

# 저성능 CCTV 인식 능력 향상 기법

2018. 11

중부대학교 정보보호학과

김인호

개요

몇 년 전부터, 머신러닝 (machine learning)이 일반인들에게 알려지기 시작하더니 2016 년 3 월 딥러닝(deep learning) 알고리즘을 이용한 구글의 딥마인드라는 딥러닝 전문 회사가 만든 인공지능 바둑 프로그램 알파고(AlphaGo) 가 바둑 천재 이세돌 9 단과의 대결에 승리하면서 다양한 분야에서 인공지능과 딥러닝에 대한 관심이 높아졌다.

딥러닝이란 사실 새로운 개념이 아닌, 1980 년대 등장한 인공신경망(ANN : Artificial Neural Networks)에 기반하여 설계된 개념으로 인간의 뇌가 학습 처리하는 과정을 모방한 머신러닝 (machine learning) 방법 중 하나이다.

세계적인 자문기관인 가트너가 발표한 2017 년 신기술 하이프 사이클 보고서에 따르면 3 가지의 신기술 메가 트렌드에 중점을 두고 있다. 3 가지의 메가 트렌드(machine learning)에는 어디에서나 인공지능(AI Everywhere), 순수하게 몰입하는 경험(Transparently Immersive Experiences), 디지털 플랫폼 (Digital Platforms) 이 선정되었으며, 이는 미래의 비즈니스 영향을 이해하기 위해서 기업 들은 이러한 3 가지 트렌드에 대하여 탐구하고 동향에 대해 전반적으로 관점을 두어야 한다고 전달해주고 있다.

가트너는 인공지능(AI) 기술에 대하여 연산능력, 무한에 가까운 데이터량, 심층 신경 네트워크 (DNN) 의 엄청난 진보로 인해 향후 10 년 간 가장 파괴적인 기술이 될 것이라고 내다보았다. 또한 기업들에게는 딥러닝, 머신러닝, 심층 강화 학습, 일반 인공지능, 자율 주행차 등과 같은 기술 들을 권장하였다 이처럼 인공지능에 대해 학계와 산업계를 비롯하여 전 사회적 관심이 집중되고 있다는 것을 알 수 있다

최근 국내외 수사기관에서 CCTV 는 활용성과 객관성이 높다고 판단되어 최근 정부에서 저화질 CCTV 를 고화질로 교체하거나 고화질 CCTV 를 새로 증설하고 있다. 또한 사설 업체 뿐만 아니라 일반 가정집에서도 CCTV 를 설치하는 가정이 늘어나고 있다. 하지만, 가정에 설치되는 대부분의 저화질 CCTV 는 물체인식이 어려울 뿐만 아니라 범위에 노출 된 경우 범죄자의 얼굴을 인식하는데도 크나큰 어려움이 있다.

그러나 기존에 설치한 품질이 낮은 CCTV 를 모두 고품질의 CCTV 로 교체하기에는 많은 비용이 필요하다. 이 비용을 감수하고 저품질의 CCTV 를 모두 고품질의 CCTV 로 교체한다 하더라도, 저품질의 CCTV 에서 촬영한 데이터는 화질이 낮아 활용되지 않을 가능성이 높다.

이러한 문제를 해결하기 위하여 이 논문에서는 SRRDN (Super Resolution Residual Dense Network)을 이용하여 영상의 품질을 개선하는 방법을 진행하였다. 실험에는 총 N 종류의 CCTV 데이터를 사용하였으며, 각 영상에서 N 개의 이미지를 샘플링하여 머신러닝에 사용하였다. SRRDNN 의 학습과정에서 역전파를 통하여 SRGNN 망의 최적의 수치를 찾아 영상 품질 개선 모델을 구축하였다. 실험을 통하여 960x540 크기의 CCTV 영상을 1920x1080 크기의 화질로 개선하는 것이 가능함을 보였다.

## 1. 배경

2014 년 1 월 구글은 영국의 작은 스타트업 기업, '딥마인드 테크놀로지(DeepMind technologies)' 를 인수한다고 발표했다. 딥마인드는 강화학습(RL : Reinforcement Learning) 분야에서 최고의 전문성을 보유한 회사로써 2016 년 3 월 구글의 인공지능과 인간 대표 이세돌 9 단과의 바둑 대결에서 승리한 바둑 인공지능 알파고(AlphaGo) 를 개발한 회사이다.

딥마인드는 2011 년에 데미스 하사비스(Demis Hassabis) 와 그가 런던대학에서 만난 셰인 레그(Shane Legg), 그리고 사업가인 무스타파 술레이만(Mustafa Shuley-man) 과 함께 공동 설립한 회사로 구체적인 사업 모델 없이 단지 12 명의 딥러닝 전문가로 구성되어 있었다. 참고로 데미스 하사비스는 1976 년생으로, 13 세에 세계 유소년 체스 대회에서 2 위를 하였고, 15 세 때 고교과정을 마치고 케임브리지대 컴퓨터공학 학부/석사 통합과정으로 졸업, 런던대학(UCL : University College London) 에서 인지신경과학 박사 학위를 받고서 이듬해인 2011 년 딥마인드를 설립했다.

구글이 딥마인드를 인수할 당시 실리콘밸리에서는 인공지능과 관련해서 이미 많은 투자가 진행되고 있는 상황이었다. 구글과 페이스북은 이미 딥러닝 분야의 세계적인 전문가들을 영입하였고, 마이크로소프트는 중국 베이징에 인공지능 연구소를 운영 중이었다. 중국의 바이두(Baidu)도 딥러닝 분야에서 세계적으로 권위자인 스탠포드 대학교의 앤드류 응(Andrew Ng) 교수를 영입하였다.

세계적인 기업들이 이처럼 인공지능 분야에 집중하고 있는 이유가 있다. 바로 4 차 산업혁명 때문이다. 4 차 산업혁명이라는 말은 2016 년 세계경제포럼(WEF : World Economic Forum) 에서 클라우스 슈바프(Klaus Schwab) WEF 회장이 언급하면서 화제가 되었다.

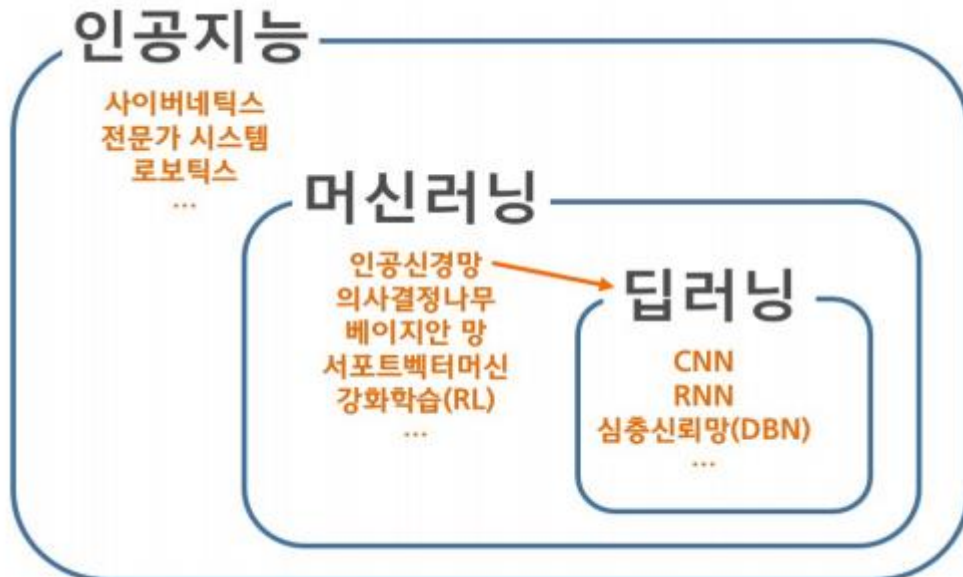
1784 년 영국에서 시작된 증기기관과 기계화 혁명인 1 차 산업혁명, 1870 년 전기를 이용한 대량생산이 본격화된 2 차 산업혁명, 1969 년 인터넷기반 컴퓨터 정보화 및 자동화 시스템이 대표되는 3 차 산업혁명에 이어, 인공지능 (AI : Artificial Intelligence) 로봇을 통해 사물을 자동적 지능적으

로 제어할 수 있는 가상물리시스템이 기대되는 산업혁명이 바로 4 차 산업혁명이다. 현재 구글이 사물 인터넷(IoT : Internet of Things) 과 인공지능을 접목시켜 추진 중인 자율주행차 및 로봇 사업이 이에 속한다고 할 수 있다. 마치 먼 미래의 일처럼 느껴졌지만 인공지능을 필두로 한 4 차 산업혁명이 우리 앞에 성큼 와 있다.

