



재실자 중심 열환경 제어를 위한 체질량지수 기반 열쾌적 보정계수 개발 및 성능 비교 분석

Development and Comparative Analysis of BMI-Based Thermal Comfort Correction Coefficients for Occupant-Centric Thermal Environment Control

이혜원* · 윤지영** · 문진우***

Hae Won Lee* · Ji Young Yun** · Jin Woo Moon***

* Main author; Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (haewonlee07@gmail.com)

** Coauthor; Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (yjy5350@cau.ac.kr)

*** Corresponding author; Professor, School of Architecture and Building Science, Chung-Ang Univ., South Korea (gilerbert73@cau.ac.kr)

ABSTRACT

Purpose: Thermal comfort is a critical determinant of occupant health and well-being, and the predicted mean vote (PMV) model has been widely adopted as a standard tool for its assessment. However, PMV consistently shows systematic discrepancies with actual thermal sensation votes (TSV) due to its limited capacity to reflect individual physiological characteristics such as body mass index (BMI). This study aims to address this limitation by developing BMI-based PMV correction coefficients. **Method:** Using the ASHRAE Global Thermal Comfort Database II, PMV prediction errors were analyzed across BMI categories. The corrected index PMV* is defined as $PMV^* = PMV + t$, where t is a data-driven correction coefficient derived for each combination of BMI category and PMV range. Two models were developed in parallel: a Ridge PMV* model prioritizing interpretability and an XGBoost PMV* model focusing on prediction accuracy, both providing correction coefficient lookup tables. **Result:** The Ridge PMV* model reduced MAE and RMSE by approximately 8.7% and 8.3% compared to the baseline PMV, while the XGBoost PMV* model achieved superior performance with reductions of approximately 24.0% and 20.2%, respectively. The proposed approach is expected to serve as a practical foundation for occupant-centric thermal environment control, particularly when integrated with non-intrusive image-based BMI estimation technologies.

KEYWORD

체질량지수
재실자 중심 제어
예측 평균 온열감
보정계수

Body Mass Index
Occupant-Centric Control
Predicted Mean Vote
Correction Coefficients

ACCEPTANCE INFO

Received May 14, 2026
Final revision received May 27, 2026
Accepted Jun. 2, 2026

© 2026. KIEAE all rights reserved.

1. 서론

1.1. 연구의 배경 및 목적

현대인은 하루 중 약 90%의 시간을 실내에서 보내며, 실내 공간은 현대인의 생활 전반에 걸친 주요 활동 공간으로 자리하고 있다[1]. 이에 따라 실내 환경의 질(indoor environmental quality, IEQ)은 재실자의 건강, 생산성, 만족도 및 삶의 질과 밀접하게 관련되며, 그 중요성이 높아지고 있다[2]. IEQ를 구성하는 다양한 요인 중에서도 열환경은 재실자가 가장 직접적으로 체감하는 요인 중 하나이다. 과도하게 덥거나 추운 환경은 열적 불쾌감을 유발할 뿐 아니라 업무 효율 저하, 집중력 감소, 피로 증가 및 건강상의 문제로 이어질 수 있으며, 반대로 적절한 열환경은 재실자의 쾌적감과 만족도를 높이고, 심리적 안정과 업무 수행을 지원하는 조건이 된다[3,4]. 이처럼 실내 열환경은 재실자의 열쾌적과 건강, 업무 수행에 직접적인 영향을 미치는 만큼, 건물 냉난방 시스템은 단순히 일정한 실내 온도를 유지하는 수준을 넘어 재실자의 실제 열적 반응과 상태를 고려하는 방향으로 운영될 필요가 있다. 그러나 열쾌적 반응은 개인에 따라 다르게 나타나므로, 재실자 중심의 열환경 제어를 실현하기 위해서는 열

적에 영향을 미치는 요인을 우선적으로 파악할 필요가 있다.

재실자가 느끼는 열쾌적은 다양한 요인들이 복합적으로 작용하여 결정된다. 구체적으로 실내온도(T_a), 평균복사온도(T_r), 상대습도(RH), 기류속도(v_a)와 같은 환경변수와 활동량(metabolic rate, MET), 착의량(clothing insulation, CLO)과 같은 동적변수, 그리고 체질량지수(body mass index, BMI), 연령(age), 성별(gender)과 같은 개인특성이 상호작용한다. 이 중 환경변수와 동적변수에 대해서는 비교적 많은 연구가 이루어져 왔으나, 개인특성이 열쾌적에 미치는 영향은 상대적으로 주목받지 못해왔다. 그러나 최근 연구들에서는 BMI, 성별, 연령이 인체 생리 반응과 열감각에 영향을 미칠 수 있음이 보고되었으며[5], 자연환기 건물을 대상으로 한 현장 연구에서도 이러한 개인 특성에 따라 열쾌적 반응이 달라질 수 있음이 확인되었다[6]. 이는 개인특성이 재실자의 열쾌적 반응 차이를 설명하는데 유의미한 요인으로 작용할 수 있음을 보여준다. 나아가 열쾌적은 동일한 환경 조건에서도 재실자의 생리적·신체적 특성에 따라 다르게 나타날 수 있으며, 이러한 개인 간 차이는 평균적 재실자 조건을 전제로 하는 기존 열쾌적 평가 방식에서 예측 오차의 원인으로 작용할 가능성이 있다. 따라서, 재실자의 실제 열쾌적 반응을 보다 정확하게 반영하기 위해서는 개인특성을 고려한 열쾌적 평가 접근이 필요하다.

