

인체 치수 측정기술



한현숙

- 1999. 서울대학교 의류학 학사
- 2001. 서울대학교 의류학 석사
- 2007. 서울대학교 의류학 박사
- 2007-2018. 건국대학교 i-Fashion 박사후연구원
- 2018-현재. 충북대학교 부교수

1. 서 론

인체 측정학(anthropometry)은 인체의 크기, 형태 및 기타 특성을 측정하는 학문이다[1]. Anthropometry라는 용어는 인간을 뜻하는 그리스어 anthropo와 측정을 뜻하는 metry에서 유래했다. 인체 측정은 좁은 의미에서는 신체 외부의 모양을 수치적으로 설명하는 것을 의미하며, 넓은 의미로는 신체 측정 데이터를 수집, 분석하고 문서화하는 전체 과정을 포함한다. 신체 측정은 다양한 국가, 민족, 문화, 연령대의 인구의 신체치수적 변화를 정량화하여 비교하는 데 필수적이다. 또한 의료진단, 의류피팅, 피트니스, 가상현실 및 엔터테인먼트 등 많은 산업에 큰 영향을 미친다.

인체 측정 기술은 직접측정(수동측정)에서 시작하여 2차원 이미지나 3D 스캔 데이터를 활용하는 자동화된 방식으로 발전해왔으며, 최근에는 딥러닝 기술을 통해 정확도와 효율성이 크게 향상되었다. 직접측정(수동 측정 manual)은 캘리퍼스나 줄자 같은 전통적인 도구를 사용하여 측정하는 것이다[2]. 자동측정은 2차원 사진이나 3차원 인체 스캔에서 얻는 데이터에서 컴퓨터 프로그램을 통해 측정점과 치수를 자동 측정하는 것이다. 본고에서는 2차원 사진이나 3차원 인체 스캔 데이터를 이용한 자동 인체 치수 측정기술의 연구동향과 향후 기술 개발 방향에 대해서 살펴보고자 한다.

2. 인체 측정 관련 표준

인체 치수는 서로 다른 측정자가 측정했다라도 비교가 가능해야 하고, 같은 치수를 여러번 측정해도 동일하게 측정되어야(반복성) 한다. 이를 위해, 인체 치수 측정방법(측정 자세, 측정점 설정법, 측정경로 등)을 표준화하여 정의하고 있다. 측정이 일관되고 정확하게 이루어지게 하기 위해서는, 각 측정점은 정확하고 반복적으로 찾을 수 있도록 명확하게 정의되어야 한다. 인체 측정에 대한 표준은 국제표준화기구(ISO)의 ISO 7250-1[3], ISO 8559[4]와 같은 문서에 정의되어 있다.

이후에 소개할 다양한 2차원, 3차원 디지털 측정기술들의 정확성을 판단하기 위해서는 참값을 지정할 필요가 있는데, 일반적으로 직접 측정값을 참값으로 지정하는 경우가 많다. ISO 20685-1[5]는 3D 스캐닝 측정을 전통적인 직

접측정과 호환하고 비교할 수 있도록 하기 위해, 3D 스캔 인체 치수와 직접측정 인체 치수를 비교하고 평가하는 절차를 설명하고 있다. 이 문서에서는 오차에 대한 허용 수준을 제시하고 있는데, 키, 작은 둘레, 몸통 폭 측정의 경우 ± 4 mm, 세그먼트 길이와 몸통 깊이 측정의 경우 ± 5 mm, 큰 둘레 측정의 경우 ± 9 mm, 발과 머리 측정(머리카락 포함)은 ± 2 mm, 손과 머리 측정(머리카락 제외)은 ± 1 mm의 오차가 허용되는 것으로 규정하고 있다.

3. 직접측정

직접측정은 가장 오랫동안 행해져 온 인체측정 방법이고 신뢰성이 있다고 여겨진다. 하지만 여전히 몇 가지 한계가 있다. 직접측정의 첫 번째 단점은 반복측정시 늘 같은 값을 유지하기 어렵다는 것이다. 한 피험자에 대해 여러 인체 측정자가 조금씩 다른 측정값을 얻을 뿐만 아니라 한 명의 측정자가 한 피험자를 여러 번 측정할 때에도 조금씩 다른 측정값을 얻는다. 따라서 ANSUR 연구에서는 각 측정에 대해 허용 오차(allowable error)를 결정할 것을 제안했다[6]. 허용 오차는 측정자가 신뢰할 수 있는 측정으로 분류하기 위해 허용할 수 있는 '실측치'와의 최대 편차를 나타낸다. 두 번째 단점은 시간이 많이 걸린다는 것이다. 측정자가 한 명의 피험자를 측정하는 데 약 50분이 소요되며, 따라서 많은 인원 에 대한 통계를 수집하기에는 시간이 많이 걸린다. 또한 직접측정에는 고도로 숙련된 인력이 필요하다. 2022년 제 8차 사이스코리아 직접측정에서는 기준점 표시 및 측정자 1인, 치수측정자 3인, 치수측정보조자 3인으로 인력구성을 하기도 하였다[7].

4. 2차원 이미지 기반 측정

4.1. 2차원 이미지 기반 측정의 절차

2차원 이미지 기반 인체 측정법은 세 단계로 나뉜다. 첫째 RGB 또는 그레이스케일 카메라에서 얻은 2차원 이미지에서 인체의 실루엣을 추출하고, 둘째 실루엣에서 기울기 기반의 랜드마크를 추출하며, 마지막으로, 랜드마크 간의 위치 관계를 통해 인체 치수를 측정한다. 두번째 단계에서는 2차원 실루엣에서 바로 치수를 측정하기도 하며, 아니면 실루엣을 기반으로 3차원 인체형상을 만들어서 측정하기도 한다.

4.2. 2차원 이미지 기반 측정방법의 종류

RGB 이미지에서 신체 치수를 추정하는 방법에는 직접 방법,

PCA 기반 방법, 학습 기반 방법, 템플릿 기반 방법 등 여러 가지가 있다.

