

機械学習とスマートフォンを用いた 道路損傷画像のリアルタイム検出

前田紘弥、関本義秀、瀬戸寿一、檜山武浩、小俣博司

1. 背景

道路路面の損傷検出に関する既存研究の問題点

1. 道路損傷に関する共通の画像データセットが存在しない
 → ゆえに、手法間の比較が難しい
2. 画像処理を用いた手法では、損傷の有無の検出にとどまっている
 → 損傷種類によって対応が異なるため、実務で直接使えない

2. 手法

深層学習を用いた物体検出手法には複数の手法があるが、本研究では処理速度を重視してSSDを採用

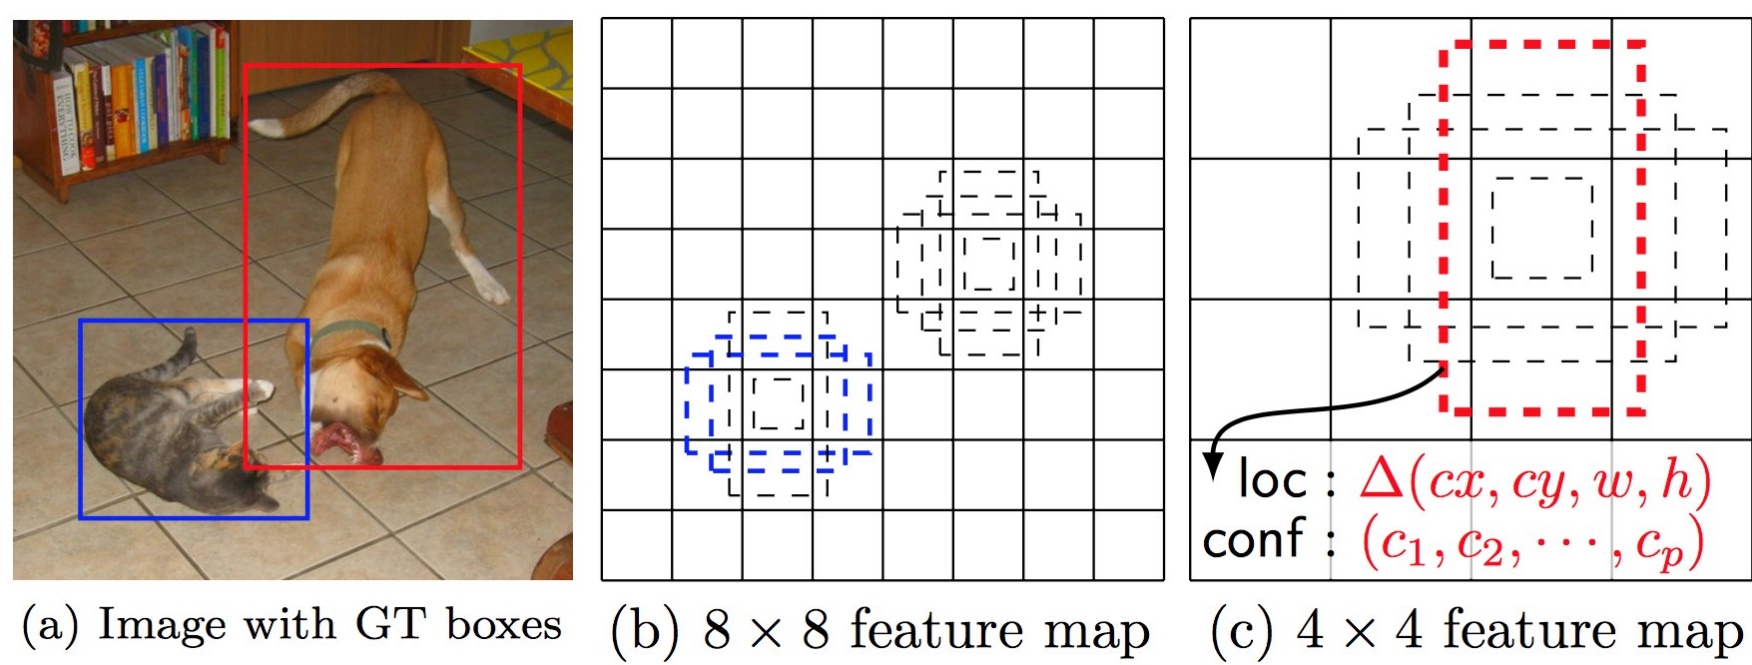


図1 SSDの概要 Liu, Wei, et al. "Ssd: Single shot multibox detector." *European conference on computer vision*. Springer, Cham, 2016.

3. 道路の損傷画像データセット

各自治体総計約**1,600km**で、**50時間分**、**16万枚**の道路画像を取得、
損傷がある画像を目視で判定。
その結果、**9,053枚**のラベル付き損傷画像を得た。