본 1 장에서는 이러한 차 산업혁명에서 기대되는 인공지능 분야를 선두하고 있는 딥러닝의 역사적 배경 딥러닝의 개념 및 원리에 대해 소개하고자 한다

## 1.1 딥러닝과 인공지능, 머신러닝의 관계

딥러닝의 역사적 배경에 대하여 설명하기에 앞서 딥러닝하면 항상 같이 언급되는 인공지능(Artificial Intelligence), 머신러닝(machine learning) 과는 어떤 상관관계가 있는지 짚고 넘어가도록 하자. 딥러닝과 머신러닝은 같은 기술인지 혹은 인공지능에 속하는 것인지, 전혀 다른 또 다른 기술인지 이해하기 쉽게 (그림 1) 에 서로의 관계에 대해 표현하였다.



(그림 1) 인공지능과 머신러닝, 딥러닝의 관계


인공지능은 머신러닝을 포괄하고 있는 상위 개념이며, 머신러닝 이외에도 사이버네틱스, 언어학, 검색 등 다양한 분야가 포함된 커다란 집합이다. 그리고 딥러닝은 머신러닝의 알고리즘중 인공신경망(Artificial neural network)이라는 알고리즘을 이용한 머신러닝의 한 분야로 볼 수 있다. 즉, 딥러닝 관련된 뉴스를 접하게 된다면 인공지능 및 머신러닝에 대해서 이야기하고 있다고 생각하는 것이 맞지만, 반대로 머신러닝 관련된 뉴스를 접할 땐 반드시 딥러닝에 대해서 이야기하고 있다고 할 수 없다.

## 1.2 신경망과 딥러닝의 역사

1943 년 미국의 신경외과 의사인 워렌 맥컬록(Warren McCulloch)과 논리학자인 월터 피츠(Walter Pitts)의 연구[1]에서 인공신경망이 시작된다. 그들은 전기 스위치처럼 온(on), 오프(off) 하는 기본적인 기능이 있는 인공 신경을 그물망 형태로 연결하면 사람의 뇌에서 동작하는 아주 간단한 기능과 비슷하게 동작할 수 있다는 것을 이론적으로 증명했다. 이 연구는 신경망 기반의 인공지능 연구에 서막을 올리는 계기가 되었다.

한편 캐나다의 심리학자인 도널드 올딩 헵(Donald Olding Hebb)은 1949 년 저서인 『The Organization of Behavior』[2] 에서 생물학적 신경망 내에 반복적인 시그널이 발생할 때 뉴런들은 그 시그널을 기억하는 일종의 학습효과가 있음을 발표했다. 또한 인공신경망을 학습하기 위해 헤비안 학습(Hebbian learning) 을 제안한다. 이것은 쉽게 말하면 뉴런의 학습효과처럼 인공신경망에서는 가중치(weight factor) 라는 것을 주어 같이 행동하는 뉴런들을 더 단단히 연결하라는 학습 원리이다.

이후 1958 년 코넬 대학교의 심리학자인 프랭크 로센블라트(Frank Rosenblatt) 는헵의 가중치 개념을 적용하여 단층 신경망인 퍼셉트론(Perceptrons)이론[3]을 발표한다 퍼셉트론은 (그림 2)와 같이 인간의 뉴런을 수학적으로 모방한 계산 알고리즘으로 인공신경망(ANN : Artificial Neural Networks) 과 딥러닝(Deep learning) 의 근간이 된다. 그는 퍼셉트론 이론을 물리적인 기구에 구현하여 이미지 인식을 수행해낸다. 이는 인공신경망을 실제로 구현한 최초의 모델이다. 이때부터 학계에서는 신경망으로 곧 사람 수준의 인공지능을 만들 수 있을 것이라는 가능성이 기대되면서 더욱 주목받았다.



(그림 2) 사람의 뇌~신경계와 퍼셉트론 이론

1969 년 MIT 의 마빈 민스키 교수(Marvin Minsky)와 그의 동료 세이무어 페퍼트(Seymour Papert) 는 저서를 통해 로센블라트의 퍼셉트론은 XOR 문제를 풀 수 없음을 증명[4]한다 이들의 발표는

신경망의 능력을 불신하게 되었고 학계의 인공지능의 가능성에 대해 뜨거웠던 분위기를 일순간 얼어붙게 만들었다.

이처럼 60년대 말부터 70년대까지 이어진 인공지능의 침체기 속에 1974년 하버드 대학교 박사과정이었던 폴 워보스(Paul Werbos)는 최초로 다층 신경망의 학습 알고리즘으로 역전파 이론을 적용할 수 있음을 박사논문[5]으로 증명한다. 하지만 그 당시 인공지능에 대한 학계의 냉랭한 분위기 때문에 자신의 연구 결과를 발표하지 못하고 8년 후에서야 학술지에 공개된다.

이 연구는 1985년 거의 같은 시기에 데이비드 파커(David B. Parker)[6]와 프랑스의 얀 르쿤(Yann LeCun)[7]에 의해 재발견되면서 인공신경망은 새로운 국면을 맞이한다. 1986년 데이비드 러멜하트(David Rumelhart), 제프리 힌튼(Geoffrey Hinton), 로널드 윌리엄스(Ronald Williams)의 논문[8]이 네이처에 발표되면서부터 역전파 알고리즘이 학계에 본격적으로 알려졌고 이는 정체상태에 있던 인공신경망 연구에 다시 활기를 띠도록 해주었다. 이 역전파 알고리즘은 단층 신경망뿐만 아니라 여러개의 은닉층을 가지는 다층 신경망도 학습 가능하도록 만들었다. 하지만 1995년 러시아의 통계학자인 블라드미르 바프니크(Vladimir Vapnik)와 그의 동료인 코리나 코르테스(Corinna Cortes)와 함께 공동연구로 소프트 마진(soft margin) 서포트 벡터 머신(SVM : Support Vector Machine)을 발표[9]한다. 서포트 벡터 머신이 신경망보다 더 좋은 성능을 보이자 사람들의 관심은 신경망에서 서포트 벡터 머신으로 옮겨갔다. 이후 서포트 벡터 머신은 1990년대와 2000년대 초반까지 머신러닝의 핵심적인 알고리즘으로 사용됐다.

