

# 기계학습과 GloSea5를 이용한 장기 농업기상 예측 : 고랭지배추 재배 지역을 중심으로

김준석<sup>1</sup>, 양미연<sup>2</sup>, 윤상후<sup>3\*</sup>

<sup>1</sup>대구대학교 통계학과 석사과정, <sup>2</sup>(재)대구디지털산업진흥원 빅데이터활용센터 연구원,  
<sup>3</sup>대구대학교 수리빅데이터학부 조교수

The long-term agricultural weather forecast methods using machine  
learning and GloSea5 :  
on the cultivation zone of Chinese cabbage.

Junseok Kim<sup>1</sup>, Miyeon Yang<sup>2</sup>, Sanghoo Yoon<sup>3\*</sup>

<sup>1</sup>Department of Statistics, Daegu University

<sup>2</sup>Daegu Digital Industry Promotion Agency

<sup>3</sup>Division of Mathematics and big data science, Daegu University

요 약 농작물 재배에 있어 가장 큰 위험 요소는 날씨이므로 재배지의 장기 농업 기상정보를 얻을 수 있다면 정식과 수확 시기 등을 예측할 수 있다. 따라서 체계적인 농작업을 기획하여 관리할 수 있으며 이는 농가의 안정적인 수확으로 이어질 것으로 기대한다. 본 연구는 GloSea5와 기계학습을 이용하여 효과적인 고랭지배추의 재배를 위한 장기 농업기상정보 예측 방법을 제시하였다. GloSea5는 계절예측시스템으로 최대 240일까지의 기상을 예측한다. 심층신경망과 공간랜덤포레스트를 이용하여 장기 일 평균기온을 예측한 결과 심층신경망이 공간랜덤포레스트에 비해 장기예측성능이 우수하였다. 하지만 공간랜덤포레스트는 강원도 전역의 기온을 짧은 시간에 예측하는 장점이 있다. 공간랜덤포레스트로 분석한 결과 여름철과 해발고도가 낮은 지역의 장기 일 평균기온이 잘 예측되었다.

주제어 : GloSea5, 고랭지배추, 농업기상, 심층신경망, 공간랜덤포레스트

Abstract Systematic farming can be planned and managed if long-term agricultural weather information of the plantation is available. Because the greatest risk factor for crop cultivation is the weather. In this study, a method for long-term predicting of agricultural weather using the GloSea5 and machine learning is presented for the cultivation of Chinese cabbage. The GloSea5 is a long-term weather forecast that is available up to 240 days. The deep neural networks and the spatial randomforest were considered as the method of machine learning. The longterm prediction performance of the deep neural networks was slightly better than the spatial randomforest in the sense of root mean squared error and mean absolute error. However, the spatial randomforest has the advantage of predicting temperatures with a global model, which reduces the computation time.

Key Words : GloSea5, Chinese cabbage, Agricultural weather, Deep neural networks, Spatial random forest

\*Corresponding Author : Sanghoo Yoon(statstar@daegu.ac.kr)

Received February 14, 2020

Accepted April 20, 2020

Revised March 25, 2020

Published April 28, 2020

## 1. 서론

농작물 재배에 있어 가장 큰 위협 요소는 날씨이다. 온도, 습도, 강수량, 조도량 등의 기상요인이 농작물 생육에 영향을 미치기 때문이다. 작물마다 성장환경 조건이 상이하므로 농작물 재배 기간의 기상정보를 수집한다면 효율적인 농작업을 위한 기초자료로 활용할 수 있다[1,2]. 또한, 기상요인은 농산물 가격과 공급 측면에서 작물의 생산량 예측에 매우 중요한 정보로 이용된다[3]. 따라서 재배지의 장기 농업 기상정보를 얻을 수 있으면 체계적인 농작업을 기획하여 관리할 수 있다.

현재 기상청은 동네 예보, 중기예보(10일), 1개월 전망, 3개월 전망, 기후 전망 등을 홈페이지를 통해 서비스하고 있다. 장기 농업 기상정보는 기상청에서 운영하고 있는 계절예측시스템인 GloSea5(Global seasonal forecast system version 5)를 통해 얻을 수 있다[4]. GloSea5는 대기-지면-해양-해빙 모델이 결합된 모델로 최대 240일의 중장기 기상예측이 가능하다. GloSea5는 계절예측시스템의 6개월간 기후 예측능력 평가[4]와 GloSea5 기반의 국내 가뭄 예보[5] 등에 활용되고 있다.

