

MODIS와 기상자료 기반 회선신경망 알고리즘을 이용한 남한 전역 쌀 생산량 추정

Convolutional Neural Networks for Rice Yield Estimation Using MODIS and Weather Data: A Case Study for South Korea

마종원¹⁾ · 우엔콩효²⁾ · 이경도³⁾ · 허준⁴⁾

Ma, Jong Won · Nguyen, Cong Hieu · Lee, Kyungdo · Heo, Joon

Abstract

In South Korea, paddy rice has been consumed over the entire region and it is the main source of income for farmers, thus mathematical model for the estimation of rice yield is required for such decision-making processes in agriculture. The objectives of our study are to: (1) develop rice yield estimation model using Convolutional Neural Networks(CNN), (2) choose hyper-parameters for the model which show the best performance and (3) investigate whether CNN model can effectively predict the rice yield by the comparison with the model using Artificial Neural Networks(ANN). Weather and MODIS(The MODerate Resolution Imaging Spectroradiometer) products from April to September in year 2000~2013 were used for the rice yield estimation models and cross-validation was implemented for the accuracy assessment. The CNN and ANN models showed Root Mean Square Error(RMSE) of 36.10kg/10a, 48.61kg/10a based on rice points, respectively and 31.30kg/10a, 39.31kg/10a based on 'Si-Gun-Gu' districts, respectively. The CNN models outperformed ANN models and its possibility of application for the field of rice yield estimation in South Korea was proved.

Keywords: Remote Sensing, Weather Data, MODIS, Rice Yield Estimation, Convolutional Neural Network, Artificial Neural Network

초 록

쌀은 오랜 기간 동안 남한 지역의 주식임과 동시에 농부들의 주 수입원이며, 농업 분야 관련 정책 수립을 위한 수확적인 쌀 생산량 추정 모델의 구축이 필요하다. 본 연구의 목적은 (1) 쌀 생산량 추정을 위한 회선신경망 모델의 구축과, (2) 최고의 성능을 보이는 회선신경망의 파라미터를 결정하는 것과, (3) 인공신경망 모델과의 비교를 통해 회선신경망의 성능을 평가하는 것이다. 각 모델의 입력데이터로는 2000~2013년도의 4~9월까지의 해당하는 기상자료와 MODIS 위성자료를 사용하였으며, 정확도 평가를 위해 교차 검증을 실시하였다. 회선신경망과 인공신경망은 쌀 생산 표본점을 대상으로 각각 36.10kg/10a, 48.61kg/10a와 시군구 지역을 대상으로 각각 31.30kg/10a, 39.31kg/10a의 RMSE를 보였다. 회선신경망 모델은 인공신경망 모델보다 우수한 성능을 보였으며, 본 연구를 통해 쌀 생산량 추정 분야에 대한 회선신경망 모델의 적용 가능성을 확인할 수 있었다.

핵심어: 원격 탐사, 기상자료, MODIS, 쌀 생산량 추정, 회선신경망, 인공신경망

Received 2016. 09. 28, Revised 2016. 10. 11, Accepted 2016. 10. 23

1) Member, Dept. of Civil and Environmental Engineering, Yonsei University (E-mail: mjw1231@yonsei.ac.kr)

2) Dept. of Civil and Environmental Engineering, Yonsei University (E-mail: conghieu.ig@gmail.com)

3) National Institute of Agricultural Science, RDA (E-mail: kdlee1@korea.kr)

4) Corresponding Author, Member, Dept. of Civil and Environmental Engineering, Yonsei University (E-mail: jheo@yonsei.ac.kr)

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

1. 서론

쌀은 오랜 기간 동안 남한 지역의 주식임과 동시에 농부들의 주 수입원이며, 쌀 생산량 예측 및 조사는 농가 및 농민 단체 등 농업 분야 기관에 영향을 주고 결과적으로는 국가의 식량 자급화 능력 및 정부의 수출입 정책 수립에 영향을 준다. 따라서 곡물 생산량 추정을 위한 수학적 모델의 개발이 필요하며, 국내 통계청에서는 남한 전역을 대상으로 5,000~10,000 개의 쌀 표본점에 대해 8월 15일, 9월 15일에 각각 작황조사, 예상 생산량 조사와 최종 수확기에 조사하는 실 수확량 조사를 실시하고 있고, 해당 자료는 웹을 통해 제공하고 있다. 국내 외 여러 연구 기관에서는 이와 같은 통계청 자료를 이용하여 남한을 포함한 세계 각국의 지역을 대상으로 곡물 생산량 추정에 관한 연구를 다수 진행하고 있다.

선형 연구를 통해 기상자료 및 위성자료 기반 곡물 생산량 추정에 관한 사례를 확인할 수 있었다. 국외에서는 Nuarsa *et al.*(2011)이 곡물 생산량 예측을 위해 AVHRR(Advanced Very High Resolution Radiometer)으로부터 제공 받은 식생지수를 사용하였으며, 해당 연구 결과, 실측값과 예측값의 R-square는 0.9262, standard error는 0.21을 나타내었다. Fang *et al.*(2011)은 옥수수 생산량 추정을 위해 MODIS(Moderate Resolution Imaging Spectroradiometer)에서 제공하는 NDVI(Normalized Difference Vegetation Index), EVI(Enhanced Vegetation Index)와 LAI(Leaf Area Index) 자료를 사용하였으며, 여러 시나리오 중 세 가지 변수를 모두 적용하였을 때 통계 자료와의 상대 오차가 3.5% 미만의 가장 높은 성능을 보임을 확인하였다. 국내에서 진행된 연구를 살펴보면, Hong *et al.*(2012)은 국내의 벼 수량을 추정하기 위해 MODIS에서 제공하는 NDVI 자료와 기상자료(일조 시간 및 일사량)를 사용하였으며 2011년 쌀 수량 추정 결과, 예측값과 통계자료와는 14.1 kg 10a⁻¹의 차이를 보였다. 또한 Na *et al.*(2013)의 연구에선 국내 쌀 생산량을 추정하기 위해 MODIS 위성자료와 태양 복사량을 CASA 모형에 적용하였으며, 통계자료와는 9.46 kg/10a의 Root Mean Squared Error (RMSE) 값을 보였다.

