

Seminario de Inteligencia Artificial de la Universidad de Sevilla

Aprendizaje Federado: conceptos, estado del arte, y retos en modelos no-deep learning.

Jose M. Moyano

28 noviembre 2023

Dpto. Ciencias de la Computación e Inteligencia Artificial



1. Introducción

2. Conceptos y fundamentos

3. FedAvg y caso de uso

4. Retos en la implementación de modelos no-deep learning

5. Conclusiones


Motivación

- Crecimiento del uso de *machine learning* (ML) e IA en general.
- Necesidad de grandes cantidades de datos.
- Cada vez más regulaciones (y escepticismo) al compartir o liberar datos.
 - P.ej. *General Data Protection Regulation (GDPR)* en la Unión Europea
- Beneficios de colaboración entre entidades.
- Computación en *IoT*.
- **Aprendizaje Federado!** (*Federated Learning, FL*)

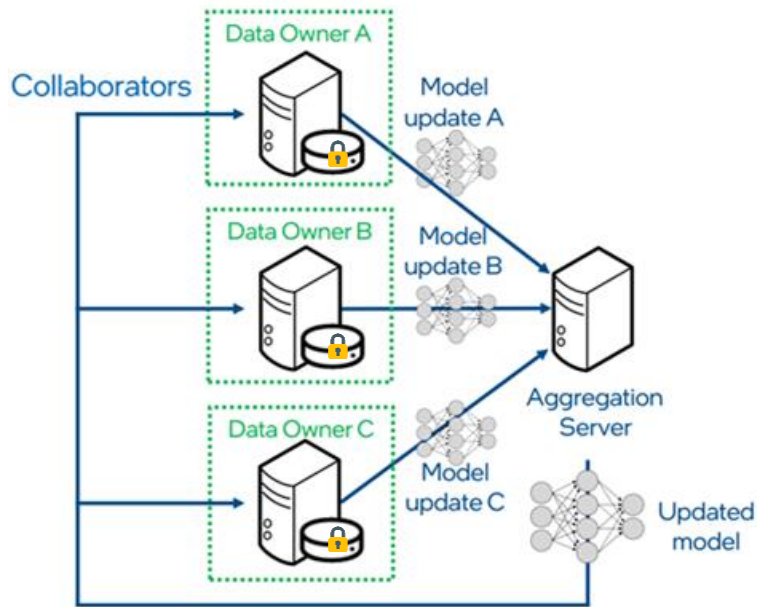
1. Introducción

Aprendizaje Centralizado vs Federado

Centralized Learning

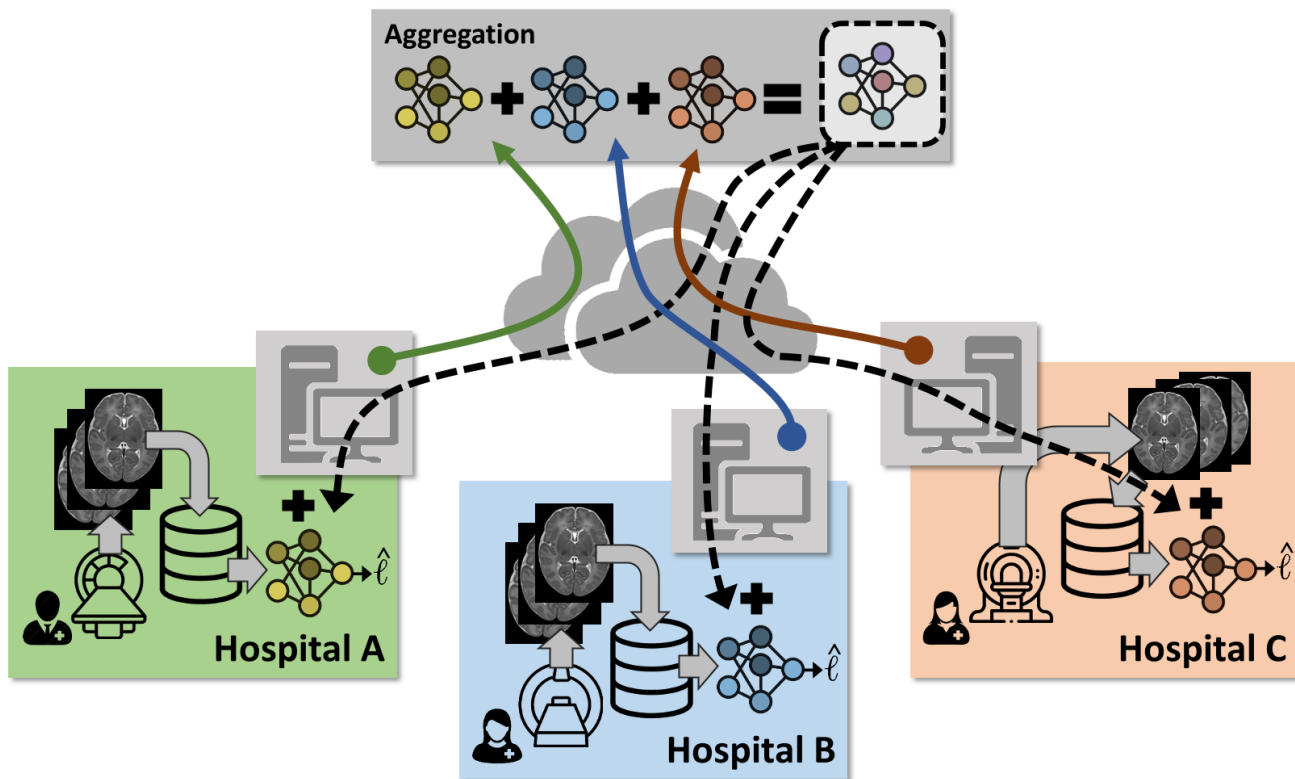


Federated Learning



1. Introducción


Aprendizaje Federado (FL)



1. Introducción

Aprendizaje Federado vs Distribuido

- Los datos nunca están centralizados.
- No se puede conocer la distribución global de los datos.
- La potencia de los clientes viene posiblemente dada.
- Los datos se encuentran distribuidos originalmente, con lo que ello implica sobre el origen y tamaño de los conjuntos.



