

2022 하계 세미나

Face Anti-Spoofing



Sogang University

Vision & Display Systems Lab, Dept. of Electronic Engineering



Presented by

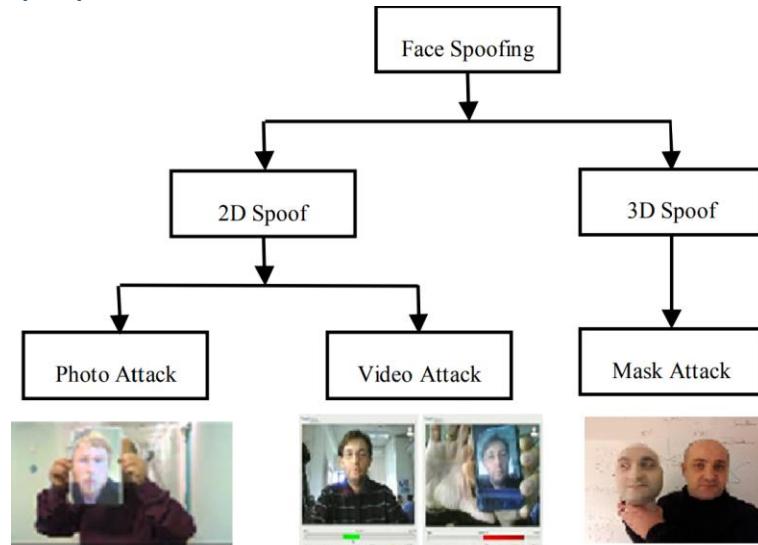
전창렬

Outline

- Background
 - What is face anti-spoofing?
 - Learn Convolutional Neural Network for Face Anti-Spoofing
- Face anti-spoofing
 - Domain generalization
 - Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing (CVPR 2022)
 - Fine-grained recognition
 - PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition (CVPR 2022)

Background

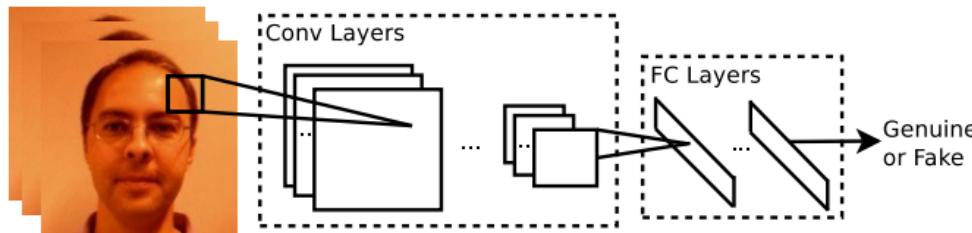
- What is face anti-spoofing?
 - 안면 인식은 얼굴을 통해 사람을 식별하거나 특정인의 신원을 인증하는 방법
 - 안면 인식 알고리즘 기술은 AI 기반으로 학습 되기 때문에 이미징 프로세스와 피사체에 따라 상당한 비율의 오류가 발생
 - 이를 활용하여 악의적인 목적을 가지고 타인의 신분으로 위장하는 범죄가 발생
 - Face anti-spoofing은 이러한 spoof attack을 인식하고 실제 얼굴과 구별해내어 안전성을 확보하기 위한 task



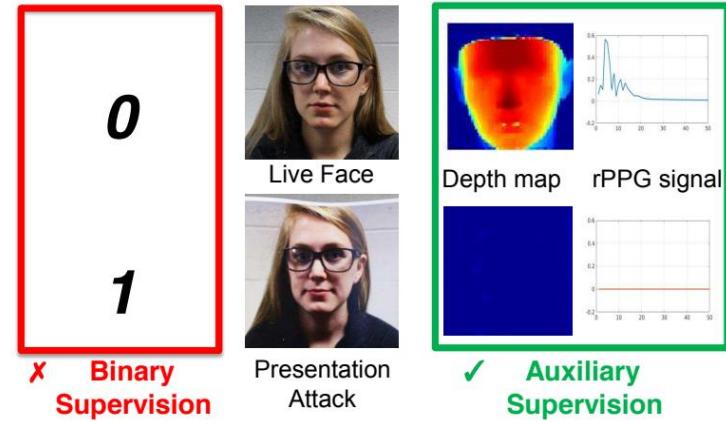
<face spoofing 개요>

Background

- Binary classification-based face anti-spoofing
 - Face anti spoofing은 기본적으로 live face와 presentation attack 2가지 경우를 구분하는 binary classification 관점
 - 이와 같은 binary classification 관점은 2가지 문제가 존재
 - Spoofing pattern에 따라 이미지 degradation 정도가 달라지는데 학습에 사용된 data로 모든 spoofing pattern에 대한 generalize가 어려움
 - 단순히 image를 binary supervision을 통해 분류하는 것이기 때문에 결과에 대한 해석이나 이유가 따르지 않음
 - 따라서 해당 분야의 연구에서는 Depth map 등의 추가 정보가 활용되기도 함