쌀 생산량 추정 모델을 위해 선형 회귀(linear regression) 모델, 인공신경망(artificial neural network) 모델 등이 주로 사용 되는데, Uno *et al.*(2005)은 캐나다 지역을 대상으로 고분광 영상으로부터 추출한 식생지수를 인공신경망 및 단계적 다중 선형 회귀 모델에 적용하여 옥수수 생산량을 추정하였으며, 두 모델의 차이가 미세하다는 결론을 도출하여 곡물 생산량 추정을 위한 인공신경망 모델의 가능성을 보였

다. Li *et al.*(2007)은 미국 내 지역들을 대상으로 AVHRR 및 MODIS 위성으로부터 추출한 NDVI를 인공신경망 및 다중 선형 회귀(multiple linear regression) 모델에 적용하여 콩 및 옥수수 생산량 추정을 하였으며, 각각의 모델에 의한 RMSE는 7.71~19.06bushal/acre, 12.90~24.99bushal/acre로 인공신경망 모델이 더 우수한 성능을 보임을 확인하였다. 또한 Ji *et al.*(2007)은 중국의 후지안 지역의 쌀 생산량 추정을 위해 강수량, 일별 일사량, 온도, 풍속 등의 기상자료를 인공신경망 및 다중 회귀 분석 모델에 적용하였으며 R-squared와 RMSE는 각 모델에 대해 각각 0.87, 891과 0.52, 1977을 보여 인공신경망이 더 우수한 모델임을 입증하였다. 선형 연구를 통해 쌀 생산량 추정 모델로 인공신경망 모델이 선형 회귀 모델과 비슷하거나 더 우수한 성능을 보임을 확인할 수 있었다.

인공신경망 모델의 발전된 형태이며 딥 러닝(deep learning) 알고리즘인 회선신경망(convolutional neural network) 모델은 분류 및 추정을 목적으로 사용되는 알고리즘으로 주로 이미지가 입력데이터(input data)로 사용된다. 이 알고리즘은 최근 패턴 인식(pattern recognition), 컴퓨터 비전(computer vision) 등의 분야에서 뛰어난 성능을 보이며 많이 사용되고 있으며(Krizhevsky *et al.*, 2012; Karpathy *et al.*, 2014), Le Callet *et al.*(2006)의 연구에선 영상(video)의 질(quality)을 추정하기 위해 회선신경망 모델을 사용하고, 사람에 의해 평가된 값과 0.92의 높은 상관성을 보였다. 또한, Liu *et al.*(2015)은 단일 이미지(single image)로부터 깊이를 추정하는데 회선신경망 모델을 사용하여 실내 및 실외 데이터 모두에서 8.60의 %RMSE를 보였고, Kang *et al.*(2014)은 이미지의 질을 예측하는데 있어 회선신경망이 타 알고리즘에 비해 스피어맨 등위상관계수(spearman rank order correlation coefficient)와 선형상관계수(linear correlation coefficient) 값이 각각 0.920, 0.903으로 높은 성능을 보임을 확인하였다.

국내에서 남한 전역을 대상으로 쌀 생산량 추정에 관해 진행된 연구로는 위에서 이미 언급한 Hong *et al.*(2012)과 Na *et al.*(2013)의 연구가 존재한다. 먼저 Hong *et al.*(2012)은 쌀 생산 지역에 대해 특정 경계를 기준으로 구분하지 않고 전체 논 지역에 대한 평균값을 사용하여 행정 구역별 또는 보다 세분화된 지역에 대해서는 쌀 생산량 예측을 하지 못한다는 한계점을 갖는다. 또한, 이 두 연구에서는 다중회귀, 단순 회귀 모형을 통해 쌀 생산량 추정을 하였는데 해당 연구에서는 각각 두 개 또는 한 개의 입력변수만을 사용함에 따라 쌀 생산 지역에 태풍, 황사, 병충해 등의 환경요인이 발생할 경우 원격 영상의 질이 저하되어 변수에 영향을 끼치게 될 수 있고, 결과적

으로 추정 모형의 성능을 보장할 수 없다는 한계가 존재한다. 선행 연구를 통해, 회선신경망 모델이 현재 여러 분야에서 우수한 성능이 입증되는 가운데 곡물 및 쌀 생산량 추정을 위해 사용된 사례는 찾아볼 수 없었으며, 본 연구에서는 쌀 생산량 추정을 위해 인공신경망 및 회선신경망 모델을 구축하고, 2000~2013년도의 4~9월까지에 해당하는 총 9종류의 기상자료와 MODIS 위성자료를 사용하여 남한 전역에 대해 쌀 생산량 추정을 하고자 하며, 각 모델의 성능을 비교하여 회선신경망 모델의 적용 가능성을 평가하고자 한다.

