

논문 2019-2-8 <http://dx.doi.org/10.29056/jsav.2019.12.08>

합성곱신경망을 이용한 제주도 강수패턴 분석 연구

이동훈*, 이봉규*†

A Study on the Analysis of Jeju Island Precipitation Patterns using the Convolution Neural Network

Dong-Hoon Lee*, Bong-Kyu Lee*†

요 약

제주는 농업과 관광이 절대적 비중이므로 강수에 대한 예측/분석은 다른 지역보다 더 중요한 요소로 작용한다. 현재 제주도의 강수 예측은 기상위성을 통해 얻어지는 관측데이터에 수치모델을 이용하나, 다른 지역보다 강수 현상에 대한 변화가 다양하므로 기존의 일반적인 수치모델을 그대로 적용하여 강수 예측/분석을 하기는 쉽지 않고 만족할만한 결과를 얻기가 어렵다. 따라서 제주지역에 맞는 새로운 제주 예측/분석 방법이 연구되어야 할 것이다. 본 논문에서는 합성곱신경망 (Convolution Neural Network, CNN) 기반의 텍스처 (Texture) 분석기법을 이용한 제주 강수패턴 분석 방법을 제안한다. 제안하는 방법은 기상위성에서 획득한 제주도 영역에 대한 수증기영상과 지역의 온도정보를 텍스처 영상으로 변환한 후, 변환된 영상들을 합성곱신경망을 이용하여 강수 여부를 분석하는 방법이다. 제안한 방법을 구현하고 실험을 통하여 제안된 방법의 유효성을 보인다.

Abstract

Since Jeju is the absolute weight of agriculture and tourism, the analysis of precipitation is more important than other regions. Currently, some numerical models are used for analysis of precipitation of Jeju Island using observation data from meteorological satellites. However, since precipitation changes are more diverse than other regions, it is difficult to obtain satisfactory results using the existing numerical models. In this paper, we propose a Jeju precipitation pattern analysis method using the texture analysis method based on Convolution Neural Network (CNN). The proposed method converts the water vapor image and the temperature information of the area of Jeju Island from the weather satellite into texture images. Then converted images are fed into the CNN to analyse the precipitation patterns of Jeju Island. We implement the proposed method and show the effectiveness of the proposed method through experiments.

한글키워드 : 강수패턴, 합성곱신경망, 텍스처, 기상위성, 제주지역

keywords : Precipitation, Convolution NN (Neural Network), Texture, weather satellite, Jeju

* 제주대학교 전산통계학과

† 교신저자: 이봉규(email: bkleee@jejunu.ac.kr)

접수일자: 2019.10.23. 심사완료: 2019.12.09.

게재확정: 2019.12.20.

1. 서론

기상은 재해를 동반할 수 있는 자연현상으로

우리 사회의 안전을 지키고 원활한 삶을 꾸려나가기 위해서는 정확한 예측이 필요한 분야이다. 태풍이나 홍수와 같은 것들은 우리에게 직접적인 위협요소이기 때문에, 이에 대한 정확한 예측을 통하여 피해를 최소화하고 인명을 보호하는 것은 매우 중요한 일이다. 이런 이유로 세계 각국은 기상에 대한 정확한 예측을 위한 기구를 두고 기상에 대한 정확한 예측을 위한 다양한 연구와 노력을 진행하며, 그 중요성이 점차 증가하는 추세다. 그리고 기후는 에너지, 여행·레저, 보험업, 농업, 유통, 해운 등 산업 전반에 영향을 주기 때문에 기상에 대한 정보와 분석은 미래의 중요산업 중 하나로 인식된다. 기상산업은 기상관련 상품을 제조·공급하거나 용역을 공급하는 산업으로 기상 예보, 기상 감정, 기상 컨설팅, 기상장비 산업 등으로 구성된다.

