

다중 재실자 대상 실시간 착의량 산출 프로세스 개발

Development of the Estimating Process for the real-time Clothing Insulation of Multiple Occupants

최 은 지* 윤 지 영** 김 남 현** 문 진 우***
Choi, Eun Ji Yun, Ji Young Kim, Nam Hyeon Moon, Jin Woo

* 중앙대학교 건축학부 박사과정, Ph.D. Candidate, Dept. of Architecture and Building Science, Chung-Ang University, Korea

** 중앙대학교 건축학부 석사과정, Master's Course Student, Dept. of Architecture and Building Science, Chung-Ang University, Korea

*** 중앙대학교 건축학부 교수, Professor, Dept. of Architecture and Building Science, Chung-Ang University, Korea

(Corresponding author : gilerbert73@cau.ac.kr)

Abstract

Information on clothing insulation (CLO) worn by individual occupants is essential for comfort-based control in buildings. It is necessary to develop a method for estimating each occupant's real-time actual clothing information in situations with multiple occupants. This study aims to suggest a novel approach to estimate the CLO of multiple occupants in real-time and confirm its practical application with the help of a performance evaluation in a test-bed. A process that combined the person detection model and the CLO estimation model was proposed. Experiments to estimate CLO worn by multiple persons in a test-bed were conducted to train the model and evaluate its performance at each stage of the process. As a result, each model of the process demonstrated an average person detection accuracy of 95% and a CLO estimation accuracy of 91% for six different clothing combinations. Consequently, these experimental findings confirmed the feasibility of estimating a person's clothing insulation in an indoor environment where multiple people exist.

키워드 : 열쾌적, 재실자중심제어, 예상평균온열감, 착의량

Keywords : Thermal comfort, Occupant-centric control, Predicted mean vote, Clothing insulation

1. 서 론

1.1 연구 배경

전 세계적으로 도시화가 진행됨에 따라, 하루 대부분의 시간을 실내에서 보내는 사람들이 증가하고 있다(De Giuli, Da Pos & De Carli, 2012; Choi et al. 2021a). 이로 인해 재실자의 건강, 업무 생산성 등의 삶의 질에 영향을 미치는 실내 열환경에 대한 중요성이 대두되고 있으며, 쾌적한 실내 열환경 제공을 위한 다양한 노력이 수행되고 있다(Jung & Jazizadeh, 2019; Choi et al., 2022a).

재실자의 열쾌적을 향상시키고 동시에 건물 에너지의 효율적인 사용을 위해서 최근 재실자의 유무, 인원, 선호도와 같은 정보를 토대로 제어를 수행하는 재실자 중심 제어(occupant-centric control, OCC)에 대한 관심이 증가하는 추세이다(Pang et al., 2021; Yang et al., 2022). Pang et al.(2020)은 시뮬레이션을 기반으로 재실자 인원 정보를

활용한 건물 제어 시 최소 24%에서 최대 58%까지 건물 에너지를 절약할 수 있음을 확인했다. 또한, Xie et al.(2020)은 OCC와 관련된 문헌 검토를 수행하여 재실자 중심의 제어를 통해 평균 22%의 에너지 절약 및 29.1%의 열쾌적성 향상이 가능함을 확인하였다.

건물 제어에 고려되는 재실자 정보는 다양하며, 재실자 정보에 따라 건물 에너지 및 열쾌적에 미치는 영향은 크게 달라질 수 있다. 재실자 정보 중 PMV (predicted mean vote)는 사람이 느끼는 온열감을 정량적으로 산출하는 지표로 재실자의 열쾌적을 결정하는 주요 변수이다(Fanger, 1970). PMV는 실내온도, 상대습도, 기류속도, 평균복사온도와 같은 환경변수 외에도 활동량(metabolic rate, MET) 및 착의량(clothing insulation, CLO)과 같은 개인변수도 함께 고려된다(ASHRAE standard 55, 2020). PMV 기반의 실내 열환경 제어 시 재실자의 열쾌적성이 향상되는 것을 확인한 연구는 다수 수행되었다. Jang & Suh(2013)는 시뮬레이션을 통해 사무소 용도의 건물에서 온도기반 제어에 비해 PMV 기반 제어가 쾌적범위 내에 분포되는 비율이 높게 나타남을 확인하였다. 또한, Wu et al.(2020)은 PMV 기반의 제어 시 온도 기반 제어보다 하루 에너지 사용량을 1.6% 절약할 수 있음을 확인했다.

이 논문은 2022년도 대한건축학회 추계학술발표대회 논문집에 게재된 내용을 수정보완하여 작성한 것임.

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임. 과제번호:2019R1A2C1084145

하지만 이러한 연구는 PMV의 개인변수를 단순히 고정값으로 사용하였으며, 보다 효과적인 쾌적 제어를 위해서는 실제 개인변수를 고려할 필요가 있다. 다시 말해서, 정확한 PMV 산출을 위해서는 개인변수의 정확한 측정이 요구된다. PMV 개인변수 중 착의량은 사람이 입고 있는 의복의 단열값을 의미하며, 일반적인 양복을 입은 사람의 착의량은 1.0 clo로, 0.155 m²K/W의 열저항 값으로 계산된다(ASHRAE standard 55, 2020). 착의량은 썬덜 마네킨(thermal mannequin)을 이용하거나 열전도센서를 의복에 부착하는 방식을 통해 직접적으로 측정될 수 있다(Konarska et al., 2007). 하지만 이러한 방법을 실제 현장에 적용하기에는 재실자의 직접적인 개입을 요구하며 다수의 인원이 거주하는 상황에서 모든 의복 정보를 실시간으로 측정하기 어렵다는 한계가 있다.

