



# 2021 인공지능 및 응용 워크숍

일시 : 2021년 7월 22일 목요일 13시 ~ 17시

주최 : 한국정보통신학회 지능정보연구회  
신라대학교 LINC+사업단 인공지능창의융합인재양성 전공

주관 : 한국정보통신학회

장소 : 신라대학교



# 목차

05 환영사

06 초대의 말씀

07 프로그램

08 세션별 논문 발표 시간표

11 초청강연

▮ 인공지능 기반 의료 영상 및 정보 분석 • 11  
김광백 교수 (신라대학교)

▮ AI DRONE For the Future MICHIGAN Project • 33  
권희춘 교수 (미국캐롤라인대학교)

99 신라대학교 LINC+사업단 인공지능창의융합  
인재양성전공 AI 성과발표

111 Oral & Poster 논문발표



# 환영사

한국정보통신학회 회원 및 산업체 전문가 여러분,

우리는 4차 산업혁명이라는 용어가 나온 이후 급격하게 발전하고 있는 인공지능 기술과 빅데이터 처리 기술이 다양한 분야에 적용되어, 예전에는 경험하지 못했던 급격한 변화의 시대를 살아가고 있습니다. 이에 저희 한국정보통신학회 지능정보연구회에서는 4차 산업혁명 시대에 필요한 인공지능 관련 기술을 공유하고, 빅데이터, IoT, 드론, 클라우드, 자율 주행, 스마트 팩토리, 스마트 시티 등과 같은 다양한 분야에 대한 기술 교류 워크숍 행사를 개최하게 됨을 매우 기쁘게 생각합니다.

이번 워크숍 행사에서는 다양한 인공지능 기법들을 소개하고, 인공지능의 원천 기술 확보를 위한 초청 특강과 대학생 및 대학원생들의 인공지능 관련 논문과 개발 실적 등의 발표를 통해 새로운 연구 방향을 제시할 것으로 기대합니다. 또한 이번 워크숍에서의 활발한 의견 교환 및 지식 공유를 통해 우리나라의 정보통신, 소프트웨어 산업이 한 단계 더 발전하는 기회가 되기를 기대합니다.

끝으로 이번 워크숍을 준비해 주신 지능정보연구회 위원장이신 신라대학교 김광백 교수님을 비롯한 관계자분들의 노고에 깊은 감사를 드리며, 참석해 주신 모든 분들의 가정에 행복이 가득 하시길 기원합니다. 감사합니다.

2021년 7월  
사단법인 한국정보통신학회  
회장 **우영운**

## 초대의 말 씬

현재 우리가 살고 있는 세상은 네트워크(IoT, 5G), 데이터(Cloud, Big Data), 인공지능(기계학습, 알고리즘) 등 지능 정보통신기술(ICT)이 기존 산업과 융합하여 새로운 서비스와 가치를 창출하는 4차 산업혁명 시대이며, 세상의 모든 것들이 빠르게 변화하는 새로운 사회의 도래를 목전에 두고 있습니다. 4차 산업혁명을 통해 인공지능기술 및 사물인터넷, 빅데이터 등 정보통신기술(ICT)과의 융합을 통해 생산성이 급격히 향상되고, 제품과 서비스가 지능화되면서 경제·사회 전반에 혁신적인 변화가 나타나고 있습니다. 또한 4차 산업혁명은 디지털 혁명으로 요약되는 3차 산업을 기반으로 물질적, 디지털, 생물학적 영역의 경계를 허무는 기술 혁명으로 분석되고 있습니다. 특히 4차 산업 혁명의 기반 기술은 인공지능 기술로서 딥러닝, 기계 학습, 심층 신경망, 퍼지 시스템 등이 실무에서 다양하게 적용되고 있고 세계는 모든 산업의 각 분야가 인공지능 기술을 기반으로한 디지털 트랜스포메이션(Digital Transformation) 혁명을 진행하고 있으며, 디지털트랜스포메이션에 따라 산업 현장 및 일상생활에서 인공지능을 적용한 지능화된 시스템 활용이 일반화 될 것으로 기대하고 있습니다.

따라서 인공지능 및 응용 워크숍에서는 인공지능 및 응용 주제로 대한민국의 인공지능과 관련하여 산학연에 종사하시는 분들이 연구하고 개발한 내용을 발표하고 정보를 공유하는 자리를 준비하였습니다.

한국정보통신학회 지능정보연구회 위원장 김광백

# 인공지능 및 응용 워크숍 프로그램

시간	발 표 장 (종합강의동 319호)	발 표 장 (종합강의동 317호)
12:00 ~ 12:50	<b>학술 발표자 등록</b>	
13:00 ~ 13:20	<b>발 표 장</b> (종합강의동 본부 2층 대회의실)	
	<b>개회사</b> 한국정보통신학회장 우영운	
	<b>축사</b> 신라대학교 LINC+사업단장 이범진	
13:30 ~ 14:30	인공지능 기반 의료 영상 및 정보 분석 김광백 교수 (신라대학교)	13:30 ~ 14:40 <b>좌장 : 김희철(인제대)</b> <b>인공지능 및 응용</b> (5편 논문 ORAL 발표)
14:30 ~ 14:40	Break Time	
14:40 ~ 15:40	A.I DRONE For the Future MICHIGAN Project 권희춘 교수 (미국캐롤라인대학교)	14:40 ~ 15:40 <b>좌장 : 신성윤(군산대)</b> <b>인공지능 및 응용</b> (7편 논문 POSTER 발표)
15:40 ~ 15:50	Break Time	
15:50 ~ 16:30	<b>“인공지능전문가 양성 프로젝트”교육을 통한 참여 학생 성과 발표</b> (신라대학교 LINC+인공지능창의융합인재양성전공 2팀 AI 기반 개발 소프트웨어 발표)	
16:30 ~ 17:00	<b>부산 지역 인공지능 기술 현황 및 기업체 애로 기술 토론</b> (교수 및 기업체 인공지능 관련 개발자 및 학생 자유 토론)	

## 인공지능 응용 : 13:30 ~ 14:40

### Screening of COVID 19 using IoT System

[Md Ariful Islam Mozumder](#) · [Ali Hussain](#) · [Ather Ali](#) · [Abdullah](#) · [Hee-Cheol Kim](#)\*(\*Inje University, \*\*)

### 홈필드 네트워크와 단층 퍼셉트론을 이용한 손상된 교통 표지판 분류

[김주완](#) · [박태언](#) · [김광백](#)(신라대학교 컴퓨터소프트웨어공학부)

### 데이터가 안되면 모델이라도

[백성복](#)\*(KT 융합기술원)

### Face Shape Classification Using Image Processing through Transfer Learning

[Abdullah](#) · [Ali Sikandar](#) · [Ali Hussain](#) · [Ali Athar](#) · [Hee-Cheol Kim](#)\* (Inje University\*)

### FCM을 이용한 Fuzzy Decision Tree의 소속 함수 개선에 따른 데이터의 재분류

[정유정](#) · [남윤만](#) · [김광백](#)(신라대학교 컴퓨터소프트웨어공학부)

## 인공지능 알고리즘 및 응용 : 14:40 ~ 15:40

### Few-Shot 기반 새로운 영상 분류

신성윤<sup>1\*</sup> · 왕광싱<sup>2</sup>(<sup>1</sup>군산대학교 · <sup>2</sup>중국 구강대학교)

### 결절종 초음파 영상 분석을 위한 개선된 퍼지 스트레칭

박태언 · 송재욱 · 박서형 · 김광백(신라대학교 컴퓨터소프트웨어공학부)

### 스마트 팩토리를 위한 LSTM (Long-Short Term Memory) 기반 재고량 예측 모델링

윤동언<sup>1\*</sup> · 이효상<sup>1\*</sup> · 오암석<sup>2\*</sup>(동명대학교)

### 장단기 메모리를 이용한 노인 낙상감지의 정규화에 대한 연구

정승수 · 유윤섭(한경대학교 전기전자제어공학과)

### 하천 홍수 예측을 위한 LSTM 기반의 수위 예측 시스템 구현

조민우 · 이태준 · 전성우 · 정회경\*(배재대학교)

### 개선된 SRCNN과 VDSR

신성윤<sup>1\*</sup> · 왕광싱<sup>2</sup> · 신광성<sup>3</sup>(<sup>1</sup>군산대학교 · <sup>2</sup>중국 구강대학교 · <sup>3</sup>원광대학교)

### 생산 효율을 높이기 위한 인공지능 적용 아쿠아포닉스 시스템 설계

이현섭<sup>1</sup> · 우영운<sup>2</sup> · 김진덕<sup>3\*</sup>(동의대학교)

## “인공지능전문가 양성 프로젝트”교육을 통한 참여 학생 성과 : (15:50~16:30)

신라대학교 LINC+인공지능창의융합인재양성전공 AI 기반 개발 소프트웨어 성과 발표

---

### Fuzzy Neural Network

왕준혁(신라대학교 LINC+인공지능창의융합인재양성전공)

### 태양 전지를 이용한 보행자 그늘막

구종은, 조혜빈(신라대학교 LINC+인공지능창의융합인재양성전공)

2021 인공지능 및 응용 워크숍

---

# 인공지능 기반 의료 영상 및 정보 분석

13:30~14:30

---

김광백 교수(신라대학교)

---


# 인공지능 기반 의료 영상 및 정보 분석

Deep Fuzzy Hierarchical Clustering & Imaging Processing LAB  
Silla University  
Kwang Baek Kim

## 인공지능 서비스 사전 평가 모델 수립

- 특정 AI 알고리즘을 어느 부분에서 사용했다고 해서 모든 인공지능 응용이 인공지능 서비스나 시스템이라 말할 수는 없다.
- AI 서비스는 사람에게 주는 편의성의 관점에서,  
AI 시스템은 해결하는 과제의 관점에서,  
AI 알고리즘은 그 효율성의 관점에서 분석해야 한다.

# 인공지능 서비스 사전 평가 모델 수립



## [ 평가 모형 ]

AI 서비스/시스템 관련 과제 평가를 한다면 아래와 같은 점에 고려해야 한다.

### (1) 연구 주제 관련

- ◎ 제안하는 과제는 AI 기반 기술이 중심이 되는가? 즉, AI 기술이 아니라면 의미 없는 서비스인가?
- ◎ 제안하는 과제는 그 영역으로 볼 때, AI 영역 내에서 참신하고 도전적인가?  
즉, 유사 연구가 이미 정립되어 있는가? 정립 중인가? 아니면 새로운 영역인가? (미래지향성)

### (2) AI 기술적 측면


- ◎ 응용 또는 개발하고자 하는 AI 기술이 제안 서비스 영역의 성격과 잘 맞는가?
- ◎ 응용 또는 개발하고자 하는 제안 AI 기술이 기존 알고리즘과 비교 우위인 측면이 있는가?
- ◎ 응용 또는 개발하고자 하는 제안 AI 기술의 확장성이 있는가?


### (3) AI 기술의 객관성/성능 평가

- ◎ 응용 또는 개발하고자 하는 제안 AI 기술의 학습 데이터가 객관적 타당성을 갖고 수집되었는가?  
혹은 공개 데이터베이스를 사용했는가?
- ◎ 응용 또는 개발하고자 하는 제안 AI 기술의 성능 평가가 타당한 도구를 사용하여 검증되었는가?

### (4) 연구자/팀 요인


- ◎ "연구자/팀이 이미 주어진 과제에 관련 성과를 갖고 있는가?" 를 평가하는 것도 매우 중요하다.






신라대학교

## 1. 인공지능적 데이터 분석



# Data Analysis



신라대학교

**정량적 데이터**


- Learning 기법
  - Linear Learning
  - Nonlinear Learning
- 비 Learning 기법
  - 통계학적 기법
  - 기계학습 (베이지안 네트워크, 의사결정 트리)

**비정량적 데이터**

- 1) 클러스터링 → Deep Learning 기법 & 심층 신경망 → 통계학적 검증
- 2) 퍼지기법 → 통계학적 기법 → 통계학적 검증

5

# 인공지능 : Methods



신라대학교

- **Symbolic Learning**
  - Version Space Learning
- **Neural Learning**
  - Multilayer Perceptrons (MLPs)
- **Evolutionary Learning**
  - Genetic Algorithms
- **Probabilistic Learning**
  - Bayesian Networks (BNs)
- **Other Machine Learning Methods**
  - Decision Trees (DTs)

\* **Fuzzy System**

- Fuzzy Decision Trees, Fuzzy Clustering

6

# Learning Method (학습 방법)

## \* 지도 학습 (Supervised Learning)

- 학습 패턴쌍 (입력 데이터, 목표 벡터)


## \* 비지도 학습 (Unsupervised Learning)

- 학습 패턴쌍 (입력 데이터)


## \* 강화 학습 (Reinforcement Learning)

- 최종 출력이 바로 주어지지 않고 시간이 지나서 주어진 경우에 해당

# Algorithm : 학습 방법



Supervised learning




Unsupervised learning

## 강화 학습 (Reinforcement Learning)

● 컴퓨터가 계산해야 할 중요한 이슈

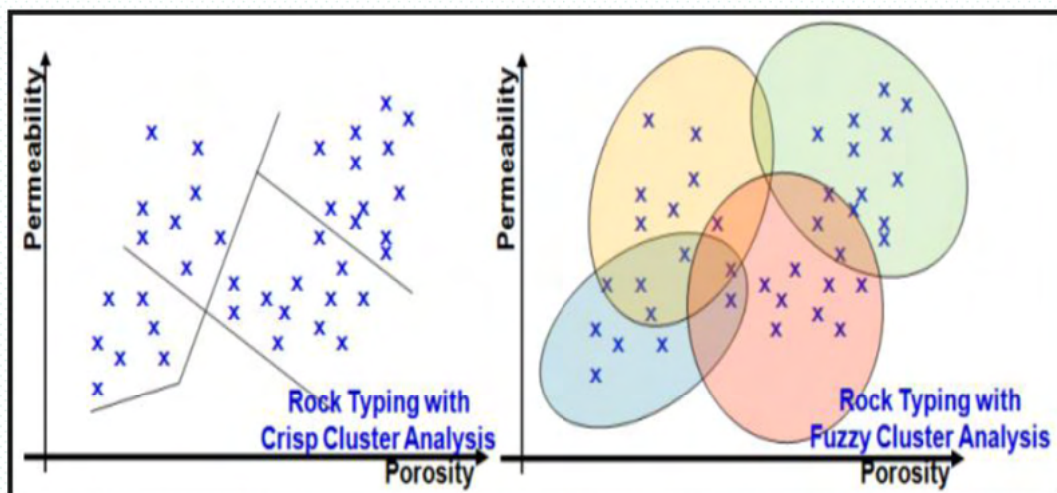
- 매 순간 어떤 Action을 선택해야 하는가?
- State에 대한 평가



# 비지도 학습 (클러스터링 기법) 비교

알고리즘	데이터 특징	클러스터 생성	Deep Unsupervised Neural Network 확장
기계학습 (K-Means)	정량화된 빅데이터	정적 생성	가능 (비효율적)
신경망 (ART : ART2, Fuzzy ART)	비정량화된 빅데이터	동적 생성	가능 (효율적)
퍼지 클러스터링 (Fuzzy C-Means)	비정량화된 빅데이터	정적 생성	가능 (보통)


## 정량적인 데이터 분석과 비정량적 데이터 분석 : Fuzzy Clustering





신라대학교  
SILLA university  
1954

## 2. Deep FCM Learning



## Deep FCM : 2 layer FCM

신라대학교  
SILLA university  
1954

**Procedure** FCM\_2LayerClustering (x) **returns** prototypes and partition matrix

**Input** data  $x = \{x_1, x_2, \dots, x_k\}$

**Local** fuzzification parameter : m  
threshold :  $\varepsilon$   
norm :  $\|\cdot\|$

INITIALIZE-PARTITION-MATRIX  
 $t \leftarrow 0$   
**repeat**  
    **for**  $i=1:c$  **do**

$$v_i(t) \leftarrow \frac{\sum_{k=1}^N u_{ik}^m(t) x_k}{\sum_{k=1}^N u_{ik}^m(t)} \text{ compute prototypes}$$

13

## Deep FCM : 2 layer FCM

신라대학교



**for** i=1:c **do**

**for** k=1:N **do**

$$u_{ik}(t+1) = \frac{1}{\sum_{j=1}^c \frac{\|x_k - v_j(t)\|^{2/(m-1)}}{\|x_k - v_i(t)\|^{2/(m-1)}}}$$

update partition matrix

t ← t + 1

**until**  $\|U(t+1) - U(t)\| \leq \varepsilon$

**repeat**

**for** s=1:cc **do**

$$w_i(t) \leftarrow \frac{\sum_{i=1}^c q_{si}^m(t) u_i}{\sum_{i=1}^c q_{si}^m(t)}$$

2 Layer compute prototypes

14

## Deep FCM : 2 layer FCM

신라대학교



**for** s=1:cc **do**

**for** i=1:c **do**

$$q_{si}(g+1) = \frac{1}{\sum_{r=1}^{cc} \frac{\|q_i - w_s(g)\|^{2/(m-1)}}{\|q_i - w_r(g)\|^{2/(m-1)}}}$$

update 2 Layer partition matrix


g ← g + 1

**until**  $\|U'(g+1) - U'(g)\| \leq \varepsilon'$

**return** w, q

## 상완동맥 추출 결과

신라대학교



원본 상완동맥 초음파 영상




FCM 처리 결과




2 layer FCM 처리 결과

## 결절종 추출 결과


신라대학교




원본 결절종 초음파 사진




FCM 처리 결과




2 Layer FCM 처리 결과



신라대학교

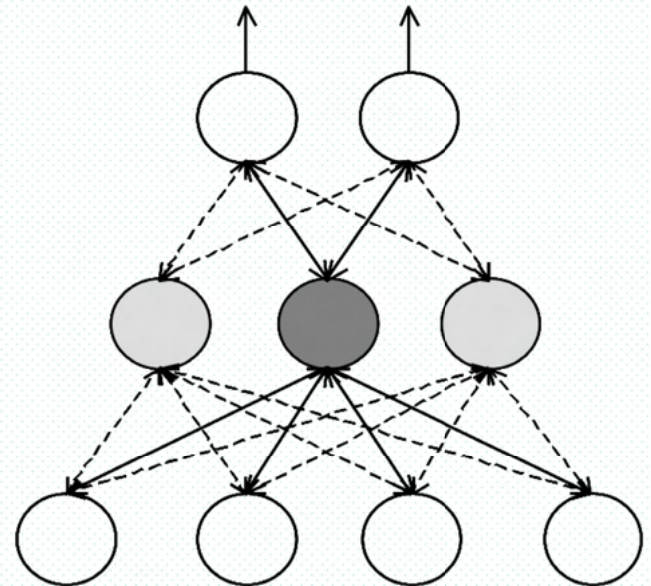



# 3. Deep Fuzzy Neural Networks g



# Deep Fuzzy Neural Networks

신라대학교



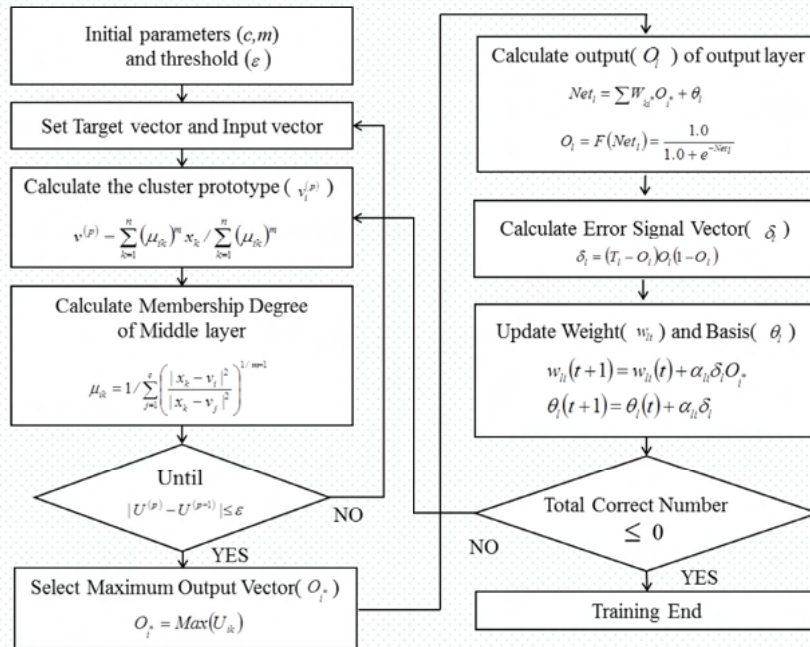
Output Layer

Middle Layer

Input Layer

# Deep Fuzzy Neural Networks

신라대학교




## 요부 근육 분석

신라대학교




### < 요부 초음파 영상 >




[요부 초음파 영상]

# 요부 두께 측정




신라대학교

## < 두께 측정 >




[두께 측정]

# 요부 근육 분석




신라대학교

• Intel(R) Core(TM)2 Duo CPU E7300 와 2.00GB RAM이 장착된 IBM 호환 PC 상에 Visual Studio 2015(C++)으로 구현.





# 실험 및 결과 분석


신라대학교



요부 초음파 영상



Deep Fuzzy Neural Networks 기반 적용 결과



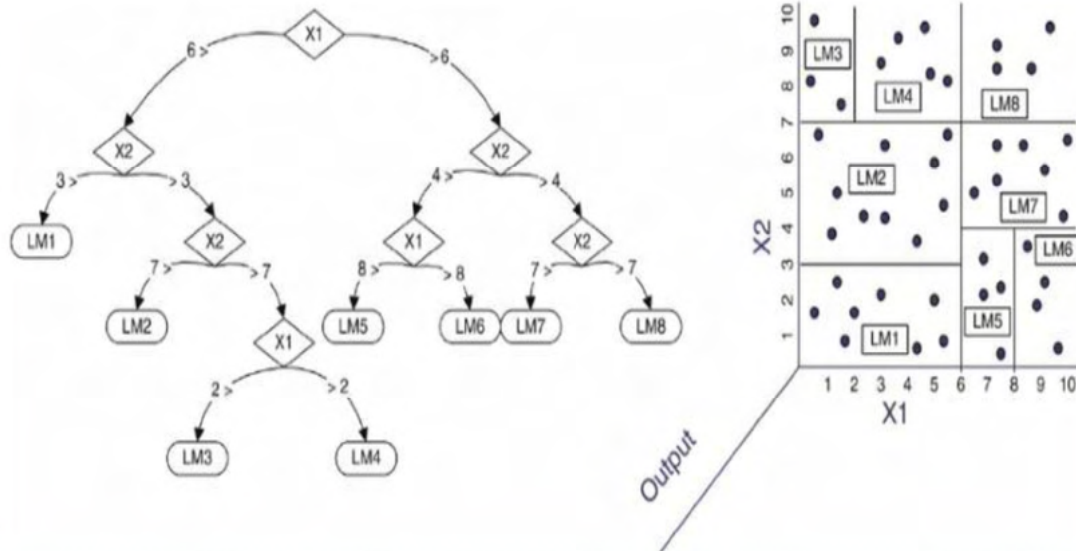
신라대학교



## 4. Fuzzy Decision Tree 기반 한방 자가 진단

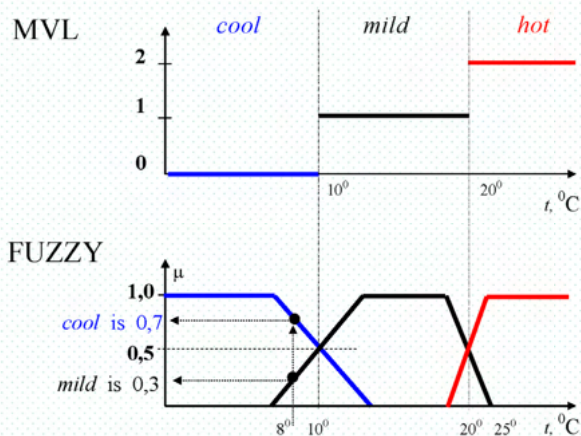


# Decision Tree



2  
5

# MVL VS. FUZZY.



Numeric attribute $\Lambda_2$	Linguistic attribute $\Lambda_2$ (Temperature)		
	$\Lambda_{2.1}$ (cool)	$\Lambda_{2.2}$ (mild)	$\Lambda_{2.3}$ (hot)
$x_1 = 8$	0.7	0.3	0.0
$x_2 = 10$	0.5	0.5	0.0
$x_3 = 15$	0.0	1.0	0.0
$x_4 = 20$	0.0	0.5	0.5
$x_5 = 23$	0.0	0.8	0.2
$x_6 = 25$	0.0	0.0	1.0

