

무인기를 이용한 인공지능 기술 기반의 농작물 피해 예찰 시스템

문현준 (세종대학교)

목 차

1. 서 론
2. 무인기를 이용한 데이터베이스 구축
3. 재배지역 영역 분류 및 영역화
4. 딥 러닝 기반의 무 시들음 병 검출
5. 결 론

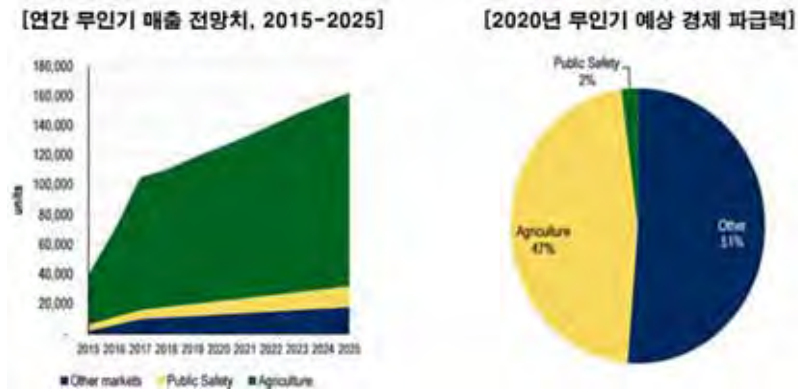
1. 서 론

최근 4차 산업혁명 시대의 급속한 발전은 새로운 시장의 성장 동력 창출 등 다양한 사회적 수요에 대응하기 위하여 Information & Communication Technology (ICT) 기반 기술 융합 및 활용의 필요성이 대두되고 있다. ICT 및 융복합 기술은 기존 산업 간 시너지의 극대화를 가능하게 하는 핵심 기술이다. 최근 각광받는 클라우드, 빅데이터, 인공지능 등의 IT 기술을 다양한 분야와 융합기술로 발전시킬 수 있는 수단으로써 주목받고 있다. 특히, 최근 컴퓨팅 환경의 비약적인 발전과 더불어 기계가 지능을 갖고 판단할 수 있는 인공지능 및 딥러닝 기술이 주목을 받으면서 사람이 사물을 인지하는 과정에 필수 요소인 컴퓨터 비전 관련 기술에 대한 수요가 증가하고 있다. 컴퓨터 환경에서의 비전 기술은 ICT 기반 융합의 핵심기술 향후 지속적인 발전 가능성을 내

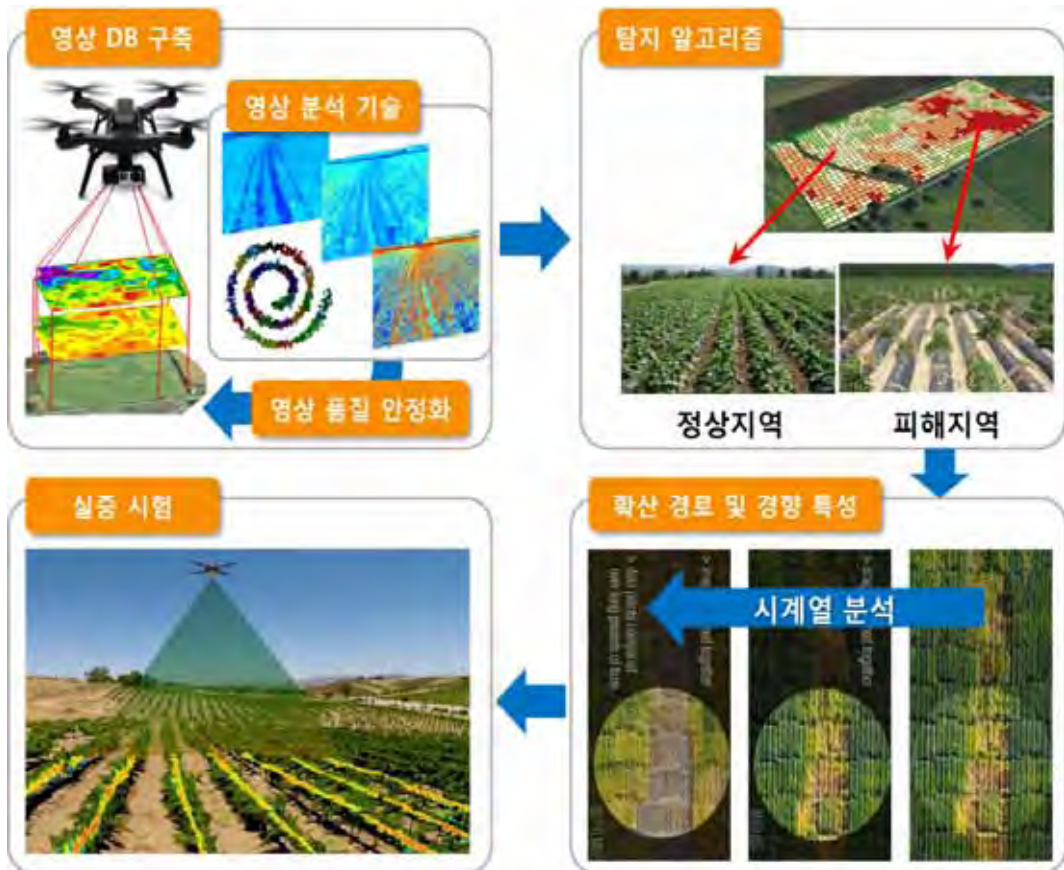
포하고 있다. 컴퓨터 비전 기술이 무인기(드론), 자동차 등에 활용되면서 사용자들에게 편의성을 제공해 주기 위한 다양한 연구가 진행되고 있다.

