

## 船舶のタンク・ホールド内画像認識に関する研究 Study on Image Recognition in Tank / Hold of Ship

平方 勝  
Masaru Hirakata

馬 沖  
Ma Chong

谷口 智之  
Tomoyuki Taniguchi

海上・港湾・航空技術研究所  
National Institute of Maritime, Port and Aviation Technology

This document describes whether image recognition using Deep Learning can be practical for images taken by unmanned aerial vehicle (drone). There is a movement to try to utilize a drone for inspection inside tank / hold of the ship. Accessibility to the inspection site becomes easy, while on the other hand, a technique to support condition evaluation on the screen is also required to judge through the video taken with the drone. In this research, we examined to verify the recognition rate of structural members in tank / hold in a bright environment. In addition to recognizing in a bright environment, we also examined to verify the recognition rate in a virtual dark environment.

### 1. はじめに

船舶のタンク/ホールド内の点検に、ドローンを活用しようとする動きがある。点検箇所へのアクセスが容易になる一方、ドローンで撮影した映像を通して現場判断するため、画面上で状態評価を支援する技術が望まれる。

ばら積み貨物船のホールド内は、ハッチを開けると明るく、また、ドローンの飛行にとって障害となる構造部材がない開放的な空間になっている。一方、タンカーのタンク内は、甲板で覆われるため暗い上にドローンの飛行に有用な GPS が効かない。そして、ウェブフレームなど大きな構造部材(ドローンの飛行にとって障害物)がタンク内に多く配置されている。

本研究では、深層学習(Faster R-CNN)を用いた物体検出技術を、第一段階として、ばら積み貨物船のホールド内の構造部材の認識に適用させ、その認識率を検証する。実験は、明るい環境での認識率の検証を行った後、暗い環境を模擬した状態での認識率の検証を行った。

### 2. 船舶の点検

大型の船舶でアクセスが困難な高所へは、図 1 に示すように、高所作業車を使用して点検を行うことが多い。図 2 に示すように、高所点検箇所にドローンを飛ばして点検する動きがある。



図 1 ばら積み貨物船の点検風景

図 2 に示すように、船舶のハッチが開いた状態では明るい環境であるが、タンカーのように甲板で覆われているような船舶のタンク内は、図 3 に示すように、暗い環境である。また、タンク内は多くの構造部材が配置されているため、直接の視界から外れることも予想される。



図 2 ドローンの貨物倉内飛行風景



図 3 貨物倉内(ハッチ閉)

### 3. 画像認識

#### 3.1 Faster R-CNN

深層学習を利用した物体検出に、R-CNN が利用されることが多い[Ross Girshick 2014]。R-CNN は Selective Search[J.R.

連絡先: 平方勝, 海上・港湾・航空技術研究所, 〒181-0004  
東京都三鷹市新川 6-38-1, 0422-41-3690, 0422-41-3085, hirakata@nmri.go.jp

R. Uijlings 2013] で検出した物体候補領域を AlexNet(または VGGNet)に入力して検出する手法である。Selective Search は、色の類似度に着目したセグメンテーション法であり、色の類似度の許容度を超えてグルーピングすることで様々な大きさの候補領域を抽出することができる。Selective Search で検出した物体候補領域を一定サイズにリサイズし、後段の CNN に入力する。物体候補領域の数だけ CNN で認識するため、計算コストが高いといわれる [情報機構 2017]。

畳み込み処理の回数を大幅に削減することで計算コストを改善した Fast R-CNN が報告された。その後、Fast R-CNN をベースとし、Selective Searchをやめ、Region Proposal Network を行うことで計算コストを削減した Faster R-CNN が報告された。現在では、Faster R-CNN が物体検出で広く使用される [情報機構 2017]。本研究では、Faster R-CNN による検出を行った。

3.2 データセット

ばら積み貨物船の重点点検箇所周辺の構造部材名を学習・認識させる。ばら積み貨物船の重点点検箇所は、一般的に図 4 に示す 5 箇所といわれている。1 箇所につき、100 画像程度を用意した。画像データを大量に用意するために、画像の中には、同じ対象箇所を別のアングルから撮影したものもある。図 5 で赤枠を記した部材名を学習させた。

学習には、訓練データを 550 画像、検証データを 250 画像用意した。テストデータに 89 画像を用意した。今回用意した画像は、すべて点検者がデジタルカメラで撮影した画像であり、ドローンカメラによる撮影画像ではない。

