



# COMPUTATIONAL MECHANICS

計算力学部門ニュースレター No. 61

May, 2019

## 目次

• 部門長の就任・退任の挨拶	
• 部門長就任にあたって	名古屋大学 松本敏郎 2
• 部門長退任にあたって	東京大学 越塚誠一 4
• 部門賞	
• 2018年度計算力学部門賞贈賞報告	東京工業大学 青木尊之 5 名古屋大学 奥村 大 5
• 功績賞を受賞して	東京理科大学 岡田 裕 7
• 功績賞を受賞して	京都大学 北村隆行 9
• 業績賞を受賞して	宇宙航空研究開発機構 大山 聖 11
• 業績賞を受賞して	慶應義塾大学 志澤一之 13
• 業績賞を受賞して	MSCソフトウェア 橋口公一 15
• 特集：IoT, AI時代のCPUアーキテクチャ	
• ポスト京のCPUアーキテクチャ：HPCとAIの融合	富士通 吉田利雄 16 富士通 秋月康伸 16
• エヌビディアが加速するディープラーニングとHP	NVIDIA 佐々木邦暢 20
• Armの「プロジェクト・トリリウム」—— 1兆個のIoTデバイスが繋がる未来へ必要なこと	アーム 菅波憲一 24
• 部門からのお知らせ	
• 第31回計算力学講演会(CMD2018)優秀講演表彰報告	東京大学 越塚誠一 28
• 第32回計算力学講演会(CMD2019)開催案内	東洋大学 田村善昭 29
• 2019年度年次大会の部門企画について	東北大学 岡部朋永 30
• 計算力学部門・イベント情報	31

## 部門長の就任・退任の挨拶



## 部門長就任にあたって

第97期部門長  
松本敏郎  
名古屋大学

この度、越塚誠一前部門長（東京大学）の後を引き継ぎ、第97期計算力学部門長を務めさせていただきます。高木周副部門長（東京大学）、白崎実幹事（横浜国立大学）、只野裕一幹事（佐賀大学）、部門運営委員会委員、各種委員会や研究会の皆様をはじめ、関係する全ての皆様のお力添えのもとに、計算力学部門の円滑な運営とさらなる発展に努めてまいりたいと思います。

計算力学部門は、設立後30年を超えましたが、固体力学や流体力学などの基盤的分野を骨格として、工学から理学にまたがる他分野との横の連携が図られている理想的な活動部門として益々発展しております。計算というキーワードのもとに、多様な専門分野の人たちが集まり、新しい問題・計算法・技術を創出するメルティング・スポットとしての役割は今後も一層重要となるでしょう。電子計算機の発明を転機に高度な数値計算手法の発展が開始し、ハードウェアとしての計算機の高速度化、大容量化、ソフトウェアとしてのオペレーティングシステムやプログラミング言語の高度化の相互作用が、計算技術の発展を加速してきました。最近では、比較的安価でGPUを搭載した高性能な計算機が大量に出回るようになり、私が大学院生の頃ブームとなっていたニューラルネットワークが最新のハードウェアと高度に発達したソフトウェア、高性能の周辺機器と組み合わせられることにより、大量のデータを学習し、大量のデータから瞬時に回答を導き出す技術として実用の域に達しています。計算機の役割が益々人間の脳に近くなるのと同時に、データの処理速度とその量は人間がまったく太刀打ちできないレベルとなっています。計算機の役割がこのように高度なものになっていく状況の中で、計算力学が計算機関連技術の中で相対的に小さな領域とならないようにしたいものです。

私が計算力学と関わったのは、境界要素法という支配微分方程式から導出される境界積分方程式の数値解析法に取り組んでいたのがきっかけでした。当初はこの方法を破壊力学における応力拡大係数の計算などに用いていたのですが、次第に形状感度解析、不均質媒体、音響、熱伝導、異方性、圧電材料などの境界要素法による解析に対象を広げていきました。その後、境界要素法の高速度化の研究の進展により、形状最適化やトポロジー最適化への有効性に着目し、特に境界要素法が得意とする波動に関連した問題のトポロジー最適化法の確立と応用に取り組んでいます。波動問題のトポロジー最適化の過程では、解析対象の形状の変化に合わせて連立方程式を繰り返し解く必要があります。連立方程式は、大抵は反

復法で解くのですが、深層学習の最近の応用に触発されて、求解に必要な反復回数を解析対象の形状から学習させ、見積もってみたりしています。波動問題は弾性波動、音響、電磁波と物理現象は多岐にわたり、応用物理学、数学を専門とする方々との連携を必要としますので、私にとって計算力学部門はまさに最適な活動の舞台となっています。計算力学部門で活動していらっしゃる方は、大なり小なり他分野の方々との交流を通じて刺激を得て、ご自身の研究を進展させておられることと思います。そのためにも、例えば計算力学講演会では新しいOSをご提案いただいたり、ご専門の研究テーマから離れた内容のOSにも積極的にご参加いただくことなどを通して、本部門からの新たな技術的課題、研究テーマ、学問領域等の創出につなげていただければと思います。

さて、日本機械学会員の計算力学部門への部門登録者数は、2018年11月の時点で第1位～5位の合計で5,939名（正員）です。これは日本機械学会の23部門の中では第3位の規模になります。この人数はこれまでは着実に増加していましたが、ここ数年はわずかながら減少に転じております。

部門講演会である計算力学講演会では例年多くの研究発表があり、活発な活動が続いています。2018年は第31回計算力学講演会として、実行委員長で徳島大学の石篤哉先生をはじめとする多くの実行委員の方のお力により、11月23～25日に徳島大学常三島キャンパスで開催されました。本公演会は特別講演2件、フォーラム3件、チュートリアル1件、オーガナイズドセッション（OS）26件、一般セッション、ポスター発表からなる充実した内容で、発表件数はフォーラム、OS、一般セッション、ポスター発表を合わせると330件、参加者は509名となりました。OSでは、従来から継続的に編成されている基盤的な研究テーマ、産業界との連携に加えて、深層学習、ペリダイナミクスなど新しい取り組みが紹介され、また応用物理学との連携など計算力学部門らしい横の広がりを持ったセッションなど多彩なテーマが議論されました。

2019年の第32回計算力学講演会は実行委員長として東洋大学の田村善昭先生をはじめとした実行委員会の方々のお力により、9月16～18日に東洋大学川越キャンパス（埼玉県川越市）で開催されます。多くの方に奮ってご参加くださいますようお願いいたします。

計算力学部門ではまた、現在5つの研究会（逆問題解析手法研究会、マルチスケール計算固体力学研究会、電磁流体解析関連技術研究会、設計情報駆動研究会、設計に活かすデー

タ同化研究会)が登録され、研究活動が行われています。

以上の研究活動の成果は、是非とも日本機械学会の英文誌 Mechanical Engineering Journalの計算力学(CM)のカテゴリーで投稿していただき、本ジャーナルの地位の向上へのご協力をお願いしたいと思います。

計算力学部門ではさらに、部門賞(業績賞、功績賞)の表彰、日本機械学会フェロー、学会賞(論文)候補者、文部科学大臣表彰「若手科学者賞」の学会本部への推薦も行っています。これらの募集に関する情報は、日本機械学会のインフォメーションメールでもタイムリーに提供されますので、計算力学部門からのインフォメーションメールの受信を有効にしておいていただければと思います。

皆様にとりまして、計算力学部門での活動がより多様で深い情報交換に資するものとなるように努力したいと思いますので、ご支援を賜りますようよろしくお願い申し上げます。



## 部門長退任にあたって

第96期部門長  
越塚誠一  
東京大学大学院工学系研究科

第96期（2018年度）計算力学部門長の退任にあたりひと言ご挨拶申し上げます。この1年間の部門の運営に関しては、副部門長の松本敏郎先生（名古屋大学）、部門幹事の高橋昭如先生（東京理科大学）はじめ総務委員会の方々、佐々木大輔先生（金沢工業大学）はじめ広報委員会の方々、青木尊之先生（東京工業大学）はじめ表彰委員会の方々、萩原世也先生（佐賀大学）はじめ新学術編集担当委員会の方々、さらには大黒卓様はじめ日本機械学会事務局の方々の多大なご貢献がございました。ここに深く感謝いたします。

この1年を振り返ると、2018年度日本機械学会年次大会が9月9日(日)～12日(水)の日程で関西大学千里山キャンパスで開催されました。部門との連絡は齋藤賢一先生（関西大学）にお世話になりました。2019年度は9月8日(日)～11日(水)の日程で秋田大学で開催されます。

部門の講演会である第31回計算力学講演会は、11月23日(金)～25日(日)の日程で徳島大学常三島キャンパスで開催されました。特別講演として、徳島大学の三輪昌史先生による「オープンソースからみたマルチコプタ型ドローンの発展と応用」、徳島に住んでおられたことがある矢川元基先生による「計算力学：その背後にあるもの」、昨年度に部門功績賞を受賞されたProf. Sung-Kie Younによる「On the Design of Viscoelastically Damped Structures against Dynamic Loads」をお話いただきました。講演会全体では、講演件数327、参加者数509を数え、大変盛況でした。懇親会では、若い研究者を含めて多くの方々に出席いただき、お互いの親睦を深め

るとともに有益な情報交換ができたものと思います。徳島ならではの阿波踊りの余興も印象的でした。計算力学実行委員会委員長の大石篤哉先生(徳島大学)はじめ、実行委員会の方々には大変お世話になりました。2019年度は9月16日(月)～18日(水)の日程で東洋大学川越キャンパスで開催されます。

部門賞として、功績賞2名および業績賞3名を表彰しました。部門講演会での講演に対しては、優秀講演賞3名、優秀技術講演賞3名、および若手優秀講演フェロー賞5名を表彰しました。また、日本機械学会に対して、フェロー賞2名、学会賞(論文)3件、奨励賞(研究)1名の推薦を行っています。さらには、昨年度の推薦になりますが、山中晃徳先生が文部科学大臣表彰若手科学者賞を受賞されました。これら受賞されたの方々には心よりお祝い申し上げますとともに、ぜひこれからの計算力学の発展を担っていただきたいと思います。

日本機械学会の学術誌についても順調に編集作業が行われています。学術誌にはカテゴリ「計算力学」がありますので、ぜひ、皆様の先進的な研究成果をご投稿ください。

その他、2回のニュースレターの発行、部門Webの更新、日本学術会議において開催された「第8回計算力学講演会」(12月12日)の運営、計算力学技術者認定試験対策講習会の開催、JACMを通じた国際活動、5件の研究会活動も行ってきました。

次年度の運営は、新部門長である松本敏郎先生（名古屋大学）および副部門長である高木周先生（東京大学）に引き継ぎます。計算力学部門のますますの発展を願っております。

部門賞



## 2018年度計算力学部門賞贈賞報告

2018年計算力学部門表彰委員会 委員長

青木尊之 東京工業大学 (左)

2018年度計算力学部門表彰委員会 副委員長

奥村 大 名古屋大学 (右)

計算力学部門では、1990年度より部門賞として、功績賞と業績賞の2賞を設けています。功績賞は、学術、技術、教育、学会活動、出版、国際交流などで計算力学の発展と進歩に幅広く顕著な貢献のあった個人に贈られます。業績賞は、計算力学の分野で顕著な研究または技術開発の業績を挙げた個人に贈られます。歴代受賞者の一覧は部門ホームページ <http://www.jsme.or.jp/cmd/> に掲載されています。

2018年度（第96期）には、5月に部門登録会員に向けたインフォメーションメールと部門ホームページにて「部門賞候補ご推薦のお願い」を周知し、7月2日を期日として候補者の募集を行いました。推薦のあった候補者について選考委員及び表彰委員会にて慎重厳正な審査を行い、10月開催の拡大運営委員会での承認を経て、功績賞2名、業績賞3名、合計5名の受賞者を以下のように決定しました。

功績賞 岡田 裕 氏 (東京理科大学)

功績賞 北村 隆行 氏 (京大)

業績賞 大山 聖 氏 (宇宙航空研究開発機構)

業績賞 志澤 一之 氏 (慶應義塾大学)

業績賞 橋口 公一 氏 (エムエスシーソフトウェア(株))

各氏には計算力学講演会における表彰式にて、表彰と記念品の贈呈が行われました。本報レター読者の皆様にも、ご受賞5氏のご業績をご紹介します、その栄誉を広くご周知させていただきますとともに、改めて各氏へのお祝いを申し上げます。

岡田裕氏は、三次元計算破壊力学解析の分野で顕著な業績を挙げています。高精度な破壊力学パラメータ計算手法の構築に取り組んでおり、四面体有限要素や非構造格子状の有限要素解析モデルを使用した仮想き裂開口積分法やJ積分法、相互積分法による高度な破壊力学解析と三次元破壊力学解析モデルの完全自動生成を可能とするなど計算破壊力学分野に多大な貢献がありました。そのほかにも境界要素法や積分方程式法、重合メッシュ法、均質化法などのマルチスケール解析において、独創的な研究成果を挙げており、これらの研究業績に対して、計算力学部門業績賞やThe K. Washizu Medal、日本計算力学連合 (JACM) Fellows Award、JACM Computational Mechanics Awardなどを授与されています。

計算力学部門では、部門長、副部門長、表彰委員会委員長、英文ジャーナル編修委員長、日本機械学会学術誌の部門

アソシエイトエディタなどを務め、部門運営に大きく貢献してこられました。現在は、JACM会長、国際計算力学連合ジェネラルカOUNスルメンバー、3月に神戸にて開催予定の国際会議COMPSAFE2020の副議長を務めるなど国際的にも活躍しています。

1990年 ジョージア工科大学博士研究員

1992年 日産自動車株式会社入社

1993年 1996年 ジョージア工科大学研究員

1996年 鹿児島大学工学部機械工学科助教授

2002年 同 准教授

2009年 東京理科大学理工学部機械工学科教授

北村隆行氏は、高温強度、ナノメートル・スケール材料の破壊力学、ナノ材料のマルチフィジックスの研究において顕著な業績を挙げています。高温破壊力学の研究成果は、多数のき裂が発生・成長する高温問題における破壊過程の解明に大きな進展をもたらしています。ナノ構造体の強度研究の分野では、原子シミュレーションを積極的に組み込み、電子顕微鏡を用いたその場観察と組み合わせるナノスケール破壊力学について先駆的な研究を行い、その確立を先導するとともに世界的に本分野を牽引しています。さらに、ナノスケール材料のマルチフィジックス研究では、第一原理計算を中心とした電子・電子レベルの精密な解析を行い、この分野の発展を牽引するとともに、新しい分野を開拓しつつあります。これらの研究成果は375報を超える研究論文として報告されており、日本機械学会賞論文賞や日本材料学会賞論文賞などを数多く授与され、そのほかにも計算力学部門業績賞、材料力学部門業績賞、JACM Computational Mechanics Awardなどを授与されています。

学会活動では、日本機械学会理事、関西支部長、日本材料学会会長、理事、日本工学アカデミー理事などを務め、最近では、著書Fracture Nanomechanics (Pan Stanford Publishing)やMultiphysics in Nanostructures (Springer)を出版するなど、国内外において大変活躍されています。

