

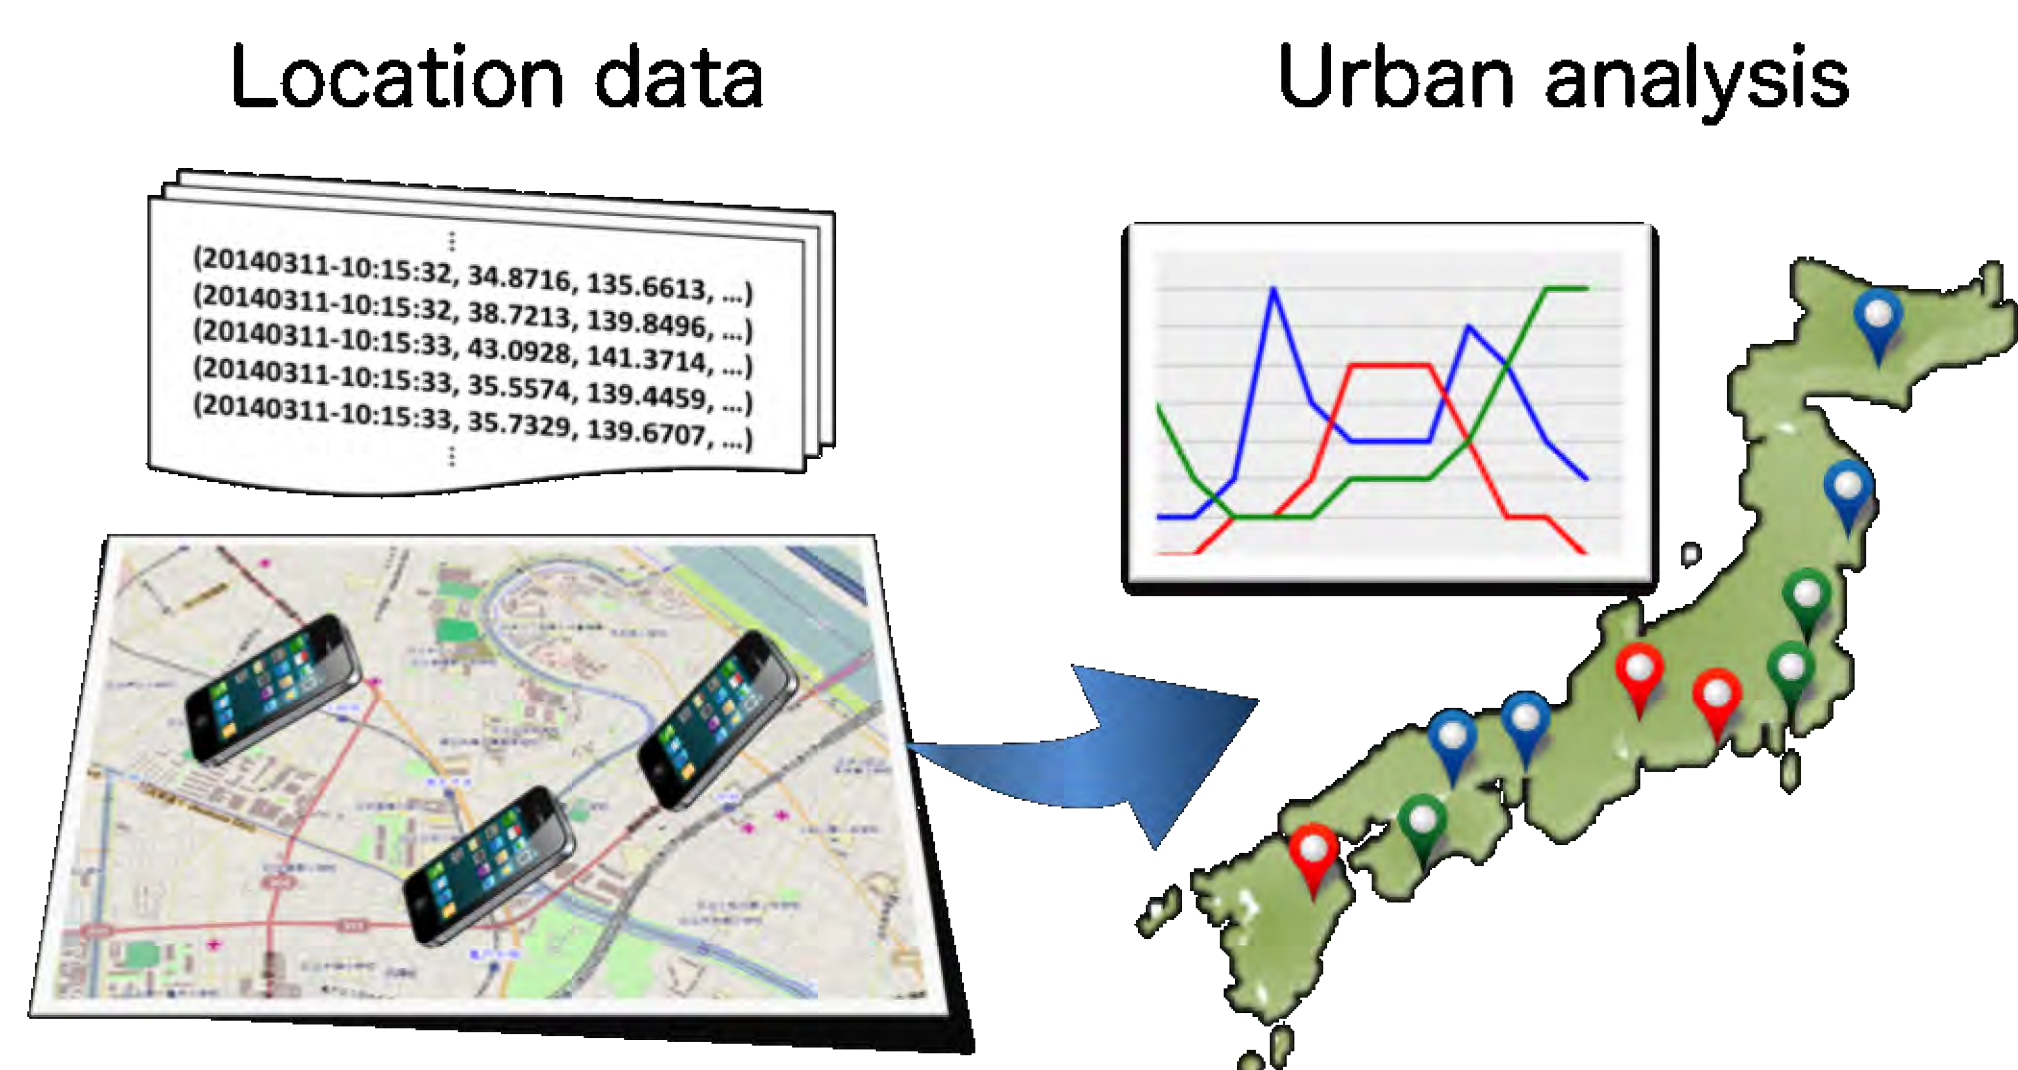
下坂研究室で扱う 研究領域

- IoT : Internet of Things
ユビキタスコンピューティング / パーベイシブコンピューティング
- Big Data
機械学習・パターン認識・データマイニング