이러한 이유로 기존의 열환경 제어 방법은 건구 온도만을 고려한 온도 설정값으로 제어하거나 재실자의 상황을 가정한 고정 착의량 값을 사용해 PMV 제어를 수행하였다(Sung & Hsiao, 2020; Wu et al., 2020). 임의의 착의량은 일반적으로 계절을 기준으로 구분하여 여름 기준 0.5 clo, 겨울 기준 1.0 clo의 값을 대입했다(Lu, Hameen & Aziz, 2018; ASHRAE standard 55, 2020). 그러나 임의의 값은 재실자의 실제 상황을 반영하지 못하므로 실제 재실자의 열쾌적과는 차이가 발생해 오히려 불쾌적인 상황을 만들 수 있다.

따라서, 실제 환경에서 재실자의 개입 없이 간접적이며 객관적으로 착의량을 산출하기 위한 방법이 요구되고 있으며, 재실자의 실시간 착의량 측정을 위한 다양한 연구가 수행되고 있다(Karyono et al., 2020; Lee et al., 2020). 실시간 착의량 측정을 위해서 주로 thermal image 또는 RGB image와 같이 이미지를 활용하는 접근 방법이 적용되었다(Miura et al., 2020; Liu, Foged & Moeslund, 2022; Choi et al., 2022b). Thermal image를 통한 착의량 산출 방법 중 Lee et al.(2016)과 Lee et al.(2020)은 적외선 카메라를 이용하여 노출된 피부와 의복 표면 온도의 관계로부터 실시간으로 의복 단열값을 추정했다. 이와 같은 방법은 실제 재실자 데이터를 반영하여 착의량 값을 산출할 수 있음을 보여줬지만, 착의량 산출의 정확도가 낮고 실시간 PMV 제어에 적용하지는 못했다. 최근에는 재실자 착의량을 산출하기 위해 RGB 이미지를 활용한 모델이 개발되고 있다. Matsumoto, Iwai & Ishiguro(2011)은 카메라를 활용하여 영상에서 옷을 감지하고, 감지된 옷의 소재를 파악해 중량을 결정하여 착의량 값을 계산하였다.

또한, Choi et al.(2021b)과 Choi et al.(2022b)는 각각 vision-based 모델을 사용해 이미지에서 감지된 의복 종류를 분류하는 방법을 개발하였으며, 나아가 개발된 모델을 활용해 실시간으로 산출된 착의량을 실제 건물 제어에 적용한 연구도 수행하였다. Choi et al.(2021b)은 딥러닝 모델을 통해 5가지 의복조합의 착의량을 실시간으로 산출하고, 주거용 건물에 PMV 제어를 구현하였다. 또한, Choi et al.(2022b)은 객체인식을 위해 합성곱 신경망(convolution neural network, CNN) 기반 영상처리 기법을

사용하였으며, 최대 32가지 의복조합의 착의량 산출이 가능한 자유도 높은 모델을 개발하였다. 또한, 의복과 관계없이 설정온도를 유지한 기존 PMV 제어에 비해 실시간으로 착의량 값을 반영하여 온도조절을 한 PMV 제어가 거주자의 편안함을 향상시키는데 효과적임을 확인했다.

그러나 이러한 연구들은 주로 단일 재실자를 대상으로 착의량을 산출하였다. 단일 재실자를 대상으로 착의량을 산출하는 방법은 1인 주거시설에 적용할 수 있다. 하지만 업무시설 및 다중이용시설과 같은 불특정 다수가 거주하는 건물에서 실질적인 PMV 기반의 열쾌적 제어를 수행하기 위해서는 다중 재실자를 대상으로 실시간 착의량 값을 산출하는 방법이 필요하다. 예를 들어 존 제어, 개별제어 등 구역별 제어가 가능한 공조 시스템을 사용할 경우, 해당 구역의 다중 재실자를 대표하는 착의량 정보를 반영할 수 있다면 실별 재실자 맞춤 제어가 가능하다. 이는 결과적으로 전체적인 건물 열쾌적 및 시스템 에너지 효율을 향상시킬 수 있다. 다시 말해서 기존의 착의량 산출 방법을 토대로 다중 인원이 거주하는 공간에 적용할 수 있는 새로운 접근 방법이 필요하다.

따라서 본 연구의 목적은 vision-based 모델을 통해 실내 영상 이미지에서 다중 재실자의 착의량을 실시간으로 산출하는 새로운 방법을 제시하고 실제 환경에서의 성능평가를 토대로 제안된 방법의 실질적인 적용 가능성을 확인하는 것이다. 이를 위해 Test-bed를 대상으로 다중 인원에 대한 착의량 산출 실험을 수행하였으며, 실험을 통해 다중 재실 상황에서의 실시간 착의량 산출 정확도를 확인하고 재실 환경에 따른 성능평가를 진행하였다.

