

Stacking ensemble을 활용한 서울의 봄철 지면 온도 예측

송유정¹ · 김찬수^{2*}

¹공주대학교 응용수학과 석사과정

²공주대학교 응용수학과 교수

(2023년 10월 23일 접수, 2023년 11월 30일 최종 수정, 2023년 12월 6일 게재 확정)

Prediction of Spring Land Surface Temperature in Seoul using Stacking Ensemble

Yujeong Song¹ · Chansoo Kim^{2*}

¹Master's student, Department of Applied Mathematics, Kongju National University

²Professor, Department of Applied Mathematics, Kongju National University

(Received 23 October 2023, Revised 30 November 2023, Accepted 6 December 2023)

Abstract : Land surface temperature is a crucial variable for monitoring physical, biological, and chemical processes within the climate system. Specifically, spring land surface temperature plays a significant role in bridging the atmospheric circulation between winter and summer. It influences not only summer land surface temperature but also precipitation patterns and drought conditions. The aim of this study is to forecast spring land surface temperature by employing multiple machine learning models. The data used in this study was collected from the Automated Synoptic Observing System (ASOS) in Seoul, covering the period from 2018 to 2022, at hourly intervals. The input variables include temperature, wind speed, humidity, dew point temperature, sunshine duration, and solar radiation. In this study, we utilized both individual and ensemble models, and we further proposed a stacking ensemble method using a multilayer perceptron as the meta learner. The results indicated that most machine learning models exhibited under-dispersion. Notably, the stacking model demonstrated superior predictive performance in both time series cross-validation and the testing set. These findings suggested that the stacking model produces stable and accurate predictions by amalgamating the predicted values of base learners.

Key Words : land surface temperature, ensemble model, meta learner, stacking ensemble

주요어 : 지면 온도, 앙상블 모델, 메타 학습기, 스택킹 앙상블

*Correspondence: chanskim@kongju.ac.kr

© KU Climate Research Institute

1. 서론

지표면에서 측정되는 지면 온도는 대기와 지표면 간의 에너지 교환에 대한 정보를 제공하므로 육지 대기 모델에서 설명변수로 활용되고 있다(Liu *et al.*, 2009; Rocha *et al.*, 2020; Tang *et al.*, 2023). 또한, 지면 온도가 식물의 영양소 흡수, 발아 및 뿌리 성장에 영향을 미침으로써 작물의 파종 날짜를 결정하는데 활용되기도 한다(Sharma *et al.*, 2010; Onwuka and Mang, 2018). 이처럼, 지면 온도는 기후 시스템의 물리적, 생물학적, 화학적 과정을 모니터링하는 핵심 변수로서, 다양한 연구에서 중요한 역할을 수행하고 있다(Imran *et al.*, 2022).

지표면은 구성요소도 다양하고 상대적으로 비열이 작아 다른 기상요소에 비해 지표면 온도는 시공간적으로 변동성이 매우 크다(Suh, 2012). 시공간적 변동성이 큰 지면 온도를 예측하기 위해 기계학습 및 딥러닝 기술을 활용한 다양한 연구가 수행되고 있다. Maddu *et al.*(2021)은 인도의 해안 도시에 대한 지면 온도를 예측하기 위해 대기압, 이슬점온도, 풍속, 풍향, 상대습도에 대한 정보를 활용하였다. 그들은 기존 신경망 모델인 RNN과 LSTM보다 LSTM-BiLSTM 하이브리드 딥러닝 모델이 지면 온도 예측에 우수한 성능을 달성함을 보였다. Dong *et al.*(2022)는 중국의 기상관측소를 대상으로 평균기온, 최고기온, 최저기온, 상대습도, 일사량, 풍속에 대한 기상 정보를 활용하여 일일 지면 온도를 예측하였다. 그들은 트리 기반 모델인 MP5, Random Forest, XGBoost를 사용한 결과, XGBoost가 가장 우수한 성능을 달성함을 보였다. 또한, Choi and Lim(2023)은 서울, 대구, 광주, 울산, 제주의 5개 지역을 대상으로 웨이블릿 분해를 활용하여 단기간 일별 지면 온도 예측을 수행하였다. ARIMA, SARIMA, SVR와 같은 전통적인 시계열 예측 방법

