creative commons

COMMONS DEED

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

dCollection

공학석사 학위논문

이미지 딥러닝을 통한 소아의 몸무게 추정 알고리즘 개발

Deep learning based pediatric weight estimation algorithm from 2D Image

2020년 8월

서울대학교 대학원
협동과정 바이오엔지니어링 전공

장 준 호

이미지 딥러닝을 통한 소아의 몸무게 추정 알고리즘 개발

지도교수 이 정 찬

이 논문을 공학석사 학위논문으로 제출함
2020년 7월

서울대학교 대학원
협동과정 바이오엔지니어링 전공

장 준 호

장준호의 공학석사 학위논문을 인준함
2020년 7월

위 원 장 _____김 성 완_____(인)
부위원장 _____이 정 찬_____(인)
위　　원 _____정 재 윤_____(인)

초록

이미지 딥러닝을 통한 소아의 몸무게 추정 알고리즘 개발

장준호
서울대학교 대학원
협동과정 바이오엔지니어링 전공

본 연구의 목표는 이미지 딥러닝을 통하여 소아 환자의 사진만으로 환자의 키 및 몸무게를 추정하는 알고리즘을 개발하는 것으로, 응급 상황 등 체중계를 사용한 정확한 몸무게 측정이 불가능한 상황에서 기존 몸무게 추정 방식을 대체하는 추정 정확도로 환자의 몸무게를 추정함을 목표로 한다.

본 연구에서는 소아과를 방문한 0~17세 사이의 환자 중 연구목적으로의 정보 사용에 동의한 환자 514명을 대상으로 네 개의 위치 기준 점이 붙어 있는 침상위에 누운 환자의 모습을 스마트폰으로 촬영하여 얻은 이미지 3802장과 실제 신장 및 체중 측정기를 통해 측정한 각 환자의 키 및 몸무게 정보를 기반으로 알고리즘을 개발하였다.

본 연구에서 개발한 알고리즘은 환자 이미지 전처리 과정과 딥러닝 학습,

그리고 몸무게 자동 추정을 위한 키 추정 및 몸무게 추정 과정으로 나뉜다. 이미지 전처리 과정에서는 실제 키 및 몸무게 추정에 중요한 영향을 끼치는 정보인 이미지 속 사람의 실루엣만을 추출해 사용하기 위해 Mask R-CNN을 통하여 자동으로 사진에서 환자를 인식하고 환자의 실루엣만을 흑백으로 추출하게 하고, 추출한 이미지를 원근 변환 방법을 사용하여 딥러닝 모델이 각 이미지의 절대적 크기를 비교할 수 있도록 하였다.

모델의 학습 및 검증을 위해 환자군을 6:2:2의 비율로 학습 세트, 검증 세트, 시험 세트의 세 집단으로 나누어 학습 및 검증에 사용하였으며, 회귀 문제 분석을 위해 마지막 층 만을 수정한 ResNet50, VGG16, DenseNet121 모델을 사용하였다. 학습 과정에서는 추출 및 변환된 흑백의 환자 실루엣 이미지를 입력, 환자의 실제 키 및 몸무게 정보를 결과로 하여 학습하게 하였으며 특히 몸무게 추정 모델의 학습 과정의 경우, 추정 혹은 측정한 키를 실루엣 이미지에 합산하여 생성한 이미지를 학습 및 추정 과정에서의 입력값으로 하여 보다 많은 정보를 몸무게 추정에 사용하게 하여 각 모델별로 총 50회의 학습 과정을 거치며 가장 검증 정확도가 높은 학습 가중치를 저장하여 키 및 몸무게 추정에 사용한다.

학습을 완료한 모델을 통하여 키 및 몸무게를 추정한 결과, 키 추정 결과에 있어서는 ResNet50이 가장 높은 정확도를 보였고, 몸무게 추정 결과로는 VGG16이 가장 높은 정확도를 보였다. 특히 가장 높은 몸무게 추정 정확도를 보인 VGG16의 경우에는 현재 일반적으로 사용하는 소아 대상 체중 추정 방법인 Broselow Tape 방법에 필적하는 높은 몸무게 추정 정확도를 보인다.

본 논문은 이미지 딥러닝을 통하여 환자의 사진에서 몸무게를 추정하는 알고리즘을 최초로 제시한 것에 가장 큰 의의가 있다. 특히 높은 왜곡도를 보인 이미지 전처리 결과와 적은 학습 데이터 개수에도 불구하고 본 알고리즘의 최종 체중 추정 정확도는 기존 체중 추정 방법과 유사한 추정 정확도를 보인다.

비록 본 논문에서는 현재의 추정 방법에 비해 높은 정확도를 보이지는 못하

였으나, 딥러닝 기반 몸무게 추정 알고리즘이라는 본 알고리즘의 특성은 추후 대중화 시에 학습량의 증가를 바탕으로 본 알고리즘의 추정 정확도가 지속적으로 상승하여 기존 체중 추정 방법을 상회하는 정확도를 얻어낼 수 있다는 가능성을 시사한다.

주요어 : 딥러닝, 추정, 몸무게, 키, 소아
학번: 2015-21219

목 차

초 록 ..... **iv**
목 차 ..... **iv**
표 목차 ..... **vi**
그림 목차 ..... **vii**

1. 서 론 **1**
1.1 소아의 몸무게 추정의 중요성 **1**
1.2 딥러닝 6
1.3 관련 연구 14
1.4 연구의 필요성 17

2. 방 법 **18**
2.1 데이터 분석 18
2.2 알고리즘 모식도 22
2.3 데이터 전처리 24
2.4 딥러닝 구조 생성 및 학습 32
2.5 결과 데이터 분석 방법 34

3. 결과 및 분석 **36**
3.1 이미지 전처리 결과 분석 36
3.2 키 추정 결과 및 분석 37

3.3 몸무게 추정 결과 및 분석 38

4. 결론 및 고찰 40

4.1 고찰 40

4.2 결론 41

참고문헌 42

Abstract 45

그림 목차

그림 1. Broselow Tape 3
그림 2. Weighing Cam의 사용 방법 예시 5
그림 3. 학습 데이터의 양과 성능 사이의 그래프 7
그림 4. ResNet50의 구조 9
그림 5. VGG16의 구조 10
그림 6. DenseNet121의 구조 11
그림 7. Mask R-CNN의 구조 13
그림 8. 선형회귀분석 기반 몸무게 추정 논문에 사용된 특징값의 위치 15
그림 9. 선형회귀분석 기반 몸무게 추정 논문에 사용된 데이터 및 추정 결과 16
그림 10. 유아용 자동신장체중계 DSB02 19
그림 11. 신장 자동측정기 GL-310 19
그림 12. 입력 이미지 예시 21
그림 13. 데이터 세트 별 히스토그램 23
그림 14. 학습 알고리즘 모식도 24
그림 15. 키 및 몸무게 추정 알고리즘 모식도 25
그림 16. Mask R-CNN을 사용한 실제 image segmentation 예시 27
그림 17. Homography 예시 29
그림 18. 전체 이미지 사전 처리 과정 31
그림 19. 본 연구를 위해 변형된 딥러닝 모델 구조 예시 (DenseNet121) 33

표 목차

표 1. 모델의 성능 비교 8
표 2. 환자의 나이 별 특성 20
표 3. 이미지 전처리 왜곡도 36
표 4. 모델 별 키 추정 비교 37
표 5. 모델 별 체중 추정 비교 39

1. 서 론

1.1. 소아의 몸무게 추정의 중요성

응급 소생 과정에서 약물의 투약량, 제세동 에너지 확인 등 소생에 결정적 영향을 미치는 치료의 양은 소아의 몸무게를 기반으로 계산된다[1]. 따라서 정확하고 안전한 치료를 위해서는 치료 전 소아의 몸무게를 정확히 계측하는 것이 필수적이다. 그러나 실제 응급 상황에서는 시간이 부족하여 소아를 체중계에 올려 몸무게를 확인하기가 실질적으로 불가능해 몸무게를 정확히 계측하기 어려우며, 특히 병원 외부에서 응급 상황이 발생할 경우에는 더더욱 측정하기 힘들다.

그래서 이와 같이 체중계를 사용할 수 없는 응급 상황에서도 보다 정확히 체중을 추정하기 위하여 여러 체중 추정 방법이 개발되었다. 대표적으로 1. 눈대중을 기반으로 측정하는 방법[2-4], 2. 연령을 기반으로 하는 체중 추정 방법, 3. 키를 기반으로 체중을 추정하는 소아소생술 테이프(i.e. Broselow Pediatric Emergency Tape) 등의 방법이 있는데, 현존하는 방법에는 각각의 한계점이 존재한다.

먼저 눈대중을 기반으로 추정하는 방법은 가장 간편하고 빠르나, 그 정확도가 의사가 추정할 경우[2] 43%의 낮은 정확도를 보이며, 숙련된 간호사가 추정하는 경우 역시 55%의 정확도, 보호자가 체중을 추정할 경우에는 78~80% 정도의 높은 정확도를 보인다고 보고된 바 있으나[3, 4] 상기 연구의 경우 응급 상황이 아닌 상황에 한하여 시행된 것이므로 보호자가 당황하기 쉬운 실제 응급 상황에서 연구 결과와 같은 높은 경확도로 추정할 것이라고 단정지을 수 없다.

연령을 기반으로 한 체중 추정 방법[5, 6]은 계산이 정말 쉽다는 장점이 있으나, 체형 및 환자 별로 다른 발달 상황을 고려하지 않기에 환자의 성장 정도가 평균보다 빠르거나 느릴 경우 혹은 환자가 평균 대비 저체중이거나 과체중일 경우에는 정확도가 급락한다.

현재 세계적으로 가장 많이 사용되는 소아 소생술 테이프(Broselow tape)의 경우에는 키를 기반으로 몸무게를 추정한다(그림 1). 소아 소생술 테이프의 경우, 다른 방법에 비해 간편하게 측정이 가능하면서도 높은 정확도를 보이기 때문에 현재까지 임상에서 널리 쓰이고 있다[7, 8]. 그러나, 이 방법은 약 3만원 내외의 장비가 늘 필요하며, 측정 범위(145cm)를 넘어서는 키를 가진 소아에게는 적용이 불가능하다는 단점이 존재한다.

또한 Broselow tape는 전체 소아의 키와 몸무게의 관계성을 통계적으로 분석하여 체중을 추정하기에 정상 체형이 아닌 환아에게는 실제 체중과의 오차가 커 적용이 어려운 단점 역시 존재한다. 이에 새로이 체형을 추가로 기반으로 하여 체중을 추정하는 시스템(PAWPER tape)이 나왔지만, 이 시스템은 현재 추정 정확도가 50% 정도로 보고되어[9] 아직은 임상적 유용성을 판단하기 어렵다.

