



**IIP-Ecosphere**

Next Level Ecosphere for  
Intelligent Industrial Production



# A scalable Federated Learning Framework for Intelligent Industrial Production

Gefördert durch:



Sofiane Laridi & Gregory Palmer (L3S)  
15. Dezember 2021 · Hannover





# Überblick

Erste KI-Experimente für relevante Anwendungsfälle

KI-Experimente mit eigenen Daten

KI-Experimente zu Produktionsanlagen

Entwicklung von KI und intelligenten Produktionsmethoden

Plattform-Entwicklung & Validierung



Guidelines & Help

Data & AI Tools

Data & AI Tools

Data & AI Tools & Platform Access

Data & AI Tools & (Platform Access)

Data & AI Tools & Platform Access

IIP Workbench mit konfigurierbaren, container-basierten KI-Umgebungen

### Konfigurationsbereich

- Datensätze für ausgewählte Anwendungsfälle
- KI-Tools (z.B. **Federated Learning ...**)
- Computing (GPU, Edge ...)
- Storage
- Plattform-Integration



- IIP-Ecosphere Plattform
- Dynamisch optimierter Container-Deployment
- Systematischer Einsatz von AAS (Verwaltungsschale)
- KI-Methoden-Integration
- Integrierte, konfigurierbare Sicherheit
- Datenintegrationsdienste



GPU Cluster & Speicher



Sensoren & Hardware von Partnern: Lenze, Bitmotec, Phoenix Contact, Artis-Marpos

Digital Twin/Simulation

Produktionstechnisches Experimentierfeld

Experimentierfeld@Messe

IIP Modellwelt



# Warum föderiertes Lernen?

- **Problemstellungen:** Montage- und Positionierungsmethoden für IoT-Sensoren sind nicht standardisiert.
- **Anforderung:** IoT-Sensoren die mit trainierten Lernmodellen über verschiedene Montageszenarien hinweg verallgemeinern können.



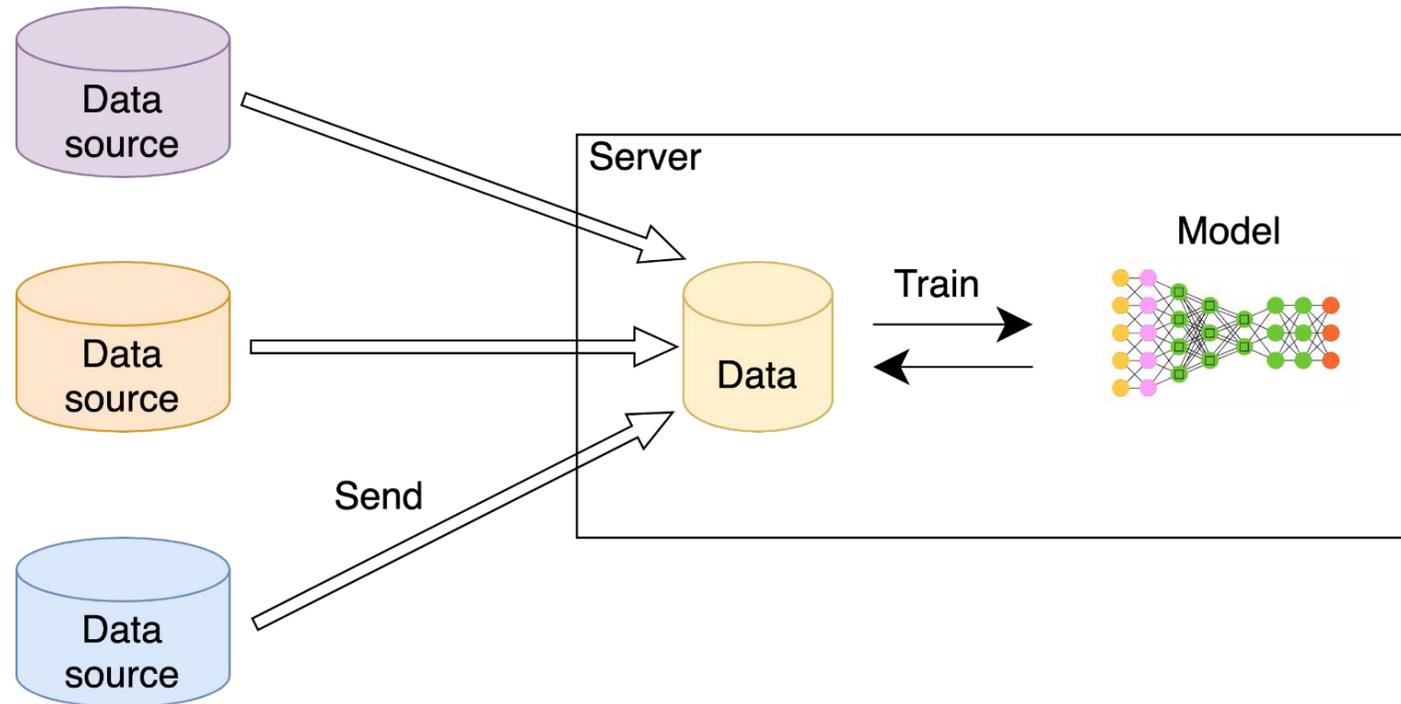
ACOUSTIC & VIBRATION  
ANALYTICS DEVICE (AVA)  
(indaaq.com)





