
Session 2 (안전진단세션)

좌장 : 정호상 인하대학교

• 시간 : 11:00 ~ 12:20

• 회의 URL: <https://inha-ac-kr.zoom.us/j/6035528835>

AzureKinect 와 시를 이용한 퇴행성 관절염 예측 진단 시스템 구축

황성환, 전호승, 김석찬, 김동현, 오승준, 김보윤, 강성우

열화상 이미지 객체검출과 공정능력지수기반 배전 설비 예측 진단 시스템

홍용민, 김남훈, 이형근, 전서영, 조승윤, 최효선, 강성우

진동 데이터를 활용한 승강기 고장 진단 시스템개발

정영진, 김성진, 김현수, 임민수, 정유진, 유재서, 조용식, 김민석, 강성우

Car crash detection using ensemble deep learning and multimodal data from dashboard cameras

최재경, 공찬우, 김경호, 임성훈 울산과학기술원



Azure Kinect 와 AI를 이용한 퇴행성 관절염 예측 진단 시스템 구축

황성환, 전호승, 김석찬, 김동현, 오승준, 김보윤, 강성우

인하대학교 산업경영공학과

2021 대한안전경영과학회
추계학술대회



목 차



서론

- 연구 동기
- 연구 목적

실험 진행 방법

- 연구 및 실험 진행도
- 실험계 구성
- 연구자 대상자 선정
- 관절 좌표 추출 GUI

실험 내용

- 보행 추적(Tracking)
- 정성적 Feature 수식화
- Feature의 유의성 검정
- Classification Model 비교

실험 결과

- 실험 결과 및 결론
- Future Work

1. 서론 - 연구 동기



Figure 1. <퇴행성 관절증 연도별 환자수 추이>




Figure 2. <퇴행성 관절증 연도별 요양급여비 추이> 자료: 건강보험심사평가원

- 퇴행성 관절증 환자수는 2014년 344만 명에서 2018년 387만 명으로 증가하고 있으며 2020년에는 400만명 예상
- 연도별 퇴행성 관절증 관련 요양급여 총액은 2014년 1조7억원에서 2018년 1조4,569억원으로 증가

고령화 추세에 따라 퇴행성 관절증 환자 및 관련 요양급여 총액은 계속 증가할 것으로 전망

1. 서론 - 연구 목적



Figure 3. <Electrogoniometer 착용>



Figure 4. <Azure Kinect>

- 기존 퇴행성 관절염 진단 시스템은 고비용을 소요하여 질병의 조기 발견 곤란
 - LED array 및 Electrogoniometer 등 고가 장비와 의사의 정성적 데이터 분석, 진단을 필요로 하는 기존 퇴행성 관절염 진단 비용은 약 \$9,200달러
- Azure Kinect와 AI 진단 시스템을 이용한 진단절차 및 비용 간소화 방안 제시
 - Azure Kinect의 key-point detection을 통해 추출되는 보행시간 별 관절좌표를 이용하여 퇴행성 관절염 발생 징후를 예측하는 AI 진단 시스템을 구축
 - 퇴행성 관절염 초기단계에 저렴하고 간단한 검사를 통해 질병의 조기 발견으로 더 심각한 수준으로 악화되지 않도록 예방하는 것을 목표
 - Azure Kinect 장비 가격은 약 \$400달러
 - AI 진단 시스템을 이용하여 고가의 분석, 진단 비용 불필요

2. 실험 진행 방법 - 연구 및 실험 진행도




Figure5. <연구 및 실험 Flow Chart>

1. 좌표추출

Azure Kinect 카메라를 이용한 환자의 관절 좌표 추출 (x,y,z 축 기준)

2. 데이터 분석

보행 속도, 양 발목이 벌어진 거리, 양 무릎이 벌어진 거리, 무릎의 각도 변화량을 분류 특성으로 사용

3. 환자 보행 판단

추출한 관절 데이터를 머신러닝/딥러닝 classification 알고리즘을 사용하여 환자 보행 분류 (병적 보행, 정상 보행)

2. 실험 진행 방법 - 실험계 구성





Figure6. <실험계 구성>


- 사용카메라: Azure Kinect
- 카메라로부터 거리: 2.21m~2.61m
- 걷는 거리: 2.49m



2. 실험 진행 방법 - 연구대상자 선정

- 연구대상자 선정 기준: 외형적 장애가 없는 건강한 20대 남녀 대학생
- 연구대상자 수: 29명(남: 12명, 여: 17명)
- 연구대상자 초기 접촉 과정: 본 연구에 대해 지성인(인하대학교 학생)을 대상으로 연구 목적과 필요성을 정확히 전달하고, 연구 동의서를 받은 후 실험 진행
- 자체적으로 정한 정상, 경증, 중증 보행의 특징을 학생들에게 설명 후, 정상걸음 10회, 경증걸음 10회, 중증걸음 10회 진행

7



2. 실험 진행 방법 - 관절 좌표 추출 GUI




Figure7. <메인 화면>




Figure8. <환자 정보 입력화면>

자체 개발한 Walk Pattern Collection Program을 통한 환자의 관절 좌표 추출

8

2. 실험 진행 방법 - 관절 좌표 추출 GUI

#	A	B	C	D	E	F	G	H	I	J
Time	Pelvis_X	Pelvis_Y	Pelvis_Z	Hip_X	Hip_Y	Hip_Z	HipR_X	HipR_Y	HipR_Z	
1	0.000	1483.717	-339.648	2128.296	1423.63	-300.259	2090.895	1285.761	-318.056	2185.461
2	0.006	1388.516	-331.077	2151.06	1390.452	-317.19	2078.224	1286.77	-343.6	2216.74
3	0.001	923.0991	-339.304	2139.927	932.9907	-324.874	2091.029	954.3892	-302.317	2211.072
4	0.726	906.3142	-326.497	2128.323	901.6606	-321.659	2047.899	930.2361	-349.08	2200.849
5	0.739	903.2091	-337.552	2128.232	898.2236	-325.747	2047.861	907.4322	-347.296	2200.888
6	0.792	890.2001	-342.77	2127.093	885.0772	-331.605	2046.146	894.8196	-352.837	2200.02
7	0.825	862.991	-351.467	2163.332	866.2712	-333.827	2085.412	880.0386	-367.374	2233.598
8	0.838	834.0995	-351.038	2169.156	843.2529	-334.526	2092.241	826.2218	-367.829	2228.512
9	0.891	812.2717	-353.129	2179.251	823.9204	-335.322	2102.541	801.7765	-369.187	2247.711
10	0.904	809.7651	-353.111	2181.487	821.3244	-335.364	2105.055	799.3458	-369.115	2249.959
11	0.957	790.983	-354.415	2207.061	765.6721	-338.452	2130.119	736.7961	-368.808	2270.32
12	0.99	708.7256	-349.491	2239.581	721.4296	-331.691	2161.269	697.2708	-365.557	2301.169
13	1.023	687.8747	-347.224	2251.78	697.4652	-328.037	2173.384	676.8469	-364.602	2322.054
14	1.056	662.8038	-353.572	2282.079	673.8476	-334.476	2203.285	652.8452	-370.790	2353.041
15	1.089	632.1591	-358.324	2297.917	638.3788	-336.789	2220.004	607.533	-377.788	2368.172
16	1.101	584.8333	-367.836	2302.087	583.8697	-348.774	2253.659	587.3046	-384.968	2372.81
17	1.155	573.2211	-376.78	2368.737	571.6982	-351.363	2293.2	575.3038	-388.194	2378.655
18	1.188	511.2702	-361.094	2392.838	517.4869	-350.613	2384.553	505.6642	-370.526	2333.381