이러한 개인 특성 중에서도 BMI는 체지방량, 체표면적, 열저항 특성과 관련된 지표로서 인체의 열조절 과정과 밀접하게 관련되며, 체열의 생성 및 방출 과정에 영향을 미칠 수 있다[7]. 이에 따라 BMI의 차이는 동일한 열환경 조건에서도 인체가 열을 축적하거나 외부로 전달하는 양상에 영향을 줄 수 있으며, 이는 열감각 및 선호 온도의 개인차로 이어질 수 있다. 즉, BMI는 단순한 신체 지표를 넘어 재실자의 열쾌적 반응 차이를 설명하는 주요 생리적 변수이다. 선행연구에서도 BMI와 열쾌적 반응 간의 관련성이 지속적으로 보고되고 있다. BMI가 높은 집단은 상대적으로 더위에 민감하고 낮은 온도를 선호하는 경향이 있는 반면, BMI가 낮은 집단은 추위에 더 민감한 경향을 보이는 것으로 나타났으며[8], 한랭 기후의 난방 환경에서는 BMI에 따라 열적 중립온도와 열환경 변화에 대한 반응 정도가 달라질 수 있음이 확인되었다[9]. 기후 챔버 실험에서도 체중 상태에 따른 선호 온도 차이가 보고된 바 있다[10]. 이러한 결과는 BMI가 특정 환경 조건에서의 단순한 온도 선호 차이를 넘어 다양한 실내 열환경에서 재실자의 열쾌적 반응 차이를 설명하는 주요 개인특성 변수로 작용할 수 있음을 시사한다. 그러나 기존 연구들은 주로 특정 환경 조건에서 BMI에 따른 열쾌적 반응 차이를 분석하는 데 초점을 두었으며, 이러한 차이가 기존 열쾌적 평가 지표의 예측 오차와 어떠한 관계를 가지는지에 대한 정량적 검토는 제한적이다.

현재 열환경 평가의 표준 지표로 널리 활용되는 예측 평균 온열감(predicted mean vote, PMV)은 환경변수(T_a , T_r , RH , v_a)와 MET, CLO를 바탕으로 재실자의 평균적인 열감각을 예측하는 지표로, ISO 7730 및 ASHRAE Standard 55 등 국제 기준에 채택되어 있다[11,12]. 그러나 BMI, age, gender와 같은 개인특성이 포함되어 있지 않으며, 실제 재실자의 주관적 온열감(thermal sensation vote, TSV)과 비교할 경우 예측 오차가 발생할 수 있다는 점이 여러 연구를 통해 보고되어 왔다[13~16]. 특히 MET과 CLO는 실제 환경에서 시간과 상황에 따라 달라질 수 있음에도 적용 과정에서 고정값으로 단순화되는 경우가 많으며, 개인 간 생리적 차이를 반영하는 변수가 포함되어 있지 않아 동일한 열환경 조건에서도 나타나는 개인별 열쾌적 차이를 충분히 설명하는 데 한계가 있다[17~20]. 이러한 한계를 보완하기 위해 기존 PMV 구조를 유지하면서 예측 성능을 개선하려는 보정 연구들이 수행되어 왔다. 대표적으로 재실자의 적응 행동을 반영한 aPMV[21], MET 역산 보정식[22], 확장계수와 열중립계수를 적용한 방식[23], 기후, 건물 유형 등 다양한 조건을 반영한 보정계수를 조건표 형태로 제시하는 방식[24] 등이 있다. 그러나 이러한 기존 보정 방법은 주로 기후, 건물 유형, 적응 행동 등 외부 환경 및 상황 요인을 중심으로 이루어져 왔으며, 개인의 생리적 특성을 직접적으로 반영하는 접근은 상대적으로 부족하다. 기존 PMV 모델은 평균적인 인체 조건을 기반으로 개발되었기 때문에, 재실자의 신체 특성에 따라 실제 열감과 예측값 간 차이가 발생할 가능성이 있다. 특히 BMI와 같은 신체 지표는 대사 및 체열 반응 특성과 연관될 수 있으므로, 동일한 환경 조건에서도 열쾌적 반응 차이를 유발할 수 있다. 따라서 BMI에 따른 열쾌적 반응 차이를 PMV 예측 오차와 연계하여 정량적으로 분석하고, 이를 반영한 보정 접근의 필요성이 제기된다.

1.2. 연구 목적

이에 본 연구는 기존 PMV 모델이 재실자의 BMI 특성을 반영하지 못함에 따라 발생하는 PMV와 TSV 간 예측 차이를 분석하고, 이를 보정하기 위한 BMI 기반 PMV 보정계수를 제안하는 것을 목적으로 한다. 이를 위해 ASHRAE Global Thermal Comfort Database II를 활용하여 BMI에 따른 PMV 예측 오차를 정량적으로 검토하고, 실제 TSV에 보다 근접한 보정 방안을 도출하고자 한다. 보정계수 산출을 위해 해석 가능성과 적용 용이성을 고려한 Ridge PMV* 모델과 예측 성능 향상에 중점을 둔 XGBoost PMV* 모델을 함께 개발하였다. PMV* 모델은 기존 PMV 모델 자체를 대체하기보다는, BMI에 따라 발생할 수 있는 PMV와 TSV 간 차이를 보완하기 위한 접근으로, 기존 PMV 보정 연구가 주로 환경 변수 중심으로 이루어져 온 것과 달리 개인 생리 특성인 BMI를 직접 반영했다는 점에서 의의가 있다. 개발된 모델은 향후 비접촉 이미지 기반 BMI 산출 기술과 연계될 경우, 재실자 맞춤형 열환경 제어를 위한 실용적 기반으로 활용될 수 있을 것으로 기대된다.

