

합성곱신경망을 이용한 초분광영상기반 토양수분 예측

전남열*, 이봉규**†

Soil Moisture Prediction Based on Hyperspectral Image using CNN(Convolution Neural Network)

Nam-Youl Jeon*, Bong-Kyu Lee**†

요 약

식물의 생육은 수분에 의해서 크게 좌우되기 때문에 토양이 재배하는 식물에 최적의 수분을 가지도록 조절하는 것은 중요하다. 최근 초분광영상을 통하여 식물의 생육정보를 자동으로 분석하는 연구가 진행되고 있으며 토양의 수분함량을 측정하는 것도 포함한다. 그러나 초분광의 경우 많은 분광밴드에서 나타나는 방대한 데이터로 인하여 분석과정이 복잡하기 때문에 사용이 어렵다. 본 논문에서는 초분광영상의 복잡도를 합성곱신경망(Convolution Neural Network, CNN)을 통하여 해결하는 방법을 제안한다. 제안한 방법은 대상 초분광의 전체 대역을 심층학습방법을 사용하여 자동 분석하기 때문에 각 영상에 대해 인식에 필요한 특정 대역을 찾는 노력을 할 필요가 없다. 제안 시스템의 유효성을 보이기 위해서 토양에서 얻은 초분광영상을 이용한 수분함량분석 실험을 수행하고 결과를 보인다.

Abstract

Since plant growth is greatly influenced by moisture, it is important to control the soil to have optimal moisture for the plant being grown. Recently, researches on automatically analyzing plant growth information including soil moisture using spectral images are being conducted. However, hyperspectral images are difficult to use due to huge amount of data appearing in spectral bands. In this paper, we propose a method to solve the complexity of hyperspectral images using a CNN. Since the proposed method automatically analyzes the entire band of the target hyperspectral using deep learning, there is no need to make an effort to find a specific band for analysis of each image. In order to show the effectiveness of the proposed system, we conduct an experiment to analyze moistures using hyperspectral images obtained from soil.

한글키워드 : 토양수분, 식물생육, 초분광영상, 분광밴드, 합성곱신경망

keywords : Soil moisture, Plant growth, Hyperspectral image, Spectral band, CNN

1. 서 론

* 제주대학교 전산통계학과

** 제주대학교 전산통계학과

† 교신저자: 이봉규(bklee@jejunu.ac.kr)

접수일자: 2021.08.09. 심사완료: 2021.09.24.

게재확정: 2021.12.20.

식물은 몸체의 75%이상이 수분으로 구성되며, 대사에 필요한 대부분의 것을 물을 통하여 이동시키기 때문에 재배 식물에서 나타나는 대부분의 영

양장에는 수분에 의해서 좌우된다. 따라서 재배하는 식물을 위한 토양의 최적 수분을 유지하는 것은 식물의 성장에 필수적이다. 기존에는 토양에 수분함량을 측정하는 장비를 통하여 직접 측정하는 방식을 사용하였다. 그러나 큰 면적에 대한 수분량 분석을 위해서는 많은 수의 측정 장치를 필요로 하기 때문에 매우 많은 비용이 소요된다. 더욱이 측정 장비를 설치하기 어려운 곳은 분석 시도가 불가능해진다. 이러한 문제점들을 해결하기 위한 방법으로 최근 초분광영상 (Hyperspectral Image)을 이용하는 방법이 최근에 연구되고 있다[1].

초분광영상은 400nm부터 1,000nm 파장영역을 수백 개로 나눈 분광밴드(spectral band)별 2차원적인 영상정보를 하이퍼큐브(Hypercube)형태로 구성한다. 초분광영상은 원격탐사 (Remote sensing)가 본격적으로 시행되는 1960년대가 시작되면서 사용되기 시작했으며, 초기에는 주로 4개에서 7개 정도의 분광밴드를 가진 다분광 센서를 이용하였다[2]. 기술의 발전으로 점차 분광밴드수가 충분히 확보됨에 따라서 환경, 국방, 헬스케어, 식품, 농업 등으로 점차 그 영역을 넓혀가고 있다. 이러한 초분광영상의 활용은 농업분야에서도 활발히 진행되고 있다. 초분광영상을 이용하여 식물의 생육상태 분석, 수분분석, 병충해 탐지를 대상을 파괴하지 않는 방법으로 할 수 있는 장점 때문에 농업분야에서 효과적으로 사용이 가능하다[3]. 그러나 초분광영상은 구성되는 영상의 복잡도로 인하여 실제 사용에 많은 제약이 따른다. 초분광영상은 기존의 RGB영상과는 달리 100개 이상의 분광밴드로 구성되어 방대한 정보를 내재하고 있기 때문에 기존 RGB영상에서 적용되는 분석기법이나 기존의 기계학습 방법으로는 효율적인 분석이 어렵다.