그렇게 신경망은 연구자들의 관심에서 멀어져갔지만, 2006년 토론토대학의 제프리 힌튼 교수(Geoffrey Hinton)가 비지도학습(unsupervised learning)을 이용한 은닉층(hidden layer)에서의 데이터 전처리 방법을 제시[10]하면서 신경망은 다시 사람들의 주목을 받기 시작했다. 이 논문은 심층신뢰망(DBN : Deep Belief Network)이라고 하는 딥러닝에 매우 효과적인 알고리즘을 발표한다. 이 알고리즘은 역전파 알고리즘을 이용하더라도 3개 층을 넘어서는 복잡한 구조에서는 제대로 학습할 수 없는 문제를 해결하는데 결정적인 역할을 했다. 힌튼 교수는 다층 퍼셉트론(MLP : Multi-Layer Perceptron)을 한꺼번에 학습하는 것이 아니라 한 층씩 따로 학습하는 방법을 제시하였는데, 이 방법으로 신경망의 층을 깊게 쌓을 수 있게 되면서 더 복잡하고 추상화된 인공지능을 구현할 수 있게 되었다. 2012년 이미지 인식 경연대회에서 힌튼 교수팀이 우승하면서 심층신뢰망 이론의 효과가 검증이 되었고 이때부터 심층신뢰망 이론을 '딥러닝'이라 명명하여 본격적으로 사용되기 시작한다.


인간의 뉴런은 약 860억 개이며 그 네트워크의 깊이는 약 15층 수준으로 알려져 있다. 딥러닝은 인간보다 더 깊은 수준의 모델을 구축할 수 있는데 실제로 48층의 인공신경망을 이용한 구글의 바둑 인공지능 알파고(AlphaGo)가 그 예이다. 현재는 100층 이상의 인공신경망 모델을 만들 수 있다고 한다. 이제 기계는 15층 깊이에 불과한 인간이 상상할 수 없는 더 깊고 고도의 지식을 이해하고 학습할 수 있게 된 것이다[11].

### 1.3 딥러닝 개요

딥러닝은 머신러닝의 가지 패러다임 중에서 신경 모형 패러다임에 속한다. 1950년대부터 계속되어온 연결주의론(Connectionism)[12]의 최신 버전이라고 할 수 있다. 연결주의론에서 그동안 장애물로 여겨졌던 문제들, 즉 비선형 문제, 다층 신경망에서의 효과적인 학습모델, 역전파 시 사라지는 경사 현상, 신경망의 층수가 늘어날 때 수렴의 어려움 문제의 규모가 커질 때 나타나는 컴퓨터 성능의 한계, 레이블 된 디지털 데이터의 부족 등이 하나씩 해결되면서 최근에는 인공지능 분야에서 가장 파괴적인 기술 분야로 자리 잡고 있다[13].

### 1.3.1 딥러닝의 정의 및 필요성

딥 이라는 말은 신경망의 층이 깊고 각 층마다 고려되는 변수가 많다는 의미이다. 2~3 층의 깊이에 따라 구분하자면 개의 층으로 되어 있는 신경망을 천층망(Shallow Network) 이라 하고, 그 이상의 층으로 구성되어 있는 신경망을 심층망(Deep Network) 이라고 한다. 딥러닝에서 깊이를 나타내는 층의 개수는 입력층과 출력층 사이에 있는 은닉층(hidden layer) 개수에 하나를 더하면 된다. 이러한 이유로 딥러닝을 심층신경망(DNN : Deep Neural Network) 이라고도 한다.



(그림 3) 천층 신경망(왼쪽) 과 심층 신경망(오른쪽)

딥러닝의 기본개념은 기존 신경망에 층을 증가시킨 심층신경망을 학습하여 패턴인식이나 추론에 사용하는 것을 말한다. 기존 신경망에 비해 더 많은 층을 사용함으로써 데이터에 대한 표현 능력을 크게 증가시킬 수 있는 심층망에 대해 2006년 제프리 힌튼 교수의 논문[14]으로 사전 학습(pre-training)이라는 개념을 통해 심층망의 학습 가능성을 보여주었다.

그런데 우리는 왜 복잡한 연산을 감수하면서까지 딥러닝의 신경망 계층 수를 늘리는 것인지를 생각해봐야 한다. 인공신경망을 하나의 은닉 계층만 가지고도 적절하게 디자인하고 연결강도를 결정하면 어떠한 함수라도 근사적으로 표현할 수 있다[15]는 것은 잘 알려진 사실이다. 그럼에도 신경망의 깊이를 늘릴 수밖에 없는 이유는 다음 두 가지로 요약할 수 있다.

첫째, 복잡한 입출력간의 관계를 가진 어려운 문제를 천층망으로는 풀 수 없었다면 딥러닝으로는 풀 수 있다. 천층망은 노드의 개수를 증가시키는 방법을 쓰는 반면, 심층망은 계층을 쌓아 올릴 수 있다. 두 개의 신경망은 비슷한 복잡도를 가지고 있다고 할 수 있지만, 심층망은 천층망보

다 입력과 출력 사이를 갈 수 있는 경우의 수가 더 많다. 즉, 더 많은 방법으로 모델링 할 수 있다는 것을 의미한다.

둘째, 생물학적인 연관성도 심층망에 대한 기대를 높이고 있다. 기존 머신러닝으로 패턴인식 정도의 문제는 성공적으로 해결했지만, 음성인식이나 영상인식에서는 여전히 저조한 성적이었다. 하지만 딥러닝이 모방하고 있는 사람의 뇌신경 분야 중 영상인식에 있어서는 무수히 많은 뉴런을 거쳐 형상화한다고 한다. 또한 MIT 의 토마소 포지오(Tomaso Poggio)[16] 교수와 구글의 미래학자 레이 커즈와일(Ray Kurzweil)[17]은 계층적 모델은 인간수준의 지능을 위해 필수적인 원리라고 말하고 있다.

### 1.3.2 신경 모형 패러다임 변화

1983년 제이미 카보넬(Jaime Carbonell) 과 그의 동료들이 발표한 논문[18]에서 머신러닝은 지금까지 세 가지 접근법으로 연구가 진행되어 왔다고 설명한다. 세 가지 접근법 중 하나인 신경 모형 패러다임(Neural Model Paradigm) 은 앞서 언급했던 연결주의론에 그 뿌리를 두고 있다.

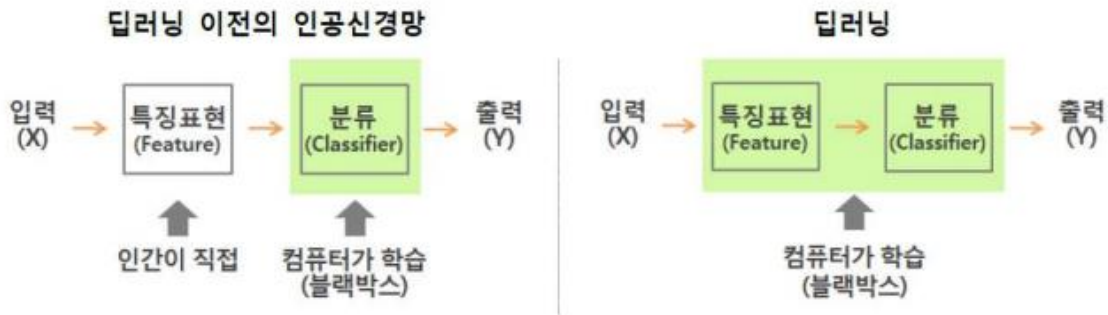
신경 모형 패러다임은 2000년대 들어서면서 심층신뢰망(Deep Belief Network), 컨볼루션 신경망(Convolution Neural Network), 순환신경망(Recurrent Neural Network) 등 획기적인 새로운 알고리즘이 소개되고 단순 이미지 처리용으로 쓰이던 그래픽 프로세서(GPU)가 숫자 연산을 위한 범용 그래픽 프로세서(GPGPU : General Purpose Graphical Processing Unit)로 재탄생하면서 깊은 신경망 구조를 가진 딥러닝(Deep Learning)으로 발전했다.

