

# 의미론적 분할을 위한 범용 온디바이스 AI 프레임워크

홍준영\* · 이경재\*\*

## Generalized On-Device AI Framework for Semantic Segmentation

Jun-Young Hong\* · Kyung-Jae Lee\*\*

### 요약

복잡한 의미론적 분할 작업은 주로 GPU, TPU와 같은 고성능 그래픽 하드웨어를 갖춘 서버 환경에서 수행된다. 이러한 클라우드 기반 AI 추론 방식은 처리된 결과를 클라이언트에 전송하는 방식으로 작동한다. 그러나 이 방식은 네트워크 통신에 의존적이며, 사용자 데이터를 서버로 전송하는 과정에서 개인정보 침해 우려가 존재한다. 따라서 본 논문에서는 사용자 접근성이 높은 모바일 환경에서 동작할 수 있는 의미론적 분할을 위한 범용 온디바이스 AI 프레임워크를 제안한다. 제안된 프레임워크는 다양한 의미론적 분할 모델을 지원하며, 모델 변환과 효율적인 메모리 관리 기법을 통해 모바일 환경에서 직접 추론을 수행할 수 있게 한다. 본 연구의 접근 방식을 통해 클라우드 컴퓨팅 환경이 아닌 IoT 장치, 자율 주행 차량, 그리고 산업용 로봇과 같이 자원이 제약된 환경에서도 의미론적 분할 알고리즘을 효과적으로 수행할 수 있을 것으로 기대된다. 이는 실시간 영상 처리, 개인정보 보호, 그리고 네트워크 독립적인 AI 응용 분야의 발전에 기여할 것으로 예상된다.

### ABSTRACT

Complex semantic segmentation tasks are primarily performed in server environments equipped with high-performance graphics hardware such as GPUs and TPUs. This cloud-based AI inference method operates by transmitting processed results to the client. However, this approach is dependent on network communication and raises concerns about privacy infringement during the process of transmitting user data to servers. Therefore, this paper proposes a Generalized On-Device Framework for Semantic Segmentation that can operate in mobile environments with high accessibility to people. This framework supports various semantic segmentation models and enables direct inference in mobile environments through model conversion and efficient memory management techniques. It is expected that this research approach will enable effective execution of semantic segmentation algorithms even in resource-constrained situations such as IoT devices, autonomous vehicles, and industrial robots, which are not cloud computing environments. This is expected to contribute to the advancement of real-time image processing, privacy protection, and network-independent AI application fields.

### 키워드

On-Device AI, Semantic Segmentation, Mobile Deep Learning, Model Conversion, Real-time Image Processing  
온디바이스 AI, 의미론적 분할, 모바일 딥러닝, 모델 변환, 실시간 이미지 처리

\* 용인대학교 AI학부 AI전공 (shaman.neo@outlook.com)

\*\* 교신저자 : 용인대학교 AI학부

• 접수일 : 2024. 08. 06

• 수정완료일 : 2024. 09. 08

• 게재확정일 : 2024. 10. 12

• Received : Aug. 06, 2024, Revised : Sep. 08, 2024, Accepted : Oct. 12, 2024

• Corresponding Author : Kyung-Jae Lee

School of Artificial Intelligence, Yong In University,

Email : kjlee@yongin.ac.kr

## 1. 서 론

고수준의 인공지능 추론에는 주로 클라우드 컴퓨팅이 활용된다. 이는 대규모 데이터를 효과적으로 저장하고 복잡한 딥러닝 모델을 학습시키는 데 필요한 고성능 컴퓨팅 자원을 제공함으로써 다양한 고품질 작업을 수행할 수 있게 한다. 현재 딥러닝 기반 컴퓨터비전 연구들은 주로 워크스테이션이나 클라우드와 같은 자원이 풍부한 환경에서의 추론을 목표로 하고 있으며, 파이토치(PyTorch)[1], 텐서플로우(TensorFlow)[2]와 같은 일반적인 딥러닝 프레임워크도 이러한 환경에 최적화되어 설계되었다.

