

# 連合学習における訓練データの一部共有による精度向上手法のテストベッドでの評価

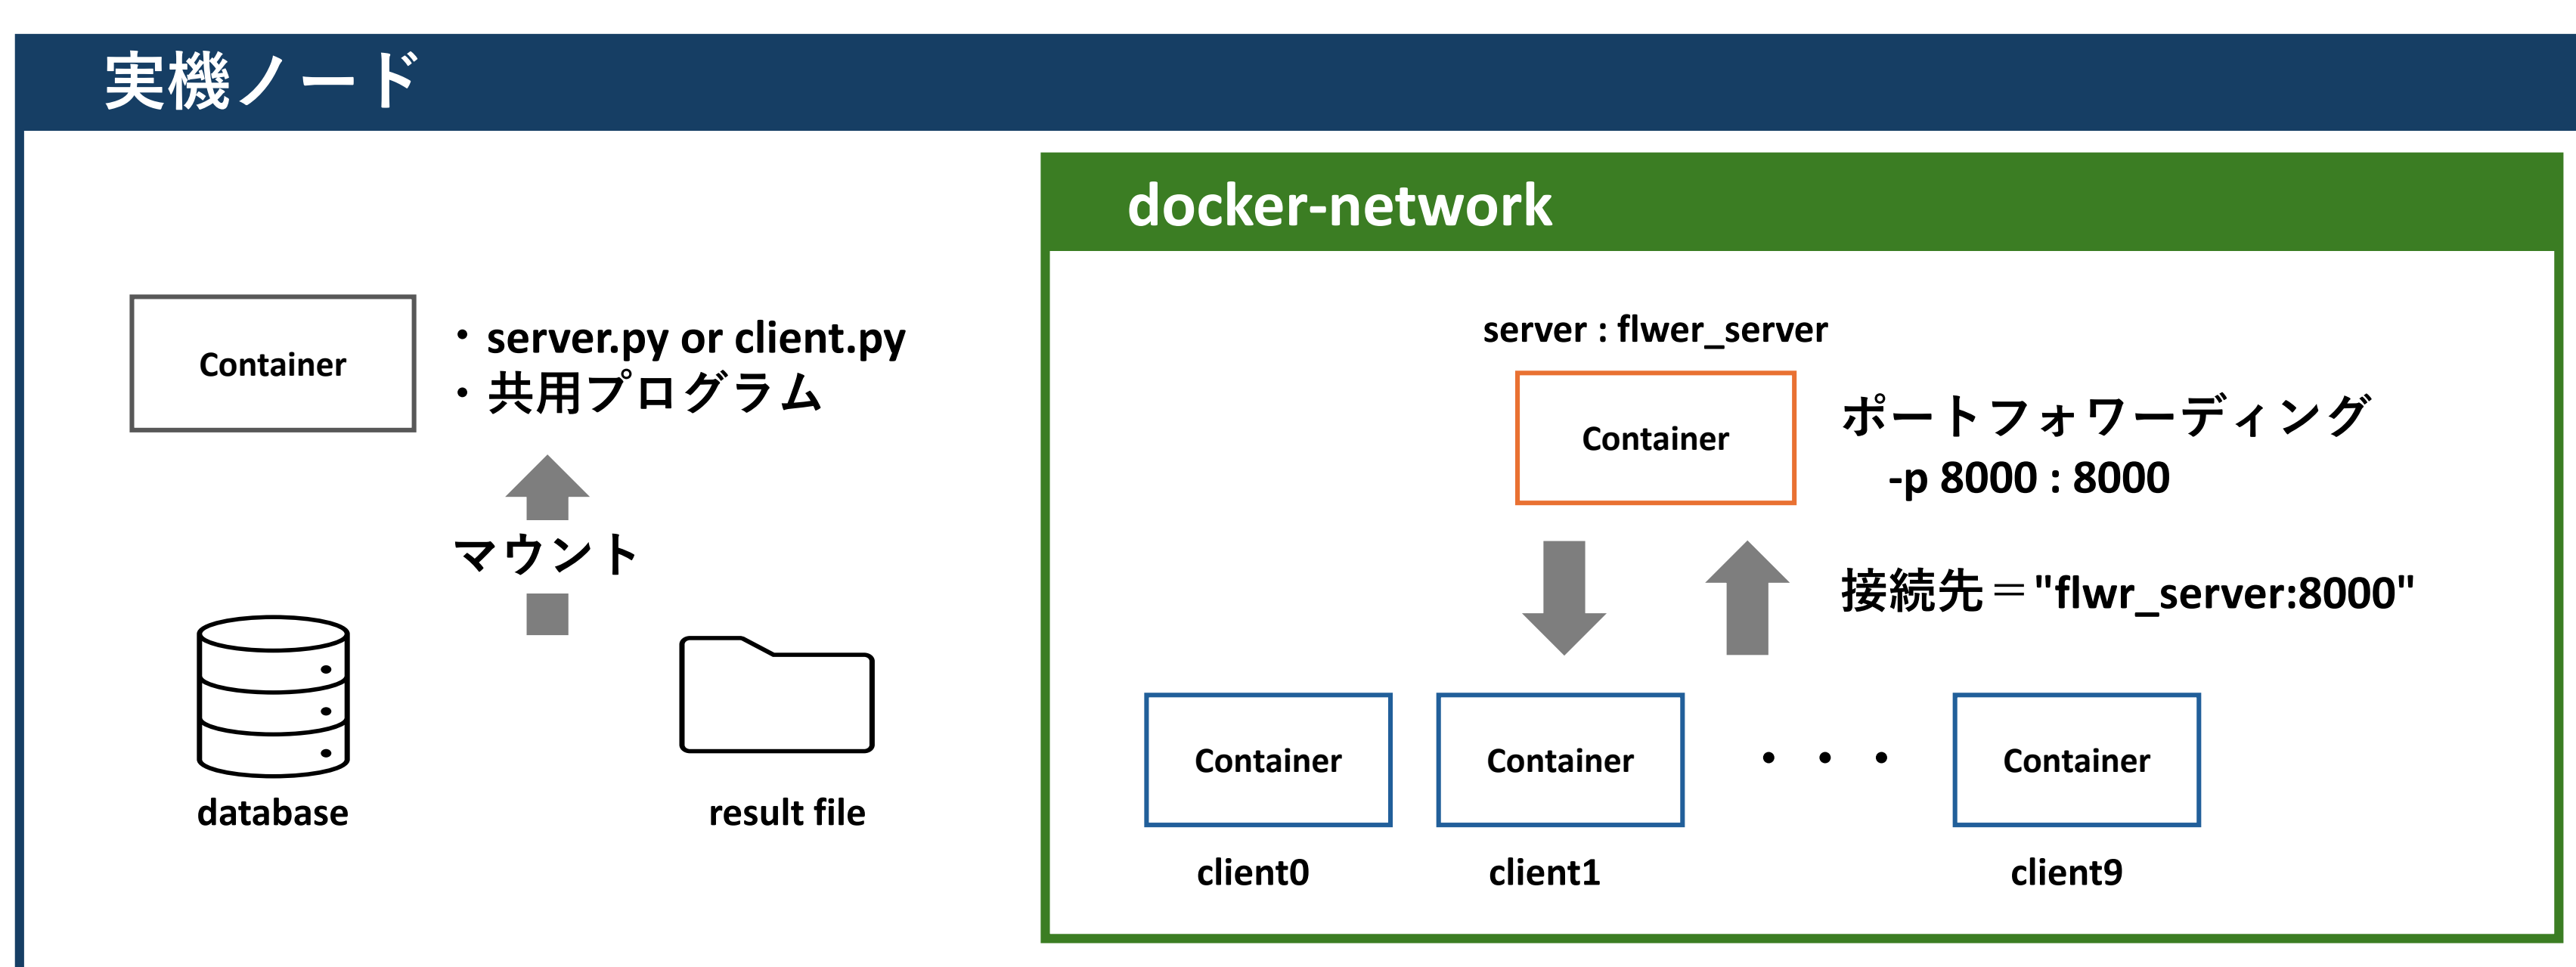
岡田明日香 川上朋也 長谷川達人 (福井大学)