図2 データセットの統計情報

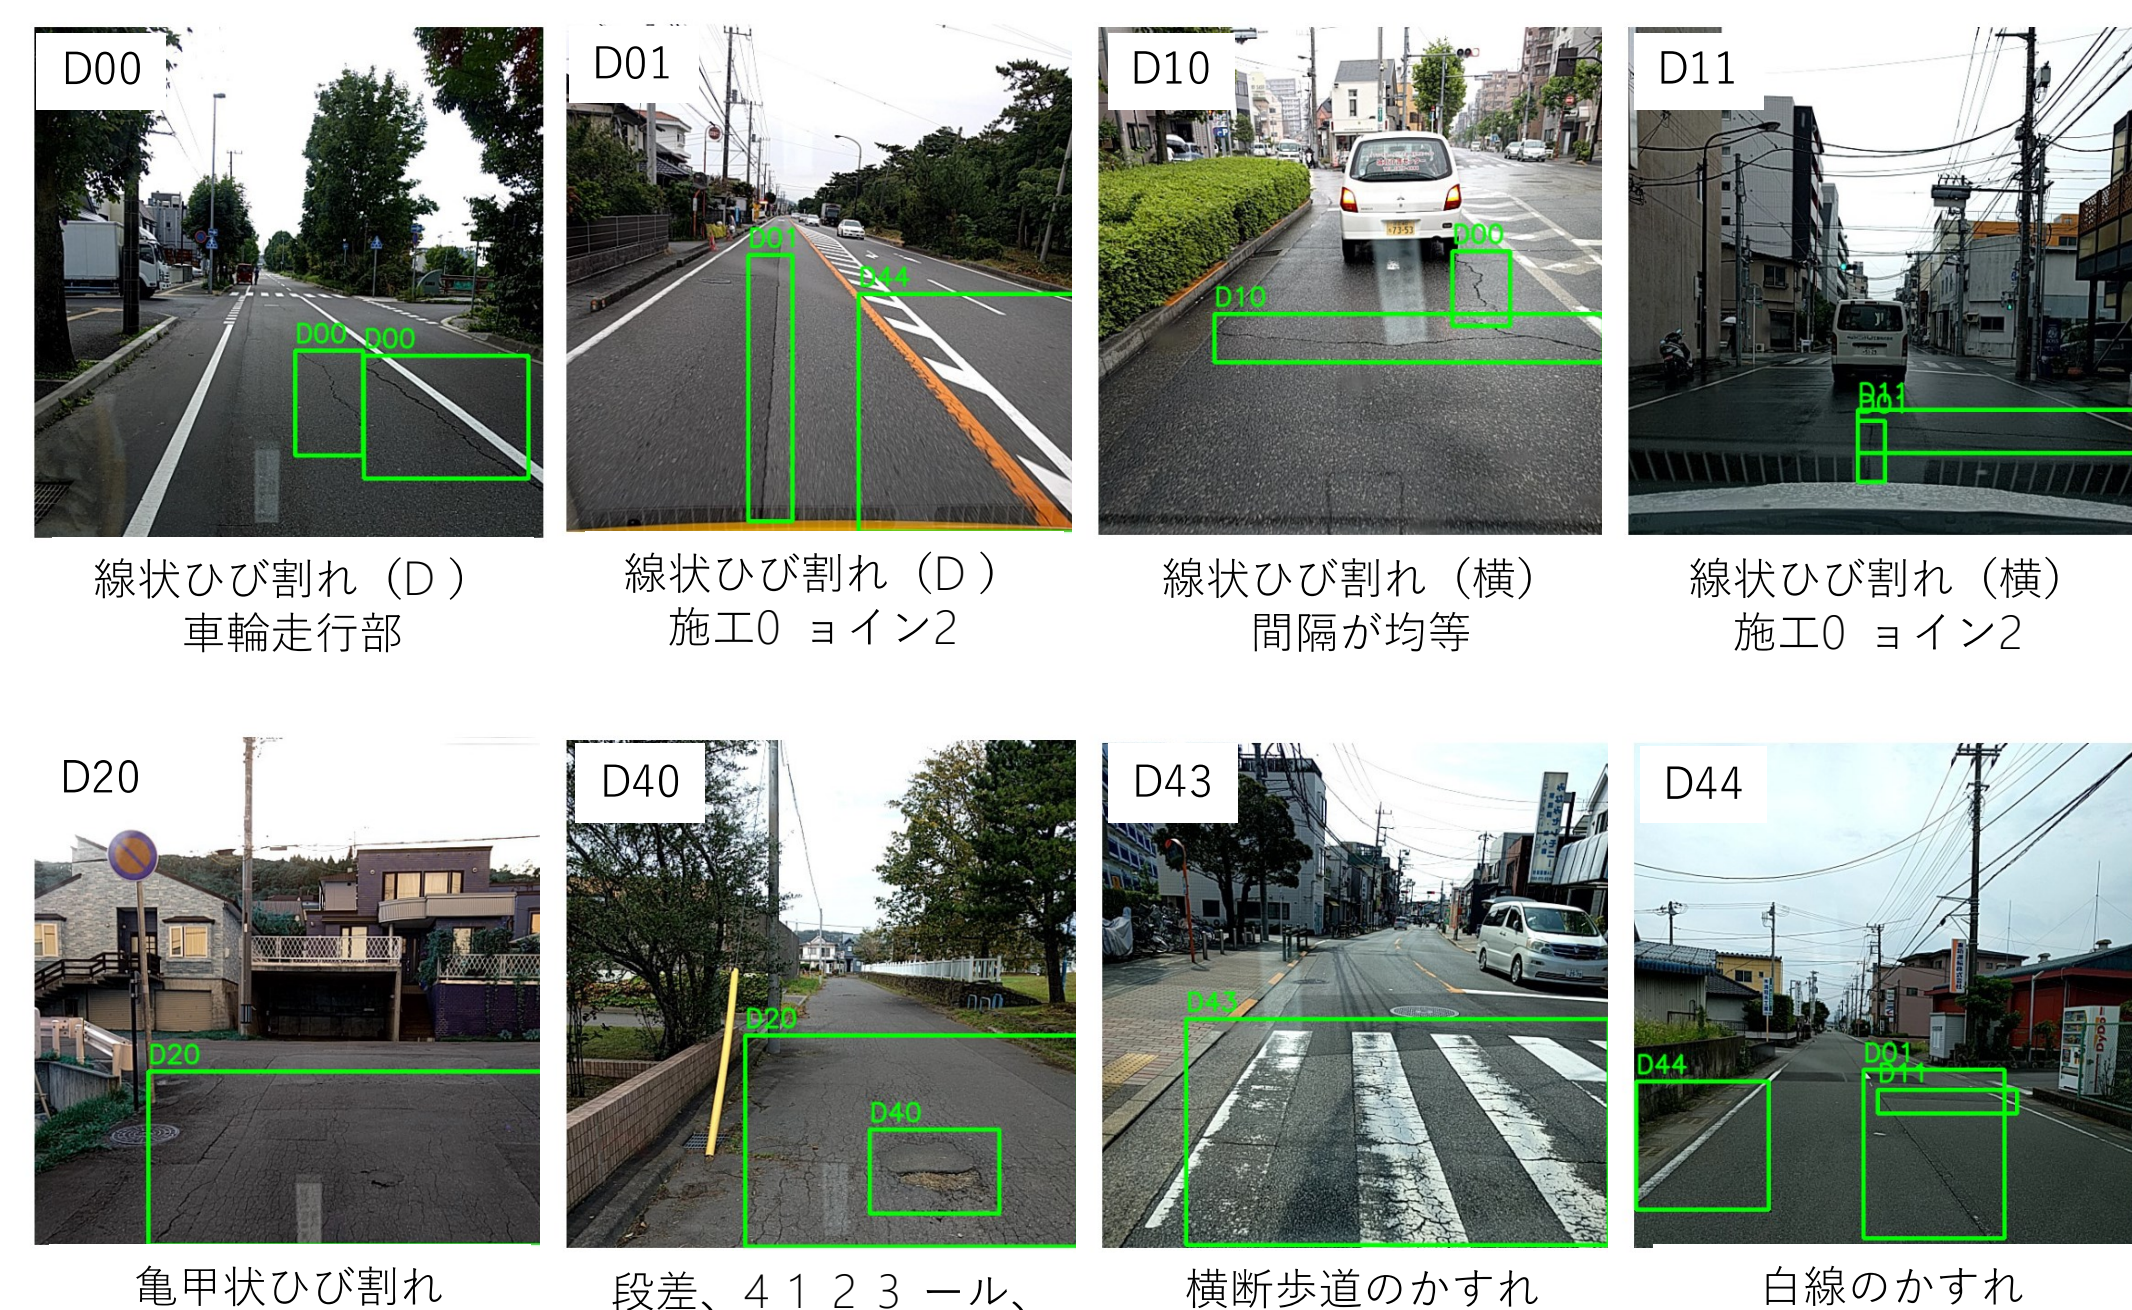


図3 損傷の定義とサンプル画像

道路損傷では世界初の大規模データセット。一般に公開している。
<https://github.com/sekilab/RoadDamageDetector>

4. 実験

0.7を超えるRecallで損傷検出できる種類もあるが、ほとんど検出できない種類もあった。

表1 損傷種類ごとのPrecision/Recall/Accuracy

	D00	D01	D10	D11	D20	D40	D43	D44
Recall	0.40	0.89	0.20	0.05	0.68	0.02	0.71	0.85
Precision	0.73	0.64	0.99	0.95	0.68	0.99	0.85	0.66
Accuracy	0.81	0.77	0.92	0.94	0.83	0.95	0.95	0.81

※3. で得た損傷を含む画像を8:2に分割し、学習と評価を行った。




図4 損傷検出例

推論の実行時間はGPUサーバー上では30.6ms、
スマートフォン上では1.5sとなった。

5. 今後の展望

- ほとんど検出できない種類は、教師データの画像枚数が不十分であるために生じたと思われる。そこで、今後はGANなどの生成モデルを用いて、不足している損傷種類の教師データ数を増やすことなどに取り組む。
- 日本国外でも今回学習させたモデルが損傷を検出できるかどうかを検証する。