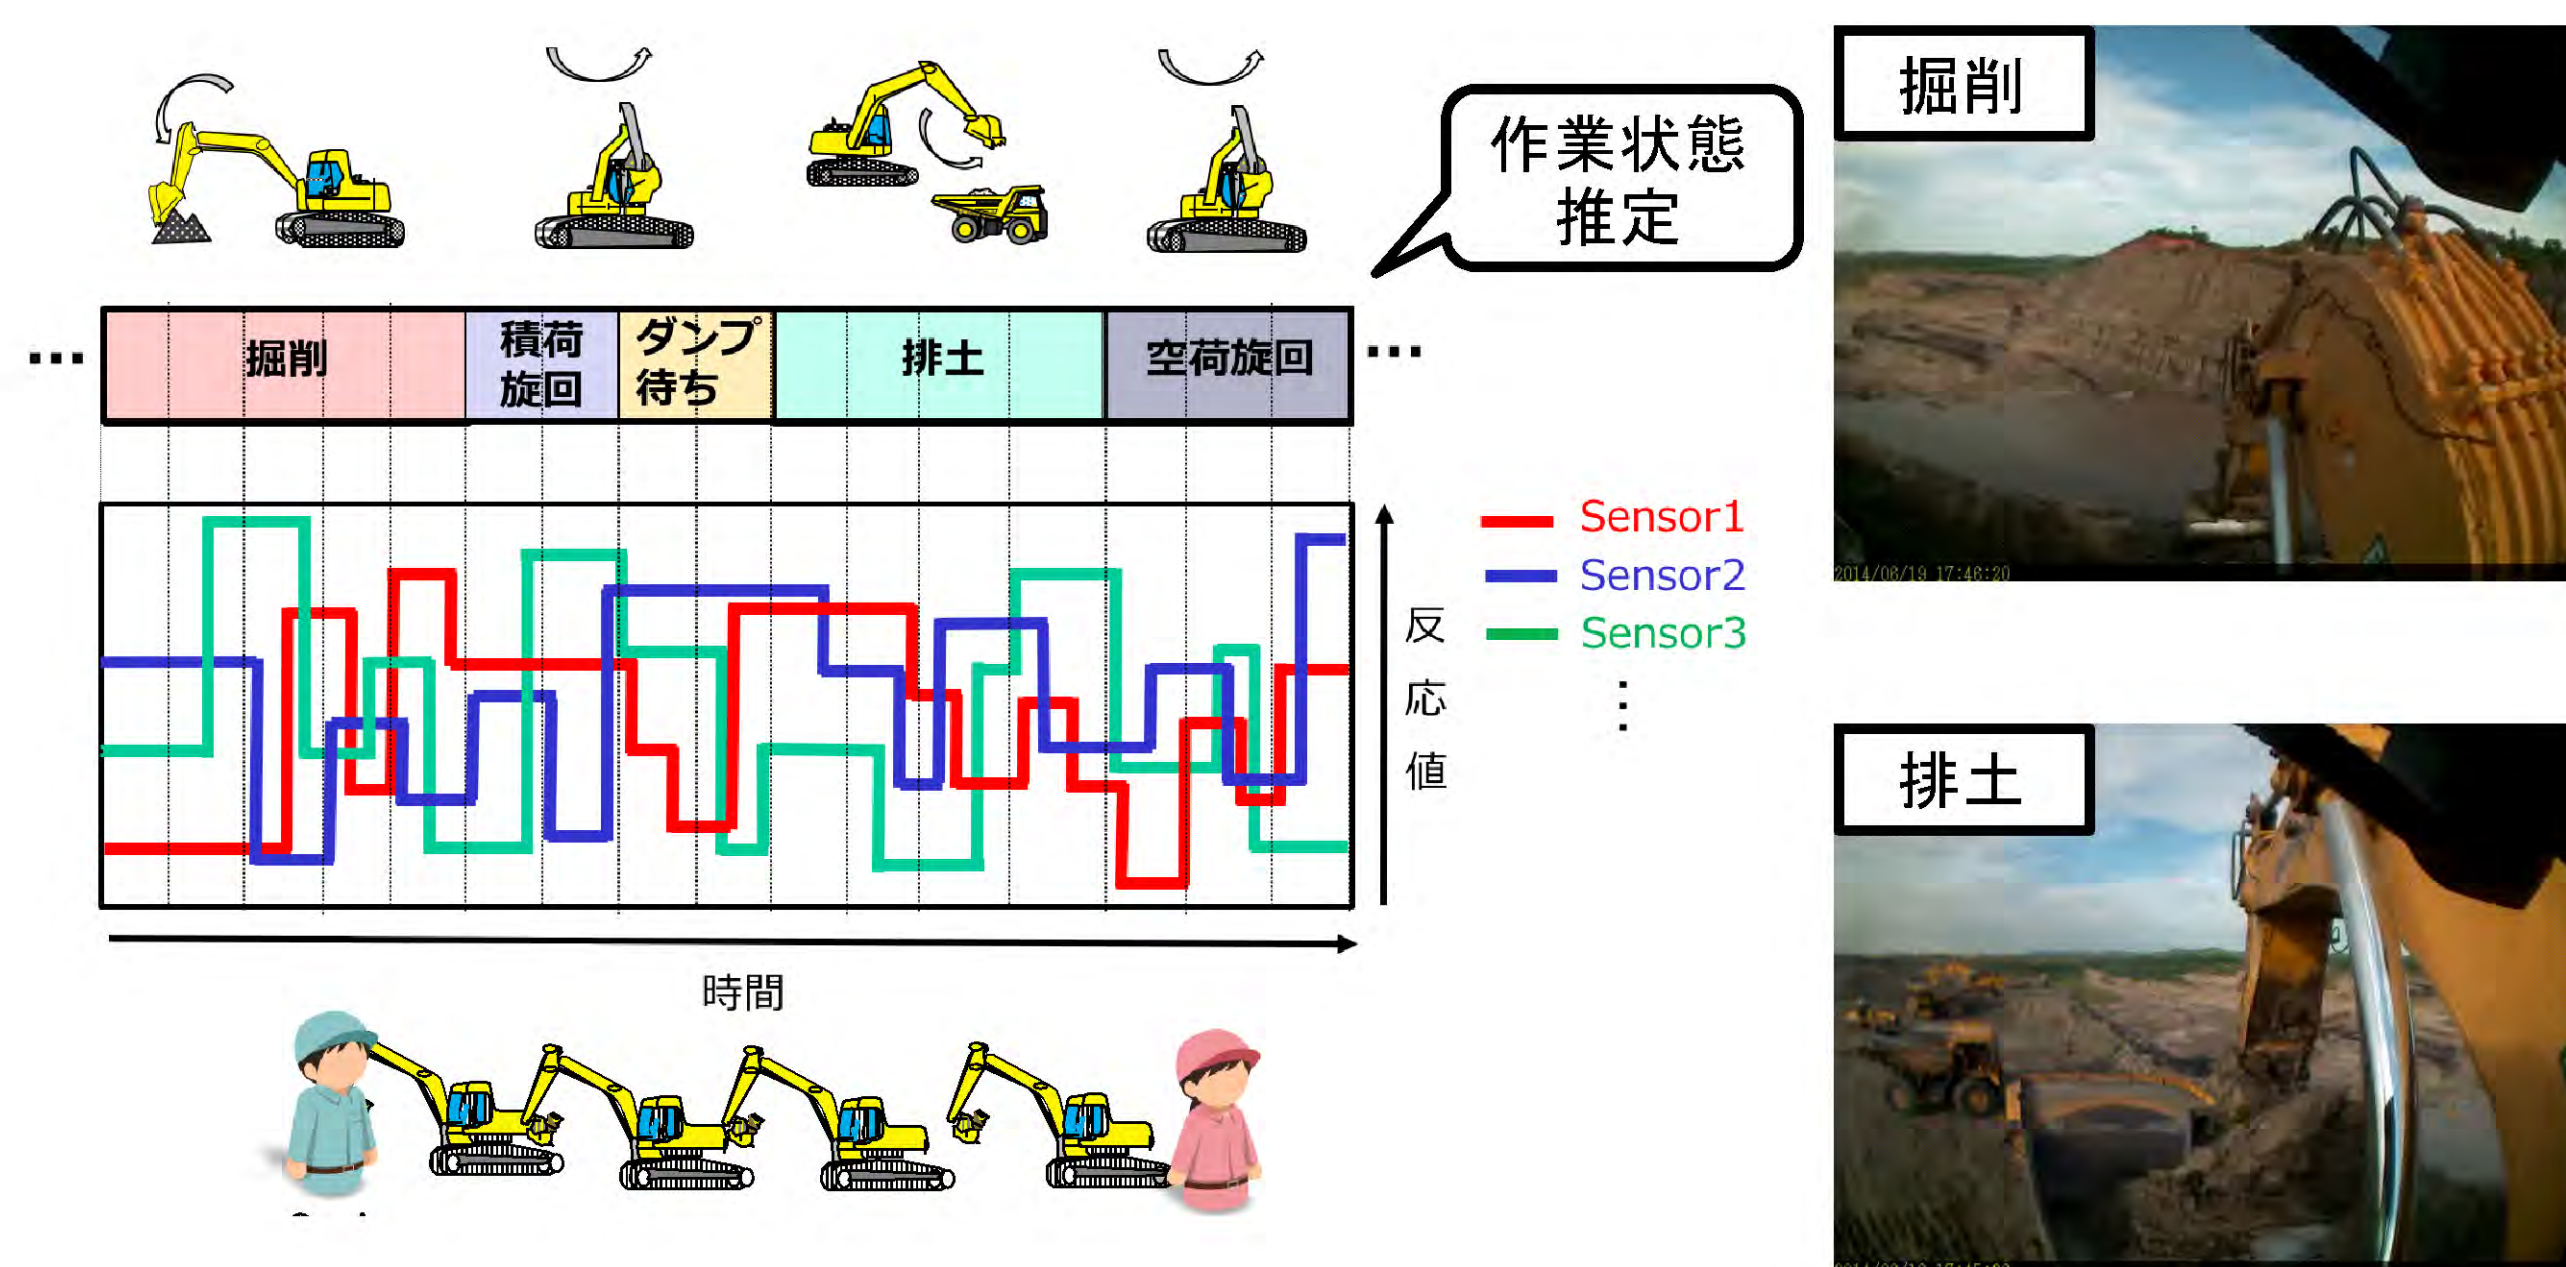
→スマホなどにより得られる, 人の行動に関連した (比較的) 新種のデータに対する統計的解析手法を研究しています.