## 背景

- 特にデータのプライバシーの観点で、**連合学習による分散型検知**が注目
- 検知の精度を向上するため、我々は先行研究[1]において「**訓練データの一部をクライアント間で共有する**」という新しい考えを提案
- ネットワーク侵入検知システム (NIDS) を例として、シミュレーションで評価していた先行研究を**DockerおよびStarBED上で評価**

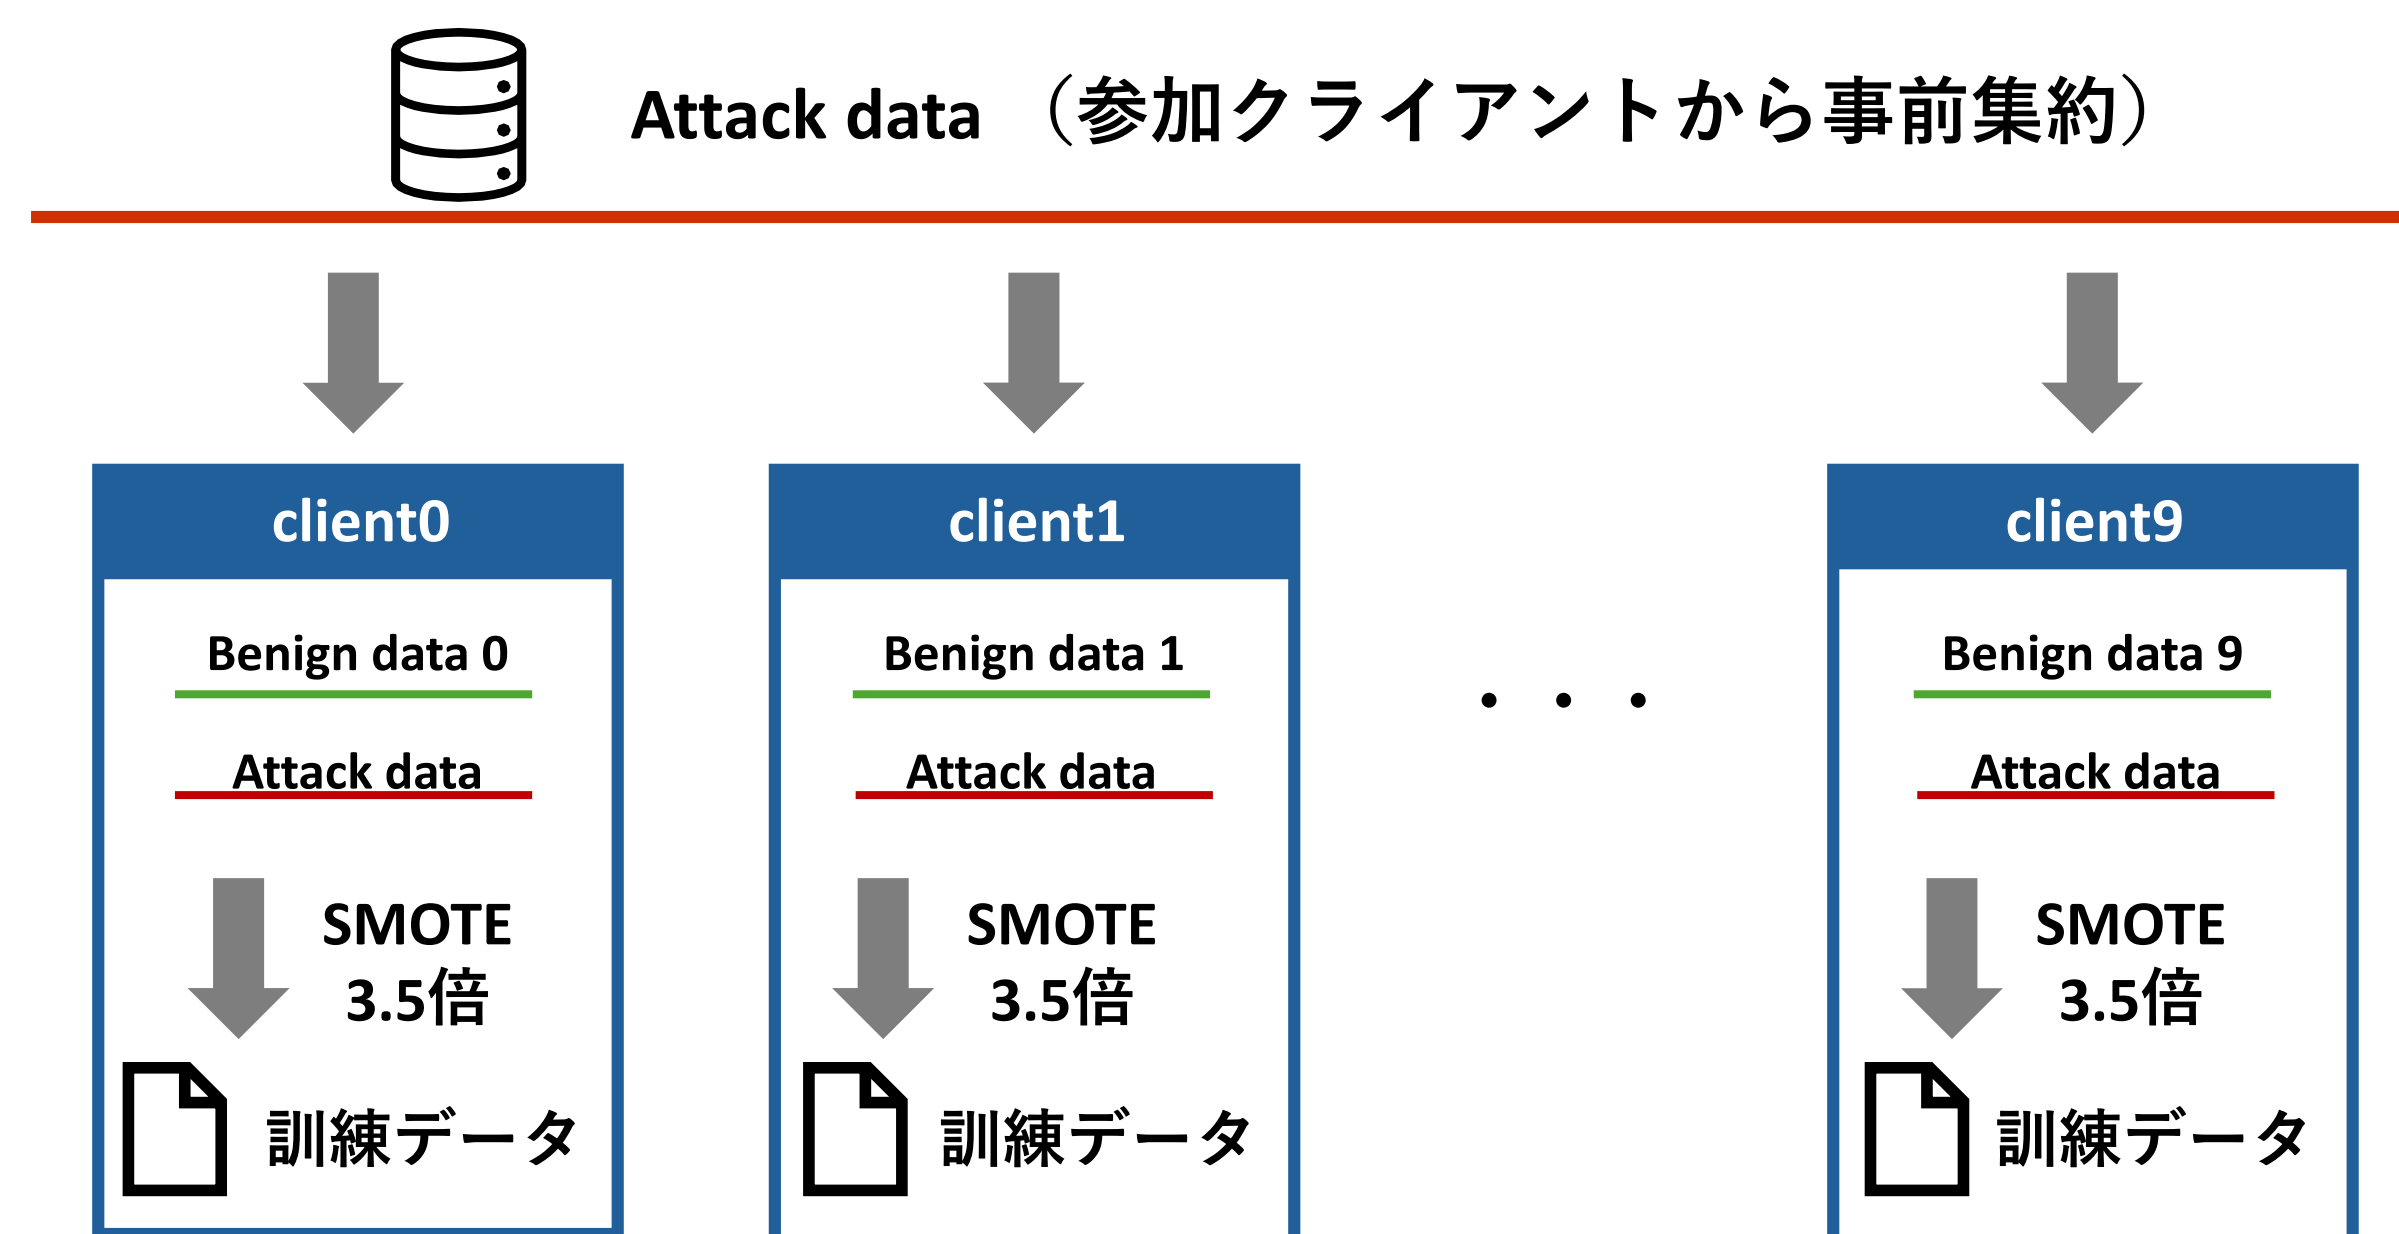
## 検証環境

- テストベッド：StarBED
  - 実機ノード：1台
  - Dockerコンテナ：11台
    - ・サーバ：1台
    - ・クライアント：10台
  - docker composeにより一括管理
  - データセットや結果格納先は外部からマウント
- ※単一実機上で論理的に分離された分散環境を構築



