

일반논문 (Regular Paper)

방송공학회논문지 제24권 제2호, 2019년 3월 (JBE Vol. 24, No. 2, March 2019)

<https://doi.org/10.5909/JBE.2019.24.2.315>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

구조적인 차이를 가지는 CNN 기반의 스테그아날리시스 방법의 실험적 비교

김재영^{a)}, 박한훈^{a)*}, 박종일^{b)}

Experimental Comparison of CNN-based Steganalysis Methods with Structural Differences

Jaeyoung Kim^{a)}, Hanhoon Park^{a)*}, and Jong-Il Park^{b)}

요 약

영상 스테그아날리시스는 입력 영상을 스테가노그래피 알고리즘이 적용된 스테고 영상과 스테가노그래피 알고리즘이 적용되지 않은 커버 영상으로 분류하는 알고리즘이다. 기존에는 주로 수제 특징 기반의 스테그아날리시스를 연구하였다. 하지만 CNN 기반의 물체 인식이 큰 성과를 이루면서 최근 CNN 기반의 스테그아날리시스가 활발히 연구되고 있다. CNN 기반의 스테그아날리시스는 물체 인식과는 달리 커버 영상과 스테고 영상의 미세한 차이를 식별하기 위해서 전처리 필터를 필요로 한다. 그러므로, CNN 기반의 스테그아날리시스 연구들은 효과적인 전처리 필터와 네트워크 구조를 개발하는 데 초점을 두고 있다. 본 논문에서는 동일한 실험 조건에서 기존 연구들을 비교하고, 그 결과를 기반으로 전처리 필터와 네트워크 구조적인 차이에 의한 성능 변화를 분석한다.

Abstract

Image steganalysis is an algorithm that classifies input images into stego images with steganography methods and cover images without steganography methods. Previously, handcrafted feature-based steganalysis methods have been mainly studied. However, CNN-based objects recognition has achieved great successes and CNN-based steganalysis is actively studied recently. Unlike object recognition, CNN-based steganalysis requires preprocessing filters to discriminate the subtle difference between cover images from stego images. Therefore, CNN-based steganalysis studies have focused on developing effective preprocessing filters as well as network structures. In this paper, we compare previous studies in same experimental conditions, and based on the results, we analyze the performance variation caused by the differences in preprocessing filter and network structure.

Keyword : Image steganography, CNN-based steganalysis, preprocessing filter, CNN structure, experimental comparison

a) 부경대학교 전자공학과(Department of Electronic Engineering, Pukyong National University)

b) 한양대학교 컴퓨터소프트웨어학부(Department of Computer Science)

* Corresponding Author : 박한훈(Hanhoon Park)

E-mail: hanhoon_park@pknu.ac.kr

Tel: +82-51-629-6225

ORCID: <https://orcid.org/0000-0002-6968-4565>

* 이 연구는 방위사업청 및 국방과학연구소의 재원에 의해 설립된 신호정보 특화연구센터 사업의 지원을 받아 수행되었음.

* This work was supported by the research fund of Signal Intelligence Research Center supervised by Defense Acquisition Program Administration and Agency for Defense Development of Korea.

· Manuscript received December 31, 2018; Revised February 18, 2019; Accepted February 18, 2019.

Copyright © 2019 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

1. 서론

스태가노그래피(steganography)는 정보 은닉의 개념 중 한 가지로 제 3자가 비밀 정보의 존재 사실 자체를 알지 못하도록 그 정보를 미디어에 내부에 숨기는 것을 의미한다. 그래서 정보를 삽입하기 위한 기반이 되는 미디어의 훼손을 최소화하여 제 3자가 인위적이거나 이질적인 느낌을 느끼지 않도록 미디어의 원본 상태를 유지하면서 정보를 삽입하기 위한 많은 알고리즘들이 연구되어왔다. 스태가노그래피는 다양한 미디어(영상, 비디오, 텍스트, 오디오 등)에 적용할 수 있지만, 특히 영상에 대한 스태가노그래피들이 많이 연구되었다. 초기에는 단순히 LSB(least significant bits)^[8]를 바꾸어 정보를 삽입하였고 좀 더 많은 정보를 삽입하기 위해서 이웃 픽셀 값의 차이를 이용하여 영상의 위치에 따라서 적응적으로 삽입 가능한 정보의 양을 조절할 수 있는 PVD(pixel valued differencing)^[9], Multiway-PVD^[10-11], Layered-PVD^[37] 등의 방법들이 제안되었다. PVD와 Multiway-PVD 등의 알고리즘을 이용할 경우 삽입할 수 있는 정보의 양이 늘어났지만 그에 비례해서 삽입 전의 커버(cover) 영상과 삽입 후의 스테고(stego) 영상 간의 왜곡 정도가 증가하였다. 여기에 더하여 블록 매칭^[38] 기반의 스태가노그래피 방법 또한 연구되었다. 위의 스태가노그래피 기법들(LSB, PVD, Multiway-PVD, Layered-PVD, 블록 매칭)은 영상 각각의 특성을 고려하지 않고 단지 정보를 삽입 순서에 따라서 균일한 확률로 삽입을 하는 특성을 가졌기 때문에 스태가노그래피 알고리즘을 검출하는 기술인 스테그아널리시스(steganalysis)에 취약했다. 그래서 이러한 약점을 극복하기 위해서 HUGO^[12], WOW^[13], S-UNIWARD^[14] 등과 같이 영상의 특성을 고려하여서 고주파수 성분이 많은 영역(즉 텍스트, 엷지 등)에 집중적으로 삽입함으로써 스테그아널리시스에 의한 검출을 어렵게 하는 스태가노그래피 기법들이 연구되었다.

스태가노그래피의 연구와 함께 초기의 스테그아널리시스는 커버 영상과 스테고 영상의 통계적인 특성을 이용한 수제(handcrafted) 특징들을 영상으로부터 획득하고 기계학습 알고리즘을 사용하여 커버 영상과 스테고 영상을 분류하였다. 수제 특징들로는 ALE^[15], SPAM^[16,39], SRM^[17] 등이

있다. 이 중에서 SPAM은 그림 1과 같이 커버 영상에 비해 LSB 기반 알고리즘이 적용된 스테고 영상의 이웃 픽셀 값 차이가 증가한다는 통계적인 특성을 이용하여 수직/수평/대각 방향에 대한 2차 동시 발생 행렬(co-occurrence matrix)을 이용하여 특징을 추출하고 SVM(support vector machine)^[26] 알고리즘을 이용하여 분류하였다. SRM(spatial rich model)은 다양한 선형/비선형의 필터를 사용하여 영상에 존재하는 저주파수 영역과 고주파수 영역에 따라서 좋은 특징을 추출할 수 있도록 설계된 필터이다. 이 필터로부터 10000차원 이상의 특징을 획득하는데 전체 특징을 SVM과 같은 알고리즘에 적용할 경우 학습 속도가 느리기 때문에 각 필터로부터 획득된 특징을 FLD(Fisher's linear discriminant)^[18] 알고리즘을 이용하여 수십 개의 분류기를 생성하고 이를 랜덤 포레스트(random forest) 알고리즘을 이용한 앙상블(ensemble) 학습^[19]을 통해서 통합된 분류기를 생성하였다.