직접 방법[8-10]은 먼저 캐니 에지 검출기[11]를 사용하여 피사체의 정면 및 측면 이미지에서 인체의 실루엣을 찾고, 이로부터 실루엣의 두 픽셀간의 방향 차이를 관찰하여 특징점을 추출한다[9-10]. 예를 들어 첫 번째 특징점은 머리에서 시작하고 90도나 45도 방향 변화가 발생한 가장자리 픽셀을 특징점으로 간주한다. 이렇게 추출된 특징점으로부터 거리를 구하여 측정값을 근사화할 수 있다. 2D측정에서 너비와 깊이는 기준점 사이의 거리로 추정할 수 있으며, 둘레는 단면의 너비와 깊이를 타원의 장축과 차축으로 사용하여 근사화하여 구할 수 있다.

PCA(주성분분석) 기반 방법은 주로 2차원 인체사진에서 3차원 인체를 생성하는 것을 목적으로 하는 연구에 사용되며 이 과정에서 2차원 인체 사진에서 특징점 인식이 이루어지지만 치수 측정까지는 진행하지는 않는다. Xi 등은 3D 인체 모델을 2D 이미지로 렌더링하여 딥 CNN에 적용해 랜드마크를 위치시켰다[12]. 이 연구에서는 2차원 인체 사진에서 특징점을 인식하기 위해 먼저 Sobel 연산자를 사용하여 실루엣(윤곽)을 검출하고 이 실루엣에서 주요 마커를 탐지했다(kd-트리 구조를 사용하여 기준 인체 실루엣상에 매핑된 마커의 가장 가까운 이웃을 2D 랜드마크로 찾아냄). 그 다음으로 2차원 실루엣을 6개의 인체부위로 자동 분할하고, 각 분할영역에 대한 PCA공간을 구축하였다. 그 다음 2차원 실루엣의 PCA 공간과 3D 데이터의 PCA 공간 사이의 선형 매핑을 계산하였다. 이 연구 외에도 실루엣 데이터의 PCA 공간에서 3D 데이터의 PCA 공간으로의 매핑을 계산하는데에 가우스 프로세스 잠재 변수 모델(shared gaussian process latent variable model, SGPLVM))을 사용하는 연구도 있다[13].

학습 기반 방법은 정면 이미지 또는 실루엣을 사용하여 인체 치수를 추정하는 네트워크를 학습하며, 이 방법은 현재 이미지 기반 방법 중 가장 높은 성능을 보이고 있다. Wang 등의 연구에서는 랜드마크 추출을 회귀 문제로 가정하고, 인체 윤곽선의 기울기 대신 딥컨볼루션 신경망(deep convolutional neural network, deep CNN)인 101층 ResNet을 사용하여 인체의 공간 구조 정보를 추출하고 랜드마크의 위치를 학습한다[14]. 또한 이 연구에서는 둘레치수 측정을 위해서 두께-너비 비율 정보를 통합한 다중 타원 모델을 통해 측정의 정확도를 향상시켰다. 다음으로 Ruiz 등은 기존 3D 인체 재구성 방법들이 카메라 정보나 스케일을 통합하지 않아 측정 정확도를 보장하기 어렵다는 점과, 실제 사람의 이미지-측정치 쌍 데이터셋이 부족하다는 문제를 해결하고자 하였다[15]. 이 연구에서는 BMnet(Body Measurement

Network)라는 심층 CNN을 훈련시켜서 사람의 정면과 측면 실루엣과 신장과 체중 정보를 사용하여 14가지의 인체 치수를 예측한다. 특히 치수 예측의 성능 향상을 위해 BMnet에서 치수 예측을 잘 하지 못하는 인체형상을 SMPL 모델의 잠재적 공간에서 찾아서 생성하는 적대적 인체 시뮬레이터(adversarial body simulator, ABS)[16]를 제안한다. ABS가 생성한 인체형상은 주로 높은 BMI를 가졌으며, 이 샘플들로 BMnet을 파인튜닝 했을 때 치수 예측 정확도가 향상되었다고 보고하고 있다. 그리고 이 연구에서는 BMnet을 훈련하고 평가하기 위해 BodyM이라는 새로운 데이터셋을 소개하고 있는데, 이 데이터셋은 총 2,505명의 전신 실루엣 이미지(정면 및 측면 자세)와 함께, 신장, 체중, 그리고 3D 스캔으로부터 추출된 14개의 인체 치수를 포함한다.

마지막으로, 템플릿 기반 방법은 3차원 인체 템플릿(소스)을 개별 2차원 인체 사진(타겟)에 맞추어(fitting, registration) 인체 치수를 추정한다. 3차원 인체 템플릿에는 SMPL[17] 또는 SCAPE[18]과 같은 통계적 인체 모델이나 다른 스캔데이터가 사용된다. 학습 기반 방법처럼 인체 치수를 직접 학습하는 대신, 통계 모델을 사용하면 인체에 대한 사전 지식을 활용할 수 있다. 따라서 다양한 체형 및 자세 정규화(regularization) 기법을 사용하여 학습과정을 보다 원활하게 만들 수 있다. 이러한 정규화 기법에는 2D 관절[19], 3D 관절[20], 체형 사전 정보(shape priors)[21], 자세 사전정보(pose priors)[21,22], 표면 노멀 정보[20], 분할 마스크(segmentation masks)[23], 장면 사전 정보(scene priors)[24], 인체 치수 정보[19] 등이 포함된다. Bogo 등의 연구는 SMPLify라는 방법을 제안하며 2D 관절 정보만을 사용하여 3D 모델을 피팅하는 기본적인 틀을 제시하였고, 3D에서의 비현실적인 자세를 막는 상호 침투 제어에 중점을 두었다[21]. Ma, X 등은 기존 스켈레톤 기반 방법론의 한계(형상정보 손실)를 극복하기 위해 대규모 모션 캡처(mocap) 데이터에 기반하여 64개의 랜드마크 키포인트를 가상 마커(virtual markers)로 학습하여 3D 형상 추정의 정확도를 획기적으로 향상시켰다[20]. 이처럼 2차원 이미지와 3차원 인체 템플릿 모델을 통한 연구는 3차원 인체 모델을 추정하는데 주로 초점이 맞추어져 있다. 그 중에서 인체 치수에 초점을 맞춘 연구는 Choutas 등의 SHAPY 연구 정도이다(Figure 1,2)[19]. 이 연구에서는 Human Bodies in the Wild(HBW) 데이터셋이라는 새로운 야외 촬영 기반 인체 데이터셋을 소개하며, 다양한 자세와 의상을 입은 피사체의 실제 인체 치수를 포함하고 있다. 이 데이터셋은 어떤 상황에서도 인체 치수를 추출할 수 있는 2D 이미지 기반 인체 측정의 최종 평가기준 역할을 한다. 또한 학습 과정

