

## 10 最新の人工知能技術の活用

## — ネスティング AI と画像認識による点検 —

構造基盤技術系 \* 谷口 智之, 平方 勝, 藤本 修平, 山根 健次  
構造安全評価系 馬 沖

## 1. はじめに

近年、機械学習の一種である深層学習（ディープラーニング）の研究開発が著しく進んでおり、画像処理や物体検出、テレビゲームや囲碁、言語処理やチャットボットなど人工知能（AI）が様々な分野において高い性能を示すことが報告されており、非常に関心が高い分野となっている<sup>1)</sup>。

機械学習には主に教師あり学習、教師なし学習、強化学習の3つに分けられるが<sup>2)</sup>、まず、一つ目の教師あり学習は、入力と出力のデータの関係を学習し、予測や分類を行う手法である。基本的に大量のデータと正解ラベルを用意する必要があり、AI が正解を出力できるように反復計算して学習する。教師あり学習には従来の多層パーセプトロンタイプのニューラルネットワークによる回帰や分類といった活用から、畳み込みニューラルネットワーク（CNN: Convolutional Neural Network）による画像認識、画像内における物体の位置と分類を検出する Region-CNN など含まれる。また、近年、再起型のニューラルネットワーク（RNN: Recurrent Neural Network）が音声認識や自然言語処理といった分野で活用されている。このほか、少量のデータを用いて学習する半教師あり学習などもある。

二つ目に、教師なし学習とは、正解ラベルのない大量のデータに対してデータの規則性を見出す方法である。主成分分析やクラスタリングなどがあり、主にビックデータ解析に活用される。

三つ目に、強化学習とは、長期的な目標を示す数値を最大化するように学習する手法である<sup>3)</sup>。上記2つとは異なり、強化学習では行動主体であるエージェントと、報酬および状態を出力する環境の2つで構成され、報酬につながる行動方針を学ぶ。2017年にDeepMindの開発チームにより強化学習に基づくAlphaGo<sup>4)</sup>が開発され、囲碁において人間のトップ棋士を上回る性能を示し、人工知能が人を越えた出来事として認識されている。囲碁などのゲームのほか、自動運転やロボット制御などの分野においても注目されている。

近年、上記手法に関する研究が進んでおり、予測や物体検出などでは実用例が報告され始めてきたが、一方で、産業利用については限定的な利用にとどまっており、さらなる研究開発が必要な状況である。

本報では、最新の人工知能技術について2章で説明するとともに、人工知能技術を活用した海事産業分野への利用に関する研究例として、3章では深層強化学習を活用したAI ネス

ティング、4章では物体検出技術を活用した風車ブレードの点検に関する基礎的な研究について紹介する。

## 2. 最新の人工知能技術動向

以下2.1~2.3に挙げる3つの分野において、それぞれ基礎となるAI手法と応用研究例の両面から最新の人工知能技術の動向を紹介する。ただし、本章では紙面の都合、数学的な背景については割愛するため、文献を参考されたい。

## 2.1 予測・分類

予測や分類は基本的に従来の多層パーセプトロンタイプのニューラルネットワークが基礎技術となり、図-1に示すような各ユニットにより構成される。隣接層のユニットはすべてが全結合されており、その入力層を $x$ のベクトル、隠れ層の重み係数を $W_h$ の行列、定数項（バイアス）を $b_h$ のベクトルとし、シグモイド関数に代表される活性化関数を $f$ で表した場合、入力に対する隠れ層の出力 $h$ は $h = f(W_h x + b_h)$ 、最終出力 $y$ は $y = f(W_y h + b_y) = f(W_y f(W_h x + b_h) + b_y)$ と表される。このように入力 $x$ と出力 $y$ のデータの関係をモデル化するネットワークを順伝播型ネットワークと呼び、未知定数である $W_h, b_h, W_y, b_y$ を決定する操作が学習である。これらの未知定数は入力 $\tilde{x}$ と出力 $\tilde{y}$ の学習のためのデータセット（訓練データ）から $\tilde{y}$ とニューラルネットワークの出力 $y$ との誤差が最小となるように決定される。誤差を表す関数を誤差関数（error function）もしくは損失関数（loss function）と呼び、損失関数を最小化するようにパラメータを決定する手法として誤差逆伝播法を用いた確率的勾配降下法などがある。