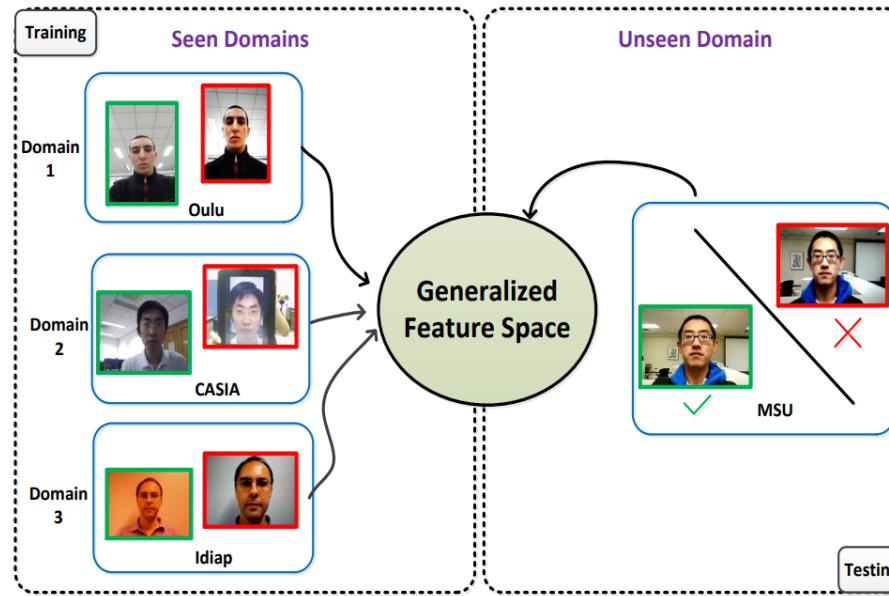
<binary classification을 통한 face anti-spoofing>



<Auxiliary supervision을 활용한 face anti-spoofing>

Face anti-spoofing (FAS)

- Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing
 - 기존의 FAS 기법들은 intra-domain 환경에서 높은 성능을 얻었으나 cross-domain setting에서 성능 저하가 발생
 - 학습 데이터 수와 네트워크의 capability의 한계로 인한 문제
 - 이로 인해 모델이 dataset bias의 영향을 받으며, 새로운 domain에 대한 generalization이 잘 되지 못함
 - 이러한 문제를 해소하기 위해 domain generalization 기법을 도입하는 연구가 진행



Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

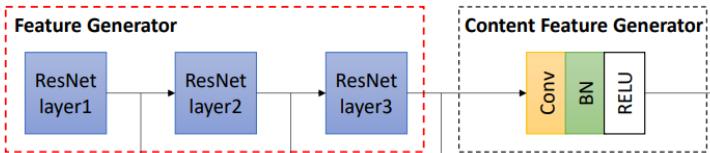
- Content and style information aggregation

• 이미지는 이미지의 외형을 표현하는 contents와 texture 등을 표현하는 style로 구성

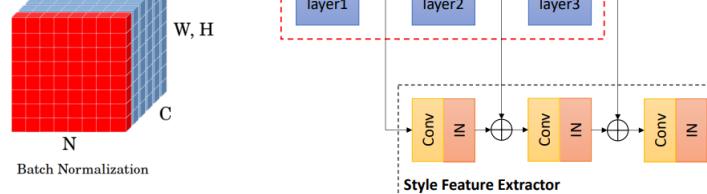
- FAS task에서는 이미지의 content information은 common factor로 존재
- 이미지의 style information은 FAS에서 discriminative cue를 제공하는 특성
- 따라서 해당 논문에서는 content와 style에 따로 각각의 information aggregation을 진행

↳ Content information은 BN을 통하여 global image statistics를 획득함으로써 얻음

↳ Style information은 IN을 통하여 개별 sample의 statistics를 획득함으로써 얻음



<content feature aggregation by BN>



<style feature aggregation by IN>

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Content and style information aggregation
 - Content information aggregation

- Content information에서는 domain 간의 distribution discrepancies가 작다고 추측

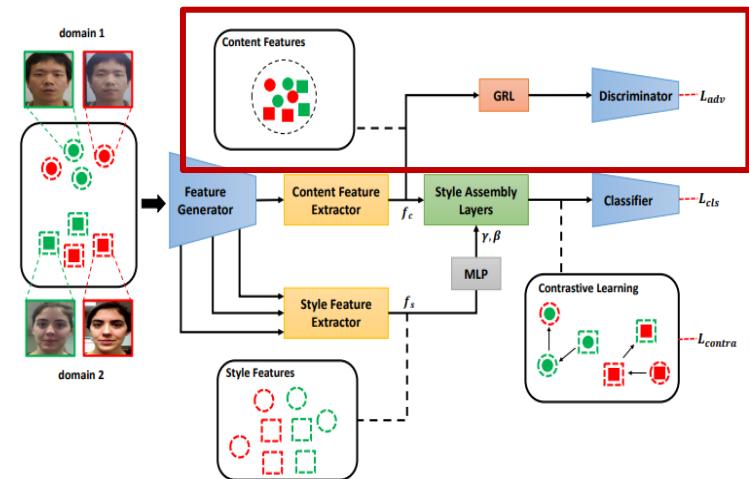
↳ Domain에 무관하게 데이터들은 모두 facial area를 다루고 있기 때문에 유사한 content feature를 가질 것

↳ Bona fide or attack presentation에 무관하게 shape나 size와 같은 attribute는 유사할 것

- 따라서 content 간의 차이가 네트워크에 영향을 미치지 않도록 adversarial 학습을 진행

$$\min_D \max_G L_{adv} (G, D) = - \mathbb{E}_{(x,y) \sim (X, Y_D)} \sum_{i=1}^M \mathbb{1}[i = y] \log D(G(x))$$

<adversarial loss>



<Content information aggregation>

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Content and style information aggregation

