



ORIGINAL ARTICLE

MLP 기반 서울지역 WBGT 예측 성능 향상 평가

김지훈 · 최형진*

육군사관학교 토목·환경학과

Evaluation of an MLP-Based Approach for Enhanced WBGT Prediction in the Seoul Region

Jihun Kim, Hyung-Jin Choi*

Department of Civil Engineering and Environmental Science, Korea Military Academy, Seoul 01805, Korea

Abstract

The Wet-Bulb Globe Temperature (WBGT) is widely used to assess heat stress in military and industrial settings, however, its operational use is limited by the scarcity of globe temperature observations. The empirical WBGT model of the Korea Meteorological Administration (KMA2016), based on air temperature and humidity, provides a practical alternative but tends to underestimate high-WBGT conditions. This study developed a multilayer perceptron (MLP) model trained on the observed temperature and humidity, and its performance was evaluated against KMA2016. Using summer observations from Seoul's Songwol-dong station during 2021–2024 for training and independent data from 11 stations in the summer of 2025 for validation, the MLP reduced the RMSE by approximately 10% for all-hour predictions and nearly 30% for daily maximum WBGT. The MLP also improved WBGT flag classification accuracy (89.4%) compared with KMA2016 (87.9%) and reduced the number of critical misclassification cases (± 2 flag levels). When driven by short-term weather forecasts, the MLP maintained superior +24 h and +48 h WBGT forecast performance. These results indicate that the MLP provides a more accurate and operationally robust WBGT prediction framework for Seoul's summer heat-stress environments.

Key words : WBGT, Deep learning, MLP, KMA2016

1. 서론

습구흑구온도(Wet-Bulb Globe Temperature, 이하 WBGT)는 기온, 습도, 복사열 등을 종합적으로 반영하는 열 스트레스 지표로서 군사훈련, 산업현장 그리고 스포츠 등 다양한 분야에서 작업 강도 조절과 휴식 지침 설정에 널리 활용되고 있다(Budd, 2008; Brotherhood, 2008; Golbabaie, 2021; Hunt et al., 2022). 우리 군에서도 흑서기 장병의 열사병 등 비전투

손실을 줄이기 위해 WBGT 기준에 따라 훈련 및 야외 활동을 통제하고 있다(Kim et al., 2014). 하지만 흑구 온도 및 복사열 관측망이 매우 제한적이기 때문에 복사 성분을 명시적으로 포함하는 물리 모델이나 경험모델을 적용하여 실제로 활용하는데 제약이 있다(Lee et al., 2025). 이러한 상황에서 기상청은 제한된 기상요소만으로 WBGT를 추정하기 위해 다중회귀 기반의 경험적 WBGT 산출 공식(이하 KMA2016)을 개발하여 현재까지도 체감온도 산출 등에 활용해오고 있다(Lee et

Received 21 November, 2025; Revised 9 January, 2026;

Accepted 9 January, 2026

*Corresponding author : Hyung-Jin Choi, Department of Civil Engineering and Environmental Science, Korea Military Academy, Seoul 01805, Korea

Phone : +82-2-2197-2961

E-mail : hjchoi@kma.ac.kr

© The Korean Environmental Sciences Society. All rights reserved.

© This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

al., 2019). KMA2016은 건구온도(Ta)와 상대습도(RH)를 통해 손쉽게 WBGT를 추정할 수 있다는 장점이 있으나, 일부 연구에서 여름철 높은 WBGT 조건에서의 과소추정 경향과 15시 이외 시간대에서의 오차가 증가하는 경향이 확인되었으며, 주의단계 구분 성능에서도 개선의 필요성이 있다. 최근 KMA2016 모델의 오차를 개선하기 위해 지면 온도나 대기권 밖 일사량을 활용한 보정 모델이 제시되었으나(Kim et al., 2023; Kim and Kim, 2025) 예보 활용이나 변수 자체의 오차 등 실질적인 측면에서의 검증이 아직 남아있는 상태이다.

한편, 선형연구는 입력에 따른 비선형 응답을 다층 퍼셉트론(Multilayer Perceptron, 이하 MLP)를 활용하여 모델링하는 것이 효과적임을 보였으며(Fan et al., 2020) 또한 오존, 질소산화물, 미세먼지 등 대기오염물질 농도 예측에서 MLP 기반 모형이 선형 회귀 모형보다 향상된 성능을 보인 사례가 보고되었다(Durao et al., 2016). 따라서 복사, 수분, 열용량 등 다양한 물리 인자가 결합된 WBGT 기상요소 간 비선형적 관계를 경험적으로 모사하는데 적합한 접근법으로 생각할 수 있다(Liljegren et al., 2008; Kong and Huber, 2022).

