

그레이스케일 영상의 병렬가산 컨볼루션 알고리즘

최종호*

Parallel-Addition Convolution Algorithm in Grayscale Image

Jong-Ho Choi*

요약 최근들어 CNN(Convolutional Neural Network)을 이용한 딥러닝 기술이 영상인식 등의 분야에서 널리 활용되고 있다. CNN에서 승산과 가산으로 수행되는 컨볼루션 처리는 단순한 연산이지만 하드웨어로 구현하는 데 문제가 되는 것은 승산을 수행하는데 필요한 계산시간이다. 컴퓨팅 파워의 사용에 문제가 없는 응용분야에서는 문제가 되지 않지만 임베디드용 딥러닝 시스템 등의 구현을 위한 하드웨어 칩설계에서는 많은 제한이 있다. 따라서 본 논문에서는 그레이스케일 영상을 2진영상의 중첩으로 표현한 후, 병렬로 가산만을 이용하여 컨볼루션을 수행하는 병렬가산 알고리즘을 제안하였다. 본 논문에서 새롭게 제안한 알고리즘의 유용성을 확인하기 위한 실험을 통해 처리시간의 감소가 가능한 병렬가산 방식으로 컨볼루션을 수행할 수 있음을 확인하였다.

Abstract Recently, deep learning using convolutional neural network (CNN) has been extensively studied in image recognition. Convolution consists of addition and multiplication. Multiplication is computationally expensive in hardware implementation, relative to addition. It is also important factor limiting a chip design in an embedded deep learning system. In this paper, I propose a parallel-addition processing algorithm that converts grayscale images to the superposition of binary images and performs convolution only with addition. It is confirmed that the convolution can be performed by a parallel-addition method capable of reducing the processing time in experiment for verifying the availability of proposed algorithm

Key Words : Chip Design, Convolution, CNN, Deep Learning, Parallel-Addition, Processing Time

1. 서론

디지털 영상처리의 영상개선, 영상복원, 영상인식 등의 분야에서 널리 사용되고 있는 공간영역에서의 필터링 기법은 컨볼루션 연산이다. 컨볼루션 연산을 이용한 필터링 기법은 주파수영역에서 수행되는 변환필터링 기법보다 연산시간이 짧고, 하드웨어 칩 구현이 용이하다는 특징을 가지고 있다.

영상필터링 기법으로 널리 사용되고 있는 컨볼루션 처리가 최근들어 인공지능에서 머신러닝을 목표로 수행하는 딥러닝 시스템의 핵심 기술로 활

용되고 있다. CNN 기반 딥러닝 기술은 RGB 컬러 입력영상을 RGB 각각의 그레이스케일 영상으로 변환한 후, 여러 계층을 거치면서 다수의 커널로 컨볼루션 처리를 수행하는 것이 그 핵심이다. CNN에서는 일반적으로 224×224 입력영상이 수십개 정도로 구성되는 각각의 계층에서 수십개 정도의 커널을 사용하여 컨볼루션 연산이 수행된다 [1,2,3,4]. 승산과 가산으로 수행되는 컨볼루션 처리는 단순한 연산이지만 하드웨어로 구현하는 데 가장 문제가 되는 것은 승산을 수행하는데 필요한 계산시간이다. 컴퓨팅 파워의 사용에 문제가 없는

This paper is the result of a study by the Kangnam University Intramural Research Support Project 2015.

*Corresponding Author : Department of IoT Electronic Engineering, Kangnam University(jhchoi@kangnam.ac.kr)

Received June 30, 2017

Revised July 15, 2017

Accepted July 19, 2017

응용분야에서는 문제가 되지 않지만 임베디드용 딥러닝 시스템의 구현을 위한 하드웨어 칩 설계에서는 많은 제한이 있다.

따라서 본 논문에서는 그레이스케일 영상을 2진 영상의 중첩으로 변환한 후, 가산만으로 컨볼루션을 수행하는 병렬가산 컨볼루션 알고리즘을 제안하였다. 본 논문에서 병렬가산 컨볼루션을 수행하기 위해 적용한 그레이스케일 영상을 이진영상으로 변환하는 영상분해 방식은 그레이레벨 기준평면 영상으로의 변환 알고리즘이다. 그레이레벨 기준평면으로의 변환은 병렬로 가산 연산만을 이용하여 컨볼루션 처리를 수행한다는 특징에 더하여 입력영상의 그레이레벨을 더하는 연산이 아니고 필터의 계수를 더하는 연산이라는 특징이 있다. 또한 응용분야에 따라 그레이레벨 기준평면의 일부만을 사용함으로써 처리시간을 추가로 감소시킬 수 있다는 특징을 가진다.

