

2022 실용 인공지능 학술대회

AAiCON 2022

주제: "인공지능으로 완성되는 디지털 세상"

2022. 07. 01 (금) ~ 02 (토)

국립중앙과학관 대강당 & 세미나실

프로그램 바로가기

<https://aaicon.aifrenz.org/info>



 aaicon2022@aifrenz.org

 <https://aaicon.aifrenz.org/>

DAY 1 (7월 1일, 금요일) - 사이언스홀

구분	시간	발표자	소속	제목
등록	09:30~10:00			학회등록 (안내데스크)
개회사	10:00~10:10	유용균	(사)에이아이프렌즈학회	학술대회 개회사
Keynote session 좌장: 한국원자력연구원 유용균	10:10~10:50	김성훈	Upstage AI / 홍콩과기대	Rule to continual learning in practice
	10:50~11:30	이수영	KAIST	손흥민 특정왕으로부터 배우는 AI 교육
	11:30~12:10	심상우	마키나락스	MLOps for manufacturing
	12:10~13:30			점심 식사
기업 발표 좌장: 페블러스 이정원	13:30~14:00	금영섭	(주)웍스	인공지능 기반 대전시 사회문제발굴과 솔루션 찾기
	14:00~14:30	김충한/이종수	K-water	K-water 디지털 플랫폼과 대전 기반 AI 실증 과제 추진현황
	14:30~15:00	김세엽	셀렉트스타	똑똑한 인공지능을 만들기 위한 좋은 학습데이터를 준비하는 방법
	15:00~15:15			Break time
Oral presentation 좌장: 한국교원대 김귀훈	15:15~15:30	함상우	(주) 이노팸	GeoAI를 이용한 서울시 항공사진 변화탐지
	15:30~15:45	임소영	한국원자력연구원	딥러닝을 활용한 교육용 포드블록 교구의 쌓기구조 패턴 추출
	15:45~16:00	이제현	한국에너지기술연구원	Open API를 활용한 고속 논문 분석
	16:00~16:15	이준기	한국교원대학교	중국 K-12 인공지능 교육 플랫폼 기술 동향
	16:15~16:30			Break time
기업 발표 & 시상 및 논문 발표 좌장: 전자통신부설연구소 고우영	16:30~17:00	안재만	Vessl.AI	MLOps를 시작하는 5가지 방법
	17:00~17:30	수상팀 발표자 1등 팀 : 김경민 2등 팀 : Igor Ivanov 3등 팀 : 안영진	데이콘 경진대회 수상팀	코드 유사성 판단 AI 경진대회 요약 1등 팀: 양상블 기법을 활용한 언어모델 기반 코드 간 유사성 판단 2등 팀: Code Similarity Assessment with a Transformer Model 3등 팀: Encoder is all you need
	17:30~18:00			시상 및 우수 논문 발표

DAY 1 (7월 1일, 금요일) - 세미나실

구분	시간	발표자	소속	제목
	12:10~13:30			점심 식사
Poster presentation 좌장: 선박해양플랜트연구소 박세길	13:30~15:00	송태근	공주대학교	조기 당뇨 진단을 위한 딥러닝 모델의 실용성 검증
		김민원	삼성디스플레이	Gamma correction AI algorithm Using process parameters of Fab
		박경태	삼성디스플레이	이상 지표 공간에서의 지도 학습을 이용한 생산 설비 이상 검출 개선 및 적용
		서등찬	삼성디스플레이	Denosing Autoencoder를 이용한 디스플레이 외광 반사 검사 이미지 불량 분류 기술
		우화성	삼성디스플레이	Display Panel 검사 이미지의 비지도 학습 Autoencoder 기반 신규 AI 모델
	황진하	삼성디스플레이	실시간 On-cell Mura Level 예측 시스템	
	류승형	한국원자력연구원	MLP-Mixer 모델의 단기 전력 부하 시계열 예측 문제 적용에 대한 연구	
	이근형	한국원자력연구원	강화학습을 활용한 열 유체 온도 균일화 유로 형성	
	전병일	한국원자력연구원	방사선 계측기 펄스 신호처리를 위한 딥러닝 모델 개발	
	손승아	한양대학교	Q-Learning 강화학습을 통한 적정재고 산출	
신정우	대전과학기술대학교	인공지능을 활용한 매개모기 자동분류 기술 연구		
	15:00~15:15			Break time
Oral presentation 좌장: 한국화학연구원 강영목	15:15~15:30	주영환	한국에너지기술연구원	그래프 신경망을 이용한 비정형 격자 기반 위상최적화 가속화 기술
	15:30~15:45	송태근	공주대학교	조기 당뇨 진단을 위한 딥러닝 모델의 실용성 검증
	15:45~16:00	김민중	한국원자력연구원	딥러닝을 활용한 아동 그림 유사유형 검출 모델 기술
	16:00~16:15	구인혁	우송대학교	실시간 시선추적 기술을 통한 비대면 수업집중도, 학업성취도 간 관계:개인별 자세의 조절효과
	16:15~16:30			Break time
Oral presentation 좌장: 한국에너지기술연구원 이제현	16:30~16:45	정재호	한국원자력연구원	강화학습을 이용한 지연 전송선의 누화 최적 설계
	16:45~17:00	이근형	한국원자력연구원	강화학습을 활용한 열 유체 온도 균일화 유로 형성
	17:00~17:15	최희선	한국원자력연구원	실시간 음향파 전파 구현을 위한 대칭성 기반의 효과적인 인공신경망 학습
	17:15~17:30	서호건	한국원자력연구원	이상탐지를 위한 Quantile Autoencoder
	17:30~18:00			Break time

DAY 2 (7월 2일, 토요일) - 세미나실 (튜토리얼 진행)

구분	시간	발표자	소속	제목 & 개요
Applied AI Tutorial 좌장: 한국전자통신연구원 손영성	10:00~11:00	강남우	KAIST / 나니아랩 스	『인공지능으로 신제품 개발하기』 AI로 신제품 개발을 더 빠르고 더 스마트하게 할 수 있습니다. AI가 스스로 설계를 생성, 평가, 최적화, 추천하는 제너레이티브 디자인 기술과 적용 사례를 소개합니다.
	11:00~12:00	최상현	경북대학교	『인공지능을 활용한 호흡기 질환의 예측』 최근 시멘트 분진 및 미세먼지 노출 등 환경성 호흡기 질환이 늘어나고 있습니다. 이번 튜토리얼에서는 딥러닝 기술을 활용하여 해당 질환을 예측하는 모형 개발에 대하여 학습합니다.
	12:00~13:00			점심 식사
	13:00~14:00	류승형	한국원자력연구원	『딥러닝을 활용한 이상탐지 기초이해』 이상탐지 문제 구성을 위한 기초적인 이론들과 DSVDD, 오토인코더 등 대표적인 딥러닝 기반 이상탐지 알고리즘의 동작 원리를 살펴본다.
NVIDIA DLI Program	14:00~18:00	최예지	SIA	『4시간 만에 끝내는 이상 탐지 맛보기! - XGBoost, Autoencoder, GAN까지』 이번에 진행하는 아노말리 디텍션은 네트워크 보안분야에서 널리 알려져있는 오픈 데이터셋인 KDD99 Intrusion Detection Dataset을 이용하여 XGBoost와 오토인코더, GAN을 이용한 이상탐지 실습을 진행합니다. 이번 강의를 통해 각 방법론의 차이를 비교해보고 직접 이상탐지를 수행하여 평가를 받고 통과되면 NVIDIA에서 제공하는 수료증도 받으실 수 있습니다. - Anomaly Detection in Network Data using GPU-Accelerated XGBoost - Network Anomaly Detection using Autoencoders - Anomaly Detection in Network Data using GANs https://www.nvidia.com/en-us/training/instructor-led-workshops/anomaly-detection/
<p>** 튜토리얼 관련하여 안내 드립니다.</p> <ul style="list-style-type: none"> - 오프라인 참석하시는 분은 개인 노트북 필요합니다. - NVIDIA DLI 페이지 회원가입 필요합니다. (신청시 알려주신 이메일로 가입방법 안내 예정) 				



2022 실용 인공지능 학술대회

2022. 07. 01 (금) ~ 02 (토)

국립중앙과학관 대강당 & 세미나실

따뜻한 AI 소중한 가치 구현 AI 프렌즈 학회



주최: (사) 에이아이프렌즈학회

후원: 데이콘, 대덕넷, 셀렉트스타, 모두의 연구소,
젠티, 연구개발특구진흥재단, 대전광역시

AiFrenz

GeoAI를 이용한 서울시 항공사진 건물변화탐지

함상우^o 김휘영 정동기

주식회사 이노팜

swham@innopam.com, hykim@innopam.com, dkc@innopam.com

Building Change Detection from Aerial Images Using GeoAI

Sangwoo Ham^o Hwiyoung Kim Dongki Chung

InnoPAM, Inc.

요 약

다시기 유인항공사진에서 건물 변화를 판독하는 일은 위반건축물 단속 근거자료 마련, 지도 제작 및 품질 검수 등을 위해 각 지방자치단체에서 수행하는 중요한 사무다. 이러한 판독 과정은 대부분 수동으로 이루어지고 있으며 공간정보 기술과 AI를 조합한 GeoAI 기술 도입이 요구된다. 본 연구는 건물 변화 유형을 신축, 철거, 재건축, 증개축, 수선으로 나누어 Siamese Network를 학습시키고, 유인항공사진으로 제작한 정사영상을 추론한 후 몇가지 후처리 과정을 거쳐 건물변화 영역을 자동으로 탐지하는데 목적이 있다. 서울시 항공사진을 대상으로 실증을 수행한 결과 완전성은 70% 초반대를 기록하였으며 정확성은 최대 약 82% 가량을 기록하였다. 향후 항공사진 변화 판독 업무에 활용할 수 있을 것으로 기대되며, 타 지방자치단체를 대상으로 추가적인 실증을 수행할 계획이다.

1. 서 론

중앙정부와 지방자치단체에서는 수치지형도 제작, 판독현황도 제작, 정사영상 제작 등 공간정보를 제작하려는 목적으로 매년 항공사진을 촬영한다. 이러한 항공사진은 지도 제작 뿐만 아니라 위반건축물 단속, 국토환경 모니터링 등 다양한 목적으로 사용할 수가 있다. 사진측량 및 원격탐사 분야에서는 항공사진 자료를 이용하여 건물변화탐지를 자동으로 수행하기 위한 연구를 오랫동안 수행해왔으며[1], 최근 사진측량 및 원격탐사 분야에 딥러닝이 도입되면서 건물변화탐지 분야에서도 딥러닝을 적극적으로 활용하고 있다[2].

사진측량 및 원격탐사 분야에서 수행하는 변화탐지 연구는 대부분 건물의 변화를 신축, 철거 여부로 규정하고 있다. 그러나 실제 행정 현장에서는 신축, 철거 여부보다는 더 미세한 단위의 건물 변화에 관심을 가진다. 예를 들어 신축, 철거 여부보다는 건물 지붕 형상이 바뀌는 경우, 건물 지붕의 색상이 바뀌는 경우가 건축물 위반행위와 더 관련이 크기 때문이다. 따라서 건물의 신축, 철거여부보다는 재건축(다른 건물로 변한 경우), 증개축(같은 건물이나 옥상의 형상이 변한 경우), 수선(같은 건물이면서 색상이 변한 경우)과 같은 분류체계를 추가적으로 제시할 필요가 있다.

또한, 변화탐지 결과를 공간정보 기술을 이용해 후처리하고 유용한 서비스를 제공할 필요가 있다. 딥러닝으로 추출한 변화 맵에 Rotated Minimum Bounding Box를 적용하거나 일정 면적 이하의 객체를 제거하는 방식으로 후처리를 수행한다면 추가적인 학습 없이 변화탐지 성능을 향상시킬 수 있을 것이다.

본 연구는 건물 변화 유형을 신축, 철거, 재건축, 증개축, 수선으로 나누어 다시기 항공사진에 라벨링을 수행한 후 매개변수를 공유하는 2개의 encoder와 이들로부터 추출한 영상 특징으로부터 변화 맵을 생성하는 1개의 decoder를 연결한 W-net을 학습시킨다[3]. 그리고 W-net의 추론 결과를 공간정보 기반으로 후처리하여 변화 영역을 표현한다. 특히, 건물 변화의 형태가 복잡한 서울시 중구, 용산구, 마포구, 강서구, 중랑구 일대를 대상으로 모델 학습과 성능 실증을 수행하였다.

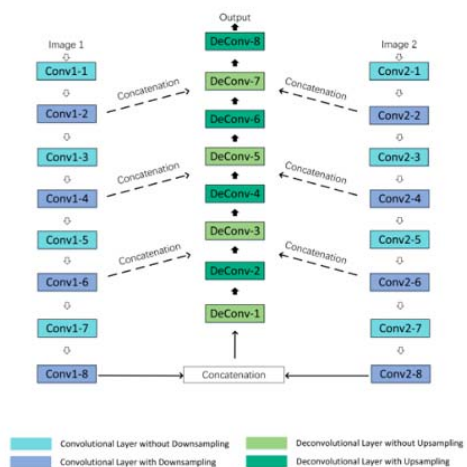


Fig. 1 W-net 구조[3]



Fig. 2 본 연구에서 제안하는 건물변화 분류체계

2. 방법론

본 연구를 수행하기 위하여 데이터셋 구축, W-net 구현, 후처리 파이프라인 구현 과정을 거쳤다.

첫째, 데이터셋 구축을 위하여 먼저 서울시에서 촬영한 다시기 항공사진을 확보하였으며 구체적으로는 중구 (2018/2019), 용산구 (2013/2019), 마포구 (2013/2019), 강서구 (2013/2019), 종랑구 (2017/2019) 일대 항공사진을 확보하였다. 확보한 항공사진을 Agisoft Metashape에 입력하여 항공삼각측량을 수행하였으며[4], 이 때 상호 위치정합을 위하여 기준영상 기반 항공삼각측량을 수행하였다[5]. 이후 Dense matching, meshing, orthorectification 과정을 거쳐 지형지물의 기복변위가 제거된 진정사영상(true orthophoto, TOP)을 제작하였다. 제작한 정사영상은 QGIS상에서 판독하여 앞서 제시한 5가지 변화 유형을 폴리곤(Polygon) 형태로 표현하는 방식으로 라벨링을 수행하였다. 정사영상과 라벨링은 512 by 512 화소 크기를 갖는 타일로 분할하여 저장하였고, 분할할 때 동서/남북 방향으로 256 화소씩 중첩하도록 하였으며, 타일 생성 후 albumentations[6]를 이용해 무작위 뒤집기와 밝기 변화를 적용하여 타일의 개수를 4배 증강(augmentation)하였다.

둘째, 구축한 데이터셋을 학습시키기 위해 Siamese network 구조를 지닌 W-net을 구현하였다. W-net은 두 개의 Encoder와 한 개의 Decoder로 구성된다. 두 개의 Encoder는 서로 매개변수를 공유한다. 본 연구에서는 [3]에서 제시된 바와 같이 Decoder를 Deconvolution 레이어로 구성하였으며, 추가적으로 Decoder를 SegNet과 유사한 형태로 Upsampling 레이어와 Convolution 레이어로 구성한 후 성능을 비교해보았다.

셋째, 추론 결과를 후처리하는 파이프라인을 구현하였다. 실제 서비스 환경에서는 공간적 범위가 자치구 전체인 수십만 화소 이상의 크기를 가지는 정사영상을 다루어야 한다. 또한, 추론 결과를 도형(Polygon) 형태로 표현할 필요가 있으며 노이즈를 제거하여 정확도를 향상시킬 필요가 있다. 따라서 주어진 정사영상을 일정한 크기의 타일로 분할하고, 각 타일별로 추론을 수행하고, 타일별로 추론 결과를 후처리하고, 타일별 추론 결과를 다시 병합하는 과정이 필요하다. 본 연구에서는 후처리 과정으로 이진화, 폴리곤화, 배경객체 제거, 10㎡ 이하의 과소객체 제거, 단순화(Rotated Minimum Bounding Rectangle), 면적계산, 디졸브(Dissolve)를 제시한다.

3. 실험 및 결과

방법론에서 제시한 데이터셋 구축 방법을 거친 결과 아래 표와 같은 물량의 데이터셋을 구축할 수 있었으며, 구축한 데이터의 예시는 아래 그림과 같았다. 데이터셋은 변화 전, 변화 후 정사영상과 변화 영역에

대한 라벨링 영상으로 구성되어있다.

Table 1 구축 데이터셋 물량

Purpose of dataset	# of tiles
Train (Jung-gu, Yongsan-gu, Mapo-gu, Gangseo-gu)	174,578
Validation (Jung-gu, Yongsan-gu, Mapo-gu, Gangseo-gu)	43,644
Test(Jungnang-gu)	2,262




Fig. 3 변화탐지 데이터셋 예시

구축한 데이터를 Decoder가 Deconvolution으로 구성된 W-net과 Upsampling으로 구성된 W-net에 학습시켰다(각 모델을 W-net과 W-net-upsample로 명명한다). Early stopping 조건을 적용하고 학습을 시킨 결과 각각 19 에포크, 49 에포크 학습이 수행되었다. 그 결과 테스트 데이터셋에서 mIoU는 각각 73.2%, 73.5%를 기록하였다.

또한, 방법론에서 제시한 후처리 파이프라인을 적용한 결과 아래 그림과 같이 단순화된 탐지 결과를 획득할 수 있었다.



Fig. 4 변화탐지 결과
(2013년 정사영상, 2019년 정사영상,
변화탐지 추론 결과 및 후처리 결과)

모델의 성능을 보다 구체적으로 판단하기 위해 본 연구에서는 객체 단위 평가 방법을 제시한다. 객체 단위 평가 방법에서는 정답 객체와 탐지 객체간의 중복도가 25%가 넘으면 True Positive로, 그렇지 않으면 False Negative로, 정답 객체가 없는 곳에 탐지 결과가 위치하면, False Positive로 계산한다. 이를 토대로 완전성(Completeness)와 정확성(Correctness)을

계산하였다. 이러한 과정을 오픈소스 GIS 소프트웨어인 QGIS에서 구현하고 모델에 대한 평가를 수행하였다. 그 결과는 아래 표와 같았으며 완전성 측면에서는 큰 차이가 없었지만 정확성은 W-net-upsample이 소폭 높았다.

Table 2 학습 결과(완전성 및 정확성)

Model	Metric	Result(%)
W-net	Completeness	73.95
	Correctness	79.91
W-net-upsample	Completeness	72.25
	Correctness	81.54

4. 결론

본 연구에서는 서울시 항공사진을 대상으로 딥러닝 기술을 변화탐지를 수행하였다. 향후 본 연구 성과를 고도화하면 지도 갱신, 위반건축물 모니터링 등 다양한 시정 업무에서 실용적으로 활용 가능할 것으로 기대하며, 서울시와 지리공간적 특성이 상이한 타 지방자치단체를 대상으로도 실증해볼 예정이다.

ACKNOWLEDGEMENT

본 연구는 2022년도 국토교통부 디지털 국토정보 기술개발사업의 지원에 의해 수행되었습니다(과제번호 RS-2022-00142501).

참고 문헌

- [1] Hussain et al., "Change Detection from Remotely Sensed Images: From Pixel-based to Object-based Approaches" in *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 80, 2013.
- [2] Shi et al., "Change Detection Based on Artificial Intelligence: State-of-the-Art and Challenges" in *Remote Sensing*, vol. 12, p. 1688, 2020.
- [3] Hou et al., "From W-net to CDGAN: Bitemporal Change Detection via Deep Learning Techniques" in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58(3), pp. 1790-1802, 2020.
- [4] Agisoft Metashape, Retrieved from <http://www.agisoft.com/>
- [5] Kim et al., "Drone Image-Based Facility Inspection - Focusing on Automatic Process Using Reference Images" in *Journal of the Korean Society for Geospatial Information Science*, vol. 26(2), pp. 21-32, 2018
- [6] Buslaev et al., "Albumentations: fast and flexible image augmentations" in *ArXiv e-prints*, 1809.06839, 2018

딥러닝을 활용한 교육용 포디블록 교구의 쌓기구조 패턴 추출

임소영¹ 임지연¹ 양효숙² 김영신² 박정호² 서창준² 조광현² 유용균¹

한국원자력연구원¹, (주)포디랜드·포디수리과학창의연구소²

isy0124@kaeri.re.kr ygyu@kaeri.re.kr

Extracting Stacking Structure Pattern of Educative 4DBlock Material Utilizing Deep Learning

Soyoung Lim¹ Jiyeon Yim¹ Hyo-Sook Yang², Young Shin Kim², Jung-Ho Park²,

Chang Jun Seo², Kwang-Hyun Cho² Yonggyun Yu¹

Korea Atomic Energy Research Institute¹,

4D Land, inc., 4D Mathematical Science & Creativity Research Institute²

요 약

블록놀이는 공간 지각능력과 창의력 발달에 도움이 되는 놀이도구이며, 교육용 블록교구는 다양하게 구성 및 조적하게 되어있어 비구조적인 특징을 갖는다. 하지만 이러한 비구조적인 특성은 발달특성상 유아들에게는 목적 없는 놀이도구로 소진되기 쉽기 때문에 보다 창의적인 높은 수준의 블록놀이를 촉진하기 위해서 체계적인 쌓기 구조에 대한 사전지식을 지원해야한다. 본 연구에서는 이를 효율적으로 하기 위한 방법으로 딥러닝 기술 적용을 검토하였다. 10가지 유형의 쌓기 구조를 규정하고, 포디블록으로 여러 유형을 조합하여 사진 데이터를 구축하였다. 여러 유형으로 조합된 블록의 패턴을 분류하기 위하여 다중 레이블 분류를 하였으며, 딥러닝 모델로는 EfficientNet-B3을 사용하였다. 또한 모델의 설명력을 확인하고, 실제 문제에 사용하기 적합한 모델인지 검증하기 위하여 설명 가능한 인공지능 기술 중 하나인 GradCAM을 사용하고 예측 결과를 해석하였다.

Keywords: 딥러닝, 블록쌓기, 포디블록, 설명 가능한 인공지능

1. 서 론

블록놀이는 교육기관에서 전통적으로 자유놀이(free play)의 중요한 영역으로 자리매김해 왔다. 어린이가 블록을 수직, 수평으로 배치하고 다양한 방향과 공간에서 위치를 파악하고 구조화하는 과정에서 공간에 대한 지각력이 증진되며[1] 보다 복잡한 쌓기 구조물을 구성하면서 높은 수준의 물리적, 수학적 사고를 할 수 있게 된다[2]. 또한 어린이는 블록 놀이를 통해서 수학, 물리학, 엔지니어링, 디자인 등 융복합적(STEAM) 영역에서 다양한 활용의 방법을 탐색하고 정교화할 때보다 더 창의적인 산출물을 구현할 수 있다[3].

교육용 블록교구는 같은 크기의 하나의 단위를 한 가지 방법으로 사용하는 것이 아닌 다양하게 구성 및 조적하게 되어 있으므로 사용의 방법과 결과가 정해져 있지 않은 비구조적 특징을 갖는다[4]. 블록교구의 이러한 비구조적이며 개방적인 특성은 발달특성상 유아들에게는 목적 없는 놀이도구로 소진되기 쉽기

때문에 보다 자유로운 표현을 위해서는 일정부분 블록 쌓기 구조를 학습할 필요가 있으며 이러한 원리의 습득 여부에 따라 자유표상의 질적 수준에 차이가 나타날 수 있다. 따라서 창의적인 구조물의 표상 이전 단계로써 원리를 이해하도록 돕는 과정이 필요하고 이는 교사나 성인의 “의도적 교수”의 영역이다[5][6].

궁극적으로 보다 창의적인 높은 수준의 블록놀이를 촉진하기위해 우리는 어린이의 체계적인 쌓기 구조에 대한 사전지식을 지원해야 하며 이를 위해 블록 쌓기 구조의 유형을 탐색할 필요성이 있다. 나아가 현장에서 보다 용이하게 어린이의 쌓기 구조 데이터를 수집하고 이에 대한 반복적인 블록 쌓기 구조 패턴 인식 및 쌓기 구조의 패턴을 분류하기 위한 효율적이고 유용한 방법 및 해결책으로 시기술을 적용 가능성을 연구할 필요성이 제기된다. 이에 따라 본 연구는 딥러닝 기반 교육용 블록교구 쌓기 구조 패턴 분류 모형을 개발하기 위해 먼저 1)현장활용과 연구에 적합한 쌓기 놀이 블록인 포디블록(4DBlock)을 선정하고, 2)블록의 쌓기

및 구성의 기본이 되는 10가지 유형요소를 규정하였으며, 3)50개 이내로 제한한 블록으로 단위, 조합에 대한 실제 영상 사진 데이터를 구축하였다.


이상의 과정을 통해서 본 연구는 딥러닝을 통한 교육용 블록의 쌓기 패턴 구조를 추출 및 시모형의 블록 패턴 분류 가능성을 탐색하고자 한다. 또한 이러한 연구문제의 결과에 따라 어린이의 블록 쌓기 기본유형 이해에 따른 상호작용 교수 및 블록 쌓기 수준 평가 등 교수학습지원, 시모형의 고도화에 따른 블록놀이 평가를 개발, AI 자유블록 표현 및 미션 수행 등 활용의 기초자료로 제시하고자 한다.

2. 딥러닝을 이용한 블록 쌓기구조 패턴 추출

2.1. 데이터 설명

2.1.1. 포디블록(4DBlock)


포디블록은 기와색, 황토색 두 가지 색상으로 된 EVA.재질이며 특성상 가볍고 물에 뜨며 높이 쌓아도 구조가 유지되는 블록이다(그림 1 참조).



[그림 1] 교육용 블록 단위

2.1.2. 블록 패턴

블록의 패턴은 A(기본), B(계단) C(모아), D(틀어), E(지그재그), F(세워), G(교차), H(돌려), I(기댈), J(비스듬), 10개 유형으로 공통기준, 최소블록 수, 구조, 한계선 등을 통해 정의하였다(그림 2 참조).



[그림 2] 교육용 블록 단위

A(기본)는 블록이 상하로 겹친 구조로 상, 하 블록

90%이상 겹치는 형태를 말한다. B(계단)은 자립 가능한 2개의 블록으로 이루어진 넓은 계단 구조로 상, 하 블록 90%미만이 겹치며 상층의 블록이 이탈되지 않아야 한다. C(모아)는 상(1개), 중(2개), 하(1개), 3개의 층이 모두 한 방향으로 쌓아진 구조로 중단의 두 블록 사이 간격을 벌려 자립해야 한다. D(틀어)는 최소 4개의 블록을 가지고 1개의 블록이 또 다른 블록 위에 엇갈려 쌓아 올라가는 구조이며 +형태로부터 X자 모양까지 틀어져 있는 형태만 인정한다. E(지그재그)는 최소 4개의 블록으로 홀수, 짝수 층 블록의 방향과 수직위치가 동일하게 쌓는 구조이다. F(세워)는 최소 3개의 블록을 가지고 2개의 블록을 간격을 두고 세워 그 위로 1개의 블록으로 2개의 블록을 연결하는 구조이다. G(교차)는 3~4개의 블록을 가지고 나란히 놓인 2개의 블록 위로 방향이 교차되어 1개 또는 2개의 블록이 쌓여진 구조이며, 동일 층의 두 블록은 반드시 평행해야 하며, 두 블록의 벌어진 정도는 무관하다. H(돌려)는 최소 6개이상의 블록으로 평면에 다각형 모양으로 층층이 쌓은 형태이다. I(기댈)은 2개의 블록을 넓은 면으로 맞대어 세워진 구조이다. J(비스듬)은 최소 3개의 블록으로 한 개의 블록을 기준하여 2개의 블록이 반대 방향으로 기울어진 형태로 만든다.

2.1.3. 블록 쌓기 조합

블록 50개 이내를 사용하여 다양한 쌓기에 대한 학습 이미지 데이터와 테스트 이미지 데이터는 그림 2의 10개 패턴 유형의 1)단위, 2)2개~10개 유형의 조합으로 하며 시는 제시된 블록쌓기 이미지에 대해 10가지 패턴유형 유무를 판단, 유형 추출하는 것을 목적으로 한다(그림 3 참조).

2합	AB	AC	AD	AE	AF	AG	AH	AI	AJ
02_1									
T02_101									
T02_102									
	BC	BD	BE	BF	BG	BH	BI	BJ	
02_1									
T02_101									
T02_102									

[그림 3] 블록 쌓기 조합 예시: 2개 유형 조합

2.2. 다중 레이블 분류를 위한 딥러닝 모델 및 학습

다중 레이블 분류(Multi-Label Classification)란 여러

개의 정답 레이블이 존재하는 분류 문제이다[7]. 이미지 분류 문제를 예로 들면, 고양이와 강아지가 함께 있는 이미지의 정답 레이블은 [고양이, 강아지]이다. 본 연구에서는 블록이 쌓여있는 구조를 총 10개로 분류하였는데, 이 구조가 결합되어 블록이 쌓일 수 있다는 점을 고려하여 한 개의 블록 이미지에 대하여 여러 레이블을 가지고 있는 다중 레이블 분류를 하였다.

