



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

석사학위논문

합성곱신경망과 초분광영상을  
이용한 토양수분량 예측 연구

제주대학교 대학원

전산통계학과

전 남 열

2021년 12월

# 합성곱신경망과 초분광영상을 이용한 토양수분량 예측 연구




지도교수 이 봉 규

전 남 열

이 논문을 이학 석사학위 논문으로 제출함

2021년 12월

전남열의 이학 석사학위 논문을 인준함

심사위원장	김철수	
위 원	이 봉규	
위 원	이윤정	

제주대학교 대학원

2021년 12월

A Study on Soil Moisture Prediction using CNN (Convolution  
Neural Network) and Hyperspectral Image

NamYoul Jeon  
(Supervised by professor BongKyu Lee)

A thesis submitted in partial fulfillment of the requirement for the degree of  
Master of Science

December 2021

This thesis has been examined and approved.

*ChulSoo Kim*

.....  
Thesis Committee Chair, ChulSoo Kim, Prof. of Computer science and Statistics

*Bongkyu Lee*

.....  
Thesis Committee Member, BongKyu Lee, Prof. of Computer science and Statistics

*Yunjung Lee*

.....  
Thesis Committee Member, YunJung Lee, Prof. of Computer science and Statistics

December 2021

Department of Computer science and Statistics  
GRADUATE SCHOOL  
JEJU NATIONAL UNIVERSITY

# 목 차

표 목차 .....	ii
그림 목차 .....	iii
초록 .....	iv
Abstract .....	v
I. 서론 .....	1
II. 배경과 관련 연구 .....	3
1. 농업분야에 대한 초분광영상 활용 .....	3
1.1. 초분광영상 (HSI) 기술 .....	4
1.2. 초분광영상 자료 활용분야 .....	7
2. 인공신경망과 합성곱신경망 .....	9
2.1. 인공신경망 (Artificial Neural Networks, ANN) .....	9
2.2. 합성곱신경망 (Convolution Neural Network, CNN) .....	13
2.3. 합성곱신경망과 초분광영상 분석 .....	21
III. 초분광영상 분석을 위한 합성곱신경망 .....	25
IV. 구현 및 실험 결과 분석 .....	27
1. 실험 환경 및 데이터 수집 .....	27
2. 실험 결과 및 분석 .....	29
V. 결론 및 향후 연구 방향 .....	31
VI. 참고 문헌 .....	32

## 표 목차

Table 2.1 초분광영상 활용분야 .....	5
Table 2.2 오류 역전과 알고리즘 .....	11
Table 2.3 합성곱신경망의 다양한 활성화함수들 .....	15
Table 4.1 실험에 사용된 컴퓨팅 환경 .....	27
Table 4.2 실험결과 .....	29
Table 4.3 시스템의 사양 .....	29

## 그림 목차

Fig. 2.1 초분광영상의 개념 .....	4
Fig. 2.2 데이터 획득 방법에 따른 초분광기술 구분 .....	5
Fig. 2.3 인공신경망의 뉴런 구조 .....	9
Fig. 2.4 다층 퍼셉트론의 일반적인 구조 .....	10
Fig. 2.5 경사하강법 .....	11
Fig. 2.6 합성곱신경망과 다층신경망 비교 .....	13
Fig. 2.7 마스크 (필터)를 이용한 합성곱 연산 .....	14
Fig. 2.8 맥스 풀링의 예 .....	15
Fig. 2.9 주요 활성화 함수의 비선형성 비교 .....	16
Fig. 2.10 합성곱신경망 일반적인 구조 .....	17
Fig. 2.11 완전 연결과 부분 연결 .....	17
Fig. 2.12 완전 연결 층에 대한 연산 과정 .....	18
Fig. 2.13 드롭아웃이 적용된 신경망 .....	19
Fig. 2.14 초분광영상의 분석 절차 .....	21
Fig. 2.15 전이 학습 과정 .....	23
Fig. 3.1 제안된 합성곱신경망 구조 .....	25
Fig. 3.2 제로 패딩(Padding) .....	26
Fig. 3.3 스트라이드(Stride) 1 이동 .....	26
Fig. 4.1 AlexNet의 구조 .....	27
Fig. 4.2 VGG16의 구조 .....	28
Fig. 4.3 제안시스템과 비교시스템의 학습 횟수와 소요시간 .....	30

## 초 록

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 초분광영상의 경우 많은 분광밴드로 인하여 발생하는 방대한 데이터로 인하여 분석과정이 복잡하기 때문에 사용이 어렵다. 이런 문제점을 해결하기 위하여 심층신경망 (Deep Neural Network, DNN)을 통한 초분광영상의 분석이 시도되고 있다.

본 논문에서는 토양수분량을 예측할 수 있는 심층신경망의 일종인 합성곱신경망 (Convolution Neural Network, CNN) 기반의 시스템을 제안한다. 제안한 방법은 합성곱신경망이 토양에 대한 초분광영상을 이용하여 수분량에 대한 학습을 한다. 인식 단계에서는 입력되는 초분광영상을 분석하여 입력된 영상이 가지는 수분량을 인식한다.

제안 시스템의 유효성을 보이기 위해서 토양에서 얻은 초분광영상 데이터를 이용하여 수분량을 분석하는 실험을 한다. 실험 결과 인식률은 96.7%로 나타났다. 제시된 기법은 대상 초분광의 전체 대역을 심층학습방법을 사용하여 자동 분석하기 때문에 각 영상에 대해 인식에 필요한 특정 대역을 찾는 노력을 할 필요가 없다.

한글키워드 : 토양 수분, 식물생육, 초분광영상, 심층신경망, 합성곱신경망, 분광밴드



## 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 the large amount of data appearing in many spectral bands. In order to solve this problem, analysis of hyperspectral images using Deep Neural Networks (DNN) is being attempted.

In this paper, we propose a Convolution Neural Network (CNN)-based system, a type of Deep Neural Network capable of predicting soil moisture. The Convolution Neural Network learns the soil moisture using hyperspectral images of the soil. In the recognition step, the soil moisture is recognized by analyzing the input hyperspectral image.

In order to show the effectiveness of the proposed system, an experiment is conducted to analyze the amount of moisture using hyperspectral image data obtained from the soil. As a result of the experiment, the recognition rate was 96.7%. Since the presented technique automatically analyzes the entire band of the target hyperspectral using a deep learning method, there is no need to make efforts to find a specific band required for recognition for each image.

Keywords : Soil moisture, Plant growth, Hyperspectral image, DNN, CNN, Spectral band

## I. 서론

식물은 몸체의 75%이상이 수분으로 구성되며, 대사에 필요한 대부분의 것을 물을 통하여 이동시키기 때문에 재배 식물에서 나타나는 대부분의 영양장애는 수분에 의해서 좌우된다. 따라서 재배하는 식물을 위한 최적 수분을 토양이 유지할 수 있도록 하는 것은 식물의 성장에 필수적이다. 기존에는 수분함량을 측정하는 장비를 토양에 장착하여 직접 측정하는 방식을 사용했기 때문에 많은 시간과 비용이 필요했고, 대면적인 경우 세밀한 정보를 얻는 것이 어려웠다. 이러한 문제점을 해결하기 위한 방법으로 최근 초분광영상 (Hyperspectral Image, HSI)을 이용하는 방법이 연구되고 있다 [1].

초분광영상을 이용하여 식물의 생육상태 분석, 수분량 분석, 병충해 탐지를 대상으로 파괴하지 않는 방법으로 할 수 있다. 이러한 비파괴 분석법은 재료가 갖는 물리적인 성질을 이용하여 시험 대상물을 손상 및 파괴하지 않고 내·외부의 상태를 파악하는 장점 때문에 농업분야에서 효과적으로 사용이 가능하다 [2]. 그러나 초분광영상은 구성되는 영상의 복잡도로 인하여 실제 사용에 많은 제약이 따른다. 초분광영상의 경우 많은 분광밴드에서 나타나는 방대한 데이터로 인하여 분석과정이 복잡하고, 기존의 기계학습 방법으로 학습이 어렵기 때문에 자동화된 분석 기법을 찾는 것이 매우 어렵다. 이러한 문제를 해결하기 위해 다양한 차원축소 기법들이 초분광영상에 적용되어왔는데, 대표적인 방법 중 하나가 주성분 분석 (Principal Component Analysis, PCA)이다. 주성분 분석은 초분광영상을 독립적인 개별 성분들로 재구성할 수 있기 때문에 초분광영상의 분광 차원축소 기법으로써 활용이 가능하다 [3]. 그러나 주성분 분석의 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, CNN) 기반의 방법을 제안한다. 제안한 방법은 초분광영상의 분광밴드들에 있는 다양한 정보를 합성곱신경망의 학습능력으로 처리한다. 데이터 세트 (Dataset) [4]를 이용한 토양 수분량 분석 실험을 통하여 제안한 합성곱신경망이 초분광영상 정보의 복잡도를 잘 해결함을 보인다.

본 논문의 구성은 다음과 같다. II장에서는 본 연구의 배경과 식물의 생육과 관련된 농업분야에 대한 초분광영상 활용 및 HSI 기술의 정의와 시스템 응용영역 그리고 인공신경망 (ANN)과 합성곱신경망 (CNN)을 기술한다. III장에서는 제안한 초분광 영상 데이터를 이용한 토양수분량 예측·분석을 위한 합성곱신경망의 과정을 기술한다. IV장에서는 예측시스템의 실제 구현과 실험을 통하여 제안한 방법의 유효성을 보인다. 마지막으로 V장에서는 본 논문의 결과 및 향후 연구에 대해 기술한다.