이에 본 연구는 서울지역 여름철 WBGT 예측 성능 향상을 위해 관측기반으로 학습한 MLP 모델을 구축하고, 현업에서 활용되고 있는 기존 KMA2016 경험모델과의 성능을 정량적으로 비교·평가하며 폭염 대응 측면에서의 활용 가능성과 한계를 논의하는 데 목적을 둔다. 이를 위해 2021~2024년 여름철(6~9월) 서울 송월동 지역 관측소의 관측값을 학습데이터로 사용하고, 2025년 여름철 송월동을 포함하여 서울 11개 지점으로 WBGT 예측 성능을 비교하였다. 또한, 운영적 활용 가능성을 평가하기 위해 주의단계 구분 성능을 비교하고 기상청 단기예보(5 km 격자) 기온과 상대습도를 입력으로 사용하여 MLP 및 KMA2016의 +24 h 및 +48 h WBGT 예보성능을 평가하였다.

2. 자료 및 방법

2.1. 실험자료 및 전처리

WBGT 관측자료는 국립기상과학원(National Institute of Meteorological Sciences, 이하 NIMS)에서 제공한 서울지역 WBGT 관련 관측자료를 사용하였다. 대상자료는 서울 송월동(지점번호 108) 지점의

2021~2025년 여름철(6~9월) 관측자료이며, 건구온도(Ta), 상대습도(RH), 흑구온도(Tg), WBGT가 분 단위 자료로 제공된다. 또한, 공간 일반화 성능 평가를 위해 2025년에는 서울 10개 지점인 서초(지점번호 401), 강동(지점번호 402), 양천(지점번호 405), 중랑(지점번호 409), 성북(지점번호 414), 은평(지점번호 416), 성동(지점번호 421), 강북(지점번호 424), 남현(지점번호 425), 관악(지점번호 509)의 동일 요소 자료를 추가로 사용하였다. 이때 품질관리(QC)로서 Ta, RH, Tg, WBGT 중 하나라도 결측이거나 0 값을 갖는 경우를 제거하였고, 분석 시간 해상도를 예보자료 및 운영 적용과 일치시키기 위해 QC 이후의 자료를 1시간 평균으로 재표본화한 뒤 동일 기준으로 QC를 재적용하였다. 이를 통해 108지점의 2021~2024년 6~9월 기간에 대해 약 11,665개의 학습용 시간 자료를 구성하였고, 2025년 6~9월 기간은 독립 검증자료로 분리하였다. 이 자료와 학습에 포함되지 않은 서울 10개 지점의 2025년 자료 약 31,622개를 함께 사용하여, 시간 일반화와 공간 일반화 특성을 동시에 평가하도록 설계하였다.

예보성능 평가 목적의 Ta, RH 예보자료는 기상청에서 제공하는 단기예보자료를 활용하였다. 단기예보자료는 수치예보모델의 예측결과를 기반으로 통계적 후처리와 예보관 편집을 거쳐 생산되는 고해상도 자료이며 전국을 약 5 km × 5 km 공간 해상도로 나눈 격자체를 활용하며, 각 격자 또는 읍면동 행정단위에 대해 기상요소를 제공한다(KMA, 2019). 본 연구에서는 425지점을 대상으로 성능 평가를 진행하였으며, 해당 지점을 포함하는 동 단위 단기예보자료가 사용되었다.

2.2. KMA2016 경험모델

식 (1) KMA2016 WBGT 경험모델은 기상청에서 체감온도 산출 등에 활용하는 2변수 회귀 모형이다.

$$WBGT_{KMA2016} = -0.2442 + 0.55399 T_w + 0.45535 T_a - 0.0022 T_w^2 + 0.00278 T_a T_w \dots \dots \dots (1)$$

여기서, Tw는 Stull 근사식(Stull, 2011)을 이용해 Ta와 RH로부터 계산하였다. KMA2016은 본 연구에서 MLP 기반 회귀모델과의 직접 비교를 위한 기준으로 사용하였다.

