

Aprendizaje Federado con Agrupación de modelos para la Detección de Anomalías en Dispositivos IoT Heterogéneos

Xabier Sáez de Cámara, Jose Luis Flores, Cristóbal Arellano,
Aitor Urbietta y Urko Zurutuza

Mondragon Unibertsitatea, IKERLAN

2022-10-20

LA TECNOLOGÍA,
NUESTRA
ACTITUD

ikerlan
MEMBER OF BASQUE RESEARCH
& TECHNOLOGY ALLIANCE

- 1. Contexto.**
- 2. Aprendizaje federado.**
- 3. Aprendizaje federado con agrupación de modelos.**
- 4. Banco de pruebas IoT.**
- 5. Resultados.**
- 6. Conclusiones.**



IoT susceptible a ataques:


- Puertos/Servicios innecesarios expuestos a Internet.
- Autenticación no adecuada, uso de credenciales débiles.
- Malas prácticas de programación, uso de software vulnerable.
- Gestión inadecuada de las actualizaciones.
- ...

Estrategias de mitigación poco efectivas:

- Sistemas de detección de intrusiones (IDS) basados en reglas presentan dificultades en IoT:
 - Uso de técnicas de ofuscación en el malware.
 - Rápida evolución de la infraestructura del malware en IoT (del orden de 10 días).
 - Ventanas de exposición largas entre el descubrimiento del malware y la publicación de reglas para detectarlas (del orden de 100 días).

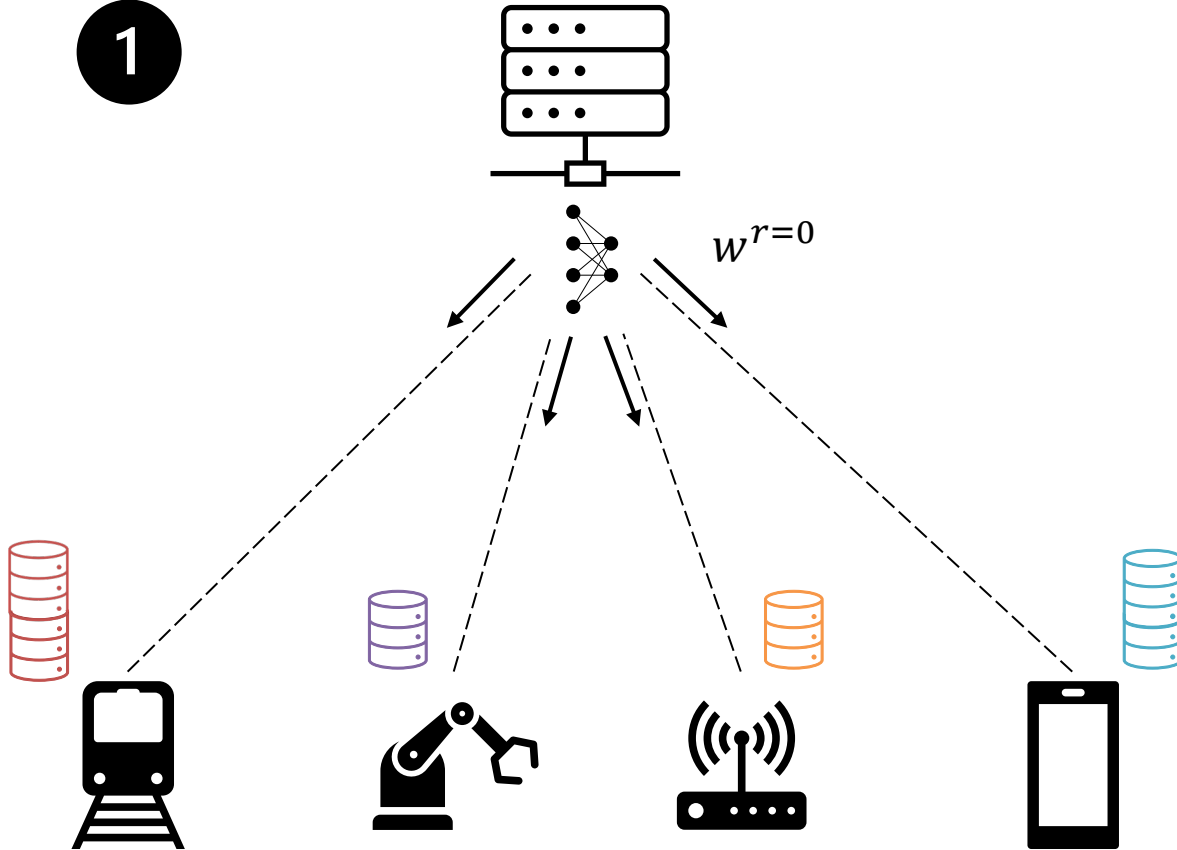
Federated Learning (FL)