에 언어적 체형 속성(“작은(small)”, “큰(big)”, “키가 큰(tall)”, “마른(skinny)” 등)과 인체 치수를 정규화 요소로 도입함으로써 우수한 체형 추정 성능을 달성한다. 하지만 이 방법도 평균 절대 오차는 8.44 cm로써 정확도가 다소 부족하다.



Figure 1. 2D 이미지에서 3차원 인체 형상 생성 성공 사례 - 남성 신체에 대한 SHAPY 예측 결과[19].



Figure 2. 2D 이미지에서 3차원 인체 형상 생성 실패 사례. 왼쪽은 체중이 과소 평가됨, 오른쪽 근육질 체형이 표현 안됨[19].

4.3. 2차원 이미지 기반 측정의 장단점

이 방법의 분명한 장점은 실용성에 있다. 한 장 또는 여러 장의 이미지로 인체 치수를 측정할 수 있는 다양한 모바일 애플리케이션들이 개발되었다(“MeThreeSixty”[25], “Verifyt”[26], “SizeYou”[27]). 대부분의 방법은 템플릿 기반 접근 방식을 채택하여, 주어진 이미지에 통계적 인체 모델을 피팅한 후 해당 모델로부터 치수를 추출한다.

하지만 2D 디지털 인체 측정은 3차원 공간에 존재하는 인체를 2D 이미지에서 인체 치수를 추출하는 과정에서 정보 손실이 불가피하다. 3D 세계에서 크기에 대한 고정된 기준(reference)이 없이 2D 이미지만으로는 절대적인 크기(스케일)를 알 수 없다. 따라서 이 문제를 완화하기 위해서 피측정자의 키[14]나 체중[15]을 기준으로 사용하거나, 카메라와 피사체 사이의 고정된 거리를 설정하는 방식 또는 이미지를 촬영할 때 보정용 보드(calibration board)를 사용한다[10]. 그러나 이러한 방법들은 피사체가 자신의 키와 체중을 제공해야 하거나, 카메라로부터 특정 위치에 정확히 서야 한다는 제약이 수반한다.

이러한 제약에도 불구하고, 2D 디지털 인체 측정은 실용적이고 간단하다는 이유로 인해 여전히 활발히 연구되고 있다.

5. 3D 스캔 기반 측정

3D 스캔 기반 측정은 3차원 인체 스캔 데이터로부터 치수를 측정하는 것이다. 현재 상용화된 3차원 스캔 기반 인체 측정 장치 중 가장 잘 알려진 것으로는 Vitronic사의 VITUSbodyscan 스캐너와 Anthroscan 인체 치수 측정 SW[63]이다. 본 고에서는 3D 스캔기반 측정을 측정점 인식과 치수 측정 두 가지로 나누어 살펴보고자 한다.

5.1. 측정점 인식

인체 측정점은 측정값을 찾는 데 필요하기 때문에 직접 및 디지털 인체 측정 모두에서 매우 중요하다. 측정점은 일반적으로 뼈 돌출부에 위치하는데 디지털 인체 측정에서는 인체의 뼈를 만져볼 수 없기 때문에 이를 찾기 위해 수년 동안 다양한 방법이 제안되어 왔다. 이러한 접근 방식은 2D 방법, 템플릿 방법, 설명자 방법, 슬라이싱 방법, 그래프 방법 등 여러 그룹으로 분류할 수 있으며 학습 방법은 이 분류들마다 모두 적용되고 있다.

2D 방법은 2D 이미지 기반 영역에서 이미 개발된 다양한 도구를 활용하기 위해 피험자의 3D 스캔을 2D 평면에 다시 투영한다. Baronetto 등은 측정점의 위치를 찾기 위해 합성곱 신경망(CNN)을 학습시키는 반면[28-29], Han은 실루엣 분석(silhouette analysis)이나 색상 임계값(color thresholding)과 같은 다양한(휴리스틱한) 도구들을 사용하여 측정점을 식별한다[30].

템플릿 기반 방법들은 앞서 2차원 이미지를 이용한 인체 측정에서도 언급이 되었는데, 그 방법에서는 3차원 템플릿을 2차원 인체 이미지에 피팅시키는 것이었다면, 3차원 방법에서는 3차원 템플릿을 3차원 개별 인체 스캔 데이터에 피팅시키는 것이라고 할 수 있다. 결국 두 방법 모두 3차원 템플릿을 피팅시키는 것은 같지만 타겟이 2차원인지 3차원인지가 다른 것이다. 인체 템플릿에는 여러 종류가 있으며 그 중에, 정점 기반 모델인 skinned multi person linear model (SMPL)[17]이 입력 모델과 등록된 메시 간의 평균 절대 정점 오차 측면에서 가장 정확한 모델이라고 알려져 있다[34]. SMPL 인체 모델은 (β, θ, τ) 라는 삼중항으로 표현되며, 다른 모델에 비해 구성 요소 수가 적어 간결하게 인체를 표현한다. 여기서 β 는 주성분(PC) 형태의 인체 형상을, θ 는 인체 자세를, τ 는 인체의 위치를 나타낸다. 3차원 템플릿 기반 방법에서는 개별 인체 스캔에 인체 템플릿을 맞추고(피팅시키고) 랜드마크를 전이시키거나[31], 템플릿 랜드마크와 스캔 포인트 간의 대응 관계를 특징 공간(feature space)에서 찾아 랜드마크를 검출한다[32]. 이 방법에서 처음에는 템플릿을

