

ディープラーニング活用事例と AI x 衛星データへの期待

BizEarth勉強会
2019年11月1日

株式会社Ridge-i
執行役員 杉山 一成



ミッション

最高峰の先端技術を活用し、ビジネスの最高地点を
クライアントと共に目指す

事業領域

ビジネスニーズに最適化したAI
技術を提供

- ① AIコンサルティング・
ソリューション開発
 - 機械学習・画像系ディープ
ラーニングが中心
- ② 共同プロダクト開発
 - AI×αによる強みの相互補完
- ③ 新規事業創出支援
 - 大企業とのオープン
イノベーション

会社概要

オフィス

- 千代田区大手町
1-6-1

従業員数

- 30名
機械学習エンジニア、
コンサルタント

パートナーシップ





杉山 一成（すぎやま いっせい）

執行役員 事業開発部長

東京工業大学大学院社会理工学研究科（工学修士）を卒業。
ボストンコンサルティンググループ（BCG）に入社し、コンサルタントとして、IT・メディア、通信、エネルギー、製造、消費財などの様々な業界で、国内外のクライアント企業に対し、事業戦略立案・実行支援、新規事業開発、M&A検討支援などのコンサルティングプロジェクトを経験。その後、国内独立系のコンサルティングファームを経て、Ridge-iに参画。

Ridge-i入社後は人工知能の活用の特化したコンサルティングに従事し、製造業のクライアント企業を中心に、深層学習を活用したProjectのManagementに従事。
衛星画像解析に、深層学習を活用するProjectを複数担当。


弊社AI事例紹介

(衛星画像以外)


想定利用シーン

① 高精度でのごみ分別



解析画像



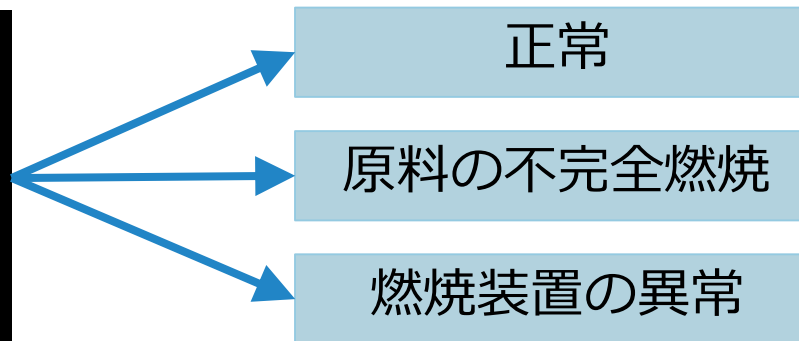
解析結果



② 高解像度での製品表面のキズ・ゆがみ検出



③ 動画でしか判定できない 燃焼状態の異常判定



白黒映像カラー化 ディープラーニング

放送実績あり



[動画はこちら](#)
(弊社HP内)

放送実績


- 「第50回 思い出のメロディー」 2018/8 NHKで放送
- NHKスペシャル「戦後ゼロ年東京ブラックホール 1945-1946」 2017/8 NHKで放送
経済産業大臣賞 VFX部門を受賞
- 大相撲「カラーで蘇る名勝負」 2017/5 NHKで放送

高精度でのごみ分別

荏原環境プラント株式会社様と共同開発：セグメンテーション活用



ごみ焼却炉イメージ図



＜クレーン操作室＞



＜燃烧状態を監視する中央操作室＞

課題と目的

従来の自動運転では投入するごみ質の変動が大きく、安定した燃烧ができない




ごみの質をピクセル単位で認識することに成功

熟練オペレータのノウハウを再現し、既に自治体で稼働中


ごみ焼却施設における AI(人工知能)活用

[動画はこちら](#)
(弊社HP内)

高精度でのごみ分別 ピクセル単位で物の識別が可能



高精度でのごみ分別 ピクセル単位で物の識別が可能



不良検知の課題 不良は定義が難しい、数がすくない、アノテーションが難しい 等

良品学習

- 良品画像のみ学習し、良品特徴を学んだ“良品画像のみ”を生成可能なディープラーニングを作成

良品画像で学習



良品画像生成DL


様々な手法が存在
**Ridge-iでは、未公開の
独自手法を開発**

**高解像度化・高精度を
実現**

不良部位 検出

- 検査画像とDLが生成した画像を比較し、ピクセル単位で不良部位を検知・可視化


検査画像



良品画像
生成DL




生成画像



比較

不良部位




異常検知技術を災害検出に使えるのではないか？

AI x 衛星データ


弊社事例紹介

レーダー画像(ALOS PALSAR)



