

## 계층적 CNN 구조를 이용한 스테가노그래피 식별

강상훈<sup>1</sup>, 박한훈<sup>1\*</sup>, 박종일<sup>2</sup>, 김산해<sup>3</sup>  
<sup>1</sup>부경대학교, <sup>2</sup>한양대학교, <sup>3</sup>국방과학연구소

### Identification of Steganographic Methods Using a Hierarchical CNN Structure

Sanghoon Kang<sup>1</sup>, Hanhoon Park<sup>1\*</sup>, Jong-Il Park<sup>2</sup>, Sanhae Kim<sup>3</sup>

<sup>1</sup>Pukyong National University, <sup>2</sup>Hanyang University, <sup>3</sup>Agency of Defense Development

**요약** 스테가노그래피(steganography)에 의해 숨겨진 데이터를 감지하고 복구하기 위한 기법이다. 스테가노그래피 방법은 데이터 삽입 시 발생하는 시각적, 통계적 변화를 분석하여 숨겨진 데이터를 찾는다. 숨겨진 데이터를 복원하기 위해서는 어떤 스테가노그래피 방법에 의해 데이터가 숨겨졌는지를 알아야 한다. 그러므로 본 논문은 다층 분류를 통해 입력 영상에 적용된 스테가노그래피 방법을 식별하는 계층적 CNN 구조를 제안한다. 이를 위해 4개의 기본 CNN을 각각 입력 영상에 스테가노그래피 방법이 적용되었는지 여부나 서로 다른 두 스테가노그래피 방법 중에 어떤 방법이 적용되었는지를 이진 판별하도록 학습시켰으며, 학습된 CNN을 계층적으로 연결하였다. 실험 결과를 통해 제안된 계층적 CNN 구조는 4개의 서로 다른 스테가노그래피 방법인 LSB(Least Significant Bit Substitution), PVD(Pixel Value Difference), WOW(Wavelet Obtained Weights), UNIWARD(Universal Wavelet Relative Distortion)을 79%의 정확도로 식별할 수 있음을 확인하였다.

• **주제어** : 스테가노그래피, CNN, 다층 분류, 계층적 구조, 비밀 데이터 복원

**Abstract** Steganalysis is a technique that aims to detect and recover data hidden by steganography. Steganalytic methods detect hidden data by analyzing visual and statistical distortions caused during data embedding. However, for recovering the hidden data, they need to know which steganographic methods the hidden data has been embedded by. Therefore, we propose a hierarchical convolutional neural network (CNN) structure that identifies a steganographic method applied to an input image through multi-level classification. We trained four base CNNs (each is a binary classifier that determines whether or not a steganographic method has been applied to an input image or which of two different steganographic methods has been applied to an input image) and connected them hierarchically. Experimental results demonstrate that the proposed hierarchical CNN structure can identify four different steganographic methods (LSB, PVD, WOW, and UNIWARD) with an accuracy of 79%.

• **Key Words** : Steganalysis, CNN, Multi-level classification, Hierarchical structure, Secret data recovery

Received 09 December 2019, Revised 26 December 2019, Accepted 30 December 2019

\* **Corresponding Author** Hanhoon Park, Department of Electronic Engineering, Pukyong National University, 45, Yongso-ro, Nam-gu, Busan, Korea. E-mail: hanhoon.park@pknu.ac.kr

## I. 서론

스테가노그래피(steganography)는 텍스트, 음성, 영상, 비디오와 같은 멀티미디어 매체에 비밀정보를 숨기는 기법이다. 영상 스테가노그래피는 영상의 픽셀 값을 조정해 제3자가 비밀정보의 삽입여부를 인식하지 못하게 데이터를 은닉한다. 이후 언급되는 스테가노그래피는 영상 스테가노그래피를 의미한다.