2. 연구방법

2.1 다중 재실자 대상 착의량 산출 프로세스

다중 인원이 거주하는 실내 환경에서 정확한 착의량을 산출하기 위해서는 추가적인 단계가 필요하다. 단일 재실자만 존재하는 환경에서는 실내 이미지에서 검출되는 의복 모두 해당 재실자가 입고 있다고 가정할 수 있다. 하지만, 다중 재실 환경에서는 감지된 의복의 대상이 누구인지 파악하기 어려우며, 개개인의 착의량을 정확하게 추정하기에 한계가 있다.

따라서, 개개인이 입고 있는 의복조합을 정확히 추정하기 위해서는 의복 감지에 앞서 사람을 먼저 감지하는 단계가 추가되어야 한다. 따라서, 다중 재실 환경에 적용하기 위해 재실자 감지 모델 및 의복 분류 모델을 통합한 착의량 산출 프로세스를 Table 1과 같이 제시하였다. 제안된 착의량 산출 프로세스는 Step 1) Person detecting과 Step 2) CLO estimation 단계를 거쳐 최종적으로 개개인의 CLO를 도출한다.

Step 1은 이미지에서 모든 재실자를 개별적으로 감지하고 감지된 사람만 잘린 경계박스(bounding box, B-box) 이미지를 추출한다. Step 2는 감지된 사람 B-box 이미지에서 의복을 감지 및 분류하여 최종적으로 분류된 의복을 토대로 감지된 사람이 입고 있는 의복조합을 추정하고

착의량을 산출한다. 단계별로 적용된 모델은 객체 검출 모델로 2.2장에서 자세히 설명한다.

제안된 착의량 산출 프로세스는 Step 1에서 사람을 제외한 주변 배경을 제거함으로써 Step 2에서 착의량 산출 모델의 오차 발생률을 감소시킬 수 있다. 예를 들어, 의복과 유사한 물체 또는 실내에 존재하는 의복 중 사람이 착의하지 않은 의복의 경우 1단계에서 배경 중 일부로 제거되어 최종 착의량에 영향을 미치지 않게 된다. 따라서, 제안된 접근 방법은 착의량 산출 정확도를 향상시킬 뿐만 아니라 다중 인원이 거주하는 환경에서 재실자의 개별 착의량에 대한 정보 취득이 가능해 실제 건물에 적용성이 높다고 볼 수 있다.

제시된 착의량 산출 프로세스는 성능확보를 위한 전이 학습 및 실제 환경에서의 성능평가를 진행하였다. 따라서, 본 장에서는 프로세스 단계별 모델의 전이 학습을 위한 데이터 수집과 성능평가를 위한 실험 방법을 제시하였다.

Table 1. CLO estimation process for multi-occupants

Step	Process	Model
Step 1	Person detection	YOLOv5 model
Step 2	CLO estimation	R-CLO model (Choi et al., 2022b)

2.2 객체 검출 모델 개요

객체 검출 모델은 실시간으로 사물을 감지 및 분류하며, 모델은 CNN 기반의 구조가 반복되는 형태로 이미지와 같은 2D 데이터에 처리에 특화되어 있다. 객체 검출 모델은 Fast R-CNN (Girshick, 2015), Faster R-CNN (Ren et al., 2015), YOLO (Redmon et al., 2015), SSD (Liu et al., 2015), RetinaNet (Lin et al., 2017) 등 다양하게 제시되어 왔으며, 그 중 YOLO는 물체 검출을 수행하는 region proposal과 물체를 분류하는 classification을 동시에 수행하는 모델이다. 이러한 방법으로 객체 검출 속도를 높였으며, 일상생활에 적용 가능한 실시간 객체 검출을 가능하게 했다.

본 연구에서는 실시간 의복 정보를 산출을 위해 빠른 데이터 처리 속도를 보이는 YOLOv5 (Jocher et al., 2020)를 기본 모델 구조로 사용하였다. 해당 모델은 다중 재실자 착의량 산출 프로세스 각 단계에 적용되었으며, 단계별 전이 학습을 수행하였다. 전이 학습은 기존 모델에 새로

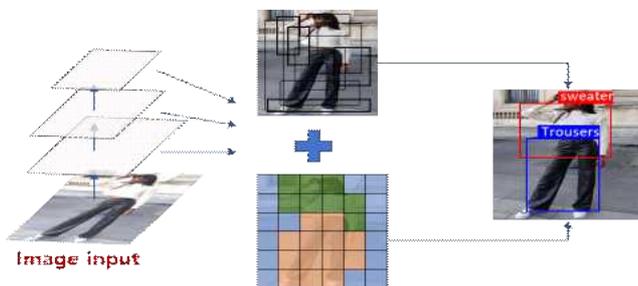


Figure 1. Conceptual diagram of R-CLO model based on YOLOv5

Table 2. The classifiable types of garment

Types	Garments
Top	SS shirt, LS shirt, T shirt, LS sweatshirt, LS sweater
Bottom	Walking shorts, Trousers, KL skirt, AL skirt, Sweat pants
Outer	Suit jacket
Dress	LS shirt dress, SS shirt dress
Pajama	Pajama trousers, LS pajama shirt, SS pajama shirt