그림 **1. Broselow Tape**, https://en.wikipedia.org/wiki/File:BTape3.jpg

이 논문의 선행 논문[10]인 Weighing Cam의 경우(그림 2), 스마트폰을 기반으로 한 새로운 몸무게 추정 방안을 개발하였다. 스마트폰을 이용하여 소아의 키를 추정하고, 키 및 체형을 기반으로 대한민국의 전체 소아의 몸무게 분포도와 비교하여 체중을 추정하는 방법을 제시하였다. 그러나 기존 논문에서 개발한 시스템의 경우에는 사용자가 직접 사진 속 환자의 머리, 발꿈치 및 마커의 위치를 스마트폰에 표시하고, 총 3단계로 나누어진 체형 중 환자가 어떤 체형에 속하는지를 계측자가 스스로 추정하여야 하는 단점이 있다. 이러한 현존하는 체중 추정 방법의 단점을 개선하기 위하여 본 논문에서는 이미지 딥러닝을 사용하여 사진에서 환자의 키를 추정 후, 추정 혹은 실측한 키와 환자의 사진을 바탕으로 딥러닝을 통해 최종적으로 몸무게를 자동으로 추정하는 알고리즘을 개발하였다.

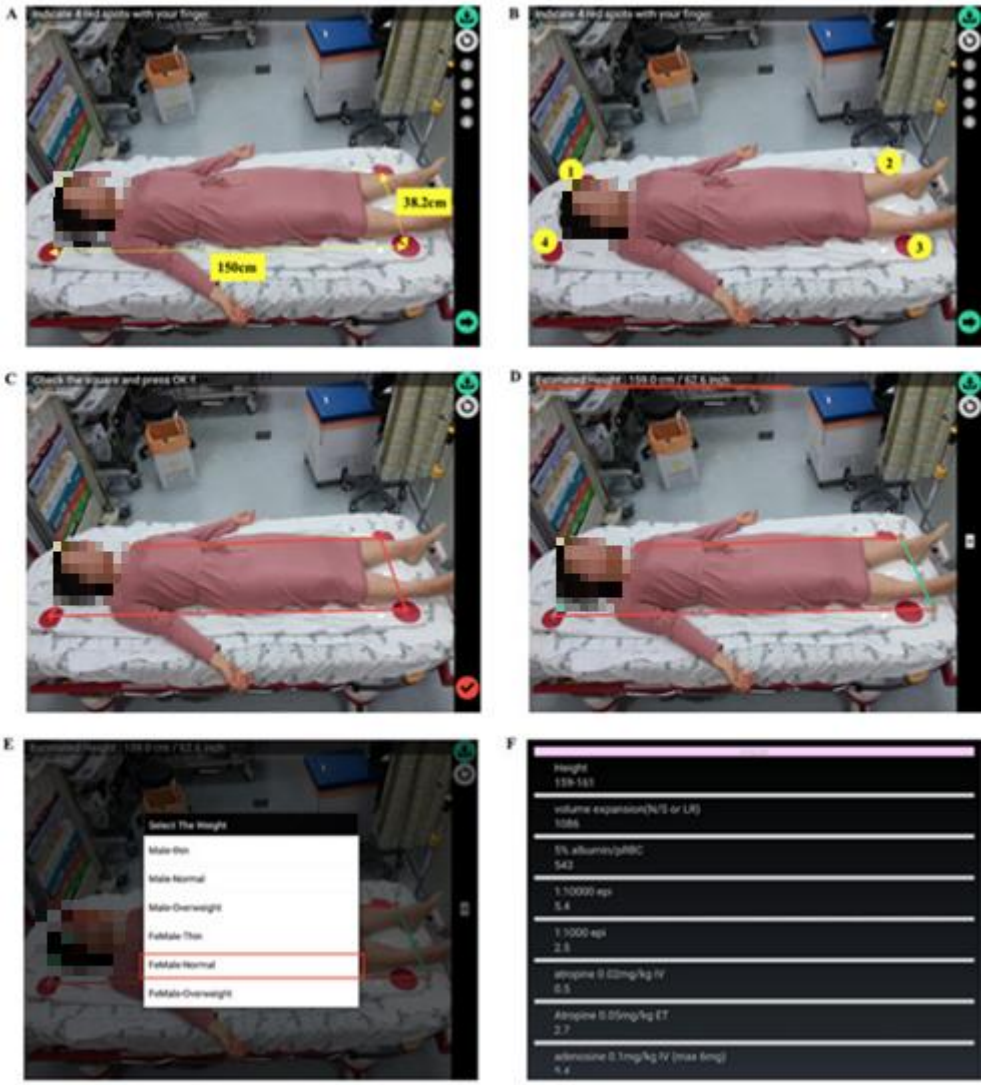

그림 2. Weighing Cam의 사용 방법 예시[10]

1.2. 딥러닝

1.2.1. 딥러닝의 원리

컴퓨터의 성능 급상승 및 계산 방식의 개선으로 인해, 최근의 시대는 가히 딥러닝의 시대라 할 수 있을 정도로 딥러닝은 다양한 분야에 이용되고 있다.

딥러닝은 두뇌의 기작을 모사한 알고리즘으로, 뉴런의 기능을 하는 퍼셉트론을 여러 층으로 중첩하여 서로 망을 이루어 인공 신경망을 구성하고, 정보의 전파 및 역전파를 사용하여 각 퍼셉트론의 weight의 값을 학습해 가며 최종 결과의 오류를 줄여 나가는 원리로 움직인다. 딥러닝은 그 특성상 많은 자료를 학습하면 할수록 기존의 머신러닝 알고리즘 기반 학습에 비하여 성능 향상 폭이 급격하게 커진다(그림 3) 특히 여러 딥러닝 구조 중 하나의 종류인 합성곱 신경망(Convolutional Neural Network, 이하 CNN)은 이미지 내의 정보 처리 및 분류, 이미지 기반 회귀 문제에 있어 뛰어난 성과를 보여 준다[11]. 현재 주로 사용되고 있는 CNN 모델로는 ResNet[12], VGGNet[13], DenseNet[14] 등이 존재한다.

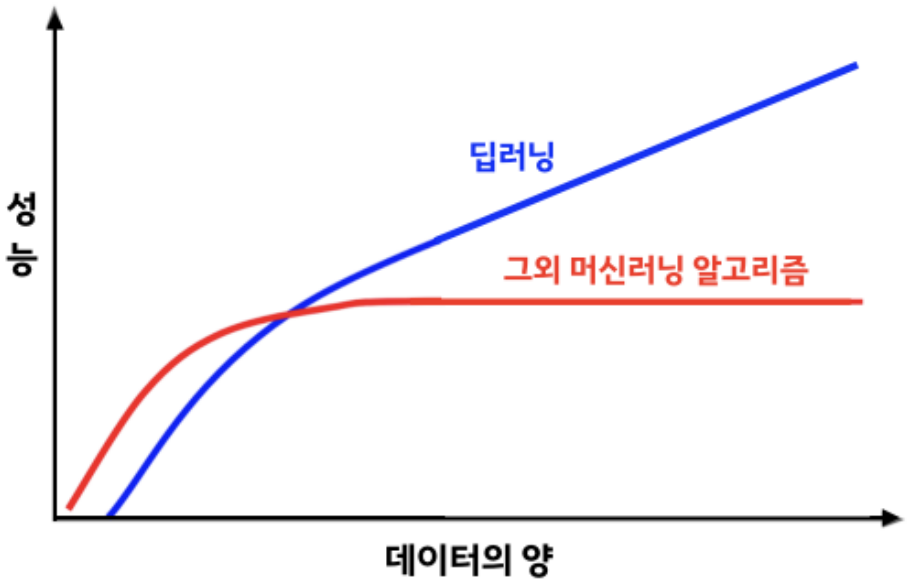

그림 3. 학습 데이터의 양과 성능 사이의 그래프,

https://www.kakaobrain.com/blog/64

1.2.2 딥러닝 모델 별 구조 및 성능

본 연구에서는 ResNet50(그림 4), VGG16(그림 5), DenseNet121(그림 6)을 이용하여 딥러닝 모델을 각각 구현하였다. 각 모델의 성능 및 특성은 표 1.에 정리하였으며 각 모델의 구조는 그림 4,5,6에 수록하였다.

표 1. 모델의 성능 비교

모델	크기	상위-1 정확성	상위-5 정확성	매개 변수	깊이
ResNet50	98MB	0.749	0.921	25,636,712	-
VGG16	528MB	0.713	0.901	138,357,544	23
DenseNet121	33MB	0.750	0.923	8,062,504	121

상위-1 정확성 및 상위-5 정확성은 ImageNet 검증 데이터세트에서의 성능을 가리킨다.

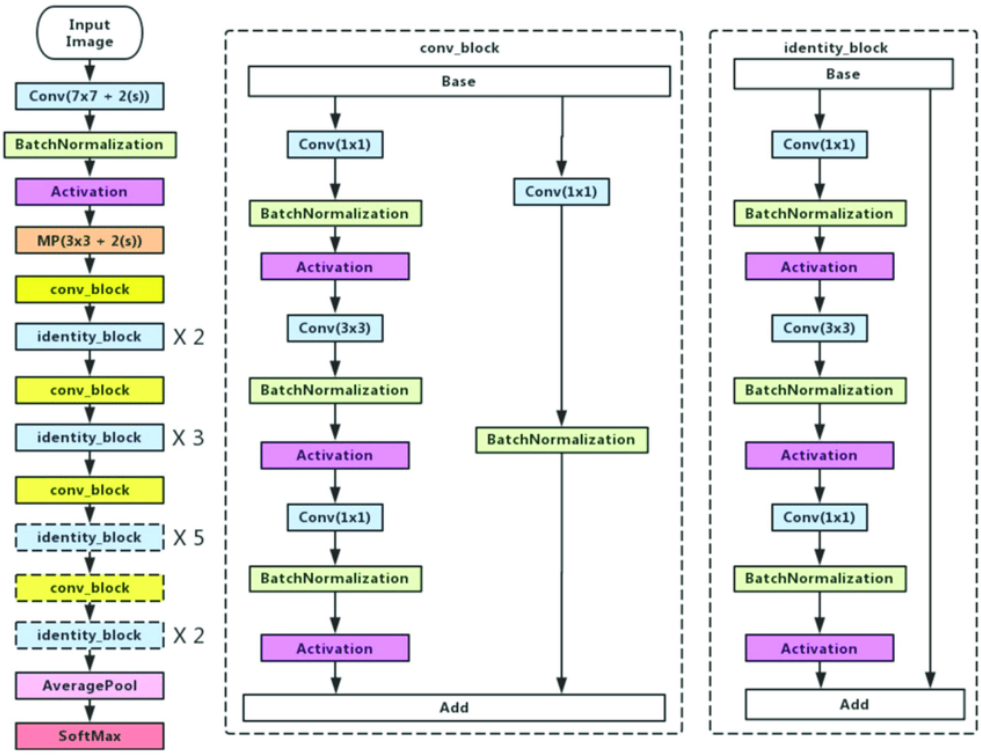

그림 4. ResNet50의 구조, residual block의 존재로 인해 몇몇 층 사이에 일종의 지름길이 생성되어 입력 데이터 및 그라디언트가 보다 다양한 경로로 이동한다.

