



家庭から宇宙まで、エコチェンジ



三菱電機技報

6

2020

Vol.94 No.6

超スマート社会を創造する“Maisart”



目 次

特集「超スマート社会を創造する“Maisart”」

超スマート社会実現のための研究開発のあり方 …… 卷頭言 1
上田修功

三菱電機でのAI技術の現状と今後の展望 …… 卷頭論文 2
三嶋英俊

コンパクトなGAN …… 8
峯澤 彰・吉田 浩・杉本和夫

コンパクトなハードウェアAI …… 12
杉原堅也・山本 亮

Deep Clustering：話者・言語非依存な
シングルチャネル音声分離技術 …… 16
相原 龍・ウイシャーン ゴードン・ルルー ジョナトン

家電ごとの電気の使い方見える化技術 …… 20
矢本恵章・坂上暁子

高精度度に機器の異常を検知するAI …… 24
小部敬純・栗山俊道・中村隆頭・増崎隆彦

制御入出力信号の非定常検出技術 …… 28
中原大貴・柴田昌彦・高井紗紀

AI技術“Maisart”による機器制御の高性能化 …… 32
越山利貢・増井秀之・穂刈寛光・太田 佳・森本卓爾

作業分析ソリューション“骨紋” …… 36
奥村誠司・草野勝大・清水尚吾・五味田 啓・櫻井智史

グラフ推定によるレンジドップラーマップ
上の異種クラッタ領域検出技術 …… 40
谷高竜馬・平嶋一貴・白石 将

超広帯域デジタル制御GaN増幅器 …… 44
小松崎優治・新庄真太郎・Rui Ma

搭乗者の状態推定技術 …… 48
小野良樹

IoT・AI人材育成の全社的取組み …… 52
細谷史郎・加藤嘉明・猪又憲治・清水広之・岡村 敦

豆知識 …… 56

特許と新案

「表示制御装置、表示システム、表示装置、表示方法

および表示プログラム」

「位置制御装置及び位置制御方法」 …… 57

「運転状態分類装置」 …… 58

新型コロナウイルス感染症で亡くなられた方に謹んでお悔やみを
申し上げますとともに、罹患(りかん)された皆さまとご家族及び
関係者の皆さまに心よりお見舞い申し上げます。

表紙：超スマート社会を創造する“Maisart”

三菱電機は、AIを様々な機器に搭載できるように、コンパクトかつ高効率な独自のAI技術の開発を進めてきた。AIのコンパクト化や高効率化によって、従来はAIの適用が難しかった機器も“賢く”することが可能になる。

その実現に向けて、2017年から展開している当社のAI技術ブランド“Maisart(マイサート)”はライフ、インダストリー、インフラ、モビリティの各領域で様々な社会課題を解決し、超スマート社会を創造する。



卷頭言

超スマート社会実現のための研究開発のあり方

Ideal R&D Systems for Realizing an Ultra-smart Society



上田修功 *Naonori Ueda*

理化学研究所 革新知能統合研究センター 副センター長
Deputy Director, RIKEN Center for Advanced Intelligence Project

超スマート社会とは、サイバー空間と現実世界(フィジカル空間)が高度に融合した社会で、“ソサエティ 5.0”として政府によって提唱された。“超スマート社会では、一人一人に、必要なサービスを、必要な時に、必要な形で提供し、一人一人にとって安全かつスマートな生活となるよう社会全体での最適化を目指す”と内閣府の公開資料で説明されている。情報の所有・分析の効率性を追求してきた情報化社会(ソサエティ 4.0)からの延長であるが、“人間中心社会”を目指しているという点で大きく進化している。

超スマート社会を実現するために、どのような分野でどのような技術開発が重要かについては、多方面で詳しく論じられているが、超スマート社会の実現に向けた研究開発のあり方についてはあまり議論されていないように感じる。どのような研究体制、どのような研究アプローチが超スマート社会の実現のために有効であるかを議論することが重要である。

高度経済成長時代、すなわち物づくり全盛時代では、製品の目標スペックが明確(例えば、省エネルギーや小型化)で、その目標が実現できれば市場を押さええることができるという担保があった。それゆえ、全員が同じ目標に向かって一糸乱れず研究開発に取り組むトップダウンの指示系統での研究開発体制が有効であった。情報化社会でも、通信がいつでもどこでもつながるために“標準化”が必要なので、物づくり時代と同じ研究開発体制が適していたと言える。

しかし、超スマート社会は“人間中心社会”である。言うまでもなく、人は一人一人価値観や考え方方が異なる。あるサービスはある人には有用でも別の人には無用、さらには不快なケースも当然あり得る。人間中心社会では、単一種類のサービスではなく、多様なサービス実現のための研究開発体制でなければならない。この場合、複数のチームが個々の目標を掲げ、全体として多様なサービスを生み出すボトムアップな研究開発体制が適している。

超スマート社会では、新たな価値の創造が重視されているが、そのためには、異分野の研究者・技術者間での連携が必須である。物づくりでは、個々の部品の組合せという点で、各々独立な縦割り組織での研究開発が適していたが、価値創造のためには、縦割り組織では連携が十分機能せず、むしろ価値創造の障壁になる。新たな価値創造を目指す超スマート社会の実現には異分野連携を促進するため組織の壁の撤廃が必須と言える。

異分野連携の成功事例として、グーグル傘下の英国ディープマインド社が開発したアルファ碁が著名である。二人零和有限確定完全情報ゲームの中では囲碁が最も難しいとされ、当時、コンピュータ将棋はプロ棋士を負かしていたが、コンピュータ囲碁は今後10年間には勝てないと言われていた。にもかかわらず、アルファ碁は、世界チャンピオンに勝利して世界を驚嘆させた。ゲーム理論分野では、探索をいかに効率化するかに主眼をおいて研究していたが、アルファ碁ではAI(Artificial Intelligence)的アプローチ、すなわち、コンピュータ同士で対戦させ、より良い手を“学習”させるというアプローチを取り入れることで偉業を成し遂げた。まさに異分野連携の賜物(たまもの)である。

また、超スマート社会を実現するにはどのような価値創造を目指すのかを十分議論し、その目的を実現するための目的指向型の研究開発のアプローチが必要である。マグロを釣るために釣りざおの材質の基礎研究に終始していてもマグロは一匹も釣れない。マグロを釣るには海に出なければならぬ。新技術の研究開発だけにこだわらず、既存の技術も含め、今までに用いられていないデータ、技術、考え方方が新たな価値創造の源泉になる。

組織や分野の壁を撤廃し、対象とする当該分野でこれまで交流があまりなかった分野の研究者・技術者が一丸となり、互いの発想を生かした革新的な成果を創出できる研究開発体制が超スマート社会(ソサエティ 5.0)での成功の鍵になる。

三菱電機でのAI技術の現状と今後の展望

Current Status and Future Prospects of AI Technologies in Mitsubishi Electric Corporation



三嶋英俊*

Hidetoshi Mishima

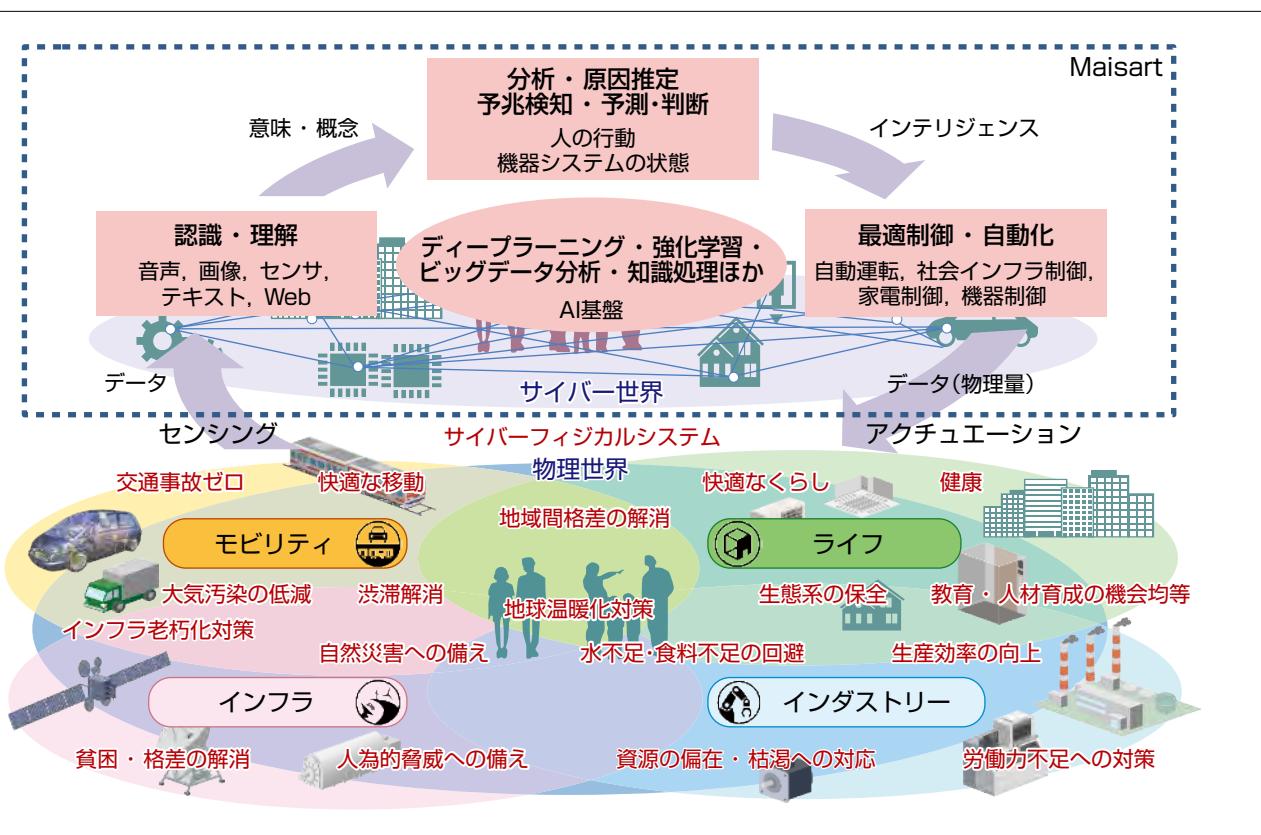
要旨

日本が目指す未来社会の姿として、サイバー世界と物理世界が高度に融合したSociety5.0が提唱されている。この中で様々な社会課題を解決する中心的な技術の一つとして、AI(Artificial Intelligence)(人工知能)技術に大きな期待が寄せられている。

AI技術には、認識、理解などで課題を解決するAI応用技術と、AI応用技術に適用されるAI基盤技術がある。AI基盤技術には、現在のAI隆盛期を迎えるきっかけになったディープラーニング(深層学習)などの機械学習や、機械学習を取り入れたビッグデータ分析、知識処理などがある。AIは膨大なデータから今までの技術では得られなかった規則性を導き出して、物理世界の課題を解決する。しかしながらデータには、欠損や重複、ノイズが含まれ、AIで

得られる結果の成否に大きく影響する。このためAI応用技術ではデータに対して、ドメイン知識を活用してクレンジングや統合、変換を行う前処理を合わせて適用することで、質の高いAIの恩恵を受けることが期待できる。また、AI基盤技術では演算量が多いことが問題である。これまで三菱電機では機器やエッジと呼ばれるローカルな機器群にも適用するために、演算量を削減した独自アルゴリズムを開発し、実用化してきた。今後のAIの更なる普及に向けて説明性向上や公平性の担保などが必要であり、これらの研究開発についても加速していく。

当社のAI技術“Maisart”がサイバー世界に適用され、物理世界の課題を解決する手段として活用されている。



当社のAI技術“Maisart”によるサイバー世界と物理世界とが高度に融合したシステム

物理世界でセンサから収集したデータを、サイバー世界でAI技術Maisartが処理し、その結果を基に物理世界を制御するサイバーフィジカルシステムによって、機器・エッジレベルから人間と同等又はそれ以上の知的な処理で全てのものを賢くし、あらゆる分野の社会課題や顧客課題を解決するソリューションを実現する。

1. まえがき

現在はもちろん未来の社会に向けて、AI技術は、様々な社会課題を解決する技術群で、中心的なものとして大きな期待が寄せられている。AI技術の社会実装は本格化しており、今や専門紙や経済紙で見ない日はないと言ってよく、一般紙でも様々な開発事例が報じられるようになった。

AI技術には過去二度の隆盛期があった。一度目の隆盛期では現実社会の課題を解くことが難しく、二度目の隆盛期では、膨大な知識情報全てをプログラミングすることが現実的に難しく、それぞれ終焉(しゅうえん)を迎えた。ディープラーニングの登場をきっかけに三度目の隆盛期を迎えた今日、データの中から規則や知識を自動獲得することが期待できるようになった。画像認識コンテストで、従来の機械学習方式で実現してきた認識精度である70%台から、ディープラーニングが10%もの差をつけ他を圧倒し、優勝したのは既に8年前のことである。その後、その認識性能は人間のそれを超えるレベルに達したともいわれている。社会実装が進んでいる昨今の状況下では、過去のような隆盛期の終焉を心配するよりも、AI技術を使うことであらゆるものをより賢くし、社会課題を解決して生活の質を向上させるには何を実現すればよいかを多方面から検討すべきであろう。

当社では、様々なAI技術を技術ブランドMaisartとして広く適用を始め、あらゆるものより賢くしていく取組みを進めている。AI技術は応用技術と基盤技術に分けられる。

本稿では、AI応用技術⁽¹⁾とAI基盤技術の現状と動向、及びAI技術の今後の展望について述べる。

2. AI応用技術

2.1 様々な分野に活用されるAI技術

日本及び世界を取り巻く環境で、経済発展が進んで人々の生活は豊かになっているものの、解決すべき社会課題は複雑化している。温室効果ガス排出の削減、気候変動に伴う自然災害への対策、高齢化に伴う労働人口の減少への対策など、経済発展と社会課題の解決を両立させるために、日本が目指すべき未来社会の姿としてSociety5.0が提唱されている。これは、サイバー世界と物理世界を高度に融合させたシステムによって実現される。人類を取り巻く物理世界に置かれた多数のセンサからの膨大な情報を集積・解析して物理世界にフィードバックする世界観を呈している。

多様化する社会課題の解決に向け、当社はライフ、インダストリー、インフラ、モビリティの四つの領域で、グループ内外の力を結集した統合ソリューションを提供し、

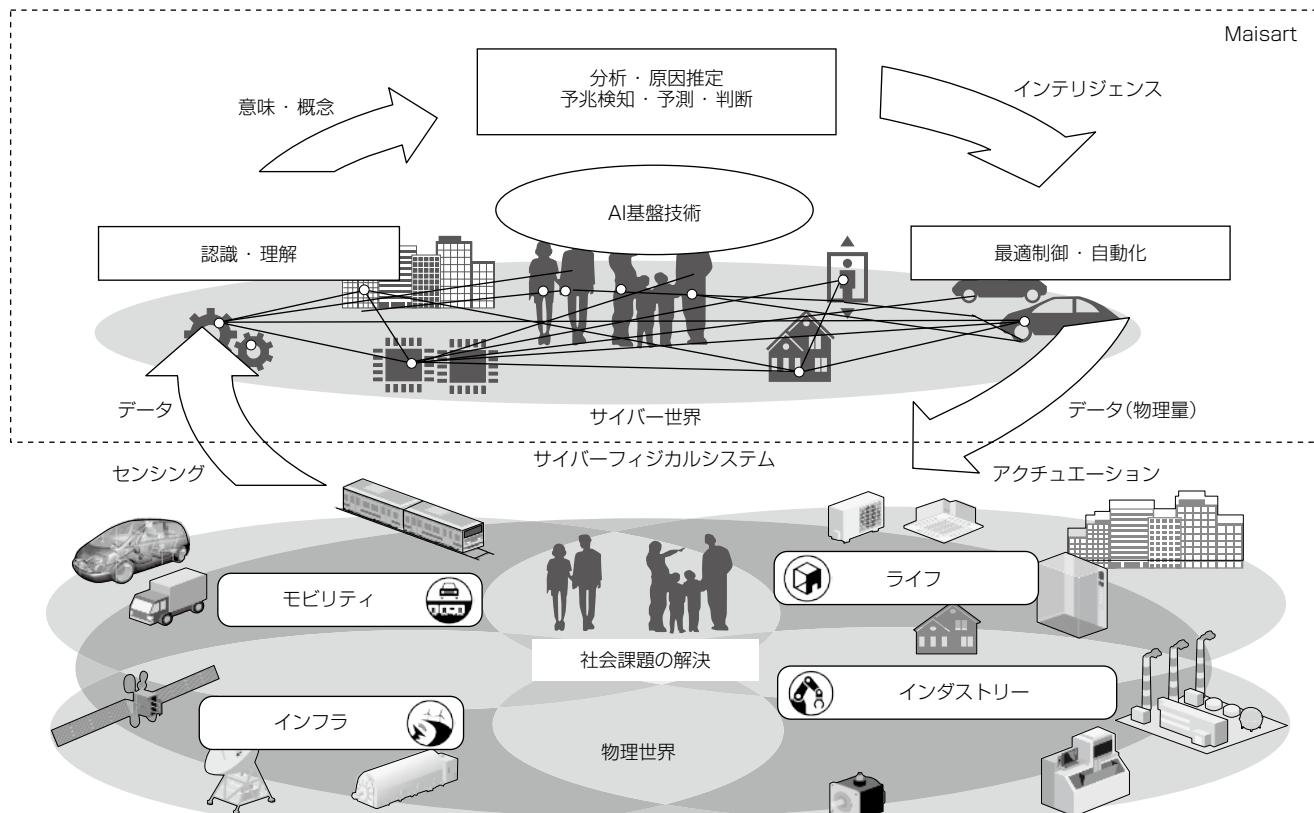


図1. 社会課題を解決するAI技術

表1. 当社の主なAI活用事例と関連するAI応用技術

領域	機器／システム／サービス	概要	応用技術
ライフ	HEMS	天気予報と太陽光発電量実績を基に発電量を予測するAI“お天気リンクAI”でエコキュートの昼間余剰電力を活用した昼間わき上げ量／夜間わき上げ量の制御	分析・予測
	ルームエアコン	“ムーブアイmirA.I.+”が住宅性能・日射影響に基づく体感温度の変化の予測、及び気流の到達先の微細な温度変化から風の流れや強さを予測し、一人一人に合わせた快適をお届け	分析・予測・最適制御
	業務用空調	学習した過去の運転データから複数台の空調機の最適な起動時刻を個別に自動設定、無駄の無い予冷・予熱運転	分析・最適制御
	kizkia	カメラ映像上の特定の“ヒト・モノ・コト”をリアルタイムかつ自動的に検知して通知するソリューション	認識・理解
	M's BRIDGE	各エレベーターの使用状況に基づく最適な保守のタイミングや、機能維持に必要な修理内容・時期を予測	分析・原因推定・予兆検知・予測
インダストリー	ファイバレーザ加工機	加工中の音と光からAIが加工状態を判断。加工条件を自動調整する“AIアシスト”を搭載することによって、“止まらない加工機”を追求	分析・判断・最適制御・自動化
	リアルタイムデータアナライザ	類似波形認識技術によってセンサ波形などのデータを学習・認識し、生産設備でのリアルタイム診断時の異常兆候検知精度を向上	分析・予兆検知
	産業用ロボット	メンテナンス時期の決定を支援する“予知保全機能”と“力覚制御の拡張機能”を追加、タクトタイム及びシステム立ち上げ時間を60%短縮	認識・予兆検知・最適制御・自動化
	形彫放電加工機 加工計画精度向上	適応制御技術、加工条件生成機能を標準搭載して生産性向上を実現。加工終了時間の予測機能によって前後工程間で発生する段取りの時間ロスを削減	分析・予測
	作業者動作分析	人のわずかな動作の違いも見つける行動分析(事前学習不要)。カメラ映像から骨格情報を抽出・分析して、特定動作を自動検出	認識・理解・分析
インフラ	河川水位計測	高感度フルハイビジョンセンサによって、昼夜を問わず高精細な画像を取得して目視と同等の水位のリアルタイムの連続観測を実現	認識・理解
	発電プラント異常兆候検知	正常運転時のデータのふるまいを学習し、学習した運転データパターンと計測値が異なった“いつもと違うふるまい”を検出(INFOPRISM APR)	予兆検知・予測・判断
	自動図化ソフトウェア	レーザ点群とカメラ画像データから、標識・道路標示などを抽出して高精度三次元地図を効率的に作成・更新	認識・理解
	短波(HF)レーダ	海の継続的な監視や不審船の検出の際、不要波がレーダの目標検出性能を低下させる要因になるため、不要波と目標を識別することで目標を正しく検出	認識・分析
モビリティ	運転者状態監視(DMS)	近赤外線カメラで運転者の顔の向きを検知して、脇見運転や居眠りを警告。脈拍をセンシングして運転者の体調急変などの検知技術を当社のコンセプトキャビン“EMIRAI S”に搭載	認識・理解
	電子ミラー	電子ミラーで、後側方から接近する物体を早期に検出すると同時に種類を識別し、ドライバーに注意を促すことで車線変更等の事故防止に貢献	認識・分析
	自動運転	人間が操作するモビリティと同じ空間で、自動で移動制御する技術を実現。人が操作するフォークリフトとAGV(無人搬送車)の間の協調した運転が可能	認識・予測・最適制御・自動化
	鉄道車両メンテナンス	鉄道車両の様々な情報をリアルタイムに収集・分析することで、点検・検査・修繕などのメンテナンスの効率化や鉄道事業者間のデータ活用などを支援	分析・予兆検知

HEMS : Home Energy Management System, HF : High Frequency, DMS : Driver Monitoring System

持続可能な社会の実現に貢献している。当社がAI技術ブランドとして展開しているMaisartは、このサイバー世界で稼働し、物理世界に対して課題を解決する手段として活用されるものである(図1)。

当社のAIの主な活用事例とAI応用技術について表1にまとめた。認識・理解、分析・原因推定、予兆検知・予測・判断、最適制御・自動化などのAI応用技術は、図1に示した全ての工程を経ずとも物理世界に資するものになる。AI応用技術は、様々な領域で社会課題を解決するものであるが、スマートシティのように四つの領域にまたがる分野に対しても多くの課題を解決していくことが期待される。

次に、各領域で活用される当社のAI応用技術の代表的な事例について述べる。

2.1.1 ライフ領域でのAI活用

調理・空調・給湯などを全て電気で賄っているオール電化は、高齢者に安心な住宅設備としてガスより好適であり、安心な高齢化社会の実現に寄与している。また、CO₂を排出しない太陽光発電システムとの組合せで、節電効果も期待できる。さらに当社では、創った電気をできるだけ使う

という観点から、天気予報を用いてエコキュート^(注1)の昼間わき上げ量／夜間わき上げ量を制御する“お天気リンクAI”を製品化している。これは太陽光発電量をAIで予測するものであり、このケースのAI応用技術は、分析・予測技術である。

(注1) エコキュートは、関西電力(株)の登録商標である。

2.1.2 インダストリー領域でのAI活用

生産性の向上は、ものづくり現場の共通の要求である。これに対応するため、止まらない設備が必要とされる。生産現場で加工機は重要な位置付けにある。例えば、レーザ加工機は加工対象の材質、板厚、表面状態、含有元素などのはらつきによって熟練者が経験に基づき加工条件を微調整する場合がある。生産に占める生産準備作業と呼ばれる工程の割合が高くなるほど、この微調整の時間を減らす必要がある。当社は、長年培ったレーザ加工機の知識を活用し、この微調整に適用する機械学習技術を開発した。熟練者よりはるかに早く調整し、高精度かつ安定に動作させる技術で“AIアシスト”機能を実現した。このケースでのAI応用技術は分析・判断・最適制御・自動化技術である。

2.1.3 インフラ領域でのAI活用

近年は気候変動による自然災害が増えており、豪雨による河川の氾濫で人命が失われることも増えてきている。対応策として、河川水位を正しくリアルタイムに把握することは極めて重要である。河川には監視カメラが取り付けられており、これを活用した画像式水位計測装置を当社グループで製品化している。カメラ画像から水面の領域を認識して水際線を理解し、水位を計測するものである。このケースでのAI応用技術は、認識・理解技術である。

また、この技術を更に深化させ、港湾施設、沖合空港の建設で必要になる躯体を地中又は海中に、下部を掘削しながら徐々に沈める工事に使われるニューマチックケーソン工法で、土砂境界を推定し、工事の安全性を高める技術を鹿島建設株と共同で開発した。

電力インフラでは、電力を供給し続けられないと社会的に大きな損失が生じる。そのため異常兆候をいち早く察知し、供給する電力量を維持するための対策を講じる必要がある。そこで、発電プラントのセンサデータから異常の兆候を抽出する“INFOPRISM APR”を製品化した。このケースのAI応用技術は、予兆検知・予測・判断技術である。

2.1.4 モビリティ領域でのAI活用

交通事故の減少に向けて自動運転と運転支援の実現が求められている。自動運転にAI技術が使われることは言うまでもないが、運転支援にもAIが活用されている。交通事故の減少のためにドライバの前方不注意を避けることが重要であり、当社はドライバの状態をモニタリングするDMSを開発した。このケースのAI応用技術は、認識・理解技術である。

2.2 AIの活用に向けたデータの重要性

三度目の隆盛を迎えたAI技術はデータの中から規則性を見いだすものであるため、AI技術の活用のためには、

良質なデータを多く集める必要がある。しかし、解決したい課題に関わる要因とまったく関係ないデータばかりが集まっていても規則性は見いだせない。また、データが欠落していることなどによって効果が得られないことも多く、AI活用の“落とし穴”になっている(図2)。このことに留意してAIを活用していくば、従来の技術では解決できなかった課題に対して有効な規則性が見いだせる。準備したデータに欠損や重複、ノイズが含まれていることも多く、クレンジングし、場合によっては統合する、又は変換することも、AIによって導き出される結果の質の向上に重要な前処理の工程である。このようにデータを扱う際には、その分野に応じた知識(ドメイン知識)を活用することが、AI技術の成否で非常に重要である。また、網羅性が確保され、偏りがないようなデータであるほど、質の高い結果を導き出すことができる。この前処理を含めてAI応用技術を適用することで、質の高いAIの恩恵を受けることが期待できる。

3. AI基盤技術

3.1 AI応用技術を支える基盤技術

2章述べたAI応用技術に適用するAI基盤技術として、1章で触れたディープラーニングのほか、機械学習の一つである強化学習や、機械学習を取り込んだビッグデータ分析、知識処理を挙げる(図3)。

ディープラーニングは主として、認識・理解と分析・予測のAI応用技術に有効なAI基盤技術である。また、ディープラーニングを使うとしても、画像認識に対応する場合には畳み込み構造のネットワーク構造が有効であることが多く、時系列データでの異常兆候の分析に対応する場合には、再帰型のネットワーク構造が有効であることが多いと言われている。機械学習を取り込んだビッグデータ分析(ここでは、統計解析に加え、機械学習を取り入れて正常モデルを学習する基盤技術を指し、狭義な分類として表

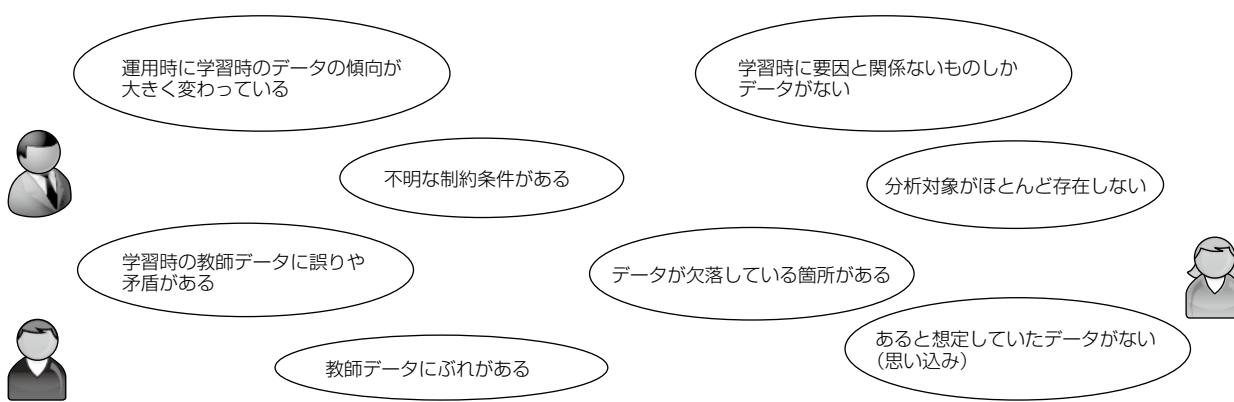


図2. AIに関するデータ収集の落とし穴

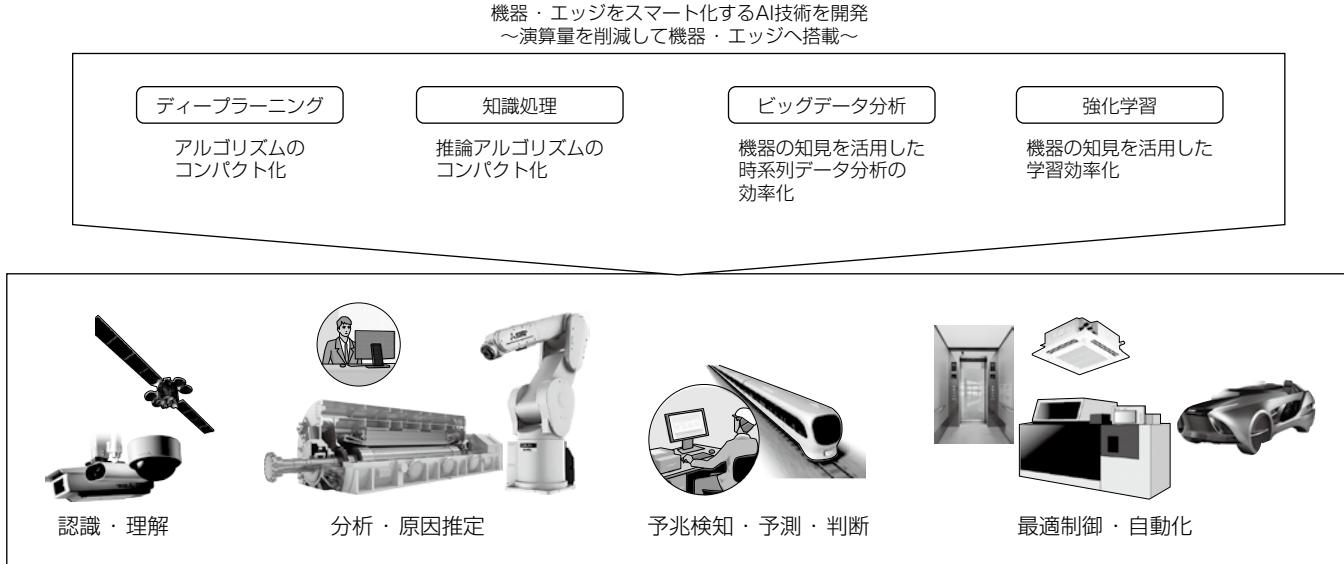


図3. Maisartの応用技術(下段)と基盤技術(上段)

現している)は、主として、分析・原因推定と予兆検知・予測のAI応用技術に有効なAI基盤技術である。このことから異常兆候抽出の応用技術に使用されることが多い。知識処理は、有向グラフで表現される知識ベースを使って演绎(えんえき)的推論するものであるが、これは統計的因果推論と並び原因推定のAI応用技術を構成する重要なAI基盤技術である。また強化学習は、最適制御や自動化の応用技術に有効なAI基盤技術である。

これらは代表的なAI基盤技術として取り上げたが、もちろんこれらに限らず、AI応用技術を支える基盤技術としての機械学習技術は数多くある。機械学習の内部パラメータの複雑さや、AIが解くべき課題によって、最も高い性能が簡単に得られる基盤技術が異なることもある。例えば、AI基盤技術で挙げたディープラーニングより、もっとレガシーな機械学習を使った方が、早く良い成果が出る場合もある。それぞれ解決したい課題に応じて、最適な基盤技術を適用することが、AIの活用には重要なポイントになる。

また、世界中の現場のデータを全てクラウドに上げることは難しいため、Maisartでは、機器やエッジでデータを収集して前処理も含めてAI基盤技術を適用できるようにし、機器やエッジのレベルから、全てのものをより賢くすることを可能にする。このために、演算量を削減する独自のアルゴリズムを開発してきた。また、2.2節で述べたように当社のドメイン知識を活用して性能を上げるAI技術もMaisartである。もちろん、演算パフォーマンスの高いGPU(Graphics Processing Unit)を用いれば、機器やエッジに搭載できる。しかし、同程度の性能を実現するために、必要な演算を省くことは演算のためのエネルギー消費を抑えることに貢献する。AIがあまねく普及す

る社会を目指す上で、エネルギー消費の増加が引き起こす社会課題に対して、より有用な技術であると言える。

もちろん、機器やエッジだけでなく、クラウドへ実装する場合にも有用であることは言うまでもない。クラウドとは言え、演算リソースは有限であり、クラウドサーバの消費電力量を削減することは重要である。

3.2 AI基盤技術の動向

AI基盤技術はグローバルに研究が続けられており、今後も更なる深化を続ける。ディープラーニングでも学習の仕方に更なる工夫がなされて、マルチタスク学習や、学習の仕方を学習するメタラーニングなど、学習に必要なデータを少なくできそうな技術の研究が進んできている。また、画像などのデータを生成できる敵対的生成ネットワークもその深化が期待される。強化学習、ビッグデータ分析、知識処理も含めて主な動向を図4にまとめる。

4. AI技術の展望

AI技術には米国と中国を始めとして世界中で巨額の投資がなされており、日々急速に進化している。その一方で、英オックスフォード大学のオズボーン准教授らによる“10~20年以内に米国の総労働者の仕事の47%が自動化される可能性が高い”との公表や、米国のレイ・カーツワイル博士による“2045年までにはシンギュラリティに到達する”との予測から、2045年までに人間の仕事の多くがAIに奪われ、失業者が増加するのではないかといった議論が行われている。このような状況の中、2017年頃から国内外の様々な政府機関等で、AI技術の研究開発や利活用に関する規程や指針の策定が進められている。