정확성이 높은 기상정보를 생성하기 위한 연구로 기계학습 또는 딥러닝이 많이 활용되고 있다. 중관기상관측장비(Automated Synoptic Observing System, ASOS)와 방재기상관측장비(Automatic Weather System, AWS)의 결측치를 인공지능경망으로 보완하는 연구가 수행되었고[6], DBN(Deep Belief Network)을 이용해 새로운 강수예측 방법이 제시되었다[7]. 시간을 고려한 모델로 RNN(Recurrent Neural Network)은 도시의 홍수 피해 방지를 위한 침수 가능성을 예측하였다[8].

고랭지 농업은 해발고도 400m~1000m에서 고산 지대의 기후 특성을 이용하여 작물을 재배하는 농업이다. 고산 지대는 여름철에 긴 일조 시간, 큰 일교차와 풍부한 강우량을 가지면서 기온이 선선하기 때문에 지운에서 자라는 배추나 무 같은 작물을 재배하는 데 유리하다. 특히 배추는 우리나라에서 소비량이 많은 채소 중 하나이고 강원도 고랭지배추는 전국 배추 생산량의 93%를 차지하고 있다. 이는 고산 지대의 기후적 특징인 긴 일조 시간과 큰 일교차가 배추의 맛에 긍정적인 영향을 미치기 때문이다[9].

본 연구에서는 고랭지배추의 주산지인 강원도 일대의 장기 농업기상정보를 고해상도로 생산하는 방법을 다루고자 한다. 장기예측을 위해 계절예측시스템인 GloSea5 자료를 이용하였다. 하지만 GloSea5는 해상도가 낮고

해발고도가 고려되지 않은 기상정보를 생산하므로 고랭지배추 재배지의 기상정보로 가공하기 위해선 기계학습 방법이 필요하다. 기계학습을 위해 강원도에 설치 운영 중인 중관기상관측장비, 방재기상관측장비, 그리고 농업 기상관측소에서 수집된 2016년부터 2017년까지의 일 평균기온 자료를 사용하였다.

시계열자료의 딥러닝은 주로 RNN으로 학습시킨다. GloSea5의 예측값은 매일 과거의 관측값이 예측모델에 반영되어 새로운 예측값이 생성되므로 RNN기반의 기계학습을 적용하는 데 어려움이 있다. 이를 해결하기 위해 선행연구에서는 슬라이딩창을 통해 장기 농업기상정보를 생산하였다[10]. 하지만 슬라이딩창을 이용할 경우 계절의 변화에 따른 추세성이 반영되어 장기예측의 정확성이 낮아지는 문제점이 발생하였다. 이 문제를 해결하기 위해 본 연구에서는 공간랜덤포레스트(Spatial Random Forest, sRF) 방법을 통해 계절 성분을 제거하여 자료를 훈련시켰다. 또한, 관측소별 딥러닝 모델을 구축하여 넓은 지역의 농업기상정보를 생산하는 계산시간이 오래 걸리는 문제점이 있다[10]. 본 연구는 거리에 따른 상관성이 고려된 공간 기계학습법인 공간랜덤포레스트를 적용하여 고해상도 장기 농업기상정보인 일 평균기온을 예측하였다. 예측모델의 정확성을 평가하기 위해 일 평균기온 예측값과 관측값의 차이를 이용한 평균제곱근오차(Root Mean Square Error, RMSE), 평균절대오차(Mean Absolute Error, MAE)를 사용하였다.

연구의 구성은 다음과 같다. 2절은 연구에 사용되는 연구 방법인 딥러닝과 공간랜덤포레스트 모델을 소개하고 예측성능 비교를 위한 모델검증방법을 다룬다. 3절은 연구 자료인 GloSea5와 기상청의 일 평균기온 관측 자료를 소개하고 4절은 예측모델의 분석 결과를 다룬다. 마지막 5장에서는 연구의 결과를 논의한다.