6. 参考

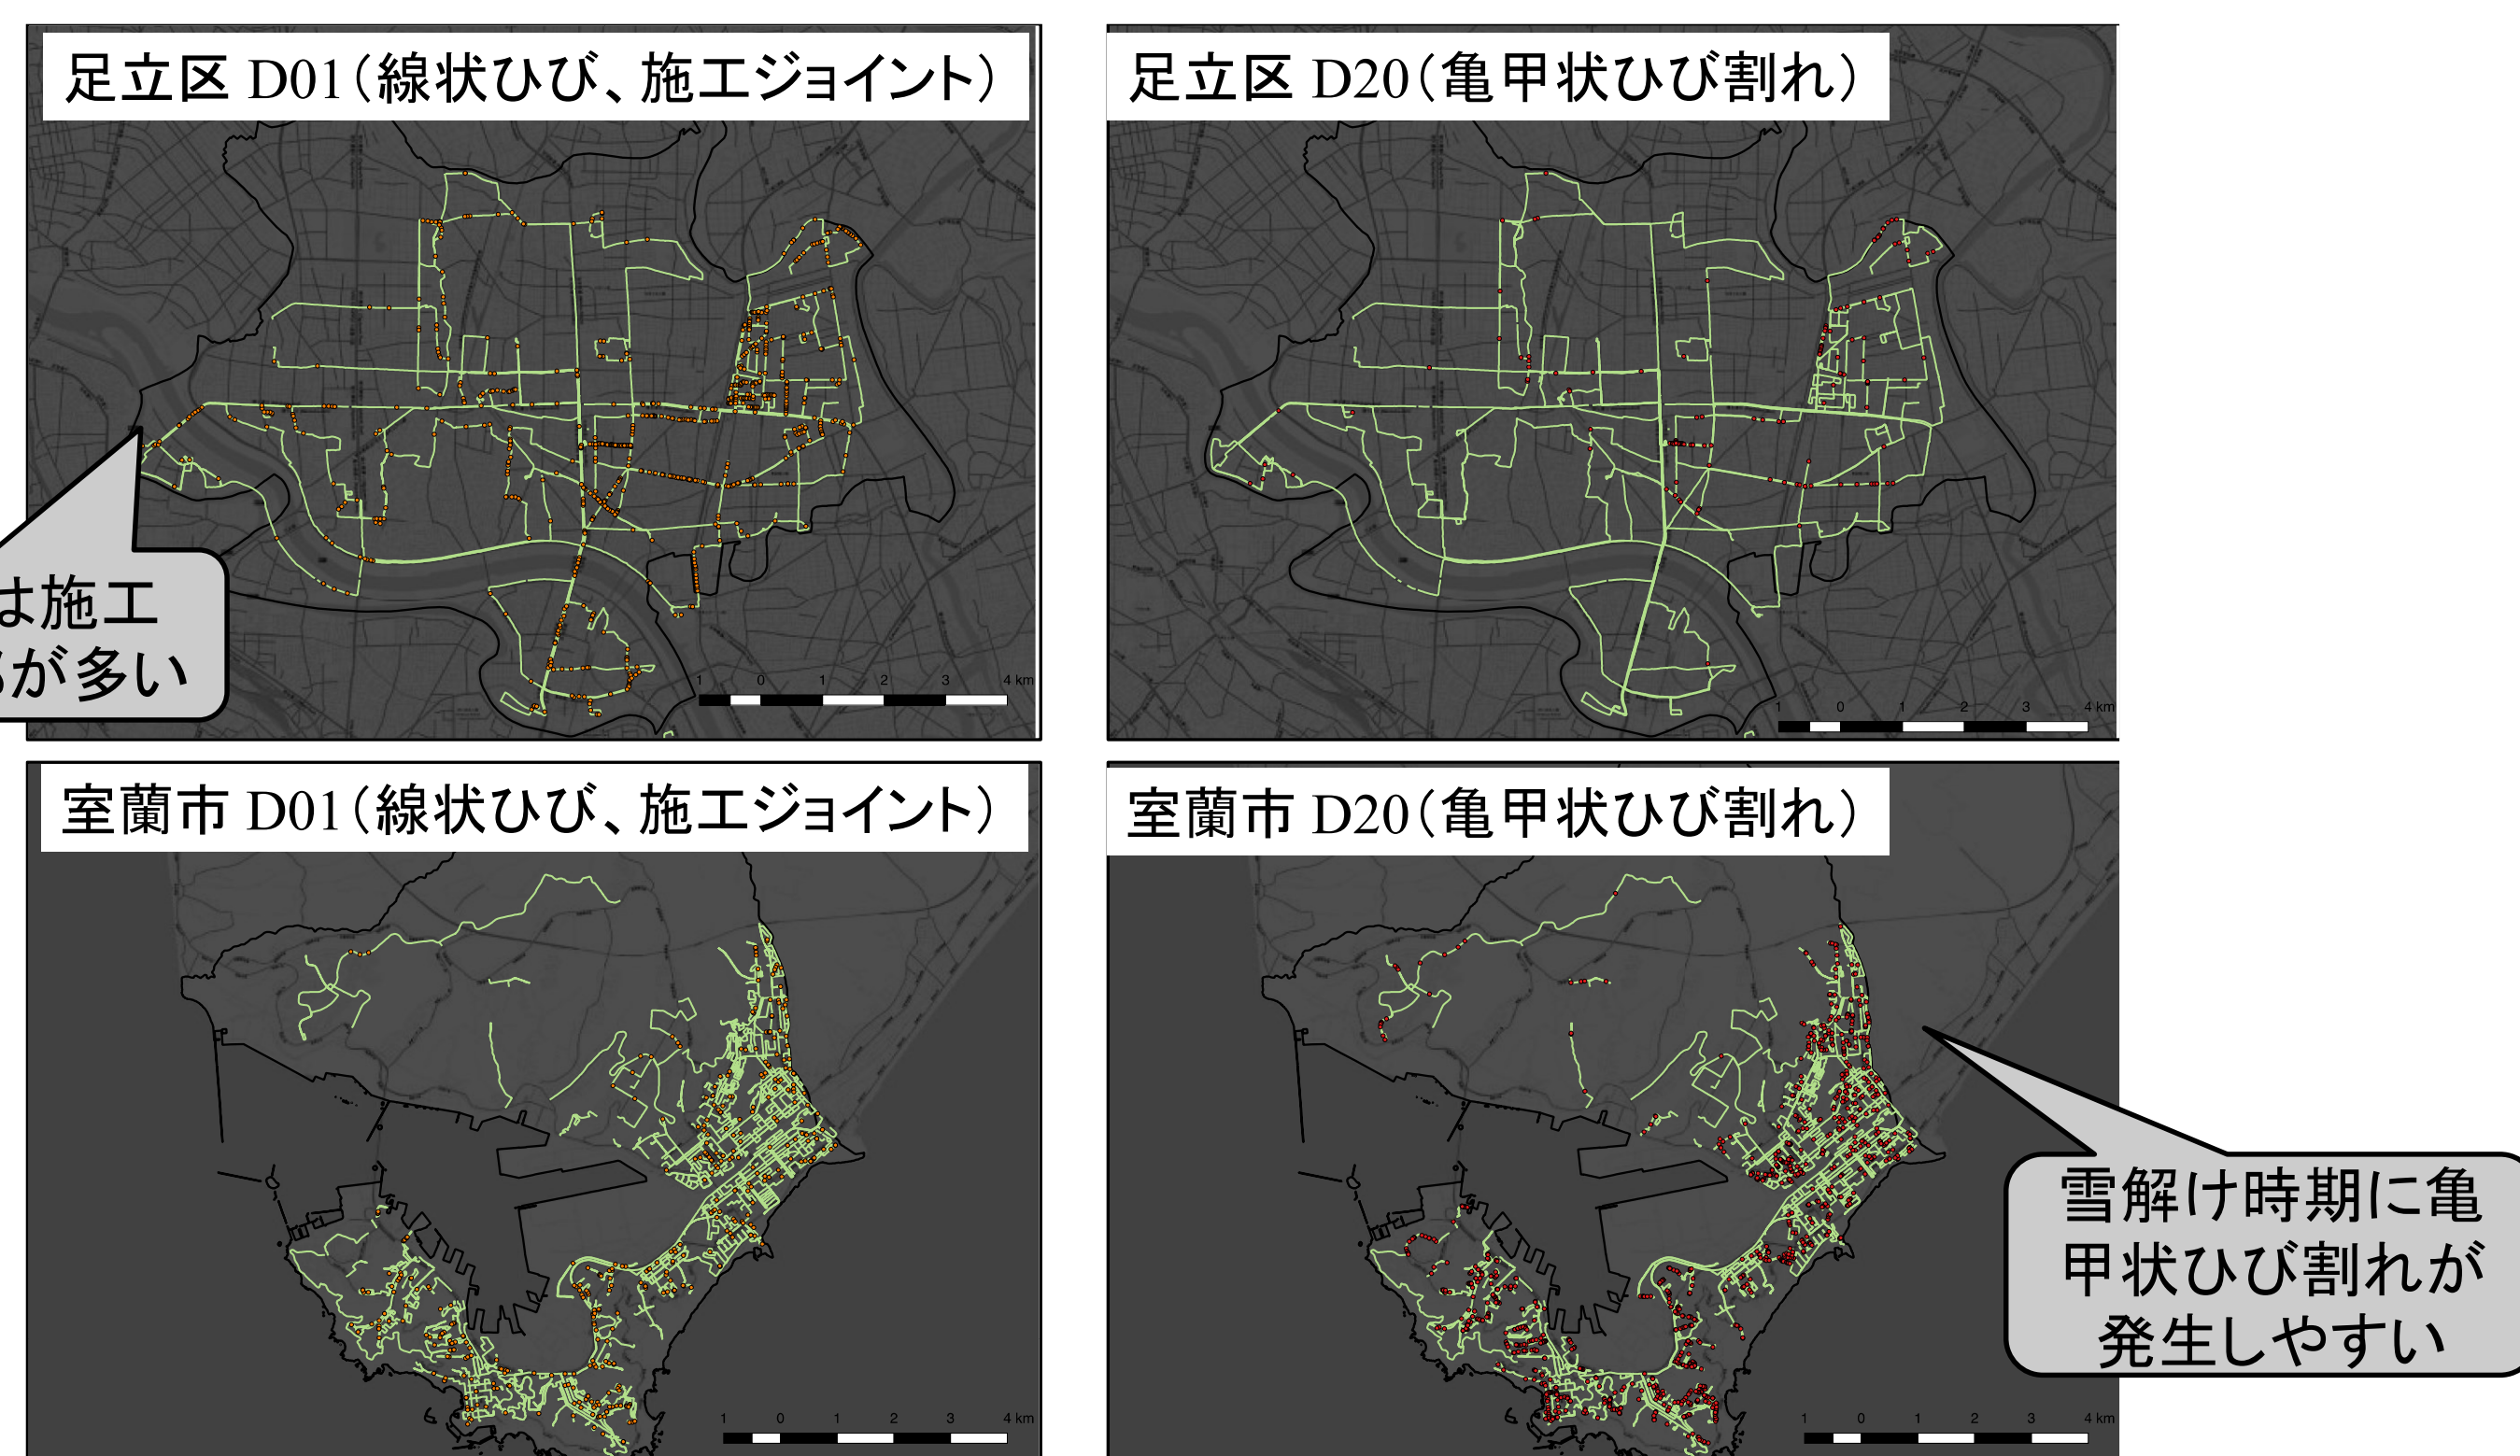


図3 各自治体における損傷箇所の分布

Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images

H.Maeda, Y.Sekimoto, T.Seto, T.Kashiyama, H.Omata

1. Background

Major disadvantages of previous road damage detection

1. No common dataset for a comparison of results
2. Many studies have been limited to the detection or classification of damage in only the longitudinal and lateral directions

