

논문 2024-13-38

준지도 학습 기반의 미세조직 이미지 분할 (Image Segmentation for Microstructure based on Semi-supervised Learning)

이 예 지, 신 우 상, 윤 종 필, 주 문 갑*
(YeJi Lee, WooSang Shin, Jong Pil Yun, Moon G. Joo)

Abstract : In order to solve problems such as data collection and expensive labeling work, we proposed an image segmentation model using semi-supervised and unsupervised learning methods. Since semi-supervised learning is used, high performance can be achieved even in situations with little ground truth. The proposed model consists of a segmentation module and a cluster module. The Segment Anything Model (SAM) is used for the segmentation module. The cluster module uses the k-means clustering algorithm, a representative method of unsupervised learning, to determine whether components belong to the same class within the microbial image. Finally, by configuring a user interface, the system was created to return all objects and corresponding components belonging to the same cluster when the user selects an element that wants to be divided. Both the segmentation module and the cluster module can use semi-supervised or unsupervised learning to reduce the cost of work such as data collection and labeling, which has been a problem with the existing image segmentation model.

Keywords : Image segmentation, Semi-supervised learning, Segment anything model, K-means clustering

1. 서 론

최근 딥 러닝 분야의 급속한 발전으로 컴퓨터 비전 분야의 이미지 분할 작업이 큰 발전을 이루었다 [1]. 이미지 분할 모델은 대량의 데이터를 빠른 속도로 처리하여 분할 작업을 수행할 수 있다. 다층 신경망 구조를 통해 복잡한 패턴과 특징을 학습하여 세밀한 분석과 인식이 가능하다. 또한, 수행시간의 제약이 없고 모델을 사용하기 때문에 결과가 일정하다는 장점이 있다. 따라서 지속적인 모니터링이나 분석이 필요한 상황에서 매우 유용하다.

그러나 이미지 분할 모델은 각 픽셀에 대한 정확한 라벨이 필요하다. 정밀한 라벨링 작업은 시간 소모적이며 비용이 많이 든다. 또한 심층학습 모델을 효과적으로 학습시키기 위해서는 대량의 데이터가 필요하다. 특히, 의료나 제조와 같은 전문적 지식을 요구하는 분야에서는 위와 같은 문제로 인해 모델 사용에 어려움을 겪고 있다 [2].

본 논문에서는 데이터 수집과 고비용의 라벨링 작업 등의 문제점을 해결하기 위하여 준지도 학습을 활용한 이미지 분할 모델을 제안한다. 준지도 학습은 특정 학습 작업을 수행하기 위해 레이블이 지정된 데이터와 레이블이 지정되지 않은 데이터를 사용하는 것과 관련된 머신러닝의 한 분야이다 [3]. 준지도 학습은 개념적으로 지도 학습과 비지도 학습 사이에 위치하기 때문에 ground truth가 적은 상황에서도 높

은 성능을 낼 수 있다. 이는 라벨링 비용을 줄이고, 모델의 일반화 능력을 향상시킬 수 있다. 그렇기 때문에, 최근 준지도 학습을 기반으로 한 모델과 관련된 연구가 활발히 이루어지고 있다 [4-7].

본 논문에서 제안된 모델은 분할 모듈과 군집 모듈로 구성된다. 분할 모듈에서는 SAM (Segment Anything Model)을 사용한다. SAM은 준지도 학습 기반의 모델로, 적은 데이터로도 이미지 전체의 분할이 가능하며, 일반화 성능이 우수하다 [8].

분할 모듈에서 이미지 분할이 수행된 후, 동일한 요소에 대하여 군집화를 수행하기 위해 K-means clustering을 이용하여 군집 모듈을 구성한다. K-means clustering 알고리즘은 비슷한 특징을 가진 데이터를 K개의 클러스터로 군집화한다. 이는 비지도 학습으로, 많은 양의 데이터가 필요하지 않다는 특징을 가지고 있다 [9].