Time	관절명	X	Y	Z	관절명	X	Y	Z
0.000	pelvis	1483.717	-339.648	2128.296	pelvis	1423.63	-300.259	2090.895
0.006	pelvis	1388.516	-331.077	2151.06	pelvis	1390.452	-317.19	2078.224
0.001	pelvis	923.0991	-339.304	2139.927	pelvis	932.9907	-324.874	2091.029
0.726	pelvis	906.3142	-326.497	2128.323	pelvis	901.6606	-321.659	2047.899
0.739	pelvis	903.2091	-337.552	2128.232	pelvis	898.2236	-325.747	2047.861
0.792	pelvis	890.2001	-342.77	2127.093	pelvis	885.0772	-331.605	2046.146
0.825	pelvis	862.991	-351.467	2163.332	pelvis	866.2712	-333.827	2085.412
0.838	pelvis	834.0995	-351.038	2169.156	pelvis	843.2529	-334.526	2092.241
0.891	pelvis	812.2717	-353.129	2179.251	pelvis	823.9204	-335.322	2102.541
0.904	pelvis	809.7651	-353.111	2181.487	pelvis	821.3244	-335.364	2105.055
0.957	pelvis	790.983	-354.415	2207.061	pelvis	765.6721	-338.452	2130.119
0.99	pelvis	708.7256	-349.491	2239.581	pelvis	721.4296	-331.691	2161.269
1.023	pelvis	687.8747	-347.224	2251.78	pelvis	697.4652	-328.037	2173.384
1.056	pelvis	662.8038	-353.572	2282.079	pelvis	673.8476	-334.476	2203.285
1.089	pelvis	632.1591	-358.324	2297.917	pelvis	638.3788	-336.789	2220.004
1.101	pelvis	584.8333	-367.836	2302.087	pelvis	583.8697	-348.774	2253.659
1.155	pelvis	573.2211	-376.78	2368.737	pelvis	571.6982	-351.363	2293.2
1.188	pelvis	511.2702	-361.094	2392.838	pelvis	517.4869	-350.613	2384.553

Figure9. <시간 별 환자의 관절 좌표가 저장된 csv 파일>

Figure10. <DB에 저장된 데이터>

보행시간별 각 관절 좌표 정보를 DB에 저장하고 csv 파일로 local에 저장
(자체 서버에서 Postgresql DB 사용)

3. 실험 내용 - 보행 추적(Tracking)




Figure11. <보행 촬영>

Table1. <Body Tracking Result Example>

Time (sec)	관반 X	관반 Y	관반 Z	...	오른 발목 Y	오른 발목 Z
t_0	x_0^{pelvis}	y_0^{pelvis}	z_0^{pelvis}	...	$y_0^{R-ankle}$	$z_0^{R-ankle}$
t_1	x_1^{pelvis}	y_1^{pelvis}	z_1^{pelvis}	...	$y_1^{R-ankle}$	$z_1^{R-ankle}$
...
t_{T-1}	x_{T-1}^{pelvis}	y_{T-1}^{pelvis}	z_{T-1}^{pelvis}	...	$y_{T-1}^{R-ankle}$	$z_{T-1}^{R-ankle}$
t_T	x_T^{pelvis}	y_T^{pelvis}	z_T^{pelvis}	...	$y_T^{R-ankle}$	$z_T^{R-ankle}$

* 정보 수집된 신체 부위는 관반, 엉덩이(L/R), 무릎(L/R), 발목(L/R)

Azure Kinect Depth Camera Body Tracker를 이용하여 피실험자의 보행을 측면에서 촬영하고 초당 30 프레임의 관절좌표를 추출하여 이를 기반으로 정상 보행과 병적 보행을 구분하는 것을 목적으로 분류 모델을 개발

3. 실험 내용 - 정성적 Feature 수식화




Figure12. <Knee's X Data>




Figure13. <Knee's Z Data>

신체부위의 X,Y,Z 축별 정상 보행과 병적 보행에서
유의한 차이를 보이는 특성 추출

3. 실험 내용 - F 검정을 통한 각 Feature의 유의성 검정

Table2. <일원배치법을 통한 유의성 검정>

Feature	F_0	기각역 ($\alpha = 0.01$)	유의성
Velocity	260.89	6.63	매우 유의
Ankle Z Gap	1325.80	6.63	매우 유의
Knee Z Gap	870.33	6.63	매우 유의
Ankle-Foot X Gap	108.16	6.63	매우 유의
Average Delta Angle	324.67	6.63	매우 유의

• 선형회귀를 통한 각 Feature Weight 계산

- Velocity (w_1) : -0.2133
- Ankle Z Gap (w_2) : 0.7017
- Knee Z Gap (w_3) : 0.3280
- Ankle-Foot X Gap (w_4) : 0.0342
- Average Delta Angle (w_5) : -0.3918

Ankle-Foot X Gap은 선형회귀를 통한 Feature Weight 계산을 통하여 목적에 부합하지 않은 Feature로 검증

Velocity, Ankle Z Gap, Knee Z Gap, Average Delta Angle 4가지의 Feature를 사용

3. 실험 내용 - 정성적 Feature(I)

I. 보행 속도

- 전체 보행 시간에 대한 $\Delta Pelvis_x$ 의 합을 보행 시간으로 나눈 것을 속도로 사용
- 보행자의 신체적 차이를 고려하기 위해 이를 각 보행자의 다리길이를 표준화
- 보행 속도 특성의 수식적 표현

$$Velocity_i = \frac{\sum_{t=0}^{T_i} \Delta Pelvis_{x_t}}{Subject_i's\ Leg\ Length_{t=0}}$$




Figure14. <Velocity>

3. 실험 내용 - 정성적 Feature(II)

II. 양 발목이 벌어진 거리

- 전체 보행 시간 동안의 $|Left\ Ankle_z - Right\ Ankle_z|$ 의 평균을 양 발목이 벌어진 거리로 사용
- 보행자의 신체적 차이를 고려하기 위해 이를 각 보행자의 골반길이를 표준화
- 양 발목이 벌어진 거리 특성의 수식적 표현

$$Difference\ of\ Z_{Left-Right\ Ankle}_i = \frac{\sum_{t=0}^{T_i} |AnkleL_z - AnkleR_z|_t}{Subject_i's\ Pelvis\ Length_{t=0}}$$




Figure15. <Difference of Left-right Ankle>

3. 실험 내용 - 정성적 Feature(Ⅲ)

Ⅲ. 양 무릎이 벌어진 거리

- 전체 보행 시간 동안의 $|Left\ Knee_z - Right\ Knee_z|$ 의 평균을 양 무릎이 벌어진 거리로 사용
- 보행자의 신체적 차이를 고려하기 위해 이를 각 보행자의 골반길이로 표준화
- 양 무릎이 벌어진 거리 특성의 수식적 표현

$$Difference\ of\ Z_{Left-Right\ Knee_i} = \frac{\sum_{t=0}^{T_i} |KneeL_z - KneeR_z|_t}{T_i} \div Subject_i's\ Pelvis\ Length_{t=0}$$




Figure16. <Difference of Left-right Knee>

3. 실험 내용 - 정성적 Feature(Ⅳ)

