



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

합성곱신경망을 이용한
제주도 강수 패턴 분석

제주대학교 대학원

전산통계학과

이 동 훈

2019년 12월

합성곱신경망을 이용한 제주도 강수 패턴 분석




지도교수 이 봉 규

이 동 훈

이 논문을 이학 석사학위 논문으로 제출함

2019년 12월

이동훈의 이학 석사학위 논문을 인준함

심사위원장	이운정	
위 원	김철수	
위 원	이봉규	

제주대학교 대학원

2019년 12월

The Analysis of Jeju Island Precipitation patten using the CNN (Convolution Neural Network)

DongHun Lee
(Supervised by professor BongKyu Lee)

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

December 2019

This thesis has been examined and approved.

Yunjung Lee

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

ChulSoo Kim

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

Bong Kyu Lee

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

December 2019

Department of Computer science and Statistics
GRADUATE SCHOOL
JEJU NATIONAL UNIVERSITY

목 차

표 목차	iii
그림 목차	iv
초록	v
Abstract	vi
I. 서론	1
II. 배경과 관련 연구	3
1. 기상산업과 제주지역 기후 특징	3
2. 딥러닝과 합성곱 신경망	7
2.1. 인공신경망 (Artificial Neural Networks, ANN)	7
2.2. 합성곱 신경망 (Convolution Neural Network, CNN)	10
3. 텍스트 분석과 합성곱 신경망	15
3.1. 기존의 텍스트 분석 방법	15
3.2. 합성곱 신경망에 의한 텍스트 분석	17
III. 제주 강수 패턴 분석을 위한 합성곱 신경망	21
1. 입력 패턴 구성을 위한 영상 전처리	21
2. 제안 합성곱 신경망 구조	25
IV. 구현 및 실험 결과 분석	28
1. 실험 환경 및 데이터 수집	28
2. 실험 결과 및 분석	32
2.1. 실험 결과	33
2.2. 학습 효율 및 오인식 분석	35

V. 결론 및 향후 연구 방향 38

VI. 참고 문헌 39

표 목차

Table 2.1. 최근 10년간 원인별 기상재해 피해액	4
Table 2.2. 최근 10년간 기상재해 현황(총괄)	4
Table 2.3. 오류 역전과 알고리즘	9
Table 2.4. 합성곱 신경망의 활성화함수	13
Table 3.1. 합성곱 신경망의 구조와 학습대상 가중치의 개수	26
Table 4.1. JejuLoc 테이블	29
Table 4.2. JejuWetHr2 테이블	29
Table 4.3. 시간단위 수증기영상 자료 분포	29
Table 4.4. 수정 전후 Alexnet	31
Table 4.5. 수정 전후 VGG16	31
Table 4.6. 제안 모델에 히스토그램 균등화 전후 정확도	32
Table 4.7. 랜덤 선택(훈련용:테스트용=3:1) 자료의 개별정확도(%)	33
Table 4.8. 비:맑음 동일 비율 자료의 개별 정확도(%)	34

그림 목차

Fig. 2.1	제주도의 연 평균 기온과 강수량 분포	6
Fig. 2.2	인공 신경회로망의 뉴런(처리요소)의 구조	7
Fig. 2.3	은닉층을 가지는 다층 퍼셉트론	8
Fig. 2.4	합성곱 신경망과 고전적 신경망의 비교	11
Fig. 2.5	합성곱 신경망 구조	11
Fig. 2.6	필터를 통한 합성곱 연산	12
Fig. 2.7	드롭아웃된 신경망	14
Fig. 2.8	텍스처 분석을 위한 CoNN	18
Fig. 2.9	산림 종류 인식용 합성곱 신경망	19
Fig. 2.10	2개의 합성곱층을 갖고있는 T-CNN	19
Fig. 3.1	위성에 의한 한반도 영상(1024×1024)과 제주영역 추출	22
Fig. 3.2	제주 지도 삭제 전후 수증기 영상	22
Fig. 3.3	온도 영상	23
Fig. 3.4	수증기와 온도 영상으로 구성된 신경망 입력영상	24
Fig. 3.5	제안 합성곱 신경망 모델	25
Fig. 4.1	제안시스템과 비교시스템간 수렴 속도 비교	35
Fig. 4.2	제안 모델의 오인식 예	37

초 록

재해를 동반할 수 있는 기상은 사회안전과 원활한 삶을 위해 정확한 기상 예측이 필요한 분야다. 그리고, 기상은 에너지, 여행·레저, 보험업, 농업 등 산업 전반에 영향을 미친다. 그래서 기상에 대한 정보와 분석은 정확한 기상 예측과 기존 산업뿐 아니라 기상 관련 상품을 제조·공급하거나 용역을 공급하는 기상 산업과 같은 미래 산업의 중요한 요소다. 기상 중에서 대기 중의 수분이 액체 또는 고체가 되어 지표면에 낙하하는 현상을 일컫는 강수는 우리 생활 전반에 영향을 미친다. 그리고, 강수를 정확히 예측하기 위한 다양한 정보가 필요하다. 그중에서도 기상위성에서 관찰된 대류권 중상층의 수증기 분포를 영상화한 수증기 영상은 강수 예측/분석에 많이 이용된다. 제주는 농업과 관광이 비중이 크다. 그러므로 강수에 대한 예측/분석은 다른 지방보다 더 중요하다. 그런데, 1,950m 높이의 한라산 지형효과와 맞물려 지역마다 다른 강수 패턴 및 기후가 나타난다. 그래서 제주도 강수 분석이 쉽지 않다. 따라서 제주지역에 맞는 새로운 제주 강수 분석 방법이 연구돼야 한다.

본 논문에서는 합성곱 신경망 (Convolution Neural Network, CNN) 기반의 텍스처 (Texture) 분석기법을 이용한 제주 강수 패턴 분석 방법을 제안한다. 구현 시스템은 수증기 영상과 지역의 온도정보를 텍스처로 변환한 영상을 합성곱 신경망을 이용하여 강수 여부를 분석하는 방법이다. 제안한 모델을 실제 구현하고 2015년부터 2018년까지의 기상 데이터를 통한 실험을 통하여 제안된 방법의 유효성을 보인다.

Abstract

Weather is often accompanied by disaster and also affects industries such as energy, travel and leisure, insurance, and agriculture. Thus, information and analysis of weather is an important component of accurate weather forecasting, existing and meteorological industry. Weather, especially precipitation affects our lives in general. In addition, various information is needed to accurately predict precipitation. Among the information, Water vapor images, which image the distribution of water vapor in the middle and upper troposphere observed in meteorological satellites, are frequently used for precipitation prediction and analysis. Agriculture and tourism are very important industries in Jeju island. Therefore, precipitation forecasting / analysis in Jeju is more important than in the other provinces. However, with the topographical effect of Mt. Halla with the height of 1,950m above sea level, different climates appear in different regions. Thus, precipitation analysis in Jeju is not easy. Therefore, a new method for analyzing precipitation in Jeju should be studied.

In this thesis, we propose a Jeju precipitation pattern analysis method using a convolution neural network (CNN) based texture analysis method. The implementation system is a method for analyzing precipitation using CNN with Water vapor images and images made of local temperature information as input. Experimental results with weather data from 2015 to 2018 show the effectiveness of the proposed method.

I. 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 꾸려나가는데 필요한 식량이나 자원의 생산에서부터, 관광 및 레저활동, 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 기상위성 (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 수증기 영상 등을 이용한다. 수증기 영상은 흰색 (구름역), 회색 (수증기역), 검은색 (건조역)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. 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 등

이 제주도를 통과할 때 한라산 지형의 영향으로 다양한 일기 패턴을 생성하는 것이다 [2, 3]. 현재 제주도의 강수 예측/분석은 기상위성을 통해 얻어지는 관측 데이터에 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/분석방법이 연구되어야 할 것이다.

본 논문에서는 합성곱 신경망 (Convolution Neural Network, CNN) 기반의 텍스처 (Texture) 분석기법을 이용한 제주 강수 패턴 분석방법을 제안한다. 제안하는 방법은 기상위성에서 획득한 제주도 영역에 대한 수증기 영상과 지역의 온도 정보를 텍스처 영상으로 변환한 후, 변환된 영상들을 합성곱 신경망을 이용하여 강수 여부를 분석하는 방법이다. 제안한 방법은 기존의 수치모델을 이용하는 방법과는 달리 인간의 인지적인 능력에 기반을 둔 신경망 방법을 이용함으로써 인간의 시각이나 단순 수치모델로 찾기 어려운 강수 여부에 대한 텍스처 상의 변화를 감지할 것이다. 제안한 방법을 프로그램으로 구현하고 실제 기상위성 관측 데이터를 통한 실험을 통하여 제안된 방법의 유효성을 보인다. 본 논문의 구성은 다음과 같다. II장에서는 제주도 기후 및 기존의 신경망 기반 등의 텍스처 분석 방법을 기술한다. III장에서는 제안한 합성곱 신경망의 구조와 입력 텍스처 영상의 획득과정을 기술한다. IV장에서는 실제 구현과 실험을 통하여 제안한 방법의 유효성을 보인다. V장에서는 본 논문의 결과를 기술한다.

II. 배경과 관련 연구

1. 기상산업과 제주지역 기후 특징

기상은 공기 중에 일어나는 하나하나의 대기 현상 또는 순간적으로 나타나는 대기의 상태이다. 자연재해의 80% 정도는 기상과 관련된다 [4]. 행정안전부의 통계자료를 이용해서 기상청에서 정리한 2008년부터 2017년까지 원인별 기상재해 피해액과 기상재해 현황을 나타낸 자료를 통하여 이런 현상을 확인할 수 있다. (Table 2.1, Table 2.2)[5]. 이러한 태풍, 호우, 강풍, 대설, 가뭄, 이상고온 및 황사와 같은 재해를 동반하는 기상이 경제, 사회에 미치는 영향력은 시간이 갈수록 점점 커져, 우리 사회의 안전을 지키고 원활한 삶을 꾸려나가기 위해 기상을 정확한 분석/예측하는 연구는 우리 사회의 필수요소이다. 이런 현상은 우리나라 뿐 아니라, 전 세계 모든 국가에서 나타나는 현상이다. 이에 따라 185개국의 국가와 6개의 지역으로부터 자료를 수집 및 표준화 뒤 회원국에 제공할 목적으로 WMO (World Meteorological Organization)를 조직하여 기상자료를 수집하고 모든 국가에 자료 제공을 담당케 한다.