사용자 인터페이스를 구성하여 사용자가 분할을 원하는 요소를 클릭할 시, 해당 구성요소와 동일 군집에 속하는 개체들을 모두 반환해준다.

분할 모듈과 군집 모듈 모두 준지도 혹은 비지도 학습 방식을 사용한다. 준지도 학습은 소량의 라벨링 데이터로도 학습이 가능하며, 비지도 학습은 라벨링 된 데이터 없이도 데이터 내의 패턴과 구조를 학습하기 때문에 라벨링 작업의 시간과 비용을 줄일 수 있어 효율적인 모델 개발을 가능하게 한다. 이러한 제안 모델을 사용하여 더 큰 규모의 데이터 셋을 활용할 수 있으며 더욱 일반화된 모델을 개발할 수 있게 된다. 따라서 제안된 모델은 기존의 이미지 분할 모델의 여러 문제점을 해결할 수 있다.

*Corresponding Author (gabi@pknu.ac.kr)
Received: Aug. 16, 2024, Revised: Aug. 28, 2024, Accepted: Sep 10, 2024.
Y. J. Lee : Pukyong National University (M.S.)
W. S. Shin : KITECH(Postdoctoral Researcher)
J. P. Yun : KITECH(Principal Researcher)
M. G. Joo : Pukyong National University (Prof.)
* 이 논문은 부경대학교 자율창의기술연구비(2023년)에 의하여 연구되었음.

II. Segmentation Module

1. SAM (Segment Anything Model)

SAM은 이미지 분할을 위한 파운데이션 모델 (foundation model)을 구축하는 것을 목표로 한다. 즉, 강력한 일반화를 가능하게 하는 작업을 사용하여 신속한 모델을 개발하고 광범위한 데이터 셋에서 사전 훈련하는 것을 목표로 한다 [8].

SAM은 작업, 모델 아키텍처, 데이터 세 가지 요소를 고려한다. 첫 번째로, 분할 모델의 작업은 NLP (natural language processing)에서 영감을 받아 프롬프트 엔지니어링을 통해 다양한 다운스트림 작업을 수행한다. 프롬프트는 전경, 배경, 바운딩 박스, 마스크 또는 자유 형식 텍스트로 분할하려는 내용을 포함하는 정보가 된다. 이러한 프롬프트가 주어지면 유효한 분할 마스크를 반환하는 것이 SAM의 작업이다.

두 번째로 신속한 분할을 위한 모델 아키텍처를 고려한다. SAM은 그림 1과 같은 모델 구조를 지니고 있다. 이미지 인코더, 프롬프트 인코더와 마스크 디코더로 구성되어 있다. 이미지 인코더는 사전 훈련된 vision transformer (ViT)를 사용한다. 프롬프트는 dense 프롬프트와 sparse 프롬프트 두 세트의 프롬프트를 채택한다. 이때, dense 프롬프트는 마스크를 의미하며 sparse 프롬프트는 포인트, 바운딩 박스, 텍스트를 의미한다. 마스크 디코더는 이미지 임베딩, 프롬프트 임베딩 및 출력 토큰을 마스크에 효율적으로 매핑한다. 디코더 블록은 모든 임베딩을 업데이트하기 위해 self attention과 cross attention을 사용한다.

SAM에서 세 번째 요소인 데이터는 11억 개의 마스크 데이터 세트인 SA-1B를 수집할 수 있도록 데이터 엔진을 구

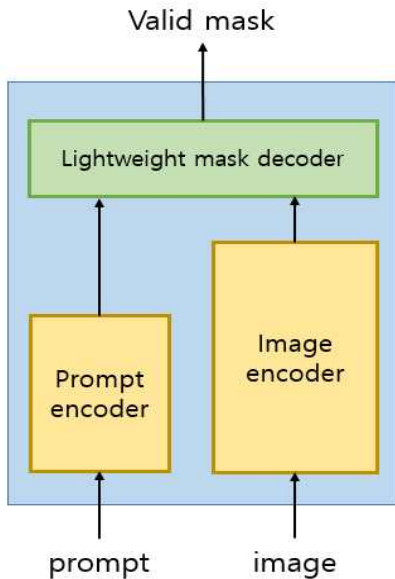


그림 1. SAM 모델 구조
Fig. 1. SAM model structure

축하였다. 데이터 엔진에는 모델 보조 수동 라벨링 단계, 자동으로 예측된 마스크와 모델 보조 라벨링이 혼합된 반자동 단계, 모델이 마스크를 생성하는 완전 자동 단계의 세 단계가 존재한다.