Ⅳ. XY 평면에서 본 무릎의 각도 변화량

- 전체 보행 시간 동안의 $|\Delta Angle_{Knee}|$ 의 평균을 무릎의 각도 변화량으로 사용
- 무릎 각도에 대한 특성이므로 별도의 표준화를 요하지 않음
- 무릎 각도 변화량 특성의 수식적 표현

$$Average_i\ of\ \Delta Angle_{Knee} = \frac{\left(\frac{\sum_{t=0}^{T_i} |\Delta Angle_{KneeL}|_t}{T_i} + \frac{\sum_{t=0}^{T_i} |\Delta Angle_{KneeR}|_t}{T_i} \right)}{2}$$




Figure17. <Average of Angle Knee>

3. 실험 내용 - Classification Model 구현 및 성능 비교

분류 모델은 선형 회귀 모델, 로지스틱 회귀 모델, 선형 SVM 모델, kernel SVM 모델, Decision Tree Model, Random Forest 모델, KNN 모델, ANN 모델로 구현한 후 각 분류기의 성능을 비교

- Training Data : 정상 보행 90개 | 병적 보행 90개
- Validation Data : 정상 보행 30개 | 병적 보행 30개
- Test Data : 정상 보행 220개 | 병적 보행 209개




Figure18. < Classifier Architecture >

Table2. <Classifier Performance Comparison>

Classifier	Train Accuracy	Validation Accuracy	Test Accuracy	mAP
Linear Regression Classifier	98.89%	98.33%	80.89%	76.36%
Logistic Regression Classifier	99.44%	100%	83.45%	79.09%
Linear SVM	99.44%	100%	85.55%	81.40%
Gaussian Kernel SVM	83.89%	83.33%	80.65%	75.34%
Decision Tree Classifier	100%	100%	91.14%	87.55%
Random Forest Classifier	100%	100%	91.14%	87.55%
KNN Classifier	100%	100%	78.79%	74.03%
1-Layer ANN Classifier	99.44%	100%	76.46%	71.88%
2-Layers ANN Classifier	99.44%	100%	82.05%	77.59%
3-Layers ANN Classifier	83.89%	83.33%	90.91%	87.48%

➡ 각 분류기에서 Hyper-parameter를 조정해가면서 Test Dataset Accuracy를 기준으로 Best Performance를 기재한 것




Table3. <Best Performance Hyper-parameter for each Classifiers>

Classifier	Hyper-parameter
Linear Regression Classifier	-
Logistic Regression Classifier	$\lambda = 0.025$
Linear SVM	$\lambda = 0.2$
Gaussian Kernel SVM	$\lambda = 10, \gamma = 0.01$
Decision Tree Classifier	Not relevant for Hyper-parameters
Random Forest Classifier	<i>Impurity = Gini, $N_{estimators} = 10$</i>
KNN Classifier	<i>Distance Measure = Manhattan Distance, $N_{neighbor} = 1$</i>
1-Layer ANN Classifier	<i>optimizer = SGD, learning rate = 0.001, momentum = 0.9, number of nodes on $L_1 = 12$, number of epochs = 20</i>
2-Layers ANN Classifier	<i>optimizer = SGD, learning rate = 0.001, momentum = 0.9, number of nodes on $L_1 = 4$, number of nodes on $L_2 = 12$, number of epochs = 20</i>
3-Layers ANN Classifier	<i>optimizer = SGD, learning rate = 0.0005, momentum = 0.9, number of nodes on $L_1 = 16$, number of nodes on $L_2 = 12$, number of nodes on $L_3 = 16$, number of epochs = 10</i>

λ 는 overfitting 방지를 위한 규제 파라미터이고, γ 는 가우시안 구의 크기를 제한하여 비선형성을 규제하는 파라미터

19



4. 실험 결과

- 실험 결과 및 결론
 - 약 91%의 정확도로 보행의 이상유무를 구분하는 성능을 가진 분류기 구현
 - 현재까지 수집된 데이터 상에서는 Decision Tree/Random Forest, 3-Layers ANN 모델의 테스트 성능이 타 기법 모델에 비해 우수
 - 실제 의료 현장 및 환자를 대상으로 수집한 데이터를 활용하여 분류 레이블을 다양화함으로써 더욱 세밀하고 정확도 높은 퇴행성질환 발생 예측 모델 개발 가능성 제시 (현재 서울 소재의 한 한의원에서 지속적으로 데이터 수집 중)

20

4. 실험 결과

• Future Work

- 환자의 기본정보, 발병 상태를 데이터화하여 질병 치료를 위한 협업 목적의 의료 체계 시스템 구축 가능
- 복합적인 질환의 예측 시스템과 통합해 퇴행성 질병의 발생 원인 규명하는데 참고할 수 있는 자료로써 사용될 수 있을 것으로 전망
- 실시간으로 3차원 보행작표 정보를 인식 가능한 카메라를 통해 질병 진행 단계 파악이 가능한 시스템 개발
- 다발성 경화증, 파킨슨 증후군, 갈랑 바레 증후군 등의 여러 종류의 퇴행성 질환의 증상을 조기진단 및 예측 모델 개발

21

참고문헌

- [1]류지선. (2008). 보행 시 퇴행성 관절염 환자의 동적 안정성 분석 (pp. 29). 한국운동역학회.
- [2]Conrad S. Tucker, Ishan Behoora, Harriet Black Nembhard, Mechelle Lewis, Nicholas W. Sterling, Xuemei Huang, Machine learning classification of medication adherence in patients with movement disorders using non-wearable sensors, Computers in Biology and Medicine, Volume 66, 2015, Pages 120-134, ISSN 0010-4825

22



열화상 이미지 객체검출과 공정능력지수기반 배전설비 예측진단 시스템

인하대학교 산업경영공학과

홍용민, 김남훈, 이형근, 전서영, 조승운, 최효선, 강성우

2021 대한안전경영과학회 추계학술대회



목 차



1. 서론	2. 실험 방법	3. 실험 결과	4. 결론 및 향후 연구
1.1 현황 및 문제제기 1.2 연구 방향	2.1 데이터 수집 2.2 이미지 객체 검출 2.3 전처리 2.4 배전설비 이상 예측 2.5 공정능력지수	3.1 이미지 객체검출 3.2 배전설비 이상 예측 3.3 공정능력지수	4.1 결론 4.2 향후 연구



1. 서론

1.1 현황 및 문제 제기



Fig1. 전기적 요인에 의한 화재 피해액과 사망자 수



Fig2. 변압기 화재 피해 현황




Fig3. 기존 변압기 점검 방식

- 최근 전기적 요인에 의한 화재 피해액 역시 2017년 약 1억 1천만원에서 2019년 약 2억 3천만원으로 증가하였으며, 변압기 열화현상으로 인한 화재피해가 연이어 발생하고 있음
- 이에 비해 변압기의 점검 방식은 진동 및 소음을 이용한 사후점검에 머무는 실정임

