



## 特集記事・3

## 鉄鋼業におけるAI・IoT技術の最前線

# エッジデバイスにおけるリアルタイムAIの可能性

## Possibility of Real-time AI in Edge Devices

(株)エイシング  
代表取締役 CEO 出澤純一  
Jun-ichi Idesawa

岩手大学  
システム創成工学科  
准教授 金 天海  
Chyon Hae Kim

### 1 (株)エイシング(AISing Ltd.)

#### 1.1 エイシング社概要

弊社はDeepLearningとは着想から全く異なる独自開発の機械学習アルゴリズムDeep Binary Tree : DBTの研究開発を行っている。

弊社のビジョンは、「ものづくり」×「AI」であり、両方の領域が重なる部分がターゲットになっている。あらゆるデバイスがIoT化していく時代において弊社は軽量のエッジデバイス用AIを提供して各々のエッジデバイスをよりスマート化していくことを目指している。エッジデバイスとは、自動車、ドローンなどのモビリティや、スマートスピーカー、スマートフォンなどのクラウド(インターネット)側から見た末端機器の総称である。

2016年12月に設立。設立半年後の2017年6月にはベンチャーキャピタルの合同会社テックアクセラベンチャーズから1億9800万円の第三者増資割当を行い資金調達を完了している。その独自性、技術的優位性、ビジネス発展の期待が認められ、2018年6月には経済産業省指定の次世代ユニコーン企業(時価総額10億ドル超の未上場企業)候補としてJ-Startup(経済産業省が推進するスタートアップ企業の育成支援プログラム)に選出され、2018年8月には大学発ベンチャー表彰で経済産業大臣賞を受賞している。

実際顧客企業と進行している共同開発案件の該当分野としては、船舶エンジン、光学センサー、PLC、サーボモーターユニット、FAロボット、射出成形機、建設用クレーン、スマートセンサー、アクチュエーター、ECUなど。主に機械制御系の分野の大手企業と取引を開始している。

その中で、株式会社デンソーとの取り組みがNEDOのAIシステム共同開発支援事業に採択され、ドローン制御をAIで行うエッジデバイスの開発を行なっている。こちらの想定用途としてはインフラなどの保守点検の際にドローンを用い

る。その際ドローンが橋脚の下などで突風にあおられた時にDBTが予測制御を行うことで危険な状態というのを回避することができるようにする。

#### 1.2 独自AIを開発できるチーム

この独自開発が可能なチームは、著者ら早稲田大学理工学部機械工学科出身者が中心となり、機械工学・ロボット工学と機械学習アルゴリズムの分野のダブルスタンダードのエキスパートであることが特徴であり、これによりビジョンとなっている「ものづくり」×「AI」の重なる領域が弊社のターゲット になっている。

## 2 背景

#### 2.1 開発背景

社会背景として、現状の少子高齢化が進んでいる中で日本国内での製品製造における生産性向上が急務である。そこで省人化、生産性向上、製品性能向上を同時に実現できる動的環境変化にも対応可能な軽量のデバイスに組み込み可能な機械制御システムを15年前から筆者らが研究開発してきた。

#### 2.2 Industry4.0

Industry4.0が省人化、コストダウンという視点は当たり前として、世界的には各分野で機械学習により新しいシステムが開発されることで業態変換が起こると考えられている。

例えば空調機器メーカー、ビルメンテナンス会社などの関係性が変わるとは考えられる。ビルメンテナンス会社が自前のビルから取得する生データを用いてビル空調制御システムを機械学習などで実現したと仮定する。横展開として他の競合会社に販売することや、今まで購入先であった空調機器メーカーにもその制御システムを販売していくことが考えられる。

このように商流が逆転したり、業態自体が変換されるなどがIndustry4.0の醍醐味になると考えている。

### 3 AI、機械学習

#### 3.1 AI、機械学習

上述の背景の通り生産性向上におけるAIの期待値は非常に高い。AIは定義が広く曖昧な表現であるが、現在AIと呼ばれる代表的なものとして、AIという広い定義の中に機械学習が含まれる。機械学習とは、人間と同様の学習能力を計算機上で実現させる手法のことである。機械学習が扱う問題は、教師あり学習と教師なし学習に大別できる。教師あり学習とは、入力ベクトルと入力ベクトルに対する出力ベクトルとの組を学習することで未知の入力ベクトルが与えられたときにそれに対する出力ベクトルを予測する問題のことである。

