



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](#)

第 130 回 碩士學位論文  
指導教授 文 鎮 宇

딥러닝 기반 재실자 포즈별  
MET 산출모델 개발

Development of Deep Learning Model  
for Estimating MET of Occupant Pose

中央大學校 大學院  
建築學科 建築環境計畫專攻  
崔 恩 智  
2019年 2月

딥러닝 기반 재실자 포즈별

MET 산출모델 개발

Development of Deep Learning Model  
for Estimating MET of Occupant Pose

이 論文을 碩士學位論文으로 提出함

2019年 2月

中央大學校 大學院

建築學科 建築環境計畫專攻

崔 恩 智

# 崔恩智의 碩士學位論文으로 認定함

審查委員長 \_\_\_\_\_ (印)

審查委員 \_\_\_\_\_ (印)

審查委員 \_\_\_\_\_ (印)

中央大學校 大學院

2019年 2月

# 목 차

제 1 장 서론 .....	1
1.1 연구의 배경 및 목적 .....	1
1.2 연구의 범위 및 방법 .....	5
제 2 장 PMV 기반 열환경 쾌적 조성 .....	7
2.1 PMV 기반 실내환경 제어 .....	7
2.2 PMV 제어를 위한 MET 산출 방법 .....	8
제 3 장 딥러닝 이론 고찰 .....	12
3.1 인공지능망 및 딥러닝 개요 .....	12
3.2 딥러닝 학습 .....	17
3.3 건축 분야의 인공지능망 및 딥러닝 적용 연구 동향 .....	20
제 4 장 딥러닝 기반 MET 산출모델 개발 .....	25
4.1 학습 이미지 데이터 .....	25
4.2 인체 관절인식 선행 모델 .....	34
4.3. MET 산출모델 개발 .....	40
제 5 장 MET 산출모델 최적화 및 성능 평가 .....	53
5.1 MET 산출모델의 성능 평가 방법 .....	53
5.2 MET 산출모델 성능 평가 .....	58

5.2.1 은닉층 구조에 따른 모델 성능 평가 .....	58
5.2.2 MET 값에 따른 모델 성능 평가 .....	59
5.3 소결 .....	64
제 6 장 결론 .....	66
참고문헌 .....	70
국문초록 .....	75
ABSTRACT .....	77

## 표 목 차

Table 1. PMV 변수 및 쾌적도 .....	2
Table 2. 재실자 MET 측정 연구 고찰 .....	10
Table 3. 퍼셉트론 다이어그램 .....	14
Table 4. 활성화 함수 종류 및 수식 .....	15
Table 5. 대표적인 딥러닝 모델 종류 및 특징 .....	19
Table 6. 학습 데이터 실내활동 구성 및 MET .....	28
Table 7. ‘Resting’의 실내활동 이미지 구축 예시 .....	29
Table 8. ‘Office Activities’의 실내활동 이미지 구축 예시 .....	30
Table 9. 인체 관절 좌표 추출 및 Boxing 방법 .....	32
Table 10. 데이터 Augmentation 기법 적용 .....	34
Table 11. MET 산출모델 파라미터 설정 .....	42
Table 12. Case 1의 은닉층 구조 설정 .....	46
Table 13. Case 2의 은닉층 구조 설정 .....	46
Table 14. Case 3의 은닉층 구조 설정 .....	47
Table 15. Case 4의 은닉층 구조 설정 .....	47
Table 16. Case 5의 은닉층 구조 설정 .....	47
Table 17. MET 산출모델의 은닉층 구조별 평균 정확도 .....	59
Table 18. PMET 산출모델의 은닉층 구조별 최대 정확도 .....	59
Table 19. MET 값에 따른 Case 5-b 모델의 오차행렬 .....	61
Table 20. MET 값에 따른 Case 5-b 모델의 PPV, TPR, F1 Score .....	61
Table 21. AUC 면적에 따른 알고리즘 성능 기준 .....	63

## 그림 목차

Fig. 1 연구 진행 과정 .....	6
Fig. 2 딥러닝 모델의 기본 구조 .....	17
Fig. 3 역전파 알고리즘 개념도 .....	18
Fig. 4 연도별 건축분야의 신경망 적용 연구동향 .....	21
Fig. 5 건축 분야의 주제별 신경망 적용 연구동향 .....	22
Fig. 6 학습 데이터셋 구축 과정 .....	26
Fig. 7 이미지 스케일 조정 방법 .....	34
Fig. 8 Mask R-CNN의 재실자 감지 .....	36
Fig. 9 Residual Block 구조 .....	38
Fig. 10 관절 인식모델 구조 .....	39
Fig. 11 MET 산출모델의 기본 구조 .....	41
Fig. 12 실내활동 데이터셋 분류 .....	49
Fig. 13 학습모델 구조 설정 .....	49
Fig. 14 모델 파라미터 설정 .....	50
Fig. 15 Train data set 분류 정확도 변화율 .....	51
Fig. 16 Train data set의 오차 변화율 .....	51
Fig. 17 Valid data set 분류 정확도 변화율 .....	52
Fig. 18 Valid data set의 오차 변화율 .....	52
Fig. 19 5-fold 교차검증 Train data set 구성 .....	54
Fig. 20 B 클래스 분류기 오차행렬 .....	55
Fig. 21 ROC 커브 및 AUC 예시 .....	57
Fig. 22 MET = 0.7 ROC curve .....	63
Fig. 23 MET = 0.8 ROC curve .....	63
Fig. 24 MET = 1.0 ROC curve .....	63
Fig. 25 MET = 1.1 ROC curve .....	63
Fig. 26 MET = 1.2 ROC curve .....	64
Fig. 27 MET = 1.4 ROC curve .....	64

Fig. 28 MET = 1.7 ROC curve ..... 64  
Fig. 29 추후 MET 산출모델의 PMV 제어 시 적용 방법 ..... 68  
Fig. 30 PMV 제어 알고리즘의 MET 대푯값 산출 방법 예시 ..... 69

# 제 1 장 서 론

## 1.1 연구의 배경 및 목적

건축은 에너지 소비, 자원소비, CO<sub>2</sub> 배출 등 자연과 기후변화에 크게 영향을 미치는 분야이다.<sup>1)</sup> 따라서, 친환경 건축에 대한 필요성과 관심을 바탕으로 지속적 기술 개발이 이루어지고 있다. 친환경 건축에 대한 평가를 위하여 국내의 경우 친환경건축물 인증제도(Green Building Certification Criteria, GBCC)가 마련되어 있고 국외는 미국의 LEED (Leadership in Energy and environmental Design), 영국의 BREEAM (Building Research Establishment Environmental Assessment Method) 등의 제도가 국가별로 개발되었다.<sup>2)</sup> 이러한 친환경 인증제도는 공통적으로 건물 실내환경(Indoor Environment Quality, IEQ)에 대한 평가가 포함되어 있으며, 이는 쾌적한 건물 실내환경이 장기적으로 재실자의 건강, 생산성 및 삶의 질 향상과 건물의 운영 및 유지 보수비용 감소 등의 이점을 가져올 수 있기 때문으로 볼 수 있다.

건물 실내환경을 결정하는 요소는 온도, 습도, 기류 등을 고려하는 열환경(Thermal Quality)을 비롯하여 실내 공기 오염 정도를 나타내는 실내 공기질(Indoor Air Quality, IAQ), 빛환경(Light Quality), 음환경(Acoustic Quality)으로 구성된다. 이 중 실내 열환경은 실내환경을 결정하는 중요한 요소로서 재실자가 실내 환경으로부터 느끼는 열쾌적(Thermal Comfort)에 대한 만족도를 의미한다. 이러한 재실자의 열쾌적 만족도를 평가하기 위해 재실자의 열쾌적 상태를 통계적으로 처리한 지표를 열쾌적지표

---

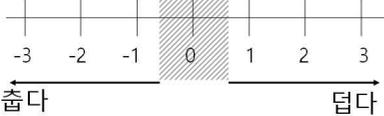
1) 녹색건축인증. (2018.11). 인증제도 개요, <http://gseed.greentogether.go.kr/sys/cis/actionVerifyOuln.do>

2) 박진철. (2012). 국내·외 친환경건축물 인증제도 비교분석 연구. 부동산 FOCUS 통권, 15호, 29-42.

(Thermal Comfort Index)라 한다. 열쾌적지표에는 불쾌지수(DI; Discomfort Index), 유효온도(ET; Effective Temperature), 작용온도(OT; Operative Temperature), 신유효온도(ET\*; New Effective Temperature), 평균온열감(Predictive Mean Vote, PMV) 등이 있다.

이 중 PMV는 1970년 P.O. Fanger에 의해 제안된 열쾌적지표로 다른 평가 지표와 달리 열환경에 영향을 미치는 6가지 온열 요소를 모두 고려하여 열쾌적을 평가한다. 6가지 온열 요소는 사람 주변의 환경적 변수인 온도, 습도, 기류속도 및 평균복사온도(MRT)와 개인적 변수인 활동량(Metabolic Rate, MET)과 착의량(Clothing Insulation, CLO)으로 구성된다. 이러한 통합 열쾌적지표인 PMV는 국제 표준 ISO 7730<sup>3)</sup>으로 채택되어 사용되고 있다.<sup>4)5)</sup> PMV 값은 열적으로 중립인 상태를 0으로 하고 -3(cold) ~ 3(hot)의 7단계의 수치 척도로 재실자의 쾌적감을 정량적으로 제시하고 있으며 ISO에 제시된 국제 쾌적 만족 기준은  $-0.5 < PMV < 0.5$ 의 범위이다. (Table 1)

Table 1. PMV 변수 및 쾌적도

분류	PMV 영향 요소	PMV 쾌적도
환경적 변수	온도, 습도, 기류속도, 평균복사온도	$-0.5 < \text{쾌적범위} < 0.5$ 
개인적 변수	활동량(MET), 착의량(CLO)	

3) ISO 7730, Ergonomics of the thermal environment, 2005.

4) Fanger, P.O., 1970, Thermal Comfort, Copenhagen: Danish Technical Press.

5) 건축환경공학, 2004, 김재수, 도서출판 서우, 제8-159호

기존에 실내 열환경을 제어하기 위한 일반적으로 사용하던 방법은 실내 공기 온도 및 습도 조절을 통한 제어로 개인적 요소를 고려하지 않는다. 이때, PMV의 개인적 요소는 0.8~4.0 MET, 0~2 CLO의 적용 범위를 가지므로 온습도만으로 제어할 경우 개인적 요소의 차이가 발생할 가능성이 커서 통합적인 PMV 측면에서 쾌적하지 않을 수 있다. 예를 들어 여름철 사무실 건물에 대해 실내 온도 26도, 습도 40%로 실내 적정 온습도 범위를 만족하더라도 사무실에서 발생할 수 있는 MET 1.4(서서 서류작업), CLO 0.96(셔츠 및 자켓)일 때 PMV는 1.04로 PMV의 쾌적범위(-0.5~0.5)를 벗어난다. 즉, 기존의 온도 및 습도 제어와 같이 개인적 요소를 고려하지 않는다면 PMV 쾌적 기준 범위를 벗어날 수 있다는 한계가 있다.

이에 반해 PMV 기반 제어법은 온도 습도뿐만 아니라 기류속도, MRT, MET, CLO와 같은 열적 요소를 모두 고려하기 때문에 기존의 온습도 기반 제어보다 세밀하고 개인화된 열환경 조성이 가능하며 실내환경의 쾌적 만족도가 높게 측정될 수 있다.<sup>6)</sup>

하지만 PMV 제어는 개인적 요소의 정확한 측정이 수반되어야 한다. 실내 온열 쾌적을 위한 연구 중 김상훈<sup>7)</sup>은 하절기와 동절기 PMV 변화에 가장 큰 영향을 미치는 요소가 재실자의 MET인 것을 밝혔다. 이에 따라 실제 PMV를 정확하게 산출하기 위해 개인적 요소 중 영향력이 큰 MET 측정이 필요하다. 재실자의 MET 측정에 있어 기존의 보편적인 적용방법은 재실자의 행동을 일반화한 후 가정하여 고정된 MET 값을 사용하는 것이다. 예를 들어 사무실 건물의 경우 실내에서 발생 가능한 1.2 MET(앉아서 작업)를 고정 값으로 가정할 수 있다. 하지만, 실제 MET는 이러한 고정된 값과 달리 다양한 값을 가질 수 있고 그 결과 실제 재실자 PMV는

6) 문진우. (2011). PMV, TS 기준 건물 열 환경 제어법의 성능 및 적용성 분석. 설비공학논문집, 23(6), 430-440.

7) 김상훈. (2015). 실내 온열 쾌적을 위한 PMV단순화 제어 프레임워크 개발, 서울과학기술대학교, 박사학위논문

고정 MET 값을 사용하여 산출된 PMV와 일치하지 않다는 문제점이 있다.

고정된 MET 값 적용의 한계 해결을 위해 MET를 측정하는 방법이 개발되었다. 기존에는 MET의 측정을 심박동기<sup>8)</sup>를 직접적으로 부착하거나 스마트폰<sup>9)</sup>을 사용하는 등 기기를 사용하여 재실자의 부가적인 정보를 간접적으로 측정하는 방법을 적용했다. 간접적인 MET 측정은 오차가 발생할 가능성이 높고 정확도 향상에 한계가 있다. 또한 측정된 MET를 사용하는 PMV 역시 오차가 발생하게 된다. 따라서 실내 환경 제어 시 PMV를 직접적으로 적용하지 못하고 실내 쾌적을 평가하는 수단으로만 제한적으로 사용되었다.

그러므로 PMV를 제어의 수단으로 사용하기 위해서 재실자의 정확한 MET를 산출할 필요가 있다. 정확한 MET 산출을 위해서 기존의 가정된 MET 값을 적용하는 방법이 아닌 재실자의 실제 행동인식을 바탕으로 MET를 도출하는 근본적이고 건물 내재적인 방법 개발이 필요하다. 근본적인 MET 측정은 인간이 판단하는 것처럼 재실자의 행동을 인식해서 실내활동을 구분할 수 있는 방법을 의미한다.

따라서 본 연구에서는 실제 재실자의 행동을 판단하는 역할을 수행할 수 있는 지능형 대리(Intelligent Agent) 모델인 딥러닝(Deep Learning, DL) 알고리즘을 사용하여 MET 산출모델을 개발하였다. MET 산출의 과정은 실내에 설치된 카메라 센서를 통해 수집되는 재실자의 이미지를 학습하여 인체의 관절을 인식하고 인식된 관절을 기반으로 재실자의 포즈와 MET를 산출하게 된다. 이때 재실자의 이미지를 통해 인체 주요 관절을 인식하여 관절 좌표 값을 추출하는 작업은 선행 모델인 관절 인식모델에

---

8) 이호기, 김현희, 이경창, 이석. (2008). 스마트 홈을 위한 심박동 기반 냉난방 제어 시스템. 제어로봇시스템학회 국내학술대회 논문집, 432-435.

9) 이혜진. (2016). PMV 기반 냉난방 제어시스템을 위한 사용자 활동량 측정 및 IoT 센서 데이터 결합 프레임워크, 아주대학교 석사학위논문

서 수행된다. MET 산출모델은 재실자의 행동에 따른 관절 좌표를 학습하고 재실자가 취하는 포즈를 판단하여 포즈에 해당하는 MET를 산출한다. 개발된 MET 산출모델은 재실자 MET 측정의 근본적인 방법을 제공하며 추후 PMV 예측 제어를 위한 기반을 형성한다.

## 1.2 연구의 범위 및 방법

본 연구는 개인 맞춤형 PMV 제어를 위해 재실자의 개인적 요소 중 MET를 산출하는 지능형 모델을 개발하였다. 개발된 모델은 추후 실제 PMV 계산에 적용될 수 있으며, 계산된 실제 PMV에 근간하여 쾌적한 실내 환경 제어가 가능할 것으로 사료된다.

본 연구의 MET 산출모델 개발 과정은 Fig.1과 같다. 먼저 연구의 첫 번째 단계는 실내 환경 변수와 재실자의 이미지를 수집하는 IoT 기반 MET 복합센서모듈 구축이다. 복합센서모듈은 오픈소스 플랫폼(Open-source Platform)인 라즈베리 파이(Raspberry Pi) 및 아두이노(Arduino)로 구성된다. 이 모듈은 실내 온도, 습도, 기류속도, 평균복사온도를 측정할 수 있는 센서를 통해 환경변수를 측정하고 PMV 계산에 직접 적용된다. 또한 모듈의 카메라 센서를 이용하여 재실자의 이미지가 수집된다.

두 번째 단계는 MET 산출모델로 카메라 센서를 이용해 수집된 재실자의 이미지를 통해 재실자의 포즈 및 MET를 산출하며 딥러닝 알고리즘을 적용하였다. MET 산출모델의 선행 연구로 개발된 관절 인식모델은 재실자의 실내활동 이미지에서 사람의 관절 좌표를 인식하여 추출하는 모델이며 한지훈<sup>10)</sup>의 선행 연구를 통하여 개발되었다. MET 산출모델은 선행 모델의 결과로 출력되는 인식된 관절의 좌표 값을 사용하여 사람의 포즈 및 MET

---

10) 한지훈, 최은지, 문진우, 유용석. (2018). 심층신경망 기반 재실자 이미지 학습을 통한 인체 관절 인식 모델 개발. 한국생활환경학회 추계학술대회 논문집. 47-48

를 산출한다.

개발된 MET 산출 모델은 추후 진행되는 관절 인식모델과 결합을 통해 MET를 산출하는 통합 모델이 되어 PMV 예측 제어 알고리즘의 기반을 형성한다. 이렇게 실제 MET를 산출하여 PMV에 적용할 경우 보다 쾌적한 실내환경 조성이 가능해지고 재실자의 생산성 향상 등의 기대효과가 있다.

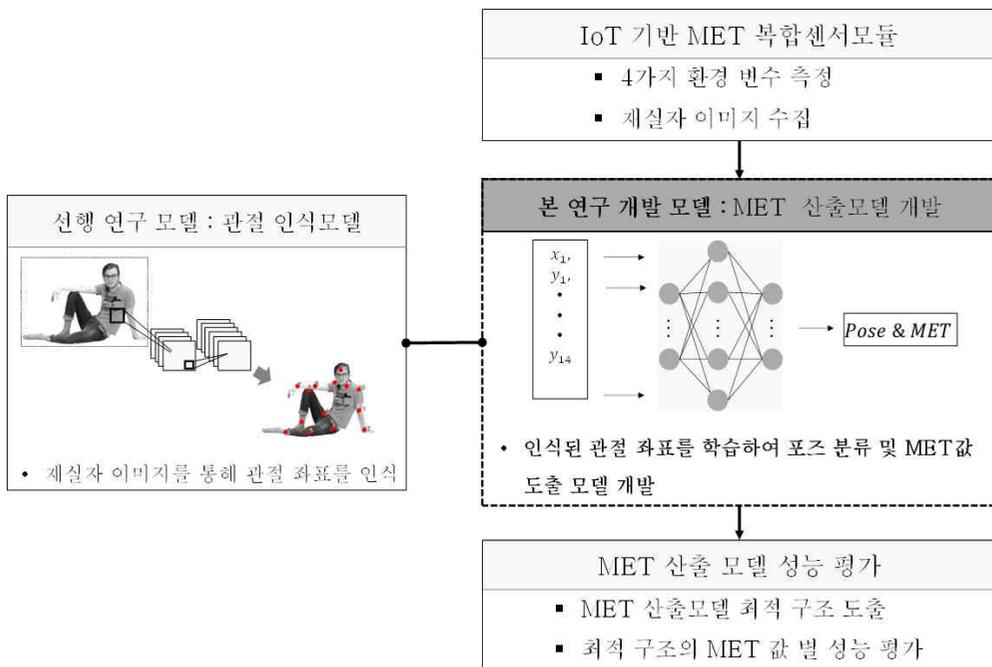


Fig. 1 연구 진행 과정

## 제 2 장 PMV 기반 열환경 쾌적 조성

### 2.1 PMV 기반 실내환경 제어

기존 실내환경 제어 방법인 온도 및 습도 제어는 개인적 요소를 고려하지 않아 PMV의 쾌적 범위를 불만족 할 경우가 발생한다. 이와 같은 온도 및 습도 제어의 한계 해결을 위해 6가지 환경 및 개인적 요소를 모두 고려하는 PMV 기반의 실내환경 제어가 필요하다.