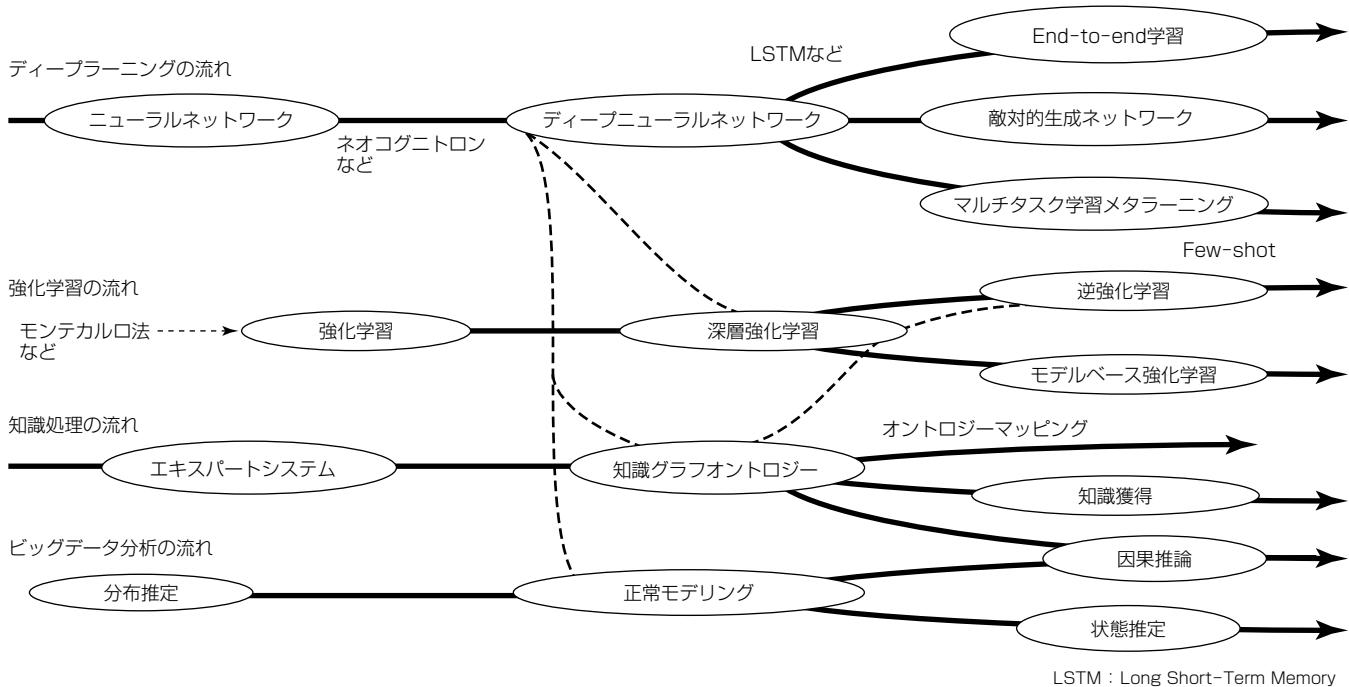


図4. AI基盤技術の研究開発動向

日本と欧米で共通に掲げられている3点を紹介する。一つ目としては、AIが人間や社会にとって有用なものであるために、人間の社会的・道徳的規範に相反しないことが求められている。二つ目は、安全性の確保が挙げられる。三つ目は、AIをブラックボックス化しないための判断根拠についての“説明責任”とその判断での“公平性”的担保である。特に三つ目については“今後ディープラーニングのモデルの説明責任、また分析された結果が公平であるかどうかということが問われるだろう”と多くの研究者から指摘されている⁽²⁾。

“説明責任”については、例えば画像診断などで利用されるディープラーニングを医療画像診断に用いる場合、AIは人間をしのぐ能力を見せている。一方で、正解が導出された理由が不明な場合がある。AIの普及に伴い、AIの“ブラックボックス化”は問題とされており、これを解消することが重要になる。AIの説明性に対する取組みとしては、米国のDARPA(国防高等研究計画局)が、説明可能なAIの実現を目指して、XAI(explainable AI)の研究プログラムを2016年から進めている。現在では、ディープラーニングで活性化されたノードを可視化して、AIが注目している箇所を表して説明性を向上させる研究が進んできている。この研究分野は、知識処理を合わせて、より幅広い分野で適用されるものになっていくであろう。

“公平性”というのは、AIによって導き出された答えが、公平であるかどうかという問題である。例えば、人材の採用にAIを活用する場合に学習モデルを作成する際のデータに偏りがあると、その判断過程に特定の人の採用に対し

て差別が生じてしまうというようなことが起こり得るので、AI自らが“公平性”を担保することは難しい。AIが出した答えの公平性を外から監視する仕組みがシステム化されるであろう。

5. むすび

AI技術は、様々な社会課題を解決する有力な技術群の一角をなすものとして、大きな期待が寄せられており、その社会実装が進む中、AI応用技術とAI基盤技術の現状と動向、及び今後の展望について述べた。しかし、データがそろっていたとしても、解決する課題が明確でないと課題を解けないことが多い。AIに対する過剰な期待から、曖昧な課題を設定してしまうと、そのデータから得られる規則性と課題との関係が明確にならず、良い結果が得られないケースがあることを最後に付け加えておく。

当社の独自AI技術Maisartは既に様々な製品に搭載されており、その成果がR&D100や十大新製品賞を受賞するなど、高く評価され始めている。当社はこれからもAIの研究開発を更に進め、新たな価値を創出し、社会課題や顧客課題の更なる解決に貢献する。これによって、全てのものを賢くして、超スマート社会を実現する。

参考文献

- (1) 三嶋英俊, ほか: 機械学習・人工知能業務活用の手引き～導入の判断・具体的応用とその運用設計事例集～, 情報機構, 158~163 (2017)
- (2) 瀬光孝之, ほか: 機械学習モデルの解釈性に関する最新動向, 電子情報通信学会誌, 102, No.10, 973~977 (2019)

コンパクトなGAN

Compact GAN

峯澤 彰*
Akira Minezawa
吉田 浩*
Hiroshi Yoshida
杉本和夫*
Kazuo Sugimoto

要旨

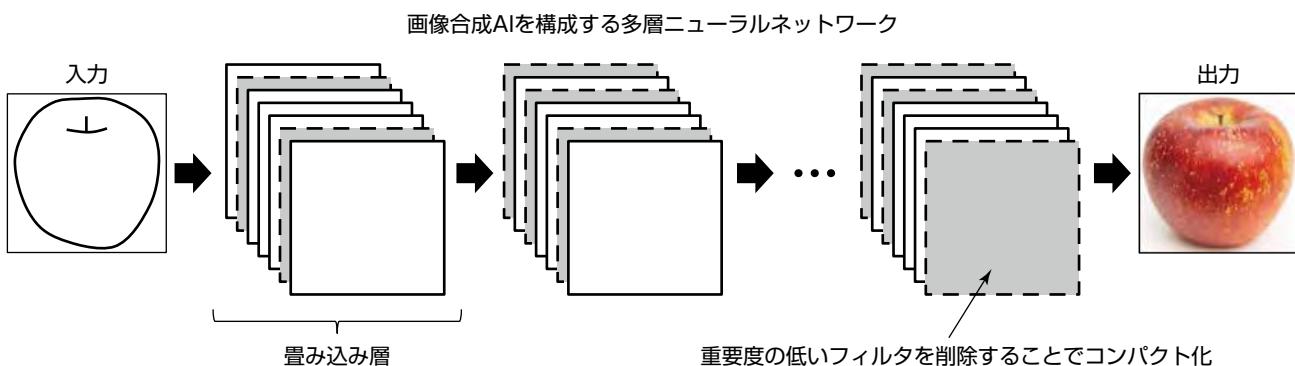
近年、画像処理技術はディープラーニングによって飛躍的な進歩を遂げており、画像合成分野では特に敵対的生成ネットワーク(Generative Adversarial Network⁽¹⁾: GAN)と呼ばれる手法によって、実物と見分けがつかないほどの写実的な画像を合成することが可能になりつつある。一方、この手法は演算負荷や消費メモリが膨大であり、利用可能な環境が限定的であることが課題であった。三菱電機はこの課題に対し、演算量やメモリ量を削減し、高速かつ省メモリで画像合成が可能な方式を開発した。

開発方式は、通常のGANと同様の学習を実施後、学習

したニューラルネットワークの畳み込み層について、畳み込み層の各フィルタに対して画像合成処理の性能寄与度の低いフィルタを削除することでコンパクトな画像合成ネットワークを実現している。このとき、性能寄与度として真贋(しんがん)判定AI(Artificial Intelligence)による判断結果が反映される点が特徴である。

シミュレーションの結果、開発方式は通常のGANによって学習されたモデルに対して、同程度の画像合成精度を保ちつつ、画像合成処理時間及び使用メモリ量を10分の1に削減できることを確認した。

- ・新アルゴリズムによって画像合成AIの各層のフィルタの重要度(合成画像の品質にどれだけ寄与するか)を評価
- ・重要なフィルタだけを残し、演算量とメモリ量を10分の1にする



- (1) ニューラルネットワークの畳み込み層の各フィルタの重要度を評価する
- (2) 重要度の低いフィルタを削除し、重要なフィルタだけを残す

GANによる画像合成AIのコンパクト化

GANは、画像合成AIであるGeneratorと真贋判定AIであるDiscriminatorという二つのニューラルネットワークが互いに敵対して学習することで高品質な画像を合成可能なGeneratorを得ることができる。しかしながら、Generatorは高い表現力を獲得するために非常に多層の畳み込みニューラルネットワークで構築されることが多いため、その演算負荷が課題となる。これを各畳み込み層のフィルタの重要度に基づいて効率的に削除することで、画像合成品質を保ったまま高速処理・省メモリを実現した。

1. まえがき

近年のディープラーニングの発展は目覚ましく、画像認識・画像合成技術でのブレークスルーを実現している。画像合成分野では特に敵対的生成ネットワーク(GAN)という技術の誕生によって、ニューラルネットワークを用いて実物と見分けがつかないほどの写実的な画像を合成することが可能になりつつあり⁽²⁾、リアルな合成画像を必要とする様々な用途への応用の可能性が広がる一方で、その合成画像の画質の高さから、特定の人物をターゲットにした実物と見分けのつかない“偽動画”的制作・拡散によるプライバシー侵害が世界的な社会問題化するなど、ディープラーニングによる画像合成技術の日常生活への影響は拡大している。一方、この技術を利用するには潤沢な計算資源が要求される点が技術課題であった。今回、この課題に対して演算量やメモリ量を削減し、高速かつ省メモリで画像合成が可能な方式を開発した。

2. GAN

2.1 ニューラルネットワークによる画像合成

図1は、畳み込みニューラルネットワークの概念図である。畳み込みニューラルネットワークは、各層を畳み込みフィルタで層を構成し、さらにその層を積み重ねたものであり、入力画像に対してフィルタ処理を繰り返しながら特徴を抽出し、抽出された特徴を処理することで所望の出力を得る。学習段階では、画像と期待される出力結果とのペアが入力され、期待される出力が得られるように各フィルタの係数が自動的に調整される。

これまで、画像を得るにはカメラを用いたり、又はコンピュータグラフィックスによって描画したりするなどの手段が取られてきたが、ニューラルネットワークの層を多数積み重ねたネットワークであるディープラーニングの発展によって、多層の畳み込みニューラルネットワークによる写実的な画像合成が可能になってきている。こうした画像合成技術によって、例えば機械学習に用いる学習データの量を増やして性能を向上させることなどが可能になる。

2.2 新しい画像合成ネットワークGAN

写実的な画像合成が可能な技術として、

GANが知られている。この技術では、画像合成AIであるGeneratorと真偽判定AIであるDiscriminatorという二つのニューラルネットワークを用いた学習手法を特徴としている。GANの概念図を図2に示す。ここで、Generatorは画像を合成するニューラルネットワークである。一方、Discriminatorは画像を入力として受け取り、その画像が本物の画像なのか、又はGeneratorが合成した偽の画像なのかを判別する。一般に、両者はどちらも畳み込みニューラルネットワークで構成される。

GANの学習では、Generatorは、例えば参考文献(1)に示すような乱数ベクトルや図2に示すようなスケッチ等の出力に対する補助情報を入力して、Discriminatorが本物なのか偽者なのかを判別できないような画像を合成するよう学習し、Discriminatorは、Generatorが合成した画像と実際の画像を格納したデータベースからサンプリングされた画像を受け取り、受け取った画像が合成画像なのか、実画像なのかを識別するように学習する。このように両者が相互に敵対しながら学習することで、最終的にGeneratorはDiscriminatorが真偽を判定できないような写実的な画像を合成できるようになる。

しかし、一般的にGANでは、特にGeneratorに大規模な多層ニューラルネットワークが用いられることが多く、

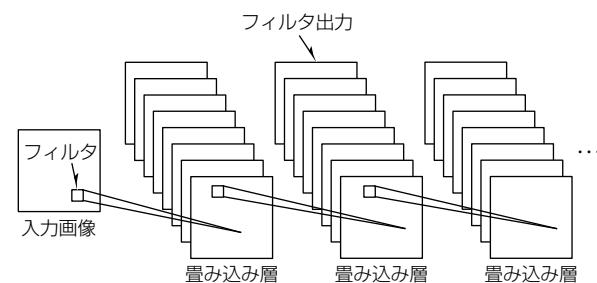


図1. 畳み込みニューラルネットワーク

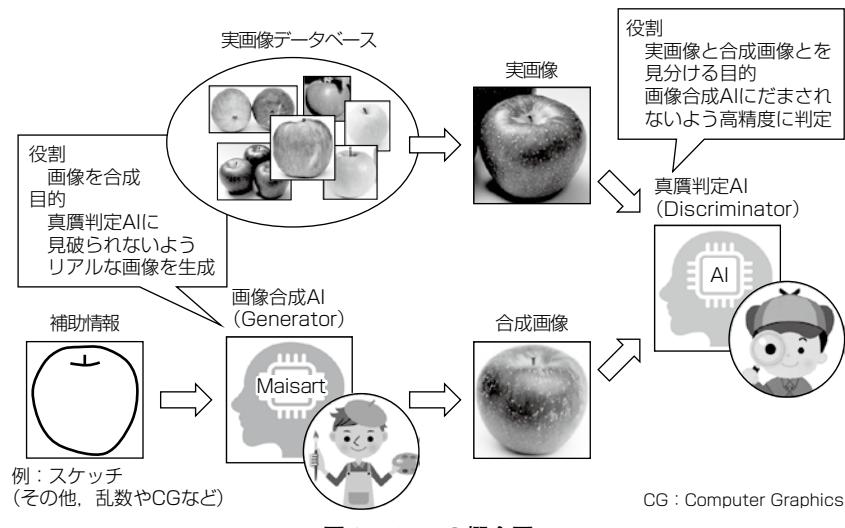


図2. GANの概念図

演算量が大きいことが課題になっていた。GANの学習完了後は、Discriminatorは不要になりGeneratorだけが画像生成のために利用されるが、Generatorの演算量が大きい場合、例えば高速な画像合成が必要とされる応用や、組み込み機器などの計算資源が限られた環境での動作が必要な応用には適用できない。

本稿では、上記課題を解決するために、GANで用いられるGeneratorを小規模化することで演算量やメモリ量を削減し、高速かつ省メモリで画像合成を可能にする方式を提案する。

3. GANのコンパクト化

3.1 開発方式

開発方式では次の手順を反復することによってGeneratorの小規模化を実現する。

- (1) GANによるGeneratorの学習
 - (2) 重要度に基づく重みパラメータの削減

図3に開発方式の処理手順のフローチャートを示す。まずGANの学習を行う。次に、Generatorとして用いているニューラルネットワークのサイズを小さくし、Generatorだけ再学習する。ここで、あらかじめGeneratorのサイズに対して目標値を設定しておき、Generatorのサイズが目標値を下回るならば処理を終了する。一方、Generatorのサイズが目標値よりも大きいならば、再びGeneratorのサイズを小さくして目標値を達成するまで同様の処理を繰り返す。

3.2 GANによるGeneratorの学習

この節ではGeneratorの学習方法について述べる。ここで、GeneratorをG、DiscriminatorをDと表し、GANの学習での目的関数は式(1)で表現される。

$$\min_G \max_D V(D, G) \dots \dots \dots \quad (1)$$

$V(D, G)$ は、実画像は実画像であると、生成画像は生成画像であるとDiscriminatorが正答する期待値(正答：1, 誤答：0)を示しており、Generatorは $V(D, G)$ が小さくなるように、Discriminatorは $V(D, G)$ が大きくなるように相反して学習を行うことを表している。図3に示すGANの学習が完了した後は、GANでのGeneratorとDiscriminatorのうち、Generatorとして用いられるニューラルネットワークの規模を小さくして、画像合成時のメモリ使用量や演算時間を削減することを目的とする。

3.3 重要度に基づく重みパラメータの削減

Generatorを小規模化する手法について述べる。一般に

Generatorは、畳み込みニューラルネットワークによって構成される。畳み込みニューラルネットワークは、畳み込みフィルタを多層に重ねたものであり、学習を通して各フィルタの係数が最適化される。各畳み込み層には図1に示すように複数のフィルタが存在し、このフィルタの数が多ければ多いほどニューラルネットワークの規模が大きくなり大量のメモリと演算量が必要になる。そこで、開発方式では、各畳み込み層でのフィルタの数を削減するため、図4に示すように各フィルタに対してスケーリングファクタを導入し、各フィルタからの出力に対してこのスケーリングファクタを乗ずる。このスケーリングファクタは、各フィルタの重要度を示すパラメータとなる。開発方式では、このスケーリングファクタをGANの学習時に自動的に最適化するため、GANの目的関数に式(2)のように追加する。

$$\min_{\mathcal{G}} \max_{\mathcal{D}} V(\mathcal{D}, \mathcal{G}) + \lambda \sum F(a) \dots \dots \dots \quad (2)$$

ここで、Generatorのコンパクト化を実現するために、関数 F はスケーリングファクタの疎性を促すL1ノルムを用いる。 λ は目的関数の第2項の影響度を調整する変数である。GANの学習完了後、重要度の低いフィルタについてはスケーリングファクタが小さくなるため、あらかじめ設定したしきい値よりも小さなスケーリングファク

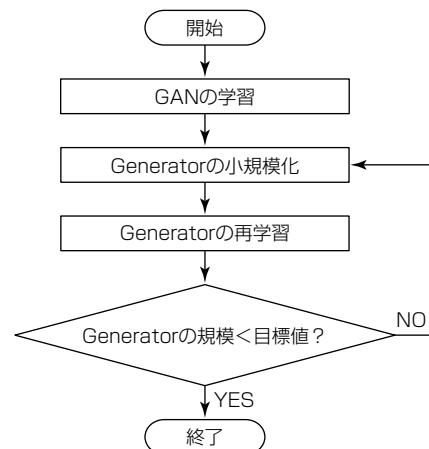


図3. 開発方式の処理手順

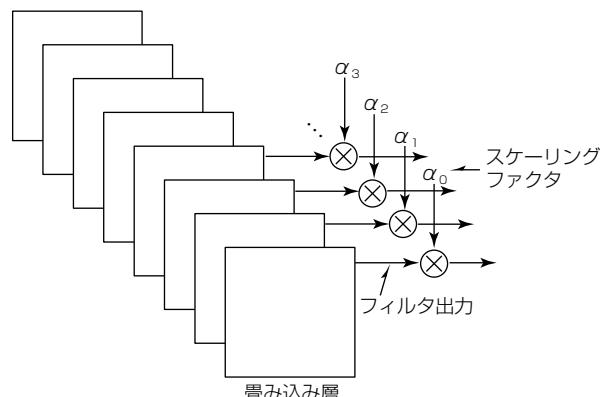


図4. スケーリングファクタの導入

タを持つフィルタを削除することで、性能を落とさずにGeneratorの規模を小さくすることが可能になる。このとき、フィルタの削除によって上記目的関数の第1項の値が増加しない場合、フィルタを削除してもDiscriminatorに對して見破られやすくならずに削除前と同等の画像合成品質を持つことを示している。さらに、開発方式では、小規模化したGeneratorを再学習させることで小規模化による性能低下を最小限に抑える。ここで、最初のGANの学習でDiscriminatorは十分な性能を獲得しているため、Discriminatorの学習は行わず、Generatorだけ再学習させることで性能向上を図る。

一般に、GeneratorとDiscriminatorの性能を拮抗(きつこう)させながら学習を行うことは困難であることが知られている。開発方式で、GANの学習が完了した段階でGeneratorの規模を小さくしすぎると、Discriminatorの性能が大幅にGeneratorを上回り、続くGeneratorの再学習が不安定になる。そこで開発方式では、Generatorを段階的に小規模化していくことで学習を安定化させる。つまり、フィルタ数削減のためにスケーリングファクタに設定するしきい値を小さくしておき、一回の小規模化で多数のフィルタが削除されることを避ける。しかしこの場合は小規模化の効果も小さくなるため、Generatorのサイズが目標値を下回るまで小規模化と再学習を繰り返すようになることで、Generatorの十分な小規模化を実現する。

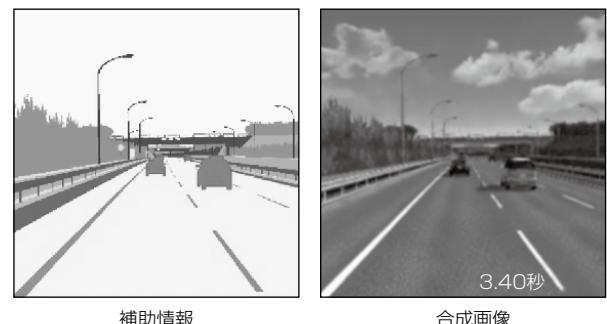
3.4 性能評価

開発方式の性能を評価するため、路上のシミュレート画像を用いて、セグメンテーション画像からシミュレート画像を合成するタスクを評価した。ここで、セグメンテーション画像とは物体ごとに色分けして塗りつぶされた画像のことを示す。このタスクでは、写実的な画像を人工的に合成したい場合に、セグメンテーション画像のような、目的の画像に対応する補助情報を用意するだけで実現できるようにすることが目的となる。このようなタスクは、例えば画像認識向けAIのための学習用画像を人工的に自動合成するといった用途に応用可能と考える。

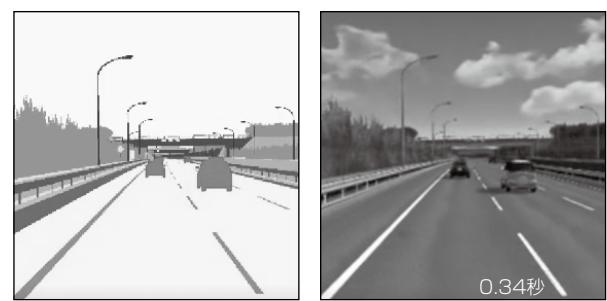
この実験では、従来のGANによって学習したモデルと、開発方式によって学習したモデルに対して、表1に示すノートパソコンの計算機環境で評価した。その結果、従来方式では、Generatorによる画像合成に画像当たり約3.40秒を要するところ、開発方式では画像当たり約0.34秒で実行

表1. 計算機環境

項目	仕様
CPU	Intel Core i7-7500U
実行時の並列数	1
メモリ	16GB



(a) 従来方式



(b) 開発方式

図5. 画像合成の性能評価結果の例

可能であることを確認した。図5に両方式の出力結果の例を示す。図から、開発方式によって、出力画像の画質を劣化させることなく画像合成の処理時間を10分の1にすることを実現していることが分かる。また、この実験でのGeneratorのパラメータ数も2,900万を超える従来方式に對して開発方式では10分の1以下の約250万となることを確認した。このことから画像合成処理時にGeneratorで用いるメモリ量も削減できることが分かる。

4. むすび

最新の画像合成技術であるGANでの、画像合成AIであるGeneratorを性能劣化なく高速処理・省メモリを実現する方式について提案した。

開発方式では、Generatorを構成するニューラルネットワークの各層の重要度を評価し、重要な層だけを残すことで画像生成品質を保ったままコンパクトなニューラルネットワークを合成することを実現した。その結果、画像合成処理の演算量、メモリ量を従来に比べて10分の1に削減することを達成した。

参考文献

- (1) Goodfellow, I.J., et al.: Generative adversarial nets, Proc. of The Twenty-eighth Conference on Neural Information Processing Systems, 2672~2680 (2014)
- (2) Radford, A., et al.: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, Proc. of The International Conference on Learning Representations (2016)

コンパクトなハードウェアAI

Compact Hardware Artificial Intelligence

杉原堅也*
Kenya Sugihara
山本 亮†
Ryo Yamamoto

要旨

三菱電機のAI(Artificial Intelligence)技術“Maisart”には全てのモノを賢くする“コンパクト化”という特長がある。機械学習の一つであり、また今日の第3次AIブームのきっかけになった“ディープラーニング(深層学習)”は膨大な演算量を必要とすることから小型機器への搭載が困難であった。これを解決するため、推論に用いるネットワーク構造と計算方法に着目して分析し、推論精度を維持したまま、推論処理の演算量・使用メモリ量を削減し、コンパクト化することに成功した。

コンパクト化を実現する多層ニューラルネットワークの枝刈り技術は、演算量を削減できる一方で、不規則な枝刈りを行う場合、FPGA(Field-Programmable Gate Array)では枝刈り前と後で大幅な回路規模削減が見込め

ず演算量削減の効果を発揮できない。これは、同一処理を行う並列化した積和演算回路で、枝刈り箇所をスキップする場合とスキップしない場合が混在してしまい、その結果、回路の動作率が低下してしまうためである。そこで、FPGA内の回路動作率を向上させるため、枝の接続に規則性を設け、並列化した回路の動作率を向上させた。これによって、道路標識の画像認識では処理時間が1/10に削減可能になった。また、処理時間を削減しない場合には回路規模を1/10にすることも可能である。

この技術によって、リアルタイム性が求められる分野や、これまでコスト面で人工知能の適用が難しかった分野にも、今後適用範囲を広げていく。



Maisartの“コンパクトな人工知能”的適用分野

当社のAI技術Maisartの一つである“コンパクトな人工知能”的計算順序の効率化と回路構成の最適化によって、小規模なFPGAにも実装できる“コンパクトなハードウェアAI”を開発した。リアルタイム性の向上と低コスト化を実現したことで、家電、エレベーターなど人工知能の適用分野拡大に貢献していく。

1. まえがき

当社のAI技術Maisartでは全てのモノを賢くする“コンパクト化”という特長を掲げている。当社では、機械学習の一つであり、また今日の第3次AIブームのきっかけになった“ディープラーニング”が膨大な演算量を必要とすることから機器への搭載が困難であるのに対し、これを解決するために、推論に用いるネットワーク構造と計算方法に着目して分析し、推論精度を維持したまま、推論処理の演算量・使用メモリ量を削減し、コンパクト化することに成功した。

これによって、従来はクラウドコンピューティングなどでしか実行することが難しかった人工知能による高度な推論が図1のようにエッジコンピューティングでも可能になり、適用範囲が広がり、活用の幅が大きく広がった。

また、この技術を発展させて、さらに計算順序の効率化と回路構成を最適化することによって、小規模なFPGAにも実装できる“コンパクトなハードウェアAI”を開発した。これによって、MaisartをFPGAに実装することで、低コスト化やリアルタイム性を向上させた。

2. コンパクトなAI

現在のAIブームの要因になった“ディープラーニング”技術は、従来のサポートベクタマシンによる認識技術と比べて高度な推論が可能になる一方、複雑なモデルを用いて計算するため、学習及び推論処理に必要な演算量・メモリ使用量が膨大になる課題があった。この章ではこれらの課題解決の手法について述べる。

2.1 ディープラーニングの課題

“ディープラーニング”とは、人間が自然に行うタスクをコンピュータに学習させる機械学習の手法の一つである。現在のAIの急速な発展を支える技術であり、その進歩によって様々な分野への実用化が進んでおり、現在のAIの中核的技術とも言える。

ディープラーニングはニューラルネットワーク(Neural Network)という機械学習の手法をベースにしたものであるが、長い間解決されていなかったニューラルネットワー-

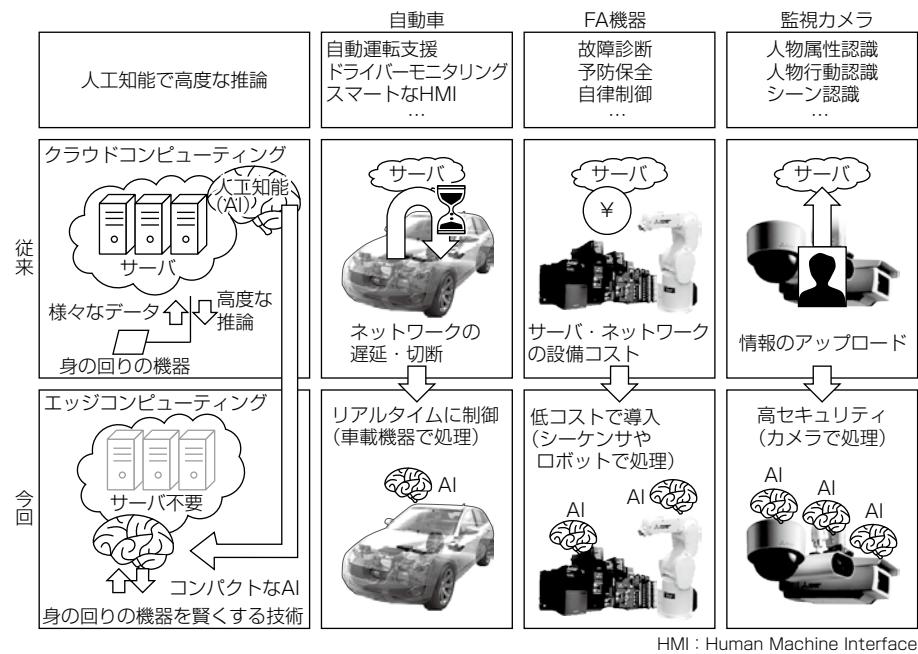


図1. AIコンパクト化

ク特有の課題を“多層(ディープ)化”するという工夫で解決している(図2)。

この多層化によって、例えば画像認識で言えば、それまでの認識精度が70%台であったものが、ディープラーニングの登場によって一気に80%を超え⁽¹⁾、2016年以降は90%を超え⁽²⁾、極めて高精度な推論が可能になった。しかし、一方で複雑なモデルを用いて計算し、非線形に識別することから、学習用データが大量に必要になり、学習及び推論処理に必要な演算量・メモリ使用量が膨大になるという課題もあった。

図2に示すように“ディープラーニング”は各層間のノード同士が全て枝で接続されており、密なネットワーク構造になっている。各枝では学習処理で定まる枝重みと枝の入力値とで積算を行うため、枝の本数が増加するほど演算量は増大することになる。また、“ディープラーニング”は多層構造を持ち、演算量が更に大きくなる。そのため、大規模サーバや組み込み機器の場合でも、演算を高速化するためのGPU(Graphic Processing Unit)等を用いないと、必要とされる要求仕様を満たせない場合が多く、エッジや機器に搭載する上での大きな課題になっていた。

2.2 ディープラーニングの演算量削減技術

ニューラルネットワークは以前から誤差逆伝播(でんぱ)法と呼ばれる方法で学習を行っていたが、中間層が2層以上になると学習が収束しにくいという問題があった。これに対し、ヒントンらがこの問題の解決のために自己符号化器を用いることを提案した⁽³⁾。学習処理を、枝重みの初期化を行う“プレトレーニング”と、教師あり学習で全体を

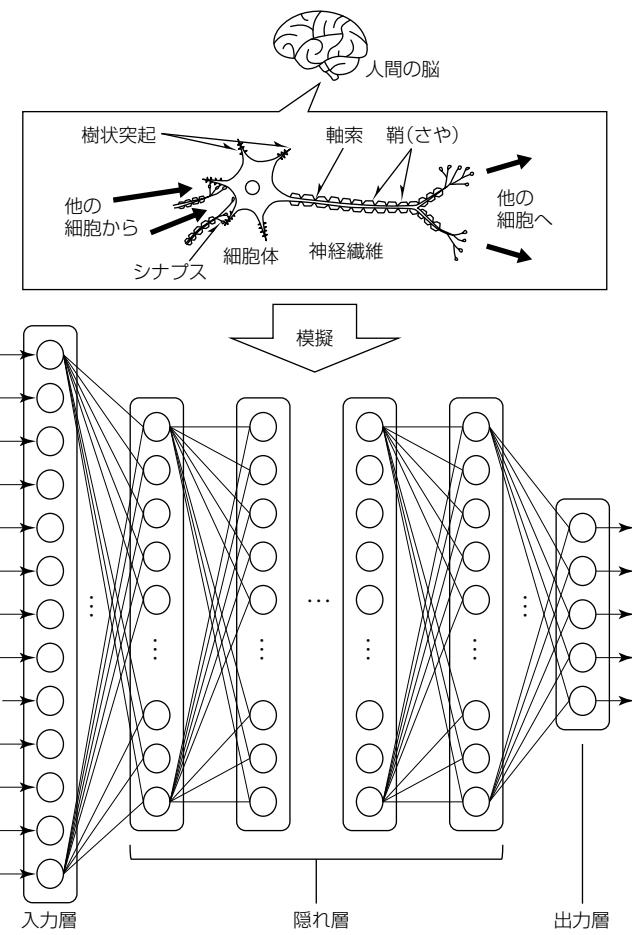


図2. 多層化されたニューラルネットワーク

最適化する“ファインチューニング”的2段階に分け，“プレトレーニング”に自己符号化器を用いて一層ずつ教師なし学習で初期化する。自己符号化器は隠れ層に対する入力層をそのまま出力層に用い、次元圧縮した中間層で入力層のデータを出力層で復元できるように学習する手法である。この自己符号化器を用いることによって、学習の収束性が向上した。

当社はこの自己符号化器が持つ機能を実現するための条件を導出し、演算量に大きな影響を与える枝の本数を削減することが可能かどうかを検討した。その結果、大幅な演算量削減にもかかわらず、正解率はほとんど劣化しないことが分かった。すなわち、当社が提案した手法はネットワーク構造と計算方法を効率化するアルゴリズムである。圧縮センシング理論を活用し、疎である事前分布の情報を伝播させるために最適な疎なネットワーク構造とそれに対する計算アルゴリズムを開発した⁽⁴⁾⁽⁵⁾。

この手法によって、従来型の“ディープラーニング”と比べて認識精度を維持したまま、低演算量化することが可能になった。演算量をどの程度まで削減できるかについては推論対象にも依存するが、画像認識の場合に、学習・推論の演算量及びメモリ使用量を従来比で1/10まで削減可能

なケースが報告されている⁽⁶⁾。低演算量化することによって、処理能力の低い組み込み機器や小型コンピュータ等に搭載することが容易になる。

3. コンパクトなハードウェアAI

一般に多層ニューラルネットワークは、大規模な演算を要するため、エッジコンピューティングで要求されるリアルタイム性を達成するためには、アクセラレータが利用される。アクセラレータの種類は、GPU、専用ASIC(Application Specific Integrated Circuit)、FPGAがある。用途などにも依存するが、エッジコンピューティングでは低消費電力であり、高いスループットが出せるFPGAが候補になる。

大規模なディープニューラルネットワークによる推論をFPGAで実現する場合、回路規模が大きくなり、FPGAが高コストになってしまうという問題がある。演算量を削減するコンパクト化を行えば、一般的に回路規模は削減傾向にはなるが、実装対象のアクセラレータによって、その効果は異なる。

この章ではFPGA向けのコンパクト化について述べる。

3.1 FPGA向け量子化技術

GPUなどは、浮動小数点演算専用のハードウェアを搭載しているため、問題にはならないが、FPGAの場合は、浮動小数点演算は、回路規模増大の原因になる。そこで、ニューラルネットワークの演算対象となるデータの量子化を行うことで、回路規模を削減する。重みデータを作成する際に、FPGA側の量子化処理と同じ処理を学習時に利用することで、推論精度を高めることができる。

3.2 FPGA向け枝刈り技術

実装先であるFPGAを意識しない不規則な枝刈りを行った場合、演算量自体は削減されても、FPGAでその効果を發揮できない。そのため、枝刈り前と後で、大幅な回路規模削減が見込めない。これは、同一処理を行う並列化した積和演算回路で、枝刈り箇所をスキップする場合とスキップしない場合が混在してしまい、その結果回路の動作率が低下してしまうためである(図3)。

そこで、FPGAの回路の動作率を向上させるため、枝の接続に規則性を設け、並列化した回路の動作率を向上させた(図4)。動作率の向上によって、必要な回路並列数を削減できる。

