

三菱電機技報

5

2025
Vol.99 No.5

AI・データ利活用による新たな価値創造への取組み

No.5

特集 AI・データ利活用による新たな価値創造への取組み

Initiatives to Create New Value through AI and Data Utilization

巻頭言

データとAIの未来：価値創出とガバナンスの

トレード・オン…………… 1-01
朝日宣雄Future of Data and AI: Trade-on in Value Creation and Governance
Nobuo Asahi循環型 デジタル・エンジニアリングによる感情分析を
活用したコールセンター向けオペレーター支援モデルの構築… 2-01
白浜広彬・渡邊健太・藤川皓一郎・藤田喜広Circular Digital-Engineering: Building of Operator Support Models for Call Centers Utilizing
Sentiment Analysis
Hiroaki Shirahama, Kenta Watanabe, Koichiro Fujikawa, Yoshihiro Fujitaサブメートル分解能の動態判読を
実現する土地利用分類AI技術…………… 3-01
三五大輔・栗原康平・藤野俊樹・小野田郁哉MELTERRA Landscan: Our Land Cover Mapping AI Reveals Terrestrial Dynamics at Sub-meter
Resolution
Daisuke Sango, Kohei Kurihara, Toshiaki Fujino, Fumiya Onoda社会インフラ事業分野でのデータ分析を
活用したソリューション創出の取組み…………… 4-01
上野洋平・今井 健・山田知史・大林昌則Solution Creation Methods Utilizing Data Analysis for Social Infrastructure Systems
Yohei Ueno, Ken Imai, Satoshi Yamada, Masanori ObayashiIoT機器のデータ統合分析基盤“KOTOLiA”…………… 5-01
伊藤山彦・古賀宗典・海津洋介・林 卓人Integrated Data Analytic Platform for IoT Devices "KOTOLiA"
Takahiro Ito, Munenori Koga, Yosuke Kaizu, Takuto Hayashi次世代コミュニケーションサービス“AnyCOMPASS”
での生成AIを活用した服薬指導、薬歴作成サービス…… 6-01
高野謙司・松田悠希・園田康博・重富健二・中村公昭Medication Instruction and Medication History Creation Services Using Generative AI in
Next-generation Communication Service "AnyCOMPASS"
Kenji Takano, Yuuki Matsuda, Yasuhiro Sonoda, Kenji Shigetomi, Takaaki Nakamura機械学習によるゴム部品の性能予測技術…………… 7-01
塙 勇太郎・中谷浩司Performance Prediction Technology for Rubber Parts Using Machine Learning
Yutaro Hanawa, Koji Nakatani生成AIによるAIチャットボットの実用化…………… 8-01
阿部貴之・山田篤史・池田貴紀・徳富 忍・衣川英之Practical Application of AI Chatbots Using Generative AI
Takayuki Abe, Atsushi Yamada, Takaki Ikeda, Shinobu Tokudomi, Hideyuki KinugawaSerendieデータ分析基盤…………… 9-01
轟木伸俊・古跡 進・水口武尚Serendie Digital Infrastructure -Data Analysis System-
Nobutoshi Todoroki, Susumu Koseki, Takehisa Mizuguchi

執筆者の所属は執筆時のものです。

本号に記載されている会社名、製品名はそれぞれの会社の商標又は登録商標です。

三菱電機では、サステナビリティ経営を実現するビジネスエリアとして、「インフラ」「インダストリー・モビリティ」「ライフ」を設定しています。

三菱電機技報ではこのビジネスエリアを中心に特集を紹介しています。

今回の特集では全エリアを支える基盤となる“AI・データ利活用による新たな価値創造への取組み”をご紹介します。

巻頭言

データとAIの未来：価値創出とガバナンスの トレード・オン

Future of Data and AI: Trade-on in Value Creation and Governance



朝日宣雄 Nobuo Asahi

執行役員 DXイノベーションセンター長

Corporate Executive, Senior General Manager, DX Innovation Center

1995年にインターネットが一般ユーザーに開放され、Webブラウザの普及とともに、多くのサーバーに蓄積されたデータが容易に利用可能になり、それを契機に様々なデータがインターネット上に蓄積されてきました。米国の調査会社IDCによると、国際的なデジタルデータの量は指数関数的に増大しており、2000年の約6.2エクサバイトから2020年には約40ゼタバイトに達したとされています(1ゼタバイト=1,000エクサバイト=10億テラバイト)。

この膨大なデータは、ビッグデータという概念を生み出し、新たな洞察やビジネスチャンスを生み出す手段として注目されるようになりました。ビッグデータによってAI(人工知能)技術も急速に進化を遂げました。かつては、論理学をベースとした記号論的なAIが主流でしたが、データを多層のニューラルネットワークで学習するディープラーニングが、2006年にジェフリー ヒントン氏によって提唱され、流れは大きく変わりました。この功績によってジェフリー ヒントン氏はニューラルネットワークの礎を築いたジョン ホップフィールド氏と共に2024年のノーベル物理学賞を受賞したことは記憶に新しいでしょう。生成AIは、2014年に生成的敵対ネットワーク(GAN)が登場したことで大きなブレイクスルーを迎えました。これらの技術はインターネット上のビッグデータによって瞬く間に実用化されてきましたが、一方、新しいAIによってビッグデータがより活用されていくという相乗効果によって、高度なパターン認識や予測、創造的なコンテンツ生成が可能になり、様々な分野での応用が進んでいます。

これらの技術革新によって、私たちはデータやAIを活用して、これまでにないスピードで新しい発見や製品・サービスを生み出すことができるようになりました。例えば、医療分野では、AIを用いた診断支援システムが開発され、早期発見や治療の精度向上に寄与しています。また、製造業では、ビッグデータ解析を通じて生産効率の向上や品質管理の強化が図られています。

しかしながら、これらの強力な技術を安全に活用するためには、データガバナンスやAIガバナンスといった課題にも取り組む必要があります。データガバナンスの議論は2010年代初頭から始まり、AIガバナンスについては2020年代に入ってから本格化しました。現在、国際的なルールとしては、EU(European Union)のAI法(AI Act)やG7広島AIプロセスなどが制定されつつあります。

三菱電機は、2022年に“循環型 デジタル・エンジニアリング企業”を目指すという経営戦略を掲げ、顧客から得られたデータをデジタル空間に集約・分析するとともに、グループ内外の知見の融合と共創によって、新たな価値を生み出し、社会課題の解決に貢献することを目指してきました。2024年にこの活動を更に進化させるため、デジタル基盤“Serendie”を構築し、データ利活用やAI応用を加速しています。データ及びAIの活用によって、加速的に価値の創出が進化する中、この強力な技術がフェイクニュースや不都合な結果を生み出さないためのガバナンスとの両立が不可欠であり、トレード・オンの考えの下に積極的な解決に取り組んでいきます。

この特集では、AI・データ利活用の最新動向や事例を通じて、皆様に新たな知見を提供するとともに、今後の技術活用の方向性について考える一助になることを願っています。

循環型 デジタル・エンジニアリングによる感情分析を 活用したコールセンター向けオペレーター支援モデルの構築

白浜広彬*
Hiroaki Shirahama
渡邊健太*
Kenta Watanabe
藤川皓一朗*
Koichiro Fujikawa

藤田喜広†
Yoshihiro Fujita

*Circular Digital - Engineering: Building of Operator Support Models for
Call Centers Utilizing Sentiment Analysis*

*三菱電機デジタルイノベーション(株)
†同社(博士(情報学))

要 旨

三菱電機デジタルイノベーション(株)(MEDigital)は、循環型 デジタル・エンジニアリングを実現する三菱電機のデジタル基盤“Serendie”(セレンディ)関連事業の開発の一環として、音声感情解析技術を応用し、コールセンター向けオペレーター支援モデルを構築した。このモデルを使用した感情分析サービス“emoiwa”(エモイワ)は、解析された会話中の感情を基にオペレーターの応対品質や離職予兆を管理者にフィードバックすることで、顧客満足度とオペレーターのウェルビーイング向上を目指している。今回、ストレス軽減や効率的な対応支援を可能にする感情分析技術の実用性を評価し、具体例を通じて効果を実証した。その結果、AI技術を活用した新たなコールセンター支援モデルの可能性を見いだした。

1. ま え が き

コールセンターの応対品質は、顧客満足度や企業の信頼に直結する重要な要素であり、オペレーターの対応が企業イメージや顧客ロイヤリティに大きく影響する。近年、顧客ニーズの多様化に伴いトラブル対応や専門的サポートを必要とするケースが増加しており、企業は教育や支援体制の強化に取り組むことが求められている。また、カスタマーハラスメントが深刻化し、オペレーターが精神的な負担を抱えて、離職することが問題になっている⁽¹⁾。離職率増加は再雇用・再教育コストの増大につながるため、その対策として企業は、研修やガイドラインの整備、法的措置の検討を進めている。職場環境を改善し、従業員のストレスを軽減することで、労働意欲や生産性の向上、離職率の低下を目指している。

MEDigitalは“循環型 デジタル・エンジニアリング企業”として、先進デジタル技術の活用による価値の高度化を推進している。デジタル基盤Serendieは、顧客から得られたデータをデジタル空間に集約・分析するとともにグループ内が強くつながり知恵を出し合うことで、新たな価値を生み出して社会課題の解決に貢献するものである。昨今サービス業での接客対応や保守員の教育、営業支援など人間が行動主体になる分野でも、現実世界の環境をデジタル上で再現する“デジタルツイン”が広がりを見せている。

MEDigitalは、前身の三菱電機インフォメーションシステムズ(株)から20年以上にわたってコールセンターや金融機関へ大規模音声ソリューションを提供している。ここ数年、AIの発展に伴い、音声認識によるコンプライアンスチェックの合理化やリアルタイムでの音声認識結果をアフターコールワークに活用することで、20%以上の業務効率化も実現してきた。図1に“人を理解するAIモデルを活用した音声ソリューション”を示す。様々なコミュニケーションで発生した音声を、独自の録音基盤や音声認識基盤でデジタル化して蓄積し“人を理解するAI”で分析することで、現実世界のオペレーターや営業を支援する。その中でも、本稿では、オペレーターの感情値と音声テキストを基に、応対品質向上や離職率改善を支援する“感情分析技術”の取組みについて述べる。

2. 関連技術と課題

音声感情解析技術は、音声から抽出された特徴量を用いて、喜怒哀楽などの基本的な感情分類を行う技術である。例えば、AmiVoice^(注1)やVerint^(注2) Communications Analyticsなどのシステムは、音声をテキスト化し、感情を数値として出力する機能を備えている。これらのシステムでは、テキスト化された内容だけでは文脈や発話のニュアンスが失われることが多く、例えば“はい”という単語が肯定的な場面で使われたのか、否定的な場面で使われたのかを正確に判断することが難しいという課題があった。さらに、従来の音声感情解析技術は、感情の分類や数値化にとどまり、それらの結果を具体的に業務にどう活用するかについての指針が明確でない場合が多く、業務改善や意思決定に結び付けることが難しいという問題も指摘されている。例えば、感情値が高いからといって、それが必ずしもオペレーターの応対品質評価や離職に直

結するわけではなく、音声感情解析技術の結果をどのように解釈し、具体的なアクションにつなげるかが課題になっていた。

(注1) AmiVoiceは、(株)アドバンスト・メディアの登録商標である。

(注2) Verintは、Verint Systems Inc.の登録商標である。




図1-人を理解するAIモデルと音声ソリューションの全体像

3. MEDigitalの感情分析技術

コールセンターの顧客満足度向上とオペレーターのウェルビーイング向上のために、MEDigitalでは感情分析技術の開発に注力している。この章では、そのうちオペレーターの対応品質向上と離職率改善を支援する分析技術について述べる。2章に述べた課題を解決するため、音声感情解析技術の結果である感情値と音声テキストを組み合わせる具体的な業務指標と結び付けることで、実用的な価値を生み出す可能性を見いだした。

3.1 対応品質向上を支援する分析技術

オペレーターの対応品質向上施策の一つとして、説明話法の統一化がある。カスタマーに説明する内容を通話のカテゴリごとにマニュアル化し、それに従って対応を行うことでオペレーターの勤続年数や業務知識、スキルにかかわらず説明内容を均一化する効果が期待できる。しかしながら、オペレーターの対応に対する顧客評価に差が生じることは往々にして起こる。これには様々な要因が考えられるが、マニュアルでは表現しきれない声の大きさや速さ、抑揚、言葉遣いなどによるオペレーターの印象も深く影響していると考えられる。某金融機関のコールセンターでも、顧客ロイヤリティであるNPS(Net Promoter Score)^(注3)が月ごとに変動する原因が分からないという課題があった。

この課題に対して、MEDigitalは通話音声解析した感情値や音声テキストに着目し、感情分析技術によって抽出した感情パターンとNPSの関係性を分析した。ここで使用した感情分析技術は、音声から認識した感情値と音声テキストを行列分解技術で次元圧縮し、複数の通話に共通する感情と単語のパターンを自動で抽出する特許取得済みの技術である(図2)。分析結果として、一部の感情パターンとNPSに関係があることを確認できた。

さらに、対応品質向上に有効な話法を抽出するために、NPSの高い通話と低い通話を選別し、比較を行った。このとき、NPSだけでなく関係性の見られた感情パターンも選定基準に含めることで、感情値による違いを抽出しやすくなった。比較の結果、NPSの高い通話には特定の感情値で対応しつつ特別な説明話法があることを発見した。また、対応の内容が同一であっても感情値の違いによってNPSが異なるケースを発見した。某金融機関からは、対応品質向上に役立つ新たな視点が得られたと評価を受けた。このことから、この分析技術は実用的な価値を生み出す可能性を見いだした。分析結果の活用方法としては、NPSの高い通話によく見られる対応をマニュアルに反映することや、NPSが低い傾向にあるオペレーターを対象に感情値を考慮した研修を行うことが考えられ、対応品質の向上が期待できる。

(注3) NPSは、ベイン・アンド・カンパニー、フレッド・ライクヘルド、NICE Systems, Inc.の登録商標である。




図2-感情パターン抽出のイメージ

3.2 離職率改善を支援する分析技術

多くのコールセンターが抱える課題の一つとして、高い離職率がある。一般的な業種と比較してもオペレーターの離職率は高いと言われている。そこで、離職率改善を支援する分析技術として、従業員の離職の予兆を検知する技術がある。機械学習などの手法を用いて離職の予兆がある従業員を検知することで、離職防止の対策を講じるための検討材料への活用が期待される。離職者を予測する既存技術では、入力データとして、年齢や階級、給与など従業員の基本属性データや、就業時間、残業時間、休暇などの勤怠データ、従業員満足度などのアンケートデータなどを用いることが多い。しかしながら、これらのデータでは数か月先に離職するかの予兆を早期に検知することは難しいという課題がある。勤怠データは離職直前に傾向が表れやすく、アンケートデータは業務負荷の観点から頻繁に取得することは難しいためである。

そこでMEDigitalでは、コールセンターでの対応業務の通話音声から得られるデータを基に、オペレーターの離職傾向を検知する技術を開発した。オペレーターと顧客の通話を録音した音声から得られるデータを用いることで、オペレーターへの新たな業務負荷もなく、日々の変化から離職の予兆を早期に検知することが可能になる。検知には機械学習の技術を利用する。通話音声を解析した感情値や音声テキストなどを入力し、機械学習を用いてオペレーターの数か月以内の離職の有無を正解として学習させる。ここで、予測に用いる音声テキストや感情値は発話ごとに記録されるため、そのままの単位では粒度が詳細であり、離職者の予測には適していない。そこで発話単位のデータを通話単位に集約し、さらにオペレーターごとの期間単位へと段階的に集約していく工夫を取り入れている(図3)。この技術の評価として、実際の離職件数のうち離職と検知できた件数の割合である“再現率”と、離職と検知した件数のうち実際に離職した件数の割合である“適合率”を測定した。その結果、半年以内に離職するオペレーターの予測精度として、再現率は約80%、適合率は約50%




