의 스펙트럼 밴드 다분광 센서가 현재는 100~200개 정도의 스펙트럼 밴드로 확장되었으며, 장치 소형화 및 분석 기술이 발달함에 따라 환경, 국방, 의료 식품 머신 비전 등 다양한 분야에 적용되고 있다. 최근 시장 자료에 의하면, 2020년부터 2024년까지 예측했을 때 높은 성장률을 보일 것으로 기대된다(Ha, R., 2014). 초분광 이미지 처리의 데이터 습득 형태로 공간 스캐닝과 스펙트럼 스캐닝 방식으로 분류된다. 공간 스캐닝 방식은 영역을 동시에 한 평면상에 공간적으로 스캔하며 들어온 분광 데이터를 좌표에 맞게 대응하는 방식이다. 스펙트럼 스캐닝 방식은 일반적으로 광학 대역 통과 필터를 통해 파장을 변화시키면서, 플랫폼이 고정되어있는 동안 하나의 필터를 차례로 교환하여 측정 영역 장면을 스펙트럼으로 스캔한다. 스펙트럼 대역은 초분광 카메라의 응용 분야를 결정하는 주요한 분류 기준인데 범위에 따라 UV(200~400nm), VIS(400~600nm), NIR(700~1100nm), SWIR(1.1~2.5 μ m), MWIR(2.5~7 μ m)로 구분된다(김거식, 2021). 밴드 수에 따라 10개 이하이면 다분광 이미지 처리, 10개 이상이면 초분광 이미지 처리, 100개 이상이면 극 초분광 이미지 처리로 분류할 수 있다(이문섭, 2019). 주로 식품 분야에서는 500nm~1000nm 대역에서 이미지 데이터 회귀 분석을 통해 성숙도나 안전성 검사에 활용되고 있으며, 의료 및 헬스케어 분야에서는 450nm~ 950nm 대역으로 소장과 피부암 종양 검출 등 다양한 진단에 연구에 적용되고 있다.

[표 1-1] 초분광 이미지 사용 대역(이문섭, 2019)

UV	VIS	VIS/NIR	SWIR	MWIR
				
미네랄 법 과학	색깔 측정 식물 색깔 출력	의료/헬스케 어 음식 원격탐사 농업	폴리머 음식 화학/국방 나무	화학 미술 가스 국방

초분광 큐브에서 공간상의 픽셀은 대상에 따른 반사율을 통해 혼합되어 표현되며, 이를 분광 혼합이라고 한다. 분광 혼합분석 기법은 하나의 픽셀이 분광 센서에서의 분광 해상도 수치가 낮아 각각 물질에서 나온 스펙트럼이 개별 스펙트럼의 합으로 표현되는 것을 분광 반사 특성을 활용하여 물질의 비율을 분석하는 방법이다. 그 비율을 구성하는 엔드멤버(Endmember)을 찾는 것이 중요하다. 분광 혼합분석 기법은 크게 3가지로 분류되는데 차원 감소(Dimension Reduction), 엔드멤버 탐지(Endmember Detection), 풍도 추정(Abundance Estimation)으로 이루어진다. 점차 딥러닝 기술의 발달로, 초분광 이미지 분석에 적용함으로써 분광 공간 분류와 분광 혼합분석, 학습데이터를 합성 및 생성으로 초분광 데이터를 분석할 수 있다. 분류와 군집화, CNN(Convolutional Neural Network)기반 분류기를 통해 초분광 데이터를 분류할 수 있다(Lorenzo, P. R., 2020).

제 2 절 연구 내용

초분광 이미지 분광 혼합분석 기법 중 차원 감소를 활용해서 밴드 선택을 진행한다. 차원 감소 방식으로, 크게 특징 추출(Feature Extraction), 특징 선택(Feature Selection)으로 나뉜다. 초분광 이미지는 밴드를 단위로, 밴드 선택(Band Selection)으로 호칭한다. 밴드 선택 알고리즘 분야에서는, 주로 선행 연구로 밴드 수를, 측정 시 초분광 카메라 사양에 따른 알고리즘 연구, 다양한 물체 적용에 대한 일반성 등을 다룬다.

모든 밴드를 딥러닝, 머신러닝 분석에 있어 임베디드 시스템 환경에서 입력값으로 사용하기에 비효율적이므로 차원 축소 방식을 적용한다. 특징 추출 방식을 적용 시 측정 대상에 대해 특정 스펙트럼 영역에 잘 검출되는지 기기에서 판단이 어려우며, 기존 밴드 선택 기법으로 성능은 높게 나오지만, 알고리즘 적용 시간이 상당히 소요된다(장두혁, 2021). 이를 개선하기 위해, 본 연구에서는 초분광 데이터 분석에 반드시 필요한 밴드를 구성하는 알고리즘을 개선한다. 모든 밴드를 최댓값과 최솟값의 차이별로 군집화하여, 부분집합의 분류 기준으로 전체 밴드들을 부분 집합(Subset)별로 분류한다. 분류된 부분집합에서 분석을 위한 최소 밴드를 선택하여 구성하는 방법으로, 파장에 무관한 초분광 이미지 픽셀 분류를 위한 알고리즘을 제안한다.

본 논문은 2장에서 관련 연구인 메타 휴리스틱 기법을 통해 밴드선택 기법과 밴드추출 대표적인 방법론에 대해서 알아본다. 3장에서는 본 논문에서 제시하는 제안 기법 및 양자화(Quantization)와 모델 설계 등을 설명한다. 4장에서는 본 논문에서 제안 알고리즘에 대한 실험과 성능에 관한 결과 및 분석을 제시하고, 마지막으로 5장에서는 향후 연구와 결론을 제시하는 것으로 논문을 마무리한다.

제 2 장 관련연구

제 1 절 밴드 선택 기법

1) 시뮬레이티드 어닐링

Simulated Annealing(SA)은 Kirkpatrick 등이 처음 제안했다. 이 방법은 탐색공간에서 주어진 문제에 대해 근사해를 확률적으로 찾아가는 단일 솔루션 기반 메타 휴리스틱 알고리즘으로 고체 상태일 때 최소 에너지를 가지는 물질의 기초 상태를 얻기 위해 재료의 가열 및 제어 냉각을 반복하는 물리적인 어닐링 기법에서 제안되었다. 열을 가해서 에너지를 끌어올린 뒤 에너지의 차가 0보다 작거나 같다면 현재의 상태가 계속 유지되고, 0보다 크다면 함수 Z 에 의해 새로운 상태로 전환될 수도 있고 그렇지 않을 수도 있다. 물질이 안정된 상태가 될 때까지 이 과정을 지속해서 온도마다 반복한다 (Kirkpatrick, S., 1983).

$$Z = T \exp\left(\frac{-E}{K_b T C}\right)$$

[수식 2-1] 시뮬레이티드 어닐링 함수 수식

여기서 K_b 는 볼츠만 상수이고, T 는 온도, E 는 에너지 변화량이다. 열적 평형은 볼츠만 분포를 따르며 메타 휴리스틱 알고리즘이다.

SA는 국소 최적해로부터의 전이(transition)가 가능한 목적 함수를 무작위로 평가해 최적해를 구한다. 이후 온도를 조절하는 매개변수 c 를 도입한다. 목적 함수를 구해가면서 최적해를 찾는 과정에서 SA는 목적 함수값이 향상되는 방향과 저하하는 방향을 모두 탐색 경로에 포함한다, c 값이 0에 가까울수록 가치 저하는 점점 적게 허용하며 c 값이 0이 되면 가치 저하는 불가하다. 이로써 SA 기법이 국부적 탐색 방법에서 자주 범하기 쉬운 국부 최적화를 벗어날 수 있게 된다. 또한 매개변수 c 의 선택에 따라 수렴 속도가 변하는

것을 알 수 있다. 비록 이 방법이 최적해를 구하기 위해서는 매우 많은 함수를 평가해야 하는 단점을 가지고 있으나, 큰 조건 수를 갖는 함수에서도 높은 정확성을 가지고 전역 최적해를 구할 수 있다는 강한 장점이 있다. 최적화 문제의 경우, SA의 표준 최적화 절차는 이와 같다(Rere, L. R., 2015).

- 1) 초기 솔루션 벡터를 생성하고 랜덤한 초기 솔루션 x_0 에서 목표 함수를 계산한다.
- 2) 온도를 초기화한다. 값이 너무 크면 수렴하는 데 더 많은 감소가 필요하고 너무 작으면 검색 과정이 완전하지 않을 수 있어 전역 최적해를 초과할 수 있다.
- 3) 현재 솔루션 부근에서 새 솔루션을 선택한다. 새로운 솔루션 x_0+x 는 온도에 따라 새로운 최신 솔루션으로 인정된다.
- 4) 새로운 솔루션을 평가한다. $f(x_0+x) <= f(x_0)$ 라면 x_0+x 가 x_0 을 대체하고 기존 최적 솔루션을 업데이트한 후 6단계로 이동한다.
- 5) 주기적으로 온도를 저하한다. 프로세스 검색하는 동안 온도 T 가 감소해야 검색 시작 시에 열화 동작을 받아들일 확률이 높으며, 점차 감소한다.
- 6) 종료 기준이 충족되면 계산이 종료된다. 그렇지 않으면 2~6단계를 반복한다.