개별 인체 스캔에 대응시키기 위해서 수동으로 대응되는 점들을 선택해주는 번거로움이 있었다. 이를 해결하기 위해 Groueix 등은 입력 포인트 클라우드를 기반으로 템플릿을 변형시키는 딥러닝 방식인 3D 딥 디포메이션 기반 대응(3D-CODED)을 이용하였다[33]. 이 네트워크의 인코더와 디코더는 각각 PointNet과 다층 퍼셉트론(MLP)으로 구성되는데, 인코더에서는 입력 3D 포인트 클라우드를 받아 전역특징 표현을 생성하고, 디코더에서는 인코더에서 생성된 특징을 이용하여 템플릿을 입력 형상에 맞게 변형한다. 이때 재구성 품질을 향상시키기 위해 chamfer거리를 최소화하는 방향으로 전역특징을 최적화하는 추가적인 회귀단계를 수행한다. Kaashki 등은 단일 3D 스캔에서 자동 인체 치수 추출을 위한 최초의 딥러닝 기반 접근 방식(AM-DL: anthropometric measurements extraction based on deep-learning)을 제안하였으며, 다중 스케일 EdgeConv 모듈을 활용하여 입력 3D 스캔에 맞게 템플릿 모델을 변형하도록 학습하는 인코더-디코더 신경망을 설계했다(Figure 3)[31].

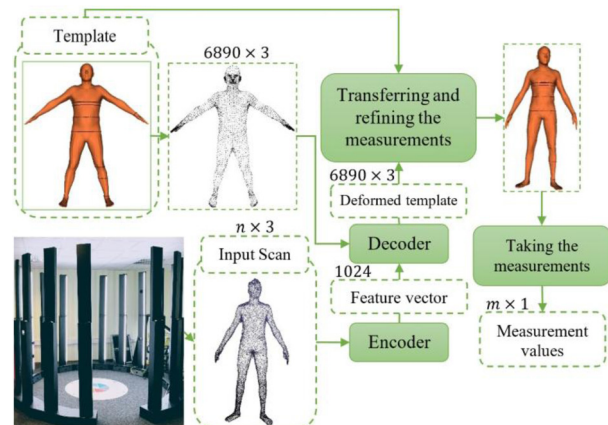


Figure 3. AM-DL 프레임워크. 인코더는 특징 추출기(feature extractor) 역할을 하며, 입력 포인트 클라우드를 잠재 특징 벡터(latent feature vector)로 매핑한다. 디코더는 이 특징 벡터를 활용하여 템플릿의 버텍스(vertices)를 변환해, 템플릿이 입력 포인트 클라우드에 맞게끔 조정함[31].

디스크립터(설명자) 기반 방법들은 3D모델의 국소적 또는 전역적 기하학적 특성을 활용하는 방식으로 열 커널 신호(heat kernel signals, HKS)[35], 형상 서명(shape signatures), 주 곡률(principal curvatures)[36] 등의 버텍스 디스크립터를 사용하여 3D 상에서 측정점을 찾는다. Markiewicz 외 (2017)에서는 입력 포인트 클라우드를 수평으로 분할하고 윤곽 분석을 기반으로 인체 부위를 분할한 후, 인체 스캔을 표면 평활화 기법으로 다듬고, 이후 포인트 클라우드의 각 점에 대해 가우스 곡률

필터를 사용하여 유두와 배꼽과 같은 측정점의 위치를 파악한다[36]. 이러한 특징들은 어떠한 점이 측정점일 확률을 예측하는 모델을 학습하는 데 사용되거나[35,37], 해당 특징들의 국소 극대값(local maxima)을 직접 활용하여 측정점의 위치를 계산하는 데 사용된다[37]. Luo 등은 가장 포괄적인 디스크립터 기반 접근 방식을 제공하며, 특히 다양한 자세와 형태 변화, 그리고 인체 모델의 본질적인 대칭성 문제를 해결하는 데 중점을 두었다[35]. 이 연구는 새로운 대칭 인식 디스크립터인 PHDS를 제안하고, 형태 정렬 알고리즘과 결합하여 AdaBoost 회귀를 통해 랜드마크를 예측한다. 이 방법은 대칭 랜드마크를 의미론적으로 구별할 수 있다는 점에서 이전 연구들보다 발전된 모습을 보인다.

슬라이싱 기반 방법들은 인체 스캔을 바닥과 평행한 평면들로 얇게 절단하여 단면을 분석함으로써 랜드마크를 찾는다. 일부 방법들은 휴리스틱을 활용하여 직접 랜드마크를 정의하기도 하는데[38], 예를 들어 가장 작은 단면을 목 부위로 식별한다. 다른 방법들은 인접한 단면들 간의 변화 양상을 분석하여 특정 랜드마크를 탐지한다[39]. 예를 들어, 세 개의 곡선을 가지는 복부 영역에서 하나의 곡선만 가지는 어깨 영역으로 전환될 때의 단면 곡선 수 변화 등을 분석한다.

그래프 기반 방법들[40]은 마르코프 네트워크(markov network)를 사용하여 스캔된 버텍스(vertex)가 특정 랜드마크에 해당할 확률을 모델링한다. 버텍스 및 엣지의 가능성도(potential)는 각각 버텍스 기술자(vertex descriptor)의 정규 분포와 점 간 거리로 모델링된다.

