



ENVI DEEP LEARNING モジュール 1.1 新機能紹介と航空機検出のデモ

2019/12/13 Fri

Harris Geospatial 株式会社 技術チーム



- Harris Geospatial 製品ラインナップのご紹介
- 背景知識:
 - 機械学習やディープラーニングの概要と比較
- ENVI Deep Learning モジュールのご紹介
 - ENVI Deep Learning モジュールの特徴 / 対応データ / ハードウェア要件など
 - 操作性の強み
 - ENVI Deep Learning モジュール 1.1のご紹介と実演
- ENVI Deep Learning 1.1 DEMO
 - WV3画像を用いた航空機検出

Harris Geospatial 製品ラインナップのご紹介



IDL

- 配列指向型のプログラミング言語
- ENVIなどの基になるテクノロジー



ENVI

- リモセン用統合アプリケーション



SARscape

- ENVI用SAR（合成開口レーダ）解析処理オプション



ENVI Deep Learning モジュール

- ENVI用Deep Learning解析処理オプション

GSF

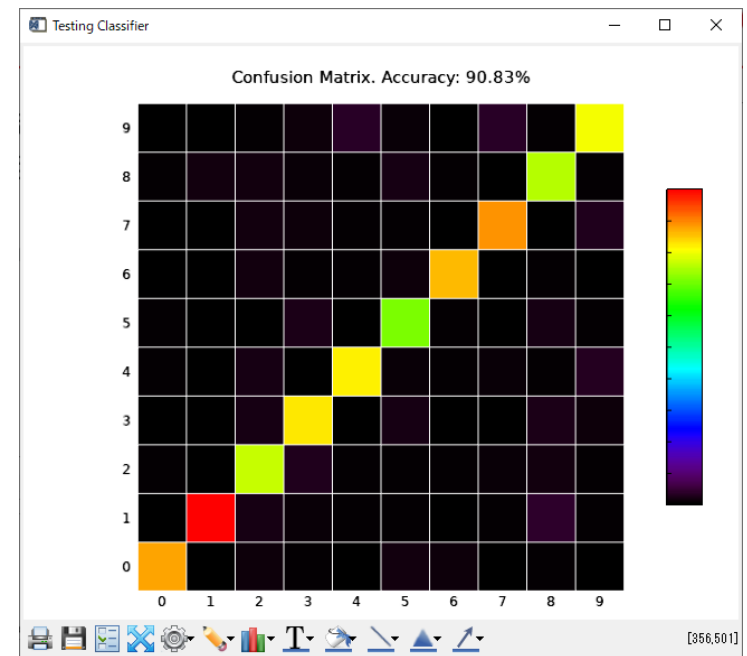
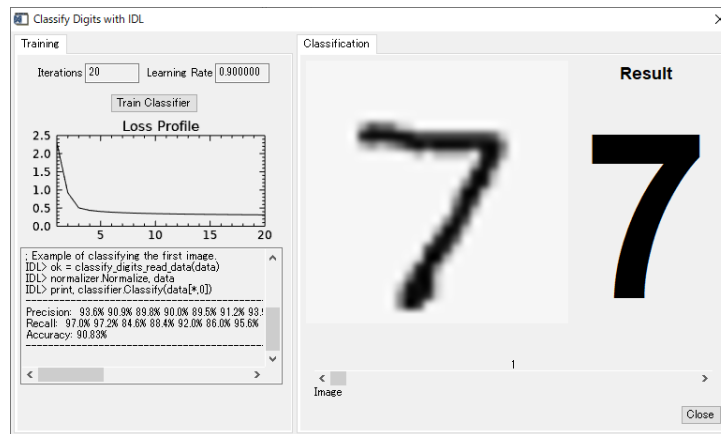
- エンタープライズソリューション

この発表のメインテーマ
.....そもそもディープラーニングとは?

背景知識: 機械学習とは



- *Arthur Samuel*による機械学習の定義(1959): 明示的にプログラミングすることなく、コンピュータに学ぶ能力を与えようとする研究分野
 - 実用例: スпамメールの検知など
- IDL8.7.1から機械学習に関するライブラリは実装されている
 - 分類 / 回帰 / クラスタリングの実施
 - 以下の図はIDLによるMNIST文字識別サンプル







IDL Machine LearningのヘルプURL: https://www.harrisgeospatial.com/docs/Machine_Learning.html