- ルールでは波とオイルは分類困難
- 読み解けるのは一部のエキスパートのみ

AIによる解析



数枚の画像で学習

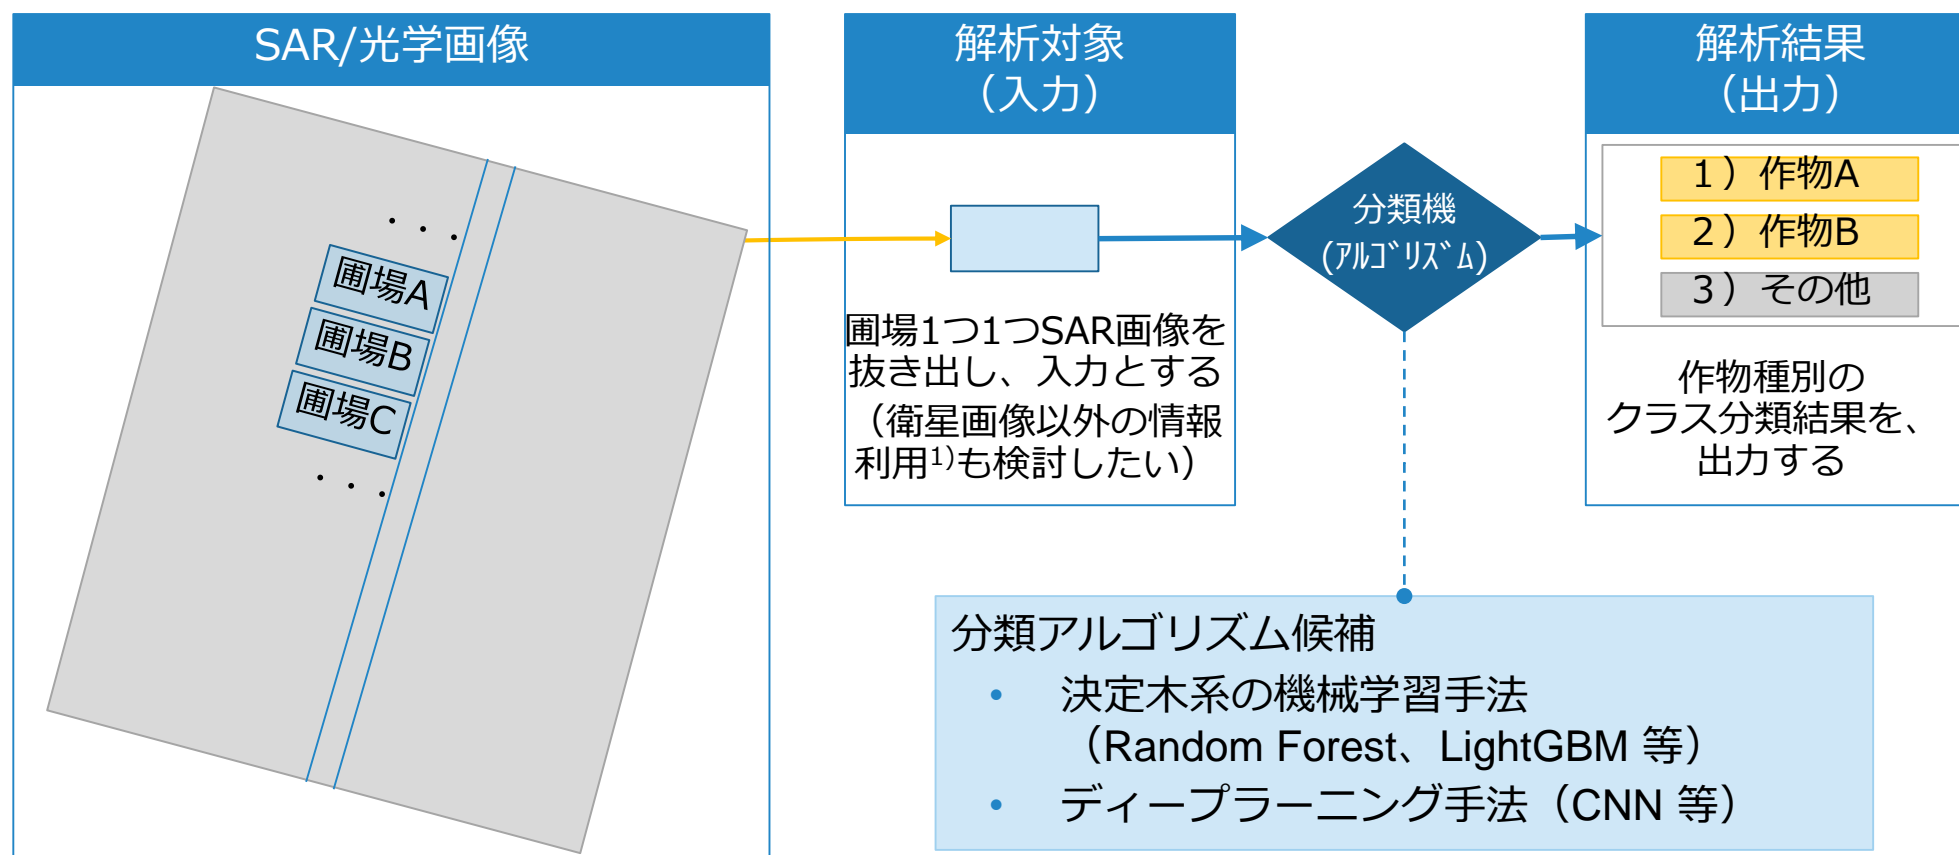
- AIの活用により、オイルスリック（油膜）があるエリアを100%の精度で特定

衛星画像に対するディープラーニングによる解析の普及活動に参画

AI x 衛星データ事例（2）

SAR及び光学データを用いた圃場の作付種別分類

衛星画像（SAR 3M、光学6.5M）を活用し、圃場別の作物種別の分類を行った




1. 付加情報候補：緯度、経度、車道に面しているかどうかのフラグ


AI x 衛星データ事例（3）

航空写真を利用した車検知事例

- 解像度15cmの航空画像を、解像度30cmに粗くして、車検知のモデルを学習
- 解像度30cmの衛星画像に対して、本モデルの解析を試行中（社内R&D）



北海道胆振東部地震により土砂災害が発生した地域を、 ディープラーニングで効率的に検出したい



■ 衛星の種類

SPOT 6

地上分解能（直下視）

パンクロ：1.5m

マルチスペクトル：8m

観測波長帯域

パンクロ： 0.455 – 0.745 μ m

マルチスペクトル：

Blue： 0.455 – 0.525 μ m