図-1は隠れ層が1層であるが、多層に拡張したディープニューラルネットワークにより、種々の実問題に対して過去の記録を超える性能を示し始めている。一方で、未知パラメータなどが性能に対してどのように寄与しているのか分かり難くブラックボックス化するなど課題が残る。

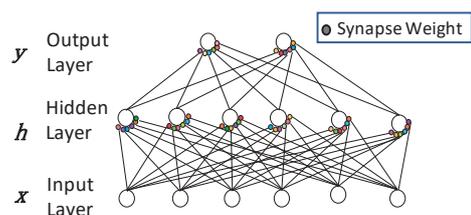


図-1 多層パーセプトロンタイプのニューラルネットワーク

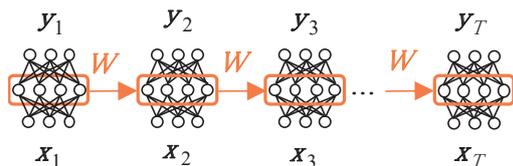


図-2 再起型ニューラルネットワーク

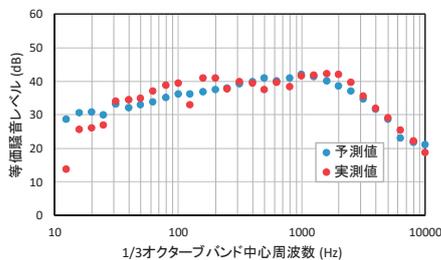


図-3 ニューラルネットワークによる騒音予測

また、上記ニューラルネットワークを音声や言語、動画画像といった時系列データに対して効果的に適用できるように研究されているのが図-2 に示す再起型ニューラルネットワーク (RNN) である。RNN は図-2 に示すように時系列の入力  $x_1, x_2, x_3, \dots, x_T$  に対して、順番に主に時系列の出力  $y_1, y_2, y_3, \dots, y_T$  を出すネットワークである。音のような時系列データ、文脈のような時間軸方向の依存関係のあるデータを取り扱うのに有効な手法である。

以上、多層パーセプトロンタイプのニューラルネットワークと再起型ニューラルネットワークに関する基盤技術について説明したが、これらを用いた応用研究が進められている。例えば、長谷川ら<sup>5)</sup>は風力発電機の主軸受けを対象に、増速機から正常時と損傷時の2種類の振動データセットを用いてディープニューラルネットワークの学習を行い、異常検知能力が従来手法を大きく上回ることを示している。また、平方ら<sup>6)</sup>は騒音実測データを用いてニューラルネットワークの学習を行い、図-3 に示すように各居室の騒音レベルの予測を行っている。R. Evans ら<sup>7), 8)</sup>はニューラルネットワークを活用してタンパク質のアミノ酸配列から3次元のタンパク質構造を予測する手法を開発している。アミノ酸間の距離と角度をそれぞれ別々のネットワークで予測し、3次元構造を予測し、国際タンパク質構造予測コンテストのA7D部門にて1位の性能を示している。

このように、従来のニューラルネットワークをうまく活用することで従来手法を上回る性能を出すことが近年報告され始めている。

## 2.2 画像認識・物体検出

物体検出とは、画像内における物体の位置と分類を検出するものであり、重要な基盤技術として、畳込みニューラルネットワーク (CNN) がある。2.1 節で示したニューラルネットワークでは隣接層は全結合であったが、CNN は図-4 に示すようにフィルタを用いて特定の領域のみが結合をもつ畳込み層を持

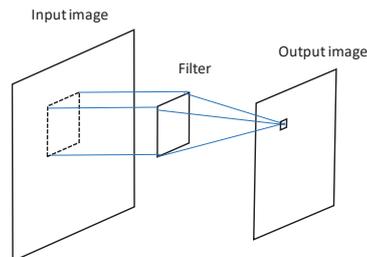


図-4 畳込み層

ち、このフィルタの係数を学習によって決定する。また、このフィルタが最大値や平均値を抽出する操作であるプーリング層を有することも CNN の特徴である。さらに、画像内で物体となる候補領域を検出し、その領域ごとに CNN で分類することで物体の位置と分類を検出する Region-CNN も盛んに研究されており、リアルタイムで検出できるよう高速化された Faster R-CNN<sup>9)</sup> や Single Shot MultiBox Detector (SSD)<sup>10)</sup>、You Only Look Once (YOLO)<sup>11)</sup> などがある。