## II. 배경과 관련 연구

### 1. 농업분야에 대한 초분광영상 활용

수분 부족 (Water stress), 병해충, 영양상태 등 농작물의 모니터링은 예전부터 현장에서 육안으로 이루어져 왔다. 육안으로 확인이 가능하게 되면 이미 농작물의 상태가 심각해져 회복이 불가능한 상태에서 발견되는 경우가 대부분이기 때문에 이러한 육안확인 방법은 한계점이 있었다. 최근 초분광영상 기술이 발달하면서 농작물의 스트레스 평가나 토양과 식생의 특성 분석 등에서 기존의 방식들을 대체할 수 있게 되었다. 가뭄지수는 농업생산량에 영향을 미치는 중요한 요소 중 하나이며, 이러한 토양수분량과 관련된 스트레스를 적시에 탐지해내는 것 또한 중요한 하나의 인자다. 심각한 수분 부족현상은 광합성 색소를 변화시키게 하고, 적색 스펙트럼의 반사도가 증가하기 때문에 작물이 노르스름하게 변하게 된다. 사람의 시각과 달리 초분광 센서는 이러한 변화를 초기에 감지해 낼 수 있다. 잎의 EWT (Equivalent Water Thickness)가 변화하는 것은 잎의 가시광선 및 적외선 반사도가 변화하는 것이 원인이다. 또한, 초분광영상을 이용하여 잎 자체뿐만 아니라 경작지 전체 토양수분량을 추정할 수 있기 때문이다. 계절별 일조량과 강수량 등 기상현상에 대해 토양의 수분 함량 변화가 다양하므로 재배하는 농작물을 위한 최적의 수분 함량이 토양에 유지될 수 있도록 하는 것은 농작물의 성장에 필수적이다.

농작물의 영양 부족이나 토양오염을 통해 발생하는 다양한 징후 또한 초분광기술을 통해 평가할 수 있다. 농작물의 스트레스 징후와 엽록소 함량의 관계를 파악하기 위하여 아연 부족과 유독성을 초분광기술을 이용하여 관측할 수 있으며, 과거의 직접적인 샘플링 조사보다 비용을 현저히 줄일 수 있다. 또한 격자 내 수은 함량을 분석하여, 분광특성이 오염 수준과 상당히 밀접한 관계가 있음을 알 수 있다. 초분광영상을 통해 생물량 (Biomass), 스트레스 상태에서의 생산량, 질소와 인의 농도 및 토양 내 탄소유기물질 함량을 추정할 수 있다. 이러한 토양특성에 대한 이해는 농작물의 성장 모니터링을 통해 농업생산량을 증가시키는데 중요한 역할을 한다. 이런 이유로 토양수분 분석 및 이에 관련된 다양한 농작물의 생육정보 획득에 초분광영상을 활용하는 방법이 진행되고 있다.

## 1.1. 초분광영상 (HSI) 기술

초분광영상은  $400nm$ 부터  $1,000nm$  파장영역을 수백 개로 나눈 분광밴드 (Spectral Band)별 2차원적인 영상정보를 초분광큐브 (Hypercube) 형태로 구성한다. 초분광 기술이란 그림 2.1처럼 공간정보 기반에 초분광영상 처리 기술을 더한 것을 의미하며, 객체의 전자기파 스펙트럼 밴드와 2차원적인 영상정보를 큐브 형태로 대상체의 상태 (State), 구성 (Composition), 특징 (Feature), 변이 (Transform) 등을 도출한다 [5].




그림 2.1 초분광영상의 개념

Fig. 2.1 The concept of Hyperspectral images

데이터 습득 형태로 초분광기술을 구분하면 그림 2.2와 같이 일정 스펙트럼 영역을 동시에 분광 측정 (병합 후 큐브생성) 하는 공간 스캐닝 (Spatial Scanning) 기술 방식과 파장을 변화시켜 스캔 (동시에 큐브 고속 생성)하는 스펙트럼 스캐닝 (Spectral Scanning) 기술 방식으로 구분할 수 있다. 공간 스캐닝 기술 방식은 공간 좌표 움직임에 따라 측정하는 점 스캐닝 (Point Scanning(a), Whisky Broom)과 하나의 라인 센서의 Y축 움직임에 따라 측정하는 라인 스캐닝 (Line Scanning(b), Push Broom)으로 구분할 수 있다. 스펙트럼 스캐닝 기술 방식은 측정 영역 전체 이미지를 스캔하는 영역 스캐닝 (Area Scanning(c), Staring) 방식과 센서를 다수의 스펙트럼 영역으로 구분하여 동시에 측정하는 스냅샷 (Snap Shot(d)) 방식으로 구분할 수 있다.

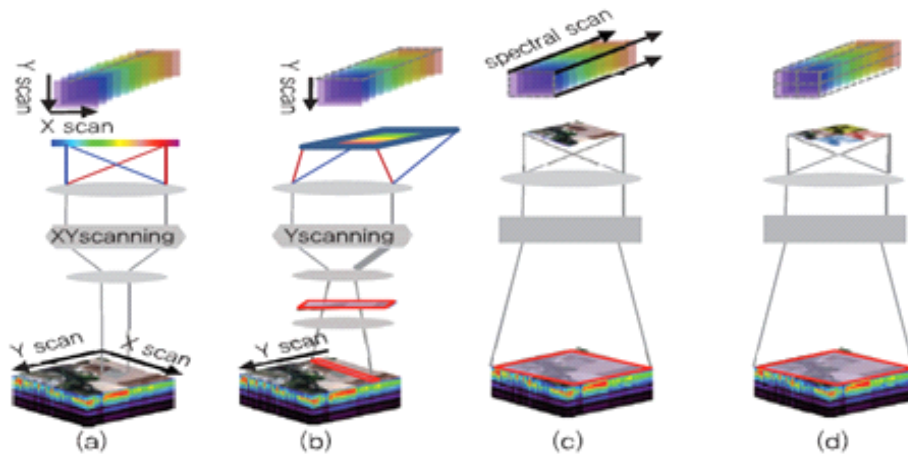



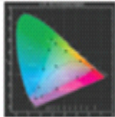
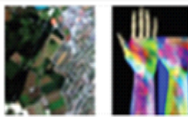


그림 2.2 데이터 획득 방법에 따른 초분광기술 구분

Fig. 2.2 Classification of HSI technologies by data acquisition methods

초분광영상은 원격탐사 (Remote Sensing)가 본격적으로 시행되는 1960년대가 시작되면서 사용되기 시작했으며, 초기에는 주로 4개에서 7개 정도의 분광밴드를 가진 다분광 센서를 이용하였다 [6]. 초분광영상 카메라의 응용분야는 표 2.1과 같이 원격탐사 및 인공위성이나 항공기 등을 이용한 지질 상태, 기상, 농작물 생육, 수분 함유량 확인 등에 활용되고 있다. 최근 초분광영상 장치의 소형화 및 대용량 데이터 분석기술의 발전으로 점차 분광밴드수가 충분히 확보됨에 따라서 환경, 국방, 헬스케어, 식품, 농업, 보안, 머신비전 (Machine Vision), 바이오·의료, 지질 및 광물 탐색 등으로 점차 그 영역을 넓혀가고 있다. 이러한 초분광영상의 활용은 농업분야에서도 활발히 진행되고 있다.

표 2.1 초분광영상 활용분야

Table 2.1 Applications of hyperspectral imaging

UV	VIS	VIS/NIR	SWIR	MWIR
				
Minerals Forensics Adbasive	Color measurement Printuing works Textile	Medical Food Machine vision Biotechnology Remote sensing Agriculture	Polymers Food Chemicals Military Wood	Chemicals Arts Gas Military

초분광영상 기술의 이슈로는 초분광 카메라의 소형화 및 저가격화와 1,000 밴드 채널 이상의 극초분광 영상처리 기술의 발달을 들 수 있고, 딥러닝을 포함한 머신러닝 기반의 실시간 데이터 분석기술을 이용한 분류 (Classification), 군집 (Clustering) 및 분광 혼합 알고리즘 (Spectral Mixture Algorithm)등 HSI 기술을 최대한으로 활용하고 있다.

## 1.2. 초분광영상 자료 활용분야

초분광영상 자료는 기존의 다중분광자료에서 얻을 수 없었던 정보 추출과 관련된 새로운 활용분야가 있다. 위장된 군사 시설과 같은 목표물의 탐지는 군사적 목적으로 초분광영상의 초기 활용분야라 할 수 있으며, 항공기 탑재 초분광영상 자료의 초기 활용 분야는 광물자원의 분포를 파악하거나 암석종류 구분 등 지질분야가 주를 이루고 있다. 식생분야에서는 식물의 생화학적 구성 요소들(클로로필양, 탄소량, 질소량 등)의 예측에 많은 연구가 진행되고 있으며 식물에 나타나는 각종 스트레스들의 탐지가 시도 되고 있다. 또한 초분광영상을 이용한 클로로필양의 예측과 관련된 수질 모니터링 등 그 활용분야가 확대되고 있다. 향후 초분광영상의 해상도와 광학 기술이 개선된 인공위성 탑재 초분광센서의 개발과 함께, 초분광영상 자료 활용을 위한 연구가 계속될 전망이다.

### 1) 지질 및 광물 탐지

초기 초분광센서의 개발 목적의 한 부분을 차지했던 분야이며, 현재까지 초분광영상 활용이 가장 성공적으로 이루어진 분야이다. 초분광영상을 이용한 지질 및 광물 탐지 분야는, 중적외선 파장구간에서 나타나는 암석 및 광물의 구성 성분에 따른 분광적 차이를 잘 이용한 결과이다. 암석 및 광물을 구성하는 화학물질의 분광 흡수 밴드가 좁은 중적외선 파장구간에서 잘 탐지되고, 초분광영상에서 이러한 흡수 밴드의 파악이 용이하기 때문이다. 현재 구축된 대부분의 분광 라이브러리에서 주된 분광반사측정 자료는 암석 및 광물에 관한 것이다. 그러나 암석이나 광물의 표층에 바깥으로 노출된 경우가 드물기 때문에 초분광영상 자료의 획득이 어렵다.