3.3 FPGAへの実装試行

量子化と枝刈りは、精度と回路規模に影響を与える。量

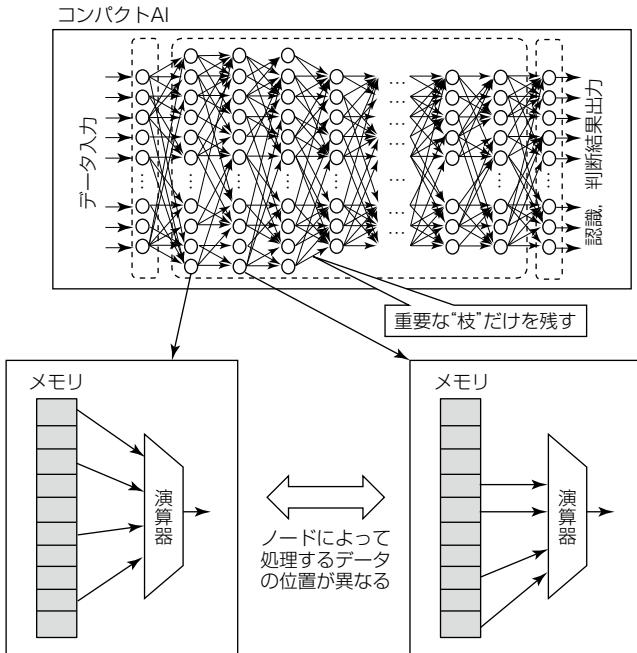


図3. 演算量削減技術の課題

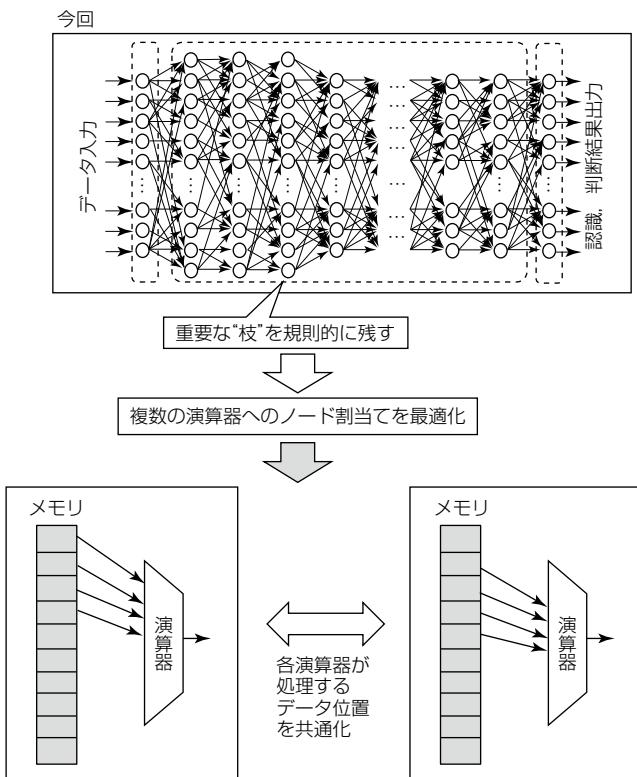


図4. コンパクトなハードウェアAI

子化によるビット数削減が大きい、又は枝刈りする量が多い場合、回路規模は小さくなるが、精度が劣化する。又は量子化によるビット数削減が小さい、又は枝刈りする量が少い場合、精度は高いが、回路規模が大きくなってしまう。そこで、精度と回路規模のトレードオフをとりながら、要求となる精度を出すことができる、最小限の量子化と枝刈りに対応した学習を実施する。

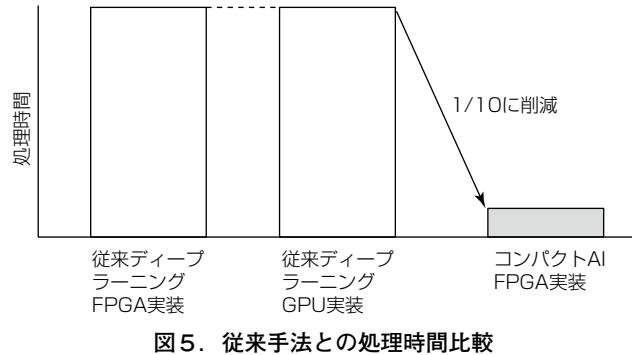


図5. 従来手法との処理時間比較

この技術を道路標識の画像認識用アルゴリズムに適用試行した。その結果、従来のディープラーニングアルゴリズムと比較して、推論精度を維持しながら推論処理にかかる演算時間を1/10に短縮し、リアルタイム性の向上を図った(図5)。また推論処理の演算時間が同等の場合には、従来に比べて回路規模を1/10に削減した。

4. む す び

当社のAI技術Maisartの一つである“コンパクトな人工知能”の演算順序効率化と回路構成最適化と、それによって小規模なFPGAにも実装できるディープラーニングのアルゴリズムを開発した。ディープラーニングは高度な推論が可能だが、多層のニューラルネットワーク構造を用いるため、推論に必要な演算量とメモリ量が膨大になる。ニューラルネットの重要な枝だけを残す“コンパクトな人工知能”で、推論処理の演算量を減らして省メモリ化を図り、組み込みCPUへの実装を可能にした。しかしながら、この手法では、枝の接続が不規則であったため、FPGAへの実装では並列処理を行う構造をとれず、回路規模を削減できないという課題があった。今回、枝の接続に規則性を持たせるために演算順序を効率化し、演算器へのノード割当てを最適化することで、小規模なFPGAへの実装を可能にした。この技術によって、リアルタイム性が求められる分野や、これまでコスト面で人工知能の適用が難しかった分野にも、適用範囲を広げていく。

参 考 文 献

- (1) Krizhevsky, A., et al.: ImageNet classification with deep convolutional neural networks, NIPS, 1097~1105 (2012)
- (2) He, K., et al.: Deep residual learning for image recognition, Proc. IEEE CVPR, 770~778 (2016)
- (3) Hinton, G.E., et al.: Reducing the dimensionality of data with neural networks, Science 313(5786), 504~507 (2006)
- (4) 松本 渉: 深層学習での演算量削減技術, 三菱電機技報, 91, No.6, 361~364 (2017)
- (5) Matsumoto, W., et al.: A deep neural network architecture using dementionality reduction with sparse matrices, ICONIP, 397~404 (2016)
- (6) 中尾克理, ほか: 疎なネットワーク構造を持つDeep Learningを用いた映像分析システム, 情報処理学会第79回全国大会, 6B-07 (2017)

Deep Clustering：話者・言語非依存なシングルチャネル音声分離技術

Deep Clustering : Speaker and Language Independent Single Channel Speech Separation Technology

相原 龍*

Ryo Aihara

ウィシャーン ゴードン†

Gordon Wichern

ルルー ジョナトン†

Jonathan Le Roux

要旨

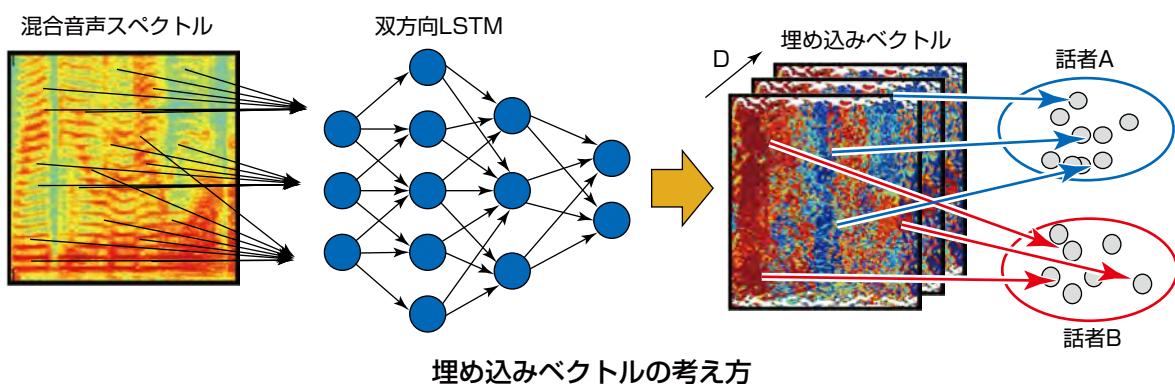
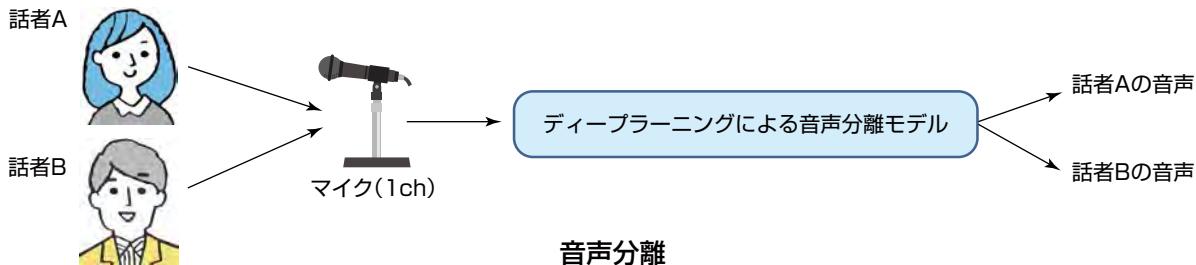
音声分離とは、複数話者の重畳音声からそれぞれの話者の音声を抽出する技術である。

ヒトは、二つの耳への音声の到來時間差から音源の位置を推定し、さらには視覚情報などを統合的に用いることで、複数話者の重畳音声から目的話者の音声を聞き取っていると考えられる。機械にとって、音声同士を分ける音声分離は、音声とノイズとを分離する音声強調と比較して難しい課題であり、特に音源の位置情報を得ることができないマイク1本での話者・言語非依存なシングルチャネル音声分離は困難であるとされてきた。

Deep Clustering(DC)は、ディープラーニング(深層

学習)とクラスタリングを組み合わせることで、世界で初めて^(注1)話者・言語非依存でありながら高精度なシングルチャネル音声分離を実現した。英語しか学習していない音声分離モデルで、未学習の日本語やそのほかの言語も事前登録なしに分離が可能であり、2話者の同時発話であれば90%程度、3話者では80%程度の再現率が得られる。公共空間やクルマなど、複数のヒトが同時多発的に発話する環境で音声認識を行う際には、背景ノイズだけでなくユーザー以外の音声によって認識率が大幅に低下することがあり、音声分離技術によって多様な環境での音声認識精度向上が期待できる。

(注1) 2017年5月24日現在、三菱電機調べ



LSTM : Long Short-Term Memory

音声分離と埋め込みベクトルの考え方

DCは、マイク1本だけで話者・言語に依存することなく音声分離ができる。ディープラーニングによる音声分離モデルでは、英語話者の音声だけを学習しており、事前に分離する話者の声を登録することなく音声分離が可能である。この技術の要になっているのは、埋め込みベクトルの考え方である。混合音声スペクトルからD次元の埋め込みベクトルを推定することで、古典的なクラスタリング手法で分離が可能になる。

1. まえがき

大勢の人がそれぞれに雑談している環境でも、ヒトは自分の興味のある話題や他人との会話を自然に聞き取ることができる。このような音声の選択的聴取を“カクテルパーティー効果”と呼び、イギリスの心理学者Cherryによって提唱された⁽¹⁾。Cherryは、被験者の左右の耳に同時に異なる音声を流し、指定された方の音声をシャドーイングする実験を行った。機械やロボットにカクテルパーティー効果を持たせようという試みは、20年以上にわたって多くの音声信号処理研究者によって研究されてきた。

一般に、ヒトは二つの耳を持ち、両耳への音の到來時間差を利用して音源の方向を推定していると考えられる。複数のマイクを用いたマルチチャネル信号処理による音源分離は既に多くの場面で実用化されており、目的音源の方向に指向性を向けるビームフォーミングがその代表的な手法である⁽²⁾。しかしながら、これらの手法は音源同士が近くに存在している場合には分離が困難であり、当然ながらマイクが一つしかないシングルチャネル環境では動作しない。

ディープラーニングの登場は機械学習の分野に飛躍的な進歩をもたらしたが、音声信号処理でもそれは例外ではない。ノイズ環境下音声からノイズを除去する“音声強調”では、ディープラーニング技術によってシングルチャネル音声強調が可能になった⁽³⁾。これはディープラーニングが、音声強調に適した特徴量の抽出と、音源情報のモデリングを一体で行うことができるためである。しかしながら、ノイズではなく、複数話者の重疊音声を話者ごとに分離する“音声分離”は、ディープラーニングをもってしても困難な課題であった。これは、ノイズと音声はその特徴が異なるのに対して、ヒトの音声同士はその特徴が類似しているためである。

DCは、ディープラーニングとクラスタリングを応用することで世界で初めて話者・言語非依存でありながら高精度なシングルチャネル音声分離を実現した⁽⁴⁾。英語しか学習していない音声分離モデルで、日本語やそのほかの言語も分離が可能であり、2話者の同時発話であれば90%程度、3話者では80%程度の再現率が得られている。この技術によって複数人が同時に話す環境でマイク1本での音声分離が可能になったため、多様なシーンでの音声認識の精度向上が期待されている。

本稿では、音声強調と比較してシングルチャネル音声分離がなぜ難しいのかを述べた後、DCの基本的なアルゴリズムとその発展的手法や低遅延化手法について述べる。

2. 音声分離の難しさ

本稿では、音声以外のノイズが重畠した音声からノイズを除去する技術を“音声強調”，音声同士が重畠した音声からそれぞれの話者の音声を分離する技術を“音声分離”として区別する。音声強調の場合は、抽出したい音声と除去したいノイズの特徴が異なることから、ノイズ重畠音声、正解となるクリーン音声及び除去したいノイズを与えてモデルを学習すればよい。しかしながら、音声分離の場合は特徴が似ているヒトの音声同士を分離するため、音声強調と同じような直接的分離モデルの構築が困難であった。

その原因の一つに、Permutation問題がある⁽⁴⁾⁽⁵⁾。図1に、話者非依存な2話者音声分離モデルを学習する例を示す。話者非依存なモデルを学習する場合、様々な話者ペアの音声を重畠し、この重畠音声と、正解となるそれぞれの話者の非重畠音声とを、学習データとして分離モデルに入力する必要がある。まず、図1の左側のように話者(A, B)の混合音声のサンプルを学習データとして入力し、左側に話者A、右側に話者Bを出力するように正解データを与える。次に話者(A, C)の混合音声サンプルを学習する場合、先ほど話者Aの正解データを左側に配置したため、図1中央のように話者Cの正解データは右側に配置することが自然であろう。しかし、話者(B, C)の混合音声サンプルを学習する場合、これまで両方とも右側に配置してきた話者の正解データを左側に配置すると、それ以前の学習との一貫性が失われてしまう。このように、2話者混合音声を3名の組合せで学習する場合でも正解データの配置方法が6通りも考えられ、混合音声から正解の分離音声を直接学習することが困難であることが分かる。

3. DCによる音声分離

DCは話者混合音声から正解音声を直接推定するのではなく、ディープラーニングを用いて“音声を分離しやすい特徴量”を推定することでシングルチャネル音声分離を可能にした。このような特徴量を“埋め込みベクトル”と呼ぶ。

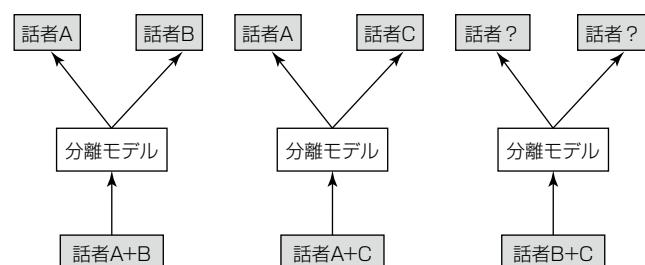


図1. Permutation問題



図2. DCの処理フロー

図2にDCの概要を示す。

音声は空気の振動であり、一次元の波形データとして表現される。波形データを短時間フーリエ変換することで、時間と音の高さを表す周波数の二次元データとして表現できる。このような時間-周波数表現をスペクトルと呼ぶ。2話者それぞれの音声スペクトルと、2話者音声を重畠させた音声スペクトルを比較すると、混合音声スペクトルのある時間 t とある周波数 f の要素点 (t, f) で、どちらの話者が支配的か(どちらの話者のパワーが大きいか)を計算できる。混合音声スペクトルの全要素数を I (時間長を T 、周波数長を F とするとき、 $I = T \times F$)とすると、音声分離は、混合音声スペクトルの全 I 個の要素点について、どの混合話者に属するかを決定する問題とみなせる。

しかしながら、混合音声スペクトルの全要素について、どの話者に属するかを直接推定することは困難である。2章で述べたように、Permutation問題によって正解ラベルの与え方が一意に決定できないためである。そこで、全ての混合音声スペクトルの要素点それぞれに対して、ディープラーニングを用いて数次元の埋め込みベクトルを推定する。ある混合音声スペクトルの要素点同士が同一話者に属する場合、対応する埋め込みベクトル同士の距離は近くなるよう、逆に異なる話者に属する場合は距離が遠くなるような基準で埋め込みベクトルを推定する。“ある混合音声スペクトルの要素 i がどちらの話者に属するか”は正解の与え方がPermutation問題によって一意に定まらないが、“ある混合音声スペクトルの要素同士が同じ話者に属するか否か”は、0か1かで表現された $I \times I$ の二次元の正解ラベルデータで表すことができるため、深層モデルでの学習が可能である。

このようにして推定した I 個の埋め込みベクトルは、混合音声に含まれる話者に対応するクラスタを形成していると考えられる。 k -means法のような簡単な教師なしクラスタリング手法を用いて、埋め込みベクトルを話者数分のクラスにクラスタリングできる。クラスタリングされた埋め込みベクトルに基づいて混合音声スペクトルを抽出し、逆フーリエ変換で音声波形に戻せば、单一話者だけの音声信号を得ることができる。

ここで注意しなければならないのは、埋め込みベクトルは、“注目する混合発話内の、対応するスペクトルの要素同士が同じ話者に属するか否かに基づいている”ため、話者固有の声質を表現しているわけではないことである。埋め込みベクトルは、あくまで“混合音声から音声を分離しや

すい特徴量”であるため、話者(A, B)の重畠音声から推定された話者Aの埋め込みベクトルと、話者(A, C)の重畠音声から推定された話者Aの埋め込みベクトルは同じである保証はなく、重畠されている音声によって、埋め込みベクトルは分離しやすいうように変化すると考えられる。

埋め込みベクトルの推定には再帰型ニューラルネットワークの一種である双方向LSTMを用いることで、混合音声スペクトルの要素同士の前後関係を考慮した推定が行われる。双方向LSTMは発話全体を録音する必要があるオフライン型の処理であり、この低遅延化手法については5章で述べる。

4. より直接的な音声分離手法

DCは埋め込みベクトルを介してクラスタリングを利用してシングルチャネル音声分離を実現したが、より直接的な音声分離手法も存在する⁽⁴⁾⁽⁶⁾。図3にその概要を示す。2話者音声分離モデルを学習するため、話者(A, B)の混合音声のサンプルを学習データとして入力する場合を考える。音声分離モデルの二つの出力に対して、正解データの配置は(A, B)と(B, A)のような二つのパターンを考えられる。両方のパターンとの誤差をそれぞれ計算し、誤差が小さい方を正解としてモデルに伝播(でんぱ)させ、モデル学習する。これを全学習データに対して繰り返し行うことでき話者非依存な音声分離モデルを学習できる。これは、深層モデルが output 話者の順列 (= permutation) を全て計算し、どの順番で出力するかを、入力された発話データごとに判断・決定していることに相当する。

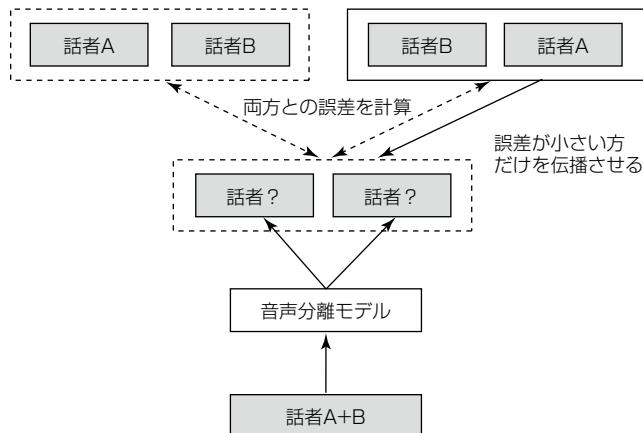


図3. より直接的な音声分離モデル

この直接的な音声分離手法とDCを組み合わせることで、更に高精度な音声分離モデルを構築できる⁽⁷⁾。この手法では、先に述べた直接的な音声分離と同時に、DCの埋め込みベクトルの推定を行う。モデルの学習時には、3章で述べたDCの誤差関数と直接的な音声分離モデルの誤差関数とを、重みを付けた上で足し合わせる。推定された埋め込みベクトルはモデルの学習だけにしか用いないが、埋め込みベクトルの推定によってモデルの汎化性能が向上し、より高精度な音声分離モデルが得られる。

5. 低遅延化手法

ここまで述べた手法では、音声分離モデルに双方向LSTMを利用している。双方向LSTMの内部では、時間軸方向にforward層とbackward層があり、前者は時系列の順方向の依存関係を、後者は逆方向の依存関係をとらえる。この構造のため、発話全体を入力するオフライン処理となり、音声分離の開始までに発話長以上の遅延が発生する。双方向性を取り除き、過去との依存関係だけをみると通常のLSTMでは、分離精度が大幅に劣化することが実験的に明らかになっている⁽⁸⁾。

双方向LSTMのブロック処理によって、発話長以上の遅延が発生していた処理開始遅延を0.6秒にまで削減することに成功した⁽⁸⁾。図4にその概略を示す。単純に発話をブロックに区切るだけでは、ブロック間の依存関係を考慮できない。そこで、各ブロックに一定時間長の補助ブロックを持たせる。この補助ブロックは時間方向の次のブロックと重なりを持たせており、forward層に関してはメインブロックからの情報を伝播させ、backward層に関しては補助ブロックから伝播させた依存関係を考慮する。このような処理を行うことで、forward層に関しては双方向LSTMとほぼ同等、backward層に関しては最低でも補助ブロックの長さ分の情報を見ることができる。メインブロックと補助ブロックのブロック長によって分離精度と処理開始遅延が変化する。

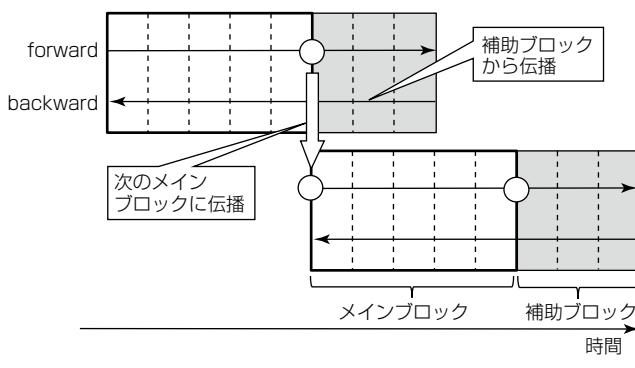


図4. 低遅延化手法

さらに、従来の双方向LSTMの音声分離モデルを用いて、低遅延音声分離モデルの分離精度を向上させることができる。このように、あるモデルの情報を他のモデルに伝播させる技術を“知識蒸留”と呼び、通常の教師あり学習と組み合わせることで、低遅延モデルでも、従来の双方向LSTMとほぼ同等の、2話者発話の分離精度90%程度を実現した。

6. む す び

世界初のシングルチャネル音声分離技術であるDCについて、基本的なアルゴリズムとその拡張、さらには低遅延化手法について述べた。次に、ここまで触れることができなかったDCの発展的手法について述べる。

ビームフォーミングを含む多チャネルのマイクアレーによる音声信号処理は、既に多くのシーンで実用化されている。DCの多チャネル拡張は参考文献(9)で提案しており、複数の2チャネルDCで求めた埋め込みベクトルを結合することで、多チャネル音声分離の精度向上が得られた。この手法が実用化されれば、更に安定した複数話者発話の同時発話分離が期待できる。音声から雑音を除去する音声強調と、音声同士を分離する音声分離を同時に使う手法も検証しており⁽¹⁰⁾、今後は更に多様な環境下での音声分離が実現する可能性がある。

以上のように、ディープラーニングの導入によって音声信号処理技術が利用できる可能性が、これまでの限られた環境からノイズ環境下、複数話者環境下へと大幅に広がりつつあり、現在これらの技術の実用化に向けて開発を進めている。

参 考 文 献

- (1) Cherry, C. : On Human Communication, MIT Press (1966)
- (2) Farrell, K., et al. : Beamforming microphone arrays for speech enhancement, Proc. IEEE ICASSP, 285~288 (1992)
- (3) Wang, Y., et al. : Towards scaling up classification-based speech separation, IEEE Trans. on Audio, Speech, and Language Processing, 21, No.7, 1381~1390 (2013)
- (4) Hershey, J. R., et al. : Deep clustering : Discriminative embeddings for segmentation and separation, Proc. IEEE ICASSP, 31~35 (2016)
- (5) Chen, Z. : Single channel auditory source separation with neural network, Ph. D. dissertation, Columbia Univ. (2017)
- (6) Yu, D., et al. : Recognizing multi-talker speech with permutation invariant training, arXiv preprint (2017)
- (7) Wang, Z.-Q., et al. : Alternative objective functions for deep clustering, Proc. IEEE ICASSP, 686~690 (2018)
- (8) Aihara, R., et al. : Teacher-student deep clustering for low-delay single channel speech separation, Proc. IEEE ICASSP, 690~694 (2019)
- (9) Wang, Z.-Q., et al. : Multi-channel deep clustering : Discriminative spectral and spatial embeddings for speaker-independent speech separation, Proc. IEEE ICASSP, 1~5 (2018)
- (10) Wichern, G., et al. : WHAM! : Extending speech separation to noisy environments, Proc. ISCA Interspeech, 1368~1372 (2019)

家電ごとの電気の使い方見える化技術

Visualization Technology for Power Usage of Home Electrical Appliances

矢本紘章*

Hiroaki Yamoto

坂上聰子*

Satoko Sakajo

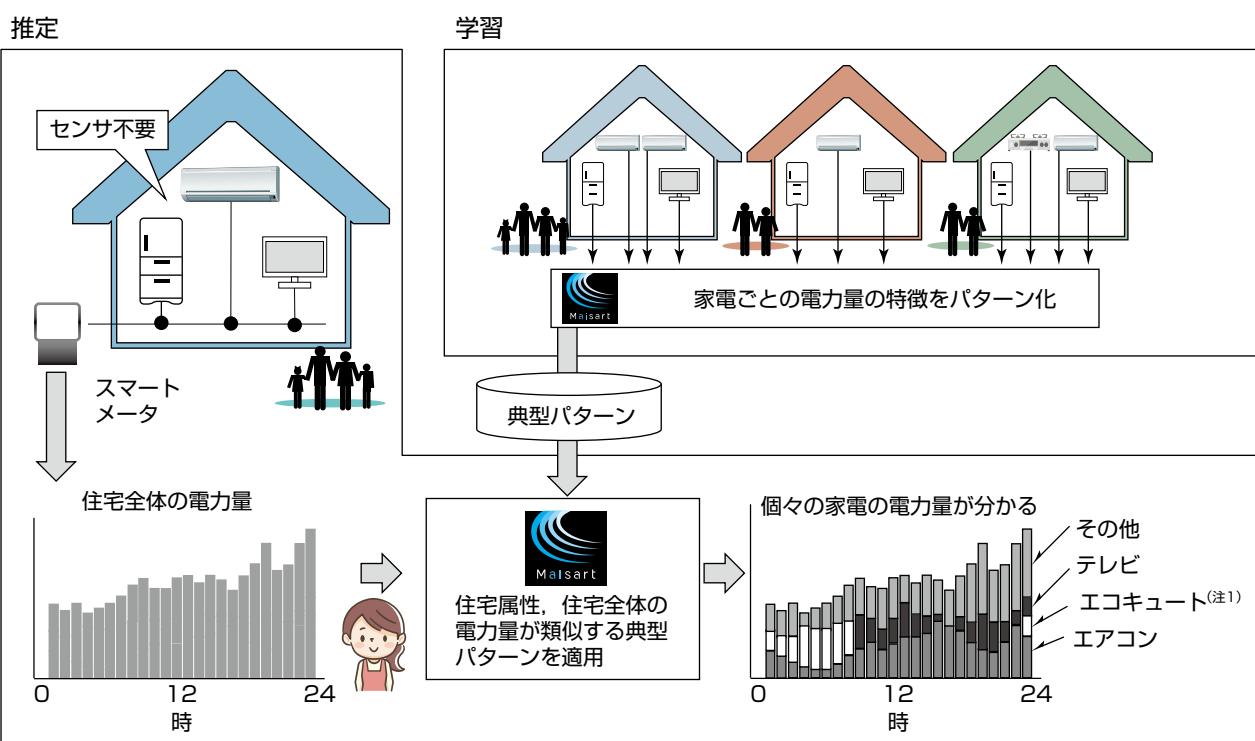
要旨

30分ごとの電力量を計測できるスマートメータの設置が進み、家庭では住宅全体でどのくらいの電力を使用しているかを時間帯ごとに把握することが可能になっている。さらにどの家電がどのくらい電力を消費しているかを知りたいというニーズに対応するため、分電盤に電流センサを設置し、電流波形から家電ごとの消費電力量(以下“電力量”という。)を推定する技術が開発されている⁽¹⁾。また、電流計測機能を内蔵した住宅分電盤が発売されており、主要な機器の電力量を測定できる⁽²⁾。しかし、購入や設置にかかるコストや既築住宅への対応が課題となり、家庭での機器導入や電力会社によるサービス展開が進んでいない。

そこで三菱電機は、当社のAI(Artificial Intelligence)技術“Maisart”を活用して新たな計測器を取り付けずに住

宅全体の30分ごとの電力量から家電ごとの電力量を推定する“家電ごとの電気の使い方見える化技術”を開発した。この技術はあらかじめ一部の住宅で計測した家電ごとの電力量から典型パターンを作成しておき、推定対象住宅で計測した住宅全体の電力量と類似する典型パターンを適用することで家電ごとの電力量を推定する。居住者の行動時間の微小な変動に起因する時間ずれを補正する機能によって、少ない典型パターンであっても多様な電気の使い方に対応できるという点が特長である。

これによって、電力データを活用した電力会社の家庭向けサービスの普及や家庭での省エネルギー意識の向上が期待できる。



家電ごとの電気の使い方見える化技術

家電ごとの電気の使い方見える化技術は、当社のAI技術Maisartを活用して、あらかじめ一部の住宅で家電ごとの電力量を計測・分類し、典型パターンを作成する“学習フェーズ”と、住宅全体の電力量と類似する典型パターンを適用して家電ごとの電力量を推定する“推定フェーズ”で構成している。日ごとや家庭ごとに異なる居住者の行動時間の微小な変動を吸収することで、家電ごとの電力量を高精度に推定できる。

1. まえがき

昨今の省エネルギー意識の高まりによって、家電が消費する電力量に対する関心が高まりつつある。スマートメータの設置によって、住宅全体の電力量を30分ごとに把握できるようになっている。しかし、家電ごとの電力量を把握するためには電流計測機能を内蔵した住宅分電盤などの設置が必要であるため、機器購入や設置にかかるコストや既築住宅への対応が課題となって、家庭での機器導入や電力会社によるサービス展開が進んでいないのが現状である。

そこで、より安価で容易に家電ごとの電力量を収集する手段として、スマートメータで計測される30分ごとの住宅全体の電力量から家電ごとの電力量を推定するディスクリゲーション技術が注目されている。例えば、住宅全体の電力量から時間帯ごとに家電の使用有無を推定し、ユーザーフィードバックして学習することで家電ごとの電力量を推定する技術が開発されている⁽³⁾。しかし、ユーザーフィードバックは手動で入力する必要があるため、居住者の作業負担が大きいという課題がある。

当社は、AI技術Maisartを活用してあらかじめ一部の住宅で家電ごとの電力量を計測して、類似するデータをグ

ループ化して典型パターンを作成しておき、推定対象住宅で計測した住宅全体の電力量と類似する典型パターンを適用することで家電ごとの電力量を推定する“家電ごとの電気の使い方見える化技術”を開発した。住宅全体の電力量は、“朝食を作る”“帰宅後に食事を作り、テレビを見る”“就寝する”といった居住者行動の影響を受けるが、これらの行動は同じ居住者でも行動の有無や時刻が日々異なる。このような多様な生活パターンに対応するためには、多数の典型パターンが必要になるが、この技術では類似度を判定する際に、行動時間の変動を許容することで、学習に用いるデータが少なくても多様な生活パターンへの対応を可能にした。

本稿ではこの技術の機器別負荷推定手法と時間ずれ補正機能の有効性検証について述べる。

2. 機器別負荷推定手法

2.1 手法の概要

開発手法は学習フェーズと推定フェーズの二つで構成されている。学習フェーズではあらかじめ学習用の住宅で家電ごとに電力量を計測するセンサを取り付け、住宅全体の

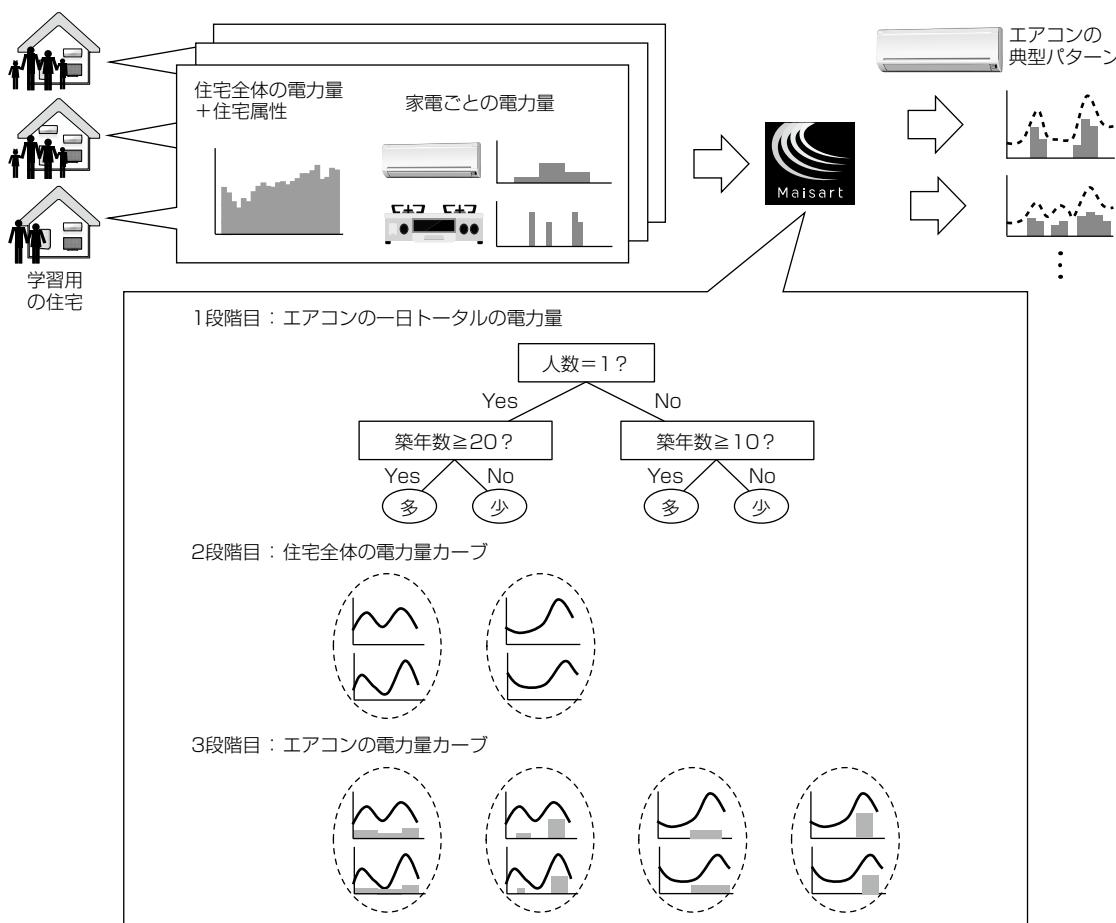


図1. 学習フェーズでのクラスタリング

電力量及び家電ごとの電力量を一定期間収集しておく。推定フェーズでは、学習結果を用いてスマートメータで計測される住宅全体の電力量から家電ごとの電力量を推定する。

2.1.1 学習フェーズ

家電が消費する電力量は、住宅の大きさや居住人数、保有家電など、住宅に関する情報(住宅属性)によって左右されるが、その影響は家電ごとに異なる。例えば、一般的にエアコンの消費電力は居住人数や家の大きさと比例して大きくなるが、冷蔵庫は小型の方が消費電力は多いため居住人数や家の大きさと反比例する傾向がある。そこでこの技術では、学習用の住宅で計測した電力量に基づいて、まず家電ごとの大まかな電力量と住宅属性との関係で分類しておいてから、時間帯ごとの電力量の推移すなわち電力量カーブで分類し、分類ごとに家電の使用傾向を学習する。