なお、そのような入力ベクトルと出力ベクトルの組を訓練データ (=教師データ) と呼ぶ。

例えば、手書き文字画像 (=入力ベクトル) とその画像に書かれている文字 (=出力ベクトル) から成る訓練データを学習することで、未知の手書き文字画像が与えられたときにその画像に書かれている文字を判別する問題は、教師あり学習である。

#### 3.2 超高速EdgeAI、Deep Binary Tree : DBTの概要

DBTは機械学習の一手法で、限られたエッジコンピュータリソース上で超高速に学習と推論を実行可能で、木構造で構成されており、学習データに基づき最適に木構造が自律的に成長していくアルゴリズムである。

DBTは、「入力ベクトルと出力ベクトルとの関係が非線形かつ連続である非線形連続関数」である教師あり学習問題を解決する手法である。さらに逐次学習と追加学習が可能である。

##### 3.2.1 DBTの学習機能

入力ベクトルを要素とする入力空間 (図2の左) を定め、訓練データの入力ベクトル (図2の三角) により入力空間を階層

的に小さな部分空間へと分割し、部分空間を木構造のノードに代表させる。また、部分空間内の入力ベクトルに対する出力ベクトルの平均を、訓練データの出力ベクトルにより学習する。

このように、各部分空間内の入力ベクトルに対する出力ベクトルの平均を各ノード (図2の円) に学習させることで、入力空間内の入力ベクトルに対する出力ベクトルを学習する。

##### 3.2.2 DBTの予測機能

未知の入力ベクトル (図3の三角) が代表する部分空間内に存在するノードを木構造から探索し、探索されたノード群 (図3の円) からノードを一つ選択する。この選択方法には、「最下層ノード選択法」と「最小誤差ノード選択法」があり、それぞれの選択方法を用いた予測アルゴリズムを「従来予測」と「誤差ベース予測」と呼んでいる。最下層ノード選択法

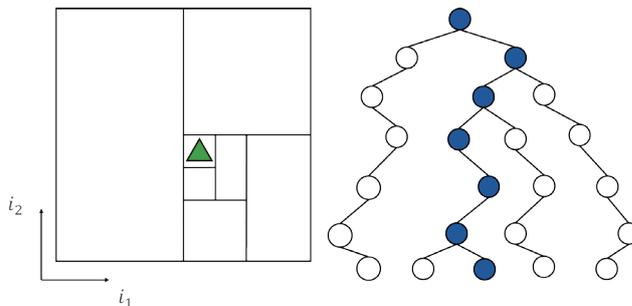


図2 DBT学習過程

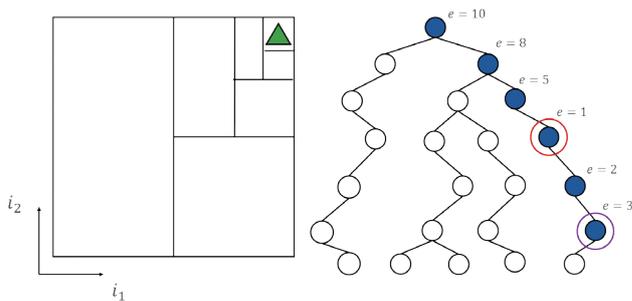


図3 従来予測と誤差ベース予測

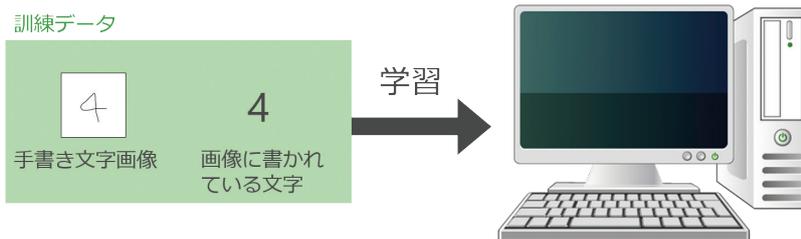


図1 教師あり学習

は文字通り、ノード群で最も深いノードを選択する。つまり、図3の円 (e=3の箇所) で囲ったノードを選択する。一方で、最小誤差ノード選択法は、「ノードが学習した平均出力ベクトル」と「訓練データの出力ベクトル」との誤差eを用いた手法である。そして、ノード群でeが最も小さいノードを選択する。従って、図3の円 (e=1の箇所) で囲ったノードを選択することになる。

