


科学技術未来戦略ワークショップ報告書

社会価値を生み出す 最適化の革新

ワークショップ報告書
CRDS-FY2025-WR-02



エグゼクティブサマリー

本報告書は、国立研究開発法人科学技術振興機構（JST）研究開発戦略センター（CRDS）が2024年8月31日に開催した科学技術未来戦略ワークショップ「社会価値を生み出す最適化の革新」の内容をまとめたものである。

JST CRDSは、科学技術に求められる社会的・経済的なニーズを踏まえて、国として重点的に推進すべき研究領域や課題、その推進方策に関する提言を行っている。この活動の一環として、意思決定と最適化の数理について、社会課題解決への貢献の質と幅を広げるために、出口戦略を意識しつつ研究開発を進化させる必要性があると考え、「社会価値を生み出す最適化の革新」についての調査活動を進めてきた。

本ワークショップでは、以下の三つの仮説を提示して、話題提供と討論を実施した。

1. 数理最適化と機械学習の融合は最適化手法の適用範囲を広げることに役立つ。
2. 数理最適化と機械学習を融合させるためには、リアルタイム性の向上、ロバスト性の向上、大規模高次元問題を解く際の計算量削減といった研究開発と人材育成が必要である。
3. 課題解決の実績を積み重ね、人材育成と人材交流を進めることで、最適化手法が社会により広く受け入れられ、社会課題解決に資するという社会価値を生み出すことができる。

研究開発課題については、「機械学習による最適化問題の高速求解」、「機械学習の最適化」、「係数が不確定で一つに決められない最適化問題」、「不確実な情報を含む多段階意思決定問題」について話題提供があり、数理最適化や機械学習を利用するためのプラットフォームや、最適化手法のリアルタイム性やロバスト性について議論を行った。

研究開発の推進方法については、「サプライチェーンマネジメント（SCM）における指標」、「数理最適化による問題解決プロセス」、「数理最適化ソフトウェア（ソルバー）」、「情報と数理の融合」について話題提供があり、最適化技術の普及の方法や壁について議論を行った。

これらの議論を踏まえ、CRDSでは今後国として重点的に推進すべき研究領域と具体的研究開発課題を検討し、研究開発の推進方法も含めた戦略プロポーザルとして、関係府省や産業界、学会等に提案する予定である。

目次

1	趣旨説明	
	吉脇 理雄 (科学技術振興機構)	1
2	研究開発課題についての話題提供	4
2.1	ハイブリッド最適化 1：機械学習による最適化問題の高速求解 高野 祐一 (筑波大学)	4
2.2	ハイブリッド最適化 2：人工知能と最適化理論 鈴木 大慈 (東京大学 / 理化学研究所)	7
2.3	ハイブリッド最適化 2：ロバスト 1 + 大規模 武田 朗子 (東京大学 / 理化学研究所)	10
2.4	ハイブリッド最適化 3：不確実な情報を含む多段階意思決定問題に対する ロバスト性向上 近似動的計画法と強化学習を中心として 小林 和博 (青山学院大学)	16
2.5	研究開発課題についての総合討議	23
2.5.1	話題提供：産業アプリケーションとアルゴリズム (最適化 (量子)、機械学習 (ML)) 藤澤 克樹 (東京科学大学)	23
2.5.2	総合討議	26
3	研究開発の推進方法についての話題提供	29
3.1	先導的研究会について：MOAI 技術による SCM Solutions Metrics, Trade-offs and Beyond 久保 幹雄 (東京海洋大学)	29
3.2	実用に沿った研究開発について：実務につなげる数理最適化 梅谷 俊治 (株式会社リクルート)	33
3.3	最適化技術の普及について 藤井 浩一 (株式会社 NTT データ数理システム)	39
3.4	情報と数理の融合について 上田 修功 (理化学研究所革新知能統合研究センター)	42
3.5	研究開発の推進方法についての総合討議	45
3.5.1	話題提供：最適化技術の普及について JST-RISTEX「政策のための科学」プログラムの知見から 黒河 昭雄 (神奈川県立保健福祉大学 / JST-RISTEX)	45

3.5.2	話題提供：最適化研究と国際的観点について 土谷 隆（政策研究大学院大学）	50
3.5.3	総合討議	52
付録	ワークショップ開催概要	55

1 | 趣旨説明

吉脇 理雄（科学技術振興機構）

JST CRDSは、科学技術に求められる社会的・経済的なニーズを踏まえて、国として重点的に推進すべき研究領域や課題、その推進方策に関する提言を行っている。この活動の一環として、研究開発の俯瞰報告書システム・情報科学技術分野（CRDS-FY2022-FR-04）の数理科学区分「意思決定と最適化の数理」領域について、社会課題解決への貢献の質と幅を広げるために、出口戦略を意識しつつ研究開発を進化させる必要があると考え、「社会価値を生み出す最適化の革新」についての調査活動を進めてきた。

社会課題に取り組む際、従来のように勘や経験に頼った意思決定に比べて、オペレーションズリサーチや最適化を導入することによって、より合理的な意思決定が可能になると考えられる。したがって、これらの手法の適用範囲を拡大し、課題解決の実績を積み重ねることや人材育成を進め、社会の受容度を高めることによって、社会課題の解決に貢献することを提案したい。

社会課題解決の具体例として、ルフトハンザ航空の飛行軌道最適化がある。燃料消費量を削減するために最適な飛行軌道を見つけるという課題に対し、ルフトハンザとZuse Institute Berlin（ZIB）が協力して研究を行った。この課題解決のための意思決定プロセスにおいて、オペレーションズリサーチや最適化は、さまざまな条件を考慮しながら飛行軌道を効果的に最適化する手法として有効であった。

オペレーションズリサーチは、数学的あるいは統計的モデル・アルゴリズムを活用し、さまざまな計画において最も効率的な解決策を導く科学的な手法である。その中でも、数理最適化が中心的なテーマとなっている。数理最適化は、最適化対象となる目的関数や、制約条件から構成される。しかし、実務上の定式化や計算量に課題がある。

最適化における具体的な問題について、物流2024問題に沿って触れることにする。物流2024問題とは、トラック事業において時間外労働がこれまでより制限され、1日に運ぶことができる荷物の量が減るなどの問題が起きることである。運転手の拘束時間に制限があるため、適切な配送計画¹を立てることが難しくなる。

一つ目の問題は、拘束時間の制限が複雑化し、決められた時間内で最適な解を出すことが困難になる点である。二つ目の問題は、原則を超える拘束時間という不確実な状況を考慮する必要が生じたため、最適解の導出が難しくなった点である。三つ目の問題は、全ての関係する運転手を考慮する必要があり、対象が増えたことによって、問題が大規模かつ高次元化し、最適解を導こうとしても現実的な時間内に計算が完了しない点である。

このような最適化の実際の問題に対して、数理最適化と機械学習を融合させたハイブリッド最適化が有効であると考えられており、研究開発が進展しつつある状況である。日本では東京海洋大学の久保先生が中心となり、2023年にMOAIフォーラムがスケジューリング学会の研究部会として設立されている。米国では、National Science Foundationの支援を受けて、2021年にArtificial Intelligence Institute for Advances in Optimizationが設立されている。ドイツでは、ZIBが2018年以降、この分野に取り組んでいる。また、中国ではAlibabaが2017年にDAMO Academyを設立し、その中のDecision Intelligence Labで研究が進められている。

物流2024問題で挙げた三つの問題に対応するには、最適化解法に対してリアルタイム性、ロバスト性、大

1 配送計画とは工場などの拠点から幾つかの店舗を回り、荷物を下ろし、拠点に戻ってくるプロセスにおいて、さまざまな条件のもとで最適なルートを決定するものである。制約条件が複雑になるため、巡回セールスマン問題より難しい問題である。

規模高次元問題を処理する能力をどのように付与するかが重要である。これらの課題に対しては、数理最適化と機械学習による最適化を組み合わせたハイブリッド最適化による対応が期待されている（図1-1）。

問題	課題
制約条件が複雑で、決められた時間内で最適な解が求められない。	MLがMOptをアシストすることによる最適化のリアルタイム性向上
データに不確実性が含まれ、最適な解を求めることが難しい。	基礎理論における、もしくは強化学習（RL）を中心とした、MOptとMLとの融合による最適化のロバスト性向上
問題が大規模高次元ゆえ、現実的な時間で計算が終わらない。	MLを用いたモデリングによる大規模高次元最適化問題の計算量削減

図1-1 解決すべき課題

研究開発を進める際には三つの障壁がある。まず、数理最適化と機械学習の分野を融合する必要があるが、両者の間に隔たりがある。次に、実用的な技術開発を行う必要があるが、最適化分野内で理論と実用の間に隔たりが存在する。最後に、最適化技術の導入自体に関する障壁がある。これらの障壁を取り除きたいと考えている（図1-2）。



図1-2 研究開発の推進方法と具体案

ハイブリッド最適化の研究開発が進展した際の社会・経済的な効果としては、社会価値の創出への寄与、意思決定の改善、初期段階から社会の要請を反映した研究開発による市場の拡大が期待される。科学技術上の効果としては、ハイブリッド最適化による問題解決の対象領域の拡大、リアルタイム性やロバスト性の向上、大規模高次元問題の計算量削減といった、新たな最適化手法の実現が期待される。また、最適化技術の発展と共に、この融合領域での人材育成が進むことで、新たな科学的知見を得ることも期待される。

このワークショップでは、数理最適化と機械学習の融合という視点を取り上げ、以下の三つの仮説を提示しつつ、今後の可能性と課題について議論したいと考えている。

1. 数理最適化と機械学習の融合は最適化手法の適用範囲を広げることに役立つ。
2. 数理最適化と機械学習を融合させるためには、リアルタイム性の向上、ロバスト性の強化、大規模高次元問題を解く際の計算量削減等の研究開発と人材育成が必要である。
3. 課題解決の実績を積み重ね、人材の育成や交流を進めることで、最適化手法が社会に広く受け入れられ、社会課題解決に貢献するという社会的価値を創出することができる。

2 | 研究開発課題についての話題提供

2.1 ハイブリッド最適化1：機械学習による最適化問題の高速求解

高野 祐一（筑波大学）

近年、組合せ最適化における機械学習の研究が盛んに行われている²。その内容としては、一貫学習（end-to-end learning）、アルゴリズム構成の学習、最適化アルゴリズムとの並行学習などがある。特に、一貫学習は、最適化の過程全体を機械学習で実現するものである。アルゴリズム構成の学習は、機械学習を用いて手法の選択やパラメータを設定するもので、最適化アルゴリズムとの並列学習は、最適化アルゴリズムの内部で機械学習を活用するものである。

これらの機械学習技法には、実行可能性、モデリング、規模拡張性、データ生成といった課題がある。実行可能性の課題は、最適化ではその制約条件を守らなければならないのに対し、機械学習では制約条件を守ることが非常に難しい点にある。モデリングの課題は、画像認識には畳み込みニューラルネット、自然言語処理にはトランスフォーマーが適しているように、最適化に適した機械学習モデルを開発する必要がある点だ。また、大規模な問題に対応するための規模拡張性や、最適化問題を解いた実例を大量に収集して訓練するためのデータ生成も課題である。以上のように、課題は多岐にわたる。

混合整数最適化問題の高速求解

興味深い研究の一つに、混合整数最適化問題の高速求解がある³。混合整数最適化問題は非常に有名なNP困難問題であり、厳密な解を求めるのは極めて難しい。ただし、整数変数とその有効な制約を事前に固定できれば、問題は簡単に解ける。そこで、大量の混合整数最適化問題例をオフライン処理で解き、問題例と最適解のデータを収集し、そのデータで機械学習モデルを訓練する。この訓練には膨大な時間がかかるが、一度訓練されたモデルを使えば、オンライン処理は高速に行える。例えば、非常に難しい混合整数の凸二次最適化問題が与えられた場合、機械学習モデルを使って整数変数の値と有効な制約を予測する。すると、問題は連続変数の問題となり、有効な制約を等式制約にできるので、KKT条件（Karush-Kuhn-Tucker condition）により連立方程式に帰着できる。オンライン処理では連立方程式を解くだけで済むため、非常に高速な計算が可能だ。

この方法はオンライン制御の問題などに応用されている⁴。例えば、ロボットの経路探索にも応用されている。障害物があるロボット経路探索は非常に面白く、研究室の学生に卒論で取り組ませてみたが、実現はなかなか難しいと感じた。実行可能性を満たすのが困難で、最適解とは言えないルートが出てしまうことや、障害物を避ける動作が機械学習には非常に難しい点が課題だった。また、スタートからゴールまで一気にルートを作成することができず、ルートを分割して作成する必要があるため、実用規模の問題を解くことは難しいと思った。このテーマは壮大で非常に興味深いが、現状では実用化には程遠いという印象を持った。

2 Bengio, Yoshua, Andrea Lodi, and Antoine Prouvost. "Machine learning for combinatorial optimization: a methodological tour d'horizon." *European Journal of Operational Research* 290.2 (2021): 405-421.

3 Bertsimas, Dimitris, and Bartolomeo Stellato. "Online mixed-integer optimization in milliseconds." *INFORMS Journal on Computing* 34.4 (2022): 2229-2248.

4 Cauligi, Abhishek, et al. "Coco: Online mixed-integer control via supervised learning." *IEEE Robotics and Automation Letters* 7.2 (2021): 1447-1454.