2. 연구방법론

본 장에서는 BMI 기반 PMV 보정계수를 도출하기 위한 연구방법론을 기술한다. 연구는 데이터 전처리 및 입력 변수 구성, 목표 변수 정의, 보정 모델 개발, 성능 평가의 4단계로 구성되며, 전체 연구 흐름은 Fig. 1.에 제시하였다.

2.1. 데이터셋 전처리 및 입력 변수 구성

ASHRAE Global Thermal Comfort Database II를 분석 데이터셋으로 활용하였다. 이 데이터베이스는 전 세계 실제 건물에서 수집된 대규모 열쾌적 현장 데이터를 종합적으로 통합한 국제 협력 데이터베이스로, 총 109,033개의 데이터 레코드와 52개 변수로 구성된다. 다양한 기후 및 건물 유형에 걸친 객관적 실내 환경 측정값과 재실자의 즉각적인 주관응답을 포함하고 있어 열쾌적 연구의 표준적 참조 데이터셋으로 폭넓게 활용된다[25]. 초기 전처리 단계에서는 모델 학습에 직접 활용되지 않는 식별자 변수를 제외하였다. 구체적으로 고유 데이터 레코드 식별자, 건물 식별자, 측정 시점, 피험자 식별자 등을 분석 대상에서 제거하였다.

변수 선정 과정은 분석 목적에 따라 고정 변수군과 후보 변수군으




Fig. 1. Research methodology for BMI-based PMV correction




Fig. 2. Variable selection process for BMI correction

로 구분하여 진행하였다. 고정 변수군은 PMV 산출에 필수적인 6개 환경·동적변수 (T_a , T_{mrt} , v_a , RH , MET , CLO)와 본 연구의 핵심 변수인 BMI로 구성하였다. 후보 변수군은 BMI 보정에 추가적인 설명력을 제공할 가능성이 있는 변수들로 구성하였다. Age와 Gender는 생리적 반응 차이를 설명할 수 있는 개인 특성 변수이며[26], Season은 계절적 특성을 반영한다[27]. 또한 T_{op} 은 공기온도와 평균복사온도를 반영한 열환경 지표이고[12], T_g 는 복사열과 기류의 영향을 반영하는 변수이다[28]. Blind curtain, Fan, Window, Door, Heater는 재실자의 환경 조절 상태를 나타내는 변수로 포함하였다[29]. 변수 선정 및 정제 과정의 전체 흐름은 Fig. 2에 제시하였다.

BMI는 재실자의 체중(kg)과 신장(m) 정보를 활용하여 BMI = 체중/신장²의 방식으로 산출하였다. 산출된 BMI는 모델 학습에 직접 활용되므로, 이상치에 의한 학습 왜곡을 방지하기 위해 BMI 분포의 상·하위 1% 분위수를 기준으로 이상치 절사를 수행하였다.

후보 변수군에 대해서는 결측치를 기준으로 정제 과정을 수행하였다. 결측률이 50%를 초과하는 8개 변수(Age, Gender, T_g , Blind curtain, Fan, Window, Door, Heater)는 분석 결과의 신뢰성과 일반화 가능성을 저해할 수 있다는 근거에 따라 제외하였다[30]. 각 변수의 결측 현황은 Table 1에 제시된다. 결측률 기준을 통과한 변수들에 대해서는 TSV - PMV 오차 설명에 유의한 정보를 제공하는지 확인하기 위해 Delta=TSV - PMV를 목표 변수로 설정하고 다중선형회귀(multiple linear regression, MLR) 분석을 수행하였다. MLR은 각 변수의 영향 방향 및 크기를 구체적으로 해석하고 통계적 유의성을 판단하는 데 적합하여 대규모 관측 데이터 분석에서 활용되는 방법론이다[31,32]. 분석 결과 Season과 T_{op} 이 통계적으로 유의한 영향 변수로 확인되어 최종 입력 변수에 포함하였다.

이러한 과정을 통해 최종 입력 변수는 PMV 필수 입력변수 6개 (T_a , T_{mrt} , v_a , RH , MET , CLO)와 Season, T_{op} , BMI를 포함한 총 9개 변수로 확정하였다. 또한 PMV, TSV 및 최종 입력 변수 9개에 결측치가 없는 3,602개의 유효 샘플을 확보하였다.

산출된 BMI는 세계보건기구(World Health Organization, WHO) 기준에 따라 저체중(Underweight, <18.5), 정상(Normal, 18.5–24.9), 과체중(Overweight, 25.0–29.9), 비만(Obesity, ≥30.0)의 4

Table 1. Missing data characteristics of candidate variables

Variable	Non-missing count (n)	Missing count (n)	Missing rate (%)
Age	17,500	34,468	66.33
Gender	25,082	26,886	51.73
Season	51,968	0	0
T_{op}	26,684	25,284	48.65
T_g	25,261	26,707	51.40
Blind curtain	1,520	50,448	97.08
Fan	4,099	47,869	92.13
Window	3,505	48,463	93.25
Door	900	51,068	98.27
Heater	3,480	48,488	93.31

Table 2. BMI classification criteria (WHO)

Category	BMI Range
Underweight	<18.5
Normal	18.5–24.9
Overweight	25.0–29.9
Obesity	≥30.0

개 범주로 구분하였으며, 상세 기준은 Table 2에 제시하였다. 범주 기반 분류는 BMI에 따른 열쾌적 반응 차이를 범주 단위로 검토하는데 적합하며, 보정계수 산출 및 제어 로직 적용 시 해석과 활용이 용이하여 현장 적용성 측면에서도 유리하다는 점을 고려하였다.

