

Super Resolution 을 이용한 MaxwellFDFD 소자 모듈 특성 예측

서장원, 김유중, 김원석, 김인수, 석준희*
고려대학교, *고려대학교

jwein307@korea.ac.kr, *jseok14@korea.ac.kr

The prediction of MaxwellFDFD device module characteristics using Super Resolution

Jangwon Seo, Yoojoong Kim, Wonsuk Kim, Insoo Kim, Junhee Seok*
Korea Univ., *Korea Univ.

요 약

MaxwellFDFD 는 특정 디자인의 소자 모듈 특성을 계산하는 시뮬레이터이다. 이 시뮬레이션은 해상도가 높아질수록 계산량이 매우 크게 증가하기 때문에 실제 소자 디자인에 고해상도의 시뮬레이션은 적합하지 않다. 본 논문에선 저해상도 시뮬레이션 결과로부터 고해상도 시뮬레이션 결과를 Super Resolution 기법을 적용한 SRCNN 모델을 통해 예측하고 단순한 예측 방법과 예측 성능을 비교한다. 이 모델은 소자 모듈 특성에 대한 고해상도 시뮬레이션의 시간적 한계에 대한 해결책을 제시한다.

I. 서 론

최근 급속도로 발전한 딥러닝 과 기계학습 기법은 복잡한 입력과 출력 사이의 관계를 효과적으로 찾을 수 있어 영상처리, 자연어처리 등 다양한 분야에 사용되고 있다. 기존의 소자 모듈 설계는 인간 전문가의 지식과 경험을 바탕으로 하여 이루어지기 때문에, 전통적인 설계에서 벗어나기 어렵고 소자 설계의 비용이 높고 비효율적이다. 하지만 반복적인 소자 설계과정에서 다양한 구조에 대한 결과가 축적되어 빅데이터를 형성할 수 있는 환경이 마련되었다. 본 연구에선 소자 시뮬레이션으로 축적된 빅데이터를 이용하여 소자 디자인 기반의 소자 모듈 특성의 예측을 다룬다.

Maxwell FDFD (Maxwell's equations by the finite-difference frequency-domain)[1]는 주파수 영역 Maxwell 의 방정식을 해결하는 Matlab 기반 패키지다. 이 시뮬레이터를 이용해 생성된 광학소자 모듈 디자인의 특성을 계산할 경우 설정된 노드와 셀을 이용해 공간을 잘게 쪼개서 미분방정식의 근사해를 추정해내는 방식이다. 노드와 셀의 숫자를 증가시켜서 측정 단위를 낮게 하여 노드와 노드 사이의 미세한 차이를 알기 위해서는 그만큼 계산 시간이 기하급수적으로 증가하게 된다. 영상처리에서 사용되는 Image Super Resolution 은 저해상도의 이미지를 고해상도의 이미지로 변화해주는 기술이다. Super Resolution 기법에 CNN (Convolutional Neural Network)[2]을 합친 SRCNN (Super resolution Convolutional Neural Network)[3]을 활용하여 낮은 해상도에서 구현 시뮬레이터의 값으로 높은 해상도의 시뮬레이터의 값을 예측하는 모델을 개발하였다.

II. 본론

Maxwell FDFD 는 특정 소자 디자인의 다양한 특성을 계산하는 시뮬레이터이다. 이 시뮬레이션은 그림 1(a)와 같이 진공상태에서 소자 모듈에 평면파를 주입하여 다양한 특성을 계산한다. 이는 복잡한 Maxwell 방정식을 풀어야하기 때문에 단순한 소자 디자인에 대해서도 시간이 매우 오래 걸린다. 시뮬레이션은 전체 해상도가 높아질수록 더욱 정밀한 측정이 가능하다. 그러나 해상도가 높아질수록 계산량이 매우 크게 증가하기 때문에 시간이 매우 오래 걸리고 소자디자인에 고해상도의 시뮬레이션은 적합하지 않다. 본 논문에선 계산된 다양한 특성 중 그림 1(b)의 전기장(E)과 자기장(H)의 크기를 다루고 저해상도의 소자 모듈 특성으로부터 고해상도의 소자 모듈 특성을 예측한다.

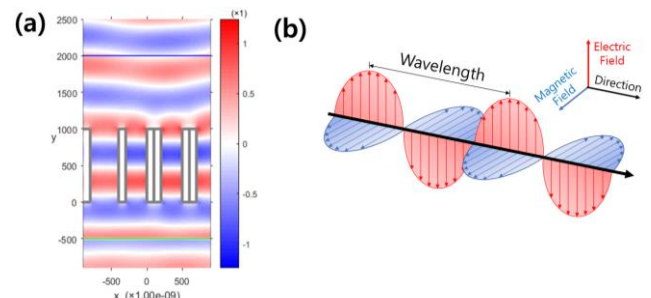


그림 1. Maxwell FDFD 시뮬레이션 예시. (a) 단순 소자 모듈 시뮬레이션 예시. (b) 소자 모듈 특성.




