

脳型統合システムの研究開発

生命体工学研究科人間知能システム工学専攻

准教授 田中 悠一郎(電シH28)



今年度の4月に大学院生命体工学

研究科人間知能システム工学専攻人間知能機械講座の准教授に就任しました田中悠一郎と申します。また、准教授着任に伴い、新しく人間知能機械講座に研究室を立ち上げる運びになりました。本稿では著者が研究室を立ち上げるに至るまでの経緯と、研究室でどのような研究を実施していくかをご紹介します。

研究室立ち上げに至るまで

著者の九州工業大学での歴史は、平成24年4月に本学工学部電気電子工学科に入学したところから始まります。入学後しばらくは戸畑キャン

パスで大学生活を過ごしておりましたが、学部3年時に生命体工学研究科の田向権先生の講義を受け、先生の研究内容に感銘を受けたことがきっかけで、学部4年時に田向研究室に配属することとなり、若松キャンパスでの大学生活が始まりました。

若松キャンパスにやってきてすぐに、若松を拠点とするロボット開発チーム Hhikino-Musashi@Home(HMA) に所属することとなり、家庭用サービスロボットの研究開発に携わるようになりました。当時、今では当たり前前の技術ですが、深層学習がブームになりつつあるところで、著者もHMAのメンバーと深層学習によるロボットの画像認識機能を開発していました。言わずもがな、深層学習による画像認識は非常に強力です、その後HMAはこの技術を以って、ロボカップ@ホームやワールドロボットチャレンジといった家庭用サービスロボットの国際競技会で複

数回優勝することとなります。

著者はこうしたHMAの活動の中で、深層学習の恩恵を受けつつも、それを応用する際の課題に常に直面していました。一つは大量の学習データが必要であることです。深層学習の性能を引き出すためには、数万以上のオーダーの学習データを用意するのが当たり前で、データの用意に多大なコストを必要とします。人物の検出や家具の認識など、世界共通の処理対象については、データを大量に収集することは容易ですが、家族の好みや習慣などといった環境固有の情報は大量に収集することが困難で、深層学習では家庭用サービスロボットに求められる学習をすべて網羅できません。

もう一つの課題は消費電力です。深層学習は膨大な計算コストを必要としますが、これを高速化するためGPUを用いた並列演算を適用するのが主流ですが、結局のところ膨大な電力を消費することとなります。HMAのロボットもGPU付のコンピュータを搭載し、深層学習による画像認識のプログラムを動作させていますが(図1)、コンピュータの

バッテリーがすぐに切れてしまう問題に直面しています。



図1 GPU付コンピュータが搭載されたロボットがロボカップに出場する様子

以上の深層学習と家庭用サービスロボットの要求のギャップから、こうしたロボットを社会実装まで持つていくためには、深層学習では実現困難な環境固有の知識を獲得する人工知能モデルと、それを高速かつ省電力に実行できる専用ハードウェアが必要であるという考えに至りました。これを実現するため、著者は博士後期課程の間に、エピソード記憶の機能を司る海馬や扁桃体を模倣した人工知能モデル、およびそのハー

ドウェア化の研究を実施し、令和3年の3月に学位を取得しますが、前述の考えは現在も実施する研究のベースの考えとなっています。

学位取得後、著者は本学ニューロモルフィックAIハードウェア研究センターの助教に就任しました。当センターは、材料に潜在する知能を引き出し、これを人工知能の計算に活用することで、既存の計算機システムを超越するエネルギー効率をもつニューロモルフィックAIハードウェアの実現を目指す組織で、材料・数理・回路・ロボットの研究者が連携できる体制を整えています。著者は当該センターメンバーとして、主に材料分野とロボット分野をつなぐ役割を担ってきました。

脳型統合システム研究室の設立

ニューロモルフィックAIハードウェア研究センターの助教として3年間を過ごした後、現職に昇任し、脳型統合システム研究室を立ち上げることとなりました。研究室の名前は、著者がこれまでに実施してきた研究に由来していて、例えば環境固有の知識を獲得するための海馬・扁桃

モデルの統合や、材料とロボットの統合などから、統合というキーワードを採用することとしました。

現在、当研究室は三つの研究テーマを掲げています。一つは海馬・扁桃・前頭前野を模倣した脳型AIの開発です。これは、著者が博士後期課程時代から継続して実施している研究で、環境固有の知識の獲得機能の充実を図っています。

二つ目はレザバー計算の機能拡張です。レザバー計算とは時系列信号処理を得意とするニューラルネットワークの枠組みの一種で、学習にかかる計算コストが低いという特徴を持ち、エッジへの実装に適しています。レザバー計算の学習が軽量である理由は、通常のニューラルネットワークが学習によってネットワークの全体を更新するのに対し、レザバー計算はネットワークの一部（リードアウト）のみを更新するため、学習にかかる計算量が少ないところから来ています（図2）。この特徴はメリットとデメリットが表裏一体で、学習が簡単である一方、学習の自由度が低く、データセットへの適合能力に限界があります。そこ


で著者は複数のリードアウトを導入して、与えられたデータに応じて学習するリードアウトを切り替えることで、学習にかかる計算コストを抑えつつも、レザバー計算の性能を向上する手法を提案しています。

三つ目はこれまで紹介してきた脳型AIやレザバー計算の家庭用サービスロボットへの応用です。研究のプラットフォームとしてヨタHSRや、Preferred RoboticsのInachakaを用いて実証実験を行っています。

今後研究を進めたいのは、提案する脳型AIやレザバー計算を、現行のAIと「統合」することです。現行AIは世界共通の知識を有し、当研究室が開発を進めるAIは環境固有の知識を有します。これらを統合し相互作用させることで、さらに賢いAIを実現することができると考えています。

通常のニューラルネットワーク

学習により全ての結合荷重を更新
= 学習コストが高い



レザバー計算

学習により一部の結合荷重を更新
= 学習コストが低い




図2 レザバー計算の特徴