

# AI技術の適用例と課題

Example of Application and Challenge of AI technology

松 元 利 裕 Toshihiro MATSUMOTO  
長 谷 川 渉 Wataru HASEGAWA  
岸 田 正 幸 Masayuki KISHIDA

## 要 旨

近年、人工知能 (Artificial Intelligence、以下AI) が急激に進化している。ディープラーニングと呼ばれる技術革新を背景に、現在では第3次AIブームとなり、従来のAI技術に比べ性能向上と広範囲にわたる応用がみられるようになってきた。特に、画像処理や音声認識などの分野では大きな成果がみられる。

当社では、強みであるセンサ製品による車両周辺の環境認識技術を開発しており、画像認識以外の分野でもAI技術を適用したセンシング能力の向上や新たな機能の提供などに取り組んでいる。

この取組み内容として、AIの適用例を紹介し、AI構築の難しさや課題について示す。

## Abstract

Artificial intelligence ("AI" hereinafter) has been evolving at a dramatic pace in recent years. Against the background of the technological innovation referred to as "deep learning", we have now entered the third AI boom period in which the performance of AI technology has vastly improved in comparison with past technology and we are now starting to see the possibilities of applications to a wide range of areas. In particular, there have been some very significant achievements in fields such as image processing and voice recognition.

FUJITSU TEN has been developing technology for environmental recognition in and around vehicles by using our sensor products, one of our strong points, as we strive to improve sensing performance and contribute new functions by applying AI technology for use in fields beyond just that of image recognition.

This paper describes the details of these efforts in the form of examples of AI application, as well as discussions of the difficulty and issues of AI construction.

## 1

## はじめに

近年、人工知能(Artificial Intelligence、以下 AI)が急激に進化している。ディープラーニングと呼ばれる技術革新を背景に、現在では第3次AIブームとなり、結果、従来のAI技術に比べ性能向上と広範囲にわたる応用がみられるようになった。

AIが能力を取得するには、その元となるデータの量と質に依存する場合が多い。そのため、種々のデータを多く保有しているネット産業がこぞってAIをサービスに組み込んでいる。また、AI技術のフレームワークが公開されたことや、研究やコンテストなどで使われたサンプルがインターネット上で入手できることなどにより、AI技術の開発に関わる人口が増えさらに進化を加速している。

当社では、強みであるセンサ製品による車両周辺環境認識技術を開発しており、画像認識以外の分野でもAI技術を適用したセンシング能力の向上や新たな機能の提供などに取り組んでいる。しかしながら、手法が確立されていない技術のため課題も多い。本稿では現在注目されているAI技術について簡単に解説するとともに、AIの適用例からAI構築の難しさや課題について示す。

## 2

## AI技術とは

AIとは人工的に作り出した知性や知能を示す。AIを作り出すためのアプローチはさまざまなものがあるが、そのなかの一方式として『機械学習』がある。機械学習は人間が持つような学習能力を機械、すなわちコンピュータや回路などで実現しようとする手法である。ここでは人間の脳の学習機能について簡単に記すとともに、それらを模倣した機械学習の手法について説明する。

## 2.1 脳の学習機能について

脳の学習機能に関わるものとして、神経細胞

(ニューロン)がある(図1)。神経細胞は各樹状突起に刺激が入力されると、その刺激の量やタイミングに応じ軸索から刺激を出力する。




図1 神経細胞概要図

細胞単体の機能は比較的単純であり、単体で実現できることは少ないが、細胞の入出力同士が相互連結しネットワークを構成することで、複数の入力に対し出力を出すような複雑な機能が実現できる(図2)。各細胞間の軸索と樹状突起の結合は、軸索から刺激が入力されることで結合が強化され、より刺激が通りやすく変化する。逆に刺激が入力されないままの結合は、次第に結合が弱まり通りにくくなる。この結合強度の変化は、同系統のデータ入力が増え繰り返されることで一定の値に収束し、ネットワークとしての入力に対する出力の関係が確立される。つまり、ネットワークが入出力の関係を『学習』したと言える。これらの機能が複雑に絡まることで脳の学習機能が実現される。




図2 神経細胞の接続イメージ

## 2.2 AIの学習機能について

『NN(Neural Network)』は近年注目されている機械学習の一種である。ここではAIの学習機能について、NNを例に示す。NNは神経細胞のネットワークを

簡易化しコンピュータで実現したものであり、神経細胞を模擬した人工ニューロンモデル(図3)を活用している。人工ニューロンは神経細胞と同じように、各入力に対する結合強度と、入力に応じた出力をする機能を持ったものである。これらを相互接続しネットワークを構成することで、神経細胞のネットワークと同様に複雑な入力に対して出力を行えるようになる。また、同系統のデータ入力を繰り返し行うことで、各人工ニューロン間の結合強度 $w$ が一定の値に収束し、入力に対する出力の関係を確立できる。つまり、人工ニューロンのネットワークも神経細胞と同じように『学習』の機能を持っている。

