

Learning an Ethical Module for Bias Mitigation of pre-trained Face Recognition Models

Journée de la chaire DSAIDIS

Jean-Rémy Conti, *IDEMIA, Télécom Paris*

Nathan Noiry, *Télécom Paris*

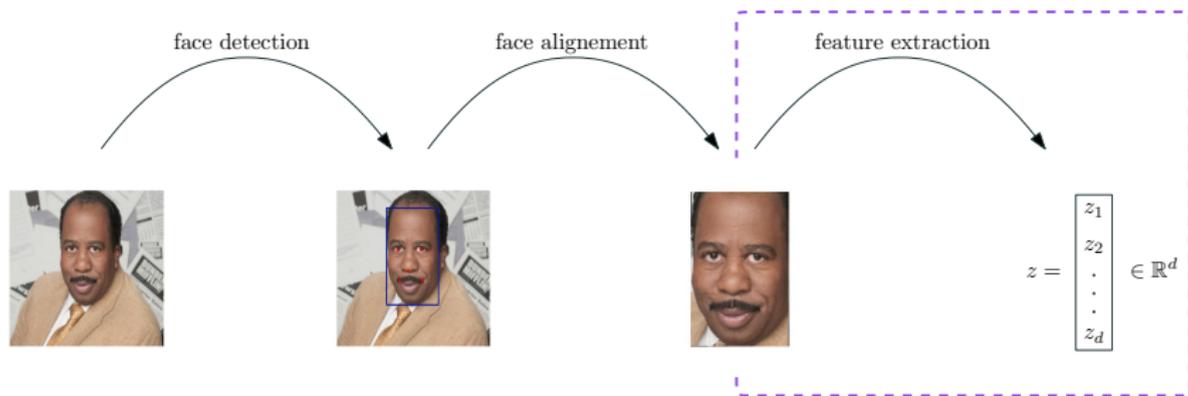
Télécom Paris

15 juin 2022

- **Comment reconnaître un visage ?**
- **Comment mesurer l'équité ?**
- **Comment corriger un biais de genre ?**

Reconnaissance faciale : **introduction rapide**

Les étapes de la reconnaissance faciale



Depuis 2014 : réseau neuronal convolutif

Objectif : Faire en sorte que les différentes représentations d'une même identité soient proches dans l'espace latent.

Ingrédients : fonction de perte, base de données, architecture.

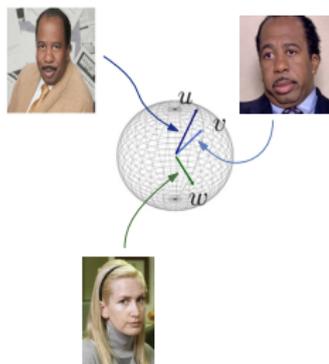
Les étapes de la reconnaissance faciale

Dernière étape : comparer deux visages (*face matching*).

La majorité des systèmes utilisent des représentations normalisées sur l'hypersphère \mathbb{S}^{d-1} et mesurent la similarité avec le produit scalaire usuel.

Règle de décision : $t \in [-1, 1]$ seuil fixé.

- $\langle u, v \rangle \geq t \Rightarrow$ "même identité",
- $\langle u, w \rangle < t \Rightarrow$ "identités distinctes".



Les étapes de la reconnaissance faciale

Dernière étape : comparer deux visages (*face matching*).

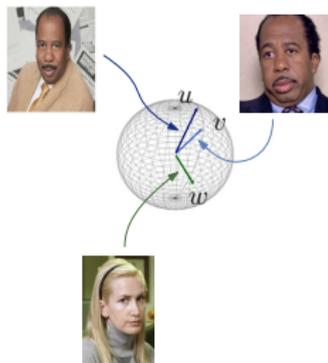
La majorité des systèmes utilisent des représentations normalisées sur l'hypersphère \mathbb{S}^{d-1} et mesurent la similarité avec le produit scalaire usuel.

Règle de décision : $t \in [-1, 1]$ seuil fixé.