2.3. Multilayer Perceptron (MLP)

본 연구에서는 서울지역 여름철의 WBGT 예측 정확도 향상을 목적으로 MLP 기반의 회귀모델을 적용하였다. MLP는 하나 이상의 은닉층이 입력층과 출력층 사이에 존재하는 구성의 순방향 인공신경망의 형태이다. 각 층의 노드는 가중합과 활성화 함수를 통해 선형 회귀나 단일 퍼셉트론으로는 표현하기 어려운 입력과 출력 사이의 복잡한 비선형 관계를 효과적으로 모형화할 수 있다(Ramchoun et al., 2016).

직접적인 비교를 위해 입력 변수는 KMA2016 WBGT 경험모델과 동일하게 Ta, RH를 사용했다. 입력 변수의 상대적 기여도는 ablation study, permutation importance, 평균 절대 민감도 방법을 활용한 변수 중요도 분석을 통해 평가되었다. 이후 신경망 학습 과정에서 변수 간 단위 및 범위 차이로 인한 학습 불안정을 방지하기 위해, 모든 입력 및 출력 변수에 대해 학습 자료에서 산출한 평균과 표준편차를 이용하여 식 (2)의 Z-score 표준화(Xz)를 적용하였다(Popescu et al., 2009).

$$x_z = \frac{x - \mu_{train}}{\sigma_{train}} \dots\dots\dots (2)$$

여기서, x 는 표준화 이전의 원래 입력 또는 출력 변수를 의미하며, μ_{train} 은 학습 자료로부터 계산된 해당 변수의 평균값이고, σ_{train} 은 학습 자료로부터 계산된 해당 변수의 표준편차이다.

이에 따라 MLP 모델은 표준화된 WBGT를 예측하도록 학습되었으며, 결과 해석 및 기존 경험모델과의 비교 단계에서는 학습 자료에서 산출한 동일한 표준화 계수를 이용하여 예측값을 실제 WBGT 값으로 역표준화하였다.

MLP 학습에는 108지점의 2021~2024년 6~9월 1시간 평균 자료 약 11,665개를 사용하였다. 학습 중 과적합을 방지하기 위해, 학습 자료 내에서 일부를 내부 검증 데이터로 무작위 분할하여 조기 종료(Early stopping)에 활용하였다. 또한, 모델의 일반화 성능 평가는 학습에 사용되지 않은 2025년 6~9월 자료 총 31,622개를 독립 검증자료로 사용하였으며, 108지점과 서울 10개 지점을 함께 평가하였다.

본 연구에서는 하이퍼 파라미터 전반에 대한 전수 탐색보다는, 기존 문헌과 예비 실험 결과를 바탕으로 예

측 성능과 학습 안정성이 균형을 이루는 합리적인 설정을 선택하였다. MLP의 전체적인 구조는 입력층, 두 개의 은닉층, 출력층으로 구성되어 있다. 은닉층은 입력 변수 수와 학습 자료 규모를 고려할 때 과도하게 복잡하지 않으면서 비선형성을 충분히 표현할 수 있도록 각각 64개와 32개의 노드로 구성되었으며, 은닉층 활성화 함수로 Rectified Linear Unit (이하 ReLU)가 적용되었다. 학습 과정에서 사용된 손실함수는 평균제곱오차(이하 MSE)이며 아래와 같이 정의된다.

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \dots\dots\dots (3)$$

여기서 y_i 는 표준화된 관측 WBGT 값, \hat{y}_i 는 표준화된 MLP가 예측한 WBGT 값, N 은 학습 표본 수이다. MSE는 연속형 변수 예측에 널리 사용되는 손실함수로, 큰 오차에 대해 상대적으로 큰 페널티를 부여함으로써 (Jadon et al., 2024) 본 연구의 주요 관심 대상인 높은 WBGT 구간에서의 예측 성능 개선에 유리하다. 학습 안정성과 수렴속도의 균형을 확보하고자 초기 학습률 0.001의 Adam 최적화 알고리즘을 사용하였고 (Kingma, 2014), 과적합을 방지하기 위해 200번의 최대 반복 횟수 동안 매 반복에서 학습 자료의 10%로 분할된 내부 검증 데이터의 검증 성능 개선이 10회 연속으로 나타나지 않으면 학습을 종료하는 조기 종료 방법을 적용했다. 이 경우 내부 검증 성능이 가장 우수했던 시점의 가중치가 최종 채택된다. 또한, 난수 시드를 고정하여 학습 과정의 재현성을 확보하였다.