## 4 既存AIの技術課題

### 4.1 既存AIのエッジデバイス実装における技術課題

エッジデバイスにおける既存AIの技術課題として、1つ目にAI専門家によるハイパーパラメーターの調整が必要となる。DeepLearningで言えば隠れ層の階層数、層ごとの素子数、素子の発火を司るシグモイド関数などの調整が必要となる。2つ目に計算コストが膨大であり、GPUなどの並列計算コンピューターリソースが必要になる。これらが相まってエッジデバイスへの軽量実装が困難を極めているのが今の世界的な現状である。そこでこれらの既存の課題を解決することが弊社のDBT技術になる。

### 4.2 オンライン型AIとオフライン型AI

現在の主流なAIはオフライン型AIと呼ばれるDeep Learning, Random Forestなどで、バッチ学習を行っており、例えば初め1000個のデータを与えられる前提で全体最適化をかけるような学習方法である。それに対してDBTは1レコードずつ逐次学習を行っていくオンライン型AIである。従来のオンライン型AI, Passive Aggressive : PA, パーセプトロンなどはパラメーター調整も必要であり、オフライン型AIに比べて性能が著しく低いためこれまであまり注目されてこなかった。その中でDBTはオフライン型AIの性能に迫る結果を出すことに成功し、図4の通り、右上→左上→右下→左下の順で学習進行していく。1レコードずつ学習を行う場合でもエラー平均値が単調に減少していくということが機械制御系に有利になる特性である。