学習フェーズのクラスタリングの処理フローを図1に示す。学習フェーズでは当社のAI技術Maisartによって、

- (1) 家電ごとの一日トータルの電力量の大小をk-means法で分類し、ランダムフォレストを用いて電力量の大小に影響する住宅属性で決定木を作成

(2) 時間帯ごとの住宅全体の電力量カーブに対してウォード法による階層的クラスタリングを実施し、時間帯ごとの住宅全体の電気の使用傾向が類似する住宅を分類

(3) 時間帯ごとの家電の電力量カーブに対してウォード法による階層的クラスタリングを実施し、時間帯ごとの家電の使用傾向が類似する住宅を分類

の3段階でクラスタリングを実施し、クラスタごとに、各時間帯の住宅全体での電力量に対する家電ごとの電力量の割合の代表値を求め、典型パターンとして作成する。なお、(2)と(3)のクラスタリングでは行動時間による時間ずれを許容するため、2.2節で述べる時間ずれ補正を行う。

2.1.2 推定フェーズ

推定フェーズでは、家電ごとに、推定対象の住宅全体の電力量カーブ及び住宅属性が最も類似する典型パターンを選定し、住宅全体の電力量に典型パターンで定義された電力量の割合を適用して、家電ごとの電力量を推定する。推定対象の住宅全体の電力量カーブと典型パターンの電力量カーブの類似度を算出する際に、2.2節で述べる時間ずれ補正を行う。

2.2 時間ずれ補正機能

生活パターンは住宅によって異なるのはもちろん、同じ住宅であっても日々変化するものであり、この変化は電力量が増減する時間帯の違いとして表れる。この技術では、電力量カーブ間の類似度を算出する際に、時間ずれを許容

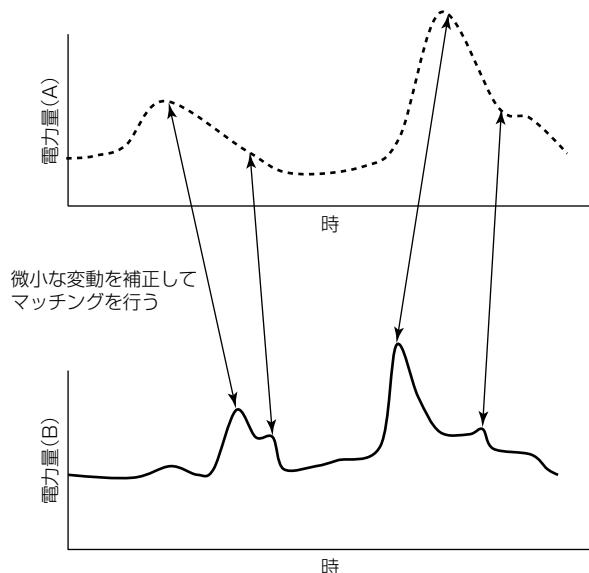


図2. 時間ずれ補正機能のイメージ

する処理を行っている。この機能は、動的計画法の一種である動的時間伸縮法(Dynamic Time Warping : DTW)⁽⁴⁾をベースにしている。時間ずれ補正のイメージを図2に示す。

DTWは二つの時系列データの各点の距離を総当たりで比較して系列同士の距離が最短になるパスを見つけるパターンマッチングの手法であり、時間軸方向のずれを補正しながら距離を算出できる。m個の要素を持つ時系列データ A_i と、n個の要素を持つ B_j のDTW距離D(A, B)は次の式(1)～式(3)によって再帰的に算出される。DTW距離が近いもの同士を類似度が高いとする。

$$d(i, j) = |a_i - b_j| + \min \begin{cases} d(i-1, j), \\ d(i, j-1), \\ d(i-1, j-1). \end{cases} \quad (2)$$

$$d(0, 0) = 0, d(i, 0) = d(0, j) = \infty \quad \dots \dots \dots \quad (3)$$

$(i=1, 2, \dots, m, \quad j=1, 2, \dots, n)$

このように、時間ずれを許容することで柔軟性の高いパターンマッチングを行うことができるので、少ない学習用の住宅で多様な生活パターンに対応でき、高精度な推定を実現できる。

3. 檢 証

3.1 檢証概要

時間ずれ補正機能の有効性を確認するため、2017年7月に仙台市で計測したある一日の住宅全体の電力負荷を入力

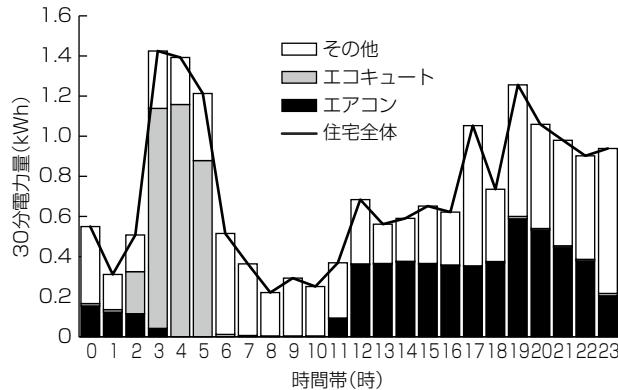


図3. 正解データ

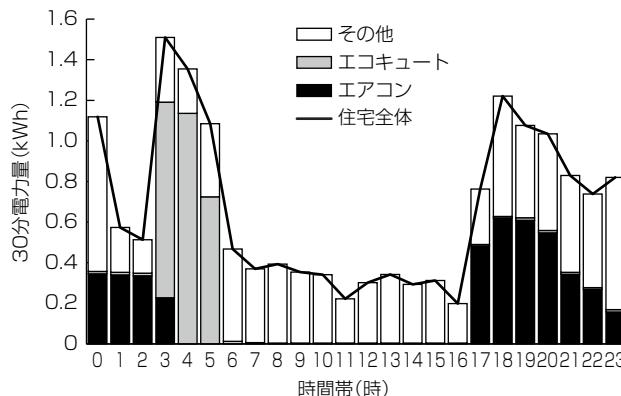


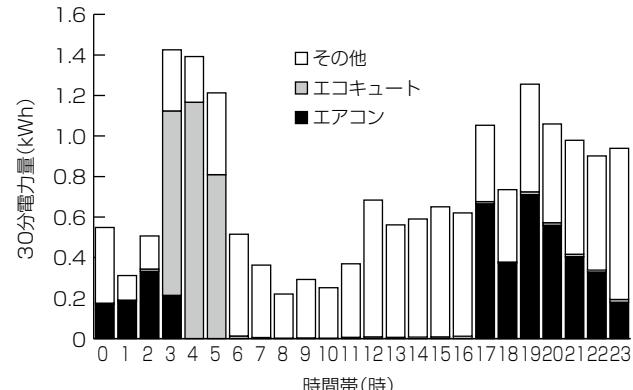
図4. 類似パターンとして選定された典型パターン

して、時間ずれ補正機能あり／なしで、それぞれ家電ごとの負荷を推定した。

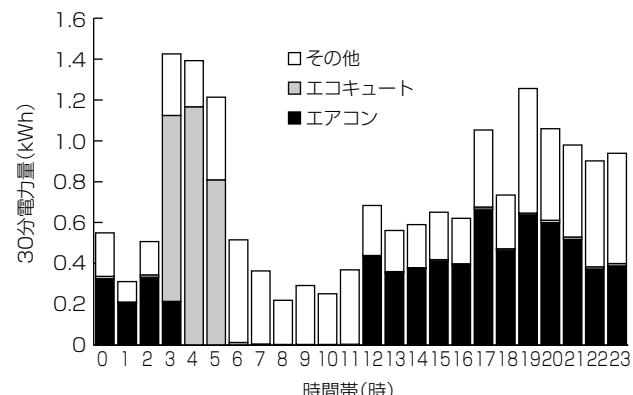
正解データを図3に示す。検証では正解データの“住宅全体”を入力として推定を行い、正解データの時間帯ごとの家電の電力量が正しく推定できるかを検証する。ここでは、住宅の中で電力消費が比較的大きいエアコンとエコキュート(自然冷媒CO₂ヒートポンプ給湯機)だけを評価対象にした。推定フェーズで、住宅属性と住宅全体の電力量カーブが類似しているとして選定された典型パターンを図4に示す。

3.2 検証結果

時間ずれ補正機能なしの場合の推定結果を図5(a)、時間ずれ補正機能ありの場合の推定結果を図5(b)に示す。図4の典型パターンでは12～17時にエアコンが使用されていないため、補正機能なしの場合はこの時間帯のエアコン使用を推定できなかった。一方、補正機能ありの場合は、エアコンの使用開始時刻のずれが補正されたため、エアコンの使用を推定できた。



(a) 時間ずれ補正機能なしの場合



(b) 時間ずれ補正機能ありの場合

図5. 家電ごとの電力量の推定結果

4. むすび

住宅全体の電力負荷から家電ごとの負荷を推定する“家電ごとの電気の使い方見える化技術”を開発した。本稿では、この技術の特長である時間ずれ補正機能の有効性を検証し、典型パターンと推定対象で行動時間が異なっている場合でも高精度に推定できることを確認した。今後は、典型パターン拡充による地域性の違いへの対応や推定対象機器の拡大を行う。

なお、この技術は東北電力(株)との共同研究によって開発したもので、同社の“よりそうスマートプロジェクト”⁽⁵⁾で採用された。

参考文献

- 機器の電力消費を推定するディスアグリゲーション、日経エレクトロニクス、No.4、81～85 (2015)
- enステーション EcoEye
<https://www.kawamura.co.jp/ecoeye/index.html>
- 高村幸宏：AIを活用した電気使用量分析、SIX2018 (2018)
https://six2018.abejainc.com/docs/c5_six2018.pdf
- Sakoe, H., et al. : Dynamic Programming Algorithm Optimization for Spoken Word Recognition, IEEE Trans. on Acoustics, Speech, and Signal Processing, 26, No.1, 43～49 (1978)
- よりそうスマートプロジェクト
https://www.tohoku-epco.co.jp/pastnews/normal/1197475_1049.html

小部敬純*

Takasumi Kobe

増崎隆彦†

Takahiko Masuzaki

栗山俊通†

Toshiyuki Kuriyama

中村隆顕†

Takaaki Nakamura

高精度に機器の異常を検知するAI

AI-based High-precision Diagnostic Technology for Equipments

要旨

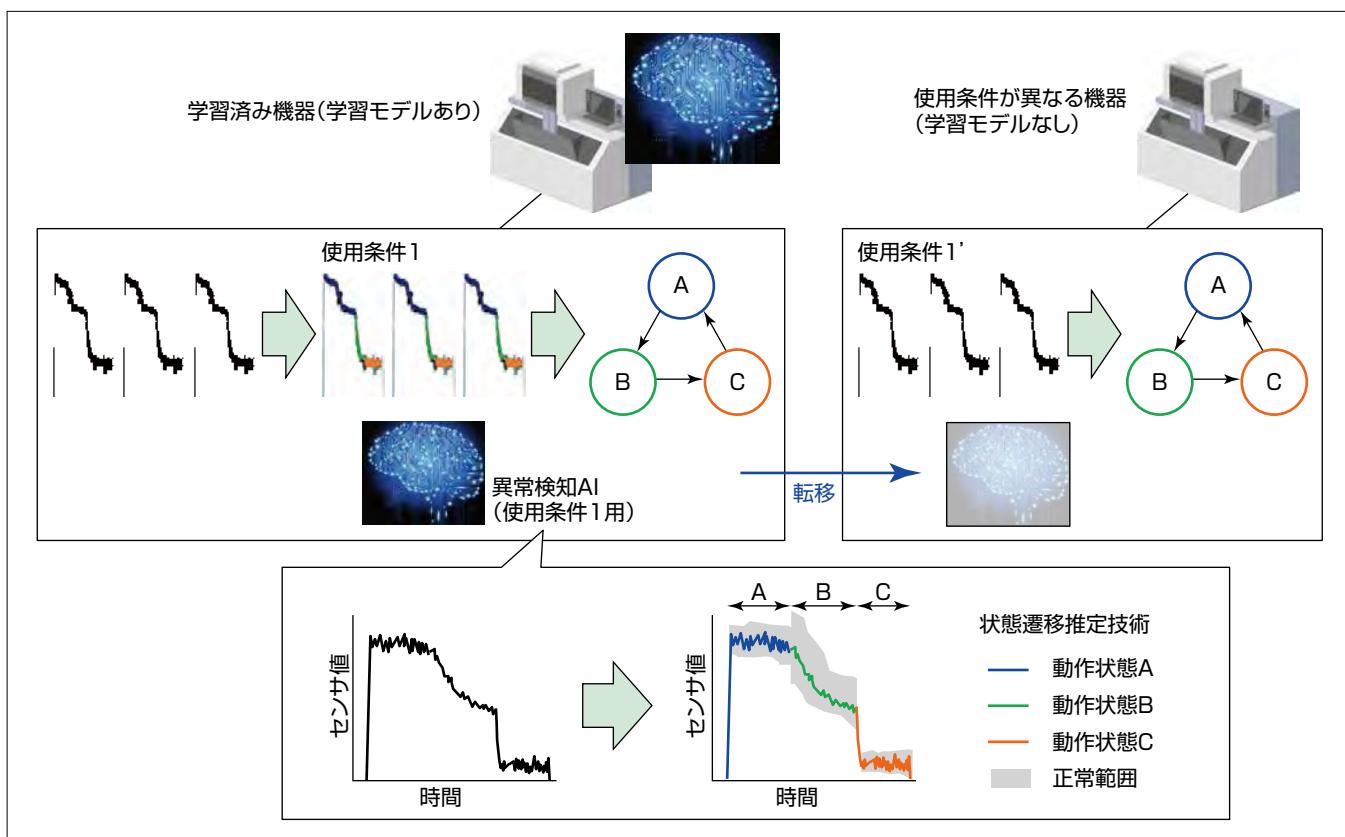
IoT(Internet of Things)技術の普及に伴い、設備や機器に設置されたセンサで計測された大量のデータを、クラウドやエッジ経由で随時取得することが可能になっている。随時取得可能な種々のセンサデータへAI(Artificial Intelligence)を活用することで、設備や機器のきめ細かな予防保全技術が実現されつつある。

異常検知を始めとした予防保全分野へのAIの活用では、設備や機器のセンサデータから、故障発生前にその予兆を検知し、故障発生前の保全を可能にすることで製造ラインのダウンタイムを削減し、効率的な保守が可能になることが期待される。

特に、製品製造時や機器運転時に収集される、時系列に発生するデータ(以下“時系列データ”という。)では、故障

予兆検出のために非常に微細な異常挙動を検出する必要がある。しかし、機器・設備の動作によって異常の頻度や異常時の波形の乱れ方が異なる場合があり、従来の単一条件設定による異常検知では、精度向上に限界があった。

動作による波形の乱れに対応するため三菱電機のAI技術“Maisart”を用いて、時系列データの特徴から動作状態の遷移を自動で推定し、動作状態ごとに適切な異常検知条件を自動設定することで、高精度に異常を検知する機器診断技術を開発した。この技術によって、機器の動作状態に応じた適切な異常検知条件が設定できるため、機器の異常を高精度に検知することが可能になった。また、この技術を応用し、予防保全技術の導入の容易化に向けた、使用条件の変化に対応可能な状態遷移推定技術を開発した。



使用条件が異なる機器のセンサデータに対する状態遷移推定技術の適用例

機器データの波形の特徴から機器の動作状態ごとに分割し、その遷移を推定することによって、機器の動作状態ごとに正常範囲を設定できる。これによって、高精度な異常検知が可能になる。また、一つの機器で学習した結果を使用条件が異なる機器に転移して活用することによって、新たに状態遷移を推定することなく、使用条件が異なる機器に対しても高精度に異常を検知できることが期待される。

1. まえがき

近年、IoTの普及によって、設備などに設置したセンサで計測したデータの活用にニーズが集まっている。特に、機器の予防保全分野では、設備の状態監視にセンサデータを利用することによって、従来のあらかじめ決められた時期に決められたメンテナンスを行う“時間基準保全(Time Based Maintenance : TBM)”から、必要なときに必要なメンテナンスを行う“状態基準保全(Condition Based Maintenance : CBM)”へと保全の最適化への発展が期待されている。当社でも設備から収集したセンサデータを利用した、異常検知技術を開発してきた。しかし、機器の高機能化によって、動作状態ごとにデータの特徴が異なる場合があり、高精度な異常検知技術の実現が課題であった。また、機器の使用条件によるデータのばらつきも考慮した異常検知も解決すべき課題である。本稿ではこれらの課題に対応した予防保全技術について述べる。

2. 機器向け状態遷移推定技術

保全の最適化のニーズに対応するため、機器の異常をきめ細かに監視し、最適な予防保全を実施する技術として、当社では、AI技術Maisartを用いた異常検知技術を持っている。

予防保全分野では、保全の最適化のほかに、予防保全技術の導入の容易化のニーズもある。従来の多くの異常検知技術では、同一機器で同様の動作条件で、既に学習済みの異常検知技術であっても、監視対象となる機器の使用条件(設置機器の外気温や稼働負荷等)が多様な場合、使用条件の特徴ごとにパラメータのチューニングが必要であった。そのため、データの蓄積や分析コストが膨大になり、同一機器であっても、使用条件が異なる機器が多い場合には、導入に障壁があった。

そこで、予防保全技術の導入の容易化のため、Maisartを用いた異常検知技術を応用し、使用条件が異なる場合でも汎用的に異常を検知可能な技術の開発に取り組んでいる。

対象とする機器のセンサデータには、気温、振動、電流、電圧、回転数等多種・多様な情報があり、機器が稼働していた季節や頻度、負荷状況などを把握できる。機器の予防保全を実施する技術には、これらのデータから、次のテーマに沿った情報を抽出するための分析が含まれる。

(1) 動作状態の推定

- ①分析対象：同じ傾向を示すデータのまとめ
- ②データの特徴：周期的な変動があるが、長期的な変動や突発的な変動等が少ない、工程の変化を抽出可能なデータ

(2) 異常検知

- ①分析対象：通常と異なる挙動
- ②データの特徴：長期的な変動や突発的な変動等があり、劣化の傾向を抽出可能なデータ

上記のテーマでは分析対象が異なるため、それぞれに望ましいデータの特徴を抽出するには、テーマに沿ったセンサデータの取捨選択が必要である。

2. 1 Maisartを用いた異常検知技術

Maisartを用いた異常検知技術は、まず、機器のセンサデータから動作状態の移り変わりを表す“状態遷移モデル”を自動生成し、状態遷移を推定している。そして、推定した動作状態ごとに適切な異常検知条件を自動設定し、細やかに機器を監視することで、高精度に異常を検知している。ここでは、この技術について述べる。

製品製造時の機器の時系列データとして、次の3種類の特徴を持つデータを対象にする(図1)。

- (1) 類似波形が繰り返し発生
- (2) 製品製造時に複数の動作状態に遷移
- (3) 動作状態ごとにデータの特徴が相違

これらの特徴を持つデータに対して適用可能な異常検知技術として、データの正常範囲を求め、その範囲から逸脱した場合に異常として検知する方式⁽¹⁾がある。しかし、故障の兆候は、製品製造時の機器の動作状態によって、データへの影響の出方が異なる場合がある。この場合、機器の動作状態を考慮せずに正常範囲を設定すると、範囲過大による異常の見逃しや、範囲過小による誤検知が発生するという課題がある(図2)。

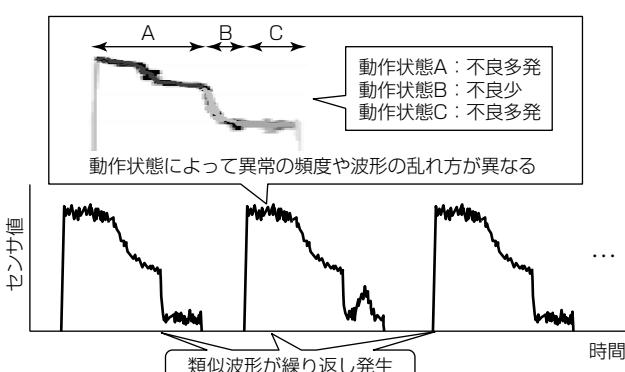


図1. 異常検知対象データの特徴

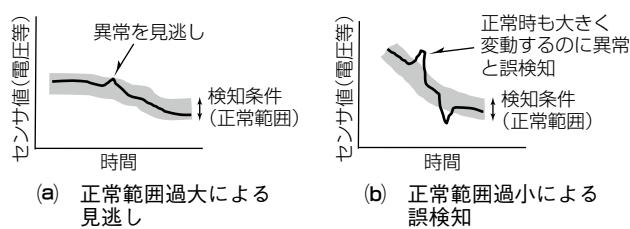


図2. 従来検知技術の課題

そこでこのような課題が存在する時系列データに対し、データの特徴から自動で機器の動作状態を推定し、動作状態ごとにデータを分割する技術を開発した(図3)。

時系列データを機器の動作状態ごとに分割し、動作状態ごとに異常検知条件を設定するための手順は次に従う。

- (1) 動作状態ごとにデータを分割し、移り変わり(状態遷移)を推定
- (2) 推定した状態遷移を基に動作状態ごとにデータを分割
- (3) 動作状態ごとに異常検知条件を設定

まず、製品の製造開始から終了までのデータ(以下“波形”という。)を動作状態ごとのデータに分割する。この際、動作状態の情報を別途収集している場合はそのデータを利用するが、今回はそうした情報が存在しないことを想定する。この場合、データの特徴から分割する必要がある。今回の対象データでは、変化の大きい点を動作状態の移り変わりの点として検出する。変化点検出の手法としてRDP(Ramer-Douglas-Peucker)アルゴリズム⁽²⁾を利用した。この手法では、波形の両端点を結んだ直線からの距離を基に、変化点を算出する手法であり、少ない計算量($O(n)$)で変化点の検出が可能である。

2.2 状態遷移の推定

2.1節で述べた手法をそのまま今回の対象データに適用した場合、変化の大きい部分に分割点が集中してしまう課題がある。そこで、所望の分割数より多く波形を分割し、その中から最適な分割点を選定する手法を開発した(図4)。

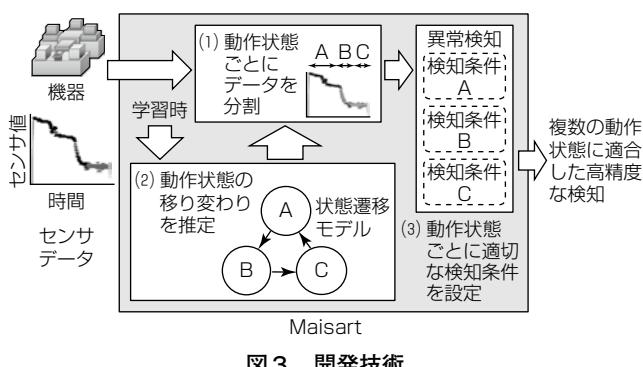


図3. 開発技術

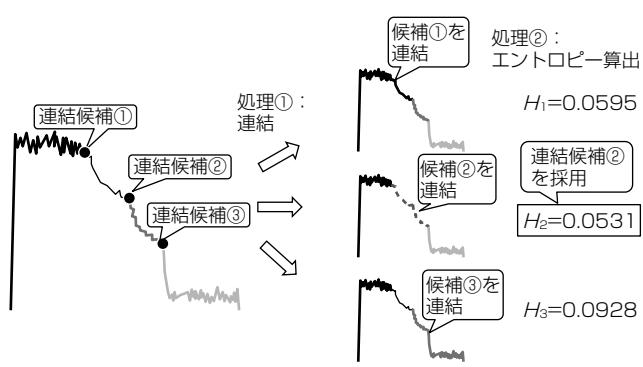


図4. 分割点の算出例

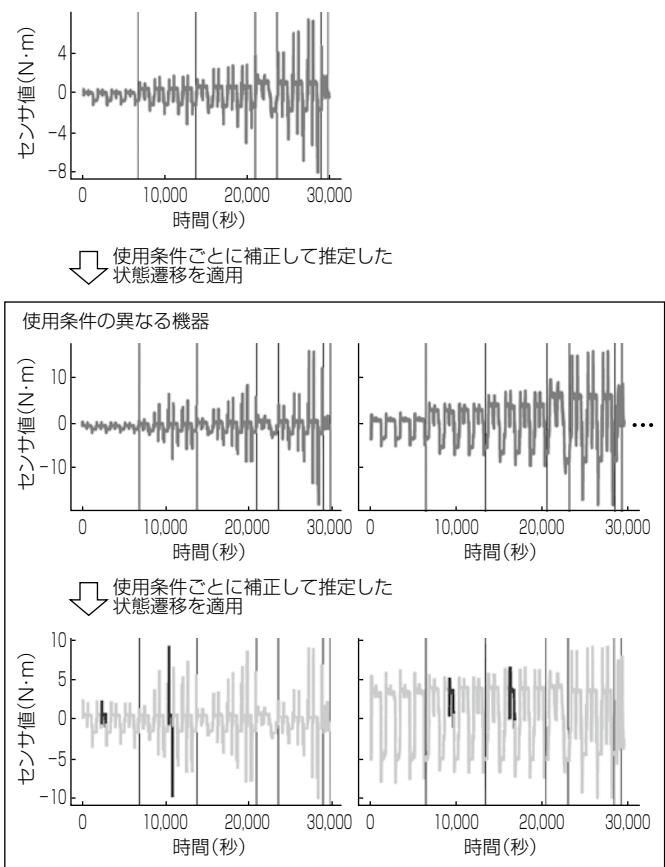
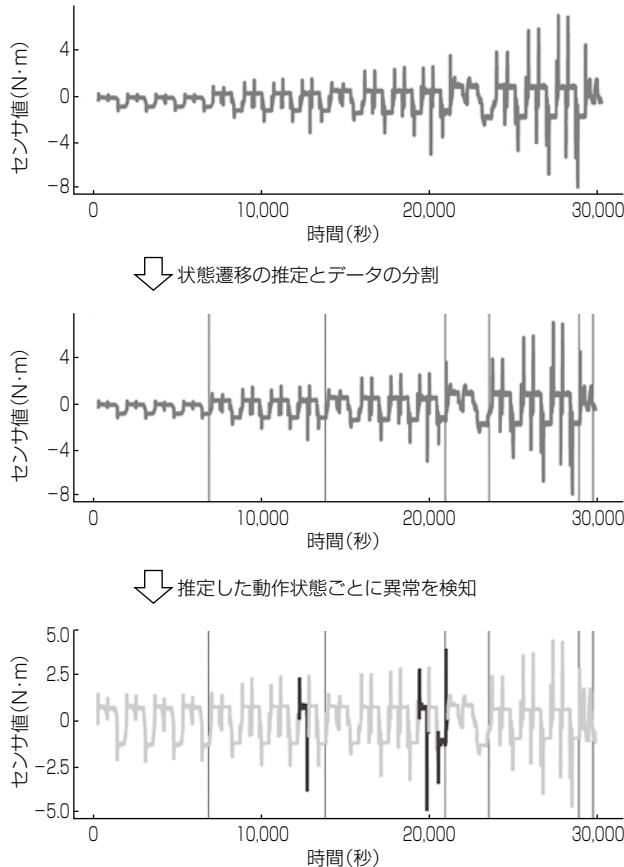
具体的には、多数の分割候補から機器の状態遷移のばらつきが最小となるような分割候補を選定する手法である。状態遷移のばらつきの指標には、状態遷移表のエントロピーを利用した。この手法によって、波形の分割点の選定失敗を防いだ上で、動作ごとに波形を分割可能にすることが期待される。

次に、この手法によって動作ごとに分割された波形(以下“部分波形”という。)に対し、動作状態ID(図3の“A”“B”“C”)を割り当てる。製品製造データでは、同一、又は類似の製品を連続して製造するため、同一動作での部分波形の形状は類似するものと考えられる。この仮定を基に、動作状態ID割当てをクラスタリング問題として捉える。なお、単純に動作の順番で動作状態IDを割り当てない理由としては、まれに設備の動作異常によって特定の動作がスキップされることがあり、その場合、動作状態ID割当てが失敗する可能性があるためである。また、動作の順番が必ずしも一定でない場合も考えられるため、今回は動作ごとの部分波形の形状ごとにクラスタリングする手法を採用した。具体的には、教師なし学習の一手法であるk-meansを利用した。この手法によって、部分波形を類似形状ごとに分類し、類似形状ごとに動作状態IDを附番する。動作状態IDが附番されることによって、動作の移り変わりの順番(状態遷移)、及びその確率も自動で学習することが可能になる。動作状態IDだけでなく状態遷移も併せて学習することによって、波形の乱れだけでなく、動作の遷移が学習時に見られないような挙動を示した場合にも異常を検知することが可能になる。

これらの手法によって、所望の分割数の入力だけから、データの特徴を利用した状態遷移推定が可能になることを示した。推定した状態ごとに、異常検知条件を設定することによって、状態ごとの動作の特徴に応じた正常範囲を設定することが可能になり、高精度な異常検知が可能になる。異常検知条件の設定には、各動作での部分波形から、各時刻のデータ分布を求め、その発生確率が $a\%$ (例： $a = 1\%$)以上になる部分を正常範囲とするなどの手法が考えられる。なお、今回対象にした製造機器のデータでは、各時刻のデータはおおむね正規分布に従うことを確認している。

図5は先に述べた異常検知技術を傾向の異なるデータへ適用した検証結果の例である。ここでは、まず、取得したセンサデータそれぞれについて、同じ傾向を示すデータのまとめりから、波形の動作状態を推定し、推定結果に応じたデータの分割を実施する。その後、分割したデータごとの特徴を学習し、学習結果に基づき、通常と異なる挙動を示した箇所を異常として検知している。

傾向の異なるデータへ適用した場合でも、状態遷移の推定とデータの分割が実施可能である。さらに、推定に基づ



く異常検知が可能であることが分かった。

この技術を応用し、既に学習済みの異常検知技術を使用条件が異なる機器へ適用する方式を考察する。この場合の課題は、使用条件ごとに特徴が異なる点である。そこで、既存技術の動作状態ごとの特徴を把握する機能を、使用条件ごとの特徴の把握へ適用する。動作状態ごとの特徴は学習済みであるため、使用条件ごとの特徴と組み合わせることで、使用条件に応じた動作状態ごとの検知条件の設定が可能になる。

図6はこの技術による使用条件の異なる機器での異常検知技術の検証結果の例である。使用条件ごとに学習済みのモデルを補正し、状態遷移の推定を実施している。この状態遷移の推定結果に基づくデータの分割を実施し、分割したデータごとに検知条件を設定することで、通常と異なる挙動を示した箇所を異常として検知している。

使用条件の異なるデータへ学習済みのモデルを適用した場合でも、状態遷移の推定とデータの分割が実施可能である。さらに、推定に基づく異常検知が可能であることが分かった。この技術によって、異常検知技術を使用条件が異なる機器へ適用することで、予防保全技術の導入の容易化が可能になる。

2.3 異常検知率

この開発手法を実際の製品製造機器のセンサデータに適

用したところ、状態推定を行わずに正常範囲を設定した場合には異常検知率85%であったのに対し、この手法を適用した場合、95%の異常を検出可能との結果を得て、この手法の有効性を確認した。

今後は、この技術を実際の製造現場に向けたツールとして開発し、実証実験を進めていく予定である。

3. むすび

予防保全技術へのAI適用による高精度化・省力化に向けた技術開発の取組みについて述べた。機器の高機能化に伴い、予防保全技術分野でのニーズは多様化していると考えられる。ニーズの多様化に対応するため、現場の知見やノウハウを吸収し、開発技術へ取り込むため、ドメイン知識の収集と実証実験の強化を実施していく。

参考文献

- (1) Yeh, CC. M.: Matrix Profile I: All Pairs Similarity Joins for Time Series: A Unifying View that Includes Motifs, Discords and Shapelets, 2016 IEEE 16th International Conference on Data Mining (ICDM), 1317~1322 (2016)
- (2) Douglas, D. H., et al.: Algorithms for the reduction of the number of points required to represent a digitized line or its caricature, Cartographica : The International Journal for Geographic Information and Geovisualization 10, No.2, 112 ~122 (1973)

制御入出力信号の非定常検出技術

Anomaly Detection Technology for Control Input-output Signals

中原大貴*
Daiki Nakahara
柴田昌彦*
Masahiko Shibata
高井紗紀*
Saki Takai

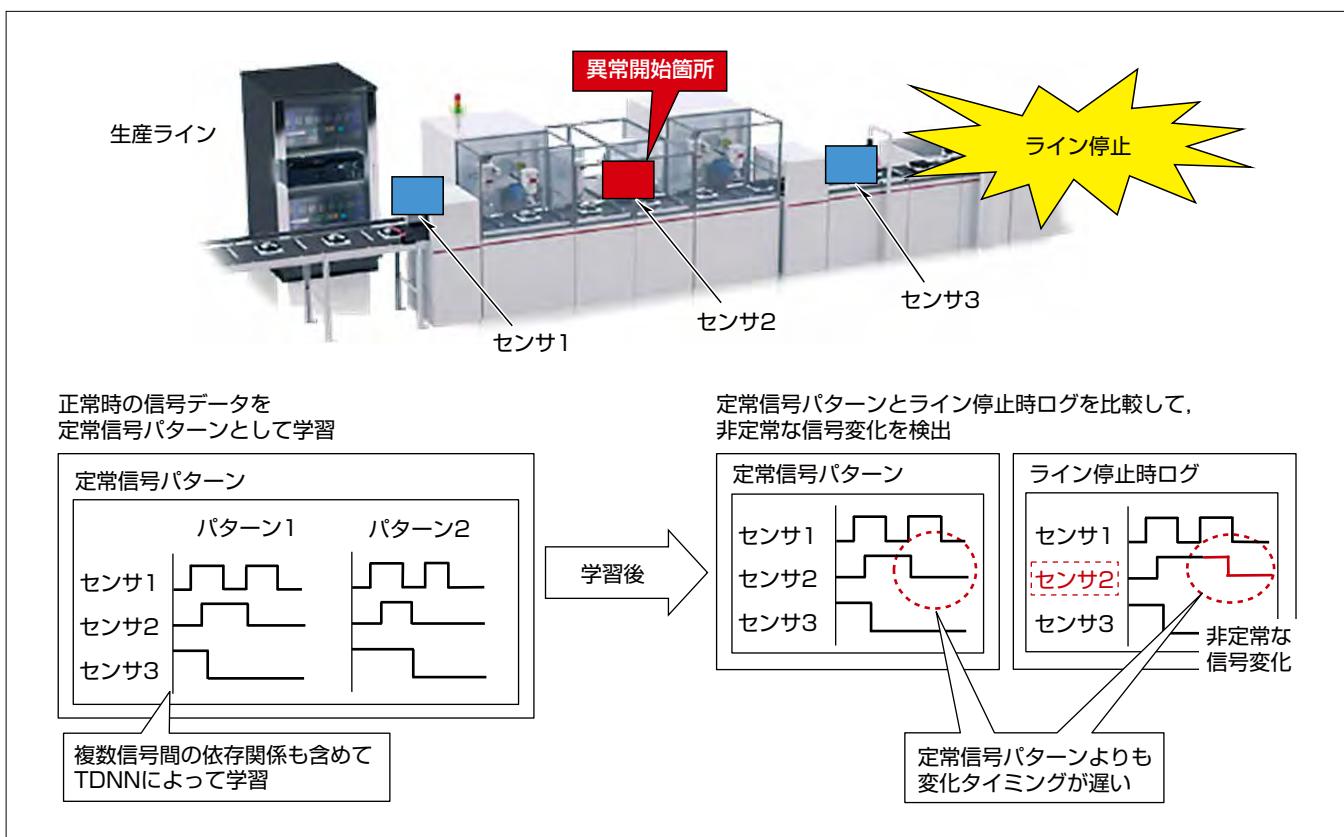
要旨

製造業では、IoT(Internet of Things)技術を活用した工場のスマート化が進められている。それに伴い、生産現場でのデータ利活用が加速しており、生産設備から取得したデータを生産現場の生産性向上へ活用する取組みが行われている。その一環として、生産設備のトラブル発生時に起きる非定常な状態や動作を検出する異常検出技術の開発が進められている⁽¹⁾。