이렇듯 기상은 생태계에 영향을 미쳐 지구상의 모든 동식물에 영향을 미치고 나아가 에너지, 여행·레저, 보험업, 농업, 유통, 해운 등 산업 전반에 커다란 영향을 미치기 때문에 기상에 대한 정보와 분석은 미래 중요산업 중에 하나로 인식된다. 국민 행복 및 풍요로운 사회 구현을 위해 사회·경제 등 다양한 분야에서 기상산업의 역할 강화 필요성이 나타난다. 기상산업은 기상 관련 상품을 제조·공급하거나 용역을 공급하는 산업으로 일반·특정 수요자를 대상으로 기상 현상에 관하여 관측된 결과를 바탕으로 미래의 기상상태를 예상하여 제공하는 기상 예보업, 특정 수요자를 대상으로 기상감정을 제공하는 기상 감정업, 기상정보를 분석·평가하여 경영활동에 관한 조언을 제공하는 기상 컨설팅업, 기상측기를 제작·수입·설치하거나 수리하는 기상 장비업 등으로 구성된다.

Table 2.1 최근 10년간 원인별 기상재해 피해액

구분 (연도)	태풍	호우	대설 (폭풍설)	강풍	풍랑	지진	합계
							(백만원)
2008	911	61,706	3,868	1,184			67,669
2009		271,337	13,603	7,489	25,642		318,071
2010	176,888	185,353	67,987	179	7,215		437,622
2011	209,783	506,994	46,101		287		763,165
2012	957,850	36,675	19,422	25,491			1,039,438
2013	1,639	153,358	11,000	904	43		166,944
2014	5,159	138,655	31,611	92			175,517
2015	13,615	1,232	13,226	3,952	39		32,367
2016	221,886	37,129	19,335		8,590	11,401	298,341
2017		101,592	83		605	85,022	187,302
평균	158,773	149,403	22,624	3,929	4,272	9,642	


Table 2.2 최근 10년간 기상재해 현황(총괄)

구분 (연도)	사망·실종 (명)	이재민 (명)	침수면적	재산 피해액	피해 복구액
			(ha)	(백만원)	(백만원)
2008	11	4,627	602	67,669	156,811
2009	13	11,931	5,677	318,071	823,401
2010	14	76,110	12,925	437,622	733,577
2011	78	70,099	14,892	763,165	1,589,393
2012	16	18,356	487	1,039,438	1,959,355
2013	4	4,233	0	166,943	374,896
2014	2	7,691	89	175,517	494,384
2015	0	92	0	32,364	38,723
2016	7	597	630	298,341	611,047
2017	7	8,731	53.93	187,302	499,672
합계	-	-	-	-	-
평균	15.2	-	-	348,643	728,126

기상의 중요성에 있어서 제주도는 지역적 특성 및 산업구조 측면에서 국내 다른 지역보다 더 중요한 의미를 지니므로 기상 분석/예측이나 기상산업이 제주도

에 미치는 영향은 매우 크다. 제주도는 해발고도 1,950m의 한라산이 그 중심에 위치하므로 해안지역은 최한월 평균 0℃ 이상이고, 연평균 15.0℃ 이상인 아열대 기후에 속하나, 고도 상승에 따라 다양한 기후대 및 식생대 분포가 나타난다. 한라산 정상부근은 연평균기온도 10.0℃ 이하로, 아고산대 식생대가 나타난다. 그리고 해발고도가 높아질수록 호우 발생빈도도 증가하는데, 10년 (2001~2010) 평균 자동기상관측 지점 통젓값에 따르면 해발고도 600m 이상의 산간지역에서는 80mm 이상의 강수일수가 해안지역보다 5배 이상 발생빈도가 높다. 이렇듯 같은 중관기후 상태에서도 한라산 사면 방향에 따라 지역마다 강수 발생 패턴이 차이 발생한다고 추정한다 [3]. 제주도는 아시아 몬순 지역으로 사계절마다 유입되는 기류의 양과 방향이 다르다. 게다가 한라산의 지형효과와 맞물려 지역마다 다른 강수 패턴 및 기후가 나타나는 등 제주도 기상분석이 쉽지 않다.

제주도의 연평균기온 분포는 산간지역으로 갈수록 기온이 낮아지는 원형분포를 보이며, 윗세오름이 6.4℃로 가장 낮고, 서귀포가 17.1℃로 가장 높게 나타난다. 제주도의 연평균강수량 분포는 산간지역으로 갈수록 강수량이 증가하며, 윗세오름이 4669.4mm로 가장 많아 제주도 내 최고 다우 지로, 산간의 강수량이 해안가 관서의 2~4배에 이르지만, 제주도 서부지역은 연평균강수량 1,200mm 내외로 가장 적어 제주도 내 다우지역과 소우지역 편차가 크게 나타난다 (Fig. 2.1)[6]. 그리고, 한라산 지역에서 해발고도 상승 시 연 강수량은 약 242mm/100m의 비율로 증가한다 [2]. 0.1mm 이상 발생일을 살펴보면, 강수일수가 가장 많았던 제주는 1951~1980년 기후 평년값부터 1981~2010년까지 기후 평년값은 139.9, 135.5, 130.6, 130.2일로 나타나 최근 년과 원년 간의 60년간 7.7일이 점진적으로 줄어든 일수를 보여 작은 변화라도 일관성을 보인다 [7].



< 연평균기온 분포(2003~2009년) > < 연강수량 분포(2003~2009년) >

Fig. 2.1 제주도의 연 평균 기온과 강수량 분포

현재 제주도의 강수 예측/분석은 기상위성 등을 통해 얻어지는 관측데이터에 캐나다 McGill University에서 개발한 MAPLE기반 외삽예측 기술 [8, 9, 10] 등 기존 존재하는 수치모델을 이용하고 있으나, 한라산의 지역적 영향으로 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/분석방법이 연구되어야 할 것이다. 합성곱 신경망이 산림의 종류 분류 [11] 등에서 패턴을 갖는 영상, 즉 텍스처 분석에 효과적이라고 한다. 따라서, 합성곱 신경망 기반의 텍스처 분석기법을 이용한 제주 강수 패턴 분석방법을 제안한다.

2. 딥러닝과 합성곱 신경망

2.1 인공신경망 (Artificial Neural Networks, ANN)

인공신경망은 인간의 뇌 신경세포와 그 결합 구조를 모방하여 컴퓨터로 구조화한 것으로, 대표적인 기계학습 모델 중 하나이다. 따라서 기존의 알고리즘 방법과는 달리 인간과 같은 예제를 통한 학습으로 문제를 해결하는 능력을 갖춘다 [12, 13]. 이런 학습/분류 능력으로 인하여 인공신경망은 패턴 분류, 인식, 최적화, 예측 분야에서 유용하게 사용된다. 신경망을 구성하는 기본단위는 인간의 신경세포 (뉴런)에 해당하는 노드 (처리기)와 이들 노드를 연결하는 연결선으로 구성된다. 연결선 각각에 각 노드 간의 연결 강도를 나타내는 가중치(W_i)가 부여되는데, 가중치와 외부 입력의 연산을 통하여 학습한다. 전형적인 신경망의 구조가 Fig. 2.2에 나타나 있다. 그림에서 보듯이 신경망은 X_i 로 표현되는 외부 입력을 가중치와 곱하여 값을 산출한다. 이런 신경망의 각 노드의 집합들은 수행하는 기능에 따라서 입력층 (Input Layer), 출력층 (Output Layer) 그리고 은닉층 (Hidden Layer)으로 나뉜다. 이런 층을 통하여 신경망은 입력층과 출력층만으로 구성되는 단층 신경망과 은닉층을 함께 가지고 있는 다층 신경망으로 나뉘어진다. 일반적으로 신경망이 단층에서 다층으로 복잡해질수록 더 복잡한 문제를 해결하는 능력을 갖춘다.




Fig. 2.2 인공 신경회로망의 뉴런(처리요소)의 구조

다층 신경망 중에서 패턴인식에 사용되는 대표적인 모델이 다층 퍼셉트론 (Multi Layer Perceptron, MLP)이다. 다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 은닉층을 가지는 전 방향 신경망으로 단층 퍼셉트론의 한계를 극복하기 위해 1960년대 이미 제안되었다. 그러나 효과적인 학습 알고리즘이 없어서 사용되지 않았으나, 1986년 오류 역전파(EBP, Error BackPropagation) 학습 알고리즘의 개발로 활발히 사용하게 된다. 이 알고리즘은 원하는 목표값(d)과 실제 출력값(o) 사이의 오차제곱합으로 정의된 비용함수(Cost Function) E의 값을 경사하강추적법(Gradient-descent Method)에 의해 최소화하는 방향으로 학습하는 방법이다.

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

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. Table 2.3에서 오류 역전파 알고리즘을 보여주고 있다 [13].




Fig. 2.3 은닉층을 가지는 다층 퍼셉트론

Table 2.3 오류 역전과 알고리즘

1단계. 가중치와 임계치를 초기화

2단계. 입력과 목표 출력 제시

3단계. 은닉층 j번째 뉴런의 값 계산

$$\text{net}_{pj} = \sum_{i=0}^{N-1} W_{ji} X_{pi} - \theta_j$$

4단계. 시그모이드 함수를 사용하여 은닉층의 출력(O_{pj}) 계산

5단계. 은닉층의 출력을 이용하여 출력층 뉴런 k로의 입력값 계산

$$\text{net}_{pk} = \sum_{j=0}^{L-1} W_{kj} X_{pj} - \theta_k$$

6단계. 시그모이드 함수를 사용하여 출력층의 출력(O_{pk})을 계산

7단계. 목표출력(d_{pk})과 실제 출력 (O_{pk}) 과의 오차값(δ_{pk}) 계산

$$\delta_{pk} = (d_{pk} - O_{pk}) f_k'(\text{net}_{pk})$$

$$E = E + E_p, (E_p = \sum_{k=1}^{M-1} \delta_{pk}^2)$$

8단계. 은닉층의 오차(δ_{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 좋은 결과를 보였다. 그러나 신경망의 구조가 복잡해지면서 기존의 다층 퍼셉트론은 많은 문제점을 보인다. 먼저 학습방법인 오류 역전파 방법은 층이 깊은 망일수록 출력에서 멀어질수록(입력에 가까울수록) 기울기 (Gradient) 크기가 작아지게 되는 기울기 값의 소실문제(Vanishing Gradient Problem)가 발생하여 학습이 잘되지 않는 현상이 발생한다. 게다가 사용하는 학습데이터에 과적합(Overfitting)로 인한 학습 일반화 제한 등의 문제가 제기된다. 그리고 다층 퍼셉트론에서는 학습 예제를 분석하여 다층 퍼셉트론의 입력을 사람이 직접 설계해야 하므로 빅데이터를 이용한 학습에 적절히 대응하기 어렵다는 것이 가장 큰 문제로 대두된다. 과적합 문제나 기울기 값 소실문제는 수정된 선형함수(Rectified Linear Unit, ReLU)의 사용으로 [14, 15], 과적합 문제는 드롭아웃(Dropout) 방법 [16, 17]을 통하여 해결이 가능하다. 그러나 빅데이터의 사용에 대해서는 새로운 방법이 필요하게 되었으며, 이에 따라 사람이 개입하지 않는 학습이 가능한 심층학습(Deep Learning)을 이용한 합성곱 신경망의 필요성이 증가한다.