下坂研究室 テーマの例


スマホ位置履歴データ
からの都市動態解析



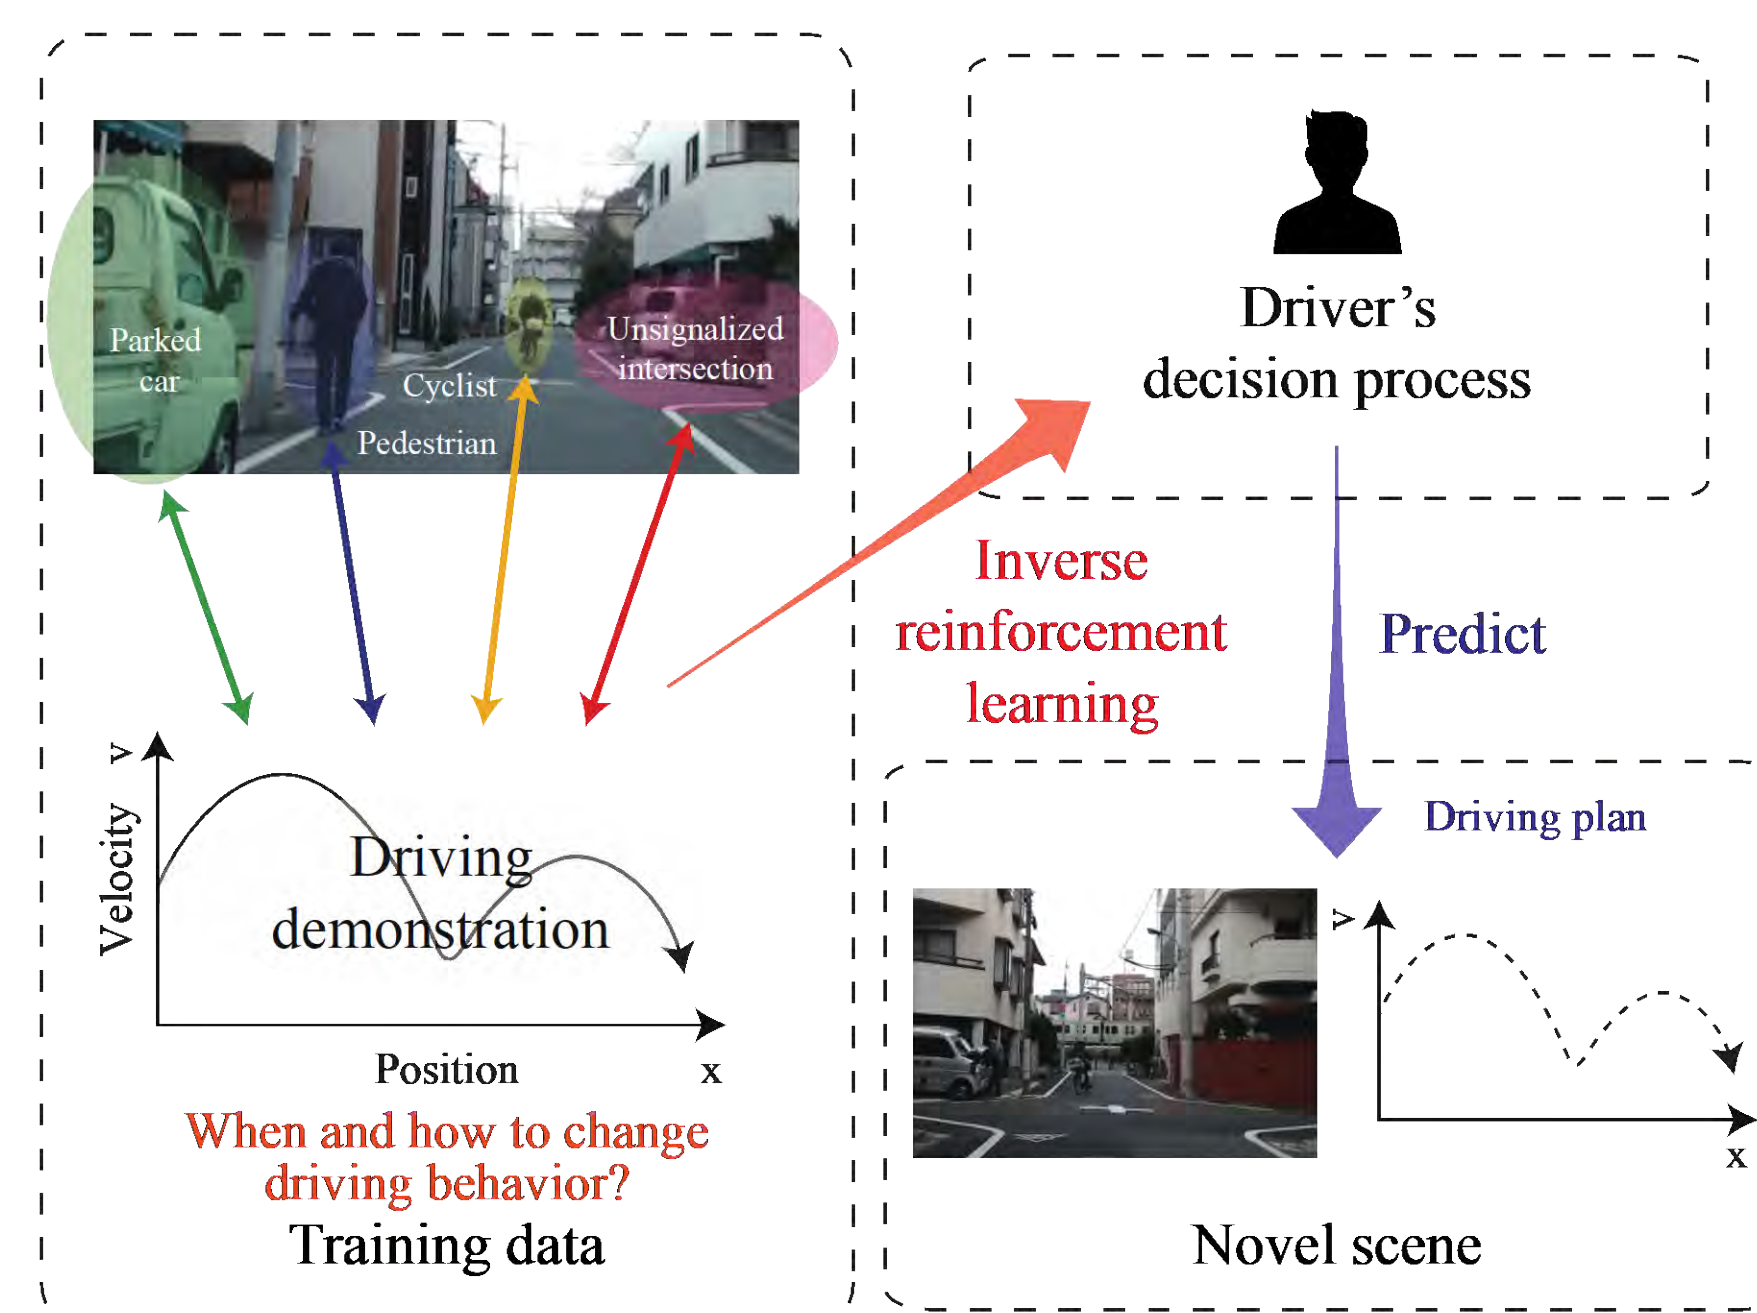
IoTセンサの時系列データを用いた作業状態推定に関する研究



ウェアラブルセンサに基づく
交流関係分析



模倣学習による運転行動モデリング



下坂正倫 2006年 東京大学 大学院情報理工学系研究科博士課程修了。2015年7月から東京工業大学 准教授。解析対象にある, 人の行動それ自体がもつ面白さ, データ解析の理論的な奥深さ, ユビキタスコンピューティングの社会的応用の難しさ, を感じながら熱意を持って楽しく研究してもらえたらと思っています。新しい研究領域を一緒に作っていきましょう。

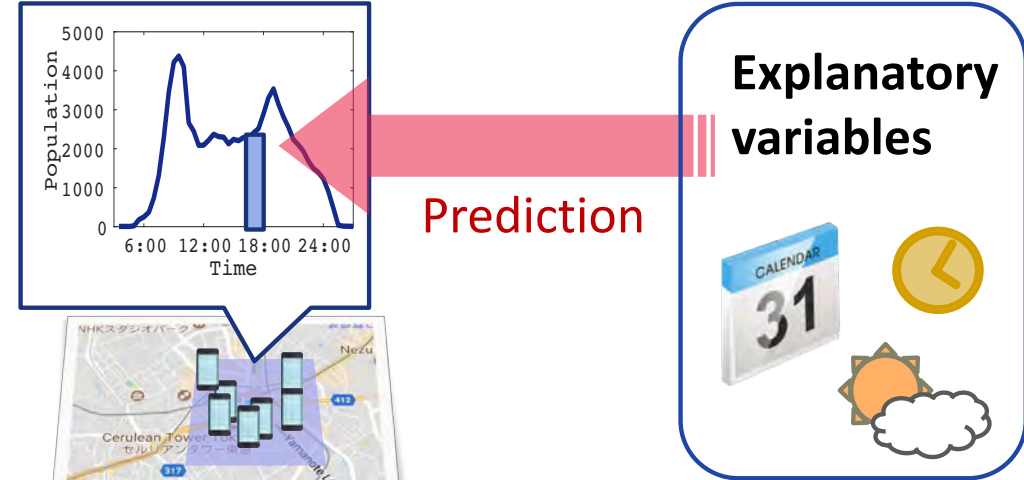
下坂研究室 研究事例(詳細)