* SS: short-sleeve, LS: long-sleeve, KL; knee-length, AL: ankle-length

운 데이터셋을 학습시켜 목적에 맞게 customizing하는 학습방법을 의미하며, 빠른 정확도 향상이 가능하다. Step 1에서는 YOLOv5의 사람 분류 성능을 향상시키기 위해 배포된 모델 파라미터를 업데이트하는 전이 학습을 수행하였다. Step 2는 YOLOv5의 구조를 활용해 의복 데이터셋을 새롭게 학습한 R-CLO 모델(Park et al. 2022; Choi et al., 2022b)을 사용하였다. R-CLO 모델의 개념도는 Figure 1과 같으며, 모델은 이미지에서 의복의 위치를 감지하고 감지된 의복의 종류를 분류한다. R-CLO 모델은 총 16가지 의복을 분류할 수 있으며 의복의 구성은 Table 2와 같다. 제안된 모델은 상의 및 하의와 같이 개별 의복을 분류하고 분류된 의복 정보를 토대로 사람이 입고 있는 다양한 의복조합의 착의량을 산출할 수 있다는 강점을 가진다.

하지만, 기존 R-CLO 모델은 단일 재실자만 존재하는 실내 환경 이미지를 학습하였으며, 이는 Step 1에서 출력되는 사람 B-box 이미지와 차이가 있다. 따라서, 제안된 프로세스에 모델을 적용하기 위해서 R-CLO 모델의 기존 학습데이터를 사람 B-box 이미지로 변경하여 학습을 수행하였다.

2.3 모델 학습데이터

프로세스 단계별 모델 학습을 위해 인터넷 및 실제 실험실에서 재실자 이미지를 수집하였다. Step 1 모델의 경우, 학습을 위해 Figure 2 (a)와 같이 10인 내외 인원이 거주하는 업무환경에서 이미지 데이터를 수집하였으며, 카메라 센서 두 대로 실내 공간을 분할하여 취득하였다. 모델의 전이 학습 및 학습된 모델의 성능 평가를 위해 실험실에 모델을 하루 동안 적용하여 재실 인원 감지 오차를 분석하였다. 학습 및 평가에 사용된 데이터는 총 5,896개이며, 학습 시 재실 시간대의 이미지만 사용하였다.

Step 2의 경우 R-CLO 모델을 착의량 산출 프로세스에 적용하기 위해 사람 B-box 이미지로 전이 학습을 위한 데이터셋을 구성하였다. 데이터셋은 인터넷과 실험실에서 취득하였으며, 총 7,068개이다. 의복 종류는 R-CLO가 분류할 수 있는 16개(Table 2)로 구성되며, 실험실에서 취득할 때는 16가지 의복을 활용한 의복조합 6개를 입고 진행하였다.

2.4 성능평가 실험

학습된 모델 기반의 착의량 산출 프로세스의 성능을 평가하기 위해 다중 재실 환경에 대한 실험을 수행하였다. 실험은 Figure 2 (b)와 같이 학습에 사용되지 않은 새

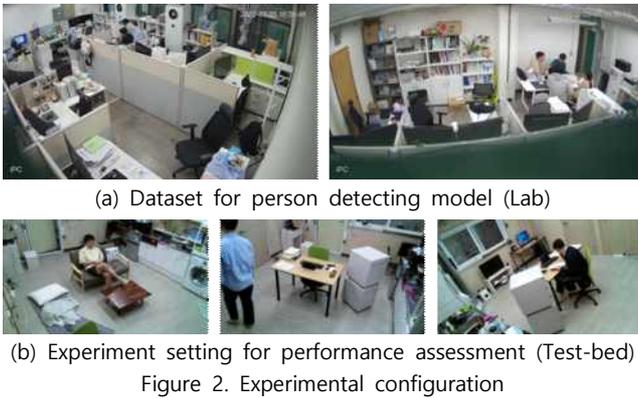


Figure 2. Experimental configuration

Table 3. Clothing ensemble cases

Case	Ensemble	CLO (I_{cl})
1	T shirt, Walking shorts	0.38 clo
2	SS shirt, Walking shorts	0.50 clo
3	LS sweat shirt, Sweat pants	0.60 clo
4	LS pajama top, Pajama trousers	0.63 clo
5	LS shirt, Trousers	0.69 clo
6	LS sweater, Trousers	0.71 clo

※ Basic clothing: underwear, socks, sneakers

로운 주거환경의 Test-bed에서 진행하였으며, 재실인원 및 의복 조건을 변경하며 실험하였다. Test-bed에서는 1, 2, 3인의 재실상황을 각각 조성하였다. 피실험자는 Table 3과 같이 상의 6개 (T shirt, Short-sleeve shirt, Long-sleeve shirt, Long-sleeve sweatshirt, Long-sleeve sweater, Long-sleeve pajama top)와 하의 4개(Walking shorts, Trousers, Sweat pants, Pajama trousers)를 사용해 0.38~0.71 clo의 6가지 의복조합을 착의하며 실험을 수행하였다.

Test-bed에 다각도로 설치된 4대의 카메라 센서를 통해 15초에 1번씩 총 1,935개의 이미지를 수집하였다. 이때, 사람의 다양한 자세에서 인식률을 함께 확인하기 위해 피실험자는 수면(sleeping), 기대기(reclining), 앉기(seating), 요리(cooking), 청소(cleaning), 업무작업(typing, filing, writing) 및 걷기(walking) 등 실내에서 발생 가능한 행동을 수행하였다. 본 실험에서는 의복의 식별을 위해서 주변 사물에 의해 재실자의 의복이 가려지는 상황을 최소화하여 진행되었다.