스테가노알리시스(steganalysis)는 스테가노그래피가 적용된 영상을 검출하고, 숨겨진 비밀정보를 복원하는 기법이다. 일반적으로 원 영상인 커버(cover) 영상과 스테가노그래피가 적용된 영상인 스테고(stego) 영상의 시각적, 통계적 차이를 탐지해 스테가노그래피의 적용 여부를 판별한다. 최근 스테가노알리시스 방법은 CNN(Convolutional Neural Network) 기반의 분류기를 사용한다[1]. CNN 기반의 분류기는 입력 영상으로부터 자동으로 판별에 적합한 특징을 추출할 수 있기 때문에, SRM[2]과 같이 미리 설계된 방법으로 특징을 추출하는 기존의 스테가노알리시스 방법에 비해 높은 정확도로 스테가노그래피가 적용된 영상을 판별할 수 있다.

그러나 현재 보고된 대부분의 스테가노알리시스 방법은 입력 영상에 대해 스테가노그래피의 적용 여부를 검출하는 데 초점을 두고 있기 때문에, 숨겨진 비밀정보를 복원하는 데는 활용되기 어렵다. 숨겨진 비밀정보를 복원하기 위해서는 영상에 적용된 스테가노그래피 방법의 식별 또는 분류가 필요하다. 하지만 스테가노그래피가 적용된 영상들은 스테가노그래피 방법에 관계없이 데이터의 삽입으로 인한 데이터의 변화(또는 왜곡)정도가 작고 방법에 따른 차이도 크지 않다. 그러므로, CNN 기반 분류기를 활용하더라도 복수의 스테가노그래피 방법을 분류하는 것은 매우 어렵다.

본 논문에서는 이진(binary) CNN 기반 분류기를 계층적으로 연결하여 복수의 스테가노그래피 방법을 검출하고 식별/분류하기 위한 방법을 제안한다.

## II. 관련 연구

최근 스테가노알리시스 방법은 WOW[3], UNIWARD[4]와 같이 보다 정교해진 스테가노그래피 방법을 탐지하기 위해 CNN 기반의 딥러닝 방법을 활용한다. Xu와 Wu에 의해 초기 CNN 기반 스테가노알리시스 방법[1]이 제안되었으며, 이후 구조가 변형되고

성능이 향상된 다양한 CNN 기반 스테가노알리시스 방법들이 제안되어왔다. CNN은 입력 영상으로부터 자동으로 필요한 특징을 추출할 수 있기 때문에, CNN 기반 스테가노알리시스 방법은 미리 설계된 방법으로 특징을 추출하는 기존의 스테가노알리시스 방법에 비해 높은 정확도를 가지며, 커버/스테고 이진 분류에서 약 80-90%의 정확도를 보였다.

그림 1은 Xu와 Wu에 의해 제안된 CNN 구조이다. 입력 영상을 받아 먼저 하나의 고주파 필터(HPF)로 전처리(preprocessing)한다. 이후 합성곱(Conv), 배치 정규화(BN), 비선 형성을 부여하는 활성화 함수(TanH, ReLU)를 거쳐 영상의 세부적인 특징을 추출한다. 한 장의 영상으로 시작하여 매 합성곱 계층마다 특징맵(feature map)의 수가 첫 번째 계층에서는 8장, 그 이후로는 2배씩 증가하며, 풀링(Average Pooling, Global Pooling)에서 영상의 크기가 감소된다.  $512 \times 512$  크기의 입력 영상으로부터 총 128 장의  $1 \times 1$  크기의 특징맵이 얻어지며, 얻어진 특징맵은 마지막 완전연결계층(Fully Connection)과 소프트맥스(Softmax)계층을 거치면서 입력 영상이 커버 영상인지 스테고 영상인지에 대한 확률 값이 도출된다.