3. 결과 및 고찰

3.1. 전 기간 추정 모델 정확도

먼저 2025년 여름철 전체 기간의 11개 지점 전체에 대해 1시간 평균 Ta, RH를 입력으로 한 WBGT 예측 성능을 비교하였다. MLP 모델은 전체 검증자료에 대해 상관관계수 RMSE는 0.849°C, MB는 -0.023°C, R은 0.976, R²는 0.952를 보였으며, 이는 KMA2016 모델보다 RMSE는 10.01%, |MB|는 93.87%, R은 0.13%, R²는 1.21% 개선된 수치이다. 피어슨 상관관계수와 결정계수는 개선율이 높진 않으나 각각 약 0.98, 0.95 정도로 유의미하게 높은 수준임을 확인할 수 있다. 지점별




Fig. 1. Comparison of WBG T prediction performance by model across 11 stations during the summer of 2025. MLP (red), KMA2016 (black).

Table 1. Comparison of model performance for predicting daily maximum WBG T at each station during the summer of 2025

Performance		Station number										
Metric	Model	108	401	402	405	409	414	416	421	424	425	509
MB	MLP	0.088	0.225	0.586	0.277	0.479	0.389	0.241	0.213	-0.087	0.063	0.251
	KMA2016	-0.833	-0.700	-0.364	-0.655	-0.404	-0.544	-0.754	-0.732	-0.994	-0.897	-0.756
RMSE	MLP	0.622	0.527	0.815	0.595	0.763	0.712	0.575	0.647	0.523	0.955	0.587
	KMA2016	1.038	0.874	0.649	0.852	0.678	0.757	0.942	0.959	1.147	1.371	0.932
R	MLP	0.983	0.990	0.984	0.987	0.983	0.984	0.987	0.983	0.987	0.966	0.987
	KMA2016	0.983	0.987	0.986	0.986	0.986	0.987	0.984	0.982	0.984	0.960	0.986
R²	MLP	0.966	0.974	0.934	0.967	0.945	0.954	0.968	0.962	0.974	0.932	0.967
	KMA2016	0.904	0.930	0.958	0.932	0.957	0.947	0.913	0.916	0.875	0.859	0.916

성능 비교에서는(Fig. 1), 11개 모든 지점 MLP의 RMSE가 Δ RMSE 0.021-0.131 수준에서 KMA2016 보다 작았으며, 모든 지점에서 MLP가 소폭이지만 일관되게 WBG T 변동을 더 잘 재현하였다.

입력 변수의 상대적 기여도를 평가한 결과, WBG T

예측에서 Ta의 기여가 RH보다 크게 나타났으며 RH는 예측 성능을 보완적으로 개선하는 경향을 보였다. Ablation study에서 Ta와 RH를 함께 사용한 경우가 가장 우수하였고 RMSE는 0.219, R²는 0.952였다. Ta만 입력으로 사용한 경우 RMSE는 0.337, R²는

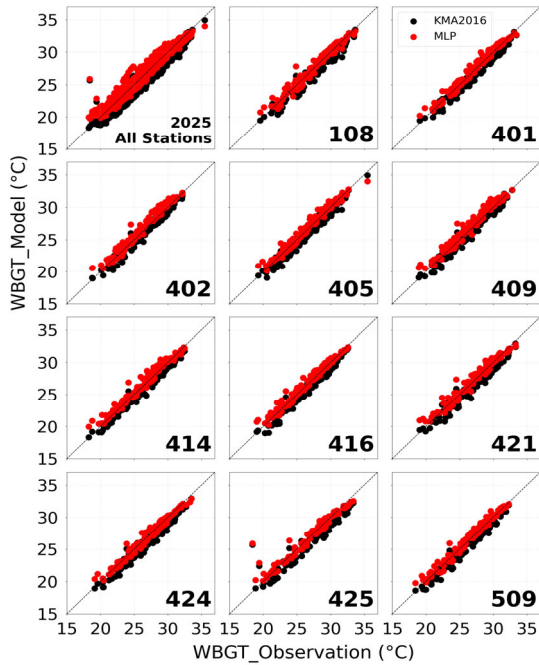


Fig. 2. Scatter plots of prediction performance for daily-maximum WBGT at all stations and individual stations in summer 2025. MLP (red), KMA2016 (black).