3. CLO 산출 프로세스 단계별 모델 학습

3.1 재실자 감지 모델 학습 (Step 1)

재실자 감지 모델은 배포된 YOLOv5 모델에 추가적으로 업무환경 이미지를 전이 학습하였다. 기존 배포된 YOLOv5 모델은 분류 가능한 객체에 사람을 포함하므로 새로운 환경에서 수집된 데이터 일부를 추가하여 300 epoch 학습을 수행하였다. Test data에 대한 학습 결과를 정밀도(precision) 및 재현율(recall)의 조화평균 값인 F1 score로 평가할 경우, class에 대한 신뢰도가 0.78 수준에서 F1 score는 0.98을 나타내 1.0에 가까운 정확도 높은 수치를 보였다.

학습된 모델의 실질적인 성능을 확인하기 위해 수집된



Figure 3. Examples of person detection results

데이터 중 학습에 사용하지 않은 1일치 데이터(0:00~23:59 분)를 통해 재실자 감지 성능을 추가로 평가하였다. 카메라 센서 두 대를 통해 감지된 사람 수를 모두 합하여 전체 재실 인원을 산출하였다. 하루 동안 측정된 재실자 수 데이터의 실제값과 모델의 산출값을 비교하여 오차를 mean absolute error (MAE)와 root mean square error (RMSE)로 비교 분석하였다. MAE는 Equation (1)과 같이 정의되어 오차의 절대적 크기를 직관적으로 산출하는 지표이며, RMSE는 Equation (2)와 같이 산출되는 지표로 오차에 가중치를 부여하여 모델의 정밀도를 나타낸다. 두 지표 모두 0에 가까울수록 모델의 오차가 낮은 것을 의미한다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2)$$

where n : the number of data point (i), y : estimated value of model for data point (i) and \hat{y} : actual value for data point (i)

모델의 재실 인원 산출 결과, 전체 기간에 대하여 MAE는 0.2762, RMSE는 0.5749로 나타났다. 주요 오차를 살펴보면, 이미지가 저장될 때 순간적으로 사람이 겹치는 상황에서 1~2인 범위의 오차가 주로 발생한 것으로 확인됐다. 수집된 날짜에 재실 시간은 8:00~21:11로 확인되었으며, 재실 시간대의 오차는 MAE 0.2608, RMSE 0.3933으로 전체 기간 오차에 비해 감소함을 알 수 있다. 이는 기존 유사한 연구인 재실 인원 예측 모델(Choi et al., 2022c)의 결과와 비교했을 때, 본 연구 모델의 MAE 및 RMSE가 모두 더 낮게 나타나 비교적 정확한 재실자 감지가 가능한 것을 알 수 있다.

3.2 의복 감지 및 분류 모델 학습 (Step 2)

Step 2의 R-CLO 모델은 기존 16가지 의복 분류 성능을 향상시키기 위해 초기모델(Choi et al., 2022b)을 기반으로 전이학습을 수행하였다. 학습 데이터는 의복만 존재하는 이미지와 의복을 착용한 사람(B-box 형태) 이미지 7,068개가 사용되었으며, 총 300 epoch 학습이 수행되었다. 학습된 모델은 데이터에 과적합되지 않고 감지 및 분류 오차는 모두 0에 가깝게 수렴하였다.

학습된 모델의 분류 성능은 개별 의복의 분류 정확도로 확인하였으며, 학습 결과 16가지 의복에 대한 분류 정확도 평균 93.9%를 보였다. 가장 낮은 정확도는 “long-sleeve sweater”에서 89.0%로 나타났으며, 주로 ‘long-sleeve sweatshirt’로 분류되어 발생한 오차로 확인되었다. 이와 같이 모델의 주된 오차는 서로 유사한 형태의 의복 사이에서 나타났으며, 이는 잘못 분류된 의복과 실제 의복 사이의 단일 면적의 차이가 크지 않음을 의미한다.

즉, 이러한 의복 분류 오차가 발생하더라도 의복 단일 값 측면에서의 값 차이가 적어 결과적으로 최종 착의량 산출 오차는 적게 나타날 수 있다. 따라서, 학습된 모델을 기반으로 사람이 입고 있는 전체 착의량 측면의 성능 분석을 수행할 필요가 있다.

4. 다중 재실자의 CLO 산출 성능 분석

본 장에서는 학습된 각 모델이 모두 적용된 착의량 산출 프로세스의 성능을 평가하기 위해, 2.4장에서 설명한 Test-bed 실험 결과를 분석하였다. 실험을 통해 결과적으로 피실험자가 입고 있는 의복의 착의량 산출 정확도를 분석하고 실제 환경에 적용 가능성을 확인하고자 하였다.

