



**HAL**  
open science

## Détection d'intrusions fédérée et semi-supervisée pour l'IoT

Ons Aouedi, Kandaraj Piamrat, Guillaume Muller, Kamal Singh

► **To cite this version:**

Ons Aouedi, Kandaraj Piamrat, Guillaume Muller, Kamal Singh. Détection d'intrusions fédérée et semi-supervisée pour l'IoT. Plate-Forme Intelligence Artificielle PFIA 2022, Jun 2022, Saint-Etienne, France. emse-03922716

**HAL Id: emse-03922716**

**<https://hal-emse.ccsd.cnrs.fr/emse-03922716v1>**

Submitted on 4 Jan 2023

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

## 1. Introduction

### Contexte : IoT Industriel (IIoT)

L'« **Industrial Internet of Thing** » (IIoT) est un réseau de petits appareils (capteurs « intelligents »...) exécutant des applications industrielles. Il permet la création **services riches**, fondés sur les données : surveillance d'usines, prédiction de pannes, planification dynamique... Il est le socle fondateur de l'**industrie du futur**. À ce titre, il est en **plein essor**.

### Problème : CyberSécurité

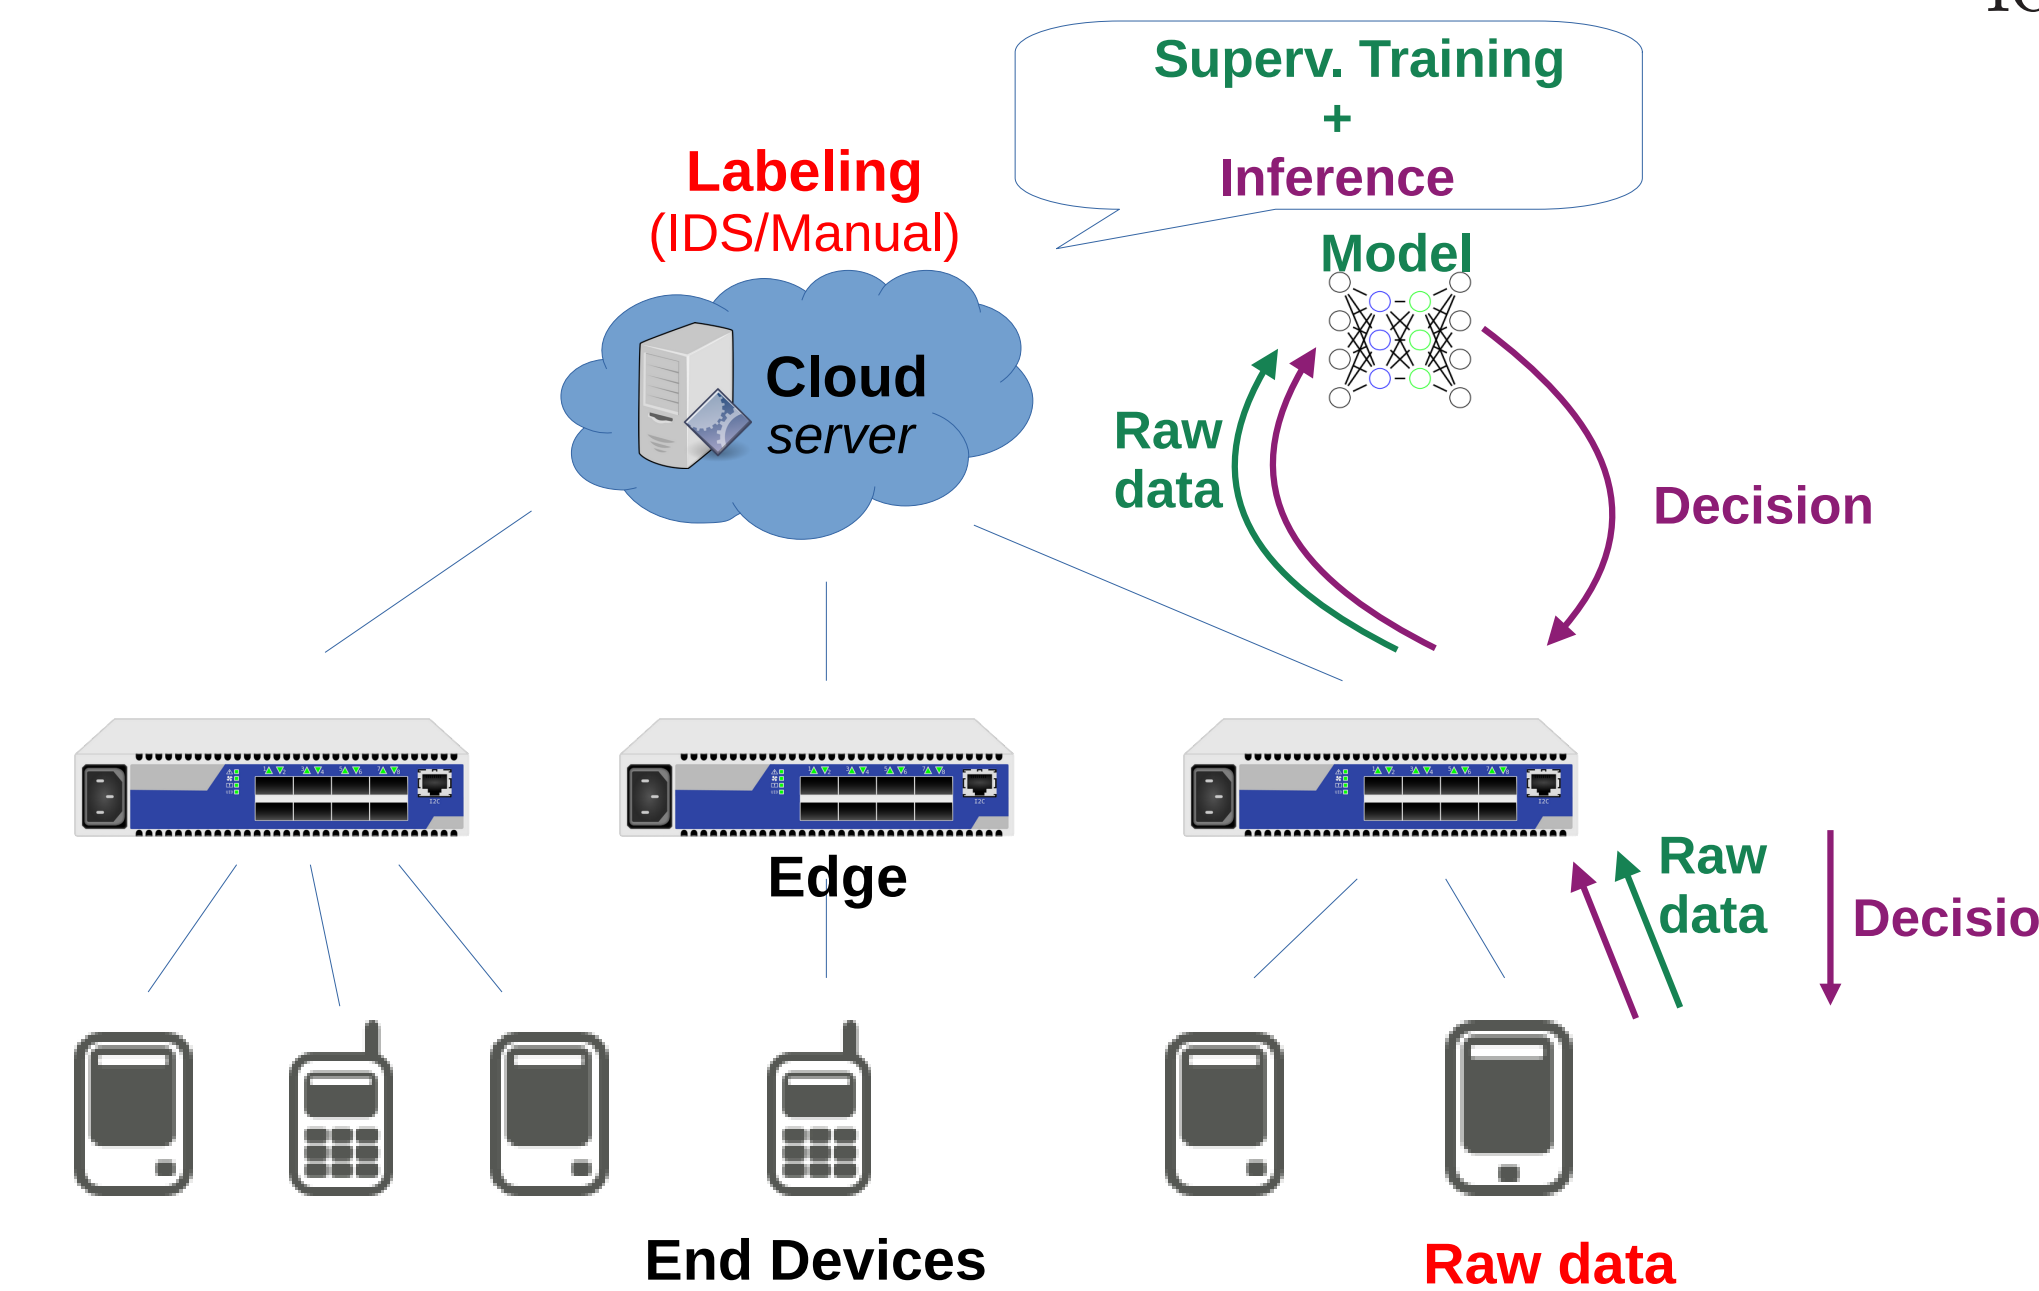
Du fait de la **criticité des installations** sur lesquelles elles sont installées, ces applications sont la cible de nombreuses **attaques**, visant soit à **paralyser l'infrastructure** (ex. : « Colonial Pipeline » en mai 2021), soit à **voler des données sensibles** (propriété intellectuelle, données personnelles...).