▶ 변압기의 열화현상을 사전에 확인할 수 있는 새로운 점검 방식의 도입이 필요함

3



1. 서론

1.2 연구 방향

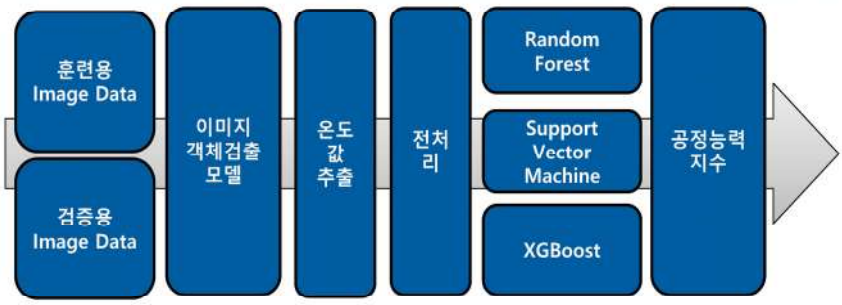


Fig4. 연구 프로세스

- 이에 위와 같이 변압기의 상태를 사전에 점검할 수 있는 변압기 실시간 모니터링 시스템의 도입을 목적으로 함

4

2. 실험 방법 | 2.1 데이터 수집




Fig5. 훈련용 열화상 이미지 데이터



Fig6. 검증용 열화상 이미지 데이터

이동지 이름	날짜	시간	온도	습도
202102251530A(1)	02월 25일	15:00	2.5	34
202102251530A(2)	02월 25일	15:00	2.5	34
202102251530A(3)	02월 25일	15:00	2.5	34
202102251530A(4)	02월 25일	15:00	2.5	34
202102251530A(5)	02월 25일	15:00	2.5	34
202102251530A(6)	02월 25일	15:00	2.5	34
202102251530A(7)	02월 25일	15:00	2.5	34
202102251530A(8)	02월 25일	15:00	2.5	34
202102251530A(9)	02월 25일	15:00	2.5	34
202102251530A(10)	02월 25일	15:00	2.5	34
202102251530A(11)	02월 25일	15:00	2.5	34

Fig7. 시간대별 온도 및 습도 데이터

- Figure 5는 훈련용 열화상 이미지 데이터로서, 640X480 해상도의 배전설비 열화상 이미지 데이터를 한국 전력공사로부터 16,866 장 제공받음
- Figure 6은 검증용 열화상 이미지 데이터로서, 인하대학교 후문가의 배전설비를 다양한 시간, 각도에서 832장 직접 촬영함
- Figure 7과 같이 촬영 일시의 온도 및 습도데이터를 기상청에서 크롤링 하여 배전설비 이상예측에 활용함.

5

2. 실험 방법 | 2.2 이미지 객체 검출




Fig8. 이미지 객체 검출 알고리즘 - YOLOv5

※ YOLOv5의 구성

1. Backbone단계 : CSP-Darknet을 사용하여 객체를 탐지하는 Feature Map을 생성
2. Neck단계 : Grid Cell을 수집하고, 전후단계(Backbone단계 - Head단계)를 연결
3. Head단계 : Feature Map에서 Bounding Box Regression과 Predict Classes 수행

➡ Bounding Box Regression과 Predict Classes를 동시에 수행하여 실시간 모니터링 시스템에 적합

6

2. 실험 방법 | 2.3 전처리



Fig9. Fir Tools Software




Fig10. 결측치 보완 과정

- 우선 객체검출 결과인 관심객체의 좌표를 기반으로 Figure 9와 같은 Flir Tools라는 소프트웨어를 통해 온도값을 추출
- 이후 Figure 10와 같이 YOLOv5가 검출해내지 못한 결측치들에 대해서 보완해주는 작업을 수행

2. 실험 방법 | 2.3 전처리




Fig11. 방사율 보정의 원리




Fig12. 오버샘플링의 예시

적용내용	속성 및 결연 구분		온도상승한도[deg]		
	속성값	결연구분	JEC 2200	IEC 76	ANSI 57.12
관련	지향법	에 자연 순환	55	65	65
		에 강제 순환	60	65(70)	65
결연유	온도계법	+외기 접촉	55	55	65
		+외기 미접촉	50	55	65

Fig13. 변압기 한계온도 기준

- 물체 표면에서의 에너지 방출정도를 의미하는 방사율 값으로 온도 보정. 여기서는 대부분 금속의 방사율인 0.95로 보정작업을 수행
- 이후 충분한 고장 데이터의 확보를 위해 Figure 12와 같은 오버샘플링 작업을 수행.
- IEC-76에 의거 변압기의 한계온도를 55도로 규정하고 해당 온도를 넘는 데이터를 1, 넘지 않는 데이터를 0으로 라벨링하여 변압기의 이상예측진단을 위한 데이터 프레임워크를 완성함

2. 실험 방법 | 2.4 배전설비 이상 예측




Fig14. 변압기 이상예측에 사용한 알고리즘. 왼쪽부터 RandomForest, Support Vector Machine, XGBoost

- 라벨링까지 완료한 데이터 프레임을 RandomForest, Support Vector Machine, XGBoost 세 알고리즘으로 배전설비 이상예측 진단을 수행.
- 이때 훈련데이터 세트와 검증 데이터 세트는 8:2의 비율로 나누어서 진행.
- 이후 예측의 성능을 평가하기 위한 지표로서, 혼동행렬(Confusion Matrix), 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-Score를 사용.




Fig15. 혼동행렬(Confusion Matrix)

$$\text{정확도(Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{정밀도(Precision)} = \frac{TP}{TP + FP}$$

$$\text{재현율(Recall)} = \frac{TP}{TP + FN}$$

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

2. 실험 방법 | 2.5 공정능력지수


Condition	Formula
Only upper standard limit	$\frac{USL - Mean}{3\sigma}$
Only lower standard limit	$\frac{Mean - LSL}{3\sigma}$
Both upper, lower standard limit	$\frac{USL - LSL}{6\sigma}$

Table1. 규격상,하한의 존재 여부에 따른 공정능력지수 산출식

C _p	Stage	Evaluation	Counterplan	Sigma level
C _p ≥ 1.67	Level 0	Very Sufficient	Cost Reduction	Level5
1.67 > C _p ≥ 1.33	Level 1	Sufficient	Keep Status	Level 4
1.33 > C _p ≥ 1.0	Level 2	Suitable	Monitoring Process	Level 3
1.0 > C _p ≥ 0.67	Level 3	Poor	Improve Management	Level 2
0.67 > C _p	Level 4	Very Poor	Review Fault Investigation	Level 1

Table2. 공정능력지수 별 평가 및 대책

- 공정능력지수는 공정의 규격 상한과 하한의 존재 여부에 따라서 산출식이 달라짐.
- 본 연구에서는 변압기의 한계온도를 규격상한으로써, 규격상한만을 가지는 경우의 산출식을 선택.
- 이후 공정능력지수의 값에 따라서 각 변압기의 단계를 0~4단계로 세분화 하였음.



