

전기 정전용량을 기반으로 U-net 모델을 이용한 반도체 후단 공정의 잔류물 모니터링

Residual deposit monitoring of semiconductor back-end process using U-net model based on the electrical capacitance

전 민 호*, 아닐쿠마*, 김 경 연*

Minho JEON*, Anil Kumar Khambampati*, Kyung-Youn Kim**

Abstract

In this study, U-net model based on electrical capacitance is applied to monitor the condition inside the pipeline of semiconductor rear end process implemented in the numerical simulation. Capacitance values measured from electrodes attached to the pipeline is used as input data for the U-net network model and estimated permittivity distribution by the U-net model is used to reconstructed cross-sectional image at the pipeline. In the numerical simulation, images reconstructed by U-net model, Fully-connected neural network (FCNN) model and Newton-Raphson method are compared for evaluation. U-net model shows good results as compared to other models.

요 약

본 논문에서는, 시뮬레이션 상에서 반도체 후단 공정의 프로세스를 구현하고 파이프 내부 상황을 모니터링하기 위해 전기 정전용량을 기반으로 한 U-net 모델을 적용하였다. 배관에 부착된 전극에서 측정된 정전용량 값은 U-net 네트워크 모델의 입력 데이터로 사용되며, 모델을 통해 추정된 유전율 분포를 가지고 파이프 단면을 이미지화하였다. 성능 평가를 위해 수치 시뮬레이션 안에서 U-net 모델, FCNN(Fully-connected neural network) 모델, Newton-Raphson 방법으로 재구성한 이미지를 비교한 결과, U-net이 다른 이미지 복원 방식보다 좋은 복원 성능을 보였다.

Key words : Electrical capacitance, Two-phase flow, U-net, Image reconstruction, Inverse problem

* Dept. of Electronics Engineering, Jeju National University

★ Corresponding author

E-mail : kyungyk@jejunu.ac.kr, Tel : +82-64-754-3664

※ Acknowledgment

This research was supported by the 2023 scientific promotion program funded by Jeju National University Manuscript received May.13, 2024; revised Jun. 10, 2024; accepted Jun. 19, 2024.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

반도체 제조 공정에는 WO_3 , TiO_2 및 Al_2O_3 와 같은 물질들이 포함되어 있으며[1]-[3] 각 물질이 가진 강한 독성으로 인해, 환경에 부정적인 영향을 끼치고 있다 [4]. 또한, 위에 언급한 독성이 있는 물질들이 공정을 거 치면서 일부가 먼지 형태의 잔류물로 변하게 되고 이것 이 계속되는 고열로 인해 파이프 내벽에 달라붙게 되어 파이프가 막히는 위험한 상황을 초래하게 된다[2], [3].

이런 위험한 상황을 피하고자, 사람이 직접 스크러버 장비나 입구 파이프를 해제하고 내벽의 잔류물을 제거하 는 PM(preliminary maintenance)이 주기적으로 진행

할 필요가 있다[5]. 그러나, 사람이 직접 제거하는 경우 독성이 있는 물질에 직접적으로 노출되어 건강에 해로운 상황이 발생할 수도 있고 잔류물을 제거하기 위해 파이프를 해제하게 되면 모든 공정을 일시적으로 멈춰야 하므로 제조 효율에 직접적인 영향을 미칠 수가 있다. 그래서, 파이프 내부에 잔류물이 쌓이는 정도를 지속해서 체크하고 PM을 실행하기 위한 적절한 시기를 정할 수 있는 모니터링 기술이 필요하다.

파이프 내부에 흐르는 이상 유동장을 관찰하기 위하여 X-ray나 Gamma-ray를 이용하는 모니터링 기술이 나[6]-[8], 광학이나 전기적 접촉을 이용한 탐지 기법[9], 폐쇄 밸브를 사용하여 불륨을 측정하는 방법들이 있지만, 파이프 내부에 프로브를 삽입하는 기술들은 파이프 내부의 흐름을 방해하며, 방사선을 기반으로 하는 방법들은 비용이 많이 들고 사람이 직접 다루기에는 건강에 안 좋은 영향을 미치는 경우가 많다. 이러한 것들과는 다르게, 전기적 임피던스를 기반으로 하는 기술들은 비용적인 측면에서 저렴하며 파이프 내부 흐름에 영향을 최소화할 수 있는 비 파괴적인 모니터링 기술이다 [11], [12].

ECT(Electrical capacitance tomography)는 다양한 산업 분야에서 물질 내부 전기적 유전율 분포를 추정하여 실시간으로 내부를 관측하는 모니터링 기술로써 사용됐다[13]. 석유와 가스가 흐르는 파이프라인을 관찰하거나[14], 제약 및 식품 공정에서 최적화를 위하여 물질의 비율을 관측하기 위해 적용됐다[15]. ECT는 파이프 내부에 물질들이 가지는 각각의 고유한 전기적 유전율 값과 각 물질의 비율로 인해 두 전극 사이의 정전용량 값의 변화를 측정하고 이를 내부 상황을 추정한다[10-11]. 측정된 정전용량 값의 변화를 이용하여 내부 상황을 추정할 때는 다양한 수치해석 기법들이 사용된다. 정전 용량값과 내부 유전율 분포의 관계를 민감도 행렬 (sensitivity matrix)을 통해 계산하거나[16], Landweber 기법을 이용한 유전율을 추정하거나[17], Tikonov 방법 또는 뉴턴 랩슨 방법을 적용한 사례도 있다. 최근에는 이상 유동을 모니터링하기 위해 딥러닝을 적용하는 사례도 있는데, 고속 사진법(high-speed photography)을 이용하여 촬영한 이미지에 U-net 모델을 적용, 기체와 액체의 영역을 구분하기 위한 전역 임계값 매개변수를 찾거나[18], 컨볼루션과 디컨볼루션 모델에 이상 유동을 촬영한 이미지를 입력으로 사용하여 void fraction 및 이상 유동의 flow pattern을 추정하는 연구 결과가 있다 [19]. 또한 기존의 ECT를 이용하여 우선 영상을 복원하

고 복원한 이미지에 CNN(convolution neural network)을 적용한 방법도 있다[20]. 그러나, 이 방법은 정전용량 값을 가지고 ECT의 역문제를 수치해석 기법을 이용하여 영상을 복원한 후 복원한 영상을 딥러닝을 통해 재조정하는 이미지 프로세싱 기법에 가깝다.