이러한 문제를 해결하기 위해 초분광영상의 복잡도 자체를 줄이는 연구가 진행되었으며 대표적인 사례가 주성분분석 (Principal Component

Analysis, PCA)을 이용하는 연구이다. 주성분분석은 초분광영상을 독립적인 개별 성분들로 재구성할 수 있기 때문에 초분광영상의 분광 차원을 축소하여 효율적인 분석을 가능토록 한다[4]. 그러나 주성분분석의 경우 학습이나 분석에 필요한 최적의 분광밴드 수를 정하는 것이 어렵기 때문에 사용에 한계를 가진다. 따라서 초분광영상의 활용도를 높이기 위해서는 새로운 해결책이 연구되어야 한다.

본 논문에서는 초분광영상의 사용에 문제점인 분광밴드의 복잡도 문제를 해결하기 위한 방법의 일환으로 합성곱신경망 (Convolution Neural Network) 기반 방법을 제안한다. 제안한 방법은 초분광영상의 분광밴드들이 가지는 정보를 심층 학습을 통하여 분석한다. 제안한 방법의 유효성을 검증하기 위하여 토양에서 얻은 초분광영상 Dataset[5]을 이용한 수분 분석을 수행하고 결과를 분석한다.

2. 합성곱신경망과 초분광영상 분석

영상패턴 분류를 위한 기존의 인공신경망은 주어진 영상으로부터 분류에 필요한 특징을 사람이 수작업으로 데이터 전처리 및 가공을 통해 미리 정한 후, 정해진 특징을 신경망을 학습하는데 이용한다. 따라서 학습할 데이터의 범주가 많고 양이 방대할 경우, 기존의 인공신경망을 학습하는데 필요한 특징을 선정하는 것이 어렵다. 이런 문제점을 해결하기 위해 그림 1에 보인 것과 같이 합성곱신경망은 특징추출과 인식을 통합하여 처리하는 형태를 가진 새로운 신경망이다. 합성곱신경망은 분석하려는 원 영상을 그대로 입력층에서 사용할 수 있기 때문에 별도의 특징추출 과정이 필요 없다[6].

합성곱신경망의 구조는 내부특징추출을 목적

으로 하는 다수의 합성곱 층과, 합성곱 층으로부터 추출한 특징을 인식하는 1개의 인식 층 (3층 구조의 다층신경망)로 그림 2와 같이 구성된다. 개개의 합성곱 층은 입력 영상에 대한 특징추출을 위한 필터연산을 수행하는 단층 신경망과 필터연산 결과의 크기를 재조정(Subsampling)하는 단층 신경망으로 구성된다. 1개의 인식 층은 완전연결 층(Full connection) 구조를 가지는 다층 신경망의 구조를 가진다. 입력된 영상은 복수의 합성곱 층에 의해서 다양한 형태의 특징으로 변환되며 최종 변환과정을 거친 특징은 완전연결 인식 층에 전달되어 인식에 사용된다.

합성곱신경망에서의 학습은 기존의 신경망에서 사용하는 오류역전과 알고리즘이 사용된다. 그렇지만 합성곱신경망에서 사용하는 오류역전과 학습은 기존의 신경망들과는 차이가 있다. 기존의 인공신경망에서는 초기 가중치 설정에 대한 명확한 근거가 없었기 때문에 효율적인 학습이 어렵다. 이에 비하여 합성곱신경망은 최적화(Optimization) 알고리즘을 사용하여 최적의 초기 가중치를 설정할 수 있는 장점이 있다[6].

