

当財団では、2018年度より会員相互の情報交換と幅広いネットワーク作りを主目的に参加者や賛助会員等から要望の強いテーマであるAIやロボットなどIT関連を講演テーマとして「中部社研ITフォーラム」を開催しております。

本レポートは、第13回（2021年2月8日）でのご講演「未来社会のための人工知能研究：環境とエネルギーの視点から」を元に、講師のトヨタ自動車株式会社 未来創生センター R-フロンティア部 主査の梶洋隆氏にその概要を執筆いただいたものです。

未来社会のための人工知能研究： 環境とエネルギーの視点から

トヨタ自動車株式会社未来創生センター R-フロンティア部 主査 梶 洋隆



1. はじめに

トヨタ自動車株式会社は、これまで、これからも、ひとやものの移動を支え、心を伝え、可動性（モビリティ）を社会の可能性に変える世界作りのために汗をかく存在でありたいと考えています。その中で、モビリティに伴う環境負荷とエネルギー消費量を減らすための人工知能（Artificial Intelligence: 以下、「AI」）技術の適用を考える際、AIが社会のエネルギー効率を高める視点と、AIが消費するエネルギーを低減する視点の2つがあります。私たち未来創生センターでは、これらに対して、①SDGs(Sustainable Development Goals)の概念である「誰1人取り残さない」社会づくりに資する機械学習技術と、②AIを含む複雑なシステムを検証する技術の視点からの研究開発に取り組んでおり、これらは今後の多様なモビリティに組み込まれていくAI技術にとって重要な鍵を握ると考えています。本レポートでは、これら2つの研究の紹介をきっかけに、AIと未来社会の関わりについて皆様と情報共有できればと考えています。

2. 環境・エネルギーを取り巻く状況

非営利団体のBerkeley Earth^(※1)によるレポート（“Global Temperature Report for 2020” <http://berkeleyearth.org/global-temperature-report-for-2020/>）によれば、2020年の地球の平均気温は1851～1900年の平均気温から約1.3℃上昇、地表面に限れば約2.0℃の上昇と報告されています。気候変動への具体的な対策は、持続可能な開発目標であるSDGsの1つとして、国際社会として取り組むべき課題として挙げられています。日本においても2050年までに温室効果ガスの排出をゼロ、すなわちカーボンニュートラルな社会の実現を目指し、また米国においても脱炭素の動きが加速しています。カーボンニュートラルとは、人間が何かを生産したりする活動の際に排出される二酸化炭素の量と森林などにより吸収される量が同量、すなわち実質的にゼロとなる状態を指します。

企業においても環境・エネルギーに関する取り組みは積極的に進められており、例えばIT企業のGoogle社は2017年以降、同社のデータセンターとオフィスで使用する電力のすべてを再生可能エネルギーから購入すると発表しています（“We’re

(※1) Berkeley Earth：気候科学のための地温データ分析に焦点を当て活動するNPO。カリフォルニア州で2010年に設立。

set to reach 100 % renewable energy – and it’s just the beginning” <https://blog.google/outreach-initiatives/environment/100-percent-renewable-energy/>). 私たち未来創生センターにおいても、大学・企業との共同研究で、電力取引を自律的に可能とする次世代電力取引システムの実証実験を実施しています。実証実験に参加した一般家庭（含、電動車）の電気料金を約9%低減し、電動車の走行利用電力の43%を再生可能エネルギーとし、二酸化炭素排出量を38%削減できることを確認しました（https://www.toyota.co.jp/jpn/tech/partner_robot/news/20201113_01.html）。

3. 環境と AI に関する動向

本章では、まずデジタル機器の生産や使用が環境・エネルギーに与える影響について概観し、AIが新たな環境・エネルギーのリスク要因になりつつあることについて紹介します。そして、このような状況を受けた新たなAI開発の動きについて紹介します。

(1) デジタル技術の環境への影響

The Shift Project によるレポート^(※2) (“LEAN ICT” https://theshiftproject.org/wp-content/uploads/2019/03/Lean-ICT-Report_The-Shift-Project_2019.pdf) によれば、世界のGDPあたりのエネルギー消費は毎年1.8%ずつ削減されていますが、デジタル技術のエネルギー消費は4%ずつ増加しています。デジタル機器の生産・使用に限れば、毎年9%ずつの増加となっています。温室効果ガスの排出割合でデジタル技術の影響をみると、2020年の時点で全体の約4%を占めており、なりゆきのシナリオでは2025年には8%に達する予想もあります。2018年時点での自動車などのモビリティの排出割合が8%ですので、これに匹敵する影響となります。