블록 구조 분류를 위하여 EfficientNet-B3 모델[8]을 사용하였다. EfficientNet 모델은 모델 사이즈가 작으며 성능은 좋은 모델로 알려져 있으며 최근 기본 모델로 자주 사용된다. 그리고 EfficientNet 저자는 층, 필터 개수, 이미지 해상도를 스케일링하여 최적의 조합을 찾아 B0~B7까지의 모델을 제안하였다. 본 연구에서는 EfficientNet-B3 모델을 사용하였으며, 이미지넷 데이터로 사전 학습된 모델을 파인 튜닝하는 방법으로 학습을 진행하였다. 이미지를 Center Crop한 뒤, 224*224 크기로 바꾸어 모델의 입력으로 사용하였다. 다중 레이블 분류는 단일 레이블의 경우와 다르게 마지막 레이어에서 softmax 함수 대신 sigmoid 함수를 사용하고, Cross entropy 로스 대신 Binary Cross entropy 로스를 사용한다. 본 연구에서 Optimizer로는 AdamW를 사용하였으며, Cosine annealing warm restarts를 사용하여 learning rate를 조절하였다. 또한 배치 사이즈는 128로 설정하였으며, 50 에포크를 학습시켰다.

2.3. GradCAM

GradCAM은 오류 역전파를 통해 최종 결과에 대한 미분값을 특성맵(feature map)과 결합하여 모델이 어떤 부분을 보고 결과값을 예측하였는지 그 중요도를 히트맵 형태로 표시한다.

일반적으로 GradCAM은 정답 클래스 한 개에 대하여 특정 합성곱 레이어의 특성맵이 갖는 가중치를 계산하여 정답 클래스를 예측하기 위하여 어떤 부분이 활성화되는지를 확인한다. 이를 다중 레이블 분류 문제에 적용하기 위하여 각 정답 레이블 각각에 대하여 활성화 맵 값을 구하고 각각 히트맵에 표현하였다[9].

3. 분류 성능 및 GradCAM 결과

3.1. 딥러닝 모델 성능

성능을 평가하는 지표로 정확도, 정밀도, 재현율, F1 점수를 사용하였다.

- 정확도(Accuracy): 전체 레이블 중 맞춘 레이블의 비율
- 정밀도(Precision): 모델이 예측한 레이블 중에서 실제로 맞은 것의 비율
- 재현율(Recall): 실제 레이블 중에서 모델이 맞춘

레이블의 비율

- F1 점수(F1 score): 정밀도와 재현율의 조화평균

평가 지표에 따른 클래스별 및 클래스 평균 성능은 표 1과 같다. 정확도는 0.84이며, F1 점수는 0.76이다. 클래스 비율은 트레인 데이터셋과 테스트 데이터셋 모두 비슷하게 구성되어 있다.


[표 1] 평가 지표 별 성능

	Acc	Precision	Recall	F1 score
A	0.75	0.71	0.39	0.50
B	0.64	0.47	0.71	0.56
C	0.80	0.78	0.55	0.65
D	0.94	0.91	0.91	0.91
E	0.91	0.79	0.95	0.86
F	0.94	0.97	0.83	0.90
G	0.68	0.50	0.59	0.54
H	0.96	0.95	0.91	0.93
I	0.93	0.91	0.85	0.88
J	0.90	0.80	0.90	0.85
Micro avg	0.84	0.78	0.76	0.76
Macro avg	0.84	0.76	0.76	0.76


3.2. GradCAM 결과

다음 그림 4와 그림 5는 예측된 레이블에 대하여 GradCAM을 적용한 결과이다.

그림 4의 경우에는 F, I 블록 구조 조합을 나타내고, 그림 5는 A, C, D, H 조합에 대한 예시이다. 두 예시 모두 모든 레이블을 바르게 예측했을 때의 GradCAM 결과이다. GradCAM 결과를 통하여, 각 레이블을 예측하는 데에 있어서 모델이 어떤 부분을 보고 예측하였는지 확인할 수 있다. 또한 각 GradCAM 결과의 왼쪽 상단에 있는 단일 구조 블록과 히트맵이 활성화 된 부분을 비교하면, 서로 일치하는 것을 알 수 있다. 즉, 우리가 제안한 모델은 다중 조합된 블록 구조의 패턴을 추출할 때 각 단일 구조의 특징을 파악하고 패턴을 추출한다고 말할 수 있다.



[그림 4] GradCAM 예시: F, I 조합



[그림 5] GradCAM 예시: A, C, D, H 조합

4. 결론

본 연구는 딥러닝 기반 교육용 교구 쌓기 패턴 구조를 추출하는 모형을 개발하여 블록 쌓기 유형이 조합된 이미지에 대해 10가지 패턴 유형요소의 유무를 판단하고 그룹을 지정하는지 그 가능성을 살펴보고자 하였다. 연구결과를 요약하면 다음과 같다.

사전 학습된 EfficientNet B3 모델을 파인 튜닝한 결과, 테스트 데이터셋에 대한 성능은 84%였으며, GradCAM을 활용하여 모델이 어떤 부분을 보고 해당 레이블을 정답으로 예측하였는지 살펴보았다. GradCAM의 결과를 통해, 모델이 단일 구조의 패턴을 올바르게 파악하고 분류하고 있음을 확인하였다.

딥러닝을 통한 교육용 블록의 쌓기 패턴 구조를 추출 및 시모형의 블록 패턴 분류 가능성을 탐색한 본 연구의 결과는 어린이의 블록 쌓기 기본유형 이해에 따른 상호작용 교수 및 블록 쌓기 수준 평가 등 교수학습지원, 시모형의 고도화에 따른 블록놀이 평가를 개발로 보다 확장될 수 있음을 시사한다.

ACKNOWLEDGMENT

본 연구 논문은 연구개발특구진흥재단 21년도 시특성화 기업 역량강화 사업(No.1711150114)과 한국원자력연구원 주요사업(KAERI-524450-22)의 지원으로 수행되었음.

참 고 문 헌

[1] 지성애, 조유진, & 신상아. “주제 중심 쌓기놀이

활동이 유아의 공간지각력과 언어능력, 자아존중감에 미치는 영향”. *유아교육학논집*, 23(5), 151-175. 2019.

[2] Trawick-Smith, J., Swaminathan, S., Baton, B., Danieluk, C., Marsh, S., & Szarwacki, M. “Block play and mathematics learning in preschool: The effects of building complexity, peer and teacher interactions in the block area, and replica play materials”. *Journal of Early Childhood Research*, 15(4), 433-448. 2017.

[3] Van Meeteren, B. D. “Building Structures With Young Children”. *Science and Children*, 52(4), 16. 2014.

[4] Pepler, D. J., & Ross, H. S. “The effects of play on convergent and divergent problem solving”. *Child Development*, 1202-1210. 1981.

[5] Cherrington, S., & McLaughlin, T. “Creating a rich curriculum through intentional teaching”. In *Institute for Early Childhood Studies Spring Research Seminar, Wellington, New Zealand*. 2017.

[6] Epstein, A. S. “The intentional teacher.” *Washington, DC: National Association for the Education of Young Children*. 2007.

[7] 김무성, 김남규. "다중 레이블 분류의 정확도 향상을 위한 스킵 연결 오토인코더 기반 레이블 임베딩 방법론." *지능정보연구* 27.3 (2021): 175-197.

[8] Tan, Mingxing, and Quoc Le. "Efficientnet: Rethinking model scaling for convolutional neural networks." *International conference on machine learning*. PMLR, 2019.

[9] Jiang, Hongyang, et al. "A multi-label deep learning model with interpretable Grad-CAM for diabetic retinopathy classification." *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. IEEE, 2020.

중국 K-12 인공지능 교육 플랫폼 기술 동향

이준기[†] · 김지윤[†] · 김귀훈^{††}

[†]한국교원대학교 컴퓨터교육과

^{††}한국교원대학교 인공지능융합교육전공

{goodteacher1, jykim, kimkh}@knue.ac.kr

K-12 Artificial Intelligence Education Platform's Technology Trends in China

Junki Lee[†] · Ji-Yun Kim[†] · Kwihoon Kim^{††}

[†]Dept. of Computer Education, Korea National University of Education

^{††}Dept. of Artificial Intelligence Convergence Education, Korea National University of Education

요 약

한 나라의 성장과 발전의 필요조건은 인재이다. 본 논문은 우리나라의 인공지능 국가 경쟁력 향상을 위한 인재 양성을 목적으로 국가와 산학연이 연계한 중국 K-12 인공지능 교육 플랫폼의 기술 동향을, 교육의 도구로서의 AI와 교육의 내용으로서의 AI를 기준으로 살펴본다. 그 결과로 첫째, 중국의 국가와 산학연 연계로 가능하게 된 세계적 기술력을 가진 인공지능 기업의 학생 교육 활동, 둘째, 탑 글로벌 인공지능 기업의 역량이 교육의 도구로 활용되어 학생들에게 맞춤형 개별화 교육 지원, 셋째, 일류 인공지능 기업의 차원 높은 콘텐츠가 플랫폼에 적용되어 학생들에게 차별화된 교육 경험 제공을 현 국내 교육의 상황에 비추어 보고, 진정한 우리나라의 인공지능 인재 육성을 위한 인공지능 교육에 요구되는 시사점을 도출하여 제안한다.

1. 서론

국가와 산학연은 각각 근본적으로 추구하는 목적이 다르다. 이로 인해 각 주체는 쉬이 반목을 일으킬 수도 있다. 그런데, 중국 K-12 인공지능 교육 플랫폼은 국가와 산학연의 유기적인 연계로 동작된다. 그 이유는 2018년 정부의 '고등교육 인공지능 혁신 행동계획'을 근거로 대학과 기업이 초중등학교의 인공지능 교육을 지원할 수 있는 길이 열린 것과, 각 주체가 동반 성장하기 위해서는 인공지능 인재 육성이 필요조건임을 깊이 공감하기 때문이다. 2019년 기준 중국의 AI 고급인력(박사 후 과정 이상)의 수는 우리나라의 약 6배이다[1]. 이 추세가 유지된다면 앞으로 중국과 우리나라의 격차는 더욱 크게 벌어질 것이다. 이에 본 논문에서는 우리나라 인공지능 발전을 위한 인재 양성 교육의 측면에서, 중국의 인공지능 산업을 이끄는 우수 기업들이 중국 내 인공지능 교육을 어떻게 지원하는가를 중심으로, 중국 K-12 인공지능 교육 플랫폼의 기술 동향을 살피고, 국내 플랫폼에 빚대어 우리나라 인공지능 교육에 요구되는 시사점을 도출하여 제시하고자 한다.

2. 이론적 배경

2.1 중국 K-12 인공지능 교육 관련 국가 정책

2017년 7월 8일 중국 국무원 명의로 발행된 '차세대 인공지능 발전계획'과 그 뒤를 이어 2018년 4월 2일 중국 정부가 발행한 '고등교육 인공지능 혁신 행동계획'에서는 국가 발전을 위한 인재의 중요성을 강조하고, '산학연 협력을 통한 인재양성 역량 강화'와 인공지능의 다층적 교육 체계 구축을 위한 '초중등학교 인공지능 교육 보급'이 명시되어 있다. 이는 초중등학교 인공지능 교육의 주체로 대학과 기업이 참여할 수 있는 길을 국가가 열어준 것이다[2].

2.2 인공지능 교육의 구분

교육 분야에서의 인공지능에 대한 접근은 '교육에서의 인공지능(AIED)', 'AI 기반 교육(AIBE)', 'AI(인공지능) 교육' 등 다양한 용어가 혼용되어 왔다. 본 논문은 인공지능을 구분하는데 대표적인 '교육의 도구로서의 AI'와 '교육의 내용으로서의 AI'를 기준으로 작성한다[3].

3. 중국 K-12 인공지능 교육 플랫폼

3.1 교육의 도구로서의 AI

3.1.1 텐센트 교육



그림 1 텐센트 교육

1998년 설립된 텐센트는 초기 SNS사업에서 출발하여 현재는 게임, 디지털미디어, 인터넷 금융, 첨단 산업 및 혁신 생태계를 아우르는 글로벌 IT기업이다[4].

텐센트 교육은 AI 기술과 데이터 분석 능력을 바탕으로 영어 듣기, 과학 실험, 체육, 미술 등 교과목의 특성을 살려 교수, 학습, 단계별 평가 등 다양한 장면을 담은 교육평가 솔루션인 텐센트 교육 AI 평가 솔루션을 제공하여 학생에게 맞춤형 개별화 교육을 지원한다[5].

3.1.2. iFLYTEK AI + 교육



그림 2 iFLYTEK AI + 교육

iFLYTEK는 1999년 설립된 자연어 처리 특화 기업이다 [4]. 중국 내 음성인식 시장 점유율은 약 70%로 압도적이고, 2만여 개가 넘는 가전제품 기업과 샤오미, 오포 등 모바일 기업도 iFLYTEK의 음성인식 기술을 활용하고 있다 [6]. 2021년 10월 상하이사범대학과 협력하여 AI교육 연구센터를 설립하고, AI+교육 분야 정책연구, 기술연구, 교육과목 개발, 초중등학교의 디지털화 교육 연구 분야에서 협력하고 있다[4].

빅데이터와 인공지능 기술을 이용하여 학습 분석, 맞춤형 학습 기반 추천 시스템, 인공지능 자연어 처리에 기반한 영어 듣기 말하기 쓰기 평가 스마트 테스트 등의 서비스를 제공한다.

3.2 교육의 내용으로서의 AI

3.2.1. kitten 블록 프로그래밍 언어




그림 3 kitten 블록 프로그래밍 언어

Kitten은 2020년 약 1억 9,800만 달러(약 2,500억원)의 투자를 유치한 중국 온라인 코딩 교육 플랫폼 Codemao에서 제공하는 온라인 기반 블록 프로그래밍 도구이다[7].

틱톡 등 모바일 기반 플랫폼의 유행으로 학생들에게 세로형 화면들이 친숙하게 된 것을 반영하듯, 학생들에게 편안한 모바일 화면 구성에서의 프로그래밍을 지원한다.

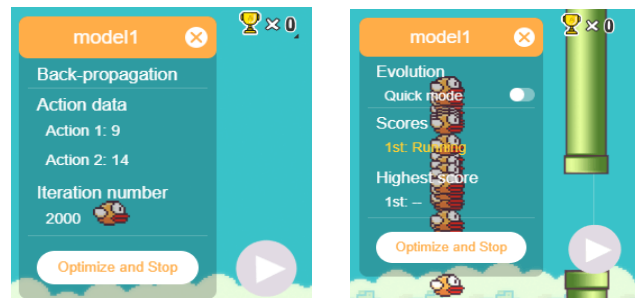


그림 4 게임 AI 지도학습 모델과 강화학습 모델 장면

일반적인 블록프로그래밍 도구에서 제공하는 인공지능 사전 학습 모델인 음성 인식, 음성 합성, 얼굴 인식, 감정 인식 등에 더하여, 독특한 게임 AI 확장 블록 모음을 제공한다. 이를 활용하면 타 프로그래머는 차별화된 게임 피케이션 기반 인공지능 게임 프로그래밍이 가능하다. 지도학습과 유전 알고리즘을 적용한 강화학습 인공지능 모델을 개발할 수 있다.

3.2.2. coding.qq 블록 프로그래밍 언어



그림 5 coding.qq 블록 프로그래밍 언어

Coding.qq는 중국 일류의 텐센트 기업이 자국에서만 서비스하는 인공지능 블록 프로그래밍 도구이다. 인공지능 관련 텐센트의 압도적 기술력으로 구글의 텐서플로를 자체 프로그램에 블록 형태로 내장하고 있다.

4. 결론

본 논문은 우리나라 인공지능 국가 경쟁력 향상을 위한 인재 양성을 목적으로 국가와 산학연이 연계한 중국 K-12 인공지능 교육 플랫폼의 기술 동향을, 교육의 도구로서의 AI와 교육의 내용으로서의 AI를 기준으로 살핀다. 이를 통해 우리나라 인공지능 교육에 요구되는 시사점을 도출하여 제시한다. 논문의 결론은 다음과 같다. 첫째, 중국은 국가와 산학연의 유기적인 연계를 통해 세계적 인공지능 기술을 갖춘 기업이 학생 교육 활동을 한다. 둘째, 탑 글로벌 인공지능 기업의 역량이 교육의 도구로 활용되어 학생들에게 맞춤형 개별화 교육을 지원한다. 셋째, 일류 인공지능 기업의 차원 높은 콘텐츠를 교육 플랫폼에 적용하여 학생들에게 차별화된 교육 경험을 제공한다.

이상의 결론을 바탕으로 다음과 같이 제안한다. 첫째, 현재 국내의 네이버의 지원을 받는 엔트리와, KT의 AI codiny 플랫폼처럼 우수 탁월한 인공지능 기업이 그들의 기술력을 담은 K-12 인공지능 교육 플랫폼을 제작하여 우리나라 인공지능 인재 양성에 적극 참여할 수 있도록 중국과 같이 국가와 산학연의 유기적인 연계가 필요하다 [8][9]. 둘째, 국내에서 서비스되는 EBS 콘텐츠 추천 EBS 단추와 AI핑퐁, 수학톡톡 플랫폼처럼 학생 한 명 한 명의 다름을 소중히 하고 각 학생의 속도에 맞는 따뜻한 학생 맞춤형 개별화 교육이 가능하도록 도구로서의 AI가 교육

전반에 확대되어야 한다. 셋째, 교육의 내용으로서의 AI는 인공지능 기술의 급격한 발전과 주변 환경의 변화가 즉각적으로 반영할 수 있는 최신성의 적용을 통해 삶과 배움이 괴리되지 않도록 돕고자 하는 것이며, 이를 위해서는 탑 인공지능 개발 능력을 가진 기업의 교육 진출이 필요하다.

국가와 산학연의 유기적인 연계로 최고의 기업들이 AI를 교육의 도구로, 그리고 내용으로 하여 K-12 인공지능 교육 플랫폼을 개발함으로써 우리나라가 경쟁력이 있는 인공지능 인재로 가득하고, 인공지능으로 완성되는 디지털 세상을 만들 수 있기를 고대한다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1G1A1093306).

5. 참고문헌

- [1] 임형규 외, "AI융합인력 양성을 위한 전략산업 분야 분석," 정보통신산업진흥원, 제18호, p3, 2020
- [2] 손민정 외, "중국의 인공지능(AI) 교육 동향 탐색," 대외경제정책연구원 & 한국교육과정평가원, 2020-91-03, p44, 2020
- [3] 홍선주 외, "학교 교육에서의 인공지능(AI) 활용 방안 탐색," 한국교육과정평가원, 16, 2021-5-16, p4, 2021
- [4] 백서인 외, "2021년 중국(중화권) 첨단 기술 모니터링 및 DB 구축 사업 스마트 에듀-디지털 헬스케어," 본권: 정책연구, 2021-32-01, p81, p85, 2021
- [5] 교육정책네트워크 정보센터 국가별 교육동향 사이트, 2022. 06.10. 검색 <https://edpolicy.kedi.re.kr/frt/boardView.do?strCurMenuId=10092&nTbBoardArticleSeq=832591>
- [6] 대외경제정책연구원 중국전문가포럼 사이트, 2020.06.10 검색 https://csf.kiep.go.kr/issueInfoView.es?article_id=43935&mid=a20200000000&board_id=20
- [7] Kitten, <https://kitten.code.game/>
- [8] Entry, <https://playentry.org/>
- [9] AI Codiny, <https://aicodiny.com/>

그래프 신경망을 이용한 비정형 격자 기반 위상최적화 가속화 기술

주영환¹⁾ 정영석²⁾ 유용균³⁾

1) 한국에너지기술연구원, 2) 현대자동차, 3) 한국원자력연구원
yhjoo@kier.re.kr, ys.jung@hyundai.com, ygyu@kaeri.re.kr

Acceleration of topology optimization for unstructured mesh using graph neural networks

Younghwan Joo¹⁾, Youngsuk Jung²⁾, Yonggyun Yu³⁾

1) Korea Institute of Energy Research, 2) Hyundai motor group, 3) Korea Atomic Energy Research
Institute

요 약

위상최적화는 기계적 구조를 높은 자유도로 설계할 수 있는 기술로서 인공지능 및 3D 프린팅 기술과의 조합을 통해 설계부터 제조까지 다양한 방면에서 많은 잠재성을 갖는다. 위상최적화의 실용화를 위해서는 3D 해석과 같이 많은 계산 부하를 요구하는 조건에서도 신속한 설계 결과 도출이 요구된다. 따라서 인공 신경망을 통해 위상최적화를 가속화하는 기술이 개발되고 있다. 본 연구에서는 비정형 격자를 갖는 해석 도메인에 대해서 그래프 신경망을 이용하여 위상최적화를 가속화하고자 한다. 비정형 삼각 요소들 사이의 연결성을 그래프를 통해서 표현하고 이를 바탕으로 국부적인 형태와 전체적인 형태를 학습하고 예측하는 기능을 구현한다. 제안된 그래프 신경망을 이용하여 경계조건의 정보만을 이용해서 최적 형태를 예측하고 이로부터 추가적인 위상최적화를 수행함으로써 위상최적화의 반복 계산을 단축하였다.

1. 서 론

위상최적화[1]는 기계적 구조의 최적 형상을 높은 자유도로 설계하는 기법이다. 주어진 해석 영역을 많은 수의 요소로 나누고 각 요소에 개별적으로 밀도를 정의하여 요소들의 밀도 값에 의해 전체적인 구조물의 형태가 결정되도록 한다. 각 요소의 밀도 값은 설계 변수가 되므로 다수의 설계 변수를 동시에 최적화하기 위해 민감도 기반의 최적화 기법이 사용된다. 위상최적화의 결과물을 얻기 위해서는 하나의 해석 조건에 대해서 유한요소해석을 통한 변위 정보와 민감도를 계산하는 과정이 반복된다. 이러한 반복 계산은 계산 부하를 증가시켜 위상최적화 기술을 실제로 적용하는데 걸림돌이 된다.

따라서 위상최적화의 계산 부하를 줄이기 위한 연구들이 수행되었다. 특히 최근에는 인공 신경망을 이용하여 반복 계산을 단축시키는 연구가 많이 수행되었다[2-5]. Yu [6] 등은 위상최적화의 경계 조건을 행렬로 정의하여 이로부터 최적화 결과를 직접 예측하는 autoencoder 방식의 가속화 모델을 제안하였다.

그러나 기존 연구는 대부분 잘 정돈된 사각형 요소를 갖는 정형 격자에서 수행되었다. 복잡한 형상의 설계가 요구되는 실제적인 기계 설계 문제들은 대체로 비정형

격자 기반의 해석 도메인을 갖는 경우가 많으므로 정형 격자 기반의 위상최적화 가속화 기술의 적용에는 한계가 있다. 본 연구에서는 이러한 문제를 해결하기 위해 비정형 격자를 갖는 해석 도메인에 대해서 위상최적화를 가속화하고자 하였다. 비정형 격자에서의 요소들 간의 상호 관계를 고려하기 위해 그래프 신경망을 이용하였다. 위상최적화를 가속화하기 위해서는 각 절점에서의 밀도 정보의 변화를 학습하는 것뿐만 아니라 인접한 절점 그리고 나아가 전체적인 형상 변화를 학습해야 한다. 이러한 특성을 구현하기 위해 edge convolution을 포함하는 dynamic graph convolution neural network를 이용하였다. 가속화 모델을 학습시킨 이후에는 이들의 가속 성능을 평가하기 위해 학습되지 않은 100회의 위상최적화 케이스에 대해 가속화 모델을 통해 초기 형상을 예측한 경우와 그렇지 않은 경우에 대한 가속화 여부를 확인하였다.

2. 해석 방법

그림 1은 위상최적화의 경계조건으로부터 최적 형상을 예측하는 방법의 개념을 나타낸다. 위상최적화의 경계조건은 크게 하중 조건과 고정 경계 조건으로 구분된다. 하중 조건의 경우 하중이 가해지는 절점에서

하중의 방향과 크기가 숫자로 표시된다. 본 연구에서는 두 개의 하중 조건이 고정 경계면 외의 면에서 임의의 위치에 임의의 방향으로 가해지도록 정의하였다. 고정경계 조건은 고정된 절점에 대해서 1이 되도록 정의하였다. 이러한 절점 기반의 경계조건 표현은 최소 행렬의 특성을 갖는다. 전체 절점에서는 대부분 값이 0이며 한정된 일부 절점에 대해서만 유한한 값이 주어진다. 따라서 이러한 희박한 정보로부터 도메인 전체의 밀도 분포를 예측하기 위해서는 그림 1과 같이 encoder 특성을 갖는 신경망을 이용하여 정보를 압축하고 이로부터 다시 전체 필드의 값을 예측해야 한다.




그림 1 초기 형상 예측 개념도

본 연구에 사용된 Dynamic graph convolution neural network (DGCNN)의 구조는 그림 2와 같다. Edge convolution은 주어진 feature 정보를 이용하여 의미적으로 가장 인접한 K개의 node를 그래프로 연결시키는 knn_graph 기능을 포함하고 있다. 여기서 의미적으로 인접하다는 의미는 가장 단순하게는 공간적으로 가까운 특성을 의미하며 feature의 정의에 따라서 경계조건을 포함하는지 여부 등이 고려될 수 있다. Edge convolution이 수행된 이후 전체 field는 fully connected layer를 거치며 압축되어 다시 압축 전의 field에 덧붙여진다. 이러한 과정을 통해 전체적인 정보를 다시 개별 요소에 반영한다. 그래프 데이터에 가장 널리 사용되는 Graph convolution neural network를 이와 같은 문제에 적용하는 경우 edge의 특성을 학습하지 못해 경계 조건으로부터 최적 형상을 예측하지 못하는 것을 확인하였다.




그림 2 Dynamic graph convolution neural network

3. 결 과

DGCNN의 학습을 위해 정사각형의 해석 도메인에 대해서 4면 가운데 한 면을 임의로 고정 경계조건으로 설정하고 나머지 3개 면에 2개의 서로 다른 임의의 방향을 갖는 하중이 가해지도록 설정하여 총 5000개의 위상최적화 케이스를 생성하였다. 각 케이스에는 경계조건 뿐 아니라 필터 반경 및 부피율을 임의의 값으로 갖도록 하였다. 그림 3은 학습 진행에 따른

MAE loss의 변화를 보여준다. 총 235 epochs 진행 이후 training loss는 0.034, test loss는 0.037이 얻어졌다.

그림 4은 5000개의 위상최적화 데이터를 이용하여 학습시킨 DGCNN의 예측 결과를 원래의 위상최적화 예측 결과와 비교한 것이다. 위상최적화와 유사한 구조가 예측되는 것을 확인할 수 있다. 다만, 형태가 전반적으로 흐릿하게 보이면서 상세한 형태들은 뭉개지는 특징들이 확인된다. 이는 부피율이나 필터 크기와 같이 상세한 형상에 영향을 끼치는 설계 변수들과 그래프의 연결성을 결정하는 K 값 등에 의해 발생된 특징으로 보인다. 또한 그래프 신경망의 특성상 layer 수가 증가함에 따라 정보의 경계가 모호해지는 특성이 나타났을 가능성도 있다.




그림 3 Epoch에 따른 training loss (녹색)과 test loss (적색)




그림 4 DGCNN 네트워크를 통한 예측 형상과 위상최적화 형상 비교

그림 5는 DGCNN을 이용하여 초기 형상을 예측하여 가속화를 수행하는 경우와 그렇지 않을 경우의 위상최적화 반복계산 수의 변화를 살펴본 결과이다. 가속화를 적용한 경우 100개의 케이스에 대해서 평균적으로 계산 속도가 34% 향상된 것을 확인할 수 있다.




그림 5 가속화 여부에 따른 반복계산 수 분포

4. 결론

본 연구에서는 그래프 신경망을 이용하여 비정형 격자 기반에서의 위상최적화를 가속화하는 방법을

제안하였다. 정형 격자에서 사용되는 convolutional neural network를 대체하기 위해 경계조건 데이터로부터 의미적 유사성을 기반으로 layer마다 그래프를 새롭게 정의하는 신경망 구조를 활용하였다. 그래프 데이터의 node feature 뿐 아니라 인접한 node 사이의 edge의 특성을 고려하는 edge convolution을 적용하여 경계조건 정보만으로도 기존 위상최적화와 유사한 최적 형상을 예측하였다. 또한 예측된 형상을 초기 조건으로 활용하여 위상최적화의 계산 속도를 향상시킬 수 있음을 확인하였다. 이러한 비정형 격자 기반의 방법론은 3D 격자에 확장이 용이하므로 향후 3D 비정형 격자 기반의 위상최적화 가속화에 응용하고자 한다.

