인공 신경망을 이용한 구오스테나이트 결정립계의 재구성 및 크기 예측

김봉규¹ · 구남훈^{2,*} · 이종혁² · 한준현^{1,*}

¹충남대학교 신소재공학과
²현대제철 기술연구소 선행연구팀

Reconstruction and Size Prediction of Prior Austenite Grain Boundary (PAGB) using Artificial Neural Networks

Bong-Kyu Kim¹, Nam Hoon Goo^{2,*}, Jong Hyuk Lee², and Jun Hyun Han^{1,*}

¹Department of Materials Science and Engineering, Chungnam National University, Daejeon 34134, Republic of Korea
²Advanced Research Team, Hyundai Steel Co., DangJin 31719, Republic of Korea

Abstract: To automatically reconstruct the prior austenite grains from as-quenched martensitic structure, we applied a deep learning algorithm to recognize the prior austenite grains boundaries hidden in the martensitic matrix. The FC-DenseNet architecture based on FCN (fully convolutional networks) was used to train the martensite and ground truth label of the prior austenite grain boundaries. The original martensite structures and prior austenite grain boundaries were prepared using different chemical etching solutions. The initial PAGS detection rate was as low as 37.1%, which is not suitable for quantifying the basic properties of the microstructure such as grain size or grain boundary area. By changing the weight factor of the neural net loss function and increasing the size of the data set, the detection rate was improved up to 56.1%. However, even when the detection rate reached 50% or more, the quality of the reconstructed PAGS was not comparable to the analytically calculated results based on EBSD measurements and crystallographic orientation relationships. The prior austenite grain size data sets were obtained from martensite samples via the FC-DenseNet method, and had a linear correlation with the mechanical properties measured in the same samples. In order to improve the accuracy of the detection rate using neural networks, it is necessary to increase the number of neural networks and data sets.

(Received November 16, 2020; Accepted November 24, 2020)

Keywords: A.I (artificial intelligence), artificial neural networks, deep learning, martensite, prior austenite grain boundary (PAGB)

1. 서 론

구조용 철강 소재의 개발에서 중요한 강화상인 마르텐사이트 조직은 탄소강을 오스테나이트 영역까지 가열하고 급속 냉각처리에 의해서 얻어진다. 마르텐사이트는 빗살무늬 모양의 침상 조직으로 구성되어 있으며 이를 래스(lath)라고 부른다. 침상의 래스구조는 그 특징을 정의하기 매우

어려우며 조직 관찰상 길이와 폭이 구분되는 정도이다. 한편 이러한 래스가 배열된 방향은 급냉 이전 재 가열 단계에서 생성된 오스테나이트 결정립의 크기와 방향에 따라 결정되는데, 이러한 오스테나이트 결정립에 관한 정보는 급냉 이후에 생성된 래스의 관찰 만으로는 정확하게 알기 어렵다. 따라서 화학성분이 동일한 경우라도 마르텐사이트 조직의 기계적성질은 재가열과 급냉 열처리의 공정 변수에 따라서 크게 다르지만 이에 따른 조직학적 차이점을 밝혀내는 것은 매우 어렵다 [1-5].

높은 강도를 가지는 마르텐사이트 조직의 특성상 외력에 의한 가공 및 변형 조건에서 파단이 발생하기 쉬운데 이 파단 경향은 래스의 조직 차이로는 판단하기 어렵고, 급냉 이전의 오스테나이트 조직 상태에 따라 결정되며 오스테나

- 김봉규: 석사과정, 구남훈·이종혁: 연구원, 한준현: 교수
*Corresponding Author: Jun Hyun Han
[Tel: +82-42-821-5633, E-mail: jhhan@cnu.ac.kr]
**Corresponding Author: Nam Hoon Goo
[Tel: +82-41-680-8252, E-mail: namhgoo@hyundai-steel.com]
Copyright © The Korean Institute of Metals and Materials