### 2) 도시 피복물 구분

도시 지역은 매우 다양한 종류의 피복이 분포하고, 그 공간적 규모와 구성 상태가 매우 복잡하기 때문에 높은 분광해상도와 공간해상도의 이미지 데이터가 필요하다. 특히 도시 피복물 중 콘크리트나 아스팔트와 같은 비교적 동일한 화학 물질로 구성된 경우 초분광영상을 이용한 탐지가 가능하며, 건물의 지붕재료 및 페인트의 경우도 초분광영상을 이용하여 효과적으로 구분할 수 있다. 그러나 복잡한 시설물의 구조로 인해 높은 공간해상도를 요구하는 단점이 있어 항공기 탑재 초분광영상만 진행되고 있다.



### 3) 수질

해양관측 센서의 중요한 특징은 좁은 파장영역에서 나타나는 클로로필 흡수밴드를 포함하고 있으며, 이를 이용한 바다색 및 수질과 관련된 분야에 활용되고 있다. 초분광영상의 높은 분광해상도를 이용하여 클로로필, 플랑크톤, 용존 유기물 등 물속의 다양한 물체에 의하여 나타날 수 있는 분광반사특성을 분석할 수 있다. 또한 수질과 관련된 원격탐사에서 전처리과정이 다중분광영상에서는 어려웠지만, 초분광영상에서는 전처리가 비교적 정확하고 쉽게 수행될 수 있다.

### 4) 대기

초분광영상은 기존 다중분광영상에 비해서 영상 촬영 시점의 대기와 관련된 정보를 직접 얻을 수 있다는 장점이 있다. 수많은 분광 밴드 중 특정 밴드에서 대기 중 수분 함유량이나 가시거리와 같은 정보를 예측할 수 있기 때문에 대기와 관련된 초분광영상 활용 연구 중 많은 부분은 초분광영상의 대기보정과 함께 진행되고 있다.

### 5) 식생

식생분야는 지질 및 광물 분야와 함께 초분광영상의 활용이 가장 많은 분야이다. 기존 다중분광영상에서 얻기 어려운 수증 분류, 잎면적 지수 및 잎량 등 예측과 가뭄 및 병충해 등 각종 스트레스에 의한 식물의 생화학적 변화를 탐지하는 연구가 주를 이룬다. 식물의 생·물리적 특성과 관련된 분석을 위하여 초분광영상 밴드를 조합한 다양한 식생지수들이 개발되고 있으며, 식물의 화학적 구성성분과 관련된 특정 밴드를 파악하는 연구가 중점적으로 진행되고 있다.

초분광영상을 이용하여 식물의 생육상태 분석, 수분분석, 병충해 탐지를 대상으로 파괴하지 않는 방법으로 할 수 있는 장점 때문에 농업분야에서 효과적으로 사용이 가능하다 [6]. 그러나 초분광영상은 구성되는 영상의 복잡도로 인하여 실제 사용에 많은 제약이 따른다. 초분광영상은 기존의 RGB영상과는 달리 100개 이상의 분광 밴드로 구성되어 방대한 정보를 내재하고 있기 때문에 기존 RGB영상에서 적용되는 분석기법이나 기계학습 방법으로는 효율적인 분석이 어렵다. 따라서 본 논문에서는 초분광영상을 분석하기 위한 방법으로 합성곱신경망을 이용하고자 한다.

## 2. 인공신경망과 합성곱신경망

### 2.1. 인공신경망 (Artificial Neural Networks, ANN)

인공신경망은 사람의 뇌 조직을 모방하여 신경세포와 그 결합 구조를 컴퓨터로 표현하여 구조화한 것으로, 대표적인 머신러닝 (Machine Learning, 기계학습) 모델이다. 따라서 기존의 알고리즘 방법과는 달리 사람과 같은 샘플을 통한 학습으로 문제를 해결하는 능력을 갖추고 있다 [7, 8]. 이런 학습 및 분류 능력으로 인하여 인공신경망은 패턴분류 및 패턴인식, 패턴예측과 최적화 분야에서 유용하게 이용된다. 인공신경망을 구성하는 기본 단위 (Unit)는 사람의 신경세포 (Neuron, 뉴런)에 해당하는 노드 (처리기)와 각 노드를 이어주는 링크로 구성된다. 각각 링크에 각 노드 간의 연결 강도를 나타내는 가중치( $w_i$ )가 부여되는데, 가중치와 외부 입력의 계산을 통하여 학습한다.

전형적인 인공신경망의 구조[9]는 그림 2.3처럼 표현된다. 그림에서 보듯이 인공신경망은  $x_i$ 로 표현되는 외부 입력을 가중치에 곱하여 결과 값을 계산하여 출력한다. 이런 인공신경망의 각 노드의 집합들은 수행하는 기능에 따라서 입력층 (Input Layer), 출력층 (Output Layer) 그리고 은닉층 (Hidden Layer)으로 구별된다. 이런 층을 통하여 인공신경망은 입력층과 출력층만으로 구성되는 단층 신경망과 은닉층을 함께 가지고 있는 다층 (Multi Layer, 복층) 신경망으로 나누어진다. 일반적으로 신경망이 단층에서 다층으로 복잡해질수록 더 난해하고 어려운 문제를 해결하는 능력을 갖춘다.




그림 2.3 인공신경망의 뉴런 구조

Fig. 2.3 The neuron structure of artificial neural networks

다층 신경망 중에서 패턴인식에 사용되는 대표적인 모델은 그림 2.4처럼 표현되는 다층 퍼셉트론 (Multi Layer Perceptron, MLP)이다. 다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 은닉층을 가지는 전 (Full) 방향 신경망으로 단층 퍼셉트론의 한계를 극복하기 위해 1960년대에 이미 발표되었다. 그러나 효율적인 머신러닝 알고리즘이 없어서 이용되지 않았으나, 1986년에 오류 역전파 (Error BackPropagation, EBP) 머신러닝 알고리즘의 개발로 활발하게 이용하게 된다. 이 알고리즘은 원하는 목표값(d)과 실제 출력값(o) 사이의 오차의 제곱합으로 정의된 비용함수(Cost Function) E의 값을 그림 2.5의 경사하강법 (Gradient-descent Method, GDM)에 의해 최소화 하는 방향으로 학습하는 방법이다.




그림 2.4 다층 퍼셉트론의 일반적인 구조

Fig. 2.4 A common structure of Multi Layer Perceptrons

$$E = \sum_p E_p, (E_p = \frac{1}{2} \sum_j (d_{pj} - o_{pj})^2) \quad (1)$$

식(1)에서 p는 p번째 학습 패턴,  $E_p$ 는 p번째 패턴에 대한 오차,  $d_{pj}$ 는 p번째 패턴에 대한 j번째 요소,  $o_{pj}$ 는 실제 출력의 j번째 요소이다. 표 2.2에서 오류 역전파 알고리즘을 보여주고 있다 [8].

$$W := W - \alpha \frac{\partial}{\partial W} \text{cost}(W)$$

$$\text{cost}(W) = \frac{1}{n} \sum_{i=1}^n (H(x_i) - y_i)^2, \quad H(x_i) = Wx_i$$

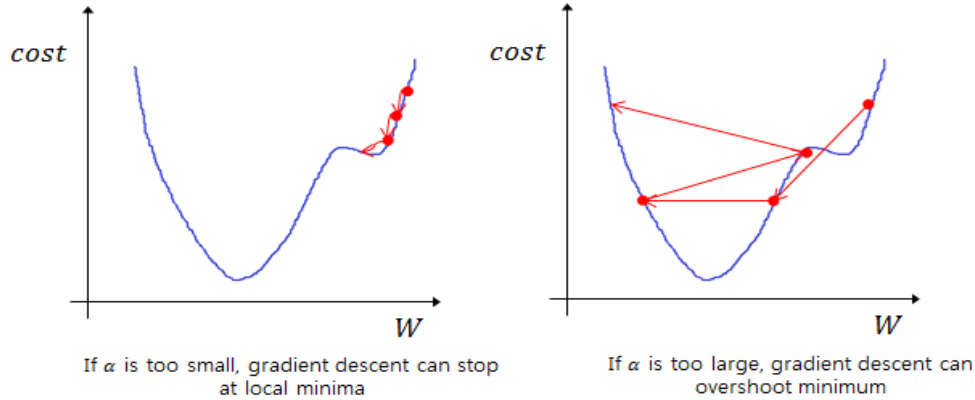


그림 2.5 경사하강법

Fig. 2.5 Gradient-descent Method

표 2.2 오류 역전파 알고리즘

Table 2.2 Error BackPropagation (EBP) Algorithm

<p>1단계. 가중치와 임계치를 초기화</p> <p>2단계. 입력과 목표 출력 제시</p> <p>3단계. 은닉층 j번째 뉴런의 값 계산</p> $\text{net}_{pj} = \sum_{i=0}^{N-1} W_{ji} X_{pi} - \theta_j$ <p>4단계. 시그모이드 함수를 사용하여 은닉층의 출력(<math>O_{pj}</math>) 계산</p> <p>5단계. 은닉층의 출력을 이용하여 출력층 뉴런 k로의 입력값 계산</p> $\text{net}_{pk} = \sum_{j=0}^{L-1} W_{kj} X_{pj} - \theta_k$ <p>6단계. 시그모이드 함수를 사용하여 출력층의 출력(<math>O_{pk}</math>)을 계산</p> <p>7단계. 목표출력(<math>d_{pk}</math>)과 실제 출력 (<math>O_{pk}</math>) 과의 오차값(<math>\delta_{pk}</math>) 계산</p> $\delta_{pk} = (d_{pk} - O_{pk}) f_k(\text{net}_{pk})$ $E = E + E_p, (E_p = \sum_{k=1}^{M-1} \delta_{pk}^2)$
--

8단계. 은닉층의 오차( $\delta_{pj}$ ) 계산

$$\delta_{pj} = f'_j(\text{net}_{pj}) \sum_{k=0}^{M-1} \delta_{pk} W_{kj}$$

9단계. 출력층의 가중치( $W_{kj}$ ) 갱신 (임계치도 조정)

$$W_{kj}(t+1) = W_{kj}(t) + \eta \delta_{pk} O_{pj}$$

$$\theta_k(t+1) = \theta_k(t) + \beta \delta_{pk}$$

10단계. 입력층과 은닉층의 가중치 값과 임계치값 갱신

$$W_{ji}(t+1) = W_{ji}(t) + \eta \delta_{pj} X_{pi}$$

$$\theta_j(t+1) = \theta_j(t) + \beta \delta_{pj}$$

11단계. 모든 학습패턴에 대하여 전부 학습할 때까지 2단계로 분기.