1986年 京都大学工学部助手

1990年 同 講師

1992年 同 助教授

1999年 同 教授

大山聖氏は、設計最適化手法や設計探査手法の研究開発と航空宇宙工学分野や流体工学分野における応用の研究を軸にして多大な成果を挙げています。2015年度まで実施されたHPCI戦略プログラム「分野4次世代ものづくり」において「多目的設計探査による設計手法の革新に関する研究開発」の課題責任者を務め、大規模設計最適化問題のための効率的な多目的設計探査手法を開発するとともに、スーパーコンピュータ「京」を利用して、これまでは実施することが不可能だった複数車種の車両構造の同時設計最適化問題などの大規模問題を解くことに成功しています。また、JAXAが研究開発を進めているロケットエンジンLE-9のターボポンプなど、航空宇宙工学分野や流体工学分野におけるさまざまな設計最適化問題に取り組み、これらの分野の発展に大きく貢献しています。産業界とも連携し、計算力学、特に設計最適化手法の利用分野の拡大に大きな貢献をしています。これまでの研究に対して、学会において、論文賞や業績賞を授与されており、部門運営でも、部門幹事や表彰委員会副委員長を務めるなど多くの貢献があります。

- 2000年 NASA グレン研究所 NRC研究員
- 2003年 宇宙航空研究開発機構宇宙科学研究所 助手
- 2007年 宇宙航空研究開発機構宇宙科学研究所 助教
- 2010年 宇宙航空研究開発機構宇宙科学研究所 准教授
- 2015年 東京大学大学院工学系研究科 准教授（委嘱）

志澤一之氏は、材料のミクロ構造の挙動とマクロ構造の変形を橋渡しするマルチスケールモデルの開発とそれを用いたマルチスケール有限要素解析に精力的に取り組み、優れた研究成果を挙げています。大きく別けると3つの研究業績、すなわち、金属の転位挙動に基づくマルチスケール結晶塑性解析、フェーズフィールド法を組み合わせた金属組織形成に対するマルチスケール結晶塑性解析、ポリマに対するマルチスケール分子鎖塑性解析があります。とりわけ、時代に先駆けて転位密度テンソルをひずみこう配と結び付けて有限塑性理論に導入する研究に着手しており、このような理論は現在では一般にひずみこう配結晶塑性理論と呼ばれ広く認知されています。関連する論文は国際的に高い評価を得ており、その後の理論の発展の基礎を与えたという点で高く評価されています。材料のマルチスケールモデリング及びマルチスケールシミュレーション手法の開発を通して、計算固体力学に立脚した計算材料科学の新しい可能性を見出し、構造材料の材料設計や材料評価のための新規な手法を構築しており、これらの研究業績は計算力学、特に計算固体力学の発展に大きく貢献しています。

- 1989年 慶應義塾大学理工学部機械工学科助手
- 1992年 同 講師
- 1996年 同 助教授
- (1996年 ワシントン州立大学訪問教授)
- 2004年 同 教授

橋口公一氏は、弾塑性構成式の研究において、従来の構成式の問題点に着目し、下負荷面モデルを新しく提案しています。このモデルでは、降伏面内においても正規降伏比に応じて塑性変形が連続的に発生するという仮定を導入しており、従来の問題点が解決され得ることを特徴としています。下負荷面の概念は、摩擦モデルや結晶塑性モデルの構築にも応用されており、最終的には繰り返し負荷における有限変形・有限回転を厳密に表現し得る乗算分解・超弾性塑性モデルへの発展に繋がっています。下負荷面モデルは、橋口モデルとして、大学や研究所、企業において活用され、有限要素解析ソフトMarcには標準搭載されるとともに、スプリングバックのような変形現象に対して高い実用性が確認されています。精力的に執筆活動を行っており、機械と研究（養賢堂）において2005年から2015年にかけて「詳説・弾塑性力学」を100回連続して掲載してこられました。また、著書Elastoplasticity Theory (Springer)やIntroduction to Finite Strain Theory for Continuum Elasto-plasticity (Wiley)は国内外において広く購読されており、材料・計算力学の啓蒙活動にも寄与が大きく、学会から業績賞などを多く授与されています。

- 1966年 九州大学農学部助手
- 1980年 同 助教授
- 1989年 同 教授
- 2007年 第一工業大学教授
- 2013年 大阪大学招へい教授
- 2016年 エムエスシーソフトウェア（株）技術顧問



## 功績賞を受賞して

岡田 裕  
東京理科大学 理工学部機械工学科

この度は、日本機械学会計算力学部門功績賞という大変栄誉ある賞を頂き誠に光栄に存じます。この場をお借りし、今までお世話になった諸先生方、先輩方、同僚、学生の皆様にお礼申し上げます。この機会に私の研究の紆余曲折について少しご紹介させていただこうと思います。

計算力学との出会いは、大学4年生のときに卒業研究のテーマで結晶塑性論を用いた大変形弾塑性有限要素法プログラムを作るものでした。客観応力速度、例えばJaumann 応力速度や、有限変形問題で用いられる第一/第二Piola-Kirchhoff 応力、等々、固体力学の基礎事項に悪戦苦闘したことを思い出します。当たり前ですが、研究というより勉強してなんとかプログラムを書いたということでした。ただ、これは大変勉強になる課題でした。課題を与えて下さった東京理科大学の故宮本博先生と菊池正紀先生には大変感謝しています。後の勉強や研究で大変役に立ちました。

大学卒業後、大学院に入ったのですが、前述の両先生にご紹介いただきアメリカジョージア州アトランタのジョージア工科大学に留学し、S. N. Atluri 教授の下でPh.D. 課程を修了しポストドクターまでジョージア工科大学で過ごすことになりました。私の渡米の少し前、1986年春に東京で第一回の国際計算力学会議 (International Conference on Computational Mechanics; ICCM, 共同議長: 東京大学・矢川元基教授、ジョージア工科大学・S. N. Atluri教授) が開催され、計算力学/Computational Mechanics という分野が確立され広く認知されはじめた頃だと思います。自動車などの設計に有限要素法を中心としたCAE (計算機援用設計) が広く用いられるようになる少し前の頃でしたので、大きく伸びていく新しい分野の勉強をすと思い大変張り切っていたことをよく覚えています。ジョージア工科大学では多くの先輩に恵まれ、特にポストドクターでAtluri先生の研究室に所属していたDr. H. Rajiyah (現・GE) とは多くの議論をさせて頂き、また多くのことを学びました。また、当時はどれだけ偉大な方々か良くわかっていませんでしたが、客員教授としてジョージア工科大学に滞在されていた R. Rivlin 先生の講義を聴講したり、J. R. Rice 先生のセミナーを拝聴する機会に恵まれました。あまり良く理解できなかつたというのが実感でしたが、今になって思うと恵まれた環境で勉強できたことを有難く感じています。

ジョージア工科大学では当時注目を浴びていた境界要素法に関する研究をすることになりました。境界要素法解析を用いて二次元大変形弾塑性問題の解法に関する研究を行ったのですが、境界上の応力やひずみの計算をすと物体内部と比較して精度が落ちてしまうという問題のあることがわかり、

根本的な解決を試みる中で変位勾配のための新しい積分方程式を提案しました (Okada, Rajiyah and Atluri(1))。詳しいことは割愛しますが、このときの経験がその後の私の研究スタイルに大きく影響してきたように思います。その後、自動車会社の研究所での勤務、再びジョージア工科大学での研究員を経て鹿児島大学に職を得ることができました。32歳の時でしたが、やっと常勤の職に就き、落ち着いて仕事ができると張り切っていたことをつい昨日のこのように思い出します。鹿児島大学では独立した研究者として一体何から手を付けていかかわからず、試行錯誤の繰り返しでした。均質化法解析や重合メッシュ法など様々試行錯誤的に研究をしていましたが、なかなかインパクトのある研究成果に結び付かず悶々としていました。

最近、三次元破壊力学解析の高度化研究を主に行っていました。この研究は、日本溶接協会・原子力研究委員会・MF (繰返し複合荷重に対する軽水炉機器・構造物の健全性評価に関する研究、2001~2003年度) 小委員会での解析課題がきっかけで取り組むことになりました。その一部として半だ円表面き裂の混合モード応力拡大係数データベース構築を行いました。そのための有限要素法解析モデル生成を、当時大学院生だった東さんが大変苦労しながら、繰り返し行っていました。当時そのような解析モデル生成は簡単だと思っけていましたが、私の勘違いでした。このことが四面体有限要素用の仮想き裂閉口積分法 (VCCM; Virtual Crack Closure-Integral Method) の提案(2)に繋がりました。その後三次元のみ裂進展解析など様々な研究へと発展していきました。

ジョージア工科大学で博士課程を修了してから今年で29年になりますが、研究テーマについては試行錯誤の連続でした。また、自分の研究者や大学教員としての資質に自信を持つことができず、どのようにしたら世界的に活躍されている方々に一歩でも近づくことができるのだろうか、など悩みの尽きない日々を過ごしてきました。これが正直なところです。しかし、結果としては今まで出会ってきた多くの方々にある種の憧れを持ち、日々悩み抜いた結果として、少しは世の中の方々に認めて頂ける成果を上げることができ、「功績賞」という私にとっては重過ぎる賞を頂くことができたのだろうと理解しています。

つい最近、2019年3月24日から28日に、冒頭の国際計算力学会議 (ICCM) に続く、計算理工学国際会議 (International Conference on Computational & Experimental Engineering and Sciences; ICCES) が東京で開催されました。S. N. Atluri先生はじめ、多くの旧知の先生方ともお会いすることができ、30年前の大学院生時代のことを思い出して初心

に戻ることができたように感じています。悩みは尽きないのですが、これからも研究・教育に励む所存です。今後ともご指導ご鞭撻のほど、よろしくお願い申し上げます。

- (1) H. Okada, H. Rajiyah and S. N. Atluri, Non-hyper-singular integral-representations for velocity (displacement) gradients in elastic/plastic solids (small or finite deformations), Computational Mechanics., Vol. 4, pp. 156-175, 1989.
- (2) H. Okada, H. Kawai and K. Araki, A virtual crack closure-integral method (VCCM) to compute the energy release rates and stress intensity factors based on quadratic tetrahedral finite elements, Engineering Fracture Mechanics, Vol. 75, pp. 4466-4485, 2008.





## 功績賞を受賞して

北村隆行  
京都大学 工学研究科 教授

計算力学部門より功績賞をいただいたことを、とても光栄に存じます。ありがとうございます。恩師である大谷隆一先生には研究者としての道を開いていただき、懇切なご指導を賜りました。深甚の謝意を表します。また、21世紀COEプログラムを切っ掛けに広い視点の重要性をご指導いただいた土屋和雄先生に、心より御礼申し上げます。さらに、お世話になった方々のお名前を挙げて御礼申し上げるべきですが、あまりに多くの方々に語りつくせないご援助をいただきましたので、紙面の関係から本稿ではお名前をあげた紹介をいたしません。どうか、失礼をご容赦ください。これまで多くの先生、先輩、同僚、後輩の皆様方、さらに学生諸君のご支援のお陰でいただけた賞であると、心より感謝申し上げますとともに嬉しく感じています。

さて、定年近くの年齢に達したためか「工学の将来」を議論する会合に出席する機会が増えてきて、工学の学術やその基盤概念やあり方について考えることが多くなってきました。日本の総合大学は設立時から工学部を擁していましたが、世界の大学の中では特殊・異様な歴史・経緯であると言われることがあります。新たな日本社会を切り開こうと苦悩した先人達は、技術の基盤として学術が必要とされる世界の潮流を見抜いて、日本の発展を工学という学術に期待していたのでしょう。技術は人間や社会に幸せをもたらすためのものごとであり、その体系的知識すなわち学術・学問が工学に結晶化しています。昔は職人さん達が苦心惨憺して獲得した「経験と勘」に基づくものづくり技術でしたが、近代になって合理的な考え方に立脚した「予測」に基づくもの（こと）づくり技術への転換の波が押し寄せたということでしょう。正確に設計するためには法則性の理解が不可欠であり、経験から予測への脱皮は自然科学躍進の時期と符合し、工学が学術として形づくられる時期とシンクロしていました。産業界に技術者、大学に工学者が誕生・成長しつつある世界の潮流に乗ったと言うこともできます。現在に至るまで、その波は拡大と深化を続けており、社会の根幹を支えるものとなっています。高度化した技術・学術の下、多彩な境界条件によって有効な機能を見つけ出すためには、計算シミュレーションはうってつけの手段だと思います。したがって、20世紀後半から現代までの飛躍的な計算機の発展を背景に、工学分野のなかで計算工学が大きな位置を占めたのは自然な流れでした。また、工学は、自然科学（認識科学）とシステム科学（設計科学）から構成されていることに特徴がある分野です。機械工学における前者は力学（材料力学、熱力学、流体力学、機械力学）ですから、「計算力学」が現代の機械工学

の中心部に位置するようになるのも、当然と言えば当然です。その計算力学の部門から賞を頂けることは、工学者の一人としてとても誇らしく存じます。

ここで、自分の40年間の研究を振り返って、私の計算力学との関わりを整理してみます。

1979年に修士課程を修了した私は、電力中央研究所で研究職の道を歩き出しました。研究対象は、発電プラント機器の高温強度全般でしたが、とくにクリープや疲労に対する破壊力学に興味を持っていて、無理をお願いして亀裂の研究させてもらいました。そのころは実験的アプローチでしたが、自分でも情けないほどの不器用で、お世辞にも「実験屋」の端くれとは認められない奇妙な研究者だったと思います。一方、私は研究者人生を通じてとてもラッキーな人間で、この時も実験に優れた研究者・技術者の方々に助けて（おんぶ・抱っこ状態）いただいて研究が進みます。実験研究は現在まで続きますが、生来の不器用が治るはずもなく、周囲の優れた研究者に頼り切っています。

時間依存性、非線形性、特異場のkey wordsに代表されるように、破壊力学分野の中でも最も難解なクリープ亀裂伝播を対象としていました。納得のゆく結果が出ていたので、重心は時間依存破壊（クリープ）と応力繰返し数依存性破壊（疲労）の相互作用に移ってゆきます。すなわち、破壊力学を用いて破壊現象間の非線形な関係性を主題としたのです。京都大学に職を得て、この研究成果が博士論文として結実しました。

学位取得後、NASAへ研究留学する前後（80年代後半）に高温疲労における微視組織的微小亀裂に取組み始めます。境界条件の複雑さに困惑し、大きなバラつきを示す実験データを目の前にして、モデル化と数値シミュレーションの威力を思い知るようになります。計算力学の重要性を認識した第一歩と考えています。また、自分の研究に将来に繋がるマイクロからナノへの微小化の方向性が始まったのもこの頃です。そして、微小亀裂(10 $\mu$ mオーダー)からその発生起源であるキャビティ（ナノスケール）に進展します。その頃に日本はメモリーの産業が全盛の時代に入っており、意外にもデバイス配線の信頼性のキ要素が高温キャビティ成長だったので、これを端緒にして、導かれるようにナノ材料力学に吸い込まれてゆきました。

分子動力学解析に出会ったのもこの頃でしょうか。研究室で指導した卒業論文では、1991年度にその最初の課題が見えます。実験装置のみならず計算機にも弱い自分の乏しい能力が十分に自覚できたときでもあります。研究者なのに、実

験も解析も苦手だなんて……。ナノで悪戦苦闘する90年代でしたが、実験と数値解析の両輪でゆく決心がついた時でもあり2000年以降の方向性が定まってきます。材料力学は、形（外的幾何要因）と下部組織（内的幾何要因）が大きな因子です。理想強度にこれらを取り込むことから始めました。優秀な若手研究者が第一原理やフェーズフィールドを用いた研究を進めてくれて、気が付けば強誘電性や磁性といった異なる物理物性間が非線形に関係するマルチフィジックスに材料力学をリンクする新しい領域が目の前に広がっていました。解析でも優れた研究者に助けをいただいで研究が進み、おんぶ・抱っこスタイルの研究姿勢が本格的に定着します。

一方、2000年以降に連続して大型ファンドをいただける幸運に恵まれ、実験も一貫して微小化を大幅に進めることができました。特別推進研究1回、基盤研究(S)3回獲得の強運は、私の密かな自慢です。その後、若手研究者の努力によって微小化を極めつつあり、現在では5nmより小さな特異場寸法の破壊力学実験に成功するなど、ナノ破壊力学から原子破壊力学を標榜するまでに至っています。

以上の経緯から、生体材料等を含めたあらゆる材料に対するナノ力学による機能の探求がこれからの機械工学における力学の進展分野と確信しています。

さて、科学技術振興機構(JST)に「さきがけ」というプログラムがあります。戦略的に選ばれた特定の研究分野の研究提案募集をして、優れた若手（20-30人程度）に研究費を配分して将来発展に向けて伸び伸びと研究をしてもらおうとともに、相互交流や他流試合で研究を深めてもらおうというプログラムです。バーチャル若手研究所を形成すると言い換えてもよいと思います。本年度の研究分野として、「力学機能のナノエンジニアリング[ナノ力学]」が選定され、私とその研究総括を承ることになりました。その具体的な対象分野の内容は下記です（研究領域概要より引用）。

「各種材料（金属材料、無機材料、有機材料など）において、強度特性等を決定している支配因子やそのメカニズムについてのナノスケールからの解明と、それに基づく機能創出を進めます。また、同スケールにおける力学特性を中心とした他の物理特性（熱物性、磁性、電導性など）との相関性に着目した新奇な機能創出も対象に含めます。これらの目的の達成のため、その場計測下の力学実験技術、力学解析法、シミュレーション技術等を発展させ、ナノ材料からマクロ材料の共通基盤であるナノスケールの力学学理の展開と多様な特性解明への解析評価技術の確立を推進します。さらに、基礎研究の結実として、材料の高機能化や新機能創出につながる材料設計指針を獲得することを目指します。」

このプロジェクトを含め、産学とともに若手研究者・技術者を刺激する側にまわりたいと思うこの頃です。ナノ力学分野を開拓する若者を、さらに別分野を探検する野望を持つ若者を、機械工学のみならず全理工学領域から集めてナノ力学分野が発展してゆくことを夢に見ています。若い研究者のみならず、一緒にこの分野を造りましょう !!!

