

船舶の設計・検査における AIの適用研究

国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所

平方 勝、馬 沖、
谷口智之、小森山 祐輔

目 次

1. 人工知能研究とその周辺
2. 最近の人工知能研究と適用事例の紹介
3. 船舶に関連する適用研究紹介
 - A) 船舶設計・検査における対話システムの構築
 - B) NC切断ネスティング最適計画
 - C) 船舶のタンク内点検画像認識処理技術の開発
 - D) ニューラルネットワークを活用した騒音予測
4. まとめ

1. 人工知能研究とその周辺(1)

シュレディンガー

生命とは何か

物理的に生命を説明する

シュレディンガーの著書

1943年

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生命とは何か

生物は環境から負のエントロピーを取り入れている

生物の本質

代謝・自己組織化開いた系

J.ワトソン

F.クリック

DNAは二重らせん構造

情報処理系

E.クリック



1995年

脳（情報処理器官）はニューラルネットワークでできたもので、分子の働き以上のなにものでもない

”認知”研究が自然科学の対象になる

人工知能研究

ダートマス会議 1956年

認知研究：認知・思考、知識、記憶、理解

脳・神経科学

第一次ブーム

第二次ブーム

第三次ブーム

1960年代～

1980年代～

2000年代～

ニューラルネットワーク

- ・パーセプトロン（小脳）
- ・ホップフィールド
- ・自己組織化マップ
- ・RNN

対話システム (ELIZA)

エキスパートシステム
知識表現

ニューラルネットワーク
<深層学習>

- ・CNN他（皮質<視覚>）
- ・RNN (LSTM)


知覚処理（ボトムアップ）から
認知・対話（トップダウン）
知識ベースの推論処理

哲学

パース
プラグマティズム

フッサール
現象学

ウィトゲンシュタイン
言語ゲーム



人工知能研究テーマ(1)

(1)「人工知能学会 論文投稿分野より編集」

1. 人工知能研究とその周辺 (2)

人工知能は、

ツール（計算機、情報処理端末）としての存在を超えて

人間と**協働**する**知的情報処理システム**に

文部科学省「人間と機械の創造的協働を実現する知的情報処理技術の開発」（2014年）

人間（他者）の振る舞いを**理解（知覚・認知）**し、**行動（作用）**できるように：環世界の構築⁽¹⁾

ヒト（生き物の一員）とは何か

環境への適応：まねる、記憶（学習）

自己組織化：分類

イメージ処理（右脳）：知覚、認知

人工知能

☞ ニューラルネットワーク（回帰モデル）

☞ ニューラルネットワーク（分類モデル）

☞ 画像ディープラーニング

人間（社会的生き物の一員）とは何か

意識的行動：自律性、外界の価値、注意

記号・**言語**処理（左脳）：思考・対話

推論・思考：帰納、演繹、仮説検証

内省：客観、メタ認知

感情移入：対話

人工知能

☞ 強化学習、？？？

☞ 再帰型ニューラルネットワーク、？？？

☞ 知識グラフ、？？？

☞ IBM Watson、？？？

☞ ？？？

(1)ユクスキュル, 生物から見た世界

2. 最近の人工知能研究と適用事例の紹介 (1)

画像認識

Restricted Boltzman Machine(2002) 、 Deep Belief Network(2006年) 、
Stacked Auto Encoder (2007年)

現在画像認識では、**畳み込みニューラルネットワーク (CNN)**が主流




図 多層モデル

「麻生英樹、ディープラーニングの発展と
展望 (第1回AI・人工知能EXPO)」

CNNの発展

ILSVRC (ImageNet Large Scale Visual Recognition Challenge)

2012年	AlexNet	誤り率 15.3 % (2位 の機械学習26.2 %)
2013年	VGGNet	誤り率 11.2 %
2014年	GoogLeNet	誤り率 6.7 %
2015年	ResNet	誤り率 3.6 %

CNNは、大量の学習セットが必要

➡ **GAN** (Generative Adversarial Network) の研究が盛ん

識別モデルと**生成モデル**の訓練を同時に進め、互いに競わせることで精度の高いモデルを構築できる。
少量の学習セットで本物に近い画像を生成することができる。

2. 最近の人工知能研究と適用事例の紹介 (2)

言語処理

音声や言語といった系列データを扱うニューラルネットワークは、**再帰型ニューラルネットワーク(RNN)**が利用できる。

最近では、**RNN**の一種で、勾配消失問題を回避するための、長・短期記憶(**LSTM**)が話題になっている。

Googleが**LSTM**をGoogle翻訳に適用 (2016～)





図 Recurrent Neural Network (**RNN**) (1)

対話処理

シンボルグラウンディング問題：

コンピュータは**記号の意味を理解していない**ので、記号の操作だけでは知能は実現できない。シンボル（記号）をそれが意味するものと結びつける（グラウンディングさせる）ことが必要であるが、現在の人工知能では解決できていない。



強い**AI**は実現するか？ By J.サール

2. 最近の人工知能研究と適用事例の紹介 (3)

テキストと画像の結び付け

CNNとRNN (LSTM)を組み合わせる。

画像から物体認識を行い、**画像の説明文**を作成する。

マルチモーダル

A person riding a motorcycle on a dirt road.



