



Machine Learning ohne Preisgabe privater Daten mit Federated Learning

Christian Becker

Karlsruhe, 11. März 2020

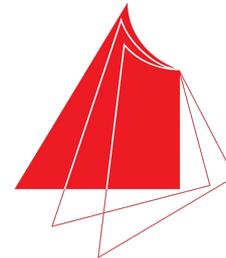
Christian Becker

Informatikstudent an der Hochschule Karlsruhe:

2019/02 Werkstudent inovex

2019/2020 Bachelorthesis bei inovex

2020 Master in Informatik an der Hochschule Karlsruhe



**Hochschule Karlsruhe
Technik und Wirtschaft**

UNIVERSITY OF APPLIED SCIENCES

Roadmap

1. Was ist Federated Learning
2. Worauf muss man in Federated Learning achten
3. Differential Privacy & Secure Aggregation
4. Evaluation
5. Ergebnisse
6. Zusammenfassung

Overview Federated Learning

- Spezialfall von verteiltem Machine Learning mit mehreren Teilnehmern
- Ermöglicht das Training ohne Herausgabe der Trainingsdaten
- Schützt die Privatsphäre der Daten durch Differential Privacy

Machine Learning

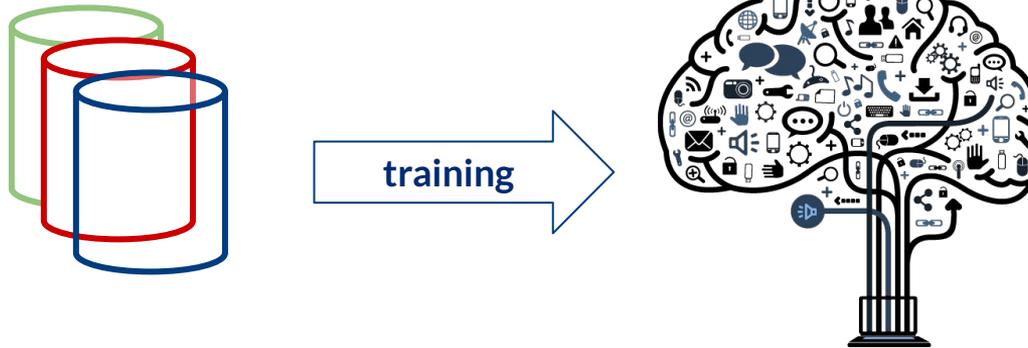
Modell lernt Muster und Gesetzmäßigkeiten von Daten

Training: Optimierungsprozess der wiederholt mit den Daten durchgeführt wird



Federated Learning

- Ermöglicht das Lernen mit privaten dezentralen Daten
- Daten verbleiben bei den Besitzern
- Eine Art von verteilten maschinellem Lernen