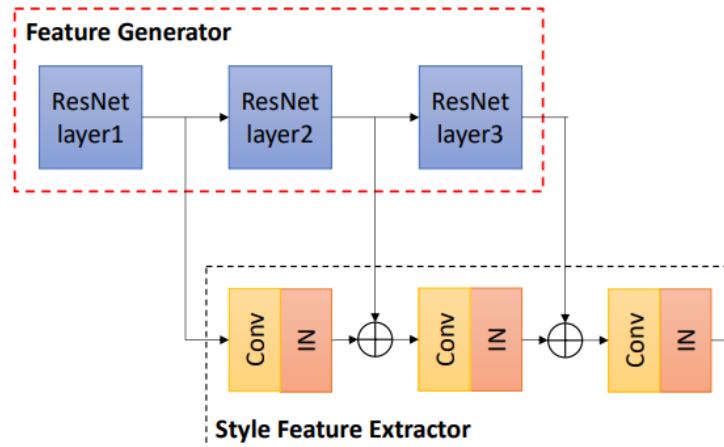
- Style information aggregation

- Style information은 hierarchical 구조를 통해 multi-layer feature를 모아서 진행

↳ Style은 scale 별로 각기 다른 특징을 포함하고 있음

✓ 밝기 정보는 주로 feature의 broad-scale에 포함

✓ Texture와 같은 정보는 이미지의 local-scale에서 담고 있음



<Style information aggregation>

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Shuffled style assembly

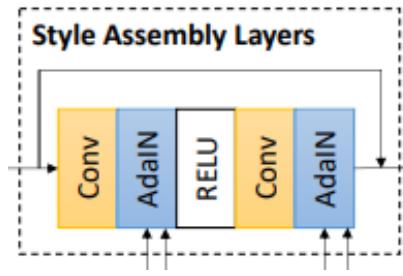
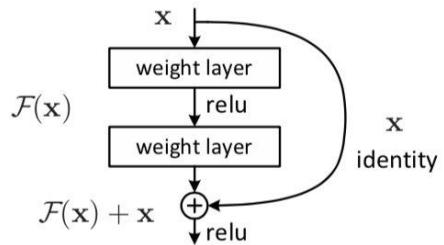
- Style feature가 MLP를 통과하여 AdaIN에 적용하기 위한 affine parameter γ, β 추출
- 3x3 convolution을 적용한 content feature에 AdaIN을 적용하여 intermediate variable z 를 얻음
- z 에 추가로 3x3 convolution이 적용되고 AdaIN + content feature를 적용해 style assemble이 적용

$$\text{AdaIN}(x, \gamma, \beta) = \gamma \left(\frac{x - \mu(x)}{\sigma(x)} \right) + \beta$$

$$\gamma, \beta = \text{MLP}[\text{GAP}(f_s)],$$

$$z = \text{ReLU}[\text{AdaIN}(K_1 \otimes f_c, \gamma, \beta)]$$

$$\text{SAL}(f_c, f_s) = \text{AdaIN}(K_2 \otimes z, \gamma, \beta) + f_c,$$



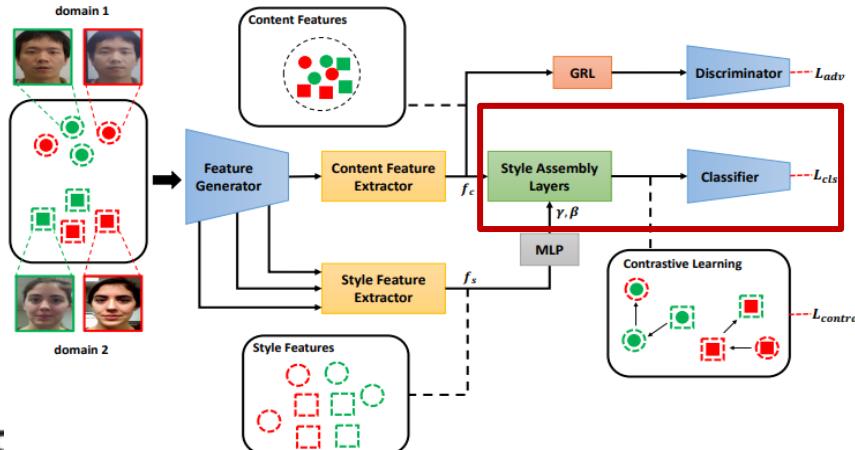
$$S(x_i, x_i) = \text{SAL}(f_c(x_i), f_s(x_i))$$

$$S(x_i, x_{i^*}) = \text{SAL}(f_c(x_i), f_s(x_{i^*}))$$

$$i^* \in \text{random } \{1, 2, \dots, N\}$$

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Contrastive Learning for Stylized Features
 - Shuffled style assembly를 통해 generalization을 진행하는데 이 과정에서 style은 generalize한 style이 domain specific feature인지 liveness-related feature인지 불분명
 - liveness-related style feature를 강조하고 domain-specific feature를 suppress하기 위해 contrastive learning을 적용
 - Content & style feature를 combine함으로써 self-assembly feature $S(x_i, x_i)$, shuffle-assembly features $S(x_i, x_{i*})$ 를 획득
 - Self-assembly feature는 live / spoofing에 대한 classification 네트워크에 입력
 - Shuffle-assembly feature는 $S(x_i, x_i)$, $S(x_i, x_{i*})$ 간의 cosine similarity를 계산

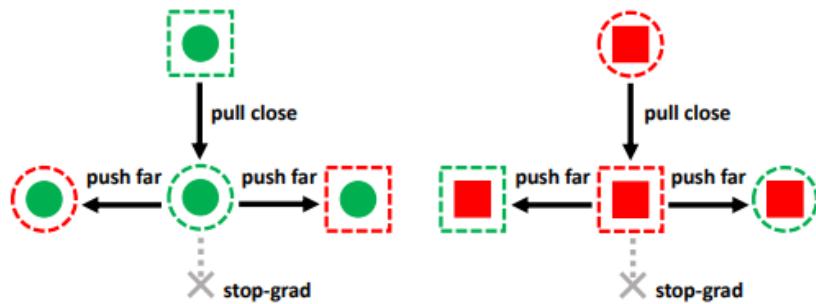


$$\text{Sim}(a, b) = -\frac{a}{\|a\|_2} \cdot \frac{b}{\|b\|_2}$$

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Contrastive Learning for Stylized Features