ただし、相性のいい問題がある。それは巡回セールスマン問題である。いろいろな都市の座標が与えられて、それらを全部回るような一番短いルートを作る問題である。問題構造として非常に単純なので、機械学習との相性がいいと感じている。

巡回セールスマン問題

巡回セールスマン問題に対しては良い研究成果が幾つか出ている。2016年のブレイクスルーになった論文⁵がある。都市の座標集合を入力して、都市の訪問順列を出力する Pointer Network というニューラルネットワークを学習する。Pointer Network は、強化学習で訓練するというのが面白いところである。強化学習なので、教師データである最適化問題の問題例と最適解をたくさん用意する必要はなく、問題例をたくさん入れればこの Pointer Network が巡回路を自分で作ってくれる。提案手法と非常に性能が良い配送計画問題を解く局所探索ソルバーで比較実験した結果として、都市数 100 程度の比較的小さな問題であれば、提案手法は局所探索ソルバーと同程度の性能を出すということが示されている。

2021年のAAAIの論文⁶は教師あり学習である。事前に最適化問題の問題例と最適解をたくさん用意し、その座標集合と最適解の関係を学習する。最適解は巡回路で与えられるが、それを隣接行列、ヒートマップとして学習する。推論時に大規模な問題が与えられると、それを部分問題に分けて、部分ごとにニューラルネットでヒートマップを推論し、それらを組み合わせて全体のヒートマップを作成し、モンテカルロ木探索⁷という方法を使って巡回路を作る。実験結果として、都市数 100 以下の問題では、ほぼ厳密解に近い解を高速に出力できている。都市数 1000 の問題に対しても、ギャップ 3% 程度の解を出せるという結果も得られている。

大規模問題への拡張についての論文⁸もある。Encoder と Decoder のネットワークを用いるが、通常は Encoder を大規模にするところを逆に Decoder を大きくして性能を向上させるという論文である。また、最適経路だけでなく、その部分経路も学習に用いる。推論時には巡回路を作り、その部分的な経路を取り出して改善するということを繰り返して性能を向上させる。実験結果は、部分的な経路の改善を繰り返す LEHD (Light Encoder and Heavy Decoder) という提案手法で性能が向上し、1000 都市の問題に対してギャップ 1% 以下の解を出力できている。特に、OR Tools という手法では 10 時間かかっても、ギャップ 5% の解しか得られないのに対して、LEHD では 1.6 分という非常に短い時間でギャップ 3% の解を出力できるという驚異的な結果が得られている。

最後に

最後に、機械学習と数理最適化の融合について触れる。このようなワークショップが開かれている背景には、混合整数最適化問題の高速求解が注目を集めているという状況があるのだと思う。個人的には、巡回セールスマン問題に対しては局所探索ソルバーを圧倒する結果が出始めているが、混合整数最適化問題の実用化にはまだ距離があると感じる。確率制御と数理最適化の融合も有効である。機械学習の研究者と数理最適化の研究者が協力して研究を進める必要がある。特に深層学習を活用するためには、深層学習の専門家との協力が不可欠である。また、数理最適化の研究者が強化学習や確率制御の手法を理解し、動的な最適化問題を

5 Bello, Irwan, et al. "Neural combinatorial optimization with reinforcement learning." *arXiv preprint arXiv:1611.09940* (2016).

6 Fu, Zhang-Hua, Kai-Bin Qiu, and Hongyuan Zha. "Generalize a small pre-trained model to arbitrarily large tsp instances." *Proceedings of the AAAI conference on artificial intelligence*. Vol. 35. No. 8. 2021.

7 モンテカルロ木探索は、木探索アルゴリズムの一種であり、シミュレーションを繰り返し、その平均的な結果が良い候補手を優先的に探索するアルゴリズムである。(今川 孝久, 「モンテカルロ木探索の改善に関する研究」, 2017 年度研究会推薦博士論文, 一般社団法人情報処理学会, <https://www.ipsj.or.jp/magazine/hakase/2017/GI02.html> (アクセス 2025 年 7 月 17 日))

8 Luo, Fu, et al. "Neural combinatorial optimization with heavy decoder: Toward large scale generalization." *Advances in Neural Information Processing Systems* 36 (2023): 8845-8864.

適切に扱うことが重要である。

質疑

吉脇：確率制御と数理最適化の融合について簡単に説明してもらいたい。

高野：自分はシェアサイクルの再配置問題を研究している。シェアサイクルは放っておくと一部の駅に自転車がたまってしまうので、うまく移動して分散しなければならない。その移動の最適化問題を解くものである。論文⁹では、1日の移動スケジュールを事前に決めてしまう静的な最適化と、状況に応じて動的に移動させるモデル予測制御と、提案手法である線形制御方策の比較を行った。事前に決めてしまう静的な最適化は性能が悪く、モデル予測制御や線形制御方策のほうが性能はいい。モデル予測制御は、リアルタイムで何度も最適化問題を解くので計算時間はかかってしまうが、今回提案した線形制御方策はオンラインでもかなり短い時間で計算できて、モデル予測制御に勝る制御はできないが、かなり近い制御ができることが分かった。最適化に制御の方法を利用することは非常に有効である。

吉脇：提案手法は、予測あるいは確率的な制御を最適化に入れるということか。

高野：最適化問題に対して、最適解を出すのではなく、最適解を出す関数を学習するという手法である。状況に応じてその関数に値を入れれば最適解が予測できるので、オンラインで実行する。オフラインだと計算時間がかかるが、オンラインであれば関数への入力だけで解が出るので計算が速い、という手法になる。制御方策を作っていく方法なので、強化学習に近い。

吉脇：説明の中で、「混合整数最適化のオンライン問題は実用化に程遠い」というコメントがあったと思うが、実用化に向けて決定的にやらないといけないことがあるとしたら、何だろうか。

高野：いきなり高性能化するのはかなり難しいので、いろいろな問題を解いて知見を積み重ねていって、最終的には一般的なフレームワークで扱えるようにしていくのが重要ではないか。

9 Yoshida, Yasuhiro, and Yuichi Takano. "Linear control policies for online vehicle relocation in shared mobility systems." *Expert Systems with Applications* 210 (2022): 118417.

2.2 ハイブリッド最適化2：人工知能と最適化理論

鈴木 大慈（東京大学/理化学研究所）

機械学習の最適化の問題点や課題について述べる。機械学習の最適化にはさまざまな範囲があるが、ここでは特にLLM（Large Language Models）や拡散モデルに代表される深層・基盤モデルの学習における難しさについて取り上げたい。大スケールで、損失が非凸で、訓練損失ではなく汎化誤差を最小化しなければならない、といった状況があるので、通常最適化の常識が成り立たないことが多い。

大スケール

まず、大スケールという点に関連して、LLMの学習環境について述べる。少し古いモデルであるGPT-3の場合、パラメータ数が1750億個に上る。学習のコストは、おおよそ5億円かかっており、1台のGPU（Graphics Processing Unit）で学習しようとする、約355年かかるため、大量のGPUを並列動作させて学習することが基本戦略になる。モデルのサイズはどんどん大きくなっており、GPT-4ではパラメータ数が1兆個を超えていると言われている。このようなスケールの学習で最適化を行う必要がある。学習にはGPUを多数使い、クラスターを組んで並列計算を行うことになる。例えば、NVIDIAのクラスターは数千台のGPUを使用している。また、一つのGPUに一つのモデルのパラメータが全て収まるわけではないため、モデルを分割して最適化する、いわゆるモデル並列の最適化も必要である。深層学習特有の並列計算のテクニックが求められる。さらに、データを並列化して学習させる連合学習も必要となる。

並列計算では、GPUが壊れてノードが停止した場合でも学習が継続できるインフラが求められる。連合学習の観点からも、一つのクラスターで行うのではなく、世界中の大陸に計算クラスターを配置し、各クラスターが2000台ほどのGPUを持ち、データ通信しながら並列計算で学習させる研究が進められている。いかに計算資源をスケールさせるかが非常に重要であり、インフラ整備が注目されている。例えば、1枚450万円するNVIDIAのGPUであるH100を、Anthropicというクラウドで有名な会社は数万枚使用して学習している。また、他のスタートアップも1万枚または2万枚単位でGPUを調達し、GPUを取り合う状況が見られる。このようなスケールで学習を行うことを考え、学習手法と最適化手法を検討する必要がある。

われわれは連合学習の最適化手法を提案している。詳細は省くが、通信やアップデートの回数が最も少ない手法を提案している。これは理論的に最適な手法であるが、深層学習に適用するにはギャップがある。上記のスケールで最適化を行うと、単純にスケールが大きだけでなく、深層学習特有の問題が生じる。それは非凸な損失であったり、訓練損失を最小化するのではなく、汎化誤差を最小化することが目的であったりするため、通常最適化の常識が成り立たないことがある。このため、専門家から「なぜこんな手法を使っているのか」と問われることがある。機械学習の研究者が何も分かっていないと言われがちだが、それには理由がある。

勾配法と非凸性

機械学習は基本的にn個の訓練データに対する損失を最小化するものであり、パラメータを更新する際には通常勾配法を使用する。一番ナイーブな方法は全勾配、つまり毎回全データを使って勾配を計算してアップデートする方法である。これはいわゆる正当な勾配法であるが、データ数が1億個あるような場合、毎回数億回の計算コストを負担することは現実的ではないため、実際は一部のデータを使用して更新する確率的勾配法を用いる。

例えば、LLMの学習では、全データを端から順に処理することはせいぜい6回、すなわち6エポック程度であり、全勾配を毎回計算することは非現実的である。確率的勾配法では、毎回の更新に使われる勾配が不正確になるため、更新の回数が増える。しかし、各更新に必要な計算量が少なく済むため、トレードオフが

生じ、トータルの計算量で見ると得をすることが理論的に示されている。強凸の場合、サンプルサイズの \sqrt{n} 倍だけ速度が上がる。例えば n が 10^6 であれば、1000倍高速化できることが言える。大量データで学習する場合、確率的最適化なしでは非現実的な時間がかかるため、確率的最適化を用いないことはあり得ない。

さらに、深層学習特有の問題として、損失の多くは非凸であるということがある。そのため、局所最適解が多くあり、その中にも良い局所最適解と悪い局所最適解がある。悪い局所最適解はシャープミニマムと呼ばれ、局所最適解の周りの傾きが大きく、尖った形になっている。シャープミニマムな局所最適解では、データが少し揺れただけで損失が急激に上がるためロバストではない。すなわち、汎化誤差が悪い状況になる。

対照的に、フラットな形をした局所最適解であれば、データが揺れても損失があまり変わらないため、汎化誤差が良いとされている。フラットな局所最適解に到達するには確率的勾配降下法が有利であることが知られている。確率的勾配は真の全勾配にノイズを加えたものであり、そのノイズによってシャープミニマムから抜け出しフラットミニマムに到達するからである。確率的最適化法は、ぎざぎざした目的関数を平滑化して最適化する方法であるとみなせる。それにより、フラットミニマムな解にたどり着くことができる。

ステップサイズ¹⁰

また、最適化においてはステップサイズの選択が重要である。最適化時にはステップサイズを選ばなければならないが、基本的にはステップサイズはある程度小さく設定する。滑らかさのパラメータ L に対して $2/L$ ほどの大きさに設定する。ステップサイズを小さく取れば、より正確な最適化が可能であるが、繰り返し(iteration)の数は増える。

しかし、深層学習の場合、ステップサイズを小さくするだけでは十分ではなく、ある程度大きなステップサイズを取る必要がある。実験的にも、ステップサイズが小さいと最適化手法としては良好だが、汎化誤差を見るとステップサイズを大きく取ったほうが好ましい場合がある。これは、小さなステップサイズを使うとシャープミニマムにはまりやすいが、大きなステップサイズを使うとシャープミニマムから抜け出しやすいためである。このことを踏まえて最適化の問題を考える必要がある。

他にも、ステップサイズを小さく取って収束する領域と、大きく取って発散する領域の間にステップサイズを設定する「Edge of Stability」という概念もある。ステップサイズを小さく取ると一番近い局所最適解に収束するが、あえて収束させず振動させることで領域を探索し、フラットな解に収束させるほうが良いという考え方である。

これは特徴学習とも関係があり、われわれの研究でも明らかになっている。ニューラルネットワークは初期化時にパラメータの大きさを大きく設定し、小さなアップデートを行うことで訓練誤差を小さくすることが理論的に知られている。一方で、初期値を小さく設定し大きくアップデートすることで、重要な特徴だけを学習し汎化性能が良くなることが示されている¹¹。小さなステップサイズで学習するだけでは汎化誤差が改善されず精度が上がらないが、最初に大きなステップサイズで学習し、最後に局所的に小さなステップサイズで収束させることで予測誤差が良好にスケールすることが理論的にも示されている。

まとめ

これらの要素を考慮しながら最適化手法を設計する必要があり、数値最適化の常識とは異なる手法が必要となる。深層学習特有の問題を考慮し最適化手法を組み立てる必要があるが、それは非常に難しい過程であ

10 ステップサイズ (=学習率) は、機械学習モデルが最適化アルゴリズムの各ステップでパラメーターをどの程度調整するかを管理するハイパーパラメーターのことである。(IBM,「機械学習の学習率とは」, <https://www.ibm.com/jp-ja/think/topics/learning-rate> (アクセス2025年7月17日))

11 Ba, Jimmy, et al. "High-dimensional asymptotics of feature learning: How one gradient step improves the representation." *Advances in Neural Information Processing Systems* 35 (2022): 37932-37946.