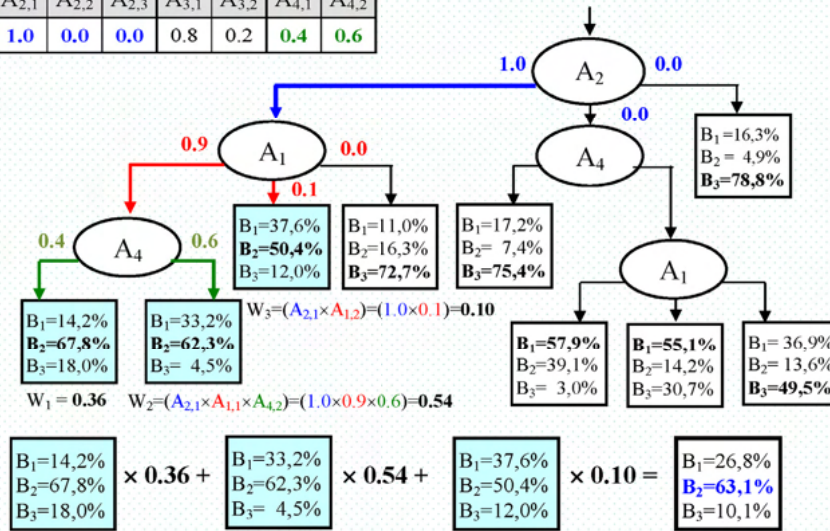
# Fuzzy Decision Rules

신라대학교



- Fuzzy Decision Rule is path from root to leaf
- One example describes by several Fuzzy Decision Rules

A <sub>1</sub>			A <sub>2</sub>			A <sub>3</sub>		A <sub>4</sub>	
A <sub>1,1</sub>	A <sub>1,2</sub>	A <sub>1,3</sub>	A <sub>2,1</sub>	A <sub>2,2</sub>	A <sub>2,3</sub>	A <sub>3,1</sub>	A <sub>3,2</sub>	A <sub>4,1</sub>	A <sub>4,2</sub>
0.9	0.1	0.0	1.0	0.0	0.0	0.8	0.2	0.4	0.6

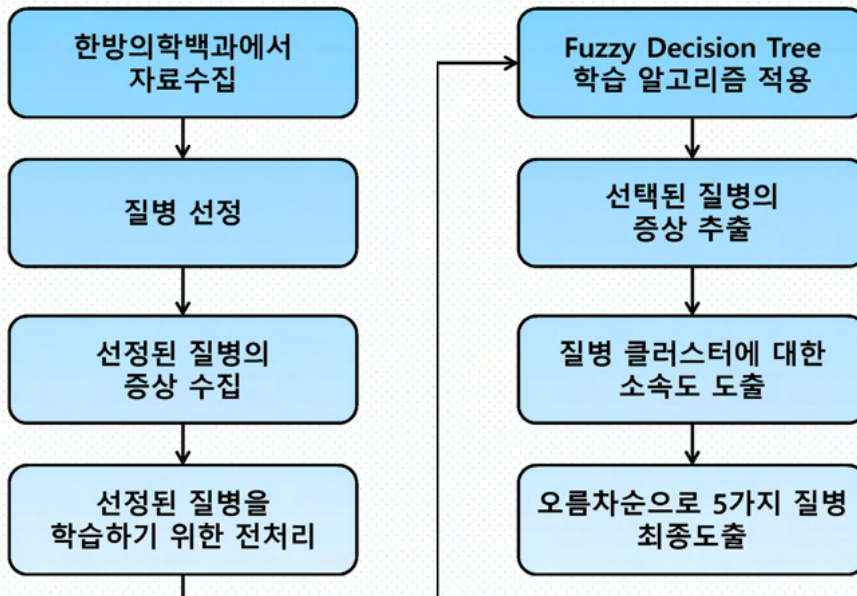


# 한방자가진단 순서도

신라대학교



## 한방 자가 진단 순서도

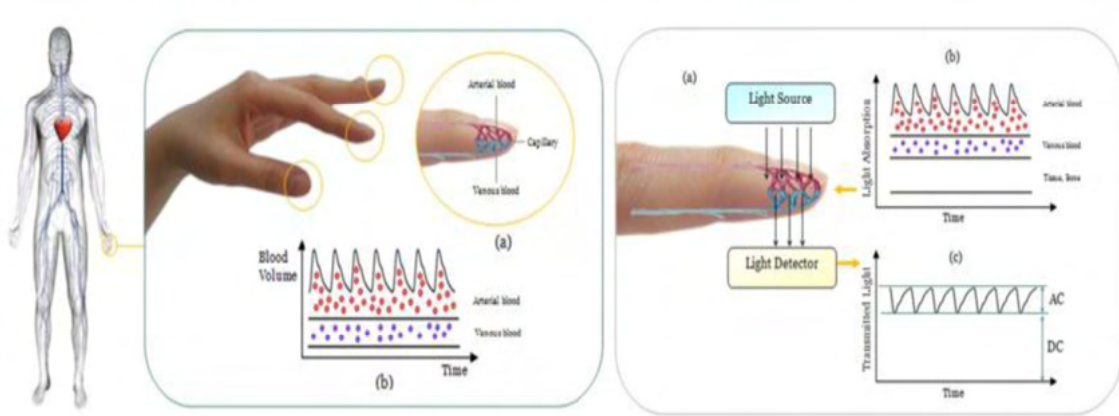


# 맥박 및 혈류 검사

신라대학교



맥박 및 혈류검사를 통한 정확도 향상

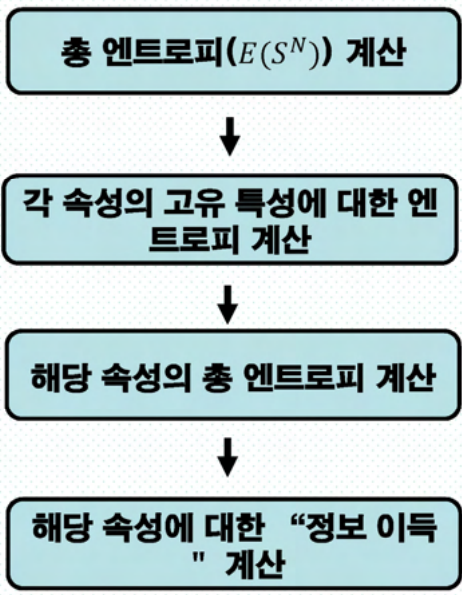


# 질병 분류를 위한 퍼지 의사 결정 트리

신라대학교



순서도

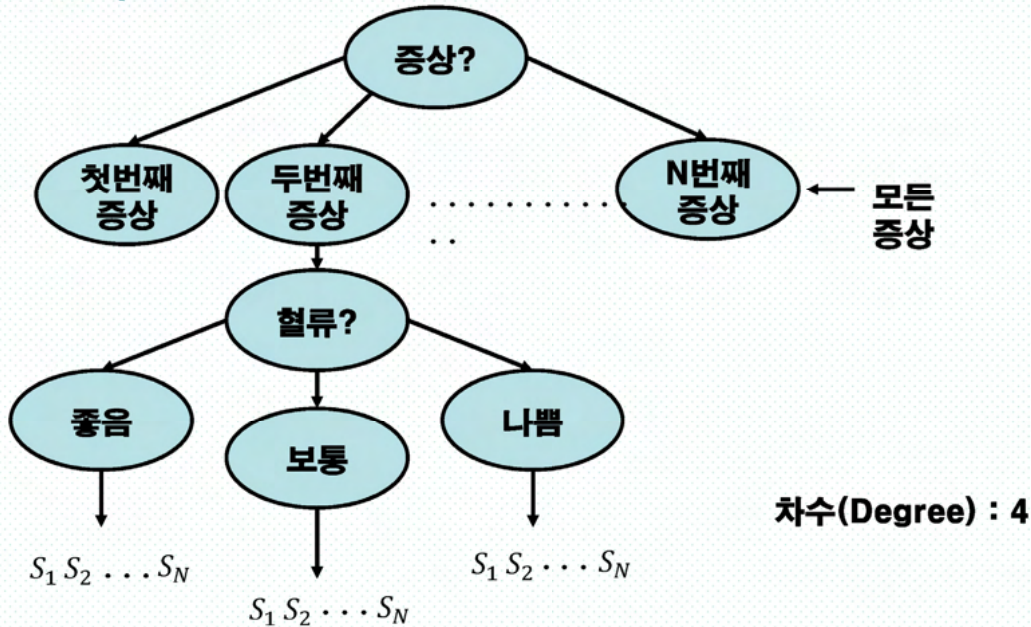


다른 속성에 대한 해당 속성들의 소속도를 계산

$$E(S_N) = -\frac{P}{P+N} \log_2 \frac{P}{P+N} - \frac{N}{P+N} \log_2 \frac{N}{P+N}$$

# II. 본론

## Fuzzy Decision Tree 구조



# 개발 화면



실험 환경


- Intel i5-6600 3.3GHz CPU와 16GB RAM이 장착된 IBM 호환 PC
- Android Studio 2.3.3
- Ubpulse 맥파 센서로 실험

# 개발 화면

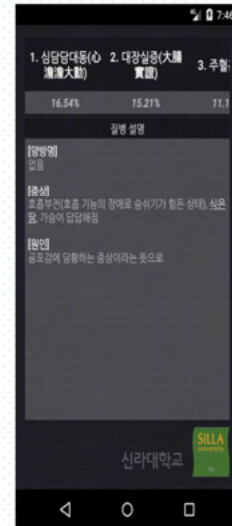
신라대학교



부위 선택 화면



부위별 증상 선택 화면



선택된 증상에 대한 질병 결과



신라대학교



## 5. 인공지능 기반 의료 영상 및 정보 분석 소프트웨어



# 장폐색 영역 검출 및 분석

신라대학교




- 장폐색 환자 영상의 특징**
- 장폐색 영역은 폐와 골반 사이에 위치
  - 대장폐색 영역에는 공기 액체층이 위치함
  - 소장폐색 영역은 형태학적 특징이 없음
  - 장폐색 영역은 모두 유사한 명암도를 가짐



# 장폐색 영역 검출 화면

신라대학교




CPU : Intel® Core™ i7-7700K@4.20GHz  
 RAM: 32.0GB  
 Visual Studio 2017 C#

DK Medical Solution  
 Accuray-650R  
 진단용 방사선발생장치

# 클러스터링 기법 간의 비교



ART2



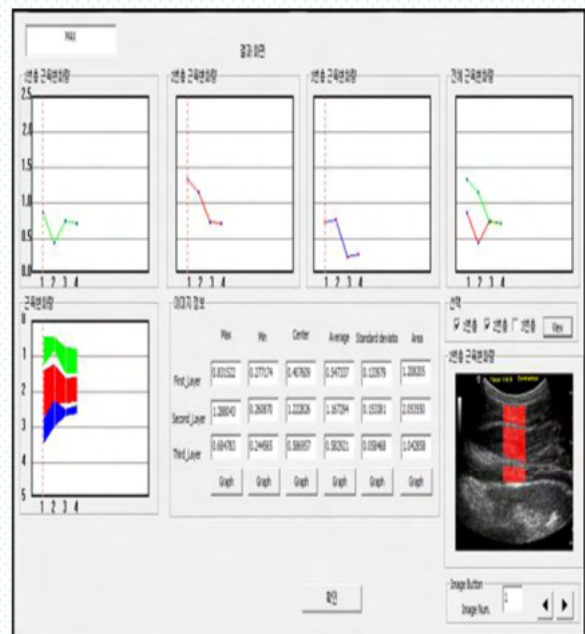
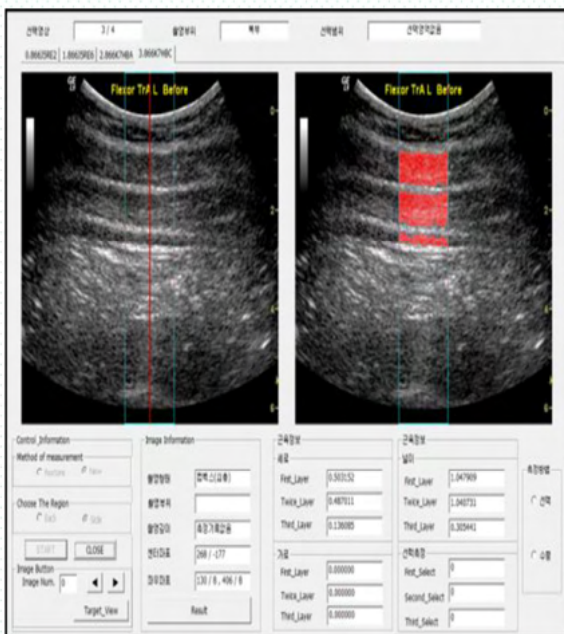
PCM



FCM


	기존의 방법	ART2	PCM	FCM
성공(대장)	19	25	13	4
성공(소장)	0	0	3	0
실패(대장)	6	0	6	15
실패(소장)	0	0	3	6
클러스터 수	-	-	4	6

# 복부 근육의 초음파적 분석 소프트웨어



# 경추 초음파 영상기반 심부 경부 굴곡근 두께 측정 소프트웨어

신라대학교



# DNA 염기 서열의 단편 결합 알고리즘 기반 소프트웨어

신라대학교





2021 인공지능 및 응용 워크숍

---

## A.I DRONE For the Future MICHIGAN Project

14:40~15:40

---

**권희춘 교수(미국캐롤라인대학교)**

---



## Professor/Lecturers



**Name:** Kwon Hee CHoon

**Department:** NACSI

**Contact:** 010-6261-8517

**E-mail:** kwonheecheon@gmail.com

**<Education Background>**

BS of Sung Kyun Kwan University

MA of Sung Kyun Kwan University

Ph.D in Engineering of Sung Kyun Kwan University

Thesis "VMME over Multimedia Framework"

10 year experience as Associate Professor at Suwon Women's College

Korean App award Judge

Director of Korea Electronic publishing agency(present)

Vice Chairman of Korea Digital convergence agency(present)

Visiting Professor of Hanyang Cyber University(present)

Secretary General of National Agency of Cognitive Science (present)



**Caroline  
University**

[www.carolineuniversity.org](http://www.carolineuniversity.org)

## Kwon Heechoon, Ph.D

Professor / A.I Drone Major  
School of Business Administration  
Instructor Pilot of Ultra Light Vehicle

Mobile : 82-10-6261-8517   
Tel : 1-215-514-5799  
E-mail : [kwonheecheon@gmail.com](mailto:kwonheecheon@gmail.com)  
3660 Wilshire Blvd #320, Los Angeles, CA 90010




## Kidnapping in Brazil caught on CCTV




DRONE??

- ✓ **D** : Dynamic
- ✓ **R** : Robotics
- ✓ **O** : Objective
- ✓ **N** : Networked
- ✓ **E** : Energetic Ever









## Drug Delivery Drone



## Drone Port Apartment



## Drone Port Apartment







**DP-14 HAWK: KEY CAPABILITIES**

- Useful weight: 430 lbs
- 23 Cubic foot internal cargo area
- No runway or recovery equipment required
- Self-launch and self-recover in unprepared sites
- Extend range: Vary fuel versus payload to optimize range and endurance for each mission
- Precision cargo drops better than 3 meters
- Fast and agile: Speed up to 105 kts.
- Crosswinds 40 knots
- All-terrain landing gear for uneven ground, slopes to 15 degrees, and heaving pitching rolling ships
- Fits in Sprinter\* van or utility trailer







## Ambulance Drone



## Ambulance Drone



## Ambulance Drone




## Ambulance Drone




## Drug Spray Drone




## COVID-19 Detections by Drone



## COVID-19 Pizza Delivery by Drone










15년 2월, 용산역 인근서 지름 5m·깊이 3m 싱크홀 발생...2명 추락



<p>융합서비스</p>				
	<p>자율주행</p>	<p>드론</p>	<p>AR/VR</p>	<p>지능형로봇</p>
<p>산업기반</p>				
	<p>신재생에너지</p>	<p>V2G/스마트그리드</p>	<p>스마트워터그리드</p>	<p>블록체인</p>
<p>지능형인프라</p>				
	<p>빅데이터</p>	<p>5G · 10Giga</p>	<p>IoT</p>	<p>인공지능</p>

## Drone Taxi





## Weapon Drone



Play  
Ground

autonomousweapons.org

## Aerial Dragnet



054

POLICE

PROTECT & SERVE


## Aerial Dragnet(드론 수사대)



## Aerial Dragnet(드론 수사대)


영국 드론 관련 범죄 및 사건·사고 자료: 영국 경찰청





**Saved by drone: Girl, 16, is found by police remote-controlled aircraft with thermal imaging camera while she was still with the man she said had raped her**















**4차 산업혁명시대  
치안드론 도입 및  
활용 컨퍼런스**

2018. 3. 23 (금), 10:30 - 17:00  
경북대학교 연구강의동, 대운동장

시간	주요 내용	강사
10:00-10:30	개회식 및 기념촬영	장관(사) 김민우(경북대학교) / 총 서: 차명배(한국드론산업협회 부회장)
10:30-11:00	기초강연 드론의 문화, 응용, 기술적 문제점	말 호: 이광호 교수 (서울대학교 기계항공공학부)
11:00-12:10	기초강연 국내 산업용 드론의 활용 가능성 분석 및 과제	말 호: 김광용 강연 (경북대학교 항공우주공학부)
12:10-12:20	휴식	
제1세션 13:20-14:00	지상수령기 가능한 로컬라이즈 드론과 제안서비스의 이용현황	말 호: 이재호 교수(충남대학교) 말 호: 최영환 교수(가천대학교) 말 호: 김철민 교수(가천대학교) 말 호: 이희원 교수(충청남도청)
14:00-14:20	휴식 / Coffee Break	
제2세션 14:20-15:00	드론 안전가용성 토론	말 호: 김복 교수(충남대학교) 말 호: 최영환 교수(가천대학교) 말 호: 이희원 교수(충청남도청)
제3세션 15:00-15:40	드론 기술 현황	말 호: 김희철 박사(한국과학기술연구원) 말 호: 송지호, 박민호, 박스, 최민호, 최지현, 최지우
15:40-16:00	시각인 지능(컴퓨터비전)	
제4세션 16:00-16:50	치안드론 및 공중용 드론 시연	- 송지호, 박민호, 박스, 최민호, 최지현, 최지우
16:50-17:00	결합행사 및 폐회식	