12단계. 출력층의 오차 합 E가 허용값 이하이거나 최대 반복회수보다 크면 종료,  
그렇지 않으면 2단계로 가서 반복한다.

오류 역전파를 이용한 다층 퍼셉트론은 특히 패턴인식 분야에서 많이 활용되면서 만족할 만한 결과 값을 보였다. 그러나 인공신경망의 구조가 복잡해지면서 기존의 다층 퍼셉트론은 많은 문제점을 보인다. 먼저 학습방법인 오류 역전파 방법은 층이 깊은 망 (Network) 일수록 입력에 가까울수록 출력에서 멀어져 기울기 (Gradient) 값이 작아지게 되는 기울기 값 소실문제 (Vanishing Gradient Problem)가 발생하여 학습이 잘되지 않는 현상이 발생한다. 게다가 사용하는 학습 데이터에 과적합 (Overfitting)로 인한 학습 일반화의 제한 등 문제가 발생한다. 그리고 다층 퍼셉트론에서는 학습 샘플을 분석하여 다층 퍼셉트론의 입력을 사람이 직접 설계해야 하므로 빅데이터 (Big Data)를 이용한 학습에 적절하게 대응하기 어렵다는 것이 가장 큰 문제로 대두된다. 과적합 문제나 기울기 값 소실문제는 수정된 선형함수 (Rectified Linear Unit, ReLU)의 사용으로 [10, 11], 과적합 문제는 드롭아웃 (Dropout) 방법 [12, 13]을 통하여 해결이 가능하다. 그러나 빅데이터 사용에 대해서는 새로운 방법이 필요하게 되었으며, 이에 따라 인간이 개입하지 않는 학습이 가능한 심층 학습 (Deep Learning, 딥러닝)을 이용한 합성곱신경망의 필요성이 증대되었다.

## 2.2. 합성곱신경망 (Convolution Neural Network, CNN)

영상패턴 분류 (Image pattern classification)를 위한 기존의 인공신경망은 주어진 영상으로부터 분류에 필요한 특징을 사람이 수작업으로 데이터 전처리 및 가공을 통해 미리 정한 후, 정해진 특징을 신경망을 학습하는데 이용한다. 따라서 학습하는 데이터가 방대할 경우, 효과적으로 패턴인식 시스템을 설계하는 것은 매우 어려운 일이다. 이런 문제점을 해결하기 위해 그림 2.6에서 보듯이 합성곱신경망은 특징추출과 패턴인식을 통합하여 처리하는 형태를 가진 새로운 신경망이다. 합성곱신경망은 분석하려는 원래 영상을 그대로 입력 층에서 사용할 수 있기 때문에 별도의 특징추출 과정이 필요 없다 [14].

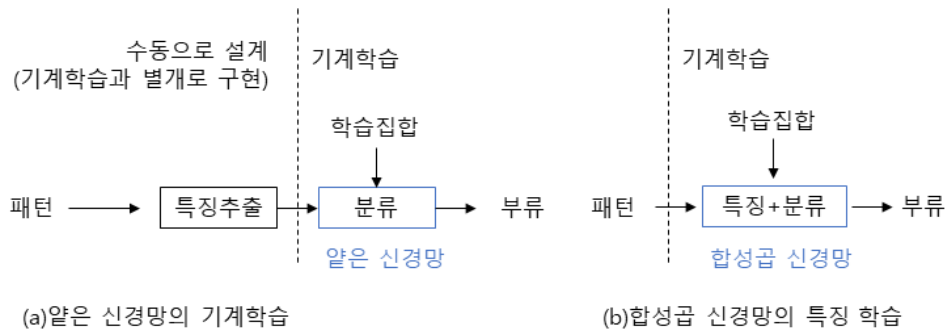


그림 2.6 합성곱신경망과 다층신경망 비교

Fig. 2.6 Comparison of CNNs and MLPs

합성곱신경망의 구조는 내부특징추출을 목적으로 하는 다수의 합성곱 층과, 합성곱 층으로부터 추출한 특징을 인식하는 1개의 인식 층 (3층 구조의 다층신경망, MLP)로 구성된다. 각각의 합성곱 층은 입력 영상에 대한 특징추출을 위한 필터연산을 수행하는 단층 신경망과 필터연산 결과의 크기를 재조정 (Subsampling)하는 단층 신경망으로 구성된다. 1개의 인식 층은 완전연결 (Fully Connected) 구조를 가지는 다층신경망의 구조를 가진다. 입력된 영상은 복수의 합성곱 층에 의해서 다양한 형태의 특징으로 변환되며 최종 변환과정을 거친 특징은 완전연결 인식 층에 전달되어 인식 작업에 사용된다.

합성곱신경망이 기존 인공신경망과 구별되는 것은 자체적인 합성곱 (Convolution)과 풀링 (Pooling)을 통한 자동으로 특징을 뽑아내는 것이다. 합성곱 층의 각 노드는 입력에 대해서 학습을 통하여 최고로 적합한 특징을 뽑아낸다. 합성곱 연산은 영상 처리에서의 필터를 이용한 방법을 사용하는 것과 같은 원리이다. 그림 2.7처럼 합성곱 연산에서 커널 (Kernel)로 표현된 가중치 값의 행렬을 필터 (Filter) 또는 마스크 (Mask)라고도 하며 일반적으로 너비와 높이가 같은 정사각형 (Square)의 형태이다 [12]. 합성곱의 결과로 얻어지는 결과를 특징 맵 (Feature Map)이라 하며 여러 단계의 합성곱을 거친 최종단계의 특징 맵이 인식 층의 입력이 된다. 커널은 입력 영상을 왼쪽에서 오른쪽으로 이동하면서 해당 영역 내의 영상 부분과 합성곱 연산을 수행하는데, 이동 정도는 스트라이드 (Stride) 값으로 조절이 가능하며, 스트라이드  $s$ 의 크기는 합성곱 결과의 크기를 조절하기 위해서 사용한다. 만약 입력 영상과 커널의 크기가 각각  $n_h \times n_w$ ,  $l_h \times l_w$ 이고 채우기 값 (입력 영상의 확장 지수, Padding)과 스트라이드 값이 각각  $p$ ,  $s$ 이면 커널로 처리된 합성곱 결과 크기는 식(2)과 같이 결정된다.

$$o_h = \frac{n_h + 2p - l_h}{s} + 1$$

$$o_w = \frac{n_w + 2p - l_w}{s} + 1 \quad (2)$$

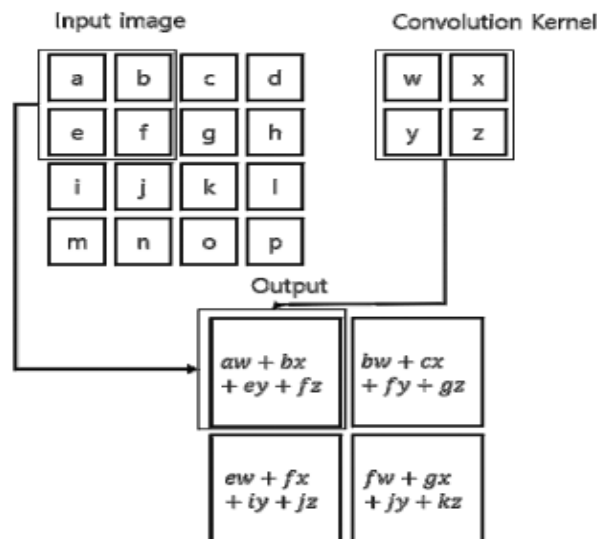


그림 2.7 마스크 (필터)를 이용한 합성곱 연산  
Fig. 2.7 Convolution operations using a mask (filter)

합성곱 연산 결과는 일반적으로 풀링 (Pooling) 층에서 샘플링을 통하여 크기가 조절된다. 풀링이란 일정한 크기의 대상 영역을 통합해 한 개 대표적인 값으로 표현하는 연산이다. 그림 2.8처럼 풀링은 매번 합성곱 연산이 수행된 후 반복되어 실행된다. 그리고 풀링 연산은 합성곱 결과에 대해 위치가 변하지 않는 성질을 제공하고 데이터양을 축소해 연산의 효율성을 극대화할 수 있는 특징이 있다 [15].




그림 2.8 맥스 풀링의 예

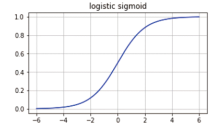
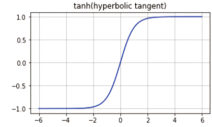
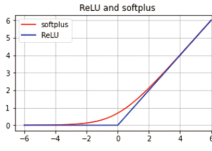
Fig. 2.8 An example of max-pooling operations

합성곱신경망은 기존 인공신경망에서 나타나는 3가지 문제점인 기울기 값 소실 문제, 학습속도 문제 및 과적합 문제를 풀 수 있는 해법을 제공한다. 먼저 다층 퍼셉트론 (MLP)과 달리 딥러닝 (Deep Learning)에서는 로지스틱 시그모이드 (Sigmoid)나 하이퍼볼릭 탄젠트 (Tanh) 시그모이드 등과 같은 비선형 함수와 선형 함수인 렉티파이어 (ReLU)나 소프트플러스를 주로 사용한다. 표 2.3의 활성화 함수를 이용해 합성곱 신경망을 구성하는 층이 비교적 적으면 로지스틱 시그모이드나 하이퍼볼릭 탄젠트 시그모이드를 그대로 사용하여 학습하면 되고, 층의 개수가 많아질 경우에는 렉티파이어 (ReLU)함수나 소프트플러스를 사용하여 기울기 값 소실문제를 해결 한다. 그림 2.9는 비선형성의 일반적인 유형을 나타낸다.