最後に、改めて皆様に感謝し、受賞の御礼の言葉といたします。ありがとうございました。



## 業績賞を受賞して

大山 聖  
宇宙航空研究開発機構 宇宙科学研究所

このたびは、日本機械学会計算力学部門業績賞をいただき、大変光栄に思います。私が目標とする先生方が過去に受賞されてきた業績賞を受賞できるような研究成果をあげることが目標の一つとして参りましたので、大変うれしく思います。

「業績賞を受賞して」という原稿の執筆依頼を受け、なにを書こうかと考えましたが、この場をお借りして、お世話になった皆様方にお礼を申しあげさせていただきたいと思えます。

はじめに、学部4年生から博士3年までの6年間に渡りご指導いただいた中橋和博先生および大林茂先生に感謝申し上げます。私が大学4年生に進級するタイミングで中橋先生と大林先生が東北大学にいらっしゃり、私はとても幸運でした。それまで、大学の教授というと堅苦しくて厳しいイメージを持っておりましたが、(皆さんご存じのように)お二人ともとても気さくなお人柄で研究室の雰囲気はとてもよく、かつ、的確な研究指導をしていただくことができました。また、NASAに連れて行っていただいたり、海外の研究者にもご紹介いただいたりして、国際的な研究成果をあげていくことの重要性も教えていただきました。お二人の先生に巡り会わなければ、この道に進んでいなかったかもしれません。

私の修士論文・博士論文での研究テーマは進化アルゴリズムを使った航空機主翼の空力設計最適化でした。進化アルゴリズムは大域的な探索を可能とする新しい手法として注目を集めていましたが、必要な計算コストが高いことがボトルネックでした。しかしながら、幸運なことに私が研究を始めた頃に航空宇宙技術研究所(当時)の数値風洞(Numerical Wind Tunnel, NWT)が稼働し、航空宇宙技術研究所の中村孝さんと共同研究をさせていただくことでNWTを使わせていただくことが出来ました。おかげで世界で初めてとなる3次元NS計算を使った航空機主翼の大域的設計最適化を実施することが出来ました。中村さんにはスパコンの使い方などをご指導いただくとともに、航空宇宙技術研究所の研究者の方々をご紹介いただき、その後の研究にも大きな影響を与えました。中村さんにも深く感謝いたします。

つぎに、2000年から2003年までNASAグレン研究所にてお世話になった故Meng-Sing Liouさんに感謝の意を述べさせていただきたいと思えます。博士取得後すぐ、右も左も分からない状態でアメリカに渡ったのですが、Liouさんにご多忙にもかかわらず、アパート探しや、車探し、銀行口座開設などにまでつきあってくださりました。また、折々にご自宅で開かれるパーティにご招待いただいたり、私が病気になった

際にはお見舞いに来ていただいたり、とても親切にしてくださいました。私のNASAグレン研究所での研究テーマはターボ機械の設計最適化でした。Liouさんはご存じのように数値流体力学の大家ですが、最適化に関してはおそらくそれまでまったく研究されていなかったと思います。しかしながら、何回か研究に関する意見交換をただけで、その当時の設計最適化手法の長所や短所などの本質を見抜き、適切なアドバイスをくださりました。人格者であり、非常に聡明な方でした。

2003年からは宇宙航空研究開発機構宇宙科学研究所の藤井孝藏先生(現在は東京理科大学)にお世話になりました。藤井先生には研究についてのご指導を受けたことはもちろんですが、学生の指導方法や研究費の獲得方法などの研究室の運営方法や組織の運営方法などについてもいろいろ学ばせていただくことが出来ました。また、JEDIセンターでの活動などにより、自分が専門としてきた流体力学や設計最適化以外の分野にも視野を広げることができました。

2011年度から2015年度に実施されたHPCI戦略プログラム「分野4次世代ものづくり」、および、2016年度から2019年度まで実施されている重点課題「近未来型ものづくりを先導する革新的設計・製造プロセスの開発」において一緒に研究開発をすすめていただいている、加藤千幸先生を始めとする諸先生方、企業の皆様、研究室のポストドクの皆さんにも感謝を申し上げます。このプロジェクトにおいて、京コンピュータを利用して、世界に先駆けた大規模最適化計算を実証できたことは、非常によい経験となりました。また、重点課題では大規模設計最適化のためのアルゴリズム開発をさせていただき、ポスト京稼働後の研究も非常に楽しみにしています。

宇宙航空研究開発機構の同僚の皆様にも感謝を申し上げたいと思えます。これまでロケットエンジンポンプの流体設計や再使用観測ロケットの空力設計などに関する研究をさせていただいてきました。現在も、火星衛星探査計画(MMX)や月極域探査に関する研究などをさせていただいており、宇宙科学ミッションにかかわる重要でかつやりがいのある研究に取り組ませていただいております。

中橋研究室、大林研究室、藤井研究室の卒業生の多くが現在では学术界や産業界で研究開発にたずさわって活躍されています。卒業生の皆さんともこれまで一緒にさまざまな楽しい研究をさせていただいています。今後も切磋琢磨していけたらと思います。

学生の頃、中橋先生・大林先生からは論文を書くための重箱の隅をつつくような研究ではなく、社会に役立つ研究をす

ることが大事であると教えていただきました。独善的にならず、社会に役立つ研究をするためには、産業界の方々との交流がとても大事であると考えております。私の研究室と共同研究をさせていただいている企業の方々、意見交換をさせていただいている企業の方々にも、この場を借りてお礼を申し上げたいと思います。引き続き、よろしく申し上げます。

日本機械学会計算力学部門の皆様にも感謝いたしております。皆様の素晴らしい論文を拝見したり、講演会で議論をさせていただいたりして、日々刺激を受けております。

最後に、海外出張で長期不在にすることがあったり、土日にも仕事せざるを得なかったり、ブラックな(?)この職業に理解を示してくれている妻と子ども達に最大の感謝を表します。



## 業績賞を受賞して

志澤一之  
慶應義塾大学理工学部機械工学科

この度は、計算力学部門業績賞という大変名誉ある賞をいただき、誠に光栄に存じます。また、ご推薦いただきましたA-TS01-15「マルチスケール計算固体力学研究会」所属のOS企画者の先生方に厚く御礼申し上げます。そもそも私は、博士課程の学生時代から今日まで、流体や固体の材料モデルを構築することを主な仕事としてきたモデリング屋ですので、計算力学部門の賞に値するの躊躇する面もありましたが、提案した材料モデルを数値解析的に解いて現象が新たに再現できることを示せたことに対するの贈賞と解釈し、有り難くお受けすることにいたしました。これもひとえに、恩師である慶應義塾大学名誉教授の棚橋隆彦先生、高橋邦弘先生をはじめ、学会活動でいつもお世話になっている先生方、ともに研究に取り組んできた学生諸氏のご協力・ご支援あつての受賞であると存じ、深く感謝いたしております。

さて、本稿では私のこの20年にわたる材料のマルチスケールモデリングとシミュレーションに関する研究について紹介させていただきます。その特徴としましては、材料の変形場に対しては、一貫して結晶塑性タイプの有限変形モデルを構築するとともに、内部構造の挙動に対しては、転位組織、金属組織、分子鎖網目構造などの発展を表現するモデルを開発し、それらをマルチフィジックス的に連成させてマイクロマクロの相互作用を記述している点にあるかと思えます。それらは大別すると3つに集約できますので、以下ではその概要を簡単に触れさせていただきます。

まず第1に、金属の転位挙動に基づくマルチスケール結晶塑性解析が挙げられます。この研究では、1996年から転位密度テンソルをひずみこう配として有限変形塑性論に導入する研究を開始し、転位密度のこう配が背応力を与えることを、熱力学的構成式論を通して提案いたしました。当時は転位の情報を固体力学に導入する試みが始められたばかりであり、この研究は有限変形マルチスケール塑性論の草分け的存在の一つになったようです。続いて、結晶のすべり系ごとに不適合度(すべりの2次こう配)を定義し、それを転位対すなわちSS転位(統計的に蓄積する転位)密度に相当する幾何学量として結晶の加工硬化係数に導入いたしました。このモデルは、孤立転位をGN転位密度、転位対を不適合度として結晶欠陥を全て微分幾何学的に表現している点に特徴があり、超微細粒金属における強度と延性の粒径依存性や、超微細粒焼鈍材における変形帯の伝播挙動を再現しました。一方、転位セル組織のような転位組織形成(転位パターンニング)を支配する自己組織化モデル(可動-不動転位の反応-拡散方程式)を構築し、それから得られる不動転位密度を結晶の硬化係数に、また結晶塑性FEM解析で得られるすべりの活動状況を反応-

拡散方程式の易動度に反映させたマルチスケール結晶塑性モデルを構築しました。このモデルは、超微細粒の形成シミュレーションに応用され、セル構造、高密度転位壁、マイクロバンド、サブディビジョンなどの微視組織形成の発現過程を再現し、超微細粒形成の過程および機構を明らかにすることに役立ちました。さらに、FCC結晶に対してある程度の成功を収めた転位-結晶塑性モデルをHCP結晶に応用し、Mg基LPSO(長周期積層構造)相の強化機構として注目されているキンク帯形成の発現機構を解明するとともに、キンク帯の周りに形成される回位(回転性結晶欠陥)の四重極構造を再現しました。

第2に、金属の微視組織形成を伴うマルチスケール転位-結晶塑性解析について触れます。材料内の転位蓄積が再結晶核の核生成と核成長の駆動力になることに着目し、転位-結晶塑性解析によって発現したサブグレイン内の何個かのサブグレインが回転合体して核生成する過程をKWC形Phase-fieldモデルを用いて再現するとともに、核の周囲に蓄積している転位を消滅させるべく核成長する静的再結晶現象を同モデルで再現しました。一方、Phase-fieldモデルと転位-結晶塑性モデルを連成させることで、HCP結晶における双晶の発現と消滅を再現することも試みました。さらに、これらの成果をLPSO型Mg二相合金の $\alpha$ -Mg相における動的再結晶に応用し、 $\alpha$ -Mg相の結晶粒微細化過程をPhase-fieldモデルと転位結晶塑性モデルを連成させて再現し、同合金の強化機構の解明にも取り組みました。

第3に、ポリマに対するマルチスケール分子鎖塑性解析について紹介いたします。非晶性の熱可塑性ポリマにおける分子鎖セグメントのキンク回転がポリマの塑性変形の素過程であるとみなし、それを分子鎖すべりと名付け、一絡み点における分子鎖すべり系を定義しました。これにより、ポリマの非晶相を結晶塑性論的に扱うことが可能となり、複数の分子鎖すべり系が絡み点で互いに独立に回転できることを許容することで分子鎖の配向現象を直接表現することを可能にしました。このモデルは分子鎖塑性モデルと名付けられ、結晶塑性論と同様にテンソル形塑性構成式を不要とし、自由体積変化を表す熱活性形のスカラ硬化則のみで計算が可能となるという利点を有しております。また、このモデルを用いてFEM解析を実施すると、降伏前の非線形粘弾性応答、降伏後のひずみ軟化、くびれの伝播、伝播にともなう高ひずみ速度域のフェイドアウト、除荷時の顕著な非線形ひずみ回復、クレイズ(損傷)伝播による破断位置の予測など、従来の連続体モデルに基づく解析では困難であった延性ポリマの諸力学応答が、非常にシンプルなモデルで再現可能であることを示しま

した。さらに、結晶性ポリマの非晶相にこのモデルを適用するとともに、結晶相には通常の結晶塑性モデルを採用し、結晶相と非晶相の混在したユニットセルを作成して均質化法によるマルチスケールFEM解析を実施することで結晶化度の違いによる延性のひずみ速度依存性を再現可能であることを示しました。

以上が私のこれまで取り組んできた材料のマルチスケールモデリングとシミュレーションであります。未だ計算力学的に再現できない材料科学的現象は山積しておりますので、今後も精進を重ね、未解決問題の解明に力を尽くすとともに、後進の育成にも尽力していきたく思っております。最後になりますが、2018年は私が慶應義塾大学の教員に就任してからちょうど30年目に当たり、このような節目の年に本賞をいただけたことは生涯のよき記念になりました。重ねて御礼申し上げます。



## 日本機械学会計算力学部門平成30年度業績賞を受賞して

橋口公一  
エムエスシーソフトウェア(株)技術顧問

この度は、計算力学部門・業績賞を受賞し、誠に光栄に存じます。常々計算力学に関する研究推進を励まして頂き、また、本賞に推薦頂きました東大名誉教授・矢川元基先生、そして、計算力学部門の関係者の方々、特に、種々有意義な意見交換を重ねている東北大・山川優樹先生に心から感謝申し上げます。

大学卒業後2年余り農水省の外郭団体に勤めて大学院を経験することなく大学に戻って助手になり、農学部にも所属していたので、師事すべき指導者も議論し合う仲間もないまま独自に、土壌耕うんや軟弱地盤におけるトラクタ走行において生じる土の変形解析を開始しました。その過程で土の構成式や地盤構造物の極限解析解法の不備が種々目について、これらを修正しては、土木学会論文集、地盤工学会論文集等に発表していました。さらに、土は、圧力依存性、塑性体積変化等の様々な塑性変形現象を示しますが、土の構成式を単純化すれば、金属の構成式が従来より一般的に表現できることが判って来て、金属の構成式の研究に取り組み、日本機械学会論文集やJ. Appl. Mech. (ASME), Proc. Royal Soc., London等へと発表の場を広げました。