図3-離職者予測のイメージ

であった。高い再現率でありながら、トレードオフの関係にある適合率も比較的高い精度を達成した。このことから、この分析技術による高精度での予兆検知の可能性を見いだした。

4. 市場での評価とサービス開発

4.1 市場での評価

コールセンターを持つ企業で、応対音声サービスを品質の向上などに役立てる取組みは今後も続くと思われる。MEDigitalの感情分析の取組みで、特に離職防止対策については取引先の関心が高い。金融機関のコールセンターでは、一人当たりの採用・教育コストは230万円との試算結果もある。年間離職率を30%、離職者の20%を防止できたとすると、オペレーター数200人規模のコールセンターでは年間の離職防止人数は12人、2,760万円の削減効果が得られる計算になり、離職防止対策は投資対効果が高いことも関心が高い一因と考えられる。3.2節に述べた分析技術で離職者の予測については異業種のコールセンターでも共通の傾向を出しやすい可能性があり、離職防止対策による人材の定着が起これば、先に述べたコスト以外にも様々なメリットが得られると考えられる。これらによって他社展開が可能と考えて、離職者の予測を行うサービスを開発した。

4.2 感情分析サービスemoiwaの開発

感情分析サービスemoiwaは、離職確率の推定と可視化によって、離職傾向のあるオペレーターを早期に検出し、管理者による効果的な対策を支援する。図4にemoiwaの表示画面と離職防止対策のイメージを示す。時系列の表示では特定時期に離職確率が増加したオペレーターに対して、1on1面談など個人に特化したケアを行うことが可能である。オペレーターの応対スキルの推定結果と組み合わせた可視化では、応対スキルが高く離職傾向のあるオペレーターへ優先的なケアの提供や、応対スキルが低く離職傾向のあるオペレーターへの再教育の実施などに活用が可能である。これらの機能を含むemoiwaは既存の通話録音システムへの影響を与えず簡易的な導入を可能にしており、取引先から好評を得ている。一方で離職確率結果の活用で、確率だけでは離職防止対策につなげにくいという意見もあり、今後はオペレーターのケアにつながる情報の追加提供を検討していく。




図4-感情分析サービスemoiwaと離職防止対策イメージ

5. む す び

MEDigitalの感情分析サービスemoiwaは、AI技術を活用し、オペレーターごとの応対スキルや離職確率を予測して管理者に通知することで、従業員が安心して働ける環境を整備し、人材確保や業務効率化に貢献するとともに、ウェルビーイングの向上を目指すものである。人手不足が一層深刻化することが予想される中、従業員の健康や満足度を重視することが重要である。“人を理解するAIモデルを活用した音声ソリューション”は、顧客対応分析やカスタマーハラスメント

対策に加えて、業務負担を軽減しつつ、適切なフィードバックやスキル向上の機会を提供する。MEDigitalは、デジタル基盤Serendieを活用し、顧客との共創を通じて、人を理解するAIモデルと音声ソリューションの更なる提供を推進していく。