이에 따라 열쾌적 측면에서 우수한 PMV를 사용한 제어법의 개발 및 적용과 관련된 연구가 지속적으로 진행되고 있다. 김성경(2017)<sup>11)</sup>은 온습도, CO<sub>2</sub>, PMV 및 엔탈피(Enthalpy)로 구성된 다양한 실내 지표를 평가하여 거주자의 쾌적감과 에어컨의 운전 패턴을 분석하였다. 그 결과 물리적 환경을 고려하는 PMV를 기준으로 제어할 경우 가장 높은 쾌적성을 보이는 것을 확인했다. PMV 제어의 경우 쾌적성을 향상시킬 뿐만 아니라 에너지 저감에도 효과를 미친다. 성남철(2010)<sup>12)</sup>은 난방기 공동주택의 온도 제어와 PMV 제어에 따른 실내 환경 및 에너지 소비를 비교한 결과 PMV 제어는 사람의 쾌적 상태를 유지할 뿐만 아니라 일반적인 온도 기반 제어보다 난방에너지를 절약할 수 있다는 것을 밝혔다. 또한 PMV 제어의 에너지 측면에서 장향인(2013)<sup>13)</sup>은 중앙공조방식의 사무소를 대상으로 온도 제어와 PMV 제어에 따른 실내 온열 환경과 냉난방 에너지 소비 특성을 비교하는

---

11) 김성경, 홍원화, 류지혜. (2017). 공동주택 내 온열환경 제어기준을 통한 냉방기기 운전 시 거주자 쾌적성에 관한 연구. 대한건축학회 논문집 - 구조계, 33(11), 43-52.

12) 성남철, 윤동원. (2010). 공동주택에서 쾌적지표를 활용한 난방제어 시 온열환경 변화와 에너지소비 특성에 관한 연구. 한국생활환경학회지, 17(6), 758-765.

13) 장향인, 서승직. (2013). PMV 제어에 따른 사무소 건물의 실내열환경과 에너지소비량 분석. 한국태양에너지학회 논문집, 33(4), 15-22.

연구를 진행하였다. PMV 제어의 경우 온도 외에도 다른 쾌적 인자가 반영되어 온도제어에 비해 실내 쾌적 구간 분포 비율이 높게 나타나는 것을 확인하였다. 또한, 설정온도를 PMV 제어 때의 재실자 열 쾌적 빈도와 비슷하도록 조절한 온도 제어와 PMV 제어를 비교했을 때, PMV 제어의 난방 에너지 사용량이 6.1% 낮게 나타났다. 이처럼 에너지 소비 측면에서 PMV 제어의 우수함을 밝혀 PMV 제어를 통한 공조존 제어의 효과와 활용 가능성을 확인하였다. 이와 같이 PMV의 제어를 통해 실내 쾌적 범위 만족 및 에너지 저감의 가능성을 확인하는 연구가 다수 존재했다.

하지만, 미국 공기조화냉동공학회인 ASHRAE(American Society of Heating, Refrigerating and Air-Conditioning Engineers)에서 PMV 모델의 산출 값이 CLO, MET 및 열환경에 대한 개인의 심리적 태도 등에 의해 실생활에서 재실자가 느끼는 쾌적감과 오차가 발생한다는 점을 밝혔다.<sup>14)15)</sup> 이러한 오차는 기존에 PMV를 산출할 경우 재실자의 개인적 요소를 가정된 값을 사용하여 발생되었다. 따라서, PMV 기반 제어를 위해서는 재실자의 개인적 요소로 인한 PMV 산출 오차를 줄여야 한다.

## 2.2 PMV 제어를 위한 MET 산출 방법

PMV 기반의 제어를 통해 실내 쾌적 제어를 하기 위해서 재실자의 MET 및 CLO와 같은 개인적 요소의 정확한 측정의 필요성이 제기되었다. 재실자의 개인적 요소 중 MET는 PMV 산출에 미치는 영향이 크며<sup>16)</sup> MET의 정확한 측정의 필요성은 홍성협<sup>17)</sup>의 연구에 의해서도 확인된 바 있다. 이 연

---

14) Humphreys, M.A. & Nicol, J.F., (2002), The validity of ISO-PMV for predicting comfort votes in every-day thermal environments, Energy and Buildings, Vol. 34, pp. 667-684

15) 윤근영. (2015). 실내환경 쾌적 제어와 건물 에너지. 설비저널, 44(8), 24-30.

16) 김상훈. op. cit., p 3

17) 홍성협, 도성록, 이광호. (2018). 아파트 건물에서 재실자 활동량이 고려된 PMV제어에

구에서는 아파트 건물에서 발생할 수 있는 실내활동 MET를 취침상태(MET 0.7)부터 청소상태(MET 3.4)의 범위로 Energy Plus 시뮬레이션에 스케줄을 적용하여 PMV 제어와 건구온도 제어의 쾌적 범위 만족에 대한 비교를 실시하였다. 건구온도 제어의 경우 PMV 값이 최소 0, 최대 1.5로 쾌적 범위를 벗어나는 경우가 많았고 대부분의 시간대에서 재실자의 쾌적성을 만족시키지 못하였다. 하지만 MET의 변화를 적용한 PMV 제어 결과 여름철과 겨울철 모두 재실자가 쾌적함을 느끼는 -0.5~0.5 사이의 값을 나타내며 쾌적성을 만족시켰다. 홍성협<sup>18)</sup>의 또 다른 연구에서는 시간에 따른 MET를 고려한 PMV 제어시 실제 열 부하, 에너지 사용 및 생애주기 비용(Life Cycle Cost, LCC)에 대한 효과를 조사하였다. 분석을 위해 실내에서 요구되는 온도 차이를 확인하였고 결과적으로 MET를 고려한 PMV 제어시 건구온도 제어와 비교하여 난방에너지는 7.3%, 냉방에너지는 28.8% 저감이 가능했다. 이와 같은 연구 결과에 의해 MET의 정확한 측정이 가능하다면 효과적인 PMV 통합제어가 가능하다는 점을 입증하였다. 따라서 재실자의 MET를 정확하게 측정할 수 있는 기술 개발이 필요하다.

기존의 고정된 MET 값을 적용하는 한계를 극복하고 재실자가 나타내는 실제 MET 산출을 위한 연구가 진행되고 있다. Table 2와 같은 재실자 MET의 측정에 관한 기존의 연구가 수행되었다. Hasan과 이해진은 웨어러블 기기를 사용한 MET 측정 방법을 제시하였고 김현희는 재실자의 맥박, 이호기는 심박동기를 사용하여 MET를 측정하였다.

---

다른 연간 국가 차원의 1차 에너지 및 온실가스 감축량 분석, 대한건축학회논문집, 34(10), 37-44.

18) Hong, S., Lee, J., Moon, J., & Lee, K. (2018). Thermal Comfort, Energy and Cost Impacts of PMV Control Considering Individual Metabolic Rate Variations in Residential Building. *Energies*, 11(7), 1767.

Table 2. 재실자 MET 측정 연구 고찰

저자	내용
Hasan <sup>19)</sup>	웨어러블 기기를 사용하여 실시간 MET의 지속적인 피드백을 받음
김현희 <sup>20)</sup>	심전도 센서를 통해 맥박을 측정하여 실시간 재실자의 MET 측정
이호기 <sup>21)</sup>	심박동기를 재실자의 인체에 부착하여 MET를 측정
박은주 <sup>22)</sup>	Zigbee 모듈을 사용하여 재실자의 위치를 파악
이혜진 <sup>23)</sup>	스마트폰 및 웨어러블 디바이스의 복합 센서 (가속도, 압력, 소음 등) 데이터를 활용하여 재실자의 MET를 파악

기존 MET 측정 방법의 분석결과 주로 다양한 센서와 기기를 기반으로 간접적 방법을 사용하고 있으며 재실자의 활동에 따른 속도, 소음, 위치 등 부수적인 정보를 측정하였다. 하지만 이러한 기존의 측정 방법은 MET 산출에 있어서 근본적 접근 방법인 재실자의 행동을 구분하는 것이 아니며 본질적 목적에서 벗어난다. 또한 기기나 재실자의 부수적인 정보

19) Hasan, M. H., Alsaleem, F., & Rifaie, M. (2016). Sensitivity study for the PMV thermal comfort model and the use of wearable devices biometric data for metabolic rate estimation. *Building and Environment*, 110, 173-183.

20) 김현희, 이경창, 이석. (2014). 인간 적응형 가전기기를 위한 거주자 심박동 기반 신체활동량 추정. *제어로봇시스템학회 논문지*, 20(5), 486-494.

21) 이호기, 김현희, 이경창, 이석. (2008). 스마트 홈을 위한 심박동 기반 냉난방 제어 시스템. *제어로봇시스템학회 국내학술대회 논문집*, 432-435.

22) 박은주, 김현희, 이경창, 이석. (2010). 인간 적응형 냉난방기를 위한 ZigBee 위치 기반 신체활동량 추정 알고리즘. *한국정밀공학회 학술발표대회 논문집*, 763-764.

23) 이혜진. (2016). PMV 기반 냉난방 제어시스템을 위한 사용자 활동량 측정 및 IoT 센서 데이터 결합 프레임워크. *아주대학교 석사학위논문*

에 의존하는 간접적인 MET 산출은 오차가 발생하고 정확도 향상에 한계가 있어 PMV 제어의 적용에 제한적이다. 이러한 한계를 개선하기 위해서는 재실자의 부수적인 정보 없이도 행동을 구분하고 MET를 산출할 수 있는 근본적인 MET 산출 방법이 필요하다.

따라서 재실자의 실내 이미지를 통해 행동을 구분하여 MET를 산출하는 방법 개발을 위해 본 연구에서는 딥러닝 MET 산출 모델을 제시하였다. 개발 모델은 실내에서 활동하는 재실자의 이미지를 학습하여 실내활동 포즈를 분류하고 포즈에 해당하는 MET를 산출한다. 이는 기존 측정 방법의 한계를 보완하고 실제 재실자의 행동을 판단 및 분류할 수 있는 방법으로써 PMV 제어에 사용될 MET를 산출 할 수 있다.

## 제 3 장 딥러닝 이론 고찰

### 3.1 인공신경망 및 딥러닝 개요

인공신경망(Artificial Neural Network, ANN)은 생물학적 신경망에서 영감을 얻은 학습 알고리즘으로 머신러닝(Machine Learning, ML)의 일종이다. 다시 말해서 인간의 뇌에서 발생하는 신경망의 문제해결 처리 과정을 유사하게 구현한 수학 모델이다. 인공신경망의 가장 큰 특징은 주어진 데이터의 정보를 스스로 학습하여 해결한다는 것이며 문제를 해결하는 능력이 강력하고 다양한 데이터를 다룰 수 있는 확장성이 좋다. 따라서 기존의 머신러닝으로 해결하지 못했던 이미지 분류, 음성 인식 서비스, 자연어 처리, 비디오 추천 등 대규모 데이터를 처리하는 문제를 다루기에 적합하다.<sup>24)</sup>

초기 인공신경망은 1943년 Warren McCulloch와 Walter Pitts에 의해 처음 제안되며 시작되었다. Warren과 Pitts는 단순한 이진(Binary) 입력 및 출력을 가지도록 구현한 모델인 인공 뉴런 네트워크를 개발하여 어떤 논리 명제도 계산 할 수 있다는 것을 보여줬다.<sup>25)</sup> 초기 신경망의 개발 후 1949년 Donald Hebb는 뉴런의 시냅스에서 일어나는 상관 학습을 발견하여 신경망의 학습 규칙을 개발하였다.<sup>26)</sup> 이를 토대로 신경망을 학습하는 것이 가능하다는 사실이 밝혀졌고 헤브의 규칙(Hebb's rule)이라는 신경망 모델의 학습 규칙에 대한 기반이 형성되었다. 헤브의 규칙을 기반으로

---

24) Aurélien, G. (2017). Hands-On Machine Learning with Scikit-Learn & TensorFlow. O'Reilly Media.

25) McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 5(4), 115-133.

26) Hebb, D. O. (1949). The organization of behavior

1957년 가장 간단한 인공신경망 구조인 퍼셉트론(Perceptron)이 제안되었고 인공신경망의 발전의 시발점이 되었다.

퍼셉트론은 간단한 단층 퍼셉트론과 여러 문제해결을 위한 다층 퍼셉트론으로 발전되었다. 단층 퍼셉트론은 인간의 신경세포(뉴런, Neuron)를 모사한 것으로 입력층 및 출력층의 구조를 가지며 노드(Node), 가중치(Weight), 바이어스(bias), 활성화함수(activation function) 등으로 구성된다.

노드에서는 주어진 입력된 값을 받아 학습 시 선형 경계의 방향성 또는 형태를 나타내는 가중치를 곱하여 출력 값으로 내보낸다. Table 3의 a)와 같이 출력 노드는 입력값(Input Data)과 가중치를 곱하는 간단한 계산식에 의해 처리된 뒤 활성화 함수를 통해 출력값(Output Data)이 결정된다. 이때, 단층 퍼셉트론은 XOR 분류 문제와 같은 간단한 문제를 풀 수 없다는 한계를 보인다. 그로인해 Table b)와 같은 여러 층의 퍼셉트론을 쌓는 다층 퍼셉트론(Multi Layer Perceptron, MLP) 모델이 제시되었고 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)로 구성된다. 이때, 활성화 함수는 Table 4와 같이 계단함수(Step), 시그모이드(Sigmoid), tanh, ReLU 등 비선형 함수가 사용된다. 이외에도 ReLU를 변형시킨 Leaky ReLU, ELU 등 다양한 형태의 모델이 존재하기 때문에 목적에 맞는 함수를 사용한다.

Table 3. 퍼셉트론 다이어그램

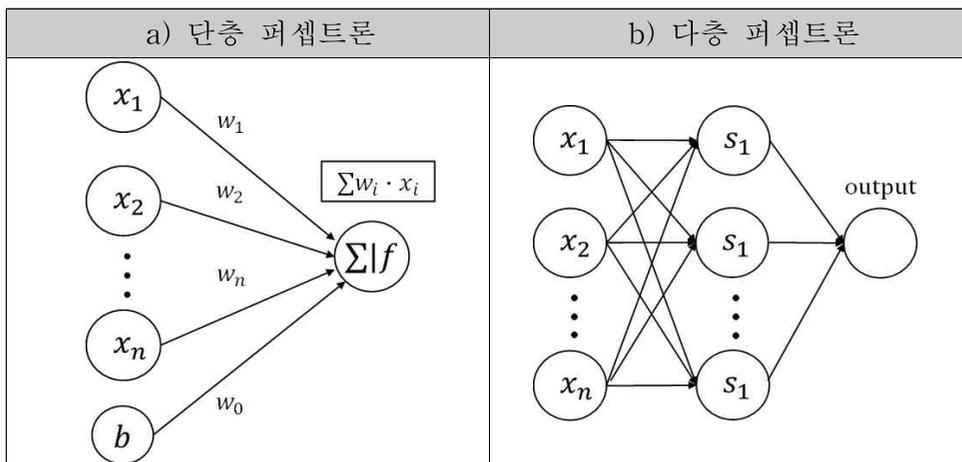
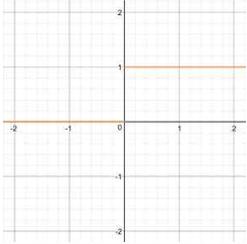
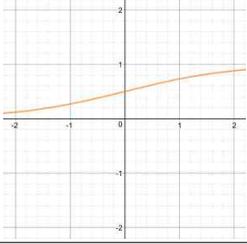
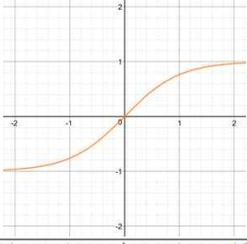
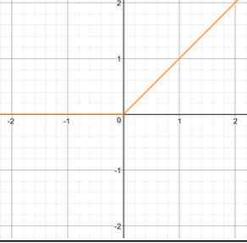


Table 4. 활성화 함수 종류 및 수식

활성화 함수	그래프	수식
계단함수 (Step)		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
시그모이드 (Sigmoid, Logistic)		$f(x) = \frac{1}{1 + e^{-x}}$
tanh		$f(x) = \tanh(x)$
ReLU		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$

딥러닝(Deep Learning, DL)은 심층신경망(Deep Neural Network, DNN)이라고도 불리며 인공지능의 일종으로 기존의 다층 퍼셉트론의 구조 중 은닉층이 2개 이상 깊어진 형태로 Fig.2와 같다. 딥러닝의 은닉층 개수는 구현하고자 하는 모델마다 다르며 은닉층의 개수가 증가할수록 복잡한 데이터에 대한 문제해결 능력이 증가한다. 각 층에는 뉴런이

존재하며 학습시에 값을 할당받아 입력받는다. 딥러닝은 단순히 깊어진 신경망이 아니라 해결해야 하는 문제에 맞는 의도를 가지도록 각각의 노드에 특별한 역할을 부여한 알고리즘이다.<sup>27)</sup> 즉, 딥러닝은 처리 문제에 따라 데이터의 관계를 분석하여 데이터의 값을 예측하는 회귀(Regression), 데이터를 해당하는 카테고리 또는 클래스(class)로 나누는 분류(Classification), 정보가 없는 상태에서 데이터를 유사한 것들끼리 모으는 군집화(Clustering) 등 여러 방법론을 가질 수 있다.

딥러닝은 기존에 인공신경망의 한계였던 비선형 문제 해결을 개선하였고 일반적인 데이터를 충분히 제공하면 높은 정확도를 가진다는 특징이 있다.<sup>28)29)</sup> 최근에는 컴퓨터 GPU(graphics processing unit)의 성능이 향상됨에 따라 연산량 증가 문제를 해결하고 딥러닝 규모가 커지면서 여러 분야에서 두각을 나타내고 있다. 특히, 이미지를 다루는 패턴인식 및 이미지 복원, 소리를 다루는 작곡 및 음성 생성, 이외에도 자율 주행 자동차, 번역 등의 다양한 분야에서 딥러닝이 적용되고 있다.<sup>30)</sup>

---

27) 나카이 에츠지. (2017). 텐서플로로 시작하는 딥러닝 (진명조 역). 제이펍.

28) 최은지, 박보람, 최영재, 문진우. (2018). 재실자 활동량 산출을 위한 Pose 분류 모델 개발, KIEAE Journal, 18(5), 93-98

29) 문성은, 장수범, 이정혁, 이종석. (2016). 기계학습 및 딥러닝 기술동향. 한국통신학회지 (정보와통신), 33(10), 49-56.

