

심층신경망을 이용한 농업기상 정보 생산방법

양미연¹, 윤상후^{2*}

¹대구대학교 통계학과 석사과정, ²대구대학교 수리빅데이터학부 조교수

Production of agricultural weather information by Deep Learning

Miyeon Yang¹, Sanghoo Yoon^{2*}

¹Dept. of Statistics, Daegu University, Master's course

²Division of Mathematics and big data science, Daegu University, Assistant professor

요 약 기상은 농작물 재배에 많은 영향을 미친다. 농작물 재배지의 기상정보는 효율적인 농작물 재배 및 관리에 필수적이다. 농업기상 정보의 높은 수요에도 불구하고 이에 대한 연구는 부족하다. 본 연구는 중장기 계절예측정보인 GloSea5와 심층신경망을 통해 양파의 주산지인 전라남도의 농업기상 정보 생산 방법을 다룬다. 연구방법으로는 매일 생산되는 GloSea5 기상정보를 훈련시키기 위해 슬라이딩 창 방법을 활용한 심층신경망 모형이 사용되었다. 모형의 정확도평가는 농업기상관측소의 일 평균기온과 GloSea5 예측값 그리고 딥러닝 예측값 차이의 RMSE와 MAE로 계산하였다. 심층신경망 모형은 학습기간이 늘어날수록 정확도가 향상되므로 학습기간과 예측기간에 따른 예측성능을 비교하였다. 분석결과 학습기간과 예측기간은 비례하지만 계절변화에 따른 추세성이 반영되는 한계점이 있었다. 이를 보완하기 위해 예측값과 관측값의 차이를 다음날 예측값에 적용시킨 후보정 심층신경망 모형을 제시하였다.

주제어 : 농업기상, 딥러닝, 슬라이딩창, 심층신경망, GloSea5

Abstract The weather has a lot of influence on the cultivation of crops. Weather information on agricultural crop cultivation areas is indispensable for efficient cultivation and management of agricultural crops. Despite the high demand for agricultural weather, research on this is in short supply. In this research, we deal with the production method of agricultural weather in Jeollanam-do, which is the main production area of onions through GloSea5 and deep learning. A deep neural network model using the sliding window method was used and utilized to train daily weather prediction for predicting the agricultural weather. RMSE and MAE are used for evaluating the accuracy of the model. The accuracy improves as the learning period increases, so we compare the prediction performance according to the learning period and the prediction period. As a result of the analysis, although the learning period and the prediction period are similar, there was a limit to reflect the trend according to the seasonal change. a modified deep layer neural network model was presented, that applying the difference between the predicted value and the observed value to the next day predicted value.

Key Words : Agricultural weather, Deep learning, Sliding window, Deep neural network, GloSea5

1. 서론

기상은 농작물 재배 시 생산량, 생육관리, 농가 수익 등에 많은 영향을 미친다. 성공적인 농작물 재배를 위해

선 농작물 주산지의 정확도 높은 농업기상 정보가 필요하다. 만약 중장기단위의 농업기상 정보는 농작업 활동에 효율적으로 관리하는데 도움이 된다. 하지만 계절 규모 기간 이상의 중장기 단위의 기상 예측에 관한 연구는

*This research was supported by the Daegu University Research Grant, 2017.

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

Received September 11, 2018

Accepted December 20, 2018

Revised November 30, 2018

Published December 28, 2018

아직 부족하다[1].

중장기계절예측을 위해 기상청은 2014년 한영 공동계절예측시스템인 GloSea4에서 수평분해능과 물리과정을 향상시킨 고해상도 계절예측시스템 GloSea5를 도입하여 운영 중이다[2]. GloSea5는 대기, 해빙, 해양, 지표면 4개의 모델이 결합된 모델로서 최대 240일의 중장기 기상예측이 가능하다.

중장기 기상인 GloSea5와 기후, 수문학, 도시 홍수 등을 융합한 다양한 연구가 수행되고 있다. 과거 GloSea5 모의자료와 계절예측시스템의 기후 예측능력이 평가되었고[2], GloSea5 기반의 수문학적 가뭄전망을 통한 가뭄예보의 활용성이 제시되었다[3].