연결주의론의 시작이었던 맥컬록과 피츠의 인공신경망 이론에서부터 현재 딥러닝까지 특별한 패러다임의 변화는 없어 보이기도 하지만, 기존의 신경망에서 층수를 더 증가시킨 심층망이라는 것은 패턴인식에 있어서 패러다임의 큰 변화를 가져왔다. 패러다임의 변화는 크게 두 가지로 요약되는데 첫째는 해당분야의 전문지식 없이도 데이터로부터 자동으로 특징을 추출해낼 수 있다는 것이고, 둘째는 이것이 기존의 특징 추출기(feature extractor)와 분류기(classifier)를 대규모의 신경망으로 통합하여 학습함으로써 독립적인 성능 향상에 비해 성능 개선을 이루었다는 점이다[19]. 이러한 변화는 예를 들어 의료 영상 분석에서 의사들의 사전 지식에 의존하던 기존의 패턴인식 방법에서 심층망 학습만으로 단순화되는 것을 의미한다. 아래의 <표 1>에서는 천층망 기반 학습과 심층망 기반 학습의 차이를 요약했다.

천층망 기반 학습	심층망 기반 학습
✓ 분야 전문가에 의한 특징 추출 (예: 음성 MFCC, 동영상 SIFT)	✓ 데이터로부터 자동 특징 추출
✓ 특징 추출과 분류기의 독립 개발	✓ 특징 추출과 분류기의 통합

### 1.4 딥러닝의 장단점

딥러닝 이전의 머신러닝에서는 기계에 학습을 시키기 위해서 데이터의 특징적인 표현 하나 하나를 설명해 줘야했다. 특히, 추상적인 표현을 학습시키는 것은 상당히 어려운 일이었다. 하지만 딥러닝은 이러한 특징적인 표현을 학습시키기 위해 고민할 필요가 없다. 충분히 학습할 데이터만 입력시켜주면 기계가 스스로 특징적인 표현 등을 찾아내고 학습한다 (그림 6 참고). 딥러닝은 스스로 학습하기 때문에 학습을 시키기 위한 고도의 지식이나 프로그래밍 능력도 필요하지 않다. 또한 사람이 직접 모델링하여 만든 모델보다 기계 스스로 학습하여 만들어 낸 모델이 대부분 성능이 우수하게 나타난다.



(그림 6) 딥러닝 이전의 인공신경망과 딥러닝의 학습 비교

반면 최근 딥러닝이 다양한 분야에서 좋은 성능을 보이고는 있지만 철저하게 학습 데이터에 의존하다보니 접하지 못했던 새로운 입력을 접하는 경우에는 치명적인 오류를 범할 수도 있는 문제점이 있다. 또한 학습 데이터에만 최적화되다 보니 과적합(overfitting) 문제를 초래할 수 있다. 이 부분은 연구자가 모델의 일반화 특성을 높여 모델을 조정해 나가야 한다.

딥러닝을 포함한 신경망 모형의 작동 원리는 그림 과 같이 철저하게 블랙박스로 구성되어 있다. 이는 기계가 만들어 낸 모델의 알고리즘을 사람이 알 수가 없다는 의미이다. 그 말은 곧, 모델의 튜닝이나 업그레이드를 사람이 할 수 없고, 기계만이 가능하다는 문제점을 남긴다. 다음 <표 2>에 딥러닝의 장점과 단점을 간략히 정리했다.



<b>장 점</b>	<ul style="list-style-type: none"> <li>✓ 기계에게 학습시킬 특징표현을 고민하지 않아도 됨</li> <li>✓ 모델의 성능이 사람이 만든 모델보다 일반적으로 좋은 성능을 냄</li> <li>✓ 고도의 수학적 지식이나 프로그래밍 능력을 요구하지 않음</li> <li>✓ 오픈소스 알고리즘이 풍부하여 저렴하고 빠르게 개발이 가능함</li> </ul>
<b>단 점</b>	<ul style="list-style-type: none"> <li>✓ 학습 데이터 확보에 많은 시간과 비용이 듦</li> <li>✓ 학습 데이터의 범위를 벗어나는 패턴에 대해서는 해석이 어려움</li> <li>✓ 과적합(overfitting) 문제가 발생할 수 있음</li> <li>✓ 생성된 모델의 블랙박스를 사람이 해석하거나 개선하기 어려움</li> </ul>

<표 2> 딥러닝의 장점과 단점

[20]

## 2. 서론

CCTV (Closed Circuit Television)는 폐쇄회로 TV 으로 방재용, 교통 감시용, 의료용, 산업용 및 실내의 화상정보 전달용 등 용도가 다양하다. 특히 범죄예방·법정 증거[21]로써 큰 장점을 지니게 되는데 CCTV 는 비밀이 없는 개방된 상태라는 느낌을 주어 범죄 유혹에 노출된 사람에게 범죄의 기회를 축소시키는 장점을 가진다. 또한 CCTV 는 직접적으로 범인의 인상착의를 파악하는데 효과적일 뿐 아니라 CCTV 를 통해 범인을 인식할 수 있는 목격자(증인)를 확보하는 데에도 중요한 단서[22]를 제공한다

마지막으로 교통사고 현장에서 자동차의 스키드 마크를 찾아내듯, 요즘 사건 현장 주변에서는 수사에 활용할 만한 5~10 종의 비디오 테이프를 찾아낼 수 있다고 한다. 비디오 화면은 인간의 기억력보다 훨씬 더 정확하다. 녹화된 CCTV 테이프는 객관적이고 과학적인 범행 증거로써의 역할을 한다. 즉, CCTV 테이프는 유죄를 입증하는데 결정적인 역할을 한다. 최근 전 세계 공통적으로 CCTV 의 증거능력[23]을 인정하는 판례가 늘고 있다.

최근 부산시에서는 CCTV 통합관제센터 조식을 신설하고 안전분야 감찰 추진과 지난 2011 년부터 총 192 억원을 들여 2017 년 16 개 구·군에 CCTV 를 증설하였다. 그동안 발생한 안전사고에 대한 문제점 뿐만 아니라 재난사각지대 해소에 따른 감시체계를 향상시켰다. 부산시는 스쿨존에 설치된 방법용 CCTV 를 2022 년까지 연차적, 선별적으로 300 여대의 고성능 CCTV 로 교체해 나갈 계획이다. 부산시 전역에 설치된 1 만 2700 여대의 CCTV 화면을 통합관제센터에서 실시간으로 감시를 하게된다. 이처럼 재난에서도 CCTV 의 활용이 중요해지고 있으며 통신기술과 접목되어 점차 증대되는 추세이다.

2016년 '알파고'를 통해 인공지능이 전 세계의 관심을 끌게 되었다. 인공지능은 4차 산업혁명의 핵심 요소로 떠오르고 있으며 적용 분야도 다양하다. 인공지능을 활용한 의료기술, 제약, 금융, 헬스케어, 콘텐츠 등으로 빠르게 분야가 확대되고 있다. 인공지능이 흥행하는 주원인은 클라우드 환경의 급속한 발전과 컴퓨터 하드웨어의 크나큰 발전, SNS가 발달함에 따라 빅 데이터가 형성되었기 때문이다. 이러한 많은 발전들이 지원되어 AI를 구현하기 위한 딥러닝 또한 많은 주목을 받고 있다[24].

딥러닝도 많은 기술들이 있지만, 가장 대표적인 기술로 손꼽히는 기술은 인공 신경망으로 알려진 CNN(Convolutional Neural Network)이다. 최근에는 GAN(Generative Adversarial Networks)처럼 별도의 라벨링 처리가 필요 없는 비지도 학습도 주목을 받지만, 더욱더 확실한 정확성을 위하여 이 논문에서는 지도학습을 통한 SR(Super Resolution)을 하였다.

