

固定型Wi-Fi APと可搬型Wi-Fi APを用いた 時空間通信需要推定方式の提案と評価

- 情報ネットワーク研究会 (IN) 2026.3.5

大阪大学 坂口 来実, 大平 健司, 大下 裕一, 下西 英之



Shimonishi Lab
The University of Osaka

省資源で効率よく通信需要を満たすネットワークの最適化

- キャンパス面積167万平方メートルに対してODINS Wi-Fi APは約1,100台
→ すべての需要をカバーしきれていない
- 限られたAP数でカバレッジを最大化するためには
「**キャンパス全体の通信需要**」を把握することが重要
- **需要把握の障壁**：
 - ✓ 既存の固定型APは屋内設置のみ
→ **屋外やイベント時の高需要エリアの実態は把握不可能**
 - ✓ 通信需要が時間帯・場所・イベントに応じて**動的に変動**
→ 統計指標ではボトルネックを把握できない

可搬型APを用いた通信需要計測 と その限界

- 屋外に**可搬型AP**を一時的に設置することで、
これまでブラックボックスだった**屋外の通信実態を観測可能**
- しかし、可搬型APの台数や稼働時間には限りがあり、
全地点・全時間帯を同時に観測することはできない (**観測の限界**)
- さらに、可搬型APのデータは、設置期間外が「欠測 (GAP)」となり、
連続的な需要把握が困難 (**データの断片化**)