기상 중에서 강수는 대기 중의 수분이 액체 또는 고체가 되어 지표면에 낙하하는 현상을 말하는데 우리 생활 전반을 지배하는 중요한 요소이다. 특히, 생활을 꾸려나가는 데 필요한 식량이나 자원의 생산에서부터, 관광 및 레저 활동, 재해 발생 등 직접적 영향을 미치는 요소이다. 따라서 강수를 정확히 예측하기 위한 다양한 정보수집과 분석은 매우 중요한 분야이다. 우리나라에서는 현재 강수 예측을 위한 정보수집을 위하여 기상 위성 (천리안 1, 2)을 활용한다. 기상위성은 태양, 지구, 대기로부터 복사되는 전자파의 복사량을 복사계로 측정하는 관측기로, 기상(氣象) 상황을 관측한다. 강수 예측을 위한 정보로는 위성에서 관찰된 대류권 중상층의 수증기 분포를 영상화한 수증기영상 등을 이용한다. 수증기영상은 흰색 (구름영역), 회색 (수증기영역), 검은색 (건조영역)으로 정보를 표현하며, 이를 통하여 중상층의 대기 상태를 파악한다[1].

제주는 농업과 관광이 절대적 비중이므로 강수에 대한 예측/분석은 다른 지역보다 더 중요한

요소로 작용한다. 그러나 제주도는 국내에서 유일하게 연평균기온이 15℃ 이상인 아열대 기후를 보이는 곳이며, 중심에 1,950m 높이의 한라산이 있어 고도에 따른 다양한 기상현상이 나타난다. 시베리아 기단, 태풍, 이동성 기압 등이 제주도를 통과할 때 한라산 지형의 영향으로 다양한 일기 패턴을 생성하는 것이다[2]. 현재 제주도의 강수 예측/분석은 기상위성을 통해 얻어지는 관측데이터에 수치모델을 이용하나, 다른 지역보다 강수 현상에 대한 변화가 다양하므로 기존의 일반적인 수치모델을 그대로 적용하여 강수 예측/분석을 하기는 쉽지 않고 만족할만한 결과를 얻기가 어렵다. 따라서 제주지역에 맞는 새로운 예측/분석 방법이 연구돼야 할 것이다.

본 논문에서는 합성곱신경망 (Convolution Neural Network, CNN) 기반의 텍스처 (Texture) 분석기법을 이용한 제주 강수패턴 분석 방법을 제안한다. 제안하는 방법은 기상위성에서 획득한 제주도 영역에 대한 수증기영상과 지역의 온도정보를 텍스처 영상으로 변환한 후, 변환된 영상들을 합성곱신경망을 이용하여 강수 여부를 분석하는 방법이다. 제안한 방법은 기존의 수치모델을 이용하는 방법과는 달리 인간의 인지적인 능력에 기반을 둔 신경망방법을 이용함으로써 인간의 시각이나 단순 수치모델로 찾기 어려운 강수 여부에 대한 텍스처 패턴 변화를 감지하는 방법이다. 제안한 방법을 프로그램으로 구현하고 실제 기상위성 관측데이터를 통한 실험을 통하여 제안 방법의 유효성을 보인다.

2. 합성곱신경망과 텍스처 분석

2.1 합성곱신경망 (CNN)

영상패턴 분류를 위한 기존의 인공신경망은

주어진 영상으로부터 분류에 필요한 특징을 사람이 수작업으로 데이터 전처리 및 가공을 통해 사전에 추출한 후, 이 특징을 입력으로 하여 분류기만을 기계 학습한다. 따라서 학습데이터가 방대할 경우, 효과적으로 패턴인식 시스템을 설계하는 것이 매우 어려운 일이다. 이런 문제점을 해결하기 위해 그림 1에서 보듯이 합성곱신경망은 특징추출과 인식을 통합하여 처리하는 형태를 가진 새로운 신경망이다. 합성곱신경망은 입력 영상을 그대로 입력 층에 제공함으로써 별도의 특징추출 과정이 필요 없다[3, 4].