2. 모델 파인튜닝

본 논문에서 이미지 분할 작업의 대상은 물성 특성을 구분하기 위한 미세조직 상을 현미경으로 촬영한 이미지이다. 대상 이미지에 높은 적합성을 확보하고 모델이 최상의 성능을 발휘할 수 있도록 파인튜닝 과정을 거친다. 이를 위해, 기존에 학습된 ‘vit-b’ 모델을 기반으로 세밀한 조정을 수행한다.

파인튜닝 시, 모델 구조 중에 이미지 인코더와 프롬프트 인코더는 제외하고 마스크 디코더만 최적화 과정에 포함시킨다. 이는 사전 학습된 기능을 활용하고 연산 효율성을 높이기 위함이다. 또한, 본 논문에서 파인튜닝의 목표는 모델의 출력 부분인 분할 작업의 성능을 향상시키는 것이기 때문에 마스크 디코더만 파인튜닝을 진행한다. 파인튜닝 과정을 거치면서 대상 이미지 데이터 셋의 특성에 맞게 모델의 가중치를 조정한다. 또한, 학습된 모델이 다양한 이미지 분할 작업에서 더 정확하고 일관된 결과를 제공하도록 한다.

학습에 사용된 데이터셋은 256*256 크기를 가지는 280장의 이미지로 구성되어 있다. 이미지의 ground truth는 배경을 포함하여 0부터 3까지 4개의 클래스로 분류하여 라벨링하였다. 학습은 배경과 배경이 아닌 구성요소로 구분하여 모델 파인튜닝을 수행하였다. 즉, 각 클래스를 구분하는 것이 아닌 배경과 전경을 구분하도록 학습한다.

모델 훈련에 사용된 파라미터는 다음과 같다. 총 2000번의 epoch 동안 학습이 진행되었으며, 학습률은 모델이 학습하는 동안 손실 함수의 최소값을 안정적으로 탐색하기 위하여 0.0001로 설정하였다. 옵티마이저는 Adam 알고리즘을 사용한다. 모델의 성능을 측정하기 위한 손실 함수 값은 mean loss를 채택하였다.

이와 같은 파라미터로 학습된 모델의 손실함수는 그림 2와 같다. 학습 데이터에 대한 epoch 당 손실함수가 부드러운 곡선 형태를 띠며 epoch 수가 커질수록 loss 값이 0에




그림 2. 파인튜닝 모델의 손실 그래프
Fig. 2. Fine Tuning Model Loss Graph




그림 3. 이미지 분할 결과
Fig. 3. Image Segmentation result

가까워지고 수렴하는 것을 보아, 파인튜닝이 정상적으로 잘 진행되었다고 판단하였다.

그림 3은 파인튜닝 된 모델을 적용하여 이미지 분할을 수행한 결과 이미지이다. 위쪽부터 순서대로 원본 이미지, 이미지의 ground truth 마스크, probability map을 나타낸다. 이미지의 ground truth 마스크는 0 (배경) 아니면 1 (전경)로 이루어져있으며, probability map은 각 픽셀 당 전경일 확률을 나타낸 것이다. ground truth 마스크와 probability map을 비교하면 각 요소들에 대하여 분할이 올바르게 진행되었음을 알 수 있다.

III. Clustering Module

1. K-means clustering 알고리즘

분할 모듈의 SAM은 이미지를 분할하고 배경과 전경을 구분한다. 분할된 구성요소를 제공하지만, 이러한 구성요소가 실제로는 어떤 군집에 속하는지에 대한 군집화 정보는 제공하지 않는다. 따라서 이미지 내의 각 구성요소를 구분하고 군집화하기 위하여 K-means clustering 알고리즘을 도입하여 군집 모듈을 구성한다.

