

지역특화 기후변화 정보 생산기술 개발

부제: 지역특화 상세화 기반기술 개발

**Advanced Downscaling for High-resolution
Climate Information and Sectoral Applications (I)**

박경원, 신용희, 이성규, 이우섭

기후사업본부 기후변화분석과

2025.12.

아시아·태평양경제협력체 기후센터

Executive Summary

Global warming has led to a continuous increase in both the frequency and intensity of extreme weather events, such as heatwaves, floods, and droughts. In this climate crisis, effectively responding to diverse climate-related hazards and establishing adaptation strategies has emerged as a major national priority. To develop rational and effective responses to future climate conditions, the construction of high-resolution climate change scenarios is essential. At present, the generation of high-resolution climate change scenarios relies primarily on dynamical downscaling approaches, which are associated with substantial computational costs. To address this limitation, statistical downscaling and artificial intelligence (AI)- and machine learning-based downscaling methods have been applied; however, these approaches still face constraints in accurately representing regional climate characteristics. In this study, we investigated core downscaling technologies that are critical for the production of high-resolution climate change scenarios. The proposed downscaling framework integrates a multivariate downscaling method (CoKriging) to incorporate physical correlations—one of the key strengths of dynamical downscaling—together with AI techniques capable of learning complex nonlinear patterns. In addition, topographic information was employed as auxiliary data to better capture regional characteristics. For precipitation data, given the limited spatial representativeness of station-based observations, we further examined a data construction approach utilizing satellite-based gridded precipitation datasets.

Accurate rainfall estimation is a crucial element for water resources management, disaster prevention, and climate change analysis. However, conventional ground rain gauge networks struggle to capture rainfall distribution in ungauged areas, such as mountainous terrains and oceans, due to limitations in spatial density. Therefore, this study aims to produce long-term, high-resolution gridded rainfall data by combining the extensive spatial coverage of satellite observation data with the nonlinear analysis capabilities of Machine Learning techniques. In this study, a machine learning-based algorithm was developed to enhance rainfall accuracy by utilizing multi-spectral channel data obtained from satellites and topographic information (DEM) as input variables. The model was trained and optimized using data from ground stations (AWS/ASOS) as Ground Truth. In particular, a correction technique was applied to mitigate underestimation errors, a persistent issue in satellite rainfall data. Validation results of the generated long-term high-resolution rainfall grid data confirmed significant improvements in the Correlation Coefficient and Root Mean Square Error (RMSE) compared to existing single satellite products. The high-resolution rainfall grid constructed through this study was applied to the ungauged region of Vanuatu to establish a database. These data can serve as foundational material for future climate change research, while further improvements to deep learning models remain necessary.

This study aims to produce 1km high-precision meteorological grid data essential for

climate change adaptation and precision agriculture across Jeju Island, where complex terrain creates limitations in capturing accurate weather information with existing observation stations. Based on temperature and precipitation data from 2020 to 2024, various spatial interpolation methods (IDW, OK, CSI, SCOK, OCOK) were compared and validated. Consequently, Universal Cokriging (UCOK) was identified as the optimal downscaling technology by integrating a high-resolution Digital Elevation Model (DEM) as a covariate to model the correlation with altitude as a trend. The UCOK method explicitly models physical characteristics, such as temperature lapse rates and orographic rainfall effects, as linear trends, while spatially correcting residuals for local anomalies. In temperature prediction, UCOK achieved superior performance with an annual coefficient of determination (R^2) exceeding 0.98 and an RMSE below 1.0° C. It successfully captured local phenomena like the Seogwipo warming effect and accurately estimated temperatures in winter highlands, which simple lapse rate models often miss. For precipitation, UCOK effectively simulated both orographic lifting effects by Hallasan and local coastal heavy rain patterns, overcoming the excessive smoothing issues of SCOK and realistically reproducing extreme precipitation events. In conclusion, this study proved that UCOK is the most effective methodology for regions with complex terrain like Jeju, as it simultaneously accounts for physical trends and local variability. The high-resolution grid data constructed through this research successfully restored detailed climate information for the previously unmonitored mid-mountain and highland areas. These datasets are expected to serve as reliable foundational data for sectoral applications, including predicting changes in citrus cultivation areas, preventing road icing accidents in mountainous regions, and managing water resources.

In this study, we developed and evaluated a deep learning-based artificial intelligence approach for climate data downscaling. An Enhanced Deep Super-Resolution (EDSR) model with residual learning was adopted as the base network to downscale ERA5 near-surface air temperature (T2M) data, and training datasets were constructed for $2\times$, $4\times$, and $8\times$ resolution enhancement using various upsampling and downsampling interpolation methods. To better represent regional characteristics, multiple model configurations (CASE OLR, D, DU, DUR, and UD) were designed by incorporating topographic data (DEM) as auxiliary inputs. Model performance was assessed over East Asia, including the Korean Peninsula, through comparisons with high-resolution ERA5 data and ASOS station observations using both image quality and statistical evaluation metrics. The results showed that models incorporating DEM as an auxiliary variable consistently outperformed those without it, and that models trained with nearest-neighbor-based datasets exhibited particularly strong performance. Across different downscaling factors, the DU-, DUR-, and UD-type models using nearest-neighbor interpolation achieved the highest overall performance.

This study quantitatively assessed the spatio-temporal reproduction performance of high-resolution climate information using the 1km MK-PRISM and 500m MS-PRISM (v1, v2)

models. Based on statistical and spatial analyses of observed data from 2000 to 2019, the 500m_v2 model consistently demonstrated superior performance across all evaluation metrics. By applying a narrow influence radius and incorporating the latest GIS data, the model accurately reproduced local extreme temperatures in complex terrains, significantly reducing prediction errors that had previously occurred in mountainous and coastal regions with the older 1km model.

Future climate projections under the SSP5-8.5 scenario (2071-2100) indicate that South Korea will undergo a pronounced climate shift, including an approximate 8.8° C increase in annual maximum temperature and a substantial rise in the frequency and intensity of extreme heat events in major cities. In particular, Seoul exhibited a marked rate of temperature increase due to the urban heat island effect. These findings highlight that high-resolution (500m) climate information, which captures local topography and urban characteristics, provides critical evidence for developing national climate adaptation policies and region-specific disaster response strategies.

국문 요약

지구온난화로 인해 폭염, 홍수, 가뭄과 같은 극한 기상 현상의 발생 빈도와 강도가 지속적으로 증가하고 있다. 이러한 기후위기 상황에서 다양한 기후 재해에 효과적으로 대응하고 적응 전략을 수립하는 것은 국가적 차원의 주요 과제로 부각되고 있다. 미래 기후 조건에 대한 합리적인 대응책을 마련하기 위해서는 고해상도 기후변화 시나리오의 구축이 필수적이다. 현재 고해상도 기후변화 시나리오의 산출은 주로 역학적 상세화 방법에 의존하고 있으며, 이는 막대한 계산 비용이 요구된다는 한계를 지닌다. 이러한 한계를 보완하기 위해 통계적 상세화 및 인공지능·기계학습 기반 상세화 기법이 활용되고 있으나, 지역적 기후 특성을 충실히 반영하는 데에는 여전히 제약이 존재한다. 이에 본 연구에서는 고해상도 기후변화 시나리오 산출에 핵심적인 상세화 기반 기술을 연구하였다. 제안된 상세화 기법은 역학적 상세화의 주요 장점인 물리적 상관관계를 반영하기 위해 다변수 상세화 기법(CoKriging)과 복잡한 비선형 패턴을 학습할 수 있는 인공지능 기술을 이용하였다. 또한 지역적 특성을 보다 효과적으로 반영하기 위해 보조 자료로 지형 정보를 활용하였다. 아울러 강수 자료의 경우, 지점 관측 자료가 지니는 공간적 범위의 한계를 극복하기 위해 위성 기반 격자 강수 자료를 활용한 자료 구축 방법을 검토하였다.

정확한 강수량 산출은 수자원 관리, 재해 예방 및 기후 변화 분석에 있어 필수적인 요소이다. 그러나 기존의 지상 우량계 관측망은 공간적 밀도의 한계로 인해 산악 지형이나 해양과 같은 미계측 지역의 강우 분포를 파악하는 데 어려움이 있다. 이에 본 연구는 위성 관측 자료의 광범위한 공간 커버리지와 기계학습(Machine Learning) 기법의 비선형 해석 능력을 결합하여 장기간의 고해상도 격자 강우 자료를 산출하는 것을 목적으로 한다. 본 연구에서는 위성에서 획득한 다중 분광 채널 자료와 지형 정보(DEM)를 입력 변수로 활용하여 강우 정확도를 높이기 위해 기계학습기반의 알고리즘을 구축하였으며, 지상 관측소(AWS/ASOS) 자료를 참값(Ground Truth)으로 하여 모델을 학습 및 최적화하였다. 특히, 위성 강우 자료의 고질적인 문제인 과소 추정 오차를 줄이기 위한 보정기법을 적용하였다. 산출된 장기간의 고해상도 강우 격자 자료를 검증한 결과, 기존 위성 단일 산출물 대비 상관관계수(Correlation Coefficient)와 제곱근평균오차(RMSE)가 유의미하게 개선되었음을 확인하였다. 본 연구를 통해 구축된 고해상도 강우 격자는 미계측 지역인 바누아투 지역에 적용하여 데이터베이스를 구축하였다. 이러한 자료는 향후 기후변화 연구의 기초자료로 활용될 수 있으며, 딥러닝 모델의 추가적인 개선이 필요하다.

복잡한 지형 특성으로 인해 기존 관측소만으로는 기상 정보를 정확히 파악하기 어려운 제주도 전역을 대상으로, 기후변화 적응 및 정밀 농업 등에 필수적인 1km 고해상도 기상 격자 데이터를 구축하고자 하였다. 2020년부터 2024년까지의 기온 및 강수량 관측 데이터를 바탕으로 다양한 공간 보간 기법(IDW, OK, CSI, SCOK, OCOK)을 비교·검증한 결과, 해발고도(DEM)를 보조 변수로 통합하여 고도와 상관성을 경향성(Trend)으로 모델링하는 범용 공동 크리깅(Universal Cokriging, UCOK)이 최적의 상세화 기술로 도출되었다. UCOK 기법은 고도에 따른 기온 감률과 지형성 강우 효과를 일차식 형태의 명시적 경향성으로 반영하고, 이에 따르지 않는 국지적 이상치(Anomaly)는 잔차 보정을 통해 정교하게 수정하는 방식이다. 분석 결과, 기온 예측에서 UCOK는 연중 결정계수(R^2) 0.98 이상, RMSE 1.0°C 미만의 압도적인 성능을 기록하

였으며, 단순 고도 감률로는 설명되지 않는 서귀포의 국지적 고온 현상과 겨울철 산간 오지의 기온까지 정확히 구현하였다. 강수량 예측에서도 한라산에 의한 강제 상승 효과와 해안가의 국지성 호우 패턴을 유연하게 모의하여, SCOK 기법의 과도한 평활화 문제를 극복하고 극한 강수 사상을 현실적으로 재현해 냈다. 이 연구는 지형적 영향이 지배적인 제주도에서 UCOK 기법이 물리적 경향성과 국지적 변동성을 동시에 포착하는 최적의 방법론임을 입증하였다. 이를 통해 구축된 고정밀 격자 자료는 관측 공백지대였던 중산간 및 산간 지역의 상세 기후 정보를 성공적으로 복원하였으며, 향후 감귤 재배 적지 선정, 산악 도로 결빙 방재, 수자원 관리 등 지역 맞춤형 기후변화 대응 정책 수립에 있어 신뢰도 높은 기초 자료로 활용될 것이다.

본 연구에서는 딥러닝 기반 인공지능 기후자료 상세화 기법을 개발·평가하였다. EDSR(잔차 학습 기반) 모델을 기본 네트워크로 활용하여 고해상도 ERA-5 기온(T2M) 자료를 대상으로 2배, 4배, 8배 상세화 학습자료를 구축하였으며, 업·다운샘플링 과정에서 다양한 보간법을 적용하였다. 또한 지역 특성 반영을 위해 지형자료(DEM)를 보조변수로 결합한 여러 모델 구조(CASE OLR, D, DU, DUR, UD)를 설계하였다. 모델 성능은 동아시아(한반도 포함) 지역을 대상으로 고해상도 ERA-5 자료 및 ASOS 관측자료와의 비교를 통해 이미지 품질 지표와 통계 지표로 평가하였다. 그 결과, DEM 보조변수를 활용한 모델들이 전반적으로 우수한 성능을 보였으며, 특히 NN 보간법 기반 학습자료를 사용한 경우 성능 향상이 두드러졌다. 상세화 배율별로는 NN 보간법 기반 학습자료를 이용한 DU·DUR·UD 계열 모델이 상위 성능을 보였다.

본 연구는 전 지구 기후모델의 낮은 해상도에서 발생하는 구조적 불확실성을 저감하고, 복잡한 지형에서 국지적 기후 변동성 및 극한 기상현상의 시공간적 재현 성능을 정량적으로 비교 및 평가하기 위해 1km 해상도의 MK-PRISM 모델과 개선된 500m 해상도의 MS-PRISM(v1, v2) 모델을 분석하였다. 2000년부터 2019년까지 국내 605개 기상 관측소 자료를 기준으로 상관 계수, 평균 제곱근 오차, KGE 지표 및 Morans' I/LISA 공간 분석을 수행한 결과, 최신 500m_v2 모델이 모든 평가 지표에서 가장 우수한 성능을 보였다. 특히 500m_v2 모델은 좁은 영향반경(1.3km)과 최신 GIS정보를 적용하여 복잡한 지형에서의 기온 변동성과 국지적 극한기온을 정밀하게 재현하였으며, 기존 1km 모델이 보였던 산악 및 해안 지역의 예측 오차를 획기적으로 개선하였다.

미래 기후 전망 분석 결과에 따르면, 고배출 시나리오(SSP5-8.5) 하에서 우리나라는 연최고기온이 약 8.8℃ 상승하고 한파가 완화되는 뚜렷한 기후 변화를 겪을 것으로 전망하였다. 재현수준 분석 결과, 서울과 부산등 주요 도시에서 극한 고온의 빈도와 강도가 크게 증가할 것으로 나타났으며, 특히 서울은 도시열섬 효과로 인해 단기 재현주기에서도 높은 온도 상승폭을 보였다. 이러한 결과는 국지적 지형과 도시 특성을 반영할 수 있는 고해상도(500m)기후정보가 국가 차원의 기후 적응 정책 및 지역 맞춤형 재해 대응 전략 수립에 필수적임을 시사한다.

목차

Executive Summary	i
국문 요약	iv
목차	vi
표 차례	vii
그림 차례	xi
1. 서론	1
2. 방법 및 자료	3
2.1. 위성기반 고해상도 격자 자료 산출 및 알고리즘 개발, 품질관리	3
2.1.1. GPM 위성	3
2.1.2. PERSIANN	6
2.1.3. CMORPH	7
2.1.4. CHIRPS	9
2.1.5. 지상관측자료	11
2.1.6. 기계학습모델	13
2.1.7. 방법	13
2.2. 다변수 상세화 기반기술 개발	16
2.2.1. 자료 및 연구 대상 지역	16
2.2.2. 단변수 상세화 기법	17
2.2.3. 다변수 상세화 기법(Cokriging 기반)	21
2.3. 기후변화 전망자료의 활용성 증대를 위한 AI 기반 상세화 기술 개발	25
2.3.1. 연구자료 및 학습자료 구축	25
2.3.3. 인공지능 기반 상세화 모델 설계	29
2.3.4. 인공지능 기반 상세화 모델 평가	32
2.4. 기후자료 해상도에 따른 극한기후 재현성 평가	36
2.4.1. 자료	36
2.4.1.1 관측자료	36
2.4.2. 분석방법	40
2.5.1. 현황 분석 및 전문가 의견 수렴	46
2.5.2. 세부 지수별 산출 및 개선 방법	46
3. 결과	48

3.1. 위성기반 고해상도 격자자료 산출 및 알고리즘 개발, 품질관리	48
3.1.1. 위성자료 검증	48
3.1.2. 기계학습 모델 산출 자료 검증	51
3.1.3. 산출 알고리즘 활용	63
3.2. 다변수 상세화 기반기술 개발	64
3.2.1. 공간 데이터 구축	64
3.2.2. 단변수 공간 보간 기법 적용 결과	67
3.2.3. 다변수 공간 보간 기법 적용 결과	79
3.2.3.3. Universal Cokriging (UCOK) 기법 적용	93
3.3. 기후변화 전망자료의 활용성 증대를 위한 AI 기반 상세화 기술 개발	104
3.3.1. 인공지능 기반 상세화 모델 결과	104
3.4. 기후자료 해상도에 따른 극한기후 재현성 평가	123
3.4.1. 지형고도와 기온의 연관성	124
3.4.2. 상세화모델들의 예측성 평가	127
3.4.3. KGE 기반 종합 성능 분석	135
3.3.4. 모델 성능의 공간적 자기상관 및 패턴 분석	139
3.3.5. 극한기온지수 기반 상세격자모델 성능 검토	142
3.3.6. 극한지수의 미래전망	151
3.5. 부문별 영향정보지수(농업부문 8종 개선)	155
3.5.1. 작물 생육 지표의 통합 및 표준화	155
3.5.2. 과수 및 시설농업 맞춤형 지표 고도화	155
3.5.3. 축산부문 폭염 대응력 강화	156
4. 요약 및 결론	157
사사	161
References	162
Appendix A. Examples of top-ranked downscaling results compared with reference data	
.....	167

표 차례

Table 2.1. Comparison of the Advantages and Limitations of Spatial Interpolation Methods.	20
Table 2.2. Summary of study data (C3S CDS, 2023).	25
Table 2.3. Summary of GMTED 2010 DEM data (Danielson and Gesch, 2011).	26
Table 2.4. Automatic Quality Control (QC) Criteria (Reconstructed from the 2023 Final Report of the National R&D Project on Climate Monitoring and Prediction Applications).	38
Table 2.5. Description of Data Sources, Resolution, and GIS Attributes.	39
Table 2.6. Local Clusters and Outliers Based on Standard Deviation.	43
Table 2.7. Climate Extreme indices used in this study.	45
Table 3.1. The results of a statistical analysis from rainfall of machine learning models and satellite precipitation products.	59
Table 3.2. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by OK Model.	69
Table 3.3. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by OK Model.	72
Table 3.4. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by IDW Model.	73
Table 3.5. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by IDW Model.	75
Table 3.6. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by CSI Model.	77
Table 3.7. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by CSI Model.	78
Table 3.8. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by OCOK Model.	80
Table 3.9. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by OCOK Model.	84
Table 3.10. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by SCOK Model.	88
Table 3.11. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by SCOK Model.	91

Table 3.12. Annual Validation Metrics for Temperature Interpolation (2020–2024) Estimated by UCOK Model.	95
Table 3.13. Annual Validation Metrics for Precipitation Interpolation (2020–2024) Estimated by UCOK Model.	98
Table 3.14. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the training dataset for the period 2020–2024.	105
Table 3.15. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE OLR results for the period 2020–2024.	107
Table 3.16. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE D results for the period 2020–2024.	108
Table 3.17. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE DU results for the period 2020–2024.	109
Table 3.18. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE DUR results for the period 2020–2024.	110
Table 3.19. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE UD results for the period 2020–2024.	111
Table 3.20. Ranking summary of image quality and statistical evaluation metrics for all 2x downscaling results.	113
Table 3.21. Ranking summary of image quality and statistical evaluation metrics for all 4x downscaling results.	114
Table 3.22. Ranking summary of image quality and statistical evaluation metrics for all 8x downscaling results.	115
Table 3.23. Summary of statistical evaluation metrics comparing CASE OLR results with ASOS observations for the period 2020–2024.	116
Table 3.24. Summary of statistical evaluation metrics comparing CASE D results with ASOS observations for the period 2020–2024.	117
Table 3.25. Summary of statistical evaluation metrics comparing CASE DU results with ASOS observations for the period 2020–2024.	118
Table 3.26. Summary of statistical evaluation metrics comparing CASE DUR results with ASOS observations for the period 2020–2024.	119
Table 3.27. Summary of statistical evaluation metrics comparing CASE UD results with ASOS observations for the period 2020–2024.	120

Table 3.28. Ranking summary of statistical evaluation metrics for all 2x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.	121
Table 3.29. Ranking summary of statistical evaluation metrics for all 4x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.	121
Table 3.30. Ranking summary of statistical evaluation metrics for all 8x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.	122
Table 3.31. Model Specifications: Resolution and Influence Radius.	128
Table 3.32. Model Performance Evaluation Based on KGE Values.	136
Table 3.33. LISA-Based Spatial Clustering Performance: Comparison of 500m_v2, 500m_v1, and 1km Models.	142
Table 3.34. Results of Improvement on Agricultural Impact Indices.	156

그림 차례

Figure 2.1. GPM IMERG Final run version 7 product for KOREA penninsular.	5
Figure 2.2. Flowchart of NOAA PERSIANN retrival algorithm.	7
Figure 2.3. Flowchart of NOAA CMORPH product.	9
Figure 2.4. CHIRPS precipitation distribution in Korea peninsular at jun 22, 2000.	11
Figure 2.5. Locations of AWS, ASOS observation station in Jeju.	12
Figure 2.6. The rainfall of gridded ground observation stations.	12
Figure 2.7. Flowchart of machine learning method by raw satellite precipitation products. ·	15
Figure 2.8. Locations of Meteorological Observation Stations in Jeju.	16
Figure 2.9. 1-km Grid Elevation (DEM) Distribution Map within Jeju.	17
Figure 2.10. Example of ERA-5 T2M daily data.	25
Figure 2.11. GMTED 2010 (30 arc-seconds) global elevation dataset: (a) Breakline Emphasis (BE), (b) Systematic Subsample (DS), (c) Median Statistic (MD), (d) Minimum Statistic (MI), (e) Mean Statistic (MN), (f) Maximum Statistic (MX), (e) Standard Dev. Statistic (SD).	27
Figure 2.12. Schematic overview of the dataset generation process for AI-based climate downscaling.	28
Figure 2.13. Structure of 1 patch of the dataset.	28
Figure 2.14. Example of the 1 patch of the dataset.	29
Figure 2.15. Comparison of residual blocks: (a) Resnet, (b) EDSR.	30
Figure 2.16. EDSR-based downscaling model: CASE OLR.	31
Figure 2.17. EDSR-based downscaling model: CASE D.	31
Figure 2.18. EDSR-based downscaling model: CASE DU.	31
Figure 2.19. EDSR-based downscaling model: CASE DUR.	32
Figure 2.20. EDSR-based downscaling model: CASE UD.	32
Figure 2.21. Comparison of PSNR and SSIM values according to variations in image quality.	33
Figure 2.22. Diagram of the ASOS station data construction process.	35
Figure 2.23. Distribution of selected 605 observation sites across South Korea.	36
Figure 2.24. Trend in Valid Station Usage (2000-2019).	37
Figure 2.25. Gridded Data Production Method Using MK-PRISM and MS-PRISM.	40
Figure 3.1. The statistical results of comparison with GPM IMERG and ASOS rainfall.	49

Figure 3.2. The statistical results of comparison with PERSIANN and ASOS rainfall.	51
Figure 3.3. Coefficient of determination for machine learning models by raw satellite precipitation.	52
Figure 3.4. Root Mean Square Error of machine learning models for rainfall product.	54
Figure 3.5. The MAE value for rainfall from the machine learning models.	54
Figure 3.6. Correlation coefficient comparison with satellite precipitation estimation and rainfall of machine learning models.	56
Figure 3.7. THE RMSE and MAE comparion with satellite precipitation estimation and rainfall by machine learning models.	57
Figure 3.8. The scatterplot of raw satellite rainfall and observed station rainfall.	61
Figure 3.9. The scatterplot of rainfall from machine learning models and observed station rainfall.	62
Figure 3.10 Visualization of precipitation from machine learning model for Vanuatu peninsular.	63
Figure 3.11. Daily Temperature Time Series for Selected Meteorological Stations in Jeju Island (2020-2024).	65
Figure 3.12. Daily Precipitation Time Series for Selected Meteorological Stations in Jeju Island (2020-2024).	65
Figure 3.13. Observed Daily Climatology Across All Stations (5-Year Mean).	66
Figure 3.14. Elevation-Based Variations in Observed Daily Temperature Climatology (5-Year Mean).	66
Figure 3.15. Monthly Mean Temperature Distribution (2020-2024) Estimated by OK Model.	68
Figure 3.16. Seasonal Mean Temperature Distribution (2020-2024) Estimated by OK Model.	68
Figure 3.17. Annual Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by OK Model.	69
Figure 3.18. Monthly Temperature Validation Metrics (OK Model, 2020-2024).	69
Figure 3.19. Monthly Cumulative Precipitation Distribution (2020-2024) Estimated by OK Model.	70
Figure 3.20. Seasonal Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by OK Model.	71
Figure 3.21. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by OK Model.	71

Figure 3.22. Monthly Precipitation Validation Metrics (OK Model, 2020–2024).	72
Figure 3.23. Mean Temperature Distribution in Jeju Island (2020–2024) Estimated by IDW Model.	73
Figure 3.24. Monthly Temperature Validation Metrics (IDW Model, 2020–2024).	74
Figure 3.25. Annual Cumulative Precipitation Distribution in Jeju Island (2020–2024) Estimated by IDW Model.	75
Figure 3.26. Monthly Precipitation Validation Metrics (IDW Model, 2020–2024).	75
Figure 3.27. Mean Temperature Distribution in Jeju Island (2020–2024) Estimated by CSI Model.	76
Figure 3.28. Monthly Temperature Validation Metrics (CSI Model, 2020–2024).	77
Figure 3.29. Annual Cumulative Precipitation Distribution in Jeju Island (2020–2024) Estimated by CSI Model	78
Figure 3.30. Monthly Precipitation Validation Metrics (CSI Model, 2020–2024).	78
Figure 3.31. Mean Temperature Distribution in Jeju Island (2020–2024) Estimated by OCOK Model.	80
Figure 3.32. Monthly Temperature Validation Metrics (OCOK Model, 2020–2024).	80
Figure 3.33. LOOCV RMSE Map of the OCOK Temperature Model.	81
Figure 3.34. LOOCV R2 Map of the OCOK Temperature Model.	81
Figure 3.35. RMSE by Elevation Band (OCOK Temperature Model).	82
Figure 3.36. R2 by Elevation Band (OCOK Temperature Model).	82
Figure 3.37. Annual Cumulative Precipitation Distribution in Jeju Island (2020–2024) Estimated by OCOK Model.	83
Figure 3.38. Monthly Precipitation Validation Metrics (OCOK Model, 2020–2024).	84
Figure 3.39. LOOCV RMSE Map of the OCOK Precipitation Model.	85
Figure 3.40. LOOCV R2 Map of the OCOK Precipitation Model.	85
Figure 3.41. RMSE by Elevation Band (OCOK Precipitation Model).	86
Figure 3.42. R2 by Elevation Band (OCOK Precipitation Model).	86
Figure 3.43. Mean Temperature Distribution in Jeju Island (2020–2024) Estimated by SCOK Model.	87
Figure 3.44. Monthly Temperature Validation Metrics (SCOK Model, 2020–2024).	88
Figure 3.45. LOOCV RMSE Map of the SCOK Temperature Model.	89
Figure 3.46. LOOCV R2 Map of the SCOK Temperature Model.	89

Figure 3.47. RMSE by Elevation Band (SCOK Temperature Model).	90
Figure 3.48. R2 by Elevation Band (SCOK Temperature Model).	90
Figure 3.49. Annual Cumulative Precipitation Distribution in Jeju Island (2020–2024) Estimated by SCOK Model.	91
Figure 3.50. Monthly Precipitation Validation Metrics (SCOK Model, 2020–2024).	92
Figure 3.51. LOOCV RMSE Map of the SCOK Precipitation Model.	92
Figure 3.52. LOOCV R2 Map of the SCOK Precipitation Model.	92
Figure 3.53. RMSE by Elevation Band (SCOK Precipitation Model).	93
Figure 3.54. R2 by Elevation Band (SCOK Precipitation Model).	93
Figure 3.55. Mean Temperature Distribution in Jeju Island (2020–2024) Estimated by UCOK Model.	94
Figure 3.56. Monthly Temperature Validation Metrics (UCOK Model, 2020–2024).	95
Figure 3.57. LOOCV RMSE Map of the UCOK Temperature Model.	96
Figure 3.58. LOOCV R2 Map of the UCOK Temperature Model.	96
Figure 3.59. RMSE by Elevation Band (UCOK Temperature Model).	96
Figure 3.60. R2 by Elevation Band (UCOK Temperature Model).	96
Figure 3.61. Annual Cumulative Precipitation Distribution in Jeju Island (2020–2024) Estimated by UCOK Model.	97
Figure 3.62. Monthly Precipitation Validation Metrics (UCOK Model, 2020–2024).	98
Figure 3.63. LOOCV RMSE Map of the UCOK Precipitation Model.	99
Figure 3.64. LOOCV R2 Map of the UCOK Precipitation Model.	99
Figure 3.65. RMSE by Elevation Band (UCOK Precipitation Model).	99
Figure 3.66. R2 by Elevation Band (UCOK Precipitation Model).	99
Figure 3.67. Spatial Classification of Temperature Zones in Jeju Island using K-means Clustering.	100
Figure 3.68. Spatial Classification of Precipitation Zones in Jeju Island using K-means Clustering.	100
Figure 3.69. Spatial Patterns of the First Three Leading EOF Modes for Temperature in Jeju Island.	102
Figure 3.70. Spatial Patterns of the First Three Leading EOF Modes for Precipitation in Jeju Island.	103
Figure 3.71. Comparison of PSNR results between high-resolution ERA5 data and the training	

dataset for the period 2020-2024.	105
Figure 3.72. Comparison of SSIM results between high-resolution ERA5 data and the training dataset for the period 2020-2024.	105
Figure 3.73. Comparison of PSNR results between high-resolution ERA5 data and the CASE OLR results for the period 2020-2024.	106
Figure 3.74. Comparison of SSIM results between high-resolution ERA5 data and the CASE OLR results for the period 2020-2024.	106
Figure 3.75. Comparison of PSNR results between high-resolution ERA5 data and the CASE D results for the period 2020-2024.	107
Figure 3.76. Comparison of SSIM results between high-resolution ERA5 data and the CASE D results for the period 2020-2024.	108
Figure 3.77. Comparison of PSNR results between high-resolution ERA5 data and the CASE DU results for the period 2020-2024.	109
Figure 3.78. Comparison of SSIM results between high-resolution ERA5 data and the CASE DU results for the period 2020-2024.	109
Figure 3.79. Comparison of PSNR results between high-resolution ERA5 data and the CASE DUR results for the period 2020-2024.	110
Figure 3.80. Comparison of SSIM results between high-resolution ERA5 data and the CASE DUR results for the period 2020-2024.	111
Figure 3.81. Comparison of PSNR results between high-resolution ERA5 data and the CASE UD results for the period 2020-2024.	111
Figure 3.82. Comparison of SSIM results between high-resolution ERA5 data and the CASE UD results for the period 2020-2024.	112
Figure 3.83. MAE comparison between CASE OLR results and ASOS observations for the period 2020-2024.	117
Figure 3.84. MAE comparison between CASE D results and ASOS observations for the period 2020-2024.	118
Figure 3.85. MAE comparison between CASE DU results and ASOS observations for the period 2020-2024.	118
Figure 3.86. MAE comparison between CASE DUR results and ASOS observations for the period 2020-2024.	119
Figure 3.87. MAE comparison between CASE UD results and ASOS observations for the period	

2020–2024.	120
Figure 3.88. Spatial Distribution of Observation Stations and DEM Elevation in South Korea (500m Resolution).	124
Figure 3.89. Elevation differences between observational data (black) and PRISM DEM (green) for 605 stations.	125
Figure 3.90 Coastal Proximity and Terrain Facet Orientation in Relation to RMSE of Temperature.	126
Figure 3.91. Gridded Model Performance Comparison for TAVE (2000–2019).	130
Figure 3.92. Gridded Model Performance Comparison for TMAX (2000–2019).	131
Figure 3.93. Gridded Model Performance Comparison for TMIN (2000–2019).	132
Figure 3.94. Boxplot Analysis of Monthly R^2 for TAVE Prediction Across Three Grid Models (2000~2019).	133
Figure 3.95. Boxplot Analysis of Monthly Correlation coefficient for TAVE Prediction Across Three Grid Models (2000~2019).	134
Figure 3.96. Boxplot Analysis of Monthly BIAS for TAVE Prediction Across Three Grid Models(2000~2019).	135
Figure 3.97. Boxplot Comparison of KGE Values for TAVE, TMIN, and TMAX Across Three Grid Models (2000–2019).	137
Figure 3.98. Spatial Distribution of KGE for Temperature Variables Across Different Grid Models.	138
Figure 3.99. Spatial Cluster Comparison of Observed and Modeled Temperature Using Local Moran' s I.	140
Figure 3.100. Comparative Evaluation of Grid Models Based on LISA Metrics: Relative Performance of 500m_v2, 500m_v1, and 1km.	141
Figure 3.101. Spatial Comparison of YearMaxT: Observations vs. Grid-Based Models (500m_v1, 500m_v2, 1km).	144
Figure 3.102. Statistical Comparison of YearMaxT: Observations vs. Three Grid-Based Models.	145
Figure 3.103. Spatial Comparison of YearminT: Observations vs. Grid-Based Models (500m_v1, 500m_v2, 1km).	146
Figure 3.104. Statistical Comparison of YearMaxT: Observations vs. Three Grid-Based Models.	148

Figure 3.105. Yearly Variation of Extreme Temperature Indices.	150
Figure 3.106. Mean and Standard Deviation of Climate Indices: Observations vs. 500m_v1, 500m_v2, and 1km Models.	151
Figure 3.107. Spatial distribution and change of Annual Maximum Temperature under SSP Scenarios.	152
Figure 3.108. Spatial distribution and change of Annual Minimum Temperature under SSP Scenarios.	153
Figure 3.109. Return Level Analysis of Annual Maximum Temperature in Busan and Seoul.	154
Figure A1. Examples of top-ranked results on 21 January, 2020.	167
Figure A2. Examples of top-ranked results on 21 July, 2024.	168

1. 서론

전 지구적인 기온 상승으로 인해 폭염, 홍수, 가뭄 등 극한 기상 현상의 빈도와 강도가 과거보다 점점 증가하고 강해지고 있다. 이러한 기후위기 속에서 다양한 재해에 효과적으로 대응하고 적응 대책을 수립하는 것이 중요한 국가적 핵심 과제로 대두되었다.

현재 널리 사용되는 전 지구 기후모델(GCM, Global Climate Model)은 공간 해상도가 낮아, 지역 단위의 상세한 재해 위험도 평가, 적응 계획 등 지역 계획 및 의사 결정에 직접 활용하기에 어려움이 있다. 공간 해상도에 따라서는 산악과 해안 지역처럼 지형 변화가 큰 곳에서는 격자 해상도가 낮아질수록 실제보다 기온이 과대 추정되는 등 큰 편향이 발생하여 지역적 기후 특성을 반영하는데 제한이 있다. 따라서, 지역적 특성과 복잡한 지형을 정밀하게 반영할 수 있는 고해상도 기후자료 구축이 필요하다.

정확한 강수량의 추정은 수문학적 순환의 이해, 수자원 관리, 홍수 및 가뭄과 같은 기상 재해의 예방과 대응에 있어 가장 기초적이면서도 필수적인 요소이다. 전통적인 지상 우량계(Rain gauge) 네트워크는 지점 관측(Point measurement)으로서 가장 높은 정확도를 제공하지만, 산악 지형, 해양, 개발도상국의 오지 등 접근이 어려운 지역에서는 공간적 연속성을 확보하기 어렵다는 물리적 한계를 지닌다. 이러한 시공간적 공백을 메우기 위해 위성 기반 강수 산출물(Satellite Precipitation Products, SPPs)이 광범위하게 활용되어 왔으며, 대표적으로 GPM, CHIRPS, CMORPH, PERSIANN 등이 전 지구적 강수 모니터링의 핵심 자원으로 자리 잡았다.

그러나 이들 위성 산출물은 관측 센서의 종류(적외선, 마이크로파 등)와 산출 알고리즘의 고유한 특성으로 인해 지상 관측 대비 여전히 상당한 오차를 내포하고 있다. 특히 복잡한 지형에서의 과소 추정이나, 온난 강우(Warm rain)의 탐지 실패, 그리고 증발이나 바람에 의한 오차 등은 기후변화의 기초자료로서의 신뢰성을 저하시키는 주요 요인으로 지적된다. 이에 따라 최근 데이터 과학의 발전과 함께 기계학습(Machine Learning, ML) 기법을 도입하여 위성 강수 산출물의 오차를 보정하고 예측 성능을 고도화하려는 시도가 활발히 이루어지고 있다.

이 연구에서는 서로 다른 원시 위성을 입력자료로 하는 기계학습 모델(Random Forest, XGBoost)에서 산출된 고해상도 강우 격자자료와 주요 원시 위성 강수 산출물(CHIRPS, CMORPH, PERSIANN, GPM)의 성능을 정량적으로 비교 분석한 결과를 상세히 기술한다. 본 분석은 상관계수(Correlation Coefficient, R), 평균 제곱근 오차(Root Mean Square Error, RMSE), 평균 절대 오차(Mean Absolute Error, MAE) 등의 통계적 지표 분석을 통해 각 모델의 강수 탐지 능력과 강도 추정의 정확성을 심층적으로 평가하였다. 특히 기계학습 모델이 기존 위성 산출물의 한계를 어떻게 극복하였는지, 그리고 각 위성 산출물이 보여주는 오차의 패턴이 어떠한 물리적 배경에서 기인하는지를 규명하는 데 주안점을 두었다. 산출된 기계학습 모델을 이용하여 미계측 지역인 바누아투 지역에 장기간의 고해상도 자료를 구축하고 데이터베이스화 하였다.

고해상도 기후변화 표준 시나리오 산출 과정은 전지구 기후변화 시나리오(135km)자료를 역학적 상세화(dynamic downscaling) 기법을 이용하여 동아시아 지역과 같이 특정 대륙에 특화

된 기후변화 시나리오(25km) 자료를 생산한다. 이 자료를 이용하여 Parameter-elevation Regressions on Independent Slopes Model (PRISM) 등 통계적 상세화(statistical downscaling) 기법을 이용하여 좀 더 상세한 지역에 특화된 기후변화 시나리오를 생산한다(KMA, 2025). 지역 기후 특성을 보다 정확하게 반영하기 위한 편의보정(bias correction) 방법을 이용한 고해상도 미래전망 기온 자료 생산 과정은 GCM 미래전망 시나리오 자료와 GCM 과거 재현 시나리오의 편차를 관측자료에 더하여 생산한다(Lee, 2021). 고해상도 기후변화 시나리오 산출에서 정밀한 상세화 기법과 종관기상관측자료(ASOS, Automated Synoptic observing System)와 자동기상관측자료(AWS, Automatic Weather Station)의 한계인 지점자료를 보완하기 위한 격자자료를 구축하는 것이 중요하다.

기후 자료 상세화에는 통계적 상세화(statistical downscaling), 인공지능/기계학습 상세화(Artificial Intelligence/machine learning downscaling), 역학적 상세화(dynamic downscaling) 방법이 있다. 통계적 상세화는 과거 과측자료와 모델 간의 관계를 기반한 방법이며, 다른 방법에 비해 낮은 계산 비용이 장점이다. 단점으로는 미래 기후변화 변수 간의 연관성을 반영하는데 한계가 있다. 인공지능/기계학습 상세화 방법은 복잡한 비선형 관계 학습을 통해 높은 예측 정확도를 갖고 있으며 예측 속도도 빠르다. 다만, 학습에는 고성능의 GPU가 필요하다. 단점으로는 학습 데이터 가용성에 의존하기 때문에 데이터가 부족하면 모델을 제대로 학습하기 어렵다. 역학적 상세화는 고해상도 물리 모델 재모의를 통해 복잡한 지형과 기후 상호작용을 반영하여 우수한 예측성능 보이지만, 다른 방법에 비해 매우 높은 계산 비용이 발생한다.

우리는 통계적 상세화와 인공지능/기계학습 상세화 기법을 이용하여 고해상도 기후변화 시나리오 자료생산에 필요한 상세화 기술을 개발하려고 한다. 두 방법에 역학적 상세화의 장점인 물리적 상관관계를 반영하기 위한 다변수 상세화 기법(CoKriging) 활용하고 지역적 특성을 고려하기 위해 지형 보조자료로 활용하고자 한다. 또한, 기후변화 시나리오 자료 평가 및 국가 기후변화 표준 시나리오 자료의 활용성 증대를 위한 영향정보지수 개선도 수행하고자 한다.

2. 방법 및 자료

2.1. 위성기반 고해상도 격자 자료 산출 및 알고리즘 개발, 품질관리

2.1.1. GPM 위성

GPM 미션은 단일 위성에 의존하던 기존 방식에서 탈피하여, 핵심 위성과 파트너 국가들의 위성들로 구성된 위성군(Constellation) 개념을 도입하여 저궤도 위성의 방문 주기 한계를 극복하고, 전 지구 어디서나 3시간 이내의 재방문 주기(Revisit Time)를 확보하는 것을 목표로 한다. IMERG(Integrated Multi-satellitE Retrievals for GPM)는 이러한 GPM 미션의 모든 관측 자료를 통합하여 생산되는 Level 3 최종 강수 산출물중에서 일강수량을 본 연구에서 이용하였다(Huffman et al.,2000). IMERG는 저궤도 위성의 마이크로파(Passive Microwave, PMW) 센서가 제공하는 높은 정확도의 강수 추정치와 정지궤도 위성의 적외선(Infrared, IR) 센서가 제공하는 높은 시공간 해상도를 결합한다. 여기에 지상 우량계 자료를 이용한 편이 보정(Bias Correction)을 적용하여, 연구 및 현업에 활용 가능한 최적의 강수장을 제공하고 있다. 2023년 공개된 IMERG Version 07은 이전 버전인 V06에서 제기되었던 다양한 기술적 한계를 극복하고, 물리적 정합성을 높이기 위해 알고리즘이 전면적으로 개편된 최신 알고리즘으로 이루어졌다.

본 보고서는 이 V07 자료, 특히 기후학 연구에 가장 널리 활용되는 일강수량(Daily Precipitation) 자료를 장기간 기후격자 자료 산출에 핵심 자료로 이용하였다. IMERG V07 알고리즘에서 입력 자료가 되는 위성 센서들의 물리적 특성에서 GPM 위성은 65°의 경사각을 가진 비태양동기 궤도를 돌며, 극지방을 제외한 전 지구를 관측하며 두 가지 핵심 센서가 탑재되어 있다. GMI (GPM Microwave Imager)은 다채널 수동 마이크로파 센서로, 10GHz부터 183GHz까지의 넓은 주파수 대역을 관측한다. 낮은 주파수는 액체 상태의 빗방울에서 방출되는 마이크로파를 직접 감지하며, 높은 주파수는 얼음 입자에 의한 산란(Scattering) 효과를 감지한다. GMI는 IMERG 알고리즘 내에서 다른 모든 위성 센서의 강수 추정치를 보정하는 기준(Reference standard) 역할을 수행한다. V07에서는 이 GMI의 보정 역할이 더욱 강화되었다. DPR (Dual-frequency Precipitation Radar)센서는 Ku-band(13.6 GHz)와 Ka-band(35.5 GHz)의 두 가지 주파수를 사용하는 강수 레이더이다. 3차원 강수 구조와 입자 크기 분포(DSD)를 직접 측정할 수 있어, GMI 강수 산출 알고리즘(GPROF)의 물리적 데이터베이스를 구축하는 데 핵심적인 지상 검증(Ground Truth) 대체재 역할을 한다. IMERG는 핵심위성 외에도 미국(NASA, NOAA, DoD), 일본(JAXA), 유럽(EUMETSAT) 등에서 운용하는 다양한 위성들의 마이크로파 센서 자료를 통합하여 자료를 제공한다. 보조위성(Constellation satellites)으로 원추형 스캐너 센서인 GMI, TMI(TRMM), SSMIS(DMSP 위성), AMSR-2(GCOM-W1) 등이 포함되며, 지표면을 일정한 입사각으로 관측하므로 복사휘도온도(Brightness Temperature, Tb)의 편광 특성을 일정하게 유지할 수 있어 강수 산출 정확도가 높으며, IMERG V07에서는 이들 센서 간의 상호 보정(Intercalibration)이 더욱 정교해져, 센서 교체에 따른 시계열 불연속성을 최소화하여 정확도를 향상시킨다. 크로스 트랙 스캐너 센서는 MHS(MetOp, NOAA), ATMS(Suomi-NPP, JPSS) 등이 있으며, 관측 폭이 넓어 시공간 커버리지 확보에 유리하지만, 스캔 각도에 따라 지표면 방사율과 대기 경로 길이가 달라지는 단점이 있다. V07에서는 이러한 Cross-track 센서들의 강수 산

출 알고리즘(GPROF V07) 성능이 개선되었으나, 여전히 원추형 스캐너 센서에 비해 불확실성이 큰 편이다. 마이크로파 센서는 궤도 특성상 관측 공백(Gap)이 발생할 수밖에 없기 때문에 이를 메우기 위해 전 지구를 상시 감시하는 정지궤도 위성(GOES, Meteosat, Himawari 등)의 적외선(IR) 채널 자료를 결합하여 사용한다. IR 자료는 구름 꼭대기 온도(Cloud Top Temperature)를 측정하여 간접적으로 강수 강도를 추정하므로 물리적 직접성은 떨어지지만, 높은 시공간 해상도를 제공하기 때문에 알고리즘에 활용된다.

본 연구에 사용된 V07은 V06 대비 알고리즘의 거의 모든 단계에서 중대한 개선이 이루어졌다. 알고리즘은 크게 상호 보정(Intercalibration), 격자화(Gridding), 모핑 및 칼만 필터통합(Morphing & Kalman Filter), 그리고 편이 보정(Bias Correction)의 단계로 자료를 생산한다. 1단계인 센서 상호 보정은 서로 다른 특성을 가진 위성 센서들의 데이터를 하나로 묶기 위한 과정이다. V06까지는 TRMM 시대에는 TMI를, GPM 시대에는 GMI를 기준으로 각각 보정을 수행하여 두 시대 간의 연결부에서 미세한 통계적 불일치가 발생하였는데 V07에서는 전 기간(TRMM-GPM Era, 2000년~현재)에 대해 GPM Core Observatory의 GMI 센서를 단일 기준(Anchor)으로 설정하여 일관성을 확보하였다. 이를 위해 TMI 데이터를 GMI 기준에 맞게 재보정하는 과정을 거쳤으며, 이는 장기간의 기후 분석(Climatological Analysis)을 수행하는 연구자들에게 매우 중요한 개선 사항으로 보고되며, 보정 과정에서 사용되는 히스토그램 매칭 기법을 고도화하여, 강수 강도별 보정 계수를 더욱 세밀하게 산출하여 자료를 생산한다. 2단계인 격자화는 각 위성 궤도 좌표계(Swath)에서 산출된 Level 2 강수 자료(GPROF)를 0.1° 격자로 변환하는 과정으로 V06 및 그 이전 버전의 IMERG에는 치명적인 기하학적 오류가 존재하였는데 이는 PMW 데이터를 격자화하는 과정에서 약 0.18° (적도 기준 약 20km) 정도 동쪽으로 위치가 치우치는(Eastward Shift) 오류가 발생하여 해안선이나 급경사 산악 지역에서 강수의 위치가 실제 지형과 어긋나는 현상이 발생했었다. V07에서는 오류를 발견하고 완전히 수정하였다. 이는 국지적 호우 사상의 공간적 정확도를 획기적으로 향상시켰다. 본 연구에서 기후변화의 도시의 홍수 분석이나 산악 강수 연구를 위해 V07을 이용하였다. 3단계인 칼만필터와 모핑 기법을 더 고도화한 알고리즘으로 위성이 지나가지 않는 시간대의 강수량을 추정하기 위해, IMERG는 수치예보모델(MERRA-2, GEOS-FP)의 바람 벡터를 이용하여 강수 구름을 이동시키는 모핑(Morphing) 기법을 사용하여 위성이 지나가지 않는 시간대의 정확도를 향상시켰다. V06에서는 PMW 관측이 있는 시각에는 해당 PMW 값을 그대로 사용하고, 관측이 없는 시각은 모핑된 값으로 채우는 방식으로 자료를 산출하였다. 그러나 V07에서는 PMW 관측값이 있는 순간이라도 이를 절대적인 진실(Ground Truth)로 간주하지 않고, 칼만 필터의 업데이트 단계에서 하나의 관측 변수로 통합하였다. 즉, PMW 관측값과 이전 시간 단계에서 전파되어 강수 추정값을 각각의 오차 공분산에 따라 가중 평균하여 최적의 상태 값을 도출한다. 이는 위성 관측 자체의 불확실성을 통계적으로 인정하고 처리하는 방식으로, 강수장의 시간적 연속성을 부드럽게 만들고 급격한 값의 튜핑 현상을 방지한다. PMW 관측이 장시간 부재할 경우 사용되는 IR 기반 강수 추정 알고리즘이 기존의 PERSIANN-CCS에서 PDIR-Now(Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Dynamic Infrared Rain Rate)로 교체되었다. PDIR-Now는 더 짧은 지연 시간과 높은 반응성을 가지며, 구름의 발달 및 소멸 단계에 따른 밝기 온도와 강수 강도 간의 비선형적 관계를 더 잘 모의한다. 이를 통해 대류성 강수의 급격한 발달을 포착하는 능력이 향상되었다. 4단계는 지상 우량계와의 편이 보정 단계로 IMERG

Final Run은 독일 기상청(DWD)의 GPCC(Global Precipitation Climatology Centre)에서 제공하는 월강수량 분석장을 적용하며 전 세계 기상청이 GTS망을 통해 공유하는 약 7,000~9,000개소의 SYNOP 및 CLIMAT 전문 데이터를 기반으로 위성 강수량의 월 합계가 GPCC 격자값과 일치하도록 위성 강수량에 보정 계수를 적용한다. 지상 우량계 자체도 바람에 의한 포착 손실 오차를 가지고 있다. 기존 V06에서 사용된 Legates-Willmott 보정식은 고위도나 한랭 지역에서 우량계 손실을 과도하게 추정하여, 결과적으로 강수량을 지나치게 과대추정 경향이 있었다. V07에서는 이를 개선하기 위해 유라시아 대륙 45° N 이북 지역에 대해서는 새로운 보정식을 결합하여 적용되었다. 이는 고위도 지역의 강수량 과대평가 문제를 완화하고, 수문 수지 분석의 정확도를 높였다. 더불어 V07의 기술적 혁신은 위성 강수 자료를 시공간적으로 평균하거나 보간(Interpolation)하는 과정, 특히 칼만 필터를 거치는 과정에서 필연적으로 발생하는 통계적 부작용은 강수 강도의 확률밀도함수(PDF)가 좁아지는 현상이다. 즉, 평균화 효과(Smoothing Effect)로 인해 약한 비의 빈도는 늘어나고, 강한 비(Extreme Rain)의 강도는 낮아지며 면적은 넓어지는 왜곡이 발생한다. V07에 처음 도입된 SHARPEN(Scheme for Histogram Adjustment with Ranked Precipitation Estimates in the Neighborhood) 기법은 이러한 왜곡을 후처리로 교정한 다. 이 기법은 각 0.1° 격자점 주변의 이웃 격자값들을 참조하여, 뭉개진 강수 값의 히스토그램을 원래의 날카로운(Sharp) 분포 형태, 즉 실제 PMW 관측값이나 고해상도 IR 추정값이 가지는 통계적 분포로 재조정(Remapping)하여 자료를 산출한다(Figure 2.1).

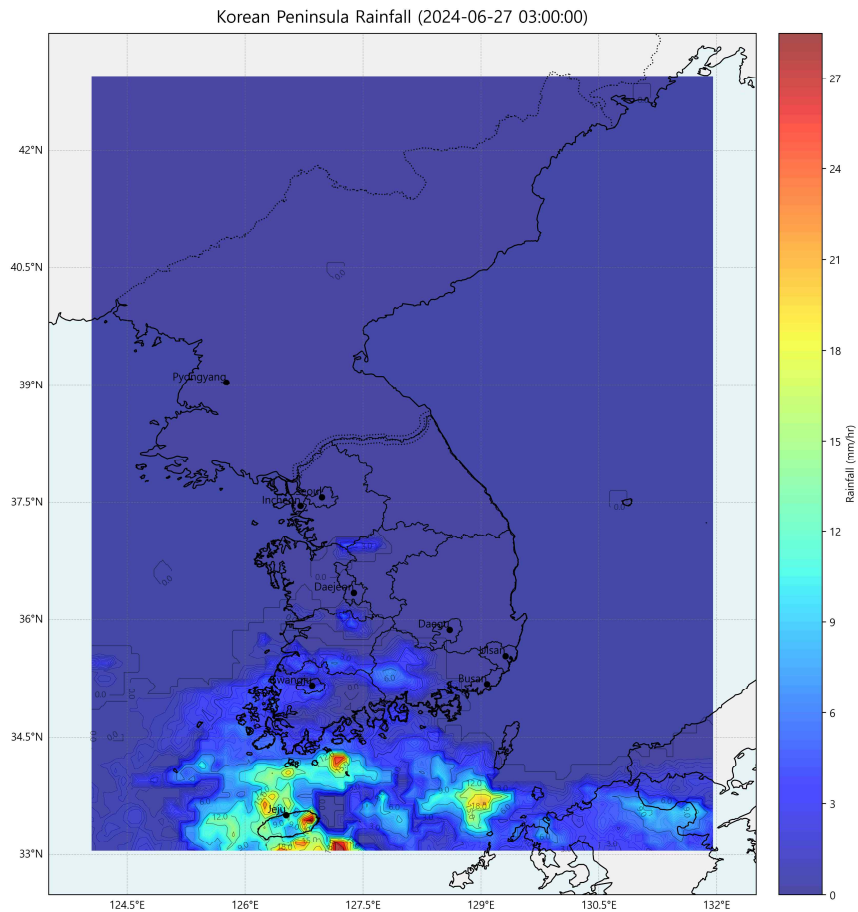


Figure 2.1. GPM IMERG Final run version 7 product for KOREA penninsular.

2.1.2. PERSIANN

PERSIANN(Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks) 시스템은 인공지능, 특히 인공신경망(Artificial Neural Networks, ANN) 기술을 위성 기상학에 선도적으로 도입한 혁신적인 알고리즘으로 캘리포니아 대학교 어바인(UC Irvine)의 CHRS(Center for Hydrometeorology and Remote Sensing)와 애리조나 대학교, 그리고 NOAA(미국 해양대기청)의 협력으로 개발된 PERSIANN은 정지궤도 위성의 높은 시간 해상도와 저궤도 위성의 마이크로파 센서 정확도를 결합하여 전 지구적 강수 데이터를 산출한다(Sorooshian et al.,2000). 본 보고서는 NOAA PERSIANN 시스템의 핵심 알고리즘인 수정된 역전파 네트워크의 수학적 구조부터, 다양한 데이터 제품군(Standard, CCS, CDR)의 특성, 그리고 기후 연구를 위한 장기 데이터셋인 PERSIANN-CDR을 이용하였다. PERSIANN 알고리즘의 핵심은 위성에서 관측된 적외선(Infrared, IR) 휘도 온도(Brightness Temperature, Tb)와 지표면 강수량(Rain Rate) 사이의 복잡하고 비선형적인 관계를 인공신경망을 통해 학습시켜 산출한다. 이는 구름 상단 온도(Cloud Top Temperature)가 낮을수록 구름이 두껍고 강수 확률이 높다는 물리적 전제를 바탕으로 하되, 단순한 회귀분석으로는 설명하기 어려운 구름의 Texture와 변동성을 신경망이 스스로 학습하게 함으로써 추정의 정확도를 획기적으로 높인 알고리즘으로 수정된 역전파 네트워크(Modified Counter Propagation Network, MCPN)라는 독특한 신경망 아키텍처를 기반으로 하는데 이 모델은 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)으로 구성된 다층 순방향 네트워크의 형태를 띠지만, 정보 처리 방식에 있어 기존의 역전파 알고리즘과는 차별화된 하이브리드 접근법을 사용한다.

PERSIANN은 구름의 공간적 분포 특성을 반영하기 위해 해당 픽셀을 중심으로 한 국소적 텍스처 정보를 입력 벡터로 사용하는데 10.2, 11.2 μm 파장대의 적외선 윈도우 채널(IRWIN)의 휘도 온도를 $n \times n$ 픽셀 윈도우 내의 평균 온도와 표준편차의 정보를 이용하여 강수를 유발하는 적란운(Cumulonimbus)과 강수가 없는 층운형(stratiform)이나 얇은 권운(cirrus)을 구별하여 강수량을 산출하는데 입력된 적외선 텍스처 정보는 은닉층에서 자기 조직화 특징 지도(Self-Organizing Feature Map, SOFM) 알고리즘을 통해 처리되는데, SOFM은 비지도 학습(Unsupervised Learning) 방식을 사용하여 입력 데이터 내에 존재하는 위상적 구조와 패턴을 감지하고, 유사한 특성을 가진 구름 패턴들을 자동으로 군집화하여 수많은 위성 이미지 픽셀들을 대표적인 구름 원형(Prototype)으로 분류하는 역할을 수행하고 SOFM을 통해 분류된 구름 패턴은 출력층으로 전달되어 실제 강수 강도(Rain Rate)로 변환된다. 이 단계에서는 지도 학습(Supervised Learning)이 적용되며, 지상 레이더나 수동 마이크로파 위성 데이터와 같은 참값(Ground Truth)과의 오차를 최소화하는 방향으로 가중치가 조정하는 방식으로 강수량을 산출한다. PERSIANN 시스템의 가장 강력한 기능적 특징은 적응형 학습 방식으로 정지궤도 위성(GEO)의 적외선 센서는 높은 시간 해상도(15분~1시간)를 제공하지만, 구름 상단 정보만으로는 구름 내부의 빗방울을 직접 탐지하는 데 한계가 있지만 저궤도 위성(LEO)에 탑재된 수동 마이크로파 센서(TRMM TMI, GPM GMI, SSM/I, AMSU-B 등)는 강수 입자와 직접 상호작용하여 물리적으로 더 정확한 강수 정보를 제공하지만, 관측 빈도가 하루 1~2회로 매우 낮기 때문에 이 두 데이터의 장점을 결합하기 위해 먼저 마이크로파 위성이 특정 지역을 통과할 때마다, 해당 시점의 IR 데이터와 마이크로파 강수 데이터를 co-located화 하여 신경망의 파라미터를 실시간으

로 업데이트하고 계절, 위도, 그리고 대기 상태의 변화에 따라 지속적으로 IR-강수 관계식을 진화시켜 서로 다른 가중치를 적용하여 데이터를 산출한다(Figure 2.2). 본 연구에서 사용된 자료는 1983년 1월부터 제공되는 표준 자료로 역전파 네트워크와 IR센서와 마이크로파 센서를 융합한 자료로 공간 해상도는 $0.25^{\circ} \times 0.25$ 시간해상도 일강수량 자료이다.

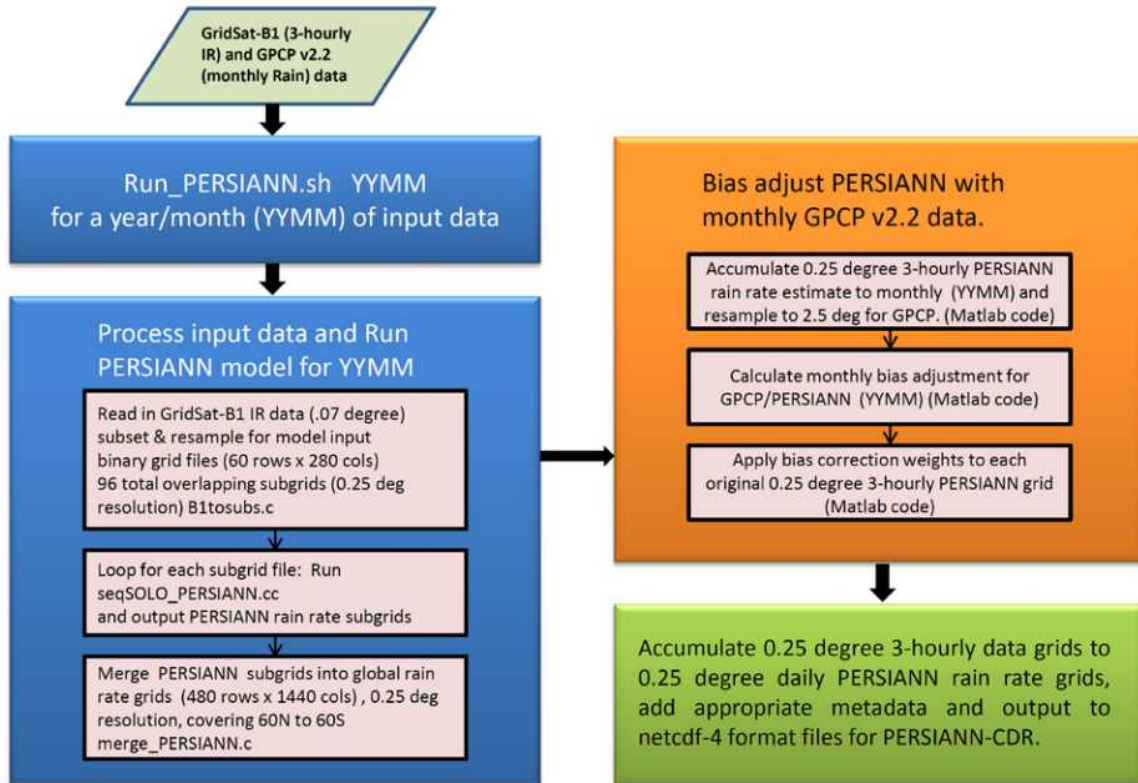


Figure 2.2. Flowchart of NOAA PERSIANN retrieval algorithm.

2.1.3. CMORPH

NOAA(National Oceanic and Atmospheric Administration) 기후예측센터(Climature Prediction Center, CPC)에서 제안된 자료로 정지궤도 적외선 센서와 수동 마이크로파 센서의 장점을 결합하는 혁신적인 기법을 제안된 CMORPH(CPC Morphing technique) 기법의 자료이다. Joyce et al. (2004)에 의해 처음 소개된 CMORPH는 기존의 적외선 기반 강수 추정 방식이나 단순한 통계적 블렌딩과는 근본적으로 다른 접근 방식을 취한다. CMORPH의 핵심 알고리즘은 적외선 데이터는 강수량의 강도(Intensity)를 추정하는 데 사용하지 않고, 오직 강수 시스템의 이동(Motion)을 추적하는 데에만 사용한다는 것이다. 즉, 물리적으로 우수한 마이크로파 강수 추정장을 적외선 영상에서 유도된 이동 벡터(Motion Vector)를 따라 시공간적으로 유체처럼 변형(Morphing) 및 이류(Advection)시킴으로써, 마이크로파 센서의 정확성과 적외선 센서의 시공간 해상도를 동시에 확보하는 것이다. 본 보고서는 기후 분석 연구 수행을 위해 NOAA CMORPH CDR 일강수량(Daily Precipitation)을 이용한다. NOAA 기후 데이터 기록(CDR) 프로그램의 일환으로 개발된 일강수량 자료는 1998년 1월부터 현재까지의 전체 기간에 대해 하나의 알고리즘(Fixed Algorithm)과 일관된 입력 자료 처리 방식을 적용하여 재처리된 데이터셋으로. CDR 버

전은 기후 변화 연구와 같이 장기적인 경향성 분석이 필요한 분야에서 인위적인 데이터 불연속성(Artificial Discontinuity)을 최소화하기 위해 설계된 자료이다. 자료의 공간해상도는 25km이며, 시간해상도는 일강수량으로 위도 60° S ~ 60° N의 전 지구를 커버하며, 극지방(60° 이상)이 제외되는 주된 이유는 눈/얼음 지표면에서의 마이크로파 방사율(Emissivity) 변화가 심해 강수 신호와 지표면 신호를 분리하기 어렵고, 정지궤도 위성의 시야각 확보가 어렵기 때문에 극지방의 자료를 제공하고 있지 않다,

CMORPH는 많은 저궤도 위성 마이크로파 센서를 사용하는데 SSM/I(Special Sensor Microwave Imager) & SSMI 센서는 미국 국방성(DoD)의 DMSP 위성군(F13, F14, F15 등)에 탑재된 영상 센서(Imager)로, 19, 22, 37, 85 GHz 대역을 관측하는 자료를 이용중이고 AMSU-B(Advanced Microwave Sounding Unit-B) & MHS (Microwave Humidity Sounder) 센서는 NOAA 위성(NOAA-15~19) 및 유럽의 MetOp 위성(A, B)에 탑재된 사운더(Sounder)이다. 이 센서는 주로 89, 150, 183 GHz 대역을 사용하여 대기 중의 얼음 입자 산란(Ice Scattering)을 통해 육상 강수를 효과적으로 탐지한다. TMI (TRMM Microwave Imager)센서는 TRMM 위성에 탑재되어 열대 지역 강수 관측의 기준(Standard) 역할을 수행하며, 10GHz 채널을 포함하여 강한 강수 탐지에 유리한 센서이다. GMI (GPM Microwave Imager) 센서는 GPM(Global Precipitation Measurement) Core 위성에 탑재된 최신 센서로, TRMM의 후속으로서 고위도까지 커버하며 정밀한 보정 기준을 제공한다. AMSR-E & AMSR2 센서는 NASA Aqua 및 JAXA GCOM-W1 위성 에 탑재된 고해상도 센서로, 넓은 관측폭(Swath)을 제공한다. ATMS (Advanced Technology Microwave Sounder)센서는 Suomi-NPP 및 NOAA-20 위성에 탑재된 차세대 사운더로 알고리즘 입력자료로 이용된다. 각 센서의 휘도온도(Brightness Temperature, Tb)를 강수량으로 변환하기 위해 다양한 알고리즘이 사용되는데, 초기에는 Ferraro (1995) 알고리즘(SSM/I), Ferraro et al. (2000)(AMSU-B), GPROF 2001(TMI) 등이 혼용되어 강수량을 산출하였다. 2020년에는 기존의 입력 자료 소스였던 NESDIS의 MSPPS(Microwave Surface and Precipitation Products System) 시스템 운영이 종료됨에 따라, 2021년 1월부터는 NASA의 GPROF (Goddard Profiling Algorithm) V05 기반의 Level 2 강수 자료로 입력 소스가 전면 전환되었다. GPROF는 베이지안(Bayesian) 통계 기법을 기반으로, 위성 관측 Tb와 사전에 구축된 방대한 물리적 강수 프로파일 데이터베이스(A-priori Database)를 매칭하여 최적의 강수량을 추정하는 알고리즘이다.