Green： 0.530 – 0.590 μ m

Red： 0.625 – 0.695 μ m

NIR： 0.760 – 0.890 μ m

観測幅（直下視） 60km

■ 土砂崩れエリアの正解データ

正射画像判読図：国土地理院判読（航空画像利用）

①セグメンテーション

※ピクセル毎にラベル付けするディープラーニング

②異常検知ディープラーニング

③画像単位で分類するディープラーニング

①

セグメンテーション

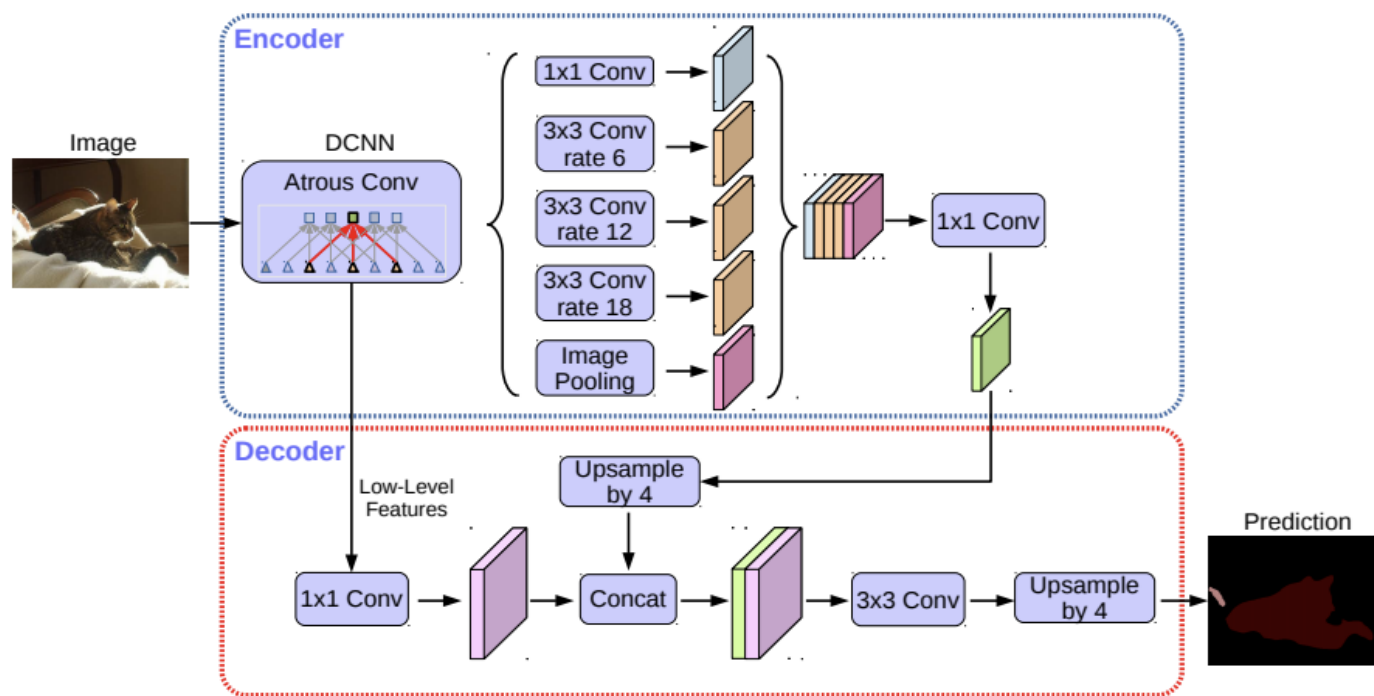
手法①： 解析手法：セグメンテーション

データセット

- 20,000x18,957の元画像に対して、土砂崩れ部分をアノテーション
- 256x256のグリッドに分割して学習および推論を行う

ネットワーク

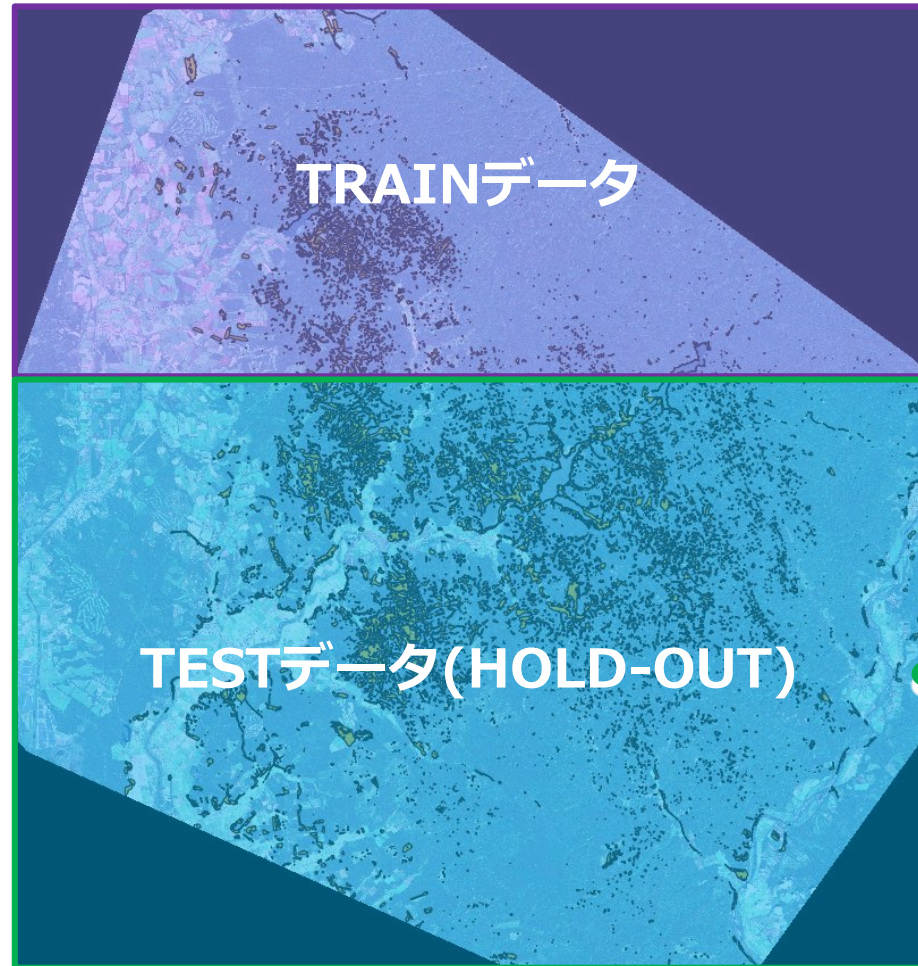
- DeepLab v3+によるセマンティックセグメンテーション



Dataset	Samples
TRAIN データ	3,000
Validation データ	500
TEST データ	2,050

手法①： TRAIN・TESTデータ (HOLD-OUT) の範囲

元データを、2分割し、TRAINデータとTESTデータ(HOLD-OUT)に分割