Spatially Preservable Factored Poisson Regression for Large-Scale Fine-Grained GPS-based Population Analysis

Masamichi Shimosaka*, Yuta Hayakawa*, Kota Tsubouchi**
* Tokyo Institute of Technology, ** Yahoo! JAPAN Research

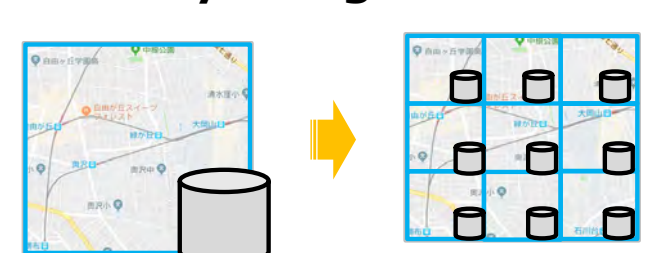
Active population prediction using GPS info.

- The spread of smartphone → Analyses of population from GPS logs of smartphone has been explored
- Population prediction from GPS logs count and explanatory variables are actively explored [1][2]



Fine-grained prediction and limitation of conventional approach

- The demands of urban dynamics analyses of street-level or small town-level (e.g. 100 ~ 200m meshes)
- Conventional approaches only use dataset only in each mesh [1] and provides prediction on 1km ~ 2km meshes [1][2]
- ⊗ Applying previous model [1][2] naively causes over-fitting issues by using small size of dataset

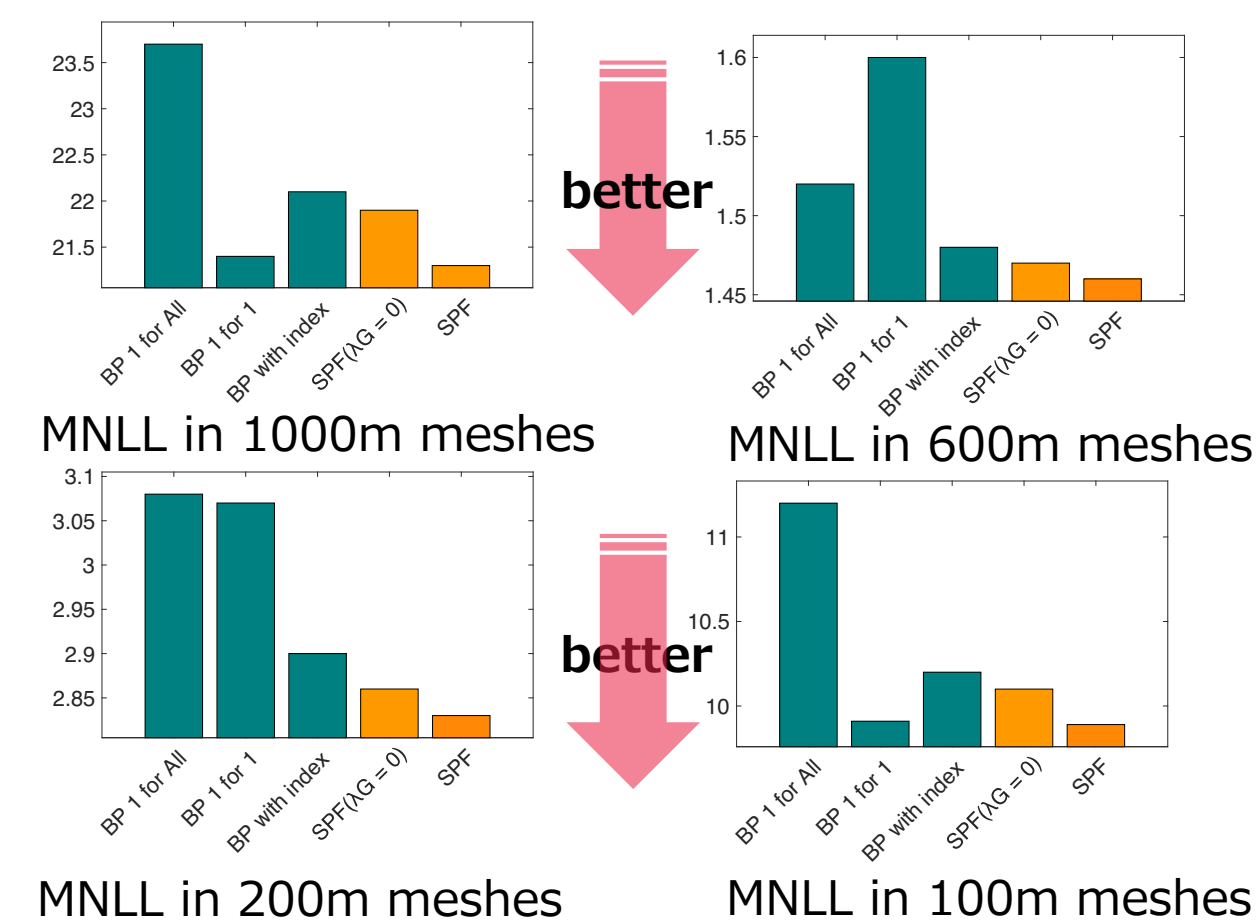


Sharing dataset between areas are needed

Experimental results

Evaluation on population prediction

- Dataset:
 - GPS log data from Yahoo! JAPAN disaster alert app
 - 365 days data and 32 M count logs 3km x 3km area in Tokyo
 - Area is divided into (100m, 200m 600m, 1000m meshes)
- External Features: day of the week, weather, holiday
- Metric: MNLL (Mean Negative Log Likelihood)



Reference

- [1] Shimosaka+, Forecasting Urban Dynamics with Mobility Logs by Bilinear Poisson Regression, UbiComp2015
[2] Zhang+, Deep spatio-temporal residual networks for citywide crowd flows prediction, AAAI2017.

Shimosaka Research Group pursuing MIUBIQ (machine intelligence in UbiComp Research) <http://www.miubiq.cs.titech.ac.jp> Tokyo Institute of Technology

Spatially Preservable Factored (SPF) Regression

Modeling with Bilinear Poisson regression [1]

$$y_{c,\tau}^{(d,l)} \sim \text{Poisson}(y_{c,\tau}^{(d,l)} | \lambda_{c,\tau}^{(d,l)})$$

$$\ln \lambda_{c,\tau}^{(d,l)} = \varphi(c)^T W^{(l)} \phi_\tau(\tau)$$

$y_{c,\tau}^{(d,l)}$: an active population in a mesh l in the l -th time segment in the d -th day
 $\lambda_{c,\tau}^{(d,l)}$: parameter of Poisson distribution $\phi_\tau(\tau)$: a time feature
 $\varphi(c)$: a weight matrix for mesh l
 $\varphi(c)$: an external feature

Pattern factorization via parameter space

- Represent a parameter as a weighted mean of parameter components
- Thanks to the factorization, dataset and parameters are shared between areas
- Reduce the parameter size and promotes stability in learning

$$W^{(l)} = \sum_{b=1}^B z_b^{(l)} Q_b \quad \sum_{b=1}^B z_b^{(l)} = 1, z_b^{(l)} \geq 0$$