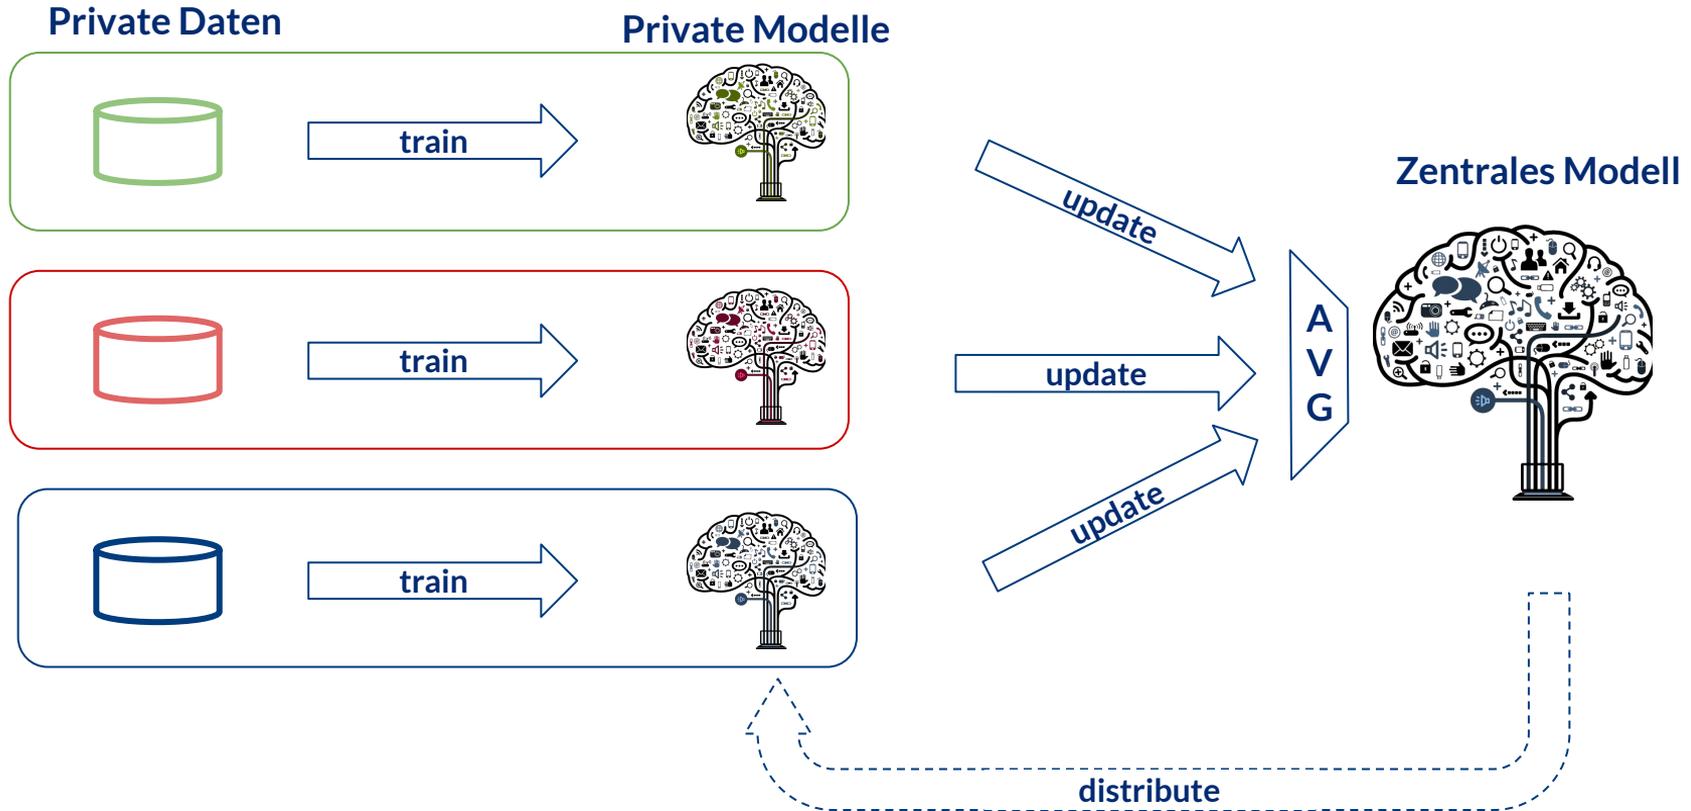


Beispiele für Private Daten

- MRT Bilder aus mehreren Krankenhäusern zur Tumorerkennung
- Sensordaten aus autonomen Autos zu Verbesserung der Gefahrenerkennung
- Tastatureingabe von Smartphones zum Trainieren einer Autovervollständigung



Federated Learning mit privaten Daten



Aggregation in Federated Learning

Gewichteter Mittelwert über die Modellparameter:

Zentrale Modellparameter

#Teilnehmer

#Samples von Teilnehmer k

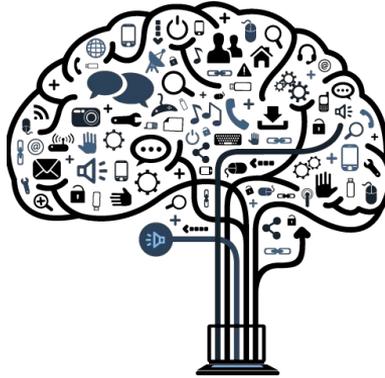
Lokale Modellparameter des Teilnehmers k

#Samples

$$w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k$$

The diagram illustrates the aggregation formula for federated learning. It features a central equation: $w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k$. The variables are color-coded: w_{t+1} is in a red box (Zentrale Modellparameter), K is in a blue box (#Teilnehmer), n_k is in a pink box (#Samples von Teilnehmer k), n is in a purple box (#Samples), and w_{t+1}^k is in a green box (Lokale Modellparameter des Teilnehmers k). The summation symbol \sum and the index $k=1$ are in black.