1. Introducción

2. Conceptos y fundamentos

3. FedAvg y caso de uso

4. Retos en la implementación de modelos no-deep learning

5. Conclusiones

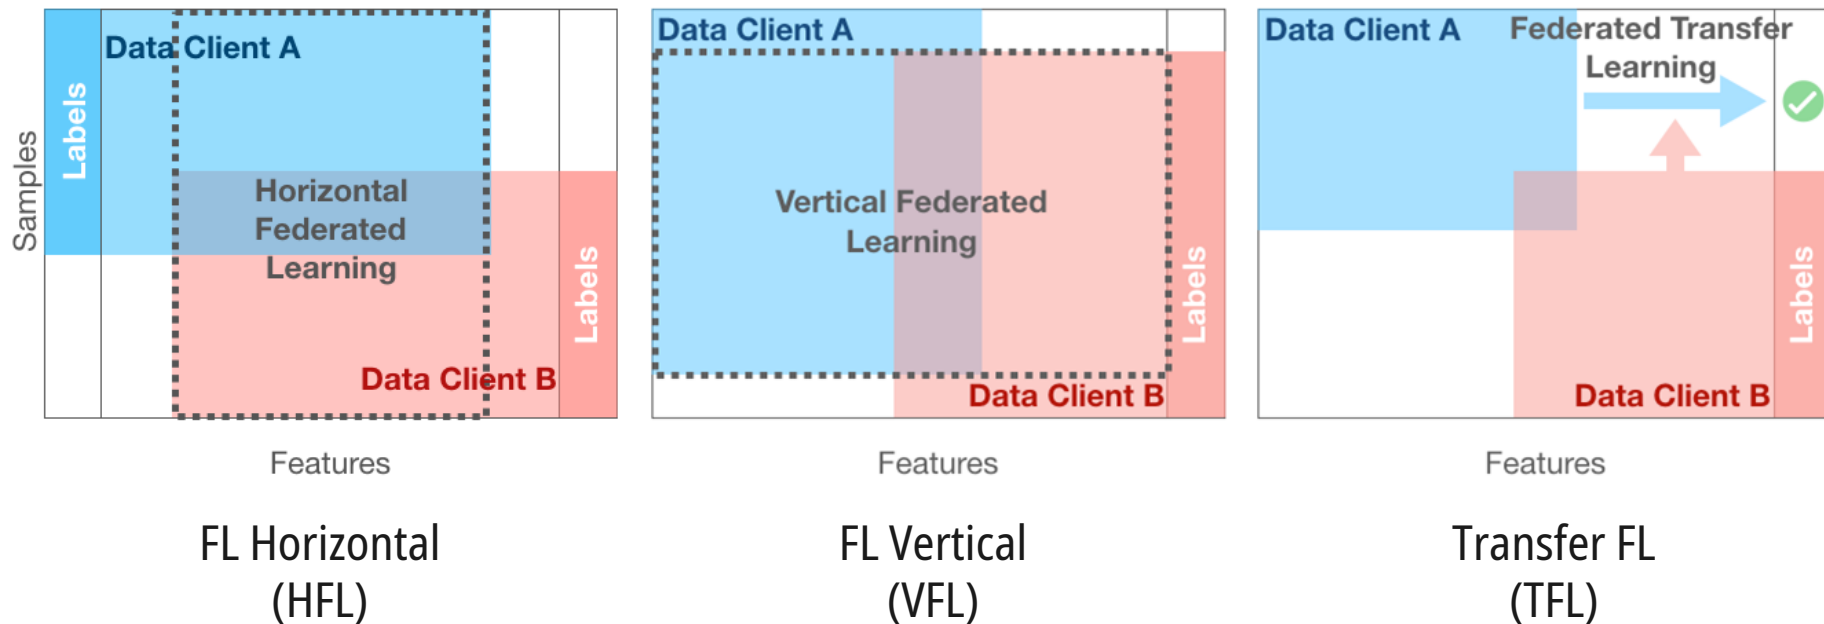
2. Conceptos y fundamentos

Definición de FL

- Marco algorítmico para construir modelos de ML.
- Hay dos o más **partes interesadas** (clientes) que quieren construir un **modelo** de ML **conjunto**.
 - Cada parte posee sus propios datos para contribuir al entrenamiento.
- Los **datos privados** no salen de cada parte durante el entrenamiento.
- Se pueden transferir partes del **modelo** bajo **encriptación**, de forma que las otras partes no puedan hacer ingeniería inversa para obtener los datos.
- El **rendimiento** del modelo resultante es una buena **aproximación** del modelo ideal centralizado.