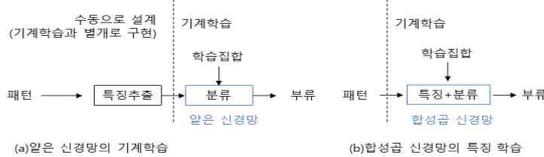


그림 1. 합성곱신경망과 기본신경망
Fig. 1. CNN and Traditional NN

합성곱신경망의 구조는 내부특징추출을 목적으로 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 인식작업에 사용된다.

합성곱신경망의 학습은 기존의 신경망에서 사용하는 오류 역전파 알고리즘이 사용된다. 그러나 합성곱신경망에서 사용하는 오류역전파 학습은 기존의 신경망과는 차이가 있다. 기존의 인공

신경망에서는 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 추정할 수 있는 장점이 있다[5].

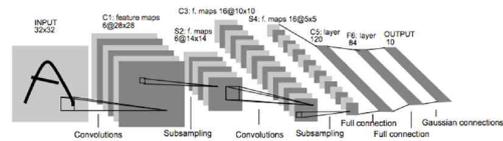


그림 2. 합성곱신경망 구조
Fig. 2. The architecture of CNN

2.2 텍스트 분석과 합성곱신경망

텍스처는 상호 관련된 요소들로 구성된 물체 표면의 조직구조를 의미하는 것으로, 영상 내의 부드러움 (Smoothness), 거침 (Coarseness), 규칙성 (Regularity) 등으로 영상의 표면을 규정하는 방법이다. 텍스처는 패턴을 분류/인식하는 특징으로 효과적으로 사용될 수 있기 때문에 다양한 분석기법이 제안되었다. 먼저 구조적 방법은 텍스처를 구성하는 기본 요소가 되는 텍셀(Texture)을 추출하고 텍셀의 공간적 배열 규칙을 구문문법으로 기술하는 방법이다[6]. 그러나 다양한 자연현상에서는 기본 요소인 텍셀을 정의하거나 추출하기가 어렵고, 찾아진 텍셀의 구조적 관계를 문법으로 표현하기가 쉽지 않기 때문에 효과적으로 사용이 어렵다. 또 다른 방법으로는 통계적 접근법이 있다. 이 방법은 텍스처로부터 히스토그램, 분산 값 및 모멘트 등과 같은 통계적 수치값을 추출하여 분류에 사용하는 방법이다[6]. 그러나 이 방법 역시 분류대상인 텍스처 영상들에 대한 면밀한 분석을 통하여 특징이나 규칙성을 찾아주는 작업이 필요하기 때문에 일반화된 분류

기법이 될 수 없다. 이에 따라서 현재 학습을 통하여 텍스처를 자동으로 분류하는 기능을 가진 합성곱신경망을 사용하는 방법이 활발히 연구되고 있다.

합성곱신경망은 다양한 텍스처에 대해서 일반화하여 사용이 가능한 방법으로 인식된다. 학습을 통하여 텍스처 분석과 분류를 하나의 구조에서 구현이 가능하면서 우수한 분류능력을 보이고 있다[7]. 이런 배경을 바탕으로 합성곱신경망인 LeNet-5에 기반을 둔 CoNN(Convolutional Neural Network)을 이용한 텍스처를 분석하는 방법이 제안되었다[8]. 제안된 CoNN은 Brodatz 데이터베이스[9]에 있는 이미지를 대상으로 한 분류실험에서 일반화가 가능하면서도 기존의 분석적인 방법과 유사한 성능을 나타내고 있다. 또한 Luiz G. Hafemann와 2명은 합성곱신경망으로 산림의 종류를 분류하는 합성곱신경망을 제안하고 성능을 보임으로써 합성곱신경망의 우수성을 보였다[10]. 이렇게 합성곱신경망은 기존의 방법에서 찾을 수 없는 일반화 기능을 가지면서 분류 능력 역시 우수한 것으로 나타난다. 따라서 본 연구에서는 제주 강수 패턴을 텍스처로 가정하고 합성곱신경망을 이용한다.