Privacy in Machine Learning



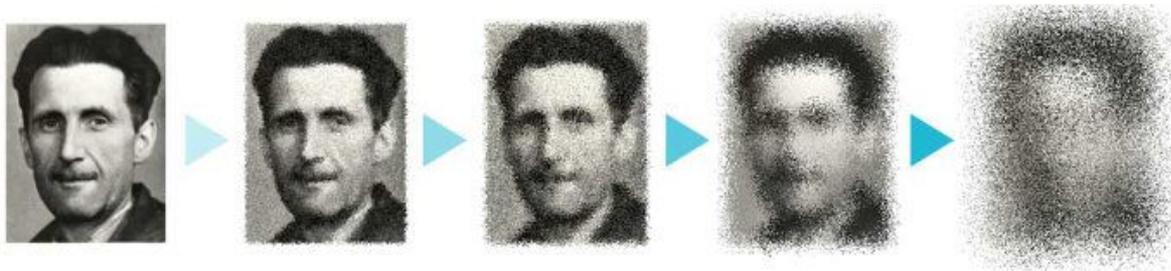
Trainingsdaten können aus dem Modell extrahiert werden:

“Meine Kreditkartennummer ist **4567-4321-8932-0973** “

Sanitizer können nicht alle personenbezogenen Informationen entfernen.

Differential Privacy

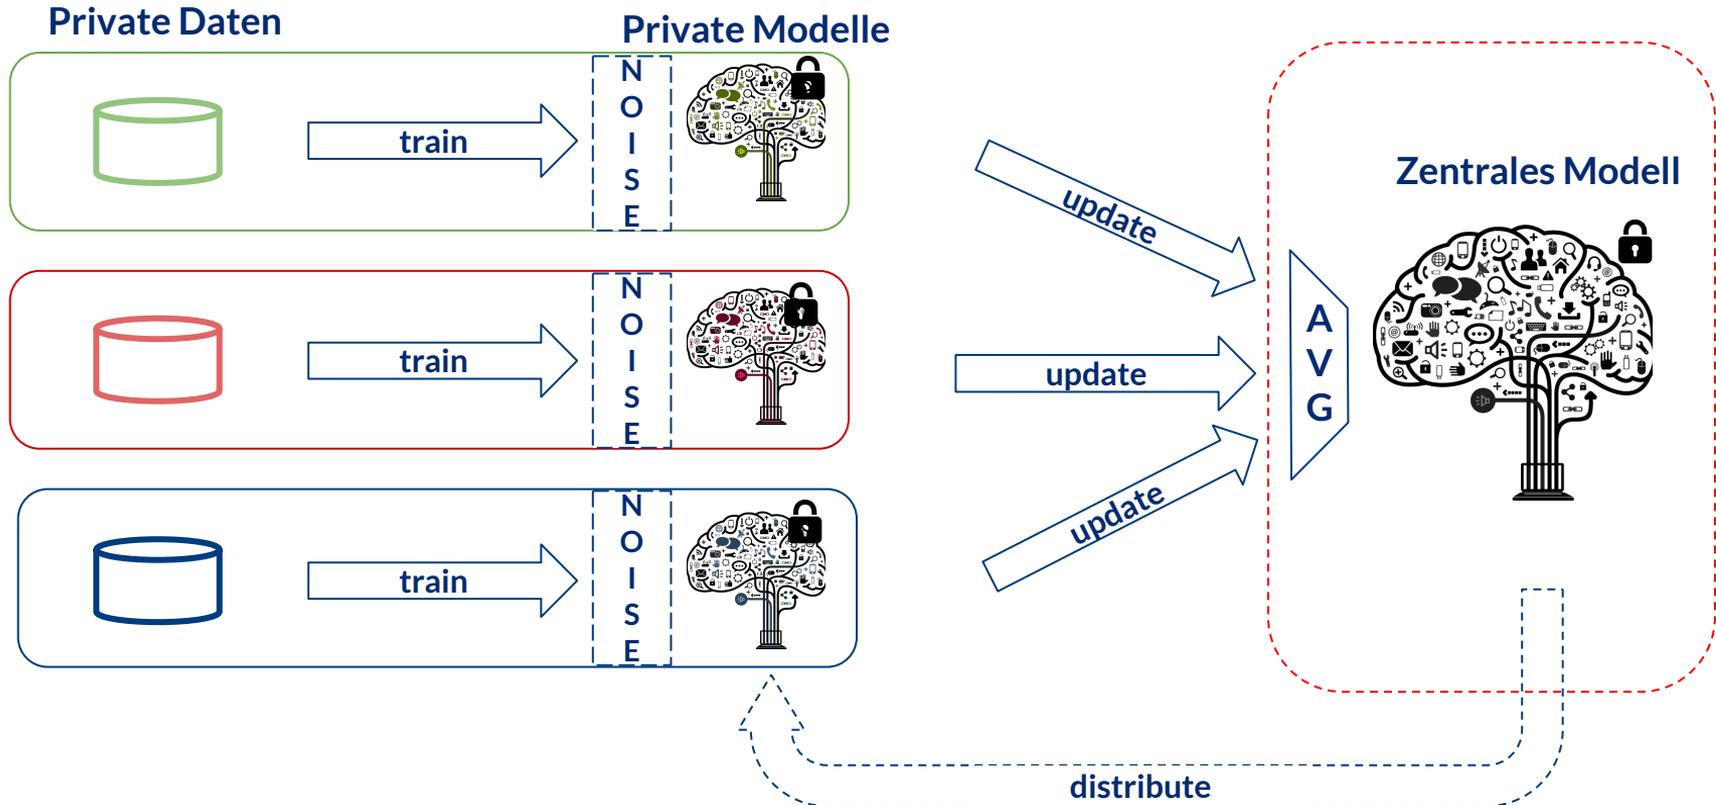
- Differential Privacy verhindert, dass Trainingsdaten aus den Modellen generiert werden können
- Verrauscht Gradienten im lokalen Optimierungsprozess des SGD
- Beeinflusst durch das Rauschen die Qualität des Modells
- Begrenzt die Anzahl der Möglichen Trainingsepochen



