

디스플레이에서의 Deep Learning 응용

남형식
(경희대학교 정보디스플레이학과)

1. 서론

Intelligence는 목표를 달성하기 위한 결정을 내리도록 학습하는 능력을 의미한다. 이를 위해 목표를 설정하는 능력, 결정을 내리는 능력, 그리고 학습을 할 수 있는 능력이 필요하다. 기계에게 이런 능력을 심어주기 위한 연구 분야가 artificial intelligence (AI), 즉 인공지능이고 machine learning은 이런 여러 능력 중 학습할 수 있는 능력에 대한 연구라고 볼 수 있다. 2000년대 후반부터 구글과 같은 인터넷 기업 등을 통해 확보된 많은 데이터, graphic processing unit (GPU)과 같은 강력한 연산 장비들, 그리고 다양한 구조의 신경망을 힘입어 성능면에서 엄청난 발전을 이루었다. 특별히 많은 층과 뉴런으로 구성된 machine learning을 deep learning으로 분류하고 이를 많은 분야에 적용하면서 deep learning이라는 용어를 더 많이 사용하고 있다. 무엇보다도 구글 딥마인드의 알파고^[1]가 기계는 불가능할 거라고 믿고 있던 바둑에서 이세돌 9단을 1번을 제외하고 모두 이기고 이후 최고의 프로바둑기사들에게 한 번의 패배 없이 모두 이기면서 일반인들도 deep learning에 대한 큰 관심을 갖게 되었고 다양한 분야와 여러 기업들은 deep learning을 적용하여 문제를 해결하려는 노력들을 활발히 진행하였다.

현재까지도 가장 활발히 연구가 진행되고 있고 또

한 적용되고 있는 대표적인 분야는 computer vision이다. Image classification은 주어진 영상이 어떤 물체를 나타내는지를 분류해 내는 분야인데, 이미 사람보다 더 높은 정확도를 보이는 deep learning 신경망들이 발표되었다.^[2] 영상에서 물체의 위치를 찾고 그 물체가 어떤 물체인지를 분류하는 object detection이라는 분야도 많은 발전을 이룬 분야 중 하나이다.^[3] 특히 자율주행 분야에서 차량 주변의 상황을 인지하기 위해 보행자나 다른 차량, 그리고 다양한 물체들을 구별하고 인지해야 하기 때문에 object detection 기술은 필수이며 현재 많은 기업들이 해당 기술 개발에 전념하고 있고 실제 차량에 적용되고 있다.^[4] 생성망 (generative network) 분야도 deep learning이 활발히 적용되고 있는 분야인데, 실제 존재하지 않으나 존재할 것 같은 사람의 얼굴을 만들거나, 글이나 음악을 기계가 만든다는 이야기를 누구나 한 번은 들어보았을 것이다.^[5] 최근 스마트폰에는 사진을 찍었을 때 원하지 않는 배경이나 물체가 들어갔을 때 해당 영역을 지우고 주변 배경으로 채우는 기술이 많이 적용되고 있는데 이런 분야도 deep learning을 적용하는 연구가 활발히 이루어지고 있다.^[6] 신약 개발에도 deep learning을 사용하면 시간과 비용을 절감할 수 있다는 기사를 인터넷에서 쉽게 접할 수 있다.^[7]

이렇게 성능면에서 많은 발전을 이루었지만 완벽

한 성능을 보장할 수는 없다. 따라서 신경망의 결과에 대한 분석이 필요한데, 많은 층과 뉴런으로 이루어진 deep learning 망을 해석하는 것은 불가능하기 때문에 deep learning 망을 black box라고 표현하다. 하지만 수술이나 자율주행처럼 사람의 목숨과 관련되었거나 재판이나 대출처럼 결과에 대한 부연 설명이 필요한 부분에서는 deep learning 망의 해석이 필수적이다. 이런 연구를 explainable AI (XAI)로 부르고 deep learning 망의 성능을 높이려는 노력들과 함께 많은 연구들이 진행되고 있다.^[8, 9]

이 글에서는 deep learning을 적용하는 다양한 분야 중, 디스플레이와 연관되어 진행되고 있는 deep learning 연구들에 대해 좀더 구체적으로 들여다보자 한다.

2. 디스플레이 적용 Deep Learning 기술

2.1. 불량 검출

가장 많이 가장 쉽게 deep learning을 적용하고 있는 분야가 디스플레이 패널 공정 상에서 발생하는 불량 검출의 자동화이다. 생산되는 패널의 양도 많고 패널 크기가 크기 때문에 발생하는 불량의 종류와 위치가 다양하다. 따라서 사람의 눈으로 판별하기보다 deep learning을 이용하여 불량의 종류나 위치를자동으로 사람보다 더 높은 정확도로 분류할 수 있다면 공정에 큰 도움을 줄 것이다.