이러한 SA는 몇 가지 특징을 가지고 있다. 함수나 구속 조건 평가에 있어서 불연속적 성질을 도입하기 때문에, 수렴이나 전이 같은 특징들이 함수의 연속성에 영향을 받지 않는다. 여기서 수렴은 실현 가능한 영역의 블록 상태에 영향을 받지 않는다. 그리고 변수가 반드시 양일 필요가 없다. 이러한 특성에 따라서 SA는 임의의 경계 조건 및 제약 조건이 비선형성, 불연속성 및 확률을 펼 때, 다른 비선형 최적화 알고리즘과 비교했을 때 계산 시간을 단축하여 해에 가까운 값에 도달한다. 이는 통계적으로 복잡한 문제를 위한 최적의 솔루션 찾기를 보장한다. 그러므로 대략적인 전역 최적해를 찾는 것이 정확한 국부 최적해를 찾는 것보다 중요할 때 자주 사용된다. 특징 선택 문제는 앞서 최적화 문제로 재구성될 수 있기에 초분광 이미지 분야에서도 SA 알고리즘이 분류 정확도 속도를 높이는 관련 대역을 선택할 수 있다.

```

Simulated annealing algorithm
1 Select the best solution vector  $x_0$  to be optimized
2 Initialize the parameters: temperature  $T$ , Boltzmann's constant  $k$ , reduction factor  $c$ 
3 while termination criterion is not satisfied do
4   for number of new solution
5     Select a new solution:  $x_0 + \Delta x$ 
6     if  $f(x_0 + \Delta x) > f(x_0)$  then
7        $f_{new} = f(x_0 + \Delta x)$ ;  $x_0 = x_0 + \Delta x$ 
8     else
9        $\Delta f = f(x_0 + \Delta x) - f(x_0)$ 
10      random  $r(0, 1)$ 
11      if  $r > \exp(-\Delta f/kT)$  then
12         $f_{new} = f(x_0 + \Delta x)$ ,  $x_0 = x_0 + \Delta x$ 
13      else
14         $f_{new} = f(x_0)$ ,
15      end if
16    end if
17     $f = f_{new}$ 
18    Decrease the temperature periodically:  $T = c \times T$ 
19  end for
20 end while

```

[그림 2-1] 시뮬레이티드 어닐링 슈도 코드(Rere, L. R. 2015)

2) 상호 정보량

엔트로피는 물질계의 열적 상태를 나타내는 물리량으로 계의 무질서 정도를 나타내는 지표이다. 1948년 Shannon이 제안한 정보이론은 각 변수의 정보량을 이런 엔트로피 개념을 각 변수의 정보량 측정기준으로 정량화했다. 여기서 엔트로피는 모든 사건에 대한 정보량의 기댓값을 뜻하며, 전체 사건에 대한 확률분포의 불확실성을 나타낼 때 사용한다(Shannon, C. E., 2001). 해당 변수에 정보량이 많을수록 어떤 사건일지 불확실하고, 이를 ‘엔트로피가 높다’라고 표현한다. 변수 X의 확률밀도함수를 $p(x)$ 로 정의하면 변수 X의 엔트로피는 다음과 같다.

$$H_{(x)} = - \sum_{x \in X} p(x) \log p(x)$$

[수식 2-2] 변수 X의 엔트로피 수식

변수 X, Y 중 한 변수의 정보량을 알고 있을 때 나머지 변수의 정보량은

조건 엔트로피(conditional entropy)를 이용하여 산정할 수 있다(한광희, 2010).

$$H(Y, X) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y, x)$$

[수식 2-3] 상호 정보량 수식

상호 정보량은 두 개의 확률변수가 얼마나 상호 의존적인지에 관한 정보량이다. 엔트로피 $H(X)$ 에서 Y 가 주어지면 X 에 대한 조건 엔트로피 $H(X|Y)$ 를 뺀 정보량에 해당한다. Y 로 인해 X 의 엔트로피가 줄어드는 양으로, 두 확률변수의 상호 정보량은 두 확률변수가 공유하는 엔트로피로 볼 수 있다. 각 확률변수의 엔트로피와 조건부엔트로피 또는 결합엔트로피를 알고 있으면 상호 정보량을 구할 수 있다. 한 확률변수 자신에 대한 상호 정보량은 확률변수의 엔트로피이기도 해서 엔트로피는 자기 정보(self-information)로 불리기도 한다. 상호 정보량은 $[0, 1]$ 으로 도출되며 0에 가까울수록 두 변수가 독립성을 띠고, 1에 가까울수록 종속성을 가지게 된다.

$$\begin{aligned} I(X: Y) &= H(X) - H(X, Y) \\ &= H(Y) - H(Y, X) \\ &= H(X) + H(Y) - H(X, Y) \end{aligned}$$

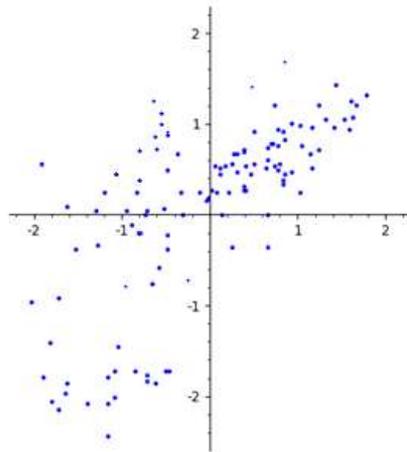
[수식 2-4] 상호 정보량과 엔트로피의 관계

상호 정보량은 베이지 확률론에서 이전에 비해 새로운 확률에서의 엔트로피가 얼마나 감소하는지를 확인하는데 이용된다(Guo, B., 2006). 주어진 군집에 얼마나 비슷한 원소들이 들어있는지를 측정하는 척도로 쓰일 수 있으며, 특히 특징이 유사한 군집형 부분집합에서 밴드 선택 관련 연구에서 자주 사용된다. 초분광 영상 분류의 경우, 적절한 계수를 추가하여 유사 엔트로피를 구하고 이를 유의미한 지표로 사용한다.

제 2 절 밴드추출 기법

1) 주성분 분석 기법

주성분 분석(Principal Component Analysis, PCA)은 기존 원형 데이터의 분포를 투영해 최대한 보존하면서 고차원 공간의 데이터들을 저차원 공간으로 변환한다. 큰 비중을 차지하지 않는 데이터를 제거하여 본 데이터의 분포와 유사한 데이터의 구성으로 변환하는 것이다(Yang, J., 2004). 즉, 변수 조합들을 찾아내어 주성분으로 새로운 특징으로 변수들을 추출하고, 추출된 변수들의 분산의 분포를 통해 모델 분석을 구축하는 것이 주목적이다. PCA는 기존의 변수 조합으로 서로 연관성이 없는 새로운 변수를 생성한다. 물체의 모든 밴드 특성에 대한 학습을 위해 모두 필요하지도 않고 특징이 증가할수록 각 특징인 하나의 차원 또한 증가하게 된다. 데이터 공간의 부피가 급수적으로 커져 데이터 밀도는 희소(sparse)해진다. 오히려 예측 신뢰도가 저하되거나 과학습이 발생할 가능성이 크므로 이를 방지하고자 활용된다.

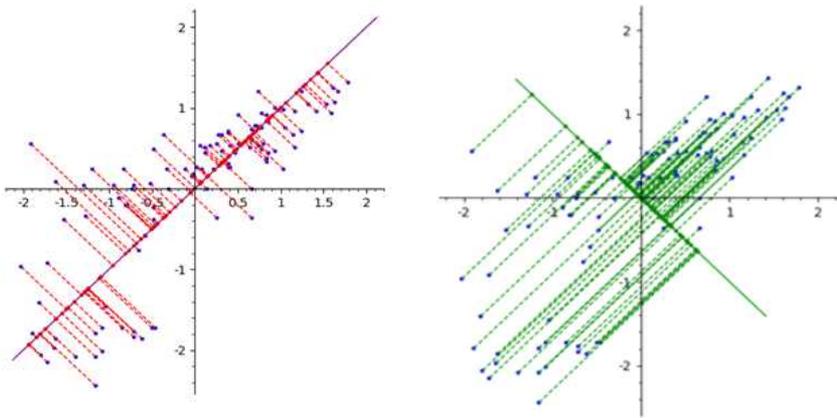


[그림 2-2] 주성분 분석 기법 2차원 데이터 예시

2) 주성분을 추출하는 방법

데이터를 2차원으로 표현하고자 한다면 가정한다면, 첫 번째 주성분 PC1이 원 데이터의 분포를 가장 많이 보존하고, 두 번째 주성분 PC2가 그다음으로 원 데이터의 분포를 많이 보존하는 식이다.

주성분을 구하기 위한 새로운 축을, 주축(principal axes) 또는 주방향(principal directions)이라고 한다. 첫 번째 축은 원 데이터를 축 상에 정사영할 때, 데이터들의 분포가 모두 표현 되도록 정한다. 아래는 주어진 2차원 원 데이터(왼쪽 그림)를 첫 번째 축으로 정사영한 그림(오른쪽 그림)이다. 이때 변환된 데이터들이 PC1이다. 두 번째 축도 원 데이터를 2번째 축 상에 정사영하여 얻어진 데이터들의 분포가 PC1 다음으로 높다. 그리고 PC1과 PC2가 무관하도록 첫 번째 주축과 두 번째 주축은 수직이 되어야 한다. 앞 절에서 차원 축소를 언급할 때 필요한 일부 데이터만 사용할 수 있으나, 이런 경우 특징들 사이에 밀접한 관계가 있는지는 미리 알 수 없어 특징 간에 어떤 영향을 미치는지 파악할 수가 없다. 주성분 분석은 이를 막고자 연관성 있는 변수끼리는 각 주성분에 모이도록 하고, 주성분들 사이에는 서로 관계가 없도록 한다.



