

Présentation Finale

Amélioration des systèmes de vérification du locuteur contre les attaques Deepfakes

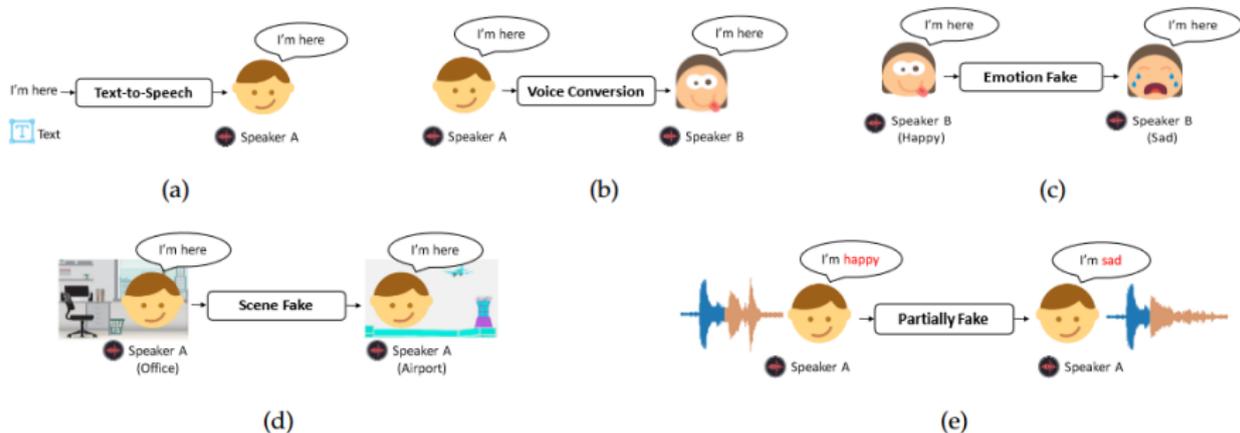
Encadré par **Réda Dehak** et **Théo Lepage**



Contexte

Usurpation d'identité avec de l'audio deepfake

Différents types de deepfakes [10]:



Objectif du système:

- Détecter les *artefacts* laissés par l'algorithme dans l'audio

Problèmes:

- Type d'attaque inconnu
- Compression de l'audio sur les plateformes en lignes
- Les attaquants ont accès aux systèmes de détections pour améliorer la qualité de leur algorithme



Schéma du système proposé par l'atelier ASVspoof 2019 [9]




Figure 1: LA access and PA access adopted for ASVspoof 2019

Deux systèmes étudiés:

- RawNet2 [7]
- AASIST [3]

Proposition:

Améliorer les performances du système en intégrant un modèle auto-supervisé pré-entraîné comme encodeur [6] [4]




- a introduit le fait d'utiliser l'audio brut en entrée d'un système de détection
- modèle compact ($\approx 25 * 10^6$ paramètres)
- crée pour le challenge ASVspoof 2019 et utilisé comme *baseline* dans l'édition 2021

Layer	Input: 64000 samples	Output shape	
Fixed Sinc filters	Conv(129 ,1,128)	(21290,128)	
	Maxpooling(3) BN & LeakyReLU		
Res block	$\left\{ \begin{array}{l} \text{BN \& LeakyReLU} \\ \text{Conv}(3,1,128) \\ \text{BN \& LeakyReLU} \\ \text{Conv}(3,1,128) \\ \text{Maxpooling}(3) \\ \text{FMS} \end{array} \right\} \times 2$	(2365,128)	
Res block	$\left\{ \begin{array}{l} \text{BN \& LeakyReLU} \\ \text{Conv}(3,1, \mathbf{512}) \\ \text{BN \& LeakyReLU} \\ \text{Conv}(3,1, \mathbf{512}) \\ \text{Maxpooling}(3) \\ \text{FMS} \end{array} \right\} \times 4$	(29,512)	
GRU	GRU(1024)	(1024)	
FC	1024	(1024)	
Output	1024	2	

Architecture du modèle RawNet2 [7]



- se base sur un encodeur similaire au RawNet2
- sépare la dimension fréquentielle et la dimension temporelle à la sortie de l'encodeur
- utilise des GANs (Graph Attention Networks)




Architecture du modèle AASIST [3]

Proposition

Extension du RawNet2 avec le modèle Wav2Vec2.0


Modèle Wav2Vec2.0[1]:

- Modèle auto-supervisé pré-entraîné sur de très gros corpus de voix
- S'entraîne en essayant de reconstruire des parties de l'audio qui ont été masqué