불량의 종류를 자동 분류하는 기술은 image classification 기술로 해결할 수 있다. 불량의 종류를 미리 분류해 놓고 각 불량에 대한 영상 데이터를 충분히 모아 놓는다. 이 때 영상 데이터에 해당하는 미리 지정한 종류(class)를 정답(machine learning에서는 label이라고 함)으로 해서 주어진 신경망을 지도학습(supervised learning) 방식으로 훈련시키고 이를 통해 분류가 가능하도록 한다.

기존의 한 논문에서는 그림 1과 같이 4개의 종류로 불량을 정의하고 이를 convolutional neural network (CNN)을 이용하여 구분할 수 있음을 보여주었다.^[10] 또 다른 논문에서는 그림 2와 같이 7개의 불량과 1개의 정상 영상으로 분류하고 마찬가지로

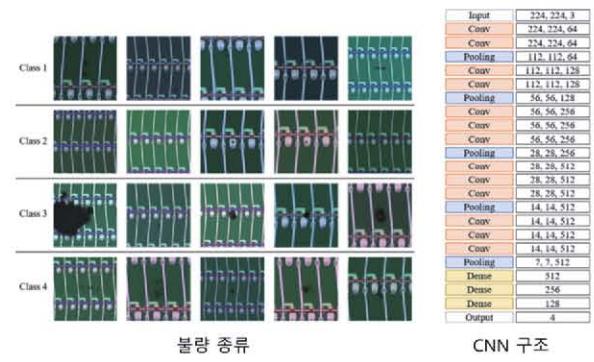
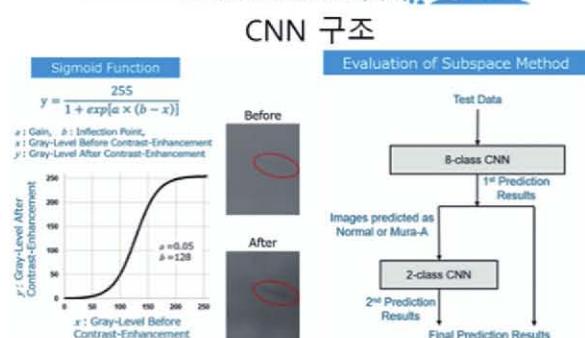
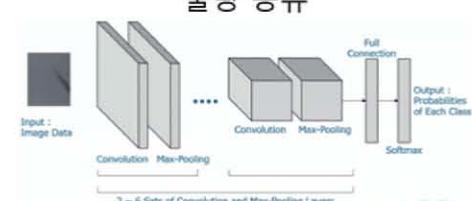
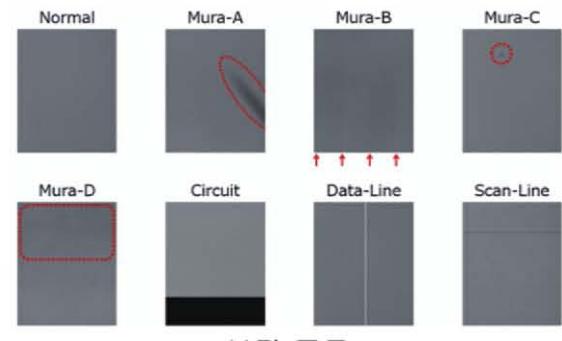


그림 1. 불량 종류 분류 신경망 기술의 예 1



Contrast Enhancement

2단계 분류

그림 2. 불량 분류 신경망 기술의 예 2

CNN을 통해 추출하는 기술을 제안하였고, contrast enhancement와 2단계의 분류를 통해 추가적인 성능 개선을 확보할 수 있었다.^[11]

그러나 이렇게 주어진 영상 전체를 하나의 불량으로 분류하는 것은 한계를 가진다. 여러 가지의 불

량이 한 영상 안에 존재할 수 있고 작은 크기의 불량인 경우, 다양한 위치에서 발생할 수 있다. 따라서 위치와 불량의 종류를 동시에 검출할 수 있는 object detection 기술을 적용하는 연구가 수행되었다.^[12] 그림 3과 같이 기존의 object detection 신경망을 이용하여 불량의 위치와 불량의 종류를 동시에 검출할 수 있었다.