2. Method

Considering the processing speed and accuracy, we used SSD with MobileNet

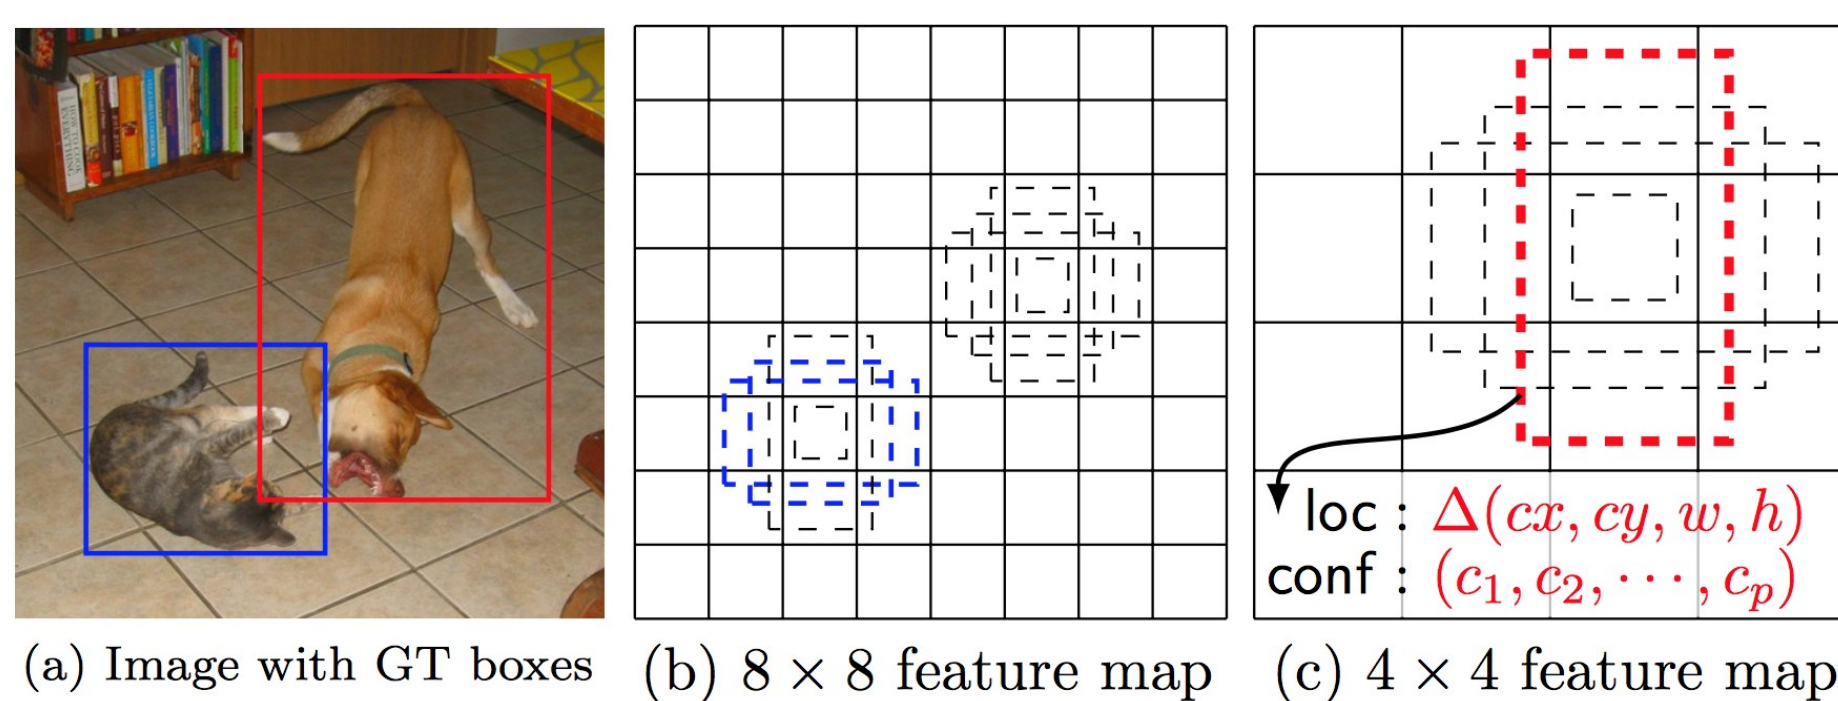


Fig.1 Overview of SSD Liu, Wei, et al. "Ssd: Single shot multibox detector." European conference on computer vision. Springer, Cham, 2016.

3. Road Damage Dataset

We traveled through every municipality covering approximately 1,500 km in total. And all the images were visually inspected and annotated. The dataset includes 9,053 damage images and 15,435 damage bounding boxes.




