発 行 所 日本機械学会 計算力学部門
お問合せ 03-3560-3501

ISSN 1340-6582

日本機械学会 計算力学部門

CMD Newsletter

COMPUTATIONAL MECHANICS

計算力学部門ニュースレター No.58 Nov., 2017

目次

・特集「機械学習」

IoT、AI時代の製品開発と拡張CAE～深層学習、強化学習、転移学習の工学分野への応用～
……ダイキン情報システム（株）、CAE懇話会　平野　徹 …2

深層学習の発展と画像認識 ……東京大学　中山英樹 ……4

深層学習の実世界応用へのアプローチ ……早稲田大学基幹理工学部表現工学科
産業技術総合研究所人工知能研究センター　尾形哲也 …8

深層学習 ……近畿大学 理工学部 機械工学科　和田義孝 ……11

・部門からのお知らせ

30回計算力学講演会（CMD2017）の開催報告 ……近畿大学 理工学部 機械工学科　和田義孝 ……15

2017年度年次大会の部門企画開催報告 ……東洋大学 総合情報学部　中林　靖 ……18

KSME-JSME Joint Symposium 開催報告 ……東京理科大学理工学部機械工学科　岡田　裕 ……20

特集「機械学習」

IoT、AI時代の製品開発と拡張CAE
～深層学習、強化学習、転移学習の工学分野への応用～

平野　徹
ダイキン情報システム（株）、CAE懇話会

1．はじめに

昨今のICT技術の急激な進展を受けて、携帯電話だけではなくあらゆる物がインターネットに繋がり膨大な情報を発信、新たなビジネスをスマート・サービスとして実現するIoTが、今後の大きなビジネスの潮流として急拡大をしている[1]。さらに、IoTによって生成される膨大なデータを解析するビッグデータ解析のニーズとビジネスにおける活用も、大きな課題となりつつある。

一方、画像処理に深層学習（Deep Learning）を適用することで大幅な認識率の向上が得られたことから、第３次AIブームとして機械学習、特に深層学習や強化学習（Reinforcement Learning）の研究と応用が非常に活発化している[2]。

ここでは、IoTやAIを前提とした製品開発の在り方や、そのために利用するCAE技術の定義範囲を拡張することを提案したい。

2．AIの急進展：深層学習、強化学習、転移学習

深層学習の一般物体認識における大成功は、畳み込みニューラルネットワーク（CNN）の構造がタスクに非常に良く適合したことに加え、質の良い大規模教師付データセットがいち早く整備され、研究コミュニティで共有されることになったことに拠るところが大きい[2]。現在では、1400万枚以上のアノテーション済み画像データを有するImageNetをベースに画像認識コンペ（ILSVRC）が毎年開催され、人間の認識率を超えるレベルでGoogleやMSの戦いが続いている[2]。

一方、昨年広く世間の耳目を集めたのは、Google傘下のDeep Mindチームが作成した囲碁AIソフトであるAlphaGOが韓国No. 1棋士を破った事であろう。囲碁はチェスなどに比べてはるかに巨大な探索空間を持つので、当分の間、人にAIソフトは勝てないという世間の認識に対し、CNNとモンテカルロ・ツリー探索、更に強化学習を組合せてAlphGOを構築、学習を継続しながらレベルを向上してきている。まず、16万局の棋譜をCNNで学習、更に学習済ＮＮ同士を互いに対局させる強化学習によって囲碁のValue Networkを構築、膨大な数の学習を大量のCPU／CPUを使い高速化し（それでも３週間以上）を完成させたという[3]。

強化学習は教師データを明示的に与えるのではなく、報酬というスカラー値の定義を与えるだけで、エージェントが試行錯誤を通じて環境に適応する学習制御の枠組みであるため、ロボット制御プログラミングの自動化などに適用されつつある[4]。

さらについ最近のトピックスとして、Deep Mindチームは事前の学習を一切せずに、囲碁のルールだけを組み込んだ強化学習によって僅か3日間の対局学習によって、AlphaGOを完全に凌駕するAlphaGO Zeroを構築したことをNatureに発表し衝撃を与えた[6]。これは、強化学習による教師無学習の強力な可能性を示していると言える。

一方、既に人間の認識レベルに到達した深層学習による画像処理の学習済CNNを利用して、異なるタスク・データセットへの知識転移を図る転移学習（Transfer Learning）の実現可能性が早くから示唆されてきた[2]。最近では、教師有学習（Supervised Learning）の次に機械学習の進展を推進するのは転移学習であると、注目されている[5]。転移学習では、最初に機械学習をした対象ドメインと、転移利用対象のドメインの違いを学習させるアプローチも出てきている[5]。

今後、製品の知能化開発として転移学習を活用するために、組み込みソフトの一部に学習済ＮＮを取込むプロセスが必要となるだろう。

3．IoTとCyber Physical System (CPS)

IoTとは物（機器）や設備がネットワークによってクラウド・プラットフォームに接続され、機器の運転データなどが時々刻々集められ、クラウド上にある機器モデル（Digital Twin）の仮想運転データと比較し性能や寿命の予測を行い、さらに多数の機器群の運転データを統合的に学習し予測機能の改善を継続的に行い、合わせてその予測結果から機器群の運転を最適に制御するものである。

その基本アーキテクチャがCyber Physical System（CPS）と呼ばれる概念で、クラウド側のDigital Twinのソフトウエア構成とともに、機器側の組み込みソフトの重要性と機能的拡充の要求が増大している。例えば、機器の構成や転送するデータの定義などをクラウド側からフレキシブルに変えられる機能（Software Defined Machine）や、機器側の組み込みソフトとして取り込まれた学習済ＮＮを、定期的に改訂する機能も必要になるだろう。

さらに、機器とクラウドの間に適切なローカル処理を行うエッジ・コンピュータを設置することなども、データ転送を最適化する現実的アプローチとして考えられている。

4．Connected Productsの製品開発

今後開発されるあらゆる製品は、上記の様にIoTによってネットワーク接続されてゆく（Connected Products）。さらに知能化製品として、学習済ＮＮを取込んでゆくことになる。そのためには、従来の製品単体での機能設計・構造設計と合わせて、知能化設計とネット化設計が必要であり、その開発プロセスでのそれぞれの検証システムが新たに必要となる。

近年、自動車の設計において広く適用されつつあるＭＢＤ（Model Based Development）は、個々のコンポーネントの数値モデルを組み合わせ、更にエンジン制御回路の運転制御ソフトウエアの動作も含めてモデリング言語を用いて統合化し、自動車の運転性能と振動騒音特性を同時に時系列的に机上予測するマルチパラダイム統合設計システムであるが、このＭＢＤモデルに上述のConnected Productsの開発のために、知能化設計とネット化設計の機能コンポーネントを組合せる必要が出てくる。さらにＭＢＤモデルを使った開発が完了した時点でクラウド側のDigital Twinのモデルとして適用することができる。

ネット化設計では、インターネットなどを介して機器が接続されるため、ネットワーク・セキュリティーやハッキング等のリスクに関する考慮も非常に重要である。

図１に、Connected Productsの革新的設計軸及び、ＣＰＳ構成と、組込ソフトの必要項目を示す。

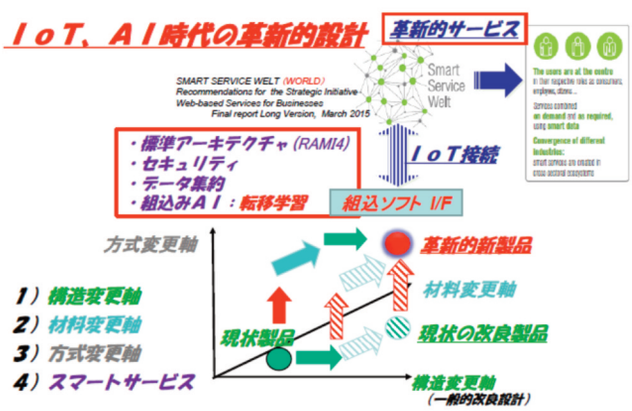

図１．Connected ProductsのCPS構成と組込ソフト

５．IoT、AI時代の拡張CAE

製品開発に利用されるCAEの基盤となる技術である計算力学は、様々な工学分野や自然現象を適切な支配方程式を用いて定式化・モデル化し、それを離散化して計算機上で数値的に解を求めるものである。一方、計算科学の定義は図２に示すように、理論と実験と共に第３の科学として位置づけられ、特に工学分野での計算力学活用の目的は、最終的に必要とする人工物を安全性・コスト等を考慮して最適に設計することである（シンセシス・アプローチ）。そのために３次元の構造物を離散化モデルとして形状設計し（設計工学）、構造健全性を評価するための構造力学解析と、周囲環境負荷や機能性を評価するための流体力学、熱力学など、異なる物理現象を連成するマルチフィジクス解析の必要性が高い。

設計最適化計算を行うためには、複数の設計変数を多様に変化させて多数の解析を行うアンサンブル・コンピューティングにより設計解空間を探索する必要がある。その際、初期設計条件から出発し目的関数を最適化（最大化、或は最小化）するための条件変更・探索には、非線形計画法や供役勾配法等の数理的手法の他に遺伝的アルゴリズムやニューラル・ネットワークなどの知識工学的手法が有効である。

一方、自然現象への計算力学活用の主たる目的は、気象予測のように時々刻々変化する実現象データから短期的な将来気象を予測するための解析や、長期的な地殻変動によって引き起こされる地震や津波による地域や都市の災害シミュレーションのように、将来起こりうる災害等に備えるために予測をすることにある（プレディクティブ・アプローチ）。

特に気象予測解析で広く活用されているデータ同化手法は、ベイズ統計学と状態空間モデルを組み合わせ、多数の実計測データを継続的に用い予測解析の精度を改善してゆく数理的手法で、工学分野での応用として解析結果と計測データを融合したデータ駆動型シミュレーション技術として、さらに上述のIoTにおけるCPSと対比すべき概念であり、拡張CAEの定義に含めるべきと考える。

さらに、HPCとして確立されてきた大規模計算力学手法は、その並列化手法や膨大な入出力データを処理するアルゴリズムを含めて、今後、あらゆる機器・設備がネットワークに接続され膨大なデータを生成・蓄積・処理するIoT時代に、AIやデータ駆動型サービスのシステム・モデルとして、拡張CAEの範疇に含めるべき技術と考える。