K-means clustering 알고리즘은 정답 데이터 없이 학습하는 비지도 학습의 대표적인 알고리즘이다. 비슷한 특성을 지닌 데이터를 K개의 클러스터로 군집화 한다. 이 알고리즘은 각 클러스터와 거리 차이의 분산을 최소화하는 방식으로 동작한다. 직관적이고 구현이 쉬우며, 빠른 수행 시간이 장점이다. 하지만 초기 값에 민감하며 클러스터 개수 K를 매번 지정해줘야 한다는 단점이 있다.

K-means clustering 알고리즘은 주어진 n 개의 데이터 (x_1, x_2, \dots, x_n) 에 대하여 $k(\leq n)$ 개의 집합 $S = \{S_1, S_2, \dots, S_k\}$ 으로 분할한다. i 번째 클러스터 중심을 μ_i , 클러스터에 속하

는 데이터의 집합을 S_i 라고 할 때, K-means clustering 알고리즘의 목적함수는 수식 (1)과 같이 계산된다. 이 값을 최소화 하는 S_i 를 찾는 것이 목표가 된다 [10].

$$V = \sum_{i=1}^k \sum_{x \in S_i} |x - \mu_i|^2. \quad (1)$$

알고리즘은 초기 μ_i 를 설정하는 것으로 시작한다. 이후에는 각 데이터로부터 각 클러스터들의 μ_i 까지 유클리드 거리를 계산하여 해당 데이터에서 가장 가까운 클러스터를 찾아 데이터를 배당한다. 이 과정은 클러스터를 설정하는 단계이다. 다음으로 μ_i 를 각 클러스터에 있는 데이터 포인트들의 무게중심 값으로 재설정해준다. 이 작업을 반복하다보면 점들이 소속된 집합을 바꾸지 않거나, 무게중심이 변하지 않는 상태로 수렴할 수 있게 되어 알고리즘이 종료된다.

2. 군집화 알고리즘 적용

본 논문에서는 구성요소의 군집화를 위하여 SAM의 반환 값 중 하나인 마스크의 좌표 정보를 활용한다. SAM을 통해 이미지 전체 분할을 진행하면, 자동으로 이미지 내에 여러 개의 grid point들이 할당되어 각 포인트를 기준으로 이미지가 분할된다. 알고리즘을 거쳐 남은 최종 마스크들에게는 각 1개의 좌표 정보가 반환된다.

그림 4는 분할된 마스크의 좌표 정보를 시각화한 이미지이다. 주황색으로 표시된 부분은 자동 분할된 요소이며, 초록색 포인트는 좌표 정보를 의미한다. 분할된 마스크 한 개당 포인트가 한 개씩 할당되어 이미지화 된 것을 알 수 있다. 이러한 좌표 정보를 이용하여 분할된 마스크의 색상 정보인 RGB 값을 추출한다. 색상 채널 벡터를 K-means clustering 알고리즘의 입력 데이터로 사용하여 분할된 마스크의 군집화를 수행한다. 이미지 내에서 구성 요소들을 가장 쉽게 군집화 할 수 있는 기준은 각 구성요소의 색상이므로 이러한 방법을 채택한다.




그림 4. 분할된 마스크의 좌표 정보 이미지
Fig. 4. Image of coordinate information for the segmented mask




그림 5. 입력 이미지
Fig. 5. Input image



그림 6. Segment everything 결과 이미지
Fig. 6. Segment everything result image




그림 7. K-means clustering 결과 이미지
Fig. 7. K-means clustering result image

본 실험의 입력 이미지 원본은 다음의 그림 5와 같다. 그림 5를 참고하면 이미지 내의 각 구성요소는 검정색, 짙은 회색, 밝은 회색과 같이 크게 3개의 군집으로 나눌 수 있다. 따라서 K-means clustering의 하이퍼파라미터 k 는 배경을 포함해 4으로 설정하여 4개의 군집으로 나타내었다. 배경은

분할 대상이 아니므로 군집화 과정에서만 사용하며, 이후의 과정에서는 표시를 생략하도록 한다.