[그림 2-3] 주성분 분석 기법으로 PC1(좌)과 PC2(우)에 대한 예시

제 3 절 풀링 연산과 컨볼루션 연산

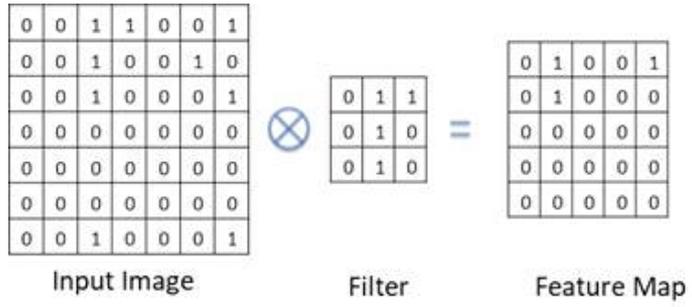
1) 맥스 풀링 연산과 컨볼루션 연산

특징 지도(Feature Map)를 필터를 통해, 필터 안에서 가장 큰 값을 뽑아내는 방식으로, 풀링 연산을 통해 인풋 크기를 줄일 수 있어 다운샘플링 효과로 뉴럴 네트워크 학습에 있어 과적합을 피하는 데 도움이 된다(Zhai, H., 2017). 그리고 연산에 사용되는 컴퓨팅 자원이 적어지고, 특징을 잘 추출 할 수 있다. 입력 데이터에 대한 필터의 크기와 스트라이드(Stride) 크기에 따라서 특징 지도 크기가 결정해, 입력 데이터의 높이(H), 폭(W), 필터의 높이(FH), 폭(FW), 스트라이드 크기(S), 패딩 크기(P)를 통해 출력 데이터 크기를, 수식을 통해 계산할 수 있다(장두혁, 2021).

$$Output\ H(W) = \frac{(H+2P-FH(FW))}{S} + 1$$

[수식 2-5] 풀링 연산 출력 크기 수식

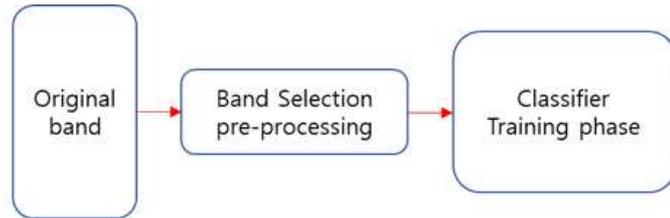
컨볼루션 연산(Convolution Operation)은 두 개의 함수가 특정 시점에서 얼마나 중복(overlap)이 되었는지 계산하는 연산이다(Highlander, 2016). 두 함수의 곱의 적분으로 정의가 되며, 적분은 컨볼루션 함수를 생성하는 모든 이동 값에 대해서 적용된다. 입력된 이미지로부터 커널로 컨볼루션 연산을 수행해 결과로 피쳐 지도를 만들게 된다. 따라서 피쳐 지도는 커널의 패턴이 입력 이미지에 얼마나 잘 표현되어있는지에 대한 정보를 가지게 된다. 딥러닝 분야에서는 컨볼루션 레이어 구조로 되어 활용된다.



[그림 2-4] 풀링 연산 계산 과정 예시

제 3 장 제안 기법

제 1 절 이산 범위별로 대표하는 밴드 추출(DI)

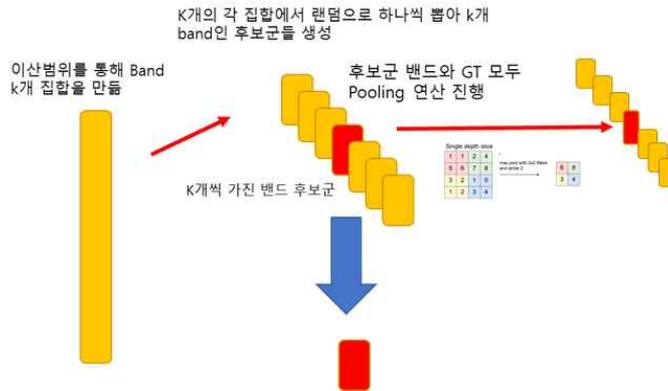


[그림 3-1] 전처리 과정으로 적용되는 밴드 선택 알고리즘

양자화(Quantization)에서는 표현하고자 하는 최솟값, 최댓값 사이 범위를 이산값(discrete value)들로 주기 위해서, 사용하고자 하는 텐서의 비트의 수를 정해, 비트의 수만큼 2에 제곱하여, 표현하고자 하는 실수 범위에 나눈다(장두혁, 2021). 양자화 스텝(Quantization step)의 범위를 정해 양자화 레벨(Quantzation level)을 설정하여, 실숫값과 정숫값에 대응하게 된다. 이 개념을 활용해, 이 실험에서는 픽셀별 반사율의 최솟값과 최댓값의 차이에 따른 이산 범위를 통해 전체 밴드를 반올림한 차이값을 활용하여 부분집합으로 분류하게 된다(Nagel, M., 2020).

X는 알고리즘 적용 입력(Input)인 전처리 되지 않은 밴드이며, Y는 밴드에 따른 정답 값(GT)에 해당한다. 밴드별로 1차원으로 나열해(Flatten), 밴드에서 최솟값과 최댓값의 차이(G)를 반올림한다. 반올림하여 같은 차이를 가진 집합을 생성한다. 임계값(G)을 반사율의 차이로 부분집합(D)의 분류 기준으로 설정하여, 밴드 전체를 부분 집합(Subset)별로 분류하게 된다. 각 부분집합에서 무작위로 하나의 밴드 선택하여 부분집합 개수만큼을 가진 밴드 후보군(x)을 생성한다. 생성한 밴드 후보군 중 풀링(Pooling) 연산(Liyanage, D. C., 2020)을 통해 밴드 크기를 2배로 축소된 특징(xx)을 분류기 0.3 비율로 커널 크기를 5로, 스트라이드는 2로 설정하여 학습한 결괏값이 높은 밴드 후보(x)

를 선택한다(İmamoğlu, N., 2019). 결괏값이 가장 높은 밴드로 추출한다.



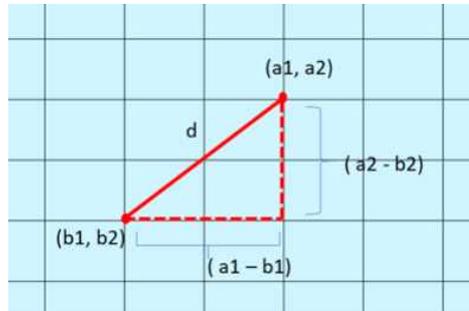
[그림 3-2] 밴드 선택 알고리즘 적용 방식

제 2 절 모델 설계

1) k-최근접 이웃 분류기(k-Nearest Neighbor Method)

K-최근접 이웃 분류기는 KNN 알고리즘을 활용한 지도학습에 한 종류로 거리기반 분류 모델이다. 클래스의 종류에 대해서는 알고 있지만 표본들 각각에 대한 확률밀도 분포를 알지 못하는 상황에서 활용되며, 군이 각 표본에 대한 확률 모수들을 구하지 않고 표본이 기존 관측치의 Y값과 가장 유사하거나 거리상으로 가장 가까운 클래스에 속하는 것으로 분류하는 방법이다(박종선, 2010). 분류기의 장점은 단순하고 효율적이며, 기저 데이터 분포에 대한 가정은 없다. 그래서 훈련단계가 빠르며 수치 기반 데이터 분류작업에 대해서 성능이 우수하지만 모델을 생성하지 않아 특징과 클래스 간 관계를 이해하는데 제한적이다. 또한 적절한 K의 선택이 필요하며, 데이터가 많아지면 분류단계 소요 시간이 느리게 된다. 또한 분류기를 설계할 때 고려해야 할 사항으로는 거리함수가 있다. 거리함수에 대해서는 유클리드 거리 측정법과 맨해튼 거리 측정법이다(김승환, 2020). 2차원 평면에 두 점 $A(x_1, y_1)$, $B(x_2, y_2)$ 에 대해

서 이 둘의 거리 d 는 유클리드 거리 수식으로 계산된다.



[그림 3-3] 유클리드 거리 시각화

$$d = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2}$$

[수식 3-1] 유클리드 거리 수식

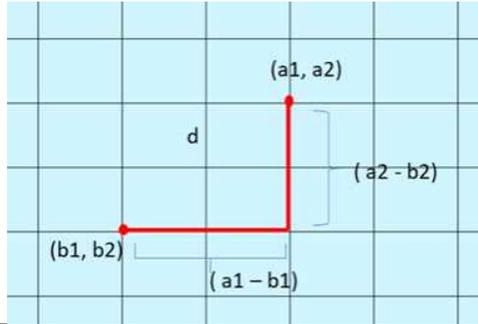
맨해튼 거리 측정법은 평면에 서로 다른 두 점 $A(x_1, y_1)$ 와 $B(x_2, y_2)$ 가 있을 때, 수식에 따라서 거리 d 가 결정된다. 어떤 거리 측정 함수를 적용에 따라 대상으로부터 거리가 달라져, 결과적으로 분류 가능성에 영향을 준다. 선택 가능한 거리함수로는 통상적으로 유클리디안 거리함수를 주로 사용한다. 이 실험에서도 유클리드 거리함수를 사용하여 분류기에 적용한다.

$$d = |a_1 - b_1| + |a_2 - b_2|$$

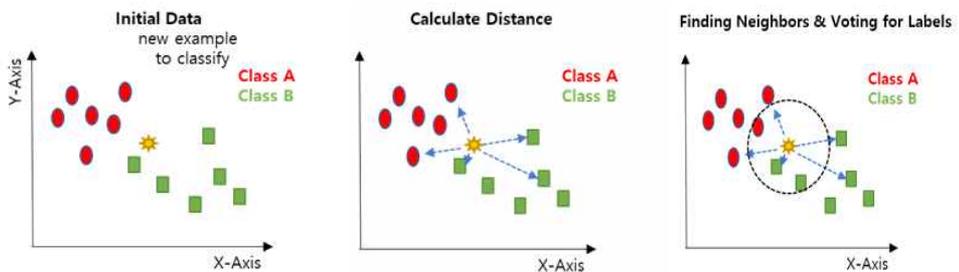
[수식 3-2] 맨해튼 거리 수식

K-최근접 이웃 분류기는 K-NN 알고리즘을 기반으로 분석하는데, 아래 [그림 3-5]에 따라서 알고리즘이 작동한다.