주최: 경북대학교, 후원: 경북대학교 드론시큐리티연구실, 후원: 한국드론산업협회, 후원: 한국과학기술연구원











- 69 -

**Modular Intelligent and Children  
Hide Investigation on**

**GAN  
(Generative Adversarial Nets)**

**called MICHIGAN**

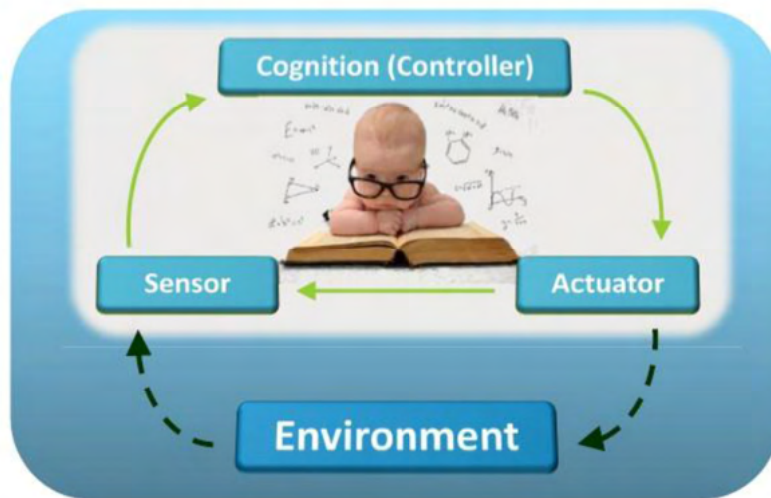
- 70 -



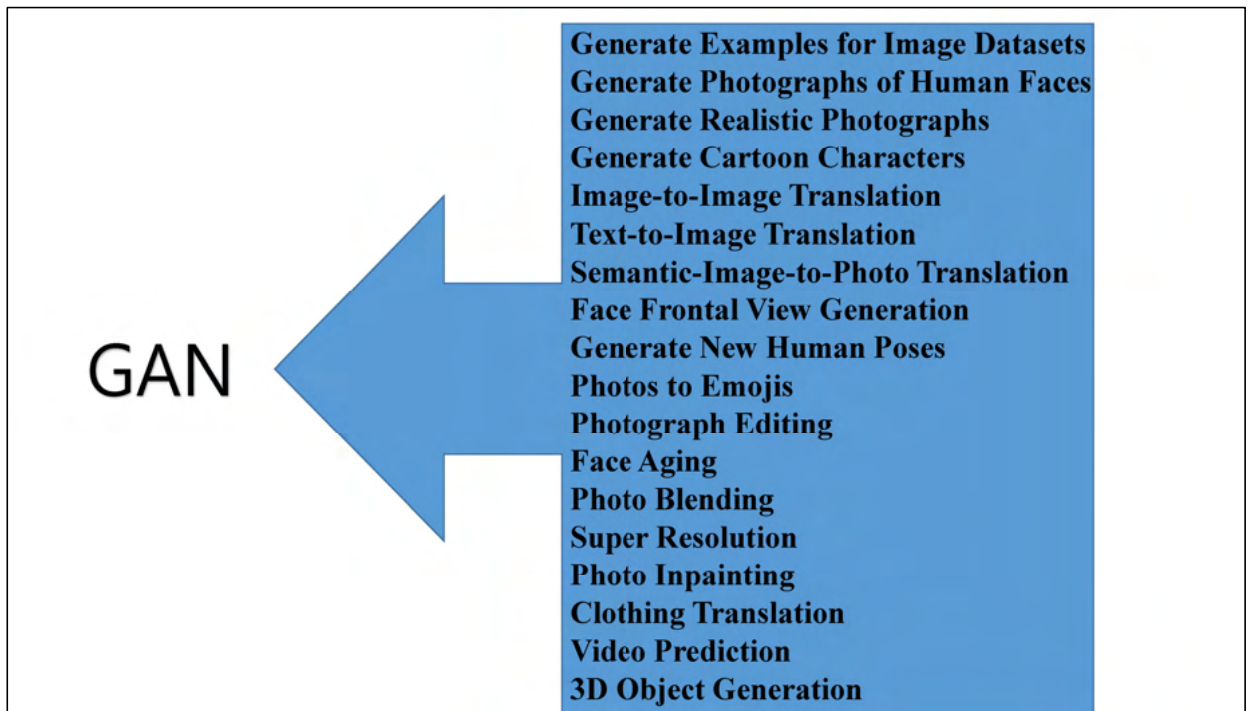
- 71 -

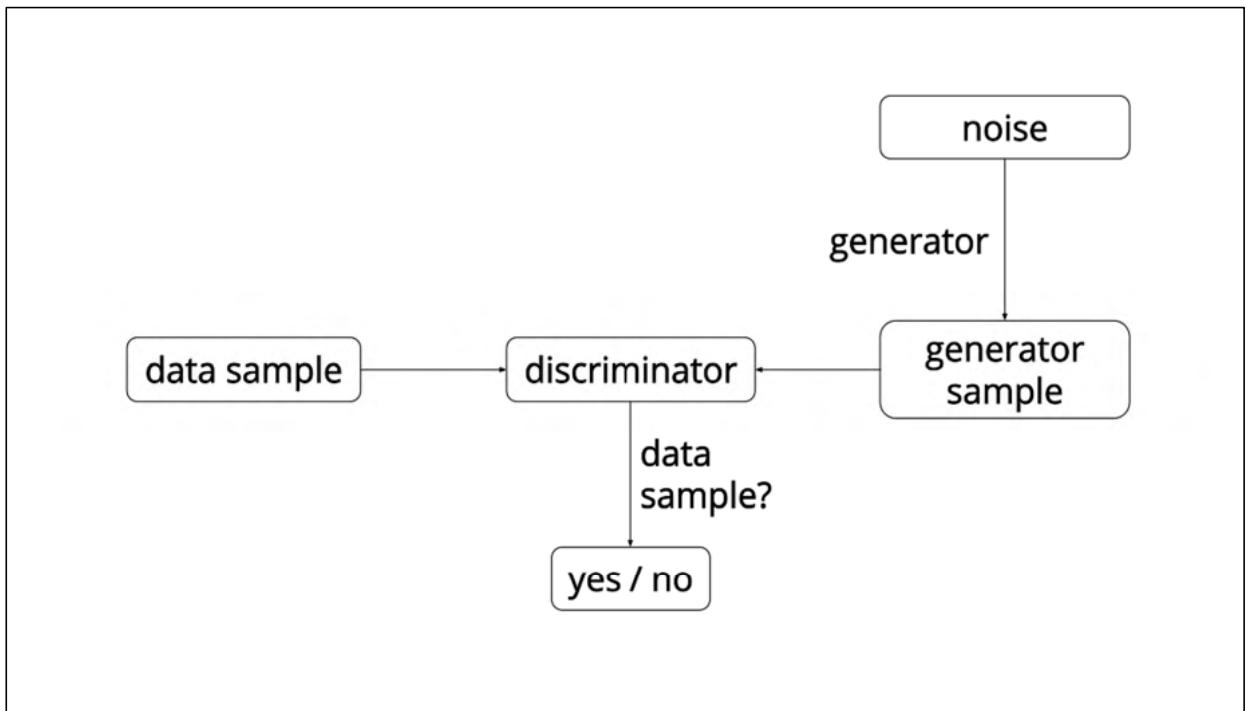


## Are we done ?

Intelligence (지능) = Ability to observe and act upon an environment



6






## Generative Adversarial Networks

$$\min_G \max_D V(D, G)$$

$$V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))]$$




Input



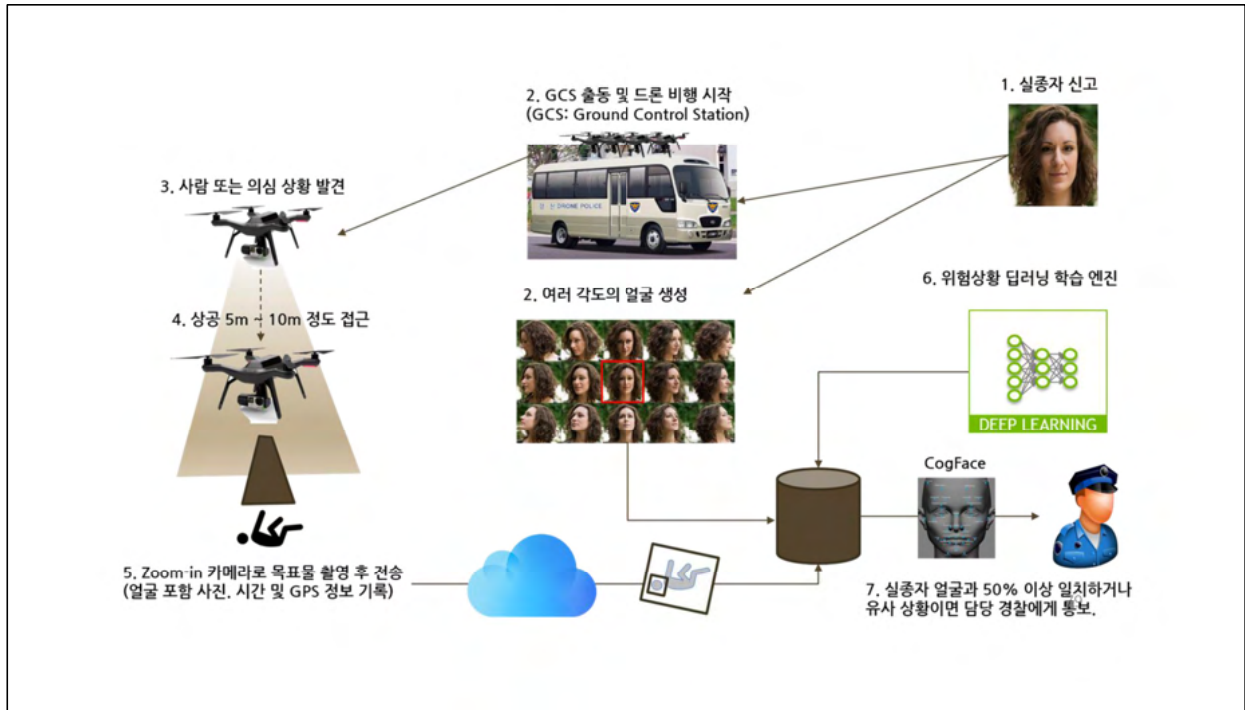
Picture of Money

Deep Convolutional  
Neural Network

Output



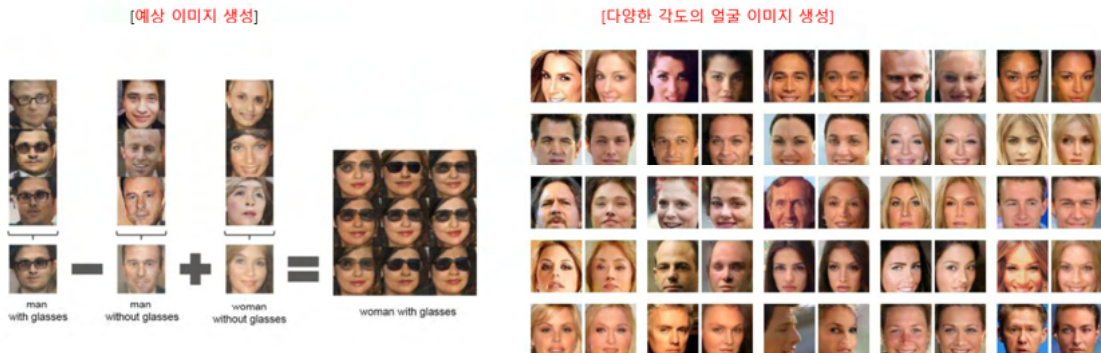
Whether or not the  
picture contains money



딥러닝 분야에서 최근 연구되고 있는 GAN(Generative Adversarial Network) 알고리즘의 상용화 2  
 - 예상 이미지를 생성, 다양한 각도의 얼굴 이미지 생성



딥러닝 분야에서 최근 연구되고 있는 GAN(Generative Adversarial Network) 알고리즘의 상용화 2  
 - 예상 이미지를 생성, 다양한 각도의 얼굴 이미지 생성





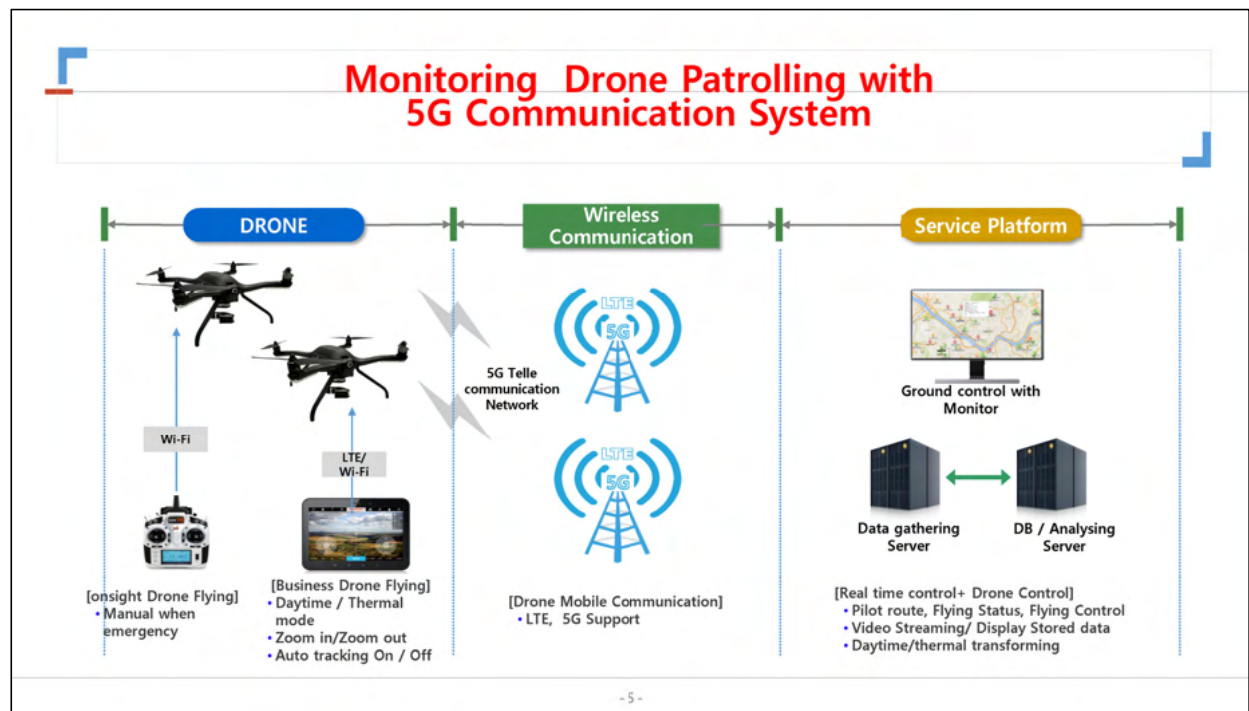
## Style GAN

제너레이티드 포토스  
(Generated Photos)

100K Faces Project

2년간 69명의 모델과 29,000장의 사진을 찍었다 한다. 이렇게 찍은 실제 모델 사진을 바탕으로 시를 돌려서 실존하지 않는 인물 사진을 만들어냈다

This slide features the text 'Style GAN' in red, followed by '제너레이티드 포토스 (Generated Photos)' and '100K Faces Project'. Below this is a paragraph in Korean describing the project: '2년간 69명의 모델과 29,000장의 사진을 찍었다 한다. 이렇게 찍은 실제 모델 사진을 바탕으로 시를 돌려서 실존하지 않는 인물 사진을 만들어냈다'. To the right of the text is a 3x3 grid of nine AI-generated human faces, showing a variety of ethnicities and features.



## Drone Patrolling and Finding Terror site

### Object Match

- 테러사건 접수
- 위치확보, 의심 지역 정보 획득

#### [ 비행주요 사항 ]

- 테러 발생 가정 → 드론을 활용한 테러지역 수색 진행
- 비행 총 거리 : 2km 내외
- 비행 고도 : 100m
- 비행 속도 : 5m/s
- 수색 반경 : 94,000m<sup>2</sup> (2만7천평)



### Connection to Drone

- 업무용 드론 접속
- 의심 지역 설정, 자동경로 생성, 업무용 카메라 영상 수신 확인
- 자동 비행 시작 명령

### Routh Flying

- 경로 비행 시작
- 카메라 수직 아래 방향으로 설정 후

### Detecting Object

- 테러지역 발견
- 정지 비행, 주간 카메라 증인으로 대상 확인
- 테러용의자 아닌 것을 확인 후 카메라 zoom 후 비행 재개
- 테러 사이트 발견
- 정지 비행, 주간 카메라 증인으로 대상 확인
- 열감지를 통한 정보획득
- 자동 추적 시작
- 테러지역 특공대 투입위치 확인



## Missing Point Map and Automatic Flying

### ▶ SALM

- 비행경로 입력 → 입력된 경로로 자율비행
- 정밀탐색영역 설정



### ▶ Group Flying

- 다수 드론 영역분담 → 보다 광범위한 지역 효율적 탐색
- 복합정보 (지형, 열화상 등) 동시 취득 및 관리



## Monitoring Realtime Drone Flying and Security Check

### Monitoring realtime Drone Flying

- 다수 드론이 전송하는 복수영상 동시 실시간 모니터링
- 끊임없는 고화질 영상제공
- 다양한 정보 취득 (열화상 정보, 유해물질 정보 등)



### Cloud system

- 드론 운행으로 수집된 정보는 통신망(5G)을 통해 클라우드 서버에 자동전송 및 저장
- 불의의 상황으로 드론이 유실되는 경우에도 수집된 정보는 안전하게 보관
- 저장된 정보가 외부에 유출되는 않도록 보안 가능



- 8 -

## An Applying High Creditable DRONE Monitoring System

### Delivery Emergency kit




- 섬지역 등에서 신속한 의료장비 전달
- 의료장비 전달을 통해 골든타임 확보 및 수송인력 절감
- 자동 이 / 착륙 및 지정 경로 최적화 비행
- 전력충전을 위한 포트활용

### Anti Terror, and Critical Area Monitoring CNI



- 재난현장 상황판단과 의사결정을 위한 영상자료 획득
- 전용앱을 이용하여 드론에서 획득한 영상/사진을 동시에 송수신
- 미리 설정된 지점이나 목적지에 감시정찰 비행

### Patrolling and Fire Watching



- 중요한 장비의 작동 상태 감시
- 주/야간 경계 봉안 유지
- 가연성 물질 저장 상태에 있어 이상온도 변화 감지
- 잠재적인 안전 위협에 대한 사전 보호

### Realtime Traffic Control



- 고속도로 교통량 분석을 통한 실시간 영상제공

- 9 -





**"드론부터 띄우세요" 산불 진화 위해 규정위반 무릅 쓴 산림청장**

강원 산불 당시 규정 위반 무릅 쓴 산림청 적극행정 화제  
강풍에 추락 위험에도 '진화가 먼저' 판단해 드론 운용  
열화상카메라 장착 드론 덕에 산불 진화작전 수립 용이해져









## The Scenario of missing person by Using MICHIGAN



Missing Point




Drone Patrolling Missing Area



Share a Missing Point Video with control center



### The secret that a suspect in "Gangjin high school student murder"



Detecting Phone Signal and share with it

## The Actual Scene of Gangjin Girl Student Search by DRONE





### 전주 실종 여성 시신 발견

자료: 전북지방경찰청





An infographic with a light blue background. On the left, a large black drone is shown in flight against a blue sky. Below it, a small circular inset shows a man in a suit. Text in Korean reads: '경기남부경찰청' (Gyeonggi Province Southern Police Agency), '설 연휴 고속도로 양체 차량 드론 띄워 단속' (During the Lunar New Year holidays, two-body vehicles on the highway launch drones for enforcement). On the right, a man in an orange shirt and blue pants stands on a green hill, holding a remote control. A smaller drone is on the ground next to him. Text in Korean reads: '드론, 설 연휴 기간 교통법규 위반차량 130건 단속' (Drones, 130 traffic law violation vehicles during the Lunar New Year holidays). The MBC logo is in the top right corner of the left panel.



## Drone으로 촬영한 자살테러



## Drone's Future

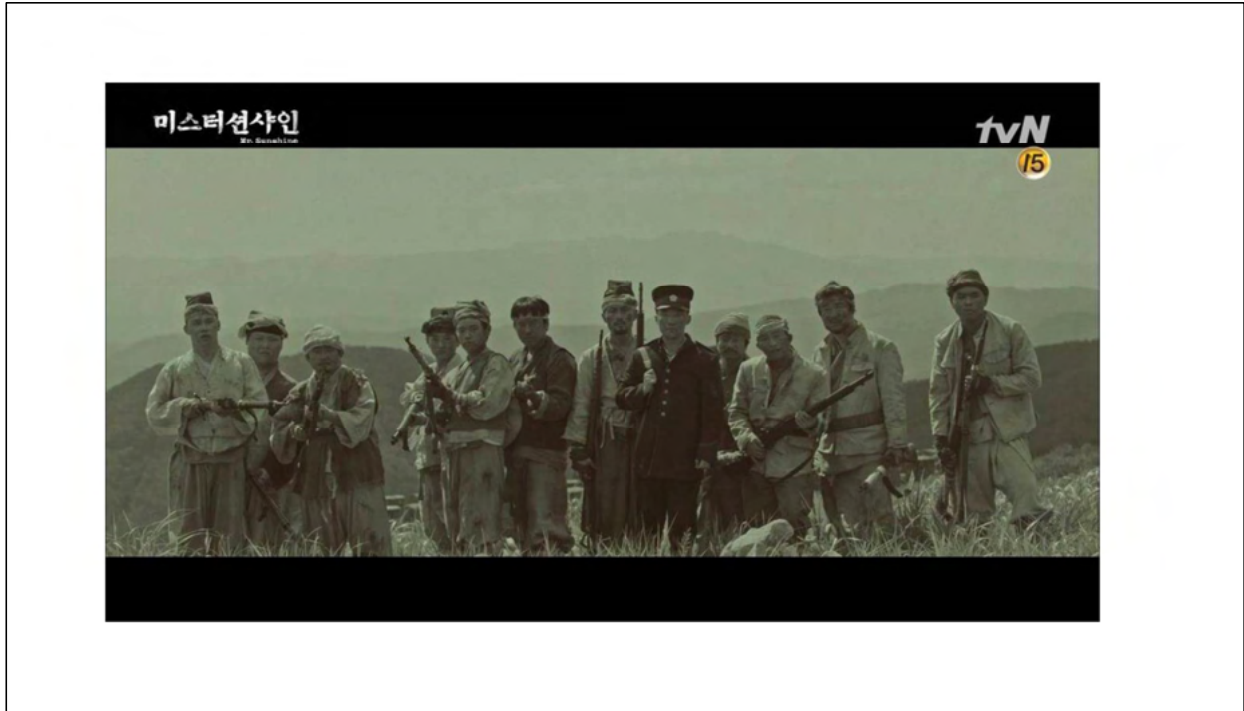
## 결 론

3년안에 스마트콘텐츠 (사물인터넷, 드론, VR, AI 등) 시장 전체 시장규모는 크게는 현재보다 5배 이상 성장할 전망  
특수목적용 드론(경찰, 해양, 군, 지자체 등)의 수요개발 및 구매를 통한 공공기관의 수요 창출 및 기술선도

109



1907년 영국인 종군기자 맥켄지가 양평군 지평 인근에서 촬영한 의병대 모습: <The tragedy of Korea> (1908년에 뉴욕에서 발간 된 책) p207, 사진: 맥켄지(F. A. McKenzie) / 자료 출처: 위키미디어






좋은 친구와 함께 가는 것

영국의 한 매체  
가장 빨리 가는 방법

다.

113




A leader is one who knows the way,  
goes the way, and shows the way.  
*John C. Maxwell*


**A leader** is one who knows the way, goes the way, and shows the way.  
리더는 길을 **알고**, 길을 **가며**, 그 길을 **보여주는** 사람이다.

John C. Maxwell

114









## The 1st Drone Congress in Helsinki 1 – 3 October, 2019









125




126



- 127 -



# Thank You



ID: callan

129



- 130 -

---

**“인공지능전문가 양성 프로젝트”  
교육을 통한  
참여 학생 성과 발표**

15:50~16:30

---

**신라대학교 LINC+인공지능창의융합인재양성전공  
2팀 AI 기반 개발 소프트웨어 발표**

---

h y b r i d   a l g o r i t h m

# Fuzzy Max-Min Neural Network

발 표 자   왕   준   혁

## CONTENTS

01

목표

- 핵심주제
- 전체 구조

02

FCM

- Fuzzy 이론
- FCM

03

FMMNN

- Fuzzy Min-Max  
Neural Network
- Activation  
Function

04

정리

- 알고리즘
- 결과 및 개선사항

핵심 주제 Fuzzy Max-Min Neural Network

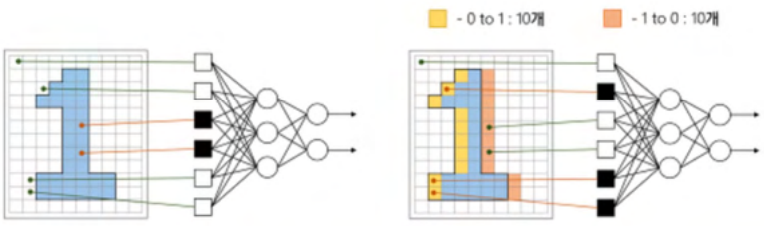
**01**

## “ 숫자 인식 ”

### Number recognition

FCM으로 군집 분석 후 Fuzzy Max-Min Neural Network로 분류

- 소프트웨어 구성 기법 가운데 퍼지시스템과 신경망의 장점을 융합한 시스템
- 3개의 계층으로 구성되는 다층 신경망
- 이미지픽셀을 소속도로 군집분석



■ - 0 to 1: 10개    ■ - 1 to 0: 10개

전체 구조 Fuzzy Max-Min Neural Network

**01**

### 1. Backbone

FCM + FMMNN (하이브리드 알고리즘)

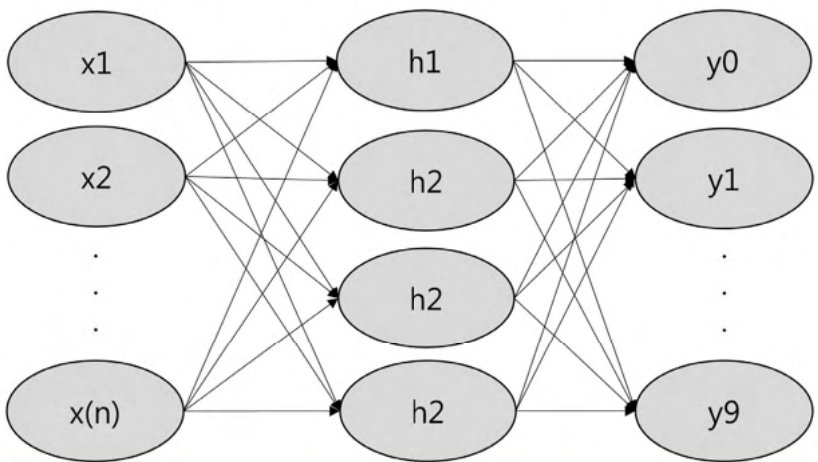
Clustering  
Layer

Classification

Input

hidden


Output



2. FCM

Fuzzy 이론

- 어렵듯하고 애매모호하다는 뜻으로, 애매모호한 인간의 언어를 컴퓨터 언어로 표현하고자 한 이론




[그림 1] 정확한 값의 퍼지화


2. FCM

Fuzzy C-Means + Euclidean distance

- 동일한 군집에 속하는 데이터는 어떠한 중심을 기준으로 분포할 것이라하는 가정을 기반으로 하는 중심 기반(Prototype-based)
- 유클리디안 거리는 두 점 사이의 거리를 계산할 때 쓰이는 방법으로 소속도를 구할때 적용



Fuzzy C-Means Clustering 결과 >




02

2. FCM

FCM을 응용한 4방향 균집분석

- 동서남북으로 클러스터를 정하고 이미지에 소속도를 구해 특징을 추출



- 소속도(유클리디안 거리)

$$d(p, q)^2 = (q_1 - p_1)^2 + (q_2 - p_2)^2$$

- 모든 클러스터의 가중합은 1이다

$$\sum_{k=1}^K w_{ik} = 1$$

- 각 클러스터는 0이 아닌 가중값을 가지며 모든 클러스터는 가중값이 1이 될수는 없다


$$0 < \sum_{i=1}^n w_{ik} < n$$

02

2. FCM

Activation Function

- 4방향 소속도라서 가중치가 크게 차이 나지 않는 문제가 생김
- Max-Min한 소속도를 극적으로 차이 나게 하기 위한 Stretch

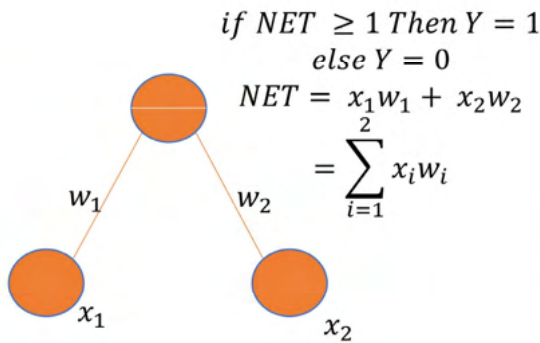


03


3. FMMNN

Fuzzy Max-Min Neural Network

- 양 시스템의 융합으로 그 장단점의 보완에 의하여 시너지 효과를 거두려는 것으로 융합의 형식은 응용의 성격에 따라 사용자가 선택할 수 있다.