McMahan, B., Moore, E., Ramage, D., Hampson, S., & y Arcas, B. A. (2017, April). Communication-efficient learning of deep networks from decentralized data. In *Artificial intelligence and statistics* (pp. 1273-1282). PMLR.



- Entrenamiento distribuido.
- Los datos se mantienen en local.
- Solo se transmiten los modelos.

1




Federated Learning (FL)

Ronda inicial $r = 0$

Inicialización y distribución del modelo.

2

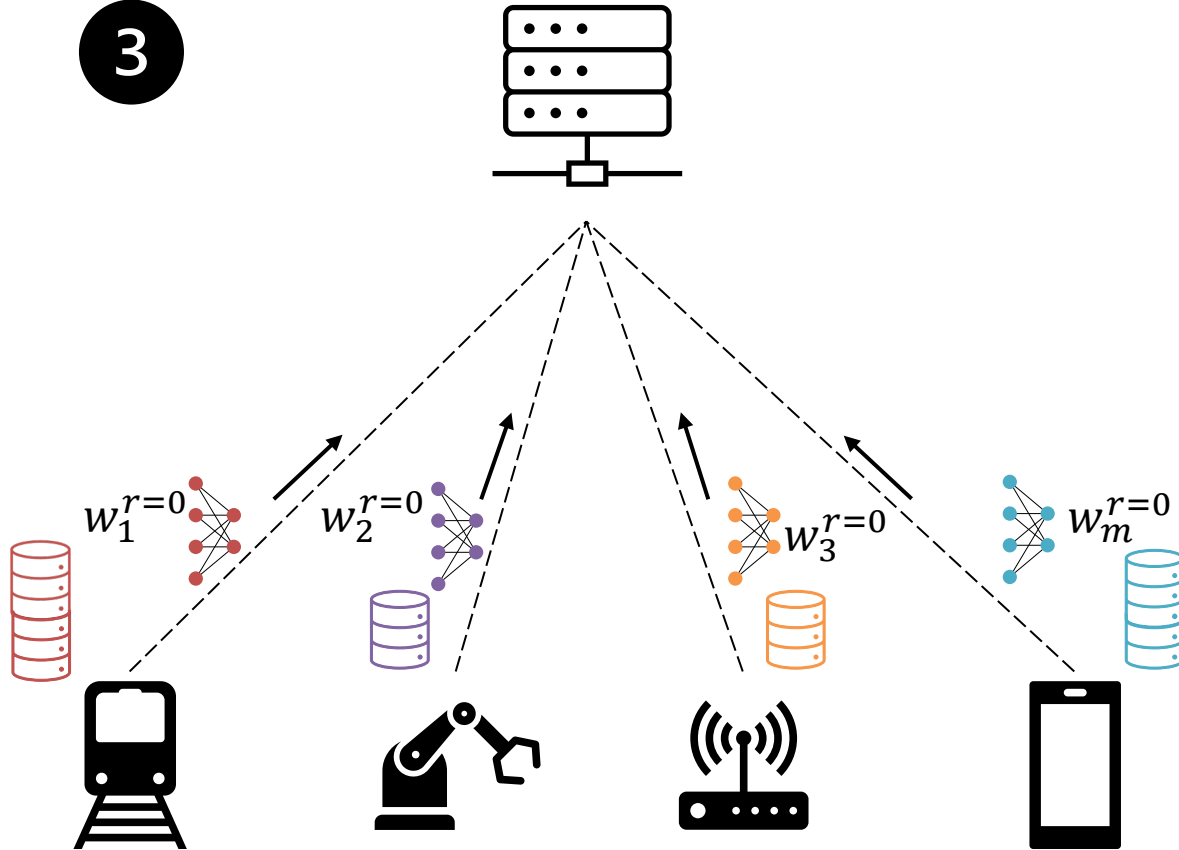
Federated Learning (FL)



Ronda inicial $r = 0$

Entrenamiento local de los
modelos (E épocas).