## 2. 관련 연구

### 2.1 연구방법론

#### 2.1.1 인공신경망

인공신경망은 인간의 신경계를 모형화하여 지능을 구현하고자 하는 알고리즘이다. 인공신경망은 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer) 총 세 가지 층으로 구분되고 각 층은 노드(Node)로 구성되어 있다(Fig. 1). 인공신경망의 기법 중 은닉층이 2개 이상일 경우 심층신경망이라고 하며 심층신경망

을 학습시키는 기술을 딥러닝이라 한다[11]. 기존의 기계 학습보다 나은 성능을 가지기 위해 데이터 연산 속도의 향상, 데이터양의 증가, 인공신경망 알고리즘 개선을 하였다. 인공신경망 내부의 노드를 비활성화 시키는 것과 같은 인공신경망을 구조적으로 변화를 시키거나 인공신경망의 은닉층의 수를 늘리는 것을 통해 정확도를 향상시킬 수 있다.

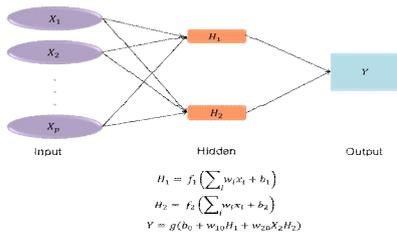


Fig. 1. Structure diagram of Artificial neural network[10]

### 2.1.2 공간랜덤포레스트

랜덤포레스트는 Breiman(2001)가 제안한 기계학습의 기법 중 하나로 의사결정나무의 심화된 기법이며 그 결과를 앙상블 방법(ensemble method)으로 종합한다[12]. Hengli 등(2018)은 랜덤포레스트는 비공간적 접근법으로 이를 해결하기 위하여 공간적 관계를 설명하는 버퍼거리를 추가한 공간랜덤분포를 제안하였다[13]. 본 연구는 입력변수로 해발고도(Digital Elevation Model, DEM)와 GloSea5 그리고 버퍼거리(Buffer distance)를 고려하였다(Fig. 2).

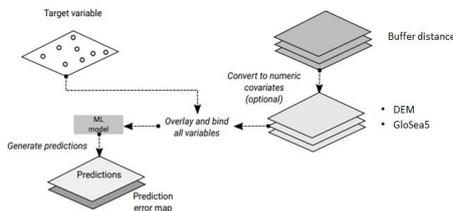


Fig. 2. Proposed structure diagram of spatial random forest[13]

기계학습을 통해 자료를 설명하는 모델을 세우기 위해 선 훈련자료와 검증자료의 구분이 필요하다. 본 연구에서는 현재 시점의 1년 전 자료를 훈련자료로 사용하고 현재 시점 자료를 검증자료로 사용하였다. 예를 들어 2017년 11월 14일을 기준으로 계절예측을 한다고 하자. 이

경우 훈련자료는 2016년 11월 14일이다. 자료의 수가 충분하지 않으므로 본 연구는 ±3일을 추가하여 2016년 11월 11일부터 2016년 11월 17일까지 자료를 훈련자료로 사용하였다. 훈련된 자료로 세워진 기계학습모델을 통해 2017년 11월 15일부터 2018년 7월 12일까지 일 평균기온을 예측할 수 있다(Fig. 3).

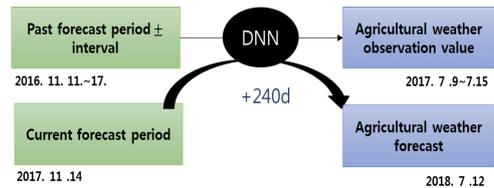


Fig. 3. The technique to learn in Machine learning

### 2.2 모델 검증

예측모델의 예측성능을 평가하기 위해 예측값과 실제 관측값의 차이를 계산하였다. 평가 기준으로 RMSE, MAE를 사용하였고 그 식은 아래와 같다.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{z}_i - z_i)^2}, \quad MAE = \frac{1}{m} \sum_{i=1}^m |\hat{z}_i - z_i|$$

여기서  $\hat{z}_i$ 는 예측값,  $z_i$ 는 관측값, 그리고  $m$ 은 예측 일의 수이다. RMSE와 MAE는 값이 작을수록 실제 관측값과 예측값의 차이가 작음을 의미하므로 예측성능이 우수하다고 평가한다.

### 3. 연구자료

본 연구에서 기계학습에 사용한 자료는 GloSea5, 고도자료(DEM), 버퍼거리, 그리고 강원도 지역에서 관측한 일 평균기온이다.