NOAA의 기술 보고서에 따르면, 이러한 입력 소스 변경에도 불구하고 구버전(MSPPS 기반)과 신버전(GPROF 기반) 간의 강수 패턴 상관계수는 매우 높으며, 시계열의 불연속성은 미미한 것으로 평가되었다. 마이크로파 센서들은 지구를 스캔하는 저궤도 위성 에 탑재되어 있어, 특정 지점을 관측하는 시간 간격(Revisit Time)이 3시간 이상 벌어지는 경우가 많다. 이 공백 기간 동안 강수 시스템의 이동과 발달/소멸을 모사하기 위해 CMORPH는 정지궤도 위성(GEO IR)을 활용한다. 전 지구를 덮고 있는 정지궤도 위성군(GOES, Meteosat, Himawari 등)으로부터 30분 간격, 4km 해상도의 적외선(10.7 μ m 등) 영상을 획득한다. 연속된 두 적외선 영상 사이의 공간적 상관관계(Spatial Cross-Correlation)를 계산하여, 각 격자별로 구름 시스템의 이동 속도(u)와 방향(v)을 나타내는 이동 벡터(Advection Vector)를 산출한다. 산출된 이동 벡터를 이용하여, 마이크로파 관측이 존재하는 시점의 강수장을 관측이 없는 목표 시점(Target Time)으로 전파한다. 순방향 전파는 과거 시점에 관측된 PMW 강수장을 이동 벡터를 따라 미래 방향으로 이동시켜 목표 시점의 강수장 위치를 추정하고, 역방향 전파는 미래 시점에 관측될 PMW 강수장을

이동 벡터를 역추적하여 과거 방향으로 이동시켜 목표 시점의 위치를 추정한다(Joyce et al.,2004). 목표 시점에서의 최종 강수량은 순방향으로 전파된 강수량과 역방향으로 전파된 강수량의 가중 평균으로 결정된다. 가중치는 관측 시점과의 시간적 거리에 반비례하도록 설정된다.

$$R(t) = w_{fwd} \cdot R_{fwd}(t) + w_{bwd} \cdot R_{bwd}(t) \quad [2.1]$$

여기서

$$w_{fwd} = \frac{t_{end} - t}{t_{end} - t_{start}}, w_{bwd} = \frac{t - t_{start}}{t_{end} - t_{start}} \quad [2.2]$$

이 수식은 목표 시점이 과거 관측 시점 t_{start} 에 가까우면 순방향 전파 값에 더 큰 가중치를, 미래 관측 시점 t_{end} 에 가까우면 역방향 전파 값에 더 큰 가중치를 부여함을 의미한다. 이를 통해 강수 시스템의 위치뿐만 아니라 형태와 강도가 시간의 흐름에 따라 부드럽게 변형(Morphing)되는 효과를 구현하여 최종 강수량을 산출한다(Figure 2.3).

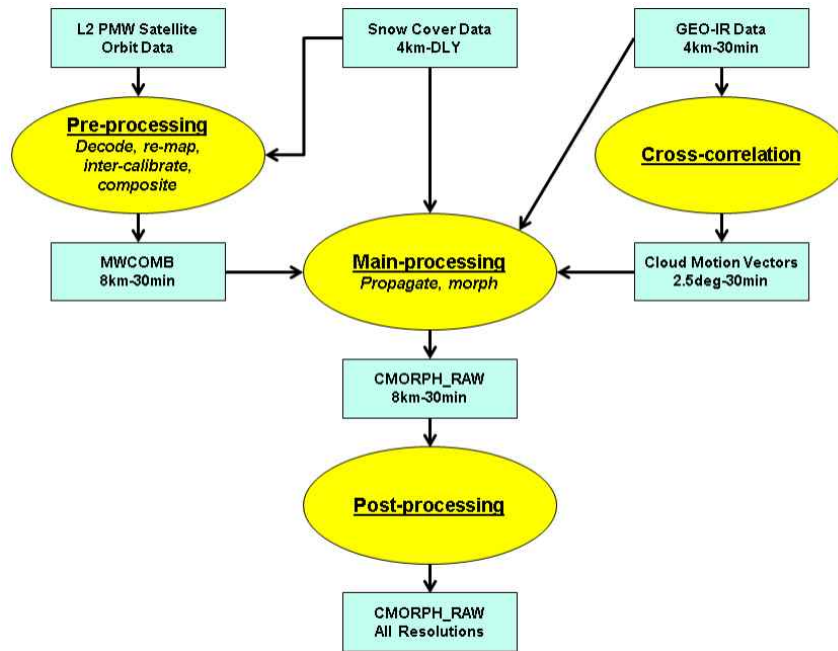


Figure 2.3. Flowchart of NOAA CMORPH product.

2.1.4. CHIRPS

정지 궤도 위성(Geostationary Satellite)의 적외선(Infrared, IR) 센서는 높은 시간 해상도로 구름의 상단 온도를 관측하여 간접적으로 강수 강도를 추정할 수 있게 했으며, 극궤도 위성(Polar-orbiting Satellite)의 마이크로파(Microwave) 센서는 구름 내부의 수분 함량을 보다 물리적으로 탐지할 수 있다. 이를 통해 GPCP(Global Precipitation Climatology Project), CMORPH(CPC MORPHing technique), TRMM(Tropical Rainfall Measuring Mission) 등 다양한 전 지구 강수 데이터셋이 개발되었다. 하지만 초기 위성 강수 산출물들은 몇 가지 결정적인 한계

를 안고 있었다. 첫째, 적외선 기반 추정은 구름 상단 온도와 지표 강수 간의 간접적 관계에 의존하므로 정량적 정확도가 떨어지는 경향이 있었다. 둘째, 마이크로파 관측은 정확도는 높으나 관측 빈도가 낮아 연속적인 시계열 확보가 어려웠다. 셋째, 많은 위성 산출물들이 0.25° (약 25km) 이상의 거친 공간 해상도를 가지고 있어, 복잡한 지형에서의 국지적 강수 패턴이나 소규모 유역의 수문학적 반응을 모의하는 데 한계가 있었다. 넷째, 무엇보다도 기후 변화 연구에 필수적인 30년 이상의 장기간 일관성 있는 기록(Long-term Homogeneous Record)을 제공하는 고해상도 데이터셋이 부재했다. 이러한 배경 속에서 미국 캘리포니아 대학교 산타바바라(UCSB)의 기후 위험 그룹(Climatic Hazards Group, CHG)과 미국 지질조사국(USGS)은 미 국제개발처(USAID)의 기근 조기 경고 시스템 네트워크(FEWS NET)를 지원하기 위해 CHIRPS (Climate Hazards Group InfraRed Precipitation with Stations) 데이터셋을 개발하였다. CHIRPS는 위성 관측의 광범위한 공간 커버리지와 지상 관측의 정량적 정확성을 결합한 하이브리드 데이터셋으로, 1981년부터 현재까지 35년 이상의 기간 동안 준전구(Quasi-global) 영역(50° S- 50° N) 고해상도 강수 정보를 제공한다. CHIRPS는 단순한 위성 데이터가 아니며, 단순한 지상 관측의 보간도 아닌 데이터다. 이는 다중 센서(Multi-sensor) 및 다중 소스(Multi-source) 데이터를 복합적으로 융합한 산출물로 CHIRPS의 핵심 설계 알고리즘은 지상 관측소가 없는 지역에서는 신뢰할 수 있는 기후학적 평균과 위성 변동성을 따르고, 관측소가 있는 지역에서는 관측값을 정확히 반영하는 데이터를 구현하는 것이다. 이를 구현하기 위해 CHIRPS 알고리즘은 크게 세 가지 핵심 기둥으로 구성된다: (1) 고해상도 기후장(CHPclim), (2) 위성 기반 강수 추정(CHIRP), (3) 지상 관측소와의 합성(Station Blending) 데이터이다. 본문에서 사용된 데이터는 CHIRPS자료로 시공간적 변동성을 결정하는 핵심 동적 입력 자료는 정지 궤도 위성에서 관측한 열적외선(Thermal Infrared, TIR) 데이터이다. 대류성 강수 시스템에서 구름의 상단 온도는 구름의 높이와 밀접한 관련이 있다. 구름이 높게 발달할수록 상단 온도는 낮아지며, 이는 강한 상승 기류와 높은 강수 확률을 의미한다. CHIRPS는 구름 상단 온도가 특정 임계값 미만인 상태가 지속된 시간, 즉 CCD(Cold Cloud Duration)를 강수량의 대리 변수(Proxy)로 사용한다. 데이터 소스는 1981년부터 2000년까지 NOAA CPC(Climatic Prediction Center)의 B1 데이터셋과 GridSat-B1 등을 사용하여 30분 간격의 위성 이미지를 처리한다. 이 시기의 데이터는 위성 커버리지의 한계로 일부 지역(특히 초기 아프리카 및 인도양)에서 자료 공백이 있을 수 있다. 2000년 이후 자료는 NOAA CPC의 고해상도(4km) 적외선 데이터가 가용해지면서 보다 정밀한 CCD 산출이 가능해졌다. 반면에 단점은 CCD 방식은 구름의 상단 온도만을 이용하므로, 구름 상단은 차갑지 않지만 하층에서 비를 뿌리는 따뜻한 비(Warm Rain) 과정(예: 층운형 강수, 해안가 강수)을 감지하는 데 취약하다. 이는 CHIRPS가 특정 열대 해양성 기후나 낮은 구름에서 발생하는 강수를 과소 추정할 수 있는 원인이 된다. 알고리즘은 0.05° 픽셀에 대해 5일 단위의 CCD 값을 계산한다. 이 CCD 값은 TRMM 3B42와 같은 마이크로파 기반 위성 강수량과의 회귀 분석을 통해 강수량(mm)으로 변환된다. 생성된 CHIRP 데이터에 지상 관측소 데이터를 융합하여 최종 CHIRPS를 생성하는 과정이다(Funk et al, 2015). 이 과정은 수정된 역거리 가중법(Modified Inverse Distance Weighting)을 사용하여 수행된다. 지상 관측소가 위치한 지점에서, 관측된 강수량과 CHIRP 위성 추정치 간의 비율을 계산한다. 이는 위성 데이터가 해당 지점에서 실제 강수량을 얼마나 과대 또는 과소 평가했는지를 나타내는 보정 계수가 된다. 산출된 점 단위의 비율을 격자 전체로 보간하여 비율장을 생성한다. 이때 사용되는 가중치(Weighting)는 단순한 거리가 아니라, 위성 강수장의 공간적 상관관계수 감쇠 거리(Spatial Decorrelation Distance)를 반영

한다. 즉, 강수 패턴이 균질하게 유지되는 지역 내의 관측소에는 높은 가중치를, 상관성이 떨어지는 지역에는 낮은 가중치를 부여한다. 보간된 비율장을 원본 CHIRP 데이터에 곱하여 최종 CHIRPS 값을 산출한다(Figure 2.4).

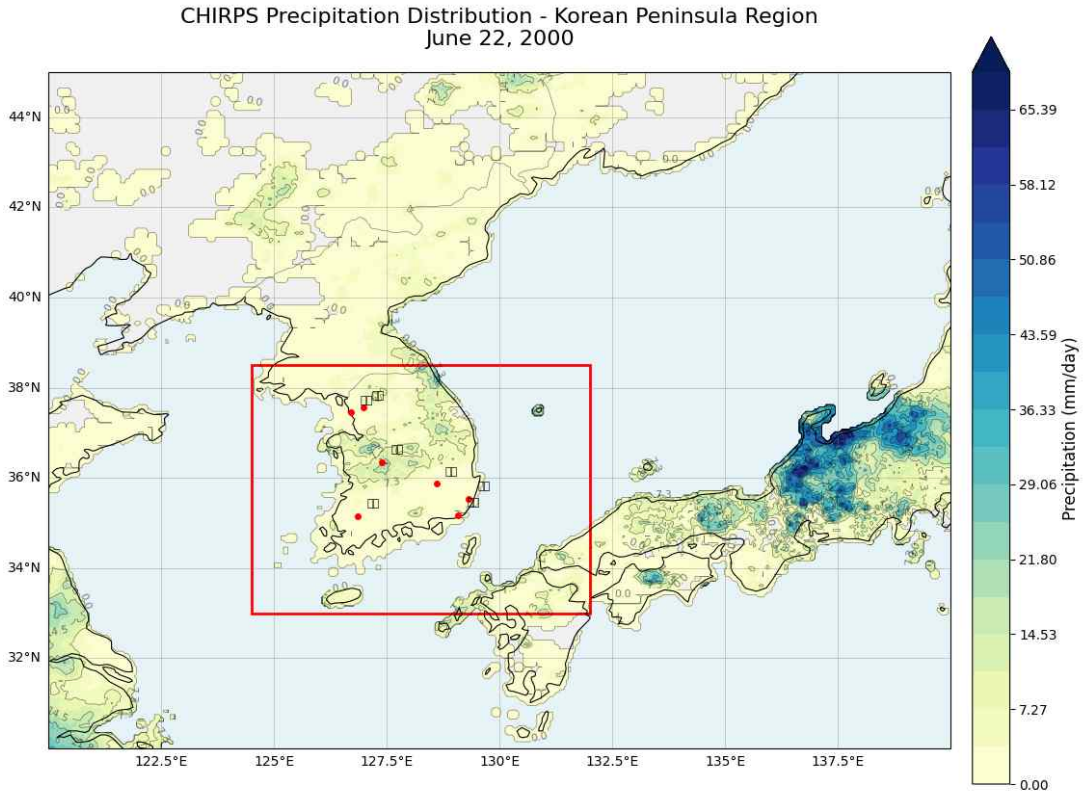


Figure 2.4. CHIRPS precipitation distribution in Korea peninsular at jun 22, 2000.

2.1.5. 지상관측자료

제주도는 동아시아 몬순 시스템의 길목에 위치하여 태풍, 장마전선, 그리고 겨울철 시베리아 기단의 변질 과정을 가장 먼저, 그리고 가장 강렬하게 겪는 지역이다. 특히, 겨울철 북서풍이 따뜻한 해수면을 통과하며 형성된 해양과 대기 기온차에 의한 대류운은 한라산의 지형적 강제 상승 효과와 결합하여 산간 지역에 폭설을 내리게 하는 반면, 풍하측인 서귀포 지역에서는 뽕 현상으로 인해 맑고 건조한 날씨가 나타나는 등 국지적 미기상 현상이 복잡한 기상 현상을 정밀하게 포착하고 분석하기 위해서는 고해상도의 관측 자료가 필수적이다. 현재 기상청은 제주도 전역에 종관기상관측장비(ASOS)와 방재기상관측장비(AWS)를 운영하고 있다(Figure 2.5). 학습데이터의 타겟변수로 자료를 입력하기 위하여 포인트 관측자료를 보간하여 격자화된 자료로 전처리하여 학습 및 검증자료로 이용하였다(Figure 2.5).

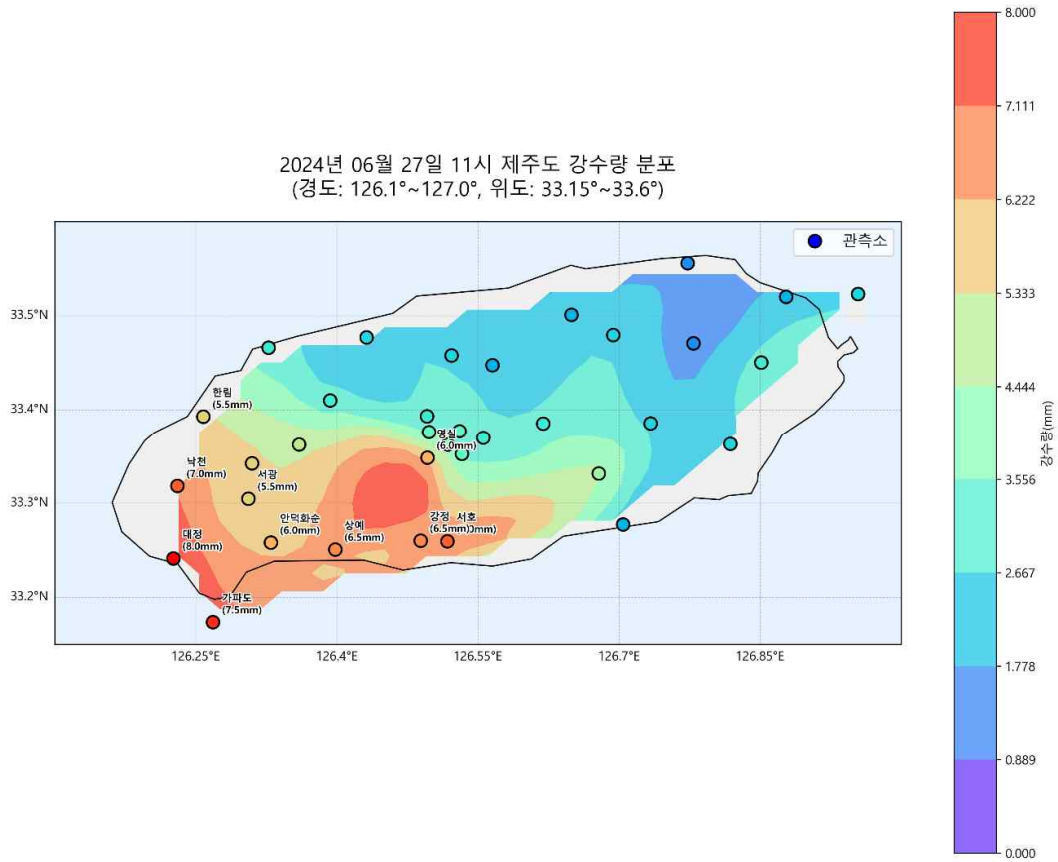


Figure 2.5. Locations of AWS, ASOS observation station in Jeju.

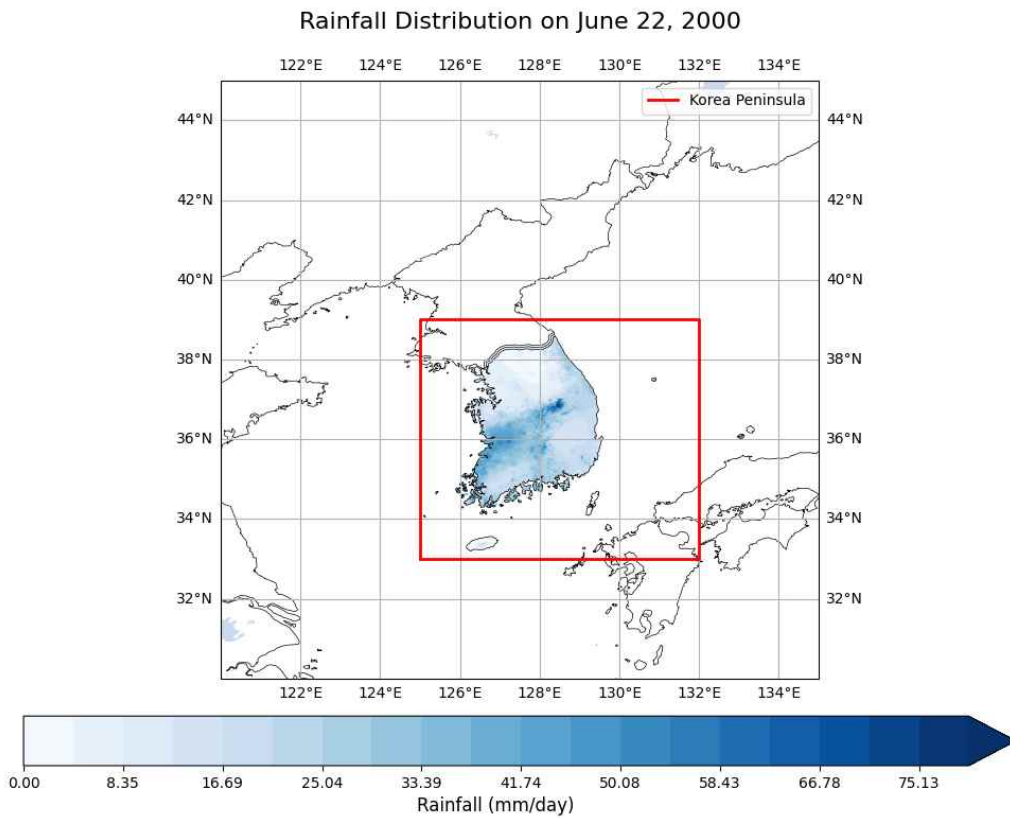


Figure 2.6. The rainfall of gridded ground observation stations.

2.1.6. 기계학습모델

원시 위성의 많은 경우에서의 과소추정하는 경향과 정확도 향상을 위하여 인공지능 모델 중의 하나인 기계 학습(Machine Learning)모델을 이용하여 고해상도 격자자료의 신뢰성과 정확도를 확보하고자 하였다. 특히, 복잡한 비선형성을 내포하고 있는 강수 자료의 경우에는 국소적인 패턴에 지나치게 적합되는 과적합(Overfitting) 현상을 보이거나, 반대로 데이터의 복잡한 구조를 충분히 학습하지 못하는 과소적합(Underfitting) 문제가 많기 때문에, 이러한 문제를 해결하기 위해 본 연구에서는 RandomForest와 XGBoost(eXtreme Gradient Boosting)를 사용하였다. 두 알고리즘은 앙상블 학습의 양대 산맥인 배깅(Bagging, Bootstrap Aggregating)과 부스팅(Boosting)을 각각 대표하는 기계학습 모델로서, 수많은 실증 연구에 성능이 증명되어 왔다.

Random Forest는 Leo Breiman(2001)에 의해 제안된 이래로, 모델의 분산을 획기적으로 감소시키는 능력과 하이퍼파라미터에 대한 강건성(Robustness) 덕분에 분류 및 회귀 문제의 표준적인 베이스라인 모델로 자리 잡았다. 반면, Chen과 Guestrin(2016)이 제안한 XGBoost는 기존 Gradient Boosting Machine(GBM)의 한계를 극복하기 위해 2차 테일러 근사와 정규화항을 도입하고, 시스템 레벨에서의 병렬 처리를 구현하여 속도와 정확도에서 좋은 성능을 보이는 알고리즘으로 본 연구에 기본 모델로 이용하였다.

2.1.7. 방법

본 연구의 방법론적 프레임워크는 이질적인 특성을 가진 다수의 위성 센서 데이터와 지상 관측 데이터를 융합하는데 기초한다. 입력 변수(Input Features)로 사용되는 4가지 주요 위성 강수 자료(GPM IMERG, CMORPH, PERSIANN, CHIRPS)와 타겟 변수(Target Variable)로 사용되는 지상 관측 자료(AWS)를 이용하여 인공지능 알고리즘을 산출하였다. 지상 관측 자료는 위성 강수 자료의 편의를 보정하고 최종 산출물의 정확도를 검증하기 위한 참값(Ground Truth)으로 이용하였다. 본 연구에서는 고밀도 관측망을 통해 수집되는 ASOS, AWS의 강수 데이터를 활용한다. AWS는 일반적으로 전도형 우량계(Tipping Bucket Rain Gauge) 방식을 채택하고 있다. 이는 유입된 빗물이 일정량(0.1mm, 0.5mm 등)에 도달하면 버킷이 전도되면서 전기적 신호를 발생시키는 원리이다. 이 방식은 높은 시간 해상도를 제공하지만, 강풍 시 빗방울이 입구로 들어가지 못하고 날리면서 발생하는 포착 손실(Wind-induced Catch Deficit), 버킷 내부의 잔류 물방울 증발에 의한 손실(Evaporation Loss), 그리고 매우 강한 강우 시 버킷의 전도 속도 한계로 인한 과소 추정(Undercatch) 등의 기계적 오차를 포함할 수 있다. 따라서 자료의 품질관리를 통한 전처리를 실시하였다. 음수(-) 값이나 센서의 최대 관측 한계를 초과하는 값(예: 1시간 강수량 > 200mm 등 지역 기후 특성을 고려한 임계값 설정)은 기계적 오류로 간주하여 즉시 결측(NaN) 처리하거나 제거하였다. 또한 인접한 관측소(Nearest Neighbors)들의 강수량과 비교하여 특정 관측소의 데이터가 공간적으로 예러값이 들어오면 이상치인지를 판단한다. 대상 관측소 주변의 AWS 값들을 이용하여 크리깅(Kriging)이나 역거리 가중법(IDW)으로 해당 지점의 예상 강수량을 추정하고, 실제 관측값과의 편차(Residual)가 허용 오차 범위를 벗어날 경우 신뢰할 수 없는 데이터로 분류하여 품질관리 하였다. 위성자료는 GPM IMERG version7은 이전 V06에 비해 알고리즘이 대폭 개선되었고, 자료를 크리깅 방법을 통해서 공간해상도를 0.01°로 보

간하였다. CMORPH, PERSIANN, CHIRPS 데이터들도 타겟변수인 지상관측자료와 같은 해상도로 보간하였다. 각각의 데이터 중에서 결측(NaN) 자료는 기계학습 모델(특히 Random Forest)은 결측치를 입력으로 허용하지 않는 경우가 많다. 따라서 본 연구에서는 시간적으로 연속된 데이터셋(Time Series)을 구축한 후, 입력 변수나 타겟 변수 중 하나라도 결측이 존재하는 타임스텝의 데이터 행(Row)을 전체 제거하는 방식을 채택한다. 이는 데이터의 무결성을 보장하기 위하여 전처리 하였다. XGBoost 모델의 경우 내부적으로 희소성(Sparsity)을 처리하는 알고리즘이 내장되어 있어 결측치를 정보의 부재가 아닌 하나의 특징으로 학습할 수 있으나, 정확한 비교 검증을 위해 동일한 기준으로 전처리하였다. 단순히 위성 강수량만을 입력으로 사용하는 것을 넘어, 모델이 강수의 물리적 메커니즘과 지역적 특성을 학습할 수 있도록 다양한 보조 변수를 특징(Feature)으로 추출하여 구성한다. 다중 위성 강수 GPM, CMORPH, PERSIANN, CHIRPS 4종의 강수량을 모두 입력으로 사용하여 각 산출물의 장점을 앙상블하였다. 지형 인자 (Topographic Factors)는 강수는 지형성 효과에 민감하므로, 고해상도 수치표고모델(DEM)로부터 추출한 고도 (Elevation), 경사(Slope), 향(Aspect) 정보를 입력 변수에 추가하였다. 계절성을 반영하기 위한 월(Month), 일(Day of year) 정보와 공간적 위치(위도, 경도)를 포함시켜 모델이 시공간적 패턴을 학습하도록 입력자료를 구성하였다. 전처리가 완료된 데이터셋은 'Data Splitting' 단계를 거쳐 훈련(Train), 검증(Validation), 테스트(Test) 세트로 분할되며, 이후 두 가지 강력한 앙상블 학습 알고리즘인 Random Forest와 XGBoost에 적용된다. 입력자료 데이터 분할은 모델의 일반화 성능을 평가하고 과적합(Overfitting)을 방지하기 위해 전체 데이터를 70%, 15%, 15%의 비율로 분할하였다. 학습자료(70%)는 모델의 파라미터를 학습시키는 데 사용되었고, 검증자료(15%)는 하이퍼파라미터 튜닝(Hyperparameter Tuning) 및 모델 선택(Model Selection) 과정에서 성능을 모니터링하는 데 사용하였다. 테스트 자료(15%)는 학습 및 튜닝에 전혀 관여하지 않은 독립적인 데이터로, 최종 모델의 성능을 객관적으로 평가하는 데 사용하였다. 강수 자료는 시간적 자기상관성(Autocorrelation)을 가지므로, 무작위 셔플링(Random Shuffling)보다는 시간 순서에 따른 분할(Chronological Split)이나 연도별 분할을 고려하여 고해상도 자료를 평가하였다(Figure 2.7).

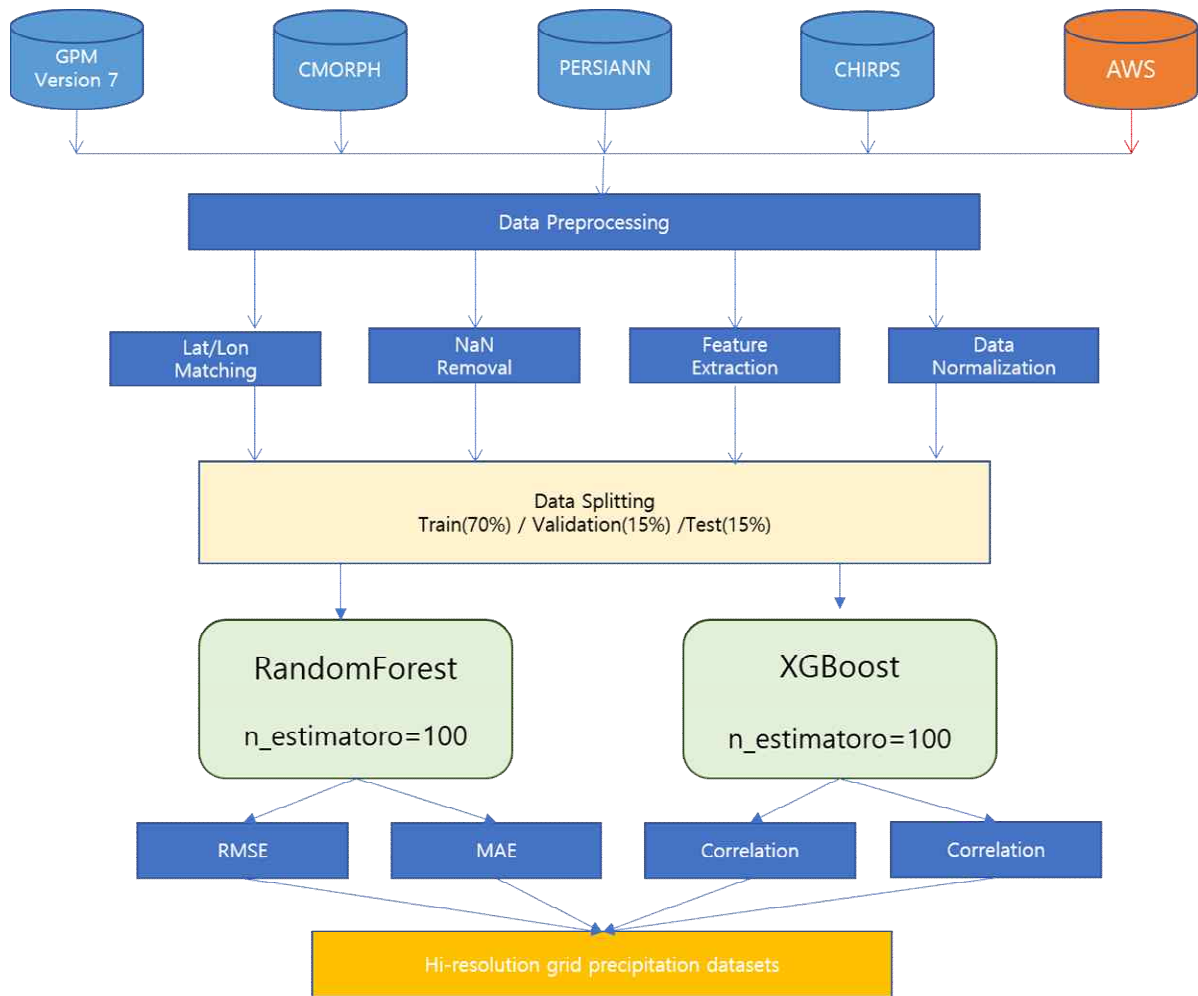


Figure 2.7. Flowchart of machine learning method by raw satellite precipitation products.

2.2. 다변수 상세화 기반기술 개발

2.2.1. 자료 및 연구 대상 지역

시범지역은 제주특별자치도 전역으로 설정하였다. 연구에 사용된 기상 관측자료는 제주지방기상청 관할의 지상 관측소(ASOS 4개 지점 : 제주(184), 고산(185), 성산(188), 서귀포(189), AWS 32개 지점 : 상예(328), 산천단(329), 대흘(330), 우도(725), 유수암(727), 와산(751), 서광(752), 어리목(753), 한림(779), 제주남원(780), 구좌(781), 성관악(782), 표선(792), 대정(793), 가파도(855), 제주김녕(861), 송당(862), 외도(863), 오등(865), 1)한라생태숲(866), 삼각봉(867), 사제비(868), 영실(869), 진달래밭(870), 윗세오름(871), 2)금악(880), 새별오름(883), 3)서호(884), 한남(885), 성산수산(892), 애월(893), 강정(980)) 총 36개 관측소에서 수집된 2020년 1월 1일부터 2024년 12월 31일까지의 일별 기온과 강수량을 사용하였다(Figure 2.1). 다만, 장기간 결측이 발생하여 통계적 신뢰성을 확보하기 어려운 일부 지점(한라생태숲, 금악, 서호)은 분석 시 제외하였다(KMA, 2025).




Figure 2.8. Locations of Meteorological Observation Stations in Jeju.

보조변수로는 국토지리정보원(NGII)에서 제공하는 90 m 해상도의 DEM을 기반으로 연구 해상도에 맞게 재가공한 1 km 격자 고도 자료를 구축하여 활용하였다(NGII, 2025)(Figure 2.2). 관측자료는 최근접 이웃 보간법(Nearest Neighbor Interpolation)을 이용해 단기 결측을 보완한 후, 각 관측지점의 위·경도와 고도 정보를 포함하는 공간보간 입력자료 형태로 재구성하였다.

격자 체계는 지리 좌표계(EPSG:4326)를 기반으로 제주도 전역(126.09° E ~ 127.01° E, 33.14° N ~ 33.61° N)을 포괄하도록 구축하였다. 목표 공간 해상도는 약 1 km로 설정하였으며, 이를 구현하기 위해 위도 방향은 1° 를 약 111.32 km로 적용하여 격자 간격을 산출하였다. 경

1) 한라생태숲(866): 2024년 4월 3일 이후 결측
 2) 금악(880): 2021년 5월 16일 이후 결측
 3) 서호(884): 2024년 10월 23일 이후 결측

도 방향의 경우, 위도 상승에 따라 경도 1°의 실제 거리가 줄어드는 특성을 반영하여 연구 지역의 평균 위도에서 위도 방향과 동일한 물리적 거리가 유지되도록 격자 간격을 보정하였다.

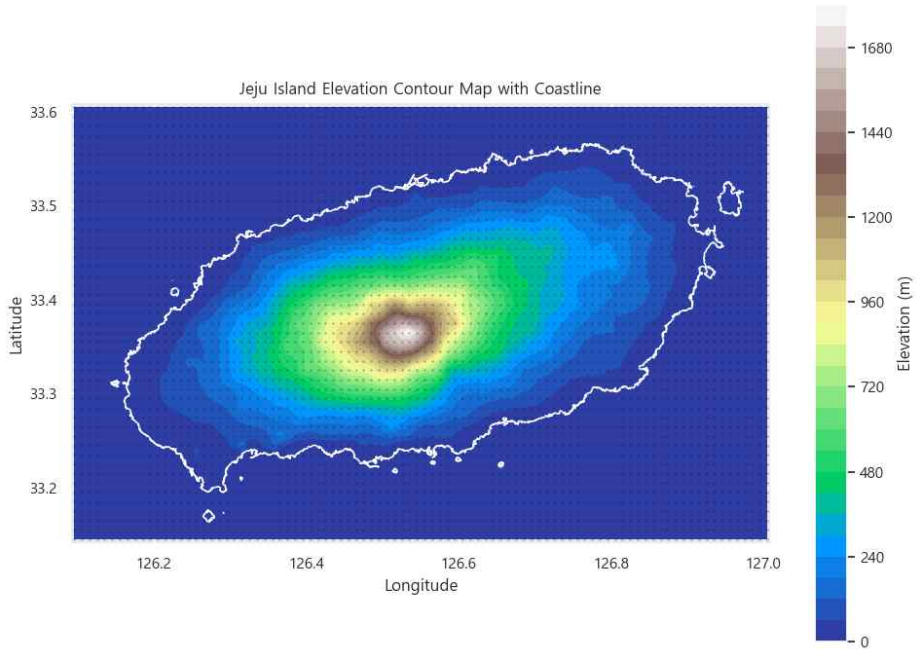


Figure 2.9. 1-km Grid Elevation (DEM) Distribution Map within Jeju.

2.2.2. 단변수 상세화 기법

2.2.2.1. Ordinary Kriging 기반 공간 상세화 모델

Ordinary Kriging(OK)은 통계적 공간보간법(geostatistical interpolation)의 대표적인 기법으로, 인접한 관측지점 간 값의 유사성이 크다는 공간적 자기상관을 기반으로 미지 지점의 값을 최적 추정하는 방법이다(Cressie, 1993). OK 기법의 가장 큰 특징은 전체 관측값에 대해 단일 전역 평균을 가정하지 않고 국소적으로 일정하지만 미지의 상수로 취급함으로써, 지역적 기후 특성이 뚜렷하게 나타나는 지역에서 보다 유연한 보간이 가능하다는 점이다. 이 연구에서 OK 기법은 기온과 강수량 각각에 대해 일별로 독립적인 모형을 구성하여, 일 단위 기후변수의 공간 분포 변동성을 정교하게 재현할 수 있도록 설계되었다.

OK 기법의 핵심은 관측 지점 간의 거리에 따른 공간적 상관성을 정량적으로 규명하는 베리오그램(Variogram) 분석에 있다. 반변동도(Semivariance, $\gamma(h)$)는 두 지점이 거리 h 만큼 떨어져 있을 때 해당 지점 간 속성값 $Z(s)$ 차이의 제곱을 이용해 거리별 평균 제곱 차를 나타내는 함수로 Eq. 2.1과 같이 정의된다(Isaaks and Srivastava, 1989).

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(s_i) - Z(s_i + h)]^2 \quad [2.3]$$

공간적 상관 구조를 모델링하기 위하여 이 연구에서는 공간 통계 실무에서 가장 보편적으로 활용되는 구형(Spherical) 베리오그램 모형을 채택하였다. 구형 모형은 일정 거리까지는 상관성이 감소하다가, 특정 거리 이상에서는 상관성이 사라지는 지리적 현상을 잘 반영하며 Eq. 2.2와 같다.

$$\gamma(h) = \begin{cases} C_0 + C \left[1.5 \left(\frac{h}{a} \right) - 0.5 \left(\frac{h}{a} \right)^3 \right], & h \leq a \\ C_0 + C, & h > a \end{cases} \quad [2.4]$$

여기서, C_0 (Nugget Effect)는 관측 오차 또는 가장 인접한 거리 미만에서 발생하는 미세한 국지적 변동을 의미한다. C (Partial Sill)는 구조적 변동성의 크기를 나타내며, 전체 실(Sill)에서 너겟 효과를 제외한 값이다. a (Range)는 공간적 상관성이 유지되는 유효 거리를 의미하며, 이 거리($h > a$)를 벗어나면 데이터 간의 상관성은 사라진다.

OK 기법은 미계측 지점 s_0 의 속성값을 주변에 위치한 n 개의 관측값 $Z(s_i)$ 의 선형 결합으로 추정하며 Eq. 2.3과 같다.

$$\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i) \quad [2.5]$$

여기서 λ_i 는 각 관측 지점에 부여되는 가중치(Weight)를 의미한다. OK 기법은 국지적인 평균(Local Mean)이 미지의 상수로 존재한다고 가정하므로, 추정량의 편향(Bias)을 제거하기 위해 가중치의 합이 1이 되도록 하는 Eq. 2.4과 같은 제약 조건을 적용한다.

$$\sum_{i=1}^n \lambda_i = 1 \quad [2.6]$$

이 조건은 추정 오차의 기댓값을 0으로 만듦으로써, 국소적인 평균 변화에도 불구하고 추정값이 통계적으로 편향되지 않도록 보장한다. 이 기법은 결정론적(Deterministic) 방법인 단순 거리 가중 역산(IDW, Inverse Distance Weighting)과 달리, 데이터가 가지는 고유의 공간적 상관 구조(Variogram)를 수식에 직접 반영한다는 점에서 차별화된다. OK 기법은 불편성 제약 조건 하에서 예측 오차 분산을 최소화하는 가중치 λ_i 를 산출한다. 위 과정을 통해 OK 기법은 통계적으로 최적 선형 불편 추정량(BLUE)을 제공한다. 즉, 물리적 거리가 동일하더라도 공간적 상관성이 높은 지점에 더 큰 가중치를 부여하는 방식이다. 이를 통해 지형이나 기류 등의 영향으로 형성되는 기후장의 비균질한 공간 패턴을 단순 거리 기반 보간보다 통계적으로 더 정교하게 재현할 수 있다.

2.2.2.2. Inverse Distance Weighting 기반 공간 상세화 모델

Inverse Distance Weighting(IDW)은 가장 널리 사용되는 결정론적(deterministic) 공간보간 기법으로, 미지 지점의 값이 주변 관측지점의 값에 의해 영향을 받는다는 가정하에 “거리(distance)”를 중심으로 보간을 수행한다(Shepard, 1968). IDW의 기본 원리는 예측지점과 가까운 관측지점일수록 더 큰 영향력을 갖는다는 개념으로, Kriging처럼 공간적 확률구조(variogram)를 추정하지 않고 거리 기반 가중치만으로 예측을 수행하는 점이 특징이다. 이러한 단순성과 계산 효율성 덕분에 IDW는 대규모 격자 계산에 적합하다(Lu and Wong, 2008).

IDW는 미계측 지점 s_0 의 값을 주변 관측 지점 s_i 들의 거리에 반비례하는 가중 선형 결합으로 추정하는 결정론적 보간 기법이다. 예측 지점 s_0 와 관측 지점 s_i 간의 거리 d_i 에 기반한 정규화된 가중치(Normalized Weight, w_i)는 Eq. 2.5와 같이 산출된다.

$$w_i = \frac{d_i^{-p}}{\sum_{j=1}^n d_j^{-p}} = \frac{1/d_i^p}{\sum_{j=1}^n (1/d_j^p)} \quad [2.7]$$

여기서, d_i 는 예측 지점(s_0)과 i 번째 관측 지점(s_i) 사이의 유클리드 거리이다. p 는 거리에 따른 가중치 감쇠율을 결정하는 지수 파라미터이다. w_i 는 i 번째 관측값에 부여되는 가중치로, 예측의 편향을 방지하기 위해 총합이 1이 되도록 정규화($\sum w_i = 1$)된다. IDW 기법에서 지수 p 는 거리가 멀어질수록 관측값의 영향력이 얼마나 빠르게 감소하는지를 결정하는 핵심 모수이다. p 값이 커질수록 근거리 관측값에 지배적인 가중치가 부여되어 국지적인 패턴이 강조되는 반면, 값이 작을수록 전체적인 평활화(Smoothing) 효과가 나타난다. 이 연구에서는 수문 기상 분야에서 가장 보편적으로 채택되며 물리적 거리에 따른 영향력 감소를 합리적으로 반영하는 역사승(Inverse Square) 모델인 $p=2$ 를 적용하였다.

IDW 기법을 이용한 미계측 지점 s_0 에서의 예측값 $\hat{Z}(s_0)$ 는 산출된 가중치 w_i 와 주변 관측값 $Z(s_i)$ 의 선형 결합으로 Eq. 2.6과 같이 정의된다.

$$\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i) \quad [2.8]$$

이 방식은 확률론적 모형인 Kriging과 달리, 결정론적 접근 방식을 취한다. 수학적 예측 오차 분산의 최소화를 보장하지는 않으나, 관측망이 조밀한 지역에서는 연산 속도가 빠르고 관측값의 경향성을 직관적으로 보존한다는 장점이 있다. 특히 관측 지점과의 거리가 멀어질수록 그 영향력은 거리의 제곱에 반비례하여 급격히 감쇠하는 특성을 갖는다.

2.2.2.3. Cubic Spline Interpolation 기반 공간 상세화 모델

Cubic Spline 보간은 관측 지점들을 단순 선형(Linear)으로 연결하는 대신, 각 구간을 3차 다항식(Cubic Polynomial)으로 연결하여 전체적으로 미분 가능하고 부드러운 곡선 또는 곡면을 생성하는 기법이다. 1차원 공간상의 두 관측 지점 구간 $[x_i, x_{i+1}]$ 에서 정의되는 Cubic Spline 함수 $S_i(x)$ 의 일반형은 Eq. 2.7과 같다(Burden and Faires, 2010).

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3 \quad [2.9]$$

여기서 각 구간의 계수 a_i, b_i, c_i, d_i 는 인접한 구간의 함수들이 접점에서 다음의 연속성 조건을 만족하도록 결정된다. 함수값의 연속성(Continuity of function values), 1차 도함수의 연속성(Continuity of first derivative), 2차 도함수의 연속성(Continuity of second derivative). 이러한 수학적 특성으로 인해 Cubic Spline은 데이터의 국지적 변화율과 곡률을 반영한 최적의 이음매 없는(Seamless) 연결 곡선을 구성한다. 이 연구에서는 기상 관측소와 같이 불규칙하게 분포된 2차원 위·경도 데이터를 격자화하였으며 2차원 Cubic Spline 보간은 1차원 이론을 평면으로 확장하여, 삼각 분할(Delaunary Triangulation)과 구획적 곡면 구성을 거쳐 곡면 $S(x, y)$ 를 구성한다. 최종적으로 임의의 격자점 (x_0, y_0) 에서의 예측값 \hat{Z} 는 구성된 곡면 함수를 통해 Eq. 2.8과 같이 산출된다.

$$\hat{Z}(x_0, y_0) = S(x_0, y_0) \quad [2.10]$$

Cubic Spline은 Kriging과 같은 통계적 확률 모형은 아니지만, 기하학적 부드러움을 최우선으로 고려하는 결정론적 방법이다. 관측값 주변의 곡률을 반영하므로, IDW(역거리 가중법)에 비해 자연스러운 공간 변동성을 재현하며, 기온이나 평균 강수량과 같이 공간적으로 연속성이 강한 기후 변수 추정에 유리한 반면 데이터 값의 변화가 극심한 구간에서는 곡선이 실제 범위를 벗어나 과도하게 요동치는 오버슈트(Overshoot) 현상이 발생할 수 있으므로 적용 시 주의가 필요하다.

Table 2.1. Comparison of the Advantages and Limitations of Spatial Interpolation Methods.

Spatial Interpolation Method	Advantages	Disadvantages	Suitable Use Cases
Ordinary Kriging (OK)	High accuracy Allows error estimation	Computationally complex	Climate data Terrain data
Inverse Distance Weighting (IDW)	Fast and intuitive	Does not reflect spatial patterns	Basic spatial interpolation
Cubic Spline Interpolation (CSI)	Smooth and continuous	Sensitive to noise	Time series Curvilinear data

2.2.3. 다변수 상세화 기법(Cokriging 기반)

Cokriging (공동 크리깅)은 단일 변수의 자기상관성만을 고려하는 Ordinary Kriging을 확장한 다변량 지구통계 기법이다(Isaaks and Srivastava, 1989). 이 방법은 예측 대상인 주요 변수(Primary Variable)와 공간적·물리적으로 밀접한 상관관계를 갖는 보조 변수(Secondary Variable)의 교차상관 정보를 모델링에 반영함으로써, 관측 공백 지역에서의 예측 불확실성을 획기적으로 개선한다. 이 연구에서는 제주도의 복잡한 지형적 특성을 반영하기 위해 주요 변수로 지상 관측소의 기온 및 강수량을 설정하고 보조 변수로 1 km 해상도의 수치표고모델(DEM)을 설정하였다.

제주도는 한라산을 중심으로 해발고도에 따른 기후 변화가 뚜렷한 지역이다. 따라서 고도를 보조 변수로 활용함으로써, 대류권의 기온 감률 효과와 산악 지형에 의한 강제 상승 효과를 상세화 모델에 직접 반영하였다. 이는 단순 보간법이 포착하기 어려운 산간 및 중산간 지역의 국지적 기후 특성을 재현하는 데 핵심적인 역할을 수행한다.

Cokriging은 주요 변수와 보조 변수 간의 복합적인 공간 구조를 규명하기 위해 자기 베리오그램(Auto-variogram)과 교차 베리오그램(Cross-variogram)을 동시에 고려한다. 이때, 모든 베리오그램 행렬이 수학적으로 양의 정부호성을 만족하기 위해 선형 공공분산 모형(Linear Model of Coregionalization, LMC)을 적용하였다(Journel and Huijbregts, 1978; Wackernagel, 2003). LMC는 관측된 모든 변수의 베리오그램 $\gamma_{ij}(h)$ 를 동일한 기본 구조(예: Nugget, Spherical 등) $g^{(k)}(h)$ 의 선형 결합으로 표현하며, Eq. 2.10와 같다.

$$\gamma_{ij}(h) = \sum_{k=1}^K b_{ij}^{(k)} g^{(k)}(h) \quad [2.11]$$

여기서 $b_{ij}^{(k)}$ 는 각 구조에 대한 변수 간의 공변동 기여도를 나타낸다. 본 연구에서는 LMC 적합(Fitting) 과정을 통해 고도와 기상 변수 간의 상관 구조를 수학적으로 정합성 있게 모델링하였으며, 이를 통해 Cokriging 연립방정식 해의 안정성을 확보하였다.

대용량 기후 데이터 처리의 효율성과 지구통계 알고리즘의 정밀도를 동시에 확보하기 위해, 이 연구에서는 Python과 R을 연동한 하이브리드 분석 환경을 구축하였다.

구체적인 구현 절차는 다음과 같다.

1. 데이터 전처리(Python): 1 km 격자 기반의 DEM 생성 및 관측소 위치 매칭, 시계열 데이터셋 구성을 수행한다.
2. 지구통계 연산(R 연동): rpy2 라이브러리를 통해 전처리된 데이터를 R 환경으로 전송하고, 지구통계 전용 패키지인 gstat을 호출하여 LMC 적합 및 Cokriging 예측을 수행한다. R의 gstat 패키지는 다변량 베리오그램 모델링에 있어 타 라이브러리 대비 월등한 안정성과 기능을 제공한다.
3. 결과 통합 및 검증(Python): 산출된 예측값과 크리깅 분산을 다시 Python 환경으로 회

수하여 저장하고, 교차 검증(LOOCV, Leave-One-Out Cross Validation)을 통해 RMSE, MAE 등의 정량적 성능 지표를 산출한다.

2.2.3.1. Ordinary Cokriging 기반 공간 상세화 모델

Ordinary Cokriging (OCOK)은 주요 변수와 상관성이 높은 다수의 보조 변수를 동시에 활용하여 예측 정확도를 극대화하는 다변량 지구통계 기법이다. 이 연구에서는 기상 변수 간의 물리적 상호작용과 제주도의 지형적 특성을 모두 반영하기 위해, 기온(Temperature) 모델링 시 보조 변수를 이원화(DEM, 강수량)하여 구성하였다(Ishida and Kawashima, 1993).

- 주요 변수 (Z_1): 기온 (Temperature)
- 보조 변수 1 (Z_2): 고도 (DEM) → 고도 상승에 따른 기온 하강(Lapse Rate) 반영
- 보조 변수 2 (Z_3): 강수량 (Precipitation) → 강우 시 수반되는 증발 냉각 및 일사 차단에 의한 기온 저하 효과 반영

이는 기존의 고도 의존적 경향성뿐만 아니라, 강수 유무 및 강도에 따라 변화하는 기온의 미세한 변동성까지 포착하기 위한 고도화된 전략이다. 또한, 강수량(Precipitation) 모델링 시 보조 변수를 이원화(DEM, 기온)하여 구성하였다.

두 개의 보조 변수를 사용하는 경우, 예측 지점 s_0 에서의 기온 예측값 $\hat{Z}_1(s_0)$ 는 주요 변수(기온)와 두 보조 변수(DEM, 강수량) 관측값의 선형 결합으로 Eq. 2.12와 같이 확장된다.

$$\hat{Z}_1(s_0) = \sum_{i=1}^{n_1} \lambda_i Z_1(s_i) + \sum_{j=1}^{n_2} \mu_{1,j} Z_2(s_j) + \sum_{k=1}^{n_3} \mu_{2,k} Z_3(s_k) \quad [2.12]$$

여기서 λ, μ_1, μ_2 는 각각 기온, DEM, 강수량 관측값에 부여되는 가중치이다. 서로 다른 물리적 단위를 가진 변수들의 편향을 제거하고 주요 변수(기온)의 평균을 보존하기 위해, 가중치는 다음의 Eq. 2.13과 같이 확장된 제약조건을 만족해야 한다.

$$\sum_{i=1}^{n_1} \lambda_i = 1, \quad \sum_{j=1}^{n_2} \mu_{1,j} = 0, \quad \sum_{k=1}^{n_3} \mu_{2,k} = 0 \quad [2.13]$$

가중치 산출을 위한 크리깅 시스템 역시 3개 변수 간의 자기 상관성과 변수 쌍 간의 교차 상관성을 모두 포함하는 형태로 확장된다. 이 연구에서는 이러한 복잡한 다변량 구조가 수학적 안정성(양의 정부호성)을 유지할 수 있도록, 선형 공공분산 모형(LMC)을 적용하여 3개 변수(T, DEM, P) 간의 모든 베리오그램을 통합 모델링하였다. 이를 통해 “고도가 높고 비가 오는 지역의 기온이 더 낮다”는 복합적인 기후 물리 기작을 통계적으로 엄밀하게 구현하였다.

일반적으로 기온 상세화에는 고도(DEM)만이 보조 변수로 사용되나, 제주도과 같이 국지성 호우와 해무가 잦은 지역에서는 동일 고도라 하더라도 강수 여부에 따라 기온 편차가 크게 발

생한다. 따라서 이 연구에서는 강수량을 제2의 보조 변수로 추가하여, 강우 냉각(Rain cooling) 효과에 의한 기온 하강 패턴까지 상세화 모델에 반영하였다.

2.2.3.2. Simple Cokriging 기반 공간 상세화 모델

Simple Cokriging(SCOK)은 다변수 공간 보간 기법 중 가장 이론적으로 간결한 형태이다. Ordinary Cokriging(OCOK)이 각 국소 지역마다 평균이 미지의 상수라고 가정하는 것과 달리, SCOK은 연구 지역 전체에 대해 사전에 알고 있는 전역적 평균(Known Stationary Mean)을 적용한다(Goovaerts, 1997). SCOK은 전역 평균을 고정함으로써 공분산 구조의 추정이 단순해지고, 특히 관측점이 부족하거나 분산이 큰 날(일 변동이 심한 날)의 계산 안정성이 향상된다(Wackernagel, 2003). 이 연구에서는 기온 및 강수량 자료가 장기간의 관측을 통해 신뢰할 수 있는 평균값을 보유하고 있다는 점, 그리고 전역적인 경향성이 뚜렷하다는 점에 착안하여 SCOK을 OCOK과 병행 적용하였다. 이는 국소적인 평균 변동에 민감한 OCOK의 과적합(Overfitting) 가능성을 보완하고, 모형의 통계적 안정성을 확보하기 위함이다.

SCOK에서 예측 지점 s_0 의 주요 변수 예측값 $\hat{Z}_1(s_0)$ 는 각 변수의 전역 평균(m)을 기준으로 한 잔차(Residual)의 선형 결합으로 Eq. 2.14와 같이 표현된다.

$$\hat{Z}_1(s_0) = m_1 + \sum_{i=1}^{n_1} \lambda_i [Z_1(s_i) - m_1] + \sum_{j=1}^{n_2} \mu_j [Z_2(s_j) - m_2] \quad [2.14]$$

여기서 m_1 , m_2 는 주요 변수(기온/강수량)와 보조 변수(DEM)의 사전 정의된 전역 평균을 나타내며, $Z(s) - m$ 은 각 관측 지점에서의 평균에 대한 편차를, λ_i , μ_j 는 공간적 상관성에 기반한 크리깅 가중치를 나타낸다. SCOK의 가장 큰 특징은 가중치 합이 제약조건이 존재하지 않는다는 점으로($\sum \lambda + \sum \mu \neq 1$) 이는 이미 알고 있는 참값(전역 평균)을 모델에 주입함으로써 추정량의 불편성이 자연스럽게 만족되기 때문이다. 따라서 라그랑주 승수(Lagrange Multiplier)가 불필요하며, 이는 가중치 산출 과정에서의 수치적 불안정성을 줄이는 효과를 가져온다.

2.2.3.3. Universal Cokriging 기반 공간 상세화 모델

Universal Cokriging(UCOK)은 데이터가 공간상에서 일정한 평균을 갖지 않고, 특정 방향이나 지형에 따라 체계적으로 변화하는 추세(Trend, Drift)를 가질 때 적용하는 고급 다변수 지구 통계 기법이다(Wackernagel, 2003). 이 연구 대상지인 제주도는 고도가 높아질수록 기온이 낮아지고(고도 감률), 해안에서 내륙으로 갈수록 강수량이 변하는 뚜렷한 비정상성(Non-stationarity)을 보인다. 이에 연구에서는 기후 변수의 공간 변동을 ① 결정론적 대규모 추세(Trend)와 ② 확률론적 잔차(Residual)의 합으로 분해하여 모델링하는 UCOK를 적용하였다. 이는 OCOK나 SCOK가 포착하기 힘든 광역적인 공간 구조를 명시적으로 반영할 수 있다는 장점이 있다.

UCOK의 핵심은 기온과 강수량의 기대값(평균) $m(s)$ 가 위치의 함수로 표현된다는 점이다. 이 연구에서는 위도(lat), 경도(lon), 고도($elev$)를 설명변수로 하는 다중 선형 회귀식을 Eq. 2.15와 같이 설정하였다(Hudson and Wackernagel, 1994).

$$m(s) = \beta_0 + \beta_1 \cdot lon(s) + \beta_2 \cdot lat(s) + \beta_3 \cdot elev(s) \quad [2.15]$$

이 모형은 고도 증가에 따른 기온 하강, 위·경도에 따른 지리적 기후 편차 등을 물리적으로 설명한다. UCOK는 이 추세 성분을 제외한 잔차(Residual, $R(s) = Z(s) - m(s)$)에 대해 공간적 상관성을 분석함으로써, 추세에 의해 설명되지 않는 국지적 변동성까지 정밀하게 보정한다. 예측 지점 s_0 에서의 주요 변수 예측값 $\hat{Z}_1(s_0)$ 는 수식적으로 추세 성분과 잔차 성분의 최적 선형 결합으로 Eq. 2.16과 같이 도출된다.

$$\hat{Z}_1(s_0) = \sum_{i=1}^{n_1} \lambda_i Z_1(s_i) + \sum_{j=1}^{n_2} \mu_j Z_2(s_j) \quad [2.16]$$

이때, 가중치 λ 와 μ 를 산출하는 UCOK 시스템은 OCOK보다 복잡한 제약조건을 갖는다. 추세 모형의 계수(β_k)가 미지수이므로, 추정량이 편향되지 않도록 각 기저 함수(Basis function: 상수항, lat , lon , $elev$)에 대응하는 추가적인 라그랑주 승수 제약조건을 만족해야 한다. 즉, UCOK는 단순히 추세를 제거하고 끝나는 것이 아니라, 추세가 존재함에도 불구하고 편향되지 않은 최적의 가중치를 수학적으로 한 번에 도출하는 방식을 취한다.

이 연구에서의 실제 구현은 다음의 절차를 따랐다.

- 추세 정의: gstat 패키지의 모형식 설정 단계에서 $temperature \sim lon + lat + elev$ 와 같이 외부 표류(External Drift) 항을 명시하였다.
- 잔차 베리오그램 산출: 관측값에서 선형 추세를 제거한 잔차를 대상으로 다변량 베리오그램(자기 및 교차 베리오그램)을 계산하고 LMC를 적합하였다. 이는 추세에 의한 과대 변동성을 배제하고 순수한 공간 상관 구조만을 추출하기 위함이다.
- 예측 수행: 도출된 잔차 베리오그램과 추세 모형을 결합하여 최종적으로 제주도 전역의 기후 격자값을 산출하였다.

이러한 UCOK 접근 방식은 고도와 지형 효과가 지배적인 제주도의 기후 특성을 합리적으로 모사할 수 있는 방법론이다.

2.3. 기후변화 전망자료의 활용성 증대를 위한 AI 기반 상세화 기술 개발

2.3.1. 연구자료 및 학습자료 구축

연구자료는 유럽중기예보센터(ECMWF, The European Centre for Medium-Range Weather Forecasts)에서 제공하는 ERA-5 (ECMWF Reanalysis v5) 자료와 USGS (U.S. Geological Survey) 와 NGA (National Geospatial-Intelligence Agency)가 제공하는 GMTED 2010 (Global Multi-resolution Terrain Elevation Data)를 이용하였다(Table 2.1). 지형자료(DEM, digital elevation model)는 기온자료의 보조변수로서 사용되었다.

Table 2.2. Summary of study data (C3S CDS, 2023).

Provider name	Dataset name	Variable name	Data period	Spatial Resolution
ECMWF	ECMWF ERA-5	T2M	1979 - 2024	0.25 degree
USGS and NGA	GMTED 2010	DEM		7.5 arc-seconds

기온자료는 1979년부터 2024년까지 ERA-5 T2M (2-meter air temperature) 4시간 자료를 일 단위 자료로 변환하였다. T2M 자료의 온도 단위가 kevin (K)으로 되어 있어서 Eq. 2.17을 이용하여 섭씨 온도(celsius temperature)로 변환하여 자료를 구축하였다. 일 단위와 섭씨 온도로 변환된 자료의 예제는 Figure 2.10와 같다.

$$Temperature (^{\circ}C) = Temperature (K) - 273.15 \quad [2.17]$$

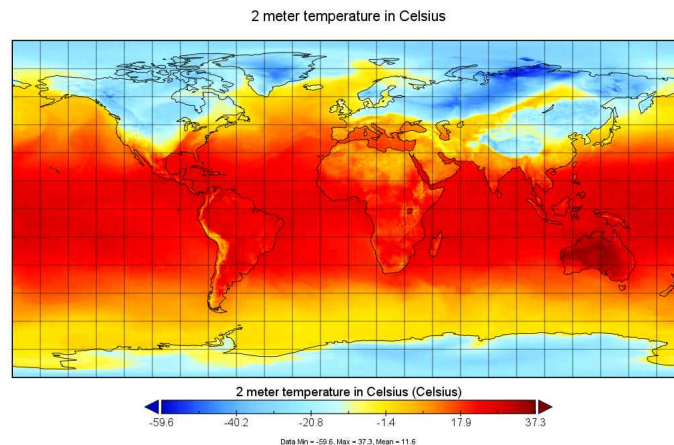


Figure 2.10. Example of ERA-5 T2M daily data.

GMTED 2010 자료는 7.5 (약 250 미터), 15 (약 500 미터), 30 (약 1 킬로미터) arc-seconds 의 공간해상도로 breakline emphasis (BE), systematic subsample (DS), 그리고 median (MD), minimum (MI), mean (MN), maximum (MX), standard deviation (SD) 통계기법을 이용하여 공간 보간된 자료를 제공한다. GMTED2010 자료는 공간보간법에 따라 표현되는 고도의 최저/최고값 이 다르기 때문에, 이 연구에서는 일반적인 평균(mean) 기법에 따라 생산된 7.5 arc-seconds (약 250 미터) 자료를 이용하였다(Figure 2.11).

Table 2.3. Summary of GMTED 2010 DEM data (Danielson and Gesch, 2011).

Dataset name	Interpolation method	Spatial Resolution
GMTED 2010	Breakline Emphasis (BE)	7.5, 15, and 30 arc-seconds
	Systematic Subsample (DS)	
	Median Statistic (MD)	
	Minimum Statistic (MI)	
	Mean Statistic (MN)	
	Maximum Statistic (MX)	
	Standard Dev. Statistic (SD)	

ERA-5 T2M (0.25 degree)와 GMTED 2010 (7.5 arc-seconds) 자료를 기초로 일반적으로 딥 러닝 모델에서 많이 사용되는 2배(0.5 degree), 4배(1.0 degree), 8배(2.0 degree) 인공지능 모델 학습자료를 구축하였다.

인공지능 기반 기후자료 상세화 모델 구축을 위한 학습자료 구축은 2 단계로 구성된다 (Figure 2.12). 첫 번째 단계는 기준 해상도를 구축하려는 모델의 배수(scale)에 맞춰 upsampling 을 통해 저해상도로 변환한다. 두 번째 단계는 공간해상도를 기준 해상도와 맞추기 위해 downsampling을 통해 고해상도와 같은 배열 크기로 변환한다. 보조변수 DEM 자료는 고해상도 자료와 같은 공간 해상도로 리샘플링하여 변환하였다. DEM 자료의 리샘플링은 오픈소스 소프트웨어인 QGIS 프로그램으로 평균(average) 보간법을 이용하여 자료를 구축하였다. 학습자료는 한반도를 포함한 동아시아지역을 대상으로 저해상도 자료 Step1과 Step2, 고해상도 DEM 자료를 1 패치(patch) 단위로 묶어서 구축하였다(Figure 2.13, 2.14).