기계학습은 인공지능의 한 분야로 컴퓨터가 학습을 할 수 있도록 하는 기술을 의미한다. 기상분야에 기계학습을 활용한 다양한 연구가 진행되고 있다. 인공지능망 모형으로 자동기상관측장비 ASOS(Automated Synoptic Observing System)와 AWS(Automatic Weather System)의 결측치를 보완하고[4], DBN (deep belief network)를 이용한 새로운 강수예측 방법이 제시되었다[5]. 시계열 데이터 분석에 활용되는 RNNs (Recurrent Neural Networks)는 도시의 홍수 피해 방지를 위한 침수 가능성을 예측하는데 사용되었고[6], 시계열 자료의 수요예측에 활용되고 있다[7].

본 연구는 GloSea5와 심층신경망 모형을 통해 양과주 산지인 전라남도의 일 평균 기온을 생산하는 방법을 다루고자 한다. 매일 생산되는 기상예측자료의 시계열 특성을 반영한 슬라이딩 창 방식의 심층신경망 모형이 사용되었다. 일반적인 시계열 자료의 기계학습은 순환신경망모형이 널리 사용된다[8]. 하지만, 순환신경망모형은 현재와 과거의 입력정보에 서로 의존성이 존재하는 구조이다[9]. GloSea5는 매일 기상예측값이 생성되므로 기존의 순환신경망모형이 적합하지 않아 본 연구에서는 슬라이딩 창 기법으로 매일 갱신되는 기상예측정보를 반영한 심층신경망모형을 세웠다.

모형의 정확성 검증을 위해 전라남도에 설치운영중인 농업기상관측소 관측 자료가 사용되었다. 심층신경망 모형을 이용한 농업기상관측소 예측정보와 GloSea5의 예측정보의 평균제곱오차(Root Mean Square Error, RMSE)와 절대평균오차(Mean Absolute Error, MAE)를 통해 제안된 심층신경망 모형의 예측성능을 평가하였다. 최적 GloSea5 격자 선정과 학습기간은 RMSE와 MAE로

선정되었다. 심층신경망의 중요 입력변수는 GloSea5와 일 평균기온 간 상관계수로 선택되었다.


본 연구의 구성은 다음과 같다. 2절은 연구에 사용되는 심층신경망 모형과 슬라이딩 창 기법에 대해 소개하고 예측 성능 비교를 위한 모델 검증방법을 다룬다. 3절은 연구에 사용된 자료를 제시하고 분석결과를 기술한다. 4장에서는 새로운 방법제시와 그에 따른 결과를 기술하고, 마지막 5장에서는 연구의 결과 및 향후 연구방향에 대해 논의한다.

2. 연구방법론

2.1 인공신경망

인공신경망은 인간의 뇌를 모형화하여 지능을 구현하고자 하는 방법이다. 인공신경망은 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)으로 이루어져있고 그것을 구성하는 노드(Node)로 구성되어있다. 입력층은 외부로부터 입력값을 받아 은닉층의 노드들에게 정보를 전달한다. 출력층의 노드는 은닉층의 노드를 통해 전달받은 값에 대해 출력값을 산출한다[10-12]. 은닉층과 출력층을 구성하고 있는 노드들은 합산함수와 전이함수를 가지고 있으며 입력층의 노드들은 가지고 있지 않다. 은닉층은 입력층과 출력층 사이에 존재하며 은닉층 수, 은닉노드의 수를 적절히 조정하여 원하는 값을 산출하도록 도와준다[13]. 이 때 노드의 수가 너무 많은 경우 과잉 맞춤 현상이 발생하여 설명력은 있지만 예측력이 의미가 없어지는 경우가 많다[11].

인공신경망의 학습이란 출력 값과 실제 값의 오차를 최소화하기 위해 노드와 노드를 연결하고 있는 가중치를 조절하는 방법이다[14]. 또한 학습을 통해 가중치를 조절하여 새로운 정보를 변경하거나 추가할 수 있다[15].



$$H_1 = f_1(\sum_i w_i x_i + b_1)$$

$$H_2 = f_2(\sum_i w_i x_i + b_2)$$

$$Y = g(b_0 + w_{10}H_1 + w_{20}X_2H_2)$$

Fig. 1. Structure diagram of DNN

2.2 심층신경망

은닉층이 2개 이상일 경우 심층신경망이라고 하며 심층신경망을 학습시키는 기술을 딥러닝이라고 한다[16]. 딥러닝은 심층신경망에 기반한 기계학습으로 사람의 사고방식을 컴퓨터에게 가르치는 분야이며 데이터 연산속도의 향상, 데이터 양의 증가, 인공 신경망 알고리즘 개선을 통해 기존의 기계학습보다 나은 성능을 가진다. 인공신경망의 은닉층의 수를 늘리거나 신경망 내부의 노드를 비활성화 시키는 것과 같은 인공신경망을 구조적으로 변화를 통해 정확도 향상시킬 수 있다.