# Zentralisiertes maschinelles Lernen

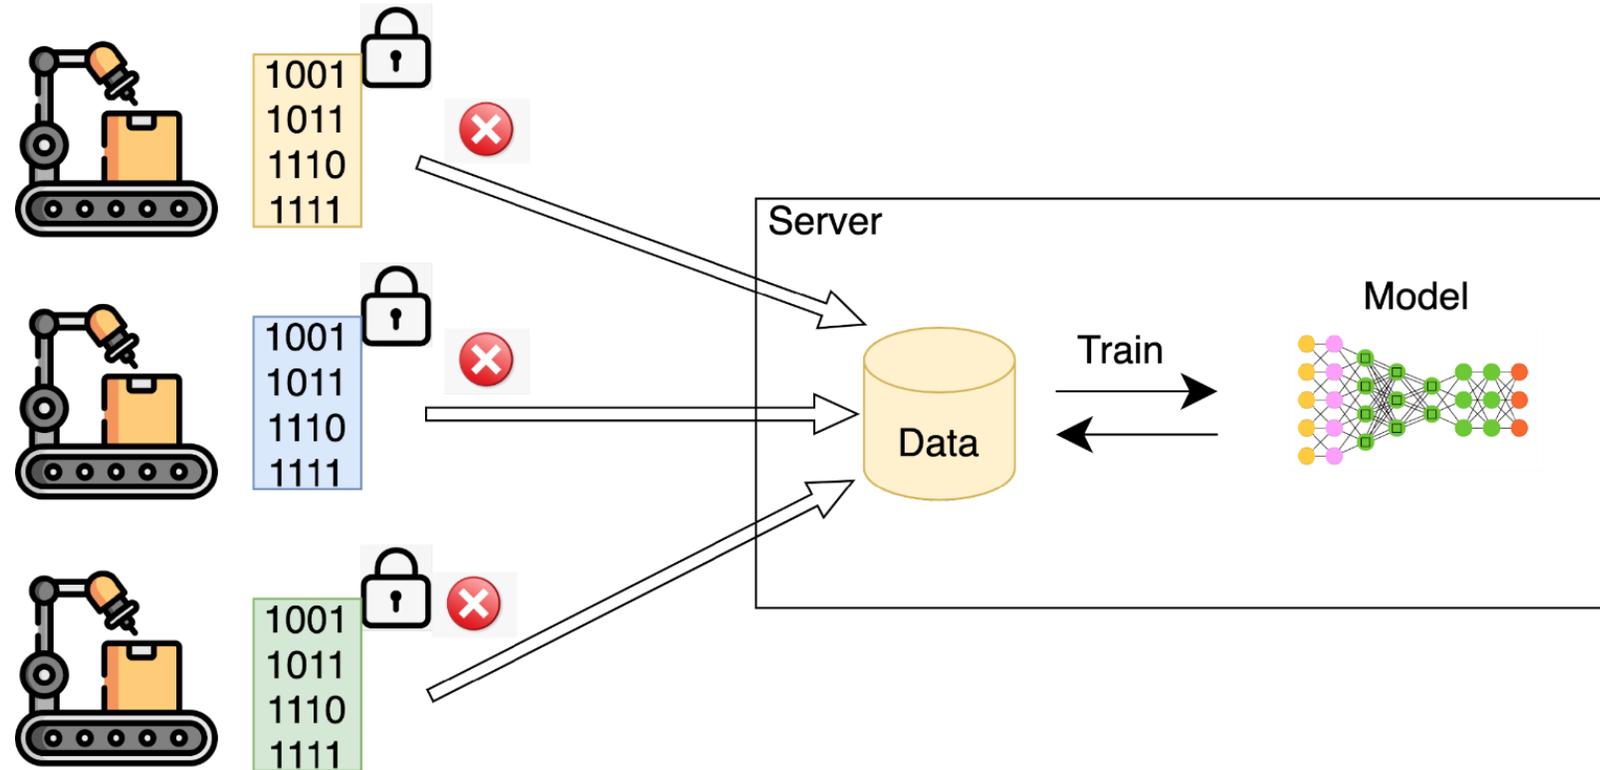
- Bei der traditionellen ML müssen die Daten an den Server gesendet werden.
- Das Modell und die Daten befinden sich am selben Ort.