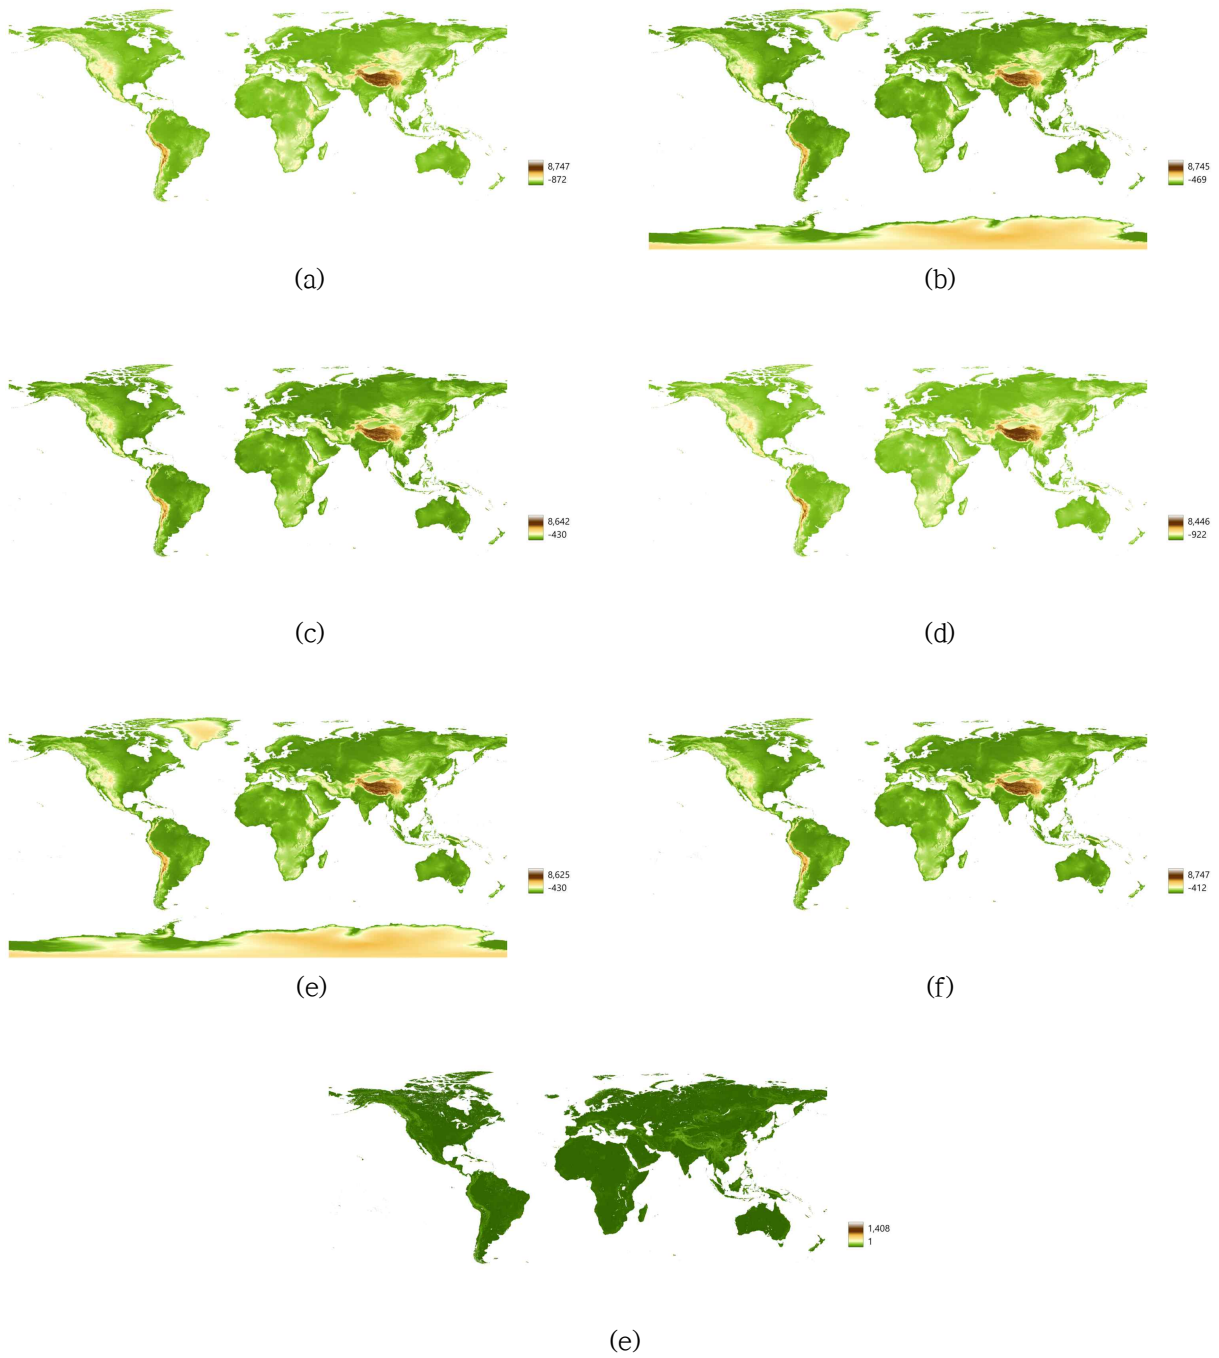


Figure 2.11. GMTED 2010 (30 arc-seconds) global elevation dataset: (a) Breakline Emphasis (BE), (b) Systematic Subsample (DS), (c) Median Statistic (MD), (d) Minimum Statistic (MI), (e) Mean Statistic (MN), (f) Maximum Statistic (MX), (g) Standard Dev. Statistic (SD).

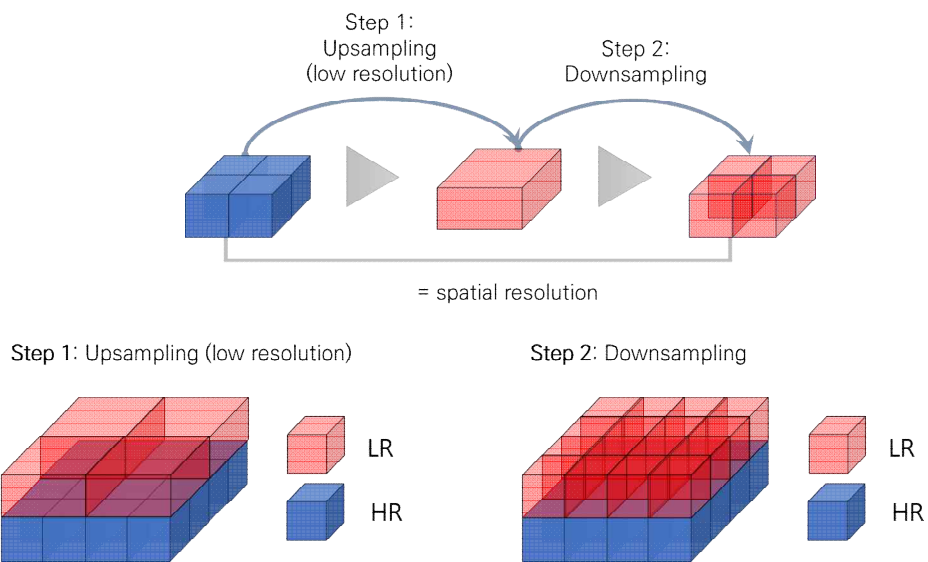


Figure 2.12. Schematic overview of the dataset generation process for AI-based climate downscaling.




Figure 2.13. Structure of 1 patch of the dataset.




Figure 2.14. Example of the 1 patch of the dataset.

2.3.3. 인공지능 기반 상세화 모델 설계

딥러닝 기반의 이미지 상세화 연구는 ill-posed problem을 다루는 분야로, 1개의 y값이 무수히 많은 x값을 가질 수 있다. 이미지 상세화 연구에서 중요한 것은 최고해를 찾는 것이 아니라 풀고자 하는 작업(task)에 가장 적합한 최적해를 찾는 것이다. 딥러닝 분야에서는 딥러닝을 이용한 최초의 SR (super resolution) 모델인 SRCNN (super-resolution convolutional neural network)를 시작으로 SRCNN (Dong et al., 2015)을 개선한 FSRCNN, ESPCN 등이 있다(Dong et al., 2016; Shi et al., 2016). 네트워크의 깊이를 늘린 VDSR (Very Deep Super-Resolution), ResNet에서 사용한 잔차 블록(residual block)을 활용한 EDSR (Enhanced Deep Super-Resolution) 모델이 있다(Kim et al., 2016; He et al., 2016; Lim et al., 2017). GAN (Generative Adversarial Network)을 기반으로 하는 SRGAN (Super-Resolution GAN), ESRGAN (Enhanced SRGAN)이 있으며(Ledig et al., 2017; Wang et al., 2018), ChatGPT를 개발하는데 기여한 트랜스포머(transformer)를 기반으로 한 SwinIR, HAT (Hybrid Attention Transformer) 등도 있다(Liang et al., 2021; Chen et al., 2023). 최근에는 Diffusion Model을 기반으로 하는 SR3 (Image Super-Resolution via Iterative Refinement) 등도 나왔다(Saharia, et al. 2022).

이 연구에서는 다양한 이미지 상세화 모델 중에서 잔차 블록을 적용한 EDSR (Enhanced Deep Super-Resolution)을 기초로 모델을 설계하였다. 모델 설계과정에서 데이터셋 구축방법, 입출력자료 구조, 보조자료 사용 등 다양한 조건을 고려하여 테스트하고 비교 평가하기 위해 모델의 구조가 쉬우면서도 성능이 좋은 잔차 블록이 적용된 EDSR 모델을 이용하였다. CNN 기반의 EDSR 모델을 이용하였다. EDSR 모델은 Figure 2.15와 같이 ResNet의 잔차 블록에서 batch normalization (BN)과 addition 후의 ReLU 활성화 함수(activation) 제거하여, GPU 메모리 사용량을 줄이고 유연성을 증가시켰다(Lim et al., 2017). EDSR를 기초로 데이터 증강 기법을 적용한 EDSR+, multi scale을 적용한 multi-scale enhanced deep residual (MDSR) 등도 제안하였다.

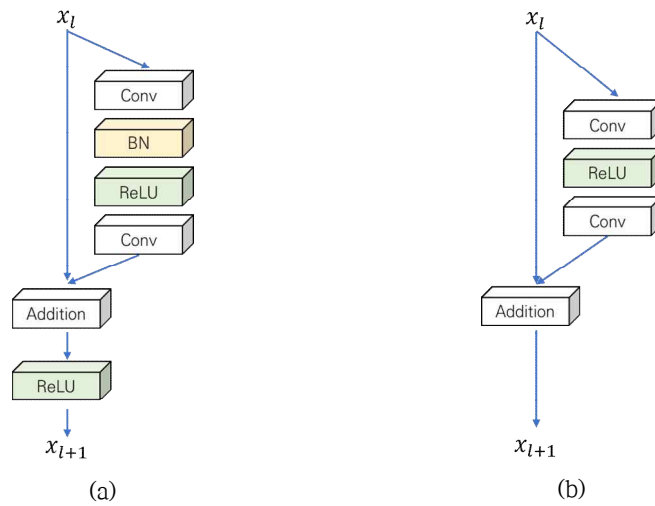


Figure 2.15. Comparison of residual blocks: (a) Resnet, (b) EDSR.

이 연구에서는 EDSR 모델을 기초로 상세화 배율에 따라 저해상도 자료(Step 1)와 고해상도 자료와 격자 크기가 같은 저해상도 자료(Step 2), 고해상도 자료와 같은 격자 크기의 보조변수(고해상도 DEM) 자료를 고려하여 CASE OLR (only ERA-5 low-resolution), CASE D, CASE DU, CASE DUR, CASE UD 등 총 5가지 모델을 설계하였다. 입력자료의 배열 구조는 batch, channel, height, weight이다.

CASE OLR은 저해상도 ERA-5 자료만을 이용하여 상세화하는 모델로 보조변수 DEM 자료 없이 입력자료는 ERA-5 저해상도 Step 2 자료만을 이용하여 학습하도록 설계하였다(Figure 2.16). CASE D는 CASE OLR 모델에 보조변수 DEM 자료를 입력자료와 함께 ERA-5 저해상도 Step 2 자료를 이용한다. 두 자료는 같은 패치(patch)를 기준으로 channel 0 (ERA-5 LR Step 2), 1 (DEM HR) 순서대로 입력된다(Figure 2.17).




Figure 2.16. EDSR-based downscaling model: CASE OLR.




Figure 2.17. EDSR-based downscaling model: CASE D.

CASE DU는 ERA-5 저해상도 Step 1 자료(ERA-5 LR Step 1)와 고해상도 DEM 자료(DEM HR)를 입력자료로 이용하며 다른 모델과 다른 점은 두 입력자료가 같은 네트워크로 학습한다. 저해상도 자료와 고해상도 자료가 같은 네트워크 학습을 통해 bias, weights 업데이트와 공유하며, 고해상도 자료의 풍부한 수용 영역(receptive field) 정보에서 학습된 정보를 통해 저해상도 자료도 풍부한 수용 영역 정보 생성이 가능한 장점이 있다. 학습자료의 Step 1 자료는 고해상도 자료와 배열 크기가 다르므로 upsample 구간을 이용한다(Figure 2.18).

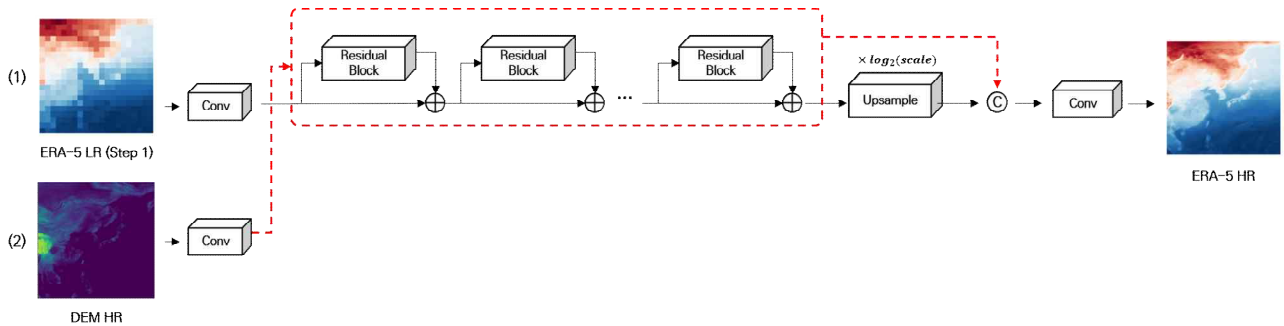


Figure 2.18. EDSR-based downscaling model: CASE DU.

CASE DUR은 CASE DU에서 공유하는 네트워크를 분리하여 각자 다른 네트워크를 통해 학습하도록 하였다(Figure 2.19). 마지막으로 CASE UD는 저해상도 ERA-5 자료 Step 1 자료를 이용하여 우선 학습하고 상세화 전 단계에서 보조변수 DEM 자료를 추가하여 고해상도 ERA-5 자료를 예측하는데 DEM 자료가 가이드(guide) 역할을 하도록 설계하였다(Figure 2.20).

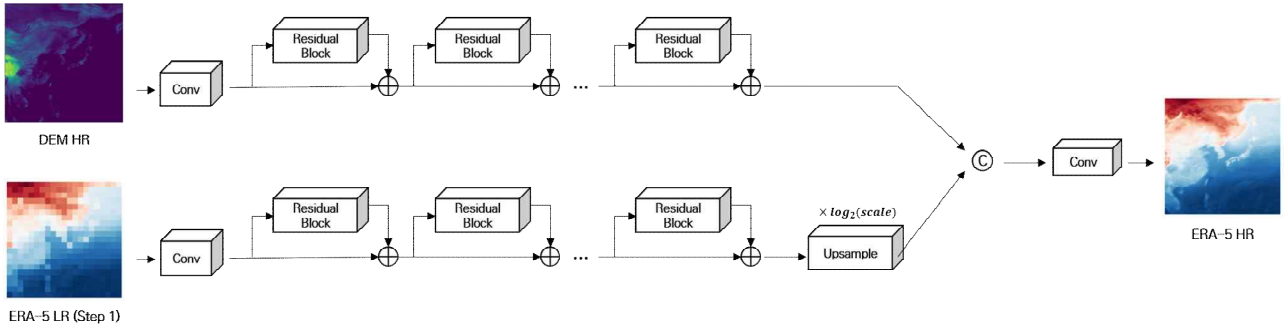


Figure 2.19. EDSR-based downscaling model: CASE DUR.

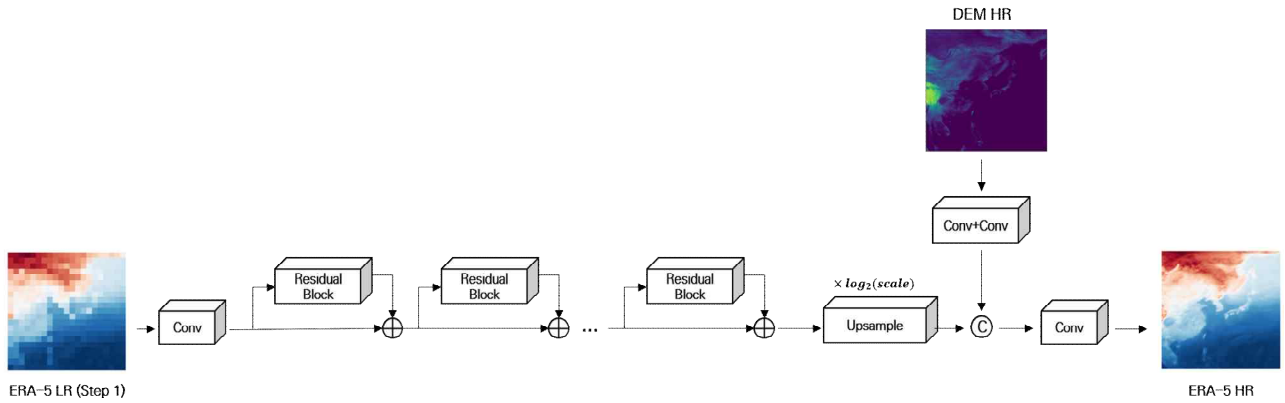


Figure 2.20. EDSR-based downscaling model: CASE UD.

2.3.4. 인공지능 기반 상세화 모델 평가

인공지능 기반 상세화 모델의 평가는 Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM) 등 이미지 화질에 기반한 평가 지표를 이용한다(Wang and Shikh, 2004; Sara et al. 2019).

PSNR은 최대 신호에서 잡음 비율로 생성 또는 압축된 영상의 화질에 대한 손실 정보를 평가할 때 사용하며 손실이 적을수록(화질이 높을수록) 큰 값을 가진다. PSNR은 Eq. 2.18과 Eq. 2.19을 이용하여 계산된다.

$$MSE(I, \hat{I}) = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (I_{ij} - \hat{I}_{ij})^2 \quad [2.18]$$

$$PSNR(I, \hat{I}) = 10 \times \log_{10} \left(\frac{R_I^2}{MSE(I, \hat{I})} \right) \text{ [dB]} \quad [2.19]$$

여기서, I 는 고해상도 ERA-5 자료, \hat{I} 는 고해상도 예측자료이고, m 과 n 는 고해상도 자료의 격자 크기이다. R_I 은 자료의 범위로 이미지 자료에서는 8bit 영상의 경우 255를 사용하지만,

기후자료 같은 경우는 데이터의 범위를 계산하여 이용한다.

SSIM은 인간의 시각적 화질 차이를 평가하기 위해 고안된 평가지표로 휘도(Luminance), 대비(Contrast), 구조(Structural) 등 3가지 측면에서 품질을 평가한다. 수식은 Eq. 2.20와 2.21와 같다. 여기서, 휘도는 빛의 밝기, 대비는 밝기 차이, 구조는 상관관계를 의미한다. SSIM 값은 1에 가까울수록 이미지가 더 유사한 것을 의미한다.

$$SSIM(I, \hat{I}) = \frac{(2\mu_I\mu_{\hat{I}} + C_1)(2\sigma_{I\hat{I}} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)} \quad [2.20]$$

$$C_1 = (K_1 \times R)^2, \quad C_2 = (K_2 \times R)^2 \quad [2.21]$$

여기서, I 는 고해상도 참값 자료, \hat{I} 는 고해상도 예측자료, μ_I 과 $\mu_{\hat{I}}$ 는 각 이미지의 평균값, σ_I 와 $\sigma_{\hat{I}}$ 는 각 이미지의 분산, $\sigma_{I\hat{I}}$ 두 이미지 간 공분산이다. C_1 와 C_2 는 안정화를 위한 상수이다. K_1 과 K_2 은 각 0.01, 0.03, R 은 자료의 범위로 기후자료 같은 경우에는 데이터의 범위를 이용한다.

이미지 화질 변화에 따른 PSNR과 SSIM 값은 Figure 2.21과 같다. 이미지의 화질이 낮아질수록 PSNR과 SSIM 값도 낮아진다.




Figure 2.21. Comparison of PSNR and SSIM values according to variations in image quality.

Wang et al.(2003)은 SSIM을 확장하여 이미지의 스케일이 다른 구조적 유사성을 평가하는 방법으로 multi-scale SSIM (MS-SSIM)을 제안하였다. MS-SSIM 수식은 Eq. 2.22과 같다.

$$MS-SSIM = \sum_{j=1}^M SSIM_j^{\beta_j} \quad [2.22]$$

여기서 j 는 스케일로 1은 원본, 2는 원본 크기의 1/2로 j 는 $1/j$ 크기이다. β 는 가중치로 자료의 스케일에 따라 스케일 1부터 0.0448, 0.2856, 0.3001, 0.2363, 0.1333을 이용한다.

PSNR은 이미지, 비디오 품질을 측정하는데 널리 사용되지만, 인의 시각 시스템을 고려하지 않는다. 이 지표는 이미지 간의 구조적 및 지각적 비유사성을 고려하지 못하며, 인간의 지각과는 제한적인 관련성을 갖는다. PSNR은 유클리드 거리(Euclidean distance)와 같은 고전적인 픽셀당(per-pixel) 측정은 픽셀 간 독립성(pixel-wise independence)를 가정하므로 이미지와 같은 구조화된 출력물을 평가하기에는 부적합하다. 그리고 지각적으로는 관련이 없을 수 있는 픽셀 값의 작은 변화에도 민감할 수 있으며, 이로 인해 인간의 인식과 상관관계가 낮다 (Arabboev et al., 2024; Aveq, 2024; Zhang et al., 2018). SSIM의 단점은 이미지 특정영역이 평균 RGB 값으로 채워지면 SSIM이 전체 평균과 표준편차값을 사용하기 때문에 SSIM 값이 커질 수 있다. 이미지가 흐리게(blur) 처리가 되면 값의 분포가 비슷하기 때문에 SSIM 값이 높을 수 있으며, 선 명도를 평가할 수 없다(xoft, 2022). 또한, PSNR은 평균 오차 기반으로 계산되기 때문에 극값(peak), 경계(edge), 공간적 구조 변화 같은 중요한 특징 손실을 반영하지 못할 수 있음과 SSIM 값이 커도 가장 좋은 결과가 아닐 수 있다(Johnson et al. 2016).

이 연구에는 위와 같은 이미지 기반 평가지표 대신 기후연구에서 많이 사용하는 종관기상 관측자료(ASOS, Automated Synoptic observing System)와 비교를 통해 모델 간 성능을 비교한다. 평가 지표로는 mean absolute error (MAE), mean square error (MSE), root mean square error (RMSE), 그리고 피어슨 상관관계 계수인 R^2 를 이용하며, 수식은 Eq. 2.23, 2.24, 2.25, 2.26과 같다. 상관계수 R^2 는 공간 패턴 또는 변동성의 재현력을 평가하는데 이용한다.

$$MAE = \sum_{i=1}^M \sum_{j=1}^N |I_{ij} - \hat{I}_{ij}| \quad [2.23]$$

$$MSE = \sum_{i=1}^M \sum_{j=1}^N (I_{ij} - \hat{I}_{ij})^2 \quad [2.24]$$

$$RMSE = \sqrt{\sum_{i=1}^M \sum_{j=1}^N (I_{ij} - \hat{I}_{ij})^2} \quad [2.25]$$

$$R^2 = 1 - \frac{\sum_{i=1}^M \sum_{j=1}^N (I_{ij} - \hat{I}_{ij})^2}{\sum_{i=1}^M \sum_{j=1}^N (I_{ij} - \bar{I})^2} \quad [2.26]$$

앞서 2단계로 구축한 학습자료에서 고해상도 자료 격자를 기준으로 지점 자료인 ASOS 자료의 2020년~2024년 최근 5년 자료를 이용하여 격자 단위로 데이터를 구축하였다(Figure 2.22). 격자 내 ASOS 관측소가 2개 이상일 경우에는 평균값을 이용하고, 결측값이 존재하면 결측값을 제외한 평균값을 이용하였다.




Figure 2.22. Diagram of the ASOS station data construction process.

2.4. 기후자료 해상도에 따른 극한기후 재현성 평가

2.4.1. 자료

2.4.1.1 관측자료

본 연구에서는 2000년부터 2019년까지 20년간의 기상 관측 자료를 활용하였다. 사용된 기상 변수는 평균기온, 최고기온, 최저기온 등 3종이며, 자료는 기상청(KMA)의 종관기상관측소(ASOS, Automatic Synoptic Observation System) 97개 지점과 자동기상관측소(AWS, Automatic Weather Station) 508개 지점에서 제공하는 자료를 기반으로 하였다(Figure 2.23). 일별 분석에 이용 가능한 관측소의 개수는 다르기 때문에 관측소의 개수는 날짜에 따라 변화한다. 2000년에는 평균 443.9개의 지점자료가 사용되었으며, 2016년에 가장 많은 관측소 개수(589.1개)를 사용하였다. 최근 연도로 갈수록 새로운 관측소가 추가되어 입력자료의 공간밀도가 점점 높아지는 것을 알 수 있다(Figure 2.23).

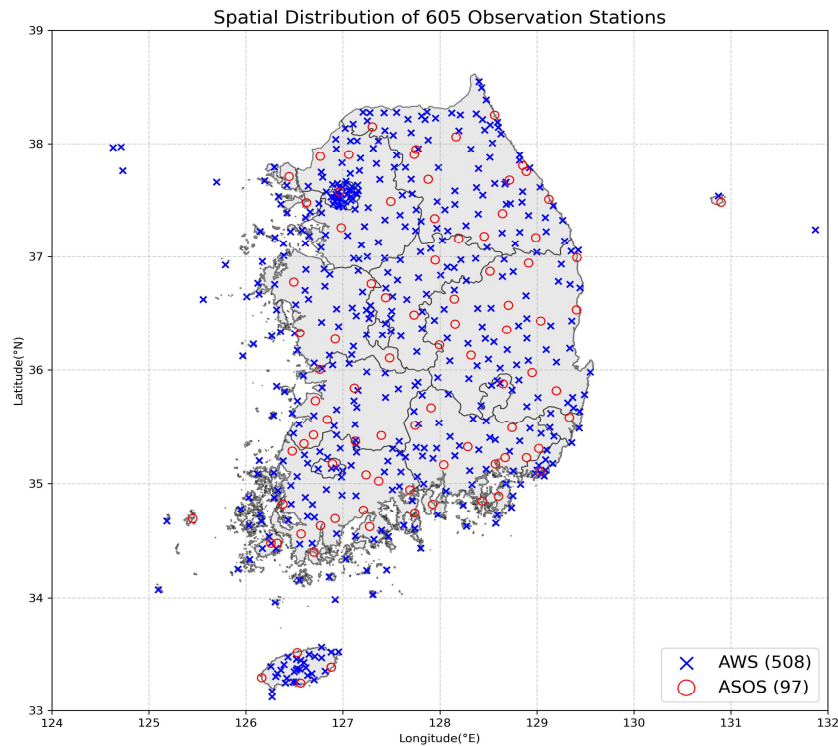


Figure 2.23. Distribution of selected 605 observation sites across South Korea.

수집된 관측자료의 신뢰성과 정확도를 확보하기 위해 자동 품질검사(QC, Quality Control)를 수행된 자료를 사용하였다(기상청, 2019). 품질검사는 변수별 특성과 관측 조건을 고려하여 결측검사, 물리한계검사, 역전검사등의 절차로 구성되었다.

- 결측 검사: 관측값의 존재 여부를 확인하여 누락된 데이터를 식별

- 물리한계 검사: 기상청(KMA)에서 제시한 변수별 허용범위를 기준으로 이상값을 오류값으로 처리
- 역전검사: 기온3종에 대해 논리적 관계를 기반으로 오류 여부를 판단

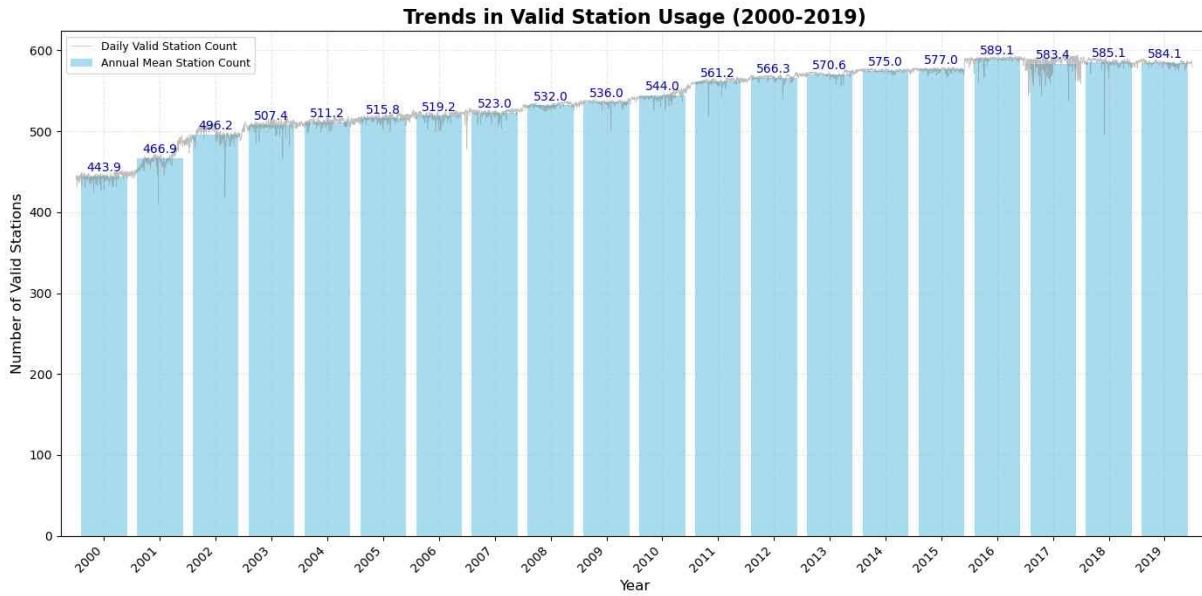


Figure 2.24. Trend in Valid Station Usage (2000-2019).

기온 3종 및 강수량에 대해서는 결측검사와 물리한계 검사를 수행하였으며, 이 범위를 벗어나는 관측값은 오류값으로 간주하여 제외 처리하였다. 또한 기온 3종은 추가로 기온 연적 검사(일최고기온 < 일평균기온 < 일최고기온)를 적용하였다. 이 조건을 만족하지 않는 관측값은 기온 역전 오류로 판단하여 오류값으로 처리하였다. 풍속, 상대습도, 일사량에 대해서도 결측 및 물리 한계 검사를 포함한 자동 품질검사를 수행하였다(Table 2.4)

Table 2.4. Automatic Quality Control (QC) Criteria (Reconstructed from the 2023 Final Report of the National R&D Project on Climate Monitoring and Prediction Applications).

Variable	Test Item	Criteria or Condition	Processing Method
Mean Temp	Physical Limit Test	-45°C ~ 45°C	Treat out of range values as error
Max Temp	Physical Limit Test	-45°C ~ 45°C	Treat out of range values as error
Min Temp	Physical Limit Test	-45°C ~ 45°C	Treat out of range values as error
Precipitation	Physical Limit Test	0mm~1500mm	Treat out of range values as error
Temp (3 types)	Consistency Test (Inversion)	Daily Min < Daily Mean < Daily Max	Treat out of range values as error
Wind speed	Physical Limit Test	Based on limit per variable	Treat out of range values as error
Relative Humidity	Physical Limit Test	0%~100%	Treat out of range values as error
Solar Radiation	Physical Limit Test	Based on Max allowance per device	Treat out of range values as error

2.4.1.2. 고해상도 격자자료

이 연구에서는 고해상도(수평해상도 1km, 500m)의 격자형 관측자료를 이용하여 우리나라 기온 3종(일평균기온, 일최고기온, 일최저기온)자료에 대해 검증을 하였다. 1km 격자형 관측자료는 Modified Korean-Parameter-elevation Regressions on Independent Slopes Model(MK-PRISM)이라는 통계적 상세화 기법을 활용하여 산출되었다. 이 기법은 우리나라의 복잡한 지형 특성을 반영할 수 있도록 개발되었으며, 고도, 사면방향, 해안선 거리 등의 지형 요소를 고려하여 고해상도 기후자료를 생성하였다(Kim et al., 2012;2013;2022;Park et al., 2014.). 500m 격자형 관측자료는 1km자료를 기반으로 500m 지형자료를 이용하여 생산하는 Multi-Step PRISM(MS-PRISM) 기법을 활용하여 산출되었다(Table 2.5).

MK-PRISM은 우리나라의 복잡한 지형 특성을 반영하여 고해상도 격자형 기후자료를 생산하기 위해 개발된 통계적 상세화 기법이다. 이 모델은 미국에서 개발된 PRISM(Parameter-elevation Regressions on Independent Slopes Model)을 기반으로 하되, 한국의 지형적 특성과 기후 특성에 맞게 수정·보완된 형태로 적용된다. 특히 산악지형이 많은 한반도의 특성을 고려하여, 지형고도뿐만 아니라 해안선 거리, 사면 방향, 지형 경사도 등 다양한 공간적 요소를 반영함으로써 보다 정밀한 기후자료를 생성할 수 있도록 설계되었다.

MK-PRISM의 핵심 원리는 각 격자점에 대해 주변 관측지점과의 관계를 회귀 분석을 통해 추정하는 것이다. 이때 단순한 거리 기반 보간법이 아닌, 지형 요소에 따라 가중치를 부여하는 방식으로 선형 회귀식을 구성한다. 예를 들어, 고도가 높은 지역에서는 고도에 따른 기온 감소를 반영하고, 해안선과 가까운 지역에서는 해양의 완화 효과를 고려하여 기온이나 강수량을

조정한다. 이러한 방식은 각 격자점의 값을 독립적으로 계산함으로써 지점 편향을 최소화하고, 관측값의 공간적 연속성을 확보하는 데 유리하다.

Table 2.5. Description of Data Sources, Resolution, and GIS Attributes.

Item	MK-PRISM	MS-PRISM
Data Period	2000~2019	2000~2019
No. of Stations	605(ASOS:97, AWS:508)	605(ASOS:97, AWS:508)
Variables	Temp(Mean, Max, Min), Precipitation, Wind, RH, Solar Radiation	Temp(Mean, Max, Min), Precipitation
Spatial Resolution	Approx. 1km(751x601)	Approx. 500m (1501x1201)
Time Resolution	1day	1day
GIS Data Used	NASA ASTER GDEM Version 3, 2019	

MK-PRISM은 약 12km 해상도의 관측기후자료를 기반으로 1km 수준의 고해상도 격자자료를 생성할 수 있으며, 일최고기온, 일최저기온, 일평균기온, 강수량 등 다양한 기후변수에 적용된다. 최근에는 풍속 내삽 기능까지 확장되어, 기존에 정확한 재현이 어려웠던 해안 지역이나 능선 부근의 풍속 분포도 보다 정밀하게 산출할 수 있게 되었다. 풍속 내삽에서는 기존의 지형 요소 외에도 풍향, 지형면의 방향성, 바람의 차단 효과 등을 고려하여 회귀식의 계수를 지역별로 다르게 적용하는 방식이 도입되었다. MK-PRISM은 단순한 내삽 기법을 넘어, 관측자료와 지형정보, 통계모델을 융합하여 공간적 정밀도와 기후학적 타당성을 동시에 확보할 수 있는 한국형 상세화 모델로 평가받고 있다.

이러한 MK-PRISM 기법은 기후변화 영향 평가, 극한기후 분석, 지역기후 시나리오 생산 등 다양한 분야에서 활용되고 있으며, 특히 국가 차원의 기후적응 정책 수립과 재해 대응 전략 마련에 있어 핵심적인 기초자료로 사용된다. 고해상도 격자자료는 농업, 수자원, 도시계획, 보건 등 다양한 부문에서 기후 리스크를 정량적으로 분석하고, 지역별로 차별화된 대응 방안을 마련하는 데 필수적인 역할을 한다.

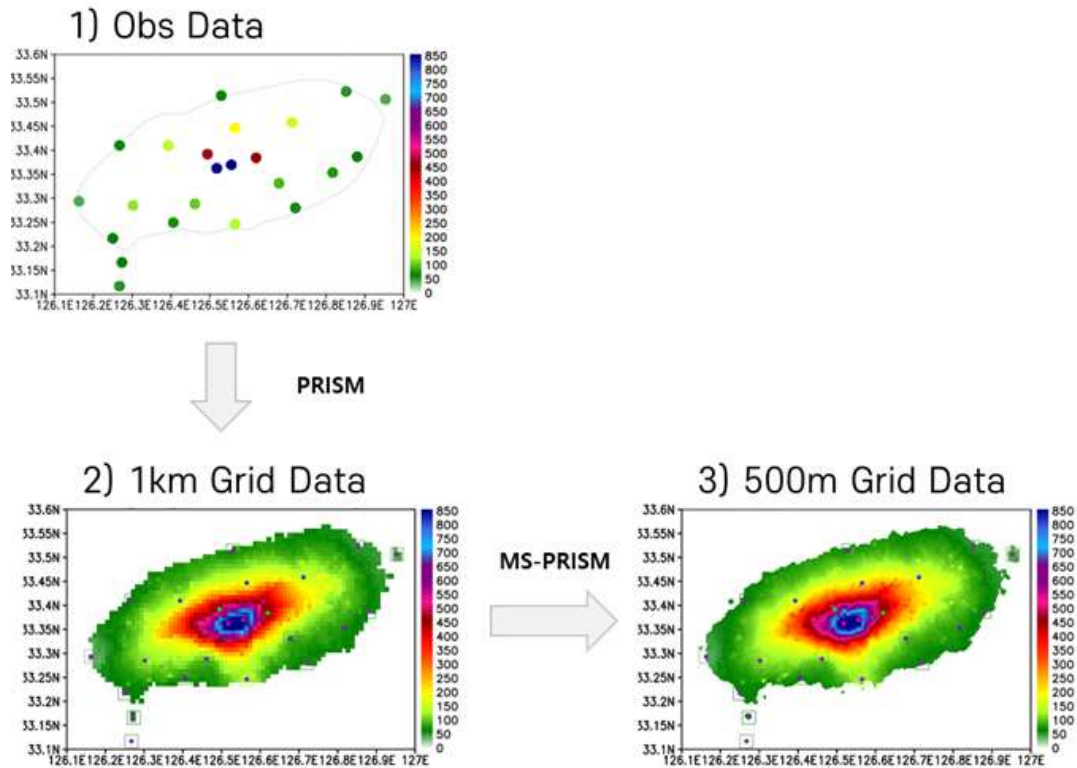


Figure 2.25. Gridded Data Production Method Using MK-PRISM and MS-PRISM.

Multi-step PRISM 기법은 관측기후자료와 기후모델 시나리오를 결합하여 고해상도 격자형 미래기후자료를 생산하기 위한 통계적 상세화 방법이다. MS-PRISM은 크게 여섯 단계로 구성된다. 첫 번째 단계에서는 MK-PRISM을 활용하여 관측기후자료를 1km 격자 해상도로 상세화한다. 두 번째 단계에서는 상세화된 관측값을 기반으로 일 단위 또는 시간 단위의 기후변수를 산출한다(Figure 2.25). 세 번째 단계에서는 지역기후모델(RCM)에서 생산된 현재 및 미래 기후자료를 객관분석 기법을 통해 보정하며, 이 과정에서 모델의 계통오차 및 계절적 편차를 최소화한다. 네 번째 단계에서는 보정된 모델 기후값을 기반으로 미래 시나리오에 따른 기후변동량을 계산한다. 이때 RCP 또는 SSP 시나리오에 따른 기온, 강수량 등의 변화량이 도출된다. 다섯 번째 단계에서는 관측 기반의 상세화 자료와 모델 기반의 변동량을 결합하여 미래 기후자료를 생성한다. 마지막으로, 여섯 번째 단계에서는 변수별 기후학적 특성에 따라 보정 작업을 수행하며, 극한기후지수나 지역별 민감도 등을 반영하여 자료의 신뢰도를 높인다.

이러한 MS-PRISM 기법은 단순한 내삽을 넘어 관측과 모델의 융합을 통해 신뢰도 높은 미래기후자료를 구축할 수 있다는 점에서, 기후변화 영향 평가, 적응 정책 수립, 재해 예측 등 다양한 분야에서 활용되고 있다. 특히 폭염, 한파, 호우 등 극한기후 분석에 효과적으로 적용되며, 국가 차원의 기후 리스크 대응 전략 수립에도 중요한 기반자료로 사용된다.

2.4.2. 분석방법

2.4.2.1 모델 성능평가 지표

본 연구에서는 제안된 모델의 성능을 다각적으로 평가하기 위하여 다양한 통계적 지표를 활용하였다. 구체적으로는 예측값과 관측값 간의 선형적 관계를 파악하기 위한 상관계수 (Correlation Coefficient), 평균 제곱근 오차(RMSE, Root Mean Square Error)를 통해 모델의 전반적인 오차 크기를 정량화하였으며, 결정계수(R^2)를 사용하여 모델이 관측값의 변동성을 얼마나 설명할 수 있는지를 검증하였다(Gupta et al., 2009). 또한 평균 편향(BIAS)을 통해 예측값이 관측값에 비해 체계적으로 과대 혹은 과소 추정되는 경향을 확인하였고, 상관성·분산성·편향성을 종합적으로 고려하는 Kling-Gupta Efficiency(KGE) 지수를 적용하여 모델의 종합적인 재현 능력을 평가하였다. 마지막으로 Morns I 지수를 활용하여 공간적 자기상관을 분석함으로써 모델이 공간적 패턴을 얼마나 충실히 반영하는지를 검토하였다. 이러한 다양한 지표의 활용을 통해 모델 성능을 단일 지표에 의존하지 않고 다면적으로 평가함으로써, 보다 신뢰성 있고 종합적인 성능 검증을 수행하였다. 따라서 본 연구에서 사용된 모델 평가 지표의 정의는 아래와 같다.

- 상관계수 (Correlation Coefficient, Cor, r)

상관계수는 예측값과 관측값 간의 선형 관계의 강도와 방향을 나타내며, 기온 시계열 등의 패턴 일치도를 평가할 때 사용되며, -1과 1 사이의 값을 가진다. 1에 가까울수록 두 변수가 강한 양의 선형 관계를 갖는 것을 의미한다(Eq. 2.27).

$$Cor = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum_{i=1}^n (x_i - \bar{x})^2)} \sqrt{(\sum_{i=1}^n (y_i - \bar{y})^2)}} \quad [2.27]$$

- 평균 제곱근 오차 (Root Mean Square Error, RMSE)

RMSE는 오차의 크기를 나타내는 지표로, 예측값과 관측값의 차이를 제곱하여 평균 낸 후 제곱근을 취한 값으로, 값이 작을수록 예측 성능이 우수한 것이다(Eq. 2.28)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad [2.28]$$

- 편향 (Bias)

BIAS는 예측값과 관측값의 평균적인 차이를 나타낸다(Eq. 2.29). 양수이면 과대 예측($P > O$) 경향, 음수이면 과소 예측($P < O$) 경향이 있음을 의미하며, 0에 가까울수록 시스템적 편향이 적은 것이다.

$$BIAS = \frac{1}{N} \sum_{i=1}^N (P_i - O_i) \quad [2.29]$$

• 결정계수 (Coefficient of Determination, R^2)

결정계수는 모델이 관측 데이터의 변동성 중 얼마나 많은 부분을 설명하는지를 나타내는 지표이다(Eq. 2.30). 0 과 1 사이의 값을 가지며, 1에 가까울수록 모델의 적합도가 높은 것을 의미한다.

$$R^2 = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad [2.30]$$

여기서 분자 $\sum_{i=1}^N (O_i - P_i)^2$ 는 잔차 제곱합 (Sum of Squares Residual, SSR)을, 분모 $\sum_{i=1}^N (O_i - \bar{O})^2$ 는 총 제곱합 (Sum of Squares Total, SST)을 의미한다.

• KGE (Kling-Gupta Efficiency)

수문학 모델의 성능을 평가하기 위해 2009년에 Gupta, Kling, 등에 의해 제안된 효율성 지표이다(Eq. 2.31). 기존의 NSE(Nash-Sutcliffe Efficiency)의 단점을 보완하여, 모델 예측값과 관측값 간의 상관관계, 변동성, 편의 세 가지 요소를 통합적으로 평가하는 지수이다. KGE의 값은 $-\infty$ 에서 1 사이의 범위를 가지며, 1에 가까울수록 모델의 성능이 완벽함을 의미한다.

$$KGE = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad [2.31]$$

여기서 r은 상관계수이고, α 는 변동성(variability ratio) 비율, β 는 평균비율(Bias ratio) 이다.

2.4.2.2 공간적 자기상관 분석

본 연구에서는 공간적 자기상관을 분석하기 위하여 Moran's I와 LISA(Local Moran's I)를 활용하였다. Moran's I는 전역적 공간 자기상관 지수로서 전체 데이터가 균집(양의 자기상

관), 분산(음의 자기상관), 혹은 무작위 패턴을 보이는지를 평가한다. 값이 +1에 가까울수록 유사한 값들이 공간적으로 모여 있음을 의미하며, 0에 가까울수록 무작위 분포, -1에 가까울수록 이웃 간 상반된 값들이 분산되어 있음을 나타낸다(Moran, 1950). 반면 LISA는 Moran's I를 지역 단위로 분해하여 특정 지역이 전체 패턴에 얼마나 기여하는지를 보여준다. 이를 통해 국지적 군집(High-High, Low-Low)과 이상치(High-Low, Low-High)를 식별할 수 있으며, 이는 공간적 패턴을 보다 세밀하게 해석하는 데 유용하다. 특히 표준편차를 기준으로 중심값과 주변값의 상대적 위치를 비교함으로써 군집과 이상치를 구분할 수 있다(Table 2.6)

- Moran' I (전역적 공간 자기상관 지수)

Moran's I 값은 +1에 가까울수록 강한 양의 공간적 자기상관, 0에 가까울수록 무작위, -1에 가까울수록 강한 음의 자기상관을 의미한다(Eq. 2.32).

$$I_i = \frac{(x_i - \bar{x})}{m^2} \sum_{j=1}^N w_{ij} (x_j - \bar{x}) \quad [2.32]$$

N: 관측 지점의 개수, x_i : i 번째 지점의 관측값, \bar{x} : 전체 평균값, w_{ij} : i와 j 지점간의 공간가중치(인접성), W: 전체가중치의 합

- LISA (Local Indicators of Spatial Association)

LISA는 Moran's I를 지역 단위로 분해하여 국지적 공간 자기상관을 측정하는 지표이며, 대표적으로 Local Moran's I가 사용된다.

Table 2.6. Local Clusters and Outliers Based on Standard Deviation.

Type	Target Region	Neighboring Region	Meaning
High-High (HH)	Higher than average (+ Ste Dev)	Higher than average (+ Ste Dev)	High-Value Cluster (Hot Spot)
Low-Low (LL)	Lower than average (- Ste Dev)	Lower than average (- Ste Dev)	Low-Value Cluster (Cold Spot)
High-Low (HL)	Higher than average (+ Ste Dev)	Lower than average (- Ste Dev)	Outlier (A high value located among low values)
Low-High (LH)	Lower than average (- Ste Dev)	Higher than average (+ Ste Dev)	Outlier (A low value located among high values)

2.4.2.3. 극한기후지수

기후자료에서 극한기후현상을 정의하는 기준은 기관마다 상이하며, 사용 목적과 지역 특성에 따라 다양한 방식으로 제공되고 있다. 일반적으로 극한기후는 기온이나 강수량 등의 기후 요소가 평년값을 크게 벗어난 상태를 의미하며, 절대적 기준과 상대적 기준으로 구분된다.

절대적 기준은 고정된 수치(예: 일최고기온 33°C 이상, 일최저기온 -12°C 이하 등)를 기준으로 극한현상을 정의하며, 사회경제적 영향과 직결되는 분석에 유리하다(Min et al., 2015). 반면, 상대적 기준은 해당 지역의 과거 기후 통계를 기반으로 퍼센타일(percentile) 값을 산출하여 극한 여부를 판단한다. 예를 들어, 온난일은 일최고기온이 기준기간의 90퍼센타일을 초과한 날로 정의되며, 이 기준값은 지역별로 상이하다. 상대적 기준은 지역 특성을 반영할 수 있어 전 지구적 또는 광역적 기후변화 경향 분석에 적합하다.

국제기구 및 각국 기상청은 이러한 기준을 바탕으로 극한기후를 정의하고 자료를 제공하고 있다.

- IPCC는 관측값의 10퍼센타일 이하 또는 90퍼센타일 이상을 기준으로 극한기후를 정의하며, 특별보고서를 통해 관련 정보를 제공한다.
- WMO는 확률분포의 끝단에 위치한 값, 즉 통상적으로 20년에 한 번 발생하는 수준의 현상을 극한기후로 간주한다.
- 호주기상청은 1%, 3%, 97%, 99% 퍼센타일 기준을 적용하고 있으며,
- 영국기상청은 기후요소별 월별 최댓값 및 최솟값을 중심으로 극한기후 통계를 제공한다.
- 프랑스기상청은 20퍼센타일 이하 또는 80퍼센타일 이상을 기준으로 삼고 있으며,
- 일본기상청은 기온의 경우 $\pm 1.83\sigma$ 를 벗어난 값을, 강수량의 경우 기준기간(30년)의 최대·최소값을 초과한 경우를 극한으로 정의한다.
- 우리나라 기상청에서 이상기후는 평년에 비해 현저히 높거나 낮은 수치를 나타내는 극한 현상으로 이상저온은 최저·최고기온 10퍼센타일 미만, 이상고온은 90퍼센타일 초과로 정의된다. 이 연구에 사용된 극한기후지수는 Table 2.7에 제시하였다.

Table 2.7. Climate Extreme indices used in this study.

Index Name	Description
Number of Hot Days	Days with daily maximum temperature $\geq 30^{\circ}\text{C}$
Number of Heatwave Days	Days with daily maximum temperature $\geq 33^{\circ}\text{C}$
Number of Extreme Hot Days	Days with daily maximum temperature $\geq 35^{\circ}\text{C}$
Warm Days	Days with daily maximum temperature $\geq 90^{\text{th}}$ percentile of reference period
Warm Spell Duration Index	Period ≥ 6 consecutive warm days ($\text{TX} \geq 90^{\text{th}}$ percentile)
Summer Days	Day with daily maximum temperature $\geq 25^{\circ}\text{C}$
Tropical Nights	Day with daily minimum temperature $\geq 25^{\circ}\text{C}$
Frost Days	Day with daily minimum temperature $< 0^{\circ}\text{C}$
Ice Days	Day with daily maximum temperature $< 0^{\circ}\text{C}$
Max Daily Maximum Temperature(TX_x)	Annual maximum of daily maximum temperature
Min Daily Minimum Temperature(TN_n)	Annual minimum of daily minimum temperature
Diurnal Temperature Range	Annual mean of daily temperature range($\text{TX}-\text{TN}$)

2.5. 부문별 영향정보지수(농업부문 8종 개선)

2.5.1. 현황 분석 및 전문가 의견 수렴

기상청의 국가 기후변화 표준 시나리오(SSP)를 기반으로 생산되는 농업부문 영향정보를 서비스하기 위해, 기존 지수의 현장 활용성을 진단하고 개선 방향을 도출하는 과정을 선행하였다. 이를 위해 국립한국농수산대학교, 국립축산과학원, 국립원예특작과학원, 국립식량과학원 등 각 분야 전문가 자문을 통해 기존 지수의 한계점과 실무적 문제점을 다음과 같이 파악하였다.

- **용어 및 정의의 비현실성:** ‘식물기간’, ‘작물기간’ 등은 농업 현장에서 통용되지 않는 용어이며, 단순히 기준온도 이상인 일수의 합으로 산출하는 방식은 생육 환경의 다양성을 반영하지 못한다는 지적이 제기되었다.
- **데이터 가용성 문제:** 기존 ‘Chill Units(저온요구도)’ 산출 방식은 시간(Hour) 단위 기온 자료를 필요로 하나, 기후변화 시나리오(SSP)는 주로 일(Day) 단위로 제공되어 시나리오 적용 시 데이터 용량 및 처리 속도에 한계가 있음이 확인되었다.
- **낮은 현장 활용도:** ‘냉방도일(CDD)’의 경우 농업 시설 재배 시 비용 문제로 냉방 활용이 극히 제한적이므로 영향 지수로서의 효용성이 낮은 것으로 평가되었다.
- **분야별 특수성 미반영:** 기존 ‘난방도일’과 ‘온습도지수’는 에너지 및 일반 기상 분야 용어로, 농업 시설과 가축 생육 환경의 특수성을 충분히 반영하지 못한다는 의견이 있었다.

2.5.2. 세부 지수별 산출 및 개선 방법

전문가 자문 결과를 반영하여 총 8종의 농업부문 영향지수에 대한 개선안을 마련하였으며, 주요 산출 방법은 다음과 같다.

1) 유효적산온도 (Growing Degree Days, GDD)

- 기존의 ‘생육온도일수’와 ‘유효적산온도’를 통합하여 유효적산온도(GDD)로 명칭을 일원화하였다.
- 산출식: 일최고기온과 일최저기온의 평균에서 작물의 기준온도(T_b)를 뺀 값을 적산한다. 단, 일평균기온이 기준온도 미만일 경우 계산하지 않는다.

* 기준온도(T_b): 5°C(고추, 배추 등), 10°C(벼, 옥수수 등) 적용

2) 작물재배가능기간 (Growing Season Length, GSL)

- 기존의 단순 누적 방식(식물기간, 작물기간)을 폐지하고, 생육 시작일과 종료일의 개념을 적용한 작물재배가능기간(GSL)을 도입하였다.

- 산출 기준:

시작일: 일평균기온 5°C 이상이 5일 이상 지속되는 시점

종료일: 일평균기온 5°C 이하가 5일 이상 지속되는 시점

3) Chill Days / Anti-Chill Days (저온/고온 축적값)

- 일 단위 기상자료(시나리오) 활용이 가능한 Cesaraccio et al.(2004)의 생물계절모형을 적용하였다.
- 산출 방법: 일최고(Tx), 일최저(Tn), 일평균(Tm) 기온을 활용하여 과수 휴면 타파에 필요한 저온 축적값(Cd)과 개화에 필요한 고온 축적값(Ca)을 산출한다.

4) 시설 난방적산온도 (Heating Degree Days, HDD)

- 기존 난방도일 개념을 농업 시설에 맞춰 개선하였다.
- 산출식: 시설 외부 일평균기온이 작물 생육한계온도(Tb)보다 낮을 때, 그 차이를 적산한다. (Tb: 저온성 작물 5°C, 고온성 작물 10°C)

5) 가축더위지수 (Livestock Heat Index, THI)

- 미국 육우 NRC(National Research Council) 사양표준 공식을 적용하여 일평균기온과 상대습도를 변수로 산출한다.
- 산출된 지수는 축종별(소, 돼지, 닭) 임계값에 따라 5단계 위험도(양호~폐사)로 구분한다.

3. 결과

3.1. 위성기반 고해상도 격자자료 산출 및 알고리즘 개발, 품질관리

3.1.1. 위성자료 검증

제시된 GPM 위성과 지상관측자료와의 비교 산포도는 위성 강수 추정의 전형적인 오차 특성과 제주도 지역의 특수성을 동시에 보여준다. 통계 지표의 결과를 보면 상관관계수 ($R = 0.584$)는 위성 데이터와 지상 관측값 사이에 뚜렷한 양의 상관관계가 존재함을 나타낸다. 그러나 R 값이 0.6 미만이라는 점은 1998-2005년 기간 동안 위성 데이터가 지상 관측의 변동성을 약 34% 정도만 설명할 수 있음을 의미한다. 이는 복잡한 지형과 해양성 강우 시스템의 난수적 특성이 위성 관측의 불확실성을 높이는 요인으로 작용했음을 나타낸다. RMSE는 19.57 mm/day으로 일 강수량 기준으로 약 20mm에 달하는 오차는 수문학적 모델링이나 일 단위 홍수 예보에 직접 활용하기에는 다소 큰 수치이다. 특히 RMSE는 큰 오차에 가중치를 부여하므로, 이는 태풍이나 집중호우 시 발생하는 극단적인 오차가 전체 정확도 지표를 저하시키고 있음을 암시한다. 편의값은 -1.06 mm/day으로 음의 편이 값은 GPM IMERG가 전체적으로 지상 관측보다 강수량을 과소추정(Underestimation)하고 있음을 나타낸다. 이는 위성 강수 산출물, 특히 마이크로파 기반 추정에서 흔히 나타나는 현상으로, 강한 강우 시스템 내에서의 신호 감쇠(Attenuation)와 빔 채움 효과(Beam-filling Effect)에 기인한다. 데이터 분포를 보면 낮은 강수 구간의 과대추정으로 ASOS 관측값은 0에 가까우나 GPM 값이 높게 나타나는 데이터들이 Y축을 따라 분포한다. 얇은 층상운을 강한 비로 오인하거나 강수량의 유무를 잘 관측 못하는 위성 알고리즘의 한계를 보여준다.

높은 강수 구간의 과소추정은 ASOS 관측값이 100mm/day를 초과하는 구간에서 GPM 데이터는 1:1 선 아래로 처지는 경향이 뚜렷하다. 즉, 지상은 폭우를 기록했으나 위성은 이를 중간 정도의 강우로만 인식하는 현상이 발생한다. 이는 위성 센서의 시공간 해상도 한계로 인해 국지적인 호우 셀(Cell)의 피크 값을 평균화해버리기 때문으로 판단된다. 선행 연구 및 관련 데이터 분석에 따르면, GPM IMERG와 지상 관측 간의 상관관계수는 특정 강우 강도 구간에서 정점을 찍고 하락하는 경향을 보인다. 제주도 지역의 경우, 시간당 강수량 약 18mm/hr 수준까지는 상관관계수가 증가하다가, 그 이상의 극한 강우에서는 급격히 감소하는 패턴이 관찰된다. 이는 위성 알고리즘이 중간 강도의 강우(Moderate Rain)에 최적화되어 있으며, 재해를 유발하는 수준의 극한 강우(Extreme Precipitation)에 대해서는 탐지 능력이 저하됨을 정량적으로 입증한다. 반면, 보통 지상 레이더 합성장(CAPPI)은 강우 강도가 강할수록 상관성이 높아지는 대조적인 특성을 보이므로, 위성 데이터와 지상 레이더의 상호 보완적 활용(Fusion)이 필수적이다.

그리고 지점별로 보면 서귀포 지점이 가장 높은 상관관계수가 관찰되었다. 이는 서귀포 지역은 연강수량이 가장 많고 강우 강도가 뚜렷한 지역이다. 위성 센서(특히 마이크로파 센서)는 미량 강수보다는 일정 수준 이상의 신호 대 잡음비(SNR)가 보장되는 강한 강우에서 패턴 인식 능력이 뛰어나다. 즉, 강수 신호가 확실하기 때문에 탐지 성공률(POD)이 높아져 상관관계수가 상승한 것이다. 서귀포에 영향을 주는 장마 전선이나 태풍은 대규모의 조직화된 구름 시스템(Mesoscale Convective Systems)을 동반한다. 이러한 대규모 시스템은 위성의 해상도로도 충분

히 분해 가능하므로, 국지적 소나기가 잦은 북부(제주)보다 공간적 대표성이 확보되기 쉽다. IMERG Final Run의 보정 효과: 분석에 사용된 IMERG 데이터(Final Run 추정)는 월 단위 지상 우량계(GPCC) 보정 과정을 거친다. 서귀포와 같이 강수량이 풍부하고 관측 데이터 품질이 좋은 지점은 보정 알고리즘의 효과가 극대화되어 편의(Bias)가 효과적으로 제거되고 선형성이 회복되었을 가능성이 크다. 좌측 하단의 박스플롯은 각 지점별 상관계수의 분포 범위를 보여준다. 서귀포 지점은 중앙값(Median)이 가장 높을 뿐만 아니라, 상위 75% 구간의 분포도 높게 형성되어 있어 전반적으로 안정적인 성능을 보인다. 반면, 고산 지점은 박스의 크기가 상대적으로 작아 성능의 변동폭이 좁고 일관적인 특성을 보이며, 이는 고산이 GPM 지상 검증(Ground Validation)을 위한 테스트베드로 선정된 이유를 뒷받침한다. 제주 지점은 중앙값이 낮고 분포가 아래로 치저 있어, 위성 강수 활용 시 가장 큰 불확실성을 내포한 지역임이 확인된다 (Figure 3.1).

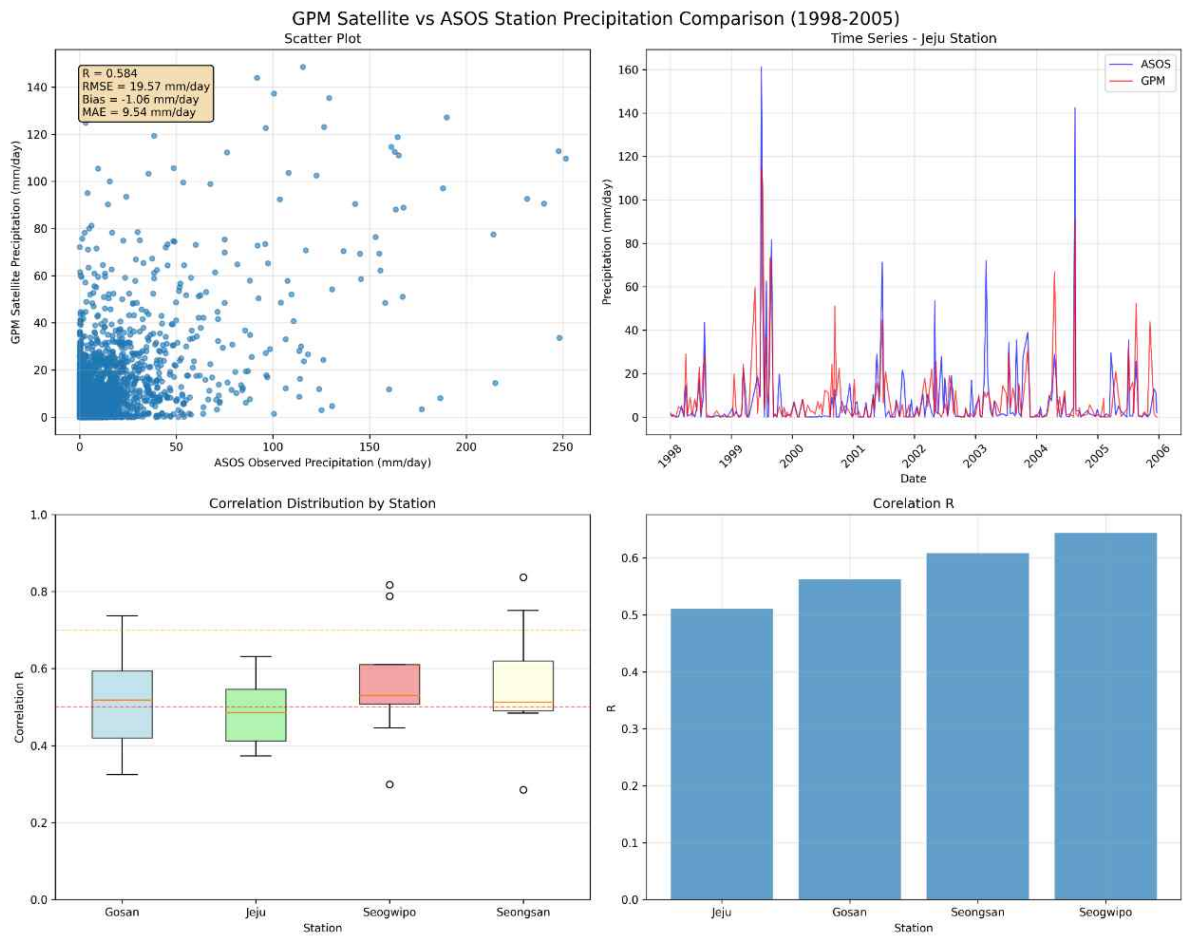


Figure 3.1. The statistical results of comparison with GPM IMERG and ASOS rainfall.

위성강우의 정확도 평가를 위해 사용된 CMORPH 자료는 수동 마이크로파(PMW) 센서의 강수 추정치를 정지궤도 위성(GEO)의 적외선(IR) 자료를 이용한 구름 이동 벡터(Motion Vector)로 보간(Morphing)하여 생산된 고해상도(0.25°, 3시간/일 단위) 강수 산출물이다. 검증 대상인 지상 관측 자료는 기상청(KMA)에서 운영하는 4개 주요 ASOS 지점(제주, 고산, 성산, 서귀포)의

일 강수량 자료를 사용하였다. 정량적 평가를 위해 사용된 통계 지표는 상관계수(Correlation Coefficient, R), 평균제곱근오차(Root Mean Square Error, RMSE), 평균절대오차(Mean Absolute Error, MAE), 그리고 편이(Bias)이다. 각 지표는 위성 강수 자료의 선형적 관계, 오차의 크기, 그리고 과대/과소 추정 경향을 파악하는 데 활용하였다. 분석결과 제주도 전체 ASOS 관측소의 일 강수량과 CMORPH 위성 강수량 간의 관계를 도시한 산점도 분석 결과는 위성 자료의 전반적인 성능과 한계를 명확히 보여준다. 분석 기간(1998-2005) 동안 산출된 전체 상관계수(R)는 0.517로 나타났다. 이는 위성 강수 자료가 지상 강수의 변동성을 약 26.7%정도 설명할 수 있음을 의미하며, 기후변화 연구에 적용을 위해서는 추가적인 보정이 필요한 수준의 상관성이다. 특히 주목해야 할 점은 RMSE(20.23 mm/day)와 MAE(9.16 mm/day) 간의 차이이다. RMSE가 MAE보다 두 배 이상 크게 산출된 것은 오차 분포가 정규분포를 따르지 않고, 큰 오차를 유발하는 극치값들이 다수 존재함을 시사한다. 이는 태풍이나 장마철 집중호우 시 위성이 강수량을 크게 놓치거나 과소평가하는 사례가 빈번함을 통계적으로 뒷받침한다.

산점도에서 데이터 포인트들은 1:1 대각선(One-to-one line) 아래쪽에 밀집해 있으며, 산출된 Bias는 -3.38 mm/day로 뚜렷한 음의 편이(Negative Bias)를 보였다. 이는 CMORPH가 제주도 지역의 실제 강수량보다 평균적으로 일일 3.38mm 과소추정하고 있음을 나타낸다. 이러한 과소 추정 경향은 강수 강도가 강해질수록 더욱 심화되는 양상을 보인다. 예를 들어, ASOS 관측 강수량이 100mm/day를 초과하는 호우 사례에서 위성 강수량은 대부분 50~100mm/day 범위에 머무르는 포화된 상황을 보여준다. 위성 센서의 관측 픽셀(약 25km) 내에서 발생하는 국지적인 집중호우가 픽셀 전체 면적으로 평균화되면서 강수 강도가 낮게 산출되는 현상이다. 제주도는 한라산 지형에 의해 강수 구역이 좁고 강하게 발달하는 특징이 있어 이 효과가 더욱 두드러지게 나타난다. 제주도와 같은 해양성 기후 지역에서는 구름 상층부의 온도가 낮지 않아도 하층에서 다량의 수증기 유입과 충돌-병합(Collision-Coalescence) 과정에 의해 강수가 발생하는 경우가 많다. 그러나 CMORPH의 마이크로파 알고리즘이나 적외선 보정 과정은 주로 차가운 구름 꼭대기(Cold Cloud Top)와 강한 빙정 산란(Ice Scattering) 신호에 의존하기 때문에, 이러한 따뜻한 비 형태의 강수를 효과적으로 탐지하지 못하고 과소평가하는 경향을 나타내게 된다.

시계열 그래프에서 파란색 실선(ASOS)과 빨간색 실선(CMORPH)은 전반적으로 여름철(6-9월)에 강수가 집중되는 동아시아 몬순(Changma) 기후 특성을 잘 반영하고 있다. 그러나 피크(Peak) 값의 일치 여부를 살펴보면, 위성 자료는 강수 발생 시점(Timing)은 비교적 정확하게 포착하고 있으나, 그 강도(Intensity)를 따라가지 못하는 한계를 드러낸다. 특히 1999년, 2002년, 2003년 여름철에 발생한 200mm/day 이상의 기록적인 폭우 사례들에서 CMORPH는 실제 강수량의 절반 수준인 100mm/day 내외만을 탐지하는 데 그쳤다. 또한 겨울철(12~2월)의 시계열을 보면 강수량이 적고 위성과 지상 관측 간의 차이가 작아 보이지만, 실제로는 위성이 약한 강수나 강설(Snowfall)을 전혀 탐지하지 못하는 미탐지(Miss) 사례가 빈번하여 상관성이 매우 낮게 나타난다. 이는 지표면의 방출률(Emissivity)이 낮은 눈 덮인 지형이나 차가운 지표면 위에서 마이크로파 센서가 강수 신호를 구별해내기 어렵기 때문이다.