3. 제주 강수패턴 분석을 위한 합성곱신경망

본 논문에서는 수증기와 온도에 대한 위성 영상을 합성곱신경망을 통하여 분석하는 방법을 제안한다. 위성에서 얻어진 수증기 영상과 온도 영상을 분류하는 것을 텍스처 분석으로 정의하고, 강수 여부에 관한 판단을 합성곱신경망을 통하여 결정하는 방법이다.

수증기 영상과 날씨 정보를 이용해서 생성된 영상을 합성곱신경망에 입력으로 사용하기 위한

진처리 과정은 다음과 같다. 먼저 천리안위성으로 관측된 시간대별 한반도 영역의 수증기 영상(1일 24개)에서 제주도 영역을 추출한다. 이 과정을 통하여 입력 영상의 크기를 줄임으로써, 합성곱신경망의 계산 부하를 줄이는 효과도 함께 가질 수 있다. 그림 3에서 보듯이 원 영상의 크기는 1024×1024이지만 실제 사용되는 영상은 40×80으로 제주지역을 대상으로 한다.

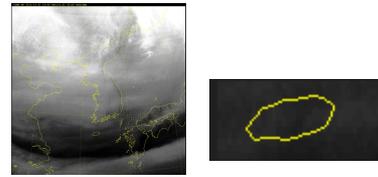


그림 3. 원 관측 영상과 추출영상
Fig. 3. The original image and the extracted image

또 다른 입력인 기온을 표현하는 영상은 시간대별로 (1일 24회) 측정된 제주도의 지역별 온도를 그레이 (Gray) 영상으로 표현한 것이다. 제주지역에서 공식적으로 온도를 관측하는 곳은 성산, 서귀포, 제주, 고산 네 곳이다. 이것을 바탕으로 한라산 중심 (한라산 백록담)까지의 고도에 따라서 10개 등고선 형태로 식 (1)을 사용하여 고도별 온도를 계산한다. 식(1)에서 p 는 계산되는 온도영상의 화소 값을 나타내며, d 는 제주도 4개 지역 (고산, 서귀포, 제주, 성산)에서 시간대별로 관측된 온도를 나타낸다.

$$p = \frac{d - i - (-20)}{40 - (-20)} \quad (1)$$

이 값은 시간 간격이 1시간보다 크면 대상이 되는 시간대들 온도의 평균을 사용한다. -20은 최저 기온이고 40은 최고 기온이다. i 는 외곽에서 중심까지 등고선을 나타내는 타원 10개로 구분되며, 중심방향으로 갈수록 -1℃ 낮아짐을 나타낸다. 계산된 p 의 값은 0에서 1까지의 범위로

정규화 한다. 이런 과정을 통하여 얻어지는 온도 영상 이미지의 예가 그림 4에 나타나 있다.



그림 4. 제주지역 온도영상 예
Fig. 4. An example of Jeju temperature images

제안한 합성곱신경망은 입력으로 수증기 및 온도에 관련된 2종류의 영상을 받아들인다. 따라서 특정 시간에 대한 합성곱신경망의 입력 이미지는 $[n \times 40, 80]$ 바이트 크기의 매트릭스가 된다. 너비 부분은 80픽셀로 고정이지만 깊이 부분은 40픽셀의 배수 크기로 가변이다. 실제 입력의 크기를 결정하는 입력영상 개수 n 은 식 (2)에 의해서 결정된다.

$$n = (w + \frac{w}{t}) \quad (2)$$

w 는 수증기 영상 개수를 나타내며 t 는 평균온도를 측정하는 시간 단위(시)를 나타낸다. 만약 1일에 대해서 매시간 당 수증기 영상 24개와 12시간 단위의 온도 영상 2개를 입력으로 사용할 경우에는 n 은 26이 되어 전체 입력 이미지 크기는 $[1,040(26 \times 40), 80]$ 의 크기를 가진다. 그림 5에서는 n 이 2인 경우 (5(a))와 n 이 4인 경우 (5(b))의 합성곱신경망의 입력영상을 보여준다.

