



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

Master of Engineering in Biomedical Engineering

**Patient Posture Estimation Using Super-
Resolution Reconstruction of Pressure
Distribution Image for Pressure Ulcer Prevention**

**체압 분포 영상 초고해상도 보정을 이용한 욕창 예방을
위한 환자 자세 추정**

Asan Medical Institute of Convergence Science and Technology,

University of Ulsan College of Medicine

Department of Biomedical Engineering

Kim, Jin Gyu

**Patient Posture Estimation Using Super-
Resolution Reconstruction of Pressure
Distribution Image for Pressure Ulcer
Prevention**

Supervisor : Jae Soon Choi

A Master's Thesis submitted in partial fulfillment of
the requirements for the degree of
Master of Engineering in Biomedical Engineering
in the Department of Biomedical Engineering
Asan Medical Institute of Convergence Science and Technology,
University of Ulsan College of Medicine,
Seoul, South Korea
August 2023

**Patient Posture Estimation Using Super-Resolution Reconstruction
of Pressure Distribution Image for Pressure Ulcer Prevention**

This certifies that the Master's Thesis of Jin Gyu Kim is approved.

Committee Vice Chair Dr. Chang Mo Hwang

Committee Member Dr. Jae Soon Choi

Committee Member Dr. Young Jin Moon

Department of Medicine

Seoul, South Korea

August 2023

ABSTRACT

본 연구에서는 중증, 고령의 환자의 욕창 방지를 위해 욕창 부위를 예측 하는 시스템을 개발 하였다. 기존 체압 이미지를 활용한 욕창 부위를 예측에 있어 저해상도 센서는 간접 측정 및 해상도의 물리적인 한계점을 가지고 있다. 따라서 소프트웨어적으로 저해상도 체압 이미지를 고해상도 체압 이미지로 복원하는 초고해상도 기법을 적용하였다. 이를 통해 병상의 환자의 현재 자세를 파악하고 욕창 발생 가능성이 높은 부위를 예측하고자 복원된 체압 분포 이미지에서 사용자의 자세 및 욕창 위험 부위를 검출하는 알고리즘을 개발하였다.

체압 분포 이미지의 고해상도 복원과 환자의 자세 예측을 위해 초고해상도 생성적 적대 신경망(SRGAN)와 컨볼루션 신경망(CNN)을 구현하였다. 원본 체압 분포 이미지와 저해상도에서 SR기법에 의해 고해상도(4x)로 복원된 체압 분포 이미지의 유사성을 평가하기 위해서, 이미지 평가 기술(IQA)에서 사용하는 지표인 피크 신호 대 잡음비(PSNR)과 구조적 유사성(SSIM)을 사용하였다. 복원된 체압 이미지는 4가지의 자세(정자세, 오른쪽 누운 자세, 왼쪽 누운 자세, 그 외)로 분류되었다.

각 자세에서 욕창 발생 가능성이 높은 부위를 예측하기 위해 자세추정기술인 Openpose의 Body_25 Key Point구조에서 얼굴, 손, 발 부분을 축약하여 정자세는 9 Key Points(머리, 등, 왼쪽 팔, 오른쪽 팔, 엉덩이, 왼쪽 골반, 왼쪽 발목, 오른쪽 골반, 오른쪽 발목), 오른쪽 누운 자세, 왼쪽 누운 자세는 7 Key Points(머리, 어깨, 팔꿈치, 손, 엉덩이, 무릎, 발목)으로 정의하였다. SRGAN을 이용한 고해상도 복원 결과는 정자세에서는 PSNR 37.17dB, SSIM 0.9622, 오른쪽 누운자세에서는 27.02dB, SSIM 0.9224, 왼쪽 누운자세에서는 31.44dB, SSIM 0.9470으로 SRCNN 대비 높은 결과를 보여주었다.

이미지를 육안 관찰로 정성적 비교해 보아도 SRGAN 결과가 상대적으로 보다 많은 고해상도세부사항을 보여주는 결과를 나타내었으며, 자세 검출 알고리즘은 약 98.37%의 분류 정확도를 나타내어, 실용적 기술 구현 가능성을 보였다.

Keyword: Pressure Ulcer, Super Resolution, Generative Adversarial network, Posture Detection, Image Quality Assessment

TABLE OF CONTENTS

ABSTRACT.....	i
TABLE OF CONTENTS.....	ii
List of figures.....	iii
List of tables	iv
INTRODUCTION	1
BACKGROUND	4
1. Pressure Ulcer Prevention	4
2. Super Resolution	9
3. Generative Adversarial Network.....	10
4. Posture Detection	12
METHOD	14
1. 저해상도 이미지의 해상도 향상 알고리즘	14
2. 체압분포이미지 자세 검출 알고리즘	19
3. 체압분포이미지의 획득 및 라벨링	21
4. 정확도 평가 방법	22
RESULT.....	24
1.1. 고해상도 복원 인공지능 알고리즘 결과.....	24
1.2. 자세 검출 알고리즘 결과.....	28
DISCUSSION & CONCLUSION	31
REFERENCE.....	33
ENGLISH ABSTRACT	37

LIST OF FIGURES

Figure 1 피부 허용 응력 산출 방식	8
Figure 2 피부 허용 응력을 시간에 따른 욕창위험도로 판단하는 방식	8
Figure 3 GAN 은 판별 분포.	12
Figure 4 SRCNN architecture.....	16
Figure 5 SRGAN architecture	16
Figure 6 SRGAN architecture for Pressure Ulcers.....	19
Figure 7 Pose Output Format (BODY_25).....	20
Figure 8 Supine 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지	25
Figure 9 Left log 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지.....	26
Figure 10 Right log 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지..	27
Figure 11 자세 검출 알고리즘결과	29
Figure 12 자세 분류 알고리즘의 학습 과정 중 훈련 데이터와 검증 데이터 단계 정확도 변화	30

LIST OF TABLES

Table 1 Braden 욕창 방지 도구.....	4
Table 2 Cubbin & Jackson 도구.....	5
Table 3 Waterlow 도구.....	6
Table 4 압력 이미지 데이터 간 유사도 결과.....	28

INTRODUCTION

EPUAP(European Pressure Ulcer Advisory Panel)에 따르면 욕창은 압력, 전단, 마찰, 그리고 온도, 습도와 같은 복합적 요인들의 조합으로 인해 신체 돌출부에 주로 나타나는 피부 및 기저 조직의 국부적인 손상을 의미한다[1]. 그 중 압력은 욕창 발생의 주 원인이 되는 요인으로 대개 오래 병상에 누워있는 중증 환자, 고령자, 입원환자 등에서 자주 발생하며, 장시간 동안 높은 압력에 노출되기 쉬운 등, 천골, 머리, 엉덩이, 팔꿈치, 발 뒤꿈치 등과 같은 돌출된 신체 부위에 발생할 위험도가 높다[2] 욕창 발생 이후 오랜 시간이 지날 경우 손상된 신체 일부를 수술을 통해 절단해야 하거나, 심각한 경우 추가적인 질환의 원인이 되어 사망 위험도를 높이기 때문에 욕창이 생기지 않도록 사전에 예방하는 것이 매우 중요하다. EPUAP 에서는 욕창을 증상에 따라 다음과 같이 4 단계로 분류하고 정기적으로 검사, 예방, 치료하는 방법을 제시한다[3].

1 단계: 피부가 붉어지며, 열이 나고, 통증이 있을 수 있으며, 신체 일부 부위에 압력이 가해졌을 때

2 단계: 피부가 파괴되고, 괴사 되기 전의 상태로 나타난다. 상처 부위 주위에 발적성 덩어리가 생길 가능성

3 단계: 피부 및 근육 조직이 괴사하여 상처 부위의 깊이가 더 깊어진다. 근육 조직이 노출

4 단계 깊이가 매우 깊어지며, 뼈와 연골까지 노출된다. 상처 부위에 부속 조직의 감염이 발생할 향상

욕창 발생의 원인이 되는 여러가지 요인들 중에서 전단력은 가장 직접적으로 욕창을 발생시키는 요인으로 정의하며 전단력은 신체부위에 가해지는 압력에 비례한다. 또한 온도, 습기, 영양 결핍, 수분 부족, 청결 상태의 나쁨 등의 다른 요인들도 피부의 보호 기능을 약화시키고 욕창을 더욱 심화시킬 수 있다.

따라서 예방과 조기 발견은 욕창의 치료 및 관리를 위한 가장 중요한 요소다. 실제 병실 현장에서는 욕창 발생 정도를 낮추기 위해 Braden Scale 과 같은 욕창 판단 도구를 사용한다. 여기서 말하는 욕창 판단 도구는 환자의 욕창 발생 위험도를 평가하기 위한 것으로, 의료기관에서 욕창 예방 및 조기 발견을 위한 중요한 평가 도구로 사용되고 있으며 간호사 혹은 간병인들이 욕창 발생 위험도가 높은 환자의 자세를 수작업으로 매 1~2 시간 간격으로 바꾸어 줌으로써 집중된 압력을 주기적으로 해소해 주고 있다. 그러나 이러한 조치를 24 시간 내내 유지하는 것은 현실적으로 시간-비용 면에서 쉽지 않은 작업이기에, 지속적이고 자동적으로 체압을 관리해 주는 시스템의 필요성이 대두되고 있다. 본 연구 에서는 수작업으로 측정하는 시스템의 대안으로 대상의 신체에 가해지는 전단력의 정도를 실시간으로 추정 혹은 분석하고 욕창 발생 가능성이 높은 부위를 분류할 수 있는 모니터링 기능 구현하여, 압력 측정 매트리스와 같은 체압 분포 측정 장비를 활용하여 일정 주기 간격으로 자동으로 환자의 자세를 변환할 수 있는 시스템 개발을 통해 기존의 한계점을 극복하려고 한다.

체압 분포 데이터에 기반한 욕창 예방 기법은 체압 모니터링과 이를 바탕으로 한 환자 자세 인식과 욕창 위험도 추정, 예상 위험 부위 압력 누적 해소를 위한 환자 자세 변경 계획과 실제 자세 변경 실행의 과정으로 나누어 볼 수 있다. 환자의 현재 자세와 체압 분포 데이터, 그리고 과거 자세와 체압 분포 데이터를 피부 강도 모델에 적용시킴으로써 욕창 위험 부위와 효과적으로 욕창 위험을 완화시킬 수 있는 자세의 도출이 가능할 수 있다. 따라서, 체압 분포 데이터로부터 환자의 현재 자세를 파악하는 것이 가장 핵심적인 과정이라고 할 수 있다.