무인기의 경우 최근 보급이 증가하며 무인기를 활용한 다양한 예찰 시스템이 제안되고 있다. 미국 국제무인기협회(AUVSI)[1] 분석 자료에서 확인할 수 있는 것과 같이 무인기의 시장 규모는 2025년 까지 85조원에 이를 것으로 예상된다(그림 1).

최근 미국 및 중국에서는 농업용 무인기 관련 시장이 매년 성장하고 있지만, 국내의 무인기 시장의 경우 대부분이 군사용에 집중되어 있어 실제 농업 현장에 활용도는 매우 낮은 실정이다. 때문에 하드웨어 환경에서 구동 가능한 소프트웨어 기술에 대한 공급은 매우 부족하며, 향후 해당 기술에 대한 요구가 증가하는 경우 상대적으로 취약할 수밖에 없을 것으로 예상된다. 본 연구는 농업분야와 IT분야의 ICT 융합연구를 컴



(그림 1) 무인기 시장 동향 (출처: AUVIS)



(그림 2) ICT 기반 무 시들음 병 예찰시스템 과정

퓨터비전과 인공지능 기술을 무인기와 딥러닝 기반으로 무 재배지에서 발생된 시들음 병을 예

찰하는 시스템을 제안한다 (그림 2).

2. 무인기를 이용한 데이터베이스 구축

2.1 재배지 영역 데이터베이스 구축

본 연구에서는 무인기와 인공지능 기술을 기반으로 무 재배지 영역 분류 및 무 시들음 병 예찰을 최종목표로 한다. 무인기를 이용한 재배지 영역의 무 시들음 병의 검출을 위하여 가시광선 및 Normalized Density Vegetation Index (NDVI) 영상을 획득하는 과정이 필요하다. 재배지 영역은 크게 무, 포장, 땅 세 가지로 분류하고 컴퓨터비전 기술을 통한 영역 분류를 위해 딥러닝을 위한 데이터베이스를 구축하였다. 획득한 재배지 영상에서 영역을 표기하고 표시된 정보를 통해 재배지 영역 데이터베이스를 구축하였다 <표 1>. 이미지의 크기는 선택된 영역에 따라 다양한 크기를 가진다.

<표 1> 재배지 영역 데이터베이스 구축 결과

	데이터베이스 예시	데이터 수
무 영역		620 개
땅 영역		580 개
포장 영역		506 개

2.2 무 시들음 병 데이터베이스 구축

본 연구에서는 무 시들음 병 분류를 위한 데이

터베이스 구축을 위해 무 재배지역의 무와 실험실 재배 무에 대한 영상을 획득하였다 [2]. 무 재배지역에서 발생하는 시들음 병은 크게 정상, 초·중기, 후기 세 가지 단계로 구별할 수 있다. 따라서 무 시들음 병 데이터베이스는 병 단계에 따른 정상, 초·중기, 후기 세 가지로 분류하여 구축하였으며, 해당 부분을 표기하여 데이터베이스를 구축하였다. 또한 시들음 병 데이터베이스의 신뢰성을 높이기 위하여 해당 분야 전문가의 도움을 받아 시들음 병 단계에 따른 데이터베이스를 검증하였으며, 구축 결과는 <표 2>와 같다.