[그림 3-4] 맨해튼 거리 시각화



1	표본으로부터 가장 가까운 이웃을 찾기 위해 거리 측정 함수를 사용해 이웃 간의 거리를 계산
2	거리가 가까운 이웃들 K개만큼 찾음
3	찾아진 이웃들을 다수결 투표 원칙으로 기반하여 신규 데이터 Label로 예측



[그림 3-5] K-NN알고리즘 순서(좌>> 우)

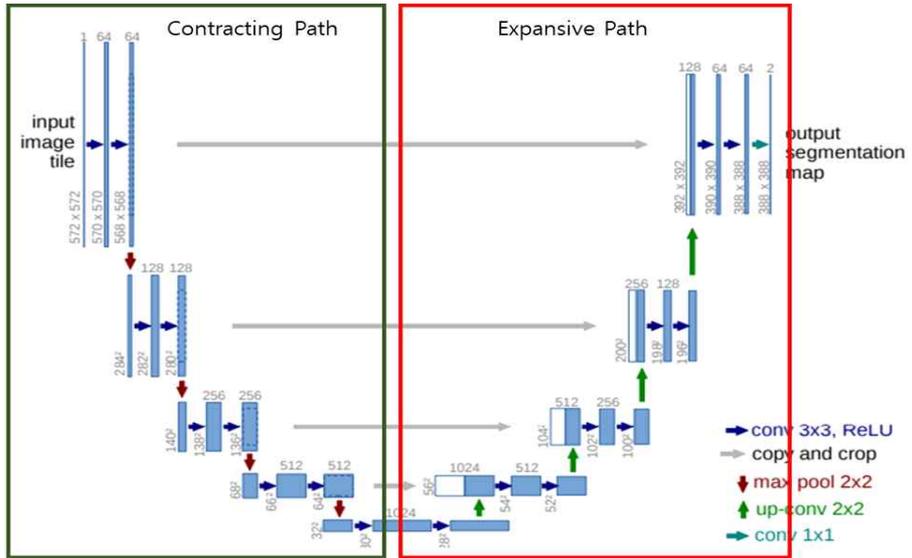
2) U-Net 모델

모델의 구조 모양이 U자여서 지어진 모델명으로, 생물 의학 분야에서 의료 이미지 특성상 적은 양의 데이터로 정확한 세그멘테이션이 가능하도록 개선된 이미지 분할(Image Segmentation)을 목적으로 제안된 엔드-투-엔드(End-to-End) 방식의 Fully-Convolutional Network 기반 모델이다 (Ronneberger, O., 2015). 구조적으로 U-Net 아키텍처의 마지막 레이어의 아웃풋으로 만들어진 세그멘테이션 지도를 학습해 얻어내는 구조이다. 이전의 Window-slide를 나누어 학습시킬 때 패치 개수도 많아지고 높은 정확도의

지역성(localization)을 나타낼 수 있지만, 학습 속도가 오래 걸리는 문제점과 지역성과 컨텍스트(Context) 간의 trade-off가 존재하여, 두 특성을 모두 가져가기 어려운 두 가지의 문제점이 있었다. U-Net을 통해 Overlap-Tile Strategy를 사용하여 첫 번째 문제점을 해결하고, Contracting Path, Exansive Path로 구성된 U-Net은 Conbtracting Path에서 Expansive Path로 Skip Connection을 통해, Patch size 에서도 특징이 컨텍스트에 대한 정보를 포함함으로써 두 번째 문제에 대한 솔루션을 제시한 모델이다. Contracting Path와 Exansive Path의 아키텍처로 엔드-투-엔드 학습(End-to-End Learning) 방식으로 되어있다. 엔드-투-엔드 학습은 필요한 여러 단계를 하나의 신경망을 통해 재배치하는 과정이며, 데이터 크기가 클 때 효율적으로 두 단계로 나누어 각 네트워크를 구축하여 학습한 후 그 결과를 합쳐 성능을 올리는 방식이다(Ronneberger, 2015). 학습에 대한 Energy Function은 아래 [수식 3-3]인 Pixel-Wise Softmax함수와 Cross-Entropy Loss함수로 계산을 했다.

$$p_k(X) = \frac{e^{a_k(X)}}{\sum_{k'=1}^K e^{a_{k'}(X)}} \quad E = \sum_{X \in \Omega} \omega(X) \log(p_{l(x)}(X))$$

[수식 3-3] pixel-Wise Softmax 함수 & Cross-Entropy Loss함수



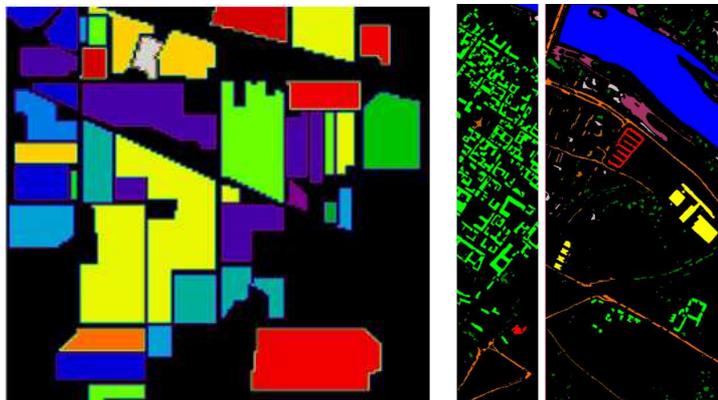
3) 데이터세트

가) Indian Pines(IP)

북서부 인도파인즈 시험장 위에 AVIRIS센서로 수집된 파장 범위 0.4~2.510-6m의 (145,145) 픽셀과 200개의 스펙트럼 반사 대역 밴드로 구성되어있다. 그리고 16개의 클래스로 구성되어있다.

나) Pavia Centre(PC)

ROSIS 센서로 이탈리아 북부 파비아 지역을 비행하여 획득한 장면이다. 파비아 센터는 9개 클래스와 (1096, 715) 픽셀로 구성되어있다. 그리고 102개의 밴드로 구성되어있다.

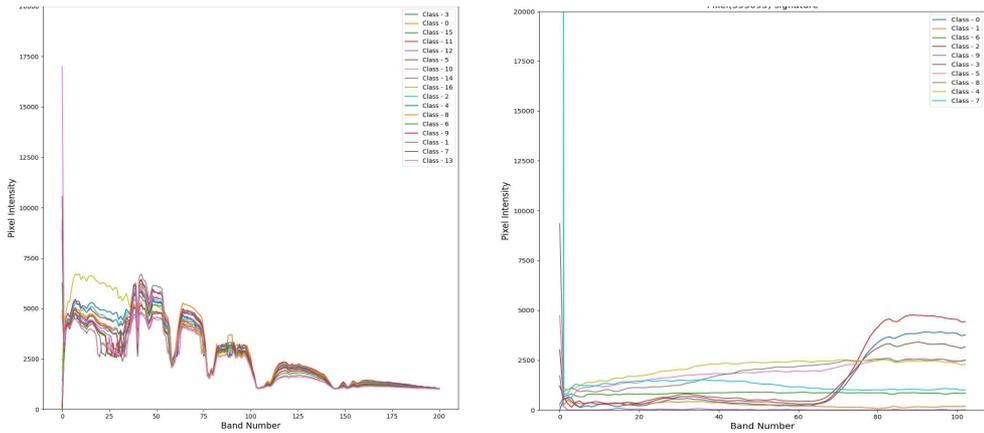


[그림 3-7] Indian Pines, Pavia Centre 의 Groud Truth

4) 데이터세트 분석

데이터세트 분석을 통한 데이터의 복잡성에 대해 파악하는 것이 중요하다. 인디안 파인즈 데이터세트 경우, 그림을 보면 40 밴드 이전에 곡선들이 넓게 분포한 경향이 있고, 이후에는 대부분 클래스별 특징들이 수렴한다. 하지만,

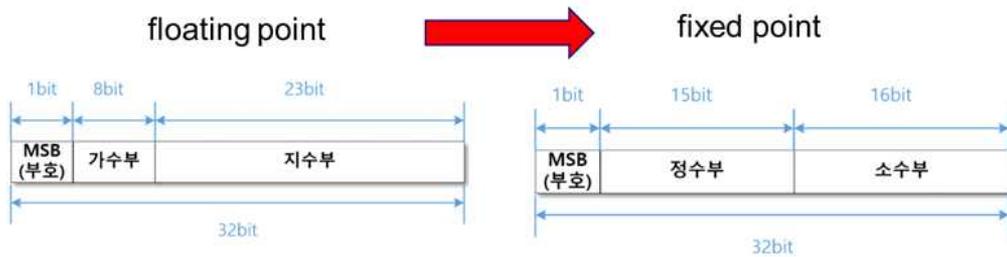
PC 경우 거의 모든 밴드에서 픽셀별 클래스 특징들이 다른 영역보다 멀리 떨어져 있음을 알 수 있다. 각 스펙트럼 특징은 클래스에 해당하기 때문에, 곡선이 더 넓게 분포는 대역이 픽셀 클래스 분류에 좋은 성능의 분리성을 제공한다(Habermann, M., 2019). 그래서 밴드 선택 기법을 하기 전 K-최근접 이웃 분류기 성능은 IP 경우보다 PC가 0.825로 클래스별 분류성능이 높았다.



[그림 3-8] 밴드에 따른 픽셀별 클래스 그래프(IP와 PC)

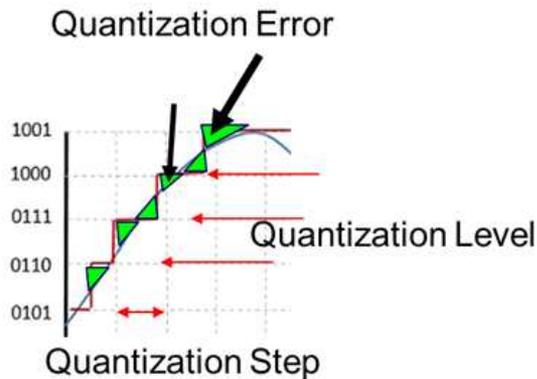
제 3 절 양자화 기법

통상적으로, 활성화 함수와 가중치를 컴퓨터에서 계산할 때 IEEE754 규격에 맞는 부동 소수점의 실수 연산을 하게 된다. 양자화를 통해 정수 연산으로 변환하여, 고정소수점도 변경하는 것을 말한다. 부동 소수점은 실수를 가수부와 지수부로 표현하여, 값을 표현 범위가 넓지만, 실수 연산의 효율이 떨어진다. 고정소수점은 값을 표현하는 범위는 좁지만, 실수 사칙연산에서 정수 사칙연산 문제로 바뀌어 연산에 요구되는 시스템 자원을 줄어드는 장점이 있다. 하지만, 비트 수를 줄이면서 고정소수점도 텐서를 표현하면서 제한적이다. 그리고, 모델의 정확도가 떨어지는데, 이 오차를 줄이는 것을 양자화라고 한다. (Li, Y., Gong, R., Tan, X., Yang, Y., Hu, P., Zhang, Q., ... & Gu, S. (2021).)