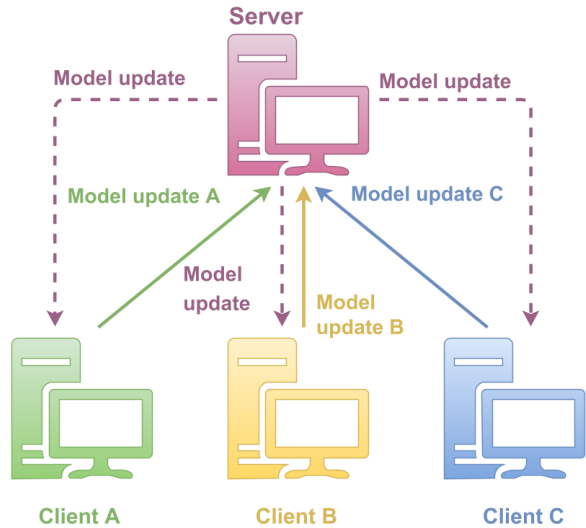
2. Conceptos y fundamentos

Tipos de FL

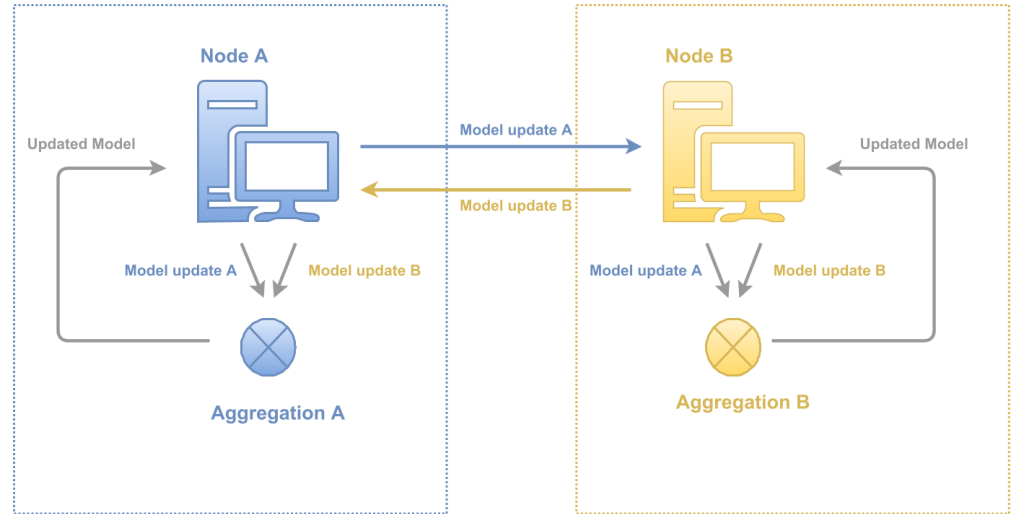


2. Conceptos y fundamentos


Arquitecturas principales



Cliente-servidor



Peer-to-peer (descentralizado)



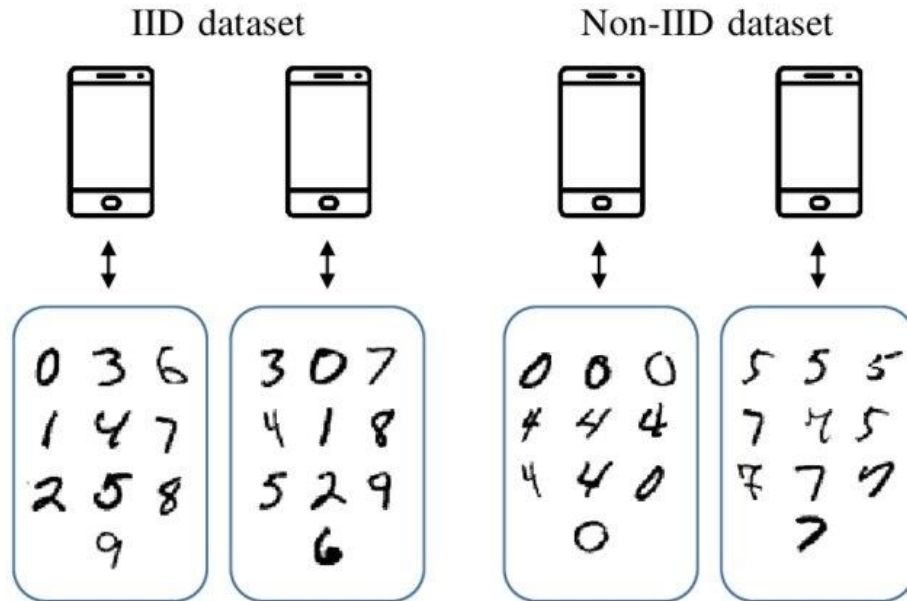
2. Conceptos y fundamentos

Modelo global / descentralizado / personalizado

- El concepto general gira entorno a tener un modelo global alojado en un servidor.
- En otras arquitecturas, el modelo puede estar alojado en diferentes sitios:
 - Cada cliente tiene una copia del mismo modelo
 - O el modelo debe estar, por restricciones, almacenado “por partes” entre todos los clientes.
- Personalización de modelos en cada cliente.

2. Conceptos y fundamentos

Distribución de los datos (IID / non-IID)



- Tamaño del dataset
- Diferentes clases (o diferente número de instancias por clase)
- Distintos orígenes
- Sesgo en los datos
- ...

