

産業界の技術動向

オムロンサイニックエックスにおける機械学習研究の最先端

オムロンサイニックエックス株式会社

米 谷 竜

1. はじめに：オムロンサイニックエックスについて

オムロンサイニックエックス (OSX) は 2018 年に設立されたオムロンの子会社です。大学から転職してきたメンバーが非常に多く、十数名の小さな会社でありながら、社長も含めてメンバーの多くが博士号を取得しています。JSPS や JST の競争的資金にも応募できますし、大学との共同研究も活発に行われています。そして何より、会社全体の活動として、学術的にハイインパクトな成果を見据えた基礎研究に邁進しています。それぞれのメンバーはインターンとともに研究することもあれば、メンバー同士で協力して研究を進めることもあります。ただし、いずれのケースにおいても、研究活動における重要なマイルストーンとして国際会議・ジャーナルでの論文発表があり、成果のオープンソースソフトウェア化がありおます。つまり、成果をオープンにすることに関して OSX は非常に積極的であり、それがメンバーやインターンにとっての魅力・原動力になっています。

もちろん、事業的な側面を全く無視しているわけではありません。オムロンサイニックエックスという名前は、オムロン創業者である立石一真が提唱した「SINIC (Seed-Innovation to Need-Impetus Cyclic Evolution) 理論」が元になっています。要点を言うと、科学が技術の種となり、それが社会を革新する — 一方で、社会からのニーズが技術の開発を促進し、ひいては新たな科学の創出へとつながる—これらのサイクルにより社会を発展させていこう、ということになります。個人的には、事業的なニーズをできる限り普遍的な課題へと抽象化し、基礎研究の世界においてその課題を解決する技術体系を創出するとともに、その過程で得られた知見をニーズ側にフィードバックする、という営みとして SINIC を理解し、また実践しています。また、OSX を特徴づけるもう一つの要素として、「近未来デザインからのバックキャスト」という考え方があります。つまり、現状の社会情勢、課題、技術から将来のあり方を予測(フォアキャスト)するのではなく、まず先に目指す近未来のあり方を具体的に思い描き、その実現に必要な戦略を明確化しようということです。これを常に意識することで、目の前にある技術的・事業的課題を近視眼的に解決しようとするのではなく、より長期的な視点をもって、広がりのある研究に取り組むことができます。

2021 年 10 月 22 日に開催された電気系懇話会では、OSX で取り組まれている研究プロジェクトのうち、とりわけ機械学習に関連したものを取り上げて紹介しました。本稿ではそのいくつかについて改めて振り返ります。

2. モデル統合に基づく分散環境からの機械学習

データセントリック AI という言葉があります。AI、より狭義には機械学習モデルを学習するためには、良質・大量・多様な学習データが不可欠であるという、いわばデータ中心的な考え方です。実際、どれほど複雑な処理が可能な機械学習モデルであっても、その処理のお手本となるデータが十分になれば、学習されたモデルは期待する性能を発揮することができません。

一方で、分野によってはそもそもデータを大規模に収集することが難しい状況もあります。たとえば、

医用画像処理という分野では X 線画像等から異常部位の検出や臓器領域の抽出を行うために機械学習が利用されることがあります。しかしながら、このような画像やそこから得られる処理結果はもともと特定の個人と紐づくものであり、適切なデータ取得や利用、保守には多くの手続きや労力を要します。ほかにも、製造業における基盤検査や外観検査といった課題においても機械学習は有力なアプローチですが、製造中の製品に関する情報は多くの場合機密に扱う必要があり、たとえば各地に点在する工場からデータを吸い上げて一つのサーバで保管するといった、ともすれば機械学習分野では自然と考えられる前提を満たすことがそもそも難しいことがあります。