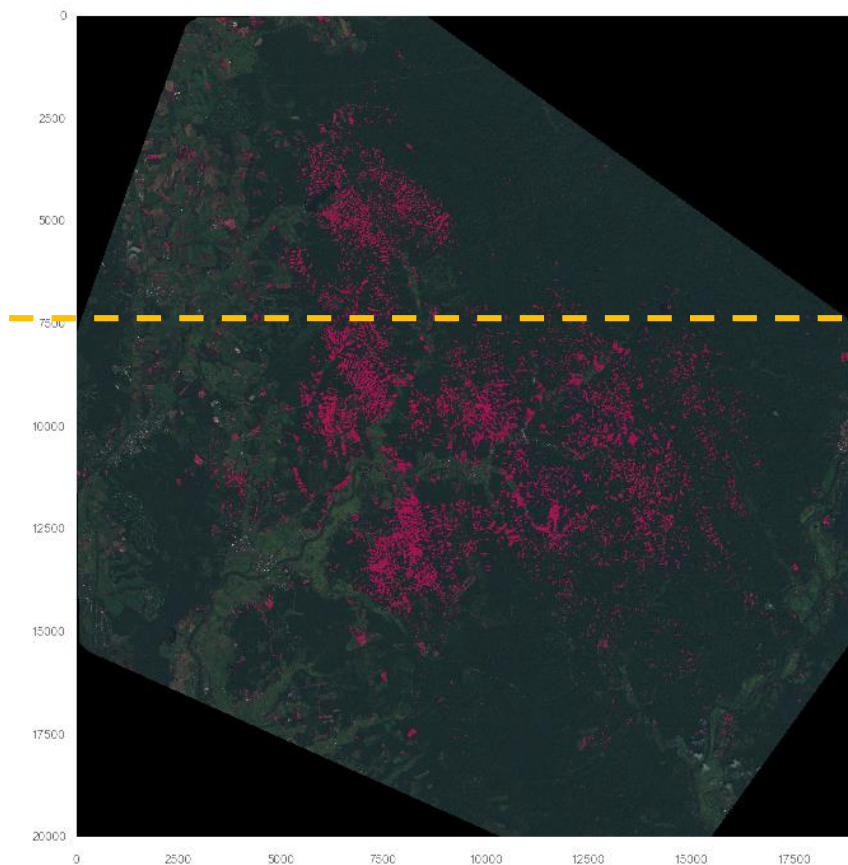


元データのうち、TRAINデータと重複しない部分をTESTデータ(HOLD-OUT)して利用

手法①： 定性評価（全体）

Prediction

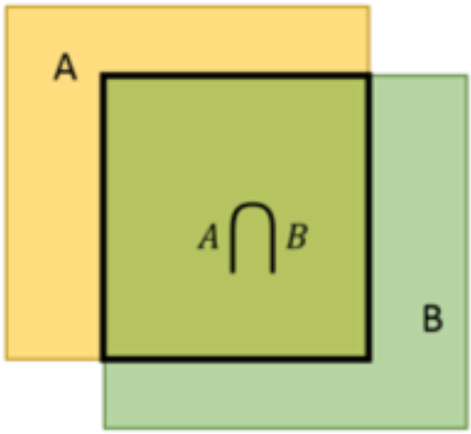
Ground truth



手法①： 定量評価 (1)

- Mean IoUによって評価

Ground Truth



Prediction

$$IOU_{AB} = \frac{A \cap B}{A + B - A \cap B}$$

Dataset	Mean IoU
TRAINデータ	83.90%
TESTデータ	81.05%

Mean IoU 約80%の精度で正しく認識

手法①： 定量評価 (2)

検知したもののうち、何%が正解か?
Recall = (1 - 誤検知率)

正解の何%が検知できているか?
Recall = (1 - 未検知率)

DataSet	Accuracy	F1	Precision	Recall
TRAINデータ	97.41%	65.93%	72.79%	60.25%
TESTデータ	98.14%	62.82%	68.31%	58.15%