표 2.3 합성곱신경망의 다양한 활성화함수들

Table 2.3 Various activation functions of CNNs



함수이름	도표	함수	1차 도함수	범위
로지스틱 시그모이드		$\tau(s) = \frac{1}{1+e^{-as}}$	$\tau'(s) = a\tau(s)(1-\tau(s))$	(0, 1)
하이퍼볼릭 탄젠트 (Tanh) 시그모이드		$\tau(s) = \frac{2}{1+e^{-as}} - 1$	$\tau'(s) = \frac{a}{2}(1-\tau(s)^2)$	(-1, 1)
렉티파이어(ReLU)		$\tau(s) = \max(0, s)$	$\tau'(s) = \begin{cases} 0 & s < 0 \\ 1 & s > 0 \\ \text{불가} & s = 0 \end{cases}$	(0, ∞)
소프트플러스		$\tau(s) = \log_e(1+e^s)$	$\tau'(s) = \frac{1}{1+e^{-s}}$	(0, ∞)




그림 2.9 주요 활성화 함수의 비선형성 비교

Fig. 2.9 Non-linearity comparison of various activation functions

합성곱신경망의 학습은 기존의 신경망에서 사용하는 오류역전파 알고리즘이 사용된다. 그러나 합성곱신경망에서 사용하는 오류 역전파 학습은 기존의 신경망과는 차이가 있다. 기존의 인공신경망에서는 초기 가중치 설정에 대한 명확한 근거가 없었기 때문에 효율적인 학습이 이루어지지 못하였다. 이에 비해 합성곱신경망은 초기 가중치를 효율적으로 추정하는 최적화(Optimization) 알고리즘을 사용하여 최적의 초기 가중치를 설정할 수 있는 특징이 있다 [14].




그림 2.10 합성곱신경망 일반적인 구조  
 Fig. 2.10 The general structure of CNNs

그림 2.10에서 합성곱신경망의 구조를 보여준다. 그림에서처럼 합성곱신경망은 특징추출을 목적으로 하는 다수의 합성곱 층과, 합성곱 층으로부터 추출한 특징을 인식하는 1개의 인식 층 (3층 구조의 MLP)로 구성된다. 개개의 합성곱 층은 입력 영상에 대한 특징추출을 위해 커널 필터연산을 수행하는 단층 신경망과 커널 필터 연산 결과의 크기를 서브 샘플링 (Subsampling 재조정)하는 단층 신경망으로 구성된다. 1개의 인식 층은 그림 2.11처럼 완전 연결 층 (Full Connection) 구조를 가지는 다층 신경망의 구조를 가진다. 완전 연결된 레이어의 처리 절차 [9]는 그림 2.12와 같다. 그림 2.10에서 보듯이 입력된 영상은 복수의 합성곱 층에 의해서 다양한 형태의 특징으로 변환되며 최종 변환과정을 거친 특징은 완전연결 인식 층에 전달되어 인식 작업에 사용된다. 전체 합성곱 신경망의 학습에는 오류 역전파 알고리즘이 사용되며, 출력 층에서 합성곱 층까지 오류를 역전파 하는 방식으로 학습을 한다.

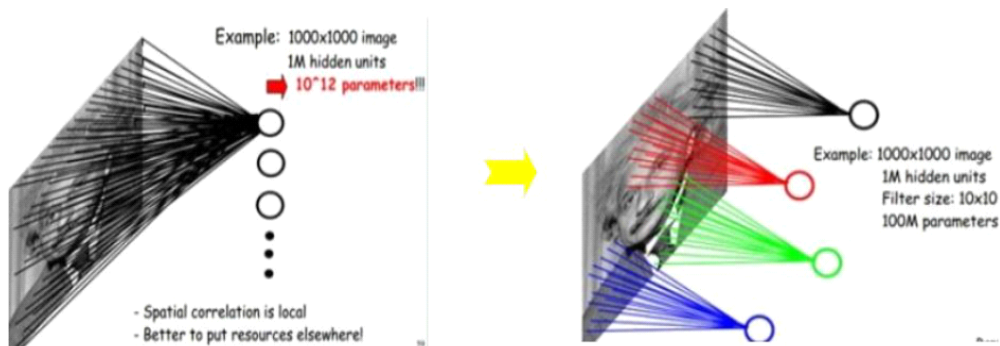


그림 2.11 완전 연결과 부분 연결  
 Fig. 2.11 Fully connected and partial connected

오류 역전과 학습 방식을 위해서는 학습 초기에 최초 가중 값을 부여하고, 오류를 측정하는 목적함수가 작아지는 쪽으로 가중 값을 바꾸어 나간다. 따라서 초기 가중 값은 학습속도에 중요한 인자이다. 기존 인공신경망은 초기의 가중 값 설정에 대한 정확한 근거가 없었기 때문에 효과적인 학습이 이루어질 수 없었다. 합성곱신경망에서는 초기 가중 값을 효과적으로 추정하는 방법으로 최적화 (Optimization) 알고리즘을 사용한다. 확률적 경사 하강법 (Stochastic Gradient Descent, SGD)은 손실 함수의 기울기 값을 계산하여 이 기울기 값에 학습률 (Learning Rate)을 연산하여 이 결과 값으로 기존의 가중 값을 새로이 한다.  $\mu\eta$ 는 학습률을 의미하며 상수 값인 0.01이나 0.001등의 미리 정해진 값을 사용한다.

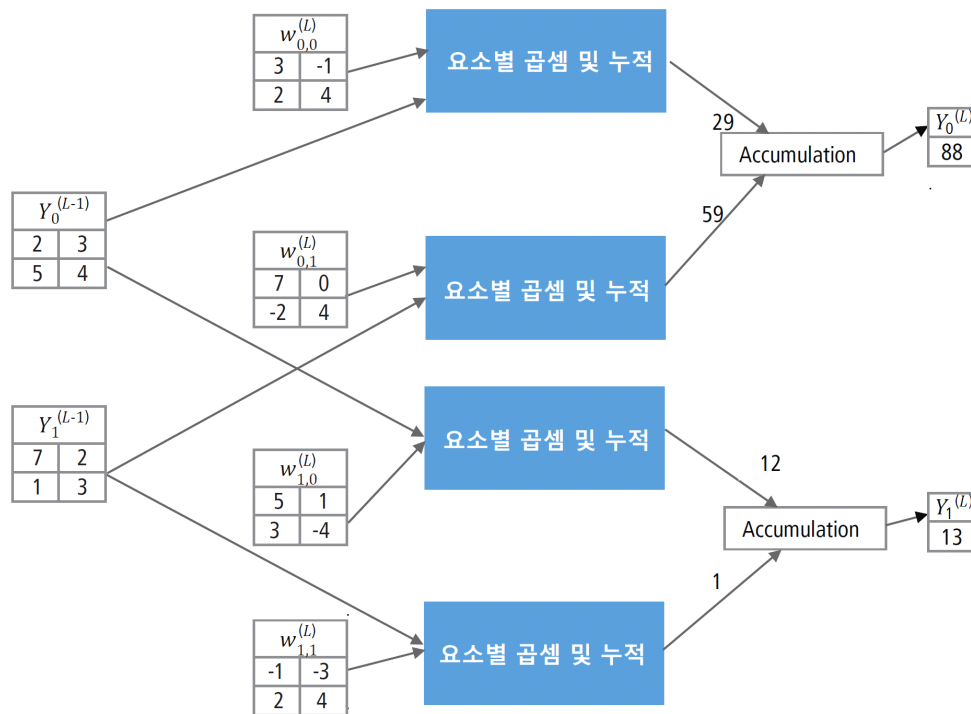


그림 2.12 완전 연결 층에 대한 연산 과정

Fig. 2.12 Computational process for fully connected layers

$$W \leftarrow W - \mu \frac{\partial O}{\partial W} \quad (3)$$

확률적 경사 하강법 알고리즘은 지역 극소량 (Local Minima) 문제와 느린 학습 속도를 갖는 단점이 있다. 이러한 문제점을 보완한 방법은 순간기반 최적화 (Moment

Based Optimization)이다. 이 방법은 현재시간  $\frac{\partial O}{\partial W^{(t)}}$ 에는 가장 높은 중요도를, 그 이전 시간  $\frac{\partial O}{\partial W^{(t-1)}}$ 에는 두 번째로 높은 중요도를 가지는 방식으로 이전 시간의 모든  $\frac{\partial O}{\partial W}$ 을 고려하여 방향을 설정하도록 만든다.  $\alpha$ 는 보통 0.9이다

$$v \leftarrow \alpha v - \eta \frac{\partial O}{\partial W}$$

$$W \leftarrow W - v \tag{4}$$

인공신경망에서 나타나는 과적합 (Overfitting)문제를 합성곱신경망에서는 드롭아웃으로 해결한다. 그림 2.13의 (b)와 같이 드롭아웃 (Dropout)은 입력 층과 은닉 층의 노드 중 일부분을 학습에서 배제함으로써 전체 신경망이 하나의 입력에 대해서 반응하는 것을 방지함으로써 특정 입력에 과적합 되지 않도록 하는 방법이다. 선택된 노드는 입력되는 가중 값과 출력되는 가중 값 정보까지 모두 삭제되기 때문에 남아 있는 노드만 학습에 참가하게 된다. 이 방식을 통하여 하나의 인공신경망 구조 위에 여러 개의 다른 인공신경망 구조를 가깝게 접근시켜 결합하는 방법을 제공한다.