3. 실험결과

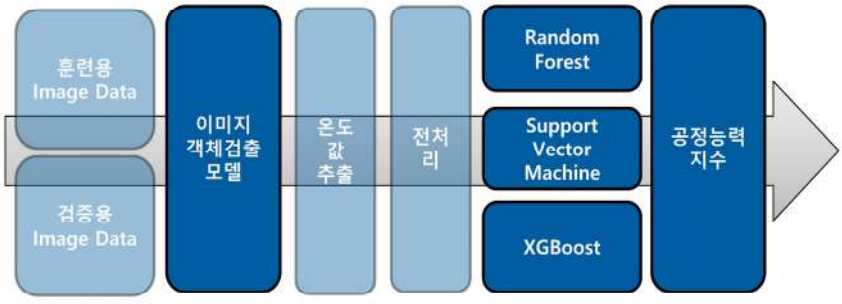



Fig16. Flow Chart


- 이미지 객체검출, 배전설비 이상예측, 공정능력지수에 대한 결과는 다음 슬라이드와 같음

1
1




3. 실험 결과

3.1 이미지 객체 검출

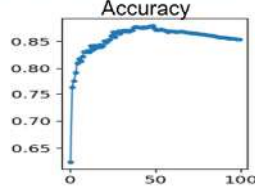


Input Image

YOLOv5



Output Image



Accuracy

100개 중
85개 검출

Epochs	Accuracy
100	85.32%
300	83.94%
500	81.68%

Fig17. YOLOv5 이미지 객체 검출 예시

Fig18. YOLOv5의 정확도 결과

Table3. Epoch별 YOLOv5의 정확도

- 한국전력공사로부터 제공받은 열화상 이미지로 YOLOv5를 학습시킨 후 직접 촬영한 변압기 열화상 이미지를 활용하여 성능 검증을 수행함.
- 100, 300, 500 Epoch로 반복 실험을 한 결과, 100Epoch의 경우가 85.32%로 가장 높은 정확도를 보임.
- 이는 100개의 변압기 중 85개의 변압기 객체 검출에 성공하였음을 의미함.

12



3. 실험 결과 | 3.2 배전설비 이상예측

Confusion Matrix	Random Forest		Support Vector Machine		XGBOOST	
	True	False	True	False	True	False
True	168	0	168	0	168	567
False	0	93,333	0	93,333	0	92,766
Accuracy	1.0000		1.0000		0.9939	
Precision	1.0000		1.0000		0.2286	
Recall	1.0000		1.0000		1.0000	
F1-Score	1.0000		1.0000		0.3721	

Table4. 배전설비 이상예측 결과

- Random Forest, Support Vector Machine, XGBoost 세가지 알고리즘 모두에서 99%이상의 정확도를 보임
- 변압기의 경우 **고장데이터를 쉽게 분류하는 것이** 중요한 만큼 Recall값이 세 알고리즘 모두에서 100%를 기록한 것은 매우 **유의미한** 지표임.



3. 실험 결과 | 3.3 공정능력지수

C _p	Count	Stage		Ratio
C _p ≥ 1.67	261,391	Level 0	Stability	99.47%
1.67 > C _p ≥ 1.33	17,632	Level 1		
1.33 > C _p ≥ 1.0	424	Level 2	Caution	0.16%
1.0 > C _p ≥ 0.67	24	Level 3		
0.67 > C _p	1,032	Level 4	Danger	0.37%

Table5. 배전설비 공정능력지수 결과

- 단순히 정상 / 고장으로 분류하는 것이 아니라 보다 세부적인 분류를 위해 공정능력지수를 도입.
- 0단계와 1단계를 '안정' 상태, 2단계와 3단계를 '주의' 상태, 4단계를 '위험' 상태로 구분하였음
- 안정 상태의 경우 99.47%, 주의 상태의 경우 0.16%, 위험 상태의 경우 0.37%의 결과가 산출되었음
- 주의상태와 위험상태의 합인 0.53%는 실 고장률인 0.18%를 포함하므로, 유의미한 평가지표임을 검증함.


인하대학교

4. 결론 및 향후 연구

4.1 결론 & 4.2 향후 연구

결론



- 기존의 배전설비 점검 방식과 달리 사전에 점검할 수 있는 점검방식을 열화상 이미지 딥러닝 기술과 공정능력지수의 도입을 통해서 구축하였음
- 단순 정상 / 고장의 분류가 아닌 Level 0 ~ Level 4의 5단계로 구분함으로 인해 보다 세분화된 분류가 가능함.

한계점



- 충분한 데이터의 확보만 가능하다면 배전설비 이외의 다른 열화현상을 원인으로 하는 분야에 적용 가능하여 시스템화 시킬 수 있음
- GUI의 도입으로 인해 관리자들에게 보다 높은 접근성 제공 가능

15


인하대학교

참고문헌

Cho, 2017. An Experimental Study on the Detection Characteristic of Draft Ice by Thermography System. Korea Academy Industrial Cooperation Society, 2017.05. 302-307(6 pages)

Kong J, Ha T, Lee Y. 2020. Study of an Oil Whip and Oil Whip Initial State Detect in Rotating Machine Using by Convolution Neural Network. KSFM J Fluid Mach. 23(3):5-12. doi:10.5293/ksfm.2020.23-3-005.

Korean Statistical Information Service. 2020. "Monthly property damage due to ignition factors". https://kosis.kr/statHtml/statHtml.do?orgId=156&tblId=DT_15601N_008&conn_path=I2

Ku K, Kwon J, Jin H. 2019. A Study on Searching Stabled EMI Shielding Effectiveness Measurement Point for Military Communication Shelter Using Support Vector Machine and Process Capability Analysis. Journal of the Korea Academia-Industrial cooperation Society Vol. 20, No. 2 pp. 321-328. 2019

Lee H. 2020. Analysis of partial discharge in medium-voltage cables using IR(Infra Red) camera. The Korean Institute of Electrical Engineers. 2020.7. 2170-2171 (2 pages)

Lee K, Kim S. 2020. Thermo-physical Properties of the Asphalt Pavement by Solar Energy. J Korea Acad Coop Soc. 21(1):717-724. doi:10.5762/KAIS.2020.21.1.717.

Lee S, Yoon Y, Jung J. 2020. A Machine Learning Model for Predicting Silica Concentrations through Time Series Analysis of Mining Data. J Korean Soc Qual Manag Vol. 48, No.3: 499-508. September 2020

Lee Y, Lee H, Jang H. 2021. Development of a New Similarity Index to Compare Time-series Profile Data for Animal and Human Experiments. J Korean Soc Qual Manag Vol. 49, No.2: 145-159 June 2021

Yiqi L. 2021. Density Adaptive Grid-based k-Nearest Neighbor Regression Model for Large Dataset. J Korean Soc Qual Manag Vol. 49, No.2: 201-211. June 2021

Min B, Yoo J, Kim S. 2021. Network Intrusion Detection with One Class Anomaly Detection Model based on Auto Encoder. Journal of Internet Computing and Services. Volume 22 Issue 1, Pages.13-22

Shi X, Hu J, Lei X. 2021. Detection of Flying Birds in Airport Monitoring Based on Improved YOLOv5. 2021 IEEE 6th Int Conf Intell Comput Signal Process ICSP 2021.0csp:1446-1451. doi:10.1109/ICSP51882.2021.9408797.