처리시간의 감소효과를 갖는 병렬 가산 방식으로 컨볼루션을 수행할 수 있으므로 딥러닝에서의 다양한 활용이 가능하다는 것을 실험을 통해 확인하였다.

2. 그레이스케일 영상 분해

CNN 기반 딥러닝에서 사용되는 컬러영상을 R, G, B 성분으로 분해한 각각의 영상은 그림 1에 나타낸 바와 같이 256 그레이스케일 영상으로 변환된다. 256 그레이스케일 영상의 그레이레벨 값은 0~255이므로 각각의 화소는 8비트로 표현된다.

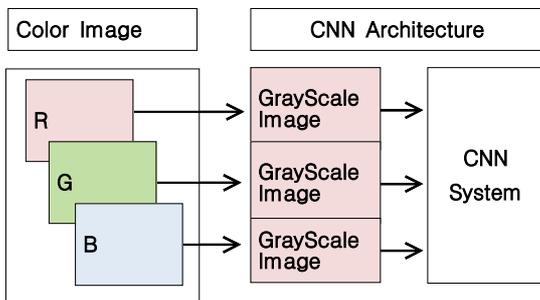


그림 1. CNN에서의 컬러영상 처리
Fig. 1. Color image processing in CNN

그림 2에 나타낸바와 같이 3×3 커널에서 8비트 화소값과 필터와의 컨볼루션 연산은 9개의 승산과 8개의 가산이 수행된다. 이 경우 출력영상의 값은 식 (1)로 표현된다. 현재의 디지털시스템에서는 가산 보다는 승산에 필요한 처리시간이 매우 길고, 이는 또한 칩 설계에서의 복잡성을 증가시킨다.

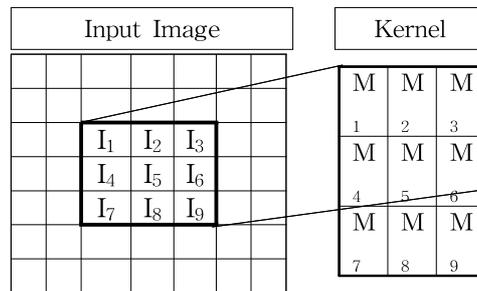


그림 2. 컨볼루션 연산
Fig. 2. Convolution operation

$$\text{OutputImage}(i,j) = I_1M_1+I_2M_2+I_3M_3+I_4M_4+I_5M_5+I_6M_6+I_7M_7+I_8M_8+I_9M_9 \quad (1)$$

식 (1)을 계산하기 위해서는 승산과 가산이 필요하다. 3×3 커널의 경우, 입력영상 각각의 화소에 대해 9개의 승산이 필요하다. 물론 커널의 크기가 증가하면 연산 수는 기하급수적으로 증가한다. 디지털시스템에서의 승산은 계산시간의 측면에서 매우 불리하다. 물론 칩설계의 분야에서는 더욱 문제가 되는 부분이다. 이 경우, 승산을 가산으로 바꾸는 문제를 생각할 수 있다. 승산을 가산으로 변환하여 수행하는 알고리즘은 기존의 시프트레지스터 등을 사용한 칩설계의 분야에서도 일반적으로 널리 적용되고 있는 것이다. 따라서 승산을 가산으로 변환하는 것에 대한 이점은 병렬처리의 적용이 가능할 때이다.

승산을 가산는 CNN에 적용하는 경우를 고려하여, 입력영상을 이진영상으로 분해하여 컨볼루션을 가산만을 이용하여 병렬로 처리하는 알고리즘을 제안하였다.

그레이스케일 영상을 이진영상으로 분해하는 방법은 크게 두가지로 나눌 수 있다. 그 첫 번째는 그림 3에 나타낸 바와 같이 256 그레이레벨영상에서 화소당 비트수가 8비트이므로 8개의 비트플랜 영상으로 분해하는 방법이다[5].