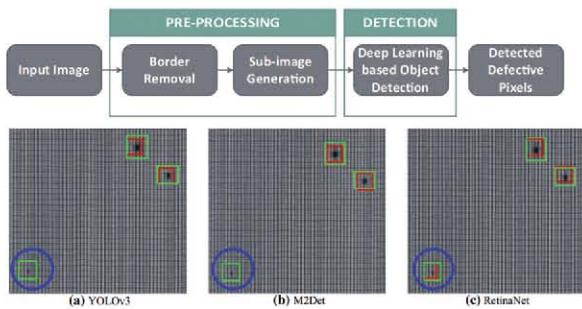


그림 3. 불량의 위치 및 종류 검출 신경망의 예

2.2. 불량 데이터 불균형 개선

Deep learning 신경망을 정상적으로 훈련시키기 위해서는 정답에 해당하는 데이터와 정답이 아닌 데이터가 비슷한 비율로 주어져야 한다. 예를 들어 공정의 수율이 너무 좋아서 1 %의 불량이 발생한다고 하자. 양품에 대한 데이터가 99 %에 해당하기 때문에 deep learning을 사용하지 않더라도 99 %의 정확도를 가지게 된다. Deep learning을 적용하더라도 100 %의 정확도를 얻을 수 없기 때문에 무조건 양품으로 판단되도록 훈련될 수도 있다. 실제 제품을 양산하는 공정은 수율이 높아야 가격 경쟁력을 가질 수 있기 때문에 실제로 90% 후반대의 높은 수율을 가지고 있으며 양품과 불량 품에 대한 데이터의 양이 양품에 치우쳐 있는 문제를 피할 수 없다. 불량 품에 대한 데이터를 늘려 양품과 불량의 데이터 비율을 맞추기 위해 deep learning을 이용하여 그림 4와 같이 가상의 불량 데이터를 만들어 내는 신경망에 대한 연구를 활발히 하고 있다.^[13]

가상 데이터를 만들어내는 분야에서 많이 활용하고 있는 신경망 기술이 generative adversarial network (GAN) 기술이다.^[14] 그림 5와 같이 GAN은 generator network과 discriminator network으로 구성하여 훈련을 시키는데, generator network은 가상의 영상을 만들어 내고



그림 4. 가상 불량 영상 생성 예

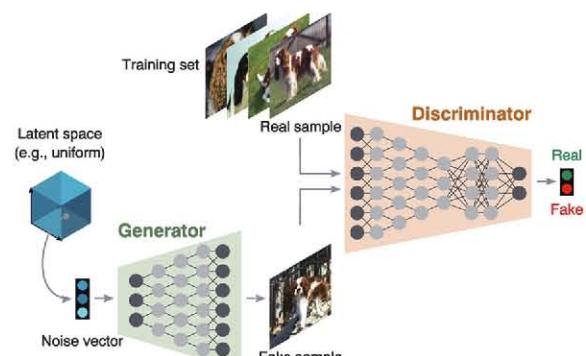


그림 5. GAN의 구조

discriminator network^[15] 주어지는 이미지가 가상의 영상인지 실제 영상인지를 구별해 내도록 한다.^[15] 이 둘을 함께 훈련시키면 generator network은 discriminator network이 잘 구별해 낼 수 없도록 성능이 향상되고 동시에 discriminator network은 향상된 generator network의 결과물에 대해서 더 잘 구별해 낼 수 있도록 향상이 된다. 이렇게 서

로 반대 방향으로 성능을 향상시키면서 generator network 성능을 개선하는 기술로 많은 데이터 생성 응용 분야에서 연구하고 있다. 한 논문에서는 다양한 GAN 구조를 적용하여 불량에 대한 가상 이미지를 만들어 보고 그 장단점을 공유하였다.^[16]

2.3. 해상도 변환

디스플레이의 해상도가 급속히 증가함에 따라 실제 디스플레이의 해상도가 현재 존재하는 입력 영상 해상도보다 높아지는 상황이 발생하게 되었다. 물리적으로 더 높은 해상도의 디스플레이에 낮은 해상도의 영상을 보여주기 위해서는 입력 영상의 해상도를 증가시키는 기술이 필요한데, 그림 6과 같이 낮은 해상도의 영상을 높은 해상도로 증가시키는 기술을 super resolution (SR)이라고 한다.

