

제조업 노동자 근골격계 부담요인 데이터셋 클래스 분류와 유효성 검증

Class Classification and Validation of a Musculoskeletal Risk Factor Dataset for Manufacturing Workers

강영진¹ · 노태경² · 김기환³ · 정석찬^{4†}

동의대학교 인공지능그랜드ICT연구센터^{1,3}, 동의대학교 대학원 인공지능학과, 부산IT융합부품연구소²,
동의대학교 e비즈니스학과, 인공지능그랜드ICT연구센터, 부산IT융합부품연구소^{4†}

요약

제조업의 안전보건 기준은 다양한 항목이 존재하지만, 질병 재해자 기준에서 업무상 질병과 근골격계 질환으로 나눌 수 있다. 이 중 근골격계 질환은 제조업에서 가장 많이 발생하며, 나아가서 제조 현장의 노동생산성 감소 및 경쟁력 약화까지 유발할 수 있어서 이를 사전에 확인할 수 있는 시스템이 필요한 실정이다. 본 논문에서는 제조업 노동자의 근골격계 유해 요인을 검출하기 위하여 근골격계 부담작업 요인 분석 데이터 속성, 유해 요인 작업자세, 관절 키포인트를 정의하고 인공지능 학습용 데이터를 구축하였다. 구축한 데이터의 유효성을 판단하기 위해서 YOLO, Dite-HRNet, EfficientNet 등의 AI 알고리즘을 활용하여 학습하고 검증하였다. 실험 결과 사람 탐지 정확도는 99%, 탐지된 사람의 관절 위치 추론 정확도는 @AP0.5 88%, 추론된 관절 위치를 종합하여 자세를 평가한 정확도는 LEGS 72.2%, NECT 85.7%, TRUNK 81.9%, UPPERARM 79.8%, LOWERARM 92.7%를 도출하였으며, 추가로 딥러닝 기반의 근골격계 질병을 예방할 수 있는 연구에 필요한 요소를 고찰하였다.

■ 중심어 : 딥러닝, 작업자세 분류, 근골격계 질환, 포즈추론, 인간공학기반

Abstract

There are various items in the safety and health standards of the manufacturing industry, but they can be divided into work-related diseases and musculoskeletal diseases according to the standards for sickness and accident victims. Musculoskeletal diseases occur frequently in manufacturing and can lead to a decrease in labor productivity and a weakening of competitiveness in manufacturing. In this paper, to detect the musculoskeletal harmful factors of manufacturing workers, we defined the musculoskeletal load work factor analysis, harmful load working postures, and key points matching, and constructed data for Artificial Intelligence(AI) learning. To check the effectiveness of the suggested dataset, AI algorithms such as YOLO, Lite-HRNet, and EfficientNet were used to train and verify. Our experimental results the human detection accuracy is 99%, the key points matching accuracy of the detected person is @AP0.5 88%, and the accuracy of working postures evaluation by integrating the inferred matching positions is LEGS 72.2%, NECT 85.7%, TRUNK 81.9%, UPPERARM 79.8%, and LOWERARM 92.7%, and considered the necessity for research that can prevent deep learning-based musculoskeletal diseases.

■ Keyword : Deep Learning, Perception, AI training data, Object Detection, Autonomous Driving

2023년 05월 22일 접수; 2023년 06월 12일 수정본 접수; 2023년 06월 16일 게재 확정.

* 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 지역지능화혁신인재양성(GrandICT연구센터, IITP-2023-2020-0-01791) 사업의 연구 결과로 수행되었음.

† 교신저자 (scjeong@deu.ac.kr)

I. 서론

대한민국 경제활동인구 노령화가 진행되면서 업무상 질병 재해자는 2010년 약 7천 8백 명에서 2019년 1만 5천 2백 명으로 약 94.7%가 증가하였다. 업무상 질병 재해자 중 55세 이상의 질병 재해자는 2019년 8천 5백 명으로 300%가 넘는 수치이다[1]. 이러한 질병 재해자 기준에서 질병의 구분을 업무상 질병과 근골격계 질환으로 크게 나눌 수 있으며, 노동자의 부담작업 증상 방지 시 통증, 감각 이상 등 근골격계 질환으로 확장되고 있다. 예를 들어, 택배 저상차에서 택배 노동자의 작업 부담은 허리에 2.3배로 과로사의 원인으로 판명되는 등 근골격계 질환에 무방비한 상황임을 알 수 있으며, 제조업은 업무상 질병/사고 발생 정도가 타업종 대비 노동자의 질병 등으로 제조 현장 노동생산성이 감소하여 경쟁력 약화에 영향을 주고 있다.

산업안전보건기준에 관한 규칙 제12장 및 ‘근골격계 부담작업 범위 및 유해 요인조사 방법에 관한 고시’에 의거하여 적용 사업장은 유해요인 조사를 실시해야 하며, 근골격계 부담작업 유해요인 조사는 사업장이 지침에 따라 3년마다 조사를 수행하여야 하나, 중소기업 및 소규모 사업장은 전담팀 인력 확보, 조사 시간 및 비용 등의 문제로 자체 수행에 어려움을 겪고 있는 실정이다. 기존의 근골격계 부담작업 판별 방법은 인간공학 전문가들이 많이 사용하고 있는 설문조사 방법과 워크샘플링 (Work Sampling), 인간공학 적 평가기법에 근거한 작업측정 방법이 주로 사용되고 있지만, 이는 위에서 언급한 문제와 같이 큰 비용과 시간 등의 문제를 포함하고 있다[2-4].