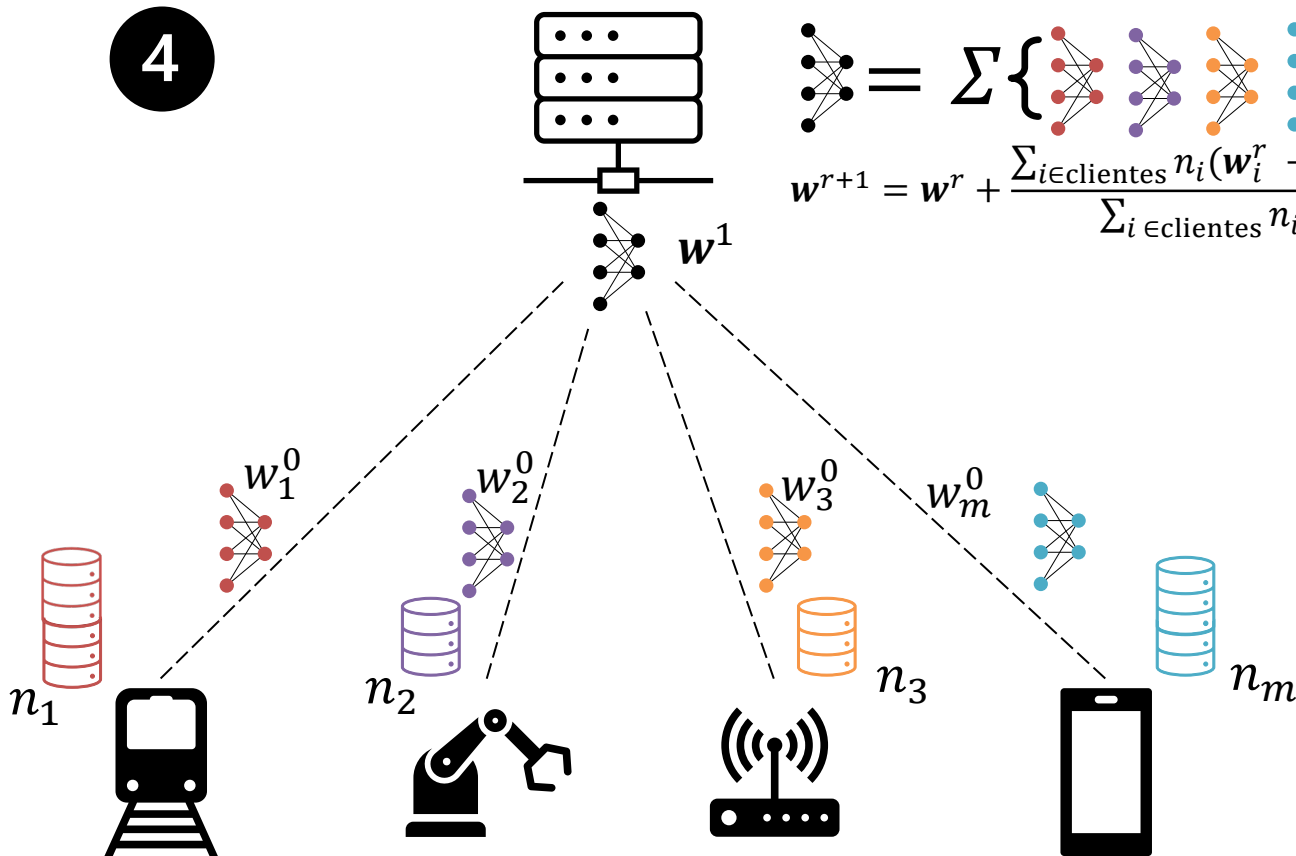
3



Federated Learning (FL)

Ronda inicial $r = 0$

Transmisión de los modelos al servidor de agregación.