従来技術では、電流や振動等のアナログ信号だけを監視するものが多く、トラブル要因箇所の特定後であれば、関連する信号に注目することで予防保全等が可能である。一方、トラブル要因箇所が不明な場合に複数の信号間の依存関係を含めて多数のアナログ信号を同時に監視しようとすると処理負荷が高く、実用的ではない。

そこで、三菱電機では、信号の予測・学習モデルとしてTDNN(Time Delay Neural Network)を採用し、生産設備の制御にも活用される2値の制御入出力信号(ビット信号)を、複数の信号間の依存関係を含めて監視することで異常開始箇所を特定する技術⁽²⁾を開発した。ビット信号であれば、アナログ信号よりも処理負荷が小さく、製造現場で活用される産業用パソコン等で実用可能な処理負荷にとどめることができる。実証実験の結果、9割以上の精度で異常開始箇所を検出でき、実装置へ適用可能であることを確認した。

この技術によって、異常開始箇所をいち早く把握し、迅速なトラブル要因の特定が可能になることから、生産設備のダウンタイム短縮に大きく貢献できる。



非定常検出技術

非定常検出技術では、生産設備の異常時に発生する非定常な信号変化を検出することで、異常開始箇所としてユーザーへ提示する。まず、生産ラインの正常稼働時での信号データを一定期間収集し、信号間の依存関係も含めて定常時の信号パターンだけTDNNによって学習する。学習後は、トラブル発生時の信号データと定常時の信号パターンとを比較することで、非定常な信号変化の発生時刻と箇所を検出する。

1. まえがき

近年、製造業で、IoT技術を活用した工場のスマート化が進み、それに伴い、生産現場で取得されるデータを生産現場の稼働率向上に活用する取組みが活発化している。

生産現場では、ライン停止等の生産設備でのトラブル発生時で、異常箇所を迅速に突き止めることができることが求められており、当社では、生産設備で発生したトラブルの異常開始箇所を自動検出する技術の開発に取り組んでいる。この技術では、生産設備の制御に活用される複数のビット信号間の依存関係に基づいて、異常に発生する非定常な信号変化を検出し、異常開始箇所としてユーザーへ提示する。

本稿では、当社で開発した非定常検出技術と、実装置にこの技術を適用して実施した実証実験について述べる。

2. 非定常検出技術

2.1 開発方式

一般的な教師あり機械学習を利用した非定常検出方式では、検出対象とする非定常な信号データも合わせて機械学習する。しかし、生産現場で非定常な信号パターンを網羅的に収集することは現実的ではない。そのため、開発方式では教師なし学習、すなわち正常な信号データだけで機械学習する。具体的には、正常な信号パターンから、過去一定時間長の信号値を基にして次の信号値を予測するモデルを構築する。学習後の、生産ライン稼働時の開発方式の手順は次のとおりである。

- (1) 生産ラインから信号データを収集
- (2) 過去一定時間長の信号値を保持
- (3) TDNNによって過去の実測値から次の信号値を予測
- (4) 予測値と実測値の比較から異常度を算出
- (5) 異常度から非定常な時刻と信号を特定

開発方式では、正常な信号パターンに時間的なずれが生じる場合でも対応可能なTDNNを採用し、ビット信号の学習・予測を行う。そして、ビット信号の予測値と実測値から負の対数尤度(ゆうど)を異常度として算出する。TDNNについては2.2節で、異常度の算出については2.3節で詳細を述べる。

2.2 TDNN

TDNNは主に時系列データを扱う際に利用されるNN(Neural Network)であり、過去の数セットのデータを入力とする。開発方式で利用するTDNNを図1に示す。NNの入力層には一定時間長のビット信号値を、出力層には次

の時刻の信号値を適用する。学習の間は、正常な信号のデータを生産現場から十分な期間収集し、TDNNに入出力のパターンを学習させる。この学習によって、TDNNは過去一定時間長の信号値を基にして次の信号値の予測を出力するようになる。学習後に生産現場で非定常検出を行う間は、信号値をリアルタイムで取得し、そのたびにTDNNによって次の信号値の予測を行う。

生産現場では、装置が正常に稼働している場合でも、信号が変化するタイミングにずれが生じることがある。TDNN以外の手法(パターンマッチングや状態遷移モデル等)では、最悪の場合、こうしたずれも含めて全ての信号パターンを学習・登録する必要があるため、学習データ量や学習モデルサイズが膨大になり、実用的ではない。一方、この方式で採用したTDNNでは、信号変化タイミングのずれも含めて一つのモデルで表現できる。例えば、図2のように正常な信号変化タイミングにある程度の時間範囲がある場合でも、幾つかの信号パターンでの依存関係も加味して正常な範囲として学習できる。また、学習結果とし

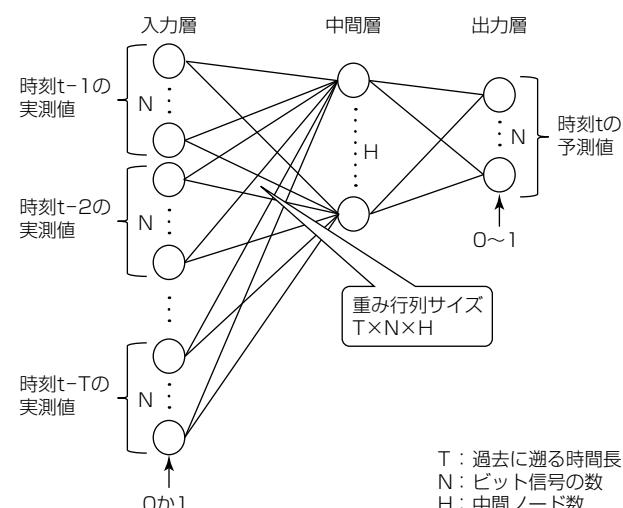


図1. この方式でのTDNN

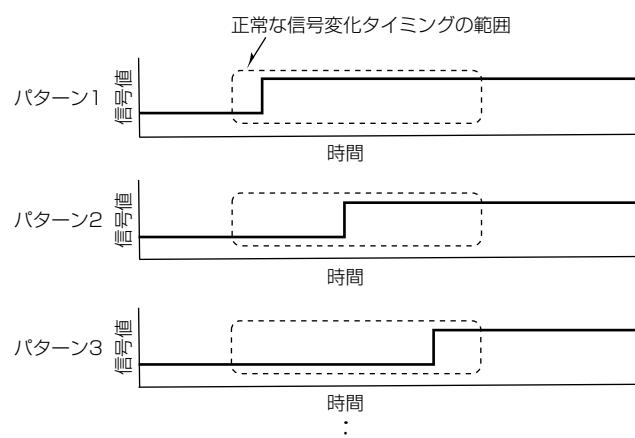


図2. 変化タイミングに時間範囲がある信号パターン例

て保持する重み行列のサイズ(図1の $T \times N \times H$ の部分)は、信号数の1次相関(図1のNの部分)及び遡る時間長の1次相関(図1のTの部分)で増大する。そのため、信号数が増大した場合でも、行列のサイズが指数関数的に増大することなく、データ量を抑えることが可能である。

2.3 異常度の算出

開発方式の異常度の算出について述べる。開発方式でのTDNNによる信号の予測値は0から1の間の小数値になる。予測値は信号値の期待値であり、式(1)から各信号で“1の値を取る確率”とみなすことができる。

同時に、“1-予測値”を各信号で“0の値を取る確率”とみなすことができる。

$$\begin{aligned} p &= E[X] \\ &= 1 \times P(X=1) + 0 \times P(X=0) \\ &= P(X=1) \end{aligned} \quad \dots \quad (1)$$

ここで、 p ：予測値

X ：信号値

各信号が実測値を取る確率の負の対数尤度を異常度とする。実測値と予測値によって、異常度は式(2)で表される。

$$E = -x \log p - (1-x) \log(1-p) \quad \dots \quad (2)$$

ここで、 E ：異常度

x ：実測値($x=0$ 又は $x=1$)

p ：予測値($0 \leq p \leq 1$)

稼働時には、全信号の異常度の合計を算出し、それがしきい値以上であるか否かによって非定常の判定を行う。しきい値は、例えば、正常データでの異常度の最大値で設定することが考えられる。非定常と判定された場合は、異常度の高かった信号を抽出し、ユーザーに提示できる。予測誤差を ε とし、予測誤差に対する異常度を図3に示す。この方式は、予測値を確率とみなして負の対数尤度を異常度としてすることで、ユークリッド距離等の一般的な手法に比べ、重大な非定常に対し顕著な異常度を与えることができる。

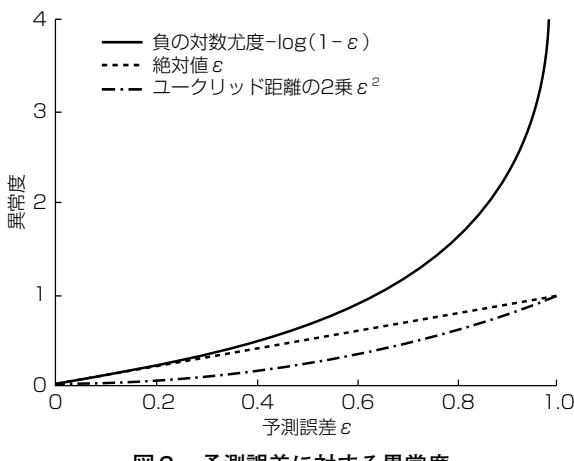


図3. 予測誤差に対する異常度

3. 実証実験

生産現場の様々な装置に開発方式が適用可能であるか検証する実証実験を実施した。具体的には、実装装置へ適用した際の学習時間と検出時間、そして非定常検出可否(非定常発生時刻と非定常信号の特定)を確認する。

この検証では、漏電遮断器の組立てを行う製造ラインで稼働する遮断器組立て・試験装置と遮断器部品組立て装置を対象にして、各装置から収集する信号データの想定環境を表1に示す。また、2章で述べた方式に基づき非定常検出を行うプログラムの動作環境を表2に示す。さらに、この検証での目標性能を表3に示す。表3で、製造現場で許容可能と考えられる時間を学習時間の目標値として、リアルタイムでの非定常検出可能な時間を検出時間の目標値として設定した。

なお、装置で発生する正常でない事象を“エラー”と呼び、この方式が学習データとは異なると判断した事象を“非定常”と呼ぶことにする。

3.1 信号値の予測

対象装置から収集した正常な信号データを学習したところ、予測精度の低い信号データが幾つか存在することが判明した。予測精度の低い信号の特徴を次に示す。

- (1) プッシュボタン等人手の操作に応じて変化する信号
- (2) 他の装置の動作や、他の装置から送られる信号値に基づいて変化する信号
- (3) エラー発生時等動作サイクルと関係なく不定期に変化する信号
- (4) 変化の前兆が長時間(数十秒以上)前にある信号

表1. 想定環境

サンプリング周期 (ミリ秒)	使用信号数 ^(注1) (個)	学習データ量 (セット)
100	1~256	100~1,000

(注1) この方式で対象となる、定期的に変化のあるビット信号の数

表2. プログラムの動作環境

項目	内容
CPU	Intel Core ^(注2) i7-7700K CPU@4.20GHz
メモリ	64GB
OS	Windows ^(注3) 10 Enterprise 64bits
GPU	GeForce GTX ^(注4) 1080 Ti

(注2) Intel Coreは、Intel Corp.の登録商標である。

(注3) Windowsは、Microsoft Corp.の登録商標である。

(注4) GeForce GTXは、NVIDIA Corp.の登録商標である。

表3. 目標性能

学習時間	検出時間	検出精度
72時間以内	サンプリング周期以内	ライン停止エラーを100%検出

- (5) アナログ値を2進数で表現し、各桁のビット値を取り出した信号
 (6) 短い間隔(10ミリ秒程度)でON/OFFを繰り返す信号
 (1)～(6)以外のビット信号は、精度良く変化を予測できており、この検証では、(1)～(6)に該当する信号データを対象から外した上で、学習及び非定常検出を実施した。

3.2 学習時間と検出時間

各装置の学習時間と検出時間の結果を表4に示す。なお、学習時間は、学習誤差の減少が収束するまでにかかる時間としている。装置ごとに使用する信号数や学習データ量に差異はあるが、全ての装置で目標とする学習時間及び検出時間の目標を達成する結果が得られた。

3.3 非定常検出結果

各装置で発生したエラーの種類数と、そのうち非定常検出ができたエラーの種類数及び割合を表5に示す。どちらの装置でも、発生したエラーに対して9割程度を検出した。

表4. 学習時間・検出時間

対象	使用信号数 (個)	学習時間 (分)	検出時間 (ミリ秒)
遮断器組立て・試験装置	237	360	
遮断器部品組立て装置	119	190	全て100ミリ秒以内

表5. 非定常検出結果

対象	エラー種類数 (個)	検出種類数 (個)	検出割合 (%)
遮断器組立て・試験装置	28	27	96
遮断器部品組立て装置	12	11	92

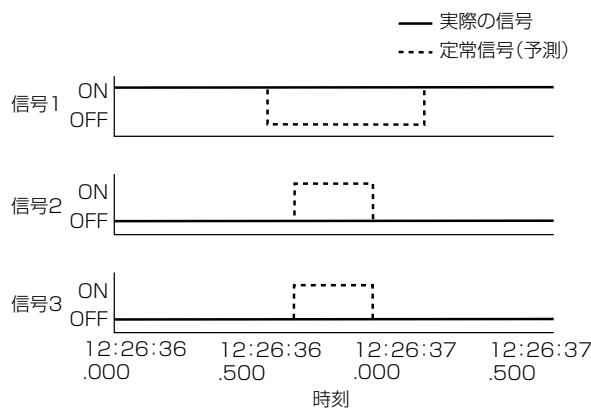


図4. 非定常検出例

3.4 考 察

非定常検出について、エラー発生前後のデータに対して開発方式を適用した結果の一例を図4に示す。図4から、信号1～信号3は定常動作として予測した変化とは異なる非定常な信号変化になっており、開発方式によって、信号1～信号3を非定常変化がある信号と判断してそれぞれの信号と非定常変化箇所を検出している。

信号1～信号3は、非定常変化の検出時刻より後に発生したエラーに関連する信号であり、開発方式で、エラーに関連する非定常変化を適切に検出できたと言える。

一方で、エラー発生時の動作サイクルとは関係なく不定期に変化する信号(3.1節の(3)で示した予測対象外の信号)に関連するエラーについては検出できなかった。

このことから、予測対象とする信号で動作サイクルに応じた非定常変化が発生するエラーであれば、この方式で検出可能であると考えられる。

4. む す び

TDNNを利用した制御入出力信号の非定常検出技術について述べた。この技術は、生産設備のトラブル発生時の異常開始箇所を特定するものであり、実証実験によって、この技術が製造現場の装置へ適用可能であることを実証した。

非定常検出に関しては、9割程度の種類のエラーを検出しておらず、予測対象とする信号に動作サイクルに応じた非定常変化が現れるエラーであれば、この技術によってエラーに関連する信号及び信号変化を検出可能であることを確認した。また、学習時間と検出時間の面では、目標とする数値を達成し、製造現場の装置が対象であっても、十分な性能を実現できることを確認した。

この技術では、さらにアナログ信号も対象にできれば、ビット信号とアナログ信号の関係性から非定常検出し、装置の動作をより詳しく確認できるようになる。そのため、今後は、アナログ信号等の現状では対象にできない信号にも対応可能になるように方式の改良を目指す。

参 考 文 献

- (1) Vodenčarević, A. et al.: Data Analytics for Manufacturing Systems, 2015 IEEE 20th Conference on Emerging Technologies & Factory Automation, 1~4 (2015)
- (2) 柴田昌彦, ほか: デジタル制御入出力信号の非定常検出方式の検討, 情報処理学会 第80回(平成30年)全国大会講演論文集(1), 157~158 (2018)

AI技術“Maisart”による機器制御の高性能化

Sophisticated Equipment Control by Artificial Intelligence Technology
"Maisart"

越山利貞*
Toshiyada Mariyama

太田 佳†
Kei Ota

増井秀之†
Hideyuki Masui

森本卓爾†
Takuji Morimoto

穂苅寛光†
Hiroaki Hokari

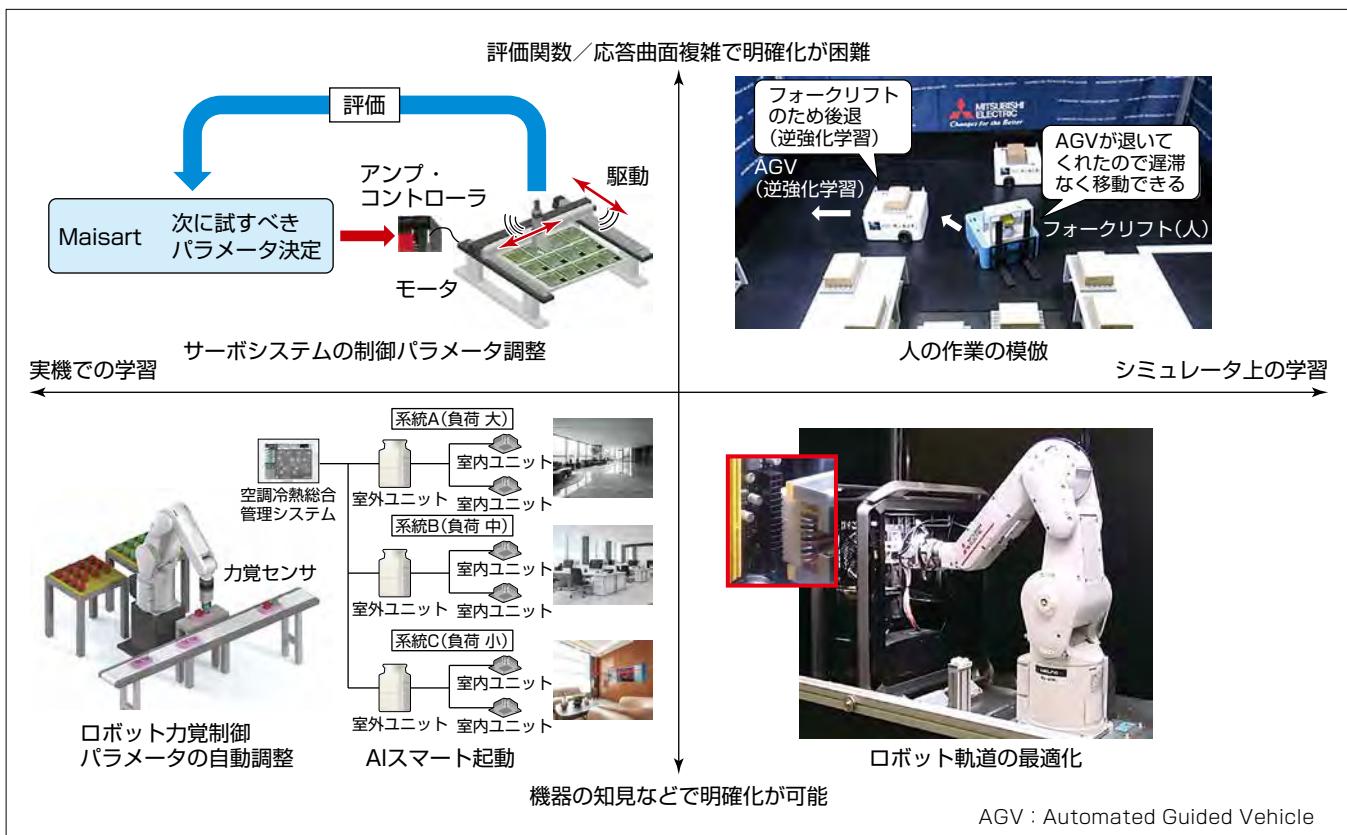
要旨

三菱電機では、機器の課題に応じてAI(Artificial Intelligence)技術Maisartを開発することで、機器制御の高性能化を実現している。高精度なシミュレータの有無、評価関数や応答局面の複雑さによって用いる手法が変わる。

高精度なシミュレータが利用できない場合、制御分野でAIを用いる利点の一つは、機器の生のデータを使用することで最適な制御を実現できることである。その場合、実機でデータを収集するため、できる限りデータ収集量を少なく済ませる必要がある。例えば、機器の知見を用いることでパラメータの探索空間を小さくする手法や、ベイズ最適化のような効率よく良解を求めるアルゴリズムの導入が考えられる。この事例として、空調機器の予冷・予熱運転

の高機能化技術、産業用ロボットの力覚制御パラメータ調整によるタクトタイム短縮技術、サーボシステムでのパラメータチューニングによるタクトタイム短縮技術を開発した。

一方、高精度なシミュレータが利用できる場合には、AIを用いることによって、より高性能な制御を導き出すことが可能になる。代表的な手法として深層強化学習や逆強化学習などが挙げられるが、どちらもシミュレータ上で膨大な試行錯誤によって最適解を求めるため、アルゴリズムの工夫で計算時間を短縮することが求められる。この事例として、産業用ロボットの軌道を短時間で自動生成する技術や、無人搬送車の制御ルールを人の運転ログデータを基に獲得する技術を開発した。



“Maisart”的機器制御への適用事例

横軸に、学習としてシミュレータを用いたか、実機を用いたかを示し、縦軸に評価関数の設計が容易か困難かを示し、当社のAI技術Maisartの機器制御への適用事例をマッピングした。右上にいくほど課題としての難易度が上がる。難易度の高い課題に対しては、シミュレータを駆使してAI手法を高度化することで課題を解決している。左下の事例は、機器の知見を用いることでデータ収集コストを下げ、課題を解決している。

1. まえがき

AI技術は2010年代前半では画像識別技術を中心に発展してきたが、2010年代後半からは制御分野での利用が活発に検討されるようになった。本稿では、当社が開発したAI技術Maisartの制御分野での取組み事例について述べる。AIによる制御を考えた場合、解きたい問題の難易度、シミュレータの有無などによって手法が大きく異なる。そこで、事例を紹介しながら、開発目的に応じたAI技術について実例を引用して述べる。

制御分野では、シミュレータの有無が手法選択の大きな分岐点となる。まず、シミュレータを用いずにAIを用いる場合は、試行錯誤を伴わないケースと、伴うケースの二つに大きく分けられる。試行錯誤を伴わない場合には、既に最適な、又は目的となる軌道・設定が設計されており、データを大量に収集して学習することで自動化を実現することになる。いわゆる教師あり学習が主に用いられる。試行錯誤を伴う場合、主に実機そのものを用いてデータを取得することになる。試行錯誤の回数を減らし、機器を故障から守る手段を用意することが必要である。そのため、設定するパラメータ数が少なく、実機を動かした後に、その動きを評価する指標が事前に作り込まれている必要がある。これらの取組みを2章で述べる。

一方、シミュレータが用意できる場合、シミュレータ上で様々な動きの再現が可能になる。そのため、調整するパラメータ数が大きい場合、入力次元が多い場合、出力を時系列的に扱う場合などにも使用できる。ただし、膨大な計

算時間を使えることを前提にしているが、実用上は計算時間に制約がかかるため計算時間の短縮が求められる。これらの取組み事例を3章で述べる。

2. 機器で取得したデータを用いるAI

2.1 AIスマート起動

シミュレータを用いず、実機そのものを用いて未知の最適な制御方法を学習する場合には、試行錯誤の回数を減らす必要がある。この実現には様々な方法が存在するが、一つには機器や制御対象の環境に由来する知見を用いて、学習データ数を増やしてしまう方法がある。図1に示す空調機器の予冷・予熱運転のための最適な起動時刻の学習部分がそれに当たる。この最適な起動時刻の自動設定機能“AIスマート起動”では、数日分(数回分)の起動時の実運転データ及びそこから増やしたデータを用いて、空調機器の使用環境の特性を学習させる。これを用いて、システムを立ち上げた数日間は、得られた数少ない実データから最適な起動時間を決定する。一方、実データが十分にたまつてると、実データだけをそのまま用いて学習し、最適な起動時間を決定する。Maisartのこのような工夫によって、試験設備で、学習開始から3日分(3回分)のデータで、適切な起動時間を予測できるようになった。当社ビル用マルチエアコンの最上位モデル“グランマルチ”に接続することで、この機能を活用できる空調冷熱総合管理システム“AE-200J”は2020年7月中旬に発売予定である。

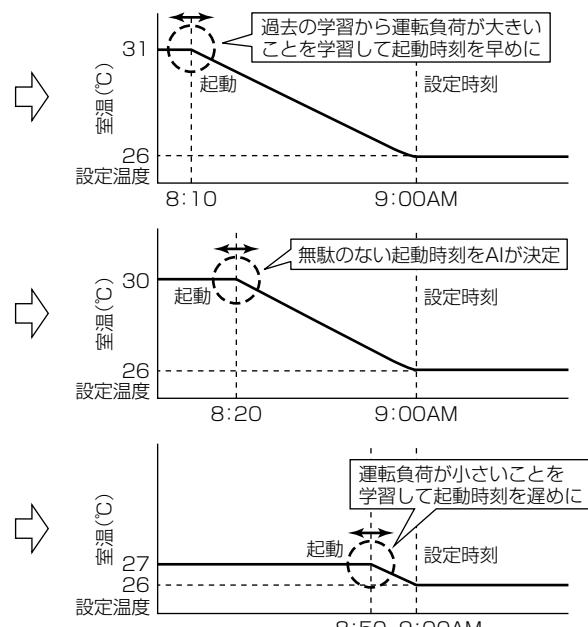
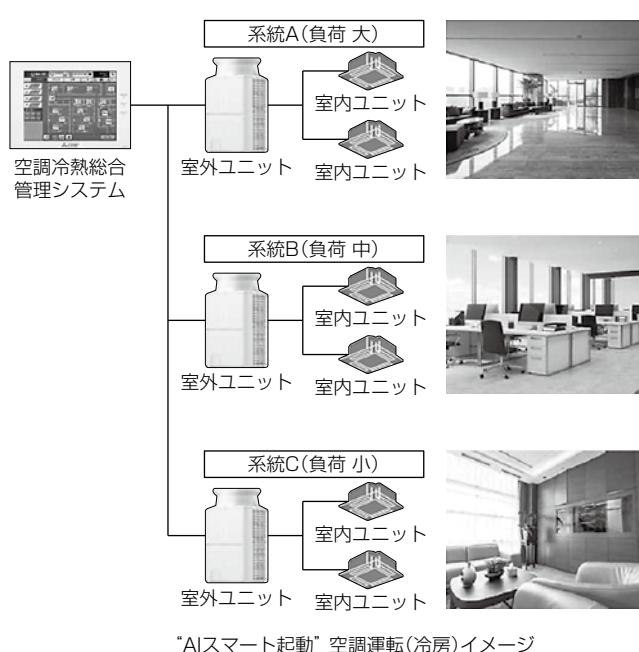


図1. Maisartによって最適な起動時刻を自動的に決定する“AIスマート起動”

2.2 力覚制御パラメータの自動調整

熟練技術者が“機器の知見”を豊富に持つ場合、重要な制御パラメータを特定し、実機での試行錯誤を経て調整が可能である。図2に示す産業用ロボットに部品の挿入動作を行わせる事例で、当社は、ロボットの制御パラメータ調整に関わる“機器の知見”に基づいて自動調整するMaisartを開発した。Maisartによって自動的に速度パターンや力覚制御パラメータが短時間の試行錯誤によって調整され、ある実験条件ではコネクタ挿入作業のタクトタイムを従来比60%削減できた。一般に、挿入作業を高精度にシミュレータ上で再現することは難しいため、シミュレータによるパラメータ調整は非常に困難である。そのため、実機を用いたパラメータ調整作業が必要になるが、この開発手法では少ない試行錯誤での自動調整を実現している。これらの機能は、当社産業用ロボット“MELFA FRシリーズ”的機能拡張オプション“MELFA Smart Plus”で“力覚センサ拡張機能”を有効化することで使用できる⁽¹⁾。

2.3 サーボシステムの制御パラメータ調整

機器や環境の特性上、取得データから機器特性の予測が難しい場合には、先に述べた手法は使えない。このような場合には、ペイズ最適化などの勾配情報を必要としない最適化手法が有効である。ペイズ最適化は、過去の試行結果からパラメータに対応した評価値の応答曲面を予測し、最適だと予測されるパラメータを試行する手法である。ここで評価値とは、機器の性能などの試行したパラメータに対する良し悪(あ)しを数値化したものである。図3はサーボモータを用いた位置決め制御システムを示している。この課題では、できる限り早く目標位置にヘッドを移動させたい一方で、振動を一定のしきい値以内に抑える必要がある。この例では、振動と位置決め時間を基に評価指標を定義し、ペイズ最適化を用いて最適な制御パラメータを求めている。その結果、今回の実験例では、従来であれば熟練技術者が1週間程度を要していた制御パラメータの調整が、1日程度で達成できるようになった。また、位置決め時間を最

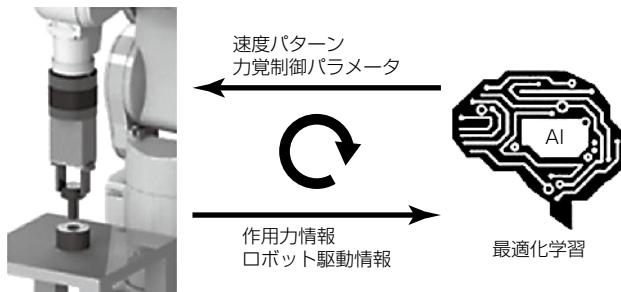


図2. ロボット力覚制御パラメータの自動調整

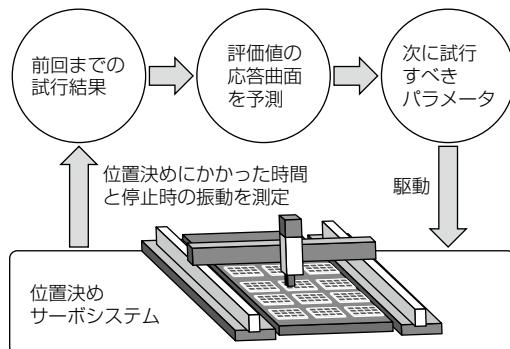


図3. AI位置決めサーボシステムの制御パラメータ調整

大20%短縮できた。このような課題を解く上で重要な点は、実機で動かす以上、試行錯誤的な動作を行える回数は非常に限られている点である。後述する深層強化学習などは、膨大な試行錯誤数が必要になるため、シミュレータを用いて実機で実現することは極めて困難である。今回のような実機による試行錯誤を行うためには、決定する制御パラメータの次元数を抑える(例: 10次元以下)などの工夫が必要である。

3. シミュレータを利用した学習

3.1 ロボット軌道の最適化

シミュレータが存在する場合、シミュレータ上で多量の試行錯誤が可能になる。ただし、シミュレーション時間が無制限に確保できるというわけではない。多くの場合、現状行われている人手による設計時間との対比になる場合が多く、アルゴリズムとして計算時間の短縮が重要な要素になる。図4に示す課題は、障害物が存在する状況でロボットアームを障害物と干渉することなく、最適な軌道を生成する課題である。この課題では、人手で軌道を設定する場

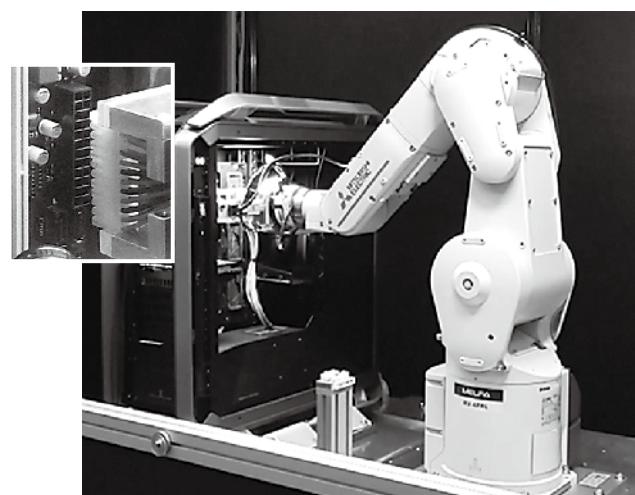


図4. 6自由度ロボットを用いた干渉回避タスク

合、通常約2日(15時間)程度の時間を要する。自動化によるエンジニアリングコスト削減のため1.5時間目標時間と設定してアルゴリズムを開発した。

今回開発したアルゴリズムは、課題を段階的に分けることで計算時間を短縮している⁽²⁾。大きく二段階に分けている。第1段階ではRRT(Rapidly-exploring Random Tree)という経路を算出するアルゴリズムを用いて参照軌道を算出している。RRTは最適な経路の保証、また速度や加速度などを考慮しないが、高速に解を算出できる。第2段階ではこの第1段階の経路に近い軌跡をたどり、タクトタイムが短く、加減速がロボットの物理的特性の範囲内に入るような軌道を生成する。このアルゴリズムによって、第1段階では1.00秒かかっていた動作が、0.44秒にまで短縮されている。また、計算時間は、今回の課題に対して目標である1.5時間以内に収めることができるとある。ちなみに、このような工夫を凝らさずに強化学習を事前に行った場合、72時間の計算でも解を算出できなかった。

3.2 人の作業の模倣

3.1節では強化学習の実例について述べたが、この節では逆強化学習を用いた実例について述べる。強化学習を用いるためには報酬関数と呼ばれる行動結果の良好度合いを定量化した関数が必要であるが、その報酬関数の設計が非常に困難な場合がある。例として、自動車の運転を考えた場合、前の車と適切な車間を取り、急ぎ過ぎず、他の交通参加者への安全に配慮しながら運転をするのが好ましい運転であると考えられるが、これを表現した報酬関数の設計は極めて困難である。“お手本となる動きは存在するが、評価関数が設定しきれない”といった状況下で現在注目されているのが逆強化学習といわれる手法である。

この節では、AGVと呼ばれる工場内で走行する無人搬送車を対象に、人のような運転を学習させる技術を述べる⁽³⁾。現状では、無人搬送車は設計者によって、防護範囲の設定、防護範囲に障害物を検知した場合の動作などの制御ルールをあらかじめ設計している。逆強化学習では、人がAGVを運転したとき、その運転データから人の考える報酬関数を推定することで、人のような動作を模倣することを可能にする手法である。図5に表示されたタスクに対し、人が操作したログデータを用いて逆強化学習でAGVに学習させた。その結果、従来であれば人手によって設計した制御ルールをAIがログデータから獲得することで、AGVとフォークリフトの経路干渉の機会が減り、テストシステム全体で30%程度の作業効率の改善ができた。

教師あり学習もこれを実現できるが、教師用のデータを

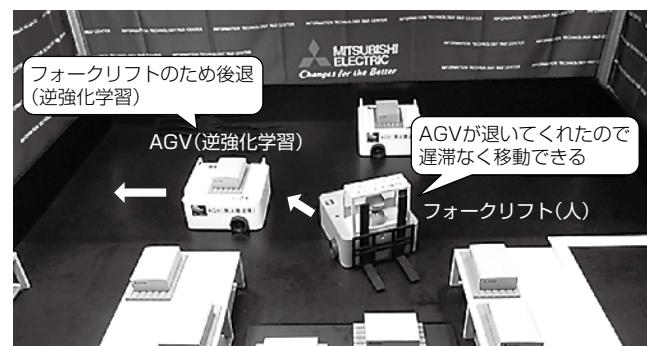


図5. 逆強化学習の応用例(人の協調動作)