대상의 자세 파악은 광학 카메라 등을 통해 수집된 영상 정보로부터 대상 관절이 공간상 위치 정보를 추출하는 방식으로 용이하게 구현이 가능하나, 개인정보보호가 중요한 병원 환경에서 적합한 도구로 권장되지 않는다. 때문에 일부 연구에서는 영상 정보 대신 체압 분포 정보를 활용하여 대상의 자세

정보를 추출해 내는 방식을 제안하고 있다[4-5]. 하지만, 체압 분포 측정은 이미징 센서와는 달리 압력 센서를 조밀하게 구성하면 비용 면에서 실용성이 크게 떨어지게 되고, 조밀한 구성의 센서를 사용하여도 영상 정보에 비해 형상 정보의 양이 낮아, 실용적인 센싱 방식 구현을 위해 적은 수의 압력 센서를 이용하는 낮은 해상도의 체압 분포데이터를 바탕으로 높은 해상도의 정보를 추정해 내는 알고리즘이 유용하게 이용될 수 있다.

본 연구에서는 임상 현장에서 하드웨어적인 한계를 극복하고 육상 위험도 예측이 가능한, 환자의 자세 정보를 적절한 수준으로 향상시키는 알고리즘을 개발하고자 하였다. 컴퓨터 비전 분야에서 이미지와 비디오의 해상도를 향상시키는 SR(Super-Resolution) 기법의 하나인 딥러닝 알고리즘에 기반한 SRGAN(Super-Resolution Generative Adversarial Networks) 기법을 활용하여 저해상도의 체압 분포데이터를 고해상도 데이터로 향상시키는 방법을 시도하였다.

본 논문은 다음과 같이 구성된다. 저해상도의 이미지를 고해상도로 보정하는 알고리즘과 체압 분포 이미지에서 자세 정보를 추정하는 알고리즘에 대해 기술하고, 실제 병상에서 실험을 통한 체압분포 이미지 수집 및 자세 라벨링 작업 과정을 통해 얻은 데이터를 알고리즘의 성능 검증을 진행하고 알고리즘의 정확도를 평가하기 위한 방법에 대해서 기술한다. 최종적으로 계산된 수치들을 바탕으로 제시한 알고리즘의 성능을 평가한 결과를 고찰한다.

BACKGROUND

1. Pressure Ulcer Prevention

기존에 욕창을 예측하고 예방하는 방법으로는 다음 Table[1~3]과 같이 간호인력 및 돌봄 인력이 직접 판단하는 Barden Scale 도구[6], Cubbin & Jackson 도구[7], Waterlow 도구[8]를 이용하여 수작업으로 직접 판단 후 자세 변환을 진행한다.

Table 1 Braden 욕창 방지 도구, 환자의 현재 상태를 6 개의 항목으로 나타낸다. 점수의 범위는 6~23 점이며, 판단기준은 저 위험 15~18 점, 중 위험 13~14 점, 고위험 10~12 점, 초고위험 9 점 이하로 나타낸다.

항목	1점	2점	3점	4점
감각인지 불편감을 주는 압력에 대해 의미있게 반응하는 능력	전혀없음 의식이 저하되거나 진정제로 인해 통증자극에 대해 전혀 반응 없음. 또는 신체 대부분의 감각이 떨어짐	매우 제한됨 통증 자극에 대해서만 반응함. 신음하거나 안절부절 못하는 외에는 불편감을 호소하지 못함. 또는 신체의 1/2 이상의 감각이 떨어짐	약간 제한됨 구두로 요구를 표현하나 불편감을 느끼거나 돌릴 필요가 있을 때마다 하는 것은 아님. 또는 하나나 둘의 사지에서 감각이 떨어짐	장애 없음 구두로 요구를 표현할 수 있으며, 감각기능 장애가 전혀 없음
	지속적으로 습함 땀, 소변 등으로 피부가 계속 습한 상태임. 돌리거나 움직일 때마다 축축함	습함 항상은 아니나 자주 습한 상태임. 적어도 8시간 마다는 린넨을 교환해야 함	때때로 습함 낮 동안에는 때때로 걸으나 짧은 거리만 가능함. 대부분을 의자나 침대에서 보냄	거의 습하지 않음 적어도 하루에 두번 정도는 산책할 수 있음
활동 신체 활동 정도	침상안정 계속적으로 침대에 누워있어야 함	의자에 앉을 수 있음 보행 능력이 없거나 매우 제한됨. 몸을 지탱할 수 없거나 의자나 휠체어로 옮길 때 도움이 필요함	때때로 보행 낮 동안에는 때때로 걸으나 짧은 거리만 가능함. 대부분을 의자나 침대에서 보냄	정상 적어도 하루에 두번 정도는 산책할 수 있음
	전혀 없음 도움 없이는 몸이나 사지를 전혀 움직이지 못함	매우 제한됨 가끔은 몸이나 사지를 움직이나 자주 혼자서 움직이는 아님	약간 제한됨 혼자서 약간씩이나 자주 움직임	정상 도움없이 자주, 크게 자세를 바꿈
영양상태 평소 음식 섭취 양상	불량 제공된 음식의 1/3이상을 먹지 못함. 금식, 5일 이상	부적절함 보통 제공된 음식의 1/2 정도를 먹음. 유동식, 경관 유동식	적절함 대부분 반 이상을 먹음. 경관 유동식, TPN	양호 거의 다 먹음

마찰력과전단력	문제 있음	잠재적 문제 있음	문제 없음	
	이동 시 많은 도움이 요구되며, 끌지 않고 드는것을 불가능함. 종종 침대나 의자에서 미끄러져 자세를 다시 취해야 함. 경축, 초조가 계속적으로 마찰을 일으킴	최소한의 조력으로 움직일 수 있음. 이동 시 시트, 의자, 억제대나 다른 도구에 약간은 끌림. 때때로 미끄러지나 의자나 침대에서 대부분은 좋은 자세를 유지함	침대나 의자에서 스스로 움직일 수 있고 움직이는 동안 몸을 들어 올릴 수 있음. 항상 침대나 의자에서 좋은 자세를 유지할 수 있음	

Table 2 Cubbin & Jackson 도구, 중환자의 욕창 발생 위험을 사정하기 위해 개발된 도구로서 환자의 상태를 5가지의 항목으로 나타낸다. 14점이하는 욕창 고위험군으로 간주한다.

신체 상태		정신 상태		활동		움직임		실금		총점
좋음	1	명료	1	보행	1	원활	1	없음	1	
보통임	2	무감동	2	도움 받아서 걸음	2	약간 부전	2	빈번	2	
나쁨	3	혼동	3	휠체어 보행	3	매우 제한 적임	3	일반 요실 금	3	
매우 나쁨	4	혼미	4	누워만 있음	4	매우 제한 적, 부동	4	요 & 변 실금	4	

참조: 14점 이하는 '욕창 고위험'으로 간주함.

Table 3 Waterlow 도구, 환자의 현재 상태를 다양한 분류로 나타낸 도구로, 판단기준은 위험 10 점 이상, 고위험, 15 점 이상, 매우 고위험 20 점이상으로 나타낸다.

체질량 지수	피부상태(시각)		성 연령		영양결핍			
정상 (BMI=20-24.9)	0	건강	0	남	1	A. 최근 체중 감소	B. 체중감소	1
		종이피부	1	녀	2	예 - B로	0.5-5kg 5-10kg	2
과체중 (BMI=25-29.9)	1	건조	1	14-49	1	아니오 - C로	10-15kg	3
		부종	1	50-64	2	모름 - C로, 2점	>15kg	4
비만 (BMI≥30)	2	축축함, 할열	1	65-74	3	C.식이섭취불량과 식욕부진 예 - 1 아니오 - 0	모름	2
		탈색(1단계)	2	75-80	4		영양점수 2점 이상시	
저체중 (BMI<20)	3	탈색(2-4단계)	3	81+	5		영양사정/중재 의뢰	
실금		움직임		특이 사항				
원활(도뇨)	0	정상	0	조직 불량		신경 장애		
요실금	1	안절부절	1	말기 악액질	8	당뇨/다발성경화증/뇌졸중		
변실금	2	무감각	2	다장기 부전	8	운동/감각장애		
요&변실금	3	제한적	3	단장기 부전	5	마비		
		침상생활 (예:견인)	4	(예:호흡기,신장,심장) 말초혈관질환	5	수술/사고		
		의자생활 (예:휠체어)	5	빈혈(Hb<8) 흡연	2 1	정형외과/척추 수술 > 2시간 수술 > 6시간		
10+ 위험 15+ 고위험 20+ 매우 고위험								

하지만 수작업으로 진행되는 부분을 하드웨어적이나 소프트웨어적으로 육창을 예방과 조기 발견하는 것을 자동화하기 위해서 다양한 관점에서 연구가 많이 진행되고 있다.[9-11]

Barden 도구, Cubbin 과 Jackson 도구, Waterlow 도구의 민감도, 특이도, 양성 예측도, 음성 예측도 및 곡선하면적등 욕창발생률을 확인 하기 위한 도구들을 비교함으로써 예측타당도가 높은 욕창 위험사정도구를 확인하는 연구[9], 욕창 예방과 치유를 위해 현재 시판되고 있는 교대 부양식, 수동 공압식 방식의 욕창 방지 공기 매트리스에 체압센서를 내장해서 환자의 데이터를 분석하여 위급시 경보를 알리는 제품 연구[10]등 욕창 예방을 위해 병상 환자로부터 생체 신호 획득과 관련된 측면이 많은 연구가 되어 왔다[11] 또한 욕창 예방과 모니터링의 몇 가지 측면을 개선하기 위해 환자의 데이터, 외부의 환경 등을 조합하여 인공지능을 이용한 솔루션들이 제시되고 있다[12-14].

체압분포 데이터 기반 욕창 판별 알고리즘은 침상 위에서 환자의 압력을 측정 할 수 있는 체압 매트리스를 이용하여 욕창을 예방, 예측 하며 다음과 같은 방법을 제안한다.[14]

1. 각 압력 센서에서 취득하는 압력 값이 환자 신체 어느 부위에 가해지는 압력인지를 판단함
2. 특정 시간 구간(time window)동안 각 부위에 가해진 압력 값들 중 최대값의 평균을 활용함
3. 각 부위에 가해진 응력(φ , Stress)과 피부 허용 응력 (φ_{ws} , Skin tolerance)을 비교하여 욕창 위험도를 계산된 수치에 따라 1-3 등급(Risk level 1-3)으로 판단함.