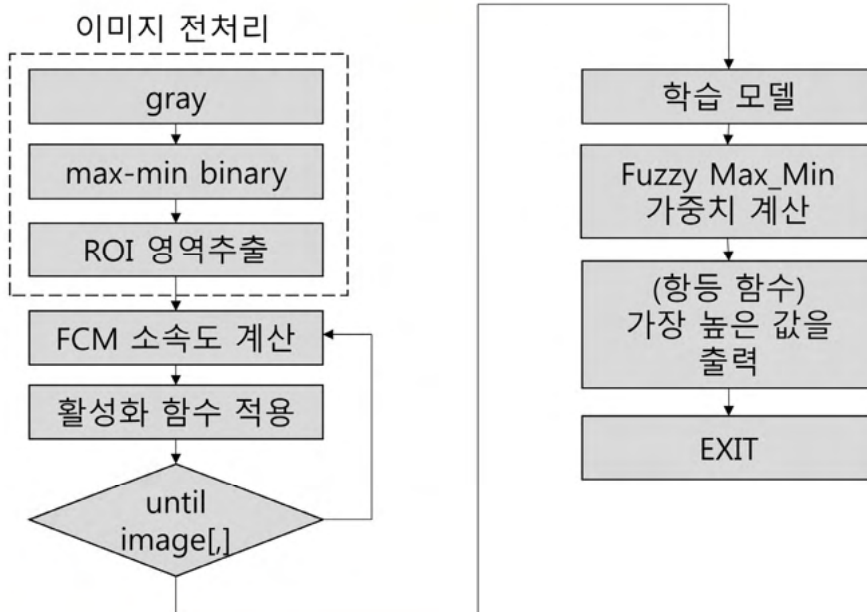
단층 퍼셉트론



Fuzzy Max-Min Neural Networks

04

4. Algorithm




결과 Fuzzy Max-Min Neural Network

**04**

### 4. 결과 및 개선사항


```
Clustering 출력값
1번째 클러스터 : 0.524294446290456
2번째 클러스터 : 1
3번째 클러스터 : 0
4번째 클러스터 : 0.423506793012037
-----
출력값
result[0] : 1.43
result[1] : 0.923506793012037
result[2] : 1.93350679301204
result[3] : 1.86780123930249
result[4] : 1.72429444629046
result[5] : 1.14780123930249
result[6] : 1.14780123930249
result[7] : 1.90429444629046
result[8] : 2.04
result[9] : 1.79780123930249
결과
```

Menu NeuralNetwork FCM



```
Clustering 출력값
1번째 클러스터 : 0
2번째 클러스터 : 0.883076585061398
3번째 클러스터 : 0.770971822480661
4번째 클러스터 : 1
-----
출력값
result[0] : 1.85404840754206
result[1] : 1.67097182248066
result[2] : 2.7530765850614
result[3] : 2.02
result[4] : 1.1830765850614
result[5] : 1.77097182248066
result[6] : 1.75
result[7] : 1.3630765850614
result[8] : 1.5030765850614
result[9] : 1.95
결과
```

Menu NeuralNetwork FCM



**THANK  
YOU**


발 표 자 왕 준 혁

# 태양전지를 이용한 보행자 그늘막



스마트전기전자공학부 201894007 구종은  
스마트전기전자공학부 201894070 조혜빈

## 목차



- |    |                   |    |                  |
|----|-------------------|----|------------------|
| 01 | 연구목적<br>추진목적 및 목표 | 02 | 사용부품<br>(작품의 구성) |
| 03 | 제작과정              | 04 | 기대효과             |

## 1. 연구목적



-보행자 그늘막장치-

1. 개폐수단의 수동작동으로 인해 그늘막 장치를 관리할 관리자필요
2. 급변하는 기상여건에 적절한 대처능력부족
3. 가시광선을 피할 수 있는 수단 외 기능부족

## 1. 추진목적 + 목표

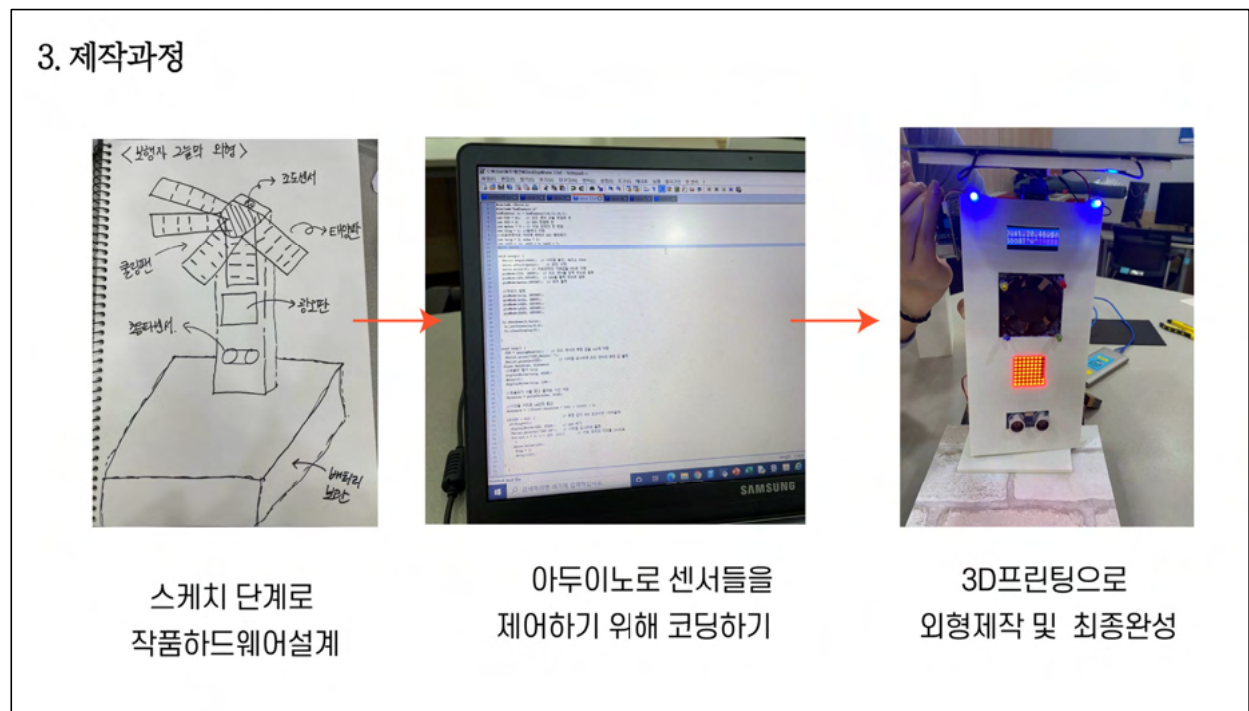
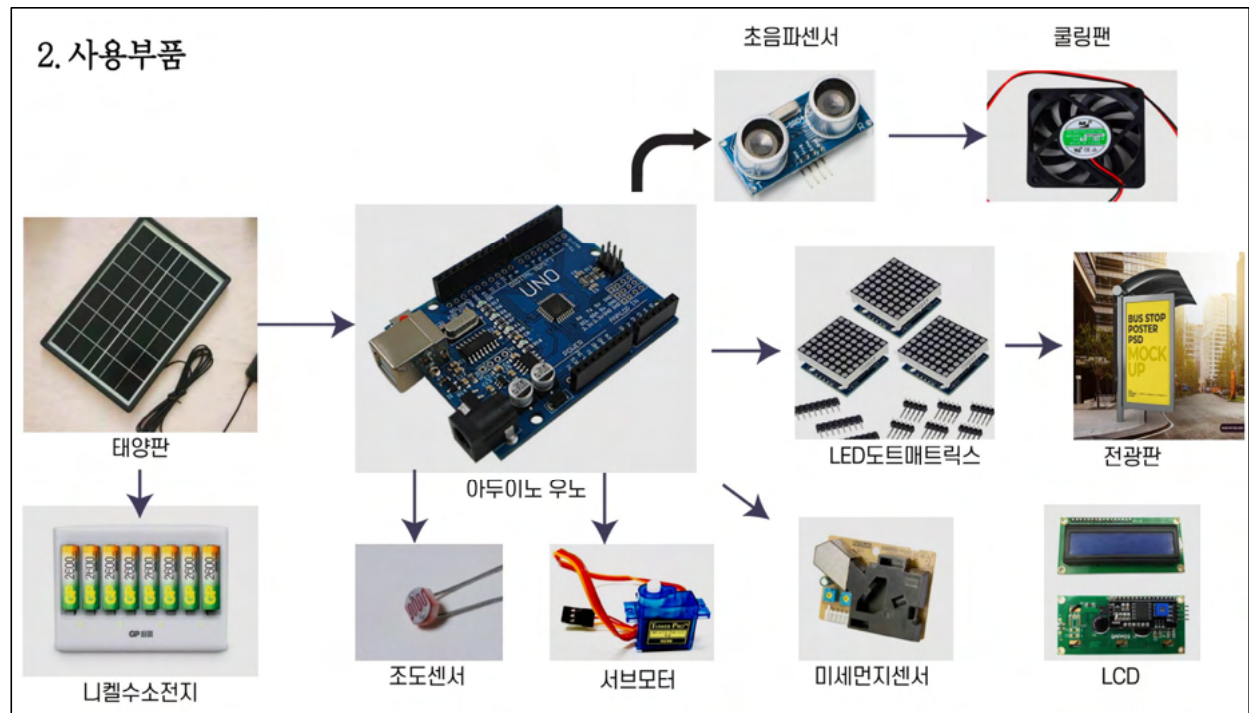
>지난 2017년 12월 19일 정부에서 2030년까지 재생 에너지의 비율을 20%까지 늘리고 그 중에서도 태양광 에너지를 95%로 늘린다는 재생에너지 3020계획을 발표하였습니다.

>저희는 재생에너지 중에서도 가장 비율이 높게 선정된 태양광 에너지를 동력으로 여름의 무더위를 개선 할 수 있는 작품을 구상하게 되었습니다.



본 발명의 목적은, 횡단보도의 보행자 안전구역 또는 버스정류장 등에 설치하여 보행자가 신호등을 기다리는 동안 비를 피하거나 햇볕을 가려 줄 수 있게하고, 태양광발전에 의한 친환경 재생에너지를 이용하여 외기온도에 따라 차양막 하부로 시원하거나 따뜻한 바람을 공급해 줌으로써 그늘막을 이용하는 보행자에게 쾌적함을 줄 수 있는, 스마트 횡단보도 그늘막을 제공하기 위한것입니다.

The Footnote






### 3. 제작과정



3D모델링을 통하여 다양한 외형디자인을 구상 및 제작



태양판+조도센서

#### 4. 기대효과



폭염 및 한파로부터 보행자를 보호하며 쾌적한 보행환경을 제공할 수 있다.



친환경 에너지를 이용하여 경제적이다.



광고판을 통하여 지자체의 수입증가를 기대해 볼 수 있다.

보행자에게는 편안함과 쾌적함을 느끼게 하여 신호등을 기다리는 시간을 편안하게 보낼 수 있는 도심속의 작은 쉼터 공간을 제공해 줄 수 있다.

# 감사합니다

Thank you

Fin  
마침

2021 인공지능 및 응용 워크숍

---

**ORAL**  
**인공지능 응용**

13:30~14:40

---

## Screening of COVID 19 using IoT System

Md Ariful Islam Mozumder · Ali Hussain · Ather Ali · Abdullah · Hee-Cheol Kim\*

\*Inje University

E-mail : arifulislamro@gmail.com

### ABSTRACT

Coronavirus is well known for all countries from the year 2019 and from the same year it has become a global pandemic with an exponential growth rate and an incompletely understood transmission process. Internet of Things (IoT) is being used to aid various aspects of the COVID-19 crisis, including related research and drug development, medical development, and treatment. In this study, we propose to create a medical device utilized consisting of the composable sensor to monitor remotely and in real-time the health status of those who have symptoms of the coronavirus. The whole IoT system will be implemented by using a wearable medical sensor integrated using Arduino hardware interfacing and a smartphone application. Here, the analysis will be performed on the patient's critical status of the coronavirus symptoms using heartbeat, temperature, and cough.

### Key words

Coronavirus, IoT, Arduino, Cough, Temperature, Cough & custom algorithm

### I. INTRODUCTION

The IoT has been widely identified as a potential solution to alleviate the pressures on healthcare systems and has thus been the focus of much recent research. A considerable amount of this research looks at coronavirus screening and monitoring patients. Several studies have shown novel designs for smart healthcare solutions using IoT-based systems. An in-depth study is presented in [1], focusing on some of the available solutions, well-known applications, and remaining problems. Each subject is considered separately, rather than as a part of an overall system[1]. This paper is structured as follows: At first, in section 2, we presented the relation between IoT and Coronavirus, section 3 highlights the important role of the architecture of our proposed IoT-based systems focusing on some of the IoT devices that are used in the screening coronavirus.

### II. Coronavirus and Internet of Things

In recent years, IoT technology has received significant attention in the medical healthcare domain where it plays an essential role in several phases of various infectious[2]. In the running pandemic, as the contingency of COVID-19 is high, there is an essential need for patients to be connected with and monitored by their physicians proactively in different phases of COVID-19. IoT devices can speed up the screening process by capturing real-time data from patients. This can be implemented by capturing body temperatures, collecting cough samples, and counting heartbeat rates using different sensors and IoT devices. IoT devices in this phase can monitor patients remotely for their treatments and suggest whether to stay-at-home. IoT

devices can help to reduce the spreading of coronavirus[3].

### III. Contributions of this work

We propose a screening system of COVID-19 remotely, with the help of wearable sensorial devices and a custom algorithm. Our proposed solution has several novel features: (1) the sensors utilized in our approach are cheaper, available off-the-shelf, and can be easily integrated to detect various prefixes, (2) the test can be carried out by experts and non-experts or any stranger, also the results obtained can be inferred by expert or non-expert. Processing is performed by the sensors and IoT devices in the accompanying proposed process, (3) results are monitored and resolved without physical contact, (4) definitely the result in real-time, (5) there is some technique used for the detection of coronavirus we will describe details technique in our future work,(6) lastly, by using the IoT infrastructure, efficient stream processing, and data integration is ensured in the cloud. Our rule-based system for decision-making can assess the outputs in linear time as compared to the exponential growth in most machine-learning problems. The proposed algorithm will be able to respond to any scale of data.

### IV. Coronavirus Screening Device

The device is accompanied by a smart phone application to remotely follow and determine the patient's health condition if he/she is infected with coronavirus in a combination of the data from the sensors[3]. Using patterns from visualization concepts, we use different widgets and different colors to display the results of the sensors as well

as the diagnosis, based on data from the sensors[3]. The application uses an algorithm to decide on the status of the patient without any symptoms or have mild, moderate, or severe symptoms along with individual sensor reading for explanation and evaluation[4]. After viewing our figure anyone can understand our proposed covid-19 screening method.

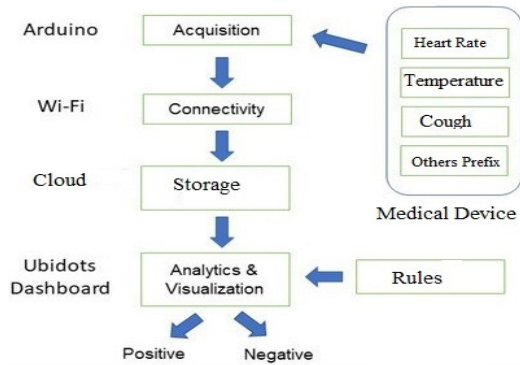


Figure 1. Describing essential of our approach

There is a rules-based system for decision-making and this is an important part of our study. A patient is evaluated against the rules and is assigned a class based on the conditions stated in each class, shown in table.

Future Work

In the future, we will develop a complete IoT framework for screening COVID-19 using real-time data from Wearable and sensors which is easily accessible for everyone. Also, perform classification machine learning algorithm.

V. CONCLUSION

In this paper, we have presented a project proposal in the form of an innovative real-time screening system using IoT devices for Covid-19 patients. At present, as we are facing different kinds of problems across the world, the proposed method can provide a promising solution and help to control the spread of the virus which can motivate researchers and clinicians[6,7]. The proposed system is simple and easy to understand.

ACKNOWLEDGMENTS

This work was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF), supported by the Ministry of Science, ICT & Future Planning (NRF2017R1D1A3B04032905).

REFERENCES

- [1] M. Ennafiri and T. Mazri “Internet of Things for Smart Healthcare: A Review on a Potential IOT Based System and Technologies to Control COVID-19 Pandemic,” Ibn Tofail University, Kenitra, Morocco.
- [2] Mwafaq Ottom, Nesreen Otoum, amohammad A. Alzubaidi, Yusef Etoom “An IoT framework for identification and monitoring of Covid-19 cases” Yarmouk University, Irbod, Jordan.
- [3] Hamid Mukhtar, Saeed Rubaiee, Moez Krichen, Roobaea Alroobaea “An IoT Framework for Screening of COVID-19 Using Real-Time Data from Wearable Sensors”. Taif University, Saudi Arabia.
- [4] Pratnadeep Biswas, Sumanta Chatterjee “IoT Based Scanner for Corona Detection” JIS College of Engineering, India.
- [5] Hu F, Xie D, Shen S (2013) On the application of the internet of things in the field of medical and health care. In: 2013 IEEE International Conference on Green Computing and Communications an IEEE Internet of Things and IEEE Cyber, Physical and Social Computing. IEEE, pp. 2053-2058.
- [6] <https://www.marketsandmarkets.com/Market-Reports/iot-healthcaremarket-160082804.html>. Accessed June 29, 2020.
- [7] Shigao Huang, Jie Yang, Simon Fong, Qi Zhao “Helping Roles of Artificial Intelligence (AI) in the Screening and Evaluation of COVID-19 Based on the CT Images” University of Macau 999078, Macau SAR, China.

Table 1: ⚡

No.⚡	Class 0 ⚡ (Non-Symptomatic)⚡	Class 1⚡ (Mild-Symptoms)⚡	Class 2⚡ (Moderate Clinical-Symptoms)⚡	Class 3⚡ (Serious-Clinical-Symptoms)⚡
1.⚡	Oxygen Saturation (SpO2) ≥ 95%⚡	Oxygen Saturation (SpO2) ≥ 95%⚡	93% ≤ Oxygen Saturation (SpO2) ≤ 94%⚡	Oxygen Saturation (SpO2) ≤ 92%⚡
2.⚡	Cough Rate: NIL⚡	Cough Rate ≤ 5/min⚡	5/min ≤ Cough Rate < 30/min⚡	Cough Rate ≥ 30/min⚡
3.⚡	Heartbeat Rate ≤ 100 bpm⚡	Heartbeat Rate ≤ 100 bpm⚡	Heartbeat Rate > 100 bpm⚡	Heartbeat Rate > 120 bpm⚡
4.⚡	Temperature ≤ 37.2 °C⚡	36 °C ≤ Temperature ≤ 38 °C⚡	Temperature ≥ 38 °C⚡	Temperature > 38 °C⚡
5.⚡	No headache and pains⚡	No shortness of breath.⚡	⚡	Occurrence of comorbidities.⚡
6.⚡	No comorbidities⚡	No comorbidities⚡	⚡	Oxygen Saturation (SpO2) ≤ 92%⚡

# 홉필드 네트워크와 단층 퍼셉트론을 이용한 손상된 교통 표지판 분류

김주완 · 박태언 · 김광백

신라대학교 컴퓨터소프트웨어공학부

## Corrupted Traffic Sign Classification using Hopfield Networks and Single Layer Perceptron

Ju-wan Kim · Tae-eun Park · Kwang-baek Kim

Division of Computer Software Engineering, Silla University

E-mail : wndhks00000@naver.com / ase6733@naver.com / gbkim@silla.ac.kr

### 요 약

본 논문에는 홉필드 네트워크와 단층 퍼셉트론을 이용하여 손상된 교통 표지판의 이미지를 분류하는 방법을 제안한다. 제안된 방법에서는 손상된 교통 표지판에 특징들을 분석한 후, 그 특징들을 학습 패턴으로 구성하여 단층 퍼셉트론에 적용하여 1차적으로 교통 표지판의 특징을 분류한다. 1차적 분류된 특징이 있는 학습 영상들을 홉필드 네트워크에 적용하여 손상된 특징을 복원한다. 홉필드 네트워크를 적용하여 복원된 교통 표지판의 특징들을 다시 단층 퍼셉트론에 적용하여 최종적으로 손상된 교통 표지판을 분류하고 인식한다. 제안된 방법의 성능을 평가하기 위하여 손상된 정도가 다른 다양한 교통 표지판 8개를 적용하여 실험한 결과, 제안된 방법이 단층 퍼셉트론 기법에 비해 평균적으로 48.13%의 분류 성능이 개선되었다.

### 키워드

홉필드 네트워크, 단층 퍼셉트론, 교통 표지판, 학습 패턴

## I. 서 론

교통 표지판은 도로이용자에게 일관성 있고 통일된 방법으로 교통 정보를 제공해야 하며 정보 제공 목적에 따라 크게 4종류로 나누어지는데 도로 상태와, 도로 부근의 위험을 알리는 “주의표지”, 도로교통의 제한, 금지 등의 규제를 알리는 “규제표지”, 도로교통 안전을 위해 도로이용자를 따르도록 하는 지시가 담긴 “지시표지”, 주의표지, 규제표지, 지시표지를 보조 설명하는 “보조표지”가 있다[1].

기존의 관련 연구로는 웨이블릿(Wavelet)변환과 형태정보를 이용하여 교통표지판을 인식하는 방법이 제안되었다. 이 방법은 추출된 표지판 영역에 대해서 웨이블릿 변환을 적용하여 얻은 고주파 및 저주파정보를 기반으로 모멘트, 에지 코렐로그램(edge cabrlegram), 동심 원형 패턴 정보를 추출하고 사전에 구축한 데이터베이스와의 유사도측정에 의해 인식하는 방법이지만 입력 영상을 전처리과정이 복잡하여 처리 시간이 많이 소요되고 입력 영상이 작은 경우에는 크기에 대한 정규화 하는 기법으로 선형보간법을 적용하였지만 정보의 손실이 많아 인식률이 저하되는 문제점이 있다[2,3].

따라서 본 논문에서는 교통 표지판에 대한 형태학적 특징을 단층 퍼셉트론에 적용하여 교통 표지판의 특징들을 1차적으로 분류하고 분류된 특징을 가진 교통 표지판을 홉필드 네트워크에 적용한 후 교통 표지

판의 특징을 정량화한다. 그리고 정량화된 특징을 다시 단층 퍼셉트론에 적용하여 손상된 교통 표지판 영상에서 정확히 특징을 분류하고 인식하는 방법을 제안한다.

## II. 홉필드 네트워크와 단층 퍼셉트론을 이용한 손상된 교통 표지판 분류 방법

### 2.1 단층 퍼셉트론

단층 퍼셉트론은 신경망의 기본적인 지도 학습 방법으로 간단한 패턴 인식에 적용되는 학습 알고리즘이다[4]. 단층 퍼셉트론의 학습 구조는 입력층과 출력층으로 구성되고 단층 퍼셉트론 알고리즘은 다음과 같다.

#### 단층 퍼셉트론 알고리즘

$w$  : 가중치,  $p$  : 패턴 쌍  
 $k$  : 1,  $\alpha$  : 학습률  
 $X$  : 입력된 패턴  
 $d$  : 목표 값  
 $y$  : 출력 값

**Step 1.**  $w$ 를 임의의 값으로 초기화 한다.

**Step 2.**  $p$ 의 개수를 지정한다.

**Step 3.**  $\alpha$ 을 0과 1사이의 값으로 설정한다.

**Step 4.**  $k$ 가  $p$ 의 개수가 될 때 까지 Step 5 ~ Step 7을 반복한다.

**Step 5.**  $y$  값을 식 1을 적용한다.

$$y_k = \begin{cases} 1 : NET > 0 \\ y_k : NET = 0 \\ -1 : NET < 0 \end{cases} \quad (1)$$

**Step 6.** If  $y = d$

$k = k + 1$  하고 Step 4로 돌아간다.

else

Step 7로 간다.

**Step 7.**  $w$ 를 식 (2)에 적용하여 조정한다.

$$w = w + \alpha(d - y)X \quad (2)$$

이후  $k = k + 1$  하고 Step 4로 돌아간다.

**Step 8.** 종료 조건을 검사한다.

Step 4 - 7을 진행한 후에  $w$ 이 변경 되지 않으면 학습을 종료 한다. 그렇지 않으면  $k = 1$  하고 Step 4로 돌아간다.

교통 표지판은 일상생활 속에서 부식, 노화 등의 외부 작용으로 인해 변형, 손상될 수 있어 일상 속 교통 표지판을 분류하기 위해서는 변형, 손상된 교통 표지판도 정확히 분류해야 한다. 따라서 딥러닝 기법인 CNN이나 다층 퍼셉트론 중에서 오류 역전파 알고리즘을 적용할 수 있으나 이 두 기법은 많은 학습 데이터를 요구한다. 따라서 본 논문에서는 교통 표지판의 특징을 분석하여 변형이나 손상된 교통 표지판을 원형으로 복원하여 정량화 하기 위한 방법으로 동질 연상 메모리 기법인 홉필드 네트워크와 정량화된 교통 표지판을 분류하고 인식하기 위해서 단층 퍼셉트론 기법을 적용한다.

### 2.2 홉필드 네트워크

본 논문에서 손상되거나 변형된 교통 표지판의 특징들을 복원하여 정량화하기 위한 방법으로 사다음과 같은 홉필드 네트워크를 적용한다[5].

홉필드 연상메모리 알고리즘

$w$  : 가중치,  $p$  : 패턴 수

$s$  : 기억시킬 입력 패턴

$t$  : 연상되는 출력 패턴

$X$  : 입력 값,  $Y$  : 출력 값

**Step 1.**  $p$ 개 패턴을 저장하기 위한 가중치를 다음과 같이 계산한다.

$$W = \sum_{i=1}^p s^T(i)s(i) - pI \quad (3)$$

**Step 2.** 업데이트(복구) 순서를 결정한다.

**Step 3.** 초기 출력을 설정한다.

$$Y \leftarrow X$$

**Step 4.** 출력노드  $y_i$ 에 대해서 단계 5부터 단계 6까지 반복한다.

**Step 5.**  $NET$  값을 식 (4)와 같이 계산한다.

$$NET = x_i + YW^T \quad (4)$$

**Step 6.** 내부 중간 출력 값을 식 (5)를 적용하여 구한다.

$$y_i = \begin{cases} +1 : NET > 0 \\ y_i : NET = 0 \\ -1 : NET < 0 \end{cases} \quad (5)$$

**Step 7.** 종료조건을 검사한다.

$y$ 값이 변화가 없다면 종료하고 그렇지 않으면 Step 4로 가서 학습을 반복한다.

### 2.3 제안된 교통 표지판 인식 방법

교통 표지판은 종류에 따라 빨간색, 노란색, 파란색, 흰색, 검은색 총 5가지 색채 중 3가지 이하의 색 조합으로 이루어져 있다. 위와 같은 색의 조합을 이용하여 단층 퍼셉트론으로 4개의 클래스로 분류하고 분류된 클래스별로 홉필드 네트워크를 적용하여 학습한다. 이는 하나의 가중치 행렬에 학습되는 패턴간의 중복 특성을 최소화 한다. 그 후에 홉필드 네트워크를 통하여 복원된 교통 표지판의 특징들을 단층 퍼셉트론에 적용하여 최종적으로 교통 표지판을 분류하고 인식한다.

### III. 실험 및 결과분석

본 논문에서 본 논문에서는 제안된 방법의 성능을 분석하기 위하여 Intel(R) Core(TM) i7-8700 CPU @3.20Hz와 16GB RAM이 장착된 PC상에서 Visual Studio 2019 C#으로 제안된 방법을 구현하였고 70×70 해상도를 가진 교통 표지판 영상 8개를 대상으로 전체 픽셀 중에서 30%에서 부터 70% 사이로 임의로 손상시켜 실험하였다.