https://www.researchgate.net/figure/Left-ResNet50-architecture-Blocks-with-dotted-line-represents-modules-that-might-be_fig3_331364877

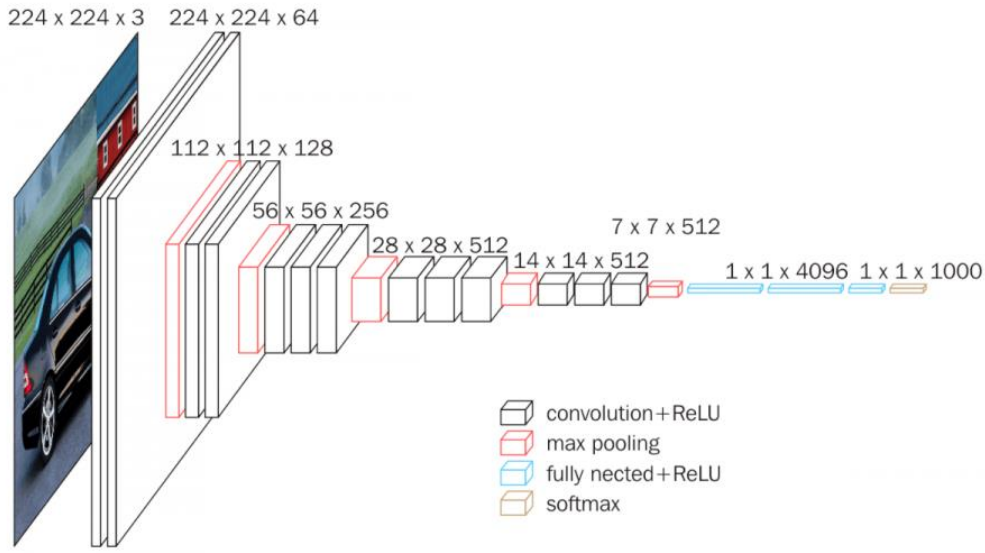

그림 5. VGG16의 구조, 총 16개의 층으로 구성되어 있다.

https://www.pyimagesearch.com/2017/03/20/imagenet-vggnet-resnet-inception-xception-keras/

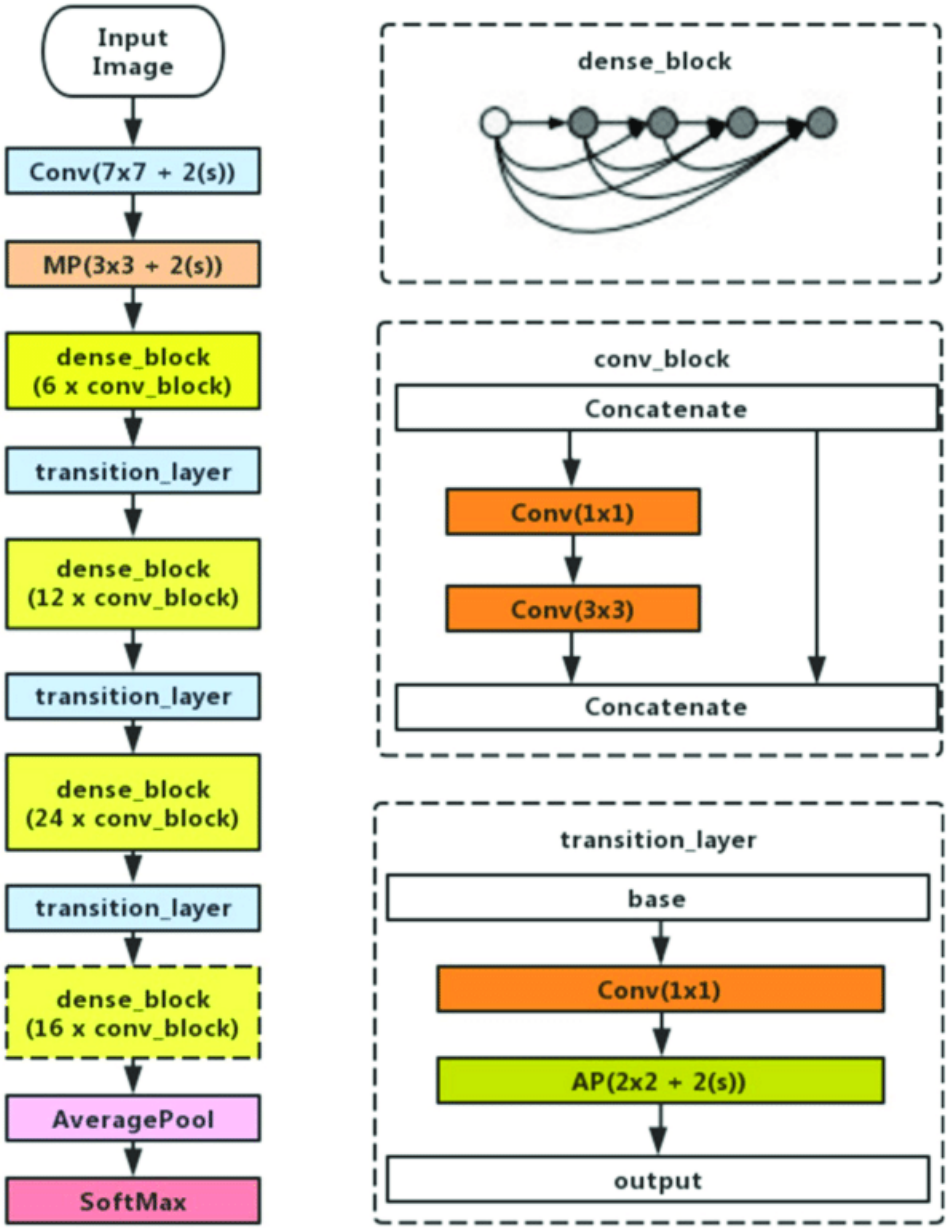

그림 6. DenseNet121의 구조, 전체 네트워크가 지름길을 통하여 서로 연결되어 ResNet에 비해서 더욱 많은 정보의 순환이 가능하다.

https://www.researchgate.net/figure/Left-DenseNet121-architecture-Right-Dense-block-conv-block-and-transition-layer_fig4_331364877

1.2.3. 사물 인식 및 마스킹 모델 Mask R-CNN

CNN을 이용하여 이미지 속 인물을 인식하고 그 위치를 찾아주는 시스템은 여러 연구자에 의해 R-CNN, Fast R-CNN[15], Faster R-CNN[16]으로 발전되어 왔으며, 최근에는 Mask R-CNN이라는, 인물 및 사물 인식과 동시에 그 사물의 마스크를 자동으로 추출하는 딥러닝 모델이 개발된 바 있다[17].

Mask R-CNN은 기존의 Faster R-CNN 모델에 이진 마스크를 생성하는 한 개의 층을 추가한 모델이다(그림 7). 기존 Faster R-CNN 모델처럼 이미지 내 각 물체를 인식하여 ROIAlign을 통하여 인식한 물체에 ROI 박스를 씌워주는 동시에, 이진 마스크 층에서는 각 픽셀 별 클래스를 예측하여, 인식 완료 후 생성된 ROI 박스의 클래스와 동일한 클래스의 픽셀을 출력하는 방식으로 인식한 물체에 마스크를 씌운다.

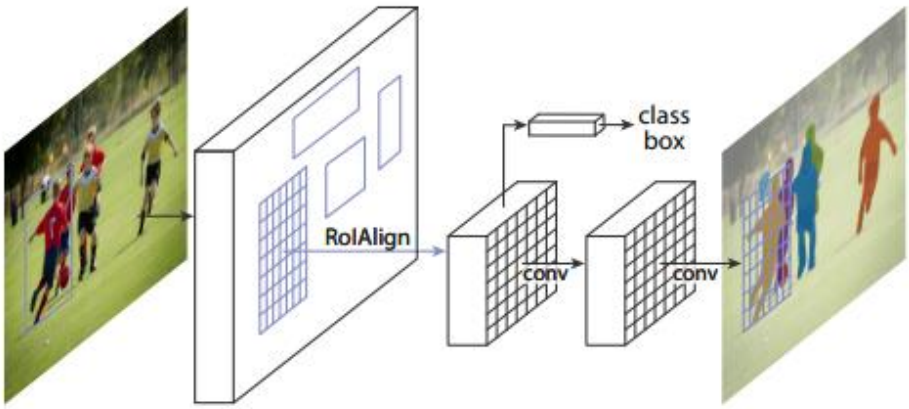

그림 7. Mask R-CNN의 구조[17]

1.3. 관련 연구

기존에 2D 이미지에서 키 및 몸무게를 추정하는 방법을 연구한 논문을 조사하였다.

먼저, 2D 이미지에서 키를 추정하는 방법으로는 다수의 사진을 연결하여 분석함으로써 알고 있는 일부 인물의 키를 바탕으로 다른 인물들의 키를 추정하는 방법[18], 카메라의 특징(시야각 등)을 바탕으로 사진 속 물체의 거리 및 길이를 추정하는 방법[19, 20], 크기를 알고 있는 기준 물체와의 비례도를 측정하여 키를 추정하는 법[21, 10] 등이 존재한다.

2D 이미지에서 체중을 추정하는 방법으로는 현재 기준, 다중 선형 회귀 분석 기법을 사용한 실루엣으로부터의 체중 추정[22] 방법만을 찾을 수 있었다.

다중 선형 회귀 분석 기법을 사용한 인체 실루엣 이미지에서의 체중 추정 방법은 서 있는 사람을 정면에서 찍은, 절대 크기를 알고 있는 정면 사진의 실루엣 이미지를 추출하여 세로로 동일한 너비가 되도록 총 8조각으로 나눈 후(그림 8), 각 조각의 위치에서 가장 긴 좌우 길이를 찾아냄으로써 키, 어깨의 너비, 발의 너비, 복부의 너비의 총 네 가지 정보를 뽑아낸 후 이 네 개의 정보를 다중 선형 회귀 분석을 통하여 몸무게를 분석하는 방법이다. 이 논문의 경우에는 총 10명의 성인 남성의 실루엣을 분석하여 몸무게를 분석하는 가장 최적의 공식을 찾아내었다. 이 논문에서는 최적의 결과일 때 R^2 = **0.80** 이며 이때의 RMSE = 2.68kg 이라는 결과를 얻었다. 그러나 이 방법은 성인 남성의 경우에 한하며, 샘플의 크기 역시 작으며 10명 중 8명이 거의 동일한 체격을 가진(190~200cm) 성인 남성의 경우에 한해 계산하였기에, 실제 추정에 사용하기에는 부적합하다. 이 논문에 사용된 정보 및 결과는 그림 8, 9에 수록하였다.