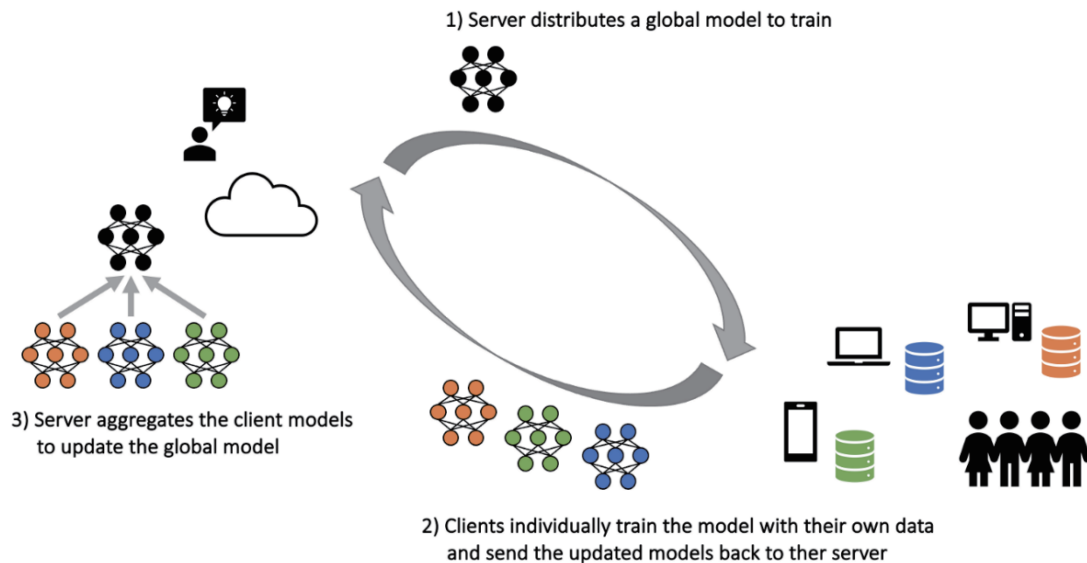


図 1 モデル統合に基づく分散環境からの機械学習

このような困りごとを抽象化していくと、一つの学術問いが見えてきます — データを計算サーバに集約することなく、かつそのデータの中身に直接アクセスすることもせず、しかしそのデータを用いて機械学習モデルを学習することはできるでしょうか？

この問いに対する一つの有力なアプローチが、「モデル統合に基づく分散環境からの機械学習」です。図 1 に示すように、複数のクライアントがそれぞれ独自にデータを保持している状況を考えます。これに対してサーバは、クライアントのデータに直接アクセスすることなく、しかしそれらのデータを活用することで機械学習モデルを学習することを目指します。より具体的には、(1) まずサーバが各クライアントに対してモデルを配布し、(2) クライアントはそのモデルを自身のデータを用いて学習、サーバに返送します。(3) その後、サーバはクライアントから送られてきた学習済みモデルを蒸留 (distillation) と呼ばれる方法で統合することで、全モデルの学習結果を反映したかような、より良いモデルを獲得します。これにより、サーバがクライアントのデータそのものにアクセスする必要がなくなるのです。

上記のような基本アイデアのもと、具体的に解きたい機械学習の問題の種類にあわせて実際の学習パイプラインを構築することになります。たとえば、文献 [1] では画像分類という典型的な教師あり学習に関して、それぞれのクライアントが持つデータの分布や学習可能なモデルの大きさが異なる状況に適したモデル統合方法および全体のパイプラインを提案しています (図 2)。また文献 [2] では、強化学習において各クライアントが異なる環境からデータを収集した状況をとりあげ、新たな未知環境でモ

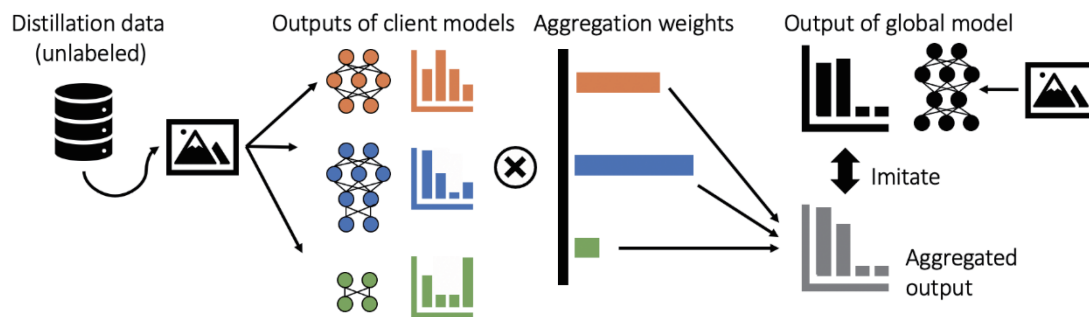


図2 モデル統合に基づく教師あり学習の一例 [1]

デルを効率的に学習する課題に取り組んでいます。さらに文献 [3] では、同様の考え方を実際のロボット操作に応用しています。このように、アイデア自体はシンプルながら人工知能、ロボティクスという複数領域にわたって成果を論文化することができました。