る。したがって、一見すると最適化のスケジューリングやスキームが数理最適化の常識からそれているように見えることもあるが、汎化誤差を最小化する観点からすると、必ずしも矛盾していないことが多い。

今後も、学習理論の分野と数理最適化の理論が融合しながら研究を進めていく必要があるが、まだその進展は十分ではなく、今後の大いなる発展が望まれる。

質疑

吉脇：まとめのスライドに「最適化法による陰的バイアスも考慮に入れる」とあるが、どういう意味か。

鈴木：先ほど、大きいステップサイズを使うと、よりフラットなミニマムに行くという話をしたが、それは最適化の方法によって収束する先が変わるということを言っている。それが意味、機械学習でいう正則化のような形になる。どう最適化を使うかが学習結果に影響することが、統計的な正則化になる、ということを陰的バイアスと言っている。

吉脇：素直に最適化するのではなく、現象に合わせた最適化手法を選ばなければならないということか。

鈴木：そのとおり。

吉脇：最適化との融合ということで、最適化の研究者に期待することはあるか。例えば、こういうことを検討してほしいといった点。

鈴木：例えば、先ほどから出てきている、ステップサイズを大きくした時の収束解析などが挙げられる。これが結構難しい問題である。既存の王道のテクニックではうまく対応できない場合が多い。新しいテクニックが必要であり、そのために融合して研究を進めることが期待される。

2.3 ハイブリッド最適化2：ロバスト1 + 大規模

武田 朗子（東京大学/理化学研究所）

連続最適化研究の進展

大規模をキーワードとして、私自身が行ってきた連続最適化研究の進展について話す。

私が博士号を取ったのが2001年である。図2-3-1に示すように、1970年代～80年代はすごくシンプルな勾配降下法（Gradient Descent）、1985年代～90年代の終わり頃はDC（Difference of Convex functions）アルゴリズム等が研究されていて、その後徐々に内点法や錐計画のように問題も難しくなり、手法もだんだん凝ったものになってきたのが2001年頃であった。この頃は、難しい制御の問題を解くという目的意識を持った研究がなされていたと思う。

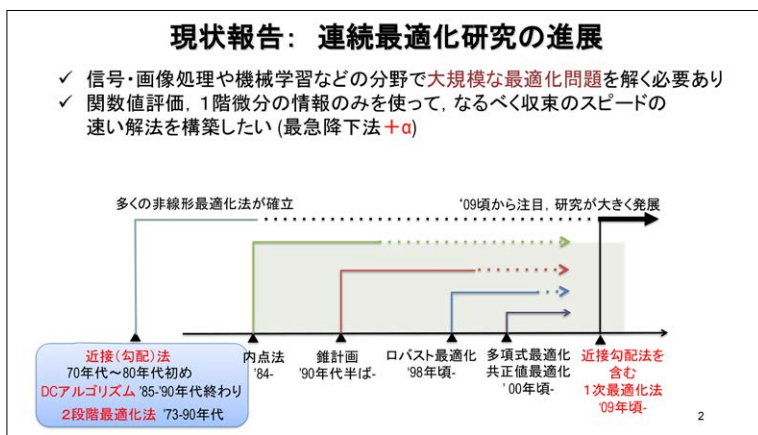


図2-3-1 現状報告：連続最適化研究の進展

連続最適化と機械学習

私自身、初めてICML（International Conference on Machine Learning）という機械学習の国際会議に採択されて発表したのが2008年頃で、その頃から機械学習分野にも乗り込んで、問題意識として研究の種を見つけながら、機械学習分野や最適化分野で論文を書いてきた。私は、2009年頃から、すごくシンプルなアルゴリズム（近接勾配法、1次最適化法、勾配の情報のみを使った方法等）が機械学習で使われていると感じていた。その頃から、だんだんその影響が最適化分野にも来て、（昔に確立された手法だが）新しいタイプのアルゴリズムの評価方法が生まれたりしていた。さまざまなワーストケースでの反復回数の評価の方法等が、さまざまな昔のアルゴリズムに適用されて研究され始めていた頃であった。

今、深層学習から生じる最適化問題について、簡単にここでまとめておく。図2-3-2に示すように、シンプルな線形関数や、それを切断したようなものが合成された関数（切断冪関数）が入れ子（多層構造）になっているので、一個一個は簡単な関数でも、まとめてみるとものすごく複雑な非線形性の強い最適化問題を扱うことになる。ここで、 θ と書いてあるのが、われわれの言葉でいうところの意思決定変数になる。鈴木先生がおっしゃったように、 m （サンプルサイズ）が非常に大きい。 θ も、機械学習の層が深くなれば、非常に大きいサイズになるので、そのような中で大規模問題を解きたいと私たちは考えている。

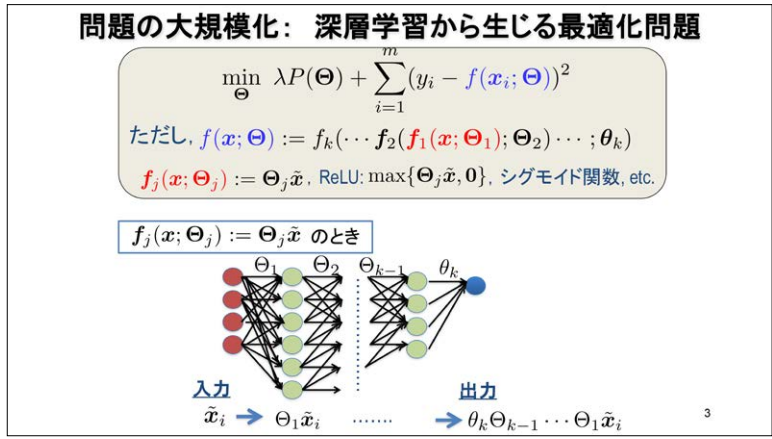


図 2-3-2 問題の大規模化： 深層学習から生じる最適化問題

鈴木先生は、確率勾配法ということ、 m (サンプルサイズ) を少なくすることを確率的に選ぶということをおっしゃっていたが、われわれのグループが最近やっているのは、 θ という大規模変数を小さくする研究をやっている。図 2-3-3 に示すように、その場合の解き方としてシンプルなのは、「合成関数の微分は、それぞれの関数の微分の積である」という合成関数の微分公式を使って求めて、それを毎反復使って点を更新していく方法である。ただし、われわれの理論的な興味としては、例えば、これが $\epsilon (\geq \|F(\theta)\|)$ の最適性条件と呼ばれる、関数 F を θ で微分してゼロに近い解が出るまでどれぐらい反復回数が必要になるか、例えば、 ϵ のマイナス 2 乗のオーダー $O(\epsilon^{-2})$ のレートで解が ϵ の最適な停留点で求まるといった理論保証のやり方をしている。

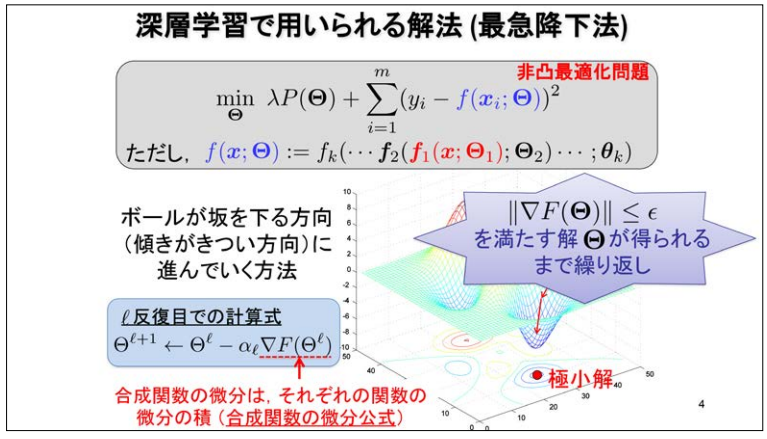


図 2-3-3 深層学習で用いられる解法 (最急降下法)

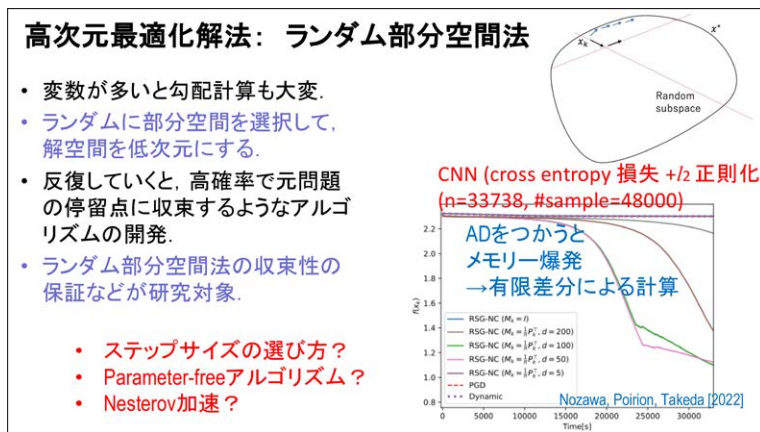


図 2-3-4 高次元最適化解法：ランダム部分空間法

変数の数が多いと勾配計算も大変なので、図2-3-4に示すように、われわれのグループでは、高次元最適化解法として、ランダムに部分空間を選択して、その部分空間に解空間を射影することで、解空間を低次元化する研究を最近行っている¹²。例えば、図に示すように、二次元空間の中に変数を二次元で更新していくのではなく、1変数として線に限定して線上を動かして、また違う線をランダムに部分空間を選んで動かしていくという、低次元で点列を更新していくことをやると、計算する勾配の長さが小さく済むので、計算量も削減できることになる。畳み込みニューラルネットワーク（Convolutional Neural Network：CNN）の問題において、n=33738程度の変数を使うと、普通のパソコンレベルではメモリ爆発を起こしてしまい、フルディメンジョンで有限差分による計算を行うと全然動かなくなってしまうが、ランダム射影で小さい5次元や50次元等の中に射影して計算するときちんと動くような解法を理論的に提案している。そのような低次元で動かしながらも、反復していくと高確率で元の問題の欲しい解（停留点）に収束するようなアルゴリズムを開発し、ランダム部分空間法の収束性の保証を与えたいとわれわれは考えている。

今、基本的なところはさまざまな研究が進んでいる段階であるが、まだまだやれることはあると思っている。先ほどの鈴木先生に、最適化の研究者に期待することとして、ステップサイズ（ステップ幅）のことを挙げていただいたが、そのようなこともやりたいと思っている。なるべくインプットとして与えるパラメータが少なければ、ユーザーにとってはありがたい。数多くのトライ・アンド・エラーをしてパラメータを選択することが必要なくなるので、このようなハイパーパラメータのチューニングが必要はないような、アルゴリズムの中で自動的に予想・推測するアルゴリズムを考えて研究を行っている。

融合に関するこれからの動き

機械学習と最適化との融合に関する動きとしては、より大きい問題や、より難しい問題を目指していくのではないかと（図2-3-5）。現在、LLMの影響で問題の規模がすごく大きくなり、GPUに特化した演算を考えたアルゴリズム等の、藤澤先生が得意とするHPC（High Performance Computing）分野のほうに行くのではないかと考えている。ただ、最適化の私にとってHPC分野はあまり強みを持っていないので、より難しい問題の方向に行くのがいいと考えているところである。より難しい問題としては、電力や制御の分野は結構難しい問題を解くために機械学習の需要があるので、そのような分野への寄与もあると思っている。

12 Nozawa, Ryota, Pierre-Louis Poirion, and Akiko Takeda. "Randomized subspace gradient method for constrained optimization." *arXiv preprint arXiv:2307.03335* (2023).