딥러닝 기법들 중 심층 신경망(deep neural networks; DNN)은 입력 층과 출력 층 사이에 여러 개의 은닉 층들로 이루어져 구조상으로 인공신경망과 동일하다. 본 연구에 적용되는 심층신경망 구조는 Fig. 1과 같다. 여기서 입력변수는 폭우비율(Israin), 온도(temp), 온도(temp_1), 온도(temp_2), 시간단위 표면온도(temp_3), 상대습도(rh), 특정습도(q), 이슬점(field17), 대류성 강우비율(cvrain), 총 강수비율(precip), 평균 해면 압력(p), 토양수분 함량(sm), 총 표면 흐름(field184)이고, 출력변수는 일 평균 기온이다.

2.3 GloSea5

GloSea5는 영국 기상청의 기후모델인 HadGEM3 (HadleyCentre Global Environment Model version 3)에 기반하여 구축되었다. HadGEM3는 Unified Model(UM)인 대기모델과 Nucleus for European Modeling of the Ocean (NEMO) 해양모델 및 Los Alamos sea ice model (CICE) 해빙모델, 그리고 Met Office Surface Exchange Scheme (MOSES) 지면 모델 및 대기-해양 플럭스 교환을 위한 OASIS 커플러로 구성된다[2]. 기상청은 2010년 6월 영국 기상청과 운영 협정을 체결하여 2014년부터 현업에 적용하고 있다. GloSea5는 계절예측의 성능향상을 위해 예측자료 FCST(Forecast)와 과거재현자료 HCST(Hindcast)를 동시에 생산하고 있다[17].

2.4 모델 검증

모형예측검증은 2016년을 모의한 GloSea5를 학습(15일, 30일, 45일, 60일, 75일, 90일)시켜 중단기 예측값(30일, 60일, 90일, 120일, 150일, 180일, 210일, 240일)과 실제 관측값 비교를 통해 검증되었다. 슬라이딩 창 방식의 심층신경망 모형을 도식화하면 Fig. 2와 같다. 슬라이딩 창

의 학습기간을 일정하게 유지한 채 시작점을 순차적으로 1일 단위씩 이동하여 학습하도록 심층신경망 모형을 구성하였다[18].




Fig. 2. Sliding Window.

최적 GloSea5 격자(4개, 16개, 36개) 선정과 심층신경망 모형의 예측성능을 평가하기 위해 RMSE와 MAE가 사용되었다.

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

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{z}_i - z_i|,$$

여기서 \hat{z}_i 는 예측 값, z_i 는 관측 값, 그리고 m은 예측 일의 수이다.

3. 자료 분석

3.1 연구자료

계절예측시스템인 GloSea5는 4개의 모델(대기, 해빙, 해양, 지표면)이 결합된 모델이다. 본 연구는 GloSea5와 농업기상 관측자료를 혼련시켜 중장기 농업기상 정보를 생산하는 방법을 다루고자 한다. 연구지역은 양과 주산지인 전라남도이다. 연구지역의 주산지 그리고 농업기상 관측소의 위치는 Fig. 3과 같다.

GloSea5는 한반도 전역의 중장기 예측값을 수평해상도 60km로 생산한다. 기계학습을 위한 입력 범위 설정을 위해 Fig. 4와 같이 농업기상관측소 인근의 격자(4개, 16개, 36개)를 이용했다. 농업기상 관측자료는 2016년 1년 동안 관측된 일 평균기온이다. GloSea5에서 생산되는 기상변수는 Table 1과 같다.