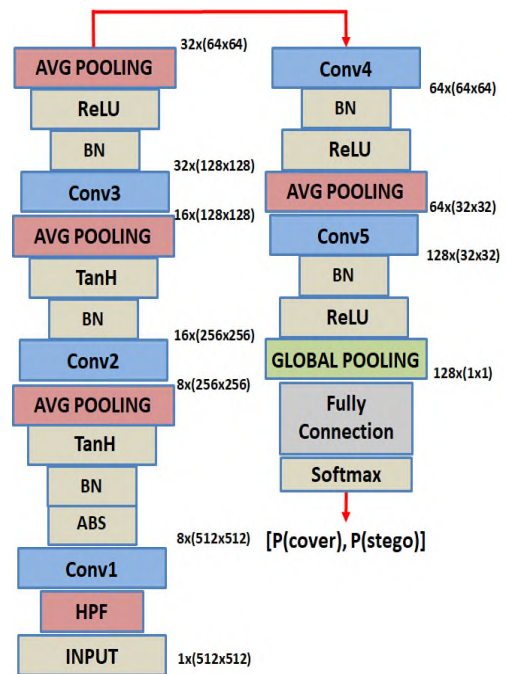


Fig. 1. Steganalytic CNN proposed by Xu and Wu

CNN 기반 분류기는 합성곱 연산을 통해 영상의 세밀한 특성을 추출하고 학습된 파라미터를 이용해 데이터를 분류한다. CNN 기반의 분류기는 기존의 머신러닝 기반 방법들에 비해 비교적 간단한 구조를 가지면서 동시에 높은 성능을 지닌다.

### III. 스테가노그래피의 특성

스테가노그래피 방법은 송신자와 수신자만 공유하는 특정한 알고리즘을 통해 영상의 픽셀 값을 미세 조정해 데이터를 삽입하기 때문에, 제3자는 데이터의 삽입 여부를 인식하거나, 삽입된 데이터를 복원하는 것은 매우 어렵다. 기존의 CNN 기반 스테그아날리시스 방법은 커버/스테고에 대한 이진 분류를 통해 데이터의 삽입 여부만을 검출하기 때문에, 동일 구조를 가지고 복수의 스테가노그래피 방법을 식별/분류하기 위해 분류해야 할 클래스의 수를 증가시키면 학습이 불가능하거나 특정 클래스로 오버피팅(overfitting)되는 문제가 발생할 수 있다.

#### 3.1 스테가노그래피 적용에 의한 영상 변화

스테가노그래피를 이용해 영상에 데이터를 삽입할 경우 픽셀 값의 변화, 통계적 수치의 변화와 같은 영상 왜곡이 발생한다. 스테가노그래피 방법에 따라 영상의 왜곡 정도는 달라진다. 하지만 스테가노그래피 방법은 제3자에게 데이터의 삽입 여부를 인식하지 못하게 미세하게 삽입하기 때문에 데이터의 삽입으로 인한 왜곡을 최소화한다.

표 1은 그림 2의 10 장의  $256 \times 256$  영상에 대해서도 다른 스테가노그래피 방법으로 데이터를 삽입했을 때의 픽셀 값의 평균 변화 및 PSNR 값을 보여준다. PSNR 값은 스테가노그래피의 적용으로 인한 픽셀 값의 상대적인 변화 정도를 나타내며, PSNR 값이 클수록 커버 영상과 스테고 영상 사이의 차이가 적음을 의미한다. 일반적으로 30dB 이상의 PSNR 값을 가질 경우 시각적으로 구분이 불가능하다. 표 1의 픽셀 값의 절대적인 변화를 보더라도 PVD에 의한 변화가 약 0.62 정도로 가장 크지만, 모든 방법에 대해 변화 정도가 매우 작음을 알 수 있다.