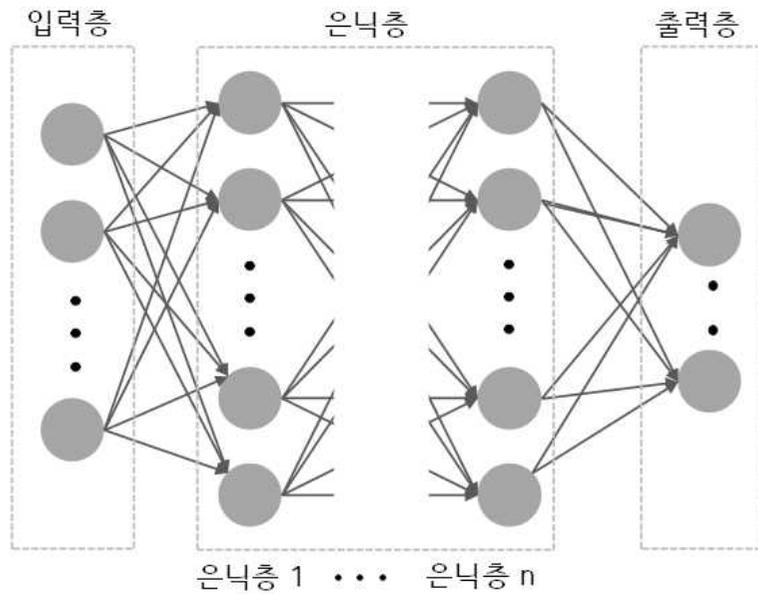


Fig. 2 딥러닝 모델의 기본 구조

### 3.2 딥러닝 학습

딥러닝의 학습은 크게 순전파(feedforward)와 역전파(Back-propagation)으로 이루어지며 학습 과정은 다음과 같다. 역전파 알고리즘(Back-Propagation Algorithm)은 딥러닝의 학습 원리 중 가장 기본이 되는 개념이다. 먼저 딥러닝 학습은 기존 뉴런에서 입력값을 알고리즘의 정방향으로 계산하여 가중치와 예측값을 산출하는 순전파 계산이 수행된다. 이때 역전파는 Fig.3과 같이 순전파를 통해 계산된 예측값과 실제값의 차이인 오차를 감소시키도록 역방향으로 가중치를 수정하는 방법이다. 이때 가중치를 최적화하기 위한 방법 중 가장 대표적인 방법은 (식 1)의 계산을 수행하는 경사하강법(Gradient Descent)이다. 경사하강법은 계산된 오차를 최소화하기 위해 가중치에 대한 오차함수의 편미분 값을 사용하고 발생된 오차가 최소가 되는 점을 찾을 때까지 반복하여 가중치를 수정한다. 이때 학습

률은 학습속도를 조절하는 상수로 학습률의 크기에 따라 학습이 수렴하지 못하거나 속도가 느려지는 문제가 발생할 수 있다. 따라서 초기에 적절한 학습률 값을 정해줘야 한다. 학습 오차를 계산하는 오차함수(Cost Function)는 대표적으로 회귀 문제에서 주로 사용하는 MSE (Mean Square Error)와 분류 문제에서 사용하는 Cross Entropy 함수 등이 있다.

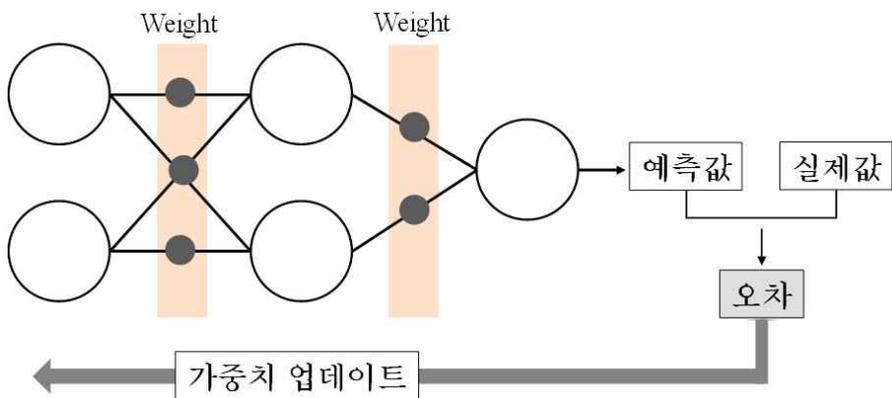


Fig. 3 역전과 알고리즘 개념도

$$W := W - \eta \cdot \frac{\partial}{\partial W} \text{cost}(W) \dots\dots\dots (\text{식 1})$$

( $W$ : 가중치,  $\text{cost}(W)$ : 오차함수,  $\eta$ : 학습률(Learning Rate))

딥러닝은 머신러닝의 일종으로 학습 방법은 크게 지도학습(Supervised Learning), 비지도학습(Unsupervised Learning) 및 강화학습(Reinforced Learning)으로 구분된다. 지도학습은 학습데이터에 정답이 표시된 정답 레이블(Label)이 포함되어 있으며 선형 회귀(Linear Regression), SVM(Support Vector Machine), 결정트리(Decision Tree) 및 신경망(Neural Networks) 등의 알고리즘을 포함한다. 반면, 비지도학습은 정답

레이블 없이 데이터를 학습하여 데이터의 군집화(Clustering), 시각화(Visualization), 차원축소(Dimensionality Reduction) 등의 작업을 수행한다. 강화학습은 이와 별개로 행동에 대한 보상과 벌점을 부여하여 최상의 전략을 스스로 학습하는 방법이다.<sup>31)</sup> 대표적인 딥러닝 모델은 학습 방법에 따라 Table 5와 같이 분류된다.

Table 5. 대표적인 딥러닝 모델 종류 및 특징

학습	딥러닝 모델 종류	특징
지도 학습	FC (Fully-Connected)	전 층이 결합된 기본적인 딥러닝 모델
	CNN (Convolutional Neural Network)	특징 필터를 사용하며 이미지 분야에서 성능 우수
	RNN (Recurrent Neural Network)	시계열 데이터인 텍스트, 음성, 영상 데이터 다루는 성능 우수
비지도 학습	RBM (Restricted Boltzmann Machine)	차원 축소, 분류, 선형 회귀 분석, 필터링 등에 사용
	DBN (Deep Belief Network)	부분 이미지에서 전체를 연상하는 일반화, 추상화 과정 구현 가능
	GAN (Generative Adversarial Network)	학습된 패턴을 이용하여 이미지 및 음성 복원에 적용
강화 학습	RL (Relation Networks)	인간의 사고에 근사한 논리적 추론이 가능한 알고리즘

31) Aurélien, G. op. cit., p 13

딥러닝 모델 중 본 연구에서 다루는 지도학습에 속하는 대표적 모델은 FC (Fully Connected), CNN (Convolutional Neural Network), RNN (Recurrent Neural Network) 등이 있다. FC는 신경망 각 층의 노드가 모두 결합된 형태로 가장 기본적인 신경망 모델이다. FC 모델로 일반적인 1차원 데이터의 학습이 가능하지만 2차원의 픽셀로 구성된 이미지나 음성, 자연어와 같은 시계열 데이터 처리를 위해서는 다른 네트워크 모델이 필요하다. 이미지 분야에서 우수한 성능을 보이는 CNN 모델은 이미지에서 특징을 추출하는 필터를 사용하여 학습한다. 이때 이미지 필터가 이미지의 특징을 얼마나 잘 추출하는지에 따라 성능이 크게 달라진다. RNN 모델은 언어, 음성, 영상 등 순서가 있는 데이터를 처리하기 위해 고안된 네트워크로 이전 정보를 현재의 문제에 적용하여 처리한다. 내부에 순환 구조가 포함된 특징을 가지며 음성 인식, 기계 번역 등의 분야에서 좋은 성과를 내고 있다.

### 3.3 건축분야의 인공지능 및 딥러닝 적용 연구 동향

강인성<sup>32)</sup>은 2000년부터 2016년 까지 국내외에서 인공지능 및 기계학습 모델을 건축분야에 활용한 417개의 연구를 연도, 분야, 주제, 기법으로 나누어 분석하였다. 연구에 따르면 2002년 국내외 9건의 연구에 비하여 2016년에 50건으로 인공지능 및 기계학습을 건축분야에 적용한 연구가 약 5.5배 증가하였다. 적용된 건축의 분야는 크게 건물 환경 및 시설, 건축 계획, 건축 구조, 건축 자재, 시공으로 분류 하였으며 건축 환경 및 시설 분야 비중이 59%를 차지하였다. 또한 주요 연구 주제는 건물 에너지 최적화, 냉난방 시스템, 건물 구조물 안정성, 일사량 예측 및 건물 실내환경 순으로 나

---

32) 강인성, 문진우, 박진철. (2017). 최근 건축분야의 인공지능 기계학습 연구동향. 대한건축학회 논문집-구조계, 33(4), 63-68.

타났다.

또한, 2014년부터 2018년 11월까지 최근 5개년동안 인공지능망 및 딥러닝 모델이 적용된 건축분야의 연구 논문 동향을 “딥러닝(Deep Learning)”, “인공신경망(Artificial Neural Network, ANN)”, “심층신경망(Deep Neural Network)”, “건물(Building)” 등의 주요 키워드로 검색한 결과 건축분야 국내외 논문 137개가 수집되었고 이를 연도 및 분야별로 나누어 분석하면 Fig.4와 Fig.5와 같다.

최근 5년 동안 인공지능망 및 딥러닝 모델을 건축분야에 적용한 연구는 국외를 중심으로 증가 추세를 보이고 있다.(Fig.4) 연도별 국내외 논문의 총 개수는 2017년도 까지 30건 이하였지만 2018년도에 46건까지 증가하였다. 이러한 추세를 토대로 앞으로도 여러 건축분야의 연구에서 신경망 모델 적용이 증가할 것으로 예상된다.

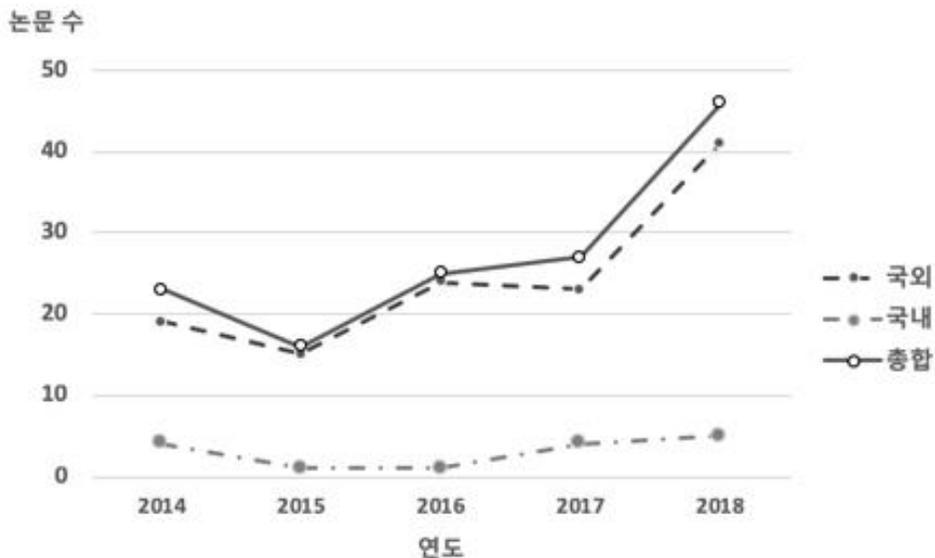


Fig. 4 연도별 건축분야의 신경망 적용 연구동향

주제별 동향의 경우 인공지능망 및 딥러닝 모델을 사용한 주된 건축분야는 크게 건축환경, 건축설계, 건축구조, 시공 등으로 분석되었다. (Fig.5) 수집된 전체 연구 중 건물 에너지에 대한 연구는 50건으로 36.5%를 차지했고 냉난방 시스템 등의 HVAC 시스템 관련 연구는 31건으로 22.6%, 실내 쾌적감 및 환경 관련 연구는 22건으로 16%를 차지했다. 그 외에도 외피 시스템 제어, 콘크리트 진단 등의 주제로 진행된 연구가 있었다. 주로 건물 에너지 최적화, 냉난방 시스템의 예측 및 제어, 실내환경 제어와 같은 고려할 변수가 다양하고 예측하기 어려운 주제에 신경망을 접목한 연구가 진행되었다.

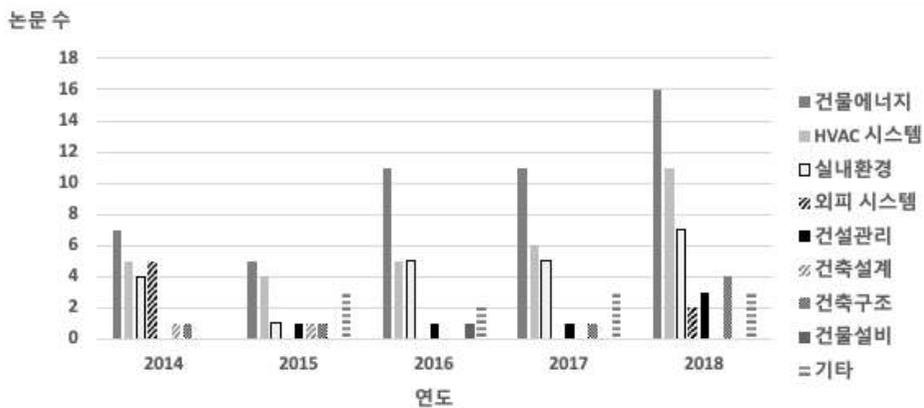


Fig. 5 건축 분야의 주제별 신경망 적용 연구동향

수집된 논문 중 본 연구와 관련이 있는 실내환경 및 열쾌적을 주제로 한 논문에 대한 분석을 추가로 진행하였다. 먼저, 실내 열환경의 쾌적 제어를 주제로 한 Deng<sup>33)</sup>은 20개의 실제 사무소와 주거지의 환경 데이터 및 재실자 데이터를 수집하여 재실자의 온열 쾌적함을 측정하는 인공지능

33) Deng, Z., & Chen, Q. (2018). Artificial neural network models using thermal sensations and occupants' behavior for predicting thermal comfort. Energy and Buildings, 174, 587-602.

망 모델을 개발하였다. 또 문진우<sup>34)</sup>는 인공지능망 모델 및 알고리즘을 통한 외부 기후, 실내 온도, 재실율, 개폐조건에 따른 건물 이중외피 최적 제어에 대한 연구를 수행하였다. 인공지능망 모델을 사용하여 냉난방 시스템을 안정적이고 효과적으로 작동시킬 수 있고 실내 열 쾌적을 유지할 수 있음을 확인하였다. Attoue<sup>35)</sup>는 에너지 소비를 줄이면서 동시에 쾌적한 조건과 사용자의 만족도를 향상시킬 수 있도록 인공지능망을 적용한 실내온도 예측 모델을 개발하였다. 이와 같이 실내환경을 다루는 논문 중 신경망 모델을 적용하여 실내 쾌적 조건 및 만족도를 향상시킨 연구가 다수 존재하였다.

실내 열환경 쾌적 제어를 위한 연구 중 재실자의 유무, 수 등을 예측하는 다양한 연구도 수행되었다. Zuraimi<sup>36)</sup>는 이산화탄소 센서를 사용하여 거주자의 수를 예측하는 인공지능망 모델을 개발하였다. 이를 통해 건물 운영 기능을 효과적으로 관리하고 에너지 효율을 향상시키자 하였다. Chen<sup>37)</sup>은 실내 환경 변수를 수집하여 재실자의 점유율을 예측하는 모델에 인공지능망을 적용하여 정확도를 향상시켰다. 실내환경 분야의 연구는 열 쾌적 조건, 재실자의 만족감 및 재실자의 재실 정보를 예측하는 모델 개발이 중점적으로 수행되었다.

건축분야에서 인공지능망 및 딥러닝 모델을 적용한 연구의 동향 조사 결

---

34) Moon, J. W., Park, J. C., & Kim, S. (2018). Development of control algorithms for optimal thermal environment of double skin envelope buildings in summer. *Building and Environment*, 144, 657-672.

35) Attoue, N., Shahrour, I., & Younes, R. (2018). Smart building: Use of the artificial neural network approach for indoor temperature forecasting. *Energies*, 11(2), 395.

36) Zuraimi, M. S., Pantazaras, A., Chaturvedi, K. A., Yang, J. J., Tham, K. W., & Lee, S. E. (2017). Predicting occupancy counts using physical and statistical CO<sub>2</sub>-based modeling methodologies. *Building and Environment*, 123, 517-528.

37) Chen, Z., Masood, M. K., & Soh, Y. C. (2016). A fusion framework for occupancy estimation in office buildings based on environmental sensor data. *Energy and Buildings*, 133, 790-798.

과, 최근 5개년 동안 국내외 연구는 증가하는 추세이며 특히 건축 환경 분야에 대한 연구의 비중이 높게 나타났다. 그 중 열환경 분야의 경우 신경망 모델 적용을 통해 주로 실내 쾌적 조건과 만족도를 향상 시킨 연구가 진행되었다. 이와 더불어 신경망 모델을 사용하여 재실자의 점유율, 수 등 정보를 파악 정확도를 향상시켰다 연구가 다수 진행되었다. 기존 재실자의 MET를 측정하고자 신경망을 적용한 연구는 미비하였지만 딥러닝과 같이 이미지 처리 성능이 좋은 신경망 모델을 적용하여 재실자 이미지를 통한 MET 측정 시 효과적일 것으로 사료된다. 따라서 재실자의 MET를 측정하는 지능형 모델의 개발을 위해 딥러닝 알고리즘을 사용한 재실자 M모델의 개발을 진행하였다.

## 제 4 장 딥러닝 기반 MET 산출모델 개발

### 4.1 학습 이미지 데이터

본 연구에서는 실내 영상 이미지를 사용해 재실자의 포즈를 분류하여 MET를 산출하는 MET 산출모델 개발을 위해 딥러닝 알고리즘을 적용한다. 모델의 학습을 위해 일반적인 실내활동을 선정하여 이미지 구축 및 데이터 전처리와 선행 모델인 관절 인식모델의 구조를 제시하고 있다. 또한 MET 산출모델의 파라미터 및 구조를 제시하고 이미지 데이터의 학습 및 최적화 과정을 진행한다.

딥러닝을 포함한 모든 기계학습은 데이터를 기반으로 학습하여 새로운 알고리즘을 만드는 것으로 데이터 처리 방법에 따라 모델의 구조 및 목적이 달라진다. 학습에 사용되는 데이터는 충분한 양으로 구성되어야 하고 목적에 맞는 대표성을 가져야한다. 따라서 일반화하고자 하는 정보를 대표하는 학습 데이터를 사용하는 것이 중요하다.<sup>38)</sup> 제대로 된 일반화 데이터를 학습하지 않으면 데이터의 대표성이 사라지게 되는 “샘플링 잡음”이나 “샘플링 편향”이 발생한다. 또한 학습할 데이터에는 에러값, 잡음이 없는 질 좋은 데이터를 사용하는 것이 오차를 줄이는데 중요한 역할을 한다. 즉, 학습에 사용할 데이터를 제대로 구축하는 것은 모델 개발에 앞서 다뤄져야 하는 중요한 과정으로 MET 산출모델의 학습에 사용할 데이터 구축을 먼저 실시하였다.