### Solution : Système de Détection d'Intrusions (IDS)

Les systèmes de **détection d'intrusions** permettent de détecter et réagir rapidement pour **contrer ces attaques**. Les systèmes actuels s'appuient sur du **Machine Learning**, afin d'être en mesure de s'**adapter** aux nouveaux types d'attaques.

## 2. Limites de la détection d'intrusions dans l'IIoT

Particularités de la détection d'intrusion (IDS) dans le contexte IIoT :

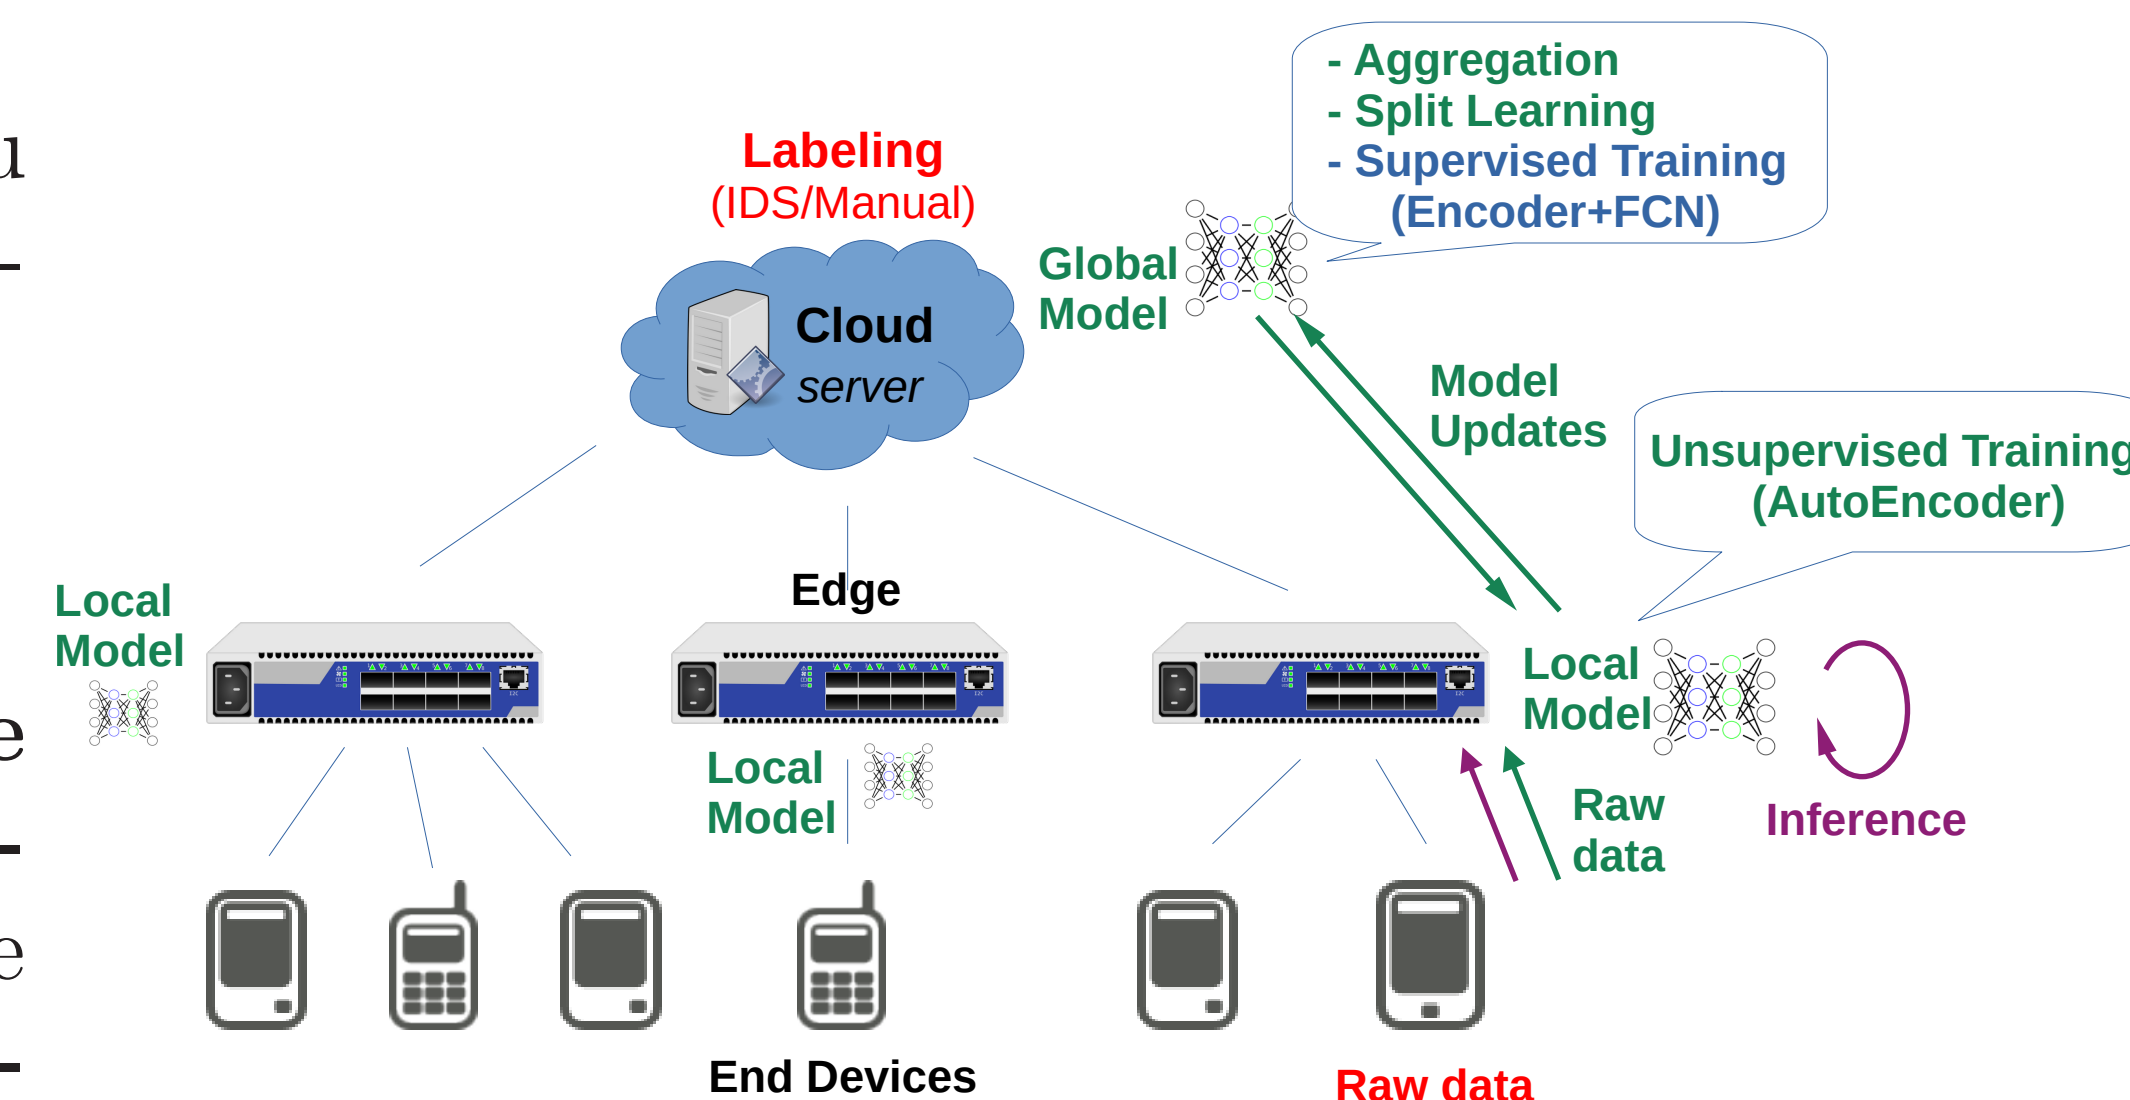


- Les *données* sont générées sur les petits appareils.
- L'*étiquetage des données* (la caractérisation du trafic : attaque ou pas) nécessite une vision globale du trafic, donc doit avoir lieu *dans le « cloud »* et est très coûteux (⌚, 📡).
- Un processus de Machine Learning traditionnel (centralisé) supervisé nécessiterait la transmission des données, or :
  - Ces dernières peuvent être **sensibles** ;
  - Cela **alourdit la charge réseau** ;
  - Le **serveur** devient un **point de faiblesse** : il doit stocker et analyser une grande masse de données.

## 3. FLuIDS

Dans FLuIDS [1, 2] notre contribution consiste à combiner :

- un **apprentissage non-supervisé** au niveau des petits appareils, grâce à des auto-encodeurs.
- un **apprentissage supervisé** sur le serveur.
