都市モニタリングからのグラフマイニング

慶應義塾大学　環境情報学部
中澤　仁

NTTソフトウェアイノベーションセンタ
飯田恭弘　岸本康成　岩村相哲

概要

- 公用車を用いた安価で継続的な道路点検手法の提案
  - 畳み込みニューラルネットワーク
    - 組み込みコンピュータ上で**90**%以上の精度で**0.1**秒以内の検出を実現
  - ラベル伝播
    - 全体の**1.8**%という少ない教師データから，ラベル伝播で約**85**%の正解率を実現

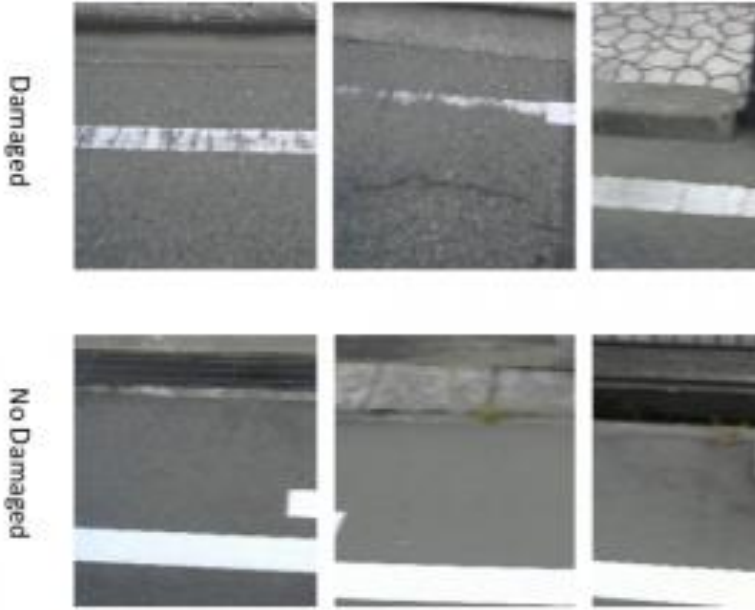

社会インフラにおける道路

- **全国の道路で老朽化が進んでいる**

藤沢市の例

- 管理対象道路：1,300km
- 土木担当職員：220人程度
- 1年間で全ての道路を点検するには1人当たり年間5kmを担当
- 道路性状測定車は運用が非常に高価

- 道路点検業務以外にも様々な業務があることから、市全体の道路を点検するのに5年間要している

http://www.c-nexco.co.jp/corporate/safety/torikumi/torikumi/vol04/

既存の道路点検の自動化手法(1)

- 加速度センサによる道路の状態認識
  - 加速度やジャイロセンサを用いた地表面のダメージ検出手法が主流
  - IRI指標に合わせることで信頼性を高める*
  - 走行時に危険な段差を検出する**
    - 4値分類で75%の精度
- 課題
  - 車両の走行速度やスマホの設置箇所など走行環境に依存しやすい
  - **路面標示などの付帯設備は加速度などのセンサでは点検できない**

*Boyu Zhao, Tomonori Nagayama, N. Makihata, M. Toyoda, M. Takahashi, and M. Ieiri. 2016. IRI Estimation by the Frequency Domain Analysis of Vehicle Dynamic Responses and Its Large-scale Application. In Adjunct Proceedings of the 13th International Conference on Mobile and Ubiqui- tous Systems: Computing Networking and Services (MOBIQ- UITOUS 2016). ACM, New York, NY, USA, 41-46. DOI: https://doi.org/10.1145/3004010.3004013

**Takahashi, Junji, et al. ”Classification of Steps on Road Sur- face Using Acceleration Signals.” proceedings of the 12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services on 12th EAI Interna- tional Conference on Mobile and Ubiquitous Systems: Com- puting, Networking and Services. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engi- neering), 2015.

既存の道路点検の自動化手法(2)

- 画像認識による道路の状態認識
  - 道路の状態を3値分類
  - GoogLeNetによって93%の検出精度
- 課題
  - **モデルが非常に大きい**
    - 畳み込み層だけで50層以上
    - 計算コストが大きい
    - メモリ専有が大きい

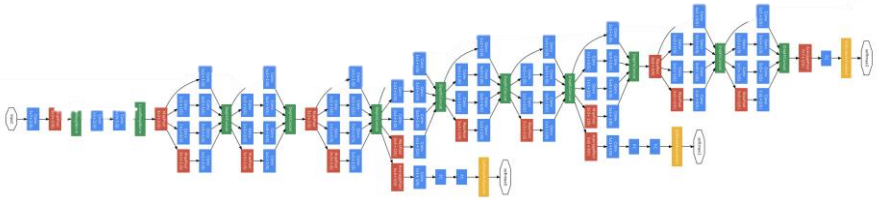

GoogLeNet

Smooth	Damaged	
	No Need Repair	Need Repair
500 images	396 images	107 images

Maeda, Hiroya, Yoshihide Sekimoto, and Toshikazu Seto. ”An Easy Infrastructure Management Method Using On-Board Smartphone Images and Citizen Reports by Deep Neural Net- work.” Proceedings of the Second International Conference on IoT in Urban Space. ACM, 2016.
MLA Szegedy, Christian, et al. "Going deeper with convolutions." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015.

目的と概要

道路管理の負担を抑えて継続的に行うために
高精度・高速・安価な道路点検の自動化を実現

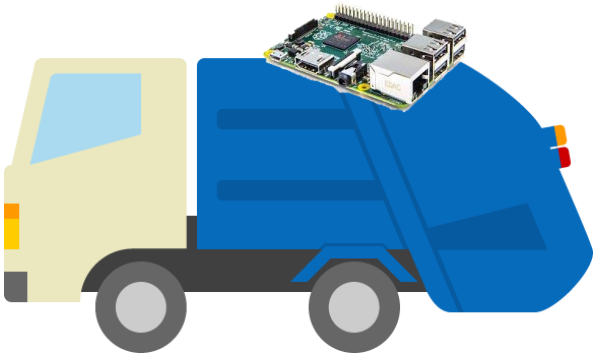

- 公用車にカメラとセンサを設置して、道路面の劣化具合や道路性状を継続的かつ安価に把握
- 2016年度は路側帯を示す道路標示をかすれの有無により2値分類
- NTTSICと慶應義塾大学環境情報学部との共同研究を実施