CNN은 최근 SR에서 큰 성공을 거두었고 계층적 특징도 잘 잡아내었다. 그러나 대부분의 CNN 기반 SR 모델은 원본 저해상도(LR) 이미지에서 계층적 기능을 완전히 활용하지 못하고, 이에 따른 상대적인 성능 저하로 이어졌다. 이 논문에서는 새로운 기법인 RDN(Residual Dense Network)을 활용하여 저화질의 CCTV 영상 화질을 개선시키는 실험을 진행하여 화질 개선이 가능함을 보이고자 한다.

본 논문은 크게 2장에서는 RDN 기법과 관련 연구에 대하여 소개하고 3장에서는 전체적인 영상 화질 개선 모델의 실험 방법과 과정에 대하여 살펴본다. 이후 4장에서는 학습 모델을 통하여 원본 CCTV 데이터와 SR을 거친 후의 CCTV 데이터의 차이점을 보인다. 마지막으로 5장에서는 결론과 한계점, 향후 계획을 설명한다.

### 3. 관련 연구

본 논문에서 활용하는 SRRDN은 기존의 CNN(Convolutional Neural Network)에서 파생된 영상처리 관련 딥러닝 기법이다. 이 장에서는 SRRDN의 진행 과정을 이해하기 위하여 CNN과 관련된 기존의 연구내용과 활용되어진 분야를 살펴본다. 또한 본 논문에서 제안하는 기법과의 차별성과 필요성을 설명한다.

[25]는 CNN에 관한 개념과 배경, 그리고 구조 분석과 적용 사례를 설명한다. CNN은 신경망으로 구성된 딥러닝 유형으로 특히 이미지의 사물 인식분야, 음성 인식 분야에서 광광을 받고 있다. 컬러 이미지와 같은 다차원 배열로 이루어진 데이터 처리가 가능하다는 것이 특징이다. 일반적인 신경망은 이미지 데이터 그대로 처리하지만, CNN은 이미지에서 특징을 추출해 처리한다. 그러나 [25]에서는 현재 CNN으로 생성한 이미지의 해상도가 낮고, 아직 완벽하지 못한 문제점이 있다고 지적한다. 이러한 문제점들을 해결하면 새로운 분야에 CNN을 적용하여 더욱 다양한 분야에 쓰일 수 있을 것으로 기대하고 있다.

[26]은 CNN 의 한 종류인 Very Deep Convolutional Networks 기법을 활용하여 CNN 보다 더욱 특징을 잘 잡아내는 고성능의 VDSR 을 개발하여 다른 기존 방법들과 학습 결과를 비교한다. 특히 일반 SRCNN 과 Bicubic 확장 보다 더욱 뚜렷한 feature 를 잡아내어 좋은 결과를 만들어 내는 것을 확인한다.

[27]은 MemNet 이라는 이미지가 기억에 남을지 아니면 잊힐지를 사람만큼 잘 예측하는 알고리즘 기법을 활용하여 만들어진 SR 기법이다. MemNet 은 사람들에게서 여러 다른 데이터 세트에서 수십만장의 이미지들로 추출한 '인상 점수'로 사전학습을 받아 완전히 새로운 이미지가 사람들에게 얼마나 기억될지 예측하여 실제로 비교하였다. 그 결과 현재의 알고리즘보다 예측력이 30% 가까이 향상되었으며, 사람들의 인상점수보다 얼마 차이 나지 않았음을 확인하였다. 향후에는 특정 사람의 기억력을 예측하고, 의류 및 로고 디자인 등 개별업계 등에 활용 가능한 기술을 개발할 예정이다.

[28]은 SRGAN 을 소개한다. 기존의 GAN 보다 속도가 빠르고 깊은 계층을 가진 인공 신경망을 적용한 SRGAN 을 사용하였다. SRGAN 기법을 단일 이미지에 적용하여 SR 의 정확성과 속도의 비약적인 발전을 시켰다. 이를 달성하기 위해 [28]은 적대적 손실 및 콘텐츠 손실되는 지각 손실 함수를 제안한다. 손실 함수(Loss function)로 초고해상도 사진과 원본 사진 이미지를 구별하도록 훈련된 식별기 네트워크를 사용한다.

[29]는 시간 중복성을 효율적으로 활용하고 실시간 속도를 유지하면서 재구성 정확도를 향상시키는 CNN 모델을 적용한 네트워크를 소개한다. 특히 여러 개의 연속적인 비디오 프레임의 병렬 처리를 위해 early fusion 과 slow fusion 및 3D convolution 의 사용에 대하여 설명한다. 또한 End-to-End 학습이 가능한 공간 트랜스포머 모듈에 의존하는 새로운 방법과 SR 을 동일한 품질을 유지하며 계산 비용(computational cost)의 값을 30% 줄이거나, 비슷한 계산 비용으로 0.2dB 의 향상을 시켰다.

[30]은 DRCN 을 소개한다. 이는 layer 의 깊이를 더욱 깊숙이 늘린다 하더라도, 추가 컨볼루션 레이어를 위한 새로운 매개변수를 도입하지 않고도 성능을 향상시킬수 있게 만들어진 네트워크 모델이다. 하지만, 기울기 소실 문제(Vanishing gradient problem)으로 인하여 표준 옵티마이저로는 DRCN 을 학습하기가 어렵다. 그리하여 새로운 옵티마이저 방식을 제안하였다.


[31]은 EDSR 을 소개한다. 이 모델은 2016 년 Twitter 연구팀에서 SRResNet 이라는 네트워크구조를 소개한적이 있었는데, 그 SRResNet 을 변형하여 SISR 문제에 더욱 집중하게 만들었다. 다른 모델과의 다른 점은, 기존의 residual block 에서 불필요한 Batch normalization(BN)층을 제거함(Drop out)으로써, 더욱더 뛰어난 최적화를 이루었다는 점이다. 또한 BN 을 제거함으로써 학습시에 메모리 사용량을 대략 40%정도 절감할 수 있었고, 덕분에 메모리 사용량이 절감된 만큼 더 큰 네트워크를 학습시킬수 있었다

또한 [31]은 Multi-scale deep super-resolution system(MDSR)도 소개한다. 이는 하나의 네트워크로 여러 scale 의 (x2, x3, x4) SISR 에 적용이 가능한 네트워크 구조이다. MDSR 은 네트워크 중앙에

하나의 학습된 모델을 공유한다. 그리고 각 스케일에 대처할 수 있도록 각 스케일에 서로 다르게 적용되는 Pre-processing module 을 적용했고, 최종단의 upscaling 역시 각 스케일에 대응하는 구조를 따로 배정하였다. 이때 Pre-processing module 에는 두 개의 ResBlcoks 를 쌓았고, 여기서는 5x5 convolution 을 적용했다.

[32]에서는 심층 네트워크에서 dense skip connections 을 도입하여 새로운 SR 기법을 제시한다. 이 논문에서 제안된 네트워크를 통하면, 각 레이어의 맵은 모든 후속 레이어에 전파되어 낮은 레벨의 특징들과 높은 레벨의 특징을 결합하여 성능을 향상시키는 효과적인 방법을 제공한다. 또한 네트워크의 각 계층을 직접 구축할 수 있으므로, 기울기 소실 문제를 완화 할 수 있다.

[33]은 [31]의 MDSR 의 기법중 Residual block 과 [32]의 Dense block 기술을 결합하여 새로운 방법인, Residual Dense Block(RDB) 을 소개한다. 이 기법은 연속 메모리(Contiguous Memory, CM)메커니즘을 통해 이전 RDB 의 상태를 읽으며, 로컬의 밀집한 연결들을 통하여 모든 계층을 완전하게 활용한다. RDB 를 거치며 누적된 특징들은 로컬 특징 합성(Local Feature Fusion, LFF)을 통해 보존되며, 모든 RDB 의 계층적 특징을 적응적으로 결합하기 위하여 전역 특징 합성 (Global Feature Fusion, GFF)를 실행한다.