- pour relier les deux, un **apprentissage fédéré** [4] et une méthode de **Split-Learning** [5], qui permet à l'ensemble des entités d'apprendre l'Encodeur **conjointement** et en **respectant la sensibilité** des données.



## 4. Résultats

FLuIDS a été testé sur 2 jeux de données classiques de la détection d'intrusions, notamment IIoT : **UNSW-NB15** et **SCADA Gas Pipeline**. Les résultats suivants portent sur le premier. Il a pu être montré que :

- FLuIDS **exploite les données non-étiquetées** : augmenter leur volume (à nb. étiquetées constant), augmente l'accuracy.
- FLuIDS **réduit de 20% à 99% le volume de communications**, en envoyant des mise-à-jour de modèles plutôt que des données brutes.
- FLuIDS est **au moins aussi performant** (F1-score) que les modèles **centralisés supervisés**.
- FLuIDS est **plus performant** quand il est entraîné **en mode fédéré** qu'en mode centralisé : il est peu sensible à une distribution non-IID des données.
- FLuIDS nécessite **plus temps pour converger** qu'un modèle centralisé, mais dans une limite *raisonnable*.

## 5. Conclusions

- FLuIDS exploite **toutes** données (étiquetées ou non), grâce au Split Learning.
- FLuIDS **péserve la sensibilité** des données, puisqu'elles ne sont pas transmises.
- FLuIDS **réduit la charge du serveur**, puisque les calculs/stockages sont distribués.