그림 1과 같이 교통 표지판의 특징이 많이 손상된 경우에는 단층 퍼셉트론만으로는 교통 표지판의 특징들이 분류되지 않은 경우이지만 그림 2와 같이 제안된 방법을 적용할 경우에는 그림 2에서와 같이 교통 표지판의 특징이 손상된 경우에 대해서 홉필드 네트워크로 특징들을 복원하여 특징들을 정량화하였기 때문에 단층 퍼셉트론에서 특징들을 정확히 분류하여 교통 표지판이 인식된 경우이다.

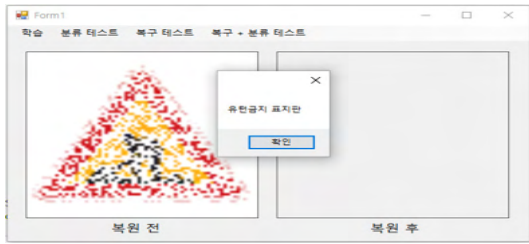


그림 1. 단층 퍼셉트론을 적용한 영상 분류 실패 예시



그림 2. 제안된 방법을 적용한 영상 분류 성공 예시



그림 3. 제안된 방법을 적용한 영상 분류 실패 예시

그림 3과 같이 교통 표지판의 특징들이 많이 손상된 경우에는 제안된 방법으로도 교통 표지판을 인식할 수 없었다. 그 이유는 1차적으로 적용한 단층 퍼셉트론에서 서로 다른 교통 표지판의 특성들이 혼합하여 분류되었다. 그리고 서로 다른 특징들이 혼합된 상태로 홉필드 네트워크의 입력으로 적용되어서 교통 표지판의 특성들이 복원되지 않아 비 정량적인 데이터로 존재한 상태에서 단층 퍼셉트론 알고리즘에 적용되었기 때문에 서로 다른 교통 표지판의 특징들을 정확히 분류되지 않았기 때문이다.

#### IV. 결론

본 논문에서는 손상, 변형된 교통 표지판들을 효과적으로 분류 및 인식 하기 위한 인공지능 접근 방법으로 Hopfield Network와 단층 퍼셉트론을 적용하는 방법을 제안하였다. 교통 표지판의 색의 조합을 이용하여 단층 퍼셉트론으로 4개의 클래스로 분류하고 분류된 클래스별로 홉필드 네트워크로 학습하여 하나의 가중치 행렬에 학습되는 패턴간의 중복 특성을 최소화 하였다. 그 후에 복원된 교통 표지판의 특징들을 단층 퍼셉트론에 적용하여 최종적으로 교통 표지판을 분류하고 인식하였다.

본 논문에서는 교통 표지판 영상 8개를 대상으로 흰색과 색채로 임의로 손상시켜 영상 당 10회 씩 분류 성능을 실험하였고, 기존 단층 퍼셉트론만을 적용

시킨 분류 경우보다 홉필드 네트워크를 적용하여 영상을 복원한 후에 단층 퍼셉트론으로 분류한 경우가 48.13%의 분류 성능이 개선되었다.

향후 연구 과제로는 학습 과정에서 영상을 복원하는 방법으로 홉필드 네트워크를 적용하였지만 학습 영상 개수가 증가할수록 복원 성능이 낮아진다. 따라서 제안된 학습 과정에서 특징의 분류 성능이 낮아지는 경우가 발생할 수 있다. 이러한 문제점을 개선하기 위하여 IFAM 기법을 적용하는 방안에 대해 연구할 것이다.

#### REFERENCES

- [1] [https://www.koroad.or.kr/kp\\_web/knTrafficSign1.do](https://www.koroad.or.kr/kp_web/knTrafficSign1.do)
- [2] G. W. Bang, D. W. Kang, W. H. Cho, "Traffic Sign Recognition Using Color Information and Error Back Propagation Algorithm," The KIPS Transactions : Part D, Vol.14-D, No.7, pp.809-818, 2007.12.
- [3] J. T. Oh, H. W. Kwak, W. H. Kim, "Recognition of Traffic Signs using Wavelet Transform and Shape Information," Journal of the Institute of Electronics and Information Engineers, Vol.41, No.5, pp.125-134, September, 2004.
- [4] J. E. Dayhoff, Neural Network Architectures, Van Nostrand Reinhold, 1990.
- [5] M. S. M. Kashihmuddin, M. A. Mansor, S. sathasivam, "Discrete Hopfield Neural Network in Restricted Maximum k-Satisfiability Logic Programming," Sains Malaysiana, Vol.47, No.6, pp.1327-1335, 2018.

# 데이터가 안되면 모델이라도

백성복\*

KT 융합기술원

## If not data, then model

Seongbok Baik\*

KT Institute of Convergence Technology

E-mail : s.baik@kt.com

### 요 약

데이터는 인공지능분야의 구성요소 중 가장 근본적인 요소라 할 수 있다. 기술을 연구하고 개발하는 기술 진영은 현실에서 사용되는 데이터가 반드시 필요한 상황이나, 정작 가치 있는 데이터를 소유하고 있는 데이터 진영은 다양한 이유로 데이터를 공개하지 못하고 있다. 가치 있는 데이터를 공유하는 환경을 구축한다는 것은 개인 정보 보호법 등 법안을 포함하여 사회 문화적 인식을 바꿔야 하는 문제로서 상당한 시일이 걸릴 것으로 보인다. 현재 익명화 또는 암호화를 통해 데이터를 공개하는 법안이 작성되고 있으나 이로 인해 가려지는 부분에 있는 정보들이 모델 학습에 중요한 역할을 하는 경우도 많아서 법제화가 어느 정도 완성된다 해도 학습 효율성의 문제가 여전히 남는다. 한편 법제도가 완비되기를 기다리는 동안에도 기술 진영과 데이터 진영 간의 협업은 지속적으로 시도되고 있다. 본고에서는 데이터 진영에서 데이터 자체를 제공하는 대신 모델을 학습시켜 제공하고, 기술 진영에서는 해당 모델을 활용하여 기존 솔루션을 인공지능형 솔루션으로 개선시킨 사례에 대해 소개한다.

### ABSTRACT

Data can be considered as one of the key components to construct the artificial intelligence(AI) technology. AI researchers and engineers desperately need the real data, but the data owners cannot easily disclose it due to the various reasons, such as prohibition by the Personal Information Protection Act. It seems to take a long time to be able to open the data to the research domain, because it is a matter of changing social and cultural perceptions, including the laws and regulations. Today, some of the legislations focusing on data anonymization or encryption are being drafted. However, even if the legislation is completed to some extent, the model learning process may be confined, because the anonymized or encrypted parts of the original data can play an important role to build up the better model. Even while waiting for the legal system to be complete, collaboration between the technology and data groups continues to be attempted. In this paper, we introduce the case in which the data owner provides a model instead of the data itself, and the technology owner uses the model to improve their legacy solution into an AI-based solution.

### 키워드

collaboration between AI data owner and technology owner, international fraud call

## I. 서론

필요한 데이터를 어디에서 어떻게 확보할 것인가 하는 문제는 인공지능, 특히 딥러닝 기술과 관련한 가장 핵심적인 문제라 할 수 있다. 가치 있는 중요한 모델을 만들기 위해서는 그만큼의 가치 있는 중요한 데이터가 먼저 확보되어야 한다. 데이터 진영은 기술 진영으로부터 지속적으로 데이터를 공개할 것을 요청받아 왔으나 법제도 등 여러 가지 문제로 적극적인 대응이 어려운 실정이다.

지금 당장 데이터를 공개하거나 제공하는 것이 어렵다고 해서 기술 진영과 데이터 진영의 협업이 늦춰지는 것은 바람직한 현상이 아니기 때문에 사안 별로 현실적인 대안을 적극적으로 찾아낼 필요가 있다.

본고는 데이터를 소유한 회사(KT<sup>1</sup>)와 솔루션을 소유한 회사(Mobileum<sup>2</sup>)간에 이루어진 공동 개발 프로젝트에 대해 기술한다. 해당 협업을 통해 KT는 딥러닝 모델을 개발하고 Mobileum은 기존 제품에 해당 모델을 정합하여 인공지능형 제품을 신규 개발할 수 있었다.

## II. 배경

해외로부터 해커가 국내에서 출발하는 국제호를 유발함으로써 사용하지 않은 국제전화에 대해 통신비가

1) <https://www.kt.com/>

2) <https://www.mobileum.com/>

청구되는 사고가 발생하고 있다[1]. 통신사에서는 고객 서비스 차원에서 이런 유형의 공격을 방어하기 위한 국제전화 불법호 탐지 시스템을 운용하고 있다.

하지만 국제전화 불법호를 탐지하는 기존의 시스템들은 보통 경험이 많은 운용자들이 작성한 규칙을 기반으로 개발되어 운용되고 있다. 규칙 기반의 시스템들은 그 정적인(deterministic) 속성으로 인해 해커들의 공격 유형이 약간만 달라도 이를 탐지하지 못하는 문제가 있다. 해커들이 탐지 규칙을 추정하여 해당 규칙을 회피하는 공격루트를 개발할 때마다 이를 방어하기 위한 새로운 규칙을 만들어 넣어야 하는 어려움이 있다.

국제전화 불법호 탐지 솔루션 제작사인 Mobileum에서는 최신 딥러닝 기술을 이용하여 규칙 기반의 자사 시스템의 단점을 개선하고자 하였으나, 딥러닝 모델에 필수적인 데이터 확보의 어려움으로 인해 개발이 어려운 상황이었다.

국제전화 불법호 데이터를 생산하고 관리하는 주체는 주로 통신사이나, 통신사 내부 규정, 또는 국가의 법률 등, 여러 가지 규제로 인해 해당 데이터의 외부 반출은 현실적으로 불가능한 상태였다.

이에 데이터를 소유한 KT와 솔루션을 소유한 Mobileum이 협업하여 딥러닝 기반의 불법호 탐지 시스템을 개발하는 공동 프로젝트를 수행하게 되었다.

### III. 공동 개발 시스템

프로젝트는 두 단계로 나누어 진행되었는데, 1단계에서는 모델 개발과 1차 평가 및 기존 솔루션으로의 기능적 정합이 이루어 졌고, 2단계에서는 실제 운용환경에서 정합된 모델의 기능 및 성능을 확인했다.

딥러닝 모델 학습에 사용된 데이터는 통화 관련 정보를 담고있는 CDR(Call Detail Records)[2] 데이터로서 저수준 프로토콜의 매 단계별로 매우 상세하고 풍부한 정보를 제공하기 때문에 해커들의 공격 패턴을 탐지하기에 유용한 측면이 있다.

설계된 딥러닝 모델은 전반부에 해커들의 공격 패턴을 시간 측면에서 감지하고 이를 2차원 평면으로 실시간 매핑시켜 주는 전처리 모듈이 배치되어 있고, 후반부에 매핑된 2차원 평면 자료를 바탕으로 분류 작업을 수행하는 CNN 모듈이 장착되었다.

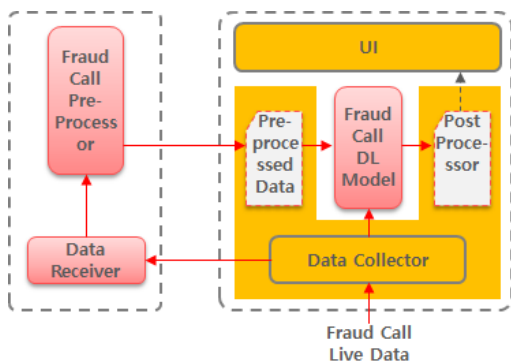


그림 1. 공동 개발 시스템 구성도

그림 1은 공동 프로젝트에서 개발된 시스템의 구성도이다. 전처리 모듈은 실시간성을 보장하기 위해 그림의 왼쪽 부분에 위치한 KT측 시스템에 장착하였

고, 딥러닝 모델은 Mobileum의 불법호 탐지 솔루션에 장착하는 형태로 구성하였다.

### IV. 시스템 구현

1단계에서 모델 개발과 솔루션 정합을 완료한 후, 2 단계에서는 실제 운용환경에서 정합 시스템을 시험하여 성능을 확인하였다.




그림 2. 딥러닝 모델 성능 비교

시스템의 성능을 측정한 결과가 그림 2에 표시되어 있다. 지면상의 제약으로 3가지 항목(정확도와, 재현율, 정밀도)만을 표시하였으나 NPV와 F1-Score 등 다양한 항목에 대한 조사가 수행되었다.

각 항목별로 기존의 rule 기반 엔진 대비 딥러닝 모델의 성능을 비교하여 표시하였다. 특이한 사항은 딥러닝 모델을 시험하는 과정 중에 잘못 설정된 rule들이 발견되었다는 점이다. 그림 2의 각 항목별 그래프에서 두 번째 그래프는 잘못 설정된 rule을 수정한 후에 다시 측정한 rule 기반 엔진의 성능치이다. 그래프에서 확인할 수 있듯이 최초 rule 엔진 대비 딥러닝 모델이 30%~50% 수준의 성능 향상을 보이고 있다.

A Number	B Number	Destination	Duration (s)	Amount	Prediction
0222222001	00134939652221	Spain	10	50	82.5%
0222222001	00134939652221	Spain	10	50	69.5%
0222222001	00134939652221	Spain	10	50	81.4%
0222222001	00134939652221	Spain	10	50	95.6%
0222222001	00134939652221	Spain	10	50	86.0%
0222222001	00134939652221	Spain	10	50	63.3%
0222222001	00134939652221	Spain	10	50	43.0%
0222222001	00134939652221	Spain	10	50	86.3%
0222222001	00134939652221	Spain	10	50	83.7%
0222222001	00134939652221	Spain	10	50	50.9%
0222222001	00134939652221	Spain	10	50	62.7%
0222222001	00134939652221	Spain	10	50	85.5%

그림 3. 딥러닝 모델의 예측 화면

그림 3은 실제로 사용자 화면에서 딥러닝 모델의 예측 활동을 모니터링한 예이다. 통화 시작 정보와 도착 정보, 통화 기간, 등의 일반적인 정보와 더불어 해당 통화가 불법호일 가능성을 확률값으로 표시해 주기 때문에 운용자는 이를 바탕으로 어떤 조치를 취한 것인지를 신속하게 판단할 수 있다.

## V. 결 론

본 연구를 통해 데이터 진영의 KT와 기술 진영의 Mobileum이 현행 법제도의 테두리 안에서 각자의 경계를 지키면서 성공적인 협업을 수행하는 방법을 제시하였다.

딥러닝 연구자들이 원하는 데이터에 자유롭게 접근하는 이상적인 환경을 조성하기 위해서는 아직도 긴 시간이 필요할 것으로 예상되는 점을 감안하면 본 공동 연구가 양 진영 간의 협업을 계획하는 후발 연구자들에게 유용한 참고 자료가 될 것으로 기대된다.

본 공동 연구를 통해 KT에서 개발한 딥러닝 모델은 Mobileum의 솔루션에 장착되어 90% 이상의 정확성과, 98% 이상의 재현율을 보이고 있으며, 기존에 운용되던 rule set의 오류를 찾아내거나, 유사한 패턴의 불법호를 탐지하고, 불법호 가능성을 확률 형태로 표시함으로써 운용자의 신속한 판단을 지원하는 등 다양한 가능성을 증명하였다.

## REFERENCES

- [1] SBS 뉴스. 쓰지도 않은 국제전화 요금 폭탄, 알고 보니[Internet]. Available : [https://news.sbs.co.kr/news/ndPage.do?news\\_id=N1006020459](https://news.sbs.co.kr/news/ndPage.do?news_id=N1006020459)
- [2] wikipedia. Call Detail Record[Internet]. Available : [https://en.wikipedia.org/wiki/Call\\_detail\\_record](https://en.wikipedia.org/wiki/Call_detail_record)

# Face Shape Classification Using Image Processing through Transfer Learning

Abdullah · Ali Sikandar · Ali Hussain · Ali Athar · Hee-Cheol Kim\*

\*Inje University

E-mail : [abdullahbaltistani@gmail.com](mailto:abdullahbaltistani@gmail.com)

## ABSTRACT

Face shape identification plays a vital role in many used cases. This work illustrates that the classification of four types of face shapes based on their facial attributes using transfer learning. The MobileNet is used for experimental setup as a pre-train model and OpenCV is also used for preprocessed the data. The private dataset which is used in this experiment contains 400 images of both males and females. The face images are cropped by using a haar cascade classifier, which removes the unnecessary part from the whole image, furthermore that cropped images are sent to the pre-train model. We have combined the image processing and deep learning (Mobile-net) technique to evaluate the face shape from the images. The accuracy of the pre-train mobile-net model is high as compared to feature engineering techniques, like KNN, SVM, and Random forest The accuracy of our model is 85.6%, which is quite good. In addition, the result shows that the transfer learning approach is a valuable technique to detect face shapes with a little computation power.

## Key words

Pre-train model, Classification, transfer learning, openCv, facial attribute

## I. INTRODUCTION

Face shape classification having an important role in image processing and computer vision. In many literature studies and the guidelines of beauty experts [1], the face shape is classified into five sub-classes such as oval, oblong, round, heart, and square-shaped.

Face shape acknowledgment is widely used and has many applications like recommendation systems for make-up, hairstyle, eyewear [2], and many other fashion accessories. From a healthcare perspective, It also helps to recommend food and medicine for a human. The recommender system plays a vital role as a personal digital assistant which is mostly linked to social media and product advertisement. Similarly, face shape classification could be used in facial profiling to improve the speed of facial identification and recognition. The shape of face classification is easily available in the literature and mostly scientific article publications base on feature engineering techniques. Face can be recognized using appearance base, model-based, Template-based, and Statistical based [3].

With the rapid growth in technology, the pre-train model like Inception V3 [4], VGG16 [5], Resnet, etc becoming more and more popular to perform the same task in low power consumption and good result performance.

learning-based approaches, such as k-nearest neighbors (KNN), support vector machine (SVM), and neural network are used to analyze facial beauty and its application [6]. The facial attribute is also analyzed in age and gender recognition. The landmark detection is also used to study a crucial part of the face like eyes, mouth, nose, and edge of the face [7].

Facial attributes like color, shape, texture, size are the most prominent geometrical feature to developed an intelligent system to address the face distinction and assess problems [8]. From a few years ago deep neural networks get more attention, especially convolutional Neural networks (CNN) performing well to solved face detection and recognition problem. The classification of face type by using Inception V3 and machine learning method is also studied [9] and the accuracy is 84.4% .

In this paper, we are using a mobile-net pre-train model to train and classify the face shape on the given dataset. Mobile-net is one of such models, which used CNN, it was already trained to classify 1000 classes using millions of images but it can easily retrain on custom image classification problems according to our required classes. The accuracy of image classification by using CNN is quite helpful to enhance it, without the need to handpick specific features to extract from the images and then use training the model.

## II. RELATED WORKS

In the past various machine learning and deep learning techniques are used to analyze the variety of face shapes but still, it is a challenging topic in a research area. Machine

## III. METHODOLOGY

To experiment, first, we have to preprocess the image to enhance the quality of an image by using a filter, furthermore by using the image processing technique, we

detect the region of interest (ROI). The OpenCV has become with a lot of pre-train classifiers like face, eye, mouth, and nose having their classifier in the form of an XML file. We used the frontal face haar cascade classifier to detect the corner of the faces and make a rectangular box around it. For further processing, we cropped the face inside the box then resize the image 224 x 224 according to the required size of the pre-train model to train.



Fig. I Cropped face image




Fig. II Workflow Diagram

When the model is completely retrained then by using the test dataset train model is tested and the Whole workflow is as shown in Fig. III.

IV. RESULTS AND DISCUSSION

We have a private label dataset consist 400 images. The whole dataset is divided into train and test, with a ratio of 80-20. In this way, we have 320 images in the training set and similarly 80 images in the testing set. The MobileNet architecture is used to retrain the model. We freeze the base layer and retrain the top few layers accordingly.




Fig. III Training Size and Overall Accuracy

The overall accuracy of our model is 85.6%, which shows, the result is kind of good as compare to existing other models and methods. Still, there is a gap to improve its result by increasing the number of the dataset.

The graph shows that still there is a huge gap in overall performance because of the small-scale training dataset. It also depicts that when our training dataset is 250 it accuracy is 70.1% as we increase to 400 images, its accuracy

becomes 85.6%. So the model accuracy can be enhanced by using large training data set.

V. CONCLUSION

In this paper, we have discussed four face shape types and also perform an experiment by using image processing and transfer learning technique (MobileNet) to get output results. Because of the limited size of training data, its overall accuracy is 85.6%. But still, it is a satisfactory result and it will help for future work on a large dataset.

VI. FUTURE WORK

Our future work is to developed face shape type classification by using machine learning technique on the basis of face color, face size, neck size and distance from ear to nose and also make comparison between machine learning and deep learning technique. Secondly we can also developed a food and medicine recommender system for a human on the basis of face type.

ACKNOWLEDGMENTS

This work was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF), supported by the Ministry of Science, ICT & Future Planning (NRF2017R1D1A3B04032905).

REFERENCES

- [1] ZergNet (2017). Find the perfect cut for your face shape. (Accessed 1 January 2018). <http://www.instyle.com/hair/find-perfect-cut-your-face-shape>
- [2] Intelligent Recommendation System for Eyeglass Design [2019].
- [3] <https://towardsdatascience.com/face-recognition-for-beginners-a7a9bd5eb5c2>
- [4] Inception v3 Transfer Learning Image Classification [2018]
- [5] Deep Convolutional Networks VGG16 for Image Recognition in Keras [2020]
- [6] Aarabi et al., 2001, Bottino and Laurentini, 2010, Eisenthal and Dror, 2006, Gray et al., 2010, Mu, 2013, Sutić et al., 2010.
- [7] Extra Facial Landmark Localization via Global Shape Reconstruction
- [8] Slater et al., 2001)69. <https://www.sciencedirect.com/science/article/pii/S0957417417302658>
- [9] Face shape classification using Inception v3 [2019].

# FCM을 이용한 Fuzzy Decision Tree의 소속 함수 개선에 따른 데이터의 재분류

정유정 · 남윤만 · 김광백

신라대학교 컴퓨터소프트웨어공학부

## Dat Reclassification According to Enhanced Tree Membership Function of Fuzzy Decision Tree by Using FCM

Jeong-yu Jeong · Youn-man Nam · Kwang-beak Kim

Division of Computer Software Engineering, Silla University

E-mail : jeong8493@naver.com / kedin13579@naver.com / gbkim@silla.ac.kr

### 요 약

의사결정트리를 비선형 데이터나 비정량적인 데이터에 적용하기 위한 방법으로 퍼지 의사 결정 트리(FDT)가 제안되었다. 그러나 FDT는 의사결정나무와 마찬가지로 노드 분할 시에 하나의 속성을 기준으로 데이터를 분류하는 특징을 가진다. 그러나 여러 속성에 영향을 받는 데이터의 경우에는 데이터 분류를 여러 번 반복해야하는 문제점이 있다. 따라서 본 논문에서는 이러한 문제점을 개선하기 위하여 FDT를 적용하여 노드를 생성한 후, FCM 클러스터링 기법을 적용하여 FDT의 소속 함수를 변경하고 데이터를 재분류 하는 방법을 제안한다. 제안된 방법의 성능을 평가하기 위하여 정확도와 트리의 깊이를 기준으로 기존의 FDT와 제안된 FDT를 비교 분석한 결과, 제안한 방법이 기존의 FDT보다 정확도는 평균적으로 2.98%가 개선되었고, 깊이는 평균적으로 약 2 레벨이 낮아지므로 트리의 분류 성능이 개선된 것을 확인할 수 있었다.

### 키워드

의사결정트리, 퍼지이론, 퍼지의사결정트리, FCM

### 1. 서 론

FDT(Fuzzy Decision Tree)는 의사 결정 트리와 퍼지 이론을 조합하여 두 가지 모두의 이점이 있는 모델이다[1]. 그러나 FDT는 의사 결정 트리 기반의 학습 방법을 사용하기 때문에 일반적인 의사결정트리와 마찬가지로 노드 생성 시 데이터를 한 가지 속성을 기준으로 분류하는 특징을 가진다[2]. 따라서 여러 속성들을 동시에 고려하여 데이터를 분류해야 하는 경우에는 데이터 분류를 여러 번 반복해야 하는 문제점이 있다. 따라서 본 논문에서는 이러한 문제점을 개선하기 위하여 퍼지 클러스터 기법인 Fuzzy C-means(FCM)를 적용하여[3] FDT의 소속 함수를 변경하여 데이터를 재분류 하는 방법을 제안한다.

### II. FCM을 이용한 FDT 노드 재분류

FDT에서 분류 기준 값을 선정하여 초기 소속함수를 생성한다. 그리고 FCM을 적용하여 그림 1과 같이 소속 함수를 변경한 후에 데이터를 재분류 한다. 제안된 재분류 알고리즘은 다음과 같다.