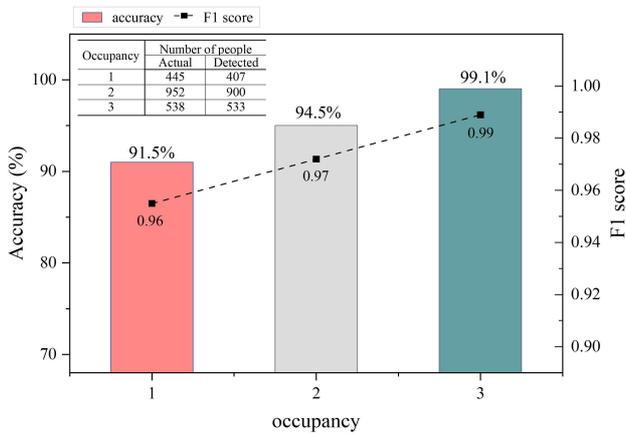


Figure 4. Performance of person detection model

실험 시 재실 인원은 단일 및 다중 재실 상황을 모두 포함시키기 위해 1~3인으로 증가시켰으며 6가지 의복조합 조건(Table 3)을 번갈아 착용하며 진행하였다.

먼저 사람 감지 성능은 재실 인원수에 따라 산출 정확도 및 F1 score 값으로 평가하였다. 그 결과, Step 1의 사람 감지 성능은 Figure 4와 같이 나타났으며, 전체 평균 95%의 정확도와 0.97의 F1 score 값을 나타냈다. 또한, 인원수가 증가함에 따라 재실자 감지 정확도와 F1 score 모두 증가하는 결과를 보이며, 동일 면적에서 재실자 밀도가 높을수록 감지 성능은 더 좋아질 수 있음을 나타냈다. Figure 5는 재실 인원수에 따른 감지 결과의 예를 나타냈다. 주요 오차로 재실자 밀도가 상대적으로 낮은 1인, 2인의 재실 환경에서는 재실자가 있음에도 감지하지 못하는 missing error가 주로 확인되었다. 하지만, 3인 재실 상황에서는 missing error는 나타나지 않았고, 오히려 창문에 반사된 사람의 잔상까지 추가로 감지하는 over detecting error가 나타났다.

Step 2에서는 감지된 사람 이미지를 입력받아 개별 의복을 감지 및 분류하고 사람이 입고 있는 의복조합을 추정하여 최종 착의량을 산출한다. 분류된 의복 정보를 토대로 각 재실자의 착의량을 산출한 결과, Figure 6과 같은 결과가 나타났다. 착의량 산출 성능은 각 의복조합 case

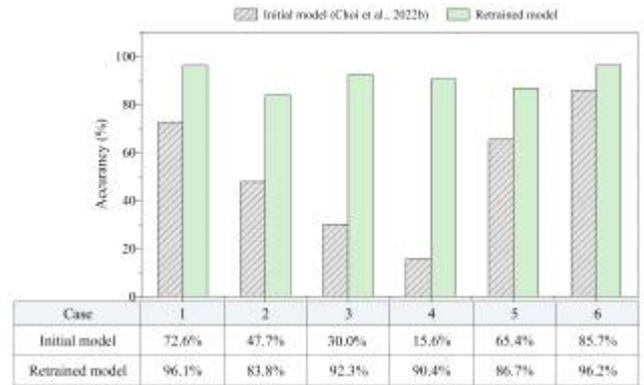


Figure 6. CLO estimation accuracy

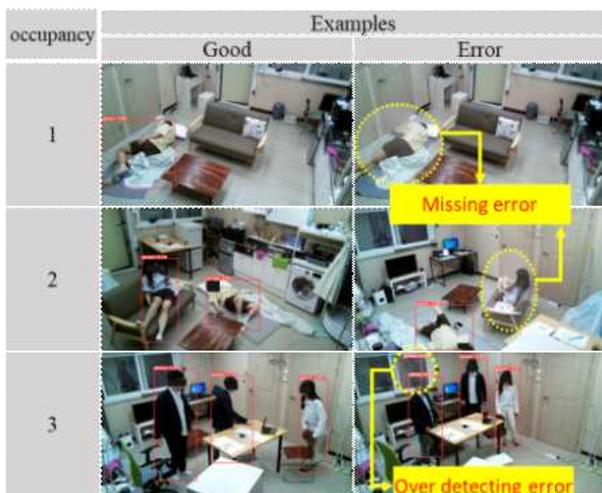


Figure 5. Examples of person detection results



Figure 7. Garments classification examples

별 착의량 산출 정확도로 평가하였으며, 학습 전 초기 모델인 R-CLO 모델(Choi et al., 2022b)과 비교하여 분석하였다. Figure 6에서 확인할 수 있듯이 새롭게 학습된 모델은 평균 91 %의 정확도를 나타냈다. 또한, 초기 모델과 비교하여 모든 의복조합 case에서 성능이 향상되었으며, 최소 10.5 %, 최대 72.8 % 향상되었다.

초기 모델의 학습 이미지는 사람뿐만 아니라 주변 배경까지 포함되는 실내 전체 이미지가 주로 포함되었기 때문에 사람만 잘린 B-box 이미지에서 성능이 떨어질 수 있다는 것을 보여준다. 동시에 추가학습을 수행한 본 연구 모델은 더 다양한 의복 이미지와 사람 B-box 이미지를 학습했기 때문에 의복 감지 및 분류 정확도가 향상됨을 알 수 있다. Figure 7은 의복조합 case별 의복 감지 및 분류 결과 예를 보여주며, 재실자의 다양한 자세에도 대부분 상의 및 하의의 위치를 정확히 감지하고 그 종류를 분류함을 알 수 있다. 결과적으로 본 실험을 통해 다중 재실자가 거주하는 환경에서 개개인의 착의량을 산출할 수 있는 방법을 검증하고 산출 가능성을 확인하였다.