往時、工業設計において、繰り返し負荷に対する塑性変形挙動の合理的予測への要求が高まり、多面モデル(Mroz)、2面モデル(Dafalias他, Yoshida-Uemori)、重ね合わせ移動硬化モデル(Chaboche他, Ohno-Wang)等の繰り返し塑性モデルが提案されていました。しかし、これらは、いずれも、古典塑性モデルの降伏面の内部を弾性域とする負の遺産を引きずって、降伏面の内部に純粋弾性域を囲む小降伏面を仮定し、それが移動して降伏面に近づくにつれて、塑性ひずみ速度が発達することを前提にしています。したがって、これらによっては、小降伏面の内部における応力変化による塑性変形を全く表現できず、また、塑性変形を発達を小降伏面の移動に帰しており、物理的妥当性・一般性も欠いています。しかし、斯様なモデルに多少の修正を施したモデルを発表する者、それらを工業設計に用いる企業技術者が続き、学術・産業の発展が阻まれている実情には頭痛むものがあります。

以上の従来の繰り返し塑性モデルの基本的欠陥を打破するため、『下負荷面モデル』(subloading surface model)を創出しました。

下負荷面モデルは、「応力が降伏面に近づくにつれて、塑性ひずみ速度が発達する」という自然な仮定に基づいています。なお、現応力点を通して、降伏面(“正規降伏面”と改称)に相似な面“下負荷面”を導入し、前者の大きさに対する後者の大きさの比を“正規降伏比”(0~1の値を取ります)

と称して、正規降伏面への接近の尺度として用います。

下負荷面モデルによれば、1)降伏面内においても正規降伏比に応じて塑性変形が連続的に発達する、2)したがって、常に滑らかな“弾塑性遷移”が表現され、3)応力が降伏面に達したか否かの降伏判定は不要で、4)正規降伏比の合理的な発展則を導入することにより、数値計算において有限な増分入力で応力が降伏面から飛び出すと、自動的に降伏面に引き戻される制御機能が備わり、数値計算においても際立った長所が賦与されます。これにより、従来の弾塑性モデルにおける上述の不備は、本モデルにより全て解消されます。

下負荷面の概念は、摩擦現象にも適用されて、“下負荷摩擦モデル”が定式化され、繰返しすべり現象、地震の決定論的予知に不可欠なスティックスリップ現象等の合理的解析が達成されています。さらに、弾塑性力学史上の最重要難題であった単調負荷のみならず繰返し負荷における有限変形・有限回転を厳密に表現し得る構成式が下負荷面モデルに基づく厳密な乗算分解・超弾性-塑性モデルの定式化により完成されました。下負荷面モデルは、固体の非可逆力学現象の支配法則であるとみなされます。今後、固体の非可逆力学変形現象は、下負荷面モデルによって解析される方向に急速に収斂するに違いありません。現時、弾塑性論は、下負荷面モデルへの歴史的転換点に立っているとと言えます。

なお、下負荷面モデルは、諸大学・試験研究機関における学術研究、諸企業における工業設計に活用され、また、構造・流体解析ソフトウェアメーカーMSC Software, Ltd.により、「Hashiguchi model」として同社の大型汎用構造解析ソフトMarcに標準搭載(標準機能として全ユーザーが使用可能)され、単調比例負荷にとどまらず繰返し非比例負荷を受ける諸機械要素の変形現象を対象に高精度・高速計算が達成されて、国内外で広範に活用されています。

なお、下負荷面モデルについては、拙著『Elastoplasticity Theory』(2009, 2013; Springer)、『Introduction to Finite Strain Theory for Continuum Elasto-plasticity』(2012, Wiley)、『Foundations of Elastoplasticity: Subloading Surface Model』(2017, Springer)および『Nonlinear Continuum Mechanics for Finite Elasticity and Plasticity: Multiplicative Decomposition with Subloading Surface Model』(2019年11月, Elsevier)に詳述されています。これらを購読され、或いは、Marcを導入されて、本モデルの広範な活用により、弾塑性力学の発展そして工業設計の高度化が飛躍的に推進されるよう願って止みません。

特集 lot, AI時代の新CPUアーキテクチャ



# ポスト京のCPUアーキテクチャ：HPCとAIの融合

吉田利雄（左）  
秋月康伸（右）  
富士通株式会社 AI基盤事業本部

## 1. はじめに

富士通はHPCおよびAI領域に最適化されたCPUであるA64FX(1)(2)を開発した。このCPUはポスト京コンピュータに採用される。A64FXは汎用CPUの中で、世界トップレベルの演算処理性能、メモリバンド幅を有する。

A64FXは、Arm社の命令セットArmv8-Aをベースに、さらにHPC、AI領域向けにベクトル拡張したSVE(Scalable Vector Extension)(3)を採用した世界初のCPUである。富士通はSVEの仕様策定にあたって、Arm社のリードパートナーとして協力して取り組んだ。

A64FXがターゲットとするHPCとAIの領域は、大量の並列演算処理と高いメモリバンド幅を必要とする点で共通している。実際にディープラーニングや機械学習で代表されるAI領域において、これまでのGPU（グラフィックスプロセッサ）やアクセラレータに加え、レイテンシ重視な推論や複雑なアルゴリズム処理を必要とする学習等に対応しようと、SIMD(Single Instruction Multiple Data)演算器を有した汎用CPUの活用が近年広がってきている。今後HPCシステムでは、AI領域も有力なターゲットとなってくると思われる。

本稿では、最初にA64FXのアーキテクチャについて説明し、次にHPCとAI領域のベンチマークの特徴を述べ、それらの領域における現時点でのA64FXの性能評価結果について紹介する。

## 2. A64FXのアーキテクチャ

### 2.1. 富士通のCPU開発の歴史

A64FXのアーキテクチャに関する詳細説明に先立ち、富士通のこれまでのCPU開発の歴史について概説する。富士通は60年以上にわたって、メインフレーム、UNIXサーバ、HPC向けにCPUを開発してきた（図1）。富士通はマイクロアーキテクチャを性能と信頼性の両面で継続的に改善しながら、そのマイクロアーキテクチャを共通基盤として異なる命令セットのCPUを開発してきた。

最新のA64FXは新たにArm命令セットを採用したCPUである。A64FXは、これまでメインフレーム開発で培ってきた高信頼性技術、UNIXサーバにおける高いシングルスレッド性能と広範囲なアプリケーションを扱うことができる柔軟性、また大規模HPCで求められる高スループットな演算とメモリ、低消費電力、超並列向けインターコネクトといった富士通の技術を集約して開発したCPUである。（図2）

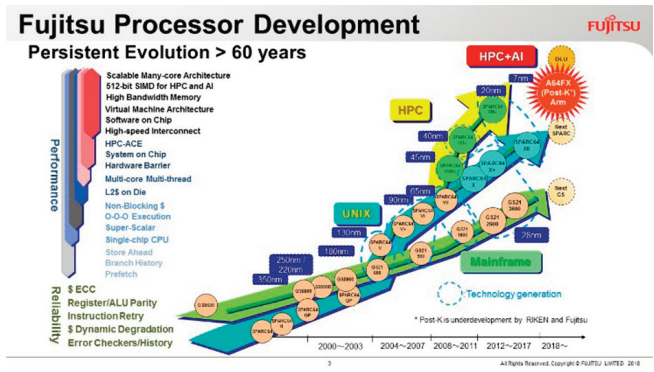


図1：富士通CPUの開発の歴史

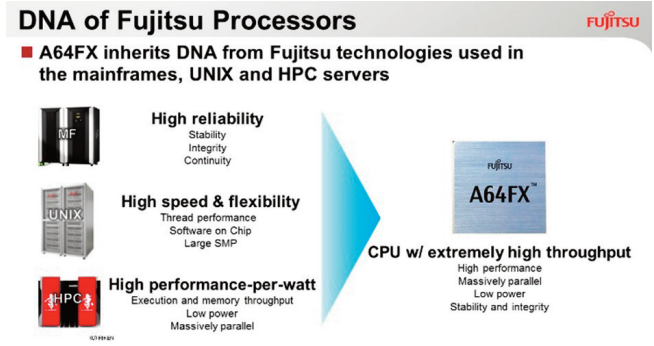


図2：富士通CPUのDNA

### 2.2. A64FXチップ概要

図3に、A64FXの概要を示す。A64FXはArmアーキテクチャArmv8.2-Aと、HPC、AI向けにベクトル拡張したSVEに準拠し、512ビットのデータ幅でのSIMD並列演算処理をサポートする。A64FXはArm上で動くOSやアプリケーションなどのソフトウェアをそのまま動かすことが可能である。

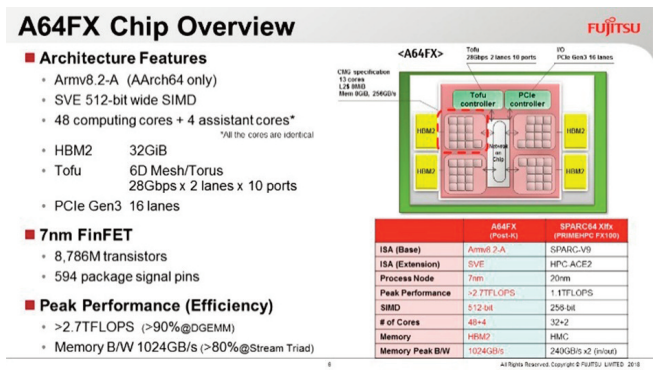


図3：A64FXの概要



チップは48個の計算コアと4個のアシスタントコアの合計52コアで構成される。52コアは全て同一のコアである。計算コアの48コアでの性能は、倍精度浮動小数点演算で2.7TFLOPS(浮動小数点演算を1秒間で2.7テラ回実行可能。テラは、10の12乗)を上回る。アシスタントコアは主にOS、I/O処理等を行い、システムのOSジッタを軽減することで、大規模システムの性能を安定させる役割を担う。

また、この演算性能を最大限に引き出すためにデータ供給側も強化し、メモリに高バンド幅メモリHBM2を4つ備え、1024GB/sの高いピークバンド幅を確保している。なお総メモリ容量は、32GiBである。

CPU間の接続は、超並列システムを実現可能とする富士通独自のTofuインターコネクトを採用。そのコントローラ部をCPU内に蔵する。I/O接続は、標準インターフェースPCIe Gen3を16レーン備える。

また、A64FXは7nmプロセステクノロジーで製造され、1チップに約90億個のトランジスタを実装している。

### 2.3. A64FXの命令セットについて

図4にA64FXの命令セットの特徴を示す。A64FXは前述の通り、ArmアーキテクチャをHPC、AI向けにベクトル拡張するSVEを世界で初めて採用するCPUである。SVE策定にあたってはArm社と富士通が共同で取り組み、HPC分野をはじめとした広い範囲のアプリケーションで高い性能を発揮することを旨とした。

#### A64FX Features

- Collaboration with Arm to develop and optimize SVE for a wide range of applications
  - FP16 and INT16/8 dot product are introduced for AI applications

	A64FX (Post-K)	SPARC64 X1fx (PRIMEHPC FX100)	SPARC64 V8ifx (K computer)
ISA	Armv8.2-A + SVE	SPARC-V9 + HPC-ACE2	SPARC-V9 + HPC-ACE
SIMD Width	512-bit	256-bit	128-bit
Four-operand FMA	✓ Enhanced	✓	✓
Gather/Scatter	✓ Enhanced	✓	✓
Predicated Operations	✓ Enhanced	✓	✓
Math. Acceleration	✓ Further enhanced	✓ Enhanced	✓
Compress	✓ Enhanced	✓	
First Fault Load	✓ New		
FP16	✓ New		
INT16/INT8 Dot Product	✓ New		
HW Barrier <sup>1)</sup> /Sector Cache <sup>2)</sup>	✓ Further enhanced	✓ Enhanced	✓

<sup>1)</sup> Utilizing AArch64 implementation-defined system registers

図4：命令セットの特徴

富士通は、京コンピュータなどのHPCシステムで、これまでSPARCアーキテクチャをベースに、富士通が独自にHPC向けに拡張したHPC-ACEアーキテクチャ(4)(5)のCPUを開発していたが、今回新たに採用したArmのSVEにおいても各機能をサポートしている。

HPC向け機能として、SIMD幅については前機種の256ビットから512ビットに拡張。4オペランド浮動小数点積和演算(FMA)、メモリ上の離散データを並列にベクトル処理するgather/scatter、三角関数、指数関数などの数学関数高速化命令などは、単精度、半精度などより多くのデータタイプを扱うこととpredicate操作をサポートすることで一層広範囲なアプリケーションへの適用を可能にする。新規に導入したfirst faultロード命令により、“do-while”文などこれまでSIMD化が不可能だったデータ依存が存在するループのベクトル化

が可能になる。

また、主にディープラーニングや機械学習などのAIアプリケーションをターゲットとして、半精度浮動小数点データFP16の積和演算(FMA)、並びに16ビット、8ビットの整数データINT16、INT8の内積演算(Dot Product)を512ビットのSIMD並列処理で実行する命令を新規に導入している。

これらの新規拡張命令を図4の表にまとめた。

### 2.4. コアの強化

図5にコアのパイプラインを示す。A64FXのコアのパイプラインとしては、基本となるスーパースカラ、アウトオーダー、分岐予測を、富士通が開発してきたSPARC64をベースに拡張している。図5のオレンジの部分、A64FXで強化した部分である。512ビット幅のSIMDのFMA演算器の2つのパイプラインを備える。(図5のFLA,FLB) この演算器で、先に述べたFP16のFMAやINT16、INT8のDot Productも処理する。また、predicate操作用に1つのパイプラインを新規に備えている。(図5のPRX) 1次データキャッシュでは、スループットを強化するために、512ビット幅のSIMDロードのパイプラインを2本、512ビット幅SIMDストアのパイプラインを1本備えている。(図5のL1D\$)

#### A64FX Core Pipeline

- A64FX enhances and inherits superior features of SPARC64
  - Inherits superscalar, out-of-order, branch prediction, etc.
  - Enhances SIMD and predicate operations
    - 2x 512-bit wide SIMD FMA + Predicate Operation + 4x ALU (shared w/ 2x AGEN)
    - 2x 512-bit wide SIMD load or 512-bit wide SIMD store




図5：A64FXのコアパイプライン

図6のグラフは、各データタイプのチップのピーク性能(TOPS：1秒間で実行される演算処理回数。単位はテラ)の比較を示す。比較する3種類のCPUは、京コンピュータで採用されたSPARC64V8ifx(グラフ：緑色、一番左側)、富士通の前機種のHPCサーバPRIMEHPC FX100で使用されたSPARC64X1fx(グラフ：濃い赤、中央)とA64FX(グラフ：明るい赤色、一番右側)である。A64FXは、倍精度で

#### Execution Unit

- Extremely high throughput
  - 512-bit wide SIMD x 2 Pipelines x 48 Cores
  - >90% execution efficiency in (D)S(H)GEMM and INT16/8 dot product




図6：演算実行ユニットの性能

2.7TFLOPS以上、単精度で5.4TFLOPS以上のピーク性能であり、富士通の前機種CPUであるSPARC64Xifxより約2.5倍高い性能を達成する。また、半精度FP16、16ビット整数INT16のそれぞれで10.8TFLOPS、10.8TOPS、8ビット整数INT8で21.6TOPSのピーク性能となる。

またA64FXは、SPARC64VIIIfx、SPARC64Xifxと同様に、マイクロアーキテクチャの最適化により、これらの全ての演算で効率90%以上の高い実行性能を発揮する。