이트의 결정립계를 따라 파단이 전파되는 양상이 자주 관찰된다. 특히 이러한 파단 경향은 마르텐사이트 조직이 생성된 후 취성을 완화 시키기 위하여 실시되는 템퍼어닐링(temper annealing) 처리 시 특정한 온도구간에서 관찰되며 이 현상을 템퍼취성(temper embrittlement)이라고 하는데, 그 중요한 원인은 오스테나이트 결정립에서의 고용원소 편석현상으로 밝혀졌으며 템퍼링된 마르텐사이트 조직 내에서 C, Mn과 같은 고용원소들이 결정립계를 따라 분포하는 현상이 관찰된 바 있다 [6,7]. 따라서 마르텐사이트 조직의 기계적 물성은 마르텐사이트 변태 이전 고온에서 존재하는 오스테나이트 조직에 영향을 받으며 특별히 이러한 경우의 오스테나이트를 구오스테나이트라고 부른다. 따라서 구오스테나이트의 결정립 크기와 방향성(texture)을 파악하는 것은 매우 중요하다.

하지만 구오스테나이트의 결정립계를 직접적으로 관찰하는 것은 결코 쉬운 일이 아니다. 현미경으로 관찰하기 위해서는 시편을 고온으로 유지하거나 연속적으로 승온하면서 조직을 관찰해야 하는데 이것은 전자현미경과 광학현미경의 어떤 경우라도 그 적용이 매우 제한적일 수 밖에 없다 [8]. 상온에서 관찰할 수 있는 방법 중에서는 마르텐사이트 조직에 특별한 에칭방법을 적용하여 마르텐사이트 래스가 아닌 구오스테나이트 결정립계(prior austenite grain boundary, PAGB)들이 드러나게 하는 방법과 EBSD(electron back scattered diffraction) 장치가 탑재된 전자현미경 관찰 조직으로부터 얻어진 OIM(orientation image mapping) 데이터를 기반으로 FCC-BCC 상변화의 결정학적 연관성을 추론하여 PAGB를 재구성하는 방법이 있다. 에칭법에 의해 생성된 PAGB 경우에는 에칭액의 조성 및 시간 및 온도에 따라 미세조직의 변화가 매우 민감하게 반응하여 정확한 결정립계의 관찰이 어려울 뿐 만아니라 본래의 마르텐사이트 조직의 특징을 동시에 관찰하기가 어렵다. 또한 관찰자에 따라서 결정립계의 해석이 다르게 나타날 수가 있으므로 정확한 분석을 위해서는 숙달된 전문가의 경험과 많은 시간이 필요하다 [9,10].

EBSD를 활용하여 분석하는 방법은 마르텐사이트로부터 얻어진 결정학적 정보를 바탕으로 상변화 이전의 결정방향을 픽셀(pixel)별로 추론하는 것인데 에칭방법에 비해서 상대적으로 정확한 PAGB의 재구성이 가능하고 특히 결정방위(crystallographic orientation)의 정보가 얻어지는 장점이 있다. 그러나 이 방법은 현재까지는 상변화의 결정학적 관계에 대한 근본적인 가설을 전제로 하고 있고 데이터 수집과 처리에 많은 시간이 소요된다는 단점을 가지고 있다 [1,11-19].

최근 딥러닝(deep learning)을 활용한 이미지 인식 기술의 효율성이 큰 화제가 되고 있으며 이러한 이미지 인식 기술을 철강의 미세조직 분석에 접목시키는 연구들이 꾸준히 진행되고 있다. 딥러닝 방식을 통한 이미지 처리 기법은 여러 종류가 있으며, 크게 분류(classification)와 분할(sematic segmentation)로 나눌 수 있다 [20]. 그림 1은 컴퓨터 비전(computer vision) 분야의 분류와 분할의 예시를 보여준다. 분류는 입력 이미지가 여러 라벨 중 어떤 라벨에 해당하는지를 보여주는 기법이다. 분류를 위한 신경망은 대개 convolutional 계층을 포함하는 구조를 가지며 이런 신경망을 대표적으로 convolutional neural networks(CNN)이라고 부른다 [21,22]. 분할은 이미지 내에 분류하고자 하는 객체가 여러개인 경우 각각의 객체를 이미지 내 픽셀 별로 따로 구별하여 표기하는 기법이다 [23,24].