これら画像認識技術を活用した応用研究として、例えば、全ら<sup>12)</sup>は CNN を用いて車載カメラから撮影された路面画像より、ひび割れを検出および評価する手法を開発しており、目視による診断に近い結果が得られている。また、平方ら<sup>13)</sup>は Faster R-CNN を用いて船舶のタンク・ホールド内画像から構造部材を検出する手法について検討している。画像認識技術による応用研究例は幅広く、近年盛んに研究が進んでいる。また、敵対的生成ネットワーク (GAN)<sup>14)</sup> に関する研究も盛んに進んでおり、Tao Xu ら<sup>15)</sup>は GAN を用いて文章から画像を生成するなどマルチモーダルな研究が行われている。

## 2.3 最適化・制御

強化学習は、図-5 に示すように、制御器 (エージェント) がシステム (環境) から現在の状態とそれに伴う報酬を観測し、それに基づいてシステムに対して働きかける行動を計算する。この行動によりシステムが新しい状態へと遷移し、上記が繰り返される。強化学習ではこのシステムから得られる報酬の総和を最大化するようにエージェントを学習する。学習には割引率を考慮した報酬の総和を求める Q 学習と、どの行動が相対的に良いかを表す方策を直接求める REINFORCE などがある。深層強化学習ではエージェントが状態から最適行動を近似的に推定する手法にディープニューラルネットワークや CNN が用いられる。



図-5 強化学習の概要

応用研究として、例えば Volodymyr Mnih ら<sup>16)</sup>は従来の Q 学習アルゴリズムに CNN を適用した Deep Q Network (DQN) を構築し、Atari2600 と呼ばれるビデオゲームに対して、ゲーム画面の画像データから直接最適な行動を推定することで、過半数のゲームにて人間を超える性能を示している。また、近年は計算機の性能を活用し、分散学習を行う手法も研究されており、Ape-X DQN<sup>17)</sup>などの手法は人間をはるかに凌駕する性能が示されている。このほか、David Silver ら<sup>4)</sup>は囲碁を対象に、モンテカルロ木探索と A3C (Asynchronous advantage actor-critic) を活用した AlphaGo を開発し、人間のプロ棋士を打ち破るほどの性能を示し、後に人間の棋譜データを用いずに学習を行い更なる性能向上を果たした AlphaGo Zero<sup>18)</sup>を開発している。DeepMind ではリアルタイム戦略シミュレーションゲームである StarCraft II を対象として AlphaStar<sup>19)</sup>を開発しており、プロのゲーマーに対して圧勝する結果を示している。また、ロボティクス分野においても広く活用されており、Sergey Levine ら<sup>20)</sup>はロボットアームによる物体把持について、画像データから CNN を用いて行動を推定する手法を提案している。

このように、強化学習は人間を大きく上回る性能を示している一方で、産業応用についてはあまり進んでおらず、より一層の研究開発が必要である。

### 3. 深層強化学習を活用した AI ネスティング

2 章までは最新の人工知能技術について紹介したが、本章ではその中の強化学習について造船分野への応用を目指し、株式会社大島造船所と海上技術安全研究所とで共同研究を実施している AI ネスティングについて紹介する。

#### 3.1 ネスティング作業の自動化について

造船分野では、長方形の鋼板から船体構造を構成する様々な形状の部材を切り出すが、複数の部材をできるだけ廃棄する面積が少なくなるよう、歩留まり率が良くなるように配置すること（ネスティング）が望まれる。これまでに歩留まり率が良くなるような最適配置を自動で出力する自動ネスティングに関する研究が行われており、例えば、山内ら<sup>21)</sup>は遺伝的アルゴリズムを用いて自動ネスティングシステムを開発し、長島ら<sup>22)</sup>は確率論的手法による新たなアルゴリズムに基づく手法を提案している。しかしながら、自動ネスティングによって出力された結果に対し、人手による手直しを行っているのが現状であり、人手に代わる更なる自動ネスティング手法の開発が期待されている。