2. 데이터 수집 및 전처리

2.1 연구 대상 지역

본 연구에서는 남한 지역을 연구 대상 지역으로 선정하였다. 남한 지역은 동아시아에 위치하고 북위 33~38도, 동경 126~131도에 걸쳐 있으며, 면적은 약 100,210 km^2 이다. 계절은 사계절이 뚜렷이 나타나 4월 초에서 5월에 걸쳐 봄, 6월경에서 9월 초에는 여름, 9월 말에서 10월 말까지는 가을, 11월에서 2월까지는 겨울 날씨가 이어진다. 연 평균기온은 10~15°C이며, 가장 무더운 달인 8월엔 23~26°C, 가장 추운 달인 1월엔 -6~3°C를 나타낸다. 행정적으로는 서울특별시, 1개의 특별시, 6개의 광역시, 8개의 도, 1개의 특별자치시, 1개의 특별자치도로 구성되며 본 연구에서는 남한 전역과 시군구를 대상으로 쌀 생산량 추정을 하고자 한다.

2.2 데이터 수집

본 연구에서는 쌀 생산량 추정을 위한 토지피복도와 쌀 추정 모형의 독립 변수로 사용할 기상자료, 위성자료 및 종속 변수로 사용할 생산량 통계 자료를 수집하였으며 이에 대한 자세한 설명은 아래와 같다.

2.2.1 토지 피복도 및 쌀 생산량 통계

토지 피복도는 환경부의 환경공간정보서비스 웹 사이트(<https://egis.me.go.kr>)에서 수집하였다. 본 연구에서 사용한 토지 피복도는 Landsat TM, IRS 1C, SPOT5, 아리랑 2호 위성영상을 통해 수집된 자료를 활용하여 제작되었으며 5m의 공간해상도, 1:25,000의 축척을 가지고 이는 남한 전역을 주거지역, 공업지역, 논, 밭 등 총 22개 항목으로 분류한다. 쌀 생산량 통계는 통계청 웹 사이트(kostat.go.kr)에서 제공하는 시군별 논벼 생산량 자료를 사용하였으며 이는 행정구역별 재배면적(ha), 생산량(ton) 및 10a당 생산량(kg) 정보를 포함한다.

2.2.2 기상자료

본 연구에서 수집한 기상자료는 Hong *et al.*(2012)과 Lee *et al.*(2013)의 연구에서 사용된 자료와 동일한 방법으로 생산되었다. 이는 기상청에서 제공하는 89개 지점의 관측소 및 599개 지점의 자동 기상관측 장치(automatic weather station)에서 관측된 2000~2013년의 일별 기상자료(최대, 최저 및 평균 온도, 강수량 및 일사량)이며, 이는 Cressman 기법을 적용함으로써 3km의 격자간격을 갖는다(Ahn *et al.*, 2010; Cressman, 1959).

2.2.3 위성자료

남한 전역 쌀 생산량 추정 모형의 독립 변수로 사용하기 위해 위성자료로는 MODIS 위성으로부터 취득 가능한 NDVI, EVI, LAI, FPAR의 총 네 개의 식생지수 영상을 수집하였다. 각 자료는 USGS MODIS 웹사이트(<https://mrtweb.cr.usgs.gov>)에서 취득 가능하다. 먼저 NDVI와 EVI는 MOD13A1 제품으로 1km의 공간해상도와 16일의 시간해상도를 갖고 있어 본 연구에선 벼의 생육단계를 고려한 4월부터 9월까지 매년 각 10개의 영상을 수집하였다. LAI와 FPAR는 MOD15A2 제품으로 1km의 공간해상도와 8일의 시간해상도를 가지며 매년 각 15개의 영상을 수집하였다.

2.3 데이터 전처리

쌀 생산량 추정 모형을 위한 데이터의 전처리 과정은 Fig. 3과 같다. 먼저 쌀 생산량 표본점을 추출하기 위해 폴리곤(polygon) 상태의 토지 피복도를 모두 집합(merge)시킨 이후 셰이프 파일(shapefile)을 래스터(raster) 형태로 변환시켰다. 이 때 각 셀(Cell)의 크기는 MODIS 영상과 동일한 1km로 지정하였으며 좌표계도 또한 WGS 1984 UTM zone 52N으로 변환하였다. 이후, 분류 코드가 210인 논 지역만을 추출하여 포인트(point) 형태로 변환함으로써 남한 전역에 대해 총 10,693개의 쌀 생산량 표본점 자료를 구축하였다. 앞에서 생산한 표본점에 대한 최대, 최저, 평균 온도 및 강수량, 일사량, NDVI, EVI, LAI, FPAR 값을 추출하기 위해 기상자료와 위성자료는 각 년도마다 4월부터 9월까지의 자료를 스택(stack)시켰다. 기상자료의 경우 5개의 변수는 15일 주기의 평균값을 사용하여 각각 12개의 값을 가지고, 위성자료의 경우 NDVI, EVI는 각각 10개, 마지막으로 LAI와 FPAR는 각각 15개의 값을 가진다. 이후, ArcGIS 프로그램의 Extract Multi Values to Points 도구를 이용하여 각 표본점에 해당하는 기상자료 및 위성자료 값을 모두 추출하였다.

쌀 생산량 통계자료는 행정 구역 경계 셰이프 파일에 결합(join)하여 각 지역마다 2000~2013년까지의 매년 쌀 생산량

을 추출하였고, 기상자료와 위성자료와 동일한 방법으로 쌀 생산 표본점에 대해 값을 추출하였다.

위의 과정이 모두 진행된 이후 쌀 생산량 추정 모델의 입력 변수로 사용하기 위해 기상자료와 위성자료 모두 -1과 1사이의 값을 가지도록 하는 정규화(normalization) 과정을 통해 데이터 전처리 과정을 마무리 하였다.