非観測時間帯・未設置地点における通信需要推定（GAP補完）

- **通信傾向の学習とGAP推定**

常時観測の固定型APのログと、スポット観測の可搬型APのログとの関係を学習し、非観測時間帯や未設置地点における通信需要（GAP）を推定する

- **通信需要の全体像把握とAP配置最適化**

屋外も含めたキャンパス全体の通信需要を把握し、
現状カバーできていない潜在的な通信需要を可視化する → AP配置の見直し

固定型・可搬型APログの統合による時空間通信需要推定モデル

固定型AP：屋内 493台

常時観測

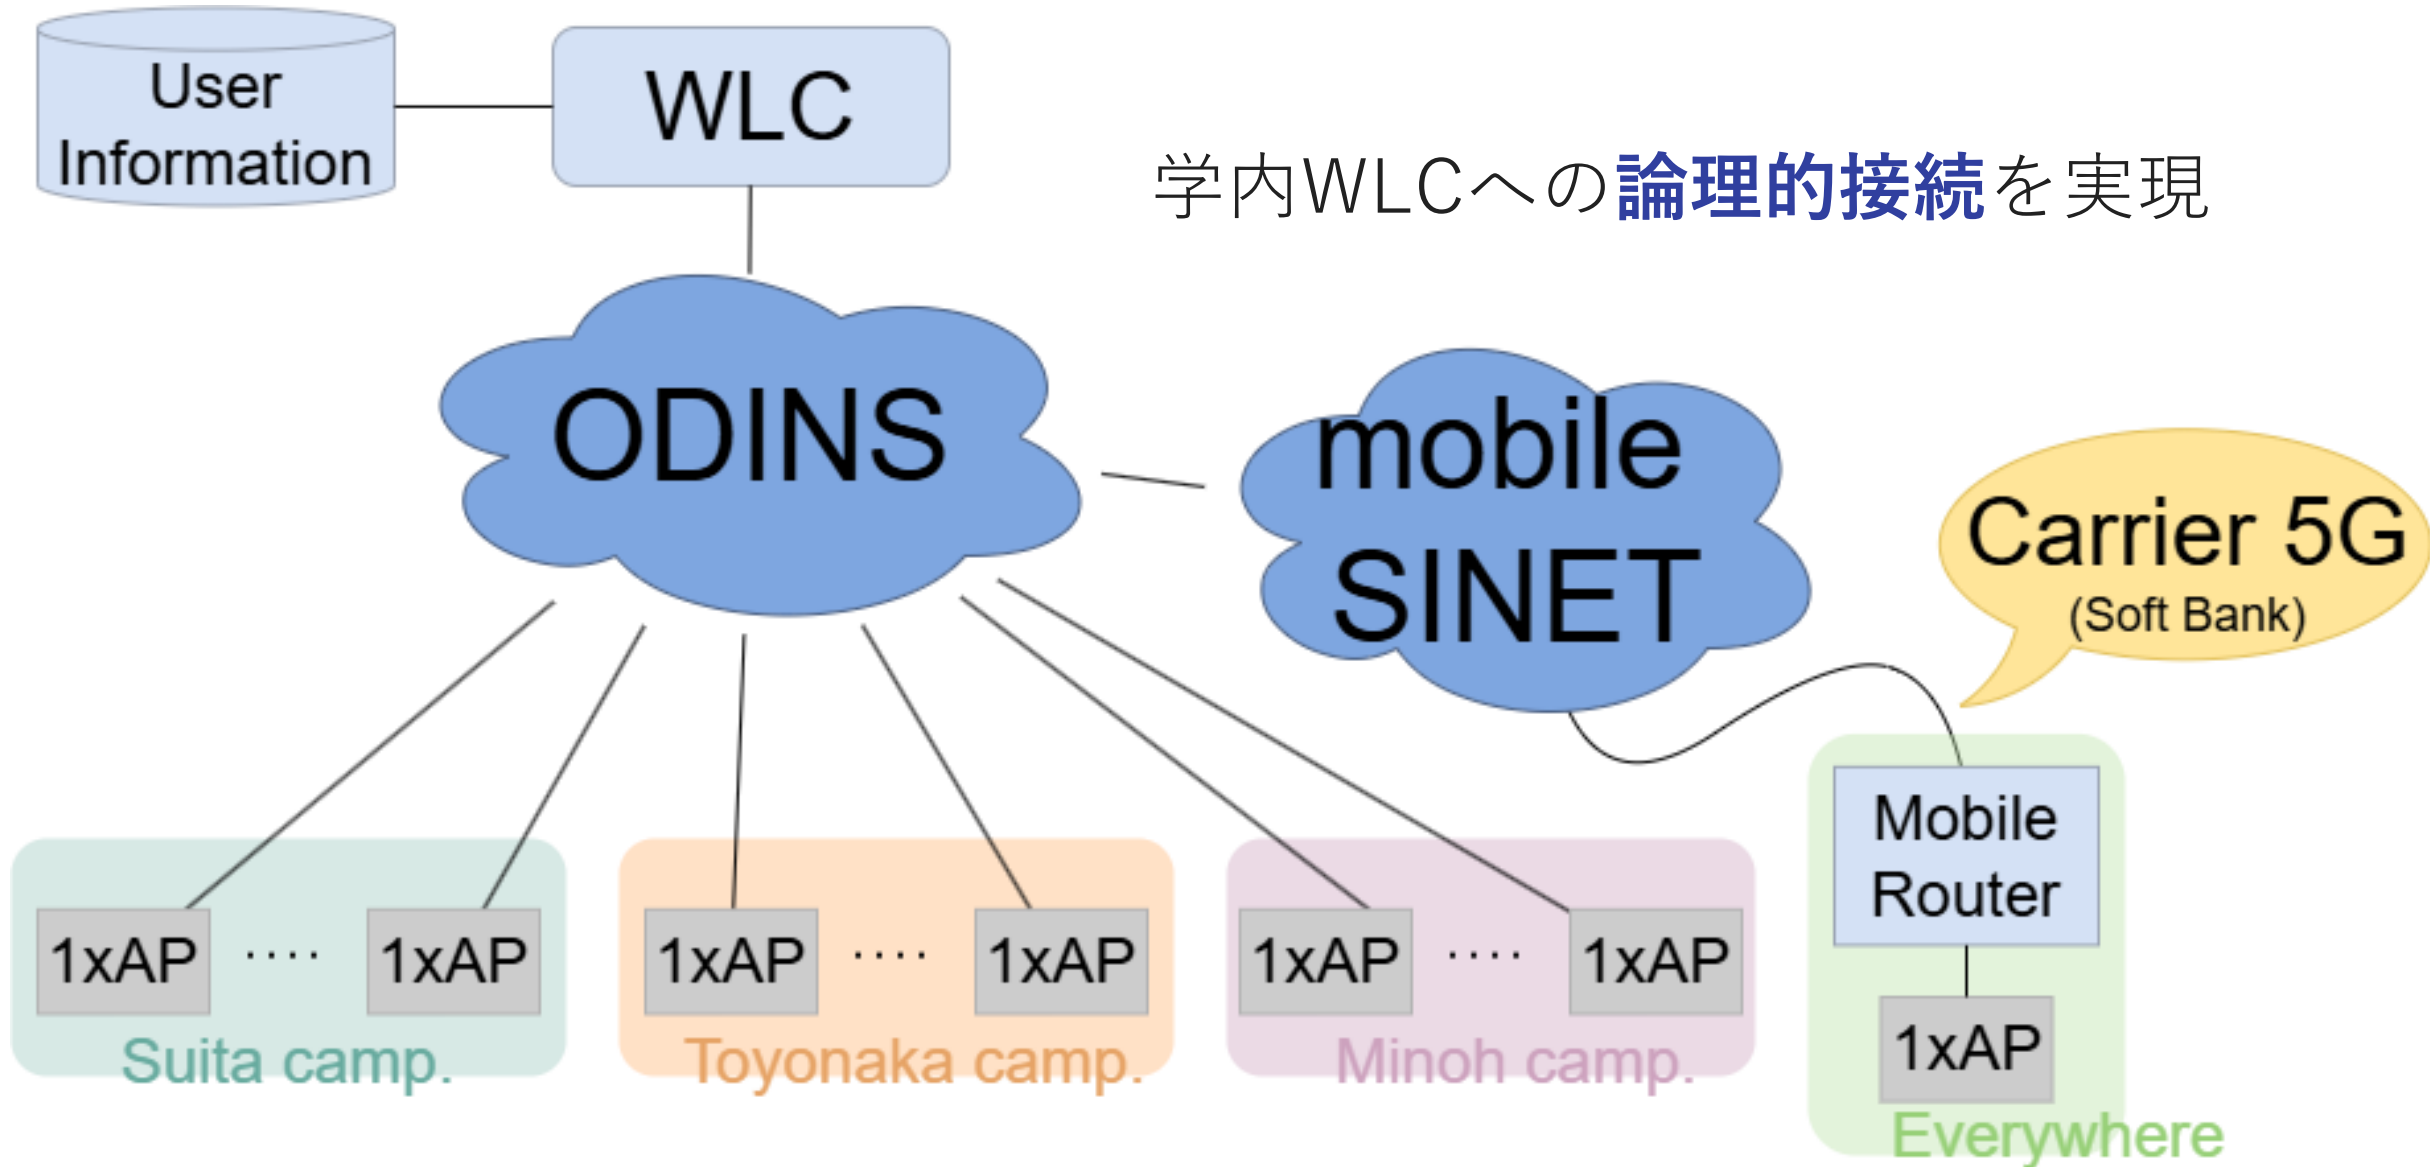


可搬型AP：2台

スポット観測



豊中キャンパス
図書館前バス停



アプローチ

固定型APログ：多地点/24時間の通信傾向

↓ ↑ 相関関係を学習

蓄積

可搬型APログ：「地点固有の通信パターン」

局所的・断片的
GAPを含む

時空間特徴



通信データ

固定型・可搬型APログ：当日の「混雑トレンド」

未観測時間/地点：接続数・通信量