그리고 본 논문에서는 정전용량 값을 가지고 ECT의 기존의 수치 해석적 기법을 사용하지 않고 바로 이미지 복원을 하기 위해 U-net 모델과 FCNN(Fully-connected neural network)을 결합한 방법을 사용하였다. 제안한 모델을 훈련하기 위해, 매트랩에서 ECT의 정문제 해법을 계산하여 유전율 분포에 따른 정전용량 값들을 계산하였고, 이를 훈련용 데이터와 검증용 데이터로 분리하여 사용하였다. 제안한 모델의 성능을 평가하기 위하여 기존에 많이 사용되는 NR(Newton-Raphson method) 방법을 적용하여 복원한 이미지와 단순히 FCNN 모델만 사용하여 복원한 이미지를 비교하였다.

II. 관련 연구

1. U-net 모델

U-net 모델은 CNN(convolution neural network)에서 슬라이딩 윈도우 방식에 의해서 나타나는 계산 비용의 증가나 클래스 불균형과 같은 문제점을 극복하기 위한 FCN(Fully Convolution network)의 한가지 변형 형태이다[21]. U-net 모델은 입력 이미지와 같은 해상도의 출력을 생성하고 입력 이미지의 컨텍스트 정보를 보존하면서 높은 해상도의 출력을 얻을 수 있도록 그림 1과 같이, 인코더-디코더(encoder-decoder)의 대칭 형태를 이루고 있으며, 인코딩 단계에서는 입력된 이미지의 특징을 추출할 수 있도록 채널을 늘리며 차원을 축소

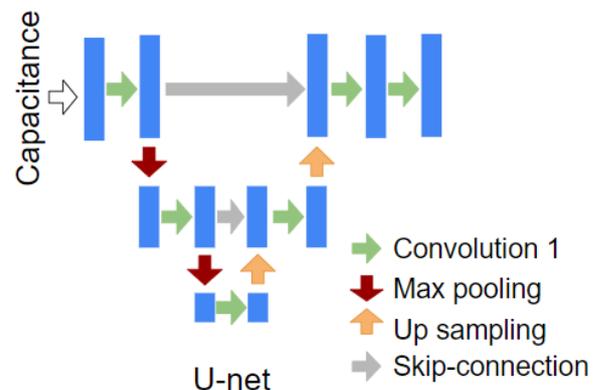


Fig. 1. U-net model architecture.
그림 1. U-net 모델 구조

해나가고 디코딩 단계에서는 축소된 차원에 남은 정보만 이용하여 채널의 수와 차원을 줄이며 원래 차원의 이미지를 복원한다[23].

그러나, 인코딩 단계를 거칠수록 기존의 위치 정보를 잃게 되고 디코딩 단계에서는 저차원의 정보만 이용하기 때문에 위치 정보의 손실을 복원하지 못하므로 각 인코딩 단계에서 얻은 위치 정보들을 디코딩 단계에 합치는 skip-connection 방법을 사용한다[24].

2. 전기 정전용량 단층촬영의 정문제 해법

ECT(Electrical capacitance tomography)는 유전율 분포를 두고 전극에서의 정전 정전용량을 계산하는 정문제와 전극에서 측정된 정전용량으로 내부 유전율 분포를 계산하는 역문제로 이루어져 있다[25]. 정문제 해법은 내부 유전율 분포와 전극 주변의 경계치 조건을 고려한 지배방정식을 가지고 정전용량을 계산하며, 맥스웰 방정식으로부터 유도된 식은 다음과 같다[26].

$$\nabla \cdot [\epsilon(x,y)\nabla\psi(x,y)] = 0 \quad (1)$$

위 식에서 $\epsilon(x,y)$ 는 내부 유전율 분포, $\psi(x,y)$ 는 내부 전위 분포를 의미한다. 식 (1)에서 불균일한 유전율 분포를 고려하기 위해, 유한요소법(Finite element method, FEM)을 이용하여 다음과 같은 관계식으로 유도할 수 있다[27].

$$C = \frac{1}{\Delta V} \oint_{\Gamma} \epsilon(x,y)\nabla\psi(x,y)d\Gamma \quad (2)$$

위 식에서 C 는 두 전극 사이에 정전용량이며, ΔV 두 전극 사이의 전압차, Γ 는 전극의 표면을 의미하고 식 (2)를 기반으로 내부 유전율 분포를 이용하여 정전용량을 계산하지만, 대부분은 유전율 분포와 정전용량이 비선형 관계를 가지고 있으므로 선형화 과정을 거쳐 다음과 같은 식을 유도한다[25], [26].

$$C = f(\epsilon)\delta C = \frac{df}{d\epsilon}(\delta\epsilon) + O(\delta\epsilon)^2 \quad (3)$$

$$\delta C = J\delta\epsilon \quad (4)$$

$$\lambda = Sx \quad (5)$$

위 식에서 J 는 자코비안 매트릭스이며, S 는 민감도 행렬, λ 는 정규화된 정전 용량값, x 는 정규화된 유전율 분포이다.

III. 이미지 복원 방법 및 훈련

1. 이미지 복원을 위한 네트워크 모델

본 논문에서는 정전용량을 가지고 내부 유전율 분포를 추정하기 위하여 그림과 같이 U-net 모델과 FCNN(fully-connected neural network) 모델을 조합하여 그림 2와 같이 사용하였다. FCNN 모델은 각 레이어에 있는 모든 뉴런이 다음 레이어에 있는 모든 뉴런과 서로 연결되는 기본적인 인공신경망 모델로서, 컨볼루션 네트워크나, LSTM(long-short term memory), DFCNN(Dual fully connected neural network) 등 다양한 네트워크 모델들과의 조합을 위해 사용되기도 한다[28], [29].