[그림 3-9] 부동 소수점에서 고정소수점으로 변환

양자화된 범위 내에서 [그림 3-9]와 같이, 하나의 Interval을 양자화 스텝 (quantization step) 이라고 하고, 각 양자화 스텝에서 사용되는 이산적인 값을 양자화 레벨(quantization level)이라고 한다. 양자화(Quantization)는 표현하고자 하는 최솟값, 최댓값 사이 범위를 이산 값(discrete value) 값들로 주기 위해서, 사용하고자 하는 정수 비트의 수를 정해, 비트의 수만큼 2에 제곱하여, 표현하고자 하는 실수 범위에 나눈다. 양자화 스텝(Quantization step)의 범위를 정해 양자화 레벨(Quantization level)을 설정하여, 실숫값과 정숫값에 대응하게 된다(Banner, R., 2018).



[그림 3-10] Quantization term image

양자화 기법은 학습을 기준으로 양자화 타입 변환을 언제 하느냐에 따라 크게 두 가지로 나뉘게 된다. 양자화 인식 훈련과 사후 훈련 양자화로 나뉘게 된다.

1) 양자화 인식 훈련

양자화 인식 훈련 방식 전반적인 메커니즘은, 학습 진행 시점에서 floating point 모델에서 양자화된 정수 타입 모델로 변환하는 동안 양자화가 발생하는 위치에 fake quantization module을 통해, quantization 및 dequantization 모듈을 배치하여 순전파와 역전파 방향에서의 가중치와 활성화 함수 출력에 대해서 양자화에 의해 가져오는 클램핑 및 반올림의 효과를 시뮬레이션한다. 양자화 모델의 정확도 손실을 최소화시킬 수 있다. quantization-aware training 중에 활성화 함수의 실제 출력 범위 확인도 진행되어 추가적인 캘리브레이션 단계를 생략할 수 있다.

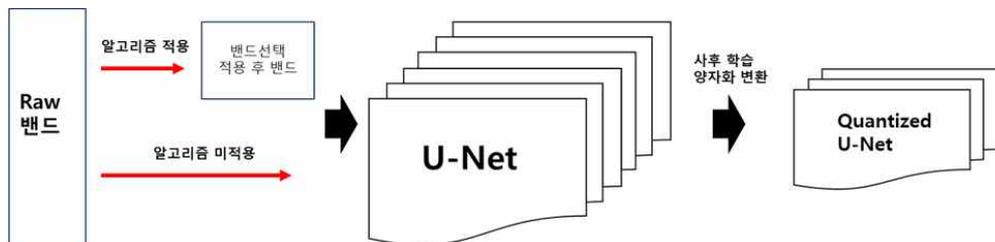
딥러닝 네트워크에 컨볼루션 계층과 활성화 함수 사이에 배치 정규화를 적용하면서 컨볼루션 연산과 배치 정규화 모두 선형 변환되어 각 계층의 파라미터를 결합하는 과정(위성민, 2021)을 folding이라고 부르는데, 추론 시에

folding 되는 것을 적용하여 시뮬레이션을 수행한다.

하지만, 드론과 같은 배터리로 운용하는 임베디드 시스템에서는, 학습을 보드에서 진행함으로써, 연산에 따른 배터리 소비가 클 것으로 예상됨으로, 이번 실험에는 적합하지는 않다.

2) 사후 훈련 양자화

사후 학습 양자화는 학습을 완료한 후에 CPU나 Edge TPU/GPU 같은 하드웨어 엑셀 레이터의 지연시간을 개선하면서 정확도 성능에 대한 손해를 최소화한 기법이다. 사후 학습 양자화 기법의 경우 이미 학습된 모델에 대해서 양자화를 적용 후 손실을 최소화하기 위한 학습 과정이 필요가 없어 학습에 시간을 소요하거나 학습데이터를 요구하지 않아 학습에 대한 전력 소모가 들지 않은 장점이 있다. 하지만 앞에서 언급한 양자화 인식 훈련 방식보다 양자화에 따른 성능 손실의 폭이 크다는 단점이 있다. (Banner, R., Nahshan, 2018). 이번 실험에서는 밴드 선택 알고리즘이 적용된 데이터셋에 대해서 U-Net을 사후 훈련 양자화 방식을 통해 타입을 변경 임베디드 보드에 모델 크기와 추론 시간 및 정확도 손실을 비교한다.



[그림 3-11] 밴드 선택 알고리즘 적용 & 사후 훈련 양자화 방식 적용 흐름

컨볼루션 레이어(C), 맥스 풀링 레이어(M), 풀 커넥티드-레이어(F)로 구성된 5개의 블록 형태의 이미지넷의 VGG 16 모델을 통해, 224x224 크기의 채널3의 이미지를 통해 임베디드 보드인 라즈베리파이 3B+에 float32비트 모델을 학습시킨 레이어별 모델과 사후 양자화 기법으로 가중치만 uint8비트로 양자화를 적용하여 라즈베리파이 3B+에 Google Coral USB Accelerator를 통해 추론 시 비교했다. Float32비트 VGG 16 모델을 돌릴 때, 메모리 부족으로 [그림 3-10]의 14번째 레이어까지 진행되고 15번째 풀 커넥티드 레이어부터 측정할 수 없었다. 14번째 레이어를 지날 때의 모델 사이즈는 87.35MB이므로 1회 평균 누적 전력량을 보면 약 7WS 소비한다. 하지만 동일하게 [그림 3-11]에서 uint8비트로 양자화된 VGG 모델의 14번째 레이어를 비교했을 때, 약 5.5 WS 소비되며 7.35MB의 모델 크기로 1/10배 이상 경량화된 것을 확인했다.

layer 개수	모델구성	평균 1회 실행시간(Sec)	100회 누적 전력량(W)	1회평균 누적 전력량(WS)	이전레이어와 1회 평균 누적 차이	모델 사이즈
1	C	0.1267	54.606888	0.546		4.59KB
2	CC	0.2614	80.1748194	0.802	0.256	42.7KB
3	CCM	0.2721	106.6459936	1.066	0.265	43.0KB
4	CCM C	0.3522	153.7393876	1.537	0.471	118KB
5	CCM CC	0.5250	207.7227744	2.077	0.540	266KB
6	CCM CCM	0.5370	208.251175	2.083	0.005	267KB
7	CCM CCM C	0.5520	229.1017024	2.291	0.209	562KB
8	CCM CCM CC	0.6855	291.673229	2.917	0.626	1.11MB
9	CCM CCM CCC	0.9417	379.7758305	3.798	0.881	1.68MB
10	CCM CCM CCCM	0.9769	380.3627779	3.804	0.006	1.68MB
11	CCM CCM CCCM C	1.0536	416.9392326	4.169	0.366	2.82MB
12	CCM CCM CCCM CC	1.1949	477.3284856	4.773	0.604	5.09MB
13	CCM CCM CCCM CCC	1.3775	550.4526092	5.505	0.731	7.35MB
14	CCM CCM CCCM CCCM	1.3862	553.8931644	5.539	0.034	7.35MB
15	CCM CCM CCCM CCCM F	1.7161	673.6713376	6.737	1.198	105MB
16	CCM CCM CCCM CCCM FF	1.7642	693.9951664	6.940	0.203	121MB
17	CCM CCM CCCM CCCM FFF	1.8016	708.7256754	7.087	0.147	121MB

[그림 3-12] uint8 VGG 16 모델 누적 전력 및 추론 시간 분석

layer 개수	모델구성	평균 1회 실행시간(Sec)	30회 누적 전력량(W)	1회평균 누적 전력량(W)	이전레이어와 1회 평균 누적 차이	모델 사이즈	Output Size
1	C	0.6087	47.097	0.471		38.6KB	(None, 112,112,64)
2	CC	1.3745	140.623	1.406	0.935	475KB	(None, 112,112,64)
3	CCM	1.4014	149.789	1.498	0.092	485KB	(None, 56,56,64)
4	CCM C	1.8205	186.631	1.866	0.368	1.32MB	(None, 56,56,128)
5	CCM CC	2.5310	270.303	2.703	0.837	3.01MB	(None, 56,56,128)
6	CCM CCM	2.5599	279.633	2.796	0.093	3.03MB	(None, 28,28,128)
7	CCM CCM C	2.9219	321.458	3.215	0.418	6.41MB	(None, 28,28,256)
8	CCM CCM CC	3.6422	389.403	3.984	0.779	13.1MB	(None, 28,28,256)
9	CCM CCM CCC	4.4110	495.423	4.954	0.960	19.9MB	(None, 28,28,256)
10	CCM CCM CCCM	4.5472	524.2361	5.242	0.288	19.9MB	(None, 14,14,256)
11	CCM CCM CCCM C	4.7425	525.5577	5.256	0.013	33.4MB	(None, 14,14,512)
12	CCM CCM CCCM CC	5.4980	608.889	6.089	0.833	60.4MB	(None, 14,14,512)
13	CCM CCM CCCM CCC	6.2576	701.484	7.015	0.926	87.4MB	(None, 14,14,512)
14	CCM CCM CCCM CCCM	6.2933	701.785	7.018	0.003	87.5MB	(None, 7,7,512)
15	CCM CCM CCCM CCCM F	M.S	M.S	M.S	M.S	1.23GB	(None, 4096)
16	CCM CCM CCCM CCCM FF	M.S	M.S	M.S	M.S	1.28GB	(None, 2048)
17	CCM CCM CCCM CCCM FFF	M.S	M.S	M.S	M.S	1.28GB	(None, 2)

[그림 3-13] float32 VGG16 모델 누적 전력 및 추론 시간 분석

제 4 장 실험

제 1 절 실험환경

본 논문은 표와 같은 기준으로 평가실험을 진행한다. 분류기 평가모델은 K-최근접 이웃 분류기를 사용하며, 훈련과 테스트의 비율은 7:3 비율로 진행한다. 그리고 딥러닝 모델은 U-Net을 적용하여, 분류기 평가모델 훈련 테스트 비율은 동일하다. 밴드 선택 알고리즘 적용비교에 따른 모델 입력에 대한 밴드 사이즈는 200과15로 들어간다. 최적화함수는 adam를, 손실함수는 categorical cross-entropy를 사용한다. 코드는 python3.7.12으로 작성되었으며 딥러닝 프레임워크는 Tensorflow 2.6.0 기반으로 동작한다.