参考文献

- (1) 厚生労働省：カスタマーハラスメント対策企業マニュアル（2022）
<https://www.mhlw.go.jp/content/11900000/000915233.pdf>

~~~~~

# サブメートル分解能の動態判読を実現する土地利用分類AI技術

三五大輔\*  
Daisuke Sango  
栗原康平†  
Kohei Kurihara  
藤野俊樹\*  
Toshiki Fujino

小野田郁哉\*  
Fumiya Onoda

MELTERRA Landscan: Our Land Cover Mapping AI Reveals Terrestrial Dynamics at Sub-meter Resolution

\*鎌倉製作所  
†防衛・宇宙ソリューション事業部

## 要 旨

日本の労働人口が減少する中、国内のインフラや経済活動の監視の効率化の一手法として、リモートセンシングデータ、特に衛星画像を活用した土地利用状況の把握が提案されている。しかし、今までの衛星画像を活用した土地利用状況情報では、①目視判読では時間を要する、②自動的に作成された情報の空間解像度が10～50mと粗い、といった問題があった。そこで、三菱電機では、AIを用いて超解像処理を行う“MELTERRA HD”、及び土地利用状況をサブメートル単位で自動分類する“MELTERRA ランドスキャン”を開発した。このAIを令和6年能登半島地震に活用したところ、目視判読と比べて1/12以下の短時間で、同程度の精度が得られることが確認できた。今後、このAIについて、防災分野やESG (Environment, Social, Governance) 分野での利活用が見込まれる。

## 1. ま え が き

日本の総人口は2050年にかけて約3,000万人減少し、労働人口は30%減少すると言われる中、国内のインフラや経済活動をいかに効率的に支えて、発展させていくかが喫緊の課題になっている。例えば、不動産や建築、建設業界の企業や行政、指定公共機関では、都市部や山間部の広域な範囲の土地状況の変遷を時系列で把握するモニタリング業務があり、慣習的には、現地への定期的な実地調査で実現されてきた。これは作業時間や作業範囲の観点で大きな制約があった。

一方で、近年、広域な範囲の土地状況を把握する代替手段として、リモートセンシングデータを活用した解析手法が提案されている。リモートセンシングの例として、航空機やUAV(ドローン)に加えて、光学衛星、合成開口レーダー(SAR)衛星などの観測衛星が挙げられる。とりわけ観測衛星のデータは、自然災害の被災状況の把握や、インフラ・地盤変動のモニタリング、農業や海洋分野での利用が広がっているが、当社はESG分野での利活用に注目しており、特に“Social(社会)”の領域での衛星データ活用に取り出した。衛星画像で都市部や山間部の変貌を確認できれば、省人化につながると思う。本稿の2章では、3章以降のAI技術のベースになるAIを用いた超解像処理について述べる。3章では、当社の土地利用分類AI技術と、その特長や適用事例を述べる。4章では、土地利用分類AI技術を活用した具体的な想定ユースケースとして、令和6年能登半島地震での事例について言及する。

## 2. MELTERRA HDの特長と事例

この章では、MELTERRA HDの特長と適用例について述べる。

### 2.1 従 来 手 法

衛星画像は、分解能(ものをどのくらい細かく識別可能かという能力)と撮像範囲、及びコストがトレードオフの関係にある。一般に、低分解能の衛星ほど広域を観測可能でコストが安く、高分解能の衛星ほど狭域の観測範囲でコストが高い傾向にある。そこで、衛星画像に超解像処理を適用すると、低コストの画像を基に、より高い分解能の画像と同等の精度を得ることでコストの低減可能、及び衛星画像の最高分解能を超える分解能を実現して航空写真やドローン撮影の代替可能、といったメリットがある。そこで、衛星画像へのAIを用いた超解像処理の適用が進められているが、偽像の発生等の課題があった。

### 2.2 MELTERRA HDの手法

当社では、これまでの光学衛星開発で実績がある高精度な衛星画像シミュレーション技術を持っている。そこで、AI



超解像の学習データに用いる低解像度画像と高解像度画像のペアをシミュレーション技術によって作成し、現実の衛星画像の劣化に即した超解像モデルを学習することで、高精細な超解像処理を達成するMELTERRA HDを開発した(図1)。

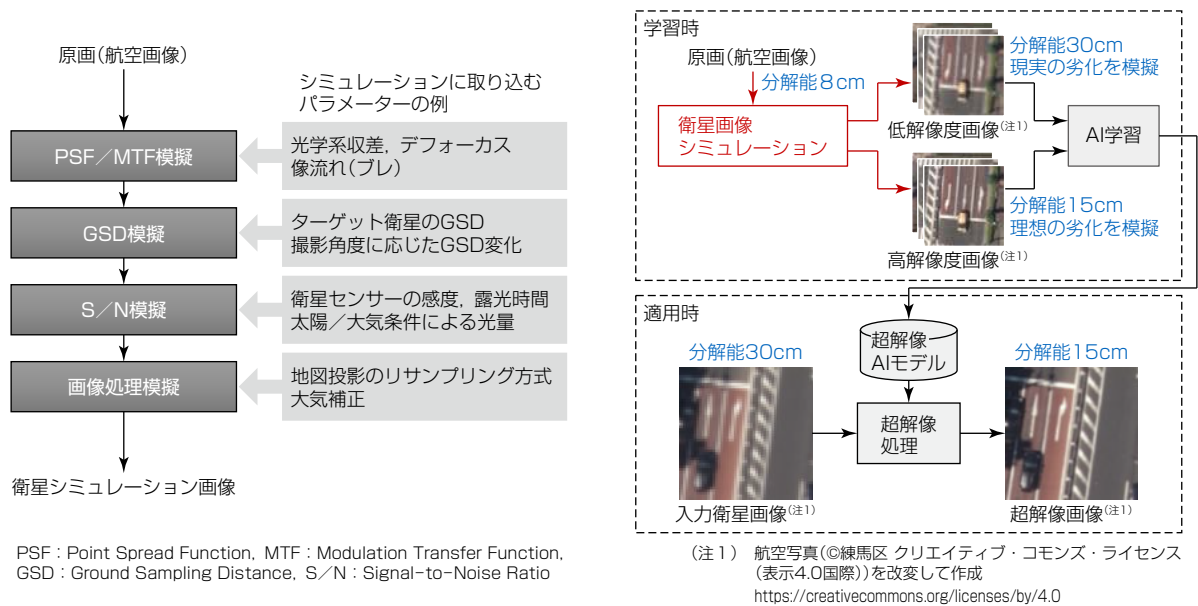


図1-MELTERRA HDのアルゴリズム

### 2.3 MELTERRA HDの例

MELTERRA HDを適用することで、オリジナル衛星画像から分解能の向上が可能になった。図2は、分解能30cmの衛星模擬画像から、MELTERRA HDによって分解能を15cm相当に向上させた例である。超解像処理後の画像は分解能が向上し、建設中の建物の様子や車両の詳細な形状まで判読可能になった。




図2-MELTERRA HDによる超解像処理の例

## 3. MELTERRA ランドスキャンの特長と事例

この章では、MELTERRA ランドスキャンの特長と適用例について述べる。

### 3.1 従来手法

衛星画像が持つ広域性・網羅性という特長を余すことなく活用するためには、広範囲の土地利用状況を衛星画像から識

別することが重要になる。しかし、広域の識別には時間と、また識別に熟練した多くの技術者が必要である。これを全て人手で行うのは難しいため、処理の自動化が求められる。国内の先行的な取組みとして、JAXA(国立研究開発法人 宇宙航空研究開発機構)地球観測研究センターが公開した日本国内の土地利用、及び土地被覆マップを示すJAXA高解像度土地利用土地被覆図(JHR LULC Map)<sup>(1)</sup>がある。JHR LULC Mapは、光学画像とSAR画像の両方を使用して10～50mの空間解像度で作成している。

### 3.2 MELTERRAランドスキャンの手法

当社は独自の機械学習モデルを使用し、衛星画像から土地利用の状況をサブメートル単位で自動的に分類するMELTERRAランドスキャンを開発した。MELTERRAランドスキャンの分類作業は、画像の1画素単位で行われるため、センチメートル級の高分解能画像からメートル級の画像まで幅広く対応する。図3にMELTERRAランドスキャンを用いて鎌倉市の土地利用分類を実施した例を示す。MELTERRAランドスキャンの分類結果を活用すると、緑地、建物、道路、水域などの変化を自動的に検出し、これらの面積の変化を定量的に分析できる。



図3- 高分解能光学衛星(Worldview-3)から土地利用AIを実行した例

また、図4にJHR LULC MapとMELTERRAランドスキャンの比較を示す。10m分解能のJHR LULC Map(図4(a))では、住宅地一帯を都市部として識別するが、Worldview-3画像にMELTERRAランドスキャンを適用した結果(図4(b))では、衛星のネイティブ分解能である30cm分解能の分類を実現しており、各戸建ての宅数、サイズ、道路、周囲の緑地などを高精度に識別可能である。なお、この技術は東京大学横矢研究室のグループが開発したOpenEarthMap<sup>(2)</sup>の成果を利用している。さらに、この技術と当社の超解像技術(MELTERRA HD)との組合せで、使用する衛星画像よりも更に高い分解能での分類が可能になった。

### 3.3 エキスパートモデルを用いた活用事例

特定の土地利用種別に着目する場合には、その種別に特化したエキスパートモデルを用いることで抽出精度の向上が可能になる。図5に、1m分解能の衛星で小型コンステレーションを形成するSatellogic<sup>(注2)</sup>衛星の画像を用いて建物検出した結果を示す。中分解能の小型衛星画像からでも、住宅地の個別の建物を識別している。これは、小型衛星を活用した低コストかつ高頻度なソリューションを実装する上でも、市街地での建物の変化の検出や災害時の被災状況の早期把握が可能であることを示した。

(注2) Satellogicは、URUGUS S.A.の登録商標である。






図4-JHR LULC MapとMELTERRAランドスキャンの比較




図5-Satellogic衛星画像から建物検出を実施した例

### 3.4 定量的な土地利用変化の把握

MELTERRAランドスキャンによる土地利用解析技術は、高度な機械学習モデルを使用して衛星画像から土地の現状を正確に把握し、その変化の時系列追跡が可能である。この技術はターゲットになる衛星画像に対して、モデルを特化させることで、その地域特有の特徴を反映した土地利用状況の解析を実現する。これによって、観測された瞬間の土地の状況だけでなく、時間経過による変化も定量的に捉えることが可能である。

図6に、2014年から2022年のWorldview-3画像を用いて、AI技術を活用して土地利用の変化を検出し、緑地や建物、道路などの面積の増減を具体的に示した結果を示す。この結果は、都市計画や環境管理の意思決定で重要な情報になると考える。例えば、自治体が進めるまちづくりの施策の効果について、接する緑地の割合や建物の更新率等の土地利用の変化を通した定量的な評価によって、政策の有効性の検証や今後の計画策定が可能になる。

### 3.5 想定ユースケース

3.4節までに述べた結果は、MELTERRAランドスキャン技術が持つ可能性を示しており、土地利用の分析だけでなく、都市計画、環境保全、災害対策など幅広い分野での応用が期待される。定量的なデータに基づく意思決定支援は、持続可能な社会の実現に向けた重要な一歩になると考える。当社が想定する具体的なユースケースの例を次に示す。





図6－高分解能光学衛星(Worldview-3)から定量的な土地被覆量を算出した結果

### 3.5.1 生態環境の監視

生態環境への監視は、環境変化、特に人間活動による影響を把握し、対応策を講じるために使用される。図7は、2016年と2023年の神戸市の空中写真を分析した例である。MELTERRAランドスキャンが県道周辺の法面工事の変化を



(注3) GeoSpaceは、エヌ・ティ・ティ・インフラネット㈱の登録商標である。

図7－MELTERRAランドスキャンを用いて法面変化を捉えた例



正確に検出したことを示す。この分析は、法面の維持管理や災害リスク評価での重要な支援ツールになると考える。衛星データを活用すれば、従来の現地調査に代わる手法として、より広範囲で迅速かつ効率的に法面の状態を把握し、必要な対策を講じることが可能になると考える。

### 3.5.2 都市拡大モニタリング

都市拡大モニタリングは、都市部の成長や拡大の監視に役立つ。この技術の活用で、都市開発のパターンや速度を理解可能になる。図8は、2014年と2023年の鎌倉市のWorldview-3画像を分析し、分譲地の宅地開発を検出した事例である。この分析は、建築・建設・土木の営業活動を代替し、支援可能なツールになると考える。衛星画像の時系列変化を見ることで、現地に赴くことなく、各業種にとって適切な営業のタイミングを見つけることが可能になる。



図8-MELTERRAランドスキャンを用いて分譲地の宅地開発を検出した例

### 3.5.3 被災状況把握

図9は、災害発生前後の地表の変化を検出したものである。災害発生前後の地表変化の検出によって、災害対応や復旧計画の策定に役立てることができる。特に衛星画像の広域性を生かして、建物被害が深刻なエリアや、通行可能な道路を抽出することで、被害の全容を瞬時に把握する。なお、この事例については、4章で詳しく述べる。




図9-MELTERRAランドスキャンを用いて被災した建物を抽出した例



### 3.5.4 建築物の情報更新

都市部や郊外の建築物の情報更新は、都市部の建物の変化を検出し、建築物データベースを最新の状態に保つ。また、自然災害などによる建物の損傷を評価し、復旧計画の立案に利用可能である。図10に、湘南鎌倉総合病院の増改築及び増築された建屋の面積を検出した事例を示す。建物の増改築は不動産の評価額に影響を及ぼすため、従来人手や航空機で行われてきた実地調査であるが、衛星からの自動解析で支援が可能である。




図10-MELTERRAランドスキャンを用いて湘南鎌倉総合病院の増改築を抽出した例

### 3.5.5 森林伐採監視

図7の事例の応用で、違法な伐採活動や森林の健康状態を監視し、環境保護政策の策定へ貢献できる。MELTERRAランドスキャンは広範囲の森林をリアルタイムで監視可能なため、違法伐採の兆候を即座に検出可能である。このアプローチは、地球規模での森林保護努力に大きなポテンシャルを持ち、環境保全と資源管理の改善に寄与する可能性がある。

### 3.5.6 スマート農業

図7の事例の応用で、農地の健康や作物の成長を監視し、最適な灌漑(かんがい)や肥料施用のタイミング等を判断することで、農業効率の向上に貢献可能である。このアプローチは、資源の効率的な利用と持続可能な農業生産性の向上に寄与する可能性がある。

## 4. 令和6年能登半島地震での適用例

この章では、MELTERRAランドスキャンを用いて令和6年能登半島地震での建物被害把握を実施した結果について述べる。

### 4.1 令和6年能登半島地震での適用例の概要

2024年1月1日に発生した令和6年能登半島地震では、住宅の甚大な被害として、石川県内で全壊5,910棟、半壊16,231棟などが報告されている<sup>(3)</sup>。被害が広範囲であったため、全容把握に労力と時間を要した。また、余震が続く中で被害把握には困難な場合も多かった。そこで、近年広域の被災状況を把握するための現地調査に代わる代替手段として、衛星によるリモートセンシングデータの活用が進められている。例えば、令和6年能登半島地震でも、様々な枠組み

の中で地球観測衛星による緊急観測が行われ、その衛星データの解析結果が活用された。当社でも衛星を利用した観測ソリューション技術であるMELTERRAランドスキャンを用いて災害被害把握を実施し、被害状況把握を支援した。そこで、MELTERRAランドスキャンを用いた被災把握の結果と、目視での判読結果との定量的評価の実施結果を述べる。

## 4.2 従来手法

3.1節に述べた理由から、広範な土地利用状況を衛星画像から正確に識別するためには自動処理が必要である。国内では、国立研究開発法人 防災科学技術研究所が災害対応に必要な情報を集約し、統合的に発信している防災クロスビューがある<sup>(4)</sup>(図11)。防災クロスビューの建物被害推定では、震動分布の推定結果を使って、建物構造、被災度、耐震基準・年代ごとに異なる被害関数を適用し、250mメッシュごとの被害率、建物被害棟数を計算し表示している。




図11-従来手法(防災クロスビュー)によって建物被害を抽出した例

また、従来の建物被害状況把握の手法として、航空写真や光学衛星画像から目視判読によって建物被害を抽出する手法がある。図12は、令和6年能登半島地震で被害が大きかった輪島市の建物被害を抽出した例であるが、図中の黄枠の範囲の判読を1人で実施した結果、数時間を要した(約360棟の建物へのラベリングを実施)。このように、従来手法でも建物単位での被害把握は可能であるが、時間とコストがかかる問題があった。そのため、時間とコストをかけずに建物単位での被害状況を把握する技術の開発が必要であった。そこで、令和6年能登半島地震の建物被害抽出にMELTERRAランドスキャンを適用した。

### 崩壊の判断基準

- ・ European Macro-seismic Scale (EMS-98)のGrade5に相当する崩壊
- ・ 地震被害調査のための建物分類と破壊パターン(日本建築学会構造系論文集第524号66-72)の木造軸組工法の崩壊も参照



背景に国土地理院の空中写真を使用

2010 HAITI EARTHQUAKE Final Report記載のGrade5建物例



背景に国土地理院の空中写真を使用

目視での建物崩壊判読結果

判読作業時間: 数時間(360個の建物のラベリング)

図12-従来手法(航空写真からの判読)によって建物被害を抽出した例

図13に、MELTERRAランドスキャンを用いた建物単位の被害解析と建物被害解析のフローを示す。今回は災害前後の航空写真を用いた。災害前後の航空写真にMELTERRAランドスキャンを実施し、それぞれの土地利用分類を算出した。次に、災害前後の土地利用分類から建物の分類結果から差分を抽出し、変化建物ポリゴンを抽出した。この変化建物ポリゴンが建物被害抽出結果になる。なお、図13のフローについて2枚の画像から建物被害までの処理時間は5分で



ある。AI建物被害解析を能登半島全域に実施した例を図14に示す。図14の範囲の処理に要した時間は1時間強であった。例えば図14左の輪島市を拡大していくと、先に述べた解析結果と同じ結果が確認できる。




図13-建物単位の被害解析の例と解析フロー




図14-能登半島全域での建物単位の被害抽出例

### 4.3 評価

建物被害解析結果の精度評価のために、防災科学技術研究所が実施した輪島市の被害判定結果との比較を実施した。図15に現地調査結果を示す。なお、現地調査結果では、ダメージグレードをD0～D5まで分類していたが、航空写真からD0～D4の識別は困難ため、D5と火災を対象とした。

今回能登半島全域に対して、提案手法を適用した。適用結果の一部を図16に示す。図16に白色で示された場所は建物に大きな被害があると予想される場所である。また、黒色で示された場所は、雲による遮蔽で建物が検出できなかったエリアである。背景及び検出処理を実施した画像は、国土地理院が公表している2024年1月5日に撮影された航空写真である。

表1に、建物被害解析結果及び目視判読結果と現地情報との精度評価結果を示す。両結果を比較すると、適合率はあまり変わらないが、再現率を見ると建物被害解析結果が低いことが分かる。これは、倒壊した建物を見逃した事例が多いことを示している。一方で、建物被害情報の作成時間を見ると、図16の青枠の範囲で12倍以上の速度で建物被害解析が結果を算出していることが分かる。したがって、この解析結果で建物被害と判定した箇所は、実際に建物被害が発生したと判断し、建物被害が少ない箇所の現地調査に注力することで、現地調査の負荷を低減可能と考える。ただし、安全サイドの考え方では、見逃し率が高いのは問題であると考ええる。

- ・能登半島の20エリアを選定し、そのエリア内の建物1棟ごとの被害判定の結果を現地調査
- ・地震被害調査のための建物分類と破壊パターンのD0～D6及び火災で分類<sup>(5)</sup>
- ・比較対象は、崩壊(Destruction)の現地調査結果D5以上と火災
- ・今回は青枠の範囲の精度評価を実施

| Damage Grade | D-level | 定義                                 |
|--------------|---------|------------------------------------|
| 0            | D0      | 被害なし                               |
| 1            | D1      | 仕上げ材ひび割れ                           |
| 2            | D2      | 仕上げ材剥落                             |
| 3            | D3      | 剪断ひび割れ・構造被害。層変形無し                  |
| 4            | D4      | 結合部連結性喪失、層変形有り、バンケーキ状崩壊無し          |
| 5            | D5      | 1階の1/2～3/4破壊、もしくはそれ以外の階でバンケーキ状崩壊発生 |
| 6            | D6      | 全層バンケーキ状崩壊                         |



図15-現地調査結果




図16-JHR LULC MapとMELTERRAランドスキャンの比較

表 1-AIによる建物被害解析結果及び目視判読結果と現地情報との精度評価結果

|                    |                  | AI建物被害解析結果の精度 |     | 目視判読結果の精度 |     |
|--------------------|------------------|---------------|-----|-----------|-----|
|                    |                  | 最高値           | 最低値 | 最高値       | 最低値 |
| 正答率<br>現地情報との      | 正                | 237           | 134 | 296       | 75  |
|                    | 誤                | 60            | 444 | 37        | 467 |
|                    | 適合率              | 0.80          |     | 0.89      |     |
|                    | 再現率              | 0.64          |     | 0.80      |     |
|                    | F値(適合率と再現率の調和平均) | 0.71          |     | 0.84      |     |
| 解析範囲の建物被害情報の作成時間   |                  | 5分            |     | 1時間～数時間   |     |
| 能登半島全域の建物被害情報の作成時間 |                  | 1時間強          |     | 1日～数日     |     |


4.4 見逃し事例

図17は、建物被害解析で見逃した建物倒壊の例である。左図は建物の2階はそのまま、1階が押し潰(つぶ)されていることが分かる。また、右図は1階が押し潰されて家屋が傾いていることが分かる。このような事例の場合、上空から一見すると屋根部分は変化がないように見えるので、AIによる土地被覆分類で“被害なし”と誤抽出されることが考えられる。今後はこれらの見逃したケースについて、AIに追加学習させることで精度向上を図る予定である。

4.5 令和6年能登半島地震への適用のまとめ

MELTERRAランドスキャンを用いて能登半島地震での建物被害把握を実施し、目視での判読結果との定量的評価を実施した。その結果、適合率0.80、再現率0.64の結果を得られた。再現率が低い理由が、1階が押し潰されたような被害事例であったため、今後は他エリアや衛星画像での検出評価も実施するとともに、押し潰されたような建物被害への学習を進めていく。



図17-建物被害解析で見逃した建物倒壊例<sup>(6)</sup>

## 5. む す び

日本での人口減少と労働力不足の問題に対処し、国内のインフラや経済活動を支えて、発展させるためのリモートセンシング技術の活用について述べた。特に、衛星画像を用いた土地利用状況の自動分類技術MELTERRAランドスキャンの開発とその応用可能性に焦点を当てた。また、令和6年能登半島地震の事例からMELTERRAランドスキャンが実用に耐える精度を持つことが確認できた。これによって、従来の現地調査に代わる効率的な手法として、広域な範囲の土地利用の変遷を時系列で把握し、都市部や山間部での環境変化の監視、災害管理、都市計画、環境保全など幅広い分野での意思決定支援に貢献することが示された。この研究が提供するリモートセンシングデータの活用は、社会的課題への対応だけでなく、当社が発信するESG分野でのサステナビリティイノベーションに向けた一歩になる。今後も技術の進化とともに、これらの応用範囲の拡大と精度向上を実現する。

## 参 考 文 献

- (1) JAXA：高解像度土地利用土地被覆図  
[https://www.eorc.jaxa.jp/ALOS/jp/dataset/lulc\\_j.htm](https://www.eorc.jaxa.jp/ALOS/jp/dataset/lulc_j.htm)
- (2) Xia, J., et al. : OpenEarthMap: A benchmark dataset for global high-resolution land cover mapping, 2023 IEEE/CVF Winter Conference on Applications of Computer Vision, 6254~6264 (2023)
- (3) 内閣府：令和6年能登半島地震に係る被害状況等について  
<https://www.bousai.go.jp/updates/r60101notojishin/r60101notojishin/index.html>
- (4) 国立研究開発法人 防災科学技術研究所：防災クロスビュー：令和5年石川県能登地方を震源とする地震  
<https://xview.bosai.go.jp/view/index.html?appid=6ee66425288a4778ac62c517bade15f5>
- (5) 高井伸雄，ほか：地震被害調査のための鉄筋コンクリート造建物の破壊パターン分類，日本建築学会構造系論文集，66，No.549，67~74 (2001)
- (6) 一般社団法人 日本住宅基礎鉄筋工業会：能登半島地震の現地調査 第二報 (2024)  
<https://www.jhr-net.jp/serialms05>

# 社会インフラ事業分野でのデータ分析を活用したソリューション創出の取り組み

*Solution Creation Methods Utilizing Data Analysis for Social Infrastructure Systems*

上野洋平\*  
Yohei Ueno  
今井 健\*  
Ken Imai  
山田知史†  
Satoshi Yamada

大林昌則†  
Masanori Obayashi

\*先端技術総合研究所  
†神戸製作所

## 要 旨

社会インフラの監視制御システムに注目し、システムに記録された膨大な計測データを分析することで、オペレーションの理解とソリューション創出を促進する手法を開発した。社会インフラのオペレーションは、安全性、経済性、環境性などの目標が複合的に存在しており、これらを体系化することは困難である。そこで、オペレーターの認知手法を参考に、計測データからプラント状態モデルを作成する手法を開発した。この手法を用いることで、膨大な計測値データをパターン化でき、データからオペレーション上の目標や課題を容易に発見できるようになった。また、分析結果をシステム要求分析に用いることで、オペレーターと開発者間の認識共有を促進し、ソリューションの共創につながると考えている。

## 1. ま え が き

上下水道、道路、河川、鉄道など、社会インフラ事業は、人々の生活を支える上で重要な基盤であるだけでなく、その規模の大きさから、エネルギー利用や環境負荷等、社会に与える影響が大きいという特徴がある。そのため、これらの社会インフラ事業では、安全かつ安心な運営に加えて、経済的、環境的側面からも、適切な事業運営を行うことが求められている。