제안된 재분류 알고리즘	
Step 1.	목표 데이터의 클래스 개수와 동일하게 클러스터 개수를 초기화 한다.
Step 2.	내부 측정 항목을 유클리디언 거리로 선정하고 FCM 알고리즘을 적용한다.
Step 3.	FDT 알고리즘을 적용하여 노드의 데이터 분류 속성과 기준 값을 선정한다.
Step 4.	데이터 분류 기준 값을 이용하여 초기 소속 함수를 생성하여 데이터를 분류한다.
Step 5.	분류된 노드의 클래스별 소속도 값의 분산을 계산하여 최대값을 가지는 클래스를 대표 클래스로 선정한다.
Step 6.	Step 1의 중심값 중에서 Step 5의 대표 클래스의 소속도가 가장 높은 중심의 분류 속성 값을 이용하여 그림 1과 같이 소속 함수를 변경한다.
Step 7.	변경된 소속 함수를 이용하여 데이터를 재분류 한다.
Step 8.	노드의 클래스 소속도 합이 임계치보다 큰 클래스의 개수가 2개 이상인 노드가 존재할 경우 4번으로 돌아가 반복한다.




그림 1. 초기 소속 함수와 변경된 소속함수

III. 실험 및 결과 분석

본 논문에서 제안한 FDT의 성능을 평가를 위하여 iris data를 사용하였다.

기존의 FDT와 제안된 FDT의 분류 모델 생성 및 성능 정확도를 측정하기 위하여 전체 데이터의 70%를 트레이닝 데이터, 30%를 테스트 데이터로 사용하였다. 노드생성 중지 기준인 임계치를 0.01%로 설정하였고 기존의 FDT와 제안된 FDT의 분류 모델을 10번씩 실험하였다.

제안한 방법의 성능을 평가하기 위하여 분류 정확도와 트리의 깊이를 기준으로 모델의 성능을 비교 분석하였다. 정확도는 식 (1)과 같이 구하고 결과는 표 1과 표 2와 같이 나타내었다.

$$\text{정확도} = \frac{\text{classdegree}_i + \sum_{\substack{j=0 \\ (j \neq i)}}^n (1 - \text{classdegree}_j)}{2n \times \text{node}_1} \quad (1)$$

식 (1)에서  $i$ 는 대표 클래스 번호이고,  $n$ 은 클래스 개수,  $\text{classdegree}_i$ 는  $i$ 번째 클래스 소속도 합,  $\text{node}_1$ 은 임계치를 넘은 클래스가 1개 이하인 노드의 개수이다.

표 1 정확도와 깊이 평균 비교

	정확도	깊이
기존	52.50%	56.1
제안된	55.49%	53.9

표 2 실험 결과 비교

횟수		정확도	깊이
1	기존	47.97%	67
	제안된	48.64%	51
2	기존	44.92%	48
	제안된	48.66%	33
3	기존	73.22%	42
	제안된	84.97%	34
4	기존	46.62%	71
	제안된	48.59%	59
5	기존	80.51%	51
	제안된	80.05%	84
6	기존	44.67%	48
	제안된	48.16%	62
7	기존	47.85%	68
	제안된	49.11%	76
8	기존	47.87%	58
	제안된	48.79%	59
9	기존	43.76%	59
	제안된	48.75%	28
10	기존	47.68%	49
	제안된	49.15%	53

표 1에서는 기존의 방법보다 제안된 방법의 정확도가 평균적으로 2.98%가 개선되었고, 깊이의 경우에는 평균적으로 약 2 레벨이 더 낮은 것을 확인할 수 있었다. 그러나 표 2에서 6, 7, 8, 10 번의 경우에는 제안된 방법이 정확도는 더 높았지만 기존의 방법이 깊이가 더 낮은 것을 확인할 수 있었고, 5번의 경우에는

기존의 방법이 정확도가 더 높고 깊이 또한 더 낮은 것을 확인할 수 있다. 따라서 제안된 방법이 기존의 FDT 분류 방법보다 정확도는 개선되었지만 트리의 깊이는 기존의 방법과 비교하여 큰 차이가 없는 것을 확인하였다.

IV. 결론

FDT는 의사결정트리모델을 기반으로 하기 때문에 노드 분할 시에 하나의 속성만을 기준으로 데이터를 분류하는 특징을 가지고 있다. 따라서 여러 속성에 영향을 받는 데이터의 경우 분류를 여러 번 반복해야하는 문제점을 개선하기 위하여 본 논문에서는 FDT의 노드가 생성된 이후에 FCM 알고리즘을 적용하여 FDT의 소속 함수를 변경하여 분할된 노드의 데이터들을 재분배 하였다. 기존의 방법과 제안된 방법을 정확도와 트리의 깊이를 기준으로 비교 분석한 결과, 정확도가 평균적으로 2.98%가 개선되었고, 깊이의 경우에는 평균적으로 약 2레벨이 더 낮은 것을 확인할 수 있었다.

향후 연구 과제는 FDT를 적용하여 각 데이터를 분류하여 노드를 생성한 후에 생성된 노드를 재분류하는 과정에서 노드의 깊이를 효과적으로 감소시키는 방법으로 Recurrent SOM 기법을 적용하는 방안에 대해 연구할 것이다.

REFERENCES

[1] E. C. Marcos ,C. M. Maria, A. C. Heloisa, "A Fuzzy Decision Tree Algorithm Based on C4.5," Mathware & Soft Computing Magazine, vol. 20 no. 1, pp. 56-62, Jan. 1977.

[2] Y. C. Wang, B. T. Wang, Z. B. Li, "A survey of fuzzy decision tree classifier," Fuzzy Information and Engineering, vol.1, no. 2, pp. 149-159, May. 2009.

[3] N. Janmenjoy, N. Bighnaraj, H. S. Behera, "Fuzzy C-Means Clustering Algorithm: A Decade Review from 2000 to 2014," Computational Intelligence in Data Mining, vol. 2, pp. 133-149, Dec. 2014.



2021 인공지능 및 응용 워크숍

---

**POSTER**

**인공지능 알고리즘 및 응용**

14:40~15:40

---

# Few-Shot 기반 새로운 영상 분류

신성윤<sup>1\*</sup> · 왕광싱<sup>2</sup>

<sup>1</sup>군산대학교, <sup>2</sup>중국 구강대학교

## New Image Classification Based on Few-Shot Learning

Seong-Yoon Shin<sup>1\*</sup> · Guangxing Wang<sup>2</sup>

<sup>1</sup>Kunsan National University, <sup>2</sup>Jiujiang University in China

E-mail : s3397220@kunsan.ac.kr / wanggxrs@163com

### 요약

본문 논문에서는 소규모 데이터 셋의 이미지 분류 작업에서 모델 과적합 및 비수렴을 해결하고 분류의 정확도를 높이는 데 주로 사용되는 몇 번의 학습을 기반으로 한 새로운 이미지 분류 방법을 제안한다. 이 방법은 모델 구조 최적화를 사용하여 기본 컨볼루션 신경망(CNN) 모델을 확장하고 컨볼루션 레이어를 추가하여 더 많은 이미지 특징을 추출하여 분류 정확도를 향상시킨다. 우리는 모델의 성능을 향상시키기 위해 특정 조치를 통합했다. 먼저 모델의 빠른 수렴을 촉진하기 위해 낮은 학습률 설정 및 셔플링과 같은 일반적인 방법을 사용했다. 둘째, 데이터 확장 기술을 사용하여 작은 데이터 세트를 전처리하여 훈련 데이터 세트의 수를 늘리고 과적합을 억제했다.

### ABSTRACT

In this paper, we propose a new image classification method based on Few-Shot learning, which is mainly used to solve model overfitting and non-convergence and to increase the accuracy of classification in image classification tasks on small datasets. This method uses model structure optimization to extend the basic convolutional neural network (CNN) model and adds convolutional layers to extract more image features to improve classification accuracy. We have incorporated certain measures to improve the performance of our models. First, we used general methods such as low learning rate settings and shuffling to facilitate fast convergence of the model. Second, we used data expansion techniques to preprocess small datasets to increase the number of training datasets and suppress overfitting.

### 키워드

image classification, few-shot learning, convolutional neural network, training dataset

## I. INTRODUCTION

In recent years, deep learning models have been applied to computer vision tasks such as face recognition, object recognition, image classification, semantic segmentation, etc. [1-3]. In addition, several outstanding deep learning models have emerged, such as LeNet, AlexNet, GoogLeNet, Visual Geometry Group (VGG) and ResNet [4-8]. These deep learning models based on convolutional neural network (CNN) models have different characteristics and can achieve satisfactory results for different tasks. Deep learning models can automatically learn features from data, and typically require large amounts of available training data, especially for very high-dimensional input samples such as image and video processing. If the number of samples is small, the deep learning model can extract minimal features, and the expected results generated by the model are not satisfactory.

## II. Few-Shot Learning

In a learning process with only Few-Shot training sessions, different meta-tasks are sampled for each training (episode). Therefore, the overall training includes various combinations of categories. This mechanism allows the model to learn the common parts of various meta-tasks, such as extracting important features and comparing sample similarities, but it removes the relational task-specific parts from the meta-tasks. Models trained using this learning mechanism can classify well even when faced with new, unseen meta-tasks.

## III. PROPOSED METHOD

We mainly reformed and optimized the CNN model structure without significantly increasing the model parameters, including the following aspects:

First, we extracted more data features by adding fewer



extract sample data features from small datasets based on CNNs. Then, we improved the classification accuracy by fine-tuning the fully connected layer and adopting a dropout mechanism to keep the most extensive feature data in the classification function to achieve fast and accurate classification.

#### ACKNOWLEDGEMENT

"This research is partially supported by Institute of Information and Telecommunication Technology of KNU."

#### REFERENCES

- [1] L. Jiao, F. Zhang, F. Liu, S. Yang, L. Li, Z. Feng, and R. Qu, "A survey of deep learning-based object detection," *IEEE Access*, vol. 7, pp. 128837-128868, 2019. DOI: 10.1109/ACCESS.2019.2939201.
- [2] H. Laga, L. V. Jospin, F. Boussaid, and M. Bennamoun, "A survey on deep learning techniques for stereo-based depth estimation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1-27, 2020. DOI: 10.1109/TPAMI.2020.3032602.
- [3] G. X. Wang and S. Y. Shin, "An improved text classification method for sentiment classification," *Journal of Information and Communication Convergence Engineering*, vol. 17, no. 1, pp. 41-48, 2019. DOI: 10.6109/jicce.2019.17.1.41.
- [4] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998. DOI: 10.1109/5.726791.
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications on ACM*, vol. 60, no. 6, pp. 84-90, 2017. DOI: 10.1145/3065386.
- [6] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabino-vich, "Going deeper with convolutions," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, pp. 1-9, 2015.
- [7] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in *Proceedings of International Conference on Learning Representations*, San Diego, CA, USA, 2014. DOI: <http://arxiv.org/abs/1409.1556>.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of Computer Vision & Pattern Recognition 2016*, Las Vegas, NV, USA, pp. 770-778, 2016.

# 결절종 초음파 영상 분석을 위한 개선된 퍼지 스트레칭

박태언 · 송재욱 · 박서형 · 김광백

신라대학교 컴퓨터소프트웨어공학부

## Enhanced Fuzzy Stretching for Ganglion Cyst Analysis of Ultrasound Image

Tae-eun Park · Jae-uk Song · Seo-hyeong Park · Kwang-back Kim

Division of Computer Software Engineering, Silla University

E-mail : ase6733@naver.com / jaeuk139@gmail.com / 1379sh@naver.com / gbkim@silla.ac.kr

### 요 약

본 논문에서는 기존의 퍼지 스트레칭 방법에서 경험적으로  $\alpha_{cut}$ 을 설정하여 상한과 하한을 구하는 문제점을 개선한 퍼지 스트레칭 방법을 제안한다. 기존의 퍼지 스트레칭에서는 스트레칭의 상한과 하한을 구하는  $\alpha_{cut}$ 을 경험적으로 설정하기 때문에 명암 대비가 낮은 영상에서 효과적으로 스트레칭을 할 수 없기 때문에 초음파 의료 영상과 같이 명암 대비가 낮은 영상에서 특징을 추출하는데 효율적이지 못하다. 따라서 제안된 방법에서는 명암 대비가 낮은 영상에서 효율적으로  $\alpha_{cut}$ 을 구하기 위하여 영상 전체의 평균 명암도와 최대 명암도 및 최소 명암도를 이용하여  $\alpha_{cut}$ 을 동적으로 설정하여 하한과 상한을 구하여 영상을 스트레칭 한다.

제안된 퍼지 스트레칭 방법의 성능 분석하기 위하여 결절종 초음파 영상 20개를 대상으로 실험한 결과, 기존의 퍼지 스트레칭 방법보다 제안된 방법이 결절종 특징을 추출하는데 효과적으로 스트레칭된 것을 확인하였다.

### 키워드

퍼지 스트레칭,  $\alpha_{cut}$ , 상한, 하한

### I. 서 론

사람의 눈은 대비에 민감하게 작용하므로 대체적으로 대비가 높은 영상일수록 영상의 품질이 향상되어 보인다. 영상의 품질 향상을 위해 낮은 명암 대비 영상을 높은 명암 대비 영상으로 바꾸는 과정을 영상 대비 향상이라고 하는데, 영상 대비 향상 과정은 영상 처리 분야의 전처리 과정으로서 매우 중요한 역할을 한다[1].

그러나 영상의 품질 향상을 위해 스트레칭 기법을 적용할 수 있지만 의료 초음파 영상과 같이 명암 대비가 낮은 영상에서 특징을 추출하기 위한 전처리 과정에서도 스트레칭 기법이 필요하다. 일반적으로 의료 초음파 영상들은 명암 대비가 매우 낮아서 스트레칭 방법을 적용하지 않을 경우에는 특징들을 추출하는 과정에서 정확성이 낮아진다. 이러한 문제점을 개선하기 위해 퍼지 스트레칭 기법이 제안되었다[2].

기존의 퍼지 스트레칭 기법은 의료 초음파 영상과 같이 특징 영역과 그 외의 영역간의 명암 대비를 뚜렷하게 하는 과정에서 상한과 하한을 구하는  $\alpha_{cut}$ 을 설정하는 것이 중요하다. 기존의 퍼지 스트레칭 기법에서는  $\alpha_{cut}$ 을 경험적으로 설정하기 때문에 효과적으로 명암 대비를 강조할 수 없는 경우가 발생한다.

따라서 이러한 문제점을 개선하기 위하여 본 논문에서는 평균 명암도와 최대 명암도 및 최소 명암도를 이용하여  $\alpha_{cut}$ 을 동적으로 설정하여 하한과 상한을 구하여 개선된 퍼지 스트레칭 방법을 제안한다.

### II. 개선된 퍼지 스트레칭

본 논문에서는 히스토그램의 스트레칭 기준인 하한과 상한을 구하기 위하여 퍼지 이론을 적용한다[3]. 영상의 평균 밝기 값을 식 (1)과 같이 설정한다.

$$X_{ji}^m = \frac{\sum_{j=0}^{H-1} \sum_{i=0}^{W-1} x_{ji}}{W \times H} \quad (1)$$

식 (1)에서  $x_{ji}$ 는 원 영상의 픽셀이고  $W$ 와  $H$ 는 각각 영상의 넓이와 높이이다. 그리고  $X_{ji}^m$ 은 영상의 평균 명암도이다.

$$D_{ji}^{\max} = |X_{ji}^h - X_{ji}^m| \quad D_{ji}^{\min} = |X_{ji}^m - X_{ji}^l| \quad (2)$$

식 (2)에서  $D_{ji}^{\max}$ 는 영상에서 명암도의 최댓값과 평균값의 거리이고,  $D_{ji}^{\min}$ 은 명암도의 최솟값과 평균값의 거리이다. 식 (3)은 퍼지 스트레칭에서 소속 함수의 구간을 설정하는데 적용되는 밝기 조정률은 식 (3)과 같이 구한다.

$$\begin{aligned} \text{if}(X_{ji}^m > 128) \text{adjustment} &= 255 - X_{ji}^m \\ \text{else if}(X_{ji}^m \geq D_{ji}^{\max}) \text{adjustment} &= D_{ji}^{\max} \\ \text{else if}(X_{ji}^m \leq D_{ji}^{\min}) \text{adjustment} &= D_{ji}^{\min} \\ \text{else} \text{adjustment} &= X_{ji}^{\max} \end{aligned} \quad (3)$$

퍼지 스트레칭의 소속 함수의 구간은 밝기 조정률을 이용하여 식 (4)와 같이 계산한다.

$$\begin{aligned} I_{ji}^{\max} &= X_{ji}^m + adjustment \\ I_{ji}^{\min} &= X_{ji}^m - adjustment \\ I_{ji}^{\text{mid}} &= \frac{I_{ji}^{\max} + I_{ji}^{\min}}{2} \end{aligned} \quad (4)$$

식 (4)에서  $I_{ji}^{\max}$ 은 *adjustment*을 적용하여 소속 함수에 적용되는 최대 밝기 값이고,  $I_{ji}^{\min}$ 은 *adjustment*을 적용한 소속 함수의 최소 밝기 값이다. 그리고  $I_{ji}^{\text{mid}}$ 는 소속 함수의 평균 밝기 값이다.

$$\begin{aligned} \text{if}(I_{ji} \leq I_{ji}^{\min} \text{ or } I_{ji} \geq I_{ji}^{\max}) \mu[I_{ji}] &= 0 \\ \text{elseif}(Val > I_{ji}^{\text{mid}}) \\ \mu(Val) &= (I_{ji}^{\max} - Val) / (I_{ji}^{\max} - I_{ji}^{\text{mid}}) \\ \text{elseif}(Val < I_{ji}^{\text{mid}}) \\ \mu(Val) &= (Val - I_{ji}^{\text{mid}}) / (I_{ji}^{\text{mid}} - I_{ji}^{\min}) \\ \text{else } \mu(Val) &= 1 \end{aligned} \quad (5)$$

식 (5)에서  $I_{ji}$ 은 소속 함수의 x축인 명암도 값으로 0부터 255까지의 픽셀 값이다. 식 (4)에서 구한  $I_{ji}^{\min}$ 과  $I_{ji}^{\max}$ 을 이용하여 스트레칭에 필요한 상한과 하한을 구하기 위한 기존 퍼지스트레칭의  $\alpha\_cut$ 은 식 (6)과 같이 설정한다.

$$\begin{aligned} \text{if}(I_{ji}^{\min} = 0) \alpha\_cut &= 0.5 \\ \text{else } \alpha\_cut &= I_{ji}^{\min} / I_{ji}^{\max} \end{aligned} \quad (6)$$

식 (6)을 적용한 기존의 퍼지 스트레칭에서는 하한과 상한을 구한다. 그러나 기존의 퍼지 스트레칭에서는 명암 대비가 낮은 영상에서는 효과적으로 스트레칭 되지 않는 경우가 발생하여 의료 초음파 영상에서 객체를 정확히 추출하는데 비효율적이다. 그 이유는 결절종 초음파 영상에서 결절종 경계 영역이 그 외의 영역과의 명암도 차이가 매우 적어서 단순히 명암도 최댓값과 최솟값과의 관계만으로는 결절종 영역이 뚜렷하게 스트레칭 되지 못한다. 따라서 본 논문에서는 최댓값과 최솟값의 평균과 영상 전체의 평균 정보를 모두 이용하여 명암 대비가 낮은 영상에서도 객체들이 효과적으로 스트레칭 되도록 식 (7)을 적용하여  $\alpha\_cut$ 을 구한다.

$$\alpha\_cut = \left( \frac{\sum_{j=0}^{H-1} \sum_{i=0}^{W-1} x_{ji}}{W \times H} + \frac{x_{ji}^h + x_{ji}^l}{2} \right) / 255 \quad (7)$$

식 (6)에서  $\frac{\sum_{j=0}^{H-1} \sum_{i=0}^{W-1} x_{ji}}{W \times H}$ 은 식(1)에 평균 명암도와 같고,  $\frac{x_{ji}^h + x_{ji}^l}{2}$ 는 영상의 최대 밝기 값과 최소 밝기 값의 평균이다.  $\alpha\_cut$ 은 소속 함수의 픽셀 값들을 255로 나누어 0과 1사이로 정규화 한다.




그림 1. 제안된 방법의 삼각형 소속 함수

그림 1은 제안된 방법의 삼각형 소속 함수를 나타낸 것이며, 소속도가  $\alpha\_cut$  이상인 영상의 픽셀 값 중에서 가장 높은 값을 상한으로 설정하고, 가장 낮은 픽셀 값을 하한으로 설정하여 스트레칭 한다.

### III. 실험 및 결과분석

본 논문에서는 제안된 방법의 성능을 분석하기 위하여 AMD Ryzen 3 3300X 4-Core Processor, 3.79 GHz와 16GB RAM이 장착된 PC에서 Visual Studio 2019 C#으로 제안된 방법을 구현하였다. 그림 2와 같은 결절종 초음파 영상을 각각 기존의 퍼지스트레칭 방법과 제안된 퍼지스트레칭을 적용한 결과는 각각 그림 3과 그림 4와 같다.




그림 2. 결절종 초음파 영상



그림 3. 기존 퍼지 스트레칭을 적용한 영상




그림 4. 제안된 퍼지스트레칭을 적용한 영상

기존의 퍼지 스트레칭 기법과 제안된 방법을 적용하여 결절종 초음파 영상을 스트레칭 한 결과, 기존의 퍼지 스트레칭 기법에서는 그림 3과 같이 결절종 경계 영역이 명확하지 않은 것을 알 수 있으나 그림 4와 같이 제안된 방법을 적용한 경우에는 결절종 영역이 다른 영역에 비해 경계가 명확한 것을 확인할 수 있다. 따라서 제안된 퍼지 스트레칭 방법이 결절종과 같이 명암 대비가 낮은 초음파 영상을 스트레칭 하는 데에 효과적인 것을 알 수 있다.

#### IV. 결 론

본 논문에서는 영상 전체의 평균 명암도와 최대 명암도 및 최소 명암도를 이용하여  $\alpha_{cut}$ 을 동적으로 설정하여 하한과 상한을 구하여 영상을 스트레칭 하는 방법을 제안하였다.

기존의 퍼지 스트레칭에서는 스트레칭의 상한과 하한을 구하는  $\alpha_{cut}$ 을 경험적으로 설정하기 때문에 명암 대비가 낮거나 객체와 그 외의 영역의 명암도 차이가 적은 의료 초음파 영상에서는 효과적으로 스트레칭을 할 수 없는 경우가 발생한다. 그러나 제안된 방법에서는 영상의 평균 명암도와 최댓값과 최솟값의 평균을 이용한  $\alpha_{cut}$ 을 스트레칭의 상한과 하한을 설정하는데 적용하여 객체와 그 외의 영역의 명암도 대비가 낮은 의료 초음파 영상에서 효과적인 것을 실험을 통하여 확인 하였다.

향후 연구 방향은 제안된 퍼지 스트레칭 기법을 결절종 초음파 영상에서 결절종을 추출하고 분석하는데 적용할 것이다.

#### REFERENCES

- [1] T.C. Raja Kumar, S. Arumugaerumal, N. Krishnan, "FUZZY BASED CONTRAST STRETCHING FOR MEDICAL IMAGE ENHANCEMENT," ICTACT JOURNAL ON SOFT COMPUTING, vol.2, no.1, pp. 233-236, July 2011.
- [2] K. B. Kim, "Fuzzy Stretching Method of Color," Journal of The Korea Society of Computer and Information, vol.18, no.5, pp.19-23, May 2013.
- [3] K. B. Kim, Y. J. Kim, "Enhanced Binarization Method using Fuzzy Membership Function," Journal of The Korea Society of Computer and Information, vol.10, no.1, pp.67-72, 2005.

# 스마트 팩토리를 위한 LSTM (Long-Short Term Memory) 기반 재고량 예측 모델링

윤동언<sup>1\*</sup> · 이효상<sup>1\*</sup> · 오암석<sup>2\*\*</sup>

<sup>1</sup>동명대학교, <sup>2</sup>동명대학교

## Inventory Forecasting Modeling Based on LSTM (Long-Short Term Memory) for Smart Factory

Dong-eon Yoon<sup>1\*</sup> · Hyo-sang Lee<sup>1\*</sup> · Am-suk Oh<sup>2\*\*</sup>

<sup>1</sup>Tongmyong University, <sup>2</sup>Tongmyong University

E-mail : ehddjs97@naver.com / asoh@tu.ac.kr

### 요 약

스마트 팩토리는 공급업체와 생산업체 그리고 고객에 이르기까지 거래 관계에 있는 기업들을 연결하는 시스템으로서 효율적 재고관리와 제품의 적시 공급으로 기업 이익을 극대화하고, 광범위한 시장으로 인해 발생하는 복잡한 관리의 문제를 해결해야 한다. 본 논문에서는 공급업체와 생산업체 그리고 고객에 이르기까지 거래 관계에 있는 기업들을 연결하여 효율적 재고관리와 제품의 적시 공급으로 기업 이익을 극대화하고, 광범위한 시장으로 인해 발생하는 복잡한 관리의 문제를 해결하고, 인공지능(AI), 사물인터넷(IoT) 등 4차 산업혁명 기술을 기반으로 생산업체와 공급업체 간의 공급망의 가시성, 안전성, 효율성 향상을 위한 물류 표준을 준수하며 고도화 및 지능화된 스마트 팩토리 솔루션을 제시하고자 한다.