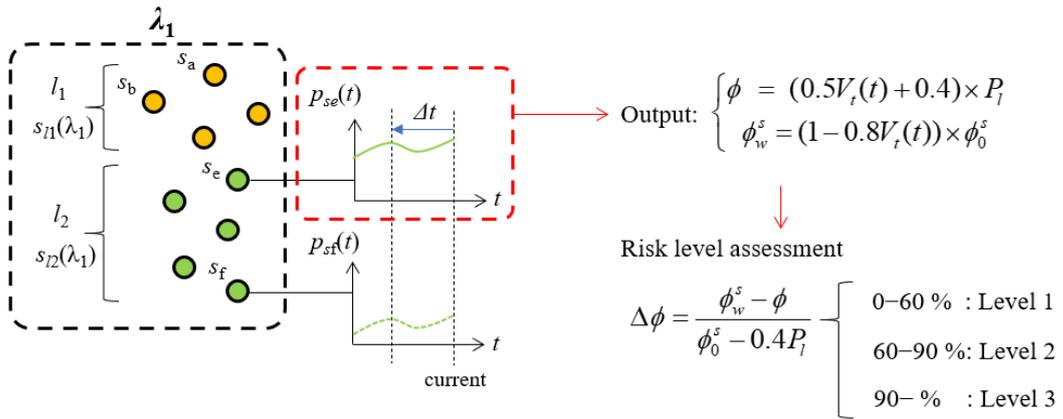


Figure 1 피부 허용 응력 산출 방식

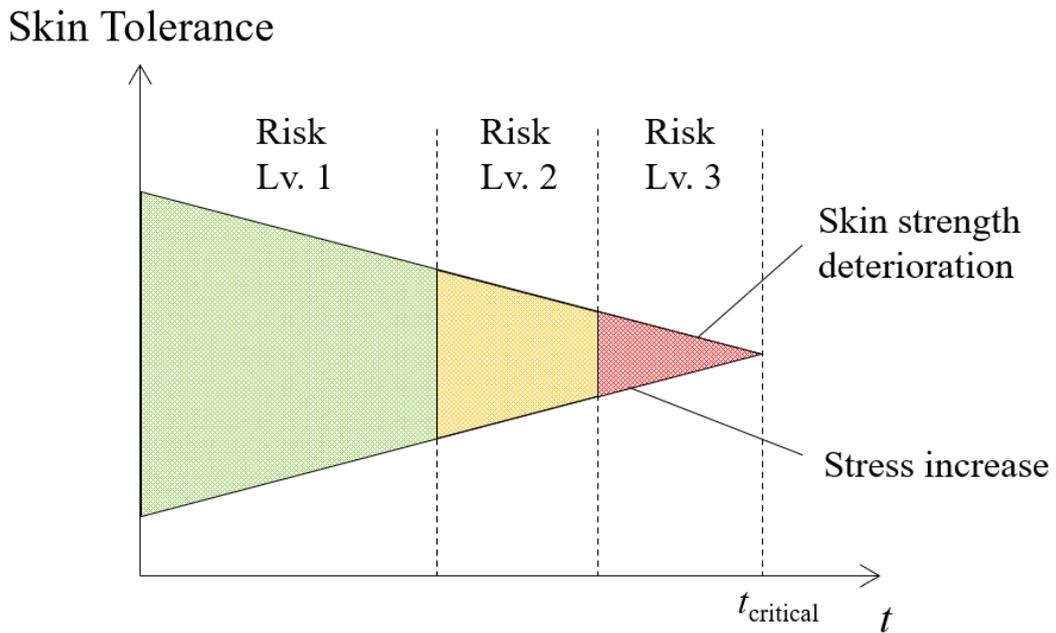


Figure 2 피부 허용 응력을 시간에 따른 육창위험도로 판단하는 방식

여기서 각 부위에 가해지는 응력(ϕ) 와 피부 허용 응력(ϕ_{ws})는, Figure[1-2]와 같이 시간의 흐름에 따라서 땀 배출 등의 요인으로 인해, 가해지는 응력은 증가하고, 피부가 견뎌낼 수 있는 응력은 감소하는 양상으로 모델링 된다.

2. Super Resolution

Super Resolution(SR)은 컴퓨터 비전 에서 이미지 및 비디오의 해상도를 향상시키는 중요한 이미지 처리 기술 중 하나이다. 이 기술은 Michael Elad와 Alfred M. Bruckstein이 1992년에 발표한 “A generalized Gaussian image analysis and restoration model for super-resolution” 논문[15]에서는 초고해상화 기술을 위한 일반화된 가우시안 이미지 분석 및 복원 모델이 제안되었다.

SR 기술은 저해상도(low-resolution, LR) 이미지를 고해상도(high-resolution, HR) 이미지로 변환하는 기술로서 기존의 저해상도 이미지를 활용해 더 높은 해상도의 이미지를 생성하는 방식으로, 이미지나 비디오 등에서 세부적인 정보를 추출할 수 있게 해주며, 이미지나 비디오의 화질을 개선할 수 있다. 하지만 SR기술이 개발되기 전에는 다음과 같은 문제가 많이 대두되었다.

첫째, 이미지나 비디오의 해상도가 낮아지는 경우가 많이 있다. 예를 들어, 디지털 카메라나 스마트폰 카메라에서 낮은 해상도를 설정하면 저장 용량이 줄어들어 저장이 편리 해지나 이로 인해 저장된 이미지나 비디오가 해상도가 낮아지는 문제가 발생한다. 이러한 문제는 여러 분야에서 발생하는데, 주로 의료 분야에서는 CT 또는 MRI 등의 의료 영상에서 해상도가 낮아지는 문제가 발생한다.

둘째, 고해상도 영상을 얻기 위해서는 더 많은 정보가 필요하다. 즉, 고해상도 이미지는 더 많은 정보를 담고 있는데 이는 더 많은 세부 정보와 미세한 차이점들을 포함하기 때문이다 하지만 고해상도 이미지를 얻기 위해서는 더 많은 정보를 수집해야 하므로 시간과 비용 등이 많이 들어간다.

이러한 문제들을 해결하기 위해서 SR 기술이 개발되었으며, 저해상도 이미지를 고해상도 이미지로 변환하는 방식으로 더 많은 정보를 담은 고해상도 이미지를 생성하는 것이 가능하다. 이는 의료 분야에서는 CT나 MRI 등의 의료 영상에서도 세부 정보를 추출하고 진단에 활용할 수 있게 해주며, 다양한 분야에서도 고화질 영상을 생성하는 데 큰 도움을 준다. SR기술에 딥러닝 기술을 활용하는 방법이 많이 연구되고 있다.

대표적으로 초해상화 문제에 처음으로 딥러닝을 도입한 네트워크인 Super Resolution Convolutional Neural Network(SRCNN)을 제안한 논문[16]에서는 SR문제를 CNN 기반의 Regression 문제로 정의하고, end-to-end 방식으로 해결을 제안하여 기존 초해상도 알고리즘 대비 높은 성능을 보여주며 이후에 많은 딥러닝 기반 SR모델 개발에 기초가 되었다.

이후 SRCNN모델에서 발생하는 연산량이 많은 문제를 해결하기 위해, 더욱 빠르고 경량화된 모델인 FSRCNN(Fast Super-resolution Convolutional Neural Network) 모델[17]을 제안하여, 네트워크 내에서 이미지를 확대하는 층인 Deconvolution 층을 추가하여 학습을 통해 보다 최적화된 고해상도 이미지를 생성하는 네트워크를 개발하였다. 이 네트워크는 SRCNN모델보다 빠르면서도 SR 성능을 개선시켰다.

이 논문은 기존의 CNN 방식에서 SR문제를 해결하기 위해 [18]GAN(Generative Adversarial Network)을 활용하는 방법을 제안한다. SR문제를 생성 모델링 문제로 정의하고, 생성자 모델과 판별자 모델을 함께 학습시켜 SR결과를 생성하여 사람 눈으로도 거의 구분이 불가능한 수준으로 고해상도 이미지를 생성할 수 있다.

3. Generative Adversarial Network

생산적 적대 신경망(Generative Adversarial Network)은 2014년 Ian Goodfellow가 제시한 모델[18]로서 최종적인 목표는 실제 이미지와 유사한 거짓 이미지를 생성해 내기 위해 제안된 네트워크 모델이다.

생성(generative) 네트워크와 판별(discriminative) 네트워크의 2개 네트워크로 구성된다. 판별 네트워크는 데이터 인스턴스가 실제 트레이닝 데이터 세트인지 아닌지를 구별하는 역할을 하고, 생성 네트워크는 주어진 데이터 세트를 그에 상응하는 데이터 세트를 생성하는 함수를 훈련하는 역할을 한다. 생성네트워크가 생성한 ‘가짜’ 데이터 세트를 넣고 판별 네트워크의 판정을 계속 받는 과정에서 점차 데이터 세트가 ‘진짜’ 데이터 세트와 가까워지도록 소위 적대적 학습을 통해 결

과를 도출하는 것이 핵심이다.

GAN의 주요 수식(1)은 2가지 관점에서 해석되는데 첫째 D 가 $V(D,G)$ 를 최대화 하는 관점에서 Discriminator D 는 출력이 실제 데이터가 들어오면 $D(x)=1$ 에 가깝게 나타나고, G 가 만든 가짜 이미지가 들어오면 $D(G(z))=0$ 에 가깝게 출력이 되는 방식이다.

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)}[\log D(x)] + E_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (1)$$

둘째 G 가 $V(D,G)$ 를 최소화 하는 관점에서 Generator G 에 넣어 만든 가짜 데이터를 Discriminator D 가 속아서 진짜로 판별하면, $D(G(z))=1$ 이 되어 $\log 1$ 이 되어 $-\infty$ 로 발산한다. 이에 반해 Discriminator D 를 속이지 못하면, $D(G(z))=0$ 값이 들어가 $\log 0$ 이 되어 0에 가까운 최댓값이 나오게 된다.

따라서 위 수식은 G 는 $V(D,G)$ 를 최소화 하는 방향으로 학습하게 된다. Figure[3] 처럼 $V(D,G)$ 에 있어서 G 는 이를 ‘최소화’하는 방향으로 가고, D 는 ‘최대화’하는 방향으로 가게 되어 minimax Problem을 보여준다.

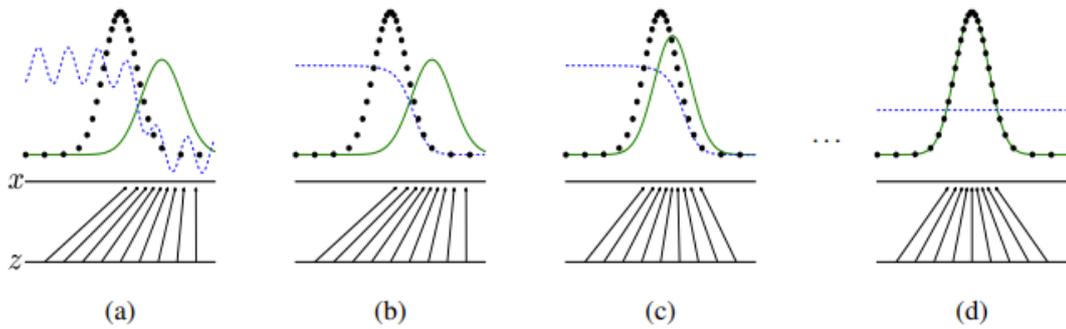


Figure 3 GAN 은 판별 분포(D, 파란색 파선)를 동시에 업데이트하여 데이터 생성 분포(검은색, 점선) p_x 의 샘플과 생성 분포 $p_g(G)$ 의 샘플을 구별하도록 학습된다(녹색, 실선). 아래쪽 수평선은 z 가 샘플링 되는 도메인, 위의 수평선은 x 도메인은 일부이다.