大量に用意する必要が出てくる。教師あり学習は発生し得る状況のデータを収集し尽くし、制御の最中に発生する制御誤差が発生した場合の補正用のデータを準備する必要がある。逆強化学習は、推定した報酬関数に基づいてシミュレータ上で試行錯誤することで、上記課題を回避する特性がある。先の例で評価した場合、教師あり学習と比較して1/2~1/10程度のデータでより良い性能が得られている。このように、報酬関数が設計しづらい一方、教師となるログデータが存在し、シミュレータが利用できる場合には、ログデータのルールを自動的に獲得する逆強化学習も今後有力な選択肢になっていく。

4. むすび

制御分野でのMaisartの開発事例をユースケースとして紹介し、課題に合わせたAIの選定方法を述べた。本稿では触れてはいないが、開発の現場では、今回述べたようなシミュレーションなどの機上検討の前にサンプルデータによるデータ解析、シミュレーション後の実機検証試験に非常に多くの時間を費やしている。どのステージも重要であり、検証を重ねる必要がある点を付け加える。

今後、AIの制御分野進出に関しては、シミュレーションと実環境との差、AIの信頼性、品質保証、説明性といった課題が数多くあり、これらを解決していくことがAIの成功の鍵を握っていると考えられる。

参 考 文 献

- (1) 三菱電機産業用ロボット機能拡張オプションMELFA Smart Plus <https://www.mitsubishielectric.co.jp/fa/products/rbt/robot/pmerit/msp/forcecensor.html>
- (2) Ota K., et.al.: Trajectory optimization for unknown constrained systems using reinforcement learning, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 3487~3494 (2019)
- (3) Matsunaga S., et.al.: Learning to Drive via Generative Adversarial Imitation Learning with Top-down View, IROS. IEEE (submitted)

作業分析ソリューション“骨紋”

"KOTSUMON" : Solution for Work Analysis

奥村誠司*

Seiji Okumura

五味田 啓*

Kei Gomita

草野勝大*

Katsuhiko Kusano

櫻井智史†

Satoshi Sakurai

清水尚吾*

Shogo Shimizu

要旨

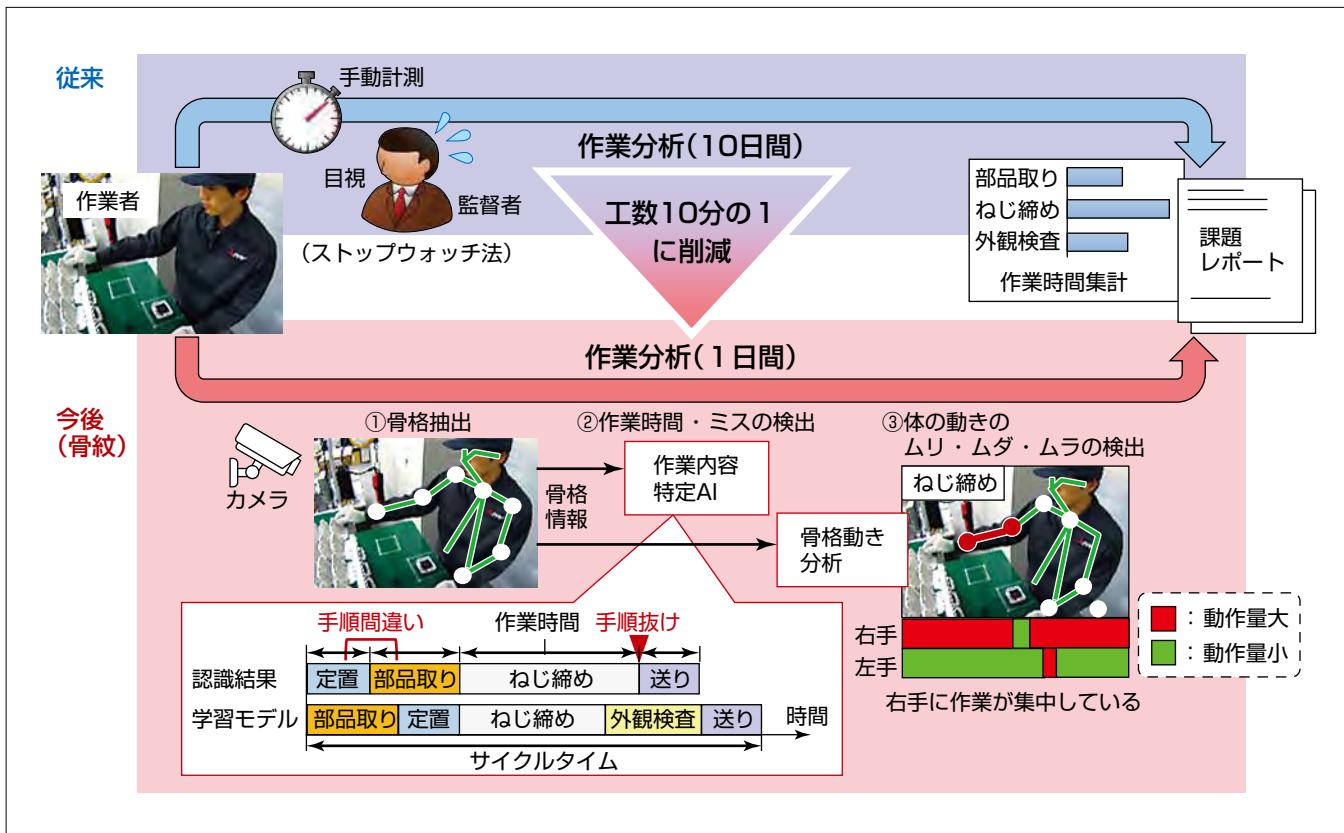
製造現場では、人手作業の生産性を改善するために、作業時間のばらつき、作業ミス、ムダな動作などの問題点を抽出している。しかし、監督者が目視で作業時間の計測や作業ミス・ムダの有無確認を行っていたため、問題点の抽出に膨大な時間を要していた。また、監督者の経験の差によって抽出する問題点にばらつきがあった。

そこで、三菱電機は独自のAI(Artificial Intelligence)技術“Maisart”による作業分析ソリューション“骨紋”を開発した。骨紋はカメラ映像から抽出した作業者の骨格情報を分析することで、作業時間の計測やムダな動作の検出を

自動化し、問題点の見える化を行う。作業時間の計測では、骨格情報からAIで作業手順を認識し、作業時間を計測する。ムダな動作の検出では、“動作経済の原則”に従って骨格情報を評価し、効率的な作業ができているかという観点でムダな動作を検出する。問題点の見える化では、作業時間のばらつきやムダな動作の可視化によって、監督者の経験に依存しない問題点の抽出を可能にした。

これによって、監督者の作業分析の工数を10分の1に削減するとともに、問題点の抽出のばらつきを抑制した。

今後は、実用化に向け、当社工場で検証を重ねていく。



作業分析ソリューション“骨紋”的イメージ

カメラ映像から抽出した骨格情報で動作を特定する作業内容特定AIによって作業手順を認識し、作業時間の計測と作業ミスの検出を行う。また、骨格動き分析によって体の動きのムリ・ムダ・ムラを検出できる。1日分の作業を分析する場合、従来10日間かかっていた作業分析の工数が、“骨紋”を適用することで1日までに削減できる。また、監督者の経験の差によって生じる問題点の抽出のばらつきを抑えることができる。

1. まえがき

近年、労働者人口の減少を背景に製造現場ではロボットによる作業の自動化が進んでいるが、依然として人手作業が多く存在している。人手作業は複雑な作業が可能である反面、作業者ごとの熟練度に依存して作業時間や品質にはばらつきが生じやすく、生産ラインでのボトルネックになりやすい。人手作業の生産性を改善するための取組みとして、従来は監督者が目視で作業を確認して作業時間を手動計測するストップウォッチ法が主流であった。しかし、監督者の負担が大きいことや、計測に膨大な時間・工数を要することが課題であった。さらに、監督者の経験の差によって抽出する問題点がばらつくことも課題であった。この課題に対して、当社はAI技術Maisartを用いた作業分析ソリューション“骨紋”を開発した。

本稿では、骨紋の仕組みや、検証結果と今後の展望について述べる。

2. 作業分析ソリューション“骨紋”的仕組み

作業分析ソリューション“骨紋”は、カメラ映像から抽出した作業者の骨格情報をAIで分析することで、作業時間の計測や作業ミス・ムダ動作の検出を自動化する。これによって、当社工場での検証では、作業分析の工数を10分の1に削減できた。“骨紋”を製造現場に適用することで、常時計測が可能になるため、問題点の抽出で、見逃しがなくなるだけでなく、工程改善のポイントを定量的に把握できる。“骨紋”は“作業時間・手順分析技術”と“分析結果見える化技術”で構成されており、これらの技術によって作業分析の業務を省力化するとともに、監督者の経験の差によって生じる問題点の抽出のばらつきを抑制する。

2.1 作業時間・手順分析技術

作業時間・手順分析技術は、カメラ映像から抽出した作業者の骨格情報をAIで分析し、作業時間や手順を出力する。この技術は“作業内容特定AIの構築”“作業認識”“作業時間計測・手順分析”的三つの処理で構成される(図1)。

2.1.1 作業内容特定AIの構築

作業内容特定AIは骨格情報から作業を認識するAIである。学習用の映像から骨格情報を抽出し、その骨格情報を作業ごとに学習して作業内容特定AIを構築する。製造現場では、作業手順単位で作業を認識することが多く、作業手順ごとに骨格情報を学習させることで、現在の作業がどの作業手順なのかを認識する作業内容特定AIを構築できる。

通常、AIで動作認識する場合、数千から数万規模の学習サンプルが必要であるが、骨格情報は人の動きを最もよく表す特徴量であるため、“骨紋”では10サンプル程度の骨格情報で認識できる。

2.1.2 作業認識

分析用の映像から抽出した骨格情報を作業内容特定AIに入力することで、作業者がどの作業手順を行っているか認識する。作業内容特定AIの構築時に、作業者の体格差を吸収できるように骨格情報を加工して学習させているため、作業手順が同じであれば、学習用と分析用の映像の作業者が異なる場合でも作業認識が可能である。

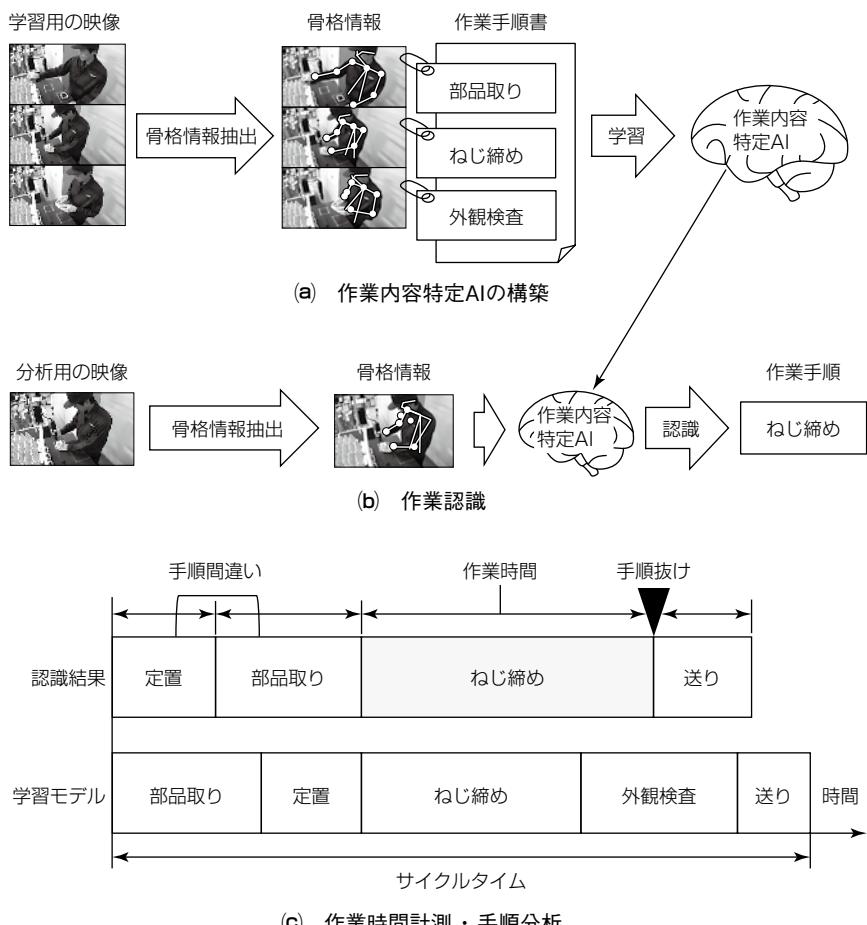


図1. 作業時間・手順分析技術

2.1.3 作業時間計測・手順分析

作業認識の結果を基に、同一の作業手順が連續した時間の長さから作業時間を計測する。各作業時間を合計したものがサイクルタイムとなる。また、作業認識の結果と学習モデルの作業手順を比較することで、手順間違いや手順抜けを検出する。しかし、異なる作業でも動作が類似していると、作業内容特定AIが間違った作業認識をしてしまう場合があり、作業時間の計測精度が低下する。そこで、学習モデルの作業手順を基に、誤り訂正技術を用いて作業認識結果を補正する。具体的には、作業手順の順番に整合性がとれない箇所を認識誤りとみなし、作業手順の連続性を考慮してもっともらしい作業手順に補正する。これによって、高精度な作業時間計測や手順分析が可能になる。

2.2 分析結果見える化技術

製造現場では、人手作業の生産性を改善するために、現状の様々なデータを計測して問題点を抽出し、改善方法を検討する。現状を計測する手法はメソッドメジャーメントと呼ばれ⁽¹⁾、主に工程分析、作業分析、時間分析、動作分析に分けられる。これらの中で、2.1節で述べた作業時間・手順分析の結果や骨格情報などのデータは、時間分析と動作分析に活用できる。

この節では、時間分析、動作分析のための見える化について述べる。

2.2.1 時間分析のための見える化

時間分析は、作業時間が標準より長い／短い作業や、ばらつきの大きい作業を特定する手法であり、作業時間・手順分析の結果から算出した平均値とばらつきを見える化することで、特定を容易化できる。

作業時間・手順分析技術は、作業手順単位で分析できるため、この見える化では、作業手順単位及びサイクル単位で平均値と標準偏差(ばらつき)を算出し、図2(a)のように棒グラフなどで表示する。また、問題になるサイクルを直感的に把握できるよう、全サイクルの時間を棒グラフで表示する(図2(b))。さらに、監督者が問題になり得るサイクルや作業手順を確認できるように、指定したサイクルの映像を表示する(図2(c))。

2.2.2 動作分析のための見える化

動作分析は、作業の動作を細かくとらえてムリ・ムダ・ムラを特定するための手法であり、代表的な手法として、動作経済の原則、サーブリック分析、PTS(Predetermined Time Standard)法などがある。これらのうち、動

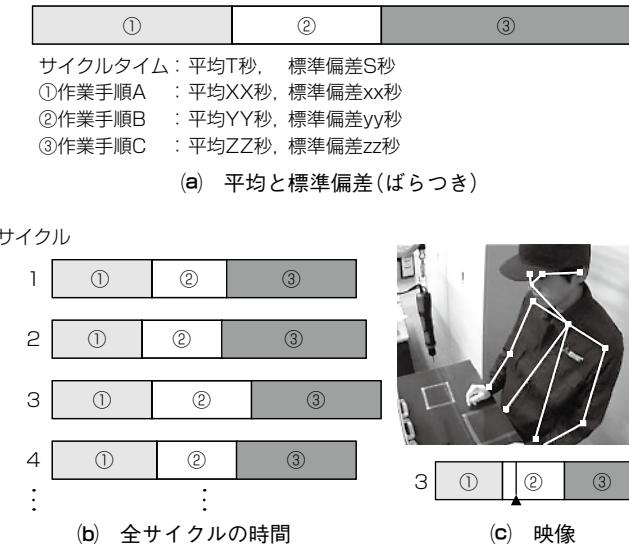


図2. 時間分析向けの見える化イメージ

作経の原則を用いた手法には、作業者の身体動作に着目した手法がある。そこで、骨格情報の分析にこの手法を適用し、ムリ・ムダ・ムラの見える化を行う。

動作経済の原則は、“動作能活用の原則”“動作量節約の原則”“動作法改善の原則”的三つの基本原則と、それらを具体化するための改善着眼で成り立っている。改善着眼には様々なものがあるが、身体動作に関するものとして、“不必要的動作を排除せよ”“動作は最適最低次の身体部位(末端部位)で行え”“作業域は作業に支障のない限り狭くせよ”がある。作業域とは、作業中に手先が動く範囲である。これらの改善着眼から、指先だけの動作で済むほど効率的な作業動作であり、逆に、肘、肩、上体、腰、体全体と、末端から離れた箇所が動く作業動作はムダがある可能性が高い。

この見える化では、これらの改善着眼を見やすくするために、上半身の左右それぞれで、肘・肩が動いていない(手首から先だけが動いている)時間帯、肘が動いている時間帯、肩が動いている時間帯を骨格情報から検出し、映像のタイムラインを時間帯で動作量に応じて色分けして表示する。図3(a)に色分けしたタイムラインのイメージを示す。

また、改善着眼にはほかにも“作業には両手を使用し、かつ両手は同時に動かし始め、同時に終われ”“両手は同時に、対称方向に動かせ”“休憩時間以外に手を休めてはならない”がある。これらの改善着眼を見やすくするために、手首が動いている時間帯と動いていない時間帯を検出し、映像のタイムラインをそれら時間帯で色分けして表示する。図3(b)に色分けしたタイムラインのイメージを示す。

一方で、動作の大きさや動作の有無をタイムライン上に見える化した場合、実際にどの程度大きい動作をしているか確認できるように、動作の範囲を静止画で空間的に表示する。具体的には、手首関節の移動軌跡を矢印で表現し、

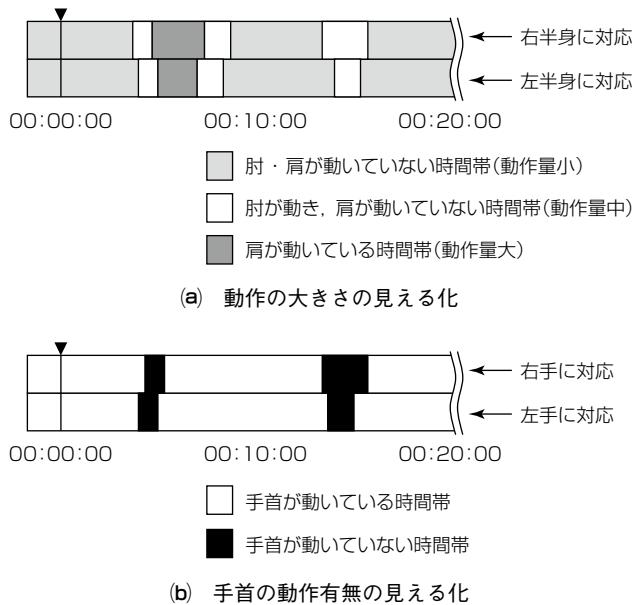


図3. タイムライン上での動作の見える化イメージ



図4. 静止画での動作の見える化イメージ

合わせて軌跡の長さを色で表現する。図4に、手首の移動軌跡を静止画で見える化した例を示す。

3. 作業時間の計測精度の検証

“骨紋”的有効性を確認するため、セル生産方式の製品組立て工程を模擬した環境でサイクルタイム計測精度を検証した。学習用と分析用の映像で作業者が異なる場合でも分析ができる事を確認するために、作業者5人について映像を撮影した。作業は九つの手順で構成される製品組立て作業であり、平均的なサイクルタイムは約50秒である。学習用の映像は1人分とし、学習サンプルは最大10サイ

表1. 検証条件

大項目	小項目	内容
検証工程	作業内容	組立て工程
	サイクルタイム	約50秒
	作業者	作業者A～E(5人)
	作業手順数	9
撮影条件	解像度	1920×1080(フルHD)
	フレームレート	30fps
	ピットレート	5 Mbps
	映像長さ	約15分／人
検証条件	学習人数	1人分
	学習サンプル数	5～10サイクル

HD : High Definition

表2. 検証結果(サイクルタイム平均誤差)

分析	A	B	C	D	E
A	0.09 (0.17)	0.34 (0.77)	0.04 (0.07)	0.48 (0.83)	0.92 (2.60)
	0.19 (0.40)	0.37 (1.03)	0.10 (0.20)	0.41 (0.60)	0.62 (1.20)
C	0.09 (0.23)	0.33 (0.87)	0.07 (0.17)	0.69 (0.90)	2.26 (3.73)
	0.39 (1.03)	0.48 (1.10)	0.14 (0.17)	0.11 (0.20)	0.84 (2.17)
E	0.24 (0.50)	0.48 (1.50)	0.19 (0.50)	0.28 (0.53)	0.63 (1.27)
	単位:秒, ()内の数値は最大誤差を表す				

クルにした。その他、詳細な検証条件を表1に示す。

検証結果(サイクルタイム平均誤差)を表2に示す。全体の平均誤差は0.43秒と小さく良好であった。しかし、作業者Eでは誤差が大きく、最大で3.73秒であった。作業者Eが作業に慣れておらず他の作業者と動作に違いがあったためと考えられる。

4. む　す　び

製造現場での作業分析の業務省力化を実現する作業分析ソリューション“骨紋”を開発した。

検証の結果、実用的な精度で作業時間を抽出でき、作業時間のばらつきが大きい作業の特定が可能になった。また、動作分析向けの見える化によってムダな動作の特定が容易になった。

これによって、従来10日間かかっていた作業分析の工数を10分の1の1日間に削減した。また、監督者の経験の差に依存しない問題点の抽出が可能になった。

今後は、実用化に向け、当社工場で検証を重ねていく。

参 考 文 献

- (1) 吉本一穂, ほか: メソッドエンジニアリング, 朝倉書店 (2001)

グラフ推定によるレンジドップラーマップ上の異種クラッタ領域検出技術

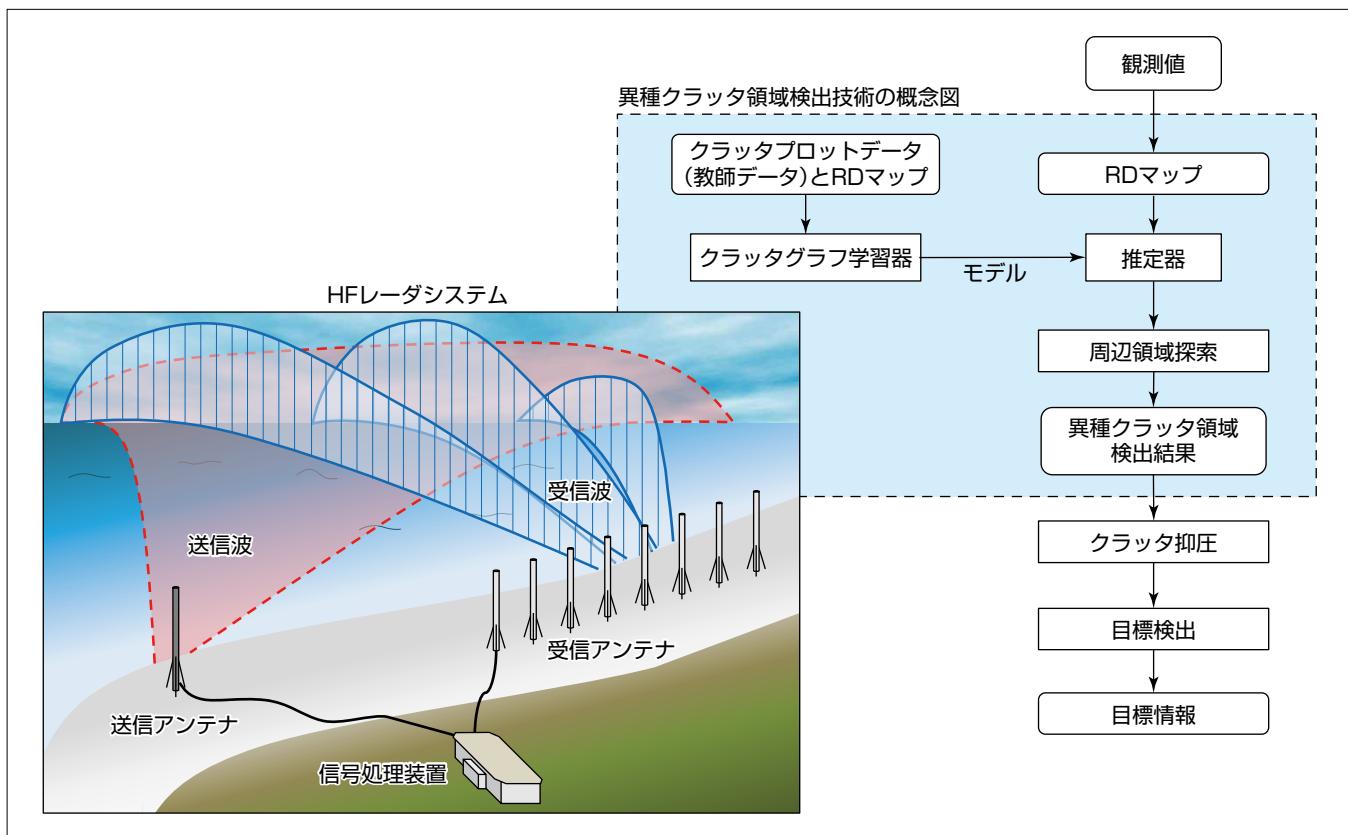
Graph-based Instance Segmentation Technique for Heterogenous Clutter on Range-doppler Map

谷高竜馬*
Ryoma Yataka
平嶋一貴*
Kazuki Hirashima
白石 將*
Masashi Shiraishi

要旨

短波(High Frequency : HF)レーダによる観測信号を処理して得られるレンジドッpler(Range-Doppler : RD)マップには、検出対象である目標のほかに海波や電離層等のクラッタが含まれる。従来クラッタへの対処として一定誤警報確率(Constant False Alarm Rate : CFAR)処理によるクラッタ抑圧が適用されているが、性質の異なる複数種類のクラッタが混在する状況では高精度な目標検出が困難という課題があった。このような状況でも高精度な目標検出器を構築するためには、あらかじめRDマップ内のクラッタ領域及び種別を推定し、クラッタ種別に応じて適切な抑圧を行うことが有効と考えられる。そこで、クラッタ抑圧の前処理として、一般物体検出等で高い性能が報告されているCNN(Convolutional Neural Networks)を応

用したセグメンテーション(領域分割)方式を開発した。一般的にセグメンテーションを実現するためには領域分割された教師データが必要であるが、クラッタ領域の境界は曖昧であるためアノテーションが困難である。この課題に対して開発方式では、CFARで誤検出したプロットからクラッタ領域ごとに生成したグラフを教師データとしてCNNを学習し、学習済みのCNNで推定したプロットの周辺領域を探索することでセグメンテーションを実現する。これによって、領域分割された教師データを用意することなくセグメンテーションが可能になる。評価実験を行い、各種クラッタの領域を種別及び詳細な境界として推定できることを確認した。



グラフ推定によるRDマップ上の異種クラッタ領域検出技術

HFレーダは海面に電波を送信する送信アンテナと、目標で反射した電波を受信する受信アンテナ及び受信した信号を解析する信号処理装置で構成される。異種クラッタ領域検出技術はシークラッタや電離層クラッタ等の不要波を誤検出したデータを基にクラッタプロットを表現するグラフを学習することで、クラッタプロットを検出し、さらにその周辺領域の探索を行うことで種別ごとのクラッタ領域の検出を可能にする。

1. まえがき

HF(3-30MHz)レーダは、表面回折伝搬のメカニズムに基づき動作するレーダであり、高周波電波を送信してその反射エコー(ドップラーエコー)を受信する。HFレーダの受信信号を解析することで、50km以遠の海の表層の流況(流向・流速)や船舶、低空飛行物体等の目標情報を取得可能なため、広範囲にわたる海の継続的な状態監視や不審船の検出のために広く利用されている。

一方で、クラッタ(シークラッタや電離層クラッタ等)は、HFレーダの目標検出性能を低下させる要因として知られており、目標検出を行う前にクラッタ抑圧を適用することが一般的である。クラッタを抑圧する主な技術として、HFレーダで観測した信号を処理することで得られるRDマップに対して施すPost-Doppler型の手法が研究されている。例えば、CFARを用いることで、クラッタを抑圧しつつ、目標検出を行うことができる。しかし、シークラッタや電離層クラッタ等の、性質の異なる複数種類のクラッタが混在する状況では、それら全てのクラッタをCFARだけの適用によって適切に抑圧することは困難であり、目標検出での誤警報確率が高くなるという問題があった。複数種類のクラッタが混在する状況でも高性能な目標検出器を構築するためには、あらかじめRDマップ内のクラッタごとにその領域と種別を推定した上で、クラッタ種別に応じて適切な抑圧手法を適用することが有効である。

本稿ではRDマップの目標検出で、クラッタ抑圧の前処理として適用するクラッタ検出技術について検討した結果を述べる。

2. CFARを用いたRDマップの信号解析

2.1 RDマップ

RDマップは、目標からの反射波を距離(レンジ)と速度(ドップラー)で表した二次元マップである。シークラッタや電離層クラッタ等はこのRDマップ上に高い信号電力値を持って分布しており、シークラッタはレンジ方向、電離層クラッタはドップラー方向に広がって分布する。これらの分布は天候や時間帯によって不規則に変化することしばしば目標信号が埋もれてしまうため、これを避けるためにクラッタ抑圧を行う必要がある。

2.1.1 CFAR

RDマップ上でクラッタを抑圧して目標だけを検出する一般的な方法として、クラッタの誤検出を一定に保ちながら

検出を行うCFARがある。CFARはリファレンスセルと呼ばれる分解能セル領域の統計量からRDマップ内の各セルでの信号電力のしきい値を求め、しきい値以上の電力を持つセルを目標として検出する。CFARにはリファレンスセルを含め幾つかのハイパーパラメータがあり、それらの設計方法によって性能が変化する。シークラッタと電離層クラッタの特性は大きく異なるため、例えばRDマップ上でレンジ方向に分布するシークラッタを抑圧する設定を行った場合には、ドップラー方向に分布する電離層クラッタ等の誤警報が増加し、その逆も同様となる。さらに、クラッタは天候や時間帯によっても変化するため、性質の異なるクラッタを抑圧するには、その都度設計をし直す必要があるという問題がある。

3. 開発方式

クラッタに左右されずに汎用性の高い目標検出器を構築するためには、あらかじめRDマップ上に存在するクラッタごとにその領域と種別を推定し、領域ごとに適切なクラッタ抑圧を適用することが有効である。そこで、この研究では近年盛んに研究が行われているCNN⁽¹⁾を応用したクラッタ領域のセグメンテーション方式を開発した。一般的に、セグメンテーションを実現するためには詳細に領域分割された教師データが必要である。しかし、RDマップ上のクラッタ領域は境界が曖昧なため人手によるアノテーションが困難になる。そこで、開発方式では実データでCFARで誤検出したプロットを加工することで各クラッタをクラッタグラフとして表現し、これを教師データとして利用する。クラッタグラフは、単一のクラッタ領域内で誤検出された複数のクラッタプロットを互いに連結させて生成されるグラフである。これによって、詳細に領域分割された教師データを用意することなくセグメンテーション領域を学習することが可能になる。具体的なセグメンテーションの手順を図1に示す。まずRDマップを学習済みのCNNに入力し、RDマップ上の各クラッタ領域のクラッタグラフとその種別を推定する。その後、推定したクラッタグラフごとに、その周辺領域を探索してクラッタ領域(前景)とそれ以外の領域(背景)とに分離する。このような手順によって、RDマップ上のクラッタ領域のセグメンテーションが完了する。

3.1 教師データ用クラッタグラフの生成

開発方式では、CNNで各クラッタのクラッタグラフ(プロット位置とそのつながり方及びその種別)を学習する。しかし、プロットのつながり方には膨大な組合せがあるため、各プロットをランダムに接続した場合には学習が収束

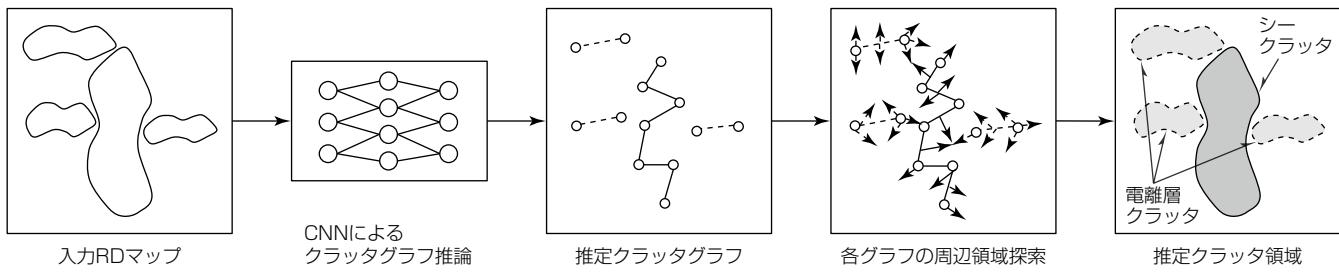
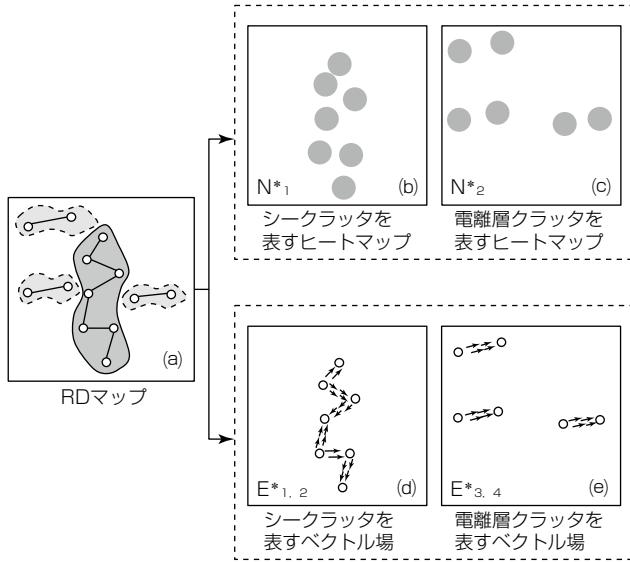


図1. RDマップでの異種クラッタ領域のセグメンテーション方式手順

しないという問題が生じる。よって、適切なつながり方を事前に定義する必要がある。本稿では、教師データに適したクラッタグラフとして、最小全域木に基づくグラフを構築した。最小全域木はグラフ理論における各エッジの重みの総和が最小で、かつ余分なつながりを排除した全域木である。エッジの重みはRDマップの信号電力値に基づいて定義した。**図2(a)**に生成したクラッタグラフの例を示す。このような最小全域木を用いることで、教師データの生成に規則性が生まれ、ネットワークの学習が容易になる。

3.2 CNNによるクラッタグラフ学習

プロット集合をクラッタグラフとして学習するCNNを構築した。図3に開発方式で用いるCNNのアーキテクチャの概念図を示す。このアーキテクチャは二つの枝で構成されており、一方はRDマップ $\mathbf{X} \in \mathbb{R}^{R \times V}$ を入力してクラッタグラフのノードの位置とその種別を推定するノードネットワーク $\Phi(\mathbf{X})$ 、他方はクラッタグラフのエッジとその種別を推定するエッジネットワーク $\psi(\mathbf{X})$ である。 R はレンジ方向のセル数、 V はドップラー方向のセル数を表す。各ネットワークは、次の式で定義された損失関数 f を最小