Fig.2 Statistics of the dataset

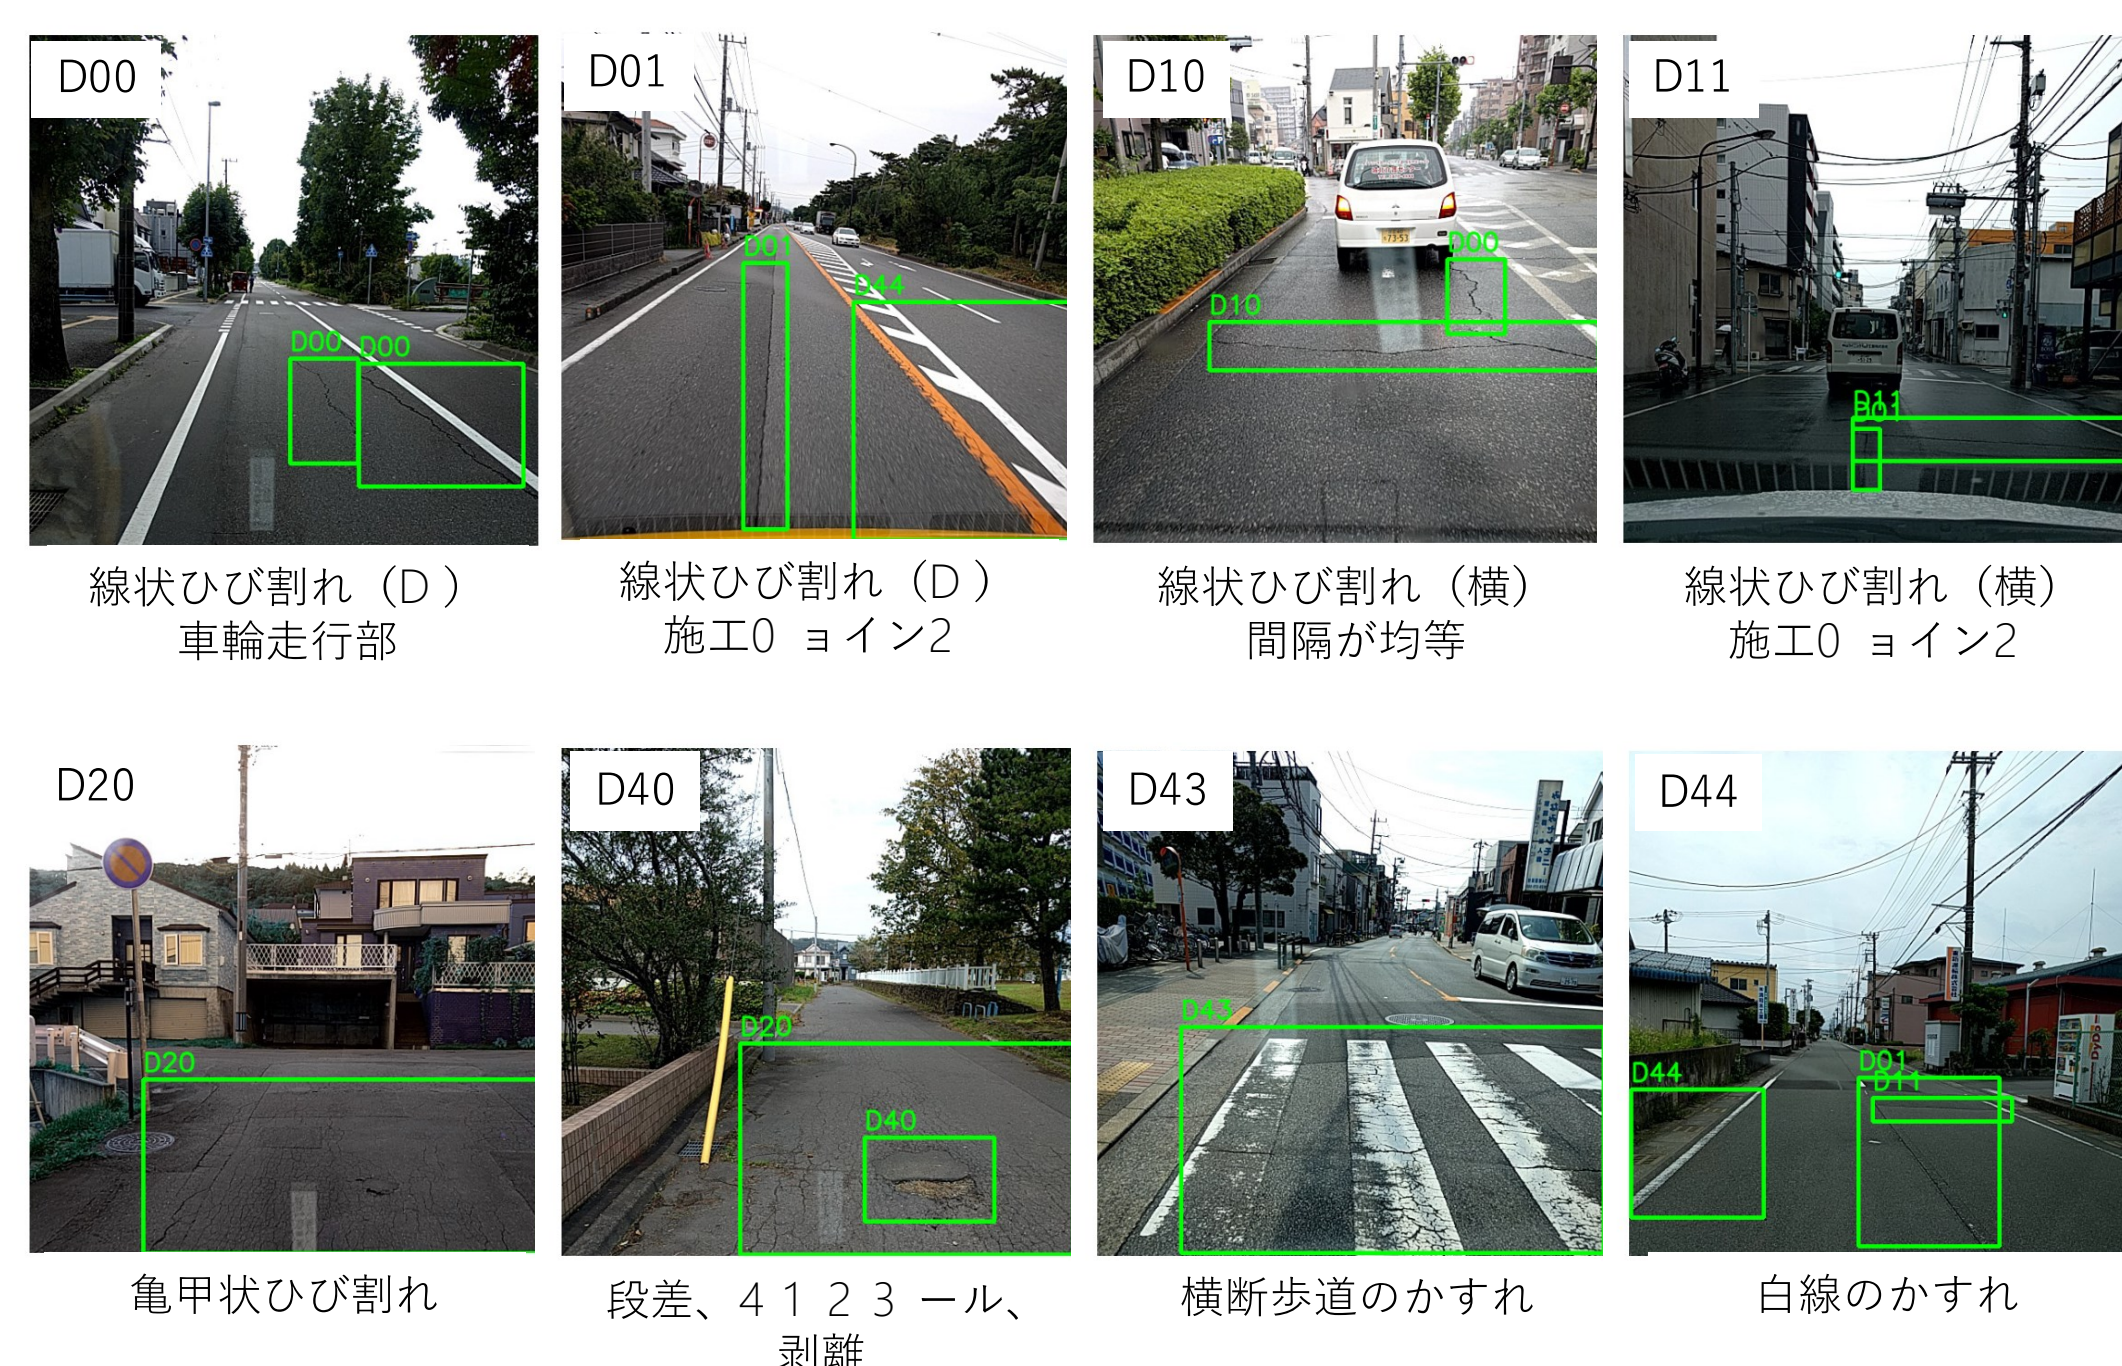


Fig.3 Definition of the damage type and sample images

All the dataset is publicly available!
<https://github.com/sekilab/RoadDamageDetector>