SAM을 활용하여 이미지 전체 분할을 진행한 결과는 그림 6과 같다. 이미지 내의 객체를 분할하여 랜덤 색상으로 표시하였다. 하지만 3장 1절의 설명처럼 SAM을 통한 이미지 분할은 객체의 군집 정보를 제공하지 않는다. 그림 7은 본 논문에서 제안한 알고리즘의 결과 이미지이다. 그림 6과 달리 분할된 객체가 속하는 군집을 각각 다른 색상으로 표시하여 군집화가 이루어진 것을 시각화하였다. 이를 통해 본 논문에서 제안한 알고리즘을 통해 분할된 마스크들의 군집화가 가능함을 알 수 있다.

IV. 사용자 인터페이스 및 모델 성능

앞선 2절의 분할 모듈과 3절의 군집 모듈을 조합하여 사용자 인터페이스를 구현한다. 전체 시스템의 플로우 차트는 다음의 그림 8과 같다.

시스템이 시작되면 가장 먼저 사용자는 분할 모듈의 프롬프트를 통해 자신이 분할을 원하는 마스크를 클릭한다. 이후에 사용자가 클릭한 마우스 좌표가 자동 저장된다. SAM의 입력으로 마우스의 좌표 값과 이미지가 함께 들어가게 된다. SAM을 통해 이미지 전체 분할이 진행되고, 각 마스크의 좌표 값을 이용하여 RGB 색상 채널을 추출한다. 여기서 얻은 색상 채널 정보를 군집 모듈의 K-means clustering 알고리즘의 입력으로 전달한다. 군집화가 수행되면 각 마스크의 클래스 정보를 알 수 있다. 클래스 정보를 이용하여 사용자가 입력한 mask의 class와 동일한 마스크들은 모두 표시해주는 것으로 시스템이 종료된다.

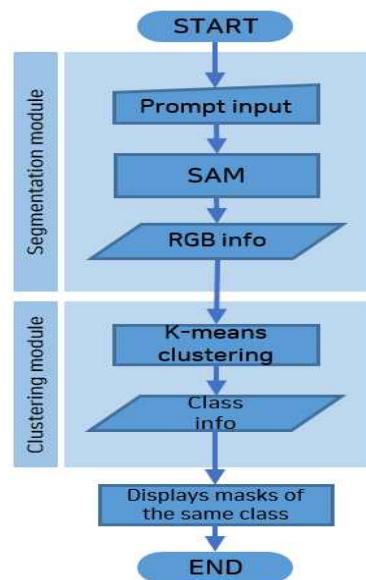


그림 8. 시스템 흐름도
Fig. 8. System Flowchart




그림 9. 사용자 인터페이스 결과 이미지
Fig. 9. User Interface Result image

그림 9은 사용자 인터페이스의 출력 결과를 표시한 것이다. 사용자가 클릭한 요소와 동일 클래스에 속하는 구성요소들을 분할된 마스크와 바운딩 박스로 표시해주었다. 그림 9의 첫 번째 사진 우측 중간에 보이는 포인트는 사용자가 프롬프트를 통해 입력한 마우스 좌표를 의미한다. 두 번째 사진의 경우 사진의 좌측에 위치한 구성요소를 클릭하여 포인트 좌표가 표시되었고, 이와 같은 클래스에 속하는 미세조직 요소들에 대하여 바운딩 박스를 그리며 분할이 진행된다.

동일한 이미지를 입력으로 설정하여도, 사용자가 다른 요소를 클릭하여 프롬프트가 달라진다면 프롬프트 입력 값에 따라 분할의 대상이 바뀌는 것을 알 수 있다. 이를 통해 본 시스템은 사용자가 입력한 구성요소와 동일한 클래스에 속하는 미세조직 상을 올바르게 분할할 수 있음을 알 수 있다.