2.2 합성곱 신경망 (Convolution Neural Network, 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. 합성곱 신경망은 이런 문제점을 해결하기 위해 특징추출과 인식을 통합하여 신경망이 모두 처리하도록 한 형태를 가진다 (Fig. 2.4). 합성곱 신경망은 입력 영상을 그대로 입력층에 제공함으로써 별도의 특징추출 과정이 필요하지 않으며, 특징추출 작업도 학습으로 해결한다 [18, 19].

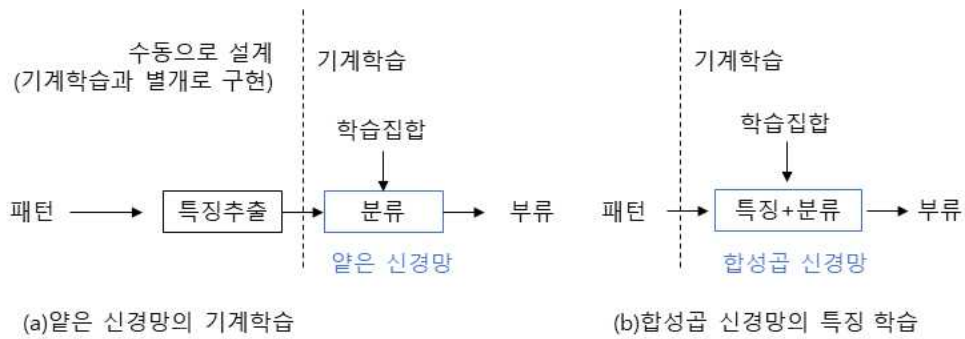


Fig. 2.4 합성곱 신경망과 고전적 신경망의 비교

Fig. 2.5에서 합성곱 신경망의 구조를 보여준다. 그림에서 보듯이 합성곱 신경망은 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 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. 그림에서 보듯이 입력된 영상은 복수의 합성곱 층에 의해서 다양한 형태의 특징으로 변환되며 최종 변환과정을 거친 특징은 완전연결 인식 층에 전달되어 인식작업에 사용된다. 전체 합성곱 신경망의 학습에는 오류 역전파 알고리즘이 사용되며, 출력층에서 합성곱 층까지 오류를 역전파 하는 방식으로 학습을 한다.




Fig. 2.5 합성곱 신경망 구조

합성곱 신경망이 기존 신경망과 차별화되는 것이 자체적인 합성곱과 풀링을

통한 자동화된 특징추출을 하는 것이다. 합성곱 층의 각 노드는 입력에 대해서 학습을 통하여 최적의 특징을 추출한다. 합성곱 연산은 영상처리에서의 필터를 이용한 방법을 사용하는 것과 같은 원리이다. 합성곱 연산에서 필터로 표현된 가중치 값의 행렬을 커널 또는 마스크라고도 하며 일반적으로 높이가 너비가 같은 정사각형 (Square)의 형태를 가진다 (Fig. 2.6). 합성곱의 결과로 얻어지는 결과를 특징 맵 (Feature Map)이라 하며 여러 단계의 합성곱을 거친 최종단계의 특징 맵이 인식 층의 입력이 된다. 필터는 입력 영상을 왼쪽에서 오른쪽으로 이동하면서 해당 영역 내의 영상 부분과 합성곱 연산을 수행하는데, 이동 정도는 스트라이드 값으로 조절이 가능하며, 스트라이드 s 의 크기는 합성곱 결과의 크기를 조절하기 위해서 사용한다. 만약 입력 영상과 필터의 크기가 각각 $n_h \times n_w$, $l_h \times l_w$ 이고 패딩 값 (Padding, 입력 영상의 확장 지수)과 스트라이드 값이 각각 p , s 이면 필터 처리된 합성곱 결과 크기는 식(2)과 같이 결정된다.

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

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

합성곱 연산 결과는 일반적으로 풀링 (Pooling) 층에서 샘플링을 통하여 크기가 조절된다. 풀링이란 일정크기의 대상 영역을 통합해서 한 개의 대푯값으로 표시하는 연산이다. 풀링은 매번 합성곱 연산이 수행된 후 반복되어 실행된다. 그리고 풀링 연산은 합성곱 결과에 대해 위치 불변성을 제공하고 데이터양을 축소해 계산의 효율성을 높일 수 있는 장점을 제공한다 [19].

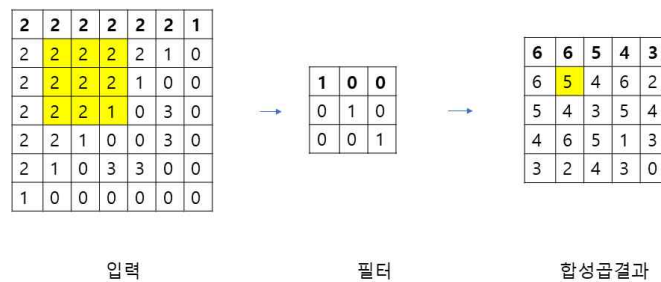





Fig. 2.6 필터를 통한 합성곱 연산

합성곱 신경망에서는 기존의 인공신경망에서 나타나는 3가지의 문제점인 기울기 값의 소실문제, 학습속도 문제 및 과적합 문제를 해결하려는 방법을 제공한다. 먼저 다층 퍼셉트론과 달리 딥러닝에서는 기존의 시그모이드 (Sigmoid)나 하이퍼탄젠트 (Tanh)등과 같은 비선형 함수 외에도 ReLU를 주로 사용한다. 합성곱 신경망을 구성하는 층이 비교적 적으면 기존의 시그모이드나 하이퍼탄젠트를 그대로 사용하여 학습하면 되고, 층의 개수가 많아질 때는 ReLU함수를 사용함으로써 기울기 값 소실문제를 해결한다.

Table 2.4 합성곱 신경망의 활성화함수

함수이름	그림	함수	1차도함수	범위
로지스틱시그모이드		$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$	(0,1)
하이퍼볼릭탄젠트		$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$f'(x) = 1 - f(x)^2$	(-1,1)
렉티파이어(ReLU)		$f(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 & \text{for } x > 0 \end{cases}$	(0,무한)

기존 인공신경망과 같이 합성곱 신경망에서도 오류 역전파와 학습을 사용한다. 오류 역전파와 학습을 위해서는 학습 초기에 초기 가중치를 부여하고, 오류를 측정하는 목적함수가 작아지는 방향으로 가중치를 갱신해 나간다. 따라서 초기 가중치는 학습속도에 중요한 요인이다. 기존의 인공신경망에서는 초기 가중치 설정에 대한 명확한 근거가 없었기 때문에 효율적인 학습이 이루어지지 못하였다. 합성곱 신경망에서는 초기 가중치를 효율적으로 추정하는 방법으로 최적화 (Optimization) 알고리즘을 사용한다. 확률적 경사 하강법(Stochastic Gradient Descent, SGD)은 손실함수의 기울기를 계산하여서 이 기울기 값에 학습률 (Learning Rate)를 계산하여 이 곱값으로 기존의 가중치 값을 갱신한다. μ 는 학습률을 의미하며 0.01이나 0.001등의 값으로 미리 정해서 사용한다

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

SGD 알고리즘은 지역 국부 (Local Minima) 문제와 느린 학습속도를 가지는 단점이 있다. 이런 문제점을 보완한 방법이 모멘트 기반 최적화 (Momentum-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. α 는 보통 0.9이다

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

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

그 밖에도 적응 경사법 (Adaptive Gradient, Adagrad), RMSprop (Root Mean Squared propagation), Adam(Adaptive Momentum Estimation)과 같은 다양한 최적화 기법을 이용하여 기존 신경망의 문제점을 해결한다 [20, 21].

인공신경망에서 나타나는 과적합 문제를 합성곱 신경망에서는 드롭아웃으로 해결한다. 드롭아웃은 입력층과 은닉층의 노드 중 일부분을 학습에서 배제함으로써 전체 신경망이 하나의 입력에 대해서 반응하는 것을 막음으로써 특정 입력에 과적합 되지 않도록 하는 방법이다. 선택된 노드는 입력되는 가중치와 출력되는 가중치 정보까지 모두 제거되기 때문에 나머지 노드만이 학습에 참여하게 된다. 이런 방법을 통하여 하나의 신경망 구조 위에서 여러 개의 다른 신경망 구조를 근사적으로 결합하는 방법을 제공하는 것이다.




Fig. 2.7 드롭아웃된 신경망

3. 텍스처 분석과 합성곱 신경망

영상처리 분야에서 텍스처는 상호 관련된 요소들로 구성된 물체 표면의 조직 구조를 의미한다. 이는 영상 내의 부드러움 (Smoothness), 거침 (Coarseness) 그리고 규칙성 (Regularity) 등과 같은 특징으로 영상의 표면을 규정하는 방법이다. 영상분석이나 패턴인식 분야에서 이러한 영상에 대한 텍스처 정보는 매우 유용하게 사용된다. 본 논문에서는 수증기 영상과 온도 영상을 텍스처로 규정하여 텍스처 분석기법을 통한 제주 강수 패턴 분석을 제안한다. 본 장에서는 합성곱 신경망이 기존의 다양한 텍스처 분석방법보다 우수한 효과를 보이는 연구 사례를 분석을 통하여 본 논문에서 제안하는 방법이 타당함을 보인다.