최근 딥러닝 기술 중에서 CNN(convolutional neural network)^[20-22,30]이 영상의 분류 문제에 있어서 효과적으로 영상의 특징을 추출한다는 점이 CIFAR^[31], ILSVRC^[32] 등의 영상 인식 대회에서 검증이 되었다. 특히 AlexNet^[21]을 통해 수제 특징 기반의 영상 분류 모델^[33]보다 CNN 기반의 딥러닝이 특징의 추출과 분류에 대한 뛰어난 성능을 보여준다는 것을 확인할 수 있었다. 이후로 VGG^[30]과 같이 CNN 기반의 딥러닝 모델들이 분류 문제를 해결하기 위해서 주로 사용되고 있다. 영상 스테그아널리시스 분야에서도 이런 우수한 특징 추출 및 분류의 성능을 효과적으로 활용하기 위한 스테그아널리시스 방법들^[1-7]이 연구되고 있다. 하지만 CIFAR 10 데이터 셋과 같은 기존의 일반적인 물체 분류 문제와는 다르게 스테그아널리시스는 커버 영상과 스테고 영상 사이의 아주 미세한 스테고 신호를 추출할 필요가 있기 때문에 기존의 CNN 분류와는 차이가 있다. 기존의 CNN은 물체의 두드러진 특징들을 추출하여 분류했지만 CNN 기반의 스테그아널리시스에서는 스테고 신호의 세기 때문에 방법이 제한되어 입력에 가까운 계층일수록 영상의 정보를 유지하기 위해서 풀링(pooling)이나 큰 스트라이드(stride)를 가지는 합성곱의 사용이 제한된다. 이를 해결하기 위해 최근 발표된 논문들에서 여러 가지 알고리즘을 조합하여 검출

를 향상시키기 위한 방법을 제시했지만 각 방법은 특정, 제한적인 실험 결과만을 제시하고 있어 상호 간의 성능을 비교, 분석을 하는 것은 쉽지 않다. 그러므로, 본 논문에서는 최근 발표된 CNN 기반 스테그아날리시스 방법에 대하여 BOSSBase 1.01^[23] 데이터 셋을 활용하여 동일한 실험(영상의 크기와 알고리즘, payload 등) 환경을 설정하고, 각 방법의 구조적인 차이로부터 나타나는 성능을 실험적으로 비교, 분석한다.

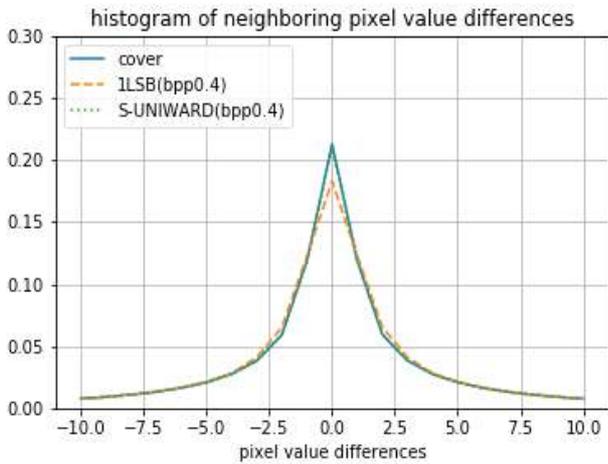


그림 1. BOSSBase 데이터 셋의 1,000장의 커버 영상과 1LSB(bpp = 0.4), S-UNIWARD(bpp = 0.4)에 의한 스테고 영상의 이웃 픽셀 사이의 값 차이 분포

Fig. 1. Histogram of neighboring pixel value differences of 1,000 cover images in BOSSBase data sets and their stego images made by 1LSB(bpp = 0.4) and S-UNIWARD(bpp = 0.4)

II. 관련 기술

CNN은 기존의 인공 신경망에 합성곱 계층을 추가한 알고리즘으로 합성곱 계층으로부터 자동으로 특징을 추출하고 추출한 특징을 완전연결 계층을 통해서 분류한다. CNN의 이러한 특성 때문에 분류 문제에 강점을 보이며 CIFAR-10 등의 대회에서 수제 특징에 의한 분류 모델들보다 대부분 좋은 결과를 보였다. 하지만 일반적인 물체 분류와는 달리 스테그아날리시스 문제는 영상 내부의 아주 미세한 스테고 신호를 추출해야한다는 어려움이 존재하고 구조적인

최적화를 위해서 많은 연구들이 시도되고 있다. 그래서 실제 CNN 기반의 스테그아날리시스의 비교와 분석을 다루기에 앞서 2절에서는 CNN의 기본구조와 스테가노그래피, 스테그 아날리시스에 대해서 소개한다.

1. CNN(convolutional neural network)

CNN은 기존의 신경망에서 사용자 정의 필터를 사용한 합성곱 계층이 추가된 딥러닝 알고리즘으로 기존의 신경망이 각 계층간에 완전 연결(fully connected)된 가중치의 학습을 통해서 전체 구조를 학습시킨다면 CNN은 각 계층에 사용자 정의된 필터와 입력의 합성곱을 하고 정의된 필터의 가중치를 학습시킨다. 그림 2와 같이 완전 연결 계층의 경우에 n -계층의 각 노드는 5개의 가중치를 갖게 되고 20개의 가중치가 소요된다. 반면에 합성곱 계층의 경우에는 초기에 정의된 필터의 크기 3과 필터의 수 2에 의해서 총 6개의 가중치만을 필요로 한다. 이러한 특성은 입력되는 정보가 고차원일수록 많은 컴퓨터 성능을 요구하는 기존의 신경망에 비해서 CNN이 많은 이점을 갖는다. 특히 영상 내부의 스테고 잡음을 추출하기 위한 스테그아날리시스 문

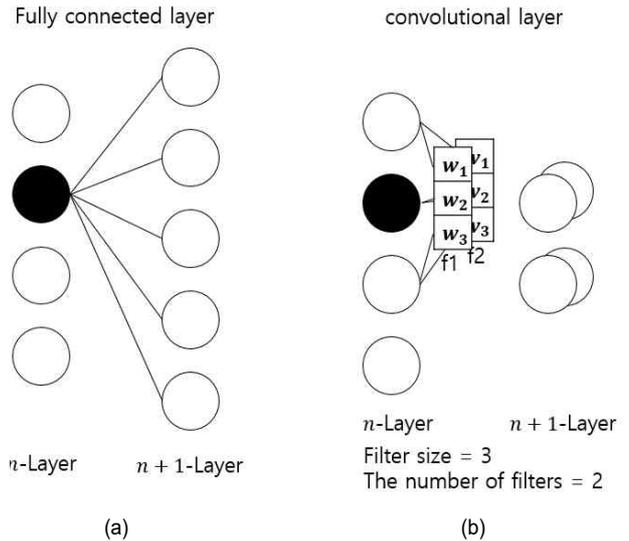


그림 2. 1차원 입력을 가지는 신경망의 계층. (a) 완전 연결 계층, (b) 합성곱 계층
 Fig. 2. Layers in 1D-input neural network. (a) Fully connected layer, (b) convolutional layer

제의 경우에 영상 전체를 입력으로 사용하는 고차원 입력을 갖기 때문에 효과적이라고 볼 수 있다. 완전 연결 계층으로만 이루어진 신경망의 경우에 각 계층의 노드의 수를 사용자가 할당하면 각 계층의 구성이 끝나는 반면에 합성곱 계층의 경우에 초기의 입력 정보와 각 합성곱 계층별로 구성된 필터의 크기와 그 채널수에 의해서 다음 계층의 입력 정보의 차원과 채널이 결정된다. 패딩 크기, 필터의 크기, 스트라이드, 필터의 수를 각 P, H, S 라고 할 때 입력과 출력 값의 차원 I, O 의 관계는 식 1과 같다(그림 3 참조). 출력된 크기가 O 인 필터의 채널 수는 C 가 된다.

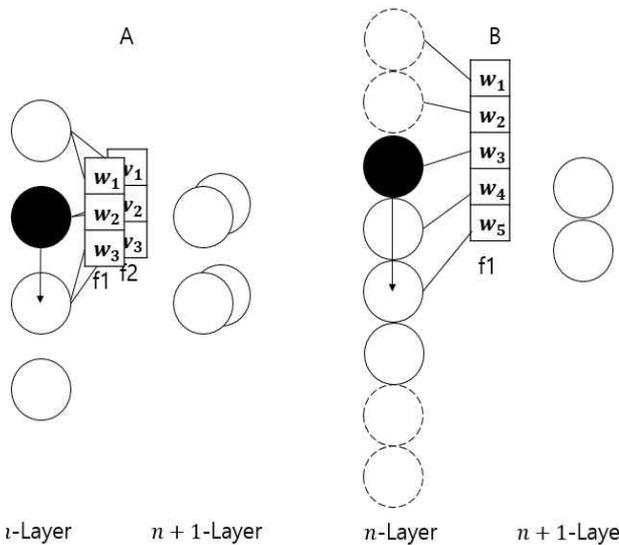


그림 3. CNN 파라미터. 서로 다른 패딩 크기, 필터의 크기, 스트라이드, 필터 채널을 가지는 두 CNN, 각각 $A = \{0, 3, 1, 2\}$, $B = \{2, 5, 2, 1\}$
 Fig. 3. CNN parameters, Two CNNs with different padding sizes, filter sizes, stride, and filter channels, $A = \{0, 3, 1, 2\}$, $B = \{2, 5, 2, 1\}$

$$O = \frac{I + 2P - F}{S} + 1 \quad (1)$$

3절에서 소개할 스테그아날리시스에 사용된 CNN 구조 중에서 하나인 Xu-net^[2]을 보면 5개의 합성곱 계층과 2개의 완전 연결 계층(소프트맥스 계층 포함)으로 구성되어 있으며 스테고 신호를 효과적으로 추출하기 위해서 ABS(absolute)^[2], BN(batch normalization)^[24]과 pooling^[25] 계층을 사용하였다(그림 4 참조).