상관계수의 분포 범위(Box Plot)을 통해 살펴본 지점별 상관계수의 분포(Distribution) 또한 이러한 지형적 특성이 나타난다. 서귀포 및 성산은 박스(Box)의 위치가 상대적으로 높고 길이가 짧아 연도별 혹은 계절별로 안정적인 성능을 유지하고 있음을 알 수 있다. 이는 강수 시스

템이 크고 명확하여 위성 탐지의 일관성이 확보됨을 의미한다. 제주 및 고산의 박스의 위치가 낮고 분포 범위가 넓게 나타난다. 특히 제주 지점은 중앙값(Median) 자체가 낮을 뿐만 아니라, 특정 시기에는 상관관계수가 0.3 미만으로 떨어지는 등 성능의 변동폭이 매우 크다. 이는 북부 지역의 강수 패턴이 위성이 탐지하기 어려운 국지적, 비정형적 특성을 강하게 띠고 있음을 알 수 있다(Figure 3.2).



Figure 3.2. The statistical results of comparison with PERSIANN and ASOS rainfall.

3.1.2. 기계학습 모델 산출 자료 검증

Figure 3.3은 기계 학습(Machine Learning) 기반의 회귀 문제 해결에 있어 널리 활용되는 트리 기반 앙상블(Tree-based Ensemble) 모델들의 성능을 실험적으로 검증하고, 그 결과를 심층적으로 분석하는 데 목적을 둔다. 분석 대상 모델은 배깅(Bagging) 방식의 대표 주자인 Random Forest와 부스팅(Boosting) 계열의 Gradient Boosting Machine (GBM), XGBoost (eXtreme Gradient Boosting), LightGBM이다. 본 분석은 제공된 세 가지 주요 성능 지표인 결정 계수(R^2), 평균 절대 오차(MAE), 평균 제곱근 오차(RMSE)의 통계적 결과를 산출하였다. 실험 결과는 훈련(Train), 검증(Validation), 테스트(Test) 데이터셋에 대한 모델별 거동을 포괄하며, 이를 통해 각 알고리즘의 예측 정확도뿐만 아니라 과적합(Overfitting) 경향성, 일반화

(Generalization) 능력, 그리고 이상치(Outlier) 민감도를 분석하였다.




Figure 3.3. Coefficient of determination for machine learning models by raw satellite precipitation.

결정 계수(R^2)는 독립 변수가 종속 변수의 변동성을 얼마나 설명하는지를 나타내는 지표로, 회귀 모델의 적합도를 판단하는 가장 직관적인 척도이다. 본 연구의 R^2 비교 결과(Figure 3.3)는 모델 간의 학습 차이를 명확히 보여준다. XGBoost의 우월성과 부스팅의 효과실험 결과, XGBoost는 테스트 데이터셋에서 0.458의 R^2 값을 기록하며 비교군 중 가장 높은 설명력을 보였다. 이는 2위인 Gradient Boosting(0.408)보다 약 12% 이상 향상된 수치이며, Random Forest(0.387)와 LightGBM(0.383)을 크게 앞선다. XGBoost와 같은 부스팅 알고리즘은 이전 트리가 설명하지 못한 잔차(Residual)를 다음 트리가 순차적으로 학습하는 방식(Sequential Ensemble)을 취하기 때문에 모델의 편향(Bias)을 획기적으로 줄여주며, 결과적으로 데이터의 복잡한 비선형 패턴을 Random Forest보다 더 정교하게 포착할 수 있게 한다. R^2 수치의 차이는 XGBoost가 데이터 내의 신호(Signal)를 가장 효과적으로 추출했음을 시사한다. XGBoost가 기존 Gradient Boosting보다 높은 성능(0.458 vs 0.408)을 보인 핵심 요인은 정규화된 부스팅(Regularized Boosting) 기법에 있다. XGBoost는 목적 함수에 L1(Lasso) 및 L2(Ridge) 정규화 항을 포함하여 모델의 가중치가 지나치게 커지는 것을 방지한다. 이는 훈련 데이터에 대한 과도한 적합을 억제하면서도 테스트 데이터에서 높은 설명력을 유지하게 하는 결정적 요인으로 작용한다. 훈련-테스트 격차(Generalization Gap)와 과적합 분석그래프에서 관찰되는 훈련(Train) 점수와 테스트(Test) 점수 간의 격차는 모델의 과적합 여부를 진단하는 중요한 단서로 활용되는데 XGBoost는 훈련 데이터에서 0.6이 넘는 매우 높은 R^2 를 기록했으나, 테스트에서는 0.458로 하락하였다. 이러한 큰 격차는 일반적으로 과적합의 징후로 해석될 수 있으나 테스트 점수 자체가 타 모델 대비 가장 높다는 점을 고려해야 한다. 이는 XGBoost가 높은 모델 복잡도를

바탕으로 훈련 데이터의 패턴을 공격적으로 학습했으며, 그 과정에서 일부 노이즈까지 학습했음에도 불구하고 일반화 성능의 절대치 역시 끌어올렸음을 의미한다. 즉, '과적합'이라기보다는 '높은 학습 능력'으로 해석하는 것이 타당하다.

Random Forest 역시 훈련 점수(0.58)와 테스트 점수(0.387) 간의 차이가 존재한다. Random Forest는 배깅(Bagging) 방식을 통해 분산(Variance)을 줄이는 데 특화되어 있어 과적합에 강하다는 이론적 특성에도 불구하고, 테스트 성능이 부스팅 계열보다 낮게 나타났다. 이는 Random Forest가 개별 트리의 편향(Bias)을 줄이는 데에는 한계가 있음을 보여준다. 즉, 데이터 자체가 높은 비선형성을 내포하고 있어 배깅만으로는 최적의 적합도에 도달하지 못한 상태일 가능성이 높다. 성능 원인 분석중에서 가장 의외의 결과는 LightGBM이 0.383으로 가장 낮은 R^2 를 기록했다는 점이다. 일반적으로 LightGBM은 XGBoost와 대등하거나 더 나은 성능을 보이면서도 속도가 빠른 것으로 알려져 있다. 그러나 LightGBM은 리프 중심(Leaf-wise) 트리 분할 방식을 사용하여 손실을 빠르게 줄이지만, 이는 데이터 수가 적거나 깊이(Depth) 제어가 되지 않을 경우 과적합 위험이 있기 때문에 성능이 가장 낮게 나온 것으로 판단된다. 본 실험의 훈련 데이터 R^2 가 약 0.45 수준으로 타 모델 대비 낮게 형성된 것을 볼 때, LightGBM은 훈련 데이터조차 충분히 학습하지 못한 과소적합(Underfitting) 상태이거나, 혹은 하이퍼파라미터(num_leaves, max_depth) 튜닝이 해당 데이터셋의 특성에 맞게 최적화되지 않았을 가능성이 큰 것으로 보인다. 특히 데이터셋의 크기가 충분히 크지 않다면 Leaf-wise 방식은 Level-wise 방식(XGBoost)보다 불안정한 결과를 초래할 수 있다

RMSE 그래프에서 XGBoost는 20 미만의 수치를 기록하며, 타 모델(모두 20.7 이상) 대비 유의미하게 낮은 오차를 보였다. 이는 XGBoost의 목적 함수가 2차 미분(Hessian) 정보를 활용하여 최적화를 수행하기 때문이다. 제곱 오차를 최소화하는 방향으로 학습이 진행되므로, 예측값이 실제값에서 크게 벗어나는 대형 오차를 억제하는 데 탁월한 성능을 나타내기 때문이다. 결과적으로 XGBoost는 예측의 안정성 측면에서 가장 신뢰할 수 있는 모델임을 입증한다. Random Forest는 21.147의 높은 RMSE를 기록했다. 이는 평균화(Averaging) 과정이 전반적인 분산은 줄여주지만, 개별 트리가 범하는 큰 오차들을 부스팅만큼 정교하게 보정하지 못함을 시사한다(Figure 3.4).




Figure 3.4. Root Mean Square Error of machine learning models for rainfall product.

MAE는 오차의 절대값을 평균 낸 것으로, 이상치에 덜 민감하며 전체적인 오차의 중앙값 성격을 나타낸다. MAE 지표에서는 Gradient Boosting (5.655)이 XGBoost (5.66)보다 미세하게 앞서거나 대등한 모습을 보인다. 이는 Gradient Boosting이 이상치(RMSE에 영향을 주는 요소)를 잡는 능력은 XGBoost보다 떨어지지만(RMSE 20.788 vs 19.9), 대다수의 데이터 포인트들에 대해서는 매우 정확한 예측을 수행하고 있음을 의미한다(Figure 3.5).




Figure 3.5. The MAE value for rainfall from the machine learning models.

XGBoost는 이번 분석에서 좋은 성능을 나타내었다. R^2 은 0.458이라는 수치는 기계학습 모델에서 특히 노이즈가 많은 강수량 데이터셋에서는 비교적 좋은 결과값을 나타낸다. XGBoost의 Level-wise 트리 성장 방식은 트리의 균형을 유지하며 깊이를 제어하므로, LightGBM의 Leaf-wise 방식보다 적은 데이터셋이나 노이즈가 많은 데이터셋에서 더 안정적인 성능을 보인다. learning rate와 gamma와 같은 파라미터가 오차에서의 최적해 탐색을 효과적으로 도왔을 것으로 판단된다. 훈련 데이터 점수와 테스트 점수의 격차가 가장 크다는 점은 여전히 경계해야 한다. 이는 향후 max_depth를 줄이거나 subsample 비율을 낮추는 식의 추가적인 하이퍼파라미터 튜닝을 통해 일반화 성능을 더 끌어올릴 여지가 있음을 나타낸다. Gradient Boosting은 견고한 라이브러리인 Scikit-learn의 기본 GBM으로 이 모델은 MAE에서 1위, R^2 에서 2위를 기록하며 매우 견고한 성능을 보여주었다. 이 모델은 기본적인 부스팅 원리만으로도 Random Forest의 배깅 방식을 압도했다. 이는 데이터가 편향(Bias)을 줄이는 것이 분산(Variance)을 줄이는 것보다 더 중요한 구조임을 알수 있다. 그러나 정규화 부재와 1차 미분 기반의 최적화로 인해 RMSE에서는 XGBoost에 정확도가 떨어진다. 그러나 구현의 단순성 대비 성능 효율은 매우 뛰어나다.

Random Forest은 안정적이거나 정밀도 부족으로 테스트 결과값에서 R^2 0.387로 정확도가 세 번째에 머물렀다. Random Forest는 데이터의 차원이 높거나 희소한 경우, 또는 결정 경계가 매우 복잡한 경우 부스팅 계열보다 성능이 떨어지는 경향이 있다. 개별 트리가 독립적으로 학습되므로, 강수량처럼 특정 데이터 포인트의 미세한 패턴을 집요하게 학습하는 부스팅의 능력을 따라가지 못했다. 그러나 Random Forest는 하이퍼파라미터 튜닝 없이도 준수한 성능을 내는 것으로 유명하기 때문에 본 연구에서도 최악의 성능은 면했으며, 과적합 격차가 부스팅보다 상대적으로 작다는 점에서 안정성이 요구되는 모델에서는 여전히 유효하다는 것을 알수 있다.

LightGBM은 본 실험에서 가장 낮은 성능(R^2 0.383, RMSE 21.213)을 나타내었다. LightGBM은 대용량 데이터셋에서 XGBoost와 대등한 성능을 내면서 속도는 훨씬 빠른 것이 보편적인데 데이터셋의 크기가 작을 경우 Leaf-wise 성장은 과적합을 유발하기 쉽다는 볼 수 있다. 본 연구가 제주도 지역만을 대상으로 하였기 때문에 데이터 학습수가 적을 수 있어서 향후 한반도 전역에 대해서는 다른 결과를 보여줄 수도 있을 것이다. 본 연구에서는 LightGBM이 데이터의 노이즈에 과민 반응했거나, 반대로 훈련 자체가 충분히 수렴하지 못했을 가능성을 보여준다. 특히 훈련 R^2 자체가 낮은 것으로 보아, 모델 복잡도가 강수량 데이터의 패턴을 충분히 학습하지 못했을 것으로 판단된다. 향후 연구에서는 XGBoost의 학습결과와 테스트 결과와의 오차를 줄이기 위해 gamma, alpha, lambda와 같은 파라미터를 조정할 필요성이 있으며, XGBoost와 Gradient Boosting의 예측 결과가 상호 보완적일 가능성이 있기 때문에, 두 모델의 예측값을 가중 평균(Weighted Averaging)하는 스택킹(Stacking)기법을 도입한다면 보다 높은 성능을 보일 것으로 판단된다.

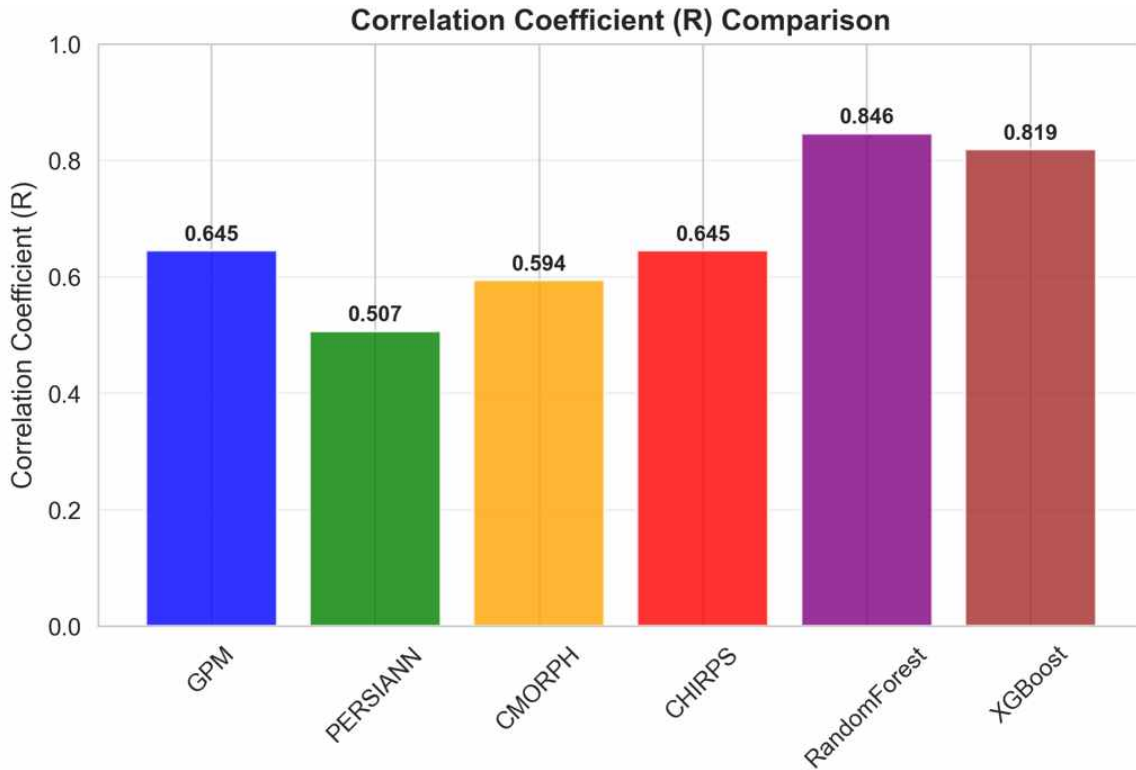


Figure 3.6. Correlation coefficient comparison with satellite precipitation estimation and rainfall of machine learning models.

제공된 Figure 3.6의 상관계수(Correlation Coefficient, R) 비교 차트와 Figure 3.7의 오차 (RMSE, MAE) 비교 차트는 원본 위성 강수 산출물(GPM, PERSIANN, CMORPH, CHIRPS) 간의 성능 격차를 명확하게 보여준다. 각 산출물은 고유의 센서 조합과 알고리즘을 사용하기 때문에, 오차의 패턴과 그 원인 또한 상이하게 나타난다. 분석 결과, GPM IMERG는 상관계수 $R = 0.645$, $RMSE = 28.5$ mm, $MAE = 7.1$ mm의 성능을 기록하였다. 이는 비교군 중 CHIRPS와 함께 가장 높은 상관계수를 보이며, 강수의 시공간적 패턴을 탐지하는 능력(Probability of Detection)이 우수함을 시사한다. 그러나 동시에 높은 RMSE 값은 강수량의 절대적인 크기 추정에 있어 상당한 오차, 특히 과대추정 경향이 있음을 암시한다. GPM IMERG는 기본적으로 마이크로파 (PMW) 센서에 의존도가 높은 알고리즘을 사용한다. PMW 센서는 구름 내부의 빗방울이나 얼음 입자에 의한 산란(Scattering) 및 방출(Emission) 신호를 직접 감지하기 때문에, 구름 꼭대기 온도만을 측정하는 적외선(IR) 센서보다 물리적으로 강수와 더 직접적인 연관성을 가진다. 이로 인해 GPM은 강수 발생 유무를 판단하는 데 있어 타 산출물 대비 우수한 성능을 보인다. 그럼에도 불구하고 28.5 mm라는 높은 RMSE가 발생하는 주된 원인은 과대추정(Overestimation) 경향 때문이다. 특히 내륙 지역의 여름철 대류성 강수(Convective Rain) 시, 얼음 입자에 의한 강한 산란 신호를 위성이 과도하게 해석하여 실제보다 많은 강수량을 산출하는 경우가 많다. 또한, 위성의 공간 해상도(0.1도) 내에서 강수 강도의 불균일성(Sub-pixel inhomogeneity)으로 인해 발생하는 'Beam-filling error' 역시 오차를 증폭시키는 요인으로 작용한다.

CHIRPS는 $R = 0.645$ 로 GPM과 동일한 수준의 높은 상관성을 보였으며, $RMSE = 27.8$

mm로 원본 위성 산출물 중 가장 낮은 오차를 기록하였다. 이는 CHIRPS가 위성 기반 적외선 데이터(Cold Cloud Duration)와 장기간의 지상 관측 기후값(CHPclim), 그리고 이용 가능한 지상 관측소 데이터를 결합(Blending)하여 생성된 제품이기 때문이다. 지상 관측소 데이터가 알고리즘에 통합되어 있기 때문에, 위성 단독 산출물(GPM, CMORPH 등)에 비해 편의(Bias)가 보정되어 나타나는 경향이 있다. 이는 RMSE가 타 산출물 대비 상대적으로 낮게 측정된 결과(27.8 mm vs 31.1 mm for PERSIANN와 일치한다. 그러나 CHIRPS는 적외선 센서에 크게 의존하기 때문에, 적란운(Cumulonimbus)과 같이 구름 정상부가 매우 차가운 경우에는 강수량을 잘 포착하지만, 구름 정상부가 상대적으로 따뜻한 층운형 강수(Stratiform Rain)나 따뜻한 비(Warm Rain)에 대해서는 탐지 능력이 떨어진다. 또한, 지상 관측소가 희소한 지역에서는 위성 데이터의 가중치가 높아져 오차가 다시 증가하는 경향을 보인다. 제공된 결과에서 GPM과 동일한 R 값을 보인 것은, 분석 대상 지역의 지상 관측소 밀도나 강수 특성이 CHIRPS의 보정 효과를 극대화하지 못했거나, 반대로 GPM의 마이크로파 탐지 능력이 CHIRPS의 지상 보정 효과만큼 강력했음을 나타낸다.

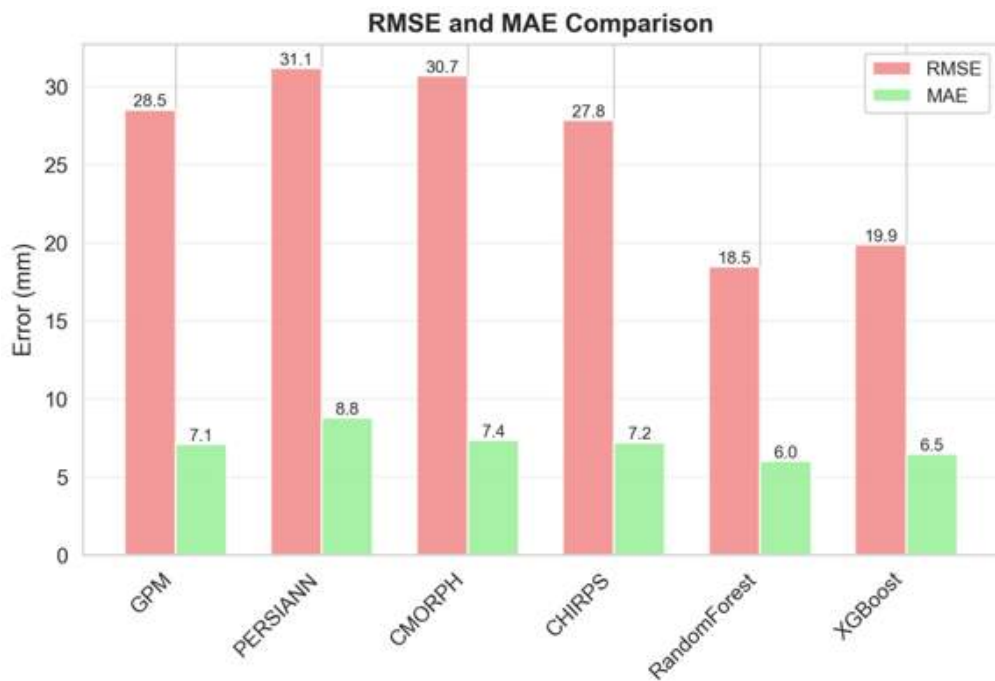


Figure 3.7. The RMSE and MAE comparison with satellite precipitation estimation and rainfall by machine learning models.

CMORPH는 $R = 0.594$, $RMSE = 30.7$ mm, $MAE = 7.4$ mm의 성능을 보였다. 이는 GPM이나 CHIRPS에 비해 상관계수가 다소 낮고 오차는 높은 수준이다. CMORPH는 저궤도 위성의 마이크로파 강수 추정치를 정지궤도 위성의 적외선 영상에서 추출한 구름 이동 벡터(Cloud Motion Vector)를 따라 이동(Morphing)시키는 방식을 사용한다. 이 방식은 마이크로파 관측 공백을 메우는 데 효과적이지만, 구름의 이동과 강수 시스템의 발달/소멸 과정이 일치하지 않을 때 큰 오차를 유발할 수 있다. 특히 강수 시스템이 빠르게 생성되거나 소멸하는 경우, 모핑 알고리즘은 이를 실시간으로 반영하지 못하고 단순히 강수 영역을 이동시키기만 하므로, 강수의 위치나 타이밍에서 오차가 발생한다. R값이 0.6 미만으로 떨어진 것은 이러한 시간적 불일치가 원인일 가능성이 크다. 또한, CMORPH는 강우 강도가 약한 경우에 대해서는 비교적 정확하지

만, 극한 강우 사상에 대해서는 과소평가하는 경향이 있어 RMSE를 증가시키는 요인이 된다.

PERSIANN은 $R = 0.507$, $RMSE = 31.1$ mm, $MAE = 8.8$ mm로 4가지 산출물 중 가장 저조한 성능을 기록하였다. 특히 상관계수가 0.5 수준에 머물렀다는 것은 PERSIANN이 강수의 패턴을 설명하는 데 있어 상당한 불확실성을 내포하고 있음을 의미한다. PERSIANN은 주로 적외선(IR) 밝기 온도와 인공신경망을 이용하여 강수를 추정한다. 문제는 차가운 구름은 많은 양의 강수량을 동반하는 기본 가정이 항상 성립하지 않는다는 점이다. 높은 고도의 권운(Cirrus)은 온도가 매우 낮지만 비를 내리지 않으며, 반대로 해양성 온난 구름은 온도가 높지만 많은 비를 내릴 수 있다. 이러한 물리적 관계의 모호성이 PERSIANN의 낮은 탐지율과 높은 오차로 나타나고 있다. 건조한 지역이나 고산 지대에서는 지표면의 복사열이나 눈 덮인 지형이 적외선 센서에 의해 구름으로 오인되는 경우가 많아 False Alarm이 증가하며, 이는 전체적인 정확도를 떨어뜨리는 주요 원인이 되고 있다.

원시 위성 데이터의 한계를 극복하고 원시 위성데이터들의 높은 강수량일 때 과소추정하는 경향을 극복하기 위해 적용된 기계학습 모델(Random Forest, XGBoost)은 통계적 지표 전반에서 획기적인 성능 향상이 있었음을 보여준다. 이는 기계학습이 위성 데이터의 비선형적 오차 특성을 효과적으로 학습하고 보정할 수 있음을 입증한다. 본 연구 결과에서 Random Forest(RF)는 $R = 0.846$, $RMSE = 18.5$ mm, $MAE = 6.0$ mm를 기록하며, 원본 데이터 및 비교 모델(XGBoost)을 통틀어 가장 우수한 성능을 달성하였다. 원시 위성 데이터 중에서 가장 성능이 우수했던 GPM/CHIRPS(0.645) 대비 약 31% 향상된 0.846을 기록하였다. 이는 RF 모델이 강수의 시간적 변동성과 공간적 분포 패턴을 실제 관측값에 매우 근접하게 모의하고 있음을 의미한다. Random Forest는 다수의 의사결정나무(Decision Tree)를 생성하고 이를 평균(Averaging)하여 예측하는 앙상블 기법이다. 이 과정에서 개별 나무(Tree)들이 가질 수 있는 과적합(Overfitting) 위험이 상쇄되고, 데이터의 잡음에 robust해지는 특성이 있다. 위성 강수 데이터는 센서 오차, 대기 효과 등으로 인해 잡음이 많은 데이터(Noisy Data)에 속하는데, RF의 분산 감소(Variance Reduction) 효과가 이러한 데이터 특성과 잘 맞아떨어져 가장 안정적이고 높은 성능을 낸 것으로 해석된다. 특히 Figure 3.7에서 RF가 가장 낮은 RMSE를 보인 것은 큰 오차를 억제하는 능력이 탁월함을 시사한다.

XGBoost는 $R = 0.819$, $RMSE = 19.9$ mm, $MAE = 6.5$ mm를 기록하여, RF에 이어 우수한 성능을 보였다. 비록 본 연구의 특정 데이터셋에서는 RF보다 소폭 낮은 성능을 보였으나, 원시 위성 데이터 대비 괄목할 만한 성능 개선이 있었다. XGBoost는 이전 단계의 나무가 범한 오차(Residual)를 다음 단계의 나무가 순차적으로 학습하여 보정하는 부스팅(Boosting) 방식이다. 이는 모델의 편의(Bias)를 줄이는 데 매우 효과적이다. 일반적인 문헌 연구에서는 XGBoost가 RF보다 우수한 성능을 보이는 경우가 많다. 이는 XGBoost가 경사 하강법(Gradient Descent)과 정규화(Regularization) 항을 사용하여 복잡한 비선형 관계를 더 정교하게 모델링하기 때문이다. 그러나 본 결과에서 RF가 더 우수하게 나타난 이유는 두 가지로 추론해볼 수 있다. 강수 데이터에 노이즈가 극심한 경우, 부스팅 계열 모델은 노이즈까지 과도하게 학습(Overfitting)하여 오히려 일반화 성능이 떨어질 수 있다. 반면 RF는 배깅(Bagging)을 통해 노이즈를 평탄화하므로 더 유리할 수 있다. XGBoost는 학습률(Learning Rate), 트리 깊이, 정규화 파라미터 등에 매우 민감하다. 최적의 튜닝이 이루어지지 않았을 경우, 기본 설정(Default)에서도 강력한 성능을 내

는 RF가 좀 더 나은 성능을 낼 수 있었다. 그럼에도 불구하고 R값이 0.819에 달한다는 것은 XGBoost 역시 위성 강수 보정에 있어 매우 강력한 도구임을 입증한다. 특히 고해상도 데이터나 대용량 데이터 처리 속도 면에서는 XGBoost가 RF보다 유리하므로, 실시간 운영 시스템 구축 시에는 더 좋은 모델 선택이 될 수 있을 것이다(Table 3.1).

Table 3.1. The results of a statistical analysis from rainfall of machine learning models and satellite precipitation products.

Product	Type	R	RMSE(mm)	MAE(mm)
Random Forest	machin learning	0.846	18.5	6.0
XGBoost	machin learning	0.819	19.9	6.5
GPM	satellite rainfall	0.645	28.5	7.1
CHIRPS	satellite rainfall	0.645	27.8	7.2
CMORPH	satellite rainfall	0.594	30.7	7.4
PERSIANN	satellite rainfall	0.507	31.1	8.8

GPM, CMORPH, PERSIANN, CHIRPS 등 원시 위성 데이터에서 RMSE와 MAE의 격차가 큰 것은, 이들 모델이 대부분의 경우 적절한 값을 내다가도 간혹 폭우 시 엄청난 과대평가를 하거나, 강수 발생 자체를 놓치는(Miss) 등의 대형 오차를 범하고 있음을 시사한다. 특히 강수 데이터는 '0'이 많은(Zero-inflated) 특성과 오른쪽으로 긴 꼬리를 가진(Right-skewed) 분포를 가지므로, 이러한 현상이 더욱 두드러진다. RF와 XGBoost를 적용했을 때, MAE는 약 7~8 mm에서 6 mm 수준으로 20~30% 감소한 반면, RMSE는 약 30 mm에서 18~20 mm 수준으로 30~40% 감소하였다. 즉, 기계학습 모델은 단순한 평균적인 오차를 줄이는 것뿐만 아니라, 극치를 줄이는데 더욱 탁월한 효과를 보였다. 이는 기계학습 모델이 강수의 유무 판별(Classification) 능력을 향상시켜 허위 경보(False Alarm)를 줄이고, 강수 강도 추정(Regression) 단계에서 극치에서 과소추정하는 것의 정확도를 향상시켰기 때문으로 분석된다.

제주도 지역과 같은 복잡한 지형에서는 위성 강수 산출물의 정확도가 급격히 떨어진다. 눈이나 얼음으로 덮인 지표면은 마이크로파 산란 신호를 교란시켜 GPM 등이 강수를 과소평가하게 만들거나, 지표면의 낮은 온도가 적외선 센서에 의해 구름으로 오인되어 PERSIANN이 과대추정하게 만들기도 한다. 기계학습 모델(특히 XGBoost)은 고도(Elevation), 경사도(Slope) 등의 지형 변수를 입력받아 이러한 지형적 편의를 보정 할 수 있다. 연구 결과에서 기계학습 모델의 성능이 월등히 높은 이유는 이러한 지형적 오차 요인을 효과적으로 보정했기 때문일 것으로 판단된다. 강수 보정 성능은 계절에 따라 다르게 나타날 수 있다. 일반적으로 여름에는 강수량이 많아 RMSE가 절대적으로 커지는 경향이 있으나, 강수 패턴이 뚜렷하여 상관계수(R)는 높게 나타난다. 반면 겨울철에는 미세한 강수나 강설을 탐지하기 어려워 위성의 탐지율(POD)이 떨어지고 허위 경보(FAR)가 증가한다. Random Forest 모델이 가장 우수한 성능을 보인 배경에는 이러한 계절적 변동성에도 불구하고 과적합 없이 안정적인 예측을 수행하는 앙상블 모델의 특성이 작용했을 것으로 보인다.

기계학습 모델을 적용하지 않은 원본 위성 강수 산출물(CHIRPS, CMORPH, PERSIANN, GPM)은 기계학습 모델 대비 상대적으로 낮은 정확도를 보였으며, 각 산출물의 센서 특성과 알고리즘에 따라 뚜렷한 성능 차이와 오차 패턴을 나타냈다. GPM과 CHIRPS는 위성 산출물 그룹 내에서 가장 우수한 성능의 정확도를 보였다. 두 모델의 상관계수(R)가 0.645로 동일하게 나타났다. GPM은 RMSE=28.495 mm/day, MAE=7.068 mm/day를 기록하였다. GPM은 핵심적인 마이크로파(Active/Passive Microwave) 센서를 탑재하여 구름 내부의 강수 입자를 직접 관측할 수 있는 능력을 갖추고 있다. 이로 인해 강수의 물리적 구조를 파악하는 능력은 타 위성 산출물 대비 가장 우수하며, 이는 CHIRPS와 동등한 높은 상관계수(R=0.645)로 나타났다. 그러나 GPM IMERG 산출물은 복잡한 지형이나 해안가에서 마이크로파 신호의 지표면 방출률(Emissivity) 혼선으로 인해 오차가 발생할 수 있다. 또한, 저궤도 위성의 방문 주기 간극을 메우기 위해 적외선 데이터를 통한 모핑(Morphing) 기법을 사용하는데, 이 과정에서 발생하는 불확실성이 RMSE를 다소 높이는 원인이 되었을 것으로 분석된다.

CHIRPS는 RMSE=27.835 mm/day, MAE=7.196 mm/day를 기록하여 위성 산출물 중 가장 낮은 오차(RMSE 기준)를 보였다. CHIRPS는 적외선(IR) 위성 정보에 장기간의 지상 관측소 기후 데이터를 결합한 산출물이다. 이러한 지상 관측 자료와의 융합은 위성 관측이 가지는 시스템적 편이를 줄이는 데 결정적인 역할을 하였으며, 결과적으로 GPM보다 낮은 RMSE를 달성하는 요인이 되었을 것으로 판단된다. 산점도 상에서 CHIRPS는 데이터가 다소 퍼져 있는 형태를 보이는데, 이는 지상 관측소가 부족한 지역이나 일 단위(Daily) 이하의 단기 강수 변동성을 포착하는 데에는 여전히 한계가 있음을 보여준다. 특히 적외선 센서 기반이기 때문에 구름 상단 온도가 낮은 차가운 구름에 대해서는 강수를 잘 탐지하지만, 온난 강수에 대한 탐지력은 떨어질 수 있다.

CMORPH는 R=0.594, RMSE=30.661 mm/day, MAE=7.352 mm/day를 기록하여 중간 수준의 성능을 보였다. CMORPH는 마이크로파 강수 추정치를 정지궤도 위성의 적외선 이미지로부터 추출한 구름 이동 벡터를 따라 이동(Morphing)시키는 방식을 사용한다. 이 방식은 강수 시스템의 공간적 이동을 모사하는 데에는 효과적이지만, 위성 관측 사이의 시간 동안 강수 시스템이 발달하거나 소멸(Evolution/Decay)하는 과정을 반영하지 못한다는 구조적 한계를 지닌다. 산점도에서 관측값 대비 과소추정하는 경향이 나타나는데, 이는 강수 시스템의 급격한 발달을 따라 잡지 못해 피크 강수량을 놓치는 현상과 관련이 깊을 것으로 이해된다. 또한, 따뜻한 비(Warm rain)와 같이 마이크로파 센서가 감지하기 어려운 강수 유형에 대해서는 탐지 실패가 발생하여 상관계수를 낮추는 요인으로 작용한다.

PERSIANN은 R=0.507, RMSE=31.147 mm/day, MAE=8.785 mm/day로 분석 대상 중 가장 낮은 성능을 기록하였다. PERSIANN은 주로 정지궤도 위성의 적외선(IR) 밝기 온도(Brightness Temperature)와 강수량 간의 비선형적 관계를 인공신경망으로 학습하여 강수를 추정한다. 그러나 구름이 차가울수록 강수량이 많은 대류성 강수에는 잘 맞지만, 층운형 강수나 온난 강수에는 적용력이 떨어진다. 산점도 분석 결과, 데이터의 분산(Scattering)이 매우 크고, 특히 Y축 방향으로 튀는 과대추정값과 과소추정하는 값이 동시에 많이 관측된다. 높은 구름(Cirrus)을 강수 구름으로 오인하여 발생하는 과대 추정(False Alarm)과, 낮은 구름에서 내리는 비를 감지하지 못하는 과소 추정이 복합적으로 작용하여 RMSE와 MAE를 크게 만들었다(Figure 3.8).

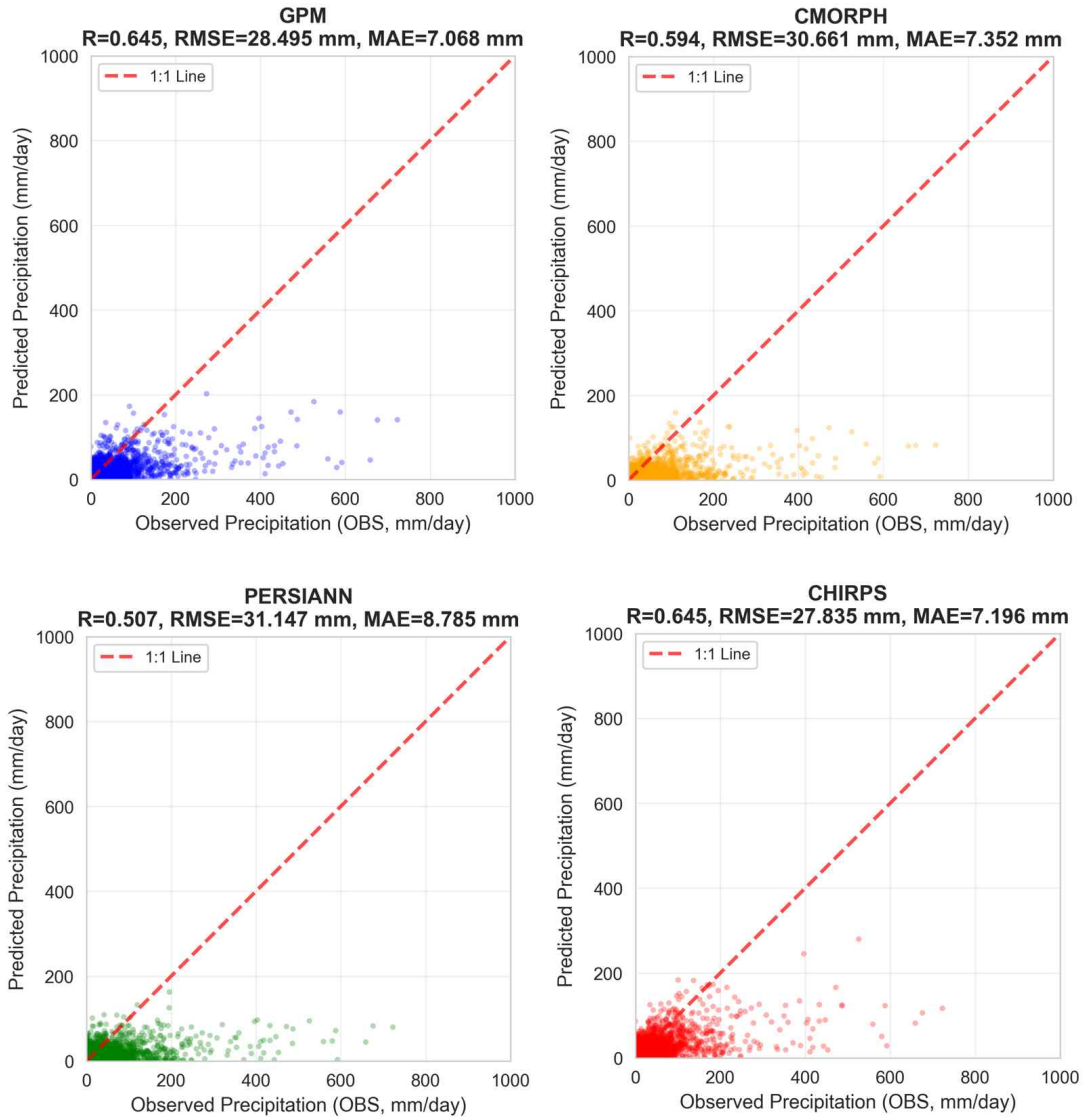


Figure 3.8. The scatterplot of raw satellite rainfall and observed station rainfall.

본 연구에서 적용된 두 가지 기계학습 모델인 Random Forest(RF)와 XGBoost(XGB)는 기존의 위성 강수 산출물 대비 압도적인 성능 향상을 있었음을 알 수 있었다. 이는 위성 데이터가 가지는 비선형적 오차 구조를 기계학습 알고리즘이 효과적으로 학습하여 보정하였음을 나타낸다. Random Forest 모델은 본 연구의 비교 분석에서 가장 우수한 예측 성능을 기록하였다. 산점도 분석 결과, 관측 강수량과 모델 강수량간의 상관관계수(R)는 0.846으로, 비교 대상 모델 중 가장 높은 선형 관계를 나타냈다(Figure 3.9). 또한, 오차의 크기를 나타내는 RMSE는 18.456 mm/day로 가장 낮았으며, MAE 역시 5.997 mm/day로 최소치를 기록하여, 전반적인 강수량 추정의 정확도와 정밀도 좋은 결과를 보였다. Random Forest의 이러한 우수한 성능은 배깅(Bagging) 방식의 앙상블 학습 구조에 기인한다. 다수의 의사결정나무(Decision Tree)를 독립적으로 학습시키고 그 결과를 평균화(Averaging)함으로써, 개별 트리가 가질 수 있는 편향(Bias)과 분산(Variance)을 효과적으로 제어한다. 특히 강수 데이터와 같이 노이즈가 많고 이상치(Outlier)가 빈번한 데이터셋에서 RF의 평균화 메커니즘은 모델의 일반화 성능을 극대화하여,

새로운 데이터에 대해서도 안정적인 예측값을 산출하는 데 기여한 것으로 판단된다. RF모델의 산점도는 1:1 대각선을 중심으로 데이터 포인트들이 매우 밀집된 형태를 보인다. 이는 저강도 강수부터 고강도 강수까지 전 구간에 걸쳐 예측의 일관성이 유지되고 있음을 의미한다. 특히 위성 산출물에서 흔히 나타나는 과대추정이나 많은 강수일 때 과소 추정 패턴이 기계학습을 통해 현저히 성능이 보강되었다. RMSE가 18.456 mm/day라는 것은 일일 강수량 예측에 있어 평균적으로 약 18mm 내외의 오차 범위를 가진다는 것을 의미하며, 이는 수문학적 모델링의 입력 자료로 활용하기에 충분히 유의미한 정확도로 해석된다.

XGBoost 모델은 R=0.819, RMSE=19.856 mm/day, MAE=6.454 mm/day를 기록하며 Random Forest에 이어 두 번째로 우수한 성능을 보였지만 크게 차이가 나지 않았다. 비록 본 강우 데이터셋에서는 RF 대비 다소 낮은 성능 수치를 보였으나, 기존 위성 산출물들과 비교했을 때는 월등히 높은 정확도를 자랑한다. XGBoost는 이전 단계의 트리가 예측하지 못한 잔차(Residual)를 순차적으로 학습하여 오차를 줄여나가는 부스팅(Boosting) 방식을 채택한다. 이 방식은 일반적으로 편향(Bias)을 줄이는 데 탁월한 성능을 발휘하며, 강수 데이터의 희소성과 비정규성을 처리하는 데 강점이 있다. 결과에서 RF보다 약간 높은 RMSE를 기록한 원인은, 부스팅 알고리즘의 특성상 학습 데이터에 존재하는 노이즈까지 과도하게 학습(Overfitting)하려는 경향이 일부 반영되었거나, 하이퍼파라미터 튜닝의 최적화 여지에 따른 차이로 추정된다. 그럼에도 불구하고 XGBoost는 고강도 강수 사상(Extreme Events)에 대한 예측력에서 강점을 보인다. 산점도를 살펴보면, 고강도 구간(High precipitation intensity)에서도 데이터들이 1:1 선을 따라 상승하는 경향을 유지하고 있다. 이는 위성 산출물이 강한 강우 시 신호 감쇠 등으로 인해 값을 과소 평가하는 경향을 XGBoost가 효과적으로 보정하고 있음을 시사한다. 제주도지역과 같은 복잡한 지형에서의 선행 연구에서도 XGBoost는 강수 과소 추정 문제를 50% 이상 개선하는 등 뛰어난 성능을 보인다(Figure 3.9).




Figure 3.9. The scatterplot of rainfall from machine learning models and observed station rainfall.

3.1.3. 산출 알고리즘 활용

원시 위성을 입력자료로 앙상블 트리 기반의 기계학습 알고리즘인 XGBoost(Extreme Gradient Boosting)를 적용하여, 남태평양 도서 국가인 바누아투(Vanuatu)의 복잡한 지형적 특성을 반영한 고해상도 강수 격자자료를 산출하였다(Figure 3.10). 특히 본 연구 결과는 원시 위성강우가 가지는 본질적인 한계점과 산악 지형에서의 과소/과대 추정 및 공간적 평활화(Smoothing) 문제를 XGBoost 모델이 다변량 환경 변수와의 비선형적 관계 학습을 통해 고해상도 자료를 산출하고 데이터베이스를 구축하였다. 향후 구축된 자료는 해외사업의 기후변화 연구 기초자료로 활용될 예정이다.




Figure 3.10 Visualization of precipitation from machine learning model for Vanuatu peninsular.

3.2. 다변수 상세화 기반기술 개발

3.2.1. 공간 데이터 구축

제주도 전역에 대한 정밀한 공간 보간을 수행하기 위해, 기상청이 운영하는 관측망을 활용하여 고해상도 기상 데이터를 수집하고 전처리를 수행하였다. 연구 대상 지역인 제주도는 복잡한 지형으로 인해 기온과 강수량의 공간적 변동성이 매우 크게 나타나는 지역이므로, 이를 반영하기 위해 종관기상관측장비(ASOS) 4개 지점뿐만 아니라 국지적 기상 감시에 특화된 방재 기상관측장비(AWS) 29개 지점을 모두 포함하여 총 33개 지점의 조밀한 관측 데이터를 확보하였다. 분석 기간은 최신 기후 경향을 반영하고 통계적 신뢰성을 확보하기 위해 2020년 1월 1일부터 2024년 12월 31일까지 총 5년(1,827일)으로 설정하였다. 수집된 원시 데이터(Raw Data)에는 기상 장비의 일시적 장애나 통신 오류 등으로 인해 필연적으로 관측값이 누락된 결측 구간이 존재하였다. 이러한 데이터의 불연속성은 시공간 모델링 과정에서 예측 오차를 증폭시키는 주요 원인이 되므로, 엄격한 품질 관리(QC) 과정을 거쳐 결측치 보정(Gap-filling)을 수행하였다. 결측치 보정은 공간적 상관성을 최대한 보존하는 방식으로 진행되었다. 결측이 발생한 시점과 지점에 대해 지리적으로 가장 인접한 유효 관측소의 데이터를 참조하여 값을 대체함으로써 데이터의 공간적 패턴이 왜곡되지 않도록 조치하였다.

기온의 시계열적 변동 특성을 분석한 결과 ASOS 4개 관측 지점(제주:184, 고산:185, 성산:188, 서귀포:189)의 기온 시계열은 Figure 3.1과 같이 매년 뚜렷한 주기성을 가지는 정현파 형태의 연변화 패턴을 보인다. 여름철(7~8월)에는 최고 기온이 30°C에서 35°C에 이르는 고온 현상이 나타나며, 겨울철(1~2월)에는 최저 기온이 -5°C에서 5°C 내외로 하강하는 전형적인 온대 기후의 계절적 특성을 반영하고 있다. 4개 관측 지점 간의 기온 변화 추이는 매우 유사한 동조화 현상을 보이나, 각 지점의 위도와 해발고도 차이에 따라 극값의 미세한 차이가 관찰된다. 이는 Cokriging 기법 적용 시 고도와 같은 지형적 보조 변수가 기온 예측 모델의 설명력을 높이는 중요한 역할을 할 것임을 시사한다.

강수량의 시계열적 분포 특성을 분석한 결과 연속적인 흐름을 보이는 기온과 달리, 강수량은 Figure 3.2와 같이 시간적으로 매우 불연속적이고 간헐적인 분포 특성을 보인다. 시계열 그래프상에서 대부분의 날은 0mm 또는 미량의 강수를 기록하지만, 특정 시점에 강한 스파이크 형태의 강수량이 집중되는 경향이 뚜렷하다. 계절적으로는 장마철과 태풍이 내습하는 여름철(6~9월)에 강수 현상이 집중되며, 일강수량 100mm를 초과하는 극한 강수 사례가 주기적으로 관찰된다. 공간적으로는 기온에 비해 지점 간 변동성이 크게 나타나는데, 이는 제주도의 한라산을 중심으로 한 지형적 효과가 반영된 결과로 해석된다. 따라서 강수량의 공간 보간 시에는 이러한 국지적 변동성과 0값이 많은 데이터 분포 특성을 고려한 모델링 기법 적용이 요구된다.

제주도 내 33개 기상관측지점(ASOS 및 AWS)에 대한 5년(2020~2024)간 일별 평균 데이터를 Figure 3.3과 같이 산출하고, 이를 관측소의 해발고도에 따라 세 가지 구간으로 범주화하여 다중 라인 그래프로 Figure 3.4와 같이 시각화하였다. 고도 구간은 저지대(200m 미만, 적색), 중산간(200m~600m, 녹색), 고지대(600m 이상, 청색)로 구분하여 표시하였으며, 이를 통해 기상 변수의 시계열적 변화와 지형적 특성 간의 상관관계를 직관적으로 파악하고자 하였다.




Figure 3.11. Daily Temperature Time Series for Selected Meteorological Stations in Jeju Island (2020–2024).

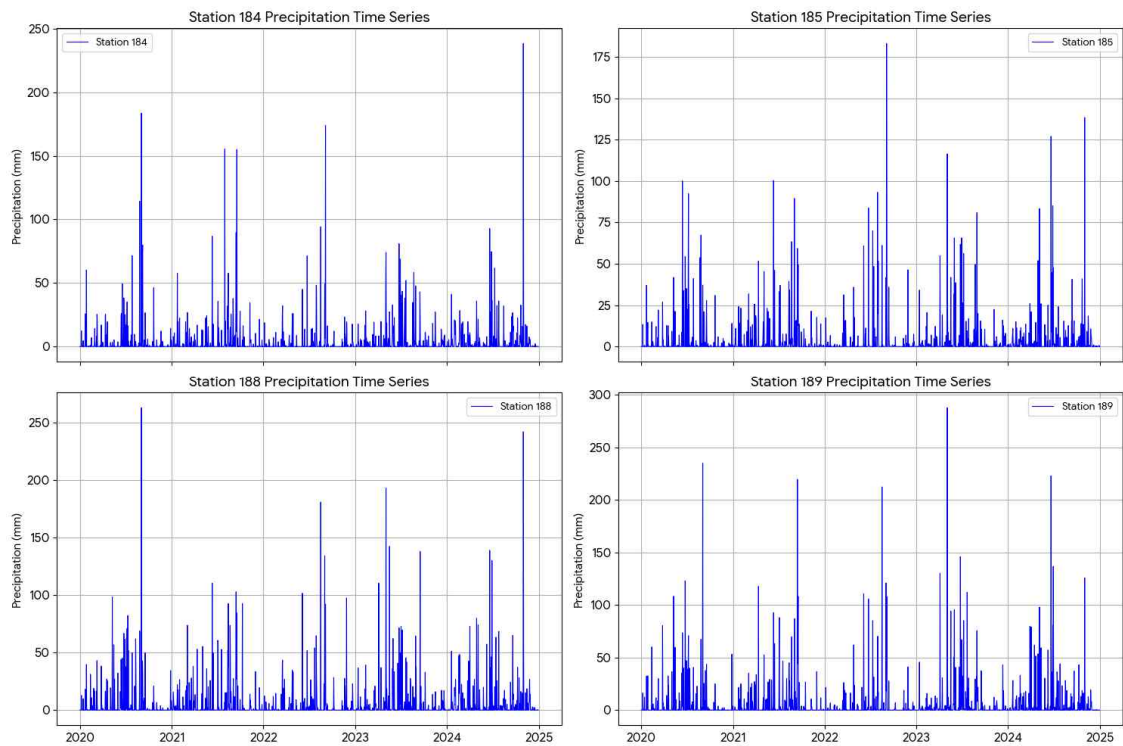


Figure 3.12. Daily Precipitation Time Series for Selected Meteorological Stations in Jeju Island (2020–2024).

고도에 따른 층위 현상과 기온 감률 그래프 분석 결과, 가장 두드러진 특징은 고도 구간 별로 데이터가 뚜렷하게 층을 이루며 분리되는 현상이다.

- 저지대(적색, <200m): 그래프의 최상단에 밀집하여 분포하며, 제주 해안가 및 도심 지역의 온난한 기후 특성을 반영한다. → 20개 지점
- 중산간(녹색, 200~600m): 적색 그래프 하단에 위치하며, 해발고도가 높아짐에 따라 수치가 낮아지는 중간 전이대(Transition Zone)의 특성을 보인다. → 6개 지점
- 고지대(청색, >600m): 그래프의 최하단에 위치하며, 다른 두 그룹과 확연한 격차를 보이며 가장 낮은 값을 기록하고 있다. → 7개 지점




Figure 3.13. Observed Daily Climatology Across All Stations (5-Year Mean).




Figure 3.14. Elevation-Based Variations in Observed Daily Temperature Climatology (5-Year Mean).

3.2.2. 단변수 공간 보간 기법 적용 결과

3.2.2.1. Ordinary Kriging(OK) 기법 적용

제주도 전역(33.14° N~33.61° N, 126.09° E~127.01° E)의 기온 및 강수량 분포를 고해상도로 재현하기 위해 2020년부터 2024년까지 5년간 33개 기상관측지점(ASOS 4개, AWS 29개)의 데이터를 활용하였다. 이 절에서는 공간 보간 기법으로 Ordinary Kriging (OK)을 선정하고 구형(Spherical) 베리오그램 모델(Nugget: 0.01, Sill: 0.3, Range: 0.08)을 적용하여 1km 간격의 정규 격자망을 구축하였다. 이를 통해 관측 공백 지역인 산간 및 해안의 상세 기온 및 강수량 정보를 확보하고 시공간적으로 연속적인 기온장 및 강수장을 생성하였다. 모델의 신뢰성은 Leave-One-Out 교차 검증(LOOCV)을 통해 평가되었다. 먼저 전체 33개 지점 중 1개 지점을 검증용으로 제외하고 나머지 32개 지점을 학습용으로 사용하여 Ordinary Kriging (Spherical Variogram 모델)을 수행하였다. 이 과정을 33회 반복하여 모든 지점에 대한 예측값과 실측값의 오차를 산출하였다.

OK 기법을 통해 생산된 일별 기온 격자 자료를 활용하여 제주도 전역의 기온 분포 특성을 다각도로 시각화하였다. 기온의 시공간적 변동성을 정밀하게 파악하기 위해 분석 단위를 월별(Monthly), 계절별(Seasonal), 그리고 5년 전체 평균(5-Year Mean)으로 세분화하였으며, 각 기간에 대한 평균 기온 분포도를 작성하여 지형적 요인과 계절적 요인이 기온장에 미치는 영향을 분석하였다. 월별(Figure 3.5) 기온 변동성을 보면 1월(최한월)과 8월(최난월)의 기온 분포는 전체적인 패턴은 유사하나, 1월에는 한라산 고지대와 해안가 간의 기온 격차가 더욱 심화되는 경향을 보였다. 반면, 전이 계절인 5월과 10월에는 등온선의 간격이 상대적으로 완만해지는 특성을 보였다. 계절별(Figure 3.6) 기온 변동성을 보면 겨울에는 한라산 중심부의 저온 영역이 가장 넓게 확장되며, 해안과 산간의 기온 경사가 가장 급격하게 나타났다. 여름에는 전체적으로 기온이 상승하여 평탄화된 분포를 보이나, 중산간 지역 이상에서는 여전히 고도에 따른 서늘한 기후 특성이 유지됨을 확인하였다. 봄/가을에는 겨울과 여름의 중간적 성격을 띠며, 점진적인 기온 변화 패턴이 뚜렷하게 나타났다. 5년 평균(Figure 3.7) 기온 분포 특성을 보면 5년(2020-2024) 전체 기간에 대한 평균 기온 분포도 분석 결과, 제주도의 기온은 위도보다는 해발 고도에 의해 지배적인 영향을 받는 것으로 나타났다. 해안 저지대에서 한라산 정상부로 갈수록 기온이 점차 낮아지는 전형적인 기온 감률 효과가 뚜렷한 동심원 형태의 등온선 분포를 보였다. 작성된 기온 분포도는 제주도의 복잡한 지형이 기온 형성에 미치는 지배적인 영향력을 시각적으로 입증하였다. 특히 OK 기법은 관측소가 부재한 산간 및 중산간 영역에 대해서도 주변 관측값의 공간적 상관성을 바탕으로 자연스러운 기온 구매를 모의함으로써, 제주도 전역에 대한 상세한 기후 정보를 제공하였다.

5년 전체 기간에 대한 기온 예측 검증 결과(Table 3.1), 결정계수(R^2)는 약 0.961로 산출되어 모델이 제주도의 복잡한 시공간적 기온 변동성을 96% 이상 설명하는 높은 설명력을 보였다. 예측 오차인 RMSE와 MAE는 각각 1.69°C, 1.37°C로 분석되었다. 연도별 분석 결과, RMSE는 최저 1.62°C(2020년)에서 최고 1.73°C(2022년)의 좁은 범위 내에서 변동하였고, R^2 또한 0.959~0.964의 높은 수준을 유지하였다. 이는 이상 기후 현상 등 외부 요인에도 불구하고 모델

이 일관된 예측 성능을 보임을 입증한다. 계절별 정확도 분석 결과, 대기 상태가 안정적인 5~6월에는 RMSE가 1.20~1.31°C로 가장 낮게 나타난 반면, 겨울철인 12~1월에는 1.91~1.99°C로 다소 증가하는 뚜렷한 계절 변동성을 보였다(Figure 3.8).

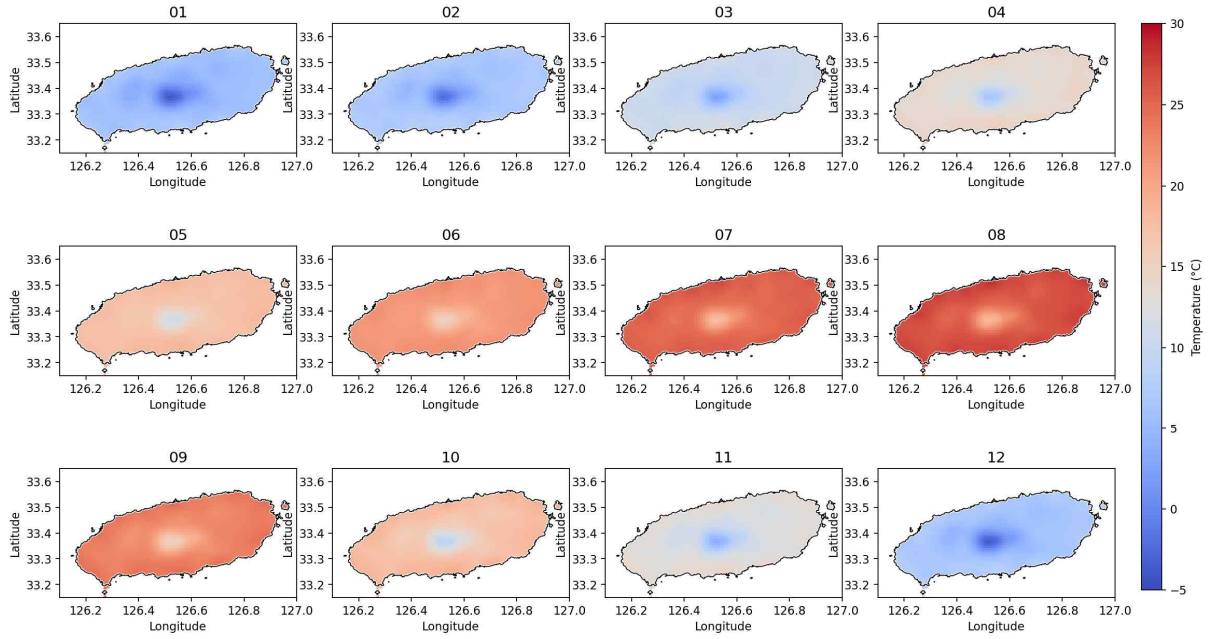


Figure 3.15. Monthly Mean Temperature Distribution (2020-2024) Estimated by OK Model.

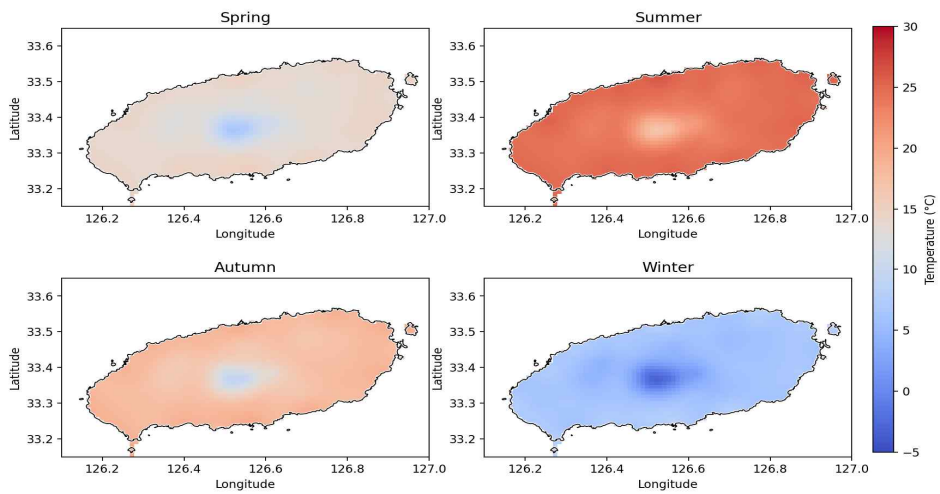


Figure 3.16. Seasonal Mean Temperature Distribution (2020-2024) Estimated by OK Model.




Figure 3.17. Annual Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by OK Model.

Table 3.2. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by OK Model.

Year	RMSE(°C)	MAE(°C)	R ²
2020	1.62	1.31	0.959
2021	1.65	1.33	0.962
2022	1.73	1.39	0.964
2023	1.73	1.40	0.960
2024	1.71	1.40	0.961
Average	1.69	1.37	0.961




Figure 3.18. Monthly Temperature Validation Metrics (OK Model, 2020-2024).

OK 기법을 통해 생산된 일별 강수량 격자 자료를 활용하여, 제주도 전역의 강수 분포 특성을 다각도로 시각화하였다. 강수의 시공간적 변동성을 정밀하게 파악하기 위해 분석 단위를 월별, 계절별, 그리고 5년 연평균 누적으로 세분화하였으며, 각 기간에 대한 누적 강수량 분포도를 작성하여 계절적 요인이 강수장에 미치는 영향을 분석하였다. 월별(Figure 3.9) 강수 변동

성을 보면 장마와 태풍의 영향이 집중되는 여름철(6~9월)과 건조한 겨울철의 강수량 차이가 뚜렷하게 나타났다. 특히 강수량이 많은 7월과 9월에는 한라산 고지대를 중심으로 극대값이 형성되며 해안가와의 강수량 격차가 크게 심화되는 경향을 보였다. 반면, 강수량이 적은 겨울철이나 봄철에는 등강수선의 간격이 상대적으로 넓어지며 지역 간 편차가 다소 완화되는 특성을 보였다. 계절별(Figure 3.10) 강수 변동성 계절별 분포를 보면 여름에는 한라산 중심부 지역에 강수량이 집중되는 전형적인 다우(多雨) 패턴이 나타났다. 겨울(Winter)에는 북서 계절풍의 영향으로 북부와 산간에 강수(설)가 유입되는 반면, 한라산 남쪽 지역은 상대적으로 강수량이 적게 나타났다. 봄/가을(Spring/Autumn)은 건기와 우기의 전이 구간으로서, 점진적인 강수 패턴의 변화가 확인되었다. 5년 연평균 누적(Figure 3.11) 강수량 분포 특성을 보면 제주도의 강수는 위도보다는 해발고도와 지형에 의해 지배적인 영향을 받는 것으로 나타났다. 해안 저지대에서 한라산 정상부로 갈수록 강수량이 점차 증가하는 전형적인 지형성 강수 효과가 나타났다. 작성된 강수량 분포도는 제주도의 복잡한 지형이 강수 형성에 미치는 지배적인 영향력을 시각적으로 입증하였다.

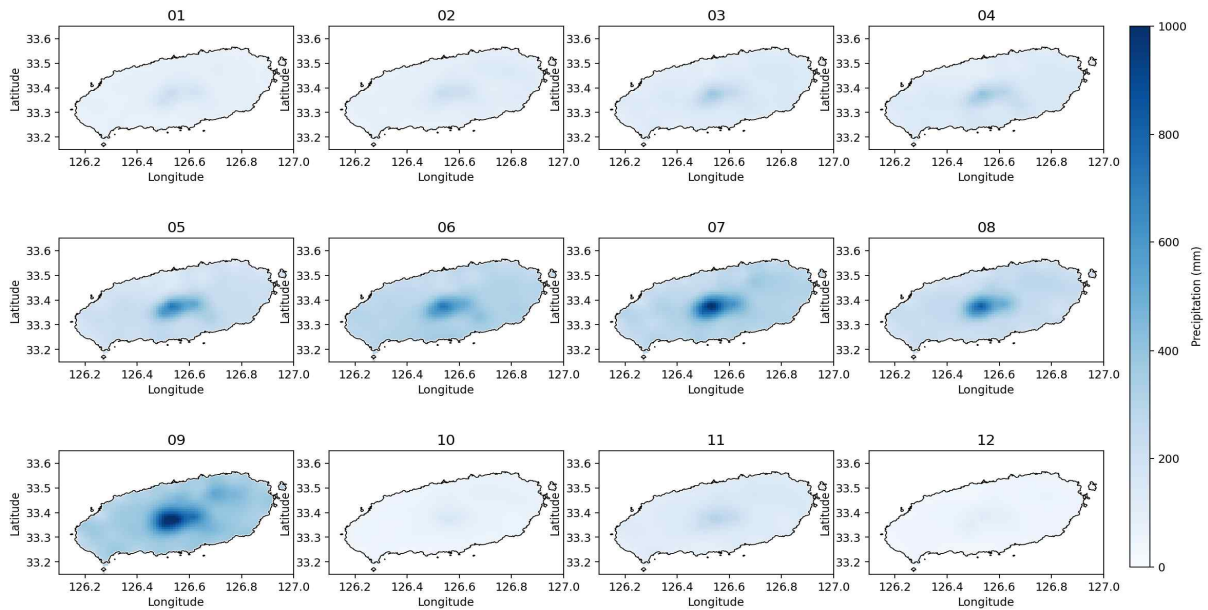


Figure 3.19. Monthly Cumulative Precipitation Distribution (2020-2024) Estimated by OK Model.