마르텐사이트에 특수한 에칭기술을 적용하여 PAGB를 관찰하는 방법에 있어서 기존의 연구 결과에 의하면 원래의 마르텐사이트와 구오스테나이트 결정립을 겹친 이미지를 분석하면 PAGB의 흔적이 마르텐사이트 래스의 배열상에 일부 나타나는 것을 발견할 수 있다. 여기서 알 수 있는 사실은 마르텐사이트 조직 상에서 래스들이 배열되는 패턴 사이로 구오스테나이트의 결정립계가 드러나게 된다는 것이다. 이것을 기계학습의 이미지 분할 기법과 연결 지어 생각하면 마르텐사이트 조직을 수많은 래스들로 구성된 기지 조직(matrix)과 PAGB로 구성되는 이미지 분할 학습 문제로 처리할 수 있다. 기계학습에 의해서 이미지 내의 다양한 요소를 정확히 찾아내는 등 최근 신경망의 비약적인 성능 향상 사례들을 고려하면 기계학습에 의해서 마르텐사이트 조직과 에칭을 통해서 드러난 PAGB를 신경망에 투입하여 학습 시키면 이후에 마르텐사이트 조직에서 자동으로 구오스테나이트 결정립 크기(prior austenite grain size, PAGS)를 추출해내는 신경망의 구현이 가능할 수 있을 것으로 판단된다. 따라서 본 연구에서는 마르텐사이트로부터 PAGS를 추출하는 신경망을 구성하였으며 이를 학습하기 위한 데이터 집합을 준비한 후 최종적으로 학습된 신경망의 성능을 평가하였다.

2. 실험 방법

2.1 신경망의 구성

이미지 해석을 위한 신경망의 종류는 크게 두가지로 구분 되는데, 첫번째, 다수의 이미지를 분류(classification)하는 용도로 사용되는 신경망과 두번째, 한개의 이미지에 포함되는 다수의 객체(object)를 각각 구분하여 분할(semantic

Fig. 1. Structures of CNN (convolutional neural networks) (a) and FCN (fully convolutional networks) (b).

segmentation)해 내는 기능을 가지는 신경망이다. 두가지 신경망 모두 이미지의 픽셀 데이터를 기반으로 신경망 학습을 진행하며 학습효율을 높이기 위해서 여러 단계의 convolution 연산을 수행한다는 점이 공통된 특징이다. 이것은 convolution 연산을 통해서 분류 내지는 분석하고자 하는 이미지의 데이터 픽셀을 특징적으로 압축시킨 행렬을 구성하게 되고 이것으로부터 계산효율이 향상된다.

그림 1(a)에 이미지 분류를 위해 사용되는 CNN (convolutional neural networks) 신경망의 구조를 도시하였다. 원본 이미지에 대하여 여러 번의 convolution과 pooling을 반복하여 작은 단위의 축소된 행렬을 구성하고 최종 단계에서는 축소된 행렬 원소를 일렬로 나열하여 1차원 행렬을 구성한다. 1차원 행렬 값에 soft-max를 적용하여 학습하고자 하는 분류 집단에 속하는 지를 판단하고 지속적으로 학습을 수행한다. CNN 신경망에서는 원본 이미지의 특징만이 추출되고 이미지상의 각 구성요소와 그 요소의 위치 정보는 연산 및 학습 과정에서 모두 소실된다. 그런데 금속조직학에 응용 시에는 그 적용이 매우 제한적인데 이는 통상의 금속조직이 최소한 두개 이상의 다양한 상들(multi phases)로 구성되어있기 때문이다. 이외는 다르게 기본적으로 분할 용도는 원본 이미지의 각 구성요소를 위치 별로 구분해 내는데 사용된다. 이러한 신경망은 down-sampling구간과 up-sampling구간 두 가지 부분으로 구성된다. 최초의 성공적인 분할 신경망인 FCN (fully convolutional networks)이 이런 구조를 가지고 있으며, 이후 발표된 분할

Fig. 2. Structure of FC-DenseNet neural network.