MOpt と ML との融合: これからの動き

- より大きく, より難しい問題へ?
 - 「より大きく」を目指しすぎると, 高性能計算やGPU上での演算を想定したアルゴリズムの開発に行き着く? 最適化分野よりは hyperperformance computing?
 - 「より難しく」はいろいろ方向性ありそう?
- ユーザーフレンドリーなソルバーの開発?
 - 問題にあったアルゴリズムの選択
 - パラメータ設定の自動化
- より難しい問題, より精度の高い解に対する需要は, 機械学習分野よりも電力や制御分野の方が高い? 6

図 2-3-5 数理最適化 (MOpt) と機械学習 (ML) の融合に関する今後の動向

また、ユーザーフレンドリーなソルバーの開発も必要であり、例えば、問題に合ったアルゴリズムの選択を自動的にやってもらえたら、ユーザーにとってはうれしいと思う。また、ハイパーパラメータとして、先ほどのステップサイズをどのように選択するかに関しては、理論的には問題となる関数のリブシツツ定数を使う等のさまざまな方法が実際にあるが、そのような計算は非常に難しいのが現状である。ハイパーパラメータの設定は、実際にはいろいろ難しくトライ・アンド・エラーの要素が大きいので、それをうまくアルゴリズムの中で自動化して予測して使えたらいいと個人的には思っている。

より難しい問題設定

次に、自分の考える、より難しい問題について説明する。図 2-3-6 に示すように、より難しい問題とは、係数が不確実で一つに決められない時の定式化と解法としての (ロバスト最適化を含む) min-max 最適化問題や、制約集合が少し複雑な時の 2 レベル最適化問題であり、これらは割と機械学習の分野で使われ出している。もっと目的関数が複数であるような、あるいは徐々に変化するようなさまざまなタイプの最適化問題があるので、そのような機械学習の分野の需要をつかんで、いち早くこういうような問題設定でやってみせるということができたらいいと思っている。

より難しい問題設定の例

最適化問題: $\min_{x \in S} f(x)$

- 係数が不確実で一つに決められない時, 定式化と解法は?
 - ロバスト最適化を含む min-max 最適化問題
- 制約集合が少し複雑だったら?
 - 2 レベル最適化
- 目的関数が複数なら? → 多目的最適化
- 目的関数が時間と共に徐々に変化する, など.

$$f(x) = \max_{y \in U} g(x, y)$$

$$f(x) := \tilde{f}(x, y(x))$$

$$y(x) \in \arg \min_{y \in U} g(x, y)$$

図 2-3-6 より難しい問題設定の例

min-max最適化問題が機械学習で使われた有名は例としては、Googleの研究チームによる「機械学習に対する敵対的サンプル (Adversarial Example)」と呼ばれる2014年に公表された研究¹³があり、最初は機械学習モデルでパンダと予測されたものが、パンダの画像データに (人間の目には分からない) 敵対的摂動 (Adversarial Perturbation) としてのノイズを与えると、テナガザルと誤分類してしまうことが報告された。このようなデータのノイズが目的関数値を増大させる方向に働くので少しデータが振れても解が変わらないといったmin-max最適化問題が機械学習に需要があり、非常に研究が進んでいるのが現状である。また、min-max最適化よりも一般的な枠組みである2レベル最適化の概念は、今の問題設定を含んだ、もう少し広い枠組みで昔から最適化分野では研究されているが、今では、機械学習でも盛んに使われ始めている。われわれは、いち早く、このような問題設定を機械学習に持っていき、うまく解けることを示したいと考え、実際、機械学習の分野で生まれた新しいアルゴリズムの探求に取り組んでいる。

図2-3-7に示すように、われわれは、2レベル最適化問題に対する既存解法¹⁴を多レベル最適化問題に対して拡張することで、3レベルという (古くて) 新しい問題に対する新たな漸近的収束性を持つ解法を提案した¹⁵。次にどのような最適化問題が注目を集めるのかを考えているところである。

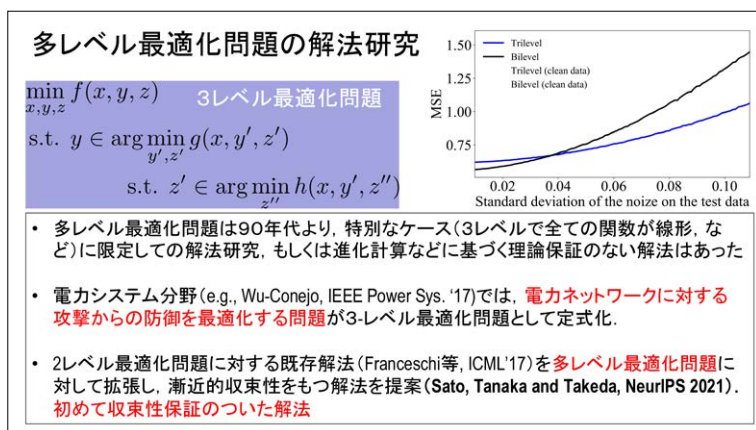


図2-3-7 多レベル最適化問題の解法研究

まとめ

図2-3-8に、まとめのスライドを示す。要するに、ロバスト最適化をはじめとするmin-max最適化問題の解き方がいろいろと開発されており、min-max最適化よりも一般的な枠組みである2レベル最適化、そして多レベル最適化まで進展している。機械学習で注目された最適化問題や最適化手法の研究に取り組み始めるとスピード競争で大変であるので、うまく需要をつかんで、いち早く最適化研究ができると良い。次は、どのようなタイプの最適化問題が注目を集めるか、この需要をうまくつかんで、いち早く最適化研究を行い、研究を進展させたい。

13 Goodfellow, Ian J., Jonathon Shlens, and Christian Szegedy. "Explaining and harnessing adversarial examples." *arXiv preprint arXiv:1412.6572* (2014).

14 Franceschi, Luca, et al. "Forward and reverse gradient-based hyperparameter optimization." *International conference on machine learning*. PMLR, 2017.

15 Sato, Ryo, Mirai Tanaka, and Akiko Takeda. "A gradient method for multilevel optimization." *Advances in Neural Information Processing Systems* 34 (2021): 7522-7533.

研究の進展

- ロバスト最適化をはじめとするmin-max最適化問題の解き方がいろいろと開発されている。
- Min-maxよりも一般的な枠組である2レベル最適化, そして多レベル最適化まで進展!
- 機械学習で注目された最適化問題, 最適化手法の研究に取り組み始めるとスピード競争で大変. うまく需要を掴んで, いち早く最適化研究ができるとうい。
- 次はどんな最適化問題が注目を集めるか・・・! ?

12

図 2-3-8 まとめ (研究の進展)

質疑

吉脇 : min-maxの話題の際に、より問題が大きくなり高次元化するものと、より難しくなる方向の2種類を示していたと思う。一方で、例えば、高性能計算・GPU計算が必要な問題、もしくは、先ほど鈴木先生がおっしゃったような連合学習に近いような問題になった時に、最適化研究としてもやれることはあるのか？

武田 : もちろんやれることはあると思うが、やはり、例えば、藤澤先生のように、HPCにすごく詳しい研究者が必要になってくる。自分自身は、そこはあまり得意とはしておらず、最適化分野にも、そのようなコミュニティがあるものの、(藤澤先生はHPC分野のほうにも数多く出入りされているように) HPC分野の方で機運が高まっているのではないかと思っている。

2.4 ハイブリッド最適化3：不確実な情報を含む多段階意思決定問題に対するロバスト性向上 近似動的計画法と強化学習を中心として

小林 和博（青山学院大学）

不確実な情報を含む多段階意思決定問題に対するロバスト性向上について、近似動的計画法と強化学習を中心として研究課題に関する話題提供をする。

生産計画と数理最適化

数理最適化問題を用いる場面では、同じ形の問題を異なるデータで繰り返し解くケースがある。例えば、図2-4-1に示すように、その週の生産計画を毎週金曜日に作成するというような、期0における S_0 （需要予測、在庫量）を見て、生産量 x_0 を決定するケースである。この時点では、先の期1の確率的な情報 W_1 はまだ実現しておらず、確率的な情報が W_1 で実現して、その次の期の生産量 x_1 を決定するような状況を想定している。

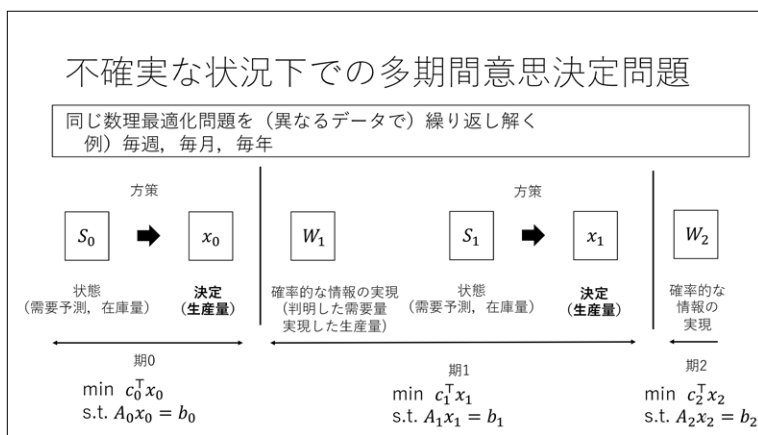


図2-4-1 不確実な状況下における多期間意思決定問題（1）

期 t におけるシステムの状態を S_t 、期 t での意思決定（つまり生産量）を x_t 、期 t から期 $t+1$ への推移の過程で明らかになった情報を W_t として、 $S_0, x_0, W_1, S_1, x_1, W_2, S_2, x_2, W_3, \dots$ と表す（図2-4-2）。こうすると、 x_0 という決定をした時にコスト $C(S_0, x_0)$ が発生し、次の期 $t (=1)$ にコスト $C(S_1, x_1)$ がかかるというふうに、期ごとにコストがかかってくる。多段階の意思決定問題の場合は、目的が各期 t のコスト $C(S_t, x_t)$ の最小化ではなくて、総コスト $\sum_{t=0}^T C(S_t, x_t)$ の最小化と考えるほうが妥当である。

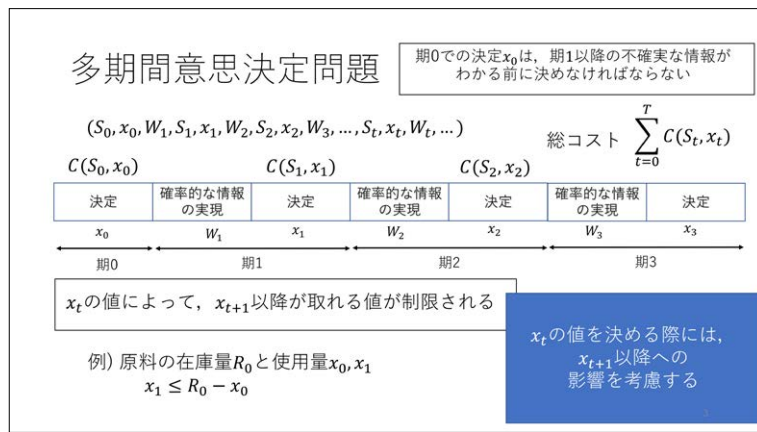


図2-4-2 不確実な状況下における多期間意思決定問題 (2)

ここで注意すべきは、生産量 x_t の値によって、それ以降の取れる値 x_{t+1} が制限されるということである。例えば、図2-4-2に示すように、原料の在庫量が R_0 である時に、生産量を x_0 と決める（意思決定する）と、次の期の生産量 x_1 は $R_0 - x_0$ 以下にしなければならない状況 ($x_1 \leq R_0 - x_0$)になる。つまり、 x_t の値を決める際には、 x_{t+1} 以降への影響を考慮しなければならない。ここで問題となるのは、決定空間の大きさである（図2-4-3）。コスト C を決める時に最適化問題を解くわけであるが、通常、数理最適化問題では非常に取り得る値の数が大きく、 x_t は多次元ベクトルである。例えば、 x_t が10次元ベクトルだとすると、 $x_t = (x_{t1}, x_{t2}, x_{t3}, \dots, x_{t10})$ の各要素が10個の整数値を取り得るので、ベクトル x_t の取り得る値の数は 10^{10} 通りもあることになる。このような場合、列挙による探索や価値の評価などに対して通常の強化学習の手法をそのまま適用するのが難しいので、工夫する必要がある。




図2-4-3 決定空間の大きさ (課題1)

期ごとの最小化と総コストの最小化の違いをイメージ的に表現する。期ごとの最小化では時々すごく良いコスト（小さいコスト）の結果が出るが、その期でリソースを使い過ぎてしまって、次の期のコストがあまり小さくならないケースが起り得る。一方、全体の和の最小化を考えると、あまり極端なケースが出なくなり、ロバストな計画が作れると期待できる。ただし、全体の和を最小化するには、実際は将来の情報が不確実なので、 S_t という状態は確率的なものになるので、コストの和ではなくて、コストの和の期待値を最小化しなければならない。したがって、生産量 x_t の値を求めるのではなく、 x_t を決める方策を決めなければならない。こ

2 研究開発課題に関する話題提供

ここで、方策とは、将来、 S_t という状態が確定した時に実行する x_t を決める（つまり、実現した状態 S_t に対して x_t を決める）ルールであると考えてもらえば良い。つまり、決定 x_t は方策 π により定まるので、 $X^\pi(S_t)$ と表記する。例えば、金融商品売買におけるbuy-low & sell-high（安く買って高く売る）戦略として、ある銘柄の株を5カ月後に売るか買うかを決めたいとする。5カ月後の価格(p_t)は不確実で決まってないので、売るか買うかのどちらかに決めることはできないが、 $p_t < \theta_{low}$ であれば買う、 $p_t > \theta_{high}$ であれば売るというルールを決めておけば、5カ月後にその株の価格が確定した時点で売るか買うかが自動的に決まる。これが、方策と呼ばれるものである。

最適化問題として扱うためには

しかしながら、最適化問題を扱うためには状態空間のサイズ（状態 S_t の取り得る値の数）や、決定空間のサイズ（決定 $X^\pi(S_t)$ の取り得る値の数）が大きすぎることから難しくなる。しかも、期待値 $\mathbb{E}\{\sum_{t=0}^T C(S_t, X^\pi(S_t)) | S_0\}$ を最小化する方策 π を求める問題を取り扱わなければいけないので、捉えどころがない。さらに、実際の問題で、どのように数式で表現するかも問題に依存するので、なかなか簡単にかかない。したがって、方策は無数にあり得るので、近似的に解くことしかできない。さまざまな近似的解法があるが、Warren B. Powell（Princeton University）によれば、四つの方法に分類できる（図2-4-4）。その最初の方法であるPolicies based on value function approximationsが、近似動的計画（Approximate Dynamic Programming）、あるいはニューロDP（Neuro-Dynamic Programming）や強化学習と呼ばれる類いの手法であり、この方法について少し説明をする。