5.2. 신체측정

3D 스캔에서 신체 치수를 자동으로 추정하는 방식은 측정점(landmark) 및 스캔 데이터 기반, 템플릿 기반, 측정점 및 딥러닝 기반 방식으로 나눌 수 있다

측정점(landmark) 및 스캔 데이터 기반 방법들은 3D 측정점과 고밀도 스캔 데이터를 활용하여 신체 치수를 추정한다[39,41]. 길이 측정값은 랜드마크 간의 유클리드 거리 또는 지오데식 거리(geodesic distance)로 계산되며, 둘레 측정값은 원하는 랜드마크 위치에서 평면으로 스캔을 절단하고 단면을 분석하여 산출된다. 절단 대신, 스캔 상에서 geodesic distance 경로(3차원 표면상의 두 점 사이의 가장 짧은 경로)를 찾는 방법도 사용된다[42]. 하지만 이러한 방법들은 일반적으로 피험자의 성별[43], 자세[44], 방향[43,45]과 같은 사전 정보를 필요로 한다. 또한, 측정값을 직접 스캔으로부터 추정하기 때문에 고밀도 스

캔 데이터가 필요하며, 이로 인해 노이즈나 결측 데이터에 민감하다는 단점이 있다[46].

템플릿 기반 방법들은 3D 스캔에서 바로 측정하지 않고 측정점을 이용하여 템플릿(소스)을 개별 3D 스캔(타겟)에 맞추고(fitting, registration) 측정값을 학습하거나, 전이하거나, 3D 랜드마크로부터 추정한다. 측정값을 학습하려면[47-49] 피팅된 템플릿으로부터 특징을 추출하여 ElasticNet[50], SVR[51], PLS[52] 등 다양한 모델을 학습시킨다. 템플릿으로부터 추출하는 특징들에는 3D 점들, 사전 정의된 경로[50], 형상 파라미터, 메시 엣지 길이, 삼각형 변형의 PCA 계수[49] 등이 있다. 측정값을 전송하려면[46,53,54] 템플릿 상에 신체 측정 경로를 미리 정의하고, 각 경로상의 점에 대해 스캔에서 가장 가까운 이웃점을 찾아 스캔으로 경로를 전이한다. Kaashki 등은 템플릿에서 측정값을 정의하는 소프트웨어를 개발해서, 1) 두 점을 사용하여 호 측정 정의하기, 2) 수평면에서 한 점을 사용하여 둘레 측정 정의하기, 3) 세 개의 다른 점을 사용하여 둘레 측정 정의하기와 같은 방법을 제공한다[31]. 소스 템플릿을 변형하여 타겟 개별 인체 스캔에 피팅한 후에는 템플릿 표면에 정의된 모든 측정 지점을 변형된 템플릿으로 변환해야 한다. Figure 4(a)와 (b)는 각각 템플릿 상의 측정 지점들과 변형된 템플릿에서의 해당 지점들의 위치를 보여준다. 그림에서 알 수 있듯이, 템플릿 피팅 후에는 측정 지점들이 하나의 평면 위에 존재하지 않는다. 따라서 이 측정 지점들에 평면을 피팅하고, 이 평면과 변형된 템플릿 표면이 교차하는 지점들을 최종 인체 치수 측정에 사용되는 점들로 간주한다. Figure 4(c)는 평면 피팅 이후의 최종 측정 지점들을 나타낸다.




Figure 4. 템플릿에서 변형된 템플릿에 측정값 전송하기. (a) 템플릿에 정의된 허리 측정값, (b) 템플릿 피팅 후 허리 측정, (c) 변형된 측정값에 평면을 피팅하는 모습[31].

템플릿 기반 방법에서 측정점으로부터 치수를 추정하는 방법[55]은 피팅된 템플릿으로부터 측정점을 스캔으로 전이한 후, 앞서 설명한 측정점 기반 방법을 이용하여 치수를 산출한다. 이 방법은 피팅 과정에 민감하며 보통 랜드마크[48], 텍스처 맵[56], 렌더링된 실루엣 등 추가 정보를 통해 피팅을 안정화한다.

템플릿 기반 방법들의 장점은 첫째, 신체 일부가 누락되지 않은 구멍 없는 메쉬를 생성하고 포인트 클라우드 노이즈를 줄여준다. 둘째, 모든 피사체의 등록된(registered) 메쉬가 동일한 위상을 가지게 되어, 미리 정의된 둘레 경로의 대응점을 찾기 쉽게 한다.

반면에 템플릿 기반 방법들의 단점은 첫째, 템플릿의 완전성에 크게 의존하기 때문에 템플릿이 불완전할 경우 부정확한 인체 측정 데이터가 생성될 수 있다. 둘째, 스캐닝 포즈 및 성별 차이와 같이 템플릿과 차이가 큰 스캔 데이터는 정확한 피팅이 어려울 수 있다. 다음으로, 템플릿 등록(registration)시에 실시되는 ICP 및 CPD와 같은 최적화 프로세스는 계산량이 많아 속도가 느리다. 또한, 랜드마크 기반 방법들과 마찬가지로, 피험자의 형상을 정확히 표현하기 위해 고밀도 스캔 데이터를 필요로 한다[57,58]. Hasler의 템플릿 기반 방법은 SCAPE[18] 신체 템플릿을 스캔에 맞추고 선형 회귀함수 모델을 사용하여 신체 모델 정점에서 키, 체지방, 허리둘레, 근육량 등의 측정값을 예측한다[59]. 이러한 접근 방식은 최종 측정값이 주어진 스캔이 아닌 템플릿에서 추출되기 때문에 피팅프로세스에 매우 민감하다.