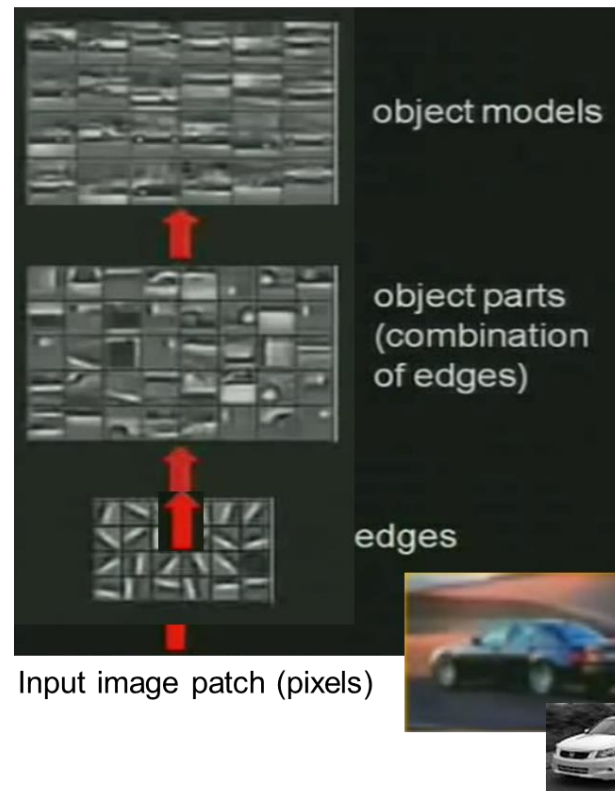
背景知識: ディープラーニングとは



- 機械学習の中の、ニューラルネットワークを発展させた手法
- (期待される)実用例: 自動運転や翻訳分野



From NVidia



背景知識: 機械学習とディープラーニングの比較




	機械学習	ディープラーニング
使いやすさ	簡単	難しい
処理時間の目安	数分	数時間から数日
扱うデータ量	極端に多くはない	きわめて多い
処理	CPUまたはGPUで行う	基本的にはGPUで行う
データの空間解像度	結果に影響を与えない	結果に影響を与える
想定される学習データ	スペクトル情報	スペクトル + 空間情報

ENVI Deep Learning モジュールのご紹介



- ディープラーニングを用いた画像解析のためのENVIオプションモジュール
- TensorFlow™を使用したディープラーニングモデルの学習を行う
- UAVや衛星で取得した画像の波長・空間特性を使用し対象物の抽出を行う
- 学習済みのモデルは、別画像の同様の対象物抽出に利用できる