# Datenschutz beim zentralisierten maschinellen Lernen

Beispiel: Erkennung von Anomalien bei Industriemaschinen.

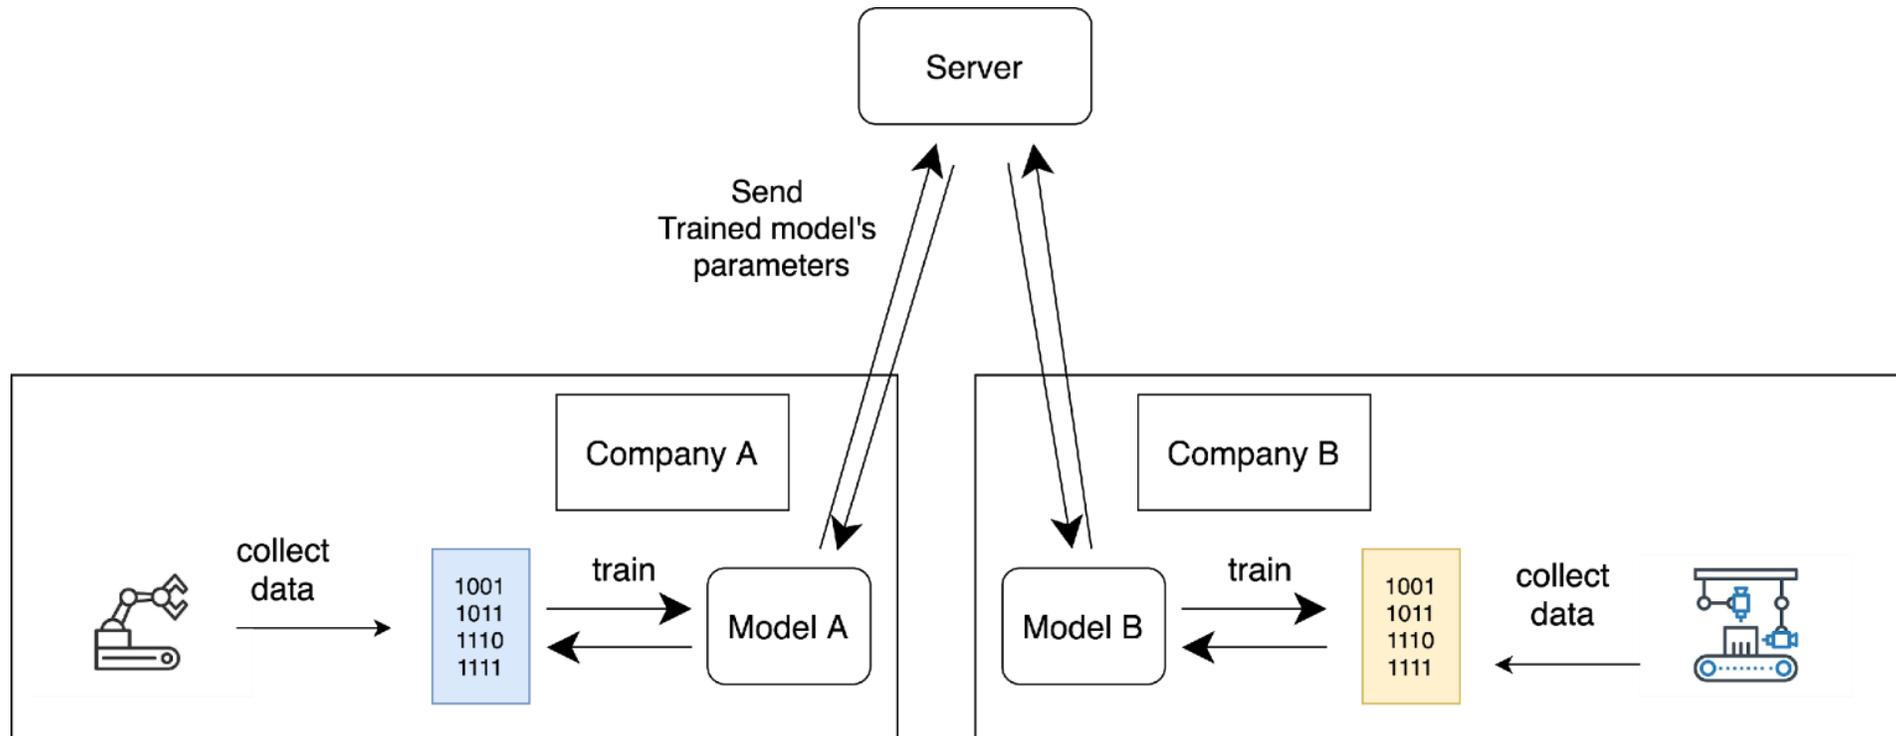


Wie kann man ein hochwertiges Modell erstellen, das die Daten nutzt, ohne sie zu teilen?