3.1 기존의 텍스처 분석 방법

구조적 방법은 텍스처를 구성하는 기본 요소가 되는 텍셀(Texture)을 추출후, 텍셀의 공간적 배열을 찾는 방법이다. 이때 찾아진 텍셀의 반복 규칙성을 식(5)과 같이 구문 구성 문법으로 기술하는 방법이다. 이 방법은 텍스처에 규칙성이 있음을 가정하는 방법으로 $S \rightarrow aS$, $S \rightarrow aaS$, $S \rightarrow aaaS$ 와 같이 반복되는 패턴으로 텍스처를 기술하는 방법이다. 이 방법은 간단한 영상에서는 적용 가능하나, 다양한 자연현상에서는 기본 요소인 텍셀을 정의하거나 추출하기 어렵고, 찾아진 텍셀의 구조적 관계를 문법으로 표현하기가 쉽지 않다.

$$S \rightarrow aS \quad (5)$$

통계적 접근법은 텍스처에서 통계적으로 추출 가능한 특징을 사용하는 방법이다. 텍스처로부터 영상분석에서 일반적으로 사용되는 히스토그램이나 분산 값, 모멘트 등에 대한 정보를 추출하여 사용하는 방법이다. 대표적인 방법의 하나는 영상 히스토그램의 γ 차 모멘트를 사용한 분석이다 [22]. 이 방법에서 사용된 γ 차 모멘트는 텍스처를 구성하는 픽셀의 밝기에 따른 기준 히스토그램 $\hat{h}(l)$ 로부터 식(6)과 같이 얻는다. γ 이 2차이면 상대적 부드러움 정도, 3차면 반대칭성, 4차면 평탄성 등을 나타낸다. 그리고, 텍스처의 각 영역의 균일함과 영역변화율에 대해 나타낼 수 있는 uniform과 entropy를 식(7)과 같이 구한다 [22]. 이런 다양한 통

계적인 특징을 통하여 텍스처를 분류하고 인식하는 기법이 제안되었다 [22, 23, 24].

$$\mu_r = \sum_{l=0}^{L-1} (l-m)^r \hat{h}(l), \quad m = \sum_{l=0}^{L-1} l \hat{h}(l) \quad (6)$$

$$uniform = \sum_{l=0}^{L-1} \hat{h}(l)^2, \quad entropy = \sum_{l=0}^{L-1} \hat{h}(l) \log_2 \hat{h}(l) \quad (7)$$

또, 다른 통계적 방법으로 사용된 것 중 하나가 GLCM(Grey Level Co-occurrence Matrix) 방법이다. GLCM은 텍스처를 구성하는 화소들의 이웃 관계를 통해 텍스처의 균일성, 엔트로피, 대비 (Contrast), 화소간 동질성에 관련된 정보를 사용하는 것이 가능하다. GLCM방법에서 사용되는 균일성(에너지)와 엔트로피는 식(8)과 식(9)을 통하여 얻을 수 있다. 균일성의 경우 모든 화소가 같은 값일 경우 1을 나타내며 범위는 [0, 1] 사이 값이다. 엔트로피는 요소들의 랜덤성을 측정하며, 모든 p_{ij} 가 같을 때 최댓값이 된다. 최댓값은 $2\log_2 k$ 다. 통계적 접근법은 구조적 방법 보다 덜 직관적이지만, 다양한 텍스처에 접근이 가능하고, 계산에서 효율적이다. 동시 발생 행렬이 주어질 때, n 은 전체 화소 수, g_{ij} 는 (i, j) 에 있는 요소 수, p_{ij} 점 쌍의 값들이 (i, j) 일 때의 확률이다. k 는 정사각형 매트릭스 형의 행(또는 열)의 길이이다.

$$p_{ij} = \frac{g_{ij}}{n}, \quad \sum_{i=1}^k \sum_{j=1}^k p_{ij} = 1 \quad (8)$$

$$energy = \sum_{i=1}^k \sum_{j=1}^k p_{ij}^2, \quad entropy = - \sum_{i=1}^k \sum_{j=1}^k p_{ij} \log_2 p_{ij} \quad (9)$$

통계적인 방법은 주어진 텍스처를 구성하는 화소들의 기하학적인 형태나 화소간의 분포에 따른 통계적인 값을 이용한 것이다. 또 다른 텍스처 분석 방법으로는 영상변환 방법이 있다. 이 방법은 주어진 텍스처를 다른 영역으로 변환하여 기술하는 방법으로 대표적인 방법의 하나가 푸리에(Fourier) 스펙트럼을 이용한 방법이다. 푸리에 변환은 텍스처에 존재하는 주기성과 위상에 대한 정보를 추출하는데 효율적이다. 이 방법은 변환으로 얻어진 스펙트럼으로부터 텍스처를 구성하는 화소의 주 방향과 주파수 성분을 이용한 텍스처 내에서의 주기(Frequency) 정보를 얻을 수 있도록 한다 [23].

기존의 텍스처 분석 방법은 주어지는 텍스처 영상들에 대한 면밀한 분석을 통하여 분석에 필요한 특징이나 규칙성을 찾아주는 작업을 추가로 필요하다. 따라서 텍스처 종류에 무관하게 일반적으로 사용할 수 있는 방법을 찾기가 어렵다. 그러므로 현재 새로운 방법으로 합성곱 신경망을 사용하는 방법이 활발히 연구되고 있다.

3.2 합성곱 신경망에 의한 텍스처 분석

합성곱 신경망은 다양한 텍스처에 대해서 일반화하여 사용이 가능한 방법으로 인식된다. 그리고 학습에 의한 텍스처 분석과 분류를 하나의 아키텍처(Architecture)를 통하여 구현할 수 있으므로 일반화가 가능하면서도, 다른 방법에 비교하여 좋은 분류 능력을 보여준다 [24]. 합성곱 층에 의해서 스스로 주어진 텍스처들을 분류할 수 있는 특징을 스스로 찾고, 찾아진 특징을 바로 인식/분류에 사용함으로써 사람의 개입을 최소화하면서 좋은 성능을 나타낼 수 있는 것이다.

F. H. Tivive 외 1명은 LeNet-5 [25]에 기반을 둔 CoNN(Convolutional Neural Network)을 제안하고 이를 통하여 텍스처를 분석한다 [26]. CoNN은 Fig. 2.11과 같이 2차원 (13×13) 픽셀 이미지를 입력받아 텍스처를 분류하는 기능을 보인다. 이 모델은 Brodatz 텍스처 데이터베이스 [27]에 있는 이미지를 대상으로 수행한 결과, 텍스처 분류 성능이 기존의 동시 발생 매트릭스(Co-occurrence Matrix), 가버/웨이블렛(Gabor/Wavelet) 필터 방법 및 QMF(Quadrature Mirror Filter) 필터 방법들과 비교해서 유사한 성능을 나타낸다 [26]. 성능 이외 측면에서 CoNN의 경우 이전 연구와 같이 특정 필터를 사용하지 않기 때문에 다양한 텍스처에 일반적으로 사용이 가능하다는 장점도 가진다. 기존 텍스처의 특징추출은 이미 주어진 텍스처에 맞춰 필터를 직접 선택한 방식이었다면, 합성곱 신경망은 훈련(학습, Training)과정에서 자동으로 특징추출하는 방식이다.

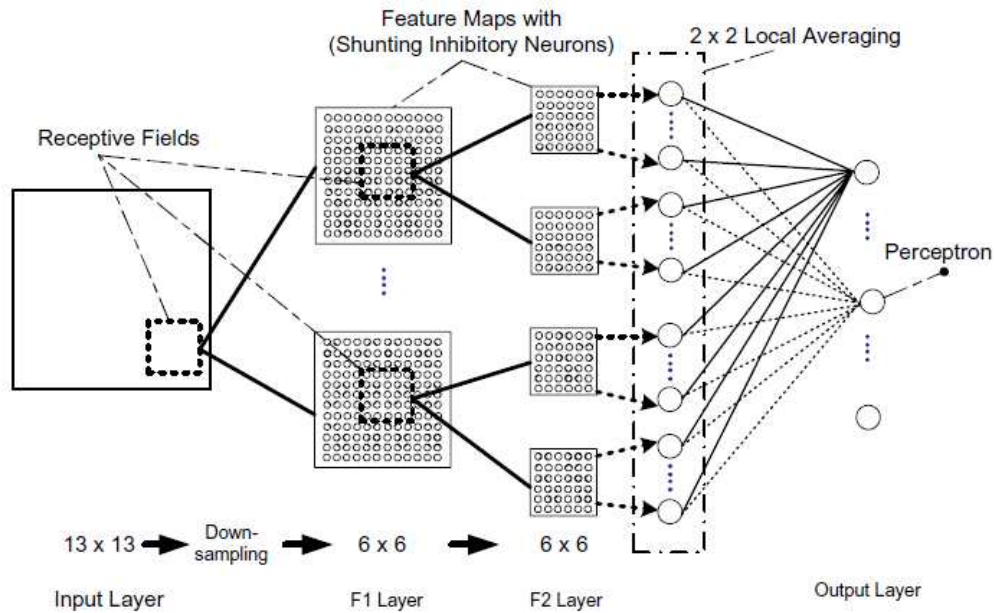


Fig. 2.8 텍스처 분석을 위한 CoNN

Luiz G. Hafemann의 2명은 합성곱 신경망으로 산림의 종류를 분류 기능 이외, 저해상도 텍스처 분류에 적합한 합성곱 신경망을 수정 없이, 고해상도의 텍스처 분류에 적용하는 방법을 제시한다 [11]. Fig. 2.9에서 텍스처 분석에 사용할 수 있는 제안된 합성곱 신경망 구조를 보인다. 합성곱 층은 5x5 크기의 64 필터 갖는다. 그리고 이 필터의 스트라이드는 1이다. 풀링 층의 윈도우 크기는 3x3이고, 스트라이드는 2이다. 지역적 연결 층(Locally Connected)은 합성곱 층과 유사한 작은 필터를 통해 다음 층과 연결되지만, 가중치 공유는 없는 방식으로 3x3 크기와 스트라이드 1을 갖는 32 필터로 구성된다. 완전연결 층은 가중치 공유 없이 다음 층과 완전연결 구조이고, 최종 노드는 분류 종류의 개수에 좌우된다. 매크로 이미지면 제안 모델은 분류기 정확도 95.77%로 기존 방법 중 최신 것 97.77%에 다소 못 미쳤으나, 마이크로 이미지면 97.32%로 기존 최신 것 93.2%보다 우수한 성능을 보인다. 일반적으로 합성곱 신경망은 32x32 CIFAR 또는 28x28 MNIST를 벤치 마크한 입력 이미지를 사용한다. 그런데, 산림의 종류 인식의 이미지 경우 3264x2448로 고해상도이다. 이에 따라, CIFAR와 MNIST의 데이터 크기와 유사한 치수의 이미지 조각(Patch)을 고해상도 산림 이미지에서 추출하는 것이 중요 아이디어이다.




Fig. 2.9 산림 종류 인식용 합성곱 신경망

V. Andrearczyk의 1명은 기존 CNN보다 단순하지만, 성능이 우수하도록 에너지 층을 갖는 T-합성곱 신경망 (Texture Convolutional Neural Network, T-CNN)을 제안한다 [28].