TensorFlowベース



Web上で公開されている構造物ラベルデータ

ENVI Deep Learning モジュールによる新たな構造物の検知

ENVI Deep Learning モジュールの特徴



プログラマでなくても、
GUIベースでディープラーニングができる


1枚の画像からでも、モデルの学習ができる

モデルの学習に必要な教師はENVIのROIツールで作成でき、
Point, Polyline, Polygonいずれも使用できる

ENVI Deep Learning モジュールの対応データ



- 対象のデータは必ずしも地理情報を持っている必要はない
- 指標値やDSM等をレイヤスタックした独自データに対して実行することも可能



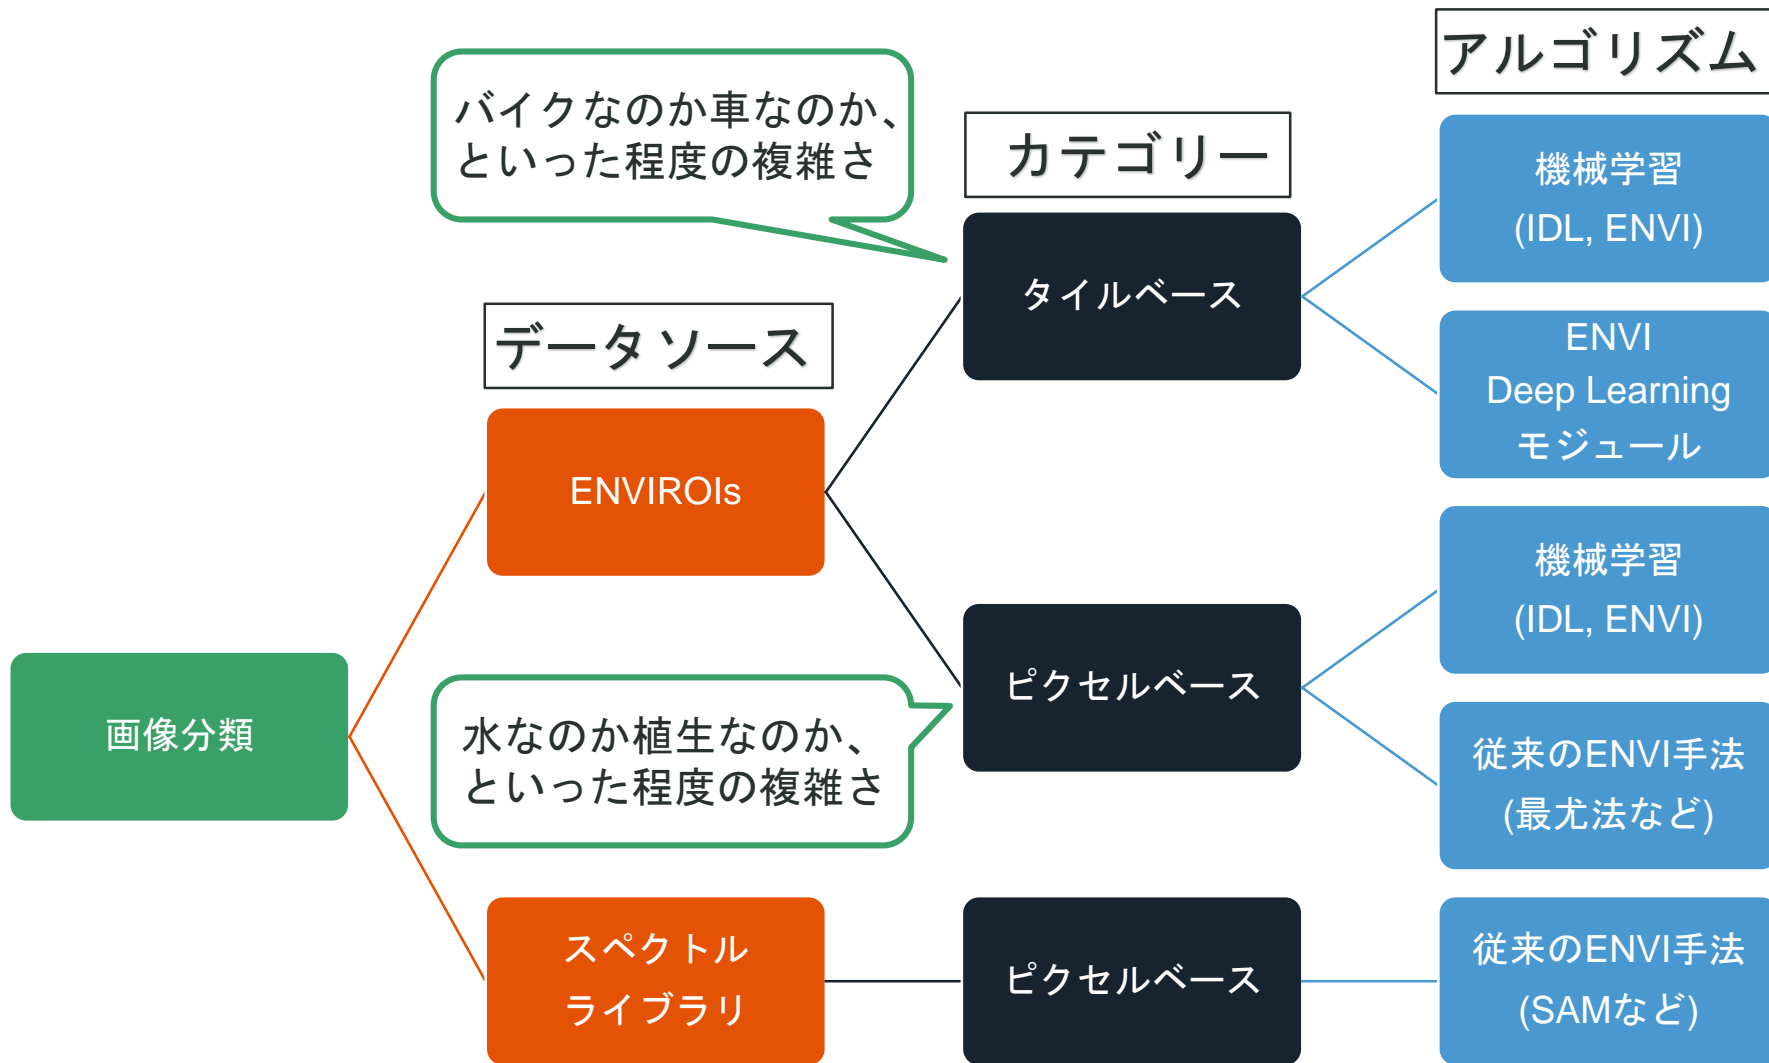
ハードウェア要件



- WindowsまたはLinuxマシンであること
 - MacOSでは動作しない
- CUDA(Compute Capability 3.5以上)対応のNVIDIA GPUを搭載していること
- 最低 8GB のメモリを搭載していること(※推奨要件)

プラットフォーム	ハードウェア	サポートバージョン
Windows	Intel/AMD 64bit	10, 2016 Server
Linux	Intel/AMD 64bit	Kernel 3.10以上 glibc 2.17以上