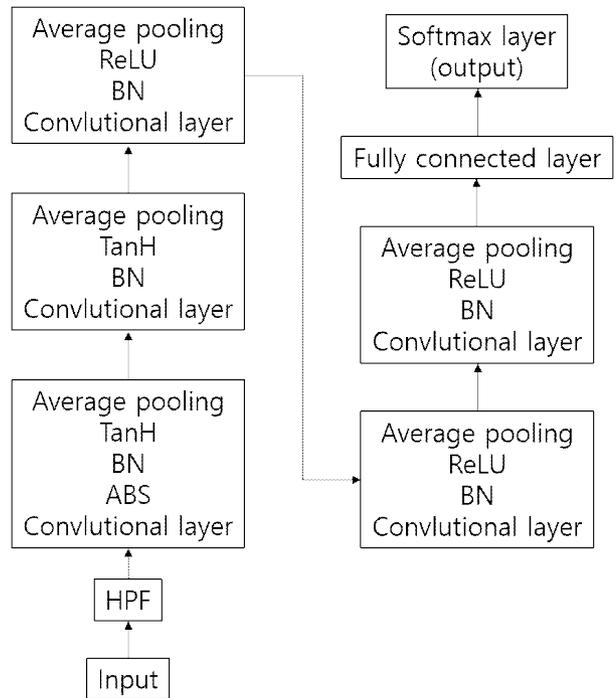


그림 4. Xu-Net^[2]에서 제안한 CNN
 Fig. 4. CNN proposed in Xu-net^[2]

1.1 BN(Batch normalization)

신경망은 교사 학습(supervised learning)이며 입력 특징으로부터 각 계층이 신호를 순전파하고 정답과의 차이를 손실 함수를 통해서 정의한다. 정의된 손실 함수의 전역 최저치(global minima)를 경사 하강법(gradient decent methods)을 이용하여 반복적인 학습으로 각 계층의 가중치와 바이어스를 학습하게 된다. 특히 인공 신경망에서는 각 계층의 가중치와 바이어스 그리고 활성화 함수들이 연결되어 있어서 출력으로부터 그래디언트가 역전파되어 순전파의 역순으로 학습이 이루어진다. 각 계층마다 존재하는 그림 8과 같은 활성화 함수들의 그래디언트가 주로 0~1의 값을 갖기 때문에 깊은 인공 신경망일 경우에 역전파되는 그래디언트가 소실될 수 있다. 배치 정규화는 신경망의 학습과정에서 그래디언트의 소실문제^[34,35]를 해결하기 위해서 사용하는 알고리즘으로 입력 데이터의 값을 일정하게 유지하여 문제를 해결한다. N 개의 미니 배치로 구성된 입력 값을 x_i 이라고 할 때 그 평균과 분산은 각 식 2, 3과 같이 계산할 수 있다. 계산된 미니 배치의 분산과 평균을 이용하여 미니

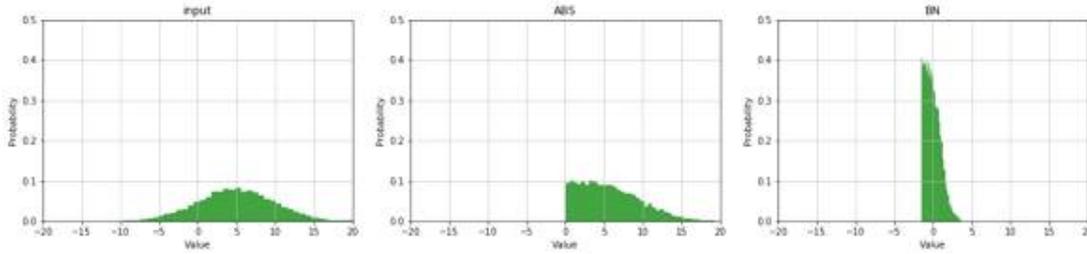


그림 5. ABS와 BN 적용 전/후 히스토그램. (a) 입력, (b) ABS 적용 후, BN 적용 후
 Fig. 5. Histogram before/after applying ABS and BN. (a) input, (b) after ABS, (c) after BN

배치 내부의 입력 값을 식 4와같이 조정한다. 그림 5에서 확인할 수 있는 것처럼 입력값이 클 경우 또는 반대로 너무 작을 경우에 배치 정규화는 입력값을 정규화 시켜서 효과적으로 그래디언트 소실/폭주 문제에 기여한다.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (3)$$

$$x_i = -\frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (4)$$

1.2 풀링(pooling)

풀링은 입력 값의 차원을 줄이기 위해서 사용한다. 합성곱 계층과 동일하게 커널 크기, 스트라이드, 패딩 등이 요구되며 그 기능은 풀링의 종류에 따라서 커널 내의 값들의 최대, 최소, 평균 연산을 통해서 대푯값을 획득한다. 영상이라는 특수한 2차원 배열이 입력 값이므로 인접한 거리에 있는 픽셀들은 유사한 값을 갖고 이러한 성질은 계층을 통과하더라도 유지된다. 그러므로 풀링을 통해서 입력 값의 차원을 감소시켜서 성능은 유지하면서 학습 속도는 향상시키는 효과를 얻을 수 있다. 그리고 커널 내부의 대푯값을 선별하기 때문에 외부의 잡음에도 영향을 덜 받는 효과가 있지만 스테가널리시스 분류 문제에서는 스테고 신호 또한 아주 작은 값을 갖기 때문에 잡음과 특성이 유사할 수 있으므로 풀링의 사용에 주의할 필요가 있다.

2. 영상 스테가노그래피(Image steganography)

단순 LSB만을 고려하지 않고 영상의 텍스처나 엣지같은 고주파수 성분에 정보를 삽입하는 것이 영상의 배경과 같이 변화량이 거의 없는 저주파수 성분에 삽입하는 것보다 검출하기 어렵다는 점에 착안하여 이후로는 영상의 콘텐츠에 대해서 고려한 알고리즘들이 연구되었다. 대표적인 방법들로는 HUGO, WOW, S-UNIWARD 등이 있으며 위의 3가지 방법은 알고리즘을 적용하기 위해서 특정 필터를 이용하여 삽입하기 용이한 고주파수 성분을 특정하고 각 픽셀에 대한 비용 함수를 구하고 비용함수의 값이 가장 적은 왜곡의 정도가 덜한 픽셀에 정보를 삽입한다. WOW와 S-UNIWARD는 Daubechies 8 웨이블릿 LPF(low pass filter), HPF(high pass filter)인 h 와 g 를 사용사용하여 그림 6과 같은 3가지 필터 $F_1 = h \cdot g^T$, $F_2 = g \cdot h^T$, $F_3 = g \cdot g^T$ 를 생성하여 잔차 $R_k = F_k * I$ 를 계산한다. 각 필터에 의해서 계산된 잔차는 미리패딩된 I 와 합성곱을 통해서 계산되어 영상과 동일한 크기의 잔차를 구할 수 있다. 이렇게 추정된 잔차로부터 ξ 와 ρ 를 계산한다.