그러나 클라우드 기반 인공지능 기술에는 다음과 같은 대표적인 문제점들이 존재한다. 첫째, 사용자 단말과 서버 간의 데이터 통신이 필수적이다. 이 과정에서 통신 속도와 데이터 무결성 수준은 네트워크 환경에 따라 달라지므로, 모델의 실시간 성능과 사용자 경험에 큰 영향을 미칠 수 있다. 둘째, 클라우드 데이터 센터의 대규모 데이터 저장량으로 인한 보안 문제가 발생할 수 있다. 효과적인 모델 추론을 위해 사용자의 개인 정보가 클라우드에 저장될 수 있으며, 이렇게 집약된 대량의 데이터는 다양한 보안 공격의 주요 표적이 될 수 있다. 셋째, 클라우드 기반 인공지능을 위해 대규모 데이터 센터를 운영하는 과정에서 많은 전력이 소모되어 환경 문제를 야기할 수 있다.

이러한 문제점들을 해결하기 위해 온디바이스 AI(On-Device AI) 기술이 등장하였다. 온디바이스 AI는 데이터를 클라우드 서버로 전송하지 않고 해당 기기 내에서 자체적으로 모델 추론을 수행하는 기술이다. 이는 데이터 처리가 로컬 장치에서 자체적으로 수행되므로 네트워크 환경의 제약을 받지 않는다. 또한 외부 서버로의 개인정보 관련 데이터 전송이 불필요하므로 프라이버시 관련 문제를 해결할 수 있다.

본 논문에서는 온디바이스 AI 기술 개발을 목적으로, 가장 널리 사용되는 안드로이드 환경에서 의미론적 분할 모델 추론을 수행할 수 있는 범용 온디바이스 AI 프레임워크를 제안한다. 의미론적 분할(semantic segmentation)은 컴퓨터비전의 전통적인 작업 중 하나로, 이미지 내의 모든 픽셀을 특정 클래스에 따라 분류하는 것이다. GPU 하드웨어를 사용하여 리눅스 환경에서 수행될 수 있는 다양한 관련 연구들이 제안되었

다[3-5]. 또한 의료 분야[6], 사람 자세 추정[7] 등 다양한 응용 분야에서 활용되었고 고급 컴퓨터비전 연구의 발판이 되는 분야이다. 그러나 상대적으로 자원이 제한된 모바일 환경에서 분할 작업을 수행할 수 있는 체계적인 방법론에 관한 연구가 부족하며, 다양한 의미론적 분할 모델을 적용할 수 있는 범용 알고리즘은 아직 제안되지 않았다.

효과적인 프레임워크 개발을 위해 텐서플로우 라이트(Tensorflow Lite)[2] 라이브러리를 기반으로 하여, 이를 확장 및 개선하였다. 텐서플로우 라이트는 모바일과 같은 엣지 디바이스에 모델을 배포하기 위해 구글에서 개발한 라이브러리로, 모바일 환경에서 분할 모델을 추론하는 데모 프로그램을 소개했다. 그러나 이는 사전 변환된 모델을 사용하며, 더욱 복잡한 딥러닝 모델에 적용하기에는 유연성이 부족하다는 단점이 있다. 본 연구에서 제안하는 프레임워크는 이러한 한계를 극복하고, 다양한 의미론적 분할 모델을 효율적으로 변환하며 안정적으로 추론할 수 있는 방법을 제시한다.

제안된 기술은 안드로이드 환경에서 의미론적 분할 알고리즘을 수행하는 방법에 대한 이정표를 제시하며, 자원이 제한된 모바일 환경에서 온디바이스 AI 방식으로 추론할 수 있는 방안을 제공한다. 이는 모바일 기기에서의 실시간 영상 처리, 증강 현실, 자율 주행 등 다양한 응용 분야에 적용될 수 있으며, 더 나아가 객체 탐지, 객체 추적 등 다른 컴퓨터비전 작업으로의 확장 및 적용도 기대된다. 이를 통해 모바일 환경에서 고급 컴퓨터비전 기술의 보편화와 개인정보 보호를 동시에 달성할 수 있는 새로운 패러다임을 제시하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안된 프레임워크의 구조와 주요 기술을 설명하고, 3장에서는 실험 결과를 제시하고 분석한다. 4장에서는 결론과 향후 연구 방향을 제시한다.