一方で、2 章で述べた強化学習は、人手を介することなく自律的に学習し性能が向上していく特徴がある。また、David Silver らの研究<sup>4)</sup>にあるように、人間の結果を活用することが可能であるため、膨大な学習により人手と同程度もしくはそれ以上の自動ネスティングが実現する可能性がある。

そこで、本研究では船殻部材のネスティングを対象に、深層強化学習を用いた自動ネスティング手法の開発を目的としている。具体的には DQN を活用して船殻部材の 2 次元データから最適配置を推定するシステムを構築し、テストデー

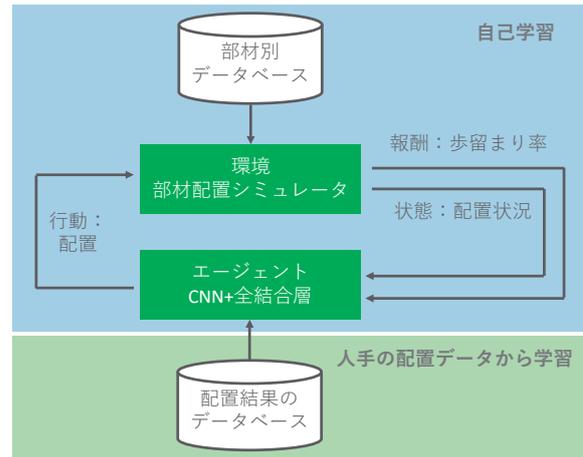


図-6 AI ネスティングの概要



図-7 配置結果の例

タにて検討を行った。

#### 3.2 AI ネスティングの概要

提案する AI ネスティング手法は図-6 に示すように自己学習と人手の配置データから学習する部分の 2 つで構成される。自己学習では、まず一品ごとの部材別データベースから配置したい部材を複数個選び、環境である部材配置シミュレータに入力する。部材配置シミュレータでは、歩留まり率と現在の配置状況を出し、エージェントは現在の配置状況から一つの部材に対してどこに配置すればよいかを出力し、再び部材配置シミュレータにて次の配置状況へ遷移する。これを繰り返し実施し、報酬の総和、つまり歩留まり率がよくなるように学習を行う。次に、人手の配置データから学習する部分については、人手の配置結果をまず行動履歴として分解し、それらを模倣するようにエージェントに学習させる。これにより、人手の良い結果と同様の結果を出力できるようになる。図-7 は AI ネスティングによって配置された結果の一例である。左図は 3 個の部材を配置した結果、右図は 10 個の部材を配置した結果であり、部材を濃い青色～黄色で色分けして表示している。このように、強化学習および人手の配置データを活用することで、人手による修正が不要なレベルで配置できる可能性を確認している。

#### 3.3 3章のまとめ

深層強化学習をネスティング問題に対して応用し、自己学習と人手による配置データから学習する部分の 2 つ学習を構築することにより、人手の手直しが不要なレベルの結果を得ることができた。今後はより一層歩留まり率の良い解を出力できるような性能向上と、多様な部材に対する汎用性向上など実用化を念頭に置いた検討を実施する。

#### 4. 物体検出技術を活用した風車ブレードの点検

本章では2章で述べた画像認識・物体検出技術に関する応用研究として、洋上風力発電ブレードに対する落雷痕の検出について紹介する。

##### 4.1 背景

風力発電ブレードへの落雷は、ほとんどの場合、レセプタに被雷し問題なく対処されるが、稀にレセプタを外れてブレードを構成するGFRP (Glass Fiber Reinforced Plastics) 部に落雷し、破壊される被害が報告されている。GFRP層が破壊されたまま風車の運転を続けた場合、繰り返し荷重による疲労等により破壊箇所が拡大しブレード折損等の大事故につながる恐れがある。このため、風車が被雷した場合は運転を停止させ点検する必要がある。本研究では、こうした点検のコスト低減あるいは点検作業の短縮による風車のダウンタイム低減を目指して、物体検出技術を用いて自動的に落雷痕を検出し、レセプタあるいはそれ以外の箇所に落ちたのかを判別する方法について検討した。