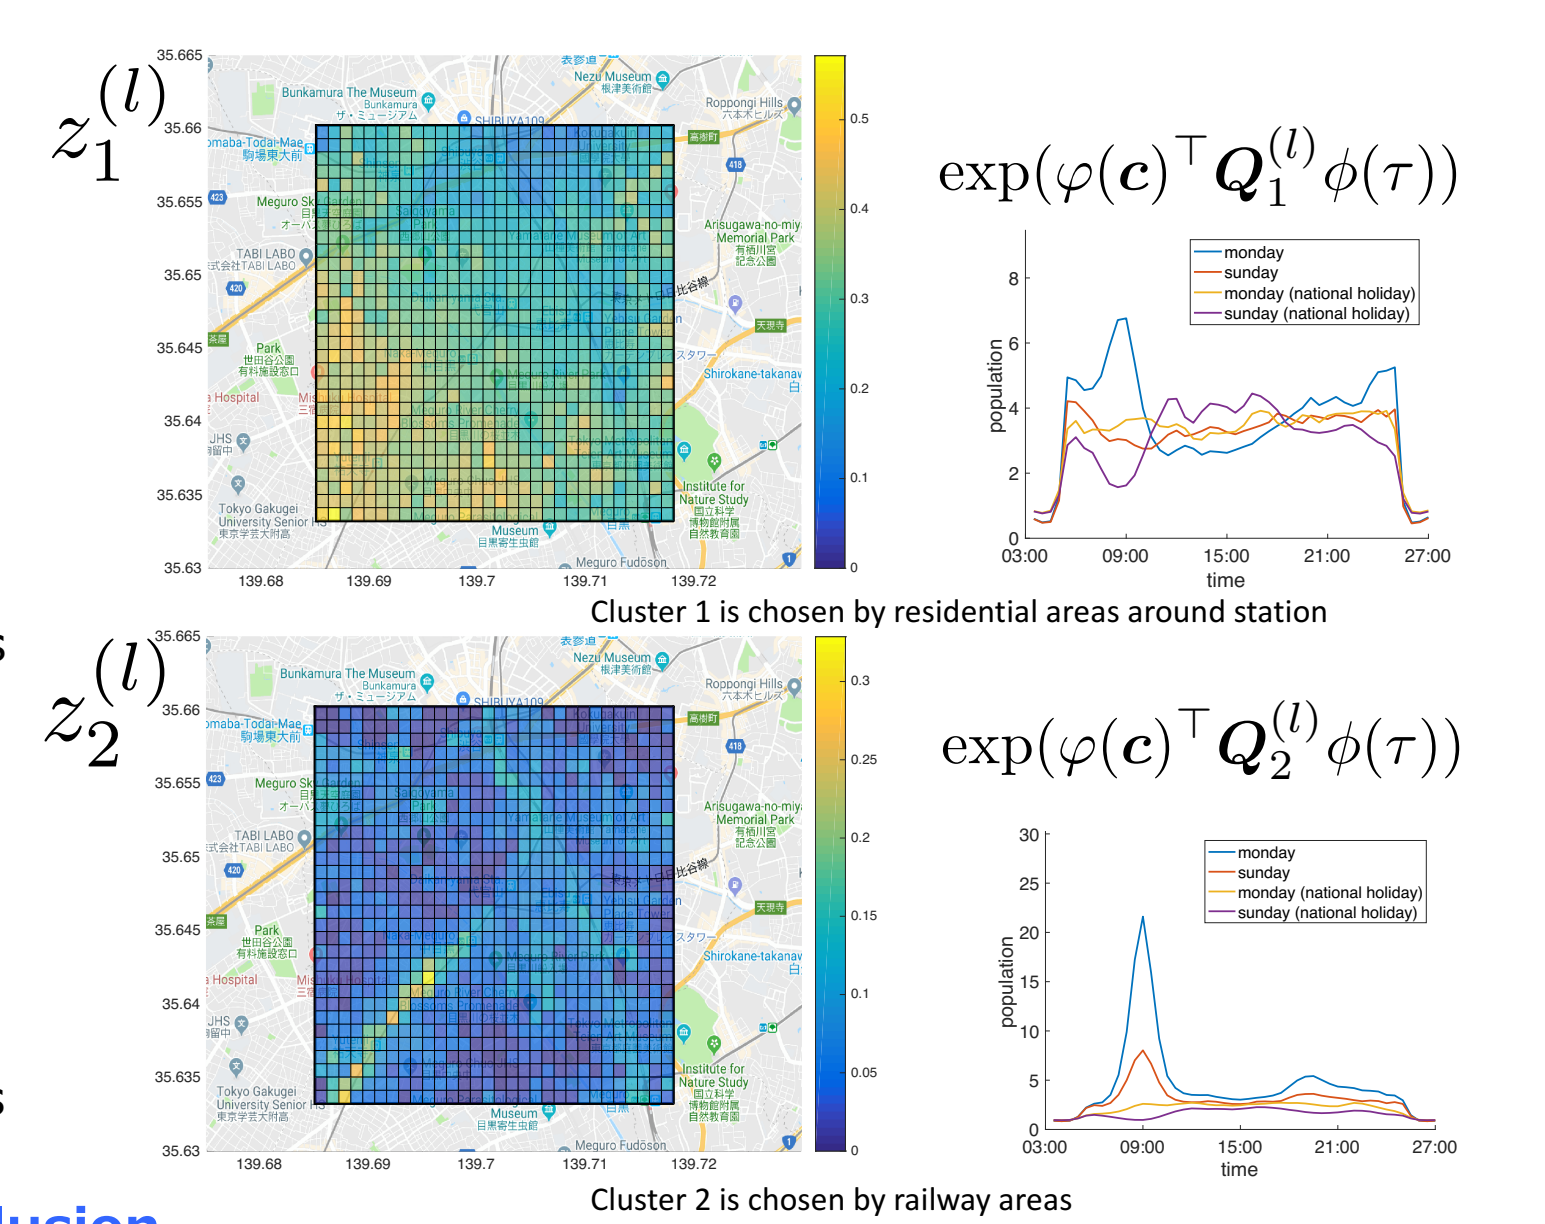
Spatiality preservation via graph proximity matrix

- Objective function
 - $-\ln \text{Poisson}(y_{c,\tau}^{(d,l)} | \lambda_{c,\tau}^{(d,l)}) + \sum \|Q_b\|_{Fro}^2 + \Omega_G(Z)$
 - Regularization term for spatiality preservation
- $$\Omega_G(Z) = \frac{1}{2} \sum_{l,l'} \|z^{(l)} - z^{(l')}\|_2^2 A_{l,l'}$$
- $$A_{l,l'} = \exp(-\eta \text{dist}(l, l'))$$
- $\text{dist}(l, l')$: distance between l and l'

Areas are close → Parameters are close
→ Effectively share dataset and parameters between areas.

Visualization of latent parameters

- Visualizing $z_b^{(l)}$ on map and predictive pattern from $Q_b^{(l)}$
- Relationship among the meshes was captured



Conclusion

- We propose SPF regression which shares the dataset and parameters between meshes by factorization with spatiality preservation and promotes the stability in training and prediction for fine-grained population prediction.
- We confirm the effectiveness of factorization and spatial preservation in the experiments.

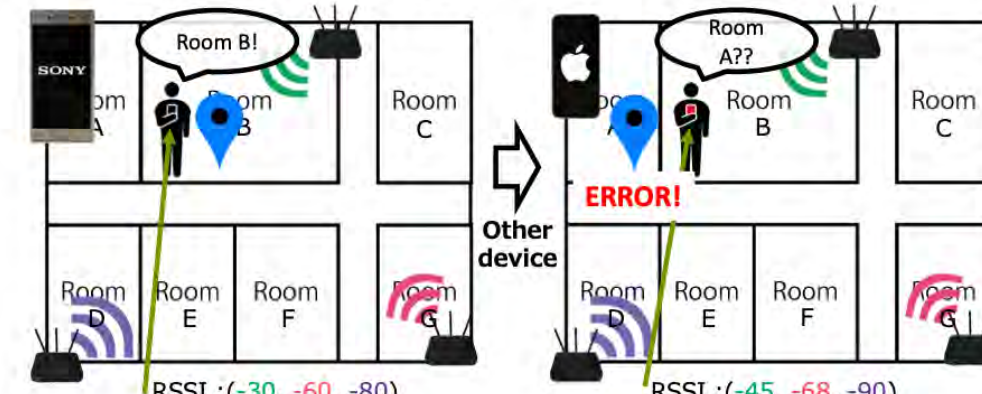
Shimosaka Research Group pursuing MIUBIQ (machine intelligence in UbiComp Research) <http://www.miubiq.cs.titech.ac.jp> Tokyo Institute of Technology

複数受信電波強度に基づく楕円周特徴量を用いた機種依存性の低い高精度屋内測位

須ヶ崎聖人 下坂正倫
東京工業大学 情報理工学院

背景

- 様々なアプリの基礎技術としてWi-Fi屋内測位の需要増加[1]
- Wi-Fiの屋内測位において機種ごとに取得される電波強度の違いにより測位の誤差が発生



- 既存のキャリアレーション手法: 転移学習, ドメイン転移
- それぞれの端末でのデータが必要
- すべての端末でのデータ取得は現実的でない

問題設定

線形識別器による多クラス分類として定式化

環境中のラベル集合: $\mathcal{L} = \{A, B, \dots\}$

以下の式によりラベルの事後確率より測位を行う

$$f(x) = \arg \max_{l \in \mathcal{L}} \theta_l^T \phi(x)$$

l : ラベル θ_l : 重み $\phi(x)$: 特徴量

目標と解決のための注目点

機種依存性の低い測位手法の構築

- 電波伝搬方程式の端末依存成分をキャンセル
- 電波伝搬方程式

$$x_i = z(m, l_0) - 10\beta_i \log \left(\frac{l_i}{l_0} \right) + \psi$$

少数AP下で正確な測位が可能なる手法の構築

- ガウス基底を使用した変換による特徴量の作成

実験

- 実験設定
 - 場所: 東工大4F
 - データ取得点: 105点
 - 取得回数: 各点10回×5日
 - データ数: 5,250/device
 - 取得端末: Nexus5, Nexus5X, Nexus6P, Xperia X performance
 - 必ずしもAndroid6.0
- 比較手法
 - UniNaive: 単一のRSSIをそのまま特徴量として使用
 - UniGaussian: 単一のRSSIをガウスカーネルで変換して使用
 - PairNaive: RSSIの差分値をそのまま特徴量として使用
 - PairBinary: 最新既存手法[2]のバイナリ特徴量を使用