- $\langle u, v \rangle \geq t \Rightarrow$ "même identité",
- $\langle u, w \rangle < t \Rightarrow$ "identités distinctes".

Deux applications :

- **Vérification (1:1)** : est-ce que deux images correspondent à la même personne ?
 \rightsquigarrow contrôle aux frontières.
- **Reconnaissance (1:N)** : est-ce qu'une image donnée correspond à l'identité d'une base existante ?
 \rightsquigarrow recherche d'individu.



Métrique d'évaluation

Deux types d'erreur peuvent se produire :

- Faux positifs : prédire “même identité” pour une paire d'images de deux individus distincts. \rightsquigarrow False Acceptance Rate: FAR.
- Faux négatifs : prédire “identités distinctes” pour une paire d'images d'un même individu. \rightsquigarrow False Rejection Rate: FRR.

Métrie d'évaluation

Deux types d'erreur peuvent se produire :

- Faux positifs : prédire “même identité” pour une paire d'images de deux individus distincts. \rightsquigarrow False Acceptance Rate: FAR.
- Faux négatifs : prédire “identités distinctes” pour une paire d'images d'un même individu. \rightsquigarrow False Rejection Rate: FRR.

En pratique :

1. On fixe un point de fonctionnement $t \in [-1, 1]$ afin d'obtenir un taux de faux positifs α jugé acceptable.
2. On calcule le taux de faux négatifs à ce seuil.

$$\text{FRR} @ (\text{FAR} = \alpha) := \text{FRR}(t), \text{ où } \text{FAR}(t) = \alpha.$$

Typiquement $\alpha = 10^{-1}, 10^{-2}, \dots, 10^{-8}$.

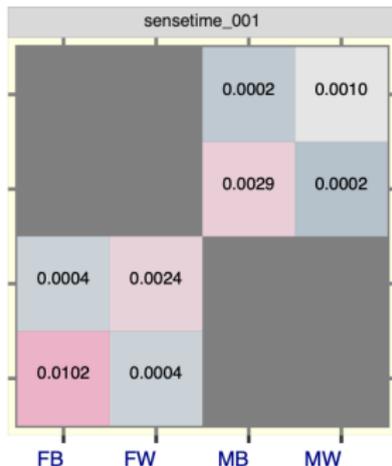
Le *National Institute of Standards and Technology* évalue régulièrement les algorithmes de reconnaissance faciale. Sur la performance...