６．まとめ

IoTやAI技術の急進展を概観し、今後の製品開発やスマート・サービスの方向性を示し、その開発を支援する技術群を拡張CAEと再定義した。特に、今後のAI技術の進展に関し、転移学習に注目すべきと考える。

なお、本稿はCMD2017での筆者の講演（7）に新情報等を加え、一部加筆したものである。

７．参考文献

１）平野、Industry4.0、IoT時代のものづくりとCAEの再定義、機械学会2017年度年次大会、埼玉大学、先端技術フォーラム、F011001（2017）
２）中山、深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習、電子情報通信学会音声研究会7月研究会, 2015
３）D. Silver, et al., Mastering the game of Go with deep neural networks and tree search, NATURE, Vol.529, 28 Jan. 2016
４）http://sysplan.nams.kyushu-u.ac.jp/gen/edu/RL_intro.html#Section1
５）http://ruder.io/transfer-learning/index.html
６）D. Silver, et al., Mastering the game of Go without human knowledge, NATURE Vol.550, 19 Oct. 2017
７）平野、IoT、AI時代の製品開発と拡張CAE、機械学会・第30回計算力学講演会(CMD2017)、フォーラム０１、F01-1 (2017)

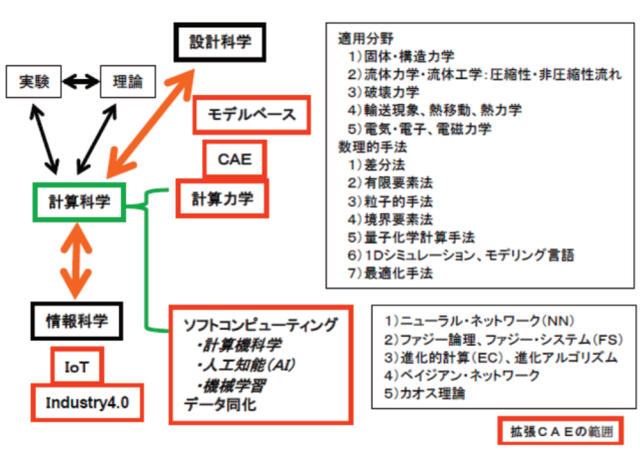

図２．計算力学と他の諸科学との関係（拡張CAE）

深層学習の発展と画像認識

中山英樹
東京大学大学院情報理工学系研究科（創造情報学専攻）

1. 画像認識における深層学習の歴史

一般画像認識とは、制約のない実世界画像を言葉によって説明するタスクであり、古くから人工知能の究極的な目標の一つとされてきた。本分野の歴史は長いが、2000年代から機械学習によるアプローチが成功を収めるようになり、コンピュータビジョン分野において精力的に研究されるようになった。より具体的に画像認識の目的を述べると、 入力画像xが与えられた時に、これを自動的に何らかのラベルy（例えばカテゴリ名や物体の座標など）へ変換する関数$f: x \rightarrow y$を得ることであると言える。 機械学習に基づくアプローチは、 入出力の多数の事例データからなる訓練データセット$\{x_i, y_i\}_{i=1}^{N}$（Nはデータ数） から、 そのような関数f を帰納的に推定する。すなわち、 fとしてある識別モデルや確率モデルを仮定し、そのパラメータを推定する一連の手続きを与えるものである。深層学習はこのような機械学習手法の一つであり、ニューラルネットワークと呼ばれる技術を用いた手法の総称である。ニューラルネットワーク自体は数十年に及ぶ研究の歴史があるが、深層学習という言葉は特に最近の多層化が進んだ大規模なニューラルネットワークを指すことが多い。

さて、ニューラルネットワークは最初から現在のような成功を収めていたわけではなく、長い冬の時代を経験していたが、2010年代に入り状況が大きく変化しはじめた。特筆すべきは、ImageNet [1]という大規模教師付き画像データセットが公開されたことである。ImageNetは21841クラス、1400万枚ものアノテーション済み画像データを有する。2010年から2017年まで、ImageNetのデータの一部（1000クラス）を用いたコンペティション型ワークショップであるImageNet Large-scale Visual Recognition Challenge (ILSVRC)が毎年開催されており、2000年代の研究の数百倍から数千倍もの規模のデータを自由に利用し、共通の土俵で競い合うことが可能になった。また、同時期にGPU技術の進歩により計算機能力の著しい発達があったことも忘れてはならない。このように、学習データ量・計算機資源の双方において、深層学習が真の力を発揮する土壌が整いつつあった。

ブレークスルーとなったのは、2012年のILSVRCにおけるトロント大学のHintonらの躍進である。彼らは8層の畳み込みニューラルネットワーク(CNN)を用い、1000クラス識別のエラー率において二位のチームに10%以上もの差をつけて圧勝し、世界中の研究者に極めて大きな衝撃を与えた[2]（図1）。2013年以降のILSVRCではほぼすべてのシステムがCNNベースに置き換わり、現在に至るまで驚くほどの性能向上が続いている（図2）。同タスクにおける人間のエラー率は約5.1%であるとの報告もあり、2012年のブレークスルー後わずか三年ほどで人間レベルを超える驚異的な発展を遂げていることが分かる。

2. 深層学習手法の進化

2.1 畳み込みニューラルネットワーク(CNN)

深層学習の手法は数多く提案されており、画像認識分野においても様々なネットワークが検討されてきたが、現在最も顕著な成功を収めているのはCNNである。CNNは古典的な多層パーセプトロンの延長にあるが、脳の視覚野の構造における知見[3]を基に、ニューロン間の結合を局所に限定し層間の結合を疎にしていることを特徴とする。より具体的には、図3に示すように、画像の局所的な特徴抽出を担う畳み込み層と、局所ごとに特徴をまとめあげるプーリング層（サブサンプリング層）を繰り返した構造となっている。このような畳み込み・プーリングの繰り返しによるアーキテクチャは日本の福島らが開発したNeocognitron [4]が初出であった。その

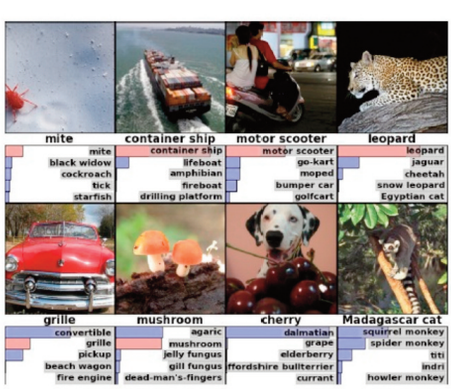

図1：AlexNetの画像認識結果. 図は[2]より引用.

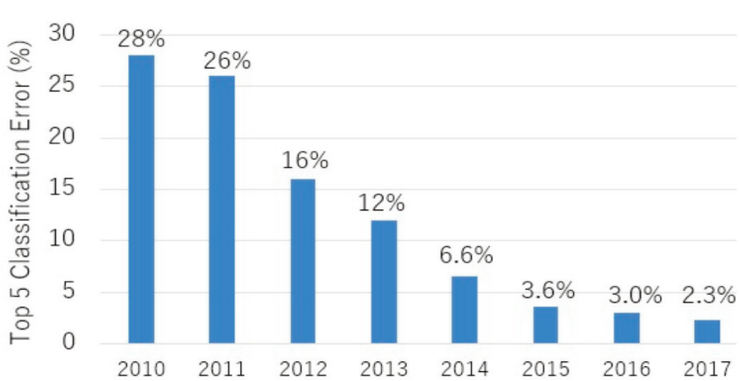

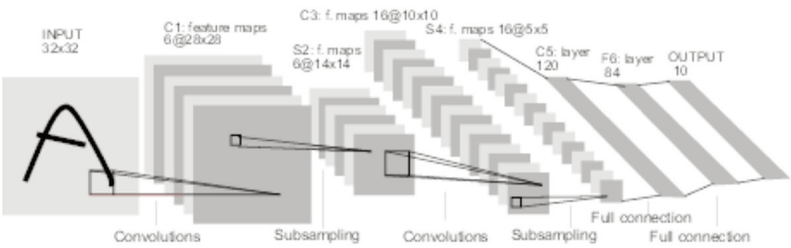

図3：畳み込みニューラルネットワークの構造. 図は[5]より引用

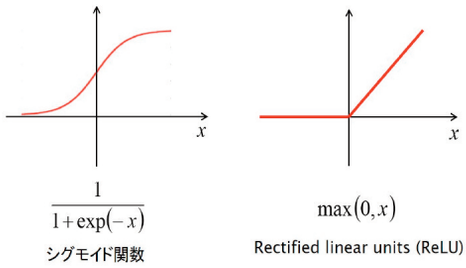

図4：活性化関数.

後、1990年代にLeCunらによって誤差逆伝搬法による学習法が提案され[5]、現在にまで至るCNNの基本技術が確立された。

CNNのパラメータは、訓練サンプルに基づき入力から出力に至るまで自動的に最適化されていくため、その内部構造は基本的にブラックボックスとなる。しかしながら、内部状態を可視化する研究も進んでおり、CNNが合理的に画像の特徴を抽出し、集約していることが明らかになってきている。Zeilerら[6]は、比較的入力に近い低層においては各ニューロンが単純な色やエッジ・円や縞などの基本的な形状パターンに反応しており、層を上っていくにつれ、人や動物の顔、車のタイヤのような意味的な内容に反応するニューロンが獲得されていることを示した。このような構造を獲得することはCNNの興味深い性質であり、実用的にも重要な役割を果たしている。

2.2 活性化関数

古典的な多層パーセプトロンにおいては、活性化関数として主にシグモイド関数が用いられてきた（図4左）。シグモイド関数は、導関数が自分自身を用いて解析的に表せるなどの便利な性質もあり広く使われてきたが、入力の絶対値が大きすぎる場合には関数値が平坦になってしまうため勾配がほとんど出なくなり、パラメータの更新が極めて遅くなるという問題があった。これは、多層になるほど顕著になる問題であるため、シグモイド関数を活性化関数に用いたままではネットワークの多層化は困難であった。

この点においてブレークスルーとなったのは、rectified linear units (ReLU)と呼ばれる活性化関数の良さが再発見されたことである[7]（図4右）。これは図中に示すように、入力xについて$\max(0, x)$をとる関数である。極めてシンプルな関数でありながら、正値の入力のみを通すことで閾値処理の効果を実現していると同時に、正値の入力に対しては常に一定の勾配を有していることからシグモイド関数のような勾配消失問題も発生しない。ReLUは現在の深層ネットワークにおいて広く用いられている活性化関数であり、必要不可欠な基礎技術の一つとなっている。