# Federated Learning

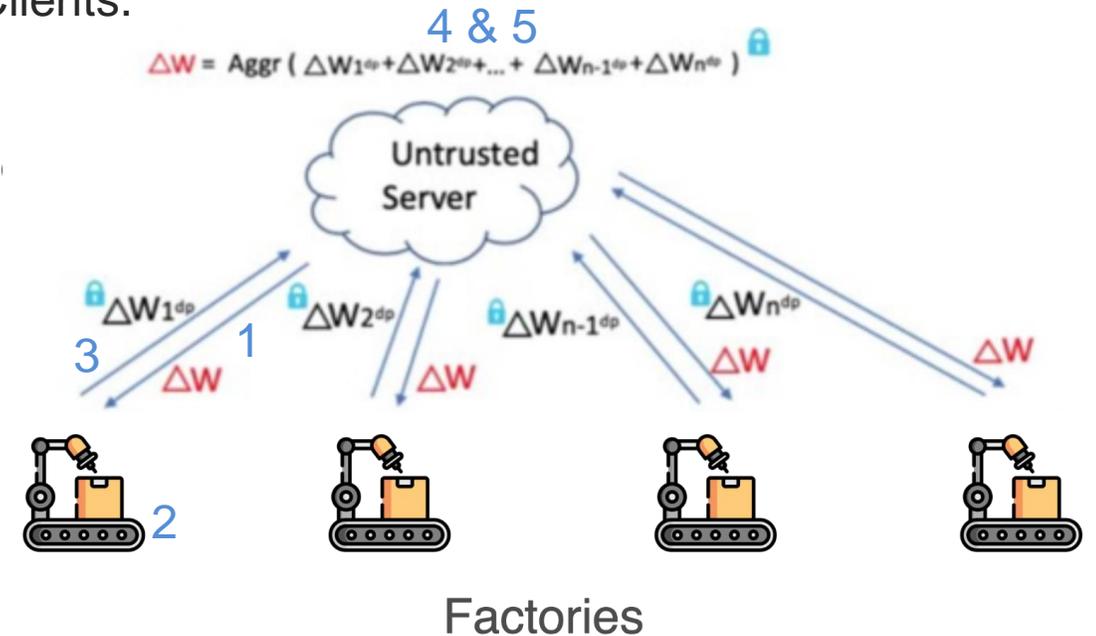
- Gemeinsames Trainieren eines Modells ohne gemeinsame Nutzung der Daten.
- Die Modelle werden lokal trainiert und nur die Modellparameter/Gewichte an den Server weitergegeben.