본 논문에서는 [33]에서 사용한 SRRDN 의 기법의 과정을 참조하여 저화질의 CCTV 영상 화질을 개선시키는 실험을 진행하였고, 화질의 개선이 가능함을 보이고자 한다. [1~3]에서 본 논문에서는 실질적으로 사용될 수 있는 CCTV 와 흡사한 영상 데이터를 이용하여 SRRDN 기법에 사용하였다. 또한, 본 논문에서 제안하는 기법은 기존의 SR 모델들이 RGB 데이터들을 사용한 것과 다르게 CCTV 라는 특성에 맞게 YUV 데이터, 즉 영상의 Raw 데이터를 사용하였다.

#### 4. SRRDN 기반의 영상 화질 개선 기법

이 장에서는 SRRDN 기반의 영상 화질 개선 기법에 대하여 설명한다. SRRDN 의 모체가 되는 CNN 은 학습이 가능한 가중치 (weight)와 편향 (bias), 계층 (Layer)으로 구성되어 있다. 우선 3.1 에서는 CNN 의 기본적인 과정을 흐름도를 이용하여 살펴본다. 이후 3.2 에서는 SRRDN 딥러닝을 거치기 위한 데이터 전처리 과정을 보인다. 마지막으로 3.3 에서 SRRDN 기반의 영상 화질 개선 기법 모델을 흐름도와 수식을 통해 설명한다.

#### 4.1 CNN(Convolutional Neural Networks)

이미지를 다루는데 일반 신경망이 아닌, CNN 을 사용하는 이유로는 일반 신경망은 이미지를 다루기에 적절하지 않다는 점이다. 전연결 계층 (Fully Connected Layer) 만으로 구성된 인공 신경망의 입력 데이터는 1 차원배열 형태로 한정된다. 하지만, 한 장의 컬러 이미지는 3 차원 데이터로 구성이 되고 배치에 사용되는 여러장의 사진은 4 차원 데이터이다. 사진 데이터로 전연결 신경망을 학습시켜야 할 경우, 3 차원 사진 데이터를 1 차원으로 평면화 시켜야 한다. 사진 데이터를 평면화를 시키는 과정에서 공간 정보가 손실될 수 밖에 없다. 결과적으로 이미지 공간 정보 유실로 인한 정보 부족으로 인공 신경망이 특징을 추출 및 학습이 비효율적이고 정확도를 높이는데 한계가 있다. 이미지의 공간 정보를 유지한 상태로 학습이 가능한 모델이 바로 CNN 이다. CNN 은 각 뉴런은 입력을 받아 내적 연산 (dot product)을 한 뒤 선택에 따라 비선형 (non-linear) 연산을 한다. 전체 네트워크는 일반 신경망과 마찬가지로 미분 가능한 하나의 스코어 함수 (score function)을 갖게 된다. 또한 CNN 은 마지막 레이어에 SVM 이나 SofrMAX 와 같은 손실함수 (loss function)을 가지며, 우리가 일반 신경망을 학습 시킬 때 사용하던 각종 기법들을 동일하게 적용시킬 수 있다. 또한 CNN 은 입력 데이터가 이미지라는 가정 덕분에 이미지 데이터가 갖는 특성들을 인코딩 할 수 있다. 이러한 아키텍처는 포워드 함수 (forward function)을 더욱 효과적으로 구현할 수 있고, 네트워크를 학습시키는데 필요한 모수 (parameter)수를 크게 줄일 수 있게 해준다.



#### 4.2 기계학습을 위한 데이터 전처리 과정

영상 화질 개선 기법을 구현하기 위한 데이터셋은 DIV2K 를 이용하였다. 여기서 이용한 DIV2K 는 SR 연구시에 사용되는 이미지 데이터셋이며, 1000 장의 2K(1920x1080 pi) 해상도의 다채로운 이미지로 이루어져 있으며, Label 과 Validation, Test data 는 80 : 10 : 10 의 비율로 사용하였다.

각각을

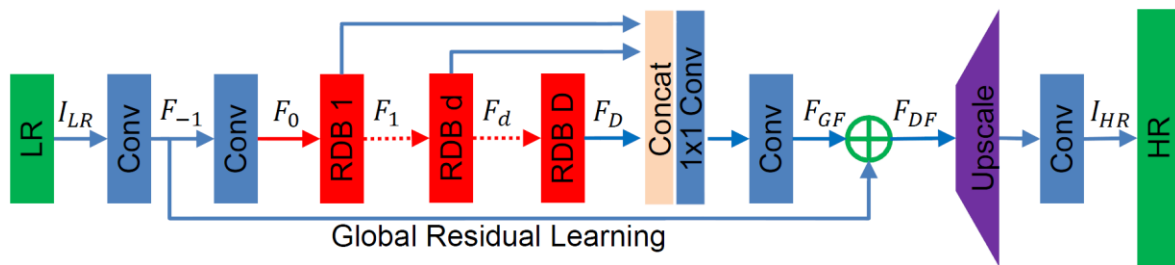
살피자면

Train data : 800 장의 고해상도 이미지로 이루어져 있으며, 1/2 스케일, 1/3 스케일 그리고 1/4 스케일의 저해상도 이미지 또한 같이 저장되어 있다. 저해상도 이미지는 기본 설정 (Bicubic 기법)으로 생성한 데이터셋과 알려지지 않은 기법으로 사용한 이미지들을 사용하였다.

Validation data : 100 개의 고해상도 이미지로 이루어져있으며, 이미지를 생성하는데 사용된다. 저해상도 이미지는 유효성 검사(Validation)을 하는데 사용된다.

Test data : 100 개의 이미지가 고해상도 이미지를 생성할 때 사용된다.

### 4.3 SRRDNN 의 과정



SRRDN 의 목적은 입력받은 낮은 해상도의 이미지에서 높은 해상도의 이미지를 생성하는 것이다. 이를 위하여 SRRDN 의 인공 신경망을 학습시켜야 한다. RDN 의 네트워크는 크게 4 부분으로 구성되어 있는데, 얇은 특징 추출 네트워크 (SFENet), RDB, 밀집 특징 합성 (Dense Feature Fusion, DFF), 그리고 마지막으로 업샘플링 네트워크(UPNet)로 구성되어 있다. 이 중  $I_{LR}$  을 입력,  $I_{SR}$  을 출력으로 표현한다. 특히 이 논문에서는 두 개의 컨볼루션 레이어를 사용하여 얇은 특징을 추출한다. 첫 번째 레이어에서는  $I_{LR}$  입력에서  $F_{-1}$  의 특징을 추출한다.

$$F_{-1} = H_{SFE1}(I_{LR})$$

여기서  $H_{SFE1}(I_{LR})$  는 컨볼루션 작동을 의미한다. 그런 다음  $F_{-1}$  을 사용하여 특징 추출 및 전범위의 잔류되어있는 학습 (Global Residual Learning, GRL)을 진행한다.

$$F_0 = H_{SFE2}(F_{-1})$$

여기서  $H_{SFEZ}(F_{-1})$  는 두 번째 SFENet 을 작동을 의미하고, RDB 의 입력값으로 사용된다. 만약 RDB D 가 있다고 가정할 때, d 번째 RDB 의 출력  $F_d$  는

$$F_d = H_{RDB,d} ( F_{d-1} )$$

$$= H_{RDB,d}(H_{RDB,d-1}( \dots (H_{RDB,1}(F_0) \dots ))$$

여기서  $H_{RDB,d}$  는 d 번째 RDB 의 작동을 의미한다.  $H_{RDB,d}$  는 ReLU 함수와 같은 활성화 함수로 작동된다.  $F_d$  는 블록 내의 각각의 레이어들을 작동하여 d 번째 RDB 에 의해 생성되므로  $F_d$  를 지역 특징으로 활용할 수 있다. RDB 를 이용하여 계층적 특징을 추출한 후 GFF 및 GRL 을 포함한 DFF 를 추가적으로 실행한다. DFF 는 앞의 모든 레이어의 특징을 최대한 활용하여 다음과 같이 나타낼 수 있다.

$$F_{DF} = H_{DFF}(F_{-1}, F_0, F_1, \dots, F_D)$$

여기서  $F_{DF}$  는 합성함수  $H_{DFF}$  를 이용한 DFF 의 출력 특징 맵이다. 그 후 LR 공간에서 지역 및 전역 특징을 추출 한 후 HR 공간에 UPNet 을 쌓는다. 그 후 UPNet 의 ESPCN 에 이어 새로운 컨볼루션 레이어를 사용한다. 즉 RDN 의 출력은


$$I_{SR} = H_{RDN}(I_{LR})$$

로, RDN 의 알고리즘을 나타낼 수 있다.