이러한 문제를 해결하기 위해 딥러닝 기반 노동자 자세 모델링과 학습을 수행하여 인간공학 기반 근골격계 위험요인 분석과 평가를 지원하는 플랫폼을 개발하여 제조 현장에 적용하고 작업환경을 개선하려는 시도들이 국내·외에서

진행되고 있다.

기존의 인간공학적 관점의 평가 방법은 OWAS (Ovako Working Posture Analysis System), RULA (Rapid Upper Limb Assessment), REBA (Rapid Entire Body Assessment) 등의 평가자 수작업을 바탕으로 발생하는 인체 부위별 측정값 (각도, 무게, 자세 등)에 대한 정확도 및 평가시간 등을 개선하기 위하여 자동화된 인공지능 기법들이 도입되고 있다. 특히 인체의 Skeleton을 정의하고 이를 인체의 각종 자세 및 각 관절이 이루는 각도를 자동으로 계산하여 OWAS나 RULA의 판정법에 적용하는 기술 개발의 필요성이 점차 대두되고 있다[5-8].

이와 더불어 정부에서는 데이터 혁신을 주도하기 위해서 많은 양의 데이터를 수집하여, 저장 및 분석을 통한 서비스 기술의 중요성을 언급하고 있다. 이를 바탕으로 국내에서는 빅데이터 구축, AI 융합 확산을 발표하면서 디지털화에 대응하고 디지털 기반 경제혁신의 필요성을 언급하고 있다. 이처럼 기술 선도국가 간의 기술 격차 해소를 위해서는 양질의 인공지능 학습용 데이터 구축이 최우선으로 요구되며, 학습데이터 구축은 산업 전반 분야에 대한 활용성 고려와 산업 동향을 비추어 시대 변화에 대응할 수 있도록 구축되어야 할 필요성이 있다.


본 논문에서는 노동자의 근골격계 부담작업 유해 요인을 분석하기 위해 실제 제조환경의 노동자 작업자세 (자세 정보, 각도/위치정보, 부가 정보 등)에 대한 인공지능 학습용 데이터를 구축하였다. 구축한 데이터에 대한 유형을 소개하고, 유효성을 판단할 수 있게 AI 알고리즘을 통해 그 결과를 분석하고자 한다.

II. 관련 연구

기존의 근골격계 부담작업 판별 방법을 살펴보면, 설문조사 방법의 경우, 작업 노동자 및 관

리자 등 노사의 의견을 바탕으로 부담작업 평가표를 이용하여 하루에 2시간 이상 수행하는 단위작업에 대한 부담작업의 해당 여부를 묻는 방식으로 진행한다. 이러한 방법은 피조사자가 부담작업 여부를 추측하여 응답하기 때문에 누락(부담작업이 있으나 없다고 판정된 경우) 또는 허위(부담작업이 없으나 있다고 판정된 경우)로 그 의미의 정확성을 판별하기 어려운 문제가 존재한다.

다른 방법으로는 워크샘플링 방법이 있으며, 이 방법은 간헐적으로 랜덤한 시점에서 연구대상을 순간적으로 관측하여 대상이 처한 상황을 파악하고, 이를 토대로 관측 기간에 나타난 항목별로 비율 추정을 하는 방식이다. 워크샘플링 방법을 사용하면 설문조사 방식에서 발생하는 누락 또는 허위 판정의 오류를 제거할 수 있으며, 국내·외에서는 근골격계 질환 예방과 관련한 작업측정 방법으로 캠퍼코더를 이용하여 작업모습을 촬영한 후 작업 장면들의 표본을 추출하여 분석하는 것을 일반적으로 적용하여 사용하고 있다.



〈그림 1〉 작업 과정에서 촬영된 영상 특정 시점 작업 장면 샘플링

인간공학적 평가기법에는 크게 OWAS, RULA, REBA로 구분 지을 수 있다. 먼저, OWAS[9-10]는 Karhu 등이 1977년 철강업에서 노동자들의 부적절한 작업 자세를 정의하고 평가하기 위해 개발한 대표적인 작업자세 평가기법으로 비디오로 작업을 촬영하여 신체 부위별로 정의된 자세 기준에 따라 자세를 기록해 코드화하여 분석하는 기법이다. 이 기법은 배우기 쉽고, 현장에

적용하기 쉬운 장점 때문에 많이 이용되고 있으며, 작업자세 특성에 대한 정성적인 분석에 주로 적용되고 있다.

다음으로 RULA[11] 기법은 영국의 노팅햄대학에서 1993년에 어깨, 팔목, 손목, 목 등 상지에 초점을 맞추어 작업 자세로 인한 작업부하를 평가하기 위해 개발한 기법이다. 이 기법은 OWAS 기법과 마찬가지로 분석자가 관찰을 통해 작업자세를 분석할 수 있도록 고안된 것이나, OWAS 기법 계통의 작업자세 평가기법과는 다르게 작업 자세 분류체계에 부하 수준을 정의하고, 이를 근거로 작업부하를 분석하는 방법을 이용하고 있으며 접근방식이 더 합리적이다. 하지만, 상지의 분석에 초점을 두고 있어서 OWAS 기법 보다는 전신의 작업자세 분석에는 한계가 있으나, 상체의 작업부하가 많이 부과되는 작업의 작업 자세에 대한 근육 부하를 평가하기 위해서는 더 효율적으로 적용될 수 있다.