*high utility
no privacy*

*high privacy
no utility*

Differential Private - SGD



Secure Multi-Party Computation (SMPC)

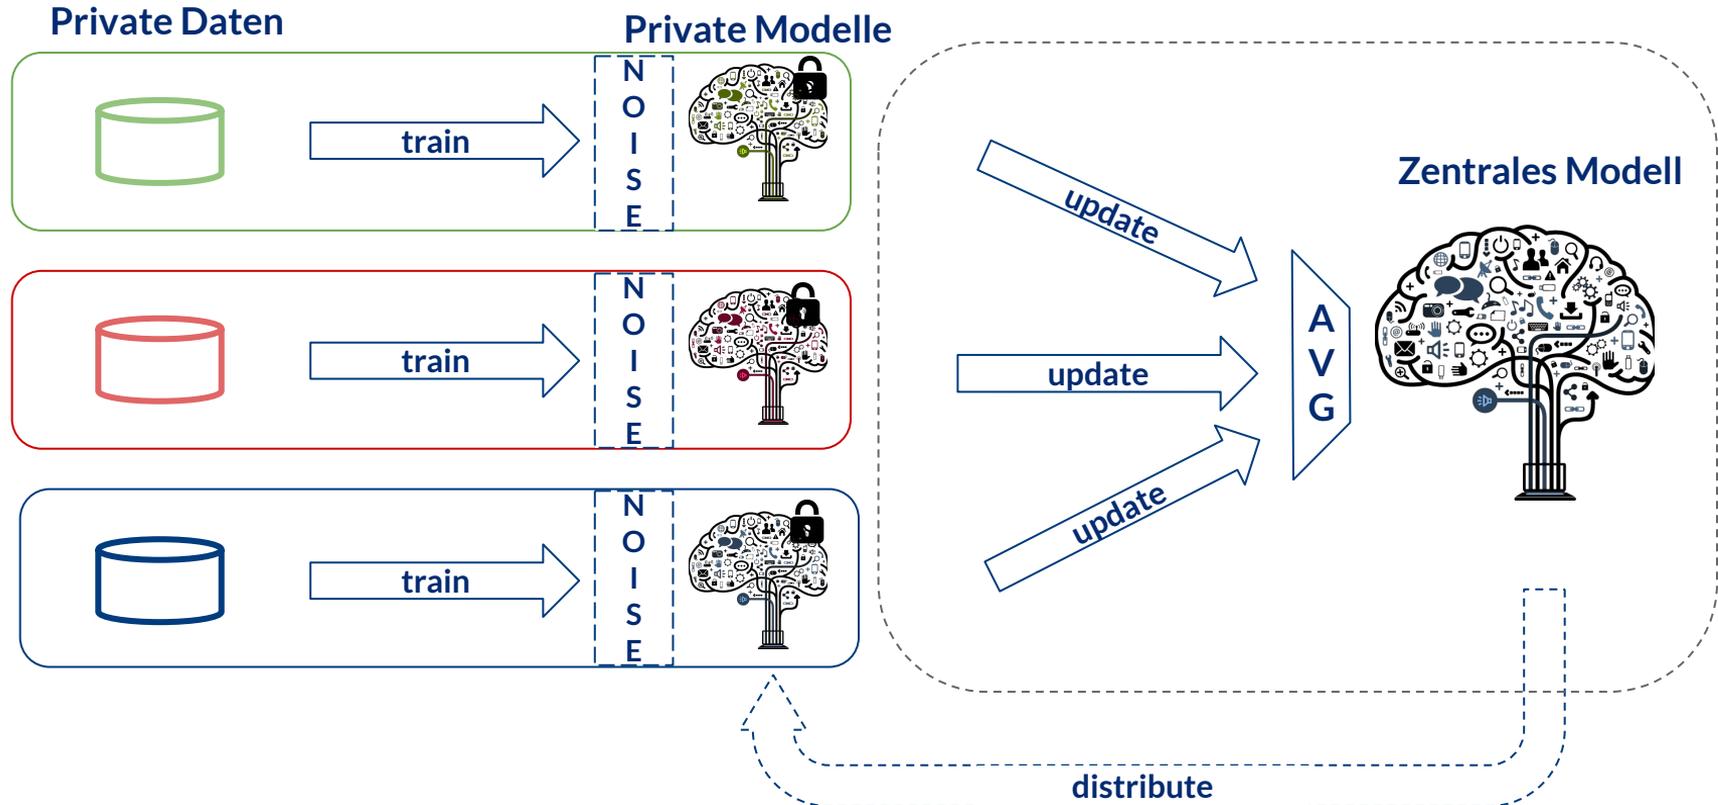
- Ermöglicht das Rechnen mit verschlüsselten Zahlen!
- Beschränkt auf ganze Zahlen, Addition und Multiplikation

