

U-net을 활용한 영상 분할 기법으로 구상 흑연 정량적 판별

황 석민
조선대학교 컴퓨터공학과
doshal024@gmail.com

정 호엽
조선대학교 컴퓨터공학과
hoyub@chosun.ac.kr

Identifying quantitatively Spheroidal graphite by image segmentation analysis using U-net

Seok Min Hwang
Department of Computer
Engineering
Chosun University
Gwangju, South Korea

Ho Yub Jung
Department of Computer
Engineering
Chosun University
Gwangju, South Korea

요 약

주철은 우리 주변에 다양한 곳에서 사용된다. 그 중 구상 흑연 주철은 보통 주철에 비해 물리적 성질이 우수하다. 구상 흑연 주철의 여러 물리적 성질을 좌우하는 요소들 중 미세조직 속 구상 흑연이 있다. 구상 흑연 주철의 미세조직 속에는 구상 흑연, CV, 이상흑연(chunky), Pearlite와 같은 여러 흑연이 있다. 이러한 구상 흑연은 다른 흑연과 형태적 유사성을 갖는다. 또한 구상흑연은 크기, 개수, 밀집도에 따른 물리적 성질을 알 수 있다. 미세조직 속 구상흑연 판별 연구는 기존에 연구자가 구상 흑연과 다른 흑연을 직접 판별하거나, 색상 구분을 통한 객체 인식을 통해 판별되었다. 이러한 방법들은 연구자의 주관성과, 구상 흑연 외의 다른 흑연까지 인식되어 정확한 판별이 힘들다. 따라서 본 연구에서는 U-Net을 사용하여 주철의 미세조직에서 구상 흑연 영역화를 연구하고자 한다. 구상 흑연 미세조직을 segmentation하는 사례를 찾아보기 어려워, 특히 데이터의 미세조직 이미지를 이용하여 Label을 제작하였다. 본 논문에서 U-Net을 사용하여 segmentation은 기존 방식보다 정확하게 판단하였다. 또한 이를 통해 판별된 구상 흑연으로 구상 흑연 입수를 측정하고 미세 조직 속 구상 흑연 입수(분율)을 구할 수 있다. 구해진 분율을 통해서 구상 흑연 주철 연구의 간소화와 성능평가에서 조금 더 높은 객관성을 확보할 수 있다.

중심어 : 영상분할 ; 구상 흑연 주철 ; U-Net;

1. 서 론

주철은 매우 오래된 역사를 가지고 있다. 철기 시대부터 많은 분야에서 사용되어 왔으며 오랜 시간 동안 다양한 변화와 성능 개선이 이루어졌다. 그와 함께 주철에 대한 많은 연구와 개발이 이루어지고 있다. 그 중 구상 흑연 주철은 일반적인 주철보다 인성이 강하며, 주조라는 최고의 장점을 가지고 있어 많은 곳에서 쓰인다. 구상 흑연 주철의 성능 평가는 물리적 성질을 직접 측정하거나, 미세조직 분석하는 방법들이 있다. 그 중에서 미세조직 분석 방법은 다음과 같다. 미세조직 속 구상 흑연과 타 조직과의 판별 후 미세조직 전체에서 구상 흑연의 분율을 측정하는 것이다. 이러한 판별 방식들에서 기존의 구상 흑연 주철의 미세조직에서 여러 판별 방식들이 있다. 연구자가 직접 판별하는 방법과 미세조직 이미지에서 그레이스케일로 변환하여 색상의 차이를 통해 물체 인식하는 방식들이다. 그 중 연구자가 직접 판단하는 경우는 사람의 주관성이 들어가 불확실성이 크다[1]. 또한 물체 인식 방법은 색상 차이로

만 구분하게 되는 구조로 다른 흑연까지 구상 흑연으로 인식되게 된다는 문제점이 있다. 본 연구에서는 기존 방법에서의 신뢰도를 보완하고자 한다. 구상 흑연 주철의 미세조직에서 segmentation을 사용하여 미세조직 속 구상 흑연 판별하는 방법에 대해 제안한다.

구상 흑연 주철의 특허 데이터를 사용하였는데, 구상 흑연 미세조직에서 구상 흑연 segmentation을 위한 labeling 된 사례를 찾아보기 어려워 직접 labeling하여 사용하였다 [2]. 그 다음 학습된 모델로 구상 흑연 주철의 미세조직에서 Pearlite, CV, 이상 흑연과 같은 유사한 형태와, 색상을 가지고 있는 조직 또한 구분하게 될 것이다. segmentation 성능 평가는 dice coefficient를 사용하여 측정 한다. 이러한 연구를 통하여 미세조직 속 구상 흑연의 개수에 따른 입수를 구할 수 있다. 이는 구상 흑연 주철의 성능 평가가 기존 방식보다 객관적인 방식으로 이루어질 것이다.