2.2. BMI 기반 PMV 보정 모델 개발

본 연구에서는 기존 PMV에 데이터 기반 보정계수 t 를 가산하는 그레이박스(grey-box) 구조를 채택하였다. 이는 PMV의 물리적 타당성을 유지하면서 BMI를 포함한 입력 변수에 따른 예측 오차를 보정할 수 있는 방식이다[33]. 구체적으로, 모델은 입력 변수 9개를 받아 보정계수 t 를 예측하도록 학습하였으며, 목표 변수는 Delta=TSV - PMV로 설정하였다. 학습 완료 후, 각 BMI 범주-PMV 구간 조합에 대해 예측된 t 값들의 평균을 산출하여 조건표를 구성하였다. 보정된 열쾌적 지표는 $PMV^* = PMV + t$ 로 정의되며, t 의 부호에 따라 보정 방향이 결정되어 $t > 0$ 인 경우 PMV는 따뜻한 방향으로, $t < 0$ 인 경우 차가운 방향으로 조정된다.

회귀 기반 모델로는 L2 정규화가 적용된 Ridge 회귀 모델을 사용하였다. Ridge 모델은 회귀 계수에 페널티를 부여하여 다중공선성 문제를 완화하고 모델 안정성을 높이는 장점이 있으며, 특정 BMI 범주-PMV 구간 조합에서 표본 수가 상대적으로 적은 본 연구의 데이터 특성에 적합하다[34]. 또한 해석 가능한 형태의 보정계수를 도출할 수 있어, 현장 적용성이 높다는 점도 고려하였다.

머신러닝 기반 모델로는 XGBoost (eXtreme Gradient Boosting)를 사용하였다. XGBoost는 트리 기반 앙상블 학습 알고리즘으로, 변수 간 비선형 관계 및 복합적 상호작용을 효과적으로 학습할 수 있다[35]. Delta는 다양한 환경 변수와 개인 특성 변수의 복합적 상호작용에 의해 발생하는 만큼, 이러한 관계를 학습하기 위한 모델로 XGBoost를 적용하였다.

두 모델 모두 2.1절에서 확정된 9개 입력 변수를 동일하게 사용하

Table 3. XGBoost model configuration

Model	Key hyperparameters	Selected value
XGBoost	Number of estimators	1200
	Learning rate (η)	0.02
	Maximum depth	4
	Minimum child weight	10
	Subsample ratio	0.75
	Column subsample ratio	0.75
Common	Input variables	Season, RH, CLO, MET, v_{as} , T_{as} , T_r , T_{op} , BMI

였으며, XGBoost 모델의 주요 하이퍼파라미터 설정값은 Table 3.에 제시하였다. 모델 학습 시에는 목표 변수의 안정성을 확보하기 위해 두 가지 기법을 적용하였다. 첫째, 학습 데이터 기준 상·하위 1% 분위수를 초과하는 Delta 값을 해당 분위수 값으로 대체하는 이상치 절사를 수행하였다. 둘째, 표본 수가 제한된 특정 BMI-PMV 구간에서의 추정 불안정성을 완화하기 위해 경험적 베이즈 축소(empirical bayes shrinkage) 기법을 적용하여 각 구간의 평균 Delta를 전체 학습 데이터 평균 방향으로 조정함으로써 소표본 구간에서의 과도한 보정값 발생을 억제하였다.

2.3. 모델 학습 및 성능 평가

전체 3,602개의 유효 샘플을 기준으로 학습 데이터(80%, 2,881개)와 테스트 데이터(20%, 721개)로 무작위 분할하였다. 모델 학습은 학습 데이터를 기반으로 수행하였으며, 학습 과정에서 9개 입력 변수를 모델에 입력하고 목표 변수 Delta를 학습하여 보정계수 t 를 산출하는 과정을 학습 데이터 전체(2,881개) 샘플에 대해 반복 수행하였다. 각 학습 샘플마다 모델은 입력 변수 조합에 대응하는 보정계수 t 를 산출하며, 학습이 완료된 후에는 학습 데이터의 각 BMI 범주와 PMV 구간 조합별로 산출된 t 값들을 집계하여 평균값을 계산하였다. 이렇게 도출된 평균 보정계수는 BMI 범주와 PMV 구간에 따른 조건표 형태로 정리되며, 이는 3장의 Table 6. (Ridge)과 Table 8. (XGBoost)에 제시된다.

모델 성능 평가는 학습 과정에 사용되지 않은 테스트 데이터(721개)를 활용하여 수행하였다. 테스트 데이터의 각 샘플에 대해 해당 샘플의 BMI 범주와 PMV 구간을 확인한 후, 학습 단계에서 도출된 보정계수 조건표로부터 해당 구간의 t 값을 적용하여 PMV^* 를 산출하였다. 이후 보정 전 오차 $\Delta_{TSV} = TSV - PMV$ 와 보정 후 오차 $\Delta_{PMV^*} = TSV - PMV^*$ 를 각각 계산하여 비교함으로써 보정 효과를 평가하였으며, Δ_{PMV^*} 의 절대값이 감소할수록 보정 효과가 크다고 해석한다. 여기서 TSV는 모델 학습에는 사용되지 않으며, 테스트 단계에서 모델의 예측 성능을 평가하기 위한 정답 레이블로만 활용된다.

성능 평가 지표로는 평균 절대 오차(mean absolute error, MAE)와 평균 제곱근 오차(root mean squared error, RMSE)를 사용하였다. MAE는 예측값과 실제값 간 절대 오차의 평균으로 전반적인 오차 크기를 나타내며(Eq. 1), RMSE는 오차의 제곱 평균에 제곱근을 취한 값으로 상대적으로 큰 오차에 더 민감하게 반응한다(Eq. 2)[36].