# Federated Learning Workflow

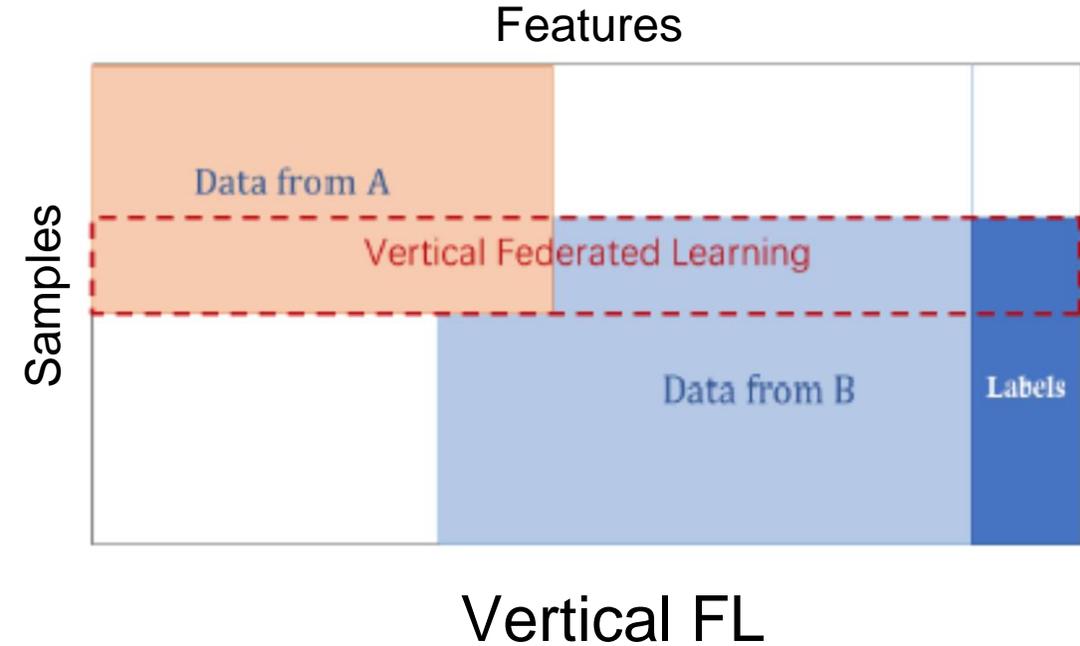
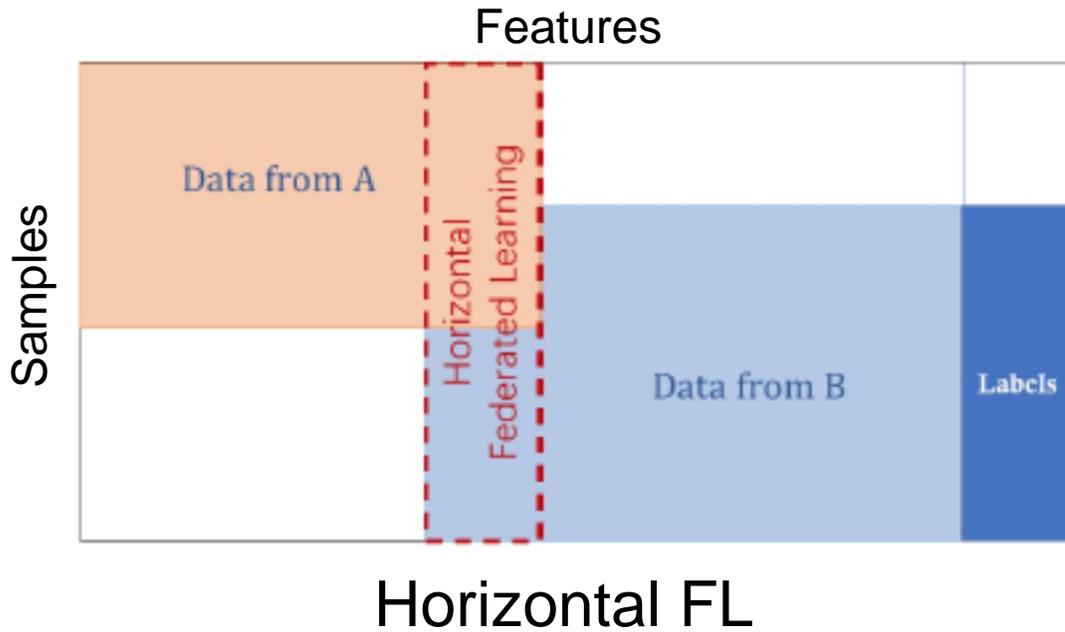
1. Der Server sendet das globale Ausgangsmodell an die Clients.
2. Clients trainieren mit lokalen Daten für n Epochen.
3. Die modifizierte Gewichte werden an den Server gesend
4. Der Server aggregiert die empfangenen Gewichte
5. Der Server aggregiert die Gewichte und sendet das aktualisierte Modell an die Clients zurück.
6. Die Schleife wird  $m$ -mal (Runden) wiederholt, bis das globale Modell konvergiert.