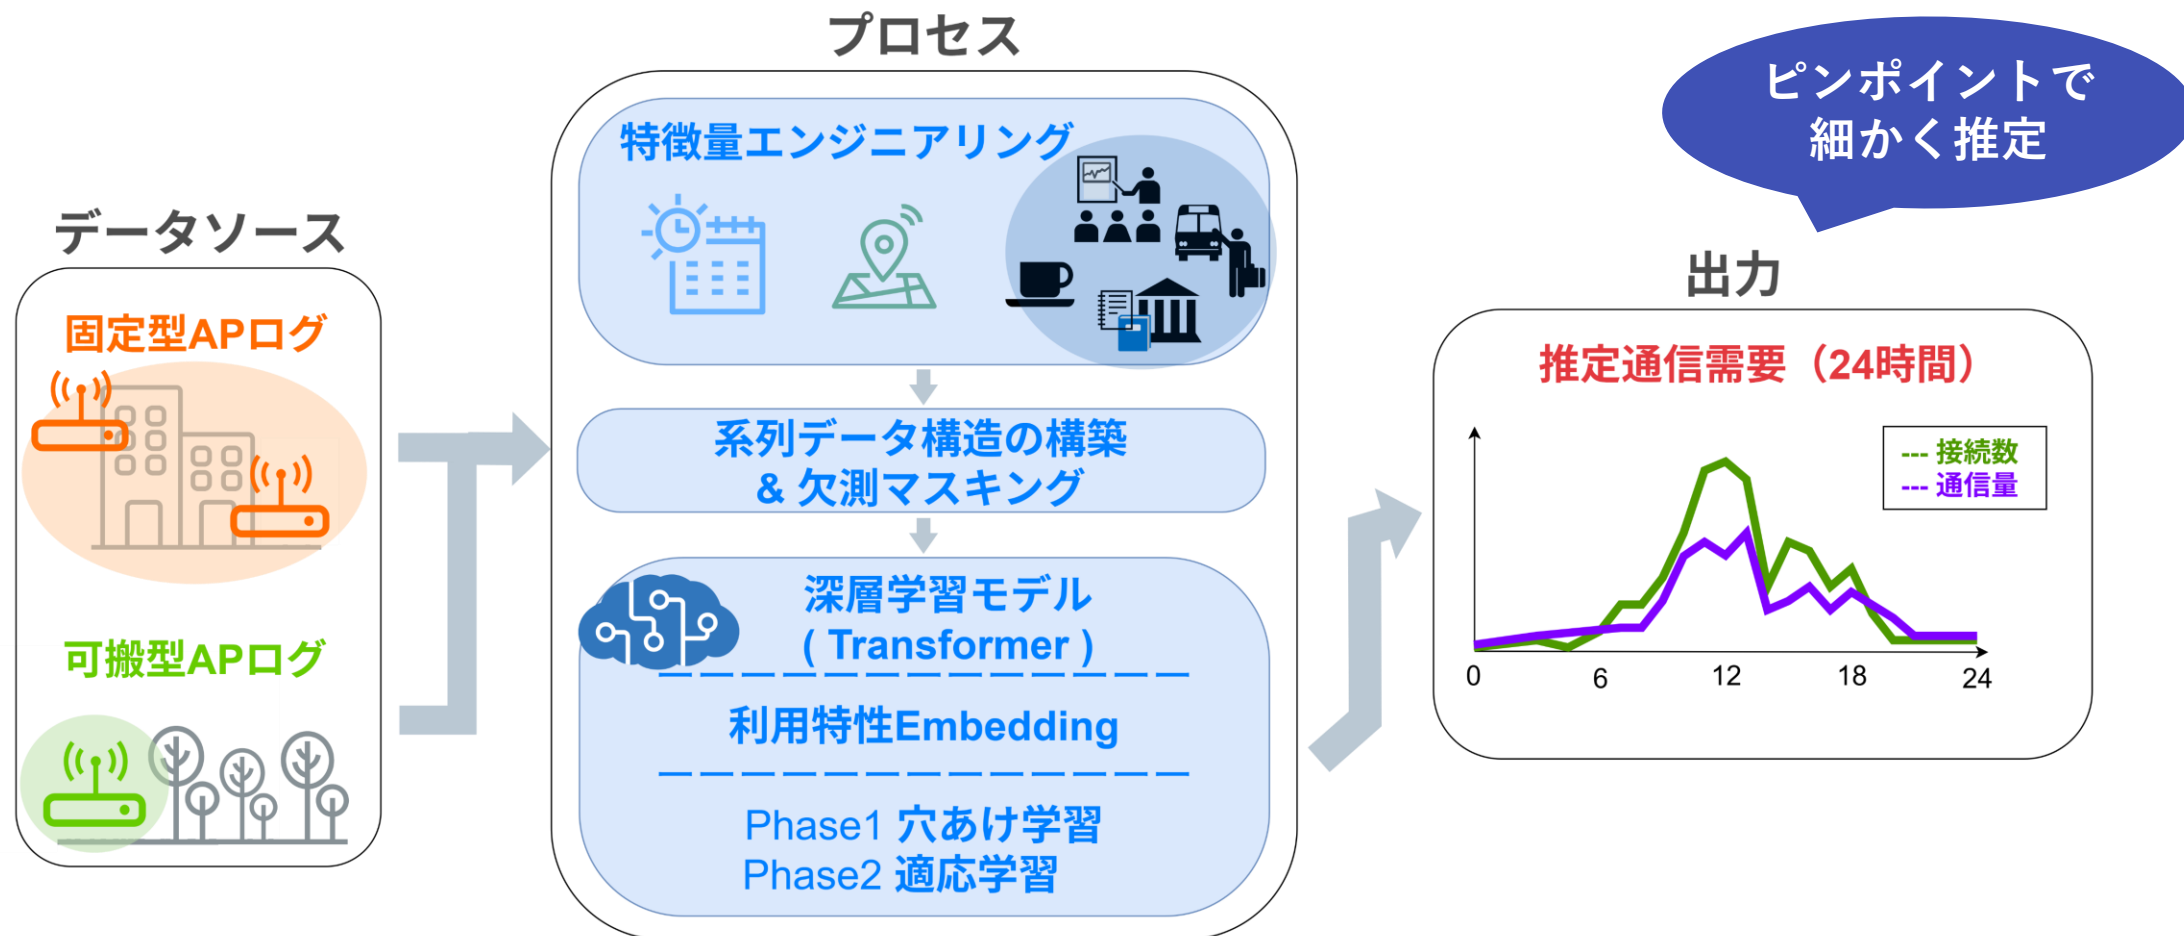
推定

対象日



キーポイント

1. 利用特性を含んだ特徴量エンジニアリング
2. 穴開け学習と適応学習による2段階学習



1. 特徴量エンジニアリング

時間的特徴



- ✓ 時刻 (2次元) : sin/cos
- ✓ 曜日 (7次元) : One-hot
- ✓ 相対日程 (1次元)

空間的特徴



- ✓ 座標 (2次元) : 50m単位
- ✓ 屋内/外 (1次元)

- ✓ 立地ID (1次元)