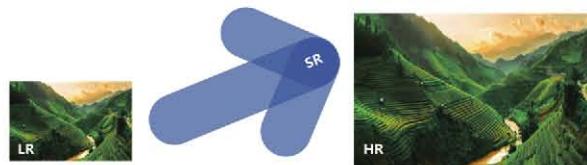


그림 6. SR 기술의 개념

Deep learning 이전에도 interpolation을 이용하여 해상도를 증가시키는 기술이 있었으나 화질 성능 면에서 많이 부족한 결과들을 보였다. 이에 반해 deep learning을 적용한 경우는 매우 높은 화질 향상을 얻을 수 있었다.^[17] SR에 적용되는 deep learning은 그림 7과 같이 다양한 구조의 신경망을 통해서 성능 향상을 이루었고 앞절에서 다루었던 GAN을 이용하여 화질 향상을 얻은 연구도 발표되었다. Deep learning SR 기술은 일반적으로 고해상도 영상이 있고 그에 대응되는 저해상도 영상을 마련하여 저해상도 영상을 입력으로 넣고 해당하는 고해상도 영상과의 차이를 최소화하도록 CNN으로 구성된 신경망을 지도학습 방법으로 훈련시키도록 구현한다. 최근 발표된 논문에서 높은 해상도의 head mounted display (HMD)에 적용하는 foveated rendering 기술과 접속하여 그림 8과 같이 progressive 구조와 recursive 구조를 통해 복잡도를 획기적으로 낮춘 SR 기술도 발표되었다.^[18]

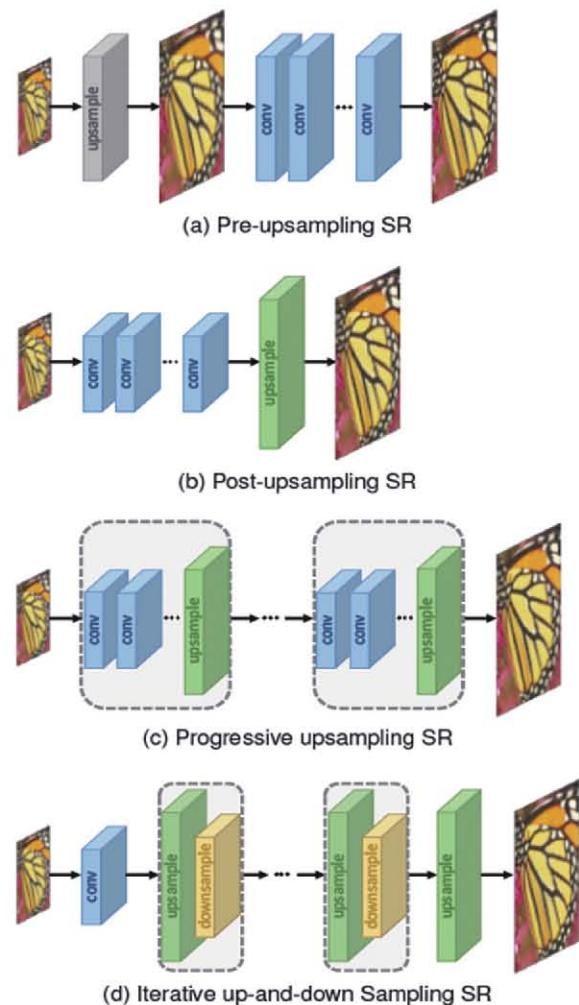


그림 7. 다양한 SR 신경망 구조

Proposed SR = Cropping + Progressive + Recursive

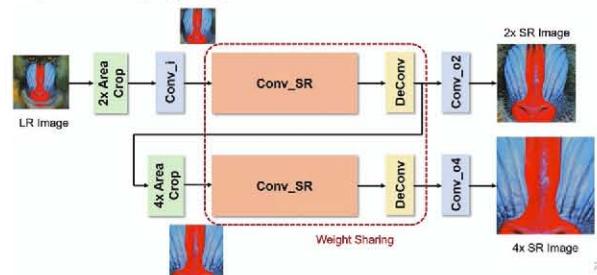


그림 8. Foveated rendering 적용된 HMD를 위한 SR 신경망

2.4. Dynamic Range 변화

디스플레이의 기술이 발전하면서 해상도뿐만 아니라 표현할 수 있는 휘도의 범위 (dynamic range)도 함께 증가되었다. 그림 9와 같이 현재 많이 활용되고 있는 8 bit의 계조 표현을 뛰어 넘어 12 bit의 계조 표