## II. 온디바이스 AI 의미론적 분할 프레임워크

본 장에서는 제안된 온디바이스 AI 의미론적 분할 프레임워크의 구축 과정을 설명한다. 온디바이스 AI 추론을 위해 단말기 자체적으로 데이터를 처리해야 하고 이미지 픽셀 단위로 클래스를 파악하여야 한다. 프레임워크의 전체 과정은 크게 모델 변환과 모델 추론으로 구성된다. 모델 변환은 딥러닝 모델을 텐서플로

우 라이트 모델 형식으로 변환하는 과정이며, 모델 추론은 변환된 모델을 안드로이드 환경에서 텐서플로우 라이트 API를 활용하여 추론을 수행하고 결과를 후처리하는 과정이다.

### 2.1 모델 변환

모델 변환의 궁극적인 목적은 안드로이드 환경에서 추론 가능한 텐서플로우 라이트 형식으로 모델을 변환하는 것이다. 본 연구에서는 컴퓨터비전 연구 분야에서 널리 사용되는 파이토치[1] 프레임워크로 구현된 의미론적 분할 모델의 변환을 목표로 한다.

서로 다른 딥러닝 프레임워크 간의 모델 변환을 위해 ONNX(Open Neural Network Exchange)[8] 기술을 활용한다. ONNX는 다양한 플랫폼 간 모델 호환을 위해 제안된 오픈소스 라이브러리로, 구체적인 변환 과정은 사전 학습된 의미론적 분할 파이토치 모델을 ONNX 형식으로 변환한 후, 이를 텐서플로우 라이트 형식으로 최종 변환하는 것이다. ONNX 모델로의 변환 과정에서는 임시 입력값을 설정하고 이를 모델에 통과시킴으로써 모델 구조를 저장한다. 이 과정에서 주의할 점은 컨볼루션, 활성화 함수와 같은 기본적인 연산층은 변환이 가능하지만, 비-최대 억제(Non-Maximum Suppression), RoIAlign[9]와 같은 논문에서 새롭게 제안된 모듈이나 후처리 알고리즘은 ONNX로 변환이 불가능하다는 것이다.

이러한 제약으로 인해, 네트워크의 기본적인 연산층으로 구성된 부분만 ONNX와 텐서플로우 라이트 형식으로 변환하고, 추가적인 모듈이나 알고리즘은 안드로이드 환경에서 별도로 구현해야 한다. 그러나 최신 텐서플로우 라이트는 상위 라이브러린 텐서플로우에 비해 신경망 관련 연산자가 상대적으로 적게 지원되는 상황이며, 이를 구현하기 위해서는 변환하려는 모델에 대한 깊은 이해가 필요하다.




그림 1. 애플리케이션 흐름도  
Fig. 1 Application workflow

따라서 본 연구에서는 추가적인 알고리즘이 필요하지 않은 의미론적 분할 모델을 대상으로 프레임워크를 구축한다. 구체적으로, 기본적인 연산층으로만 구성되어 변환이 용이하고, 실시간 추론이 가능하며, 높은 정성적 성능을 보인다는 점을 고려하여 BiSeNet[10-11]을 채택하였다. 이러한 접근 방식을 통해, 안드로이드 환경에서 효과적으로 동작할 수 있는 의미론적 분할 모델의 변환 및 구현이 가능해진다.

### 2.2 모델 추론

본 절에서는 앞서 변환한 텐서플로우 라이트 모델을 사용하여 안드로이드 환경에서 의미론적 분할을 수행하는 방법을 제안한다. 전체 흐름도는 그림 1과 같다. 제안된 애플리케이션은 코틀린 언어를 기반으로 작성되었으며 안드로이드 API 버전 32로 개발되었다. 사용자는 스마트폰 카메라로 촬영하거나 개인 저장소에서 임의의 이미지를 선택하여 분할 알고리즘을 수행할 수 있으며, 변환된 다양한 분할 모델들에 대해 안정적으로 추론을 수행할 수 있다.

텐서플로우 라이트에서 모델 추론을 수행하는 방법은 크게 두 가지이다. 첫째, 인터프리터(Interpreter)를 직접 참조하여 추론을 수행하는 방법과 둘째, 텐서플로우 라이트 태스크(Tensorflow Lite Task) 라이브러리에서 제공하는 고수준 API인 분할기(Segmenter)를 활용하는 방법이다. 분할기를 사용할 경우, 변환된 모델에

필요한 사전 조건이 복잡해져 다양한 모델의 일관된 추론이 어렵고, 분할기 내부에서 추론이 이루어져 세밀한 조정 및 개발이 불가능하다. 따라서 본 연구에서는 텐서플로우 라이트 인터프리터를 직접 활용하는 방식으로 프레임워크를 개발한다.