2. Conceptos y fundamentos


Conjuntos de datos

- Inherentemente federados


| text string | date string | user string | sentiment int32 |
|------------------------------------------------------------------------|-----------------------------|----------------|--------------------|
| Ok, first assesment of the #kindle2 ...it fucking rocks!!! | Mon May 11 03:18:54 UTC_ | chadfu | 4 |
| @kenburbarry You'll love your Kindle2. I've had mine for a few_ | Mon May 11 03:19:04 UTC_ | SIX15 | 4 |
| @mikefish Fair enough. But i have the Kindle2 and I think it's_ | Mon May 11 03:21:41 UTC_ | yamarama | 4 |
| @richardebaker no. it is too big. I'm quite happy with the Kindle2. | Mon May 11 03:22:00 UTC_ | GeorgeVHulme | 4 |
| Fuck this economy. I hate aig and their non loan given asses. | Mon May 11 03:22:30 UTC_ | Seth937 | 0 |

<https://huggingface.co/datasets/sentiment140>

- Simulación



<https://towardsdatascience.com/from-centralized-to-federated-learning-b0074793e9f>



https://github.com/aswarth123/Federated_Learning_MNIST

2. Conceptos y fundamentos

Frameworks

- TensorFlow Federated
 - <https://www.tensorflow.org/federated>
- Flower
 - <https://flower.dev/>
- FATE
 - <https://fate.fedai.org/>
- ...



TensorFlow



Flower

FATE

2. Conceptos y fundamentos

Frameworks

| | PyS | TFF | FAT | Pad | Flo | Xay | IBM | Sub | OFL | FML | FJx | 101 | FLb | SFL | EFL | TFL | AFL | NVF | |
|-----------------------------------------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|---|
| Federated Learning: | | | | | | | | | | | | | | | | | | | |
| Horizontal Federated Learning | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Vertical Federated Learning | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Federated Transfer Learning | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Support other ML frameworks | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Sampling IID or non-IID distribution | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Federated aggregation mechanisms | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Adversarial attacks in FL: | | | | | | | | | | | | | | | | | | | |
| Privacy attacks | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Defenses against Privacy attacks | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Attacks to the federated model | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Defenses against attacks to the model | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Differential Privacy (DP): | | | | | | | | | | | | | | | | | | | |
| Mechanisms: Exponential, Laplacian... | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Subsampling methods to increase privacy | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Advanced DP Composition | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Advanced properties: | | | | | | | | | | | | | | | | | | | |
| Interpretability / Explainability | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Personalization | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Documentation and tutorials | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| High-level API | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Ability to extend the framework | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |
| Actively maintained | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● | ● |

2. Conceptos y fundamentos

Desafíos

- Privacidad de los datos / encriptación
- Costes de comunicación y latencia
- Limitaciones en el acceso de los datos
- Distribución de los datos
- Selección del modelo / personalización
- Ataques maliciosos
- Entrada/salida de entidades, y asincronía en las actualizaciones
- Simulación
- Incentivos
- Evaluación
- ...

1. Introducción

2. Conceptos y fundamentos

3. FedAvg y caso de uso

4. Retos en la implementación de modelos no-deep learning

5. Conclusiones

Federated Averaging (FedAvg)

- HFL
- Cliente-servidor
- Redes neuronales
 - U otros modelos que puedan descomponerse como conjunto de pesos
- Asume:
 - Datos non-IID y desbalanceo
 - Gran número de clientes
 - Conexiones lentas y poco fiables

Federated Averaging (FedAvg)

- **Servidor inicializa** el modelo, y lo envía a los K clientes.
- PARA cada ronda de entrenamiento federado:
 - Se selecciona un **ratio** ρ de **clientes** para participar en la ronda
 - Cada **cliente actualiza** el modelo con sus **datos locales** por S épocas, usando un mini-batch de tamaño M de su dataset D_k
 - Cada **cliente envía** al servidor los **pesos** actualizados (*model averaging*) o los **gradientes** obtenidos (*gradient averaging*).
 - **Servidor actualiza** calculando una media de los pesos/gradientes, obtiene un nuevo modelo global, y lo reenvía a los clientes.


Federated Averaging (FedAvg)

- Versión asíncrona
 - A la actualización del modelo recibida por el cliente se le asigna un peso.
 - Peso basado en cuánto ha tardado en devolver la actualización.
 - Evita incluir actualizaciones de modelos “antiguos”.