- FLuIDS **réduit la charge du réseau**, puisque seuls des données « compressées » (modèles) sont transmises.
- FLuIDS **réduit la latence** lors de l'inférence (détection d'intrusion à proprement parler), puisque cette dernière s'effectue directement sur les petits appareils.

## 6. Références

- [1] O. Aouedi et al. "Federated Semi-Supervised Learning for Attack Detection in Industrial Internet of Things". In: *IEEE Transactions on Industrial Informatics, SS on Security and Privacy Issues in Industry 4.0 Applications* (2022)
- [2] O. Aouedi et al. "Intrusion detection for Softwarized Networks with Semi-supervised Federated Learning". In: *IEEE-ICC'22*. Seoul, South Korea, June 2022
- [4] Brendan McMahan et al. "Communication-efficient learning of deep networks from decentralized data". In: *Artificial Intelligence and Statistics*. PMLR. 2017, pp. 1273–1282
- [3] Peter Kairouz et al. "Advances and Open Problems in Federated Learning". In: *CoRR* abs/1912.04977 (2019). arXiv: 1912.04977. URL: <http://arxiv.org/abs/1912.04977>
- [5] P. Vepakomma et al. "Split Learning for health: Distributed deep learning without sharing raw patient data". In: *CoRR* abs/1812.00564 (2018). arXiv: 1812.00564. URL: <http://arxiv.org/abs/1812.00564>