



## VERS UNE PROTECTION DE LA VIE PRIVÉE ÉQUITABLE POUR LES SERVICES DE SANTÉ

AKRAM BENDOUKHA SAMOVAR, TÉLÉCOM SUD-PARIS/IP-PARIS



DIRECTION : ENCADREMENT :

NESRINE KAANICHE AYMEN BOUDGUIGA RENAUD SIRDEY

SAMOVAR, TÉLÉCOM SUDPARIS/IP-PARIS CEA PARIS-SACLAY CEA PARIS-SACLAY



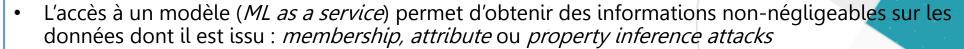
## **CONTEXTE**

#### LES DEUX AXES DE LA THÈSE



#### 1. Protection de la vie privée :



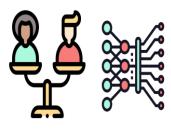


 Grâce aux protocoles d'apprentissage décentralisé, aucun transfert de données n'est nécessaire, mais les risques de fuite de données à partir des update (Gradients, paramètres ...) doivent être considérés



#### 2. Equité des modèles :

- Les biais contenus dans les données sont reproduits et amplifiés par le modèle à travers ses prédictions.
- Etant donnée une tâche d'apprentissage, certains attributs (informations) ne sont pas pertinents dans l'entrainement.
  - ❖ Exemple : « le genre » pour la prédiction du risque lié à un prêt bancaire.
- Plusieurs approches pour améliorer l'équité :
  - Atténuer les corrélations entre les attributs pertinents des attributs non-pertinents
  - Définir une fonction de coût qui exprime la non-équité des prédictions et la minimiser
  - ❖ Identifier les composants du modèles responsables du comportement discriminant et les améliorer







## DIRECTION DE RECHERCHE

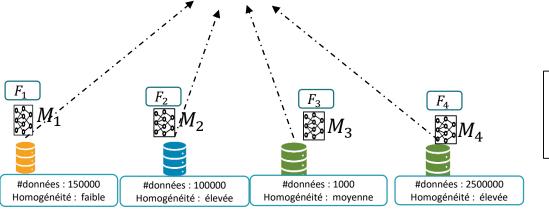
#### PRIVACY-PRESERVING & FAIRNESS-AWARE FEDERATED LEARNING



$$M_{global} = \sum_{i=1}^{4} \omega_i \cdot M_i$$

 $\omega_i = f(F_i, \#donn\acute{e}s_i)$ 

- Définition d'une fonction d'agrégation prenant en compte l'équité des modèles produits par les clients.
- Nécessite la partage d'une information supplémentaire par les clients : Le score d'équité de leur modèle



 La mesure d'équité peut être exploitée pour améliorer des attaques de reconstruction par un serveur d'agrégation honnête mais curieux

#données : 150000 #données : 100000 #données : 10000 Homogénéité : faible Homogénéité : élevée Homogénéité : élevée

 Défi : Demander davantage d'informations aux détenteurs de données tout en leur garantissant une protection robuste de leur données

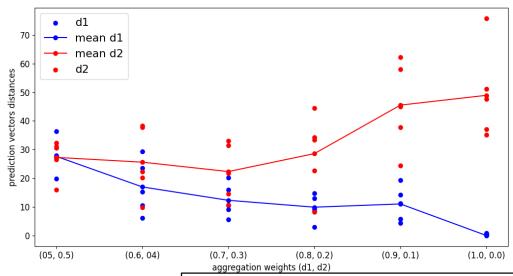


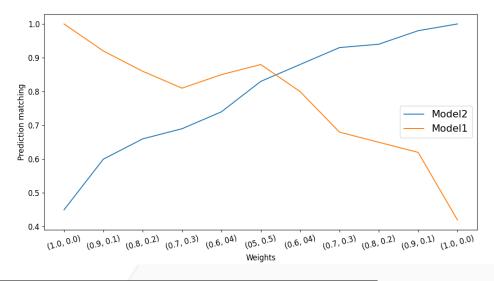


## DIRECTION DE RECHERCHE

#### PRIVACY PRESERVING & FAIRNESS-AWARE FEDERATED LEARNING

- <u>Second risque</u>: l'efficacité des attaques sur le modèle agrégé et une base de données  $D_i$  est proportionnelle au poids  $\omega_i$  attribué au modèle  $M_i$  lors de la phase d'agrégation.
- Améliorer l'équité d'un modèle aura pour conséquence l'augmentation des risques des attaques d'inférence (membership/attribute inference) sur la base de données associée.







Distance entre les prédictions du modèle agrégé et les prédictions de deux modèles provenant de deux datasets en fonction de leurs poids respectifs.



### DIRECTION DE RECHERCHE

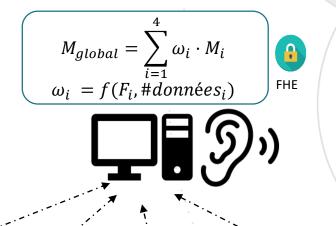
PRIVACY PRESERVING & FAIRNESS-AWARE FEDERATED LEARNING

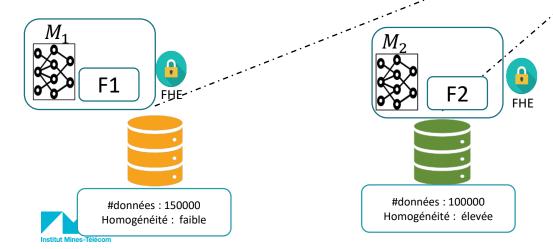


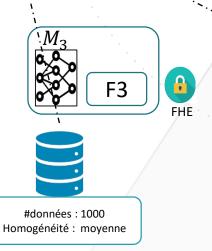
Le chiffrement homomorphe permet d'opérer (addition & multiplication) sur des données tout en garantissant leur confidentialité

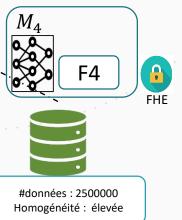
Choix du schéma de chiffrement : CKKS (aka HEAAN) Possibilité d'opérer sur des réels (Gradients/paramètres des modèles)

Proposer un protocole prenant en compte les collusions à l'aide d'un chiffrement homomorphe à seuil ThFHE











# MERCI DE VOTRE ATTENTION