1日24ステップに集約
GAPは0埋め & mask=0


深層学習モデル

Embedding層

8~16次元
ベクトル

利用特性の類似する
ものが、近い値

出力指標



- ✓ 接続数 (2次元)
 - 平均
 - 最大
- ✓ 通信量 (2次元)
 - 平均
 - 最大

2. GAP補完・当日コンテキスト適応

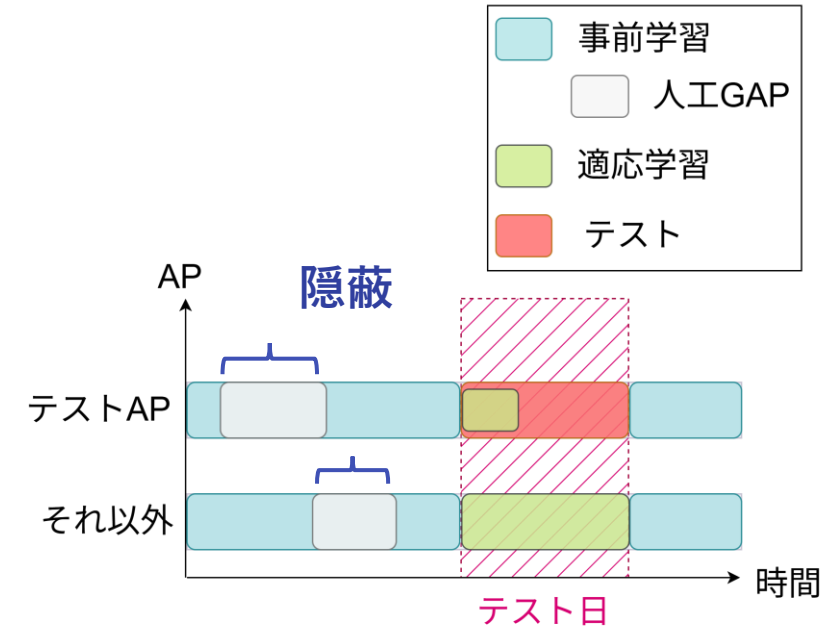
穴あけ学習（ランダムマスキング）

1. 実際のGAPに加え，連続する時間ブロックを意図的に隠ぺいする
2. その区間を周囲のデータから推定させるタスクをモデルに課す

→ 他地点のトレンドや地点固有の周期性から**GAPを補完する能力**を強制的に獲得

テストAP自身のログ数時間分を活用した2段階学習

1. 事前学習：テスト日以外のデータで一般的な知識を習得（穴あけ学習）
2. 適応学習（Fine-tuning）：テスト日当日のデータで微調整



学習時のLossは**Masked MSE**で計算

$$\text{Loss} = \frac{\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 (\hat{y}_{i,t,k} - y_{i,t,k})^2 \times m_{i,t}}{\max(\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 m_{i,t}, 1)}$$

大きな誤差を厳しく評価し、
外れ値の発生を抑制
→モデルの**推定精度が安定**

★" **Self-Attention** 機構を持つ **Transformer** が高相性

《対象データ》

大阪大学豊中キャンパスに設置されているODINS Wi-Fi APログ（5分間隔で記録）

- **期間**：2025年10月1日～2026年1月31日
- **固定AP（豊中キャンパス）**：493台（常時観測）
- **可搬型AP**：2台（部分観測、バッテリー持ち約11～12時間）

《推定対象》

- **テスト日**：2026年1月30日（金曜日）
- **テストAP**：s-ap-254-002（バス停前に設置された可搬型AP）

《実験準備》

- **データベース構築**：膨大なAPログをAP属性とともに保管・管理

比較実験

1. **固定型APのみ**：固定型APログのみを用いた1段階学習

2. **可搬型AP併用 (Fine-tuningなし)**：

固定型・**可搬型AP**ログを統合した1段階学習

3. **可搬型AP併用**：

テストAP自身のログ数時間分を用いた**2段階学習**


評価指標

- Masked MAE =
$$\frac{\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 |\hat{y}_{i,t,k} - y_{i,t,k}| \times m_{i,t}}{\max(\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 m_{i,t}, 1)}$$