본 논문에서는 범용 프레임워크 개발의 핵심 기능을 담당하는 SimpleSegmenter 알고리즘을 새롭게 제안한다. SimpleSegmenter는 텐서플로우 라이트로 변환된 모델에 대해 모델 로드, 전처리, 모델 추론, 그리고 후처리 과정을 통합적으로 제공하여 효과적인 모델 추론을 가능하게 한다. SimpleSegmenter는 안드로이드 에셋(assets) 파일에 저장된 텐서플로우 라이트 모델을 로드하고, 모델에 적합한 인터프리터를 클래스 내부에서 생성한다.

이미지 전처리 단계에서는 텐서플로우 라이트 서포트(Tensorflow Lite Support)[2] 라이브러리의 ImageProcessor 클래스를 활용한다. 변환된 모델의 입력 텐서 크기에 맞게 쌍선형 보간법(Bilinear Interpolation)으로 이미지 크기를 조정한 후, 정규화(Normalization) 과정을 거친다.

추론 단계에서는 안드로이드 바이트 버퍼(byte buffer)를 사용하여 최종 분할 마스크를 예측한다. 이때 모델의 출력 텐서와 일치하는 타입과 형태의 버퍼를 미리 생성해야 한다. FLOAT32, INT32, INT64 등 다양한 타입의 출력 텐서에 대해 안정적인 추론을 지원하기 위해, 필요한 바이트 수와 출력 이미지의 높이, 너비를 곱한 크기의 바이트 버퍼를 사전에 할당한다. SimpleSegmenter를 통해 입력 이미지를 모델에 통과시키면, 바이트 버퍼에 할당된 메모리의 크기만큼 예측값이 저장된다.

후처리 단계에서는 출력 바이트 버퍼에 저장된 값을 이용하여 결과 텐서를 생성하는 알고리즘을 수행한다. 구체적인 작동 과정은 그림 2와 같다. 인터프리터 추론을 통해 얻은 바이트 버퍼는 실제 구현에서 1차원 배열이지만, 그림 2에서는 이해를 돕기 위해 2차원 형태로 시각화하였다. 가로축은 오프셋(offset)을 나타내고, 세로축은 이미지의 높이와 너비를 곱한 값으로 설정하였다.

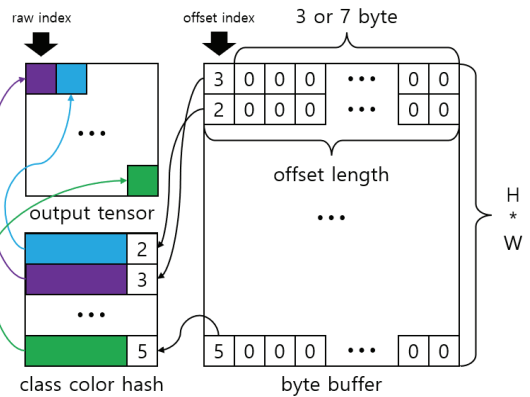


그림 2. 후처리 알고리즘  
Fig. 2 Post-processing algorithm

변환 타입에 따라 오프셋은 4바이트 또는 8바이트로 설정되며, 각 오프셋 위치에 해당하는 픽셀의 클래스가 저장된다. 바이트 버퍼를 순회할 때는 오프셋 크기만큼 인덱스를 증가시킨다.

로우 인덱스(raw index)는 결과 이미지의 픽셀 수준 위치를 나타내며, 오프셋 인덱스(offset index)가 바이트 수만큼 증가할 때마다 1씩 증가한다. 이를 통해 1차원 배열을 2차원 이미지 공간으로 매핑한다. 클래스 라벨 값을 시각화하기 위해 사전에 정의된 클래스 색상 해시(class color hash) 정보를 활용한다. 이 색상 해시는 모델이 학습된 데이터셋에 따라 고정되거나, 무작위로 생성될 수도 있다.

본 논문에서는 모바일 환경에서의 범용 의미론적 분할 모델 추론을 목표로 하므로, 무작위 생성 방식을 채택하여 클래스에 색상을 할당한다. 최종적으로 바이트 버퍼를 모두 순회하며 각 픽셀의 클래스에 해당하는 색상으로 변환하여 분할 결과 마스크를 생성한다.