検討する手法

手法1：オフライン検出

画像

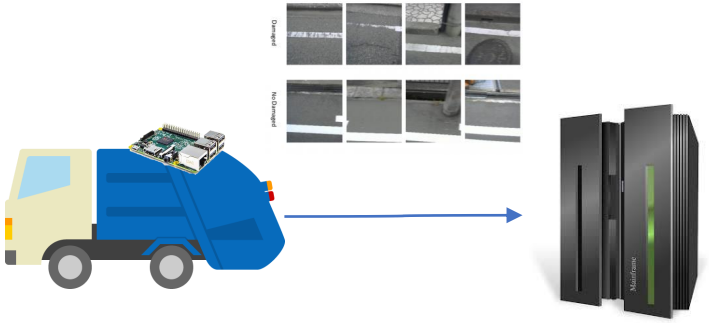

撮影　　検出

手法2：オンライン検出

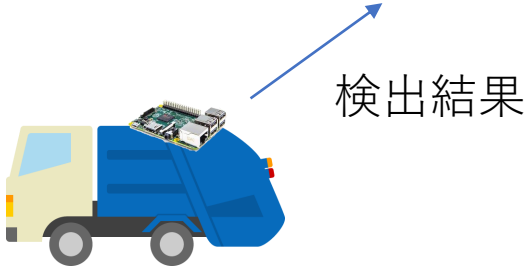

撮影＋検出

検出手法：CNN（慶應）、グラフマイニング(ラベル伝播・NTT)に加えてSVM、ランダムフォレストを使用

実験の内容

- 精度実験
  - 検出手法間の精度の比較
- 検出速度実験
  - 検出手法間の検出速度の比較
- モデルの小型化
  - 小型化によって生じる速度と精度の変化の検証
- 組み込みコンピュータ上での処理検証
  - 実用に耐えうるか検証

主な実験環境

- 精度実験
  - OS : Ubuntu
  - CPU Intel Core i7
  - メモリ 64 GB
  - GPU GeForce GTX TitanX (搭載メモリ12 GB)
- 検出速度実験
  - Macbook Air
  - CPU Intel Core i7
  - メモリ 8GB
- 使用ライブラリ
  - Python, Tensorflow, scikit-learn

実験に使用したデータセット

- 車両の側面にカメラを取り付けて走行
- 環境：晴れた昼間の公道 (速度：0 – 40 km/h)
- 汎用的なwebカメラを使用
- 60fpsの動画で撮影→フレームからランダムに切り出し，静止画を生成
- アノテーション：擦り切れなし/擦り切れあり (23歳男性1名)
- 学習画像25,426枚，テスト画像6,781枚（ラベル伝播を除く）

データセット中の画像

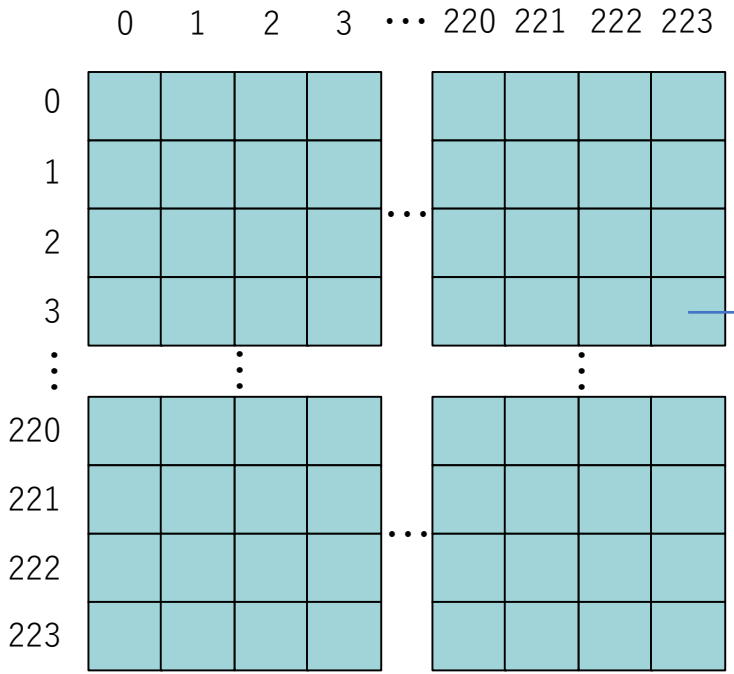

縦横224x224の画素数のカラー画像(jpg)

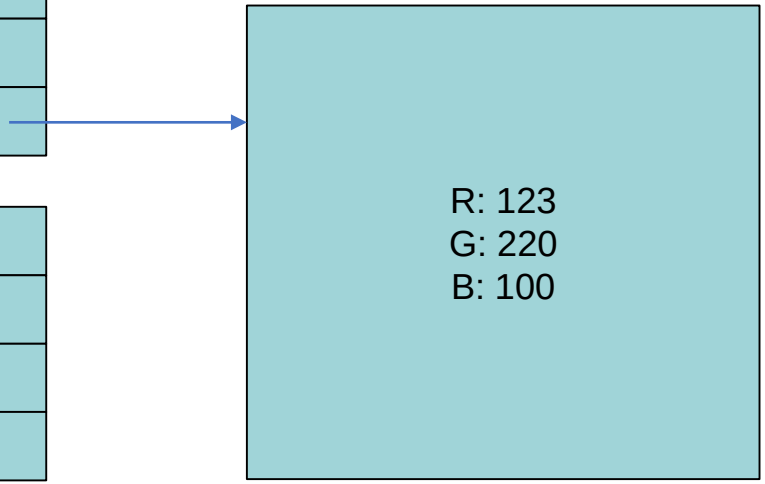

CNNを用いた検出手法（慶應）

- 画像系のタスクにおいて非常に効果
- 長所
  - 画像の特徴を理解した学習が可能
  - 回転や平行移動に対してロバストな学習
- 短所
  - モデルが大きくなる(層・チャンネルが増える)ことで**計算コストが増加**

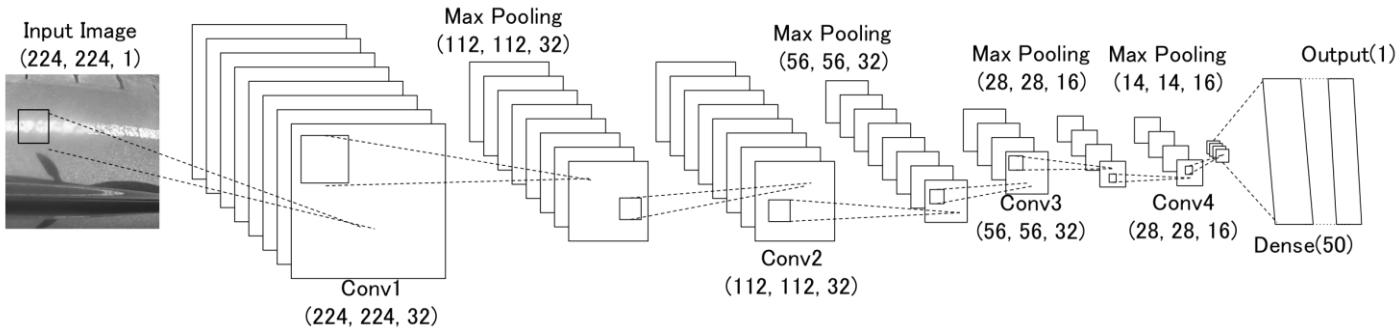

"Convolutional Neural Networks (LeNet) – DeepLearning 0.1 documentation". DeepLearning 0.1. LISA Lab. Retrieved 31 August 2013.