## 5 DBTのメリット

DBTのメリットは大きく三つある。

一つ目がAIの専門家AIエンジニアが不要である。DBTはハイパーパラメータを基本的に設定する必要はなく利用がで

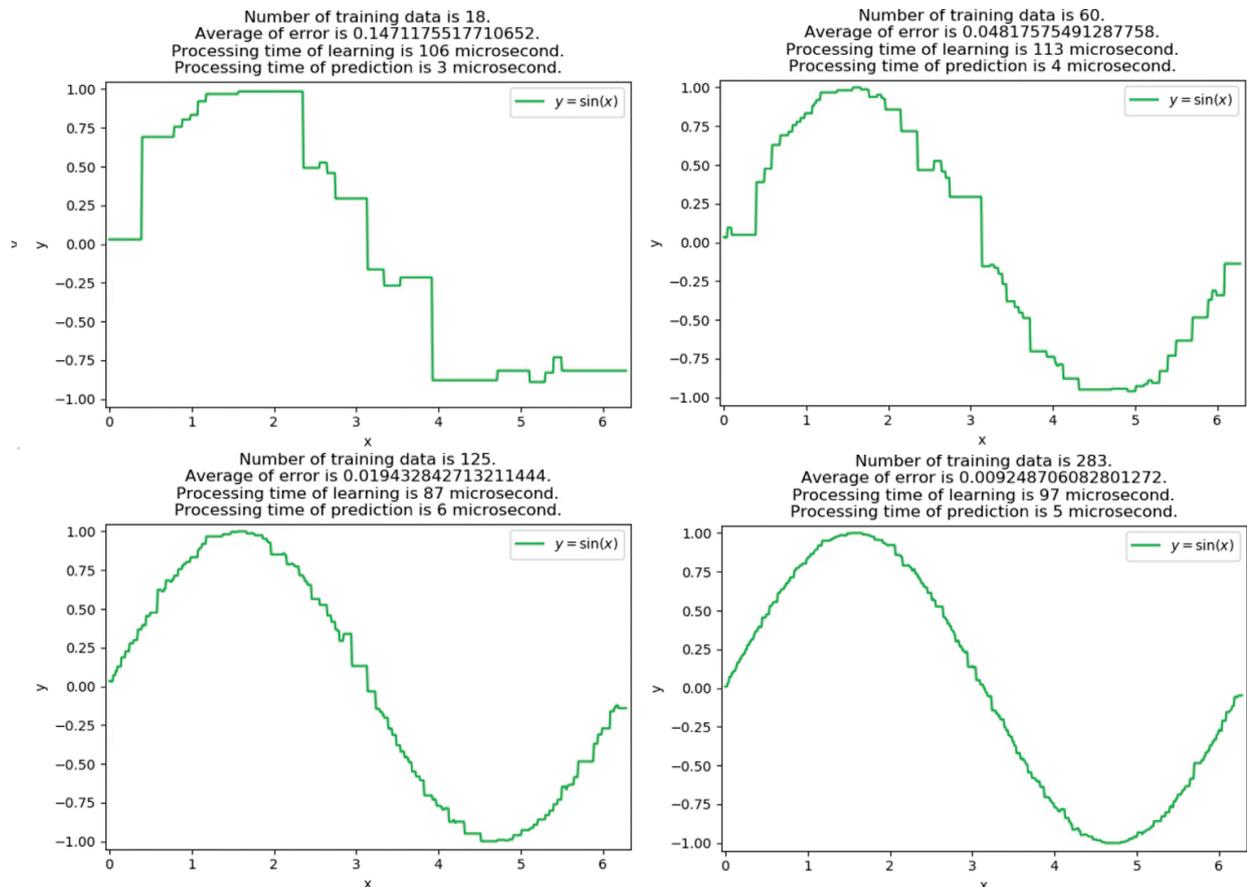


図4 単振動振り子軌道学習

きるためである。

二つ目が製品の個体差や環境の変化、個々人の個体差などに合わせて学習が可能である。

三つ目が最も大きな特徴としてはRaspberryPiなどの安価で限られたコンピューターリソースの中で高速学習が可能である。

## 6 DBTのエッジデバイス実装事例

そもそもDBTは組み込みを念頭に作られたAIアルゴリズムである。図5の写真はRaspberryPiZEROである。アメリカでは約5ドルで販売されている。このRaspberryPiZEROにDBTを組み込み、単振動振子運動の軌跡を学習させた実験において学習速度は50~200マイクロ秒で応答することが

確認でき、推論においては1~5マイクロ秒で応答していた。RaspberryPiのように軽量な限られたcomputingPowerにおいて、ここまで高速応答ができるAIアルゴリズムは現時点では世界でDBTのみである。

## 7 Deep LearningとDBTの比較

表1にDeepLearningとの比較を示す。DeepLearningは画像認識、音声認識が得意なアルゴリズムである。一方DBTは画像認識が苦手である。その理由はDeepLearningの入力種別数は大変量に対応できるようになっており数万ピクセルの入力があっても耐えられるようになっている。それに対してDBTは100個程度しか許容できないようになっている。これは制御系で100個も入力があるような事例が少ないので上限

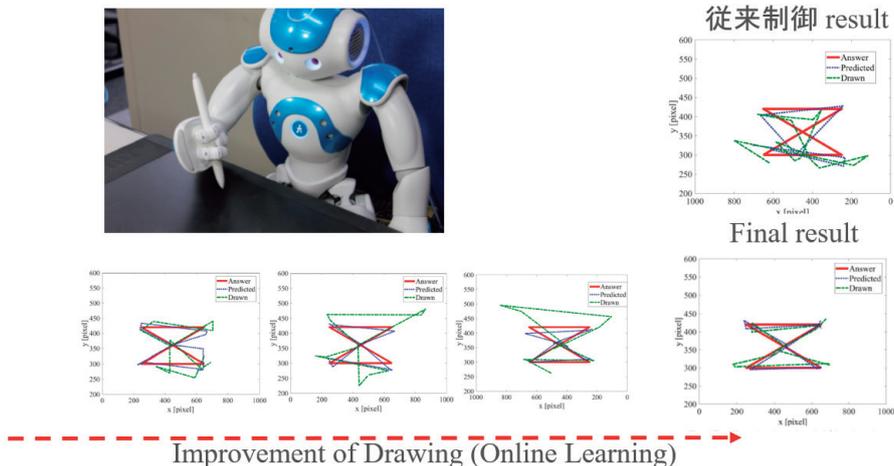
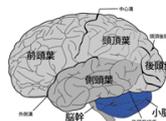


図5 ロボットアーム個体差補正

表1 DeepLearningとDBTの比較

	DeepLearning	DBT
入力種別数	多い(数百万)	少ない(100個程度)
メンテナンスコスト	高い	低い
学習速度	遅い	速い
プログラムの大きさ	大きい	小さい
複雑タスクへの対応	可能	不向き
学習精度	メンテナンス次第	メンテフリーで高精度
追加学習	静的な対応	動的な対応
得意分野	画像認識・処理、音声認識、自然言語処理	機械制御、統計解析、予測制御

DLは認識を司り頭頂葉的な働きに近く、DBTは反射的な反応ができる小脳的な働き



を設定している。ただこれを増やそうとすると計算コストが膨大になり、せっかくの高速応答性の性能を低減させてしまう可能性がある。従ってDBTはメンテナンスコストが低く、学習速度も早く、プログラムの大きさも小さく、また動的な環境変化に対応できる逐次学習が可能となっていることから機械制御系への応用が望ましい。上記の通りイメージ的にはDeepLearningが大脳的な働きであり、DBTは小脳的な働きに近いと考える。