Table 1. Pixel value variation and PSNR of stego image created by different steganographic methods

| Method  | Absolute variation | PSNR (dB) |
|---------|--------------------|-----------|
| LSB     | 0.1987             | 55.12     |
| PVD     | 0.6198             | 43.88     |
| WOW     | 0.0557             | 59.25     |
| UNIWARD | 0.0795             | 59.36     |



Fig. 2. Images used in generating the results of Table 1

#### 3.2 WOW와 UNIWARD의 유사도

그림 3은 커버 영상과 각 스테가노그래피 방법에 의해 생성된 스테고 영상에 대해 이웃하는 픽셀 사이의 픽셀 차이 값에 대한 히스토그램(스테그아날리시스 방법에서 활용되는 통계적 정보)이다. LSB[5]와 PVD[6]는 영상 전반에 걸쳐 상대적으로 픽셀 변화가 큰 데이터 삽입을 수행하기 때문에 생성된 스테고 영상의 경

우 커버 영상과의 히스토그램의 차이가 크고 상대적으로 쉽게 검출될 수 있다. 이와 달리 WOW와 UNIWARD는 영상의 각 픽셀에 +1, -1의 변화만을 발생시키며 주변 픽셀과의 변화 정도를 계산해 변화 정도가 일정 기준보다 작은 픽셀에만 데이터를 삽입한다. 그러므로 WOW와 UNIWARD를 이용한 데이터 삽입에 의한 픽셀 변화는 매우 작으며(표 1), WOW 스테고 영상과 UNIWARD 스테고 영상의 히스토그램은 커버 영상의 히스토그램과 거의 차이가 없다(그림 3). WOW와 UNIWARD의 이러한 특성은 기존의 스테가노그래피 방법들에 비해 검출을 어렵게 한다.




Fig. 3. Pixel value difference between neighboring pixels

WOW와 UNIWARD는 데이터의 삽입으로 인한 변화 정도를 계산해 데이터를 삽입하는 유사한 방법을 사용한다. 이로 인해 WOW와 UNIWARD는 높은 유사도를 지닌다. 표 2는 동일한 CNN 구조와 실험 조건에 대해서 커버 영상과 WOW 스테고 영상, 커버 영상과 UNIWARD 스테고 영상을 이진 분류하도록 각각 학습시킨 두 이진 분류기에 각각 WOW 스테고 영상과 UNIWARD 스테고 영상을 입력으로 주었을 때의 분류 결과를 보여준다. WOW 스테고 영상으로 학습한 이진 분류기에 UNIWARD 스테고 영상을 입력으로 주었을 때의 정확도는 약 67%, UNIWARD 스테고 영상으로 학습한 이진 분류기에 WOW 스테고 영상을 입력으로 주었을 때의 정확도는 약 61%의 결과를 보였다. 이는 낮은 정확도로, WOW와 UNIWARD 사이의 유사도가 높음을 의미한다.

Table 2. Cross classification rates [%] of WOW and UNIWARD

| Training/Testing | Cover | WOW  | UNIWARD | Mean |
|------------------|-------|------|---------|------|
| WOW/WOW          | 77.6  | 78.3 | -       | 77.9 |
| WOW/UNIWARD      | 77.6  | -    | 67.1    | 72.4 |
| UNIWARD/UNIWARD  | 84.0  | -    | 73.6    | 78.8 |
| UNIWARD/WOW      | 84.0  | 60.5 | -       | 72.3 |

### 3.3 다중 분류의 한계

CNN 기반 분류기는 많은 양의 데이터를 통해 클래스 사이의 차이를 학습한다. 일반적인 분류 문제의 경우 클래스 간의 차이는 크기 때문에 클래스의 수가 증가해도 분류에 큰 어려움은 없다. 하지만 스테그아날리시스의 경우, 일반적인 분류 문제에 비해 클래스 사이의 차이가 매우 작다. 이를 개선하기 위해 기존의 스테그아날리시스 방법은 커버 영상과 스테고 영상의 차이를 크게 하기 위해 CNN을 적용하기 전에 입력 영상에 고주파 필터를 적용했다. 그러나 분류해야 하는 스테가노그래피 방법의 수가 증가할수록 분류 성능이 급격히 떨어지며, 학습 자체가 불가능해 질 수 있다.