표 1은 임의의 이미지 1장을 입력하였을 때, 사용자 인터페이스를 통해 나온 클래스별 색상과 면적, 개수를 나타낸다. 분할 모듈을 거쳐 나온 마스크들을 군집화하여 3가지 클래스로 분류한다. 전체 이미지에서 분할된 마스크의 각 면적 차지율과 개수를 통해 미세조직 상의 분포 정도를 파악할 수 있다.

표 2는 제안된 모델에 ground truth가 있는 임의의 이미지 4장을 입력한 경우의 성능을 나타낸다. 성능은 정확도와 손실 값으로 측정하였으며, 이때 손실 함수는 L1 loss를 사용하였다. L1 loss는 실제 값과 예측 값 사이의 차에 절댓값

표 1. 사용자 인터페이스 결과표
Table 1. User Interface Result table

| class # | color | area | count |
|---------|------------|--------|-------|
| 0 | black | 40.6 % | 47 |
| 1 | dark gray | 9.4 % | 24 |
| 2 | light gray | 13.9 % | 37 |

표 2. 제안된 모델의 성능 표
Table 2. Performance table of the proposed model

| image # | accuracy | L1 loss |
|---------|----------|---------|
| 0 | 90.02 % | 0.19 |
| 1 | 89.60 % | 0.20 |
| 2 | 91.89 % | 0.16 |
| 3 | 89.09 % | 0.18 |

을 취한다. 서로 다른 사진 4장의 정확도가 일관되게 높은 정확도인 약 90%를 유지하고 L1 loss가 약 0.2로 낮게 계산되어 본 논문에서 제안한 모델의 성능이 우수함을 확인할 수 있다. 이러한 결과를 통해 제안된 모델이 다양한 이미지에 대해 성능을 발휘할 수 있으며 모델의 일반화 능력이 뛰어나다는 것을 알 수 있다.

V. 결론

본 논문에서는 SAM을 이용하여 분할 모듈, K-means clustering 알고리즘을 이용하여 군집 모듈을 구성하였다. 두 모듈을 통합하여 이미지 분할 프로그램을 제작하였다. 분할 모듈에서는 280여장의 현미경으로 촬영한 미세조직 이미지를 사용하여 기존의 모델을 재학습하고 데이터셋에 맞춰 모델을 최적화하였다. 군집 모듈에서는 비지도 학습 군집화 알고리즘인 K-means clustering 알고리즘을 활용한다. 분할된 마스크에서 특징 정보를 추출하고 해당 정보를 바탕으로 군집화하여 동일한 구성요소를 구분할 수 있도록 하였다.

심층학습 모델은 다량의 데이터와 라벨링을 요구한다. 따라서 전문성이 필요한 분야에서는 위와 같은 문제로 인해 이미지 분할 모델을 현실적으로 사용하기가 어렵다. 하지만 준지도 학습 방식을 활용한 본 모델은 데이터 수집과 라벨링에 대한 비용을 크게 절감할 수 있다. 또한, 이미지 분할에 대하여 정확하고 편차가 없는 결과를 도출할 수 있다. 따라서 의료나 제조와 같은 전문성이 필요한 분야에서 준지도 학습 방식의 이미지 분할 모델이 효과적으로 사용될 것이다.

제안한 모델의 군집 모듈에서는 현미경으로 촬영한 미세조직 상의 구성요소를 군집화 할 때, 해당 객체의 색상 정보만을 이용한다. 오로지 색상 정보만 이용하기 때문에 색상 특징이 뚜렷하지 않고 모호한 구성요소에 대하여 정확하지 않은 결과를 도출할 수 있다. 이를 해결하기 위해 구성요소의 색상 정보 이외에도 다양한 특징 정보를 활용하여 군집화를 수행할 수 있는 연구를 진행 중이다.