16

진동 데이터를 활용한 승강기 고장 진단 시스템 개발

인하대학교 산업경영공학과
정영진, 김성진, 김현수, 임민수, 정유진, 유재서, 조용식, 김민석, 강성우

2021 대한안전경영과학회 추계학술대회

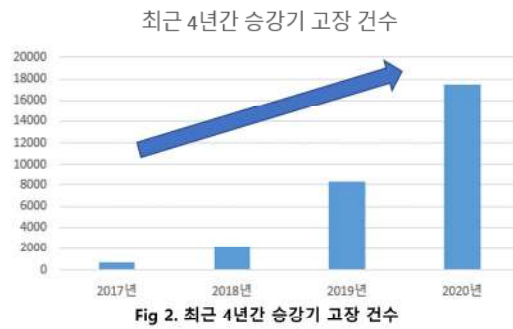



목차 / Contents

1. 승강기 고장 현황
2. 문제점 및 연구 목적
3. 연구 방법
4. 결론 및 향후 과제



1. 승강기 고장 현황



국내에 설치되어 운영 중인 승강기는 757,290대로 **역대 최대**
 승강기 고장 건수도 2017년 710건에서 2020년 17,450건으로 약 **24배 증가**
 승강기 수가 증가함에 따라 **고장과 사고 또한 계속 증가할 것으로 전망**

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



2. 문제점 및 연구 목적

문제점

- 승강기 고장 내용을 수리 기사기 **수기로 작성**하여 고장 내용 항목의 일관성 부족
- 고장을 진단하기 위해 주행 구간의 **경계를 지정하는 번거로움**
- 기존에는 **사람이 직접** 진동 데이터를 확인하여 고장을 진단
- 비슷한 진동 데이터를 고장 내용으로 **분류해야 하는 문제점** 존재

연구 목적

- 고장 내용을 **일관된 표기**로 바꿔 주는 시스템 개발
- 진동 데이터를 바탕으로 통계적 기법과 딥러닝 기법을 활용한 **고장 진단 자동화 시스템** 개발
- 시스템 개발을 통한 **인적 자원의 낭비 및 비용의 절감**

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 자카드 유사도

- 협력 기업 A사의 승강기 고장 데이터를 확인한 결과,
- 같은 고장임에도 다른 형식으로 표기되어 있는 문제를 발견
- 이는 수리 기사가 수리 일지를 수기로 작성하였기 때문
- 전문가조차 같은 고장을 다르게 해석할 수 있음

63689	111410L2;LXVF7	2012-03-30	2019-07-20	운행이상-도어동작이상
63690	111410L2;LXVF7	2012-03-30	2019-07-20	정지-정지
63691	111410L2;LXVF7	2012-03-30	2019-07-21	정지-정지
63692	111410L2;LXVF7	2012-03-30	2019-07-21	정지-정지
63693	111410L2;LXVF7	2012-03-30	2019-07-23	정지-정지
63694	111410L2;LXVF7	2012-03-30	2019-07-16	운행중정지
63700	111569L1;LXVF7	2012-03-29	2019-07-15	인터폰 불량
63701	111569L0;LXVF7	2012-03-29	2019-07-19	정지-OP/CL반복
63702	111569L0;LXVF7	2012-03-29	2019-07-10	정지-OP/CL반복
63703	111569L0;LXVF7	2012-03-29	2019-07-27	정지-정지
63704	111569L1;LXVF7	2012-03-29	2019-07-11	정지-OP/CL반복
63705	111569L14;LXVF7	2012-03-29	2019-07-26	정지-OP/CL반복
63706	111569L14;LXVF7	2012-03-29	2019-07-27	정지-도어고장 정지
63707	111581L0;SSVF7	2011-10-27	2019-07-05	정지
63708	111581L0;SSVF7	2011-10-27	2019-07-06	승강기(카) 소음발생
63709	111594L0;STVF7	2011-09-28	2019-07-30	열림/달힘 반복
63710	111602L0;SSVF7	2011-08-11	2019-07-08	운행중정지
63711	111655L0;STVF7	2012-03-16	2019-07-03	도어 동작 이상

Fig 3. 협력 기업 A사의 승강기 고장 데이터

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 자카드 유사도

HALL DOOR-SPRING
IN CAR and OPB-OPB PCB
CAR DOOR-CAR DOOR SILL
CAR DOOR-GATE SWITCH
IN CAR and OPB-CAR FLOOR BUTTON
IN CAR and OPB-BUTTON JACK
INDICATOR and 승장버튼-HALL DOWN BUTTON (HPB DOWN)
HALL DOOR-HALL DOOR SILL
T/M and BRAKE-BRAKE MICRO S/W
IN CAR and OPB-OPB ASSY
CAR DOOR-CAR DOOR CLUTCH

Fig 4. 승강기 고장 데이터 조치 부품 리스트

- 승강기 고장 데이터 조치 부품이 부품 가이드 항목에 일치하는지 시스템이 찾아서 일관된 데이터로 통일

01. 기계실 [Machine room]	04. 버튼 [Button]
1. 권상모프(주 로프) Main Rope	21. 운전반 및 버튼 (Operation Panel)
2. 구동 시차 Gear/Shaft (Main Shaft)	22. 흡유시기 Proton Indicator
3. 기어리스 전동기 Gearless Motor	23. 스마트 인디케이터 Smart Indicator
4. 제어반 Control Panel	24. 행선층 예약시스템 Destination/Selecting System
5. 인버터 Inverter	25. 카드키 Cardkey
6. 전액화생장치 Battery	26. 터치리스 숫버튼 Touchless Numeric Button
7. 브레이크 Brake	05. 소모품 [Expendables]
8. 로프 브레이크 Rope Brake	27. 릴레이 Relay
9. 브레이크 다발 플런저 Brake Piston Plunger	28. 비상안전 내타디 Emergency Contactor
10. 과속조절기 Governor	29. 전자 접촉기 Magnet Contactor
02. 승강로 [Hoistway]	30. 과부하 측정장치 Overload/Weighting Device
11. 가이드슈, 가이드롤러 Guide Shoe, Guide Roller	31. 리미트스위치 Limit Switch
12. 이동케이블 Traveling Cable	32. 레일우일 Oil
13. 환풍기 Blower	33. 가스켓 및 오일실 Gasket, Oil Seal
03. 도어 [Door]	06. 비상 [Emergency]
14. 손가압방지장치 Hand Nudging Preventive System (HNPS)	34. 자진감지기 Seismic Sensor
15. 멀티빔 Multi-Beam Door Safety Device	35. 비상통화장치 Emergency Intercom
16. 도어 인터록 스위치 Interlock Switch	36. 자동구출수단 자동착상장치 Emergency Landing Device
17. 승강장문 이월방지장치 Landing Door Preventive Device	37. LED비상조명장치 Emergency Lighting Device
18. 상 승 Emergency Stop	38. 비상정지장치 Safety Device
19. 도어행기 Door Hanger	25
20. 도어 인버터 Door Inverter	26

Fig 5. 승강기 고장 조치 부품 가이드

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 자카드 유사도



자카드 유사도:
집합 간의 유사도
측정 방식

$$J(S1, S2) = \frac{|S1 \cap S2|}{|S1 \cup S2|} = \frac{|S1 \cap S2|}{|S1| + |S2| - |S1 \cap S2|}$$

S1 = ['apple', 'banana', 'everyone', 'like']
S2 = ['apple', 'banana', 'coupon']

S1 ∩ S2 = {'banana', 'apple'}
S1 ∪ S2 = {'banana', 'apple', 'coupon', 'like', 'everyone'}

$$J(S1, S2) = \frac{2}{5}$$

- 승강기 데이터는 같은 의미의 항목들을 하나의 단어로 표현해야 함
- 단어의 일치도를 계산할 수 있는 자카드 유사도를 사용함

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 진동 데이터 경계 표시




Fig 6. 주행구간의 경계를 표시한 승강기 진동 데이터

B1 ~ B4 란?