ACKNOWLEDGMENT

본 연구는 한국에너지기술연구원 기본사업 (C2-2423), 한국원자력연구원 주요사업 (KAERI-524450-22, 하나로 및 연구시설 운영 지능화 플랫폼 구축) 의 지원을 받아 수행되었음.

참고 문헌

- [1] M.P. Bendsoe, O. Sigmund. Topology optimization: theory, methods, and applications. Springer Science & Business Media, 2013.
- [2] A. Chandrasekhar, K. Suresh. TOuNN: Topology optimization using neural networks. Struct Multidiscip Optim. 63, 1135-49, 2021.
- [3] E. Ulu, R. Zhang, L.B. Kara. A data-driven investigation and estimation of optimal topologies under variable loading configurations. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization. 4, 61-72, 2016.
- [4] K. Liu, A. Tovar, E. Nutwell, D. Detwiler. Towards nonlinear multimaterial topology optimization using unsupervised machine learning and metamodel-based optimization. ASME 2015 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference. American Society of Mechanical Engineers Digital Collection, 2015.
- [5] I. Sosnovik, I. Oseledets. Neural networks for topology optimization. Russ J Numer Anal Math Model. 34, 215-23, 2019.
- [6] Y. Yu, T. Hur, J. Jung, I.G. Jang. Deep learning for determining a near-optimal topological design without any iteration. Struct Multidiscip Optim. 59, 787-99, 2019.

조기 당뇨 진단을 위한 딥러닝 모델의 실용성 검증

김윤겸¹, 한승희¹, 이우석², 송태근¹

¹공주대학교 데이터정보물리학과

²퍼스트바이오테라퓨틱스

tsong@kongju.ac.kr

Verification of the practicality of a deep learning model for diagnosis of the early-stage diabetes

Yun Gyeom Kim¹, Seung Hee Han¹, Woo Seok Lee², Taegeun Song^{1,*}

¹ Department of Data Information and Physics, Kongju National University

²1st Biotherapeutics, Inc.

요 약

본 논문에서는 지난해 제안된 실시간 혈당 추적을 통한 조기 당뇨 진단 딥러닝 모델[1]을 기반으로 실질적인 사용을 위해 고려할 만한 요소들을 확인함으로써 해당 모델의 실용성을 검증하였다. 데이터의 부재로 인하여 기존에 사용하던 생물물리학적 혈당 항상성 모델에서 얻은 실시간 혈당 데이터를 이용하였다. 본 논문에서 새롭게 고려한 질문은 다음과 같다: 1) 측정하는데 피할 수 없는 노이즈가 어느정도 영향을 주는가, 2) 시간분해능이 성능에 미치는 영향은 어떠한가, 그리고 3) 인슐린 저항성을 라벨로 분류하는 기법에서 인슐린 저항성을 예측하는 기법으로의 전이가 가능한가. 이 논문을 통하여 제안된 조기 당뇨 진단 모델이 조금 더 유용하게 활용될 수 있기를 기대한다.

1. 서 론

당뇨병은 명확한 치료법이 존재하지 않는 대표적인 만성 질환이다. 지난해 국제당뇨연맹(international Diabetes Federation)에서 발간된 자료에 따르면, 전세계 성인(20~79세) 인구 중 약 5억 3천 7백만 명이 당뇨로 고통을 받고 있으며 이는 세계인의 약 10.5 %에 해당한다 [2]. 나아가 치료법이 존재하지 않기 때문에 진단 후 생활 습관 관리를 통해 치명적인 합병증을 예방하는 것이 최선이다. 따라서 당뇨병을 조기 진단하는 것은 매우 중요한 도전 과제이다.

현재 당뇨병을 진단하는 대다수의 인공지능 방법론은 위험인자들로 이루어진 특성 벡터공간에서 당뇨인지 정상인지 판별하는 알고리즘을 기반으로 한다 [3,4,5]. 한편, 실시간 혈당 추적을 이용하여 조기 당뇨를 진단하는 알고리즘은 상대적으로 미진하다 할 수 있다 [1,6]. 이러한 시도가 아직 많이 이루어지지 않은 이유는 무엇보다 연속 혈당 센서(continuous glucose monitoring sensor; CGM 센서)의 기술적 요인에 의한 데이터의 부재 때문이라 할 수 있다.

CGM 센서는 인공 체장 기술의 한 요소로서 다양한 타입과 종류가 존재한다. 하지만, 현존하는 연속 혈당 센서들의 시간 분해능은 5~10분으로 설계된다 [7,8]. 이는 호르몬을 방출하는 내분비 세포의 호르몬 방출 주기와 비슷한 시간 척도와 비슷하는데, 그 이유는 혈당 측정 센서 중 선호되는 타입은 초음파 센서로서, 실제 혈관 안의 혈당량을 재는 것이 아닌 체내에 흡수된 피하지방의 혈당량을 측정하기 때문이다.

이로 인한 실제 혈당과 측정 혈당의 차이를 줄이기 위해 CGM 센서의 시간 분해능을 5~10분 사이로 설계하게 된다. 혈당은 두가지 반대 작용을 일으키는 호르몬, 혈당을 올리는 글루카곤과 혈당을 내리는 인슐린에 의해 조절된다. 이 두가지 호르몬은 약 5~8분가량의 주기를 갖고 체장의 내분비 기관, 랑게르한스섬에서 펄스 형태로 방출된다 [9]. 전체 당뇨병 환자의 90 % 이상 차지하는 제 2형 당뇨의 경우, 방출 되는 호르몬 중 '인슐린 저항'이 증가하는 것으로 발병한다. 따라서 패턴의 인식에 특화된 딥러닝을 활용하여 실시간 혈당량의 변화로 인슐린 저항성을 알아낼 수 있다는 가능성을 보여준 선행 연구[1]를 바탕으로 실질적인 사용에서 고려되어야 할 요소들을 본 논문에서 다루었다.

본 논문은 2장에서 데이터를 생성한 혈당 항상성 모델에 대하여 간략히 설명하고, 3장에서 실용적 관점에서 다루는 요소들을 기술할 것이며, 끝으로 4장에서 결론을 도출 한다.

2. 혈당의 항상성 모델

인슐린에 대한 저항성이 증가할 때, 혈당의 실시간 반응을 관찰하기 위해선 호르몬이 방출되는 5분보다 짧은 시간 안에 혈당 시계열의 위상 변화를 알아내야 한다. CGM 센서로 불가능한 측정 영역을 다음과 같은 생물물리학적 체장의 내분비 모델을 활용하여 합성 데이터를 생성하였다 [1,10].

$$\frac{dG}{dt} = G_0 H_\alpha - \delta_{IR} G H_\beta \quad (1)$$

여기서, H_{α}, H_{β} 는 방출된 글루카곤과 인슐린의 양을 나타내며, G_0 와 G 는 평형상태와 현재 시간의 혈당 레벨을 나타낸다. 인슐린 저항성은 δ_{IR} 로 나타내며 $[0,1]$ 사이의 값으로 생산된 인슐린의 작용하는 비율로 설정하였다.

호르몬의 총량은 체장의 생물물리학적 모델[10]을 통해 구하였으며, 모델은 혈당-인슐린 동반흐름(entrainment) 현상을 정성적으로 잘 기술한 바 있다[11,12].

3. 실용적 관점으로 접근

CGM 센서를 통해 혈당데이터를 얻는 것을 감안하여 두가지 사항을 고려하였다. 먼저 측정에서 불가피한 노이즈가 발생하는 경우, 그리고 센서의 시간 분해능과 비슷한 영역에서 성능이 어떻게 나올 것인가 하는 것이다. 나아가, 측정하기에 어려운 인슐린 저항을 다섯 개 라벨, $\delta_{IR} \in [0, 0.1, 0.2, 0.3, 0.4]$, 로 분류하는 것이 아닌 인슐린 저항 자체를 예측하는 방법으로 변환이 가능한가 검증하였다. 훈련 데이터셋은 각 라벨당 2,000개씩 총 10,000개의 혈당 시계열을 생성하고, 테스트 데이터 셋으로 200씩 총 1,000개의 시계열에 노이즈를 추가하였다. δ_{IR} 을 분류하는 모델은 90 % 정도의 정확도를 보였다.

3.1 노이즈 영향

측정에서 야기되는 노이즈를 모사하기 위해 식 (1)을 통해 얻은 혈당 시계열 데이터, $G(t)$ 에 백색 노이즈(Gaussian white noise)를 더한 새로운 시계열을 인풋 데이터로 사용하였다:

$$G_{\eta}(t) = G(t) + \eta \zeta(t),$$

여기서, $\langle \zeta \rangle_t = 0$, 이며 $\langle \zeta(t)\zeta(t') \rangle = \delta(t - t')$ 을 만족하는 정규분포 함수이며, python numpy 패키지에서 추출하였다.

기준이라 할 수 있는 노이즈가 없는 $G_0(t)$ 에서 적용한 딥러닝 모델 구조는 10개 층으로 MLP로 구성하고, 은닉층의 활성화함수는 ReLU, 출력층은 softmax 함수를 사용했으며, Adam optimizer를 사용하여 훈련하였다

3.2 시간 분해능이 성능에 미치는 영향

각 시계열 데이터는 500개의 데이터 포인트를 갖고 있다. 우리의 전산모사에서 각 시계열 안에 평균 5개의 호르몬 주기를 포함하도록 모델 파라미터를 설정하였기에 시간으로 환산하면 대략 25분 가까이 된다. 즉, 생성한 데이터의 시간 분해능은 0.05분(3초)정도로 환산되는데 CGM 센서의 분해능으로 보면 각 시계열은 5 개의 데이터 포인트로 생각할 수 있다. 따라서 500개의 데이터 포인트를 샘플링하여 5개가 될 때까지 인풋데이터를 변화시켜가며 정확도를 구하였다.

먼저 섹션 3.1, 그리고 3.2의 결과를 그림 1에 나타내었다. 그림 1 (A)는 각 라벨에 대한 시계열 데이터를 다른 색으로 표시하였다: $\delta_{IR} = 0$ (검정), 0.1 (빨강), 0.2 (파랑), 0.3 (초록), 0.4 (보라). 맨눈으로 보기엔 차이가 나지 않아 보인다. 그림 1 (B)에서는 3.1에서 소개한 노이즈의 효과를 나타내기 위해 $G_{\eta}(t)$ 에서 노이즈가 없는 신호($\eta = 0$, 검정)와 노이즈가 인가된 신호($\eta = 0.2$, 빨강)를 비교하였다. 그림 1 (C)는 시간 분해능을

고려하기 위해 가한 샘플링이 $G(t)$ 를 얼마나 변형 시켰는지 나타내는 그림이다. 그림 1 (D)는 앞선 결과들을 요약해서 보여주는 히트맵이며, x축은 샘플링 후 데이터 포인트의 개수 N , y축은 노이즈 크기 η , 그리고 칼라코드는 MLP의 정확도이다. 그림 1 (D)에서 보듯이, 본 연구에서 $\eta = 0.2$ 근방까지, 그리고 시간 분해능은 약 1분 정도 영역에서 80 % 부근의 정확도를 확인하였다.

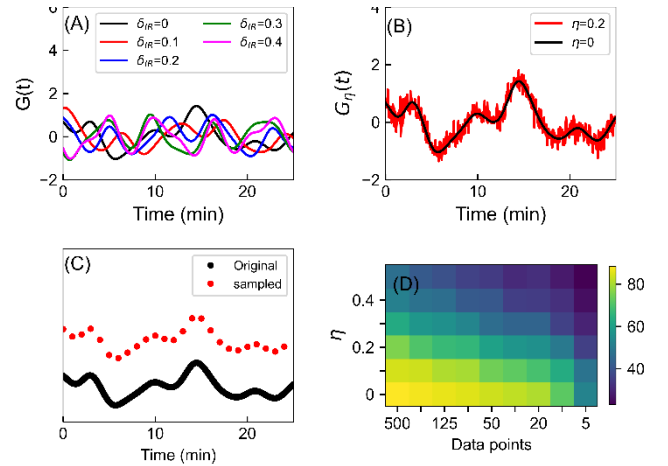


그림 1 (A) 라벨 δ_{IR} 에 따른 $G(t)$ 이다. 여기서, 시간은 분으로 환산하였으며, 선 색으로 라벨을 구별하였다. (B) 두가지 노이즈 크기에 대한 $G_{\eta}(t)$ 이다. (C) 시간 분해능이 증가했을 때 인풋 데이터의 변화 정도를 보여준다. 각 플롯의 범례는 각 그래프에서 적용한 조건을 나타낸다. (D) 시간 분해능과 노이즈 크기에 따른 정확도를 히트맵으로 표현하였다.

3.3 인슐린 저항성 예측모델의 가능성

앞서 언급하였듯, 인슐린 저항성을 측정하는 것은 매우 어렵다. 따라서 앞선 분류기 모델에서 회귀 모델로 인슐린 저항성을 예측하는 것이 가능한지 본 논문에서 검증하였다. 식 (1)에서 $G(t)$ 를 얻기 위해 체장의 내분비 시스템 모델과 연계하여 총 601개의 연립 일계 미분방정식을 수치적으로 풀었다. 전체 모델에서 28 개의 독립적인 모델 매개변수 중 하나, δ_{IR} 의 미묘한 변화를 인식하는 것이 가능하다면, 시계열로부터 δ_{IR} 자체를 예측하는 것이 가능한지 검증하였다. 시계열데이터를 학습할 때 널리 쓰이는 LSTM을 10 층으로 구성하고, δ_{IR} 의 값 자체를 예측하도록 tanh와 sigmoid 함수를 활성화함수로 택하고, 평균제곱오차(MSE)를 손실함수로 적용하였다. Adam optimizer를 사용하여 모델을 최적화하였으며 예측의 정확도를 평가하기 위해 평균 퍼센트 에러($\Delta = \frac{1}{M} \sum_{i=1}^M \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100$)를 고려하였다. 여기서, M 은 테스트 데이터의 개수 1,000개이며 y_i 는 모델의 예측 값, \hat{y} 는 정답이다. 10번의 반복 계산을 통해 노이즈가 없는 경우 약 $\Delta = 2.35 \pm 0.1$ % 정도, 노이즈가 매우 강할 때($\eta = 0.5$)에도 $\Delta = 5.84 \pm 0.21$ % 정도의 예측도를 보여 δ_{IR} 자체를 예측하는 것이 충분히 가능하다는 것을 검증하였다.

4. 결론

본 논문에서 우리는 조기 당뇨 진단 모델의 실용적인 사용을 위해 선행연구[1]에서 확장하여 혈당 시계열 데이터를 얻기 위해 피할 수 없는 측정 노이즈와 현재 활발히 연구되는 CGM 센서의 시간 분해능을 고려하였다. 그 결과로서 비교적 단순한 MLP구조임에도 불구하고 노이즈 첨가에 강건함을 보였으며, 해당 모델을 적용하기 위해선 1분가량의 시간 분해능이 필요할 것으로 예상됨을 확인하였다. 또 나아가 분류 모델에서 회귀 모델로 접근하였을 때, 5 % 이내의 정교한 인슐린 저항성을 예측한다는 결과를 얻었다.

향후 후속연구로는, 분류 모델의 학습법을 지도학습에서 반지도학습(semi-supervised learning), 음식물을 섭취하거나 운동과 같은 혈당의 외부 자극에 대한 반응을 고려한 모델 등 여러가지 방향이 존재한다.

하지만, 가장 커다란 장벽은 모델에서 생성한 합성 데이터가 아닌 실생활에서 얻은 임상 데이터를 확보해야 한다는 점이 될 것이다. 실제 데이터로 적용하기까지 많은 노력이 필요하나 나날이 발전해가는 인공지능 학습 방법론들, 전이학습(transfer learning), 혹은 transformer 등 최신 기술과 접목하여, 본 논문에서 시도한 인공지능 모델을 통해 가장 흔한 만성질환인 당뇨병을 조기진단 함으로서 유용하게 쓰이기를 기대한다.

ACKNOWLEDGMENT

본 연구 논문은 2022년 공주대학교 학술연구 지원사업의 연구지원에 의하여 연구되었음.

5. 참고 문헌

[1] W.S. Lee, J. Jo, and T. Song, Machine learning for the diagnosis of early-stage diabetes using temporal glucose profiles. *J. Korean Phys. Soc.* 78, 373–378 (2021).

[2] International Diabetes Federation. *IDF Diabetes Atlas*, 10th edn. Brussels, Belgium: International Diabetes Federation, 2021.

[3] I. Kavakiotis, et. al. *Machine Learning and Data Mining Methods in Diabetes Research*. *Comput. Struct. Biotechnol* (2017).

[4] A. Nomura, M. Noguchi, M. Kometani, et al. *Artificial Intelligence in Current Diabetes Management and Prediction*. *Curr Diab Rep* 21, 61 (2021).

[5] Y. Liu, *Artificial Intelligence-Based Neural Network for the Diagnosis of Diabetes: Model Development* *JMIR Med Inform* 8(5):e18682 (2020).

[6] H.N. Mhaskar, S.V. Pereverzyev and M.D. van der Walt, *A Deep Learning Approach to Diabetic Blood Glucose Prediction*. *Front. Appl. Math. Stat.* 3:14 (2017).

[7] Cobelli, Claudio et al. "Artificial pancreas: past, present, future." *Diabetes* vol. 60, 11:2672–82 (2011).

[8] D.C. Klonoff, D. Ahn, and A. Drincic, *Continuous glucose*

monitoring: A review of the technology and clinical use, *Diabetes Res. Clin. Pract.*, 133, 178–192 (2017).

[9] G. Brabant, K. Plank, and C. Schofl, *Pulsatile patterns in hormone secretion*, *Trends. Endocrinol. Metab.* 3, 189 (1992)

[10] D.H. Park, T. Song, D.-T. Hoang, J. Xu, and J. Jo, *A local counter-regulatory motif modulates the global phase of hormonal oscillations*, *Sci. Rep.* 7 (1), 1–8 (2017)

[11] B. Lee, T. Song, K. Lee, J. Kim, P.O. Berggren, S.H. Ryu, and J. Jo, *Insulin modulates the frequency of Ca²⁺ oscillations in mouse pancreatic islets*, *PLoS ONE*, 12 (8), e0183569 (2017)

[12] B. Lee, T. Song, K. Lee, J. Kim, S. Han, P.O. Berggren, S.H. Ryu, and J. Jo, *Phase modulation of insulin pulses enhances glucose regulation and enables inter-islet synchronization*, *PLoS ONE*, 12 (2), e0172901 (2017)

딥러닝을 활용한 아동그림 유사유형 검출 모델 기술

김민종¹⁾, 이성옥²⁾, 유용균^{1,3)}

1) 한국원자력연구원

2) ㈜티엔에프에이아이

3) 교신저자(ygyu@kaeri.re.kr)

Child picture similarity detection model technology using deep learning

Minjong Kim¹⁾, Seongoak Lee²⁾, and Yonggyun Yu¹⁾

1) Korea Atomic Energy Research Institute

2) TnF.AI

요약

본 논문은 아동심리 분석을 위해 딥러닝을 활용하여 아동 그림 유사유형 검출 모델 기술을 총 세 가지 방법을 통해 제안하였다. 첫 번째는 Triplet loss 함수 기반으로 anchor, positive, negative 클래스로 나누어 학습하는 딥러닝 기반 유사유형 검출 알고리즘이다. 두 번째는 딥러닝 기반 segmentation 정보를 데이터베이스에 저장하고 입력값과 저장된 데이터를 비교하여 위치 기반 검출 방법을 제안하였다. 세 번째는 각 영상의 채널 기반 히스토그램 방법을 통해 제안하였고 마지막으로 제안된 기술의 분석을 위한 3D 입체 변환기술을 제안하였다. 이를 통해 인공지능을 활용한 아동심리 분석 기법의 좋은 방법이 될 수 있다.

1. 서론

오늘날 맞벌이 부부 증가, 부모의 이혼과 별거, 핵가족화, 구성원의 자살 등 다양한 삶의 위험으로 인해 아동의 발달과 정신건강에 부정적인 영향을 주고 있다. 아동기의 심리상태는 성인까지 지속해서 영향을 미칠 수 있어서 심리적 문제가 있는 아동의 조기발견과 적절한 관리가 필요하다. 아동심리 분석 중 대표적인 방법은 아동 그림을 통한 방법이 있으며 대부분이 심리 전문 상담사에 의해 대면으로 진행된다. 이런 상담은 비언어적 표현의 소통과 라포형성에 유리한 장점이 있지만, 코로나 시대에 비대면 방식을 선호하는 시대적 흐름에 맞지 않고, 언제 어디서나 빠르게 접근 가능한 분석을 진행하기에는 무리가 있다. 이에 비대면 심리분석의 필요에 따라 인공지능을 활용한 아동심리 분석 연구가 이루어지고 있다. [1]. 본 논문에서는 딥러닝을 활용한 아동 그림 유사유형 검출 모델 기술을 세 가지 방법을 통해 제안하고자 한다.

첫째, 아동 그림의 특징에 따라서 세 가지 클래스로 분류하였고, 이를 triplet loss 함수에 적용해 딥러닝을 적용해 아동 그림 유사유형 분석에 적용하였다.

둘째, 아동 그림의 영상 채널 특징에 따라 유사이미지를 분류하였다.

셋째, 아동 그림의 객체 위치에 따라 유사이미지를 분류하였다.

본 논문의 나머지 부분은 다음과 같이 구성되어 있다. 2장에서는 Triplet loss 함수 기반 이미지 유사도 측정 방법에 대해 설명한다. 3장에서는 영상의 위치와 채널 기반 이미지 유사도 측정을 설명하며 4장은 3D 입체변환 기술을 통한 시각에 관한 내용과 5장은 연구결과에 대해 설명한다. 마지막 장은 결론으로 본 연구결과의 의미와 활용도에 대해 생각해볼 수 있다.

2. Triplet loss 함수 기반 이미지 유사도 측정

Triplet loss 함수는 참조 입력인 anchor를 positive, negative 입력값과 비교하는 딥러닝 네트워크에 대한 손실함수이다. [2]. 모델에 학습된 데이터셋은 ㈜티엔에프에이아이에서 제공한 아동 그림 데이터셋을 사용하였다. 총 세 가지의 클

스로 구성되어 있으며 한 개의 인물 객체에 다양한 이미지 특징을 사용한 그림 군과 한 개의 인물 객체에 대해 단순한 이미지 특징을 사용한 그림 군, 마지막으로 한 개 이상의 객체에 다양한 이미지 특징을 사용한 그림 군으로 나뉜다. 클래스별 아동 그림 이미지 숫자는 200장이다. 훈련데이터와 테스트 데이터는 8:2의 비율로 설정하였다.

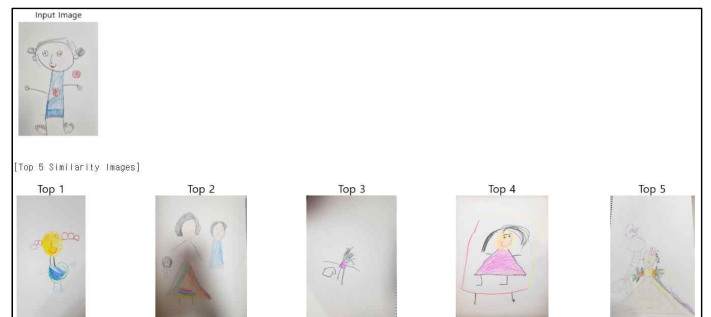


그림 1. Triplet loss 이미지 유사도 측정

3. 영상의 위치와 채널 기반 이미지 유사도 측정

아동 그림객체 위치에 따른 유사이미지 분류를 위해 기존 아동 그림 데이터셋의 위치 정보(ground truth) 데이터베이스를 생성하였고 입력 이미지에 딥러닝 기법 중 instance segmentation을 Mask r-cnn을 통해 적용하였다. [3]. 이를 통해 입력 이미지와 데이터셋 간의 정교화된 값에서의 위치를 서로 비교할 수 있었다. 그리고 가장 유사한 top-5의 그림을 추출하는 알고리즘을 개발하였다.

이미지 영상 채널 기반 이미지 유사도 측정을 위해서 각 영상값의 도수분포표를 적용하였고, 이미지 색채에 따른 아동 그림의 특징을 분석하는데 적용했다.




그림 2. 히스토그램 기반 이미지 유사도 측정




그림 3. 위치 기반 이미지 유사도 측정

4. 3D 입체 변환기술을 통한 시각화

아동 그림 분석을 위해 딥러닝 기반 segmentation을 적용하였고, 픽셀별로 classification을 하였다. 객체별 2D 이미지를 3D로 부풀리는 기술인 몬스터매쉬를 활용하고 이를 통해 심리 분석 시 시각화에 도움 줄 수 있다. [4].



그림 4. 3D 입체 변환기술 전 이미지




그림 5. 3D 입체 변환기술 후 이미지

5. 연구결과

Triplet loss 함수 기반 이미지 유사도 모델 평가를 위해 k-nearest neighbors algorithm (k-NN) 방식을 사용하였으며 유사 이미지를 그림 1의 결과를 통해 확인할 수 있다. 평가한

결과, Triplet loss, contrastive loss 기반 ResNet-152 모델에서 각각 92.1%, 85.5% 정확도를 나타냈다. [표. 1]. 영상 위치와 채널 기반 이미지 유사도 측정을 위해서는 그림 2번과 3번을 통해 정성적으로 평가하였다. [그림 2-3]. 3D 입체 변환 기술을 통한 시각화 결과 역시 정성적인 평가를 통해 이루어지고 있으며 입체변환을 적용하기 전의 그림4 이미지와 적용한 후 3D로 부풀려진 그림5의 이미지를 확인할 수 있다.

<표 1> KNN기반 유사유형 정확도

	KNN
ResNet-152 with Triplet Loss	92.1%
ResNet-152 with Contrastive Loss	85.5%

6. 결 론

본 연구에서는 아동심리 분석을 위해 세 가지 아동 그림 유사유형 검출 알고리즘을 제안하였다. 먼저 Triplet loss 함수 기반 이미지 유사도 측정은 제한된 클래스에서 적용하였지만, 딥러닝을 활용한 아동 그림 이미지의 유사도에 대한 가능성을 보여주고 있다. 위치와 영상채널 기반 알고리즘은 단순하지만, 직관적으로 아동 그림의 유사도를 비교할 수 있기 때문에 유형분류에 적용 시킬 수 있다. 또한, 3D 입체변환 기술을 통해 유사유형 알고리즘 분석 시 시각화에 도움 줄 수 있을 것이다.

결과적으로 제안한 알고리즘을 통해 아동 그림 유사유형 분류를 통해 아동의 심리분석에 적용 시킬 수 있으며 이 기술이 아동심리 분석을 위한 하나의 지표로 이용될 수 있기를 기대한다.

ACKNOWLEDGMENT

본 논문은 연구개발특구진흥재단 기술사업화 역량강화사업(세부과제번호: 2022-DD-RD-0472-01)과 한국원자력연구원 주요사업인 “하나로 및 연구시설 운영 지능화 플랫폼 구축”(과제번호: 524450-22)의 일환으로 수행되었습니다.

참 고 문 헌

- [1] Moon, J. Y., Kim, M. J., Lee, S. O., & Yu, Y. G. (2022). A deep learning model based on triplet losses for a similar child drawing selection algorithm. Journal of the Korea Industrial Information Systems Research, 27(1), 1-9.
- [2] Schroff, F., Kalenichenko, D., & Philbin, J. (2015). Facenet: A unified embedding for face recognition and clustering. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 815-823).
- [3] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 2961-2969).
- [4] Dvorožňák, M., Sýkora, D., Curtis, C., Curless, B., Sorkine-Hornung, O., & Salesin, D. (2020). Monster mash: a single-view approach to casual 3D modeling and animation. ACM Transactions on Graphics (TOG), 39(6), 1-12.

실시간 시선추적 기술을 통한 비대면 수업집중도, 학업성취도 간 관계: 개인별 자세의 조절효과

구인혁
우송대학교 엔디컷국제대학
ihkoo@wsu.ac.kr

Concentration and Academic Achievement in an E-learning Context Using Real-time Eye Tracking: The Moderating Effect of Learners' Postures

Inhyouk Koo
Woosong University, Endicott College of International Studies

요 약

본 연구는 비대면수업에서의 학습자 시선과 수업자세를 실시간으로 측정하고 화상수업에 최적화된 집중도의 개념을 재정의한다. AI 기술을 접목한 동공추적 방법론을 활용하여, 수업집중도의 변화에 따른 장단기 학습성과의 차이와 그 관계를 분석하여 효과적인 온라인수업에 요구되는 학습자 선행조건에 대해 논의하고자 한다. 특히, 온라인교육 영역에서 인지과정을 다룬 정보처리이론과 지각심리학에서 제공하는 시각-자극-반응의 효과성(SRC) 이론 등을 기반으로, AI 학습을 통한 시선유지시간(dwell time)을 비대면수업의 집중도로 측정하는 최적화된 방법론을 설정하고, 학습자의 시선응시와 장단기 학습성과 간 개념적 관계를 바른 자세의 조절효과를 통해 증명한다.