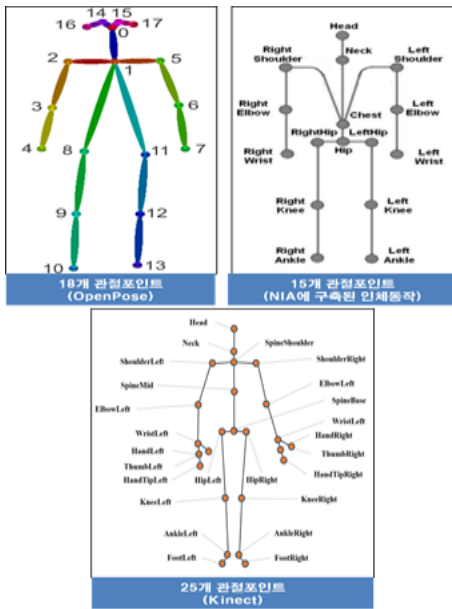
마지막으로 REBA[12] 기법은 근골격계 질환과 관련한 위해 인자에 대한 개인 노동자의 노출 정도를 평가하기 위한 목적으로 개발되었으며, 특히 상지작업을 중심으로 한 RULA와 비교하여 예측하기 힘든 다양한 자세에서 이루어지는 서비스업에서의 전체적인 신체에 대한 부담 정도와 위해 인자의 노출 정도를 분석하기 위한 목적으로 개발되었다.

2.1 국내·외 관절 키포인트 동향

앞서 설명한 바와 같이 인간공학적 관점의 평가 방법의 평가자 수작업을 통하여 진행함으로써 발생하는 인체 부위별 측정값에 대한 정확도 및 평가시간 등을 개선하고 현장에 적용하기 위해서는 자세의 정의에 따라 구축된 인공지능 학습용 데이터 구축이 필요하며, 실제 제조환경에서의 작업자세 (자세 정보, 각도/위치정보, 부가 정보) 데이터를 구축하고 정량화하여 서비스를 개발할 필요가 있다. 특히 인체의 Skeleton을 정

의하고 인체의 각종 자세 및 각 관절이 이루는 각도를 자동으로 계산하여 인간공학적 관점의 평가 방법의 판정법에 적용하는 기술 개발을 위해서는 사람의 관절을 데이터로 표현한 관절 키포인트 데이터가 중요하다.

먼저, OpenPose[13]는 2017년 CPR에서 최초로 제시되었으며, 하나의 이미지로부터 몸, 손, 얼굴 및 발을 포함하여 총 18개의 관절 포인트를 가지고 있다. 먼저 키포인트들을 모두 도출해낸 뒤, 이들을 Instance에 따라 구분하는 Bottom-up 방식을 사용하여 다중 사람에 대한 작업을 진행하는 대표적인 라이브러리다. 이외에도 25개의 관절 키포인트를 가지는 Kinect과 국내에서 15개 관절 키포인트를 가지는 NIA 데이터 셋도 존재한다.



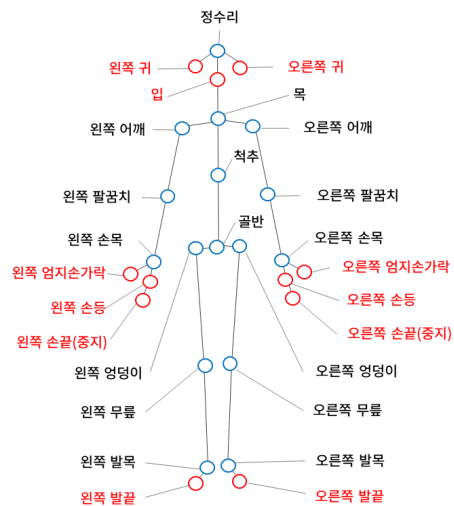
〈그림 2〉 대표적인 관절 키포인트

기존에 구축된 데이터는 재활이나 스포츠 산업을 위해 구성되어 있으며, 동작에 대한 데이터의 목적을 주로 해서 제조업의 작업자 근골격계 부담작업을 평가하는 목적으로는 적절하지

않다. 특히 안전을 위하여 작업자 착용 보호구를 사용할 시 사람의 얼굴 관절 미인식의 결과를 도출할 수 있다. 이는 제조업 노동자의 근골격계 유해 요인 평가를 위한 데이터 구성으로는 유용하지 않으며, 인간공학 전문가들이 요구하는 전신사진에서 허리/상체/하체 등에 대한 작업 자세를 분석하고 평가할 수 있도록 27개 관절 키포인트의 학습데이터가 필요한 실정이다. 또한 기존 방법에서 추가되는 키포인트는 각 관절의 정확한 각도 계산을 위하여 눈, 코, 엄지, 약지, 발끝 등 정보를 활용할 수 있어야 한다.