2 研究開発課題提供
研究開発課題についての

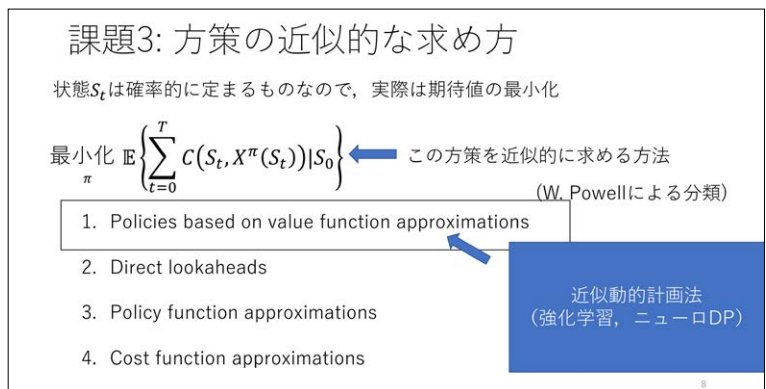


図2-4-4 方策の近似的な求め方（課題3）

期待値 $\mathbb{E}\{\sum_{t=0}^T C(S_t, X^\pi(S_t)) | S_0\}$ を最小化することは捉えどころがないので、 S_t の価値を表す価値関数 V_t を導入して（目的関数の価値関数による表現として）以下のように表す（図2-4-5）。

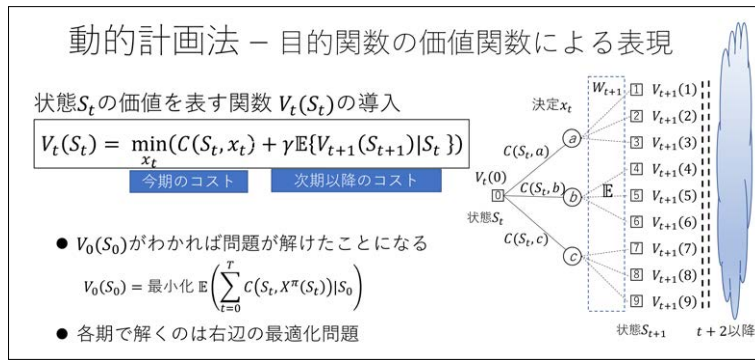


図2-4-5 動的計画法：目的関数の価値関数による表現

$$V_t(S_t) = \min_{x_t} (C(S_t, x_t) + \gamma \mathbb{E}\{V_{t+1}(S_{t+1}) | S_t\})$$

ここで、上式の右辺にある $C(S_t, x_t)$ が今期のコストで、期待値 \mathbb{E} が次期以降のコストである。つまり、今期のコストと次期以降のコストを両方考えて、今期のコストを決める問題である。これが元の期待値 $\mathbb{E}\{\sum_{t=0}^T C(S_t, X^{\pi}(S_t)) | S_0\}$ の最小化と、どのように関係しているかを以下に説明する。この $V_t(S_t)$ について $V_0(S_0)$ が分かれば、それが解きたかった和（総コスト）の期待値の最小化になっているので、この元の期待値の最小化をする代わりに（再帰的な構造をしている）価値関数 V_t を求めれば良い。これを各期で解くのは右辺の最適化問題であり、 $V_t(S_t)$ は $V_{t+1}(S_{t+1})$ で決まる（図2-4-6）。

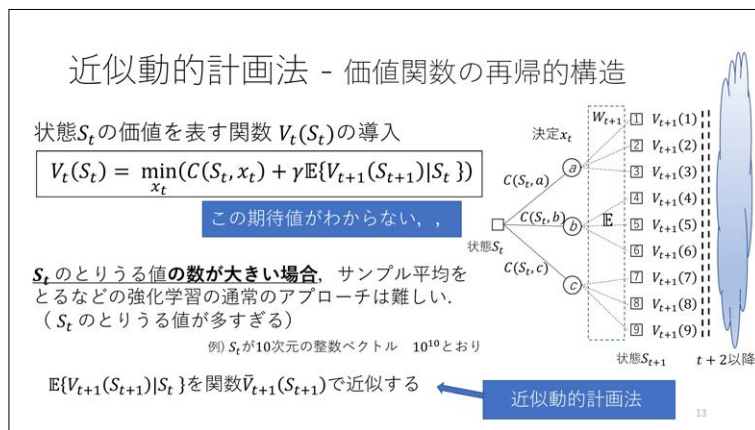


図2-4-6 近似動的計画法：価値関数の再帰的構造

図2-4-6に示した $V_t(S_t)$ の第2項が分かれば、それを解けばいいが、期待値 \mathbb{E} が分からないので、強化学習の手法を使って、期待値 \mathbb{E} の評価値を求めるためにサンプル平均を取るといった単純な方法が考えられる。つまり、 S_t の取り得る値の数が大きくなければ、サンプル平均を取るなど、通常強化学習の手法を適用して、期待値 $\mathbb{E}\{V_{t+1}(S_{t+1}) | S_t\}$ の評価値 $\bar{V}_{t+1}(S_{t+1})$ を求めれば良い。しかしながら、この強化学習のスタンダードな方法は、最適化では実行するのが難しい。なぜならば、 S_t の取り得る値の数が大きい場合、サンプル平均を取るなどの強化学習の通常のアプローチは難しいからである。そのために、値を正確に評価することが難しくなるので、図2-4-7に示すように、期待値 $\mathbb{E}\{V_{t+1}(S_{t+1}) | S_t\}$ を近似価値関数 $\bar{V}_{t+1}(S_{t+1})$ で近似することを考え、各期では次式で表される最適化問題を解く。これが、近似動的計画法に採用されている手法である。

近似価値関数 $\bar{V}_{t+1}(S_{t+1})$ の望ましい形

各期では、次の最適化問題を解く

$$\min_{x_t} (C(S_t, x_t) + \gamma \bar{V}_{t+1}(S_{t+1}))$$

単期の最適化問題 $\min_{x_t} (C(S_t, x_t))$ が解けるなら、この問題も解けるようにしたい

例) 線形最適化問題, 整数最適化問題, 二次最適化問題

$C(S_t, x_t)$ が x_t の線形関数なら, $\bar{V}_{t+1}(S_{t+1})$ も x_t の線形関数として表す, など

図 2-4-7 近似価値関数 $\bar{V}_{t+1}(S_{t+1})$ の望ましい形

$$V_t(S_t) = \min_{x_t} (C(S_t, x_t) + \gamma \bar{V}_{t+1}(S_{t+1}))$$

ここで、単期の最適化問題として $C(S_t, x_t)$ の最小化ができるなら、上記の最適化問題も解けるようにしたい。そのために、 $C(S_t, x_t)$ が x_t の線形関数であるのならば、 $\bar{V}_{t+1}(S_{t+1})$ も x_t の線形関数として表したい。

例えば、図 2-4-8 に示すような、A、B、C、D という場所から物を運ぶ貨物割当問題を考える。期 t に場所 i から場所 j への貨物を割り当てる台数を $x_{t(i,j)}$ 、貨物を 1 台運ぶことによる利益を $c_{t(i,j)}$ とすると、A から C に 3 台運んで D から C に 2 台運ぶと、利益は $3c_{t(A,C)} + 2c_{t(D,C)}$ となる。各期の最適化なら、これを最適化すれば良いが、車が移動してしまうことで次期 $t + 1$ において車に偏りが出てしまうので、(次期以降に影響を及ぼす) 次期の偏りをきちんと一つ手前の評価に入れなければならない (図 2-4-9)。このような次期の偏りを何らかの関数で近似するために、例えば、次式のような近似価値関数を (大ざっぱに) 定義して導入する。

$$\bar{V}_{t+1}(S_{t+1}) = \sum_j \bar{v}_{t+1,j} R_{ij}^x$$

近似価値関数の例: 貨物割当問題

$x_{t(i,j)}$: 期 t に、場所 i から場所 j への貨物を割り当てる台数
 $c_{t(i,j)}$: 期 t に、場所 i から場所 j への貨物を一つ運ぶことによる利益

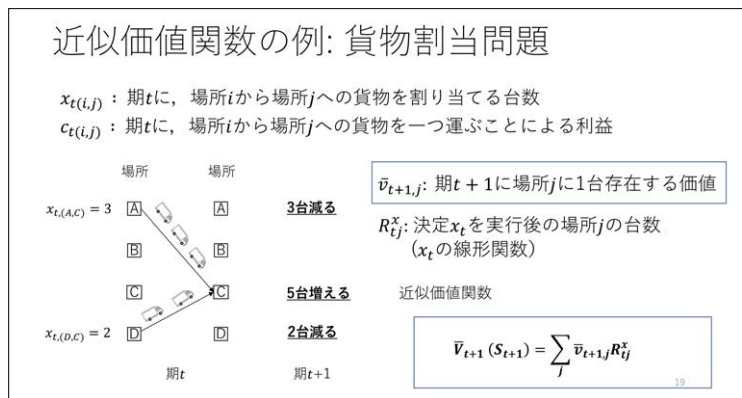
期ごとの最適化なら $C(S_t, x_t)$ を最大化すればよい

最大化 $C(S_t, x_t) = \sum_{(i,j)} x_{t(i,j)} c_{t(i,j)}$

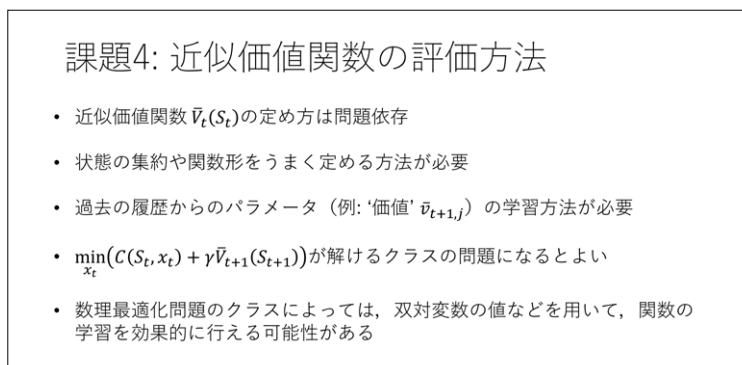
条件 $x_{t(i,j)} \in \mathcal{X}_t$

期 $t + 1$ 以降への影響 $\bar{V}_{t+1}(S_{t+1})$ を取り入れる

図 2-4-8 近似価値関数の例: 貨物割当問題 (1)



ここで、 R_{ij}^x は決定 x_t を実行後の場所 j の台数、 $\bar{v}_{t+1,j}$ は期 $t+1$ に場所 j に1台存在する価値（過去の履歴からの学習パラメータ）である。各期で解く問題は、単期での目的関数の最初の項に、（第2項として）次期以降の影響を加えたものであり、第2項も x_t の線形関数で書けるので、近似価値関数を加えても全体として線形関数で解けることになる。ただし、このようなアプローチにより、確かに扱いやすい形になるが、この近似価値関数が妥当なのかどうか、その評価方法には、図2-4-10に示すような課題があり、検討の余地があることは事実である。課題としては、近似の方法は問題に依存し、状態数が多過ぎるので集約とか関数をうまく定める必要があること、パラメータとして、価値の決め方を強化学習の手法等できちんと整える必要があること、そしてコスト関数に近似価値関数を加えたもの $(C(S_t, x_t) + \gamma \bar{V}_{t+1}(S_{t+1}))$ の最適化も解けるクラスの問題にしなければならないことなどが挙げられる。



近似動的計画法と対応案

近似動的計画法の適用例を図2-4-11に示す。ここ数年でも非常に多くの適用例があり、大体どの発表論文でも、不確実性のモデル、近似関数の定義とそのパラメータの学習方法、数値検証というようなことが述べられている。

2 研究開発課題に関する話題提供

近似動的計画法の適用例

<ul style="list-style-type: none"> ● トラックの運用 ● 病室運用 ● 生産計画 ● 配送計画 ● 血液管理 ● 石油ガス田掘削 ● 宅配便配達 ● 災害時トラックUAV運用 ● 電力管理 	<ul style="list-style-type: none"> ● 治療・投薬計画 ● 倉庫でのAGV運用 ● 映像内の物体追跡 ● 自立型無人潜水期の制御 ● 対話応答生成 ● オンデマンド輸送 その他 <ul style="list-style-type: none"> ・ 不確実性のモデル化 ・ 近似価値関数の定義とその学習 ・ 数値検証
---	---

モデルは問題依存ではあるが、関数のパラメータの学習手法などで知見を共有できる

22

図2-4-11 近似動的計画法の適用例

最後に、不確実な情報を含む多段階意思決定問題に対するロバスト性向上について、本発表で言及した（近似的計画法と強化学習を中心とした）四つの課題と、それらに対する対応案に関するまとめスライドを示す（図2-4-12）。

課題

1. 決定空間，状態空間の大きさへの対処
2. 不確実性のモデル化手法の開発
3. 方策の近似的な求め方
4. 近似価値関数の定義と学習

対応案

1. 状態の集約方法などの検討
2. 問題ごとの状態 S_t の過不足ない表現方法の検討
3. 精度の良い方策の定め方と，現場での運用とのバランス（実行可能な方策）
4. 履歴データを用いた近似価値関数の学習方法の確立（ロバスト性）