## 5. 실험 방법 및 결과

실험 당시 수집한 데이터셋은 전 세계적으로 SR 실험시 사용되는 DIV2K 의 이미지 1000 장으로 학습을 진행하였다. 이미지는 2K 이며 각각이 다른 특징을 가지고 있는 사진 데이터 이다. 학습에 필요한 데이터셋들은 학술 연구 목적으로만 제공된 이미지 데이터셋만을 이용하였다. 또한 실험에 사용한 CCTV 녹화 영상은 CC0 1.0 으로 지정된 저작물에 대한 변형이 가능하고, 사용자 출처 표시의 의무가 없으며, 학술적 용도로 사용 가능한 파일을 pixabay 에서 다운받아 사용하였다. 영상은 총 4 개의 영상에서 .png 파일로 10 프레임당 한 장씩, RGB 포맷 png 압축방식으로 저장하였으며, 프레임 이미지 데이터에서 10 장을 랜덤하게 추출하여 사용하였다.

### 5.1 실험 배경 및 방법



실험은 Python 3.5 ver. 과 TensorFlow 1.10.1 ver. TensorFlow-GPU 1.4.0 ver. 과 CUDA 8.0 ver. CUDNN 6.0 ver 을 사용하여 진행하였다. SRRDN 기반의 CCTV 영상 화질 개선 기법은 그림 4 과 같은 과정을 거쳐 진행되었다. 먼저 입력 데이터의 조건에 맞춰 SRRDN 을 구성한다. SRRDN 의 학습된 모델을 이용하여 LR 의 이미지가 SR 의 이미지로 도출된다. 결과로 출력되는 이미지의 크기는 전처리 과정을 거치기 전 입력 데이터의 크기인 2K(1920x1080)를 qHD(960x540) 화질로 Bicubic 변환하였다.

처음, 학습에 필요한 입력 데이터를 Train 데이터와 Validation 데이터로 분할한다. 데이터를 분할하는 것은 1000 개의 이미지중 800 번까지의 이미지를 Train 데이터로, 801 번째 이미지부터 900 번째 이미지를 Validation 데이터로, 901 번부터 1000 번의 이미지를 Test 데이터로 지정하였다.

그 후, 이미지 데이터의 고유한 헤더를 OpenCV 를 이용하여 분리한 후, 학습에 진행시킬 데이터 이미지를 120x120 픽셀과 1/2 스케일인 60x60 스케일로 numpy 로 분할한다. 이후 각각 이미지는 가로와 세로 크기의 1/2 바이큐빅 변환하여 60x60 Bicubic 이미지셋과, SR 이미지의 선명도를 높이기 위한 Gaussian Blur 를 적용한 60x60 Blur 이미지를 사용하였다. 즉 트레이닝 데이터셋 (960x540)과 Bicubic LR(480x270), Blur SR(480x270) 을 준비하게 된다.

학습시 쓰이는 Test 이미지는 같은 크기의 960x540 크기의 이미지를 120x120 픽셀로 numpy 분할하여 사용한다.

## 5.2 성능 평가

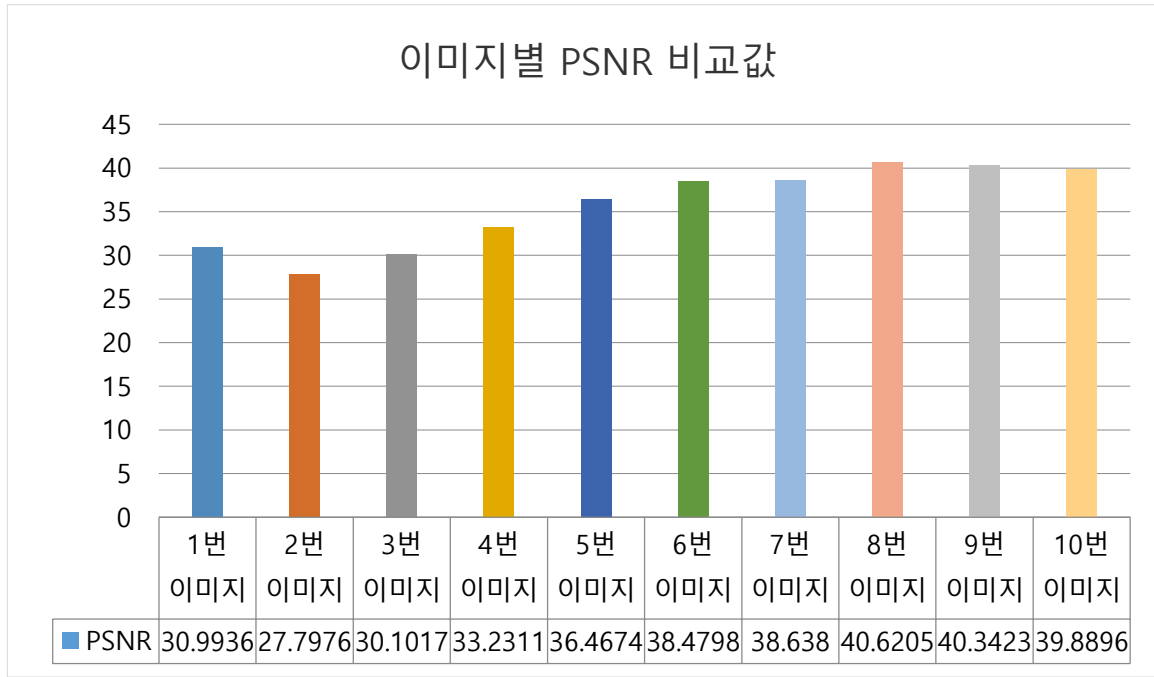
### 5.2.1 소요 시간

실험에 들어가기에 앞서 SRRDN 기법이 평균적으로 어느 정도의 처리량을 보이는지 살펴본다. 이를 평가하기 위해 SRRDN 기법이 이미지 10 장의 화질 개선 과정을 진행하는 동안 걸리는 시간을 측정하였다. 실험에 사용된 PC 의 성능은 다음과 같다.

CPU	Intel(R) Xedon(R) CPU E5-2690 0 @ 2.90GHz
RAM	64 GB
GPU	GeForce GTX 1080, GeForce GTX 1070
OS	Ubuntu 16.04



학습모델을 만든 후, 10 장의 이미지의 화질 개선 과정을 거치기 위해 소요된 시간은 평균 6.96 초가 걸렸으며, 원본대비 PSNR(최대 신호 대 잡음비) 값은 10 장 평균 39.01 이 추출되었고, 최고값인 40.6025 와 최저값인 27.7976 을 제했을 때 평균값은 36.01 이 추출 되었다



### 5.2.2 CCTV 영상 화질 개선 실험 결과

본 논문에서 제시한 영상 화질 개선 기법을 적용하기 전의 영상과 적용한 후의 영상의 프레임들을 비교해 놓은 표이다. Input 은 입력 데이터로 사용된 기법이 적용되기 전의 이미지 이며, Output 은 기법을 거친 후 출력된 결과 이미지 이다. 1 번은 거리에 설치되어있는 카메라로 얻은 영상이며, 자동차의 움직임과 사람들의 움직임이 확인된다. 2 번은 자동차 도로에 설치되어 있는 카메라로 얻은 영상이며, 교통 상황이 확인된다. 3 번은 식당 외부 좌석을 비추는 카메라로 얻은 영상이며, 사람의 유동성이 높은 위치에 설치되어 있다. 4 번은 복잡한 거리에 설치되어 있는 카메라로 얻은 영상이며, 자동차와 사람의 유동성이 높은 위치에 설치되어 있다.