## 提案手法

FLにおける**攻撃データのクライアント間共有の許可**  
+ **正常・攻撃両データのSMOTE[2]アップサンプリング**

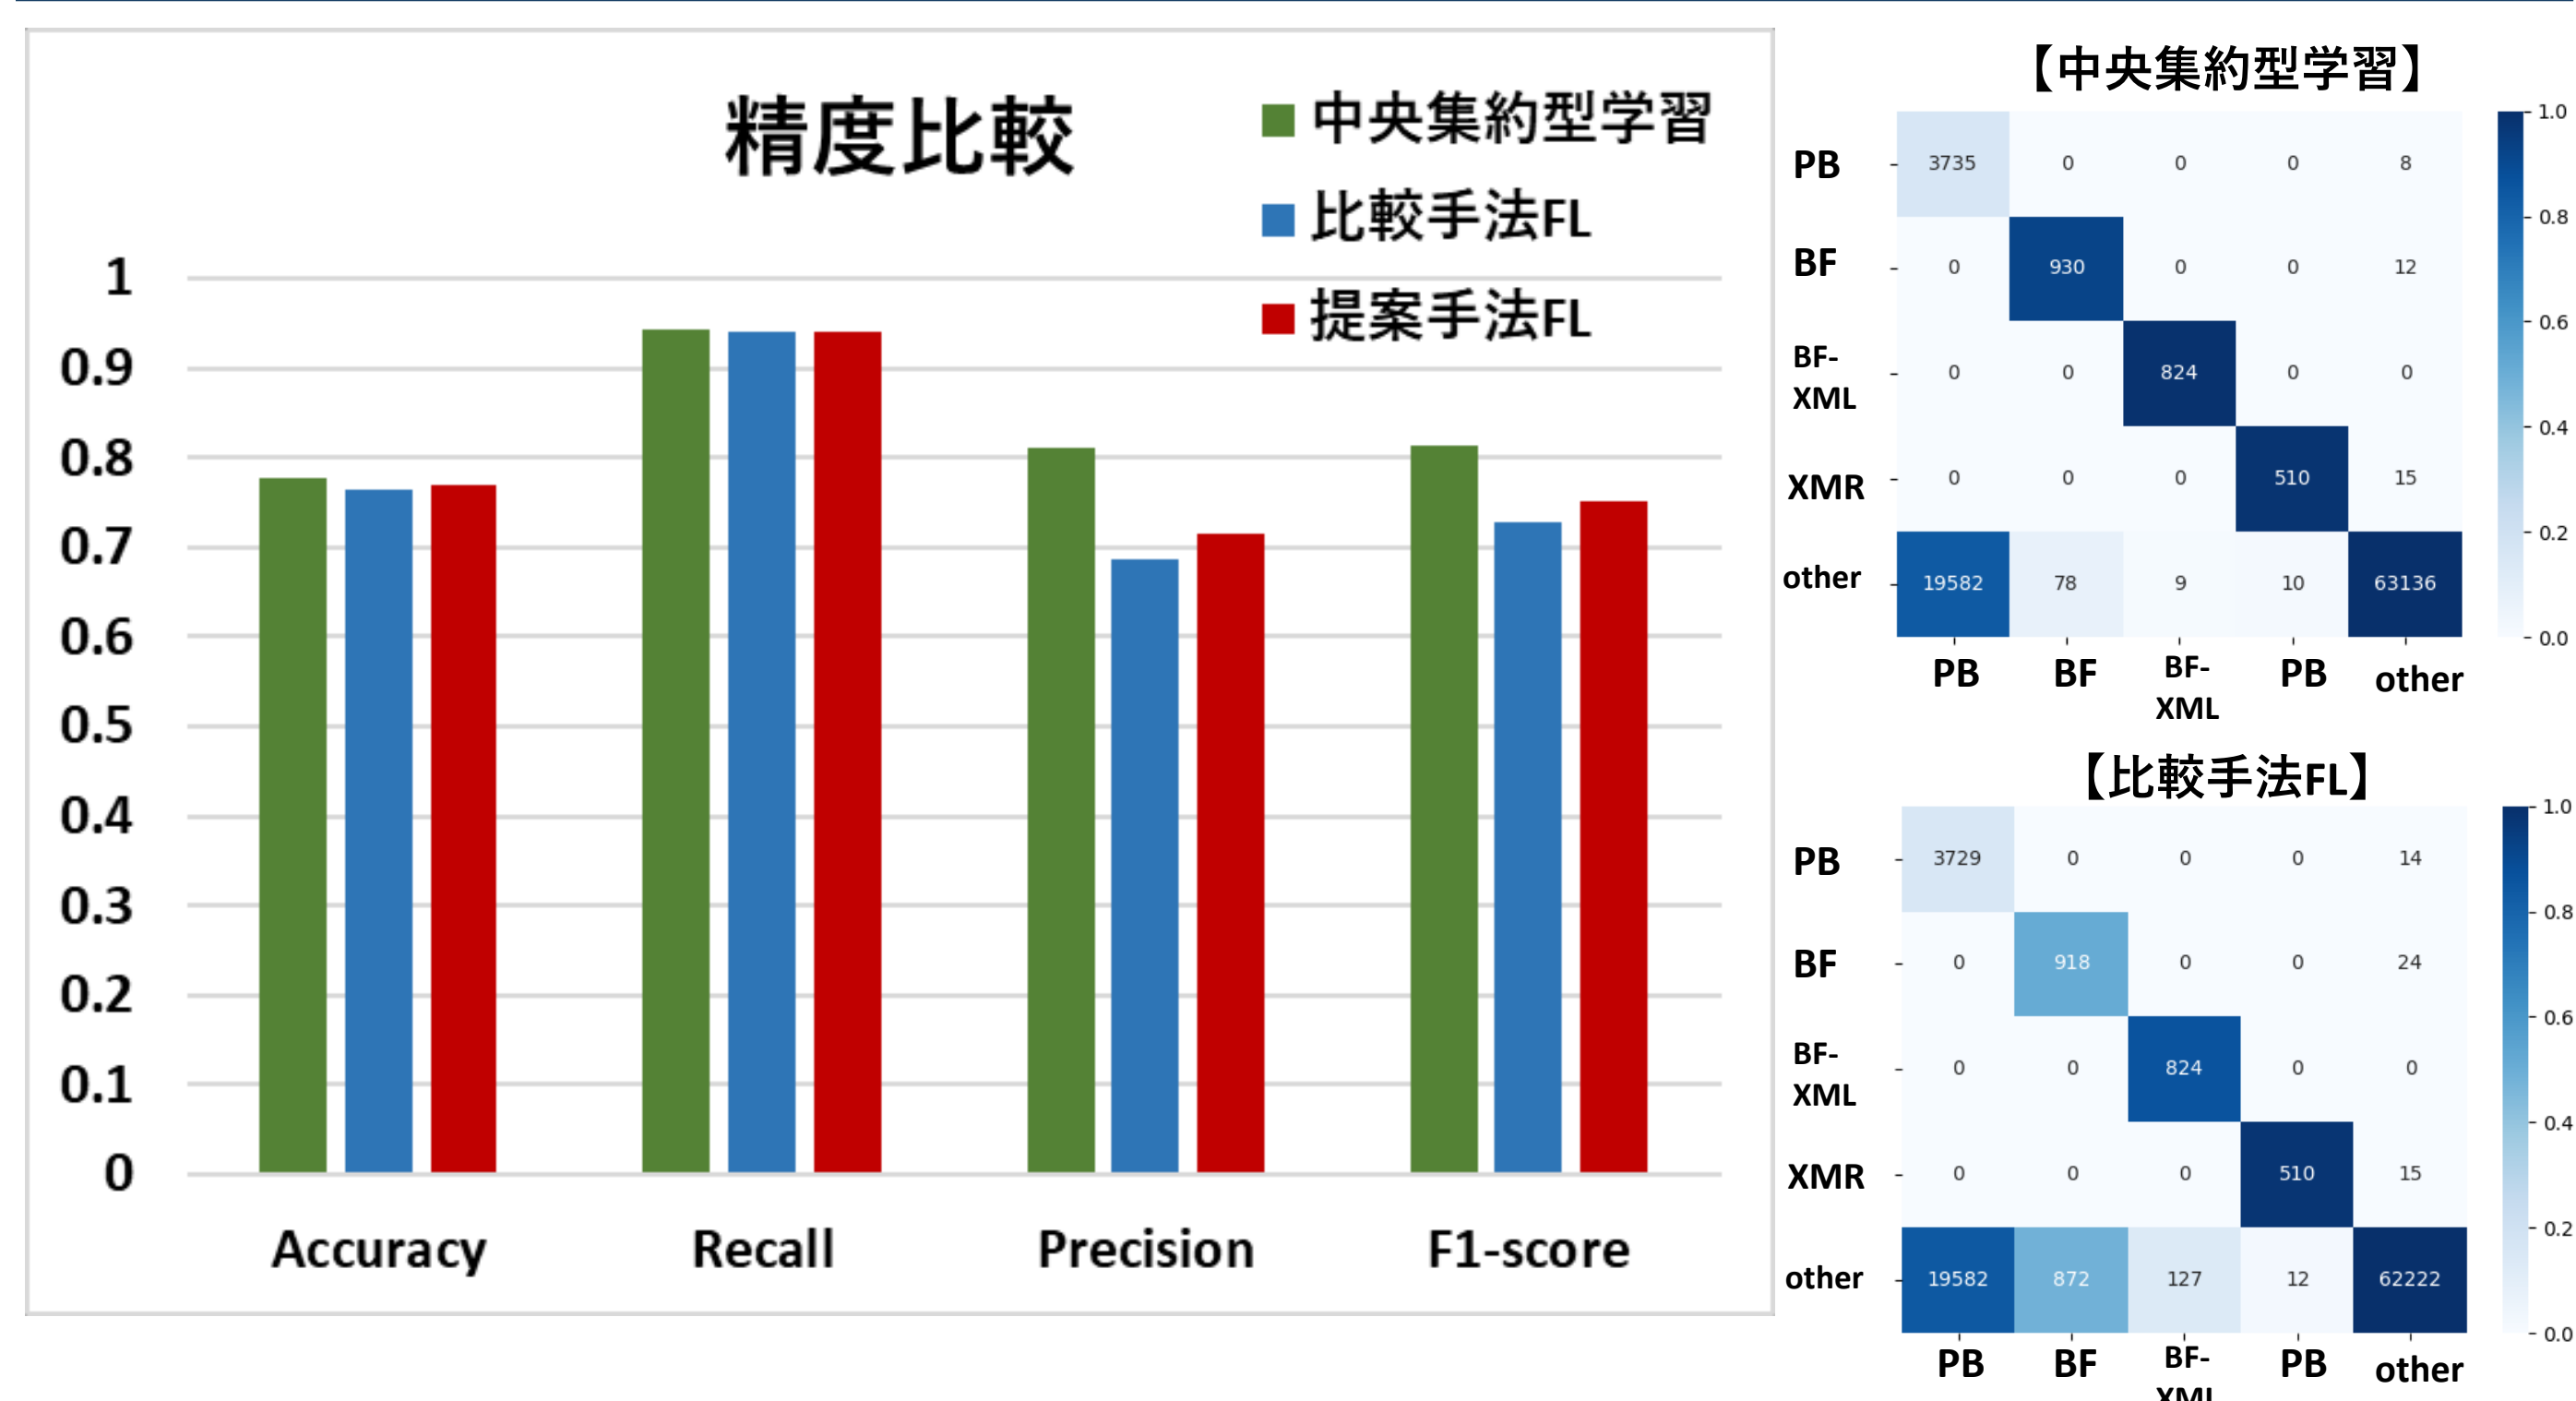


## 実験設定

- **提案手法FL**
  - 攻撃データ共有
  - SMOTE : 3.5
- **比較手法FL**
  - 各クライアント内で
  - 攻撃データを10倍に複製
- **中央集約型学習**
  - 連合学習なし
  - ローカル環境で実施
  - 攻撃データの10倍複製

連合学習	
FLフレームワーク	Flower[3]
集約アルゴリズム	Federated Averaging
クライアント数	10
連合学習ラウンド数	60
クライアントモデル	
機械学習ライブラリ	TensorFlow
モデル	Multi-layer-Perceptron
ニューロン数	[128, 64, 5]
活性化関数	隠れ層 : relu, 出力層 : softmax
バッチサイズ	32
最適化アルゴリズム	Adam
学習率	0.00001
