

삼차원 합성곱 신경망과 X선 단층 영상에서 추출한 형태학적 특징을 이용한 PEMFC용 가스확산층의 투과도 예측

유한길* · 윤군진*†

Permeability Prediction of Gas Diffusion Layers for PEMFC Using Three-Dimensional Convolutional Neural Networks and Morphological Features Extracted from X-ray Tomography Images

Hangil You*, Gun Jin Yun*†

ABSTRACT: In this research, we introduce a novel approach that employs a 3D convolutional neural network (CNN) model to predict the permeability of Gas Diffusion Layers (GDLs). For training the model, we create an artificial dataset of GDL representative volume elements (RVEs) by extracting morphological characteristics from actual GDL images obtained through X-ray tomography. These morphological attributes involve statistical distributions of porosity, fiber orientation, and diameter. Subsequently, a permeability analysis using the Lattice Boltzmann Method (LBM) is conducted on a collection of 10,800 RVEs. The 3D CNN model, trained on this artificial dataset, well predicts the permeability of actual GDLs.

초 록: 본 연구에서는 고분자 전해질막 연료전지용 가스확산층의 투과도를 예측하기 위해 삼차원 합성곱 신경망 모델을 사용하는 방법론을 소개한다. 먼저, 기계학습 모델을 학습시키기 위해 X-선 단층 촬영을 통해 얻은 실제 가스확산층 이미지에서 형태학적 특징을 추출해 가스확산층의 대표 체적 요소로 이루어진 인공 데이터셋을 생성한다. 이러한 형태학적 특성은 다공성, 섬유 배향, 직경의 통계적 분포가 포함된다. 구축한 인공 데이터셋 대표 체적 요소들의 투과도를 평가하기 위해 격자 볼츠만 방법이 사용되었으며 각각의 대표 체적 요소들의 투과도를 도출하였다. 이러한 인공 데이터셋을 통해 삼차원 합성곱 신경망 모델을 학습시켰으며 인공 데이터셋을 학습한 삼차원 합성곱 신경망 모델이 실제 가스확산층의 대표 체적 요소 투과도 또한 잘 예측하는 것을 확인하였다.

Key Words: 가스확산층(Gas Diffusion Layer), 고분자 전해질막 연료전지(Proton Exchange Membrane Fuel Cell), 삼차원 합성곱 신경망(3D Convolutional Neural Network), 미세구조(Microstructure)

1. 서 론

최근 몇 십년간 인간의 활동으로 인해 지구온난화와 기후 변화가 가속되고 있는 것으로 인식되어 이에 대한 대처

로 이산화탄소 배출 규제가 강화되고, 저공해 에너지의 수요가 커지고 있다[1-5]. 특히 자동차 업계의 경우, 이산화탄소 배출 규제강화로 인해 전기자동차, 수소자동차로의 패러다임의 전환이 요구되고 있다[6-8]. 여러 수소연료전지

Received 22 August 2024, received in revised form 18 September 2023, accepted 18 February 2024

*Department of Aerospace Engineering, Seoul National University

†Corresponding author (E-mail: gunjin.yun@snu.ac.kr)

중 낮은 (80°C)와 여러 출력조건에서 작동 가능하다는 장점이 있는 고분자 전해질막 연료전지는 차량용 수소연료전지로 적합해 연구가 활발히 일어나고 있다[9,10].