과 웨이블릿 분해를 기반으로 한 모델을 비교 분석한 결과, 웨이블릿 분해를 활용한 모델이 우수한 예측 성능을 보였다. 대부분의 이전 연구들은 계절에 상관없이 지면 온도에 대한 예측을 수행하였다. 그러나, Wu *et al.*(2014)에 따르면 봄철 지면 온도는 겨울 대기순환과 여름 대기순환 사이를 연결하며, 이는 기후 패턴과 연관이 있다. 특히 서부 유라시아에서 발생하는 봄철 지면 온도의 이상 현상은 초여름 중국 북부 지역의 강수량을 증가시키고 북동부 지역의 기온을 높이며, 이는 더 나아가 전세계 기후에 영향을 미칠 수 있는 잠재적인 원인으로 간주된다(Song *et al.*, 2022). Xue *et al.*(2016)에 따르면, 미국 북서부의 봄철 토지 온도는 미국 남부 평원 및 주변 지역의 여름 강수량 및 지면 온도와 유의미한 상관관계를 가진다. 그들은 봄철 지면 온도가 여름철 지면 온도뿐만 아니라 강수량, 가뭄에 영향을 미친다는 것을 보였다. 즉, 봄철 지면 온도는 기후 및 환경변화에 대한 이해와 예측을 향상시키는데 중요함을 알 수 있다.

본 연구에서는 2018년부터 2022년까지 서울에서 수집된 봄철 종관기상관측자료를 기반으로 기상 정보를 활용하여 지면 온도를 예측하는 stacking 앙상블 모델을 생성하고자 한다. Stacking 모델은 Wolpert(1992)에 의해 제안된 앙상블 방법으로 다양한 알고리즘의 예측 결과를 결합하여 알고리즘의 편향을 제거하고 안정적인 예측을 수행할 수 있다(Hwang and Kim, 2019). 따라서, 5가지 기계학습 모델을 기저 학습기(base learner)로 활용하여 stacking 앙상블 모델을 생성하고자 한다. 생성된 stacking 앙상블 모델과 기저 학습기들의 예측 성능을 비교 분석하여 모델의 예측 정도를 평가하고자 한다.

2장에서는 연구에 사용된 데이터에 대한 설명이 주어졌으며, 3장에서는 연구 방법으로 stacking 앙상블 방법과 기저 학습기로 사용된 기계학습 모

델에 대한 설명이 주어져 있다. 각 기계학습 모델의 예측 결과를 비교하고 분석한 결과가 4장에 주어졌고, 마지막으로 5장에서는 결론이 주어져 있다.

2. 자료

본 연구에서는 기상청의 기상자료 개방포털에서 제공하는 중관기상관측(automated synoptic observing system, ASOS)자료를 사용하였다. 연구 대상 지역은 국내 도시화가 고밀하게 진행된 서울(지점번호: 108)로, 2018년부터 2022년까지 5년간의 봄철 데이터를 활용하고자 한다. 봄철은 3월부터 5월까지로 MAM(March, April, May)이라 정의하며, 1시간 지면 온도(TS)를 예측하기 위해 해당 시간의 평균 기온(TA), 풍속(WS), 습도(HM), 이슬점온도(TD), 일조량(SS), 일사량(SI)에 대한 정보를 수집하였다. 수집된 데이터는 5(년)×92(일)×24(시간)=11,040개의 기상 및 지면 온도 정보이다. 이 중 2018년부터 2021년까지 4년간의 봄철 데이터는 훈

련 데이터로, 2022년 봄철 데이터는 테스트 데이터로 정의하였다. 결측치는 일조량과 일사량 데이터에서 발생하였는데, 이는 일사가 존재하지 않는 시간대에 속해 모두 0으로 처리하였다. 연구에서 사용된 훈련 및 테스트 데이터에 대한 정보는 Table 1에 주어져 있다.