まとめ

- 機種依存性の解決
 - アンテナ特性を除去することが鍵となることを指摘
 - 端末依存性を解消する特徴量の提案: 「楕円周特徴量」
- 機種依存性の解消に向けた特徴設計の最新手法[2]と比べ、性能が良いことを確認

参考文献

- [1] Bahi, P. and Patnamashah, V. N.: RADAR: An in-building RF-based user location and tracking system. In Proc. of INFOCOM2000.
[2] Zhang, Y. W. et al.: Cold-Start Heterogeneous Device Wireless Localization. In Proc. of AAAI2016.
[3] Sugasaki, M. and Shimosaka, M.: Robust indoor localization across smartphone models with ellipsoid features. Proceedings of ACM on IMWUT, Volume 1 Issue 3, 2017 (also presented in UbiComp 2017).

Shimosaka Research Group pursuing MIUBIQ (machine intelligence in UbiComp Research) <http://www.miubiq.cs.titech.ac.jp> Tokyo Institute of Technology

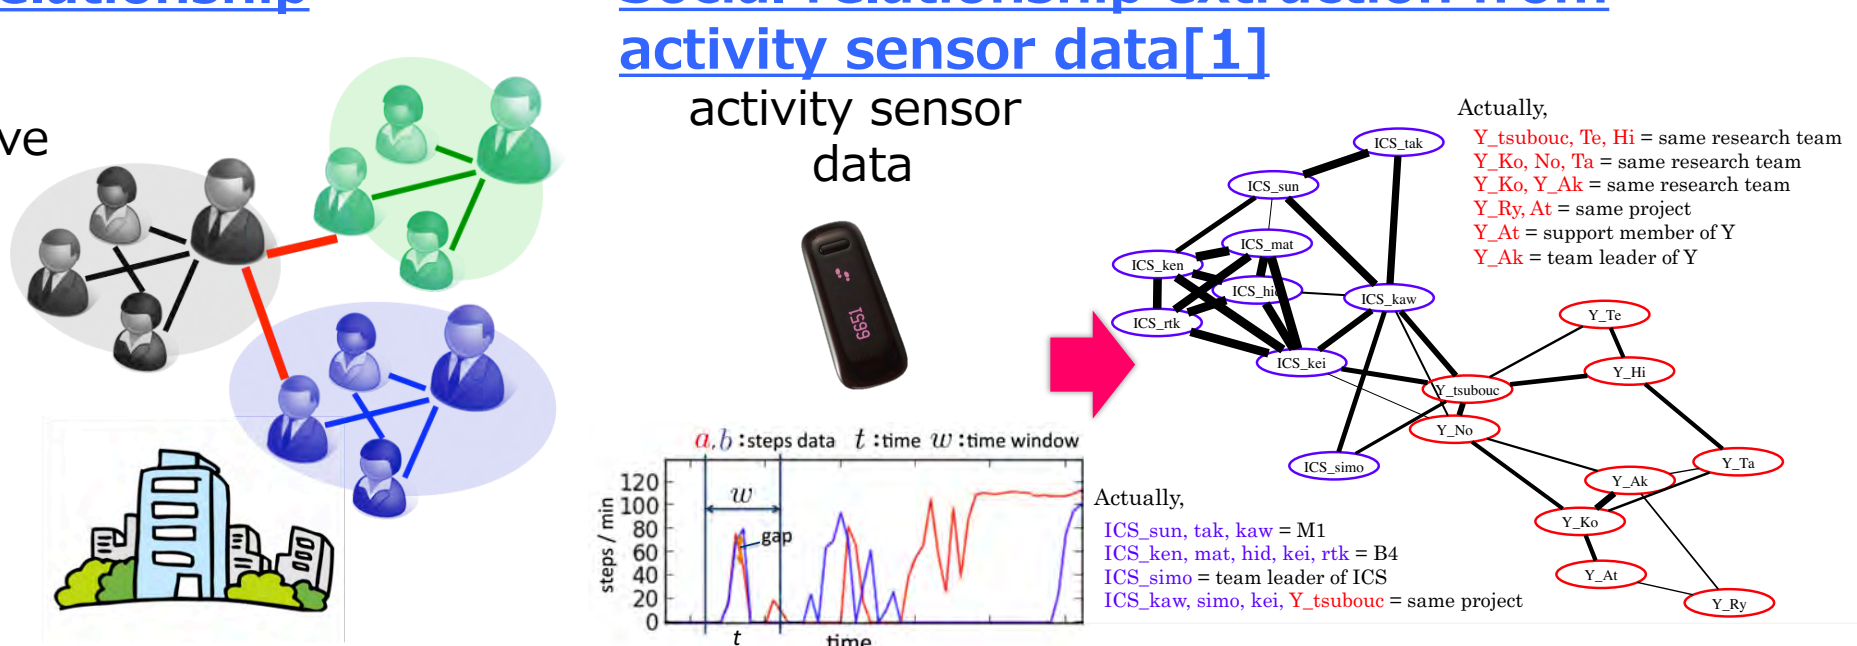
Fine-grained Social Relationship Extraction from Real Activity Data under Coarse Supervision

Kota Tsubouchi, Osamu Saisho, Junichi Sato, Seira Araki, Masamichi Shimosaka
Yahoo! JAPAN Research, The University of Tokyo, Tokyo Institute of Technology

Importance of grasping social relationship

- Managers should grasp...
 - what characteristics the company have
 - who is in the hub of community

Social relationship tells us such various and useful information!