スマートフォンなどのデジタル機器のプロセッサやデータ伝送の消費電力は2～3年で1/2倍の

ペースで省電力化が進んでいますが、データの生み出される量・通信量・IoT（Internet of Things）センサ数がそれを上回る速度で増加しており、効果を打ち消している構造になっています。このように、デジタル機器やそれに付随するサービスの需要の高まりにより、世界中で生成されるデータと計算リソースの使用量は急激に増加しており、その結果としてのAI開発に対するニーズの高まりは、それらをサポートするためのエネルギー消費の高まりと密接に関連していると考えられます。

AI開発に要するエネルギーに関しては、例えば、ロボットハンドを操作してルービックキューブを解くアルゴリズムの開発に、約2,800kWhを要したと言われています（<https://wired.jp/2020/03/07/ai-great-things-burn-planet/>）。また、機械翻訳などで用いられる自然言語処理モデルの訓練によって排出される二酸化炭素は、自動車のライフサイクル（燃料を含む）のそれを超える可能性があることが指摘されています（Emma Strubell et al, Energy and Policy Considerations for Deep Learning in NLP, <https://arxiv.org/pdf/1906.02243.pdf>）。

AI開発で中心的役割を果たす機械学習、とくに深層学習を用いたモデルは非常にパラメータ数が多く、モデルの訓練に大量のデータを用いるため、結果として膨大な計算リソースを使用することになります。Open AI^(※3)の報告によれば、2012年以降、同等の性能で比較すれば16か月で1/2倍のペースで訓練の計算量は低下しているのですが、2012年以降、3.4か月で2倍のペースで訓練の計算量の総量が増加しています（<https://openai.com/blog/ai-and-compute/>）。

これらはあくまでも1つの機械学習モデルの訓練についての話です。しかし実用においてはさまざまな目的や使用するデータに応じてモデルを用意し、訓練を行います。また、モデルが搭載されるのはクラウドだけでなくスマートフォンなどのエッジにまで及ぶことを考えれば、新たな環境・エネルギーのリスク要因になることは想像に難くありません。

(※2) The Shift Project：気候変動と化石燃料枯渇の2つの問題に取り組むフランスのNPO。2010年に設立。

(※3) Open AI：人工知能を研究するアメリカのNPO。2015年に設立。

(2) Frugal AI (質素な AI)

2020年11月16日～20日、「人間中心のAI：第2回仏独日シンポジウム」が、ドイツ科学・イノベーションフォーラム東京、在日フランス大使館、人工知能研究開発ネットワークとの共同で開催されました。本シンポジウムは、3カ国からの講演者100名、視聴登録者数1,000名以上の参加があり、3か国のAI戦略の紹介、「人間中心のAI (Human-centric AI)」をテーマに、信頼性、COVID-19、環境、社会、技術とAIについてのディスカッションがなされました。詳細については <https://www.ai-symposium-france-germany-japan.com/> をご覧ください。

著者は、その中の「環境とAI(AI & Environment: Frugal AI)」というセッションの4人のパネラーの1人として参加しました。Frugal AI (質素なAI)とは聞きなれない言葉ですが、本セッションでは、AI開発のエネルギーフットプリントをどのように制御・削減できるかについてディスカッションがなされました。

Hugues Ferreboeuf氏 (The Shift Project) は本セッションのオーガナイザーであり、“Why we need AI to be frugal” と題し、デジタルセクターの温室効果ガスへのインパクトが自動車セクターに匹敵する可能性や、デジタル機器の効率は向上している一方、デバイス数とデータ量は急激に上昇していること、深層学習の発展で、モデルの訓練の計算量が増大していることが報告されました。前節の内容は Ferreboeuf 氏の報告をベースに、著者が情報と見解を追加したものです。

続いて、Rémi Bouzel 氏 (Qarnot computing) からは、“3 steps towards AI frugality” と題し、グリーンインフラとしてプロセッサの排熱を家庭用ヒーターやビル用ボイラーへ活用すること、カーボンインパクトのモニタリングによるユーザの意識向上とアルゴリズムのエコ度評価をおこなうこと、さらにはスマートビルディングと個人への行動推薦によりエネルギー消費を低減させるAIシステムの研究に着手していることが紹介されました。