GloSea5는 전지구 계절예측시스템으로 지구규모의 대기과 해양의 효과를 반영한 대기-지면-해양-해빙의 결합모델이다. 또한 2010년부터 우리나라 기상청과 영국 기상청(Met Office)이 공동구축 및 운영 중이며 전지구 기후모델인 HadGEM(Hadley Center Global Environmental Model)을 기반으로 개발되었다. 대기 모델은 Unified Model(UM), 해양모델은 Nucleus for European Modeling of the Ocean(NEMO), 해빙모델은 Community Ice CodE(CICE)와 지표모델은 Joint UK Land Environment Simulator(JULES)로 이루어졌으며 결합자(Coupler)는 Ocean Atmosphere

Sea Ice Soil3(OASIS3)이다[14-18].

대기모델의 수평해상도는 중위도에서 60 km로 한반도는 16\*22개의 격자로 1일부터 240일 후까지 18개의 기상요인에 대해 기후 예측장이 생성되고 있다(Fig. 4). GloSea5는 14년간(1996~2009년)의 과거재현자료 HCST(Hindcast)와 실시간예측자료인 FCST(Forecast)로 구성되어 있다. 본 연구는 실시간예측자료인 FCST를 사용한다. FCST는 1개월 예보용(월 예측)과 3개월 예보용(계절예측)으로 나누어져 있으며 매일 2개씩, 총 4개의 앙상블 멤버를 수행한다. 1개월 예보용은 시작일로부터 60일, 3개월 예보용은 시작일로부터 220일씩 산출한다.

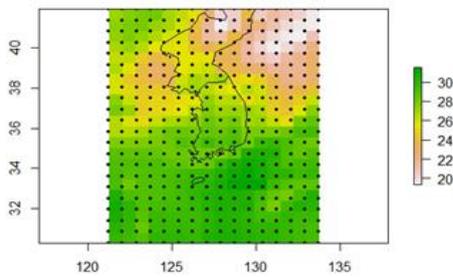


Fig. 4. The mean temperature in GloSea5

DEM은 실제 지형 정보 중 건물, 수목, 인공 구조물 등을 제외한 지형 부분만을 표현한 모형이며 지형의 고도값을 수치로 저장함으로써 지형의 형상을 나타내는 자료이다(Fig. 5). 보편적인 방법으로 90m 해상도의 격자 방식으로 저장되어 활용된다.

고랭지배추는 주로 강원도에서 재배되고 있다. 고랭지배추가 재배되는 밭의 일 평균기온을 예측하기 위해선 GloSea5의 예측값과 실제 관측값 사이의 관계를 기계학습을 통해 훈련시켜야 한다. 이를 위해 기상청에서 강원도에 설치하여 운영하고 있는 기상관측장비 85개를 이용하였다. 기상관측장비의 위치는 Fig. 5이고 관측소의 위치는 강원도 전역에 균등하게 분포되어있다.

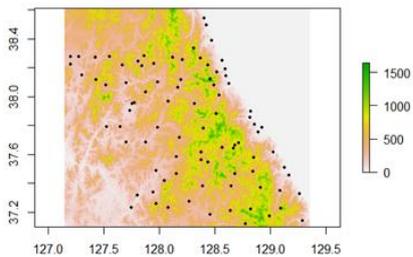


Fig. 5. The location of weather stations and DEM

버퍼거리는 기상관측장비 사이의 거리를 유클리디안(Euclidean) 방법을 이용하여 계산하였다. Fig. 6은 계산된 버퍼거리를 시각화하여 나타낸 것이며 각 관측소에서 가까울수록 진한 파란색을 띠고 있다. 공간랜덤포레스트에서는 각 기상관측소의 버퍼거리를 입력자료로 사용하여 공간적 상관성을 훈련시킨다[13].



Fig. 6. The buffer distance for each station

#### 4. 연구결과

강원도의 고해상도 농업기상정보를 예측하기 위해 사용된 GloSea5의 입력자료는 2017년 1월 4일부터 2017년 8월 4일이다. 자료의 훈련은 Fig. 3과 같이 수행되므로 실제 관측자료는 2016년 1월 1일부터 8월 7일의 일 평균기온이다. 모델예측 검증은 2017년 1월 5일부터 2017년 11월 18일까지 강원도 일 평균기온 관측 자료가 사용되었다.