수집된 데이터에 대한 변수들의 정보를 살펴보고자 한다. Table 2에는 기상 변수와 지면 온도에 대한 기술 통계량이 주어져 있다. 지면 온도는 평균 기온에 비해 평균은 약 2.3℃ 더 높으며, 최고 58℃까지 관측되었다. 또한, 지면 온도는 상대적으로 높은 표준편차를 가지므로 변동성이 크다는 것을 알 수 있다.

Figure 1은 연구에 사용된 변수 간 상관관계를 나타낸 그래프이다. Koo *et al.*(2006)에 따르면, 기온이 지면 온도와 강한 상관관계를 보이며, 일사량은 직접적으로 지면을 가열시키므로 지면 온도에 큰 영향을 미친다. 본 연구에서도 기온과 일사량은 지면 온도와 강한 양의 상관관계를 보이며, 일조량도 지면 온도와 0.6 이상의 양의 상관관계를 보인다.

Table 1. Descriptions of training and testing set.

Data	Training set				Testing set
	2018 MAM	2019 MAM	2020 MAM	2021 MAM	2022 MAM
Count	2,208	2,208	2,208	2,208	2,208

Table 2. Descriptive statistics of the variables.

Variable	Min	Max	Average	Standard deviation
TA(°C)	-6.60	33.20	13.07	6.45
WS(m/s)	0.00	8.30	2.32	1.23
HM(%)	10.00	100.00	56.57	21.46
TD(°C)	-19.70	22.00	3.49	7.26
SS(hr)	0.00	1.00	0.31	0.44
SI(MJ/m2)	0.00	3.77	0.75	1.05
TS(°C)	-4.30	58.00	15.27	10.97




Figure 1. Correlation coefficients between input and output variables.

이슬점온도, 습도, 풍속은 지면 온도와 상대적으로 약한 상관관계를 갖지만, 상관계수의 절댓값이 0.3 이상이므로 연구에 사용된 기상 변수들은 지면 온도 예측에 유의미한 영향을 미칠 것으로 보인다.

3. 연구 방법

본 연구에서는 서울의 봄철 지면 온도를 예측하기 위해 stacking 앙상블 모델을 생성하고 기저 학습기들과 예측 성능을 비교 분석하고자 한다. 이를 위해 훈련 데이터에 대한 평균 교차 검증 성능을 계산하여 일반화 성능을 확인하고 테스트 데이터에 대한 모델의 예측 결과를 분석하여 예측 능력을 평가하고자 한다.

1) 기계학습 모델

서울의 지면 온도를 예측하기 위해 앙상블 학습 모델인 stacking 모델을 적용하였다. Stacking은 여러 기저 학습기의 예측값을 메타 학습기(meta learner)의 학습 데이터로 활용하여 최종 예측을 수행하는 앙상블 기법이다. 이때, 학습 데이터에 과적

합하는 것을 방지하기 위해 교차 검증을 활용하여 메타 학습기의 학습 데이터를 생성한다(Breiman, 1996). Stacking 방법은 개별 모델의 편향을 줄이고 분산을 감소시켜 일반화 성능을 향상시킬 수 있다. 또한, 단일 모델뿐만 아니라 배깅 및 부스팅과 같은 앙상블 모델을 기저 학습기로 사용할 수 있어 기존의 앙상블 모델보다 우수한 예측 성능을 달성할 수 있다(Ves *et al.*, 2019; Liu *et al.*, 2021; Ksibi *et al.*, 2023).

Stacking 모델에 대한 학습 알고리즘은 Algorithm 1에 주어져 있다. Stacking 모델을 구축하기 위해 먼저 주어진 데이터로 기저 학습기들을 학습한다(line 1). 그 후, 각 기저 학습기에 대해 교차 검증을 수행하고 검증 데이터에 대한 예측값을 저장하여 메타 학습기의 학습 데이터를 생성한다(line 2-4). 이를 기반으로 메타 학습기를 학습하며 최종 생성된 stacking 모델은 line 1에서 학습된 기저 학습기들과 메타 학습기를 활용해 예측을 수행한다(line 6).