III. 데이터 구조 및 유효성 검증

구축한 데이터는 다음과 같다. 먼저, 제조업 노동자의 근골격계 데이터 구축을 위해 제조기업 4곳을 선정하고, 다양한 작업 자세를 위해 작업장 공정별 16개 카테고리(절단, 벤딩, 사상, 용접, 조립, 레이저가공, 포장, 적재, 선별, 가공, 주조 등)로 나누었다. 또한 작업자의 전신을 기준으로 총 12만 장을 구축하였으며, 다음 표 1은 부위별 작업자세(자세 정보, 각도/위치정보, 부



〈그림 3〉 27개의 관절 포인트 구조

〈표 1〉 데이터 작업자세 속성 정의

부위	상세부위	평가틀			분류(측정여부)
		OWAS	RULA	REBA	
목	Neck Position		✓	✓	뒤로 젖힘
			✓	✓	0~10도 굽힘
			✓	✓	10~20도 굽힘
			✓	✓	20도 이상 굽힘
	Neck Adjust		✓	✓	비틀림
			✓	✓	옆으로 구부림
어깨 (상완)	Upper arm Position		✓	✓	-20도 이상 뒤로
			✓	✓	-20도 뒤로~20도 앞으로
			✓	✓	20~45도 앞으로
			✓	✓	45~90도 앞으로
			✓	✓	90도 이상 위로
	Upper arm Adjust		✓	✓	위팔 벌어짐
			✓	✓	어깨 들림
			✓	✓	팔이 지지되거나 어딘가에 노동자가 기댐
손목	Wrist Position		✓	✓	15도 이상 들림
			✓	✓	중립
			✓	✓	-15도 아래~15도 사이
			✓	✓	-15도 이상 꺾임
	Wrist Adjust		✓	✓	손목이 옆으로 굽혀짐(deviation)
			✓	✓	중립에서 비틀림
팔	Lower arm Position		✓	✓	0~60도 (위팔 수직선에서)
			✓	✓	60~100도 (위팔 수직선에서)
			✓	✓	100도 이상 (위팔 수직선에서)
	Lower arm Posture	✓			양손을 어깨 아래로 내린 자세
		✓			한 손만 어깨 위로 올린 자세
		✓			양손 모두 어깨 위로 올린 자세
	Lower arm Adjust		✓	✓	위팔이 교차 또는 몸통을 벗어남
✓				물건을 들고 있음	
허리	Trunk Position		✓	✓	-20도 이상 뒤로 젖힘
			✓	✓	-10~20도 뒤로 젖힘
			✓	✓	-10~0도 뒤로 젖힘
			✓	✓	똑바로
			✓	✓	0~20도 굽힘
			✓	✓	20~60도 굽힘
			✓	✓	60 이상 굽힘
	Trunk Posture	✓			곧바로 편 자세(서 있음)
		✓			상체를 앞으로 20도 이상 굽힌 자세
		✓			바로 서서 허리를 옆으로 20도 이상 비튼 자세
✓				상체를 앞으로 굽힌 채 옆으로 비튼 자세	

부위	상세부위	평가틀			분류(측정여부)
		OWAS	RULA	REBA	
다리	Trunk Adjust		✓		허리 지지됨
			✓	✓	비틀림
			✓	✓	옆으로 구부림
	Legs Position			✓	무릎을 30~60도 굽힌 자세
				✓	무릎을 60도 이상 굽힘
	Legs Posture	✓			앉은 자세
		✓			두 다리를 펴고 선 자세
		✓			한 다리로 선 자세
		✓			두 다리를 구부린 선 자세
		✓			한 다리로 서서 구부린 선 자세
✓				무릎을 꿇는 자세	
Legs Adjust		✓		걸기	
			✓	다리가 지지된 상태	

가 정보)의 속성을 정의한 내용이다. 평가 항목은 각 부위 자세 분류 값을 평가할 수 있는 항목을 조사한 것으로 각각의 자세별로 포즈 추론한 값을 대입하고, 자세 분류와 연관하여 부담작업 유해 요인을 점수화할 수 있다.

다음으로 본 논문에서 소개하는 27개의 관절 포인트는 다음과 같다. 먼저, 그림 2에서 소개한 국내·외 기관에서 이미 구축된 관절 포인트에서 최소 2개에서 최대 12개까지 키포인트의 차이를 나타내며, 그림 3에서는 파란색으로 표현된 관절 포인트는 기존에 구축된 부분이다. 빨간색으로 표현된 관절의 포인트는 본 논문에서 인간공학적 평가를 위해 필요한 요소로 추가한 관절 포인트로 볼 수 있다.

마지막으로 라벨링 속성 정의는 표 2와 같이 관절에 대하여 위치/각도 정보(젓혀짐, 꺾임, 들림, 올린 자세, 내린 자세 등)를 표현하였다. 또한 기본자세 외에도 부가 정보를 통해 다양하게 표현하여 유해 요인을 판별할 수 있도록 구성하였다.

〈표 2〉 라벨링 속성 정의

No	속성명	항목설명	타입
1	images	이미지 정보	list
1-1	id	식별자	number
1-2	images[].id	이미지 식별자	number
1-3	images[].file_name	이미지 파일명	string
1-4	images[].width	이미지 너비	number
1-5	images[].height	이미지 높이	datetime
1-6	images[].date_caputred	취득 시간	datetime
1-7	images[].camera_angle	카메라 구도	string
2	annotations	라벨링	list
2-1	annotations[].id	어노테이션ID	number
2-2	annotations[].image_id	이미지 식별자 매칭	number
2-3	annotations[].factory_no	작업장/사업장	number
2-4	annotations[].process_id	작업공정	number
2-5	annotations[].bbox	작업자 인식	list
2-6	annotations[].keypoints	키포인트 수	list
2-7	annotations[].POSTURE	작업자세 자세정보	list
2-8	annotations[].ADJUST	작업자세 부가정보	list