MET 산출모델에서 학습되는 데이터는 인체 관절 좌표 값으로 재실자의 이미지를 입력받은 선행 모델 결과로 도출된다. 하지만 선행모델과 별개로

---

38) Aurélien, G. op. cit., p 13

개별적인 모델의 학습을 위해서 MET 산출모델에 필요한 데이터를 구축해야 한다. 따라서 학습을 위한 인체 관절 좌표로 구성된 학습데이터세트 구축을 진행하였다. 진행 방법은 Fig.6과 같이 학습할 실내 활동을 선정하고 그에 해당하는 이미지 데이터를 기존 데이터 세트에서 참고하거나 데이터 세트 구축을 위해 조성된 환경에서 직접 이미지를 촬영하여 데이터를 구축하였다. 최종적으로 구축된 이미지를 통해 실제 학습에 사용할 인체 관절 좌표를 추출하는 과정으로 진행하였다.

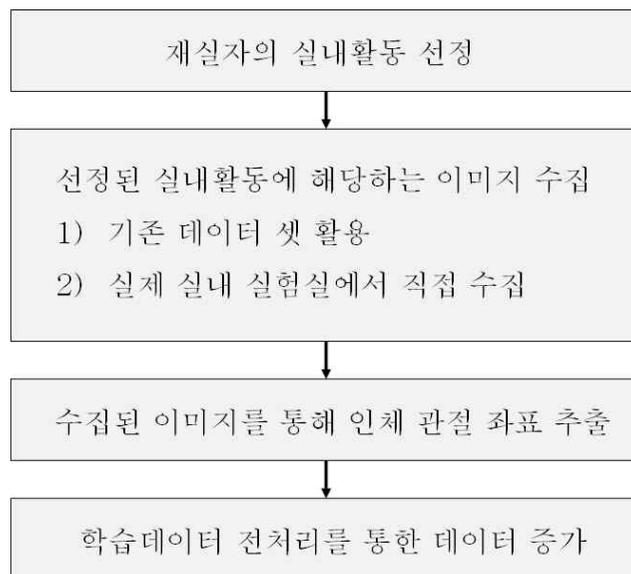


Fig. 6 학습 데이터세트 구축 과정

## (1) 재실자 실내활동 선정

재실자의 실내활동은 미국 공기조화냉동공학회인 ASHRAE에서 제공하는 ASHRAE 55의 표 5.2.1.2 “Metabolic Rates for Typical Tasks”<sup>39)</sup>를 기준으로 선정하였다. 실내활동은 총 32가지로 실내외에서 발생 가능한 대표적인 활동과 각 활동에 해당하는 MET 값이 주어진다. ASHRAE에서는 MET 값을 설정할 때, ASHRAE의 제시된 실내활동 중 가장 비슷한 활동의 MET 값을 선택하도록 권하고 있다. 본 연구에서는 재실자의 실내활동을 다루기 때문에 ASHRAE가 제시한 활동 중 실내에서 발생하는 일반적인 활동을 선택하였다. 선택한 활동은 총 10가지로 Table 6에 제시되어 있다. ‘Resting’에는 ‘sleeping’, ‘reclining’, ‘seated,quiet’, ‘standing,relaxed’와 같이 주거지에서 주로 나타날 수 있는 4가지의 활동이 포함되었고 ‘Office Activities’에서 오피스 실내에서 주로 발생할 수 있는 ‘reading,seated’, ‘writing’, ‘typing’, ‘filing,seated’, ‘filing,stand’, ‘walking about’과 같은 6가지 활동이 포함되었다. 실내활동은 각 활동별로 0부터 9까지 레이블을 설정하여 학습 시 정답 값으로 해당 레이블 번호가 입력된다. 이때, ASHRAE에서 제공하는 활동 중 ‘Cooking’, ‘House cleaning’등은 일반적인 실내활동에 포함되지만 재실자가 사용하는 도구를 인식하는 것이 행동 예측에 있어 중요한 역할을 한다. 이로 인해 본 모델이 분류하고자 하는 실내활동에서 제외하였고 추후 도구 인식 모델의 개발을 통해 해당 활동에 대한 보완을 할 수 있을 것으로 예상된다.

---

39) ANSI/ASHRAE. (2010). ANSI/ASHRAE Standard 55 Thermal Environmental Conditions for Human Occupancy. ASHRAE. Atlanta.

Table 6. 학습 데이터 실내활동 및 MET 구성

실내활동	MET Units	Label
Resting		
sleeping	0.7	0
reclining	0.8	1
seated.quiet	1.0	2
standing.relaxed	1.2	3
office activities		
reading.seated	1.0	4
writing	1.0	5
typing	1.1	6
filing.seated	1.2	7
filing.standing	1.4	8
walking about	1.7	9

(2) 선정된 실내활동 이미지 수집

10가지 실내활동의 선정 후, 각 활동에 맞는 이미지 수집을 진행하였다. Table 7과 Table 8은 각각 'Resting'과 'Office Activities'의 각 활동에 대한 수집된 이미지 예시이다. 이미지는 기존에 수행된 학습알고리즘 연구 결과로 구축된 기존의 데이터세트를 참고하거나 인터넷 검색을 활용하였고 부족한 이미지는 실제 실내 환경을 구현해 둔 실험실에서 직접 수집하였다. 이때 기존의 데이터세트는 다양한 목적을 가지는 딥러닝 알고리즘의 개발을 위해 수집된 다양하고 독자적인 데이터세트를 의미한다. 공개된 기존의 데이터세트는 크게 이미지, 자연어, 오디오 및 음성 데이터로 구분되며 분류, 인지, 추출, 감지 등의 목적으로 나뉜다. 그 중 대표적인 이미지 데이터세트는 1~9까지 숫자를 손글씨 이미지 데이터로 수집한

‘MNIST’, 객체 탐지를 위한 91개 카테고리를 가지는 이미지 데이터인 ‘MS-COCO’, 물체 인식을 위해 수집된 동물 및 운송장치 이미지로 구성된 ‘CIFAR-10’ 등이 있다.<sup>40)</sup> MET 산출모델에서는 다양한 활동을 하는 사람 이미지를 수집한 ‘LIP (Look Into Person)’ 데이터세트와 Google 이미지를 참고하여 이미지를 수집하였다. 부족한 이미지는 선정된 10가지의 실내 활동이 발생 가능한 환경을 구현해둔 실험실에서 직접 찍어서 수집하였다. 수집된 이미지 데이터세트를 각 활동별로 50개로 총 500개의 이미지로 구성된다.

Table 7. ‘Resting’의 실내활동 이미지 구축 예시

sleeping					
reclining					
seated,quiet					
standing, relaxed					

40) Analytics Vidhya. (2018, 11). 25 Open Datasets for Deep Learning Every Data Scientist Must Work With, <https://www.analyticsvidhya.com/blog/2018/03/comprehensive-collection-deep-learning-datasets/>

Table 8. 'Office Activities'의 실내활동 이미지 구축 예시

reading. seated					
writing					
typing					
filing. seated					
filing. standing					
walking about					

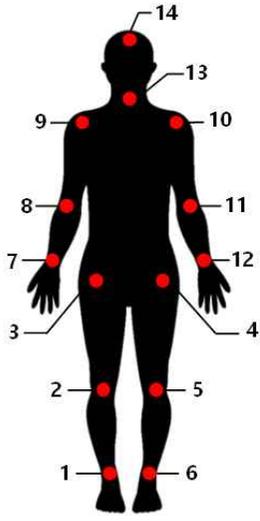
### (3) 학습을 위한 좌표 데이터 구축

MET 산출모델은 이미지 상의 인체 주요 관절 14개의 절대 좌표값 (x, y) 를 학습한다. 따라서 수집된 이미지에서 좌표값을 추출하여 학습데이터로 사용할 수 있도록 가공하는 과정이 추가로 진행되었다. 인체의 주요 관절의 위치는 Table 9, (a)에 나타난 것과 같이 발목(右), 무릎(右), 골반(右), 골

반(左), 무릎(左), 발목(左), 손목(右), 팔꿈치(右), 어깨(右), 어깨(左), 팔꿈치(左), 손목(左), 목, 이마 순서로 설정하였다. Table 9, (b)는 실제 이미지에서 각 순서에 맞게 관절 위치를 설정한 예시이다. 좌표 데이터는 하나의 이미지 당 14개의 (x,y) 좌표를 x 값과 y 값을 하나씩 나열하여 총 28개의 값을 가진다.

각 이미지에 좌표 값이 결정되면 Table 9, (c)와 같이 좌표 데이터를 모두 포함하는 선에서 이미지를 딱 맞게 잘라내는 Boxing 작업이 수행된다. Boxing 작업은 재실자를 중점적으로 학습하기 위해 좌표 값을 제외한 불필요한 정보가 담긴 주변 이미지를 잘라내는 과정이다. Boxing 과정이 마무리 된 후 전처리 과정을 통해 데이터를 증가시키는 과정이 진행된다.

Table 9. 인체 관절 좌표 추출 및 Boxing 방법

(a) 관절 위치 및 번호			
	1	오른쪽	발목
	2		무릎
	3		골반
	4	왼쪽	골반
	5		무릎
	6		발목
	7	오른쪽	손목
	8		팔꿈치
	9		어깨
	10	왼쪽	어깨
	11		팔꿈치
	12		손목
	13	목	
	14	이마	
(b) 좌표 추출 예시		(c) Boxing 예시	
			

(4) 전처리 과정을 통한 데이터 증식

이미지 수집을 통하여 구축된 학습 이미지는 총 500개이며 학습 전 전처리 과정을 통해 데이터를 증가시켰다. 이와 같은 과정은 충분한 학습데이터

를 통해 모델의 성능을 향상시키고 데이터가 적을 경우 학습 데이터에만 최적화되는 과적합(Overfitting) 문제를 방지하기 위한 과정이다. 데이터 증가는 Data Augmentation이라고도 하며 모델의 목적에 맞게 원본 데이터를 자르기, 뒤집기, 밝기 조절 등의 변형을 시켜주어 데이터를 증가시키는 것을 의미한다. 이는 학습모델이 다양한 데이터의 변수를 고려하여 학습할 수 있게 하여 모델의 성능을 향상시킬 수 있다.

본 연구에서는 다소 적은 데이터의 한계를 보완하기 위해 좌표 데이터에 사용할 수 있는 Augmentation 기법 3가지를 적용하여 데이터를 증가시켰다.(Table 10) 첫 번째 방법은 이미지의 중심선을 기준으로 좌표를 좌우 반전하는 방법이다. 이 과정을 통해 모델이 같은 실내활동에 대해 다양한 포즈를 학습할 수 있게 하였다. 두 번째 방법은 이미지의 중심선을 기준으로 +, - 방향으로  $-5^{\circ}$ 에서  $5^{\circ}$  범위에서 좌표를 회전하는 방법을 사용하였다. 이 기법은 좌표 데이터에 이상치(outlier)를 생산하지 않는 선에서 데이터를 증가시키는 방법이다. 세 번째 방법은 이미지의 스케일을 조정하는 방법으로 이미지 상의 재실자 주위에 여백을 주는 방법이다. 이 방법은 Fig.7처럼 Box친 이미지와 원본 이미지를 비교하여 그 사이에 남은 여백을 0.1 간격으로 0.0(Box 이미지)부터 5.0(원본 이미지)까지 나눈다. 이때 간격의 크기를 설정하면 Box의 크기가 늘어나 이미지 스케일이 변경된다. 이미지의 왼쪽 상단을 원점 (0,0)으로 설정하였을 때 사람 주위 여백의 크기가 변경되면 포즈는 그대로이지만 좌표의 절대값이 변경되는 방법이다. 3가지의 데이터 Augmentation 기법은 Table 10과 같이 적용하여 학습데이터를 총 198배 증가시켰다. 결과적으로 전체 학습데이터의 개수를 데이터의 전처리 기법을 적용하여 기존 500개에서 99,000개로 증가시켰다.

Table 10. 데이터 Augmentation 기법 적용

Augmentation	변경 내용	증가량
Flip	좌우 반전	2배
Rotate	-5°, -4°, -3°, -2°, -1°, 0°, 1°, 2°, 3°, 4°, 5°	11배
Scale	0.9, 1.0, 1.1, 1.2, 1.3, 1.4, 1.6, 1.8, 2.0	9배

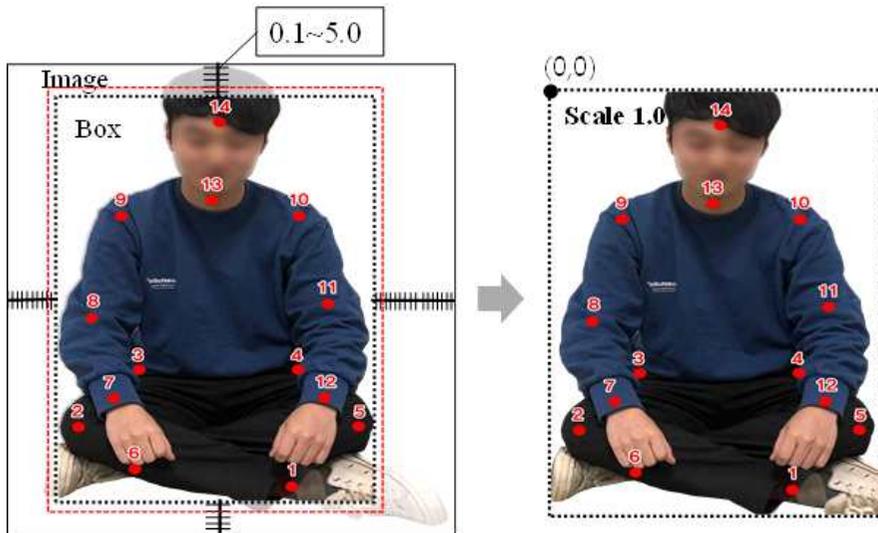


Fig. 7 이미지 스케일 조정 방법

## 4.2 인체 관절인식 선행 모델

MET 산출모델 개발 시 1 장의 Fig.1과 같이 이미지에서 관절 좌표를 추출하는 관절 인식모델이 선행모델로 개발되었다.<sup>41)</sup> 선행모델인 관절 인식모델은 실내활동 데이터의 원본 이미지를 입력받고 이미지 상의 재실자 관절 좌표를 추출한다. 관절 인식모델은 학습 시에 각 이미지에 해당하는 정답 좌표를 포함하는 지도학습을 수행한다. 이때, 모델에 이미지가 입력되기 전

41) 한지훈, op. cit., p.5

이미지 상의 사람의 위치를 감지하는 전처리 과정을 먼저 수행한다. 사람을 감지할 때 사용한 함수는 Mask R-CNN으로 He<sup>42)</sup>에 의해 제안된 사물 인식 및 추출 함수이다. Mask R-CNN을 사용해 사람의 위치를 찾아 불필요한 정보를 담고 있는 주위 배경을 제거한다. 이 함수는 앞서 MET 산출모델의 학습 시에 적용한 Boxing 과정을 처리해주는 역할로 좌표가 없는 이미지에서도 사람을 찾아 Boxing을 할 수 있다. Fig.8은 Mask R-CNN을 통해 재실자를 감지하는 이미지 예시로 재실자만 포함된 새로운 이미지를 내보고 내보낸 이미지는 관절 인식모델에 입력된다.

관절 인식모델은 감지된 이미지를 128×128 크기로 변환하여 일정하게 입력받는다. 이때 모델의 학습 시 오차 측정 방법으로 Euclidean Distance (식 2)를 계산하였다. Euclidean Distance는 측정해야하는 14개의 좌표에 대하여 정답으로 주어진 재실자의 실제 좌표값과 모델의 학습 결과로 추출된 좌표값 사이의 거리를 계산한다. 거리의 계산은 (식 2)와 같이 두 점 p와 q 사이의 길이를 계산한다. 이때  $i$ 는 공간의 차원 수를 의미하며 관절 인식모델은 2차원의 이미지를 다루므로  $i=2$  이다. 관절 인식모델의 파라미터 및 최적화 알고리즘은 조절하며 성능을 향상시킨다.

---

42) Kaiming, H, Georgia, G, Piotr, D, & Ross, G. (2017). Mask R-CNN, arXiv : 1703.06870

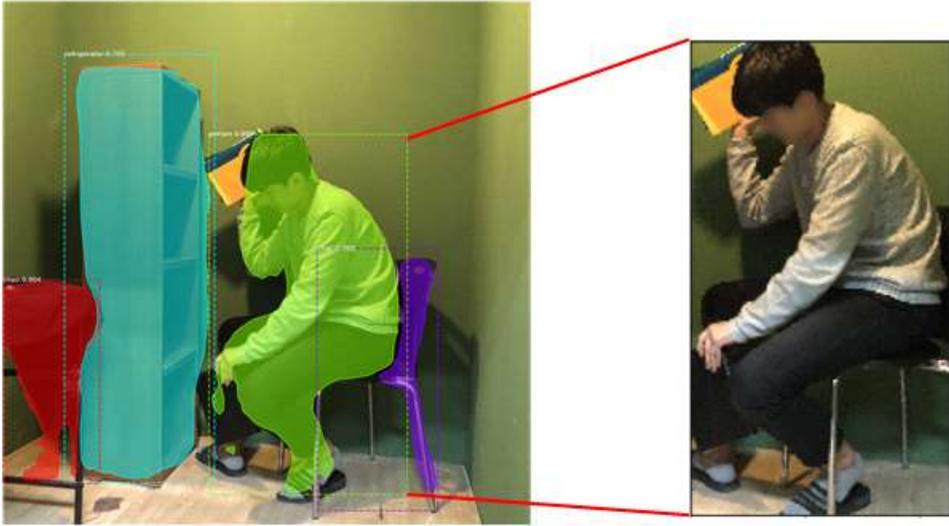


Fig. 8 Mask R-CNN의 재실자 감지

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \dots\dots\dots (\text{식 2})$$

또한 관절 인식모델은 이미지 데이터 학습을 위해 CNN (Convolutional Neural Network) 구조를 포함하는 ResNet을 활용하였다. ResNet은 Microsoft Research 연구팀이 개발한 모델로 매년 개최되는 이미지 인식 및 관절인식 경진대회인 ImageNet and COCO 2015<sup>43)</sup>의 주요 분야에서 우수한 모델이다. ResNet은 이미지뿐만 아니라 회귀 및 분류 문제를 해결하는데 우수한 성능을 보인다.

ResNet의 핵심이 되는 구조는 Fig.9의 Residual Block이다. 관절 인식 모델의 Residual Block은 3개의 Convolution Layer와 1개의 Batch Normalization, 1개의 ReLU로 구성된다. 이때 Residual Block은 입력층에

43) IMAGENET. (2018.11). ImageNet and MS COCO Visual Recognition Challenges Joint Workshop. <http://image-net.org/challenges/ilsvrc+mscoco2015>

서 마지막 Convolution Layer까지 Short-cut이라는 선으로 연결되어 역전파 학습 시 오차 값이 중간에 소실되는 것을 방지하는 기능을 수행하고 성능을 향상시키는 역할을 한다. 이러한 구조를 가지는 Residual Block을 관절 인식모델에 반복적으로 연결하여 모델을 구성했으며 총 30번 사용된다.

관절 인식모델은 Fig.10과 같은 구조로 구성된다. Input Data에 이미지가 입력되면 Residual Block 16개, Convolution Layer 총 52개를 통과하며 이미지의 특징을 추출한다. 추출된 이미지 특징을 14개의 각 좌표를 학습한 Residual Block에 보내 각 관절별로 좌표를 추출한다. 최종적으로 관절 인식모델은 이미지의 인체 관절 좌표 14개의 값을 Output으로 출력하고 출력된 좌표를 MET 산출모델로 보내는 과정을 수행한다.