0.885로 성능이 일정 수준 유지된 반면, RH만 입력으로 사용한 경우 RMSE는 0.944, R^2 는 0.100으로 예측 성능이 크게 저하되었다. 순열 기반 중요도 분석에서도 T_a 를 고관했을 때 검증 RMSE 증가량은 1.36으로 RH 고관 시 증가량 0.26보다 크게 나타났다. 표준화 공간에서의 평균 절대 민감도는 T_a 가 1.06, RH가 0.30으로 산출되어, 모델 출력이 T_a 변화에 더 민감하게 반응하는 경향을 확인하였다. 종합하면 T_a 가 주요 설명력을 제공하며 RH는 추가 정보를 제공하여 예측 성능을 향상시키는 것으로 해석된다.

3.2. 일 최고 WBGT 예측 성능

일별 최고 WBGT(1시간 평균 중 최댓값) 예측 성능을 평가한 결과, MLP 모델의 개선 효과는 전 기간 성능 평가보다 뚜렷하게 나타났다(Fig. 2). 2025년 여름철 11개 전체지점을 대상으로 일 최고 WBGT에 대한 성능 비교 결과, MLP는 R 은 0.982, RMSE는 0.674°C, R^2 는 0.959를 보인 반면, KMA2016은 R 은 0.981,

RMSE는 0.943°C, R^2 는 0.919로 나타났다. 즉, 일 최고 WBGT에 대해서는 RMSE가 약 0.94°C에서 0.67°C로 약 29% 감소하였고, R^2 는 0.919에서 0.959로 약 4.4% 증가하여, MLP가 극값(Heat peak) 재현에 특히 유리함을 확인하였다.

지점별로 살펴보면(Table 1), 대부분 지점에서 MLP가 일 최고 WBGT에 대한 RMSE와 |MBI| 모두에서 KMA2016보다 작았고, R^2 도 0.93–0.97 수준으로 높게 유지되었다. 다만 일부 지점(예: 402, 409지점)에서는 MLP의 RMSE가 KMA2016보다 약간 크게 나타나, 모든 지점에서 절대 우위를 보인 것은 아니었다. 그러나 11개 지점 전체를 종합했을 때는 MLP의 평균 성능이 명확하게 우세하였으며, 특히 WBGT 편향이 절대적인 수치 감소와 함께 음에서 양으로 전환되는 경향은 군·현업에서 관심이 높은 일 최대 WBGT 예측에 있어서 KMA2016의 체계적 과소추정을 동일한 변수조건에서 상당 부분 완화될 수 있음을 시사한다.

3.3. WBGT Flag 분류 성능

운영적 활용 가능성 평가를 위해 WBGT 값을 Flag (White : 26.5 미만, Green : 26.5~29.5, Yellow : 29.5~31.0, Red : 31.0~32.0, Black : 32 이상)으로 변환하여 분류 정확도를 비교한 결과(Fig. 3), 두 모델의 성능 차이는 수치상 크지 않았지만, MLP가 소폭 우세한 것으로 나타났다. 2025년 여름철 전체 11개 지점의 1시간 평균 자료에 대해, Flag 분류 정확도는 전체 자료에 대하여 MLP는 89.39%, KMA2016은 87.86%로, MLP가 약 1.5% 높은 분류 정확도를 보였다. White 및 Yellow, Red, Black 구간에서는 MLP가 KMA2016보다 높은 정답률을 보였고, Green 구간에서는 KMA2016이 다소 높은 정답률을 보였다. 특히 실질적인 통제기준이 반영되는 고위험 구간(Yellow 이상)에서의 범위가 상대적으로 좁아 Green 이하의 구간보다 추정 난이도가 높기 때문에 정답률이 양 모델 모두 충분히 높다고 보기는 어렵지만, MLP가 KMA2016보다 약간 더 나은 수준임을 확인할 수 있다. 이를 활용함에 있어 정답 구간의 전후 1구간에 대해서도 운영 측면에서 유의할 필요가 있다. 그러나 관측 Flag와 예측 Flag의 차이가 ± 2 구간 이상인 경우에는 운영적 유효성 측면에서 허용될 수 없는 수준의 오차에 해당하며 이것을 본 연구에서는 중대 오차로 간주한다. 중대 오차 비율은 Green 구간에서 KMA2016 모델이