WOW는 $\xi_k = |R_k| * |F_{k,rotate 180}|$, $\rho = \sum_{k=1}^3 \frac{1}{\xi_k}$, S-UNIWARD

는 $\xi_k = |-\frac{1}{R_k}| * |F_{k,rotate 180}|$, $\rho = \sum_{k=1}^3 \xi_k$ 로 각 다르게 계산하고

결과적으로 동일한 영상에 대해서 각 픽셀에 대해서 다른 확률로 비밀 정보를 삽입하게 된다. 그림 7는 payload=0.4의 고정키로 동일한 커버 영상에 비밀 정보를 삽입하였을 때 삽입된 비밀 정보의 분포를 보여준다. 결과적으로 이러한 알고리즘들은 비밀 정보의 삽입 영역을 효과적

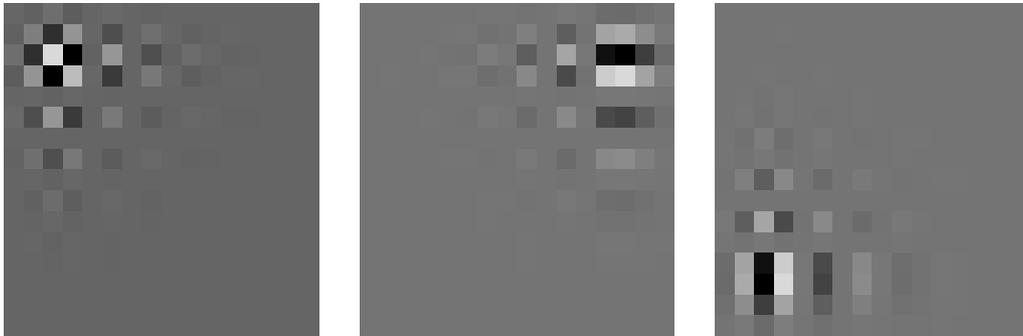


그림 6. WOW와 S-UNIWARD에 사용된 16 × 16크기의 3가지 필터
 Fig. 6. Three 16 × 16 filters used in WOW and S-UNIWARD

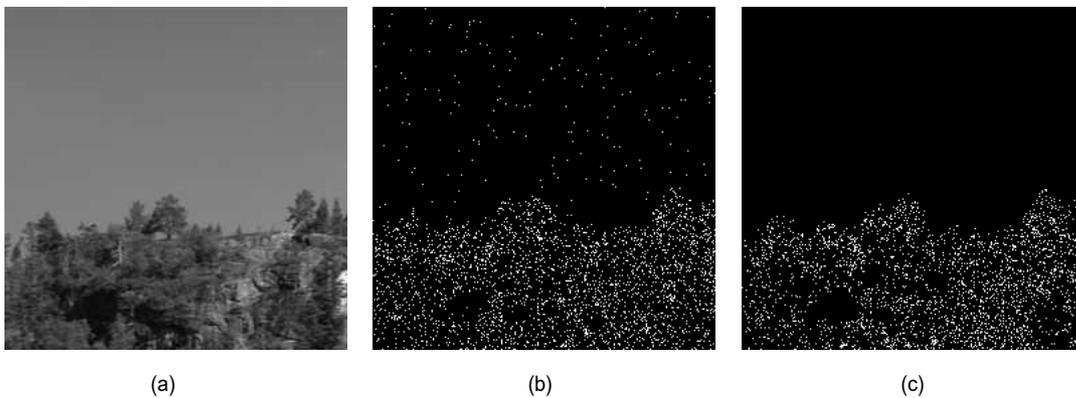


그림 7. S-UNIWARD와 WOW에 의한 비밀 정보 삽입 영역. (a) 커버 영상, (b) S-UNIWARD, (c) WOW
 Fig. 7. Secret information insertion regions by S-UNIWARD and WOW. (a) Cover image, (b) S-UNIWARD, (c) WOW

으로 선택하여 생성된 스테고 영상의 픽셀 값 차이의 분포 정도를 그림 1의 커버 영상과 같이 분포를 유사하게 만들어 초기의 스테그아날리시스 방법으로 검출했을 때 LSB 기반의 스테가노그래피 알고리즘 보다 효과적인 은닉성을 보여주었다.

3. 영상 스테그아날리시스(Image steganalysis)

스테가노그래피 알고리즘이 적용된 스테고 영상과 적용되지 않은 커버 영상을 분류하는 알고리즘을 스테그아날리시스라고 한다. 초기의 스테그아날리시스는 스테가노그래피에 대한 사전지식을 기반으로 전문가들에 의해서 ALE, SPAM과 같은 수제 특징을 영상으로부터 추출하였다. 이런 초기의 특징들은 그림 1처럼 스테고 영상과 커버 영상 사이에 통계적인 차이가 발생한다는 점에 착안하여 특징을 설

계하였고 영상으로부터 특징을 추출하고 분류 문제에 적합한 다양한 기계학습 알고리즘을 적용하여 분류 문제를 해결하였다. 최근에는 특징의 추출과 기계학습의 구분없이 CNN알고리즘을 사용하여 특징의 추출과 분류를 동시에 해결하려는 연구들이 주를 이루고 있다([1-7] 참조). 초기의 스테가노그래피 알고리즘인 LSB, PVD등의 알고리즘들은 수제 특징인 ALE, SPAM등의 특징을 사용하여 효과적으로 분류를 하였다. 이후에 기존의 스테그아날리시스 방법으로 검출이 어려운 HUGO, WOW, S-UNIWARD등 영상의 콘텐츠를 이용한 스테가노그래피들이 개발되면서 10000 차원 이상의 특징을 갖는 SRM과 같은 특징들이 연구되었고 고정된 정보를 삽입한 스테가노그래피에 대해서는 효과적인 분류를 보여주었다. 하지만 고차원의 특징으로 인해서 SVM같은 단일 기계학습 알고리즘을 사용해서 학습을 할 경우에 소요되는 시간이 급증하여서 FLD분류기

수십개를 학습시키고 학습된 분류기를 랜덤 포레스트 알고리즘으로 통합한 단일 분류기를 사용하였다. 이후의 스테그아날리시스는 CNN을 이용한 방법들이 연구되고 있으며 공통적으로 초기화와 학습의 속도를 돕기위해서 전처리 단계로 다양한 종류의 필터를 사용하고 있다. 1채널의 HPF (high pass filter) 필터부터 SRM 필터까지 다양한 종류의 필터를 사용한다. 초기의 전처리 단계가 끝나면 CNN의 구조에 따라서 다양한 알고리즘들 옵티마이저, 손실함수, 초기화, 활성화 함수, 풀링등 각 계층들을 적절하게 조합해가면서 CNN의 검출률을 향상시킨다.

III. CNN 기반의 스테그아날리시스

본 논문에서는 SC(selection-channel)^[36] 처럼 스테고 영상의 알고리즘이나 사전 지식이 포함된 CNN에 대해서는 고려하지 않고 계층의 수, 전처리 필터의 종류, 계층에서 사용한 방법등 구조적인 차이를 보이는 CNN에 대해서 성능의 차이를 비교하기 위해서 5가지 구조를 비교하였다. 그림 10에서 확인할 수 있는 것처럼 [2-3,5-6]의 4가지 구조는 BN을 적용하며 4의 구조는 BN을 사용하지 않았다. 그리고 [2]는 1채널의 HPF를 전처리에서 사용하였고 [3]은 [2]와 유사한 3채널의 HPF를 사용하였다. [4]와 [5]는 동일한 30채널의 SRM 필터를 사용하였고 마지막으로 [6]은 3가지 종류의 필터를 사용하는 구조적인 차이를 보였다. 이러한 차이로부터 분류 결과와 함께 분석함으로써 각 계층의 이점을 함께 분석해본다. 실험은 5가지 구조에 대해서 영상의 크기와 스테가노그래피 알고리즘(WOW와 S-UNIWARD) 삽입 정보량(payload) 삽입 정보의 고정키, 랜덤키에 대해서 비교하고 동일한 조건 하에서 CNN의 구조적인 차이가 검출률에 어떤 결과를 보여주는지 비교 분석한다. 3.1에서는 각 논문들의 구조적인 차이에 대해서 비교하고 3.2에서는 실험 환경에 대해서 소개하고 검출 결과에 대한 분석을 한다.