## 8 DBTの実用例

### 8.1 ロボットアームの個体差補正

ロボットの個体差を自動補正できるという事例である。図5のようなNAOというロボットで、比較的安価なため肘肩関節をバックラッシュが存在し、さらにそれぞれのロボットで個体差があり手先位置がずれてくるという問題がある。

従来制御の結果の図5の従来制御resultでは、秒時計型の目標線に対してロボットが描く線がうまく追従できていないことがわかる。一方でDBTを用いて自動的に600回ほど学習を繰り返すことで、最終的にはそれなりにロボット自身の肘肩関節の特性を理解して補正することで、それなりに追従できるようになる(図5のFinal Result)。このようにロボット個体差に追従可能な自動補正を実現できている。

### 8.2 サーボモータユニットの個体差補正

サーボモーターそれぞれを個別に補正をかけられたらどうかという視点のものがこのサーボモーターユニットの事例である(図6)。同じ製造ラインで製造されたものであっても巻線の巻き方、導線の状態などによって個体差が出る。それらを出荷前に自動でキャリブレーションすることが可能である。これより省人化はもちろんのこと製品性能の向上にもつなげることができる。さらに製品出荷後に関してはどのような場所でどのように使われるかは誰も分からない未知の環境になるわけだが、従来技術では実現が難しい。しかしDBTボードを実装すればそれがどのような環境であろうか、その場その場で逐次学習を行うことで自動補正を実現できる現時点では世界で唯一のソリューションである。

### 8.3 自動車制御における物理モデル構築

自動車のエンジンコントロールユニット：ECUの開発における横方向加速度の物理モデルを構築する実証例である。通常は10個のパラメーターをエンジニアが二人がかりで一週間程度かけて調整を行うが、DBTでは5分で完了した。内訳は2分間で実機からデータを取得し、3分間でDBTSaaSで学習を行った。したがって従来の開発手法に比べ工数を99%削減することに成功している。図7のセンサーの実測値のグラフとDBTの予測線のずれの部分がある。丸で示している部分が階段状に破断しているのが見受けられる。これは学習データが足りず、DBTの予測精度が十分ではないことを示