2.3 Dropout

ReLUの導入により深層ネットワークにおいても誤差逆伝播法自体は動作するようになったが、学習結果が訓練サンプルに過度に適応する過学習と呼ばれる状態に陥りやすく、実用上の有効な性能が得られないことが多い。Dropoutは過学習を抑える目的で提案され、CNNをはじめ多くの深層学習手法の性能を飛躍的に押し上げた技術である[8]。具体的には、各訓練サンプルをフィードフォワードし誤差逆伝播を実行する際に、一定確率でランダムに各ニューロンをないものと見なし、それに関連するパラメータの更新をスキップする。この確率を増減させることで正則化の強さを調整することも可能である。

Dropoutはシンプルながら極めて優れた効果をもたらし、大きな注目を浴び分析が進められた。著者らからは、微妙に異なる訓練サンプルで学習された多数のネットワークのアンサンブル学習であるという解釈により、正則化効果の説明がなされている。

2.4 さらに多層のネットワークへ

画像認識において最初のブレークスルーを起こしたCNNであるAlexNetは8層の構造であったが、その後の研究により、さらに層数を重ねて深い非線形を与えることが性能向上のために重要であることが分かってきた。現在画像認識では数十層から数百層のモデルを使うことが一般的になっている。なぜ深いモデルが良い性能を発揮するかは完全には解明されていないが、直感的には、浅いモデルはパラメータ数に対し線形にしか表現能力が向上しないのに対し、深いモデルでは指数的な向上が見込めることが示唆されている。例として、7×7の畳み込みを考えよう。単純に一層で7×7の畳み込みを行う場合、必要なパラメータ数は7×7 = 49 となる。これに対し、3×3の畳み込み層を三層積むと、同じ入力の領域をカバーしながら、パラメータ数は3×(3×3) = 27で済み、かつ三度活性化関数を経ることでより深い非線形性を与えることになる。

一方で、数百層にも及ぶ多層ネットワークを学習させることは容易ではなく、2015年以降はこれを可能とするための新しい技術が多数提案されている。ネットワークの初期値の与え方[9]や、低層の更新に起因する共変量シフトの影響を緩和するバッチ正規化法[10]や、非線形変換をスキップして低層の入力を高層へバイパスするネットワーク構造の設計法[11]などが特に重要な技術である。

3. 最新の研究動向

深層学習が関わる領域は幅広いが、近年では個々の分野の枠を超え、多くの分野を横断しながら驚異的な進歩を見せつつある。ここでは、いくつかの興味深い研究例を紹介する。

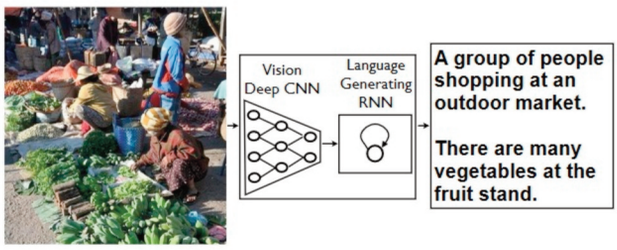

図5：画像説明文生成の例. 図は[12]より引用.

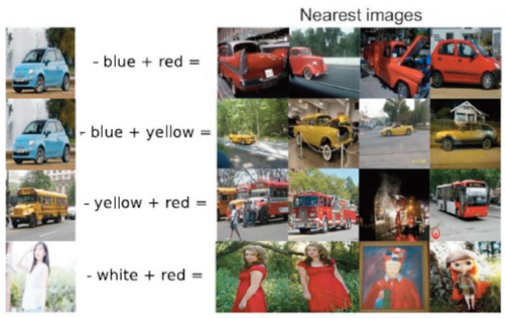

図6：画像とテキストの演算. 図は[15]より引用.

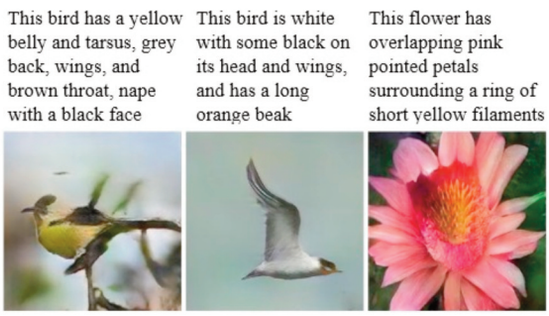

図7：Stack GANによる画像生成. 図は[19]より引用.

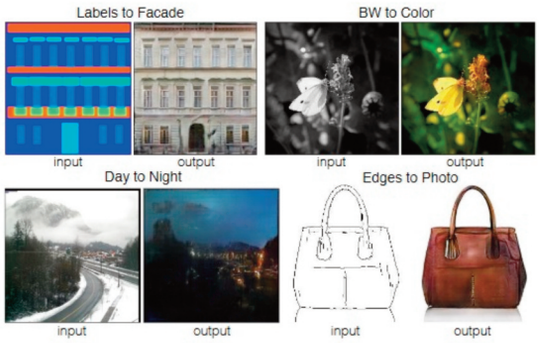

図8：画像スタイル変換の例. 図は[20]より引用.

3.1 画像認識と自然言語処理の融合

画像認識研究の最前線では、古典的な物体認識タスクに留まらず、画像の自然言語による説明文生成[12]（図5）や、画像内容についての質疑応答[13]など、さらに挑戦的なタスクも次々に取り組まれている。これらは、CNNをrecurrent neural network (RNN) [14]等の別のネットワークと組み合わせることで実現されており、本質的には画像とテキストを横断するマルチモーダル分散表現が内部に獲得されている。これを用いて、単純なベクトルの演算によって画像と言語の間の意味的な“計算”が実行できる[15]（図6）。例えば、青い車の画像からblueを引き、redを足した点の近傍の画像を見ると、赤い車の画像が集まっていることが分かる。他にも同様の例が示されており、このベクトル空間が意味的に妥当な構造を備えていることが示唆される。

3.2 強化学習との融合

Mnihら[16]は、深層学習と強化学習を融合させたDeep Q-Network (DQN) なる機械学習手法を開発し、Atariのクラシックゲームをプレイする AIを自動的に学習させることに成功した。ゲーム画面の画像のみを入力としており、ゲームルールはもちろんのこと、キャラクター（自機、敵など）の区別等、環境に関する知識は事前に一切教えていないにも関わらず、単純なゲームにおいては人間以上のプレイ能力を獲得している。

強化学習とは、行動計画・戦略の学習に古くから用いられている学習手法である。システムは、将来（行動終了後）までに渡って得られる報酬を最大とするように、各タイミング（状態）において自身がとる行動の価値関数を学習していく。一般に、入力が高次元になると次元の呪いにより価値関数の学習が困難になるが、DQNではこの部分を深層学習に置き換え、画像のような非常に高次元な入力に対しても高い汎化性能を実現している。同様のアプローチはさまざまなタスクへ急速に応用されており、特に囲碁AIであるAlphaGo [17]が人間の世界チャンピオンを圧倒し衝撃を与えたことは記憶に新しい。

3.3 パターン生成

ここまで見てきた手法は、いずれも極めて高次元であるパターン情報（画像)をいくつかのシンボル（またはシンボル列）に落とし込む情報圧縮のプロセスである。この点で、大枠としては古典的なパターン認識の延長にあるといえる。これに対し、最近ではパターン自体を生成する深層学習モデルが多く提案されはじめている。認識とは逆に、少ない情報から高次元情報を復元・推定しようとする本質的に不良設定なプロセスであり、極めて挑戦的な試みであると言える。

この分野では、generative adversarial network (GAN) [18]と呼ばれるアプローチが注目されている。これは、パターンを作る生成モデルと、生成モデルが作ったパターンと真のパターンを識別する（すなわち偽物と本物を見分ける）識別モデルを競合的に学習させることにより、結果的に優れた生成モデルを得る手法である。例えば、図7に示すように、かなりリアルな高解像画像を生成することが可能になっている[19]。また、画像の属性を自由自在に変換するものも登場している[20]（図8）.

4. おわりに

深層学習を中心とする機械学習手法の急激な発展により、画像認識は一昔前には考えられなかったレベルにまで到達している。さらに、単に与えられたパターン（画像）を認識する古典的な枠組みに留まらず、他分野の技術とシームレスに

結びつきながらより知的なタスクをこなせるようになっている。近年はAIの新たな可能性を感じさせる成果が次々に生み出されており、さながらカンブリア爆発のような様相を呈していると言える。さらなる高度な知能の実現に向けてどのような進化が起こるのか、今後数年間の展開は目が離せないであろう。

参考文献

[1] J. Deng et al., “ImageNet : a large-scale hierarchical image database,” In Proc. of IEEE CVPR, 2009.
[2] A. Krizhevsky et al., “ImageNet classification with deep convolutional neural networks,” In Proc. of NIPS, 2012.
[3] D. H. Hubel and T. N. Wiesel, “Receptive fields of single neurons in the cat's striate cortex,” The Journal of Physiology, 148:574-591, 1959.
[4] K. Fukushima, “Neocognitron : a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” Biological Cybernetics, 36(4):93-202, 1980.
[5] Y. LeCun et al., “Gradient-based learning applied to document recognition,” Proc. of the IEEE, pages 2278-2324, 1998.
[6] M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks,” In Proc. of ECCV, 2014.
[7] V. Nair and G. E. Hinton, “Rectified linear units improve restricted Boltzmann machines,” In Proc. of ICML, 2010.
[8] N. Srivastava et al., “Dropout : a simple way to prevent neural networks from overfitting,” Journal of Machine Learning Research, 15:1929-1958, 2014.
[9] K. He et al., “Delving deep into rectifiers : surpassing human-level performance on ImageNet classification,” In Proc. of IEEE ICCV, 2015.
[10] S. Ioffe and C. Szegedy, “Batch normalization : accelerating deep network training by reducing internal covariate shift,” In Proc. of ICML, 2015.
[11] K. He et al, “Deep residual learning for image recognition,” In Proc. of IEEE CVPR, 2016.
[12] O. Vinyals et al., “Show and tell : a neural image caption generator,” In Proc. of IEEE CVPR, 2015.
[13] M. Ren et al., “Exploring models and data for image question answering,” In Proc. of NIPS, 2015.
[14] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” Neural Computation, 9(8):1-32, 1997.
[15] R. Kiros et al., “Unifying visual-semantic embeddings with multimodal neural language models,” Transactions of the Association for Computational Linguistics (TACL), 2015.
[16] V. Mnih et al., “Human-level control through deep reinforcement learning,” Nature, 518:529-533, 2015.
[17] D. Silver et al., “Mastering the game of Go with deep neural networks and tree search," Nature, 529:484-489, 2016.
[18] J. Goodfellow et al., “Generative adversarial nets,” In Proc. of NIPS, 2014.
[19] H. Zhang et al., “StackGAN: text to photo-realistic image synthesis with stacked generative adversarial networks,” arXiv:1612.03242, 2016.
[20] P. Isola et al., “Image-to-image translation with conditional adversarial networks,” In Proc. of IEEE CVPR 2017.

