

超広帯域レーダのレンジプロファイル画像を用いた各種CNNモデルによるドローンの識別精度の比較検討

防衛大学校理工学研究科電子工学専攻 川口大貴 中村僚兵 葉玉寿弥

研究背景

- ドローンが活躍する社会へ
 - 現在、空撮やインフラの点検等で広く活用
 - 近い将来、有人地帯での警備・配送体制が実現
 - ➔ 多くの機体が同時飛行、高い安全性が求められる
 - ➔ ドローンを利用したテロ行為の可能性

多種多様なドローンの識別及び違法ドローンの早期発見が必要


ドローンの自動検出技術

自動検出技術	長所	短所
カメラ	<ul style="list-style-type: none"> 設置が容易 視覚的に捉えられる 	<ul style="list-style-type: none"> 鳥との自動識別が困難 天候の影響を受ける
音響センサ	<ul style="list-style-type: none"> 設置が容易 低価格 	<ul style="list-style-type: none"> 外乱の影響を受ける 検出可能距離が小さい
制御信号 (RF) の検知	<ul style="list-style-type: none"> 検出可能距離が大きい 操縦者を検知できる 	<ul style="list-style-type: none"> 周波数帯域の混雑 自律飛行を検知できない
リモートID信号の検知	<ul style="list-style-type: none"> 高い信頼性 	<ul style="list-style-type: none"> 未登録の機体を検知できない


レーダ	特徴
レーダ	<ul style="list-style-type: none"> 全天候性で外乱や他の電波の影響を受けづらい 事前登録を必要とせず、自律飛行の機体も検知できる 検出可能距離が大きい 高い距離分解能により対象の識別が期待できる(UWB)

超広帯域(UWB)レーダによって各種ドローンの識別ができるか検討


超広帯域レーダによるドローンの検知



	(A)	(B)	(C)	(D)	(E)	(F)
Diagonal Size [mm]	1200	460	390	365	270	330
Appearance						




各対象のレンジプロファイル画像 [1]



- UWBレーダによって得られるドローンの特徴的なレンジプロファイル画像をレーダ画像化することによって、AlexNet (8層のCNN) による識別を行った[2].
 - ➔ 各対象を88%以上の精度で識別できることを確認
 - さらに層の深いCNNを用いることでより高い識別精度が期待できる
- 4種の層の深さの異なるCNNモデル(AlexNet, GoogLeNet, ResNet-50, ResNet-101)による識別精度を比較検討

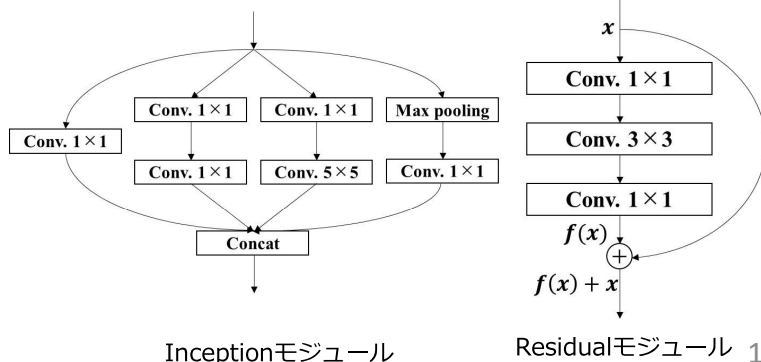
CNNの概要

- CNN (Convolutional Neural Network)
 - 画像認識で高い精度を発揮するニューラルネットワーク
- ➔ 画像認識の研究は目覚ましく、様々なCNNモデルが発表されている
- ➔ 転移学習を行うことで、様々な用途に応用できる
- ➔ AlexNet [3]
 - 5層の畳み込み層及び3層の全結合層等、計8層で構成される
 - ➔ 比較的、層の浅いCNN



AlexNetの構造

- ➔ GoogLeNet [4]
 - 22層で構成される
 - 複数の畳み込み層やプーリング層から成る“Inception モジュール”を通常の畳み込み層のように重ねている
 - ➔ 1回の畳み込み計算におけるチャンネル数とフィルタの重みを軽量化しつつ、性能を維持向上している
- ➔ ResNet [5]
 - 非常に深いニューラルネットワークにおける効率的な学習を実現した代表的なCNN
 - “Residual モジュール”を複数重ねて構成される
 - ➔ 勾配の消失が抑制され、計算量を抑えつつ精度の向上が実現
 - 18層、34層、50層、101層及び152層のモデルがあり、本研究では、50層及び152層のモデルを使用



Inceptionモジュール

Residualモジュール 1

データセットの作成

• CNNを利用した学習・識別には、データの画像化が必要

＜主なレーダ画像化手法＞

- ◆ 合成開口処理
- ◆ RPM (Range Points Migration) 法 etc...
 - ➔ 高度なイメージングのための複雑な数値解析




本研究では、単純なレーダ画像化処理によって識別を実現

① 受信電力をRCS (Radar Cross-Section) 値に変換

➔ 目標の距離による変動がない


$$\sigma = \left(\frac{P_t}{P_r} \right) \cdot \left(\frac{R_t}{R_r} \right) \cdot \sigma_r$$