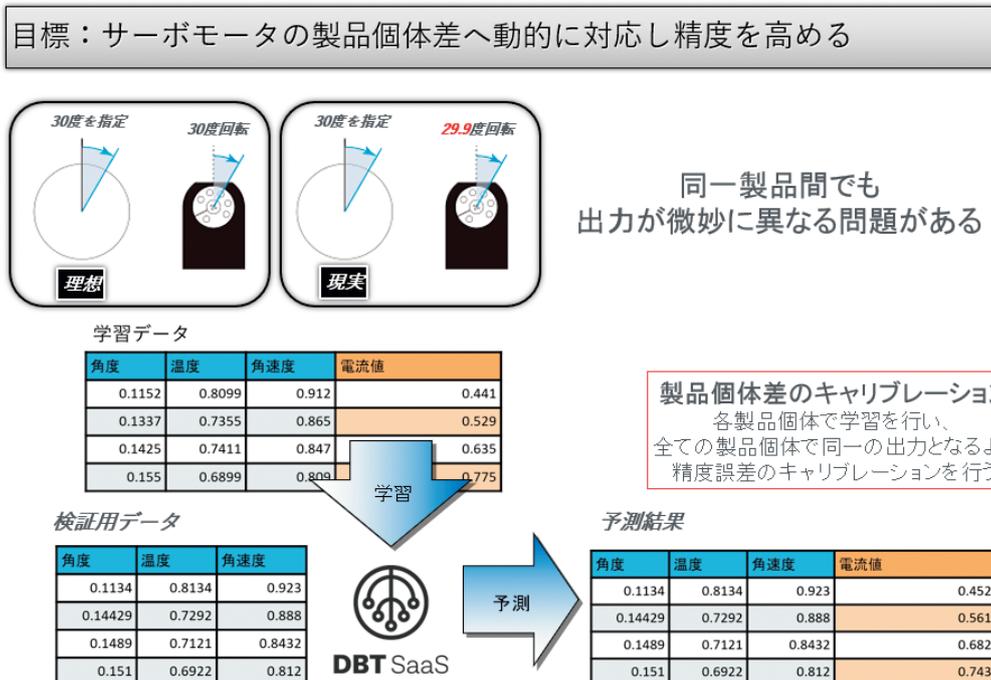


図6 サーボモータユニット個体差補正

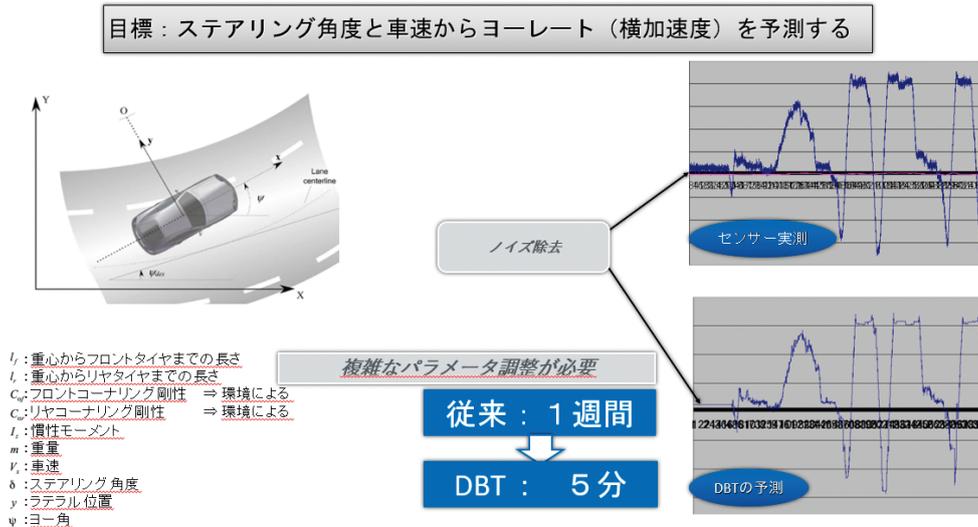


図7 自動車の横方向加速度モデルの構築

している。そこで弊社の真骨頂である追加学習で例えばもう2分間データを取得し、メンテナンスなしで追加学習を行うことで補正することができる。

8.4 船舶における予測制御

船舶の予測制御の応用事例である。高精度な制御ブロックモデルを構築する。まず造波水槽の上で船舶を浮かべて実機の加速度センサーからデータを取得する。その取得した生データから船舶固有の運動方程式を逆算学習させる形で運動方程式にあたるものを学習獲得させる。それを高精度に作ることで予測の予測の予測ということを繰り返しても予測結果が劣化せず従来の制御よりも安定した予測制御を構築することを目的とした。実際にグラフの点線の部分がDBTが瞬時に予測した状態予測である。これをリアルタイムに行うことで高精度な予測制御が実現できた。従来PID制御を行う場合はオーバーシュートと収束時間のトレードオフになる。DBTよりも高精度を実現できる可能性も非常に高いPID制御であるが、実際には調整に要する時間がかかるということと、もし未知の環境においてその場で適応しなければいけないという場合においては、弊社DBTに非常に優位性がある(図8)。例えば津軽海峡で学習した船舶モジュールを太平洋のど真ん中を持って行った時に本当にそれが同じように通用するかどうかというのは不明確である。その場合でもDBTはその場その場で適応できる。人がアルゴリズムの調整をしなくてもできるということが大きなポイントである。