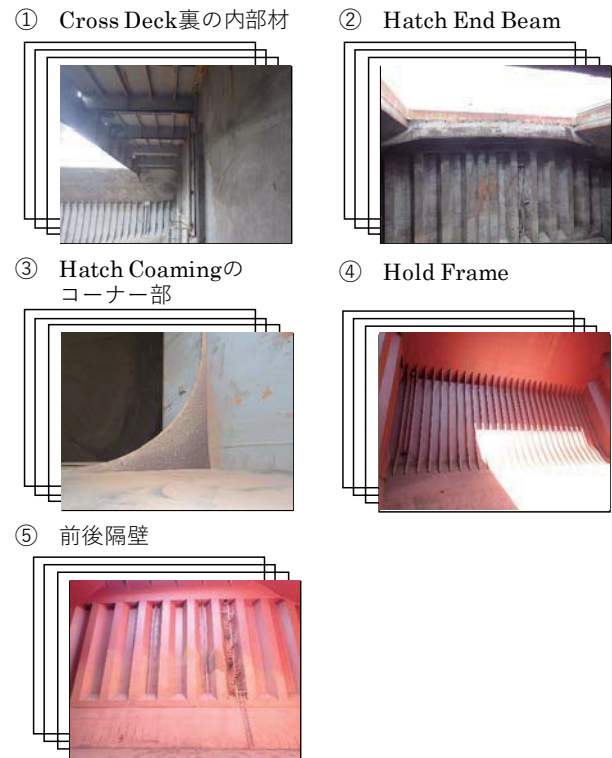


図 4 データセット




図 5 学習させた部材名

3.3 明るい環境での認識実験

図 6 は、ばら積み貨物船の貨物倉内の画像認識結果及び撮影箇所を示した図面である。表 1 は、認識できた部材名とその認識率である。図 6 で撮影されたすべての部材名が 100%または 100%に近い認識率となっている。訓練データに同様のアングルからの撮影画像が多かったためと考える。

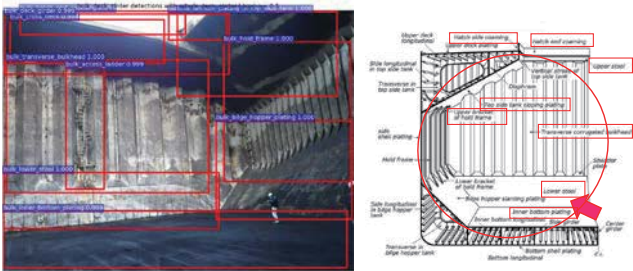


図 6 部材認識(1)

表 1 部材認識(1)の認識率	
部材名	認識率
Top side tank sloping plating	100%
Hold frame	100%
Bilge hopper plating	100%
Transverse bulkhead	100%
Lower stool	100%
Access ladder	99.9%
Inner bottom plating	99.9%
Deck girder	99.9%
Hatch side coaming	99.9%
Hatch end coaming	99.4%
Cross deck	99.4%

図 7 も、ばら積み貨物船の貨物倉内の画像認識結果及び撮影箇所を示した図面である。表 2 は、認識できた部材名とその認識率である。表 1 と同様、すべての部材名が 100%または 100%に近い認識率となっている。Inner Bottom Plating は、画像の中で僅かに写っているだけだが、高い認識率で認識できて

いる。Lower Stool の床(エッジ)を認識し、それが、Inner Bottom Plating であると、構造位置関係も認識できている。




図 7 部材認識(2)

表 2 部材認識(2)の認識率

部材名	認識率
Transverse bulkhead	100%
Lower stool	100%
Inner bottom plating	99.7%

図 6 及び図 7 の認識結果は、学習で使用した画像ではないが、同じ船舶の他の画像データを学習させていたことが、高い認識率につながったものと考え、別の船舶の同様の箇所について認識させた。図 8 は、ばら積み貨物船の貨物倉内の認識結果である。学習で使用した船舶は全て、船側部に Hold Frame が配置された構造様式であったが、図 8 の船舶は Hold Frame が配置されていないタイプの船側構造となっている。そのため、Transverse bulkhead が船側を含めて認識された。船舶の構造様式について多様な学習データを用意して改善していく必要がある。また、Deck girder, Cross deck が画像(図 8)に写っているが、認識率は 50%を下回っていた。訓練データを増やして学習を重ねる必要がある。Access Ladder は画像に写っておらず、認識しなかったことは正しい結果である。



図 8 部材認識(3)

表 3 部材認識(3)の認識率

部材名	認識率
Top side tank sloping plating	98.3%
Transverse bulkhead	95.3% (船側を誤認)
Access ladder	認識せず(正解)
Inner bottom plating	97%
Deck girder	50%未満
Cross deck	50%未満

3.4 暗い環境を模擬した認識実験

ばら積み貨物船のハッチを閉じると、図 3 に示すようにライトがないと周りを知覚できないほど暗い。ドローンにライトをつけて

撮影した画像はない。ライトをつけて飛行したドローンの撮影画像をどの程度認識できるか、ここでは、図 9 に示すように、オリジナルの画像(明るい環境)から画像処理によって、暗い環境でライトが当たった模擬的な状態を作り出して、認識率の検証を行う。Case1, Case2 にしたがって、明るい範囲を中心位置に集中させ、全体的に暗い環境を作り出した。