2. 관련 연구

2.1 금속 미세조직 판별 연구

금속의 미세조직은 물질의 기원을 저장하고 물리적, 화학적 성질을 결정한다. 금속의 미세 조직 분류와 관련된 기존 작업은 앞서 설명한 두 가지 특징이 있다. 첫째 전문가들에 의한 수작업이 있다. 이는 주관성이 짙어 불확실성이 크다. 둘째 다소 간단하게 설계된 detection을 활용하는 것이다. 이 방법을 사용하면 다른 흑연까지 물체 인식되어 정확한 판별이 어려우며, 마지막 단계에서 수작업으로 다시 수정을 해야 한다. 위 내용과 유사한 문제점 해결을 위해서 최근 SEM(투과 전자 현미경, scanning electron microscope)을 사용하여 강철의 다양한 조직 상(phase)을 촬영된 MECS 데이터를 판별하는 연구가 이루어 졌다 [1]. 기존 연구에서는 MECS 데이터의 미세조직 판별하는 방법으로 MVFCN을 사용되었다. MVFCN은 핵심단위 영상 분할(pixel-wise segmentation) 방식으로 통하여 학습한다[1]. 이미지 분류 모델을 사용할 때, 높은 정확도를 보인다. 또한 입력 데이터의 크기를 직접 조정하여 차별성을 두었고, CNN학습에서 특징 추출과 분류단계를 분리하지 않고 end-to-end 방식으로 사용됐다. 다양한 모델들과 분류 정확도 비교했을 때, CIFAR-NET은 57.03%, VGG16은 66.50%의 분류 정확도를 달성하였다. 이에 반하여 MVFCN을 사용할 시 93.94%의 분류 정확도를 보였다[1].

2.2 구상 흑연 주철(Spheroidal graphite cast iron)

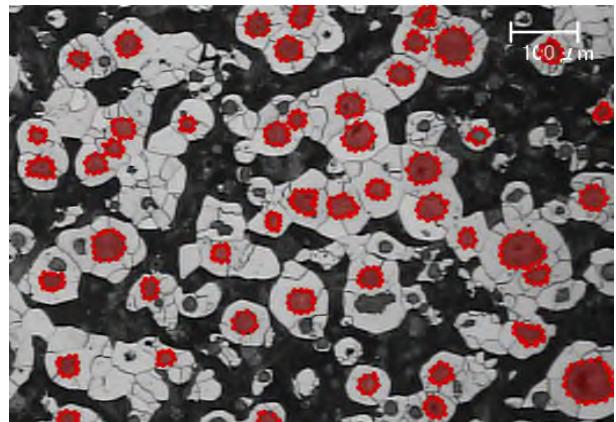
구상 흑연 주철은 강도와 연성이 높은 주철로 자동차 바퀴 부품과 엔진 부품에 알맞게 적용된다. 구상 흑연의 둘레는 Ferrite 둘러 쌓여있으며 Pearlite로 바탕을 이룬다. 물리적 성질로는 인장 강도(tensile strength)가 550MPa 이상, 연신율(percentage of elongation)이 12% 이상이다. 미세조직 속 구상 흑연은 직경이 $10\mu\text{m} \sim 100\mu\text{m}$ 의 사이즈를 갖고 있다. 사이즈 측정은 전체 면적에서 나타나는 구상 흑연의 개수를 구하여, 구상 흑연 입수를 구한다. 구상 흑연 입수는 구상 흑연 입수는 전체 미세조직 이미지에서의 구상 흑연이 차지하는 면적을 나타내며, 분율을 의미한다. 구상 흑연은 보통 분율이 10% 내외이다. 구상 흑연 주철은 분율에 따라 인성과 인장강도와 같은 여러 물리적 성질을 결정된다[3]. 본 연구에서의 segmentation으로 예측된 이미지의 핵심을 구할 수 있다. 구해진 결과 값으로 구상 흑연 입수를 측정한다면 구상 흑연 입수를 사용하여 성능 평가에 사용 가능하다.