CNNを用いた検出手法（慶應）

- モデルは右図を参照
  - 最後の全結合層でdropoutを適用
- たたみ込みの計算式

$$\mathbf{z}_{i,j} = \sum_{i'=1}^{n'_i} \sum_{j'=1}^{n'_j} \Phi(\mathbf{f}_{i',j'}^{\mathrm{T}} \mathbf{x}_{i+i',j+j'}),$$

$$f(x) = max(x, 0)$$

- 活性化関数にはReLUを使用

Type	Kernel	Stride	Outputs
Conv	(3,3)	(1, 1)	32
Maxpool	-	-	32
Conv	(3,3)	(1, 1)	32
Maxpool	-	-	32
Conv	(3,3)	(1, 1)	16
Maxpool	-	-	16
Conv	(3,3)	(1, 1)	16
Maxpool	-	-	16
Dense	-	-	50
Output	-	-	1

Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting." Journal of Machine Learning Research 15.1 (2014): 1929-1958.

ラベル伝播を用いた手法（NTT）

- 分析の流れ
  - 白線抽出：　画像中の白線領域を検出して特徴量を計算
  - グラフ構築：　特徴量を用いて画像間のグラフを構築
  - ラベル伝播：　教師データ（ラベル付与済データ）をもとに，画像（11234枚）を白線のかすれ有無の2値に分類

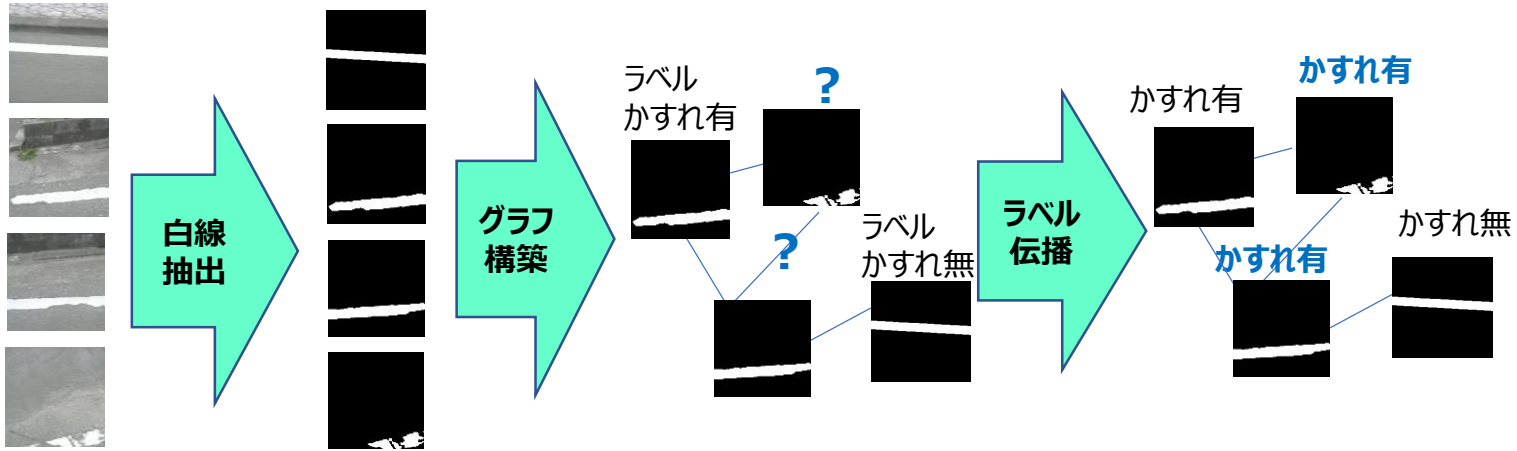

ラベル伝播を用いた手法（NTT）
（1）白線抽出

1. RGB値をグレースケール化
2. さらに，輝度（0～255）に対して閾値を設定（200とした）し、白と黒に2値化
3. 白の連続領域の抽出により白線部分を抽出

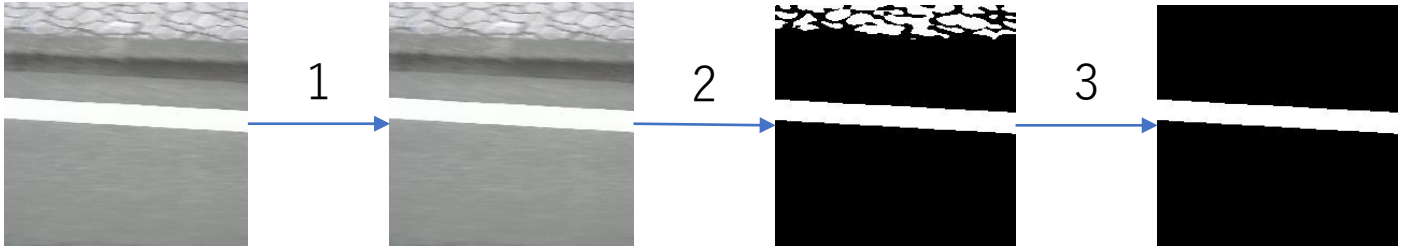

ラベル伝播を用いた手法（NTT）
（2）かすれ度合いの計算

- 白線がかすれた画像ほど，白線を表す画素とそれ以外の画素との境界が多いと考えられることから、かすれの度合を以下により数値化

  r ＝境界の画素数/白線領域の画素数

- rの分布より，かすれの度合いをrで表すことが有効であることを確認.

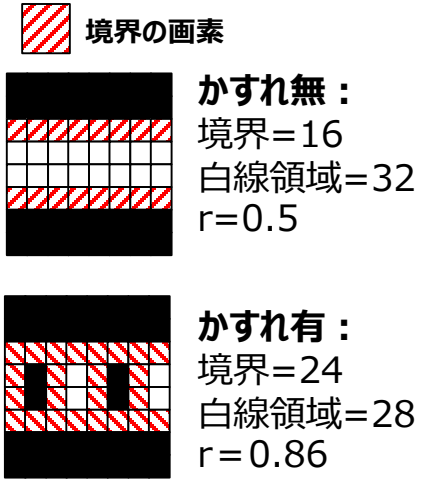

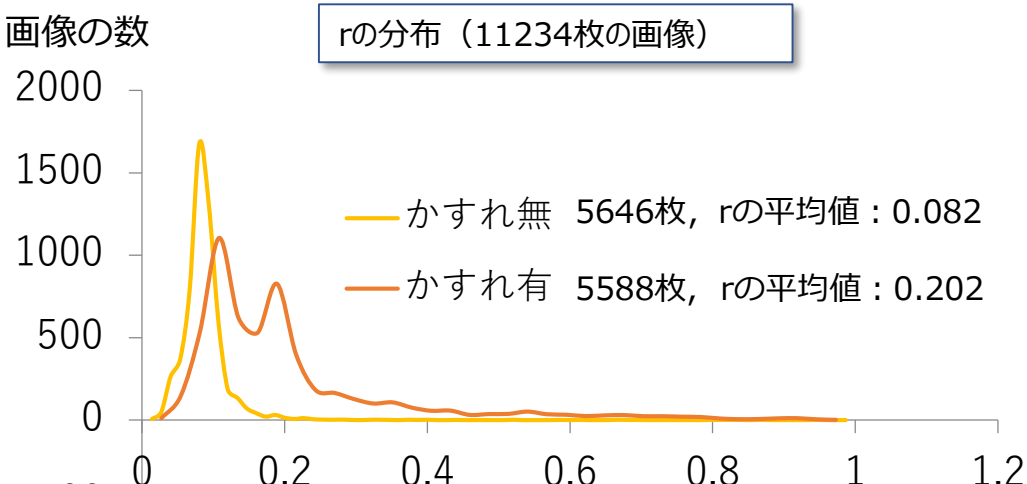

ラベル伝播を用いた手法（NTT）
（3）グラフの構築とラベル伝播による推定

- かすれ度合い **r** を用いてグラフ構築（rの類似性でエッジを作成）
- 一部を教師データとして，ラベル伝播を実行.