分類したいオブジェクトの複雑さに基づく 使用する手法のフローチャート



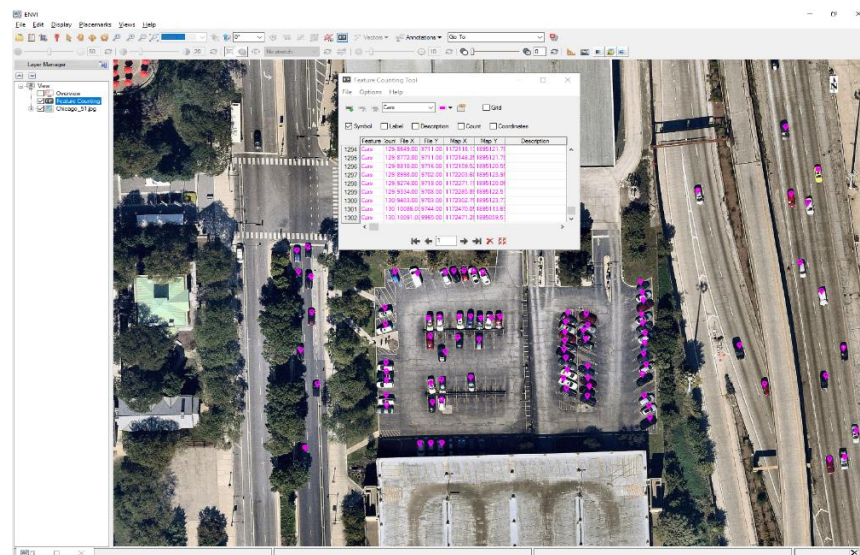
操作性の強み: ENVIを使用した教師ROIの作成



実行に必要なのは画像データとROIデータのみ

ROIの取得方法

1. ROIツールで直接作成・保存する
2. シェープファイルをROIツールで読み込み、ROIとして保存する
3. Feature Conting Toolの結果をポイント形式のシェープファイルに出力し、ROIツールで読み込んでROIとして保存する

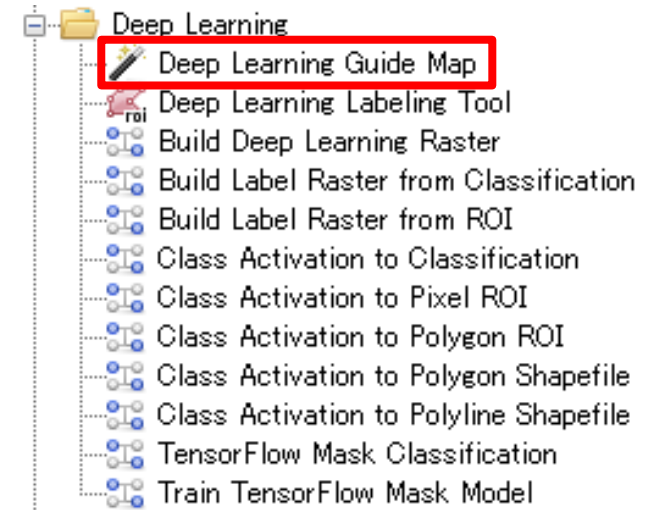
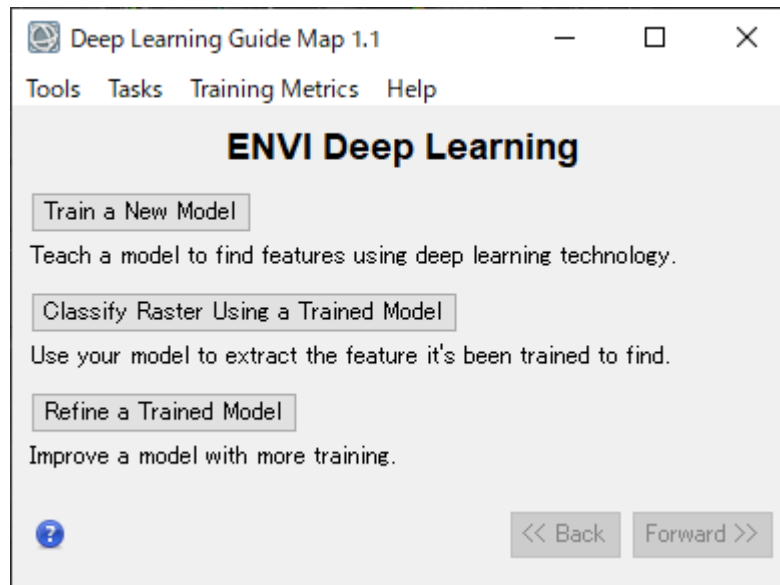


Feature Conting Toolによる車のカウント

操作性の強み: Deep Learning Guide Map



ENVIツールボックスからDeep Learning Guide Mapツールを起動し
Tensorflowモデルの作成・学習・分類はすべてこのツールから実行可能