Lokal bei den Teilnehmer Dezentral mit SMPC

$$w_{t+1} \leftarrow \sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k \quad \longrightarrow \quad w_{t+1} \leftarrow \left[\frac{1}{n} \sum_{k=1}^K n_k w_{t+1}^k \right]$$

Lokal beim Teilnehmer k

Federated Learning mit SMPC



Evaluation



PySyft Framework

PySyft ermöglicht Federated Learning mit PyTorch:

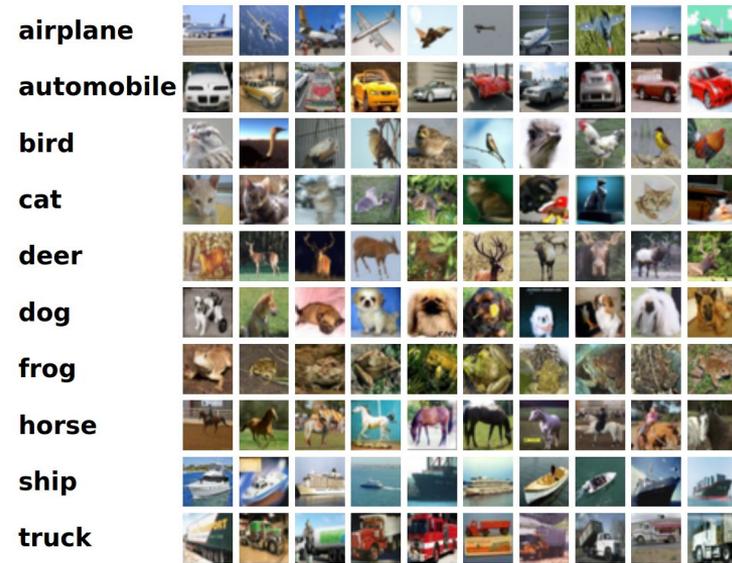
- Worker sind passive Einheiten die private Daten vorhalten
- Trainingsprozess wird zentral gesteuert (mit hook auf PyTorch)
- Training nur auf der CPU nicht auf der GPU möglich
- Noch keine Verschlüsselung der Kommunikation
- Keine Differential Privacy implementierung

Datensätze

MNIST-10:



CIFAR-10:



Evaluationsaufbau

- Vergleich verschiedener Federated Learning Training Setups:

Parameter	Optionen
Worker type	virtual or docker
Number of workers	2 to N workers
Amount of samples	up to 50.000 samples
Klassenverteilung	Percent per worker
SMPC	Activate or Deactivate

Evaluations Metriken

- Vergleichen von folgenden Metriken:
 - Accuracy des Zentralen Modells
 - Accuracy pro Klasse
 - Anzahl an gesendeten Nachrichten
 - Trainingszeit