항목	구성 내용
Model	U-Net
Patch size	4
Input Band Size - IP(PC)	200(102) / 15(10)
Loss function	categorical cross-entropy
Optimizer	adam
Language	python3.7.12
Deep learning framework	Tensorflow 2.6.0

[표 4-1] 딥러닝 구성 기준

분류기 모델에 대해서 정답 값에 해당하는 라벨 클래스에 대해서, 인디안 파인드 데이터셋 경우 클래스는 16개이지만, 라벨이 없는, 즉 배경에 해당하는 라벨에 대해서도 포함해서 17개 항목으로 학습과 테스트를 진행한다. 그리고 U-Net인 딥러닝 모델에 대해서는 인스턴스 세그멘테이션에 대한 평가로, 배경은 제외하고 16가지 클래스에 대해서 평가를 진행한다.

모델	총 패치된 데이터	패치된 학습데이터	패치된 검증 데이터
Indian Pines	6342	4439	1903
Pavia Centre	89792	62854	26938

[표 4-2] 세그멘테이션 패치된 데이터세트 구성

모델	총 데이터 개수	학습데이터	검증 데이터
Indian Pines	21025	14717	6307
Pavia Centre	783640	548548	235092

[표 4-3] 분류기 데이터세트 구성

제 2 절 제안 알고리즘 결과

제안 기법으로 밴드 선택 방식을 적용했을 때, 다음 표와 같이 Indian Pines 데이터세트 경우 알고리즘 적용 후에 기존 200개 밴드에서 15개로 약 92%로 감소했으며, Pavia Centre 데이터세트 경우 102개 밴드 중에 10개로 약 90%로 감소했다. 또한 밴드 인덱스에 대해서는 다음과 같이 선택되었다. 또한 기존 휴리스틱 밴드 선택 대표적인 알고리즘 시뮬레이티드 어닐링과 소요 시간을 비교했을 때, 약 77~92% 정도 감축시켜 실시간 처리에 대한 가능성을 확인할 수가 있었다.

데이터세트	밴드 수	밴드 인덱스
Indian Pines	15	191, 72, 152, 103, 29, 38, 187, 7, 31, 45, 194, 114, 76, , 34, 36,
Pavia Centre	10	23, 43, 52, 31, 78, 4, 0, 6, 1, 90

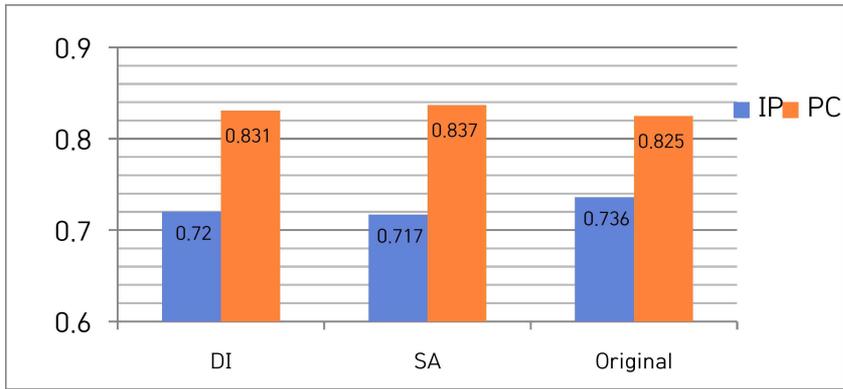
[표 4-4] 제안 알고리즘 결과



[그림 4-1] 밴드 선택 알고리즘 적용 시간 비교

제 3 절 K-최근접 이웃 분류기 평가

제안 기법으로 밴드 선택 방식과 미적용 방식(original)에 대해서 K-최근접 이웃 분류기를 통해 성능을 비교했다. K-최근접 이웃 클래스분류기(K-Neighbor classifier)를 k=5로 적용하여, 5번 테스트 결과 평균이다. 아래 표를 보면 그림3의 모든 밴드를 사용했을 때와 결과 예측된 Ground Truth를 보더라도, 유사한 결과가 나오는 것을 알 수 있다(Habermann, M., 2019). 그런데도, 정확도 측면에서는 표를 보았을 때 라벨별 픽셀 분류 정확도를 확인할 수가 있다.



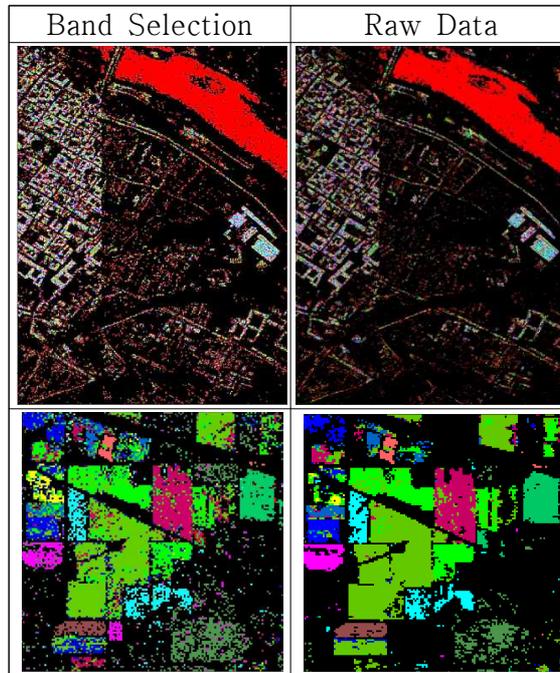
[그림 4-2] 밴드 선택 알고리즘과 기존 휴리스틱 알고리즘 및 밴드 선택 미적용 분류기 성능 비교

또한 not labeled 클래스에 대해서도 인스턴스와 배경의 구분이 명확히 되는 것을 확인할 수가 있었다. 또한 기존 밴드 선택의 대표적인 알고리즘 중 시물레이티드 어닐링 기법과 비교했을 때, Pavia Centre 경우 제 3 장에서 제안한 기법과 기존방식의 성능과 유사한 결과로 뒤처져 있지 않은 결과를 볼 수 있다.

PC	Original	band selection(DI)
not labeled	0.90	0.90
water	0.46	0.47(+0.01)
Tress	0.61	0.62(+0.01)
Asphalt	0.40	0.52(+0.12)
Self-Blocking Bricks	0.27	0.31(+0.04)
Bitumen	0.83	0.82(-0.01)
Tiles	0.28	0.33(+0.05)
Shadows	0.64	0.66(+0.02)
Meadows	0.44	0.47(+0.03)
Bare Soil	0.36	0.46(0.10)

[표 4-5] Pavia Centre 데이터 라벨별 성능 점수

예측한 결과로 이미지를 보았을 때, 알고리즘 적용 이미지와 미적용 결과가 유사한 것을 확인할 수가 있다.

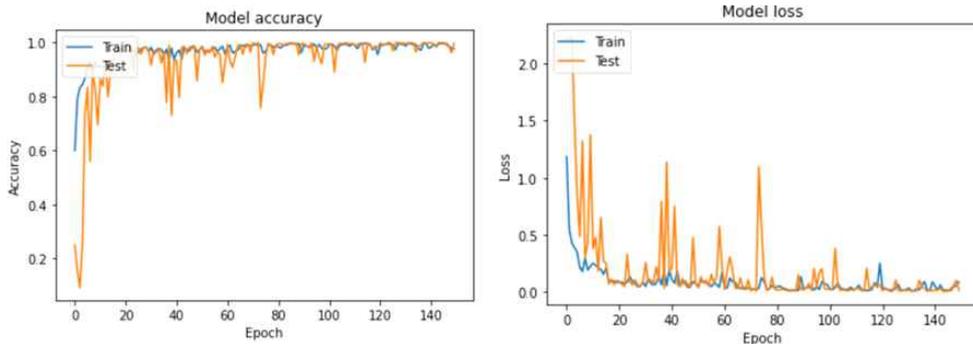


[그림 4-3] 밴드 선택 알고리즘 및 밴드 선택 미적용 분류기 예측 결과

제 3 절 세그멘테이션 딥러닝 모델 성능평가 & 양자화 적용비교

1) 알고리즘 미적용 밴드에 대한 U-Net 모델 성능평가

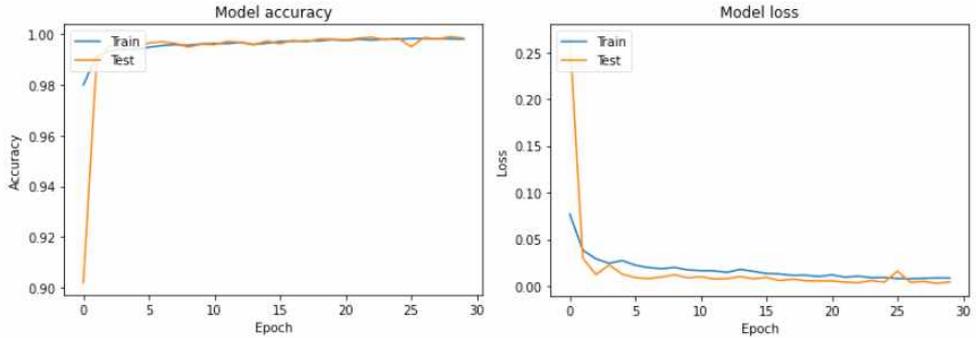
4장 1절의 실험환경을 기준으로, 앞서 제 4장 2절의 분류기 모델 평가에서 더 나아가 딥러닝 U-Net 모델에 적용하여 모델 성능을 테스트했다. 인스턴스 세그멘테이션으로 U-Net 모델의 베이스라인 모델을 그대로 사용했으며, 제4장 1절의 표 조건에 따라서 모델 학습을 진행했다. 과학습을 방지하고 early-stopping 옵션을 통해, 과적합 되는 현상을 방지하고자 했다. 입력 데이터로 제3장의 제안 기법 알고리즘 미적용방식으로, 밴드 전체를 모델에 넣어, 인디안 파인즈 데이터세트에서는 에폭 150과 배치 크기 72로 진행하여, early-stopping 옵션을 20으로 설정하였다. 모델 정확도와 모델 손실 간의 그래프를 다음 그래프로 비교할 수 있다. 학습 손실 곡선과 검증 손실 곡선이 같이 수렴하는 형태로, 에폭이 진행될수록 손실에 대한 진폭이 감소하는 것을 통해 학습이 제대로 진행되는 점을 확인할 수가 있다. 그래서 0.9317의 정확도를 확인할 수가 있었다.