### 2.3 색상 디코딩 및 결과 이미지 출력

안드로이드 API를 이용해 화면에 결과 이미지를 출력하기 위해서는 텐서 이미지(TensorImage) 클래스로의 변환이 필수적이다. 이 과정에서 필요한 입력 버퍼의 크기는 출력 이미지의 높이 × 너비 × 채널 수로 결정된다. 의미론적 분할 결과를 시각화하기 위해서는 각 클래스에 대한 RGB 색상 값이 필요하다. 일반적인 방법으로는 이러한 RGB 값을 각각 해시에 저장할 수 있다.




그림 3. 색상 인코딩 & 디코딩 프로세스  
Fig. 3 Color encoding & decoding process

그러나 대규모 데이터셋을 사용하는 경우, 클래스 수가 급격히 증가하면 모바일 환경과 같이 제한된 자원을 가진 기기에서 RGB 값을 개별적으로 저장하는 것은 메모리 사용량 측면에서 비효율적일 수 있다.

이러한 문제를 해결하기 위해, 본 연구에서는 그림 3과 같이, 본 연구에서는 RGB 값을 직접 저장하는 대신 인코딩된 단일 값을 저장하고 필요할 때 디코딩하는 방식을 채택하였다. 이는 지연 로딩(lazy loading) 방식의 일종으로, 효율적으로 메모리 관리를 가능하게 한다.

클래스 색상 해시에는 인코딩된 RGB 값이 저장되어 있으며, 이 값으로부터 빨강, 초록, 파랑 값을 각각 추출하기 위해 비트 연산이 수행된다. 저장된 인코딩 값에서 우측 시프트 연산을 통해 각 색상 채널 값을 추출하고, 비트 마스크 연산을 사용하여 각 채널의 8비트 값을 얻는다. 이렇게 얻어진 개별 RGB 값을 사용하여 각 픽셀의 색상을 결정한다.

최종적으로, 이렇게 계산된 텐서 이미지 클래스를 바탕으로 비트맵(bitmap) 형식의 데이터를 생성한다. 이 과정에서 전처리 단계와 마찬가지로 쌍선형 보간법을 사용하여 결과 이미지를 원본 입력 이미지의 해상도로 조정한다. 시각적 편의성을 위해, 조정된 분할 비트맵 마스크를 원본 입력 이미지 위에 겹친 후 최종 시각화 결과를 안드로이드 화면에 출력한다. 이러한 접근 방식을 통해, 제한된 모바일 환경에서도 의미론적 분할 모델의 정성적 성능을 평가하고 분석할 수 있다.

### III. 결 과

본 연구에서는 모바일 환경에서 임의의 단일 이미지에 의미론적 분할 알고리즘을 적용하여 픽셀 수준

의 분류를 수행하고 시각화하는 범용 온디바이스 AI 프레임워크를 제안하였다. 이 프레임워크의 핵심인 SimpleSegmenter 알고리즘은 모델 로드, 데이터 전처리, 모델 추론, 그리고 후처리 과정의 통합적인 파이프라인을 제공하여 안정적이고 메모리 효율적인 추론을 가능하게 한다. 본 프레임워크의 주요 장점은 기존 방법들과 달리 의미론적 분할 모델의 출력 텐서 형식만 조정하면 다양한 분할 모델을 제약 없이 사용할 수 있어, 온디바이스 AI 추론의 적용 범위를 크게 확장한다는 점이다. 구체적으로, 최신 의미론적 분할 모델들은 특정 해상도의 단일 차원 결과 텐서를 생성한다. 이때 픽셀에 대한 클래스 예측값이 저장되며, ONNX를 통해 모델을 변환할 때, 해당 텐서 형태  $1 \times H \times W$ 를 만족시키면 제안된 SimpleSegmenter로 안정적으로 추론을 수행할 수 있다.

그림 4는 제안된 애플리케이션의 실제 구동 결과를 보여주며, ADE20k[12]와 COCO[13] 데이터셋으로 각각 전이학습된 BiSeNetV2[11] 모델의 추론 결과를 제시한다. 사용자는 스마트폰으로 직접 이미지를 촬영하거나 개인 저장소에서 이미지를 불러와 분석할 수 있어, 실생활에서의 즉각적인 응용이 가능하다. 또한, 안드로이드 스피너 기능을 통해 다양한 의미론적 분할 모델의 성능을 비교할 수 있으며, 각 모델의 추론 시간도 초 단위로 표시되어 성능과 속도의 균형을 평가할 수 있다.