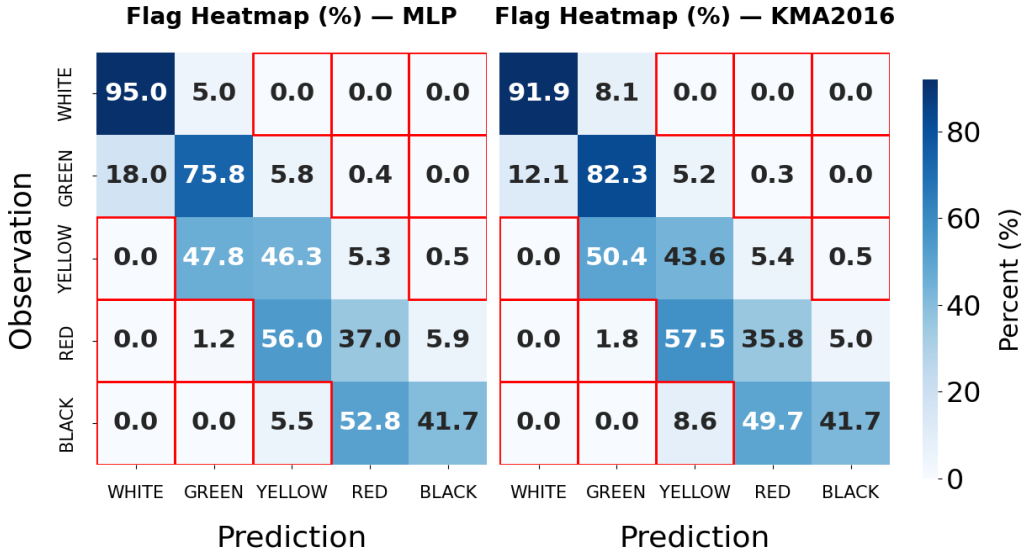


Fig. 3. Heatmap of WBGT flag classification performance for models used in the Republic of Korea Army (Red boxed regions indicate critical misclassification zones).

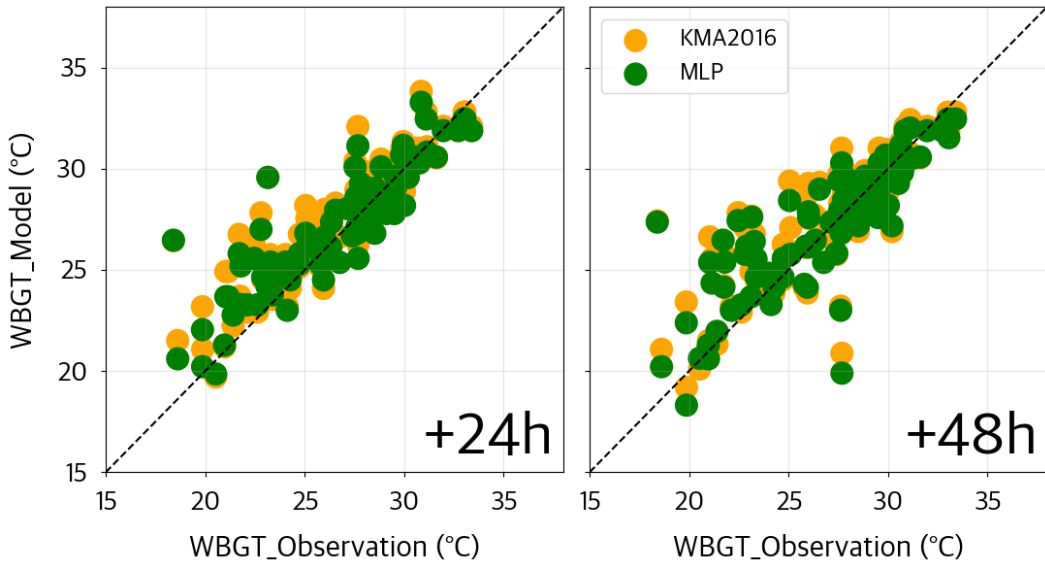


Fig. 4. WBGT forecast scatter plots by lead time for 425 station, summer 2025 at 15 LST. MLP (green), KMA2016 (yellow).

MLP 모델의 결과보다 0.1% 적은 수치를 보였으나, Yellow 이상의 고위험 구간에서는 MLP가 KMA2016의 중대 오차 수준을 밑돌았고, 더 위험한 수준에서 더 개선된 결과를 보이는 경향을 보였다. 이는 KMA2016

의 체계적 과소추정을 상당 부분 완화한 영향으로 해석될 수 있으며 결과적으로 MLP 기반의 Flag 추정은 운영 측면의 유의구간 내에서 더 안정적인 대안으로 제시될 수 있다.