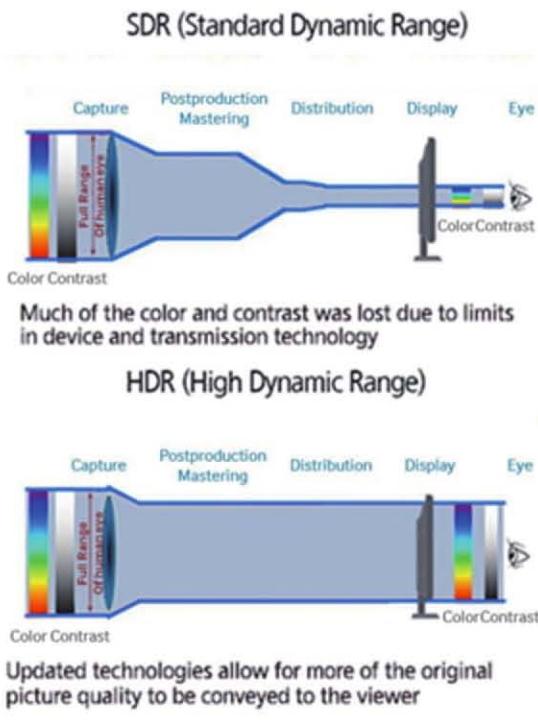


그림 9. High Dynamic Range 디스플레이

현이 가능한 디스플레이에 대한 표준이 마련되었고 해당 디스플레이들이 개발되고 있다. [19]

그러나 현재 대부분 영상들의 dynamic range는 8 bit의 standard dynamic range (SDR)에 맞춰져 있어 이를 high dynamic range (HDR)로 만드는 기술이 필요하고 이를 위해 deep learning을 적용하여 HDR 영상을 만드는 연구도 활발히 진행되고 있다. [20]

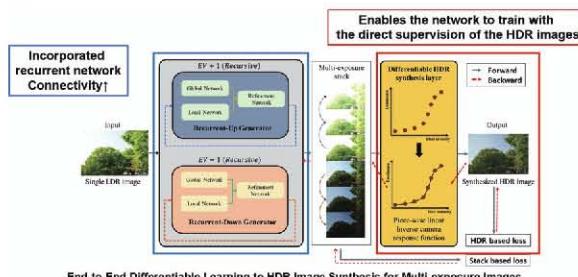


그림 10. HDR 영상을 만드는 Deep Learning 구조 예

한 논문에서는 HDR 영상을 만드는 방법 중에 노출 시간을 다르게 적용한 여러 장의 영상을 찍고 이를 결합하여 dynamic range를 늘리는 방식을 기반으로 한 deep learning 기술을 발표하였다. 그림 10

과 같이 입력으로는 하나의 SDR 영상만 받고 deep learning 신경망 내에서 노출 시간이 다른 여러 장의 영상을 SDR 영상으로부터 만들어 낸 후 이 영상들을 결합하여 HDR 영상을 만들 수 있음을 보여주었다. [21]

2.5. 이미지 복원

최근에 스마트폰에서 많은 관심을 받고 있는 기술 중 하나가 under display camera (UDC)다. 현재 까지 그림 11과 같이 영상 통화나 자신의 영상을 찍기 위해 화면 상단부에 camera가 위치하게 되고 그 영역은 디스플레이를 비워 두는 방식으로 채택해 왔다. [22]

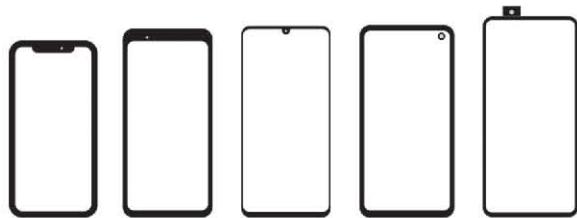


그림 11. 스마트폰 디스플레이 면의 카메라 배치



그림 12. Under Display Camera가 적용된 스마트폰

하지만 Camera를 디스플레이 아래에 두고 디스플레이를 통과하여 들어오는 빛을 이용하여 영상을 캡쳐 할 수 있다면 그림 12와 같이 모든 영역에 디스플레이를 구현할 수 있다는 장점을 가지게 된다. [23] 하지만 빛이 디스플레이를 통과하면 회절 등에 의해 캡쳐된 영상에는 왜곡이 발생하게 된다. 이렇게 왜곡된 영상으로부터 원래 영상을 복원하기 위해 deep learning을 적용하는 기술이 연구되고 있고, 여러 논문들을 통해 발표되었다. 한 논문에서는 그림 13과 같이 높은 주파수 영역과 낮은 주파수 영역을 나눠서 처리함으로