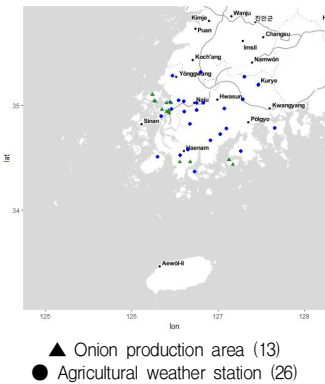


Fig. 3. Production areas and Agricultural weather stations




Fig. 4. The location of agricultural weather station and GloSea5

Table 1. Variables of GloSea5

Variable	Description
Issnow	Large Scale Snowfall Rate (Kg m2 s-1)
lsrain	Large Scale Rainfall Rate (Kg m2 s-1)
temp	Temperature AT (1.5 m K)
temp_1	Temperature AT (1.5 m K)
temp_2	Temperature AT (1.5 m K)
temp_3	Surface temperature after timestep
rh	Relative Humidity AT (1.5 m)
q	Specific Humidity AT 1.5 m (Kg Kg-1)
field17	DEWPOINT AT 1.5 m (K)
cvsnow	Convective Snowfall Rate (Kg m2 s-1)
cvrain	Convective Rainfall Rate (Kg m2 s-1)
precip	Total Precipitation Rate (Kg m2-1)
p	Pressure AT Mean Sea Level Pa
sm	Soil Moisture Content (Kg m2-1)
snowdepth	Snow Amount Over Land AFT TSTEP (Kg m2-1)
icedepth	Sea Ice Depth (Mean Over Ice) (m)
iceconc	FRAC of Sea Ice In Sea After Tstep (0-1)
field184	Surface Total Moisture Flux (Kg m2 s-1)

3.2 분석결과

GloSea5에서 생산되는 18개의 입력변수와 농업기상을 위한 일 평균기온과의 상관분석을 통해 상관계수가 0.7이상인 입력변수를 심층신경망 모형의 입력변수로 선택하였다. 농업기상관측소 인근 격자 크기에 따른 예측 성능을 비교한 결과는 Table 2과 같다. 분석결과 농업기상관측소 인근의 16개 격자자료를 사용했을 때 평균 RMSE가 3.820으로 가장 낮았다. 심층신경망 모형의 입력변수는 16개의 격자에서 생산된 18개의 기상정보 288개 중 일 평균기온과의 상관성이 높은 변수이다.

Table 2. The result of validation by number of grid and predicted days - training days : 60days

size	days	RMSE	MAE	days	RMSE	MAE
4	30	3.341	2.521	150	3.880	2.947
	60	3.105	2.423	180	4.049	3.326
	90	3.628	2.843	210	4.319	3.400
	120	3.583	2.801	mean	3.862	3.051
16	30	3.393	2.514	150	3.867	3.049
	60	3.215	2.495	180	4.174	3.328
	90	3.301	2.532	210	4.034	3.258
	120	3.593	2.777	mean	3.820	3.035
36	30	3.288	2.465	150	3.812	2.945
	60	3.192	2.492	180	4.287	3.498
	90	3.497	2.624	210	4.192	3.330
	120	3.641	2.848	mean	3.869	3.068

심층신경망 모형은 학습량이 증가할수록 예측정확도가 향상된다. 슬라이딩 창의 길이와 학습기간은 모형의 예측정확도에 영향을 준다. 최적 슬라이딩 창의 길이와 학습기간을 결정하기 위해선 모든 조합의 결과가 비교 분석해야 한다. 하지만 계산시간이 비싼 어려움이 있다. 본 연구는 슬라이딩 창의 길이를 단기(30일)로 고정하여 최적 학습기간을 15일, 30일, 45일, 60일, 75일, 90일로 구분하여 예측성능을 평가하였다[Fig. 5]. 학습기간이 증가할수록 RMSE도 증가하므로 단기예측을 위해선 학습기간이 짧아야 한다. 하지만 학습기간이 너무 짧을 경우 갑작스런 기상변화를 반영하지 못하는 단점이 있다.

단기예측(30일)에 적합한 학습기간이 장기예측(210일)에도 동일하게 적용되는지 살펴보기 위해 슬라이딩 창의 길이를 210일로 설정하여 분석한 결과는 Fig. 6과 같다. 장기예측은 학습기간을 90일로 설정했을 때 RMSE가 낮았다. 즉 슬라이딩 창의 길이는 학습기간과 비례한다.




Fig. 5. Boxplot of RMSE and MAE by training days - predicted days : 30 days.




Fig. 6. Boxplot of RMSE and MAE by training days - predicted days : 210 days.