- Self-assembly feature는 $S(x_i, x_i)$ 는 stylized features space의 anchor 역할
 - Anchor의 역할을 하는 feature는 고정되어야 하므로 stop-gradient가 적용
- shuffle-assembly features $S(x_i, x_{i^*})$ 는 liveness information에 따라 guide됨
 - Live face와 spoofing attack 간의 contrastive learning을 통해 live face와 spoofing attack feature들 간에 compact한 feature mapping을 구성하게 됨



$$L_{contra} = \sum_{i=1}^N Eq(x_i, x_{i^*}) \cdot Sim(\text{stopgrad}(a), b)$$

$$Eq(x_i, x_{i^*}) = \begin{cases} +1, & \text{label}(x_i) == \text{label}(x_{i^*}) \\ -1, & \text{otherwise.} \end{cases}$$

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Experiments

| Method | O&C&I to M | | O&M&I to C | | O&C&M to I | | I&C&M to O | |
|-----------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) |
| MMD-AAE [24] | 27.08 | 83.19 | 44.59 | 58.29 | 31.58 | 75.18 | 40.98 | 63.08 |
| MADDG [41] | 17.69 | 88.06 | 24.50 | 84.51 | 22.19 | 84.99 | 27.98 | 80.02 |
| SSDG-M [21] | 16.67 | 90.47 | 23.11 | 85.45 | 18.21 | 94.61 | 25.17 | 81.83 |
| DR-MD-Net [48] | 17.02 | 90.10 | 19.68 | 87.43 | 20.87 | 86.72 | 25.02 | 81.47 |
| RFMeta [42] | 13.89 | 93.98 | 20.27 | 88.16 | 17.30 | 90.48 | 16.45 | 91.16 |
| NAS-FAS [60] | 19.53 | 88.63 | 16.54 | 90.18 | 14.51 | 93.84 | 13.80 | 93.43 |
| D ² AM [6] | 12.70 | 95.66 | 20.98 | 85.58 | 15.43 | 91.22 | 15.27 | 90.87 |
| SDA [50] | 15.40 | 91.80 | 24.50 | 84.40 | 15.60 | 90.10 | 23.10 | 84.30 |
| DRDG [31] | 12.43 | 95.81 | 19.05 | 88.79 | 15.56 | 91.79 | 15.63 | 91.75 |
| ANRL [30] | 10.83 | 96.75 | 17.83 | 89.26 | 16.03 | 91.04 | 15.67 | 91.90 |
| SSAN-M (Ours) | 10.42 | 94.76 | 16.47 | 90.81 | 14.00 | 94.58 | 19.51 | 88.17 |
| SSDG-R [21] | 7.38 | 97.17 | 10.44 | 95.94 | 11.71 | 96.59 | 15.61 | 91.54 |
| SSAN-R (Ours) | 6.67 | 98.75 | 10.00 | 96.67 | 8.88 | 96.79 | 13.72 | 93.63 |

Domain Generalization via Shuffled Style Assembly for Face Anti-Spoofing

- Experiments

- Feature visualization

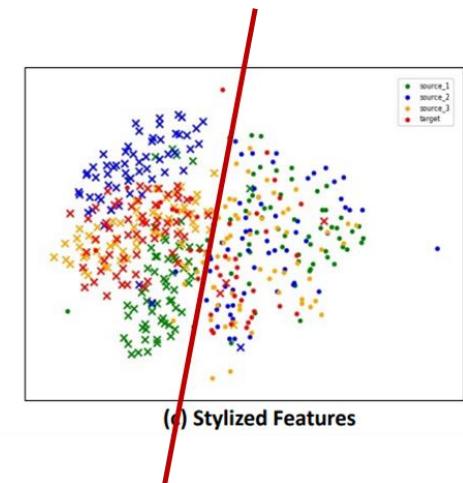
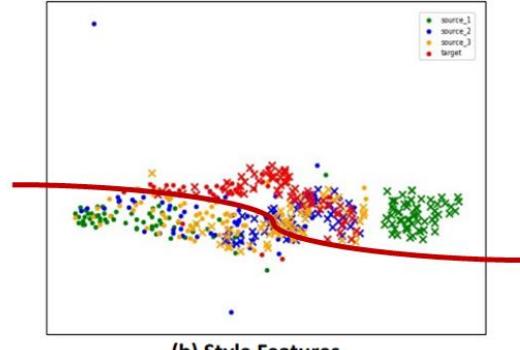
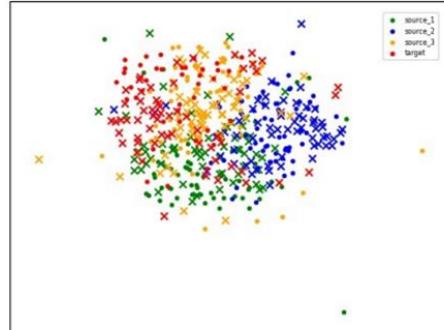
- Content features의 distribution은 compact하고 mixed되어 있는 형태로 나타남