고분자 전해질막 연료전지(PEMFC)는 수소의 산화환원 반응을 통해 화학 에너지를 전기 에너지로 변화하는 발전 장치로 고분자막, 촉매층, 가스확산층, 분리판, 전류 집전 장치로 이루어져 있다[11]. PEMFC 작동 시, 분리판을 통해 들어온 수소기체가 음극(anode) 쪽 가스확산층을 통과해 촉매층에서 산화반응을 통해 수소 양이온이 되고 떨어져 나온 전자는 전류 집전장치로 이동한다. 이때 음극에서 생성된 수소 양이온은 고분자막을 통과해 양극에서 산소와 반응해 물이 생성된다[12,13]. 그 중 가스확산층은 반응물을 촉매층으로 확산시키는 가스수송 역할, 생성된 물과 열을 배출하는 물 배출 역할, 기계적 하중에 대한 지지체의 역할, 생성된 전자를 전류 집전장치로 전달하는 전기전도체의 역할을 수행하는 핵심 구성 요소이다[14-16]. 가스확산층은 탄소 섬유(Carbon fiber)로 이루어진 이종(Heterogeneous) 미세구조를 갖는다는 특징이 있으며 가스 확산의 용이성을 위해 높은 다공성을 갖는다. 그리고 이 때 가스확산층의 다공성 구조는 성능에 큰 영향을 미치게 된다[17]. 과거 문헌에서 이러한 가스확산층의 투과도, 구조, 제조방법, 소수성이 성능에 미치는 영향이 연구되었다[18-20]. 최근 인공지능의 장점들이 대두되면서 재료분야에서도 데이터 기반 연구들이 제시되고 있다[21-23]. 기존 연구들 중 신경망을 통해 가스확산층의 투과도를 예측하려는 시도도 있었지만, 훈련 데이터 획득에 시간과 비용이 많이 들며 3차원 합성곱 신경망을 이용한 가스확산층 투과도 예측 연구는 부족하다는 한계점을 가지고 있다.

본 연구에서는 삼차원 합성곱 신경망을 통해 가스확산층의 투과도를 예측하는 방법론을 제시한다. 먼저 실제 가스확산층의 삼차원 이미지를 컴퓨터 단층 촬영을 통해 도출하고 가스확산층의 구조를 특성화 하여 통계적으로 동등한 미세구조를 재생성 한다. 그 후 격자 볼츠만 방법(Lattice Boltzmann Method)를 통해 미세구조 데이터셋의 투과도를 도출한다. 마지막으로 앞서 생성한 데이터셋을 사용하여 삼차원 합성곱 신경망을 학습시킨다. 이를 통해 삼차원 이미지를 기반으로 가스확산층의 투과도 예측 방법론을 제시한다.

2. 가스확산층 미세구조 인공데이터셋 생성

2.1 X선 단층 이미지 획득

본 연구에서는 독일의 SGL(Smart solution in Graphite & Fiber)사에서 39BB 모델의 가스확산층을 공급받아 연구에 사용한다. 제공받은 가스확산층 시편은 고해상도 삼차원 X선 현미경(Xradia 620 Versa)을 사용해 2 마이크로미터 분해능으로 단층 촬영하였다. Fig. 1은 X선 현미경 시스템을

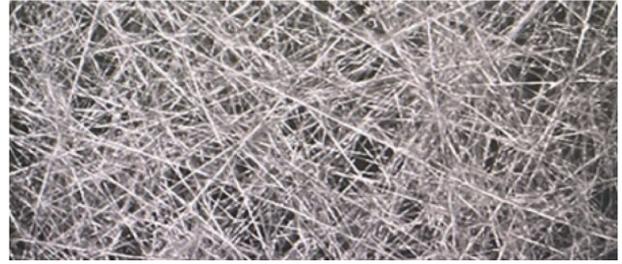


Fig. 1. Gas diffusion layer image obtained by X-ray tomography microscope system (SNU NCIRF)

통해 촬영한 가스확산층 단층 이미지를 보여준다. 얻어진 가스확산층의 단층 이미지는 adjust filter, gaussian filter, median filter, binary filter 등 여러가지 이미지처리 필터를 통해 이진 이미지로 변환되었다.