3.1 AI 학습용 데이터 유효성 검증

인공지능 학습용 데이터셋 활용에 대한 품질

지표인 유효성을 검사하기 위해서는 활용 분야별로 다양한 지표를 사용할 수 있다. 유효성은 학습용 데이터를 인공지능 알고리즘으로 훈련

했을 때 분류성능, 탐지성능, 인식성능, 질의응답, 기계번역 등에 대해 목표로 했던 수준의 성능 달성이 가능한지에 대한 부분으로 정의된다. 구축한 학습용 데이터셋은 작업자의 위치를 탐지할 수 있게 바운더리 박스 형태로 라벨링되었으며, 사람의 관절을 추론하기 위해서 키포인트 좌표값, 작업 자세를 분류할 수 있는 형태로 구성이 되어 있다.

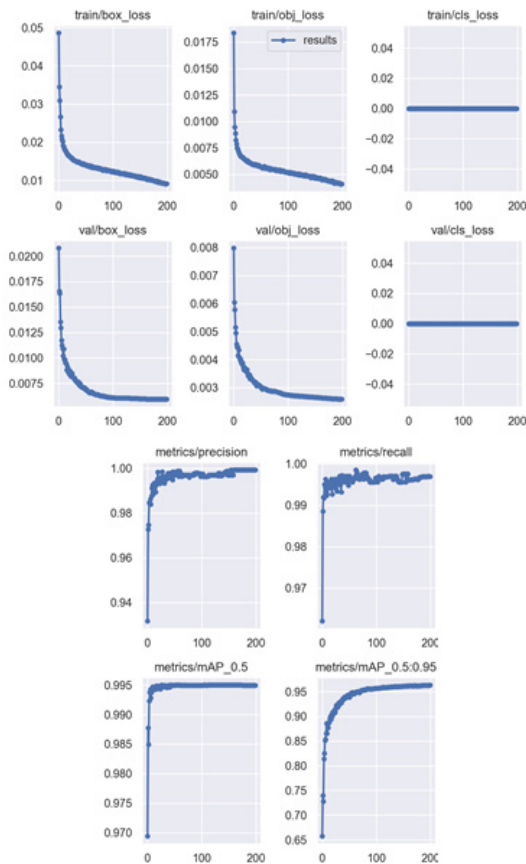
이를 통해 사람의 위치를 식별하기 위한 객체 탐지, 식별된 사람의 관절 키포인트 탐지, 관절의 상태를 종합하여 작업 자세 분류를 할 수 있게 3개의 모델을 기반으로 유효성을 진행하였다. 객체 검출을 위해 Yolo[14] 알고리즘을 활용하였으며, 작업자를 검출하는 역할을 한다. 그리

고 검출한 작업자의 키포인트 탐지를 위해 Dite-HRNet[15] 알고리즘과 검출한 키포인트의 연결을 통해 스켈레톤 이미지로 결과를 확인할 수 있게 진행하였다. 마지막으로, EfficientNet[16] 알고리즘을 사용하여 공정별 작업 자세를 분류할 수 있게 구성하였다.

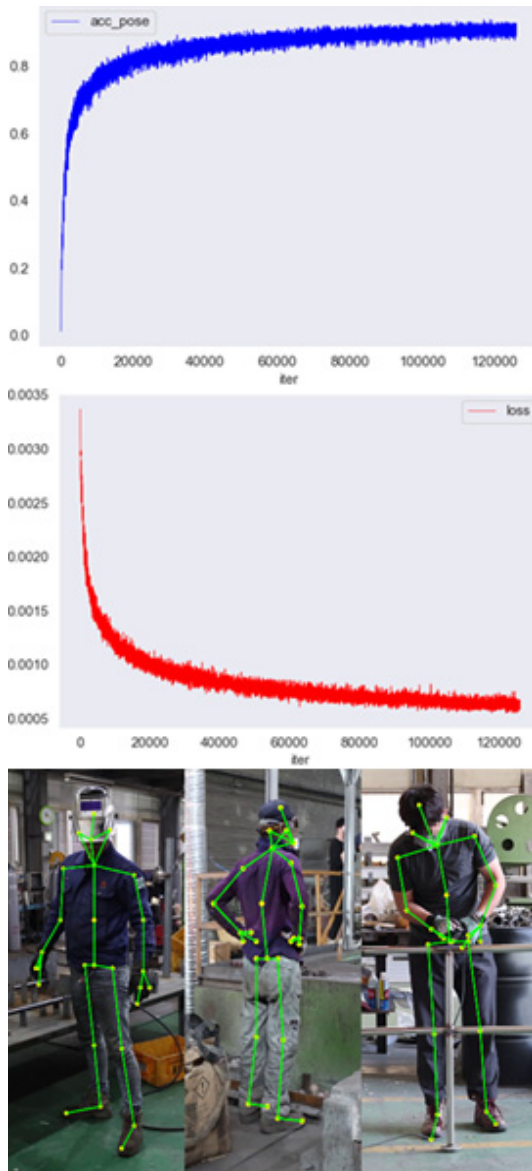
먼저, 객체 탐지를 위해 작업장별로 촬영된 작업자 이미지를 총 13,682개를 사용하였으며, 10,945개의 학습용 데이터, 1,368개의 검증용 데이터 및 1,369개의 평가용 데이터로 구분 지어서 사용하였다. 기존의 데이터가 4k로 구성되었기에 이미지를 640사이즈로 리사이징하여 사용하였고, 반복 학습을 위해 epochs는 200번, Batch_size는 16으로 입력값을 주고 학습을 진행하였다. 성능 고도화를 위해서 하이퍼파라미터 튜닝을 진행하여 최적화된 학습모델을 구성하여 객체 검출 정확도를 99% 달성하였고, 그림 4와 같이 주요 성능지표를 확인할 수 있다.