신경망 역시 이런 구조를 채용한다. Down-sampling구간의 역할은 입력 이미지의 특징을 추출하고 공간정보를 줄여서 다음 계층에 전달하는 것이다. Up-sampling구간에서는 압축된 정보와 공간 크기를 다시 복원하여 최종적으로 이미지 내 각각의 픽셀에 라벨을 매칭시킨다. 이 중 down-sampling구간은 앞서 설명하였던 분류(classification)용도의 CNN구조를 사용한다. FCN의 down-sampling구간은 CNN의 대표적인 아키텍처인 convolution & pooling 구조를 거의 그대로 사용하고 있다. 전형적인 FCN 신경망 구조를 그림 1(b)에서 도시하였는데, 해당 신경망 구조는 convolution & pooling 층이 깊어질수록 그 성능이 저하되는 문제를 가지고 있다. 이 후 여러 연구에서 이를 개선하고자 하는 시도가 이어져 왔으며 그 중 최근에 많은 주목을 받은 신경망이 DenseNet이다.

본 연구에서는 이 DenseNet을 기반으로 만들어진 분할용 신경망인 FC-DenseNet을 사용하였으며 FC-DenseNet의 구조를 그림 2에 나타내었다. DenseNet에서는 이전 계층의 출력값을 채널(channel)방향으로 계속 더하는 concatenate라는 기법을 사용한다. 이전 신경망들은 입력 데이터가 여러 계층을 지나면서 점차 흐려지는 단점이 있는데 concatenate 기법은 입력 데이터의 정보를 끝까지 유지할 수 있는 장점을 가지고 있다. 그러므로 집약적인 데이터를 밀도 있게 유지할 수 있기 때문에 이 신경망을 DenseNet라고 부른다. 앞선 계층들의 정보가 집약되는 과정은 Denseblock (DB)

이라는 구간 안에서 진행되며, 각각의 DB내의 Dense계층에서 새롭게 채널 방향으로 추가되는 특징맵(feature map)의 수를 growth rate라고 부른다. 그림 2에 나타난 바와 같이 down-sampling구간 내 DB에서 데이터의 특징이 추출되고 transition-down 계층에서는 데이터의 공간 크기가 축소된다. 또한 DB를 통해 기존 FCN보다 데이터의 흐름이 유연하게 추출된 데이터는 다시 up-sampling 구간에서 복원된다. 이때 transition-up계층으로 공간 크기를 증가시키면서 같은 공간 크기를 갖는 down-sampling구간의 데이터를 넘겨받는 skip connection과 DB로 원본 데이터의 해상도를 유지하는데 도움을 받는다. 이처럼 본 연구에서 사용된 FC-DenseNet은 down-sampling구간 그리고 up-sampling구간 모두 기존 FCN보다 우월한 구조를 갖는다.

2.2 데이터 준비

먼저 0.2C-6.5Mn-1.5Si의 조성을 갖는 실험용 철강 시편을 주조 및 압연을 통해 제조한 후 860 °C에서 2시간 오스테나이트 열처리 후 급냉 과정을 통하여 마르텐사이트 조직을 생성시켰다. 해당 마르텐사이트 조직의 항복강도를 측정된 결과 1.3GPa 이상임을 알 수 있었다. 준비된 마르텐사이트 시편을 20 mm (L) × 10 mm (W) × 0.5 mm (T)의 크기로 절단 및 연마한 후 광학현미경으로 X1200의 배율에서 미세조직을 관찰하였다. 최초의 관찰은 통상적인 나이탈(nital) 에칭 방법을 사용하여 마르텐사이트의 래스와 packet 조직 유무를 확인하였고, 해당 시편에 위치 표시 인자를 설정하고 다시 연마하여 동일 위치에 대하여 피크릭산(picric acid) 용액을 사용하여 에칭하였다. 에칭용액을 변경한 이유는 마르텐사이트 조직을 관찰하고자 하는 것이 아니라 마르텐사이트 조직 관찰에서 드러나지 않는 오스테나이트 결정립을 관찰하기 위함이다. 일반적으로 피크릭산을 이용한 에칭은 Mn, P등의 편석 지점에 대해서 선택적 에칭이 가능하므로 주로 결정방위 차이에 대한 에칭이 지배적인 나이탈 에칭에서는 드러나지 않는 고용원소가 편석된 PAGB의 관찰이 가능하다. 그러나 피크릭산 에칭 만으로도 완벽하게 드러나지 않은 PAGB를 보다 명확히 표시하기 위해 polygonal austenite 결정립의 형상을 가정하고 PAGB를 연속적으로 연결하는 작업을 수작업을 통해 추가로 실시하였다. 이후 수작업을 통해 보정된 이미지의 픽셀 정보를 변형하여 그림 3와 같이 grain matrix (Green)와 grain boundary (Red)가 선택적으로 드러나도록 이미지를 처리하였다. 그림 3에 나타난 바와 같이 FCN 신경망을 학습하기 위해 원본 이미지로서 나이탈 에칭된 마르텐사이트 이미지를 준비하고, 여기에 피크릭산 에