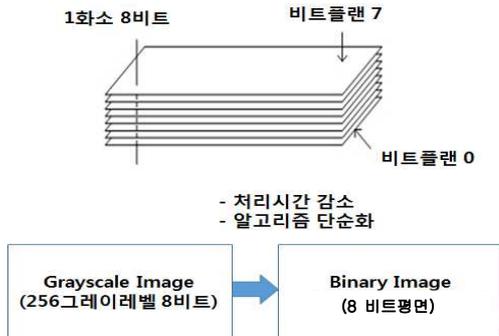


그림 3. 비트플랜 영상분해
Fig. 3. Decomposition into bit-plane

화소당 8비트의 영상을 8개의 비트플랜으로 분해하는 연산은 식 (2)와 같다.

$$\begin{aligned}
 &\text{Bit-Plane 0 :} \\
 &\quad 0\text{번째 비트가 1인 화소}=1 \\
 &\quad 0\text{번째 비트가 0인 화소}=0 \\
 &\text{Bit-Plane 7 :} \qquad \qquad \qquad (2) \\
 &\quad 7\text{번째 비트가 1인 화소}=1 \\
 &\quad 7\text{번째 비트가 0인 화소}=0
 \end{aligned}$$

그레이스케일 영상을 이진영상으로 분해하는 두번째 방법은 그림 4에 나타낸 바와 같이 기준플랜 영상으로 표현하는 방식이다[6].

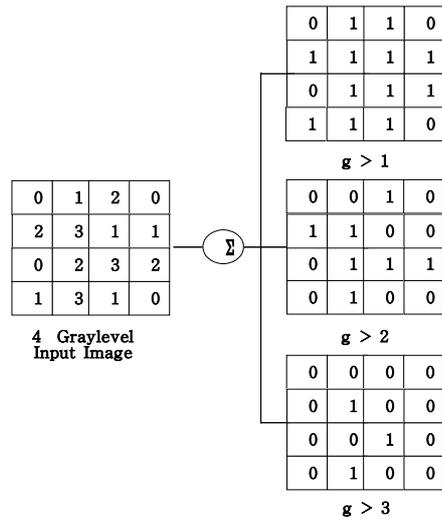


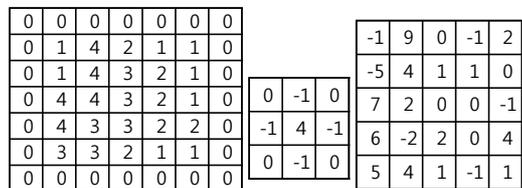
그림 4. 기준플랜 영상분해
Fig. 4. Decomposition into criterion-plane

256 그레이레벨의 그레이스케일 영상을 그레이레벨 값을 기준으로 255개의 영상으로 분해하는 연산은 식 (3)과 같다.

$$\begin{aligned}
 &\text{Criterion-Plane 1 :} \\
 &\quad \text{그레이레벨이 1이상인 화소}=1 \\
 &\quad \text{그레이레벨이 1미만인 화소}=0 \\
 &\text{Criterion-Plane 255 :} \qquad \qquad \qquad (3) \\
 &\quad \text{그레이레벨이 255이상인 화소}=1 \\
 &\quad \text{그레이레벨이 255미만인 화소}=0
 \end{aligned}$$

3. 병렬가산 컨볼루션 알고리즘

병렬가산 컨볼루션 알고리즘을 서술하기 위해 그림 5와 같이 영상과 커널 패턴을 가정하였다. 입력영상을 에지검출 커널로 컨볼루션 연산한 결과로서 컨볼루션 커널의 시작화소는 (1,1)이다.



(a) Input Image (b) Kernel (c) Output Image
그림 5. 에지검출 컨볼루션 연산
Fig. 5. Convolution operation in edge detection

3.1 비트플랜 병렬가산 컨볼루션

비트플랜에 에지검출 커널을 적용하여 컨볼루션 연산한 결과를 단순하게 더하면 그레이스케일 영상의 컨볼루션 결과와 일치하지 않는다. 각각의 비트플랜은 가중치가 서로 다르기 때문이다. 따라서 그림 6에 나타난 바와 같이 각각의 비트플랜에 가중치를 곱한 결과를 더해야 최종 컨볼루션 결과가 산출된다.