3.4. 단기예보를 이용한 WBGT 예보성능

폭염 정보시스템에 주로 사용되는 여름철 오후 3시에 대하여, 부대 환경이 조성되어있는 남현동의 기상청 단기예보(5 km 격자) 기온·상대습도를 입력으로 사용하여 공간 범주에 포함되는 425지점의 관측 WBGT에 대한 +24 h 및 +48 h WBGT 예보를 수행한 결과, 관측기반 예측보다 오차가 전반적으로 증가하고 설명력이 감소하였다(Fig. 4). 이는 단기예보의 기온·습도 자체의 오차가 WBGT 예측 오차로 전파된 결과로 볼 수 있으나 이 경우에도 MLP가 KMA2016보다 일관되게 우수한 성능을 보였다. +24 h 예보의 경우, MLP는 R은 0.883, RMSE는 1.74°C, MB는 0.50°C, $R^2 \approx 0.75$ 를 보였고, KMA2016은 R은 0.869, RMSE는 1.98°C, MB는 0.95°C, $R^2 \approx 0.68$ 로 나타났다. 즉, 예보 기반 상황에서도 MLP는 KMA2016에 비해 RMSE를 약 12% 정도 감소시키고, MB도 약 53% 정도 감소시키는 것으로 나타났다. +48 h 리드 타임에서는 MLP가 R은 0.811, RMSE는 2.10°C, MB는 0.34°C, $R^2 \approx 0.65$, KMA2016이 R은 0.802, RMSE는 2.27°C, MB는 0.79°C, $R^2 \approx 0.59$ 로, 리드 타임이 길어지면서 양 모델 모두 오차가 커지고 설명력이 감소하였으나, MLP의 상대적 우위는 유지되었다. 결과적으로 MLP가 예보 차원에서 일관되게 오차 감소에 기여했다. 이러한 점에서 예보 기반 운영 환경에서도 MLP가 더욱 정확한 WBGT 정보를 제공하는 데 유리한 모델임을 시사한다.

4. 결론

본 연구에서는 서울지역에서의 여름철(6~9월) WBGT 예측 정확도 향상을 위해, 관측기반 MLP 모델을 구축하고 현재 활용되고 있는 기상청 KMA2016 경험모델과의 성능을 비교·평가하였다. 2021~2024년 여름철 108지점(송월동)의 관측자료를 학습에 사용하고, 2025년 여름철 서울 11개 지점의 관측자료로 검증한 결과, MLP 모델은 KMA2016 대비 RMSE를 약 10% 정도 감소시켰으며, 일 최고 WBGT 예측에서는 RMSE를 약 29% 수준까지 크게 감소시키는 등 극값 재현 성능에서 뚜렷한 향상을 보였다. WBGT Flag 구분에서도 MLP의 전체 분류 정확도는 89.4%로 KMA2016의 87.9%보다 약간 높았고, 고위험 구간(Yellow 이상)에서도 소폭 개선을 보여, 군 운용 측면에서 더욱 안정적인 의사결정 지원이 가능함을 확인하였다. 또한, 단기

예보 기온·습도를 입력으로 사용하는 +24 h 및 +48 h 예보성능에서도 MLP가 KMA2016보다 일관되게 작은 RMSE, MB와 향상된 설명력을 보였으며, 예보 입력의 불확실성에도 불구하고 상대적 우위가 유지되었다.

이러한 결과는 서울 지역과 같이 관측자료가 충분히 확보된 국지적인 영역에서, MLP 기반 WBGT 예측의 신뢰성을 시사한다. 특히 일 최고 WBGT와 같은 위험도가 높은 상황에서 예측 오차를 줄임으로써, 폭염 정보 발령, 군/산업현장의 작업 강도 조절, 야외훈련 및 행사 계획 수립 등 다양한 분야에서 더욱 안정적인 열 스트레스 관리가 가능해질 것으로 기대할 수 있다.

다만, 본 연구의 MLP 모델은 서울지역의 2021~2025년 자료에 기반하여 학습되었으므로, 다른 지역이나 기후 조건에 적용하기 위해서는 추가적인 데이터 확보와 재학습, 지역별 보정이 필요하다. 또한, 예보 입력의 오차가 WBGT 예측에 직접적인 영향을 미치므로, WBGT 예측 성능 향상과 더불어 기온과 상대습도 예보 정확도 개선도 병행되어야 한다. 추후, 토지 피복 및 열환경 특성과 도시 구조(예: LCZ) 등의 추가 고정변수를 통합한 확장형 MLP 또는 다른 기계학습 모델을 개발하고, 서울 외 타 도시 및 군부대 지역으로 적용 범위를 확대하여 일반화 가능성을 검증할 필요가 있다.