템플릿 기반 방법들의 단점을 해결하기 위해 Tsoli 등은 BlendSCAPE[61] 신체 모델을 템플릿으로 사용하여 이를 3D 스캔에 맞춰 피팅하고, 가장 예측력 있는 특징유형을 찾고 형상특징과 각 치수간의 관계를 학습하기 위해 ElasticNet[62]이라는 정규화된 선형 회귀 모델을 사용했다[60]. 이 선형 회귀모델은 전역 형상 통계 특징(PCA 계수)과 국소 형상 특징(둘레, 사지 길이)을 모두 고려하기 때문에 이전 방법보다 더 나은 결과를 얻을 수 있다. 또한 이 연구는 Hasler 등의 연구에서 측정한 치수 항목의 범위가 제한적이었다고 평가하며 더 광범위한 40가지 치수항목에 대해서 연구하였다[59].

측정점 및 딥러닝 기반 방법[64]은 어떤 자세에서든 최소한 랜드마크 데이터만으로 신체 치수를 얻을 수 있는 방법을 제안한다. 이를 위해 먼저 다양한 자세의 스캔 데이터베이스를 분석하여, 자세에 영향을 받지 않으면서 신체 치수에 영향을 미치는 특징들을 식별한다. 그 다음으로 식별된 특징들과 랜드마크 좌표를 바탕으로 다층 퍼셉트론(multilayer perceptron, MLP) 네트워크를 사용하여 11개의 인체 치수를 예측한다. 하지만 이 방법에도 한계점이 있는데 특히 치수 추정에 이용되는 측정점이 많지 않은 경우 치수값이 부정확해진다는 것이다. 가슴둘레와 엉덩이둘레는 연관된 측정점들이 각각 1개만 있어서 치수가 부정확한 편이다.

그 밖에 템플릿을 사용하지 않으면서 딥러닝을 사용하는 3D 방법으로서 Cha 등의 연구가 있다[65]. 이 연구에서는 Coarse-to-fine 전략으로 먼저 글로벌 감지 단계(global detection)에서 pointNet++ 기반의 네트워크를 사용하여 전신 포인트 클라우드

스에서 기하학적 특징을 계층적으로 추출하고, 랜드마크 위치의 확률 분포를 나타내는 geodesic 거리 기반 히트맵을 학습하여 초기 인체 측정 랜드마크를 추정한다. 다음으로 로컬 정제 단계(local refinement)에서 글로벌 감지 단계에서 얻은 초기 예측값을 기반으로 각 랜드마크 주변의 국부적인 포인트 세트 구조를 캡처하여 각 랜드마크에 대해 개별 DNN을 훈련하여 예측 정확도를 향상시킨다. 이 연구는 Size Korea 데이터셋을 활용하였기 때문에 한국인에 보다 적합하다는 특징도 있다.

6. 결 론

본 고에서는 인체측정 기술 중에서 2차원 이미지를 기반으로 한 방법과 3차원 스캔 데이터를 기반으로 한 방법의 연구동향에 대해서 소개하였다.

2D 이미지 기반 인체 측정은 측정장비가 간단하여 실용적이라는 면에서 장점이 크지만 3D 방법보다는 부정확하다는 단점이 있는데, 앞으로 이 부정확성을 개선하는 연구가 계속될 것으로 전망되며, 정확성이 향상된다면 간단한 신체 치수 추정 방법으로 자리 잡을 가능성이 높다.

3D 스캔 데이터 기반 인체측정은 과거에는 단순히 인체실루엣이나 단면의 기하학적 형상을 기반으로 측정하고자 하는 연구가 많았고 그러한 방법이 정확성이 더 높았다면, 근래에는 인체 템플릿이나 학습기반 방법이 대세를 이루고 있고 정확성도 높아지고 있는 것을 볼 수 있다. 하지만 템플릿 방법이나 학습기반 방법도 단점이 있으므로 앞으로 기존의 여러 가지 방법의 장점을 결합하는 연구가 수행된다면 정확도가 더 향상될 것으로 기대된다. 또한 모델의 일반화 능력을 향상시키기 위해 다양한 인종, 연령, 체형, 자세, 의류 상태를 반영하는 대규모의 고품질 3D 인체 스캔 및 측정 데이터셋 구축 및 활용이 중요해질 것이다.

참고문헌

1. S. Pheasant and C. M. Haslegrave, "Bodyspace: anthropometry, ergonomics, and the design of work(3rd ed)", w Boca Raton, FL, USA: CRC Press, 2005, pp.7.
2. N. Zakaria and D. Gupta, "Anthropometry, Apparel Sizing and Design", The Textile Institute Book Series. Elsevier Science, 2019.
3. ISO 7250-1:2017, "Basic human body measurements for technological design - Part 1:Body measurement definitions and landmarks", Standard, International Organization for Standardization, 2017.
4. ISO 8559-3:2018, "Size Designation of Clothes—Part 3: Methodology for the Creation of Body Measurement Tables and