기존 이진(커버/스테고) 분류를 위해 개발된 CNN 기반 스테그아날리시스 방법을 이용하여 복수의 스테가노그래피 방법을 분류하는 예비 실험을 진행했다. 기본적으로 3개의 클래스(커버, 스테고 #1, 스테고 #2), 즉 두 개의 서로 다른 스테가노그래피 방법이 적용된 영상을 분류하는 것은 이진 분류 성능과 큰 차이를 보이지 않았다. 하지만 클래스의 수를 더 늘릴 경우, 특정 스테가노그래피 방법을 분류할 수 없거나, 일부 스테가노그래피 방법만 높은 정확도를 가지고 분류하는 오버피팅 문제가 발생했다. 이러한 경향은 학습 횟수가 증가할수록 악화되었다. 이는 CNN 기반 스테그아날리시스 방법에서 기존의 단일 구조 CNN을 이용할 경우, 분류 가능한 클래스의 수가 제약되는 것을 알 수 있다.

## IV. 제안 방법

본 논문에서는 입력 영상에 대해 5개의 클래스(커버 영상, LSB 스테고 영상, PVD 스테고 영상, WOW 스테고 영상, UNIWARD 스테고 영상)로 분류하는 방법을 제안한다. 스테가노그래피 방법의 차이에 의한 스테고 영상 사이의 차이는 크지 않다. 이는 CNN 기반 분류




Fig. 4. Proposed hierarchical CNN structure

기를 사용하더라도 쉽지 않은 이유이며, 앞서 언급한 대로 클래스의 수가 늘어날 경우 분류 성능은 크게 떨어진다. 따라서 스테고 영상과 같이 유사도가 매우 높은 영상의 분류를 위해서는 한 번에 분류해야 할 클래스의 수를 적절히 조절해야 할 필요가 있다.

본 논문에서는 5개의 클래스 분류를 위한 여러 개의 CNN을 계층적으로 구성하는 방법을 제안한다. 제안 방법은 기본적으로 그림 1과 동일한 이진 분류 CNN을 사용한다. 각 CNN은 입력된 256x256의 영상을 SRM 필터로부터 선택된 10개의 고주파 필터[7]를 이용해 입력 영상을 전처리하고, 여러 단계의 합성곱, 풀링, 정규화 처리를 통해 최종적으로 1,920 장의 특징 맵을 생성하여 학습하며, 마지막 softmax 층을 거쳐 두 클래스의 확률을 도출한다.

총 4개의 이진 분류 CNN을 이용하여 커버와 스테고 분류, 스테가노그래피 방법 군 분류, 각 스테가노그래피 방법을 식별하기 위해 개별적으로 학습되며, 학습된 CNN은 그림 4와 같이 계층적으로 연결하였다. 결과적으로 입력 영상(X)이 주어지면, 먼저 Net #1을 통해 커버 영상인지 스테고 영상인지 분류를 한다. 커버 영상일 경우 영상에 COVER 라벨을 부여한다. 스테고 영상일 경우 다시 Net #2을 통해 스테가노그래피 방법 군을 분류한다. 방법 군은 데이터 삽입 형태에 따라 LSB와 PVD를 묶어 HANDY, WOW와 UNIWARD를 묶어 EDGE라고 명명했다. Net #2에서 분류된 각 방법 군에 대해 마지막으로 Net #3과 Net #4에서 각각의 스테가노그래피 방법을 식별한다. Net #3는 LSB와 PVD를 분류하고, Net #4는 WOW와 UNIWARD를 분류한다.

### V. 실험 결과

제안 방법의 성능을 분석하기 위해 그림 1의 구조

를 가지는 CNN을 LSB, PVD, WOW, UNIWARD 각 스테가노그래피 방법 별로 BOSSbase[8]의 영상을 4등분하여 30,000 장의 256 × 256영상을 이용해 200,000 번의 학습을 진행했다. 학습 결과의 검증을 위해 각 10,000장의 영상을 이용하여 분류 정확도를 분석했다.