먼저 GloSea5와 관측값을 관측소별 DNN의 입력자료로 훈련시켜 GloSea5만으로 예측한 모델과 RMSE와 MAE를 비교하면 Table 1이다. GloSea5만으로 예측한 것에 비해 DNN으로 예측했을 때의 RMSE와 MAE가 낮아 DNN이 더 우수한 예측력을 보인다. GloSea5와 DNN 모두 60일까지의 RMSE와 MAE가 90일 이상의 RMSE와 MAE보다 높으므로 단기예측에 비해 중장기 예측을 더 잘하고 있다.

DNN은 관측소별로 자료를 훈련시켜 예측하므로 관측소의 수가 증가할수록 계산 시간이 오래 걸리는 단점이 있다. 또한 실제 관측이 이루어지지 않은 지점의 기상

정보는 훈련시킬 수 없으므로 공간보간법(Spatial interpolation)을 통해 예측해야 한다. DNN 특성상 활성화함수의 가중치를 계산해야 하므로 30일 단위의 예측 결과만 Table 1에 반영되었다. 이에 본 연구에서는 공간 랜덤포레스트를 통해 강원도 전역의 일 평균기온을 예측하는 방법을 제시하고자 한다.

Table 1. The result of validation by DNN and GloSea5

	DNN		GloSea5	
	RMSE	MAE	RMSE	MAE
30day	<b>4.66</b>	<b>3.51</b>	5.45	4.30
60day	5.23	4.12	<b>4.18</b>	<b>3.42</b>
90day	<b>2.99</b>	<b>2.30</b>	4.88	3.88
120day	<b>2.82</b>	<b>2.50</b>	3.97	3.32
150day	3.02	2.40	<b>2.53</b>	<b>1.97</b>
180day	<b>3.14</b>	<b>2.59</b>	3.33	2.75
210day	<b>3.58</b>	<b>2.92</b>	3.69	3.32
240day	<b>2.79</b>	<b>2.25</b>	3.90	3.25

강원도 지역의 일 평균기온의 공간분포를 예측하기 위해선 이를 설명하기 위한 입력자료가 필요하다. 또한, 입력 자료의 해상도가 모두 같아야 한다. 본 연구에서는 R의 'projectRaster' 함수를 이용하여 해발고도, GloSea5, 버퍼 거리의 해상도를 bilinear방법을 통해 30m로 맞추었다.

예로 강원도 지역을 대상으로 2017년 7월 31일의 GloSea5 입력자료는 Fig. 7이다. 기상관측장비에서 측정된 관측값은 Fig. 8이다. 기상관측값을 공간 보간법으로 시각화하면 Fig. 9이다. 해발고도가 높은 백두대간의 기온이 낮고 평지의 기온이 높게 표현되어 있다. 버퍼거리와 고도 그리고 GloSea5를 입력자료로 사용하여 공간 랜덤포레스트로 예측하면 Fig. 10이다. 실제 관측값과 비슷한 기온 패턴이 반영되어 있을뿐더러 해발고도가 높은 설악산 지역의 기온이 더 낮게 표현되어 있다. DNN은 관측소의 수만큼 모델이 필요하지만 공간랜덤포레스트는 하나의 모델로 전체지역이 예측되므로 강원도의 일 평균 기온을 예측하는 시간이 DNN에 비해 짧다.