전극에서 측정된 정전 용량값은 U-net 모델의 인코더 구조를 거치며 저차원 특성 맵으로 다운샘플링 되고 디코더 구조에서는 저차원 특성 맵을 업샘플링 하여 최종 세그멘테이션 맵을 생성한다. 이 과정을 통해 측정된 정전 용량값으로부터 내부 유전율 분포와 관련 있는 컨텍스트 정보를 추출하게 되고 이후 FCNN과 연결하여, 유한요소법으로 나누어진 각 요소의 유전율 값이 추정된다. FCNN 모델에서는 뉴런이 존재하는 레이어 사이에 오버피팅을 방지하기 위해서 드랍 아웃 레이어(dropout layer)를 배치하였다[30].

2. 훈련을 위한 데이터 생성

제한한 모델의 훈련을 위해, 매트랩에서 ECT의 정문제 해법을 가지고 유전율 분포에 따른 정전 용량값을 계산하였다. 모델 훈련 시, 이상 유동장에서 생길 수 있는 다양한 상황을 가정하고 각 상황에 맞는 정전용량 값이 필요하므로, 다음과 같은 순서로 각 상황에 따른 유전율 분포와 정전용량 값을 생성하였다.

- 1) 유전율 값 선정 : 가스의 유전율은 1 pF/m, 침전물의 유전율은 21 pF/m으로 설정
- 2) 유한요소법 적용 : 파이프 단면을 3,538개의 삼각형 요소로 분리하고 전극의 위치를 설정.
- 3) 유전율 분포 선정 : 가스의 모양이 원형인 것을 고려하여 파이프 내부에서 가스의 중심과 반지름을 무작위로 설정한 후 가스와 침전물의 구역을 설정
- 4) 정전용량 계산 : 2)에서 설정한 구역에 각 물질의 유전율 값을 선정하고 ECT의 정문제 해법을 사용하여 정전용량 값 계산
- 5) 입력 데이터 정리 : 계산한 정전용량 값을 모델에 입력 데이터로 사용하기 위해 그림 3과 같은 형태

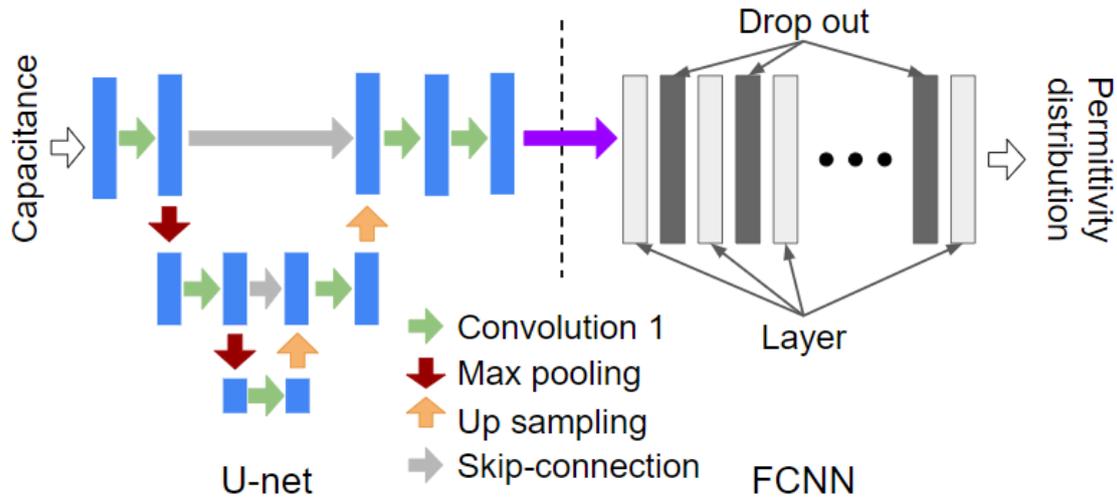


Fig. 2. Model architecture for image reconstruction with capacitance value.

그림 2. 정전용량을 가지고 영상 복원을 위한 모델의 구조

의 행렬로 변환

6) 3)~5) 과정을 반복.

그림 3에서 $C_{l,m}^t$ 는 t 번째 선정된 유전율 분포를 이용하여 ECT의 정문제 해법으로 l 번째 전극과 m 번째 전극 사이에서 정전용량을 계산한 값이며, C^t 는 t 번째 입력 데이터다.

이러한 과정을 모두 거친 후 생성된 데이터 세트는 총 2,514개이며, 이중 무작위로 추출한 1,935개 데이터는 모델 훈련용으로, 나머지 579개의 데이터는 훈련한 모델을 평가하기 위한 목적으로 분류하였다.

$$C^t = \begin{bmatrix} 0 & C_{1,2}^t & C_{1,3}^t & C_{1,4}^t \\ C_{3,4}^t & 0 & C_{2,3}^t & C_{2,4}^t \\ C_{2,4}^t & C_{2,3}^t & 0 & C_{3,4}^t \\ C_{1,4}^t & C_{1,3}^t & C_{1,2}^t & 0 \end{bmatrix}$$

Fig. 3. the Architecture of input data with capacitance data.

그림 3. 정전용량 값으로 구성된 입력 데이터의 구조

3. 하이퍼 파라미터 선정 및 훈련

제안한 모델을 위한 최적화기법과 활성화함수를 그리드 검색 방법(grid search technique)을 사용하였다[31]. 모델 훈련을 위한 최적화기법으로는 SGD, Momentum, Adam, 선정하였고[32], U-net 모델을 위한 활성화함수

로는 Sigmoid, Relu, LeakyReLu를 선정하였으며[33], Leaky Relu 함수의 식은 다음과 같다[34].

$$\max(kx, x) = \begin{cases} x & \text{if } x > 0 \\ kx & \text{if } x \leq 0 \end{cases} \quad (6)$$

이번 훈련에서 k 는 0.1로 설정하였다.

FCNN에서 뉴런 수는 유한요소법의 요소 수와 같이 3,538개로 모든 레이어에서 같은 값을 사용하였고 총 레이어 수는 20개, 드랍 아웃의 비율은 0.1로 설정하였다. 손실 함수로는 mean-squared error를 사용하였고 식은 다음과 같다[35].

Table 1. loss value by grid search technique for 200 epoch.