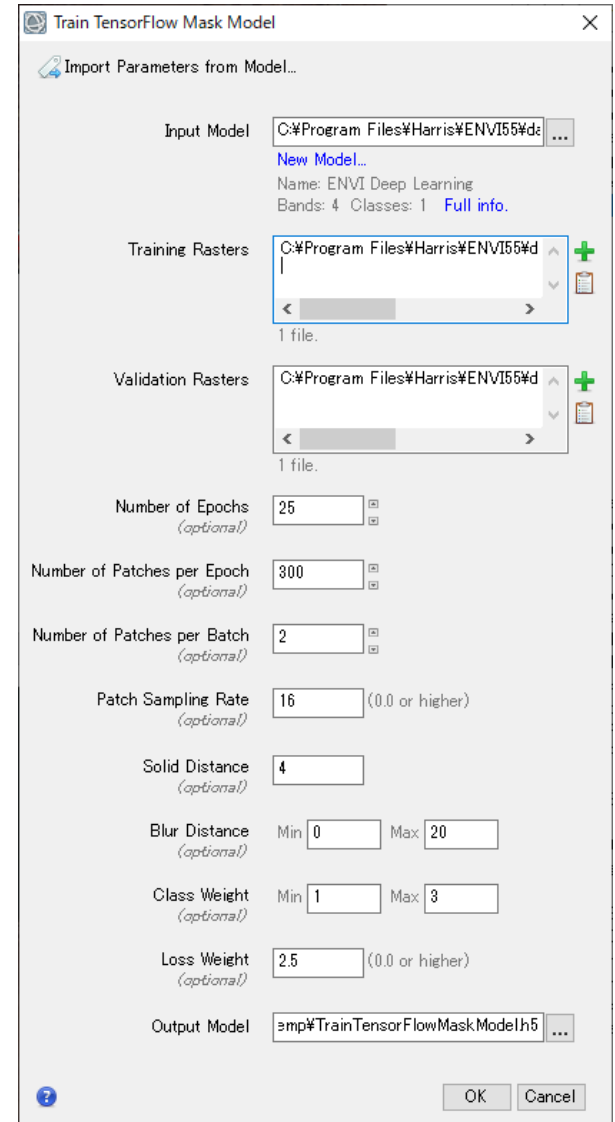


操作性の強み: モデル学習のパラメータ



いくつかのパラメータを調整し
モデルのパフォーマンスをコントロール

- Patch size
- Class weight
- Loss weight
- Solid distance
- Blur distance

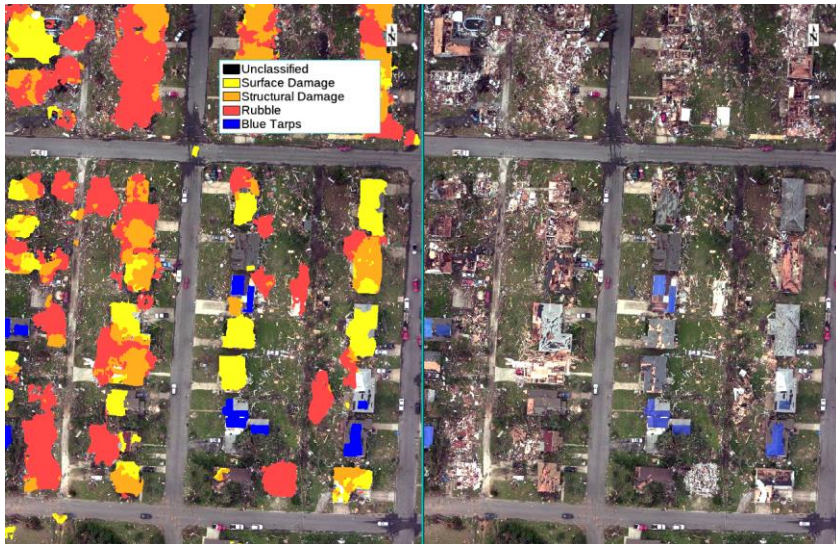


ENVI Deep Learning モジュール 1.1のご紹介 (まもなくリリース予定)