Loreto Mateu 博士 (Fraunhofer Institute for

Integrated Circuits) からは、“Neuromorphic Hardware for Edge AI” と題し、神経科学にインスパイアされたニューロモーフィックハードウェアの活用の提案がありました。ニューラルネットワークをFPGAやASICで実装することで、クラウドやエッジでエネルギー効率が高く、低レイテンシーなコンピューティングを実現可能であるとのこと。

最後に著者からは、“AI Researches for Future Society: Frugal AI perspective” と題し、以下の我々が取り組んでいる2つのAI研究のFrugal AIへの活用を提案しました。詳細については次章で紹介をします。

- ・個人ごとの行動・状態予測にもとづくサービスへの弱教師付き学習の適用
- ・複雑 (分散・相互作用のある) なAIシステムへのソフトウェア検証の適用

以上をまとめると、Frugal AIの取り組み領域としては、図1に示すように個人と社会、コンピューティング視点とシステム・サービス視点からなる4つの象限に整理することができます。

余談ではありますが、本シンポジウムはLAVAL VIRTUALという環境を使ったオンラインのシンポジウムでした。大きなカンファレンスセンターのある

要求	コンピューティング視点	システム・サービス視点
個人	<ul style="list-style-type: none"> - エッジ (携帯電話やIoTデバイス) から収集されるデータの低減 - デバイス上での計算量低減 - 低消費電力型のプロセッサ 	<ul style="list-style-type: none"> - AIシステムによるエネルギー消費低減 → 個人の行動・状態予測にもとづくサービス
社会	<ul style="list-style-type: none"> - クラウド上でのデータ量・計算量低減 - 低消費電力型のプロセッサ 	<ul style="list-style-type: none"> - グリーンインフラ：発熱の効率的な利用 - AIシステムによるエネルギー消費低減 → AIを含む複雑なシステムの検証

図1 Frugal AIの取り組み領域



図2 シンポジウムの様子

仮想の島にログインし、カメラ画像は使わずすべてアバターのみでコミュニケーションを行います。プレゼンテーションもアバターで壇上に上がり、レーザーポインタを使いながら説明を行うことで、臨場感のある発表ができました（図2）。

4. 未来創生センターの取り組み

本章では、未来創生センターで取り組んでいる2つのAI研究について、Frugal AIの観点から活用の可能性を論じたいと思います。AIは、図3に示すように非常に幅広い研究領域ですが、ここでは主に、機械学習とそれを含むシステムの検証について述べます。

(1) 個人ごとの行動・状態予測にもとづくサービスへの弱教師付き学習の適用

機械学習とは、総務省ICTスキル総合習得教材の説明によれば「データから規則性や判断基準を学習し、それに基づき未知のものを予測、判断する技術」とAIに関わる分析技術を指しています。以下では、機械学習の代表的な枠組みであ

る教師付き学習と教師なし学習について簡単に説明します。

教師付き学習（Supervised learning）では、例えばワインの成分に関するデータが手元にある場合、ワインの値段（連続的な値）を正解値（教師）として、これを成分から予測したり、ワインが品評会で合格するか否か（離散的な値）を正解ラベルとして、これを成分から分類をしたりすることが考えられます。このように、成分と価値の関係を訓練データ（ラベル付きサンプル）として、モデルのパラメータを学習することで、新しいワインの成分が分かれば、その価値が予測できるというわけです。

もう1つの代表的な枠組みである教師なし学習（Unsupervised learning）では、たとえばワインの種類が多い場合に、成分でいくつかのグループ分けをするクラスタリングや、成分の数が多い場合に、いくつかの軸で要約を行う次元削減を行うことで、成分のみのデータ（ラベルなしサンプル）から成分の関係性を把握することができます。