GAN은 기존의 생성 모델들과는 달리 높은 품질의 이미지를 생성할 수 있으며, 다양한 분야에서 이미지 생성 문제를 해결하는 데에 적용된다. 예를 들어, GAN은 이미지 생성뿐만 아니라 음악, 텍스트, 비디오 등 다양한 형태의 생성 문제에도 적용될 수 있다.

4. Posture Detection

기존의 수작업으로 진행하는 육창 예방 방법은 시간과 노력이 많이 소모되며, 높은 인력 비용을 필요로 한다. 따라서 이러한 문제점을 해결하기 위해 육창 예방을 위한 자동화된 예측 방법[19], 인공지능을 이용한 인간 자세 추정 알고리즘[20-21] 등이 좋은 대안으로 떠오르고 있다.

자세 검출 알고리즘은 인체 부위 중 머리, 몸, 팔, 다리 등과 같은 키 포인트(Keypoint)의 위치를 올바르게 추정하는 것으로 대표적인 것으로는 체중 분포 패턴을 이용한 자세 판별 시스템, 단일 카메라 영상에서 자세 검출 알고리즘 등이 있다. 의료환경에서도 환자를 대상으로 하는 자세 추정 알고리즘을 활용한 연구들이 많이 진행되고 있는데 2D 자세 추정 알고리즘, 3D 자세 추정 알고리즘, 웨어러블 기기를 이용한 자세 추정 알고리즘 등의 방식이 제안된다. 또한 딥러닝

기반으로 2차원 이미지에서 자세를 추정하는 방법은 영상 이미지 안에 사람이 1명인지 2명 이상 인지에 따라 달라진다.

현재 개발된 라이브러리를 예를 들면 첫째 "MediaPipe Pose" Google에서 제작한 Machine Learning 솔루션으로, RGB 비디오 프레임에서 전신에 대한 33개의 3D 랜드마크와 배경 분할 마스크를 추론하고 신뢰도가 높은 신체 포즈 추적을 위한 기술이[22]다. 둘째 "OpenPose"는 인간 자세 추정(Human Pose Estimation) 기술 중 하나로 딥러닝의 CNN 기반으로 이미지 혹은 영상을 입력 값으로 하여 객체의 위치 및 방향을 감지한다. 인간의 몸, 얼굴, 손가락마디를 정확하게 예측할 수 있으며, 신체의 관절을 추론하는 기술이다[23]. 마지막으로 TensorFlow.js PoseNet3는 TensorFlow.js에서 제공하는 포즈 추정 모델로 이미지와 비디오에서 사람의 모습을 감지하는 컴퓨터 비전 기술을 사용하여 포즈 예측을 할 수 있다. PoseNet은 단일 포즈 또는 다중 포즈 알고리즘을 사용하여 이미지와 비디오에서 인간의 도형을 감지할 수 있다.[24]

METHOD

본 연구에서는 체압 분포 데이터를 기반으로 하여 환자의 자세 추정 알고리즘을 제안한다. 추정 알고리즘은 크게 3단계에 거쳐 진행되며 두가지의 인공 신경망 알고리즘을 활용한다.

첫번째 단계에서는 전신 체압측정장비를 이용하여 환자의 체압 분포 데이터를 획득하고 체압 분포 데이터의 고해상도 보정을 위해 SR 기법인 SRCNN에서 고주파세부사항(high frequency detail)과 지각적인 부분이 보완된 SRGAN 기술을 이용하여 저해상도 저해상도 전신 체압분포 이미지를 고해상도 체압 분포 이미지로 보정한다.

두번째 단계에서는 OpenPose의 자세 추정 기술을 이용하여 보정된 이미지의 라벨링을 진행하고 one-hot-encoding 기법, CNN 기술을 이용하여 체압 분포 이미지에서 자세의 key point를 추출한다.

마지막 단계에서는 2개의 인공 신경망 알고리즘을 통해 얻은 데이터를 이미지 품질 평가 기술과 4개의 자세 상태를 다중 분류 손실 함수(categorical_crossentropy)를 활용하여 알고리즘의 정확도를 측정한다.

1. 저해상도 이미지의 해상도 향상 알고리즘

본 연구에서는 자세 추정을 위한 최적 결과를 얻기 위해서, 앞서 기술한 저해상도 이미지의 고해상도 향상 알고리즘인 SRCNN과 SRGAN의 두 가지 방식을 활용하여 학습을 진행한다.

단일 이미지 초해상도(single image SR)에 최초로 딥러닝을 적용한 기술로써, 간단한 구조로 기존의 SR방법보다 좋은 성능을 보여 많은 연구자들이 SR 문제에 딥러닝을 적용하는 계기를 제공한 SRCNN은. Figure[4]과 같이 SRCNN은 저해상도 이미지를 입력 받아, patch extraction representation, non-linear mapping, reconstruction의

과정을 거쳐 고해상도 이미지를 출력한다[25].

SRCNN은 학습 과정 중 손실함수, $L(\theta)$ 로 수식(2)을 이용하여 mean square error(MSE)를 계산하여 사용한다.

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \|F(Y_i; \theta) - X_i\|^2 \quad (2)$$

θ 는 CNN의 레이어들의 feature map의 크기와 패치의 차원을 나타내며 F 는 각 레이어들의 매핑 함수이며, Y_i 는 저해상도 이미지 데이터, X_i 는 고해상도의 이미지 데이터이다. MSE는 전체적인 학습에는 좋은 결과를 보이지만 고주파 영역의 특징을 나타내는 지표로는 좋은 성능을 보이지 못한다.

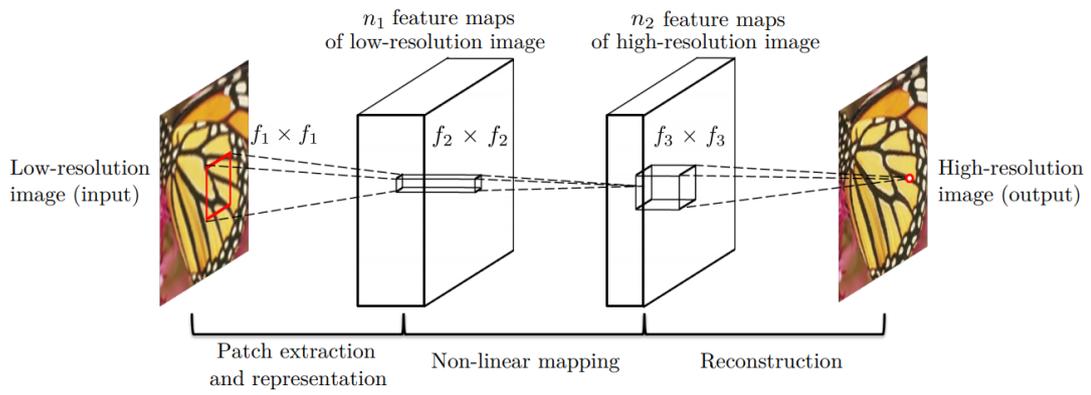


Figure 4 SRCNN architecture

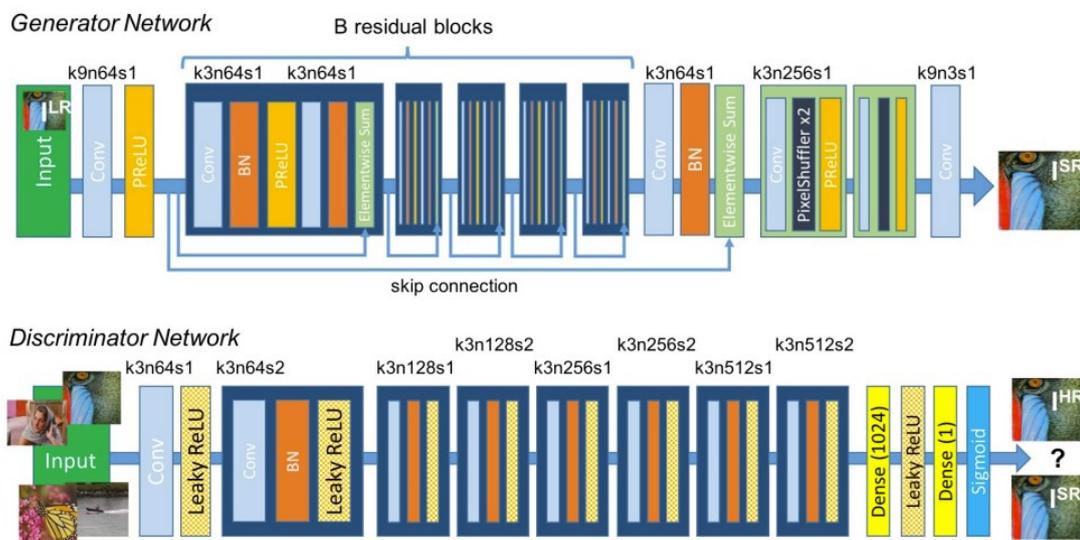


Figure 5 SRGAN architecture

SRGAN은 SRCNN에서의 MSE의 차이를 최소화함으로써 Figure [5]과 같이 PSNR을 높게 만들어 해상도를 향상시키는 방법으로, 본 연구에서는 SRCNN의 MSE 기반 loss function의 한계를 보완하고, SRGAN에서는 픽셀공간에서의 유사성이 아닌 지각적 유사도(perceptual similarity)에 기반하여 콘텐츠 손실(content loss)와 적대적 손실(adversarial loss)로 구성된 지각적 손실 함수(perceptual loss function)를 체압 분포 이미지 맞춰 파인 튜닝을 진행한다.

파인 튜닝은 사전 학습 모델을 기반으로 새로운 목적을 위해 학습된 weight나 bias를 조정하는 과정을 말하며[26], 이를 통해 기존의 SR기술을 체압 이미지에 적합한 알고리즘을 개발하였다.

1.1. 콘텐츠 손실

일반적으로 MSE를 기반으로 할 때 pixel-wise MSE loss를 사용하지만 이러한 방식은 텍스처를 부드럽게 하는 효과로 고주파세부사항을 흐리게 보이게 한다. SRGAN에서는 이 문제를 해결하기 위하여 pre-trained model VGG19[26]의 activation function ReLU를 기반으로 콘텐츠 손실을 아래 수식(3)과 같이 구성하였다.

$$l_{VGG/i,j}^{SR} = \frac{1}{W_{i,j}H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\phi_{i,j}(I^{HR})_{x,y} - \phi_{i,j}(G_{\theta_G}(I^{LR}))_{x,y})^2 \quad (3)$$

I^{LR} 은 low-resolution image, I^{HR} 은 high-resolution image이며, $W_{i,j}$ 와 $H_{i,j}$ 은 VGG19 네트워크 내의 각 feature map의 차원, $\phi_{i,j}$ 은 VGG19 네트워크 내에서 i 번째 매핑 계층과 j 번째 컨볼루션에 의해 얻는 특성을 나타내며 $G_{\theta_G}(I^{LR})$ 은 저해상도 이미지가 고해상도로 재구성된 이미지이다.