표 1. 그리드 검색 방법을 사용하여 200 epoch 동안 훈련을 시킨 결과

Optimizer	Activation function	Loss value
SGD	Sigmoid	14.496
Momentum	Sigmoid	12.561
Adam	Sigmoid	11.389
SGD	Relu	11.987
Momentum	Relu	12.211
Adam	Relu	12.233
SGD	LeakyReLu	13.579
Momentum	LeakyReLu	12.258
Adam	LeakyReLu	11.140

$$MSE = \frac{1}{n} \sum_{i=1}^n (\epsilon_i^t - \epsilon_i^{pre})^2 \quad (7)$$

형성된 그리드 안에서 조합마다 모델을 구성하여 200 epoch만큼 훈련했고 Adam 방법과 LeakyRelu의 조합이 가장 낮은 손실 값을 가지고 있는 것을 표 1에서와 같이 확인할 수 있다.

최종적으로 선정된 하이퍼 파라미터로 훈련용 데이터를 가지고 모델을 1000 epoch만큼 훈련했고 훈련 하는 동안 손실 함수인 mean-squared error의 변화를 훈련용 데이터와 검증용 데이터로 각각 계산하여 그림 4에 표시했다.

그림 4의 그래프를 확인해보면, 훈련용 데이터의 손실 값은 epoch가 커질수록 점차 낮은 값으로 수렴하는 것을 확인할 수 있었고 검증용 데이터의 손실 값은 훈련용 데이터의 손실 값과 비슷하게 감소하다가, 300 epoch부터 불안정한 모습을 보이는 것을 확인할 수 있다.

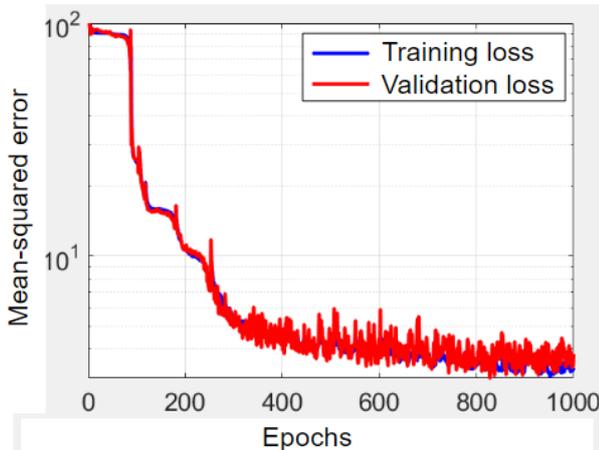


Fig. 4. Mean-squared error for the training process.
그림 4. 훈련 프로세스 중 평균 제곱 오차의 변화

IV. 이미지 복원 결과 및 평가

1. 모델의 성능 비교 방법

제안한 모델의 이미지 복원 성능을 확인하기 위해서, ECT의 역문제 풀이에 자주 사용되던 NR(Newton-Raphson) 방법을 사용하여 복원 이미지와 U-net 모델 없이 FCNN만 사용하여 복원한 이미지를 비교했다. NR 방법을 역문제 풀이에 사용하기 위해서 다음과 같은 수식을 적용했다[27].

$$\epsilon^{pre} = \epsilon + (S^T S + \alpha R^T R)^{-1} (S(C_i - C_h) - \alpha R^T R \epsilon) \quad (8)$$

위 수식에서 ϵ 는 가스의 유전율을 의미하며, ϵ^{pre} 은 NR 방법으로 추정된 유전율 분포이다. C_i 는 i 번째 정전용량 벡터이고 C_h 는 파이프 내부에 가스만 존재할 때 정전용량 벡터이다. s 는 민감도(sensitivity) 행렬이고 α 와 R 은 각각 조정 파라미터와 조정행렬이다.

FCNN을 모델 구성을 위한 하이퍼 파라미터들은 제안한 모델과 같은 값들을 사용하였으며, 훈련용 데이터도 같은 데이터 세트를 사용하였다.

2. 이미지 복원 결과

총 578개의 검증용 데이터 세트를 가지고 제안한 모델, FCNN, NR 방법을 이용하여 파이프 내부의 유전율 분포를 추정하였고 추정된 유전율 분포 중 16번째, 185번째, 235번째, 343번째, 423번째의 복원 결과를 실제 영상과 비교하기 위해 그림 5에 표시하였다.

그림 5에서 첫 번째 행은 시뮬레이션에서 구현한 실제 유전율 분포이고 두 번째 행은 NR 방법으로 복원한 이미지, 세 번째 행은 FCNN으로 복원한 이미지, 마지막 행은 제안한 모델로 복원한 이미지이다. 그림 5를 보면, NR 방법으로 추정된 유전율 분포로 복원된 이미지와 실제 유전율 분포로 만들어진 이미지를 비교해보면, 링 모양의 경계선을 발견할 수 있지만, 실제 영상에서 가스와 침전물의 경계선과는 다르다는 것을 확인할 수 있다. 그리고 가스로 추정되는 부분의 경계선과 그 안쪽 영역의 유전율이 서로 달라 실제 이미지와 다르다는 것을 확인할 수 있었다. 그리고 423번째 데이터에서는 가스가 너무 작은 나머지 복원한 이미지에서 가스의 위치나 크기를 정확하게 파악하기 어렵다. FCNN과 U-net 모델로 추정된 이미지를 확인해보면, 가스의 크기나 위치가 실제 이미지에서 보이는 것과 비슷하다는 것을 확인할 수 있다. 그러나, 추정된 요소별 유전율 값을 확인해보면, 실제 이미지에서 가스 부분의 색은 짙은 파란색이지만, FCNN으로 추정된 유전율로 만든 이미지에서는 가스 부분의 색이 좀 더 옅은 것을 확인할 수 있으며, 이것은 추정된 요소별 유전율 값이 실제 유전율 값과 다르다는 것을 의미한다. U-net 모델로 만든 이미지에서는 가스의 경계선으로 추정되는 부분에서 색이 약간 연해지기는 경향이 있으나, 가스로 추정되는 곳이 실제 영상과 비교하여 비슷한 색을 가지고 있으므로, 추정된 유전율 값이 비슷하다는 것을 알 수 있다. 그러나, 침전물이 쌓여있는 영역을 확인해보면, U-net으로 복원한 영상에서는 실제 영상에서 볼 수 있는 노란색보다 좀 더 짙은 색으로 표현되는 것으로 추정된 유전율 값이 실제 값과는 차이가