3. 실험 및 결과

3.1 데이터셋 구축

구상 흑연 특허 데이터로 기존 연구가 없어, 구상 흑연 주철 특허 데이터를 사용하여 labeling을 직접 진행하였다[2]. 구상 흑연 주철 미세조직의 구상 흑연을 판별하기 위하여 구상 흑연 주철에서 OM(optical microscope) 현미경으로 관찰된 시험 편 단면의 조직 이미지 4장을 사용했다. 4장의 이미지는 각 2500×1912 pixel 사이즈이다. 적은 데이터로 충분한 학습을 위하여 augmentation을 진행하였다. 먼저 256×256 pixel 사이즈로 각 이미지를 overlappin-

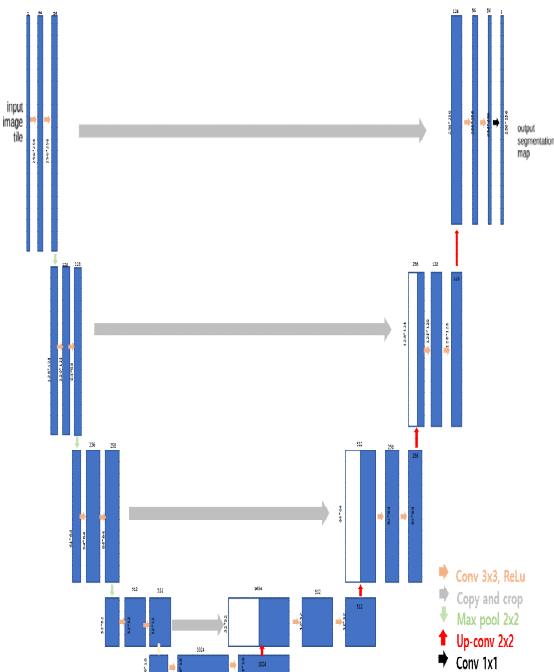
g하여 잘라내었다. 잘라낸 각 이미지를 OpenCV를 활용한 horizontal flip, vertical flip, rotate 등을 하여 총 4장의 이미지는 각 936장으로 총 3744장의 이미지로 augmentation 했다. 4장 중 3장을 학습에 사용하였고, 나머지 1장을 테스트로 구성하였다. 구상 흑연은 직경은 $10\mu\text{m}$ 이상 $100\mu\text{m}$ 이하의 크기를 만족해야 구상 흑연으로 판단되며, 미세조직에서 10% 내외의 구상 흑연이 존재해야 한다. 이와 같은 판단 기준점을 두고, 그림1과 같이 구상 흑연 미세조직 이미지를 LabelMe[4] annotation 프로그램을 사용하여 labeling 하였다.



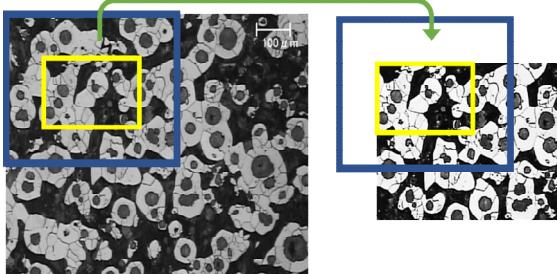
(그림 1) 구상 흑연 주철을 OM 현미경으로 관찰된 미세조직을 Labelme[4] 프로그램을 활용하여 labeling 작업

3.2 segmentation

segmentation으로는 U-Net을 사용하였다[5]. 충분한 학습을 위해 Data augmentation을 사용했다. 다음 그림2는 U-Net의 구조이다. 그림2의 앞부분은 contracting path로 input data의 context포착을 위한 목적으로 구성되어 있다. 뒷부분은 expanding path로 localization을 위한 구성이다. skip architecture 개념을 사용해 contracting path에서 나온 특징맵과 각 expanding 스텝마다 결합하는 방식이다. 이는 contracting path의 최종 특징맵으로 부터 보다 높은 해상도의 결과를 얻기 위해 행해진다. FCN[6]처럼 구조의 특성상 input data의 크기는 제약이 없고, 그림3은 노란색 영역의 이미지를 입력하면 노란색 영역의 segmentation 결과를 얻는다. overlap-tile을 사용하여 target data의 높은 정확도를 지닌 segmentation 결과를 얻을 수 있다. FCN과의 다른 중요한 2가지는, 먼저 up-sampling 과정에서 feature channel수가 많다. 이는 contracting path에서 down-sampling 과정에서 채널이 증가로 인한 것이다. 다음으로는 각 convolution의 유효한 부분만 사용한다. 이는 overlap-tile 기법을 사용하여 원활한 segmentation이 가능하도록 한다. U-Net을 사용하여 context 정보와 localization 정보를 얻을 수 있다[7]. 본 연구에서는 이러한 정보들로부터 구상 흑연과 다른 흑연들과의 분류 및 segmentation 된 이미지들을 사이즈 측정을 할 수 있다.