[그림 4-4] 밴드 선택 알고리즘 미적용 분류기 성능과 손실 그래프(IP)

Pavia Centre 데이터세트 경우 학습 손실 곡선과 검증 손실 곡선이 같이 수렴하는 형태이지만, 학습하면서 손실과 정확도에 대한 곡선 진폭이 초기 단계에서는 튀면서 크지만, 점차 학습될수록 진폭이 작아지는 것을 발견할 수

있었으며, early-stopping 옵션으로 6으로 설정하였다. 또한 에폭 30과 배치 사이즈 144로 진행한 결과를 도출하였다. 따라서, 0.9920의 정확도를 얻을 수가 있었다.

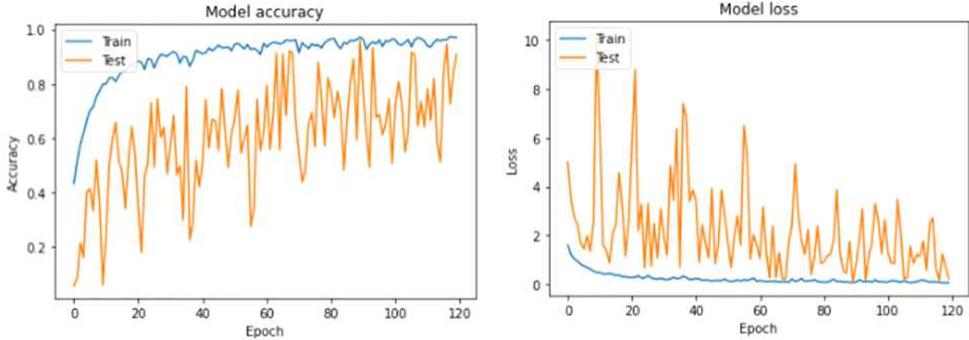


[그림 4-5] 밴드 선택 알고리즘 미적용 분류기 성능과 손실 그래프(PC)

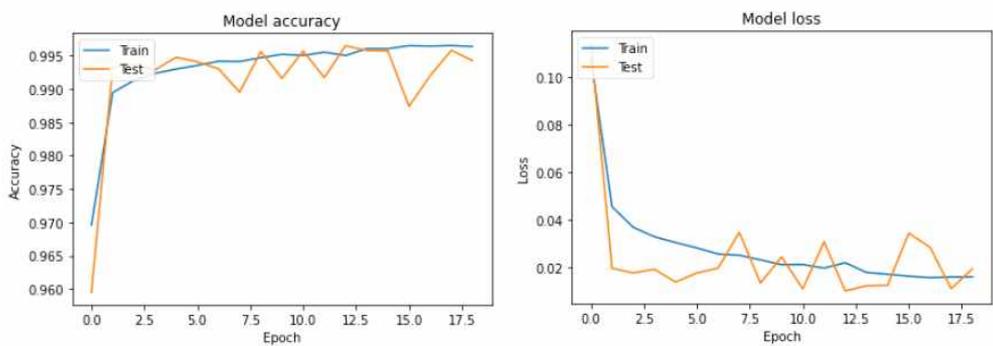
2) 제안 기법 적용된 밴드에 대한 U-Net 모델 성능평가

제4장 1절에 따른 알고리즘 적용 결과를 U-Net 모델에 적용했을 때, 다음과 같은 결과를 얻을 수 있었다. Indian Pines 경우에는 200개 중에서 15개로 선택된 밴드를 모델 학습에 따른 정확도와 손실 그래프를 보았을 때, 학습 정확도가 증가함에 따라 검증 데이터의 정확도도 따라 커지지만, 진폭이 알고리즘 적용 전보다 크게 발생하는 것을 확인할 수가 있으며, 하지만 에폭이 진행됨에 따라 진폭이 작아지는 현상을 볼 수 있다. 따라서 손실 그래프도 학습이 진행됨에 따라 검증 데이터 손실의 폭이 시발에는 컸지만, 점차 작아지는 형태를 띠게 된다. 그래도 밴드 전체를 사용하는 결과보다는 조금 떨어진 85%의 성능을 유지했다.

Pavia Centre 데이터세트 경우 102개 중에서 10개로 선택된 밴드를 모델의 입력으로 넣었을 경우도 다음과 같은 결과를 도출하여, 94%라는 성능을 유지했다.



[그림 4-6] 밴드 선택 알고리즘 적용 분류기 성능과 손실 그래프(PC)

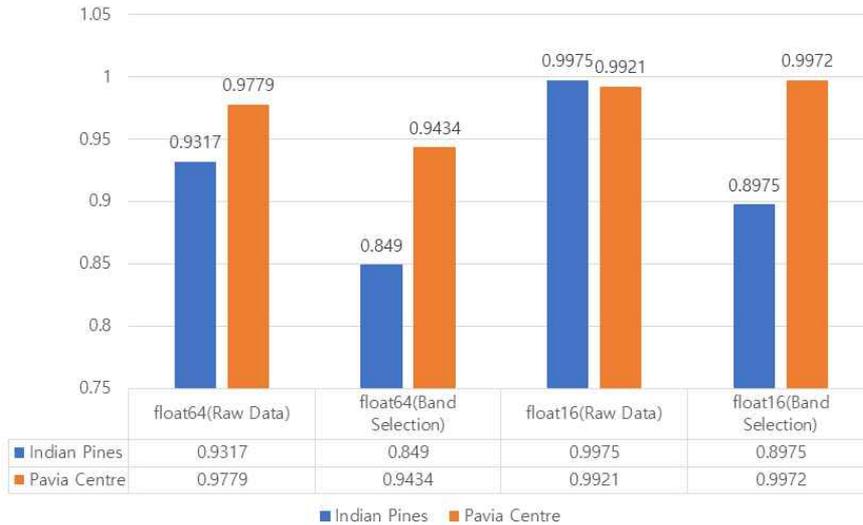


[그림 4-7] 밴드 선택 알고리즘 적용 분류기 성능과 손실 그래프(PC)

3) 사후 양자화 기법 세그멘테이션 딥러닝 모델 변환 적용

제 4장 1절에 따른 알고리즘 적용 결과를 U-Net 모델에 적용했을 때, 다음과 같은 결과를 얻을 수 있었다. 양자화를 적용하기 전에는 가중치 타입이 float64 비트였지만, 제3장 제3.1절의 사후 훈련 양자화 방식으로 float16비트로 변환하여, 모델 성능 손실을 비교했을 때, 전체 밴드를 사용한 Indian Pines와 Pavia Centre 데이터세트는 약 93%와 97%로 높은 성능이 나왔다. 양자화 적용 후에 오히려 성능이 유지뿐만 아니라 미비하게 향상되는 것을 확인했다. 각각 6%, 2%씩 향상했다. 제안 기법을 적용한 밴드는 약간 떨어진 85%와 94%로 약 4~8% 프로 떨어지는 것을 그래프를 통해 알 수 있다. 하지만 양자화 변환으로 float64비트에서

데이터세트 양자화 성능 비교



[그림 4-8] 밴드 선택 알고리즘 적용 여부에 따른 사후 훈련 양자화 적용에 따른 성능 비교

float16비트로 변환되어, 모델 크기가 경량화되었을 뿐만 아니라 성능 면에서 향상된 것을 확인할 수가 있었다. Indian Pines 경우 5% 이상 향상되어 양자화하기 전의 전체 밴드를 사용한 성능과 4% 이하로 차이가 나며, 반면 Pavia Centre 경우 양자화하기 전의 전체 밴드의 성능보다 2%의 성능 향상을 보여주는 효과를 얻었다.

모델의 크기를 비교했을 때, 제안 기법 알고리즘을 적용 시 밴드의 수가 Indian Pines 경우 200개에서 15개로 감소하고, Pavia Centre는 102개에서 10개로 감소했지만, 다음 표의 전처리 되지 않은 데이터 항목을 보았을 때, 저장된 U-Net 모델의 크기 비교는 0.1~0.2MB 차이로 작아졌지만, 오히려 사후 훈련 양자화로 모델을 Float64에서 Float16로 양자화시켰을 때, 오히려 모델 크기가 약 83%로 작아진 것을 확인할 수 있었다.