# Federated Learning Types

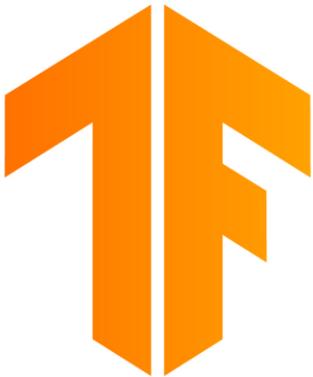
- Je nach den Daten der Teilnehmer kann die FL horizontal oder vertikal aufgebaut werden:





IIP-Ecosphere

# Federated Learning open-source frameworks



TENSORFLOW  
FEDERATED (TFF)



IBM FEDERATED

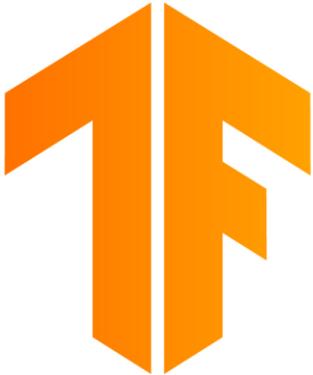


FLOWER: BUILT ON  
TOP OF TFF



IIP-Ecosphere

# Federated Learning open-source frameworks



TENSORFLOW  
FEDERATED (TFF)