다음으로 키포인트를 탐지를 위해 총 13,682개의 데이터를 활용하였으며, 12,314개의 학습용 데이터와 1,368개의 검증용 데이터로 나누어 사용하였다. 원활한 학습을 진행하기 위해 30 layer와 384*288 이미지 크기로 리사이징하고, epochs는 150, Batch_size는 16으로 입력값을 주었으며, Visible에 대한 정보는 0, 1, 2 값으로 설정하였다. 기존 라이브러리의 경우, 0과 1로 나뉘는데 0은 보이지 않는 영역, 1은 보이는 영역으로 나뉘어 있지만, 본 논문에서 소개하는 데이터의 경우, 0은 보이지 않는, 1은 가려져 보이는, 2는 보이는 영역으로 속성이 정의되어 있어서 이에 대한 라이브러리의 함수 범위를 조정하여 학습을 진행하였다.

학습 결과, 그림 5와 같이 정확도 @AP0.5 기준으로 88%의 정확도가 나왔으며, 각 관절을 연결한 스켈레톤 이미지를 확인하였을 때, 착용 보호구에 대해서도 문제없이 관절을 유추하여 연결한 것을 확인할 수 있었다. 다만, 다중 작업



〈그림 4〉 Yolo를 활용한 객체 검출 성능



〈그림 5〉 Dite-HRNet의 관절 추론 성능 결과

자에 대한 포즈 추론이 아니기 때문에 사람이 겹쳐 있는 부분과 다른 사람이 먼저 포커싱되는 이미지 등에 관해서는 오차율 문제가 존재하였다.

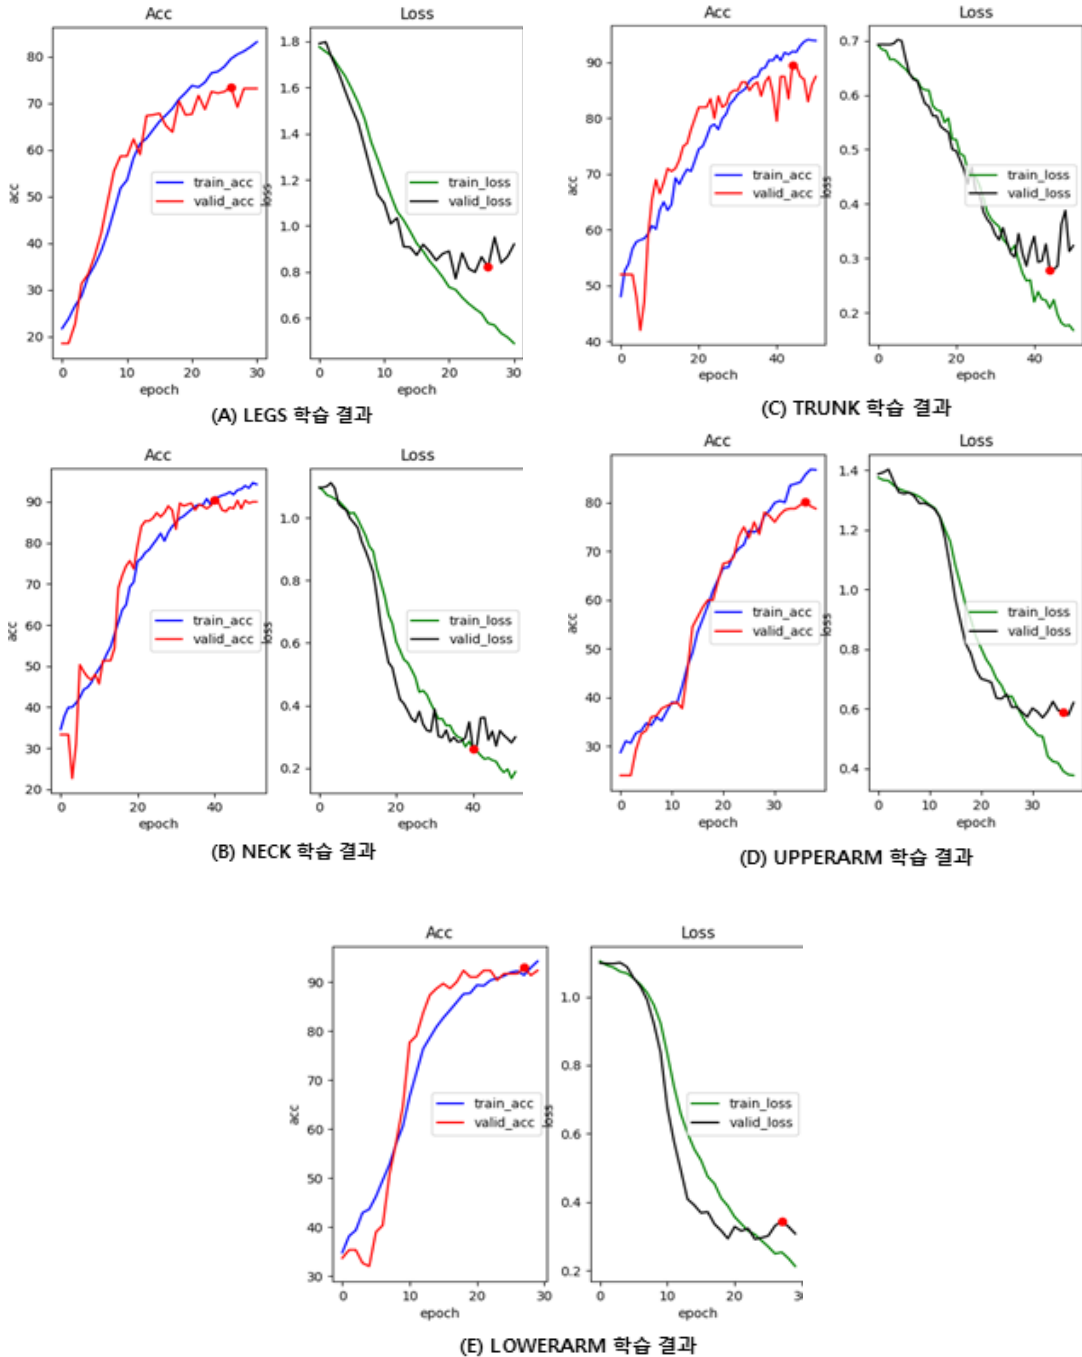
마지막으로 자세 분류의 경우, 기존에는 EfficientNet 하나의 모델로 작업 자세 전체를 분류하는 것이 조금 더 옳은 방법일 수 있으나, 작업공정을 기준으로 데이터를 구축하다 보니 작업 자세의 데이터 불균형이 너무 심했고, 다리,