1. 서 론

COVID-19의 범유행이 지속되면서 일상은 완전히 바뀌었다. 과거 한번도 경험하지 못했던 전면 비대면수업은 교육환경 전반에 걸쳐 급진적인 디지털화를 촉진했다. 유례없는 온라인수업이 지속되면서, 정상적인 교육과정을 제공 받지 못한 대학생들의 불만은 사회 문제로까지 대두되었다[1]. 온라인수업이 활성화된 첫째, 부족한 학습지원시스템과 준비되지 못한 원격수업에 대한 설문결과가 일관되게 회의적이었고 특히, 응답인원의 75.1%는 대학등록금 반환까지 동의하는 것으로 나타났다[2].

대학의 비대면수업이 활성화되면서, 학습자의 성향과 자세, 집중도 및 학업성과와 관련된 다양한 연구들이 이루어지고 있다. 청각과 시각정보의 관리방법을 개념화한 멀티미디어 설계 이론을 바탕으로, 정보선택, 주의집중의 과정을 인지적 측면에서 분석하려는 연구들이 시작되고 있다[3]. 동시에, 학습자의 시선고정시간(eye-fixation time)과 교육 콘텐츠의 상호작용도 수업설계 영역에서 새로운 연구 주제로 떠오르고 있다. 예를 들어, 정보처리이론에서 인지과정은 시각정보 입력의 응시와 정보처리 과정인 집중의 두 가지 측면으로 구분되는데[4], 학습자의 응시시간, 응시공간을 측정하여 학습집중을 유도하는 선행요인과 그 결과 사이의 연구가 활발하게 진행중이다 [5][6][7][8].

선행연구를 바탕으로 본 연구에서는 학습자 시선응시의 실시간 방향과 빈도, 자세의 가중치가 적용된 온라인 수업집중도 점수를 산출하고 단기 과제수행 결과와 장기 학점과의 관계를 분석하여 통합된 생체데이터와 학습자의 학업 성취도 간 유의미한 연구모형을 정립하고자 한다. 또한, 실시간/장기간 현장연구(field research) 환경에서 학습자의 인지과정 및 학습결과의 연계를 위해 한달 이상의 실시간 수업에서 집중도, 자세 변화의 균형(안정성)을 분석하여 시선응시 및 개인별 수업특성을 효과적으로 활용할 수 있는 방법론을 적용하고자 한다. 마지막으로, 학습자의 상황요인으로 '수업자세'를 제시하여 두 변수(응시-자세)간 방향과 강도의 변화를 검증하고 온라인수업의 주의집중과 장단기 학업성취 사

이의 관계를 조절하는 요인들의 상호관계를 규명하고자 한다.

같은 맥락에서, 선행연구에서 '쳐다보고 있음'을 '응시-집중'의 관계와 동일시하고 그것을 온라인수업의 성취도와 직접 연계하는 접근방법의 문제점을 논의한다. 예를 들어, 집중하지 않고 쳐다보는 경우 또는 교수자의 특성에 맞춰 간헐적/효과적으로 쳐다보는 행위를 구분해야 할 필요가 있다. 또한, 화상수업에서는 단순 응시만으로 학업성과 향상이 보장되지 않는다. 대면수업과는 달리 학습자가 응시의 강도와 방향을 효과적으로 관리할 때, 오히려 더 나은 성과를 만들어낼 가능성도 배제할 수 없다. 따라서, 응시 자체를 집중도와 동일시하지 않고 다중 생체데이터의 통합(시선 응시와 자세의 결합)으로 온라인수업 집중도의 개념을 재정립하고, 학제간 통합연구의 필요성을 함께 논의할 것이다. 결론적으로, 응시→집중도→학업성과의 정(+)의 관계는 자세의 조절효과를 통해 강화되고 자세와 연동된 시선추적의 분석에서 집중도 변화, 개인별 맞춤형 수업이해 및 학업성취도간 관계를 정의하는 교육학적 접근 등 향후 추가 연구가 필요할 과제들까지 공유하고자 한다.

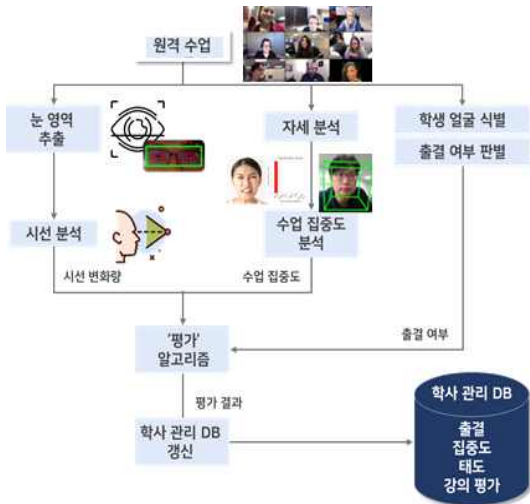
2. 연구방법 및 시스템 구성

전국 4년제 대학 중 한 곳을 선택하여 시선, 자세와 관련된 수업집중도 측정 관련 설명회를 진행한다. 전공수업을 수강한 학생들을 대상으로 온라인수업 측정에 필요한 시선추적기의 구동, 개인정보보호를 위한 준수사항을 사전 안내한다. 이 연구에서 사용된 시선, 자세추적은 Sensor Motoric Instrument(SMI)사에서 개발한 iViewX RED와 상응하는 SW를 사용한다[9]. 수강자들은 모니터 상단에 측정기기를 부착하고 자기선택하여 시선 및 자세의 변화를 녹화한다. 수강 환경은 수강자의 자택(책상유무 확인) 및 공부방으로 한정하고, 카페 및 외부환경에서의 접속은 데이터로 반영하지 않는다. 이것은 시각적 주의력을 저해하는 요소들 선제적으로 방지하기 위함이다.

교수자의 강의, 보조자료 활용 등이 강의계획에 반영되어야 하고 데이터 수집은 온라인수업당 3시간 동안 진행된다. 측정 장

비를 통해 화상 모니터에 반영된 학습자별 시선 응시데이터를 수집하고 상반신 데이터를 실시간으로 매칭한다. 이후, 수업집중의 시계열 정보와 함께 개인별 종속변수(학업성취도: 정성/정량 평가)와의 상관관계 및 회귀모형의 적합성을 분석한다. 정성평가는 수업태도에 대한 교수평가(7점 척도) 설문을 수집하고, 정량평가는 수강과목 관련 학사정보(학점, 과제수행 이력 등)와 평균학점을 사용한다. 수업 외에 수행해야 하는 추가과제(소그룹 활동 포함)를 마감시간 내 제출했는지의 여부도 집중-학업성취도 간 연구모형의 통제변수로 활용한다. 이것은 학업성취도(학점)와는 달리, 학습자가 수업목표를 달성하기 위한 의지와 노력의 결과를 의미한다. 해당 변수는 온라인 학사과정을 관리하는 대학 내 학습관리시스템에서 과제 업로드 시간과 평가점수를 반영한다 <그림 1>.

그림 1. 연구방법 및 시스템 구성



동시에, 신체부위별 자세패턴 분석에 따라 5개 관찰 부위와 관절움직임 중 3가지 기준을 반영하여, 수업화면에 반영된 학생들의 자세를 실시간으로 계측한다[10] 이미지데이터에서 계측된 양 어깨 견갑골의 위치를 마킹하고 어깨선과 안면부의 기울기(수평)를 기준으로 바른 자세인지, 바르지 않은 자세인지의 비율을 산출한다. 연구를 수행하기 위한 구체적 연구가설은 다음과 같다.

- <연구가설 1-1> 온라인수업에서 학습자들의 집중도는 단기 학업성취도(과제수행)에 긍정적 영향을 미칠 것이다.
- <연구가설 1-2> 온라인수업에서 학습자들의 집중도는 장기 학업성취도(학점)에 긍정적 영향을 미칠 것이다.
- <연구가설 2> 온라인수업에서 학습자의 집중도와 학업성취도는 장기간의 시선추적 정보와 시선응시의 편차가 크지 않을 때 정(+)의 관계를 갖는다.
- <연구가설 3> 온라인수업에서 학습자의 자세는 집중도와 학업성취도 사이의 정(+)의 관계를 조절할 것이다. 즉, 바른자세를 유지할수록 수업집중도와 학업성취도 간 정(+)의 관계가 커질 것이다.

3. 연구결과

소비 행동(마케팅), 온라인 주문(유통경영), 안구 운동(보건), 교과서 응시(아동교육) 등 시선추적을 통한 인지역량을 추정하는 연구들이 다양한 영역에서 시도되고 있다[11],[12],[13],[14]. 상기 연구들의 결과들을 종합하여, 우리는 AI 분석기술을 고등교육 분야에 적용

한 학제간 융합연구를 시도한다. 비대면수업에서 학생들의 시선과 자세변화를 실시간으로 분석한 결과는 수업집중도의 측정타당성(개념, 분석, 판별)을 제공하고, COVID-19 상황에서 심각해지는 학업격차의 원인을 수업집중도 측면에서 논의하고자 한다. 이전 연구의 분석법을 반영하면, 데이터 분석결과는 시간에 따른 학습자의 응시 변화량으로 측정장치에 기록될 것이다.[7] 시간경과에 따른 시선응시의 비교변화량도 함께 계측된다<그림 2>. 즉, <그림 3>에서 시선변화 0을 기준으로 양의 방향은 시선분산의 증가, 음의 방향은 시선집중의 증가를 나타낸다.




그림 2. 시간 변화에 따른 시선응시




그림 3. 시선 응시점의 변화: 시선분산 vs 시선집중

설정된 가설의 결과는 <그림 4>에서 제시된 것과 같이, 자세가 바르지 않은 그룹에서는 온라인 수업집중도와 학업성취도간 부정적 영향이 나타났고 바른자세의 비율이 높을수록 시선응시를 기준으로 한 집중의 강도, 학업성취도 간 양(+)의 관계가 상대적으로 높게 나타났다.




그림 4. 수업집중도와 자세의 조절효과

온라인수업에서의 개인별 자세에 대한 조절효과는 집중도와 학업성과 사이에 바른자세의 (+)의 효과가 입증되었다. 동시에 조절효과의 강도는 단기적 과제수행보다는 장기적 학업성취도와 더욱 밀접한 관계를 나타내었다. 환언하면, 학업성취도 관점에서 온라인 수업의 집중도는 동공응시를 기반으로 한 몰입이 선행되어야 하고 바른자세의 촉매작용은 긍정적인 학업성과의 필수적인 조건이라고 할 수 있다.

본 연구에서 동공의 주시 횟수(fixation time)와 주시 빈도(fixation count)가 분리된 생체데이터를 반영함으로써 온라인교육 분야에서 정보처리이론과 자극-반응-결과(SRC)이론 발전에 기여

할 것이다[7]. 따라서, 기존 연구에서 단순히 '쳐다보고 있음'을 '응시-집중'의 관계와 동일시하고 그것을 온라인수업의 성과와 직접 연계하는 방법론은 문제가 있다는 점을 제기한다. 예를 들어, 집중하지 않고 쳐다보는 경우와 교수자의 특성에 맞춰 간헐적/효과적으로 쳐다보는 행위를 구분해야 할 필요가 있는 것이다. 또한, 화상수업에서는 단순 응시만으로 학업성과 향상이 보장되지는 않는다. 대면수업과는 달리 학습자가 응시의 강도와 방향을 효과적으로 관리할 때, 오히려 더 나은 성과를 만들어낼 가능성도 배제할 수 없다. 그러므로, 응시 자체를 집중도와 동일시하지 않고 다중 생체데이터의 통합(시선응시와 자세의 결합)으로 온라인수업 집중도의 개념을 재정립하고, 학제간 통합연구의 필요성을 함께 논의할 것이다. 즉, 응시→집중도→학업성과의 정(+)의 관계는 자세의 조절효과를 통해 강화되고 자세와 연동된 시선추적의 분석에서 인지역량과 집중도의 변화, 개인별 수업이해도 및 학업성취도 간 관계를 정의하는 교육학적 접근 등 향후 추가연구가 필요할 과제들을 제안하고자 한다.

4. 기대효과

시선추적을 통한 인지역량을 추정하는 이전 연구들의 결과들을 종합하여, 본 연구는 동공분석, AI기술 등을 고등교육 분야에 적용한 학제간 융합연구를 시도한다. 비대면수업에서 학생들의 시선과 자세변화를 실시간으로 분석한 결과는 수업집중도의 측정 타당성(개념, 분석, 판별)을 제공하고, COVID-19 상황에서 심각해지는 학업격차의 원인을 수업집중도 측면에서 논의할 수 있다. 본 연구는 학문적, 교육정책적, 산업적 측면에서 다음과 같은 기대효과가 예상된다.

첫째, 학문적 측면에서, 다중 생체데이터를 통합하는 시도(학습자의 시선응시와 자세정보의 결합)는 온라인 환경에서의 수업 집중도의 개념 정립에 도움을 줄 것이다. 동공의 주시 횟수(fixation time), 주시 빈도(fixation count)의 적용, 자세 변화에 따른 시선의 움직임이 포함된 데이터를 활용하여 온라인교육 영역에서 인지과정을 다룬 정보처리이론과 자극-반응-결과(SRC)이론 발전에도 기여할 것이다.

둘째, 교육정책 측면에서, 시선추적 연구의 노하우를 확보하고 신기술이 접목된 미래형 화상교육 환경에서 필수적인 학습자 행동, 환경요인의 영향력을 보다 과학적인 방법으로 분석한다. 교육부는 온·오프라인(O2O)융합 학습환경과 디지털리터러시 전환이라는 시대적 흐름에 맞춰 학습자 맞춤형 화상교육 서비스를 제공하고 그 결과까지 확인할 수 있는 정책과제를 수립중이다. 향후, 온라인교육 콘텐츠의 질적 수준은 향상될 것이고 학업성취도 평가 등 학습격차 파악 및 해소를 위한 맞춤형 데이터도 확충될 것이다. 그 과정에서 본 연구의 시선-자세의 통합분석법은 온라인 학습자의 태도와 인지능력을 구분하면서 수업집중도, 학업성과의 개인별 차이를 예측하는데 도움을 줄 것이다. 학습자별 수업집중도와 상이한 학업성과에 따라, 강의자는 교재 및 교수법의 미흡한 점을 보완하고, 학생들은 온라인수업에서도 자기주도학습의 중요성을 다시 한번 깨닫는 계기를 만들고자 한다.

셋째, 산업 영역에서 기대효과는 학생들이 본인의 집중도 결과데이터를 특정 플랫폼을 통해 실시간 확인할 수 있는 시스템으로 구축될 수 있다는 점이다. 앱/웹을 통해 구현되는 이 시스템은 대학에서 실증사업화를 통해 상용화도 가능하다. 본 연구의 결과를 확장하고 지속적인 연구를 진행함으로써, 대학생들의 집중도 및 반응데이터가 학사관리에 유효한 자료로 활용될 수도 있다. 나아가 온라인수업에서만 발견할 수 있는 학생들의 선호, 만족도, 참여도 분석을 통해 학생, 수업 관련 연구주제들이 논의되고 이것은 교육분야의 다양한 SW개발에 활용할 수 있는 자료로 활용될 것이다.

ACKNOWLEDGMENT

본 연구 논문은 2022년도 한국연구재단의 신진연구지원사업 일환으로 수행되었음.

참 고 문 헌

- [1] 정향기. (2020). 코로나19 상황의 대학교육에 있어서 전면적 온라인 수업 실행 및 평가에 대한 학습자 만족도. 멀티미디어 언어교육, 23(3), 392-412.
- [2] 리얼미터(2020). 온라인 개학 찬반 의견, 찬성 60.5% vs 반대 23.2%.
- [3] 손태권, 이광호. (2020). 토크모델링을 활용한 국내 수학교육과정 연구 동향 분석: 1997년부터 2019년까지 게재된 국내 수학교육 학술지 논문을 중심으로. 수학교육, 59(3), 201-216.
- [4] 은석함, 박민희, 황미경, 남가영, 권만우. (2019). 시선추적장치를 활용한 캐릭터의 시지각 집중도에 관한 연구. 한국콘텐츠학회논문지, 19(6), 105-113.
- [5] Li, W., Wang, F., Mayer, R.E., & Liu, H. (2019). Getting the point: Which kinds of gestures by pedagogical agents improve multimedia learning? Journal of Educational Psychology.
- [6] 김민재, 임대근, 박영준, 김진홍, 정승도. (2020). 자세 분석 및 시선 인식 기반의 학습 효율 향상 방안 연구. 컴퓨터교육학회 논문지, 23(6), 59-66.
- [7] 류지현, 김국현. (2020). 가상현실 수업시뮬레이션에서 가상 학생과의 정서적 상호작용이 사용자의 시선응시 및 가상실재감에 미치는 영향. 한국콘텐츠학회 논문지, 20(2), 581-593.
- [8] 박충호, 박노진, 노성혁, 곽노윤. (2018). 얼굴 인증 및 시선추적 기술을 응용한 온라인 강의 모니터링 시스템. 대한전자공학회 학술대회, 504-507.
- [9] 이용진, 류지현, 강의동영상 자료에서 시선응시정보를 활용한 학습자의 주의집중 및 분산에 대한 탐색연구. 한국교육학연구, 2017
- [10] 배민우, 곽은창, 고등학생들의 신체통증과 자세습관 실태분석. 한국스포츠교육학회지, 2016
- [11] Reutskaja, E., Nagel, R., Camerer, C. F., & Rangel, A. . Search dynamics in consumer choice under time pressure: An eye-tracking study. American Economic Review, 2011
- [12] Shi, S. W., Wedel, M., & Pieters, F. G. M, Information acquisition during online decision making: A model-based exploration using eye-tracking data. Management Science, 2013
- [13] Vidal, M., Turner, J., Bulling, A., & Gellersen, H. Wearable eye tracking for mental health monitoring. Computer Communications, 2012
- [14] Strohmaier, A. R., MacKay, K. J., Obersteiner, A., & Reiss, K. M. Eye-tracking methodology in mathematics education research: A systematic literature review. Educational Studies in Mathematics, 2020

강화학습을 이용한 지연 전송선의 누화 최소화 설계

정재호¹ 유용균¹ 이수범²

¹한국원자력연구원

²메릴랜드 볼티모어 카운티 주립대학

jungjaeho@kaeri.re.kr, ygyu@kaeri.re.kr, sblee@umbc.edu

Delay Line Circuit Design Optimization for Crosstalk Minimization using Reinforcement Learning

Jaeho Jung¹ Yonggyun Yu¹ Soobum Lee²

¹ Korea Atomic Energy Research Institute

²University of Maryland, Baltimore County

요약

전기 신호의 시간 동기화를 위해 사용되는 지연 전송선은 전자장비의 소형화에 따라 조밀해지는 구조를 가지므로 전기적 잡음(누화)이 발생된다. 본 연구에서는 해당 잡음을 최소화하기 위해 강화학습을 적용한 설계 방법을 제안한다. 설계 영역과 지연 전송선을 이산화하고 상태, 행동, 보상을 규정하여 강화학습에 적합하게 환경을 정의하였다. DQN을 변형하여 강화학습을 수행하였고 그 결과 입력된 길이에 따라 전기적 잡음이 낮은 형태의 지연 전송선이 도출되는 것을 확인하였다.

1. 서론

전자 회로 기판의 칩 또는 패키지 간의 전기적 신호는 시간 동기화를 위해 전달 시간 조절이 필요하다. 시간 조절 방법 중 회로의 길이를 통해 전달 시간을 조절하는 방법인 지연 전송선(delay line)이 비용 측면에서 유리하여 널리 사용되고 있다. 그러나 패키지나 회로기판의 크기가 점점 작아지기 때문에 지연 전송선이 조밀해져서 잡음의 일종인 전기적 누화(crosstalk)가 발생한다. 가까운 선로 사이에서 발생하는 누화는 신호의 품질을 저하시키며 심각한 경우 오작동을 일으킨다.

방향 전환이 많은 지연 전송선(serpentine delay line)은 전송 신호의 상승 에지(rising edge) 주변으로 누화의 적층이 일어나 오작동이 일어나기 쉽다[1]. 이를 개선한 형상으로 나선형 지연 전송선(spiral delay line)이 Wu and Chao[1]에 의해 제안되었다. 이후 입력단과 출력단의 누화의 형태를 특정한 형태로 설계할 수 있는 방법으로 유전자 알고리즘을 이용한 회로 설계 방법이 Chung *et al.* [2]에 의해 제안되었다. 하지만 유전자 알고리즘을 이용한 방법은 결과가 나오기까지 시간이 오래 걸리며 시간 복잡도가 높은 단점이 있다.

본 연구에서는 지연 전송선의 누화 최적 설계를 위한 방법으로 강화학습을 적용한 방법을 제안한다. 본 방법은 유전자 알고리즘을 이용한 설계방법이 가지는 시간 문제를 해결하면서 다양한 지연 전송선의 설계를 최적화할 수 있다.

2. 설계 공간 및 환경 설정

설계 공간은 지연 전송선이 들어갈 수 있는 공간으로 한정한다. 본 연구에서는 그림 1과 같이 32mm 길이의 정사각 공간으로 설계 공간을 한정하였고 선로의 폭은 1.92mm 로 설정하였다. 설계 공간은 Chung *et al.* [2]에 의해 제안된 방법으로 8x8 크기로 이산화하였다. 전송선의 시작점은 좌상단, 끝점은 우상단으로 고정하였다. 누화의 계산은 Kim *et al.* [3]에 의해 제안된 방법을 적용하였다. 지연 시간이 주어지면 길이로 변경되어 설계의 입력이 되도록 하였다.

3. 강화학습 설정

강화학습을 적용하기 위해 시작점과 끝점을 이어서 지연 전송선을 설계하는 행동을 시작점으로부터 끝점까지 길을 찾아가는 에이전트(agent)에 의해 수행되는 것으로 가정하였다. 상태(state)_t는 그림 2와




그림 1. 지연전송선의 설계 공간 및 설정




그림 2. 강화학습을 위한 네트워크 구조 및 입력 데이터

같이 현재 회로의 그림과 선로 길이가 사용된다. 에이전트의 행동(action)은 시작점으로부터 진행방향으로 그대로 진행하는 행동, 좌측 또는 우측으로 진행방향을 변경하는 행동 등으로 총 3가지가 사용된다.

적용한 강화학습 알고리즘은 DQN을 수정하여 적용하였다. DQN은 차원이 적은 문제에서 적용이 가능하나 본 문제는 각 상태의 행동에 따라 경우의 수가 급증한다. 따라서 일반적인 탐험 전략으로는 안정적인 학습 수렴을 기대하기 어렵다. 본 연구에서는 에이전트가 행동할 수 있는 가상의 행동을 먼저 취하고 그 행동을 취했을 때 끝점까지 길이를 만족하며 연결되는 임의의 방법을 100회를 시도한 후 각 시도된 형상에서 보상이 최대화되도록 지연 전송선을 이동하는 방법으로 각 행동의 탐험 수행 결과를 수집한다. 이때 보상은 다음 식 (1)을 사용한다.

$$r = P^{-1}, \quad (1)$$

여기서 P 는 발생하는 누화의 최대값이다. 100회의 시도 중에 보상의 최대값을 구하고 이전 행동에서 구한 최대 보상과 비교하여 더 높은 보상값을 선정하여 Q 값으로 활용한다. 초기에는 탐험된 결과들을 통해 네트워크를 학습한다. 사건(episode)이 진행됨에 따라 학습된 네트워크로부터 추정되는 Q값을 계산하며 각 가상 행동에 따른 탐험된 Q값과 비교하여 더 높은 보상을 추론하는 경우 네트워크에 학습된 결과로부터 행동을 선택한다. 끝점에 도달한 경우 보상을 계산하고




그림 3. 강화학습을 통한 입력 길이별 지연 전송선의 누화 최적화 설계 결과. (a) 길이=8. (b) 길이=22. (c) 길이=32. (d) 길이=40. (e) 길이=50. (f) 길이=60.

도달까지의 각 상태에 따른 행동과 최종 보상을 학습 자료로 임시 저장소(buffer)에 저장한다. 네트워크의 학습은 특정량 이상의 학습 자료가 누적되면 매 사건마다 임의의 500개 학습 데이터를 추출하여 100번의 epoch를 수행하여 그림 2의 네트워크를 학습한다. 사건은 총 500번을 수행한다. 학습을 수행한 장비는 Ryzen9 3900X CPU, 64GB 메모리, RTX 2080 그래픽카드를 장착한 PC 였으며 총 학습 시간은 약

2일이 필요하였다.

4. 결과

임의의 길이를 설정하여 학습된 네트워크에 입력하면 각 상태에 따라 행동의 최적 보상이 추론된다. 따라서 추론되는 보상값 중 최고의 값을 선택하며 행동하면 누화가 최소화되는 설계 결과가 도출된다. 단 학습된 네트워크의 추론이 완벽하지 않으므로 각 행동이 길이를 만족하며 끝점에 도달 가능한 행동인지는 매 행동별로 확인하며 진행한다. 최종적으로 끝점까지 연결되어 완성된 지연 전송선은 보상을 더욱 높이기 위해 마지막 형상 최적화를 수행한다.

그림 3은 학습된 네트워크를 이용한 입력 길이 별 지연 전송선의 누화 최적화 설계 결과이다. 길이가 짧은 경우 최대한 외벽으로 지연 전송선이 배치되는 것을 확인할 수 있으며 길이가 길어짐에 따라 나선형의 형태를 띠는 것을 확인할 수 있다.

5. 결론 및 향후 연구

본 연구에서는 강화학습을 이용하여 지연 전송선의 누화를 최소화하는 설계 방법을 제안하였다. 본 방법으로 누화 최적화 지연 전송선을 길이에 따라 설계해본 결과 기존에 누화의 최대값이 낮은 것으로 알려진 나선형의 형태를 생성할 수 있었다. 따라서 본 방법이 합리적인 결과를 도출하는 것을 확인하였다.

향후 본 연구의 심화 방안으로 더욱 다양한 누화 형상에 따른 설계가 가능하도록 연구를 적용할 예정이다. 또한 지연 전송선 뿐만 아니라 선로 연결 형상 설계가 필요한 다른 문제로 본 설계 방법을 확장할 수 있을 것으로 예상된다.

참 고 문 헌

- [1] R.B. Wu and F.L. Chao, "Flat spiral delay line design with minimum crosstalk penalty," IEEE Transactions on Components, Packaging, and Manufacturing Technology: Part B, vol. 19, no. 2, pp. 397-402, 1996.
- [2] C. Chung et al., "A delay line circuit design for crosstalk minimization using genetic algorithm," IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, vol. 27, no. 3, pp. 578-583, 2008.
- [3] G. Kim et al., "TDR/TDT analysis by crosstalk in single and differential meander delay lines for high speed PCB applications," In Proc. IEEE International Symposium on Electromagnetic Compatibility, EMC 2006, pp. 657-662, 2006.

강화학습을 활용한 열 유체 온도 균일화 유로 형성

Formation of a thermofluid temperature equalization flow path using reinforcement learning

요 약

반도체 양산 공정에 사용되는 웨이버 프로버 칩은 항상 일정한 온도가 유지가 되어야 한다. 일정한 온도를 만족하기 위해 유로를 형성하여야 하며 지정된 공간 내 일정 온도를 만족하는 최적화된 유로의 형상을 구축하여야 한다. 유로의 형상은 다양하기 때문에 대상의 크기와 재질에 따라 최적화된 경로가 다르다. 문제를 해결하기 위해 강화학습의 도움을 받아 보상 과정을 통하여 열 유체 유로 형상을 도출할 수 있는 방안을 제시하였으며 형성된 유로 경로를 통해 온도 분포를 도출하였다.

1. 서 론

반도체 양산 공정에 사용되는 웨이버프로버 칩은 웨이퍼의 온도를 시험 온도인 -50°C 에서 150°C 내외로 균일하게 가열 및 냉각을 해주는 역할을 한다 [1]. 웨이퍼 상의 모든 소자가 균일온도에서 측정되어야 하기 때문에 칩 전체의 표면 온도가 $\pm 1.5^{\circ}\text{C}$ 이내여야 한다.

낮은 온도 차를 만족하기 위해 형상을 최적화하는데 여러 방법이 존재하며 그 중 지정된 공간 내 민감도분석을 하여 자유도가 높은 위상최적화가 존재하지만, 민감도 분석을 할 때마다 매번 열 유체 해석을 수행하여야 하기 때문에 계산 자원이 많이 소모되어 메시가 높은 복잡한 유로의 형상의 구현이 어렵다.

평판에 온도균일화를 위해서는 가장자리를 포함한 가능하면 많은 부분에 유체가 흘러야 한다. 유체가 흐르는 관형 파이프를 통하여 유로를 형성할 경우에 그림 1의 (a)와 같이 두꺼운 mesh의 경우 모든 구역을 지나치는 유로의 형태가 쉽게 예측이 되나 (b)와 같이 얇은 mesh의 경우 모든 구역을 지나치는 유로의 형태를 쉽게 예측할 수 없으며 유로 형성 방법의 경우의 수가 많기 때문에 모든 경우의 수를 계산하여 최적화할 수 없다.