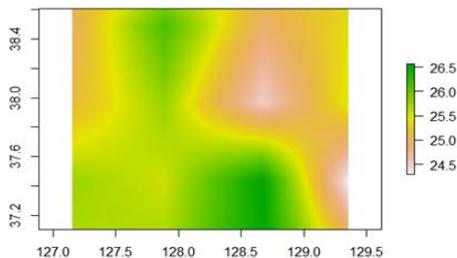


Fig. 7. The projected GloSea5 to 30m

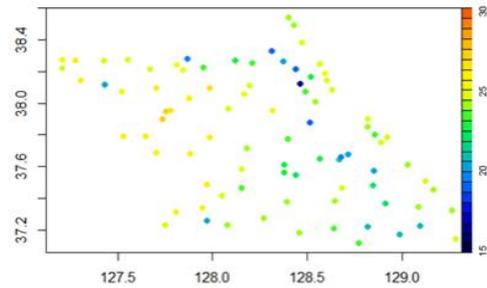


Fig. 8. The observed daily mean temperature

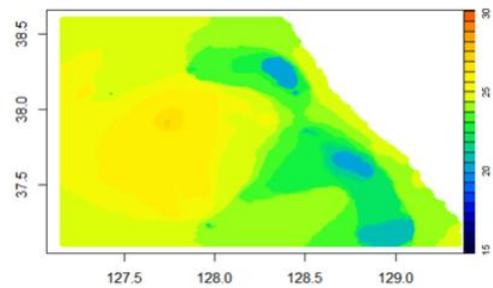


Fig. 9. The spatial distribution of observed temperature

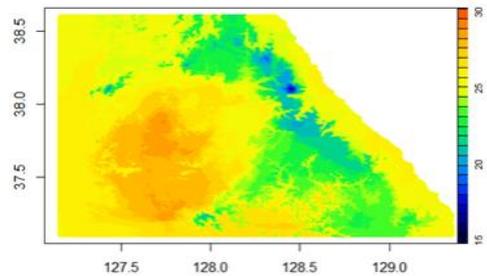


Fig. 10. The predicted spatial distribution by spatial random forest

공간랜덤포레스트를 이용하여 DNN과 같이 2016년 1월 1일부터 8월 7일의 일 평균기온을 예측한 결과는 Fig. 11, Fig. 12와 같다. RMSE를 기준으로 하였을 때 50일부터 90일까지의 예측성능이 비교적 좋은 것을 확인할 수 있고 150일 이후의 장기예측력은 낮았다(Fig. 11). MAE도 RMSE와 유사한 패턴을 보인다(Fig. 12).

공간랜덤포레스트의 RMSE는 3.0~3.7이며 DNN의 RMSE와 비교해 보면 60일까지의 예측성능은 공간랜덤포레스트가 좋지만 90일 이후의 예측성능은 DNN이 우수했다. 공간랜덤포레스트의 장기 예측성능은 DNN에

비해 부족하나 하나의 모델로 전체지역을 예측하므로 DNN에 비해 계산시간이 짧다. 계산시간이 DNN에 비해 짧아 시간해상도를 30일 단위가 아닌 일 단위로 +1일부터 +240일까지 계산하였다.

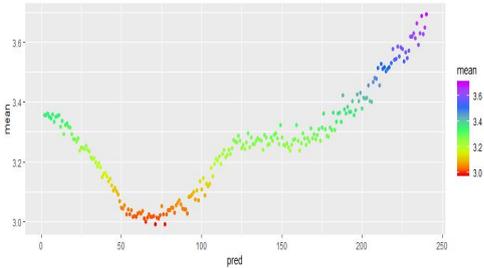


Fig. 11. The mean of RMSE

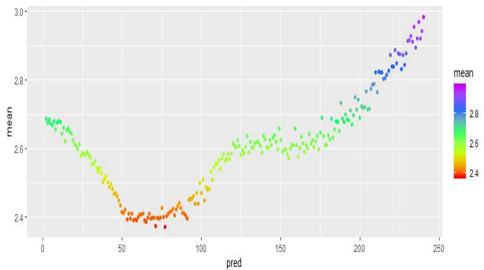


Fig. 12. The mean of MAE

공간랜덤포레스트의 예측성능의 특징을 살펴보기 위해 월별 예측성능을 그리면 Fig. 13와 Fig. 14이다. 월에 무관하게 여름철 예측성능이 우수하였다. 하지만 겨울철 예측성능이 그리 좋지 못했다. 이는 2017년의 겨울철 기온이 2016년보다 현저히 낮아 GloSea5의 훈련이 모델에 잘못 반영되었기 때문이다. 고랭지배추는 5월에 정식하여 9월 말부터 10월 초까지 주로 수확하므로 여름철의 예측성능이 우수한 공간랜덤포레스트를 농업기상에 활용할 수 있다.