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

Recall 約60%の精度で土砂崩れの地域を正しく検出

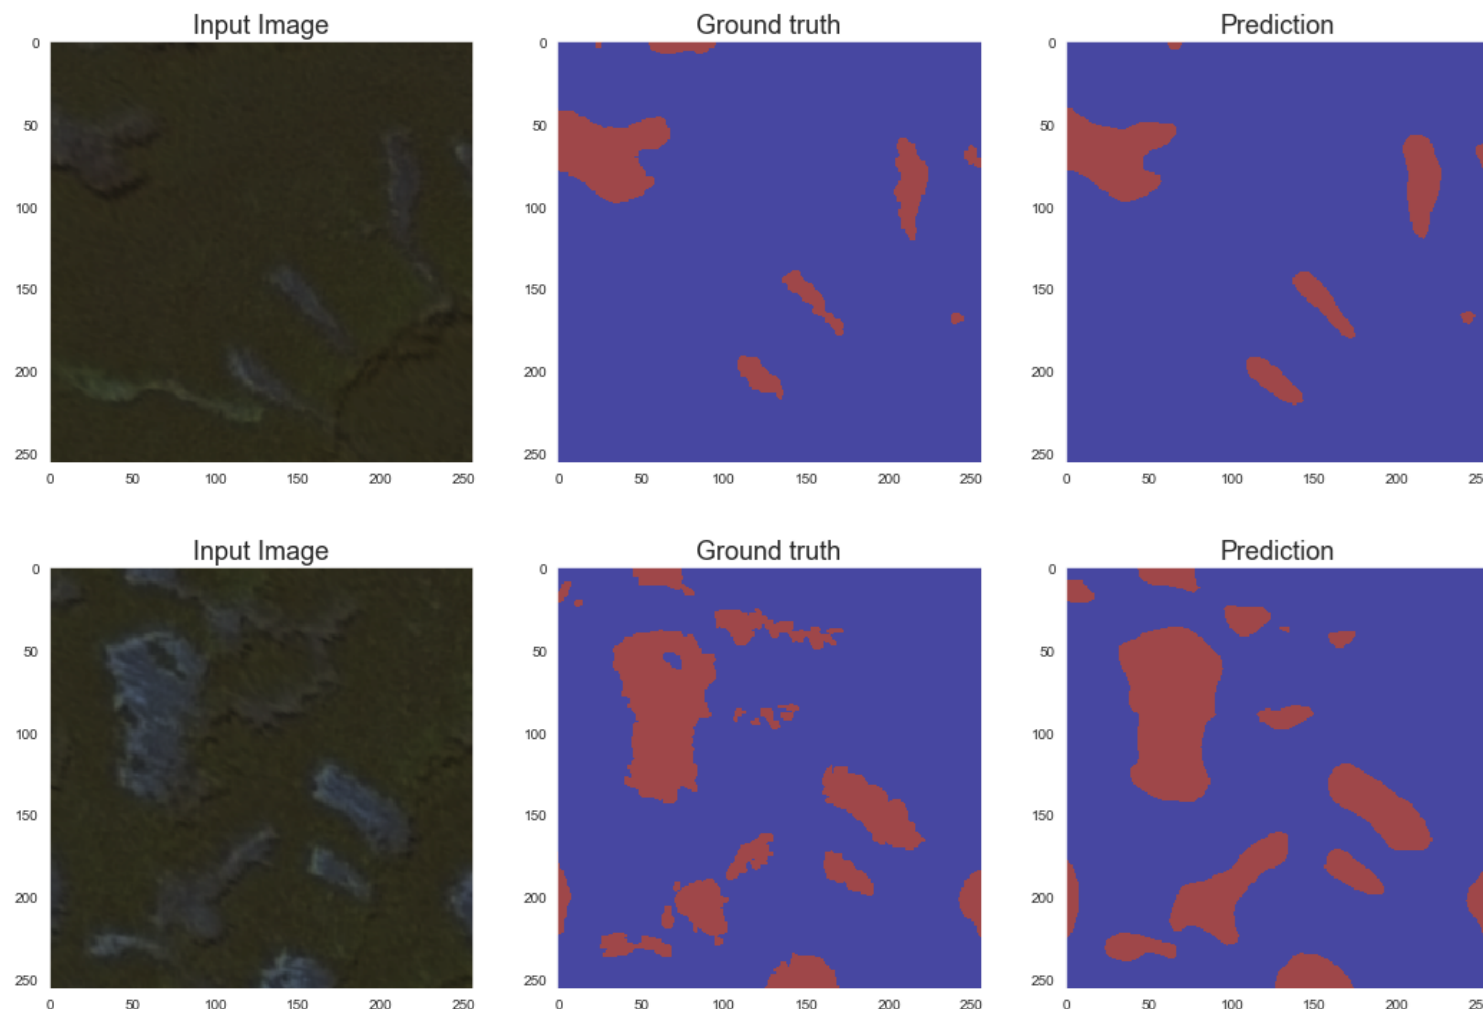
手法①： 定性評価（詳細）

定性評価

- 概ね良好に検出できている
- ピクセル毎に判断できるのでより微細な測定が可能

今後の予定

- 北海道胆振東部地震の土砂崩れは大規模かつ視覚的にわかりやすく、技術的には難易度が低い事例
- SARデータも用いた精度の向上




②

異常検知DL

良品画像として、災害のない部分の衛星画像を活用


学習

- 良品画像のみ学習し、良品特徴を学んだ“良品画像のみ”を生成可能なディープラーニングを作成
良品画像で学習




検出

- 検査画像とDLが生成した画像を比較し、ピクセル単位で不良部位を検知・可視化




今回の手法




手法②： 対象エリアの画像

Input

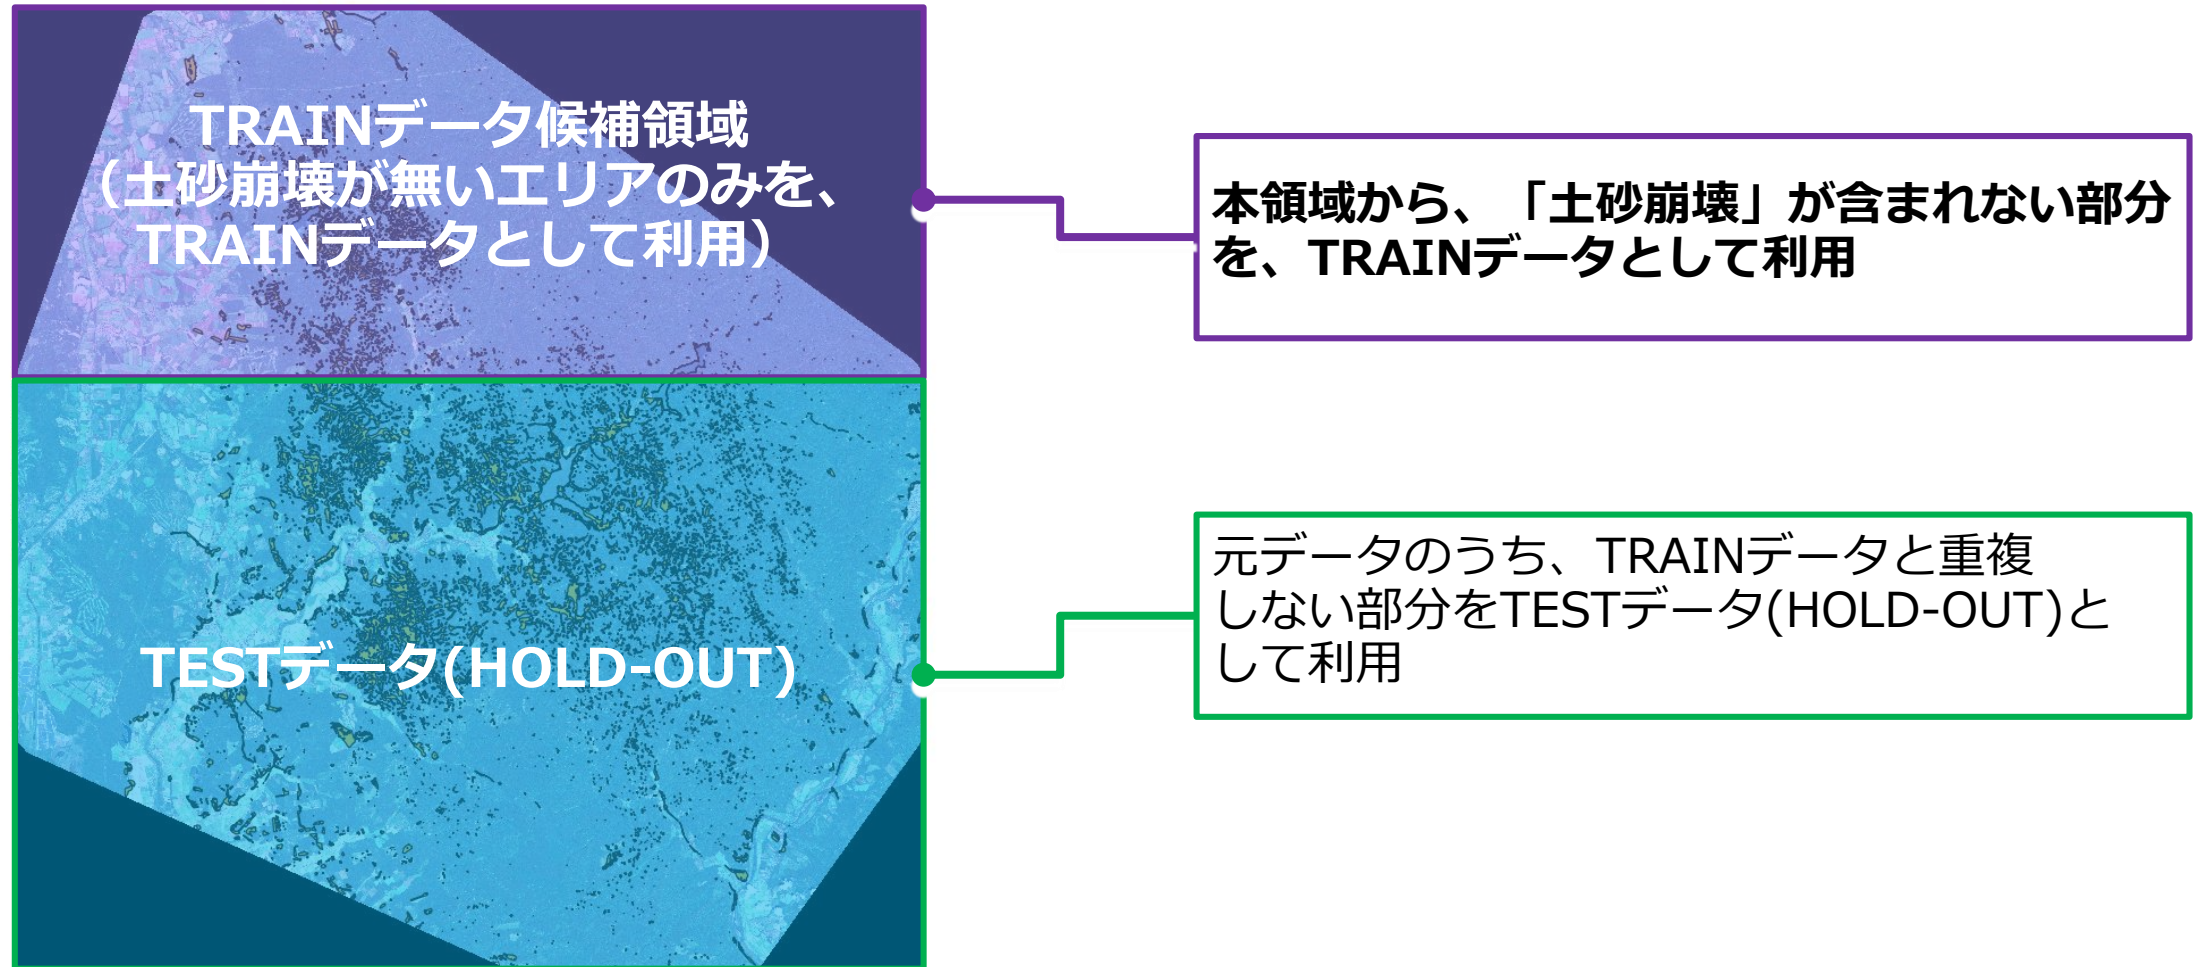


Ground truth



手法②： TRAIN・TESTデータ(HOLD-OUT)の範囲

元データを、2分割し、TRAINデータとTESTデータ(HOLD-OUT)に分割



手法②： 定性評価（閾値設定：平均値）


定性評価