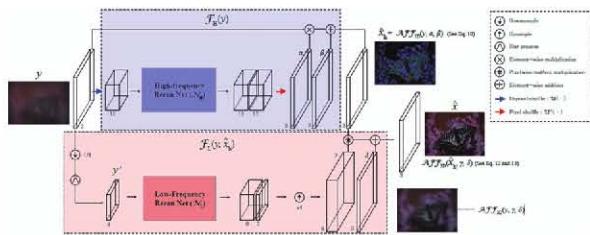


그림 13. UDC 왜곡 영상 보상을 위한 Deep Learning 신경망

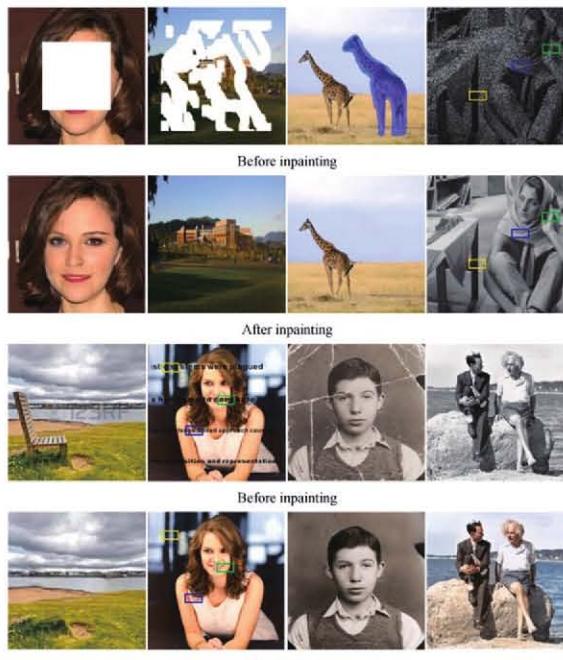


그림 14. Inpainting 적용 예

써 UDC에서 발생할 수 있는 다양한 왜곡을 보상할 수 있음을 보여주었다.^[24]

또한 그림 14와 같이 이미지의 손상이나 원하는 영역의 이미지를 제거한 후 해당 영역의 주변의 영상 정보를 이용하여 채워 넣는 inpainting 기술에도 deep learning이 활용되고 있다.^[6]

특히 GAN 신경망을 활용하는 방법이 많이 연구되고 있는데, 한 논문에서는 두 개의 GAN을 활용하여 우선 영상의 테두리를 먼저 채우고 그 다음 색을 채우는 구조를 통해 우수한 결과를 보여주었다.^[25] 또한 aspect ratio가 다른 경우 예를 들어 4:3 영상을 16:9 디스플레이에 나타내고자 할 때 영상의 좌우에 블랙 화면을 채우는 방식을 많이 활용하는데, 그 부분에 그럴싸한 영상으로 채워서 16:9 영상을 만드는

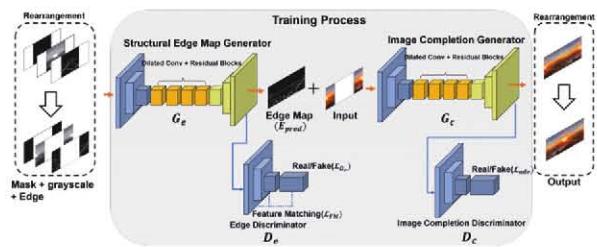


그림 15. Outpainting 신경망 예

outpainting 기술도 제안되었다. 한 논문에서는 그림 15와 같이 입력 영상을 둘로 나눠 양쪽 끝으로 이동시킨 후 가운데를 채우는 inpainting 문제로 변환하여 해결하였다.^[26]

2.6. 재료/소자 설계

디스플레이의 재료나 소자 설계 분야에도 deep learning이 활용되고 있는데, 복잡한 물리 기반의 연산을 통한 시뮬레이션으로 재료나 소자의 특성을 해석하는 것은 시간을 많이 필요로 하는 반면 이것을 신경망으로 대체하면 분석 시간을 줄일 수 있고 재료나 소자를 설계하는 과정 전체를 신경망으로 구현할 때 신경망으로 구성되어 있으면 쉽게 결합하여 활용될 수 있다.

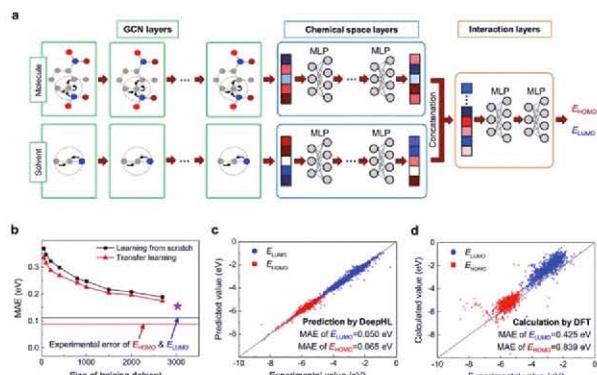


그림 16. 소자의 에너지 레벨 예측을 위한 deep learning 적용 예

한 논문에서는 OLED의 HOMO와 LUMO 에너지 레벨을 예측하는 deep learning 기술을 소개하였다.^[27] 그림 16과 같이 Graph convolutional network (GCN) 기반으로 측정 데이터들로 deep learning 구조를 구현하여 에너지 레벨을 예측하도록 하였고, 그 결과 density functional theory (DFT)

를 기반으로 예측한 결과보다 더 정확한 결과를 얻을 수 있었다. 이런 정확도를 기반으로 실제 제작 전에 가능한 구성을 선별할 수 있다고 강조하고 있다.