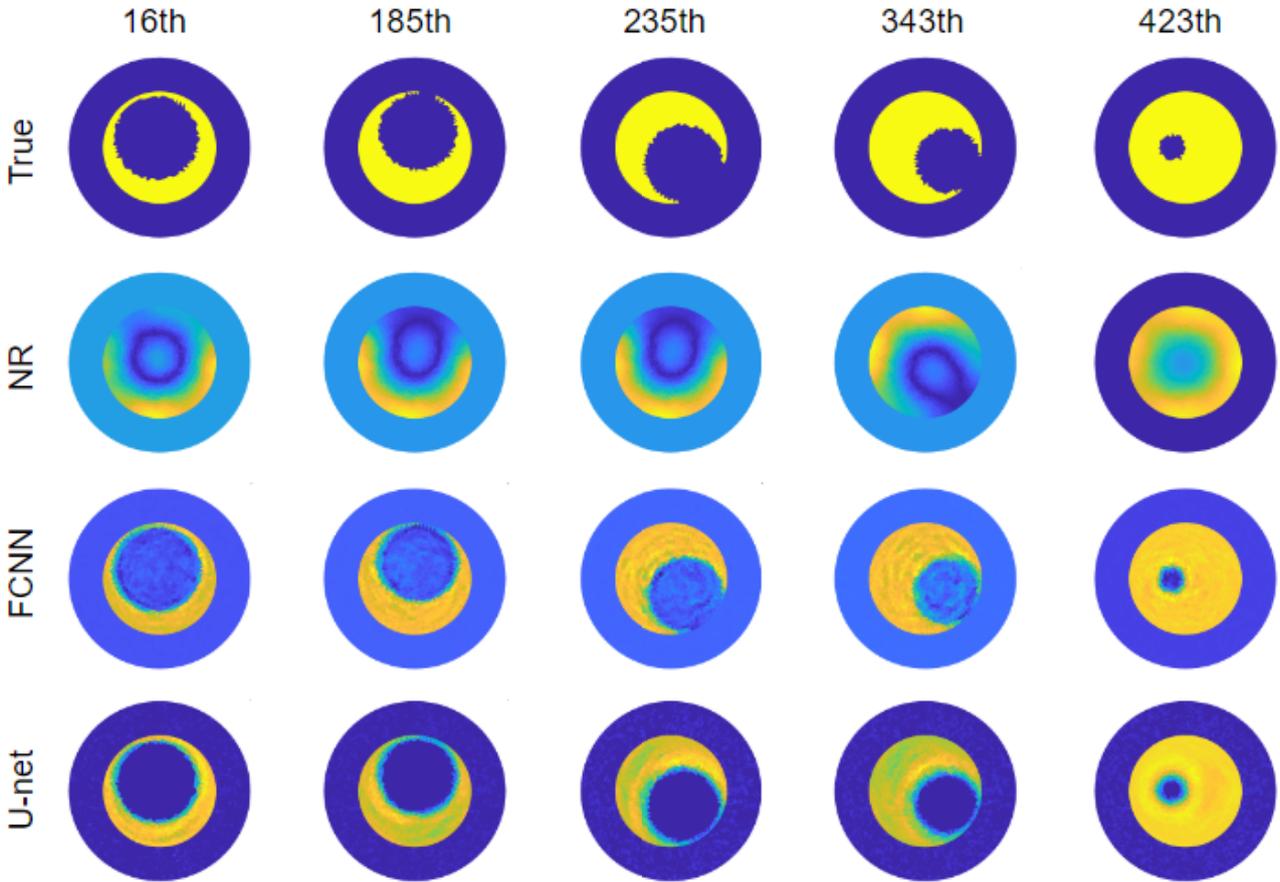


Fig. 5. Reconstruction image results by NR, FCNN and U-net model with 16th, 185th, 235th, 343th and 423th validation data set in the numerical simulation.

그림 5. 시뮬레이션에서 NR, FCNN, U-net 모델로 검증용 데이터를 가지고 영상을 복원한 결과

있다는 것을 확인할 수 있다.

실제 유전율 값과 추정된 유전율 값의 크기 및 변화를 직접적으로 비교하기 위해, 요소별 유전율 값의 분포를 각각 나열하고 비교해보았다. 그림 6에 있는 그래프에서 y축은 요소별 유전율 값이고 x축은 영상을 구성하고 있는 각 요소의 번호이다. 각 그래프는 검증용 데이터로 추정한 유전율 값과 실제 유전율 값의 분포를 하나의 그래프에 동시에 표시하여 비교하고 가스와 침전물의 경계선을 화살표로 표시하였다. 16번째 검증용 데이터부터 423번째 검증용 데이터로 갈수록 침전물의 영역이 점차 넓어지고 있기에 그래프에서도 경계선을 기준으로 가스 영역인 왼쪽 부분은 점차 줄어들고 있고 침전물 영역은 점차 넓어지는 것을 확인할 수 있다.

NR 방법으로 추정된 유전율 값의 변화를 살펴보면, 경계선을 기점으로 유전율 값이 소폭 상승하는 것을 볼 수 있지만, 실제 유전율 값을 따라가지 못하는 것을 확인할 수 있다. FCNN과 U-net으로 추정된 유전율 값의 변화

를 살펴보면, 침전물 영역이 좁은 16번째, 185번째에서는 가스와 침전물의 경계선에서 유전율의 값이 급격하게 변할 때, U-net이 FCNN보다 좀 더 나은 추정 결과를 가지고 있는 것을 확인할 수 있다. 그리고 침전물의 영역이 절반은 넘어가는 343번째, 423번째 데이터서는 두 모델이 모두 비슷한 유전율 추정 결과를 확인할 수 있다.