図 9 仮想的な暗い環境創出

図 10 は、図 6 の画像をオリジナルにして、Case1, Case2 の暗い環境を模擬的に作り出した状態の認識結果である。その状態の認識結果を表 4 に示す。なお、明るい画像で学習させた状態の重みを使用している。ヒトの知覚のように、Case1, Case2 の順に認識率が低下している。画面中央の明るい部材の認識率は依然高いものの、周辺の暗い部材の認識率は低下している。Inner Bottom, Cross Deck の認識率は 50%と低いものの認識できていることは画像判断するヒトにとって有用である。Case2 の認識結果で、Transverse Bulkhead が高い認識率となっていることは、この画像からでは Transverse Bulkhead を見落とす可能性があるため、判断するヒトに有用な判断材料を提供できると考える。Case2 の静止画像を見ただけでは全体判断が困難である。ヒトは、静止画像だけでは対象を認知できなくても、連続的な動きの中では認知できることもあるため、システムも同様にリアルタイムの連続的な動きから認識できるようにする必要がある。



図 10 部材認識の変化(1)

表 4 部材認識の変化(1)での認識率変化

部材名	元画像	Case1	Case2
Top side tank sloping plating	100%	53%	50%未満
Hold frame	100%	99.8%	98.7%
Bilge hopper plating	100%	99.4%	86.8%
Transverse bulkhead	100%	100%	99.8%
Lower stool	100%	98.9%	90%
Access ladder	99.9%	99.3%	50%未満
Inner bottom plating	99.9%	57.9%	50%未満
Deck girder	99.9%	50%未満	50%未満
Hatch side coaming	99.9%	50%未満	50%未満
Hatch end coaming	99.4%	50%未満	50%未満
Cross deck	99.4%	52.4%	50%未満

図 11 は、図 7 の画像をオリジナルにして、Case1, Case2 の暗い環境を模擬的に作り出した状態の認識結果である。その状態の認識結果を表 5 に示す。Case1,Case2とも画像に写っていない



い Top side tank sloping plating を誤認している。Case1 では Transverse bulkhead を認識できていることは、この画像からでは Transverse Bulkhead を見落とす可能性があるため、判断するヒトに有用な判断材料を提供できると考える。Case2 はヒトがみても、この画像のみでは判断が困難である。リアルタイムの連続的な動きから認識できるようにする必要がある。また、構造部材の位置関係等、船体構造の知識をベースにヒトは判断することがあるため、このような仕組みを取り入れることによって、認識率が向上すると思われる。



図 11 部材認識の変化(2)

表 5 部材認識の変化(2)での認識率変化

部材名	元画像	Case1	Case2
Top side tank sloping plating	認識せず (正解)	95.3% (誤認)	86.2% (誤認)
Transverse bulkhead	100%	99.6%	50%未満
Lower stool	100%	90.2%	50%未満
Inner bottom plating	99.7%	50%未満	50%未満

#### 4. おわりに

船舶のタンク/ホールド内の点検にドローンを活用する動きがあり、ドローンが撮影した映像から自動評価できる実用的なシステムを構築するための基礎実験を行った。本研究では、Faster R-CNN を用いて船体構造部材の認識を行った。

データセットは、明るい環境での画像を用い、訓練データが 550 画像、検証データが 250 画像で 15 時間学習した結果を基に、テストデータ 89 画像の検証を行った。

学習した明るい環境での画像では、認識率は高かった。ただし、学習した船舶にない構造様式については誤認していたため、学習データは画像の数に加えて多様な画像を用意する必要がある。

明るい環境で学習した重みを使用して、暗い環境での認識率を検証した。暗い環境での画像は、画像処理によりライトがあたった模擬的な状態を作り出したものである。明るい環境での画像認識率に比べると、認識率は低下する。ライトのあたったと想定する明るい(画像中央)の認識率は高いものの、周辺の暗い部材の認識率は低下し、認識できなかったケースも見られた。ヒトの視覚認知に似ている。実際にライトを当てると、ハレーションが起こり、ライトを当てた箇所周辺が真白になる場合もある。このような問題処理も含めて、ライトを当てた実際の画像を整備し、そのもとで学習を行っていく必要がある。

暗い静止画像だけでは人も判断が困難であることがある。ヒトは、静止画像だけでは対象を認知できなくても、連続的な動きの中では認知できることもあるため、システムも同様にリアルタイムの連続的な動きから認識できるようにする必要がある。

今後は、検査場面で最も重要な損傷を認識できるように学習データを整備して検証を行っていく予定である。深層学習はブラックボックスであるといわれることが多い。認識結果の解釈を数多くこなすことで、認識率の向上につなげる予定である。

#### 参考文献

- [Ross Girshick 2014] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik: Rich Feature hierarchies for Accurate Object Detection and Semantic Segmentation, CVPR '14 Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, pp. 580-587, 2014.
- [J.R. R. Uijlings 2013] K. E. A. Van De Sande, T. Gevers and A. W. M. Smeulders: Selective search for object recognition, International Journal of computer vision, vol. 104, no. 2, pp.154-171, 2013.
- [情報機構 2017] 機械学習・人工知能業務活用の手引き, 情報機構, 2017
- [Shaoqing Ren 2015] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, IEEE Trans. Pattern Anal. Mach. Intell. 39(6): 1137-1149, 2017