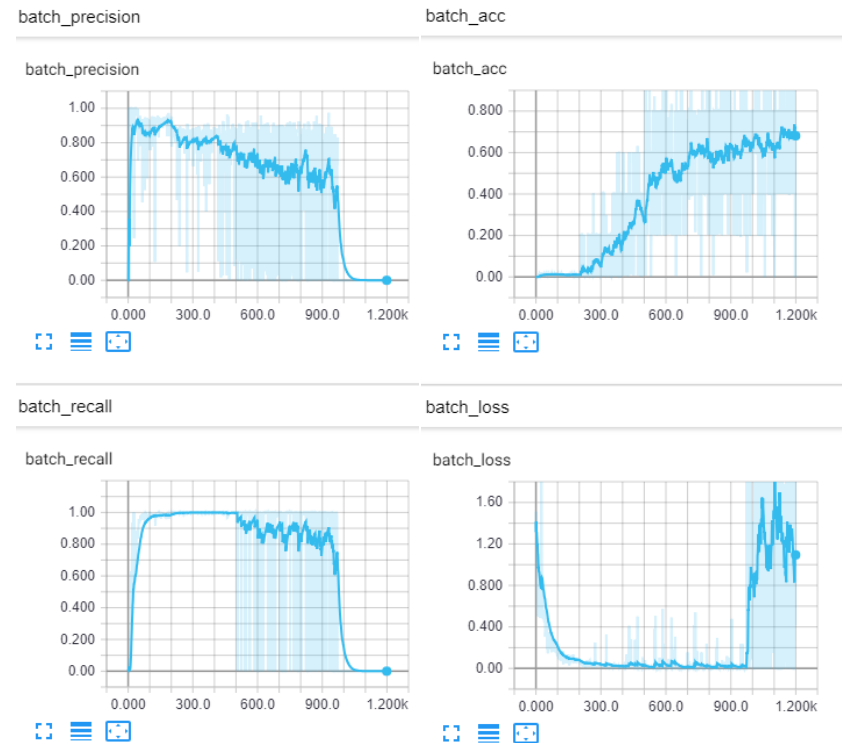


- マルチクラス分類をサポート
- TensorBoardによる、ニューラルネットのパフォーマンスを可視化

ENVIで実演



ハリケーン後の構造的損傷におけるマルチクラス分類



TensorBoardによるニューラルネットワークのパフォーマンス視覚化



ENVI Deep Learning 1.1 DEMO WV3画像を用いた航空機検出

World View 3で撮影された
羽田空港のパンクロマティック画像を対象に
ENVI Deep Learningモジュールを使用して
航空機だけを検出する

使用データおよび処理概要



使用データ

- 衛星: World View 3
- 解像度: 40cm
- 撮影場所: 羽田空港周辺
- パンクロマチック画像



処理概要

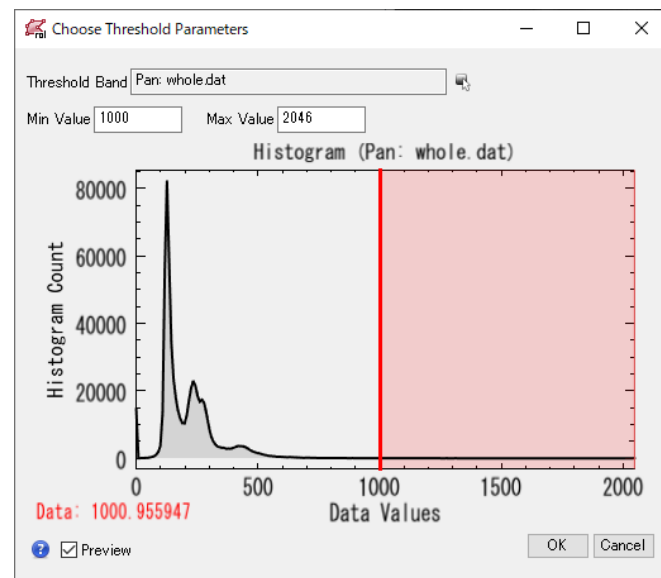

1. 教師データを作成
2. ENVI Deep Learning モジュール 1.0で分類処理
3. ENVI Deep Learning モジュール 1.1で分類処理
4. 結果の比較

14SEP22012152-P2AS-053976924100_01_P001

疑問1: Classificationツールでは分類できないのか?



- ピクセルに基づく分類なので形状レベルの区別ができない
- 航空機も滑走路もともに同じようなピクセル値を示している




疑問2:

Feature Extractionツールでは分類できないのか？



- セグメント抽出の段階ですでに航空機をうまく切り出しことが難しい
 - 影がある対象などはうまくセグメント抽出ができない
- 適用できるルールについても、十字の形状などは設定できない
 - 試しに「スペクトル平均値1000以下」および「セグメント面積35ピクセル以下」の条件で抽出したが、別の構造物も抽出してしまった。