深層学習の実世界応用へのアプローチ

尾形哲也
早稲田大学基幹理工学部表現工学科
産業技術総合研究所人工知能研究センター

ロボティクス　Robotics
深層学習　Deep Learning

近年、深層学習が、画像認識、音声認識、自然言語処理などの各分野で、従来手法を大きく上回る能力を示し、多くの企業の注目を集めている。これまで、その適用範囲は大規模なデータが収集可能な電子化されたデータ処理に特化されてきたが、近年、この手法の実世界システム、具体的にはロボットや自動運転への応用研究も急激に盛んになりつつある。

本稿では、これらの背景の元に、これまで筆者らが行ってきた、深層学習のロボット技術への応用研究、特に認識、動作、言語、そして認知ロボティクスに関する学習モデルについて、その概略を簡単に紹介する。また今後の展望、課題などについて述べる。

1. 認識タスク

深層学習が最もその成果を発揮する課題として、画像、音声などの認識タスクが挙げられる。我々は特にマルチモーダルの統合認識という視点から、Honda Research Instituteとともに深層学習によるリップリーディングの萌芽研究を行った[1]。ここでは、音声の雑音除去、唇画像からの音素推定を両方とも深層学習のみで行なっている（図１）。

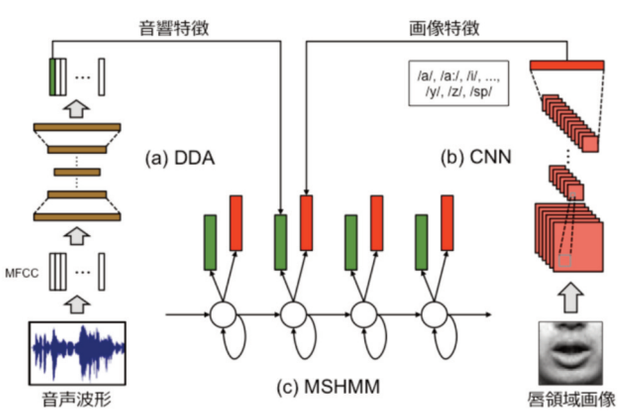

図１　DLマルチモーダル統合による音声認識

雑音入りのMFCC特徴量から雑音を除去したMFCCを出力するAuto-Encoderと、唇領域の生映像から40種類の音素を出力するCNN (Convolutional Neural Net) で構成される

Google DeepMindは、本研究を発展させた形で5000時間の映像データをEnd-to-End学習（深層学習のみで、入力データから出力を直接得る枠組み）させた"LipNet"[2]を開発し、人間の能力とほぼ同等かそれ以上のリップリーディングの能力を示している。このようにクラウド上でのデータ処理では、その目的に対応して非常に早く高い性能を得るシステムが、Google, Microsoftなどによって開発されるのが現状である。

2. 動作生成タスク

このようなクラウド上の電子化されたデータのみではなく、実世界で動作するシステムへの導入として、ロボットへの応用研究を行っている。そもそもロボット研究は機械工学（物理解析）を基盤とし、人工知能研究は情報工学（確率統計）を基盤としているものの、深層学習はこの両者の領域において有効となりうる手法である。

我々が先駆的に取り組んできた、深層学習のみによるロボットによるマルチモーダル学習、また物体操作の学習を行った。特にロボット動作生成では、これまでモデル化及び画像処理に大きなプログラミングコスト、計算コストが必要となっていた柔軟物の折りたたみ動作学習を実現している[3]。深層学習により、カメラ取得イメージから直接、関節角度情報をEnd-to-End学習を行うフレームワークにより、ロボットは次状態イメージ画像を予測しながら、柔軟物だけでなく、複数の未学習物体の操作が可能となることを示した（図２）。

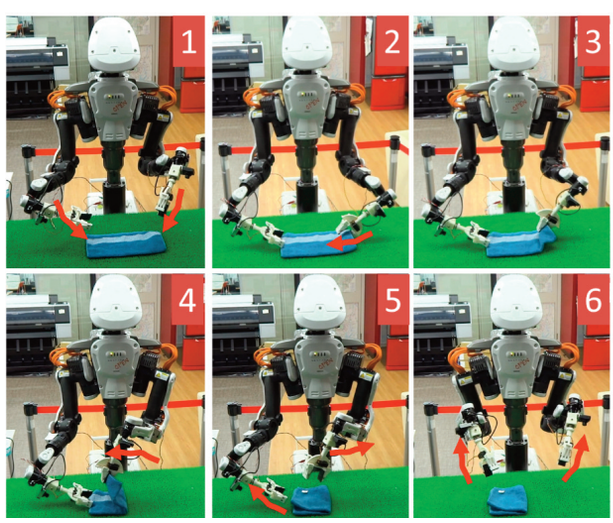

図２　Nextageによる柔軟物の折り畳み学習

複数のタオルを乱雑な位置と姿勢で数十回学習させることで、未学習のタオルや本を短時間で繰り返したためるようになる

3. 言語タスク

深層学習、特に再帰型神経回路モデル（Recurrent Neural

Network: RNN）を用いた自然言語処理を、ロボットの言語理解へ応用する基礎実験行なっている[4, 5]。

実環境において利用される言語は、その状況によって大きく意味が変化する多義性を含み、全ての解釈の可能性を事前に予測することは不可能である。そこでRNNのSequence to Sequence学習と呼ばれる手法をマルチモーダルに拡張し、否定やAND, ORなどの論理語を含む、未学習の多義的な文章の指示に対して対応できるようにした。具体的には、RNNに、現状の視野画像、ロボットの動作状態と対応する単語列を学習させる。この結果、現時点での"意味"を多様な状態空間に内在させ、ロボットの動作として対応が可能になることを示した。特に"OR"の処理については、感覚入力に付随するノイズが、神経回路モデルの複雑なダイナミクスとして表現され、利用されていることなども確認した。

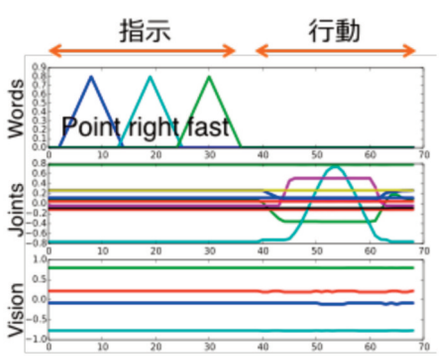

図３ NIPS2016におけるデモ

ベル叩きの指示の多義性（指定色のベルの場所と有無、動作の否定など）を解釈できる。下はRNNの入出力。言語、運動、画像を同時に処理する。

4. 認知発達ロボティクス研究

これまでに示した、深層学習の実ロボットシステムへの導入は、今後、大きく発展すると考えられる。この時に重要なコンセプトは、知能を単なるデータ学習として捉えるのではなく、身体と環境との能動的なインタラクションプロセスと考える視点であろう。これはまさに認知発達ロボティクスとして、長年提案されているものである。

例えば、我々が取り組んできた模倣学習の実験モデルでは、ロボット自身の動作を学習した神経回路モデルが、少数のニューロンの追加学習のみで、教示者である他者の位置と動作の種類を認識可能となることを示している。この学習プロセスは、深層学習で提案される「転移学習」の一種であると捉えることができる。今後、認知発達ロボティクスで扱われて来た、人間の認知に関する基礎モデルが、深層学習により、より実用的なシステムに発展していくと期待される。

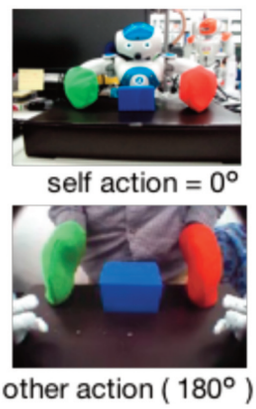

図４ 深層学習による自己視点と他者視点の変換

位置と動作の変換のためのニューロンを５つ追加することで、自己の動作経験から他者の動作の認識と予測を行う。

５. 終わりに

本稿では、深層学習モデルの実世界の応用の方向性を示した。深層学習の大きな問題点として、その機構がブラックボックスとなっており、安易な利用は避けるべきとの指摘もある。しかしその大きな可能性を考えるならば、その利用を避けるのではなく、積極的に応用することで、理論やノウハウなど様々なレベルでの理解を行う活動が極めて重要であろう[8]。今後、より多くの実世界システム応用例が現れることを期待したい。

参考文献

[1] K. Noda, Y. Yamaguchi, K. Nakadai, H. G. Okuno, and T. Ogata: Audio-Visual Speech Recognition using Deep Learning, Applied Intelligence, Springer, Vol. 42, Issue. 4, pp. 722-737, April 2015.

[2] Y. M. Assael, B. Shillingford, S. Whiteson, N. de Freitas, LipNet: End-to-End Sentence-level Lipreading, arXiv:1611.01599, December 2016.

[3] P. Yang, K. Sasaki, K. Suzuki, K. Kase, S. Sugano, and T. Ogata: Repeatable Folding Task by Humanoid Robot Worker using Deep Learning, IEEE Robotics and Automation Letters (RA-L), Vol.2, No.2, pp. 397-403, Nov. 2016.

[4] T. Yamada, S. Murata, H. Arie, and T. Ogata: Dynamical Integration of Language and Behavior in a Recurrent Neural Network for Human–Robot Interaction, Frontiers in Neurorobotics, 15 July 2016.

[5] T. Yamada, S. Murata, H. Arie, and T. Ogata, “Dynamical Linking of Positive and Negative Sentences to Goal-oriented Robot Behavior by Hierarchical RNN,” In Artificial Neural Networks and Machine Learning – ICANN 2016, Lecture Notes in Computer Science (LNCS), 2016.