3. FedAvg y caso de uso

GBoard

- Desde 2017, comenzaron a utilizar FL para recomendación de la siguiente palabra.
- Primera incursión de Google en FL.
- No envía datos, y solo entrena mientras el móvil está cargando, conectado a WiFi, y sin usar.
- Usando FedAvg (primera propuesta de Google también)
- Usa una versión mini de TensorFlow en Android.



1. Introducción

2. Conceptos y fundamentos

3. FedAvg y caso de uso

4. Retos en la implementación de modelos no-deep learning

5. Conclusiones

4. Retos en la implementación de modelos no-deep learning

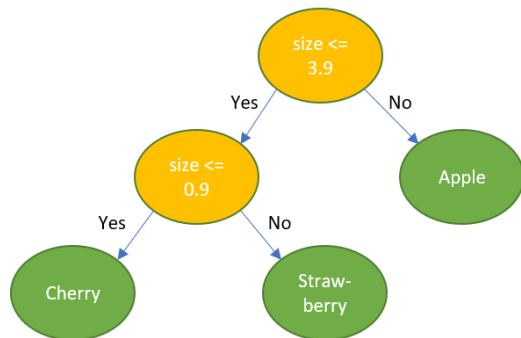
Retos

- No es trivial agregar modelos que no se compongan de un conjunto de pesos.
 - Árboles de decisión
 - Modelos de ensemble
 - K-means clustering
 - ...

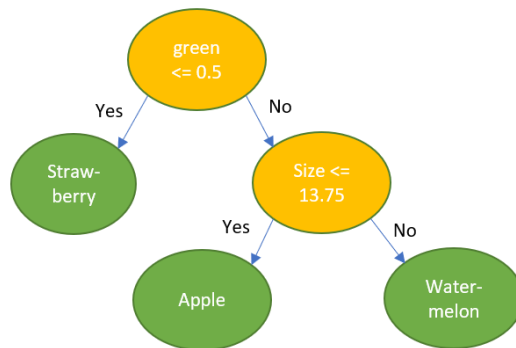
4. Retos en la implementación de modelos no-deep learning

Árboles de decisión


Decision Tree 1



Decision Tree 2



Decision Tree 3



4. Retos en la implementación de modelos no-deep learning

Árboles de decisión (HLF)

[Todos los clientes poseen los mismos atributos]

- El servidor almacena el árbol común
- Pide a los clientes que seleccionen el siguiente atributo para la partición
 - Deben enviar, además de la partición, alguna métrica que indique su bondad.
 - Si envía información sobre n° de patrones por clase, incluye ruido.
- El servidor puede:
 - Seleccionar la mejor partición de entre las recibidas
 - Obtener un consenso
- El servidor actualiza el árbol y pide a los clientes la siguiente partición
- En muchos casos puede que no haya datos suficientes en un nodo concreto

4. Retos en la implementación de modelos no-deep learning

Árboles de decisión (VLF)