Evaluations Experimente

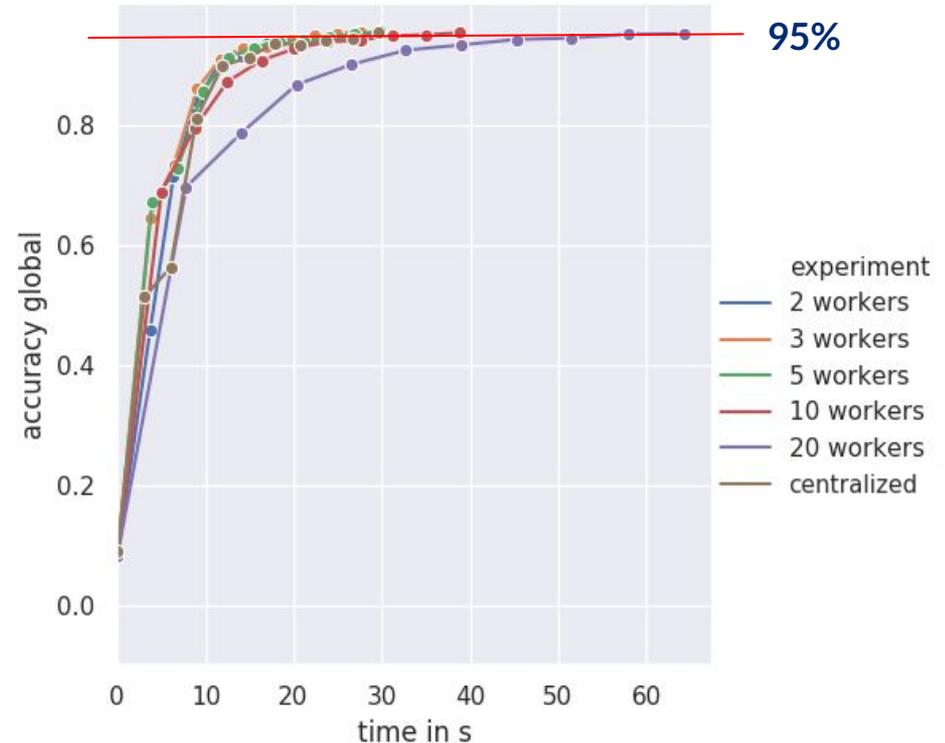
- Zentralisiertes vs Federated Learning
- Ungleichmäßige Verteilung der Klassen auf die worker
- Unbalancierte Klassenverteilung

Zentralisiertes vs Federated Training

- 2 bis 20 worker
- 10k samples
- 10 epochs
- gleichmäßige Klassenverteilung

Anzahl der Worker beeinflusst
Accuracy nicht

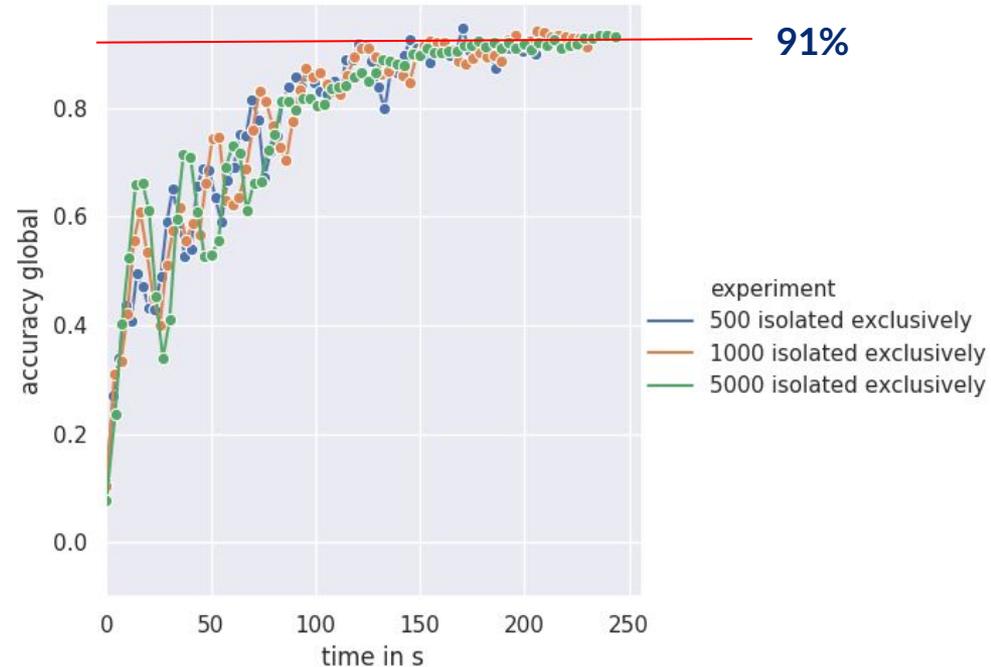
Je mehr worker je länger ist die
Trainingszeit



