

Auteurs

Adda Akram BENDOUKHA

Nesrine KAANICHE

Renaud SIRDEY

Aymen BOUDGUIGA


MOTIVATION ET OBJECTIFS

- Des systèmes de santé intelligents reposant sur la collecte massive de données sensibles
 - Plusieurs lois et réglementations : RGPD, AI Act, e-privacy,
 - Absence de législation sur l'équité
- Des applications basées sur l'IA développées avec un souci limité de la vie privée des utilisateurs
 - Reconstruction des données, inférence d'informations sensibles, reconstitution des profils des patients.
- Difficile d'utiliser de larges bases de données, équilibrées et diverses, nécessaires pour garantir de meilleurs résultats de classification
- Des algorithmes d'apprentissage distribués développés sans considération majeure des problèmes d'équité
 - Des données d'entraînement conduisant à des comportements discriminatoires et/ou amplifiant des biais sociétaux.
 - Des algorithmes augmentant des risques d'identification des classes minoritaires de 20%.
 - Divulguer les métriques d'équité permettant d'améliorer le taux de succès des attaques par inférence

⇒ Assurer un compromis entre équité, respect de la vie privée et utilité.

MÉTHODOLOGIE

- Proposer une nouvelle approche d'**apprentissage fédéré**, répondant aux métriques d'**équité** et assurant une **agrégation** respectueuse de la vie **privée**.
- Concevoir de nouvelles attaques sur la confidentialité des modèles et des données et combinant des métriques d'équité dans un contexte d'apprentissage distribué.
- Evaluer l'efficacité de l'approche proposée par rapport aux attaques implémentées.



Partenaires




Soutenu par
Projet EQUIHID



NOTRE APPROCHE

CHIFFREMENT HOMOMORPHE POUR UN APPRENTISSAGE FÉDÉRÉ ÉQUITABLE ET SÉCURISÉ



Etat de l'art: Les fonctions d'agrégation des protocoles d'apprentissage fédéré ne prennent pas en compte le niveau d'équité des modèles générés au niveau des clients.

Problème 1: Un modèle-client peu équitable contribuera à part égal à la génération du modèle global qu'un modèle équitable, amplifiant ainsi les biais.

⇒ **Solution:** Ajouter une **pondération proportionnelle à un score d'équité**, calculé au niveau chaque modèle-client, lors de l'agrégation du modèle global.

Problème 2: La révélation d'une métrique d'équité du modèle constitue un risque de confidentialité.

⇒ **Solution:** Utiliser le chiffrement homomorphe, *multi-clés*, (CKKS & BFV) [2] pour protéger à la fois les mises à jour du modèles ainsi que les métriques d'équité individuelles et de groupe.

RÉFÉRENCES

- A-A Bendoukha, A. Boudguiga, R. Sirdey, Homomorphic Sortition - Single Secret Leader Election for PoS Blockchains *IACR Cryptol. ePrint Arch.* 2023: 113 (2023).
- L. Freitas de Souza, A. Tonkikh, A-A Bendoukha, S. TucciPiergiorganni, R. Sirdey, Oana Stan, P. Kuznetsov, Revisiting Stream-Cipher-Based Homomorphic Transciphering in the TFHE Era. *FPS* 2021: 19-33
- A-A Bendoukha O. Stan, R. Sirdey, N. Quero, and L. Freitas, Practical homomorphic evaluation of block-cipher-based hash functions with applications *FPS* 2023.

RÉSULTATS

- Une première approche prometteuse pour un modèle d'attaque: Serveur et Clients honnête(s) mais curieux
 - Une amélioration de l'équité de groupe (EOD et SPD) du modèle agrégé par rapport à une agrégation dont la pondération n'est pas liée aux scores d'équité.
 - Les calculs homomorphes : (évaluation de la fonction f + agrégation) permettront d'avoir de résultats prometteurs grâce à la méthode du **Batching** des crypto-systèmes CKKS et BFV.