ネットワークの構成はさまざまなものがあるが、ここでは例として層状に構成したものを図4に示す。このネットワークは、大きく分けて四つの塊に別かれている。この塊のことを『層』と呼ぶことから、図4のネットワークは『4層のネットワーク』という。1層目の入力はネットワークに入ってくる入力そのものであるが、2層目の入力は1層目の出力となり、その出力結果をさらに次の層に渡す。このように層を重ねていくことで、人工ニューロンの組合せが多くなり、複雑な入力に対応できるようになる。近年では、より複雑な学習をさせるため、層の数を拡大する傾向にあり、大規模な多層のネットワークを使った学習が主流となっている。






図3 人工ニューロンのモデル図



単ニューロンモデル

図4 ニューラルネットワークの概念図

繰り返しのデータ入力による『学習』が行えることから、人工ニューロンを用いたNNは神経細胞のネットワークの機能を模擬できていることがわかる。しかしながら、工学的な面を考慮すると、ネットワークが入出力関係を勝手に学習するのではなく、任意の入出力関係を確立できたほうが利用しやすい。そこで機械学習では入出力の関係が所望のものになるよう意図的な『学習』を行う場合がある。ここでの意図的な学習とは、入力に対する正しい出力を教示し繰り返し学習させることで、所望する入出力関係を確立させることを示す。これは、結合強度 $w$ の値が変化することでネットワークの入出力関係も変化することを利用している。図5に意図的な学習による $w$ の調整イメージを示す。入力が犬の画像であるのに対し出力は猫となっているため、これは誤りである。そのため、この入力に対して出力が犬となるように $w$ の値を調整する。このような調整を繰り返し行うことで意図的な学習が実施でき、任意の入出力関係を構築することができる。

図5 学習による $w$ の調整イメージ

## 3

## AI技術の適用例と課題

AI技術において、ネットワークの構成である『ネットワーク構造』と、学習のための繰り返し入力データである『学習データ』は認識能力に大きく関わる要素である。本章ではAIを適用した技術の一部を例として、ネットワーク構造と学習データの差異による認識能力の違いからAI適用の課題について示す。

### 3.1 ネットワーク構造の差異による認識能力の変化例(上方物検出技術)

ミリ波レーダは、レーダ本体から照射されたビームが対象物に反射した反射波を受信することで物体を検知する。このようなレーダの課題の一つに、遠方の反射体が地上にある物か、陸橋や案内看板のように高い位置にある物かを判断するものがある(図6)。




図6 ミリ波レーダの上方物判定イメージ

この問題と密接に関わるレーダの要素として、高い位置の反射体ほど距離による反射レベルの変動が大きいという特徴がある。今回はその特徴に着目し、反射体までの距離とその反射レベル変動を用いて、AIによる上方物の判定を試みた。AIへの学習データは、レーダの出力データとし、学習データに対する正

解は車両の走行記録から上方／下方物を分け使用した。

ここではAIのネットワークの差異による認識能力の変化の一例として、2種のネットワークを使用した例を表1に示す。

表1 各ネットワークでの識別結果

| ネットワーク層数       | 識別率   |
|----------------|-------|
| 大規模ネットワーク(22層) | 52.5% |
| 小規模ネットワーク(5層)  | 97.5% |

一般的には層数が多い大規模なネットワーク構成の方が認識能力は高くなる傾向にあるが、本件では大規模なネットワークよりも小規模なネットワークの方が認識能力が高い結果となった。このことから、今回のネットワーク構成では、使用した小規模ネットワークの方がデータの処理に向いていたことがわかる。

現在のAI技術は汎用的な処理ができるものではなく、一部の専用のタスクに特化したものである。そのため、一般的な認識能力が高いとされるネットワーク構造を使用するだけでは、入力データによっては認識能力が向上せず所望の出力が得られないことも多い。入力データと求める出力が決まっている場合には、正しい学習を行えるようデータ種類や性質などを踏まえ、その処理に向けたネットワーク構成を選択、作成する必要がある。

### 3.2 学習データの差異による認識能力の変化例(空き場所検知技術)

画像認識の分野は現在のAIの最も得意とする技術の一つであり、学習方法についても基礎的な部分では確立されている。しかしながら、画像認識の分野においても所望の出力を得るためには入力データや学習データについて正しく作成、調整する必要がある。