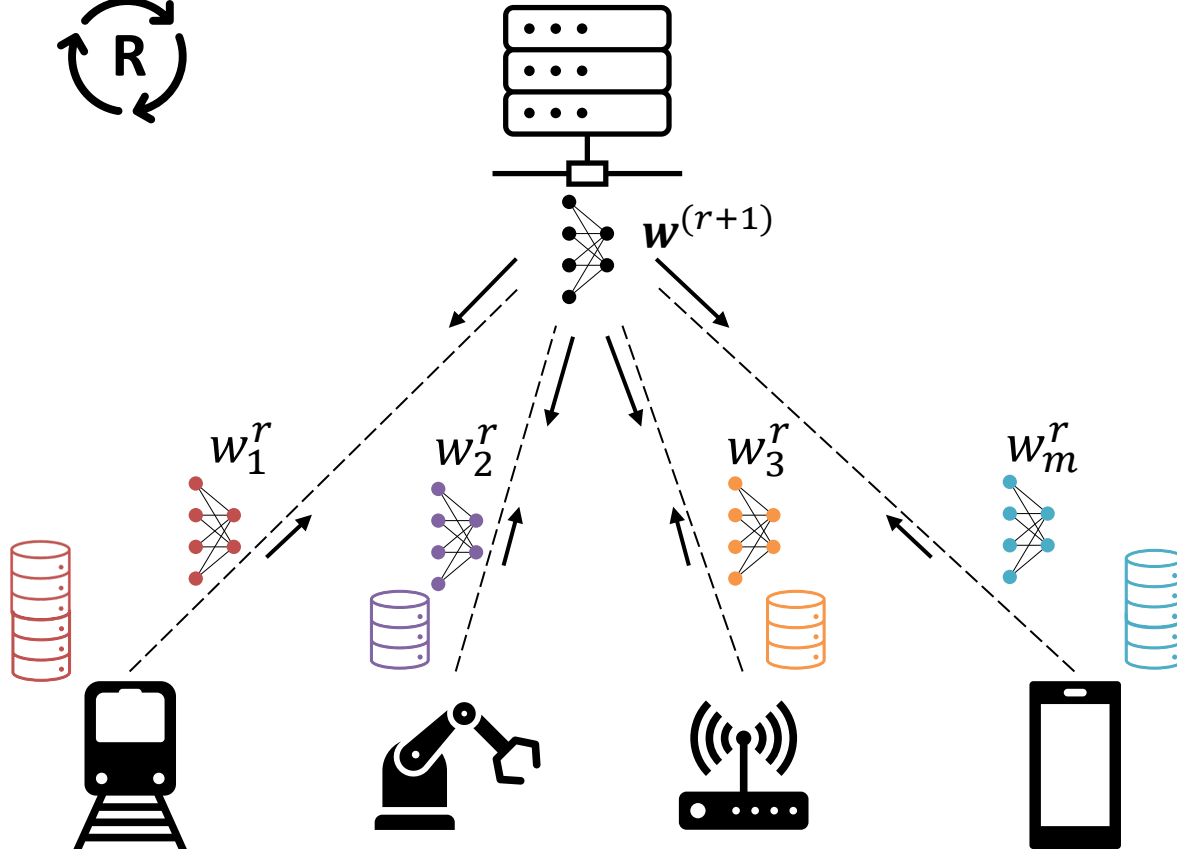
$$w^{r+1} = w^r + \frac{\sum_{i \in \text{clientes}} n_i (w_i^r - w^r)}{\sum_{i \in \text{clientes}} n_i}$$

Fin de la ronda inicial

Actualización del modelo global: FedAvg, FedAdam, FedSGDm, ...