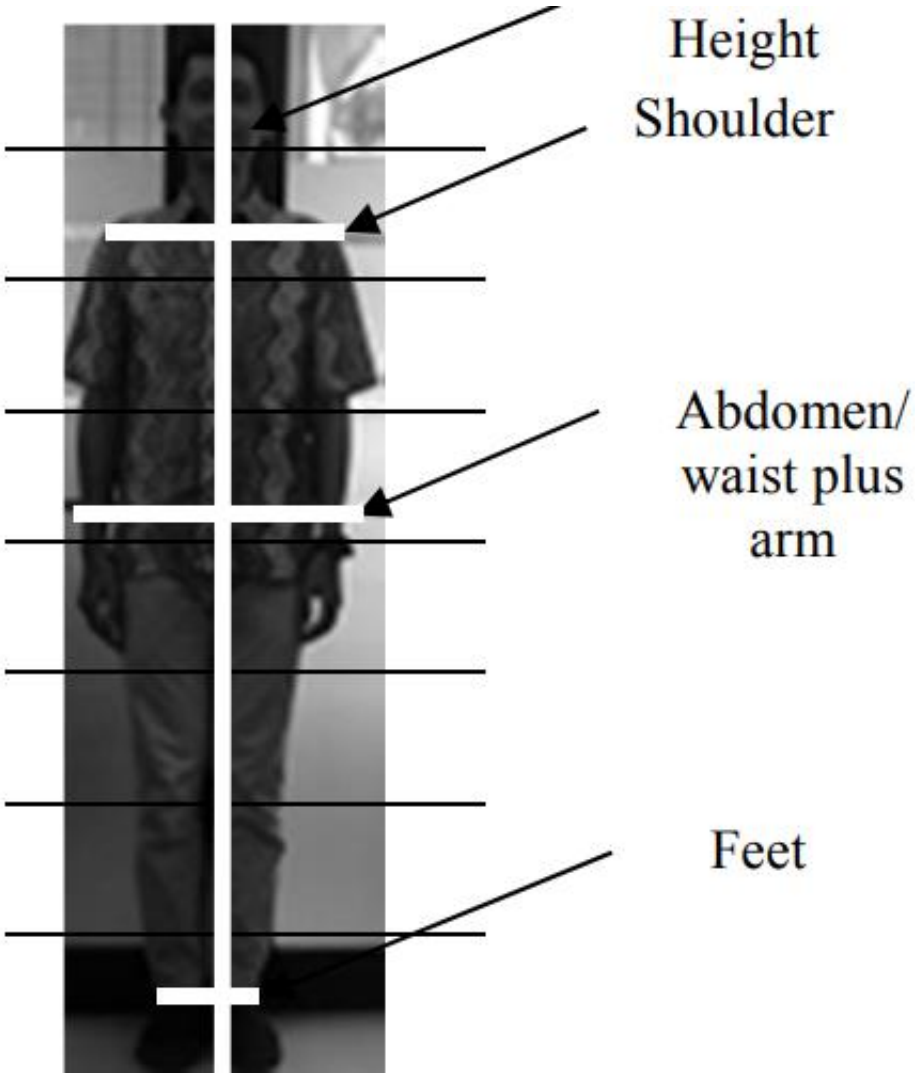

그림 **8.** 선형회귀분석 기반 몸무게 추정 논문에 사용된 특징값의 위치**[22]**

BODY FEATURE FROM DATA

No	F1	F2	F3	F4	Actual Weight (Kg)
1	176	52	53	15	70
2	192	48	57	26	71
3	192	51	59	20	76
4	197	52	48	19	81
5	198	54	54	17	67
6	209	54	55	16	58
7	194	52	54	22	78
8	185	48	58	21	60
9	200	51	52	15	65
10	197	53	57	25	85

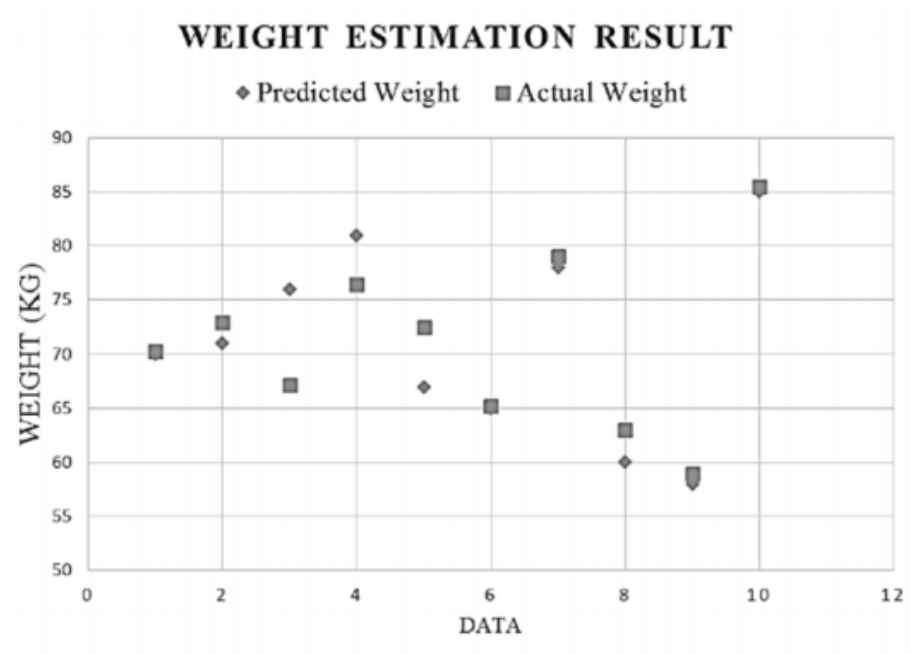

그림 9. 선형회귀분석 기반 몸무게 추정 논문에 사용된 데이터 및 추정 결과[22]

1.4. 연구의 필요성

딥러닝이 이미지 처리 분야에 있어 혁신적인 성과를 내고 있음에도 불구하고 현재까지 딥러닝을 사용하여 2차원 이미지만으로 사람의 체중을 추정하는 방법에 대한 연구는 존재하지 않는다.

딥러닝을 이용하여 인물의 2D 이미지에서 체중을 추정할 수 있게 된다면 체중계 없이 누워 있는 사람을 찍는 것 만으로 바로 체중을 추정할 수 있게 되어 응급 상황에서의 체중 추정에 큰 도움을 줄 뿐만이 아니라, 자료가 쌓일수록 정확도가 상승하는 딥러닝의 특성 상 그 정확도 역시 계속 상승하여 보다 높은 추정 수준에 이를 것으로 예상되는 바, 본 연구에서는 딥러닝을 통하여 사람의 키 및 체중을 추정하는 방법을 제시하고자 한다.

2. 방 법

2.1. 데이터 분석

2.1.1. 연구에 사용된 데이터 특징 분석

데이터는 기존 연구[10]에서 모은 소아별 사진으로, 서울대병원 본원 및 분당 서울대병원 소아과 병동을 2017년 3월부터 2018년 2월까지 주중 10:00부터 17:00까지 방문한 만 17세 이하의 환자를 대상으로 환자로부터 동의서를 받은 후 수집하였으며, 조산아, 선천성 기형, 만성 신장 부전, 악성 종양, 신경근육조직 환자 등의 키와 몸무게에 영향을 미치는 만성 질환 환자는 제외되었다. 몸무게와 키는 스스로 일어설 수 없는 영아 및 유아에게는 유아용 자동신장체중계 (DSB02, (주)동산제닉스, 대한민국)(그림 10)를 사용하여 측정하였고, 스스로 서 있을 수 있는 환자를 대상으로는 신장 자동측정기 (GL-310; (주)지테크인터내셔날, 대한민국)(그림 11)를 사용하여 측정하였다. 환자 및 환자의 보호자에게 동의서를 받고 난 후, 네 개의 마커가 있는 침대 위에 누워 있는 환자를 총 8방향으로 찍은 사진을 사용하였으며, 신장 및 체중 데이터는 Microsoft Office Excel 2013 spreadsheet에 저장하여 사용하였다.

본 연구는 헬싱키 선언을 준수하였으며, 서울대병원 본원 및 분당 서울대병원 연구윤리 심의 위원회의 승인을 받았다(institutional review board no. 1703-103-840, 1609-361-304 및 2006-189-1136).

그림 **10.** 유아용 자동신장체중계 **DSB02**,

http://cumedicals.cafe24.com/member/login.html?noMember=1&returnUrl=%2Forder%2Forderform.html%3Fbasket_type%3DA0000%26delvtype%3DA&delvtype=A

그림 **11.** 신장 자동측정기 **GL-310**,

http://itempage3.auction.co.kr/DetailView.aspx?itemno=B404882787

2.1.2. 연구에 사용된 컴퓨터의 성능 및 사용된 데이터

본 연구에 사용된 컴퓨터의 성능은 다음과 같다.

GPU: NVIDIA GeForce GTX 1060 3GB, CPU: AMD Ryzen 7 2700X, RAM: 16GB

선행 논문[10]의 연구 과정에서 수집된 사진의 개수는 선행 논문에서 사용된 총 480명의 환자에게서 나온 3840장보다 많은, 총 523명의 환자를 촬영하여 얻은 4364 장으로, 본 연구의 모델에 최대한 많은 정보를 학습시키기 위하여 수집된 전체 사진 데이터 중 정보가 누락되거나 손실, 장애물 등으로 환자를 인식할 수 없는 등의 부득이한 사유로 학습을 할 수 없는 환자 9명 및 총 사진 562장을 제외하고, 총 514명의 환자에게서 얻은 3802장의 사진(그림 12)을 연구에 사용하였다. 본 연구에 사용된 총 514명의 환자의 특성은 표 2에 나타내었다.

표 2. 환자의 나이 별 특성

특성	남성, n (%)	평균 측정 키(cm)	평균 측정 몸무게(kg)
전체 (n = 514)	255 (49.6)	128.7	34.5
0~3세 (n = 120)	60 (50)	85.3	12.1
4~6세 (n = 89)	44 (49.4)	112.1	19.6
7~9세 (n = 89)	44 (49.4)	131.2	30.3
10~12세 (n = 88)	43 (48.9)	150.2	46.2
13~15세 (n = 88)	45 (51.1)	164.1	60.2
16~17세 (n = 40)	19 (47.5)	165.2	62.4

그림 12. 입력 이미지 예시

2.1.3. 샘플의 크기 결정

학습의 지표가 되는 실제 키와 몸무게 데이터로는 선행 논문[10]의 연구 과정에서 얻은 엑셀 파일을 사용하였다.