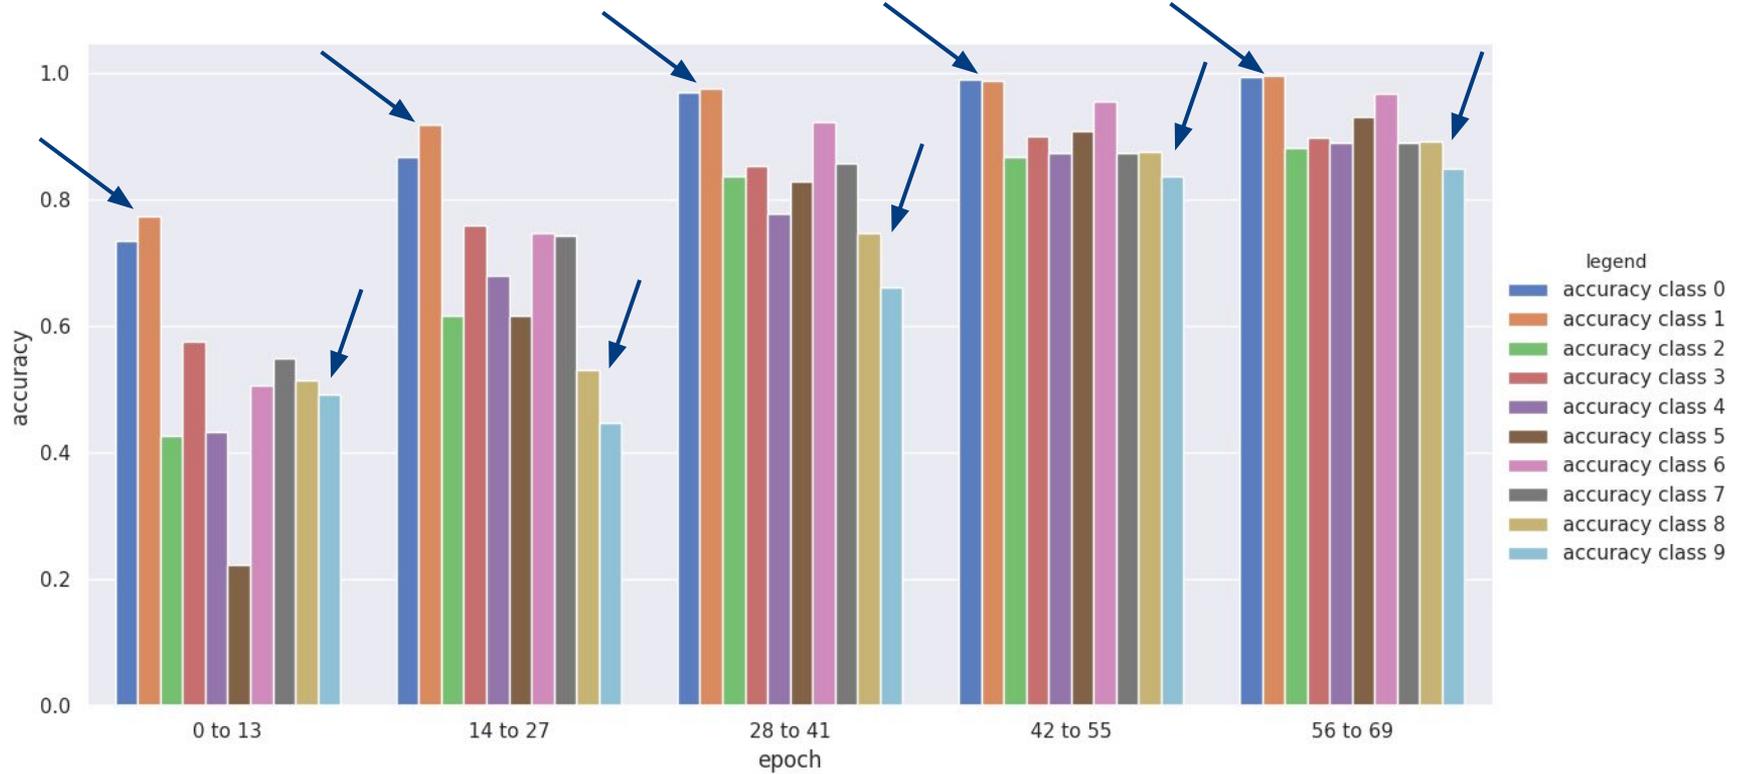
Ungleichmäßige Klassenverteilung

- 10 worker
- 500, 1.000 und 5.000 samples
- 70 epochs
- Jede Klasse isoliert auf einen worker