2.7. 회로 설계

회로 설계에서 가장 활발히 machine learning이 활용되고 있는 것은 parameter optimization 분야다. 원하는 특성을 만족하기 위해 설계 parameter 값을 최적화하는 데 활용하고 있다. 한 논문에서는 그림 17과 같이 operational amplifier의 동작 주파수와 전력 소모를 최적화하기 위해 deep learning을 활용한 결과를 보여주었고,^[28] 다른 논문에서는 layout에서 신호 지연과 전력 소모를 최적화하기 위해 그림 18과 같이 강화학습을 적용한 예를 발표하였다.^[29]

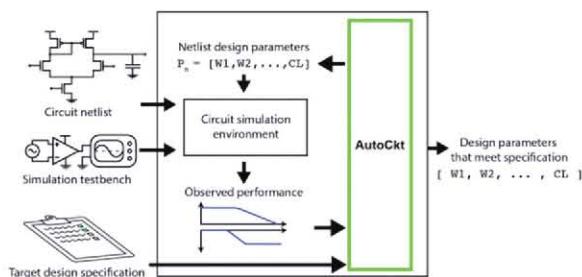


그림 17. Operational amplifier의 parameter 최적화

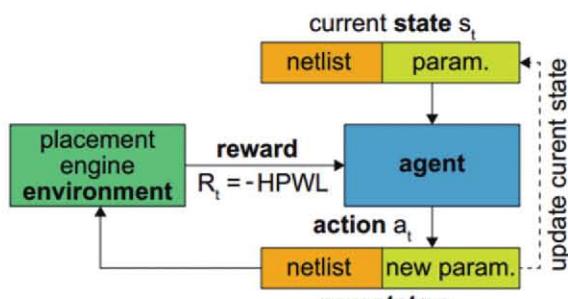


그림 18. Layout 최적화를 위한 강화학습 구조

다른 한 편으로는 회로를 트랜지스터 레벨에서 설계하는 deep learning 구조에 대한 연구도 발표되었다. 이 논문에서는 강화학습을 이용하여 레고 블록처럼 트랜지스터들을 한 번에 하나의 노드 연결을 추가하면서 원하는 목표 디지털 회로를 자동으로 구성해 줄 수 있음을 발표하였다. 강화학습을 사용했기 때문

에 여러 경로를 따라 회로를 구성해 보면서 최적의 회로를 도출해 낸 결과를 소개하였다.[30]

3. 결론

이 글을 통해 디스플레이에서 활용되고 있는 deep learning 기술들에 대해 간단히 설명하였다. Deep learning이 많은 성능 향상을 가져다주었고 주로 컴퓨터 공학 전공자들을 통해 이루어진 것이 사실이지만, deep learning을 적용할 수 있는 문제를 찾는 것은 디스플레이를 직접 연구하고 개발하는 인력들에 의해 수행되어야 한다. 즉, 디스플레이 엔지니어들이 deep learning을 활용할 수 있는 문제를 찾고 문제를 정의해 주어야 하고 이 문제들을 기반으로 deep learning 엔지니어들이 해결할 수 있는 알고리즘을 제시하도록 해야 하는 것이다. 이를 원활하게 하기 위해서 두 분야의 협력이 필수이며 원활한 협력을 위해서는 디스플레이 엔지니어들이 deep learning이 어디에 어떻게 활용되고 있는지를 알아야 하고 또한 deep learning에서 사용하는 용어들에 대해 어느 정도 이해하고 있어야 한다고 생각한다. 두 분야의 협력을 원활하게 하는데 조금이라도 도움이 될 수 있기를 바라며 이 글을 마무리한다.