Introduction de deux nouveaux paramètres[4]: **TTL** et **FTL**

- TTL: # de couches Transformers sélectionnées
- FTL: # de couches Transformers fixées



Proposition

Adaptation du modèle MHFA pour la détection de deepfake

Modèle utilisé originellement pour de la vérification du locuteur [6] [5]

- *Fine-tune* un modèle auto-supervisé pré-entraîné en *front-end*
- Effectue un calcul d'attention entre les sorties des différentes couches Transformers
- Applique une régularisation des poids sur l'encodeur pour ne pas trop s'éloigner des paramètres de base

Pour adapter ce modèle à une tâche de détection:

- Ajout d'une couche linéaire à la fin du réseau avec deux éléments en sortie

Structure du modèle[6]:




Fig. 3. (c) Proposed Multi-Head Factorized Attentive Pooling.

Protocole d'évaluation

Jeu de donnée *ASVspoff 2019 LA*

Les jeux de données utilisés sont issus de l'ensemble ***ASVspoff2019 LA***:

Jeu de donnée	# d'échantillons	% d'échantillons factices
<i>Entraînement</i>	25 380	89.83%
<i>Développement</i>	24 844	89.74%
<i>Évaluation</i>	71 237	89.67%



Equal Error Rate (EER) sur la tâche de détection: Probabilité d'erreur lorsque l'on choisit un seuil pour lequel on a autant de faux positifs que de faux négatifs sur le jeu de données d'évaluation.

min-DCF: Score qui prend en compte la probabilité de la catégorie cible (P_{tar}), et qui attribue un coût aux deux types d'erreurs: faux positif (C_{FA}) et faux négatif (C_{miss}).

$$C_{det}(P_{miss}, P_{FA}) = C_{miss}P_{miss}P_{tar} + C_{FA}P_{FA}(1 - P_{tar})$$



Protocole d'évaluation

Métriques d'évaluation

min-tDCF: Similaire au min-DCF, mais prend en compte les scores d'un système de vérification du locuteur (ASV) en plus des scores d'un système de détection (CM). Cela introduit 4 types d'erreurs:

- le système ASV rejette un positif (miss):

$$P_a(s, t) = (1 - P_{miss}^{cm}(s)) \times P_{miss}^{asv}(t)$$

- le système ASV accepte un négatif (False-Alarm):

$$P_B(s, t) = (1 - P_{miss}^{cm}(s)) \times P_{FA}^{asv}(t)$$

- le système CM accepte un deepfake:

$$P_c(s, t) = P_{FA}^{cm}(s) \times (1 - P_{miss}^{asv}(t))$$

- le système CM rejette un positif:

$$P_d(s) = P_{miss}^{cm}(s)$$

Il faut aussi définir des coûts d'erreurs associés: C_{miss}^{asv} , C_{FA}^{asv} , C_{miss}^{cm} , C_{FA}^{cm}

$$t\text{-DCF}(s, t) = C_{miss}^{asv} P_{tar} P_a(s, t) + C_{FA}^{asv} P_{non} P_b(s, t) \\ + C_{FA}^{cm} P_{spoofer} P_c(s, t) + C_{miss}^{cm} P_{tar} P_d(s)$$



Jeu de données d'évaluation: **ASVspoof2019 LA evaluation**

Modèle	EER	min-tDCF
RawNet2	5.67%	0.1306
AASIST	1.47%	0.0481
Wav2Vec2.0 + RawNet2	0.204%	0.0068
MHFA	4.22%	0.1074

Challenge ASVSP00F5

Spécifications

Trois nouveaux jeux de données:

Jeu de donnée	# d'échantillons	% d'échantillons factices
<i>Entraînement</i>	182 357	89.69%
<i>Développement</i>	140 950	60.11%
<i>Évaluation</i>	40 765	???

Deux conditions:

- Fermée: seule les données d'*entraînements* fournies peuvent être utilisées
- Ouverte: même condition, mais il est possible d'utiliser des modèles auto-supervisés, pré-entraînés sur d'autres jeux de données

Quelques dates:

- Début du challenge: 20 Mai 2024
- Soumission des scores: 23 Juillet 2024
- Soumission de l'article: 31 Juillet 2024
- Atelier ASVspooF 2024 à Interspeech: 31 Août 2024



Protocole d'évaluation

Configuration ASVSPOOF5

Le jeu de données de *développement* a été divisé en 2 parties pour former un jeu de validation et un jeu d'évaluation

Jeu de donnée	# d'échantillons	% d'échantillons factices
<i>Validation</i>	37 091	77.77%
<i>Évaluation</i>	103 859	77.77%

Les systèmes sont entraînés sur l'ensemble du jeu de données *d'entraînement* et les meilleurs modèles sont sélectionnés à partir des résultats sur l'ensemble de *validation*.