Training mit ungleichmäßiger Klassenverteilung ist möglich



Ungleichmäßige Klassenverteilung



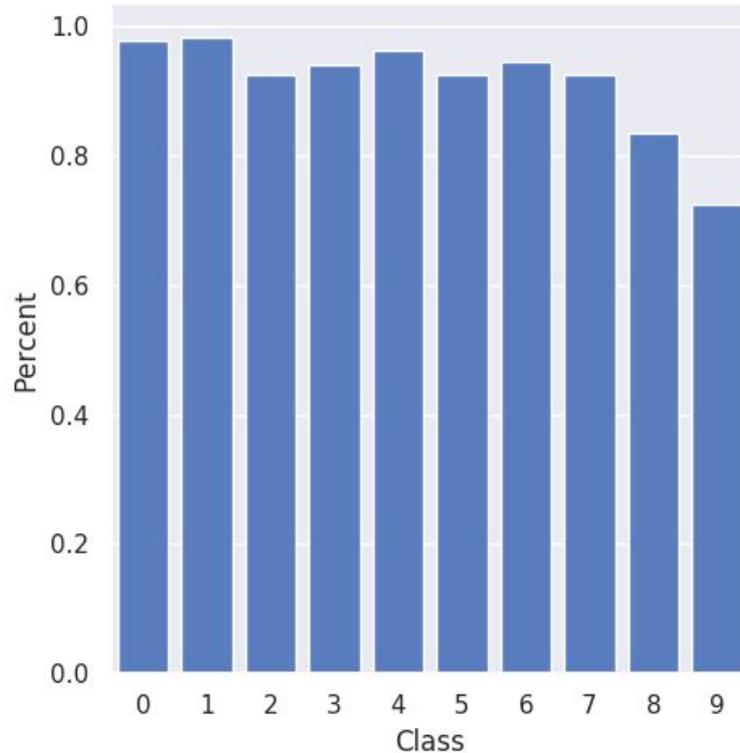
Unbalancierte Klassenverteilung

- Alle Klassen sind exklusive auf einem Worker verfügbar

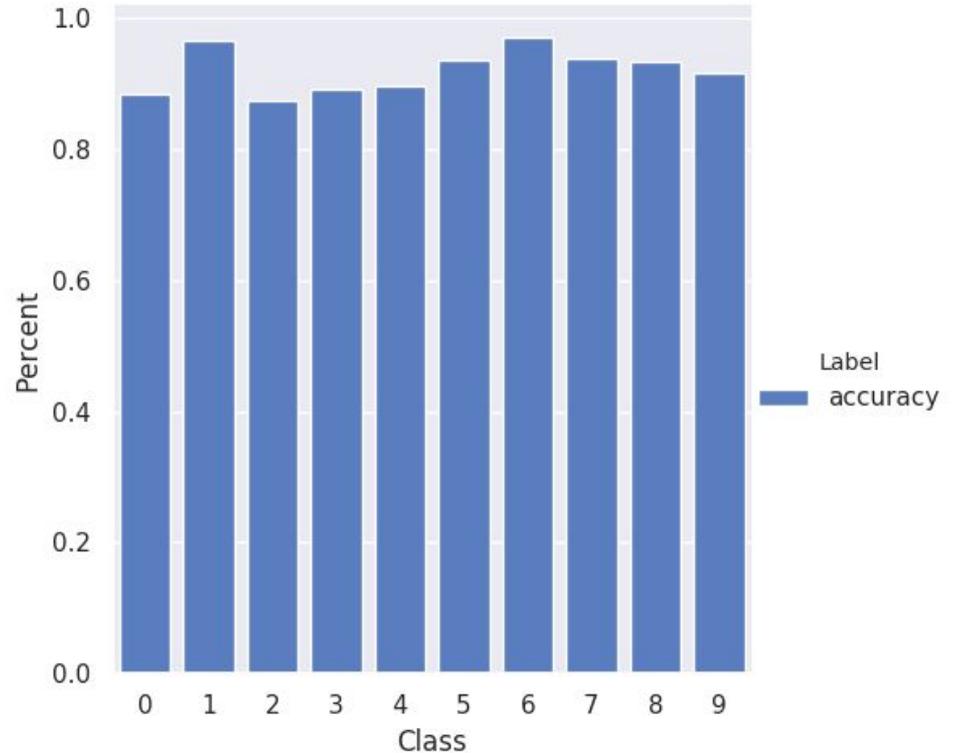
Klasse	0	1	2	3	4	5	6	7	8	9
decreasing ↓	500	450	400	350	300	250	200	150	100	50
increasing ↑	50	100	150	200	250	300	350	400	450	500

- 100 epochs
- Erreichen eine Accuracy von 91%

Unbalancierte Klassenverteilung



decreasing ↓



increasing ↑

Zusammenfassung

Federated Learning ermöglicht das:

- Trainieren mit privaten Daten durch Differential Privacy
- Verteiltes Lernen auf vielen Endgeräten
- Skalieren auf den Use Case

Ergebnisse aus meiner Evaluation:

- Federated Learning mit ungleichmäßiger Klassenverteilung ist möglich
- Verteilung der Klassen ist relevant für die Accuracy ist
- Für die Anwendbarkeit muss Differential Privacy als Technik leichter zugänglich werden

Vielen Dank

Christian Becker
working student
@ Team DMA

inovex GmbH
Ludwig-Erhard-Allee 6
76131 Karlsruhe

cbecker@inovex.de