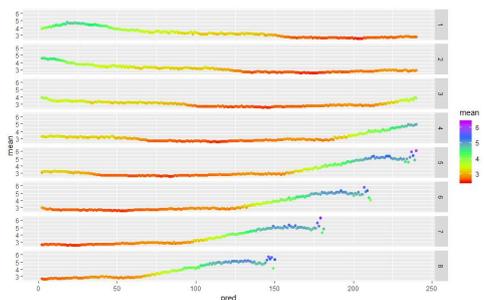


Fig. 13. The mean of RMSE by month

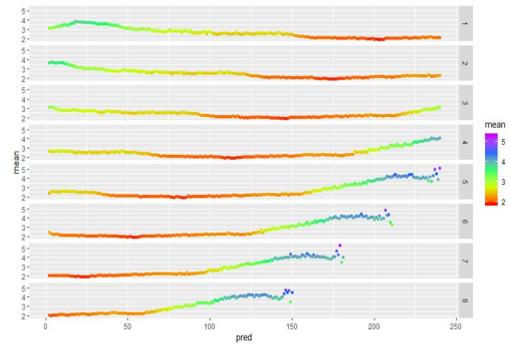


Fig. 14. The mean of MAE by month

고랭지배추는 주로 해발고도가 높은 고산지에서 재배된다. 해발고도에 따른 RMSE 공간분포를 그리면 Fig. 15이다. 해발고도가 낮을수록 RMSE가 낮아지고 해발고도가 높을수록 RMSE가 높아지는 경향이 있다. 이는 해발고도가 높은 지역의 훈련자료가 충분하지 않아 고산지의 평균기온 특성이 제대로 훈련되지 않았기 때문이다. 따라서 고산지역에 관측소를 추가설치 운영한다면 고랭지 지역의 농업기상정보의 정확성을 향상시킬 것이다.

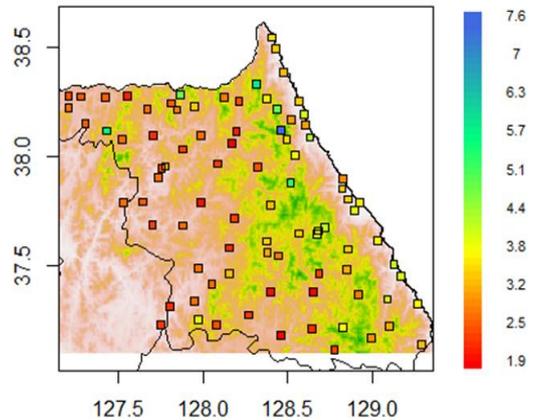


Fig. 15. RMSE result of spatial random forest according to station

## 5. 논의 및 결론

본 연구에서는 강원도의 고랭지배추 재배를 위한 장기 농업기상정보 예측 방법을 DNN과 공간랜덤포레스트로 제시하였다. 농업기상정보를 예측하기 위해 사용된 GloSea5의 입력자료는 2017년 1월 4일부터 2017년 8

월 4일까지이며 관측 자료는 2016년 1월 1일부터 8월 7일의 일 평균기온 자료가 사용되었고 모델예측 검증은 2017년 1월 5일부터 2017년 11월 18일까지 강원도 일 평균기온 관측 자료가 사용되었다.

선행연구에서는 슬라이딩창을 이용한 DNN으로 장기 농업기상정보를 생산하였지만 이는 계절의 변화에 따른 추세성이 반영되어 장기예측의 정확성이 낮아지는 문제점이 발생되었다[10]. 이를 해결하기 위해 본 연구에서는 기계학습 훈련 방법을 Fig. 3의 방식으로 수행하였다. DNN과 공간랜덤포레스트를 비교한 결과 단중기예측(60일)은 공간랜덤포레스트가 예측을 잘하지만 90일 이후인 장기예측은 DNN이 더 우수했다. 하지만 DNN은 관측소별 모델로 구현되어 공간랜덤포레스트에 비해 계산시간이 오래 걸리는 단점이 있다. 예측성능을 계절별로 살펴보면 여름철이 겨울철에 비해 상대적으로 장기예측이 우수하다. 또한 해발고도가 낮은 지역이 높은지역에 비해 잘 예측되었다.

본 연구에서의 모델은 1년 전 GloSea5만 훈련자료로 사용하였다. 만약 과거 20년~30년까지의 GloSea5를 훈련시켜 예측한다면 평년의 개념과 유사하게 평균적인 장기계절예측을 할 수 있다. 또한 연도별 자료를 샘플링하여 모델을 앙상블시키면 장기예측의 불확실성을 평가할 수 있다. 추가적으로 해발고도가 높은 지역의 관측 자료가 충분하지 않아 예측성능이 좋지 않으므로 향후 고산 지역에 관측소를 추가설치 운영한다면 고랭지배추지역의 장기 농업기상예측성능 향상에 도움이 될 것이다.