2.2 가스확산층 미세구조 특성화

삼차원 합성곱 신경망을 훈련시키기 위한 학습 데이터셋을 생성하기 위해, 실제 가스확산층 미세 구조 이미지를 특성화 및 재구성(Microstructure Characterization and Reconstruction)하여 통계적으로 동등한 대표체적요소(Representative Volume Element)를 생성한다. 미세구조 재구성에 앞서, 가스확산층 미세 구조 특성화를 진행하였다. 가스확산층 미세 구조 특성화를 위해서 X선 현미경 시스템으로 획득한 미세구조 이미지의 섬유 배향 분포, 섬유 직경 분포, 공극률을 수학적으로 모델링하였다. 먼저 가스확산층의 섬유 배향 분포를 모델링하기 위해 선 검출 알고리즘인 Hough-Transformation을 이용하여 각 섬유의 배향분포를 얻었다. 아래 그림 Fig. 2는 Hough-Transformation을 이용한 가스확산층 이미지의 섬유 검출 예시를 보여준다.

Hough-Transformation을 통해 가스확산층 이미지 내부의 섬유에 대해서 x 축과 z 축 사이의 각도 θ 와 z 축과 x - y 평면 사이의 각도 ϕ 를 얻었다. 이때 z 축과 x - y 평면 사이의 각도 ϕ

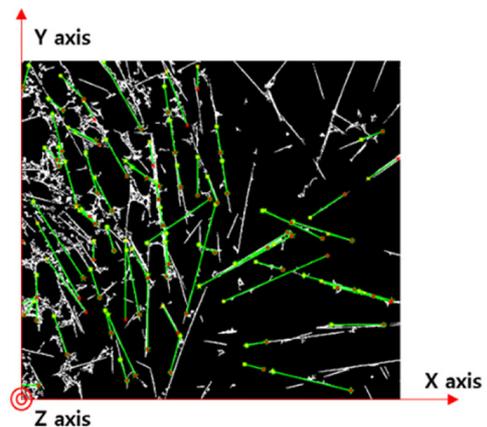


Fig. 2. Line detection using Hough-Transformation

Table 1. Probability density function and parameters obtained by microstructure characterization

	Fitting Curve	Parameter value
θ	$F(\theta) = \frac{1}{\sigma_1\sqrt{2\pi}} e^{-\frac{(\theta-\mu_1)^2}{2\sigma_1^2}}$	σ_1 : 3.8932 μ_1 : 90.5866
φ	$F(\varphi) = \frac{1}{\sigma_2\sqrt{2\pi}} e^{-\frac{(\varphi-\mu_2)^2}{2\sigma_2^2}}$	σ_2 : 43.3455 μ_2 : 98.7152
V_f	$F(V_f) = \frac{k}{\lambda} \left(\frac{V_f}{\lambda}\right)^{k-1} e^{-(V_f/\lambda)^k}$	λ : 0.081626 k : 2.0384
D	$F(D) = \frac{1}{D * \sigma\sqrt{2\pi}} e^{-\frac{(\ln(D)-\mu)^2}{2\sigma^2}}$	σ : 0.29536 μ : 1.37819

는 y-z평면 이미지에서 얻어진 각도와 x-y평면 이미지에서 얻은 각도를 이용해 얻는다. 특성화 작업으로 얻어진 θ , φ 확률분포를 정규분포를 통해 모델링하였다. 공극률 V_f 분포의 경우, X선 현미경을 통해 얻은 3차원 가스확산층 단층촬영 복셀 이미지에서 1000개의 $20 \times 40 \times 40$ 복셀 크기의 단위 셀 요소를 랜덤 추출해 계산하였다. 마지막으로 섬유 직경 D 은 X선 단층 이미지의 yz면에서 원형 형태의 섬유들을 Watershed 알고리즘을 통해 검출하고 면적을 계산해 섬유의 직경을 역산하였다. 이때 섬유의 횡단면은 원형으로 가정했으며, 특성화 결과 6~10 마이크로미터의 직경을 가지는 것으로 확인하였다. 이때, 섬유의 횡단면을 원형으로 가정하였기 때문에 이로 인한 편차 및 오차가 존재할 수 있다. 이는 문헌에 조사된 가스확산층의 섬유 직경과 일치하였다. Table 1은 미세구조 이미지의 형태학적 특성 분포를 수학적으로 모델링하기 위한 확률 밀도 함수와 대응되는 파라미터 값을 나타낸다.