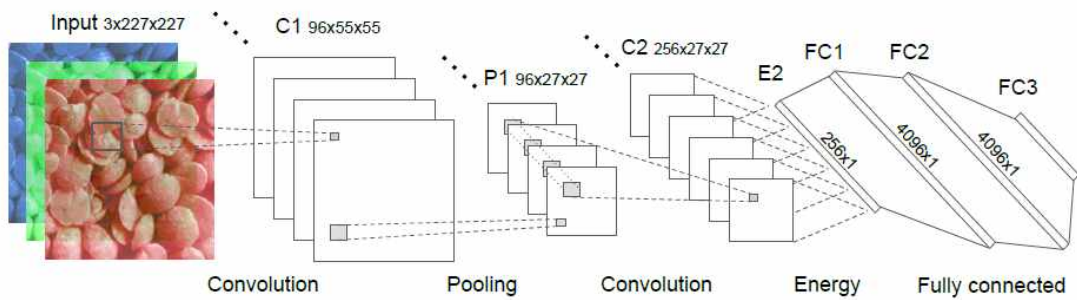


Fig. 2.10 2개의 합성곱층을 갖고있는 T-CNN

T-CNN에서 사용하는 에너지(Energy) 층은 마지막 합성곱 층의 특징 맵의 활성화된 결핍값을 단순히 평균해서 값이 정해진다. 즉, 마지막 합성곱 층의 특징 맵의 크기의 커널로 평균 풀링한 개념과 유사하다.

$$e_j = \frac{1}{WH} \sum_{x_1=1}^W \sum_{x_2=1}^H f_j(x_1, x_2) \quad (10)$$

$e \in R^N$ 은 벡터 결과값, $f_j(x_1, x_2)$ 는 공간 위치 (x_1, x_2) 의 j 번째 입력 특징맵, W , H 은 특징 맵의 넓이와 높이값, N 은 입력 특징 맵의 개수이다. 이 것은 마지막 합성곱 층의 특징 맵마다 하나의 결괏값에 대응함을 의미한다. T-CNN은 ReLU 함수, 정규화, 드롭아웃 방식은 Alexnet과 동일한 수법을 사용한다. 그러나, 이런 에너지 층의 사용은 Alexnet나 VGG 에 비해 복잡도를 상당히 낮춘다. 비록 모델 제안할 당시 최신 방법보다는 성능이 다소 미흡하지만, Alexnet보다는 대부분 성능상 우위를 보인다.

기존의 텍스처 분석 방법보다 합성곱 신경망은 다양한 텍스처에 대해서 일반화하여 사용할 수 있고, 분류기로서의 성능이 유사하거나 낫다. 그러므로, 수증기 영상은 하나의 텍스처이므로 제주도의 강수 패턴을 합성곱 신경망 통해 분석하고자 한다.

Ⅲ. 제주 강수 패턴 분석을 위한 합성곱 신경망

수증기와 기온은 강수에 직접적인 영향을 미치는 중요한 요인으로 기상예보에 실제 활용되고 있다. 본 논문에서는 수증기와 온도에 대한 위성 영상을 합성곱 신경망을 통하여 분석하는 방법을 제안한다. 위성에서 얻어진 수증기 영상과 온도 영상을 분류하는 것을 텍스처 분석으로 정의하고, 강수 여부에 관한 판단을 합성곱 신경망을 통하여 결정하는 방법이다. II장에서 합성곱 신경망은 다른 텍스처 분석기법과 달리 특징추출이나, 분류가 동시에 가능하고 하나의 구조를 서로 다른 텍스처 분석에 사용할 수 있다는 장점이 있음을 보였다. 그리고 다른 기존의 방법에 비교하여 우수한 인식/분류 능력을 보임을 확인하였다. 본 논문에서는 이러한 배경을 바탕으로 수증기 및 온도 영상을 통한 강수 여부를 판단하는 합성곱 신경망 모델을 제안한다. 본 장에서는 본 논문에서 제안하는 합성곱 신경망에 대한 입력 영상 구성에 관한 내용과 구성된 입력 영상을 처리하는 합성곱 신경망의 구조를 기술한다.

1. 입력 패턴 구성을 위한 영상 전처리

수증기 영상과 날씨 정보를 이용해서 생성된 영상을 합성곱 신경망에 입력으로 사용하기 위한 전처리 과정은 다음과 같다. 먼저 천리안위성으로 관측된 시간 대별 한반도 영역의 수증기 영상 (1일 24개)에서 제주도 영역을 추출한다. 이 과정을 통하여 입력 영상의 크기를 줄임으로써, 합성곱 신경망의 계산 부하를 줄이는 효과도 함께 가질 수 있다. Fig. 3.1에서 보듯이 원 영상의 크기는 1024×1024이지만 실제 사용되는 영상은 40×80으로 제주지역을 대상으로 한다.




Fig. 3.1 위성에 의한 한반도 영상(1024×1024)과 제주영역(40×80) 추출

추출된 수증기 영상(Fig. 3.1)에서 제주도 지도 모양을 나타내는 픽셀들은 제거되어야 한다. 이를 위하여 필터링 기법을 사용한다. 지도를 표시하는 픽셀 (노란색)들에 대해서 그 값을 주변 8개 값의 평균값으로 처리한다. Fig. 3.2에서 제주 지도 픽셀 (중심 픽셀)의 값은 자신의 값을 제외한 픽셀들의 평균값으로 표시된다 (식(11)).

$$p_{\text{목표}} = \frac{\sum_1^9 p - \sum_1^n p_{\text{지도}}}{9 - n} \quad (11)$$

$p_{\text{목표}}$ 는 제주도 지도영역을 표시하는 픽셀 (노란색)의 필터링 후의 값이며, n 은 $p_{\text{목표}}$ 주변 3×3영역 내 제주 지도영역의 해당하는 픽셀 개수, p 는 3×3 지역의 각 픽셀값, $p_{\text{지도}}$ 는 원래의 지도영역 표시 픽셀값에 해당한다. Fig. 3.2에서 식(11)을 적용 후 제주도 지도의 삭제 전후의 수증기 영상을 보여주고 있다. 픽셀값은 실제 입력될 때에는 [0, 1] 범위로 정규화된다.




Fig. 3.2 제주 지도 삭제 전후 수증기 영상

또 다른 입력 중 하나는 온도 영상은 시간대별로 (1일 24회) 측정된 제주도의

지역별 온도를 그레이 (Gray) 영상으로 표현하여 사용한다. 제주지역에서 공식적으로 온도를 관측하는 곳은 성산, 서귀포, 제주, 고산 네 영역이다. 이 온도를 바탕으로 한라산 고도를 기반으로 제주지역 나머지 지역의 온도를 계산한다. 최외곽(제주 해안가)에서 중심(한라산 백록담)까지는 고도에 따라서 10개 등고선 형태로 온도 영역이 구별되며, 실제 고도별 온도는 식(12)과 같이 계산한다 [6, 4].

$$p = \frac{t - i - (-20)}{40 - (-20)} \quad (12)$$

식(12)에서 p는 계산되는 온도 영상의 픽셀값을 나타내며, t는 제주도 4개 지역 (고산, 서귀포, 제주, 성산)에서 시간대별로 관측된 온도를 나타낸다. 이 값은 시간 간격이 1시간보다 크면 대상이 되는 시간대들 온도의 평균을 사용한다. 예를 들면 0시부터 6시까지의 온도를 함께 고려할 때는 t로 6시간 평균온도를 사용한다. -20은 최저 기온이고 40은 최고 기온이다. i는 외곽에서 중심까지 등고선을 나타내는 타원 10개로 구분되며, 중심방향으로 갈수록 -1℃ 낮아짐을 나타낸 것이다. 계산된 p의 값은 0에서 1까지의 범위로 정규화한다. 이런 과정을 통하여 얻어지는 Fig. 3.3 이미지가 온도 영상이다.



Fig. 3.3 온도 영상

제안한 합성곱 신경망은 입력으로 앞에서 언급한 2개의 영상을 같이 받아들인다. 따라서 특정 시간에 대한 합성곱 신경망의 입력 이미지는 $[n \times 40, 80]$ 매트릭스 (Matrix) 형태를 가진다. 너비 부분은 80픽셀로 고정이지만 깊이 부분은 40픽셀의 배수 크기로 가변이다. 그 이유는 실험 방법에 따라 입력 이미지를 구성하는 수증기 영상 및 온도 영상 조합하는 방식이 달라진다.

$$n = (w + \frac{w}{t}) \quad (13)$$

n은 입력 영상 총개수, w는 수증기 영상 시간 단위 즉, 수증기 영상 개수, t는

평균온도를 측정하는 시간 단위(범위), $\frac{w}{t}$ 는 온도 영상 개수이다. 24시간 단위 수증기 영상에 12시간 단위 평균 온도 영상을 이용한 입력 패턴이 필요하다면, 수증기 영상 개수 24($w=24$), 온도 영상 개수 2($=\frac{24}{12}$, $t=12$ 이므로), 총 입력 이미지 개수 26($n=24+2$)으로 입력 이미지는 $(26 \times 40, 80)$ 크기가 된다. 1시간 단위($p=1$, 1개) 수증기 영상과 1시간 단위($t=1$, $\frac{1}{1}=1$ 개) 온도 영상으로 구성된 이미지의 경우는 Fig. 3.4(a)와 같다. 그리고, 만일 수증기 영상을 3시간 단위($w=3$)로 묶어 3시간 단위($t=3$) 평균온도 영상이 필요하다면 영상 이미지는 Fig. 3.6(b)과 같다.




Fig. 3.4 수증기와 온도 영상으로 구성된 신경망 입력 영상

2. 제안 합성곱 신경망 구조

본 논문에서 제안한 신경망 중 입력이 이미지의 크기는 $(x \times 40, 80) = (\text{Height}, \text{Width})$ 형태로 너비 부분은 80픽셀로 고정이고, 깊이 부분은 40픽셀의 배수 크기로 가변이다. 여기서는 x 를 25($25 \times 40, 80$) 즉, $(1000, 80)$ 입력 이미지 크기라 가정해서 신경망 구조 및 가중치 크기를 가정하고 기술한다.