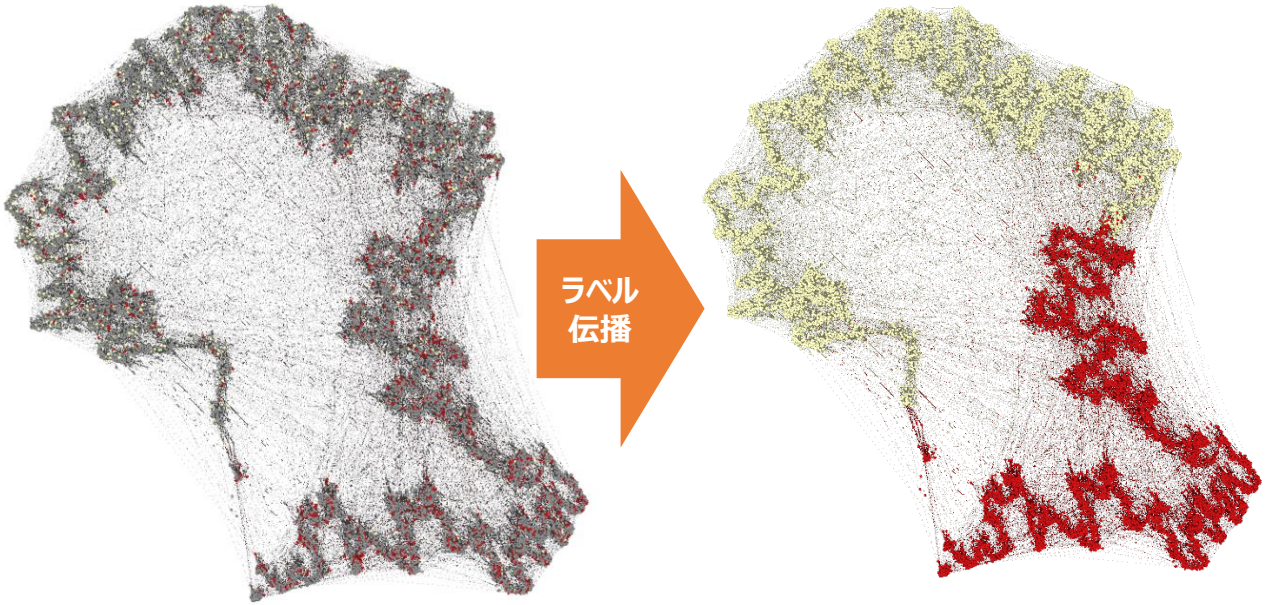

グラフ構造（教師データのみ色付き表示）

推定結果

ラベル伝播を用いた手法（NTT）
（3）グラフの構築とラベル伝播による推定

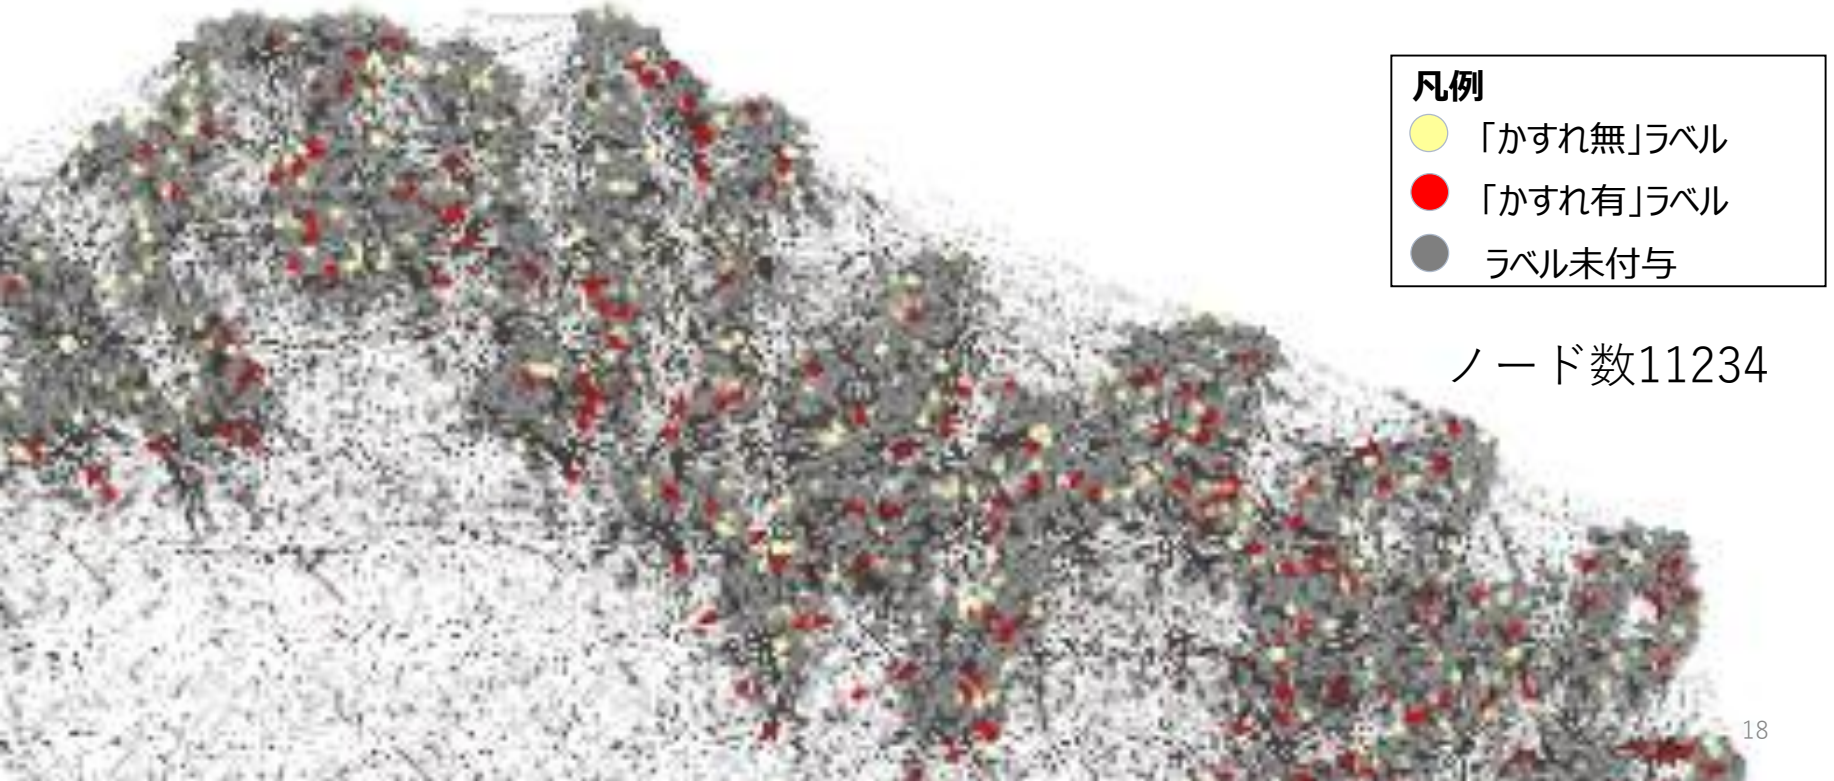

ノード数11234

精度実験

- 線形SVM、ランダムフォレスト、CNN、ラベル伝播を比較
- 評価指標
  - Accuracy(acc):正解率
  - recall: 再現率(正解のうちどれくらいを正しく検出できたか割合)
  - precision: 適合率（予測結果に正しい答えが含まれる割合)
  - f1: 再現率と適合率のバランスを評価する
- 使用計算機（ラベル伝播を除く）
  - OS : Ubuntu
  - CPU Intel Core i7
  - メモリ 64 GB
  - GPU GeForce GTX TitanX (搭載メモリ12 GB)

精度実験

検出手法 (学習データ数)	acc(%)	recall	prec.	f1
線形SVM (25426)	82.4	0.87	0.83	0.85
Random Forest (25426)	84.0	0.91	0.83	0.87
CNN (25426)	**93.4**	**0.90**	**0.95**	**0.94**
ラベル伝播 (**200**)	85.5	0.84	0.87	0.85
ラベル伝播 (2000)	85.8	0.83	0.87	0.85
ラベル伝播 (7000)	85.3	0.83	0.87	0.85