これらの演算性能を最大に引き出すためには、キャッシュ、メモリのスループットの強化が重要である。図7にA64FXの1次データキャッシュの特徴を示す。

512ビット幅のSIMDをサポートした場合、一回のSIMDロード命令でさえ2つのキャッシュラインを跨ぐことが高い確率で発生する。一般的な汎用CPUではキャッシュラインを跨ぐ場合、1次データキャッシュの2つの連続するキャッシュラインごとに計2回のアクセスが生じ、スループットが低下してしまう。それに対しA64FXでは、連続するキャッシュライン2つ同時にアクセスを可能とし、SIMDロード命令がキャッシュラインを跨ぐ場合でもスループットを低下させることはない。

**Level 1 Cache**

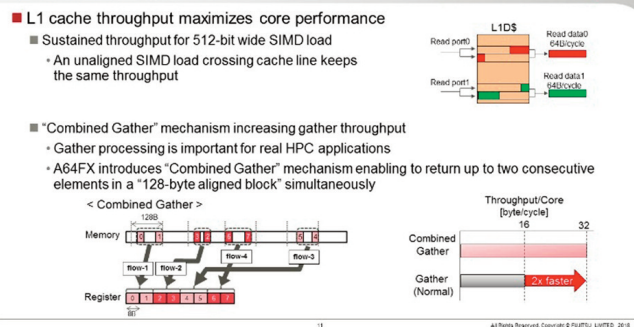


図7：1次データキャッシュ制御

また非構造格子を扱うアプリケーションでは、メモリ上に離散的なデータ配列が頻出するため、離散データのSIMDロード命令 (gather命令) の性能が重要となる。gather命令は、各SIMD要素に与えられたオペランドアドレスのメモリ領域からデータの読み出し処理を行う命令であり、一般的な汎用CPUでは、1次データキャッシュにヒットした場合もSIMD要素数分のアクセスが必要となる。しかし実際のアプリケーションの動作を分析したところ、これらの離散データは完全にランダムな配置ばかりではなく、多くの場合で各要素がメモリ上の近い場所に存在することがわかった。その特性に着目しA64FXのgather命令処理では、隣り合う2つのSIMD要素が同じ128Byte境界の中に存在する場合、2つのデータを1回の1次データキャッシュアクセスで読み出すことを可能とした(Combined Gather機構)。これによりgather命令のスループットを最大2倍まで引き上げる。

**2.5. メニーコアアーキテクチャ**

図8にA64FXのメニーコアアーキテクチャを示す。チップ

**Many-Core Architecture**

- A64FX consists of four CMGs (Core Memory Group)
  - A CMG consists of 13 cores, an L2 cache and a memory controller
  - One out of 13 cores is an assistant core which handles daemon, I/O, etc.
  - Four CMGs keep cache coherency by ccNUMA with on-chip directory
  - X-bar connection in a CMG maximizes high efficiency for throughput of the L2 cache
  - Process binding in a CMG allows linear scalability up to 48 core
- On-chip-network with a wide ring bus secures I/O performance




図8：1次データキャッシュ制御

の性能最大化と省面積を両立するために、コアとキャッシュの間の接続方法は非常に重要な課題である。A64FXでは、CMG(Core Memory Group)という4つのグループに分割する方式を採用している。1つのCMGは、12個の計算コア、1個のアシスタントコア、2次キャッシュ、メモリコントローラで構成される。CMG内のコアと2次キャッシュの接続は、高いスループットのクロスバー方式を採用する。一般的にクロスバー接続方式は他のリングやメッシュ接続方式などに比べて実行効率が出しやすいものの、その分配線領域によるチップ面積を必要とするが、CMG内に閉じたクロスバー接続とすることでチップ面積増大を抑えている。さらに、CMGごとにメモリと直結することで、メモリレイテンシとスループットを最適にしている。また4つのCMG間は省面積のリング接続方式で、ccNUMA制御を採用している。プロセスを一つのCMG内に括り付け、4つのプロセスを各CMGに割り当てることにより、48コアまでリニアな性能スケラビリティを発揮する。なおTofuコントローラ、PCIeコントローラとCMG間はリングバスで接続される。

図9に、A64FXの演算器、キャッシュ、メモリそれぞれの階層のピークスループットとBF比(Byte per Flops)を示す。BF比はHPCアプリケーションの実行性能を左右する重要な指標である。A64FXは、前述の通りHBM2採用によるメモリバンド幅と、CMG構成による2次キャッシュの高いスループットを有することが大きな特徴である。アプリケーションの性能チューニングに際しては、2次キャッシュサイズに合わせてデータを配置し、キャッシュ上のデータ再利用性を活用するブロッキングという最適化手法があるが、A64FXの高

**Level 1 Cache**

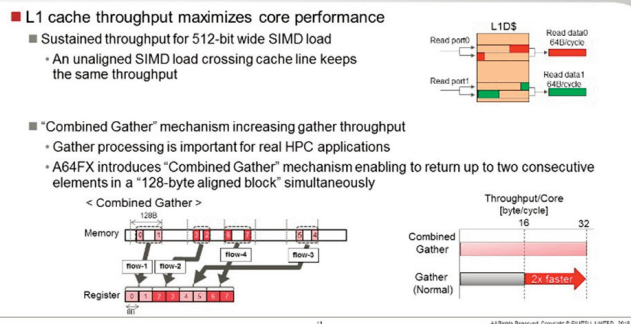


図9：キャッシュとメモリの高バンド幅

い2次キャッシュバンド幅によって、ブロッキングの効果を一層高めることが可能になる。

またA64FXは高いピークスループットに加え、コア、キャッシュ、メモリコントローラの高効率なアウトオブオーダー制御によって、各階層の実スループットを最大化し、広範囲のアプリケーションにおいて、優れた効率を達成する。

### 3. ベンチマークの特性とA64FXの性能

#### 3.1. HPCベンチマーク

HPC領域で一般的に知られるベンチマークとしては、LinpackとStream Triadがある。Linpackは密行列の行列積演算性能を評価するベンチマークで、主にDGEMM（倍精度浮動小数点の行列積演算ライブラリ）から構成される。またStream Triadは連続メモリアクセスにおけるメモリスループットを評価するベンチマークである。

また実際のアプリケーションでは、上記の密行列や連続メモリアクセスの他に、非構造解析などで疎行列を主に扱う場合も多数あり、そのようなアプリケーションではSIMDを用いた並列処理による性能向上が難しい特徴がある。

#### 3.2. AIベンチマーク

ディープラーニングや機械学習では新たなアルゴリズムが次々と開発され続けているが、基本的な処理である畳み込み演算処理は、学習用途では単精度の浮動小数点データのSIMD積和演算(FMA)、推論用途では8ビット整数のSIMD内積演算(Dot Product)を主要とするカーネルで構成される。また、これらを処理する演算器にデータを供給するための、メモリやキャッシュのスループットも重要であり、この点でHPC領域と共通する特徴を持つ。

#### 3.3. 性能評価

A64FXは、HPC、AI領域で必要とされる様々なデータ型の512ビット幅SIMD並列演算処理および、HBM2メモリ、高バンド幅キャッシュのマイクロアーキテクチャ、さらには最先端の7nmプロセステクノロジーの採用によって性能を大きく向上させている。

図10にA64FXの、富士通のHPC向けの前機種CPU SPARC64XIfxに対するHPCアプリケーションの性能向上比を示す。この結果は、SVEに最適化した富士通コンパイラ、ライブラリを用いて測定した結果である。

A64FXのDGEMMとStream Triadの性能は、2.5TFLOPSと830GB/sとなっており、汎用CPUとして非常に高い性能を示している。また流体や気象、地震解析などHPCアプリケーションのカーネルにおいては、512ビット幅SIMDに加え、Combined gather機構含めた1次、2次キャッシュスループットの強化によって、SPARC64XIfxより2.5倍以上の性能を達成している。

AI領域では、学習用途の性能として単精度浮動小数点の畳み込み演算、推論用途として低精度の畳み込み演算それぞれで高い性能向上を達成する。特に推論用途では、A64FXで導入した整数8ビットの内積演算(Dot Product)によりSPARC64XIfxに対し10倍近い性能向上となる。

### 4. まとめ

富士通が開発したA64FXは、HPC領域においてLinpackやStream Triadなどのシンプルなベンチマークに加えて、実アプリケーションのカーネルにおいても高い実行性能が発揮できることを示した。

またディープラーニングや機械学習といった新たなAI領域で必要とされる、単精度浮動小数点や8ビット整数データの畳み込み演算処理においても高い性能を発揮することを示した。

今後A64FXを搭載したシステムが多くのユーザの方々に活用され、HPC領域、AI領域の広範囲のアプリケーションにおいて高い性能を発揮し、ユーザの方々の持つ課題の解決に貢献していくことを期待する。

### 文献

- (1) T.Yoshida, "Fujitsu High Performance CPU for the Post-K Computer," Hot Chips 30, 2018  
<https://www.fujitsu.com/jp/Images/20180821hotchips30.pdf>
- (2) S.Yamamura, "A64FX High Performance CPU Design," Cool Chips 22, 2019.
- (3) Architecture Reference Manual ARMv8, for ARMv8-A architecture profile, ARM, <https://developer.arm.com/docs/ddi0487/latest/arm-architecture-reference-manual-armv8-for-armv8-a-architecture-profile>
- (4) SPARC64XIfx Extensions: Architecture Manual, Fujitsu, 2008 ;  
<https://www.fujitsu.com/downloads/JP/archive/imgjp/jhpc/sparc64viiiifx-extensions.pdf>
- (5) SPARC64XIfx Extensions 日本語版: Architecture Manual, Fujitsu, 2016; <https://www.fujitsu.com/jp/solutions/business-technology/tc/catalog/sparc64xifx-extensionsj.pdf>.

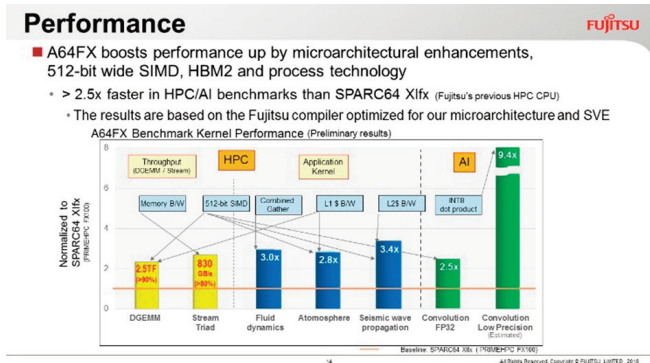


図10：A64FXの性能



## エヌビディアが加速するディープラーニングとHPC

佐々木邦暢  
NVIDIA

初めに

本稿では、GPUコンピューティングの状況とそれを支えるエヌビディアのハードウェアおよびソフトウェアについて歴史を簡単に振り返り、最新の状況をお伝えする。特に、昨今の所謂「AI」を支える機械学習技術と、伝統的なHPCの相互作用・融合に着目したい。

GPUコンピューティングの15年

2004年8月のSIGGRAPH 2004において、スタンフォード大学(当時)のIan Buck氏らによるチームが“Brook for GPUs: Stream Computing on Graphics Hardware”と題する発表を行った。BrookはC言語を拡張する形でGPUによる汎用的なデータ並列計算を実現するものであり、発表の中でIan氏はGPUコンピューティングの用途として、生命情報科学、レンダリング、シミュレーション、統計学などを示している。

その後エヌビディアで「CUDA」を生み出したIan Buckは現在もアクセラレーテッドコンピューティング担当副社長兼ジェネラルマネージャとしてGPUコンピューティングを推進し続けている。

2010年11月には中国のTianhe-1AがGPUスパコンとして初めてTOP500リストの首位に輝いた。またこの時、Tianhe-1Aと同じTesla M2050 GPUを4、224基備えるTSUBAME 2.0も4位に入っている。

その後、2012年11月にはFermiの後を継いだKeplerアーキテクチャによるTesla K20X GPUを18、688基搭載したORNLのTitanが首位を獲得。Titanを含め50システムがNVIDIA GPUを搭載しており、全体の10%がGPUスパコンとなった。

そして2018年6月には27、648基のTesla V100を搭載したORNLのSummitが1位に、これによってアメリカは4年半ぶりにTOP500の首位を中国から奪還した。

直近(2018年11月)のTOP500リストでは全500システム中128システム、そして上位10システムのうち5システムがGPUをアクセラレーターとして搭載している他、電力性能比のランキングであるGreen500では上位26システムのうち実に23システムがGPUを搭載している。またそれ以外の3システムもすべてアクセラレーターを活用したシステムで、PEZY-SC2を搭載した理研のShoubu system BはGreen500を3連覇中である。CPUのシングルスレッド性能の向上が頭打ちとなった現在、アクセラレーターを組み合わせたヘテロジニアスコンピューティングは高い電力性能比を実現するために欠かせない技術となった。

### summary

GPU-based computing for the masses




図 1 Brook for GPU

Brookの発表から今年で15年、その間にGPUコンピューティングはHPC分野を中心に大きな広がりを見せた。これはスーパーコンピューターの性能ランキングであるTOP500リストの変遷からも見て取れる。2008年に東京工業大学のTSUBAME 1.2が170台のTesla S1070 (GPU 680基)を搭載してTOP500リストの29位にランクインし、GPUスパコンという新たな分野を切り開いた。翌2009年にはエヌビディアがFermiアーキテクチャを発表。倍精度演算性能が飛躍的に向上したこの世代からHPC分野でのGPU利用は本格化し、

### HPCとAIの融合

昨今の注目すべき流れとして、高性能計算(HPC)とAI(ここでは統計的機械学習による分類・回帰等のタスク)の融合がある。これには「AIのモデルやデータセットが巨大化してマルチGPU、マルチノードの分散学習が必要となり、HPC環境で実行されるようになった(MLのHPC化)」「従来からのシミュレーションに、例えば機械学習による代理モデル等のAIを活用するようになった(HPCへのML活用)」という双方向の連携がある。ここではそれらの例をいくつか示す。

### ResNet-50チャレンジ

2012年のILSVRCを圧倒的なエラー率の低さで制したトロント大学のSupervisionチームは、2基のGeForce GTX 580で彼らのニューラルネットワークであるAlexNetをトレーニングするのに5-6日を要した。2012年といえば既にTOP500リストに50のGPUスパコンが並んでいたのは前述の通りであるが、AlexNetはまだそのような環境で生まれたわけではなかった。その後、ディープラーニング研究はさらに熱を帯び、モデルの複雑化とデータセットの大型化がさらに進んだ。

このような流れの中で生まれてきたのが、マルチノード環

境での大規模な分散深層学習である。2017年6月にFacebookの研究チームがTesla P100 GPUを256基(ノードあたり8基の32ノードクラス)使ってResNet-50のトレーニングを1時間で完了させたのは一つの大きな出来事であった。この「ResNet-50をILSVRC2012データセットで90エポック、精度75%」が一つの基準となり、以後次々に記録が塗り替えられていくことになる。

2017年の11月にはPreferred NetworksがTesla P100を1、024基搭載する自社のスーパーコンピューター“MN-1”を使って同じトレーニングを15分で完了させた。MN-1はノードあたり8基のTesla P100を搭載し、ノード間をFDR InfiniBandで接続した構成で、2017年11月のTOP500リストの91位にランクインしている。同社はより新しいVolta世代GPUであるTesla V100を512基搭載した“MN-1b”も構築し、これによって世界454チームが参加した物体検出コンペティション“Google AI Open Images - Object Detection Track”で準優勝を遂げた。この物体検出モデルは、MN-1bの全ノードを使ってなお1回の学習に33時間以上かかる規模であり、まさに“Machine Learning in HPC Environments”であると言える。同社はさらにTesla V100を1、024基搭載した“MN-2”を稼働させるなど、機械学習向けスーパーコンピューターの強化を続けている。