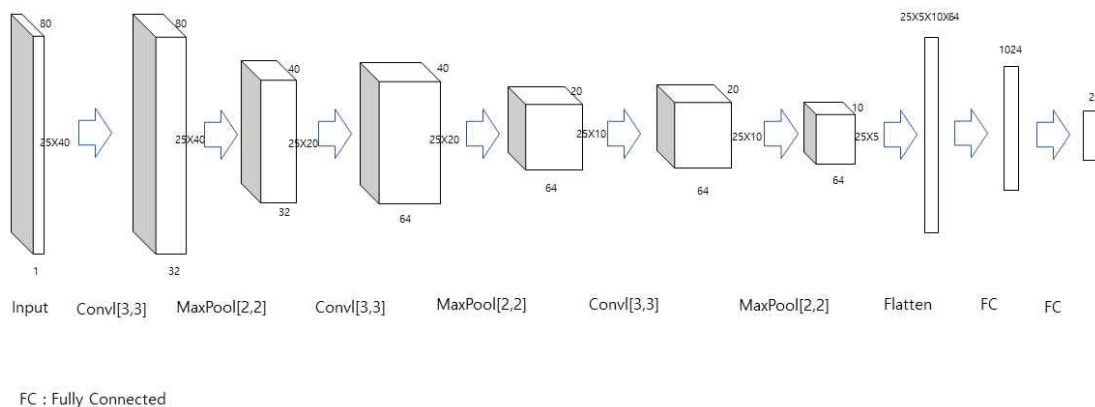


Fig. 3.5 제안 합성곱 신경망 모델

입력 이미지 크기는 이 전에 언급했듯이 1000×80 크기의 흑백 영상을 입력받아 2개 부류 (비, 맑음)으로 분류하는 구조이다. 첫 번째 합성곱 층은 입력 이미지를 제로 패딩에 $3 \times 3 \times 1$ 크기의 필터 32개를 통해 슬라이딩(스트라이드 1을 사용) 시 최외곽에서 한 칸 밖으로 더 움직이는 옵션을 이용하여 합성곱 연산을 한다. 이렇게 해서 합성곱 층에서 $1000 \times 80 \times 32$ 크기의 특징 맵 형태를 생성한다. 다음 풀링 층은 2×2 의 블록 단위로 스트라이드 2씩 움직이면서 최댓값을 곱댓값으로 하면서 $500 \times 40 \times 32$ 크기의 특징 맵을 만든다.

두 번째 합성곱 층에서는 제로 패딩에 스트라이드 1씩 이동하는 $3 \times 3 \times 32$ 필터 64개를 사용해서 특징 맵을 만든다. 따라서 이 층에서는 채널 수가 64개로 늘어나, 특징 맵은 $500 \times 40 \times 64$ 크기가 된다. 이 풀링 층에서는 앞 풀링 층과 같은 기능을 해서 $250 \times 20 \times 64$ 크기의 곱댓값이 생성된다. 세 번째 합성곱 층도 제로 패

딩에 스트라이드 1씩 이동하는 $3 \times 3 \times 64$ 크기 필터 64개를 이용해서 $250 \times 20 \times 64$ 크기의 특징 맵을 만든다. 또, 풀링 층은 2×2 블록 단위로 스트라이드 2씩 움직이면서 최대 풀링형식으로 $125 \times 10 \times 64$ 크기의 특징 맵을 만든다. 네 번째, $125 \times 10 \times 64$ 크기의 3차 구조 형태의 특징 맵을 80000($125 \times 10 \times 64$) 크기의 1차원 형태로 평탄화(Flattening)한다. 이것은 다음 단계인 완전연결 (Fully Connected, FC) 층에서 사용하기 위함이다. 이후는 (80000, 1024) 형태의 완전연결 층과 (1024, 2) 형태의 완전연결 층을 통해 최종 결과를 얻는다.

Table 3.1. 합성곱 신경망의 구조와 학습대상 가중치의 개수

층	필터 /블록크기	필터개수	스트라이드	패딩	노드 개수	가중치 수
입력					1000X80X1 (=80,000)	
Conv:1	3X3X1	32	1	1	1000X80X32 (=2,560,000)	(3X3X1+1)X32 (=320)
Pool:1	2X2		2		500X40X32 (=640,000)	
Conv:2	3X3X1	64	1	1	500X40X64 (=1,280,000)	(3X3X1+1)X64 (=640)
Pool:2	2X2		2		250X20X64 (=320,000)	
Conv:3	3X3X1	64	1	1	250X20X64 (=320,000)	(3X3X1+1)X64 (=640)
Pool:3	2X2		2		125X10X64 (=80,000)	
flatten					80,000	
FC:4					1,024	80,000X1,024 (=81,920,000)
FC:5					2	1,024X2 (=2,048)

제안 신경망의 가중치수는 $81,923,648 (= 320+640+640+81,920,000+2,048)$ 이다. 가중치를 4바이트로 한다면 약 312M 정도의 메모리가 필요하다. 그리고, 전체 노드 수는 5,041,026으로 각 노드가 4바이트를 소요한다면, 약 19M의 저장공간이 필요하다. 가중치 정보와 노드 정보를 합하면 총 약 331M의 메모리를 제안한 합성곱 신경망은 메모리를 사용한다. 제안한 신경망 모델의 경우 입력 층의 높이 크기(x값)를 크게 하면 노드 개수 및 합성곱 층의 가중치 수는 많이 늘어나지 않으나, 완전연결 층 가중치 수가 늘어 신경망 연산 처리 중 대부분 시간을 이

층에서 써야 한다.

합성곱 신경망의 결과를 나타내는 최종 출력 노드는 (y_1, y_2) 2개로 구성된다. 이 노드들은 비가 오는(비) 입력에 대해서는 $(0, 1)$ 로 출력이 되도록 학습된다. 비가 오지 않는 경우(맑음)의 입력에 대해서는 $(1, 0)$ 으로 출력되도록 학습이 된다. 강수 여부는 입력 영상에 해당하는 시간대에 4개 지역 중 한 곳이라도 0.1mm 이상 비가 온 경우와 그렇지 않은 경우로 구분한다.

IV. 구현 및 실험 결과 분석

1. 실험 환경 및 데이터 수집

제안한 합성곱 신경망 구현을 위한 실험 환경으로 Ubuntu 16.04.6 LTS 운영 체제 기반의 워크스테이션을 이용한다. 합성곱 신경망은 많은 부동소수점 연산이 필요하므로 연산능력 향상을 위해 GPU (Graphics Processing Unit)를 사용한다. 그리고, 입력 영상을 위한 전처리와 합성곱 신경망의 구현은 Python 2.7.15rc1 프로그래밍 언어와 텐서플로우 1.13.1 (Tensorflow 1.13.1)를 이용한다. 수집한 수증기 영상과 및 온도 영상을 구성하는데 필요한 기본 기상데이터 및 관련 정보는 Sqlite 3.26.0 DB (Data Base)를 이용하여 관리한다.

수증기 영상과 날씨 정보를 이용하기 위해서는 국가기상위성센터[29]와 기상자료개방포털[30]을 사용한다. 국가기상위성센터에서 천리안위성 (Communication, Ocean and Meteorological, COMS)이 제공하는 한반도 영역의 4년간의(2015 ~ 2018) 15분간 단위의 수증기 영상을 수집하고, 기상자료개방포털에서는 온도, 강수량 등 4년간 1시간 단위 기상정보를 포털에서 제공하는 오픈 API를 통하여 수집한다. 획득한 수증기 영상은 누락분이 있거나, 데이터가 파괴된 것을 분리 및 제거하는 등 검증 과정을 통하여 최종적으로 34,776(1,449일×24시간)장의 수증기 영상을 실험용으로 결정했다. 원래 영상파일은 1024×1024×3(RGB)형태이지만, 실제 필요한 부분은 제주도 및 그 부근으로 원본 영상에서 제주도 영역에 해당하는 40×80×3(RGB) 부분(Fig. 3.2)을 추출하여 파일로 저장한다. 기상자료개방포털에서 오픈 API로 수집한 자료는 종관기상관측 자료이다. 종관기상관측이란 정해진 시각의 대기 상태를 파악하기 위해 모든 관측소에서 같은 시각에 실시하는 지상관측 자료로써, 일자, 시간, 강수량, 온도, 지역으로 구성된다. 수집되는 정보를 관리하기 위해 SQLite DB를 이용하여 테이블로 관리한다.

Table 4.1과 4.2는 기상 측정 위치를 관리하는 JejuLoc 테이블과 특정일자, 시

간의 강수와 온도를 다루는 JejuWetHr2 테이블을 보여준다. JejuLoc 테이블에는 제주, 고산, 성산, 서귀포 지역의 코드 정보가 담겨 있다. 이들 4개 지점에서 측정한 강수 여부는 제주도 전체 강수 여부의 판단기준이 된다. JejuWetHr2 테이블은 2015년부터 2019년 1월 까지 강수량, 온도 등 시간대별 날씨 정보를 관리한다. 특히 시간 부분은 0~23시 까지 24시간을 표시했다. 표현 방식은 1시 인 경우 '01' 형태이다.

Table 4.1 JejuLoc 테이블

이름(컬럼)	타입	설명	Primary Key
LocCode	TEXT	지역코드	Yes
LocName	TEXT	지역명	No

Table 4.2 JejuWetHr2 테이블

이름(컬럼)	타입	설명	Primary Key
CalDate	TEXT	일자	Yes
Hour	TEXT	시간(00,01,...,22,23)	Yes
LocCode	TEXT	지역코드	Yes
RainAmt	REAL	강수량(mm)	No
Temp	REAL	기온(°C)	No

DB에 저장된 정보에 대한 분포를 분석해보면 제주, 고산, 성산, 서귀포 중 한 지역이라도 0.1mm (테스트 시 목표 강수량)이상이 관측된 강수일수는 전체 1449일 중에서 643일로 44.7%에 해당한다. Table 4.3에서 24시간 단위 수증기 영상인 경우 개수는 강수일수와 같다.

Table 4.3 시간단위 수증기 영상 자료 분포

요건 수증기(시간 단위)	날씨		비		맑음	
	개수	비율	개수	비율	개수	비율
1	4,103	11.7	30,673	88.3		
2	2,814	16.2	14,574	83.8		
24	643	44.4	806	55.6		

성능평가를 위한 실험에서는 비와 맑은 날에 대한 훈련 자료 비율을 다양하게 조정하면서 실험한다. 강수일수가 전체의 44.4%이기 때문에 특히, 랜덤하게 훈련용 데이터를 선택할 때는 비 온 날보다 맑은 날에 해당하는 훈련용 데이터가 더 많이 선택될 것이다. 이를 통하여 훈련 데이터의 비율에 따른 제안한 합성곱 신경망의 성능을 비교해 봄으로써 최적의 훈련 데이터 비율을 찾는다.

기상청에서 강수확률은 현재와 유사한 대기 상태에서 예보기간 중 지정된 장소에 0.1mm 이상 강수가 내릴 가능성을 확률로 나타낸 것이다. 만일, 동네예보인 경우 예보기간은 3시간이 된다 [31, 32, 33]. 따라서 기상청에서 사용하는 0.1mm 이상을 강수로 보는 기준이 우리 실험에도 적용 가능하다고 판단하고 강수 여부 즉, 비와 맑음의 구분 기준으로 강수량 0.1mm 이상을 사용한다.