2.3 가스확산층 미세구조 재구성

미세구조 특성화를 통해 도출한 가스확산층의 형태학적 특징 분포를 이용해 가스확산층 미세구조의 재구성을 수행하였다. Algorithm 1은 수행된 가스확산층 미세구조 재구성 과정을 나타낸다. 재구성 알고리즘의 입력 값으로 가스확산층 미세구조 특성화를 통해 도출한 여러 형태학적 특징의 통계적 분포가 주어진다. 공극률의 통계적 분포를 기반으로 재구성 대표체적 요소의 목표 공극률을 결정한다. 그 다음으로는 반복문을 활용하여 재구성 대표체적 요소가 목표 공극률에 도달할 때까지 탄소 섬유를 해당 요소에 채워 넣는 과정을 진행한다. 이때, 탄소 섬유의 직경과 배향은 가스 확산층의 특성화 작업을 통해 얻은 섬유의 특성과 일치하도록, Table 1에 제시되어 있는 확률분포 함수와 대응되는 변수 값을 사용하여 난수를 생성한다.

Algorithm 1. Algorithm to train and generate microstructure with given permeability and volume fraction

```

Input:  $F(\theta)$ ,  $F(\varphi)$ ,  $F(V_f)$ ,  $F(D)$ 
Output: Reconstructed GDL microstructure  $RVE^{Recon}$ 
1  $RVE^{Recon} \leftarrow$  Creates an voxel matrix with size  $20 \times 40 \times 40$ 
2  $VF^{Target} \leftarrow$  Random numer using Weibull distribution  $F(V_f)$ 
3 while  $|VF^{Target} - VF^{RVE}| > 0.01 * VF^{Target}$ 
4    $D \leftarrow$  Random numer generation using Log-Normal
   distribution  $F(D)$ 
5    $\theta, \varphi \leftarrow$  Random numer generation using Normal
   distribution  $F(\theta)$ ,  $F(\varphi)$ 
6    $(x, y, z) \leftarrow$  Create an random coordinate within size
    $20 \times 40 \times 40$ 
7    $\vec{l} = (\sin\theta\cos\varphi, \sin\theta\sin\varphi, \cos\theta) \leftarrow$  Create fiber direction
   vector
8    $F^{Unit} \leftarrow$  Create an fiber RVE with fiber diameter  $D$  and
   fiber orientation  $\vec{l}$  that passes point  $(x, y, z)$ 
9    $RVE^{Recon} = RVE^{Recon} + F^{Unit} \leftarrow$  Update
   Reconstructed RVE
10   $VF^{RVE} = ones(RVE^{Recon}) \leftarrow$  Caculate volume fraction of
   the Reconstructed RVE
11 End

```

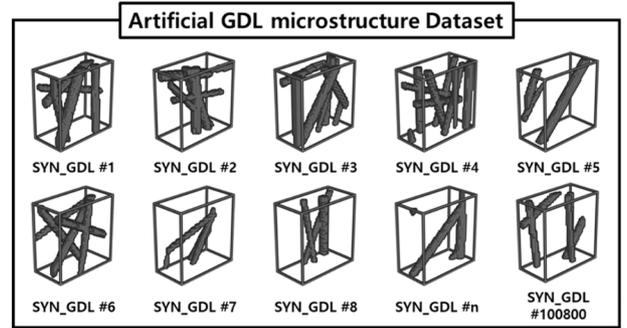
**Fig. 3.** Artificial dataset consists of gas diffusion layer microstructure

Fig. 3은 제시된 미세구조 특성화 및 재구성을 통해 생성된 가스확산층 미세구조 인공데이터셋의 모식도를 나타낸다. 재구성 알고리즘을 이용해 총 100800개의 대표체적요소를 생성하였으며 각각의 대표체적요소가 인공데이터셋에 저장되었다.