- Intervals”, International Organization for Standardization, 2018.
5. ISO 20685-1:2018, “3-D scanning methodologies for internationally compatible anthropometric databases - Part 1: Evaluation protocol for body dimensions extracted from 3-D body scans”, Standard, International Organization for Standardization, 2018.
6. C. Gordon, T. Churchill, C. Clauser, B. Bradtmiller, J. McConville, I. Tebbetts, and R. Walker, “1988 anthropometric survey of u.s. army personnel: Methods and summary statistics”, **01**, 1989.
7. Korean Agency for Technology and Standards, “The 8th size Korea 3D scan & measurement technology report”, Seoul: Government Printing Office, 2022.
8. Y. L. Lin and M. J. Wang, “Automated body feature extraction from 2D images”, *Expert Systems with Applications*, 2011, **38**, 2585-2591.
9. Y. L. Lin and M. J. J. Wang, “Constructing 3d human model from front and side images”, *Expert Systems with Applications*, 2012, **39**(5), 5012-5018.
10. M. Montazerian and F. F. Leymarie, “Simple hybrid camera-based system using two views for three-dimensional body measurements”, *Symmetry*, 2024, **16**(1).
11. J. Canny, “A computational approach to edge detection”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986, PAMI-**8**(6), 679-698.
12. P. Xi, W. S. Lee, and C. Shu, “A data-driven approach to human-body cloning using a segmented body database”, in 15th Pacific Conference on Computer Graphics and Applications (PG’07), 2007, 139-147.
13. J. Boisvert, C. Shu, S. Wuhner, and P. Xi, “Three-dimensional human shape inference from silhouettes: reconstruction and validation”, *Machine Vision and Applications*, 2011, **24**(1), 145-157.
14. X. Wang, B. Liu, Y. Dong, S. Pang, and X. Tao, “Anthropometric landmarks extraction and dimensions measurement based on resnet”, *Symmetry*, 2020, **12**(12).
15. N. Ruiz, M. Bellver, T. Bolkart, A. Arora, M. C. Lin, J. Romero, and R. Bala, “Human body measurement estimation with adversarial augmentation”, *2022 International Conference on 3D Vision(3DV)*, 2022, 219-230.
16. I. J. Goodfellow, J. Shlens, and C. Szegedy, “Explaining and harnessing adversarial examples”, *arXiv preprint arXiv, 1412.6572*, 2014.
17. M. Loper, N. Mahmood, J. Romero, G. Pons-Moll, and M. J. Black, “SMPL: A skinned multi-person linear model”, *ACM Transactions on Graphics (TOG)*, 2015, **34**(6), 1-16.
18. D. Anguelov, P. Srinivasan, D. Koller, S. Thrun, J. Rodgers, and J. Davis, “Scape: Shape completion and animation of people”, in *ACM Siggraph*, 2005, 408-416.
19. V. Choutas, L. Müller, C. H. P. Huang, S. Tang, D. Tzionas, and M. J. Black, “Accurate 3d body shape regression using metric and semantic attributes”, in *Proceedings IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, 2022, 2718-2728.
20. X. Ma, J. Su, C. Wang, W. Zhu, and Y. Wang, “3d human mesh estimation from virtual markers”, in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR)*, 2023, 534-543.
21. F. Bogo, A. Kanazawa, C. Lassner, P. Gehler, J. Romero, and M. J. Black, “Keep it SMPL: Automatic estimation of 3D human pose and shape from a single image”, *In European conference on computer vision*, 2016, 561-578.
22. M. Kaufmann, J. Song, C. Guo, K. Shen, T. Jiang, C. Tang, and J. J. Zárate, Hilliges, O., “EMDB: The Electromagnetic Database of Global 3D Human Pose and Shape in the Wild”, in *International Conference on Computer Vision(ICCV)*, 2023, 14632-14643.
23. S. K. Dwivedi, N. Athanasiou, M. Kocabas, and M. J. Black, “Learning to regress bodies from images using differentiable semantic rendering”. In *Proceedings of the IEEE/CVF international conference on computer vision*, 2021, 11250-11259.
24. S. Zhang, Q. Ma, Y. Zhang, S. Aliakbarian, D. Cosker, and S. Tang, “Probabilistic human mesh recovery in 3d scenes from egocentric views”, in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2023, 7989-8000.
25. Size Stream Home Page. <http://sizestream.com>. (accessed July 24, 2025).
26. Netvirta, L., “Verifyt” Apple App Store Home Page. <https://apps.apple.com/us/app/verifyt/id1540056127> (accessed July 24, 2025).
27. SizeYou Home Page. <https://www.sizeyou.it/en> (accessed July 24, 2025).
28. A. Baronetto, D. Wassermann, and O. Amft, “Deep 3d body landmarks estimation for smart garments design”, in *2021 IEEE 17th International Conference on Wearable and Implantable Body Sensor Networks(BSN)*, 2021, 1-5.
29. L. Deng, T. Yan, and Q. Zhao, “Anthropometric parameter measurement from equivariant multi-view images”, *Journal of Physics: Conference Series*, 2020, **1576**(1), 012006.
30. H. Han, Y. Nam, and S. Hwang Shin, “Algorithms of the automatic landmark identification for various torso shapes”, *International Journal of Clothing Science and Technology*, 2010, **22**(5), 343-357.
31. N. N. Kaashki, P. Hu, and A. Munteanu, “Deep learning-based automated extraction of anthropometric measurements from a single 3-d scan”, *IEEE Transactions on Instrumentation and Measurement*, 2021, **70**, 1-14.