- 未検知は少なく、概ね検知できている様子
- 誤検知は、セグメンテーションと比べると若干多いように見える
 - 地震前の土砂崩れにも反応しているように見える


今後の予定

- 地震前と後それぞれで解析を行い、解析結果の差分を取ることで、今回発生した土砂崩れを検知する

Prediction



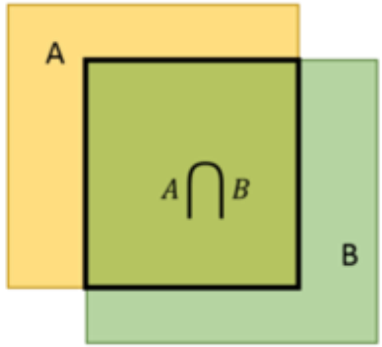
Ground truth



手法②： 定量評価（1）（閾値設定：平均値）

- Mean IoUによって評価

Ground Truth



Prediction

$$IOU_{AB} = \frac{A \cap B}{A + B - A \cap B}$$

Dataset	Mean IoU
TRAINデータ	NA
TESTデータ	72.09%

Mean IoU 約70%の精度で正しく認識

手法②： 定量評価（2）（閾値設定：平均値）

検知したもののうち、何%が正解か？
Recall = (1 - 誤検知率)

正解の何%が検知できているか？
Recall = (1 - 未検知率)

DataSet	Accuracy	F1	Precision	Recall
TRAINデータ	NA	NA	NA	NA
TESTデータ (HOLD-OUT)	92.26%	57.42%	64.40%	52.76%