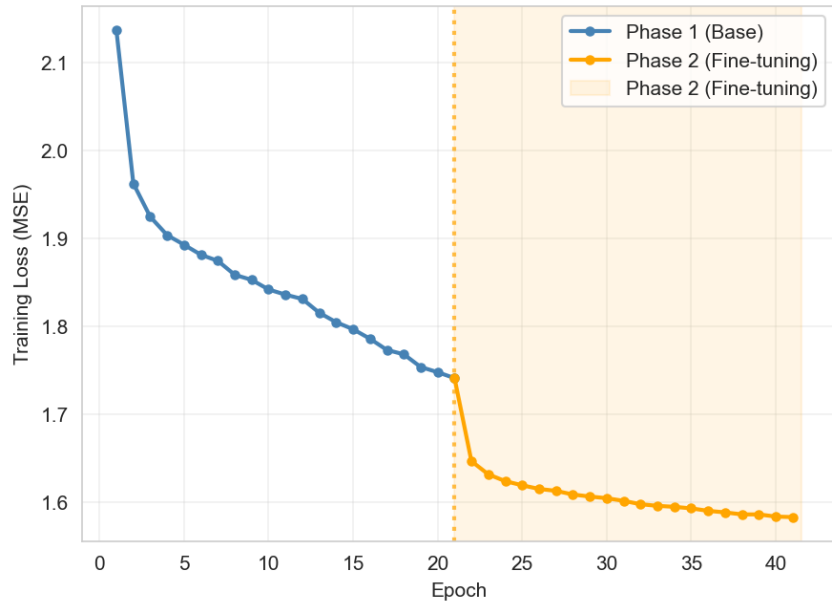
平均的な
ずれ

- Masked RMSE =
$$\sqrt{\frac{\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 (\hat{y}_{i,t,k} - y_{i,t,k})^2 \times m_{i,t}}{\max(\sum_{i=0}^{N-1} \sum_{t=0}^{23} \sum_{k=0}^3 m_{i,t}, 1)}}$$