↳ Adversarial learning을 통해 content feature의 기존 distribution 차이가 줄어들었음을 확인 가능

- Style feature들 간에는 별도의 supervision이 없음에도 coarse boundary가 존재

↳ Contrastive learning의 효과로 liveness-related style feature가 emphasize됨

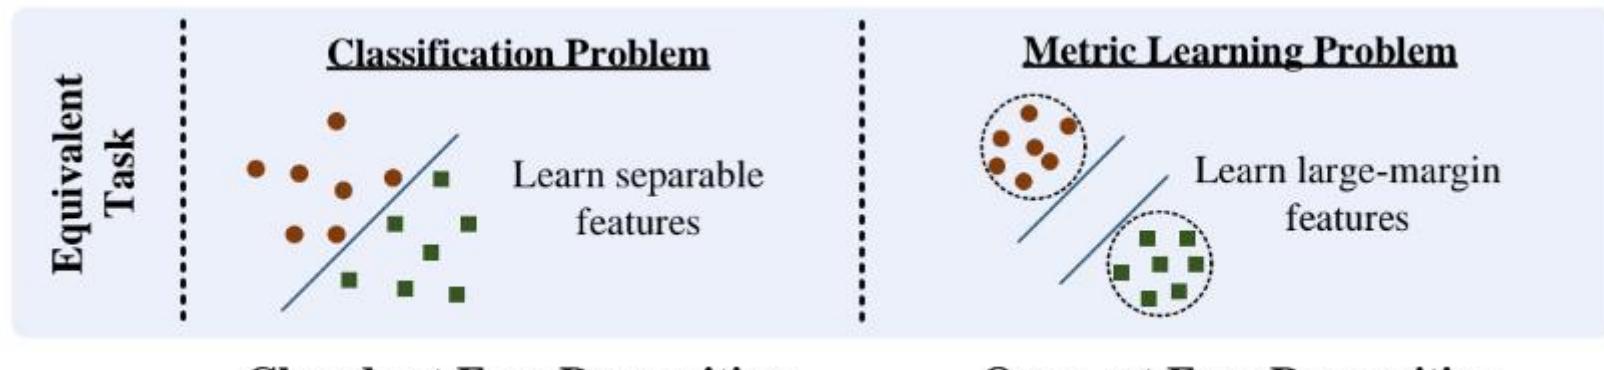
- Stylized feature는 content와 style information을 combine한 feature로 unseen target domain에 대해서도 잘 generalize되었음을 확인 가능



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Preliminary

- 대규모 얼굴 인식을 위해 feature learning을 하는 데에 있어서 주요한 challenge 중 하나는 discriminative power를 강화하는 loss function의 설계임
- 기존의 softmax 기반 loss는 closed-set 분류 문제에 대해서는 feature가 분류 될 수 있지만 open-set 환경에서 충분히 discriminative 하지 못함
- Angular margin softmax는 마지막 fully connected layer에서의 linear transformation matrix가 angular space에서 class의 중심을 나타내는 표현으로 사용 될 수 있다고 가정



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Preliminary

- Example

- 얼굴 이미지 feature $x = [10, 20, 30]$

- Feature를 입력으로 받았을 때, 2가지 identity로 분류하는 task를 진행하는 fully connected layer를 구성하는 matrix $A = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{pmatrix}$

이때 A의 행은 class의 개수, 열은 feature의 차원을 의미함

(1 2 3)은 첫 번째 identity의 중심, (4 5 6)은 두 번째 identity의 중심을 나타냄

- Fully connected layer를 통한 xA^T 연산 결과는 $(10*1 + 20*2 + 30*3, 10*4 + 20*5 + 30*6)$

이러한 과정을 통해 얼굴 이미지 feature 입력 시 각 identity에 대한 prediction score 계산

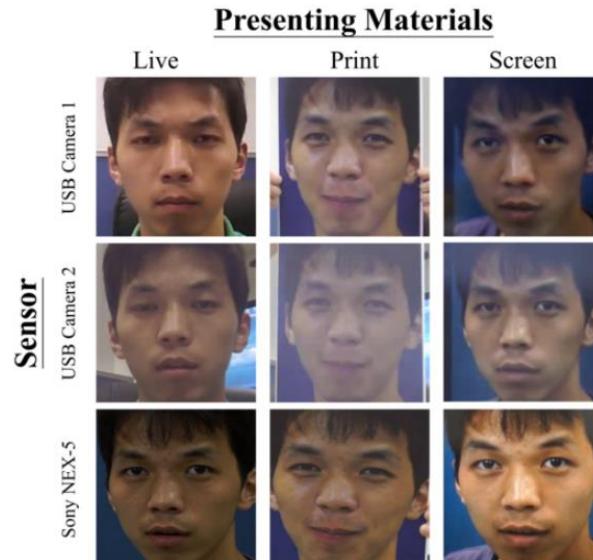
- 각 identity의 중심과 prediction score를 normalization한 결과는 각각 $(1/\sqrt{14}, 2/\sqrt{14}, 3/\sqrt{14})$, $(4/\sqrt{77}, 5/\sqrt{77}, 6/\sqrt{77})$, $(10/\sqrt{1400}, 20/\sqrt{1400}, 30/\sqrt{1400})$

- 이러한 과정을 통해 identity의 중심과 얼굴 이미지 feature의 prediction이 모두 중심이 (0,0,0)인 구 위에 mapping 됨