본 논문에서 제안한 알고리즘은 VLSI 설계 등 연산시간을 줄이기 위해 가산만으로 컨볼루션을 수행하는 것이므로 비트플랜으로 입력영상을 분해하여 각각을 병렬로 연산하는 방법은 한계가 있다.

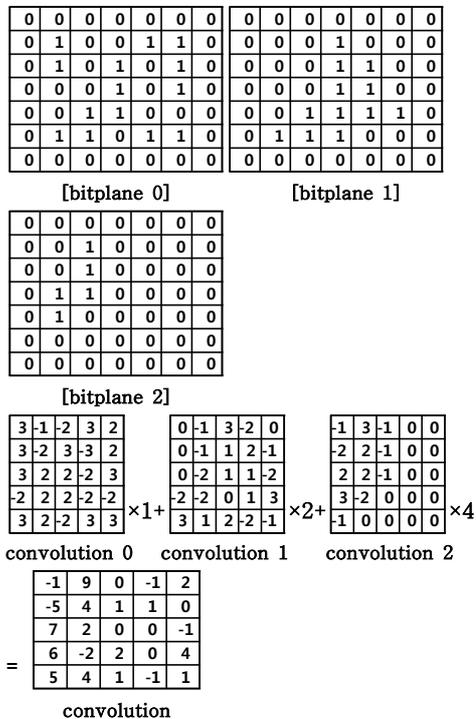


그림 6. 비트플랜 컨볼루션 결과
Fig. 6. Convolution results of bit plane

3.2 기준플랜 병렬가산 컨볼루션

기준플랜으로 분해하는 기준은 화소의 그레이 레벨이다. 그림 5에서 가정한 입력영상 패턴에서는 5

그레이레벨 즉 0, 1, 2, 3, 4가 존재하므로 4개의 기준플랜으로 분해된다. 그림 7에 4개의 기준플랜으로 분해한 이진영상을 나타냈다. 그림 8은 기준플랜의 컨볼루션 결과와 4개의 컨볼루션 결과를 더한 에지 검출 영상이다. 각각의 연산결과를 더하는 것만으로 컨볼루션 결과를 얻을 수 있다는 결론이다. 이는 각각의 입력에 의한 출력의 합은 전체입력에 의한 출력과 같다는 중첩의 원리가 성립하기 때문이다.

이와 같이 기준플랜으로 분해하여 컨볼루션을 수행하는 방법에서는 가산만으로 컨볼루션을 수행할 수 있다는 장점이 있다. 물론 256그레이스케일 영상에서는 최대 255개의 이진 입력영상 패턴이 존재한다. 이는 처리시간의 측면에서 장점이 되지 않는 것으로 해석할 수도 있으나, 병렬로 처리가 가능한 경우에는 처리시간의 측면에서 매우 큰 장점이 될 수 있다. 또한 256그레이스케일 영상에서 처리해야할 이진영상의 수는 최대 255개이나, 응용 분야 또는 학습결과에 따라 이진영상의 수를 다수 감소시키는 것이 가능하다.

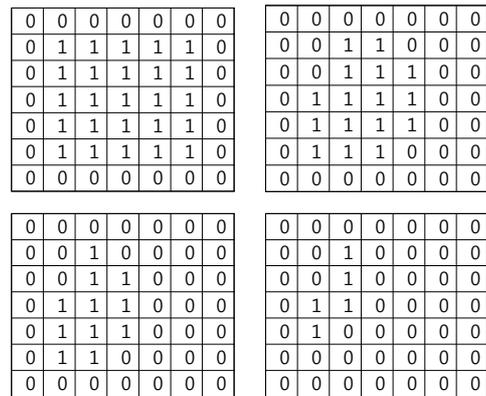
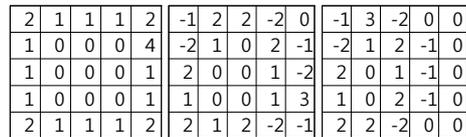


그림 7. 기준플랜
Fig. 7. Criterion-plane



-1	3	-1	0	0
-2	2	-1	0	0
2	2	-1	0	0
3	-2	0	0	0
-1	0	0	0	0

-1	9	0	-1	2
-5	4	1	1	0
7	2	0	0	-1
6	-2	2	0	4
5	4	1	-1	1

그림 8. 기준플랜 컨볼루션 결과
Fig. 8. Convolution results of criterion plane

4. 실험

인터넷에 공개되어 있는 영상 중에서 선택한 소녀영상을 대상으로 본 논문에서 제안한 병렬가산 컨볼루션 알고리즘의 유용성을 검증하였다. 그림 9에 224×224 컬러 테스트 영상과 R, G, B 성분으로 분해한 각각의 영상을 나타냈다.