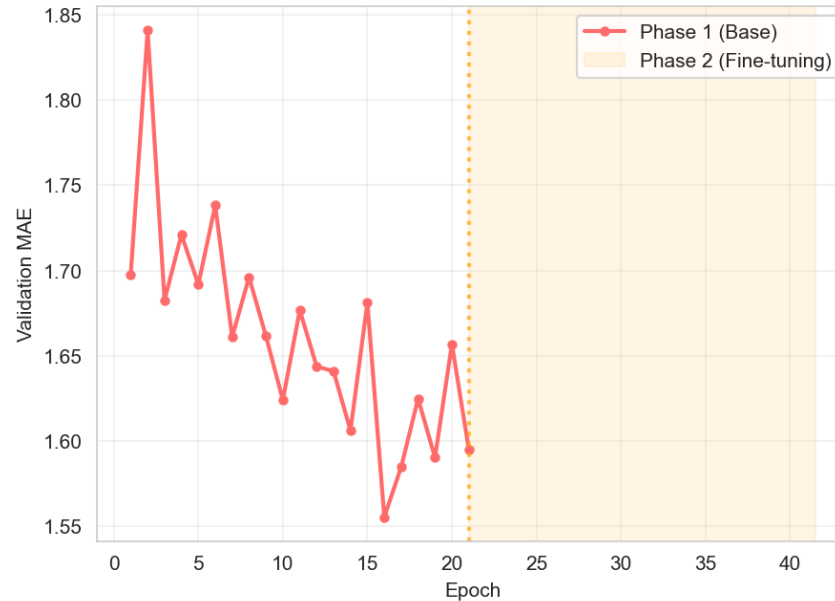
大きなミス



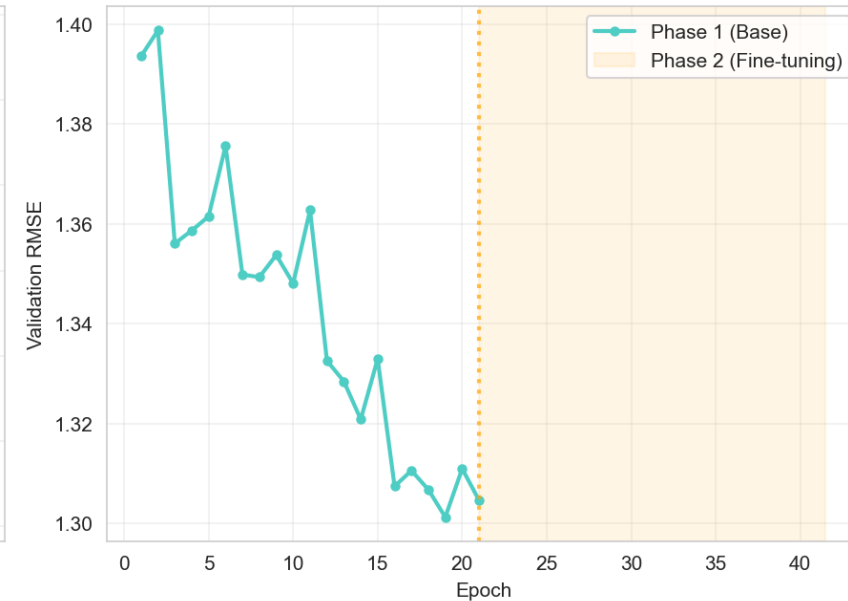
Training Loss



Validation MAE



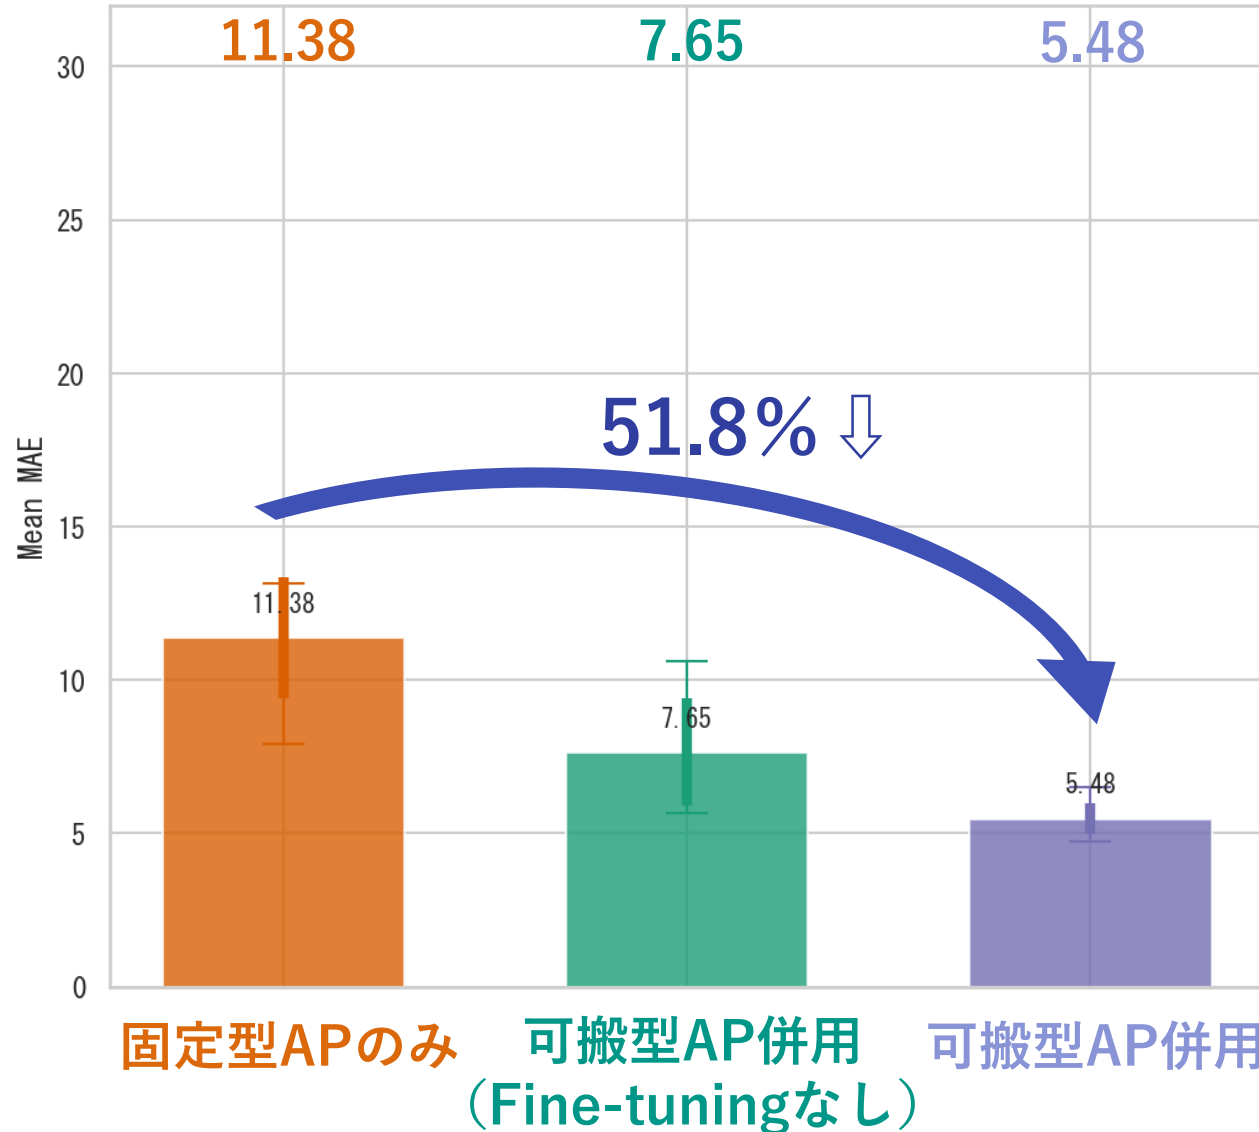
Validation RMSE




Fine-tuningの開始で
Training Lossが不連続
かつ大幅に減少

Fine-tuning
が機能している
ことを確認

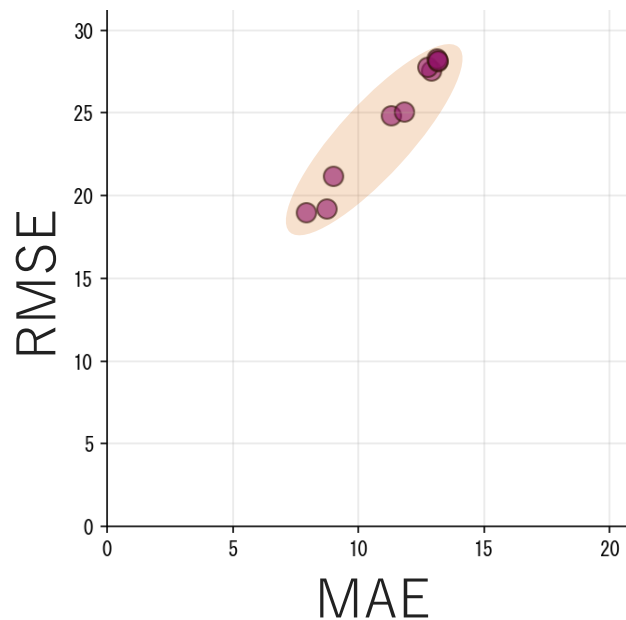
MAE




RMSE




固定型APのみ



可搬型AP併用（Fine-tuningなし）



可搬型AP併用




		固定型APのみ	可搬型AP併用 (Fine-tuningなし)	可搬型AP併用
MAE	平均値	11.38	7.65	5.48
	標準偏差	1.96	1.74	>> 0.51
RMSE	平均値	24.92	18.39	13.16
	標準偏差	3.59	3.37	>> 1.32


- Ground truth
- ★ Observed
- estimated

固定型APのみ


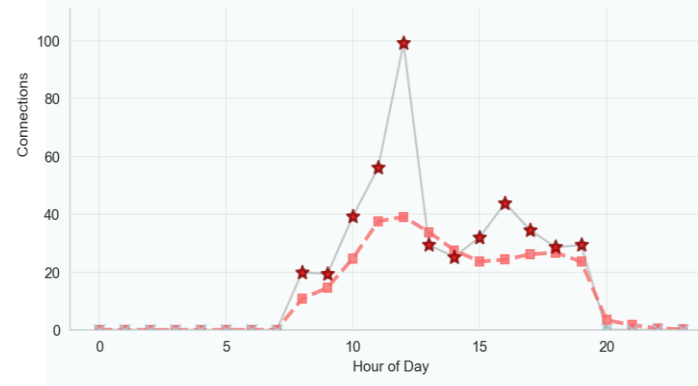
接続数
(台)