Table 4. Analysis of PMV prediction error by BMI category

BMI category	n	Mean TSV	Mean PMV	Mean error (TSV-PMV)
Underweight	380	0.089	0.064	0.025
Normal	2236	0.033	0.117	-0.084
Overweight	690	-0.130	0.018	-0.148
Obesity	296	-0.155	-0.188	0.033

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

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

3. 결과

개발된 BMI 기반 PMV^* 모델의 성능을 기존 PMV 모델과 비교하여 분석하고, BMI에 따른 PMV 예측 오차 특성과 보정 효과를 중심으로 결과를 제시한다. 분석은 BMI 그룹별 기준 TSV-PMV 예측 오차 특성 확인, PMV^* 모델 적용 결과 비교, 그리고 모델 간 성능 및 적용 가능성 검토의 순서로 구성하였다. 모델 성능 평가는 보정 전 오차인 Delta와 보정 후 오차인 Δ_{PMV^*} ($\Delta_{PMV^*} = TSV - PMV^*$)를 기준으로 수행하였다.

3.1. BMI 그룹별 PMV 오차 특성

PMV^* 모델 개발에 앞서, 기존 PMV 모델이 BMI에 따라 어떠한 예측 오차 특성을 보이는지를 확인하기 위해 BMI 그룹별 TSV-PMV 오차를 분석하였으며, 결과는 Table 4.에 제시하였다.

BMI 범주별 TSV-PMV 평균 오차(Delta)를 분석한 결과, 오차가 음(-)인 경우 PMV가 실제 TSV보다 따뜻하게, 양(+)인 경우 차갑게 예측됨을 의미한다. Normal 그룹($n=2,236$)은 -0.084 , Overweight 그룹($n=690$)은 -0.148 로, 특히 Overweight 그룹에서 PMV가 실제 TSV보다 따뜻하게 예측되는 경향이 두드러졌다. 반면 Underweight 그룹($n=380$)은 $+0.025$, Obesity 그룹($n=296$)은 $+0.033$ 으로, PMV가 실제 TSV보다 다소 차갑게 예측되는 경향을 보였다. 다만 Underweight 및 Obesity 그룹은 오차의 절댓값이 상대적으로 작고 표본 수도 제한적이므로, 표본 수 규모와 온열감 분포 특성을 함께 고려하여 해석할 필요가 있다.

이와 같이 기존 PMV의 예측 오차는 BMI 범주에 따라 상이한 양상을 보였으며, 이는 기존 PMV 모델이 개인의 체형 특성에 따른 온열감 차이를 충분히 반영하지 못함을 시사한다. 특히 전체 데이터의 대다수를 차지하는 Normal 및 Overweight 그룹에서 음의 오차가 일관되게 관찰된 점은 이러한 한계를 보다 명확히 뒷받침한다. 따라서 BMI를 고려한 보정 접근이 필요하며, PMV^* 모델의 적용 결과는 다음 절에서 제시한다.

3.2. Ridge 기반 PMV 보정 성능

Ridge 기반 PMV^* 모델의 성능은 기존 PMV와 비교하여 평가하

였으며, 결과는 Table 5.에 제시하였다. 기존 PMV의 MAE는 0.8350, RMSE는 1.0412였으나, Ridge 기반 PMV* 모델 적용 후 MAE는 0.7626, RMSE는 0.9551로 각각 8.7%, 8.3% 감소하였다. MAE와 RMSE가 모두 감소한 점은 Ridge 기반 보정이 평균적인 오차 크기뿐 아니라 상대적으로 큰 오차도 일정 부분 완화했음을 의미한다.

Table 6.에 제시된 보정계수를 살펴보면, BMI 범주와 PMV 구간에 따라 서로 다른 보정계수 t 가 도출되었다. Cool 및 Slightly cool 구간에서는 양(+)의 보정계수가 나타나 PMV를 따뜻한 방향으로 보정하였으며, Neutral, Slightly warm 및 Warm 구간에서는 음(-)의 보정계수가 나타나 차가운 방향으로 보정하는 경향을 보였다. 이는 기존 PMV의 예측 오차가 BMI 범주와 PMV 구간에 따라 다르게 나타남을 반영한 것이다. 또한 보정계수표는 BMI 범주와 PMV 구간에 따라 적용 가능한 조건표 형태로 제시되어, 기존 PMV 기반 제어 로직에 직접 적용할 수 있는 형태를 가진다.

Ridge 기반 PMV* 모델은 선형 보정 방식임에도 기존 PMV의 예측 오차를 유의미하게 완화하였다. 본 모델은 선형 회귀 구조를 통해 각 변수가 보정에 기여하는 방식을 회귀 계수로 표현하므로 보정 매커니즘을 직관적으로 이해할 수 있다. 이는 복잡한 비선형 모델과 달리 변수별 기여도를 명확히 확인할 수 있다는 해석 가능성을 제공한다. 다만 선형 모델 특성상 변수 간 비선형적 상호작용을 충분히 반영하는 데 한계가 있으며, 이를 보완한 XGBoost 기반 PMV* 모델

의 성능을 다음 절에서 검토한다.

3.3. XGBoost 기반 PMV 보정 성능

XGBoost 기반 PMV* 모델의 성능을 기존 PMV와 비교하여 평가하였으며, 결과는 Table 7.에 제시하였다. 기존 PMV의 MAE는 0.8350, RMSE는 1.0412였으나, XGBoost 기반 PMV* 모델 적용 후 MAE는 0.6343, RMSE는 0.8305로 각각 24.0%, 20.2% 감소하였다. 이는 Ridge 기반 보정(MAE 8.7%, RMSE 8.3% 감소) 대비 더 큰 폭의 오차 감소로, 입력 변수 간 비선형 관계를 반영한 보정이 PMV 예측 오차 감소에 추가적으로 기여한 것으로 판단된다.