4. 참고문헌

- [1] D. Silver, A. Huang, C. Maddison, A. Guez, L. Sifre, G. van den Driessche, J. Schrittwieser, I. Antonoglou, V. Panneershelvam, M. Lanctot, S. Dieleman, D. Grewe, J. Nham, N. Kalchbrenner, I. Stutskever, T. Lillicrap, M. Leach, K. Kavukcuoglu, T. Graepel, and D. Hassabis, *Nature* **529**, 484 (2016).
- [2] W. Rawat and Z. Wang, *Neural Comput.* **29**, 2352 (2017).
- [3] L. Liu, W. Ouyang, X. Wang, P. Rieguth, J. Chen, X. Liu, and M. Pietikaninen, *Int. J. Comput. Vis.* **128**, 261 (2020).
- [4] A. Gupta, A. Anpalagan, L. Guan, and A. S. Khwaja, *Array* **10**, 100057 (2021).
- [5] H. GM, M. K. Gourisaria, M. Pandey, and S. S. Rautaray, *Comput. Sci. Rev.* **38**, 100285 (2020).

- [6] Z. Qin, Q. Zeng, Y. Zong, and F. Xu, *Displays* **69**, 102028 (2021).
- [7] A. Lavecchia, *Drug Discov. Today* **24**, 2017 (2019).
- [8] A. Adadi and M. Berrada, *IEEE Access* **6**, 52138 (2018).
- [9] J. Lee, H. Cho, Y. J. Pyun, S.-J. Kang, and H. Nam, *IEEE Access* **10**, 64832 (2022).
- [10] M. Lee, J. Jeon, and H. Lee, *J. Intell. Manuf.* **33**, 1747 (2022).
- [11] S. Tomita, P. Siritanawan, and K. Kotani, *SID Symp. Dig. Tech.* **53**, 963 (2022).
- [12] A. Celik, A. Kucukmanisa, A. Sumer, A. T. Celebi, and O. Urhan, *J. Intell. Manuf.* **33**, 985 (2022).
- [13] L. Melchior, <https://dida.do/blog/data-augmentation-with-gans-for-defect-detection>.
- [14] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, *Proc. NeurIPS* **27** (2014).
- [15] L. Goetschalckx, A. Andonian, and J. Wagemans, *Trends Cogn. Sci.* **25**, 788 (2021).
- [16] S. Mou, M. Cao, Z. Hong, P. Huang, J. Shan, and J. Shi, *SID Symp. Dig. Tech.* **53**, 957 (2022).
- [17] Z. Wang, J. Chen, and S. C. Hoi, *IEEE Trans. Pattern Anal. Mach. Intell.* **43**, 3365 (2021).
- [18] H. Nam, H. Kang, and H. Cho, *SID Symp. Dig. Tech.* **53**, 869 (2022).
- [19] <https://news.samsung.com/global/what-is-high-dynamic-range-hdr>
- [20] L. Wang and K.-J. Yoon, *IEEE Trans. Pattern Anal. Mach. Intell.*, Early Access (2021).
- [21] Y.-I. Park, J. W. Song, and S.-J. Kang, *SID Symp. Dig. Tech.* **53**, 865 (2022).
- [22] <https://otilmionics.com/under-display-camera/>
- [23] <https://bgr.com/tech/under-display-camera-samsung-upc-for-oled-laptops/>
- [24] J. Koh, J. Lee, J. Kim, Y. Yoo, B. You, and S. Yoon, *SID Symp. Dig. Tech.* **53**, 861 (2022).
- [25] K. Nazeri, E. Ng, T. Joseph, F. Qureshi, and M. Ebrahimi, arXiv: 1901.00212 (2019).
- [26] K. Kim, Y. Yun, K.-W. Kang, K. Kong, S. Lee, and S.-J. Kang, *Proc. WACV*, 2122 (2021).
- [27] M. Jeong, J. F. Joung, J. Hwang, M. Han, C. W. Koh, D. H. Choi, and S. Park, *Npj Comput. Mater.* **8**, 147 (2022).
- [28] K. Settaluri, A. Haj-Ali, Q. Huang, K. Hakhamaneshi, and B. Nikolic, *Proc. DATE*, 490 (2020).
- [29] A. Agnesian, K. Chang, and S. K. Lim, *Proc. ICCAD*, 144 (2020).
- [30] H. Nam, Y. I. Kim, J. Bae, and J. Lee, *Electron.* **10**, 1032 (2021).

저자 약력

남형식



- 1996년 : 한국과학기술원 전기및전자 학사
- 1998년 : 한국과학기술원 전기및전자 석사
- 2004년 : 한국과학기술원 전기및전자 박사
- 2005년 ~ 2010년 : 삼성전자 LCD사업부 책임연구원
- 2010년 ~ 현재 : 경희대학교 정보디스플레이학과 조교수/부교수/교수

• 관심분야 : 디스플레이 회로 및 알고리즘, Machine Learning