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Patch Features Extraction

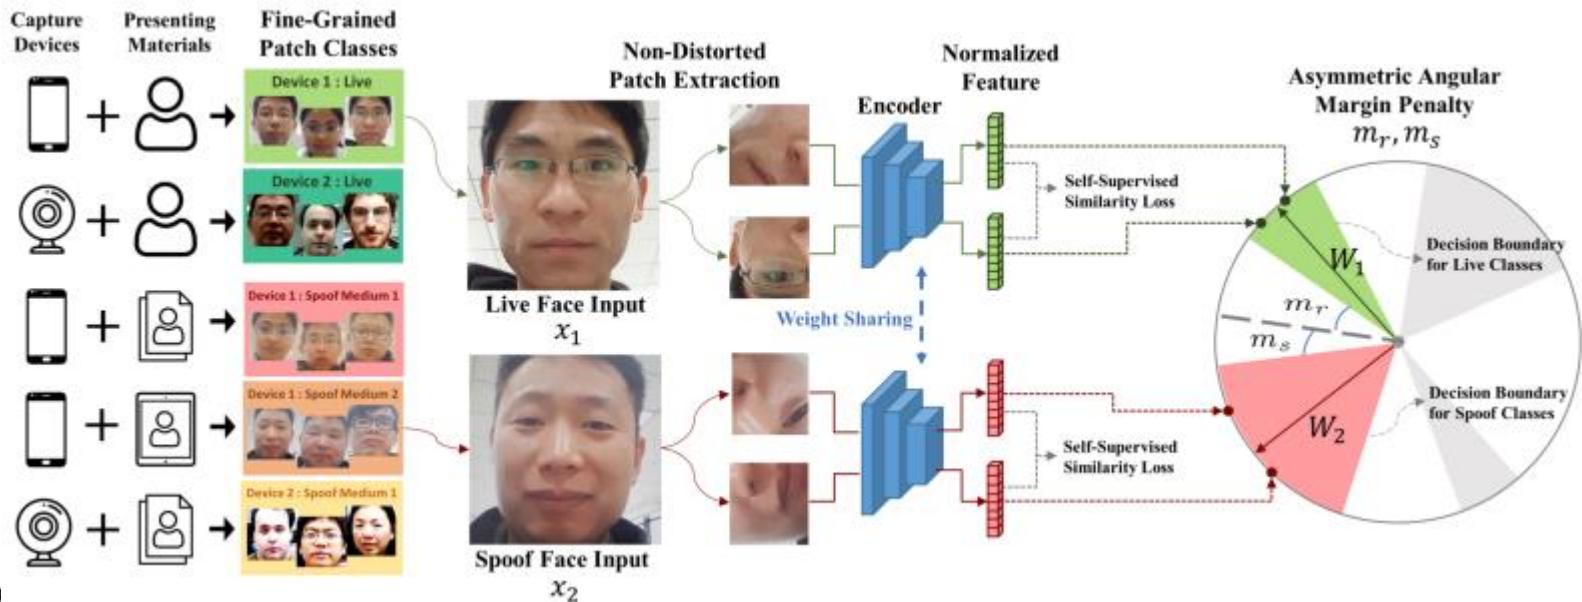
- 해당 논문에서는 face image를 capturing devices와 presenting materials에 따라 category를 세분화하여 fine-grained 환경으로 세분화함
 - 예시로 CASIA-FASD 데이터 셋에는 2가지의 spoof medium과 3종류의 capturing device가 존재
3개의 live types과 2*3개의 spoof types으로 총 9개의 class로 나뉘어짐
 - 이를 통해 해당 논문은 기존의 binary 관점의 구분이 아닌 세분화된 구분으로 학습된 robust한 네트워크를 구성함



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

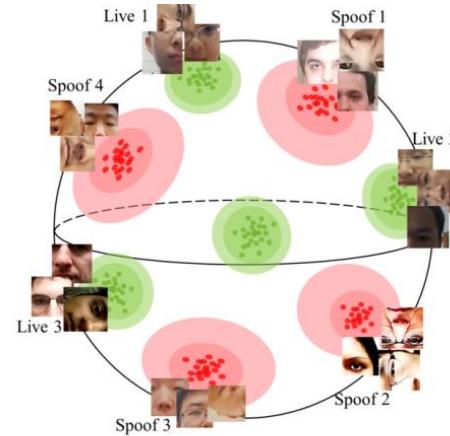
- Patch Features Extraction

- 해당 논문에서는 fine-grained patch를 얻는 데에 있어서 이미지의 distortion이나 spoof-related information을 잃는 것을 막기위해 augmentation을 선별적으로 사용
 - Random horizontal flip, random rotation, fixed size cropping을 활용
- face region x_i 에 대하여 2개의 각기 다른 augmentation t_1, t_2 를 적용하여 $x_i^{t_1}, x_i^{t_2}$ 를 얻음



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Fine-Grained patch Recognition
 - 학습 데이터 셋에 patch type classes가 N개가 있다고 가정 시 k개의 live class, N-k의 spoof classes로 구성
 - 각각의 input patch는 해당 $y_i \in \{L_1, L_2, \dots, L_k, S_1, S_2, \dots, S_{N-k}\}$ 중 하나의 class에 포함
 - Patch feature를 regularize하기 위해 AM-Softmax loss를 활용
 - Open-set identity에 최적화된 loss를 활용함으로써 generalization ability를 향상 시킴



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Asymmetric AM-Softmax Loss

- **AM-Softmax**

- 기존 Softmax는 feature embedding에 대해 intra-class compactness가 얼굴 인식에 적용될 만큼 고려되지 않고 class 구분에만 초점이 맞추어져 있음

- AM-Softmax loss 를 활용하여 intra-class에서는 compact하면서 generalization 능력을 높임

- $\log W_j^T f_i = \|W_j\| \|f_i\| \cos \theta_j$ 로 변환

$\therefore \theta_j$ 는 W_j 와 feature f_i 간의 각도

$$\begin{aligned} \mathcal{L}_S &= -\frac{1}{n} \sum_{i=1}^n \log \frac{e^{W_{y_i}^T f_i}}{\sum_{j=1}^c e^{W_j^T f_i}} \\ &= -\frac{1}{n} \sum_{i=1}^n \log \frac{e^{\|W_{y_i}\| \|f_i\| \cos(\theta_{y_i})}}{\sum_{j=1}^c e^{\|W_j\| \|f_i\| \cos(\theta_j)}} \end{aligned}$$

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Asymmetric AM-Softmax Loss

- **AM-Softmax**

- $0 \leq \theta_1 \leq \frac{1}{m}$ 의 조건 하에 cos함수는 단조 감소의 형태를 나타냄

- 따라서 함수에 m값을 크게 적용하게 되면 θ_1 의 범위가 줄어들고 더 compact한 구성으로써 margin을 크게 가져갈 수 있게 됨

- Margin을 직관적으로 간편하게 가져가기 위해서 m을 곱하는 형식이 아니라 $\cos \theta_{y_i} - m$ 으로 처리하여도 의미적으로 같은 뜻을 가짐

$$\begin{aligned}
 \mathbf{W}_1^T \mathbf{x} &> \mathbf{W}_2^T \mathbf{x} \\
 \|\mathbf{W}_1\| \|\mathbf{x}\| \cos(\theta_1) &> \|\mathbf{W}_2\| \|\mathbf{x}\| \cos(\theta_2) \\
 \|\mathbf{W}_1\| \|\mathbf{x}\| \cos(\theta_1) &\geq \|\mathbf{W}_1\| \|\mathbf{x}\| \cos(m\theta_1) \\
 &> \|\mathbf{W}_2\| \|\mathbf{x}\| \cos(\theta_2). \\
 (0 \leq \theta_1 \leq \frac{\pi}{m})
 \end{aligned}$$