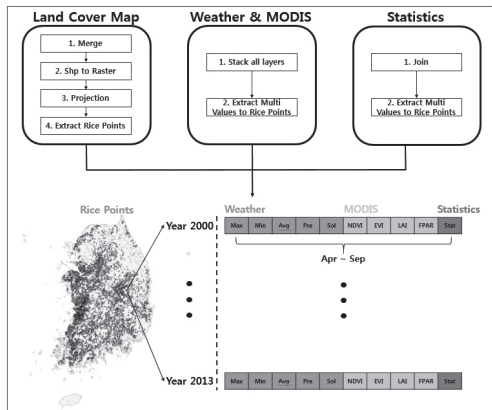


Fig. 1. Flowchart for data preprocessing

3. 쌀 생산량 추정 모델 및 정확도 평가 방법

3.1 인공신경망(Artificial Neural Network)

3.1.1 인공신경망 이론

인공신경망은 인간의 뇌에 있는 뉴런의 모습을 형상화하여 만든 인공 뉴런으로 구성되어 있으며 이는 인간이 행동을 하고

이에 대한 경험을 통해 학습해 나가는 과정을 토대로 개발된 알고리즘이다. 인공신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)의 삼층 구조를 이루며 입력층의 뉴런 수는 독립 변수 갯수와 같고 출력층의 뉴런 수는 종속 변수의 갯수와 같다. 데이터는 입력층부터 출력층까지 전달되며 각 층의 뉴런이 포함하는 값은 가중치와 선형결합 되고(Ravari *et al.*, 2016), 활성화함수를 통해 다음 층의 뉴런으로 이동하게 되는데 활성화함수로는 주로 시그모이드(sigmoid) 함수가 사용된다(Kaul *et al.*, 2005). 출력층까지 값이 전달되고 나선 전달된 값과 비교 대상 값과의 차이를 나타내는 오류 함수(error function)를 최소화하는 오차역전파(error back propagation) 학습 알고리즘이 적용되며 이 경우, 오류함수의 가중치 및 바이어스에 대한 기울기를 이용하여 각각의 값을 조절하게 된다.

3.1.2 인공신경망 모델 구조 선정

인공신경망 모델의 성능에 영향을 주는 파라미터(parameter)로는 대개 학습율(learning rate), 훈련허용치(training tolerance), 은닉층의 수, 은닉층의 뉴런 수 등이 존재한다(Kaul *et al.*, 2005). 이와 관련된 선행 연구를 보면, 한 개의 종속 변수를 사용하여 곡물 생산량 추정을 하는 경우, 한 개의 은닉층과 최소 4개부터 최대 8개의 은닉뉴런을 사용할 수 있었다(Kaul *et al.*, 2005; Jiang *et al.*, 2004; Ye *et al.*, 2006). 따라서 본 연구에서는 Table 1과 같이 연구를 진행하여 최적의 모델을 찾고자 하였다. 연구 결과, 인공신경망 구조는 두 개의 은닉층과 각각 5, 11개의 은닉뉴런을 포함하며, 500번을 반복하여 학습시킨 경우 가장 높은 성능을 보였으며, 해당 모델은 Fig. 2로 표현하였다.

Table 1. Parameter optimization for searching optimal ANN model

| Parameters for SCG Algorithm | Values | # of Neurons in Input Layer | # of Neurons in Output Layer | # of Hidden Layers | # of Neurons in Hidden Layer 1 | # of Neurons in Hidden Layer 2 | # of Epochs | | |
|--|-----------|-----------------------------|------------------------------|--------------------|--------------------------------|--------------------------------|-------------|----|------|
| Performance goal | 0 | 110 | 1 | 1 | 5 | | 500 | | |
| Minimum performance gradient | 0.000001 | | | | 7 | | 1000 | | |
| | | | | | 9 | | 1500 | | |
| | | | | | 11 | | | | |
| | | | | | 13 | | | | |
| Maximum validation failures | 6 | | | 15 | | | | | |
| Determine change in weight for second derivative approximation | 0.00005 | | | 110 | 1 | 2 | 5 | 5 | 500 |
| | | | | | | | 7 | 7 | 1000 |
| | | | | | | | 9 | 9 | |
| | | | | | | | 11 | 11 | |
| 13 | 13 | | | | | | | | |
| Parameter for regulating the indefiniteness of the Hessian | 0.0000005 | 15 | 15 | | | 1500 | | | |

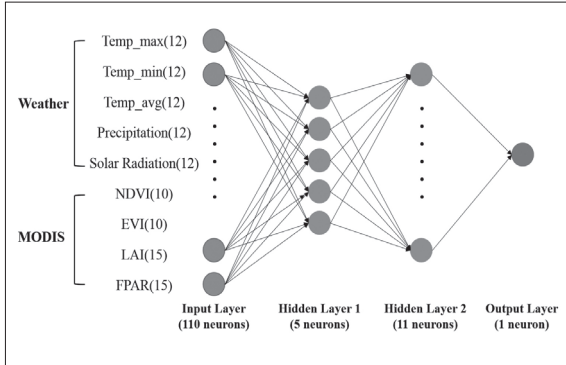


Fig. 2. Optimal ANN model

3.2 회선신경망(Convolutional Neural Network)

3.2.1 회선신경망 이론

회선신경망은 인공신경망을 발전시킨 형태의 모델이며 이는 영상 인식, 음성 인식 등의 분야에서 분류 및 예측에 널리 사용되고 있다(Sainath *et al.*, 2013; Abdel-Hamid *et al.*, 2014). 회선신경망은 입력층, 은닉층, 출력층이 완전히 연결되어 있는(fully-connected) 인공신경망과는 달리 회선층(convolution layer), 서브 샘플링층(subsampling layer)을 혼합한 구조의 연속으로 이루어져 있다. 회선신경망 모델은 입력데이터의 변화(shift) 또는 약간의 왜곡(distortion) 현상에 어느 정도 불변성을 확보하기 위한 ‘(1)Local receptive fields, (2)Shared weights. (3)Subsampling’의 세 가지 구조적 방안을 포함한다(LeCun and Bengio, 1995).