1.2. 적대적 손실

이 부분은 이미지 손실을 최소화하기 위해 GAN에서 특이적으로 사용하는 방식으로, (1-x)는 훈련 초기 gradient가 flat한 경향이 있어 이것을 역으로 바꾼 -(x)방식을 사용한다. 아래 수식(4)과 같이 변경된 방식은 gradient초기값은 매우 크게 나타나지만 generator가 고해상도인 상태로 훈련 되기 위한 학습으로 좋은 효과를 보여준다[24]

$$l_{Gen}^{SR} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I^{LR})) \quad (4)$$

D_{θ_D} 은 재구성된 이미지 $G_{\theta_G}(I^{LR})$ 가 원본 고해상도 이미지일 확률이다.

위에 설명한 2가지의 손실 함수를 더하여 최종적으로 아래 수식(5) 와 같은 지각적 손실 함수가 완성된다[27].

$$l^{SR} = l_{VGG/i,j}^{SR} + 10^{-3}l_{Gen}^{SR} \quad (5)$$

본 연구에서는 그림 9과 같이 네트워크를 구성하였다. 기존의 판별 네트워크에서 체압 분포 이미지의 크기에 적합한 학습을 진행하기 위하여 판별네트워크 레이어의 kernel Size를 3x3으로 수정하였고 moment는 0.9, Leaky ReLU는 0.2, dropout은 0.2와 같이 기존의 유사한 SRGAN 구성 사례에서 사용된 매개변수 값을 활용하여 구성하였다.

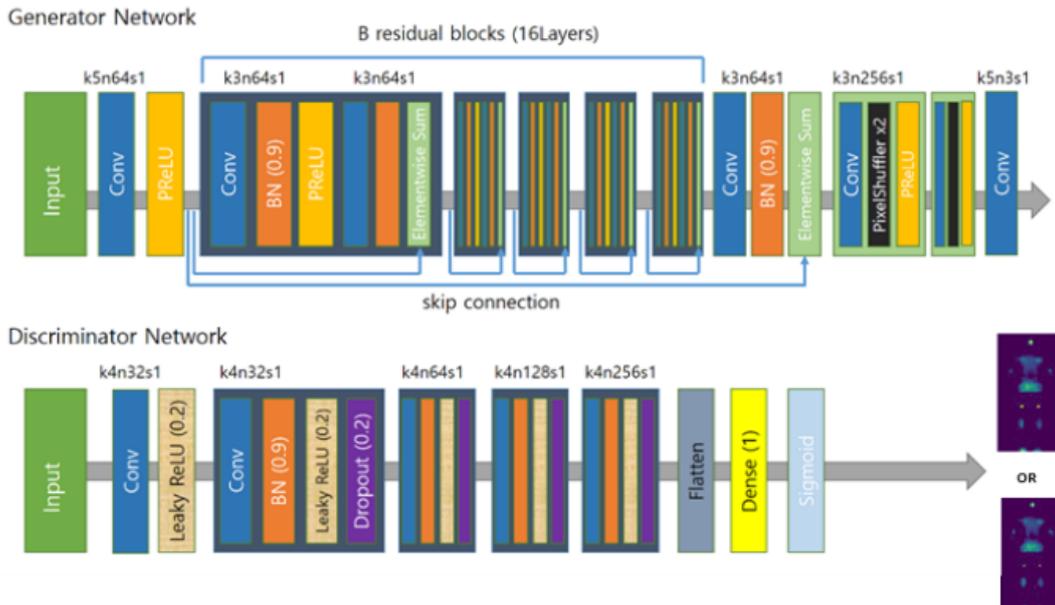


Figure 6 SRGAN architecture for Pressure Ulcers

2. 체압분포이미지 자세 검출 알고리즘

자세 검출을 위해서는 Figure[7]와 같이 OpenPose에서 제안하는 Pose Output Format[body 25] 기존의 분류방식에서 체압분포데이터에 맞춰 Face, Hand, Foot 부분을 Supine은 9 Key Points(Head, Back, Left arm, Right arm, Hip Left ischial, Left Ankle, Right ischial, Right Ankle), Right, Left는 7 Key Points(Head, Shoulder, Elbow, Hand, Hip, Knee, Ankle) 3가지 자세 분류로 정의하여 Key Points 변환 하였다.

자세 검출 알고리즘의 손실 함수는 MSE, binary crossentropy, categorical crossentropy, sparse categorical crossentropy 등이 사용되고, 손실 함수를 이용하여 실제 값과 추정 값의 차이를 최소화하는 파라미터들을 찾아가는 딥 러닝 형태로 구성하였다, 본 연구에서는 3개의 환자 자세를 분류하는 목적을 고려하여, categorical crossentropy 기법을 이용하여 다중 클래스 분류 학습을 진행하였다[28].

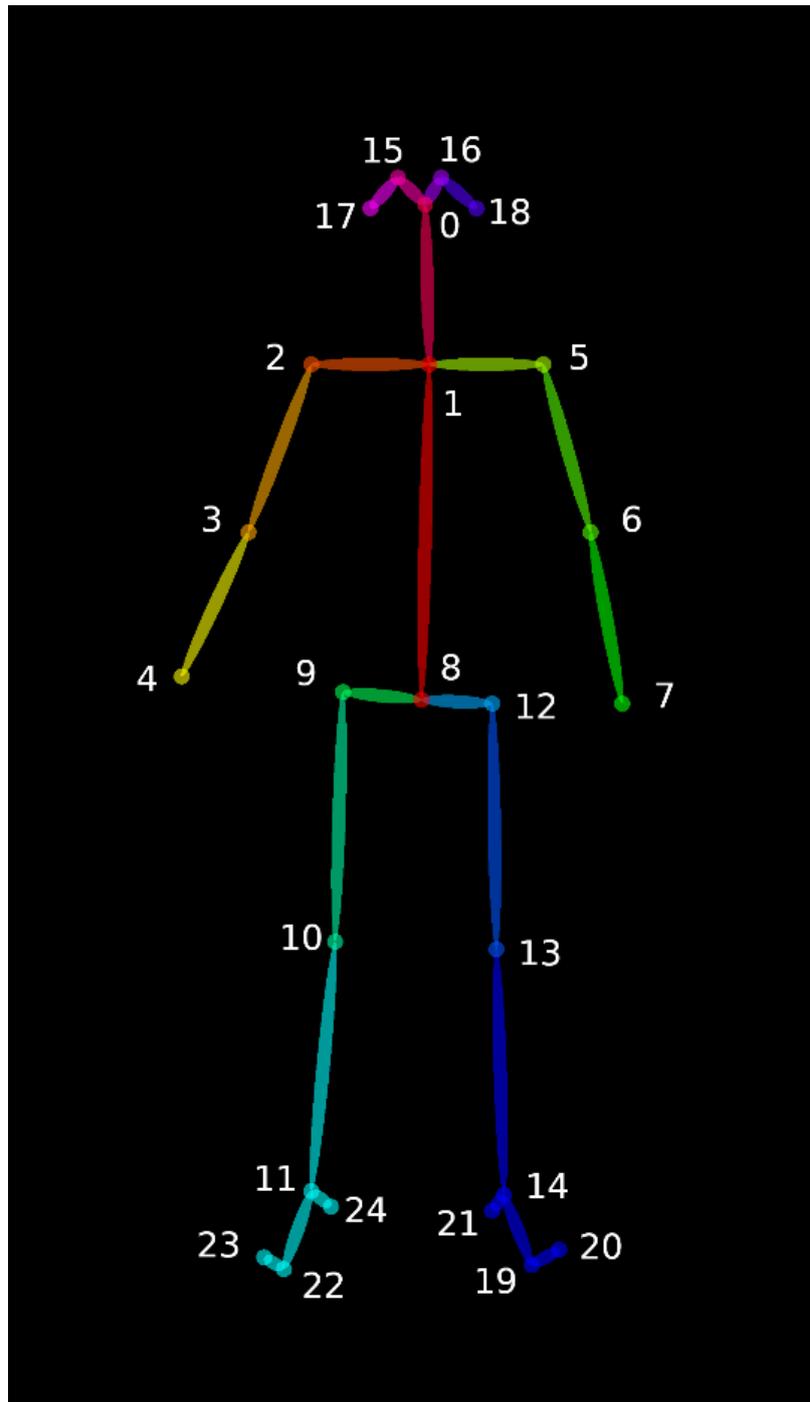


Figure 7 Pose Output Format (BODY_25)

3. 체압분포이미지의 획득 및 라벨링

총 3가지의 자세(supine, right log, left log)에 대한 압력데이터셋은 각기 다른 2가지의 전신체압측정기를 이용하여 획득하였다. 데이터의 획득에는 계명대학교 사용성 평가 센터의 전신체압측정기(Pliance, Novel Inc, U.S.A.)와 서울아산병원에서 보유중인 전신체압측정기(BPMS, 테크스툼, 대한민국)을 활용하여 진행되었다.

64x32 해상도의 이미지 1800장과 48x16 해상도의 이미지 1200장을 획득하였다. 추가적으로, Vista Medical FSA SoftFlex로 측정된 open dataset[29]의 3가지 자세에 대해 64x32 해상도를 가진 이미지 3000장(각 1000장)을 네트워크 학습에 활용하였다.

3가지 자세 분류에 속하지 않는 기타 자세는 실측 데이터를 따로 만들지 않고, 위에 설명한 측정 데이터에 임의적인 변형을 가하여 - 각도 변환(-15°, -10°, -5°, 0°, 5°, 10°,15°) - "others"의 네 번째 분류 데이터셋(총 12만장)을 만들고, 총 4가지의 자세 형태(supine, right log, left log, others)로 데이터셋을 one-hot encoding을 기법으로 분류 학습을 진행하였다.

자세 분류를 위해 사용된 CNN에서 학습 데이터는 다음과 같이 세부 구성을 나누어 진행하였다. 학습 데이터는 대개 훈련용 데이터 집합(train set)과 학습이 이루어진 인공지능 엔진의 성능을 시험하는 시험용 데이터 집합(test set)으로 나누어 사용되는데, overfitting의 문제를 피하기 위해 훈련용 데이터도 다시 두 가지로 나누어, 처음 훈련용 데이터 집합과 검증용 데이터 집합(validation set)을 나누어, 초기 훈련 데이터로 어느 정도 정확도가 높아지고(손실 함수의 값이 낮아지고) 수렴되는 경향을 보일 때까지 학습을 한 후에 검증용 데이터를 통해 다시 학습을 시키면서 정확도의 변화 양상을 보아 일정한 수준에서 학습을 종료시키는 과정으로 진행된다.[30] 본 연구에서는 위에 설명된 데이터들을 6:3:1의 분량으로 각각 훈련, 검증, 시험 데이터로 사용하였다.