Table 8.에 제시된 보정계수를 살펴보면, BMI 범주와 PMV 구간에 따라 서로 다른 보정계수 t 가 도출되었다. Cool 및 Slightly cool 구간에서는 양(+)의 보정계수가 나타나 PMV를 따뜻한 방향으로 조정하였으며, Neutral, Slightly warm 및 Warm 구간에서는 음(-)의 보정계수가 나타나 차가운 방향으로 조정하였다. 이는 기존 PMV의 예측 오차 방향이 BMI 범주와 PMV 구간에 따라 다르게 나타남을 반영한 것으로, 3.2절의 Ridge 기반 보정계수와 유사한 경향을 보였다.

XGBoost 기반 PMV* 모델은 입력 변수 간 비선형 상호작용을 반영함으로써 Ridge 기반 모델 대비 더 큰 폭의 오차 감소를 달성하였다. 다만 보정 구조의 해석이 Ridge 모델에 비해 상대적으로 제한되므로, 예측 정확도와 해석 가능성 중 어느 측면을 우선하느냐에 따

Table 5. Ridge model performance metrics

Model	Type	MAE	RMSE
Ridge	Baseline Delta	0.8350	1.0412
	Ridge Delta*	0.7626	0.9551

Table 6. Ridge model-based correction coefficient lookup table

BMI	PMV	Delta	Delta*	t (Correction coefficient)
Underweight	Cool	0.7533	0.5559	0.1974
	Slightly cool	0.5252	0.3823	0.1429
	Neutral	-0.0152	0.0272	-0.0424
	Slightly warm	-0.3516	-0.1405	-0.2111
	Warm	-1.9100	-1.3100	-0.6000
Normal	Cool	0.7741	0.6889	0.0851
	Slightly cool	0.4411	0.3644	0.0767
	Neutral	-0.1351	-0.0790	-0.0561
	Slightly warm	-0.2682	-0.0784	-0.1898
	Warm	-0.9486	-0.4124	-0.5362
Overweight	Cool	1.1718	0.8690	0.3028
	Slightly cool	0.4977	0.3899	0.1078
	Neutral	-0.3733	-0.2013	-0.1720
	Slightly warm	-0.5219	-0.3353	-0.1865
	Warm	-1.3400	-1.1263	-0.2137
Obesity	Cool	1.3700	1.1444	0.2256
	Slightly cool	0.5410	0.4184	0.1226
	Neutral	-0.3034	-0.1628	-0.1406
	Slightly warm	-0.0031	0.2381	-0.2413
	Warm	-1.7600	-1.4955	-0.2645

Table 7. XGBoost model performance metrics

Model	Type	MAE	RMSE
XGBoost	Baseline Delta	0.8350	1.0412
	XGBoost Delta*	0.6343	0.8305

Table 8. XGBoost model-based correction coefficient lookup table

BMI	PMV	Delta	Delta*	t (Correction coefficient)
Underweight	Cool	0.7533	0.3575	0.3959
	Slightly cool	0.5252	0.2374	0.2878
	Neutral	-0.0152	0.0707	-0.0859
	Slightly warm	-0.3516	-0.1507	-0.2010
	Warm	-1.9100	-1.4343	-0.4757
Normal	Cool	0.7741	0.5524	0.2217
	Slightly cool	0.4411	0.1444	0.2967
	Neutral	-0.1351	-0.0312	-0.1039
	Slightly warm	-0.2682	-0.0472	-0.2210
	Warm	-0.9486	-0.6464	-0.3021
Overweight	Cool	1.1718	0.7485	0.4233
	Slightly cool	0.4977	0.2546	0.2431
	Neutral	-0.3733	-0.0634	-0.3099
	Slightly warm	-0.5219	-0.2036	-0.3182
	Warm	-1.3400	-1.1356	-0.2044
Obesity	Cool	1.3700	1.0809	0.2891
	Slightly cool	0.5410	0.2964	0.2446
	Neutral	-0.3034	-0.0698	-0.2336
	Slightly warm	-0.0031	0.0765	-0.0797
	Warm	-1.7600	-1.7473	-0.0127




Fig. 3. Comparison of model performance metrics (MAE, RMSE) across baseline PMV, ridge PMV*, and XGBoost PMV*

라 두 모델을 구분하여 적용할 필요가 있으며, 이에 대한 비교는 다음 절에서 검토한다.

3.4. 모델 간 성능 비교 및 적용 가능성

Ridge 기반 PMV* 모델과 XGBoost 기반 PMV* 모델의 성능 비교 결과는 Fig. 3.에 제시하였다. 두 모델 모두 기존 PMV 대비 MAE와 RMSE가 감소하였으며, XGBoost 기반 PMV* 모델(MAE 0.6343, RMSE 0.8305)은 Ridge 기반 PMV* 모델(MAE 0.7626, RMSE 0.9551) 대비 MAE 16.8%, RMSE 13.0%의 추가적인 오차 감소를 나타냈다.

Ridge 기반 PMV* 모델과 XGBoost 기반 PMV* 모델은 모두 BMI 범주와 PMV 구간에 따른 보정계수를 조건표 형태로 제시할 수 있다는 공통점이 있다. Ridge 기반 PMV* 모델은 선형 구조로 변수와 보정계수 간 관계를 비교적 단순하게 해석할 수 있는 반면, XGBoost 기반 PMV* 모델은 변수 간 비선형 관계와 상호작용을 반영하여 더 큰 폭의 오차 감소를 달성하였다. 따라서 두 모델은 단순한 우열 관계라기보다, 해석 가능성과 예측 성능이라는 서로 다른 목적에 따라 활용할 수 있다.