합성곱신경망은 고수준의 공간분광 특징을 추출할 수가 있어 초분광영상 분석에 효과적으로 적용되고 있다. [7]에서는 합성곱신경망을 이용하여 초분광영상의 분광 응답 함수(spectral response function)를 학습함으로써 우수한 분류 성능을 보였다. 또한 초분광영상의 한 픽셀과 주변 픽셀을 포함하는 패치(patch)를 사용하여 효율적이고 높은 정확도의 분류 결과를 보인 연구 결과가 있다[8]. [9]에서는 3차원 커널(3D kernel) 기반의 3D-CNN을 초분광영상의 3차원 데이터 큐브(data cube)에 적용하여 공간-분광 특징을 효과적으로 분석하였다. [10]에서는 주성분 분석을 사용하여 초분광영상의 차원을 축소함으로써 심층신경망의 학습을 효과적으로 하는 방법을 제시하였다. 이러한 기존 연구들은 합성곱신경망을 통하여 많은 양의 데이터들을 효과적으로 처리함과 동시에 깊은 층을 통한 추상화된 내부 표현을 사용하면 초분광영상을 효과적으로 처리할 수 있음을 보여준다. 이런 다양한 연구결과로 인하여 심층신경망을 이용한 초분광영상에 대한 연구는 더욱 활발해지고 있다.

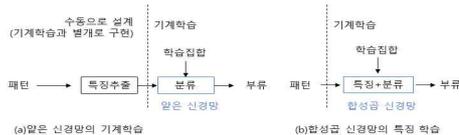


그림 1. 합성곱신경망과 기본신경망
Fig. 1. CNN and Traditional NN

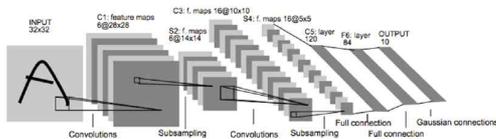


그림 2. 합성곱신경망 구조
Fig. 2. The architecture of CNN

3. 초분광영상 분석을 위한 합성곱신경망

그림 3에서 본 논문에서 제안하고 있는 합성곱 신경망의 구조를 보여준다. 제안신경망은 입력 층의 노드 수는 입력되는 영상의 크기에 따라 구현에서 가변적으로 구현되어야 한다. 제안된 합성곱 신경망은 입력 층의 노드는 125개 (각 초분광영상의 대역 수)이고 출력 층은 입력 초분광영상이 나타내는 토양수분함량을 이진수의 형태로 표현하기 위해 정수부분 출력층 1개와 소수부분 출력 1개로 구성된다. 입력에 대한 수분함량이 40.34%인 경우 정수부분 출력노드에는 0.4, 소수부분에는 0.34가 학습을 위해 각기 주어진다. 수분함량

을 하나의 노드로 표현할 경우에는 정확한 판정을 위하여 10^{-4} 에 이르는 정밀도를 학습해야하지만 두 개의 노드로 나누어 표시할 경우 학습정밀도를 10^{-2} 로 낮출 수 있어 빠르게 학습이 가능할 뿐 아니라 인식과정에서의 판별도 용이하게 된다.

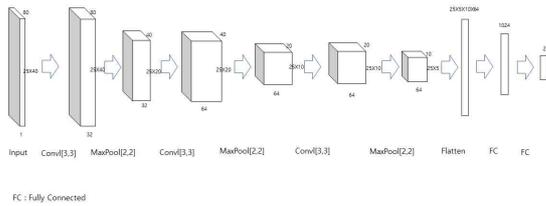


그림 3. 제안된 합성곱신경망 구조
Fig. 3. The architecture of the proposed CNN

입출력 층 사이에는 3개의 합성곱 층과 1개의 인식 층이 존재한다. 각 합성곱 층은 합성곱을 수행하는 층과 풀링 층의 2개로 구성된다. 첫 번째 합성곱 층은 입력 이미지를 3×3 크기의 필터 32개를 통한 합성곱 연산과 2×2 의 블록 단위로 연산하는 풀링 층을 거쳐서 500×40 크기의 32개 특징 맵으로 만든다. 두 번째 합성곱 층에서는 패딩에 스트라이드 1씩 이동하는 3×3 크기의 필터 64개를 통한 합성곱 연산과 풀링 층을 통과하면서 250×20 크기의 특징 맵 64개를 구성한다. 세 번째 합성곱 역시 3×3 크기의 필터 4개로 구성되기 때문에 연결된 풀링 층을 최종 통과한 결과는 4개의 125×10 크기의 특징 맵을 만든다. 최종적으로 얻어진 4개의 125×10 크기 특징 맵은 인식 층에 해당되는 다층신경망에 입력되어 결과를 얻는다.