제안하는 합성곱 신경망과 성능 비교를 위하여 기존의 텍스처 분석에 사용된 두 개의 합성곱 신경망을 함께 구현한다. 본 연구에서는 비교 모델로써 Alexnet [34]과 VGG16 [35]을 선정한다. 두 개의 모델에 대해서 전체적인 구조는 유지하면서 결과 비교를 위하여 입력 층과 최종 출력 층의 구조를 수정한다. Alexnet의 경우에는 원래 모델에서의 입력 층은 $224 \times 224 \times 3$ 의 크기이지만, 본 연구에서의 입력 영상을 사용하기 위하여 $(x \times 40) \times 80 \times 1$ 로 변경하고 출력의 수는 1000에서 2로 수정한다. 그러나 Alexnet의 원래 구조인 합성곱 층 5개와 완전연결 층 3개는 그대로 유지한다. 활성화 함수로 ReLU를 사용하며, 합성곱 결과를 이웃 커널 값을 고려하여 조정하는 지역 반응 정규화와 과잉적합 방지를 위해 드롭아웃을 사용한다.

VGG16은 13개의 합성곱 층과 3개의 완전연결 층으로 구성된 모델로써, 합성곱 층에서 사용한 필터의 크기는 3×3 이다. Alexnet과 마찬가지로 제안한 모델과 같은 입력 데이터와 출력 데이터를 사용하기 위해서 VGG16에 대해서도 입력 층의 크기를 $(x \times 40) \times 80 \times 1$ 로 변경하고 출력의 수는 1000에서 2로 수정한다. 비교를 위한 최종 Alexnet과 VGG16 모델의 구조는 Table 4.4과 4.5에 나타나 있다.

Table 4.4 수정 전후 Alexnet

	수정 전	수정 후
Input	224×224×3(RGB)	(x×40)×80×1(Gray)
		conv11-96
		conv5-256
		maxpool
		conv3-384
		maxpool
		conv3-384
		conv3-256
		maxpool
		flatten
		FC-4096
		FC-4096
	FC-1000	FC-2

Table 4.5 수정 전후 VGG16

	수정 전	수정 후
Input	224×224×3(RGB)	(x×40)×80×1(Gray)
		conv3-64
		conv3-64
		maxpool
		conv3-128
		conv3-128
		maxpool
		conv3-256
		conv3-256
		conv3-256
		maxpool
		conv3-512
		conv3-512
		conv3-512
		maxpool
		conv3-512
		conv3-512
		conv3-512
		maxpool
		FC-4096
		FC-4096
		FC-1000
	soft-max	flatten
		FC-1000
		FC-2
		soft-max

2. 실험 결과 및 분석

학습데이터의 선정은 신경망의 학습 효율 및 인식률에 영향을 미치는 중요한 요소(Factor)이다. 그 이유는 전체 데이터에서 각 그룹 (비, 맑음)에 대해서 대표성을 가지는 학습데이터를 사용한 학습이 중요하기 때문이다. 본 논문에서는 이런 점을 고려하여 1) 비와 맑음에 대한 비율을 무작위로 선정하여 학습하는 방법과 2) 비와 맑음 데이터를 1:1의 비율이 되도록 하여 학습하는 방법을 사용한다. 무작위 추출에서는 비 비율은 전체 데이터의 비 비율과 유사한 각각 12, 16, 44%로 추출된다. 비율을 1:1로 하는 실험에서는 비의 경우와 맑음의 경우의 학습데이터 수를 인위적으로 맞추는 추출방법을 사용한다. 두 경우에 대해서 실험을 한 후, 나머지 데이터를 테스트용으로 사용한 성능평가 결과를 바탕으로 우수한 결과를 나타내는 방법을 최종적인 실험 방법으로 선택하고 분석한다.

신경망을 통한 텍스처 분석에서는 일반적으로 입력 영상에 나타나는 노이즈나 명암 등을 보정하기 위해 히스토그램 균등화(Histogram Equalization)를 사용한다. 본 논문에서도 히스토그램 균등화가 필요한지를 확인하기 위하여 히스토그램 균등화를 한 영상과 하지 않은 영상을 사용한 인식/분류 실험을 통하여 사용 여부를 판단한다. 사전 실험 결과 (Table 4.6), 본 논문에서 대상으로 하는 수증기 영상의 경우는 히스토그램 균등화가 미치는 영향이 없는 것으로 판단되어 입력 영상에 대해 전처리는 하지 않는다.

Table 4.6 제안 모델에 히스토그램 균등화 전후 정확도
(2015~2018년 6월분 수증기 영상 자료)

요건 \ 모델			전 (원 영상)			후 (균등화 사용 영상)		
			전체	강수	맑음	전체	강수	맑음
강수 (mm)	온도 (개수)	수증기 (시간)	68.8	20.6	85.8	68.3	18.6	85.8
0.1	0	2						

2.1 실험 결과

먼저 무작위로 선택한 훈련용 데이터를 사용하는 실험을 진행한다. 전체 데이터를 훈련용과 테스트용 75대 25 비율로 분류한다. 단, 분류 시 랜덤 선택 방식을 채택한다. 전체 대비비 영상 비율은 테스트용과 훈련용 모두 수증기 영상을 몇 시간 단위로 조합하느냐에 따라 Table 4.3과 같다. 2시간 단위 이상인 경우, 하나의 수증기 영상이 강수량 0.1mm 이상이면 나머지 영상의 강수 여부와 상관없이 비 라벨을 부여받기 때문에, 시간 단위가 많아지는 조합일수록 비 영상을 포함할 확률은 높아진다. 실험 결과는 1시간 단위, 2시간 단위, 24시간 단위 등에 상관없이 맑음이면 자료에 대한 정확도가 대부분 비 자료 보다 높게 나타난다. Table 4.7에 나타난 결과는 비보다 많은 맑음 자료가 훈련에 더 많은 비중으로 이용됨에 따라서, 맑음에 대한 정확도가 높아진 것으로 판단된다. Table 4.7에 나타난 강수, 온도 및 수증기의 의미는 강수를 판단하는 기준과 사용된 온도 영상 수 및 사용된 수증기 영상 수를 나타낸다. 만약 수증기 항목이 24이고 온도 항목이 1이면 수증기 영상의 경우는 관측된 수증기 영상 24개 (1일 24시간), 온도 영상은 1일 기온의 평균값을 사용한다는 것을 의미한다.

Table 4.7 랜덤 선택(훈련용:테스트용=3:1) 자료의 개별정확도(%)

요건 \ 모델			제안 모델			Alexnet			VGG16		
강수 (mm)	온도 (개수)	수증기 (시간)	전체	비	맑음	전체	비	맑음	전체	비	맑음
0.1	0	2	78.2	31.3	87.3	80.1	22.4	91.3	81.0	22.8	92.3
0.1	0	24	59.8	56.4	62.3	62.8	62.2	63.3	59.8	52.6	65.2
0.1	1	24	63.1	61.1	64.7	67.5	64.2	70.1	59.2	58.6	59.7
0.1	0	1	83.7	21.3	92.3						

훈련용 자료의 비와 맑음 비율이 같은 경우는 실험 결과는 랜덤 선택 방식과 정확도에서 다른 양상을 보인다. 테스트 결과인 정확도는 랜덤 분류에서는 훈련 시 맑음 자료가 상대적으로 높아 비와 맑음 자료 비율에 따른 영향을 크게 받지 만, 훈련 시 비와 맑음 자료 동일 비율에서는 온도 영상 개수와 수증기 영상 시간단위 조합 비율에 영향을 많이 받는다. 온도 영상 없이 수증기 1시간 단위로

테스트한 경우 비와 맑음에 대한 정확도 약 62%, 63%로, 수증기 24시간 단위 테스트의 약 59%, 59%보다 정확도가 높다. 1시간에 0.1mm가 1일 동안 0.1mm인 경우보다 강수 패턴 정보가 수증기 영상에 더 많이 포함되기 때문일 것이다. 그러나 랜덤 분류보다 정확도 차이는 줄었다. 그리고, 24시간 단위 수증기 영상과 임의의 시간마다 온도 영상을 추가 한 경우와 아닌 경우 정확도 다소 차이가 있지만, 최고 비와 맑음이 약 71%의 정확도를 보인다. 1일 동안 24개(24시간 단위) 수증기 영상과 4시간마다 추출한 6개의 온도 영상의 조합 영상 $((24+6) \times 40) \times 80 \times 1$ 의 패턴을 분석한 결과 다음과 같다. 비, 맑음을 맞출 확률은 각각 제안 모델은 약 73%, 71%, Alexnet은 약 63%, 79%, VGG16은 약 60%, 71%이다. 2시간단위 수증기 영상 조합 $((2 \times 40) \times 80 \times 1)$ 의 경우 제안 모델은 약 63%, 64%, Alexnet은 약 63%, 60%, VGG16은 약 64%, 59%이다. 조합 영상 중에 수증기 영상이 24개 이상이면 전체항목 평균 정확도는 제안 모델 약 66%, Alexnet은 약 66%, VGG16은 약 65%로 거의 대동소이하다. 그러나, 2시간 단위 즉, 2개 수증기 영상의 분석 시 제안 모델이 정확도가 제일 높다. 날씨 예보에서 날씨가 맑다는 정보보다 비가 온다는 점에 더 가중치를 주듯이, 이를 고려해 Table 4.7, Table 4.8을 위한 테스트 결과 가운데서 대푯값을 선택한다.