3.2.2 회선신경망 모델 구조 선정

회선신경망 모델은 LeCun *et al.*(1998)이 개발한 LeNet 모델을 사용하였으며 이는 회선층과 서브 샘플링층의 구조가 연속으로 존재하고 마지막엔 한 개의 완전 연결층(fully connected layer)을 갖는 구조로 이루어져 있다. 회선층에선 특정 사이즈의 필터(filter)가 이미지를 순회하면서 회선(convolution)한 이후 탄젠트(tangent) 비선형 함수를 통해 값을 출력하는 과정을 통해 다음 이미지를 생성하고 서브 샘플링층에서는 2x2의 필터가 순회하면서 각 필터의 최댓값을 추출해 내고 이는 완전 연결층을 통해 마지막의 출력층과 연결된다. 본 모델에서는 훈련 알고리즘으로 스토캐스틱 경사 하강(stochastic gradient descent) 방법을 사용하며, 이는 전체 훈련 샘플(sample) 중 미니 배치(mini-batch) 수를 지정하여 그만큼의 양을 동시에 학습시키는 방법이다.

회선신경망 알고리즘은 기본적으로 x (수평)과 y (수직)마

다 픽셀(pixel)값을 갖는 2D 맵 형태의 입력데이터를 필요로 한다. 하지만 본 연구에서 사용된 기상자료와 위성자료는 각각 동일한 시간간격으로 측정된 시계열(time-series) 벡터(vector) 자료이며, Abdel-Hamid *et al.*(2014)에서 사용한 방법과 같이 각각의 자료를 행순으로 나열하여 2D 맵 형태로 제작하였다. 2D 맵을 작성하기 위해 보유하고 있는 자료 중 가장 큰 비율을 차지하고 있는 기상자료를 기반으로 NDVI와 EVI의 행을 LAI와 FPAR로 확장시키고, LAI와 FPAR 각각 1개의 자료를 제거하여 9행 12열 형태의 2D 맵을 제작하였다. 이는 Fig. 3과 같이 표현할 수 있으며 이를 통해 쌀 생산량 추정 분야에 대한 회선신경망 모델의 적용 가능성을 확인해보고자 한다.

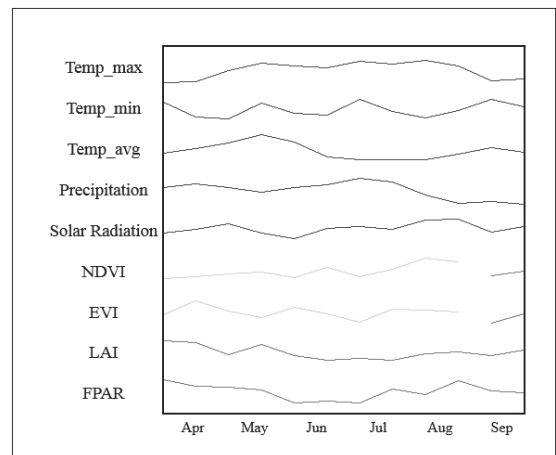


Fig. 3. 2D feature map of Weather and MODIS data for April to September

회선신경망 모델을 구현하기에 앞서 파라미터 값을 지정해 주어야 하는데, 파라미터의 종류로는 회선층과 서브 샘플링층의 피쳐 맵 크기 및 수와 학습율, 반복 횟수, 완전 연결층의 뉴런 수, 배치 크기가 존재한다. 본 연구에서 사용될 입력데이터의 크기는 9행 12열이며, 이는 타 연구에서 사용되는 이미지와는 달리 크기가 작아 회선층에서 사용될 필터의 크기를 지정하는 데 제한이 있었다. 따라서 각 회선층과 서브 샘플링층에서는 2x2의 필터를 사용하였으며, 두 번째 서브 샘플링층은 사용하지 않고 바로 완전 연결층으로 연결시키는 구조를 사용하였다. 나머지의 파라미터는 Table 2와 같이 설정하여 최적의 모델을 탐색해 보았다. 실험 결과 최적의 파라미터 조합은 Table 3과 같았으며, 최종적으로 본 연구에서 구축한 회선신경망 모델은 Fig. 4와 같다.

Table 2. Parameter optimization for searching optimal CNN model

| # of Feature maps | Learning rate | # of Epochs | # of Neurons in Fully Connected Layer | Batch Size |
|-------------------|---------------|-------------|---------------------------------------|------------|
| 5 | 0.001 | 30 | 10 | 200 |
| 10 | 0.0001 | 60 | 30 | 600 |
| 15 | 0.00001 | 90 | 50 | 1000 |

Table 3. The optimal parameters

| # of Feature maps | Learning rate | # of Epochs | # of Neurons in Fully Connected Layer | Batch Size |
|-------------------|---------------|-------------|---------------------------------------|------------|
| 15 | 0.001 | 30 | 10 | 1000 |




Fig. 4. Optimal CNN model

3.3 정확도 평가

본 연구에서는 쌀 생산량 추정 모델의 정확도를 평가하기 위한 통계적 방법으로 RMSE(Root Mean SRMSE), %RMSE, MAE(Mean Absolute Error) 및 MAPE(Mean Absolute Percentage Error)를 구하였으며 이는 Eq. (1)와 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{r}_i - r_i)^2}$$

$$\%RMSE = \frac{RMSE}{\bar{r}} \times 100\%$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{r}_i - r_i|$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{r_i - \hat{r}_i}{r_i} \right|$$

(1)

where \hat{r}_i : Estimated rice yield for i th rice point, r_i : Rice yield statistics, \bar{r} : Mean value for yield statistics of rice points in target area, n : The number of samples

수집한 데이터는 2000~2013년도까지 총 14개 년도에 해당하며 이중 한 개 년도를 검증 데이터로, 나머지 13개 년도는 학습 데이터로 사용하여 모델의 정확도를 평가하기 위해 모델을 총 14번 구동하는 교차 검증을 실시하였다.