[6] 浅田稔、國吉康夫：ロボットインテリジェンス、岩波書店,

2006.
[7] R. Nakajo, S. Murata, H. Arie, and T. Ogata, “Acquisition of Viewpoint Representation in Imitative Learning from Own Sensory-Motor Experiences,” IEEE International Conference on Development and Learning and on Epigenetic Robotics (ICDL-EpiRob 2015), pp.326-331, Aug. 2015.
[8] http://www.jdla.org/（2017年11月）

深層学習

和田義孝
近畿大学 理工学部 機械工学科

1．はじめに

画像認識におけるコンペティションであるILSVRCにおける深層学習[1]の有効性示されその可能性に多くの人々が期待する状況になって久しい。しかし、計算力学やCAEといった分野こそ、深層学習との親和性が高いと期待するもののその応用方法・利用方法については先行研究事例すら少ない状況である。本稿ではまず深層学習の歴史的背景および現状を紹介する。そして、コンピューティングパワーにより学習用データを大量生成できる状況において、何をどのように学習するのが最も効果的かつ効率的なのかをき裂進展挙動の学習結果を通して論じる。

2．深層学習の歴史

深層学習は多層ニューラルネットワークで実現される。しかし、多層ニューラルネットワークは期待されたものの思うような結果が得られず失望された歴史[2]がある。ニューラルネットワークは1940年代に研究が始まりブームが2度ほどあった。計算力学分野においても80年代半ばから90年代前半にかけてニューラルネットワークのブームは記憶にある方もいると思われる。このときに注目された手法が誤差逆伝播法（バックプロパゲーション法）である。失望の原因は、過学習による汎化性能の低下および学習に関するパラメータの決定方法が発見的なため工学的な指針が得られなかったことである。一方で、画像認識においては畳み込みニューラルネットワークが80年代前半から90年代後半にかけて研究され完成された[3]。2000年代前半から事前学習を行うことで過学習を回避する方法が提案された。また、自己符号化によっても事前学習を行えることも示された[4]。この自己符号化の学習は教師なしで行われることも重要な点である。

3．深層学習の現状

画像認識に代表される文字認識、人認識、顔認識等のピクセル単位で学習する深層学習（＝大規模入力、多階層のニューラルネットワーク）の成功例[1]から大規模な研究開発およびIT企業および自動車企業による投資が始まった。これらの動きに呼応する形で、例えばNVIDIAによるGPGPU開発の深層学習向けの開発[5]、各研究機関および大学による深層学習向けのAPIの開発など加速した。これらの動向に対してCAEに対するAIおよび深層学習への適用の期待も高まっている[6,7]。しかし、画像解析による応用はその事例は多数見受けられるが、一方で物理現象、工学設計における応用方法が全く示されていない現状がある。USNCCM2017（米国計算力学学会）においてE. Haberにより深層学習の新しい学習方法の提案がSemi-plenary lecture[8]があった。この講演における要旨は、計算力学の手法をディープニューラルネットワークの学習に適用することにより効果的な学習が達成できるという点である。計算科学研究者の提案よりすぐれた学習手法に関わる画期的な発表があった。複雑な問題、多入力・他出力のディープニューラルネットワークの学習方法の進歩に大きく貢献することが現在進行している。一方で、トヨタ自動車は、自動運転実現のためにはあと142億㎞の走行距離が必要だという試算を示している[9]。この数値は、技術のある運転手が10,000人・台が一人1万㌔メートル以上の走行距離が必要だと示唆している。学習は人間の経験と相対するところがある。例えば、事故、回避などのアクシデント事例は特に学習が必要であるが、そういったケースは全体のデータに対する学習ケース（時間）は少ない。詳細は後述（4章）するが、荷重方向に対して角度を有するき裂は進展の直後少ない時間で進展方向を変える。つまり、学習するためのデータ数が少なくなる。このことは、多くの工学応用に関して常に問題となる。また、多くの工学問題ではどこの場所のどのような物理量を学習させればよいのかの知見が全くないことが大きな課題であると指摘できる。

3．深層学習とは

現在、深層学習という言葉には次のような意味が込められていると考える。

> バックプロパゲーション(BP)法の改良および過学習の防止手法も含めた多入力多階層のニューラルネットワーク(NN)の学習手法およびそれらの学習で得たNNの重み係数

つまり、深層学習とはアルゴリズムを指し示すだけのテクニカルタームではない。このタームは自動運転や人工知能を実現するための重要な役割があることが同時に期待されていると昨今の報道[10]から理解できる。

ニューラルネットワークは、図1に示すノードとそれらを結ぶ結線によりモデル化される。すべての結線はノードから出力された値を変更する重みW_{ijk}とバイアスb_{ijk}が与えられる。各ノードは式１に表されるシグモイド関数（他の関数形式も存在する）により演算されることが一般的である。この関数の特徴は、図2に示すように、入力値が大きくなると１に漸近し、入力値が小さくなると0へ漸近する。0近傍の場合は傾きが1/4である1/2を出力する。

最も基本的な関数$f(x)$のフィッティングを行うには1入力1

出力のニューラルネットワークの学習を行えばよい。一般的には入力、出力ともにベクトルないしマトリックスになる。画像の学習（文字認識、人や車の認識）は1ピクセル＝1入力となるためマトリックスがその入力になる。

ニューラルネットワークでは、大規模な重みW_{ijk}とバイアスb_{ijk}の逐次更新により学習を進める。学習が進んだニューラルネットワークはエンジニアが望んだ能力を獲得している状態を学習により達成する。具体的には、図3に示すような流れで学習を行う。これらの方法は、SOR法などのような初歩的な反復法ソルバーと同じ程度のプログラミングが要求されているためニューラルネットワーク実現のための基本的な骨子の理解は極めて容易である。現在では、事前学習により初期の重みおよびバイアスを決定したあとに図3の手順で学習を行うことが一般的である。

本章の冒頭においても述べたように通常の誤差逆伝播学習では大規模なニューラルネットワークは学習ができなかった。それらの学習を可能にしたのがいくつかの学習方法の改善である。例えば、10層以上の学習を確実に進めるためには、出力と入力に同じ値を用いて1層ずつ学習を進める方法がよくとられている。また、最新の研究結果では2階層のマルチグリッドであるコースグリッドコレクションを利用した学習方法も提案[8]されており、学習結果もより誤差が小さくなることも示されている。図4(a)に示すように、学習をより強固にするためにノードを停止（値の出力を行わない）させて学習をさせる。また、図4(b)では入力データに意図的に誤差を与えて学習をさせる方法も取られる。この方法の利点はデータセット数が簡単に数倍に増やせる点である。これらの学習を強化する方法を組み合わせて深層学習が実装され様々な成果を生み出している。

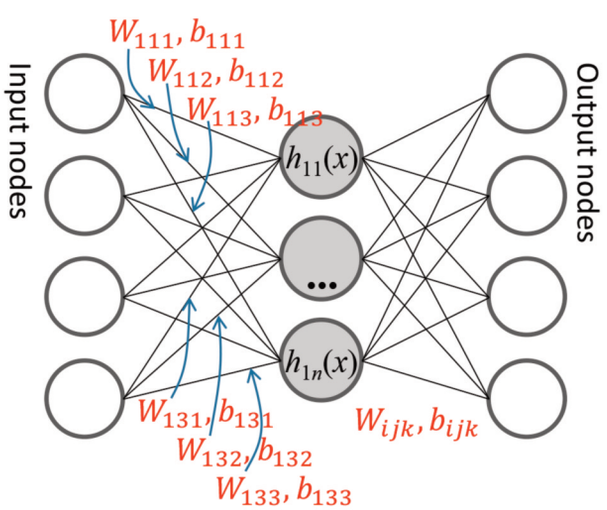

図1 ニューラルネットワークの構成

$$h_{mn}(x) = \frac{1}{1 + e^{-\sum_{i=1}^{k}(W_{mni}x + b_{mni})}} \qquad (1)$$

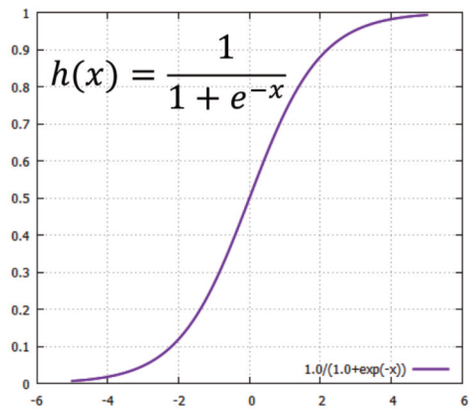

図2　シグモイド関数

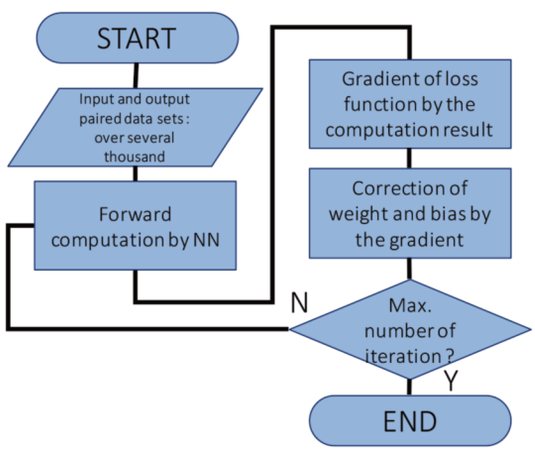

図3　ニューラルネットワークの学習

４. 深層学習の適用事例

筆者らは、疲労き裂進展を具体事例として深層学習技術を適用しき裂進展挙動が予測できるかどうかを検証した。3つのフェーズを想定し、フェーズ１は応力拡大係数から進展方向ベクトルおよび進展速度を学習、フェーズ2はき裂近傍応力、変位から進展方向ベクトルおよび進展速度を学習、フェーズ3は初期き裂中心位置を原点としき裂先端位置およびき裂が向いている方向ベクトルから進展方向ベクトルおよび進展速度を学習、という３つの場合に分けた。実用上はき裂先端の位置および進展方向のベクトルから学習できることが望ましい。その理由は、き裂を画像的に扱うことにより直接その余寿命やき裂形状の予測が可能になるためである。

疲労き裂進展解析は、弾性計算（ポアソン方程式）、応力拡大係数、等価応力拡大係数、き裂進展速度、き裂進展方向を微小ステップで解析を行いその履歴（積分）として最終的なき裂進展形状が計算される。図5に等価応力拡大係数、き裂進展速度およびき裂進展方向を決定する経験則による式を示す。深層学習によりこれら式を陰的に再構成されるかどうかが工学分野における応用のための提示すべき具体例である。