강화학습을 통한 길 찾기 문제인 Gridworld의 예제는 출발지점과 도착지점 사이 간의 최단 경로를 Q-learning을 통하여 학습시키며 [2] 딥러닝을 통해 경로에 장애물을 두어 최단거리를 학습하기도 한다 [3]. 현 논문에서 Gridworld의 예제를 변형하여 경로 상의

최단 거리가 아닌 최장 거리를 찾는 방법을 구현해 열 유체 유로 경로를 구축하였다. 복잡한 형상의 최적화된 유로를 형성하기 위해 강화학습의 알고리즘 종류 중 하나인 PPO (Proximal Policy Optimization) 알고리즘을 통하여 연구하였다 [4].




그림 1. 온도균일화 유로 형성 방법
(a) 3×3 mesh (b) $n \times n$ mesh

2. 연구 방법

유로를 형성하는데 있어 보상 값 조절을 통하여 가능한 많은 방향으로 유체가 퍼질 수 있게끔 하였다.

Discrete 방법을 통하여 5개의 action을 주었으며 각 action은 방향 벡터인 위, 아래, 좌, 우 및 환경 초기화로 나타내었다. 그림 2와 같이 한번도 흐르지 않은 곳에 유체가 흐르고자 한다면 +의 보상 값을 주며 해당 방향으로 이동하였고, 유체가 이미 흘렀던 곳이라면 -의 보상 값을 주고 해당 방향으로 이동하지 않게 함으로써 랜덤으로 주어지는 불필요한 action 값을 줄이는 역할을 하였다.

만일 경로가 막힌다면 5번째 action은 초기화를 통해 전체 경로를 초기화 하였으며 최종적으로 도착지에 도착하였을 때에는 많은 보상 값을 주었다.




그림 2. 경로 지정에 따른 보상 방법

강화학습 환경 구축을 위해 Open AI GYM을 통하여 환경을 구축하였으며 [5] stable-baseline3를 사용하여 PPO 알고리즘을 적용하였다 [6].

3. 연구 결과

새로운 경로로 가는 보상 값 10, 기존 경로로 되돌아가는 보상 값 -1, 목표지점에 도달하는 보상 값 500을 기준으로 하였을 때 10×10 mesh의 형상에서 도출된 유로 결과 보상 값은 948 이며 유로가 형성된 경로는 그림 3과 같다.




그림 3. 형성된 유로 경로

노란색은 사전에 구성된 벽을 나타내며 파란색 부분에 화살표 방향으로 유체가 흐르며 보라색 영역은 유체가 지나가지 않는 영역이다. 학습 결과물로 모든 공간을 지나가는 최대경로의 구축을 예상하였지만 경우의 수가 많아 예상과 달리 학습을 통한 최대 경로의 구축은 실패하였다.

형성된 유로 경로를 토대로 COMSOL을 통하여 열 유체 해석을 수행하였다 [7]. 기하학적 및 경계조건으로 한 변이 200 mm, 두께 20 mm 인 판에서 30 °C의 물을 0.1 L/min 유량으로 흘리며 빠져나가는 열을 10 W 로 가정하였을 때의 온도 분포는 최대 3°C 이하의 온도분포를 가짐을 확인하였다.




그림 4. FEM 해석을 통한 온도 분포

4. 향후 계획

강화학습의 알고리즘을 변경하여 학습시켜 유로의 최대 경로 구축을 수행할 것이며, 현실과 더욱 부합하게 만들고자 Python의 library를 이용한 FEM 시뮬레이터를 구현하여 보상 값에 유로를 찾는 경로뿐 아니라 해석을 통해 얻어진 목적 함수인 온도 차를 넣어 강화학습을 구현할 예정이다.

또한 다양한 유로 형성을 위해 출발 및 도착 지정 변경, 유로의 두께 변경 등 기하학적 측면에서의 다양한 분석을 통해 최적화된 유로 형상을 도출하여 공학적 목표 값에 만족하는 열 유체 경로를 찾을 계획이다.

5. 참고 문헌

- [1] 주영철; 신휘철; 강명구. 웨이퍼 프로버 척의 저온 온도균일도 향상에 관한 연구. 한국산화기술학회 논문지, 10.10: 2572-2576, 2009.
- [2] TIZHOOSH, Hamid R. Reinforcement learning based on actions and opposite actions. In: International conference on artificial intelligence and machine learning. 2005.
- [3] PANOVA, Aleksandr I.; YAKOVLEV, Konstantin S.; SUVOROV, Roman. Grid path planning with deep reinforcement learning: Preliminary results. Procedia computer science, 2018, 123: 347-353.
- [4] SCHULMAN, John, et al. Proximal policy optimization algorithms. arXiv preprint arXiv:1707.06347, 2017.
- [5] BROCKMAN, Greg, et al. Openai gym. arXiv preprint arXiv:1606.01540, 2016.
- [6] RAFFIN, Antonin, et al. Stable baselines3. 2019.
- [7] COMSOL, A. B. COMSOL multiphysics user's guide. Version: September, 2005, 10: 333.

실시간 음향파 전파 구현을 위한 대칭성 기반의 효과적인 인공지능망 학습

최희선¹ 서호건² 유용균³

34057 대전광역시 유성구 대덕대로 989번길 111 한국원자력연구원

미래전략본부 인공지능응용전략실

heesunchoi@kaeri.re.kr hogeony@kaeri.re.kr ygyu@kaeri.re.kr

Effective training of neural networks with symmetricity constraint for real-time acoustic wave propagation

Hee-Sun Choi¹ Hogeon Seo² Yonggyun Yu³

111, Daedeok-daero 989beon-gil, Yuseong-gu, Daejeon, 34057, Republic of Korea

요약

일반 시뮬레이터를 통한 음향파 데이터의 취득은 큰 경제적, 시간적 비용을 필요로 한다. 이 논문에서는 순간적인 진동 펄스에 의한 음향파의 전파를 실시간(real-time)으로 예측하기 위한 인공지능망을 구성한다. 또한 상대적으로 적은 데이터를 사용해 효율적이고 정확하게 학습하기 위해 물리적 대칭성 조건을 부여하였다. 대칭성 조건(symmetric constraint)은 주어진 학습 데이터에 의존하지 않고 강제할 수 있다는 점에서 데이터 운용에 효과적이며 인공지능망의 정확도와 일반화 능력을 개선할 수 있다. 이 연구에서는 대칭성 조건이 인공지능망의 학습과 성능에 미치는 영향력을 분석한다.

1. 서론

음향파(Acoustic wave)는 인간과 동물에 의한 소리, 지진, 초음파 등을 포함하며 과학과 의학, 공학 등 광범위한 연구 분야에 관련되어 있다. 음향파 연구는 수많은 측정 데이터와 시뮬레이션 데이터의 분석을 바탕으로 이루어지는 경우가 많은데, 시뮬레이터의 계산 시간 절감을 위해 다양한 머신 러닝(machine learning)과 딥 러닝(deep learning) 기법들이 중요한 대안으로 부상하고 있다 [1-2]. 예를 들어 [3]에서는 인공지능망(deep neural network, DNN)을 이용하여 다양한 채널 모양에 따른 음향파의 전파를 예측할 수 있게 했다. 위 논문에서는 시뮬레이터 음향파 솔루션의 이미지를 학습 데이터로 사용해 인공지능망을 구성했다. 학습된 인공지능망은 실제 실험에서 얻은 음향파 모양을 만들어 낼 수 있는 채널의 모양을 유추하기 위한 inverse problem에 사용되었다.

음향파를 위한 인공지능망 구성에 관련된 기타 다른 연구들은 대부분 [2]과 같이 인공지능망의 응용에 집중하고 있다. 하지만 본 연구에서는 인공지능망의 학습과 효과적인 데이터의 사용에 자체에 집중한다. 시뮬레이터를 통한 음향파나 유체 역학 데이터의 생성은 (1)fine mesh의 경우 데이터 생성에 상당한 시간이 걸리며 (2)인공지능망 모델의 다양한 응용을 위해 입력의 차원을 늘리는 경우 필요한 데이터가 기하급수적으로 늘어날 수 있고 (3)GPU 메모리 제한 문제를 야기하거나 비현실적인 학습 시간을 요구하고 오히려 학습의 정확도를 떨어뜨리기도 한다. (4)또한, 그

어떤 물리적 특성을 학습에 반영하지 않았을 때, 마땅히 드러나야 하는 물리적 특성이 관측되지 않을 수 있으며 (5)인공지능망의 일반화(generality) 능력 또한 떨어뜨릴 수 있고 (6)hyperparameter에 대한 의존도를 높일 수 있다.

이 연구는 acoustic wave 전파의 실시간 해석을 위한 인공지능망 모델 생성을 효율적이고 효과적으로 하기 위해 대칭성 조건(symmetric constraint) 적용한다. 3장에서 구체적으로 다루게 될 symmetric constraint의 가장 큰 강점은 학습 데이터에 의존하지 않는다는 것이다. 이는 주어진 학습 데이터의 개수가 적을 때도 효과적으로 대칭성 조건을 만족할 수 있도록 하며 인공지능망 모델의 일반화 능력을 올릴 것이라고 기대할 수 있다.

참고로 대칭성 조건을 부여하는 것은 일종의 physics-informed machine learning (PIML)기법이라고 할 수 있다 [4-5]. 일반적으로 PIML 혹은 PINN은 지배 방정식(governing equation)을 만족하도록 하고 이를 다른 유체 역학이나 파동 전파 문제에도 적용할 수 있다. 그러나 본 연구에서 다루는 예제는 초기 조건과 경계 조건을 수치적으로 표현하기가 어렵기 때문에 지배 방정식을 적용하는 PINN의 방식을 직접 적용하기 어렵다. 지배 방정식만큼 총체적인 정보를 주지는 않지만 대칭성 조건이 인공지능망 모델이 물리적 특성을 가지도록 설계할 수 있다는 점에서 이 논문의 접근법은 PIML과 유사하다고 할 수 있다.

2. 지배 방정식

이 연구에서는 아래와 같은 지배 방정식을 따르는 음향파 모델을 고려한다.

$$\square \frac{\partial^2 u}{\partial t^2} - \square \frac{\partial^2 u}{\partial x^2} = \square \sin(\omega t)$$

여기에서 u 는 변위, \square 는 응력, \square 는 단위 부피당 용체힘, \square 는 밀도이다. 초기 조건은 일정한 너비(width, \square)를 갖는 틈, 즉 \square 위에서 발생하는 순간적인 진동 펄스이다. 펄스가 발생하는 지점이 $x = 0$ 을 중심으로 대칭적이므로 이로 인해 발생하는 음향파 또한 대칭성을 갖는다.

3. 인공신경망 구조와 학습 데이터

Feed-forward neural network(FNN)는 가장 대중적, 기본적으로 사용되는 인공신경망이며 다음과 같이 정의된다.

$$y = \sigma(\sum_{i=1}^n w_i x_i + b)$$

$$z = \sum_{i=1}^n w_i x_i + b$$

여기에서 \square 은 신경망의 각 층을, \square 은 층의 개수를, 그리고 \square 은 각 층에서의 비선형 활성화 함수(activation function)를 의미한다. \square 와 \square 는 각각 FNN의 입력과 출력을 나타낸다.

2장에서 묘사한 음향파를 임의의 시공간과 초기 조건에 대해 풀기 위해 입력 \square 을 4차원의 \square 로 정의하고 각 차원의 입력변수를 위한 학습 데이터는 각각 주어진 구간 $[-50, 50]$, $[0, 50]$, $[5, 15]$, $[100, 600]$ 에서 균등하게 분포하도록 추출했다.

위 FNN 모델(\square)은 다음과 같은 mean-square error (MSE) 기반의 손실 함수를 통해 학습, 즉 최적화가 이루어 진다:

$$L = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

여기서 \square 와 \square 는 각각 학습 데이터 \square 에서의 시뮬레이터의 응력 솔루션과 \square 의 솔루션을 의미한다.

4. 대칭성 조건

한편, \square 과 정확히 동일한 구조를 가지고 있는 FNN 모델을 대칭성 조건을 더해 학습 시킬 수 있다. 새로운 모델 \square 은 기존의 MSE에 대칭성 잔차(residual)를 함께 고려한 손실 함수 \square 로 학습된다:

$$L = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{i=1}^n |r_i|$$

$$r_i = y_i - \hat{y}_i$$

여기에서 눈 여겨 볼 점은 두 번째 항인 대칭성 잔차가 주어진 학습 데이터에 의존하지 않는다는 것이다. 주어진 구간에서 균등한 간격으로 뽑은 시뮬레이션 학습 데이터와는 무관하게, 주어진 구간 안팎에서 임의의 입력 값에 대해 대칭성 잔차를 계산할 수 있다. 시뮬레이션과 무관하기 때문에 입력 값 개수(M)의 제한 또한 없이 잔차 계산이 가능하다. 이는 학습 데이터로의 overfitting을 방지해 주며 모델의 일반성 능력 (generality ability)를 향상시켜 줄 수 있다.

아래 그림 1과 2는 각각 \square 과 \square 의 결과를 보여준다. 이는 초기 조건의 너비 $w = 10$, 시간 $t = 500$ 에서의 결과이다. \square 와 \square 모두 R-squared 값은 0.99 이상의 값을 보여준다. 그러나 상대 MSE 오차값은 각각 5.23×10^{-2} , 3.28×10^{-3} 으로, 한 차수(order) 이상의 차이를 보이며 대칭성과 파형의 유지에서도 다른 양상을 드러낸다. 구조적으로 동일한 모델에 대해서 대칭성 잔차가 학습을 개선시킴을 확인할 수 있다.



[그림 1 일반적인 FNN에서 얻은 음향파 응력]



[그림 2 대칭성 잔차를 활용한 모델의 음향파 응력]

5. 결론 및 향후 연구

이 연구에서는 임의의 공간 위치, 시간, 그리고 초기 펄스에 대해 음향파 전파를 실시간으로 예측하기 위한 인공신경망을 구성했다. 동일한 구조의 모델과 학습 데이터를 가지고 있을 때 더 효과적인 학습을 유도하기

위해 대칭성 잔차를 더한 손실 함수를 고려하고 그 영향을 평가했다. 대칭성 잔차를 고려한 모델은 추가적인 학습 데이터 없이 더 정확한 예측 솔루션을 산출했다. 또한 물리적으로 만족해야 하는 파형의 대칭성이나 부드러움(smoothness) 역시 더 뛰어난 결과를 보여준다.

현재 고려한 모델은 임의의 초기 펄스 조건에 대한 결과를 내기 위해 펄스의 너비(w)를 모델의 입력 변수를 사용하고 있으나 이는 학습 데이터 처리에 있어 비효율적이다. 음파의 중첩 이론(superposition principle)을 고려해 너비를 입력에서 제외하면서도 임의의 초기 조건에 대응할 수 있는 모델로 확장시킬 수 있으리라 기대한다. 또한 음향파에 관련된 다른 물리적 조건(constraint)이 인공지능망 모델의 학습과 성능에 미치는 영향도 향후 연구에서 자세히 다루어야 할 것이다.

ACKNOWLEDGMENT

본 연구는 한국원자력연구원 주요사업인 “하나로 및 연구시설 운영 지능화 플랫폼 구축”(과제번호 524450-22)의 일환으로 수행되었습니다.

참 고 문 헌

[1] Leonardo Gabrielli, György Fazekas, and Juhan Nam, Special Issue on Deep Learning for Applications in Acoustics: Modeling, Synthesis, and Listening, *Appl. Sci.*, 11, 473, 2021.

[2] Michael J. Bianco, Peter Gerstoft, James Traer, Emma Ozanich, Marie A. Roch, Sharon Gannot, and Charles-Alban Deledalle, Machine learning in acoustics: Theory and applications, *J. Acoust. Soc. Am.* 146 (5), 2019.

[3] Samuel J. Raymond, David J. Collins, Richard O’Rourke, Mahnoush Tayebi, Ye Ai, and John Williams, A deep learning approach for designed diffraction-based acoustic patterning in microchannels, 10:8745, 2020.

[4] M. Raissi, P. Perdikaris, and G. E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378:686–707, 2019.

[5] B. Moseley, A. Markham, and T. Nissen-Meyer,

Solving the wave equation with physics-informed deep learning, arXiv:2006.11894v1

이상탐지를 위한 Quantile Autoencoder

서호건, 류승형, 임지연, 서정훈, 유용균

¹한국원자력연구원, ²SI Analytics, Co.

hogeony@kaeri.re.kr, ashryu@kaeri.re.kr, jyyim@kaeri.re.kr, jhseo@si-analytics.ai, ygyu@kaeri.re.kr

Quantile Autoencoder for Anomaly Detection

Hogeon Seo¹, Seunghyoung Ryu¹, Jiyeon Yim¹, Jeonghoon Seo², and Yonggyun Yu¹

¹Korea Atomic Energy Research Institute, ²SI Analytics, Co.

요약

이상 탐지(anomaly detection: AD)는 다양한 산업 분야에서 시설물 및 시스템을 관리에 필수적인 기술이다. 최근 심층신경망을 활용한 이상탐지 기법(Deep Anomaly Detection: DAD)이 효과적임을 보여주는 연구들이 제시되어 왔다. 보편적으로 DAD는 입력된 데이터와 재구성된 데이터의 차이 또는 정상적인 경우로 정의된 클러스터 중심으로부터의 거리를 이상점수(anomaly score)로 사용한다. 그러나 이러한 측정항목은 데이터의 정상적인 조건에서의 다양성을 고려하지 않고 있다는 한계가 있다. 본 연구에서는 데이터의 불확실성(data uncertainty)을 고려하기 위한 새로운 DAD 방법으로 Quantile Autoencoder (QAE)를 제안한다. QAE는 재구성 오차 뿐 아니라 재구성 오차의 분포에서의 두 분위수 범위를 채널별 데이터 불확실성으로 함께 고려하여 이상 점수를 산출한다. 이러한 접근법은 이상점수 분포의 폭을 좁혀 정상 표본과 비정상 표본의 점수 분포를 더 멀어지게 하여 이상탐지 성능 향상에 기여한다. 제안된 QAE의 성능을 다양한 데이터셋으로 검증한 결과, 벤치마크 결과보다 높은 성능을 보였다.

1. 서론

이상 탐지(anomaly detection: AD)는 데이터 수집 또는 연속 데이터 전송 중 [1]에 정상과 비정상을 구분하는 작업으로써, 금융 사기 탐지 [2, 3], 네트워크 보안 [4-6], 비디오 감시 [7, 8], 의료 진단 [9-11], 센싱 [12-14] 등의 분야에서 광범위하게 활용되고 있다. 딥러닝 기술의 고도화는 이상탐지 분야에도 고무적인 영향을 미치고 있다. 특히, DAD(Deep Anomaly Detection)는 복잡한 이상탐지 조건에서 향상된 성능을 보여줬다 [15].

DAD는 지도(supervised), 비지도(unsupervised) 및 준지도(semi-supervised) 학습을 기반으로 할 수 있다. 정상 및 비정상 데이터가 모두 충분하고 레이블이 정리되어 있다면 지도 이상탐지를 사용할 수 있다. 그러나 대부분 비정상 샘플이 부족하고 더욱이 레이블이 지정되지 않은 상황이 많기 때문에 비지도 또는 준지도 이상탐지가 널리 적용되고 있으며 주로 모델은 Autoencoder (AE)를 기반으로 하는 경우가 많다. 이상탐지는 입력과 모델로부터 재구성된 데이터 간의 차이로부터 이상점수를 산출하고, 이상점수가 임계값을 초과하는지 여부를 확인하여 이상 여부 판정할 수 있다.

한편, 정상 데이터에서도 어느 정도 범위의 변화가 있을 수 있으므로 DAD를 통한 이상 점수에 산출함에 있어서 데이터 불확실성을 추가로 채택하는 것이 필요하다. 불확실성에는 인식론적 불확실성(epistemic

uncertainty)과 내재적 불확실성(aleatory uncertainty)이 있다. 축소 가능한 불확실성 또는 모델 불확실성으로도 알려진 인식론적 불확실성은 딥러닝 과정에서 모델 매개변수의 편차에서 비롯된다. 내재적 불확실성은 데이터 자체에서 존재하는 임의성에서 비롯되며, 동일한 대상에 대한 데이터의 편차에서 발생하므로 내재적일 뿐만 아니라 해소가 곤란하다. 때문에 데이터의 내재적 불확실성은 해소 불가능한(irreducible) 불확실성이라고 한다. 최근 인식론적 불확실성을 고려하고자 Monte-Carlo (MC) Dropout을 사용한 여러 DAD들이 이상탐지의 성능 향상을 보여줬다. 그러나 정상 및 비정상 데이터의 분류를 위한 이상탐지 모델임에도 불구하고 데이터의 내재적 불확실성을 고려하는 것은 DAD에 적극적으로 활용되지 않고 있다.

이 연구에서 우리는 비유적 불확실성 향을 고려하기 위해 Quantile Autoencoder (QAE) [16]를 도입하는 새로운 DAD 프레임워크를 제안한다. QAE에서 고려되는 불확실성은 정상 데이터의 채널별 일관성, 즉 정상 데이터 편차가 비정상 데이터보다 상대적으로 작다는 전제를 기초로 하여 재구성 오차의 분포의 두 분위수 사이의 범위이다. 비정상 샘플에서 재구성된 데이터는 정상 샘플에 대해 QAE가 훈련된 후 정상 샘플보다 채널별 불확실성이 더 높은 경향이 있다. 재구성 오차 및 채널별 데이터 불확실성을 고려한 QAE의 효과를 다양한 데이터 세트를 사용하여 평가한 바, 제안된 QAE는 이상탐지에서 상당한 성능 향상을 보여줬다.

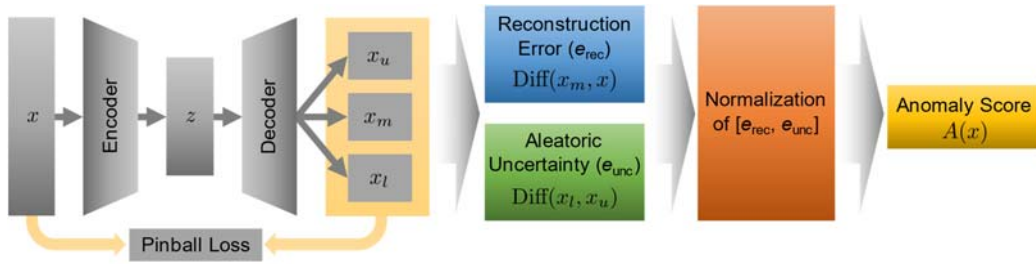


그림 2 AD에 대해 제안된 QAE 프레임워크

표 1 QAE의 이상탐지 성능평가 결과

Modality	Dataset	N	dx	dz	Class Count	Domain	Anomaly Target	without Normalization		Normalization		
								AE MSE Loss	QAE MAE Loss	QAE MSE Loss	QAE MAE Loss	QAE MSE Loss
Uni	RARM	20,221	6	3	2	Robotics	Malfunctions	68.7	78.2	78.1	80.3	80.4
Uni	NASA	4,687	33	10	2	Astronomy	Hazardous Asteroids	71.9	68.8	71.0	72.6	72.7
Uni	MI-F	25,286	58	23	2	CNC Milling	Machine not completed	60.7	50.4	47.4	73.0	74.6
Uni	MI-V	23,125	58	23	2	CNC Milling	Workpiece out of specification	89.7	68.4	69.7	92.3	92.0
Uni	EOPT	90,515	20	6	2	Storage System	System failures	61.0	71.6	70.6	61.5	61.6
Multi	SNSR	58,509	48	17	11	Electric Currents	Defective conditions	61.3	59.9	62.4	66.6	67.3
Multi	OTTO	61,878	93	66	9	E-commerce	Types of product	61.7	61.9	58.6	59.4	60.7

2. 제안 기법

QAE는 재구성 오차와 재구성 오차 분포의 하위 및 상위 분위수 범위인 채널별 데이터 불확실성 모두에서 이상점수를 얻는다. 이러한 이상점수 산출법은 이상점수 분포의 폭을 좁혀 정상과 비정상 간의 이상점수 분포를 더 멀어지게 하여 AD 성능 향상에 기여한다.

- **불확실성의 사용:** 앙상블의 이점으로 인해 변칙 점수에 사용되는 소스가 다양할수록 이상탐지 성능이 향상된다. 내재적 불확실성은 DAD 기반 이상탐지에 기여할 수 있는 효과적인 요소이다.
- **내재적 불확실성의 사용:** AE가 잠재 공간 z에서 정규성의 특징을 학습할 수 있는 경우 z로부터의 재구성은 정규 데이터의 각 채널에 대해 특정 수준의 내재적 불확실성을 갖게 된다. 그러나 네트워크는 비정상 데이터에 노출되지 않기 때문에 비정상 데이터에 대한 채널별 일관성이 정상 데이터의 수준을 초과할 수 있다. 이러한 차이를 활용하면 이상탐지의 성능 향상에 기여할 수 있다.
- **QAE 사용:** 내재적 불확실성은 여러 분위수를 함께 출력하도록 설계된 QAE 모델을 훈련함으로써 채택할 수 있으며, 이는 각 분위수 간의 비선형적 관계로 인해 다중 작업 학습과 유사한 이점이 있다.

3. Quantile Autoencoder (QAE)

QAE는 하한, 상한 및 중위 분위수 모두를 출력한다. 비정상 분위수의 하위 분위수와 상위 분위수 사이의 범위는 잠재 공간의 특징이 정상 데이터에 대해서만 학습되었기 때문에 비정상의 경우는 정상보다 해당 범위가 더 큰 경향이 있다. 이상점수는 재구성 오차와 내재적 불확실성에 해당하는 분위수 차로부터 산출된다.

표 2 QAE의 이상탐지 성능 비교

Method	Model	Dataset							
		optdigits	pendigits	satellite	letter	featuredmnist	ionosphere	speech	
Machine Learning Methodology	IForest	71.5	96.2	68.6	60.0	79.3	84.2	44.2	
	LODA	71.4	95.1	72.6	62.2	59.6	85.3	44.1	
	LOF	61.2	85.1	57.9	84.2	84.0	90.0	47.9	
	DTM2	56.1	95.8	76.8	85.6	86.2	92.8	48.3	
	kNN	53.7	95.0	76.5	86.2	86.1	92.8	48.3	
	kthNN	84.2	97.1	79.6	81.0	86.2	92.0	47.9	
Deep Learning Methodology	OCSVM	55.8	93.5	65.0	55.7	83.5	81.2	-	
	DSVDD	50.6	61.3	63.1	46.5	53.8	73.5	-	
	DAGMM	29.0	87.2	66.7	43.3	65.2	46.7	-	
	SO-GAAL	48.7	25.7	64.0	60.1	79.5	78.3	-	
	AE	90.7	68.5	57.5	82.9	80.2	82.1	-	
	VAE	76.8	93.1	60.3	51.7	84.7	76.0	-	
	RCA	91.4	90.3	69.0	79.5	82.7	79.6	-	
	QAE	96.9	99.1	86.4	89.0	90.6	95.8	55.5	

4. Experiments

제안된 QAE의 성능을 검증하는데 사용된 데이터 세트는 표 1에 성능 비교 결과와 함께 명시하였으며, 데이터셋 정보는 RAPP[17]를 참고하였다. AE 성능 결과는 RAPP의 성능 결과이며, QAE는 Normalization과 손실 함수에 따라서 4 가지 조건에 대해서 성능을 표기하였다. 재구성 오차에 대한 Normalization은 각 채널별로 나타나는 오차의 특성이 불균일 하기 때문에 이를 보완하고자 Mahalanobis Distance를 산출하여 Normalization을 수행하였다. 재구성 오차에 대해 Normalization이 없는 QAE (A_Q)와 Normalization이 있는 QAE (A_{QN})에 대해서 손실함수를 MAE (mean absolute error)로 하는 경우와 MSE (mean square error)로 하는 경우로 나뉘볼 수 있다. 대체로 QAE가 RAPP의 AE (A_R)보다 높은 AUROC를 보여주고[17], 특히 MSE를 손실함수로 하는 A_{QN} 은 표 2에서 보여지는 바와 같이 다른 이상탐지 방법론들과 성능을 비교하였을 때, 대부분 데이터셋에 대해서 가장 높은 성능을 보여줬다.

4. 결론

QAE (A_Q , A_{QN})는 AE (A_R)보다 더 높은 AUROC를 보여주며, 이는 이상점수 산출 시 재구성 오차와 내재적 불확실성 항을 모두 사용하는 것이 이상탐지 성능을 향상시킨다는 것을 보여준다. 또한 A_{QN} 은 특히 대부분의 경우 최고의 성능을 보여주며, 이는 이상점수 산출 시 정규화가 이상탐지 성능 향상에 기여함을 의미한다.