また、社会インフラは一般的な工場生産工程と異なり、天候や市民動態など外部に起因する影響を強く受けるという特徴がある。起こり得る様々な状況に対応するため、各設備にバッファを持たせるとともに、オペレーターによる柔軟な判断を基に運転が行われているが、一方で、これらの状況判断と自由度は、運転操作での技術継承を困難にさせる一つの要因になっている。

このような課題に対して、近年急速に発展しつつあるIoT(Internet of Things)技術を活用し、インフラ運営の効率化と安全性向上を両立させるための取り組みが検討されている<sup>(1)(2)</sup>。運転自動化、予測、異常検知など、様々な提案があるが、本稿では特に、社会インフラの監視制御システムに蓄積された操作データ、計測データに注目し、これらの情報を活用することで、オペレーターの暗黙知であった運転操作の判断基準を定量的に把握する技術について述べる。従来、個々人のノウハウとして蓄積されていたこれらの情報を整理することで、運用上重要な条件や課題を把握できる。運用高度化だけでなく、若手オペレーターの育成など、多岐にわたるソリューションの創出につながると考えている。

## 2. 監視制御システムと計測データ

この章では、監視制御システムとそこに蓄積される計測データについて述べる。

### 2.1 監視制御システムに蓄積されるデータの特徴

社会インフラ事業は、非常に広大なエリアを監視制御の対象範囲とすることが多い。効率的に情報収集を行うために、監視システムを設置し、各設備の計測値を集約して表示する手法が採用されており、大規模なプラントでは表示信号数が数千点に上る。オペレーターは、監視システムに表示された多種多様の計測値を基に、現在プラントで発生している状況や機器の状態を推測しつつ、制御指令値を設定している。一般的に、プラント運転での評価指標は、運用コスト、安全性、環境への影響など、複数の種類がある。これらの指標は、一方を改善すれば一方が悪化するようなものが多く、全体のバランスを取りながら運転が実施される。また、気象の変化や災害、機器故障などが発生した場合、通常時以上に安全性が優先されるなど、状況によって評価指標の優先度が変わることもある。

このように監視制御システムに蓄積されるデータは、時々刻々と変化する様々な運転目標や評価指標を内包している。

これらのデータを分析、解釈する場合、それらを単一の処理又は関数として扱うことは難しく、状況に応じた運用目標を正しく分類、整理することで、初めて運用の実態に即した情報の抽出が可能になる。このアプローチは様々な事業で適用可能であり、上下水道や河川管理、また電力、鉄道、ビル管理などの分野で分析と評価を実施している。

## 2.2 計測データの分類とモデル化

監視制御システムに蓄積された時系列データを解釈するに当たっては、オペレーターがシステム操作を通じて行っている認知方法を参考にモデル化を行った。上下水道での貯水池水位を例にとると、オペレーターは、システムに表示される計測値を読み取ると同時に“水位が高い”“水位が低い”などの解釈を加えている。ここでは、各計測値に統計手法を用いることで“水位高”“水位低”などの範囲を自動的に設定し、それらの組合せによってプラントの状態を定義する手法を開発した<sup>(3)</sup>。この手法によって、同じ水位が1m低下する事象に対しても、“水位高”の範囲内での変化であればプラント状態での変化は小さく、“水位高”から“水位低”への変化であれば状態が大きく変化しているという、非線形の表現が可能になる。このようなプラント状態モデルは、特に、操作入力の前後の変化を観察する際に有効であり、操作の意図や目的を俯瞰(ふかん)的に把握しやすくなる。

図1は、計測データの分類手法について示したものである。オペレーターが意図を持って貯水池水位を制御している場合、その分布は一樣分布ではなく、幾つかのクラスターに分かれることが多い。そこで、この手法では、統計手法を用いてクラスター間の境界値を自動で決定し、各クラスターにラベル付けを行うことで、プラントの状態を分類した。時系列データの変化を数値的な差分としてだけ捉えるのではなく、状態遷移として扱うことで、複雑なプラント操作についても表現が容易になるという効果がある。




図1-計測データの分類手法

## 3. オペレーションの理解と課題抽出

この章では、社会インフラのオペレーションを理解するための課題抽出とその手法について述べる。

### 3.1 計測データの可視化

上下水道、電力、ビル等、社会インフラの監視制御システムに記録されるデータは、最終需要家である市民の生活リズムに同期したパターンを持つことが多い。これらのデータは、24時間周期の形状をベースにしつつ、気象や曜日などの影響を受けて変化するという特徴を持つ。監視制御システムに記録された長期間のデータに対して、2章で述べた分析手法を適用することで、平日-休日、晴天時-雨天時などの典型的なパターンを抽出可能になる。また、典型的なパターン分類に属さないパターンも存在することから、それらを調査することで、例外的に発生した事象を網羅的に見つけることができる。これらの例外パターンには、機器の点検や故障によって通常と異なる運転をした場合や、局所豪雨による天候の急変などの対応などが含まれることが多い。

図2は、三菱電機のオフィスでの8か月間の電力使用量データを用いて、パターン分類を行った結果について示したものである。図中の同一の色は、電力消費の類似した状態を示しており、X軸方向に日付、Y軸方向に時刻を表現した二次



元の表示になっている。ほぼ全ての期間で、0～5時と、21～23時は同一色になっており、これはオフィスから退勤したことを表している。5～21時は電力消費が増加し、特に8～17時の区間で電力消費量が高くなっており、これは就業時間と一致している。24時間を通じてY軸方向に同一色が続いている箇所は休日を示しており、7日ごとに同じような模様として表れている。

また、長期的な視点で見ると、配色の出現パターンが数か月単位で変化しており、これは季節による変化を示している。実際に、夏と秋とでは空調機の電力消費量が大きく変動しており、これらの変化が配色の変化として表れている。




図2-オフィスビル電力消費量のパターン分類事例

### 3.2 オペレーションの目標の理解

社会インフラのオペレーションでの評価指標は、動力費や薬品費などコストの削減だけでなく、水質、環境などへの影響や、安全性等、複数のものが存在している。また、気象やイベントなどの各種条件によって、特に重要とされる目標は変化していく。データからオペレーションを理解する際には、各期間での目標設定を正しく把握する必要がある。

従来、社会インフラのオペレーションを理解する際は、オペレーターへのヒアリングによる調査が実施されていた。しかし、期間によって変化する目標設定を網羅的に把握することは難しく、かつ、個人による考え方の差異もあって、全ての意見を集約することは困難であった。

そこで、オペレーションの理解に当たっては、3.1節で述べた可視化手法を用いることにした。この手法を用いると、時間による変化や季節による運転方法の変更を集約して表示できる。また、日単位でのパターン分類を行うことで、どのような操作が、どの程度の頻度で実施されたのかということを定量的に把握することが可能になった。図2のオフィスビルを例にとると、平日-休日の違いや、季節による変化がどのタイミングで起こったかについて把握できる。オペレーションのパターンから“夏季”等の期間を定義できるので、“夏季”での運転改善によってどの程度の効果が得られそうか、またどのような影響があるかについて、精度良く見積もることが可能になった。

このように、プラント状態遷移モデルを用いたパターン化によって、運用上の目標や課題をより明確に捉えることができる。また、オペレーターとのヒアリングでも、この分析結果を用いることで、暗黙知の抽出や、課題の思い起こしなどの効果が期待でき、発生頻度は低いものの、一度発生すると影響が大きいような課題を見落とすことなく発見できるようになると考えている。

## 4. ソリューションの検討

一般的に、監視制御システムに実装される運転支援ソリューションは、予測機能やガイダンス機能など、直接的な情報提供を行うものが多い。これらの機能は、あらかじめ想定された課題については効果的である一方、人口減少や環境への配慮など、将来にわたって取り組まなければならない目標については、出力精度の保証が困難であり、適用や調整に時間がかかるといった課題があった。

長期的に取り組む必要がある目標については、一般にPDCA(Plan Do Check Action)サイクルによって継続的に改善を進めることが多い。今後、インフラ建設の時代から維持管理の時代へ移行するに当たって、監視制御システムについても同様の発想が必要であり、PDCAサイクルの各フェーズでの支援機能の実装が必要と考える。例えば、計測データ分析による課題の発見支援や、オペレーションを変更した際の影響評価など、従来型のガイダンス機能にとどまらないソリューションが考えられるが、これらの機能開発では、ただアイデアを発散させるのではなく、先行して実際のオペレーションを理解しておくことで、真に解決すべき課題の把握と、効果的な機能提案につなげられると考えている。

次に、上水道を例に、計測データを用いたソリューションの検討事例について述べる。ここでは、上水道のデータに2章で述べた分析手法を適用し、オペレーションパターンを可視化して、“晴天時”“雨天時”などのパターンに分類した。ここで、“雨天時”とは、降雨によって河川水質(濁度)が一時的に悪化した期間を意味しており、実際の降雨期間とは異なる。通常、河川濁度の上昇は雨がやんだ後も一定期間継続するため、浄水処理における“雨天時”は、“雨天時用のオペレーションを継続する期間”として定義した。分析結果を用いて上水道事業者へのヒアリングを行った結果、雨天時の薬品注入制御に関して運転支援のニーズがあることが分かり、具体的なソリューションの検討を開始することになった。

図3は、当社と上水道事業者との協議によって創出されたソリューションの事例について示したものである。機能検討では、ガイダンス情報の提示にとどまらず、過去事例の振り返りのための機能や、オペレーションパターンの変更に伴う影響評価など、様々なユースケースとアイデアを創出できた。これらはどれも、計測値データ分析から得られた情報を基に、オペレーターと開発者との間で認識を共有することで得られたものであり、計測データ分析やパターン化は、関係者間のコミュニケーション促進としても効果があるとの知見が得られた。




図3-上水道向け薬品注入ソリューションの検討例

## 5. む す び

社会インフラ事業分野で、監視制御システムに蓄積された時系列データを基に、プラントの状態遷移モデルを作成する手法と、状態遷移モデルを活用したソリューション創出の事例について述べた。社会インフラオペレーションに関するニーズは日々変化しており、現在実施中の操作内容をデータ分析によって定量的に把握し理解することは、新しいニーズの抽出やソリューションの創出に有効であると考えている。また、今回述べた上下水道事業以外でもこの分析手法を適用したソリューション検討を開始しており、今後もソリューション創出のための基盤技術開発として、手法改善とツール化の検討を進めていく。

## 参 考 文 献

- (1) 後藤田 佳, ほか: 上下水道向けデータ利活用ソリューション, 三菱電機技報, **97**, No.7, 5-01~5-07 (2023)
- (2) 西田孝平, ほか: 豪雨時の原水濁度予測および運転支援システムの開発, 令和6年度全国会議(水道研究発表会)講演集, 190~191 (2024)
- (3) 今井 健, ほか: プラント状態分類技術の下水処理場監視制御データへの適用性検討, 下水道研究発表会講演集, **60**, 1192~1194 (2023)





# IoT機器のデータ統合分析基盤 “KOTOLiA”

伊藤山彦\*  
Takahiro Ito  
古賀宗典\*  
Munenori Koga  
海津洋介\*  
Yosuke Kaizu

林 卓人\*  
Takuto Hayashi

*Integrated Data Analytic Platform for IoT Devices "KOTOLiA"*

\*IoT・ライフソリューション新事業推進センター

## 要 旨

家電製品や空調設備などインターネット接続されたIoT(Internet of Things)機器の運転データをクラウド上に収集・蓄積し、新機能・新サービスの開発や製品保守の効率化等に利用するデータ統合分析基盤“KOTOLiA”を開発した。KOTOLiAの導入によって三菱電機内の様々なプロジェクトで収集されたデータを統一形式で一元的に管理し、必要なときに速やかに分析することが可能になった。開発と並行してデータ分析支援活動を進めることによって、KOTOLiAの登録者数は400人に達して、オフィス空調の状態監視ダッシュボードやおやすみサポートサービスの開発に結び付いた。今後、KOTOLiAの利便性向上を図るとともに、他システムと連携してデータ利活用の範囲を広げる予定である。

## 1. ま え が き

パブリッククラウドの普及で大量のデータを低コストで管理することが可能になったことによって、多くの企業がクラウド上でデータを利活用することに関心を持つようになった。データの重要性が認識される一方で、製造業でデータの利活用を普及させるためには幾つかの課題がある。一つは、データを収集した部門がデータを自部門の目的のためだけに利用するため、他部門からアクセスできず部門間でのデータ共有や活用が滞る、いわゆるデータのサイロ化の問題が起き得ることである。もう一つは、データの利用者の多くは製品の開発者であってITの専門家ではないため、データ分析のノウハウを十分に備えていない場合が多いことである。

当社は、データ統合分析基盤KOTOLiAを開発し、異なる業務に携わる非IT専門家の利用者に対して、家庭やオフィスに設置された製品の運転データを共通の方法で利用できる環境を整備した。一般にIoTデータを含むビッグデータには、Volume(多量性)、Velocity(速度)、Variety(多様性)、Veracity(正確性)、Value(価値)、及びVariability(変動性)などの特徴があることが知られている。KOTOLiAのデータ処理では多種多様な製品を扱うことによる多様性と、新しいモデルや新機能が常に追加されることによる変動性への対応が課題になる。

本稿では、データの多様性と変動性に対応し、異なる職務の利用者の目的に合ったデータの利活用を可能にするデータ処理とシステムアーキテクチャーについて述べるとともに、データ利活用の事例、運用や利用者サポート業務を通じて達成した効果、得た知見、及び今後の開発について述べる。

## 2. システム構成

この章では、KOTOLiAのシステム構成について述べる。

### 2.1 全 体 構 成

KOTOLiAは、Amazon Web Services(AWS)<sup>(注1)</sup>上に実装されている。家庭やオフィスに設置された機器の運転データは、まず機器クラウドに収集される。機器クラウドは社内の各部門が運用するクラウドであり、当社IoT共通プラットフォーム“Linova”、ホームエネルギーマネジメントシステム、ルームエアコンを遠隔から制御する“霧ヶ峰REMOTE”、ビル空調のクラウドサーバーなどを含む。KOTOLiAのストレージは、機器クラウドから収集したデータを機器クラウドと同じ形式で蓄積するデータレイク、データレイクのデータを分析用にSQL(Structured Query Language)で検索可能なテーブル形式に整形したデータウェアハウス(DWH)、及びDWHからデータ分析の目的に合わせて抽出したデータを個別のテーブルとして管理するデータマートの3階層で構成される。KOTOLiAは、機器データのほかにも機器利用者のスマートフォンアプリから取得できる機器利用情報や、市販の気象情報配信サービスが提供する気象データも収集し、機

器データと合わせてデータ分析に利用することを可能にする。利用者は、DWH又はデータマートをSQLで検索し、抽出したデータをグラフで可視化するためのBusiness Intelligence(BI)ツールやAIツールを使用してデータ分析することが可能である。また、データをダウンロードして、利用者が使い慣れたツールを使用して分析することもできる。KOTOLiAのシステム構成を図1に示す。

(注1) Amazon Web Services, AWSは、Amazon Technologies, Inc.の登録商標である。




図1-システム構成

## 2.2 DWHとデータ変換処理

KOTOLiAのDWHの構成はスタースキーマに基づいている。スタースキーマのファクトテーブルには機器の設定値やセンサー値の時系列データが格納され、ディメンションテーブルには物件や機器の情報が格納される。DWHはデータの形式や仕様を統一して管理するためのストレージであるが、利用者にとっては本来の業務で使い慣れたプロパティ名やプロパティ体系でデータを扱えることが望ましい。このため、KOTOLiAのDWHは、機器クラウドのデータ仕様で格納する個別DWH、プロパティ名やデータ型などを業界標準のECHONET Lite<sup>(注2)</sup> Web API(Application Programming Interface)仕様で統一した標準DWH、複数の標準DWHのファクトテーブルを一つのテーブルに統合した統合DWHの3階層の構成としている。社内で使用されるプロパティ形式に慣れた製品の開発者は個別DWH、他社の製品との比較などのため業界共通のプロパティ形式での分析が必要な利用者は標準DWH、複数のデータ収集元クラウドのデータを連携させて新サービスを開発したい利用者は統合DWHを参照してデータを分析するなど、分析者の目的や業務内容に適した仕様のデータが参照可能になる。

データレイクのデータをDWHに登録する処理はETL(Extract Transform Load)処理と呼ばれる。KOTOLiAでは、日本国内の利用者がDWHにほぼアクセスしていない時間帯(毎日0:00から8:00)にETL処理を起動し、前日分のデータをDWHに追加する。ETL処理では、データ管理構成(例：キーバリュー型とリレーショナル型)、プロパティ名(例：“postal\_code”と“zip-code”)、プロパティ体系(社内体系とECHONET Lite Web API体系)、単位(例：“Wh”と“kWh”)、データ表記(例：16進数を表す接頭辞“0x”と接尾辞“H”)等を統一し、データの多様性を解消する。

新モデルや新機能の追加によってデータ型が不明な未定義データが発生した場合、未定義データを誤ったデータ型でDWHに登録することを防ぐ必要がある。KOTOLiAは、利用者が通常参照する利用者参照テーブルの前段に全てのデータを一旦文字列型で格納する定義前テーブルを設けて、定義済みのデータだけを利用者参照テーブルに登録する構成にしている。未定義データは、データの定義が確定した後で利用者参照テーブルに登録される。データの定義確定前に未定義データの内容を確認したい場合は、文字列型のデータとして定義前テーブルから参照可能である。

なお、定義前テーブルはETL処理の負荷を軽減するため機種別に生成される。利用者参照テーブルは定義前の機種別のテーブルをViewに統合して生成される。これらDWHの構成を図2に示す。

(注2) ECHONET Liteは、一般社団法人 エコネットコンソーシアムの登録商標である。




図2-DWHの構成

### 3. データ利活用事例

この章では、KOTOLiAのデータ利活用の事例について述べる。

#### 3.1 オフィス空調の状態監視

KOTOLiAは、分析作業に直接関与していない利用者でも製品の使用状況を把握できるように、インターネットに接続された機器の数や運用状況の統計情報など一般的な情報を掲示するダッシュボードを提供するとともに、個別の部門からの要求に対応した特定用途のダッシュボードも提供する。図3は、空調機の品質管理業務を担当とするスタッフと協力して開発したオフィスの空調機の運転状況を監視するためのダッシュボードである。室内機の起動後に設定温度と室温の差が変化しない室内機とその時間帯が表に一覧表示され、利用者が詳細を確認したい“行”を選択すると、空調機器の過冷却度、過熱度、電子膨張弁開度、蒸発温度、凝縮温度などの値の変化を示すグラフが選択に応じて表示される。このダッシュボードを使用することによって、利用者は温度変化が見られない空調機に対して、運転データが正常であるか否かを確認できる。




図3-オフィス空調の状態監視



### 3.2 おやすみサポート

KOTOLiAに蓄積されたデータを使用して夏の夜間のルームエアコンの運転状況を調査したところ、多くの人が就寝時にタイマーを使ってエアコンをオフにするが、約半数の人が暑さのため目が覚めて、深夜に手でエアコンをオンにしていることが分かった。エアコン再稼働時の室温の平均値と標準偏差は各エアコンで異なる。この分析に基づいて、エアコンの利用者が深夜に目が覚める前に再起動する機能をエアコンの開発者と協力して開発した。再起動時の室温の値はエアコンごとに適切に自動調整される。この機能は“おやすみサポート”サービスとして市場に導入された。

## 4. システム導入の効果

KOTOLiA導入で得られる効果の一つは、データアクセシビリティの向上である。KOTOLiAの導入以前、データを利用するためには、データの入手のためにデータを所有する部門との交渉が必要であったほか、データ分析のための前処理やデータベース化などの処理が必要であり、データが必要になってから実際に分析を開始するまでに数週間を要した。KOTOLiA導入後は、アカウント作成のための1日で分析の開始が可能である。

もう一つの効果はデータ利活用の普及である。筆者らは、KOTOLiA導入に伴い、データ分析に関する情報共有サイトを開設し、データ分析に関するドキュメントの公開、問合せの受付、及びデータ分析のコツやヒントなどを掲載したほか、KOTOLiAの使用方法に関するハンズオンセッションやデータ分析の情報共有会議を開催した。継続的な利用者支援活動の結果、KOTOLiAの登録者数は400人に達した。

## 5. 利用者からのフィードバック

KOTOLiAの運用開始から2年経過した時点で利用者にアンケートを実施した。KOTOLiAの利用者が所属する部門の代表者21名に対して次の質問を送付し、必要に応じて代表者から部門員に展開してもらうことによって61名分の回答(複数回答あり)を受け取った。

質問1：貴部門でKOTOLiAによるデータ分析を促進するにあたり、実施してほしいイベントはありますか？

質問2：データ分析を進める上での問題や要望、その他の意見があれば教えてください。KOTOLiAに対するご要望などがあれば教えてください。その他、自由意見があれば教えてください。

表1に質問1に対する回答を示して、表2に質問2に対する回答を示す。

表1-利用者が希望するイベント

|       | 機械学習 | SQL  | 説明会  | 可視化  | その他  | なし  |
|-------|------|------|------|------|------|-----|
| 人数    | 42   | 37   | 36   | 35   | 9    | 3   |
| 割合(%) | 68.9 | 60.7 | 59.0 | 57.4 | 14.8 | 4.9 |

表2-自由記述で受け取った意見(2名以上)

|      | No. | 問題                     | 人数 |
|------|-----|------------------------|----|
| 困りごと | 1   | データ分析のスキル不足            | 7  |
|      | 2   | 何を分析すればよいか分からない        | 2  |
|      | 3   | 分析すべき十分なデータがない         | 2  |
| 要求   | 1   | ポータルサイトやダッシュボードによる情報発信 | 9  |
|      | 2   | データ分析活動の共有             | 9  |
|      | 3   | データの範囲の拡張              | 6  |
|      | 4   | 仕様書のデータの説明の充実化         | 6  |
|      | 5   | SQL-lessツールの導入         | 4  |
|      | 6   | 個別サポート                 | 2  |
|      | 7   | データ分析に関する人材育成          | 2  |

表1では機械学習のイベントの要望が最も多く、AIを利用した高度な分析に対する期待が高いことがうかがえる。一方で、表2では“困りごと”に7名が“データ分析のスキル不足”を挙げている。“要求”のNo.1, 2, 4, 6, 7も利用者サポートに関するものであり、今後も基本的なデータ分析支援活動を継続する必要があることを示している。No.3の“データの範囲の拡張”は、出荷データや利用者属性などの運転データ以外のデータを指している。No.5の“SQL-lessツール”については、生成AIを使用したSQL作成支援ツールを公開して社内で運用を開始した。

## 6. む す び

家庭やオフィスに設置された電気製品から収集されたデータを分析するデータ統合分析基盤について述べた。IoTデータの特徴である多様性と変動性を持つデータを統合し、利用者がデータ準備のためのリードタイムなく効率的に分析することを可能にする。システムの開発に加え利用者の支援活動も継続し、IT専門家でない利用者に対するデータ分析の普及にも努めている。

今後、機器データ以外のデータへの対応や、現状1日1回であるDWH更新の頻度を上げてリアルタイム性を向上させることによってKOTOLiAの利便性を高めるほか、他システムとの連携によってデータ共有の範囲を拡大し、新たなソリューションの開発に利用していく予定である。

## 参 考 文 献

- (1) 古賀宗典, ほか: IoTデータ統合分析プラットフォームKOTOLiAの開発-システム開発-, 情報処理学会第85回全国大会講演論文集, **2023**, No.1, 429~430 (2023)
- (2) 林 卓人, ほか: IoTデータ統合分析プラットフォームの開発-ETL開発-, 情報処理学会第85回全国大会講演論文集, **2023**, No.1, 431~432 (2023)
- (3) Ito, T., et al.: An Integrated Data Analytic Platform for Internet of Things Products, 2025 IEEE International Conference on Consumer Electronics (2025)
- (4) Sasaki, Y.: A Survey on IoT Big Data Analytic Systems: Current and Future, IEEE Internet of Things Journal, **9**, No.2, 1024~1036 (2021)