훈련기간에 따른 단·장기 예측패턴이 파악하기 위해 1년동안 관측된 농업기상 관측자료와 심층신경망 모형의 예측값 차이를 비교하였다. 단기예측(30일) 결과는 Fig. 7이고 장기예측(210일)한 예측 결과는 Fig. 8과 같다. 단기예측은 슬라이딩 창 길이와 훈련기간이 짧아 3월부터 12월까지 예측값과 관측값의 변화를 살펴볼 수 있지만, 장기예측은 슬라이딩 창 길이(210일)와 훈련기간(90일)이 길어 11월과 12월의 예측값과 관측값의 변화를 볼 수 있다. Fig. 7과 Fig. 8에서 보여주듯이 심층신경망 모형의 예측값의 평활선이 관측값의 평활선의 약간 오른쪽에 존재한다. 이는 계절성분을 지니는 추세성이 심층신경망 모형에서 학습되기 때문이다.

슬라이딩 창 방식의 심층신경망 모형에서 추세성을 제거하기 위해선 장기간(1년) 자료를 훈련기간으로 설정하면 된다. 또 다른 대안은 예측된 값의 후보정을 통한 추세성 제거이다.




Fig. 7. The result of DNN - predicted days : 30 days, training days : 30days.




Fig. 8. The result of DNN - predicted days : 210 days, training days : 90days.

4. 추세성 제거

본 연구에서는 추세성이 반영된 심층신경망 모형의 예측값과 실제 관측값 차이를 다음날 예측값에 반영하여 보정된 예측값을 새로 생성하였다. 단기예측의 관측값(obs), GloSea5, 심층신경망(DNN1) 그리고 후보정한 심층신경망(DNN2) 결과는 Fig. 9이고 RMSE와 MAE는 Table 3과 Table 4이다. 여기서 model 1과 model2는 GloSea5에서 생산된 여러 모형의 결과 중 일부이다. Fig. 9에서 전반적으로 DNN2가 다른 모형들보다 obs와 가깝다. 또한 DNN1에 존재한 추세성이 DNN2에서는 많이 제거됨을 알 수 있다. 하지만, 후보정을 통한 슬라이딩 창 방식의 심층신경망 모형은 미래의 관측값을 알 수 없어 과거 GloSea5 모의자료에만 적용가능하다.




Fig. 9. Comparison of obs, GloSea5, DNN1 and DNN2

Table 3. Comparison of RMSE by GloSea5, DNN1 and DNN2 - training days : 30days

p_days	model	RMSE		
		GloSea5	DNN1	DNN2
30	1	3.34	3.36	3.08
	2	3.01	3.48	3.32
60	1	3.01	3.34	2.97
	2	3.08	3.31	2.73
90	1	3.15	3.41	2.92
	2	3.07	3.29	2.72
120	1	3.34	3.57	3.21
	2	3.27	3.51	2.98

Table 4. Comparison of MAE by GloSea5, DNN1 and DNN2 - training days : 30days

p_days	model	MAE		
		GloSea5	DNN1	DNN2
30	1	2.48	2.49	2.30
	2	2.25	2.67	2.46
60	1	2.32	2.54	2.11
	2	2.40	2.59	2.08
90	1	2.48	2.54	2.21
	2	2.34	2.53	2.04
120	1	2.56	2.71	2.38
	2	2.49	2.74	2.23

5. 논의 및 결론

본 연구에서는 심층신경망 모형을 활용하여 양파의 효율적인 재배관리를 위한 중장기 농업기상 정보를 생산하는 방법을 제시한다. 기상청에서 운영 중인 GloSea5와 2016년에 농업기상관측소에서 관측된 일 평균기온을 훈련자료로 사용한 슬라이딩 창 방식의 심층신경망 모형이 사용되었다. 슬라이딩 창의 길이와 학습기간의 관계를 살펴본 결과 단기예측은 학습이 짧을수록 장기예측은 학습이 길수록 예측정확도가 높았다. 하지만 슬라이딩창 방식의 심층신경망은 계절변화에 따른 추세성도 훈련되는 문제점이 있었다. 후보정을 통한 심층신경망 모형을 통해 이러한 문제점을 해결하였다.