Algorithm	Constrained, Cooperative					
	FMR	= 0.000001	= 0.00001	= 0.00001	= 0.000001	= 0.000001
Submission Date	VISA Photos	MUGSHOT Photos	MUGSHOT Photos 12+YRS	VISABORDER Photos	BORDER Photos	
sensetime-005	2021-05-24	0.0029 ⁽¹⁷⁾	0.0022 ⁽¹⁾	0.0021 ⁽¹¹⁾	0.0023 ⁽¹⁾	0.0044 ⁽¹⁾
visionlabs-011	2021-10-13	0.0022 ⁽⁷⁾	0.0024 ⁽⁹⁾	0.0026 ⁽⁷⁾	0.0028 ⁽²⁾	0.0053 ⁽²⁾
ntechlab-011	2021-09-13	0.0019 ⁽⁴⁾	0.0024 ⁽⁸⁾	0.0028 ⁽¹⁸⁾	0.0029 ⁽³⁾	0.0055 ⁽³⁾
clearviewai-000	2021-09-22	0.0019 ⁽⁵⁾	0.0024 ⁽⁵⁾	0.0028 ⁽¹¹⁾	0.0030 ⁽⁴⁾	0.0058 ⁽⁵⁾
mendaxiatech-000	2021-09-15	0.0036 ⁽²⁵⁾	0.0029 ⁽²⁶⁾	0.0036 ⁽³²⁾	0.0031 ⁽⁵⁾	0.0057 ⁽⁴⁾
ntechlab-010	2021-04-30	0.0017 ⁽²⁾	0.0024 ⁽¹⁰⁾	0.0029 ⁽²⁰⁾	0.0031 ⁽⁶⁾	0.0058 ⁽⁶⁾
cubox-002	2021-08-24	0.0041 ⁽³⁵⁾	0.0025 ⁽¹¹⁾	0.0025 ⁽⁶⁾	0.0033 ⁽⁷⁾	0.0064 ⁽⁹⁾
visionlabs-010	2021-01-25	0.0024 ⁽⁹⁾	0.0026 ⁽¹⁶⁾	0.0030 ⁽²²⁾	0.0033 ⁽⁸⁾	0.0061 ⁽⁷⁾
toshiba-004	2021-09-27	0.0042 ⁽⁴⁰⁾	0.0025 ⁽¹²⁾	0.0027 ⁽⁹⁾	0.0034 ⁽⁹⁾	0.0063 ⁽⁸⁾
jdemia-008	2021-07-07	0.0032 ⁽¹⁹⁾	0.0023 ⁽³⁾	0.0028 ⁽¹⁰⁾	0.0034 ⁽¹⁰⁾	0.0067 ⁽¹¹⁾
kakao-006	2021-10-13	0.0029 ⁽¹⁶⁾	0.0024 ⁽⁴⁾	0.0028 ⁽¹⁶⁾	0.0035 ⁽¹¹⁾	0.0065 ⁽¹⁰⁾
insightface-001	2021-09-27	0.0014 ⁽¹⁾	0.0027 ⁽¹⁹⁾	0.0024 ⁽³⁾	0.0035 ⁽¹²⁾	0.0070 ⁽¹³⁾
paravision-008	2021-07-01	0.0025 ⁽¹¹⁾	0.0024 ⁽⁶⁾	0.0025 ⁽⁵⁾	0.0036 ⁽¹³⁾	0.0070 ⁽¹⁴⁾
insightface-000	2021-03-17	0.0027 ⁽¹⁵⁾	0.0029 ⁽²⁵⁾	0.0030 ⁽²³⁾	0.0038 ⁽¹⁴⁾	0.0077 ⁽²⁰⁾

Différentiel démographique

Rapports du NIST

... Et sur les disparités de performance en fonction des sous-groupes de la population !



FAR pour des sous-groupes ethnie+genre.

F: female, M: male, B: black, W: white.

↪ Certains algorithmes commettent 10 fois plus d'erreurs sur les femmes noires que sur les hommes blancs.

Contexte

- \mathcal{G} : ensemble de sous-groupes de la population.
Exemples : hommes / femmes, jeunes / âgés ...
- Pour tout $g \in \mathcal{G}$, FAR_g et FRR_g False Acceptance and False Rejection Rates au sein du sous-groupe g .

Contexte

- \mathcal{G} : ensemble de sous-groupes de la population.
Exemples : hommes / femmes, jeunes / âgés ...
- Pour tout $g \in \mathcal{G}$, FAR_g et FRR_g False Acceptance and False Rejection Rates au sein du sous-groupe g .

Plusieurs propositions de métriques

1. Deux propositions de ratios :

$$\underbrace{\frac{\max_g FAR_g(t)}{\min_g FAR_g(t)}}_{\text{pire écart}} \quad \text{v.s.} \quad \underbrace{\frac{\max_{g \in \mathcal{G}} FAR_g(t)}{(1/|\mathcal{G}|) \sum_g FAR_g(t)}}_{\text{écart à la moyenne}}$$

Contexte

- \mathcal{G} : ensemble de sous-groupes de la population.
Exemples : hommes / femmes, jeunes / âgés ...
- Pour tout $g \in \mathcal{G}$, FAR_g et FRR_g False Acceptance and False Rejection Rates au sein du sous-groupe g .