각 방법의 정량적 평가를 위해서 모든 검증용 데이터에서 추정된 유전율 분포를 가지고 상관 계수(Correlation coefficient, CC)와 Mean squared error(MSE)를 계산하였고 계산식은 다음과 같다.

$$CC = \frac{cov(\epsilon^t, \epsilon^{pre})}{\sigma(\epsilon^t)\sigma(\epsilon^{pre})} \quad (9)$$

위 식에서 cov 는 공분산을 계산하는 함수이고 ϵ^t , ϵ^{pre} 는 실제 유전율 분포와 추정된 유전율 분포이고 ϵ_i 는 유한요소법을 나누어진 i 번째 요소에 유전율 값을 의미한다.

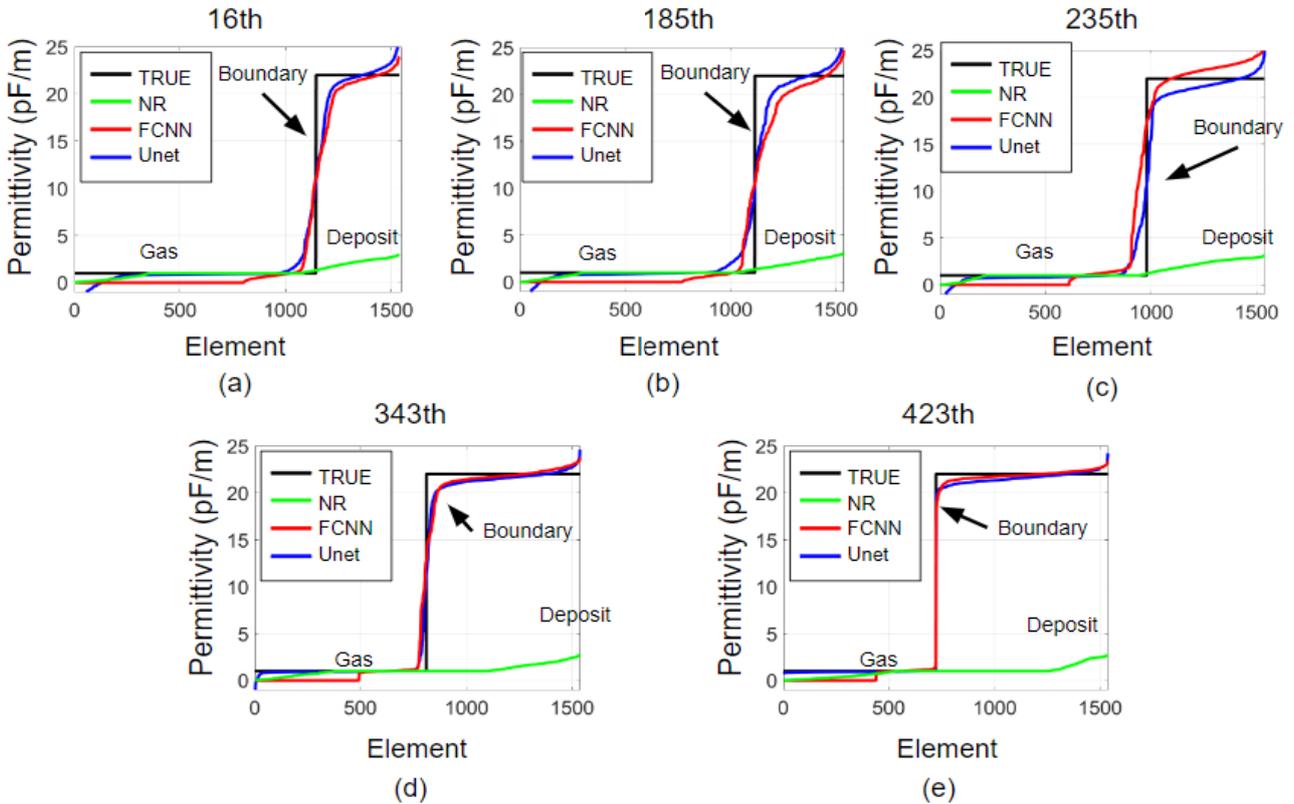


Fig. 6. permittivity distribution comparison in the reconstructed image by NR, FCNN and U-net.

그림 6. 복원한 이미지에서 요소별 유전율 값의 변화 비교

Table 2. CC and MSE comparison results by NR, FCNN and U-net method.

표 2. NR 방법, FCNN 방법, U-net 방법의 CC와 MSE 비교 결과

Data No.	Value					
	NR		FCNN		U-net	
	CC	MSE	CC	MSE	CC	MSE
16th	0.17	15.21	0.96	4.26	0.97	3.98
185th	0.20	16.23	0.97	4.06	0.97	3.74
235th	0.17	14.12	0.96	5.29	0.97	4.74
343th	0.34	15.01	0.97	4.28	0.97	4.11
423th	0.26	14.41	0.96	3.75	0.99	3.60
Total data	0.23	15.32	0.97	4.37	0.98	3.23

표 2를 확인해보면, NR 방법에 비해 FCNN과 U-net 모델의 CC 값이 크며 모든 CC 값이 0.96 이상을 가지고 있는 것을 확인할 수 있다. 그리고 U-net 모델의 CC 값이 FCNN과 거의 유사한 것은 각 방법으로 복원한 이미지와 실제 이미지가 유사성이 높다는 것을 알 수 있다.

MSE에서는, FCNN과 U-net 모델이 NR 방법에 비해 낮은 값을 가지고 있는 것을 알 수 있다. 그리고 침전물

의 영역이 작은 16번째와 185번째 검증용 데이터에서는 U-net 모델로 추정된 유전율 값이 실제 값과 더 비슷하기에 U-net 모델이 FCNN보다 더 낮은 MSE 값을 가지고 있는 것을 볼 수 있다. 그리고 침전물의 영역이 넓은 343번째와 423번째 데이터에서는 경계선 근처에서 추정한 유전율 값이 비슷하기에 MSE값이 비슷한 것을 알 수 있다. 그리고 위에서 언급한 5개의 검증용 데이터 이외에도 모든 검증용 데이터에 관한 평가지수를 한눈에 파악하기 위해, 각각의 검증용 데이터로 복원한 이미지마다 평가 지수를 계산하고 평균값을 계산하여 표 2 맨 마지막 행에 추가하였다. 평가 지수의 평균값을 살펴보면, CC 값은 FCNN과 U-net이 0.97과 0.98, MSE에서는 4.37과 3.23으로 차이가 나는 것을 확인할 수 있다. 이것은 데이터 생성시 가스의 영역이 침전물의 영역보다 작은 상황을 고려한 데이터가 많기에 이러한 차이가 생기는 것을 확인되었다.