GloSea5의 수평해상도는 60km로 산지가 많은 한반도의 논과 밭의 농업기상 정보에 활용하는데 많은 어려움이 있다. 본 연구에서 제안한 심층신경망 모형은 농업기상 관측자료와 GloSea5의 학습을 통해 농업재배지의 중장기 농업기상 정보를 생산하는 방법을 다루고 있다. 하지만 대부분의 재배지에는 기상관측장비가 설치되어 있지 않아 연구에서 제안한 방법을 바로 적용시키는데 어려움이 있다. 따라서 기상청에서 운영하는 자동기상관측자료의 공간간격을 통한 재배지의 농업기상 정보 생산과 심층신경망 모형이 결합된다면 맞춤형 농업기상 정보를 생산하는데 도움이 될 것이다.

REFERENCES

- [1] G. V. Oldenborgh, F. Doblas-Reyes, B. Wouters & W. Hazeleger. (2012). Skill in the trend and internal variability in a multi-model decadal prediction ensemble. *Climate Dynamics*, 38(7), 1263-80.
- [2] 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.
- [3] K. H. Son, D. H. Bae & H. S. Cheong. (2015). Construction & Evaluation of GloSea5-Based Hydrological Drought Outlook System. *Atmosphere*, 25(2), 271-281.
- [4] 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.
- [5] 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.
- [6] Q. K. Tran & 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.
- [7] I. H. Ryu. (2006). *A Comparative Study of Time Series Forecasting By Artificial Neural Networks*. Master dissertation. Yonsei University, Seoul.
- [8] E. M. Yang, H. Jae. Lee & C. H. Seo. (2017). Comparison of Detection Performance of Intrusion Detection System Using Fuzzy and Artificial Neural Network. *Journal of Digital Convergence*, 15(6), 391-398.
- [9] H. S. Song. (2017). Comparison of Performance between MLP and RNN Model to Predict Purchase Timing for Repurchase Product. *Journal of information technology applications & management*, 24(1), 111-128.
- [10] J. S. Kim. (2013). *Long-Term Runoff Prediction Using Artificial Neural Network in the Bocheong-Cheon*. Master dissertation. Kyung Hee University, Seoul.
- [11] K. T. Bae. (2016) *Development of a Price Prediction Model of Agricultural Product using Artificial Neural Networks*. Master dissertation. Soongsil University, Seoul.
- [12] K. K. Seo. (2015). Sales Prediction of Electronic Appliances using a Convergence Model based on Artificial Neural Network and Genetic Algorithm. *Journal of Digital Convergence*, 13(9), 177-182.
- [13] Y. Cho & I. Kim. (2010). Predicting the Performance of Recommender Systems through Social Network Analysis and Artificial Neural Network. *Journal of Intelligence and Information Systems*, 16(4), 159-172.
- [14] M. Kim & C. Hong. (2016). The Artificial Neural Network based Electric Power Demand Forecast using a Season and Weather Informations. *Journal of The Institute of Electronics and Information Engineers*, 53(1), 71-78.
- [15] B. W. Chio. (2006). *Prediction of Swell Index of Clay Using the Artificial Neural Networks*. Master dissertation. Kyungpook National University, Daegu.
- [16] N. R. Jo. (2017). *Design and Implementation of criminal Identification System Based on Deep Learning*. Master dissertation, Gachon University, Gyeonggi.
- [17] S. Moon, S. Han, K. Choi & J. Song. (2016). Data processing system and spatial-temporal reproducibility

assessment of GloSea5 model. *Journal of Korea Water Resources Association*, 49(9), 761-771.

- [18] Y. Shin & S. Yoon. (2016). Electricity forecasting model using specific time zone. *Journal of the Korean Data and Information Science Society*, 27(2), 275-284.

양 미 연(Yang, Mi Yeon)

[학생회원]



- 2017년 2월 : 대구대학교 전산통계학과 (학사)
- 2017년 2월 ~ 현재 : 대구대학교 통계학과 (석사)
- 관심분야 : 통계, 인공지능
- E-Mail : aldus9706@naver.com

윤 상 후(Yoon, Sanghoo)

[정회원]



- 2011년 8월 : 전남대학교 통계학과 (박사)
- 2013년 12월 ~ 2014년 11월 : The University of Southampton 박사후연구원
- 2015년 2월 ~ 2016년 2월 : 차세대도시농림융합기상사업단 선임연구원
- 2016년 3월 : 대구대학교 조교수
- 관심분야 : 시공간모형, 기상환경, 빅데이터분석
- E-Mail : statstar@daegu.ac.kr