관절 인식모델의 결과로 도출된 좌표 14개의 x, y 값은 MET 산출모델이 입력받아 좌표가 나타내는 실내활동 포즈를 학습한다. 학습을 통해 재실자의 포즈 및 해당하는 MET 값을 출력한다.

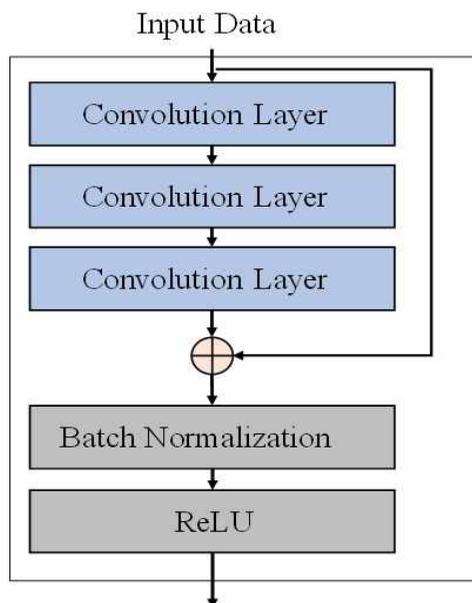


Fig. 9 Residual Block 구조

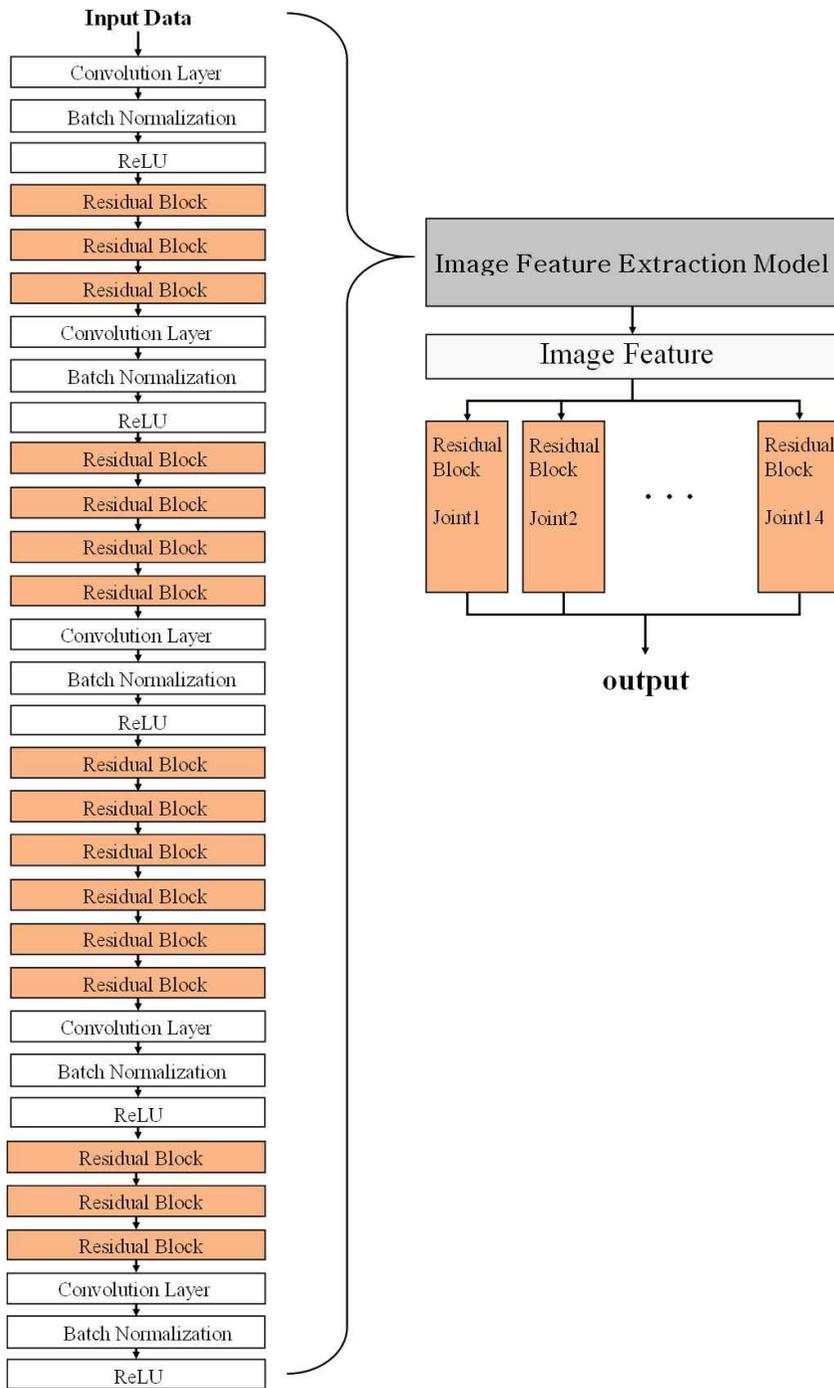


Fig. 10 관절 인식모델 구조

### 4.3 MET 산출모델 개발

MET 산출모델 개발은 선행모델인 관절 인식모델이 제공하는 좌표의 형태를 기반으로 개발 및 학습을 진행하였다. 즉 MET 산출모델은 이미지의 인체 관절 좌표와 포즈 레이블 정보를 가지는 데이터를 학습하여 관절 좌표가 나타내는 포즈와 MET를 출력한다.

#### (1) MET 산출모델의 기본 구조

재실자의 실내활동을 구분하기 위해 분류(Classification) 모델을 사용하여 재실자의 포즈를 분류하였다. 분류모델의 학습은 지도학습으로 각 실내활동에 레이블 번호를 부여하여 정답을 정해주었다. 즉 MET 산출모델은 인체 관절 14쌍의 (x,y) 좌표인 28개가 입력되고 실내활동 레이블을 결과로 내보낸다. 따라서 예측모델은 Fig.11과 같이 딥러닝의 기본 구조인 입력층, 은닉층, 출력층 구조를 가지며 입력 노드 28개, 출력 노드 1개로 구성된다. 결과적으로 예측모델을 통해 출력되는 재실자 포즈 정보로 MET 값 예측이 가능하다. 은닉층의 구조는 최적 모델을 찾기 위해 모델의 학습 시에 은닉층과 은닉 뉴런의 개수를 변경하며 진행하였기 때문에 모델 최적화 진행 후에 결정되었다.

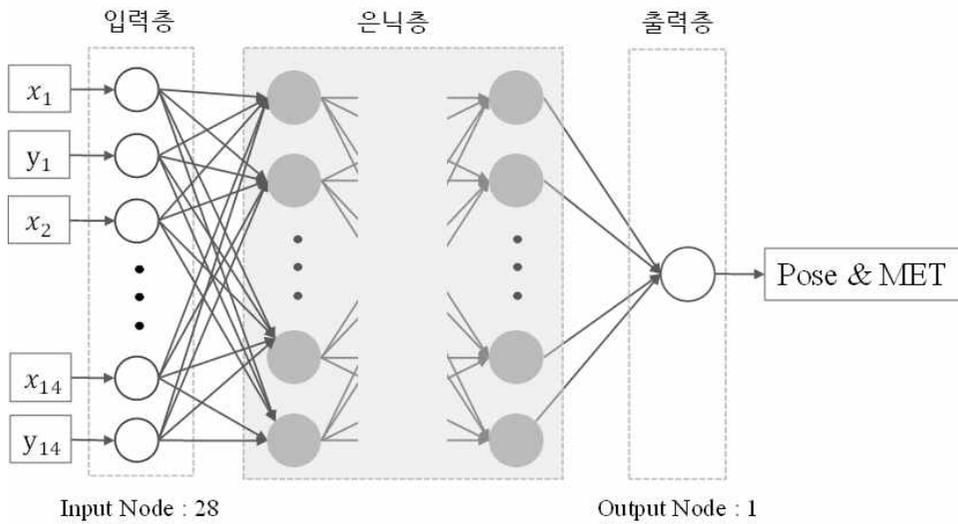


Fig. 11 MET 산출모델의 기본 구조

## (2) 모델 파라미터 설정

일반적으로 신경망 모델은 데이터에 따라 유연하게 동작하기 때문에 조절해야 하는 파라미터가 많다.<sup>44)</sup> 따라서 모델 개발에 앞서 딥러닝 학습 시에 발생하는 느린 학습 속도, 학습 데이터의 과적합 및 그래디언트 소실 및 폭주(Gradient Vanishing or Exploding) 등의 문제를 해결하기 위한 모델 파라미터를 설정하였다. 그 중 그래디언트 소실 및 폭주(Gradient Vanishing or Exploding) 문제는 모델 은닉층이 깊어질수록 발생하는 문제로 역전파 알고리즘에서 사용하는 미분 값이 사라지거나 폭주하는 현상을 말한다. 예를 들어 기존 활성화 함수인 계단함수를 사용할 경우 미분 값은 어떤 값이 들어오더라도 0이 되므로 그래디언트 값이 소실되어 학습이 수렴하지 않게 된다. 이러한 그래디언트 소실 및 폭주 문제 해결을 위한 설정은 Table 11의 설정 파라미터 중 활성화 함수, 가중치 초기화, 배치 정

44) Aurélien, G. op. cit., p.13

규화를 통하여 보완할 수 있다. 먼저 MET 산출모델의 활성화 함수는 ReLU (Rectified Linear Unit) 함수로 설정하였다. ReLU는 2장의 Table 4와 같이 음수 값을 받는 경우 0을 내보내고 양수 값을 받을 경우 양수 값 그대로를 내보내기 때문에 미분할 경우 값이 살아있기 때문에 그래디언트 소실 문제를 해결할 수 있다.

배치 정규화 기법<sup>45)</sup>은 활성화 함수의 출력값을 다시 정규화 해주는 작업으로 데이터의 분포를 치우치지 않게 하여 그래디언트 소실 및 폭발 문제를 해결할 수 있다. 이에 따라 MET 산출모델에도 배치 정규화를 적용하였다. 그 외에도 딥러닝 모델은 종종 학습데이터에 대해 과적합(Overfitting)이 발생한다. 이 문제는 모델이 학습데이터에 대한 학습에 최적화되어 다른 데이터에 대한 일반성이 낮은 것을 의미한다. 과적합 문제 해결은 계층 간 뉴런의 연결을 무작위로 끊어주는 드롭아웃(Dropout) 파라미터를 설정하여 방지할 수 있다. 본 모델에서는 각 층에서 30%의 뉴런의 연결을 끊어주며 연결을 하도록 설정하였다.

Table 11. MET 산출모델 파라미터 설정

파라미터	설정 값
활성화 함수	ReLU Function
배치 정규화	Batch Normalization
Dropout	30%

45) Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167.

### (3) 오차 함수 설정

MET 산출모델은 레이블의 확률 분포를 다루는 오차 함수인 교차 엔트로피(Cross Entropy)를 적용하였다. 교차 엔트로피는 (식 3)과 같은 수식에 의해 계산되고 분류 모델에서 오차를 확인하는데 주로 사용된다. (식 3)의  $H(P,Q)$ 는 오차(Cost)를 나타내고  $Q(x)$ 는 모델이 예측한 레이블 값,  $P(x)$ 는 실제 정답 레이블 값 그리고  $i$ 는 분류하고자 하는 클래스 개수를 의미한다. 분류 모델의 출력 시 도출되는 각 레이블의 확률을 오차의 변수로 사용하기 때문에 얼마나 정확하게 정답을 맞혔는지에 대한 정확도가 고려된다.

$$H(P, Q) = - \sum_i P_i(x) \cdot \log(Q_i(x)) \dots\dots\dots (식 3)$$

여기서,  $P_i(x)$  = 실제 정답 레이블

$Q_i(x)$  = 모델의 예측 레이블

$H(P, Q)$  = 오차

### (4) 최적화 알고리즘 설정

모델의 최적화 알고리즘으로 Adam Optimizer를 사용하였다. 초기의 최적화 알고리즘인 경사하강법은 일정한 간격으로 이동하며 학습하는 학습률(Learning Rate, LR)을 이용하기 때문에 학습 속도가 오래 걸릴 수 있다. 따라서 학습률은 고정값, 일정 스텝마다 학습률 크기를 줄이는 지수 기반 등 학습 속도와 최적점을 고려해 적용하게 된다. 이때, Adam Optimizer는 적응형 모멘트 추정이라고도 부르며 경사하강법에 모멘텀(Momentum) 개

념을 추가하여 이전에 계산한 그래디언트 값을 고려하는 가속도의 개념을 적용한 방법이다. Adam Optimizer는 최적화하는 동안 자동으로 학습률을 감소시켜 주는 알고리즘이기 때문에 초기 학습률을 지정해주면 스스로 학습률을 변경하며 학습을 수행한다.

#### (5) 은닉층 구조 설정

MET 산출모델은 은닉층과 은닉뉴런의 수를 변경하여 학습을 진행하고 성능이 가장 좋은 최적모델을 찾는 과정을 수행한다. 은닉층과 은닉뉴런 개수의 조합은 분석하고자 하는 데이터세트에 따라 다양하며 각 모델의 최적 구조가 다르게 나타난다. 본 연구에서도 마찬가지로 효과적인 성능을 나타내는 모델을 찾기 위해 학습 시 적용할 은닉층의 수(Number of Hidden Layer, NHL) 및 은닉뉴런의 수(Number of Hidden Neurons, NHN)에 대한 Case를 설정하였다. 신경망의 경우 노드의 구조에 따라 모델의 특징이 다르게 나타나며 다양한 형태의 기존 신경망이 개발되었다.<sup>46)</sup> 따라서 본 모델의 학습을 위해 설정된 Case는 기존 개발된 신경망이 지니는 구조를 기반으로 5가지 형태로 표현하였다.

신경망의 각각의 노드는 스스로 학습하기 때문에 어떤 정보에 얼마의 가중치가 주어지는지 정확히 알기 어렵고 구조 형태에 따라 성능이 바뀔 수 있다. 관련 연구로 최은지<sup>47)</sup>에 의해 재실자의 포즈 분류모델 학습을 진행한 선행연구가 수행되었다. 이 연구는 NHL에 상관없이 뉴런 수가 일정하게 유지되는 25가지의 구조를 학습하였다. 이때, NHN은 50개부터 250개, NHL는 1개부터 5개까지 변경하였고 결과적으로 NHL 1개 및 NHN 200개 구조를 가지는 경우에 가장 높은 성능을 보였다. 학습에 사

46) The Asimov Institute, (2018. 12), The Neural Network Zoo, <http://www.asimovinstitute.org/neural-network-zoo/>

47) 최은지, op. cit., p.17

용한 데이터는 Augmentation 과정을 통해 66배 증가시킨 다소 적은 데이터를 사용하였다.

그러나 본 연구에서는 데이터 Augmentation 기법을 늘려 198배 증가시킨 데이터를 학습하였다. 3배 증가한 다량의 데이터를 학습하기 위해 은닉층의 구조를 다양하게 변경시켜 Case Study를 수행하였다. 따라서 MET 산출모델 개발을 위해 은닉층의 구조를 Table 12~Table 16과 같이 총 5가지 Case로 설정하였다. 표에 제시된 구조도는 각 Case의 NHN에 의해 형성되는 은닉층의 구조 형태를 표현하였다. 구조도는 은닉층의 구조만 보여주고 있으며 화살표는 입력된 데이터가 구조도의 위에서 아래로 이동하며 학습되는 것을 의미한다.

Case1의 경우 최은지<sup>48)</sup>의 선행연구에 의해 NHL의 수가 한 개일 때 가장 성능이 좋은 것을 확인하였고 Cybenko<sup>49)</sup>는 뉴런수가 무한하다면 은닉층 한 개로도 복잡한 함수의 모델링이 가능하다고 주장했다. 이에 따라 Case1은 NHL를 한 개로 유지하고 NHN은 선행연구의 결과 가장 정확도가 높게 산출된 200개를 기준으로 50개씩 증가시킨 4가지의 세부 Case(Case 1-a ~ Case 1-d)로 구성하였다.

Case2부터 Case5는 설정한 은닉층의 형태를 표현하기 위해 3개 이상의 은닉층으로 구성하였다. 심층 신경망은 은닉층이 1개일 때보다 적은 수의 뉴런을 사용하더라도 복잡한 모델 훈련이 가능하다. 때문에 Case2부터 Case5의 NHN은 Case1보다 뉴런의 수를 적게 설정하였다. 이때, NHN을 정하는 규칙은 없지만 David Hunter<sup>50)</sup>의 연구를 통해 BMLP (Bridged Multilayer Perceptron) 모델의 경우,  $(2 \times \text{입력뉴런} + 1)$ 와 같은 수식으로

---

48) 최은지, op. cit., p.17

49) Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303-314.

50) Hunter, D., Yu, H., Pukish III, M. S., Kolbusz, J., & Wilamowski, B. M. (2012). Selection of proper neural network sizes and architectures—A comparative study. *IEEE Transactions on Industrial Informatics*, 8(2), 228-240.

NHN을 결정한 사례를 확인했다. 이를 토대로 Case2 ~ Case5는 입력뉴런 개수가  $n$ 개일 때, 그와 비례하게  $2n \sim 6n$  까지 뉴런개수를 증가시켜 NHL에 맞게 적용하였다. 즉, 입력뉴런이 28이므로 NHL은 56, 84, 112, 140, 168개인 배수로 구성하여 학습을 진행하였다. 따라서 은닉층의 형태 별로 5가지 Case(Case1 ~ Case5)와 각 Case에서 뉴런 수를 변경한 4가지의 세부 Case로 구성되어 총 20개의 모델에 대한 학습이 수행된다.

Table 12. Case 1의 은닉층 구조 설정

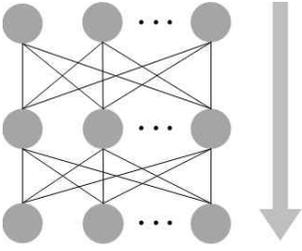
Case1			
구조도	구분	NHL	NHN
	Case 1-a	1	200
	Case 1-b		250
	Case 1-c		300
	Case 1-d		350

Table 13. Case 2의 은닉층 구조 설정

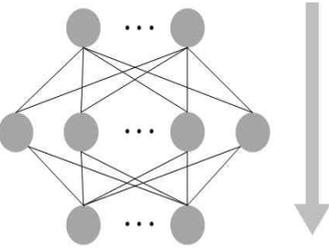
Case2			
구조도	구분	NHL	NHN
	Case 2-a	3	56-84-56
	Case 2-b	4	56-84-84-56
	Case 2-c	5	56-84-112-84-56
	Case 2-d	6	56-84-112-112-84-56

Table 14. Case 3의 은닉층 구조 설정

Case3			
구조도	구분	NHL	NHN
	Case 3-a	3	84-56-84
	Case 3-b	4	84-56-56-84
	Case 3-c	5	112-84-56-84-112
	Case 3-d	6	112-84-56-56-84-112

Table 15. Case 4의 은닉층 구조 설정

Case4			
구조도	구분	NHL	NHN
	Case 4-a	3	56-84-112
	Case 4-b	4	56-84-112-140
	Case 4-c	5	56-84-112-140-168
	Case 4-d	6	56-84-112-140-168-196

Table 16. Case 5의 은닉층 구조 설정

Case5			
구조도	구분	NHL	NHN
	Case 5-a	3	112-84-56
	Case 5-b	4	140-112-84-56
	Case 5-c	5	168-140-112-84-56
	Case 5-d	6	196-168-140-112-84-56

## (6) MET 산출모델 학습 및 최적화

MET 산출모델은 Google Brain Team이 개발한 수치계산을 위한 오픈소스 소프트웨어 라이브러리인 텐서플로(TensorFlow)를 사용하였다. 텐서플로는 복잡한 계산들에 대하여 쉽게 구현 가능하도록 함수로 제시하고 있어 대규모 머신러닝 등 수치 연산에 특화되어 있다.