연구 과정의 제한적 상황으로 저해상도 데이터, 즉 센서 숫자가 적은 실제 측정용 압력 센서 시스템의 개발이 완료 되지 않아, 위에 설명된 고밀도 센서로 얻은

데이터, 고해상도 데이터를 각각 /2 weight, /2 height를 총 /4 downsampling 한 후에 이를 다시 bicubic interpolation 방식으로 scaling 하여 일부로 해상도를 낮춘 입력용 데이터를 생성하여 사용하였다.

4. 정확도 평가 방법

정확도 평가에는 이미지 품질 평가 기술(IQA)을 활용하였다[31]. 최대 신호 대 잡음 비(PSNR)는 영상 정보의 화질을 평가할 때 사용하는 지표로 아래 식 (6) 와 같다. 품질이 좋은 이미지는 큰 PSNR값을 가지며, 품질이 좋지 않은 이미지는 작은 PSNR값을 가지게 된다.

$$PSNR = 20 \cdot \log_{10}(MAX_I) - 10 \cdot \log_{10}(MSE) \quad (6)$$

구조적 유사도(structural similarity)는 PSNR의 한계를 극복하기 위해 제안된 지표로서 정의는 아래 수식(7)과 같다. 사람의 지각 능력과 일치시키는 목적으로 개발되었다. 사람은 영상에서 구조 정보를 반영하여 영상을 바라보게 되는데, 영상이 얼마나 구조 정보를 변화시키는 가를 측정하는 기술이다.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

$\mu_x, \mu_y, \sigma_x, \sigma_y, \sigma_{xy}$ 는 이미지 x, y 의 국소 평균, 표준 편차, 교차 공분산이다.

고해상도 향상 이미지 결과물의 정확도는, 상기 두 가지의 이미지 평가 기술을 사용하여 평가되었으며, 자세 검출에 대한 CNN 알고리즘은 아래의 다중 분류 손실 함수를 이용하여 실측 값과 추정 값의 차이를 수식(8)과 같이 이용하여 정확도를 평가하였다.

$$CE = - \sum_i^c t_i \log\left(\frac{e^{s_i}}{\sum_j^c e^{s_j}}\right) \quad (8)$$

t_i 는 ground truth, s_i 는 각 클래스 i 에 대한 CNN의 마지막 층의 출력인 score 벡터의 i 번째 요소이다. c 는 분류할 카테고리의 수를 나타낸다.

RESULT

1.1. 고해상도 복원 인공지능 알고리즘 결과

초고해상도 보정 알고리즘은 운영체제 windows 10 Home 64비트, 프로세서 AMD Ryzen 9 3900X 12-Core Processor(24 CPUs), ~3.8GHz, 그래픽 NVIDIA GeForce RTX 2080 Ti 환경에서 총 12만장의 이미지를 100번 시행을 통해 알고리즘 학습을 진행되었으며, Figure [8-10] 은 체압 분포 데이터의 고해상도 복원 인공지능 알고리즘의 실제 출력 결과의 예시들이다.

체압 분포 측정장비에서 얻은 저해상도 체압 분포 이미지, 변경한 SRCNN, 변경한 SRGAN의 출력 결과와 고해상도 이미지를 총 3가지의 자세(supine, right log, left log)로 알고리즘을 구현했으며, SRGAN으로 보정된 이미지는 육안으로 확인할 수 있을 정도로 원본과 유사함을 확인 할 수 있다.

또한 고해상도 보정 알고리즘을 이미지 평가 기술로 평가하여 고해상도 이미지와 SRCNN, SRGAN 출력 이미지의 유사도 계산 결과 아래 Table [4]로 나타낸다.

SRGAN을 이용한 고해상도 복원 결과는 supine자세에서는 PSNR 37.17dB, SSIM 0.9622, right Log 자세에서는 27.02dB, SSIM 0.9224, left Log자세에서는 31.44dB, SSIM 0.9470으로 SRCNN 대비 높은 결과를 보여주었다. 이미지를 육안 관찰로 정성적 비교해 보아도 SRGAN 결과가 상대적으로 보다 많은 고해상도세부사항을 보여주는 것으로 판단된다.

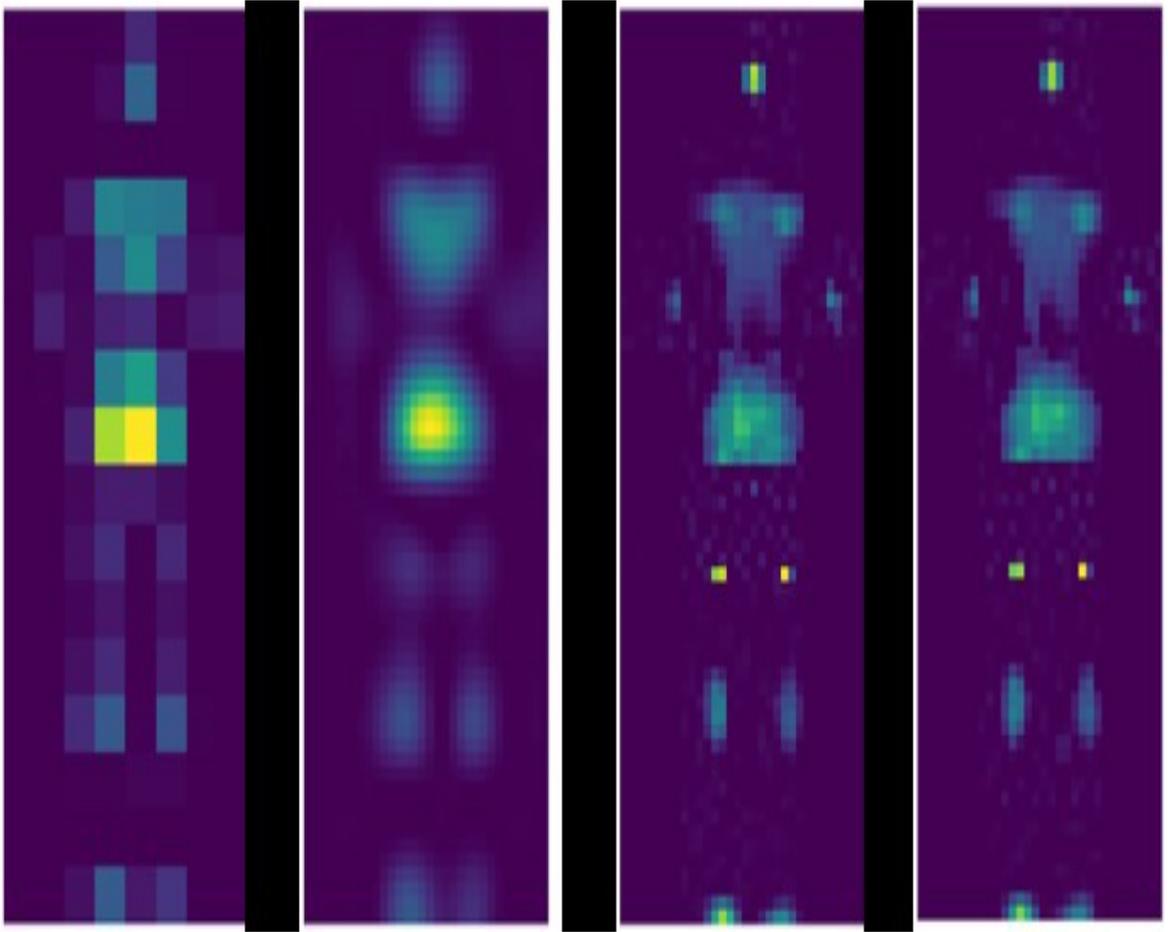


Figure 8 Supine 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지

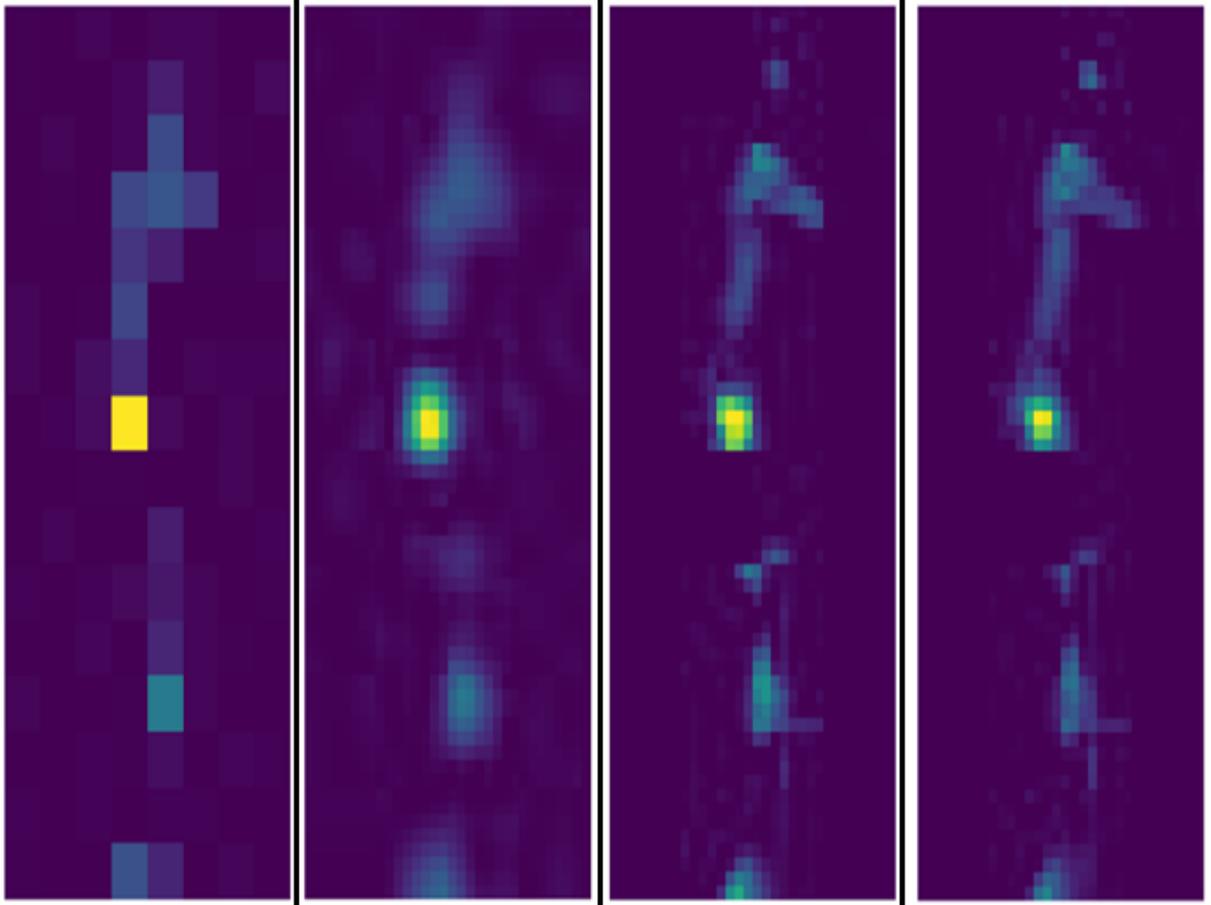


Figure 9 Left log 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지.