1. CNN 구조

[2]의 Xu-net은 5개의 합성곱 계층과 2개의 완전연결 계

층으로 구성된다. 전처리 과정으로는 식 5와 같은 HPF를 사용한다. 특징으로는 첫 번째 합성곱 계층에서 HPF를 통과한 전처리 ABS(absolute activation) 계층과 BN 계층을 함께 사용한다. 2가지 계층을 통과한 값의 분포는 그림 5 ABS와 같이 변하며 0을 중심으로 분포한다. 이 분포는 직후에 적용되는 tanH 활성화 함수가 입력 신호가 0에 근사할 경우에 학습이 용이하다는 점을 극대화한다. [3]은 Xu-net과 동일한 구조에서 전처리에 사용된 필터를 추가한 구조이다. 추가된 필터는 식 7, 8이며 Xu-net에 비해서 2가지 필터를 추가함으로써 영상으로부터 더 다양한 스테고 신호를 추출할 수 있게 해주었다. [4]에서는 전처리에 영상 스테그아날리시스에서 효과적으로 스테고 신호를 추출했던 SRM 필터를 사용하였다. SRM 필터는 선형적인 필터와 비선형적인 필터로 구성이 되는데 그 중에서 선형적인 필터 30가지를 사용하였다. 전처리에 사용된 필터 적용 과정을 스테그아날리시스 문제에 최적화 될 수 있도록 역전과 과정에 포함시켜서 SRM 필터 또한 학습이 가능하도록 하였고 필터링된 입력 값은 TLU(truncated linear unit) 활성화 함수를 이용하여 신호의 밀도가 큰 0에 가까운 값들에 대해서만 작용할 수 있도록 하여서 신호를 더 정제하였다 (그림 8. (a) 참조). 30가지 필터를 통해서 얻어진 입력값은 8개의 합성곱 계층과 1개의 완전 연결 계층으로 구성된 신경망에서 효과적인 스테그아날리시스 성능을 보여주었다. [5]는 Xu-net에서 사용한 BN, ABS의 조합과 [4]의 SRM 필터와 TLU 활성화 함수를 사용하였다. 전처리에서는 SRM 필터만 적용하고 첫 번째 합성곱 계층에서는 T=3, 두 번째 합성곱 계층에서는 T=2를 적용한 TLU를 사용하고 합성곱 계층 전체에 BN을 적용하여 각 합성곱 계층에서 얻어지는 특징맵의 값을 정제하였다. 마지막으로 [6]은 전처리 과정에서 선형 SRM, 비선형 SRM, Gabor 필터^[27] 3가지를 사용하였고 각 필터는 16, 14, 16개로 구성된다. Gabor 필터는 6×6 의 크기를 갖고 식 8과 같으며 세부 파라미터는 $x' = x \cos \theta + y \sin \theta$, $y' = -x \sin \theta + y \cos \theta$ 로 θ 는 필터의 위상이며 나머지 변수는 $\lambda = \sigma / 0.56$, $\gamma = 0.5$ 와 같다. ReST-net에서 사용한 필터는 θ 의 값이 $0 \sim 7\pi/8$ 로 8방향과 $\sigma = 0.5$ or 1.0 으로 16개의 필터가 생성된다. 생성된 3종류의 필터에 의해서 전처리된 3가지 입력은 그림 10의 (c)에서 서브 모델의 입력이 된다. 서브 네트워크는 5개의 합

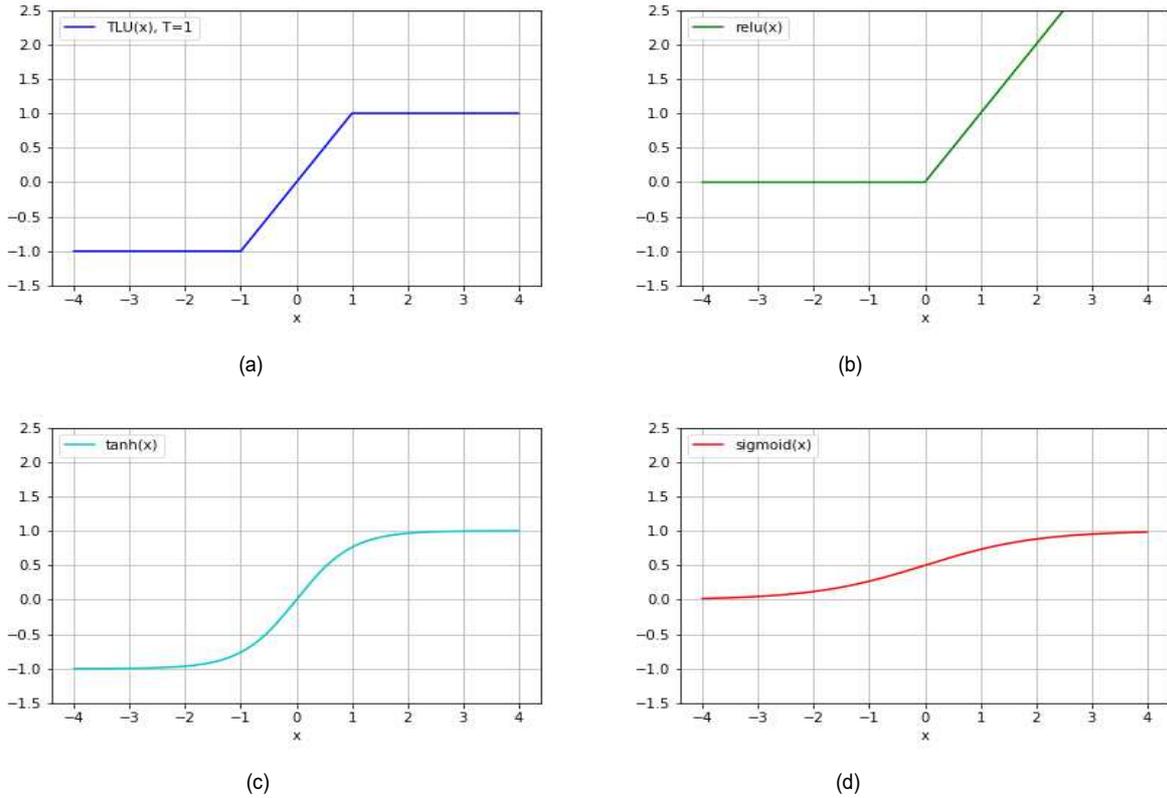


그림 8. 4가지 활성화 함수. (a) TLU, (b) ReLU, (c) tanH, (d) sigmoid
 Fig. 8. 4 activation functions. (a) TLU, (b) ReLU, (c) tanH, (d) sigmoid

성공 계층으로 구성되는데 2, 4번은 DAM(diverse activation module)이라는 개념을 도입한다(그림 9 참조). DAM은 그림 8의 (b), (c), (d) 3가지 활성화 함수 ReLU, tanH, sigmoid가 병렬적으로 배치된 합성곱 계층으로 각 활성화 함수는 동일한 입력값으로부터 다른 비선형적으로 출력해주는 역할을 하여 성능 향상에 기여하였다. 실험에 사용한 전체 CNN의 구조는 그림 10과 같다.

$$\frac{1}{4} \begin{pmatrix} 2 & -1 & 2 \\ -1 & -4 & -1 \\ 2 & -1 & 2 \end{pmatrix} \quad (7)$$

$$g(x,y) = \exp\left(-\frac{x'^2 + \gamma y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda}\right) \quad (8)$$

$$\frac{1}{12} \begin{pmatrix} -1 & 2 & -2 & 2 & -1 \\ 2 & -6 & 8 & -6 & 2 \\ -2 & 8 & -12 & 8 & -2 \\ 2 & -6 & 8 & -6 & 2 \\ -1 & 2 & -2 & 2 & -1 \end{pmatrix} \quad (5)$$

$$\frac{1}{4} \begin{pmatrix} -1 & 2 & -1 \\ 2 & -4 & 2 \\ -1 & 2 & -1 \end{pmatrix} \quad (6)$$