MET 산출모델의 학습을 위해 수집된 실내활동 이미지 데이터는 학습을 위한 Train data set과 모델의 검증을 위한 Valid data set 그리고 학습된 모델의 최종 성능을 평가하기 위한 데이터인 Test data set으로 분리하였다. (Fig.12) Train data set은 모델의 학습에 사용되는 데이터이며 Valid data set은 학습된 모델 중 가장 성능이 좋은 모델이 판별하기 위한 검증용 데이터로 Train data set에 속한다. Test data set은 학습에는 사용하지 않고 최종 모델의 평가에만 적용하여 성능을 파악하는 용도로 사용한다. 구축된 전체 실내활동 데이터 99,000개의 80%는 Train data set, 20%는 Test data set으로 나누어 학습을 진행하였다. 이때 Valid data set 구축을 위해 Train data set의 20%를 다시 분리하였다. 학습에 사용하는 데이터는 규칙적인 좌표 패턴을 학습할 수 있도록 이미지의 크기를 일정하게 처리하였다. 이때 이미지의 크기는 선행 모델에서 사용한 128\*128 크기를 그대로 사용하였다.

MET 산출모델의 구현을 위해 컴퓨터 프로그래밍 언어인 Python을 사용하였다. 앞서 모델의 구조 및 파라미터를 설정하였으며, 텐서플로를 사용해 Fig.13, Fig.14와 같이 구축되었다. Fig.13은 레이어의 구성 및 은닉층의 구조를 설정하는 과정이다. 이때 레이어의 구성에는 가중치(weights), 편향(biases), 활성화함수, 배치정규화 등이 적용된다. 은닉층의 개수에 따라 레이어 개수를 조절하게 되며 Fig.13은 첫 번째의 입력층을 제외하고 총 4개의 은닉층 구조를 가지는 예시 모델이다. 또한 은닉층 설정 시 HN1~HN4

는 은닉뉴런의 개수를 적용하는 변수로 MET 산출모델은 앞서 설정된 은닉층 구조 Case에 따라 적용한다.

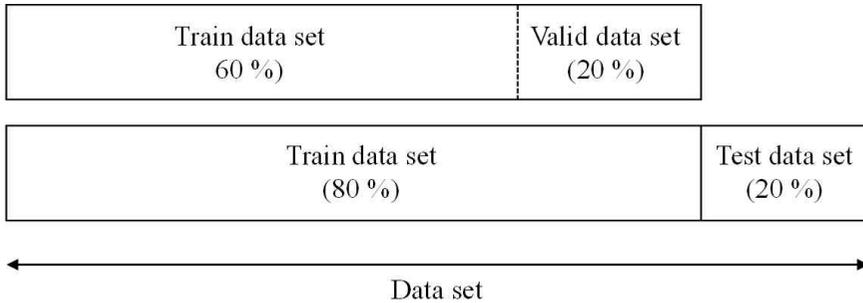


Fig. 12 실내활동 데이터세트 분류

레이어의 구성 설정
<pre>def fc(data, num_in, num_out, name=None, relu=True, bn=True, is_train=None):     with tf.variable_scope(name) as scope:         weights = tf.get_variable('weights', shape=[num_in, num_out], trainable=True)         biases = tf.get_variable('biases', [num_out], trainable=True)         output = tf.nn.xw_plus_b(data, weights, biases, name=scope.name)         if bn : output = batch_norm(output, is_train)         if relu : output = tf.nn.relu(output)      return output</pre>
은닉층 및 은닉뉴런 설정
<pre>self.fc1 = fc(self.X, 28, HN1, name='fc1', relu=True, bn=True, is_train=self.is_train) self.fc1 = tf.nn.dropout(self.fc1, self.keep_prob)  self.fc2 = fc(self.fc1, HN1, HN2, name='fc2', relu=True, bn=True, is_train=self.is_train) self.fc2 = tf.nn.dropout(self.fc2, self.keep_prob)  self.fc3 = fc(self.fc2, HN2, HN3, name='fc3', relu=True, bn=True, is_train=self.is_train) self.fc3 = tf.nn.dropout(self.fc3, self.keep_prob)  self.fc4 = fc(self.fc3, HN3, HN4, name='fc4', relu=True, bn=True, is_train=self.is_train) self.fc4 = tf.nn.dropout(self.fc4, self.keep_prob)  self.fc5 = fc(self.fc4, HN4, 10, name='fc5', relu=True, bn=True, is_train=self.is_train) self.fc5 = tf.nn.dropout(self.fc5, self.keep_prob)  self.logit = fc(self.fc5, 10, self.output_shape, name='logits', relu=False, bn=False) self.hypothesis=tf.nn.softmax(self.logit)</pre>

Fig. 13 학습모델 구조 설정

또한 Fig.14는 입출력 변수와 파라미터, 오차함수, 최적화 알고리즘을 설정을 나타낸다. 이때, X는 입력, Y는 출력을 의미하고 “keep\_prob”는 노드의 연결을 얼마나 유지할지 입력하는 변수로 이 값을 사용해 드롭아웃을 설정한다. 오차함수와 최적화 알고리즘은 Cross Entropy와 Adam Optimizer가 사용되었고 텐서플로에서 제공하는 함수를 사용하여 간단하게 구현 가능하다.

입출력 변수 및 파라미터 설정
<pre>def batch_norm(data, is_train, is_trainable=True, name=None):     return tf.layers.batch_normalization(data, training=is_train,  trainable=is_trainable, name=name)  with tf.variable_scope('input', reuse=True):     self.X = tf.placeholder(tf.float32, self.input_shape)     self.Y = tf.placeholder(tf.int32, [None, 1])     self.keep_prob = tf.placeholder(tf.float32)</pre>
오차함수 및 최적화 알고리즘 설정
<pre>cost=tf.reduce_mean(tf.nn.softmax_cross_entropy_with_logits(logits = net.logit,  labels= net.Y_one_hot)) optimizer = tf.train.AdamOptimizer(learning_rate=1e-4)</pre>

Fig. 14 모델 파라미터 설정

구현된 모델은 Train data set를 학습하며 각 학습마다 Valid data set으로 성능을 검증하고 오차 및 정확도를 측정한다. 학습은 총 8,000번 진행하였고 학습이 진행됨에 따라 Train data set 및 Valid data set에 대한 오차와 정확도의 분포는 Fig.15~Fig.18와 같이 나타났다. Fig.15~Fig.18에 제시된 모델은 앞서 설정한 은닉층 구조 형태별 Case 5가지의 첫 번째 모델(Case1-a~Case5-a)에 대한 학습 결과를 예시로 나타냈다. 나머지 15가지 Case의 그래프도 이와 비슷한 추세를 가진다. Fig.15, Fig.16에서 Train data set의 오차는 0에 가깝게 감소하고, 정확도는 1.0에 가깝게 증가한다. 이를 통해 Train data set에 대한 학습이 이루어진 것을 알 수 있

다. Valid data set의 오차와 정확도는 Fig.17, Fig.18과 같이 나타난다. 이때, Valid data set의 오차는 감소하다가 5,000번 이상 학습이 진행되면서 약간 증가하는 추세를 보인다. 이는 학습이 Train data에 과적합되는 것을 의미한다. 모델의 가중치와 편향은 Valid data set의 오차가 가장 낮을 때를 최적 값으로 저장된다. Valid data set으로 모델의 검증을 마친 뒤 Test data set을 활용한 성능평가를 통해 정확한 성능을 확인 할 수 있다.

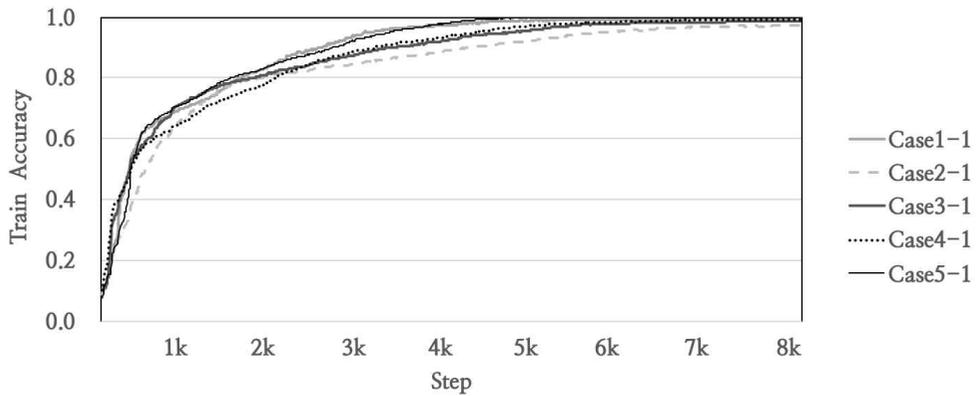


Fig. 15 Train data set 분류 정확도 변화율

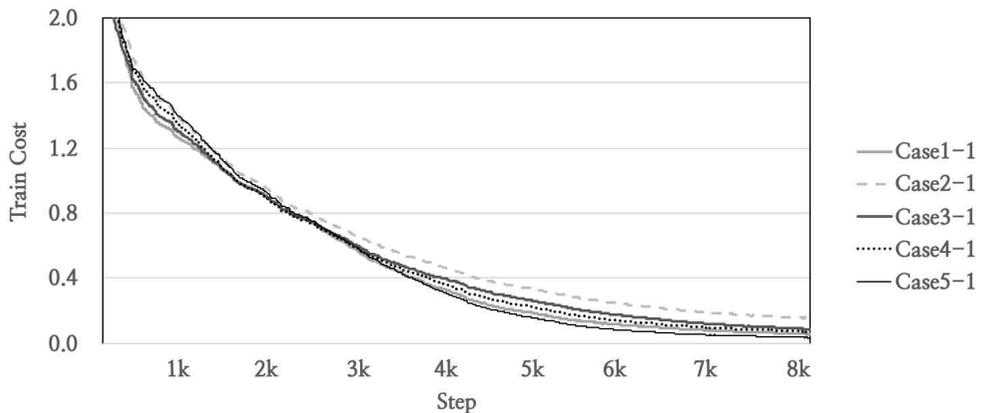


Fig. 16 Train data set의 오차 변화율

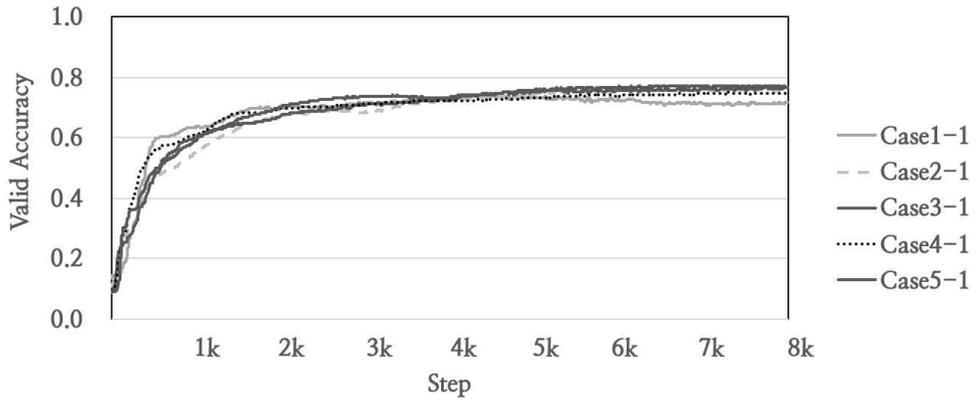


Fig. 17 Valid data set 분류 정확도 변화율

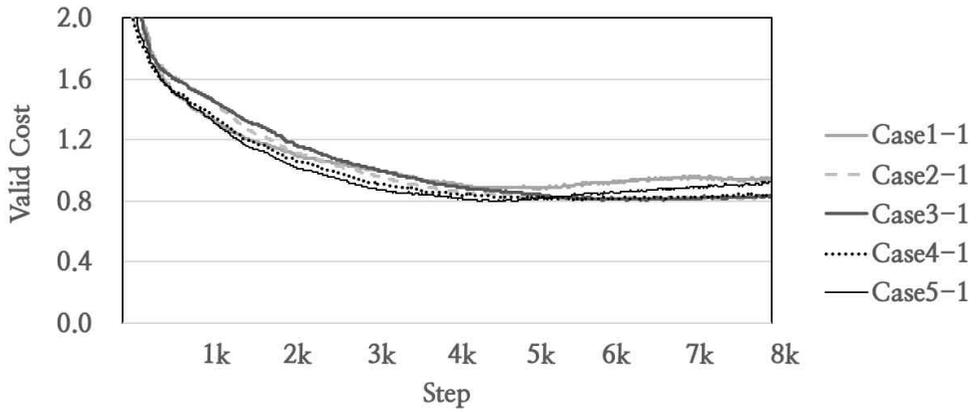


Fig. 18 Valid data set의 오차 변화율

## 제 5 장 MET 산출모델 최적화 및 성능 평가

### 5.1 MET 산출모델의 성능 평가 방법

MET 산출모델 개발을 위해 총 20가지의 은닉층 구조를 가지는 모델의 학습 및 평가를 실시하였다. 산출모델은 학습 및 검증이 완료된 모델에 대하여 Test data set을 사용하여 성능을 평가하였다. 또한 모델의 성능을 확인하기 위해 주요 성능 평가 방법인 K-fold 교차검증(Cross-Validation) 과 오차행렬(Confusion Matrix), F1 Score, ROC (Receiver Operating Characteristic curve) 곡선을 사용하였다.

#### (1) K-fold 교차검증 (Cross-Validation, CV)

K-fold 교차검증은 Train data set을 균등하게 K개의 그룹(fold)으로 나누고 각 fold를 번갈아 가면서 Train data와 Valid data로 사용하여 검증하는 방법이다. K-fold 교차검증 방법은 K번의 검증과정을 거치기 때문에 모든 Train data가 최소 한 번씩 학습된다. 이로 인해 총 데이터의 수가 적은 경우 데이터 샘플링에 의해 성능이 상이하게 나오는 것을 방지하고 모델에 대한 신뢰성을 높일 수 있다.

MET 산출모델의 성능 평가는 Test data set을 20%로 분류한 비율과 동일하게 Valid data set을 Train data set의 20% 씩 분류하기 위해 K=5인 5-fold 교차검증을 실시하였다.(Fig.19) Fig.19는 K=5인 교차검증 시 Train data set의 구성을 나타낸다. Valid data set을 변경하며 5번의 교차 검증을 수행하였고 학습이 완료된 모델에 대해 Test data를 적용하여

정확도를 측정하였다. 따라서 총 5번의 Test data set의 정확도의 평균값과 각 모델에서 도출된 정확도의 최대값으로 모델의 성능을 확인 하였다.

Train data set (80 %)					Test data set (20 %)
Fold 1 (Valid)	Fold 2	Fold 3	Fold 4	Fold 5	
Fold 1	Fold 2 (Valid)	Fold 3	Fold 4	Fold 5	
Fold 1	Fold 2	Fold 3 (Valid)	Fold 4	Fold 5	
Fold 1	Fold 2	Fold 3	Fold 4 (Valid)	Fold 5	
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5 (Valid)	

Fig. 19 5-fold 교차검증 Train data set 구성

## (2) 오차행렬 (Confusion Matrix)

오차행렬은 분류모델의 성능에 대한 보다 자세한 정보를 포함하는 방법으로 실제 정답값과 모델의 예측값을 비교한 행렬이다. 오차행렬의 행은 실제 클래스, 열은 모델의 예측클래스를 나타낸다. Fig.20은 A와 B로 구성된 이진클래스 분류기의 오차행렬 예시로 B 분류에 대한 행렬 정보를 나타낸다. 이때, TP(True Positive)는 실제로 B일 때 B로 정확히 예측한 횟수, FP(False Positive)는 실제로 A일 때 B로 잘못 예측한 횟수, TN(True Negative)는 실제로 A일 때 A로 예측한 횟수, FN(False Negative)는 실제로 B이지만 A로 잘못 예측한 횟수를 의미한다. 이와 같이 정답과 예측 값에 대한 오차행렬의 정보를 통해 분류모델의 정확도(Accuracy), 정밀도(Precision), 민감도(Recall) 등의 성능을 확인할 수 있다.

정확도는 전체 예측 결과에 대하여 정답으로 맞춘 개수로 (식 4)로 표

현된다. 정확도는 직관적이고 일반적으로 사용하는 방법이지만 분류기 요소들의 성능을 파악하기 위해 세부적인 지표를 사용한다. 세부적인 지표 중 정밀도(Positive Predictive Value, PPV)는 모델이 정답으로 예측한 데이터 중 실제 정답인 데이터의 비율로 (식 5)와 같다. 또 다른 지표인 민감도(True Positive Rate, TPR)는 실제 정답인 데이터 중 정답으로 예측한 비율을 나타내며 (식 6)과 같다. 정밀도와 민감도 두 가지 지표의 조화 평균을 사용해 단일 숫자로 요약하여 표현한 지표로 F1 score를 사용한다. F1 Score는 정확도와 민감도 두 값의 중요성을 동일하게 고려하는 모델의 경우 두 지표의 종합적 평가를 위해 사용하는 방법으로 (식 7)과 같다. 이때 F1 지표의 점수가 높을수록 정밀도와 민감도의 성능이 비슷한 분류 모델이라는 의미를 가지며 정확도로는 확인이 어려운 민감도를 고려할 수 있다.