대표적인 의미론적 분할 모델 중 하나인 DeepLabv3+[14]에 대한 추론 결과도 제시하여 다양한 모델 간의 정성적 성능 비교가 가능하다. 예시로 사용된 영상은 자율 주행 자동차 상황을 가정하여 도시 풍경 장면에 대해 추론한 결과이다.



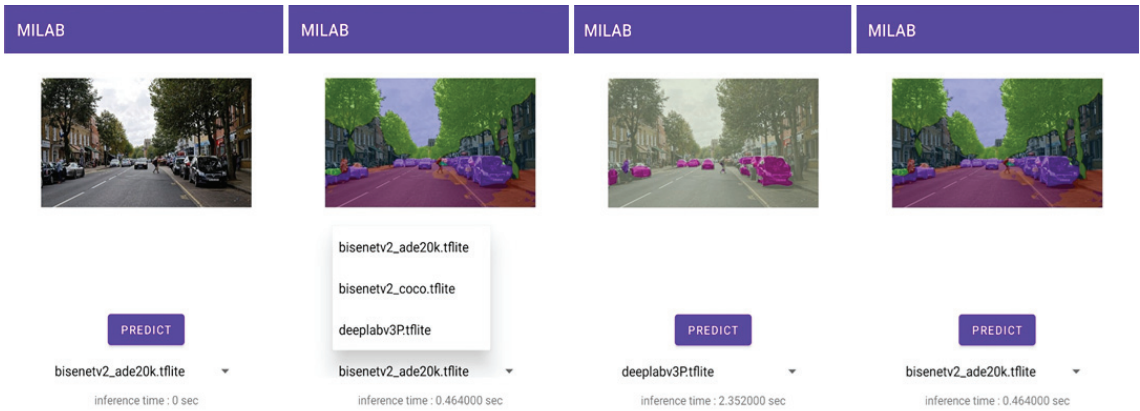


그림 4. 애플리케이션 결과  
Fig. 4 Application result

BiseNetV2의 경우, 한 장의 이미지를 분할하는 데 약 0.46초가 소요되며, 자동차, 도로, 사람 등 핵심적으로 인식하고 구별해야 할 객체들에 대해 우수한 정성적 분할 성능을 보인다. 반면 DeepLabv3+는 자동차 영역만을 분할 한 것을 확인할 수 있으며, 한 장의 이미지를 처리하는 데 약 2.35초가 소요됨을 알 수 있다. 이와 같이 제안된 범용 프레임워크는 온디바이스 AI 방식으로, 각 데이터셋에 전이학습 된 다양한 의미론적 분할 모델들의 정성적 결과와 수행 시간에 대한 비교 및 분석을 가능하게 한다. 이는 이전에 주로 서버 환경에서만 수행되었던 딥러닝 연구를 넘어, 다양한 의미론적 분할 모델들의 비교 실험이 온디바이스 AI 방식으로 가능해짐에 따라 자원이 제한된 환경에서도 효과적인 인공지능 추론을 실현할 수 있을 것으로 기대된다.

#### IV. 결론 및 향후 연구

본 연구에서는 ONNX를 활용한 모델 변환과 텐서 플로우 라이트를 통한 효율적인 추론 과정을 핵심으로 하여, 모바일 환경에서 의미론적 분할을 수행할 수 있는 범용 온디바이스 프레임워크를 제안하였다. 주요 성과로는, 모델의 결과 텐서 형식을 조정하여 다양한 의미론적 분할 모델의 온디바이스 AI 추론 가능성을 입증한 것, 메모리 효율적인 색상 인코딩 및 디코딩

방식을 제안한 것, SimpleSegmenter 알고리즘을 통한 통합 추론 파이프라인을 구축한 것, 그리고 실시간 추론 및 시각화를 위한 안드로이드 애플리케이션을 개발한 것이 있다. 향후 연구에서 해결해야 할 과제는 다음과 같다. 첫째, 복잡한 후처리 알고리즘을 포함한 최신 모델들을 모바일 환경에 구현하는 도전 과제가 있다. 둘째, 모델의 경량화와 최적화에 대한 추가 연구가 필요하다. 셋째, 다양한 실제 시나리오에서 성능을 검증해야 한다. 이러한 과제를 해결하여 더욱 안정적이고 효율적인 온디바이스 AI 의미론적 분할 시스템을 개발하는 것이 목표이다. 특히, 복잡한 최신 모델에서도 안정적인 추론 성능을 확보하고, 엣지 컴퓨팅과의 연계를 통해 고도화된 온디바이스 AI 시스템을 구축할 계획이다.