(그림 2) 본 연구의 U-Net, 이미지 분할(Image segmentation)을 목적으로 제안된 end-to-end 방식의 네트워크



(그림 3) Overlap-tile 본 연구의 데이터를 예시로 표기

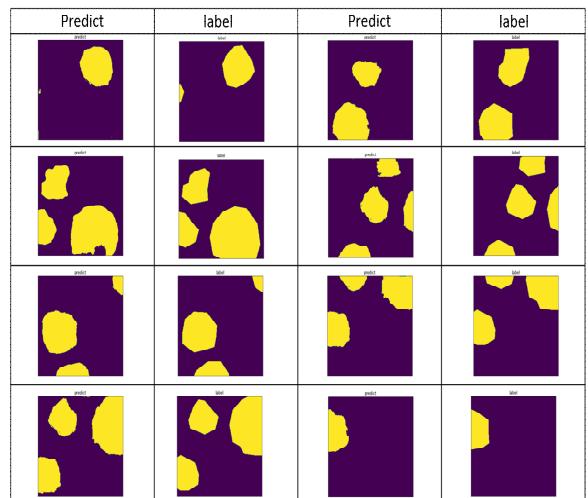
3.3 결과 및 분석

표1은 기존 연구 Network와 본 연구 U-Net의 비교 결과를 나타내었다. 기존 연구의 MVFCNN과 VGG16-Net은 다중 분류 목적을 둔 설계되어 정확한 비교는 어려워 임의의 수정 후 진행하였다. VGG16은 67.74%으로 U-Net의 96.15%보다 28.41% 낮으며, MVFCNN은 91.42%로 4.73% 낮게 나왔다. 그림4는 본 연구에서 테스트 이미지를 예측 값과 Ground Truth와 실제 이미지의 비교 이미지다. 표2에서 U-Net과 MVFCNN의 각각의 예측값과 Ground Truth, ImageJ의 Pixel의 개수를 구하여 구상 흑연 입수를 구하였다. 표2의 결과에서는 ImageJ보다 U-Net과 MVFCNN의 분율이 낮은 점을 확인할 수 있다. 이는 ImageJ에서는 [8] 다른 흑연까지 인식되어 실제 분율 값이 더 높게 측정된 점이다. 또한 MVFCNN의 결과도 높은 점수를 나타내었지만, 2개의 이미지를 제외하고 U-Net이 앞선 결과이다. 이러한 결과로 본 연구의 정확도 향상으로 다른 흑연들의 인식률이 낮아짐을 확인할 수 있다. 8개의 이미지를 테스트를 하여 모든 이미지에서 예측 값이 정확하진

못했지만, 두 이미지를 제외하고 유의미한 결과를 도출되었다. MVFCNN의 결과로 분율을 구하였다.

(표 1) 구상 흑연 주철 이미지 데이터를 segmentation한 U-Net과 기존 연구의 network들의 정확도 비교 결과 값

Method	Dataset	Dice Coefficient(Pixel Accuracy)
VGG16-Net ^[1]	구상 흑연 주철	67.74% (66.81%)
MVFCNN ^[1]	구상 흑연 주철	91.42% (91.24%)
U-Net	구상 흑연 주철	96.15% (95.33%)



(그림 4) U-net으로 예측한 Predicted와 Ground truth

(표 2) 학습에 사용된 구상 흑연 주철 미세조직 이미지를 사용하여 Ground Truth와 U-Net, MVFCNN, ImageJ 3가지의 분율을 측정 결과비교, Ground Truth의 구상 흑연 분율과 가까운 값이 정확함, Ground Truth와 U-Net의 Predicted 평균 차이는 0.1%, Ground Truth와 MVFCNN의 Predicted 평균 차이는 0.25% 차이를 보임.

	Ground Truth 분율 (픽셀 수)	U-net Predicted 분율 (픽셀 수)	MVFCNN Predicted 분율 (픽셀 수)	ImageJ ^[18] 분율 (픽셀 수)
Img 1	16.6% (10,917)	16.4% (10,781)	16.2% (10,613)	16.9% (11,075)
Img 2	2.4% (1,591)	2.2% (1,441)	2.7% (1,779)	2.8% (1,836)
Img 3	11.3% (7,408)	11.0% (7,208)	12.1% (7,973)	11.4% (7,471)
Img 4	13.5% (8,869)	13.4% (8,847)	13.6% (8,908)	14.9% (9,764)
Img 5	14.1% (9,278)	14.2% (9,301)	14.3% (9,371)	14.5% (9,511)
Img 6	15.4% (10,115)	15.2% (9,981)	15.5% (10,182)	15.4% (10,151)
Img 7	10.5% (6,915)	10.5% (6,882)	10.5% (6,894)	10.3% (6,782)
Img 8	3.6% (2,378)	3.5% (2,329)	3.7% (2,426)	3.8% (2,517)
원본 사이즈 구상 흑연의 분율	9.0002% (430,211/ 4,780,000)	8.90014% (425,427/ 4,780,000)	8.88195% (421,589/ 4,780,000)	9.30075% (444,576/ 4,780,000)