4. 구현 및 실험 결과

제안한 합성곱신경망은 GPU (Graphics Processing Unit)가 설치된 Ubuntu 16.04.6 LTS 를 운영체제로 하는 서버에서 구현된다. 입력 영

상을 위한 전처리 및 합성곱신경망의 구현은 Python 2.7.15rc1 프로그래밍 언어와 텐서플로우 1.13.1 (Tensorflow 1.13.1)을 이용한다. 제안하는 합성곱신경망의 성능 비교 분석을 위해 기존의 영상 분석에 사용된 두 개의 합성곱신경망인 ALEXNET [11]과 VGG16 [12]을 사용한다. 비교 시스템들은 전체적인 구조는 유지하면서 입력 층과 최종 출력 층의 구조는 입력 영상에 맞게 수정한다. 제안시스템과 비교 시스템 모두 활성화 함수로 ReLU를 사용하며, 이웃 커널 값을 고려하여 합성곱 결과를 조정하는 지역 반응 정규화와 드롭아웃을 사용한다. 사용된 최적화 방식은 SGD이며 학습율은 0.15이다.

제안한 시스템의 성능분석을 위하여 [5]에서 제공하는 토양수분 초분광영상 Dataset을 사용한다. 이 Dataset은 4일간 2분 간격으로 대상 토양에 대해서 $454nm$ 에서 $950nm$ 대역을 $4nm$ 로 분할하여 125개의 대역밴드를 가지는 679개의 영상으로 구성된다. 각각의 초분광영상에 대한 레이블링 데이터는 실제 측정된 수분함량(%)과 온도 정보이다. 679개 중에서 250개를 학습에 사용하고 429개는 테스트 데이터로 사용한다. 학습데이터는 제안 신경망과 비교 시스템을 모두 학습하는데 사용한다. 학습에서는 초분광영상을 구성하는 전체 대역을 모두 사용한다. 따라서 학습할 초분광영상들에 대한 전처리가 필요 없는 장점을 가진다.

실험 결과 3가지의 합성곱신경망 모두 실험에 사용한 초분광영상을 잘 학습하고 우수한 일반화 능력을 보인다. 3개 시스템 모두 96%이상의 결과를 보였다. 가장 우수한 분석능력을 보인 것은 VGG16이고 그 다음이 ALEXNET이며 제안 시스템이 상대적으로 낮은 분류 능력을 보였다. 그러나 제안시스템은 비교시스템에 비교하여 단순한 구조를 가진다 (표 2). 이렇게 적은 수의 학습파라미터로 인하여 비교시스템에 비하여 학습

과정이 빠르게 진행되는 장점이 있다 (표 3). 이런 장점과 함께 분류능력에 있어서도 VGG16과 비교하여 2%이내의 차이를 나타내고 있다. 따라서 학습 효율성과 분류능력을 모두 고려할 경우 제안시스템은 초분광영상의 분석에 효과적으로 사용이 가능하다.

표 1. 실험결과
Table 1. The experimental results

시스템	테스트 수	인식/오인식	인식률
제안시스템	429	415/14	96.7%
ALEXNET	429	417/12	97.2%
VGG16	429	422/7	98.3%

표 2. 시스템의 사양
Table 2. Configurations of systems

시스템 명	제안시스템	ALEXNET	VGG-16
학습 파라미터 수	51,020	120,000	276,000

표 3. 시스템의 학습시간
Table 3. The learning time of each system

시스템	학습 횟수 (Epoches)	학습 소요시간 (초)
제안시스템	198	1,188
ALEXNET	150	2,850
VGG16	290	11,326

5. 결론

본 논문에서는 토양의 수분량을 초분광영상을 이용하여 효과적으로 분석할 수 있는 새로운 합성곱신경망 방법을 제안하였다. 제안한 합성곱신경망은 토양수분 측정을 위해 많은 밴드로 구성된 서로 다른 초분광영상에서 나타나는 밴드별 변화를 잘 학습하여 높은 인식율을 보였다. 합성

곱신경망을 사용하여 측정된 전체 밴드영역을 모두 사용하기 때문에 다른 연구와는 달리 입력에 대한 전처리 과정이 필요치 않는 장점이 있다.

제안시스템의 평가를 위하여 ALEXNET과 VGG16을 제안시스템과 같은 방법으로 학습시키고 인식을 수행하였다. 실험을 통하여 제안시스템은 비교시스템에 비해서는 인식율은 낮지만 효율적인 구조로 인하여 빠른 학습을 고려하면 전체적 우수한 성능을 보였다. 실험을 통하여 제안시스템이 초분광영상을 효과적으로 학습하고 분석하는 것을 보였기 때문에 초분광영상을 활용하는 다양한 영역에 사용이 가능할 것으로 보인다.