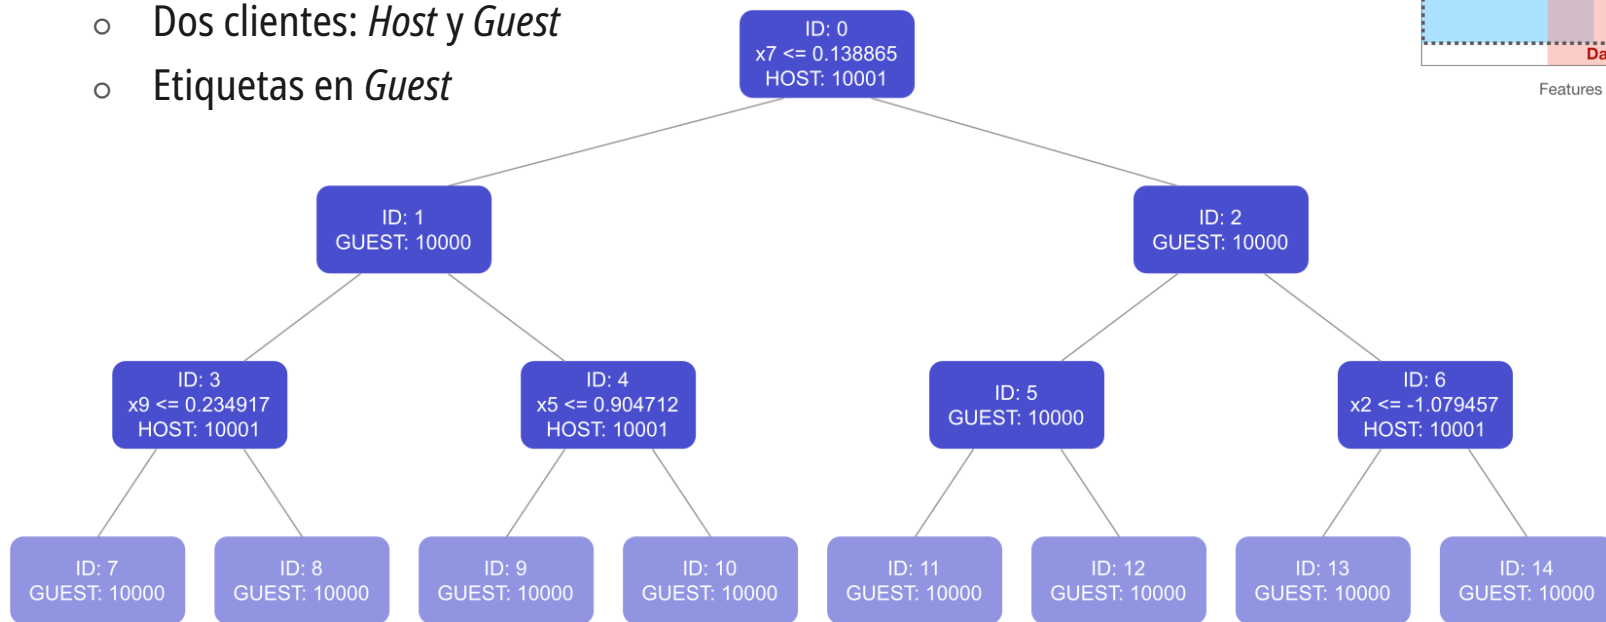
[Cada cliente tiene un subconjunto de atributos distinto]

- El servidor (o cada cliente) almacena la estructura parcial del árbol.
- Cada cliente calcula la mejor partición entre sus atributos.
- Se selecciona la mejor partición de entre todas.