4. 결론 및 개선점

본 논문에서 U-Net을 사용하여 구상 흑연 주철 미세조직에서 구상 흑연 판별하였다. 판별의 목적으로는 기존의 방식에서 색상 구분을 통한 판별 방법과 주관성의 개입으로 정확도가 낮은 점을 보완하는 것이다. 구상 흑연을 segmentation된 사례가 없어 특허 데이터를 직접 labeling하여 사용하였다. labeling된 데이터를 사용한 segmentation 결과로 예측 값의 정확도 향상과 분율 측정에서 유의미한 결과가 나왔다. 또한 기존 연구자가 직접 판별하는 방법과, 색상 차이로 판별하는 두 방법보다 속도 개선이 되었다. 이러한 실험 결과를 보면, 개선 방향으로 크게 두 가지, 추가적인 접근 방향 두 가지가 가능할 것으로 보인다. 우선 개선할 점으로 구상 흑연 주철의 미세조직 이미지 데이터에 다양성을 높이는 것이다. 광학 현미경으로 관찰된 데이터는 조도, 실험실의 환경, 실험자의 주관성이 들어간다. 다음으로는 현재 학습에 들어가는 이미지 데이터는 구상흑연이 대부분인 데이터로서, 객체가 구상 흑연으로 이루어져 있다. 이후 실험에서는 Pearlite, CV, Chunky 와 같은 미세조직이 보다 많이 들어가 있는 데이터를 사용하면 조금 더 높은 분류 정확도를 가질 수 있을 것으로 보인다. 추가적인 접근 방향으로는 먼저, 이러한 미세조직

과 물리적 성질을 함께 학습하게 된다면, 추후 미세조직만으로도 물리적 성질을 예측할 수 있을 것으로 보인다. 이는 구상 흑연 주철의 경도 측정하는 실험을 단축시켜 실험 방법이 간소화되게 된다. 또한 성능 평가 또한 시간 단축되어진다. 본 연구에서는 Semantic segmentation으로 진행 하여 구상 흑연입수를 측정하였는데, 다음 접근 방향으로는 instance segmentation으로 진행하는 것이다. instance segmentation은 같은 Class이여도 서로 다른 instance로 구분해주는 것이다. 이러한 방법을 사용한다면, 각 구상 흑연 하나씩을 객체로 두어 개수를 측정한다면, 전체 면적에서의 개수를 통한 성능 평가 또한 가능할 것으로 보인다. 기존의 방식에서의 색상 구분 판별에서의 단점을 보완하였다.

참고 문헌

- [1] Seyed Majid Azimi, Dominik Britz, Michael Engstler, Mario Fritz & Frank Mücklich, “Advanced Steel Microstructural Classification by Deep Learning Methods”, Scientific Reports, volume 8–1, February 2018, pp.1–14
- [2] 和重 三戸和重 三戸直人 斎藤直人 斎藤, “Spheroidal graphite cast iron” 특허청, 출원번호 KR 20160025518 A0
- [3] 방현식, 김선중, “고용강화 페라이트계 구상흑연주철의 미세조직 및 기계적 성질에 미치는 합금원소의 영향” 『조선대학교 대학원 : 첨단소재공학과』 2021년 2월
- [4] labelme, <https://github.com/wkentaro/labelme>(02월 10일 2021년)
- [5] Abol Basher, Byeong C Kim, Kun Ho Lee, Ho Yub Jung, “Automatic Localization and Discrete Volume Measurements of Hippocampi From MRI Data Using a Convolutional Neural Network”, IEEE Access, Vol 8, May 2020, PP(99):1–1
- [6] Evan Shelhamer, Trevor Darrell, Jonathan Long, “Fully Convolutional Networks for Semantic Segmentation”, Computer Vision and Pattern Recognition, Nov 2014
- [7] 김서정, 김형석, “Multi-Tasking U-net 기반 파프리카 병해충 진단”, 스마트미디어저널, 9권 1호 pp 16 ~ 22
- [8] Abramoff, M.D.; Magalhães, Paulo J., Ram, Sunanda J. “Image processing with ImageJ”, Biophotonics International, volume 11, issue 7, pp. 36 – 42, June 2004