V. 결론

본 논문에서는 이상 유동장에서 내부 상태를 유전값의 분포를 기준으로 이미지화하기 위해 U-net 모델을 적용

하였다. U-net 모델을 훈련하기 위해, 수치해석 시물레이션에서 전기 정전용량 단층촬영법의 정문제 해법을 이용하여 유전을 분포에 따른 정전용량 값들을 계산하였다. 계산한 정전용량 값과 유전율의 분포를 이용하여 U-net 모델을 훈련한 후 파이프 단면의 이미지를 추정하였다. U-net 모델의 성능을 평가하기 위해, 전기 정전용량 단층촬영에서 많이 사용되는 NR(Newton-Raphson) 방법과 FCNN(full-connected neural network)의 결과를 비교하였다. 이미지와 유전율 값의 분포, 정량적 평가를 위한 CC, MSE 값을 확인한 결과, NR 방법은 모든 검증용 데이터에서 낮은 성능을 보여주었다. FCNN과 U-net 모델로 복원한 이미지에서는 침전물의 영역이 넓고 가스의 영역이 낮은 데이터에서는 U-net 모델이 두 영역의 경계선에서 더 나은 복원 성능을 보여주었으며, 침전물의 영역이 절반 이상을 넘어가는 데이터에서는 두 방법이 비슷한 결과를 가지고 있음을 확인하였다.

References

- [1] G. S. May and C. J. Spanos, *Fundamentals of semiconductor manufacturing and process control*, John Wiley & Sons, 2006.
- [2] M. F. Yoo, J. Wang and J. C. Sheu, "Method for preventing clogging of reaction chamber exhaust lines" *U.S. Patent Application* No.11/466,922, 2008.
- [3] K. M. Choi, H. C. An and K. S. Kim, "Identifying the hazard characteristics of powder byproducts generated from semiconductor fabrication processes," *Journal of Occupational and Environmental Hygiene*, vol.12, no.2, pp.114-122, 2014. DOI: 10.1080/15459624.2014.955178
- [4] D. M. McElvenny, A. J. Darnton, J. T. Hodgson, S. D. Clarke, R. C. Elliott and J. Osman, "Investigation of cancer incidence and mortality at a Scottish semiconductor manufacturing facility," *Occupational Medicine*, vol.53, no.7, pp.419-430, 2003. DOI: 10.1093/occmed/kqg111
- [5] C. Beall, T. J. Bender, H. Cheng, R. Herrick, A. Kahn, R. Matthews and E. Delzell, "Mortality among semiconductor and storage device manufacturing workers," *Journal of Occupational and Environmental Medicine*, vol.10, pp.996-1014, 2005. DOI: 10.1097/01.jom.0000183094.42763.f0
- [6] A. A. Kendoush, and Z. A. Sarkis, "Void fraction measurement by X-ray absorption," *Exp. Therm. Fluid Sci*, vol.25, no.8, pp.615-621, 2002. DOI: 10.1016/S0894-1777(01)00117-0
- [7] E. Nazemi, S. A. Feghhi, G. H. Roshani, R. G. Peyvandi and S. Setayeshi, "Precise void fraction measurement in two-phase flows independent of the flow regime using gamma-ray attenuation," *Nuclear Engineering and Technology*, vol.48, no.1, pp.64-71, 2016. DOI: 10.1016/j.net.2015.09.005
- [8] M. Alamoudi, M. A. Sattari, M. Balubaid, E. Eftekhari-Zadeh, E. Nazemi, O. Taylan and E. M. Kalmoun, "Application of gamma attenuation technique and artificial intelligence to detect scale thickness in pipelines in which two-phase flows with different flow regimes and void fractions exist," *Symmetry*, vol.13, no.7, pp.1198-2003, 2021. DOI: 10.3390/sym13071198
- [9] C. R. Zamarreno, C. Martelli, V. H. Baroncini, E. N. Santos, M. J. Silva, R. E. Morales and I. R. Matias, "Single and multiphase flow characterization by means of an optical fiber Bragg grating grid," *Journal of Lightwave Technology*, vol.33, no.9, pp.1857-1862, 2015. DOI: 10.1109/JLT.2015.2394788
- [10] H. C. Yang, D. K. Kim and M. H. Kim, "Void fraction measurement using impedance method," *Flow Meas. Inst*, vol.14, no.4-5, pp.151-160, 2003. DOI: 10.1016/S0955-5986(03)00020-7
- [11] Z. Huang, B. Wang and H. Li, "Application of electrical capacitance tomography to the void fraction measurement of two-phase flow," *IEEE Trans Inst. Meas*, vol.52, no.1, pp.7-12, 2003. DOI: 10.1109/TIM.2003.809087
- [12] W. Q. Yang, M. S. Beck and M. Byars, "Electrical capacitance tomography-from design to applications." *Measurement and Control*, vol. 28, no.9, pp.61-266, 1995. DOI: 10.1177/002029409502800901
- [13] T. York, "Status of electrical tomography in industrial applications," *Journal of Electronic*