본 연구에서는 stacking 앙상블 모델의 기저 학습기로 Support Vector Regressor(SVR), 선형회귀(LR), Decision Tree(DT), Random Forest(RF), Gradient Boosting(GBM) 모델을 사용하였다. SVR은 모든 학습 데이터에 대해 최소 오차를 갖도록 학습하는 대신, 일부 오차를 허용하면서 학습을 수행한다. 이를 통해, 모델의 과적합을 방지하고 일반화 성능을 향상시킨다. LR은 독립 변수들의 선형 결합으로 종속변수를 설명하는 모델로 잔차제곱합이 최소가 되도록 독립 변수들의 회귀 계수를 추정한다. DT는 트리 기반 알고리즘으로 지니 인덱스 또는 오차제곱합을 활용하여 학습 데이터에 대한 트리를 생성한다. DT는 직관적으로 이해하기 쉬워 그래프 형태로 시각화할 수 있지만, 복잡한 규칙 구조를 가져 학습 데이터에 과적합될 위험이 존재한다. RF는 대표적인 배깅 알고리즘으로, 부트스트랩

Algorithm 1. Stacking Model with Cross-Validation

Input

The dataset $D=\{(X_i, Y_i): i=1, \dots, n\}$; Number of base learners K ; Number of subsets V

Output

A stacking ensemble H

```

1: Train a base learner  $\hat{h}_k$  with the dataset  $D$  for  $k=1, \dots, K$ .
2: Split the dataset into  $V$  equal-size subsets.
   for  $v=1, \dots, V$ 
       Set the  $v$ -th fold as a validation set  $V(v)$  and the rest folds as a training set  $T(v)$ ,  $T(v)=D \setminus V(v)$ .
   end for
3: Save the prediction of a base learner  $h_k$  on the validation sets for  $k=1, \dots, K$ .
   for  $k=1, \dots, K$ 
       for  $v=1, \dots, V$ 
           Train a base learner  $h_k$  on the training set  $T(v)$ .
           Save the prediction set  $h_k(V(v))$  on the validation set  $V(v)$ .
       end for
       Stack the prediction sets  $h_k(D)=\{h_k(V(v)), v=1, \dots, V\}$ .
   end for
4: Create the training set  $X^*=\{h_1(D), \dots, h_K(D)\}$  of a meta learner by aggregating  $h_k(D)$  for  $k=1, \dots, K$ .
5: Train a meta learner  $h^*$  with  $D^*=\{(X_i^*, Y_i): i=1, \dots, n\}$ .
6: Generate a stacking ensemble with a meta learner  $h^*$  and the predicted values of base learners  $\hat{h}_k$  that are generated in line 1.
return  $H(x)=h^*(\hat{h}_1(x), \hat{h}_2(x), \dots, \hat{h}_5(x))$ 

```

샘플을 사용하여 여러 개의 DT 모델을 학습하고 결합하여 예측을 수행한다. 여러 DT 모델의 예측 결과를 결합하기 때문에 기존의 단일 DT 알고리즘보다 더 안정적인 예측을 제공하며, 과적합 위험을 줄일 수 있다. GBM은 대표적인 부스팅 알고리즘으로 여러 DT 모델을 순차적으로 결합하여 예측하는 모델이다. 각 DT 모델을 학습할 때, 경사 하강법을 사용하여 손실 함수를 최소화하도록 훈련을 수행한다. 순차적인 학습 방식으로 인해 훈련 시간이 오래 걸릴 수 있지만, 우수한 예측 성능을 보이는 알고리즘 중 하나이다.

Stacking 모델은 기저 학습기들의 예측 결과를 효과적으로 결합하여 하나의 예측 모델을 생성하기 위해 메타 학습기를 사용한다. 본 연구에서는 stacking 모델의 메타 학습기로 2개의 은닉층

을 가진 인공신경망 모델인 Multilayer Perceptron (MLP)을 사용하였으며, 은닉층의 노드 수는 각각 50개와 32개로 구성하였다.