먼저 엑셀 파일 속 키, 몸무게를 전처리된 이미지에 대응시켜 전체 데이터 세트를 만들고 이를 6:2:2의 비율로 무작위로 나누어 각각 학습 데이터 세트, 검증 데이터 세트, 시험 데이터 세트를 만들었다. 이 때, 동일한 환자에게서 생성된 다른 사진이 학습 세트와 시험 세트에 각각 들어가 실제 성능보다 더 높은 정확도를 보이는 것을 막기 위하여 6:2:2의 비율로 사진 데이터를 무작위로 나누는 대신, 환자군을 무작위로 6:2:2($\approx 302:100:112$)의 비율로 나누어 데이터 세트를 생성하였다. 학습 세트의 경우 총 환자 수: 302명, 총 사진 수 2243장, 평균 키: 128.5cm, 평균 체중: 34.4kg, 검증 세트의 경우 총 환자 수: 100명, 총 사진 수 740장, 평균 키: 129.3cm, 평균 체중: 34.2kg, 시험 세트의 경우 총 환자 수: 112명, 총 사진 수 819장, 평균 키: 128.8cm, 평균 체중: 35.1kg 이다.

각 데이터셋 별 키 및 몸무게의 분포 히스토그램은 그림 13과 같다.

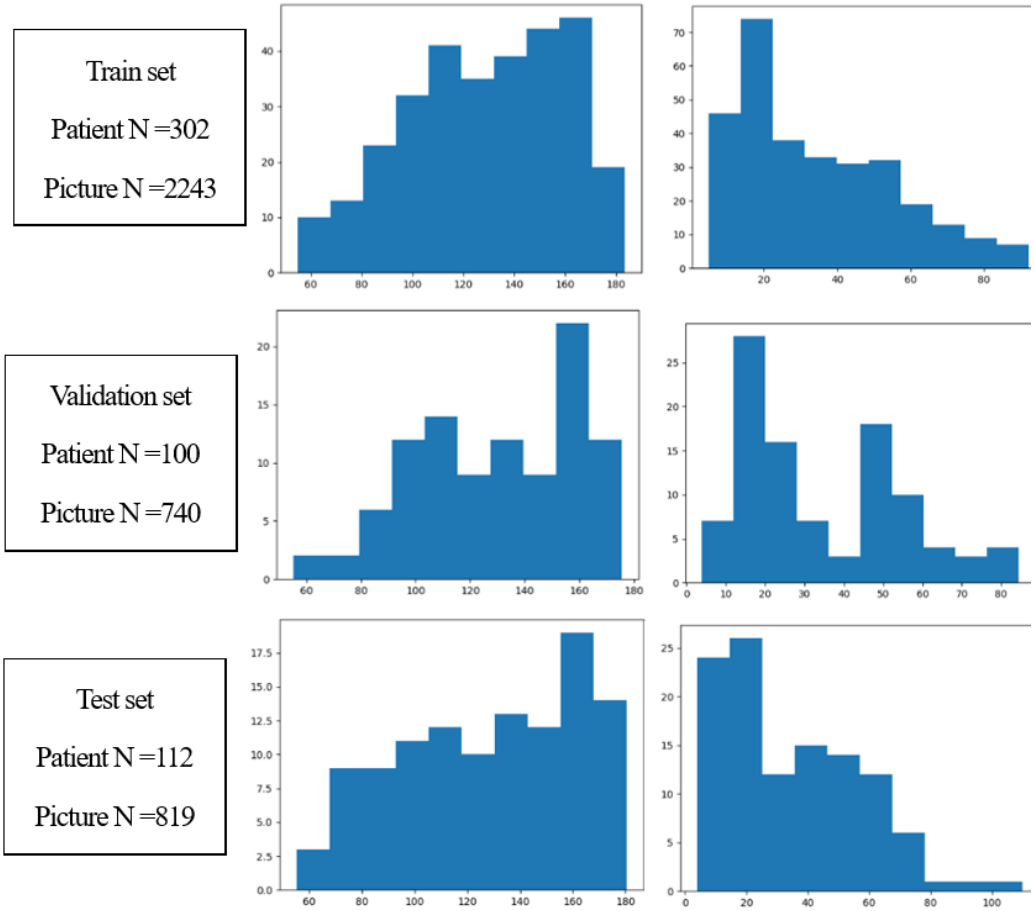

그림 13. 데이터 세트 별 히스토그램. 왼쪽: 키(cm), 오른쪽: 몸무게(kg)

2.2. 알고리즘 모식도

이 논문에서 사용하는 알고리즘은 크게 총 2개로 학습 알고리즘과 추정 알고리즘이 있다. 이를 각각 그림을 그려 간단히 표현하였다.(그림 14, 15)

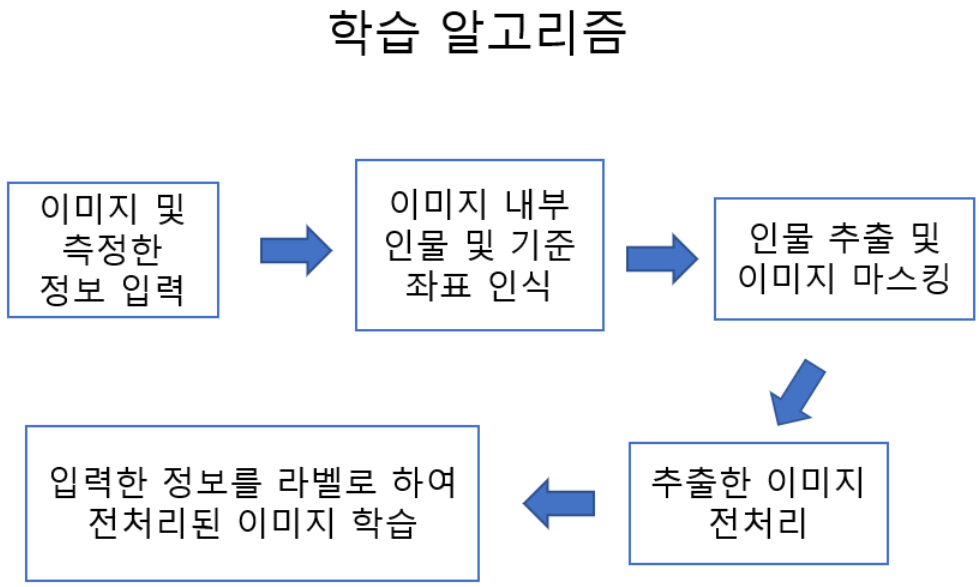

그림 14. 학습 알고리즘 모식도

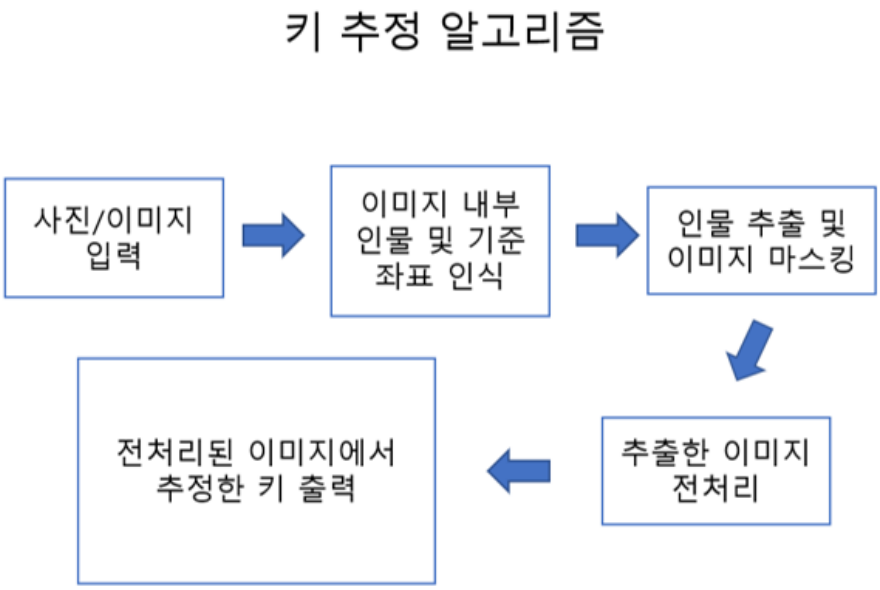

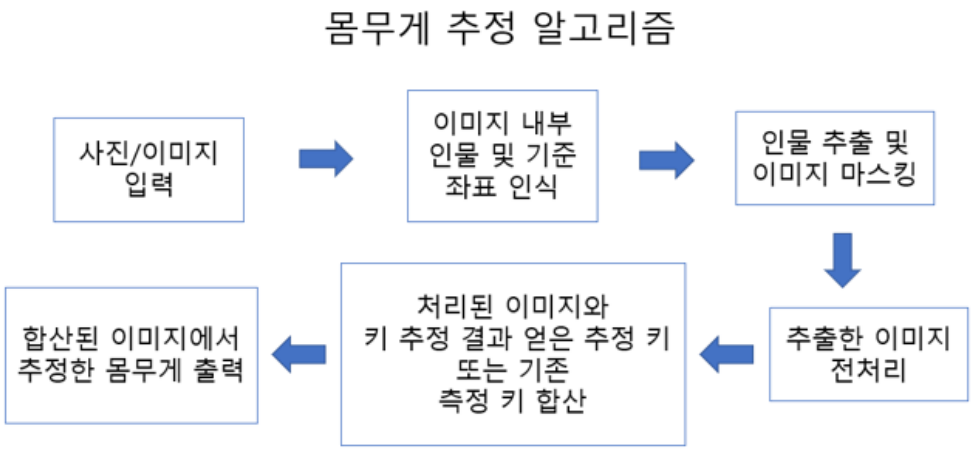

그림 15. 키 및 몸무게 추정 알고리즘 모식도

2.3. 데이터 전처리

2.3.1. 이미지 전처리

2.3.1.1. Mask R-CNN

딥러닝 시스템에 이미지를 학습시키기 전에, 학습이 보다 적절하게 이루어질 수 있도록 이미지를 전처리하는 과정을 거쳤다. 먼저, 실제 학습에 상관이 없거나 과적합을 불러일으킬 수 있는 침대 및 주변 환경, 인물의 생김새 및 의상 등을 학습에서 배제하고 체중과 키를 판별하는 주 목표인 체형만을 얻기 위해 사물 인식 및 마스킹 시스템인 Mask R-CNN으로 이미지를 처리 후(그림16) 이미지에서 환자의 마스크만을 추출하여 인물 부분을 흰색(255,255,255), 배경 부분을 검은색(0,0,0)으로 처리하여 흑백의 인물 마스크 이미지를 추출하였다.

인물로 인식하게 하는 최소 점수는 0.95 이상으로 설정하였으며, Mask R-CNN은 MS COCO set을 이용하여 이미 학습된 모델을 사용하였다.

또한, 사진의 절대 크기를 알려주는 지표인 네 원형 마크 역시 Mask R-CNN을 사용하여 네 점의 위치를 추출함으로써 선행 논문과는 달리[10] 기준 좌표를 자동으로 입력하게끔 설계할 수 있으나, 본 연구에서 사용된 이미지에서는 육안으로도 4개의 점을 모두 식별할 수 있는 이미지가 매우 적어, 부득이하게 본 연구 역시 기존 논문처럼 네 기준 좌표의 위치를 수동으로 추측하여 입력하였다.