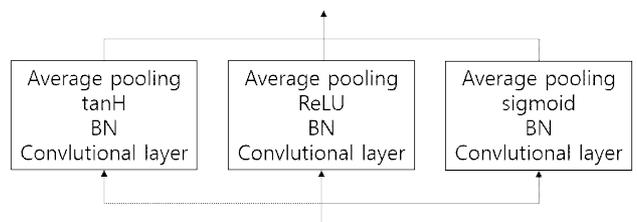


그림 9. DAM 구조
 Fig. 9. DAM structure

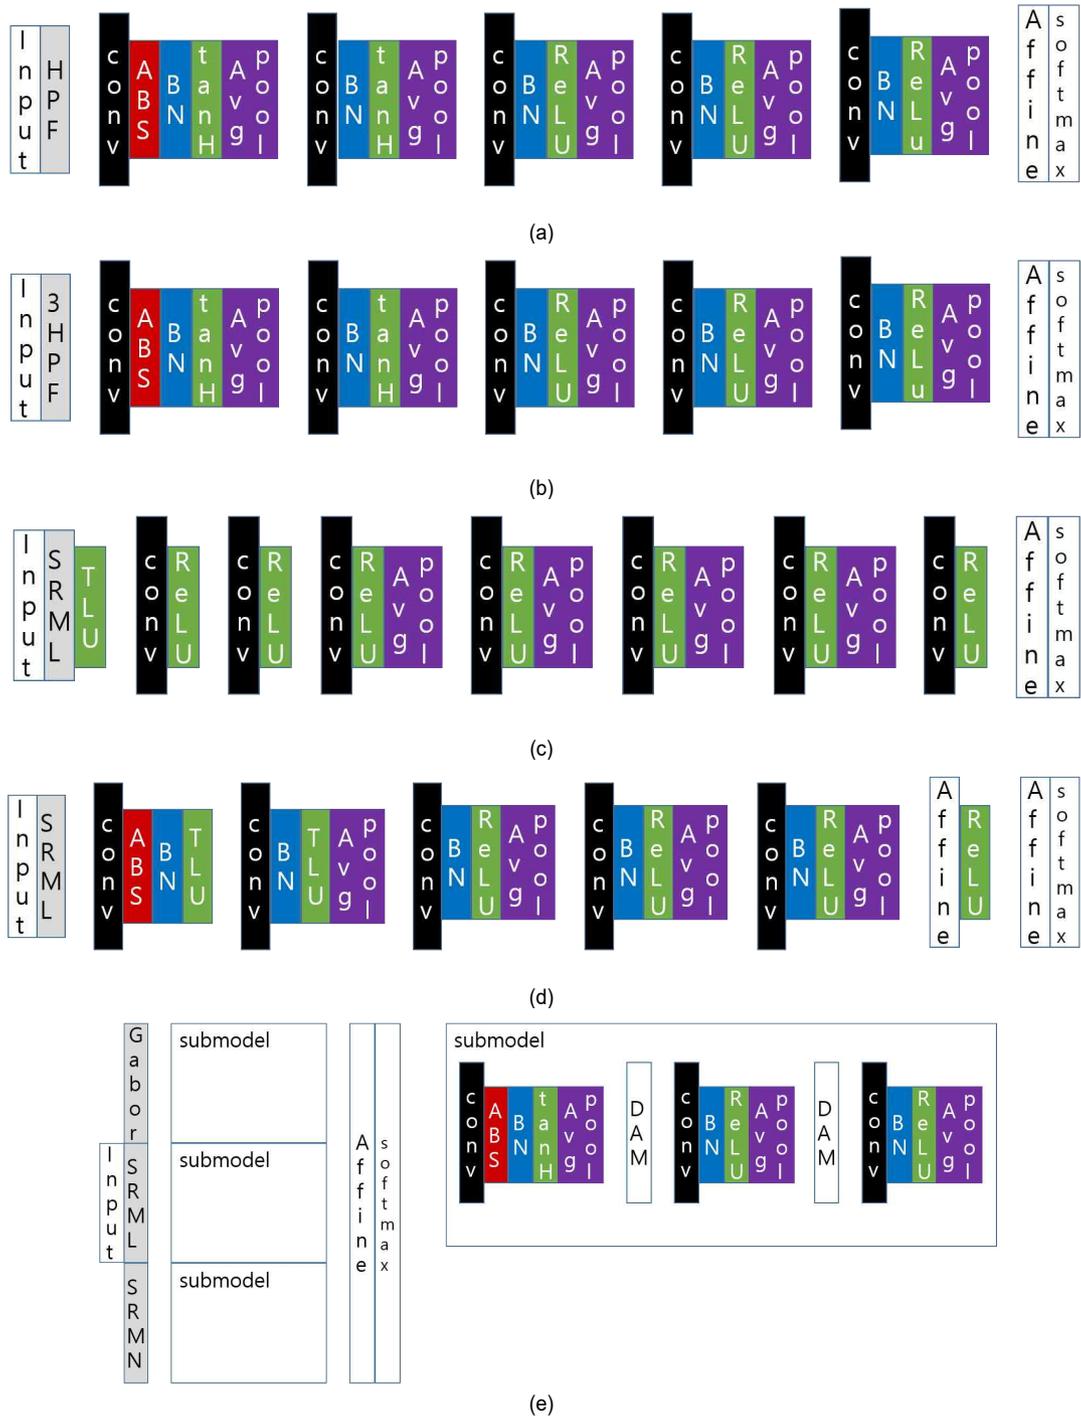


그림 10. 성능 분석에 사용된 CNN 기반의 스테그아날리시스 방법의 네트워크 구조. (a) [2]의 방법, (b) [3]의 방법, (c) [4]의 방법, (d) [5]의 방법, (e) [6]의 방법

Fig. 10. Network structures of CNN-based steganalysis methods used in performance analysis. (a) Method of [2], (b) method of [3], (c) method of [4], (d) method of [5], (e) method of [6]

2. CNN 기반의 스테그아날리시스 성능

실험은 512×512 크기의 BOSSBase 1.01^[23] 흑백 영상 셋 10,000장을 중복되지 않도록 4분할 한 256×256 크기의 흑백 영상 40,000장을 사용한다. 커버 영상 40,000장은 조건마다 S-UNIWARD와 WOW 스테가노그래피 방법에 대해서 스테고 영상 40,000장을 생성한다. 고정키 스테고 영상을 생성하기 위해서 사용되는 시뮬레이터는 [28]에서 제공하는 Windows C++ 버전을 사용하였고 랜덤키 스테고 영상은 Matlab 버전을 사용하였다. 생성한 스테고 영상의 pay-

load는 각 0.2, 0.4로 생성된다. 생성된 영상 셋은 각 조건에 따라서 1 대 1 비율의 60,000장의 학습 셋과 20,000장의 실험 셋으로 나누어 학습과 검증에 사용한다. 실험은 텐서플로우(tensorflow) 라이브러리^[29]의 환경에서 진행하였고 S-UNIWARD와 WOW 알고리즘에 대한 분류 결과는 표1, 2와 같으며 초기화와 최적화의 파라미터는 표 3과 같다.

표 1과 2는 각 S-UNIWARD와 WOW에 대한 검출률의 실험 결과를 보여준다. 검출률은 커버 영상과 스테고 영상의 비율이 1대1인 20,000장의 테스트 셋으로부터 32/32의 커버 /스테고 영상의 임의의 배치를 1000번 반복한 결과이다.

표 1. S-UNIWARD 알고리즘 분류 결과
Table 1. Classification results for S-UNIWARD

paper	iteration	fixed key		random key	
		payload=0.2	payload=0.4	payload=0.2	payload=0.4
[2]	200,000	0.67258	0.75602	0.66748	0.79158
[3]	200,000	0.59453	0.75992	0.59631	0.74195
[4]	100,000	0.77894	0.86453	0.68609	0.80656
[5]	100,000	0.66656	0.79383	0.67247	0.78625
[6]	50,000	0.55388	0.73620	•	•
	100,000	0.60098	0.76719	0.64994	0.77238

표 2. WOW 알고리즘 분류 결과
Table 2. Classification results for WOW

paper	iteration	fixed key		random key	
		payload=0.2	payload=0.4	payload=0.2	payload=0.4
[2]	200,000	0.63214	0.76269	0.69930	0.79702
[3]	200,000	0.61322	0.70811	0.70672	0.78714
[4]	100,000	0.66308	0.81608	0.74703	0.82398
[5]	100,000	0.62330	0.77574	0.70111	0.79234
[6]	50,000	0.53030	0.61514	•	•
	100,000	0.65652	0.73864	0.68791	0.65486

표 3. 실험에 사용된 각 CNN의 하이퍼파라미터
Table 3. Hyperparameters of CNNs used in experiments

paper	initializer		optimizer		
	convolution	fully-connected	optimizer	moment	learning rate
[2]	gaussian	xavier	Momentum	0.9	0.001
[3]	gaussian	xavier	Momentum	0.9	0.001
[4]	gaussian	gaussian	AdaDelta	0.95	0.4
[5]	xavier	xavier	Momentum	0.95	0.01
[6]	gaussian	gaussian	Momentum	0.9	0.001