32. Z. Zhou, and S. Hao, "Anatomical landmark detection on 3D human shapes by hierarchically utilizing multiple shape features", *Neurocomputing*, 2017, **253**, 162-168.
33. T. Groueix, M. Fisher, V. G. Kim, B. C. Russell, and M. Aubry, "3DCODED: 3D correspondences by deep deformation", *In Proceedings of the european conference on computer vision(ECCV)*, 2018, 230-246.
34. Z. Q. Cheng, Y. Chen, R. R. Martin, T. Wu, and Z. Song, "Parametric modeling of 3D human body shape—A survey", *Computers & Graphics*, 2018, **71**, 88-100.
35. S. Luo, Q. Zhang, J. Feng, "Automatic location and semantic labeling of landmarks on 3d human body models", *Computational Visual Media*, 2022, **8**(4), 553-570.
36. L. Markiewicz, M. Witkowski, R. Sitnik, and E. Mielicka, "3D anthropometric algorithms for the estimation of measurements required for specialized garment design," *Expert Syst. Appl.*, 2017, **85**, 366-385.
37. C. Lovato, U. Castellani, C. Zancanaro, and A. Giachetti, "Automatic labelling of anatomical landmarks on 3d body scans", *Graphical Models*, 2014, **76**(6), 648-657.
38. H. Han, and Y. Nam, "Automatic body landmark identification for various body figures", *International Journal of Industrial Ergonomics*, 2011, **41**(6), 592-606.
39. H. Xie, Y. Zhong, Z. Yu, A. Hussain, and G. Chen, "Automatic 3d human body landmarks extraction and measurement based on mean curvature skeleton for tailoring", *The Journal of The Textile Institute*, 2021, **113**(8), 1677-1687.
40. A. Giachetti, E. Mazzi, F. Piscitelli, M. Aono, A. B. Hamza, T. Bonis, P. Claes, A. Godil, C. Li, M. Ovsjanikov, *et al.*, "Shrec'14 track: automatic location of landmarks used in manual anthropometry", in *Eurographics Workshop on 3D Object Retrieval*, 2014, 93-100
41. H. Han, "Development of automatic 3d body scan measurement line generation method", *International Journal of Clothing Science and Technology*, 2023, **35**(3), 350-362.
42. T. Xiaohui, P. Xiaoyu, L. Liwen, and X. Qing, "Automatic human body feature extraction and personal size measurement", *Journal of Visual Languages & Computing*, 2018, **47**, 9-18.
43. J. Lu, and M. Wang, "Automated anthropometric data collection using 3d whole body scanners", *Expert Systems with Applications*, 2008, **35**(1-2), 407-414.
44. Y. Zhong, D. Li, G. Wu, and P. Hu, "Automatic body measurement based on slicing loops", *International Journal of Clothing Science and Technology*, 2018, **30**(3), 380-397.
45. L. Markiewicz, M. Witkowski, R. Sitnik, and E. Mielicka, "3d anthropometric algorithms for the estimation of measurements required for specialized garment design", *Expert Systems with Applications*, 2017, **85**, 366-385.
46. N. N. Kaashki, P. Hu, and A. Munteanu, "Anet: A deep neural network for automatic 3d anthropometric measurement extraction", *IEEE Transactions on Multimedia*, 2023, **25**, 831-844.
47. P. Li, and S. Paquette, "Predicting anthropometric measurements from 3d body scans: Methods and evaluation". *In International Conference on Applied Human Factors and Ergonomics*, 2019, 561-570, Cham: Springer International Publishing.
48. S. Yan, J. Wirta, and J. K. Kämäräinen, "Anthropometric clothing measurements from 3d body scans", *Machine Vision and Applications*, 2020, **31**(1), 7.
49. B. K. D. Park, H. Jung, S. M. Ebert, B. D. Corner, and M. P. Reed, "Efficient modelbased anthropometry under clothing using low-cost depth sensors", *Sensors*, 2024, **24**(5), 1350.
50. H. Zou, and T. Hastie, "Regularization and variable selection via the elastic net", *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 2005, **67**(2), 301-320.
51. C. C. Chang, and C. J. Lin, "LIBSVM: A library for support vector machines", *ACM Transactions on Intelligent Systems and Technology(TIST)*, 2011, **2**(3), 1-27.
52. P. Geladi, and B. R. Kowalski, "Partial least-squares regression: a tutorial", *Analytica Chimica Acta*, 1986, **185**, 1-17.
53. W. F. de Ferreira, D. G. Balreira, D. M. Filho, and M. Walter, "A template-based anthropometric measurement approach for 3d scanned bodies", In *2023 36th SIBGRAPI Conference on Graphics, Patterns and Images(SIBGRAPI)*, IEEE, 2023, 13-18,.
54. J. Uriel, A. Ruescas, S. Iranzo, A. Ballester, E. Parrilla, A. Remón, S. Alemany, "A methodology to obtain anthropometric measurements from 4d scans", In *Proceedings of the 7th International Digital Human Modeling Symposium*, University of Iowa, 2022, 7(1).
55. N. E. Garcia-D'Urso, J. Azorin-Lopez, and A. Fuster-Guillo, "A Template-Based Method for Automatic Anthropometric Measurements from Multiple 3D Scans", In *International Conference on Ubiquitous Computing and Ambient Intelligence*. Springer International Publishing, 2022, 157-168.
56. F. Bogo, J. Romero, G. Pons-Moll, and M. J. Black, "Dynamic FAUST: Registering human bodies in motion", In *IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, 2017, 6233-6242.
57. D. Bojanić, S. Wuhner, T. Petković, and T. Pribanić, "Pose-independent 3d anthropometry from sparse data", In *European Conference on Computer Vision*, 2024, 237-256.
58. L. Pishchulin, S. Wuhner, T. Helten, C. Theobalt, and B. Schiele, "Building statistical shape spaces for 3d human modeling",

- Pattern Recognition*, 2017, **67**, 276-286.
59. N. Hasler, C. Stoll, M. Sunkel, B. Rosenhahn, and H. P. Seidel, "A Statistical Model of Human Pose and Body Shape", In *Computer Graphics Forum*, 2009, **28**(2), 337-346.
 60. A. Tsoli, M. Loper, and M. J. Black, "Model-based anthropometry: Predicting measurements from 3d human scans in multiple poses", In *IEEE Winter Conference on Applications of Computer Vision*, IEEE, 2014, 83-90.
 61. D. A. Hirshberg, M. Loper, E. Rachlin, and M. J. Black, "Coregistration: Simultaneous alignment and modeling of articulated 3D shape", In *European conference on computer vision*, 2012, 242-255, Berlin, Heidelberg, Springer Berlin Heidelberg.
 62. H. Zou, and T. Hastie, "Regularization and variable selection via the elastic net", *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 2005, **67**(2), 301-320.
 63. Anthroscan, Human solutions Home Page, <https://www.human-solutions.com/> (accessed: July 24, 2025).
 64. D. Bojanić, S. Wuhler, T. Petković, and T. Pribanić, "Pose-independent 3d anthropometry from sparse data", In *European Conference on Computer Vision*, 2024, 237-256, Cham: Springer Nature Switzerland.
 65. M. H. Cha, J. H. Park, J. S. Byun, S. Ahn, G. Lee, S. H. Yoon, and S. I. Cho, "Anthropometric Landmark Detection Network via Geodesic Heatmap on 3D Human Scan", *IEEE Access*, 2024.