<표 2> 무 시들음 병 데이터베이스 구축결과

	데이터베이스 예시	데이터 수
정상 무		1552 개
초·중기 시들음 무		445 개
후기 시들음 무		283 개

3. 재배 지역 분류 및 영역화

3.1 재배지 영역 특징 추출

본 연구에서는 획득한 영상의 영역의 분류의 정확성을 높이기 위해 영상 데이터에서 특징을 추출할 때 색상 특징뿐만 아니라 질감 특징을 추

출하였다.

3.1.1 색상 기반 특징 추출

재배지 영역 이미지 데이터베이스를 사용하여 각 재배지 영역에 대한 각각의 RGB, HSV, Lab 컬러 채널에 따른 재배지 영역의 평균 히스토그램을 계산하였을 때, 재배지 영역 별 히스토그램 분포의 차이가 클수록 각각의 영역을 대표하는 유효한 특징이 될 수 있다. 따라서 재배지 영역간의 평균 히스토그램 분포의 코사인 유사도 (Cosine Similarity)를 계산하여 재배지 영역을 대표할 수 있는 컬러 채널을 파악하였고 결과는 <표 3>과 같다.

<표 5>의 결과를 통해 Hue, a, b 컬러 채널에서 각각의 재배지 영역의 히스토그램의 분포가 큰 차이를 보이는 것을 알 수 있으며 이 세 가지 컬러 채널의 히스토그램 분포를 재배지 영역 분류를 위한 색상 기반의 특징으로 추출하였다. 또한 인공신경망 기반의 Auto Encoder (AE) [3, 4]를 적용하여 차원을 축소하였다. 추출한 색상 특징 중 의미 있는 특징을 축소된 차원으로 표현하기 위해 두 개의 AE를 중첩하여 학습하였다. 첫 번째 AE는 786개의 입력을 hidden 계층을 통해 384개의 특징으로 압축하고 두 번째 AE는 첫 번째 AE 학습을 통해 얻어진 384개의 입력을 최종적 100개의 특징으로 압축하였다. 이 과정은 (그

<표 3> 컬러 채널 별 재배지 영역간의 코사인 유사도

	무 / 땅 유사도	무 / 포장 유사도	땅 / 포장 유사도	평균 유사도
RED	0,22	0,97	0,33	0,50
GREEN	0,66	0,97	0,53	0,72
BLUE	0,62	0,78	0,94	0,78
Hue	0,05	0,38	0,48	0,30
Saturation	0,89	0,30	0,23	0,47
Value	0,34	0,96	0,35	0,55
L	0,52	0,97	0,48	0,66
a	0,05	0,22	0,32	0,20
b	0,68	0,31	0,17	0,39


림 3)과 같다.

3.1.2 질감 기반 특징 추출


Local Binary Pattern (LBP) 특징 추출을 위한 변수인 반지름과 주변 영역을 각각 (1,8), (2,16), (3,24)로 설정하여 재배지 영역 데이터베이스를 분석하였다. LBP를 통해 계산된 재배지 영상의 LBP 특징 분포를 계산하여 각각 무, 땅, 포장 역역에 대한 질감 특징을 추출하였고 적용 결과는 (그림 4)와 같다.

3.2 주요 특징 판별

추출된 특징 중 의미 있는 특징을 판별하고 선택하여 사용하기 위해 Wincoxon Rank-Sum



(그림 3) 특징 추출을 위한 인코딩 과정



(그림 4) LBP 적용결과 예시

test [5]와 Out-of-Bag 추정을 통해 특징의 중요도를 판별하였다. 먼저, Wincoxon Rank-Sum test를 통해 얻어진 각각 무/땅, 무/포장, 땅/포장 특징에 부여된 순위를 이용하여 p-value(유의확률)를 산출하였고 p-value 값들을 통해 재배지 영역의 주요한 특징을 선택하였다. p-value 값이 작을수록 데이터 간의 관계가 약하다는 것을 의미하므로 각 영역들의 특징들 간 0.01 이하의 p-value 값을 가지는 특징들을 선택하였다. 또한 50개의 트리를 가지는 Random Forests 모델을 학습하여 Out-of-Bag (OOB) 오차를 계산하였다. 중요도는 OOB 오차와 원본 데이터를 학습하여 얻은 오차 간 차이의 평균을 통해 정의가 된다. 따라서 학습의 결과로 얻어진 특징의 중요도 점수를 기반으로 0 이상의 중요도 점수를 가지는 특징만을 선택하였다. Wincoxon Rank-Sum test 및 Out-of-Bag Estimation을 통해 추출된 70만 개의 특징 중 1770개의 의미 있는 특징을 선택하여 재배지 영역 분류를 위한 특징으로 사용하였다.