— クラッタグラフのエッジ

図2. クラッタグラフ及び正解特徴マップ

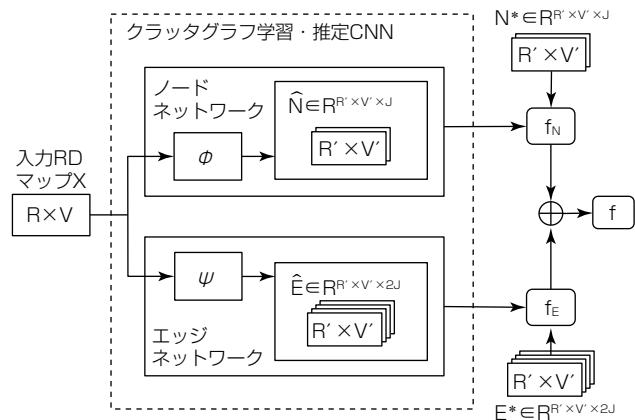


図3. 開発方式で用いるCNNアーキテクチャ

化することで最適化する。

$$f=f_N+f_E \quad \dots \quad (1)$$

$$f_N = \sum_{j=1}^J \sum_{\mathbf{p}} \| \hat{\mathbf{N}}_j(\mathbf{p}) - \mathbf{N}_j^*(\mathbf{p}) \|_2^2. \dots \quad (2)$$

$$f_{\mathbf{E}} = \sum_{i=1}^{2J} \sum_{\mathbf{p}} \| \hat{\mathbf{E}}_j(\mathbf{p}) - \mathbf{E}_j^*(\mathbf{p}) \|_2^2 \dots \dots \dots \quad (3)$$

ここで、 J はクラッタの種別数($J=2$)、 $\hat{\mathbf{N}} \in R^{R' \times V'}$ はノードネットワーク $\varPhi(\mathbf{X})$ の J 枚ある推定特徴マップの j 枚目、 $\hat{\mathbf{E}}_j \in R^{R' \times V'}$ はエッジネットワーク $\psi(X)$ の $2J$ 枚ある推定特徴マップの j 枚目である。 \mathbf{p} はその特徴マップ内の位置を表す。また、 $\mathbf{N}^*{}_j$ 及び $\mathbf{E}^*{}_j$ は対応する正解特徴マップを表しており、クラッタの種別ごとに正解となる値が割り当てられている。ここで、教師データであるクラッタグラフのエッジは、3.1節で述べたとおり最小全域木として構築されるが、それらのノードの位置は、CFAR のハイパーパラメータの設定に依存する。そのため、ノードの位置は分散が大きくて正解が一意に定まらないという問題が生じる。これを解決するために、 $\mathbf{N}^*{}_j$ はクラッタグラフの各ノードを 1 点ではなく、これらを頂点とする分散 σ の二次元混合ガウス分布とし、 $\mathbf{E}^*{}_j$ は各エッジ上の信号電力に基づいて生成されるベクトル場として設計した(図 2(b)～(e))。これによって、CFAR のパラメータ等に大きく依存しない学習を可能にした。

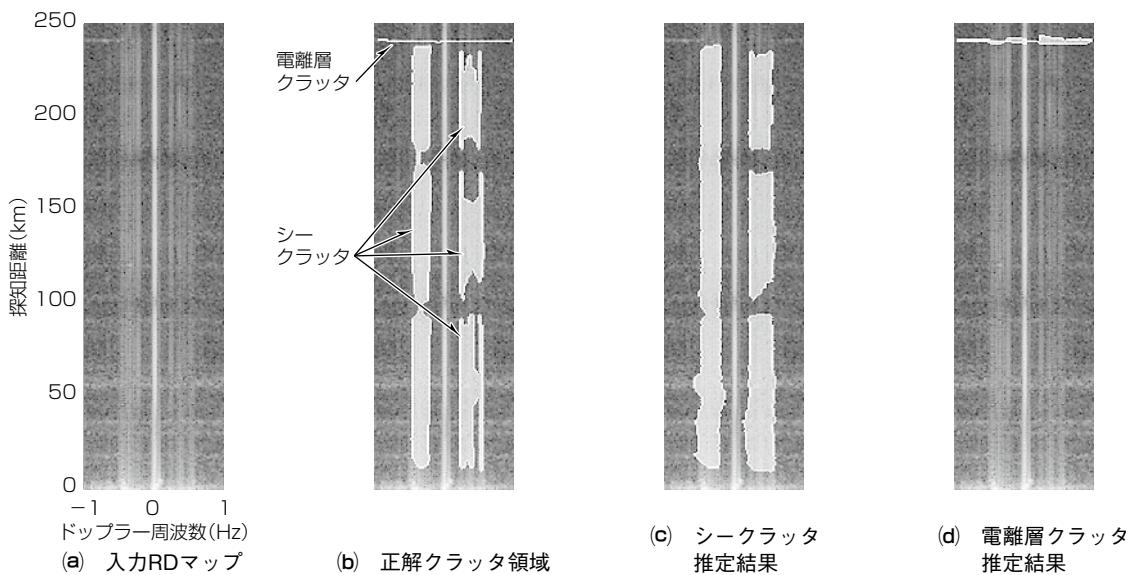


図4. 開発方式によるRDマップ上のシークラッタ及び電離層クラッタのセグメンテーション結果

3.3 推定プロット集合の周辺領域探索による領域セグメンテーション

推定したクラッタグラフごとに、その周辺領域の探索を行うことで、RDマップ上で各クラッタ領域の詳細なセグメンテーションを行う。この研究では、周辺領域の探索の方法としてグラフカット⁽²⁾を用いた。グラフカットはあらかじめ大まかに指定した前景領域と背景領域を基準として、それらの境界を求めるための最小切断問題を解くアルゴリズムである。開発方式では、CNNで推定したクラッタグラフを前景領域として、前景領域と一定の距離d以上離れた領域を背景領域として設定した上で、グラフカットを適用した。

4. 評価実験

開発方式の有効性を示すための評価実験について述べる。実験で使用したデータは、国土交通省の海洋レーダーを用いて東京湾の横浜大黒埠頭(ふとう)局から発せられている反射波を受信して得た信号である。表1に実験で用いたHFレーダーの諸元を示す。教師データ生成時のCFARは、クラッタに複素ガウス分布を仮定するCA-CFAR(Cell-Averaging CFAR)を用いた。また、ノード・エッジネットワークはそれぞれ5層のCNNで構築し、学習時のエポック数を50とした。データセットとして $R=512$, $V=100$ のRDマップを1,000枚用意し、これを学習用データと評価用データに9:1の割合で分割した。正解特徴マップ生成時の分散を $\sigma = 1$ 、領域探索時の距離を $d = 10$ とした。また、評価指標として、各データの領域推定結果と正解データとの重なり度合いを評価するmIoU(mean Intersection over Union)を用いた。この指標は[0, 1]の範囲で1に近いほど高精度であることを表す。

表1. レーダの諸元

項目	値
最大探知距離(km)	250
ドップラー周波数(Hz)	[-1, 1]
チャーブ信号のスイープ幅(kHz)	100

表2. セグメンテーション評価結果

指標	シークラッタ	電離層クラッタ	平均
mIoU	0.906	0.751	0.829

over Union)を用いた。この指標は[0, 1]の範囲で1に近いほど高精度であることを表す。

表2にmIoUの評価結果を示す。この結果からどちらのクラッタも高精度に領域推定ができていることが確認できる。また、図4にセグメンテーションの可視化結果の一例を示す。各推定結果から、RDマップ内のクラッタ領域をクラスごとに正しく検出できることを確認した。また、矩形(くけい)ではなく適切な形で推定可能なことを確認した。

5. むすび

HFレーダーの信号を処理して得られるRDマップ上の異種クラッタのセグメンテーションを行う異種クラッタ領域検出技術について述べた。実験の結果、RDマップ内のシークラッタ及び電離層クラッタの領域をそれぞれ推定可能なことを確認した。

参考文献

- (1) Ian, G., et al.: Deep Learning, The MIT Press (2016)
- (2) Camille, C., et al.: Power Watershed : A Unifying Graph-Based Optimization Framework, IEEE Trans. on Pattern Analysis and Machine Intelligence, 33, No.7, 1384~1399 (2011)

超広帯域デジタル制御GaN増幅器

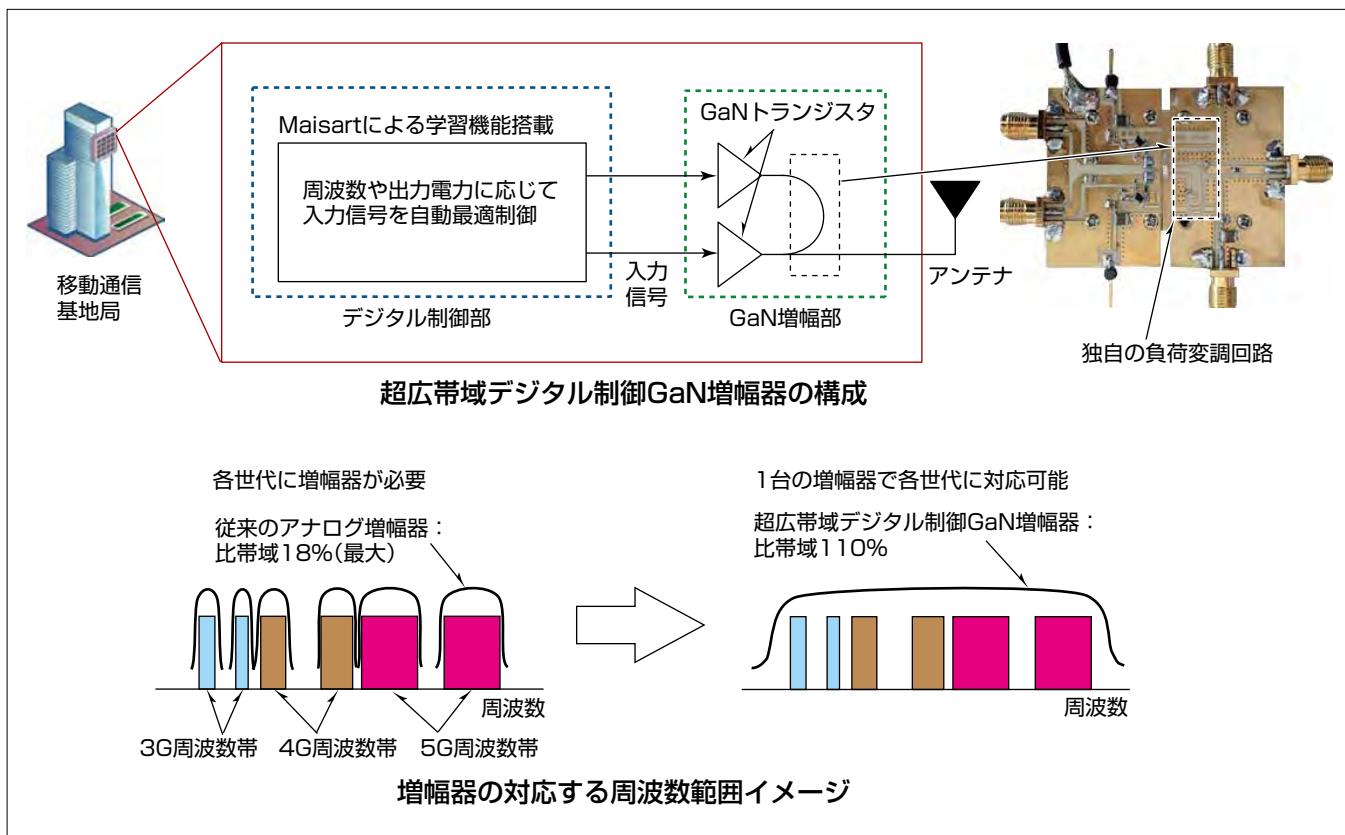
Ultra-Wideband Digitally Controlled GaN Amplifier

小松崎優治*
Yuji Komatsuzaki
新庄真太郎*
Shintaro Shinjo
Rui Ma †
Rui Ma

要旨

多種多様な新しいサービスの提供に向けた第5世代移動通信方式(5G)の円滑な立ち上がり、新たな動作周波数帯の追加や既存の複数周波数帯との併用などによる通信容量の増強を見据えた5Gの次の世代(Beyond 5G)の実現に向け、移動通信基地局を構成するキーコンポーネントの一つであるGaN(窒化ガリウム)増幅器の開発が盛んに行われている。Beyond 5Gでは、第3世代移動通信方式(3G)、第4世代移動通信方式(4G)及び5Gの周波数範囲を一つの移動通信基地局でカバーすることが望まれるとともに、基地局装置の設置性を高めるため低消費電力化が急務になる。GaN増幅器には、複数の周波数帯に対応するための広帯域動作と、低消費電力化のための高効率動作の両立が課題になっている。

今回、アナログGaN増幅部とデジタル制御部を組み合わせた新たな発想の増幅器を開発した。GaN増幅部には二つのGaNトランジスタを並列配置し、広帯域を実現する独自の負荷変調回路を用いて信号を合成することによって、3Gから5Gの主要周波数帯を1台の増幅器でカバーする広帯域動作を実現した。また、デジタル制御部には三菱電機のAI(Artificial Intelligence)技術“Maisart”による学習機能を搭載し、増幅器の動作状態に応じた最適な二つの入力信号の組合せを選択させることで周波数や出力電力に応じた高効率動作を実現した。これによって、従来のアナログ増幅器と比べて6倍となる比帯域110%の周波数範囲で動作効率40%以上を達成した。今後大容量通信化と低消費電力化へ貢献していく。



GaN増幅部とデジタル制御部で構成する超広帯域デジタル制御増幅器

5Gを中心とした複数の周波数帯に1台で対応できる移動通信基地局向け超広帯域デジタル制御GaN増幅器を試作した。この増幅器はGaN増幅部とデジタル制御部を組み合わせた新たな発想の構成を採用し、GaN増幅部には独自の負荷変調回路の適用による広帯域化、デジタル制御部にはMaisartの適用による入力信号の自動最適制御を実現することで、広帯域動作と高効率動作の両立を実現した。

1. まえがき

スマートフォンやタブレットなどの移動通信のトラフィックの増加対策や、多種多様な新しいサービス・アプリケーションの実現に向け、5Gの開発が進められている。また、新たな通信周波数帯の追加や既存の複数周波数帯の併用などによる通信容量の増強を可能にする5Gの次の世代Beyond 5Gや第6世代移動通信方式(6G)の検討も開始された。

基地局装置は、主に信号送受・信号処理部と、信号を増幅する増幅器から構成される。これまで3G、4G、5Gの移動通信基地局ごとに信号送受・信号処理部と増幅器が必要であったが、将来的には各通信世代を一つの基地局で運用することが望まれるであろう。同時に、基地局装置の設置性を高めるために低消費電力化への対策が急務になっている。移動通信基地局の導入から廃棄までを含めたTCO(Total Cost of Ownership: 総保有コスト)の低減もまた重要な課題になる。これらの要求・課題に応えることが要求されるキーコンポーネントの一つがGaN増幅器である。

GaN増幅器には、複数の周波数帯に対応するための広帯域動作と、低消費電力化対策のための高効率動作との両立が課題になる。これまでのアナログで動作する増幅器では、その構成上、広帯域動作と高効率動作の両立には限界があった。そこで、今回、アナログとデジタルを融合させた新たな発想の構成からなるGaN増幅器を提案し、その限界を打ち破ることに挑戦した。

本稿では、アナログで動作するGaN増幅部とデジタル制御部から構成する超広帯域デジタル制御GaN増幅器を示し、その試作結果について述べる。GaN増幅部には二つのGaNトランジスタを並列配置し、広帯域を実現する独自の負荷変調回路を用いて信号を合成する。またデジタル制御部には三菱電機のAI技術Maisartによる学習機能を搭載し、増幅器の動作状態に応じて二つの入力信号を自動最適制御することで周波数や出力電力に応じた高効率動作を実現する。試作の結果、従来の移動通信用高効率増幅器⁽¹⁾と比べて6倍となる比帯域110%の周波数範囲で動作効率40%以上を達成し、この増幅器構成の有効性を確認した。今後、移動通信基地局の大容量通信化と低消費電力化への貢献が期待される。

2. 移動通信基地局用増幅器の技術動向

移動通信のトラフィック量は急激に増大している。これに伴い、移動通信基地局に用いられる増幅器などの高周波デバイスに対する効率、動作帯域幅、動作周波数に対する

要求は年々高まっている。この章では、増幅器の変遷と現在主流になっている構成の特徴を示す⁽²⁾。

2.1 移動通信基地局向け増幅器の変遷

図1に2000年頃に立ち上がった3G、2010年頃に立ち上がった4G、そして5Gの各世代の移動通信基地局向け増幅器に用いられたデバイスや増幅器の構成の変遷を示す。

3G及び更にその前の世代で用いられた通信は、動作周波数は最大2GHz、伝送速度も最大2Mbps程度であった。このため、増幅器に用いられるデバイスはSi(シリコン)系のLDMOS(Laterally Diffused Metal-Oxide-Semiconductor)が主流であった。その後、4G、5Gと世代が上がるにつれ、動作周波数は5GHz程度まで上昇し、伝送速度もギガオーダーまで増加した。このため現在では、高周波帯での動作に優れ、広帯域動作が可能なGaNが増幅器のデバイスとして主に用いられるようになってきている。

他方、3G及び更にその前の世代では、アナログ変調方式やデジタルのFM(Frequency Modulation)変調方式や直交変調方式が用いられていた。このため、増幅器は飽和電力付近での性能が重視されてAB級などのバイアス条件で動作する飽和電力付近での効率特性に優れた線形増幅器が主に用いられていた。現在では64QAM(Quadrature Amplitude Modulation)/OFDM(Orthogonal Frequency Division Multiplexing)変調などのマルチキャリア多重変調方式が用いられるようになり、大きなバックオフ電力(増幅器の最大出力電力と平均出力電力の差。変調信号の最大振幅と平均振幅の差に対応)付近での動作効率が重視されるようになってきており、ドハティ増幅器と呼ばれる構成が移動通信基地局向け増幅器の主流になっている。

2.2 ドハティ増幅器の構成の特徴

ドハティ増幅器とは1936年にW. H. Dohertyによって考案された負荷変調による高効率化技術を用いて構成された増幅器である。一般に増幅器の効率は、バックオフ動作

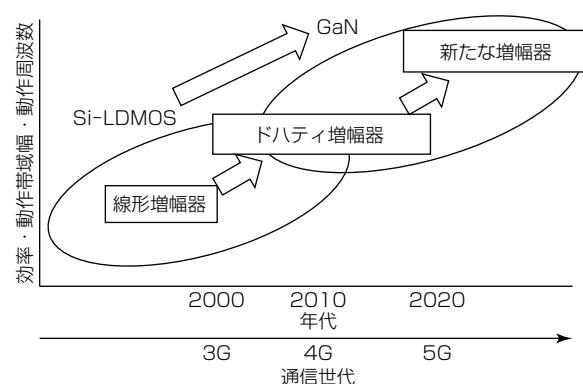


図1. 移動通信基地局向け増幅器の変遷

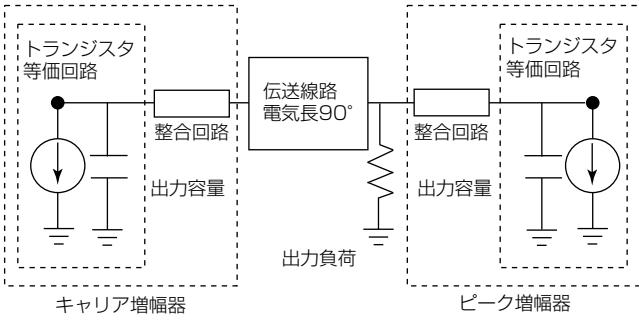


図2. ドハティ増幅器の出力部の構成

時には飽和動作時に比べると大きく低下する。例えばバックオフ10dBの出力電力での効率は、A級増幅器の場合は最大効率の1/10、B級増幅器の場合は $1/\sqrt{10}$ まで低下してしまう。そこでバックオフ時の動作効率を改善するために考案されたのがドハティ増幅器である。

特徴的であるドハティ増幅器の出力部の構成を図2に示す。ドハティ増幅器は、AB級又はB級にバイアスされた増幅器(キャリア増幅器)とC級にバイアスされた増幅器(ピーク増幅器)の二つの増幅器から構成される。キャリア増幅器の出力側には波長の4分の1の長さの線路(電気長90°の伝送線路)が設けられており、ピーク増幅器がオフ状態になる低出力動作時と、ピーク増幅器がオン状態になる高出力動作時で負荷インピーダンス条件を変化させる。この負荷変調を利用してバックオフ動作時の高効率化を実現するのがドハティ増幅器の動作原理である。図2のとおり、ドハティ増幅器は構成上、電気長90°の伝送線路、又はそれに相当する回路が必要になる。しかしながら、伝送線路の電気長は周波数に依存して90°から変化してしまうため、ドハティ増幅器を広帯域にわたって正しく動作させることは困難である。そのため、5G以降の移動通信システムの実現に向けては、ドハティ増幅器にかわる広帯域性と高効率性を両立させる新しい増幅器が望まれている。

3. 超広帯域デジタル制御GaN増幅器

3G、4G、5Gが並存していくこの時代、移動通信基地局の導入から廃棄までを含めたTCOを低減していくためにも、1台の増幅器で各世代の複数の周波数帯に対応できることが望まれている。そのためには、広帯域性と高効率性を兼ね備えた新たな構成の増幅器の開発が必要になると考えている。

3.1 アナログとデジタルを融合させた増幅器構成⁽³⁾

今回開発した超広帯域デジタル制御GaN増幅器は、アナログで動作するGaN増幅部と、増幅部への入力信号を生成するデジタル制御部を組み合わせた新たな発想の増

幅器である。図3に超広帯域デジタル制御GaN増幅器のGaN増幅部の回路構成を示す。GaN増幅部は、並列配置した二つのGaNトランジスタと、その出力側に接続した非対称な形をした独自の負荷変調回路によって構成する。デジタル制御部には、二つのGaNトランジスタに入力する信号間の最適な振幅と位相の組合せを瞬時に選択するために、AI技術Maisartによる学習機能を搭載する。これによって、周波数や出力電力に応じて、増幅部への入力信号の自動最適制御が可能になる。

図3の中心周波数 f_0 時を基に回路構成について述べる。一方のGaNトランジスタFET1には周波数 f_0 で90°の電気長を持つ出力回路を、他方のGaNトランジスタFET2には180°の電気長を持つ出力回路を装荷する。この際、出力容量などの寄生成分は出力回路に取り込み、トランジスタ等価回路上の電流源端に、特性インピーダンスがトランジスタの最適負荷インピーダンス R_{opt} の等価的な伝送線路が接続された構成をとる。この構成によって、周波数に応じてFET1及びFET2の出力回路の電気長が変化することを利用し、負荷変調の動作モードを切り替えて広帯域動作を実現する。

次に、各周波数での動作モードについて述べる。周波数 f_0 付近では、FET1の出力に90°線路が接続された状態になる。この場合、二つの入力信号に関して、適切な位相差で振幅比を制御することで、FET1側をキャリア増幅器、FET2側をピーク増幅器として駆動し、ドハティ増幅器として動作できる。次に、周波数 $1/2f_0$ 及び $3/2f_0$ 付近での動作を考える。この場合、 f_0 時とは逆にFET2の出力に90°線路が接続された状態になる。したがってFET1側をピーク増幅器、FET2側をキャリア増幅器として駆動することでドハティ増幅器として動作できる。さらに周波数 $2/3f_0$ 付近では、FET1の出力に60°線路、FET2の出力に120°線路が接続された状態になり、 $90 \pm 30^\circ$ の関係に

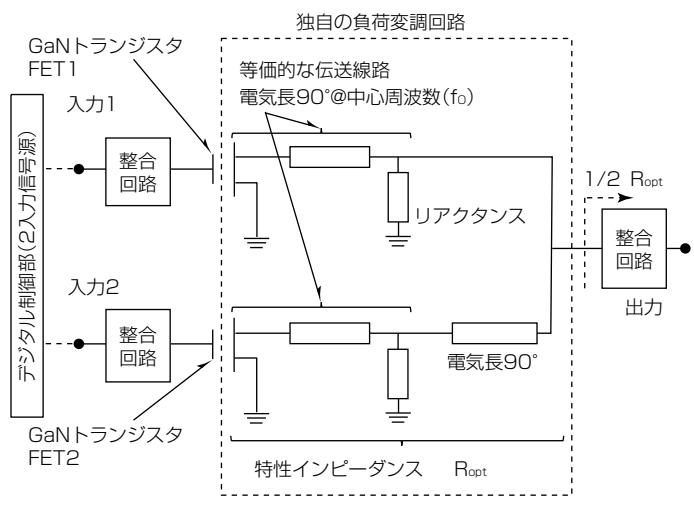


図3. GaN増幅部の回路構成

なる。この場合には、二つの入力信号を同振幅で位相差を制御して、FET 1 と FET 2 をそれぞれ駆動することでアウトフェージング増幅器として動作できる。同様に、周波数 $4/3f_0$ 付近では、 $2/3f_0$ 付近と逆相のアウトフェージング増幅器として動作できる。

独自の負荷変調回路によって増幅器の広帯域動作が可能になる一方、厳密に動作モードが規定できる前記の周波数条件以外の周波数やトランジスタの非線形性も考慮すると、二つのGaNトランジスタに入力する2入力信号間の振幅や位相の組合せは無数に存在する。中には、増幅器として動作はするものの効率が低くなってしまう組合せも含まれるため、周波数や出力電力に応じて高い効率での動作を実現する2入力信号の組合せを求める必要がある。しかし、人手で探索すると、非常に長い時間を要するという問題があるため、デジタル制御部にはMaisartによる学習機能を搭載して、出力電力や動作効率などで決定される増幅器の特性を最大化する、最適な2入力信号の組合せを自動最適制御させることで、周波数や出力電力に応じた増幅器の高効率動作を実現する。

3.2 試作結果

試作したGaN増幅部の外観と測定系を図4に示す。このGaN増幅部とデジタル制御部を組み合わせて、無変調信号を用いた高周波性能評価を実施した。6.0dBバックオフ動作時の動作効率と出力電力の周波数依存性評価結果を図5に示す。独自の負荷変調回路の適用によって、3Gから5Gまでの主要な周波数帯をカバーする1.4から4.8GHzの超広帯域動作を確認した。また、周波数や出力電力に応じた増幅器の入力信号の自動最適制御によって、2入力信

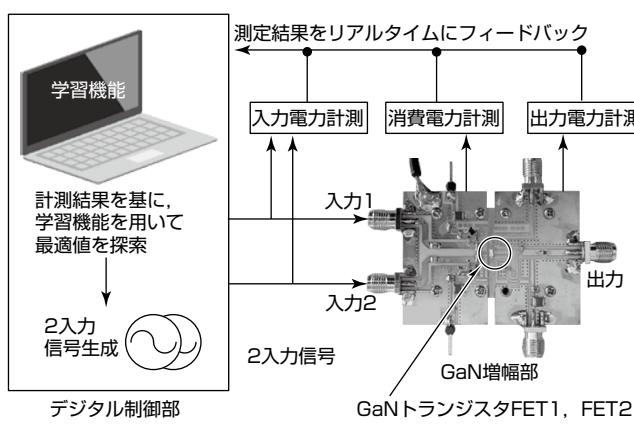


図4. 試作したGaN増幅部の外観と測定系

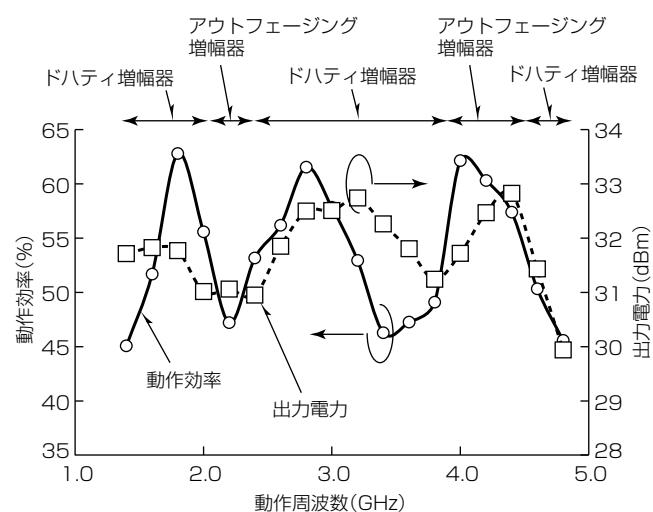


図5. 動作効率と出力電力の周波数依存性評価結果

号の振幅と位相の関係性を最適化して、周波数に対して周期的に負荷変調のモードが変化する所望の動作を確認した。その結果、動作効率40%以上の高効率動作を達成した。

4. む す び

3G, 4G, 5Gの各通信世代を一つの基地局で運用とともに、基地局装置の設置性を高めるというニーズに応えるために、6GHz以下の複数の周波数帯に1台の増幅器で対応できる超広帯域デジタル制御GaN増幅器を開発した。この増幅器はアナログで動作するGaN増幅部と、増幅部の動作モードを制御する入力信号を生成するデジタル制御部を組み合わせた新たな発想の増幅器である。今後、実際の変調信号を用いた評価を進め、多種多様なサービス・アプリケーションを実現する大容量通信に貢献とともに、TCO低減のため移動通信基地局の低消費電力化に寄与していくことを期待する。

参 考 文 献

- (1) Komatsuzaki, Y., et al.: 3.0–3.6GHz Wideband, over 46% Average Efficiency GaN Doherty Power Amplifier with Frequency Dependency Compensating Circuits, IEEE Topical Conference on RF/Microwave Power Amplifiers for Radio and Wireless Applications(PAWR), 22~24 (2017)
- (2) Ma, R., et al.: A GaN PA for 4G LTE-Advanced and 5G, IEEE Microwave Magazine, 18, No.7, 77~85 (2017)
- (3) Komatsuzaki, Y., et al.: A Novel 1.4–4.8GHz Ultra-Wideband, over 45% High Efficiency Digitally Assisted Frequency-Periodic Load Modulated Amplifier, IEEE MTT-S International Microwave Symposium(IMS), 706~709 (2019)

搭乗者の状態推定技術

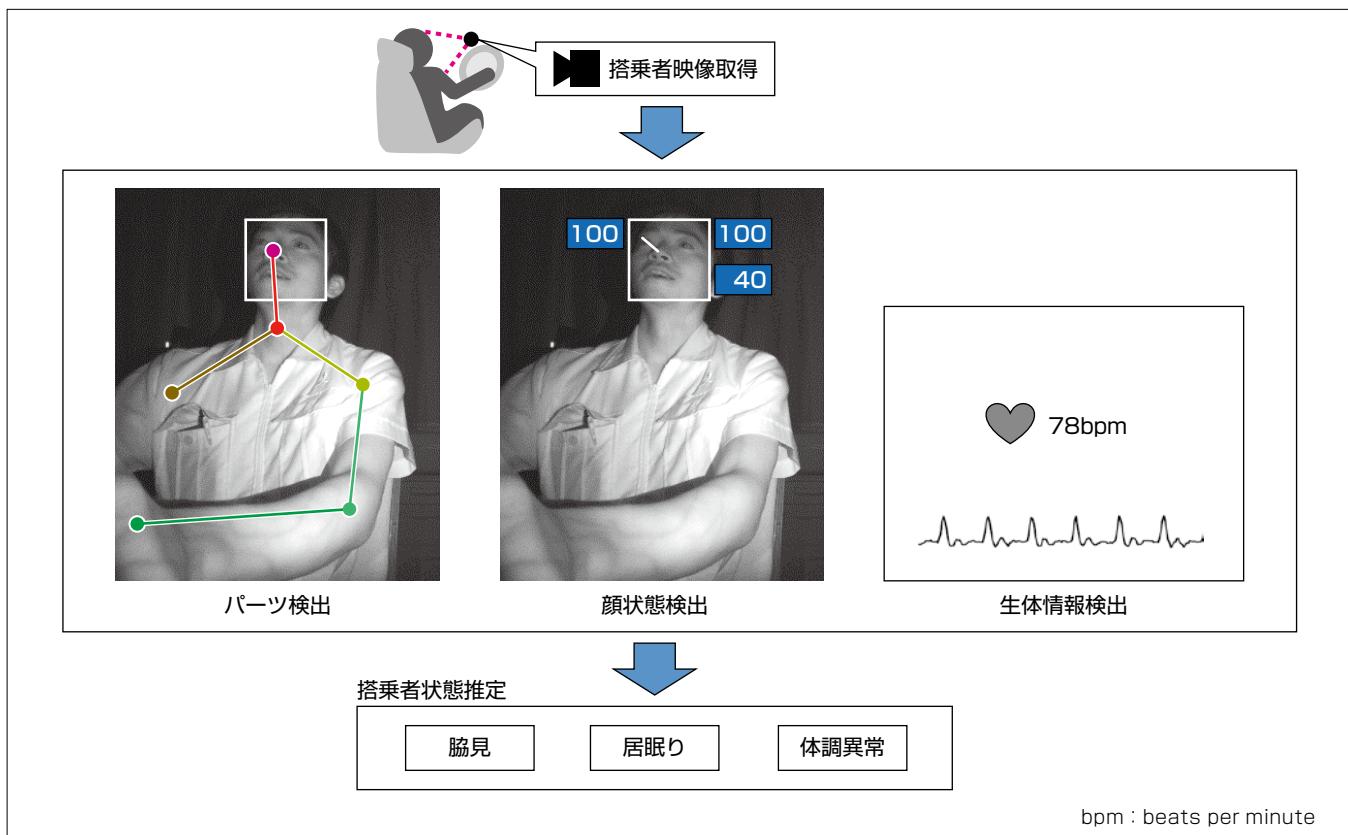
Estimation Technologies for Driver's State

要旨

交通事故を予防するために、運転中の脇見や居眠りなどの不注意を検知して注意を促す搭乗者モニタリングシステムが車に搭載され始めている。また、体調異常による交通事故の発生を抑えるために、国土交通省からも体調異常を表す典型的な姿勢崩れパターンや、体調異常が発生した際に安全に車を停止させるためのガイドラインなどが示されており、今後の搭乗者モニタリングシステムには、不注意だけではなく、体調異常を推定して交通事故予防につなげることも求められる。

搭乗者モニタリングシステムでは、これらの不注意や体調異常を推定するために次の技術を用いる。

- (1) 搭乗者が直接装着することなく非接触で、かつ夜間でも動作可能な近赤外線カメラを使った搭乗者の映像取得
 - (2) 骨格や顔の位置情報を検出するパーツ検出
 - (3) 顔の位置を使い、顔向きや目・口の開き度合いなどを検出するための顔状態検出
 - (4) 居眠りや体調異常の検出精度を上げるための脈拍などの生体情報検出
 - (5) 骨格、顔向き、目・口の開き度合い、生体情報を用いて脇見、居眠り、体調異常を推定する搭乗者の状態推定



搭乗者の状態を推定する技術

近赤外線カメラを用いて映像を取得した後、骨格や顔などのパート検出、顔向きや目・口の開き度合いなどの顔状態検出、脈拍などの生体情報検出を行い、最後に脇見、居眠り、体調異常など搭乗者の状態を推定する。

1. まえがき

車に関する交通事故を減らすことが社会課題になっており、脇見運転や居眠り運転など搭乗者の状態を検知して注意を促す搭乗者モニタリングシステムが車に搭載され始めている。国土交通省や欧州の委員会も交通事故を減らすためのガイドライン、Euro NCAP(European New Car Assessment Programme)等を作成しており、今後、搭乗者モニタリングシステムの搭載義務化が法令化されると普及が加速することが見込まれる。