~~~~~

次世代コミュニケーションサービス“AnyCOMPASS” での生成AIを活用した服薬指導、薬歴作成サービス

高野謙司*
Kenji Takano
松田悠希†
Yuuki Matsuda
園田康博*
Yasuhiro Sonoda

重富健二*
Kenji Shigetomi
中村公昭*
Takaaki Nakamura

Medication Instruction and Medication History Creation Services Using
Generative AI in Next-generation Communication Service "AnyCOMPASS"

*三菱電機デジタルイノベーション(株)
†(株)mediLab

要 旨

三菱電機の目指す“循環型 デジタル・エンジニアリング”の方針を受けて、患者の各種医療データを集約して薬局及び地域で共有・活用することで新たな価値を生み出す基盤である調剤薬局向けの次世代コミュニケーションサービス“AnyCOMPASS”を2023年にリリースした。“Serendie”（セレンディ）関連事業開発の一環として、2024年には東京大学発のヘルスケアAIベンチャー(株)mediLabと協業して、生成AIを活用してクラウド基盤上に蓄積されたデータを分析し薬剤師に提供するサービスAIアシスタントを開発した。(株)mediLabが保持している他社にはない生成AI活用技術（プロンプトエンジニアリング、RAG(Retrieval-Augmented Generation：検索拡張生成)技術、ハルシネーション対策等)を利用し、薬歴(薬剤服用歴)作成だけでなく薬剤師向けの服薬指導アドバイス機能を開発して、新たなカスタマーエクスペリエンス(CX)を提供できるサービスになっている。2024年9～11月に開催された日本薬剤師会学術大会ほか多くの展示会に参考出展を実施した。2024年11月に開催された日本薬局学会学術総会では先進事例として学会発表を行い、薬剤師からは生成AIを使い服薬指導のアドバイスが受けられることに関して非常に高い評価を得ており、2025年1月から正式リリースを開始している。

1. ま え が き

三菱電機デジタルイノベーション(株)(MEDigital)では、保険薬局向けの窓口点数計算と保険請求業務を行うためのレセプトコンピューター“調剤Melphin”(メルフィン)、電子薬歴システム“Melhis”(メルヒス)などの保険薬局向けシステムを企画・開発・販売している。現在、全国に約六万軒ある薬局の内、約七千軒の薬局に導入しており、全国シェアは約12%を占めている(業界シェア第3位)。MEDigitalではクラウド基盤上に調剤薬局向けの次世代コミュニケーションサービスAnyCOMPASSを開発し、2023年6月にサービス開始した。AnyCOMPASSは、自社のサービスだけでなく、第三者のアイデア・サービスを含めて、新たな価値を共創し、エコシステムを構築する場と位置付けている。Serendie関連事業開発の一環として、2024年に共創の一環で生成AIを活用してクラウド基盤をベースに蓄積されたデータを分析し薬剤師に新たなCXの提供を目指すサービスを(株)mediLabと協業して開発し、“AIアシスタント”として製品化した。さらに図1に示すとおり、電子薬歴から在庫管理／本部分析、レセプトコンピューターへと機能拡張を予定している。また、AnyCOMPASSはMEDigital内の他サービスへも展開を行い、MEDigitalの技術基盤として活用していく予定である。

本稿では、AIアシスタントでの生成AIの活用技術、及びこの技術で実現した他社にはない新たなCXを実現したサービスについて述べる。

2. 調剤薬局を取り巻く状況

政府が掲げる医療DX(Digital Transformation)の一環として2023年1月から電子処方箋が開始され約2年間での普及が進んでおり、2024年12月からのマイナンバー^(注5)カードの保険証利用義務化と併せて、医療情報の電子化基盤の整備が今後大きく進む予定である。さらに少子高齢化社会の本格化に伴い地域包括ケアシステムの構築が求められている中、保険薬局はこれまでの“薬を渡す場所”から、“地域での健康管理の中核プラットフォーム”への進化が期待されており、薬剤師の業務も対物から対人へのシフトが期待されている(図2)。

(注5) マイナンバーは、デジタル庁会計担当参事官の登録商標である。




図 1 -AnyCOMPASSイメージ図




図2-保険薬局業務の近未来の姿とコミュニケーションサービスの位置付け

3. 調剤分野への生成AIの活用

2023年度以降生成AI技術が目覚ましい速さで進化しており，特に言語モデルの精度向上が顕著で，より自然で人間らしいテキスト生成が可能になってきている。OpenAI社のChatGPT，Google社のGemini^(注6)，Anthropic社のClaudeなど，大規模なデータセットを用いて訓練されたモデルは，文章生成だけでなく，要約，翻訳，質問応答など，多岐にわたるタスクで高いパフォーマンスを発揮しており，ヘルスケア分野での活用も進んでいる。調剤分野での生成AIの活用としては，薬歴及び服薬情報提供書などの医療文書の作成支援に活用されている事例が出ており，特にSOAP薬歴(“S(subjective：主観的情報)”“O(objective：客観的情報)”“A(assessment：評価)”“P(plan：計画)”の四つの項目で記載した薬歴)での生成AIの活用サービスが多くの薬歴ベンダーから発表されており競争が活発になっている。

しかし，現在発表されているサービスは薬剤師と患者の会話内容を基に生成AIを活用して薬歴を作成するサービスになっており，“O(客観的情報)”と“A(評価)”などは薬剤師が画面などで確認，かつ自ら思考した内容のため，会話内容だけでは情報が足りず，追記する必要があるなどの課題が存在する。また，電子薬歴とは独立して会話内容からSOAP薬歴を単独で生成するサービスもリリースされているが，同様の理由で電子薬歴側で生成したSOAP薬歴のひな形から薬剤師が内容をコピーし，SOAP薬歴に成形する必要がある。

一方，生成AIという観点では薬剤師に対する服薬指導アドバイスでの活用が有効であるが，薬剤師の服薬指導プロセスを忠実に生成AIで実現することが難しく，かつ服薬指導アドバイスにハルシネーションが混入すると薬剤師の服薬指導業務に支障を来す。そのため，ハルシネーション対策が重要になっており，服薬指導アドバイスの領域で本格的にサービスをリリースしているベンダーは存在しない状況であった。

(注6) Geminiは，Google LLCの登録商標である。

4. AnyCOMPASSのAIアシスタントサービス

3章に述べた課題を解決し，薬剤師向けに薬歴作成支援だけでなく服薬指導アドバイスの領域も生成AIを活用して安全かつ効果的なサービスを開発するため，ヘルスケア分野での生成AI活用に対して知見の深い協業先である(株)mediLabと共同でAIアシスタントを開発した。

4.1 生成AIの活用技術

(1) セキュアな構築基盤

AnyCOMPASSはヘルスケア業界で多くの実績を保持しているAWS上にシステムを構築している。運用コストを最小化するためOS(Ubuntu^(注7))，データベース(PostgreSQL^(注8))などはライセンスフリー(OSS(Open Source Software)ほか)のものを使用し，さらにマルチテナント方式によって，サーバー資源を効率的に利用している。セキュリティの観点では政府の3省2ガイドラインにも準拠しており，クライアント証明書及び多要素認証にも対応したアーキテクチャーになっている。AIアシスタントの実装に当たってはAnyCOMPASSと同じAWS上の生成AIが標準搭載されたAmazon Bedrockを用いて，AIでの安全性重視の研究を継続的に発表することに注力しているAnthropic社のClaude 3.5 Sonnetを利用した⁽¹⁾。Amazon Bedrock及びClaude 3.5 Sonnetは国内リージョンを利用し，かつAmazon Bedrockは入力データを生成AIベンダーのトレーニングに利用しないことを保証しているためセキュリティは確保されている環境になっている。また，今後のAIガイドライン等の更新によって，更に安全性が高いモデルに切り替える場合でも，生成AI基盤モデルを柔軟に変更できるシステム及びアルゴリズム構成になっており，発展が著しい生成AIのセキュリティ動向での不確実性も吸収可能な構成にしている。

(2) プロンプトエンジニアリングによる工夫

生成AIに対する指示はプロンプト(AIに対して指示や質問を行うためのテキスト入力のこと)で行う。プロンプトは，①システムプロンプト，②ユーザープロンプトの2種類があり，①システムプロンプトでは生成AIの役割(今回は薬剤師)，状況，目的，関連知識，制約条件，出力形式(今回はJSON(JavaScript Object Notation))，ユーザープロンプトのキー説明などを定義することによって生成AIに対して薬剤師思考モデルを前提条件として提示する。②ユーザープロンプトには服薬指導を実施する患者での指導内容データベース，過去の指導実績，患者属性情報，患者基本確認情報，及び