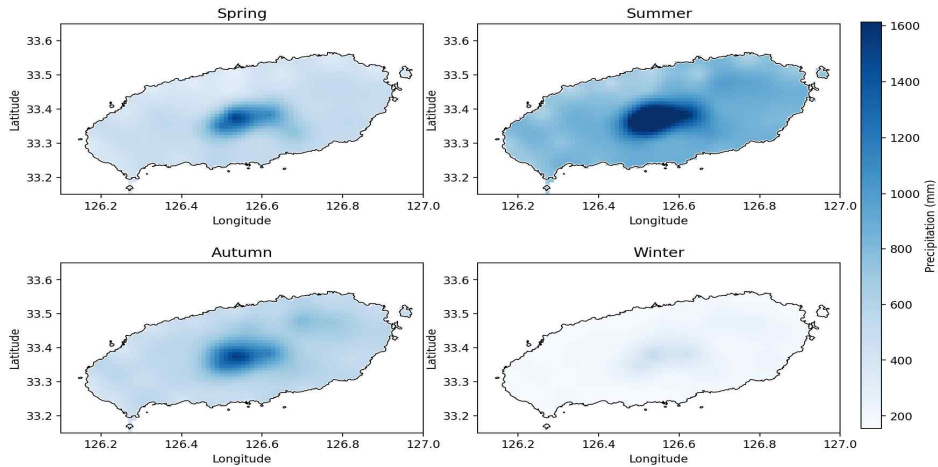


Figure 3.20. Seasonal Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by OK Model.

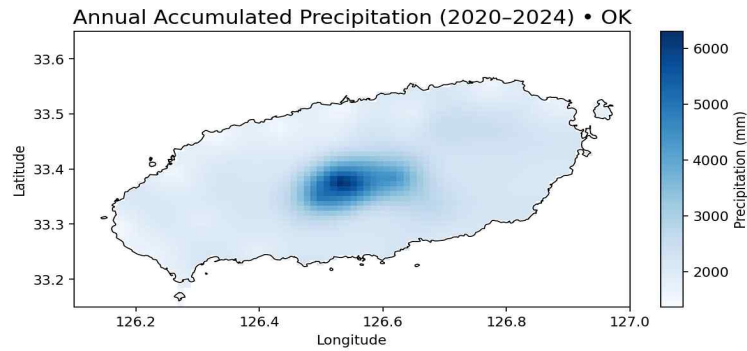


Figure 3.21. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by OK Model.

5년 전체 기간에 대한 강수 예측 검증 결과(Table 3.2), 결정계수(R^2)는 약 0.835로 산출되어 모델이 제주도의 복잡한 시공간적 강수 변동성을 83% 이상 설명하는 준수한 설명력을 보였다. 예측 오차인 RMSE와 MAE는 각각 13.97mm, 5.37mm로 분석되었다. 연도별 분석 결과, RMSE는 최저 12.33mm(2022년)에서 최고 15.76mm(2020년)의 범위 내에서 변동하였고, R^2 또한 0.794~0.870의 수준을 유지하였다. 이는 연도별 강수 패턴과 강도의 차이에도 불구하고 모델이 비교적 일관된 예측 성능을 보임을 입증한다. 계절별 정확도 분석 결과, 강수량이 상대적으로 적고 안정적인 10월과 12월에는 RMSE가 5.27~5.84mm로 가장 낮게 나타난 반면, 집중 호우와 태풍의 영향이 잦은 5월과 9월에는 22.34~24.09mm로 크게 증가하는 뚜렷한 계절 변동성을 보였다(Figure 3.12).

Table 3.3. Annual Validation Metrics for Precipitation Interpolation (2020–2024) Estimated by OK Model.

Year	RMSE (mm)	MAE (mm)	R ²
2020	15.76	5.88	0.866
2021	13.63	5.81	0.807
2022	12.33	4.35	0.870
2023	14.22	5.53	0.794
2024	13.92	5.26	0.837
Average	13.97	5.37	0.835




Figure 3.22. Monthly Precipitation Validation Metrics (OK Model, 2020–2024).

3.2.2.2. Inverse Distance Weighting (IDW) 기법 적용

이 절에서는 공간 보간 기법으로 역거리가중법(Inverse Distance Weighting, IDW)을 선정하고, 관측 지점과 예측 지점 간의 거리에 반비례하는 가중치를 적용하여 1km 간격의 정규 격자망을 구축하였다. 이를 통해 관측 공백 지역인 산간 및 해안의 상세 기온 및 강수량 정보를 확보하고 시공간적으로 연속적인 기온장 및 강수장을 생성하였다. IDW 모델의 신뢰성은 마찬가지로 교차 검증(LOOCV)을 통해 평가되었다.

IDW 기법을 적용하여 제주도의 기온 분포 특성을 시각화한 결과, 한라산 고도 상승에 따라 기온이 낮아지는 동심원 형태의 등온선 구조가 관찰되었다(Figure 3.13). 이러한 지형 및 고도에 따른 기온의 공간적 분포 양상은 OK 기법의 분석 결과와도 일치한다. IDW 기법을 적용한 기온 분포도는 관측소가 없는 산간 및 중산간 지역에 대해 거리 반비례 가중치를 통해 기온 구배를 모의함으로써 상세한 기후 정보를 제공하였다. 그러나 5년 평균 기온 분포도에서 관측소를 중심으로 등온선이 고립된 동심원 형태를 띠는 ‘황소 눈 효과(Bull’s-eye Effect)’가 관찰되었다. 이는 거리가 가까울수록 가중치가 급격히 증가하는 IDW 기법의 고유한 특성 때문이다. 베리오그램을 통해 공간적 상관성을 고려하여 등온선을 부드럽게 연결하는 OK 기법과

달리, IDW 기법은 단순 거리 인접성에 의존함에 따라 지형적 연속성보다는 다소 인위적이고 불연속적인 분포 패턴을 나타내는 한계를 보였다.

5년 전체 기간에 대한 기온 예측 검증 결과(Table 3.3), 결정계수(R^2)는 약 0.951로 산출되어 모델이 제주도의 복잡한 시공간적 기온 변동성을 95% 이상 설명하는 높은 설명력을 보였다. 예측 오차인 RMSE와 MAE는 각각 2.14°C, 1.55°C로 분석되었다. 연도별 분석 결과, RMSE는 최저 2.07°C(2020년)에서 최고 2.19°C(2024년)의 범위 내에서 변동하였고, R^2 또한 0.948~0.955의 높은 수준을 유지하였다. 이는 이상 기후 현상 등 외부 요인에도 불구하고 모델이 일관된 예측 성능을 보임을 입증한다. 월별 정확도 분석 결과(Figure 3.14), 대기 상태가 안정적인 5~6월에는 RMSE가 1.76~1.83°C로 가장 낮게 나타난 반면, 겨울철인 12~1월에는 2.42~2.54°C로 다소 증가하는 뚜렷한 계절 변동성을 보였다.




Figure 3.23. Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by IDW Model.

Table 3.4. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by IDW Model.

Year	RMSE(°C)	MAE(°C)	R^2
2020	2.07	1.49	0.948
2021	2.10	1.51	0.952
2022	2.17	1.58	0.955
2023	2.17	1.58	0.949
2024	2.19	1.59	0.949
Average	2.14	1.55	0.951




Figure 3.24. Monthly Temperature Validation Metrics (IDW Model, 2020-2024).

IDW 기법을 이용하여 2020년부터 2024년까지 제주도의 강수량 분포를 분석한 결과(Figure 3.15), 강수량 역시 위도보다는 해발고도에 지배적인 영향을 받는 것으로 나타났다. 해안에서 한라산 정상으로 갈수록 강수량이 증가하는 전형적인 지형성 강수 효과와, 남풍 기류의 강제 상승으로 인해 남부 지역이 북부보다 많은 비가 내리는 특성이 확인되었다. 그러나 분포도상에서 관측소를 중심으로 등강수선이 고립된 동심원 형태를 그리는 ‘황소 눈 효과’가 기온 분석과 마찬가지로 뚜렷하게 관찰되었다. 이는 거리에 따른 가중치만을 적용하는 IDW 기법의 한계로, 지점 간 강수량의 자연스러운 공간적 연속성보다는 관측 지점 주변에 국지적인 왜곡이 발생함을 시사한다.

5년 전체 기간에 대한 강수 예측 검증 결과(Table 3.4), 결정계수(R^2)는 약 0.833으로 산출되어 모델이 제주도의 복잡한 시공간적 강수 변동성을 83% 이상 설명하는 준수한 설명력을 보였다. 예측 오차인 RMSE와 MAE는 각각 14.82mm, 5.08mm로 분석되었다. 연도별 분석 결과, RMSE는 최저 13.49mm (2021년)에서 최고 16.72mm (2020년)의 범위 내에서 변동하였고, R^2 또한 0.813~0.871의 수준을 유지하였다. 월별 정확도 분석 결과(Figure 3.16), 강수량이 상대적으로 적고 안정적인 12월과 10월에는 RMSE가 5.03~5.48mm로 가장 낮게 나타난 반면, 집중 호우와 태풍의 영향이 잦은 5월과 9월에는 24.11~26.58mm로 크게 증가하는 뚜렷한 계절 변동성을 보였다. 여름철과 초가을의 국지적이고 폭발적인 강수 패턴은 공간적 불확실성을 심화시키는 요인으로 작용하였다. IDW 분석 결과, 한라산 지형에 의한 강제 상승 효과가 반영되어 산간 지역의 다우지 패턴은 명확히 재현되었으나, 관측소 밀도가 낮은 지역에서는 거리 기반 가중치의 한계로 인해 ‘황소 눈 효과’가 나타나 국지적인 패턴 왜곡이 발생함을 확인하였다.

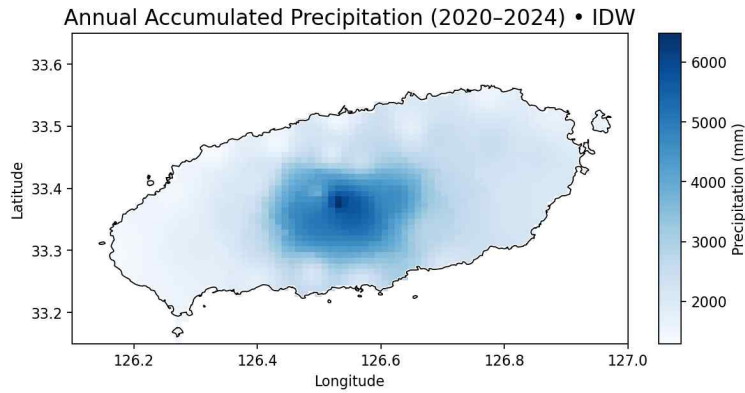


Figure 3.25. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by IDW Model.

Table 3.5. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by IDW Model.

Year	RMSE(mm)	MAE(mm)	R ²
2020	16.72	5.63	0.871
2021	13.49	5.45	0.825
2022	14.73	4.29	0.835
2023	14.09	5.18	0.813
2024	15.08	4.83	0.821
Average	14.82	5.08	0.833




Figure 3.26. Monthly Precipitation Validation Metrics (IDW Model, 2020-2024).

3.2.2.3. Cubic Spline Interpolation (CSI) 기법 적용

이 절에서는 관측 지점 사이의 곡률을 최소화하여 급격한 변화 없이 자연스러운 공간 연속성을 모의하는 3차 스플라인 보간법(CSI)을 선정하고, 이를 통해 1km 해상도의 기상 격자망

을 구축하여 교차 검증(LOOCV)을 수행하였다. 2020년부터 2024년까지의 기온 데이터를 시각화한 결과(Figure 3.17), 해발고도에 따른 기온 감률 효과와 한라산 지형에 의한 남북 기온 차이가 뚜렷한 동심원 형태의 등온선으로 구현되었다. CSI 기법은 관측점을 통과하는 유려한 3차 다항식 곡면을 생성하여 지형에 따른 자연스러운 기온 구배를 시각화하는 데 탁월한 성능을 보였다. 그러나 통계적 상관성을 기반으로 하는 Kriging이나 거리 가중치에 의존하는 IDW와 달리, CSI는 데이터 간격이 넓거나 변동 폭이 큰 산간 고지대 등에서 수학적 특성에 기인한 과대(Overshoot) 또는 과소(Undershoot) 추정 현상이 국지적으로 관찰되었다. 이는 모델이 곡선의 경향성을 유지하며 전체적인 형상의 매끄러움을 강조하는 과정에서, 극값 주변의 수치적 불안정성이 반영된 결과로 해석된다.

5년 전체 기간에 대한 기온 예측 검증 결과(Table 3.5), 결정계수(R^2)는 약 0.978로 산출되어 모델이 제주도의 복잡한 시공간적 기온 변동성을 97% 이상 설명하는 매우 높은 설명력을 보였다. 예측 오차인 RMSE와 MAE는 각각 1.33°C, 0.95°C로 분석되었다. 연도별 분석 결과, RMSE는 최저 1.26°C(2021년)에서 최고 1.40°C(2023년)의 매우 좁은 범위 내에서 변동하였고, R^2 또한 0.976~0.979의 안정적인 수준을 유지하였다. 월별 정확도 분석 결과(Figure 3.18), 예측 오차를 나타내는 RMSE는 겨울철에 증가하고 여름철에 감소하는 경향이 뚜렷했다. 1월과 2월, 12월의 RMSE는 각각 1.52, 1.46, 1.48로 연중 가장 높은 수치를 기록한 반면, 8월의 RMSE는 0.84로 가장 낮게 나타나 하절기의 예측 정밀도가 동절기에 비해 상대적으로 우수함을 확인하였다. 반면, 결정계수(R^2)는 연중 0.88에서 0.96 사이의 높은 수준을 유지하여, CSI 기법이 기상 요소의 공간적 변동성을 효과적으로 모의하고 있음을 입증하였다. 특히 대기 상태가 상대적으로 안정적인 가을철(10월, 11월)에는 0.95 이상의 가장 높은 설명력을 기록하여 모델의 적합도가 극대화됨을 확인하였다.




Figure 3.27. Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by CSI Model.

Table 3.6. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by CSI Model.

Year	RMSE(°C)	MAE(°C)	R ²
2020	1.28	0.91	0.976
2021	1.26	0.92	0.979
2022	1.37	1.00	0.979
2023	1.40	0.99	0.976
2024	1.37	0.94	0.978
Average	1.33	0.95	0.978




Figure 3.28. Monthly Temperature Validation Metrics (CSI Model, 2020-2024).

CSI 기법을 적용하여 2020년부터 2024년까지의 5년 평균 강수량 분포를 시각화한 결과 (Figure 3.19), OK 및 IDW 분석 결과와 마찬가지로 제주도의 강수량은 해발고도에 지배적인 영향을 받는 것으로 재확인되었다. 무엇보다 CSI 기법은 관측 지점 사이의 곡률을 최소화하는 알고리즘의 특성상, 등강수선을 유려하고 연속적인 곡선 형태로 연결하여 공간적 분포의 시각적 자연스러움을 극대화하였다. 그러나 이러한 시각적 장점에도 불구하고, 관측망의 밀도가 낮은 산간 고지대나 강수량 변동폭이 큰 급경사 구간에서는 한계점이 관찰되었다. 데이터의 경향성을 부드럽게 유지하려는 수학적 특성으로 인해, 실제 물리적 범위를 벗어나는 과대(Overshoot) 또는 과소(Undershoot) 추정 현상이 발생하였다. 즉, 전반적인 형상은 매끄러우나 극값 (Extremes) 주변에서는 수치적 불안정성을 내포하고 있음이 확인되었다.

5년 전체 기간에 대한 강수 예측 검증 결과(Table 3.6), 결정계수(R^2)는 약 0.883으로 산출되었고 예측 오차인 RMSE와 MAE는 각각 11.92mm, 4.03mm로 분석되었다. 연도별 분석 결과, RMSE는 최저 11.17mm(2024년)에서 최고 12.93mm(2023년)의 범위 내에서 변동하였고, R^2 또한 0.840~0.921의 높은 수준을 유지하였다. 월별 정확도 분석 결과(Figure 3.20), RMSE가 5월에 19.21로 연중 최고치를 기록한 반면, 강수량이 적은 2월에는 5.93의 낮은 수치를 보였다. R^2 는 월별 변동성이 매우 크게 나타났는데 특히 12월에는 0.54 수준으로 급격히 하락하여 겨울철의

불규칙하거나 미량인 강수 패턴을 포착하는 데에는 상대적인 한계가 있음이 드러났다.

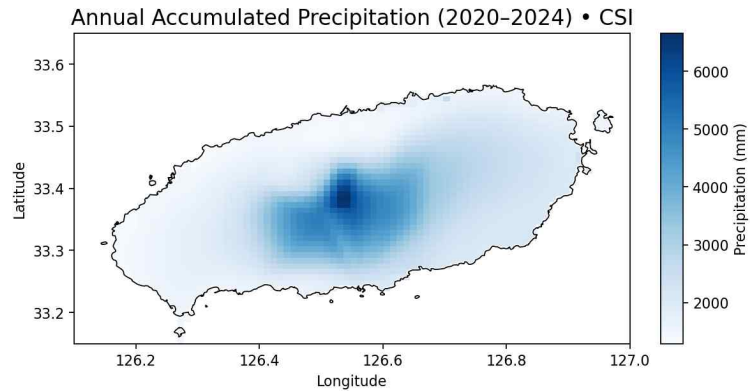


Figure 3.29. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by CSI Model

Table 3.7. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by CSI Model.

Year	RMSE (mm)	MAE (mm)	R ²
2020	12.42	4.31	0.921
2021	11.53	4.32	0.868
2022	11.54	3.29	0.891
2023	12.93	4.56	0.840
2024	11.17	3.68	0.896
Average	11.92	4.03	0.883




Figure 3.30. Monthly Precipitation Validation Metrics (CSI Model, 2020-2024).

3.2.3. 다변수 공간 보간 기법 적용 결과

3.2.3.1. Ordinary Cokriging (OCOK) 기법 적용

이 절에서는 기상 예측의 정확도를 극대화하기 위해, 분석 대상인 주요 변수(기온, 강수량)와 통계적으로 유의미한 상관성을 가지는 보조 변수를 결합하는 Ordinary Cokriging (OCOK) 기법을 적용하였다. 특히 제주도는 해발고도의 변화에 따라 기온이 하강하거나 강수량이 증가하는 등 지형적인 상관성이 매우 뚜렷한 지역이다. 이러한 특성을 모델에 반영하기 위해 고해상도 수치표고모델(DEM)을 보조 자료로 통합하여 공간 보간을 수행하였다. 그 결과, 단순 통계적 추정만으로는 한계가 있었던 산간 및 중산간 등 관측 희소 지역의 예측 불확실성을 개선하고, 실제 지형 효과가 반영된 기상장을 구축하였다.

OCOK 기법을 적용해 5년(2020-2024) 평균 기온 분포도를 시각화한 결과(Figure 3.2.21), OCOK 기법은 한라산을 중심으로 한 제주도의 복잡한 지형적 기온 구배를 매우 사실적으로 재현하는 것으로 나타났다. 분포도 상의 등온선은 해발고도의 등고선과 매우 유사한 동심원 형태를 띠며, 해안 저지대에서 산간 고지대로 갈수록 기온이 일정하게 하강하는 기온 감률 효과를 뚜렷하게 시각화하였다. 특히 서귀포를 포함한 남부 지역이 동일 고도의 북부 지역에 비해 상대적으로 온난하게 나타나는 현상을 포착하여, 한라산이 북서 계절풍을 차단하는 지형적 효과가 모델에 반영되었음을 확인하였다. 이는 거리 정보에만 의존하여 산간 지역에서 과도하게 평활화되거나 국지적인 '황소 눈 효과(Bull's-eye Effect)'를 유발했던 IDW 및 단순 OK 기법의 한계를 극복한 결과이다. OCOK는 고도(DEM)라는 물리적 보조 변수를 모델링에 직접 통합함으로써, 관측소가 부재한 미계측 고지대에서도 지형에 부합하는 정밀한 기온 구배를 성공적으로 모의하였다. 또한, 수학적 곡률 최소화를 통해 등치선을 부드럽게 연결하는 CSI(3차 스플라인) 기법과 비교했을 때, OCOK는 더욱 뛰어난 물리적 안정성을 보여준다. CSI 기법은 시각적 연속성은 우수하나 데이터가 희소한 급경사지 등에서 실제 물리적 범위를 벗어나는 과대 또는 과소 추정의 수치적 불안정성을 내포하고 있다. 반면, OCOK는 기온과 고도 사이의 통계적 상관성을 기반으로 값을 추정하기 때문에, 급격한 지형 변화 구간에서도 수치적 발산 없이 사실적이고 물리적으로 타당한 공간 분포를 재현해 낸다.

해발고도(DEM)를 보조 변수로 통합한 OCOK 기법의 기온 예측 안정성을 평가하기 위해, 교차 검증(LOOCV)을 수행하여 도출된 통계 지표(RMSE, MAE, R^2)를 분석하였다. 5년 전체 기간에 대한 기온 예측 검증 결과(Table 3.7), 결정계수(R^2)는 0.98 이상(0.981 ~ 0.984)의 매우 높은 값을 유지하였다. 이는 OCOK 모델이 제주도 기온의 공간적 변동성을 98% 이상 설명하고 있음을 의미하며, 연도별 기후 특성 변화에 관계없이 일관된 성능을 보였다. RMSE 또한 1.06°C 에서 1.17°C 사이의 안정적인 범위를 유지하여, 복잡한 지형 조건에서도 연중 고르게 정밀한 예측이 가능함을 입증하였다. 특히 월별 분석에서는 고도 정보를 활용한 효과가 더욱 두드러졌다(Figure 3.21). 앞선 CSI 기법 분석에서 예측 오차가 약 1.5°C 까지 치솟았던 겨울철(1~2월)의 경우, OCOK 기법은 RMSE를 1.12°C ~ 1.13°C 수준으로 현저히 낮추는 성과를 보였다. 이는 고도 데이터를 통해 산간 지역의 기온 감률 효과를 효과적으로 보정함으로써, 겨울철 기온 추정의 불확실성을 구조적으로 개선했음을 시사한다. 또한 월별 RMSE의 편차가 약 0.1°C 내외에 불과하여, 계절적 요인에 따라 성능 변동이 심했던 타 기법들과 달리 연중 균일

한 고품질 데이터를 생산할 수 있음이 통계적으로 증명되었다.




Figure 3.31. Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by OCOK Model.

Table 3.8. Annual Validation Metrics for Temperature Interpolation (2020-2024) Estimated by OCOK Model.

Year	RMSE (°C)	MAE (°C)	R ²
2020	1.07	0.83	0.982
2021	1.06	0.82	0.984
2022	1.13	0.87	0.984
2023	1.17	0.90	0.981
2024	1.16	0.89	0.982
Average	1.12	0.86	0.982




Figure 3.32. Monthly Temperature Validation Metrics (OCOK Model, 2020-2024).

제주도 내 기상관측지점을 대상으로 OCOK 모델의 국지적 예측 신뢰성을 검증하기 위해, 지점별 교차 검증(LOOCV)을 수행하고 평균제곱근오차(RMSE)와 결정계수(R^2)의 공간 분포 특성을 정밀 분석하였다. 이는 모델이 특정 지역에 편향되지 않고 전역에서 일관된 성능을 발휘하는지, 혹은 지형적 요인에 따라 성능의 공간적 이질성이 나타나는지를 파악하기 위함이다. RMSE의 공간 분포에서는 지형 및 미기후 특성에 따른 미세한 패턴 차이가 관찰되었다(Figure 3.23). 관측소 밀도가 높고 지형이 평탄한 대부분의 해안 도심 지역에서는 1.0°C 미만(최저 0.4 1°C)의 매우 높은 예측 성능을 보였다. 지형적 기복이 심한 일부 산간 지점에서는 오차가 다소 상승하였으나, 대부분 1.2°C 내외로 효과적으로 억제되었다. 이는 거리 정보에만 의존하여 산간 지역에서 과도한 오차를 유발했던 기존 IDW나 단변량 Kriging 기법과 달리, OCOK 기법이 고도 정보를 통해 산간 지역의 기온 추정 오차를 성공적으로 보정했음을 의미한다. 전반적인 고 성능에도 불구하고, 서귀포(189번) 지점은 RMSE 2.32°C로 타 지점 대비 이례적으로 높은 오차를 기록하였다. 이는 서귀포 지역이 단순 해발고도 기반의 기온 감률 모델로는 완전히 설명하기 어려운 독자적인 고온 미기후 특성을 갖기 때문으로 해석된다. 지점별 R^2 분포를 분석한 결과(Figure 3.24), 해안 저지대에 위치한 대부분의 관측소뿐만 아니라 해발고도가 높은 산간 지역의 관측소에서도 0.94 이상의 매우 높은 설명력이 균일하게 나타났다. 특히 표선(792번) 지점($R^2=0.996$)과 성산(188번) 지점($R^2=0.996$) 등은 거의 완벽에 가까운 추정 능력을 보여주었다.




Figure 3.33. LOOCV RMSE Map of the OCOK Temperature Model.




Figure 3.34. LOOCV R^2 Map of the OCOK Temperature Model.

제주도의 복잡한 지형적 특성이 모델의 예측 성능에 미치는 영향을 정량적으로 파악하기 위해, 전체 관측 지점을 해발고도에 따라 저지대(200m 미만), 중산간(200m~600m), 고지대(600m 이상)의 세 구간으로 범주화하여 심층 분석을 수행하였다. 각 고도 구간별로 R^2 (Figure 3.25)와 RMSE(Figure 3.26)의 통계적 수치를 통해 구간 내 성능 변동성과 모델의 안정성을 진단하였다.

- 저지대(200m 미만): 전체 데이터의 약 60%를 차지하는 관측소 밀도가 가장 높은 구간으로 평균 R^2 가 0.981, 평균 RMSE가 1.03°C로 나타나 안정적이고 균일한 예측 성능을 나타내는 구간임을 확인하였다.
- 중산간(200~600m): 기온 감률의 선형성이 잘 나타나는 구간으로 세 구간 중 평균 R^2 가

가장 높은 0.987, 평균 RMSE가 가장 낮은 0.94°C로 나타나 설명력과 정밀도 모든 면에서 우수한 성과를 보였다.

- 고지대(600m 이상): 지형이 험준하고 기상 변화가 심하며 관측 데이터가 희소한 고지대 구간으로 다른 구간에 비해 평균 R^2 가 0.972로 다소 낮아지고 평균 RMSE가 1.45°C로 상승하는 경향을 보였다. 비록 오차가 증가하였으나 관측소가 극히 드문 산간 오지임에도 불구하고 97% 이상의 높은 설명력을 유지한다는 점은 매우 고무적이다. 이는 고도 정보를 전혀 활용하지 못해 산간 지역 예측이 불가능했던 기존 기법들과 비교할 때, OCOK 기법이 고지대 기온 추정에 있어서도 물리적으로 타당한 성능을 발휘하고 있음을 시사한다.




Figure 3.35. RMSE by Elevation Band (OCOK Temperature Model).




Figure 3.36. R2 by Elevation Band (OCOK Temperature Model).

OCOK 기법을 적용해 생산된 5년 연평균 누적 강수량 분포도(Figure 3.27)를 분석한 결과, 제주도의 강수 패턴은 한라산을 중심으로 한 지형적 요인에 의해 지배적인 영향을 받는 것으로 확인되었다. 우선 다우(多雨) 지역은 해발고도가 높은 한라산 정상부(진달래밭, 윗세오름)와 성판악을 포함한 동부 및 남부 중산간 지역에 집중되어 나타났다. 이는 습윤한 남풍 및 남동풍 계열의 기류가 한라산 사면을 타고 강제 상승하며 발생하는 전형적인 지형성 강수 패턴이다. OCOK 모델은 고도를 보조 변수로 활용하여 이러한 물리적 메커니즘을 효과적으로 모의하였으며, 그 결과 분포도의 등강수선이 해발고도 등고선과 유사한 동심원 형태를 그리며 고도 상승에 따라 강수량이 뚜렷하게 증가하는 경향을 시각적으로 구현하였다. 반면, 소우(少雨) 지역은 고도가 낮은 서부(고산, 대정) 및 북부 해안 저지대를 중심으로 형성되었다. 특히 서부 해안 지역은 제주도 내에서 가장 건조한 특성을 보였는데, 이는 지형에 의한 강제 상승 효과가 미미할 뿐만 아니라 수증기 유입 경로상의 풍하측 효과가 복합적으로 작용한 결과로 해석된다. 결론적으로 OCOK 모델은 제주도의 복잡한 지형이 강수량에 미치는 효과를 정밀하게 반영하여, 산간의 다우 현상과 해안의 소우 현상을 물리적으로 타당하게 재현하였다.

해발고도(DEM)를 보조 변수로 통합한 OCOK 기법의 강수량 예측 신뢰성을 평가하기 위해 연별 및 월별 교차 검증 지표를 정밀 분석한 결과, 기온과 달리 시공간적 변동성이 극심한 강

수 데이터임에도 불구하고 모델이 유의미한 예측 성능을 확보하고 있음이 확인되었다. 2020년부터

2024년까지의 연별 분석 결과를 살펴보면(Table 3.8), OCOK 모델은 0.85에서 0.92 사이의 높은 R^2 를 기록하며 제주도 강수 패턴의 85% 이상을 설명해 내는 것으로 나타났다. 또한 연평균 RMSE가 11.7mm에서 12.1mm 사이의 매우 좁은 범위에서 변동하여, 특정 해에 강수량이 집중되거나 가뭄이 발생하는 등 기후 특성이 변화하더라도 모델의 예측 오차 수준은 크게 흔들리지 않고 일관된 구조적 안정성을 유지하고 있음을 입증하였다. 월별 분석에서는 강수량의 절대적인 규모와 모델 성능 지표 간의 뚜렷한 상관관계가 관찰되었다(Figure 3.28). 강수량이 적은 갈수기인 1월과 2월에는 RMSE가 6~8mm 수준으로 연중 가장 낮게 나타났으나, R^2 는 0.73 수준까지 하락하여 상대적으로 낮은 설명력을 보였다. 반면, 본격적인 호우가 집중되는 5월 이후의 하절기에는 강수량의 규모가 커짐에 따라 RMSE가 19.58mm로 급격히 증가하는 양상을 보였다. 그러나 이때의 R^2 는 오히려 0.89 수준의 높은 수치를 유지하였는데, 이는 여름철 호우가 한라산 지형에 의한 강제 상승 효과, 즉 지형성 강수 특성이 지배적이기 때문이다. 결과적으로 OCOK 모델은 오차의 절대적인 크기가 커지는 시기에도 강수량의 공간적 분포 패턴 자체는 더욱 정확하게 포착하는 특성을 보여, 제주도의 지형성 강수 분포를 재현하는 데 있어 고도 변수의 활용이 필수적임을 통계적으로 증명하였다.

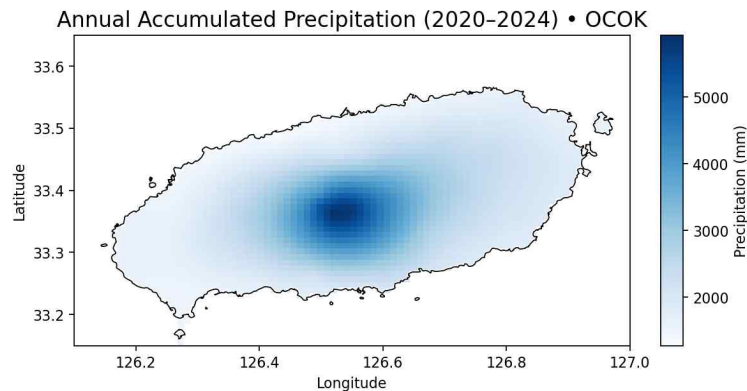


Figure 3.37. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by OCOK Model.

Table 3.9. Annual Validation Metrics for Precipitation Interpolation (2020–2024) Estimated by OCOK Model.

Year	RMSE (mm)	MAE (mm)	R^2
2020	12.13	4.77	0.920
2021	11.86	4.90	0.853
2022	11.81	3.71	0.880
2023	11.71	4.60	0.860
2024	11.74	4.30	0.883
Average	11.85	4.46	0.879




Figure 3.38. Monthly Precipitation Validation Metrics (OCOK Model, 2020–2024).

제주도 내 관측 지점별로 OCOK 모델의 교차 검증 결과를 정밀 분석한 결과, 전 지점에서 균일한 고성능을 보였던 기온과 달리 강수량은 지점의 위치와 지형적 특성에 따라 성능 편차가 뚜렷하게 나타나는 공간적 이질성이 확인되었다. 우선 산간 및 남동부 중산간에 위치하여 강수량이 많은 다우(多雨) 지점들은 RMSE가 16mm~17mm 이상으로 저지대 평균(약 8mm) 대비 2배 이상 높게 나타났다(Figure 3.29). 그러나 이러한 높은 오차에도 불구하고 해당 지점들의 R^2 는 0.88 이상의 매우 높은 수준을 유지하였다(Figure 3.30). 이는 강수량의 절대 규모가 커짐에 따라 수치적 오차는 필연적으로 증가했으나, OCOK 모델이 고도 변수를 통해 지형성 강우의 발생 시점과 공간적 패턴 자체는 매우 정확하게 포착하고 있음을 의미한다. 반면, 지형적 강제 상승 효과가 미미하거나 독자적인 강수 메커니즘을 갖는 일부 해안 지역에서는 설명력이 다소 저하되는 경향이 관찰되었다. 특히 제주도 서쪽 끝에 위치한 고산(185번) 지점은 R^2 가 0.69로 전체 지점 중 낮은 수준을 기록하였다. 한편, 제주 북부(184번) 및 구좌(781번) 등을 포함한 다수의 일반 해안 및 저지대 관측소에서는 RMSE 6~7mm, R^2 0.85~0.89 수준의 균형 잡힌 성능을 보였다. 이는 OCOK 모델이 제주도 전역의 일반적인 강수 패턴을 모의하는 데 있어 전

반적으로 준수한 신뢰도를 확보하고 있음을 보여준다.




Figure 3.39. LOOCV RMSE Map of the OCOK Precipitation Model.




Figure 3.40. LOOCV R^2 Map of the OCOK Precipitation Model.

제주도의 강수량 분포는 해발고도에 따른 지형성 강우 효과가 지배적이므로, OCOK 모델의 예측 신뢰성을 검증하기 위해 전체 관측 지점을 저지대(200m 미만), 중산간(200m~600m), 고지대(600m 이상)로 구분하여 분석을 수행하였다. 분석 결과, 강수량의 절대적인 규모와 지형적 복잡성에 따라 각 구간별로 상이한 성능 특성이 관찰되었다(Figure 3.31, Figure 3.32).

- 저지대(200m 미만): 전체 데이터의 약 60%를 차지하는 관측소 밀도가 가장 높은 구간으로 평균 RMSE가 8.37mm로 가장 낮게 나타나고 R^2 또한 0.837로 준수한 수준을 유지하고 있어 정량적으로 가장 안정적인 예측 성능을 보였다.
- 중산간(200~600m): 중산간 지역은 해안의 기상 특성과 산간의 지형성 강우가 혼재되는 복잡한 전이 구간(Transition Zone)으로 R^2 가 0.765로 전체 구간 중 가장 낮은 설명력을 보였다. 기온 분석에서 중산간 지역이 좋은 성능을 보였던 것과는 대조적인 결과이다. 이 구간에서는 단순히 고도뿐만 아니라 사면의 방향(Aspect), 경사도(Slope), 풍향 등 미시적인 지형 인자들이 강수량에 복합적인 영향을 미치기 때문에, 고도만을 보조 변수로 사용한 OCOK 모델의 설명력이 상대적으로 약화된 것으로 판단된다.
- 고지대(600m 이상): 가장 주목할 점은 고지대 구간에서 R^2 가 0.914로 세 구간 중 가장 높게 나타났으며 RMSE 또한 17.79mm로 가장 높게 나타났다. 비록 오차의 절대값은 크더라도 '고도가 높아질수록 비가 많이 온다'는 강수 패턴 자체를 모델이 매우 정확하게 설명하고 있음을 의미한다. 즉, OCOK 모델이 한라산의 강한 지형성 강우 효과를 물리적으로 타당하게 포착하고 있음이 입증되었다.

OCOK 모델은 저지대에서는 '정량적인 정확도(낮은 RMSE)'를, 고지대에서는 '경향성의 정확도(높은 R^2)'를 강점으로 가짐이 확인되었다. 다만 중산간 지역의 상대적으로 낮은 설명력은 향후 모델 고도화 시 다변량 지형 인자(경사, 향 등)의 추가 도입 필요성을 시사한다.




Figure 3.41. RMSE by Elevation Band (OCOK Precipitation Model).




Figure 3.42. R2 by Elevation Band (OCOK Precipitation Model).

3.2.3.2. Simple Cokriging (SCOK) 기법 적용

이 절에서는 기상 변수의 공간적 분포가 전역적으로 일정한 경향성을 따른다는 가정하에, Simple Cokriging (SCOK) 기법을 적용하여 분석을 수행하였다. 제주도는 해발고도 상승에 따른 기온 하강이나 강수량 증가와 같은 물리적 상관성이 국지적으로 변하기보다는 섬 전역에 걸쳐 매우 견고하고 일관되게 나타나는 지역이다. 이러한 특성을 반영하기 위해 고해상도 수치표고 모델(DEM)을 보조 변수로 통합하여, 도메인 전체의 평균 관계가 일정하다는 정상성 (Stationarity) 기반의 공간 보간을 수행하였다. 그 결과, 국지적 데이터 부족으로 인해 추정이 어려웠던 산간 및 중산간 지역에서도 고도와의 전역적 상관 구조를 바탕으로 물리적으로 타당하고 안정적인 기상장을 구축하였다.

SCOK 기법을 적용해 5년(2020-2024) 평균 기온 분포도를 시각화한 결과(Figure 3.33), 한라산을 중심으로 한 제주도의 복잡한 지형적 기온 분포를 매우 사실적으로 재현하였다. 기온 분포도의 등온선은 지형적 기온 감률이 반영되어 해발고도 등고선과 유사한 동심원 형태를 띠며, 해안 저지대에서 한라산 정상부로 갈수록 기온이 일정하게 하강하는 특성이 잘 나타나고 있다. 또한, 서귀포를 포함한 남부 해안 지역이 동일 고도의 북부 지역에 비해 상대적으로 온난하게 나타나는 현상이 확인되었다. 이는 한라산이 겨울철 차가운 북서 계절풍을 차단하는 지형적 효과(Blocking Effect)가 장기 평균 기온 분포에 반영된 결과로 해석된다.




Figure 3.43. Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by SCOK Model.

도메인 전체의 평균 관계가 일정하다는 가정을 전제로 하는 SCOK 기법의 예측 안정성을 평가하기 위해, 연별 및 월별 교차 검증 지표(RMSE, MAE, R^2)를 정밀 분석하였다. 2020년부터 2024년까지의 연별 분석 결과, SCOK 기법은 국지적 평균을 추정하지 않음에도 불구하고 매우 안정적인 예측 성능을 유지하였다. 5년 전 기간에 걸쳐 R^2 가 0.974에서 0.978 사이의 높은 값을 유지하였다(Table 3.9). 이는 제주도 기온 분포의 97% 이상이 고도에 따른 전역적인 기온 감률 하나만으로도 충분히 설명될 수 있음을 시사한다. 연평균 RMSE는 1.25°C에서 1.37°C 범위를 기록하였는데 이는 앞서 분석한 OCOK 기법(약 1.12°C)에 비해 소폭 높은 수준이나, 복잡한 국지적 추정 과정 없이 전역 평균만을 사용했음을 고려할 때 매우 효율적이고 준수한 성능으로 평가된다. 월별 분석에서는 기온의 절대적인 크기와 대기 안정도에 따라 모델의 성능 특성이 뚜렷하게 구분되었다(Figure 3.34). 동절기(1~2월)의 RMSE는 각각 1.42°C, 1.37°C로 연중 가장 높게 나타났다. 그러나 흥미롭게도 R^2 는 0.92~0.93 수준으로 연중 상위권의 설명력을 기록하였다. 이는 겨울철 산간 지역의 낮은 기온으로 인해 절대적인 오차(RMSE)는 커지지만, 차가운 북서풍이 강하게 불며 대기가 혼합됨에 따라 고도에 따른 기온 하강 경향 자체는 매우 뚜렷해져 전역 모델의 적합도가 높아지기 때문으로 해석된다. 기온이 오르는 5월과 6월에는 RMSE가 1.1°C~1.2°C 수준으로 감소하여 정량적인 오차는 줄어들었다. 반면 R^2 는 0.86~0.87 수준으로 겨울철에 비해 다소 낮아지는 경향을 보였다. 이는 여름철에 지표 가열, 해륙풍, 국지성 호우 등 고도 이외의 국지적 미기후 요인이 활발해지면서, 고도 하나에 의존하는 전역적 경향성(Global Trend)의 설명력이 상대적으로 약화되었기 때문으로 판단된다. 결론적으로 SCOK 기법은 연중 R^2 0.87 이상(최대 0.93)의 설명력을 확보하며, 제주도 기온장이 전역적으로 매우 강력한 고도 상관성을 따르고 있음을 통계적으로 입증하였다. 비록 OCOK에 비해 RMSE가 약 0.1~0.2°C 가량 높게 나타났으나, 국지적 변이에 과민하게 반응하지 않고 제주도 전체의 거시적인 기후 상황을 파악하는 데에는 SCOK 기법이 매우 효과적임을 확인하였다.

Table 3.10. Annual Validation Metrics for Temperature Interpolation (2020–2024) Estimated by SCOK Model.

Year	RMSE (°C)	MAE (°C)	R ²
2020	1.26	1.00	0.975
2021	1.25	1.00	0.977
2022	1.34	1.06	0.978
2023	1.37	1.08	0.974
2024	1.35	1.08	0.975
Average	1.32	1.04	0.976




Figure 3.44. Monthly Temperature Validation Metrics (SCOK Model, 2020–2024).

제주도 전역의 33개 기상관측지점을 대상으로 SCOK 모델의 국지적 예측 신뢰성을 평가하기 위해, 지점별 교차 검증 결과인 RMSE와 R^2 의 공간 분포 특성을 정밀 분석하였다(Figure 3.35, Figure 3.36). 해발고도(DEM)를 보조 변수로 활용하되 전체 영역의 평균을 상수로 가정하는 SCOK 모델이 지역적 위치나 지형 복잡도에 따라 어떠한 성능 편차를 보이는지 고찰하였다. RMSE의 공간 분포에서는 지역적 특성에 따른 뚜렷한 성능 편차가 확인되었다. 관측소 밀도가 높고 지형이 완만한 해안 저지대에서는 대체로 0.4°C~1.3°C 수준의 안정적인 오차 분포를 보였다. 반면, 서귀포(189번) 지점은 RMSE \approx 2.77°C로 타 지점 대비 매우 높은 오차를 기록하였으며, 진달래밭(870번) 등 일부 산간 지점에서 RMSE가 2.0°C 이상으로 다소 높게 나타났다. 지점별 R^2 분포를 분석한 결과, 제주도 내 대부분의 관측소에서 0.90 이상의 높은 설명력이 관찰되었다. 특히 표선(792번) 지점($R^2 \approx 0.997$)과 성산(188번) 지점($R^2 \approx 0.989$) 등에서는 거의 완벽에 가까운 선형 관계가 확인되었다. 이는 기온과 해발고도 간에 강한 선형적 상관관계가 존재하기 때문에, 도메인 전체의 평균을 하나의 상수로 가정하는 SCOK 기법으로도 고도에 따른 기온 변동성(Global Trend)을 상당히 효과적으로 설명할 수 있음을 입증한다. 남북 사면의 고도 차이가 뚜렷한 관측소들에서 고르게 높은 R^2 값이 나타난 점은, 지형 인자가 제주도 기온 모델링의 핵심 변수임을 재확인시켜 준다. 이러한 국지적 오차는 SCOK 기법이 연구 대상 지역 전체의 기온 평균 관계를 하나의 전역적 상수(Global Constant)로 가정하기 때문에 발생한다.

즉, 서귀포의 온난한 미기후나 산간의 냉기류 침강 등 국지적인 지형 효과로 인해 전역 평균으로부터 이탈하는 현상을 정밀하게 보정하지 못했기 때문이다. 국지적 평균을 유연하게 추정하여 오차를 1.0°C 내외로 억제했던 OCOK 기법과 달리, SCOK는 전역적인 경향성은 잘 맞추지만 국지적인 변동성 대응에는 구조적인 한계가 있음이 공간 오차 분포를 통해 드러났다. 관측지점별 정확도 분포도는 SCOK 기법이 해발고도와의 전역적 상관성을 통해 전반적으로 준수한 예측 성능을 확보했음을 보여준다. 다만, 공간적으로 균일한 예측력을 보인 OCOK와 달리, SCOK는 지형 복잡도가 높거나 독자적인 미기후를 갖는 특정 지점에서 오차의 편차가 크게 발생하는 특성을 보였다. 이는 향후 격자 자료 활용 시, 산간 오지 등 국지 기상 변화가 큰 지역에 대해서는 SCOK 결과 해석에 주의가 필요함을 시사한다.




Figure 3.45. LOOCV RMSE Map of the SCOK Temperature Model.




Figure 3.46. LOOCV R^2 Map of the SCOK Temperature Model.

제주도의 기온 분포가 고도에 따른 전역적인 경향성(Global Trend)을 얼마나 잘 따르는지 검증하기 위해, 관측 지점을 해발고도에 따라 저지대(200m 미만), 중산간(200m-600m), 고지대(600m 이상)로 구분하여 SCOK 모델의 예측 성능을 심층 분석하였다. 각 고도 구간별로 RMSE와 R^2 의 통계적 분포(중앙값, 사분위수 범위 등)를 산출하여, 고도 변화에 따른 모델의 공간적 안정성을 평가하였다(Figure 3.37, Figure 3.38).

- 저지대(200m 미만): 전체 데이터의 대다수를 차지하는 저지대에서는 RMSE 1.37°C, R^2 0.968을 기록하여 중산간에 비해 오차가 약 0.4°C 이상 높게 나타났다. 앞서 분석한 OCOK 모델이 저지대에서 약 1.03°C의 정밀한 성능을 보였던 것과 대조적이다. 저지대 해안 지역은 서귀포의 고온 현상, 제주시의 도심 효과 등 지역별로 평균 기온이 상이한 비정상성(Non-stationarity)을 띤다. 그러나 SCOK는 이를 무시하고 도메인 전체의 평균을 일괄 적용했기 때문에, 국지적 특성이 강한 해안 저지대에서 필연적으로 오차가 증가하는 구조적 한계를 노출하였다.
- 중산간(200~600m): 가장 주목할 점은 중산간 구간에서 SCOK 모델이 RMSE 0.93°C, R^2 0.987로 세 구간 중 압도적으로 가장 우수한 성능을 기록했다는 것이다. 이는 해당 고도 대역이 해안가의 복잡한 국지적 미기후나 도심 열섬 효과의 영향권에서 벗어나 있고, 고도 상승에 따른 기온 하강이라는 물리적 법칙이 가장 선형적이고 모범적으로 적용되

는 구간이기 때문이다. 즉, SCOK 모델이 가정한 제주도 전역의 평균적인 기온 감률이 이 구간에서 완벽하게 맞아떨어짐을 의미한다.

- 고지대(600m 이상): 기상 변화가 심한 고지대에서는 RMSE 1.44°C, R^2 0.972를 기록하였다. 이는 OCOK 모델(RMSE 1.45°C)과 거의 유사한 수준이다. 데이터가 희소한 산간 오지에서는 국지적인 평균을 추정할 이웃 관측소가 부족하기 때문에, 결국 고도와 전역적 상관성에 의존하게 된다. 따라서 고지대에서는 SCOK와 OCOK 간의 성능 차이가 거의 없으며, 이는 고도에 따른 기온 감률 경향이 산 정상부까지 매우 견고하게 유지되고 있음을 시사한다.




Figure 3.47. RMSE by Elevation Band (SCOK Temperature Model). Figure 3.48. R2 by Elevation Band (SCOK Temperature Model).

SCOK 기법을 적용하여 구축된 2020년부터 2024년까지의 1km 해상도 일별 강수량 격자 자료를 바탕으로 제주도 전역의 강수 분포 특성을 분석하였다. 5년(2020-2024) 연평균 누적 강수량 분포도를 분석한 결과(Figure 3.39), 제주도의 강수 패턴은 위도보다는 해발고도(Elevation)에 의해 강하게 지배되는 경향이 확인되었다. 해안 저지대에서 한라산 정상부로 갈수록 강수량이 증가하는 전형적인 지형성 강수 효과가 뚜렷하게 나타났으며, 서귀포를 포함한 남부 해안 지역은 북부 해안에 비해 상대적으로 많은 강수량을 기록하여 한라산에 의한 남풍 기류의 강제 상승 효과가 잘 반영되었다. 해발고도를 보조 변수로 활용함으로써 IDW 기법에서 나타나는 인위적인 '황소 눈 효과(Bull's-eye Effect)' 없이 비교적 자연스럽고 연속적인 강수 구배를 재현하였다. 다만, SCOK 기법은 연구 대상 지역 전체의 강수량 평균 관계를 하나의 상수로 가정하는 특성이 있어, 국지적인 평균 변화를 허용하는 OCOK 기법에 비해 극한 강수값이 다소 평활화되는 경향을 보였다.

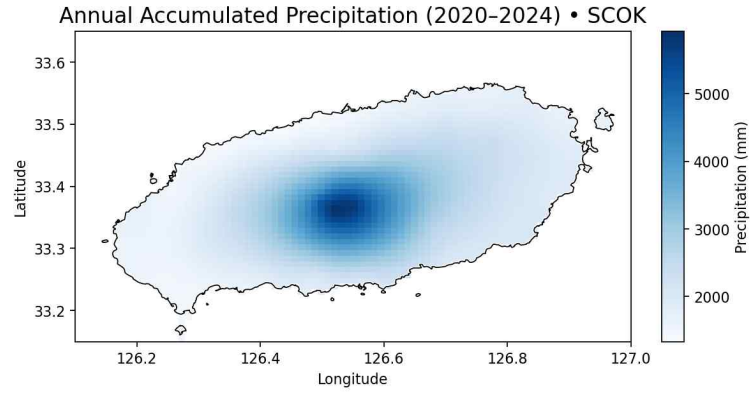


Figure 3.49. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by SCOK Model.

SCOK 모델의 예측 신뢰성을 정량적으로 검증하기 위해 5년 전체 기간에 대한 교차 검증 (LOOCV)을 수행하였다(Table 3.10). 모델의 설명력을 나타내는 결정계수(R^2)는 약 0.872로 산출되어, SCOK 모델이 제주도의 복잡한 시공간적 강수 변동성을 87% 이상 설명하는 준수한 성능을 보였다. 예측 오차인 RMSE와 MAE는 각각 12.24mm, 4.67mm로 분석되었다. 연도별 RMSE는 최저 11.99mm(2023년)에서 최고 12.92mm(2020년) 사이에서 변동하였으며, R^2 또한 0.847~0.910 수준을 유지하였다. 이는 연도별 강수 패턴의 차이에도 불구하고, SCOK 모델이 고도와의 전역적 상관성을 바탕으로 일정 수준 이상의 예측 안정성을 확보하고 있음을 시사한다. 월별 정확도 분석 결과(Figure 3.40), 강수량이 상대적으로 적은 10월(5.79mm)과 12월(5.15mm)에는 RMSE가 가장 낮게 나타나 매우 안정적인 성능을 보였다. 반면, 집중 호우가 잦은 5월(20.36mm)과 9월(17.82mm)에는 강수량의 절대적 크기가 커짐에 따라 오차(RMSE) 또한 증가하는 뚜렷한 규모의존적 특성을 보였다. 공간적으로는 한라산 지형에 의한 강수 증가 트렌드를 잘 반영하였으나, 전역 평균을 가정하는 모델의 구조적 한계로 인해 성판악 등 고지대 다우 지역의 국지적 극한 강수를 모의하는 데 있어서는 OCOK 대비 오차가 소폭 증가하는 경향이 관찰되었다.

Table 3.11. Annual Validation Metrics for Precipitation Interpolation (2020-2024) Estimated by SCOK Model.

Year	RMSE (mm)	MAE (mm)	R^2
2020	12.92	5.05	0.910
2021	12.11	5.13	0.847
2022	12.08	3.88	0.875
2023	11.99	4.78	0.853
2024	12.09	4.49	0.876
Average	12.24	4.67	0.872




Figure 3.50. Monthly Precipitation Validation Metrics (SCOK Model, 2020-2024).

제주도 전역 33개 기상관측지점을 대상으로 SCOK 강수량 예측 모델의 국지적 신뢰성을 평가하기 위해, 지점별 교차 검증 결과인 RMSE와 R^2 의 공간 분포도를 작성하였다. 이를 통해 해발고도를 보조 변수로 사용하되, 연구 대상 지역의 강수량 평균을 상수로 가정하는 SCOK 기법이 지형적 강수 변동성을 어느 정도 수준으로 설명하는지 분석하였다. RMSE의 공간 분포에서는 강수량의 절대적 크기와 모델의 구조적 특성이 복합적으로 작용한 패턴이 확인되었다 (Figure 3.41). 강수량이 상대적으로 적고 지형이 평탄한 서부 및 북부 해안 지역에서는 낮은 RMSE 분포를 보이며 안정적인 예측 성능을 나타냈다. 반면, 성판악, 윗세오름 등 연강수량이 매우 많은 고지대 및 다우 지역에서는 RMSE가 상대적으로 높게 나타났다. 이는 강수량의 절대값이 커짐에 따라 오차의 크기도 비례하여 증가하는 자연스러운 현상이기도 하지만, 한편으로는 SCOK 모델이 전역 평균으로 회귀하려는 성향으로 인해 극값을 과소 추정하면서 발생하는 잔차의 영향이 큰 것으로 분석된다. 지점별 R^2 분포를 분석한 결과(Figure 3.42), 제주도 대부분의 관측소에서 양호한 설명력을 보였다. 이는 강수량과 해발고도 간에 존재하는 강력한 양의 상관관계(지형성 강수)가 SCOK 모델의 선형 결합 구조 내에서 효과적으로 작동했기 때문이다. 그러나 국지적 평균 변화를 허용하는 OCOK 결과와 비교할 때, 강수량의 공간적 이질성이 매우 큰 일부 산간 및 남부 지역에서는 R^2 값이 다소 낮게 나타나는 경향이 관찰되었다.




Figure 3.51. LOOCV RMSE Map of the SCOK Precipitation Model.




Figure 3.52. LOOCV R^2 Map of the SCOK Precipitation Model.

제주도의 지형적 강수 특성이 SCOK 모델의 예측 성능에 미치는 영향을 분석하기 위해, 전체 관측소를 해발고도에 따라 저지대(<200m), 중산간(200m~600m), 고지대(>600m)의 세 구간으로 분류하여 구간별로 RMSE와 R^2 의 통계적 분포를 산출하였다(Figure 3.43, Figure 3.44).

- 저지대(200m 미만): RMSE 9.26mm로 가장 낮은 오차를 기록하여 정량적으로는 안정적인 성능을 보였으나 R^2 는 0.801을 기록하여, OCOK 기법(약 0.837)에 비해 소폭 감소하였다.
- 중산간(200~600m): 해안의 특성과 산간의 특성이 혼재되는 복잡한 전이 구간으로 RMSE 13.00mm, R^2 0.764를 기록하여, 전체 구간 중 가장 낮은 설명력을 보였다.
- 고지대(600m 이상): RMSE 17.75mm로 가장 높았으나 전역적 평균과 고도에 따른 강수 증가 경향으로 인해 R^2 0.915를 기록하여 전체 구간 중 가장 높은 설명력을 보였다.

SCOK 기법은 고지대의 지형성 강우 패턴을 모의하는 데 있어 탁월한 성능($R^2 \geq 0.91$)을 보였다. 이는 산간 오지의 강수량 추정에 있어 복잡한 모델링 없이도 고도 정보를 활용한 전역적 경향성 적용이 유효함을 시사한다.




Figure 3.53. RMSE by Elevation Band (SCOK Precipitation Model).




Figure 3.54. R2 by Elevation Band (SCOK Precipitation Model).

3.2.3.3. Universal Cokriging (UCOK) 기법 적용

Universal Cokriging (UCOK) 기법을 적용하여 2020년부터 2024년까지의 1km 해상도 일별 기온 격자 자료를 생산하고 그 특성을 분석하였다. UCOK는 기온 데이터에 내재된 비정상성, 즉 해발고도가 높아질수록 기온이 일정하게 하강하는 기온 감률 효과를 1차 트렌드(Trend) 함수로 설정하여 수식적으로 제거한 뒤, 남은 잔차에 대해 크리깅을 수행하는 기법이다. 5년(2020-2024) 전체 기간에 대한 평균 기온 분포도 분석 결과(Figure 3.45), UCOK 모델은 한라산

을 중심으로 한 제주도의 지형적 기온 구배를 가장 완벽에 가깝게 재현하였다. 전역 평균을 가 정하는 SCOK나 국지적 평균을 따르는 OCOK와 달리, UCOK는 고도에 따른 기온의 물리적 감 소 경향을 직접 모델링함으로써, 관측소가 부재한 한라산 정상부와 급경사면의 기온 분포를 매 우 정밀하고 매끄럽게 모의하였다. 특히 해안 저지대와 산간 고지대 간의 기온 차이를 뚜렷한 동심원 형태의 등온선으로 표현하며, 지형에 의한 기온 냉각 효과를 구조적으로 설명하였다.

기온 예측 정확도 검증 결과(Table 3.11), UCOK 모델은 비교 대상 기법들 중 가장 우수한 성능을 기록하였다. 5년 전체 기간 평균 결정계수(R^2)는 약 0.989로 산출되어, 제주도의 시공간 적 기온 변동성을 99% 가까이 설명하는 극도로 높은 신뢰도를 보였다. 예측 오차인 RMSE와 MAE는 각각 0.89°C, 0.64°C로 분석되어, 모든 기법 중 유일하게 RMSE 1.0°C 미만의 정밀도를 달성하였다. 연도별 분석 결과, RMSE는 최저 0.81°C(2021년)에서 최고 0.96°C(2023년)로, 모든 해에 걸쳐 1.0°C를 넘지 않는 안정적인 성능을 보였다. R^2 또한 0.987~0.991의 범위를 유지하 여, 연도별 기후 변동이나 이상 기온 현상과 무관하게 모델이 매우 잘 작동함을 입증하였다. 월별 정확도 분석 결과(Figure 3.46), 대기가 불안정하거나 변동성이 큰 계절에도 성능 저하가 거의 발생하지 않았다. 6월(0.77°C), 8월(0.77°C) 등 여름철에는 극히 낮은 오차를 기록하였으며, 기온 변동폭이 가장 큰 1월(0.99°C)과 2월(0.93°C)에도 RMSE가 1.0°C 이하로 유지되었다. 이는 UCOK의 트렌드 모델이 겨울철의 강한 기온 감률 효과를 완벽히 포착했기 때문으로 해석된다. 결론적으로 UCOK는 지형적 기온 구배가 뚜렷한 제주도 지역에서 미세측 지점의 기온을 추정 하는 데 있어 가장 신뢰할 수 있는 최적의 방법론으로 평가된다.




Figure 3.55. Mean Temperature Distribution in Jeju Island (2020-2024) Estimated by UCOK Model.

Table 3.12. Annual Validation Metrics for Temperature Interpolation (2020–2024) Estimated by UCOK Model.

Year	RMSE (°C)	MAE (°C)	R ²
2020	0.84	0.63	0.989
2021	0.81	0.60	0.991
2022	0.94	0.70	0.989
2023	0.96	0.71	0.987
2024	0.91	0.66	0.989
Average	0.89	0.66	0.989




Figure 3.56. Monthly Temperature Validation Metrics (UCOK Model, 2020–2024).

제주도 전역 33개 기상관측지점에 대하여 UCOK 기온 예측 모델의 국지적 신뢰성을 평가하기 위해, 지점별 교차 검증(LOOCV) 결과인 RMSE와 R^2 의 공간 분포도를 작성하였다. 분석에서는 이러한 해발고도에 따른 기온의 선형적 경향성 모델링이 지점별 예측 정확도에 미치는 영향을 공간적으로 고찰하였다. 지점별 RMSE 분포를 분석한 결과(Figure 3.47), RMSE의 공간 분포는 매우 낮은 수준의 오차 범위를 보였다. 대부분의 지점에서 RMSE는 0.5°C~0.8°C 내외로 분포하였으며, 오차가 상대적으로 큰 지점조차 1.1°C를 넘지 않는 것으로 확인되었다. 특히 주목할 점은 지형이 복잡한 중산간이나 한라산 인근 고지대 관측소에서도 해안가 평지와 유사한 수준의 낮은 RMSE를 기록했다는 것이다. 이는 UCOK 기법이 고도에 의한 비정상성을 효과적으로 제거함으로써, 지형적 요인에 의한 예측 오차의 공간적 편향을 근본적으로 해소했음을 시사한다. IDW나 일반 Kriging에서 관찰되던 산간 지역의 오차 쏠림 현상이 UCOK 기법에서는 거의 나타나지 않았다. 지점별 R^2 분포를 분석한 결과(Figure 3.48), 제주도 내 거의 모든 관측소에서 0.98~0.99 이상의 높은 설명력이 관찰되었다. 이는 기존의 OCOK 기법이나 SCOK 기법이 보인 성능(약 0.95~0.97 수준)을 상회하는 결과이다. 이러한 공간적 균질성과 높은 정확도는 UCOK 모델이 '기온은 고도에 따라 감소한다'는 물리적 경향성을 명시적으로 모델링했기 때문이다.




Figure 3.57. LOOCV RMSE Map of the UCOK Temperature Model.




Figure 3.58. LOOCV R^2 Map of the UCOK Temperature Model.

기온의 공간적 분포에 내재된 비정상성을 고려하는 UCOK 모델의 고도별 예측 안정성을 평가하기 위해, 전체 관측소를 해발고도에 따라 저지대(<200m), 중산간(200m~600m), 고지대(>600m)의 세 구간으로 분류하였다. 각 구간별로 RMSE와 R^2 의 통계적 분포를 산출하여, 고도 변화에 따른 모델의 성능 편차를 정량적으로 분석하였다. 고도 구간별 RMSE 분포 분석 결과(Figure 3.49), 고도에 따른 오차 증가 현상이 거의 나타나지 않는 '공간적 등분산성'이 확인되었다. 저지대 및 중산간 구간에 위치한 대부분의 관측소에서는 RMSE가 0.5°C~0.8°C 수준의 매우 낮은 분포를 보였다. 이는 관측 오차를 제외하면 모델의 구조적 오차가 거의 없음을 의미한다. 타 기법에서 높게 나타나던 고지대 RMSE가 UCOK에서는 저지대와 유사한 1.0°C 미만 수준으로 억제되었다. 고지대 특유의 급격한 기상 변화에도 불구하고 오차 분포의 폭이 좁게 유지되는 것은, UCOK가 지형적 요인에 의한 예측 편향(Bias)을 근본적으로 해결했음을 시사한다. 고도 구간별 R^2 분포 분석 결과(Figure 3.50), 모든 고도 구간에서 0.98~0.99에 육박하는 극도로 높고 균일한 설명력이 관찰되었다. 이는 UCOK 기법이 해발고도에 따른 기온의 선형적 감소 경향을 '드리프트(Drift)' 함수로 명시적으로 모델링하여 제거했기 때문이다. 그 결과, 단순 거리 보간이나 전역 평균을 가정하는 기법(SCOK)과 달리, 지형에 따른 기온 변동의 트렌드가 완벽히 설명됨으로써 고도에 상관없이 최상의 예측 성능을 유지함을 확인하였다.




Figure 3.59. RMSE by Elevation Band (UCOK Temperature Model).




Figure 3.60. R^2 by Elevation Band (UCOK Temperature Model).

UCOK 기법을 적용하여 2020년부터 2024년까지의 1km 해상도 일별 강수량 격자 자료를 생산하고 그 특성을 분석하였다. UCOK는 강수량 데이터에 내재된 비정상성, 즉 해발고도가 높아질수록 강수량이 증가하는 선형적 경향성을 '드리프트(Drift)' 함수로 명시적으로 모델링하는 기법이다. 5년(2020-2024) 전체 기간에 대한 연평균 누적 강수량 분포도 분석 결과(Figure 3.5 1), UCOK 모델은 제주도의 강수 패턴을 결정짓는 핵심 인자인 지형성 강수 효과를 가장 명확하고 정밀하게 재현하였다. 전역 평균을 가정하는 SCOK와 달리, UCOK는 고도에 따른 강수량의 지역적 편차를 트렌드로 설명함으로써, 한라산 정상부와 성판악 등 고지대 다우(多雨) 지역의 강수 집중 현상을 과소 추정 없이 사실적으로 모의하였다. 동시에 해안 저지대의 소우(少雨) 패턴 또한 정확히 반영하여, '황소 눈 효과' 없는 매끄럽고 물리적으로 타당한 강수 구배를 구현하였다.

강수량 예측 정확도 검증 결과(Table 3.12), UCOK 모델은 비교 대상 기법들 중 가장 우수한 성능을 기록하였다. 5년 전체 기간 평균 R^2 는 약 0.901로 산출되어, 제주도의 복잡한 강수 변동성을 90% 이상 설명하는 매우 높은 신뢰도를 보였다. 예측 오차인 RMSE와 MAE는 각각 10.72mm, 4.07mm로 분석되어, 타 기법(OCOK: 11.85, SCOK: 12.24mm) 대비 현저히 낮은 오차 수준을 달성하였다. 연도별 분석 결과, RMSE는 최저 10.01mm(2022년)에서 최고 11.26mm(2020년)의 범위 내에서 변동하였으며, R^2 또한 0.874~0.931의 매우 높은 수준을 유지하였다. 특히 강수량 변동이 심했던 해에도 0.88 이상의 높은 설명력을 유지한 것은 경향성 모델링이 연도별 기후 특성에 강건하게 대응함을 시사한다. 월별 정확도 분석 결과(Figure 3.52), 강수량이 적은 2월(5.26mm)과 1월(7.92mm)에는 RMSE가 매우 낮게 나타났으며, 강수량이 많은 5월(16.77mm)과 4월(10.96mm)에도 타 기법 대비 오차 증가폭이 억제되었다. 무엇보다 5월, 6월 등 강수 집중기에도 R^2 가 0.91~0.93에 달하는 등, UCOK 모델은 계절에 상관없이 한라산 지형에 의한 강수 패턴을 구조적으로 잘 파악하고 있음을 입증하였다. 이는 미세측 산간 지역의 수문 기상 정보를 생산하는 데 있어 UCOK가 가장 신뢰할 수 있는 방법론임을 확인시켜 준다.