3.3 재배지 영역 분류

앞서 재배지역 영역의 특징을 추출한 결과 1770개의 특징이 추출되었다. 추출된 1770개의 특징들을 입력으로 하고 3개 출력을 가지는 인공 신경망 기반의 softmax 분류기를 학습하여 재배지 영역을 분류한다. softmax 분류기는 200번의 반복을 통해 학습되었고 Mean Squared Error (MSE) 비용함수를 통해 오차율을 계산하였다. 학습된 softmax 분류기를 K-fold Cross-Validation을 통해 성능을 검증하였다. K=3으로 설정하여 3-fold cross validation을 통해 softmax 분류기를 검증하였고 검증 결과는 <표 4>와 같다. 무

<표 4> 재배지 영역 분류 결과

Class / Prediction	무 영역	땅 영역	포장 영역
무 영역	620 (100.0%)	0 (0.0%)	0 (0.0%)
땅 영역	0 (0.0%)	573 (98.8%)	7 (1.2%)
포장 영역	0 (0.0%)	12 (2.4%)	494 (97.6%)

영역의 경우 100% 올바르게 분류하였으며 땅/포장 영역 분류에 일부 오차가 발생하는 것으로 나타났다. 학습된 분류기의 정확성 검증 결과 전체적으로 최소 97.62% 이상의 분류결과를 보이는 것으로 확인 되었다.

3.4 재배지 영역화

k-means clustering(군집화) 알고리즘을 사용하여 재배지역을 영역화 하였다. 재배지역 영상의 효율적인 군집화를 위해 재배지 영역 간 색상에서 큰 차이를 보이는 HSV, Lab 색 공간으로 변경한 후 Hue, a, b, 컬러 채널로 영상을 구성하고 k-means 알고리즘을 적용하여 군집화 하였다. 각각 유사한 픽셀 값으로 군집화 된 영상은 학습된 softmax 분류기를 통해 무/땅/포장 영역으로 분류하였다. 그리고 영역화 된 이미지의 정확성은 ground truth를 기반으로 평가되는데 무 재배 지역에서 수작업으로 선택된 무, 땅 포장 영역을 ground truth로 사용하여 성능을 평가하였다. 영역화 된 결과 이미지의 정확성을 평가하기 위하여 영역화 된 결과이미지와 수작업으로 재배지역에서 선택된 영역을 비교하여 픽셀 분류 정확성을 측정하였다[6]. 픽셀 분류 정확성은 영역화 된 결과 이미지와 수작업으로 선택된 재배지 영역과의 픽셀 값 비교를 통해 영역화 결과의 분류 정확성을 판단한다. 재배지역 영역화 결과는 3-fold cross validation을 통해 정확도를 평가하

〈표 5〉 클러스터 수에 따른 영역화 성능 평가 결과

클러스터 수	무 영역	땅 영역	포장 영역	전체 결과
3	93.21%	92.80%	56.38%	90.01%
5	91.47%	93.82%	92.41%	92.01%
10	92.87%	94.44%	91.10%	93.02%
15	87.49%	91.40%	92.38%	88.66%
20	81.31%	87.40%	92.66%	83.38%

였다. 즉, 3-fold로 나누어진 학습 데이터를 통해 훈련된 분류기로 클러스터를 분류하고 훈련 데이터 셋을 통해 영역화의 정확성을 평가하였다. 〈표 6〉은 클러스터 수에 따른 영역화 정확도를 보여준다.

4. 딥 러닝 기반의 무 시들음 병 검출

4.1 CNN 모델을 통한 무 시들음 병 분류

본 연구에서는 VGGnet[7]를 이용하여 무 재배지역의 시들음 병을 분류 및 검출하였다. VGGnet은 2013년 ILSVRC[8]에서 소개된 Convolutional Neural Network (CNN) 모델 중 하나이다. VGGnet은 이전에 제안되었던 CNN 모델보다 CNN을 구성하는 계층의 수가 증가되