	Input	Output
--	-------	--------

1 번		
2 번		
3 번		
4 번		

### 5.2.3 Output 이미지 확대

각각 1 번과 3 번 영상의 일부분을 확대한 이미지이다. SR 을 적용하기 전보다 전체적으로 화질이 뚜렷하고, 노이즈가 줄어든 것을 육안으로 봐도 확인을 할 수 있다. 이러한 기법의 효과는 CCTV 영상을 분석하여 불분명한 숫자나, 글자가 있는 경우 보다 정확한 자료가 필요할 때 유용하게 사용될 수 있다.



<1 번 이미지 원본>



<1 번 이미지 SR 결과>



<3 번 이미지 원본>



<3 번 이미지 SR 결과>

## 6. 결론 및 향후 연구

본 논문에서는 SRRDN 을 활용하여 CCTV 영상의 화질을 개선시키는 실험을 진행하였다. 실험 결과 SRRDN 기법을 사용하여 960x540 화질의 CCTV 영상을 1920x1080 화질로 개선시키는 것을 보였다. 이는 실생활에도 활용할 수 있음을 의미한다. 범죄나 재난 예방에 활용될 수 있으며, 오래된 영상의 복구에도 사용될 수 있다. 또한 특징점 분석과 같이 CCTV 영상을 기반으로 하는 연구에도 보다 정확한 영상 데이터를 제공함으로써 도움을 줄 수 있다.

향후 연구 과제로는 데이터 전처리를 보다 다양하게 하여, 더욱 영상의 선명도가 높아지게 하는 기법을 개선하는 것이 필요하다. 또한 본 논문에서 제안한 기법의 프로세싱 속도를 높일 수 있도록 보완하여, 실시간으로 화질을 개선하는 방안을 연구하는 것이 향후 과제라 생각한다. 한편 제안한 기법의 외부적인 한계점으로 컴퓨터가 고성능이 아니라면 기법을 적용하기 어렵다는 점을 들 수 있고, 기계 학습을 시키기 위한 전처리 과정이 수작업으로 진행된다는 점이 보완해야 할 부분이다.

## 참고문헌

[1] Warren, S. M., Walter, P., "A logical calculus of the ideas immanent in nervous activity", *Bulletin of mathematical biophysics* 1943

[2] Hebb, D. O., "The Organization of Behavior", New York: Wiley & Sons 1949

- [3] Rosenblatt, F., "The perceptron: A probabilistic model for information storage and organization in the brain", *Psychological Review* 1958
- [4] Minsky, M., Papert, S., "Perceptrons: An Introduction to Computational Geometry" MIT Press, Cambridge MA 1969
- [5] Werbos, P., "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Phd thesis", Harvard University, Cambridge MA 1974
- [6] Parker, D. B., "Learning-logic", Technical Report TR-47, Center for Comp. Research in Economics and Management Sci., MIT 1985
- [7] LeCun, Y., "Une procedure d'apprentissage pour r´eseau a seuil asym´etrique", *Proceedings of Cognitiva 85*, Paris 1985
- [8] Rumelhart, D. E., Hinton, G. E., Williams, R. J., "Learning representations by back-propagating errors", *Parallel Distributed Processing* MIT Press 1986
- [9] Vapnik, V., Cortes, C., "Support-Vector Networks", *Machine Learning* 20 1995
- [10] Geoffrey E. Hinton, Simon Osindero, Yee-Whye Teh, "A fast learning algorithm for deep belief nets", *Neural Computation* MIT Press 2006
- [11] 류성일 차 산업혁명을 이끄는 인공지능 딥러닝을 중심으로 , kt BigData Project TF
- [12] 당시 인공지능망을 연결주의론이라고 부름
- [13] 김의중 "알고리즘으로 배우는 인공지능, 머신러닝, 딥러닝, 입문" 위키북스
- [14] G. E. Hinton, S. Osindero, Y. Teh, "A fast learning algorithm for deep belief nets", *Neural Computation*, Vol. 18, 2006
- [15] Bishop C. M., "Neural Networks for Pattern Recognition", Oxford University Press 1995
- [16] Poggio T., Riesenhuber M., "Hierarchical models of object recognition in cortex", *Nature Neuroscience* Vol. 2, No. 11, 1999
- [17] Kurzweil R., "How to Create a Mind: The Secret of Human Thought Revealed", Penguin Books 2012
- [18] Jaime G. Carbonell, Ryszard S. Michalski, Tom M. Mitchell, "Machine Learning: A Historical and Methodological Analysis", *The AI Magazine* 1983
- [19] 최희열, 민용홍, "딥러닝 소개 및 주요 이슈", *한국정보처리학회지* 제 22 권 1 호 (2015.1)
- [20] 박원기 "딥러닝 소개와 금융업 적용 사례" 2017

- [21] J.Y Son, J.S Kim "Research on Determining the Admissibility of Digital Evidence" Judicial Policy Research Institute 2015
- [22] Y.C Park "The Admissibility and Probative Force of Testimonial Evidence of whom Watched CCTV" Seokang University 2012
- [23] H.K Peak "Evidence admissibility of VIDEO tape" 대법원 2012 도 5041
- [24] S.M Rho "Artificial Intelligence technology R&D Trend by Patent Analysis" Journal of Digital Contents Society 2017
- [25] Alex Krizhevsky, Ilya Sutskeve, Geoffrey E. Hinton "ImageNet Classification with Deep Convolutional Neural Networks" University of Toronto 2015
- [26] J.W Kim, J.K Lee, K.M Lee "Accurate Image Super-Resolution Using Very Deep Convolutional Networks" Seoul National Unuversity 2016
- [27] Ying Tai, Jian Yang, Xiaoming Liu, Chunyan Xu "MemNet: A Persistent Memory Network for Image Restoration" Michigan State Ubiversity 2017
- [28] Christian Ledig, Lucas Theis, Ferenc Huszar, Jose Caballero, Andrew Cunningham, Alejandro Acosta, Andrew Aitken, Alykhan Tejani, Johannes Totz, Zehan Wang, Wenzhe Shi "Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network" Twitter 2017
- [29] Jose Caballero, Christian Ledig, Andrew Aitken, Alejandro Acosta, Johannes Totz, Zehan Wang, Wenzhe Shi "Real-Time Video Super-Resolution with Spatio-Temporal Networks and Motion Compensation" Twitter 2017
- [30] J.W Kim, J.K Lee, K.M Lee "Deeply-Recursive Convolutional Network for Image Super-Resolution" Seoul National Unuversity 2016
- [31] Bee Lim, S.H Son, H.W Kim, S.J Nah, K.M Lee "Enhanced Deep Residual Networks for Single Image Super-Resolution" Seoul National Unuversity 2017
- [32] Tong Tong, Gen Li, Xiejie Liu, Qinquan Gao "Image Super-Resolution Using Dense Skip Connections" Imperial Vision Technology 2017
- [33] Yulun Zhang, Yapeng Tian, Yu Kong, Bineng Zhong, Yun Fu "Residual Dense Network for Image Super-Resolution" Northeastern University 2018