図2-4-12 四つの課題に対する対応案

質疑

吉脇：近似動的計画法の適用例に関して、不確実性のモデル化、近似価値関数の定義とその学習、数値検証について、何か共通項のようなものがあると思うが、いかがか。

小林：例えば、生産管理の問題であれば、コスト C の関数形（線形関数あるいは二次関数）について述べ、期待値のところは、確率的な現象をどの部分（例えば、在庫量や天気）を取り出して不確実なものとし、それらについて述べられている。われわれは、これらを不確実な現象とみなし、その関数形を定義して、近似価値関数の中に取り入れている。いずれも、生産管理に関する方程式の取り扱いは共通である。たしかに、モデルは問題依存であり、それぞれの適用例について、具体的にどう決めるかということが述べられているが、関数のパラメータの学習手法などで知見を共有できると考えている。

2.5 研究開発課題についての総合討議

2.5.1 話題提供:産業アプリケーションとアルゴリズム(最適化(量子)、機械学習(ML))

藤澤 克樹 (東京科学大学)

ここでは、産業応用の立場からバックキャストして、最適化の今後の取り組みについて述べる。

私は現在、国内外のさまざまな企業と共にサイバーフィジカルシステムの産業応用に取り組んでいる。必要な技術としては、今日のワークショップの話題である最適化や機械学習のみならず、データを取得する際のIoT技術、データを迅速に送る場合にはNTTのIOWN (Innovative Optical and Wireless Network) のような高速ネットワーク、クラウドでの高速計算、最近注目される生成AI (Generative Artificial Intelligence) や粒子計算も求められる。

プレスリリースした例として、ロート製薬とのスマート工場プロジェクトがある。当初は特定の工場でデータを取得して、スケジューリングや生産計画、モビリティ最適化を考え、アプリケーション化を目指していた。その中で、対象が良い意味で拡大し、一つの工場だけでなく、サプライチェーンの外側といったところも考慮するようになった。この場合、どの領域・規模の問題で、どの程度のデータが必要かによって、使える最適化や機械学習の手法が変わってくる。

現実の問題解決では、大規模な問題を長時間かけて解くわけにはいかず、仮定を置いて問題を限定しなければならない。しかし、実際のプラットフォームがないと、仮定が現実的でない可能性がある。スマート工場プロジェクトでは、いろいろなアプリケーションを定義していくに当たって、最適化や機械学習がどういう場面で使われる可能性があって、その場合にはどういうデータが使えて、どれぐらいの速さでどれぐらいのデータ量が取れて、それをどうモデル化して、何分で解けるかを総合的に評価する必要があるため、プラットフォームが重要であると考えます。

サイバーフィジカルシステム

サイバーフィジカルシステムとは、簡単に言えばデジタルツインの一種であり、フィジカル空間とサイバー空間がデジタルツインの関係にある。図2-5-1では、左下から順に、まず現場でデータ収集を行う。カメラを用いた映像や、IoTセンサー、Radio Frequency Identification (RFID) などを使って取ったデータを、無線通信でクラウドに送り、デジタルデータに変換し、右側では今回のワークショップの主眼である、AI・ディープラーニングや、最適化機械学習、統計的手法を使ったデータ解析による分析最適化などを行う。ここで大事なことは、単なる分析可視化だけでなく、今後現場がどのように変わってほしいかということを計画する・企画するという点である。その場合はAI的手法だけでなく、数理最適化の手法が必要になるというのが重要な点だと思う。それを現場にフィードバックして、それがまた次のデータになってという形でこのループを回していくことでプロジェクトが成立する。

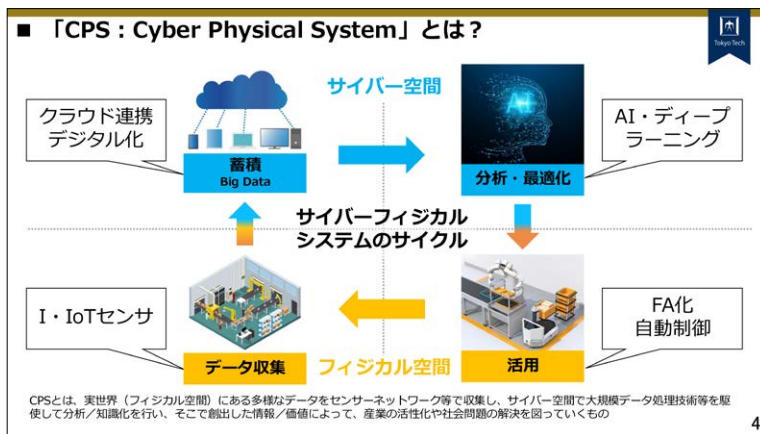


図 2-5-1 サイバーフィジカルシステム

ロート製薬に関して述べたが、ロート製薬は目薬やコスメティックなどの薬・化粧品系を扱う、小さい製品がラインとなって流れていく形の工場だが、逆の形もあって、ボーイング787の製造工場では、機体自体が大きいので、機体は動かさず、部品や工具、作業員やロボットが動いて生産を進める。こういった工場における、最適化や機械学習の利用ということで、二つのアプリケーションを定義している。一つ目はTool accountabilityで、工場内にある全てのツールや部品、そして、作業員や物が、いつどこにどういう状態で何個存在しているか、ということを実時間リアルタイムでトラッキングするものである。ディープラーニングやグラフ解析などが重要になってくる。二つ目はMobility optimizationである。これは、ある工程が開始される前に、その工程の作業に関して必要なツール、部品や、作業員や物、ロボットなどを必要な場所に送り届ける、移動の最適化である。これを繰り返すことで生産性を向上させる、ということをやっている。

モビリティ最適化

図2-5-2はモビリティ最適化の流れを示す。左側の画像は単なるサンプルで工場ではないが、工場であれば、現場でカメラやセンサーを使ってデジタルデータを取る。そして、ディープラーニングを使って、人や物の場所の検知や追跡を行う。

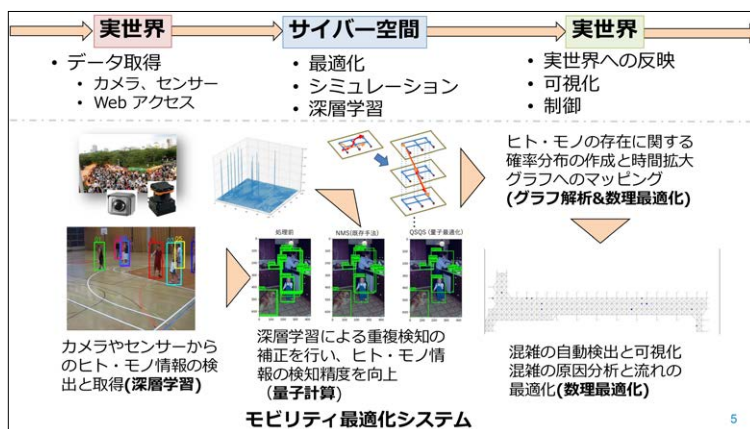


図 2-5-2 モビリティ最適化システム

その次に、量子計算で深層学習による重複検知の補正を行っている。量子計算については、最適化の理論

と応用の先進的な研究所の一つであるドイツのZIBと共同研究をやっている。鈴木先生からNVIDIAのH100で深層学習を行うという話があったが、H100のようなチップは価格が高いため、エッジで使うのは難しい。そこで、エッジでは安めのGPS (Global Positioning System) を使い、精度は低くてもいいからリアルタイムでデータを取って、最適化を使って補正をかけるということをやっている。量子計算と言っても、実用的なゲート方式の量子コンピューターを使うわけではなく、古典コンピューターでQuadratic Unconstrained Binary Optimization (QUBO) ソルバーを使って計算している。最新のQUBOソルバーを使うと、10~15 fps (frames per second)、つまり1秒間に10~15フレームぐらい処理できるので、実用的になってきている。

その後、今日のワークショップの本題の一つである次元削減もしくはデータ量削減を考えることになる。方法の一つとして、連続的に動くものを離散的なものに変換する際にグラフにマッピングしてデータ量を減らし、グラフ系のアルゴリズムをいろいろ使えるようにしている。このようにして、モビリティ最適化を実現しようとしている。

現実問題と最適化

現実問題に最適化を適用しようとする、複雑かつ大規模な問題に直面する。現場でその最適化問題を何分で解かなければならないのか、という問題がある。その時間内に答えが出てくることを保証する問題もある。ルールベースの近似解法とか、主に整数計画を使った厳密解法とか、深層強化学習系を混ぜてハイブリッドにやる方法などから、ある時間の中で一番速いものを選ぶようなシステムが世界中で提案されている。

厳密解法では整数計画を使うのだが、Gurobi OptimizerとかIBM ILOG CPLEX Optimizerといった有名な整数計画ソルバーも含め、整数計画ソルバーは、問題が既存の定式化モデルのどれに近いかを判断して前処理をやっている。その前処理の過程でカットを入れるのであれば、初めから定式化の段階でカットを入れることで、かなり速く解けるようにする、といった研究もZIBと共同研究している。結論として、最適化問題を数分で解く必要があると考えている。

2.5.2 総合討議

問題を解くためのかかる時間について

小林：私の発表で、今期と次期以降のコストを足したものが取り扱いやすい関数になってほしいと言ったのは、解く時間に制限があるからである。藤澤先生の、5分で解かなければいけない、というのは、近似の精度がどんなに良くても、近似に2時間かかっては意味がなく、5分以内に計算が終わるような範囲で、できるだけ精度の良い近似をしなければいけないということである。

もう一つは、現場の日々のレベルでオペレーションの方策を決めるというのであれば、現場の人がすぐ使える方策でなければいけないということである。例えば、先ほど言ったような、この価格よりも下だったら買う、上だったら売るぐらい簡明な方策でないと実行できないケースがあると思う。判断する時に、毎回、現場の各人が手元のコンピューターで整数計画問題を解いて答えを出さなければならぬようなことでは、実行ができないというケースがあると思う。最初にバランスを考えて、最適化問題をどの範囲で選ぶかとか、近似とか学習の手法をどの範囲で考えるのかとかを考えること、つまり最初に大枠で目安を付けないと、実用には遠くなってしまわないかと思っている。

高野：現場でどれぐらいの時間で解けばいいのかはよく分からないのだが、普通に最適化しようと思うと、何か問題が与えられたらその場でオンラインで最適化をするということになる。いい答えは出るのだが、計算効率はどう考えても悪い。機械学習で簡単に最適解が出てくれば一番いいし、そこまではできないとしても、機械学習で問題をいくらか解きやすくして高速化することはできるのではないか。時間をかけてオフラインで良い機械学習モデルを作って、オンラインの計算時間を短縮するという手法は有効なのではないか。これからさまざまな研究が進んでいくのではないかと思う。

鈴木：エッジコンピューティングは大変重要だと思っている。機械学習で言えば、推論側については、モデル圧縮とかクオンタイズーションとかを駆使して、小さくして現場で動くようにし、とにかく答え出すことが必要だと思う。末端ではそういった高速化が、まず必要だと思う。

さらにシステム全体の最適化として、どう機械学習を使えるかを考えると、現状はあまり試行ができないというか、工場の中で何かモビリティ動かして試行することができないので、機械学習に必要なデータを収集するのは難しいと思う。一方で、デジタルツインみたいな考え方をすると、シミュレーションができる環境であれば、強化学習ができると思うので、そのトレードオフというか、どれだけシミュレーター作るのに投資できるかによって、機械学習の使い方が変わってくるという印象を持った。

吉脇：武田先生の観点から見て、例えば複雑な問題、複雑な最適化をする時に、時間感覚的なところについて、例えば何分で解きたいとかっていう要望があった時に、数理最適化からできることは何か考えられるか。

武田：リアルタイムに問題を徐々に何度も解くといったことを、あまり経験したことがないのでずれた感想になるかもしれないが、次のようなことを思った。こういう研究は使える研究で良いけれども、時間をかければかけるほどクオリティーの高い解が出てくる、という状況をどうやって評価しながら折り合いを付けるのが気になった。

吉脇：折り合いを付けるという点について、藤澤先生の意見を伺いたい。

藤澤：折り合いの付け方としては主に二つの観点がある。一つはきちんと安全に操業できるか、ということ。高い性能は大事だが、皆さんも普段Gurobi Optimizerを使われていると思うので分かると思うが、たまに実行時間が大幅に延びて答えが出なくて、次の生産計画が止まったということでは済まない。高性能は大事だが、どうやって安全に実行するか、ということ。

もう一つの観点は、必ずしも高い性能だけが現場で求められるものではなく、生産性や安全性など、いろいろなKPI (Key Performance Indicators) があるので、そういったものをどうやって総

合的に満たすかということ。必ずしも数理情報技術だけで解決できるわけではないが、そういう中に研究者として入って行って、どうやれば一体的にKPIを達成できるようになるかということ、数理情報の立場から提案するということかと思う。その辺が落としどころかなと思う。

特に大事なのは最初の観点である。こんな最新の手法を使って本当にだいたいどうぶなのか、暴走したりしないのか、ちゃんと答えは出るのか、というように現場の人から非常に反対される。そういう懸念を払拭するのがまず第一かと思う。その後はさっき言ったとおり、総合的にこちらからも提案して、何ができるか決めて話し合っていくのではないかと思う。