「ResNet-50チャレンジ」はさらに続き、2018年11月にはSONYが産総研のスーパーコンピューター“AI Bridging Cloud Infrastructure (ABCI)”で2分という記録を達成。2019年3月には富士通が同じくABCIを使って1.2分の世界記録を樹立している。ABCIは、1、088台の計算ノードが合計4、352基のTesla V100 GPUを備えるスーパーコンピューターであり、2018年11月のTOP500リストでは7位にランクされている。

表 1 ResNet-50 トレーニング時間の変遷

組織	アクセラレーター	フレームワーク	所要時間
Facebook	Tesla P100 x 256	Caffe	1 時間
Google	TPUv2 x 256 (TPU Pod)	TensorFlow	30 分
PFN	Tesla P100 x 1,024	Chainer	15 分
Tencent	Tesla P40 x 2,048	TensorFlow	6.6 分
SONY	Tesla V100 x 3,456	NNL	2.0 分
Google	TPUv3 x 1,024	TensorFlow	1.8 分
富士通	Tesla V100 x 2,048	MXNet	1.2 分

2018年のゴードン・ベル賞

「Machine Learning in HPC Environments」のもう一つの象徴的な例として、2018年のゴードン・ベル賞を受賞した“Exascale Deep Learning for Climate Analytics”<sup>[1]</sup>が挙げられる。LBNL、ORNLとエヌビディアのチームによるこの研究は、台風やハリケーンなどの熱帯性低気圧 (TC) や、豪雨の元になる大気河川 (AR) といった気象状況を検出するためTiramisu と DeepLabv3+ という二つのセマンティック セグメンテーション ネットワークの改良版をトレーニングした。使われたのは2018年11月のTOP500リストで首位にあるORNLのSummitと、同じく5位にランクするCSCSのPiz Daintである。Piz Daintでの改良版Tiramisuネットワークのトレーニングは5、300 GPUまでスケラブルで並列化効率は79.0%、演算スループットは21.0 PFLOPSを記録。また、SummitでのDeepLabv3+は27、368 GPUまでスケールし、並列化効率は単精度で90.8%、スループットは325.8 PFLOPSを達成した。さらに、Tesla V100が備える行列積和演算器Tensor コアを使うように改良したDeepLabv3では1.13 ExaFLOPSのピーク スループットを記録した。

HPCへのML活用

次に、HPC分野でMLを活用する動きについて見てみたい。その一つは2018年のゴードン・ベル賞において、惜しくも受賞は逃したもののファイナリストに選出された東京大学地震研究所、ORNL、CSCSによる研究[2]である。これはHPCとAIを組み合わせた超高分解能都市地震シミュレーションに関する研究であり、反復ソルバの収束性を改善するためにニューラルネットワークを利用、標準ソルバと比較して1/5.56に演算量を削減することに成功している。もう一つ重要な点として、倍精度(FP64)でのシミュレーションから半精度(FP16)を使ったニューラルネットワークの処理まで、複数の精度を使い分ける変動精度演算を活用している点が挙げられるこの研究にもSummitとPiz Daint、そして日本の京コンピューターが利用された。

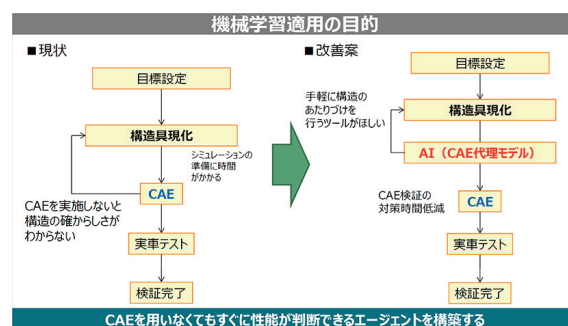


図 2 「歩行者保護性能を予測するためのサロゲートモデルの構築」

続いて2018年9月のGTC Japan 2018で発表された本田技術研究所の事例[3]を紹介したい。これは歩行者保護性能の高いエンジンフード形状を設計するために、従来のCAEモデルに代わってニューラルネットワークを利用するものであ

る。過去に開発した29機種のデータをTensorFlowで学習。得られたモデルはCAEによるシミュレーションとの誤差を5%以下に抑えながら、40時間程度かかっていた性能予測を10秒程度に短縮した。

### 混合精度演算

HPCからAIまで、GPUコンピューティングの適用領域が広がるとともに、GPUの機能も進化している。ここでは計算に用いる数値データ型について見てみたい。HPC用途には倍精度浮動小数点演算が重要であり、多くの倍精度演算器を搭載するようになったFermi世代GPUの登場から本格的なGPUコンピューティングの時代が始まったのは既に述べたとおりである。一方、機械学習分野でのGPU利用は単精度浮動小数点演算を中心に始まり、近年はさらに小さな数値型で演算を行うようになってきている

InterSpeech 2014でのMicrosoft Researchによる[1]は、データ並列の分散SGDにおいてGPU間でやりとりされる勾配を1ビットで表現する方式を提案し、これはMicrosoftのディープラーニングフレームワークであるMicrosoft Cognitive Toolkit (CNTK) にも1-bit SGDとして実装された。2015年のIBMの論文[6]では半精度の固定小数点数での演算で精度の低下なくトレーニングを高速化できることが示され、2017年の大山らによる[5]ではfp8でのトレーニングについて述べられている。また、Baidu Researchとエヌビディアによる[7]では、後述する混合精度演算について詳細な解説がなされている。

### 混合精度演算をサポートするエヌビディアのGPU

このように、現在のGPUコンピューティングでは様々な精度の数値型を使った演算が一般化しつつあり、エヌビディアはこれをハードウェアおよびソフトウェアの両面からサポートしている。

2015年発表のPascal世代GPUであるTesla P100では、1つのCUDAコアで2つのFP16数値を同時に処理することがサポートされ、これによってFP16の理論演算性能はFP32の2倍となった。また、同じくPascalアーキテクチャのTesla P40は主に推論用途向けにINT8型に対応し、47 TOPSという高い性能を発揮する。エヌビディアの推論最適化エンジンTensorRTはこれらFP16やINT8による最適化をサポートしている。

2017年発表のVoltaアーキテクチャでは、ディープラーニングの学習および推論フェーズにフォーカスした専用の演算器「Tensorコア」が導入された。TensorコアはFP16を入力とし、4x4行列の積和演算に相当する128演算を1サイクルで実行する能力を持つ。これによりTensorコアを搭載するTesla V100 GPUのFP16理論演算性能は125 TFLOPSに達し、Tesla P100のFP16性能21.2 TFLOPSの6倍弱に向上した。

最新のTuringアーキテクチャではTensorコアの機能がさらに拡張され、INT4およびBOOL (1ビット) の入力新たにサポートされた。これによりTuringアーキテクチャのTesla T4では、INT8で130 TOPS、INT4で260 TOPSの演算性能を持

つようになった。

### Tensor コア

混合精度行列演算ユニット

行列の FMA (Fused Multiply-Add)  
4x4 の行列の積和演算を1サイクルで計算する性能:  
128 演算/サイクル/Tensor コア、1024 演算/サイクル/SM

$$D = \begin{matrix} \text{FP32} \\ \text{(FP16)} \end{matrix} \begin{matrix} A_{0,0} & A_{0,1} & A_{0,2} & A_{0,3} \\ A_{1,0} & A_{1,1} & A_{1,2} & A_{1,3} \\ A_{2,0} & A_{2,1} & A_{2,2} & A_{2,3} \\ A_{3,0} & A_{3,1} & A_{3,2} & A_{3,3} \end{matrix} \begin{matrix} \text{FP16} \end{matrix} \begin{matrix} B_{0,0} & B_{0,1} & B_{0,2} & B_{0,3} \\ B_{1,0} & B_{1,1} & B_{1,2} & B_{1,3} \\ B_{2,0} & B_{2,1} & B_{2,2} & B_{2,3} \\ B_{3,0} & B_{3,1} & B_{3,2} & B_{3,3} \end{matrix} \begin{matrix} \text{FP16} \end{matrix} + \begin{matrix} \text{FP32} \\ \text{(FP16)} \end{matrix} \begin{matrix} C_{0,0} & C_{0,1} & C_{0,2} & C_{0,3} \\ C_{1,0} & C_{1,1} & C_{1,2} & C_{1,3} \\ C_{2,0} & C_{2,1} & C_{2,2} & C_{2,3} \\ C_{3,0} & C_{3,1} & C_{3,2} & C_{3,3} \end{matrix} \begin{matrix} \text{FP16} \end{matrix}$$

図3 Tensorコア

### 混合精度演算とモデルの正確度

Tensorコアはディープラーニングの特に学習フェーズの高速化に有用であり、前述した“Exascale Deep Learning for Climate Analytics”や東京大学地震研究所の都市地震シミュレーション、そして産総研ABCIを使ったSONYや富士通のResNet-50速度記録でもTesla V100のTensorコアが活用されている。また、機械学習の業界標準ベンチマークとして策定され、2018年11月に最初の結果が発表されたMLPerfでは、7部門中6部門でNVIDIA GPUが首位を獲得したが、これもTensorコアによる混合精度演算が大きく貢献している。

### 混合精度演算が MLPerf で勝利

7 部門中 6 部門で NVIDIA GPU が首位を獲得

シングルノードでのトレーニング時間		
画像分類 ResNet50 v.1.5 70 分	物体検出 (高負荷) Mask R-CNN 167 分	物体検出 (軽負荷) SSD 14 分
翻訳 GNMT 10 分	翻訳 Transformer 19 分	レコメンデーション NCF 0.4 分

図4 MLPerf

しかし、既存のモデルやプログラムがその恩恵を受けるためにはいくつかの課題がある。まず、Tensorコアは新しい演算器であるためディープラーニングフレームワークがこれに対応する必要があるが、この点については幸い多くのフレームワークが既に対応済みである。また、TensorコアはFP16を入力とするが、FP32とFP16では表現可能な範囲に大きな差があり、既存のモデルを単純にFP16化しただけでは同じ正確度を維持することができない。重みの原本はFP32で管理しつつ、順伝播、逆伝播の際にはFP16にコピーした値を使う、損失関数の値がFP16化で消失することを避けるために「ロススケール」を施しFP16で表現可能な範囲に収めるといった対応が必要になってくる。

### Automatic Mixed Precision

エヌビディアの提供する“Automatic Mixed Precision”機能は、このようなTensorコア対応作業の大幅な省力化を実現する。環境変数の設定、あるいは2、3行のコード追加でモデルの適切なFP16へのキャストやロススケールリングの有効化

が行われ、Tensorコアによる混合精度演算を容易に活用できる。現在、TensorFlow、PyTorch、MXNetの3フレームワークに対応済みである。

#### HPCとAIを支えるソフトウェア群

エヌビディアはGPUコンピューティングを支えるハードウェアのみならず、その性能を引き出すソフトウェアスタックを提供することを一貫して重視してきた。利用者は、土台となるCUDA、その上でディープラーニングやHPCアプリケーションを支えるcuBLAS、cuFFT、cuDNN、NCCLといったライブラリ等、様々なソフトウェアをダウンロード可能である。

しかしながら、日々進化を続けるフレームワークやアプリケーションを、依存ライブラリのバージョンを含めて整合性のある状態に維持し続けることはかなりの労力を要する。このようなソフトウェア環境の構築・維持に関する作業負担を軽減するサービスがNGCである。

NGCはHPCおよびディープラーニングのソフトウェアをDockerイメージの形式で提供するレジストリとしてスタートしたが、現在はそれにとどまらず、画像認識や物体検出等の汎用的なトレーニング済みモデル、トレーニングを実行するスクリプト、そしてスマートシティ向けの動画解析や医用画像処理といった業種特化型ソリューションまで揃ったソフトウェアハブとなった。また、HPC環境でのコンテナランタイムとして広く使われつつあるSingularityでのNGCイメージの利用もサポートされており、「HPCとAIの融合」時代の計算基盤として欠かせないものになりつつある。

NGCのコンテナイメージは、Pascal世代以降のGPUがあればオンプレミス、クラウドを問わず幅広い環境で動作する。NVIDIA DGX製品群や、NGCに対応したAWS、Microsoft Azure等のクラウド環境では必要ソフトウェアが導入済みであり、その他一般のPCやワークステーションでもGPUドライバとNVIDIA Dockerさえ準備すればすぐにNGCを利用可能となる。

例えば前述のMLPerfにエヌビディアが提出した画像分類(ResNet50-v1.5)のベンチマークテスト結果は、18.11版のMXNetイメージを利用したものであるが、このようなコンテナイメージを利用することで、GPUに最適化された実験環境をどこでもすぐに再現できる。是非、NGCと最新のGPUを活用しHPCやAIをさらに加速していただきたい。

#### 参考文献

- 1、Kurth, et al., Exascale Deep Learning for Climate Analytics, SC18 Proceedings of the International Conference for High Performance Computing, Networking, Storage, and Analysis, Article No. 51
- 2、Ichimura, et al., A Fast Scalable Implicit Solver for Nonlinear Time-Evolution Earthquake City Problem on Low-Ordered Unstructured Finite Elements with Artificial Intelligence and Transprecision Computing, SC18 Proceedings of the International Conference for High Performance Computing, Networking, Storage, and

Analysis, Article No. 49

- 3、歩行者保護性能を予測するためのサロゲートモデルの構築、<https://www.nvidia.com/content/apac/gtc/ja/pdf/2018/1037.pdf>
- 4、Seide, et al., 1-bit stochastic gradient descent and its application to data-parallel distributed training of speech dnns. In INTERSPEECH, 2014.
- 5、大山洋介、野村哲弘、佐藤育郎、松岡聡、ディープラーニングのデータ並列学習における少精度浮動小数点数を用いた通信量の削減、情報処理学会研究報告、Vol. 2017-HPC-158、No. 30、pp. 1-10、2017.
- 6、Gupta, et al., Deep Learning with Limited Numerical Precision, <https://arxiv.org/abs/1502.02551>
- 7、Narang, et al., MIXED PRECISION TRAINING, <https://arxiv.org/pdf/1710>.