- imaging*, vol.10, no.3, pp.608-619, 2001.
DOI: 10.1117/1.1377308
- [14] U. Khan, W. Pao, N. Sallih and F. Hassan, "Flow Regime Identification in Gas-Liquid Two-Phase Flow in Horizontal Pipe by Deep Learning," *Journal of Advanced Research in Applied Sciences and Engineering Technology*, vol.27, no.1, pp.86-91, 2022. DOI: 10.37934/araset.27.1.8691
- [15] A. Voss, P. Hosseini, M. Pour-Ghaz, M. Vauhkonen and A. Seppänen, "Three-dimensional electrical capacitance tomography - A tool for characterizing moisture transport properties of cement-based materials," *Materials and Design*, vol.181, no.5, pp.107967, 2019.
DOI: 10.1016/j.matdes.2019.107967
- [16] H. Wang and W. Yang, 2021. "Application of electrical capacitance tomography in pharmaceutical fluidized beds-A review," *Chemical Eng. Sci.*, vol. 231, p.116236. 2021.
DOI: 10.1016/j.ces.2020.116236
- [17] G. Lu, L. Peng, B. Zhang, and Y. Liao, "Preconditioned Landweber iteration algorithm for electrical capacitance tomography," *Flow measurement and Instrument*, vol.16, no.2 pp.163-167, 2005.
DOI: 10.1016/j.flowmeasinst.2005.02.006
- [18] B. Chen, M. C. Ekwonu and S. Zhang, "Deep learning-assisted segmentation of bubble image shadowgraph," *Journal of Visualization*, vol.25, pp.1125-1136, 2022.
DOI: 10.1007/s12650-022-00849-4
- [19] W. Chu, Y. Liu, L. Pan, H. Zhu and X. Yang, "Study on Measure Approach of Void Fraction in Narrow Channel Based on Fully Convolutional Neural Network," DOI: 10.3389/fenrg.2021.636813
- [20] W. Li, W. Song, G. Yin, M. C. Ong and F. Han, "Flow regime identification in the subsea jumper based on electrical capacitance tomography and convolution neural network," *Ocean Eng.*, vol.266, Part. 5, 2022.
DOI: 10.1016/j.oceaneng.2022.113152
- [21] J. Long, E. Shelhamer and T. Darrell, "Fully Convolutional Networks for Semantic Segmentation," *IEEE conference on computer vision and pattern recognition*, pp.3431-3440, 2015.
DOI: 10.48550/arXiv.1411.4038
- [22] O. Ronneberger, P. Fischer and T. Brox, "U-Net : Convolutional Networks for Biomedical Image Segmentation," *Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*, 2015, pp.234-241.
DOI: 10.48550/arXiv.1505.04597
- [23] Y. Ji, H. Zhang, Z. Zhang and M. Liu, "CNN-based encoder-decoder networks for salient object detection: A comprehensive review and recent advances," *Information Science.*, vol.546, pp.835-857, 2021. DOI: 10.1016/j.ins.2020.09.003
- [24] C. Yu and F. Wenru, "R-UNet Deep Learning-Based Damage Detection of CFRP with Electrical Impedance Tomography," *IEEE. Tran. Inst. Meas.*, vol.27, 2022. DOI: 10.1109/TIM.2022.3205908
- [25] W. Q. Yang and L. Peng, "Image reconstruction algorithms for electrical capacitance tomography," *Meas. Sci. Technol.*, vol.14, no.1, pp.1-13, 2002. DOI: 10.1088/0957-0233/14/1/201
- [26] W. Q. Yang, M. S. Beck and M. Byars, "Electrical capacitance tomography-from design to application," *Meas. Sci. Technol.*, vol.28, no.9, pp.261-266, 1995.
DOI: 10.1177/002029409502800901
- [27] A. K. Khambampati, S. K. Sharma and K. Y. Kim, "Estimation of electrode contact impedance and conductivity of single-layer graphene using electrical impedance tomography," *Meas. Sci Technol.*, vol.33, no.8, 084007, 2022.
DOI: 10.1088/1361-6501/ac6c76
- [28] H. Wang, H. Shi, K. Lin, C. Qin, L. Zhao, Y. Huang and C. Liu, "A high-precision arrhythmia classification method based on dual fully connected neural network," *Biomedical Signal Processing and Control*, vol.58, 101874, 2020.
DOI: 10.1016/j.bspc.2020.101874
- [29] T. N. Sainath, O. Vinyals, A. Senior and H. Sak, "CONVOLUTIONAL, LONG SHORT-TERM MEMORY, FULLY CONNECTED DEEP NEURAL NETWORK," *2015 IEEE International Conference*

on Acoustics, Speech and Signal Processing (ICASSP), 2015, pp.4580-4584.

DOI: 10.1109/ICASSP.2015.7178838

[30] B. S Ko, H. G. Kim, K. J. Oh and H. J. Choi, "Controlled dropout: A different approach to using dropout on deep neural network," *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*, 2017, pp.358-362.

DOI: 10.1109/BIGCOMP.2017.7881693

[31] P. Liashchynskiy and P. Liashchynskiy, "Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS,"

DOI: 10.48550/arXiv.1912.06059

[32] M. G. M. Abdolrasol, S. M. S. Hussain, T. S. Ustun, M. R. Sarker, M. A. Hannan, R. Mohamed, J. A. Ali, S. Mekhilef and A. Milad, "Artificial Neural Networks Based Optimization Techniques: A Review," DOI: 10.3390/electronics10212689

[33] C. E. Nwankpa, W. Ijomah, A. Gachagan and S. Marshall, "Activation Functions: Comparison of Trends in Practice and Research for Deep Learning," DOI: 10.48550/arXiv.1811.03378

[34] J. Xu, Z. Li, B. Du, M. Zhang and J. Liu, "Reluplex made more practical: Leaky ReLU," *2020 IEEE Symposium on Computers and Communications (ISCC)*, 2020, pp.1-7

DOI: 10.1109/ISCC50000.2020.9219587

[35] N. Zhang, S. -L. Shen, A. Zhou and Y. -S. Xu, "Investigation on Performance of Neural Networks Using Quadratic Relative Error Cost Function," in *IEEE Access*, vol.7, pp.106642-106652, 2019. DOI: 10.1109/ACCESS.2019.2930520

Anil Kumar Khambampati (Member)



2003 : BS degree in Mechanical Engineering, Jawaharlal Nehru Technological University, India.

2006 : MS degree in Marine Instrumentation Engineering, Jeju National University.

2010 : PhD degree in Electronic Engineering, Jeju National University.

Kyung Youn Kim (Member)



1983 : BS degree in Electronic Engineering, Kyungpook National University.

1986 : MS degree in Electronic Engineering, Kyungpook National University.

1990 : PhD degree in Electronic Engineering, Kyungpook National University.

BIOGRAPHY

Minho JEON (Member)



2014 : BS degree in electronic engineering, Jeju National University.

2016 : MS degree in electronic engineering from the Faculty of Applied Energy System, Jeju National University.