早期終了	patience : 10, min_delta : 0.001
データセット	
データセット	HIKARI-2021[4]
ラベル	Traffic_category
使用特徴量数	81 (数値型のみ)

## 評価



- RecallはFLと中央集約型学習で同程度
- **Precision, F1-scoreが約3%向上**
- 正常データ (other) をBruteforceと誤検知する件数が減少
- Probingは正常通信と特徴が似ており判別が難しい
- 中央集約型学習では正常データの誤検知率がさらに低い
- 攻撃データ共有やSMOTEにより**データのバリエーション増加**
  - ▶ モデルの精度向上

## 今後の展望

- 複数ノードを用いて分散実証実験の実施
- 特定クライアントの処理が遅いケースの実験
- クライアント数変動の影響調査

### 参考文献

- [1] A. Okada et al.: An Accuracy Improvement Method by Sharing Attack Data in Federated Learning-Based NIDS, *Proc. ICMU 2025*, pp. 138–143 (2025).
- [2] N. V. Chawla et al.: SMOTE: Synthetic Minority Over Sampling Technique, *Journal of Artificial Intelligence Research*, Vol. 16, pp. 321–357 (2002).
- [3] D. J. Beuteletal: Flower: A friendly Federated Learning Research Framework, *arXiv:2007.14390*, pp. 1–22 (2020).
- [4] A. Ferriyan et al.: Generating Network Intrusion Detection Dataset Based on Real and Encrypted Synthetic Attack Traffic, *Applied Sciences*, Vol. 11, No. 7868, pp. 1–17 (2021).