4. 결과

기계학습 모델을 학습하기에 앞서 Table 2를 통해 독립 변수인 기상 변수 간 스케일 차이가 크다는 것을 알 수 있다. 특히, SS는 0에서 1 사이 값을 가지며 시간 단위로 정보를 담고 있으나, HM은 최대 100%까지의 값을 가진다. 이처럼 스케일이 큰 변수는 모델에 미치는 영향이 상대적으로 더 크게 나타날 수 있으므로, 스케일을 조정하기 위해 표준화 방법을 사용하였다. $x_{i,j}$ 는 i 번째 변수의 j 번째 데이터이

며, μ_i, σ_i 는 각각 i 번째 변수에 대한 평균과 표준편차라 했을 때, 표준화된 데이터 $\hat{x}_{i,j}$ 는 식 (1)과 같이 계산할 수 있다.

$$\hat{x}_{i,j} = \frac{x_{i,j} - \mu_i}{\sigma_i} \quad (1)$$

$$i=1, 2, \dots, 6, \quad j=1, 2, \dots, n$$

1) 평가 지표

기계학습 모델의 성능을 비교하기 위해 Root Mean Squared Error(RMSE), Mean Absolute Error(MAE), 결정계수(R^2)를 사용하였다. RMSE, MAE를 통해 실제값과 예측값 간 차이를 확인하고, R^2 를 통해 예측 모델의 설명력을 평가하고자 한다. y_i 는 i 번째 관측값, $\hat{y}_i$ 는 이에 해당하는 예측치이고, $\bar{y}$ 는 관측값의 평균이라 할 때, RMSE, MAE, R^2 는 Table 3과 같이 정의된다.

Table 3. Equations for RMSE, MAE, and R^2

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

2) 분석 결과

기저 학습기들의 하이퍼 파라미터를 설정하기 위해 교차 검증을 수행하였다. 지면 온도는 시간의 흐름에 따라 관측된 시계열 데이터이므로 시간의 순서를 고려하는 것이 중요하다. 전통적인 교차 검증 방법과 같이 데이터의 순서를 무작위로 섞은 후 교차 검증을 수행하면 시간에 따라 특성이 달라지는 시계열 데이터에 대한 검증 신뢰도가 감소할 수 있다(An *et al.*, 2021). 따라서, 본 연구에서는 연도에 따라 3번의 시계열 교차 검증을 통해 최적의 하이퍼 파라미터를 탐색하였고, 이에 대한 정보는 Table 4에 주어졌다. 시계열 교차 검증을 통해 선정된 하

이퍼 파라미터를 활용하여 기저 학습기들을 학습하였으며, 이를 기반으로 stacking 모델을 생성하였다.

훈련 데이터에 대한 평균 교차 검증 성능을 통해 기계학습 모델의 일반화 예측 성능을 비교하고자 한다. Table 5는 3번의 시계열 교차 검증에 대한 기계학습 모델의 평균 성능과 표준편차를 나타낸다. 기저 학습기들 중에서 LR은 우수한 예측 성능을 보이지만 성능의 변동 폭이 상대적으로 크게 나타난다. Stacking은 모든 성능 지표에서 기저 학습기들을 능가한 예측 성능을 달성하며, LR에 비해 더 안정적인 예측 성능을 보인다. 다양한 기저 학습기들의 예측값을 결합하여 더 안정적이고 우수한 예측 성능을 달성하였음을 알 수 있다.



테스트 데이터에 대해 관측된 지면 온도의 분포와 기계학습 모델의 예측 분포를 분석하고자 한다. Figure 2와 3은 관측값과 예측값에 대한 Residual Q-Q(R-Q-Q) 그래프와 상자 그림을 나타낸다. Quantile-Quantile(Q-Q) 그래프는 관측값과 예측값에 대한 분위수를 비교하여 이들이 동일한 분포로부터 생성된 것인지 확인할 수 있다. R-Q-Q

Table 4. Hyper-parameters of machine learning models.