4. 결과 분석

본 연구에서는 남한 전역 쌀 생산량 추정을 위해 인공지능망 알고리즘과 회선신경망 알고리즘의 성능을 비교하고 회선신경망의 적용 가능성을 평가하고자 한다. 정확도 평가는 두 가지의 경우로 나누어 진행하였으며, 먼저 전체 10,693개의 쌀

생산 표본점에 대한 정확도와, 시군구 행정구역에 대한 정확도를 평가하였으며, 정확도 평가에 사용된 인공신경망과 회선신경망의 모델 구조는 각각 Figs. 2 and 4와 같다.

4.1 쌀 생산 표본점에 대한 정확도 평가

인공신경망과 회선신경망 모델의 쌀 생산 표본점에 대한 정확도를 비교하였으며 이는 Table 4에 정리하였다. 전체년도의 평균 %RMSE, RMSE, MAPE, MAE는 각각 9.88%, 48.61kg/10a, 8.02%, 39.40kg/10a와 7.38%, 36.10kg/10a, 6.02%, 28.72kg/10a로 회선신경망이 %RMSE의 경우 약 2.50% 더 좋은 성능을 보임을 확인할 수 있었다. 인공신경망과 회선신경망 모델은 각각 2005년도 쌀 생산량 추정에서 MAPE가 5.38%와 4.23%로 가장 높은 성능을 보였다. 회선신경망이 인공신경망 모델에 비해 전반적으로 우세한 성능을 보였으나, 2003년의 경우 인공신경망이 더 근사하게 추정하였음을 확인할 수 있었다. 회선신경망 모델의 경우, 2003년도만 %RMSE와 MAPE가 각각 12.92%, 11.45%로 타 년도에 비해 높은 값을 보였는데, 이는 해당 년도에 발생한 태풍 ‘매미’에 의한 것으로 추정된다. 태풍 ‘매미’는 9월 6일에 발생해

9월 14일에 소멸한 중형급 태풍으로 농경지가 약 3만 7986ha가 침수되었으며 전국 14개 시도와 156개의 시군구가 특별재해지역으로 선포되어, 이로 인해 해당 년도 쌀 생산에 영향을 준 것으로 판단된다.

4.2 시군구에 대한 정확도 평가

다음으로, 쌀 생산 표본점에 이어 시군구 행정구역에 대한 정확도를 평가하였다. 모든 시군구 지역에 대한 전체년도의 평균 정확도를 계산하였으며, 이는 Figs. 5 and 6로 나타내었다.

시군구 지역에 대한 전체년도의 평균 %RMSE 및 RMSE는 인공신경망과 회선신경망 각각 8.31%, 39.31kg/10a와 6.84%, 31.30kg/10a로 회선신경망이 약 1.47% 더 낮았으며, 전체 14개년도 중 2002, 2003, 2009년도를 제외한 나머지 년도에서 모두 회선신경망이 인공신경망보다 더 좋은 성능을 보임을 확인할 수 있었다. 인공신경망은 2006년도, 회선신경망은 2005년도에 각각 %RMSE가 5.96%, 4.18%로 가장 높은 성능을 보였으며, Figs. 5 and 6을 보면 회선신경망이 인공신경망보다 %RMSE가 0~7%인 지역이 확연히 더 많이 있음을 확인할 수 있다.

Table 4. Accuracy comparison of ANN and CNN models for rice points

| Year | Artificial Neural Network | | | | Convolutional Neural Network | | | |
|---------|---------------------------|---------------|---------|--------------|------------------------------|---------------|---------|--------------|
| | %RMSE | RMSE (kg/10a) | MAPE(%) | MAE (kg/10a) | %RMSE | RMSE (kg/10a) | MAPE(%) | MAE (kg/10a) |
| 2000 | 11.80 | 59.10 | 9.49 | 48.08 | 7.79 | 39.04 | 6.11 | 31.46 |
| 2001 | 10.93 | 56.79 | 9.17 | 46.70 | 5.50 | 28.55 | 4.66 | 24.21 |
| 2002 | 8.38 | 39.68 | 6.96 | 32.12 | 8.02 | 37.95 | 6.28 | 27.74 |
| 2003 | 10.79 | 47.29 | 8.76 | 38.17 | 12.92 | 56.60 | 11.45 | 47.44 |
| 2004 | 8.26 | 41.67 | 6.43 | 32.87 | 5.83 | 29.43 | 4.71 | 23.83 |
| 2005 | 6.67 | 32.74 | 5.38 | 25.95 | 5.54 | 27.19 | 4.23 | 21.00 |
| 2006 | 7.65 | 37.61 | 5.68 | 28.57 | 6.70 | 32.93 | 5.30 | 26.42 |
| 2007 | 13.92 | 65.01 | 11.92 | 54.16 | 7.20 | 33.61 | 5.93 | 26.58 |
| 2008 | 8.09 | 42.15 | 6.54 | 34.49 | 5.85 | 30.49 | 4.74 | 24.24 |
| 2009 | 7.85 | 42.14 | 6.39 | 34.39 | 7.32 | 39.27 | 6.37 | 33.16 |
| 2010 | 13.67 | 66.35 | 10.66 | 52.40 | 7.03 | 34.13 | 5.77 | 27.36 |
| 2011 | 9.17 | 45.64 | 7.27 | 36.68 | 7.30 | 36.31 | 6.01 | 29.97 |
| 2012 | 10.56 | 50.37 | 8.86 | 41.22 | 9.12 | 43.51 | 7.11 | 31.17 |
| 2013 | 10.60 | 54.05 | 8.75 | 45.78 | 7.15 | 36.45 | 5.68 | 27.57 |
| Average | 9.88 | 48.61 | 8.02 | 39.40 | 7.38 | 36.10 | 6.02 | 28.72 |