## REFERENCES

- [1] M. H. Na, Y. H. Park & W. H. Cho. (2017). A study on optimal environmental factors of tomato using smart farm data. *Journal of the Korean Data & Information Science Society*, 28(6), 1427-1435.
- [2] B. J. Kang & H. C. Cho. (2016). System of Agricultural Land Monitoring Using UAV. *Journal of the Korea Academia-Industrial cooperation Society*, 17(6), 372-378.
- [3] M. Kim, S. Hong & S. Yoon. (2018). The Comparison of Peach Price and Trading Volume Prediction Model Using Machine Learning Technique. *Journal of The Korean Data Analysis Society*, 20(6), 2933-2940.
- [4] M. I. Jung, S. W. Son, J. Choi & H. S. Kang. (2015). "Assessment of 6-Month Lead Prediction Skill of the GloSea5 Hindcast Experiment". *Atmosphere*, 25(2), 323-337.
- [5] K. H. Son, D. H. Bae & H. S. Cheong. (2015). Construction & Evaluation of GloSea5-Based Hydrological Drought Outlook System. *Atmosphere* 25(2), 271-281.
- [6] J. S. Min, M. H. Lee, J. B. Jee & M. Jang. (2016). A Study of the Method for Estimating the Missing Data from Weather Measurement Instruments. *Journal of Digital Convergence*, 14(8), 245-252.
- [7] J. H. Ha, Y. H. Lee & Y. H. Kim. (2016). Forecasting the precipitation of the next day using deep learning. *Journal of Korean Institute of Intelligent Systems* 26(2), 93-98.
- [8] Tran Q. K. & S. K. Song. (2017). Water Level Forecasting based on Deep Learning: A Use Case of Trinity River-Texas-The United States. *Journal of KIISE* 44(6), 607-612.
- [9] I. C. Son et al. (2015). Effects of Differentiated Temperature Based on Growing Season Temperature on Growth and Physiological Response in Chinese Cabbage 'Chunkwang'. *Korean Journal of Agricultural and Forest Meteorology*, 17(3), 254-260.
- [10] M. Yang & S. Yoon. (2018). Production of agricultural weather information by Deep Learning. *Journal of Digital Convergence*, 16(12), 293-299.
- [11] N. R. Jo. (2017). *Design and Implementation of criminal Identification System Based on Deep Learning*. Master dissertation, Gachon University, Gyeonggi.
- [12] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- [13] Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G. B. & Gräler, B. (2018). Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, 6, e5518.
- [14] Davies, T. et al.(2005). A new dynamical core for the Met Office's global and regional modelling of the atmosphere. *Quarterly Journal of the Royal Meteorological Society: A journal of the atmospheric sciences, applied meteorology and physical oceanography*, 131(608), 1759-1782.
- [15] Madec, G. (2008). the Nemo team (2008) NEMO ocean engine. *Note du Pôle de modélisation, Institut Pierre-Simon Laplace (IPSL), France*, (27).
- [16] Bailey, D. et al.(2010). Community ice CodE (CICE) user's guide version 4.0. *National Center for Atmospheric Research, Boulder, Colorado*, 22.
- [17] Best, M. J. et al.(2011). The Joint UK Land Environment Simulator (JULES), model description-Part 1: energy and water fluxes. *Geoscientific Model Development*, 4(1), 677-699.
- [18] Valcke, S. (2013). The OASIS3 coupler: a European climate modelling community software. *Geoscientific Model Development*, 6(2), 373.

김 준 석(Junseok Kim)

[학생회원]



- 2019년 2월 : 대구대학교 전산통계학과 (학사)
- 2019년 2월 ~ 현재 : 대구대학교 통계학과 (석사과정)
- 관심분야 : 통계, 인공지능
- E-Mail : jseok95@naver.com

양 미 연(Miyeon Yang)

[학생회원]



- 2017년 2월 : 대구대학교 전산통계학과 (학사)
- 2019년 2월 : 대구대학교 통계학과 (석사)
- 2019년 7월 ~ 현재 : (재)대구디지털산업진흥원 연구원
- 관심분야 : 통계, 인공지능

E-Mail : aldus9706@naver.com

윤 상 후(Sanghoo Yoon)

[정회원]



- 2011년 8월 : 전남대학교 통계학과 (이학박사)
- 2012년 12월 ~ 2013년 11월 : The university of Southampton 박사후연구원
- 2016년 3월 ~ 현재 : 대구대학교 조교수

· 관심분야 : 시공간모형, 극단치 분포, 통계학습

· E-Mail : statstar@daegu.ac.kr