Augmentation utilisée en vérification du locuteur (dénomé *basique*):

- Réverbération
- Ajout d'audio par dessus l'extrait: bruit, musique, voix

Augmentation spécifique à la détection de deepfake:

- *RawBoost*[8]: Applique un effet de *boost* ou de distorsion au signal, selon différents algorithmes
- *Codecs*: Applique une compression puis décompression (avec perte) selon un certain codec



Résultats actuels du challenge

Pour la condition fermée:

Modèle	Augmentation	min-DCF	EER
ResNet	non	0.4026	22%
ResNet	codec	0.4472	23%
<i>ResNet</i>	<i>basique + codec</i>	<i>0.4466</i>	<i>21%</i>
AASIST	basique	0.5497	25%
RW-ResNet	non	0.7930	40%
RW-ResNet	codec	0.7677	40%
MFCC-RW-Resnet	non	0.4857	24%
MFCC-RW-Resnet	codec	0.5081	24%



Résultats actuels du challenge

Pour la condition ouverte:

Modèle	Augmentation	min-DCF	EER
MHFA (fixée)	non	0.2073	8.36%
MHFA (fixée)	basique	0.1365	5.66%
MHFA	non	0.1049	4.78%
MHFA	basique	0.0804	3.15%
MHFA	RawBoost [8]	0.8363	32%
MHFA	RawBoost [8]	0.7160	28%



- Les données d'entraînements et l'augmentation joue un rôle primordiale dans la performance d'un système de détection
- Les encodeurs auto-supervisés (notamment le modèle WavLM [2]) améliorent les performances des systèmes de détection
- Exploiter la fusion de différents modèles pourrait améliorer les performances



- [1] Alexei Baevski et al. *wav2vec 2.0: A Framework for Self-Supervised Learning of Speech Representations*. 2020. arXiv: 2006.11477 [cs.CL].
- [2] Sanyuan Chen et al. “WavLM: Large-Scale Self-Supervised Pre-Training for Full Stack Speech Processing”. In: *IEEE Journal of Selected Topics in Signal Processing* 16.6 (Oct. 2022), pp. 1505–1518. ISSN: 1941-0484. DOI: 10.1109/jstsp.2022.3188113. URL: <http://dx.doi.org/10.1109/JSTSP.2022.3188113>.
- [3] Jee-weon Jung et al. *AASIST: Audio Anti-Spoofing using Integrated Spectro-Temporal Graph Attention Networks*. 2021. arXiv: 2110.01200 [eess.AS].



- [4] Taein Kang et al. *Experimental Study: Enhancing Voice Spoofing Detection Models with wav2vec 2.0*. 2024. arXiv: 2402.17127 [cs.SD].
- [5] Victor Miara, Theo Lepage, and Reda Dehak. *Towards Supervised Performance on Speaker Verification with Self-Supervised Learning by Leveraging Large-Scale ASR Models*. 2024. arXiv: 2406.02285 [eess.AS]. URL: <https://arxiv.org/abs/2406.02285>.
- [6] Junyi Peng et al. *An attention-based backend allowing efficient fine-tuning of transformer models for speaker verification*. 2022. arXiv: 2210.01273 [eess.AS]. URL: <https://arxiv.org/abs/2210.01273>.
- [7] Hemlata Tak et al. *End-to-end anti-spoofing with RawNet2*. 2021. arXiv: 2011.01108 [eess.AS].



- [8] Hemlata Tak et al. *RawBoost: A Raw Data Boosting and Augmentation Method applied to Automatic Speaker Verification Anti-Spoofing*. 2022. arXiv: 2111.04433 [eess.AS]. URL: <https://arxiv.org/abs/2111.04433>.
- [9] Xin Wang et al. *ASVspooF 2019: A large-scale public database of synthesized, converted and replayed speech*. 2020. arXiv: 1911.01601 [eess.AS].
- [10] Jiangyan Yi et al. *Audio Deepfake Detection: A Survey*. 2023. arXiv: 2308.14970 [cs.SD]. URL: <https://arxiv.org/abs/2308.14970>.



*Merci de votre attention !
Des questions ?*