목, 허리, 위팔, 아래팔로 구성된 형태에서 다리는 6개, 목은 3개, 허리는 2개, 위팔은 4개, 아래팔은 3개의 세부 클래스 항목으로 나누어져 있기에, 부위별로 나누어서 구성하였다. 다리의 경우, 총 6,000개의 데이터 중 4,800개는 학습용, 1,200개는 검증용/ 목과 아래팔의 경우 총 3,000개의 데이터 중 2,400개는 학습용, 600개는 검증용/ 허리의 경우 총 2,000개의 데이터 중 1,600개는 학습용, 400개는 검증용/ 위팔의 경우 총 4,000개의 데이터 중 3,200개는 학습용, 800개는 검증용으로 구분 지어서 사용하였다.

성능 결과는 “LEGS : 72.2%, NECT : 85.7%, TRUNK : 81.9%, UPPERARM : 79.8%, LOWERARM : 92.7%”를 달성하였다. 자세별로 많은 정확도 차이가 있을 수밖에 없는 이유는 자세를 단지 이미지의 정보 값만 가지고 분류를 진행하였기 때문이라고 생각되며, 만약 관절의 결과를 연동하여 구분 지어지는 동작의 각도 값을 환산해서 처리하게 된다면 더 높은 정확도를 보일 수 있을 것으로 판단된다.

IV. 결론 및 향후 연구

본 논문에서는 노동자의 근골격계 부담작업 유해 요인을 분석하기 위해 실제 제조회장의 인공지능 학습용 데이터를 구축하였다. 구축한 관절 키포인트 개수는 27개로 COCO 데이터셋보다 9개, MPII 데이터셋보다 12개 많으며, 유효성 검증을 통해 작업자 착용 보호구를 사용하여도 사람의 얼굴 관절을 제대로 인식하는 것을 확인할 수 있었다. 또한, 사용한 데이터셋은 Visible 정보가 0은 보이지 않는 영역, 1은 가려져 보이는 영역, 2는 보이는 영역으로 정의되어 있다. 따라서 기존 데이터셋과 달리 보이지 않는 영역을 예측 및 학습하는 것이 가능하다. 실험 결과 사람 탐지 정확도는 99%, 탐지된 사람의 관절 위치 추론 정확도는 @AP0.5 88%, 추론된 관절 위



〈그림 6〉 EfficientNET의 작업 자세 분류 결과

치를 종합하여 자세를 평가한 정확도는 LEGS 72.2%, NECT 85.7%, TRUNK 81.9%, UPPER-ARM 79.8%, LOWERARM 92.7%로 나타났다.

이러한 데이터 취득과 학습 결과는 국내 환경을 대상으로 AI 모델 학습과 검증을 수행한 의미 있는 사례라고 판단된다. 향후 연구를 통해 근골격

계 부담요인을 판단할 수 있는 복합 모델을 도출하게 된다면, 실시간 모니터링을 통해 근골격계 위험 작업 도출, 작업자세 실시간 분석을 기반으로 건설업, 유통/물류, 농축수산업 등에 적용할 수 있다. 이를 통해 노동자들의 위험한 작업을 사전에 방지할 수 있고 근골격계 부담작업 범위 및 유해 요인조사 방법에 관한 고시에 의거하여 3년마다 조사를 수행해야하는 중소기업 및 소규모 사업장의 조사 시간 및 비용 등에 관한 문제를 보다 편리하게 실행할 수 있다.