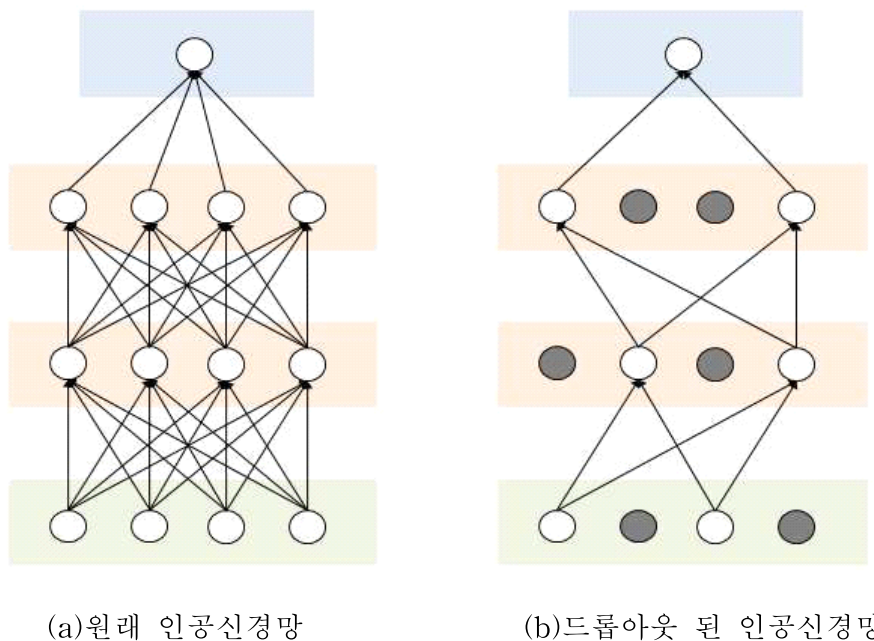


그림 2.13 드롭아웃이 적용된 신경망  
Fig. 2.13 A neural network with dropout applied

그 외에도 적응 경사법 (Adaptive Gradient, Adagrad), RMSprop (Root Mean Squared propagation), Adam(Adaptive Momentum Estimation)과 같은 다양한 최적화 방법을 이용하여 기존 인공신경망의 문제점을 해결한다 [16, 17].

### 2.3 합성곱신경망과 초분광영상 분석

합성곱신경망은 고수준의 공간분광 특징을 추출할 수 있어 영상 분류 분야에서 두각을 나타내고 있으며, 초분광영상에 대해서도 적용이 가능하다. 합성곱신경망을 이용하여 초분광영상의 연속적인 분광 응답 함수 (Spectral Response Function)를 학습함으로써 기존의 전통적인 분류 기법보다 우수한 성능을 보여주는 연구가 있다 [18]. 초분광영상의 한 픽셀과 주변 픽셀을 포함하는 패치 (Patch)를 사용한 모델을 제안하여 효율적이고 높은 정확도의 분류 결과를 보인 사례가 있다 [19]. 또한, 3차원 커널(3D Kernel) 기반의 3D-CNN을 초분광영상의 3차원 데이터 큐브(Data Cube)에 적용하여 공간-분광 특징을 효과적으로 분석한 연구가 진행되었다 [20]. 이러한 기존 연구들은 합성곱신경망을 통하여 많은 양의 데이터를 효과적으로 처리함과 동시에 깊은 층을 통한 추상화된 새로운 내부 표현을 사용할 수 있기 때문에 초분광영상을 효과적으로 처리할 수 있음을 보여주는 것이다, 이 외에도 심층신경망에 주성분 분석을 사용하여 학습데이터에 대한 차원을 축소함으로써 학습시간을 감소하는 연구 [21]과 같이 심층신경망과 기존의 분석방법을 결합하는 연구도 이루어지면서 심층신경망을 이용한 초분광영상의 분석이 더욱 활발해질 것으로 보인다.

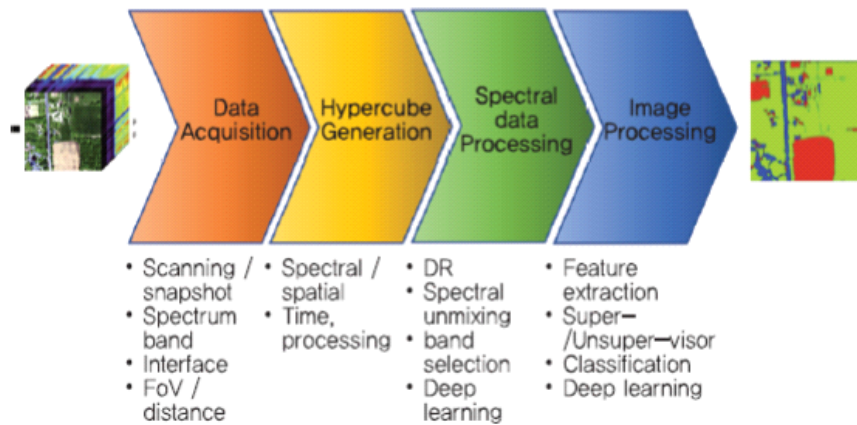


그림 2.14 초분광영상의 분석 절차

Fig. 2.14 The analysis procedure of hyperspectral images

초분광영상 데이터는 그림 2.14와 같이 데이터 수집, 초분광 큐브 생성, 초분광영상 데이터 처리, 특징 값 추출의 이미징 분석 절차를 따른다 [5].

초분광 큐브의 정량적 반사에너지 혼합화소 (Mixed Pixel)를 분석하는 분광 혼합 분석 (Spectral Unmixing)은 엔드멤버의 합과 독립적 스펙트럼을 분석하는 선형 분광 혼합분석 (Linear SU) 방식과 특성도출 어려운 엔드멤버의 비선형 조합을 분석하는 비선형 분광 혼합분석 (Non Linear SU) 방식으로 구분할 수 있다. 수행과정은 차원 축소 (Demension Reduction, DR)를 통해 노이즈를 제거하고 비지도 학습 (PCA, LDA)을 한다. 엔드멤버 도출 (End-Member Detection)은 동시 (Simultaneous) 알고리즘과 순차 (Sequence) 알고리즘을 이용한 N-Finder를 통해 도출한다. 초분광영상은 미지의 한 픽셀을 클러스터에 할당해 다른 픽셀정보와 구분하고 유사성에 따라 공간상 경계를 분류 (Classification)한다. 단순하게 스펙트럼의 특성을 분류하는 스펙트럼 분류와 인접한 픽셀의 공간의존성을 고려해 나누는 분광 공간 분류로 구분한다.

초분광영상 학습 방법에는 SVM (Support Vector Machine)이나 ELMs (eXtreme Learning Machine) 등으로 잘 알려진 훈련 샘플 데이터를 이용해 분류하는 지도 학습 (Supervised Learning) 방법과 SDS (Spectral Distance Similarity), k-means 알고리즘, SCS (Spectral Correlation Simi Similarity) 등 훈련 샘플 데이터 없이 픽셀 스펙트럼의 유사성에 의존해 군집화 (Clustering)하는 비지도 학습 (Unsupervised Learning) 방법이 있다. 밴드 선택 (Band Selection)을 통해 계산의 복잡성을 낮추고 중복 데이터 제거한 후 웨이블릿 변환으로 불필요 이미지 밴드를 제거한다. 또한 유사도 전파 알고리즘을 활용한 피쳐 선택 접근법으로 대표 밴드를 선택한다. 대용량 초분광영상 데이터의 저장, 전송, 분석, 처리를 위해 데이터 압축을 한다. 압축 방법으로는 손실 (lossy)압축, 무손실 (lossless)압축, 하이브리드 (hybrid)압축이 있다.

딥러닝 기반 초분광영상 데이터 분석 기술을 이용하여 신경망 층을 깊게 구성하여 복잡하고 비선형적인 입력신호에 높은 성능을 나타낸다. 외부영향에 불변하고 식별 가능한 특성들을 점진적으로 학습해 Low-level 특징 도출하여 높은 성능을 제공한다. 식별 (Labeled) 데이터의 모델 학습해 입력데이터 판단하여 분광공간을 분류 (Classification) 하고, 비식별 (Unlabeled)데이터를 같은 특성으로 묶어 그룹화 후에 군집화 (Clustering) 한다. SAE (Stacked Auto Encoder)나 DBN (Deep Belief Network)으로 은닉층을 학습하고 로지스틱 회귀 (Logistic Regression, LR) 분류기 등 연결해 데이터 분류를 한다. 또한 CNN 기반 (1-D, 2-D, 3-D)의 분광공간 분류기를 통해 기 식별정보로 모델을 학습하고 분류한다. 전처리 (Preprocessing)는 전통적인 PCA-CNN, Gabor-CNN 등으로 한다.

초분광영상의 해상도 개선은 단일 이미지 센서의 부화소 이동(Sub Pixel Shift) 딥러닝을 이용해 고해상도 이미지로 변환하는 초고해상도(Super Resolution) 방법이 있다. 여기에는 DSD-CNN (Deep Spectral Difference CNN), 3D-FCNN (3D Full CNN)과 SAE 기반의 S-MSDA (Stack Modified Sparse De-noising Autoencoder) 등의 기술이 있다. 고해상도 총 천연색 영상과 저해상도 초분광영상을 융합해 학습하는 영상 융합 (Pan Sharpening) 방법이 있으며 Super Resolution CNN을 이용해 미세 조정 (Fine Tuning)을 하며, 그림 2.15와 유사한 전이 학습 (Transfer Learning)을 한다.