- 学習データ数が多ければ、ほぼ全てのスコアでCNNが最良
- ラベル伝播では、200画像(全体の1.8%)のみの学習で比較的高い精度を実現

ラベル伝播による推定（正解との比較）

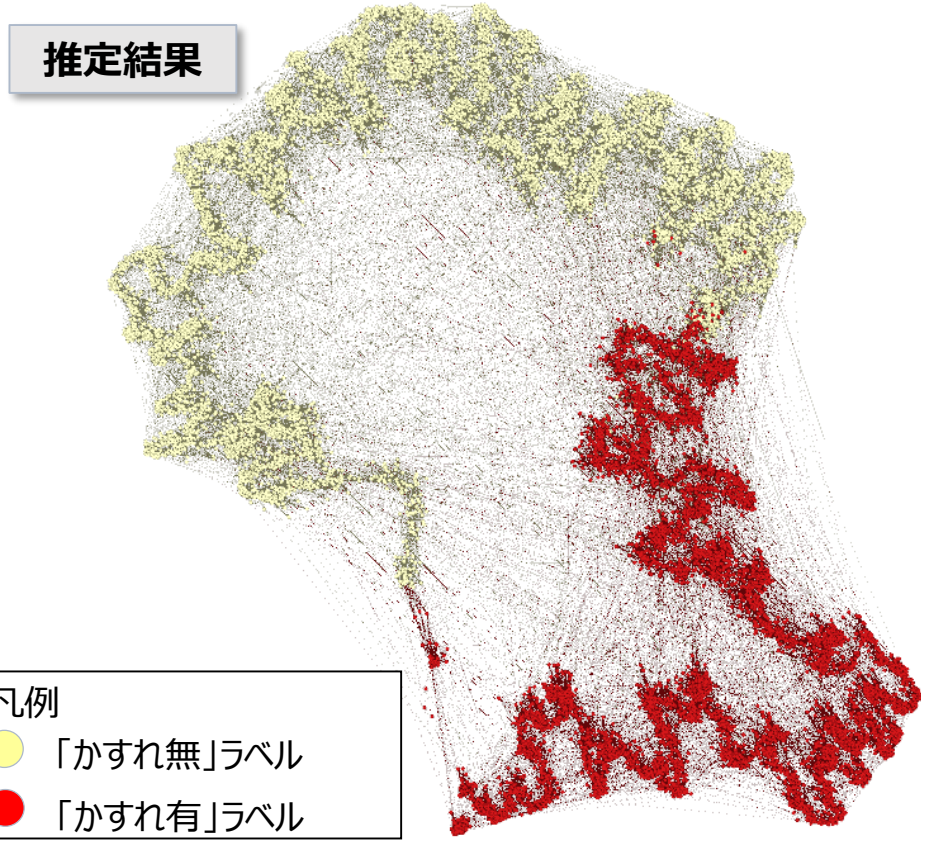

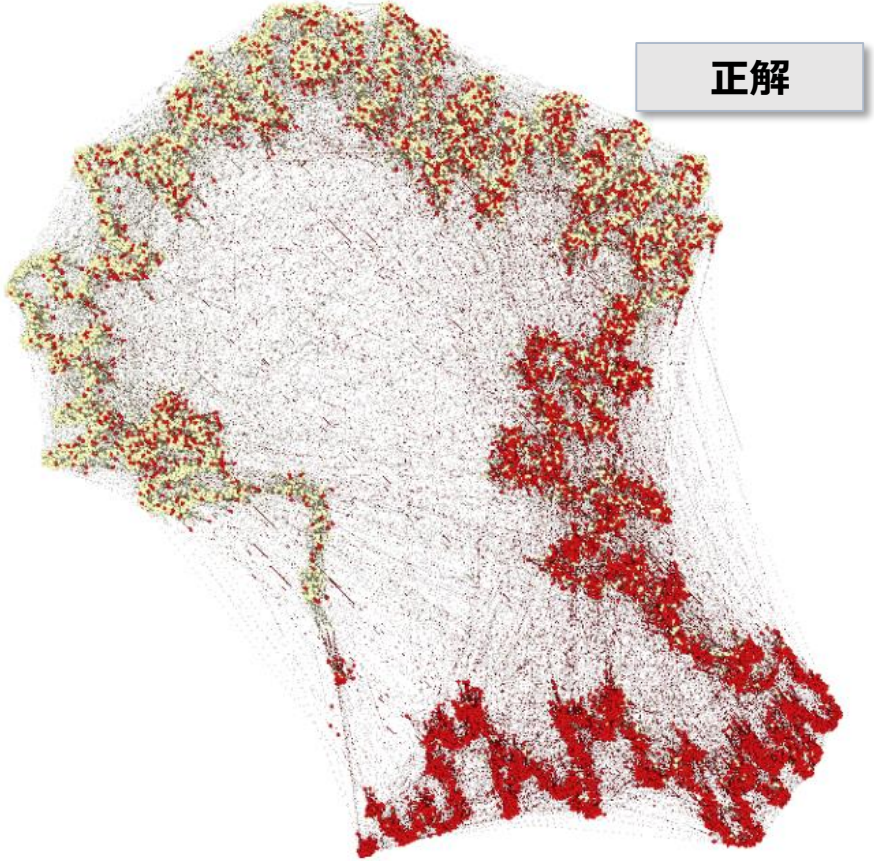

凡例

- 「かすれ無」ラベル
- 「かすれ有」ラベル

CNNによる推定（誤検出ケース）

- 画像中を占める路面表示が小さい
- 点線をダメージと判定

} 道路の傷を検出している可能性

- 影をダメージと判定
- ラベル誤りの可能性

（ラベル：擦り切れなし）
（判定：擦り切れあり）

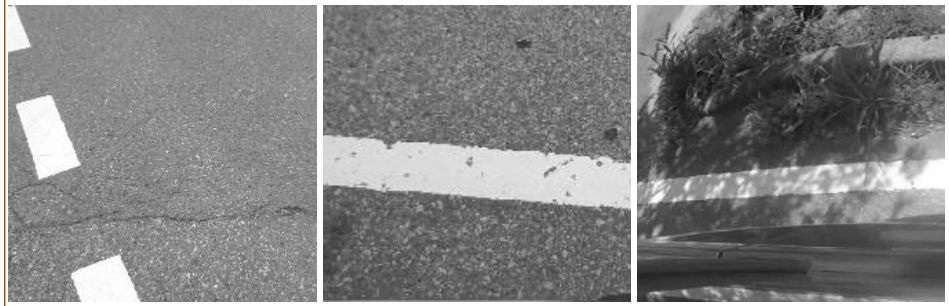

（ラベル：擦り切れあり）
（判定：擦り切れなし）

学習ファイルのサイズ及び検出速度

- 線形SVM，ランダムフォレスト，畳み込みニューラルネットワーク(CNN)の学習後のファイルサイズの比較
- 検出速度の比較を行った
  - 30枚の画像を検出した時間の平均で計測*

Model	File Size	Detection Time(s)
線形SVM	5.8 GB	**0.0007**
ランダムフォレスト	80 MB	0.0012
CNN	**709 KB**	0.0349

使用計算機：Macbook Air (CPU Intel Core i7 メモリ 8GB)

- CNNは学習ファイルサイズが最も小さい
- CNNは検出速度が最も遅いものの、30fps程度のリアルタイム検出が可能
- 時速50km走行時に35ミリ秒間の移動距離は約50cm

モデルの小型化による精度と処理速度の変化

- 層とチャンネルのバランスでモデルの高速化が実現
  - 最大**92.7**%の精度でかつ**0.014秒**の検出を実現
  - 1秒間に**50**回以上の検出が可能