Table 4.8 비:맑음 동일 비율 자료의 개별 정확도(%)

모델			제안 모델			Alexnet			VGG16		
요건	온도	수증기	전체	비	맑음	전체	비	맑음	전체	비	맑음
강수 (mm)	(개수)	(시간)									
0.1	0	24	59.0	59.0	59.0	64.5	65.8	63.9	60.4	60.2	60.5
0.1	1	24	62.9	60.2	64.2	62.9	73.3	57.7	66.8	58.4	71.0
0.1	2	24	62.9	59.0	64.8	67.0	65.8	67.6	64.1	60.9	65.7
0.1	4	24	63.9	65.2	63.3	65.6	57.1	69.8	63.7	59.0	66.0
0.1	6	24	71.3	72.7	70.7	63.1	78.9	55.2	67.6	60.2	71.3
0.1	8	24	66.2	64.6	67.0	68.4	66.5	69.4	64.9	67.7	63.6
0.1	12	24	71.3	67.1	73.5	68.7	69.6	68.2	65.8	68.3	64.5
0.1	24	24	71.7	70.8	72.2	66.8	69.6	65.4	68.9	75.7	65.4
0.1	0	1	65.1	61.6	62.6						
0.1	1	1	67.7	66.2	67.7						
0.1	0	2	64.4	63.3	64.5	60.1	63.2	60.0	59.2	64.2	59.0

2.2 학습 효율 및 오인식 분석

실험을 통하여 제안한 합성곱 신경망이 비교 시스템인 Alexnet과 VGG16에 비하여 제주의 강우패턴 분석에서 높은 인식률을 나타냄을 보였다. 인식률은 신경망 시스템의 성능을 측정하는 중요한 척도로 널리 사용되고 있으므로, 이러한 높은 인식률은 제안시스템이 제주의 강우패턴 분석에 유용함을 보여준다. 인식률 외에도 신경망의 성능을 평가 할 수 있는 방법의 하나가 학습속도(수렴속도)다. 빠른 학습속도를 가지는 신경망의 경우는 성능 향상을 위한 재학습이 쉬우므로 높은 인식률을 빠른 시간에 얻는 시스템은 실제 응용에서 또한 유용하다. 제안시스템과 비교 시스템의 수렴 패턴이 Fig 4.1에 나타나 있다. Fig. 4.1에서 보듯이 제안시스템은 Alexnet보다 수렴속도가 늦지만 VGG16보다 빨리 수렴하는 것으로 나타난다. 그러나 학습에 대한 목표치에 해당하는 70% 이상의 인식률에 이르는 속도는 제안시스템이 가장 빠름을 보여준다. 이런 결과는 제안 모델이 평균 정확도가 다른 모델에 뛰어나면서도 타 모델보다 효율적임을 보여준다.






Fig 4.1 제안시스템과 비교시스템간 수렴 속도 비교


Fig 4.2는 제안시스템에서 오인식된 테스트 영상의 일부다. 제안시스템에서 비를 맑음으로, 맑음을 비로 오인식한 24시간 단위(24개) 수증기 영상과 4시간 단위(6개) 온도 영상의 입력패턴이다. 수증기 영상은 흰색 (구름역), 회색 (수증기역), 검은색 (건조역)으로 구성된다고 I 장에서 언급했다. 각 영상에서 좌로 두 번째 이미지만 온도 영상이고, 나머지는 수증기 영상이다. 그리고, 괄호 전은 실제 날씨를 괄호 안은 제안 모델이 오인식한 날씨(라벨)를 의미한다. 따라서 (a) 영상은 2016년 7월 7일 날씨가 원래 비였지만, 제안 모델이 맑음으로 인식한 것을 의미한다. Fig 4.2에서 {(a), (b)}, {(c), (d)}, 그리고 {(e), (f), (g)} 그룹 영상은 수증기 영상의 각 회색 영역, 검은색 영역, 흰색 영역의 분포 유사성 기준으로 분류했다. {(a), (b)}, {(e), (f), (g)} 그룹 영상은 회색 또는 흰색 영역이 넓어 수증기량이 많음을 추측할 수 있고, {(c), (d)}는 검은색 영역이 넓어 건조하여 날씨가 맑으리라 추측할 수 있다. 그러나, 각 그룹 내의 영상은 원래 날씨가 비였는데 제안 모델이 맑음으로 판단하거나, 그 반대로 판단한 예를 모두 포함한다. 특히 {(e), (f), (g)} 그룹에서는 (g)는 (e)에 비해 (f)는 온도 영상의 차이가 크다. 그리고, 제안 모델은 (e), (f)를 맑음으로, (g)를 비로 오인식했다. 그런데, {(c), (d)} 그룹 영상에 (c) 영상은 실제 날씨가 비로 특별한 사례지만, (d)와 유사한 영상의 경우는 대부분 맑음으로 인식했으며, 오히려 (d)가 예외적으로 오인식한 예이다. 따라서, 오인식을 줄이기 위해서는 실험에 사용했던 4년 치보다 많은 수증기 영상 자료가 필요하리라 본다.



(a) 2016/7/7 비(맑음) (b) 2016/10/9 맑음(비)



(c) 2017/3/29 비(맑음) (d) 2017/3/9 맑음(비)



(e) 2016/7/1 비(맑음) (f) 2017/3/31 비(맑음) (g) 2017/7/17 맑음(비)

Fig 4.2 제안 모델의 오인식 예

V. 결론 및 향후 연구 방향

본 논문에서는 수증기 영상과 온도 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 합성곱 신경망 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 가르는 기준을 정하고 하루 시간별 수증기 영상 24개와 일 평균 온도 영상 6개를 입력으로 받는 실험을 수행한 결과 약 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 합성곱 신경망에 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.

강수를 판단하기 위해 수증기 영상과 기온에 대한 영상만을 사용한 것과 테스트 기간을 4년간에 국한한 것은 본 연구 결과를 일반화시키는데 제약으로 작용한다. 그리고 현재 기상청에서 사용하는 현업 강수 분석 모델과의 직접 비교 분석이 아닌 간접 비교를 통한 성능평가 방법은 개선될 문제이다. 이런 문제점은 국가기상위성센터에서 제공하는 가시, 적외, 근적외, 단파적외영상과의 앙상블 결합을 통하여 입력을 추가하고, 10년 이상의 기간에 대해서 실험을 하면서 제안 방법의 문제점이나 한계점을 찾고, 이를 해결하는 방안에 대한 향후 연구를 통하여 해결이 가능할 것이다. 또한, 기상모델을 연구하는 다양한 분야와의 공동연구를 통하여 완성도를 높일 수 있도록 할 것이다. 이러한 방향으로 실용적이고 효과적인 강수 패턴 분석을 위한 인공지능 기법 연구를 진행할 예정이다.

VI.참고 문헌

- [1]국가기상위성센터, 기상위성영상의 이해(I), 국가기상위성센터, 2013
- [2]최광용, 한라산의 사계절 극한강수현상 발생 패턴, 기후연구 제8권 제4호, 건국대학교 기후연구소, 2013, pp. 267~280
- [3]제주지방기상청, 지역기후변화보고서[제주도], 제주지방기상청, 2011
- [4]Frederick K. Lutgens · Edward J. Tarbuck, 대기과학 제13판, 안중배 · 김준 · 류찬수 · 박선기 · 서명석 · 이화운 · 정일웅 · 정형빈 역, (주)시그마프레스, 2016
- [5]기상청, http://www.weather.go.kr/weather/lifenindustry/disaster__02.jsp, (접속일:2019.10.07.)
- [6]제주지방기상청, 제주도 상세기후특성집, 제주지방기상청, 2010
- [7]손태성, 제주도의 강수량 및 계급별 발생일수 비교 분석을 통한 강우강도 변화 연구, 제주발전연구 제15호, 제주연구원, 2011, pp. 159~177
- [8]국가기상위성센터, 2018년도 연차보고서, 국가기상위성센터, 2018
- [9]유희상 · 류근수 · 이규원, MAPLE을 이용한 히마와리 위성의 초단기 예보 정확도 및 민감도 분석, 2016년 한국기상학회 가을학술대회 논문집(2016.10), 한국기상학회, 2016, pp. 648 - 649
- [10]김권일 · 이호우 · 정성화 · 류근수 · 이규원, 변분예코추적법을 이용한 제주도 지역 여름철 강수계의 이동 특성 분석, 대기 Vol.28 No.4 (2018.12), 한국기상학회, 2018, pp. 443-455
- [11]Luiz G. Hafemann, L. S. Oliveira, and P. Cavalin, "Forest species recognition using deep convolutional neural networks", 2014 22nd International Conference on Pattern Recognition, 2014, pp. 1103 - 1107
- [12]마이클 네그네빗스키, 인공지능 개론, 김용혁 역, 한빛아카데미, 2013
- [13]도용태, 김일곤, 김종완, 박창현, 강병호, 인공지능 : 개념 및 응용 4판 , (주)사이텍미디어, 2014
- [14]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), 2006, pp.1527 - 1554
- [15]G. E. Hinton and R. R. Salakhutdinov, “Reducing the Dimensionality of
Data with Neural Networks”, Vol. 313, Issue 5786(Science 28 Jul 2006),
2006, pp. 504-507
- [16]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
- [17]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
- [18]오일석, 기계학습, 한빛아카데미(주), 2018
- [19]이건명, 인공지능:튜링 테스트에서 딥러닝까지, 생능출판사(주), 2018
- [20]니컬 부두마, 딥러닝의 정석:텐서플로와 최신 기법으로 배우는 딥러닝
알고리즘 설계, 고광원·금경목 역, 한빛미디어(주), 2018
- [21]마샤 모라디·이태삼, 수문학적 예측을 위한 딥러닝기반 인공신경망의
최적화 알고리즘 비교: 남강댐 일유출량을 사례를 중심으로,
제18권 6호 2018년 10월, 한국방재학회, 2018, pp. 377-384
- [22]오일석, 컴퓨터 비전, 한빛아카데미(주), 2015
- [23]Rafael C. Gonzalez·Richard E. Woods, 디지털 영상처리 3판, 유현중·
김태우·오춘석 역, (주)피어슨에듀케이션코리아, 2013
- [24]Vincent Andrearczyk, “Deep learning for texture and dynamic texture
analysis”, PhD thesis, Dublin City University, 2017
- [25]Yann LeCun, Leon Bottou, Yoshua Bengio and Patrick Haffner,
“Gradient-based learning applied to document recognition”, Proceedings of
the IEEE (Volume: 86 , Issue: 11 , Nov 1998), 1998, pp. 2278-2324
- [26]F. H. C. Tivive and A. Bouzerdoum, “Texture classification using

- convolutional neural networks”, TENCON 2006 - 2006 IEEE Region 10 Conference, 2006, pp. 1 - 4
- [27]Phil. Brodatz, “Texture: A photographic album for artists and designers”, Dover Pubns, 1966
- [28]V. Andrearczyk and P. F. Whelan, “Using filter banks in convolutional neural networks for texture classification”, Pattern Recognition Letters vol. 84, 2016, pp. 63-69
- [29]국가기상위성센터, <http://nmsc.kma.go.kr/homepage/html/main/main.do>,
(접속일:2019.10.07.)
- [30]기상자료개방포털, <https://data.kma.go.kr/cmmn/main.do>,
(접속일:2019.10.07.)
- [31]예보용어해설, https://web.kma.go.kr/HELP/html/help__fct008.jsp ,
(접속일:2019.10.07.)
- [32]강수확률정의,
<http://www.isntimes.co.kr/news/articleView.html?idxno=2294>,
(접속일 :2019.10.07.)
- [33]기상청, 초급 예보관 훈련용 교재 : 수치예보, 기상청
- [34]Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, Proceeding NIPS’12 Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, 2012, pp. 1097-1105
- [35]Karen Simonyan, Andrew Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, conference paper at ICLR 2015, 2014