Two dogs play in the grass.



A skateboarder does a trick on a ramp.



A dog is jumping to catch a frisbee.



A group of young people playing a game of frisbee.



Two hockey players are fighting over the puck.



A little girl in a pink hat is blowing bubbles.



A refrigerator filled with lots of food and drinks.



A herd of elephants walking across a dry grass field.



A close up of a cat laying on a couch.



A red motorcycle parked on the side of the road.



A yellow school bus parked in a parking lot.




図 画像からの説明文生成

Oriol Vinyals他, A Neural Image Caption Generator, 2014

2. 最近の人工知能研究と適用事例の紹介 (4)

強化学習

ある環境内にあるエージェントが、現在の**状態を観測**し、とるべき**行動を決定**する問題を扱う機械学習の一種。エージェントは行動を選択することで**環境から報酬**を得る。**強化学習**は一連の行動を通じて**報酬が最も多く得られる**ような方策 (Policy) を**学習**する
「Wikipedia」



AlphaGo



Atari Playing

図 強化学習の適用例

<対話システム 先行研究の調査>




図1: 代表的な音声対話システムの系譜 (1)

予め大量の発話ペアを学習した上で、質問を受けた際に最も近い発話ペアの応答文を回答する仕組みとなっている、**チャットボット**の開発が進む。

コールセンター業務などに活用

質問応答システムWatson

2011年、IBMの質問応答システムWatsonが全米のクイズ番組「Jeopardy!」において人間のチャンピオンよりも高速でボタンを押し、次々と正確に解答を読み上げた。

<技術>

ファクトイド型質問応答（質問文で問われている名詞や固有名詞を答えるという課題解決）を実現

複数の**仮説を立てて**、それぞれの**妥当性を検証**する仕組み

現象学的アプローチ




図2 Watsonの処理の流れ (2)

< 目標 >

頻繁に改正される規則を、**設計**や**検査**で**活用**することを念頭にシステムが**知識**として学ぶ。設計者や検査員と**協働**できるシステム開発を目指す。



検査員に必要な情報
< 応答文教師データ >

読込 ↓ 内容を知識化
(構造化して記憶)



トップダウン
処理知識

思考・推論モデル

辞書

文法知識

言語

スキーマ
(背景知識)

ボトムアップ
処理知識

常識

スクリプト
(エピソード)


検査




検査員

対話


LLの検査をはじめるよ。



ブルワークの高さは1m以上ですか？



設計



設計者

本船は、規則△△
...

設計者支援

or

設計・建造
仕様書作成




etc.

シンボルグラウンディング
言語ゲームが一つのヒント？



NC切断ネ스팅最適計画 (1)

<問題設定>




ネ스팅?

鋼材上にマーキング

なるべく多くの船殻部材を配置する**最適計画**

Hopfieldネットワーク (相互結合型ネットワーク)



○ ニューロン


→ ニューロン間の結合の向き

$$E = -\frac{1}{2} \sum_{ij} W_{ij} X_i X_j - \sum_i h_i X_i$$


Hopfieldネットワークのエネルギーが極小値に収束するようにする。

 W_{ij} : ユニットjからユニットiへの結合荷重 h_i : ユニットiでの閾値 X_i : ある船殻部材の配置先の候補制約条件 (全て詰める、重ならない、部材距離を近く) を定めて、 W_{ij} , h_i を計算↓
 X_i を更新


① 離散データとして取り扱う



② 角度, 裏表を取りうる




規則的に配置 (8枚)



L

Hopfieldネットワーク (9枚)



L

< 今後の展開 >

- 強化学習等、別の学習方法による検討
- ネスティング以外の最適問題への適用を検討

船舶のタンク内点検画像認識処理技術の開発 (1)


< 背景 >

船舶のタンク・ホールド内点検にドローンを活用する動きがある。

アクセスは容易になる一方、

ドローンで撮影した**タンク・船倉内画像**から、対象箇所の塗膜健全性、損傷の有無を自動評価（**画像認識**）する技術が求められる。

非GPS環境では、ドローンが**外界を認識**し、衝突を避けながら、**自動飛行**することも望ましい。**位置把握**も必要。



< 研究方法 >

RCNNは、Selective Searchでオブジェクト候補を切り出し、切り出した**Region**にCNNを適用し、近傍で一番適合度の高かったものを採用




図1 Regions with CNN features (1)

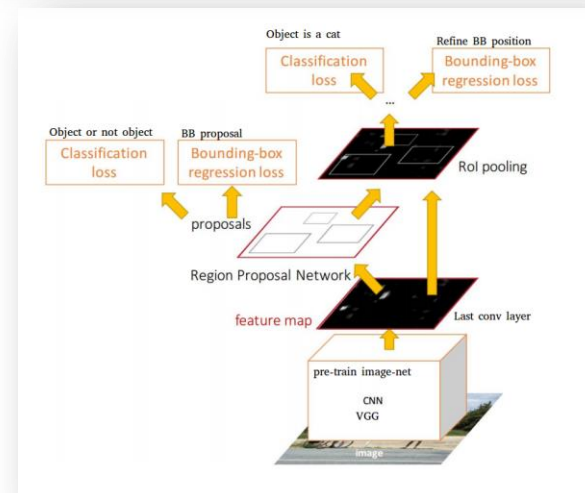


図2 Faster R-CNN(2)