본 연구에서 제안한 PMV 보정 방식은 기존 PMV 기반 제어 구조에 보정계수 t 를 추가하는 형태로 적용할 수 있으며, 재실자의 BMI에 따른 온열감 차이를 반영한 열환경 제어에 반영할 수 있는 가능성을 제시한다. 특히 향후 비접촉 이미지 기반 BMI 산출 기술과 연계될 경우, 재실자 특성을 반영한 보다 개인화된 열환경 제어로의 확장이 가능할 것으로 기대된다.

다만 본 연구 결과는 ASHRAE Global Thermal Comfort Database II를 기반으로 도출된 것으로, BMI 그룹별 표본 수 차이 및 데이터의 범위를 고려하여 해석할 필요가 있다. 실제 건물 제어 시스템에의 적용을 위해서는 추가적인 검증이 요구되며, 본 결과는 BMI 기반 PMV 보정 가능성을 확인한 분석 결과로 해석하는 것이 적절하다.

4. 결론

본 연구에서는 기존 PMV 모델이 BMI와 같은 개인 생리 특성을 충분히 반영하지 못하는 한계를 보완하고자 하였다. 이를 위해

ASHRAE Global Thermal Comfort Database II를 활용하여 TSV와 PMV 간 예측 오차를 분석하고, Ridge 기반 및 XGBoost 기반 PMV* 모델을 개발하여 보정 성능을 비교하였다.

분석 결과, BMI 범주에 따라 기존 PMV의 예측 오차가 상이하게 나타났으며, 특히 전체 데이터의 대다수를 차지하는 Normal 및 Overweight 그룹에서 PMV가 실제 TSV보다 따뜻하게 예측되는 경향이 확인되었다. 구체적인 보정 성능은 다음과 같다.

- 1) Ridge 기반 PMV* 모델은 기존 PMV (MAE 0.8350, RMSE 1.0412) 대비 MAE를 0.7626으로 8.7%, RMSE를 0.9551로 8.3% 감소시켰다.
- 2) XGBoost 기반 PMV* 모델은 기존 PMV (MAE 0.8350, RMSE 1.0412) 대비 MAE를 0.6343으로 24.0%, RMSE를 0.8305로 20.2% 감소시켰으며, Ridge 기반 PMV* 모델 대비 MAE 16.8%, RMSE 13.0%의 추가적인 오차 감소를 나타냈다.

이러한 결과는 BMI를 반영한 보정이 PMV 예측 오차 감소에 기여할 수 있으며, 특히 비선형 관계를 고려한 XGBoost 기반 접근이 보정 성능 향상에 효과적임을 확인하였다.

본 연구는 기존 열쾌적 보정 연구가 주로 환경 조건에 초점을 두었던 것과 달리, 재실자의 생리적 특성을 반영하여 PMV 오차를 분석하고 보정 모델을 개발하였다는 점에서 차별성을 가진다. 또한 제안된 PMV 보정 방식은 향후 비접촉 이미지 기반 BMI 산출 기술과 연계될 경우, 재실자 맞춤형 열환경 제어를 위한 실용적 기반으로 활용될 수 있을 것으로 기대된다.

제안한 보정 방식은 기존 PMV 모델 자체를 대체하기보다는, BMI에 따라 발생할 수 있는 PMV와 TSV 간 차이를 보완하기 위한 접근이라는 점에서 의미가 있다. 또한 Ridge 기반 및 XGBoost 기반 PMV* 모델을 함께 비교함으로써 해석 가능성과 예측 성능 측면에서의 적용 가능성을 검토하였다.

다만 본 연구는 몇 가지 한계를 가진다. 첫째, 최종 분석에 활용된 유효 샘플 수는 3,602개로, BMI 정보가 포함된 데이터의 제한으로 인해 특히 Underweight 및 Obesity 그룹의 표본 수가 상대적으로 적어 해당 범주의 결과 해석에 주의가 필요하다. 둘째, 결측률 기준에 따라 연령, 성별 등 일부 개인특성 변수가 분석에서 제외되었으며, 이에 따라 BMI 외 추가적인 개인특성의 영향은 충분히 반영되지 못하였다. 셋째, 데이터베이스의 지역 및 기후 분포 특성에 따라 보정 모델의 적용 범위에 차이가 있을 수 있으며, 실제 건물 제어 환경에서의 추가적인 검증이 필요하다.

이러한 한계를 보완하기 위한 후속 연구로는 BMI 정보를 포함한 열쾌적 데이터를 추가로 확보하고, Underweight 및 Obesity 그룹의 표본 보강, 연령·성별 등 추가적인 개인특성 변수의 통합을 통한 보정모델 고도화, 그리고 실제 건물 HVAC 제어 시스템에의 적용을 통한 실증 검증이 요구된다.

Acknowledgement

이 논문은 과학기술정보통신부(No. RS-2023-00217322·RS-

2024-00354306) 및 교육부(No. 2025-25422158)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임.