ACKNOWLEDGMENT

본 연구는 한국원자력연구원 주요사업인 “하나로 및 연구시설 운영 지능화 플랫폼 구축”(과제번호: 524450-22)의 일환으로 수행되었습니다.

참고문헌

- [1] Grubbs, Frank E. "Procedures for detecting outlying observations in samples." *Technometrics* 11, No. 1, 1969.
- [2] Pawar, Amruta D., Prakash N. Kalavadekar, and Swapnali N. Tambe. "A survey on outlier detection techniques for credit card fraud detection." *IOSR Journal of Computer Engineering* 16, No. 2, 2014.
- [3] Porwal, Utkarsh, and Smruthi Mukund. "Credit card fraud detection in e-commerce: An outlier detection approach." *arXiv preprint arXiv:1811.02196*, 2018.
- [4] Lee, Doyup. "Anomaly detection in multivariate non-stationary time series for automatic DBMS diagnosis." In *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2017.
- [5] Aoudi, Wissam, Mikel Iturbe, and Magnus Almgren. "Truth will out: Departure-based process-level detection of stealthy attacks on control systems." In *Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security*, 2018.
- [6] Kwon, Donghwoon, Hyunjoo Kim, Jinhoh Kim, Sang C. Suh, Ikkyun Kim, and Kuinam J. Kim. "A survey of deep learning-based network anomaly detection." *Cluster Computing* 22, No. 1, 2019.
- [7] Ravanbakhsh, Mahdyar, Moin Nabi, Enver Sangineto, Lucio Marcenaro, Carlo Regazzoni, and Nicu Sebe. "Abnormal event detection in videos using generative adversarial nets." In *2017 IEEE international conference on image processing (ICIP)*, IEEE, 2017.
- [8] Kiran, B. Ravi, Dilip Mathew Thomas, and Ranjith Parakkal. "An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos." *Journal of Imaging* 4, No. 2, 2018.
- [9] Schlegl, Thomas, Philipp Seeböck, Sebastian M. Waldstein, Ursula Schmidt-Erfurth, and Georg Langs. "Unsupervised anomaly detection with generative adversarial networks to guide marker discovery." In *International conference on information processing in medical imaging*, Springer, Cham, 2017.
- [10] Baur, Christoph, Benedikt Wiestler, Shadi Albarqouni, and Nassir Navab. "Deep autoencoding models for unsupervised anomaly segmentation in brain MR images." In *International MICCAI brainlesion workshop*, Springer, Cham, 2018.
- [11] Kuzin, Tomás, and Tomás Borovicka. "Early Failure Detection for Predictive Maintenance of Sensor Parts." In *ITAT*, 2016.
- [12] Zhao, Pushe, Masaru Kurihara, Junichi Tanaka, Tojiro Noda, Shigeyoshi Chikuma, and Tadashi Suzuki. "Advanced correlation-based anomaly detection method for predictive maintenance." In *2017 IEEE International Conference on Prognostics and Health Management (ICPHM)*, IEEE, 2017.
- [13] Beghi, Alessandro, Luca Cecchinato, Chiara Corazzol, Mirco Rampazzo, Francesco Simmini, and Gian Antonio Susto. "A one-class svm based tool for machine learning novelty detection in hvac chiller systems." *IFAC Proceedings Volumes* 47, No. 3, 2014.
- [14] Mohammadi, Mehdi, Ala Al-Fuqaha, Sameh Sorour, and Mohsen Guizani. "Deep learning for IoT big data and streaming analytics: A survey." *IEEE Communications Surveys & Tutorials* 20, No. 4, 2018.
- [15] Chalapathy, Raghavendra, and Sanjay Chawla. "Deep learning for anomaly detection: A survey." *arXiv preprint arXiv:1901.03407*, 2019.
- [16] Seo, Hogeon, Seunghyoung Ryu, Jiyeon Yim, Junghoon Seo, and Yonggyun Yu. "Quantile Autoencoder for Anomaly Detection." In *AAAI 2022 Workshop on AI for Design and Manufacturing (ADAM)*. 2021.
- [17] Kim, Ki Hyun, Sangwoo Shim, Yongsub Lim, Jongseob Jeon, Jeongwoo Choi, Byungchan Kim, and Andre S. Yoon. "Rapp: Novelty detection with reconstruction along projection pathway." In *International Conference on Learning Representations*, 2019.

공정 Data를 활용한 AI 감마 보정 알고리즘

삼성디스플레이 김민원

Minweun.kim@samsung.com

Gamma correction AI algorithm Using process parameters of Fab

SamsungDisplay Kim Minweun

Minweun.kim@samsung.com

요약

디스플레이 시장의 고속 구동 적용으로 복수의 주파수 적용 모델이 증가하였고, 주파수 전환 간 광 특성 편차 축소가 중요해지고 있다. LTPS 구조의 Display의 경우 별도의 감마 보정 없이는 주파수 전환 간 광 특성 편차를 줄일 수 없어, 주파수 전환 기술에는 각 주파수 별 감마 보정이 필수로 적용 되어야 하며, 이를 위해서는 공정 Tact Time 이 추가되어 공정 장비 투자 비용이 발생하게 된다. 이를 극복하기 위해 모듈 공정 big data 를 machine learning 하여 활용하는 감마 보정 알고리즘을 개발하여 사용하고 있는데, 정확도를 높이기 위해 공정 산포의 원인이 되는 Fab 공정의 공정 Data를 취득하여 AI 학습시켜 보려 한다.

OLED 모듈의 Fab 공정은 회로 구성을 하는 Back Plane 과 발광층을 구성하게 하는 증착 공정으로 크게 두 공정으로 구분할 수 있고, 원인계에 대해 세분화를 하자면 Back Plane 에서는 배선 굵기 및 각 layer 의 두께 편차를 원인으로 생각할 수 있을 것이고, 증착 공정에서는 각 layer별 증착 두께를 원인계로 판단했다. 따라서 해당 원인계들의 영향을 끼칠 수 있는 parameter 로 공정 parameter 를 선택하였고, Black plane 공정과 증착 공정의 parameter 약 7000개 이상 data 를 활용하여 AI 학습 시켰다. AI 알고리즘은 numeric data 기반 regression 알고리즘 중 성능 비교를 통해 XGBoost를 사용하였고, Fab data 를 적용한 결과 0.014%의 성능 개선 결과를 얻었다.

1. 서론

고속 구동에 대한 시장 요구는 움직이는 화면에서 끊김 없는 화면 구현을 목적으로 지속적으로 요구되어 왔다. 기존 60Hz를 기본 환경에서 120Hz 이상의 고속 구동을 요구하고 있고, 이는 특히 Gaming 환경에서 중요한 marketing point로 활용되고 있으며, 그림1과 같이 Gaming 시장에서 Mobile 의 비중이 지속적으로 성장함에 따라 Mobile AMOLED에서 고속 구동 기술이 필요하게 되었다.

2012-2021 GLOBAL GAMES MARKET REVENUES PER SEGMENT 2012-2021 WITH COMPOUND ANNUAL GROWTH RATES




그림1. Gaming 시장에서 Mobile 비중 확대[1]

Mobile의 경우 한정적인 battery 용량으로 인하여 소비전력도 중요한 요소로 작용하여, AP의 소비전력이 높은 고속 주파수 단일 mode 사용이 아닌, 저주파와 고주파를 전환하며 정지화면에서는 저주파, 움직임이 많은 화면에서는 고주파 전환 시나리오를 요구하고 있어, 복수의 주파수 구현이 필요하다. LTPS(Low Temperature Polycrystalline Silicon) 구조의 경우 Hysteresis, Leakage 등의 영향으로 인해 주파수 전환간 광특성 편차가 발생하게 되는데(그림2), 광특성 편차가 JND(Just Noticeable Difference) 기준 이상 커지게 되면 깜빡임 등으로 시인되어 주파수 변화를 인지하게 되므로, 주파수 별 감마 보정을 통해 주파수 전환 간 광특성 편차가 인지되지 않도록 해야한다.




그림2. 주파수 변화에 따른 광 파형 변화

이를 구현하기 위해서 복수의 감마 전압 보정이 필요하게 되고 이는 결국 추가 공정 Tact Time 이 필요하게 되어 동일 생산량을 위해 생산 라인 감마 보정 설비 투자가 이루어 져야 한다.

이런 문제를 극복하기 위해 생산 모듈의 공정 data 를 machine learning을 통해 구동 특성 학습 추가하여 0.014%의 성능 개선 효과를 확인하였다.

2. 본 론

현재 각 휘도 단계별 감마 전압 보정은 모듈 site에서 계측된 data 기반의 AI 알고리즘을 사용하고 있다. (그림 3)




그림 3. 현재 사용 중인 AI 시스템




그림 4. Fab data 활용 시스템

현재 방식에서 문제가 되는 것은 특성에 대한 사전 예측이 되지 않고, 실시간 계측에 따른 동작인 부분으로 이는 Fab 산포에 민감한 대응이 어려운 점이 있다. Fab 에서의 이상점, 혹은 산포를 대응할 수 있는 방법에 대해 고안한 결과, Fab 에서 얻을 수 있는 Numeric data 를 활용하려는 접근을 시도하였고, Fab 에서 얻을 수 있는 Numeric data 는 공정 Setting parameter, 특성 계측값 으로 확인 하였다.

구동 회로를 구성하는 Back Plane 공정과 발광층을 증착하는 증착공정에서 7K이상의 setting parameter 와 계측값들을 취득하여, 각 휘도별 감마 전압과 매칭하여 학습하기로 하고, Data 를 수집하였다.

각 Data 를 수집하여 Cell ID 매칭하여 data 정렬한 후, Sigma Filter 를 이용하여 이상data 를 제거한 후, Numeric Regression 알고리즘들을 적용하여 평가한 결과, XGBoost 알고리즘[2]이 가장 높은 정확도를 보였으며, 개선 시스템(그림4) 에서 0.014% 의 정확도 향상 결과를 확인 하였다.

3. 결 론

고속 구동을 위한 복수의 감마전압 셋팅에 의한 공정 Tact Time 감소를 위해 감마 전압 AI 예측 정확도 향상을 위해 Fab data 활용한 결과, 0.014%의 정확도 향상 결과를 얻었다.

참 고 문 헌

- [1] Newzoo Game market report. (2018)
- [2] XGBoost: A Scalable Tree Boosting System (2016.arXiv:1603.02754 [cs.LG])

이상 지표 공간에서의 지도학습을 이용한 생산 설비 이상 검출 개선 및 적용

박경태

삼성디스플레이

Ktman.park@samsung.com

Improvement and application of abnormality detection in production facilities using supervised learning in anomaly indicator space

Kyongtae Park

Samsung Display

요 약

설비의 이상 점을 미리 발견하여 조치하는 것은 생산시설 관리의 핵심 기술이다. 그러나 해외 모듈 공장에서는 각 공정을 구성하는 동일 또는 유사한 설비를 다수의 평행한 라인 형태로 구성되어있다. 각각 다양한 모델을 생산하는 설비의 상태를 정확하게 모니터링 하고 감시하는 것은 다소 어려운 일이다. 그 주요 이유 중에 하나는 설비의 상태나 기준이 서로 상이하여 이상 상태의 기준을 잡기가 어렵고, 또한 불량에 직결된 이상 상태와 관계가 없는 이상상태를 구분하기가 어렵다. 본 논문에서는 각각 설비의 상이 한 상태 중 가급적 불량과 관련된 이상 검출을 적용하려고 한다. 그것을 위해서 다수의 이상 감지 머신 을 1차로 이용하여 이상상태를 검출한 후 다수의 이상점 지표를 이용한 이상 지표 공간(anomaly indicator space)에서 불량 이력과의 그 유사성 비교를 통해서 기존 불량 이력과의 비교를 통해서 불량 관련된 이상만 선택적으로 최종 이상 발의를 하도록 구성하였다. 다만 이상 발의 강도가 매우 높은 경우 에는 예외로 하였다. 이것의 의미는 설비의 이상 감지를 불량 이력과 관계없는 허위 이상점 발의에 지친 사용자는 다소 유출의 위험이 소량 있더라도 불량에 직결된 이상점 만 알려주는 이상점 감지가 더 의미가 있다고 산업 이용자는 요구하고 있음을 알 수있다.

1. 서 론

다수의 모듈 공정 설비를 운영하는 해외 법인에서의 각각 설비 상태 점검 및 이상점 모니터링은 매우 중요한 업무이다. 각 공정을 구성하는 동일 또는 유사한 설비를 다수의 평행한 라인 형태로 구성되어있다. 각각 다양한 모델을 생산하는 설비의 상태를 정확하게 모니터링 하고 감시하는 것은 다소 어려운 일이다. 그 주요 이유 중에 하나는 설비의 상태나 기준이 서로 상이하여 단일 이상 감지 머신러닝으로는 이상 상태의 기준을 잡기가 어렵고, 또한 불량에 직결된 이상 상태와 관계가 없는 이상 상태를 구분하기가 어렵다.

2.1 다수 이상 점검 알고리즘 적용

관련 한계점을 극복하기 위해서 다수의 상이한 방식으로 이상점을 점검하는 머신러닝의 출력을 이용하여 그 여러 출력 값(이상점 값)을 종합하여 최종 이상점을 판단하는 AI의 구성 하였다. (Fig.1)

그러나 이러한 경우에는 각각의 이상점 시가 잘 감지하지 못하는 경우에도 종합하여 판단하면 다각적인 이상점 관리가 가능하다.

그러나 이러한 앙상블 구조의 이상점 감지 시스템의 문제점은 불량에 직결된 이상점과 관련이 없는 이상점을 구분할 수 없다는 문제점이 있다. 이러한 특성은 사용자의 신뢰를 쉽게 잃어버리고 결국 그 활용성이 급격하게 감소하게 된다.




Fig.1 다수의 이상감지 알고리즘으로 구성된 설비 이상점 감지 AI 형태

2.2 이상 지표 공간(anomaly indicator space)

과거 불량 이력과 비교하여 이상점을 구분하려면 각 설비의 특성이 균일하지 않고 상이하어 이 구분 성능이 매우 부족하여 한계가 있다. 그러한 상세 특성이 다른 한계점을 직접 비교 보다는 이상 지표 공간(여러 이상시가 만든 다수의 지표를 기반으로 한 공간)에서 불량 이력과 비교를 하면 그러한 설비 간의 차이점을 감안한 이상점 공간에서의 비교가 더 가능하다. (Fig.2)

이상점 인지하는 알고리즘별로 그 index값의 경향성이 동일하지 않고 일정 독립성이 있으므로 그 space에서의 경향이 의미가 있음을 확인할 수 있다 (Fig.3)

결국 이러한 이상 지표 공간에서의 불량 이력을 저장하고 이러한 이력 공간에 가깝게 나타난 이상점만 진성 위험으로 구분하여 알려주는 구조로 구성하여 적용하였다. (Fig.4)

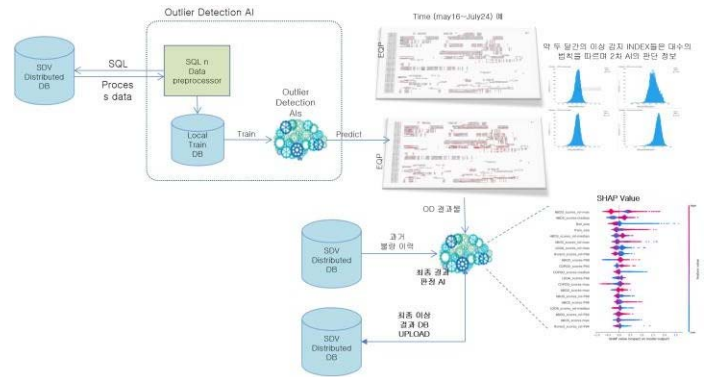


Fig.4 이상 지표 공간에서 과거 불량 이력을 구분하는 classification을 구성하여 불량 관련 이상점만 구분하도록 구성하였다.

3. 결론

다수의 생산설비의 이상 점 감지는 매우 중요한 SI의 TASK에 속하지만, 실제로 이를 적용하기 위해서는 두가지 어려움이 있다. 다수의 생산설비에서 나오는 값들이 동일한 설비라도 특성 간의 차이가 있으며 그에 따른 진성 가성 구분의 어려움이 있다. 두번째는 이상점이라고 판단되어도 불량과 관련된 진성 가성 불량을 구분하기가 어렵다. 이러한 두가지 문제점을 개선하기 위해서는 이상 지표 공간이라는 곳에 mapping하여 이곳에서 설비 간의 차이를 최소화하고 과거 불량 이력 간의 구분을 하도록 하여 그 한계점을 극복하였다. 그러나 과거 이력을 기반으로 이상 지표를 판단하기 때문에 특성변화에 따른 구분력 저하 한계는 개선안이 필요하다. 또한 이상 지표 공간으로 변동시 정보손실에 따른 구분력 감소도 개선이 필요하다.

References

- [1] Zheng Li, Yue Zhao, Nicola Botta, Cezar Ionescu, Xiyang Hu "COPOD: Copula-Based Outlier Detection" 2020 IEEE International Conference on Data Mining (ICDM)
- [2] Tang, J., Chen, Z., Fu, A. W. C., & Cheung, D. W. (2002). Enhancing Effectiveness of Outlier Detections for Low Density Patterns. In Pacific-Asia Conf. on Knowledge Discovery and Data Mining (PAKDD). Taipei. pp. 535-548. DOI: 10.1007/3-540-47887-6_53
- [3] S. Jiang and Q. An, "Clustering-Based Outlier Detection Method," 2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery, 2008, pp. 429-433, doi: 10.1109/FSKD.2008.244.




Fig.2 이상 지표 공간에서의 각각 설비 분포




Fig.3 이상 지표 공간의 영향도를 나타낸다. 해당 공간의 영향도가 각각 독립적임을 알 수가 있다.

Denoising Encoder를 이용한 디스플레이 외광 반사 검사 이미지 불량 분류 기술

Display external light reflection inspection image defect classification technology using Filtered Denoising Encoder

요 약

디스플레이 ELA (Excimer Laser Annealing) 공정에 의해서 발생하는 얼룩(Mura)을 불량을 검출하기 이를 위해서 외광 반사 검사 이미지를 활용하여 검출하는 것은 조기에 불량을 검출할 수 있으므로 매우 중요하다. 그러나 그 외광 반사 검사 이미지는 불량과 관계없는 다양한 형태의 노이즈도 많이 포함되어 사람이 검사를 하더라도 매우 숙련된 엔지니어만이 가능하고, 기존의 CNN기법을 이용해서 불량을 검출하려는 시도는 그 성능에 한계가 있었다. 본 논문에서는 외광 반사 검사 이미지와 실제 최종 불량이 확인된 부분만 정제한 이미지를 Denoising Encoder로 학습하여 그 관련 불량만 특성을 추출하도록 하고, encoder출력을 Input으로 최종 CNN으로 불량 유무를 Classification 할 수 있게 하였다. 그 결과 기존대비 월등한 성능적인 개선을 하였다. 그 의미는 제조 공정에서 특성 추출을 하기 위해서 Denoising Encoder 입출력을 동일한 검사 이미지로 학습하는 것보다, 기존 검사 이미지를 입력으로 하고 노이즈를 제거하고 명확한 불량 정보를 갖는 처리 후 이미지를 Denoising Encoder의 출력으로 학습시켜야 노이즈 제거 및 그 관련 특성 추출에 효과적인 것을 확인할 수 있었다.

1. 서 론

디스플레이 공정에서는 모듈 전 모든 LTPS(Low-Temperature Polycrystalline Oxide) 공정이 끝난 후 AVI(auto vision inspection)에서 불량 유무를 전류를 인가하여 확인한다. 하지만, 최종 AVI까지 가는 수 주의 시간 동안 ELA 선형 불량의 유무에 대해서는 낮은 정합도의 몇 가지 방어선만이 존재하였다. 그 이유는 인가 전류 검사 이미지와 동일한 알고리즘을 외광 반사 검사 이미지에 활용하고 있기 때문이다. 반사 검사 이미지는 노이즈가 많아 전류 이미지와 선형 형태의 Mura 시인성에서 큰 차이를 보인다. 본 논문에서는 이 부분을 개선하기 위해 반사 검사 이미지에 Denoising Encoder 을 활용하는 방법을 소개한다.

2. CNN 기반 불량 판정

외광 반사 검사 이미지를 어떠한 전처리 없이 VGG 19를 활용하여 학습하였다(Fig. 1). 그 결과는 Accuracy 0.5 수준으로 어떠한 정합성도 보이지 못했다. 이러한 낮은 정합도의 가장 큰 원인은 선형 형태의 Mura 시인성이 매우 떨어진다는 것이다. 외광 반사 검사 이미지의 경우 숙련된 전문 엔지니어도 어떠한 선형

Mura가 문제가 되는지, 불량으로 이어질 것 같은지를 판단하는 것이 매우 어렵다. 즉, 노이즈가 많아 사람조차 구분하기 힘든 높은 난이도의 문제를 알고리즘에 부여하였기 때문에, 깊은 Layer의 알고리즘을 활용하더라도 학습이 거의 진행되지 못하였다. 따라서, 이 부분을 개선하기 위해 아래 방법을 새롭게 고안하였다.




Fig. 1 CNN 기반 Algorithm 구조. Data의 Noise가 많아 Layer를 깊게 쌓아도 불량과의 정합성을 보이지 못하였다.

2. Denoising Encoder 기반 불량 판정

2.1 Denoising Encoder

외광 반사 검사 이미지의 경우 숙련된 엔지니어가 보더라도 Mura의 유무 및 불량 발생여부를 구분하기 매우 힘들었다. 따라서, 문제가 되는 Mura만을 따로 구분해 내는 작업이 필요하였다. 이를 위해 외광 반사 검사 이미지에서 실제 최종 불량이 확인된 부분만 정제한 이미지를 만들어내었다. 그 후 Denoising Encoder의 Input Image에는 어떠한 전처리를 하지 않은 원본 이미지를 넣고, Output Image에는 전처리를 통해 실제 최종 불량이 확인된 선형 Mura 부분만 정제한 이미지를 부여하였다(Fig. 2). 그 결과 Denoising Encoder가 학습하며 Encoder와 Decoder 사이의 Bottleneck에는 불필요한 정보가 Denoising된 Mura에 대한 핵심적인 정보만 담기게 된다.




Fig. 2 선형 Mura의 핵심적인 정보만 남기는 Denoising Encoder Algorithm 구조. Input과 Output을 동일하게 사용하는 경우와 달리, Input Image에는 노이즈가 많이 포함된 기존 반사 검사 이미지를 사용하고 Output에서는 불량 정보만 갖도록 처리한 이미지를 사용하여 denoising 및 feature extraction하도록 하였다.

2.2 CNN Classifier

이렇게 학습된 Denoising Encoder에서 Encoder만 떼내어, Encoder의 출력을 CNN의 Input으로 활용하게 하였다. 기존 Input Image는 문제가 되는 선형 Mura에 대한 정보가 부족한 상태였다면, Denoising encoder의 bottleneck에는 불필요한 정보 및 노이즈가 제거되어 최종 불량과 관계된 핵심적인 정보만이 담긴 상태이다. 이러한 Encoder의 Bottleneck을 Input으로 하는 CNN 모델을 Encoder 뒤에 추가하여 Classification을 진행하였다. (Fig. 3). 그 결과 Accuracy 0.9 이상의 높은 정합성 도출에 성공하였다.

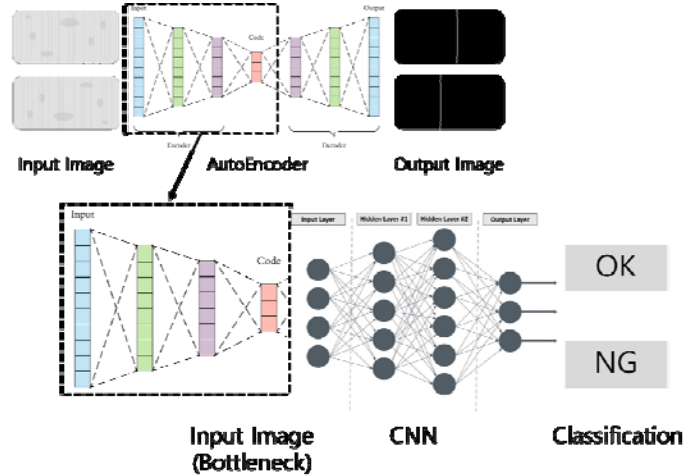


Fig. 3 Mura의 핵심적인 정보만 남기는 Denoising Encoder를 활용한 CNN Classification 구조. Noise를 제거하지 않은 Input과 달리, denoising이 되어있어 작은 layer에서도 높은 정합성을 보인다.

3. 결론

기존의 반사 광학 이미지는 노이즈가 많아 숙련된 엔지니어도 관련 불량을 구분하기 힘든 상태였다. 이로 인해, 기존 이미지를 단순하게 DeepLearning 모델에 적용하는 것은 효과를 거두지 못하였다. 따라서, 본 논문에서는 Denoising Encoder의 출력을 불량 정보만 갖도록 처리한 광학 이미지를 출력으로 학습하도록 하여 Input image의 광학 검사의 노이즈와 잘못된 정보를 전처리를 진행하는 방법을 고안하였다. 즉, 불량 정보만을 남기도록 Denoising Encoder를 제작한 후 Bottleneck이 일종의 Input이 되게 하게 하는 CNN Classification 모델을 개발하였다.

일반적으로 입력과 출력이 동일하게 Denoising Encoder를 학습시켜 latent learning을 시키는 방법보다는 명확하게 학습해야 하는 불량만을 선택하여 Denoising Encoder를 학습시키면 노이즈가 많고 정보가 명확하지 않아 학습의 어려움이 많은 경우 또는 숙련된 엔지니어도 구분하기 힘든 Mura의 경우에 본 논문에서 제시하는 방법이 효과적임을 확인할 수 있다.

References

- [1] Masci, Jonathan, Ueli Meier, Dan C. Ciresan and Jürgen Schmidhuber. "Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction." ICANN (2011).
- [2] C. Sun, M. Ma, Z. Zhao, S. Tian, R. Yan and X. Chen, "Deep Transfer Learning Based on Sparse Autoencoder for Remaining Useful Life Prediction of

Tool in Manufacturing," in IEEE Transactions on Industrial Informatics, vol. 15, no. 4, pp. 2416–2425, April 2019

[3] D. Neven, B. D. Brabandere, S. Georgoulis, M. Proesmans and L. V. Gool, "Towards End-to-End Lane Detection: an Instance Segmentation Approach," 2018 IEEE Intelligent Vehicles Symposium (IV), 2018, pp. 286–291

Display Panel 검사 이미지의 비지도 학습 Autoencoder 기반 신규 모델

우화성, 최국현, 홍권삼

삼성디스플레이

hwasing.woo@samsung.com, kookhyun.choi@saumsung.com, kshong@samsung.com

Mura Detection of Display Panel Using New Unsupervised Learning Autoencoder

Hwa Sung Woo, Kookhyun Choi, Kweon-Sam Hong

Samsung Display Co., Ltd.

요 약

개발 제품에서 발생하는 신규 얼룩을 검출하기 위해 본 논문에서는 비지도 학습 Autoencoder 알고리즘을 활용하여 평가하였다. 비지도 학습 Autoencoder 모델은 정상 이미지만을 활용하여 다양한 비정상 이미지를 검출할 수 있기 때문에 신규 얼룩에 대응할 수 있는 장점이 있다. 하지만 신제품 개발 과정에서 발생하는 얼룩은 그 발생 비율이 높아 기존 비지도 학습 Autoencoder 모델을 적용하는데 성능 저하로 어려움이 있었다. 데이터에 대수 불량 이미지가 있어도 효과적인 새로운 비지도 학습 Autoencoder 모델을 수립하고 그 성능을 검증하였다. 기존 모델 정합성이 78%로 떨어지는 얼룩 다발 이미지 데이터 조건에서도 새로운 모델은 90%의 높은 정합성을 보였다.

1. 서 론

Display 제품의 얼룩 자동 검출을 위해 최근 많은 AI 적용 사례가 있다. 적용된 AI 모델은 특정 불량 이미지를 모아 지도 학습을 통해 검출한다. [1, 2, 3, 4] 학습을 위해 사전에 불량 이미지가 충분히 확보하기 어려운 제조업의 특성 상 학습에 많은 노력이 든다.

이에 비해 양품 데이터만을 학습하여 불량을 검출하는 이상 탐지 모델인 Autoencoder는 데이터 수집의 용이성, 신규 불량 검출의 장점으로 다양하게 활용된다. [5, 6, 7] 다수의 양품 데이터는 제품 양산 과정에서 데이터를 손쉽게 확보할 수 있어 활용도가 높다.