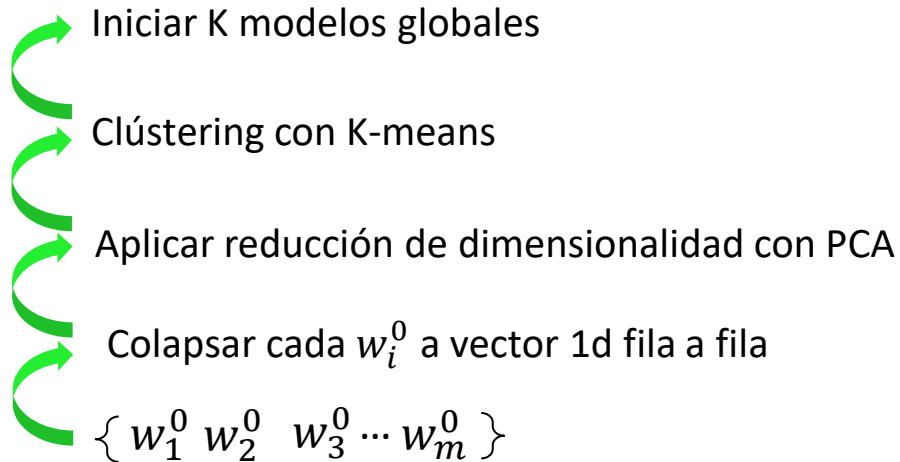
Federated Learning (FL)



- ✓ Menor transmisión de datos
- ✓ Inferencia en tiempo real
- ✓ Más muestras de entrenamiento
- ✗ Coordinación compleja
- ✗ Problemas en entornos con alta heterogeneidad

Aprendizaje federado con agrupación de modelos

- Agrupación basado en los parámetros de los modelos locales parcialmente entrenados.
- Integrado en la primera ronda ($r=0$) de FL.
- Después, se inicia un proceso de FL independiente para cada grupo.



WHERE
TECHNOLOGY
IS AN ATTITUDE

BANCO DE PRUEBAS IOT



Emulador de red GNS3



360 dispositivos IoT simulados

- MQTT tipo 1
- MQTT tipo 2
- CoAP tipo 1

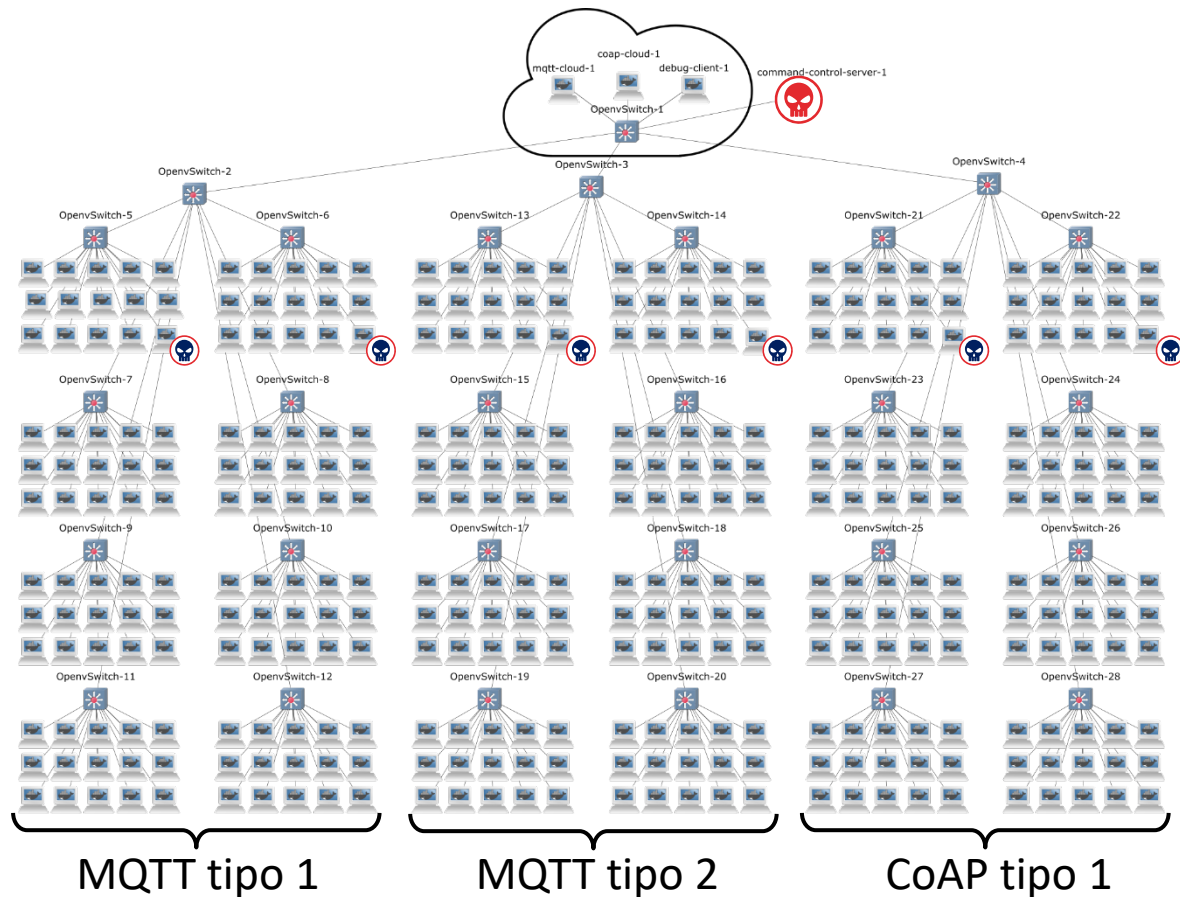
Variaciones aleatorias en la periodicidad, tamaño de los mensajes transmitidos, ...