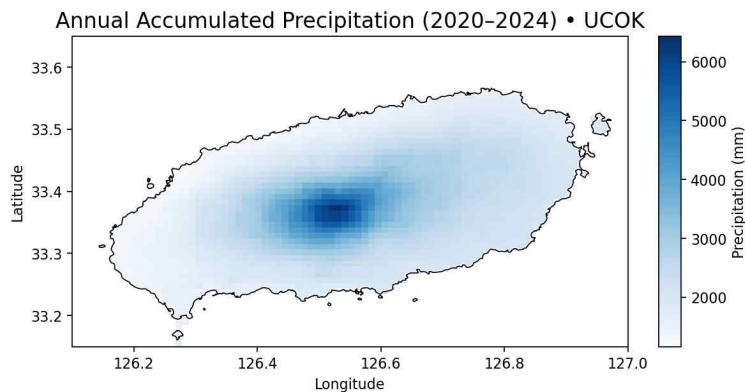


Figure 3.61. Annual Cumulative Precipitation Distribution in Jeju Island (2020-2024) Estimated by UCOK Model.

Table 3.13. Annual Validation Metrics for Precipitation Interpolation (2020–2024) Estimated by UCOK Model.

Year	RMSE (mm)	MAE (mm)	R ²
2020	11.26	4.20	0.931
2021	10.72	4.35	0.880
2022	10.01	3.18	0.914
2023	11.11	4.15	0.874
2024	10.52	3.85	0.906
Average	10.72	3.95	0.901




Figure 3.62. Monthly Precipitation Validation Metrics (UCOK Model, 2020–2024).

제주도 전역 33개 기상관측지점을 대상으로 UCOK 강수량 예측 모델의 국지적 신뢰성을 평가하기 위해, 지점별 교차 검증 결과인 RMSE와 R²의 공간 분포도를 작성하였다. UCOK는 강수량의 공간적 변동성뿐만 아니라 해발고도에 따른 선형적 경향성을 모델링에 직접 반영하는 기법으로, 이 분석을 통해 해당 기법이 지형적 강수 특성을 얼마나 효과적으로 설명하는지를 고찰하였다. 지점별 RMSE 분포를 분석한 결과(Figure 3.53), 공간 분포에서는 강수량의 절대적 규모와 연동된 패턴이 관찰되었으나, 그 오차폭은 타 기법 대비 현저히 감소하였다. 강수량이 상대적으로 적은 서부 및 북부 해안 지역에서는 매우 낮은 RMSE 분포를 보이며 안정적인 예측 성능을 나타냈다. 연강수량이 매우 많은 산간 지역의 경우, 강수량의 절대값이 크에 따라 RMSE 수치 자체는 저지대보다 다소 높게 나타났다. 그러나 이는 강수 규모에 비례하는 자연스러운 현상이며, UCOK 모델은 경향성 모델링을 통해 이 지역의 오차를 최소화하였다. 특히, 단순 거리 기반 보간법이 산간 지역의 강수량을 과소 추정하여 큰 오차를 발생시키는 문제를 UCOK는 지형 인자를 통해 효과적으로 보정하고 있음을 확인하였다. 지점별 R² 분포를 분석한 결과(Figure 3.54), UCOK 모델은 제주도 전역에서 매우 높은 설명력을 보였다. 특히 주목할 점은 한라산 성판악, 진달래밭 등 고지대 다우(多雨) 지역에서도 R² 값이 0.90 이상의 높은 수준을 유지했다는 것이다. 이는 UCOK 기법이 고도에 따른 강수량 증가 경향을 수식적으로 제거한 후 잔차를 보간함으로써, 지형성 강우로 인한 비정상성을 효과적으로 통제했음을 시사한다.




Figure 3.63. LOOCV RMSE Map of the UCOK Precipitation Model.




Figure 3.64. LOOCV R^2 Map of the UCOK Precipitation Model.

제주도의 지형적 강수 특성을 고려한 UCOK 모델의 예측 안정성을 평가하기 위해, 전체 관측소를 해발고도에 따라 저지대(<200m), 중산간(200m~600m), 고지대(>600m)의 세 구간으로 분류하였다. 고도 구간별 RMSE 분포를 분석한 결과(Figure 3.55), 강수량의 절대적 크기에 따른 비례적인 오차 증가 패턴이 확인되었으나, 타 기법 대비 억제된 양상을 보였다. 강수량이 적은 저지대에서는 RMSE가 낮고 균일하게 분포하여 모델의 기본 예측력이 안정적임을 확인하였다. 연강수량이 매우 많은 성판악, 진달래밭 등 고지대에서는 절대적인 강수량 규모가 크기 때문에 RMSE 수치 자체는 저지대보다 높게 나타났다. 그러나 단순 보간법(IDW, Spline)이나 전역 평균을 가정하는 SCOK에서 나타나던 오차 증가 현상은 UCOK의 트렌드 제거 과정을 통해 상당 부분 완화되었다. 즉, 강수량의 스케일 차이를 고려할 때 UCOK는 고지대의 극한 강수를 가장 합리적인 오차 범위 내에서 예측하는 것으로 분석된다. 고도 구간별 R^2 분포를 분석한 결과(Figure 3.56), 저지대에서 고지대로 갈수록 설명력이 오히려 상승하거나 매우 높은 수준을 유지하는 경향이 뚜렷하게 관찰되었다. 일반적으로 고지대는 기상 변동성이 커서 예측이 어렵다고 여겨지나, UCOK 모델은 강수량에 내재된 고도별 증가 트렌드를 명시적으로 모델링했기 때문에 지형성 강수 효과를 매우 효과적으로 설명하였다.

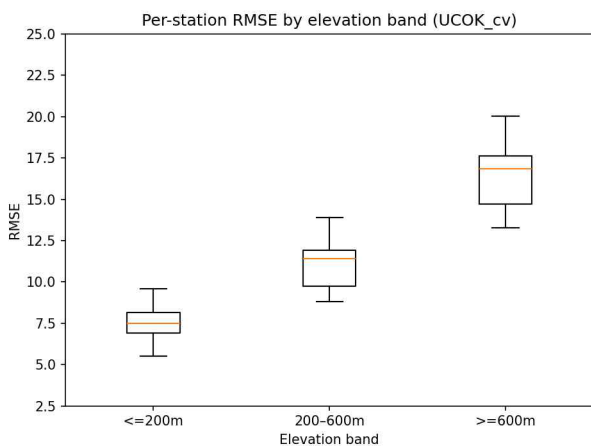


Figure 3.65. RMSE by Elevation Band (UCOK Precipitation Model).




Figure 3.66. R^2 by Elevation Band (UCOK Precipitation Model).

3.2.3.4. 시범지역 기온과 강수의 공간적 패턴 분석

이 절에서는 제주도의 계절별 기온과 강수 특성을 정량적으로 분석하여 기후지대를 도출하기 위해, 사계절 평균기온과 누적강수량을 변수로 비지도학습인 K-means 군집화(k=3)를 수행하였다(MacQueen, 1967). 이 기법은 외부 기준 없이 데이터의 통계적 유사성만으로 기후 패턴이 상이한 지역을 구분할 수 있다는 장점이 있다(Fovell and Fovell, 1993). 해안가는 사계절 기온이 높은 ‘해안 저지대’로, 한라산 중심부는 기온이 낮은 ‘고지대’로, 그 사이는 ‘중산간 지대’로 구분되어 고도 상승에 따른 감온율 구조를 명확히 보여주었다(Figure 3.57). 강수 군집화 역시 제주도의 지형성 강수 특성을 잘 반영하였다. 산악 지형을 따라 강수가 집중되는 고지대 및 중산간은 ‘고강수/중위 강수 지역’으로, 해안가는 ‘저강수 지역’으로 분류되어 기온과 마찬가지로 고도에 따른 분포 차이를 보였다(Figure 3.58). 통합적 해석 및 시사점 기온과 강수는 분포 양상(기온은 고도에 반비례, 강수는 비례)은 다르지만, 두 변수 모두 ‘해안 저지대·중산간·고지대’라는 동일한 공간적 삼중 구조를 형성하고 있음이 확인되었다(Ko et al., 2013).




Figure 3.67. Spatial Classification of Temperature Zones in Jeju Island using K-means Clustering.




Figure 3.68. Spatial Classification of Precipitation Zones in Jeju Island using K-means Clustering.

Universal Cokriging (UCOK) 기법으로 생산된 2020~2024년 고해상도(1km) 기온 및 강수 격자 자료를 활용하여, 제주도 기후의 주된 공간적 변동 모드를 규명하였다. 분석 방법으로는 EOF(Empirical Orthogonal Function) 기법을 적용하였다. EOF 분석은 시공간적으로 방대한 기상 데이터의 차원을 축소하여 전체 변동성을 가장 잘 설명하는 소수의 독립적인 공간 패턴(Mode)과 이에 대응하는 시계열(PC Score)을 추출하는 통계적 기법이다. 이 연구에서는 기온(월 평균)과 강수(계절/월 누적) 자료에 대해 각각 표준화를 수행한 후 PCA 기반의 EOF 분석을 실시하여 상위 3개 모드(EOF1, EOF2, EOF3)를 도출하였다(Figure 3.59).

기온 자료에 대한 EOF 분석 결과, 제주도의 기온 변동은 고도와 지형적 위치에 따라 서로 다른 세 가지 주요 패턴으로 구분되었다.

- 제1모드 (Mode 1): 산악 중심의 지배적 계절성

제1모드는 전체 기온 변동의 가장 큰 비중을 설명하는 지배적 패턴으로, 제주도의 계절적 기온 사이클과 한라산이라는 지형적 요인이 결합된 기본 구조를 나타낸다. 공간적으로는 한라산 중심의 고지대에서 EOF 계수가 가장 크게 나타나고 해안 저지대로 갈수록 낮아지는 분포를 보이는데, 이는 고지대가 저지대보다 평균 기온으로부터의 이탈폭, 즉 ‘계절 진폭(Seasonal Amplitude)’이 훨씬 크다는 것을 의미한다. 시간적 패턴(PC1)에서는 여름철에 강한 양(+)의 값을, 겨울철에 강한 음(-)의 값을 보여, 고지대가 여름에는 더 크게 가열되고 겨울에는 더 크게 냉각되는 ‘산악 중심의 강한 계절 변동성’이 제주 기온의 가장 주된 특징임을 시사한다.

- 제2모드 (Mode 2): 고지대와 해안 간의 계절적 온도 대조

제2모드는 기온의 절대적인 높고 낮음보다는, 제주도 내부의 ‘고지대(중산간)와 해안 저지대 사이의 온도 차이’가 시기별로 어떻게 변화하는지를 설명하는 패턴이다. 공간 패턴에서 한라산 주변부와 해안 지역이 서로 반대 부호를 가지며 뚜렷한 대조를 이루는 것이 특징이다. PC2 시계열은 봄과 가을 사이에서 부호가 역전되는 경향을 보이는데, 이는 봄철에는 고지대가, 가을철에는 해안 지역이 상대적으로 더 따뜻한(또는 편차가 큰) 쪽으로 열적 특성이 전환됨을 나타낸다. 즉, Mode 2는 계절의 전이 과정에서 산과 해안 간의 열적 불균형이 강화되는 시기와 양상을 보여주는 보조적 변동 패턴으로 해석된다.

- 제3모드 (Mode 3): 방향성 있는 기온 구배의 변화

제3모드는 고도에 따른 수직적 변화가 아닌, ‘북-남’ 또는 ‘서-동’ 간의 수평적 기온 구배를 설명한다. 공간 패턴은 제주도의 북부와 남부, 혹은 동부와 서부 지역 사이에 양(+)과 음(-)의 부호가 나뉘는 형태로 나타나, 특정 방향에 따른 뚜렷한 온도 차이를 보여준다. PC3의 시계열은 계절풍, 일사량의 입사 각도 차이, 지형에 의한 바람 차단 등 국지적 기후 인자에 따라 여름이나 겨울철 특정 시기에 그 강도가 달라지는 특성을 보인다. 이는 제주도의 기온 분포가 단순한 고도 효과 외에도, 방위(Asspect)와 해류, 바람 등의 복합적인 요인에 의해 방향성 있는 미세 변동을 겪고 있음을 입증한다.

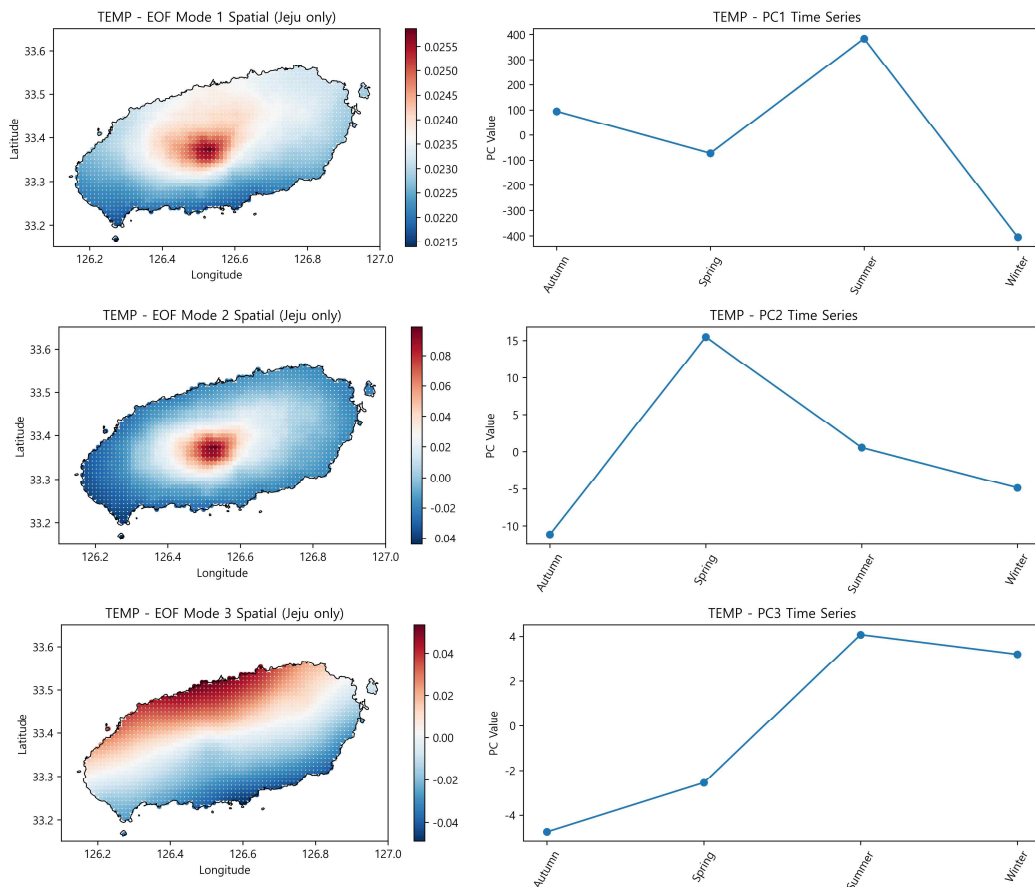


Figure 3.69. Spatial Patterns of the First Three Leading EOF Modes for Temperature in Jeju Island.

제주도의 강수량은 한라산이라는 지형적 요인과 계절풍, 태풍 등 기상학적 요인이 복합적으로 작용하여 매우 복잡한 시공간적 변동성을 보인다. 이 연구에서는 UCOK 기법으로 생산된 고해상도 강수 격자 자료에 대해 EOF 분석을 수행하여, 제주도 강수 변동을 지배하는 주요 모드를 3가지로 유형화하고 각 모드의 물리적 특성을 규명하였다(Figure 3.60).

- 제1모드 (Mode 1): 지형성 강수와 하계 집중형의 결합

제1모드는 제주도 전체 강수 변동성 중 가장 압도적인 비중을 차지하는 지배적 패턴으로, 제주도의 핵심적인 강수 메커니즘인 ‘지형성 강수’와 ‘여름철 집중’ 구조를 대변한다. 공간적으로는 한라산 고지대에서 강한 양(+)의 EOF 계수가 나타나고 해안 저지대로 갈수록 값이 급격히 낮아지는 분포를 보여, 고도에 따른 강수량의 공간적 편차를 명확히 반영한다. 시계열(PC1) 분석 결과, 장마와 태풍이 집중되는 여름철에 양(+)의 값이 극대화되고 건조한 겨울철에는 음(-)의 값으로 낮아지는 뚜렷한 계절성을 보였다.

- 제2모드 (Mode 2): 지역 간 강수 대조 패턴

제2모드는 고도에 따른 일방적인 강수 증가(Mode 1)를 넘어, ‘산악 지역과 해안 지역’ 또는 ‘동-서(혹은 남-북) 지역’ 간의 강수량 차이가 시기별로 어떻게 변화하는지를 설명하는 보조적 패턴이다. EOF 공간 패턴에서는 산악부와 해안부, 혹은 특정 방위 간에 양(+)과 음(-)의 부호가 나뉘어 나타나는데, 이는 특정 시기에 한쪽 지역의 강수가 상대적으로 더 많거나 적어지는 대조(Contrast) 현상을 시사한다. 특히 PC2 시계열은 장마나 태풍의 영향이 지배적인 여름철보다는 봄, 가을, 겨울 등 강수 비집중 시기에 강한 변동성을 보였다.

• 제3모드 (Mode 3): 복합적 국지 강수 패턴

제3모드는 단순한 지형 효과나 계절성만으로는 설명되지 않는 복합적이고 비선형적인 고차(High-order) 변동 패턴을 나타낸다. 공간적으로는 동부와 서부, 또는 남부 등 국지적 구역 간에 부호가 교차하는 복잡한 구조를 띠며, 이는 태풍의 이동 경로 변화, 국지적인 해풍 수렴, 미세 지형에 의한 적운 발달 등 다양한 기상 요인이 복합적으로 작용한 결과로 해석된다. PC3 시계열은 여름이나 겨울 등 특정 계절에 간헐적으로 강한 변동을 보이는데, 이는 해당 시기에 특정 지역에 국한된 집중 호우나 강수 비대칭 현상이 발생했음을 시사한다.

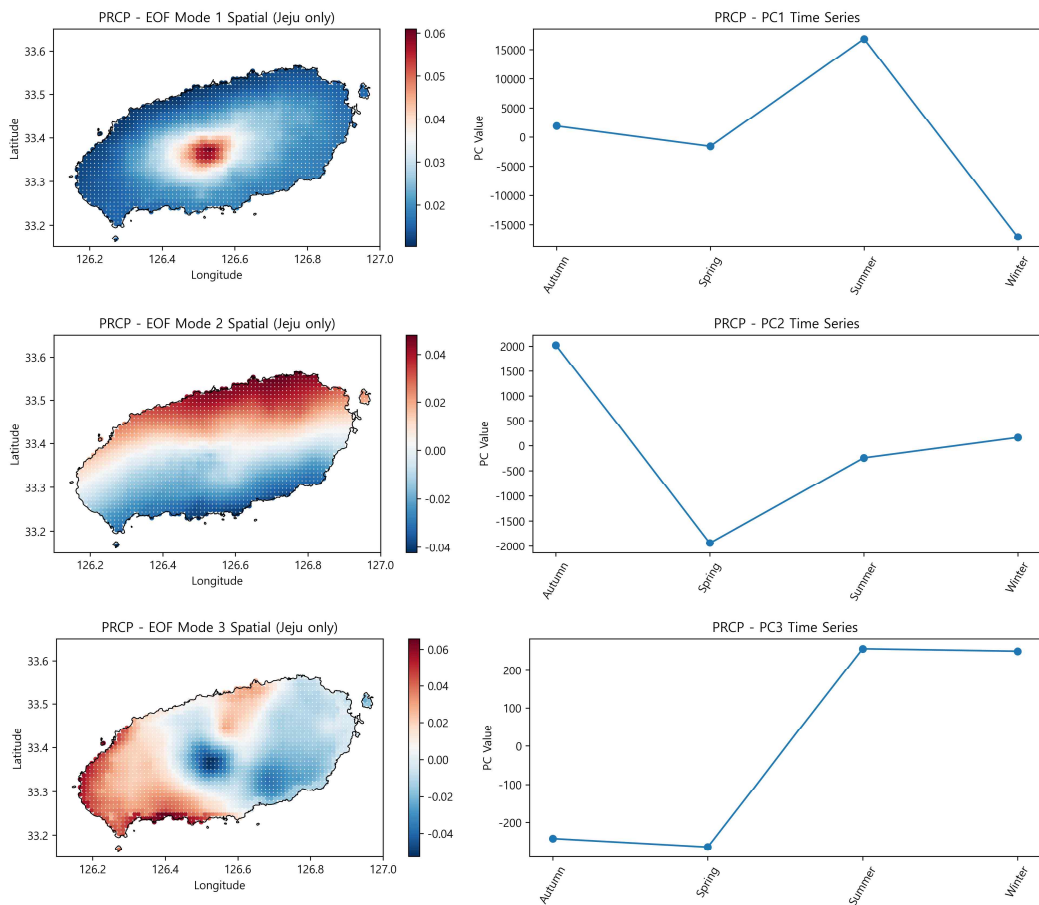


Figure 3.70. Spatial Patterns of the First Three Leading EOF Modes for Precipitation in Jeju Island.

3.3. 기후변화 전망자료의 활용성 증대를 위한 AI 기반 상세화 기술 개발

3.3.1. 인공지능 기반 상세화 모델 결과

학습자료는 CUB_CUB, CUB_NN, LIN_LIN, LIN_NN, NN_NN 등 2단계로 총 5종류의 자료로, 단계별 상세화 비교 평가를 위해 2배, 4배, 8배 자료를 구축하였다. CUB는 쌍입방(bicubic) 보간법, NN은 최근린(nearest neighbor, NN) 보간법, LIN은 선형(linear) 보간법을 의미한다.

구축한 학습자료는 파이토치(pytorch) 2.6.0으로 구축한 딥러닝 모델 CASE OLR, CASE D, CASE DU, CASE DUR, CASE UD을 이용하여 하는데 사용되었다. 평가기간은 ASOS 자료와의 비교를 위해 2020~2024년 최근 5년 자료를 이용하였다. ASOS 자료는 격자 자료인 상세화 결과 비교하기 위해 일단위 고해상도 자료의 격자에 맞춰 ASOS 자료를 격자에 위치를 매핑하는 형식으로 구축하였으며, 일별로 사용된 ASOS 자료는 결측치가 일별로 달라서 90개에서 94개소의 자료가 이용되었다. 같은 격자에 ASOS 자료가 결측치를 제외한 개수가 n 개인 경우에는 평균하였다.

먼저, 연구에 사용된 학습자료와 딥러닝 상세화 결과를 고해상도 ERA-5 자료와 비교평가하였다. 평가지표는 이미지 품질 평가지표(PSNR, SSIM, MS-SSIM), 통계 평가지표(MAE, MSE, RMSE, R^2)가 이용되었다.

학습데이터를 참값인 고해상도 ERA-5 자료와 비교하였다(Table 3.1). 이미지 품질 평가지표인 PSNR, SSIM를 비교한 그림은 Figure 3.71과 Figure 3.72와 같다. 평가에 사용된 학습자료는 CUB_NN, CUB_CUB, LIN_LIN, LIN_NN, NN_NN이다. '_' 를 기준으로 왼쪽은 첫 번째 보간법, 오른쪽은 두 번째 적용한 보간법이다. DS_CUB_CUB는 상세화 2배(이하 2x)와 4배(이하 4x) 상세화 자료에서 이미지 품질 평가지표와 통계 평가지표에서 가장 좋은 결과를 보였다. 상세화 8배(이하 8x)는 DS_LIN_LIN이 가장 좋은 결과를 보였다. NN_NN은 모든 상세화 배율에서 가장 낮은 결과를 보였다. DS_CUB_CUB_8는 DS_LIN_LIN_8과 유사한 결과를 보였다. 이는 기온과 같이 공간 변화가 완만한 경우에는 cubic의 곡률 이점이 크게 드러나지 않기 때문에 유사한 결과가 나타날 수 있다. 인공지능 기반 상세화 연구에서는 학습자료를 구축 할 때 일반적으로 Bicubic 보간법을 많이 이용한다. 이 연구에서는 일부 딥러닝 모델의 경우에는 가장 낮은 결과를 보인 NN과 CUB와 유사한 결과를 보인 LIN 보간법을 제외하였다.




Figure 3.71. Comparison of PSNR results between high-resolution ERA5 data and the training dataset for the period 2020-2024.




Figure 3.72. Comparison of SSIM results between high-resolution ERA5 data and the training dataset for the period 2020-2024.

Table 3.14. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the training dataset for the period 2020-2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
DS_CUB_CUB_2	48.1556	0.9936	0.9982	0.0993	0.0359	0.1884	0.9997
DS_CUB_NN_2	41.2148	0.9733	0.9964	0.2323	0.1784	0.4194	0.9985
DS_LIN_LIN_2	44.1410	0.9829	0.9921	0.1539	0.0901	0.2987	0.9992
DS_LIN_NN_2	41.5364	0.9739	0.9954	0.2255	0.1658	0.4043	0.9986
DS_NN_NN_2	38.6097	0.9508	0.9810	0.2644	0.3240	0.5657	0.9972
DS_CUB_CUB_4	38.3215	0.9403	0.9637	0.2975	0.3444	0.5840	0.9970
DS_CUB_NN_4	34.9744	0.8929	0.9501	0.4587	0.7523	0.8608	0.9937
DS_LIN_LIN_4	38.2331	0.9350	0.9603	0.3059	0.3513	0.5899	0.9969
DS_LIN_NN_4	35.4333	0.8995	0.9546	0.4397	0.6780	0.8169	0.9944
DS_NN_NN_4	31.8655	0.8138	0.8797	0.6433	1.5334	1.2302	0.9871
DS_CUB_CUB_8	32.9214	0.8304	0.8719	0.5908	1.1902	1.0866	0.9894
DS_CUB_NN_8	30.3550	0.7561	0.8318	0.8126	2.1848	1.4660	0.9821
DS_LIN_LIN_8	33.5030	0.8375	0.8786	0.5607	1.0454	1.0173	0.9908
DS_LIN_NN_8	30.6965	0.7636	0.8387	0.7861	2.0258	1.4106	0.9835
DS_NN_NN_8	27.5951	0.6498	0.7243	1.1790	4.1340	2.0156	0.9661

학습자료만을 이용하여 학습한 CASE OLR 모델 결과를 비교하였다(Table 3.2). 이미지 품질 평가지표인 PSNR, SSIM를 비교한 그림은 Figure 3.73과 Figure 3.74와 같다. CASE OLR 모델은 2x에서 CUB_CUB 데이터셋을 이용한 모델이 NN_NN_2 데이터셋을 이용한 모델보다 PSNR 평가지표를 제외한 모든 평가에서 좋은 결과를 보였다. 이미지 품질 평가지표인 PSNR과 SSIM은 비례하지 않는다는 결과를 보여줬다. 이 결과에서 보듯이 단일 PSNR, SSIM 지표로 결과를 분석하기 보다는 다른 통계 평가지표와 함께 분석하는 것이 필요하다. 4x와 8x는 2x와 같이 CUB_CUB 데이터셋을 이용한 모델이 우수한 결과를 보였다. CASE OLR 모델의 특징은 2x보다 4x와 8x의 결과가 더 좋다는 점이다. AI 기반 상세화 모델은 자료의 미세 조정이 아니라 정보를 복원하는 역할을 한다. 정보를 복원하는 과정에서 저해상도(low-resolution, LR)와 고해상도(high-resolution, HR) 자료 간 차이가 적고, 대부분의 대규모 패턴이 이미 LR에 존재하기 때문에 딥러닝 모델이 학습하는데 어려움이 있다. 특히 CASE OLR 모델은 보조변수 자료를 사용하지 않기 때문에 이런 현상이 심한 것으로 판단된다.




Figure 3.73. Comparison of PSNR results between high-resolution ERA5 data and the CASE OLR results for the period 2020-2024.




Figure 3.74. Comparison of SSIM results between high-resolution ERA5 data and the CASE OLR results for the period 2020-2024.

Table 3.15. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE OLR results for the period 2020-2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
OLR_CUB_CUB_2	30.0283	0.7938	0.8441	0.8178	2.3235	1.5171	0.9790
OLR_CUB_NN_2	31.9497	0.8573	0.8983	0.6117	1.4828	1.2141	0.9850
OLR_NN_CUB_2	31.8613	0.8184	0.8665	0.6708	1.5112	1.2261	0.9860
OLR_NN_NN_2	32.4195	0.8398	0.8842	0.6093	1.3289	1.1497	0.9870
OLR_CUB_CUB_4	39.0763	0.9426	0.9649	0.3007	0.2901	0.5357	0.9975
OLR_CUB_NN_4	41.9570	0.9631	0.9787	0.2189	0.1521	0.3861	0.9987
OLR_NN_CUB_4	33.2780	0.8691	0.9054	0.5885	1.1031	1.0445	0.9905
OLR_NN_NN_4	33.4108	0.8668	0.9037	0.5869	1.0687	1.0283	0.9907
OLR_CUB_CUB_8	33.4188	0.8337	0.8754	0.5847	1.0665	1.0273	0.9907
OLR_CUB_NN_8	36.1090	0.8788	0.9126	0.4554	0.5790	0.7552	0.9948
OLR_NN_CUB_8	28.7890	0.6887	0.7450	1.1048	3.1082	1.7523	0.9731
OLR_NN_NN_8	28.8928	0.7051	0.7601	1.0561	3.0252	1.7301	0.9733

학습자료와 보조변수 DEM 자료를 이용하여 학습한 CASE D 모델의 결과이다(Table 3.16). 이미지 품질 평가지표인 PSNR, SSIM를 비교한 그림은 Figure 3.75과 Figure 3.76와 같다. 2x에서는 CUB_NN 자료를 이용한 모델이 이미지 품질 평가지표에서는 매우 근소하게 좋은 결과를 보였으나 통계 평가지표에서는 MAE를 제외한 모든 지표에서 NN_NN 자료를 이용한 모델보다 낮은 결과를 보였다. 4x와 8x에서는 CUB_NN 자료를 이용한 모델이 다른 모델보다 좋은 결과를 보였다. 학습자료만 이용한 CASE OLR 모델 결과와 비교하면 보조변수 DEM 자료를 이용했을 때 더 좋은 결과를 보였다. 보조변수 DEM 자료는 기온자료를 상세화하는데 중요한 자료로 판단된다.




Figure 3.75. Comparison of PSNR results between high-resolution ERA5 data and the CASE D results for the period 2020-2024.




Figure 3.76. Comparison of SSIM results between high-resolution ERA5 data and the CASE D results for the period 2020–2024.

Table 3.16. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE D results for the period 2020–2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
D_CUB_CUB_2	36.5223	0.9139	0.9385	0.4279	0.5615	0.7317	0.9959
D_CUB_NN_2	36.7235	0.9186	0.9411	0.4357	0.5147	0.7079	0.9959
D_NN_NN_2	36.6522	0.9182	0.9412	0.4257	0.5447	0.7207	0.9961
D_CUB_CUB_4	44.4900	0.9824	0.9893	0.1683	0.0904	0.2929	0.9994
D_CUB_NN_4	45.6155	0.9842	0.9909	0.1526	0.0695	0.2570	0.9995
D_NN_NN_4	34.5652	0.8939	0.9186	0.5207	0.8273	0.9025	0.9931
D_CUB_CUB_8	38.0707	0.9232	0.9440	0.3752	0.3886	0.6105	0.9970
D_CUB_NN_8	39.4389	0.9402	0.9576	0.3164	0.2850	0.5221	0.9978
D_NN_NN_8	31.0173	0.7894	0.8291	0.8734	1.9130	1.3652	0.9848

CASE DU는 학습자료 중 Step 1 자료를 이용하고 모델 내에서 upsampling을 통해 고해상도 자료와 격자크기를 맞춘다. 특히, upsample layer 전까지 같은 구간의 네트워크를 함께 사용한다. 학습자료는 CUB_NN과 NN_NN 데이터셋을 이용하여 CUB, NN Step 1의 CUB와 NN 자료만 이용한다. 결과는 NN 자료를 이용한 모델이 모든 상세화 배율에서 가장 좋은 결과를 보였다(Table 3.17). 이미지 품질 평가지표인 PSNR, SSIM를 비교한 그림은 Figure 3.7과 Figure 3.8와 같다. CASE DU의 upsample 레이어가 자료를 확대하는 과정도 학습하는 특징 때문에 Step 2 자료를 이용하는 CASE OLR와 CASE D에 비해 좋은 결과를 보인 것으로 판단된다.




Figure 3.77. Comparison of PSNR results between high-resolution ERA5 data and the CASE DU results for the period 2020-2024.




Figure 3.78. Comparison of SSIM results between high-resolution ERA5 data and the CASE DU results for the period 2020-2024.

Table 3.17. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE DU results for the period 2020-2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
DU_CUB_NN_2	41.8311	0.9747	0.9841	0.2201	0.1546	0.3906	0.9987
DU_NN_NN_2	55.4424	0.9985	0.9996	0.0426	0.0076	0.0839	0.9999
DU_CUB_NN_4	34.2503	0.8798	0.9081	0.5469	0.8892	0.9358	0.9925
DU_NN_NN_4	47.1942	0.9889	0.9938	0.1284	0.0515	0.2177	0.9996
DU_CUB_NN_8	30.0446	0.7470	0.7897	0.9803	2.3594	1.5215	0.9804
DU_NN_NN_8	41.5592	0.9611	0.9736	0.2577	0.1867	0.4155	0.9987

CASE DUR은 CASE DU 모델에서 공용으로 사용하는 네트워크 기반을 저해상도 자료와 보조변수 DEM자료가 개별로 학습하도록 분리한 모델이다. 학습자료는 CUB_NN과 NN_NN 데이터셋을 이용하여 CUB, NN Step 1의 CUB와 NN 자료만 이용한다. 결과는 NN 자료를 이용한 모델이 모든 상세화 배율에서 가장 좋은 결과를 보였다(Table 3.18). 이미지 품질 평가지표인

PSNR, SSIM를 비교한 그림은 Figure 3.79과 Figure 3.80와 같다. CASE DUR 결과는 CASE DU와 거의 유사한 결과를 보였다.

Table 3.18. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE DUR results for the period 2020-2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
DUR_CUB_NN_2	41.8393	0.9749	0.9842	0.2184	0.1543	0.3902	0.9987
DUR_NN_NN_2	53.8623	0.9979	0.9994	0.0526	0.0106	0.0998	0.9999
DUR_CUB_NN_4	34.1974	0.8777	0.9066	0.5501	0.8998	0.9414	0.9925
DUR_NN_NN_4	46.6460	0.9876	0.9932	0.1338	0.0576	0.2310	0.9996
DUR_CUB_NN_8	30.3196	0.7489	0.7923	0.9685	2.2283	1.4763	0.9817
DUR_NN_NN_8	42.5240	0.9687	0.9782	0.2256	0.1556	0.3756	0.9990




Figure 3.79. Comparison of PSNR results between high-resolution ERA5 data and the CASE DUR results for the period 2020-2024.




Figure 3.80. Comparison of SSIM results between high-resolution ERA5 data and the CASE DUR results for the period 2020-2024.

CASE UD는 CUB_NN과 NN_NN 데이터셋을 이용하여 CUB, NN Step 1의 CUB와 NN 자료만 이용한다. 결과로 모든 상세화 배율에서 NN 자료를 이용한 모델이 가장 좋은 결과를 보였다. 이미지 품질 평가지표인 PSNR, SSIM를 비교한 그림은 Figure 3.81과 Figure 3.82와 같다. CASE DUR 결과는 CASE DU와 거의 유사한 결과를 보였다.

Table 3.19. Summary of image quality and statistical evaluation metrics for high-resolution ERA-5 and the CASE UD results for the period 2020-2024.

Model	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
UD_CUB_NN_2	41.8324	0.9746	0.9844	0.2194	0.1549	0.3907	0.9987
UD_NN_NN_2	49.6663	0.9955	0.9986	0.0813	0.0259	0.1591	0.9998
UD_CUB_NN_4	34.6028	0.8821	0.9105	0.5416	0.8309	0.9015	0.9932
UD_NN_NN_4	44.0331	0.9778	0.9872	0.1853	0.0988	0.3075	0.9992
UD_CUB_NN_8	30.0960	0.7394	0.7844	0.9811	2.3404	1.5140	0.9807
UD_NN_NN_8	40.2939	0.9493	0.9660	0.2992	0.2422	0.4770	0.9982




Figure 3.81. Comparison of PSNR results between high-resolution ERA5 data and the CASE UD results for the period 2020-2024.




Figure 3.82. Comparison of SSIM results between high-resolution ERA5 data and the CASE UD results for the period 2020-2024.

2x 전체 평가 모델 결과의 이미지 품질과 통계 평가 지표별 종합 순위는 1위는 DU_NN_NN_2, 2위는 DUR_NN_NN_2, 3위는 UD_NN_NN_2이었다(Table 3.20). 4x 전체 평가 모델 결과의 지표의 종합 1위는 DU_NN_NN_4, 2위는 DUR_NN_NN_4, 3위는 D_CUB_NN_4이었다(Table 3.21). 8x 전체 평가 모델 결과의 지표의 종합 1위는 DUR_NN_NN_8, 2위는 DU_NN_NN_8, 3위는 UD_NN_NN_8이었다(Table 3.22). 보간법만 적용하거나 보조변수 DEM 자료가 없는 모델보다는 DEM 자료를 넣은 모델이 좋은 결과를 보였다.

Table 3.20. Ranking summary of image quality and statistical evaluation metrics for all 2x downscaling results.

Model	Rank						
	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R ²
DS_CUB_CUB_2	4	4	4	4	4	4	4
DS_CUB_NN_2	10	10	5	10	10	10	10
DS_LIN_LIN_2	5	5	7	5	5	5	5
DS_LIN_NN_2	9	9	6	9	9	9	9
DS_NN_NN_2	11	11	11	11	11	11	11
D_CUB_CUB_2	14	14	14	13	14	14	14
D_CUB_NN_2	12	12	13	14	12	12	13
D_NN_NN_2	13	13	12	12	13	13	12
DU_CUB_NN_2	8	7	10	8	7	7	8
DU_NN_NN_2	1	1	1	1	1	1	1
DUR_CUB_NN_2	6	6	9	6	6	6	7
DUR_NN_NN_2	2	2	2	2	2	2	2
OLR_CUB_CUB_2	18	18	18	18	18	18	18
OLR_CUB_NN_2	16	15	15	16	16	16	17
OLR_NN_CUB_2	17	17	17	17	17	17	16
OLR_NN_NN_2	15	16	16	15	15	15	15
UD_CUB_NN_2	7	8	8	7	8	8	6
UD_NN_NN_2	3	3	3	3	3	3	3

Table 3.21. Ranking summary of image quality and statistical evaluation metrics for all 4x downscaling results.

Model	Rank						
	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R2
DS_CUB_CUB_4	8	8	8	9	12	12	12
DS_CUB_NN_4	11	12	11	17	17	17	17
DS_LIN_LIN_4	9	9	9	12	13	13	14
DS_LIN_NN_4	10	10	10	15	16	16	16
DS_NN_NN_4	18	18	18	27	27	27	27
D_CUB_CUB_4	4	4	4	4	4	4	4
D_CUB_NN_4	3	3	3	3	3	3	3
D_NN_NN_4	13	11	12	18	18	19	19
DU_CUB_NN_4	14	14	14	20	20	20	20
DU_NN_NN_4	1	1	1	1	1	1	1
DUR_CUB_NN_4	15	15	15	21	21	21	21
DUR_NN_NN_4	2	2	2	2	2	2	2
OLR_CUB_CUB_4	7	7	7	11	11	11	11
OLR_CUB_NN_4	6	6	6	6	6	7	7
OLR_NN_CUB_4	17	16	16	25	25	25	25
OLR_NN_NN_4	16	17	17	24	24	24	24
UD_CUB_NN_4	12	13	13	19	19	18	18
UD_NN_NN_4	5	5	5	5	5	5	5

Table 3.22. Ranking summary of image quality and statistical evaluation metrics for all 8x downscaling results.

Model	Rank						
	average PSNR	average SSIM	average MS-SSIM	average MAE	average MSE	average RMSE	average R2
DS_CUB_CUB_8	9	9	9	9	9	9	9
DS_CUB_NN_8	12	12	11	11	12	12	12
DS_LIN_LIN_8	7	7	7	7	7	7	7
DS_LIN_NN_8	11	11	10	10	11	11	11
DS_NN_NN_8	18	18	18	18	18	18	18
D_CUB_CUB_8	5	5	5	5	5	5	5
D_CUB_NN_8	4	4	4	4	4	4	4
D_NN_NN_8	10	10	12	12	10	10	10
DU_CUB_NN_8	15	14	14	14	15	15	15
DU_NN_NN_8	2	2	2	2	2	2	2
DUR_CUB_NN_8	13	13	13	13	13	13	13
DUR_NN_NN_8	1	1	1	1	1	1	1
OLR_CUB_CUB_8	8	8	8	8	8	8	8
OLR_CUB_NN_8	6	6	6	6	6	6	6
OLR_NN_CUB_8	17	17	17	17	17	17	17
OLR_NN_NN_8	16	16	16	16	16	16	16
UD_CUB_NN_8	14	15	15	15	14	14	14
UD_NN_NN_8	3	3	3	3	3	3	3

상세화 자료를 지점 자료인 ASOS 자료와 비교 분석하였다. 여기서, 앞서 분석한 결과에서 보듯이 보간법을 이용한 학습자료는 고해상도 ERA-5 자료와의 이미지 품질과 통계 지표에서 낮은 결과를 보여 평가에서 제외하였다. 지점자료와의 비교이기 때문에 이미지 품질 지표는 제외하였으며 피어슨 상관계수 R^2 는 앞서 분석한 결과에서 보듯이 거의 모두 비슷한 결과를 보였기 때문에 제외하고, MAE, MSE, RMSE만 분석하고 평가하였다.

고해상도 ERA-5 자료는 ASOS 지점자료와 통계 지표 평가에서 MAE는 2.2574, MSE는 9.1358, RMSE는 3.0225였다. 이 결과를 기초로 딥러닝 모델을 평가하였다. 딥러닝 모델의 X 입력자료와 Y 자료가 모두 고해상도 ERA-5 자료에서 생산된 자료이다. 따라서, 딥러닝 모델을 ERA-5 자료와의 유사한 정도를 분석하여 최종 모델을 제안하였다.

CASE OLR에서 2x는 NN_NN, 4x는 CUB_NN, 8x는 CUB_NN 학습자료로 구축한 모델이 좋은 성능을 보였다(Table 3.23). 2x에서 학습자료 Step 2의 자료가 CUB 보간법으로 구축한 경우에, NN에 비해 낮은 예측성을 보였다. 2x는 딥러닝 모델이 미세 조정에 가까운 학습량으로 인해 상대적으로 예측성이 낮은 것으로 판단된다. MAE 비교 그래프는 Figure 3.83과 같다.

Table 3.23. Summary of statistical evaluation metrics comparing CASE OLR results with ASOS observations for the period 2020-2024.

MODEL	MAE	MSE	RMSE	MAE(%)	MSE(%)	RMSE(%)
OLR_CUB_CUB_2	2.7566	14.0346	3.7463	22.11	53.62	23.94
OLR_CUB_NN_2	2.4080	10.5174	3.2431	6.67	15.12	7.30
OLR_NN_CUB_2	2.4918	11.0772	3.3282	10.38	21.25	10.11
OLR_NN_NN_2	2.3951	10.2404	3.2001	6.10	12.09	5.87
OLR_CUB_CUB_4	2.3256	9.6166	3.1011	3.02	5.26	2.60
OLR_CUB_NN_4	2.2907	9.3201	3.0529	1.47	2.02	1.00
OLR_NN_CUB_4	2.4030	10.2450	3.2008	6.45	12.14	5.90
OLR_NN_NN_4	2.4137	10.3718	3.2205	6.92	13.53	6.55
OLR_CUB_CUB_8	2.3678	9.8253	3.1345	4.89	7.55	3.71
OLR_CUB_NN_8	2.3626	9.8055	3.1314	4.66	7.33	3.60
OLR_NN_CUB_8	2.6381	12.1682	3.4883	16.86	33.19	15.41
OLR_NN_NN_8	2.6358	12.1672	3.4882	16.76	33.18	15.40




Figure 3.83. MAE comparison between CASE OLR results and ASOS observations for the period 2020-2024.

CASE D에서 2x는 NN_NN, 4x는 CUB_NN, 8x는 CUB_CUB 학습자료로 구축한 모델이 좋은 예측성을 보였다(Table 3.11). CASE OLR과 비슷하게 학습자료 Step 2의 자료가 NN 보간법으로 구축한 경우에 전반적으로 좋은 예측성을 보였지만, 보조변수 DEM 자료로 인해 8x에서는 오히려 Step 2에 CUB 보간법을 적용했을 때 좋은 예측성을 보였다. MAE 비교 그래프는 Figure 3.84과 같다.

Table 3.24. Summary of statistical evaluation metrics comparing CASE D results with ASOS observations for the period 2020-2024.

MODEL	MAE	MSE	RMSE	MAE(%)	MSE(%)	RMSE(%)
D_CUB_CUB_2	2.2899	9.4151	3.0684	1.44	3.06	1.52
D_CUB_NN_2	2.2395	8.9376	2.9896	0.79	2.17	1.09
D_NN_NN_2	2.2508	9.0425	3.0071	0.29	1.02	0.51
D_CUB_CUB_4	2.2792	9.3244	3.0536	0.96	2.06	1.03
D_CUB_NN_4	2.2636	9.1536	3.0255	0.27	0.19	0.10
D_NN_NN_4	2.3820	10.0416	3.1688	5.52	9.91	4.84
D_CUB_CUB_8	2.2775	9.0625	3.0104	0.89	0.80	0.40
D_CUB_NN_8	2.2613	8.9842	2.9974	0.17	1.66	0.83
D_NN_NN_8	2.4288	10.3405	3.2157	7.59	13.19	6.39




Figure 3.84. MAE comparison between CASE D results and ASOS observations for the period 2020-2024.

CASE DU에서 모든 상세화 배율에서 NN_NN이 좋은 예측성을 보였다(Table 3.25). CASE DU 모델은 학습자료의 Step 1 자료를 이용하여 학습하며 딥러닝 모델 네트워크 내에서 upsample 레이어를 통해 고해상도 자료와 격자 크기를 맞춘다. MAE 비교 그래프는 Figure 3.85과 같다.

Table 3.25. Summary of statistical evaluation metrics comparing CASE DU results with ASOS observations for the period 2020-2024.

MODEL	MAE	MSE	RMSE	MAE(%)	MSE(%)	RMSE(%)
DU_CUB_NN_2	2.3021	9.4549	3.0749	1.98	3.49	1.73
DU_NN_NN_2	2.2571	9.1302	3.0216	0.01	0.06	0.03
DU_CUB_NN_4	2.4532	10.6976	3.2707	8.67	17.10	8.21
DU_NN_NN_4	2.2646	9.1761	3.0292	0.32	0.44	0.22
DU_CUB_NN_8	2.6091	12.0659	3.4736	15.58	32.07	14.92
DU_NN_NN_8	2.2721	9.2143	3.0355	0.65	0.86	0.43




Figure 3.85. MAE comparison between CASE DU results and ASOS observations for the period 2020-2024.

CASE DUR 모델도 CASE DU와 같이 모든 상세화 배율에서 NN_NN이 좋은 예측성을 보였다(Table 3.26). CASE DUR 모델도 CASE DU과 같이 학습자료의 Step 1 자료를 이용하여 학습하며 딥러닝 모델 네트워크 내에서 upsample 레이어를 통해 고해상도 자료와 격자 크기를 맞춘다. MAE 비교 그래프는 Figure 3.86과 같다.

Table 3.26. Summary of statistical evaluation metrics comparing CASE DUR results with ASOS observations for the period 2020-2024.

MODEL	MAE	MSE	RMSE	MAE(%)	MSE(%)	RMSE(%)
DUR_CUB_NN_2	2.3951	10.2404	3.2001	6.10	12.09	5.87
DUR_NN_NN_2	2.2580	9.1343	3.0223	0.03	0.02	0.01
DUR_CUB_NN_4	2.4748	10.8911	3.3002	9.63	19.21	9.18
DUR_NN_NN_4	2.2584	9.1295	3.0215	0.05	0.07	0.03
DUR_CUB_NN_8	2.5923	11.8876	3.4478	14.83	30.12	14.07
DUR_NN_NN_8	2.2763	9.2410	3.0399	0.84	1.15	0.57




Figure 3.86. MAE comparison between CASE DUR results and ASOS observations for the period 2020-2024.

CASE UD 모델도 CASE DU와 CASE DUR 같이 모든 상세화 배율에서 NN_NN이 좋은 예측성을 보였다(Table 3.27). CASE DUR 모델도 CASE DU와 CASE DUR 같이 학습자료의 Step 1 자료를 이용하여 학습하며 딥러닝 모델 네트워크 내에서 upsample 레이어를 통해 고해상도 자료와 격자 크기를 맞춘다. MAE 비교 그래프는 Figure 3.87과 같다.

Table 3.27. Summary of statistical evaluation metrics comparing CASE UD results with ASOS observations for the period 2020-2024.

MODEL	MAE	MSE	RMSE	MAE(%)	MSE(%)	RMSE(%)
UD_CUB_NN_2	2.2997	9.4417	3.0727	1.87	3.35	1.66
UD_NN_NN_2	2.2576	9.1364	3.0227	0.01	0.01	0.00
UD_CUB_NN_4	2.3958	10.2152	3.1961	6.13	11.81	5.74
UD_NN_NN_4	2.2672	9.1705	3.0283	0.43	0.38	0.19
UD_CUB_NN_8	2.5129	11.0891	3.3300	11.32	21.38	10.17
UD_NN_NN_8	2.2743	9.2433	3.0403	0.75	1.18	0.59




Figure 3.87. MAE comparison between CASE UD results and ASOS observations for the period 2020-2024.

전체 2x 평가 모델의 통계 평가 지표는 UD_NN_NN_2, DUR_NN_NN_2, DU_NN_NN 순으로 좋은 결과를 보였다(Table 3.28). 4x는 DUR_NN_NN_4, D_CUB_NN, UD_NN_NN_4 순으로 좋은 결과를 보였으며, 8x는 DU_NN_NN_8, D_CUB_CUB_8, DUR_NN_NN_8 순으로 좋은 결과를 보였다(Table 3.29, 3.30).

전체 상세화 배율 결과에서 보듯이 EDSR 모델을 기반으로 하는 상세화 딥러닝 모델에서는 NN 모델이 다른 모델에 비해 상대적으로 좋은 결과를 보인 것으로 나타났다(Appendix [A1], [A2]). 그러나, 우리가 사용하는 기후자료는 NN 보간법으로 생성된 자료보다 LIN, CUB 보간법에 의해 생성된 자료에 더 가깝다. 따라서, 이 실험에서는 NN_NN 모델이 좋은 성능을 보였으나, 향후에는 원시자료에서 시작하여 상세화하고 참값이 없는 점을 감안하여 ASOS 관측자료 등과의 평가를 통한 모델 분석이 필요할 것으로 판단된다.

Table 3.28. Ranking summary of statistical evaluation metrics for all 2x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.

MODEL	Rank		
	MAE	MSE	RMSE
OLR_CUB_CUB_2	14	14	14
OLR_CUB_NN_2	12	12	12
OLR_NN_CUB_2	13	13	13
OLR_NN_NN_2	10	10	10
D_CUB_CUB_2	7	7	7
D_CUB_NN_2	5	5	5
D_NN_NN_2	4	4	4
DU_CUB_NN_2	9	9	9
DU_LIN_LIN_2	6	6	6
DU_NN_NN_2	2	3	3
DUR_CUB_NN_2	10	10	10
DUR_NN_NN_2	3	2	2
UD_CUB_NN_2	8	8	8
UD_NN_NN_2	1	1	1

Table 3.29. Ranking summary of statistical evaluation metrics for all 4x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.

MODEL	Rank		
	MAE	MSE	RMSE
OLR_CUB_CUB_4	7	7	7
OLR_CUB_NN_4	6	5	5
OLR_NN_CUB_4	10	10	10
OLR_NN_NN_4	11	11	11
D_CUB_CUB_4	5	6	6
D_CUB_NN_4	2	2	2
D_NN_NN_4	8	8	8
DU_CUB_NN_4	13	13	13
DU_LIN_LIN_4	12	12	12
DU_NN_NN_4	3	4	4
DUR_CUB_NN_4	14	14	14
DUR_NN_NN_4	1	1	1
UD_CUB_NN_4	9	9	9
UD_NN_NN_4	4	3	3

Table 3.30. Ranking summary of statistical evaluation metrics for all 8x deep learning-based downscaling models against ASOS observations. Bold text indicates the 1st, 2nd and 3rd ranks.

MODEL	Rank		
	MAE	MSE	RMSE
OLR_CUB_CUB_8	7	7	7
OLR_CUB_NN_8	6	6	6
OLR_NN_CUB_8	14	14	14
OLR_NN_NN_8	13	13	13
D_CUB_CUB_8	5	1	1
D_CUB_NN_8	1	5	5
D_NN_NN_8	8	8	8
DU_CUB_NN_8	12	12	12
DU_LIN_LIN_8	10	10	10
DU_NN_NN_8	2	2	2
DUR_CUB_NN_8	11	11	11
DUR_NN_NN_8	4	3	3
UD_CUB_NN_8	9	9	9
UD_NN_NN_8	3	4	4

3.4. 기후자료 해상도에 따른 극한기후 재현성 평가

기후자료는 기후변화 감시, 재해 예측, 보건, 농업 및 에너지 모델링, 정책 수립 등 다양한 분야에서 핵심적인 의사결정 기반으로 활용되고 있다. 특히 격자형 기후자료(grided climate datasets)는 관측값의 시간적·공간적 공백을 보완할 수 있는 장점으로 인해, 재분석(reanalysis) 또는 통계적 보간(interpolation)을 통해 생성되어 광범위하게 사용되고 있다. 그러나 이러한 격자 자료는 실제 관측값이 아닌 추정값이라는 점에서 불확실성이 내재되어 있으며, 그 정확도는 관측자료의 품질, 관측망의 밀도, 보간 방법, 해상도, 관측기간 등 다양한 요소에 따라 달라진다. 특히 구조적 불확실성(자료 선택 및 분석 방법)은 극한 기후값을 다룰 때 가장 큰 영향을 미치는 것으로 나타난다(Park et al., 2022).

격자형 자료를 평가하기 위한 노력으로는 교차검증(cross-validation), 앙상블 불확실성 추정, 확률분포 함수, 공간 상관성 분석 등의 기법과 지표가 사용되고 있다. 하지만 대부분의 연구는 평균값을 얼마나 잘 재현하는지에 초점을 맞추며, 극값보다는 연간·계절·월 단위의 시간 스케일에 집중하고 있다.

대부분의 격자형 자료는 평균 기온에 대해서는 일관성을 보이지만, 분산(variance)이나 왜도(skewness) 같은 다른 통계적 특성은 자료 간에 일관되지 않다. 또한 계산 방식(보간법, 동화법, 관측망 구성, 관측기간, 처리 순서 등), 특히 관측망의 구조가 결과에 가장 큰 영향을 미치는 반면, 개별 매개변수의 변화는 영향이 적은 것으로 나타났다.

대부분의 연구는 연구 목적에 따라 서로 다른 자료를 사용하는 것이 바람직하다고 결론짓고 있으며, 관측망이 희박하거나 자료 간 일관성이 낮은 경우에는 여러 재분석 자료의 평균값을 사용하는 것보다 범위를 설정하는 것이 더 적절하다고 권장한다. 그러나 격자형 기후자료는 데이터 크기가 크고 처리에 많은 계산 자원이 필요하기 때문에, 여러 자료를 동시에 사용하는 것이 현실적으로 어려운 경우가 많다. 따라서 목적에 가장 적합한 자료의 정보를 알고 선택하는 것이 중요하다.

각 격자형 기후자료는 엄격한 검증 과정을 거치지만, 이러한 검증은 일반적으로 최종 사용자가 자신의 목적에 맞는 최적의 자료를 선택하는 데 필요한 정보를 제공하기 위한 것이 아닙니다. 또한, 특정 지역이나 특정 기후 재해에 대해 어떤 자료가 가장 적합한지를 평가하는 방법에 대한 동료 검토된 가이드라인은 거의 없습니다. 최근 기업들이 물리적 리스크 평가를 수행하는 사례가 늘고 있는 만큼, 어떤 자료가 이용 가능하며 해당 지역의 극한 및 추세를 얼마나 잘 반영하는지를 아는 것이 매우 중요합니다.

따라서 격자자료의 활용에 있어 단일 기준의 우수성을 판단하기보다는, 연구 목적과 지역 특성에 따라 적절한 자료를 선택하거나 생산하는 기준을 마련하는 것이 중요하다. 이를 위해서는 격자자료의 해상도, 생성 방식, 계산 순서 등이 최종 성능에 미치는 영향을 정량적으로 분석하고, 실제 관측값과의 비교를 통해 신뢰도와 활용 가능성을 평가해야 한다.

본 연구에서는 국내 관측소 자료를 기준으로 1km 및 500m 해상도의 격자형 기후자료를 비교 분석하고, 월별·계절별·지역별 통계지표를 활용하여 두 자료 간의 성능 차이를 평가한

다. 이를 통해 고해상도 자료의 장단점을 파악하고, 향후 기후정보 생산체계의 개선 방향을 제시하고자 한다.

3.4.1. 지형고도와 기온의 연관성

Figure 3.88은 대한민국 전역의 디지털 고도 모델(DEM)을 500m 해상도로 시각화한 것으로, 지형 고도 분포와 관측지점(총 605개)의 공간적 위치 관계를 함께 나타낸 것이다. 고도는 색상 음영으로 표현되며, 녹색은 저지대(100m 이하), 갈색~회색은 고지대(최대 1700m)를 의미한다. 관측지점은 검은색 점으로 표시되어 있으며, 위도 33° N~38° N, 경도 124° E~132° E 범위 내에 고르게 분포한다. 관측지점은 전국적으로 고르게 분포되어 있으나, 고지대 및 산악 지역에서는 밀도가 다소 낮다.

도시 및 평야 지역(예: 수도권, 호남평야, 낙동강 유역 등)에 관측지점이 집중되어 있으며, 이는 인구 밀도 및 접근성과 관련이 있다. 고도와 관측망의 상관성은 모델 검증 시 중요한 요소로, 지형 복잡성이 높은 지역에서의 관측 부족은 예측 정확도에 영향을 줄 수 있다.




Figure 3.88. Spatial Distribution of Observation Stations and DEM Elevation in South Korea (500m Resolution).

Figure 3.89는 우리나라 전역에 위치한 605개 기상 관측지점(ASOS + AWS)의 실제 해발 고도(OBS)와, 해당 지점에 가장 가까운 500m 해상도 DEM 격자(PRISM)에서 추출한 고도값 간의 차이를 비교한 결과를 시각화한 것이다. 이는 지형 기반 모델링 및 공간 보간 과정에서 발생할 수 있는 고도 불일치 문제를 진단하고 보정 가능성을 평가하기 위한 기초 분석이다.

Y축은 고도(m), X축은 관측지점 번호(0~605)를 나타낸다. 녹색 선(PRISM)은 DEM 격자에서 추출된 고도값, 검은색 선(OBS)은 실제 관측지점의 고도이다. 전반적으로 PRISM 고도가 OBS보

다 높게 나타나는 구간이 많으며, 일부 지점에서는 급격한 고도 차이가 나타난다. 이는 DEM 격자의 해상도 한계 또는 지점 주변의 지형 복잡성에 기인할 수 있다. PRISM과 관측 고도와 편차를 보면, 양의 값(빨간색)은 PRISM 고도가 OBS보다 높은 경우, 음의 값(파란색)은 PRISM 고도가 낮은 경우를 의미한다. 대부분의 지점에서 $\pm 100\text{m}$ 이내의 차이를 보이거나, 일부 산악 지점에서는 $\pm 300\text{m}$ 이상의 차이가 발생한다. 이는 지형 경사, 격자 위치 오차, 관측소 설치 환경(지붕, 구조물 등)에 따른 영향으로 해석될 수 있다. 따라서 500m 해상도 DEM은 대부분 지역에서 양호한 성능을 보이지만, 지형 변화가 급격한 지역에서는 오차 발생 가능성이 존재하다는 것을 인식해야 한다.

관측지점의 실제 고도와 DEM 격자에서 추출된 고도 간의 차이가 기온 예측 정확도(RMSE)에 미치는 영향을 평가하였다. 지형 기반 기후모델에서 고도는 중요한 입력 변수이며, 고도 불일치가 예측 오차를 유발할 수 있기 때문에, 이를 정량적으로 진단하는 것이 중요하다. Figure 3.90은 605개 관측지점을 대상으로 관측 고도와 DEM 격자 고도의 일치 정도를 확인하고, 고도 수준 및 고도 불일치가 평균기온 예측 오차에 미치는 영향을 평가한 것이다.




Figure 3.89. Elevation differences between observational data (black) and PRISM DEM (green) for 605 stations.

두 고도값(OBS vs PRISM) 간 전반적인 양의 상관을 보여주며, 관측 고도가 높을수록 PRISM 고도도 함께 증가하는 경향이 뚜렷하다. 다만 일부 지점에서는 PRISM이 관측 대비 과대 또는 과소 추정되는 편차가 확인되어, 지형 경사가 급한 지역이나 복잡한 지형 경계(협곡·해안 인접부)에서 격자 해상도 한계로 인한 불일치가 존재함을 시사한다. 이러한 불일치는 RMSE 증가와 연결되는 원인이다. 고도와 온도경향 그림은 고도가 높아질수록 평균기온 예측 오차가 커지는 완만한 증가 경향을 공통적으로 보여준다. 이는 고지대·산악지역의 기온 변동성이 크고 국지 기상(풍속·복사·눈덮임 등) 영향이 강해, 단순 고도 보정이나 보간으로는 미세한 기온 분포를 충분히 재현하기 어려운 구조적 난이도를 반영한다. 관측 고도와 PRISM 고도 모두에서 유사한 RMSE 패턴이 관측된다. Figure 3.90에서 PRISM과 관측의 고도차가 클수록 RMSE가 체계적으로 증가하는 관계를 확인시켜 준다. 특히 0선(고도차 없음)을 기준으로 양·음 방향으로 차이가 커지는 지점에서 RMSE가 명확히 상승하며, 이는 격자 고도가 실제 관측 환경의 고도와 차이가 클수록 모델 입력의 대표성이 떨어져 예측 오차가 커지는 메커니즘을 가리킨다. 관측과 모델의 고도차는 평균·최고·최저 기온 예측 오차(RMSE)를 체계적으로 증폭시키는 주요 원인이며, 특히 $\pm 200\text{m}$ 이상의 불일치가 발생하는 지점에서 예측 신뢰도가 급격히 저하된다. 따라서 상세화 모델의 정확도를 높이기 위해서는 고도차를 최소화하거나 이를 반영한 보정 과정이 반드시 필요하다.

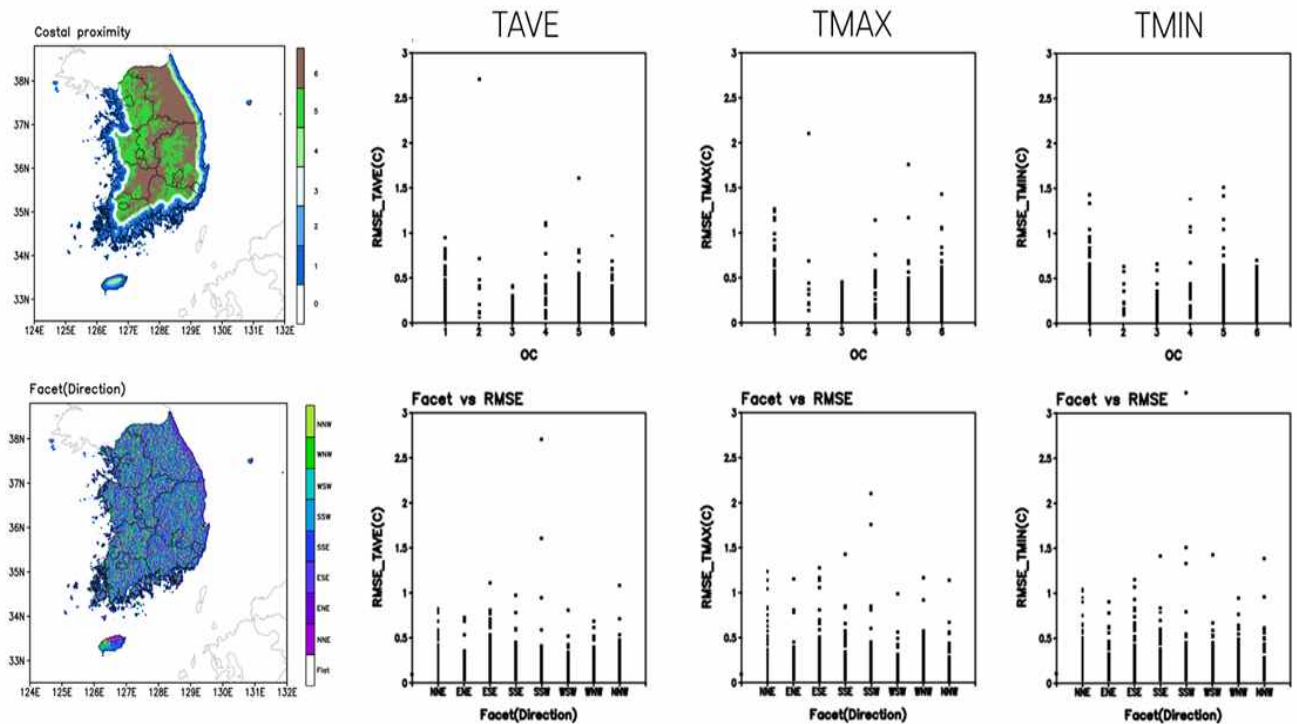


Figure 3.90 Coastal Proximity and Terrain Facet Orientation in Relation to RMSE of Temperature.

우리나라 605개 관측지점을 대상으로 해양 접근성과 지형 지향면이 평균기온, 최고기온, 최저기온의 예측 정확도에 미치는 영향을 분석한 결과, 두 공간 변수 모두 기온의 RMSE에 유의미한 영향을 주는 것으로 나타났다.

먼저 해양 접근성(Coastal Proximity)은 관측지점이 해안선으로부터 얼마나 가까운지를 1에서 6까지의 등급으로 구분하여 분석하였다. RMSE 값은 해안에 가까운 지역일수록 낮게 나타났으며, 특히 OC 등급이 1~2인 지역에서는 예측 오차가 가장 작았다. 이는 해안 지역이 해양성 기후의 영향을 받아 기온 변동성이 작고, 모델이 이를 안정적으로 재현할 수 있기 때문으로 해석된다. 반면 OC 등급이 5~6인 내륙 깊숙한 지역에서는 RMSE가 상대적으로 높게 나타났는데, 이는 일교차가 크고 지형적 요인이 복합적으로 작용하여 모델의 예측이 어려워지는 경향을 반영한다.