그림 2. 해상도에 따른 시뮬레이션 예시. (a) 저해상도 (20*20). (b) 고해상도(10*10).

전체 시뮬레이션 공간을 여러 개의 셀(Cell)로 나누어 각 셀의 소자 모듈 특성을 계산한다. 그림 2 는 해상도에 따른 소자 모듈 특성의 계산을 나타낸다. 그림 2(a)는 20*20 셀에서 하나의 소자 모듈 특성의 계산을 나타내고, 그림 2(b)는 20*20 의 동일한 셀에서 4 개의 소자 모듈 특성의 계산을 나타낸다. 즉 시뮬레이션의 셀 크기가 클수록 저해상도(그림 2(a))이고 셀 크기가 작을수록 고해상도(그림 2(a))이다.

여러 소자 디자인에 대해 각 셀의 중간지점의 전기장과 자기장의 크기를 시뮬레이터로 계산하여 5,000 개의 해상도별 소자 모듈 특성 데이터를 구축하였다. 전체 데이터 중 4,000 개의 표본이 학습에 사용되었고, 나머지 1,000 개의 표본은 검증에 사용되었다. 셀 크기 20 과 50 각각으로부터 셀 크기 10 의 소자 모듈 특성을 예측한다. 해당 분석에는 평균분석, Interpolation, SRCNN (Super Resolution Convolutional Neural Network)이 사용되었고 각 모델의 R^2 를 비교하였다.




그림 3. SRCNN 구조

본 논문에서 사용한 SRCNN 의 구조는 그림 3 과 같다. SRCNN 은 저해상도 이미지로부터 patch extraction and representation, Non-linear mapping, Reconstruction 과정을 거쳐 고해상도 이미지를 출력한다. Activation function 은 Relu 를 사용했다.

표 1. 고해상도 소자 특성 예측 성능 비교

소자 모듈 특성	셀 크기	R^2		
		평균분석	Interpolation	SRCNN
E	20	0.8883	0.8775	0.8965
	50	0.3570	0.1578	0.5262
H	20	0.9184	0.9353	0.9677
	50	0.4279	0.1690	0.6901

단순한 평균분석이나 Interpolation 모델보다 딥러닝을 적용한 복잡한 모델인 SRCNN 이 더 높은 R^2 를 보였다. 평균분석, Interpolation, 딥러닝 모델에서 공통적으로 자기장 예측 결과가 전기장 예측 결과보다 더 높은 R^2 를 보였다. 또한 셀 크기 20 으로 셀 크기 10 을 예측한 결과가 셀 크기 50 으로 셀 크기 10 을 예측한 결과보다 더 높은 R^2 를 보였다.

III. 결론

MaxwellFDFD 는 특성 소자 디자인의 다양한 특성을 계산하는 시뮬레이터로 본 논문에서 다른 전기장과 자기장의 데이터를 구축했다. 시뮬레이터로 계산한 저해상도 소자 모듈 특성으로 고해상도 소자 모듈 특성을 예측하는 SRCNN 모델을 단순한 예측 방법과 비교했다. 다른 방법에 비해 SRCNN 이 더 높은 성능을 보였다.

SRCNN 모델은 이미지의 해상도를 높이는데 사용되어 왔다. 이미지와 시뮬레이터상의 소자 모듈 특성은 고차원의 숫자로 구성되어 있는 공통점이 있다. 이를 바탕으로 소자 모듈 특성 시뮬레이션의 해상도를 성공적으로 높일 수 있었다. 또한 본 연구는 소자 모듈 특성에 대한 고해상도 시뮬레이션의 시간적 한계에 대한 해결책을 제시한다.

본 연구진은 본 연구가 소자 분야의 엔지니어 및 연구자에게 유용하게 사용되길 기대한다.

ACKNOWLEDGMENT

이 논문은 삼성전자와 한국 연구재단 (NRF-

2019R1A2C1084778)의 지원을 받아 수행된 연구임

참 고 문 헌

- [1] Shin, Wonseok, and Shanhui Fan. "Choice of the perfectly matched layer boundary condition for frequency-domain Maxwell's equations solvers." *Journal of Computational Physics* 231.8 (2012): 3406-3431.
- [2] LeCun, Yann, and Yoshua Bengio. "Convolutional networks for images, speech, and time series." *The handbook of brain theory and neural networks* 3361.10 (1995): 1995.
- [3] Dong, Chao, et al. "Image super-resolution using deep convolutional networks." *IEEE transactions on pattern analysis and machine intelligence* 38.2 (2015): 295-307.