〈표 6〉 사용 한 CNN 구조

Type	Path Size / Stride	Output Size / Features
Convolution_1	3x3 / 1	200x200 / 64
Pooling_1	2x2 / 2	100x100 / 64
Convolution_2	3x3 / 1	100x100 / 128
Pooling_2	2x2 / 2	50x50 / 128
Convolution_3	3x3 / 1	50x50 / 256
Convolution_3_2	3x3 / 1	50x50 / 256
Pooling_3	2x2 / 2	25x25 / 256
Convolution_4	3x3 / 1	25x25 / 512
Convolution_4_2	3x3 / 1	25x25 / 512
Pooling_4	2x2 / 2	13x13 / 512
Convolution_5	3x3 / 1	13x13 / 512
Convolution_5_2	3x3 / 1	13x13 / 512
Pooling_5	2x2 / 2	7x7 / 512
FC6	-	1x1 / 4096
Drop out	-	1x1 / 4096
FC7	-	1x1 / 4096
Drop out	-	1x1 / 4096
Soft-max	-	1x1

었고, Covolution layer의 필터 크기를 3×3으로 고정하였다. 본 연구에서는 <표 6>과 같은 CNN 구조를 사용하여 시들음 무를 분류 및 검출하였다. <표 7>에서와 같이 시들음 병 분류를 위해 3×3으로 구성된 총 8개의 convolutional layer와 5개의 pooling layer를 거쳐 시들음 병 및 정상 무의 특징을 추출하고 fully-connected layer를 통해서 시들음 및 정상 무를 분류하게 된다.

학습 데이터 부족으로 인한 과적응(Overfitting)[9]을 방지하기 위하여 full-connected layer에 Drop-out[10]을 적용하였다. Drop-out은 선택한 비율에 따라 CNN 네트워크를 생략하여 학습한다.

4.2 Training

앞서 구축한 데이터베이스를 사용하여 정상 무 이미지 1552장, 시들음 무 728장, 총 2280장의 이미지를 무 영상을 사용하여 CNN을 학습하였다. 본 연구의 CNN 학습과정에서 학습속도를 향상시키기 위해 ReLu[11] 활성화 함수를 적용하였다. batch의 크기를 90으로 설정하였고 gradient descent를 통해 오차를 계산하고 역전파하여 학습하였다. Gradient descent의 파라미터인 momentum 및 learning rate를 각각 0.9, 0.01로 초기화 하여 사용하였고 learning rate의 경우 validation set(학습 데이터의 20%)의 정확도에 따라 0.001, 0.0001로 변화하여 CNN이 효과적으로 학습될 수 있도록 하였다.

4.3 분류결과

앞선 과정을 통해 학습한 CNN 분류기를 3-fold cross validation 검증을 통해 성능을 평가하였다. 성능 평가 결과는 아래의 <표 7>과 같은

<표 7> 정상 및 시들음 무 분류 결과

Class / Prediction	정상 무	시들음 무
정상 무	99.0% (1536)	1.0% (16)
시들음 무	1.6% (12)	98.4% (716)

정확성을 보이는 것으로 확인되었다.

4.4 시들음 병 검출


시들음 병 검출을 위해 영역화 된 무 영역 이미지 그리고 앞서 학습된 시들음 병 분류기를 사용하였다. 영역화 된 무 영역 이미지에 학습된 분류기를 통해 Sliding-Window를 적용하여 무 재배지역에서 발생한 시들음 병을 검출한다. Sliding-Window는 이미지에서 물체의 위치를 검출하기 위해 사용되는 기본적인 방법으로서, 이미지에서 일정한 크기의 영역(Window)을 동일한 간격으로 이동시키면서 영역 내의 영상이 찾고자 하는 물체가 맞는지 아닌지를 판별하는 방법이다. 본 연구에서는 시들음 무 검출을 위해 200×200의 윈도우 크기를 사용하였으며 50 픽셀만큼 윈도우를 이동하면서 시들음 무를 검출하였다. (그림 5)는 무 영역에서 발생한 시들음 무의 검출 결과를 보여준다.




(그림 5) 시들음 무 검출 결과

4.5 실험 결과

시들음 무 검출을 위해 CNN 기반의 분류기를 학습하였다. 최종적으로 재배지역 영역화 결과 중 무 영역 이미지를 대상으로 Sliding-Window를 적용하여 학습된 분류기를 시들음 무의 여부를 판별하였다. 시들음 무의 경우 무 잎이 황화되는 것을 시작으로 심해질수록 갈색으로 변하게 된다. (그림 6)에서는 황화가 시작된 시들음 무의 검출이 올바르게 이루어진 것을 알 수 있으나 (그림 7)에서는 시들음 무의 갈변화가 심해 올바르게 검출되지 않는 것을 확인할 수 있다. 시들음 무 검출은 영역화 된 무 영역 이미지를 통해 검출된다. 하지만 영역화 과정에서 일부 땅 영역과 무 영역으로 잘못 영역화 되는 경우가 발생하여 올바르게 영역화가 되지 않은 경우 무를 땅으로 땅을 무로 오인하여 오 검출되는 경우가 발생한다.