##### 4.2 SSDによる落雷痕検出手法の概要

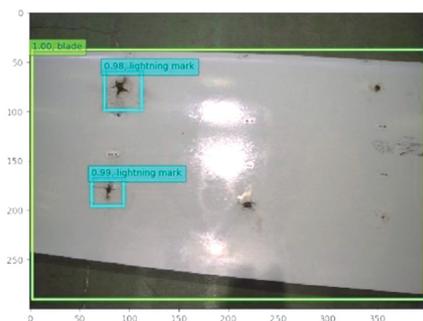
本研究では、リアルタイム物体検出技術の一つであるSSDを活用した。図-8(a)に示すようなNEDO風力発電高度実用化研究開発「雷検出装置等の性能・評価技術の開発(H28~H29年度)」にて制作された模型風車ブレードを用いて、正常な部分と落雷痕のある個所の画像データを作成し、ブレード(blade)、落雷痕(lightning mark)、レセプタ(receptor)の検出について学習を行った。落雷痕は、図-8(b)に示すように模擬雷によりブレード表面に生成した。

図-9に学習に用いていない検証用データに対する検出結果の一例を示す。このように、風車ブレード自体の検出や落雷痕、およびレセプタの検出が可能であることが確認され

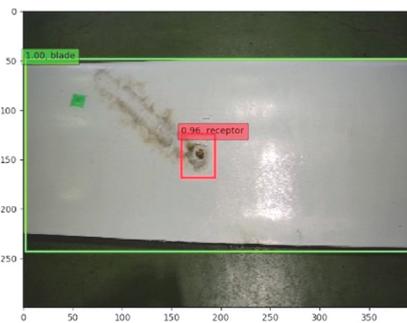


(a) (b)

図-8 模型風車ブレード(a)と模擬落雷痕(b)



(a)



(b)

図-9 検証用データに対する検出結果の例

た。一方で、図-9(a)に示すように光の反射の影響で一部落雷痕を検出できていない箇所もあり、今後の改善が必要である。

##### 4.3 4章のまとめ

物体検出技術の一つであるSSDを活用して、風車ブレードの落雷痕の検出を試みた。おおむね落雷痕とレセプタの検出が可能であることが分かったが、一部検出できていない例がみられる。今後はプレ処理の実施、学習データを増やすなど性能向上と汎用性向上に関して検討する。

#### 5. まとめ

本報では、最新の人工知能技術について、その基盤技術と応用研究例を、予測と画像認識・物体検出および強化学習の3つに分けて紹介した。それぞれ研究が盛んに行われており成果も報告され始めているが、一方で、限定的な適用にとどまる。本研究では、3章にて強化学習を用いた自動ネスティング手法について紹介し、人間の手直しが不必要な配置結果を出力できることを示した。4章では物体検出技術による風車ブレードの点検について紹介し、SSDを活用した点検の可能性について示した。これらの研究には課題が残るものの、今後は性能向上や汎用性向上を目指して検討する。

#### 謝辞

3章の深層強化学習を活用したAIネスティングに関する研究は、株式会社大島造船所との共同研究により実施しました。関係各位に深く感謝申し上げます。

4章の物体検出技術を活用した風車ブレードの点検の研究で用いた実験にNEDO雷調査研究の成果の一部を活用しました。また、本研究の一部は国土交通省交通運輸技術開発推進制度の「海洋分野の点検におけるドローン技術活用に関する研究」にて実施しました。関係各位に深く感謝申し上げます。