R_t : 目標までの距離 P_t : 標準器までの受信電力
 P_r : 目標までの受信電力 σ_r : 標準器のRCS
 R_r : 標準器までの距離




➔ -40~-10 dBsmの範囲のRCS値に注目

- ② 地上反射波やクラッタ等の外乱を除去
 - ➔ 実際のレーダ使用環境では、背景差分を用いて除去する。
- ③ レンジプロファイル画像を単位計測時間 τ ごとに分割
- ④ 反射信号のピークが画像中心となるようレーダ画像化
 - ➔ ドローンの位置変動の影響を無視
 - ➔ 飛行移動中のドローンへの対応も可能



⑤ レーダ画像を各対象ごと50枚ずつ (計300枚) 生成し、データセットとした。

データセット (CNN)



各CNNモデルによる識別結果 (k=6)

CNN models	Layers	Classification accuracy [%]							Standard deviation
		Matrice 600	3DR Solo	Phantom 3	Mavic pro	Bebop drone	Bionic bird	Average	
AlexNet	8	100	97.7	96.0	92.0	87.5	100	95.5	4.5
GoogLeNet	22	100	95.7	94.1	92.6	100	98.0	96.7	2.8
ResNet-50	50	100	100	96.0	100	90.9	100	97.8	3.4
ResNet-101	101	100	95.5	92.3	94.3	96.1	100	96.4	2.8

各CNNモデルによる識別結果 (k=10)

CNN models	Layers	Classification accuracy [%]							Standard deviation
		Matrice 600	3DR Solo	Phantom 3	Mavic pro	Bebop drone	Bionic bird	Average	
AlexNet	8	100	84.6	97.7	90.9	98.0	98.0	94.9	5.4
GoogLeNet	22	100	95.7	93.8	92.6	94.1	100	96.0	2.9
ResNet-50	50	100	95.7	94.1	98.0	96.2	98.0	97.0	1.9
ResNet-101	101	100	92.0	95.7	92.6	94.1	100	95.7	3.2

- 全てのCNNモデルが平均約**95%**以上の精度で識別
- 22層以上の層から成るCNNで、全ての対象を**90%**以上の精度で識別
 - ➔ ResNet-50は全ての対象を**94.1%**以上の精度で識別

まとめ

- 超広帯域レーダによって得られたレンジプロファイル画像を用いて、各種CNNモデルにおける識別精度を比較検討
 - ➔ ドローンの特徴的なレンジプロファイルを単純な処理によって、レーダ画像化
 - ➔ CNNの層を深くすることにより、6種の対象を90%以上の精度で識別することができた。

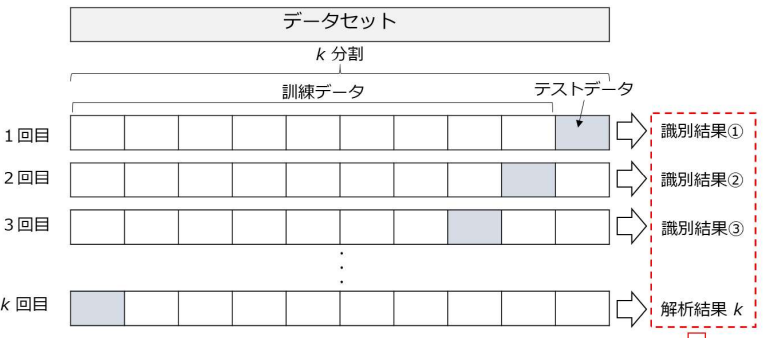
＜今後の課題＞

- レーダとドローンの位置関係の違いによる識別精度への影響
- 識別可能な帯域幅
 - ➔ 実際のドローンの飛行環境を想定し、様々な飛行姿勢のデータを取得して、識別性能を評価する。

識別結果

• k=6, 10としたk分割交差検証法で識別精度を評価

➔ 比較的少ないデータ数で汎化性能を評価できる



平均した結果を出力

k分割交差検証法

参考文献

- [1] T. Mizushima, R. Nakamura, and H. Hadama, "Reflection characteristics of ultra-wideband radar echoes from various drones in flight," Proc. of WisNet2020, pp.30-33, Jan. 2020.
- [2] 川口大貴, 中村僚兵, 葉玉寿弥, "超広帯域レーダを用いた深層学習に基づくドローンの識別手法の検討," 電子情報通信学会技術報告, WBS2020-21, pp. 73-78, Dec. 2020.
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," Proc. of NIPS' 12, pp. 1097-1105, Dec. 2012.
- [4] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," Proc. of CVPR 2015, Jun. 2015.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," Proc. of CVPR 2016, Jun. 2016.
- [6] R. Nakamura, K. Suzuki, and H. Hadama, "RCS measurements of various drones at 24 GHz," IEICE Communication Express, vol.9, no.7, pp.262-267, Jul. 2020.