(그림 6) 시들음 무 검출 결과(best case)



(그림 7) 시들음 무 검출 결과(worst case)

5. 결 론

최근 분야 간의 결합을 통해 문제를 해결하고자 하는 ICT 융합연구에 대한 중요성이 커지고 있다. 특히 농업의 경우 재배지역이 매우 크고 재배지역에서 발생하는 질병의 확산 속도가 빠르기 때문에 재배지역 관리를 통해 초기에 질병을 감지하고 예방하는 것이 매우 중요하다. 본 연구에서는 무인기를 이용하여 무 재배지역 영상을 획득하고 가시광선 및 NDVI 기반의 데이터베이스를 구축하였다. 인공지능, 빅데이터 기술을 기반으로 재배지역 영상의 분류, 영역화 및 무 시들음병 예찰 시스템을 제안하였다. 재배지역의 분류 및 영역화 그리고 시들음 무 검출 과정은 다음과 같다. 1) 재배지 영역의 분류를 위해 각 영역의 질감 및 색상 히스토그램 특징을 추출한 후 softmax 분류기를 학습하여 재배지 영역을 분류 하였다. 2) 재배지역 영상에 k-means 알고리즘을 적용하여 군집화 된 영상을 학습된 softmax 분류기를 통해 재배지를 영역화 하였으며, 93%의 정확도를 보이는 것으로 확인되었다. 3) 시들음 무 검출을 위해 Convolutional Neural Network (CNN) 모델을 학습하여 건강한 무와 시들음 무를 분류하였으며 98%의 정확도를 가지는 것으로 나타났다. 학습된 CNN 모델을 기반으로 영역화 된 재배지 이미지 중 무 영역 이미지를 대상으로 sliding-window를 적용하여 시들음 무를 검출하였다.

참 고 문 헌

- [1] <http://www.auvsi.org/home>
- [2] <http://www.syngenta.co.kr/>
- [3] Vincent, Pascal, et al. "Extracting and composing robust features with denoising

autoencoders.” Proceedings of the 25th international conference on Machine learning, ACM, 2008.

- [4] Vincent, Pascal, et al. “Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion.” Journal of Machine Learning Research 11,Dec (2010): 3371-3408.
- [5] https://en.wikipedia.org/wiki/Wilcoxon_signed-rank_test
- [6] Csurka, Gabriela, et al. “What is a good evaluation measure for semantic segmentation?” BMVC. Vol. 27. 2013.
- [7] Simonyan, Karen, and Andrew Zisserman. “Very deep convolutional networks for large-scale image recognition.” arXiv preprint arXiv:1409.1556 (2014).
- [8] Russakovsky, Olga, et al. “Imagenet large scale visual recognition challenge.” International Journal of Computer Vision 115,3 (2015): 211-252.
- [9] Hawkins, Douglas M. “The problem of overfitting.” Journal of chemical information and computer sciences 44,1 (2004): 1-12.
- [10] Srivastava, Nitish, et al. “Dropout: a simple way to prevent neural networks from overfitting.” Journal of Machine Learning Research 15,1 (2014): 1929-1958.
- [11] Glorot, Xavier, Antoine Bordes, and Yoshua Bengio. “Deep Sparse Rectifier Neural Networks.” Aistats. Vol. 15, No. 106. 2011.

저 자 약 력



문 현 준

이메일 : hmoon@sejong.edu

- 1990년 고려대학교 전자공학과 (학사)
- 1992년 State University of New York at Buffalo, Electrical and Computer Engineering (석사)
- 1999년 State University of New York at Buffalo, Electrical and Computer Engineering (박사)
- 1993년~1994년 Samsung Data Systems 연구원
- 1996년~1999년 U.S. Army Research Laboratory (ARL) 연구원
- 1999년~2003년 Viisage Technology 연구원
- 2003년~2004년 연세대학교 조교수
- 2004년~현재 세종대학교 교수
- 관심분야 컴퓨터 생체인식, 컴퓨터비전, 패턴인식, 인공지능 및 머신러닝