Atacante





Dispositivos comprometido





Ataques y comportamiento malicioso:

- Comunicación periódica con el servidor de mando y control (C&C)
 - **Merlin** (C&C y agente) <https://github.com/Ne0nd0g/merlin>
- Cargar remotamente software en los dispositivos comprometidos
- Ejecución remota de programas en la victima
- Ataques DoS: **hping3** <https://github.com/antirez/hping>
 - ICMP flood
 - UDP flood
 - TCP SYN flood
 - TCP ACK flood







pcap

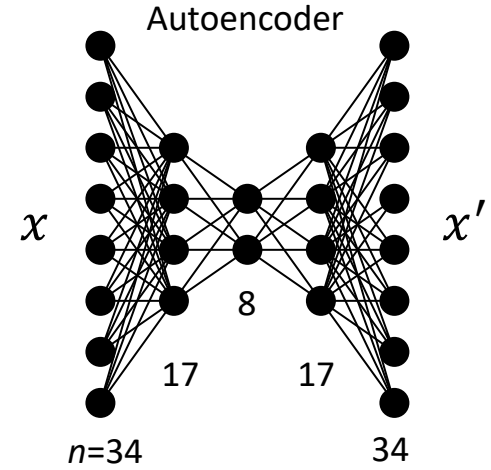
Drop IPv6
Drop ARP



- Características**
- Tamaño del paquete
 - Inter arrival time
 - Entropía del paquete
 - IP type of service
 - IP flags
 - IP protocol
 - Src port
 - Dst port
 - TCP flags
 - TCP window size


} Procesamiento de características colaborativa (FL)

Datos y modelo ML



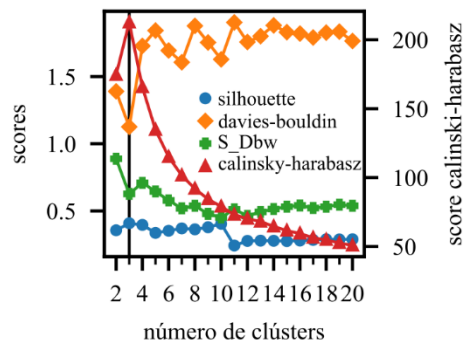
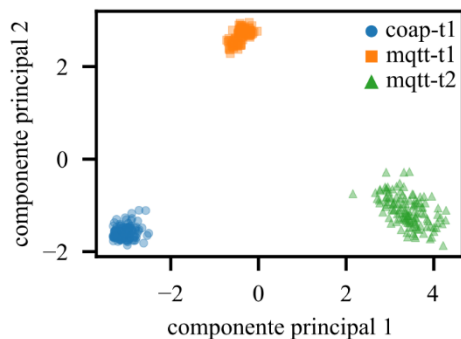
Entrenado en trafico normal

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2$$



FL: agrupación

- Entrenamiento parcial durante ϵ épocas
- Transformar pesos del modelo a vector (1d)
- PCA: mantener 90% varianza
- Clústering k-means: k de 2 a 20



$\epsilon = 2$ épocas
Adam lr = 10^{-3}

K = 3

Robusto ante distintos
valores de ϵ .