지형 지향면(Facet Direction)은 관측지점이 위치한 지형의 경사 방향을 기준으로 8방향(NNE, ENE, ESE, SSE, SSW, WSW, WNW, NNW)으로 분류하여 분석하였다. RMSE 값은 지향면에 따라 다소 차이를 보였으며, 남향(SSE, SSW) 사면에서 예측 오차가 상대적으로 낮게 나타났다. 이는 남향 사면이 태양 복사량을 더 많이 받아 기온 패턴이 안정적이고 예측이 용이하기 때문으로 해석된다. 반면 북향(NNE, NNW) 사면에서는 RMSE가 다소 높게 나타났는데, 이는 복사냉각, 그늘 효과, 눈덮임 지속 등으로 인해 기온 예측이 어려워지는 지역적 특성이 반영된 결과로 볼 수 있다.

이러한 분석 결과는 해양 접근성과 지형 방향이 평균기온 예측 정확도에 영향을 미치는 중요한 공간 변수임을 시사하며, 향후 지역별 보정 계수나 가중치를 적용하는 데 있어 유의미한 기준이 될 수 있다. 특히 해안 인접 지역과 남향 사면은 예측 안정성이 높고, 내륙 및 북향 사면은 예측 취약 지역으로 분류되어 별도의 보정 전략이 요구된다.

3.4.2. 상세화모델들의 예측성 평가

본 연구에서는 기존의 1km 격자자료를 기반으로 하여 격자해상도와 영향반경 민감도를 평가하기 위해서 Table 3.31과 같이 3가지 모델의 실험을 하였다. 관측소 기온 자료와 GIS 기반 DEM(디지털 고도모델)을 결합하여 공간적으로 보간한 상세격자모델이다. 이 모델들은 해상도와 영향 반경, GIS 데이터의 차이에 따라 공간적 정밀성과 예측 성능에서 뚜렷한 차이를 보인다.

MK_PRISM은 약 1km 격자 해상도로 구축된 모델로, 총 751×601 격자를 포함한다. 영향 반경은 30km로 설정되어 있으며, 각 격자에 대해 최소 5개 이상의 관측지점을 활용하여 기온 값을 산출한다. 이 모델은 NASA ASTER GDEM Version 2(2011)를 기반으로 제작되었으며, 2000년부터 2019년까지의 20년간 일평균기온(TAVE), 일최저기온(TMIN), 일최고기온(TMAX)을 분석하는 데 사용되었다. MK_PRISM은 비교적 넓은 영향 반경을 설정하여 관측소 밀도가 낮은 지역에서도 안정적인 값을 산출할 수 있는 장점이 있으나, 해상도가 낮아 세밀한 지형 변화를 반영하는 데에는 한계가 있다. 따라서 전국 단위의 광역적 기후 특성을 파악하는 데 적합하다.

MS_PRISM(500m_v1)은 약 500m 해상도의 격자(1501×1201)를 기반으로 구축된 모델이다. 영향 반경은 2.2km로 설정되어 있으며, 최대 13개의 격자를 활용하여 기온 값을 산출한다. 이 모델 역시 NASA ASTER GDEM Version 2(2011)를 기반으로 제작되었으며, 동일한 기간(2000-

2019년)의 기온 변수를 분석하는 데 사용되었다. [500m_v1] 모델은 MK_PRISM보다 해상도가 높아 지형의 세밀한 변화를 더 잘 반영할 수 있으며, 국지적 특성을 보다 정밀하게 표현할 수 있다. 그러나 영향 반경이 상대적으로 넓어 주변 격자의 평균화 효과가 발생할 수 있으며, 이는 특정 지점의 특성을 희석시키는 요인으로 작용할 수 있다. 따라서 국지적 정밀성과 광역적 안정성 사이에서 균형을 이루는 중간 단계 모델로 평가된다.

MS_PRISM(500m_v2)은 동일한 500m 해상도를 가지지만, 영향 반경을 1.3km로 축소하여 최대 5개의 격자만을 활용하도록 설계된 최신 모델이다. 특히 섬 지역의 경우 타겟 격자와의 거리가 20km 이상이면 제외하는 방식으로 공간 대표성을 강화하였다. 이 모델은 NASA ASTER GDEM Version 3(2019)와 국토교통부 시도경계(2024-02-21)를 결합하여 최신 GIS 정보를 반영한 것이 특징이다. 500m_v2 모델은 좁은 영향 반경을 통해 국지적 특성을 보다 정확히 반영할 수 있으며, 최신 지형 데이터와 행정구역 정보를 활용하여 공간적 정밀성이 크게 향상되었다. 따라서 고지대, 해안, 섬 지역 등 지형적 복잡성이 큰 지역에서 예측 성능이 가장 우수한 것으로 평가된다. 이 모델은 국지적 기후 특성을 정밀하게 분석하고, 공간적 불일치로 인한 예측 오차를 최소화하는 데 강점을 가진다 (Table 3.31).

Table 3.31. Model Specifications: Resolution and Influence Radius.

Model	Resolution	영향반경	GIS information	변수 및 기간
MK_PRISM (1km)	751x601 (Approx. 1km)	- 30km (Min. 5 stations) - Used 605 stations	NASA ASTER GDEM Version 2, 2011	
①MS_PRISM (500m_v1)	1501x1201 (Approx. 500m)	- 2.2km (Max. 13 grids)	NASA ASTER GDEM Version 2, 2011	Tave, Tmin, Tmax (2000~ 2019)
② MS_PRISM (500m_v2)	1501x1201 (Approx. 500m)	- 1.3km(Max. 5 grids) - (Islands) Exclude if distance to target > 20km	NASA ASTER GDEM Version 3, 2019	

모델들의 예측성을 분석하기 위해서, 본 연구에서는 2000년부터 2019년까지 20년간의 관측자료를 기반으로, 세 가지 상세격자모델([500m_v2], [500m_v1], [1km])의 일 평균기온(TMEAN), 일최고기온(TMAX), 일 최저기온(TMIN) 예측 성능을 평가를 수행하였다.

평가지표로는 평균 제곱근 오차(RMSE), 편의(BIAS), 상관계수(Cor), 결정계수(R^2)를 사용하였다. 예측 변동성은(Cor, R^2)세 가지 모델 모두 기온 변화의 경향을 매우 정확하게 예측하고 있다. 모든 변수(TMAX, TAVE, TMIN)에 대해 세 모델 모두 대부분의 지역에서 상관계수 및 결정계수 값이 0.98 이상으로 매우 높게 나타난다. 이는 모델의 격자 해상도나 영향반경의 차이

에 관계없이 기온의 변동성을 재현하는 능력은 동등하게 매우 우수함을 의미한다. 모든 모델에서 오차(RMSE)는 주로 내륙 산간 지역 및 북부 지역에서 크게 나타나는 경향이 있으며, [500_v2] 모델이 전반적으로 오차 값이 가장 낮게 분포하며, 오차가 큰 지역의 범위와 강도가 가장 약하게 나타나 가장 높은 예측 정확도를 보였다. 예측 편향 특성 (BIAS)은 예측값이 관측값에 비해 과대(양수, 빨간색) 또는 과소(음수, 파란색) 예측되는 경향을 나타낸다.

Gridded Model Performance Comparison (2000-2019) - Variable: TAVE

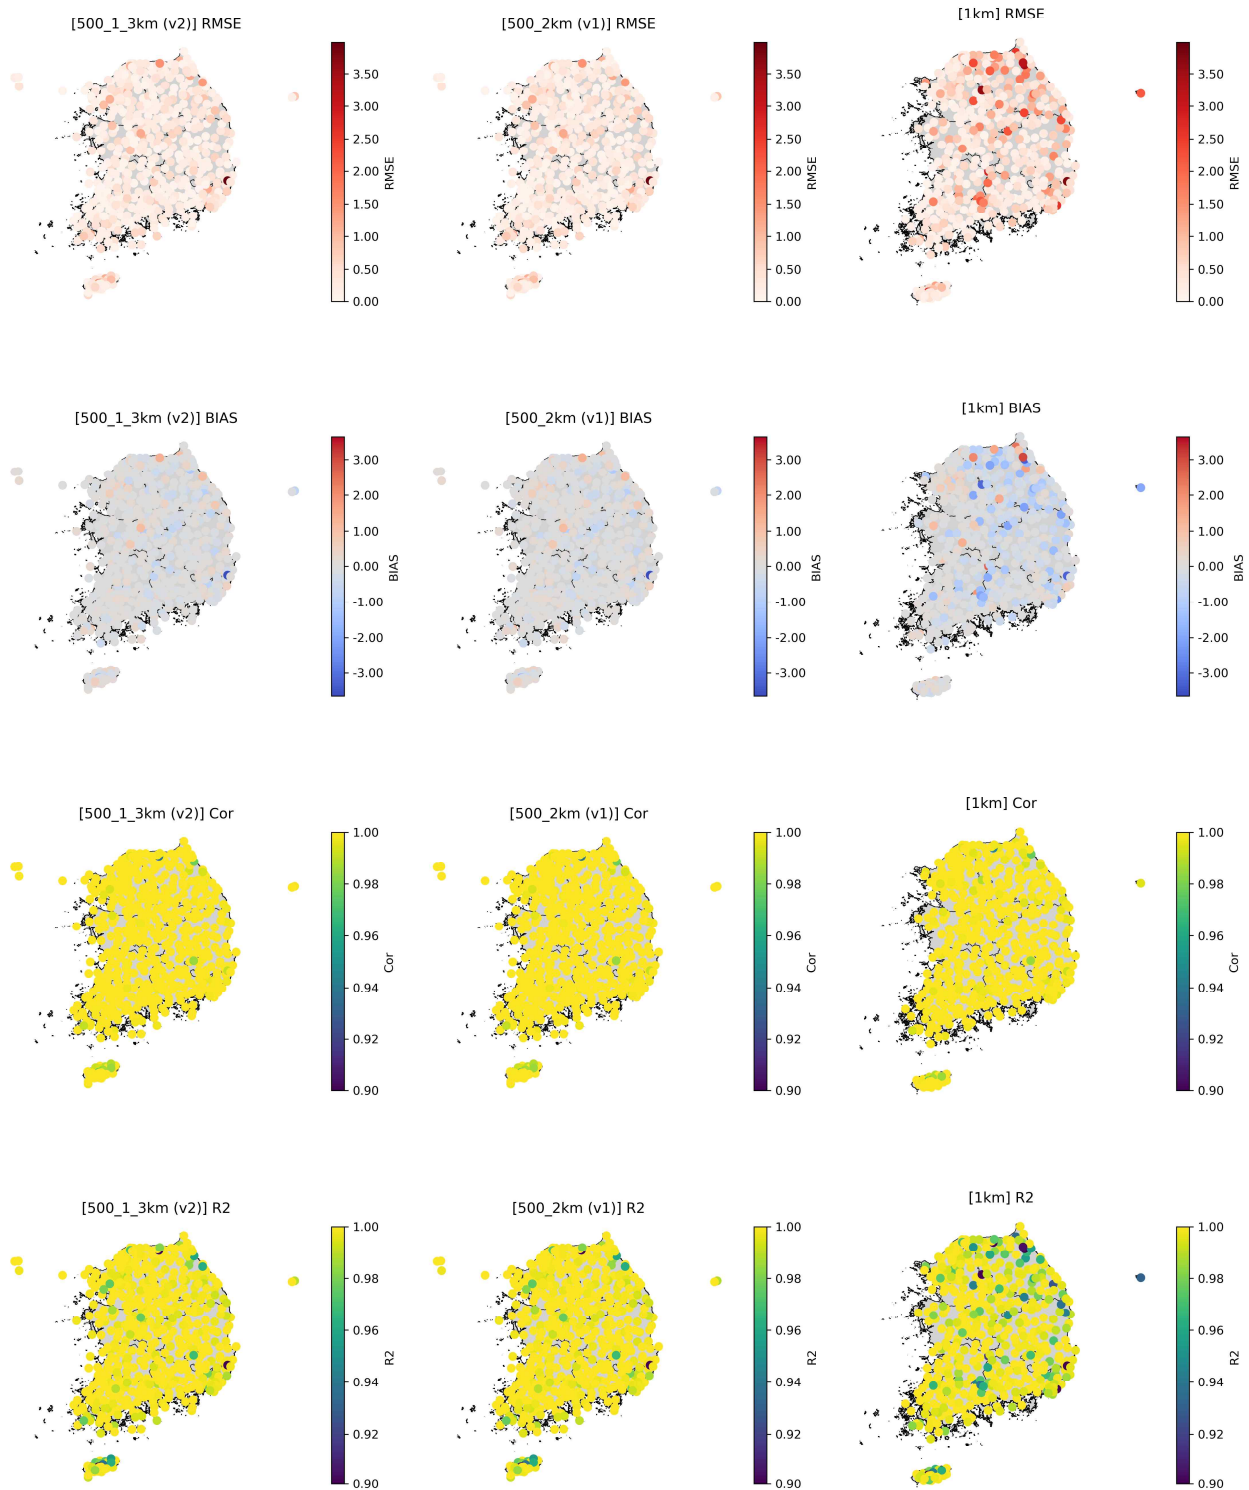


Figure 3.91. Gridded Model Performance Comparison for TAVE (2000–2019).

Gridded Model Performance Comparison (2000-2019) - Variable: TMAX

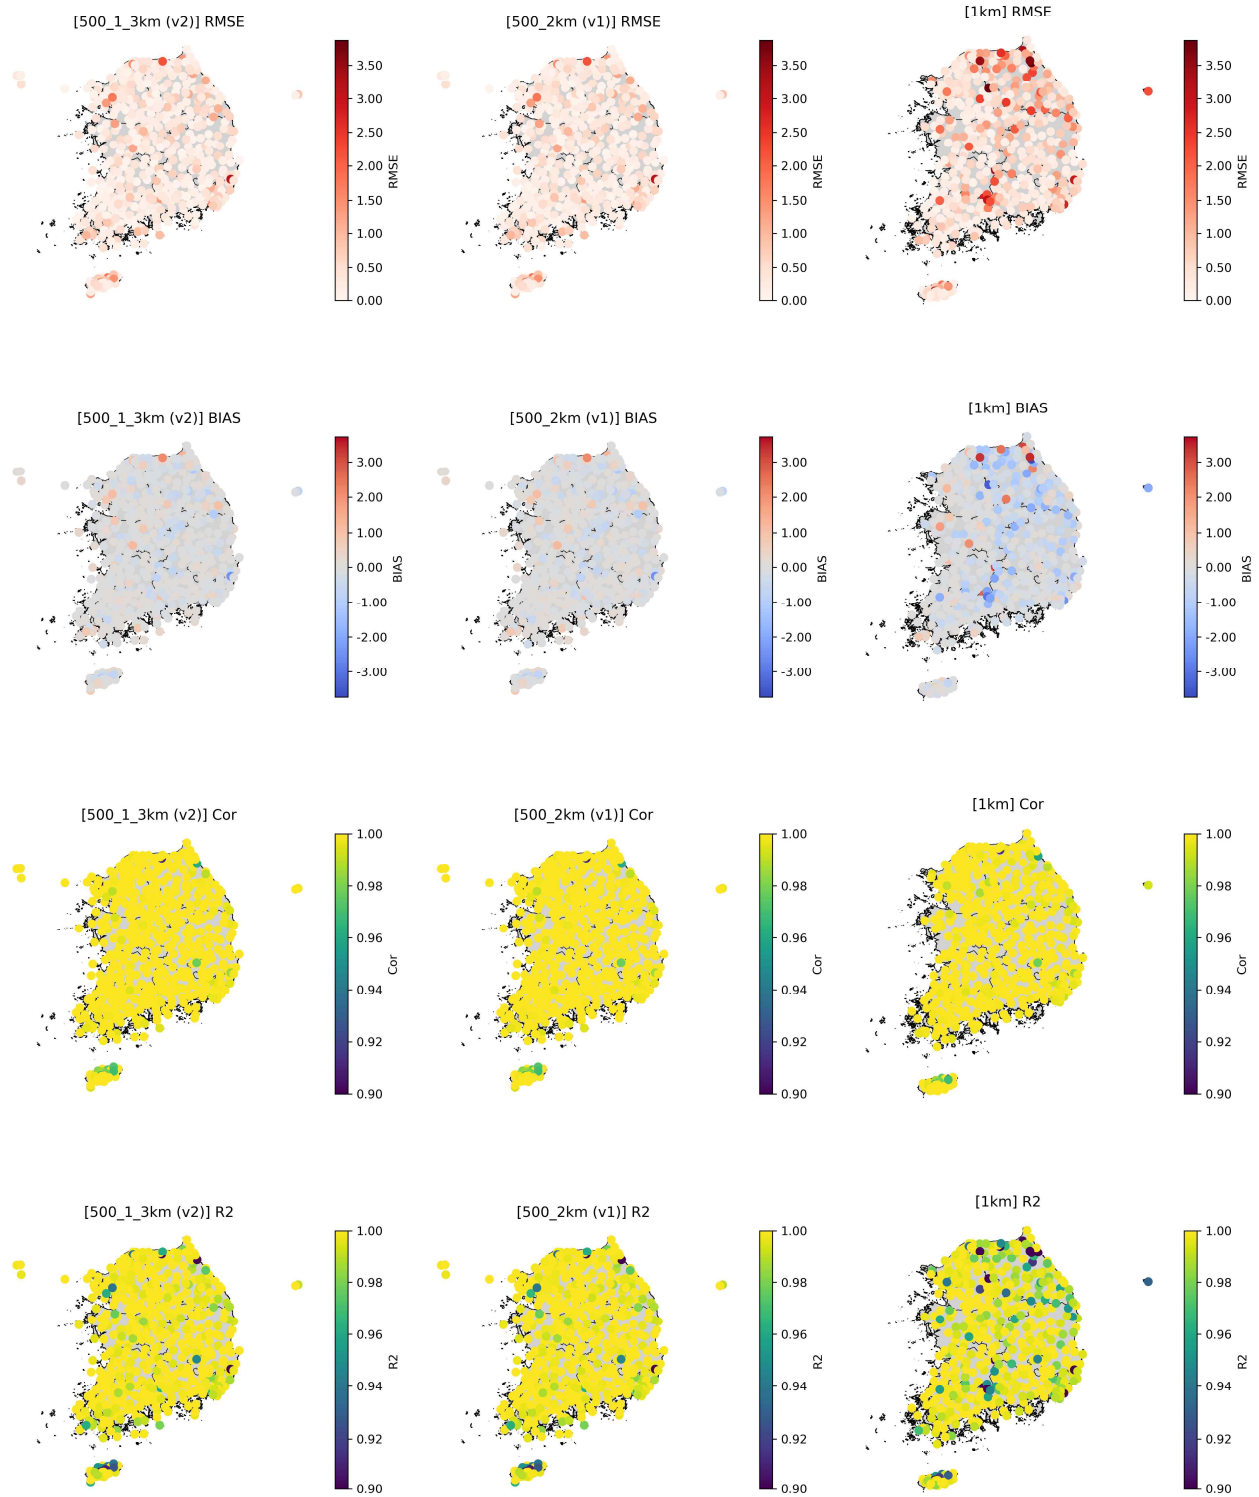


Figure 3.92. Gridded Model Performance Comparison for TMAX (2000-2019).

Gridded Model Performance Comparison (2000-2019) - Variable: TMIN

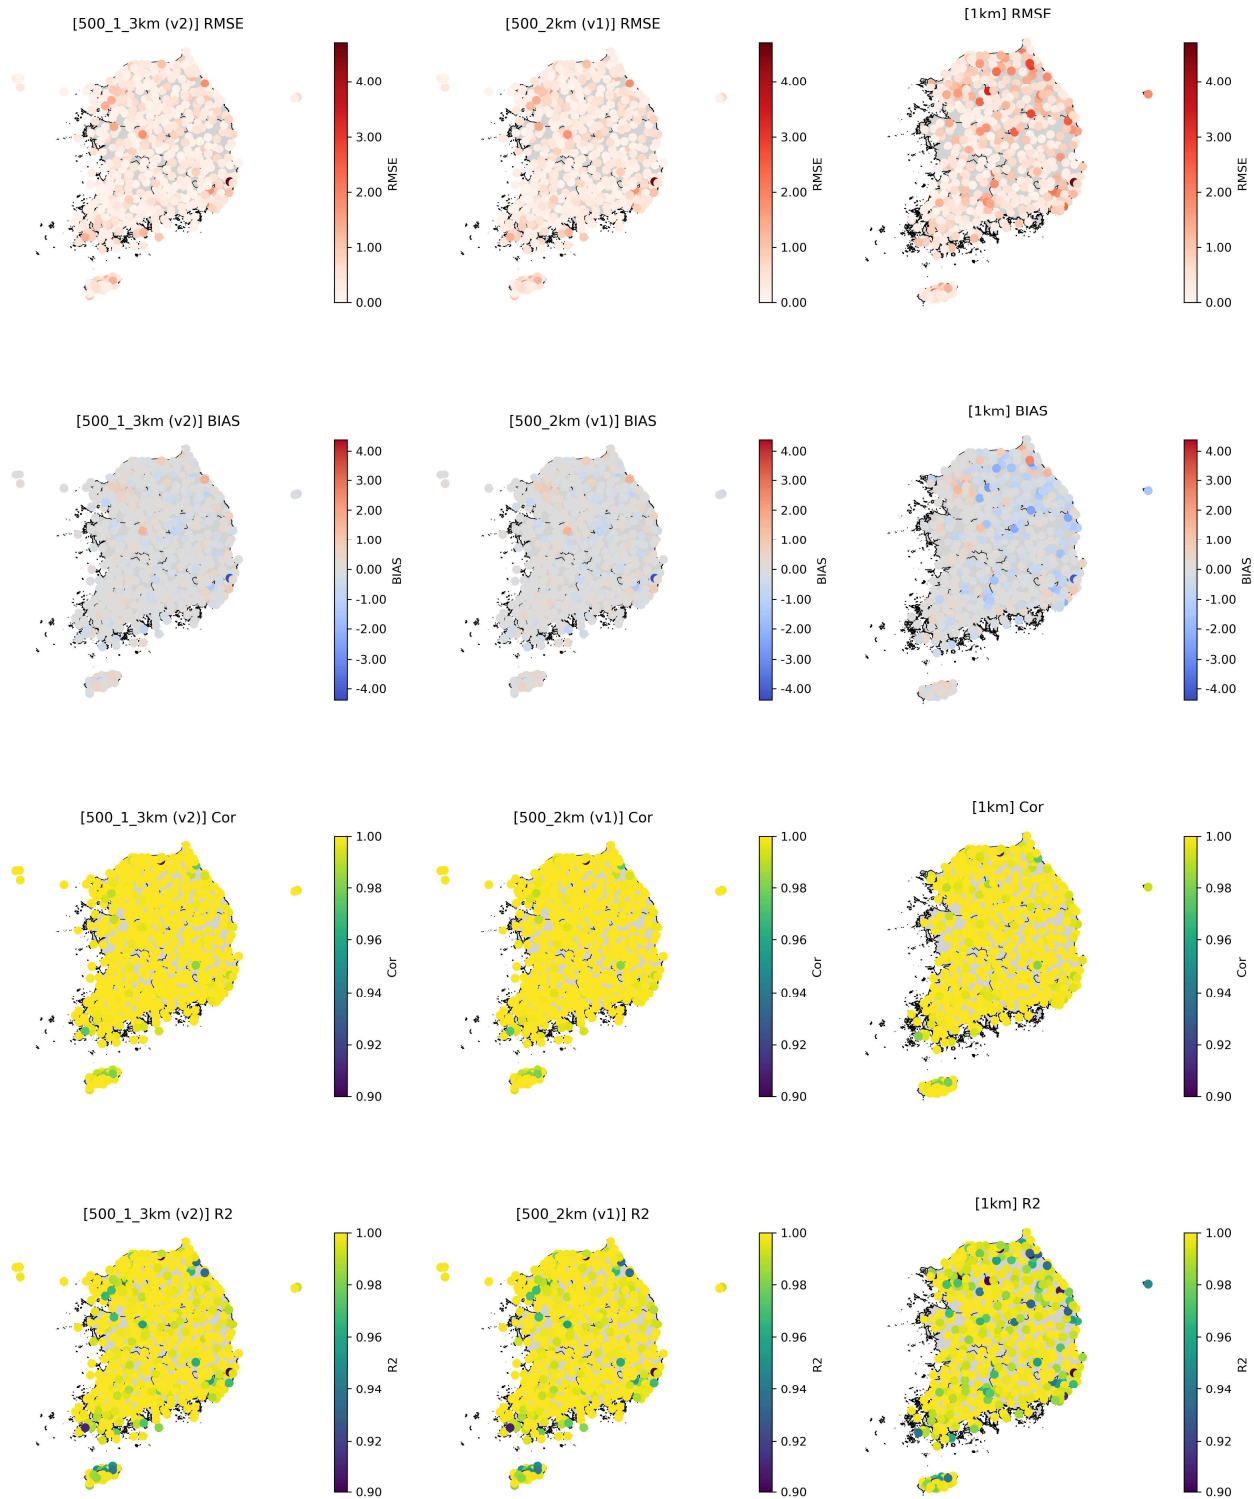


Figure 3.93. Gridded Model Performance Comparison for TMIN (2000–2019).

평균기온(TAVE)은 모델별로 공간적인 편향 특성이 다소 상이하나, [500_v2]가 전반적으로 편향의 값이 0에 가장 가깝게 분포하여 가장 낮은 시스템적 편향을 보인다(Figure 3.91). 최고기온(TMAX)은 세 모델 모두 양의 편향이 우세하게 나타나고 있어, 실제 최고 기온을 과대 예측하는 경향이 있다(Figure 3.92). 최저기온(TMIN)은 세 모델 모두 음의 편향이 우세하게 나타나, 실제 최저 기온을 과소 예측하는 경향이 있는 것으로 나타났다(Figure 3.93). 특히 북부 지역에서 그 경향이 뚜렷하게 나타나고 있다. 모든 성능 지표를 종합적으로 분석한 결과, [500_v2] 격자 모델이 세 가지 기온 변수(TMAX, TAVE, TMIN) 모두에서 가장 우수한 성능을 보였다. [500_v2]는 오차 크기(RMSE)와 시스템적 편향(BIAS) 측면에서 다른 두 모델([500_v1], [1km])보다 명확하게 개선된 결과를 보였다.

월별 상자그림(Boxplot) 분석에서는 2000~2019년 20년간의 R^2 , Cor, BIAS 분포를 월별로 시각화하여 모델별 성능의 계절적 안정성을 평가하였다. 월별 상자그림(Boxplot) 분석에서는 2000~2019년 20년간의 관측자료를 기반으로, 세 가지 격자 모델([500m_v2], [500m_v1], [1km])의 평균기온(TAVE) 예측 성능을 월별로 비교한 결과를 나타낸다. 각 그림은 상관계수(R^2), 상관성(Cor), 편향(BIAS) 지표에 대한 박스플롯(Boxplot) 형식으로 구성되어 있으며, 모델별 예측력과 계절별 변동성을 동시에 평가할 수 있다. 전반적으로 세 모델 모두 겨울철(1~2월)과 여름철(7~8월)에 R^2 값이 다소 낮아지는 경향을 보였으며, 이는 극한 기온 조건에서 모델의 예측 난이도가 높아지는 현상을 반영한다. 특히 [500m_v2] 모델은 모든 월에서 중앙값(Median)이 0.97 이상으로 유지되며, 상자 길이(IQR)가 짧아 예측 안정성이 높음을 보여준다. 반면 [1km] 모델은 월별 변동성이 크고, 일부 월에서는 하위 분위값(Q1)이 0.92 이하로 떨어지는 사례도 존재한다(Figure 3.94).

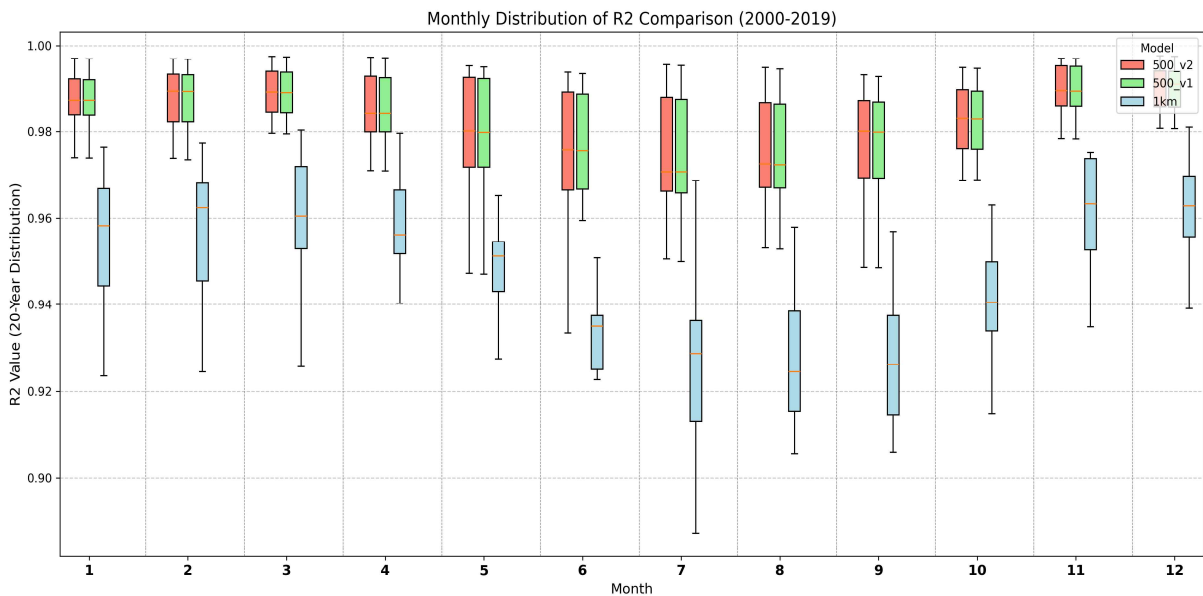


Figure 3.94. Boxplot Analysis of Monthly R^2 for TAVE Prediction Across Three Grid Models (2000~2019).

상관계수 박스플롯은 예측값과 관측값 간의 상관성을 나타내며, 세 모델 모두 0.95 이상의 높은 상관성을 유지하지만, [500m_v2]가 월별로 가장 안정적인 분포를 보인다(Figure 3.8). 특히 극한 기온이 발생하는 1~2월, 7~8월에도 Cor 값이 크게 흔들리지 않는다. BIAS 박스플롯은 예

측값의 평균 편향을 나타내며, [1km] 모델은 모든 월에서 -0.20°C 수준의 지속적인 과소 예측 경향을 보인다(Figure 3.96). 반면 [500m_v2]와 [500m_v1] 모델은 편향이 0에 가까운 값으로 분포하며, 예측의 균형성이 우수하다. 특히 [500m_v2] 모델은 공간적·계절적 안정성 모두에서 가장 우수한 성능을 보였다. 월별 평균제곱근 오차(RMSE)분포를 보면, [500m_v2]모델이 다른 두 모델에 비해 우수한 예측정보를 나타내고 있다. 500m 해상도의 두 모델은 RMSE 중앙값이 대부분 0.3°C ~ 0.55°C 사이에 위치하는 반면, 1km 모델의 중앙값은 0.75°C ~ 0.9°C 이므로 현저히 높게 나타난다. 이는 격자 해상도가 향상되면서 예측오차가 크게 감소했음을 의미한다. 월별 변화를 통해 계절적 패턴을 확인하였다. 여름철에 RMSE 중앙값이 0.35°C 내외로 연중 가장 낮은 값을 기록하였고, 겨울철에는 0.4°C 에서 0.55°C 범위에 분포하며, 예측오차가 가장 크게 나타나는 시기다. 따라서 RMSE는 500m_v2 모델이 우수하고 안정적이며, 특히 여름철에 가장 높은 정확도를 보이는 것으로 분석되었다.

이러한 결과는 모델의 공간 해상도뿐 아니라 계절별 기후 특성에 대한 민감도가 예측 성능에 영향을 미친다는 점을 보여준다. 특히 겨울철 복사냉각, 여름철 국지성 강수 및 대류 활동 등은 모델의 선형 예측 구조에 도전이 되는 요소로 작용하며, 이를 보완하기 위한 계절별 보정 모듈 또는 비선형 보간 기법이 필요할 수 있다. 기후변화 시나리오 모델 적용에 있어 가장 신뢰할 수 있는 격자 자료로 평가된다.

모델별 성능평가 결과를 바탕으로, 다음 절에서는 예측 정확도와 일관성을 동시에 고려한 KGE 지표를 중심으로 모델 성능을 추가적으로 평가하였다.




Figure 3.95. Boxplot Analysis of Monthly Correlation coefficient for TAVE Prediction Across Three Grid Models (2000~2019).

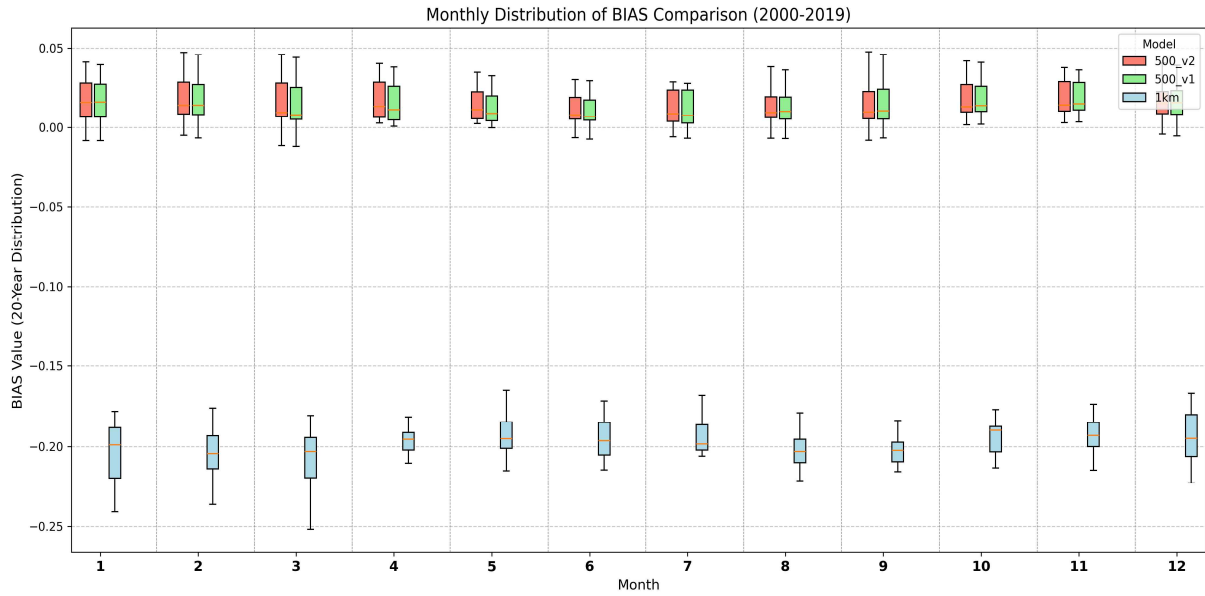


Figure 3.96. Boxplot Analysis of Monthly BIAS for TAVE Prediction Across Three Grid Models(2000~2019).

3.4.3. KGE 기반 종합 성능 분석

모델의 예측 성능을 평가하기 위해서는 다양한 통계 지표가 활용된다. 일반적으로 RMSE(Root Mean Square Error)는 평균 오차 크기를, BIAS는 예측값의 과대·과소 경향을, COR(Correlation)는 관측값과 예측값 간의 선형 상관성을, R^2 (Coefficient of Determination)는 예측값이 관측값의 변동을 얼마나 설명하는지를 나타낸다. 이러한 지표들은 각각 모델 성능의 특정 측면을 잘 보여주지만, 단일 지표만으로는 모델의 종합적인 성능을 평가하기 어렵다. 예를 들어, RMSE가 낮더라도 BIAS가 크게 존재할 수 있으며, COR가 높더라도 실제 오차 크기가 클 수 있다. 따라서 개별 지표를 종합적으로 고려할 수 있는 통합 성능 지표가 필요하다.

이러한 배경에서 제안된 것이 KGE(Kling-Gupta Efficiency) 지표이다. KGE는 기존의 Nash-Sutcliffe Efficiency(NSE) 지표의 한계를 보완하기 위해 개발된 통합 성능 지표로, 모델 예측의 상관성(COR), 평균 편향(BIAS), 변동성 재현력(분산비)을 동시에 고려한다. 즉, KGE는 단순히 예측값과 관측값의 일치 정도를 평가하는 것이 아니라, 패턴의 유사성(COR), 평균값의 일치성(BIAS), 변동성의 재현성(분산비)을 함께 반영하여 모델의 성능을 다차원적으로 평가한다.

KGE의 값은 일반적으로 $-\infty$ 에서 1 사이에 분포하며, 1에 가까울수록 모델의 예측 성능이 우수함을 의미한다(Table 3.32). 이 지표는 RMSE, COR, BIAS, R^2 와 같은 개별 지표의 정보를 통합하여 하나의 수치로 제시하기 때문에, 모델 간 성능 비교를 직관적이고 종합적으로 수행할 수 있는 장점이 있다. 특히 본 연구와 같이 상세격자모델의 해상도와 영향 반경에 따른 성능 차이를 평가할 때, KGE는 개별 지표에서 나타나는 상충된 결과를 조정하고, 모델의 전반적인 신뢰도를 판단하는 데 중요한 기준을 제공한다. 따라서 본 절에서는 앞서 제시한 RMSE, BIAS, COR, R^2 분석 결과를 바탕으로, KGE 지표를 활용하여 세 상세격자모델(MK_PRISM,

MS_PRISM v1, MS_PRISM v2)의 종합 성능을 비교·평가하고자 한다. 이를 통해 개별 지표에서 확인된 특성을 통합적으로 검토하고, 모델 선택 및 활용에 있어 보다 객관적이고 신뢰성 있는 결론을 도출할 수 있다.

본 연구에서는 우리나라 605개 관측소의 20년간(2000-2019) 기온 자료를 기반으로, 세 가지 상세격자모델(500m_v2, 500m_v1, 1km)의 예측 성능을 KGE(Kling-Gupta Efficiency) 지표를 통해 종합적으로 평가하였다. KGE는 예측값의 상관성(COR), 평균 편향(BIAS), 변동성 재현력(분산비)을 통합적으로 고려하는 지표로, 기존의 RMSE, R^2 , COR, BIAS와 같은 개별 지표의 한계를 보완하며 모델의 전반적인 예측력과 안정성을 하나의 수치로 표현할 수 있는 장점이 있다.

KGE 분석은 세 가지 기온 변수—일평균기온(TAVE), 일최저기온(TMIN), 일최고기온(TMAX)—에 대해 수행되었으며, 각 모델별로 전국 관측지점에서 산출된 KGE 값을 기반으로 박스플롯과 공간 분포도를 통해 시각적으로 비교하였다.

Table 3.32. Model Performance Evaluation Based on KGE Values.

KGE Value Range	Accuracy / Model Performance Interpretation
$KGE \geq 0.75$	Excellent: Model accurately reproduces observed values.
$0.50 \leq KGE < 0.75$	Good : Model is generally reliable.
$0.25 \leq KGE < 0.50$	Fair: Model performance is intermidiate; improvement is needed.
$0 \leq KGE < 0.25$	Poor: Model performance is insufficient; reliability is low
$KGE < 0$	Very Poor: Model performance is worse than the mean of the observed values.

먼저 박스플롯 분석 결과를 살펴보면, [500m_v2] 모델이 모든 기온 변수에서 가장 우수한 성능을 보였다(Figure 3.10). TAVE, TMIN, TMAX 모두에서 KGE의 중앙값(Median)이 0.95 이상으로 유지되었으며, 상자 길이(IQR)가 짧아 예측 안정성이 높음을 시사한다. 특히 TAVE와 TMIN에서는 대부분의 지점이 KGE=1.0에 근접한 값을 보이며, 모델의 예측력이 거의 완전한 수준에 도달한 것으로 평가된다. 반면 500m_v1 모델은 중간 수준의 성능을 보였으며, TMAX에서 하위 분위값(Q1)이 0.80 이하로 떨어지는 사례가 관찰되었다. 이는 고온 조건에서 예측 불안정성이 존재함을 의미한다. 1km 모델은 전반적으로 가장 낮은 KGE 값을 보였으며, 특히 TMIN과 TMAX에서 KGE=0.0 이하의 지점들이 다수 존재하였다. 이는 모델 해상도가 낮아 국지적 기온 변동을 충분히 반영하지 못하는 한계를 보여준다.

박스플롯 상에는 두 개의 기준선이 함께 제시되었는데, 하나는 KGE=1.0(완전 예측)을 의미하는 녹색 점선이고, 다른 하나는 KGE=0.0(수용 불가)을 의미하는 붉은 점선이다. 이 기준선을 통해 모델 간 성능 차이를 직관적으로 확인할 수 있으며, 500m_v2 모델만이 모든 변수에서 완전 예측에 근접한 분포를 유지하는 유일한 모델로 평가된다.

공간 분포 분석에서는 각 모델과 변수 조합별로 KGE 값을 지역별로 시각화하여, 기온 예측의 공간적 신뢰도를 평가하였다. TAVE의 경우, [500m_v2] 모델은 전국적으로 0.90 이상의 KGE 값을 유지하며, 해안·내륙·산악 지역 모두에서 고른 성능을 보였다. 반면 [500m_v1] 모델은 중부 내륙과 일부 산악 지역에서 KGE가 0.75 이하로 저하되는 구간이 존재하였고, [1km] 모델은 강원도 및 동부 산악 지역에서 KGE가 0.5 이하로 급감하며 공간적 불균형이 뚜렷하게 나타났다(Figure 3.98).

TMIN 분석에서는 복사냉각이 강한 지역에서도 [500m_v2] 모델이 0.85 이상의 안정적인 KGE 분포를 보이며, 국지적 냉각 효과를 잘 반영하는 것으로 나타났다. [500m_v1] 모델은 일부 고지대에서 KGE가 0.6 이하로 떨어지는 사례가 관찰되었고, [1km] 모델은 산악 및 북부 내륙에서 KGE가 -0.2 이하로 저하되는 지점이 다수 존재하여 예측 실패 수준에 해당하는 결과를 보였다.




Figure 3.97. Boxplot Comparison of KGE Values for TAVE, TMIN, and TMAX Across Three Grid Models (2000–2019).

TMAX의 경우, 500m_v2 모델은 대도시 및 해안 지역에서 0.90 이상의 높은 KGE 분포를 보이며, 복잡한 열섬 효과도 일정 수준 반영하는 것으로 평가된다. 반면 [500m_v1] 모델은 일부 내륙 지역에서 KGE가 0.7 이하로 저하되며 고온 예측의 불안정성이 존재하였고, [1km] 모델은 전국적으로 KGE가 고르게 낮으며 0.4 이하의 저성능 지역이 광범위하게 분포하였다.

이상의 결과를 종합하면, [500m_v2] 모델은 TAVE, TMIN, TMAX 모든 변수에서 가장 높은 예측 성능과 공간적 안정성을 보였다. 박스플롯과 공간 분포 모두에서 고해상도와 정밀한 영향 반경 설정이 예측 성능 향상에 결정적인 역할을 한다는 점이 확인되었다. 반면 1km 모델은 해상도와 GIS 정보의 한계로 인해 예측력이 저하되며, 특히 국지적 기온 변동이 큰 지역에서 성

능이 급격히 떨어지는 경향을 보였다.

따라서 상세격자모델의 선택에 있어 KGE는 단일 지표의 한계를 보완하고, 모델의 종합적 신뢰도를 판단하는 핵심 기준으로 활용될 수 있으며, 본 연구에서는 [500m_v2] 모델이 가장 우수한 공간 예측 성능을 제공하는 것으로 평가된다.

KGE 분석을 통해 모델의 종합 성능을 확인하였으나, 공간적 분포와 군집 특성을 이해하기 위해서는 공간통계 분석이 필요하다. 따라서 다음 절에서는 Moran's I와 LISA 분석 결과를 제시한다.

KGE Spatial Distribution: Variable vs. Model Comparison

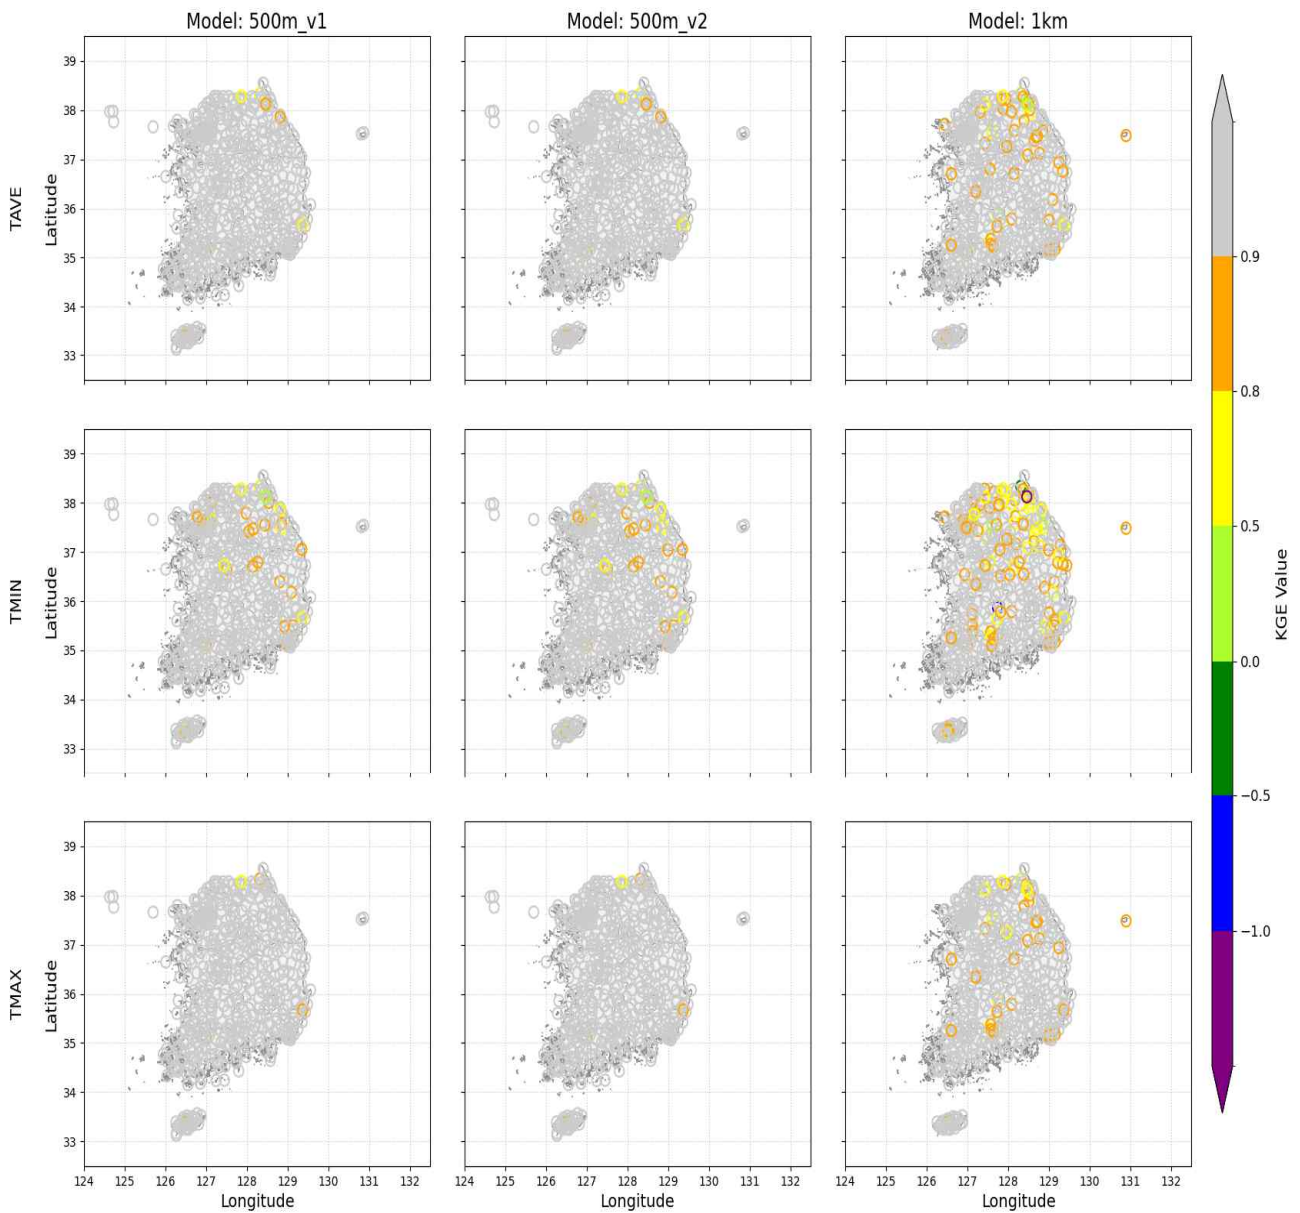


Figure 3.98. Spatial Distribution of KGE for Temperature Variables Across Different Grid Models.

3.3.4. 모델 성능의 공간적 자기상관 및 패턴 분석

기후 변수의 예측 성능은 단순히 통계적 지표나 종합 지표(KGE)만으로는 충분히 설명되지 않는다. 동일한 KGE 값을 갖더라도 지역별로 성능이 균질하게 분포하는 경우와 특정 지역에 성능이 집중되거나 저하되는 경우는 전혀 다른 의미를 가진다. 즉, 모델의 성능은 공간적 자기상관(spatial autocorrelation)과 지역적 군집(local clustering)을 고려해야만 보다 정확하게 이해할 수 있다.

특히 기온과 같은 기후 변수는 지형, 해안선, 도시화 등 공간적 요인에 의해 많은 영향을 받기 때문에, 단순 평균이나 전국 단위의 통계만으로는 지역별 특성을 충분히 반영하기 어렵다. 따라서 모델 성능을 평가할 때는 공간통계 기법을 활용하여 성능의 공간적 분포와 군집성을 검토하는 것이 필수적이다.

이에 본 연구에서는 Moran's I와 LISA(Local Indicators of Spatial Association) 분석을 통해, 상세격자모델의 예측 성능이 지역적으로 어떻게 분포하고, 어떤 공간적 패턴을 형성하는지를 심층적으로 분석하였다. Moran's I는 전체적인 공간 자기상관을 정량적으로 평가하는 지표이며, LISA는 국지적 수준에서 성능의 집적과 이질성을 파악할 수 있는 도구이다. 두 분석을 통해 모델 성능의 공간적 구조를 명확히 규명하고, KGE 결과와 연계하여 보다 종합적인 해석을 제시하고자 한다. 이를 위해 본 연구에서는 Local Moran's I 통계량을 활용하여, 관측자료와 세 가지 상세격자모델(MS_PRISM 500m_v2, MS_PRISM 500m_v1, MK_PRISM 1km)의 예측값에 대한 공간적 군집성(Local Spatial Clustering)을 분석하였다. Local Moran's I는 각 지점의 값이 주변 지점들과 유사하거나 이질적인지를 통계적으로 평가하며, 고립된 이상값이나 집적된 고·저값의 공간적 구조를 시각화할 수 있는 강력한 도구이다(Anselin, 1995).

분석 결과, 관측자료(OBS)는 전국적으로 통계적으로 유의한 군집이 고르게 분포하였으며, 특히 중부 내륙과 남부 해안 지역에서 High-High(HH) 군집이 집중되는 양상이 확인되었다. 이는 해당 지역들이 실제 기온 특성이 강하게 집적되어 있음을 의미하며, 공간적 자기상관이 높은 지역으로 해석된다(Figure 3.99).

반면 500m_v2 모델은 관측자료와 가장 유사한 군집 분포를 보였다. HH 군집이 관측과 거의 동일한 위치에 형성되었으며, Low-Low(LL) 군집 역시 북부 산악 지역과 동해안 일부에서 안정적으로 재현되었다. 또한 High-Low(HL) 및 Low-High(LH)와 같은 이질 군집의 분포도 관측자료와 유사하게 나타나, 국지적 이상값까지 일정 수준 반영하는 공간적 정밀성을 보여주었다.

500m_v1 모델은 500m_v2에 비해 군집의 위치와 형태가 다소 불안정하게 나타났다. HH 군집은 일부 지역에서 과도하게 확장되거나, 관측과 불일치하는 위치에 형성되었으며, LL 군집은 산악 지역에서 누락되는 사례가 관찰되었다. 이는 영향 반경 설정의 차이로 인해 국지적 패턴이 평균화되거나 희석되는 현상으로 해석된다.

Local Moran's I Spatial Cluster Distribution Comparison

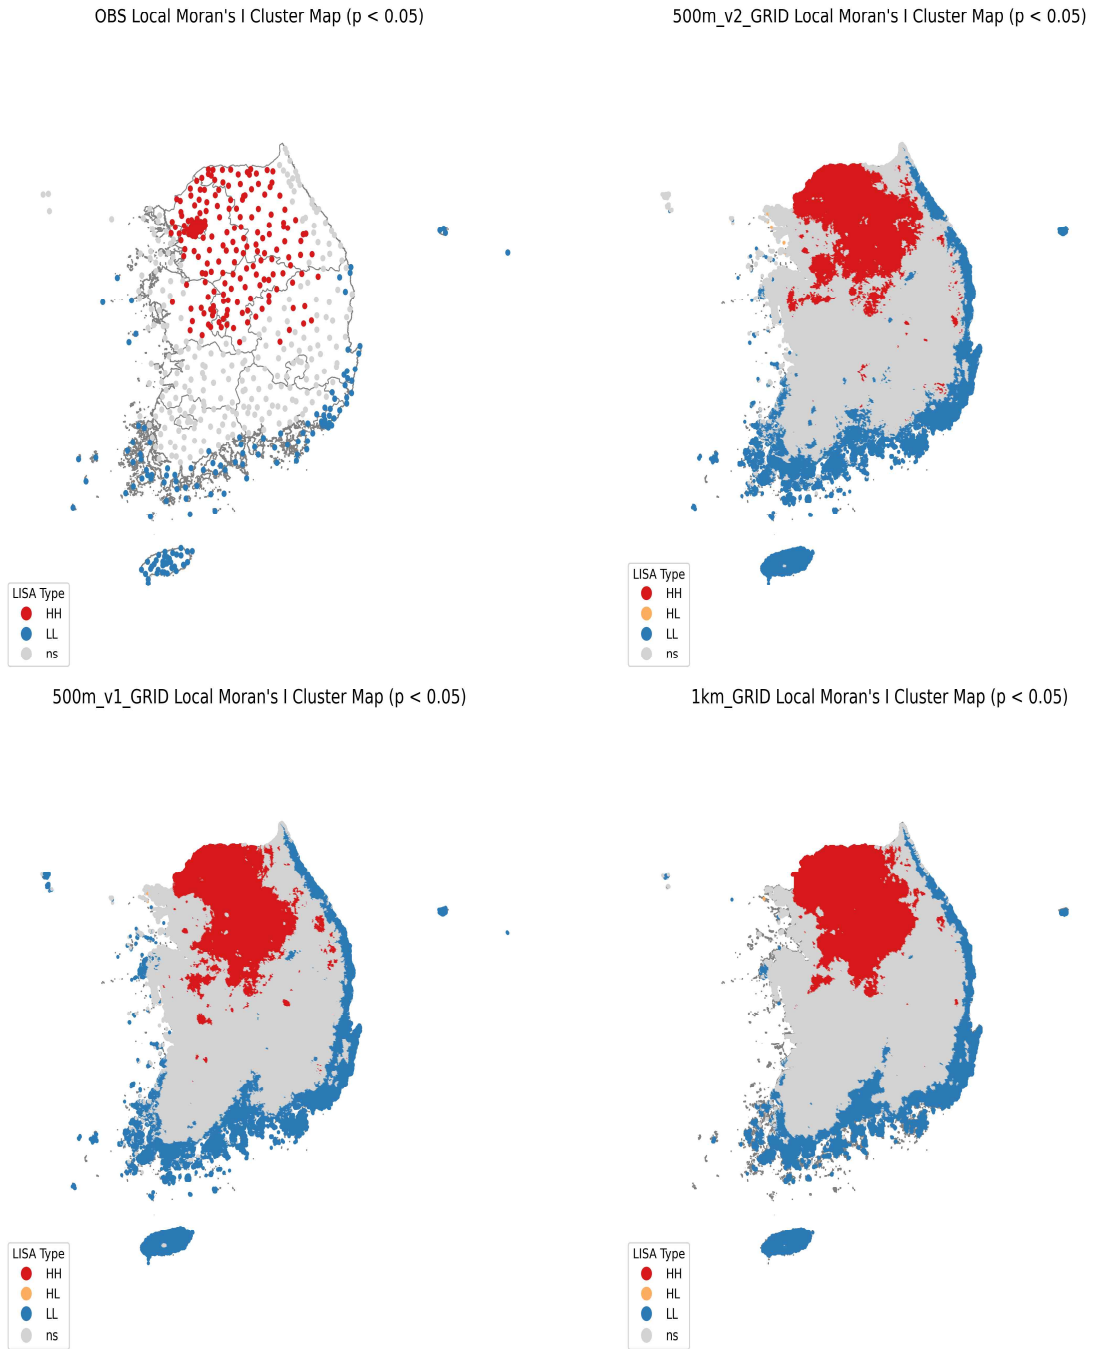


Figure 3.99. Spatial Cluster Comparison of Observed and Modeled Temperature Using Local Moran's I.

LISA Excellence Composite Score (Normalized to 100)




Figure 3.100. Comparative Evaluation of Grid Models Based on LISA Metrics: Relative Performance of 500m_v2, 500m_v1, and 1km.

1km 모델은 공간적 군집 재현력이 가장 낮았다. HH 군집은 대체로 축소되거나 위치가 이동하였으며, LL 군집은 거의 형성되지 않았다. 특히 HL 및 LH 군집은 대부분의 지역에서 통계적으로 유의하지 않게 나타났으며, 공간적 자기상관 구조를 충분히 반영하지 못하는 한계가 드러났다. 이는 해상도가 낮고 영향 반경이 넓어, 국지적 특성이 평균화되어 공간적 패턴이 소실되는 결과로 이어진 것으로 판단된다.

전체적으로 볼 때, 500m_v2 모델은 관측자료의 공간적 군집 구조를 가장 정밀하게 재현하였으며, 이는 고해상도와 최신 GIS 기반 DEM, 좁은 영향 반경 설정이 공간통계적 성능 향상에 기여했음을 보여준다. 반면 1km 모델은 공간적 패턴의 왜곡과 누락이 두드러져, 국지적 기온 특성이 중요한 지역에서는 활용에 제한이 있을 수 있다.

요약해보면, 세 가지 상세격자모델(500m_v2, 500m_v1, 1km)은 LISA 기반 공간 군집 성능에서 각기 다른 특성을 보였다(Figure 3.100). 세 모델 모두 관측자료와의 LISA 유형 일치율은 동일하게 41.86%로 나타났지만, 군집 위치 정확도와 군집 강도 재현력에서는 뚜렷한 차이를 보였다.

500m_v2 모델은 관측 군집과의 평균 거리 차이가 1.65km로 가장 작았으며, 표준편차 편향도 0.15로 낮아 공간적 정합성과 군집 강도 재현력 모두에서 가장 우수한 성능을 보였다. 반면 500m_v1 모델은 군집 위치 정확도(3.07km)와 편향(0.41)에서 상대적으로 낮은 성능을 보였고, 1km 모델은 군집 위치 오차가 가장 크면서도 편향은 가장 낮아 변동성 재현력은 우수하나 공간 위치 정밀도는 부족한 모델로 평가되었다.

이러한 결과는 모델 해상도와 영향 반경 설정이 공간 군집 재현에 결정적인 영향을 미친다는 점을 시사하며, 특히 500m_v2 모델은 국지적 공간 패턴을 가장 정밀하게 반영할 수 있는 격자 구조임을 보여준다(Table 3.33).

- LISA 유형 일치율 (%): 관측자료와 모델 간의 LISA 유형(HH, LL, HL, LH) 일치 비율을 나타내며, 값이 높을수록 국지적 공간 패턴을 정확히 재현한 것으로 평가된다. 세 모델 모두 동일한 일치율(41.86%)을 기록하였으며, 이는 분석 대상 지역의 군집 유형 분포가 일정 수준에서 공통적으로 반영되었음을 의미한다.
- 군집 위치 이동 거리 (km): 관측자료의 군집 중심과 모델 예측 군집 중심 간의 평균 거리 차이를 나타내며, 값이 낮을수록 위치 정확도가 높다. 500m_v2 모델은 1.65km로 가장 낮은 이동 거리를 보였으며, 이는 관측과 가장 유사한 군집 위치를 재현했음을 의미한다. 반면 1km 모델은 3.21km로 가장 큰 이동 거리를 보여 공간 정합성이 상대적으로 낮았다.
- 절대 표준편차 편향 (Abs STD Bias): 관측과 모델 간의 LISA 통계량 분포의 표준편차 차이를 절대값으로 나타낸 지표로, 값이 낮을수록 군집 강도의 변동성을 잘 재현한 것으로 평가된다. 1km 모델은 0.08로 가장 낮은 편향을 보였으며, 이는 군집 강도의 균형성 측면에서는 우수한 성능을 나타낸다. 반면 500m_v1 모델은 0.41로 가장 높은 편향을 보여 군집 강도 재현에 한계를 보였다.

Table 3.33. LISA-Based Spatial Clustering Performance: Comparison of 500m_v2, 500m_v1, and 1km Models.

Metric	500m_v1	500m_v2	1km	Metric Interpretation
LISA type Match Rate(%)	41.86	41.86	41.86	Higher is Better
Cluster shift Distance(km)	3.07	1.65	3.21	Lower is Better
Abs STD Bias	0.41	0.15	0.08	Lower is Better

3.3.5. 극한기온지수 기반 상세격자모델 성능 검토

앞서 평균 기온 및 공간통계 분석을 통해 모델의 전반적인 성능과 공간적 패턴을 확인하였다. 그러나 기후변화의 영향은 단순한 평균값의 변화보다 극한기온 현상의 발생 빈도와 강도에서 더욱 뚜렷하게 나타난다. 극한기온지수는 폭염일수, 열대야일수, 한파일수, 최저·최고 극값 등 다양한 형태로 정의되며, 이는 인간 건강, 농업 생산성, 에너지 수요, 도시 열환경 등 사

회·경제적 측면과 직접적으로 연결된다.

따라서 본 절에서는 세 상세격자모델(500m_v2, 500m_v1, 1km)을 대상으로 극한기온지수를 산출하고, 시간적 추세와 공간적 분포 특성을 비교·분석하였다. 이를 통해 평균 기온 분석에서 드러나지 않았던 국지적 극한현상 재현력을 평가하고, 기후변화 대응 및 지역 맞춤형 기후 서비스 개발에 필요한 기초자료를 제공하고자 한다.

YearMaxT는 연중 최고기온의 공간적 분포와 국지적 극한현상을 파악하는 데 중요한 지표로, 기후변화에 따른 고온 스트레스와 열파 발생 가능성을 평가하는 데 활용된다. 본 연구에서는 관측자료와 세 가지 상세격자모델(500m_v1, 500m_v2, 1km)을 대상으로 YearMaxT의 공간 분포와 예측 정확도를 비교·분석하였다. Figure 3.101 상단의 공간 분포도에 따르면, 관측자료는 남부 내륙과 동해안 일부 지역에서 35° C 이상의 고온 지역이 집중되어 있으며, 이는 지형적 요인과 해양 영향이 복합적으로 작용한 결과로 해석된다. [500m_v2] 모델은 이러한 고온 집중 지역을 가장 정밀하게 재현하였으며, 색상 분포와 고온 영역의 경계가 관측과 거의 일치하였다. 반면 [500m_v1] 모델은 고온 지역의 범위가 다소 과장되거나 위치가 편향되어 나타났고, [1km] 모델은 전반적으로 고온 지역의 공간적 세부 구조를 충분히 반영하지 못하는 경향을 보였다.

Figure 3.101 하단의 산점도 분석에서는 관측자료와 각 모델의 20년 평균 YearMaxT를 비교하였다. 500m_v2 모델은 $R=0.961$, $R^2=0.923$ 으로 가장 높은 상관성과 설명력을 보였으며, 이는 모델이 관측값의 변동성과 수준을 안정적으로 재현하고 있음을 의미한다. 500m_v1 모델은 $R=0.959$, $R^2=0.920$ 으로 유사한 수준의 성능을 보였지만, 일부 고온 지점에서 과대 예측되는 경향이 관찰되었다. 1km 모델은 $R=0.893$, $R^2=0.797$ 로 상대적으로 낮은 성능을 보였으며, 특히 고온 지역에서 예측값이 관측보다 낮게 나타나는 사례가 다수 존재하였다.

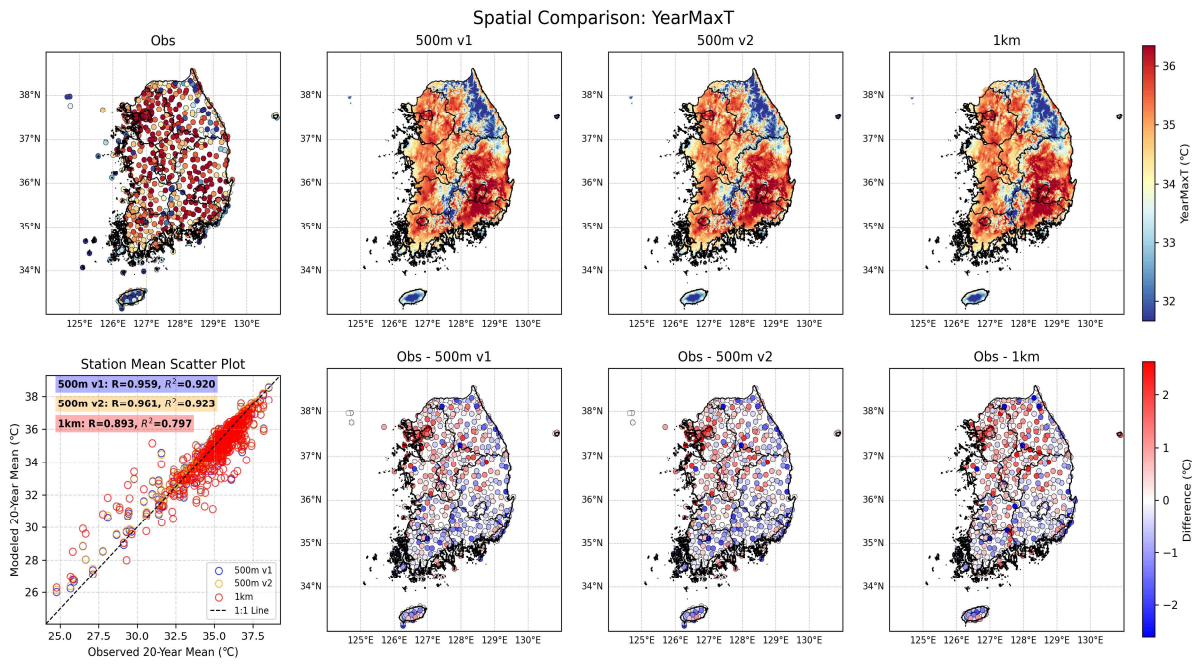


Figure 3.101. Spatial Comparison of YearMaxT: Observations vs. Grid-Based Models (500m_v1, 500m_v2, 1km).