Model	Parameter	Range
SVR	kernel	polynomial
	C	[0.1, 1, 10, 100]
	gamma	[1, 0.1, 0.01, 0.001]
DT	max_depth	range(3, 20, 2)
	max_features	range(1, 6, 2)
RF	n_estimators	[100, 200, 300]
	max_depth	range(3, 16, 2)
	max_features	range(1, 6, 2)
GBM	n_estimators	[100, 200, 300]
	max_depth	range(3, 16, 2)
	learning_rate	[0.0001, 0.001, 0.1, 0.2, 0.3]

Table 5. The average performance metrics and standard deviation of cross-validation on the training set.

Model	MAE(°C)		RMSE(°C)		R ²	
	Mean	Std	Mean	Std	Mean	Std
SVR	3.134	0.172	4.445	0.058	0.792	0.109
DT	2.301	0.107	3.541	0.083	0.869	0.065
RF	2.031	0.205	3.130	0.263	0.898	0.050
GBM	1.999	0.209	3.123	0.282	0.895	0.064
LR	1.937	0.275	2.932	0.500	0.905	0.066
Stacking	1.863	0.161	2.825	0.312	0.911	0.062

**Figure 2.** Residual Quantile-Quantile (R-Q-Q) plots for the actual values and predicted values of the machine learning models on the testing set.**Figure 3.** Box plot for the actual values and predicted values of the machine learning models on the testing set.

그래프는 y축에 분위수 대신 두 분위수의 차이인 잔차를 나타낸 그래프이다. 이는 기존 Q-Q 그래프를 45도 시계 방향으로 회전한 결과와 유사하지만, 그래프에 대한 해석이 용이하다. R-Q-Q 그래프에서 0을 지나는 수평선을 기준으로 수직 이동을 통해 편이를 파악할 수 있고, 양(음)의 기울기는 과대(과소) 변동을 나타낸다(Marzban *et al.*, 2011).

SVR은 R-Q-Q 그래프가 역의 s-형태의 분포를 띠는 것으로 보아 SVR의 예측 분포가 관측된 지면 온도의 분포보다 두꺼운 꼬리(heavy tail)을 가지고 있을 가능성이 있으며, 상자 그림에서 관측된 지면 온도보다 더 넓은 범위에서 예측값이 생성되었음을 볼 수 있다. SVR을 제외한 5개의 기계학습 모델의 R-Q-Q 그래프는 음의 기울기를 갖는 것으

Table 6. Performance skills of machine learning models on the testing set in terms of RMSE, MAE, and R^2 .

Model	MAE(°C)	RMSE(°C)	R^2
SVR	3.324	4.602	0.873
DT	2.415	3.500	0.927
RF	2.306	3.390	0.931
LR	2.267	3.285	0.935
GBM	2.189	3.192	0.939
Stacking	2.051	2.928	0.949




Figure 4. Time series plot of actual values and predicted values of Staking ensemble for test period.

로 보아 지면 온도의 변동성을 관측보다 작게 예측하였음을 알 수 있다. GBM과 stacking 모델은 다른 기계학습 모델에 비해 관측된 지면 온도와 유사한 상자 그림 분포를 보이므로 관측과 유사한 예측 분포가 생성되었음을 볼 수 있다. 특히, stacking 모델은 R-Q-Q 그래프가 0을 지나는 수평선에 가장 가깝게 분포하므로 기저 학습기들보다 과소 변동성이 적고 우수한 예측 능력을 보여주고 있다는 것을 알 수 있다.

기계학습 모델들을 사용하여 테스트 데이터에 대한 예측 결과를 비교하고 분석하고자 한다. Table 6은 테스트 데이터에 대한 기계학습 모델의 예측 성능을 나타낸다. SVR을 제외한 기계학습 모델들은 약 0.92 이상의 높은 R^2 를 달성하여, 대다수의 기계학습 모델이 지면 온도의 패턴을 효과적으로 설명하고 있음을 알 수 있다. 특히, stacking 모델은 기저 학습기에 비해 RMSE와 MAE가 낮고 높은 R^2 를 보이므로 예측 오차가 작으면서도 높은 설명력을 제공하는 우수한 예측 모델임을 보여준다.