표 1은 S-UNIWRD에 대한 분류 결과를 보여준다. [2]와 [3]은 동일한 구조에서 필터 수의 차이만을 보여주며 결과 또한 유사한 것을 볼 수 있었다. 단지 낮은 payload에 대해서 [2]가 0.67258, 0.66748로 더 뛰어난 성능을 보여주었다. [4]는 고정 키와 랜덤 키에서 모두 가장 우수한 성능을 특히 payload 고정 키의 성능에서 0.86453의 높은 성능을 보여주었다. 가장 깊은 CNN 구조와 다양한 필터, 필터의 학습이 효과적으로 스테고 신호를 추출했다. [5]는 [4]와 동일한 필터, TLU와 [2]의 ABS, BN등을 함께 사용한 CNN으로 두 번째로 뛰어난 성능을 보여주었다. 마지막으로 [6]은 DAM과 3개의 서브넷을 사용하여 가장 다양한 구조를 하나의 CNN에 결합하여 사용했지만 payload=0.2의 고정 키에서 아주 낮은 결과를 보여주었다. 표 2는 WOW에 대한 실험 결과를 보여준다. 대부분의 경우에서 S-UNIWARD와 유사한 경향을 보여주었다. [2]는 S-UNIWARD와 유사한 성능을 보여주었다. [3]은 랜덤 키 payload=0.2의 경우에 특히 0.10 정도로 성능 향상이 컸다. [4]의 경우에 고정키 payload=0.2의 경우에 성능이 0.66308로 S-UNIWARD에 비해서는 0.13정도 성능이 감소하였다. [5]는 고정키의 경우에 0.04정도 검출률이 소폭 감소하였고 랜덤 키의 경우에 검출률이 소폭 상승하였다. 마지막으로 [6]은 전반적으로 유사하나 랜덤키 payload=0.4의 경우에 0.12정도의 성능 감소를 보였다.

[2]와 [3]의 경우 동일한 구조와 동일한 하이퍼파라미터를 사용하였고 단지 입력의 HPF필터만의 구조적 차이를 갖는 CNN기반의 스테그아날리시스이다. 이러한 차이로 볼 때 1채널의 HPF를 사용한 [2]보다 3채널의 필터를 사용한 [3]이 성능이 좋을 것으로 판단했으나 오히려 3채널의 HPF를 사용한 [3]이 성능이 낮은 것을 확인할 수 있었다. 각 구조는 필터를 제외하고 그림 10의 [2], [3]에서처럼 5개의 합성곱 계층을 갖고 각 계층은 8, 16, 32, 64, 128개의 채널을 갖는다. 이는 앞서 설명한 것처럼 [3]이 필터를 3채널로 증가시켰음에도 구조가 동일한 것이 구조적인 최적화를 이루지 못한 것으로 보인다. 즉 1채널에서 3채널로 필터를 확장 시킬 경우 그에 맞는 합성곱 계층의 채널 수를 증가시키거나 CNN을 더 깊게 하여 효과적인 학습이 되도록 할 필요가 있어 보인다. [4]는 가장 깊은 CNN으로 다른 4가지 구조와는 달리 입력 영상의 필터링에 TLU를 적용함으로써 입력 신호를 한번 더 정제하였고 BN을 적용하지

않았다. 30채널의 SRM 필터를 효과적으로 학습하기 위해서 각 계층의 합성곱의 필터 채널을 30, 30, 30, 32, 32, 32, 16, 16으로 하고 깊은 합성곱 계층을 유지하고 필터의 가중치도 학습하여 가장 좋은 성능을 낼 수 있었다. [5]는 [2]의 구조에서처럼 ABS, BN, TLU를 이용하여 입력 특징의 신호 밀도를 높였다. [4]와 [5]는 같은 30채널의 선형 SRM필터를 사용하였지만 [4]와는 달리 필터의 학습을 하지 않았다. 결과적으로 동일한 필터를 사용하였지만 [4]가 더 좋은 성능을 보여주고 [5]가 두 번째로 좋은 성능을 보여주었다. 마지막으로 [6]은 선형, 비선형 SRM과 Gabor 필터를 모두 사용하고 3가지 종류의 활성화 함수를 병렬로 적용하는 DAM을 사용하여 다양한 특징을 추출하였지만 1채널의 HPF만을 사용한 [2]에 비해서도 두드러지는 성능을 보여주지는 못했다. 이는 다양한 필터와 3개의 서브 모델, 3가지 종류의 전처리 필터를 사용하여 입력으로부터 풍부한 특징을 추출할 수 있는 기반을 만들었음에도 복잡한 구조를 최적화하기 위한 수단이 부족한 것을 보여주었다.

IV. 결론

본 논문에서는 다양한 CNN기반의 스테그아날리시스의 성능을 효과적으로 분석하기 위해서 동일한 조건하에서 S-UNIWARD와 WOW, payload와 삽입 정보의 고정여부에 따라서 분류 결과가 어떤 경향을 보이는지 비교 분석하였다. 또한 구조적으로 각 계층에서 사용된 요소들의 성능을 분석하기 위해서 [7]과 같은 채널 인식 기반의 방법들은 배제하고 구조적인 차이로부터 발생하는 성능을 분석하기 위해서 [2-6]의 5가지 CNN기반의 스테그아날리시스의 성능을 비교 분석하였다. 각 구조는 평균 풀링이나 BN을 대부분 사용하고 전처리 필터로는 1채널의 HPF, 3채널의 HPF, 30채널의 SRM 그리고 선형, 비선형 SRM과 Gabor 필터를 모두 사용하는 등의 구조적인 차이를 보였다. 각 CNN은 1채널과 3채널의 HPF, SRM, 선형, 비선형 SRM 마지막으로 Gabor 필터가 사용되었는데 각 필터는 영상으로부터 잔차를 추출하기 위해서 설계되었다. 이러한 필터로부터 추출된 잔차는 합성곱 계층에서 문제 해결에 도움이 되는 특징을 추출하기 위해서 다양한 처리를 거친다. 결과적으로

5가지 [2-6]의 제안된 CNN 중에서 [4]의 CNN이 가장 좋은 성능을 보여주었고 다른 구조들과 달리 전처리 필터를 학습 과정에 포함시켰고 BN이나 ABS 등의 전파되는 신호를 이동 시키거나 스케일링을 하지 않았으며 가장 깊은 CNN을 사용하고 옵티마이저로 AdaDelta를 사용하는 학습 자체를 위한 많은 노력을 기울였다. 반면에 [6]의 경우 가장 복잡한 구조를 갖고 있으며 3개의 서브 네트워크가 각 다른 필터를 사용함으로써 가장 다양한 특징을 추출 할 수 있는 구조를 갖추었지만 성능은 1채널만 사용한 [2]와 비교했을 때에도 성능의 우위를 보여주지 못 하였다. 즉 필터의 수가 많다고 좋은 성능을 주지 않으며 오히려 학습을 제한하여 성능이 감소할 여지가 있음을 보여주었다. 즉 영상으로부터 잔차를 추출할 수 있는 우수한 전처리 필터의 사용과 효과적인 학습이 가능한 구조를 설계하였을 때 그 성능이 극대화되는 것을 볼 수 있었다. 그리고 [2]와 같이 학습을 돕기 위한 ABS, BN 등의 사용은 그림 5에서 볼 수 있는 것처럼 각 계층에서 전파되는 신호를 가공한다. 이러한 신호의 가공은 CNN의 학습단계에서 각 계층의 학습을 돕기 위해서 적용하는 계층인데 [4]에서는 오히려 이러한 가공을 최소화 하였는데 가장 좋은 성능을 보였고 CNN에 적용하기 위해서는 검증이 필요할 것이다. 그리고 CNN 기반의 스테그아날리시스는 일반 물체 인식과는 다르게 전처리 과정에서 전처리 필터를 사용하게 되는데 이 때 사용하는 필터의 채널이 다양하다. 이러한 다양한 필터를 사용할 때 합성곱의 채널을 어떻게 적용하는 것이 가장 좋은지에 대한 기준이 정해지지 않았다. [4]와 [5]도 동일한 30채널의 SRM을 사용하였지만 합성곱 채널은 30, 30, 30, 32, 32, 32, 16, 16과 30, 30, 32, 64, 128로 그 차이가 명확하다. 앞으로의 CNN 기반의 스테그아날리시스 연구는 이러한 점을 인식하고 전처리 필터의 설계 뿐 아니라 CNN 구조에 대한 연구에 적용하기 위한 방법을 함께 병행하여 연구할 필요가 있을 것이다.