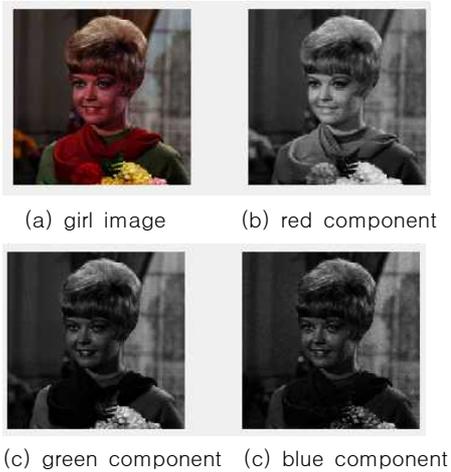


그림 9. 컬러 테스트 영상
Fig. 9. Color test image

딥러닝에서는 컬러영상을 R, G, B 성분으로 분해한 각각의 그레이스케일 영상을 처리하는 것이 일반적이다. Red 영상에 에지검출 커널을 적용하여 컨볼루션한 결과를 그림 10에 나타냈다.



그림 10. 소녀 Red 영상 컨볼루션
Fig. 10. Convolution of girl red image

기준플랜 병렬가산 컨볼루션 알고리즘을 적용하는 첫 번째 단계는 256 그레이레벨영상을 그레이레벨을 기준으로 이진영상의 중첩으로 분해하는 과정이다. 본 논문에서 사용한 소녀 red 영상에서의 그레이레벨의 최대치는 253이고 최소치는 0이다. 따라서 소녀 red 영상은 그레이레벨 기준치에 의거, 253개의 이진영상으로 분해할 수 있다. 그림 11에 그레이레벨이 50, 100, 150, 200 이상인 경우의 기준플랜을 나타냈다.

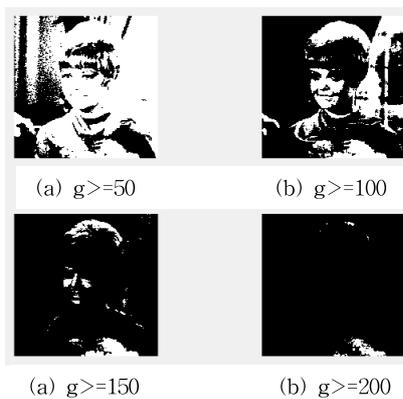


그림 11. 소녀 red 영상의 기준플랜
Fig. 11. Criterion-plane of girl image

테스트 영상인 소녀 red 영상의 경우, 253개의 2진영상인 기준플랜의 중첩으로 표현된다. 253개의 기준플랜을 병렬로 가산만을 사용해서 컨볼루션을 수행하는 것이 본 논문에서 제안한 알고리즘이다. 대표적으로 그레이레벨이 50, 100, 150, 200 이상인 경우의 기준플랜을 에지검출 커널로 컨볼루션한 결과를 그림 12에 나타냈다.

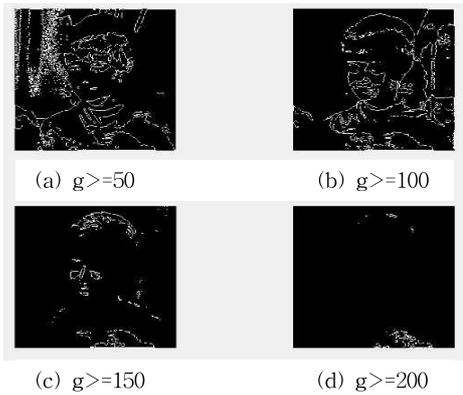


그림 12. 기준플랜의 컨볼루션
Fig. 12. Convolution of criterion-plane

소녀 red 영상의 기준플랜은 253개이므로 253개 각각을 에지검출 커널로 컨볼루션한 후, 컨볼루션 결과 모두를 합한 결과가 그레이스케일 영상을 컨볼루션한 결과이다. 그림 13에 비트플랜 병렬가산 컨볼루션 결과와 그레이스케일영상의 컨볼루션 결과를 나타냈다. 결과는 동일하다.