最高精度93.4%

精度があまり落ちず
検出速度も向上

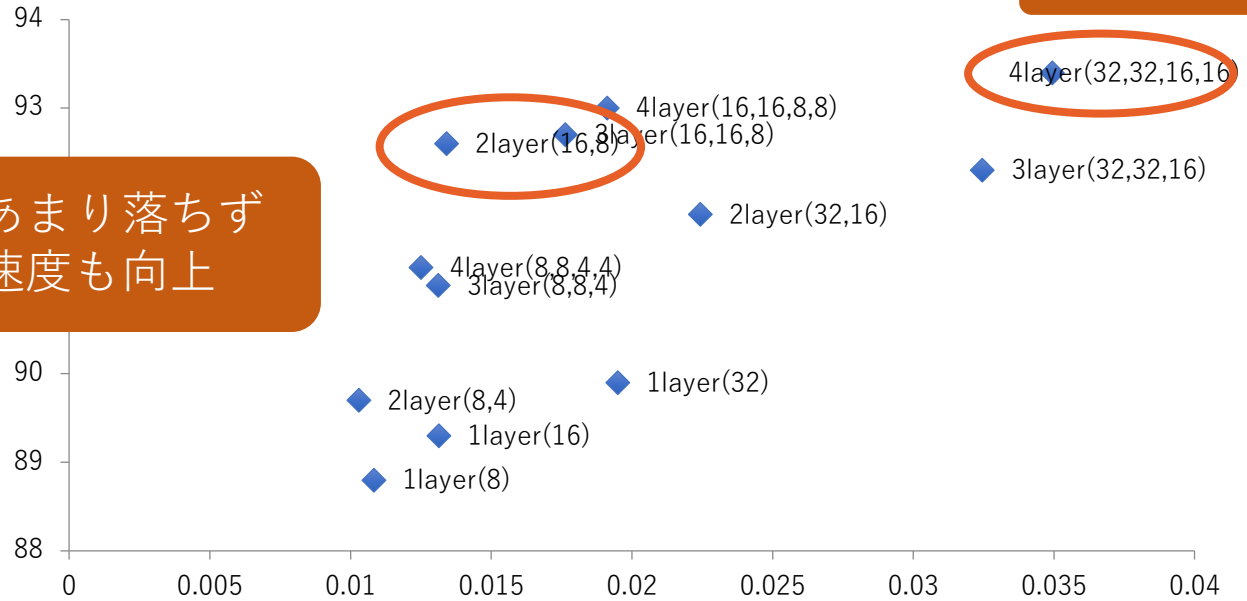

組み込みコンピュータ上での検出速度

- Raspberry pi3上で実験(4コア1.2GHz(64bit), メモリ1GB)
  - 90%以上の検出精度で**0.1**秒以内の検出

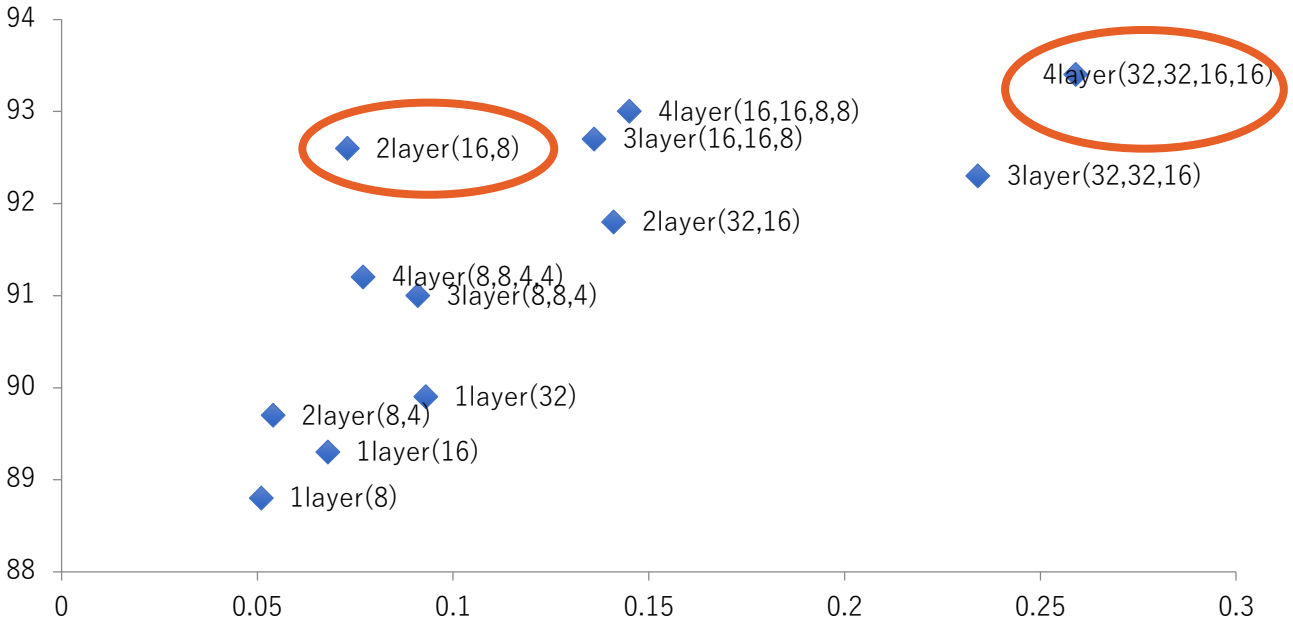

まとめ

- 車両とカメラを用いた道路標示のかすれ検出手法を提案
  - 路面表示を対象とした2値分類にて、**90**%以上の精度を示した
  - CNNを用いて**0.02**秒以下の検出速度を達成した
  - 組み込みコンピュータ上では**0.1**秒以下を示した
- 今後の展開
  - 2値分類→N値分類
  - 天候に対するロバストネスの向上
  - 画角に対するロバストネスの向上
  - 他の道路付帯設備への適用

撮影時の走行速度による学習への影響

- 走行速度が上がることで画像がぼやけていく
  - 訓練データとテストデータを速度ごとに用意して，その影響を検証
  - 訓練データ：各5000枚，テストデータ：1000枚
  - 走行速度が同じ場合にはより高精度の検出が可能

		Test Dataset			
		10 km/h	20 km/h	30 km/h	40 km/h
Training Dataset	10 km/h	**95.0**	69.0	75.0	55.0
	20 km/h	77.0	**92.3**	78.0	63.0
	30 km/h	73.2	77.0	**95.0**	72.0
	40 km/h	51.0	59.0	74.8	**97.0**

得られた知見のまとめ

- 画像から白線を抽出する手法を考案し，これによるグラフ構築とラベル伝播にて一定の精度を得られることを確認した。

- 特徴量としてかすれ度合い r を用いた場合、全体の1.8%という少ない教師データから，ラベル伝播で約85%の正解率が得られた。

- 他の特徴量としてLBPを用いたグラフ構築手法も適用評価したが，70～77%程度の正解率に留まった。

  ➔ 画像の特徴量の取り方とグラフ構築手法がカギ

本手法の制約

- 雨の日や夜に撮影された画像には適応できない
  - 一つの天候下でしか画像を収集していない
- より詳細に擦り切れの分類を行うことができない
  - よりはっきりと擦り切れの定義を設けなくてはならない
- 分類クラスが増えた時の適応性
  - 分類問題が難しくなるためモデルが複雑になるかもしれない

今後の展望

- 送信までのシステムとして設計及び実装を行う
  - 他のセンサとの競合，連携時の処理負荷の検証
- 他の付帯設備に対しての適用
  - 落書きなど一貫性が無さそうで難しい付帯設備への適用
  - ラベル伝播法など自動ラベル付け手法の実装による事前準備負荷の減少
- 複雑な検出モデルになった場合の対応
  - あらかじめ学習した大きなモデルを活用することで小さなモデルでの検出精度の向上を図る

結論

- 車両とカメラを用いた道路状況認識手法を提案
  - 加速度などでは取得できない付帯設備を対象に画像認識を用いた自動点検手法を提案
  - 路面表示を対象とした2値分類にて，**90**%以上の精度を示した
  - 検出速度は**0.02**秒以下を示した
  - 組み込みコンピュータ上では**0.1**秒以下を示した
- 今後の展望
  - システムとして運用・実証実験
  - 様々な付帯設備への対応