とはいったものの、上記の研究群はあくまでモデル統合に基づく学習方式、アルゴリズムのみに特化したものであり、これを実課題で運用しようとするとき考えるべき点は非常に多くなります。たとえば、あるクライアントからサーバに対してモデルを送信する際には、どのようなセキュリティ対策を必要と考える必要があるのでしょうか。また、送られてきたモデルに欠損がある場合や、あるいは悪意のあるクライアントが意図的に低い性能のモデルを送ってきた場合には、どのように対処すべきでしょうか。それぞれのクライアントが異なる個人や企業であった場合、そもそもモデルを共有させるためのインセンティブはどのように設計すべきでしょうか。こういった周辺課題についても、その分野の専門家や事業的な出口に近い部門も交えて検討を続ける必要があります。

3. データ駆動型アプローチによる経路計画技術の高度化

移動 —これは私達にとって最も基本的な行動の一つです。自宅の中での寝室からキッチンへの移動から通勤、買い物、あるいは旅行など、移動は日常生活のさまざまな場面で必要となります。このような人の営みをロボットによって支援するためには、ロボット自身も人と同様に洗練された自律的な移動機能を備える必要があります。実際、工場や倉庫における物品の搬送から屋内の清掃、さらには公共空間における自動運転まで、自律移動は多くの応用シーンにおいて不可欠な技術となっています。

経路計画は自律移動における最も基本的な構成要素の一つです。ある与えられた環境において、ロボットは自身のスタート地点からゴール地点まで移動するために、障害物に衝突することなく、かつできるだけ短い距離で両者をつなぐことのできる経路を探索する必要があります。ロボットが障害物の位置をあらかじめ知ることができ、かつその障害物が移動しない場合は、A*探索をはじめとした古典的なアルゴリズムにより、効率的にそのような経路を導き出すことができます。

これに対して私達は、このような古典的アルゴリズムが過去の経路計画の事例をうまく活用できるようになれば、新たな問題に対してより良い経路計画が実現できるのではないかと考えました。実際に私達は、与えられた環境の地図を一目見れば、障害物の配置を把握し、先験的な知識や過去の経験から、スタートからゴールへの効率的な移動経路を思い描くことができます。「地図を見て」「知識・経験と照合することで」「経路を探索する」—このような知的活動を、コンピュータビジョン、機械学習、経路探索アルゴリズムの融合によって実現できるでしょうか。

4. Neural A*: 微分可能な A* 探索による知的な経路計画

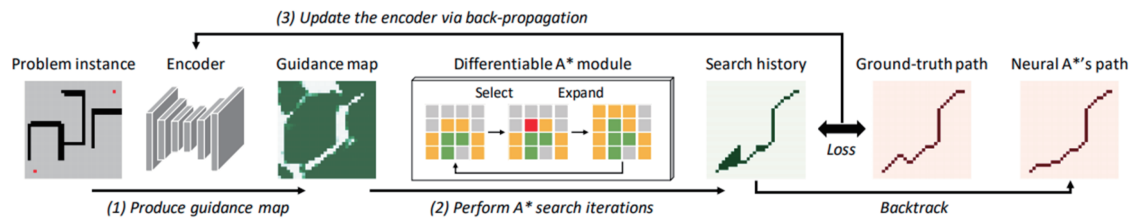


図3 Neural A* [4] のモデルアーキテクチャ

Neural A* は上記のような考え方を最も直接的に実現する機械学習モデルです。図3に示すように、このモデルは、与えられた環境地図を A* 探索によって解きやすい形に変形する深層ニューラルネットワークベースのエンコーダと、同じくニューラルネットワークの中で経路計画が可能な「微分可能 A* モジュール」から構成されます。微分可能 A* はその名の通り、A* 探索を微分可能な手続きで書き下したものであり、アルゴリズムの各ステップにおける振る舞いがどの程度理想的であったかを、誤差逆伝播によってエンコーダに伝えることができます。これと経路計画に関する大量の事例を組み合わせることで、たとえば「より探索効率を向上させるエンコーダ」や「障害物位置が未知であっても経路計画が可能なエンコーダ」を学習し、新しい経路計画問題において活用することが可能になります。