処方内容(前回, 今回)などの患者個別情報／参考情報など多岐にわたるため, JSON形式で整理し質問を行う方式を採用した。また, 生成AIで作成された服薬指導及び薬歴の結果も同じく内容が多岐にわたるためJSON形式で回答する方式にした。

(1)(2)に述べたプロンプトの活用イメージを図3に示す。




図3-プロンプトの活用イメージ

また, 今回のプロンプトエンジニアリングでは次の二つの工夫を行った。

一つ目は, システムプロンプトの多段階化である。服薬指導業務は, ①薬剤師が患者との会話に向けて多くの情報を精査して服薬指導時に聞くべき内容の仮説を持ち, その仮説に基づいて患者との会話が行われ, ②最終的に自身の仮説と患者会話の二つの情報を用いて薬歴作成を行う, という2段階の思考モデルになる。このモデルを実現するために①の事前思考段階と②の薬歴作成段階のタスクを明確化し, それぞれのタスクを達成するためのシステムプロンプトを個別で開発した。具体的には, ①では服薬指導前を想定し, 患者基本情報と処方薬情報などのデモグラフィックな情報だけを活用して, 服薬指導ガイド・OAP(SOAPから“S(主観的情報)”を除外したもの)を作成するようなプロンプトを開発し, ②では服薬指導をした後, 患者からのヒアリング情報など患者からの詳細情報を活用し, 個別最適化したSOAPとその作成理由をアウトプットするようなプロンプトを開発した(図4)。

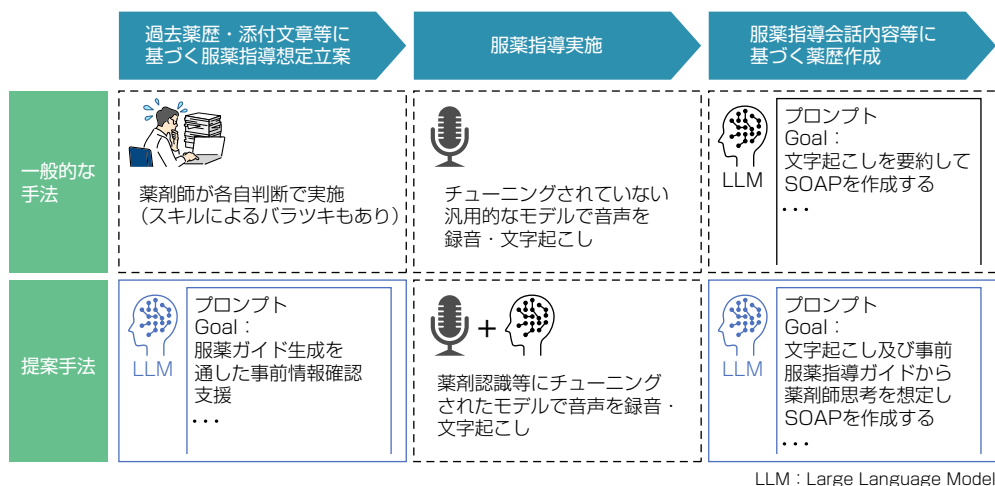


図4-プロンプトによる多段階化

二つ目は, ユーザープロンプトに入力する情報の構造化である。先に述べた多段思考プロセスで, 薬剤師は処方情報や患者属性情報全体を均一に見るのではなく, 特定の箇所に注視して情報を閲覧することが業務研究等を通して判明している。例えば今回の手法では, 服薬指導段階で事前作成したOAP, 会話情報, 前回SOAPの三つの情報に着目することで, 前回のSOAPと会話情報から患者状況に関する内容に基づいて事前作成したOAPを更新するようなタスクを定義することで, 入力情報を減らしながらも精度を維持できるような仕様にしている。このように情報の構造化を行うことによって情報ノイズが除去できるなど, 生成AIの出力を安定させる効果があり, かつプロンプトのトークン数が削減できるコストメリットもある。

生成AIはハルシネーションを発生させるリスクがあるが, 先に述べたようなプロンプトへの薬剤師メンタルモデル及び思考プロセスの注入を行う技術を活用することによって, ハルシネーションの発生を抑制しつつ, 質の高い薬歴生成を実現できた。この手法によって, 現場の薬剤師から“添付文書等を参照し, ベースとして担保すべき薬歴をAIが確実に記載してくれる安心感がある”“ここまでAIが実施できるとは正直思っていなかった”というような高い評価を得られている。

(3) RAGを用いた注入参考情報の精査とコスト適正化

このように評価を得られているプロンプト方式ではあるが、全ての処方ケースに対して添付文書情報等の多くの参考情報をモデルに注入していたため、不要なデータが参考情報に混入することによってコストの肥大化、及び標準的な提案以上は実施できない、というコスト面・性能面・内容面の課題が存在する。

これに対して、RAGの考え方をモデルに注入し、これらの課題の改善を実施している(図5)。このモデルでは、Retrieve処理として情報の一次検索を行い、その際に取得する情報の優先度をモデルに判定させた上で、コスト観点等から情報量を適切にレスポンスする方式を実現した。この際の優先度は、薬局の業務研究を通して、求められる優先度軸を定義・設計することで開発を進めている。運用上Retrieve処理とGenerate処理のどの箇所にコストがかかっているかの可視化が肝要であるため、一般的なSaaS(Software as a Service)やIaaS(Infrastructure as a Service)で提供されているRetrieve処理とGenerate処理を一括で提供するブラックボックス方式ではなく、Retrieve処理とGenerate処理のそれぞれに対してLLMをカスタマイズする形で設計・実装を進めている。




図5-RAGモデルイメージ

また、チャンク単位と呼ばれる文章のまとまりの学習データ設計(チャンキング)がRetrieveの性能向上では肝要である。Retrieve処理では検索クエリに対して、学習データ内でその意味的類似度などの指標が上位のチャンクが取得される仕様になっているため、チャンク単位の設計によって検索結果が大きく変わってしまう特徴がある。一般的には文章の文字数や章立ての単位でチャンク単位を指定するケースが多いが、このモデルでは薬剤師のメンタルモデルと学習データの特徴を考慮し、医薬品のプロブレムベースのプロブレムとSOAPをセットにした情報をチャンク単位として定義し、モデル側もそのような学習が可能のようにカスタマイズし検索結果の精度向上を目指した。

(4) Safe AIと自社業界ノウハウを用いたガイドラインへの準拠

今回開発したAIアシスタントは経済産業省の“AI事業者ガイドライン(第1.0版)⁽²⁾”に準拠するため、別添7C.具体的なアプローチ検討のためのワークシート(共通の指針/AI開発者/AI提供者)、及び医療AIプラットフォーム技術研究組合で2024年10月2日付で発出されている“医療・ヘルスケア分野における生成AI利用ガイドライン⁽³⁾”の内容を点検し、生成AI活用での技術面、運用面の課題を抽出し、各種対策を講じている。今後も各種機関からガイドラインが発出されると想定されるが、適宜内容の点検を進めて、生成AI技術を安全に活用するための技術、知見を蓄積していく。

(注7) Ubuntuは、Canonical Limitedの登録商標である。

(注8) PostgreSQLは、PostgreSQL Community Associationの登録商標である。

4.2 新たなCXの提供

4.1節に述べた生成AI活用技術を使って、AnyCOMPASSとして新たなCXの提供を目的に、服薬指導アドバイス及びSOAP薬歴の生成の2機能についてAIアシスタント機能を実現した。

(1) 服薬指導アドバイス

従来は添付文書などの内容を読んで薬剤師の能力に応じて副作用の指導などの準備を実施していたが、AIアシスタン

トによって指導内容データベース、過去の指導実績、患者属性情報、患者基本確認情報、及び処方内容(前回、今回)から、患者に合ったヒアリング内容を薬剤師に対して候補表示できる。これによって服薬指導業務ではAIアシスタントが薬剤師の業務を伴走支援するCXを提供できる。また、若手の薬剤師などは薬学的な観点で分析されたAIアシスタントからのアドバイスを活用することによって、短期間でのスキル向上が期待できる。さらに、当該アドバイスを選定した選定理由なども併せて表示することによって、薬剤師に対して当該アドバイスが選定された理由や背景なども把握できるようにしている。他社の生成AI機能が文章やSOAP薬歴の生成の範囲であることに対して、このサービスでは服薬指導のアドバイスまで踏み込んで薬剤師の支援ができる機能になっている(特許出願中)。図6にこの服薬指導アドバイス画面を示す。



図6-AIアシスタント：服薬指導アドバイス画面

(2) SOAP薬歴生成

今回開発したSOAP薬歴生成機能は指導内容データベース、過去の指導実績、患者属性情報、患者基本確認情報、及び処方内容(前回、今回)から雛形(ひながた)を生成する。そのため、情報の内容がより濃く、薬剤師が実際に記載するイメージに近い内容になるため、今までにはない新たなCXを薬剤師が体験できる。また、AIアシスタントは指導内容と薬歴記録内容を指導サマリーとして要約する機能もある。この内容を薬歴として記録することによって、当該患者への次回指導時に前回指導内容を短時間で思い出すために活用できるとともに、他の薬剤師への引継ぎがスムーズになる利点がある(2024年5月に特許取得済み)。図7にこのSOAP薬歴生成画面を示す。




図7-AIアシスタント：SOAP薬歴生成画面

このAIアシスタント機能は2024年9月から開始された日本薬剤師会学術大会ほか、多くの展示会で参考出展した際、薬剤師の人々からは、生成AIによるCX向上の観点で高い評価を受けた。

このAIアシスタントは2025年1月にサービスリリースを実施した。今後、4.1節(3)に記載のRAGの活用技術を更に追求し、服薬指導アドバイスやSOAP薬歴生成に出力される内容を強化するための研究を進める予定である。例えば、患

者向けの説明用画像もRetrieve対象にするなど，マルチモーダルな情報提供体験が実現できるサービスも検討している。医療分野では，ユーザー（薬剤師と患者）間に知識差が大きいため，画像を用いた平易な説明は患者体験向上に大きく寄与することが広く知られており，非常に重要な点であると考えている。このような技術的な拡張性も踏まえてRAGの考え方を採用しており，今後も出力内容による患者満足度の強化向上に努める。

5. む す び

エリック・トボル氏の著書“ディープメディスン⁽⁴⁾”では，“AIが提供してくれる最大の可能性は，過誤や仕事量を減らすことでもなければ，がんを治すことでもない。それは，患者と医師の間の，昔からの貴重なつながりと信頼，すなわち人間的な関わりを取り戻す機会だ。私たちはもっと時間をかけて顔を合わせ，はるかに深く心を通わせ，思いやりを抱くことができるようになるばかりか，医師志望者を篩（ふるい）にかけ養成する方法を根底から変えてしまうこともできるだろう”と述べられている。このAIアシスタントについても今後更に進化させ，薬剤師が患者に対して“思いやりを持った服薬指導”ができるサービスを目指して機能強化を図り，日本の医療の質向上に貢献していく。

参 考 文 献

- (1) Anthropic, PBC : Core Views on AI Safety: When, Why, What, and How
<https://www.anthropic.com/news/core-views-on-ai-safety>
- (2) 経済産業省：AI事業者ガイドライン（第1.0版）（2024）
https://www.meti.go.jp/shingikai/mono_info_service/ai_shakai_jisso/20240419_report.html
- (3) 非営利公益法人 医療AIプラットフォーム技術研究組合：医療・ヘルスケア分野における生成AI利用ガイドライン（2024）
https://haip-cip.org/assets/documents/nr_20241002_02.pdf
- (4) エリック・トボル：ディープメディスン，22，NTT出版（2020）

機械学習によるゴム部品の性能予測技術

Performance Prediction Technology for Rubber Parts Using Machine Learning

*先端技術総合研究所

要 旨

電機製品には種々のゴム部品が使用される。多種多様なゴム部品の中から製品に適用可能なものを見つけ出すには、複数の性能評価試験を行う必要があり、膨大な時間を要する。そこで、ゴム部品の性能評価試験の効率化を目的に、ゴム部品の性能と分析データとを機械学習させた回帰モデルによるゴム部品の性能予測技術を検討した⁽¹⁾。今回の検討では、学習データ収集に有限要素法(Finite Element Method: FEM)解析を始めとするコンピューター上の仮想実験を活用することで、実験を繰り返した場合に比べて1/10の時間で学習データの収集を実現した。開発モデルの精度検証を行った結果、ゴム部品の非線形的な荷重と変位の関係を平均84%の精度で予測可能であった。

1. ま え が き

近年、機械学習の進展によって、高速かつ効率的な材料開発が実現されつつあり、今後はより高性能な材料が短期間で市販されるようになって予想される。三菱電機を始めとする材料ユーザーでは、自社製品に適用可能な材料を迅速に見つけ出して活用することが重要になる。そこで、当社では、プラスチックやゴムを始めとする樹脂材料及びそれを用いた部品の性能を機械学習によって予測する技術を開発中である。樹脂材料は、環境要因に対する劣化が早いといった欠点があるため、製品適用までには、膨大な時間を要する種々の性能評価試験が必要になる。材料や部品の性能を推定できれば、評価試験不合格による手戻り防止や評価対象の絞り込みが可能になり、性能評価試験の効率化に貢献できる。

本稿では、そのような性能評価の効率化に貢献する、ゴム部品の性能予測技術開発の概要について述べる。

2. 学習データ収集の効率化に向けた検討

この章では、学習データ収集の効率化に向けて行った検討の内容について述べる。

2.1 コンピューター上の仮想実験を駆使した学習データの収集

この開発の特徴は、機械学習に必要な学習データの収集を、コンピューター上の仮想実験によって行ったことである。概要を図1に示す。ゴム材料の性能には、補強材として混合されるカーボンブラックの分散度合いといったマイクロ構造が影響することが知られており⁽²⁾⁽³⁾、TEM(Transmission Electron Microscope)像から特徴量を抽出して説明変数とすることを検討した。しかし、材料の試作、性能評価及びTEM像取得には膨大な時間を要する。そこで、CADによってTEM像を模擬したモデルを作成し、このモデルからマイクロ構造に関する特徴量を抽出した。さらに、目的変数であるゴム部品の性能をFEM解析によって計算した。

2.1.1 CADによるTEM像を模擬したモデルの作製と説明変数の抽出

CADによって作製した、TEM像を模擬したモデルの概要を図2に示す。カーボンブラックを模擬した円を平面状にランダムに描写することによってモデルを作成した。ゴム中に混合されたカーボンブラックとゴムの界面には、ゴムよりも高弾性な中間層が存在することが知られており⁽⁴⁾、この中間層についても同様にモデル化した。今回は円の数や直径がそれぞれ異なるモデルを100個作成し、それぞれのモデルからカーボンブラックの占める面積の割合などの特徴量を抽出した。




図1-ゴム部品の性能予測技術の概要




図2-TEM像を模擬したモデルの概要

2.1.2 FEMによる目的変数の取得

今回の検討では、目的変数に当たるゴム部品の性能をFEM解析によって収集した。FEM解析の概要を図3に示す。部品の性能としては、荷重と変位の関係、クリープ変形、シール性等があるが、本稿では、簡単な例として、短冊形状での荷重と変位の関係を予測した結果について述べる。カーボンブラックの分散度合いを始めとするミクロ構造がマクロスケールの部品の性能に影響することから、スケールの異なる構造体双方の物性、挙動を連成させるマルチスケールシミュレーションを実施した。マルチスケールシミュレーションでは、短冊状の部品の荷重と変位の関係をFEM解析2で計算する。ここで材料パラメーターとして必要な応力とひずみの関係を、2.1.1項で作成したCADモデルのFEM解析1によって取得した。この方法によって、ゴムのミクロ構造の違いで生じる材料特性の差異を、マクロな性能評価試験を模擬したFEM解析に反映させることができる。なお、FEM解析1で使用するゴム、カーボンブラック、中間層の弾性率値については、カーボンブラック未充填のゴムの試作と評価、SPM(Scanning Probe Microscopy)やAFM(Atomic Force Microscope)等の分析から推定した。