ここでは、AI技術の適用先を車両の前方カメラの画像から駐車場の空き場所を検知する『空き場所検知システム』とし、そのなかでも駐車車両位置を検出する技術を例に、2種類の学習データを使用し、学習



データの差異によるAIの認識能力の変化を示す。このとき、駐車車両の検出結果は画像上の車両の位置に矩形を重畳する形で表示するが、システムの適用先の想定から、矩形は車両位置との一定の関係性があり、個々の車両が分別できる必要がある。また、学習データはさまざまな方向の車両画像が含まれる汎用のデータセットと、システムの処理に合わせ作成、調整したものの二つとする。

### 3.2.1 汎用画像を用いた学習結果

汎用のデータセットを用いて学習、認識を行った結果を図7に示す。




図7 汎用データの学習による判定結果

車両について認識は出来ているものの、位置を示す矩形は大まかな位置しか合っていない。結果的には空き場所を明確化できる車両座標ではなかった。また、矩形が車両複数台を合わせた領域を示していることから、システムの処理に使用できない結果となった。

### 3.2.2 部分データを用いた学習結果

空き場所検知システムの動作を想定すると、駐車場内の環境に限られる。この状況下では、車両全体の検出は難しいが、車両の前面／後面の領域は常に検出できる可能性が高い。そこで、車両の前面／後面領域に限定した画像を作成し、学習、認識を実施した。認識結果を図8示す。




図8 部分画像での学習による判定結果

車両全体の画像を用いて学習した結果に比べ、矩形位置と車両の位置が一定の範囲内に納まっていることがわかる。また、矩形領域も個々の車両の範囲に納まっていることから、判定情報として使えるレベルにあることを確認できた。

### 3.2.3 学習データの差異による学習結果の比較

図9に各学習データを用いたAIでの車両検出数と目標との比較を示す。ここでは車両位置と矩形範囲の差異が規定の範囲内に収まっている検出結果だけを車両の検出台数とする。また、システムの性質上、車両の位置、数を正しく判断する必要があるため、状況の変化に合わせた目標を設定した。この目標以上の検知数があれば、システムへの転用が可能だが、大きく下回っていた場合にはシステムへの使用が出来ない結果となる。なお、経過時間が進むごとに画像の撮影範囲内にある車両台数が減少する。部分データを用いた学習結果では全体を通して目標以上又は目標に近い結果となり、システムへの使用が可能であるのに対し、汎用データでの学習結果では0～6秒の間で目標を大きく下回りシステムへの使用が出来ないことがわかる。これらの結果から、AIが所望の認識能力を得るためには、適切な学習データの選び方も重要であることを示した。一般的な処理方法やデータを用いるだけでなく、目的に応じ適切な入力データ／学習データを選択、作成することで、学習時間や認識率

に差異が生じ、所望の出力結果により近づくような認識能力を得ることができる。




図9 学習データの違いによる車両検出台数の差異

## 4

## おわりに

本稿ではAIを適用したシステムの一部を例に、学習データやネットワーク構成の差異による認識能力の変化について示した。AIに所望の認識能力を持たせるためには、システムに適したネットワーク構成や学習データを選択することが重要である。

AI技術はさまざまな分野で研究が行われ、日々新たなネットワーク構成や技術が開発されており、大いに期待ができる技術である。一方、画像処理や音声認識などの分野では大きな成果を挙げているが、これらのAIは専用のタスクに向けたものであり、それ以外の処理は行うことができない。さまざまな技術を

AI化するためには、その技術に関わる企業が持つデータやノウハウが重要である。蓄積されたデータやノウハウを活用することで、より高性能なAI技術を開発することができる。今後も、AIを適用した新たな技術を開発することで、センシング技術の高度化を図っていきたい。


## 謝辞

本稿の執筆に際し、多大なご協力を頂いた富士通株式会社 アドバンスドシステム開発本部 AIプラットフォーム事業部様に心より感謝の意を表します。

## 参考文献

- 1) K. Simonyan, A. Zisserman: Very Deep Convolutional Networks for Large-Scale Image Recognition, ICLR, 2015.
- 2) Y. LeCun, L. Bottou, Y. Bengio and P. Haffner: Gradient-Based Learning Applied to Document Recognition, Proceedings of the IEEE, 86(11): 2278-2324, November 1998.

## 筆者紹介



松元 利裕  
(まつもと としひろ)

VICT技術本部  
技術開発室



長谷川 渉  
(はせがわ わたる)

VICT技術本部  
技術開発室



岸田 正幸  
(きしだ まさゆき)

VICT技術本部  
技術開発室