- 주행구간을 나누기 위한 경계


구간을 나누는 것의 중요성

1. 구간별 진동 패턴 상이
2. 구간을 나누지 않으면 명확한 이상 원인 판독 불가

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 진동 데이터 경계 표시



- 한국 표준 협회 기준에 따라 사람이 직접 확인하여 표시한 B1 ~ B4 경계

- 통계 기법인 회귀 분석과 가중합을 이용하여 구한 B1 ~ B4 경계

Fig 7. 사람이 표시한 경계와 시스템이 표시한 경계의 비교
진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 고장 내용 판별 모델

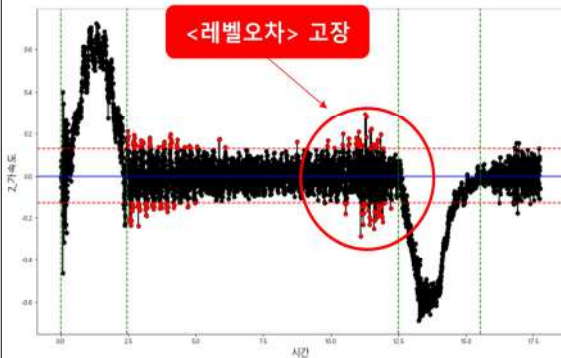


Fig 8. 진동 데이터를 통한 주행구간 내 이상탐지

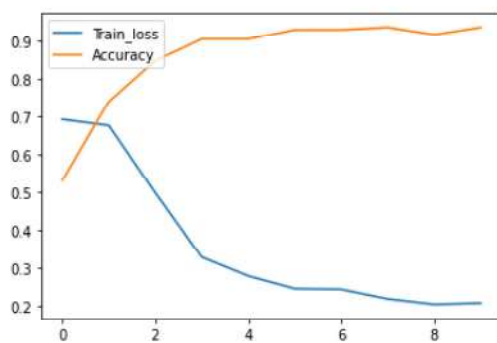


Fig 9. CNN 알고리즘을 이용한 고장 진단

- <레벨오차> 고장에 해당하는 진동 데이터

- CNN 알고리즘을 이용한 레벨 오차 고장 판별 알고리즘의 정확도 93.6%

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 고장 유형 클러스터링

K평균 알고리즘

- 주어진 데이터를 K개의 클러스터로 묶는 알고리즘
- 각 클러스터 간 거리 차이의 분산을 최소화하는 방식으로 동작함

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} |x_j - \mu_i|^2$$

- V : 전체 분산
- μ_i : i 번째 클러스터의 중심
- S_i : i 번째 클러스터에 속하는 점의 집합

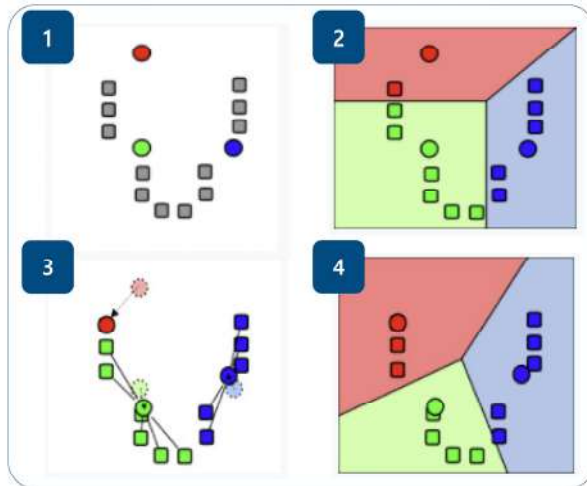


Fig 10. CNN 알고리즘을 이용한 고장 진단

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 고장 유형 클러스터링

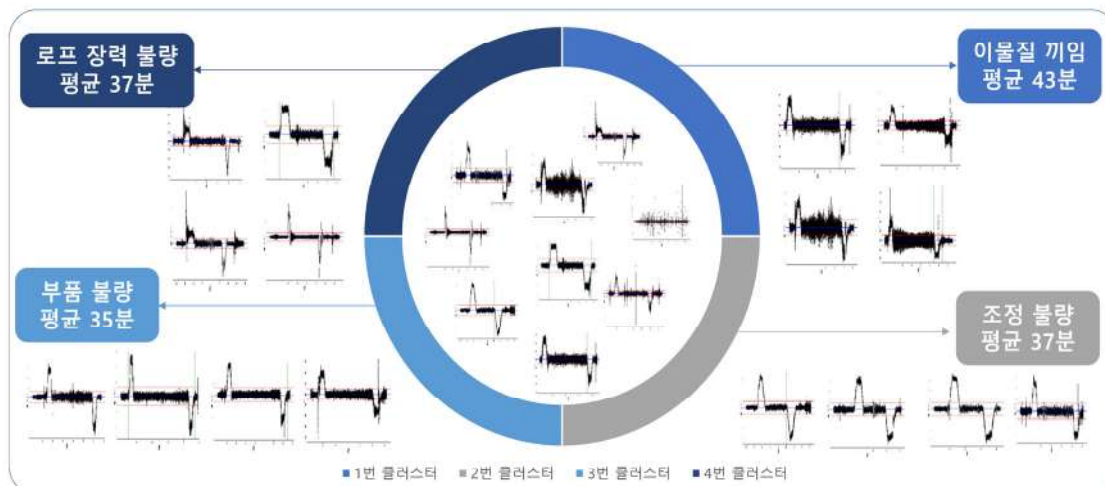
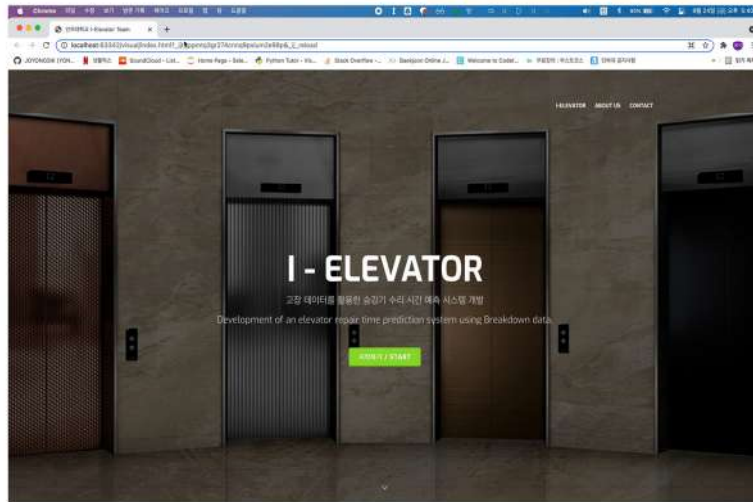


Fig 11. 고장 유형 클러스터링 결과

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



3. 연구 방법 - 시뮬레이션 예시



진동 데이터를 활용한 승강기 고장 진단 시스템 개발



4. 결론 및 향후 과제

결론

협력 기업으로부터 제공 받은 79만개의 데이터를 활용하여 승강기 고장 진단 시스템 개발

- 수기로 작성된 고장 내용을 일치시킴
- 주행구간 경계를 표시하는 시스템 개발
- 진동 데이터를 학습하여 고장 내용을 판별하는 모델 개발
- 고장 유형을 클러스터링 하는 시스템 개발

향후 과제

- 클러스터링 한 진동 데이터에 라벨링을 하여 인공지능 기반 지도학습 모델 구축
- 실시간으로 들어오는 진동 데이터의 고장 판단 시스템 개발
- 승강기 가용도 증가 시스템 개발

진동 데이터를 활용한 승강기 고장 진단 시스템 개발



Thank you



Car crash detection using ensemble deep learning and multimodal data from dashboard cameras

Jae Gyeong Choi^{1*}, Chan Woo Kong¹, Gyeongho Kim¹, and Sunghoon Lim^{1,2§}

¹Department of Industrial Engineering, Ulsan National Institute of Science and Technology, Ulsan 44919, Republic of Korea
²Institute for the 4th Industrial Revolution, Ulsan National Institute of Science and Technology, Ulsan 44919, Republic of Korea

* Presenting Author: Jae Gyeong Choi (choil6043@unist.ac.kr)
§Corresponding Author: Sunghoon Lim (sunghoonlim@unist.ac.kr)

Choi, J. G., Kong, C. W., Kim, G., & Lim, S. (2021). Car crash detection using ensemble deep learning and multimodal data from dashboard cameras. *Expert Systems with Applications*, 115400.