2.2 データの学習

2.1.1項及び2.1.2項の仮想実験によって収集した説明変数と目的変数を用いて機械学習を行い、予測モデルを構築した。実試験によって学習データを収集した場合、約50日の時間を要すると予想されるが、今回の検討では、約5日で完了した。すなわち、コンピューター上の仮想実験によって、学習データの収集を1/10に短縮させることができた。




図3-マルチスケールシミュレーションの概要と今回検討した部品形状

3. 予測モデルの精度検証

2章で構築した予測モデルに対して、添加するカーボンブラックの粒径や量を変えたニトリルブタジエンゴム (NBR) のTEM像から抽出した特徴量を入力して、荷重と変位の関係を予測した。結果を図4に示す。今回検討した全12条件で、カーボンブラックの粒径や量に依(よ)らず、ゴム部品の荷重と変位の関係を平均84%の精度で予測可能であった。機械学習では、予測に加えて予測に対する各説明変数の寄与度を評価できる。寄与度を解析したところ、カーボンブラックの充填量の寄与度が最も高く、次いで、カーボンブラックを模擬した円の輪郭長さの標準偏差やカーボンブラックを模擬した円の重心位置の分散度合いの寄与度が高かった。これは、ゴム部品の変形にはカーボンブラックの充填量だけではなく、粒径分布や分散度合いも寄与することを示唆する結果であった。




図4-予測モデルの精度検証結果

4. む す び

コンピューター上の仮想実験から収集した学習データを用いて、ゴム部品の荷重負荷時の変形量を予測する機械学習モデルを開発した。機械学習では、学習データの収集のコストの大きさが課題になる場合が多いが、今回の検討では、学習データの収集効率化を可能にするCADやFEMによる仮想実験の基礎技術を確立するとともに、その有効性を検証できた。

今後は、TEM像から抽出した情報だけではなく、配合に関する情報や赤外分光分析で得られたスペクトル画像などの画像情報を用いて、防振性能、シール性能、耐疲労性など、様々な性能の予測が可能なモデルの開発を検討する。