Fig. 3. Structure of learning data. (a) and (b) are etching images of 0.2C-6.5Mn-1.5Si steel, and (d) and (c) show grain boundary marking and generated ground truth, respectively. (e) and (f) are one set of training nital etching image and ground truth, respectively.

칭 후 수작업으로 보정한 PAGB 이미지를 원본 이미지에 대한 GT (ground truth)로 준비하였다. 초기에 준비한 이미지는 1194 × 1194 픽셀의 크기로서 총 61세트를 구성하였다. 각 세트의 이미지는 마르텐사이트 래스와 packets이 다수 분포하고 있어 이를 분할하여 사용할 수 있을 것으로 판단하고 256 × 256 픽셀의 크기로 분할하여 총 1525개의 분할 세트를 구성하고 최종적으로 이것을 FC-DenseNet의 신경망에 학습 데이터로 공급하였다. 그림 4에 데이터 분할 과정을 자세히 도시하였다.

3. 결과 및 고찰

3.1 학습 결과 분석

그림 5은 500회의 신경망 학습 후에 학습 진행의 척도로 정한 loss function의 수렴을 확인 한 후의 결과를 도시한 것이다. 그림 5에서 나타난 것과 같이 원본 이미지와 GT에 비하여 학습 결과로 나타난 이미지는 PAGB를 정확하게 인식하지 못하였음을 알 수 있으며, 이때 인식률은

Fig. 4. Training data image segmentation procedure using 0.2C-6.5Mn-1.5Si steel.

Fig. 5. Neural network training results using 0.2C-6.5Mn-1.5Si steel. (a), (b), and (c) are input image, ground truth, and training results.

37.1% 정도로 분석되었다. 학습 결과를 분석해 본 결과 인식률 저하의 원인은 결정립 전체에 대하여 PAGB의 면적

Fig. 6. Neural network training results showing the effect of changing the weight of neural network using 0.2C-6.5Mn-1.5Si steel. (a) and (b) are etched input image and ground truth, and (c) and (d) are training results before and after changing the weight, respectively.

이 상대적으로 작았기 때문이며, 신경망의 출력단에서 softmax함수의 가중치 (weight)를 조절하지 않으면 PAGB를 제대로 인식할 수 없는 것으로 판단되었다. 따라서 기존의 데이터를 기반으로 새로운 학습 배치를 구성하고 신경망을 구성하는 각 레이어의 출력단의 softmax함수의 가중치를 결정립과 결정립계에 대하여 각각 0.01과 0.99로 큰 차이를 두고 학습을 다시 실시하였다. 그 결과를 그림 6에 나타내었으며 결정립 인식률을 표 1에 정리하였다. 표 1에서 알 수 있는 것과 같이 신경망 함수의 가중치를 크게 변경하였음에도 불구하고 PAGB의 인식률은 약 8%정도 상승하는데 그쳤다. 한편 가중치를 조정한 후, 데이터 세트의 크기를 증가시켜 기존의 초기 1350세트에서부터 2500세트, 최종적으로는 3600세트까지 증가 시킨 결과 PAGB의 인식률을 56%까지 향상시킬 수 있었으며 그 결과를 그림 7에 나타내었다.