実際に私達の成果では、Neural A* が通常の A* 探索や最新の学習ベース探索と比較して経路計画の効率を向上させられることや、入力がドローンによる空撮のような実画像であっても適切に学習されたエンコーダによって経路計画が可能であることが示されています（図4、図5）。この成果は機械学習分野におけるトップ国際会議の一つである International Conference on Machine Learning (ICML) に採録された（文献 [4]）ほか、日経ロボティクスをはじめとした各種メディアに掲載されるなど、国内外で高い評価をいただきました。

5. CTRMs: 連続空間におけるマルチエージェント経路計画のためのロードマップ生成

倉庫内での自動搬送など、実用上は複数のロボットを協調的に移動させる必要があるケースも多く存在します。このような課題はしばしばマルチエージェント経路計画と呼ばれ、人工知能・ロボティクス分野で長らく研究されてきました。多くの場合は与えられた環境をグリッド（碁盤目）で表現し、その




図4 Neural A* を用いた効率的な経路計画。A*: 従来の A* 探索、BF: 最良優先探索、WA*: 重み付き A* 探索、SAIL, SAIL-SL, BB-A*, Neural BF: 既存の学習ベースアプローチ、Neural A*: 提案手法、Guidance Map: エンコーダの出力

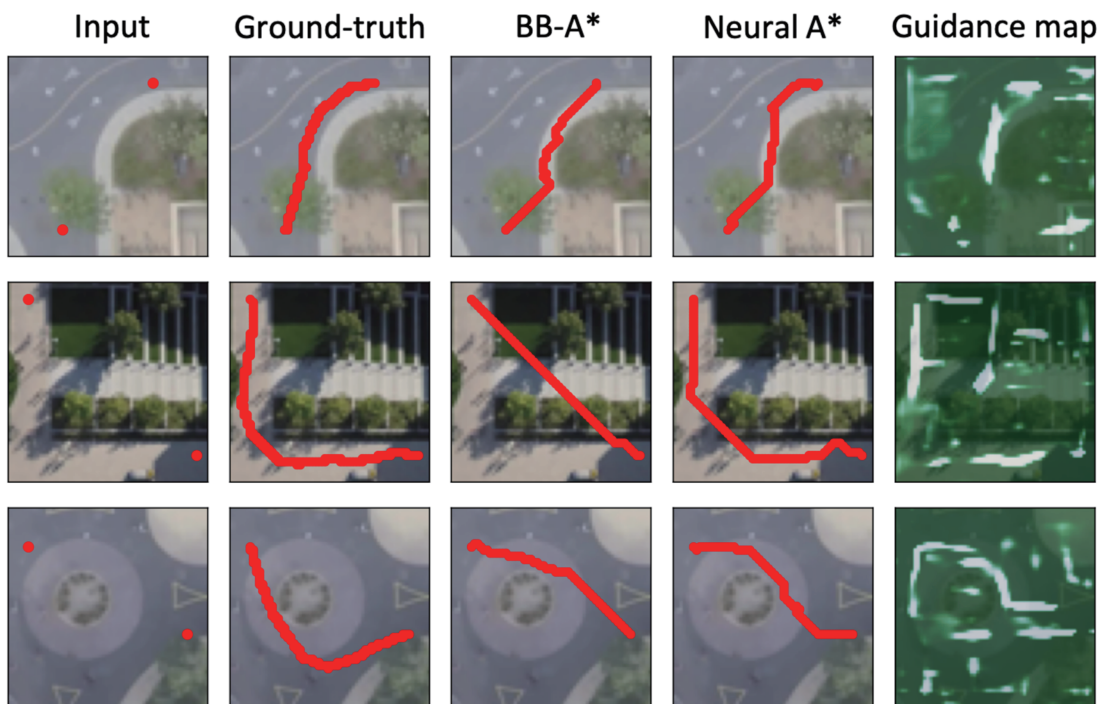


図5 Neural *A を用いた実画像からの経路計画。Ground-Truth: 人間の歩行軌跡、BB-A*: 既存の学習ベースアプローチ、Neural A*: 提案手法、Guidance map: エンコーダの出力

上を前後左右に移動するエージェントを想定します。一方で、実際のロボットは前後左右以外の方向にも自由に動けますし、そのような動きを想定することで、目的地までのより短い経路を計画することもできます。