その流れの中で、交通事故につながるような搭乗者の状態を推定できる技術の開発が求められている。

本稿では、搭乗者モニタリングシステムに用いられる技術の中で三菱電機が先行的に開発している技術について述べる。

2. 搭乗者の状態推定技術

交通事故につながる脇見、居眠り、体調異常を推定するために、図1に示すような流れで搭乗者の状態推定を行う。それぞれの詳細について順に述べる。

2.1 搭乗者映像取得技術

搭乗者から情報を得るために、接触型のセンサやミリ波センサなどを使うことも考えられるが、センサの種類や個数が多くなるとコストアップにつながるため、できるだけコストを抑える構成として、今回は、カメラを用いたセンシング技術に絞る。

カメラを用いる中で、車載用途であることを考慮すると、可視光線カメラを使う場合には夜間の被写体の照度不足が問題になる。そのため、人間の目に見えない波長帯である近赤外光線を照明として照射し、近赤外線カメラを使って

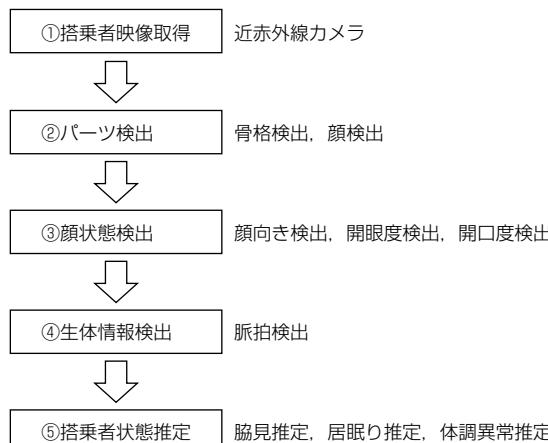


図1. 搭乗者状態推定の流れ

映像を取得する構成を用いた検出技術について述べる。

2.2 パーツ検出技術

近赤外線カメラの映像から搭乗者の不注意や体調異常を検出するためには、まず、搭乗者が映像のどこに映っており、どのような姿勢をしているか、また、搭乗者の顔が映像のどこに映っているかを検出する必要がある。

前者を検出するためには、搭乗者の骨格を検出し、後者を検出するためには、搭乗者の顔位置(顔領域)を検出する。

2.2.1 骨格検出技術

骨格検出は、映像の中から人物を検出し、さらにその人物の骨格を認識して骨格の座標データを出力する技術である。車内を撮影するカメラの場合、カメラの設置位置にもよるが、搭乗者の脚部まではあまり映り込まない画角である場合には、上体だけの骨格検出に限定することで、検出に必要な処理量を低減できる。

先行的に開発している技術を使って近赤外線カメラの映像から骨格を検出した一例を図2に示す。この技術では、映像を基に顔、首、肩、肘など骨格の関節の位置を検出しているが、当社独自のAI技術“Maisart”も活用することによって比較的少ない演算量で実現している⁽¹⁾。

2.2.2 顔検出技術

顔検出は、映像の中から人物の顔を認識して顔領域の座標データを出力する技術である。検出した顔領域の情報を用いて顔状態検出を行う。

2.3 顔状態検出技術

顔状態検出技術は、2.2.2項の顔検出技術で検出した顔領域の情報から、顔向き、開眼度、開口度を検出する技術である(図3)。

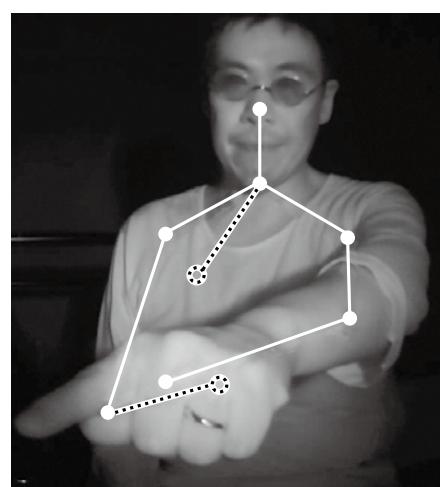


図2. 骨格検出

2.3.1 顔向き検出技術

顔向き検出は、顔領域の情報から、顔の向きを検出する技術であり(図4)，ここで検出した顔向きは、後述の脇見推定や体調異常推定に利用する。

2.3.2 開眼度検出技術

開眼度検出は、顔領域の情報から、目の周りの情報を使って、目の開き具合を検出する技術である(図5)。目の開き具合は人によって差があるため、目の最大開きを用いて搭乗者に合わせた補正を自動的に行う。

ここで検出した開眼度は、後述の居眠り推定で利用する。

2.3.3 開口度検出技術

開口度検出は、顔領域の情報から、口の周りの情報を使って、口の開き具合を検出する技術である(図6)。

ここで検出した開口度は、開眼度と同様に後述の居眠り推定で利用する。

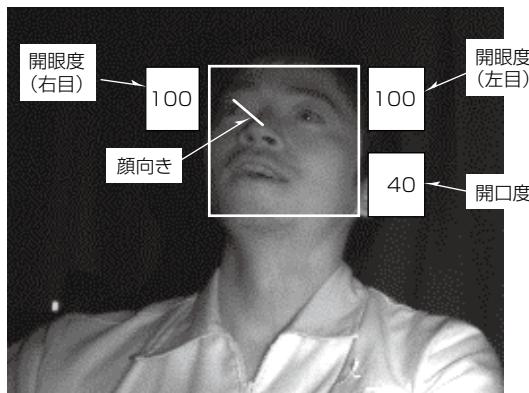


図3. 顔向き、開眼度、開口度検出

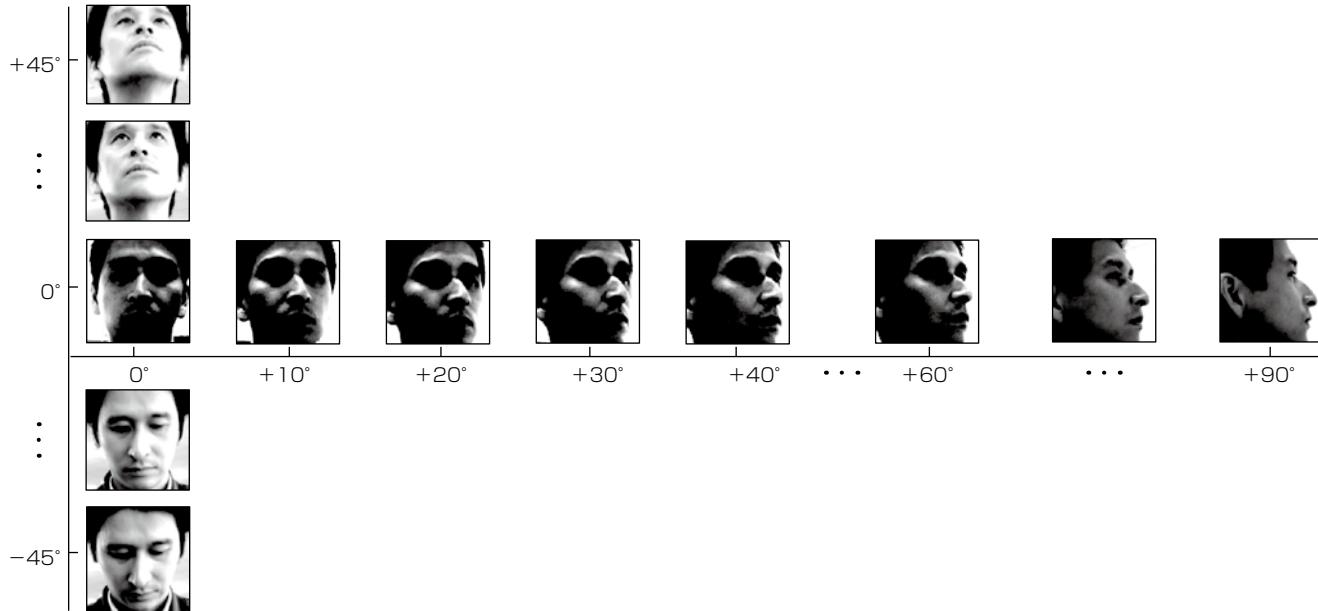


図4. 顔向き検出

2.4 生体情報検出技術

生体情報検出技術は、検出した骨格や顔領域の座標情報を用いて、生体情報の検出に用いる領域を特定し、その領域の情報を用いて目的とする生体情報を検出する技術である。

2.4.1 脈拍検出技術

脈拍を取得する際、ハンドルやシートに埋め込んだセン

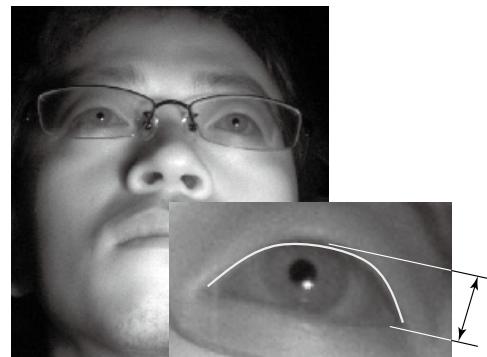


図5. 開眼度検出

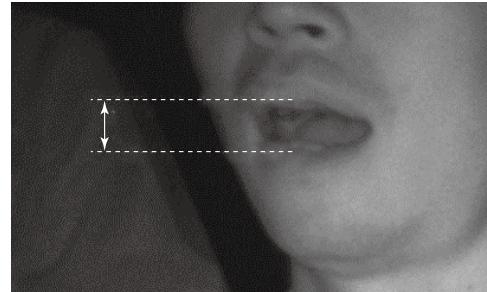


図6. 開口度検出

サを用いたり、手首や耳たぶに光学式のセンサを装着する方法が一般的であるが、カメラ以外のセンサが必要になることでコストアップにつながったり、搭乗者が直接装着するわざらわしさがあるため、近赤外線カメラの映像だけを使った方式にしている。これによって、非接触でかつ他のセンサの追加を不要にしている。

肌の下に通っている毛細血管は、脈拍に合わせて拡張と収縮を繰り返しており、毛細血管の血の量が変化している。この血の量の変動が輝度の変動として映像に表れている。脈拍による輝度変動を人間の目で検知することは難しいが、カメラで撮影した映像から、肌の微小な輝度変化をとらえて脈拍以外のノイズ成分を除去することで脈拍を検出する(図7)。

可視光のカラーカメラを利用する場合は、比較的変動幅が大きい色の変動を利用できるが、単色の近赤外線カメラでは、微小な変化しかしない輝度の変動を用いて脈拍情報を検出するため、より高精度なノイズ除去が必要になる。

この生体情報検出技術を搭載した当社のコンセプトキャビン“EMIRAI S”を東京モーターショー2019とCES 2020に出展した。

2.5 搭乗者状態推定技術

検出した骨格情報、顔状態、生体情報を用いて、搭乗者の脇見、居眠り、体調異常を推定する技術である(図8)。

2.5.1 脇見推定技術

運転中の搭乗者は、車の進行方向だけではなく、安全確認を含めた車の周囲の状況確認、メータや他の搭乗者など車内の確認などを行っている。車の停止中の進行方向以外の注視は問題ないが、車が走っている状態での周囲の注視は事故につながるため、顔向きを用いて進行方向以外を注視していることを検出し、脇見運転を推定する。

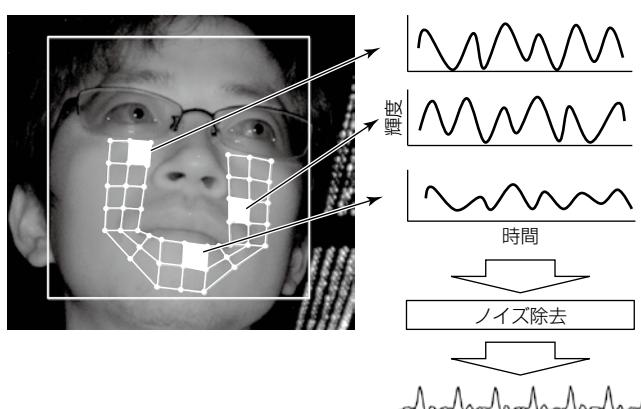


図7. 脈拍検出

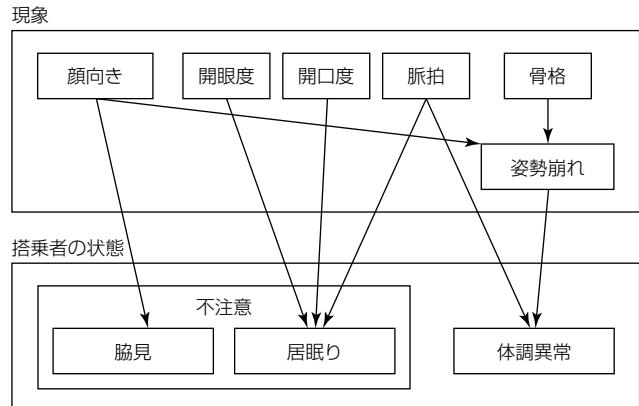


図8. 搭乗者状態推定

表1. 国土交通省が示す姿勢崩れパターン

姿勢崩れパターン
突っ伏し、うつむき、のけ反り、えび反り、首だけ横倒れ、横倒れ、横もたれ

2.5.2 居眠り推定技術

目を閉じる頻度や口を大きく開けるあくびの動作を検出することで、居眠りにつながる搭乗者の覚醒度を推定する。目を閉じる頻度としては、単位時間当たりの目を閉じている割合であるPERCLOS(PERcent of eyelid CLOSure)や、単位時間当たりの瞬(まばた)きの回数を表す瞬目率などの情報を用いる。通常、眠くなると、起きている時よりも脈拍数が下がるため、脈拍の情報を併用することで居眠りの推定精度を向上させることができる。

2.5.3 体調異常推定技術

骨格情報と顔向きの情報を用いることで、搭乗者の姿勢を検出できる。この姿勢を用いて国土交通省が示している姿勢崩れパターン(表1)を検出し、搭乗者の体調異常を推定する。また、脈拍の情報を合わせて用いることで、体調異常の検出精度を向上させることができる。

3. むすび

交通事故を減らすための搭乗者モニタリングシステムに搭載する、脇見、居眠り、体調異常を推定する技術について述べた。今後も交通事故削減に寄与する技術を継続的に開発していく。

参考文献

- (1) 津田圭一：サポートベクタ回帰を用いる骨格検出器、情報処理学会 第82回全国大会講演論文集、2-27～2-28 (2020)

IoT・AI人材育成の全社的取組み

Introduction of Human Resources Development on Internet of Things/
Artificial Intelligence Fields

細谷史郎*
Shiro Hosotani
加藤嘉明†
Yoshiaki Kato
猪又憲治‡
Kenji Inomata

清水広之*
Hiroyuki Shimizu
岡村 敦§
Atsushi Okamura

要旨

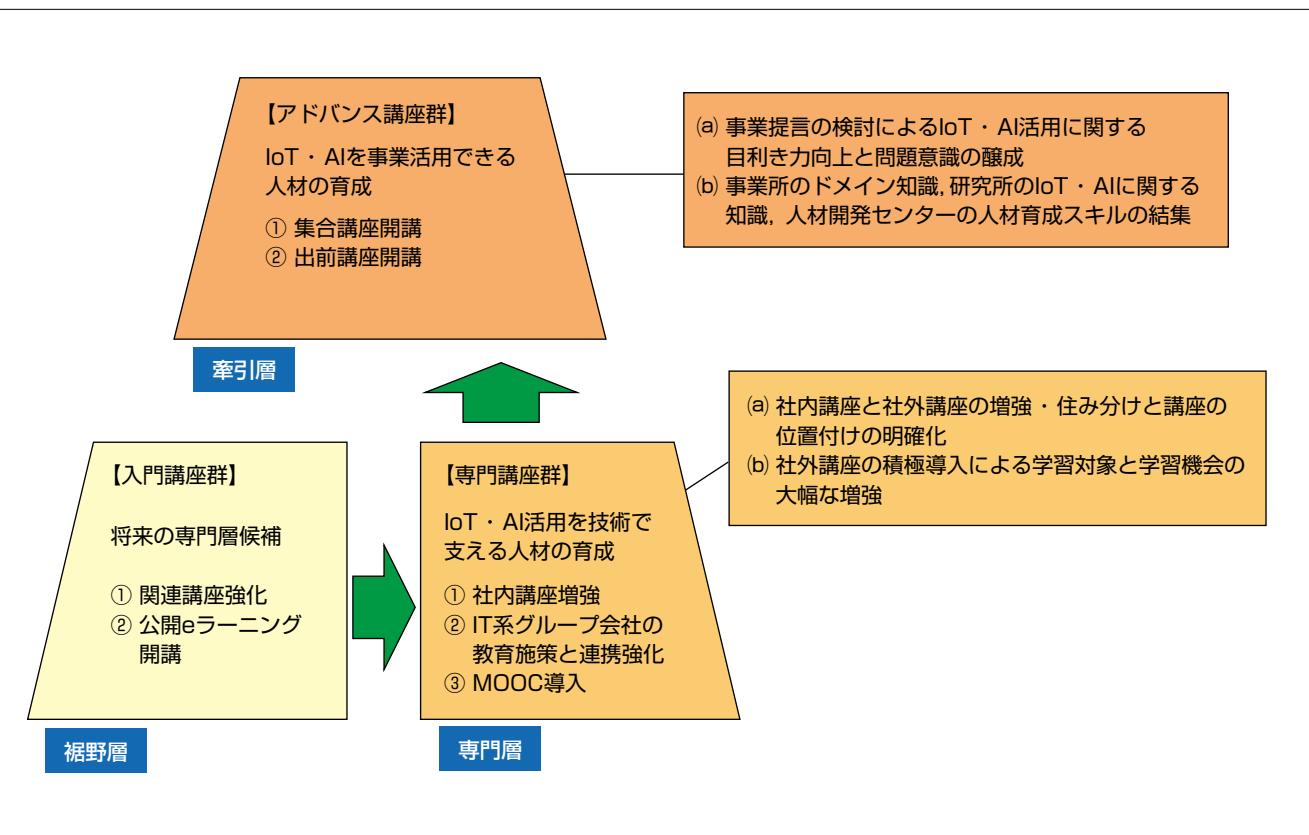
AI(Artificial Intelligence)人材不足が深刻な問題になっている中、三菱電機でもIoT(Internet of Things)やAIに関する知識を持ち、これらを事業に活用できる人材の育成が急務になっている。このため外部・内部環境の側面から分析し、牽引(けんいん)層、専門層、裾野層という三つの階層に分けて育成する取組みを体系化した。

IoT・AIを活用した事業を立案・遂行できる牽引層の育成にはビジネスモデルも含めた事業提言書作成の研修として、全社集合型と事業所出前型の講座を新設した。育成では事業ドメインに関する知識、IoT・AIに関する知識、人材育成に関する知識の全てが必要なため、事業所、研究所、人材開発センターがきめ細かく連携して教育する体制にした。

専門層の育成では社内講座と社外講座の住み分けを整理し、各々の講座を増強した。特に昨今の急速なインターネット学習環境の進展を鑑み、大規模公開オンライン講座MOOC(Massive Open Online Courses)の本格導入を施策の一つの柱として取り入れた。

裾野層の育成では、IoT・AIに関連する周辺技術の社内講座の充実と入門レベルの社内講座をeラーニング化し、全社員がいつでも受講できる環境を整えた。

今後は各事業本部内の活動との連携も強化し、更に高いレベルの教育効果を目指したIoT・AI人材育成に引き続き取り組んでいく。



IoT・AI人材育成体系と取組み内容

IoT・AI人材育成を牽引層、専門層、裾野層に3階層に分けて実施している。牽引層はIoT・AIの事業適用を具体的に検討してもらうことで目利き力を向上させ問題意識も醸成する。専門層は社外講座の積極導入で学習対象と学習機会を大幅に増強しつつ、社外講座と住み分ける形で社内講座も増強した。裾野層はIoT・AI技術と関連を持つ異分野技術者の知識レベルを向上させるとともに、公開eラーニング開講で全社底上げ教育も実施している。

1. まえがき

IoTやAIを活用できる人材(以下“IoT・AI人材”といふ)の育成が急務である。当社でも、全社レベル、事業本部レベル、開発本部レベルのそれぞれでIoT・AI人材の育成に取り組んでいる。本稿ではそのうちの全社レベルの取組みについて述べる。同取組みは、当社人材育成の特徴や外部環境の分析から始め、当社が求めるIoT・AI人材の育成方針の議論を通して講座設計をする流れで行った。

本稿では、その経緯、結果として得られたIoT・AI人材育成体系、今後の課題などについて述べる⁽¹⁾。

2. 当社人材育成の特徴

IoT・AI人材育成を考える上で考慮すべき当社人材育成の主な特徴としては次の3点が挙げられる。

- (1) 事業分野の幅広さ、求められる人材の多様さ
- (2) 確立した人材育成体系と組織横断活動の仕組み
- (3) 社内AI技術者の存在

2.1 事業分野の幅広さ、求められる人材の多様さ

図1に当社の組織図を示す。当社は八つの事業本部(事業所群)、及びこれらと横断的に関わりを持つ人事部や開発本部(研究所群)などの部門から構成される。

事業の形態は、システム～デバイス、ソフトウェアビジネス～ハードウェアビジネスなど様々であり、求められる人材も多岐にわたることが大きな特徴と言える。

2.2 確立した人材育成体系と組織横断活動の仕組み

当社の人材育成体系(図2)は、人事部／人材開発センターが所管し、全社育成施策、事業本部・事業所育成施策、全社共通施策、能力開発支援施策の4種類に分類される。

会社の中で実際に仕事を行うために必要な専門能力や実務能力、ビジネス力を身に付けるための講座群を“MELCOゼミナール(Mゼミ)”と呼んでいる。Mゼミは1983年から37年の歴史を持ち、現在では約450講座を当社グループ社員約15万人に提供している。事業を牽引する人材の育成を目指す三菱電機ビジネスイノベーションスクール(MBIS)は、その前身である“工学塾”を含めて、やはり37年の歴史を持っている。MBISで培ったマインド教育やビジ

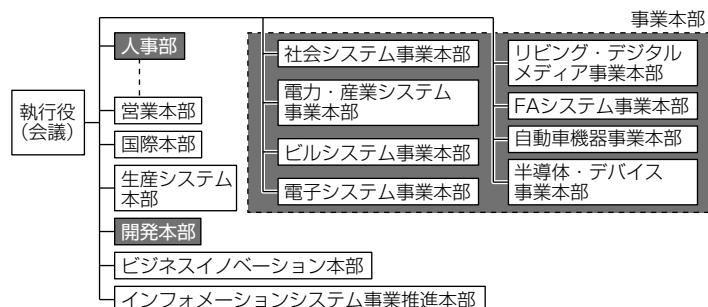


図1. 当社の組織図



図2. 当社の人材育成体系

ネススキル教育と技術者教育との融合も積極的に実施しており⁽²⁾、特に2004年に組織的取組みを開始したIT系人材育成では“ソフトウェアプロジェクトリーダー育成コース”“ソフトウェアプロフェッショナルアーキテクト育成コース”を中心として、開発系、検証系、支援系に対して段階的に人材育成する仕組みが確立している⁽³⁾。したがって、IoT・AI人材育成の検討に際しては、この取組みで不足している部分を重点的に強化することにした。

さらに特徴的な施策として全社共通施策での先端人材ネットワークがある。各種学会に相当する技術部会、技術のプロフェッショナル集団で構成される技師長会や技術士会など、様々な枠組みで組織横断的な活動が行われている。中でも新入社員研修完了直後から加入が可能になる技術部会は創設以来40年にわたり、事業本部をまたがる自由な交流の場として利用されている。技術部会とMゼミも連携しており、新規講座の開講や既存講座の見直しなどを、技術部会、人材開発センター双方から提案が可能で、互いの有識者が知恵を出し合って実施している。

2.3 社内AI技術者の存在

当社は独自開発したAI技術を持ち、AI技術ブランド“Maisart”として展開している。当社の幅広い事業分野の機器やシステムにこれらAIを搭載するには、各機器やシステムのドメイン知識(専門知識)が必要であり、製品を開発する事業所とAI技術を持つ研究所が連携して開発している。事業所経営者から見るとAI技術者はIoT・AI人材育成という観点でも貴重な存在になっている。

3. IoT・AI人材の育成方針

2章で述べた当社人材育成の特徴(内部環境分析)に加え、外部環境分析も実施し、当社に適したIoT・AI人材の育成方針を設定した。

3.1 IoT・AI技術の特徴

外部環境を分析するに当たり、まずIoT・AI技術の特徴について検討した。その結果は次のとおりである。

- (1) センシング、認識、分析、判断、制御、実行などで系を成し、その技術範囲が非常に広い。
- (2) 急速に進化した技術分野であり、現在もなお成長し続けている変化の激しい分野である。
- (3) ほとんどの事業本部に関連するが、その活用方法や活用の度合いは分野によって多様である。
- (4) 新しい製品、新しいサービスが誕生する可能性がある魅力的な技術分野だが、固定観念を打ち破った新しい発想や創造性が求められることが少なくない。

(5) 多くの場合、部門間や事業本部間、社外との連携が必要になる。

3.2 IoT・AI人材の育成方針

3.1節で述べたIoT・AI技術の特徴に基づいて現状を分析した。その結果、外部環境的には、各種サービスやフレームワークの乱立、MOOCの台頭など、混沌(こんとん)とした環境下に当社が置かれている実状が整理できた。内部環境的には社内でのIoTやAIの識者の存在、組織横断的な活動風土などが特徴として挙げられた。

これらの分析から“社内識者を活用したIoT・AI活用の実践力強化”と“MOOCの社内活用”的2点をIoT・AI人材の強化ポイントとして抽出した。さらに3.1節で述べたIoT・AI技術の特徴分析から、実践力を強化すべきIoT・AI人材としては、技術の本質を捉えて適切に同技術を事業活用できる人材と、プログラム言語や開発環境などを熟知しIoT・AI活用を技術的にカバーできる人材の2通りに分けて考えることを方針として設定した。

4. IoT・AI人材育成の講座設計

4.1 IoT・AI人材育成体系

3章で述べたIoT・AI人材の育成方針に基づいて、当社でのIoT・AI人材育成はその育成対象を牽引層、専門層、裾野層の3層に分けることにした。各層の定義は次のとおりであり、その結果として得られた人材育成体系は要旨の図で示したとおりである。

- (1) 牽引層：IoT・AIを事業活用できる人材
- (2) 専門層：IoT・AI活用を技術で支える人材
- (3) 裾野層：将来の専門層候補

4.2 牽引層の育成

牽引層が持つべき要件は、次のように整理される。

- (1) 当該事業領域に関する知識
- (2) 事業課題から取り組むテーマを抽出できるマインドやビジネススキル
- (3) 取組みテーマに対してIoT・AI技術活用の具体策が検討できる目利き力

これらの要件を満たすには、事業所(事業本部)、研究所(開発本部)、人材開発センター(人事部)の関わりが必須になる。そこでこれら三者が支援し、中堅技術者にIoT・AI活用に関する事業提言を作成してもらう研修を行ったことをした。最初は希望者が研修センターに集まって受講する集合型の研修形態で実施した。同形態で軌道に乗ったことを受け、集合講座で得た知見や経験を基に、事業所に出向

き、事業所の特徴に合わせて内容を最適化する出前講座を追加した。出前講座は複数の事業所に対して並列して実施でき、年間育成人数を一気に10倍に押し上げることができた。対応する講師は、事業所が取り上げたいテーマに対して最適なメンバーを研究所や人材開発センターから派遣する柔軟な運営体制にした。

4.3 専門層の育成

専門層の育成に当たっては、まず技術マップを作成して研修講座の過不足をチェックし、不足している領域に対して計画的に講座を追加していった。事業と関連を持たせたい講座は社員を講師とした社内講座とし、汎用的な基礎知識やスキルに関するものは社外講座を活用することで短期かつ良質な講座体系の整備を心がけた。社内講座については2.3節に述べた技術部会の枠組みを最大限に活用し、社外講座については当社IT系グループ会社の教育施策との連携強化に加え、MOOC導入を施策に加えた。MOOC導入ではIoT・AI技術者に協力してもらって受講推奨講座を抽出し、安全に運用するためのルール作りと合わせて施策化した。

4.4 堀野層の育成

堀野層向け講座としては通信技術者や電子回路設計者などIoT・AI専門技術と接点を持つ技術者を対象にした講座の強化を行った。具体的には、センサ、5Gといった関連技術講座の強化に加え、電子回路設計者向け講座にディープラーニング(深層学習)用ハードウェアの実装技術なども追加した。さらに、機械学習全般を対象にした入門レベルのeラーニング教材を作成し、グループ会社を含む全社に公開することで堀野の拡大と全体の底上げを図った。

5. 今後の課題

企業でのIoT・AI人材育成では、職務を抱えた技術者に對していかに短期間に効率良くIoT・AIという新しい技術を習得してもらうかが課題になる。

習得方法としては、

- (1) 基礎から順にレベルアップさせていく
- (2) 受講者にまず問題意識を持たせ、後は受講者の自主性を施策面で支援する

の2通りがある。前者は時間がかかり、後者は確実性に問題がある。当社ではIT系人材育成施策で、既に意識付けされた技術者も少なくないため、後者の方法で進めてきたが、目利き力の醸成、ことづくり目標の追求などが今後の課題である。

5.1 目利き力の醸成

IoT・AIを活用した製品やサービスの開発では試行錯誤が多発し、そのPDCA(Plan Do Check Action)サイクル数の多さが問題になる。目利き力とは、Plan(計画)の精度を高めることで試行サイクル数を減らせる能力と定義し、研究所など専門技術者の力を借りて計画精度を上げる能力の向上に取り組んだ。能力向上の方策にはQA4AIなどに代表されるコンソーシアムの成果なども活用した⁽⁴⁾。しかしその教育効果は実践経験の有無等によって大きくばらついたため、教育効果の向上が今後の課題である。

5.2 ことづくり目標の追求

もう一つの課題はことづくり目標の追求である。IoT・AI活用に当たってはことづくり、すなわちサプライチェーンの上流から発想し、大きな枠組みの中で具体論に落とし込むことが重要になる。しかし教育現場でよく出てくるアイデアは以前から存在する製品や仕組みの一部にIoT・AIを適用するサプライチェーンを下からさかのぼろうとするものである。現状目利き力の醸成を優先したためあえてこのようなアプローチも許容して進めているが、ことづくり本来の姿に対してまだ課題を残す取組みになっている。

6. むすび

当社のIoT・AI人材育成の全社施策のそもそもの目的が全体の底上げにあり、問題意識を持った技術者の絶対数の増加にある。その意味では受講者間や受講者・講師間などで意義のある議論ができると考える。組織間連携の重要性に対する認識は大半の受講者が持ってくれるようになり、オープンイノベーション、標準化、コンソーシアムの重要性にたどりつく受講者も少なくない。この活動を実施している間、事業本部での施策も増えてきているため、今後は事業本部施策と連携させて5章で述べた課題を解決していく段階に入る時期と考えている。すなわち、目利き力やことづくり目標は事業本部施策の中でこそ發揮すべきものであり、これら施策と連携して全社教育のあるべき姿を再整理していきたいと考える。

参考文献

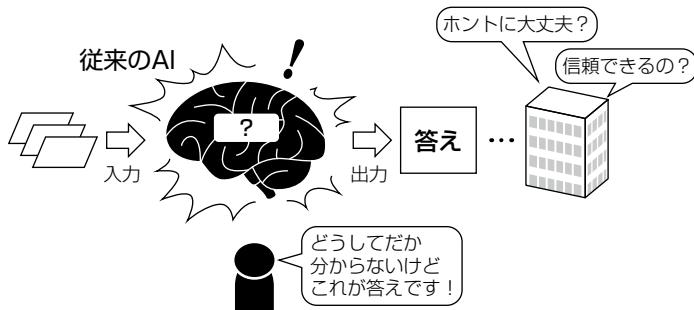
- (1) 細谷史郎、ほか：三菱電機におけるIoT・AI人材育成の全社的取り組み、電気学会全国大会講演論文集、H4-3 (2020)
- (2) 前川隆昭、ほか：ソフトウェア技術者の実践的育成体系—技術教育とマインド教育の融合—、工学教育研究講演会講演論文集、264～265 (2018)
- (3) 清水広之、ほか：ソフトウェア技術者の実践的育成体系—キヤリアマップに基づく育成体系—、工学教育研究講演会講演論文集、262～263 (2018)
- (4) QA4AI(AIプロダクト品質保証コンソーシアム)：AIプロダクト品質保証ガイドライン (2019.05版)



AIを安心して使うために 説明可能なAI

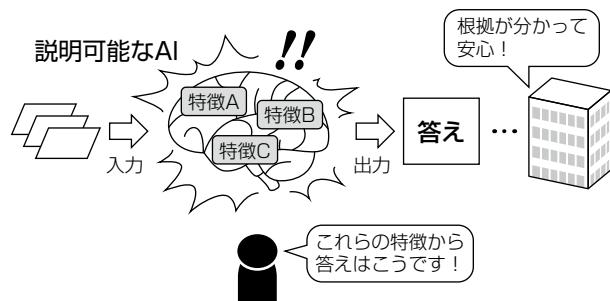
ブラックボックスの中身を知りたい

現在、様々なビジネス領域で機械学習が活用されています。しかし、AI(Artificial Intelligence)アルゴリズムが高度になるほど機械学習モデルは解釈が困難な“ブラックボックス”になり、導き出されるアウトプットがなぜそうなるのか、開発者も説明ができません。すると“判断の根拠が説明できないものは安心して使えない”という懸念が広がり、AIが社会での実利用でリスクを持つものと捉え



られてしまいます。例えば、AIによる自動運転でも事故が発生した場合、AIの判断理由が説明可能でなければ原因を探ることができず、導入する企業やユーザーの信頼を得られません。

そこで近年、機械学習モデルをホワイトボックス化する“説明可能なAI(eXplainable AI : XAI)”の研究に注目が集まっています。



XAIの代表的な研究

XAIとは、予測結果や推定結果に至る過程が人間によって説明可能になっている機械学習モデル、又はそれに関する技術や研究分野のこと指します。

XAIの実現を目指して、様々な手法や技術が考案されており、特に2016年以降、機械学習関連の国際会議でAIによる判断の根拠の説明に関する論文が増加しています。

例えば、AIが説明を提示する方法の代表的なものとして、次の四つが挙げられます。

(1) 重要な特徴の提示

“データのどの特徴が予測・認識に重要だったか”を説明として提示する方法です。例えば、集団を収入の高い群と低い群に分類した場合、収入の高い群に分類された人の重要な特徴(年齢、職種等)を説明として提示します。

(2) 重要な学習データの提示

“どの学習データが予測・認識に重要だったか”を説明と

XAIの求められる領域

XAIはAIへの不安を解消できる手段の一つとして非常に有効なものです。

冒頭に挙げた自動運転のほかにも、裁判、医療診断や予防保全など、大きな信頼を求める分野では特に判断の根拠について説明が必要です。AIが判断した過程につい

して提示する方法です。例えば、画像認識への影響が強い学習画像は何だったのか、また、ある学習画像が“なかつた”としたらどの程度認識精度が変わるかを説明として提示します。

(3) AIの可読化

予測・認識の過程を“可読な表現で記述する”ことでAIの説明とする方法です。複雑なアルゴリズムを人間が読める簡単な記述に書き換えます。

(4) 自然言語による説明

“データのどの特徴が予測・認識に重要だったか”を自然言語で説明文として提示する方法です。例えば、画像認識によって鳥の種類を判別したとき、結果とともに“これは、長い首と大きなくちばしを持つ茶色の鳥であるため、カツブリです。”という説明文を提示します。

て、人間が理解可能な説明があれば、その判断／処理結果を採用するか否かの指標にすることもできます。

これからの社会でAIの活用領域を広げるために、XAIの早期実用化が求められています。