3.2 구오스테나이트 결정립계(PAGB)

서론에서 언급한 바와 같이 마르텐사이트로부터 PAGB

Table1. Neural network training result according to weight and dataset

Data	Weight	Number (Dataset)	Accuracy (%)	Grain (%)	GB (%)
Data1	No weight	1350	95.13	98.26	37.12
Data1	Grain=0.01, GB=0.99	1350	94.65	97.30	45.18
Data2	Grain=0.01, GB=0.99	2500	93.84	96.05	53.54
Data3	Grain=0.01, GB=0.99	3600	93.59	95.62	56.84

Fig. 7. Neural network training result showing the effect of weight and dataset number using 0.2C-6.5Mn-1.5Si steel. (a) and (b) are etched input image and ground truth. (c)~(f) are training results according to weight and dataset number shown in Table 1.

를 재구성하는 방법은 화학적 에칭법 또는 EBSD 분석결과를 활용하는 방법 등 다수 보고되고 있다 [25,26]. 본 연구에서는 인공 신경망을 이용하여 분석된 결과와 기존의 방법들(화학적 에칭법, EBSD결과 활용법)을 활용하여 분석된 결과를 비교하였으며 그 결과를 그림 8에 나타내었다.

그림 8에서 알 수 있는 바와 같이 결정립계의 인식 정도를 정성적으로 살펴보면 신경망을 통해 얻어진 가장 좋은 결과는 화학적 에칭법을 이용하여 분석된 결과와 유사하지만 EBSD 분석결과를 활용한 방법과 비교할 때는 그 정확도가 크게 낮음을 알 수 있었다. 특히 EBSD 분석결과를 기반을 한 방법은 마르텐사이트 기지의 각 측정 포인

트에서의 오일러 각(Euler angle)을 기준으로 5~15도의 misorientation 값으로 결정립계를 분류하면 별다른 처리 없이도 화학적 에칭법 및 기계 학습 방법과 유사한 정도의 PAGB 인식률을 나타내었다. 그런데 오스테나이트로부터 마르텐사이트로의 상 변화에 대한 Kurdjumov-Sachs (K-S) 방위관계를 가정하고 측정된 오일러 각을 결정학적 가설을 기반으로 엄밀하게 변환하고 분류한 결과 그림 8에서 보여준 것과 같이 결정립의 크기 모양이 명확하게 구분될 수 있었을 뿐 만 아니라, 그 방위에 대한 정보도 얻을 수 있었다. 하지만 EBSD 분석결과를 기반으로 얻어진 PAGB의 재구성 결과물도 변환과정에서 중요한 몇가지 결정학적

Fig. 8. Comparison of various PAGB reconstruction methods using 0.2C-6.5Mn-1.5Si steel.

가설을 기반으로 하므로 일부 불확실성을 내포하고 있으며 또한 오랜 측정과 계산 시간이 요구된다. 따라서 일반적인 광학적 미세조직 분석에서 널리 사용되고 있는 나이트 에칭법을 적용하여 이미 학습된 신경망을 적용하면 수초 이내에 PAGB를 50%이상의 확률로 재구성 할 수 있음을 알 수 있다.

일반적으로 마르텐사이트로 이루어진 철강 소재의 기계적 특성은 구오스테나이트의 크기와 분포에 의해 크게 영향을 받으며 [27,28], 위에서 언급한 과정을 통하면 마르텐사이트의 기계적 성질을 크게 좌우하는 PAGB의 윤곽을 신속하게 분석할 수 있으므로, 신경망을 활용한 마르텐사이트의 PAGB 재구성 방법은 고강도 철강 소재의 불량 분석, 특히 파단 분석에 유용하게 적용될 수 있다. 신경망을 통한 PAGB 재구성 기법의 적용성을 평가하기 위하여, 본 연구에서는 0.2C-6.5Mn-1.5Si 조성을 가지는 강재를 850, 900 °C에서 각각 1분, 5분간 열처리한 후 급냉함에 의해 각각 5개의 마르텐사이트 시편을 얻었으며, 총 20개 마르

텐사이트 시편의 미세조직 관찰 및 인장시험을 실시하고 관찰된 미세조직에 대하여 신경망을 통한 PAGB 분석을 실시하였다. 인장시험은 만능재료 시험기(Instron 4484)를 이용하여 상온에서 0.9 mm/min의 속도로 실시하였으며, 인장시편의 폭과 두께는 각각 25 mm, 0.5 mm이고 표점거리는 50 mm이었다. 동시에 PAGB 분석 결과로부터 결정립 크기를 산출하여 이를 인장 시험 결과와 연관시켜 분석하였으며 그 결과를 그림 9과 표 2에 나타내었다.