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$


$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$


Recall 約50%の精度で土砂崩れの地域を正しく検出

手法②： (参考) 閾値別の推論結果


Prediction (平均値x0.75)



Prediction (平均値)



Prediction (平均値x1.25)



設定の変更によって、過検出の程度を一定コントロール可能か


手法②：

(参考) 異常検知手法による雲の検知：定性評価（閾値設定：平均値）


九州北部x
異常検知

 Ridge-i

Prediction



Ground truth



雲も含めて、土砂崩れと判定してしまっており、誤検知は多い。
土砂崩れは、概ね検知できているように見えるが、定性では評価しきれない


③

画像分類DL

手法③： グリッド型分類



- 各グリッドに対して、ニューラルネットワークによる2値分類を行っていく
- 実際はより小さなグリッドに分割した上で推論



手法③： グリッド型分類

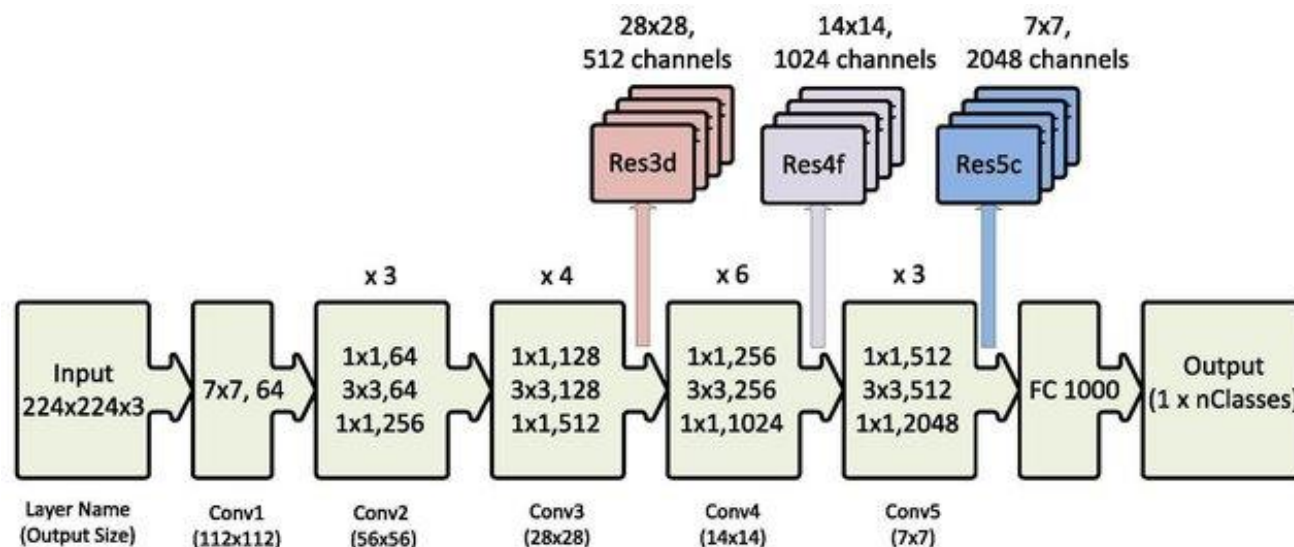
データセット

- 20,000x18,957の元画像を64x64のグリッドに分割
- 各グリッドに対して土砂崩れの有無をアノテーション

Dataset	Number of Samples
TRAINデータ	11,914
Validationデータ	723
TESTデータ	79,715

ネットワーク


- Convolutional Neural Networks (CNNs)による2値分類
- アーキテクチャはResNet50
- 損失関数はBinary Cross Entropy




手法③： グリッド型分類 定性評価

- 概ね良好に検出できている

Prediction



Ground truth



手法③： グリッド型分類 定量評価

DataSet	Accuracy	F1	Precision	Recall
TRAINデータ	93.5 %	66.3%	57.2%	78.8%
TESTデータ (HOLD-OUT)	89.0 %	66.0%	54.2%	84.6%