機械学習を用いて、お客様の行動や感情などを予測して環境への配慮と利便性を両立するサー

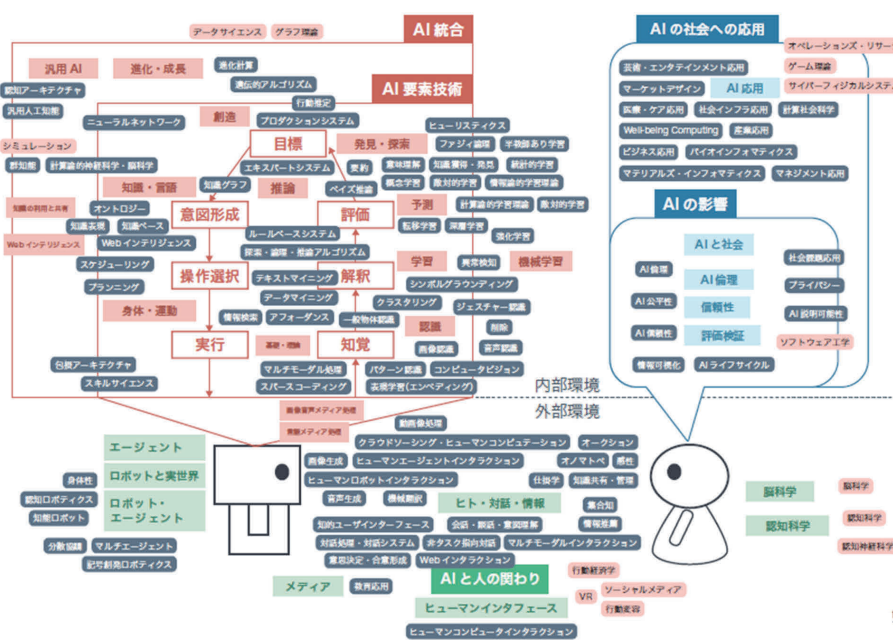


図3 人工知能研究の概観。出典：人工知能学会「AI マップβ 2.0 (2020年6月版)」
<https://www.ai-gakkai.or.jp/resource/aimap/>

ビスを提供することを考えます。個人の行動・状態予測を行う場合、センサや画像などの観測できるデータから、歩行などの行動や、感情などの状態を正解ラベルとして予測モデルを学習する教師あり学習が用いられます。

生活パターンやサービスに対する受容性はお客様ごとに大きく異なることが考えられます。このとき、図4に示すように、平均的な個人を想定した単一の予測モデル（万人モデル）では一般的に性能が不十分なため、個人ごとに予測モデル（個人モデル）を用意することが望ましいのですが、全てのお客様から十分な量の訓練データ（ラベル付きサンプル）を取得することは下記の理由から困難であると思われます。




図4 万人モデルと個人モデル

- ・お客様によるラベル付け：例えば、どのような行動をしていたかをお客様自身に記録してもらうことは、面倒でユーザ体験を損なうことになるでしょう。
- ・第三者によるラベル付け：データをメーカーに提供してラベル付けをしてもらうことは、プライバシーの観点から抵抗感があるかもしれません。

上記に加え、Frugal AIの視点からは、訓練データを減らし、データ蓄積と計算量を減らしたいという要請もあります。データ量とラベル付けの手間を低減しつつ、性能の良い個人モデルを作りたい。このような要求に対して、我々は「弱教師付き学習（Weakly supervised learning）」という機械学習手法の研究を進めています。以下では、PU-マルチタスク学習という手法についてご紹介します。詳細な内容に関心がある方は、下記の論文をご覧ください。

・ H. Kaji, H. Yamaguchi and M. Sugiyama, Multi Task Learning with Positive and Unlabeled Data and its Application to Mental State Prediction, Proc. ICASSP2018, 2018

PU-マルチタスク学習では、弱教師付き学習の一種であるPositive-Unlabeled分類と、マルチタスク学習という2つの手法を組み合わせることにより、少量のラベル付きサンプルを活用して精度を向上させることを狙います。

弱教師付き学習（Weakly supervised learning）とは、ラベル付け・収集コストの低いデータから高精度な機械学習を実現する手法です。いくつか種類がありますが、本研究で用いるPositive-Unlabeled分類では、正例（Positive）は簡単に収集でき、負例（Negative）のラベル付けが大変などの理由で収集が難しいが、正例と負例が混ざったラベルなしデータ（Unlabeled）はたくさん用いることができる条件で用いることができます。

マルチタスク学習（Multi-task learning）とは、すべてのタスクを同時に訓練することで、関連タスク間で情報を共有し性能向上を図る手法です。個人の行動・状態予測においては、似たユーザ同士の情報を共有することで、1人当たりの収集するデータ量を減らすことが期待できます。