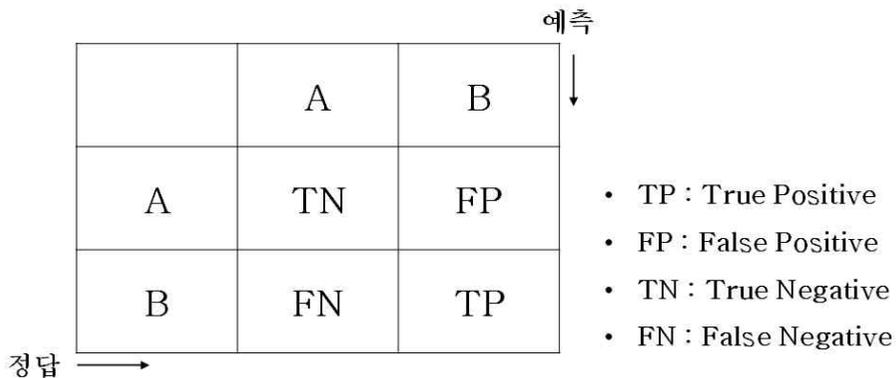


Fig. 20 B 클래스 분류기 오차행렬

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \dots\dots\dots (식 4)$$

$$PPV = \frac{TP}{TP + FP} \dots\dots\dots (식 5)$$

$$TPR = \frac{TP}{TP+FN} \dots\dots\dots (식 6)$$

$$F1 = 2 \times \frac{PPV \times TPR}{PPV + TPR} \dots\dots\dots (식 7)$$

여기서, TP : True Positive  
 FP : False Positive  
 TN : True Negative  
 FN : False Negative

### (3) ROC 커브 (Receiver Operating Characteristic curve)

ROC 커브(Receiver Operating Characteristic curve)는 이진 분류기에  
 서 사용되는 평가지표로 민감도와 거짓 양성 비율(False Positive Rate,  
 FPR)(식 8)을 고려한 그래프이다. 이때, 거짓 양성 비율은 정답이 아닌 데  
 이터를 정답으로 잘못 분류한 비율로 ‘1-특이도’라고 표현되기도 한다. 특  
 이도(True Negative Rate, TNR)는 (식 9)에 의해 계산되는 값으로 정답이  
 아닌 데이터를 정답이 아니라고 정확히 예측한 데이터의 개수를 나타낸다.  
 다시 말해 ROC 커브는 분류모델이 정답은 정답으로, 정답이 아닌 것은 정  
 답이 아닌 것으로 알맞게 예측했는지에 대한 그래프이다. (Fig.21) 이때, 민  
 감도가 높을 때 거짓 양성 비율은 낮을수록 좋은 분류 모델을 의미하므로  
 그래프가 왼쪽 위로 향할수록 분류 성능이 좋은 것을 의미한다. 분류기의  
 성능을 비교하기 위해 ROC 커브의 아래 면적(Area Under the Curve,  
 AUC)을 측정한다. 예를 들어 Fig.21의 Random 분류모델은 AUC 값이  
 0.5이고 좋은 분류모델일수록 AUC는 1에 가깝다.

$$FPR = \frac{FP}{TN+FP} \dots\dots\dots (식 8)$$

$$TNR = \frac{TN}{TN+FP} \dots\dots\dots (식 9)$$

여기서, TP : True Positive  
 FP : False Positive  
 TN : True Negative  
 FN : False Negative

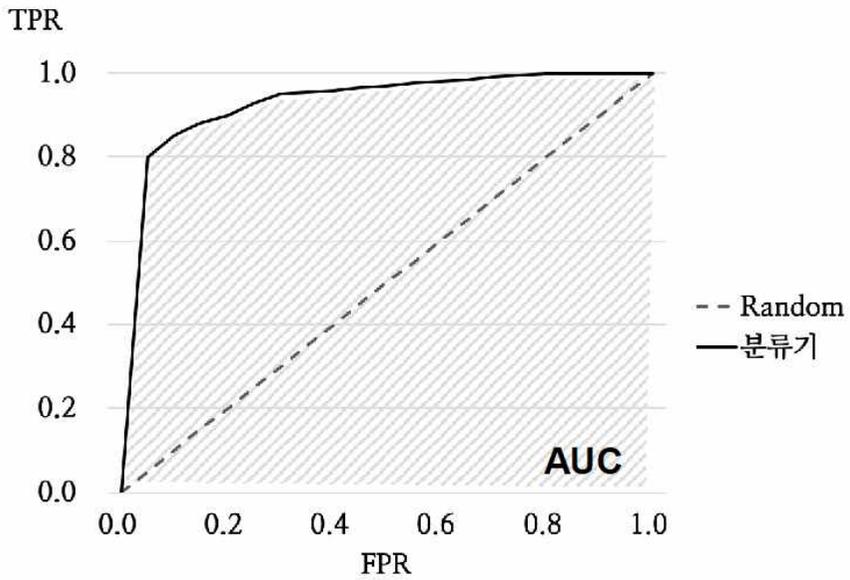


Fig. 21 ROC 커브 및 AUC 예시

## 5.2 MET 산출모델 성능 평가

### 5.2.1 은닉층 구조에 따른 모델 성능 평가

MET 산출모델은 4장에서 설정한 은닉층의 구조 Case 별로 학습을 진행하였다. 은닉층 구조별 성능평가는 MET 산출 정확도로 평가하여 모델의 10개 레이블을 통합적으로 측정하여 성능을 직관적으로 확인 할 수 있다. 이때 연구의 목적이 MET 측정에 있기 때문에 정확도는 모델의 MET 산출 정확도를 확인하였다. 다시 말해, Test data set의 정답 MET 값과 학습된 모델이 도출한 Test data set의 포즈에 해당하는 MET 값이 일치한 비율을 측정하였다. 이때 MET 산출모델은 Case 별로 5-fold Cross Validation을 진행하였고 총 데이터의 80%인 Training data set은 일정하게 유지하였다.

은닉층의 구조별 학습 결과 MET 분류 정확도는 Table 17과 같다. 이때, Table 17은 5-fold Cross Validation을 통해 5번에 걸쳐 도출된 각 모델의 평균 정확도 값을 나타냈다. 평균 정확도 결과, 가장 높은 값을 가지는 모델은 은닉층 4개와 은닉뉴런 140-112-84-56개의 구조를 가지는 Case5-b로 82.03%를 나타낸다. 모델의 평균 정확도는 77.14% ~ 82.03% 사이로 최대 4.9% 정도의 차이를 보인다. 하지만 5번의 학습을 과정 중 각 모델에서 발생하는 최대 정확도와 최소 정확도의 차이는 약 8.2%의 차이를 보인다. 이때 최대 정확도는 Table 18에 제시되었으며 평균 정확도와 같이 Case5-b 구조에서 최대 83.64%를 나타낸다. 선행된 최은지<sup>51)</sup>의 연구 결과와 비교하였을 때 정확도가 다소 낮게 도출되었으나 이는 본 연구에서 Test data set의 수가 기존에 비해 6배 증가하였기 때문에 더 다양한 포즈를 평가한 결과로 해석된다. 정확도는 다소 낮게 측정되었지만 선행 연

---

51) 최은지, op. cit., p.17

구에서 수행하지 않은 오차행렬, ROC 커브 등 분류 모델의 다른 성능평가 지표를 사용하여 각 레이블 별 분류 성능을 추가로 실시하였다. 이때 가장 정확도가 높은 Case 5-b 구조에 대하여 MET 값(0.7~1.7)에 따른 성능 평가를 실시하였다.

Table 17. MET 산출모델의 은닉층 구조별 평균 정확도(%)

은닉층 구조		Cases				
		1	2	3	4	5
구 분	a	77.14	80.80	80.42	80.50	81.94
	b	78.18	80.93	80.60	80.00	82.03
	c	80.31	80.27	81.28	81.15	81.32
	d	78.67	80.52	81.39	80.54	81.82

Table 18. MET 산출모델의 은닉층 구조별 최대 정확도(%)

은닉층 구조		Cases				
		1	2	3	4	5
구 분	a	78.58	82.16	81.80	81.51	83.39
	b	79.39	83.18	81.53	81.74	83.64
	c	81.59	81.64	82.10	83.07	82.71
	d	80.54	80.89	82.72	83.59	82.52

### 5.2.2 MET 값에 따른 모델 성능 평가

최대 정확도 83.64%를 가지는 Case 5-b 모델의 MET 값에 따른 분류 성능 평가의 결과 MET 값을 기준으로 나타낸 오차행렬은 Table 19와 같다. 이때 MET 값은 4장 Table.6에 제시된 각 포즈에 해당하는 MET값을 의미한다. 오차 행렬의 열은 정답 MET를 나타내고 행은 모델을 통해 산

출한 MET 값을 나타낸다. 개발된 MET 산출모델은 예측한 MET가 실제 MET와 같은 비율인 정밀도(PPV)와 정답 MET가 정답으로 예측된 비율인 민감도(TPR) 모두 중요하게 고려되어야 한다. 따라서 오차행렬을 통해 각 MET의 값에 대한 산출 정밀도(PPV)와 민감도(TPR) 및 두 값을 동시에 고려한 F1 Score를 통해 성능을 파악하였다. F1 Score는 분류모델의 성능을 파악하는데 주로 사용되며 기존 문헌 중 비격식 문서를 본 연구와 같이 10가지 카테고리로 분류하는 모델은 F1 Score 0.72의 성능을 보이고<sup>52)</sup>, 한국어 개체명 인식기 모델의 경우 F1 Score 0.86의 성능을 보인다.<sup>53)</sup> Table 20에는 각 MET에 해당하는 정밀도, 민감도, F1 Score가 제시되어 있고, F1 Score의 값은 ‘typing’에 해당하는 MET 1.1의 경우 0.931로 가장 높다. MET 1.2의 경우 ‘standing.relaxed’, ‘filing.seated’ 두 가지 활동을 포함하며 0.733으로 가장 낮은 성능을 보인다. 하지만 분류모델을 개발한 기존 연구에서 제시한 F1 Score의 성능과 비교하여 높은 값을 나타냈다.

---

52) 이호경, 양선, 고영중. (2016). 비격식 문서 분류 성능 개선을 위한 LDA 단어 분포 기반의 자질 확장. 정보과학회논문지, 43(9), 1008-1014.

53) 이창기, 장명길. (2010). Structural SVMs 및 Pegasos 알고리즘을 이용한 한국어 개체명 인식. 인지과학, 21(4), 655-667.

Table 19. MET 값에 따른 Case 5-b 모델의 오차행렬

정답 \ 예측	예측						
	0.7	0.8	1.0	1.1	1.2	1.4	1.7
0.7 (sleeping)	1707	46	118	0	26	0	83
0.8 (reclining)	17	1608	139	0	216	0	0
1.0 (seated.quiet, reading.seated, writing)	207	13	5132	60	524	0	4
1.1 (typing)	2	0	99	1782	97	0	0
1.2 (standing.relaxed, filing.seated)	188	0	238	0	3125	1	408
1.4 (filing.stand)	0	0	9	0	254	1589	128
1.7 (walking about)	0	0	10	6	319	27	1618

Table 20. MET 값에 따른 Case 5-b 모델의 PPV, TPR, F1 Score

MET	PPV	TPR	F1 Score
0.7	0.805	0.862	0.832
0.8	0.965	0.812	0.882
1.0	0.893	0.864	0.878
1.1	0.964	0.900	0.931
1.2	0.685	0.789	0.733
1.4	0.983	0.803	0.884
1.7	0.722	0.817	0.767

또한, MET가 제대로 분류되었는지 확인을 위해 Test data set의 출력 결과로 도출된 ROC 곡선을 사용하였다. ROC 곡선은 이진 분류에서 사용하는 평가 지표이기 때문에 Fig.22~Fig.28와 같이 각 MET를 이진 분류로 간주하여 그래프를 생성하였다. 각 ROC 커브의 AUC 면적에 따라 분류 알고리즘 성능은 Table 21과 같이 판단된다.<sup>54)</sup> AUC가 1.0일 경우 완벽한

54) Muller, M. P., Tomlinson, G., Marrie, T. J., Tang, P., McGeer, A., Low, D. E.,

분류 알고리즘이며 0.9 이상일 경우 탁월, 0.8 이상 0.9 미만을 양호로 판단한다. 각 MET의 분류 결과는 MET 1.2('standing.relaxed', 'filing.seated')와 1.7('walking about')일 경우를 제외하고 AUC가 0.9 이상을 나타내는 탁월한 알고리즘이며 MET 1.2(Fig.26)와 1.7(Fig.28)의 경우도 AUC가 0.8 이상이므로 양호한 수준이다.

분류 성능이 다소 낮은 MET 1.2는 MET 1.7('walking about')로 잘못 분류한 비율이 가장 높았다. 그밖에도 MET 1.0('reading.seated', 'writing', 'seated.quiet')과 MET 0.7('sleeping')로 잘못 분류되는 것을 확인하였다. 또한 MET 1.7의 경우도 MET 1.2로 잘못 분류하는 비율이 가장 크게 나타났다. 이러한 이유는 MET 1.2와 1.7에 포함되는 포즈 중 'standing.relaxed'와 'walking about'에 대해 두 포즈를 서로 잘못 분류한 결과인 것으로 확인되었다. 이는 가만히 서있는 포즈와 걷고 있는 포즈의 분류 시 오차가 발생할 가능성이 크다는 것을 의미한다. 이러한 이유는 걷고 있을 경우 때에 따라 관절의 좌표가 서있을 때와 비슷한 경우가 발생하기 때문으로 판단된다. 이와 같은 한계를 해결하고 정확도 향상을 위해 추후 연속적인 활동 이미지에 대한 MET를 산출하여 대표 값을 설정하는 방법으로 서있을 때와 걷고 있을 때를 구분할 수 있을 것으로 사료된다.

---

Detsky, A. S., & Gold, W. L. (2005). Can routine laboratory tests discriminate between severe acute respiratory syndrome and other causes of community-acquired pneumonia?. *Clinical infectious diseases*, 40(8), 1079-1086.

Table 21. AUC 면적에 따른 알고리즘 성능 기준

AUC 면적	알고리즘 성능 판단
$0.9 \leq \text{AUC}$	탁월
$0.8 \leq \text{AUC} < 0.9$	양호
$0.7 \leq \text{AUC} < 0.8$	보통
$\text{AUC} < 0.7$	불량

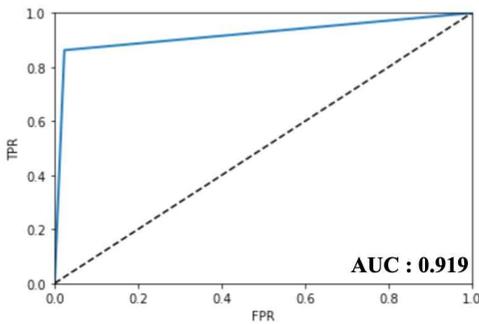


Fig. 22 MET = 0.7 ROC curve

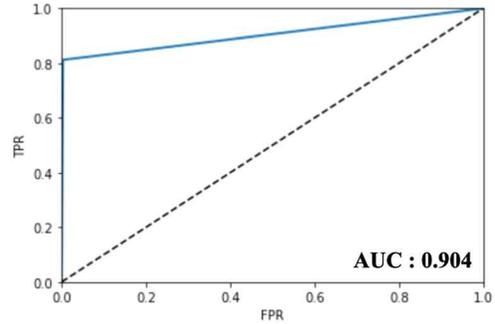


Fig. 23 MET = 0.8 ROC curve

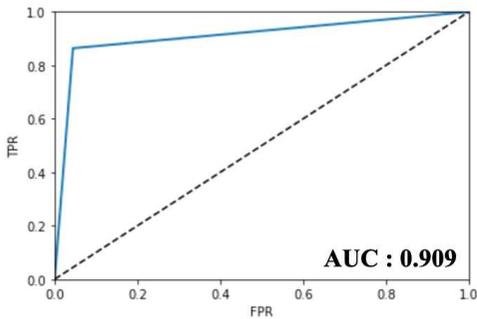


Fig. 24 MET = 1.0 ROC curve

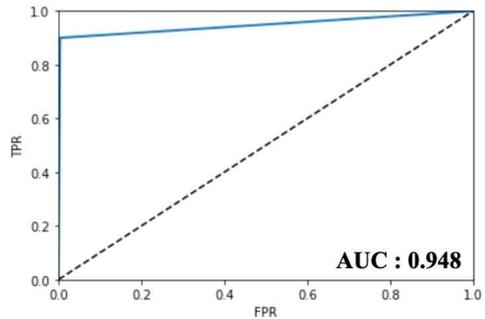


Fig. 25 MET = 1.1 ROC curve

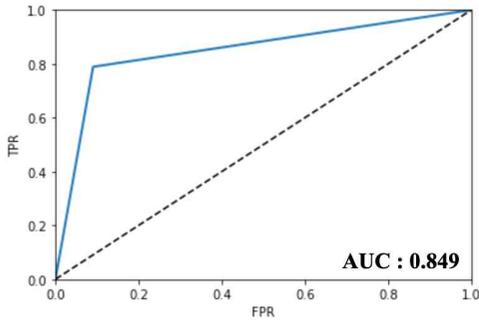


Fig. 26 MET = 1.2 ROC curve

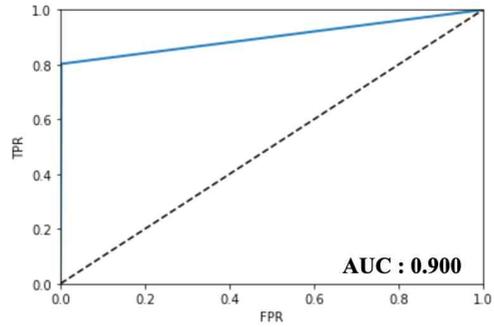


Fig. 27 MET = 1.4 ROC curve

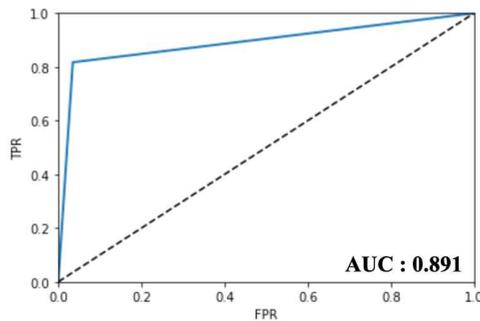


Fig. 28 MET = 1.7 ROC curve

### 5.3 소결

MET 산출모델의 평가를 위해 은닉층의 구조별 성능평가를 실시하여 최적 모델의 구조를 도출하고 최적 모델의 각 MET 값 별로 정확도 및 분류 성능을 평가하였다. 성능 평가를 위해 모델의 정답 산출 정확도와 F1 Score, ROC 곡선을 사용하였다. 결과적으로, 최적 은닉층 구조는 20 개의 구조 중 Case5-b로 은닉층 4개와 은닉뉴런 140-112-84-56개의 구조를 가진다. 해당 구조를 가지는 모델의 최대 정확도는 83.64%이며 추가로 각 MET 값에 따른 분류 성능을 F1 Score와 ROC 곡선의 AUC를 통해 분석하였다. 그 결과 ‘standing.relaxed’, ‘filing.seated’에 해당하는 MET

1.2와 'walking about'에 해당하는 MET 1.7의 분류기를 제외한 나머지 MET 값의 분류기는 F1 Score 0.8 이상의 값을 나타내며 AUC 값은 0.9로 탁월한 알고리즘 성능을 보인다.

MET 값에 따른 분류기 중 MET 1.2와 MET 1.7의 성능이 다소 낮은 이유로 MET 1.2의 활동 중 'standing.relaxed'와 MET 1.7에 해당하는 'walking about'이 서로 잘 못 분류한 경우가 가장 많이 발생하는 것으로 나타났다. 이는 단일 이미지 상에서 서있을 때와 걷고 있을 때의 포즈가 관절 좌표의 측면에서 비슷하게 나타나는 경우가 많기 때문이다. 따라서 추후 재실자의 활동 이미지를 연속적으로 고려하여 대푯값을 도출함으로써 서있는 활동과 걷는 활동을 구분하여 이를 통해 성능 향상이 가능할 것으로 판단된다.

## 제 6 장 결 론

본 연구는 실내 PMV 예측 제어를 위해 재실자의 개인적 요소 중 MET를 산출하고자 인체 관절 좌표를 통해 포즈 및 MET를 출력하는 MET 산출모델 개발을 진행하였다. 기존의 간접적인 MET 측정의 한계를 해결하고 근본적인 행동인식 기반의 MET 측정을 위해 지능형 모델을 적용하였다. 따라서 재실자의 이미지를 통해 MET를 측정 할 수 있는 딥러닝 기반의 MET 산출모델 개발 및 성능평가를 실시하였다.

MET 산출모델의 개발 및 성능평가 결과는 다음과 같다.