(1) 「Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik (2014): Rich Feature hierarchies for Accurate Object Detection and Semantic Segmentation. In 580-587」

(2) 「Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun (2015): Faster R-CNN」


船舶のタンク内点検画像認識処理技術の開発 (2)

データセット

GPS環境（ハッチカバーオープン：明るい）を想定

ばら積貨物船の重点点検箇所等（①～⑤）に関連する**部材名**（上構造図赤枠）を**学習**させる。


① Cross Deck裏の内部材




② Hatch End Beam




③ Hatch Coamingの
コーナー部



④ Hold Frame



⑤ 前後隔壁




訓練データ：550画像
検証データ：250画像
テストデータ：89画像

船舶のタンク内点検画像認識処理技術の開発 (3)


< 実験I >

bulk_deck_girder detections with $p(\text{bulk_deck_girder} | \text{box}) \geq 0.5$



Top side tank sloping plating: 99.2%
Deck girder: 93.3%
Hold frame: 50%未満

訓練画像に同様のアングルからの画像がすくなかったことが原因



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%

船舶のタンク内点検画像認識処理技術の開発 (4)

< 実験II >



閉囲環境（暗い環境）
を模擬的に作成（2段階）



明るい環境での学習結果を
基に認識率を検証



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%



Top side tank sloping plating: 53%
Hold frame: 99.8%
Bilge hopper plating: 99.4%
Transverse bulkhead: 100%
Lower stool: 98.9%
Access ladder: 99.3%
Inner bottom plating: 57.9%
Deck girder: 50%未満
Hatch side coaming: 50%未満
Hatch end coaming: 50%未満
Cross deck: 52.4%

暗い部材から認識が困難に。
明るい部材認識率は依然高い。



Top side tank sloping plating: 50%未満
Hold frame: 98.7%
Bilge hopper plating: 86.8%
Transverse bulkhead: 99.8%
Lower stool: 90.0%
Access ladder: 50%未満
Inner bottom plating: 50%未満
Deck girder: 50%未満
Hatch side coaming: 50%未満
Hatch end coaming: 50%未満
Cross deck: 50%未満

ヒトもこの静止画像だけでは判断が困難。連続した動きの中では判断が可能。

今後

リアルタイムでの認識
損傷の認識

ニューラルネットワークを活用した船内騒音予測 (1)

2012年、国際海事機関(IMO)が船舶の騒音に関するコードを義務化

基本設計（騒音予測）を支援

👉 設計の初期段階での推定の必要性高い

👉 早期に対策を検討可能






図 ニューラルネットワーク（多層パーセプトロン）


< 比較 >



SEA法：要素間のパワー平衡を定式化し、各要素のエネルギー値を求める方法



出力情報（教師データ）



騒音スペクトル



パターン学習／
記憶

入力情報

船舶要目（L, B, D, ...）

機関要目（メーカー, 型式 ...）

内装仕様（床材, 壁材, 天井材, ...）etc



実船計測で得た騒音知識を基に、入力情報を決定

自己組織化マップ (SOM) モデル

コホネンが脳皮質の視覚野をモデル化したニューラルネットワークの一つ
似たものを自然にまとめて**分類**する**教師なし学習**




図1 ニューラルネットワーク (SOM)




図2 SOM学習アルゴリズム






図3 SOM船舶分類結果 (一例)


ニューラルネットワークを活用した船内騒音予測 (3)

OA値誤差: -7.0 dB(A)

OA値誤差: -0.8 dB(A)



<運用イメージ>



4. まとめ

1. 近年、人工知能研究がニューラルネットワークを中心に発展している。
2. ニューラルネットワーク学習は、**画像認識**、**自然言語処理**、**最適化問題**、**分類問題**、**推論・予測問題**に適用できる人工知能研究の核になっている。現行**CNN**では、大量の学習データが必要となるため、適用分野によっては障害となる恐れがある。**GAN**など新たな技術が、学習データの課題を克服できると報告されている。
3. **LSTM**が**翻訳技術**など、**自然言語処理分野**の進展に寄与している。**対話処理**は**シンボルグラウンディング**（コンピュータが意味を理解できるか）が人工知能の分野で大きな問題であるが、幼児がコトバの意味を学んでいるのではなく、コトバの使用機会（規則）を学んでいるとする言語ゲームが一つのヒントになる。また、対話は、**背景知識（スキーマ）**などを活用した**推論処理問題**であり、今後ますます、研究が活発になるとと思われる。
4. 紹介した適用研究を実用化させるとともに、新たなテーマにも取り組む予定である。

ご清聴ありがとうございました