## Armの「プロジェクト・トリリウム」——1兆個のIoTデバイスが繋がる未来へ必要なこと

菅波憲一  
アーム株式会社 リージョナルマーケティング シニアマネージャー

### はじめに

Armプロセッサが搭載されたデバイスの出荷数量が、2018年に累計1300億個を超えた。最初の500億個突破は創業から22年経った2013年、しかし次の500億個突破はそのわずか4年後の2017年だった。急激に伸びた要因はマルチメディア分野、特にスマートフォン市場の急拡大による。

そして、次の4年、2021年にArmプロセッサ搭載デバイスは累計2000億個を突破すると予想されている。牽引者はIoTデバイスの急拡大によるもので間違いないだろう。

Arm搭載デバイスが出荷数を伸ばしていく中、Armは「Project Trillium（以下プロジェクト・トリリウム）」というプロジェクトを立ち上げた。これは文字通りArm搭載デバイスがさらに加速度的に累計1兆個に到達するために次に何をすべきかという自社への問いかけであり、それを旗印にした様々な取り組みである。

その第一弾と呼べるのがエッジデバイス、とりわけIoTデバイスのAI(Artificial Intelligence：人工知能)/ML(Machine Learning：機械学習)化の推進である。

そこで今回は、次の10年のテクノロジードライバーになり得るAI/MLとIoTデバイス、この2つのシナジーと必然性、技術課題を取り上げ、Armのプロジェクト・トリリウムの一端を説明したい。

### エッジかクラウドか？

AI、MLは我々の生活に入り込み、また若干誇張気味に報じられている感はあるが、テレビ番組やSNS、一般紙面でも「AI」や「機械学習」といった専門用語がそのまま使われ、広く一般に浸透、普及し始めた。この分野には既に数兆ドルの市場規模やビジネスチャンスがあるとされている。様々なAIアプリケーションやサービス、AI搭載製品が急増する中、そこには単なるAIブームでは終わらない技術的な進化がある。コンピュータ性能が著しく向上し、機械学習用ネットワークの生成が短時間でできるようになったこと、アルゴリズム開発が進み機械学習の精度が向上していること、センサーやカメラなど外界から高精度、高精細のデータ収集をする技術がデジタル家電や産業機器に組み込まれ始めたことで、低コスト化が進んでいること、また、TensorFlowやCaffeといったソフトウェアツール開発が進みアプリケーション開発期間が容易になったことなどが挙げられる。

そしてここで、もう一つの重要な点を挙げたい。それは、組み込み向けLSI内部の演算性能の飛躍的向上により、AIの推論プロセスをエッジデバイスで実現することが可能になったことだ。

これは、AIに必要な演算を全てクラウドサーバーで行う従来型の「中央集中モデル」に対し、個人が持つパーソナルデバイスでAIの推論プロセスを実行する「エッジデバイスモデル」への可能性を意味する。

クラウドサーバーは確かにAIに革新を起こした。機械学習に必要なトレーニングを極めて短時間で終わらせることができ、それによってさらに複雑で大量のデータを扱うことでアルゴリズム開発が進み、精度が向上した。また、クラウドサーバーは今後さらに圧倒的なコンピュータ性能を持ち、拡大し続けることに間違いはない。我々が今日開発する機械学習のトレーニングはクラウドサーバーでの実行がベースとなっている。機械学習トレーニングには従来よりはるかに巨大なストレージ、コンピューティングパワーとそれに伴う処理時間が問題になるし、トレーニングに最適な教育用データセットも日々急速に進化し続けているため常に新しいトレーニングを必要としている。

実際にこの6年間で機械学習のトレーニング性能要求は急速に増加していて、次の100日で約2倍、つまりは2012年に比べ2019年現在のAIに必要なコンピュートレベルは軽く30万倍に達する計算になる。これらの事情を鑑みるとAIをクラウドで実現することは理にかなっており、最適なソリューションと言える。

しかしここで、クラウドがパワフルでスケラブルであり続けるならば、機械学習は永久にクラウドにあり続けられるか？という問いに対し、その答えがNoになる可能性が出てきた。

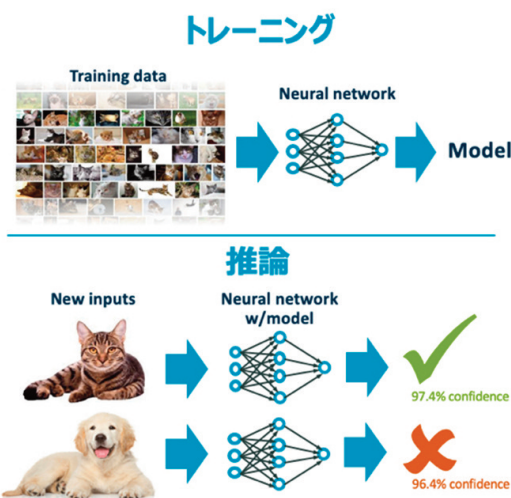


図1. トレーニングと推論



機械学習には大きく2つのパートに分けることができる。Training（トレーニング：学習）とInference（インファレンス：推論）だ。

学習は、入力するサンプルのデータセットを使った学習や認識するルールに基づきいくつかの種類のアプローチに発展させていくプロセスであり、推論はこのアプローチを使い「今」の状態を推論するプロセスであるトレーニングは過去、推論は現在についての処理となる。

例としてある写真に猫が写っているかを推論する場合、異なる100万枚の猫の写真から学習し、猫を認識するためのモデルを作ることがトレーニングというプロセスになり、写真に猫が写っているかどうかをそのトレーニングで得られたアプローチを使って判断することが推論になる。

一枚の写真の中に猫がいるかどうかを推論することにそれほど演算性能は必要とされないのだが、仮にインターネット上にあるあらゆる写真から猫を検出するとしたらここには強力な演算性能が必要になるだろう。

### 推論プロセスとエッジの優位性

ここで、推論プロセスはどこで実行するべきか？という問いが生まれる。

簡単に答えるならば、データが集まる場所、つまり将来的には推論はエッジデバイスで実行されるべきプロセスと言える。理由は明白だ。エッジデバイスにこそ必要な入力データがあり、そのエッジデバイスには推論プロセスを実行できる演算性能が備わっているからだ。

AI/機械学習が今後さらなるステージへ進化できるか否かは、エッジデバイスの革新にかかっていると見ていい。これはAIを全てクラウド側で行うには、物理的な制約、コスト的な制約、実用的な制約があるためだ。

想像してほしい。数十億、数百億台の各個人のエッジデバイスから入力された画像データや音声データをそのままクラウドにあげ、クラウド側で各個人用エッジデバイスに必要な推論を個別に施し、エッジデバイスに送り返すという作業を毎分・毎秒、異なる場面、異なるアプリケーションで行うことは実質不可能なことであることは想像に易い。

実世界で人々が関わるAIアプリケーションは、家電機器や車載のドライブアシスト、工業用ロボットなど様々な用途に広がるが、共通しているのは、これらすべてがエッジデバイスであり、かつリアルタイム応答を必要としている点だ。サーバー間とのデータのやりとりにかかるあらゆる時間が問題になる可能性がある。

例えば、ある画像データの中から何かを認識したい時、その外界データを画像データとして入力できるカメラデバイスがもっとも有効な推論プロセスの実行場所ということになる。

また、このカメラデバイスが入力した画像データをデータセンターへ送信する必要もない。よって、近い将来、推論プロセスがサーバー側からエッジ側に移行したとしたら、これは合理的で自然な流れと言える。またこの例では、カメラデバイスが推論プロセスを行う入力データの入手できる最も近いポイントであり、これは経済的にも、物理的にも、またそ

の地域性などを加味しても合理的と言える。

ここでいう物理的な要因は明確だ。あらゆる人々があらゆるアプリケーションを利用する中で、その瞬間、毎秒単位でビデオデータをクラウドサーバーに送り、その推論結果を逐一エッジデバイスにリアルタイム送信できるか？に尽きる。

インターネットは慢性的なパンク状態になり、データアクセスによる経済問題が起こる。

米国グーグル社はこう言っている。「もしすべての人がAndroid Voice Assistantを毎日たった3分使っただけで、今所有している規模の約2倍のデータセンターが必要になるだろう。これが大きなコストになるし、非現実的だ。そしてエッジ・サーバー間のデータ遅延対策は最も高額なコストになり得る。例えば自動車が横断歩道を認識しようとする。その時、我々はクラウドサーバーはセンサーからの生データを推論に使えるように加工翻訳し、その後このデータからインフェレンス(推論)し、自動車に止まるよう指示を出す、これら一連の処理をすべてクラウドサーバーに要求できるか？答えは明白だ。エッジデバイス、この場合は自動車でデータ解析と推論をする方が最も効率的で生産的だ。」

またプライバシーとセキュリティの課題もある。人々は様々な個人情報がインターネットなどに拡散されている、またはその可能性に大きな懸念と心配を抱いている。

つまり我々がAIを使うにあたり、個人のパーソナルデバイスが入手したデータがそのデバイス内で閉じて処理が行われ、決してパブリッククラウドにデータがアップロードされないことも人工知能が普及していく中で非常に重要な要因になり得る。



図2. クラウド型AIの課題

一方、推論プロセスをエッジデバイスで行う有意性を挙げ、詳細を以下に述べる。

- 多種多様なエッジデバイスによる拡張性
- リアルタイム応答性
- 省電力化
- セキュリティ
- コスト面、データセンターの活動を最小限に抑えられる

1つ目は拡張性だ。今世界中にどれくらいの数のコンピュータがあるか、正確には誰にも分からないだろう。しかし、世界中の約10%の電力がコンピュータに消費されていることはわかっている。同じように、今世界でどれくらいの数のCPUが稼働しているか正確には分からない。ただ、数十億台のスマートフォンが現在誰かの手元で動いていて、1つのス

スマートフォンには大体8コア構成のプロセッサが搭載されていることはわかっている。そこに、デジタル家電、デジタルカメラ、自動車などを加えると、おそらく、少なくとも1000億個以上のCPUが世界中で動いている。つまりは、これら1000億個のCPUが個々に推論プロセスを実行する担い手になりうる。1000億の異なる推論プロセスを同時に実行できることになる。

2つ目はリアルタイム応答だ。超巨大なスーパーコンピュータに光の速さでデータ転送される今日でも、エッジデバイスとクラウドサーバー間のデータ通信網がそれに比べて非常に遅い。もし車が自動運転中に、前方に何かが横たわっていたとする。それが猫なら急ブレーキ、スーパーのビニール袋ならそのまま進むという判断を求められた時、数百km、あるいは数千km離れたデータセンターからの推論結果を待つ時間がそこにあるだろうか？そしてこれが何百万、何千万台もの車が同時に要求する処理だとすると、サーバーで推論プロセスを実行するときに発生するエッジデバイスとの通信遅延は大きな課題である。とりわけ自動車と産業用IoTで重要になってくる。理由は工業用機械と自動車は共通して多くの異なる様々な物体を認識しなくてはならない点であり、またそれらに相互性がないため、クラウドとの画像データ通信や共有もあまり意味がない。

次に重要になってくるのは消費電力である。今密かに直面している問題は電波（ワイヤレス）のデータ送信で大量の電力が消費されることである。数メートルのBluetoothやWi-Fiであっても、数百億台に達するモバイルデバイスにおいてこのデータ通信による消費電力の抑制は地球規模でみると非常に効果的な節電といえる。

セキュリティに関するエッジデバイスの優位性は疑いようがない。仮に推論プロセスを実行するデータサーバーが数百キロ離れているとするとそのデータ経路にはセキュリティリスクが存在する。

また、コストに関してはこれまでの4つに比べてはるかにわかりやすい。エッジデバイスで推論プロセスを実行するために必要なLSI上のプロセッサのコストはクラウドデータセンターで推論プロセスを実行させるために必要なコストよりもはるかに低コストになる。

### エッジデバイスの課題

しかしながら、すべてのアプリケーションにおいて推論プロセスをエッジで実行することが良い、という単純なことでもないことも記しておきたい。クラウドで推論プロセスを実行する場合、その推論結果が接続されている全てのエッジデバイスからフィードバックされ、そこで新しいトレーニングによる改善が施され、システムは効率化を重ねる。よってこのシステムに接続されているエッジデバイスは常に改善されたAIにつながっていると言える。また推論プロセスがクラウドで実行される場合、エッジデバイスのOSやソフトウェアプラットフォームに推論プロセスが影響されない。つまり、エッジで推論プロセスを行う際の残された技術課題は新しい学習アルゴリズムのエッジデバイスへのアップデートと異なる

プラットフォームへの相互互換性である。

クラウドでの推論プロセスモデルとエッジタイプとの大きな違いは前者には大量のフィードバックデータが戻ってきて推論の精度が改善されていく点である。これらのデータは実運用中に収集されているものであるため、トレーニングによるさらなる改善が見込まれる。一方のエッジデバイスでのモデルにはデータのフィードバックはない。これはサーバーにフィードバックするトレーニングに必要なデータ収集とそれに伴うデータ通信を行う必要が出てきて、このためにエッジデバイスは常にサーバーとつながり、データをアップロードしなければならない、そのデータ収集と通信にかかるパワーとコストが非常に大きなものになるからだ。

また、ほとんどの組み込み機器は設計段階で、実現させる機能と性能をしっかりと決めていて、量産出荷後、ライフエンドまでその想定を超えるアップグレードは想定しない。

例えば、デジタルTVにおける音声コマンドやデジカメでの自動調整機能は内蔵されているLSIで既に実現可能だ。ファームウェアアップデートなどでいくつかの拡張機能はサポートされるが、それを越える機能や性能のアップデートは想定していない。

自宅にホームオートメーション機能があり、備え付けのセキュリティカメラで顔認識をして家の施錠・解錠が可能になっているとしよう。まず家族の顔とIDの登録といった初期設定を行う。その後、通常運用の中で得たデータ収集により顔認識の正確性と信頼性が高まることは利用者にとっても望ましいことである。厚手のコートやマフラーなどで顔の一部が隠れていても正しく認識できるようになり、あごひげや日焼けなどによる顔の変化にも対応できるようになる。

こうした継続的に改善が施されるためにはクラウドに置かれている顔認識アルゴリズムが継続的に日々改善され、新たな推論プロセスが安全にエッジデバイスにアップグレードされる必要がある。

これが個人のホームセキュリティデバイスでも、仮に数百店舗に並ぶ数万台のセキュリティカメラであっても、カメラの認識性能がアップグレードされることをユーザーは望んでいる。

PCやスマートフォンのアップグレードは比較的容易に感じるが、IoTデバイスの場合、機能性能や多岐にわたり様々な地域や範囲に出荷されるため、このアップグレードがどのようなシステムで行われるかは重要な課題である。

### ミドルウェアの重要性と相互互換性

例えば自動運転車を考えた時、エッジデバイスという定義は自動車全体に及ぶか、その中の電子ユニットを示すか、またはバンパーに組み込まれているセンサー部分になるか、それにより様々な意味合い役割が変わってくるが意味のあるデータが集まる場所であればその場所がエッジになりうると思う。例えばバンパーのセンサーが拾う全てのデータを、社内の中央装置やましてや搭乗者に知らせる必要はない。センサーは自動運転に必要なデータだけを中央装置に送り、その他のデータはセンサーデバイスが自己完結的に処理をすれば

いい。同様に加速度センサーのデータも必要なものだけを中央装置に送り、それ以外は内部で閉じれば良い。

実際にエッジデバイスによる推論プロセスにおいて、一体どれくらいのコンピュータリソースが必要になるかということについて、中央集権的なコンピュータで集約させるか、センサー単位で分散化する方がいいのかなどで大きく変わってくるし、様々ケースによって細かく異なっていくことが予想され、明確な答えは得られていないだろう。

ここで最も重要なことは、このようにシステムが必要に応じて変遷、細分化する中で、異なるOSやプラットフォームでも共通に使えるミドルウェアを提供し、これらのシステムがより柔軟にシフトすることができるようにすることであると考える。

将来は数え切れないほどのAI搭載のセンサーデバイスや製品が何百、何千という工場生産される。それぞれが別々のアプリケーションとして、別々の場所、時間、環境、別々の組み合わせで使われる。その一方、ニューラルネットワーク開発用フレームワークも多くリリースされている。

Caffe, Caffe2, MXNet, ONNX, PyTorch, TensorFlow Liteなど、この数多あるAIアプリケーションとAI開発のフレームワークがある中で、それぞれに対応するための個別の製品開発はコストがかかるし、非常に煩雑になる。

ここで、全てのフレームワークと全てのデバイスで共通に使えるミドルウェアが存在するとしたら、各デバイスやAI開発の効率は飛躍的に向上する。このミドルウェアも互換性を保ちつつ進化を続けていくとしたら、デバイス開発者はどのAIフレームワークを使うべきで、どう作らなくてはならないかに時間を縛られなくても良い。