Plusieurs propositions de métriques

1. Deux propositions de ratios :

$$\underbrace{\frac{\max_g \text{FAR}_g(t)}{\min_g \text{FAR}_g(t)}}_{\text{pire écart}} \quad \text{v.s.} \quad \frac{\max_{g \in \mathcal{G}} \text{FAR}_g(t)}{\underbrace{(1/|\mathcal{G}|) \sum_g \text{FAR}_g(t)}}_{\text{écart à la moyenne}}.$$

2. Deux propositions de seuil :

$$\text{FAR}(t) = \alpha \quad \text{v.s.} \quad \max_{g \in \mathcal{G}} \text{FAR}_g(t) = \alpha.$$

Correction des biais de genre

Survол de quelques méthodes existantes

Pré-entraînement : re-pondération / augmentation

- **Balanced Datasets Are Not Enough**, Wang and al. 2019.
- **How Does Gender Balance In Training Data Affect Face Recognition Accuracy?**, Albiero and al. 2020.

↪ Pas encore adapté pour la reconnaissance faciale.

Méthodes adverses pendant l'entraînement

- **PASS: Protected attribute suppression system for mitigating bias in face recognition**, Dhar and al. 2021.
- **How Does Gender Balance In Training Data Affect Face Recognition Accuracy?**, Albiero and al. 2020.

↪ Prohibitif en temps de calcul et instable.

Méthodes de post-traitement : modification des scores de similarité

- **Bias mitigation of face recognition models through calibration.**, Salvador and al. 2021.

↪ Ne résout pas le problème à la source.

Notre proposition : greffer un réseau de neurone superficiel sur la dernière couche d'un modèle pré-entraîné afin de corriger les biais de représentativité de l'espace latent.

**Mitigating Gender Bias in Face Recognition
Using the von Mises-Fisher Mixture Model**

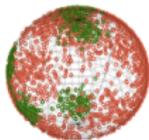
Jean-Rémy Conti^{*1,2} Nathan Noiry^{*1} Vincent Despiegel² Stéphane Gentric² Stéphan Cléménçon¹

Accepté pour publication à ICML 2022.

Origine géométrique des biais et modèle statistique

Observation : Les représentations latentes des femmes occupent une portion plus petite de l'hypersphère que les représentations latentes des hommes.

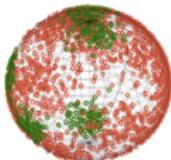
- femmes
- hommes



Origine géométrique des biais et modèle statistique

Observation : Les représentations latentes des femmes occupent une portion plus petite de l'hypersphère que les représentations latentes des hommes.

○ femmes
○ hommes



$$\mathbb{P}(X \in dx) = \sum_{k=1}^K \pi_k \overbrace{C_d(\kappa_k)}^{\text{gaussienne sur l'hypersphère}} \exp(\kappa_k \mu_k^T x)$$

K identités

μ_k : centroid de l'identité k

$$\kappa_k = \begin{cases} \kappa_F & \text{si femme,} \\ \kappa_H & \text{si homme.} \end{cases}$$

↪ Mélange de von-Mises Fisher. Le paramètre κ est appelé coefficient de concentration et peut être interprété comme l'inverse d'une variance.

Maximum de vraisemblance et loss de vMF

Si l'on fixe les coefficients de concentrations κ_H et κ_F , la log-vraisemblance ℓ du modèle s'écrit

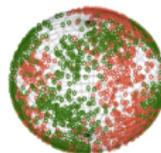
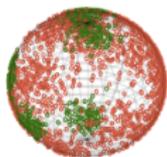
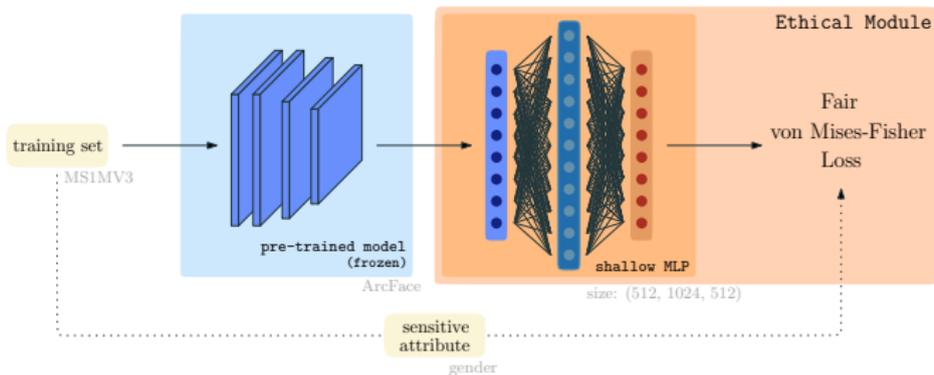
$$\ell(\mu, \theta) = \frac{1}{N} \sum_{i=1}^N \log \left[\frac{C_d(\kappa_{y_i}) e^{\kappa_{y_i} \mu_{y_i}^T z_i}}{\sum_{k=1}^K C_d(\kappa_k) e^{\kappa_k \mu_k^T z_i}} \right],$$