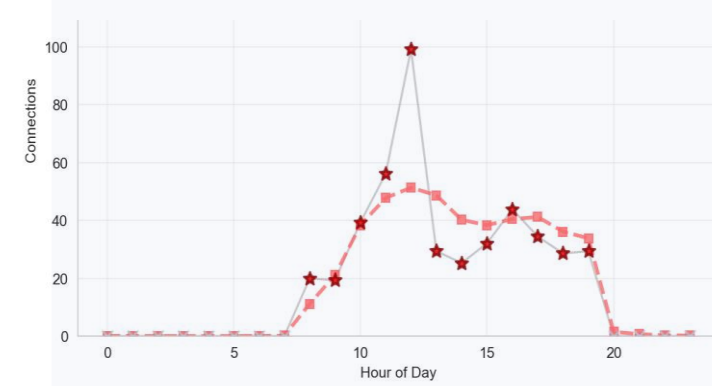
通信量
(Mbps)



可搬型AP併用 (Fine-tuningなし)



可搬型AP併用



固定型APと可搬型APの統合データを用いた時空間通信需要推定

固定型APログのみから学習する手法と比較して、提案方式では**MAEを51.8%、RMSEを47.2%**削減し、大幅な**高精度化**と高い**安定性**を達成した。



可搬型APの活用が屋外環境での**安定した推定精度向上**に直結することが実証され、その有効性は確かであり、**既存のAP配置では捉えきれなかった通信需要を高精度に推定することができた。**

一方で、実用的なキャンパス全体の需要把握には、時系列グラフに見られる**ピーク時の過小評価の改善**等、依然として課題が残される。

- **ピーク値誤差の改善**
- **通信需要の変動をより細かく推定（ログの集約単位を詳細化）**
- **環境要因も踏まえた通信需要推定**

授業時間・学内連絡バスの運行スケジュール・天気・イベントなどの環境要因を通信需要と関連付けてモデル学習させることで、推定の精度を上げる。

- **最適な観測地点を動的に決定する能動学習の導入**

ガウス過程回帰（GPR）等を用いてキャンパス全域の推定の不確かさを可視化し、次なる可搬型APの移動先を自動提示するデータ駆動型の観測戦略を確立する。

- **次期ODINS設計への提言**