#### 参考文献

- 1) 機械学習プロフェッショナルシリーズ 深層学習, 岡谷 貴之
- 2) UCL Course on RL, David Silver,

- <http://www0.cs.ucl.ac.uk/staff/d.silver/web/Teaching.html>
- 3) 速習 強化学習 —基礎理論とアルゴリズム—, Csaba Szepesvari, 小山田創哲編集, 共立出版
  - 4) David Silver, Aja Huang, Chris J. Maddison, Arthur Guez, Laurent Sifre, George van den Driessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot, Sander Dieleman, Dominik Grewe, John Nham, Nal Kalchbrenner, Ilya Sutskever, Timothy Lillicrap, Madeleine Leach, Koray Kavukcuoglu, Thore Graepel, Demis Hassabis, Mastering the game of Go with deep neural networks and tree search, NATURE, Vol.529, 2016, pp.484-489
  - 5) 長谷川隆徳, 緒方淳, 村上正宏, 小川哲司, 正常・損傷の表現学習に基づく風力発電システムの異常検知技術の高度化, 第39回風力エネルギー利用シンポジウム, 2017, pp.371-374
  - 6) 平方勝, 馬沖, ニューラルネットワークによる騒音予測, 日本船舶海洋工学会講演会論文集, 2017, pp.637-642
  - 7) R. Evans, J. Jumper, J. Kirkpatrick, L. Sifre, T. F. G. Green, C. Qin, A. Zidek, A. Nelson, A. Bridgland, H. Penedones, S. Petersen, K. Simonyan, S. Crossan, D. T. Jones, D. Silver, K. Kavukcuoglu, D. Hassabis, A. W. Senior, De novo structure prediction with deep-learning based scoring, In Thirteenth Critical Assessment of Techniques for Protein Structure Prediction (Abstracts), 2018
  - 8) Andrew Senior, John Jumper, Demis Hassabis, AlphaFold: Using AI for scientific discovery, <https://deepmind.com/blog/alphafold/>, 2018
  - 9) Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, IEEE Trans. Pattern Anal. Mach. Intell., Vol.39(6), 2017, pp.1137-1149
  - 10) Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg, SSD: Single Shot MultiBox Detector, European Conference on Computer Vision, 2016, pp.21-37
  - 11) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, You Only Look Once: Unified, Real-Time Object Detection, The IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp.779-788
  - 12) 全邦釘, 井後敦史, 南免羅裕治, 黒木航汰, 大窪和明, 車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価, 土木学会論文集, Vol.73(3), 2017, p I\_97-I\_105
  - 13) 平方勝, 馬沖, 谷口智之, 船舶のタンク・ホールド内画像認識に関する研究, 第32回人工知能学会講演論文集, 2018
  - 14) Alec Radford, Luke Metz, Soumith Chintala, UNSUPERVISED REPRESENTATION LEARNING WITH DEEP CONVOLUTIONAL GENERATIVE ADVERSARIAL NETWORKS, International Conference on Learning Representations, 2016
  - 15) Tao Xu, Pengchuan Zhang, Qiuyuan Huang, Han Zhang, Zhe Gan, Xiaolei Huang, Xiaodong He, AttnGAN: Fine-Grained Text to Image Generation with Attentional Generative Adversarial Networks, The IEEE Conference on Computer Vision and Pattern Recognition, 2018, pp.1316-1324
  - 16) Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dharshan Kumaran, Daan Wierstra, Shane Legg, Demis Hassabis, Human-level control through deep reinforcement learning, NATURE, Vol.518, 2015, pp.529-533
  - 17) Dan Horgan, John Quan, David Budden, Gabriel Barth-Maron, Matteo Hessel, Hado van Hasselt, David Silver, DISTRIBUTED PRIORITIZED EXPERIENCE REPLAY, International Conference on Learning Representations, 2018
  - 18) David Silver, Julian Schrittwieser, Karen Simonyan, Ioannis Antonoglou, Aja Huang, Arthur Guez, Thomas Hubert, Lucas Baker, Matthew Lai, Adrian Bolton, Yutian Chen, Timothy Lillicrap, Fan Hui, Laurent Sifre, George van den Driessche, Thore Graepel, Demis Hassabis, Mastering the game of Go without human knowledge, NATURE, Vol.550, 2017, pp.354-359
  - 19) The AlphaStar team, AlphaStar: Mastering the Real-Time Strategy Game StarCraft II, <https://deepmind.com/blog/alphastar-mastering-real-time-strategy-game-starcraft-ii/>, 2019
  - 20) Sergey Levine, Peter Pastor, Alex Krizhevsky, Deirdre Quillen, Learning Hand-Eye Coordination for Robotic Grasping with Deep Learning and Large-Scale Data Collection, International Symposium on Experimental Robotics, 2016, pp.173-184
  - 21) 山内重樹, 手塚研治, 遺伝的アルゴリズムを用いた自動ネスティングシステムの開発と実用化, 日本造船学会論文集, 第178号(1995), pp707-712
  - 22) 長島智樹, 丹羽太, 平野光, 岡田哲男, FINEST アルゴリズムによる鋼板自動ネスティングの実用化, 石川島播磨技法, Vol.44(2004), No3, pp229-236