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

Recall 約85%の精度で土砂崩れの地域を正しく検出

土砂解析DL まとめ

①セグメンテーション

Mean IoUは58%だが、発生地点の補足としてはほぼ100%。
局所的に精緻な情報が欲しい場合に有効。目的に合わせた改良余地あり

②異常検知ディープラーニング

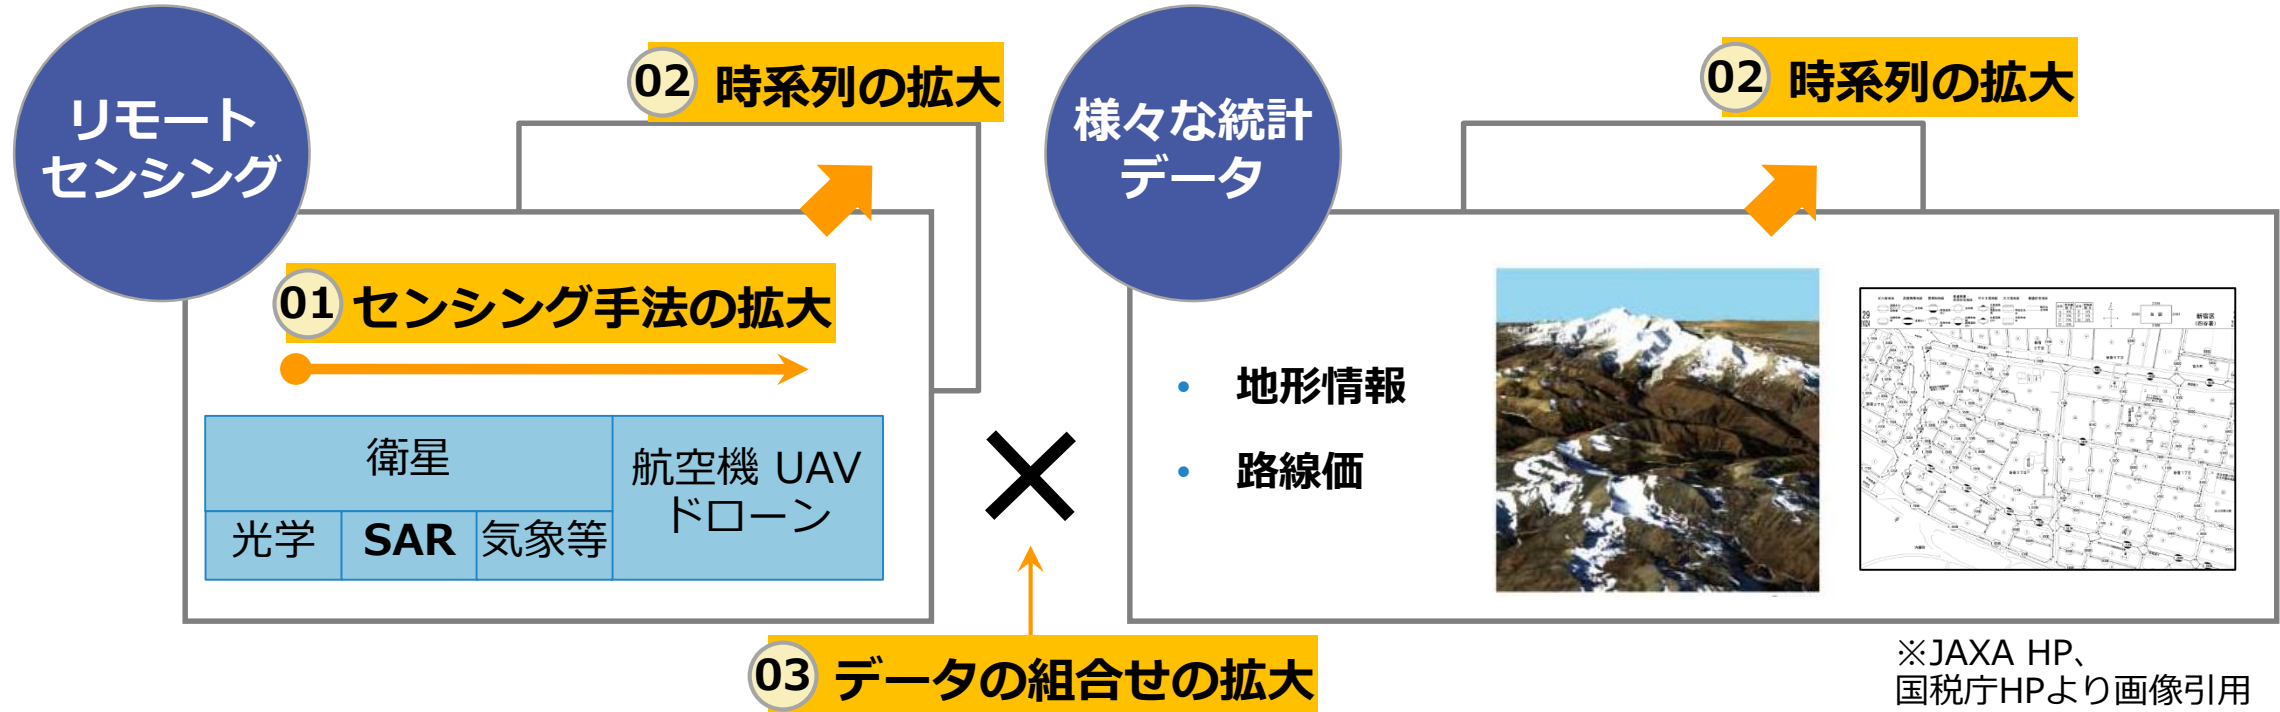
50%程度と精度は低く、使いこなしにはまだ工夫の余地あり
平常時の画像による学習が可能のため、発生直後に様々な災害を検出できる可能性に期待

③画像単位で分類するディープラーニング

84%と最も精度は高い
大域的に発生個所を特定するのに有効

目的に合わせて、複数の手法を組み合わせることが重要


AI × 衛星データ活用 今後の期待



- ✓ 定点でできること： 土砂災害の発生地域の迅速な解析
- ✓ 組合せでできること： 災害地域の被害額の測定、土砂災害発生確率と地形の因果関係
- ✓ 時系列でできること： 災害発生地域・変化地域を異常検知による自動検出

時系列・組合せから新しい知見を取り出すのに AIは有効

(ご参考) ALOS-3 なら災害の詳細把握が可能



車1台が見分けられる



津波による車両・船の散乱状況が
わかる



木々の間の歩道が見える



裏山の崩落、道路の損害を観測可能



建物が1件ずつ見分けられる



被災区域のいち早い判定が可能

(参考) Pleiades 0.5m分解能

※RESTEC HPより

AI・ディープラーニングを活用する事のメリット

- ・ 衛星データを利用すると、迅速・広範囲・精緻な物体検出・状態把握が可能に
- ・ SARのような、人目での解析が難しい対象には、AIはより有効では
- ・ 時系列および衛星以外のデータとの組み合わせで威力を発揮

今後の予定

- ・ ディープラーニングの汎用性検証（対象地域の拡大、類似事例への展開）
- ・ SARを活用した検証の継続
 - 複数チャネルを統合する前処理、光学データとの位置合わせの効率化
 - 細部の精度改善の検証、SARデータでのみ観測できるデータへの適用（例：地盤沈下、水分量、曇天への対応）
- ・ 事前学習した検出モデルによる、迅速な検出（例、災害発生時）
など、やるべきこと多数

■論文

本報告中の土砂崩れ検知に関する論文は、以下にて公開中

“Large-Scale Landslides Detection from Satellite Images with Incomplete Labels”

<https://arxiv.org/abs/1910.07129>

また、本論文は、国際学会の1つであるNeurIPS2019のPosterとして採択された

https://aiforsocialgood.github.io/neurips2019/acceptedpapers_track1.htm

■会社案内

最新の会社案内（PDF）は、以下にて公開中

https://ridge-i.com/cms/wp-content/themes/ridgei/pdf/company_brochure.pdf



Ridge-i

**AI・ディープラーニングによるインパクトを
（宇宙領域でも）実感できるまで追求します**

ぜひお気軽にご連絡ください



<https://ridge-i.com>



contact@ridge-i.com