토양수분을 비롯한 식물의 생육정보를 초분광영상을 통하여 효과적으로 분석하는 것은 농업의 첨단화 및 자동화에 매우 중요한 역할을 할 것이다. 이런 점에서 볼 때 심층신경망을 이용한 초분광영상의 분석은 많은 응용분야에 적용될 수 있을 것으로 보인다. 향후 이에 대한 다양한 연구가 필요할 것이다.

“이 논문은 2021학년도 제주대학교 교원성과 지원사업에 의하여 연구되었음”

참고 문헌

- [1] T. Lillesand, R.-W. Kiefer and J. Chipman, Remote sensing and image interpretation, John Wiley & Sons, Hoboken, 2015, <https://www.wiley.com/en-us/Remote+Sensing+and+Image+Interpretation%2C+7th+Edition-p-9781118343289>.
- [2] A. F. H. Goetz, “Three Decades of Hyperspectral Remote Sensing of the Earth: a Personal View”, Remote Sensing of Environment, vol. 113, pp. 5-16, 2009, <https://doi.org/10.1016/j.rse.2007.12.014>.

- [3] S. H. Kim, J. G. Kang, and C. S. Ryu, "Estimation of Moisture Content in Cucumber and Watermelon Seedlings Using Hyperspectral Imagery", *Protected Horticulture and Plant Factory*, vol. 27, no. 1, pp. 34-39, 2018, <https://doi.org/10.12791/KSBEC.2018.27.1.34>.
- [4] C. Rodarmel, and J. Shan, "Principal component analysis for hyperspectral image classification", *Surveying and Land Information Science*, vol. 62, no. 2, pp. 115-122, 2002, <https://www.proquest.com/docview/202974751?pq-origsite=gscholar&fromopenview=true>.
- [5] Felix M. Riese and Sina Keller, "Introducing a Framework of Self-Organizing Maps for regression of Soil moisture with Hyperspectral Data", *IEEE IGARSS*, pp. 6151-6154, 2018, <https://doi.org/10.1109/IGARSS.2018.8517812>
- [6] V. Slavkovic, S. Verstockt, W. De Neve, S. Van Hoecke, and R. Van de Walle, "Hyperspectral image classification with convolutional neural networks", *Proc. of 23rd ACM International Conference on Multimedia*, Brisbane, Australia, pp. 1159-1162, 2015, <https://doi.org/10.1145/2733373.2806306>.
- [7] Y. Chen, H. Jiang, C. Li, X. Jia and P. Ghamisi, "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232-6251, 2016, <https://doi.org/10.1109/TGRS.2016.2584107>.
- [8] H. Zhang, Y. Li, Y. Zhang and Q. Shen, "Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network", *Remote Sensing Letters*, vol. 8, no. 5, pp. 438-447, 2017, <https://doi.org/10.1080/2150704X.2017.1280200>.
- [9] M. He, B. Li, and H. Chen, "Multi-scale 3D deep convolutional neural network for hyperspectral image classification", *Proc. of 2017 IEEE International Conference on Image Processing*, Beijing, pp. 3904-3908, 2017, <https://doi.org/10.1109/ICIP.2017.8297014>.
- [10] Y. Li, H. Zhang and Q. Shen, "Spectralspatial classification of hyperspectral imagery with 3D convolutional neural network", *Remote Sensing*, vol. 9, no. 1, pp. 67, 2017, <https://doi.org/10.1016/j.patrec.2018.10.003>.
- [11] Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", *Proceedings of the 25th International Conference on Neural Information Processing Systems*, pp. 1097-1105, 2011, <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>.
- [12] Karen Simonyan, Andrew Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", *Proc. of ICLR*, pp. 1-14, 2015, <https://arxiv.org/pdf/1409.1556.pdf>.

— 저 자 소 개 —



전남열 (Nam-Youl Jeon)

2001.2 전남대학교 전산통계학과 석사
2020.3-현재 : 제주대학교 전산통계학과
석사 과정
<주관심분야> 인공지능, 패턴인식



이봉규 (Bong-Kyu Lee)

1995.2 서울대학교 컴퓨터공학과 박사
1996.3-현재 : 제주대학교 교수
<주관심분야> 인공지능, 패턴인식