양산 제품과 달리 신규 제품 개발 단계에서는 재료/구조/설계 변경에 의해 새로운 얼룩 발생 가능성이 높으며, 재료/구조/설계 기인 얼룩의 경우 발생 비율이 높다는 특징이 있다. 따라서 신제품 개발 단계에서는 사전 데이터 확보가 불가하여 지도 학습 AI 모델을 사용할 수 없고, 이상 탐지 비지도 학습 Autoencoder 모델을 사용할 경우 불량 데이터가 많아 검출 성능이 떨어진다. 본 논문에서는 이러한 조건에도 효과적인 새로운 이상 탐지 비지도 학습 Autoencoder 모델을 제안한다

2. 본 론

2.1. 이상 탐지 비지도 학습 Autoencoder 모델

아래 그림 1과 같이 주어진 입력 x 가 실수로 구성된 m 차원의 데이터일 때, 함수 f 는 m 차원의 x 를 입력 받아 식 (1)과 같이 n 차원의 z 로 변환하는 함수이다. 이때, $m > n$ 이므로 m 차원의 정보가 함수 f 에 의해서 n 차원으로 차원 축소되는 효과가 나타난다. 일반적으로 함수 f 는 Encoder라고 부른다. n 차원으로 압축된 z 는 식(2)와 같이 함수 g 에 의해서 x 으로 변환되며 x 은 x 와 동일한 m 차원의 데이터이다. 함수 g 는 압축된 정보 공간의 z 를 m 차원의 원 공간으로 복원하는 효과를 가지어 Decoder라고 부른다. Autoencoder는 식(3)과 같이 n 차원의 x 를 함수 f 와 g 를 거치면서 다시 n 차원의 x 로 변환하는 모델이다. 이때 식 (4)의 Loss를 도입하면, Loss를 최소화 하는 해는 x 과 x 가 동일할 때이다. 결국 Loss 최소화 문제에서 Autoencoder는 정보를 압축했다가 최소한의 손실로 복원하려는 특징을

나타내게 된다.

양품 이미지로 Autoencoder를 학습 시키면 해당 Autoencoder는 양품 이미지의 특성만을 복원하도록 교육 된다. 불량 이미지의 소수 특성은 복원 이미지에 반영되지 않는다. 결과적으로 복원된 이미지와 입력된 이미지의 차이가 클수록 양품 특성에서 벗어난 것을 뜻하게 되며 벗어난 정도를 수치화 하여 불량 이미지를 판정한다.

$$z = f(x), x \in R^m \text{ and } z \in R^n \quad (1)$$

$$\hat{x} = g(z), \hat{x} \in R^m \quad (2)$$

$$\hat{x} = g(f(x)) \quad (3)$$

$$\text{Loss} = \sqrt{(x - \hat{x})^2} \quad (4)$$




그림 1. Autoencoder 개념도

그림 1은 입력 이미지와 복원 이미지 한 예이다. 양품에 대해서만 학습한 Autoencoder의 복원 이미지는 불량 이미지가 입력 되었을 때 휘도 분포는 잘 복원한다. 그러나 소수 특징인 얼룩은 복원 이미지에서 소실된 것을 확인 할 수 있다.


2.1. 이미지 데이터 구성

그림 2는 LCD 신제품 TV 개발 과정에서 발생한 특정 얼룩의 시인 수준 별 대표 이미지이다. 수준 3, 4, 5는 불량 수준 강, 중, 약에 해당하며 수준 1, 2는 양호 수준으로 양품 분류이다. 해당 얼룩을 본 논문에서는 마점 얼룩이라 명명하겠다.


마점 얼룩은 위치와 형태가 모두 불규칙한 얼룩으로 Thin Film Transistor(TFT)의 특성 불균일이 개발 제품의 변경 조건 때문에 시인 되는 얼룩이다. 마점 얼룩을 평가 데이터로 선정한 이유는 불규칙한 형태의 신규 얼룩이며 발생 빈도가 높아 충분한 얼룩 이미지를 수집할 수 있었기 때문이다.

표 1은 평가 데이터 Set의 얼룩과 정상 이미지 구성 비율 정보이다. 얼룩 이미지 비율에 따른 모델의


정합성을 평가하기 위해 구성하였다. 얼룩 데이터 비율 각 15%, 30%, 45%, 60%, 75%, 90%로 준비하였다.



(a) 5수준



(b) 4수준



(c) 3수준

그림 2. 마점 얼룩 수준 별 이미지 예

표 1. 모델 검증을 위한 얼룩 비율 별 데이터 Set 구성

마점 얼룩 포함 비율	정상	마점 얼룩			총합
		5수준	4수준	3수준	
15%	850	50	50	50	1000
30%	700	100	100	100	1000
45%	550	150	150	150	1000
60%	400	200	200	200	1000
75%	250	250	250	250	1000
90%	100	300	300	300	1000

2.2. 기준 모델

모델 성능을 비교를 위한 기준 Autoencoder 모델은 Convolutional Neural Network(CNN)을 기반으로 한 표 2와 같다. 모델의 Loss는 입력 이미지와 복원 이미지의 각 pixel point에 대한 Mean Squared Error(MSE)를 사용하였다. CNN 모델의 hyper parameter는 양품 이미지만으로 학습 데이터 구성하여 양품과 얼룩 이미지에 대한 Area Under the ROC

Curve(AUC)를 최대화 하기 위해 튜닝을 거쳤다. 그 성능이 표 3의 “참고 지도 학습 모델 정합성” 결과이다. 지도 학습 모델은 학습 데이터로 정상 이미지만을 사람이 분류하여 활용한 경우이다. 양호 이미지만을 학습에 사용하므로 성능이 우수하나 이미지를 사전에 분류해야 하므로 실제 개발 상황에서 활용도가 낮다. 본문에서는 참고 지표로 활용한다.

표 2. Autoencoder 모델 구성

Name	Layer(Type)	Filters	Kernel Size	Stride	Padding	Activation function	Output Shape
Encoder	Input	-	-	-	-	-	350X630X1
	Conv2D	2	2X2	1	Active	elu	350X630X2
	Conv2D	2	4X4	2	None	elu	174X314X2
	AveragePooling2D	-	2X2	-	-	-	87X157X2
	Conv2D	16	3X3	1	Active	elu	87X157X16
	Conv2D	16	6X6	1	None	elu	82X152X16
	AveragePooling2D	-	2X2	-	-	-	41X76X16
	Conv2D	16	2X2	1	Active	elu	41X76X16
	Conv2D	16	2X2	1	None	elu	40X74X16
	AveragePooling2D	-	2X2	-	-	-	20X37X16
	Conv2D	8	3X3	1	Active	elu	20X37X8
	Conv2D	8	6X6	1	None	elu	15X32X8
	AveragePooling2D	-	3X4	-	-	-	5X24X8
	Conv2D	4	2X2	1	Active	elu	5X24X4
Z (압축공간)	Conv2D	4	4X4	1	None	elu	2X5X4
Decoder	Conv2D Transpose	4	2X2	1	Active	elu	5X24X4
	Up Sampling2D	-	3X4	-	-	-	15X32X4
	Conv2D Transpose	8	6X6	1	None	elu	20X37X8
	Conv2D Transpose	8	3X3	1	Active	elu	20X37X8
	Up Sampling2D	-	2X2	-	-	-	40X74X8
	Conv2D Transpose	16	2X2	1	None	elu	41X76X16
	Conv2D Transpose	16	2X2	1	Active	elu	41X76X16
	Up Sampling2D	-	2X2	-	-	-	82X152X16
	Conv2D Transpose	16	6X6	1	None	elu	87X157X16
	Conv2D Transpose	16	3X3	1	Active	elu	87X157X16
	Up Sampling2D	-	2X2	-	-	-	174X314X16
	Conv2D Transpose	2	4X4	2	None	elu	350X630X2
	Conv2D Transpose	1	2X2	1	Active	elu	350X630X1

2.3. 기준 모델의 데이터 Set에 따른 정합성 평가

본 논문에서 제안할 새로운 모델의 성능을 비교하기 위해 기준 Autoencoder 모델은 표 2의 구조를 그대로 따른다. 표 2의 모델을 이용하여 표 1 데이터에 대해서 비지도 학습 후 정합성을 평가한 결과가 표 3의 “기준 비지도 학습 모델 정합성”이다. 표 3의 비지도 학습 모델 결과가 본 논문의 기준점으로 활용된다. 다수의 정상 데이터에 대해서 학습한다는 가정이 들어가 있는 비지도 학습 모델의 특성상 학습 데이터에 불량 이미지가 많을수록 정합성이 저하된다.

표 3. 얼룩 비율에 따른 기준 모델 적합성

마점 얼룩 포함 비율	얼룩 수준	기준 비지도 학습 모델 정합성(AUC)	참고 지도 학습 모델 정합성(AUC)
15%	5수준	99.9%	100.0%
	4수준	99.6%	99.9%
	3수준	98.9%	99.6%
30%	5수준	99.8%	99.9%
	4수준	99.3%	99.8%
	3수준	96.3%	97.9%
45%	5수준	99.7%	99.9%
	4수준	97.3%	99.7%
	3수준	91.6%	98.3%
60%	5수준	99.4%	99.9%
	4수준	95.1%	99.4%
	3수준	85.2%	97.4%
75%	5수준	99.4%	99.8%
	4수준	93.4%	98.8%
	3수준	80.3%	95.7%
90%	5수준	99.6%	100.0%
	4수준	93.1%	99.3%
	3수준	78.4%	96.3%

2.4. 개발 이미지 데이터 특성에 적합한 신모델

신규 모델의 알고리즘은 표 4와 같다. 주 아이디어는 전체 데이터에서 비지도 학습 Autoencoder로 하위 데이터를 추출한 후 양호한 이미지로 정제된 데이터를 구성하여 재 학습을 하는 것이다. Autoencoder는 얼룩 이미지가 많아지면 얼룩 이미지 특징도 복원이 잘 되면서 양/불 간의 구별 정합성이 낮아진다. 그러나 Loss 값이 낮은 이미지들을 살펴보면 양호한 이미지 비중이 높다. 이러한 특징을 이용하여 Loss가 낮은 이미지에서 새로운 학습 데이터를 구성하면 양품 이미지 비율이 상승하면서 성능 향상이 가능해진다.

표 4는 상기의 아이디어를 알고리즘으로 표현한 것이다. 모델 A와 B는 동일한 모델 구조(표 2)를 가진다. 그러나 학습 데이터에는 차이가 있다. 전체 데이터를 학습 하는 A에 비해 B는 Step 3의 정제된 이미지 데이터를 학습한다.

표 5는 기준 모델과 신규 알고리즘 모델의 얼룩 비율 90% 데이터에 대한 계산 시간을 비교한 결과이다. 신규 모델은 A에 추가로 B를 학습하는 과정으로 인해서 epoch은 증가하나 정제된 소수 이미지 데이터에 대해서 B 학습이 이루어지므로 추가 epoch에 대한 계산량이 크게 감소하며 전체 계산 시간 증가는 미미하다.

표 4. 신규 알고리즘

알고리즘

Step 1. Autoencoder 특징 추출

- 1.1. 전체 이미지 데이터로 Autoencoder 모델 A를 구성한다.
- 1.2. 모델 A 이용해 Loss를 구한다.

Step 2. Threshold 값 계산

- 2.1. Loss 분포에서 Median을 구한다.
- 2.2. Median 값 이하의 Loss 분포 데이터만 사용하여 표준편차(σ)를 구한다.
- 2.3. Threshold 값을 Median과 표준편차를 이용하여 정한다.

Step 3. 정제된 이미지 Set 구성

- 3.1 Threshold 값 이하의 Loss 값을 가진 정제된 이미지 Set을 구성한다.

Step 4. Autoencoder 특징 재추출

- 4.1 정제된 이미지 Set로 모델 A를 재구성한다.
- 4.2 재구성된 모델을 모델 B로 명명한다.

Step 5. 이상치 이미지 검색

- 5.1 모델 B를 이용하여 전체 데이터에서 일록을 검색한다.

표 5. 기존 모델과 신규 모델의 계산 시간 비교

모델	Epoch	총 계산 시간(hr)
기존 모델	888(100%)	3.75(100%)
신규 모델	1000(113%)	3.80(101%)

알고리즘 Step 2에서 정제 이미지 구성을 결정하는 Threshold를 계산한다. 이때 통계적 데이터를 Loss가 작은 영역에서 얻어내기 위해서 아래와 같이 계산한다. 표준편차(σ)를 식 (5)와 같이 정의한다. 실제 Step 1에서 구한 Loss 값의 Histogram은 그림 3과 같다. 그림 3에서 Median을 중심으로 Loss가 작은 좌측 데이터와 Loss가 큰 우측으로 나누어 생각하면 양품은 Loss가 작은 쪽(좌측)에 주로 존재할 것이다. 따라서 양품 정보만을 최대한 활용하기 위하여 다음과 같은 가상의 분포를 가정한다. 좌측 분포가 median을 중심으로 측 대칭인 분포이다. 이 경우 좌측과 우측이 대칭이므로 식 (6), (7)에 의해서 식 (8)와 같이 표준편차를 계산한다.

$$\sigma = \sqrt{\frac{\Sigma(\text{median} - x_{\text{좌측}})^2 + \Sigma(\text{median} - x_{\text{우측}})^2}{n_{\text{좌측}} + n_{\text{우측}}}} \quad (5)$$

$$\Sigma(\text{median} - x_{\text{좌측}})^2 = \Sigma(\text{median} - x_{\text{우측}})^2 \quad (6)$$

$$n_{\text{좌측}} = n_{\text{우측}} \quad (7)$$

$$\sigma = \sqrt{\frac{2\Sigma(\text{median} - x_{\text{좌측}})^2}{2n_{\text{좌측}}}} = \sqrt{\frac{\Sigma(\text{median} - x_{\text{좌측}})^2}{n_{\text{좌측}}}} \quad (8)$$

최종적으로 Step 2.3의 Threshold(Th)는 아래 식 (9)와 같이 정의하였다.

$$\text{Th} = \text{median} + k \cdot \sigma \quad (k \text{ is constant}) \quad (9)$$

식 (9)의 k는 hyper parameter로 사용자의 적절한 정의가 필요하다. Th 값 이하를 양호 데이터의 존재 구간으로 가정하므로 양호 이미지가 많다고 예상한다면 k 값을 크게 해서 Th 값을 크게, 불량 이미지가 많다고 생각한다면 k 값을 작게 가져가야 한다. 따라서 일록 리스크에 따라 신제품의 변경점이 적고 유사한 모델이 양산 중이라면 k 값을 크게 해서 Th를 크게 가져가고 반대라면 k 값을 작게 하는 전략을 생각할 수 있다.




그림 3. 마점 얼룩 비율 90% 데이터의 표 4. Step 1에서 구한 Loss 값 Histogram

2.5. 신모델 정합성 평가

표 1의 데이터를 가지고 Th 값에 따른 신규 모델의 정합성을 평가한 전체 결과가 표 6과 같다. Th는 hyper parameter k에 따라 결정된다. k 값을 -1.0~3.0까지 변경하며 정합성의 변동을 확인하였다.

그림 4는 얼룩 포함 비율이 75%, 90%인 데이터에서의 Threshold 값에 따른 3수준 얼룩의 정합성 그래프이다. 기존 모델의 3수준 얼룩 정합성이 각각 80.3%, 78.4%로 매우 낮는데 비해서 신규 모델은 k 값에 따라 정합성이 크게 향상되는 것을 알 수 있다. 지도 학습 모델과 비교하여도 k=-1.0인 경우 정합성이 우수하다.

표 6에서 얼룩 포함 비율 15%, 30%, 45%의 정합성 결과 중 빈 칸은 k 값이 충분히 작아지기 전에 얼룩 이미지가 모두 제거된 경우로 추가적인 개선이 발생하지 않는 영역이다. 단지 양품 이미지까지 포함하여 제거되는 조건이 되며, 가장 많이 제거되는 조건($Th=median-1.0\sigma$)에서 정합성 저하가 발생하는지 확인하였다. k 값이 작아 일부 정상 이미지가 유실하는 조건임에도 15%, 30%, 45% 조건에서 k 값을 -1.0 로 설정하여도 정합성 저하는 없다. 따라서 양품 이미지 비율이 높은 경우에는 k 값을 작게 설정하여도 정합성 저하가 없다는 장점을 확인하였다. 왜냐하면, 이미지의 얼룩 비중이 얼마인지 정확히 모르는 상황에서 k 값을 작게 가져가는 hyper parameter tuning 전략으로 우수한 성능을 기대할 수 있기 때문이다.




그림 4. 3수준 얼룩에 대한 threshold 조건 별 신규 모델과 기존 모델, 지도 학습 모델의 정합성 비교

3. 결론

신규 제품 개발의 특성상 사전 학습 이미지 확보가 어렵기 때문에 비지도 학습 기반 이상 검출 모델이 적합하다. 그러나 비지도 학습 기반 기존 모델은 다수의 데이터가 정상인 조건에서만 높은 정합성을 보이는 한계가 있다. 이를 극복하고자 불량 얼룩 이미지가 다수인 데이터에도 강건한 비지도 학습 모델을 제안하였다. 새로운 모델은 다양한 비율의 얼룩 포함 이미지 데이터에서 높은 정합성을 입증하여 신규 제품 개발뿐만 아니라 양산 제품의 공정 변경 평가와 같이 얼룩 불량 다발 예상 상황에서 활용 될 수 있을 것으로 기대된다.

4. 참고문헌

[1] Park, Yongeun, et al. "76-5: Late-News Paper: Enhanced Productivity Performance through Detecting Defects on Surface of AMOLED Display" SID Symposium Digest of Technical Papers. Vol. 50. No. 1. 2019.
 [2] Ramya Bagavath Singh et al., "Deep Learning based

Mura Defect Detection", EAI Endorsed Transaction on Cloud Systems, 5(16), 2020

[3] Kim, Eunwoo, and Jaewon Kim. "High-resolution Classifier Ensemble for Defect Inspection of Display Panels" 제어로봇시스템학회 논문지 27.8 (2021): 498-501.

[4] Lee, Janghwan, et al. "Multimodal Machine Learning for Display Panel Defect Layer Identification" 2021 32nd Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC). IEEE, 2021.

[5] Chalapathy R., Chawla S. "Deep Learning for Anomaly Detection: A Survey", <https://arxiv.org/abs/1901.03407> (2019)

[6] Christoph Baur et al., "Deep Autoencoding Models for Unsupervised Anomaly Segmentation in Brain MR Images", <https://arxiv.org/abs/1804.04488>

[7] Paul Bergmann et al., "Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders", <https://arxiv.org/abs/1807.02011>

표 6. 신규 알고리즘의 Threshold 값에 따른 정합성 결과와 기준 모델의 정합성 비교

마점 얼룩 포함 비율	얼룩수준	신규 비지도 학습 모델의 Th값 (median+k·σ)에 따른 정합성(AUC)						기준 비지도 학습 모델 정합성(AUC)	지도 학습 모델 정합성(AUC)	
		median+3.0·σ	median+2.0·σ	median+1.0·σ	median+0.0·σ	median-0.5·σ	median-1.0·σ			
15%	5수준	100.0%					100.0%	99.9%	100.0%	
	4수준	99.9%					99.8%	99.6%	99.9%	
	3수준	99.6%					99.5%	98.9%	99.6%	
30%	5수준	99.7%	99.9%	99.9%			99.9%	99.8%	99.9%	
	4수준	99.5%	99.8%	99.8%			99.7%	99.3%	99.8%	
	3수준	97.5%	98.2%	97.9%			98.1%	96.3%	97.9%	
45%	5수준	99.7%	99.7%	99.8%	99.9%			99.9%	99.7%	99.9%
	4수준	98.0%	98.0%	98.5%	99.7%			99.7%	97.3%	99.7%
	3수준	93.2%	93.2%	94.0%	98.3%			98.8%	91.6%	98.3%
60%	5수준	99.5%	99.6%	99.7%	99.8%	99.8%	99.9%	99.4%	99.9%	
	4수준	95.2%	95.9%	97.2%	98.3%	98.5%	99.4%	95.1%	99.4%	
	3수준	85.2%	87.4%	90.1%	93.4%	94.1%	97.4%	85.2%	97.4%	
75%	5수준	99.4%	99.4%	99.6%	99.6%	99.7%	99.8%	99.4%	99.8%	
	4수준	93.3%	93.5%	95.8%	96.2%	96.6%	98.8%	93.4%	98.8%	
	3수준	81.0%	81.2%	86.6%	87.2%	87.8%	95.7%	80.3%	95.7%	
90%	5수준	99.6%	99.7%	99.7%	99.8%	99.8%	99.9%	99.6%	100.0%	
	4수준	93.2%	93.2%	94.4%	95.3%	96.2%	97.6%	93.1%	99.3%	
	3수준	78.8%	78.7%	81.3%	83.5%	85.7%	90.2%	78.4%	96.3%	

실시간 On-Cell Mura Level 예측 시스템

황진하

삼성디스플레이

jinha85.hwang@samsung.com

Realtime On-Cell Mura Level Predict System

Jinha Hwang

Samsung Display

요약

디스플레이 산업에서는 생산 시간을 최소화하고 생산량을 극대화하기 위해 생산 과정에서는 Sampling Inspection을 수행하고 최종단에서 모든 제품을 Inspection하여 불량률을 판정한다. 그러므로 검사되지 않은 제품은 항상 공정관리의 불안 요소이다. 이로 인해 디스플레이 제조 산업 경쟁력의 핵심은 생산공정 설비 데이터 중에서 제품의 최종 특성을 결정짓는 핵심요소를 발굴하여 관리하는 것이다. 이번 연구에서는 ELA (Excimer Laser Annealing) 공정 설비에서 실시간으로 나오는 다양한 Sensor Data를 추출 및 가공한 뒤, AI 기술을 이용하여 공정진행 중에 최종 검사 값인 On-cell Mura Level 예측 모델을 제작했다.

1. 서론

ELA(Excimer Laser Annealing) 공정은 OLED제조에서 Panel 품질을 결정하는 중요한 공정이다. 단, 결정화의 품질을 검사자가 판정하므로 검사자에 의한 수율 측정 오차가 발생할 가능성이 있다. 또한 패널 특성 확인을 위한 최종검사를 진행하는데 상당한 시간이 소요되기 때문에 잠재적인 수율 손실이 증가할 수 있다. 그래서 결정화 정도에 따른 On-cell Mura Level(디스플레이 줄얼룩 정도)의 예측이 공정에서 끊임없이 필요했다.

본 연구에서는 Laser Annealing의 품질을 예측하기 위해 설비의 종류에 따라 Machine Learning과 Deep Learning을 사용하였다.

2. DATA MANAGEMENT & ALGORITHM

최근 각종 산업에서 AI가 침투하고 있는데 그 중, 제조 공장은 Image를 사용한 과제들이 Numeric에 비해 성공 사례가 많다. Numeric이 Image 대비 Data 분석에 Domain knowledge가 요구되는 경우가 많은 것이 그 이유 중 하나라고 생각되며 이번 연구에서도 Domain knowledge에 의한 Data preprocessing이 연구 성공에 기여했다.

2.1. Sensor의 일관성

AI에서 중요한 인자는 학습에 사용할 Raw Data이다. 따라서 이를 측정하는 Sensor 측정 일관성이 중요하다. 동일한 이름의 Data라도 Sensor의 설정에 따라 다른 Data가 된다.




그림 1. Sensor 설정에 따른 Beam 측정의 변화

본 연구에서 X factor로 사용된 Beam Data는 Image Sensing에 의해 이루어진다. 그림1.은 Sensor 설정에 따라 동일 Beam 특성 값이 달라질 수 있음을 보여준다. 이러한 결과로 우리가 보는 Data들에 오차가 발생하여 실제와 다른 결과를 얻을 수 있다. Sensor 차이는 개별 장비 관리에는 큰 문제가 아닐 수 있지만 AI를 위한 Big Data로 사용하면 모델 정확성을 떨어뜨리는 요소가 된다. 이 문제를 최소화하기 위해 본 연구에서는 설비간 동일한 Sensor의 설정을 최대한 맞추는 작업을 먼저 진행했다.

2.2. Data preprocessing

AI의 결과는 Data preprocessing에 의해 결정된다. 설비 Sensor Data로 검사 결과를 예측하는 Industrial AI의 경우, 설비에 대한 이해도가 낮다면 해당 Data에 대한 해석이 어려울 것이다. 또한, 일반적인 통계론으로 Data를 처리하면 그에 따른 오차가 발생하게 된다. 예를 들어, 시간에 따른 변화를 크게 보여 중요하게 보이는 Sensor지만 품질을 결정짓는 설비 특성과는 무관할 수 있는 경우와 독립적이지 않은 Sensor를 독립 인자로 처리하는 경우를 들 수 있다.

ELA 설비는 Raw Beam을 병렬로 Mixing하여 Line Beam을 생성하는 구조다. LASER Tube 상태에 따라

Line Beam에 대한 영향력 차이가 발생하나 특정 LASER가 다른 LASER들에 비해 최대 1.5배 이상의 영향력을 가질 수는 없다.

표 1. LASER Number간 Coefficient 비교

Coefficient	Sigma	Energy	Position
LSR1	0.0012	0.0169	0.0128
LSR2	0.0399	-0.0213	0.0128
LSR3	0.0268	0.0317	-0.0186
LSR4	0.0064	-0.0208	0.0138
LSR5	0.0173	-0.0016	0.0080
LSR6	-0.0098	-0.0148	0.0290
Difference of Coefficient	33.94	19.74	77.42

그런데 PLS 또는 Linear Regression으로 학습한 Coefficient를 확인해보면, LASER 6대의 병렬적 관계가 고려되지 않은 채 학습이 진행된 것을 확인할 수 있다. 표 1.처럼 LASER 1번의 Sigma의 Coefficient는 0.0012이지만, LASER 2번의 Sigma의 Coefficient는 0.0399이다. 이 Coefficient Ratio (Sensor별 Max/Min 상대비율)는 33.94배이다. 마찬가지로 Energy의 경우는 19.74배, Position의 경우 77.42배라는 상당히 큰 가중치 차이를 보인다. 위 3가지 Sensor 외에도 전체의 50% 정도의 Sensor가 Coefficient Ratio (Sensor별 Max/Min 상대비율) 10 이상의 값을 갖는다.

표 2. 개별치 방식과 통계방식의 Parameter 비교

개별치 방식	통계 방식
LSR1	Average
LSR2	
LSR3	
LSR4	
LSR5	
LSR6	
	Standard Deviation

실시간 On-Cell Mura Level 예측 시스템에 적용된 통계적 방법론은 표2와 같이 평균, 표준편차 등의 통계 데이터로 병렬 설비 구조를 Preprocessing하는 것을 의미한다. 이는 표3과 같이 여러 LASER를 독립적인 데이터로 학습시 발생한 Overfitting을 해결할 수 있었다.

표 3. 독립인자/통계적 대표 인자 사용 비교.

Data	Independent		Statistical Variation	
	RMSE	MAPE	RMSE	MAPE
Training	2.427	3.497	2.507	3.611
Testing	2.759	4.066	2.502	3.692

2.3. Algorithm 선택

본 연구에서는 세 종류의 설비에 대한 실시간 On-

cell Mura Level 예측 시스템을 구축했다. 설비의 특성에 따라 사용한 AI 모델도 바뀌었다. 동일 공정의 설비도 종류에 따라 설비 구조와 Sensor의 차이가 존재하므로 이를 이해하고 분석할 수 있는 Domain knowledge가 필요했다. 설비에 따라 PLS, Keras Sequential Model을 사용했다. 활성화 함수는 Sigmoid와 Relu를 사용했다. 그 결과 세 종류의 설비에 대해 그림 2와 같이 R2 0.9 정도의 결과를 얻을 수 있었다.




그림 2. On-cell Mura Level 예측 일관성

3. 결론

본 연구에서는 Industrial Data를 분석하는데 있어서 설비 또는 Sensor의 특징과 같은 Domain Knowledge가 중요함을 확인했다. 대부분의 공정 Data가 ELA공정과 유사한 센서간의 상관관계가 있으며, 병렬적인 관계의 Sensor들이 많을 것이다. 따라서, 향후 제조공정에서 지속적인 Numeric Data의 Algorithm 및 Data 전처리에 관한 연구에서 좋은 사례가 될 것으로 생각한다.

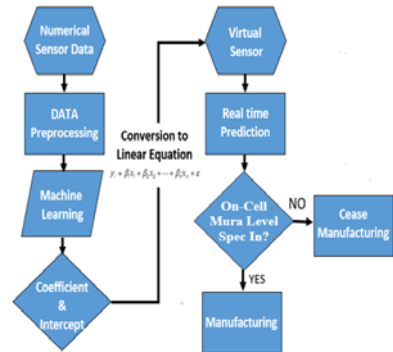


그림 3. System Diagram

참고문헌

[1] Aurelien Geron, Hands-On Machine Learning with Scikit-Learn and Tensor Flow: Concepts, Tools, and Techniques to Build Intelligent Systems, Shroff/O'Reilly, United States, Sebastopol, p.33-76,167-224 (2017).