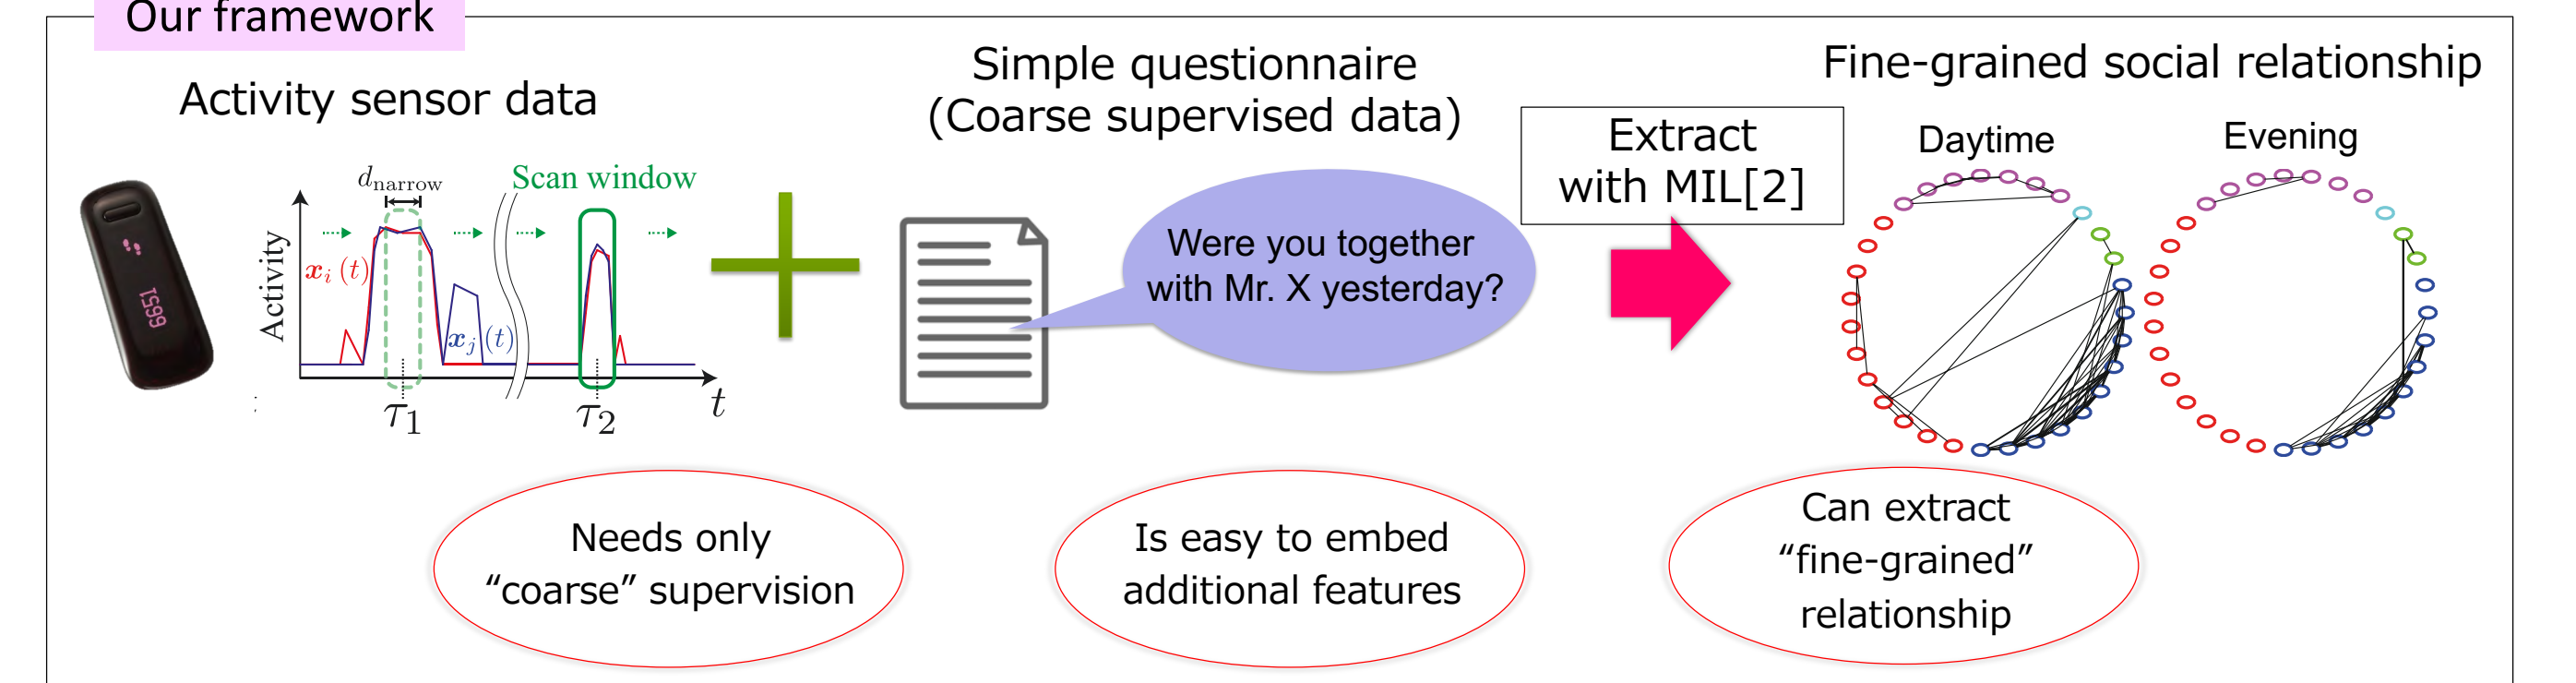


"Fine-grained" social relationship extraction under "coarse" supervision

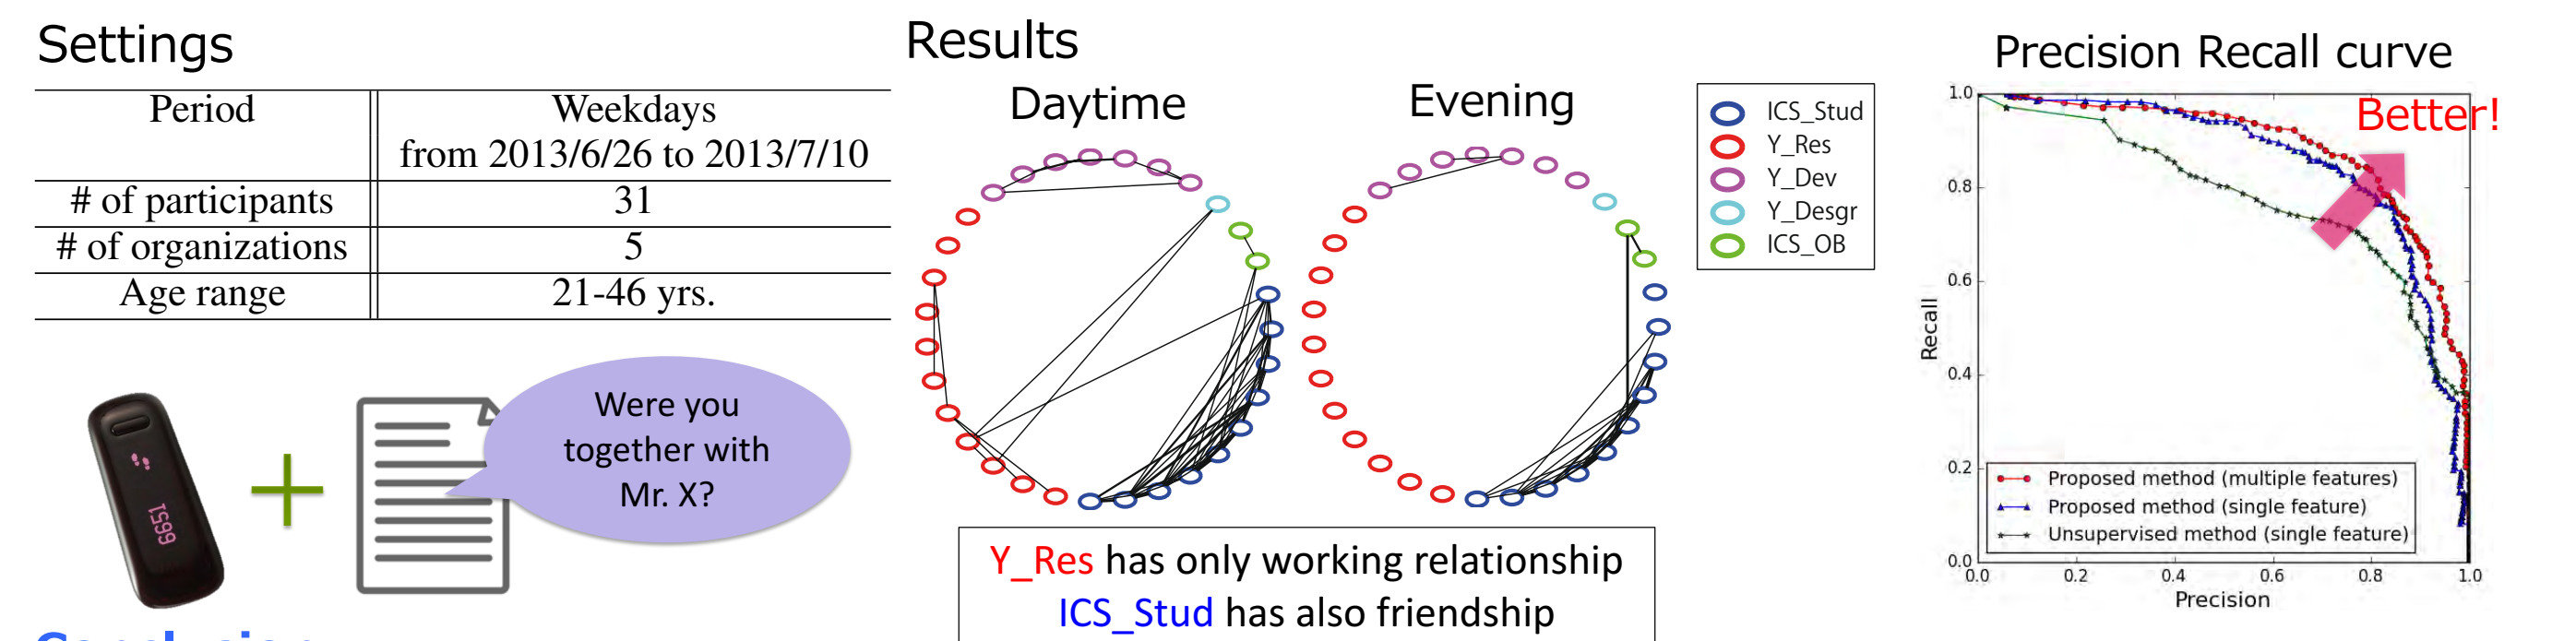
Social relationship VARIES according to the TIME: We need reference to extract "fine-grained" relationship, however:



"Fine-grained" social relationship should be uncovered Extraction from "coarse" supervised data is required



Experiment



Conclusion

- We proposed and evaluated a novel approach to extract fine-grained social relationship under coarse supervision.
- Our contributions are:
 - Enabled to extract social relationships at any time and duration.
 - Visualized the character of each organization.
 - Improved prediction accuracy.