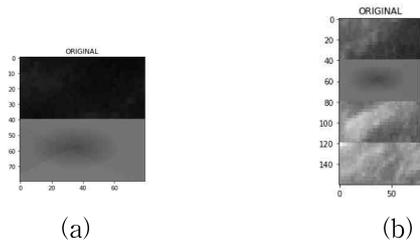


그림 5. 합성곱신경망 입력 영상 예
Fig. 5. Two examples of input images

그림 6에서 본 논문에서 제안한 합성곱신경망의 구조를 보여준다. 제안신경망은 입력 층의 노드 수는 입력되는 영상의 크기에 따라서 구현에서 가변적으로 구현되어야 한다. 그러나 구조에 대한 구체적인 기술을 위하여 입력영상의 크기는 n 이 25인 경우로 구조를 설명한다. 즉 제안된 합성곱신경망은 입력 층의 노드는 8,000 ($1,000 \times 80$)개이고 출력 층은 비 음과 맑음을 타나내는 2개의 노드로 구성한다. 입출력 층 사이에는 3개의 합성곱 층과 1개의 인식 층이 존재한다. 각 합성곱 층은 합성곱을 수행하는 층과 풀링 층 2개로 구성된다. 첫 번째 합성곱 층은 입력 이미지를 3×3 크기의 필터 32개를 통해 합성곱 연산을 수행하여 32개의 $1,000 \times 80$ 크기의 특정 맵을 구성한다. 첫 번째 합성곱 층에 연결된 풀링 층은 2×2 의 블록 단위로 합성곱 결과 맵의 크기를 500×40 크기의 32개 특징 맵으로 만든다. 두 번째 합성곱 층에서는 패딩에 스트라이드 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. 최종적으로 얻어진 64개의 125×10 크기 특징 맵은 인식 층에 해당되는 다층신경망에 입력되어 결과를 얻는다.

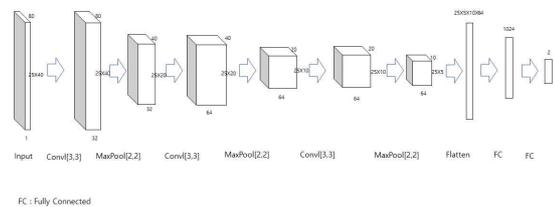


그림 6. 제안된 합성곱신경망 구조
Fig. 6. The architecture of the proposed CNN

4. 구현 및 실험 결과

제안한 합성곱신경망은 Ubuntu 16.04.6 LTS 운영체제 기반의 GPU (Graphics Processing Unit)가 설치된 워크스테이션에서 구현된다. 입력 영상을 위한 전처리 및 합성곱신경망의 구현은 Python 2.7.15rc1 프로그래밍 언어와 텐서플로우 1.13.1 (Tensorflow 1.13.1)을 이용한다. 수집되는 기상영상과 및 온도영상을 구성하는데 필요한 기본 기상데이터 및 관련 정보는 Sqlite 3.26.0 DB (Data Base)를 이용하여 관리한다. 수증기영상은 국가기상위성 센터에서 천리안위성이 제공하는 한반도 영역에서 15분 단위로 수집한 4년 (2015년 ~ 2018년)간의 데이터를 이용한다. 온도, 강수량 등에 관련된 기상정보는 오픈 API를 통하여 수집한다. 제안하는 합성곱신경망의 성능 비교를 위하여 기존의 텍스처 분석에 사용된 두 개의 합성곱신경망인 Alexnet[11]과 VGG16[12]을 구현하고 사용한다. 비교 시스템은 전체적인 구조는 유지하면서 입력 층과 최종 출력 층의 구조는 입력영상에 맞게 수정한다. 제안시스템과 비교 시스템 모두 활성화 함수로 ReLU를 사용하며, 이웃 커널 값을 고려하여 합성곱 결과를 조정하는 지역 반응 정규화와 과적합 방지를 위해 드롭아웃 (Dropout)을 사용한다.