2.4 가스확산층 미세구조 실제 데이터셋 생성

실제 가스확산층의 미세구조 데이터셋은 X선 현미경 시스템으로 획득한 미세구조 이미지에서 200개의 $20 \times 40 \times 40$ 크기의 단위 셀 요소를 랜덤 추출해 구축하였다. Fig. 4은 실제 데이터셋을 얻은 모식도를 보이며 각각의 가스확산층 미세구조 실제 데이터셋을 구성하는 대표체적요소들을 나타낸다. Fig. 3에 나타난 재구성을 통해 생성한 대표체적요소와 Fig. 4에 나타난 가스확산층 미세구조 실제데이터셋이 굉장히 유사한 것을 알 수 있다. 공극률 측면에서도 실제 데이터셋과 인공데이터셋은 거의 비슷한 분포를 보였다.

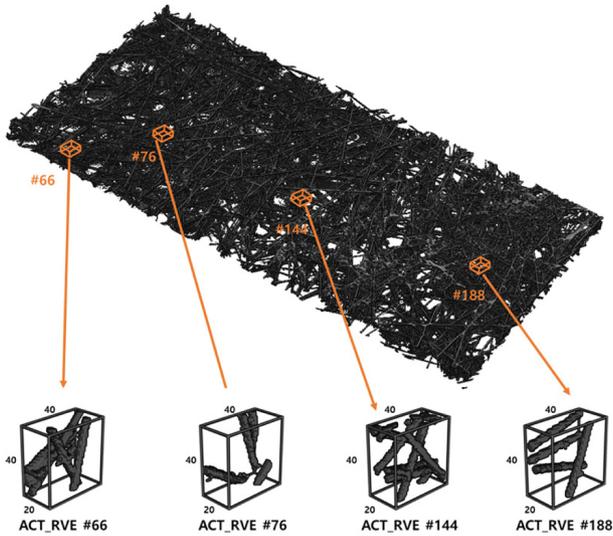


Fig. 4. Actual dataset consists of gas diffusion layer microstructure

2.5 격자 볼츠만 방법을 통한 가스확산층 이미지데이터셋 투과도 도출

삼차원 격자 볼츠만 방정식(Lattice Boltzmann Method)을 이용해 가스확산층 내부의 유동을 시뮬레이션하고 투과도를 도출하였다. 격자 볼츠만 방정식의 경우, 복잡한 모양 및 다공성 재료의 유동을 효율적으로 시뮬레이션 할 수 있어 많은 선행연구에서 또한 가스확산층에 대한 유체거동을 시뮬레이션 할 때 격자 볼츠만 방법을 사용한다. 이러한 격자 볼츠만 방정식은 유체의 움직임을 1) Collision process, 2) Streaming process 두 단계로 나누어 이를 반복해 유체 입자들의 분포함수들을 계산한다. 이는 각각 식 (1), 식 (2)와 같이 표현된다.

$$f_i(\vec{x} + \vec{e}_i \delta_t, t + \delta_t) = f_i(\vec{x}, t) + \Omega_i(f) \quad (1)$$

$$f_i(\vec{x} + \vec{e}_i \delta_t, t + \delta_t) = f_i(\vec{x}, t + \delta_t) \quad (2)$$

식 (1), 식 (2)에서 f_i 는 격자점에서 i 방향의 유체 밀도, \vec{x} 는 위치 벡터, \vec{e}_i 는 격자 속도 벡터, Ω_i 는 충돌 연산자, δ_t 는 시간 간격을 나타낸다. 본 연구에서는 D3Q19 격자 모델을 사용해 가스확산층 미세구조 인공데이터셋과 실제데이터셋의 대표체적요소 투과도를 계산하였다. 가스확산층의 투과도는 Darcy's Law를 통해 도출되었으며 가스확산층 미세구조의 인공데이터셋과 실제데이터셋에 대해 모두 도출되었다. Fig. 5는 인공데이터셋과 실제데이터셋에 대해 도출한 투과도의 분포를 나타낸다. 대표체적요소의 개수가 다르므로 확률분포를 통해 두 데이터셋의 투과도 분포를 비교하였으며 일치하는 경향성을 보였다.