(1) MET 산출모델의 학습을 위해 ASHRAE에서 제시하고 있는 활동별 MET를 기준으로 일반적인 실내활동 10가지를 선정하고 이미지 데이터를 수집하였다. 총 500개의 실내활동 이미지 데이터를 구축하였고 이미지 상의 인체 관절 14개의 절대좌표 (x, y) 값을 추가로 구축하였다. 구축된 데이터는 500개를 이미지 좌우반전, 회전, 스케일 조정 등의 전처리 과정을 통해 증가시켜 총 198배 증가된 99,000개의 데이터를 학습하였다. 이때 Train data set은 전체 데이터의 80%, Test data set은 전체 데이터의 20%로 구성하였다.

(2) MET 산출모델의 구조는 입력층, 은닉층, 출력층과 14쌍의 관절 좌표가 입력되는 28개의 입력뉴런 및 포즈를 출력하는 1개의 출력뉴런으로 구성된다. 은닉층은 형태별로 5가지 Case로 구성하였고 은닉층 수와 은닉뉴런의 수를 변경하며 총 20가지 구조의 학습을 진행하였다. 또한 모델의 학

습 파라미터와 오차 함수 및 최적화 알고리즘을 설정하였다.

(3) 모델의 평가를 위해 학습 시 K-fold Cross Validation을 적용하여 은닉층 구조 별로 5번의 학습과 검증 과정을 실시하였다. 모델의 성능 평가를 위해 학습 데이터의 정답 MET와 모델의 결과로 측정된 MET를 비교하여 정확도, F1 Score, ROC 커브를 평가 지표로 사용하였다. 각 모델의 K-fold Cross Validation을 통해 평균 정확도와 최대 정확도를 분석하였고 최대 정확도를 보이는 모델은 NHL : 4와 NHN : 140-112-84-56의 구조를 가지며 83.64%의 정확도를 보였다. 또한 최대 정확도를 보이는 모델에 대하여 MET 값에 따른 분류 성능 평가 결과, 모든 MET 값에 대해 F1 Score는 MET 1.1(typing)일 때 최대 0.931, MET 1.2('filing.seated', 'standing.relaxed')일 때 최소 0.733으로 나타났다. 또한 ROC 커브의 AUC는 7개의 MET 중 5개가 0.9 이상, 2개가 0.8 이상을 나타냈다. 즉, 각각의 MET를 분류하는 알고리즘의 성능이 양호한 수준으로 MET 산출모델의 개발을 통해 실내 재실자의 MET를 측정하는 방법의 가능성을 확인할 수 있다.

본 연구의 한계점은 모델의 학습을 위해 구축한 이미지의 수가 500개로 다소 적었으며 실내활동의 범위를 제한하였기 때문에 실제 적용 시 다양한 활동에 대한 MET 측정에 제한이 있다. 이와 같은 한계점 개선을 위해 도구를 인식하는 모델의 개발 등을 통해 실내활동의 범위를 다양하게 늘리고 이미지 데이터를 추가로 수집하는 등 모델 성능 개선을 위한 연구가 지속될 필요가 있다.

또한 개발된 MET 산출모델은 선행되는 관절 인식모델과 결합하여 실내 재실자의 이미지만으로 MET를 산출할 수 있게 된다. 추후 개발될

PMV 알고리즘은 본 연구의 MET 산출모델을 사용하여 일정 제어기간 동안 재실자의 MET를 지속적으로 산출하고 MET의 대푯값을 적용한다. 예를 들어 Fig.29와 같이 15분의 제어기간 동안 10초에 한 번씩 MET를 산출하여 총 90번 산출된 MET의 평균 또는 빈도가 가장 높은 값을 대푯값으로 사용한다. 이러한 대표 MET 값은 기존 83.64%의 정확도를 보이는 모델의 결과를 여러 번 산출하여 결정되는 값이기 때문에 제어 시 기존보다 향상된 정확도를 나타낼 수 있을 것으로 사료된다.

결론적으로 MET 산출모델은 Fig.30과 같이 선행 모델인 좌표 인식모델과 결합하여 MET를 산출하여 추후 연구로 진행될 PMV 제어 알고리즘에 적용한다. 또한 PMV 제어 알고리즘에 의해 설정된 MET 대푯값은 PMV 계산에 사용되어 PMV 기반의 실내 쾌적 제어의 기반을 형성한다. MET 산출모델과 PMV 제어 알고리즘의 개발을 통해 재실자 맞춤 PMV 제어가 가능해지면 기존 독립제어 방법 보다 쾌적한 실내환경 조성 및 건물 에너지 효율 극대화를 달성할 수 있을 것으로 판단된다.

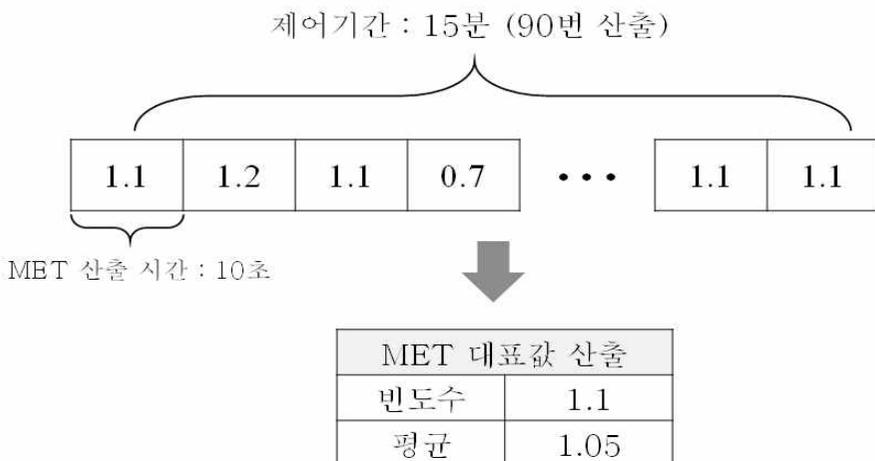


Fig. 29 PMV 제어 알고리즘의 MET 대푯값 산출 방법 예시

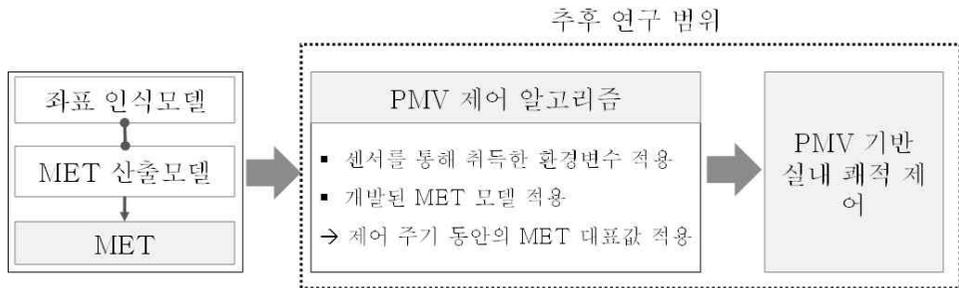


Fig. 30 추후 MET 산출모델의 PMV 제어 시 적용 방법

## 참 고 문 헌

### <국내문헌>

1. 강인성, 문진우, 박진철. (2017). 최근 건축분야의 인공지능 기계학습 연구 동향. 대한건축학회 논문집-구조계, 33(4), 63-68.
2. 건축환경공학, 2004, 김재수, 도서출판 서우, 제8-159호
3. 김상훈. (2015). 실내 온열 쾌적을 위한 PMV단순화 제어 프레임워크 개발, 서울과학기술대학교, 박사학위논문
4. 김성경, 홍원화, 류지혜. (2017). 공동주택 내 온열환경 제어기준을 통한 냉방기기 운전 시 거주자 쾌적성에 관한 연구. 대한건축학회 논문집 - 구조계, 33(11), 43-52.
5. 김현희, 이경창, 이석. (2014). 인간 적응형 가전기기를 위한 거주자 심박동 기반 신체활동량 추정. 제어로봇시스템학회 논문지, 20(5), 486-494.
6. 나카이 에츠지. (2017). 텐서플로로 시작하는 딥러닝 (진명조 역). 제이펍.
7. 문성은, 장수범, 이정혁, 이종석. (2016). 기계학습 및 딥러닝 기술동향. 한국통신학회지 (정보와통신), 33(10), 49-56.
8. 문진우. (2011). PMV, TS 기준 건물 열 환경 제어법의 성능 및 적용성 분석. 설비공학논문집, 23(6), 430-440.
9. 박은주, 김현희, 이경창, 이석. (2010). 인간 적응형 냉난방기를 위한 ZigBee 위치 기반 신체활동량 추정 알고리즘. 한국정밀공학학회 학술발표대회 논문집, 763-764.
10. 박진철. (2012). 국내·외 친환경건축물 인증제도 비교분석 연구. 부동산 FOCUS 통권, 15호, 29-42.
11. 성남철, 윤동원. (2010). 공동주택에서 쾌적지표를 활용한 난방제어 시 온열환경 변화와 에너지소비 특성에 관한 연구. 한국생활환경학회지, 17(6), 758-765.
12. 윤근영. (2015). 실내환경 쾌적 제어와 건물 에너지. 설비저널, 44(8),

24-30.

13. 이창기, 장명길. (2010). Structural SVMs 및 Pegasos 알고리즘을 이용한 한국어 개체명 인식. 인지과학, 21(4), 655-667.
14. 이혜진. (2016). PMV 기반 냉난방 제어시스템을 위한 사용자 활동량 측정 및 IoT 센서 데이터 결합 프레임워크, 아주대학교 석사학위논문
15. 이호경, 양선, 고영중. (2016). 비격식 문서 분류 성능 개선을 위한 LDA 단어 분포 기반의 자질 확장. 정보과학회논문지, 43(9), 1008-1014.
16. 이호기, 김현희, 이경창, 이석. (2008). 스마트 홈을 위한 심박동 기반 냉난방 제어 시스템. 제어로봇시스템학회 국내학술대회 논문집, 432-435.
17. 장향인, 서승직. (2013). PMV 제어에 따른 사무소 건물의 실내열환경과 에너지소비량 분석. 한국태양에너지학회 논문집, 33(4), 15-22.
18. 최은지, 박보량, 최영재, 문진우. (2018). 재실자 활동량 산출을 위한 Pose 분류 모델 개발, KIEAE Journal, 18(5), 93-98
19. 한지훈, 최은지, 문진우, 유용석. (2018). 심층신경망 기반 재실자 이미지 학습을 통한 인체 관절 인식 모델 개발. 한국생활환경학회 추계학술대회 논문집. 47-48
20. 홍성협, 도성록, 이광호. (2018). 아파트 건물에서 재실자 활동량이 고려된 PMV제어에 따른 연간 국가 차원의 1차 에너지 및 온실가스 감축량 분석, 대한건축학회논문집, 34(10), 37-44.

## <국외문헌>

1. ANSI/ASHRAE. (2010). ANSI/ASHRAE Standard 55 Thermal Environmental Conditions for Human Occupancy. ASHRAE. Atlanta.
2. Attoue, N., Shahrour, I., & Younes, R. (2018). Smart building: Use of the artificial neural network approach for indoor temperature forecasting. Energies, 11(2), 395.
3. Aurélien G. (2017). Hands-On Machine Learning with Scikit-Learn & TensorFlow. O'Reilly Media.

4. Chen, Z., Masood, M. K., & Soh, Y. C. (2016). A fusion framework for occupancy estimation in office buildings based on environmental sensor data. *Energy and Buildings*, 133, 790–798.
5. Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303–314.
6. Deng, Z., & Chen, Q. (2018). Artificial neural network models using thermal sensations and occupants' behavior for predicting thermal comfort. *Energy and Buildings*, 174, 587–602.
7. Fanger, P.O., (1970), *Thermal Comfort*, Copenhagen: Danish Technical Press.
8. Hasan, M. H., Alsaleem, F., & Rafeie, M. (2016). Sensitivity study for the PMV thermal comfort model and the use of wearable devices biometric data for metabolic rate estimation. *Building and Environment*, 110, 173–183.
9. Hebb, D. O. (1949). *The organization of behavior*
10. Hong, S., Lee, J., Moon, J., & Lee, K. (2018). Thermal Comfort, Energy and Cost Impacts of PMV Control Considering Individual Metabolic Rate Variations in Residential Building. *Energies*, 11(7), 1767.
11. Humphreys, M. A. & Nicol, J. F., (2002), The validity of ISO-PMV for predicting comfort votes in every-day thermal environments, *Energy and Buildings*, Vol. 34, pp. 667–684
12. Hunter, D., Yu, H., Pukish III, M. S., Kolbusz, J., & Wilamowski, B. M. (2012). Selection of proper neural network sizes and architectures – A comparative study. *IEEE Transactions on Industrial Informatics*, 8(2), 228–240.
13. Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*.
14. ISO 7730, *Ergonomics of the thermal environment*, 2005.

15. Kaiming, H, Georgia, G, Piotr, D, & Ross, G. (2017). Mask R-CNN, arXiv : 1703.06870
16. McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 5(4), 115-133.
17. Moon, J. W., Park, J. C., & Kim, S. (2018). Development of control algorithms for optimal thermal environment of double skin envelope buildings in summer. Building and Environment, 144, 657-672.
18. Muller, M. P., Tomlinson, G., Marrie, T. J., Tang, P., McGeer, A., Low, D. E., Detsky, A. S., & Gold, W. L. (2005). Can routine laboratory tests discriminate between severe acute respiratory syndrome and other causes of community-acquired pneumonia?. Clinical infectious diseases, 40(8), 1079-1086.
19. Zuraimi, M. S., Pantazaras, A., Chaturvedi, K. A., Yang, J. J., Tham, K. W., & Lee, S. E. (2017). Predicting occupancy counts using physical and statistical Co2-based modeling methodologies. Building and Environment, 123, 517-528.

## <Web Site>

1. 녹색건축인증. (2018. 11). 인증제도 개요, <http://gseed.greentogogether.go.kr/sys/cis/actionVerifyOuln.do>
2. Analytics Vidhya. (2018, 11). 25 Open Datasets for Deep Learning Every Data Scientist Must Work With, <https://www.analyticsvidhya.com/blog/2018/03/comprehensive-collection-deep-learning-datasets/>
3. IMAGENET. (2018. 11). ImageNet and MS COCO Visual Recognition Challenges Joint Workshop. <http://image-net.org/challenges/ilsvrc+mscoco2015>
4. The Asimov Institute, (2018. 12), The Neural Network Zoo, <http://www.>

[asimovinstitute.org/neural-network-zoo/](http://asimovinstitute.org/neural-network-zoo/)

## 국 문 초 록

# 딤러닝 기반 재실자 포즈별 MET 산출모델 개발

최 은 지

건축학과 건축환경계획 전공  
중앙대학교 대학원

재실자의 건강, 생산성, 삶의 질 향상을 위해 건물의 쾌적한 열환경 제공의 중요성이 강조되고 있다. 실내 열환경의 지표 중 PMV는 실내의 환경적 요소와 개인적 요소를 모두 고려하는 통합적 열 쾌적 지표로 적용되지만 활동량(MET)과 같은 개인적 요소의 측정에 한계가 있다. 또한 기존의 MET 측정 방법은 간접적인 측정을 기반으로 재실자의 부수적인 정보를 사용하였고 부착형 또는 휴대형 측정기기 사용하는 등 적용에 제한이 있었다. 이러한 방법은 MET 측정에 있어 오차를 야기하고 정확도 향상에 한계가 발생한다. 이와 같은 한계점을 해결하기 위해 재실자의 부수적인 정보 없이도 활동을 구분할 수 있고 건물에 적용이 쉬운 근본적인 MET 측정 방법이 요구되었다.

따라서 본 연구에서는 실내에서 재실자의 이미지를 사용하여 실내활동을 구분하고 MET를 측정하기 위해 딤러닝 알고리즘을 사용한 지능형 MET 산출모델 개발을 진행하였다. MET 산출모델은 실내 카메라 센서

로 수집된 이미지의 인체 관절 좌표를 사용해 재실자의 포즈를 분류하고 MET를 측정한다. 모델의 개발을 위해 10가지 실내 활동 이미지 총 500개를 수집하였고 다양한 데이터 증가 기법을 적용하여 198배 증가시켰다. MET 산출모델의 구조는 입력층, 은닉층, 출력층과 관절 좌표가 입력되는 28개의 입력뉴런, 포즈를 출력하는 1개의 출력뉴런으로 구성된다. 은닉층은 형태별로 5가지 Case로 구성하였고 은닉층 수와 은닉뉴런의 수를 변경하며 총 20가지 구조에 대한 학습을 진행하였다.

모델의 평가는 학습 데이터의 정답 MET와 모델의 결과로 측정된 MET의 비교를 통해 진행되었다. 먼저, K-fold Cross Validation을 통해 최대 정확도를 보이는 모델은 은닉층 4개와 은닉뉴런 140-112-84-56으로 구성되며 83.64%의 정확도를 보였다. 최대 정확도를 보이는 모델의 MET 값에 따른 모든 ROC 커브의 AUC가 0.8 이상의 값을 나타내므로 분류 알고리즘의 성능이 양호한 수준이다.

MET 산출모델의 개발을 통해 실내 영상 이미지를 이용한 재실자의 MET를 측정하는 방법의 가능성을 확인하였다. 추후 실내활동의 범위를 늘리는 등 모델의 성능을 향상시켜 개인적 요소를 고려하는 PMV 예측 제어의 기반을 형성할 것으로 기대한다.

---

핵심어 : 열환경, 평균온열감, 활동량, 딥러닝 신경망, 실내활동

# ABSTRACT

## Development of Deep Learning Model for Estimating MET of Occupant Pose

Choi, Eun Ji

Major in Environmental Design in Architecture  
Department of Architecture and Building Science  
The Graduate School of Chung-Ang University

Providing a comfort indoor thermal quality for improving the life quality, productivity, and health of occupants is important. Predicted mean vote (PMV) can be applied as an integrated thermal comfort indicator that considers both the environmental and individual factors such as metabolic rate (MET) of the indoor. However, the MET have limitations for measurement such as requiring subsidiary information of the occupants or using an attachable device. The limitations of measurement cause errors and limits the improvement of accuracy. Therefore, a new method for estimating the occupant metabolic rate (MET) that is fundamental and convenient to apply to buildings is needed.

The aim of this study was to develop an intelligent occupant MET estimation model by using a deep learning algorithm by occupant pose indoor. The MET estimation model classifies the occupant pose and MET using the human joint coordinates from an image that is captured by an indoor camera sensor. For the

MET estimation model, 500 images of 10 indoor activities were collected and various data augmentation techniques were applied to increase the data. The model has an input layer, hidden layer, output layer, and 28 input neurons for 14 pairs of coordinates and 1 output neuron for one estimated pose. Moreover, the model was trained using 20 cases of different models, which included various shapes of the hidden layer based on the number of hidden layers and hidden neurons.

The evaluation of the MET estimation model was performed by comparing the labelled and estimated MET. As a result of the training, the maximum accuracy achieved was 83.64% from the Case 5-b model that included 4 hidden layers and 140-112-84-56 hidden neurons. Also, the Case 5-b model was evaluated based on MET of each activity using the Receiver operating characteristic (ROC) curve. Because the Area under the curve (AUC) of the ROC curve was more than 0.8 for all the MET values, the performance of each classification algorithm was regarded as good.

In conclusion, by the development of the MET estimation model, the possibility of estimating the occupant MET from indoor images was confirmed. In the future, it is expected that the MET estimation model will form the basis of PMV predictive control considering the individual factors by improving the performance of the model.

---

**Keyword : Thermal environment, PMV (Predicted Mean Vote), MET (Metabolic rate), Deep Learning, Indoor activity**