検証ロジック



① 教師データ(ROI)を作成

② 学習パラメータをランダムに設定し、モデルのトレーニング

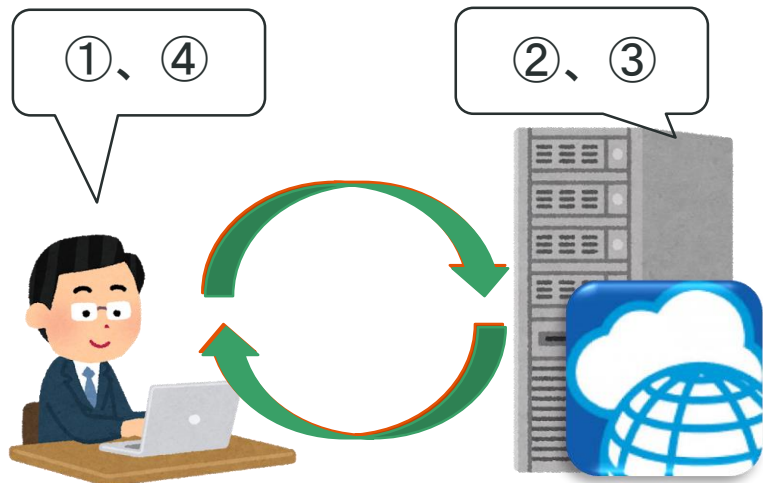
③ 上記②で学習したモデルを使用し、分類処理を実施

複数回

繰り返す

④ 結果を目視し、最もよく分類できているものを結果として採用

IDLで自動化




例えば、

教師データの作成と結果確認はローカルで行い、
学習と分類については性能の高い別マシンに対して
リクエストを通じて行うことも可能

教師データ



- 画像全域から特徴的な2シーンを切り出し、モデル学習の際の Training Rasters / Validation Rasters に使用する
- ENVI Deep Learning モジュール 1.0では、両シーンから「航空機」の形状をなぞるようにポリゴンROIを取得し教師データとする
- ENVI Deep Learning モジュール 1.1では、1.0のROIに加え「航空機以外」も同様にポリゴンROIで取得し教師データとする




モデル学習の際の
Training Rasters / Validation Rasters

備考: ポイントROIで教師取得した場合の結果について



- ポイントROIの教師によるモデルの学習も可能
- ポイントROIによる結果もポリゴンROIによる結果も、同じ傾向を示した
 - 本発表では、よりうまく分類できたポリゴンROIによる結果のほうを示す
 - なお、モデルの学習パラメータの調整によっては、ポイントROIで学習されたモデルがより良いパフォーマンスを示す可能性はある




ENVI Deep Learning モジュール 1.0:
ポイントROIによる教師で学習したモデルを用いた分類結果
→ 結果は後述するポリゴンROIと同傾向

<input checked="" type="checkbox"/>	0.752476 to 0.814023
<input checked="" type="checkbox"/>	0.814023 to 0.875571
<input checked="" type="checkbox"/>	0.875571 to 0.937119
<input checked="" type="checkbox"/>	0.937119 to 0.998667




最もよく分類できていると思われるモデルから、ENVI Deep Learning モジュール 1.0 と 1.1 との間で以下の値を計算し比較する

- 「航空機」と判断された対象のうち、実際に航空機だった対象物の割合
- 「航空機」と判断された対象のうち、実際には航空機ではなかった対象物の割合



航空機の例: 全67機




航空機でないものの例: 全67個
(白く細長い対象を、シーン全体から67個選んだもの)


ENVI Deep Learning モジュール 1.0による検証: 使用した教師データ/ROI



- 以下のように航空機をポリゴンROIで囲い、モデル学習の際の Training Rasters / Validation Rasters に使用した




㊦









㊦

ENVI Deep Learning モジュール 1.0による検証: 検証結果



ENVI Deep Learning モジュール 1.0による検証: 検証結果



「航空機」と判断された対象のうち、
実際に航空機だった対象物の割合

65/67 (= 97.01%)

「航空機」と判断された対象のうち、
実際には航空機ではなかった対象物の割合

64/67 (= 95.52%)



航空機

- 0.5 to 0.6
- 0.6 to 0.7
- 0.7 to 0.8
- 0.8 to 0.9
- 0.9 to 1


ENVI Deep Learning モジュール 1.1による検証: 使用した教師データ/ROI(マルチクラス)



- 以下のように「航空機」および「航空機以外」をポリゴンROIで囲い、モデル学習の際の Training Rasters / Validation Rasters に使用した
 - 「航空機」のROIについては1.0と同じものを使用




ENVI Deep Learning モジュール 1.1で検証: 検証結果(マルチクラス) **航空機の場合**



航空機

- 0.5 to 0.6
- 0.6 to 0.7
- 0.7 to 0.8
- 0.8 to 0.9
- 0.9 to 1

ENVI Deep Learning モジュール 1.1で検証: 検証結果(マルチクラス) 航空機以外の場合







航空機以外

- 0.5 to 0.6
- 0.6 to 0.7
- 0.7 to 0.8
- 0.8 to 0.9
- 0.9 to 1




ENVI Deep Learning モジュール 1.1で検証: 検証結果(マルチクラス)