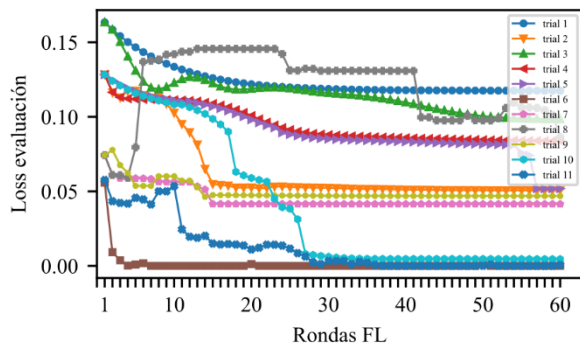
FL: entrenamiento

Ajuste de hiperparámetros.



Entrenamiento final.

Optimizador cliente / servidor



Learning rate cliente / servidor



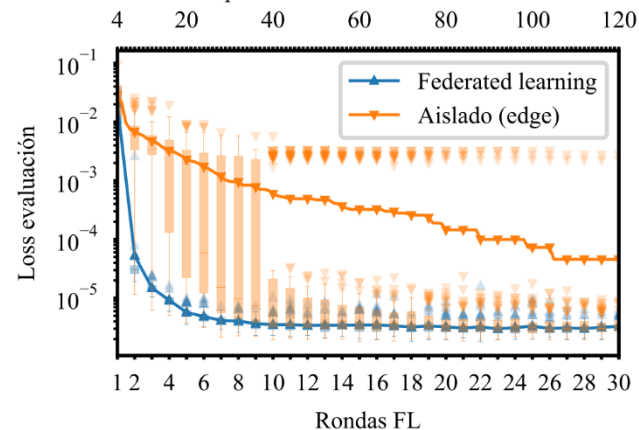
Cliente: Adam $\beta_1 = 0,9$ $\beta_2 = 0,999$

Servidor (agregación): SGD m=0

Cliente: 0,001


Servidor (agregación): 1,0

Épocas de entrenamiento aislado

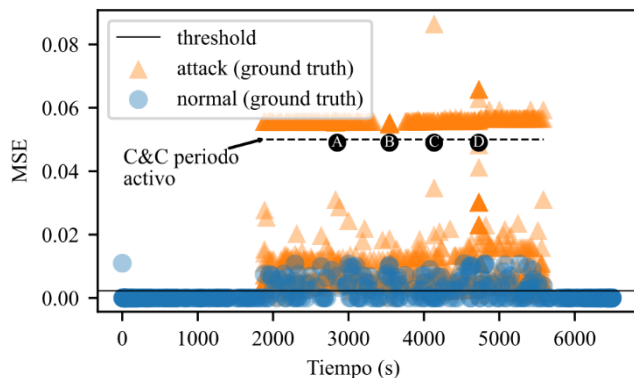


R = 30 rondas FL

E = 4 épocas locales



Detección de anomalías



- A** Cargar remotamente software hping3
- B** ICMP flood
- C** UDP flood
- D** TCP SYN + ACK flood

CoAP t1 F1=0,99704

MQTT t1 F1=0,91995

MQTT t2 F1=0,94711

		Predicción	
		Ataque	Normal
Real	Ataque	34194	0
	Normal	203	12405

		Predicción	
		Ataque	Normal
Real	Ataque	30130	5243
	Normal	0	13882

		Predicción	
		Ataque	Normal
Real	Ataque	31174	3172
	Normal	310	79938

Conclusiones:

- La fase de agrupamiento de modelos integrado en FL permite disminuir los problemas de la alta heterogeneidad sin la necesidad de usar herramientas externas, agrupamiento manual, etc.
- El agrupamiento es robusto al número de épocas locales de entrenamiento.
- FL tiene ventajas respecto al entrenamiento en la nube desde el punto de vista de la transmisión de datos.
- FL consigue una convergencia mas rápida respecto a entrenamientos no federados.

MUCHAS GRACIAS

IKERLAN

P.º José María Arizmendiarieta, 2 - 20500 Arrasate-Mondragón
T. +34 943712400 F. +34 943796944

LA TECNOLOGÍA,
NUESTRA
ACTITUD

ikerlan
MEMBER OF BASQUE RESEARCH
& TECHNOLOGY ALLIANCE