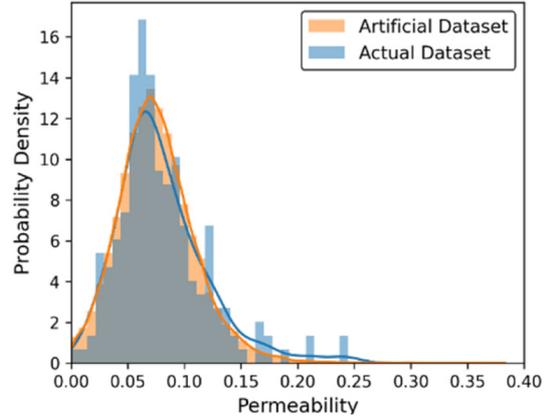


Fig. 5. Permeability of the GDL Artificial Dataset and the GDL Actual Dataset

3. 삼차원 합성곱 신경망을 이용한 가스확산층 투과도 예측

3.1 삼차원 합성곱 신경망 구조 설계

본 연구에서는 복셀 이미지에 대해 삼차원 합성곱 신경망 아키텍처를 활용해 투과도를 예측하고자 하였다. 삼차원 합성곱 신경망 아키텍처의 특징적인 부분으로 삼차원 Max-pooling 커널과 합성곱 커널을 번갈아 적용해 채널 수는 늘리면서 Feature Map의 전체크기는 줄이도록 설계하였다. 이때, 합성곱 커널은 작은 크기의 필터이며 입력 데이터에 적용되어 주변 픽셀과의 관계를 통해 특징을 탐지하는 역할을 한다. 반면 Max-pooling 커널은 Feature Map의 크기를 줄이는 역할을 수행하며 특정 영역 내에서 가장 큰 값을 선택해 좀 더 작은 Feature Map으로 대체하는 역할을 한다. Table 2는 본 연구에서 사용된 삼차원 합성곱 신경망의 구조와 학습가능한 파라미터 수를 나타낸다. 여기서 3D Convolutional Layer와 Fully-Connected Layer는 각각 Conv3D와 FC로 표기된다. Conv3D 내의 값은 채널 수와 필터 크기를 낸다. 예를 들어, Conv3D (64, (2,2,2))는 64개의 채널과 (2,2,2) 필터 크기를 가진 3D 합성곱 층을 의미한다. 마찬가지로, FC(64)는 64개의 뉴런을 가진 완전 연결 층을 의미한다. 또한 각 Conv3D 층 뒤에 3차원 Max-pooling 커널, 배치 정규화 커널과 드롭 아웃 커널을 사용하여 신경망을 훈련할 때 과적합을 줄인다.

Table 2. Description of the 3D CNN Architecture

3D CNN Architecture Description	Number of Parameters
Conv3D (32,(2,2,2))+ Conv3D (64,(2,2,2))+FC(128)+FC(64)	2,679,777

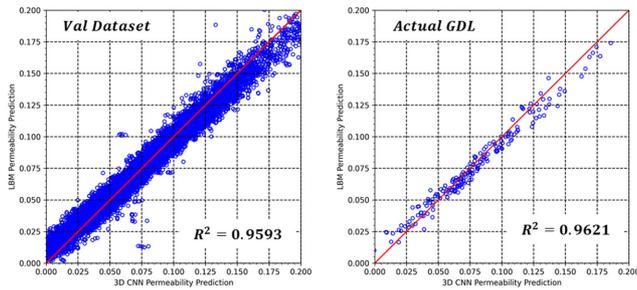


Fig. 6. Scatter plot of the predicted permeability using LBM and 3D CNN architecture

3.2 삼차원 합성곱 신경망 학습

삼차원 합성곱 신경망 학습은 Nvidia RTX 3090 Ti GPU(24GB 비디오 RAM), 64GB RAM 및 Intel Core i9-12900K 프로세서가 장착된 워크스테이션을 이용해 수행하였다. 삼차원 신경망 아키텍처는 지도 학습 회귀를 통해 학습되었으며 지도 학습 회귀 중에 딥 러닝 모델은 관측된 값과 예측된 값 사이의 손실 함수를 최소화하기 위해 내부 모델 매개변수를 변경하여 가스확산층 미세구조의 특징과 투과도 간의 관계를 학습한다. 랜덤 샘플링을 통해 전체 학습 데이터 중 20%는 검증 데이터, 80%는 학습용 데이터로 분할해 학습을 진행하였다.