`

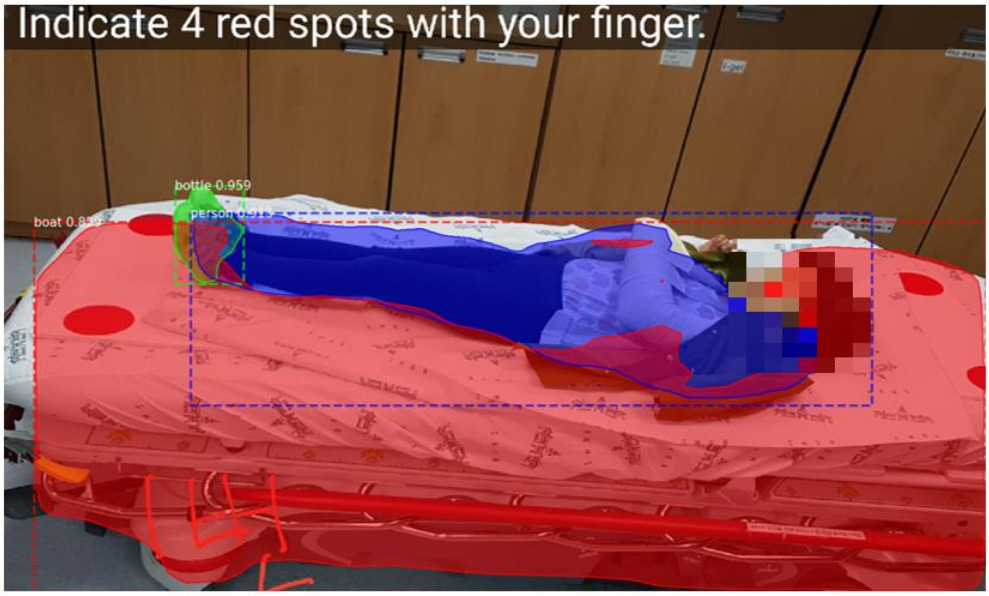

그림 16. Mask R-CNN을 사용한 실제 image segmentation 예시 색깔이 다른 마스크는 서로 다른 물체를 인식하였음을 나타낸다.

2.3.1.2. Homography

연구에 사용된 이미지는 사진을 찍은 위치 및 각도가 사진마다 다르기에 같은 인물의 이미지라도 서로 차이가 발생한다. 그렇기 때문에 각도 및 피사체와의 거리에 따른 실물 왜곡 차이를 해결하여 각 사진의 크기를 절대적으로 비교하기 위하여 원근 변환을 사용하였다.

$$\begin{pmatrix} x_1 \\ y_1 \\ z_1 \end{pmatrix} = \begin{pmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & 1 \end{pmatrix} \begin{pmatrix} X_1 \\ Y_1 \\ Z_1 \end{pmatrix}$$

$$\therefore \begin{pmatrix} x_1 \\ y_1 \\ 1 \end{pmatrix} = \begin{pmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & 1 \end{pmatrix} \begin{pmatrix} X_1 \\ Y_1 \\ 1 \end{pmatrix}$$

$$\therefore h_{11}X_1 + h_{12}Y_1 + h_{13} - x_1 = 0$$

$$h_{21}X_1 + h_{22}Y_1 + h_{23} - y_1 = 0$$

$$h_{31}X_1 + h_{32}Y_1 = 0$$

식1은 3차원 공간에서의 원근 변환을 나타낸다. 논문에서 사용되는 원근 변환의 경우에는 하나의 2차원 평면에서 다른 2차원 평면으로 상을 변환하므로 z 축은 고려되지 않아 Z=0이 된다. 이를 식1에 대입하여 정리하면 총 8개의 미지수가 존재하는 연립일차방정식이 된다. 따라서 원근 변환에 필요한 미지수의 값을 모두 알기 위해서는 변환되는 이미지가 위치한 평면과 이미지가 옮겨 갈 평면에서의 서로 대응하는 네 쌍의 좌표가 필요하다. 따라서 이 연구에서는 입력 좌표로는 사진 속 네 마커의 좌표를, 출력 좌표는 256*256 크기의 이미지 중앙에 위치하는 가로 38픽셀, 세로 150픽셀의 직사각형의 네 좌표를 출력 좌표로 하여 계산하였다. 출력 좌표의 경우, 이 논문에서는 크기 150*38.5cm의 직사각형 마크를 사용하였지만, 다른 크기의 직사각형 형태의 어떤 모습으로도 그 높이와 너비만 알고 있다면 변환이 가능하다. 이때 정보의 손실을 최소화하면서도 직관적인 이해가 가능하게끔 가로 및 세로 축적이 1픽셀 : 1cm이 되게끔 256*256 크기의 이미지로 변환하였다(그림 17).

그림 17. Homography 예시

2.3.1.3. 딥러닝을 위한 최종 이미지 규격화

보다 효과적인 딥러닝 연산을 위해, 앞서 처리한 256X256 크기의 이미지를 1/16크기인 64X64 크기의 이미지로 바꾸었고, 각 픽셀의 값을 딥러닝 학습에 맞게끔 규격화하기 위하여 각 픽셀의 값을 255로 나누어 모든 픽셀의 값을 0~1 사이의 값으로 바꾸었다.

그림 18은 입력된 사진을 전처리하는 과정에서 이미지가 변하는 전체 과정을 보여준다.

Original Image

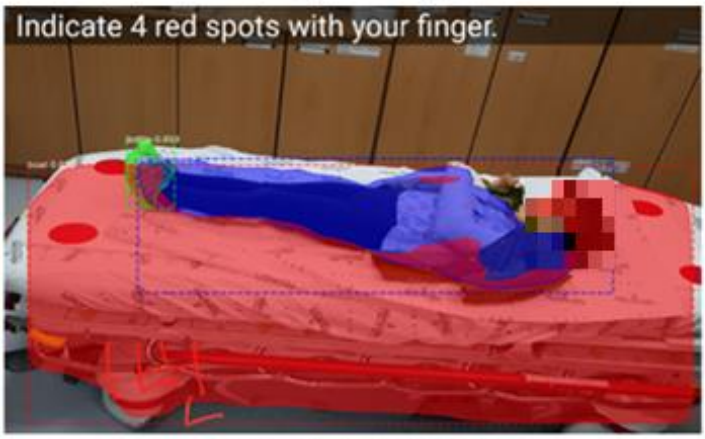

Object Detect & Mask

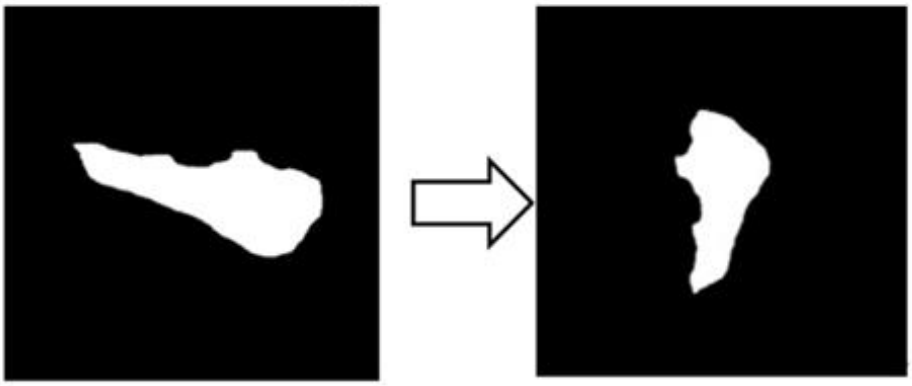

Extract human mask, Resize to (256, 256) **Homography, Resize to (64, 64)**

그림 **18.** 전체 이미지 사전 처리 과정

2.3.2. 체중 추정을 위한 키 정보 추가 대입

체중 추정에 있어서 그 정확도를 더욱 높이기 위하여 기존에 추정한 키의 값 또는 측정한 키의 값을 체중 추정 학습 과정에 추가로 넣어 학습에 도움을 주었다. 이를 위하여 최종 처리된 각 이미지에 (각 이미지에서 추정한 키÷최대 추정 키) 또는 (각 이미지 별 실제 측정한 키÷최대 측정 키)를 곱하여, 이미지의 각 픽셀이 환자의 키에 비례한 값을 가져 학습 및 추정에 사용할 수 있게 하였다.

2.4. 딥러닝 구조 생성 및 학습

2.4.1. 딥러닝 구조 생성

이 논문에서는 Resnet50, vgg16, densenet121 의 세 가지 딥러닝 모델을 기반으로 구조를 생성하였다. 본 연구의 일반적인 딥러닝의 주 연구 분야인 이미지 분류와는 달리 키와 몸무게라는 연속된 수치를 추정하는 회귀 문제를 해결하는 것이 목적이므로, 이에 맞게 연산을 처리하기 위하여 각 딥러닝 모델의 맨 마지막 Activation 층 대신, Flatten layer 및 Dense(1) layer(활성함수: linear) 를 연결하여 구성하였다. 이를 통해 학습된 모든 값을 혼합하여 1차원의 실수로 변환하여 같은 1차원의 연속된 실제 키와 몸무게와 값을 비교할 수 있어 본 연구에 적용이 가능하다.

변형한 모델의 구조 예시는 그림 19에 표현하였다.