- Se almacena una estructura común con un id de atributo en cada nodo y qué cliente lo posee.
- Al predecir, deben participar todos los clientes.

4. Retos en la implementación de modelos no-deep learning

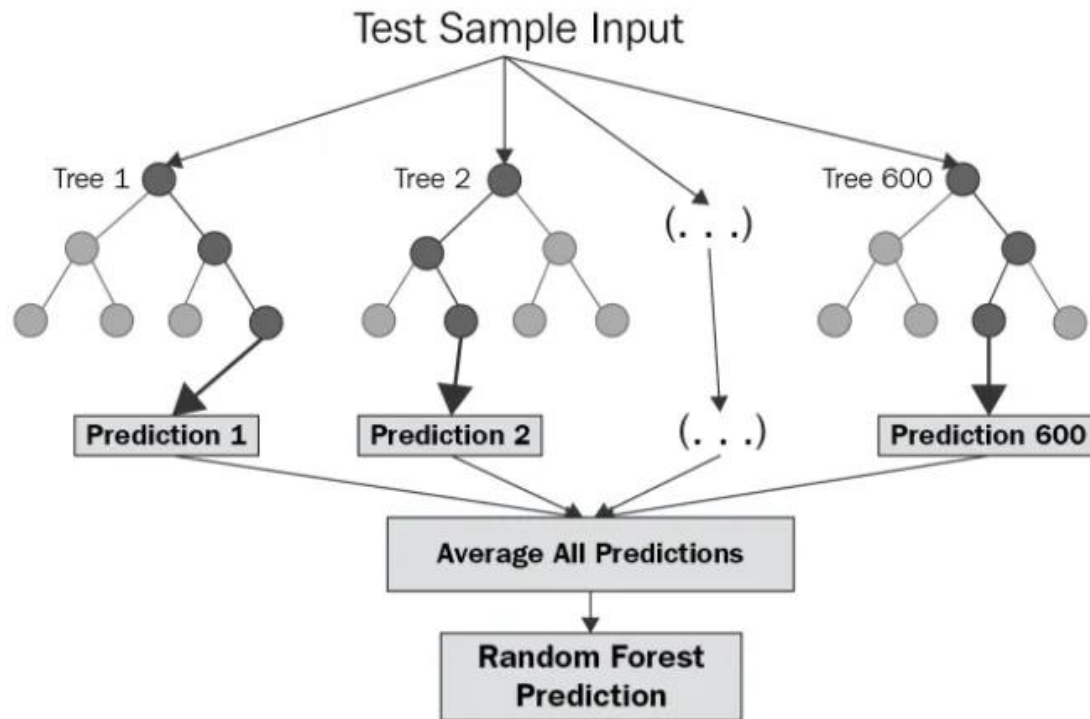
Árboles de decisión (VLF)