ご清聴有難うございました

システムの全体図

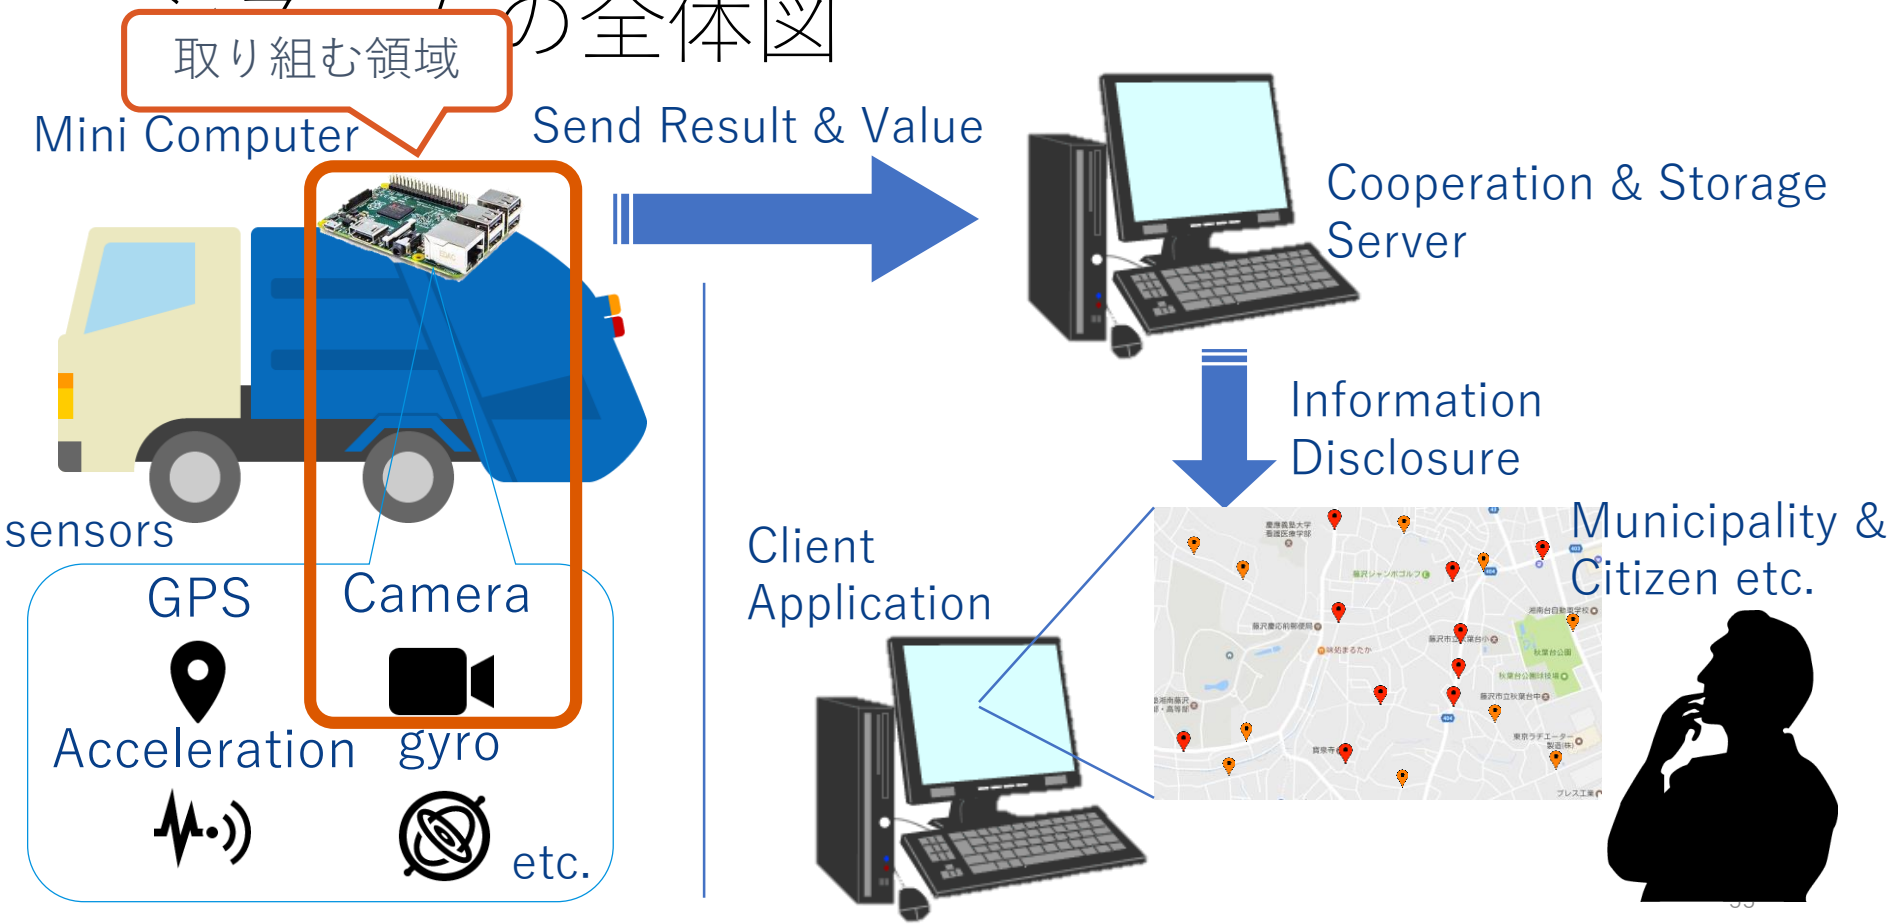
取り組む領域
Mini Computer
Send Result & Value
Cooperation & Storage Server
Information Disclosure
sensors
GPS
Camera
Acceleration
gyro
etc.
Client Application
Municipality & Citizen etc.

C’sの構築に必要な実装及び検証

- 検出手法の考案
  - 検出対象の定義付け
  - 路面表示を対象とした自動検出手法の考案
  - **高精度**かつ**小さなモデル**の検討
- 実験
  - 検出精度，処理速度の評価
  - 実装置上での使用検証(処理速度)

自治体の管理負担を抑える事例(1)

- スマートシティ
  - **<u>街全体のセンサ化</u>**によって，街の監視を実現
    - サンタンデール，シンガポールなどで取り組まれている
  - 社会インフラにもセンサを仕込むことで道路の異常も検出可能
- 課題
  - 大量のセンサを街に埋め込む必要がある
  - **運用コストが大きい**

センサの数だけ
監視できる場所も増える

自治体の管理負担を抑える事例(2)

- 参加型センシング
  - **<u>ユーザに</u>**街の状況をレポートしてもらうことでモニタリングが可能
  - センサを街に**<u>仕込む必要がない</u>**
  - ちばレポでは**<u>投稿の7割が道路に関するレポート</u>**だった
- 課題
  - 投稿内容・頻度・場所がユーザ依存
    - 都心部では投稿が多い
    - 郊外では投稿が少ない
  - **満遍なく情報収集できない**

自治体の管理負担を抑える事例(3)

- 公用車センシング
  - 清掃車などの車両を用いることで**街全体**をセンシング可能
  - 業務に抱え合わせるため**新たな労働力が発生しない**
  - ルーチン化しているため**定期的にデータを収集可能**
  - 業務のため**ほぼ毎日センシング可能**
- 課題
  - 処理デバイスを搭載させる必要性
  - 運用コストは**搭載するマシンや通信量に依存**

Sensorized garbage trucks

Covered area
by several garbage trucks

カバー範囲が広い