そのミドルウェアがArm NN(Neural Network)というミドルウェアソリューションであり、Arm NNの開発構想である。

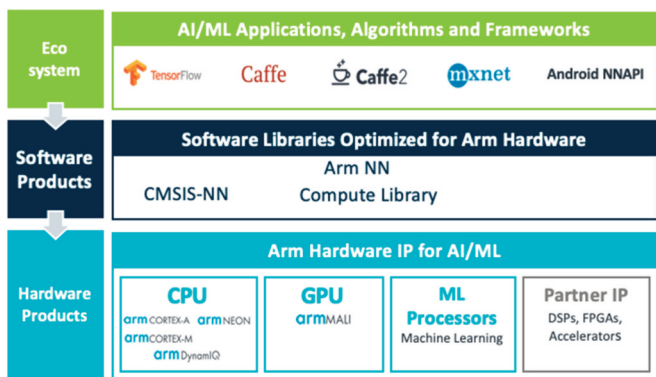


図3. ArmNNのソフトウェアブロック

エッジデバイス側でAI・MLアプリがビジネスとして成立するための最大のチャレンジがあるとすると、異なるプラットフォーム間における相互互換性になる。例えばスマホ向けのAI・MLアプリを作るとする。その時、あるスマホでは動きあるスマホでは動かないとなると、アプリ製作者は、世の中に何百種類とあるスマホへのポーティング作業と検証、新

しいスマホが出るたびに、途方もない労力をアプリ開発に割かなくてはならなくなる。

つまり、AI/MLを通して何兆ものデバイスに広がっていくためにはその規模の大小、異なるOSなど、何億ものデバイスの差異を吸収するHAL(ハードウェア抽象化レイヤー)つまりはミドルウェア層の共通化と中長期的ロードマップが必須条件であり、Armの「プロジェクト・トリリウム」における「AI/ML×IoTデバイス」への取り組みはエッジデバイスの推論プロセス用ミドルウェアArm NNへの中長期的な投資とオープンソース化が必須事項である。

これにより、AI/MLアプリ開発者はArm NNのミドルウェア層に向けて開発をすればOSがTRONであろうと、iOSであろうとAndroidであろうと、デバイスがスマートフォンであろうと、IoTデバイスであろうと中長期的な長いレンジで互換性が保たれることになる。また、ArmはArm NNミドルウェアプラットフォームの長期的なサポートを約束することにより様々なIoTデバイスが安心してAI/ML機能を搭載し、AI/ML機能によりお互いの繋がりに大きな意味を持ち、共有することでIoTデバイスが爆発的に普及し、またIoTデバイスからスマホまであらゆるエッジデバイスがAI/MLで繋がることをプロジェクト・トリリウムの根幹として戦略づけているのである。

おわりに

自動車は今日無数のセンサーを積んでいるが、私たちが普段使っているボールペンもAIデバイスになり得るかもしれない。加速度センサーがボールペンに内蔵され、今書いている文字を記憶し、電子データとして記録してくれるそしてその文字認識精度もAIにより圧倒的に向上する。コーヒーマーカーが人の視線を認識しただけでコーヒを沸かすかを判断したら、エアコンが温度計ではなくそこにいる人の動作で暑さを読み取れたら、など想像は尽きないが、近い将来、間違いなくセンサーとAIは緊密な関係になる。

エッジデバイスのコストは今後も下がり続ける。同時にエッジデバイス内の演算性能は急速に向上している。

昨日パソコンでしかできなかったことが今スマホでできるようになり、近い将来スマホでしかできなかったAIがセンサーデバイスでできるようになるかもしれない。こう考えるとIoTデバイスで実現できるAIアプリケーションやその可能性は絶大で、そこで創造されるビジネスチャンスは計り知れない。

プロジェクト・トリリウム。

一兆個突破はArmにとって大きな目標ではあるが、あなたがち大きすぎる目標ではなく、案外早く訪れるかもしれない密かに期待を寄せている。

部門からのお知らせ

### 第31回計算力学講演会(CMD2018)優秀講演表彰

越塚誠一  
東京大学大学院工学系研究科

徳島大学で開催された第31回計算力学講演会における講演等について、座長および参加者に評価をお願いした結果に基づき表彰選考委員会において選考を行い、優秀講演表彰3名、優秀技術講演表彰3名、日本機械学会若手優秀講演フェロー賞5名を表彰することとなりました。表彰状を受賞者にお送りするとともに、本誌上に公開してお祝い申し上げます。

●優秀講演表彰

荻野正雄 (名古屋大学)

粒子初期配置における機械学習の応用に関する検討

渋谷陽二 (大阪大学)

均質Micromorphic体のはり近似における局所・非局所の関係性

山口哲生 (九州大学)

ネットワーク状弾性体のトポロジカルメカニクスと強化

●優秀技術講演表彰

笹島 学 (フォスター電機株式会社)

閉塞型イヤシミュレータと実耳形状モデルの有限要素法解析

蛇川順博 (株式会社SUMCO)

ICP-MS用傾斜シリンダー型スプレーチャンバー設計へのシミュレーション適用

前田 成人 (横浜ゴム株式会社)

非線形粘弾性構成則を用いたタイヤの転動シミュレーション

●日本機械学会若手優秀講演フェロー賞

芦田 肇 (大阪大学)

銀-アルミナ 接合機構解明に向けたマルチスケール解析

工藤拓也 (東北大学)

第一原理計算に基づくダンベル型グラフェンナノリボン

塩谷光平 (金沢大学)

ハイエントロピー合金化に対する構成元素の原子半径比の影響(2体間相互作用の分子動力学シミュレーション)

中村 俊 (東京工業大学)

クラスタリングを用いた湾曲繊維CFRPの最適繊維配向モデルの探索手法の提案

堀川 由人 (大阪大学)

アイソジオメトリック解析を用いた曲面展開論


●優秀講演表彰



荻野正雄君



渋谷陽二君



山口哲生君



笹島 学君



蛇川順博君



前田成人君

●優秀技術講演表彰


●日本機械学会若手優秀講演フェロー賞



芦田肇君



工藤拓也君



塩谷光平君



中村 俊君



堀川由人君



## 第32回計算力学講演会(CMD2019)開催案内

田村善昭  
東洋大学総合情報学部／計算力学研究センター

川越市鯨井2100)で2019年9月16日(月・祝)から18日(水)までの3日間開催されます。昨年度は11月下旬でしたので、約2ヶ月早くなっています。ご注意下さい。

東洋大学は、1887年に井上円了先生により創立された「私立哲学館」をその基としています。現在は、白山、赤羽台、朝霞、川越、板倉の5キャンパスに総合スポーツセンター(板橋区)と大手町サテライトキャンパスからなり、14学部、18研究科を持つ大規模な私立大学です。

本講演会が行われる川越キャンパスは、このうち、理工学部と総合情報学部、理工学研究科、総合情報研究科および学際・融合科学研究科とそれらに関連する研究センターなどがあります。交通の便や宿泊等を考えると、白山や赤羽台などの東京都内のキャンパスの方が開催地としては適当かとも思われますが、ご他聞に漏れず本学も講演会場の教室確保が難しく、その点、自らが所属する川越キャンパスであれば、ある程度の融通も利き、講演会場も余裕を持って準備できるという判断で選びました。東京開催と思われていた方にはご不便をおかけしますが、池袋から東武東上線急行で40分の鶴ヶ島駅が最寄り、思われるほど遠くはありません。



東洋大学川越キャンパス1号館(講演会場予定)

埼玉と言えば、先日「翔んで埼玉」なる埼玉自虐映画がヒットしたように、何もない県として知られていますが、ここ川越は江戸時代より舟運の拠点、また江戸の北の守りの要衝として譜代大名が治めた土地で、「小江戸」とも呼ばれ、現在もその歴史を感じさせる町並みが多く、観光客を集めています。「栗(九里)より(四里)うまい十三里」と詠まれたさつまいもの和菓子やうなぎなど名物も多くあります。この機会に、是非訪れてみてはいかがでしょうか。

さて、講演会についてですが、川越キャンパスで機械工学や計算力学を専門とする教員、ならびに筆者が所属する本学

計算力学研究センターの客員研究員を中心に実行委員会を組織し、鋭意、準備を進めているところです。講演会のスタイルは、従来通りオーガナイズドセッションを中心に発表を募集します。特別講演は2件を予定しており、現在、講演者を調整中です。懇親会も例年通り2日目の夜になります。新しい試みとしては、機器展示の企業によるランチョンセミナーを企画しています。川越キャンパスは緑に囲まれた自然豊かな、勉学にはとても良い環境ですが、一方で昼食をとるところが学食以外あまりありません。その意味でも、お弁当が付きランチョンセミナーはご参加いただく価値があると思います。その他、詳細については、下記に記載のHPを随時ご覧下さい。

多くの皆様のご参加を心よりお待ちしております。

### 講演会HP

<https://www.jsme.or.jp/cmd/conference/cmdconf19/>

### 連絡先

田村善昭(実行委員長)  
東洋大学総合情報学部／計算力学研究センター  
〒350-8585 川越市鯨井2100  
Tel・Fax: 049-239-1475  
E-mail: [cmdconf19@jsme.or.jp](mailto:cmdconf19@jsme.or.jp) (実行委員会)



## 2019年度年次大会の部局企画について

岡部朋永  
東北大学大学院工学研究科航空宇宙工学専攻

日本機械学会2019年度年次大会は、2019年9月8日（日）から9月11日（水）までの日程で、秋田大学手形キャンパス（〒010-8502秋田市手形学園町1番1号）で開催される予定です。本年度の年次大会では、「まんず、あべ！機械学会さ！－秋田に集うしっただけおもしろ技術－」をキャッチフレーズに、「サスティナビリティ」「AI社会の機械工学」「少子高齢化・人手不足を支えるテクノロジー」を3つの主要テーマとして実施します。機械工学、計算力学に関する最先端研究の発表および活発なご議論をさせていただき、情報交換や交流の場としてご活用いただければと思います。また、特別企画なども数多く予定しており、一般の方、企業の方、学生の方も含めて数多く参加していただければと思います。詳細に関しましては2019年度年次大会webページをご覧ください。

<https://www.jsme.or.jp/conference/nenji2019/index.html>

計算力学部門では、次の特別企画・オーガナイズドセッションを実施予定です。皆様のご参加を心からお待ちしております。

### 【特別企画】先端技術フォーラム

- ・「Society5.0を支える人と人工物システム・サービスの計算情報科学基盤創成へ向けて」

（計算力学部門）

企画者：越塚誠一（東京大学）、平野徹（ダイキン情報システム）

講師：平野徹（ダイキン情報システム）、村上存（東京大学）、村川正宏（産総研、人工知能研究センター）、奥田洋司（東京大学）、佐々木直哉（日立製作所・研究開発グループ）

### 【オーガナイズドセッション】

- ・「電子情報機器、電子デバイスの強度・信頼性評価と熱制御」

（計算力学部門、熱工学部門、材料力学部門）

小金丸正明（鹿児島大学）、畠山友行（富山県立大学）、木下貴博（富山県立大学）、池田徹（鹿児島大学）

- ・「安心安全な水素社会を創る流体解析と計測技術」

（計算力学部門、流体工学部門）

松浦一雄（愛媛大学）、月川久義（元九州大学）、錦慎之助（鹿児島大学）、鈴木健吾（新コスモス電機株式会社）、寺田敦彦（日本電子力研究開発機構）、丸祐介（宇宙航空研究開発機構）、朝原誠（岐阜大学）、茂木

俊夫（東京大学）、小林弘明（宇宙航空研究開発機構）、加藤喜峰（九州大学）、湯川宏（名古屋大学）

- ・「燃料電池・二次電池とナノ・マイクロ現象」

（材料力学部門、流体工学部門、熱工学部門、計算力学部門、動力エネルギーシステム部門、マイクロ・ナノ工学部門）

橋田俊之（東北大学）、大島伸行（北海道大学）、田部豊（北海道大学）、花村克悟（東京工業大学）、鹿園直毅（東京大学 生産技術研究所）、徳増崇（東北大学 流体科学研究所）

- ・「工業材料の変形特性・強度およびそのモデル化」

（機械材料・材料加工部門、材料力学部門、計算力学部門）

佐々木克彦（北海道大学）、金子堅司（東京理科大学）

- ・「流体機械の研究開発におけるEFD/CFD」

（流体工学部門、計算力学部門）

古川雅人（九州大学）、船崎健一（岩手大学）、山本悟（東北大学）、渡邊聡（九州大学）、重光亨（徳島大学）

- ・「解析・設計の高度化・最適化」

（設計工学・システム部門、計算力学部門）

西脇眞二（京都大学）、下田昌利（豊田工業大学）、山本崇史（工学院大学）、長谷川浩志（芝浦工業大学）

- ・「医工学テクノロジーによる医療福祉機器開発」

（医工学テクノロジー推進会議、機械力学・計測制御部門、バイオエンジニアリング部門、材料力学部門、機素潤滑設計部門、流体工学部門、ロボティクス・メカトロニクス部門、熱工学部門、計算力学部門、情報・知能・精密機器部門、マイクロ・ナノ工学部門）

陳 献（山口大学）、佐久間淳（京都工芸繊維大学）、葭仲潔（産業技術総合研究所）、藤井文武（山口大学）

お問合せ先：

岡部朋永（東北大学大学院工学研究科航空宇宙工学専攻）

okabe@plum.mech.tohoku.ac.jp

## 計算力学部門・イベント情報

イベント	開催日	開催地
第 32 回計算力学講演会 (CMD2019)	2019. 9. 16-18	東洋大学 川越キャンパス
KSME-JSME Joint Symposium on Computational Mechanics & CAE 2019 ※第 32 回計算力学講演会 (CMD2019) との併催	2019. 9. 18	東洋大学 川越キャンパス
計算力学技術者 2 級 (固体力学分野の有限要素法解析技術者) 認定試験対策講習会 (関東地区会場)	2019. 10. 5	慶應義塾大学 矢上キャンパス
計算力学技術者 2 級 (固体力学分野の有限要素法解析技術者) 認定試験対策講習会 (関西地区会場)	2019. 11. 15	大阪科学技術センター
計算力学技術者 2 級 (固体力学分野の有限要素法解析技術者) 認定試験対策講習会 (東海地区会場)	2019. 11. 16	名古屋大学 東山キャンパス
第 33 回計算力学講演会 (CMD2020)	2020. 9. 23-25	鹿児島大学

※イベントの最新情報、詳細は下記 URL をご確認ください。

計算力学部門ホームページ イベント情報

<https://www.jsme.or.jp/cmd/events-j.html>

日本機械学会ホームページ イベント情報

[https://www.jsme.or.jp/?s=&eventmonth=&eventlocation=&eventdivision=event-cmd&post\\_type=event](https://www.jsme.or.jp/?s=&eventmonth=&eventlocation=&eventdivision=event-cmd&post_type=event)

---

《各行事の問い合わせ、申込先》

日本機械学会計算力学部門担当 大黒 卓 E-mail: daikoku@jsme.or.jp

〒160-0016 東京都新宿区信濃町35番地 信濃町煉瓦館5F TEL 03-5360-3503 FAX 03-5360-3508

計算力学部門ニュースレター No. 61 : 2019年5月28日発行

編集責任者：広報委員会委員長 村松真由

ニュースレターへのご投稿やお問い合わせは下記の広報委員会副委員長までご連絡ください。

なお、各記事の文責は著者にあります。

広報委員会副委員長 西正人 E-mail: nishi.masato@jsol.co.jp

株式会社JSOL エンジニアリングビジネス事業部

〒104-0053 東京都中央区晴海2-5-24 晴海センタービル

TEL 03-5859-6020 FAX 03-5859-6022