5. 결 론

본 연구는 다중 인원을 대상으로 개개인의 착의량을 산출하는 새로운 프로세스를 제시하여 실제 건물에 적용 가능성을 확인하고자 하였다. 이를 위해 기존 단일 재실자 대상의 착의량 산출 방법에 재실자 감지 단계를 추가하였으며, 실험을 통해 재실 인원 에 따른 성능평가를 수행하였다. 주요 결과는 다음과 같다.

다중 재실 환경에서 개개인의 실시간 착의량 산출을 위해 재실자 감지 단계(Step 1)와 의복 감지 및 분류 단계(Step 2)가 포함된 새로운 프로세스를 제시하였다. 제시된 프로세스는 사람을 먼저 감지하고 감지된 사람이 입고 있는 의복 종류를 추정한다는 점에서 사람을 제외한 주변 배경의 영향을 최소화하여 오차 발생률을 감소시킬 수 있다.

프로세스의 각 단계별 모델은 객체검출모델인 YOLOv5 구조를 기반으로 전이학습을 수행하였다. 사람 감지 모델의 경우 학습된 업무환경의 재실시간대 사람 감지 오차가 MAE 0.2608, RMSE 0.3933으로 낮게 나타났다. 또한, 의복 감지 및 분류 모델의 경우 초기모델에서 추가로 학습을 수행하였으며, 16가지 의복에 대한 평균 분류 정확도 93.9 %를 나타냈다.

학습된 모델을 통합하여 실제 1~3인 다중 재실 환경에서 실험을 수행하였으며, 착의량 산출 성능을 확인하였다. 그 결과 재실자 감지는 평균 95 %의 정확도를 보였으며, 재실 밀도가 높아짐에 따라 정확도도 향상됨을 알 수 있다. 감지된 재실자를 토대로 착의량을 산출한 결과 모든 의복 조합 case에서 평균 91 %의 정확도를 보였으며, 기존 모델에 비해 최대 72.8 % 향상된 결과를 나타냈다.

결과적으로 본 연구는 다중 인원이 거주하는 실내 환경에서 개개인의 착의량 산출이 가능한 새로운 프로세스

를 제시하였으며, 이를 실험적으로 평가하여 실제 환경에 적용 가능성을 확인하였다. 연구 결과를 토대로 건물 쾌적 제어에 착의량을 반영하기 위해서는 제어 기간의 다중 인원을 대표하는 착의량 선정기준을 제시하는 후속 연구가 필요하다. 이러한 기준이 마련된다면 실질적으로 카메라 센서를 구역별로 구분 설치하는 방법을 통해 존별 대표 착의량을 결정할 수 있다. 결정된 착의량은 존 및 개별 제어 등 건물 시스템에 적용되어 재실환경 맞춤형 제어가 가능할 것으로 판단된다. 또한, 본 연구에서는 최대 3인 규모의 실험을 수행하여 성능을 평가하였으나 4인 이상의 사람이 거주하는 환경에서도 정확도를 확인할 필요가 있다.

제안된 방법의 실제 건물로의 적용성을 향상시키기 위해서 몇 가지 한계점 개선이 필요하다. 우선 제안된 방법은 이미지를 기반으로 착의량을 산출하기 때문에 사람의 의복 일부가 사물에 의해 가려질 경우 정확한 추정이 불가능하다. 특히, 오피스와 같은 업무 환경에서는 재실자의 하체가 책상에 의해 가려지는 현상이 자주 발생할 수 있다. 이는 카메라 센서를 다각도로 설치해 의복이 가려지는 현상을 최소화 하거나, 객체 추적 기법을 통해 재실자의 정보를 저장하여 의복이 감지되기 어려운 상황에서 해당 재실자의 과거 정보를 반영하는 방법 등 추가적인 노력이 수행되어야 한다. 또한, 실제 건물 적용 시 모델이 사용하는 이미지 정보는 저장하지 않거나 닫힌회로(closed circuit)에서만 사용하는 방법으로 개인 프라이버시 문제를 개선할 수 있을 것으로 판단된다. 이러한 한계점 개선을 위한 추가적인 노력을 토대로 착의량 산출 알고리즘을 반영한 건물 쾌적 제어가 실질적으로 수행될 수 있을 것으로 판단된다.

REFERENCES

1. ASHRAE, ANSI/ASHRAE Standard 55-2020, (2020). Thermal Environmental Conditions For Human Occupancy. Atlanta, GA.
2. Choi, E. J., Moon, J. W., Han, J. H., & Yoo, Y. (2021a). Development of a Deep Neural Network Model for Estimating Joint Location of Occupant Indoor Activities for Providing Thermal Comfort. *Energies*, 14(3), 696.
3. Choi, E. J., Park, B. R., Kim, N. H., & Moon, J. W. (2022a). Evaluation of thermal comfort by PMV-based control applying dynamic clothing insulation. *KIEAE Journal*, 22, 53-60.
4. Choi, E. J., Park, B. R., Kim, N. H., & Moon, J. W. (2022b). Effects of thermal comfort-driven control based on real-time clothing insulation estimated using an image-processing model. *Building and Environment*, 223, 109438.
5. Choi, H., Na, H., Kim, T., & Kim, T. (2021b). Vision-based estimation of clothing insulation for building control: A case study of residential buildings. *Building and Environment*, 202, 108036.