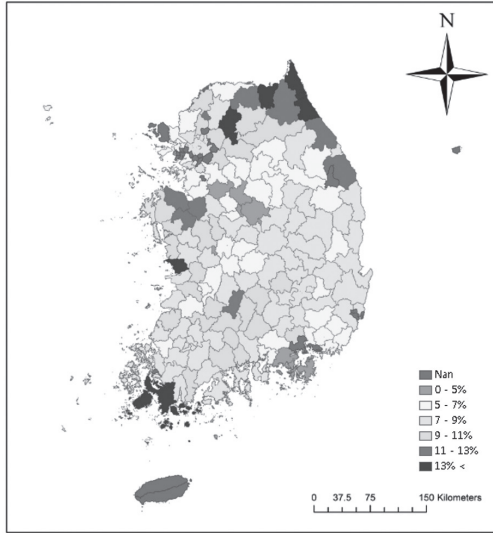


Fig. 5. ANN Accuracy(%RMSE) based on Si-Gun-Gu area

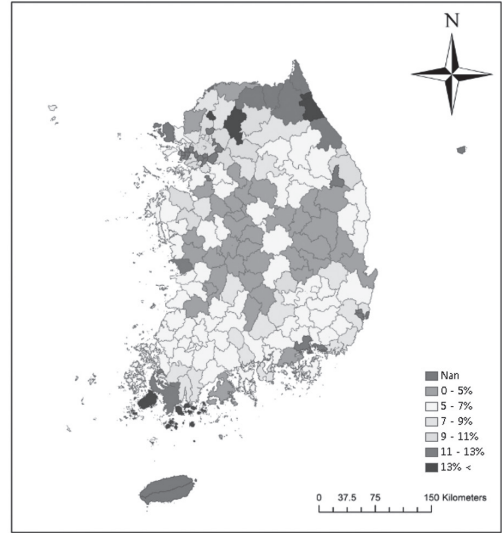


Fig. 6. CNN Accuracy(%RMSE) based on Si-Gun-Gu area

5. 결론

본 연구에서는 최대, 최소 및 평균 온도, 강수량, 일사량의 기상자료와 MODIS 위성으로부터 제작된 NDVI, EVI, LAI 및 FPAR 자료를 활용하여 남한 전역의 쌀 생산량 추정을 위한 인공신경망과 회선신경망의 성능 비교 및 회선신경망의 적용 가능성을 평가하는 것을 목적으로 하였다. 정확도 평가는 전체 10,693개의 쌀 생산 표본점과 시군구 행정구역에 대상으로 수행하였다.

인공신경망은 다양한 파라미터 조합을 실험한 결과 두 개의 은닉층과 각각 5개와 11개의 은닉뉴런으로 구성된 구조에서 전체년도 평균 %RMSE 및 RMSE가 각각 9.88%와 48.61kg/10a 로 가장 높은 성능을 보였다. 회선신경망의 경우 입력데이터로 사용될 2D 맵을 제작하기 위해 시계열 벡터 자료인 기상자료와 위성자료를 각각 행순으로 나열하였으며, 9 행 12열 형태의 2D 맵을 제작하여 쌀 생산량 추정 분야에 대한 회선신경망 모델의 적용 가능성을 확인해보았다. 회선신경망 모델은 기본적으로 LeNet구조를 사용하였으며, 다양한 파라미터 조합을 실험하여 2x2의 필터를 사용하는 두 개의 회선층과 한 개의 서브 샘플링층 및 10개의 뉴런을 갖는 완전 연결층으로 구성된 구조의 경우, 전체년도 평균 %RMSE 및 RMSE가 각각 7.38%와 36.10kg/10a로 가장 높은 성능을 보임을 확인하였다.

먼저, 쌀 생산 표본점과 시군구 지역을 대상으로 한 정확

도 비교 결과 회선신경망이 인공신경망보다 전체년도의 평균 %RMSE가 각각 2.50%, 1.47% 만큼 낮은 수치를 보여 더 우수한 성능을 보임을 확인할 수 있었다. 회선신경망이 이와 같이 인공신경망보다 높은 성능을 보이는 이유는, 입력데이터를 그대로 은닉층에 전달하여 쌀 생산량을 추정하는 인공신경망 모델과는 달리 회선신경망은 입력데이터에 대해 회선 및 풀링(Pooling)의 과정을 통해 이미지 상 변수들 간의 공간적 상관성을 고려하고, 쌀 생산량 예측에 영향력을 가지는 특징을 추출한 다음 이를 완전 연결층에 전달함으로 인해(LeCun and Bengio 1995; LeCun *et al.*, 1998) 인공신경망보다 더 높은 성능을 보인 것으로 판단된다. 결과적으로 본 연구에서는, 인공신경망과 회선신경망의 성능 비교를 통해 회선신경망 모델이 쌀 생산량 추정 분야에 충분히 활용될 수 있음을 확인할 수 있었다.

본 연구에서는 매년 4월부터 9월까지의 기간에 해당하는 총 9종류의 기상자료와 위성자료를 추정 모델의 입력데이터로 사용하였으나, 벼의 생육기간을 고려한 다양한 기간 및 변수의 조합에 따른 모델의 성능을 평가할 필요성이 있고, 쌀 생산 지역을 시군구 지역과 더불어 농업기후지역을 기준으로 세분화하여 정확도를 평가할 필요가 있다. 회선신경망의 경우, 9 행 12열 형태의 2D 맵을 입력데이터로 사용하였는데, 크기를 수정하고 기상자료와 위성자료를 분리하여 두 개의 피쳐 맵을 사용하거나 입력데이터에 대한 회선 방법을 달리하는 등의 실험을 통해 정확도 향상이 가능할 것으로 판단된다. 또

한, 회선신경망 이외의 SSAE(Stacked Sparse Auto Encoder), RBM(Restricted Boltzmann Machine) 등 타 신경망 기반 알고리즘의 쌀 생산량 추정 분야에 대한 적용 가능성 평가 연구가 향후 요구된다.