3가지 모델에 대하여 수증기 및 온도 영상을 이용한 분류 실험을 다음과 같이 실행한다. 전체 데이터를 훈련용과 테스트용으로 25대 75의 비율로 분류한다. 이때 훈련용으로 분류된 데이터에는 강우가 있는 경우와 없는 경우를 50대 50의 비율이 되도록 하여 훈련데이터의 양 차이에 따른 학습에서의 바이어스 (bias)를 제거한다. 학습에 대한 구체적인 내용 및 인식률이 표 1에 나타나 있다. 먼저 강수여부에 대한 조건으로는 기상청에서 사용하는 기준인 0.1mm이상으로 설정한다. 그리고 시간대별 온도 및 수증기 영상 사용

빈도에 따라서 통 8번의 학습이 진행된다. 개개의 학습이 완료된 후, 학습 데이터를 이용하여 8가지의 학습을 수행하고, 각각의 학습에 따른 인식률을 측정한다. 8가지의 실험은 같은 형태의 수증기 영상에 온도영상의 숫자를 다르게 사용하는 방법으로 구별한다. 수증기의 경우는 시간에 따른 변화가 크기 때문에 1시간 단위의 사용을 했으나, 온도의 경우는 변화폭이 수증기영상과 같이 크지 않기 때문에 적절한 시간대별 영상을 찾아내는 것이 중요하기 때문이다. 학습을 마친 후 테스트 데이터를 통해 각 모델별 인식률을 측정 한 결과가 표 1에 나타나 있다. 8번의 실험 결과, 1시간 단위의 온도영상 24개와 1시간 단위의 수증기 영상 24개를 조합한 입력을 사용하는 경우, 3가지 모델 모두에서 가장 우수한 인식 성능을 보인다. 이런 결과는 수증기 및 온도 영상의 변화를 시간 단위로 측정하여 학습할 경우, 시간적으로 변화하는 텍스처 패턴의 변화를 보다 정확히 학습할 수 있기 때문으로 보인다. 또한 실험 결과를 통하여 제안시스템이 비교시스템들에 비하여 평균적으로 높은 인식률을 보임을 확인하였으며, 이것은 제안시스템이 제주의 강수패턴 분석에 유효함을 보여주는 것으로 판단된다.

표 1. 실험결과

Table 1. The experimental results

요건		모델			
		제안모델	Alexnet	VGG16	
강수 판단 조건 (mm)	온도 영상 개수	수증기 영상 개수	인식률		
	0	24	59.0	64.5	60.4
	1	24	62.9	62.9	66.8
	2	24	62.9	67.0	64.1
	4	24	63.9	65.6	63.7
	6	24	71.3	63.1	67.6
	8	24	66.2	68.4	64.9
	12	24	71.3	68.7	65.8
	24	24	71.7	66.8	68.9