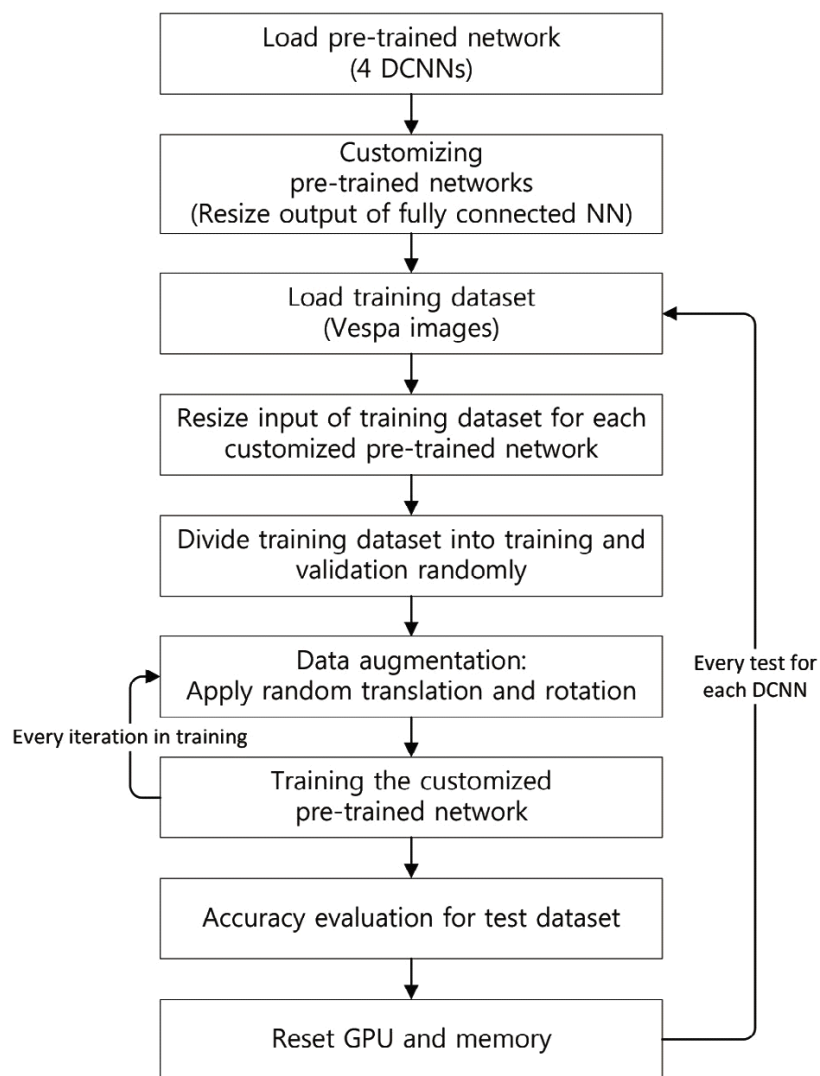


그림 2.15 전이 학습 과정

Fig. 2.15 The process of the transfer learning



CNN기반 비선형적 분광혼합 특성을 모델링해 초분광 혼합 분석을 한다. 3D-CNN을 통해 초분광 큐브형태를 입력 받아 심층 컨볼루션을 통해 특징을 추출한다. 합성 학습 데이터 생성하여 대용량의 학습 데이터 확보한다. 또한 GAN (Generative Adversarial Network)을 이용하여 학습 데이터 생성 후 딥러닝 모델을 학습한다.

초분광영상 분석 기술은 대용량의 초분광 큐브 데이터 왜곡과 인접대역 상관관계에 따른 데이터 중복성, 차원의 저주 (Curse of the Dimensionality), 시그니처의 가변성 등의 복잡한 문제가 존재한다.

### III. 초분광영상 분석을 위한 합성곱신경망

그림 3.1에서 본 논문에서 제안한 합성곱신경망의 구조를 보여준다. 제안신경망은 입력 층의 노드 수는 입력되는 초분광영상의 차원을 나타내며, 출력 층은 입력된 초분광영상이 가지는 토양의 수분함량을 표시한다. 따라서 학습된 제안신경망은 초분광영상을 입력받아 내부의 분석을 통하여 자동으로 토양수분량을 결정하게 된다.

제안된 합성곱신경망은 입력 층의 노드는 125개 (각 초분광영상의 대역 수)이고 출력 층은 입력 초분광영상이 나타내는 토양수분량을 소수의 형태로 표현하기 위하여 정수부분 출력용 1개와 소수부분 출력 1개로 구성되며 각 노드는 0에서 1사이의 값을 표현한다. 입력 초분광영상의 수분함량이 40.34%인 경우, 정확하게 인식이 되면 정수부분 출력노드에는 0.4가 출력되고 소수부분 출력노드에는 0.34가 출력된다. 입출력 층 사이에는 3개의 합성곱 층과 1개의 인식 층이 존재한다. 각 합성곱 층은 합성곱을 수행하는 층과 풀링 (Pooling) 층 2개로 구성된다. 첫 번째 합성곱 층은 입력 이미지를 3×3 크기의 필터 32개를 통해 합성곱 연산을 수행하여 32개의 내부 특징 맵을 구성한다.

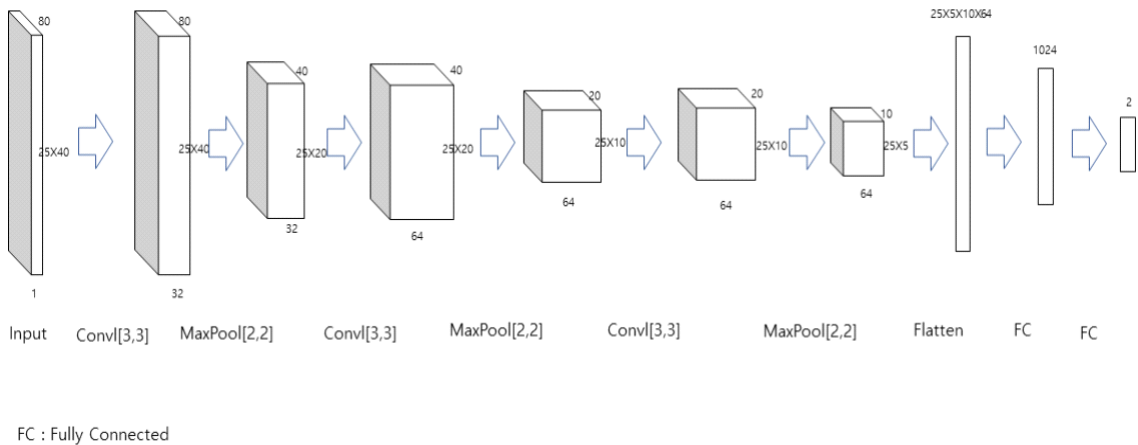


그림 3.1 제안된 합성곱신경망 구조  
Fig. 3.1 The architecture of the proposed CNN

0	0	0	0	0	0	0	0	0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0	0	0	0	0	0	0	0	0

그림 3.2 제로 패딩  
Fig. 3.2 Zero-padding

첫 번째 합성곱 층에 연결된 풀링 층은 2×2의 블록 단위로 합성곱 결과 맵의 크기를 500×40 크기의 32개 특징 맵으로 만든다. 그림 3.2처럼 두 번째 합성곱 층에서는 패딩 (Padding)에 그림 3.3과 같이 스트라이드 (Stride) 1씩 이동하는 3×3 크기의 필터 64개를 사용해서 500×40 크기의 특징 맵 64개를 만든다. 생성된 특징 맵은 두 번째 합성곱 층에 속한 풀링 층에 의해서 250×20 크기로 조정된다. 세 번째 합성곱 역시 3×3 크기의 필터 64개로 구성되기 때문에 연결된 풀링 층을 최종 통과한 결과는 64개의 125×10 크기의 특징 맵을 만든다. 이런 다양한 합성곱의 변환을 통하여 순환 기하학 변환을 해결한다. 최종적으로 얻어진 64개의 125×10 크기의 특징 맵은 인식 층에 해당되는 다층 신경망에 입력되어 결과를 얻는다.




그림 3.3 스트라이드 1 이동 (필터 창이 각 연결에 대해 한 번만 이동)  
Fig. 3.3 Stride 1, the filter window moves only one time for each connection

#### IV. 구현 및 실험 결과 분석

##### 1. 실험 환경 및 데이터 수집

제안하는 합성곱신경망은 GPU (Graphics Processing Unit)가 설치된 Ubuntu 16.04.6 LTS를 운영체제로 하는 서버에서 구현된다. 입력 영상을 위한 처리 및 합성곱 신경망의 구현은 Python 2.7.15rc1 프로그래밍 언어와 텐서플로우 1.13.1 (Tensorflow 1.13.1)을 이용한다.

표 4.1 실험에 사용된 컴퓨팅 환경

Table 4.1 Computing environments for experiments

구분	사양
운영체제	Ubuntu 16.04.6 LTS
CPU	i7-8700 CPU @ 3.20GHz × 12 Core
GPU	GTX 1070 Ti × 1 EA
메모리	64 GB

제안하는 합성곱신경망의 성능 비교를 위하여 기존의 텍스처 분석에 사용된 두 개의 합성곱신경망인 그림 4.1의 AlexNet [23]과 그림 4.2의 VGG16 [24]을 구현하고 사용한다. 비교 시스템은 전체적인 구조는 유지하면서 입력 층과 최종 출력 층의 구조는 입력영상에 맞게 수정한다.




그림 4.1 AlexNet의 구조

Fig. 4.1 The structure of AlexNet





그림 4.2 VGG16의 구조  
Fig. 4.2 The structure of VGG16

제안시스템과 비교 시스템 모두 활성화 함수로 ReLU를 사용하며, 이웃 커널 값을 고려하여 합성곱 결과를 조정하는 지역 반응 정규화와 드롭아웃 (Dropout)을 통하여 과적합 (Overfitting)을 방지한다. 제안한 시스템의 성능분석을 위하여 [4]에서 제공하는 토양수분 초분광영상 데이터 세트 (Dataset)가 사용된다. 실험에 사용한 데이터 세트는 4일간 2분 간격으로 대상 토양에 대해서 454nm부터 950nm 대역을 4nm로 분할하여 125개의 대역밴드를 가지는 679개의 영상으로 구성된다. 학습을 위하여 각 초분광영상에 대한 실제 수분함량 (%)과 온도정보 (°C)를 제공한다. 총 679개 중에서 250개를 학습에 사용하고 429개는 테스트 데이터로 사용한다. 학습데이터는 제안 신경망과 비교 시스템을 모두 학습 하는데 사용한다. 학습에서는 초분광영상의 전체 밴드를 모두 사용하기 때문에 입력에 대한 전처리 (Preprocessing)가 필요하지 않다. 따라서 찾고자 하는 정보를 가진 특정 스펙트럼 대역을 찾는 노력 또한 필요하지 않다.