References

- [1] W. Shen, Z. Peng, X. Wang, H. Wang, J. Cen, D. Jiang, L. Xie, X. Yang, Q. Tian, "A Survey on Label-Efficient Deep Image Segmentation: Bridging the Gap Between Weak Supervision and Dense Prediction," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 45, No. 8, pp. 9284-9305, 2023.
- [2] Y. J. Lee, M. G. Joo, W. S. Shin, J. P. Yun, "Image Segmentation Based on Semi-Supervised Learning," *The 19th Symposium on Embedded Technology(ISET2024)*, pp. 35-37, 2024 (in Korean).
- [3] J. E. Van Engelen, H. H. Hoos, "A Survey on Semi-supervised Learning," *Machine learning* Vol. 109, No. 2, pp. 373-440, 2020.
- [4] X. Yang, Z. Song, I. King, Z. Xu, "A Survey on Deep Semi-supervised Learning," *IEEE Transactions on Knowledge and Data Engineering*, Vol. 35, No. 9, pp. 8934-8954, 2022.
- [5] M. Zheng, S. You, L. Huang, F. Wang, C. Qian, C. Xu, "Simmatch: Semi-supervised Learning with Similarity Matching," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 14471-14481, 2022.
- [6] K. Sohn, D. Berthelot, N. Carlini, Z. Zhang, H. Zhang, C. A. Raffel, E. D. Cubuk, A. Kurakin, C. L. Li, "Fixmatch: Simplifying Semi-supervised Learning with Consistency and Confidence," *Advances in Neural Information Processing Systems*, Vol. 33, pp. 596-608, 2020.
- [7] B. Zhang, Y. Wang, W. Hou, H. Wu, J. Wang, M. Okumura, T. Shinozaki, "Flexmatch: Boosting Semi-supervised Learning with Curriculum Pseudo Labeling," *Advances in Neural Information Processing Systems*, Vol. 34, pp. 18408-18419, 2021.
- [8] A. Kirillov, E. Mintun, N. Ravi, H. Mao, C. Rolland, L. Gustafson, T. Xiao, S. Whitehead, A. C. Berg, W. Y. Lo, P. Dollar, R. Girshick, "Segment Anything," *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 4015-4026, 2023.
- [9] T. M. Kodinariya, P. R. Makwana, "Review on Determining Number of Cluster in K-Means Clustering," *International Journal*, Vol. 1, No. 6, pp. 90-95, 2013.
- [10] T. Kanungo, D. M. Mount, N. S. Netanyahu, C. D. Piatko, R. Silverman, A. Y. Wu, "An Efficient K-means Clustering Algorithm: Analysis and Implementation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, No. 7, pp. 881-892, 2002.

Yeji Lee (이 예 지)



2023 Information and Communication Engineering from Pukyong National University (B.S.)

2023 Department of Intelligent Robot Engineering from Pukyong National University (M.S.)

Field of Interests: Deep Learning & Smart Factory
Email: purple7yz@naver.com

WooSang Shin (신 우 상)



2017 Electronic and Electrical Engineering from Kyungpook National University (B.S.)

2020 Electronic and Electrical Engineering from Kyungpook National University (M.S.)

2024 Electronic and Electrical Engineering from Kyungpook National University (Ph.D.)
Field of Interest: Machine Learning, Deep Learning, Computer Vision
Email: welldone@kitech.re.kr

Jong Pil Yun (윤 종 필)



2003 Electronic and Electrical Engineering from Kyungpook National University (B.S.)

2009 Electrical Engineering from POSTECH (Ph.D.)

2016~Korea Institute of Industrial Technology (Principal Researcher)

Career:

2009~2016 Senior Researcher, POSCO

Field of Interest: Deep Learning, Computer Vision, Image Processing, Defect inspection, Fault Diagnosis, Medical Image Analysis
Email: rebirth@kitech.re.kr

Moon G. Joo (주 문 갑)



1992 Electronics and Electrical Engineering from POSTECH (B.S.)

1994 Computer and Communications Engineering from POSTECH (M.S.)

2001 Electrical and Computer Engineering from POSTECH (Ph.D.)

2003~Professor at Pukyong National University

Field of Interest: Intelligent Control & Factory Automation
Email: gabi@pknu.ac.kr