References


- [1] K. Tsubouchi et al., "Working-relationship detection from Fitbit sensor data," UbiComp2013
[2] T. Dietterich, "Solving the multiple instance problem with axis-parallel rectangles," Artificial Intelligence 89, 1997

逆強化学習を用いた生活道路における危険予知運転モデリング

金子卓弘 + 西賢太郎 + 稲垣徳也 + 福倉寿信 + 岩井明史 + 下坂正倫 +
↑ 東京大学大学院 情報理工学系研究科 + 株式会社デンソー


研究の背景と目的

- 自動車の死傷事故率
 - 幹線道路では年々低下
 - 生活道路ではほぼ横ばい
- 生活道路の主要な事故要因[1]
 - ドライバー: 安全不確認
 - 歩行者: 飛び出し



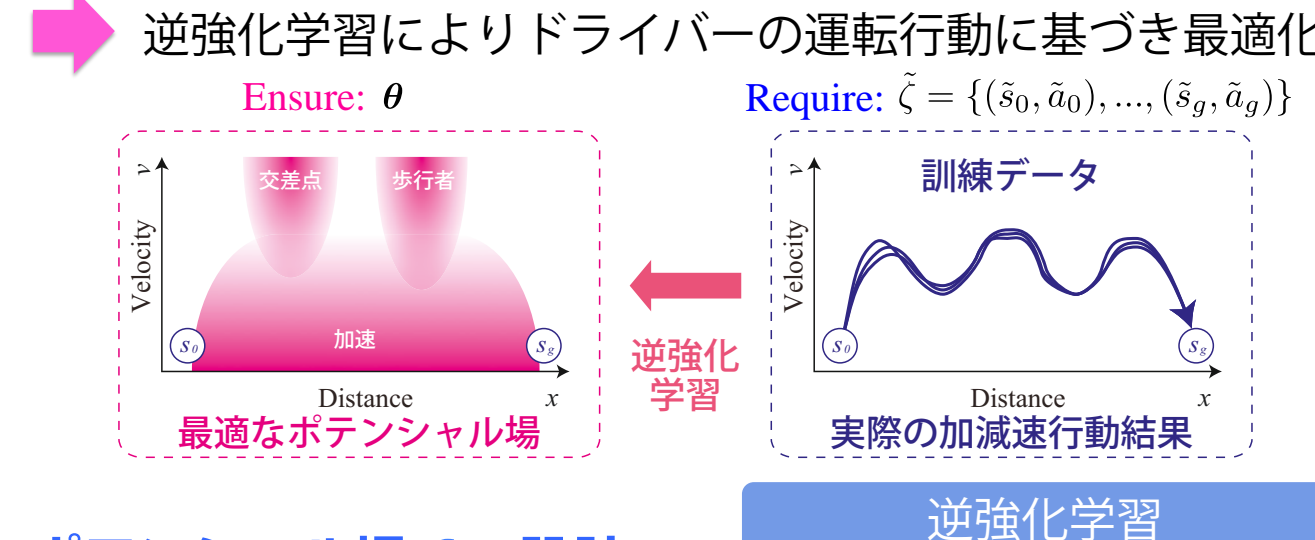
危険予知運転のモデル化

- 問題設定
 - 前提条件: 大域的なルートは既知
 - 行動単位: 右左折一時停止 → 右左折一時停止
 - モデルリング対象: 加減速行動
 - 行動単位内での位置・速度空間の経路計画として定式化



逆強化学習によるモデルの最適化[2]

- 問題設定
 - 前提条件: 大域的なルートは既知
 - 行動単位: 右左折一時停止 → 右左折一時停止
 - モデルリング対象: 加減速行動
- 逆強化学習によりドライバーの運転行動に基づき最適化
 - Ensure: θ
 - Require: $\zeta = \{(s_0, a_0), \dots, (s_n, a_n)\}$

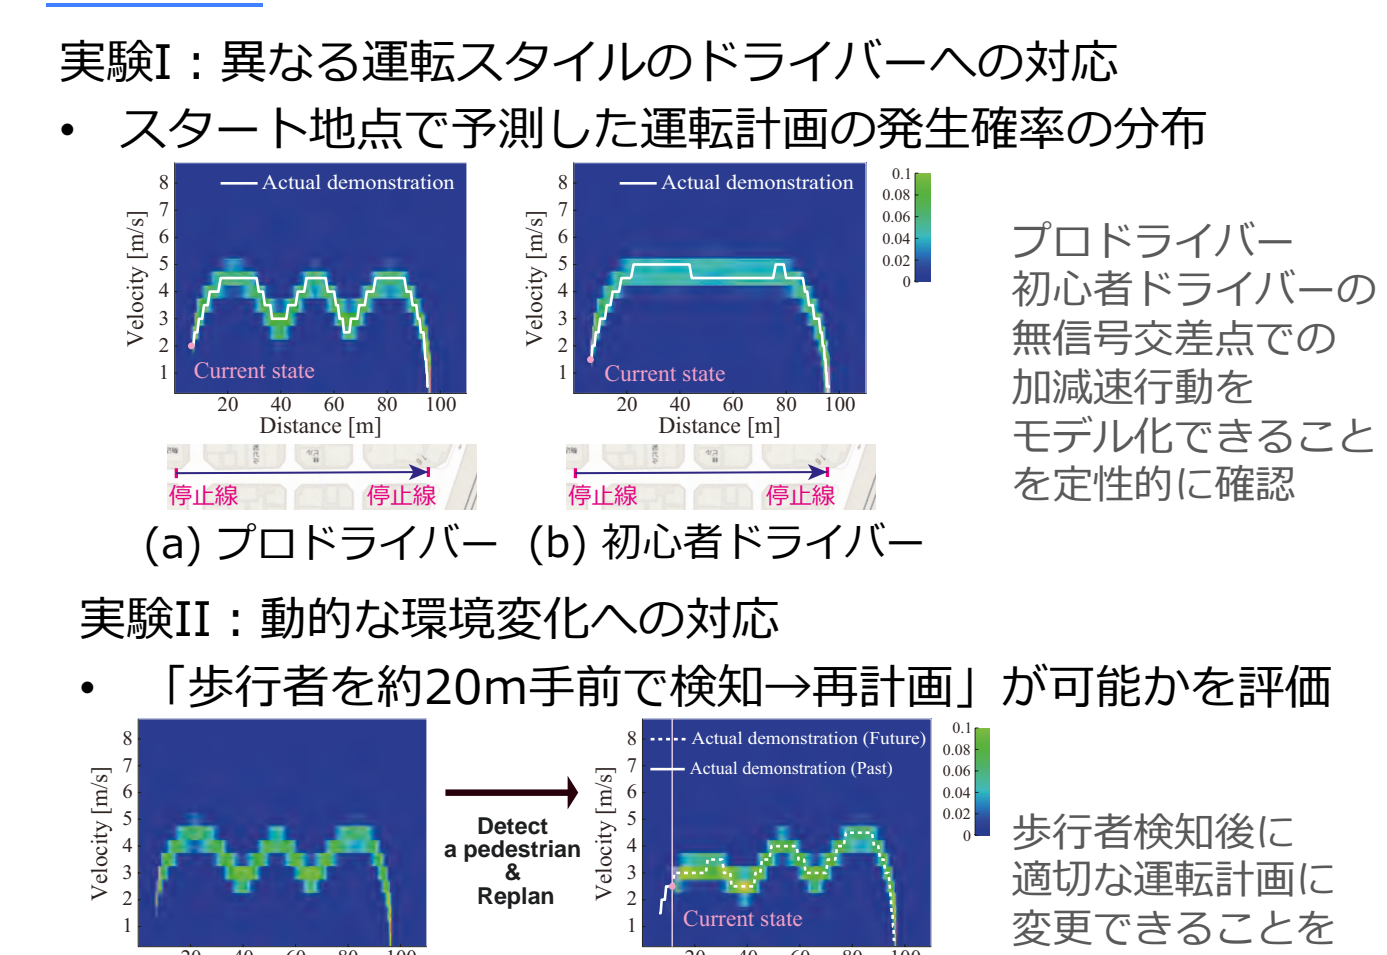


ポテンシャル場 f の設計

- 位置・速度空間での正規分布として定義
 - 静的な環境因子
 - 道路形状や標識など
 - 動的な環境因子
 - 歩行者や自転車利用者など


実験設定

- 実験車両
 - 全方位LIDAR
 - 全方位カメラ
- 実験コース
 - ドライバー2名
 - 初心者ドライバー
 - 運転頻度年数同程度
 - プロドライバー
 - ハイヤーの運転を職業
- 統計量
 - 延べ走行距離: 約20km
 - 無信号交差点延べ通過数: 約200個



逆強化学習によるモデルの最適化[2]

- 問題設定
 - 前提条件: 大域的なルートは既知
 - 行動単位: 右左折一時停止 → 右左折一時停止
 - モデルリング対象: 加減速行動
- 逆強化学習によりドライバーの運転行動に基づき最適化
 - Ensure: θ
 - Require: $\zeta = \{(s_0, a_0), \dots, (s_n, a_n)\}$



将来課題

- 危険予知運転に特化した簡易なセンサの開発
- 提案モデルを用いた運転支援システムの実験での検証

参考文献

- [1] TARDA INFORMATION, 交通事故分析レポート No. 98
[2] B.D. Ziebart et al. Maximum entropy inverse reinforcement learning, AAAI, 2008.