그림 9은 마르텐사이트 시편의 열처리 온도와 시간에 따른 PAGS와 항복강도값 사이의 관계를 나타내며, 직선의 피팅은 최소제곱법을 이용한 선형회귀분석을 이용하여 진행되었다. 그림 9에서 보는 바와 같이 열처리 조건에 따라 구오스테나이트 결정립의 크기가 각각 다르게 측정되었고, 이 결과를 측정된 항복강도값과 연관시켰을 때 구오스테나이트 결정립의 크기와 항복강도값 사이에 선형적 상관관계를 있음을 확인 할 수 있었다. 이 결과로부터 신경망을 통해 재구성한 구오스테나이트 결정립 미세구조가 야금학적 타당성을 가질 수 있는 것으로 판단 할 수 있다. 하지만 보다 정확한 분석을 위해서는 신경망의 구성이 좀더 정교하게 이루어져야 하며 데이터 세트의 크기가 증가되어 PAGB의 인식률을 더욱 향상시킬 필요가 있다.

4. 결 론

마르텐사이트 조직으로부터 급냉 이전의 가열단계에서 존재하는 오스테나이트 결정립계 즉, 구오스테나이트 결정립계(prior austenite grain boundary, PAGB)를 재구성하기 위하여 심층 신경망과 데이터 세트를 구성하여 기계적 학습을 수행한 결과 다음과 같은 결론을 얻었다.

1) FC-DenseNet으로 구성된 신경망으로 학습을 수행한 결과 초기에 출력단의 가중치(weight)를 고려하지 않았을 때 PAGB의 인식률은 37.1%로 매우 낮았으며, PAGB 인식률을 향상시키기 위해 신경망 출력단에서 결정립과 결정립계의 가중치를 각각 0.01 과 0.99로 조정하여 학습을 다

Fig. 9. Relationship between PAGS (prior austenite grain size) and yield strength according to annealing temperature (850 and 900 °C) and time (1 and 5min) in 0.2C-6.5Mn-1.5Si steel. 850-1 means the sample heat-treated at 850 °C for 1min.

Table 2. Relationship between PAGS and yield strength according to annealing temperature (850 and 900 °C) and time (1 and 5min) in 0.2C-6.5Mn-1.5Si steel.

Specimen	Annealing temp (°C)	Annealing time (min)	Mean PAGS (μm)	Mean yield strength (MPa)	Y.S St. Dev.* (MPa)
850-1	850	1	4.8	1470	±16.62
850-5		5	5.6	1433	±7.47
900-1	900	1	5.4	1440	±27.60
900-5		5	7.0	1380	±28.75

*: Yield strength standard deviation

시 수행한 결과 인식률은 45%로 향상되었다. 또한 가중치를 부여한 신경망과 데이터 세트를 3500개까지 늘려 학습을 수행한 결과 PAGB의 인식률을 56%까지 향상시킬 수 있었다.

2) 다양한 열처리 조건으로 다양한 마르텐사이트 조직을 얻은 후, 측정에 의해 얻어진 항복강도값과 최적화된 신경망을 적용하여 학습된 PAGS 결과를 분석한 결과 구오스테나이트 결정립의 크기와 항복강도값 사이에 선형적 상관관계를 있음을 확인 할 수 있었다.

3) EBSD 분석기법을 통한 PAGB 재구성 방법과 비교할 때 신경망을 사용하는 방법은 매우 짧은 시간 안에 마르텐사이트 조직으로부터 PAGB의 재구성이 가능하며 인식률은 50%를 상회하였다. 다만 신경망을 이용한 방법은 EBSD를 통한 결정학적 계산방법에 비하여 빠른 시간 안에 결과를 얻을 수 있는 장점이 있으나 정확도가 떨어지는 단점이 존재하므로 정확도를 향상시키기 위해서는 신경망의 구성과 데이터 세트의 수를 증가시킬 필요가 있다.

감사의 글

이 연구는 2020년도 산업통상자원부의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구이며 (P0002019, 2020년 산업전문인력역량강화사업), 연구비 지원에 감사드립니다.