学習データは重合メッシュ法(以下S-FEM)によるき裂進展解析[13]を用い約５０００におよぶデータを生成した。データをもとに、ノイズ混入、ノード停止などのテクニックを用いて総学習数20万回を行った。実用的な観点からは20万回

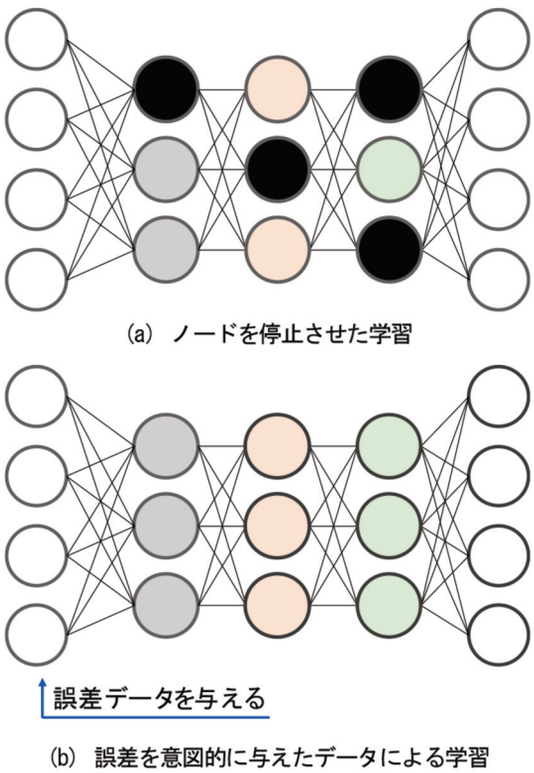

図4　深層学習のための学習方法

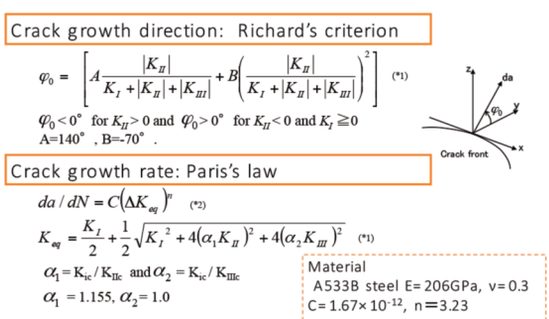

図5　き裂進展則にかかわる多くの法則とパラメータ[11,12]

の学習数は極めて少ない。図6および図7にき裂進展速度の学習結果を示す。またその具体的な予測された数値を表１に示す。S-FEMによるき裂進展解析と同様にシミュレーションによるき裂進展速度の予測は1サイクル当たりの進展量ではない。理由は、1サイクル当たりの進展量は10^{-12}のオーダーのためそのサイズではメッシュ生成ができない。したがって、最小メッシュサイズあたりに何サイクル必要か計算することで、き裂進展数値シミュレーションを連続的に行う。図6および表１から、き裂進展開始直後では大きな差異が左右のき裂先端部位でみられる。しかし、き裂進展が進むにつれS-FEMの結果と一致する。荷重方向に対して斜めに存在するき裂が繰返し荷重を受けると急激にその向きを変え、その後はほぼ水平に進展する。つまり、き裂の向きを変える学習が少ない。進展方向を変える学習データ数は全体の学習データ数のわずか4％程度にしか過ぎない。

本適用例は、CAEアプリケーション自体をデータ生成のための手法として利用することの提案である。近年の配列計算機環境およびクラウドによる並列計算サービスの利用を考えればパラメトリックにバッチ処理を実行する技術的困難さはほとんどないといえる。このような、状況を踏まえてCAEアプリケーションにデータを生成されば、意図的に境界領域（考えている解空間の端）およびデータ数の取得が相対的に少なくなる箇所（本適用例ではき裂進展直後）を適切に理解しデータの密度を適正化（必要なデータの密度の均質化）が可能となる。

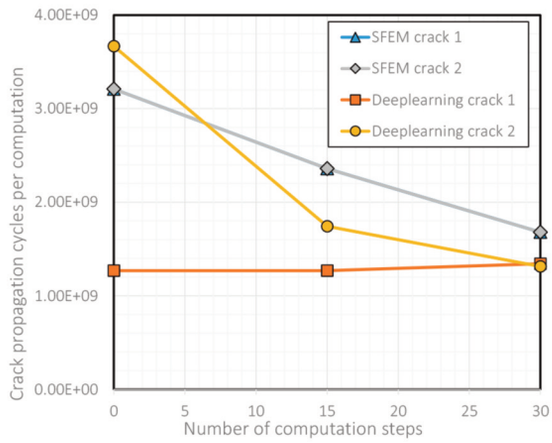

図6　き裂進展速度の予測結果と進展ステップ数

表1　き裂進展ベクトルと速度の予測結果（第1ステップ）

	き裂位置	き裂進展ベクトルdP		サイクル数N
		dPx	dPy	
S-FEM	crack 1	0.974	-0.225	3.21×10^{9}
	crack 2	-0.974	0.224	3.21×10^{9}
Deep Learning	crack 1	0.967	-0.050	$2.65\times10^{8.68}$
	crack 2	-0.955	0.084	$3.84\times10^{8.98}$

図7　機械学習によるき裂進展予測と重合メッシュ法によるき裂進展（正解）：黒・初期き裂、赤・重合メッシュ法、青・ニューラルネットワークによる予測

5.おわりに

深層学習およびそれらを実用化するための補助的技術の集積により実用化が今後ますます進むことが予想される。また、学習方法も様々な分野の知見を適用することにより今後もより効果的・効率的な手法が開発されることが期待される。また、近い将来より多くの計算力学およびCAE関連への適用により、エンジニアが望む意味のある結果をより短い時間で得られるようになることも合わせて予想される。

参考文献

[1] A. Krizhevsky, et al., ImageNet Classification with Deep Convolutional, Advances in Neural Information Processing Systems 25 (NIPS 2012), 2012
[2] 岡谷, 深層学習, 機械学習プロフェッショナルシリーズ, 講談社, 2014
[3] Y. LeCun, et al., Gradient-based learning applied to document recognition, Proc. Of the IEEE, 86(11), pp.2278-2324, 1998
[4] Y. Bengio, et al., Greedy layer-wise training of deep networks, In Proc. NIPS, 2006
[5] 井﨑, NVIDIAのディープラーニング戦略と 最新情報, GPU Technology Conference, Tokyo, 2016
[6] 和田, CAEにおけるディープラーニング活用のための一考察（ディープラーニングによるき裂進展挙動予測）, 第48回関西CAE懇話会, 京都, 2016
[7] 和田, CAEにおけるディープラーニング活用 ～重合メッシュ法によるき裂進展挙動学習～, ADVENTURECluster ユーザー会2017, Tokyo, 2017
[8] E. Haber, Deep Learning Meets Differential Equations and Optimal Control, 14th U.S. National Congress on Computational Mechanics, Semi-plenary lecture, Montreal, 2017
[9] トヨタ社長「142億キロの試験走行」で自動運転実現を宣言, https://forbesjapan.com/articles/detail/13813 , 2016
[10] 例えばhttp://monoist.atmarkit.co.jp/mn/subtop/features/
automated_vehicle/ などの特定情報をクリップする記事
[11] H. A. Richard, M. Fulland, M. Sander S. N., Fatigue Fract. Eng. Mater Struct., Vol. 28, pp. 3-12, 2005
[12] P. C. Paris and F. Erdogan, J. bas. Eng. Mater. Trans. ASME, Ser. D, 85, pp. 528-533, 1963
[13] 菊池、和田ら, 重合メッシュ法を用いた疲労き裂進展シミュレーション(第2報二つの段違いき裂の相互作用の検討）, 機論A, 74巻,745, 2008

部門からのお知らせ

30回計算力学講演会（CMD2017）の開催報告

実行委員長　和田義孝
近畿大学 理工学部 機械工学科

2017年9月16日（金）から18日（月）の3日間、近畿大学東大阪キャンパスにおいて第30回計算力学講演会が開催されました。平成27年の秋、当時の部門長である岡田裕先生（東京理科大学）より、次の計算力学講演会を大阪で開催してもらえないかとの相談を受け学内の検討を経て実施可能と判断しました。その後、実施の1年前を目処に学内の会場を押さえ、企業、大学の方々を中心に実行委員会を組織しました。2016年10月に第1回実行委員会を開催しました。会場として大学を利用する場合には、講義開始後には連休を利用する日程しか対応できず、さらに学内のイベント（学園祭や入試）日程と重複しない事を念頭に検討した結果、9月16日から18日の3日間の日程で講演会を企画いたしました。東大阪を中心としたものづくりの街は新大阪や伊丹空港から１時間程度です。また、ミナミとよばれる難波を中心とした繁華街があり安くておいしいものが食べられる街としても有名です。過去の計算力学講演会の実施を見ても成功して当たり前となっている状況で開催に向けて周到に準備を進めました。開催時期が近づくにつれて、台風直撃の可能性大との予報が出されておりましたが、最寄り駅であります近鉄奈良線および大阪線は台風による不通になりにくいと経験上判断しておりましたが不安ではございました。初日の土曜日は雨が大変激しく降りましたがバス路線2系統が運行しており無事に終えることができました。また、17日は夜に台風直撃との予報が出たため、部門表彰委員の協力を得て午後の開始を10分早めて懇親会を15分早く開始、中締めを19時過ぎに行うというスケジュールに組み直しました。暴風警報が発令されましたが雨は少ない上に、電車の運行にもほとんど影響がない状況で無事に懇親会まで終えることができました。結果として、発表件数330件、参加登録者数557名という大変盛況な講演会となりました。ここに改めて御礼申し上げます。