そこで、エージェントの移動する環境をグリッドではなく連続空間として扱うマルチエージェント経路計画を考えます。既存手法では多くの場合、このような連続空間をランダムに配置された頂点から構成されるグラフ（ロードマップ）に近似し、そのグラフ上で複数エージェントが互いに衝突せず自身のゴールに到達するための経路を探索します。このとき、頂点数が多ければ多いほど探索可能な経路も増え、より短い経路の組み合わせを得られる可能性が高まりますが、一方で探索にかかる計算コストも急増します。逆に、頂点数が少なければ少ないほど計算コストも低減できますが、場合によってはエージェント同士が衝突しない経路を得られない可能性があります。すなわち、連続空間を近似するグラフの頂点をどのように与えるかという点と、その結果どれほど良い解が得られるか、という点の間にはトレードオフがあることが知られています。




図6 機械学習を用いたマルチエージェント経路計画のためのグラフ構築

これに対して私達は、機械学習技術を活用することで、できるだけ少ない頂点数で良い解が得られるようなグラフを構成するアプローチを開発しました。鍵となるアイデアは、与えられた複数エージェントの位置関係から、それぞれのエージェントが次にどちらの方向に移動すれば、互いに衝突せずに自身

のゴールに近づけるかという、「見込みのある次ステップ」を予測するモデルを学習することです(図6)。このようなモデルは、マルチエージェント経路計画問題とその解となる経路の組を(長い時間をかけて)あらかじめ大量に生成しておき、それを学習データとすることで獲得できます。また、モデルには「条件付き変分オートエンコーダ(conditional variational autoencoder; CVAE)と呼ばれる生成モデルを用いることで、ある与えられた複数エージェントの位置関係から、見込みのある次ステップを多数生成し、成功率の向上につなげることができます。




図7 左から順にグリッド、ランダム頂点によるグラフ、提案手法によるグラフ




図8 左から順にグリッド、ランダム頂点グラフ、提案手法を用いた経路計画

図7, 8に結果の一例を示します。このように、既存手法であるグリッドやランダムな頂点から構成されるグラフと比較し、提案手法のロードマップは各エージェントのスタート地点からゴール地点までの経路を効率的にカバーしていることが分かります。実際このようなグラフを用いて経路計画をすることにより、従来手法より効率的に、それでいて同等の成功率、経路長の結果を得ることができました。この成果はマルチエージェント分野における主要国際会議である International Conference on Autonomous Agents and Multiagent Systems (AAMAS) に採録されています(文献 [5])。

6. おわりに

私自身は2013年に京大情報学研究科で博士号取得後、5年間ほど東京大学生産技術研究所で助教として研究に取り組んできました。OSXへの転職のお誘いがあった際には「企業ではどうしても事業に直結する研究開発が中心になるのでは」という先入観があって尻込みもしたのですが、蓋を開けてみると大学在籍時と変わらず基礎研究を継続しています。もちろんこれを企業全体に一般化はできないのですが、一方で博士号や大学での研究活動の業績を適切に評価し、より長期的な視点でのハイインパクトを見据えた基礎研究を積極的に推進する研究チームが国内企業で増えてきていることも、とりわけAI・

ロボティクス分野では確かだと感じます。今後もこの流れが継続・発展し、産官学すべての場所において自由で活発な研究活動が起こることを期待しています。

参考文献

- [1] Jiaxin Ma, Ryo Yonetani, Zahid Iqbal, “Adaptive Distillation for Decentralized Learning from Heterogeneous Clients” , International Conference on Pattern Recognition(ICPR), 2020
- [2] Mohammadamin Barekatain, Ryo Yonetani, Masashi Hamaya, “MULTIPOLAR: Multi-Source Policy Aggregation for Transfer Reinforcement Learning between Diverse Environmental Dynamics” , International Joint Conference on Artificial Intelligence(IJCAI), 2020
- [3] Kazutoshi Tanaka, Ryo Yonetani, Masashi Hamaya, Robert Lee, Felix von Drigalski, Yoshihisa Ijiri, “TRANS-AM: Transfer Learning by Aggregating Dynamics Models for Soft Robotic Assembly” , International Conference on Robotics and Automation(ICRA), 2021
- [4] Ryo Yonetani, Tatsunori Taniai, Mohammadamin Barekatain, Mai Nishimura, Asako Kanezaki, “Path Planning using Neural A* Search” , International Conference on Machine Learning(ICML), 2021
- [5] Keisuke Okumura, Ryo Yonetani, Mai Nishimura, Asako Kanezaki, “CTRMs: Learning to Construct Cooperative Timed Roadmaps for Multi-agent Path Planning in Continuous Spaces” , International Conference on Autonomous Agents and Multi-Agent Systems(AAMAS), 2022