航空機



航空機以外






「航空機」と判断された対象のうち、
実際に航空機だった対象物の割合

65/67 (= 97.01%)

「航空機」と判断された対象のうち、
実際には航空機ではなかった対象物の割合

4/67 (= 5.97%)


ENVI Deep Learning モジュール 1.0と1.1の比較



航空機 航空機以外





- | | |
|--|--|
| <input checked="" type="checkbox"/> 0.5 to 0.6 | <input checked="" type="checkbox"/> 0.5 to 0.6 |
| <input checked="" type="checkbox"/> 0.6 to 0.7 | <input checked="" type="checkbox"/> 0.6 to 0.7 |
| <input checked="" type="checkbox"/> 0.7 to 0.8 | <input checked="" type="checkbox"/> 0.7 to 0.8 |
| <input checked="" type="checkbox"/> 0.8 to 0.9 | <input checked="" type="checkbox"/> 0.8 to 0.9 |
| <input checked="" type="checkbox"/> 0.9 to 1 | <input checked="" type="checkbox"/> 0.9 to 1 |

備考: 検出できなかった2機



	「航空機」と判断された対象のうち、実際に航空機だった対象物の割合	「航空機」と判断された対象のうち、実際には航空機ではなかった対象物の割合
DLM 1.0	65/67 (= 97.01%)	64/67 (= 95.52%)
DLM 1.1	65/67 (= 97.01%)	4/67 (= 5.97%)


ENVI Deep Learning モジュール 1.0と1.1の比較



航空機 航空機以外

- | | |
|--|--|
| <input checked="" type="checkbox"/> 0.5 to 0.6 | <input checked="" type="checkbox"/> 0.5 to 0.6 |
| <input checked="" type="checkbox"/> 0.6 to 0.7 | <input checked="" type="checkbox"/> 0.6 to 0.7 |
| <input checked="" type="checkbox"/> 0.7 to 0.8 | <input checked="" type="checkbox"/> 0.7 to 0.8 |
| <input checked="" type="checkbox"/> 0.8 to 0.9 | <input checked="" type="checkbox"/> 0.8 to 0.9 |
| <input checked="" type="checkbox"/> 0.9 to 1 | <input checked="" type="checkbox"/> 0.9 to 1 |

備考:
航空機と誤検出した4対象



「航空機」と判断された対象のうち、
実際に航空機だった対象物の割合

「航空機」と判断された対象のうち、
実際には航空機ではなかった対象物の割合

DLM 1.0 65/67 (= 97.01%)

64/67 (= 95.52%)

DLM 1.1 65/67 (= 97.01%)

4/67 (= 5.97%)

検討課題①: 誤検出および確率について

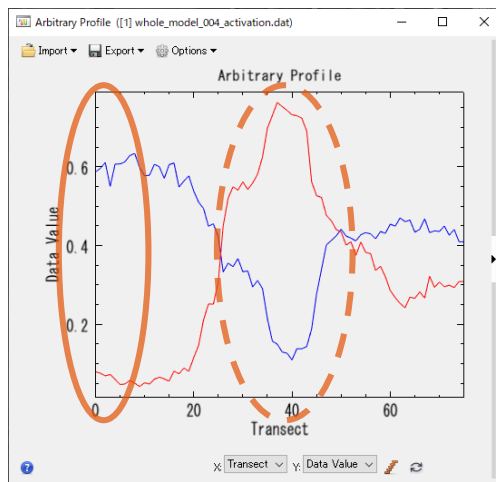



ENVI Deep Learning モジュール 1.1の結果では確率を示すピクセル値がより低くなり、航空機の一部が航空機以外と判断されるケースが現れた

– 予想される原因: 「航空機以外」という教師と「航空機」という教師が似ているため、対象を「航空機」と断定することが難しくなったのではないか

これは以下の操作によって改善される可能性がある

- 教師ROIの数を増やす
- モデルの学習パラメータの調整
- Training Rasters / Validation Rastersの数を増やすor別のものを使用する



赤: 航空機である確率
青: 航空機以外である確率
機体中心ほど航空機である確率が上昇し、
尾翼部分では下がっている

検討課題②: 検出できなかったケースについて




黒い機体など、異なる色の機体は検出できなかった

- 色で見て異なる場合、別途、教師ROIとして取得する必要がある
- エッジ抽出で境界を強調したラスタをレイヤスタックし、それをモデルの学習に使用することで解決できる可能性がある



Original




Roberts Filter




Sobel Filter



Prewitt Filter




SHIF_T_DIFF Filter




EDGE_DOG Filter



Laplacian Filter



EMBOSS Filter





ご清聴ありがとうございました！

 <https://www.harrisgeospatial.co.jp/>

 <https://www.harrisgeospatial.co.jp/技術情報/Blogs>

 https://twitter.com/HGS_KK