第1日（9月16日13：00～14：00）には、村田修近畿大学名誉教授（近畿大学水産研究所顧問）より「クロマグロ完全養殖への挑戦」と題する特別講演が行われました。クロマグロの人工ふ化種苗生産と完全養殖への苦難な道のりについて紹介をいただきました（写真１、２）。参加する多くの方々が興味を持つような話題性のある内容であったため、大きな会場がほとんど満員になるほどに大盛況でした。また、第2日（9月17日13：00～14：00）には、京極秀樹教授・日本機械学会フェロー（近畿大学工学部ロボティックス学科・次世代基盤技術研究所3D造形技術研究センター長）より「次世代ものづくりに求められる金属3Dプリンティング技術」と題する講演が行われ、金属3Dプリンティング技術の現状について紹介されるとともに、溶融凝固現象や熱変形現象、さらには設計におけるシミュレーション技術の現状と課題などについて解説がありました。米国、ヨーロッパそれぞれが急速に３Dプリンティングの実用化へ向けて研究開発を行っており主導をとるための競争が激化していることが紹介されました（写真３，４）。特別講演の他にも、フォーラムとして、「ディープラーニングと拡張ＣＡＥ～ＡＩとＣＡＥの融合に向けて～」、「企業における革新的設計のためのCAE活用」、「構造解析系オープンCAEの活用」と題する3件が企画されました。さらに、チュートリアルとして、「クラウドを活用したオープンCAE実習コース」が開催され、アマゾン ウェブ サービス ジャパンのサービスを利用したCAE実習が行われました。一般講演は、25件のオーガナイズドセッションと1件の一般セッションが9つの講義室でパラレルセッションとして行われたほか、ポスターセッションでは16件の発表が行われました。

第1日の特別講演後には、特別座談会「計算力学の過去、現在、未来 ～30年前にどのような未来を描いていたか～」を開催いたしました（写真５、６、７、８）。矢川元基先生、白鳥正樹先生、福田収一先生、加藤毅彦様に登壇いただきました。多くの示唆を含んだ今後すべきことについて語っていただきました。また、複数の学生からは大変興味深かったという感想がありました。

第2日の特別講演後には、部門表彰式が開催されました。今年度（95期、2017年度）は、大島伸行教授（北海道大学）が貢献賞を、今井陽介准教授（東北大学）、高橋昭如准教授（東京理科大学）、千葉一永准教授（電気通信大学）が業績賞を受賞されました。本講演会における、優秀講演賞、優秀技術講演賞、若手優秀講演フェロー賞については、現在、審査が進んでおり、春先に発表される予定です。

第2日の夜には、懇親会が学内の11月ホール1階ロビーにて開かれました（写真９）。大勢の参加者にお集まり頂き、大いに盛り上がる会となりました。懇親会では、参加者の皆様に楽しんで頂けるようにと、近畿大学で一番有名で食したいものとして養殖クロマグロを準備いたしました。1年以上前の2016年9月7日はクロマグロを発注いたしました。ただし、その大きさは釣り上げるまで不明した。今回はエラと内臓を除去した状態で51 kgの養殖クロマグロを準備できました。クロマグロを一匹単位で入手しても、それらを捌く必要があるため職人を雇う必要があります。そこで、余興を兼ねて裁き職人の方に来ていただきました。エンターテイメント要素を入れた形でクロマグロをご提供できたのではないかと

思っております。さらに、近畿圏は造り酒屋が大変多く地産地消の日本酒も数多くございます。13種の日本酒を準備いたしました。昨年度の第29回計算力学講演会幹事の奥山大先生からのご助言で量は多めに準備させていただきました。

本講演会では、関係する企業等の皆様からご協力を頂き、5件の機器展示（株式会社インサイト、株式会社HPCテック、日本ニューメリカルアルゴリズムズグループ株式会社、ビジュアルテクノロジー株式会社、プログレス・テクノロジーズ株式会社、）と3件のカタログ展示（サイバネットシステム株式会社、国立大学法人名古屋大学 情報基盤センター、特定非営利活動法人CAE懇話会）、１件の書籍展示（ワイリー・ジャパン）を企画させて頂きました。受付を取り囲むようにブースを設置し参加者が行き交う場所で展示され、参加者が熱心に情報収集する様子がいたるところで見つけられました。1件のプログラム広告（プロメテック・ソフトウェア株式会社）にもご協力を頂きました。特定非営利活動法人CAE懇話会には協賛学会としてご協力頂きました。この場をお借りして、厚く御礼申し上げます。簡単ながら第30回計算力学講演会の開催後報告をさせていただきました。講演会実行委員、学会事務局、部門関係の方々、機器展示等に出展頂いた皆様、多数の参加者の皆様のご協力により、盛況のうちに講演会を終えることができました。ここに厚く御礼申し上げます。

写真１　初日の特別講演

写真４　京極秀樹近畿大学教授の特別講演

写真２　村田修近畿大学名誉教授の特別講演

写真５　特別座談会　矢川元基先生（東京大学・ 東洋大学名誉教授 東洋大学名誉教授）

写真３　二日目の特別講演

写真６　特別座談会　加藤毅彦様（エムスシーソフトウア株式会社代 表取締役社長 ）

写真７　福田収一先生（元スタンフォード大学コサルティグプロフェッサー,首都大学東京 /東京都立科学技術大名誉教授）

写真９　懇親会の様子（中央左に横たわるマグロ）

写真８　特別座談会の様子（ほぼ満員となりました）

2017年度年次大会の部門企画開催報告

中林　靖
東洋大学 総合情報学部

日本機会学会2017年度年次大会が、2017年9月3日（日）から9月6日（水）までの日程で、埼玉大学（〒338-8570埼玉県さいたま市桜区下大久保255）で開催された。

首都圏での開催ということもあり、例年にも増して多くの参加者が集まり、有料参加者数1,896名（一般：1,202名、学生694名）となった。また、全体講演件数は1,072件であり、またその他、特別企画として特別講演2件、市民公開行事12件、基調講演24件、先端技術フォーラム17件、ワークショップ16件、パネルディスカッション1件、その他の企画4件と、非常に内容の濃い年次大会となった。以下の写真1は大会委員長の水野毅先生（埼玉大学）の懇親会での挨拶であり、写真2は実行委員長の綿貫啓一先生（埼玉大学）の懇親会での挨拶である。

写真１：大会委員長・水野毅先生（埼玉大学）挨拶

写真2：実行委員長・綿貫啓一先生（埼玉大学）挨拶

年次大会では各部門から多くの特別企画やオーガナイズドセッションが企画されるが、計算力学部門からは特別企画として、先端技術フォーラム「Industry4.0, IoT時代の日本のものづくりとＣＡＥ」及び市民フォーラム「オープンCAEの普及活動」の2件が企画され、またオーガナイズドセッションとして、「安全安心な水素社会を創る流体解析と計測技術」、「診療技術と臨床バイオメカニクス」、「計算力学とバイオエンジニアリング」、「電子情報機器、電子デバイスの強度・信頼性評価と熱制御」、「工業材料の変形特性・強度およびそのモデル化」、「分散型エネルギーとシステムの最適化」、「解析・設計の高度化・最適化」、「交通機関の安全安心シミュレーション」、「医工学テクノロジーによる医療福祉機器開発」の9件が企画された。（他部門との合同企画を含む。）これら9件のオーガナイズドセッションの講演数が合計95件で、これに加えて計算力学部門一般セッションで4件の講演があった。計算力学部門講演会が僅か2週間後に近畿大学で開催されるという計算力学部門にとっては微妙なタイミングではあったが、非常に多くの講演及び聴講者があり活発な議論が行われていた。以下の写真3は年次大会初日の9月3日に開催された市民フォーラム「オープンCAEの普及活動」の様子を写したものである。

写真3： 市民フォーラム「オープンCAEの普及活動」

全体の懇親会は9月5日(火) 19:00～21:00に浦和ロイヤルパインズホテル（さいたま市浦和区仲町2丁目5-1）で開催されたが、例年、年次大会で恒例の行事となっている部門同好会は9月4日（月）18:00～20:00に埼玉大学内で開催された。例年同様に計算力学、流体工学、熱工学の3部門合同で実施された。また、一部の部門の同好会の開催場所及び見学会の企画として、「ナイトミュージアム in 鉄道博物館」（鉄道博物館の夜間見学会）が企画され、非常に人気となっていた。この企画は9月4日（月）18:30-20:30に鉄道博物館（さいたま市大宮区大成町３丁目47番）の車両ステーショ

ン（車両・歴史展示ゾーン）を夜間貸し切りとし、自由に見学出来る他、ジオラマ室・運転シミュレータの利用なども出来たため非常に賑わい、埼玉大学から会場への直通バスに長蛇の列が出来ていた。以下の写真4は「ナイトミュージアム in 鉄道博物館」の様子を写したものである。

写真4：「ナイトミュージアム in 鉄道博物館」

次回の2018年度年次大会は、2018年9月9日（日）から12日（水）までの日程で、関西大学千里山キャンパス（大阪府吹田市山手町3-3-35）で開催される。

KSME-JSME Joint Symposium 開催報告

岡田　裕
東京理科大学 理工学部 機械工学科

5月26日（金）に、韓国・釜山のBEXCO (Busan Exhibition & Convention Center) において、KSME-JSME Joint Symposium on Computational Mechanics & CAE（以下、日韓シンポジウムと記す）が開催された。これは、韓国機械学会Division of CAE and Applied Mechanics と日本機械学会計算力学部門とで企画され、韓国の計算力学研究者らとの研究交流を目的とするものである。2010年、2012年、2014年、2015年にソウル、金沢、チェジュそして東京の順番で、2010年からほぼ2年おきに開催されてきた。今回（2017年）は韓国・釜山で開催された。

今回の日韓シンポジウムは韓国機械学会のいわゆる年次大会期間中に併設イベントとして開催された。韓国側の代表は Jongsoo Lee 教授（Yonsei University（延世大学））、日本側の代表は筆者であった。また、日本側との連絡／企画の詰めは主に Chang-Wan Kim 教授（Konkuk University（建国大学））が担当された。筆者の他に、高木知弘准教授（京都工芸繊維大学）と只野裕一准教授（佐賀大学）に日本側の企画を担当して頂いた。参加者全員の記念写真を図1に示す（前列左から5人目がJongsoo Lee 教授）。全員の紹介をしたいが、紙面の都合で割愛させて頂く。

今回はなるべく多くの部門登録者にシンポジウムのことを知って頂くことを考え、まずはインフォメーションメールとメーリングリストを通した参加希望者の募集を行った。また、今後の継続性の観点から、比較的若手の方々の参加者を募ることとした。結果として、高木先生と只野先生をはじめ、今後の日韓シンポジウムを継続的に担っていける方々に参加いただいたのではないかと思う。

図1　日韓シンポジウム参加者の集合写真（会場、BEXCOにて）

夕食会も含めたプログラムの内容は表１の通りであった。日本側メンバーはシンポジウム前日の5月25日（木）に釜山に移動し、夕刻は会食（Welcome dinner）に招待された。韓国の先生方には大変なおもてなしを受け恐縮するばかりだった。