표 3은 각 스테가노그래피 방법에 대한 커버/스테고 이진 분류의 결과이다. LSB와 PVD는 분류가 상당히 잘 되나 WOW와 UNIWARD는 상대적으로 낮은 분류 정확도를 보인다. 그러나 그림 1의 CNN을 이용할 경우 이진 분류에서는 우수한 성능을 가짐을 알 수 있다. 반면, 표 4에서 보는 것처럼, 그림 1의 CNN(단일 구조)을 이용하여 5 개의 클래스(커버, LSB 스테고, PVD 스테고, WOW 스테고, UNIWARD 스테고)를 분류하면, 성능이 크게 떨어졌다. 특히, PVD에 대한 분류 정확도가 매우 낮았으며, 이러한 경향은 학습 횟수를 증가시킬수록 더욱 심화되었다.

Table 3. Binary classification rates [%] of the CNN in Fig. 1

| Method  | Cover | Stego | Mean |
|---------|-------|-------|------|
| LSB     | 97.1  | 97.3  | 97.2 |
| PVD     | 99.7  | 99.9  | 99.8 |
| WOW     | 83.3  | 75.2  | 79.2 |
| UNIWARD | 76.5  | 77.4  | 77.0 |

Table 4. *N*-ary (*N* = 5) classification rates [%] of the CNN in Fig. 1 and the proposed hierarchical CNN structure

| Class         | CNN in Fig. 1 | Proposed |
|---------------|---------------|----------|
| Cover         | 68.6          | 78.1     |
| LSB stego     | 95.3          | 97.4     |
| PVD stego     | 22.5          | 99.8     |
| WOW stego     | 77.5          | 49.2     |
| UNIWARD stego | 81.8          | 71.0     |
| Mean          | 69.1          | 78.7     |

표 4에서 보는 것처럼 제안된 계층적 CNN 구조를 이용할 경우 정확도가 크게 향상되었다(약 10%). 다만, WOW에 대한 분류 정확도가 낮게 나왔는데, 이는 Net #1과 Net #2의 오차가 누적된 것과 WOW와 UNIWARD 사이의 유사도 때문인 것으로 판단된다. 따라서 Net #4의 구조를 개선하여 WOW와 UNIWARD의 분류 성능을 향상시킬 필요가 있다. 또한 본 논문에서는 제안된 계층적 CNN 구조를 구성하기 위해 동일한 CNN을 사용했으나, 각 CNN의 목적이 다르기 때문에 서로 다른 CNN을 사용함으로써 성능 향상을 도모할 수 있을 것이다.

## VI. 결론

스테가노그래피 방법으로 숨긴 정보를 복원하기 위해서는 적용된 스테가노그래피 방법의 분류가 필수적이다. 단일 CNN 기반의 스테가노그래피는 스테가노그래피의 적용 여부 검출에는 매우 효과적이거나, 스테가노그래피 방법 사이 유사도가 높고 스테가노그래피 방법 적용에 의한 영상 변화가 작기 때문에 복수의 방법을 동시에 분류하는 데는 적용하기 어렵다. 제안 방법은 기존 CNN을 계층적으로 구성하여 5개의 클래스(커버, LSB 스테고, PVD 스테고, WOW 스테고, UNIWARD 스테고)를 효과적으로 분류함으로써, 크게 향상된 정확도로 복수의 스테가노그래피 방법을 식별할 수 있었다.

그러나 앞서 언급한 것처럼, 제안 방법은 계층적인 CNN 구조를 이용한 분류이기 때문에 각 단계별로 최적화된 별도의 CNN을 사용할 수 있다. 그러므로 추후 각 스테가노그래피 방법을 분류하는 데 보다 최적화된 CNN을 사용하여 전체적인 분류 정확도의 개선을 기대할 수 있을 것이다. 또한 계층적인 구조에서는 앞 단의 오 분류로 인한 오차의 증가가 발생할 수 있다. 이는 현 계층 구조의 분류 결과를 분석해 오 분류되는 데이터의 특성을 바탕으로 우회로를 연결, 의심되는 데이터를 하위계층에서 다시 분류하는 방법을 통해 개선할 수 있을 것이다.