Figure 4는 2022년 봄철을 대상으로 실제 지면 온도와 stacking 모델의 예측값을 월별로 나타낸 그래프이다. 이를 통해, 봄철 지면 온도는 일정한 주기를 가지며 변화하는 시계열 데이터임을 알 수 있다. Stacking 모델은 증가하고 감소하는 지면 온도의 패턴을 유사하게 예측하지만, 하루 중 가장 높은 지면 온도에 대한 예측 능력에는 차이가 있는 것으로 나타난다.

5. 결론

지면 온도는 환경 변화를 모니터링하고 다양한 모델의 설명변수로 사용되므로 정확한 지면 온도 예측이 중요하다. 특히, 봄철 지면 온도는 겨울과 여름의 대기순환 변화를 이해하는 데 중요하다. 하지

만, 구성요소도 다양하고 비열이 상대적으로 적은 지면의 특성에 따라, 지면 온도는 시공간적으로 변동성이 크며 예측에 어려움이 있다. 따라서, 본 연구는 서울을 대상으로 봄철 중관기상관측자료의 기상 정보를 활용하여 1시간 간격으로 지면 온도를 예측하는 stacking 앙상블 모델을 생성하였다. Stacking 모델을 구성하기 위해 단일 모델인 SVM, LR, DT와 앙상블 모델인 RF, GBM을 기저 학습기로 사용하고 신경망 모델인 MLP를 메타 학습기로 사용하였다. 학습 데이터에 대해 연도에 따라 시계열 교차 검증을 수행했을 때, 기저 학습기들 중에서 LR이 우수한 예측 성능을 달성했지만, 성능의 변동 폭은 상대적으로 크게 나타났다. 반면, stacking 모델은 기존 기저 학습기들을 능가하는 예측 성능을 보이며, LR보다 안정적인 예측을 수행하였다.

테스트 기간에 대해 R-Q-Q 그래프를 비교한 결과, SVR은 역의 s-형태의 분포를 띄므로 관측된 지면 온도의 분포보다 두꺼운 꼬리를 갖는 예측 분포를 가질 가능성이 있다. SVR을 제외한 5개 기계학습 모델은 서로 유사한 예측 분포를 보이며, 예측값의 변동성이 관측된 지면 온도의 변동성보다 작은 과소변동을 보여주었다. Stacking 모델은 다른 기저 학습기들보다 관측과 유사한 예측 분포를 보이며 모든 성능 지표에서 좋은 예측 성능을 보여주었다. 이를 통해, stacking 모델은 다양한 기저 학습기들의 예측 결과를 반영하여 일반화 성능을 향상시킬 수 있음을 알 수 있다.

Reference

- An, N., Choi, Y., Cho, H., and Kim, J., 2021, Application of time-series cross validation in hyperparameter tuning of a predictive model for 2,3-BDO distillation process, *Korean Chemical Engineering Research*, 59(4), 532-541.