26日（金）午前中は「Nano/Micro/Multiscale Analysis」と「Multiphysics/Coupled Problem」の2パラレルセッションによるシンポジウムが行われた。筆者は、「Multiphysics/Coupled Problem」のセッションで聴講および講演を行ったので、「Nano/Micro/Multiscale Analysis」セッションの様子はわからないが、参加したセッションの印象としては、韓国側参加者はどちらかというとマイクロ／ナノ寄りの連成解析やマルチフィジックス解析の発表が多かったのに対し、日本側はもう少しスケールレベルの大きな問題に対するものが多かった印象がある。今回たまたまなのかもしれないが、韓国の計算力学研究者は比較的スケールレベルの小さな問題の取り扱いが多いような印象を受けた。

表1　日韓シンポジウムプログラム

May 25 (Thu)　18:00 Welcome Dinner
May 26 (Fri)
9:45 ~ 11:00 Session (I): Nano/Micro/Multiscale Analysis, Multiphysics/Coupled Problem
11:15 ~ 12:30 Session (II): Nano/Micro/Multiscale Analysis, Multiphysics/Coupled Problem
12:30 ~ 13:30 JSME-KSME Lunch
19:00 ~ 20:40 Cruise On-Board Banquet

[Nano/Micro/Multiscale Analysis]

Time	May 26 (Fri), Room: 104 Chair: Sung Y. Kim (UNIST)
9:45～10:00	T. Takaki (Kyoto Institute of Technology): Competitive Growth Simulation of Multiple Columnar Dendrites: large-scale Phase-Field Study
10:00～10:15	Maenghyo Cho (Seoul National University): Statistical Multiscale Homogenization of Polymer Nanocomposites
10:15～10:30	A. Takahashi (Tokyo University of Science): Multiscale Modeling of Dislocation Kinematics in BCC Iron
10:30～10:45	Byeongchan Lee (Kyunghee University): Shape Memory Effects of NiTi Alloys
10:45～11:00	Y. Tadano (Saga University): Meshfree Analysis of Higher-order Gradient Crystal Plasticity using Mixed Bases
Time	May 26 (Fri), Room: 104 Chair: T. Takaki (Kyoto Institute of Technology)
11:15～11:30	Yunjung Kim (Korea University): Effect of Water on Various Types of Silkworm Crystalline in Mechanical Perspective
11:30～11:45	Sung Y. Kim (UNIST): Negative Thermal Expansion of Metal (001) Nanowires
11:45～12:00	T. Mayama (Kumamoto University): Crystal Plasticity Analysis of Compressive Loading Behavior of Extruded LPSO-type Mg-Zn-Y Alloy
12:00～12:15	Keonwook Kang (Yonsei University): Molecular Dynamics of Al under Shock for Hugoniot Relationship
12:15～13:00	D. Okumura (Osaka University): Analysis of Biaxial Deformation and Solvent Migration of Polymeric Gels using Two Scaling Exponents

[Multiphysics/Coupled Problem]

Time	May 26 (Fri), Room: 104 Chair: K. Suga (Kogakuin University)
9:45～10:00	Kilho Eom (Seongkyunkwan University): Mechanical Deformation and Fracture Mechanisms of Amyloid Fibrils
10:00～10:15	T. Yamada (University of Tokyo): Simulation of Rotating Tank based on Fluid-Structure Interaction Model Coupling Finite Element Method and Mesh-Free Particle Method
10:15～10:30	Donyun Kim (Seoul National University): Protein Dynamics using Finite Element Modeling Approach
10:30～10:45	D. Ishihara (Kyushu Institute of Technology): Design of Micro Flexible Wing Mimicking Insect Flapping Flight using Fluid Structure Interaction Analysis

10:45～11:00	Seunghwa Ryu (KAIST): Micromechanical-Based Homogenization Method Application to a Wide Range of Interfacial Damage for Reinforced Composites

（表１の続き）

Time	May 26 (Fri), Room: 104 Chair: Donyun Kim (Seoul National University)
11:15～11:30	M. Uchida (Osaka City University): Two-Scale Computational Simulation of Bending of Polyethylene Foams with Different Microstructure Sizes
11:30～11:45	K. Suga (Kogakuin University):Modeling of Tooth-PDL for Rapid Prediction of Initial Tooth Movement in Orthodontics
11:45～12:00	Jinsung Park (Korea University): Ultra-Sensitive Detection Methods for Nano Toxic Ions
12:00～12:15	H. Okada (Tokyo University of Science): Fracture Mechanics Analyses for Welded Joints under the Influences of Weld Residual Stresses and Temperature Histories
12:15～12:30	Seunghwa Yang (Chung-Ang University): On the Effectiveness of the Covalent Grafting of CNT-Polymer Nanocomposites: Molecular Dynamics Study

例えば、Chung-Ang Univ. のYang教授らは、“On the Effectiveness of the Covalent Grafting of CNT-polymer Nanocomposites: Molecular Dynamics Study”で分子動力学を用いたカーボンナノチューブナノコンポジットに関する研究に関する成果を講演された。Seoul National University のKim 教授らは、講演 ”Protain Dynamics using Finite Element Approach” の中で新しいたんぱく質の動力学に関する研究成果と発表されていた。さらに、Sungkyunkwan Univ. のEom教授は” Mechanical Deformation and Fracture Mechanisms of Amyloid Fibrils” の中で、分子動力学を利用したアミロイド細繊維の破断（破壊）に関する講演を行っていた。これらは、分子／原子のスケールレベルを意識した研究に関するものと理解した。一方、日本側参加者の発表は、例えば、九州工業大学の石原准教授のご講演”Design of Micro Flexible Wing Mimicking Insect Flapping Flight using Fluid-Structure Interaction Analysis”で取り上げられたように、マクロなスケールレベルの連成・マルチフィジックス解析に関する研究発表が見られた。どのような発表があったかは、プログラム（表1）をご覧いただきたい。

シンポジウムは午前中で終了し、昼食会の後一旦解散した。次に日本側参加者は、夕方4時ごろから行われていた韓国機械学会Division of CAE and Applied Mechanics の Award Ceremony に合流し、日韓シンポジウムのBest Paper Award 授賞式が行われた。韓国側と日本側で受賞者1名ずつとし、韓国側はKorea University のJinsung Park 教授、日本側は佐賀大学の只野裕一准教授に賞状が授与された。次に日本側参加者に対して記念品が贈呈され閉会となった。さらに、日本側参加者もDivision of CAE and Applied Mechanicsバンケット（釜山港クルーズディナー）に招待され、釜山の夜景を満喫し全日程を終了した。

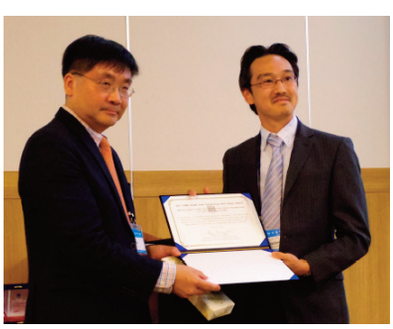

図2　Jongsoo Lee 教授（Yonsei University（延世大学））から只野裕一准教授（佐賀大学）へのBest Paper Award の賞状授与

この日韓シンポジウムは基本的に2年に1回開催することとしている。次回、2019年に日本で開催となり、日本機械学会計算力学部門がホストを務める順番である。会期中少しお酒の入った席で、九州で開催することにして講演発表は少し若手にシフトしてはどうかという会話を韓国側参加者とかわした。2年後が楽しみである。

次に、日韓シンポジウムに参加した感想を述べたい。第一に、韓国の方々の心のこもったおもてなしに心よりの感謝の気持ちと、日本開催になるときに同じようなおもてなしができるのだろうか？という不安を覚えた。一方、韓国機械学会Division of CAE and Applied Mechanics 特有のトレンドかもしれないが、ナノ／マイクロという非常にスケールレベルの小さな問題に対する計算力学研究が注目を集めている印象を受けた。また、そのレベルは大変高い。韓国の大学院の教育システムは米国のシステムに近いとのことである。すなわち、筆者の勘違いかもしれないが、大学院博士課程の学生は、主として指導教員の外部資金を原資とするリサーチアシスタントシップによる金銭的援助の下で研究に専念することできる制度が整備されているのだろうと理解した。このことが、博士課程への学生の進学を促し、研究のレベルアップに繋がっているのだろうと考えさせられた。このように、日韓シンポジウムに参加し、韓国の計算力学研究者らとの研究交流に加えて様々考える機会を得ることもできた。今後、多少参加者の年齢層の若返りと、継続を望むところである。筆者も微力だが協力を惜しまないつもりである。

最後に、今後の日韓シンポジウムを担っていくであろう、今回の日本側参加者を写真（図3）とともに紹介し、むすびとしたい。

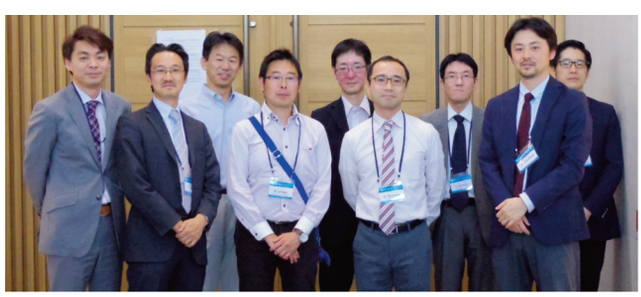

図3　日本側参加者（筆者を除く）[前列左から、須賀准教授（工学院大学）、只野准教授（佐賀大学）、内田講師（大阪市立大学）、奥村准教授（大阪大学）、髙橋准教授（東京理科大学）、後列左から、高木准教授（京都工芸繊維大学）、眞山准教授（熊本大学）、山田准教授（東京大学）、石原准教授（九州工業大学）

《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. 58 : 2017年11月22日発行
編集責任者：広報委員会委員長　佐々木大輔
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　工藤淑文
アルテアエンジニアリング株式会社
〒170-6043　東京都豊島区東池袋3-1-1 サンシャイン60 43階
TEL: 03-5396-1341 FAX: 03-5396-1851 E-Mail: kudo@altairjp.co.jp

印刷：生々文献サービス／〒151-0053 東京都渋谷区代々木2-36-6／TEL.03-3375-8446／FAX 03-3375-8447／E-mail: seiseibunken@nifty.com