où $z_i = f_\theta(x_i)$ est la représentation latente d'une image x_i .

On introduit ainsi une *Fair von Mises-Fisher loss* :

$$\mathcal{L}_{\text{FvMF}} := -\ell(\mu, \theta).$$

Description du Module Ethique



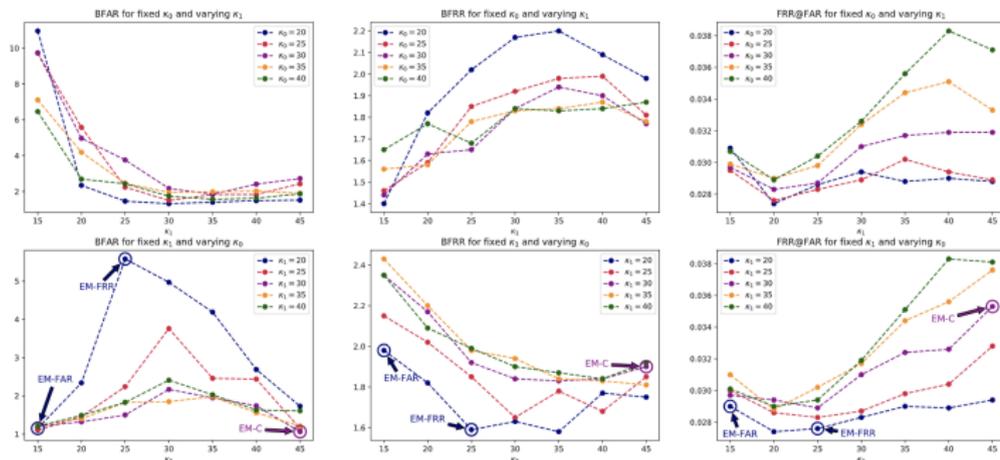
○ femmes
○ hommes

Avantages de la méthode

- Application à tout réseau pré-entraîné,
- Entraînement rapide,
- Tire partie de la performance des réseaux pré-entraînés,
- Interprétabilité : minimiser la loss de von Mises-Fisher revient à maximiser la vraisemblance d'un modèle de mélange gaussien,
- L'attribut sensible est uniquement utilisé lors de la phase d'entraînement du modèle, pas au cours de son fonctionnement en production.

Résultats prometteurs

BFAR and BFRR trends are correlated with κ_H and κ_F .



Amélioration de l'état de l'art pour certains points choisis.

FAR LEVEL:	10^{-4}			10^{-3}		
	FRR@FAR (%)	BFRR	BFAR	FRR@FAR (%)	BFRR	BFAR
ARCFACE	0.078	10.27	4.72	<u>0.059</u>	4.17	1.81
ARCFACE + PASS-G	0.315	4.54	6.51	0.107	5.22	2.11
ARCFACE + EM-FAR	0.151	11.22	2.11	0.072	9.16	1.19
ARCFACE + EM-FRR	<u>0.100</u>	<u>5.89</u>	33.65	0.058	4.11	5.24
ARCFACE + EM-C	0.164	9.18	<u>2.44</u>	0.081	5.15	<u>1.20</u>

- Adaptation de la méthode dans d'autres contextes que la reconnaissance faciale
- Adaptation de la méthode pour d'autres problèmes d'équités en reconnaissance faciale (race, âge)
- Mise au point d'un algorithme d'exploration efficace de l'espace des hyperparamètres.

...

D'autres suggestions ?

Merci de votre attention !