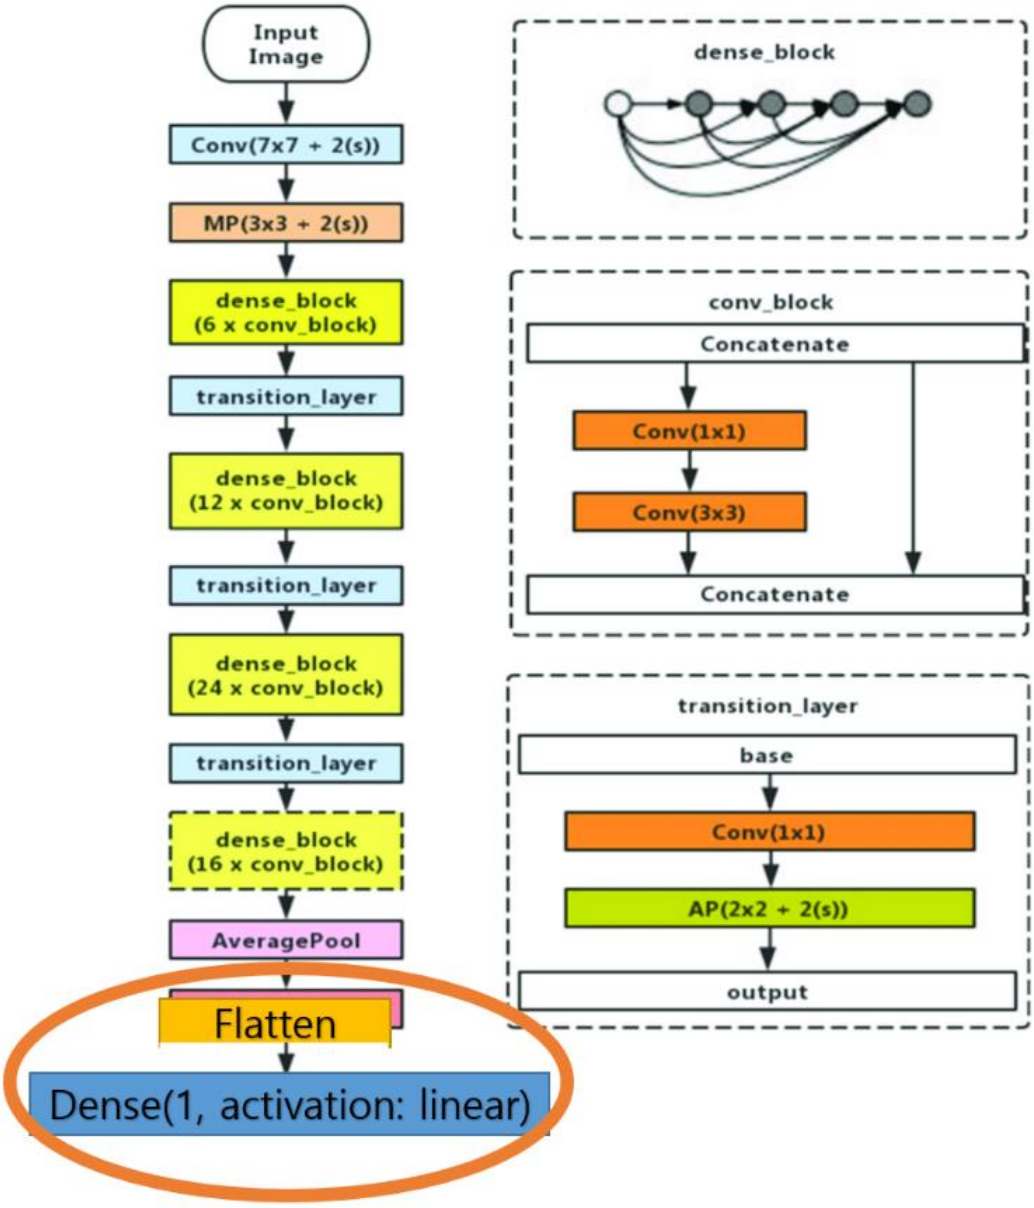

그림 19. 본 연구를 위해 변형된 딥러닝 모델 구조 예시 (DenseNet121)

2.4.2 학습 함수 지정

본 연구 데이터의 특성 상 마스킹의 오류 편차가 큰 입력값이 다수 존재한다. 그렇기에 학습에 사용되는 손실 함수로는 오류가 심한 입력값에도 학습이 잘 왜곡되지 않는 절대 백분율 편차 (MAPE) 함수를 사용하였으며, 옵티마이저 함수의 경우 Adam(학습률(lr) = 0.001, decay = 5e-6)을 사용하여 학습하였다.

2.4.3. 학습

ResNet50, VGG16, DenseNet121의 입력 이미지의 크기를 64*64*3으로 하였으며, 키 및 몸무게 정보를 출력 레이블로 하여 학습하였다. 각 모델 별로 50epoch 동안 학습하며 각 epoch마다 학습되는 가중치 중에서 가장 검증 데이터 세트에서의 성능이 좋은 가중치 데이터를 저장하였다.

2.5. 결과 데이터 분석 방법

2.5.1. 그래프 생성

이 논문에서 제시한 모든 그래프 자료는 Python을 사용하여 생성하였다.

2.5.2. 이미지 전처리 결과 분석

이미지 전처리 과정에서 실제 인물에 대비 얼마나 인물의 외곽이 잘 추출되었는지 여부는 본 알고리즘의 학습에 있어 중요하다. 따라서 이 논문에서는 이를 평가하기 위하여, 전처리된 256*256의 이미지 중 가장 위로 추출된 점의 y좌표와 가장 아래 점의 y좌표 사이의 차를 계산하여 이를 실제 키와 비교하여 분석하였다.

2.5.3. 딥러닝 결과 분석

학습된 연구 결과의 정확도를 검증하기 위하여 시험 세트를 사용하여 추정한 키, 몸무게와 실제 환자의 키 및 몸무게 정보를 비교하여 분석하였다.

선행 논문[10] 및 rolling tape를 사용한 연구에서는 추정한 체중의 정확도를 실제 체중의 10% 내외로 추정할 확률을 시스템의 정확도로 설정하였다(PW10) 따라서 이 논문에서도 학습 데이터를 기존 연구 결과와 비교하기 위하여 시험 세트에서 추정된 키와 몸무게 및 실제 키와 몸무게의 값을 바탕으로 PW10, PW20, MPE, MAPE를 계산하였다. 통계적 유의성은 P value<0.05로 정의하였다.

3. 결과 및 분석

3.1. 이미지 전처리 결과 분석

연구 과정에서 얻은 523명의 환자의 정보 및 사진 4364장 중에서 사진의 손실이나 인물의 정보 누락, 장애물의 존재로 인물 인식이 불가한 사유 등으로 사용할 수 없는 데이터를 제외하고 총 환자 514명에게서 나온 사진 3802장을 연구에 사용하였다.

먼저 인물 이미지 추출 및 Homography의 정확도를 분석하기 위하여, 축척이 1픽셀: 1cm인 이미지의 최상위 점 및 최하위 점의 y좌표 차를 실제 키와 비교하여 평가하였다(표 3).

이미지 전처리 왜곡 정도를 분석한 결과, 실제 키와 pixel 평균 약 14.81%, 절대평균 역시 18.05%의 오차율을 보였다. 이는 마스킹 과정에서 누워있는 대상의 머리카락, 옷 등을 포함하여 실제 인물의 실루엣보다 큰 영역을 마스킹하는 경우가 잦았고, 또한 사진 속 환자는 환자의 몸 두께로 인해 원근 변환 기준 평면인 침상 위로 솟아오른 형태이므로 Homography 과정에서 환자의 몸 두께가 왜곡을 일으켜 변환된 실루엣이 실제 실루엣보다 길어졌고, 환자의 신장 및 체형에 따라 실루엣의 왜곡 정도 역시 각기 다르게 나타났기 때문으로 추정된다.

표 3. 이미지 전처리 왜곡도

N = 3802	이미지 왜곡도
MPE, % (SD, %)	14.81 (15.55)
MAPE, % (SD, %)	18.05 (11.63)

3.2. 키 추정 결과 및 분석

ResNet50, VGG16, DenseNet121 모델 별로 키의 추정 정확도를 비교하였다. (표 4) 분석 결과, 정확도 PW10 및 PW20은 DenseNet121 > ResNet50 > VGG16 순으로 나왔으며 세 모델 모두 $\boldsymbol{R^2}$ > 0.80 이상의 높은 값을 보였다. 이로써 키를 추정함에 있어서는 DenseNet121이 가장 높은 정확도를 보임을 알 수 있다.

표 4. 모델 별 키 추정 비교

통계	**ResNet50**	**VGG16**	**DenseNet121**
	n = 112	n = 112	n = 112
MPE, % (SD)	0.86 (10.51)	-0.49 (10.41)	-1.09 (10.09)
MAPE, % (SD)	7.42 (7.49)	7.39 (7.35)	7.15 (7.20)
RMSPE, %	10.54	10.42	10.15
PW10, % (95% CI)	75.9 (72.2 to 79.6)	75.7 (72.0 to 79.4)	77.2 (73.5 to 80.8)
PW20, % (95% CI)	95.1 (93.2 to 97.0)	94.5 (92.5 to 96.5)	95.3 (93.5 to 97.1)
$\boldsymbol{R^2}$**, %**	84.1	82.3	83.1

3.3. 몸무게 추정 결과 및 분석

오롯이 몸무게 추정 모델 부분의 정확도만을 판단하기 위하여, 앞서 추정한 키를 입력하는 대신 실제 측정한 키를 이미지에 합산하였다.

학습된 모델의 몸무게 추정 정확도를 구하기 위하여, 시험 데이터 세트를 각 모델에 입력하고 결과를 확인 및 분석하였으며, 기존 Weighing Cam[10] 및 Broselow Tape 방법과 비교하기 위하여 ResNet50, VGG16, DenseNet121 모델 별로 예측 가능 정도를 구하여 비교하였다(표 5).

평가 결과, VGG16의 평균 절대 퍼센트 오차율이 가장 낮았고, 그 다음으로 DenseNet, ResNet 순을 보였다. 예측 정확도 역시 PW10의 경우 VGG16 모델은 56.2%, ResNet은 49.1%, DenseNet은 47.3%로 VGG16이 가장 정확도가 높았고, PW20은 VGG16 모델의 경우 85.2%, DenseNet은 83.3%, ResNet의 경우에는 79.6%의 정확도를 보여주어, 세 모델 중 VGG16모델이 이미지에서 체중을 가장 잘 추정해 냄을 알 수 있었다. R^2의 경우 세 모델 모두 R^2>0.85 이상의 매우 높은 값을 보였다.

선행 논문 및 Broselow Tape과의 정확도(PW20)를 비교하여 보면, 선행 논문[10]에 비해서는 약 12% 낮은 정확도를 보였지만, Broselow Tape과 비교해 보았을 때는 약 2.7%의 오차 범위 이내의 정확도 차이를 보임을 확인할 수 있었으며, 특히 Broselow Tape으로 추정 가능한 범위의 환자군 대상으로는 VGG16 기준 62.5%로, Broselow Tape보다 높은 정확도를 보였다.

다중 선형 회귀 분석 기법을 사용한 인체 실루엣 이미지에서의 체중 추정 방법의 값$R^2 = 0.80$ [22]과 비교해 보았을 때는 세 모델 모두 다중 선형 분석 방식 방법에 비해 확연히 높은 정확도를 보임을 확인할 수 있었다.

표 5. 모델 별 체중 추정 비교

통계	ResNet50	VGG16	DenseNet121	Weighing Cam[10]	Broselow tape[10]
	n = 112	n = 112	n = 112	n = 309	n = 309
MPE, % (SD)	--1.85 (30.30)	-0.13(15.35)	-5.07(14.99)	1.68(11.05)	3.66(12.27)
MAPE, % (SD)	13.14 (17.93)	11.32 (12.33)	12.32 (9.92)	5.38 (7.45)	7.14 (8.02)
RMSPE, %	18.01	15.34	15.81	11.16	12.79
PW10, % (95% CI)	49.1 (44.8 to 53.4)	56.2 (51.9 to 60.4)	47.3 (42.9 to 51.8)	68.0 (62.7 to 73.2)	58.9 (53.4 to 64.4)
PW10*, % (n = 69)	56.0	62.5	49.5	68.0	58.9
PW20, % (95% CI)	79.6 (76.1 to 83.1)	85.2 (82.1 to 88.3)	83.3 (80.0 to 86.5)	93.2 (90.4 to 96.0)	88.7 (85.1 to 92.2)
PW20*, % (n = 69)	85.2	89.3	85.4	93.2	88.7
R^2, %	85.5	90.0	87.4	-	-

*Broselow Tape 사용이 가능한 범위의 환자군(h < 145cm; n = 69)

4. 결론 및 고찰

4.1. 고찰

현재 기존 연구 중에는 2D 이미지를 딥러닝하여 사람의 체중을 추정하는 방법이 존재하지 않는다. 딥러닝이 아닌 머신러닝을 사용하여 2D이미지만으로 체중을 추정하는 방법에 대한 논문 역시 하나뿐이며[22] 그 결과 또한 낮은 정확도를 보였다.