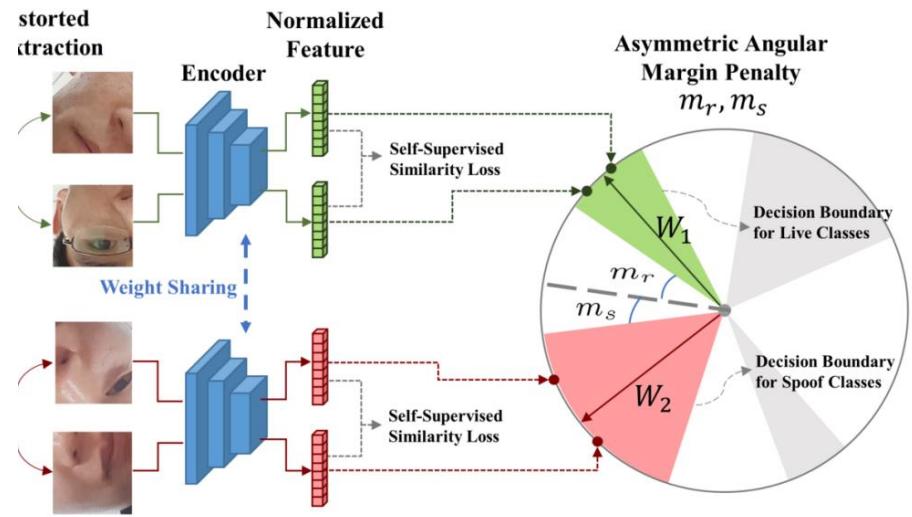
$$\begin{aligned}
 \mathcal{L}_{AMS} &= -\frac{1}{n} \sum_{i=1}^n \log \frac{e^{s \cdot (\cos \theta_{y_i} - m)}}{e^{s \cdot (\cos \theta_{y_i} - m)} + \sum_{j=1, j \neq y_i}^c e^{s \cdot \cos \theta_j}} \\
 &= -\frac{1}{n} \sum_{i=1}^n \log \frac{e^{s \cdot (W_{y_i}^T f_i - m)}}{e^{s \cdot (W_{y_i}^T f_i - m)} + \sum_{j=1, j \neq y_i}^c e^{s \cdot W_j^T f_i}}
 \end{aligned}$$

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Asymmetric AM-Softmax Loss
 - Spoofing의 패턴은 live sample에 비해 다양해 질 수 있기 때문에 distribution discrepancies 또한 spoofing sample이 더욱 큼
 - 이러한 특징을 feature space에서 realistic하게 반영하기 위해 AM-Softmax loss를 asymmetric하게 적용하여 FAS task에 더 적합하게 compact한 cluster를 구성
 - Live type에 lager angular margin을 적용하여 live type을 더 compact하게 구성

$$\mathcal{L}_{AAMS}(f_i) = \begin{cases} -\log \frac{e^{s \cdot (W_{y_i}^T f_i - m_l)}}{e^{s \cdot (W_{y_i}^T f_i - m_l)} + \sum_{j=1, j \neq y_i}^N e^{s \cdot W_j^T f_i}} & y_i \in L \\ -\log \frac{e^{s \cdot (W_{y_i}^T f_i - m_s)}}{e^{s \cdot (W_{y_i}^T f_i - m_s)} + \sum_{j=1, j \neq y_i}^N e^{s \cdot W_j^T f_i}} & y_i \in S \end{cases}$$

$$\mathcal{L}_{Asym} = -\frac{1}{n} \sum_{i=1}^n (\mathcal{L}_{AAMS}(f_i^{t_1}) + \mathcal{L}_{AAMS}(f_i^{t_2}))$$



PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Self-Supervised Similarity Loss
 - 하나의 face image에서 얻어진 2개의 transformed patch views에 대해 self-supervised similarity loss를 적용
 - Spoof-specific discriminative information이 전체 face region에 대하여 존재
 - ↳ 따라서 같은 face capture에서 얻어진 2개의 patch views의 feature가 유사한 특성을 지녀야함
 - 해당 loss를 통해서 같은 이미지에서 얻어진 다른 patch 간의 location과 rotation으로 인한 feature의 정보 차이와 무관한 feature를 구성하게 만듦

$$\mathcal{L}_{Sim}(f_i^{t_1}, f_i^{t_2}) = \frac{1}{n} \sum_{i=1}^n \|f_i^{t_1} - f_i^{t_2}\|_2$$

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Testing Strategy
 - Test 시에는 face image에서 uniform하게 crop(training에서의 crop size와 같게) 진행
 - 이를 통해 하나의 face image에 대하여 P개의 patch features를 얻음(f^1, f^2, \dots, f^P)
 - 모든 patch features들에서 얻은 live class probabilities를 평균하여 하나의 face image에 대하여 live probability를 얻을 수 있음

$$LiveProb = \frac{1}{P} \sum_{i=1}^P \sum_{y \in L} Softmax(s \cdot W_y^T f^i)$$