- Árbol de decisión en *Host*
 - Dos clientes: *Host* y *Guest*
 - Etiquetas en *Guest*



4. Retos en la implementación de modelos no-deep learning

Random Forest



4. Retos en la implementación de modelos no-deep learning

Basado en Random Forest

- Cada cliente entrena un número de árboles de decisión.
- Comparte los modelos con un servidor
 - No comparte información como tal de los clientes
 - Pero sí el número de instancias de cada clase, ya que envía los árboles completos
 - **Aún revela cierta información que sería deseable que no**
- El servidor envía a los clientes los árboles recibidos
 - Antes de incluir cada árbol en su propio *bosque*, lo evalúa sobre sus datos locales.
 - Evita posibles amenazas o ataques intrusos
 - Evita introducir modelos puntuales con mal rendimiento

4. Retos en la implementación de modelos no-deep learning

Basado en *ensemble distillation*

- Se entrena un modelo global, basado en las salidas de los modelos locales
 - Es necesario que el servidor tenga un conjunto de datos que compartir con los clientes (pueden ser datos públicos, datos sin etiquetar, generados artificialmente, ...)
- Cada cliente entrena su modelo, y evalúa sobre los datos del servidor.
- El servidor colecciona las salidas de los modelos de cada cliente, y las usa como etiquetas para entrenar su propio modelo central.
- La estructura de los modelos no tiene por qué necesariamente ser la misma.

4. Retos en la implementación de modelos no-deep learning

Uso de datos sintéticos

- Cada cliente entrena una GAN y genera datos sintéticos.
- El servidor reúne los datos sintéticos y divide en entrenamiento-validación.
- Envía el conjunto sintético de entrenamiento a todos los clientes.
- Cada cliente entrena sus árboles (sobre sus datos locales y los sintéticos) y los comparte con el servidor.
- El servidor utiliza el conjunto de validación para entrenar hiperparámetros o seleccionar árboles del bosque, si es necesario.

4. Retos en la implementación de modelos no-deep learning

Ensemble iterativo

- En cada iteración, cada cliente construye varios modelos
- Se envían al resto de clientes para que lo validen sobre sus datos
- Se calcula el error medio de validación entre todos los clientes
- Se seleccionan los mejores para formar parte del modelo global

1. Introducción
2. Conceptos y fundamentos
3. Estado del arte
4. Retos en la implementación de modelos no-deep learning
- 5. Conclusiones**

5. Conclusiones

Conclusiones

- Restricción en la privacidad de los datos
- Construcción colaborativa de modelos de ML
- Variedad de categorizaciones y conceptos dentro de FL
- Hay muchos frameworks aunque queda trabajo por hacer
- Retos a los que enfrentarse

Conclusiones

- FedAvg como algoritmo clásico
- Aplicaciones en entornos reales con buenos resultados

- Mucho trabajo para redes neuronales
- Trabajo por hacer en otro tipo de modelos
 - Mención especial a modelos de ensemble

Seminario de Inteligencia Artificial de la Universidad de Sevilla

Aprendizaje Federado: conceptos, estado del arte, y retos en modelos no-deep learning.

Jose M. Moyano



jmoyano1@us.es



<https://personal.us.es/jmoyano1/>