본 논문에서는 2D 이미지에서 소아의 실루엣을 자동으로 인식한 후 딥러닝하여 소아의 체중을 추정하는 알고리즘을 최초로 시도하였다. 특히 본 논문에서 제시한 방법의 정확도는 기존 다중회귀분석방식을 사용해 체중을 추정한 논문에 비해 큰 정확도를 보였을 뿐만 아니라, 현재 임상에서 가장 많이 사용되는 Broselow Tape의 정확도와 비교해 보아도 3% 오차 범위 이내로 거의 근접한 정확도를 보였기에, 본 알고리즘이 임상적으로 충분히 정확한 값을 추정할 수 있음을 보였다.

다만 본 연구에서 사용된 자료에서는 절대 좌표의 기준이 되는 네 붉은 동그라미 마크 중 일부가 이불, 환자 등에 의해 가려져 네 개의 마크를 모두 찾을 수 없는 이미지가 대부분이라, 부득이하게 직접 절대 좌표를 입력함으로써 완전 자동화는 이루지 못하였다. 그러나 이는 단순히 새로운 이미지를 생성하는 경우에 네 기준 점이 모두 사진에 확연히 나오게끔 찍음으로써 직접 좌표를 입력할 필요 없이 사진 속 환자의 키 및 몸무게를 빠르게 추정해 낼 수 있을 것이다.

본 논문은 또한 기존 추정 방식을 넘어서는 높은 정확도를 보이지는 못하였다는 한계가 존재한다. 하지만 학습에 사용된 이미지의 개수가 2243장으로 일반적 딥러닝 학습에 비하여 극히 적으며 이미지 전처리 과정에서의 실루엣 왜곡도 역시 상당히 높았음에도 불구하고 기존 몸무게 추정 방식과 필적하는 정확도를 보였다. 따라서 추후 보다 많은 데이터 수집 및 보다 정확한 전처리가 이루어진

다면 충분히 기존 방식보다 높은 정확도를 기대할 수 있을 것으로 보인다.

4.2. 결론

본 논문은 이미지 딥러닝을 기반으로 환자의 사진에서 대상의 몸무게를 추정하는 알고리즘을 최초로 제시 및 시도한 것에 의의가 있다. 또한 본 논문에서 구현한 알고리즘의 성능 역시 기존 소아 대상 체중 추정 방식과 유사한 정도의 추정 성능을 보임을 확인하였다.

비록 본 방법은 기존의 추정 방법을 넘어서는 결과를 얻지는 못하였으나 기존 방법에 비해 반자동화 및 비접촉식으로 키 및 몸무게를 추정할 수 있다는 장점이 있으며, 딥러닝 과정에 있어서도 일반적인 딥러닝 학습 과정에서는 30~40만 장 이상의 데이터를 바탕으로 학습을 하는 반면 이 논문에서는 총 3802장의 이미지, 특히 실제 학습에 사용된 이미지는 단 2243장으로 극히 적음에도 기존 추정 방식과 유사한 추정 결과를 보였다.

또한 본 논문의 학습 과정에서 수집하는 데이터는 수집하기 어려운 일반적인 의료 영상과는 달리 복잡한 과정 없이 크기를 알고 있는 직사각형 위에 눕거나 앞에 서서 사진을 찍는 것만으로 가정에서도 쉽게 생성할 수 있어, 본 알고리즘이 보편화되어 많은 사람들이 이용하게 된다면 본 논문의 알고리즘이 보다 많은 데이터를 수집 및 학습함으로써 더욱 높은 체중 추정 정확도를 보일 수 있을 것이다.

참고 문헌

[1] Luten R. “Managing the unique size-related issues of pediatric resuscitation: reducing cognitive load with resuscitation aids.” *Acad Emerg Med*. 2002;9:840–847.

[2] Rosenberg M, Greenberger S, Rawal A, Latimer-Pierson J, Thundiyil J. “Comparison of Broselow tape measurements versus physician estimations of pediatric weights.” *Am J Emerg Med* 2011;29:482–8.

[3] Krieser D, Nguyen K, Kerr D, Jolley D, Clooney M, Kelly AM. “Parental weight estimation of their child's weight is more accurate than other weight estimation methods for determining children's weight in an emergency department?” *Emerg Med J* 2007;24:756–9.

[4] Leffler S, Hayes M. “Analysis of parental estimates of children's weights in the ED.” *Ann Emerg Med* 1997;30:167–70.

[5] Park J, Kwak YH, “A new age-based formula for estimating weight of Korean children. Resuscitation.” *Epub* 2012;83:1129–1134.

[6] Luscombe MD, Owens BD, Burke D. “Weight estimation in paediatrics: a comparison of the APLS formula and the formula ‘Weight ¼ 3(age)þ7’.” *Emerg Med J*. 2011;28:590–593

[7] Oakley PA. “Inaccuracy and delay in decision making in pediatric resuscitation, and a proposed reference chart to reduce error.” *BMJ* 1988;297:817–9.

[8] Jang HY, Shin SD, Kwak YH. “Can the Broselow tape be used to estimate weight and endotracheal tube size in Korean children?” *Acad Emerg Med* 2007;14:489–91.

[9] Garcia CM, Meltzer JA, Chan KN, Cunningham SJ. “A validation study of the PAWPER (pediatric advanced weight prediction in the emergency room) tape: a new weight estimation tool.” *J Pediatr* 2015;167:173–7.

[10] Joong Wan Park, Hyuksool Kwon, Jae Yun Jung, Yoo Jin Choi, Ji Soo Lee, Woo Sang Cho, Jung Chan Lee et al. ""Weighing Cam": A New Mobile Application for Weight Estimation in Pediatric Resuscitation." *Prehospital Emergency Care*, vol. 24, pp. 441-450, 2020

[11] Hoo-Chang Shin, Holger R. Roth, Mingchen Gao, Le Lu, Ziyue Xu, Isabella Nogues,, Jianhua Yao et al. "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning." *IEEE Transactions on Medical Imaging*, vol.35, pp. 1285-1298, Feb 2016

[12] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. "Deep Residual Learning for Image Recognition" *The IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016

[13] SIMONYAN, Karen, ZISSERMAN, Andrew. "Very deep convolutional networks for large-scale image recognition." *arXiv preprint arXiv*:1409.1556, 2014

[14] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. "Densely connected convolutional networks." *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 4700-4708, 2017

[15] Girshick, R. "Fast r-cnn." *Proceedings of the IEEE international conference on computer vision.* pp. 1440-1448, 2015

[16] Ren, S., He, K., Girshick, R., & Sun, J. "Faster r-cnn: Towards real-time object detection with region proposal networks." *Advances in neural information processing systems*. pp. 91-99, 2015

[17] He, K., Gkioxari, G., Dollár, P., & Girshick, R. "Mask r-cnn*." Proceedings of the IEEE international conference on computer vision*. pp. 2961-2969, 2017.

[18] Dey, R., Nangia, M., Ross, K. W., & Liu, Y. "Estimating heights from photo collections: A data-driven approach." *Proceedings of the second ACM conference on*

Online social networks. pp. 227-238, Oct 2014

[19] VESTER, Johan. "Estimating the Height of an Unknown Object in a 2D Image." *KTH CSIC*, 2012.

[20] Kainz, O., Jakab, F., Horečný, M. W., & Cymbalák, D. "Estimating the object size from static 2D image." *2015 International Conference and Workshop on Computing and Communication (IEMCON)* pp. 1-5. IEEE. 2015

[21] "Measuring size of objects in an image with OpenCV." Pyimagesearch. Last modified March 28, 2016, accessed June 25, 2020, https://www.pyimagesearch.com/2016/03/28/measuring-size-of-objects-in-an-image-with-opencv/

[22] FITRIYAH, Hurriyatul; SETYAW, Gembong Edhi. "Automatic Estimation of Human Weight From Body Silhouette Using Multiple Linear Regression." *Proceeding of the Electrical Engineering Computer Science and Informatics*, 5.1: 749-752, 2018.

Abstract

Deep learning based pediatric weight estimation algorithm from 2D Image

Jun Ho, Jang
Interdisciplinary Program of Bioengineering
The Graduate School
Seoul National University

The aim of this research is to develop an image deep learning based pediatric weight estimation algorithm, which is automatic and has a competitive accuracy with previous weight estimation methods for the emergency situations when the weight measuring instruments(weight scale) are not available.

For developing the algorithm, this research used total 3802 pictures from 514 pediatric patients who agreed to use their information for the research purpose and their real height and weight information. All the pictures are photographed from each patient who lied on a bed which has four reference points.

This algorithm consists of patient's image preprocessing part, training model part, estimation of height part for weight estimation and weight estimation part..

For data preprocessing part, Mask R-CNN model is used to automatically recognize and extract the patient's monochrome silhouette only from each picture. After extraction of the silhouette, each picture gets a perspective correction with homography transformation.

For training and testing model part, we used three deep learning models- ResNet50, VGG16 and DenseNet121. The last layer of every model is modified to solve regression problems for the estimation of height or weight. All thee preprocessed pictures are labeled with each patient's height or weight information to train models. For the weight estimation model, the preprocessed pictures are also merged with each patients' height information to give more information to the model. The patient group is divided into train set, validation set and test set with 6:2:2 ratio.

Each model is trained during 50 epochs. And each model is saved as trained model when the model gets highest validation accuracy.

From the result of trained model comparison, ResNet50 model shows the highest accuracy on height estimation and VGG16 shows the highest accuracy on weight estimation.

VGG16 also shows a competitive weight estimation accuracy with the previous clinical weight estimation method(Broselow tape).

For the first time, this paper suggested the way of estimation body weight from a picture of a human with image deep learning. It showed clinically capable accuracy despite of the small size of the training set.

Though the algorithm's weight estimation accuracy does not exceed the accuracy of existing clinical weight estimation methods in this paper, this algorithm has a potential as a new weight estimation methods because the accuracy of this algorithm will keep rising with the continuous collection of user data due to the characteristic of deep learning.

Keywords : Deep learning, Estimation, Weight, Height, Pediatric

Student Number : 2015-21219