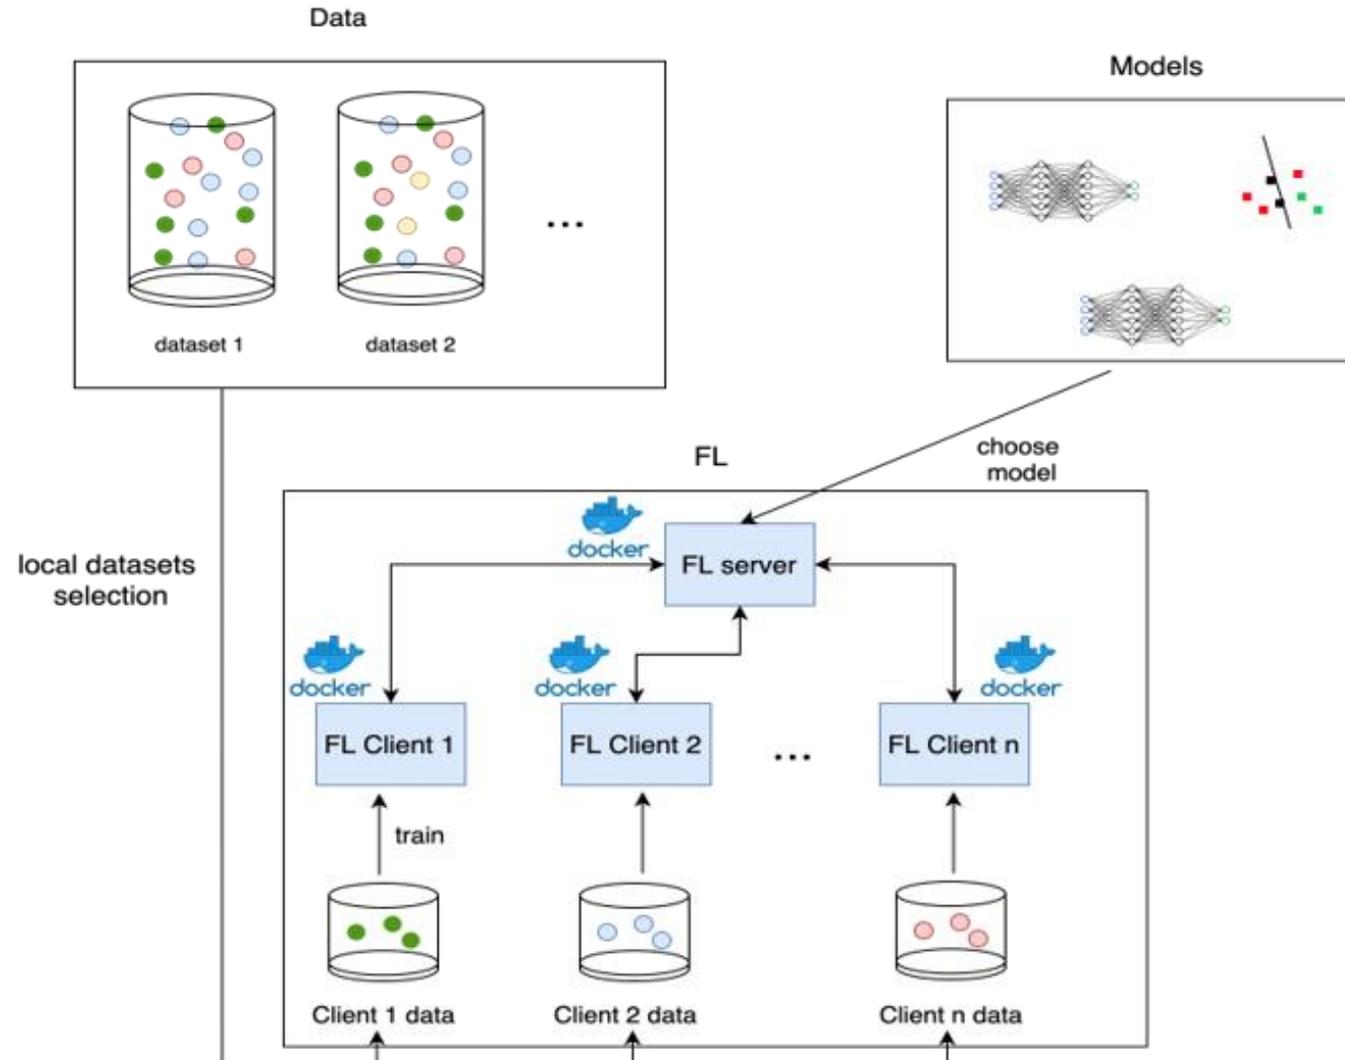
IBM FEDERATED



FLOWER: BUILT ON  
TOP OF TFF



# Flower Erweiterungen: Backend





# Flower Erweiterungen: Frontend

Dataset:  ▼

Model:  ▼

Client Num:  3

FL\_round:  6

Epochs:  8



# Flower Erweiterungen: Frontend

Dataset:	<input type="text" value="demos"/> ▼	Client Num:	<input type="range" value="3"/>	3
Model:	<input type="text" value="fgsm_cnn"/> ▼	FL_round:	<input type="range" value="6"/>	6
		Epochs:	<input type="range" value="8"/>	8

Start FL

Server is running successfully!  
172.17.0.40



# Flower Erweiterungen: Frontend

Dataset:  ▼    Client Num:  3

Model:  ▼    FL\_round:  6

Epochs:  8

Start FL

```
Server is running successfully!  
172.17.0.40  
Clients is running successfully!
```

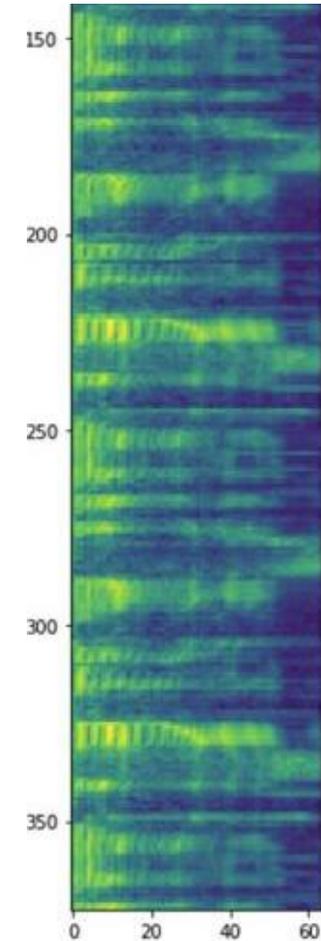
Client num:  ▼

```
server online | client-1 online  
round: 2/6 | epoch: 4  
aggregated accuracy: 0.20000000298023224 | client accuracy: 0.21  
dataset: demos | client loss: 1.93  
model: fgsm_cnn
```



# Eine Bewertung des groß angelegten föderalen Lernens

- Getestet auf dem DGX mit **68 clients** mit **6 A100** Grafikkarten (40 GB Speicher pro Karte).
- Wir konnten eine Genauigkeit von **90,1%** bei Log-Mel-Spektrogramm-Daten vom Datensatz Demos erreichen.





# Momentaner Status

- Version 1.0 unserer Implementierung, einschließlich der grafischen Benutzeroberfläche, ist abgeschlossen.
- Das Framework kann an einer Reihe von öffentlich zugänglichen Datensätzen ausprobiert werden, die wir beigefügt haben.
- Möglichkeiten zum Ausprobieren des Frameworks mit eigenen Daten - **Auf Absprache**



IIP-Ecosphere

# Kontakt



Gregory Palmer (L3S)



Sofiane Laridi (L3S)



gpalmer@l3s.de



laridi@l3s.de



<https://www.iip-ecosphere.eu>



@de\_iipecosphere