#### References

- [1] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimeshain, L. Antiga, A. Desmaison, A. Kopf, E. Yang, Z. DeVito, M. Raison, A. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, and S. Chintala, "Pytorch: An imperative style, high-performance deep learning library," *Advances in Neural Information Processing Systems*, Vancouver, Canada, 2019, pp. 8024-8035. <https://doi.org/10.48550/arXiv.1912.01703>
- [2] tensorflow. The tensorflow project, available from

- <https://github.com/tensorflow/tensorflow>.
- [3] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, USA, 2015, pp. 3431-3440.  
<https://doi.org/10.48550/arXiv.1411.4038>
- [4] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *Medical Image Computing and Computer-Assisted Intervention*, Munich, Germany, 2015, pp. 234-241.  
<https://doi.org/10.48550/arXiv.1505.04597>
- [5] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 4, 2018, pp. 834-848.  
<https://doi.org/10.48550/arXiv.1606.00915>
- [6] J. Su and K. Kim, "COVID-19 Lung CT Image Recognition," *Journal of The KIECS*, vol. 17, no. 3, 2022, pp. 529-536.  
<https://doi.org/10.13067/JKIECS.2022.17.3.529>
- [7] Y. Liu, L. C. Li, J. X. Lu, M. Xu, and Y. Jeong, "Research on Human Posture Recognition System Based on The Object Detection Dataset," *Journal of The KIECS*, vol. 17, no. 1, 2022, pp. 111-118.  
<https://doi.org/10.13067/JKIECS.2022.17.1.111>
- [8] onnx: The onnx project, available from <https://github.com/onnx/onnx>.
- [9] K. He, G. Gkioxari, P. Dollar, and R. Girshick, "Mask R-CNN," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Venice, Italy, 2017, pp. 2961-2969.  
<https://doi.org/10.48550/arXiv.1703.06870>
- [10] C. Yu, J. Wang, C. Peng, C. Gao, G. Yu, and N. Sang, "BiSeNet: Bilateral Segmentation Network for Real-time Semantic Segmentation," *Proceedings of the European Conference on Computer Vision*, Munich, Germany, 2018, pp. 325-341.  
<https://doi.org/10.48550/arXiv.1808.00897>
- [11] C. Yu, C. Gao, J. Wang, G. Yu, C. Shen, and N. Sang, "Bisenet v2: Bilateral network with guided aggregation for real-time semantic segmentation," *International Journal of Computer Vision*, vol. 129, no. 11, 2021, pp. 3051-3068.  
<https://doi.org/10.48550/arXiv.2004.02147>
- [12] B. Zhou, H. Zhao, X. Puig, T. Xiao, S. Fidler, A. Barriuso, and A. Torralba, "Semantic understanding of scenes through the ade20k dataset," *International Journal of Computer Vision*, vol. 127, no. 3, 2019, pp. 302-321.  
<https://doi.org/10.48550/arXiv.1608.05442>
- [13] T. Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and CL. Zitnick, "Microsoft coco: Common objects in context," *Proceedings of the European Conference on Computer Vision*, Zurich, Switzerland, 2014, pp. 740-755.  
<https://doi.org/10.48550/arXiv.1405.0312>
- [14] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," *Proceedings of the European Conference on Computer Vision*, Munich, Germany, 2018, pp. 801-818.  
<https://doi.org/10.48550/arXiv.1802.02611>

## 저자 소개



### 홍준영(Jun-Young Hong)

2021년-현재 용인대학교 AI학부 AI전공

※ 관심분야 : 컴퓨터비전, 의미론적분할



### 이경재(Kyung-Jae Lee)

2011년 경희대학교 전자전파공학과 졸업(공학사)

2013년 연세대학교 대학원 전기전자공학부 졸업(공학석사)

2018년 연세대학교 대학원 전기전자공학부 졸업(공학박사)

2018년-2020년 삼성전자 무선사업부 책임연구원  
2020년-현재 용인대학교 AI학부 교수

※ 관심분야 : 컴퓨터비전, 다중센서융합