MLP-Mixer 모델의 단기 전력 부하 시계열 예측 문제 적용에 대한 연구

류승형

인공지능응용전략실, 한국원자력연구원

ashryu@kaeri.re.kr

Short-term Load Forecasting model based on MLP-Mixer

Seunghyoung Ryu

Artificial Intelligence Application & Strategy Team, Korea Atomic Energy Research Institute

요 약

스마트 그리드 시대가 도래함에 따라서 전기차, 재생에너지, 에너지 저장 장치 등 망내 신규 요소들의 보급이 확대되고 있으며, 이를 효율적으로 제어하기 위해서는 정확한 예측 모델이 필수적이다. 이에 따라 다양한 에너지 수요 및 발전량 예측 모델이 개발되고 있으며, 특히 최근 딥러닝과 에너지 빅데이터의 발전에 힘입어 보다 딥러닝 기반의 예측 모델에 대한 연구가 활발히 이루어지고 있다. 에너지 데이터의 시계열적 특성에 따라서 대부분의 예측 모델들은 LSTM을 기반으로 CNN, 어텐션 기법을 활용한 모델 또한 연구되고 있다. 그러나 RNN 구조의 순차적인 연산과정과 트랜스포머 구조에서 어텐션 매트릭스의 계산으로 인해 연산에 소요되는 시간과 컴퓨팅 자원이 증가하며 이는 실시간 어플리케이션이나 소형 디바이스에서의 예측 모델의 적용을 어렵게 만들 수 있다. 본 논문에서는 이러한 문제점을 극복하기 위하여 최근 컴퓨터 비전 분야에서 소개된 MLP-Mixer 구조를 적용한 단기부하 예측 모델을 연구하였다. MLP-Mixer는 가장 단순한 형태의 신경망인 MLP만으로 구성되며 다변량 시계열 데이터의 특징을 효과적으로 추출하여 빠르고 정확한 예측이 가능하다. 본 연구에서는 4개의 전력사용량 데이터셋에 대한 예측 성능을 비교하였으며, 제안된 MLP-Mixer 기반 모델이 예측 오차, 연산 속도, 모델 크기 측면에서 다른 딥러닝 모델과 대비하여 더 좋은 성능을 달성하였다.

1. 서 론

스마트 그리드 시대가 도래함에 따라서 전기차, 재생에너지 발전원, 에너지 저장 장치 (ESS) 등의 망내 신규 요소의 보급이 확대되고 있다. 이러한 요소들은 전력망내 변동성과 복잡성을 증가시키며, 전력망의 효율적인 운영과 더불어 가상발전소 (Virtual Power Plant, VPP), 에너지 트레이딩, 수요반응 (Demand Response) 등의 다양한 스마트 그리드 어플리케이션을 위해서는 정확한 예측 모델이 필수적이다.

특히 최근 인공지능과 빅데이터의 발전에 힘입어 다양한 딥러닝 기반의 에너지 데이터 예측 모델이 활발히 연구되고 있다[1]. 에너지 데이터의 시계열적 특성을 활용하기 위하여 대다수의 연구는 RNN, 특히 LSTM을 중심으로 개발되고 있으며, 최근에는 머신러닝 기법[2], CNN[3], 어텐션[4] 기법을 활용한 LSTM 융합 모델들이 연구되고 있다. 시계열 데이터의 예측 정확도를 높이기 위하여 모델의 구조는 점차 복잡해지고 있으며, 그 과정에서 RNN 구조의 순차적인 연산과 트랜스포머 모델의 어텐션 매트릭스 계산은

연산 시간과 컴퓨팅 자원 소요를 증가시켜 높은 정확도에 비하여 실시간 어플리케이션이나 소형 디바이스에서의 적용성을 감소시킨다. 본 연구에서는 이러한 문제점을 극복하기 위하여 최근 컴퓨터 비전 분야에서 제안된 MLP-Mixer [5] 구조를 활용한 단기부하예측 모델을 연구하였다. MLP-Mixer는 시간적 특징 추출과 변수간 특징 추출을 독립적으로 수행하는 다수의 MLP (Multi-layer perceptron)으로 구성되어 있다. 이러한 구조를 통해 다변량 시계열 데이터의 특징을 효과적으로 추출할 수 있으며, 또한 가장 단순한 형태의 신경망인 MLP만으로 구성되어있기 때문에 연산 속도와 모델 구조 측면에서 장점을 갖는다.

2. 문제 구성 및 모델 구조

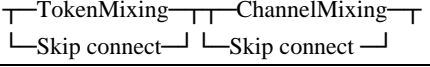
본 연구에서 고려하는 단기부하예측 문제는 특정 과거 시점까지의 다변량 시계열 데이터를 바탕으로 다음 24시간 동안의 전력 사용량을 예측하는 문제이다. 전력 데이터를 포함한 예측에 활용가능한 데이터의 차원을 D , 과거 시점을 L , 다음 24시간 동안 예측

범위를 T 라 한다면 전력 사용량 예측 모델은 입력 $\mathbf{X}_{t-L+1:t} \in \mathbb{R}^{L \times D}$, 출력 $\mathbf{x}_{t+1:t+T} \in \mathbb{R}^T$ 을 갖는 다음의 함수로 표현할 수 있다.

$$\mathbf{x}_{t+1:t+T} = f(\mathbf{X}_{t-L+1:t})$$

MLP-Mixer 모델의 구조적 특징은 시간적 특징 추출과 변수간 특징 추출이 독립적으로 이루어지는 믹서 레이어의 존재이다. 믹서 레이어는 토큰믹싱 레이어와 채널믹싱 레이어를 포함하고 있으며, 각 믹싱 레이어는 [Desne-GeLU-Dense] 레이어로 이루어진 MLP로 구성되어 있다. MLP-Mixer 기반 단기부하예측 모델의 구성은 다음 표와 같다.

표 1. 단기부하예측을 위한 MLP-mixer 모델 구조

레이어	구성
MLP	Input(d) - Dense(d') - GeLU - Dense(d)
TokenMixing	LayerNorm - Transpose - MLP - Transpose
ChannelMixing	LayerNorm - MLP
Mixer	
제안모델	Embedding-[N x Mixer]-AvgPool-Desne

따라서 토큰믹싱 레이어에서는 시계열 축에 대한 비선형변환을 수행하고 채널믹싱레이어는 특징축에 대한 비선형변환을 수행한다. 최종 모델은 입력값에 대한 임베딩레이어와 N 개의 믹서레이어를 거친 후 1dAvgPooling을 통해 시간적 측면의 정보를 압축하고 최종적으로 Dense 레이어를 통해 예측값을 출력한다. 임베딩 레이어에서는 변수축에 대한 Dense 레이어의 적용을 통해 다변량 시계열 데이터의 차원변환 및 Positional Encoding을 수행한다.

3. 데이터 및 실험

성능에 대한 비교를 위하여 4개의 전력부하 및 기상 데이터를 확보하였으며 데이터셋에 대한 대략적인 설명은 다음의 표 2 와 같다. 여기서 H 는 1시간, Q 는 15분 단위 측정을 의미하며, 차원은 전력부하와 기상데이터를 포함한 변수의 수에 해당한다.

표 2. 성능평가를 위한 데이터셋

데이터셋	기간	단위	지역	차원
UMASS	15.01~16.12	kW/H,Q	-	12
ELIA	15.01~21.12	GW/H,Q	벨기에	9
KAGGLE	15.01~18.12	MW/H	스페인	10
USHOME	17.12~20.06	MW/H	미국	16

실험을 위하여 training/validation/test 셋은 각각

순차적으로 전체데이터의 60%, 20%, 20%를 사용하였으며, 네트워크의 구조와 관련된 하이퍼 파라미터는 레이어의 수, 임베딩 차원, 잠재벡터 차원에 대한 그리드 서치 알고리즘을 통해 결정하였다. 입력 데이터는 과거 7일까지의 데이터를 활용하였으며 다음 24시간의 전력사용량을 예측한다. 성능비교를 위하여 FNN, 1D-CNN, LSTM 그리고 CNN-LSTM 하이브리드 모델과 예측오차 및 모델크기, 소요시간 들을 비교하였으며, 서로 다른 랜덤 시드에 대하여 10회 실험한 결과의 평균값을 정리하였다.

표 3. 단기부하예측을 위한 MLP-mixer 모델 구조

	FNN	1DCNN	LSTM	CNN-LSTM	MLP-Mixer
MSE	0.17	0.15	0.15	<u>0.14</u>	0.11
MAPE(%)	14.6	10	<u>9.3</u>	9.5	9.2
Param	2.8M	333k	212k	327k	<u>229k</u>
Time(s)	0.06	0.03	0.12	0.08	<u>0.05</u>

실험 결과 MLP-Mixer 기반 모델이 다른 딥러닝 모델 대비 가장 낮은 예측오차를 보이는 것을 확인할 수 있으며 동시에 두번째로 낮은 모델 사이즈와 소요시간을 갖는 것을 확인할 수 있었다.

4. 결론

본 연구에서는 컴퓨터 비전 분야에서 활용된 MLP-Mixer 모델을 전력사용량 예측 문제에 적용하였으며, MLP-Mixer의 구조적인 특징을 통하여 적은 파라미터와 빠른 연산시간을 갖으면서도 가장 높은 예측정확도를 달성하였다. 추후 연구로 제어 등 정확도 향상 및 어플리케이션 활용을 위한 확률적 시계열 예측 모델에 대한 연구를 수행할 예정이다.

ACKNOWLEDGMENT

이 성과는 한국원자력연구원 주요사업 (No. KAERI-524450-22)의 지원과 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. NRF-2021R1F1A1051290).

참고 문헌

- [1] S. Ryu, J. Noh, and H. Kim, "Deep neural network based demand side short term load forecasting," Energies, vol. 10, no. 1, p. 3, 2016.
- [2] A. Moradzadeh, S. Zakeri, M. Shoaran, B. Mohammadi-Ivatloo, and F. Mohammadi, "Short-term load forecasting of microgrid via hybrid support vector

regression and long short-term memory algorithms,” *Sustainability*, vol. 12, no. 17, p. 7076, 2020.

[3] H. Choi, S. Ryu, and H. Kim, “Short-term load forecasting based on resnet and lstm,” in *2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*. IEEE, 2018, pp. 1–6.

[4] S. Wang, X. Wang, S. Wang, and D. Wang, “Bi-directional long shortterm memory method based on attention mechanism and rolling update for short-term load forecasting,” *International Journal of Electrical Power & Energy Systems*, vol. 109, pp. 470–479, 2019.

[5] I. O. Tolstikhin, N. Houlsby, A. Kolesnikov, L. Beyer, X. Zhai, T. Unterthiner, J. Yung, A. Steiner, D. Keysers, J. Uszkoreit et al., “Mlp-mixer: An all-mlp architecture for vision,” *Advances in Neural Information Processing Systems*, vol. 34, 2021.

방사선 계측기 펄스 신호처리를 위한 딥러닝 모델 개발

전병일¹⁾, 김준혁²⁾, 문명국¹⁾

¹⁾한국원자력연구원, ²⁾한국과학기술원

bijeon@kaeri.re.kr, covent17@kaist.ac.kr, moonmk@kaeri.re.kr

Development of Deep-learning Model for Pulsed Signal Processing for Radiation Detector

¹⁾Byoungil Jeon, ²⁾Junhyuk Kim, ¹⁾Myungkook Moon

¹⁾Korea Atomic Energy Research Institute, ²⁾Korea Advanced Institute of Science and Technology,

요 약

방사선 계측기는 검출기 물질과 반응하는 방사선의 신호를 전기 신호로 변환해주는 장치로 환경 또는 시료에 존재하는 방사성 물질을 측정하는데 활용된다. 방사선이 검출기 물질에 에너지를 전달하는 과정에서, 해당 에너지가 펄스 형태의 전기신호로 변환되는데, 이때 측정하는 환경이나 시료의 방사능이 높을 경우 여러 개의 펄스 신호가 중첩되는 현상이 일어나고, 또 반응하는 방사선의 종류에 따라 펄스 신호의 모양이 다르게 생성된다. 방사선 계측 분야에서는 이러한 현상을 보정하기 위하여 다양한 펄스 중첩 현상 보정 기법과 펄스 신호 구분 기법이 활용되고 있으며, 각 각에 대한 딥러닝 응용 기법도 제안되고 있는데, 이 두 가지를 동시에 다루는 기법에 대해서는 아직 보고된 바 없다. 본 논문에서는 펄스 중첩 현상과 신호 구분을 동시에 다루는 방사선 계측기의 펄스 신호처리를 위한 딥러닝 기법 개발을 소개하고자 한다.

1. 서 론

방사선 계측의 원리는 방사선이 검출기 물질과 반응할 때 전달하는 에너지를 전기 신호로 변환하는 것으로, 방사선 계측기는 환경이나 시료에 존재하는 방사능을 측정, 평가하는데 주로 활용된다. 방사선 계측기는 검출기 물질에 따라 방사선의 유무만 확인할 수 있는 계수 용과 방사선의 에너지까지 확인할 수 있는 분광분석용으로 나눌 수 있으며, 방사선 신호는 펄스 형태의 전기신호로 변환되어 출력된다. 이때 측정 환경이나 시료에 방사능이 높은 선원이 존재할 경우 펄스 신호 여러 개가 중첩될 수 있기 때문에 이를 보정하기 위한 기법이 필요하다. 또한, 검출기 물질의 종류에 따라 입사하는 방사선의 종류에 따라 펄스 모양이 서로 다르게 발생되기도 하는데, 이 경우 발생한 펄스의 모양을 이용하여 계측기에 입사한 방사선의 종류를 구분할 수 있다. 방사선 계측 분야에서는 펄스 중첩 현상을 보정하기 위한 기법[1,2] 들과 방사선의 종류에 따른 펄스 모양을 구분하기 위한 기법[3,4]들이 많이 제안, 활용되고 있으며, 이는 고전적인 신호처리 기반의 기법부터 딥러닝 응용기법까지 다양하다. 두 가지 기법 모두 펄스의 모양을 분석하는 접근법이나, 두 가지를 동시에 다루는 연구는 아직까지 보고된 바 없다. 본 논문에서는 방사선 계측기에서 발생하는 펄스 신호를 입력으로 받아 펄스 중첩 현상 보정과 펄스 모양 구분을 동시에 수행할 수 있는 딥러닝 모델의 개발을 다루고자 한다.

2. 재료 및 방법

연구에 활용된 방사선 계측기는 중성자와 감마선과 반응하며 각 방사선마다 발생하는 펄스의 모양이 달라 두 가지 방사선을 모두 측정할 수 있는 플라스틱 섬광체(Stilbene, Irad Optics)이다. 여기에 섬광신호를 전기신호로 변환해주는 광증배관 (H7195, HAMAMATSU)과 연결 하였으며, 계측신호는 디지털이저 (N6751, CAEN)를 이용하여 획득하였다. 중성자 펄스 신호는 Cf-252 동위원소를 이용하여 획득하였으며, 감마선 펄스 신호는 Co-60과 Cs137 동위원소를 이용하여 획득하였다. 중성자는 물질과 반응하며 다양한 방사선을 내기 때문에 Cf-252의 계측 펄스에는 중성자와 감마선 신호가 혼재되어 있기 때문에, 고전적인 펄스 파형 분석 기법인 전하 적분 기법을 이용하여 두 신호를 구분해 주었다. 이렇게 중성자 펄스 신호와 감마선 펄스 신호들을 획득하여 해당 신호들을 임의로 합성하여 모델 학습 및 평가를 위한 데이터 세트를 생성하였다. 데이터세트는 총 10만개로써, 6만개는 학습, 3만개는 검증, 1만개는 테스트 세트로 활용되었다.

학습 모델은 1ns 간격의 996 채널의 길이를 가진 펄스 신호를 입력 받아 동일한 차원의 펄스 높이와 방사선 종류를 출력하는 이중 작업 학습 모델로써 996 채널의 입력을 128-64-32 채널로 압축하는 인코더 레이어를 공유하며, 펄스 높이와 방사선 종류를 각각 출력하기 위해 64-128-996 채널로 복원하는 디코더

레이어로 구성되어 있다.

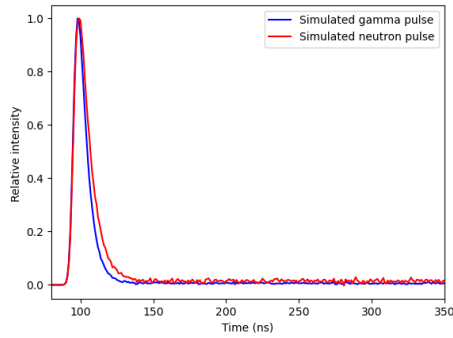


Figure 1 중성자와 감마 펄스 신호 예시




Figure 2 펄스 신호처리 모델의 구조

3. 실험 결과

모델은 파이썬 환경에서 파이토치 라이브러리[5]를 이용하여 구현하였다. 각 각의 과업에 대한 손실 함수는 평균 제곱 오차로 정의하였으며, 300 에포크 동안 ADAM 옵티마이저[6]를 이용하여 학습되었다.

학습된 모델은 그림 3, 4와 같이 입력 차원과 동일한 차원의 펄스 높이, 펄스 종류 구분 결과를 출력하였으며, 그림에 보이는 바와 같이 펄스 중첩 현상이 일어난 경우에도 높이와 방사선 종류를 잘 예측하였다. 테스트 세트에 대하여 펄스 높이 예측에 대한 평균 절대 상대 오차는 3.2 % 였고, 방사선 종류 예측에 대한 정확도는 91.5 % 였다.

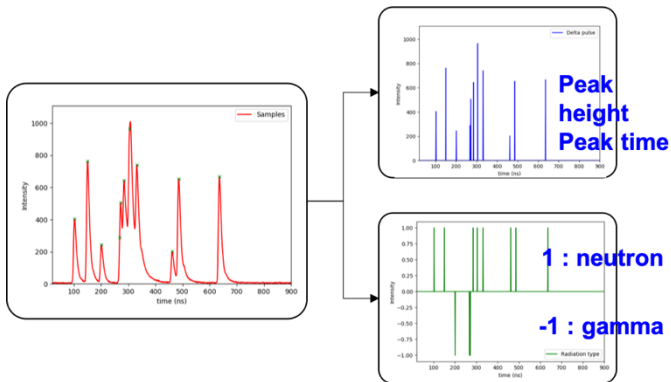


Figure 3 모델의 입력 값과 펄스 높이, 방사선 종류 예측 결과

4. 결론 및 고찰

본 논문에서는 방사선 계측기로부터 획득한 펄스 시퀀스를 입력으로 받아 펄스의 높이와 방사선의 종류를 구분하여 출력하는 이중 작업 학습 모델 개발을 다루었다. 펄스 높이 예측 결과는 테스트 세트에 대하여 평균 절대 상대 오차 3.2 % 이내의 오차를 보였으며 방사선 종류 예측 결과는 91.5 %의 정확도를 보였다. 모델의 성능의 하이퍼파라미터 최적화 또는 심층학습 모델 구조 변경 등을 통하여 개선 할 수 있을 것으로 예상되며, 모델 성능 개선 및 실험 데이터에 대한 모델 검증에 대한 후속 연구를 수행 할 예정이다.

ACKNOWLEDGMENT

본 연구는 해양수산부에서 지원하는 “지능형 대면적 중성자/감마선 검출기술 개발 (KIMST project No. 20200611)” 과제의 일환으로 수행한 것입니다.

참고 문헌

- [1] Westphal, G. P. (2008). Review of loss-free counting in nuclear spectroscopy. *Journal of Radioanalytical & Nuclear Chemistry*, 275(3).
- [2] Usman, S., & Patil, A. (2018). Radiation detector deadtime and pile up: A review of the status of science. *Nuclear Engineering and Technology*, 50(7), 1006–1016.
- [3] Ranucci, G. (2004, October). A review of the statistical foundations of the classical pulse shape discrimination techniques in scintillation applications. In *IEEE Symposium Conference Record Nuclear Science 2004*. (Vol. 2, pp. 804–809). IEEE.
- [4] Bertrand, G. H., Hamel, M., Normand, S., & Sguerra, F. (2015). Pulse shape discrimination between (fast or thermal) neutrons and gamma rays with plastic scintillators: State of the art. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 776, 114–128.
- [5] Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. In *Advances in Neural Information Processing Systems 32* (pp. 8024–8035). Curran Associates, Inc. Retrieved from <http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep->

learning-library.pdf

- [6] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.

Q-Learning 강화학습을 통한 적정재고 산출

손승아^o

한양대학교 소프트웨어융합대학

gongsoonyee@hanyang.ac.kr

A Reinforcement Learning Approach for Inventory Management using Q-Learning

Seungah Son^o

Division of Computer Science, Hanyang Univ. ERICA Campus

요 약

본 연구에서는 Model-free 강화학습 알고리즘인 Q-Learning을 이용하여 식음료업 소상공인 매장의 판매량을 예측하는 모델을 제안한다. 효율적인 재고 관리를 위해 유가, 기온, 강수량, 공휴일 데이터를 수집하고 분석해 이에 따른 소상공인 식음료업 매장의 판매량을 예측할 수 있음을 보이고, 향후 연구 발전 방향에 대해 논의한다.

1. 서 론

2021년 12월 28일에 발표된 통계청의 소상공인 실태조사에 따르면 2020년 소상공인 사업체는 1년 전과 비교해 4.7% 증가한 것에 비해 영업 실적은 43.1% 급감했다.[1] 눈여겨보아야 할 부분은 20대 이하가 대표자인 업체의 수는 전년 대비 69,000개에서 182,000개로 163.6% 증가했다는 점이다. 일반적으로 신선도가 상품의 질과 직접적으로 연관되어 있으며, 상품의 유통기한이 정해져 있는 식음료업 사업에서는 판매량 예측에 실패할 경우, 큰 손실로 이어지게 된다. 이러한 판매량 예측은 경험에 의존되는 경우가 많은데, 운영 경험이 상대적으로 부족한 소상공인은 재고 경영에 어려움을 겪을 가능성이 크다.

본 연구에서는 이러한 문제점 해결을 위해 유가, 기온, 강수량, 휴일 등의 데이터를 분석해 판매량을 예측해 소상공인의 재고 운영 가이드라인이 되어줄 모델을 제안한다.

2. Q-Learning

Q-Learning은 Q 함수를 이용하여 특정 상태에서 어떤 행동을 하는 것이 가장 최적인지를 학습하는 알고리즘이다. Q 함수에 관한 Bellman 방정식은 다음과 같다.[2]

$$Q(S_t, a_t) \leftarrow (1 - \alpha) * Q(S_t, a_t) + \dots \quad (1)$$
$$\alpha(r_t + \gamma * \max_a Q(S_{t+1}, a))$$

위의 식에서 α 는 Learning rate, γ 는 Discounting rate를 의미한다. 즉 a_t 는 다음 상태 S_{t+1} 에서 Q값을 최대로 만드는 행동을 의미한다. 본 연구에서는 해당 모델에 Epsilon greedy 탐색법을 적용해 초반에는 적극적으로 탐색하다 후반부로 갈수록 활용의 비율을 높이도록 설계하였다.

$$Action \ at \ time \ (t) \begin{cases} \max \ Q_t(a) & \text{with probability } 1 - \epsilon \\ \text{any action } (a) & \text{with probability } \epsilon \end{cases}$$

3. 데이터 수집

소비자의 구매 심리에 영향을 미치는 요인은 다양하다. 대표적으로 날씨와 기온은 직간접적으로 소비자의 감정에 영향을 미치고, 감정의 후속 행동인 소비 활동에 영향을 준다.[3] 또한 식음료 외식업계 판매량에는 휴일과 기념일 등이 큰 영향을 미친다. 이러한 연구를 바탕으로 본 연구의 종속 변수인 식음료업 매장의 판매량 데이터를 임의로 제작하는 과정에서 최종적으로 4개의 독립 변수를 선정해 가설을 세웠다.

- 1) 유가가 오르면 판매량에 음의 영향을 준다.
- 2) 폭염 또는 한파인 경우 외부 활동이 줄어들면서 판매량에 음의 영향을 준다.
- 3) 강수량이 많으면 판매량에 음의 영향을 준다.
- 4) 공휴일에는 판매량에 음의 영향을 준다.

이러한 가설을 바탕으로 독립 변수 데이터를 수집한 후, 식(2)를 세워 임의의 판매량 데이터를 제작했다.

$$a = 0.2, b = 0.6, c = 0.9, d = 0.1 \quad (2)$$

$$N = \frac{10 * (\text{지난 30일 판매량 평균})}{(a * \text{전일유가} + b * \text{강수량} + c * (\text{기온} - 15) + d * \text{연휴})}$$

if $N > 40$: 판매량 = $N - 10 + \text{random}(-5,5)$
else : 판매량 = $N + 20 + \text{random}(-5,5)$

표 1은 유가, 기온, 강수량, 연휴 여부 등을 통해 만들어낸 특정 상품 데이터의 일부를 보여준다. 유가 데이터는 오픈넷의 2015년 1월 1일부터 2020년 12월 31일까지의 두바이유 국제 가격을 활용했으며, 기온과 강수량 데이터는 같은 기간의 기상자료개방포털 중관기상관측 서울특별시 시간별 기온 자료를 활용했다.

표 1 특정 상품의 데이터 예시

일시	시간	전일 유가	기온(°C)	강수량(mm)	연휴	판매량
2015-01-01	00:00:00	53.60	-6.9	0.0	1	35
2015-01-01	01:00:00	53.60	-7.4	0.0	1	33
2015-01-01	02:00:00	53.60	-8.0	0.0	1	34
2015-01-01	03:00:00	53.60	-8.4	0.0	1	35
2015-01-01	04:00:00	53.60	-8.8	0.0	1	30
2015-01-01	05:00:00	53.60	-9.1	0.0	1	33
2015-01-01	06:00:00	53.60	-9.3	0.0	1	34

식(2)를 통해 만들어낸 판매량 데이터는 Savitzky-Golay 필터를 이용해 오차를 줄이고 매끄러운 자료를 만들어냈다.[4] 데이터 평활화에는 다양한 방법이 존재하지만, 대표적인 평활화 방법인 이동평균 (Moving Average) 필터는 평균값을 이용하기에 순간적인 peak outlier에 취약하다는 단점이 있다. 반면 Savitzky-Golay 필터는 회귀모델을 이용하기 때문에 주어진 데이터에서 순간적인 peak 값과 봉우리의 폭을 상대적으로 잘 보존한다는 특징이 있었기 때문에 선정하게 되었다.

65이다. Action의 결과가 실제 값과 같을 때 1을, 오차가 있는 경우에 보상으로 차이가 난 만큼의 음의 값을 보상으로 주었다. 모델의 하이퍼 파라미터로는 Learning rate 0.4, Discount rate 0.8을 적용했다. 환경은 open AI gym을 설치한 후 그 환경에서 agent를 작동시켜 전체 에피소드에 따라서 반복하면서 Q-table을 업데이트하면서 선택하도록 했다.

Q-Learning 모델을 이용해 향후 일주일 판매량을 예측한 결과는 그림 2와 같다. 실제 판매량 데이터와 유사한 동향을 보이고 있음을 알 수 있었으며 최종 RMSE는 8.931이다.




그림 2 판매량 예측 결과

5. 결론 및 개선 방향

본 논문에서는 시간별 판매량을 예측해 효율적인 경영을 돕는 Q-Learning 모델을 제안하였다. 날씨, 기온, 공휴일, 유가 데이터를 바탕으로 물품의 판매율을 예측하는 해당 모델은 기존에 경험이 의존해서 이루어졌던 매출 예측을 데이터 분석을 통해 체계적으로 행할 수 있으므로, 소상공인의 업무 부담을 경감시키고 불필요한 재고 발생의 확률을 줄이는 효과로 이어질 것으로 예상된다.

해당 연구에서는 한정된 기간의 데이터를 이용해 학습해야 한다는 점과 주 소비자의 연령대, 지역별 유동 인구, 인근 거주자 수 등 지역 소비자 특성을 포함한 외부 환경 요인을 반영하지 못했다는 단점이 있다. 따라서 후속 연구에서는 해당 모델의 정확도를 올리기 위해 더욱 다양한 지점의 판매 데이터를 학습시키고, 주 소비자를 분석하는 과정이 필요해 보인다.

참고 문헌

- [1] 통계청. 2020년 소상공인실태조사 결과, 2021.
- [2] Richard S. Sutton, Andrew G. Barato, Reinforcement Learning: An Introduction, 2008.
- [3] 성은영, 성현근, 최창규, 기상 요인이 식음료업의 매출에 미치는 영향 분석. 부동산학연구, vol.23, 2017.
- [4] Abraham. Savitzky, M. J. E. Golay, Smoothing and Differentiation of Data by Simplified Least Squares Procedures, Analytical Chemistry, vol.36, 1964.




그림 1 Savitzky Golay smoothing 적용 전후 비교

4. 모델의 상세 설계 및 학습 결과

이 연구에서 사용된 Q-Learning 모델은 매일 내일의 판매량을 예측하고, 그만큼의 재고를 미리 준비한다. 재고의 상황을 state, 신규 주문의 값을 action으로 정의할 때, agent가 가질 수 있는 state의 수는 창고의 최대 용량이다. 특별한 입력값이 없는 경우 최대 용량은