UNIST

2021년 대한안전경영과학회 추계학술대회

FIRST IN CHANGE

Automobile collision detection technology can be used for automatic brake operation and emergency structure through combination such as E-call

ex) E-call service (Emergency call service)



출처: ETRI


UNIST

2021년 대한안전경영과학회 추계학술대회

FIRST IN CHANGE

Car accident detection using video data (Crashcatcher)

- The video is processed as a frame and a three-dimensional RGB video is converted into gray scale to reduce the number of dimensions of each image.
- Hierarchical Recurrent Neural Network, HRNN



<https://github.com/rwk506/CrashCatcher>

Car accident detection using audio data (Crashzam)

- To distinguish the collision situation and the sound before and after the accident, two models of time and frequency features and spectrogram Image are used to determine whether the accident has occurred or not.
- Random forest classifiers

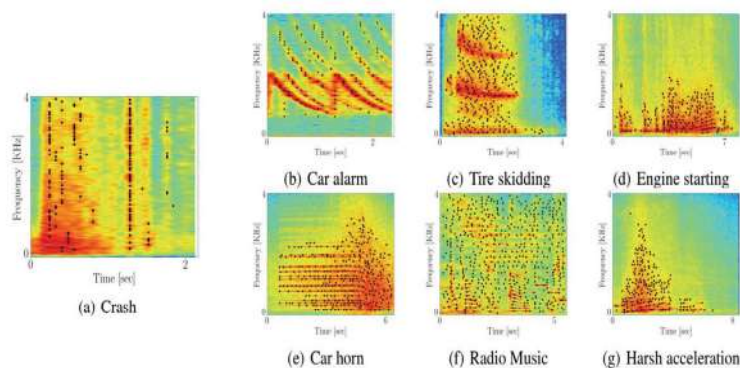
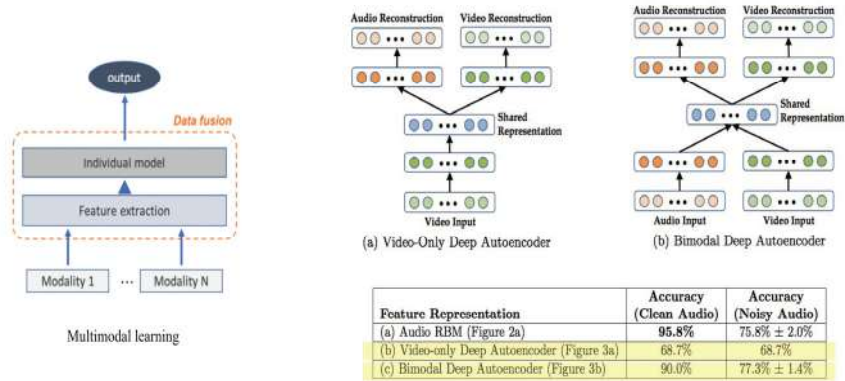


Figure 3: Example of spectrograms with constellation of peaks.

Sammarco, M., & Detyniecki, M. (2018). Crashzam: Sound-based Car Crash Detection. In VEHTS (pp. 27-35).

Multimodal learning

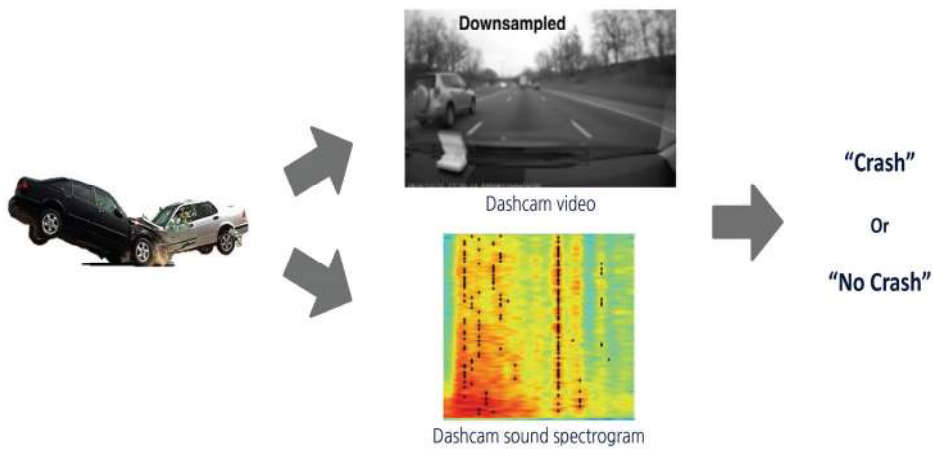
- The performance of the model is improved by combining several types of data with different characteristics collected in one resource.
- e.g., Speech classification using visual and auditory data



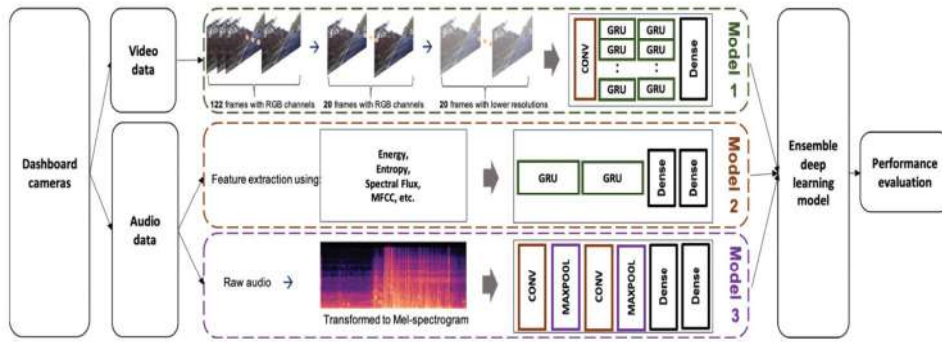
Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., & Ng, A. Y. (2011). 'Multimodal deep learning'. In Proceedings of the 28th international conference on machine learning (ICML-11) (pp. 689-696).ISO 690

Idea

- Existing vehicle collision detection models detect vehicle collisions using only one type of input data among sound, image, and sensors.
- It is expected that there will be a high need for a new model to detect vehicle collisions based on various types of data.




Proposed model



Overview of this research

Weighted average ensemble


- Contribution of each base deep learning model to the final prediction is weighted by the performance of the base deep learning model on validation data
- Weights indicate the percentage of trust or expected performance from each base deep learning model





$$w_1 \cdot \hat{y}_1 + w_2 \cdot \hat{y}_2 + \dots + w_n \cdot \hat{y}_n = \hat{Y}$$

Weighted Average Ensemble Architecture

Experiment results



1. A CNN-and-GRU using video data only
2. A GRU using audio features of audio data only
3. A CNN using spectrogram images of audio data only
4. 1+2
5. 1+3
6. 2+3
7. 1+2+3



THANK YOU