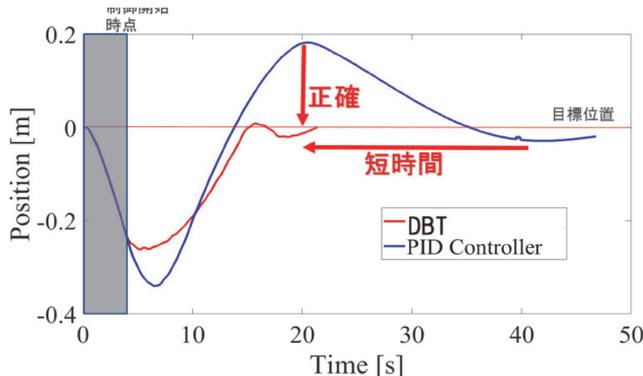


図8 船舶におけるPID制御とDBT制御

ダーからの角度、出力としてACモーターの電圧である。制御を行うコンピュータとしてはRaspberryPi3を用いた(図9)。PID制御では弊社エンジニアがパラメータ調整を30分間行った。結果として外乱を加えた際に倒立状態に戻らない場合もあるという結果になった。一方でDBT用いた制御においては調整は不要であり、代わり学習用のデータの収集時間を1分間とした。その結果、必ず倒立状態に戻ることが実現できたが、チャタリングを起こすことが見受けられた。そこでDBTの真骨頂であるオンライン型AIの特徴の追加学習を行った。先程の1分間のデータに加えて追加で2分間をオンライン学習した結果必ず倒立状態に戻るとことは実現でき、1分間学習の際のチャタリングは改善された。この後も追加学習を行っていけば制御精度は向上していくと考えられる。またモーターの動摩擦係数が経年劣化により個体差が生じて、その個体差に応じてその場その場で取得したデータから補正をかけることができるわけである。

8.5 倒立振子の制振制御(予測制御)

倒立振子の制振制御の実験である。PID制御とDBT制御と比較した。機器構成としては入力をロータリーエンコー

## 9 EdgeとCloudのコラボレーション で実現できる世界

図10はDBT技術でしか実現できない世界観である。

DBTのRestAPIとエッジデバイスに組み込むエッジAIデバイス (DBTボード) の大きく二種類の部品によって構成される。①と③はクラウド側のRestAPIで、②はデバイス側に組み込まれるDBTボードになる。まず①でベーシックネットワークを獲得するためにRestAPIを呼び出しクラウド上で初期学習を行う。この学習獲得したDBTネットワークをDBTボードにダウンロードし各エッジデバイスに組み込み、追加学習を行うことにより、それぞれのベーシックネットワークをスマート化させていく。ここまでの流れでも技術的なアドバンテージがオフライン型機械学習に比べて存在する。

弊社はさらに③の統合学習機能を開発済みである。統合学習機能の流れは、まずエッジデバイス側からクラウドに獲得したDBTネットワークモジュールをアップロードする。こ

のアップロードではセンサーなどから取得した生データそのものではなく、学習時に圧縮されているDBTネットワークモジュールをアップロードする。データそのものをアップロードする場合は、通信コストや応答遅延などの問題が発生するが、圧縮されたDBTネットワークモジュールであれば上述の問題は発生が抑えられる。それぞれのエッジデバイスで獲得されたDBTネットワークモジュールをクラウド上で統合学習を行い、一つのDBTネットワークモジュールを作り出す。これにより、統合学習で獲得されたDBTネットワークモジュール (統合モジュール) は、それぞれの分野におけるデ・ファクト・スタンダードモジュール、社会集合知のようなものが作り出せると考えられる。統合モジュールを①のベーシックネットワークとして更新し、このループによりエッジデバイスで取得可能なデータを最大限に活用できる仕組みである。