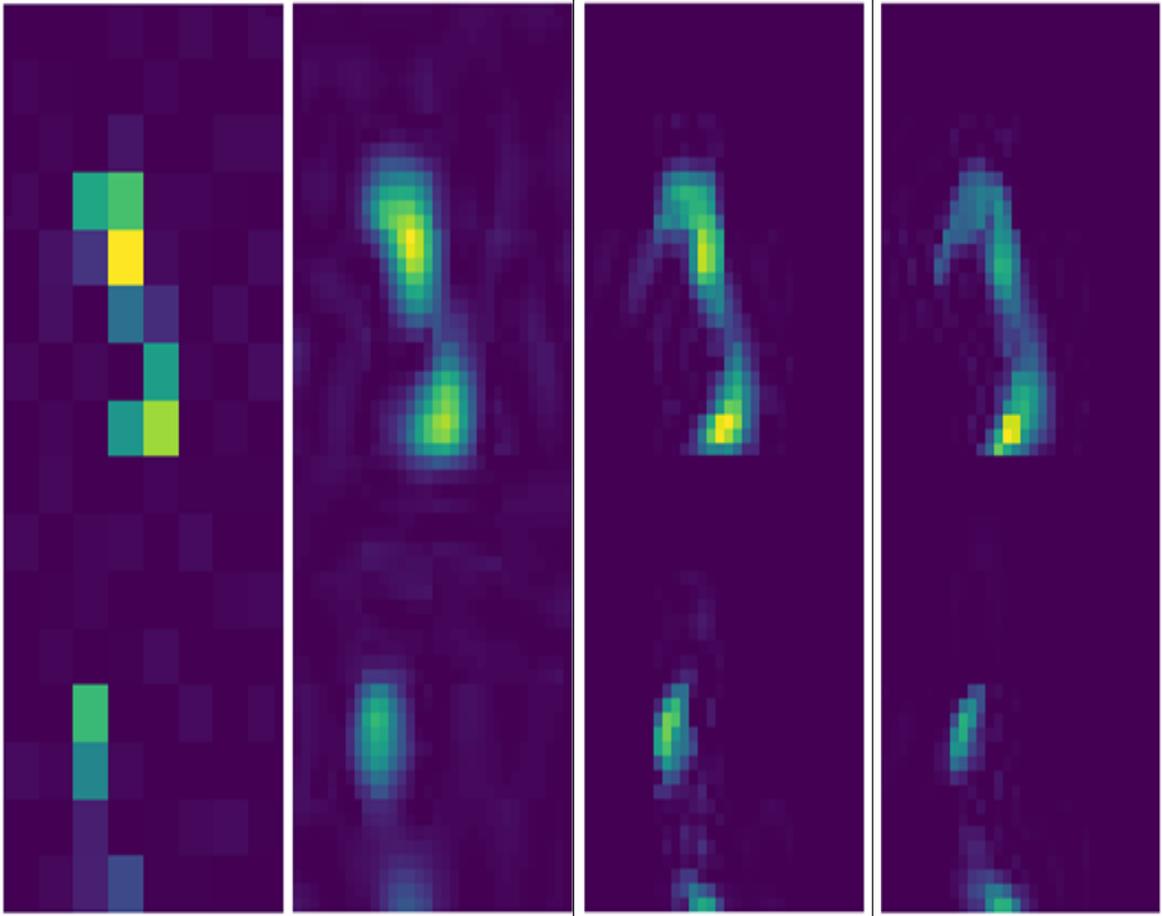


Figure 10 Right log 자세의 이미지 비교 예시. (좌로부터) 입력 저해상도 이미지, SRCNN, SRGAN 이용 처리 결과, 원본 고해상도 이미지.

Table 4 압력 이미지 데이터 간 유사도 결과

	SRCNN			SRGAN		
	Supine	Right Log	Left Log	Supine	Right Log	Left Log
PSNR (dB)	24.29	24.25	27.90	37.17	27.02	31.44
SSIM	0.8049	0.7389	0.7573	0.9622	0.9224	0.9470

1.2. 자세 검출 알고리즘 결과

자세 검출 알고리즘은 운영체제 windows 10 Home 64비트, 프로세서 AMD Ryzen 9 3900X 12-Core Processor(24 CPUs), ~3.8GHz, 그래픽 NVIDIA GeForce RTX 2080 Ti 환경에서 진행되었으며 총 6천장의 데이터를 50번의 반복학습을 진행하며 일정한 값에 수렴할 경우 학습이 종료되는 방식의 알고리즘으로 결과를 출력하였다. 자세 검출은 Figure[11]와 같은 방식으로 분류알고리즘의 결과를 얻게 되며, Figure[12]은 17번의 반복학습에서 일정한 정확도에서 수렴함을 확인하여 결과가 종료 되었으며 훈련 데이터와 검증 데이터 단계 정확도 결과는 98.37%의 결과를 얻었다.

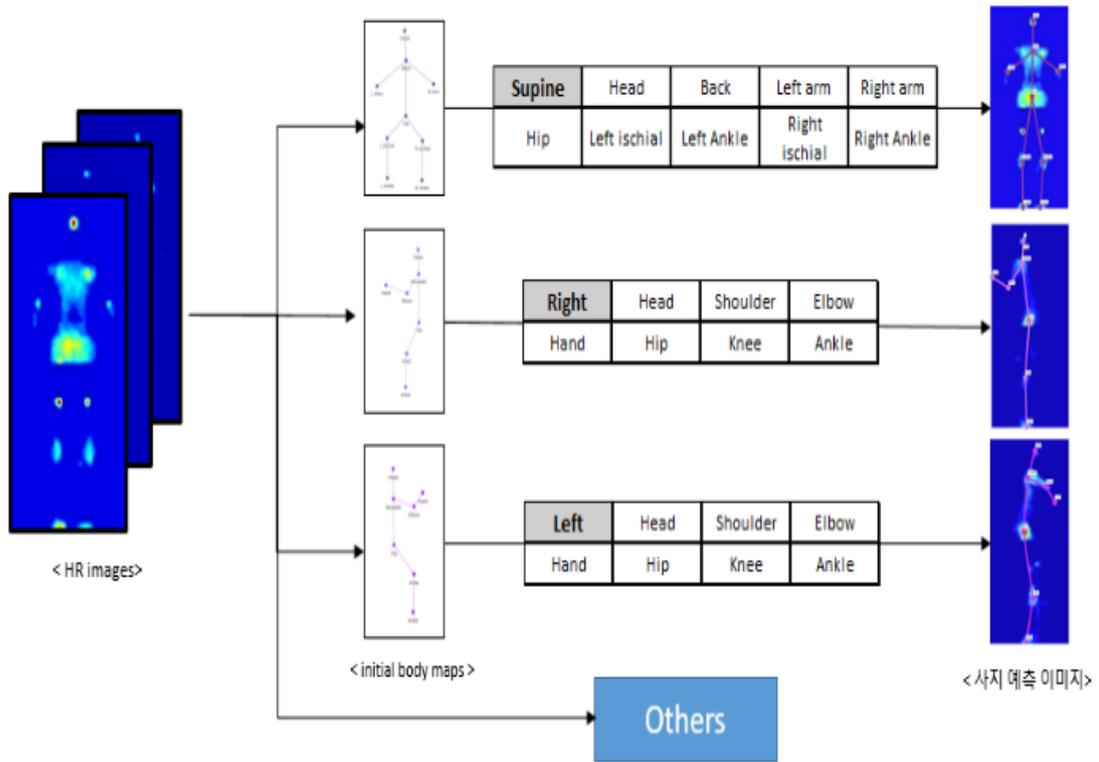


Figure 11 자세 검출 알고리즘결과

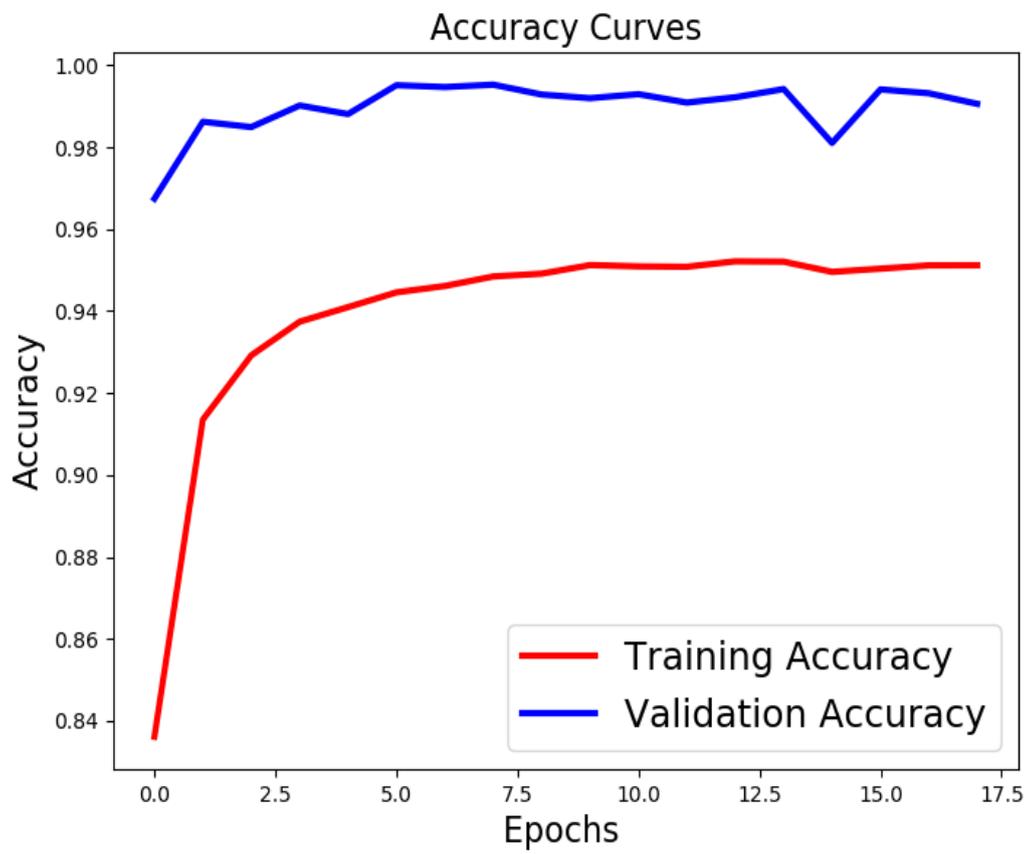


Figure 12 자세 분류 알고리즘의 학습 과정 중 훈련 데이터와 검증 데이터 단계 정확도 변화

DISCUSSION & CONCLUSION

임상 현장에서는 신체 특정 부위 중 눌러 있기 쉬운 부위들이 일정 시간 이상 지속적으로 압력이 가해진 상태가 되면 결과적으로 피부 조직의 변성이 일어나게 되는 욕창의 진행 과정과 발생 예측 위험에 대한 다수의 선행 연구의 결과를 따라 환자의 자세를 파악하고 이를 주기적으로 변화시켜 주는 것으로 기본적인 욕창 예방 효과를 얻고 있다. 본 연구에서 제안하는 인공지능 기반 초고해상도 복원 알고리즘을 활용하여 저해상도 체압 데이터로부터 고해상도 체압 데이터를 추정하는 기술과 학습 기반으로 자세를 분류하는 기술을 구현하여 실용적인 저해상도의 체압 센서 기반의 환자 욕창 예방 기술을 입증하였다. 또한 이미지 평가 기술을 통한 본 연구에서 개발된 알고리즘이 SRCNN 의 loss function 의 한계를 보완하고 콘텐츠 손실(content loss)와 적대적 손실(adversarial loss)로 구성된 지각적 손실 함수(perceptual loss function)을 보정하여 체압분포이미지는 원본 이미지와 높은 지각적 유사도를 나타냄을 확인할 수 있으며 환자 자세 분류 기술 역시 높은 정확도로 실용성을 입증하였다.