この2つの手法を、図5に示す数式で結合することで、PU-マルチタスク学習が実現できます。

PNとPUの学習を組合せ、情報共有をする項を付加する

$$\hat{J}(\alpha) = \underbrace{\frac{N}{L} \widehat{J}^{pu}(\alpha_1, \dots, \alpha_T)}_{\text{PU分類の学習規準}} + \underbrace{\frac{M}{L} \widehat{J}^{pn}(\alpha_1, \dots, \alpha_T)}_{\text{PN分類の学習規準}} + \underbrace{\frac{1}{2} \sum_{t=1}^T \lambda_t \alpha_t^T \alpha_t}_{\text{正則化項}} + \underbrace{\frac{w}{4} \sum_{t,t'} \gamma_{t,t'} (\alpha_t - \alpha_{t'})^T (\alpha_t - \alpha_{t'})}_{\text{情報共有項}}$$

$L = N+M$, N : PUサンプルの数, M : PNサンプルの数, T : タスクの数
 λ : 正則化パラメータ, w : 重み, γ : 類似度

図5 PU-マルチタスク学習

具体例として、運転者の眠気検出を考えます。この問題においても、万人モデルよりも個人モデルのほうが良い性能を期待できますが、個人から眠気を含むラベル付きデータを集めることは難し

い問題です。そこで、実験室実験で少量の覚醒 (Positive) と眠気 (Negative) のラベル付きサンプルを収集しておき、対象となる個人からは運転し始めのデータを覚醒 (Positive) とし、その後なりゆきで覚醒と眠気が混じったデータ (Unlabeled) が多く収集できると仮定します。このようにすることで1人当たりから収集するデータ量を減らしつつ、個人にフィットしたモデルを学習できることが期待できます。

実験では、3名の運転者に図6に示すドライビングシミュレータを運転してもらい、観測できるデータとして心拍情報を、眠気の顔表情評定の結果を正解ラベルとして計測します。そして、心拍情報から眠気を予測するモデルとして、上記の仮定に基づいて提案手法であるPU-マルチタスク学習と、従来手法であるPU分類、教師付き分類との比較を行いました。その結果、提案手法は、対象となる個人のデータが少ない条件・多い条件それぞれで、安定して従来手法よりも性能が向上することが、統計的に確認できました。

“覚醒”と“眠気”を顔表情評定によりラベル付け




図6 ドライビングシミュレータによる計測

今後の課題としては、弱教師付き学習であっても、何らかのラベル情報は必要ですので、よりラベル情報の少ない弱教師付き学習の手法の研究の発展が望まれます。また、ラベルなしデータを多用すると、データ量・計算量の問題は残りますので、適切なデータの間引き方も研究課題となるでしょう。

(2) 複雑(分散・相互作用のある)な AI システムへのソフトウェア検証の適用

安全・環境・快適性などの機能要求の高まり

に伴い、自動車などの制御ソフトウェアは大規模・複雑化の一途をたどっております。不具合の原因の4割がソフトウェアに由来すると市場統計もあり、その数も年々増加傾向にあります。最近では深層学習などのAIがシステムに含まれるようになってきており、また社会システムの制御となれば、複数の分散したシステムが相互作用しながら動作することになり、制御ソフトウェアの複雑さは増す一方です。結果として、開発者が意図せぬ挙動が発生することや、エネルギー的に非効率な動作をしていても気づかない可能性もあります。

制御ソフトウェアの不具合の多くは仕様設計の段階で混入するため、ここに手を打つことが重要です。従来の仕様検証プロセスでは、制御の挙動を洗い出すようなテストパターンを生成し、実行結果を1つずつ解析するため、すべての挙動を想定するのは多大な時間が必要となり現実的ではありません。そこで我々は大規模なシステムにも適用可能なシミュレーションベースの技術に着目しています。シミュレーションベースの技術では、グリッドテストという、制御パラメータを格子点状に組み合わせるテストが一般的ですが、パラメータ数が多く、条件を細かくすると組み合わせが膨大となりテストがしきれず、粗くすると見逃しが発生するという問題があります。

この問題に対処するため、我々はサーチベーステスト (Search Based Test, 以下、「SBT」) というソフトウェア検証手法の研究を進めています。SBTは一言でいうと「自動いじわるテスト」です。図7に示すように、あつてはならない振る舞い(要求違反)を定義し、要求違反が発生する入力(テストシナリオ)信号を自動で生成します。具体的には、シミュレータ上でシステムの制御パラメータや時系列入力を設定し、要求違反との距離を目的関数とした最適化を行います。