例えばロボットアームで1万時間学習する必要がある課題の場合、③の統合学習機能により②のエッジ側の学習を並列分散することで、1万台を1時間で学習することでニアリー

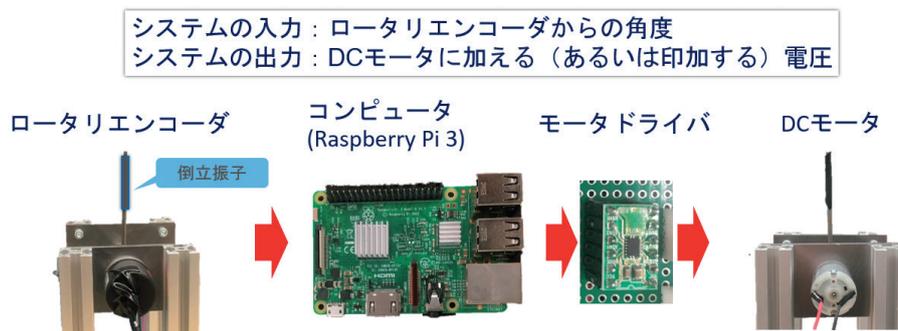


図9 倒立振り子制御

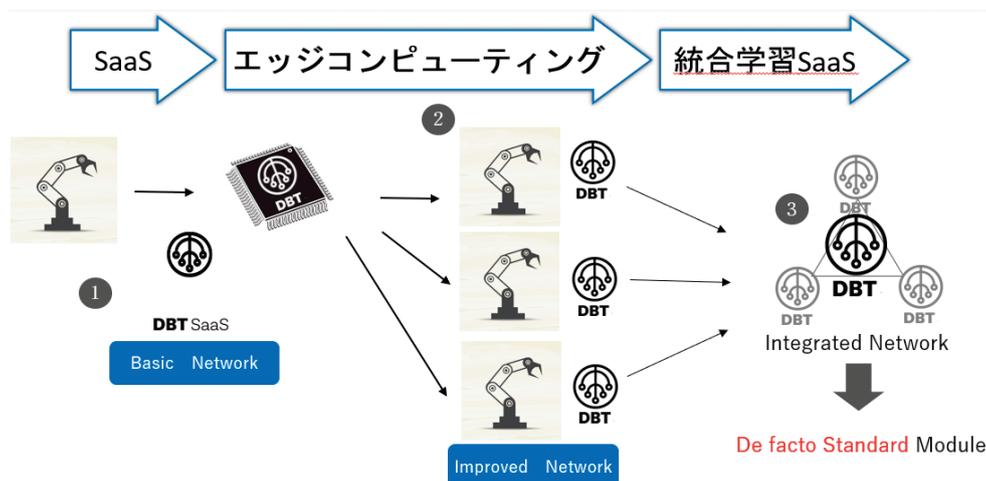


図10 エッジ×クラウド連携による統合学習

イコールな学習を実現することができる。と考える。

以上のように、各分野の各課題ごとのデ・ファクト・スタンダードモジュールができてくると、AIのISO規格的なものを実現でき、よりAIの導入がしやすくなり、且つDBTネットワークモジュール自体もよりスマート化しよりよい世界が実現すると考える。また①②③の間のエッジデバイス管理システムなどの中間システムはMicrosoft AzureであったりAmazonのAWSなど様々な選択肢がある。弊社のビジネス戦略では、SIerと言われる組み込みシステムインテグレーター企業などとの協業を検討しており、中間システム部分を担当してもらう。弊社はRestAPIとDBTボードの提供と研究開発に専念するという方針である。

## 10 鉄鋼業界におけるAI導入アイデア

鉄鋼業界における応用事例としては、圧延制御が考えられる。

圧延は例えば気温、湿度、鉄鋼材質、圧延直前の鉄鋼表面温度、圧延ロール速度、圧延ロール圧力などの要素がある。現在はこれらの状況を総合的に判断し、熟練工が圧延制御している部分が多いと思われる。この職人の勘をシステム化できれば、生産性向上が見込まれる。

実現方法としては、入力の気温、湿度、鉄鋼材質、圧延直前の鉄鋼表面温度の情報から、熟練工だったらこう制御するだろうという圧延ロール速度、圧延ロール圧力の値を予測させるモデルが考えられる。

これらの入出力データの相関性をR2乗などの統計解析手法を用いて分析し、その後機械学習にかけて検証を行い、要求性能が満たされていれば完成となる。上記はアイデアベースであるが今までの実績から、共同開発希望の企業がいれば2ヶ月程度の検証と、1年以内の研究開発で概ね実現できると考えている。

## 11 AI導入の注意点

そもそもAIが必要ない場合や、AIも種類ごとに向き不向き分野がある。それを理解して導入に取り組むべきである。まずは明確な技術課題と、必要なデータの取得、外注するか内製可能なのかを判断する。次に統計解析手法を駆使してデータ間の相関性などを検証する。その上でようやくAI、機械学習を用いて検証、開発と進めていくことが大きな失敗をしない秘訣である。と考える。

### 参考文献

- 1) C.H.Kim, T.Ogata and S.Sugano : Journal of Robotics and Mechatronics, 20 (2008) 5, 757.
- 2) 金天海, 出澤純一, 尾形哲也, 菅野重樹 : 日本ロボット学会誌, 25 (2007) 6, 913.
- 3) 金天海, 尾形哲也, 菅野重樹 : 計測自動制御学会論文誌, 42 (2006) 4, 334.
- 4) C.H.Kim, T.Ogata and S.Sugano : Proceeding of IEEE International Conference on Robotics and Automation, (2007), 92.
- 5) C.H.Kim, T.Ogata and S.Sugano : Proceeding of IEEE International Conference on Intelligent Robots and Systems, (2006), 3154.
- 6) C.H.Kim, J.Idesawa, T.Ogata and S.Sugano : Proceeding of IEEE International Conference on Information Acquisition, (2006), 53.
- 7) C.H.Kim, T.Ogata and S.Sugano : Proceeding of IEEE/ASME International Conference on Advanced Intelligent Mechatronics, (2005), 11192.

(2018年8月31日受付)