武田：例えば、近似解を求めると、実行可能解ではない解が出てくるかもしれない。実際は、実行可能な解かどうかというチェックをするのか。

藤澤：そのとおりである。特に強化学習系といった機械学習系になると、必ずそういうチェックが必要である。普通はそういう解を初期解にして、実行可能な解が出るような厳密解や近似解にしていくということをするのではないか。

ロバスト性

吉脇：続いてロバスト性というか、現場では、何らかの不確実性を含むことが大量に起こり得ると思うのだが、そういう場合にどういう対処をしていくのか、例えば最適化や機械学習をどうやって組み入れていくのかというあたりについて、コメントをいただきたい。

藤澤：ロバスト性の対処は二つあると思っている。一つは、最適化のアルゴリズム自体にロバスト性を持たせる方法である。武田先生が言われた内容である。もう一つは、異常検知のようなことが重要になってくる。つまり、今起きている状況が、平常と比べてどれだけ異常あるいは変わっているかということ、別のアルゴリズムで検知するという方法である。最適化で計算してスケジュール作ってやっている時に、何か大きな事態が変わってきた時に、どのくらい変わっているのかを別のアルゴリズム、例えば異常検知とか状態評価とかで検出して、それに応じて最適化を再実行するような方法があると思う。

一つ目は最適化の中にロバスト性を考慮したモデルなりアルゴリズムを入れていく方法。二つ目は、最適化はそのままでもいいが、事態が変わった時にどの時点で最適化を再実行すべきかを、別のアルゴリズムを使って判定する方法。ハイブリッドもあると思うが、やっているのは大体この二つである。

吉脇：ロバスト最適化の行きつく先というか、研究の方向性のようなものを、武田先生に伺いたい。

武田：最近ではロバスト最適化はあまりやっていない。実問題に使うと思った時の難しさを感じてしまったことがその理由である。ロバスト最適化では、どうしても最悪ケースを考えるので、パラメータの動き得る範囲を用意してmin-maxで最悪ケース考えて、ベストな解を得る。そうすると、私も幾つかの企業といろいろ仕事をしたのだが、最悪ケースを考えると、どうしてもチャレンジするような解が出てこず、非常に保守的な解が出てしまう。また、不確実性の領域を用意すると、どうしても答えがそこに依存する。ということで、アルゴリズムの構築とか、難しいタイプの問題をどうやって簡単で等価な最適化問題に帰着できるか、といった辺の研究をやってきた。いろいろな企業と実際に応用してみると、最悪ケースを用意する用意の仕方など、どうしても難しくなる。

吉脇：今のところ、その方向に打破するのは難しい状況なのか。

武田：自分の強みというか、自分のチームの強みを生かすことを考えると、どうしても理論のほうに行ってしまうので、ロバスト最適化に自分の時間をかけてないというだけかもしれない。そういう意味では、小林先生のほうが実問題をちゃんと丁寧に扱って、不確実性を扱ったりとかされているので。私は、使ってもらえるようなツールを提供するっていう感じである。数理的な道具立てを使うので、限界というと、最悪ケースを考えるので、平均的な状況では、あまり利益を取れないということがあると思う。ただし、最悪ケースが起こってはならないような分野では、非常に使われると思う。実際、一緒に共

同研究を、という企業からの依頼は、大抵ロバスト最適化である。したがって、世の中に求められているということは感じている。

藤澤：武田先生の話だが、1回の計算結果をどのくらい使い続けるかを考えた場合、期間が長くなればなるほど、最大値と最小値というか、最悪、最良の差が開いてしまう。ロバスト性を気にするのであれば、リアルタイム性を追求して、頻繁にデータ取って頻繁に計算し直すっていうのは、ロバスト性に対する一つ対策になると思う。

武田：そう思う。今の時点で先の予想をして、将来どうなり得るのかを長いスパンで考える場合、最悪ケースを考えなければいけない。例えば、電力なんかは20年先までのプランをしなければいけない。現実的な方法を考えるということであれば、藤澤先生がおっしゃった、その場その場で見直すリアルタイムな最適化が良いと私も思う。

小林：ローリングホライズンという手法がある。10日先までの計画を決めて、実際に実行するのは今日と明日だけみたいな手法である。明日になったらさらに1日後ろにずらして、10日分は計算するけど、使うのは1日、2日という手法は、多分、企業でもよく使われている手法だと思う。もし分布というか、不確実性集合が決めにく、あるいは数学的に扱いやすいものにしにくいとか、そもそもデータが取りにくいとかいう問題であれば、現場の方も受け入れやすい、そういうスタイルの手法を最初は取ってみるといっても有効なのではないかと思う。

吉脇：ロバスト機械学習という考え方もあるかと思うのだが。鈴木先生の意見を伺いたい。

鈴木：異常検知でいうと、異常を検知するだけでなく、システムのどこに異常があるかということを見つけることが必要だと思う。グラフのモデリングもかなり重要になってきて。ここに異常が起きたからここをチェックするというような、そういうモデリングが必要だと思う。

あと、ロバスト学習についていうと、基本的には機械学習では少数データには弱い。例えば、外れ値 (outlier) というのはなるべく起きてほしくないが、外れ値は見たことがないから外れ値なわけで、そういうデータが少ない時にロバスト性を担保するのは結構難しい。深層学習も、例えばパングのことをテナガザルと答えたみたいなことがあるように、現在進行形の研究である。したがって、そういう意味では、実応用の運用では、ある程度外れ値が観測されている状況で運用したほうが、機械学習は安全であるというふうに思う。

吉脇：リアルタイム性でロバスト性の代用をするという話があったが、高野先生はどう思われるか。

高野：ロバスト性に関していえば、武田先生はロバスト性は企業との共同研究で、使いづらいといった話をしていたと思うのだが、私は逆の印象を持っている。企業との共同研究で価格設定とか、クーポン配布とかを研究する。その際、価格の需要関数とかクーポンの配布効果とかを推定する。かなり不確実性が高いのだが、ロバスト最適化を適用すると簡単に性能が上がるので、個人的には結構使いやすいと思っている。少し話題がずれるが、機械学習で最適化問題を解く時に、データを作らなければならない。その時に、鈴木先生が言ったシミュレーション技術は非常に重要ではないかと思っている。データ生成のためのシミュレーション技術みたいなことが、これから重要ではないかと感じている。

藤澤：皆さんが最初のアプローチを考案して、論文書いて、作っていった後で、実際に試せるような、企業が実際に活用して利益を生むようなプラットフォームを構築することが非常に大事である。これは世界中のいろんな人たちと議論しているが、多分、初めにやった人が有利になるだろうと思っている。

例えば、AmazonとかGoogleとかクラウドもサービス母体だが、世界中に巨大なサーバー群を持っていて、実際に使えるようにしたからいろんなサービスができた。サイバーフィジカルにおいても同じように、最初にプラットフォームを作ることが、研究者にとっても社会にとっても有利になるかなと思う。

3 | 研究開発の推進方法についての話題提供

3.1 先導的研究会について：MOAI技術によるSCM Solutions Metrics, Trade-offs and Beyond

久保 幹雄（東京海洋大学）

タイトルにあるMOAIとは私が作った造語で、数理最適化と機械学習（Mathematical Optimization/Artificial Intelligence, MOAI）という意味である。1年ぐらい前に研究部会を立ち上げた時に付けた名前である。図3-1-1に示すように、数理最適化と機械学習の融合分野と位置付けられる。ただ、実際にやっているのは、最適化と機械学習の合体であり、ここ数年でいろいろなアイデアが出てきて盛り上がっている、日本でも研究しようと思って作った。6回ほど開催し、延べで450人超が集まった。ターゲットは、理論の融合分野ではなくて、実際の問題を解くための融合分野である。いろいろなアイデアを持ち寄って試して、現実の問題で使えるようにするのが目的である。もちろん、この研究部会だけで普及までは難しいので、有志を募ってMOAIを使ったサプライチェーン最適化のソリューションを作っている。

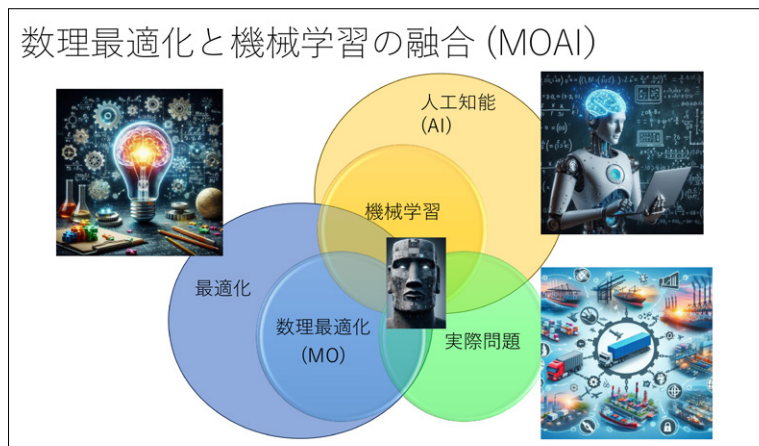


図3-1-1 MOAIとは

サプライチェーンマネジメントのメトリックス

サプライチェーンを取り上げた理由は、私自身が30年以上にわたりさまざまな会社に技術指導を行ってきた経験から、日本のみならず、世界においてもサプライチェーンがきちんと機能していないと感じているためである。最適化が十分に活用されていない分野であると認識しており、使えるものを作ることが目的である。作り方については、まずヒアリングを行うのではなく、サプライチェーン最適化のメトリックスを学び、このメトリックスを可能な限り満たすような設計をしていくという考えである。そこにMOAIを用いる。

これから話す内容は、図3-1-2に示されているようなメトリックス間のトレードオフと、トレードオフを解決するためのソリューションについてである。最初のメトリックスは問題のサイズである。大規模インスタンスではSCM（Supply Chain Management）の問題の多くがNP-困難な問題となる。つまり、問題が大きくなると理論上解決が難しくなるので、非常にシンプルな近傍探索法やグリーディ法といったヒューリスティクスが用いられる。小規模であれば、厳密解が求まる。

3 研究開発の推進方法についての話題提供

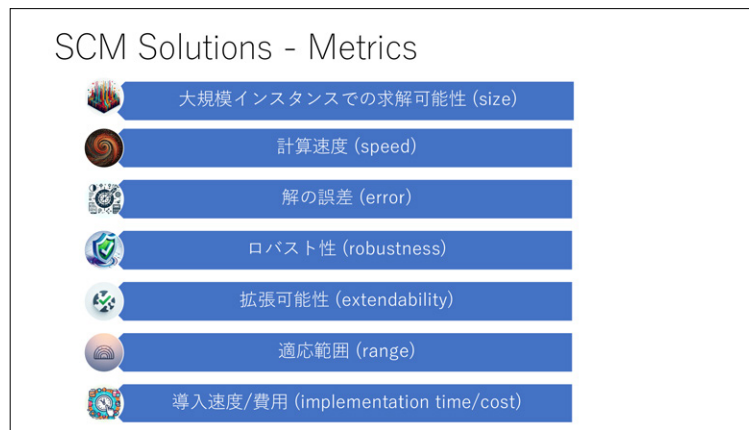


図3-1-2 SCMソリューションのメトリックス

2番目のメトリックスは計算速度である。応用によっては十分な計算時間をかけても良い場合もあるが、最近の傾向としてはできるだけ短時間で応答が望まれるし、動的な問題においてはリアルタイムで解が必要な場合が増えてきている。

3番目のメトリックスが解の誤差あるいは解の質である。市販のSCMソリューションには、スケジューリングやサプライチェーン全体の最適化が多く存在するが、ユーザーは短時間で応答を期待しているため、解の質を犠牲にしていることがほとんどである。例えば、スケジューリングでは非常に簡単なディスパッチングルールが使われたり、サプライチェーン全体の最適化においても非常に単純なルールで動作していたりして、実際には厳密解法がほとんど使用されていないのが現状である。もちろん、誤差の少ない解のほうが望ましいのは明白であるが、最適化は多くの場合、自動化や費用削減を目的として行われるため、この解の誤差や精度は非常に重要な要素となる。

4番目のメトリックスがロバスト性である。これは、解のロバスト性ではなく、解法のロバスト性を指している。具体的には、小さなデータや特定のデータに特化したPoC (Proof of Concept) として作成された簡単なヒューリスティックでは、実際のシステム運用時にデータを入れると動かなくなることがある。一方で、厳密解法を使うと速度が急に低下することがある。どのような問題にも対応できるように、より広い範囲のインスタンスを解ける解法を設計する必要がある。

これまで述べたメトリックスは基本的にトレードオフの関係にある。NP-困難性により、大規模なインスタンスに対して高速で誤差の少ない解を出すことは難しい。この課題を克服したいと考え、機械学習との統合を検討している。理論的に全てのインスタンスを厳密に解くには時間がかかる可能性がある。われわれがターゲットとするのは、頻繁に現れるインスタンスで、インスタンス情報と解がすでに分かっているものである。問題に依存するが、新しいインスタンスに対して機械学習を利用して高速に解を生成する方法はいろいろ考えられる。通常は計算速度と誤差はトレードオフの関係にあるが、問題によっては、数理最適化と機械学習を統合した手法を使うことによって、大規模インスタンスで誤差の小さい解を非常に速く計算することができると思われる。