### ABSTRACT

A smart factory is a system that connects companies in business relationships from suppliers to producers and customers. It maximizes corporate profits through efficient inventory management and timely supply of products, and solves complex management problems caused by a wide market. In this paper, we maximize corporate profits through efficient inventory management and timely supply of products by connecting companies in business relationships from suppliers, producers, and customers, and solve complex management problems caused by a wide market. Based on 4th industrial revolution technologies such as artificial intelligence (AI) and Internet of Things (IoT), we provide advanced and intelligent smart factory solutions while complying with logistics standards to improve the visibility, safety, and efficiency of the supply chain between producers and suppliers.

### 키워드

Smart Factory, LSTM, Stock, Inventory Forecasting

### 1. 서 론

최근 제조업체의 생산공정 현황: 현재 제조업체들은 생산공정을 기준으로 직접적 연관된 공급-제조업체들과 수직적 통합을 이루고 있다. 수직적 통합을 통해서 생산자와 공급자, 분배자간 의사결정을 원활히 함에 따라 불필요한 비용을 절감한다.

이와 같은 수직적 통합의 문제점은 제조 공급사슬에 있어서는 다양한 업체와 연계하고 상이한 분류의 업종과의 협력을 통해 제품의 생산이 이루어짐에 따라 효과적인 관리가 어렵다는 문제점이 존재하며 ICT 발전과 함께 기술적 고도화가 진행됨에 따라 전체 생산 공정의 부분적 최적화 형태로 발전하고 부분적인 효율은 증대되었지만 그 복잡성으로 인해 상호연계가 쉽지 않아 프로세스 간 정보 단절이라는 치명적인 문

제점이 발생하는 것이다[1-2].

그리고 제조업의 경우 제품 수요의 변동성에 따라 협력 업체 간의 수요 및 공급과 관련된 정보를 빠르게 파악하여 이에 대한 적절한 대응이 필요하다. 그러나 공급 체인에 속한 각 주체간의 정보 불균형으로 인해 각 단계를 거치면서 과잉 재고가 기하급수적으로 증가하게 되는 이른바 채찍 현상(Bullwhip effect)이 발생한다[3-4]. 예컨대 유통업체에서 주문하게 되면 물류업체, 제조업체, 원재료 공급업체 단계별로 각각의 안전 재고를 확보함으로써 과도한 재고를 보유하게 될 뿐만 아니라 이를 위한 불필요한 시설투자, 인력 고용 등 심각한 자원 낭비가 초래된다 [5]. 따라서 본 논문에서는 이러한 문제점들을 해결하기 위해 인공지능(AI), 사물인터넷(IoT) 등 4차 산업혁명 기술을 기반으로 생산업체와 공급업체 간의 공급망의 가시성, 안전

성, 효율성 향상을 위한 물류 표준을 준수하며 고도화 및 지능화된 스마트 팩토리 솔루션을 제시하고자 한다.

### II. 재고량 예측 모델링

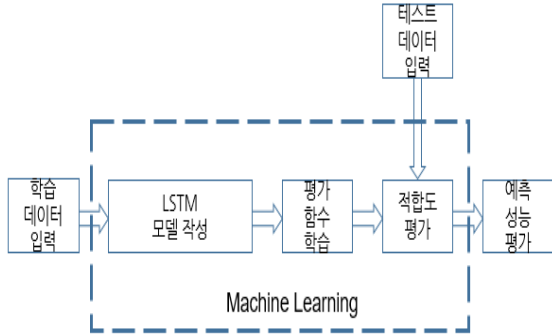


그림 1. 재고량 예측 모델링

그림 1은 재고량 예측 모델링이다. 학습 데이터를 입력받아 LSTM 모델에 보내지고 이 모델을 통해 평가함수 학습이 실행된다. 다시 테스트 데이터를 입력 받은 적합도 평가를 거쳐 예측 성능 평가 결과가 산출된다. 이러한 LSTM 모델부터 적합도 평가가 머신러닝 기술에 의해 실행된다.

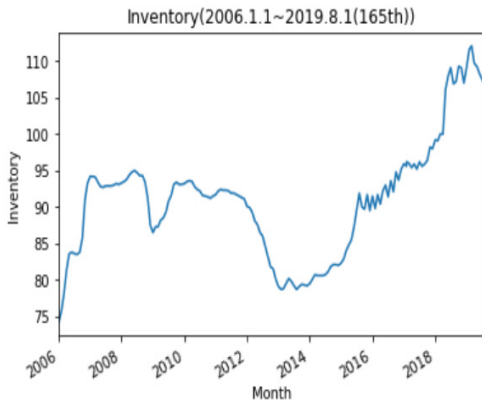


그림 2. 학습 데이터 : 재고량 데이터

그림 2는 그림 1에 의해 산출된 학습 데이터의 재고량 데이터 그래프이다.




그림 3. 학습 데이터 : 테스트 데이터

그림 3은 그림 1에 의해 산출된 학습 데이터의 테스트 데이터 그래프이다.

### III. 결론

본 논문에서는 공급업체와 생산업체 그리고 고객에 이르기까지 거래 관계에 있는 기업들을 연결하여 효율적 재고관리와 제품의 적시 공급으로 기업 이익을 극대화하고, 광범위한 시장으로 인해 발생하는 복잡한 관리의 문제를 해결하고, 인공지능(AI), 사물인터넷(IoT) 등 4차 산업혁명 기술을 기반으로 생산업체와 공급업체 간의 공급망의 가시성, 안전성, 효율성 향상을 위한 물류 표준을 준수하며 고도화 및 지능화된 스마트 팩토리 솔루션을 제시하였다.

향후 기대효과는 다음과 같다.

- ✓ 협력업체 서비스 강화
- 온라인 서비스를 통한 발주/납품 정보 공유
- 예시 및 단종정보 공유로 협력업체 생산계획에 유연성 부여
- 실시간 납입현황 및 미납 사전 확인 가능
- 업체별 실시간 납입실적 확인
- ✓ 구매/물류 업무 생산성 향상
- 실시간 이력관리 및 추적 가능
- 실무자 발주 구매/물류 관리 역량 강화
- 입고 및 마감실적 등의 업무처리 시간(Lead time/Cycle time) 감소
- ✓ 시스템 기반 실시간 모니터링
- 수주에서 납품까지 실시간 진척관리
- 긴급상황에 대한 신속한 의사결정 지원
- 정확한 Data에 근거한 업체평가 및 관리 가능
- ✓ 프로세스 개선으로 경비 절감
- 발주 Type 세분화로 적정재고관리(재고금액 감소)
- 재고 정확성 및 재고관리 신뢰성 확보
- 협력업체 생산/납입 프로세스 개선 효과로 납품 품질향상 및 경비 절감

ACKNOWLEDGEMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학지원 사업의 연구결과로 수행되었음(2018001874004).

REFERENCES

- [1] P. Lou, Q. Liu, Z. Zhou, and H. Wang, "Agile supply chainmanagement over the internet of things," in proceeding of the 2011International Conference on Management and Service Science, Wuhan, pp. 12-14, 2011. DOI: 10.1109/ICMSS.2011.5998314.
- [2] B. D. Mohamed, H. Elkafi, and B. Zied, "Internet of things andsupply chain management: a literature review," In ternational Journal of Production Research, vol. 57, no. 1, pp. 4719-4742, 2017. DOI:10.1080/00207543.2017.1402140.
- [3] A. B. Mohamed, M. Gunasekaran, and M. Mai, "Internet of Things(IoT) and its impact on supply chain: A framework for buildingsmart, secure and efficient systems," Future Generation Computer Systems, vol. 86, pp. 614-628, 2018. DOI: 10.1016/j.future.2018.04.051.
- [4] T. Nguyen, L. Zhou, V. Spiegler, P. Ieromonachou, and Y. Lin, "Bigdata analytics in supply chain management: A state-of-the-artliterature review," Computers & Operations Research, vol. 13, pp.254-264, 2018. DOI: 10.1016/j.cor.2017.07.004.
- [5] M. Roel, and K. Bas, "Mapping smart cities in the EU," EuropeanParliament Directorate-General for Internal Policies, 2014. [Online]Available: <http://www.europarl.europa.eu/studies>.

## 장단기 메모리를 이용한 노인 낙상감지의 정규화에 대한 연구

정승수 · 유윤섭

한경대학교 전기전자제어공학과

## Study of regularization of long short-term memory(LSTM) for fall detection of the elderly

Seung Su Jeong · Yun Seop Yu

Department of Electrical, Electronic, and Control Eng., Hankyong National University

E-mail : su14000@naver.com

## 요 약

본 논문에서는 고령자에게 나타날 수 있는 낙상상황을 감지하기 위해 사용하는 LSTM(long short-term memory)을 적용할 때 정규화에 대한 방법에 대하여 설명한다. 낙상감지는 3축 가속센서를 이용한 데이터를 이용하여 LSTM을 기반한 텐서플로우와 접목시켜 학습하고, 판별한다. 7가지의 행동 패턴(4 가지 일상 생활과 3 가지 낙상에 대하여 학습하며, 학습시 손실함수를 효과적으로 줄이기 위한 정규화 과정을 진행한다. 3축 가속도 센서를 이용하여 구한 SVM(Sum Vector Magnitude)에 대하여 정규화 과정의 최적의 조건을 찾는 방법에 대해서 제시한다.

## ABSTRACT

In this paper, an normalization process of a long short-term memory (LSTM) used for detecting the falls that may occur in the elderly is described. Fall detection uses the data using a 3-axis acceleration sensor to learn and discriminate by using LSTM-based TensorFlow. Learning about 7 behavior patterns (4 types of activity of living and 3 types of fall) and proceeds with the regularization process to effectively reduce the loss function. The optimal normalization process of LSTM using the sum vector magnitude (SVM) obtained using the 3-axis accelerometer is explained.

## 키워드

Tensorflow, Fall detection, The elderly, Long short-term memory(LSTM)

## 1. 서 론

고령화 문제에 따른 노인 낙상문제에 대하여 꾸준히 연구되고 있는 지금, 3축 가속도 센서를 이용하여 낙상 여부를 판단하는 연구가 진행되고 있다[1]. 3축 가속도 센서의 가공하지 않은 데이터들을 Tensorflow를 이용한 LSTM에 학습하여 행동 패턴에 대하여 판별하는 방법이 보고되었다[2].

본 논문은 3축 가속도 센서를 이용하여 측정된 데이터를 SVM(Sum Vector Magnitude)[1]과 같이 파라미터화한 데이터를 LSTM을 이용하여 학습하고 정규화(regularization) 분포에 따른 학습의 정확도 개선 및 차이점에 대하여 기술한다. 이를 통하여 낙상과 일상생활을 판별하는 방법을 기존 방법과 비교한다.

## II. 낙상 감지 시스템


## 1. 데이터의 정규화

3축 가속 센서를 이용하여 x축, y축, z축을 구하여 데이터를 추출한다. 이들 데이터를 이용하여 파라미터

화한 데이터인 SVM을 구하고 손실함수(loss function)를 최소화하기 위한 정규화 과정을 진행한다. 정규화 과정에는 데이터의 최대최소 정규화 과정과 정규화율(regularization rate; 람다)를 이용한 손실함수 L2정규화 과정이 포함되어 있다[3].

데이터의 최대최소 정규화 과정에는 7가지의 행동 패턴(4가지 일상생활: wlaing, lying, running, jumping, 3가지 낙상: fall forward, fall sideways, fall backward) 중 가장 높은 값을 이용하여 데이터의 모든 값을 높은 값으로 나눈 값을 이용한다. 여기서는 정규화를 통한 학습효율의 차이를 보기 위하여 각각 255, 127, 1을 이용하여 데이터를 정규화 시켰다.

그 다음으로는 손실함수에서의 L2정규화를 이용하였다. 손실함수에서 정규화를 하는 과정은 2가지로 분류할 수 있는데, 한 가지는 바이어스를 이용하는 방법이고, 다른 한 가지는 람다를 이용하는 방법이다. 여기서 사용한 방법은 람다의 값을 변화시키는 방법을 사용하였다. 람다의 크기가 커지면 커질수록 모델은 단순해지며 과적합(overfitting)이 감소하게 되고, 반대로 작아지면 모델은 복잡해지고 과적합이 증가하게 된다. 그림 3은 람다의 크기에 따른 모델 가중치의 분포도이다.



(a) 람다가 큰 경우 (b) 람다가 작은 경우  
그림 1. 람다의 크기에 따른 분포도 [4]

데이터의 행동 패턴은 7가지로 나뉘며, 4가지는 일상생활 패턴이고, 나머지 3가지는 낙상시의 패턴이다. 처리된 SVM으로 파라미터화한 데이터를 LSTM에 입력되며 학습된다. 학습 epoch은 대략 3만번을 가지며, validation의 비율은 8:2의 비율을 가진다.

2. 학습 결과

표 1과 그림 2는 낙상 및 일상생활에 대하여 판별 정확도를 나타낸 것이다. 표 1과 그림 2를 람다값을 작게 하는 경우가 크게 하는 경우보다 더 좋은 모습을 보여주었다. 이를 통하여 람다값은 기준값인 0.0015 보다 작을 때 학습의 효율이 올라감을 보인다. 데이터 정규화 부분에서는 대체적으로 비슷한 모습을 보여주었으나, 특히 람다값이 0.00015일 때 데이터를 127로 정규화 했을 때 가장 좋은 모습을 보여주었다. 약간의 편차는 존재하지만 대체적으로 데이터 정규화는 람다값의 변동에 의해 그에 맞는 값이 달라질 수 있는 것으로 보인다. 많은 데이터가 쌓이면 쌓일수록 데이터에 맞는 정규화 분포를 이용한다면 더 좋은 결과를 얻을 수 있을 것으로 예측된다.

표 2. 정규화에 따른 낙상과 일상생활 판별 정확도

Regularization	Accuracy [%]		
	Lambda	AOL	Fall
1	0.00015	90	90
	0.0015	88.2	88.6
	0.015	84.3	78.8
127	0.00015	98.3	95
	0.0015	83.5	87.5
	0.015	86	35
255	0.00015	76	93.75
	0.0015	91.4	93.75
	0.015	87.5	81.25

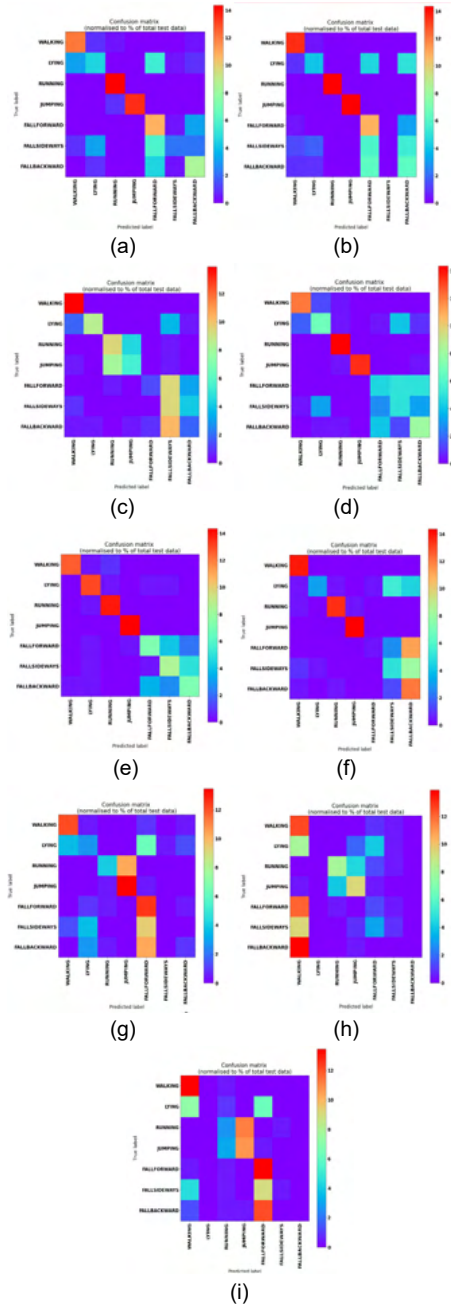


그림 2. 정규화에 따른 패턴 정확도 시각화.  
(a) Norm1 lambda0.0015, (b) Norm127 lambda0.0015, (c) Norm255 lambda0.0015, (d) Norm1 lambda0.00015, (e) Norm127 lambda0.00015, (f) Norm255 lambda0.00015, (g) Norm1 lambda0.015, (h) Norm127 lambda0.015, (i) Norm255 lambda0.015.

III. 결론

고령자의 낙상을 감지하기 위해서 고령자의 몸에 착용한 3축 가속센서 데이터와 가공한 파라미터인 SVM 데이터를 LSTM에 적용했다. 데이터에 대해서는 최대최소 정규화를 사용하였고, 손실함수에 대해서는 L2정규화를 사용하여 이에 따른 기본 학습과 정규화된 학습에 대한 결과를 비교해 보았다. 정규화를 하는

경우가 안하는 경우보다 좋았으며, 이를 통하여 다른 파라미터의 값에 대해 적용한다면 더 나은 결과를 기대할 수 있을 것으로 전망된다.

#### REFERENCES

- [1] D. Lim *et. al.*, “Fall-Detection Algorithm Using 3-Axis Acceleration: Combination with Simple Threshold and Hidden Markov Model,” *Journal of Applied Mathematics*, Vol. 2014, Article ID 896030, 2014.
- [2] E. Torti, *et. al.* “Embedding recurrent neural networks in wearable systems for real-time fall detection.” *Microprocessors and Microsystems*, Vol. 71, pp. 102895, 2019.
- [3] 단순성을 위한 정규화: 람다, Google Developers, 2020 [Internet]. Available: <https://developers.google.com/machine-learning/crash-course/regularization-for-simplicity/lambda?hl=ko>
- [4] LSTMs for Human Activity Recognition, github 2020 [Internet]. Available:<https://github.com/guillaume-chevalier/LSTM-Human-Activity-Recognition>

# 하천 홍수 예측을 위한 LSTM 기반의 수위 예측 시스템 구현

조민우 · 이태준 · 전성우 · 정희경\*

배재대학교

## Implementation of LSTM-based water level prediction system for river flood prediction

Minwoo Cho · Taejun Lee · Sungwoo Jeon · Heokyoung Jung\*

Paichai University

E-mail : kcjmw1208@kakao.com / marlrero@kakao.com / itq0319@naver.com / hkjung@pcu.ac.kr

### 요 약

행정안전부에서 발행한 2019 재해 연보에 따르면 2010년부터 2019년까지의 재해 중 호우, 태풍 등의 홍수를 유발할 수 있는 수해 피해량이 90% 이상이다. 이러한 수해는 홍수를 유발하여 더욱 큰 피해를 초래할 수 있으며, 홍수의 예측을 통한 빠른 대피 결정은 큰 피해를 줄일 수 있다. 이러한 분야에서 시계열 데이터를 활용하여 홍수를 예측하려는 연구들이 많이 진행되고 있다. 본 논문에서는 하천의 수위와 강수량을 사용하여 LSTM 기반의 수위 예측 시스템을 구현한다. 이를 통해 홍수를 예측하여 피해를 줄일 수 있는 초기 연구로써 활용할 수 있을 것으로 사료된다.

### ABSTRACT

According to the 2019 Disaster Annual Report issued by the Ministry of Public Administration and Security, among disasters from 2010 to 2019, water disasters that can cause flooding such as heavy rain and typhoons accounted for more than 90% of damage. These water disasters can cause flooding and cause even greater damage, and a quick evacuation decision based on flood prediction can reduce a lot of damage. In this field, many studies are being conducted to predict floods using time series data. In this paper, we implement an LSTM-based water level prediction system using river water level and precipitation. Through this, it is thought that it can be used as an initial study to reduce damage by predicting floods in advance.

### 키워드

Flood, Flood prediction, Long short-term memory (LSTM), Time series data, Water level prediction

### I. 서 론

2019년 행정안전부에서 발간한 재해 연보 현황을 보면 호우, 태풍 등의 수해로 인한 피해 금액이 95%를 차지하고 있다. 이러한 수해는 침수나 풍랑, 홍수 등을 유발하여 더욱 큰 손해를 끼치기도 한다[1].

이에 따라 정부에서도 기후 변화에 따른 집중호우가 증가하면서 인공지능·강우레이더·위성 등을 활용하여 2025년까지 홍수예보 시스템을 도입할 예정이다 [2]. 본 논문에서는 홍수 예측에 사용할 수 있는 핵심 요소인 수위를 예측하기 위해 시계열 데이터를 기반으로 하는 LSTM 모델 학습을 진행하였다.

로 연구가 활발히 진행되고 있다. 다층 퍼셉트론 기술을 활용하여 홍수를 예측하거나, Bayesian Random Forest 등의 기법을 활용하여 다양하게 연구가 진행되고 있다[3,4,5].

본 논문에서 홍수 예측을 위해 사용된 기법은 시계열 데이터를 처리하는 데 많이 사용되는 LSTM(Long short-term memory)으로, 딥러닝 분야에서 RNN(Recurrent Neural Network) 아키텍처 중 하나이다. RNN은 신호가 한쪽으로 흐르지 않고 순환 구조를 갖는데, LSTM은 RNN의 문제 중 하나인 과거의 값을 오래 기억하지 못하는 단점을 극복하기 위해 고안된 아키텍처이다[6,7].

### II. 본 론

홍수는 세계적으로 피해가 큰 재해이므로 세계적으

#### 2.1 학습 데이터 및 데이터 전처리

학습 데이터는 2016년 홍수 피해량이 가장 많은 울산 지역의 구주교의 수위, 강수량 데이터를 사용하였다. 그림 1, 2는 훈련 데이터로 2015년 1월 1일부터 2020년 12월 31일까지의 수위 및 강수량 데이터이다. 검증 데이터는 2021년 1월 1일부터 2021년 6월 24일

\* corresponding author

까지의 데이터를 사용하였다. 전체 데이터는 물 환경 정보시스템을 참조하였다[8].




그림 1. Water level of Guju Bridge




그림 2. Precipitation of Guju Bridge

강수량의 경우엔 결측값이 존재하여 결측값은 0으로 대체하여 진행하였고, 모델의 성능을 높이기 위해 전체 데이터를 0~1 사이의 값으로 맞춰주는 MinMax-Scaler를 통해 정규화를 진행하였다. 이후 데이터를 6개씩 묶어 5일 치의 데이터를 보고 다음 날의 수위를 예측하도록 구성하였다.

### 2.2 모델 학습 및 검증

Keras의 LSTM 모델을 통해 학습을 진행하였으며 학습에 사용된 데이터는 2016년부터 2020년까지 총 1,783개의 데이터를 사용하였으며, 검증을 위해선 2021년 데이터 171개를 사용하였다. LSTM 모델의 예측을 위한 파라미터 개수는 총 265,730개가 사용되었다. 표 1은 학습한 하드웨어 사양이다.

표 1. System specification

<b>OS</b>	Windows 10
<b>CPU</b>	AMD Ryzen 9 5950X
<b>GPU</b>	Nvidia Geforce RTX 3090
<b>RAM</b>	32GB
<b>Storage</b>	SSD 1TB & HDD 1TB

### 2.3 학습 결과

훈련 반복 횟수(epoch)는 100번 진행했다. 그림 3, 4는 학습과 검증의 정확도와 손실률을 나타낸 그래프이다. 파란 선은 훈련 시 정확도와 손실률을 나타내며, 주황 선은 검증 시 정확도와 손실률을 나타낸다. 훈련 시 최종 정확도는 0.9888, 손실률 0.0039이며, 검증 시 최종 정확도는 0.9880, 손실률 0.203의 결과를 얻었다.




그림 3. Model accuracy graph




그림 4. Model loss graph

## III. 결론

홍수로 인한 피해는 매년 꾸준히 발생하고 있고 이에 따라 본 논문을 통해 홍수 예측을 위한 중요한 요소 중 하나인 수위를 높은 수준의 정확도로 예측할 수 있는 결과를 얻었다. 이 연구를 활용하여 다음에 실제 홍수를 예측하는 데 초기 연구로써 활용할 수 있을 것으로 사료된다. 하지만 데이터의 수가 많지 않았으며, 실제 홍수 예측을 위한 추론 결과를 보이지 못한 부분은 개선해야 할 점으로 보이며, 향후 연구를 통해 이러한 문제를 보완하는 연구가 진행되어야 할 것으로 보인다.

## ACKNOWLEDGEMENT

This study was carried out with the support of 'R&D Program for Forest Science Technology(Project No. 2021340A00-2123-CD01) provided by Korea Forest Service(Korea Forestry Promotion Institute).