체압 분포 정보를 보다 정확히 알 수 있으면, 욕창 발생 예측의 정확도를 보다 높게 이루어낼 수 있으나, 이에 앞서 기본적인 단계로는 환자의 자세의 추정과 상대적으로 주변 보다 높은 압력 분포 지점의 확인 정도로도 일정 정도 임상적으로 유효한 효과를 얻을 수 있어, 본 연구의 한계점은 기존의 고해상도(64 x 32) 에서 down sampling 을 통해 얻은 저해상도를 이용하여 보정 학습을 진행했다. 실제 저해상도 센서 매트릭스를 이용할 경우 매트릭스 센서의 배열, 센서의 정확도 등에 따라 결과값이 많이 상이하게 나오는 것을 확인했고 이를 해결하는데 많은 어려움이 있었다.

앞으로 연구에서는 체압 분포 추정의 정확도를 보다 높이는 것은 추후 과제로 두고, 자세 추정의 단계를 실용적으로 구현 가능한지 탐색해 보았다. 또한 실제 임상 적용될 센서 시스템과 보다 고도화된 인공지능 네트워크를 통하여

자동적으로 욕창을 예측 및 예방하는 기술[14,15]로 최종 구현하는 임상
연구진과의 공동 연구를 다음 단계로 예정하고 있다

REFERENCE

1. European Pressure Ulcer Advisory Panel (EPUAP), Guidelines on treatment of pressure ulcers, EPUAP Rev. 1 (1999) 31–33.
2. S. Tsuji, S. Ichioka, N. Sekiya, T. Nakatsuka, “*Analysis of ischemia-reperfusion injury in a microcirculatory model of pressure ulcers*”, Wound Repair Regen. 13 (2) (2005) 209–215.
3. D. Gawlitta, W. Li, C.W.J. Oomens, F.P.T. Baaijens, D.L. Bader, C.V.C. Bouten, “*The relative contributions of compression and hypoxia to development of muscle tissue damage: an in vitro study*”, Ann. Biomed. Eng. 35 (2) (2007) 273–284.
4. M. Baran Pouyan, J. Birjandtalab, M. Nourani, and M. D. Matthew Pompeo, “*Automatic limb identification and sleeping parameters assessment for pressure ulcer prevention*,” Comput. Biol. Med., vol. 75, pp. 98–108, 2016.
5. J. E. Choi and S.-K. Hwang, “*Predictive Validity of Pressure Ulcer Risk Assessment Scales among Patients in a Trauma Intensive Care Unit*,” J Korean Crit Care Nurs, vol. 12, no. 2, pp. 26–38, Jun. 2019.
6. Barnes, D., & Payton, R. G. “*Clinical application of the Braden scale in the acute care setting*”, Dermatology Nursing, 5(88), 386, 1993.
7. Cubbin, B., Jackson, C. , “*Trial of a pressure ulcer risk calculator for intensive care patients*”, Intensive Care Nursing 7 (1), 40–44, 1991.
8. Waterlow J. Pressure sores: “*a risk assessment card*”. Nurs Times. 3;81(48):49-55. PMID: 3853163, Nov 27-Dec, 1985
9. Marchione, F.G.; Araújo, L.M.Q.; Araújo, L. V: “*Approaches that use software to support the prevention of pressure ulcer: A systematic review.*” Int. J. Med. Inform. 84, 725–736, 2015.

10. M. Seon, J. Choi, and Y. Lee, "Control Technique of a Medical Bed for Ulcer Prevention Equipped with Body Pressure Sensors," vol. 21, no. 2, pp. 89–95, 2021.
11. Marchione, F.G.; Araújo, L.M.Q.; Araújo, L. V. "Approaches that use software to support the prevention of pressure ulcer: A systematic review." *Int. J. Med. Inform.* 2015, 84, 738–759.
12. Jiang, M.; Ma, Y.; Guo, S.; Jin, L.; Lv, L.; Han, L.; An, N. "Using Machine Learning Technologies in Pressure Injury Management: Systematic Review." *JMIR Med. Inf.* 2021, 9, e25704
13. Zahia, S.; Garcia Zapirain, M.B.; Sevillano, X.; González, A.; Kim, P.J.; Elmaghraby, "A. Pressure injury image analysis with machine learning techniques: A systematic review on previous and possible future methods." *Artif. Intell. Med.* 2020, 102, 101742.
14. Koepp, Janine et al. "The Quality of Mobile Apps Used for the Identification of Pressure Ulcers in Adults: Systematic Survey and Review of Apps in App Stores." *JMIR mHealth and uHealth* vol. 8,6 e14266. 16 Jun. 2020, doi:10.2196/14266
15. C. Dong, C. C. Loy, K. He and X. Tang, "Image Super-Resolution Using Deep Convolutional Networks," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 2, pp. 295-307, 1 Feb. 2016, doi: 10.1109/TPAMI.2015.2439281.
16. C. Ledig et al., "Photo-realistic single image super-resolution using a generative adversarial network," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 105–114, 2017, doi: 10.1109/CVPR.2017.19.
17. K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
18. D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," *3rd Int. Conf.*

- Learn. Represent. ICLR 2015 - Conf. Track Proc., pp. 1–15, 2015.
19. H. Ahn, L. Cowan, C. Garvan, D. Lyon, and J. Stechmiller, “*Risk Factors for Pressure Ulcers Including Suspected Deep Tissue Injury in Nursing Home Facility Residents: Analysis of National Minimum Data Set 3.0*,” *Adv. Ski. Wound Care*, vol. 29, no. 4, pp. 178–190, 2016.
 20. D. Ramanan, “*Part-Based Models for Finding People and Estimating Their Pose*,” in *Visual Analysis of Humans*, 2011, pp. 199–223.
 21. W. Gong et al., “*Human pose estimation from monocular images: A comprehensive survey*,” *Sensors (Switzerland)*, vol. 16, no. 12, pp. 1–39, 2016.
 22. J. W. Kim, J. Y. Choi, E. J. Ha, and J. H. Choi, “*Human Pose Estimation Using MediaPipe Pose and Optimization Method Based on a Humanoid Model*,” *Appl. Sci.*, vol. 13, no. 4, 2023.
 23. Z. Cao, G. Hidalgo, T. Simon, S. E. Wei, and Y. Sheikh, “*OpenPose: Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields*,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 43, no. 1, pp. 172–186, 2021.
 24. A. Kendall, M. Grimes, and R. Cipolla, “*PoseNet: A convolutional network for real-time 6-dof camera relocalization*,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, vol. 2015 Inter, pp. 2938–2946.
 25. K. Simonyan and A. Zisserman, “*Very deep convolutional networks for large-scale image recognition*,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
 26. J. Howard and S. Ruder, “*Universal language model fine-tuning for text classification*,” *ACL 2018 - 56th Annu. Meet. Assoc. Comput. Linguist. Proc. Conf. (Long Pap., vol. 1*, pp. 328–339, 2018.

27. C. Lee, J. Park, and J. G. Shon, “*A Study on the Loss Functions of GAN Models*,” no. 1, 2019.
28. Z. Zhang and M. R. Sabuncu, “*Generalized cross entropy loss for training deep neural networks with noisy labels*,” in *Advances in Neural Information Processing Systems*, 2018, vol. 2018-Decem, no. NeurIPS, pp. 8778–8788.
29. M. Baran Pouyan, J. Birjandtalab, M. Heydarzadeh, M. Nourani, S. Ostadabbas. “*A pressure map dataset for posture and subject analytics*.” 2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). DOI: 10.1109/BHI.2017.7897206.
30. I. Rahman, P. S. Gilmour, L. A. Jimenez, S. K. Biswas, F. Antonicelli, and O. I. Aruoma, “*Ergothioneine inhibits oxidative stress- and TNF- α -induced NF- κ B activation and interleukin-8 release in alveolar epithelial cells*,” *Biochem. Biophys. Res. Commun.*, vol. 302, no. 4, pp. 860–864, 2003.
31. W. Zhou and Z. Wang, “*Quality Assessment of Image Super-Resolution: Balancing Deterministic and Statistical Fidelity*,” in *Proceedings of ACM Conference (Conference’17)*, 2022, vol. 1, no. 1, pp. 934–942.

ENGLISH ABSTRACT

In this study, we proposed Super-Resolution (SR) techniques to reconstruct a High-Resolution (HR) pressure image from a Low-resolution (LR) body pressure image in order to solve the limitations of sensor resolution when to predict pressure ulcer spots. We implemented Super-Resolution Generative Adversarial Network (SRGAN) for pressure image reconstruction and Convolution Neural Network(CNN) for posture prediction. To evaluate the similarity between the original pressure image and the 4× rescaled LR body pressure image which was restored by SR technology.

The restored pressure images were classified into four postures: Supine, Right Log, Left Log, and Others. To predict high-risk pressure ulcer sites in each posture, the face, hands, and feet were condensed from the Body_25 Key Point structure of OpenPose, a posture estimation technique, and defined as nine key points (head, back, left arm, right arm, hips, left pelvis, left ankle, right pelvis, and right ankle) for Supine posture, and seven key points (head, shoulder, elbow, hand, hips, knees, and ankles) for Right Log and Left Log.

Image Quality Assessment (IQA) technology and peak signal-to-noise (PSNR) and structural similarity (SSIM) were used. The results of high-resolution restoration using SRGAN showed higher PSNR and SSIM values (37.17 dB and 0.9622 for Supine posture, 27.02 dB and 0.9224 for Right Log, and 31.44 dB and 0.9470 for Left Log) compared to SRCNN. Qualitative comparison using visual observation also showed that SRGAN results provided more high-resolution details. The posture detection algorithm showed a classification accuracy of approximately 98.37%, demonstrating practical feasibility for technical implementation.

Key word: Pressure Ulcer, Super Resolution, Generative Adversarial network, Posture Detection, Image Quality Assessment