4. Experiment

Although D01 and D44 were detected with relatively high recall and precision, the value of recall is low in the case of D11 and D40

Table.1 Precision/Recall/Accuracy of each category

	D00	D01	D10	D11	D20	D40	D43	D44
Recall	0.40	0.89	0.20	0.05	0.68	0.02	0.71	0.85
Precision	0.73	0.64	0.99	0.95	0.68	0.99	0.85	0.66
Accuracy	0.81	0.77	0.92	0.94	0.83	0.95	0.95	0.81

※ The dataset were divided into 8:2 for training and testing.



Fig.4 Detected samples

Inference speed (ms) for one image are
 30 ms (on GPU) and 1.5 s (on smartphone)

5. Future Research

- we shall increase the amount of training data and devise the structure of a new neural network to improve the detection accuracy of categories that cannot be detected well.
- we shall determine whether a trained model can be transferable to images collected from locations other than Japan.

6. Appendix

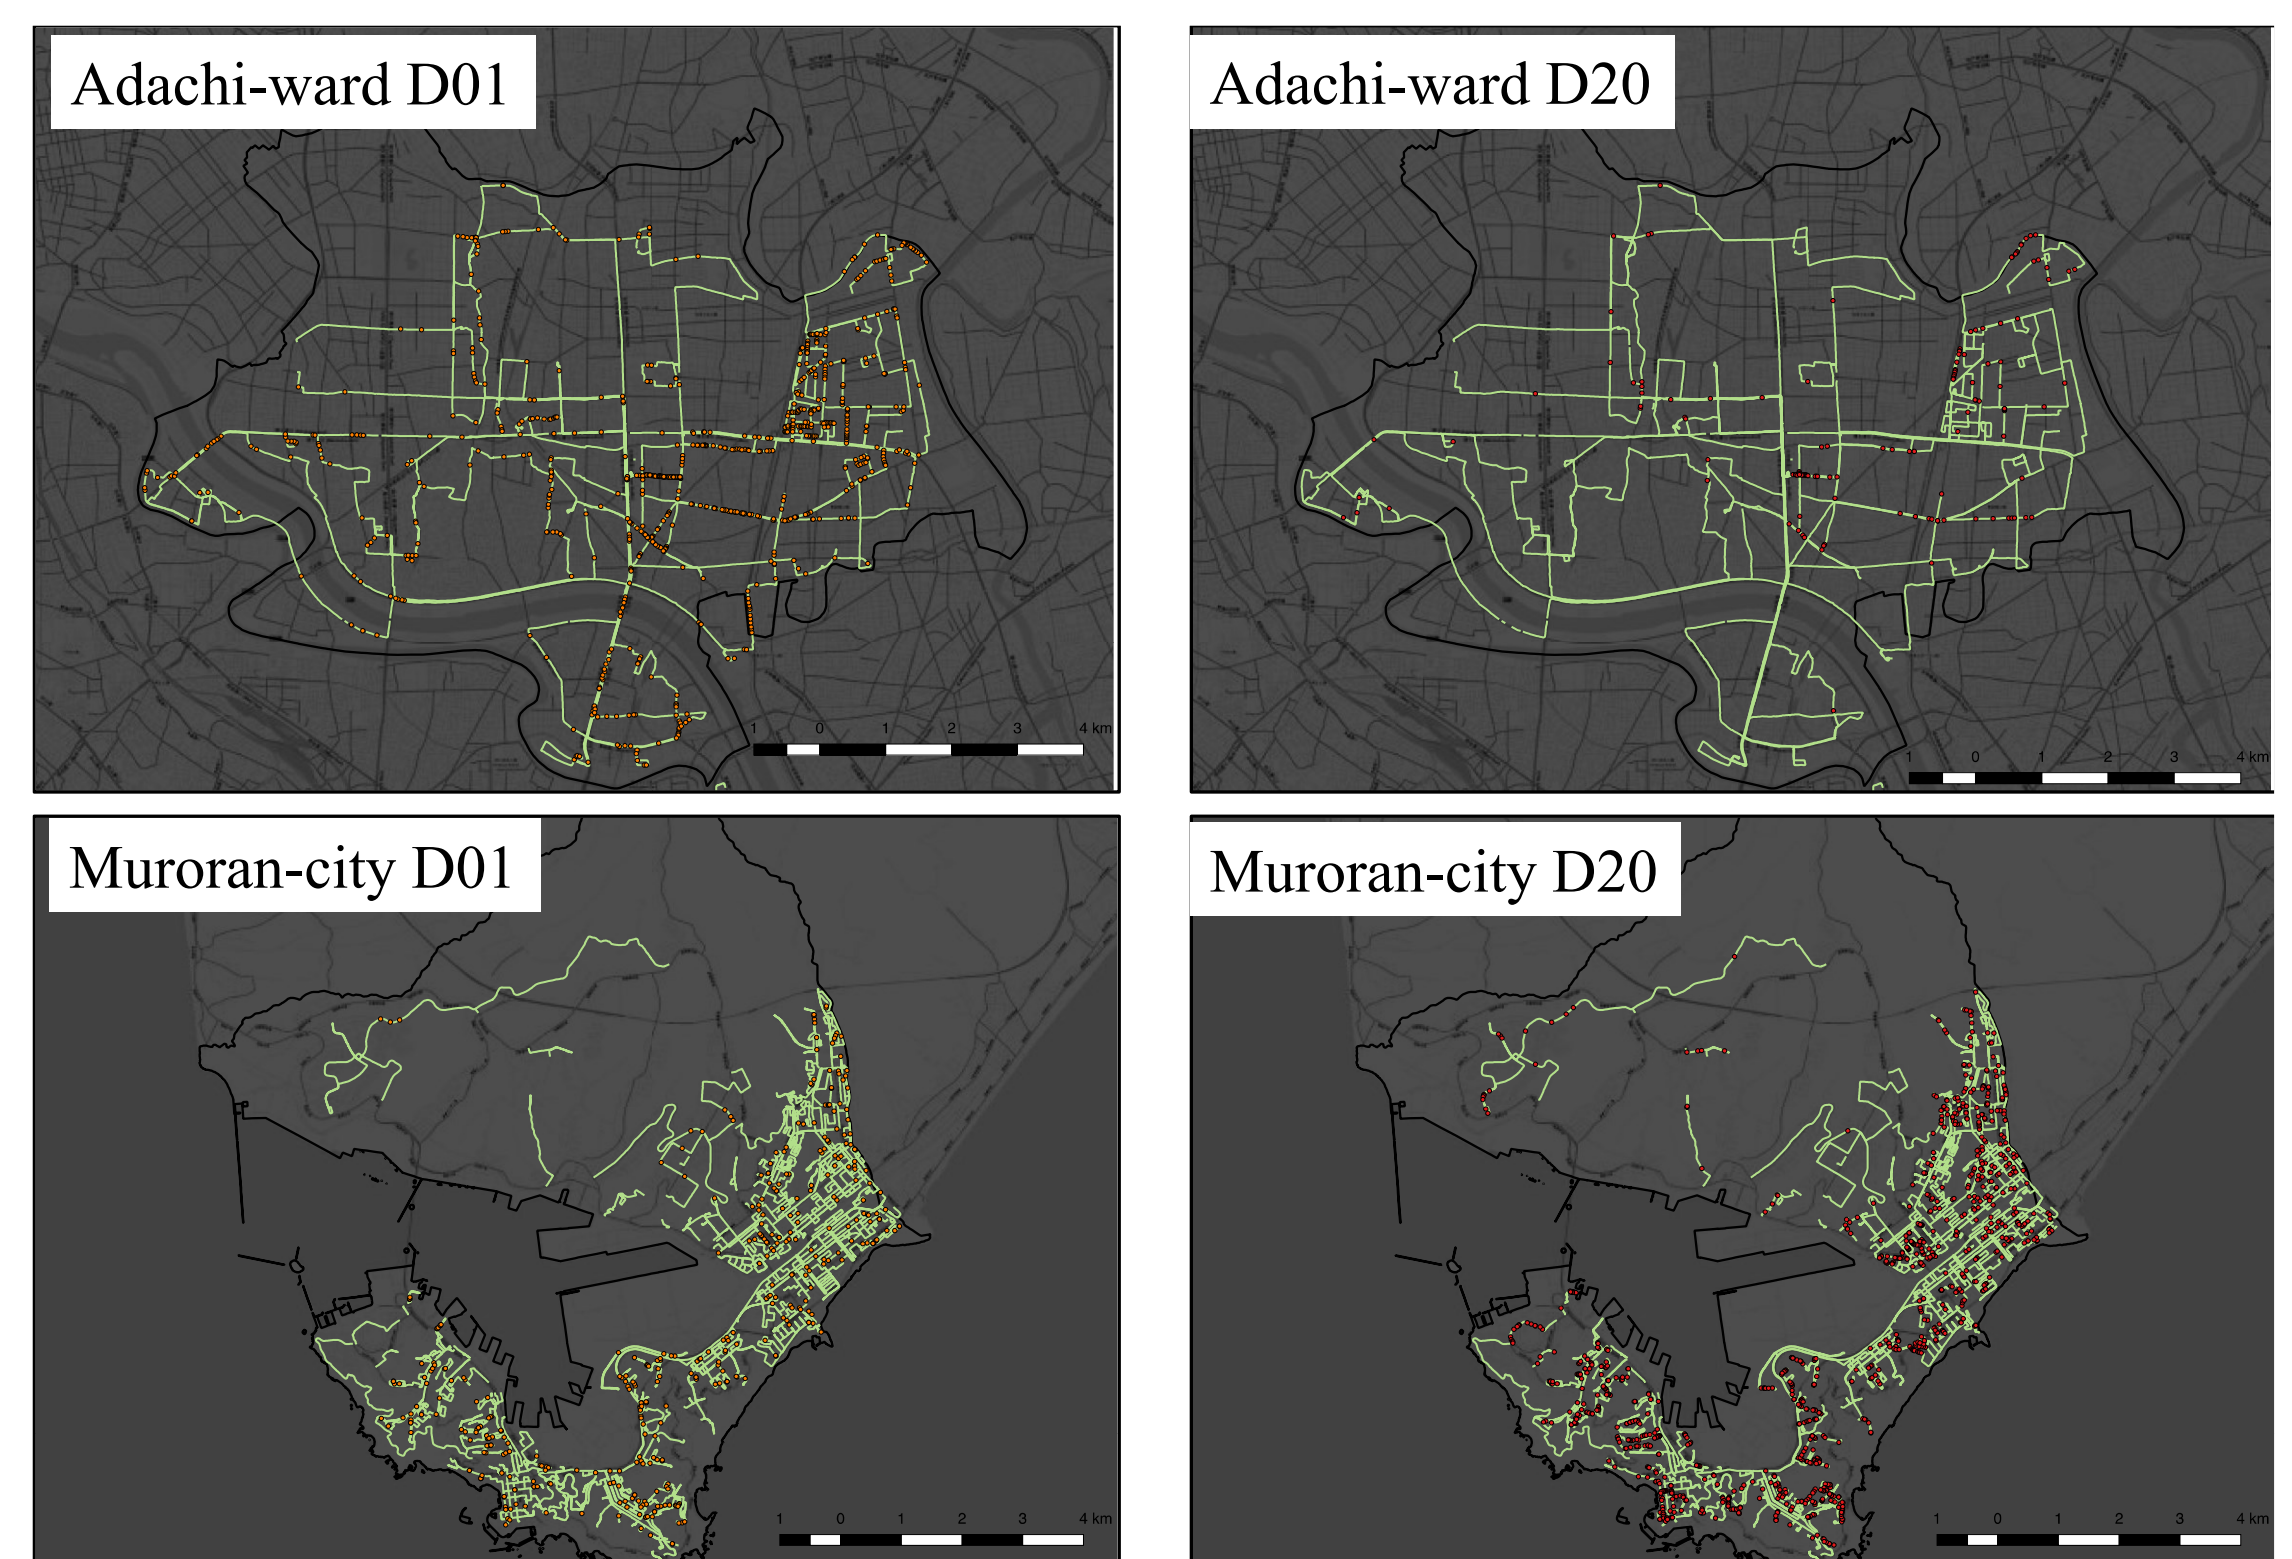


Fig.5 Distribution of the damages in each municipality