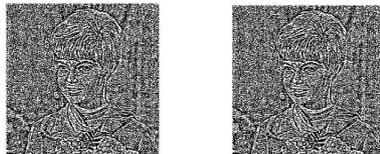


그림 13. 기준영상과 그레이스케일 영상의 컨볼루션
Fig. 13. Convolution results of criterion plane and grayscale image

본 논문에서는 그레이스케일 영상의 컨볼루션을 이진영상의 중첩으로 표현하여 가산만으로 병렬로 컨볼루션을 수행하는 알고리즘을 제안하였다. 병렬

가산의 경우, 승산이 모두 제거되므로 처리시간의 측면에서 큰 차이가 있다. 또한 VLSI 칩설계에서 승산기가 요구되지 않으므로 하드웨어 설계 분야에서 큰 장점이 있다. 컴퓨팅 파워가 보장되지 않는 임베디드 시스템에서의 딥러닝 구현에도 응용이 가능하다.

5. 결 론

딥러닝에서는 일반적으로 수십여개의 레이어에서 수십여개 이상의 커널로 컨볼루션을 수행한다. 컴퓨팅 파워가 보장되는 경우에는 컨볼루션 연산 시간이 문제가 되지 않지만 임베디드 시스템 등의 경우에는 처리시간의 문제 때문에 딥러닝 시스템의 구현이 불가능하다는 문제점이 있다. 따라서 입력영상 또는 커널 중 하나를 이진데이터로 변환하는 방법을 이용하여 승산이 없는 가산만으로 컨볼루션을 수행하는 방법을 제안하였다.

본 논문에서는 커널은 학습에 의해서 결정되는 부분으로 소수 이하의 부분이 존재하고, 그레이스케일 영상의 경우에는 0에서 255까지의 그레이레벨이 정수부분만 존재하므로 그레이스케일 영상을 이진영상으로 변환하는 방법을 사용하였다. 컨볼루션의 경우, 기준플랜 영상으로 분해하였을 경우에만 중첩의 원리가 성립하므로 기준플랜 영상으로 분해한 후, 병렬로 가산만을 이용하여 컨볼루션을 수행하는 방법을 제안하였다. 병렬로 수행할 경우 컨볼루션 단계는 동일하나 승산이 모두 제거되므로 컨볼루션 처리시간의 감소가 가능하다. 임베디드용 딥러닝 시스템 등에서 그 활용도가 매우 높을 것으로 판단된다.

REFERENCES

[1] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton, "ImageNet Classification with Deep Convolutional

Neural Networks”, Advances in Neural Information processing Systems 25, NIPS, 2012.

- [2] H. Lee, R. Grosse, R. Ranganath, and A.Y. Ng., “Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations”, Proceedings of the 26th Annual International Conference on Machine Learning, ACM, 2009.
- [3] Y. LeCun, K. Kavukcuoglu, and C. Farabet, “Convolutional networks and applications in vision”, International Symposium in Circuits and Systems(ISCAS), IEEE, 2010.
- [4] D. C. Ciresan, A. Giusti, L. M. Gambardella, and J. Schmidhuber. Deep neural networks segment neuronal membranes in electron microscopy images. In NIPS, 2012.
- [5] Tun-Wen Pai and John H.L. Hansen, “Bit Plane Decomposition and Shape Analysis for Morphological Skeletonization,” SPIE Vol.1818 Visual Communications and Image Processing, 1992.
- [6] Jongho, Choi and Jongsoo, Choi “A Morphological Recognition Algorithm of Blob Shaped Particles for Automated Visual Inspection”, Journal of KIISE, Vol. 21, No.5, May, 1994.

저자약력

최종호(Jong-Ho Choi)

[중신회원]



- 1982년 2월 : 중앙대학교 전자공학과(공학사)
- 1984년 2월 : 중앙대학교 대학원 전자공학과(공학석사)
- 1987년 2월 : 중앙대학교 대학원 전자공학과(공학박사)
- 1990년 3월 ~ 현재 : 강남대학교 IoT전자공학과 교수

<관심분야>

영상처리, 컴퓨터시각, 딥러닝