References

- [1] G. Liu et al., Indoor thermal environment and human health: A systematic review, *Renewable and Sustainable Energy Reviews*, 191, 2024, 114164.
- [2] F. Felgueiras et al., Multi-domain indoor environmental quality and worker health, well-being, and productivity: Objective and subjective assessments in modern office buildings, *Building and Environment*, 282, 2025, 113320.
- [3] Y. Yang et al., Subjective information in thermal comfort evaluation methods: A critical review, *Energy & Buildings*, 325, 2024, 115019.
- [4] G.A. Ganesh et al., Investigation of indoor environment quality and factors affecting human comfort: A critical review, *Building and Environment*, 204, 2021, 108146.
- [5] K. Rewitz, D.A. Müller, Influence of gender, age and BMI on human physiological response and thermal sensation for transient indoor environments with displacement ventilation, *Building and Environment*, 219, 2022, 109045.
- [6] S. Thapa, Insights into the thermal comfort of different naturally ventilated buildings of Darjeeling, India – Effect of gender, age and BMI, *Energy and Buildings*, 193, 2019, pp.267-288.
- [7] M. He et al., Does BMI affect thermal comfort in young people in warm indoor environments? Evidence from a climate chamber experiment in non-normal BMIs, *Journal of Building Engineering*, 106, 2025, 112618.
- [8] R.F. Rupp et al., Associations of occupant demographics, thermal history and obesity variables with their thermal comfort in air-conditioned and mixed-mode ventilation office buildings, *Building and Environment*, 135, 2018, pp.1-9.
- [9] F. Zhou et al., Effects of individual factors on thermal sensation in the cold climate of China in winter, *Energy and Buildings*, 301, 2023, 113720.
- [10] A. Lipczynska et al., Experimental evaluation of the effect of body mass on thermal comfort perception, 11th Windsor Conference on Thermal Comfort, 2020, pp.403-414.
- [11] International Organization for Standardization (ISO), Ergonomics of the thermal environment — Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria, (ISO 7730:2005), 2005.
- [12] ASHRAE, Thermal environmental conditions for human occupancy (ANSI/ASHRAE Standard 55-2017), 2017.
- [13] T. Cheung et al., Analysis of the accuracy on PMV-PPD model using the ASHRAE Global Thermal Comfort Database II, *Building and Environment*, 153, 2019, pp.205-217.
- [14] F. Tartarini, S. Schiavon, Comparative analysis of PMV Models accuracy implemented in the ISO 7730:2005 and ASHRAE 55:2023, *Building and Environment*, 275, 2025, 112766.
- [15] H. Du et al., Evaluation of the accuracy of PMV and its several revised models using the Chinese thermal comfort database, *Energy and Buildings*, 271, 2022, 112334.
- [16] E.J. Choi et al., Effects of thermal comfort-driven control based on real-time clothing insulation estimated using an image-processing model, *Building and Environment*, 223, 2022, 109438.
- [17] R. Caro et al., Data-driven research into the inaccuracy of traditional models of thermal comfort in offices, *Building and Environment*, 248, 2024, 111104.
- [18] Z. Wang et al., Individual difference in thermal comfort: A literature review, *Building and Environment*, 138, 2018, pp.181-193.
- [19] E.J. Choi et al., Seasonal effects of thermal comfort control considering real-time clothing insulation with vision-based model, *Building and Environment*, 235, 2023, 110255.
- [20] J.Y. Yun et al., Development and performance evaluation of an indoor thermal environment control algorithm incorporating MET estimation model with object detection, *Building and Environment*, 267, 2025, 112217.
- [21] R. Yao et al., A theoretical adaptive model of thermal comfort – Adaptive Predicted Mean Vote (aPMV), *Building and Environment*, 44(10), 2009, pp.2089-2096.
- [22] S. Zhang et al., Improving predicted mean vote with inversely determined metabolic rate, *Sustainable Cities and Society*, 53, 2020, 101870.
- [23] S. Zhang, Z. Lin, Extended predicted mean vote of thermal adaptations reinforced around thermal neutrality, *Indoor Air*, 31(4), 2021, pp.1217-1227.
- [24] Y. Li et al., Development of an adaptation table to enhance the accuracy of the predicted mean vote model, *Building and Environment*, 168, 2020, 106504.
- [25] V. Földváry Ličina et al., Development of the ASHRAE global thermal comfort database II, *Building and Environment*, 142, 2018, pp.502-512.
- [26] M. Indraganti, K.D. Rao, Effect of age, gender, economic group and tenure on thermal comfort: A field study in residential buildings in hot and dry climate with seasonal variations, *Energy and Buildings*, 42(3), 2010, pp.273-281.
- [27] R. de Dear, G.S. Brager, Developing an adaptive model of thermal comfort and preference, *ASHRAE Transactions*, 104, 1998, pp.145-167.
- [28] A.V.M. Oliveira et al., Globe temperature and its measurement: Requirements and limitations, *Annals of Work Exposures and Health*, 63(7), 2019, pp.743-758.
- [29] T. Mamani et al., Variables that affect thermal comfort and its measuring instruments: A systematic review, *Sustainability*, 14, 2022, 1773.
- [30] MIT Critical Data, Secondary analysis of electronic health records, Cham, Switzerland: Springer International Publishing, 2016.
- [31] M. Safaa et al., Improving sustainable office building operation by using historical data and linear models to predict energy usage, *Sustainable Cities and Society*, 29, 2017, pp.107-117.
- [32] L.-M. Yiin et al., Associations between residential environmental characteristics during pregnancy and birthweight and head circumference among term births: The Taiwan birth cohort study, *Building and Environment*, 261, 2024, 111724.
- [33] Y. Li et al., Grey-box modeling and application for building energy simulations - A critical review, *Renewable and Sustainable Energy Reviews*, 146, 2021, 111174.
- [34] C.F. Dormann et al., Collinearity: A review of methods to deal with it and a simulation study evaluating their performance, *Ecography*, 36, 2013, pp.27-46.
- [35] T. Chen, C. Guestrin, XGBoost: A scalable tree boosting system, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp.785-794.
- [36] H. Bao et al., Data-driven prediction of deep-sea near-seabed currents: A comparative analysis of machine learning algorithms, *Remote Sensing*, 17, 2025, 3131.