관측과의 차이 분석(Obs - Model) 결과에서도 이러한 경향이 명확히 드러난다. 500m_v2 모델은 대부분의 지역에서 $\pm 1^{\circ}\text{C}$ 이내의 오차 범위를 유지하며, 국지적 고온 지역에서도 예측값이 관측과 근접하였다. 반면 500m_v1 모델은 일부 내륙 지역에서 $+2^{\circ}\text{C}$ 이상의 과대 예측이 나타났고, 1km 모델은 동해안과 산악 지역에서 -2°C 이하의 과소 예측이 집중되어 공간적 편향이 뚜렷하게 나타났다.

이상의 결과를 종합하면, 500m_v2 모델은 YearMaxT의 공간 분포와 극값 수준을 가장 정밀하게 재현하며, 고해상도와 좁은 영향 반경 설정이 국지적 고온 특성 반영에 효과적임을 보여준다. 반면 1km 모델은 해상도와 공간 평균화의 한계로 인해 극한기온의 공간 구조를 충분히 반영하지 못하는 것으로 평가된다.




Figure 3.102. Statistical Comparison of YearMaxT: Observations vs. Three Grid-Based Models.

Figure 3.102에서 관측자료는 평균 YearMaxT가 약 33.5°C 수준이며, 최대값은 37°C 이상으로 나타났다. 500m_v2 모델은 평균값과 분위값 모두에서 관측과 가장 유사한 분포를 보였으며, 특히 50% 및 75% 분위값에서 관측과 거의 일치하는 수준을 기록하였다. 이는 모델이 전국적으로 고온 분포의 중심 경향을 안정적으로 재현하고 있음을 의미한다. 반면 500m_v1 모델은 평균값이 다소 높게 나타났으며, 최대값도 관측보다 과대 추정되는 경향을 보였다. 이는 일부 지역에서 고온이 과장되어 나타나는 현상으로, 군집 위치의 편향이나 영향 반경 설정의 차이에서 기인한 것으로 해석된다. 1km 모델은 평균값과 분위값이 전반적으로 낮게 나타났으며, 특히 최대값이 관측보다 1.5°C 이상 낮아지는 사례가 확인되었다. 이는 해상도가 낮아 국지적

고온 특성을 충분히 반영하지 못하는 한계를 보여준다. 최소값의 경우, 세 모델 모두 관측과 유사한 수준을 보였으나, 1km 모델은 저온 지역에서 과소 추정되는 경향이 일부 존재하였다. 이는 모델의 공간 평균화 효과로 인해 극값이 완화되는 현상으로 볼 수 있다. 이상의 결과를 종합하면, 500m_v2 모델은 YearMaxT의 중심 경향과 극값 분포를 가장 안정적으로 재현하였으며, 이는 고해상도와 정밀한 공간정보 기반의 격자 설정이 극한기온 예측에 효과적임을 시사한다. 반면 1km 모델은 평균화된 기온 분포로 인해 극값 재현력이 저하되며, 국지적 기후 특성 분석에는 한계가 존재한다.

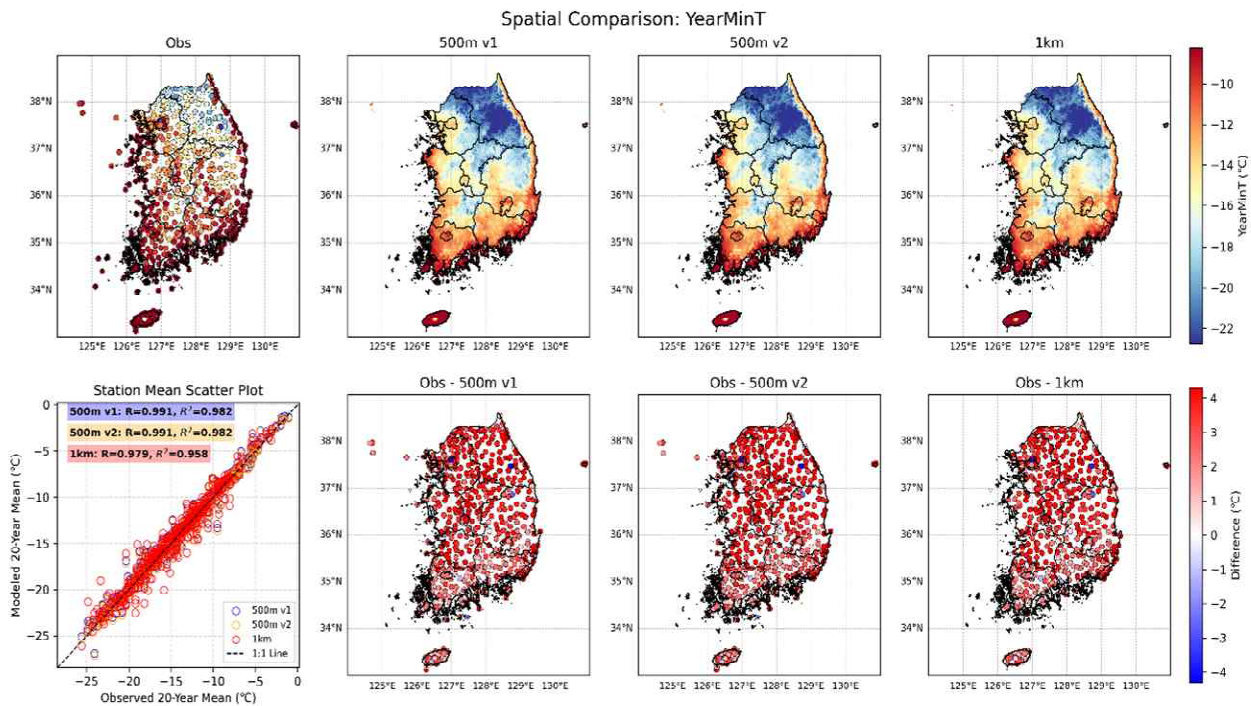


Figure 3.103. Spatial Comparison of YearminT: Observations vs. Grid-Based Models (500m_v1, 500m_v2, 1km).

관측 자료를 통해 확인된 연평균 최저기온의 공간적 분포는 남부 해안가 및 섬 지역이 높고, 강원 산간 및 내륙 북부 지역이 낮은 전형적인 우리나라 기온 분포 특성을 보였다(Figure 3.103). 격자 자료(500m v1, 500m v2, 1km)는 이러한 관측 자료의 공간적 경향성(Spatial Pattern)을 모두 매우 성공적으로 모의하고 있음을 확인하였다. 특히, 500m 해상도 자료는 1km 자료에 비해 기온의 고저차가 발생하는 지형적 특성 및 미세한 구배를 더욱 세밀하게 반영하는 경향을 보였다.

관측 지점에서의 격자 자료 모의값과 관측값 간의 통계적 비교를 통해 자료의 정확도를 검증하였다. 모든 격자 자료가 관측값 대비 매우 높은 통계적 정확도를 나타냈으며, 모든 자료에서 상관계수(R)가 0.97 이상, 결정계수(R²)가 0.95 이상을 기록하였다. 이는 제시된 격자 자료들이 20년간의 연평균 최저기온을 매우 신뢰성 있게 모의하고 있음을 의미한다. 500m v1 자료는 R=0.991, R²=0.982를 보였으며, 500m v2 자료 역시 R=0.991, R²=0.982를 기록하였다. 1km 자료는 500m 해상도 보다 낮은 값을 보였다(R=0.979, R²=0.958). 통계적 지표상으로는 500m v1

과 v2 자료가 1km 자료에 비해 상관계수와 결정계수 모두에서 약간 더 높은 수치를 보이며, 관측 지점에서의 재현력이 더 우수함을 입증하였다. 관측값과 모의값 간의 차이(오차)를 공간적으로 분석한 결과, 대부분의 지역에서 오차는 $\pm 1^{\circ}\text{C}$ 이내의 작은 값을 나타냈다. 이는 격자 자료의 전반적인 품질이 매우 높음을 의미한다. 다만, 특정 지역에서는 격자 자료가 관측값을 과대 또는 과소 모의하는 패턴이 국지적으로 나타났다. 고해상도 격자 자료는 2000-2019년 연 평균 최저기온의 공간 분포 및 정량적 정확도 측면에서 높은 신뢰도를 보이고 있다.

연 최저기온의 평균값을 비교한 결과, 관측 자료는 약 -13°C 로 네 가지 데이터 유형 중 가장 낮은 값을 기록하였다. 반면 모든 격자 자료는 관측 평균값보다 약 1°C 에서 2°C 정도 높은 값을 모의하여 평균 최저기온을 전반적으로 과대 모의하는 경향을 보였다. 특히 1km 격자 자료는 약 -15.5°C 로 나타나, 500m v1과 v2 자료보다 관측값에 더 근접한 결과를 보여주었다. 격자 자료가 극한 기온을 재현하는 능력에는 뚜렷한 한계가 확인되었다. 최솟값(Min): 관측 자료는 약 -36°C 를 기록하며 극심한 저온 현상을 포착했으나, 모든 격자 자료는 -28°C 에서 -30°C 내외의 값을 보여 관측값보다 현저히 높은 결과를 나타냈다. 이는 격자 자료가 국지적이고 극단적인 최저기온 현상을 정확히 반영하는 데 어려움이 있음을 시사한다.

관측 자료의 최댓값(Max)은 약 1°C 를 기록했으나, 격자 자료는 -1°C 에서 -2°C 내외의 값을 보여 연 최저기온이 높게 나타나는 지역의 기온을 다소 과소 모의하는 경향을 보였다. 데이터의 중간 범위 통계값(25%, 50%, 75%)에서는 격자 자료가 관측값의 분포를 비교적 잘 재현하였다. 관측값의 중앙값(50% Median)은 약 -15°C , 격자 자료는 약 -16°C 내외로 나타나 중심 경향을 유사하게 반영하였다. 격자 자료의 25% 및 75% 백분위수는 관측값과 근소한 차이를 보이며 일반적인 최저기온 분포를 성공적으로 모의하였다. 고해상도 격자 자료는 연 최저기온의 중앙 경향과 중간 범위 통계값을 비교적 정확하게 재현하였다. 그러나 극한 저온(최솟값)에서는 관측값과 상당한 차이를 보이며 극한값을 과소 모의하는 뚜렷한 한계를 드러냈다. 따라서 이들 격자 자료를 활용하여 우리나라의 극심한 한파나 최저기온 극한치를 분석할 경우, 자료가 내포하고 있는 과소 모의 오차를 반드시 고려해야 한다.




Figure 3.104. Statistical Comparison of YearMaxT: Observations vs. Three Grid-Based Models.

앞서 제시한 우리나라 평균 및 표준편차 분석을 통해 각 모델이 극한기온지수의 중심 경향과 공간적 변동성을 얼마나 잘 재현하는지를 확인하였다. 그러나 평균값과 표준편차만으로는 연도별 추세 변화나 극한사건 반응성을 충분히 설명하기 어렵다. 따라서 다음 절에서는 동일한 9개 극한기온지수를 대상으로 2000년부터 2019년까지의 시계열 분석을 수행하여, 각 모델이 시간적 변동성과 극값 발생 특성을 어떻게 재현하는지를 평가하였다.

Figure 3.105은 관측자료와 세 개 모델(500m_v1, 500m_v2, 1km)을 대상으로 2000년부터 2019년까지의 연도별 극한기온지수 변화를 시계열로 제시한 것이다. 분석 대상은 총 9개 지수로, 고온 관련 지수(Days30, Days33, Days35, SummerDay, Tropical Night, YearMaxT)와 저온 관련 지수(FrostDay, IceDay, YearMinT)를 포함한다. 격자자료의 연간 시계열을 관측자료의 통계와 비교하기 위해, 분석 대상 영역(남한전체) 내의 모든 격자 셀 값을 이용하여 해당 연도의 대푯값을 산출하였다. ▢

고온 관련 지수에서는 전반적으로 상승 추세가 뚜렷하게 나타났으며, 특히 Days35와 SummerDay는 2010년대 이후 급격한 증가세를 보였다. 대부분의 지수에서 관측값(초록선)과 년 변동성은 거의 일치하며, 관측자료의 피크 연도와 수준을 가장 안정적으로 재현하였다. 그러나 지수의 값은 대부분 관측보다 과소 모의하는 특징을 보인다.

저온 관련 지수인, FrostDay와 IceDay는 관측보다 과대 모의하는 결과를 보이고 있다. 서리일수는 관측보다 약 20일정도 많이 모의를 하고 있으며, 연 최저기온은 관측보다 약 2°C 정도 낮게 모의된 것으로 나타났다. 저온 관련 지수의 과대 모의 현상은 격자 모델이 관측자료가 없

는 고도가 높은 지역의 기온값을 산출하여 전체 영역평균에 포함시키면서 발생하는 현상으로 분석된다. 즉 관측자료의 공간적 한계를 모델이 물리적 보정을 통해 채우는 과정에서 발생한 격자 모델 특유의 시스템적 편향 때문이다.

Figure 3.106은 관측값을 기준으로 세 가지 상세화 모델(500m_v1, 500m_v2, 1km)이 전국 평균 극한기후지수(평균값과 표준편차)를 어떻게 재현하는지를 한눈에 보여준다. 각 지수별 막대는 모델별 평균을 나타내고 에러바는 공간적·연도별 변동성을 의미하므로, 시각적으로는 평균의 편향과 변동성 재현 능력을 동시에 평가할 수 있다. 관측과 모델 평균의 높낮이 차이는 모델 편향을, 에러바의 크기 차이는 모델이 변동성을 과소·과대평가하는지를 나타낸다.

전반적으로 특정 지수에서 모델 평균이 관측보다 지속적으로 높거나 낮게 나타나면 그 지수에 대해 편향이 존재한다고 볼 수 있다. 고온 관련 지수(예: Days30, Days33, Days35, TropicNight, SummerDay, YearMaxT)에서 모델 값이 관측보다 높게 분포하며 고온 지수들을 과대평가하는 경향이 있고, 반대로 FrostDay나 IceDay 같은 한랭 지수에서 모델값은 관측보다 낮으면 한랭일수를 과소평가하는 것으로 해석된다. 에러바가 관측과 유사한 크기이면 공간적·연도별 변동성을 잘 재현한 것이고, 에러바가 관측보다 좁으면 변동성 저평가, 넓으면 과대평가로 판단된다.




Figure 3.105. Yearly Variation of Extreme Temperature Indices.

모델 간 비교에서는 500m_v2가 500m_v1에 비해 관측 평균에 더 가깝고 표준편차도 유사하거나 개선된 모습을 보이면 500m_v2가 성능 개선을 이룬 것으로 해석할 수 있다. 반면 1km 모델은 해상도가 낮은 영향으로 극한일수나 극값 지수에서 평균·변동성 모두에서 차이를 보일 가능성이 크며, 이는 해상도에 따른 물리적 과정 재현 능력의 차이로 설명된다. 모델들 간 막대 그래프의 상대적 위치와 에러바의 중첩 여부를 통해 어떤 모델이 특정 지수에서 신뢰도가 높은지, 또는 어떤 지수에서 공통적인 편향이 존재하는지를 파악할 수 있다.

앞선 분석 결과를 통해 500m_v2 모델이 다른 모델 대비 가장 우수한 모의 성능을 보이는 것으로 확인되었다. 이에 본 연구에서는 해당 모델을 기반으로 편의보정을 수행하여 생산된 500m 해상도의 기후변화 시나리오 자료를 분석하였다. 다음 절에서는 이와 같이 생성된 편의보정 500m 기후변화 시나리오 자료를 활용하여 지수별 특성과 공간·시간적 변화 양상을 심층적으로 분석한 내용을 제시한다.




Figure 3.106. Mean and Standard Deviation of Climate Indices: Observations vs. 500m_v1, 500m_v2, and 1km Models.

3.3.6. 극한지수의 미래전망

본 연구에서는 RCM 5종(CCLM, GRIMs, HadGEM3-RA, RegCM, WRF)의 결과를 Kim et al.(2016)이 제시한 PRIDE(PRISM based Dynamic downscaling Error correction) 모델과 MK-PRISM 고해상도 관측 격자 자료를 적용하여 생산된 SSP 2종(SSP1-2.6, SSP5-8.5) 기반 상세 전망 시나리오 자료를 분석하였다(기상청, 2023).

극한지수의 미래 전망을 분석하기 위하여, SSP1-2.6(저배출 시나리오) 및 SSP5-8.5(고배출 시나리오)를 기반으로 2071~2100년의 연최고기온(Figure 3.107)과 연최저기온(Figure 3.4.21)의

공간분포와 변화량을 분석하였다. 기준시기는 2000~2019년 관측자료이며, 이를 바탕으로 미래 기후와의 차이를 산출하였다. 그림의 상단은 각 시나리오별 평균 연최고·최저기온의 공간적 분포를 보여주며, 하단은 관측값 대비 미래 시나리오의 변화량을 나타낸다. 연최고기온은 SSP1-26시나리오에서 평균 약 3.8°C 상승한 것으로 나타났으며, SSP5-85 시나리오에서는 약 8.8°C 상승하여 훨씬 큰 증가폭을 보였다. 특히 SSP5-85시나리오에서는 전국적으로 극값 온도의 상승이 뚜렷하게 나타났으며, 내륙 및 도시지역에서 상승폭이 더욱 크게 나타났다. 연최저기온 역시 SSP1-26시나리오에서는 평균 1.6°C 상승에 그쳤으나, SSP5-85시나리오에서는 약 6.3°C 상승하여 한파강도가 완화되는 동시에 전반적인 기온 상승이 두드러졌다.

이러한 결과는 기후변화가 우리나라의 극한 기온 패턴에 중요한 영향을 미칠수 있음을 시사한다. 저배출 시나리오에서는 상대적으로 완화된 변화가 예상되지만, 고배출 시나리오에서는 극한 고온의 빈도와 강도가 크게 증가하고, 겨울철 한파 역시 완화되면서 계절별 기후 특성이 크게 변할 가능성이 높다. 따라서 향후 기후적응 정책과 인프라 설계, 보건·농업·에너지 분야의 대응 전략 수립에 있어 시나리오별 전망을 고려하는 것은 필수적이다.

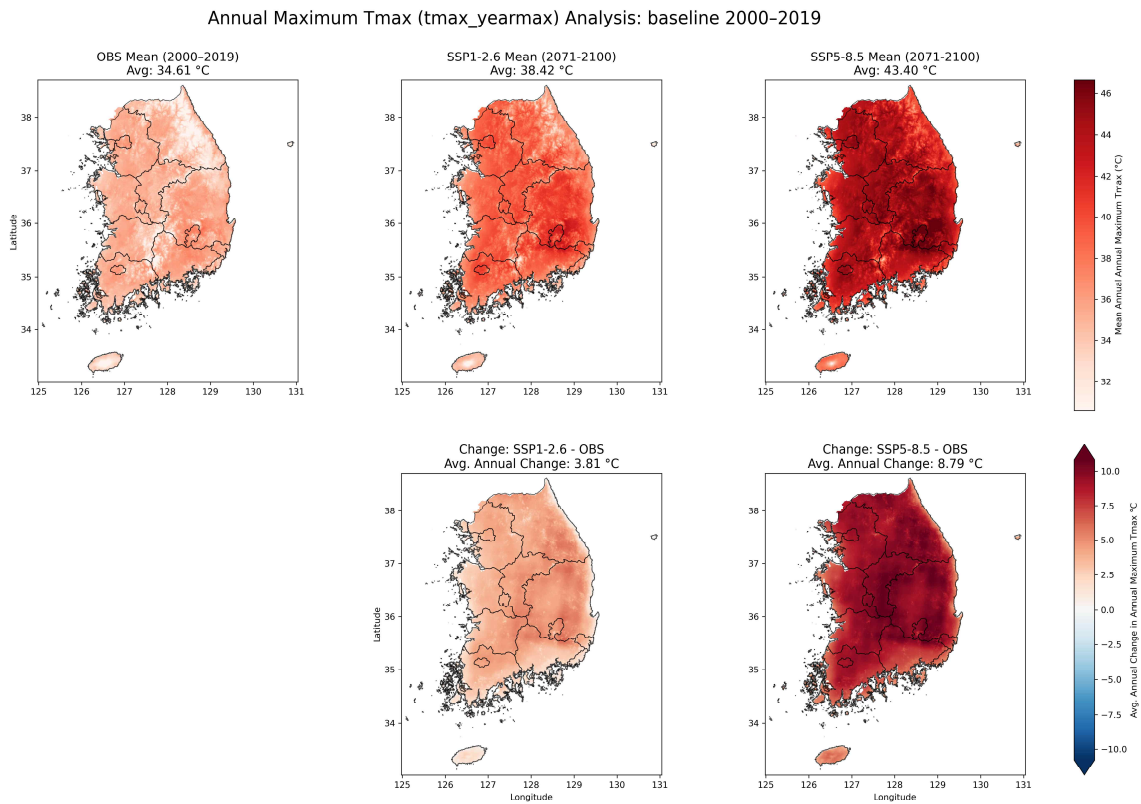


Figure 3.107. Spatial distribution and change of Annual Maximum Temperature under SSP Scenarios.

앞서 SSP1-2.6과 SSP5-8.5 시나리오를 적용하여 2071~2100년의 연최고·연최저 기온변화를 관측기간(2000~2019년)과 비교한 결과, 고배출 시나리오에서는 극한 고온과 한파 완화가 뚜렷하게 나타나며 기후변화의 영향이 크게 확대될 것으로 확인되었다. 이러한 평균적 변화 분석은 미래 기후의 전반적 경향을 보여주고 있다. 이와 더불어 실제 사회·경제적 피해와 직결되는 성은 극한 기온 사건의 발생사건이다. 이를 보다 정량적으로 평가하기 위해 연최고기온 자료를 활용하여 재현수준(return level)분석을 수행하였다. 재현수준은 특정 재현기간(예: 50년, 100년)에 한 번 발생할 것으로 예상되는 극한 기온 수준을 의미하며, GEV(Generalized Extreme Value)분포를 적용하여 추정하였다. 서울과 부산지역의 분석결과 SSP5-85시나리오에서는 장기 재현기간으로 갈수록 극한고온의 수준이 크게 상승하여, 100년·200년 빈도의 극값이 관측 대비 상당히 높게 나타났다. 반면 SSP1-2.6 시나리오에서는 상승폭이 상대적으로 완화되어, 저배출 경로가 극한 기온 위험을 줄이는 데 효과적임을 보여준다. 50년 재현기간 부산은 저탄소 시나리오에서 관측대비 약 2°C 상승하였고, 고탄소 시나리오에서는 4~5°C 상승하였고, 서울은 저배출 시나리오에서 2~3°C, 고배출 시나리오에서는 5°C 상승하는 것으로 나타났다. 재현기간에서는 서울은 부산보다 극한 고온 상승폭이 더 크며, 특히 고탄소 시나리오에서 그 차이가 뚜렷하게 나타났다(Figure 3.109).

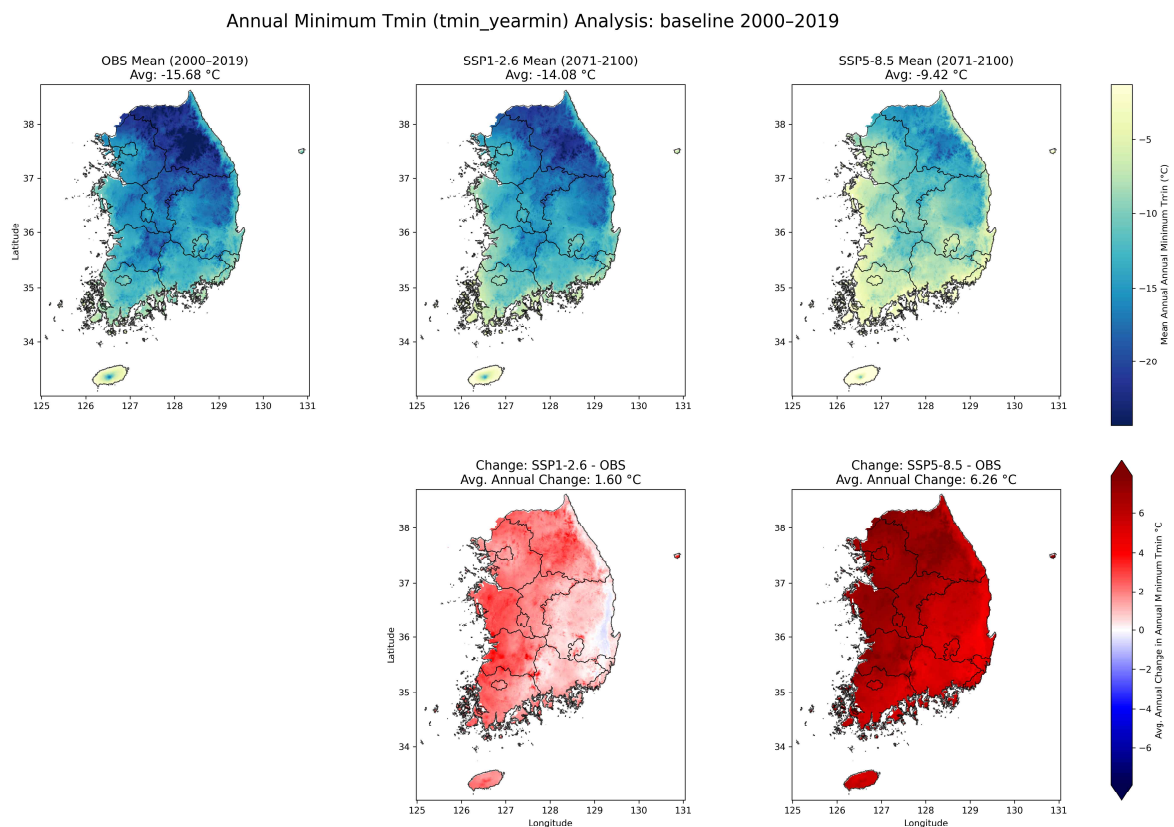


Figure 3.108. Spatial distribution and change of Annual Minimum Temperature under SSP Scenarios.

부산은 해양 완충효과고 단기상승은 완만하지만, 장기재현기간에서는 서울과 유사한 수준까지 극값이 확대되었으며, 서울은 도시열섬효과로 단기중기 재현기간에서 부산보다 더 높은 극값을 보인 것으로 추정된다. 따라서 도시 열섬, 해안·산복지형 등 지역 특성이 극한 기온의 변동성에 큰 영향을 줄 수 있음을 시사하며, 실제 지역 단위의 기후 적응 전략 수립에 있어 고해상도 자료 활용이 중요하며, 단기적 도시적응 전략과 장기적 국가 차원의 온실가스 감축 정책이 동시에 고려할 필요가 있다.

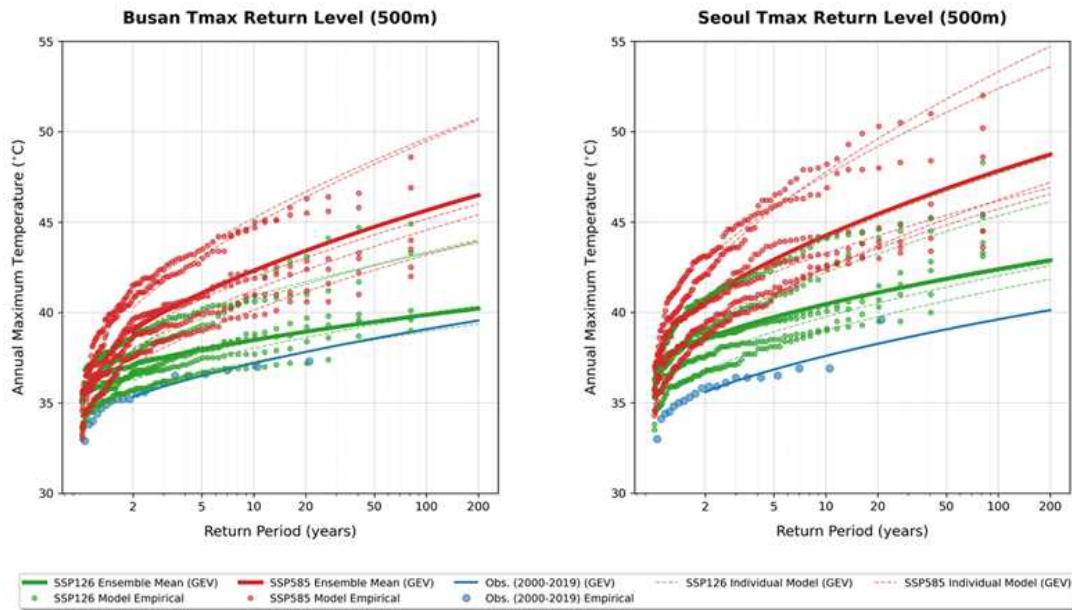


Figure 3.109. Return Level Analysis of Annual Maximum Temperature in Busan and Seoul.

3.5. 부문별 영향정보지수(농업부문 8종 개선)

3.5.1. 작물 생육 지표의 통합 및 표준화

1) 유효적산온도(GDD)로 명칭 및 산출식 일원화

- 개선 내용: 기존에 혼용되던 ‘생육온도일수(GDD)’ 와 ‘유효적산온도(EAT)’ 를 ‘유효적산온도(Growing Degree Days, GDD)’ 로 통합하였다.
- 결과: 단위는 비공식적인 ‘도일’ 대신 ‘℃·일’ 로 표준화하였으며, 산출 방식은 일평균기온과 생육한계온도(기준온도)의 차이를 적산하는 방식으로 확정하였다. 이는 작물의 발아, 개화, 수확 시기를 예측하는 데 가장 보편적으로 사용되는 방식을 따른 것이다.

2) 작물재배가능기간(GSL) 도입

- 개선 내용: 기존의 단순 기온 기준인 ‘식물기간’ 과 ‘작물기간’ 을 폐지하고, ‘작물재배가능기간(Growing Season Length, GSL)’ 이라는 명확한 용어와 기준을 도입하였다.
- 결과: 일평균기온 5℃ 이상이 5일 이상 지속되는 시점을 시작일, 5℃ 이하로 떨어져 5일 이상 지속되는 시점을 종료일로 설정하여, 실제 작물 생육이 가능한 기간을 정량적으로 산출할 수 있게 되었다.

3.5.2. 과수 및 시설농업 맞춤형 지표 고도화

1) Chill Days/Anti-Chill Days (저온/고온 축적값) 적용

- 개선 내용: 기존 ‘Chill Units’ 은 시간 단위 기상 자료가 필요하여 일 단위로 제공되는 기후변화 시나리오 적용에 한계가 있었다. 이에 일 최고/최저 기온만으로 산출 가능한 Cesaraccio et al.(2004)의 생물계절모형을 적용하여 지수를 개선하였다.
- 결과: 사과, 배, 복숭아 등 과수의 휴면 타파 시기(Chill Days)와 개화 시기(Anti-Chill Days)를 예측할 수 있는 이원화된 정보를 제공한다. 품종별 기준온도(예: 사과 알프스 오토메 5℃)와 저온요구도 실험값을 반영하여 예측 정확도를 높였다.

2) 시설 난방적산온도(HDD) 신설 및 냉방도일 삭제

- 개선 내용: 단순 ‘난방도일’ 을 스마트팜과 온실 등 농업 시설 에너지 관리에 특화된 ‘시설 난방적산온도(HDD)’ 로 명칭과 개념을 구체화하였다. 반면, ‘냉방도일(CDD)’ 은 농업 현장에서 비용 문제로 냉방 활용이 극히 제한적이라는 전문가 의견에 따라 영향정보 산출 대상에서 삭제하였다.
- 결과: 시설원에 농가의 겨울철 난방 에너지 수요를 예측하고 온실가스 감축 효과를 평가할 수 있는 실질적인 지표를 마련하였다.

3.5.3. 축산부문 폭염 대응력 강화

1) 가축더위지수(THI) 위험 단계별 정보 구체화

- 개선 내용: 단순한 ‘온습도지수’ 를 축산 농가에서 직관적으로 이해할 수 있는 ‘가축 더위지수’ 로 명칭을 변경하였다.
- 결과: 단순히 지수 값만 제공하던 기존 방식에서 벗어나, 축종(소, 돼지, 닭)별로 열 스트레스 임계값을 적용하여 5단계(양호-주의-경고-위험-폐사)의 예측 정보를 제공하도록 개선하였다.

Table 3.34. Results of Improvement on Agricultural Impact Indices.

구분	기존(8종)	개선안(5종)
지수통합	생육온도일수 (Growing Degree Days, GDD)	유효적산온도(Growing Degree Days, GDD)
	유효적산온도 (Effective Accumulated Temperature, EAT)	
명칭변경	식물기간	작물재배가능기간(Growing Season Length, GSL)
	작물기간	
부문변경	난방도일	시설난방적산온도(Heating Degree Days, HDD)
	온습도지수 (Temperature Humidity Index, THI)	
용도변경	난방도일/냉방도일	에너지 부문으로 변경
	Chill Units(고온/저온 축적값)	Chill Day/Anti-Chill Day(저온/고온 축적값)

4. 요약 및 결론

이 연구는 통계적 상세화와 인공지능/기계학습 상세화 기법을 이용하여 고해상도 기후변화 시나리오 자료생산에 필요한 상세화 기반기술을 개발하였다. 또한, 기후변화 시나리오 자료 평가 및 국가 기후변화 표준 시나리오 자료의 활용성 증대를 위한 영향정보지수 개선을 수행하였다.

위성 강수 산출물(GPM, PERSIANN, CMORPH, CHIRPS)과 기계학습 기반 보정 모델(Random Forest, XGBoost)의 성능을 다각도로 분석하였다. 분석 결과를 요약하면 다음과 같다. GPM과 CHIRPS가 상대적으로 양호한 성능($R = 0.645$)을 보였으나, 모든 원본 산출물이 높은 오차($RMSE > 27$ mm)와 낮은 정확도를 보여, 수문학적 모델링에 직접 사용하기에는 한계가 있음이 확인되었다. PERSIANN은 적외선 센서의 물리적 한계로 인해 가장 낮은 성능을 보였다. Random Forest와 XGBoost를 적용한 결과, 상관계수는 0.8 이상으로 급격히 상승하고, RMSE는 30% 이상 감소하는 등 획기적인 성능 향상을 달성하였다. 이는 기계학습이 위성 데이터의 비선형적 오차 구조를 효과적으로 학습하고 제거할 수 있음을 증명한다. 본 연구의 실험 환경에서는 Random Forest 모델이 상관계수 0.846, RMSE 18.5 mm로 가장 우수한 성능을 기록하였다. 이는 RF의 분산 감소 효과와 노이즈에 대한 강건성이 위성 강수 데이터의 불확실성을 제어하는 데 주효했음을 시사한다. 향후에는 단순한 통계적 지표 비교를 넘어, 극한 강우 사상(태풍, 집중호우)에 대한 모델별 거동 분석과, 지형 및 계절적 특성을 고려한 맞춤형 보정 알고리즘 개발이 필요하다. 또한, 딥러닝(Deep Learning) 등 최신 기법을 도입하여 시공간적 패턴 인식 능력을 더욱 강화하는 연구가 지속되어야 할 것이다. 결론적으로, 위성 강수 산출물은 기계학습 기반의 편차 보정 과정을 거침으로써 고해상도 강수 자료로 그 활용 가치가 비약적으로 상승하며, 이는 미세측 유역의 수자원 관리와 기후 변화 및 농업 기술 대응을 위한 핵심 기술로 자리 잡을 것이다.

기후변화 적응 대책 수립과 정밀 농업, 방재 등 다양한 분야에 필수적인 1km 해상도의 고정밀 기상 격자 데이터를 생산하는 것을 목적으로 수행되었다. 제주도는 해발고도에 따른 기상 변화가 극명한 지역적 특성을 가지므로, 기존 관측소만으로는 중산간 및 산간 지역의 기상 정보를 정확히 파악하는 데 한계가 있었다. 이에 본 연구는 2020년부터 2024년까지의 기온 및 강수량 관측 데이터를 바탕으로 IDW, OK, CSI, SCOK, OCOK 등 다양한 공간 보간 기법을 비교·검증하였으며, 최종적으로 고도와 상관을 경향성으로 모델링하는 범용 공동 크리깅(Universal Cokriging, UCOK)을 최적의 상세화 기술로 도출하였다. 연구의 핵심은 기온과 강수량이 해발고도에 따라 변하는 물리적 특성을 통계적 모델에 얼마나 정교하게 반영하느냐에 있었다. 이를 위해 고해상도 수치표고모델(DEM)을 보조 변수로 통합하여 분석한 결과, UCOK 기법이 가장 압도적인 성능을 발휘하였다. UCOK 기법은 데이터의 평균을 상수로 가정하는 SCOK나 국지적 평균만을 추정하는 OCOK와 달리, ‘고도에 따른 기온 감률’이나 ‘지형성 강우 효과’를 일차식 형태의 경향성으로 명시적으로 모델링하고, 그 잔차에 대해 공간 통계적 보정을 수행하는 방식이다. 기온 예측에서 UCOK 기법은 연중 결정계수(R^2) 0.98 이상, RMSE 1.0°C 미만의 최상위 성능을 기록하였다. 특히 단순 고도 감률만으로는 설명되지 않는 서귀포의 국지적 고온 현상이나 도심 열섬 효과 등 경향성에서 벗어난 국지적 이상치를 잔차 보정

과정을 통해 잡아내었다. 이는 전역적 경향성만 강조했던 SCOK의 한계와, 데이터 공백지에서 경향성 추정이 불안정했던 OCOK의 단점을 동시에 극복한 결과로, 겨울철 산간 오지의 기온 추정에 있어서도 물리적으로 가장 타당한 값을 산출하였다. 강수 예측 역시 UCOK 기법의 우수성이 확인되었다. 강수량은 시공간적 변동성이 매우 크지만, UCOK 모델은 한라산에 의한 강제 상승 효과를 기반으로 산간 다우지를 정확도 높게 예측하면서도, 해안가의 국지성 호우 패턴까지 유연하게 모의하였다. 이는 강수량의 극값을 과도하게 평활화했던 SCOK의 단점을 보완하여, 실제 관측된 극한 강수 사상을 가장 현실적으로 재현해 낸 성과이다. 결론적으로, 제주도 와 같이 지형적 복잡성이 크고 고도가 기상에 지배적인 영향을 미치는 지역에서는 물리적 경향성과 국지적 변동성을 동시에 고려할 수 있는 UCOK 기법이 최적의 방법론임이 입증되었다. 이 연구를 통해 UCOK 기반으로 구축된 1km 고해상도 기상 격자 자료는 관측 공백지대였던 중산간 및 산간 지역의 상세 기후 정보를 성공적으로 복원하였으며, 향후 감귤 재배지 변동 예측, 산악 도로 결빙 방재, 수자원 관리 등 지역 맞춤형 기후변화 대응 정책 수립에 있어 신뢰도 높은 기초 자료로 활용될 것으로 기대된다.

딥러닝 기술을 이용하여 인공지능 기반 기후자료 상세화 연구를 수행하였다. 딥러닝 모델은 고해상도 ERA-5 기온(T2M) 자료를 상세화하는 모델로, 잔차 학습(residual learning) 방법이 적용된 EDSR을 기본 네트워크로 사용하였다. 학습자료는 고해상도 ERA-5 T2M 자료(0.25도)를 이용하여 상세화 배율 2배, 4배, 8배에 해당하는 학습자료를 구축하였다. 학습자료 구축은 2 단계로 구성되며, 첫 번째 단계는 상세화 배율에 맞게 업샘플링(upsampling)을 통해 해상도를 낮추고, 두 번째 단계는 고해상도 자료와 격자 크기를 맞추기 위해 다운샘플링(downsampling)을 이용하여 구축하였다. 업샘플링과 다운샘플링 방법으로 쌍입방(bicubic, CUB) 보간법, 최근린(nearest neighbor, NN) 보간법, 선형(linear, LIN) 보간법이 이용되었다. 이 자료에 고해상도 자료와 같은 공간해상도의 보조변수 DEM 자료를 함께 구축하였다.

딥러닝 모델은 CASE OLR, CASE D, CASE DU, CASE DUR, CASE UD를 구축하고, 학습자료, 고해상도 ERA-5, ASOS 관측자료와 비교하였다. 평가는 이미지 품질 평가지표(PSNR, SSIM) 과 통계 평가지표(MAE, MSE, RMSE, R^2)를 이용하여, 연구지역 전체를 대상으로 고해상도 ERA-5 자료와 남한지역의 ASOS 관측자료 평가로 나누어 실시하였다. 연구지역은 한반도를 포함한 동아시아 지역으로 선정하였다. CASE OLR (only ERA-5 low-resolution)는 EDSR 모델을 기초로 저해상도 ERA-5 자료인 학습자료 Step 2를 입력자료로 사용하는 모델이다. CASE D는 학습자료 Step 2와 보조변수 DEM 자료를 입력자료로 이용하는 모델이다. CASE DU는 학습자료 Step 1과 보조변수 DEM 자료를 입력자료로 이용하며, 두 입력자료는 딥러닝 모델 내 같은 네트워크로 학습된다. 이는 저해상도 자료와 고해상도 자료가 같은 네트워크 학습을 통해 bias, weights 업데이트와 공유하며, 고해상도 자료의 풍부한 수용 영역(receptive field) 정보에서 학습된 정보를 통해 저해상도 자료도 풍부한 수용 영역 정보 생성이 가능한 장점이 있다. CASE DUR는 CASE DU에서 두 입력변수가 함께 사용하던 네트워크를 개별로 분리하여 구축한 모델이다. CASE UD는 CASE OLR 모델에서 고해상도 자료로 복원하기 직전 레이어에 보조변수 DEM자료를 conv+conv 레이어를 통과한 자료와 연결(concatenation)하는 구조로 설계되었다.

고해상도 ERA-5 자료 평가는 2배 상세화 배율에서는 DU_NN_NN_2, DUR_NN_NN_2, UD_NN_NN_2 순으로 좋은 결과를 보였다. 4배 상세화 배율은 DU_NN_NN_4, 2위는

DUR_NN_NN_4, 3위는 D_CUB_NN_4 순이었으며, 8배 상세화 배율은 DUR_NN_NN_8, DUR_NN_NN_8, UD_NN_NN_8이었다. 보조변수 DEM 자료를 학습자료에 포함한 모델들이 좋은 결과를 보였다. ASOS 관측자료 평가는 격자자료와 지점 자료 간의 비교로, 이미지 품질 평가 지표는 제외하였으며, 피어슨 상관계수 R^2 는 고해상도 ERA-5 자료 평가에서 거의 비슷한 값을 보여 함께 제외하였다. 또한, 학습자료는 전체적으로 낮은 결과를 보여 관측자료와의 평가에서 제외하였다.

고해상도 ERA-5 자료는 ASOS 관측자료와의 평가에서 MAE는 2.2574, MSE는 9.1358, RMSE는 3.0225을 보였다. 이 평가값을 기초로 딥러닝 모델 결과를 비교 분석하였다. 전체 2배 상세화 모델의 통계 평가 지표는 UD_NN_NN_2, DUR_NN_NN_2, DU_NN_NN 순으로 좋은 결과를 보였다. 4배 상세화 배율에서는 DUR_NN_NN_4, D_CUB_NN, UD_NN_NN_4, 8배 상세화 배율에서는 8x는 DU_NN_NN_8, D_CUB_CUB_8, DUR_NN_NN_8 순으로 좋은 결과를 보였다. 전체 상세화 배율 결과에서 보듯이 EDSR 모델을 기반으로 하는 상세화 딥러닝 모델에서는 보조변수 DEM 자료를 사용한 모델이 우수한 결과를 보였다. 또한, NN 보간법으로 생산한 학습자료를 이용한 모델이 다른 모델에 비해 상대적으로 좋은 결과를 보인 것으로 나타났다. 보간법, 딥러닝 모델 구성 방법 등의 분석 결과를 토대로 향후 인공지능 기반 상세화 모델을 설계하고 개발하는 기초자료로 활용될 것으로 기대된다. 그러나, 이 실험에서 NN_NN 모델이 좋은 성능을 보였으나, 향후에는 상세화 모델을 원시자료(참값)에서 시작하여 상세화를 진행하고 참값이 없는 점을 감안하여 ASOS 관측자료 등과의 평가를 통한 모델 분석이 필요할 것으로 판단된다.

기후변화 영향 평가 및 재해 예측의 핵심 기반자료인 격자형 기후자료의 해상도에 따른 극한기후 재현성 성능을 평가하는 것을 목표로 하였다. 특히 1km 해상도의 MK-PRISM 자료와 500m 해상도의 MS-PRISM (v1, v2) 자료를 2000년부터 2019년까지 20년간의 국내 관측소 자료(총 605개 지점)를 기준으로 비교 분석하였다. 모델 성능은 상관계수, RMSE, BIAS, KGE와 같은 통계적 지표는 물론, Moran's I/LISA 기반의 공간적자기상관 분석, 그리고 극한기온지수 재현력 비교를 통해 다각적으로 평가되었다. 주요 연구 결과는 다음과 같다.

1) 모델 성능 및 안정성:

- 최신 500m_v2 모델은 일평균, 일최고, 일최저기온(TAVE, TMAX, TMIN) 모든 변수에서 가장 높은 예측 성능과 공간적 안정성을 보였다. 특히 500m_v2 모델은 모든 월에서 중앙값(Median) R^2 값이 0.97 이상을 유지하며, 극한 기온 조건(여름철, 겨울철)에서도 예측 안정성이 높았습니다
- 1km 모델은 월별 변동성이 크고, 특히 국지적 기온 변동이 큰 산악 및 북부 내륙 지역에서 KGE가 -0.2 이하로 급감하는 등 예측 실패 수준에 해당하는 결과를 보이며 예측력 저하가 뚜렷하였다.

2) 공간적 재현성 (LISA 분석):

- 500m_v2 모델은 관측자료의 공간적 군집 구조(High-High, Low-Low)를 가장 정밀하게 재현하였다. 500m_v2 모델은 관측 군집과의 평균 거리 오차(1.65km)가 가장 작아, 공

간적 정확성과 군집 강도 재현력 모두에서 우수함을 입증하였다. 이는 고해상도 및 좁은 영향 반경 설정(1.3km)이 공간통계적 성능 향상에 결정적으로 기여했음을 시사한다. 지형 고도와 PRISM 격자 고도 간 불일치가 클수록 RMSE가 체계적으로 증가하는 경향이 나타나, 지형 복잡성이 높은 지역에서의 격자 해상도와 입력 자료의 정밀도가 예측 오차에 중요함을 확인하였다.

3) 극한기온지수 재현성:

- 연중 최고기온(YearMaxT) 분석에서 500m_v2 모델은 가장 높은 상관성($R=0.961$)과 설명력($R^2=0.923$)을 보이며, 국지적 고온 특성 및 극값 분포를 가장 정밀하게 재현하였다. 1km 모델은 해상도와 공간 평균화의 한계로 인해 극값 재현력이 저하되었으며, 특히 동해안 및 산악 지역에서 고온값을 과소 추정하는 공간적 편향이 뚜렷하게 나타났다. 전반적으로 모든 모델은 관측 대비 고온 관련 지수를 과소평가하고 한랭 관련 지수를 과대평가하는 경향을 보였다.

4) 극한기온지수의 미래전망:

- 저배출(SSP1-2.6) 시나리오에서는 전국적으로 연최고·연최저기온이 완만하게 상승하며, 상승폭은 내륙과 도시지역에서 상대적으로 크게 나타났다. 고배출(SSP5-8.5)시나리오에서는 전국적으로 극한 고온의 확대와 한파 완화가 뚜렷하게 나타났다. 재현수준의 결과 서울은 열섬효과로 단기·중기 재현기간에서 분산보다 극한 고온상승폭이 컸으며, 부산은 단기 상승은 완만하지만, 장기 재현기간에서 서울과 같은 수준의 극값에 도달하였다.

이 연구의 결과는 고해상도(500m) 격자형 기후자료인 MS-PRISM v2 모델이 기존의 1km MK-PRISM 모델은 물론 이전 버전의 500m 모델보다 평균 및 극한 기후 재현에 있어 현저히 우수한 성능과 공간적 안정성을 제공함을 정량적으로 입증하였다. 특히, 500m_v2 모델의 뛰어난 성능은 단순한 해상도 향상을 넘어, 국지적 지형 특성을 정밀하게 반영하는 GIS 정보와 함께 좁은 영향 반경(1.3km) 설정을 통해 복잡한 한국의 지형에 따른 미세한 기온 변동성(TMIN의 복사냉각 효과, TMAX의 열섬 효과 등)을 효과적으로 포착했기 때문으로 분석된다. 반면, 1km 해상도는 공간 평균화 효과로 인해 국지적 기온 극값 재현에 명확한 한계를 보였으며, 특히 지형 복잡도가 높은 지역에서는 예측력이 급격히 저하되었다. 따라서, 국가 차원의 기후변화 영향 평가, 극한 재해 대응 정책 수립, 그리고 지역 맞춤형 기후 서비스 개발을 위해서는 고해상도와 정밀한 공간정보 기반의 최신 500m 격자형 기후자료(MS-PRISM v2)를 핵심 기반 자료로 활용하는 것이 필수적이다. 본 연구는 고해상도 기후정보 생산체계 개선 방향을 제시하고, 기후 리스크 분석에 필요한 기초자료의 신뢰도를 높이는 데 중요한 기여를 할 것으로 기대된다.

사사

이 연구는 APCC의 지원을 통해 수행되었습니다.

References

- 기상청, 2019, 기상관측데이터 품질검사 프로세스. 기상자료개방포털
- 기상청, 2023, SSP 시나리오를 이용한 통계적 상세화 기반 한반도 상세 전망 자료 산출. 국가 R&D연구보고서
- Anselin, L. 1995. Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93-115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Arabboev, M., Begmatov, S., Rikhsivoev, M., Nosirov, K., and S. Saydiakbarov, 2024: A comprehensive review of image super-resolution metrics: classical and AI-based approaches. *ACTA IMEKO* 13(1), pp.1-9.
- Aveq, 2024: Video quality models and measurements - an overview, <https://aveq.nfo/video-quality-models-and-measurements-an-overview/> (Accessed on Dec. 2, 2025)
- Breiman, L. 2001: Random Forests. *Machine Learning*, 45, 5-32. <http://dx.doi.org/10.1023/A:1010933404324>
- Burden, R. L., & Faires, J. D., 2010. *Numerical Analysis* (9th ed.). Boston: Brooks/Cole.
- Chen, T., & Guestrin, C. 2016:. XGBoost: A Scalable Tree Boosting System. arXiv:1603.02754
- Chen, X., Wang, X., Zhou, J., Qiao, Y., and C. Dong, 2023: Activating more pixels in image super-resolution transformer. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. pp.22367-22377 (HAT)
- Copernicus Climate Change Service (C3S), Climate Data Store (CDS), 2023: ERA-5 hourly data on single levels from 1940 to present. <https://doi.org/10.24318/cds.adbb2b47>
- Cressie, N. A. C., 1993. *Statistics for Spatial Data* (Revised ed.). New York: John Wiley & Sons.
- Danielson J., and D. Gesch, 2011: Global multi-resolution terrain elevation data 2010 (GMTED 2010), No. 2011-1073. US Geological Survey. <https://doi.org/10.3133/ofr20111073>
- Dong, C., Loy, C. C., and X. Tang, 2016: Accelerating the super-resolution convolutional neural network. In *European conference on computer vision*. Cham: Springer International Publishing. pp.391-407. (FSRCNN)
- Dong, C., Loy, C. C., He, K., and X. Tang, 2015: Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence* 38(2) 295-307. (SRCNN)

- EPRI, 2025. Climate Model Downscaling, Accessed 20 November, 2025. <https://apps.epri.com/climate-data-user-guide/en/climate-model-downscaling.html>
- Ferraro R. R., 1995: Special sensor microwave imager derived global rainfall estimates for climatological applications, <https://doi.org/10.1029/97JD01210>.
- Fovell, R. G., & Fovell, M. Y. C., 1993. Climate zones of the conterminous United States defined using cluster analysis. *Journal of Climate*, 6(11), 2103–2135.
- Funk, C. et al. The climate hazards infrared precipitation with stations? a new environmental record for monitoring extremes. *Sci. Data*. 2:150066 doi: 10.1038/sdata.2015.66 (2015).
- Goovaerts, P., 1997. *Geostatistics for Natural Resources Evaluation*. New York: Oxford University Press.
- Gupta, H.V., Kling, H., Yilmaz, K.K., and Martinez, G.F. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91.
- Hawkins, E., and Sutton, R. 2009. The potential to narrow uncertainty in regional climate predictions. *Bulletin of the American Meteorological Society*, 90(8), 1095–1108.
- Hawkins, E., and Sutton, R. 2011. The potential to narrow uncertainty in projections of regional precipitation change. *Climate dynamics*, 37, 407–418.
- He, K., X. Zhang, S. Ren, and J. Sun, 2016: Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp.770–778). IEEE. <https://doi.org/10.1109/CVPR.2016.90>.
- Hudson, G., & Wackernagel, H., 1994. Mapping temperature using kriging with external drift: Theory and an example from Scotland. *International Journal of Climatology*, 14(1), 77–91.
- Huffman, G.J. et al. (2020). Integrated Multi-satellite Retrievals for the Global Precipitation Measurement (GPM) Mission (IMERG). In: Levizzani, V., Kidd, C., Kirschbaum, D.B., Kummerow, C.D., Nakamura, K., Turk, F.J. (eds) *Satellite Precipitation Measurement. Advances in Global Change Research*, vol 67. Springer, Cham. https://doi.org/10.1007/978-3-030-24568-9_19
- Idowu, A. O., 2007: The impact of an earthquake-generated tsunami on the earth-atmosphere system: Year 2004 Indian Ocean case history example. 21st Conf. on Hydrology, San Antonio, TX, Amer. Meteor. Soc., JP1.1, https://ams.confex.com/ams/87ANNUAL/techprogram/paper_117648.htm.
- Isaaks, E. H., & Srivastava, R. M., 1989. *An Introduction to Applied Geostatistics*. New York: Oxford University Press.

- Ishida, T., & Kawashima, S. (1993). Use of cokriging to estimate surface air temperature from elevation. *Theoretical and Applied Climatology*, 47(3), 147-157.
- Johnson, J., Alahi, A., and L. Fei-Fei, 2016: Perceptual losses for real-time style transfer and super-resolution. In *European conference on computer vision*. pp.694-711
- Journel, A. G., & Huijbregts, C. J., 1978. *Mining Geostatistics*. London: Academic Press.
- Joyce R. J., Janowiak, J.e., Arkin, P.A. and Xie, P., 2004: CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution, [https://doi.org/10.1175/1525-7541\(2004\)005<0487:CAMTPG>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2).
- Kim, J., Lee, J.K., and K.M. Lee, 2016: Accurate image super-resolution using very deep convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp.1646-1654 (VDSR)
- Kim, M. K., Kim, S., Kim, J., Heo, J., Park, J. S., Kwon, W. T., and Suh, M. S. 2016. Statistical downscaling for daily precipitation in Korea using combined PRISM, RCM, and quantile mapping: Part 1, methodology and evaluation in historical simulation. *Asia-Pacific Journal of Atmospheric Sciences*, 52, 79-89.
- Kling, H., Fuchs, M., and Gupta, H. 2012. Hydrological model performance evaluation: A comparison of metrics. *Water Resources Research*, 48(5). <https://doi.org/10.1029/2011WR011044>
- KMA, 2025: 기상청 기상자료개방 - 종관기상관측(ASOS)/방재기상관측(AWS), Accessed 15 November, 2025, <https://data.kma.go.kr/data/grnd/selectAsosRltmList.do?pgmNo=36>
- KMA, 2025: 기상청 기후정보포털 - 국가 기후변화 표준 시나리오 산출방법, Accessed 20 November, 2025, https://www.climate.go.kr/home/CCS/contents_2021/Kma_climate_RCP.html
- Ko, J. W., Kim, B. S., & Kim, S. J., 2013. Analysis of the Rate of Temperature Decrease with Increasing Elevation in Jeju Island. *Journal of the Korean Association of Geographic Information Studies*, 16(2), 16-28.
- Kummerow, C., Hong, Y., Olson, W. S., Yang, S., Adler, R. F., McCollum, J., ... & Wilheit, T. T. (2001). "The evolution of the Goddard Profiling Algorithm (GPROF) for rainfall estimation from passive microwave sensors." *Journal of Applied Meteorology*, 40(11), 1801-1820.
- Ledig, C., Theis, L., Huzsár F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., and W. Shi, 2017: Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp.4681-4690 (SRGAN)

- Lee, H., 2021. *Climate Change Biology* (Third Edition). Academic Press, 528 pp.
- Liang, J., Cao, J., Sun, G., Zhang, K., Van Gool, L., and R. Timofte, 2021: Swinir: Image restoration using swin transformer. In Proceedings of the IEEE/CVF international conference on computer vision. 1833-1844 (SwinIR)
- Lim, B., Son, S., Kim, H., Nah, S., and K. M. Lee, 2017: Enhanced Deep Residual Networks for Single Image Super-Resolution. In proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp.136-144 (EDSR)
- Lu, G. Y., & Wong, D. W., 2008. An adaptive inverse-distance weighting spatial interpolation technique. *Computers & Geosciences*, 34(9), 1044-1055.
- MacQueen, J. B., 1967. Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281-297.
- Min, S. K., Son, S. W., Seo, K. H., Kug, J. S., An, S. I., Choi, Y. S., and Lee, M. I. 2015. Changes in weather and climate extremes over Korea and possible causes: a review. *Asia-Pacific Journal of Atmospheric Sciences*, 51, 103-121.
- Moran, P.A.P. 1950. Notes on continuous stochastic phenomena. *Biometrika*, 37(1-2), 17-23. <https://doi.org/10.1093/biomet/37.1-2.17>
- NGII, 2025: 국토지리정보원 국토 정보플랫폼 수치지형도, Accessed 15 November, 2025, <https://map.ngii.go.kr/pd/ctlsSvc/ctlsSvc.do>
- Park, I.-G. and Suh, M.-S., 2022. Current status and trends of extreme precipitation characteristics during the last 30 years (1991-2020) over Korea. *Journal of Climate Research*, 17(2), 69-87.
- Saharia, C., Ho, J., Chan, W., Salimans, T., Fleet, D.J., and M. Norouzi, 2022: Image super-resolution via iterative refinement. *IEEE transactions on pattern analysis and machine intelligence*, 45(4), 4713-4726. (SR3)
- Sara, U., Akter, M., and S. U. Mohammad, 2019: Image Quality Assessment through FSIM, SSIM, MSE and PSNR - A comparative Study. *Journal of Computer and Communications*, 7, 8-18. <https://doi.org/10.4236/jcc.2019.73002>
- Shepard, D., 1968. A two-dimensional interpolation function for irregularly-spaced data. *Proceedings of the 1968 23rd ACM National Conference*, 517-524.
- Shi, W., Cabellero, J., Huszár F., Totz, J., Aitken, A. P., Bishop R., Rueckert D., and Z. Wang, 2016: Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In Proceedings of the IEEE conference on computer vision

and pattern recognition. pp.1874-1883 (ESPCN)

- Sorooshian, S., K. Hsu, X. Gao, H.V. Gupta, B. Imam, and Dan Braithwaite, 2000: Evaluation of PERSIANN system satellite-based estimates of tropical rainfall, *Bulletin of the American Meteorological Society*, 81(9), 2035-2046.
- Wackernagel, H., 2003. *Multivariate Geostatistics: An Introduction with Applications* (3rd ed.). Berlin: Springer-Verlag.
- Wang, X., Yu, K. Wu, S., Gu, J., Dong, C., Qiao, Y., and C. C. Loy, 2018: Esrgan: Enhanced super-resolution generative adversarial networks. In *Proceedings of the European conference on computer vision (ECCV) workshops (ESRGAN)*
- Wang, Z. and H.R. Sheikh, 2004: Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, 13(4), 600-12.
- Wang, Z., Simoncelli, E. P., and A. C. Bovik, 2003: Multi-scale structural similarity for image quality assessment. In *Proceedings of the 37th IEEE Asilomar Conference on Signals, Systems and Computers*, Pacific Grove, CA, Nov. 9-12, 2003.
- xoft, 2022: [평가 지표] PSNR / SSIM / LPIPS. <https://xoft.tistory.com/3> (Accessed on Jan. 23, 2025)
- Yamada, H. 2024. Moran's I for Multivariate Spatial Data. *Mathematics*, 12(17), 2746. <https://doi.org/10.3390/math12172746>
- Zhang, Ce., Wangyong, Lv., Ping Zhang, and Jiacheng Song. 2023. Multidimensional spatial autocorrelation analysis and its application based on improved Moran's I. *Earth Science Informatics*, 16, 3355-3368
- Zhang, R., Isola, P., Efros, A. A., Shechtman, E., and O. Wang, 2018: The unreasonable effectiveness of deep features as a perceptual metric.
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., and Y. Fu, 2018: Image super-resolution using very deep residual channel attention networks. In *Proceedings of the European conference on computer vision (ECCV) pp.286-301. (RCAN)*

Appendix A. Examples of top-ranked downscaling results compared with reference data

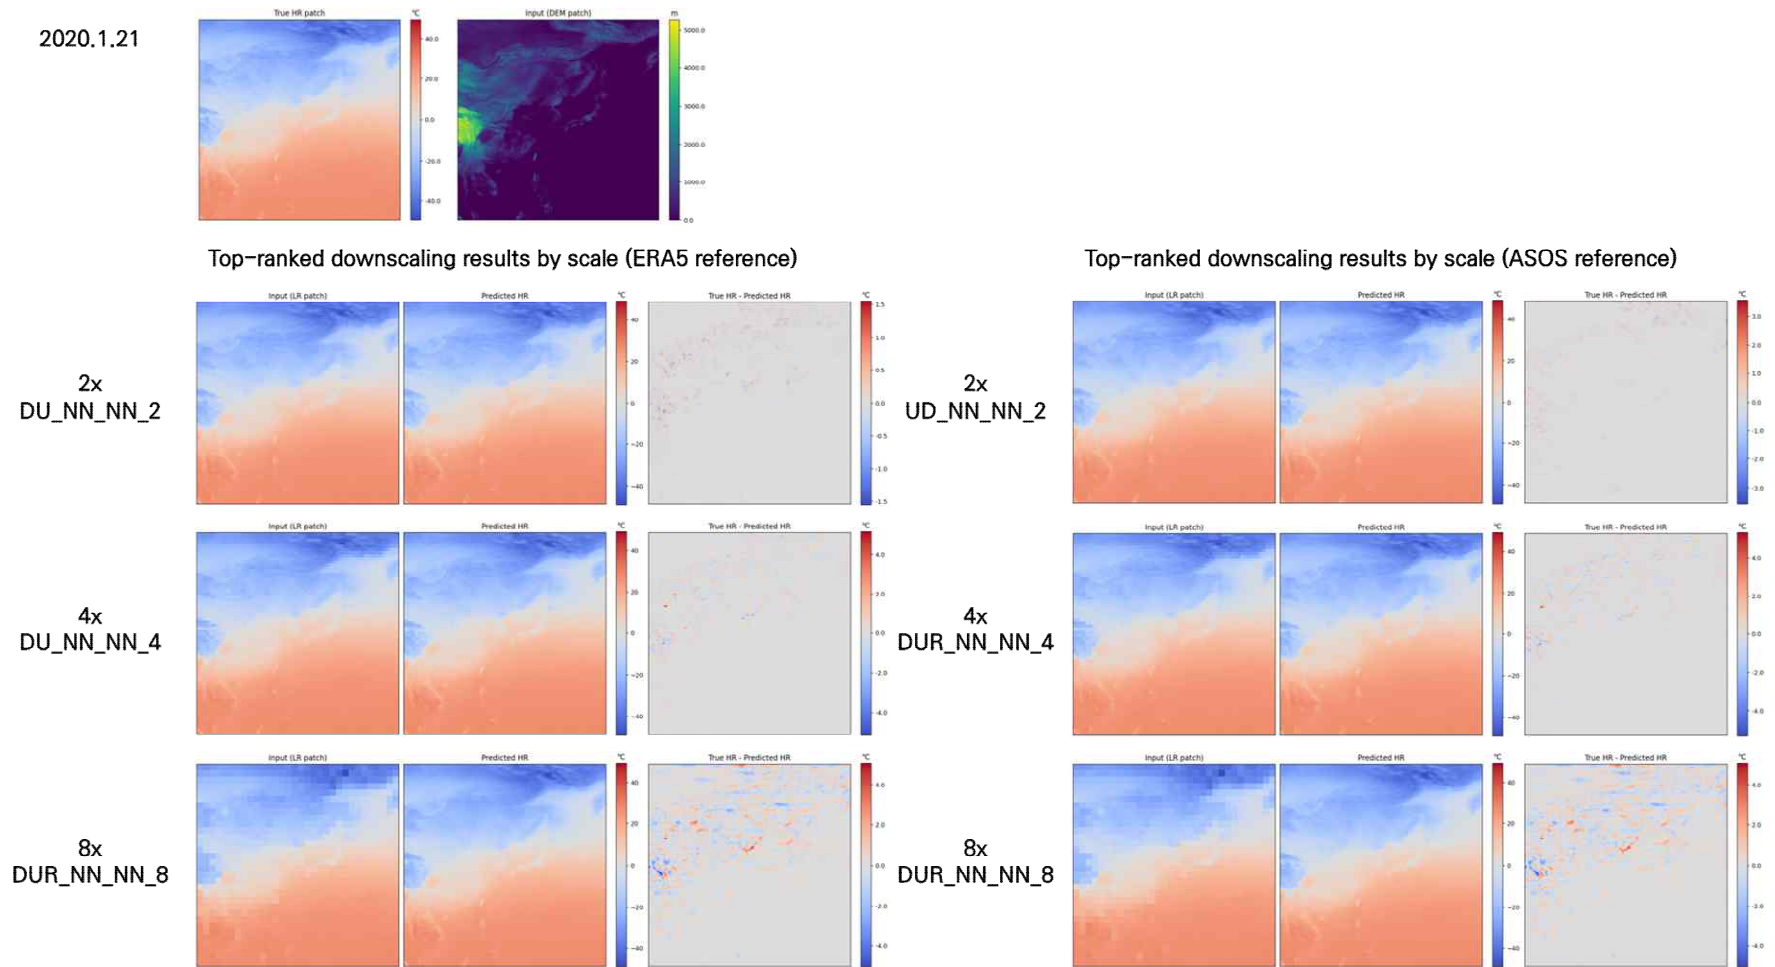




Figure A1. Examples of top-ranked results on 21 January, 2020.

2024.7.21




Top-ranked downscaling results by scale (ERA5 reference)


2x
DU_NN_NN_2



4x
DU_NN_NN_4




8x
DUR_NN_NN_8




Top-ranked downscaling results by scale (ASOS reference)

2x
UD_NN_NN_2



4x
DUR_NN_NN_4



8x
DUR_NN_NN_8




Figure A2. Examples of top-ranked results on 21 July, 2024.