- Breiman, L., 1996, Stacked regressions, *Machine Learning*, 24, 49-64.
- Choi, J. E. and Lim, Y., 2023, Wavelet-based prediction method for ground temperature in South Korea, *Journal of the Korean Data and Information Science Society*, 34(2), 279-289.
- Dong, J., Huang, G., Wu, L., Liu, F., Li, S., Cui, Y., Wang, Y., Leng, M., Wu, J., and Wu, S., 2022, Modelling soil temperature by tree-based machine learning methods in different climatic regions of China, *Applied Sciences*, 12(10), 5088.
- Hwang, Y. and Kim, C., 2019, Forecast of temperature using ensemble machine learning method, *Journal of Climate Research*, 14(2), 129-143 (in Korean with English abstract).
- Imran, H. M., Hossain, A., Shamma, M. I., Das, M. K., Islam, M. R., Rahman, K., and Almazroui, M., 2022, Land surface temperature and human thermal comfort responses to land use dynamics in Chittagong city of Bangladesh, *Geomatics, Natural Hazards and Risk*, 13(1), 2283-2312.
- Koo, M. H., Song, Y., and Lee, J. H., 2006, Analyzing spatial and temporal variation of ground surface temperature in Korea, *Economic and Environmental Geology*, 39(3), 255-268.
- Ksibi, A., Salhi, A., Alluhaidan, A. S., and El-Rahman, S. A., 2023, Airstacknet: a stacking ensemble-based approach for air quality prediction, *Computers, Materials & Continua*, 74(1), doi: 10.32604/cmc.2023.032566
- Liu, J., Fan, L., Jia, Q., Wen, L., and Shi, C., 2021, Early diabetes prediction based on stacking ensemble learning model, *In 2021 33rd Chinese Control and Decision Conference (CCDC)*, 2687-2692.
- Liu, P., Qian, Y., and Huang, A., 2009, Impacts of land surface and sea surface temperatures on the onset date of the South China Sea summer monsoon, *Advances in Atmospheric Sciences*, 26, 493-502.
- Maddu, R., Vanga, A. R., Sajja, J. K., Basha, G., and Shaik, R., 2021, Prediction of land surface temperature of major coastal cities of India using bidirectional LSTM neural networks, *Journal of Water and Climate Change*, 12(8), 3801-3819.
- Marzban, C., Wang, R., Kong, F., and Leyton, S., 2011, On the effect of correlation on rank histograms: reliability of temperature and wind speed forecasts from fine scale ensemble reforecasts, *Monthly Weather Review*, 139, 295-319.
- Onwuka, B. and Mang, B., 2018, Effects of soil temperature on some soil properties and plant growth, *Advances in Plants & Agriculture Research*, 8(1), 34-37.
- Rocha, N. S. D., Käfer, P. S., Skokovic, D., Veeck, G., Diaz, L. R., Kaiser, E. A., Carvalho, C. M., Cruz, R. C., Sobrino, J. A., Roberti, D. R., and Rolim, S. B. A., 2020, The influence of land surface temperature in evapotranspiration estimated by the S-SEBI model, *Atmosphere*, 11(10), 1059.
- Sharma, P., Shukla, M. K., and Sammis, T. W., 2010, Predicting soil temperature using air temperature and soil, crop, and meteorological parameters for three specialty crops in southern New Mexico, *Applied Engineering in Agriculture*, 26(1), 47-58.
- Song, Y., Chen, H., and Yang, J., 2022, The dominant modes of spring land surface temperature over Western Eurasia and their possible linkages with large-scale atmospheric teleconnection patterns, *Journal of Geophysical Research: Atmospheres*, 127(4), e2021JD035720.
- Suh, M. S., 2012, Land Surface Temperature (LST) Algorithm Technical Analysis (LST-v5.0), NMSC/SCI/ATBD/LST, Issue 1, rev.0, *National Meteorological Satellite Center*, 1-38.
- Tang, W., Zhou, J., Ma, J., Wang, Z., Ding, L., Zhang, X., and Zhang, X., 2023, TRIMS LST: a daily

- 1-km all-weather land surface temperature dataset for the Chinese landmass and surrounding areas (2000-2021), *Earth System Science Data Discussions*, 1-34.
- Ves, A. V., Ghitescu, N., Pop, C., Antal, M., Cioara, T., Anghel, I., and Salomie, I., 2019, A stacking multi-learning ensemble model for predicting near real Time energy consumption demand of residential buildings, *In 2019 IEEE 15th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 183-189.
- Wolpert, D. H., 1992, Stacked generalization, *Neural Networks*, 5(2), 241-259.
- Wu, R., Liu, G., and Ping, Z., 2014, Contrasting Eurasian spring and summer climate anomalies associated with western and eastern Eurasian spring snow cover changes, *Journal of Geophysical Research: Atmospheres*, 119(12), 7410-7424.
- Xue, Y., Oaida, C. M., Diallo, I., Neelin, J. D., Li, S., Sales, F. D., Gu, Y., Robinson, D. A., Vasic, R., and Yi, L., 2016, Spring land temperature anomalies in northwestern US and the summer drought over Southern Plains and adjacent areas, *Environmental Research Letters*, 11(4), 044018.

책임편집: 박창용

영문교열: 정지훈