## REFERENCES

- [1] Ministry of Public Administration and Security. 2019 Disaster Yearbook [Internet]. Available: [https://www.mois.go.kr/ft/bbs/type001/commonSelectBoardArticle.do?sessionId=9q+z++-8qP6PFH1L9NfdGfxr.node20?bbsId=BBSMSTR\\_00000000014&nttId=81886](https://www.mois.go.kr/ft/bbs/type001/commonSelectBoardArticle.do?sessionId=9q+z++-8qP6PFH1L9NfdGfxr.node20?bbsId=BBSMSTR_00000000014&nttId=81886).
- [2] Ministry of Environment. Promoting flood forecasting using artificial intelligence [Internet]. Available: <http://www.me.go.kr/home/web/board/read.do?boardMasterId=1&boardId=1393640&menuId=286>
- [3] I. R. Widiyari, L. E. Nugroho and Widyawan, "Deep learning multilayer perceptron (MLP) for flood prediction model using wireless sensor network based

- hydrology time series data mining," *2017 International Conference on Innovative and Creative Information Technology (ICITech)*, pp. 1-5, 2017.
- [4] P. Jangyodsuk, D. Seo, R. Elmasri and J. Gao, "Flood Prediction and Mining Influential Spatial Features on Future Flood with Causal Discovery," *2015 IEEE International Conference on Data Mining Workshop (ICDMW)*, pp. 1462-1469, 2015.
- [5] F. C. C. Garcia, A. E. Retamar and J. C. Javier, "A real time urban flood monitoring system for metro Manila," *TENCON 2015 - 2015 IEEE Region 10 Conference*, pp. 1-5, 2015.
- [6] S. Hochreiter, and J. Schmidhuber, "Long short-term memory," *Neural computation*, Vol. 9, No. 8, pp. 1735-1780, Sep. 1997.
- [7] T. Mikolov, M. Karafiát, L. Burget, J. Černocký, and S. Khudanpur, "Recurrent neural network based language model," *Eleventh annual conference of the international speech communication association*, 2010.
- [8] Water environment information system [Internet]. Available: <http://water.nier.go.kr/>

# 개선된 SRCNN과 VDSR

신성윤<sup>1\*</sup> · 왕광싱<sup>2</sup> · 신광성<sup>3</sup>

<sup>1</sup>군산대학교, <sup>2</sup>중국 구강대학교, <sup>3</sup>원광대학교

## Improved SRCNN and VDSR

Seong-Yoon Shin<sup>1\*</sup> · Guangxing Wang<sup>2</sup> · Kwang-Seong Shin<sup>3</sup>

<sup>1</sup>Kunsan National University, <sup>2</sup>Jiujiang University in China, <sup>3</sup>Wonkwang University

E-mail : s3397220@kunsan.ac.kr / wanggxrs@163com / waver0920@wku.ac.kr

### 요 약

본 논문에서는 재구성에 기반을 둔 초 해상도 모델에서 SRCNN과 VDSR에 대하여 전반적으로 살펴보도록 한다. SRCNN과 VDSR모델의 구조와 알고리즘 프로세스를 간단히 알아보고 개선된 성능 평가 함수에서도 다중 채널과 특수한 형태에 대하여 알아보도록 한다. 실험을 통하여 각 알고리즘의 성능을 파악하도록 한다.

### ABSTRACT

In this paper, we will look at SRCNN and VDSR in a super-resolution model based on reconstruction in general. The structure and algorithm process of SRCNN and VDSR models will be briefly studied, and multi-channels and special shapes will be studied in the improved performance evaluation function. Through experiments, the performance of each algorithm should be understood.

### 키워드

SRCNN, VDSR, super-resolution model, multi channel, evaluation function

### I. Introduction

딥러닝 기반의 초 해상도 구현 알고리즘에 관한 연구의 최신 기술 동향을 소개 및 딥러닝 기반의 초 해상도 구현 알고리즘 중 가장 많이 사용하는 네트워크들을 분석하고 딥러닝 기반의 초 해상도 구현 알고리즘의 우수성을 확인하는 연구[1]가 있었다.

RCNN[1], VDSR[2], EDSR[3]은 각각 딥러닝과 잔여 학습방법(residual learning)을 활용하여 더욱 더 놀라운 성능의 향상을 가져왔다. 그리고 residual dense block을 제시한 RDN[4]은 모델의 파라미터 수를 늘려 성능 향상을 초래했다. 또한 적은 파라미터로도 높은 성능을 보여준 RCAN[5], CARN[6]도 제시되었다.

### II. SRCNN

엔드-투-엔드 초해 알고리즘 SRCNN (Super-Resolution Convolutional Neural Network초해 루션 신경망) 알고리즘[2]이다. 이 알고리즘은 이미지 슈퍼 해상도의 연구 CNN(콘볼루션 신경망)을 적용한다.

초기에 입력 전처리로서 입력 저해상도 이미지의 크기를 조정하고 다음 단계는 콘볼루션 네트워크를 통해 흐린 저해상도 영상 입력을 처리하는 것이다. 예를 들어, G가 학습 모델의 목적 함수라면 저해상도 이미지 LI를 입력하고 이 함수를 통해 G(LI)를 처리하여

가능한 한 고해상도 원본 이미지 HOI와 유사한 결과를 얻습니다. 이 프로세스는 다음 세 단계로 구성됩니다. SRCNN 모델의 구조는 그림 1[2]과 같다.

### III. VDSR

VDSR (Very Deep Super-resolution) 모델은 이미지 초 고해상도를위한 대규모 컨볼 루션 신경망이다 [3]. 딥 러닝 기반의 초 고해상도 영상 알고리즘 중 입력 저해상도 영상과 고해상도 출력 영상은 대부분 유사하다. 즉, 저해상도 영상이 전달하는 저주파 정보는 고해상도 영상의 저주파 정보와 유사하다. 이 고주파 정보의 획득은 잔여 학습 모듈의 장점이다[7]. 이 아이디어에 영감을 받아 연구원들은 잔여 네트워크를 이미지 초 고해상도 모델에 통합했다.




Fig. 1 SRCNN Model Structure

실제 실험 결과를 살펴보면 잔여 네트워크 구조의 아이디어가 특히 다음과 같은 딥 러닝 초 해상도 방법에 영향을 미친다고 할 수 있는 초 해상도 문제를 해결하는 데 적합하다는 것을 알 수 있다. VDSR 모델의 구조는 그림 2[3]에 나와 있다.




Fig. 2 VDSR Model Structure

#### IV. Performance Evaluation Function

##### 4.1 피크 신호 대 잡음비

PSNR(Peak Signal-to-Noise Ratio)은 압축되어 재구성된 이미지의 품질을 측정하기 위해 신호의 최대 전력 대 신호의 잡음 전력의 비율이며 일반적으로 데시벨(dB)로 표시된다. PSNR 지수가 높을수록 이미지 품질이 좋아진다. PSNR의 표현은 방정식 (1) 또는 방정식 (2)에 표시된다.

$$PSNR = 10 * \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (1)$$

$$PSNR = 20 * \log_{10} \left( \frac{MAX_I}{\sqrt{MSE}} \right) \quad (2)$$

여기서 MAXI는 이미지 픽셀 값의 최대값을 나타내고, MSE는 현재 이미지 X와 참조 이미지 Y의 평균 제곱 오차(MSE)를 나타내며, H와 W는 각각 이미지의 높이와 너비를 나타낸다. 단일 채널 영상의 MSE 표현은 식 (3.26)에 나타나 있으며, 다중 채널 (C 채널) 영상의 MSE 표현은 식 (3.27)과 같다.

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - Y(i,j))^2 \quad (3)$$

$$MSE = \frac{1}{C \times H \times W} \sum_{k=1}^C \sum_{i=1}^H \sum_{j=1}^W (X(i,j,k) - Y(i,j,k))^2 \quad (4)$$

##### 4.2 구조적 유사성

SSIM(Structural Similarity)은 두 이미지의 유사성을 측정하는 지표이며 값의 범위는 [0,1]이다. SSIM 값이 클수록 이미지 왜곡 정도가 작아져 이미지 품질이 좋아진다.  $\mu_X$ ,  $\mu_Y$ 는 이미지 X와 Y의 평균값을 나타내고  $\sigma_X$ ,  $\sigma_Y$ 는 이미지 X와 Y의 분산을 나타내며  $\sigma_{XY}$ 는 이미지 X와 Y의 공분산을 나타낸다. 계산 공식은 방정식 (5), (6) 및 (7)과 같다.

$$\mu_X = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X(i,j) \quad (5)$$

$$\sigma_X = \left( \frac{1}{H \times W - 1} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - \mu_X)^2 \right)^{\frac{1}{2}} \quad (6)$$

$$\sigma_{XY} = \frac{1}{H \times W - 1} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - \mu_X)(Y(i,j) - \mu_Y) \quad (7)$$

SSIM은 밝기, 대비 및 구조의 세 가지 측면에서 이미지의 유사성을 측정한다. 밝기, 대비 및 구조적 유사성의 표현은 방정식 (8), (9) 및 (10)과 같다.

$$l(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1} \quad (8)$$

$$c(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2} \quad (9)$$

$$s(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3} \quad (10)$$

그중 C1, C2, C3는 상수이다. 0 분모를 피하려면 일반적으로  $C1=(K1*L)^2$ ,  $C2=(K2*L)^2$ ,  $C3=C2/2$ 를 취한다. 일반적으로  $K1=0.01$ ,  $K2=0.03$ ,  $L=255$ 이다. 그러면 SSIM의 표현은 식 (11)과 같다.

$$SSIM(X, Y) = l(X, Y) * c(X, Y) * s(X, Y) \quad (11)$$

SSIM의 값 범위는 [0,1]이다. SSIM 값이 클수록 이미지 왜곡이 작아지고 이미지 X가 참조 이미지에 더 가깝다. SSIM의 특수한 개선된 형태는 방정식 (12)에 나와 있다.

$$SSIM(X, Y) = \frac{(2\mu_X\mu_Y + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)} \quad (12)$$

#### IV. Experimental Result

데이터 세트의 이미지 세부 정보는 표 1에 나타나 있다.

이 실험에서는 SRCNN 및 VDSR 모델의 결과와 피크 신호 대 잡음비 및 이미지 구조 유사도를 비교하는 실험을 수행했다. 비교 실험이 수행되었으며 실험 결과는 표 2에 나와 있다. 표에서는 서로 다른 초 해상도 방법으로 얻은 개선된 평균 PSNR 및 SSIM 값이 데이터 세트 Set5, Set14, BSD100 및 Urban100에서 x4의 배율을 갖는 것으로 표시된다.

그림 3은 서로 다른 초 해상도 모델의 세 가지 이미지에서 얻은 SR 이미지의 실험 결과를 비교 한 것으로 서로 다른 SR 이미지의 PSNR 및 SSIM 평가 지표를 계산하여 나타낸다.

Table 1. Details of experimental data set of image super-resolution

Dataset	Amount	Avg. Resolution	Avg. Pixels	Format	Category Keywords
Set5	5	313*336	113,491	BMP	Baby, Bird, Butterfly, Head, Woman
Set14	14	492*446	230,203	BMP	Humans, Animals, Insects, Flowers, etc.
BSD100	100	435*367	154,401	JPG	Animal, Building, Food, Landscape, etc.
Urban100	100	984*797	774,314	JPG	Architecture, City, Structure, Urban, etc.

Table 2. Results of PSNR and SSIM values with different models

Method	Training Dataset	Set5	Set14	BSD100	Urban100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
SRCNN	291	30.48/0.8628	27.50/0.7513	26.90/0.7101	24.52/0.7221
VDSR	291	25.64/0.8830	28.01/0.7674	27.29/0.7251	25.18/0.7524




Fig. 3 Super-resolution results of "148026"(scale factor x4)

### V. CONCLUSION

본 논문에서는 SRCNN과 VDSR모델의 구조 및 알고리즘 프로세스를 간략하게 알아보았고 개선된 성능 평가 함수에서도 다중 채널과 특수한 형태에 대해서도 살펴보았다. 또한, 실험을 통하여 각 알고리즘의 성능과 우수성도 알아보았다.

### ACKNOWLEDGEMENT

"This research is partially supported by Institute of Information and Telecommunication Technology of KNU."

### REFERENCES

[1] Y. L. Seo, S. J. Kang, "Current status and latest trend of deep learning-based super resolution technology," Broadcasting and Media Magazine, Vol. 25, No. 2, pp.7-16, Apr. 2020.

[2] Dong, C., Loy, C. C., He, K., & Tang, X., "Learning a deep convolutional network for image super-resolution," In Proceedings of the European conference on computer vision, Glasgow, United Kingdom, pp. 184-199, Springer, Cham, Sep. 2014.

[3] Kim, J., Kwon Lee, J., & Mu Lee, K., "Accurate image super-resolution using very deep convolutional networks," In Proceedings of the IEEE conference on computer vision and pattern recognition, Las Vegas, NV, USA, pp. 1646-1654, 2016.

[4] Zhang, Y., Tian, Y., Kong, Y., Zhong, B., & Fu, Y., "Residual dense network for image super-resolution." In Proceedings of the IEEE conference on computer vision and pattern recognition, Salt Lake City, UT, USA, pp. 2472-2481, 2018.

[5] Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., & Fu, Y., "Image super-resolution using very deep residual channel attention networks." In Proceedings of the European Conference on Computer Vision(ECCV), Munich, Germany, pp. 286-301, 2018.

[6] Ahn N., Kang B., Sohn KA., "Fast, Accurate, and Lightweight Super-Resolution with Cascading Residual Network" In Proceedings of the European Conference on Computer Vision(ECCV), Munich, Germany, pp. 256-272, 2018.

[7] Vint, D., Di Caterina, G., Soraghan, J. J., Lamb, R. A., & Humphreys, D., "Evaluation of performance of VDSR super resolution on real and synthetic images," In 2019 Sensor Signal Processing for Defence Conference(SSPD), Brighton, United Kingdom, pp. 1-5, IEEE, 2019. May.

# 생산 효율을 높이기 위한 인공지능 적용 아쿠아포닉스 시스템 설계

이현섭 · 우영운 · 김진덕\*  
동의대학교

## Application of artificial intelligence to increase production efficiency Aquaponics system design

Hyoun-Sup Lee · YoungWon Woo · JinDeog Kim\*  
Donggeui University

E-mail : lhskmj@deu.ac.kr / ywwoo@deu.ac.kr / jdk@deu.ac.kr

### 요 약

최근 환경 문제에 관한 관심이 높아지면서 친환경 식자재 시장의 성장이 커지고 있다. 이를 위해 다양한 재배 기법들이 등장하고 있으며 아쿠아포닉스 또한 그중 하나로 볼 수 있다. 아쿠아포닉스 시스템은 민물고기 양식을 통해 발생하는 무기물이 녹아든 물을 통해 작물을 재배하는 방식으로 생산품의 질이 매우 우수하며 친환경 농법을 소비자에게도 안전하고 농약 및 화학비료를 사용하지 않기 때문에 자연환경 보존에도 큰 장점이 있다.

본 논문에서는 이러한 아쿠아포닉스 시스템의 생산성을 높이고 효율적으로 관리하기 위해 성장 작물의 상태와 양식 환경에서 발생하는 여러 가지 센서 데이터를 시계열 분석하고 학습하여 최적의 환경을 설정할 수 있는 인공지능 기반의 아쿠아포닉스 시스템의 설계에 대하여 제안한다.

### ABSTRACT

Recently, as interest in environmental issues increases, the growth of the eco-friendly food material market is growing. For this purpose, various cultivation techniques are emerging, and aquaponics can be seen as one of them. Aquaponics system is a method of cultivating crops using water dissolved in minerals generated through freshwater fish farming. The quality of the product is very good, and the eco-friendly farming method is safe for consumers and does not use pesticides and chemical fertilizers that can cause a big plus with Eco-preservation.

In this paper, we propose the design of an artificial intelligence-based aquaponics system that enables us to analysis by time-series and learn various sensor data arising from the state and aquaponics environment of growth crops to establish an optimal environment.

### 키워드

아쿠아포닉스, 수경재배, Multi level Site, AI

### I. 서 론

최근 환경 문제에 소비자들의 민감성이 크게 작용하여 친환경 식자재에 관한 관심이 커지고 있다. 일반 재배를 통해 생산되는 식자재의 경우 각종 농약 및 화학비료를 사용하기 때문에 소비자의 건강뿐만 아니라 자연환경에 부정적인 영향을 미치게 된다.

아쿠아포닉스는 물고기 양식과 친환경 수경재배를 동시에 할 수 있는 시스템으로 친환경 농법에 가까운 생산 시스템이다[1][2].

본 논문에서는 아쿠아포닉스 시스템의 특징을 반영한 시스템에 대하여 제안한다.

제안하는 시스템은 단순 아쿠아포닉스를 구축하는

것을 넘어서서 시스템에서 발생하는 raw 센서 자료를 수집하고 재배 환경별로 인공지능 학습을 수행한 뒤 이를 토대로 최적의 생육환경도출과 정량생산 예측을 수행할 수 있는 시스템을 의미한다.

### II. 아쿠아포닉스 시스템의 특징

표 1은 아쿠아포닉스 시스템의 특징에 대하여 설명한다.

\* corresponding author

표 1. 아쿠아포닉스 시스템의 특징

구분	장점	단점
친환경	<ul style="list-style-type: none"> <li>-순환 시스템에 의한 물 사용 최소화</li> <li>-공간 절약형 제작 가능</li> <li>-양식 어류용 사료만 투입하므로 화학비료를 사용하지 않으며, 토양 및 수질의 오염을 발생시키지 않음</li> <li>-해충, 잡초 없음</li> </ul>	
경제성	<ul style="list-style-type: none"> <li>-인력 투입 최소화 가능</li> <li>-투입 인력에 대한 작업 강도 낮음</li> <li>-높은 생산성</li> <li>-부가가치 증대</li> <li>-재배 식물과 양식 어류의 동시 판매</li> <li>-도심, 빌딩, 아파트 단지, 도심외곽, 섬, 농어촌, 폐교, 빌딩 등 설치 위치에 대한 제약 없음</li> </ul>	<ul style="list-style-type: none"> <li>-국내의 경우, 일반적인 양식이나 식물재배보다 축적된 정보와 경험 데이터 부족하여 초기 실패 가능성 높음</li> <li>-초기 셋업 비용 높음</li> <li>-시스템 구성이 일반적인 양식이나 식물재배 등이 시스템보다 복잡함</li> </ul>

친환경 영역에 있어서 매우 큰 장점이 있는 반면에 경제적인 측면에서 인력 최소화, 설치 제약 부분에 대한 장점과 기존 재배시스템에 비해 높은 비용 및 기술력이 필요한 단점을 가진다.

현재의 많은 연구가 아쿠아포닉스의 환경 구축에 초점이 맞추어져 있으며-아쿠아포닉스의 국내 도입가능성에 관한 연구[3], RAS기반의 현대 아쿠아포닉스 연구[4][5][6]등에서는 재배 환경 검증에 초점이 맞추어져 있다.

또한, 앞선 선행 연구에서는 생산성에 대한 의구심을 지적하고 있으며 이를 해결하지 않으면 상업적 도입의 성공이 어려울 것으로 예측한다.

본 논문에서는 이러한 문제를 해결하기 위해 아쿠아포닉스 시스템에서 발생하는 여러 가지 의미 있는 센서 데이터와 생육데이터를 기반으로 인공지능 학습을 통해 더욱 우수한 생산성을 가질 수 있는 아쿠아포닉스 시스템의 구축에 대하여 제안한다.

III. 시스템 설계

그림 1은 본 논문에서 제안하는 지능형 아쿠아포닉스 생산관리 시스템의 구조이다.




그림 1. 지능형 아쿠아포닉스 시스템

주요 요소 개발 대상은 IoT 기반의 아쿠아포닉스 시스템 site와 각 site의 아쿠아포닉스 시스템을 연동할 수 있는 네트워크 구조, raw 데이터 수집 및 연산 처리를 위한 클라우드 기반의 Pass, 머신러닝 기반 도입 데이터 분석 및 최적화 조건 도출을 위한 데이터 서버 및 사용자 인터페이스로 구성된다.

표 2. 인공지능 기반 최적 생육 환경 추출

구분	컴퓨터 비전 방식		인공지능 방식
	색상 정보 활용	부피 정보 활용	
생육 정도 판단 기준	생육 면적	생육 부피	생육 형태
판별 적용 특징	색상 정보	깊이 정보	형태 정보
사용 알고리즘	색상 필터링	3D 재구성 및 부피 추정	영상 유사도 (Isomap, LLE, CNN 등)
알고리즘 복잡도	낮음	중간	높음
사용 카메라	RGB 카메라	깊이 카메라	RGB 카메라
학습 데이터 요구량	적음	적음	많음
다양한 작물에 대한 적용성	높음	높음	낮음(대상 작물에 따라 변동)
재배 환경 의존성	높음	높음	낮음

전체 시스템 중에서 현재 논문에서 다루고 있는 부분은 인공지능 부분과 클라우드 영역으로 재배하는 식물의 정보를 비전 측정 시스템을 통해 촬영하고 이 정보와 함께 재배과정에서 수집된 온도, 무기질양, pH 농도, 온도, 습도 등의 센서 정보를 클라우드에 제공한다.

클라우드에 제공된 정보를 가공 전처리하여 머신러닝 모듈에 학습 수행하고 이를 토대로 작물의 형태적 특성과 환경 정보 기반의 인공지능 기법을 적용하여 다양한 작물에 대한 적용성과 재배 환경에 대한 의존성, 시스템 구축 비용 등을 고려하여 최적의 판별 기법을 통해 표 2와 같은 최적 생육 환경을 추출한다.

이를 통해 그림 2와 같이 다양한 타입의 아쿠아포닉스 시스템을 구축할 수 있을 것으로 사료된다.




그림 2. 다양한 조건 기반의 아쿠아포닉스 시스템

V. 결 론

본 논문에서는 아쿠아포닉스 시스템을 단독으로 활용하여 생산하는 시스템이 아닌 발생하는 데이터를 기반으로 최적의 아쿠아포닉스 환경을 구축할 수 있는 IOT 융합 아쿠아포닉스 전용 운용 기술에 대하여 제안하였다.

제안된 기술을 활용할 경우 신규 아쿠아포닉스 시스템을 구축하려고 하는 site에서 제안된 플랫폼 내에서 작물과 어류의 새로운 조합을 통한 수요자 맞춤 데이터를 활용할 수 있을 것으로 판단되며 확장될 경우 site의 데이터에 따라 분석 및 서비스 가능한 플랫폼 확보와 빅데이터를 통한 추가 및 확장 학습으로 최적 생육 환경 알고리즘의 정확도가 높아질 것으로 판단된다.

또한, 다중 데이터 분석을 통한 재배작물에 대한 생산량 예측 알고리즘을 확보할 수 있으며 다양한 재배작물의 생산 및 관리가 필요한 분야에서 활용이 가능할 것으로 예측된다.

이로 인해 소비자는 환경오염 및 기후변화와 상관 없는 양질의 채소를 소비할 수 있을 것이며 국내외적으로 환경과 기후변화 등에 따라 안정적인 식품공급이 어려운 상황을 해결할 수 있는 시스템으로 거듭날 수 있을 것으로 판단된다.

현재 국내 3개의 지역에 건물 타입, 하우스 타입, 온실 타입의 아쿠아포닉스를 구축할 예정이며 본 시스템이 적용된 아쿠아포닉스 시스템을 구축하여 raw 데이터수집 및 분석을 통해 제안된 내용을 검증할 예정이다.

REFERENCES

- [1] FAO(2014), Fisheries and aquaculture technical paper, Small-scale aquaponic food production
- [2] Banas, D, Masson, G, Leglize, L, Usseglio - Polatera, P. & Boyd, C. E.(2008). Assessment of sediment concentration and nutrient loads in effluents drained from extensively managed fish ponds in France, Environmental Pollution 152(3), 679-685.
- [3] Gonnella, M. Serio, F. Conversa, G. & Santamaria, P.(2004). Production and nitrate content in lamb's lettuce grown in floating system, Acta Horticulture (ISHS) 644, 61-68.
- [4] Leonard, N. Blancheton, J. P. & Guiraud, J.P.(2000). Populations of heterotrophic bacteria in an experimental recirculating aquaculture system. Aquacult. Eng. 22.
- [5] Martins, C. I. M. Eding, E. H. Schneider, O. Rasmussen, R. Olesen, B. Plesner, L. & Verreth, J. A. J. (2005). Recirculation aquaculture systems in Europe, Consensus. Oostende, Belgium, Consensus Working Group. Eur. Aquacult. Soc, 31.
- [6] Michaud, L. Lo Giudice, A. Troussellier, M. Smedile, F. Bruni, V. & Blancheton, J. P.(2009). Phylogenetic characterization of the heterotrophic bacterial communities inhabiting a marine recirculating aquaculture system, J. Appl. Microbiol. 107, 1935-1946.

※ 저작권법에 의해 무단전재와 무단복제를 금합니다.  
※ 본 권의 모든 저작권은 한국정보통신학회에 있습니다.

·이 발표논문집은 2021년도 신라대학교 LINC+사업단 인공지능창의융합인재양성전공의 지원을 받아 발간되었음.

### 한국정보통신학회 인공지능 및 응용 워크숍

---

서 기 2021년 7월 22일 발행

발행처 : 사단  
법인 한국정보통신학회

부산광역시 부산진구 서면문화로 27, 1802호 (부전동, 유원오피스텔)

전 화 : 051)463-3683

팩 스 : 051)464-3683

홈페이지 : <http://www.kiice.org> Email : [kiice@kiice.org](mailto:kiice@kiice.org)

조판·인쇄소 : **한림원(주)** TEL : (02) 2273-4201 <http://www.hanrimwon.com>

---