## 2. 실험 결과 및 분석

실험 결과 3가지의 합성곱신경망 모두 실험에 사용한 초분광영상을 잘 학습하고 우수한 일반화 능력을 보인다. 3개 시스템 모두 96%이상의 결과를 보인다. 가장 우수한 분석능력을 보인 것은 VGG16이고 그 다음이 AlexNet이며 제안 시스템이 상대적으로 낮은 분류 능력을 보였다.

표 4.2 실험결과  
Table 4.2 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%

이렇게 제안시스템이 비교시스템에 비교하여 분류능력이 가장 낮게 나오지만 제안 시스템은 비교 시스템에 비하여 구조가 단순하기 때문에 빠른 학습이 가능하고 분류속도 역시 빠르다는 장점을 보인다. 분류 능력에 있어서도 VGG16과 비교하여 2%이내의 차이를 보인다. 따라서 학습·분류 효율성과 분류능력을 모두 고려할 경우 제안시스템이 초분광영상을 효율적으로 분류·인식하고 있음을 보여주는 것이다.

표 4.3 시스템의 사양  
Table 4.3 Configurations of systems

시스템 명	제안시스템	AlexNet	VGG16
학습 파라미터 수 (weights)	51,020	120,000	276,000

인식율에 있어서는 제안시스템이 비교시스템에 비교하여 가장 낮게 나오지만 표 4.3처럼 제안 시스템은 비교 시스템에 비하여 단순한 구조를 가진다. 이렇게 적은 수의 학습 파라미터로 인하여 비교시스템에 비하여 그림 4.3의 학습 소요 시간이 짧아 학습과정이 빠르게 진행되는 장점이 있다. 이런 장점과 함께 분류능력에 있어서도 VGG16과 비교하여 2%이내의 차이를 나타내고 있다. 따라서 학습 효율성과 분류능력을 모두 고려할 경우 제안시스템은 초분광영상을 통한 수분함량 분석에 효과적으로 사용이 가능하다.

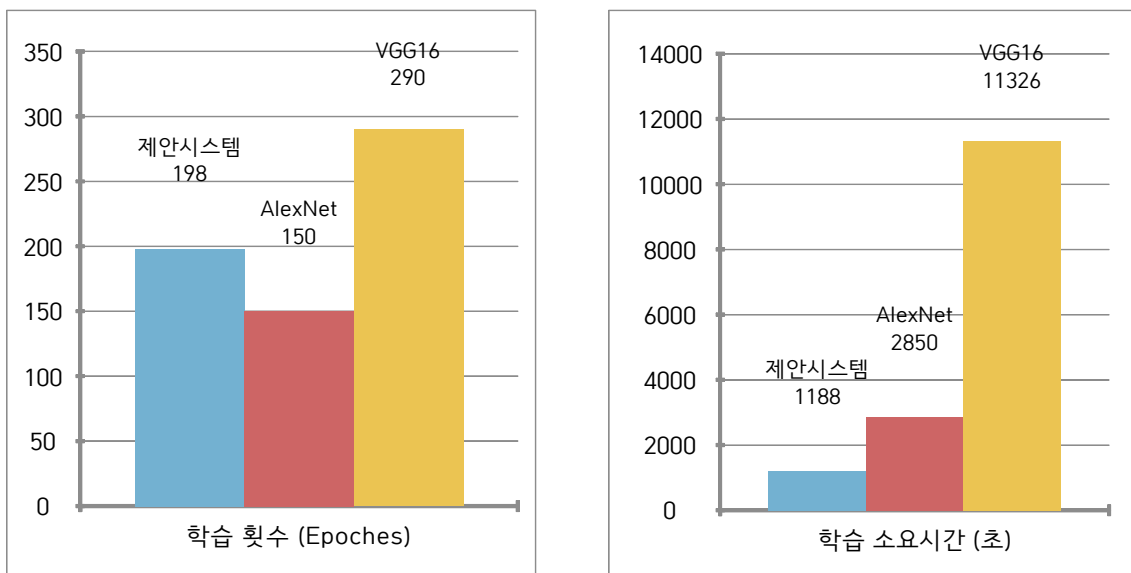


그림 4.3 제안시스템과 비교시스템의 학습 횟수와 소요시간

Fig. 4.3 Learning epoches and times for the proposed and the compared systems

## V. 결론 및 향후 연구 방향

본 논문에서는 토양의 수분량을 초분광영상을 이용하여 효과적으로 분석할 수 있는 새로운 합성곱신경망 방법을 제안하였다. 제안한 합성곱신경망은 토양수분량 측정을 위해 많은 스펙트럼 밴드로 구성된 서로 다른 초분광영상에서 나타나는 스펙트럼 밴드별 변화를 잘 학습하여 높은 인식률을 보였다. 합성곱신경망을 사용하여 측정된 전체 스펙트럼 밴드영역을 모두 사용하기 때문에 다른 연구와는 달리 입력에 대한 전처리 과정이 필요치 않은 장점이 있다.

제안시스템의 성능 비교와 평가를 위하여 AlexNet과 VGG16을 제안시스템과 같은 방법으로 학습시키고 인식을 수행하였다. 실험을 통하여 제안시스템은 비교시스템에 비해서는 인식률이 낮았으나, 효율적인 구조로 인하여 학습 및 인식시간에서는 보다 나은 우수한 분류 성능을 보였다. 제안시스템을 통하여 합성곱신경망이 초분광영상을 효과적으로 학습할 수 있음을 보였기 때문에 여러 식물의 생육정보 분석 등 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 농업 이외의 많은 응용분야에 적용될 수 있으며, 향후 인공지능 기술은 초분광영상 촬영 장치를 통해 수집된 자료이외에 가시광선, 적외선, 근적외선, 단파적외선 영상과의 유기적인 결합을 통하여 입력을 추가하고 신경망 프로세스를 개선하여 분석 전반에 활용될 가능성이 높아 보이며 이에 대한 다양한 인공지능 분석기법 연구가 진행되어야 할 것이다.



## VI. 참고 문헌

- [1] T. Lillesand, R.-W. Kiefer and J. Chipman, Remote sensing and image interpretation, John Wiley & Sons, Hoboken, 2015.
- [2] 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, Jan. 2018.
- [3] 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.
- [4] Felix M. Riese and Sina Keller, "Hyperspectral benchmark dataset on soil moisture," doi.org/10.5281/zenodo.1227837, 2018.
- [5] 이문섭 · 김거식 · 민기현 · 손동훈 · 김정은 · 김성창, 초분광 이미징 기술동향, 한국전자통신연구원, 34권 1호(통권 175), pp. 86 - 97, 2019.
- [6] A. F. H. Goetz, "Three Decades of Hyperspectral Remote Sensing of the Earth: a Personal View", Remote Sensing Environment, vil. 113, no. 1, pp. 5-16, 2009.
- [7] 지명근 · 전준철, 딥 러닝을 이용한 영상 인식 기술 동향, 한국 인터넷 정보학회 (제18권 제2호), pp.26-33, 2017.
- [8] 도용태 · 김일곤 · 김종완 · 박창현 · 강병호, 인공지능 : 개념 및 응용 4판, 사이텍 미디어, 2014.
- [9] Samer Hijazi, Rishi Kumar, and Chris Rowen, "Using Convolutional Neural Networks for Image Recognition", IP Group, Cadence, 2015.  
[http://www.multimediacdocs.com/assets/cadence\\_emea/documents/using\\_convolutional\\_neural\\_networks\\_for\\_image\\_recognition.pdf](http://www.multimediacdocs.com/assets/cadence_emea/documents/using_convolutional_neural_networks_for_image_recognition.pdf)
- [10] Geoffrey E. Hinton, Simon Osindero and Yee-Whye The, "A Fast Learning Algorithm for Deep Belief Nets", Neural Computation archive Volume 18 Issue 7(July 2006), pp.1527 - 1554, 2006.
- [11] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks", Vol. 313, Issue 5786(Science 28 Jul 2006), pp.

504-507, 2006.

- [12] Shiliang Zhang, Yebo Bao, Pan Zhou, Hui Jiang and Lirong Dai, “Improving deep neural networks for LVCSR using dropout and shrinking structure”, 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2014.
- [13] Geoffrey E. Hinton, Nitish Srivastava, Alex Krizhevsky, Ilya Sutskever and Ruslan R. Salakhutdinov, “Improving neural networks by preventing co-adaptation of feature detectors”, Department of Computer Science University of Toronto, 2012.
- [14] V. Slavkovikj, 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.
- [15] 이건명, 인공지능:튜링 테스트에서 딥러닝까지, 생능출판사, 2018.
- [16] 니컬 부두마, 딥러닝의 정석:텐서플로와 최신 기법으로 배우는 딥러닝 알고리즘 설계, 고평원·금경목 역, 한빛미디어, 2018.
- [17] 마사 모라디·이태삼, 수문학적 예측을 위한 딥러닝기반 인공지능경망의 최적화 알고리즘 비교: 남강댐 일유출량을 사례를 중심으로, 제18권 6호 2018년 10월, 한국방재학회, pp. 377-384, 2018.
- [18] 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.
- [19] 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. 38-447, 2017.
- [20] 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, China, Sep. 17-20, pp. 3904-3908., 2017.

- [21] 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.
- [22] 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*, vol. 1, pp. 1097–1105, 2011, <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
- [23] Karen Simonyan, Andrew Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, a conference at ICLR, pp. 1–14, 2015, <https://arxiv.org/pdf/1409.1556.pdf>