6. Choi, Y. J., Park, B. R., Hyun, J. Y., & Moon, J. W. (2022c). Development of Occupancy Prediction Model and Performance Comparison According to the Recurrent Neural Network Models, *Journal of the Architectural Institute of Korea*, 38, 10.
7. De Giuli, V., Da Pos, O., & De Carli, M. (2012). Indoor environmental quality and pupil perception in Italian primary schools. *Building and Environment*, 56, 335-345.
8. Fanger, P.O. (1970). Thermal comfort. Analysis and applications in environmental engineering. *Copenhagen: Danish Technical Press*.
9. Girshick, R. (2015). Fast r-cnn. *In Proceedings of the IEEE international conference on computer vision*. 1440-1448.
10. Jang, H., & Suh, S. (2013). Analysis of Indoor Thermal Environment and Energy Consumption in Office Building Controlled by PMV. *Journal of the Korean Solar Energy Society*, 33(4), 15-22.
11. Joher, G., Nishimura, K., Mineeva, T., & Vilarino, R. (accessed May 2020), YOLOv5, <https://ultralytics.com/yolov5>.
12. Jung, W., & Jazizadeh, F. (2019). Comparative assessment of HVAC control strategies using personal thermal comfort and sensitivity models. *Building and Environment*, 158, 104-119.
13. Karyono, K., Abdullah, B. M., Cotgrave, A. J., & Bras, A. (2020). The adaptive thermal comfort review from the 1920s, the present, and the future. *Developments in the Built Environment*, 4, 100032.
14. Konarska, M., Soltynski, K., Sudol-Szopinska, I., & Chojnacka, A. (2007). Comparative evaluation of clothing thermal insulation measured on a thermal manikin and on volunteers. *Fibres and Textiles in Eastern Europe*, 15(2), 73.
15. Lee, J. H., Kim, Y. K., Kim, K. S., & Kim, S. (2016). Estimating clothing thermal insulation using an infrared camera. *Sensors*, 16(3), 341.
16. Lee, K., Choi, H., Kim, H., Kim, D. D., & Kim, T. (2020). Assessment of a real-time prediction method for high clothing thermal insulation using a thermoregulation model and an infrared camera. *Atmosphere*, 11(1), 106.
17. Lin, T., Goyal, P., Girshick, R., He, K., Dollár, P. (2017). Focal Loss for Dense Object Detection, [arXiv:1708.02002](https://arxiv.org/abs/1708.02002)
18. Liu, J., Foged, I. W., & Moeslund, T. B. (2022). Automatic estimation of clothing insulation rate and metabolic rate for dynamic thermal comfort assessment, *Pattern Analysis and Applications*, 25(3), 619-634.
19. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., & Berg, A. C. (2015). SSD: Single Shot MultiBox Detector, [arXiv:1512.02325](https://arxiv.org/abs/1512.02325)
20. Lu, S., Hameen, C. E., & Aziz, A. (2018, January). Dynamic hvac operations with real-time vision-based occupant recognition system. *In 2018 ASHRAE Winter Conference*, Chicago.
21. Matsumoto, H., Iwai, Y., & Ishiguro, H. (2011, June). Estimation of Thermal Comfort by Measuring Clo Value without Contact. *In MVA* (pp. 491-494).
22. Miura, J., Demura, M., Nishi, K., & Oishi, S. (2020). Thermal comfort measurement using thermal-depth images for robotic monitoring. *Pattern Recognition Letters*, 137, 108-113.
23. Pang, Z., Chen, Y., Zhang, J., O'Neill, Z., Cheng, H., & Dong, B. (2021). Quantifying the nationwide HVAC energy savings in large hotels: the role of occupant-centric controls. *Journal of Building Performance Simulation*, 14(6), 749-769.
24. Pang, Z., Zhang, J., Chen, Y., Cheng, H., O'Neill, Z., & Dong, B. (2020). Nationwide Energy Saving Analysis for Office Buildings with Occupant Centric Building Controls. *ASHRAE Transactions*, 126(2).
25. Park, B. R., Choi, E. J., Choi, Y. J., & Moon, J. W. (2022). Development an image recognition-based clothing estimation model for comfortable building thermal controls, *Journal of the Architectural Institute of Korea*. 38, 8.
26. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection, [arXiv:1506.02640](https://arxiv.org/abs/1506.02640)
27. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
28. Sung, W. T., & Hsiao, S. J. (2020). The application of thermal comfort control based on Smart House System of IoT. *Measurement*, 149, 106997.
29. Wu, J., Li, X., Lin, Y., Yan, Y., & Tu, J. (2020). A PMV-based HVAC control strategy for office rooms subjected to solar radiation. *Building and Environment*, 177, 106863.
30. Xie, J., Li, H., Li, C., Zhang, J., & Luo, M. (2020). Review on occupant-centric thermal comfort sensing, predicting, and controlling. *Energy and Buildings*, 226, 110392.
31. Yang, T., Bandyopadhyay, A., O'Neill, Z., Wen, J., & Dong, B. (2021). From occupants to occupants: A review of the occupant information understanding for building HVAC occupant-centric control. *In Building Simulation*. Tsinghua University Press. 1-20.

(Received Dec. 21, 2022/ Revised Jan. 18, 2023/ Accepted Jan. 25, 2023)