以下では、自動運転を対象としてSBTを適用した事例について紹介します。エネルギー管理システムや社会システムのシミュレーションに適用することで、同様の議論が可能です。詳細について興味のある方は、下記の論文をご覧ください。

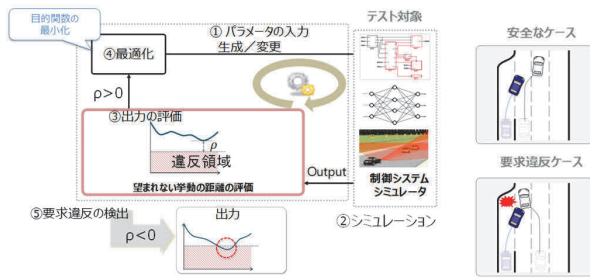


図7 AIを含むシステムのサーチベーステスト

- Y. Date, T. Baba, B. Hoxha, T. Yamaguchi and D. Prokholov, Work-in-Progress: Application of Simulation-Based Methods on Autonomous Vehicle Control with Deep Neural Network, Proc. EMSOFT2020, 2020

自動運転システムにおいて、環境の認識を深層学習による画像認識で行うことを考えます。このようなAIを含む複雑なシステムに対して、SBTによるシステム要求違反の効率的な探索と、深層学習によるシステム要求違反の修正を同時に行うことを目的とします。システム要求違反の修正は、図8に示すように、深層学習の訓練サンプルに要求違反ケースの画像を加えて再学習することにより実現します。



図8 要求違反ケースの再学習

図9に示すように、シミュレータ上に深層学習(SqueezeDetと呼ばれる公開されているモデル)で前方を認識する自動運転車両の検証環境を構築し、歩行者の手前で停止することを要求仕様とします。検証する入力変数として、前方を走るエージェント車両の色、歩行者のシャツとズボンの色、霧などを想定した可視度を変化させ、要求違反をする条件を検出します。

提案手法であるSBTと、従来手法であるグリッドテストを用い、1,000回のシミュレーションを実施しました。その結果、歩行者の手前で停止できなかった要求違反の発生するケース(入力変数の




図9 テストシナリオ

組み合わせ)が、SBTで215個、グリッドテストで98個を検出でき、SBTが効率的に要求違反を検出できることが確認できました。このとき、①可視度の低い濃霧のようなケースと、②衣服の色により認識しがたいケースが検出されました。さらに、SBTで検出したケースの画像を深層学習に再学習させ、再び1,000回のシミュレーションを実施したところ、要求違反の発生する条件を0個にすることができました。

以上より、SBTは深層学習を含むシステムに対し、要求違反を効率的に検出可能であり、さらにSBTで得られた要求違反ケースを再訓練に用いることによって、システムの性能改善が可能であることが分かります。今後の課題としては、SBTそのもののエネルギー消費を抑えるために、シミュレーションの実行回数を低減してより効率的に要求違反を検出する最適化アルゴリズムを開発する必要があります。また、社会システムを模した高精度なシミュレータを用いる場合、シミュレータ自体のエネルギー効率も改善していくことも重要になるでしょう。

5. おわりに

デジタル技術によるエネルギー消費・温室効果ガス排出量の急速な増大の背景には、機器のプロセッサや通信の効率は向上している一方で、データ量・通信量・センサ数はそれを上回るペースで増加していることが挙げられます。さらに、新たな環境・エネルギーのリスク要因として、AIの計算量が新たなリスクになりつつあります。デジタル機器と同様に、アルゴリズムの計算効率は向上す

る一方で、深層学習などのモデルの訓練に必要な計算量は、モデルの複雑化・訓練データの増大に伴い急速に増加しており、さらに、AIの普及が進むこと自体が増加のペースを加速すると予想されます。

このような状況を受けて、Frugal AI（質素なAI）という考え方がでてきています。国際的なシンポジウムでも議論がされており、AIの使用に伴うエネルギー消費がAIの新たな評価指標、ひいては新たな価値となりうる可能性を示唆しています。私たち未来創生センターでも、AI技術の研究開発を進めるうえで、環境・エネルギーの視点が重要な鍵を握ると考え、コンピューティングとシステム・サービス、個人と社会という切り口から多角的にアプローチしていきたいと考えています。