본 논문에서는 4개의 대표적인 스테가노그래피 방법에 대해서만 논의했으나, 향후 보다 많은 수의 스테가노그래피 방법에 대한 고려가 필요하다.

## ACKNOWLEDGMENTS


본 연구는 방위사업청 및 국방과학연구소의 재원에 의해 설립된 신호정보 특화연구센터 사업의 지원을 받아 수행된 것임.

## REFERENCES

- [1] G. Xu and H. Wu, "Structure design of convolution neural networks for steganalysis," *IEEE Signal Processing Letters*, vol. 23, no. 5, pp. 708-712, 2016.
- [2] J. Fridrich and J. Kodovský, "Rich models for steganalysis of digital images," *IEEE Trans. Inf. Foren. Security*, vol. 7, no. 3, pp. 868-882, Jun. 2012.
- [3] V. Holub and J. Fridrich, "Designing steganographic distortion using directional filters," *IEEE Workshop on Information Forensic and Security*, 2012.
- [4] V. Holub, J. Fridrich, and T. Denemark, "Universal distortion function for steganography in an arbitrary domain," *EURASIP J. on Information Security*, 2014.
- [5] C. Chan and L. Cheng, "Hiding data in images by simple LSB substitution," *Pattern Recognition*, 37(3), 469-474, 2004.
- [6] D. Wu and W. Tsai, "A steganographic method for images by pixel-value differencing," *Pattern Recognition*, 24, 1613, 2003.
- [7] S. Kang, H. Park, and J.-I. Park, "CNN-based ternary classification for image steganalysis," *Electronics*, vol. 8, no. 11, 1225, 2019.
- [8] P. Bas, T. Filler, and T. Pevny, "Break our steganographic system - the ins and outs of organizing BOSS," *International Workshop on Information Hiding*, pp. 59-70, 2011.

## 저자 소개

### 강 상 훈 (Sang-Hoon Kang)



2018년 8월 : 부경대학교  
전자공학과(공학사)  
2018년 9월 ~ 현재 : 부경대학교  
전자공학과(공학석사)  
관심분야 : 머신러닝, AI

### 김 산 해 (Sanhae Kim)



2000년 02월 : 숭실대학교  
전자공학과(공학사)  
2002년 02월 : 숭실대학교  
전자공학과(공학석사)  
2010년 08월 : 숭실대학교  
전자공학과(공학박사)  
2011년 01월 ~ 현재 :  
국방과학연구소(ADD) 선임연구원  
관심분야 : 전자전, 신호처리, 위치탐지 등

### 박 한 훈 (Hanhoon Park)



2000년 02월 : 한양대학교  
전자통신전파공학과(공학사)  
2002년 02월 : 한양대학교  
전자통신전파공학과(공학석사)  
2007년 08월 : 한양대학교  
전자통신전파공학과(공학박사)  
2012년 03월 ~ 현재 : 부경대학교

전자공학과 교수

관심분야 : 증강현실, 인간컴퓨터상호작용,  
컴퓨터비전/그래픽스

### 박 종 일 (Jong-Il Park)



1987년 02월 : 서울대학교  
전자공학과(공학사)  
1989년 02월 : 서울대학교  
전자공학과(공학석사)  
1995년 02월 : 서울대학교  
전자공학과(공학박사)  
1992년 ~ 1994년 :

일본NHK방송기술연구소 객원연구원

1995년 ~ 1996년 : 한국방송개발원 선임연구원

1996년 ~ 1999년 : 일본 ATR지능영상통신연구소 연구원

1999년 ~ 현재 : 한양대학교 공과대학 컴퓨터공학부  
교수

관심분야 : 증강현실, 계산사진학, 3차원 컴퓨터비전,  
인간컴퓨터상호작용