Chen, Yin, et al. "Cruisers: A public automotive sensing platform for smart cities. " Distributed Computing Systems (ICDCS), 2016 IEEE 36th International Conference on. IEEE, 2016.

自治体の管理負担を抑える各事例

	取得頻度	運用コスト	取得範囲
スマートシティ	○ （かなり高速）	× (センサのコスト)	○ (街全体)
ユーザ参加型 センシング	× （ユーザ依存）	○ (アプリのみ)	× (ユーザ依存)
公用車センシング	△ (1日1回程度)	△ (運用環境による)	○ （街全体）

センサ埋め込みほど多くのセンサが必要なくユーザ参加型センシングより
収集範囲・頻度が定期的な**公用車センシングに着目**

公用車センシング+自動点検の課題

- 運用コストは搭載するデバイス，通信量に依存する
  - 安価な組み込みコンピュータを使用することで物理的な費用を抑えられる
  - 通信量を小さくすることで通信費用を抑えられる
- 組み込みコンピュータを使用する上での制約

  →大きなデータの送信は通信量が大きく，通信時間も長い

  →SDなどにデータを保存した場合，毎回の取り出しが面倒
- **搭載された組み込みコンピュータで検出処理を行う必要がある**

短所

処理能力：低

データ容量：小

価格：安

取り替え：易

長所

既存の自動点検手法の特徴

	検出対象	検出精度	検出速度	メモリ専有
センサによる 既存研究の手法	ひび割れ	○ (程度がわかる)	○ (センサ値)	○ (データが小さい)
画像認識による 既存研究の手法	ひび割れ	○ (分類できる)	× (計算量大)	× (計算量大)

センサによる検出手法は道路のひび割れや凸凹のみ検出
画像認識による手法はモデルが大きいため，処理負荷が大きい

➡ いずれの手法も道路の点検のみ
➡ 付帯設備を対象とした点検の自動化も必要

付帯設備とは

- 交通ルールを示したり，利用者を守る役割をもつ設備
  - ガードレールや，路面表示，信号 etc.
  - 安全な交通を実現する上で重要
  - 特に劣化が早い**路面表示**
  - 路面上に描かれるため，劣化が早い＝**定期的な点検が必要**
    - 目視による点検が負担
    - 塗装が非常に薄いため加速度センサでは検出できない
- **カメラを用いることで自動点検を可能にする**