다음으로 Dite-HRNet을 사용한 방법에서 사람이 겹쳐 있는 경우 사람별 관절 추론은 올바르게 수행되었으나 평가 대상에 대한 관절 추론이 생략되는 문제로 다소 낮아진 정확도는 향후 개선이 가능할 것으로 보인다. 그러나 단순히 데이터의 유효성 검증을 위해 복합 모델이 아닌 개별 모델로 성능을 확인한 부분과 작업 자세의 유해 요인에 따른 인간공학적 평가기법을 적용하지 못한 부분이 있지만, 이러한 부분은 향후 연구를 통해 진행할 예정이다.

참 고 문 헌

- [1] 한국산업안전보건공단 보고서, “연령대별 산업재해자”, 2020.
- [2] 산업안전보건연구원 보고서, “산업재해 질병 자증 근골격계 질환자 발생 현황”, 2020.
- [3] KOSIS 국가통계포털, “업종별 근골격계 질환자”, 2020.
- [4] 한국산업안전보건공단 보고서, “제조 및 건설업 재해 발생률”, 2020.
- [5] 권영진, 김도현, 손병창, “딥러닝기반 작업자 자세 추론 및 근골격계 유해요인 평가 기술”, 대한인간공학회 학술대회논문집, Vol.2020, No. 10, pp.184-184, 2020.
- [6] 권영진, 김도현, 곽성복, 손병창, “딥러닝기반 작업자 근골격계부담작업 유해요인 분석 기술”, 대한인간공학회 학술대회논문집, Vol.2021, No.11, pp.240-241, 2021
- [7] Zhu, M., Men, Q., Ho, E. S., Leung, H., & Shum, H. P., “A Two-stream Convolutional Network for Musculoskeletal and Neurological Disorders Prediction”, *Journal of Medical Systems*, Vol.46, No.11, 2022.
- [8] Yu, Z., Zhang, J., Lu, Y., Zhang, N., Wei, B., He, R., & Mao, Y., “Musculoskeletal Disorder Burden and Its Attributable Risk Factors in China: Estimates and Predicts from 1990 to 2044”, *International Journal of Environmental Research and Public Health*, Vol.20, No.1, 2023
- [9] O. Karhu, P. Aansi, I. Ilka Kuorinka, “Correcting working postures in industry: A practical method for analysis”, *Applied Ergonomics*, Vol. 8, NO. 4, pp.199-201, 1977.
- [10] Karhu, O., Harkonen, R., Sorvali, P. and Vepsalainen, P., “Observing working postures in industry: Examples of OWAS application”, *Applied Ergonomics*, Vol. 12, No. 1, pp.13-17, 1981.
- [11] L. McAtamney, E. N. Corlett, “RULA: a survey method for the investigation of work-related upper limb disorders”, *Applied Ergonomics*, Vol. 24, No. 2, pp.91-99, 1993.
- [12] S. Hignett, L. McAtamney, “Rapid Entire Body Assessment(REBA)”, *Applied Ergonomics*, Vol. 31, pp.201-205, 2000.
- [13] OpenPOSE, <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
- [14] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A., “You only look once: Unified, real-time object detection”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.779-788, 2016.

- [15] Sun, K., Xiao, B., Liu, D., & Wang, J., “Deep high-resolution representation learning for human pose estimation”, In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp.5693-5703, 2019.
- [16] Tan, M., & Le, Q., “Efficientnet: Rethinking model scaling for convolutional neural networks”, In International conference on machine learning, pp.6105-6114, 2019.



김 기 환(Jeon, Young Jun)

- 2015년 2월 : 동서대학교 정보통신학과 (공학사)
 - 2021년 2월 : 동서대학교 유비쿼터스IT (공학석사, 박사)
 - 2021년 3월~2023년 2월 : 동서대학교 International College 초빙교수
 - 2023년 3월~현재 : 동의대학교 인공지능그랜드ICT연구센터 연구교수
- <관심분야> : 인공지능, 암호이론, 네트워크 보안

저 자 소 개



강 영 진(Young-Jin Kang)

- 2013년 8월 : 동서대학교 정보통신학과 (공학사)
 - 2020년 8월 : 동서대학교 유비쿼터스IT (공학석사, 박사)
 - 2021년 3월~2022년 2월 : 동서대학교 소프트웨어융합대학 초빙교수
 - 2022년 3월~현재 : 동의대학교 인공지능그랜드ICT연구센터 연구교수
- <관심분야> : 인공지능, 암호이론, IoT융합



정 석 찬(Jeong, Seok Chan)

- 1987년 2월 : 부산대학교 기계설계학과 (공학사)
 - 1993년 3월 : 오사카부립대학 경영공학과 (공학석사, 박사)
 - 1993년 2월~1999년 2월 : 한국전자통신연구원 선임연구원
 - 1999년 3월~현재 : 동의대학교 e비즈니스학과 교수
 - 2019년 1월~현재 부산IT융합부품연구소 소장
 - 2020년 7월~현재 인공지능그랜드ICT연구센터 센터장
- <관심분야> : 정보시스템, IoT 융합, 빅데이터, 클라우드, 블록체인, 인공지능



노 태 경(Jeon, Young Jun)

- 2019년 2월 : 동의대학교 멀티미디어공학과 (공학사)
 - 2023년 3월~현재 : 동의대학교 인공지능학과(석사과정)
 - 2022년 11월~현재 : 동의대학교 부산IT융합부품연구소 연구원
- <관심분야> : 인공지능, Back-End, 컴퓨터 비전