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Experiments

| Method | O&C&I to M | | O&M&I to C | | O&C&M to I | | I&C&M to O | |
|----------------------------------|-------------|--------------|--------------|--------------|-------------|--------------|--------------|--------------|
| | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) |
| PatchNet w/ coarse cls [12] | 10.24 | 96.45 | 15.67 | 92.47 | 21.65 | 91.08 | 16.26 | 91.33 |
| PatchNet w/o margin | 10.0 | 96.61 | 18.0 | 91.57 | 17.25 | 90.47 | 15.04 | 92.42 |
| PatchNet w/o \mathcal{L}_{Sim} | 8.9 | 97.42 | 13.44 | 93.99 | 15.1 | 92.10 | 14.24 | 92.93 |
| PatchNet (Ours) | 7.10 | 98.46 | 11.33 | 94.58 | 14.6 | 92.51 | 11.82 | 95.07 |

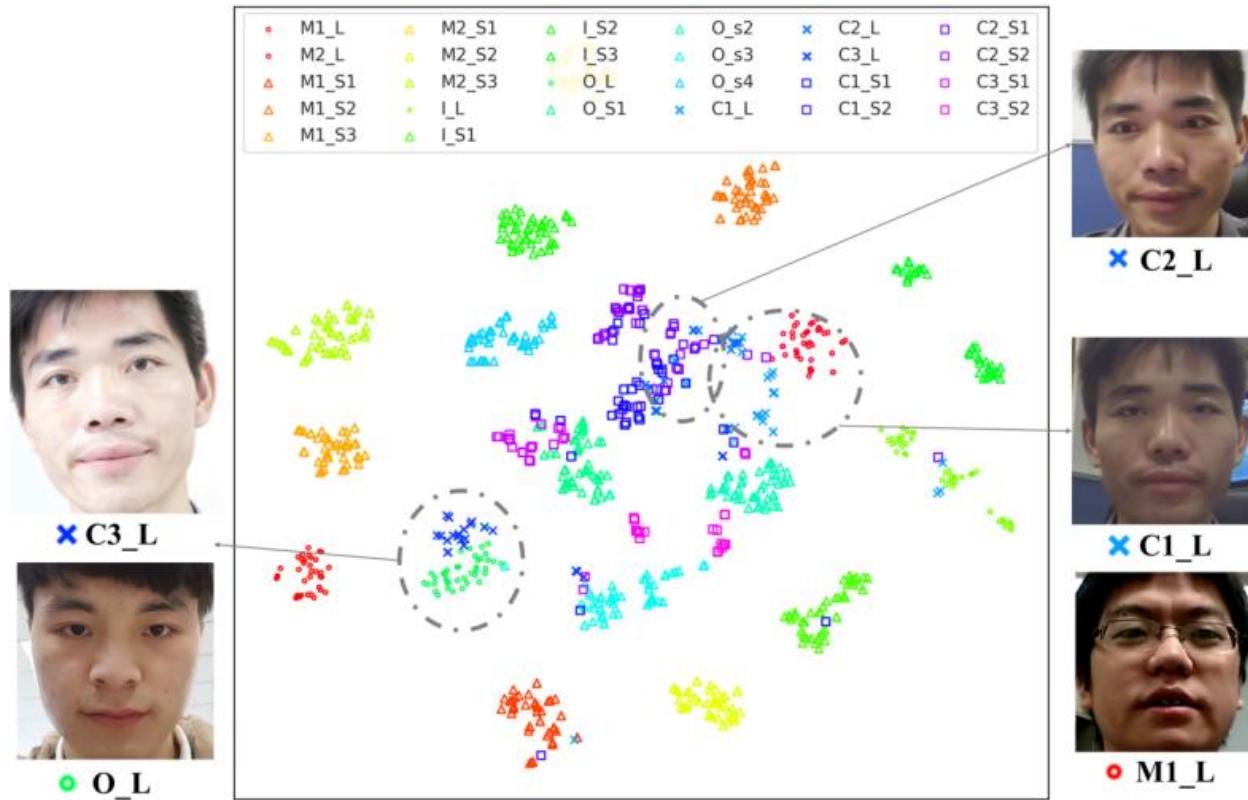
Table 7. Evaluations of different components of the proposed method on four cross-dataset protocols.

| Method | O&C&I to M | | O&M&I to C | | O&C&M to I | | I&C&M to O | |
|------------------------|-------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) | HTER(%) | AUC(%) |
| Auxiliary [18] | 22.72 | 85.88 | 33.52 | 73.15 | 29.14 | 71.69 | 30.17 | 77.61 |
| MADDG [20] | 17.69 | 88.06 | 24.50 | 84.51 | 22.19 | 84.99 | 27.89 | 80.02 |
| PAD-GAN [24] | 17.02 | 90.10 | 19.68 | 87.43 | 20.87 | 86.72 | 25.02 | 81.47 |
| RFM [21] | 13.89 | 93.98 | 20.27 | 88.16 | 17.30 | 90.48 | 16.45 | 91.16 |
| NAS-FAS [31] | 16.85 | 90.42 | 15.21 | 92.64 | 11.63 | 96.98 | 13.16 | 94.18 |
| SSDG-R [12] | 7.38 | 97.17 | 10.44 | 95.94 | 11.71 | 96.59 | 15.61 | 91.54 |
| ANRL [14] | 16.03 | 91.04 | 10.83 | 96.75 | 17.85 | 89.26 | 15.67 | 91.90 |
| DRDG [15] | 15.56 | 91.79 | 12.43 | 95.81 | 19.05 | 88.79 | 15.63 | 91.75 |
| PatchNet (Ours) | 7.10 | 98.46 | 11.33 | 94.58 | 13.4 | 95.67 | 11.82 | 95.07 |

Table 8. Comparison results between the proposed PatchNet and state-of-the-art methods on four domain generalization protocols.

PatchNet: A Simple Face Anti-Spoofing Framework via Fine-Grained Patch Recognition

- Experiments



감사합니다