참 고 문 헌 (References)

- [1] L. Pibre, J. Pasquet, D. Ienco and M. Chaumont, "Deep learning is a good steganalysis tool when embedding key is reused for different images, even if there is a cover source-mismatch," Society for Imaging Science and Technology, pp.1-11, 2016.
- [2] G. Xu and H. Wu, "Structural design of convolutional neural networks for steganalysis," IEEE Signal Processing Letters, Vol.23, No.5, pp.708-712, 2016.
- [3] Y. Yuan, W. Lu, B. Feng and J. Weng, "Steganalysis with CNN using multi-channels filtered residuals," ICCCS 2017, pp.110-120, 2017.
- [4] J. Ye, J. Ni and Y. Yi, "Deep learning hierarchical representations for image steganalysis," IEEE Transactions on Information Forensics and Security, Vol.12, No.11, pp.2545-2557, 2017.
- [5] M. Yedroudj, F. Comby and M. Chaumont, "Yedroudj-Net: an efficient CNN for spatial steganalysis," ICASSP 2018, pp.15-20, 2018.
- [6] B. Li, W. Wei, A. Ferreira and S. Tan, "ReST-Net: diverse activation modules and parallel subnets-based CNN for spatial image steganalysis," IEEE Signal Processing Letters, Vol.25, No.5, pp.650-654, 2018.
- [7] J. Yang, K. Liu, X. Kang, E. Wong and Y. Shi, "Steganalysis based on awareness of selection-channel and deep learning," IWDW 2017, pp.263-272, 2017.
- [8] D. Neeta and K. Snehal, "Implementation of LSB steganography and its evaluation for various bits," 1st International Conference on Digital Information Management, pp.173-178, 2006.
- [9] D. Wu and W. Tsai, "A steganographic method for images by pixel-value differencing," Pattern Recognition Letters, Vol.24, pp.1613-1626, 2003.
- [10] K. Chang, C. Chang, P. S. Huang and T. Tu, "A novel image steganographic method using tri-way pixel-value differencing," Journal of Multimedia, Vol.3, No.2, pp.37-44, 2008.
- [11] C. Balasubramanian, S. Selvakumar and S. Geetha, "High payload image steganography with reduced distortion using octonary pixel pairing scheme," Multimed Tools Appl., Vol.73, pp.2223-2245, 2014.
- [12] G. Gul and F. Kurugollu, "A new methodology in steganalysis: breaking highly undetectable steganography (HUGO)," International Workshop on Information Hiding, pp.71-84, 2011.
- [13] V. Holub and J. Fridrich, "Designing steganographic distortion using directional filters," International Workshop on Information Forensics and Security, 2012.
- [14] V. Holub, J. Fridrich and T. Denmark, "Universal distortion function for steganography in an arbitrary domain," EURASIP Journal of Information Security, 2014.
- [15] G. Cancelli, G. Doerr, I. J. Cox and M. Barni, "Detection of ± 1 LSB steganography based on the amplitude of histogram local extrema," ICIP, pp.1288-1291, 2008.
- [16] T. Pevny, P. Bas and J. Fridrich, "Steganalysis by subtractive pixel adjacency matrix," IEEE Transactions on Information Forensics and Security, Vol.5, no.2, pp.215-224, June 2010.
- [17] J. Fridrich and J. Kodovsky, "Rich models for steganalysis of digital images," IEEE Transactions on Information Forensics and Security, Vol. 7, No.3, pp.868-882, June 2012.
- [18] R. Haeb-Umbach and H. Ney, "Linear discriminant analysis for improved large vocabulary continuous speech recognition," IEEE International Conference on Acoustics, Speech, and Signal Processing, San Francisco, CA, USA, pp.13-16, 1992.

- [19] Tin Kam Ho, "Random decision forests," Proceedings of 3rd International Conference on Document Analysis and Recognition, Montreal, Quebec, Canada, Vol.1, pp.278-282, 1995.
- [20] 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.
- [21] A. Krizhevsky, I. Sutskever and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," NIPS, 2012.
- [22] C. Szegedy et al., "Going deeper with convolutions," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, pp.1-9, 2015.
- [23] P. Bas, T. Filler and T. Pevny, "Break our steganographic system - the ins and outs of organizing BOSS," Information Hiding 13th International Conference, Vol.6958, pp.59-70, 2011.
- [24] S. Ioffe and C. Szegedy, "Batch normalization: acceleration deep network training by reducing internal covariate shift," 2015, <https://arxiv.org/abs/1502.03167>.
- [25] K. He, X. Zhang, S. Ren and J. Sun, "Spatial pyramid pooling in deep convolutional networks for visual recognition," ECCV, pp.346-361, 2014.
- [26] C. Cortes and V. Vapnik, "Support-vector networks," Machine Learning, Vol.20, pp.273-297, 1995.
- [27] X. Song, F. Liu, C. Yang, X. Luo and Y. Zhang, "Steganalysis of adaptive JPEG steganography using 2D Gabor filters," in Proc. 3rd ACM Inf. Hiding Multimedia Secur. Workshop, pp.15 - 23, 2015.
- [28] DDE LAB download, <http://dde.binghamton.edu/download/>
- [29] Tensorflow, <https://www.tensorflow.org/>
- [30] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," ICLR, 2015.
- [31] The cifar-10 dataset, <https://www.cs.toronto.edu/~kriz/cifar.html>
- [32] ILSVRC, <http://image-net.org>
- [33] J. Sanchez and F. Perronnin, "High-dimensional signature compression for large-scale image classification," CVPR 2011, Colorado Springs, CO, USA, pp.1665-1672, 2011.
- [34] S. Hochreiter, Y. Bengio, P. Frasconi and J. Schmidhuber, "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies," in A Field Guide to Dynamical Recurrent Networks, IEEE, 2001, doi: 10.1109/9780470544037.
- [35] S. Kong and M. Takatsuka, "Hexpo: A vanishing-proof activation function," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, pp.2562-2567, 2017.
- [36] J. Ye, J. Ni and Y. Yi, "Deep learning hierarchical representations for image steganalysis," IEEE Transactions on Information Forensics and Security, Vol.12, No.11, pp.2545-2557, 2017.
- [37] J. Kim and H. Park, "Image steganography using layered pixel-value differencing," Journal of Broadcasting Engineering, Vol.22, No.3, 2017.
- [38] J. Kim and H. Park, "A statistical approach for improving the embedding capacity of block matching based image steganography," Journal of Broadcast Engineering, Vol.22, No.5, 2017.
- [39] J. Kim, H. Park, J. Park, "Experimental verification of the versatility of SPAM-based image steganalysis," Journal of Broadcast Engineering, Vol.23, No.4, pp.525-535, 2018.

저 자 소 개



김 재 영

- 2012년 : 부경대학교 전자컴퓨터정보통신공학부
- 2016년 ~ 현재 : 부경대학교 일반대학원 석사과정
- ORCID : <http://orcid.org/0000-0003-2348-3626>
- 주관심분야 : 스테가노그래피, 스테그아날리시스, 기계 학습 등



박 한 훈

- 2000년 : 한양대학교 전자통신전파공학과 공학사
- 2002년 : 한양대학교 대학원 전자통신전파공학과 공학석사
- 2007년 : 한양대학교 대학원 전자통신전파공학과 공학박사
- 2008년 ~ 2011년 : NHK방송기술연구소 박사후연구원
- 2012년 ~ 현재 : 부경대학교 전자공학과 교수
- ORCID : <http://orcid.org/0000-0002-6968-4565>
- 주관심분야 : 증강현실, 인간컴퓨터상호작용, 3차원 영상처리/비전 등

저 자 소 개



박 종 일

- 1987년 : 서울대학교 전자공학과 공학사
- 1989년 : 서울대학교 전자공학과 공학석사
- 1995년 : 서울대학교 전자공학과 공학박사
- 1992년 ~ 1994년 : 일본 NHK방송기술연구소 객원연구원
- 1995년 ~ 1996년 : 한국방송개발원 선임연구원
- 1996년 ~ 1999년 : 일본 ATR지능영상통신연구소 연구원
- 1999년 ~ 현재 : 한양대학교 공과대학 컴퓨터공학부 교수
- ORCID : <http://orcid.org/0000-0003-1000-4067>
- 주관심분야 : 증강현실, 계산사진학, 3차원 컴퓨터비전, 인간컴퓨터상호작용