REFERENCES

1. M. Abbasi, T. W. Nelson, C. D. Sorensen, and L. Wei, *Mater. Charact.* **66**, 1 (2012).
2. J. H. Han, A. K. da Silva, D. Ponge, D. Raabe, S. M. Lee, Y. K. Lee, S. I. Lee, and B. C. Hwang, *Acta Mater.* **122**, 199 (2017).
3. S. Morito, H. Saito, T. Ogawa, T. Furuhashi, and T. Maki, *ISIJ international* **45**, 91 (2005).
4. M. Yang, Y. Zhong, and Y. L. Liang, *Met. Mater. Int.* **24**, 970 (2018).
5. E. H. Hwang, H. G. Seong, and S. J. Kim, *Korean J. Met. Mater.* **56**, 570 (2018).
6. M. Kim, Y. Kang, N. Kim, S. Lee, S. Song, and N. Kang, *Korean J. Met. Mater.* **57**, 430 (2019).
7. R. M. Horn and R. O. Ritchie, *Metall. Mater. Trans. A* **9**, 1039 (1978).
8. D. Zhang, H. Terasaki, Y. I. Komizo, *Acta Mater.* **58**, 1369 (2010).
9. A. W. Brewer, K. A. Erven, and G. Krauss, *Mater. Charact.* **27**, 53 (1991).
10. V. L. Viswanathan, *Metallography* **10**, 291 (1977).
11. N. Bernier, L. Bracke, L. Malet, and S. Godet, *Mater. Charact.* **89**, 23 (2014).
12. A. F. Brust, E. J. Payton, V. Sinha, V. A. Yardley, and S. R. Niezgoda, *Metall. Mater. Trans. A* **51**, (2020).
13. A. F. Brust, S. R. Niezgoda, V. A. Yardley, and E. J. Payton, *Metall. Mater. Trans. A* **50**, 837 (2019).
14. C. Cayron, B. Artaud, and L. Briottet, *Mater. Charact.* **57(4-5)**, 386 (2006).
15. K. Hata, M. Wakita, K. Fujiwara, and K. Kawano, *Nippon Steel and Sumitomo Metal Technical Report* **114**, 26 (2017).
16. M. Humbert, P. Blaineau, L. Germain, and N. Gey, *Scr. Mater.* **64**, 114 (2011).
17. G. Miyamoto, N. Iwata, N. Takayama, and T. Furuhashi, *Acta Mater.* **60**, 1139 (2012).
18. G. Miyamoto, N. Iwata, N. Takayama, and T. Furuhashi, *Acta Mater.* **58**, 6393 (2010).
19. G. Miyamoto, N. Iwata, N. Takayama, and T. Furuhashi, *J. Alloys Compd.* **577**, S528 (2013).
20. A. Krizhevsky, I. Sutskever, and G. E. Hinton, *Adv. N. I. P. S.* p.1097-1105, Nevada (2012).
21. K. Simonyan and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*, *arXiv preprint arXiv 1409*, <http://arXiv.org>, (2014).
22. C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, *Proc. IEEE Conf. on C. V. P. R. W.* p.1-9, Boston, MA (2015).
23. S. Jégou, M. Drozdal, D. Vazquez, A. Romero, and Y. Bengio, *Proc. IEEE Conf. on C. V. P. R. W.* p.11-19, Honolulu (2017).
24. J. Long, E. Shelhamer, and T. Darrell, *Proc. IEEE Conf. on C. V. P. R. W.* p.3431-3440, Boston, MA (2015).
25. C. Ranger, V. Tari, S. Farjami, M. J. Merwin, L. Germain, and A. Rollett, *Metall. Mater. Trans. A* **49**, 4521 (2018).
26. V. Tari, A. D. Rollett, and H. Beladi, *J. Appl. Crystallogr.* **46**, 210 (2013).
27. S. Morito, H. Yoshida, T. Maki, and X. Huang, *Mater. Sci. Eng. A* **438**, 237 (2006).
28. Y. Prawoto, N. Jasmawati, and K. Sumeru, *J. Mater. Sci. Technol.* **28**, 461 (2012).