3.3 삼차원 합성곱 신경망을 통한 가스확산층 대표체적요소 투과도 예측 결과

삼차원 합성곱 신경망의 정확도를 평가하기 위해 결정 계수 (Coefficient of determination)과 평균 제곱 오차가 사용되었다. Fig. 6은 검증데이터셋과 실제 가스확산층 데이터셋에 대해 격자 볼츠만 방법과 삼차원 합성곱 신경망을 통해 예측한 투과도의 산점도를 나타낸다. 여기서 x축이 삼차원 합성곱 신경망을 통해 예측한 투과도, 축이 격자 볼츠만 방법을 통해 도출한 투과도이며 높은 상관관계를 나타냈다.

4. 결 론

본 논문은 미세구조 재구성 알고리즘으로 생성된 가스 확산층의 인공 데이터셋을 삼차원 합성곱 신경망에 훈련시켜 실제 가스확산층의 투과도를 예측하는 방법론을 제안하였다. 가스확산층의 디지털 트윈 모델은 XRM을 통해 얻어지며 섬유 직경, 배향 등의 형태학적 특성이 조사되었다. 재구성 알고리즘은 공극률, 섬유 배향 및 섬유 직경의 통계 분포를 기반으로 통계적으로 동등한 미세구조를 재구성하는 데 활용되었다. 100800개의 가스확산층 대표체적요소를 가진 인공데이터셋은 미세구조 재구성을 통해 생성되었다. 삼차원 합성곱 신경망 모델은 인공 데이터셋을 사용하여 실제 데이터셋의 투과도를 예측하는 데에 훈련되었다. 3D CNN 아키텍처의 설계와 3D CNN 아키텍처를

사용한 투과도 예측 결과가 제시되었다. 본 연구에서 제시된 신경망을 통한 투과도 예측 모델을 이용해 가스확산층의 단층 이미지에서 투과도를 예측할 수 있다. 시간 효율 측면에서는 학습된 신경망 모델을 통한 투과도 예측은 1초 미만, 격자 볼츠만 방법을 통한 투과도 예측은 200초 이상 시간이 소요됨으로 학습된 모델을 이용해 투과도를 신속히 예측할 수 있을 것으로 기대된다.

후 기

The Institute of Engineering Research at Seoul National University provided research facilities for this work.

REFERENCES

1. D'Amato, G. and Akdis, C., "Global Warming, Climate Change, Air Pollution and Allergies," Authorea Preprints, 2020.
2. Ding, Y., et al., "Increasing Cryospheric Hazards in a Warming Climate", *Earth-Science Reviews*, Vol. 213, 2021, p. 103500.
3. Stocker, T., "Climate Change 2013: the Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change," Cambridge University Press, 2014.
4. Kim, W., et al., "Research Trends and Future Perspective in Nonconventional Machining of Fiber-reinforced Polymers: A Review," *Functional Composites and Structures*, Vol. 3, No. 2, 2021, p. 022001.
5. Nurazzi, N.M., et al., "Treatments of Natural Fiber as Reinforcement in Polymer Composites—A Short Review," *Functional Composites and Structures*, Vol. 3, No. 2, 2021, p. 024002.
6. Wachsmuth, J., Schaeffer, M., and Hare, B., "The EU Long-term Strategy to Reduce GHG Emissions in Light of the Paris Agreement and the IPCC Special Report on 1, 5°C," 2018, Working Paper Sustainability and Innovation.
7. Tollefson, J., "IPCC Says Limiting Global Warming to 1.5 C will Require Drastic Action," *Nature*, Vol. 562, No. 7726, 2018, pp. 172-173.
8. Sinha, R.K. and Chaturvedi, N.D., "A Review on Carbon Emission Reduction in Industries and Planning Emission Limits," *Renewable and Sustainable Energy Reviews*, Vol. 114, 2019, p. 109304.
9. Singla, M.K., Nijhawan, P., and Oberoi, A.S., "Hydrogen Fuel and Fuel Cell Technology for 61a Cleaner Future: 61a Review," *Environmental Science and Pollution Research*, 2021, p. 1-20.
10. Ajanovic, A. and Haas, R., "Prospects and Impediments for Hydrogen and Fuel Cell Vehicles in the Transport Sector," *International Journal of Hydrogen Energy*, Vol. 46, No. 16, 2021, pp. 10049-10058.
11. Okonkwo, P.C., et al., "Nafion Degradation Mechanisms in Proton Exchange Membrane Fuel Cell (PEMFC) System: A Review," *International Journal of Hydrogen Energy*, Vol. 46, No. 55, 2021, pp. 27956-27973.
12. Okonkwo, P.C. and Otor, C., "A Review of Gas Diffusion Layer