감사의 글

본 논문은 농촌진흥청 연구사업(세부과제번호: PJ009978)의 지원에 의해 이루어진 것임

References

- Abdel-Hamid, O., Mohamed, A. R., Jiang, H., Deng, L., Penn, G., and Yu, D. (2014), Convolutional neural networks for speech recognition, *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, Vol. 22, No. 10, pp. 1533-1545.
- Ahn, J., Hur, J., and Shim, K. (2010), A simulation of agro-climate index over the Korean peninsula using dynamical downscaling with a numerical weather prediction model, *Korean Journal of Agricultural and Forest Meteorology*, Vol. 12, No. 1, pp. 1-10. (in Korean with English abstract)
- Cressman, G. P. (1959), An operational objective analysis system, *Mon. Wea. Rev.*, Vol. 87, No. 10, pp. 367-374.
- Fang, H., Liang, S., and Hoogenboom, G. (2011), Integration of MODIS LAI and vegetation index products with the CSM-CERES-Maize model for corn yield estimation, *International Journal of Remote Sensing*, Vol. 32, No. 4, pp. 1039-1065.
- Hong, S. Y., Hur, J., Ahn, J. B., Lee, J. M., Min, B. K., Lee, C. K., and Shim, K. M. (2012), Estimating rice yield using MODIS NDVI and meteorological data in Korea, *Korean Journal of Remote Sensing*, Vol. 28, No. 5, pp. 509-520. (in Korean with English abstract)
- Ji, B., Sun, Y., Yang, S., and Wan, J. (2007), Artificial neural networks for rice yield prediction in mountainous regions, *The Journal of Agricultural Science*, Vol. 145, No. 3, pp. 249-261.
- Jiang, D., Yang, X., Clinton, N., and Wang, N. (2004), An artificial neural network model for estimating crop yields using remotely sensed information, *International Journal of Remote Sensing*, Vol. 25, No. 9, pp. 1723-1732.
- Kang, L., Ye, P., Li, Y., and Doermann, D. (2014), Convolutional neural networks for no-reference image quality assessment, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1733-1740.
- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., and Fei-Fei, L. (2014), Large-scale video classification with convolutional neural networks, *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pp. 1725-1732.
- Kaul, M., Hill, R. L., and Walthall, C. (2005), Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems*, Vol. 85, No. 1, pp. 1-18.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012), Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, Vol. 25, pp. 1106-1114.
- Le Callet, P., Viard-Gaudin, C., and Barba, D. (2006), A convolutional neural network approach for objective video quality assessment, *IEEE Transactions on Neural Networks*, Vol. 17, No. 5, pp. 1316-1327.
- LeCun, Y. and Bengio, Y. (1995), *Convolutional networks for images, speech, and time series: The handbook of brain theory and neural networks*, pp. 276-279.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998), Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278-2324.
- Lee, K., Hong, S., Hur, J., Kim, Y., Ahn, J., Na, S., and Jang, S. (2013), Can satellite information estimate rice yield variability in Korea?, *Agro-Geoinformatics (Agro-Geoinformatics), 2013 Second International Conference*, IEEE, 12-16 August, Fairfax, VA, USA, pp. 429-432.
- Li, A., Liang, S., Wang, A., and Qin, J. (2007), Estimating crop yield from multi-temporal satellite data using multivariate regression and neural network techniques, *Photogrammetric Engineering & Remote Sensing*, Vol. 73, No. 10, pp. 1149-1157.
- Liu, F., Shen, C., and Lin, G. (2015), Deep convolutional neural fields for depth estimation from a single image, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5162-5170.

- Na, S. I., Hong, S. Y., Kim, Y. H., Lee, K. D., and Jang, S. Y. (2013), Prediction of Rice Yield in Korea using Paddy Rice NPP index-Application of MODIS data and CASA Model, *Korean Journal of Remote Sensing*, Vol. 29, No. 5, pp. 461-476. (in Korean with English abstract)
- Nuarsa, I. W., Nishio, F., and Hongo, C. (2011), Rice yield estimation using Landsat ETM+ data and field observation, *Journal of Agricultural Science*, Vol. 4, No. 3, pp. 45-56.
- Ravari, S. Z., Dehghani, H., and Naghavi, H. (2016), Assessment of salinity indices to identify Iranian wheat varieties using an artificial neural network, *Annals of Applied Biology*, Vol. 168, No. 2, pp. 185-194.
- Sainath, T. N., Mohamed, A. R., Kingsbury, B., and Ramabhadran, B. (2013), Deep convolutional neural networks for LVCSR, *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, IEEE, 26-31 May, Vancouver, Canada, pp. 8614-8618.
- Uno, Y., Prasher, S. O., Lacroix, R., Goel, P. K., Karimi, Y., Viau, A., and Patel, R. M. (2005), Artificial neural networks to predict corn yield from compact airborne spectrographic imager data, *Computers and Electronics in Agriculture*, Vol. 47, No. 2, pp. 149-161.
- Ye, X., Sakai, K., Garciano, L. O., Asada, S. I., and Sasao, A. (2006), Estimation of citrus yield from airborne hyperspectral images using a neural network model, *Ecological modelling*, Vol. 198, No. 3, pp. 426-432.