REFERENCES

- Brotherhood, J. R., 2008, Heat stress and strain in exercise and sport, *J. Sci. Med. Sport*, 11(1), 6-19.
- Budd, G. M., 2008, Wet-bulb globe temperature (WBGT)—its history and its limitations, *J. Sci. Med. Sport*, 11(1), 20-32.
- Durao, R. M., Mendes, M. T., Pereira, M. J., 2016, Forecasting O₃ levels in industrial area surroundings up to 24 h in advance, combining classification trees and MLP models, *Atmos. Pollut. Res.*, 7(6), 961-970.
- Fan, Y., Xu, K., Wu, H., Zheng, Y., Tao, B., 2020, Spatiotemporal modeling for nonlinear distributed thermal processes based on KL decomposition, MLP and LSTM network, *IEEE Access*, 8, 25111-25121.
- Golbabaei, F., Asour, A. A., Keyvani, S., Kolahdouzi, M., Mohammadiyan, M., RAMANDI, F. F., 2021, Limitations of WBGT index for application in industries: A systematic review, *Int. J. Occup. Hyg.*, 13(4), 365-381
- Hunt, A. P., Potter, A. W., Linnane, D. M., Xu, X., Patterson, M. J., Stewart, I. B., 2022, Heat stress

- management in the military: Wet-bulb globe temperature offsets for modern body armor systems, *Hum. Factors*, 64(8), 1306-1316.
- Jadon, A., Patil, A., Jadon, S., 2024, A comprehensive survey of regression-based loss functions for time series forecasting, *International Conference on Data Management, Analytics & Innovation*, Springer, Singapore, 117-147.
- Kim, G. H., Kim, K. R., 2025, Systematic correction method for perceived temperature using extraterrestrial solar irradiance, Korean Patent No. 10-2025-0082093.
- Kim, H., Kim, K. R., Shin, J., 2022, Heat index calculation method and device considering outdoor ground heating, Korean Patent No. 10-2540834.
- Kim, S., Eom, H. S., Hong, S. Y., Kim, J. S., Lee, C. H., 2014, Development of a future national defense climate index based on RCP scenarios: Temperature index, *Proceedings of the Korean Meteorological Society Conference*, Korean Meteorological Society, Jeju, 497-499.
- Kingma, D. P., Ba, J. L., 2014, Adam : A Method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, <https://doi.org/10.48550/arXiv.1412.6980>
- Kong, Q., Huber, M., 2022, Explicit calculations of wet-bulb globe temperature compared with approximations and why it matters for labor productivity, *Earth's Futur.*, 10(3), e2021EF002334.
- KMA (Korea Meteorological Administration), 2019, A Study on the diagnosis and development direction of the forecasting system, *Korea Meteorological Administration*, 107.
- Lee, J., Yoon, E., 2025, Development and pilot application of a high-resolution urban climate resilience assessment model considering green infrastructure supply and demand, *SSRN Working Paper*, <http://dx.doi.org/10.2139/ssrn.5336188>
- Lee, J. S., Kim, K. R., Cho, C., Kang, M., Ha, J. C., Kim, D. S., 2019, Evaluating the accuracies of the WBGT estimation models and their onsite applicability in Korea, *J. Korean Soc. Hazard Mitig.*, 19(4), 53-63.
- Liljegren, J. C., Carhart, R. A., Lawday, P., Tschopp, S., Sharp, R., 2008, Modeling the wet bulb globe temperature using standard meteorological measurements, *J. Occup. Environ. Hyg.*, 5(10), 645-655.
- Popescu, M. C., Balas, V. E., Perescu-Popescu, L., Mastorakis, N., 2009, Multilayer perceptron and neural networks, *WSEAS Trans. Circuits Syst.*, 8(7), 579-588.
- Ramchoun, H., Ghanou, Y., Ettaouil, M., Janati Idrissi, M. A., 2016, Multilayer perceptron: Architecture optimization and training, *Int. J. Interact. Multimed. Artif. Intell.*, 4(1).
- Stull, R., 2011, Wet-bulb temperature from relative humidity and air temperature, *J. Appl. Meteorol. Climatol.*, 50(11), 2267-2269.

-
- Professor. Hyung-Jin Choi
Department of Civil Engineering and Environmental Science, Korea Military Academy
hjchoi@kma.ac.kr
 - Lecturer. Jihun Kim
Department of Civil Engineering and Environmental Science, Korea Military Academy
jihun9340@kma.ac.kr