- Properties and Water Management in Proton Exchange Membrane Fuel Cell System,” *International Journal of Energy Research*, Vol. 45, No. 3, 2021, pp. 3780-3800.
13. Springer, T.E., Zawodzinski, T., and Gottesfeld, S., “Polymer Electrolyte Fuel Cell Model,” *Journal of the Electrochemical Society*, Vol. 138, No. 8, 1991, p. 2334.
 14. Kim, G.H., et al., “Impact of Cracked Gas Diffusion Layer on Performance of Polymer Electrolyte Membrane Fuel Cells,” *Journal of Industrial and Engineering Chemistry*, Vol. 91, 2020, pp. 311-316.
 15. Qiu, D., et al., “Electrical Resistance and Microstructure of Typical Gas Diffusion Layers for Proton Exchange Membrane Fuel Cell Under Compression,” *Applied Energy*, Vol. 231, 2018 pp. 127-137.
 16. Ozden, A., et al., “A Review of Gas Diffusion Layers for Proton Exchange Membrane Fuel Cells—With a Focus on Characteristics, Characterization Techniques, Materials and Designs,” *Progress in Energy and Combustion Science*, Vol. 74, 2019, pp. 50-102.
 17. Ge, J., Higier, A., and Liu, H., “Effect of Gas Diffusion Layer Compression on PEM Fuel Cell Performance,” *Journal of Power Sources*, Vol. 159, No. 2, 2006, pp. 922-927.
 18. Guo, L., et al., “Pore-scale Simulation of Two-phase Flow and Oxygen Reactive Transport in Gas Diffusion Layer of Proton Exchange Membrane Fuel Cells: Effects of Nonuniform Wettability and Porosity,” *Energy*, Vol. 253, 2022, pp. 124101.
 19. Yu, Y. and Chen, S., “Numerical Study and Prediction of Water Transfer in Gas Diffusion Layer of Proton Exchange Membrane Fuel Cells under Vibrating Conditions,” *International Journal of Energy Research*, Vol. 46, No. 13, 2022, pp. 18781-18795.
 20. Park, D.-C., et al., “Prediction of Permeability of Five-harness Satin Fabric by a Modified Kozeny Constant Determined from Experiments,” *Functional Composites and Structures*, Vol. 4, No. 1, 2022, p. 015001.
 21. Lee, W., et al., “Development of Homogenization Data-based Transfer Learning Framework to Predict Effective Mechanical Properties and Thermal Conductivity of Foam Structures,” *Composites Research*, Vol. 36, No. 3, 2023, pp. 205-210.
 22. Ahn, J.H., Bae, J.S., and Jung, S.N., “Optimal Structural Design Framework of Composite Rotor Blades Using PSGA,” *Composites Research*, Vol. 35, No. 1, 2022, pp. 31-37.
 23. Ji, S., Ham, S., and Cheon, S., “Stiffness Enhancement of Piecewise Integrated Composite Robot Arm using Machine Learning,” *Composites Research*, Vol. 35, No. 5, 2022, pp. 303-308.