5. 결론

본 논문에서는 수증기 영상과 기온 영상 패턴이 강수 여부와 관련이 있음을 전제로 한다. 그리고 수증기 영상 등을 강수 정보를 간직한 어떤 패턴이 무작위로 배치돼있는 텍스처라 가정하고, 최근 텍스처 분석에 많이 사용되는 합성곱신경망 모델을 제안하였다. 제안 방법의 타당성 검증을 위하여 국가기상위성센터의 천리안위성이 제공한 한반도 수증기 영상에서 추출한 제주도 수증기 영상과 기상자료개방포털의 온도, 강수 같은 날씨자료를 기반으로 만든 온도 영상을 조합하여 실제 실험을 수행했다. 0.1mm 이상을 강수 여부를 판단하는 기준을 정하고 실험을 수행한 결과 평균 71%의 정확도를 보였다. 성능 비교를 위하여 Alexnet, VGG16 모델을 실제 설계하고 같은 입력으로 비교 실험을 수행하였다. 비교 결과 제안 시스템이 비교 시스템보다 우수한 분류 성능을 보임을 확인하였다. 이런 결과는 합성곱신경망에 기반을 둔 인공지능 기법이 기존의 경험적 모델을 통한 기후분석과 비교하여 많은 장점을 가지고 있음을 알 수 있다. 따라서 향후 인공지능 기술은 기상위성을 통해 수집된 자료에 대한 분석 전반에 활용될 가능성을 보여주었다. 향후 기상모델을 연구하는 다양한 분야와의 공동연구를 통하여 제안한 방법의 완성도를 높일 수 있도록 할 예정이다.

이 논문은 2019학년도 제주대학교 교육-연구 및 학생지도비 지원에 의해서 연구되었음

참고 문헌

[1] 국가기상위성센터, “기상위성영상의 이해 (I)”,

ISBN: 11136055900002101, http://riss.kr/search/detail/DetailView.do?p_mat_type=d7345961987b50bf&control_no=c213217484b2690dffe0bdc3ef48d419

[2] 최광용, “한라산의 사계절 극한강수현상 발생 패턴”, 건국대학교 기후연구 vol. 8, no. 4, pp. 267~280, 2013. DOI: <http://dx.doi.org/10.14383/cri.2013.8.4.267>

[3] 오일석, “기계학습”, 한빛아카데미(주), 2018, ISBN:9791156641582

[4] 이건명, “인공지능:튜링 테스트에서 딥러닝까지”, 생능출판사(주), 2018. ISBN: 9788970509594

[5] Geoffrey E. Hinton, Simon Osindero and Yee-Whye The, “A Fast Learning Algorithm for Deep Belief Nets”, Neural Computation archive Volume 18 Issue 7, pp.1527 - 1554, 2006. <https://www.cs.toronto.edu/~hinton/absps/fastnc.pdf>

[6] Yann LeCun, Leon Bottou, Yoshua Bengio and Patrick Haffner, “Gradient-based learning applied to document recognition”, Proceedings of the IEEE Volume 86 Issue 11, pp. 2278-2324, 1998. http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf

[7] Vincent Andrearczyk, “Deep learning for texture and dynamic texture analysis”, PhD thesis, Dublin City University, 2017. http://doras.dcu.ie/22040/1/Vincent_Andrearczyk_Final_PhD_thesis.pdf

[8] F. H. C. Tivive and A. Bouzerdoum, “Texture classification using convolutional neural networks”, in TENCON 2006-2006 IEEE Region 10 Conference, pp. 1 - 4, 2006. <http://ro.uow.edu.au/cgi/viewcontent.cgi?article=1534&context=infopapers>

[9] Phil. Brodatz, “Texture: A photographic album for artists and designers”, Dover Pubns, 1966. ISBN-10: 0486216691

[10] Luiz G.. Hafemann, L. S. Oliveira, and P. Cavalin, “Forest species recognition using deep convolutional neural networks”, Proceedings of 22nd International

Conference on Pattern Recognition, pp. 1103 - 1107. 2014. http://luizgh.github.io/papers/icpr2014_ForestSpecies.pdf

- [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, vol. 1, 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", a conference at ICLR, pp. 1-14, 2015. <https://arxiv.org/pdf/1409.1556.pdf>

저 자 소 개



이동훈 (Dong-Hoon Lee)

1999.2 서울대학교 임산공학과 졸업
2018.3-현재 : 제주대학교 전산통계학과 석사과정
<주관심분야> 인공지능, 패턴인식



이봉규 (Bong-Kyu Lee)

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