参 考 文 献

- (1) 埴 勇太郎：FEMと機械学習を活用したゴム材料の性能予測技術開発(2)，2023年日本ゴム協会年次大会，B-9 (2023)
- (2) 仲田俊夫：カーボンブラックーゴム補強性能を中心として，炭素材料学会誌，No.106，111～120 (1981)
- (3) 榊原明弘，ほか：カーボンブラックによるゴム物性の改良，日本ゴム協会誌，**73**，No.7，385～391 (2000)
- (4) 高野直樹，ほか：ナノ粒子分散材の3次元モルフォロジー分析と有限要素モデリング，材料，**57**，No.5，423～429 (2008)

~~~~~

# 生成AIによるAIチャットボットの実用化

阿部貴之\*  
Takayuki Abe  
山田篤史\*  
Atsushi Yamada  
池田貴紀\*  
Takaki Ikeda

徳富 忍\*  
Shinobu Tokudomi  
衣川英之\*  
Hideyuki Kinugawa

\*三菱電機デジタルイノベーション(株)

Practical Application of AI Chatbots Using Generative AI

## 要 旨

2023年は生成AI元年とも言われ、国内外で多くの企業が生成AI活用の取組みを始めた。同年から、三菱電機デジタルイノベーション(株)(MEDigital)でも社内問合せ業務の効率化を目指して、生成AIによるAIチャットボットの開発を開始した。生成AIはクラウドLLM(Large Language Model)を利用することによって比較的容易にシステムの構築はできるが、セキュリティ対策や実用に耐え得る回答精度へのチューニング、ハルシネーション対応など実用化には多くの課題が発生した。MEDigitalはこれらの課題を解決した。

## 1. ま え が き

2012年頃からディープラーニング等の機械学習による成果が認識され始めて、AI技術に対する関心が高まり、三菱電機・三菱電機グループでもAI開発の取組みが行われた。2022年11月にOpenAI社によってChatGPT<sup>(注1)</sup>が公開されると、従来のAIが主な活用領域としていた認識や判断ではなく、新しいものを生み出すための生成AIが脚光を浴びるようになった。この状況を受けて、MEDigitalでも生成AIを活用した業務効率化及び生成AIのノウハウ獲得を目的として、社内問合せ業務を自動化するAIチャットボットの開発を開始し、2024年11月にその実用化に成功した。

生成AIを使ったシステムは、クラウドサービスを利用することで構築自体は比較的容易に実現できるが、実用化に向けては多くの課題が存在する。

本稿では、生成AIによるAIチャットボット実用化に関する課題とその対応策、及び今後の展望について述べる。

(注1) ChatGPTは、OpenAI OpCo, LLCの登録商標である。

## 2. 生成AIを用いたチャットボット開発構想

社内規則や業務システムのマニュアル・FAQ(Frequently Asked Questions)は社内ポータルで参照できるが、利用者にとって必要な情報を見つけることが困難な場合があり、また知りたいことを質問するための問合せ先を探すことも負担になることがあった。一方、利用者からの問合せを受けるヘルプデスク側では、社内文書を参照すれば利用者自ら解決できるはずの問合せに対応しなければならないことがあり、業務量増加の一因になっていた。そこでこの業務に生成AIを活用し、問合せ業務の効率化を図るAIチャットボットを構築する方針とした。システムのコンセプトは表1に示す。

表1-MEDigitalのAIチャットボットのコンセプト

| No | 要件                   | 説明                                                                                                                                                                                                                                                       |
|----|----------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | 安心・安全に利用できるセキュアなシステム | 扱う情報が企業機密のため、AIがその情報を学習すると機密情報の漏洩(ろうえい)につながるおそれがある。また、クラウドサービスを利用する場合はネットワークセキュリティも考慮する必要がある。安心・安全に利用できるシステムにする。                                                                                                                                         |
| 2  | 利便性があり真に実用性のあるシステム   | 実用化に当たっては社内規則や業務システムの問合せ対応から始めるが、将来的には取り扱う対象を更に拡充する予定である。その際に、業務システム、社内規則など目的別に別々のシステムやシステムへの入り口を用意するとユーザーの利便性が損なわれてしまう。MEDigitalのAIチャットボットでは一つのチャットボットで多くの対象に対応できるようにする。また、開発に当たってAI技術を使うこと自体が目的にならないよう留意し、利便性が高く、予備知識のない利用者にとっても簡単に利用できるシステムにすることを目指す。 |

### 3. AIチャットボット実用化の課題

今回の開発に当たり、開発容易性、実用性の観点から生成AIのエンジンはクラウドLLMを利用する方針とした。  
次に、クラウド環境、クラウドLLMを利用することの課題とシステムコンセプトから見える主要な課題について述べる。

#### 3.1 情報漏洩リスクへの対応

クラウドLLMは様々な企業、利用者が共同利用するサービスであり、Azure<sup>(注2)</sup> OpenAI ServiceやAmazon Bedrock<sup>(注3)</sup>などが知られている。そのため社内文書をLLMに学習させると、他社や他の利用者へ情報漏洩のリスクが生じる。また、サービスによっては文書の学習以外にも、問い合わせた内容の監視や、学習データとしての二次利用でサービス提供者からデータが参照されてしまうケースがあり、意図しない情報漏洩のリスクが存在する。さらに、クラウドサービスを利用するためにはインターネットとの情報のやり取りが発生し、これに伴うネットワークセキュリティーのリスクも考慮する必要がある。

(注2) Azureは、Microsoft Corp.の登録商標である。  
(注3) Amazon Bedrockは、Amazon Technologies, Inc.の登録商標である。

#### 3.2 利便性と回答精度の両立

MEDigitalのAIチャットボットは、利用者の利便性を最優先に考えて、一つのシステムで多くの問合せ対象をカバーすることをコンセプトとしている。そのため一つのシステムに学習・登録する文書量が増える傾向があり、回答精度の低下が予想される。また、生成AIには誤った情報を生成してしまうハルシネーションと呼ばれる事象があり、どれほどチューニングを行っても100%の正答率にはならないという特性がある。MEDigitalのAIチャットボットは予備知識がない利用者が使用するシステムとして位置付けており、利便性を損なわず回答精度を高く保つ仕組みとハルシネーションへの対策を講じる必要がある。

### 4. 実用化に向けた対応

3章で述べたAIチャットボットの課題を解決し、実用的なシステムを構築する必要がある。  
課題とその対応について表2にまとめた。また対応の詳細については各節で述べる。

表2-課題と対応のマッピング

| 課題          |                           | 対応                                  |
|-------------|---------------------------|-------------------------------------|
| 情報漏洩リスクへの対応 | LLMへ社内文書を学習させることによる情報漏洩対応 | RAGアーキテクチャーとAzure OpenAI Serviceの採用 |
|             | 監視等による情報漏洩対応              |                                     |
|             | ネットワーク上での情報漏洩への対応         | イントラネット延伸によるセキュリティーの確保              |
| 利便性と回答精度の両立 | 回答精度の低下に対する対策             | 対話機能による回答精度の向上                      |
|             | ハルシネーションへの対策              | AI回答時の工夫                            |

#### 4.1 RAGアーキテクチャーとAzure OpenAI Serviceの採用

3章で述べたとおり、クラウドLLMに企業機密を含む社内文書を学習させると情報漏洩につながるリスクがあるためMEDigitalのAIチャットボットはRAG(Retrieval-Augmented Generation)アーキテクチャーを採用した(図1)。




図1-RAGアーキテクチャー

RAGはAIが学習していない情報を別の情報源から取得して利用する仕組みであり、AIへの学習をさせずに情報を利用できる。さらにAIへ学習させる方法に比べて情報の管理(登録、削除、更新)が容易という点で優れており、時間経過とともに変更される文書・情報との相性が良いことで知られている。

また、企業ユースに多くの実績のあるAzure OpenAI Serviceを採用することでMicrosoft社による高水準のガバナンスやセキュリティーで管理されたLLMを利用でき、さらにベンダーの監視等による情報漏洩リスクもオプトアウト申請によって排除できる。

## 4.2 イン트라ネット延伸によるネットワークセキュリティーの確保

MEDigitalのAIチャットボットの実行環境は、三菱電機からの技術協力も得て、三菱電機イントラネット経由でAzure OpenAI Serviceへアクセスできるように構築した。この環境を用いることでインターネット経由による情報漏洩のリスクを低減し、企業機密を安心して利用できる。

## 4.3 対話機能による回答精度の向上

RAGの特性として文書データベースに多くの文書を登録すると回答精度が悪化するため、それを防ぐために目的別に別々のシステムを用意したり、チャット時に検索範囲を事前に利用者に選択させたりする対応を行うことがある。しかし、これらの方法は利用者に“探す手間”を増やす結果になって利便性と相反するため、MEDigitalのAIチャットボットではこれらの方法とは異なるアプローチでこの課題を解決した。

RAGの文書登録から回答生成までの流れと回答精度悪化のメカニズムについて図2に示す。文書は任意の長さで区切ったチャンクという単位に分割されて文書データベースに登録される。図中の“社内規則”は社内規則文書に関するチャンク、“システム”は業務システム文書に関するチャンクを表現している。検索は文書データベースに入っている全チャンクを対象に行われ、検索結果を用いて回答を生成する仕組みである。




図2-回答精度悪化のメカニズム

回答精度悪化については、文書データベース中に類似ワードが多く存在する場合、質問の意図に沿わないチャンクが検索されることが原因であった。これが検索精度の低下を引き起こして、ひいては回答精度の悪化につながっていた。

そこでユーザーの利便性を損なわず課題を解決するための仕組みとして、問合せ内容に応じてチャットボットが利用者と対話を行うことで検索精度を高める仕組みを開発した。対話機能による回答精度向上の仕組みは図3、対話のイメージは図4に示す。この仕組みを用いることで、利用者の“探す手間”を軽減しつつ、システムの回答精度の向上を実現した。

## 4.4 AI回答時の工夫

ハルシネーションへの対応のため、図5に示すとおり、回答の文章に加えて、AI回答に対する注意喚起、引用元文書への参照、ヘルプデスクへの連絡先を提示する機能を具備した。利用者はAIの回答文に疑義がある場合は引用元文書を参照でき、それでも問題が解決できない場合は担当業務のヘルプデスクへ簡単にアクセスできる。またその際、問合せ内容に応じて異なるヘルプデスクへの連絡先を提示でき、複数の対象を取り扱っても一次窓口を必要としない。これによって予備知識がない利用者に対して探す手間を低減し、精度が100%ではない回答に対するセーフティーネットを用意することで、無人の一次窓口としてのシステム利用が可能になった。






図3-対話機能による回答精度向上の仕組み

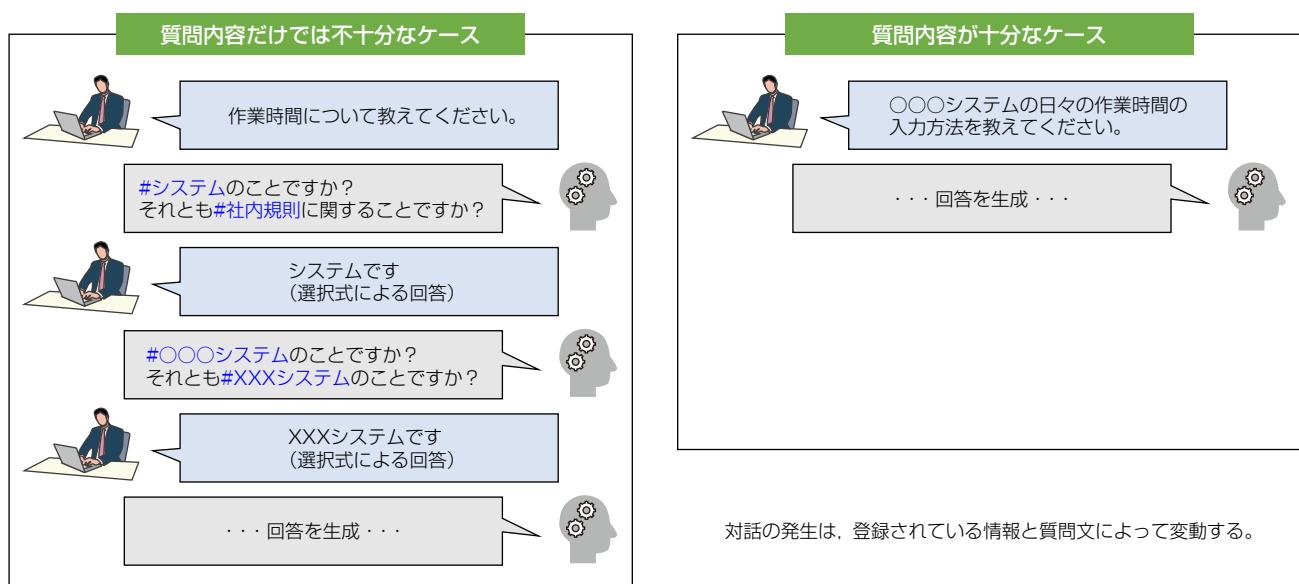


図4-対話のイメージ

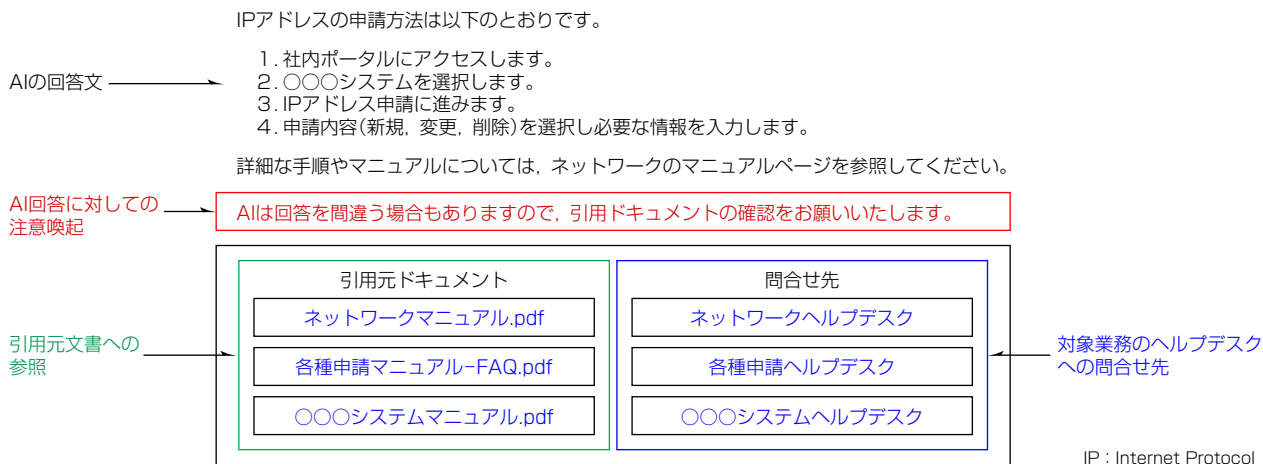


図5-AIチャットボットによる回答例

## 5. む す び

1995年のWindows<sup>(注4)</sup>95の登場によってインターネットが急速に普及し、今ではなくてはならない社会インフラになった。今後AIも同じように誰もが使えて、AIを活用できないと競争力が失われ淘汰(とうた)されていく時代が到来することが想定される。またチャットボットのような新しいサービスだけにAIが適用されるのではなく、既存の情報システムへの組み込みや融合が進んでいくと考えられる。このAI時代の技術動向を踏まえて、今後も顧客のニーズに合わせて更なるソリューションの拡充を進めていく。

(注4) Windowsは、Microsoft Corp.の登録商標である。

## 参 考 文 献

- (1) 永田祥平，ほか：Azure OpenAI ServiceではじめるChatGPT/LLMシステム構築入門，技術評論社（2024）

# Serendie データ分析基盤

Serendie Digital Infrastructure - Data Analysis System -

\*DXイノベーションセンター

## 要 旨

三菱電機のデジタル基盤“Serendie”（セレンディイ）<sup>(1)</sup>が提供する技術基盤の一つ“データ分析基盤”へ、当社の事業データを集約している。データを生み出すコンポーネントやデータを蓄積するシステムは多岐にわたっているため、事業ドメインごとの多様な方式に対応してデータを集約する、及びデータごとに異なる利用条件に細かく対応して利活用を進める、という課題がある。今回、これに対応するため、データを管理する連邦型組織を構築するとともに、データメッシュ型アーキテクチャを採用してデータ分析基盤を実現した。今後は、この取組みに基づいてデータの集約と利活用を加速させるとともに、データ分析基盤のグローバル対応も進めていく。

## 1. ま え が き

当社グループは、各種事業で当社のコンポーネントやシステムが稼働することで生まれるデータをデジタル空間へ集約し、分析することによって、顧客の潜在課題・ニーズを把握し、新たな価値を提供する“循環型 デジタル・エンジニアリング企業”を目指して変革を進めている。その実現のためには、データの事業横断的な分析・活用から価値創出を可能にするデジタル基盤が不可欠である。当社グループが培ってきた様々な分野でのナレッジを新たな価値創出に広く活用するため、組織や事業を越えた活動を促進するデジタル基盤Serendieを構築した。Serendieの活用によって、社内だけでなく、顧客やパートナーとの共創を積極的に推進していく。

Serendieでは四つの技術基盤“データ分析基盤”“WebAPI連携基盤”“サブスクリプション管理基盤”及び“顧客情報管理基盤”を提供する。このうちデータ分析基盤は技術基盤の中核であり、各事業が個別に収集してきたデータを集約し、事業横断的に分析・活用する共通システムである。例えば、電力システム事業の“BLEnDer”（ブレンダー）、ビルシステム事業の“Ville-feuille”（ヴィルフィーユ）、空調・家電事業の“Linova”（リノバ）など、これまでそれぞれのシステムの中で、異なる形式で別々に保管されていたデータを一つのデータプールに集約し、分析することによって、新たなソリューションの開発に活用できるようにしている<sup>(2)</sup>（図1）。

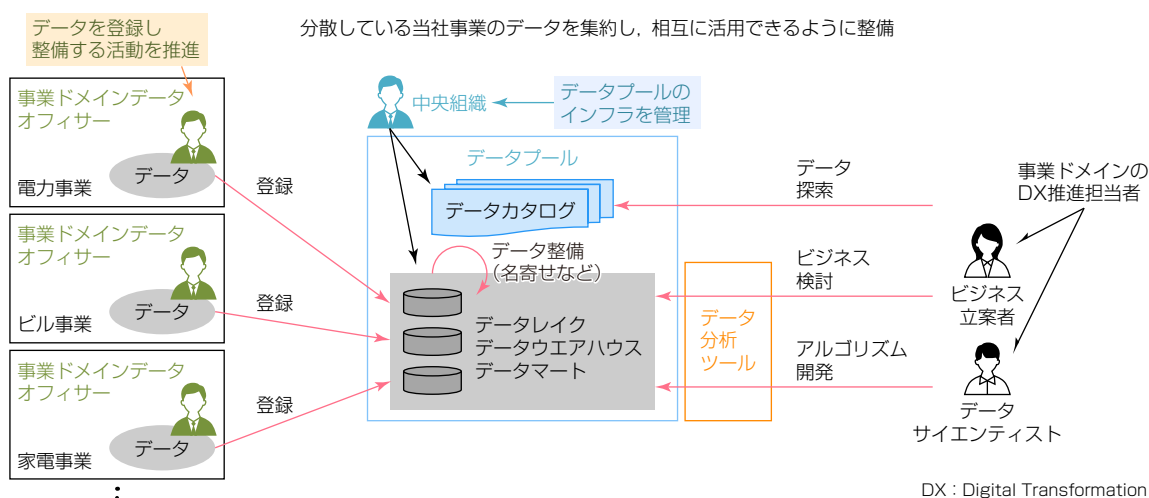


図1-データ分析基盤の全体構成

顧客やパートナーとの共創を積極的に推進していくためにデータ分析基盤が備えておくべき機能としては、全社にわたって広くデータを集約でき、データは常に最新の状態で保たれて容易に理解できる形で格納されていること、及びビジネス立案者やデータサイエンティストがいつでもデータ分析を行える環境が整っていることである。この実現に向けて、構築開始以来、データ分析基盤の変革を行ってきた。

本稿では、2章でデータ管理組織の変革について述べて、3章ではそれに伴って実施したデータ基盤のアーキテクチャの変革について概要を述べる。また4章ではデータ分析ツールと分析環境について述べる。

## 2. 事業データ管理組織

2023年度末に、データ分析基盤の構築を開始し、その管理組織については中央集権型でトライアルを開始した。

この章では、データプール構築以前、データプール初期段階、及び現時点までのデータプール管理組織の形態の変革について述べる(図2)。




図2-データプール管理組織の変革

### 2.1 データプール構築以前の状態

2023年度初期の段階では、事業ドメインによってはデータ集約の取組みが行われていないか、又はドメイン独自で取組みが進行しているかの状態であった。データを蓄積するシステムは事業ドメインごとに分かれて構築されており、ドメイン内で統合して構築されているものもあれば、より細かな事業ごとに個別に構築されているものもあった。すなわち、事業ドメインによってデータ集約の状況は様々であり、データがサイロ化されている状態であった。

また、事業間を跨(また)いでデータを連携し統合ソリューションを創出する取組みも存在したが、システム間で個々に連携を行っている状況であり、事業を跨いだ分析やソリューション構築を活発化するにはまだ効率的ではなかった。

### 2.2 中央集権型管理組織の発足

データプールを管理する組織は、中央集権型でトライアルを開始した。すなわち、中央組織でデータ基盤を整備するとともに、データ管理面でも中央組織が主導することにした。具体的には、データの登録、各データサーバーとデータプールをつなぐデータパイプラインの構築、メタデータの収集などに加えて、各事業ドメインでのデータの利用条件を調査し、それに基づいて利用者に対してデータの共有などを実施してきた。中央組織にエンジニアを集めて、集中的にこれらの作業を行うことで、短期間でデータプールの立ち上げができた。

しかしながら、データの収集範囲が事業ドメインの広範に及ぶに当たり、次第にアジリティ面で次の課題が見えてきた。

- (1) 個々のデータは、それぞれの利用条件に基づいて管理され、その利用条件は個々に更新されていく。中央集権的組織だけでこれらを把握してデータ利活用を行うには、各事業ドメインに対する問合せが頻繁に発生し、アジリティを損なう要因になった。
- (2) 事業ドメインでのデータの蓄積状況やデータの構造は、コンポーネントやシステムの実装に依存して様々である。個々データの状況を理解した上で収集していくのは手間がかかる。結果的に、各事業ドメインでのコンポーネントのエンジニアに対して頻回にヒアリングする等が生じて、アジリティを損なう要因になった。



## 2.3 連邦型管理組織化と中央組織の再構築

今回、これまで中央集権的に実施してきたデータの利用条件の管理やデータ登録などのデータ管理の責務を、全社横断的な役割に注力する中央組織と各事業ドメインとに分散させることで、データ集約でのアジリティーを確保することを目的として、データ管理組織の再構築を行った。併せて、事業ドメインが作成したデータや分析ノウハウを、他の事業ドメインでも積極的に共有していく横断的コミュニティを構築することで、データ利活用を促進する(図3)。




図3-中央組織と事業ドメインデータオフィサーの役割分担

これを実現するため、事業ドメインで、各ドメインでのデータやデータカタログの登録・管理、データ利活用を推進する役割を持つ“事業ドメインデータオフィサー”を任命した。事業ドメインデータオフィサーは、実業務を担当するデータエンジニア等も含めてドメインデータオフィスを構成する。

また、中央組織では、これまでどおりデータ基盤を継続的に整備していくことに加えて、データプール活用のためのドキュメントを整備したり、エンジニアによる支援を行ったりすることによって、ドメインデータオフィスでの業務を全面的に支援する。

## 3. データプールを実現するデータメッシュアーキテクチャー<sup>(3)</sup>

2章で述べたデータプール管理組織の変革に伴って、各組織の役割分担をシステムに落とし込むために、データ基盤のアーキテクチャー変革も実施した。事業ドメインがそれぞれ自律分散的にデータを集約可能にするために、これまでは一つの領域を共有する形であったデータプールを分割し、事業ドメインが所有するデータ格納領域である“ドメインアカウント”と、事業横断でデータを利活用するために使う領域である“プロジェクトアカウント”とに分離し、お互いをメッシュ的に接続することにした。また、利用者が自由にデータを探索するために“データカタログ”も設置した(図4)。

この章では、これらの構成要素について述べる。



図4-データ基盤アーキテクチャーの変革

### 3.1 ドメインアカウント

ドメインアカウントは、事業ドメインごとに設置するデータを格納する領域である。事業ドメインデータオフィサーは、自身の事業ドメインに存在するデータを収集してドメインアカウントに登録したり、利用者を登録したりする作業を行う。また、利用者がいつでもアクセスできるようデータを維持管理するとともに、利用者が容易に利用できるようデータを整備するといった、データの民主化に向けた活動を行う。

ドメインアカウントに登録された利用者は、同アカウントに登録されているデータを閲覧でき、事業ドメイン内でのデータ共有・利活用を進めることができる。

またドメインデータオフィサーは、データごとに利用条件を定めて、その条件に合致した他アカウントからの利用申請に対して、当該データへのアクセス許可を与えることができる。これによって他アカウントに所属する利用者にもデータを閲覧させることが可能になり、事業を跨るデータの共有・利活用を推進できる。

### 3.2 プロジェクトアカウント

プロジェクトアカウントは、データを利活用する組織のための一時的なビューや、一時的な格納場所を提供する領域である。プロジェクトアカウントは、新たな事業創出を企図するスクラムプロジェクトのプロダクトオーナーが管理することを想定している。

スクラムプロジェクトでは、事業横断的にデータを探し、データを取得し、分析等を行ってソリューションの検討を行うために、データカタログとドメインアカウントに接続する。そして、データカタログを参照してデータを探索し、所望のデータを所有するドメインアカウントに対して当該データの利用申請を行い、当該データへのアクセス権を取得する。なお、複数のドメインアカウントに対してデータの利用申請を行うことで、事業ドメインを跨いでデータを参照することも可能になる。

### 3.3 データカタログ

各事業ドメインが持つデータが、他アカウントから容易に見え、理解され、安全に利用されるように、中央組織がデータカタログを整備する。事業ドメインデータオフィサーはデータカタログにデータの説明を登録できる。データカタログには、データの内容や構造を述べるメタデータだけでなく、当該データの利用条件や機密区分(個人情報か否かなど)も掲載する。これによって利用者は、データを受け入れる領域の適切なカスタマイズや、利用条件に合わせた共創テーマの設定などを事前に行うことができるようになる。

今後、顧客との広範な共創を進めるために、データカタログは可能なかぎり当社グループ内に広く公開できるよう運用の改善を図っていく。

## 4. 事業ドメインを跨るセルフサービスのデータ分析環境

プロジェクトアカウントからは、事業ドメインを跨いでデータを参照できる。これを利用し、プロジェクトアカウントの領域と、各データ分析ツールとの間にコネクタを構築することで、データ分析ツールから事業ドメインを跨いだ分析が可能になる。

分析ツールとしては、データサイエンスの事前知識なくノーコードで容易にデータを視覚化するBI(Business Intelligence)ツールや、AIを活用したツール、プロフェッショナルな分析を行うことができるツールなど、複数の分析ツールを用意している。3章に述べたデータメッシュの機能と併せることで、ビジネス立案者やデータサイエンティストが、いつでも事業ドメインを跨いでデータを表示、評価、分析できる、セルフサービスの分析環境を提供する。

## 5. む す び

Serendieの技術基盤の一つであるデータ分析基盤の概要を述べるとともに、そのコアになるデータプールについて、各事業のデータを集約して継続的に管理していくための組織面及び技術面のアーキテクチャーについて概要を述べた。

今後はSerendieの海外展開に伴い、データプールのグローバル対応を行っていく予定である。

## ■ 参 考 文 献

- (1) 三菱電機：Serendie セレンディ  
<https://www.mitsubishielectric.co.jp/serendie/>
- (2) 三菱電機：IR DAY 2024：三菱電機のDX戦略（2024）
- (3) Dehghani, Z. : Data Mesh Principles and Logical Architecture（2020）  
<https://martinfowler.com/articles/data-mesh-principles.html>



三菱電機株式会社