모델	Indian Pines	Pavia Centre
Raw Data Float64	12.9MB	12.7MB
Raw Data Float16	2.14MB	2.10MB
Band Selection Float64	12.7MB	12.6MB
Band Selection Float16	2.11MB	2.90MB

[표 4-6] 밴드 선택 알고리즘 적용 여부에 따른
사후 훈련 양자화 적용에 따른 모델 크기 경량화 비교

제 5 장 결론

본 논문은 기존 휴리스틱 밴드 선택 알고리즘의 소요 시간 개선된 알고리즘 제안 기법에 대한 K-이웃 근접 분류기를 통한 성능 확보와 밴드 선택 알고리즘의 데이터 경량화 효과 및 모델 자체를 사후 학습 방식 양자화를 통해 모델의 성능 유지를 목표로 실험을 했다. 기존 밴드 선택 휴리스틱 알고리즘 적용 시간은 입력 데이터 크기에 결정되지만, 시뮬레이티드 어닐링 경우 Indian Pines, Pavia Centre 데이터는 46.5분과 128.9분이 소요되었다. 초분광 이미지의 밴드별로 최댓값과 최솟값의 차이를 통해 이산적 범위를 생성하여, 밴드를 분류하여 밴드 선택을 각 부분 집합별로 진행한 제안한 밴드 선택 알고리즘을 통해 3.8분, 30.1분으로 큰 폭으로 감소시키지만, K-최근접 이웃 분류기는 모델 성능은 거의 비슷하게 유지를 했으며, 더 나아가 세그멘테이션 딥러닝 U-Net 모델 경우 4~6% 성능이 감소하는 현상을 보였으나, 사후 훈련 양자화 기법으로 Float64에서 Float16비트로 변환되어 모델의 크기가 크게 감소하였지만 성능 면에서 오히려 2~5% 향상되는 효과를 보였다. 그래서 밴드 선택 알고리즘과 양자화를 적용하기 전의 모델 성능을 비교했을 때, Indian Pines 경우 4% 성능을 보였고 Pavia Centre 경우 오히려 2% 성능이 향상되었다.

임베디드 시스템에는 통상적으로 제한적인 환경에서, 컴퓨터보다 성능이 낮으며, 배터리로 운용하기 때문에 장시간 운용을 위해서는 저전력소모가 상당히 중요한 조건에 해당한다. 따라서 모델을 양자화 적용하여 레이어별로 누적 전력 소모를 비교했을 때, 양자화함으로써 최종 누적 전력 소모가 감소하는 것을 확인했으며 만약 임베디드 보드에, 딥러닝 모델이 탑재될 시에 연산량을 최소화해 전력 소모를 줄일 수 있다.

본 논문에서 제시한 양자화는 가중치를 Float64에서 Float16로 변환되지만, 더 낮은 비트의 int16, int8, uint8에 대해서는 양자화 시도 시에 변환은 되었지만, 성능 면에서 멀리 떨어지는 현상을 보였다. int16, int8, uint8는 float16에 비해 데이터와 가중치, 활성화 함수의 표현 범위가 현저히 작아지

기 때문이라고 예상한다. 또한 초분광 이미지의 엔드멤버의 반사율들의 비율로 픽셀 분류의 라벨이 정해지는데, 엔드멤버의 분포가 특정 스펙트럼에 치우치거나 균등하게 분포하지 않아 양자화 변환 시 값 표현이 잘못 스케일링 되는 현상으로 예상한다(Banner, R., 2018). 하지만 이번 실험을 통해, 알고리즘 소요 시간과 전력 소모를 줄이기 위해 모델 크기를 경량화했지만, 성능은 향상된 의의 있는 실험이었다.

참 고 문 헌

1. 국내문헌

- 이문섭, 김거식, 민기현, 손동훈, 김정은, 김성창.(2019). 『초분광 이미징 기술 동향.[ETRI] 전자통신동향분석,34(1)』. 0-0
- 김거식, 김정은, 김계은, 이아람, 강현서.(2021). DMD 공간 스캐닝 기반 초분광 이미징 시스템. 『전자공학회논문지,58(8)』, 111-118.
- Ha, R., Lee, H., & Gang, T. G. (2014). 초분광 센서 영상의 연구동향과 활용전망. 『Magazine of the Korean Society of Agricultural Engineers, 56(2)』, 33-37.
- 박종선, & 허균. (2010) 『유전알고리즘을 이용한 최적 k-최근접이웃 분류기. CSAM (Communications for Statistical Applications and Methods), 17(1), 17-27.』.
- 김승환, 권기협, 김재우, & 김동성. (2020). 『무선 센서 네트워크 성능 향상을 위한 기계학습 응용동향 및 분석.』한국통신학회논문지, 45(1), 61-79.
- 황선규. (2019). 템플릿매칭. 수록처: 『OpenCV 4로 배우는 컴퓨터 비전과 머신 러닝』 (13.1). 서울: (주)도서출판길벗.
- 위성민, 최경택, 정호기, 서재규, 김도윤.(2021).『임베디드 시스템 기반 실시간 물체 검출을 위한 YOLOv3 최적화.한국자동차공학회 춘계학술대회』, 965-971.
- 한광희, 류용준, 김태순, 허준행.(2010).『상호정보량 기법을 적용한 인공지능영상 입력자료의 선정. 한국수자원학회 논문집 43, no. 1』, 81-94.
- 장두혁, 정병현, 허준영.(2021).『초분광 이미지 픽셀 분류를 위한 풀링 연산과 PSNR을 이용한 최적 밴드 선택 기법. 한국인터넷방송통신학회 논문

지 21, no.5』,

2. 국외문헌

- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by simulated annealing. *science*, 220(4598), 671–680.
- Rere, L. R., Fanany, M. I., & Arymurthy, A. M. (2015). Simulated annealing algorithm for deep learning. *Procedia Computer Science*, 72, 137–144.
- Shannon, C. E. (2001). A mathematical theory of communication. *ACM SIGMOBILE mobile computing and communications review*, 5(1), 3–55.
- Guo, B., Gunn, S. R., Damper, R. I., & Nelson, J. D. (2006). Band selection for hyperspectral image classification using mutual information. *IEEE Geoscience and Remote Sensing Letters*, 3(4), 522–526.
- Yang, J., Zhang, D., Frangi, A. F., & Yang, J. Y. (2004). Two-dimensional PCA: a new approach to appearance-based face representation and recognition. *IEEE transactions on pattern analysis and machine intelligence*, 26(1), 131–137.
- Zhai, H., Zhang, H., Xu, X., Zhang, L., & Li, P. (2017). Kernel sparse subspace clustering with a spatial max pooling operation for hyperspectral remote sensing data interpretation. *Remote Sensing*, 9(4), 335.
- Liyanage, D. C., Hudjakov, R., & Tamr, M. (2020, July). Hyperspectral image band selection using pooling. In *2020 International Conference Mechatronic Systems and Materials (MSM)* (pp. 1–6). IEEE.
- Highlander, T., & Rodriguez, A. (2016). Very efficient training of convolutional neural networks using fast fourier transform and overlap-and-add. *arXiv preprint arXiv:1601.06815*.
- Li, Y., Gong, R., Tan, X., Yang, Y., Hu, P., Zhang, Q., ... & Gu, S. (2021). Brecq: Pushing the limit of post-training quantization by block reconstruction. *arXiv preprint arXiv:2102.05426*.
- Banner, R., Nahshan, Y., Hoffer, E., & Soudry, D. (2018). Post-training

- 4-bit quantization of convolution networks for rapid-deployment. arXiv preprint arXiv:1810.05723.
- Nagel, M., Amjad, R. A., Van Baalen, M., Louizos, C., & Blankevoort, T. (2020, November). Up or down? adaptive rounding for post-training quantization. In International Conference on Machine Learning (pp. 7197–7206). PMLR.
- Habermann, M., Fremont, V., & Shiguemori, E. H. (2019). Supervised band selection in hyperspectral images using single-layer neural networks. *International journal of remote sensing*, 40(10), 3900–3926.
- İmamoğlu, N., Ding, G., Fang, Y., Kanezaki, A., Kouyama, T., & Nakamura, R. (2019, May). Salient object detection on hyperspectral images using features learned from unsupervised segmentation task. In ICASSP 2019–2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 2192–2196). IEEE.
- Lorenzo, P. R., Tulczyjew, L., Marcinkiewicz, M., & Nalepa, J. (2020). Hyperspectral band selection using attention-based convolutional neural networks. *IEEE Access*, 8, 42384–42403.
- 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.

ABSTRACT

Efficient Band Selection for Hyperspectral Image Preprocessing in Embedded Systems

Chang, Duhyeuk

Major in Computer Engineering

Dept. of Computer Engineering

The Graduate School

Hansung University

Hyperspectral imaging technology is a method that derives hundreds of spectral channels (bands) as image information as a result of continuous spectral filters. With the development of device miniaturization and analysis technology, multi-spectral sensors with existing four to seven spectral bands have now expanded to about 100 to 200. It is also being applied to various fields such as environment, national defense, medical care, food, and machine vision. Through this study, a Dimension Reduction method is used among Spectral Unmixing methods, Dimension Reduction method is analyze the pixel composition ratio using unique spectral reflection characteristics for the target object. By improving the band selection algorithm in a dimension reduction method, preprocessed band performed through the neural network input. With the learned model, we compare power consumption based on the application of the

proposed band selection algorithm in an embedded system, and aim to minimize power consumption and minimize performance reduction. For the extraction of specific information, raw data is clustered into subsets by generating discrete values with differences between maximum and minimum values for each band. The band selection algorithm is applied to the classified subset. The dimension reduction method is largely divided into feature (band) extraction and feature (band) selection, and the feature selection technique is applied to improve the number of bands according to the data set and the time and performance required to apply the existing algorithm regardless of wavelength range. Through this experiment, a meaningful result was derived with less reduction in performance accuracy through the classifier, even though the time required was significantly reduced by about 77 to 92 percent compared to the existing band selection. Furthermore, a proposal algorithm is applied to U-Net among segmentation models, and input data bits are converted into post-training quantization. we scale from Float64 to Float16 the first input data type of the model and the data type of skip connection entering the input from the Contracting Path to the Expansive Path. As a result, an experiment was conducted in which The model size reduce by 83% from around 12MB to 2MB. and raise the model inference performance by 5-6% again. and raise the model inference performance by 5-6% again. In addition, it confirmed that the wider class distribution according to the band by pixel in the model to which the band selection algorithm proposed in this paper is applied, the greater the performance improvement due to weight reduction.

KEYWORD: Band selection, hyperspectral imaging, pixel classification, pooling operation, post-learning quantization, and weight reduction