現在のSCMソリューションには、問題の適応範囲に応じて、長期、中期、短期に分かれたものが存在する。長期としてはいわゆるIBP (Integrated Business Planning) があり、著名な企業がソリューションを提供している。中期としてはS & OP (Sales and Operations Planning) やAPS (Advanced Planning System) が挙げられる。短期の範囲としてはERP (Enterprise Resource Planning) が位置付けられている。それぞれの領域に多くのソリューションプロバイダーが存在する。これが適用範囲のメトリックスである(図3-1-3)。サプライチェーン全体という広範な範囲をカバーする企業もあれば、生産や配送に特化したソリューションを提供する企業もある。

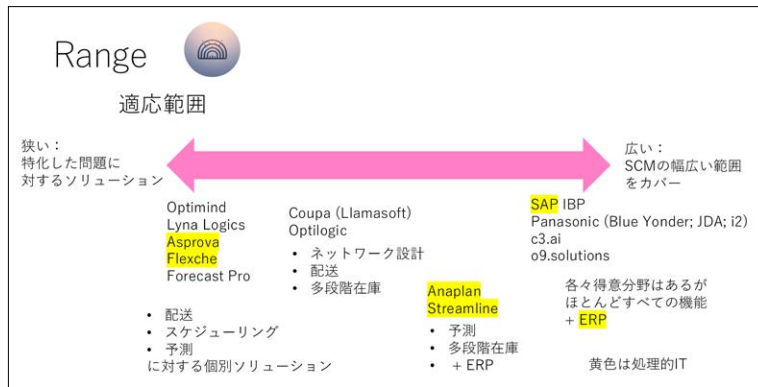


図 3-1-3 適用範囲のメトリックス

次のメトリックスが、導入にどれだけ時間がかかるかというものである。導入時間がかかるし費用もかかるタイプのもの、比較的短時間で導入でき安価なものがあり、そこにはトレードオフがあると思われる。

似たような尺度で拡張可能性がある。何か追加でやりたいという時に、時間がかかったり、費用がかかったりするのとは拡張可能性が低いということになる。例えば、会社を買収してさまざまな問題に対応できるようなソリューションを作ると、開発者の退職によって保守が難しくなり、新たな機能が追加できなくなって拡張可能性が低下する。

MOAIソリューション

適用範囲と拡張性、導入速度の間にはトレードオフがあり、適用範囲が広いソリューションは拡張が難しく、導入に時間がかかるし、拡張が簡単で導入が短時間でできるソリューションは適用範囲が狭い。

MOAIではサプライチェーンモデリングランゲージを提案して、このトレードオフを打破しようとしている。サプライチェーンモデリングランゲージでは、サプライチェーンのスケジューリングやネットワークなどを記述することができ、最適化は裏で動くようになっている。具体的には図 3-1-4 に示すように、サプライチェーン、需要予測、生産計画から輸配送を個別に最適化し、その間のデータをつなぐことによって全体最適化をすることを目指している。

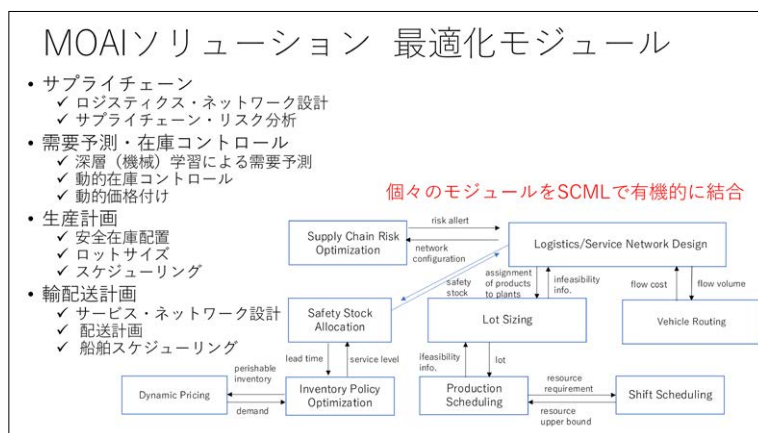


図 3-1-4 サプライチェーンモデリングランゲージ

3 研究開発の推進方法についての話題提供

アナリティクスの進化と最適化の時代

図3-1-5はアナリティクスの進化を示している。アナリティクスは、かつては記述的、診断的、発見的なものが中心であり、これらの段階までをDX（デジタルトランスフォーメーション）と称することもある。しかし最近では、AIを活用して予測的アナリティクスへと進化し、さらに最適化技術を用いた指示的アナリティクスへと進展している。今後は、これら二つを組み合わせたMOAIアナリティクスの時代が到来することを期待している。



図3-1-5 アナリティクスの進化と最適化の時代

質疑

吉脇：MOAI 研究部会としてどのような支援が必要か？

久保：今は、スケジューリング学会という小さな学会の研究部会として活動しているが、本格的なソリューションを作ろうとするとお金がかかる。そのためには、会社を作らないといけない。そこで、MOAIという名前を付けた会社を設立しようとしている。研究で作ったと言ってもなかなか使ってもらえないので、ベンチャーキャピタルから資金を調達して上場を目指すという方向でやろうとしている。大学の中で作ったもの、学生さんが作ったもの、そういうものを企業で使うのは非常にリスクである。共同研究としてやる分にはいいが、本当の運用で使う時にはきちんとした法人が必要だと考えている。もちろん、その基礎になる部分は研究費が必要ではあるが、実運用となると桁の違う資金が必要になる。

ただし、開発環境は進化しており、特にWeb APIやその周辺は非常に簡単にできるようになってきた。それこそ、生成AIを使うと、ある程度自動的にユーザーインターフェースが生成されるような時代になってきているので、われわれとしては最適化と機械学習の融合というコアな技術の部分に注力し、ユーザーインターフェースなどは、外注でもいいのかなと思っている。

3.2 実用に沿った研究開発について：実務につなげる数理最適化

梅谷 俊治（株式会社リクルート）

「実務につなげる数理最適化」ということで、幾つかポイントをかいつまんでお話しする。まず、実務で問題解決しようとする図3-2-1に示すように幾つかステップがある。

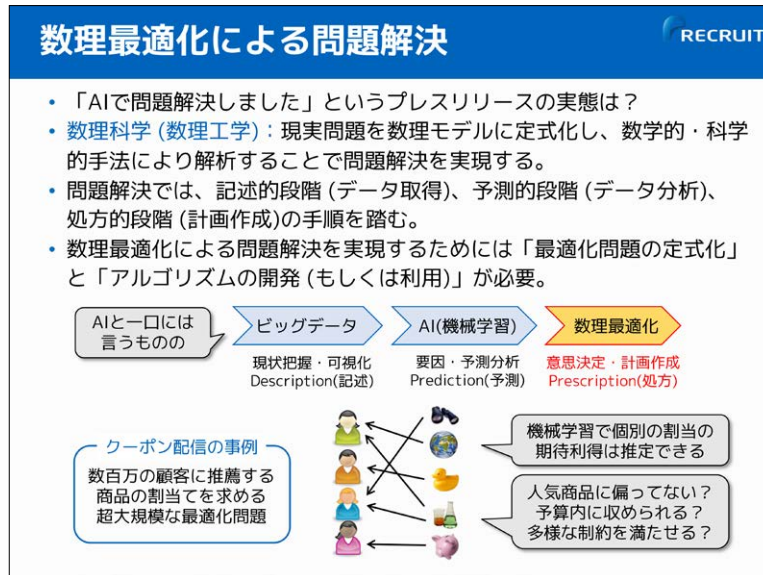


図3-2-1 数理最適化による問題解決 (1)

まず、データを収集して、現状を可視化するというステップであり、その次が予測分析である。これは、いわゆる今のAI、機械学習というもののメインターゲットになっているところである。クーポン配信の事例を説明すると、機械学習のテクニックを使うと商品とユーザーの組み合わせに対してスコアを計算することはできるが、スコアの大きい順に貪欲的に割り付けていけばそれでいいかというと、広告としては何もしなくても売れるものをわざわざ推薦しているということになってしまう。いろいろな制約の下で最適化する必要がある。機械学習で何か予測が終わったら、それですぐ問題が解決するということではなく、その後に意思決定、計画作成というフェーズがあり、そこで数理最適化が必要になる。数理最適化自体の歴史は長いですが、今、これから実務に持ち込むべきであると考えている。また、自分自身がアカデミアにいたから分かるのであるが、アカデミアの人たちは最適化問題が与えられた上で効率のいいアルゴリズムを開発するという事に集中しがちである。しかし、実務においてはどちらかという、最適化問題の定式化が重要になる。

実務問題解決のステップ

図3-2-2に、ステップを示しているが、順番に定式化、アルゴリズム開発、分析検証を進めてソリューションができたということはずがない。大体、「何か違う」とか、「全然違う」と言われる。ここにはかなりコンサルティングの問題が入ってくる。要するに、最適化問題を何度も修正して、何回も回すことが必要になってくる。

数理最適化の応用事例

他の分野でも同じであるが、われわれ数理の人間というのは、例えば数理最適化にしろ、機械学習にしろ、さまざまな分野の問題に適用できるということは知っている。一方で、世の中の大半の人は、エネルギーであ

ればエネルギーの分野、物流であれば物流の分野というようにそれぞれの分野に専門家がいる。この両者のギャップは非常に大きいので、そこをきちんと意識した上でお付き合いする必要がある。

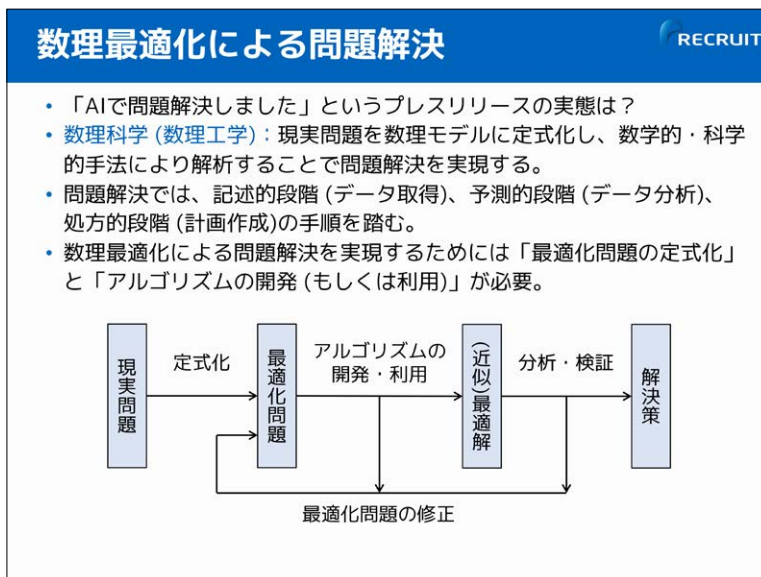


図3-2-2 数理最適化による問題解決 (2)

私自身、汎用のメタヒューリスティックソルバー、整数計画問題を解くようなソルバーの研究も続けている一方で、図3-2-3に示すように、企業のお手伝いをやってきた。

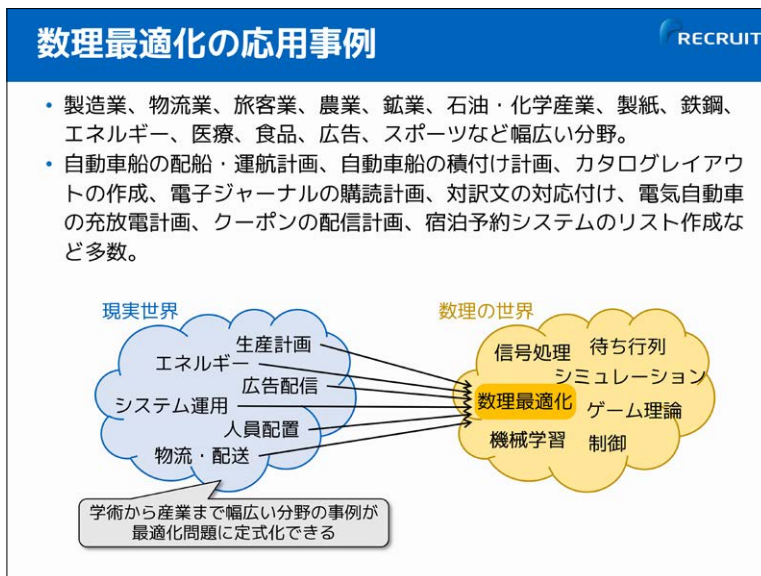


図3-2-3 数理最適化の応用事例

一つの事例として、商品推薦を紹介する。もともとレコメンデーションのシステムが動いているところでどう最適化のシステムを導入するのかという話である。図3-2-4に示すように、もともとスコアに従って何かをレコメンドするというシステムがすでに動いている上で、最適化問題のシステムでそれをすげ替えるというのは難し

い。実際にどうしたかという、このスコア自体を適応的に調整するような調整係数というのを導入することによって、システムの改変を最小で済ませるといような工夫をした。最適化問題として定式化して、この調整係数を求めるようにした。具体的には、実際に最適な割り付けというレコメンドを一度最適化問題で解いてしまい、それと同等の結果を出すような調整係数を求めるという問題をまた最適化問題として解くということを行う。こういう工夫が実際の導入では必要になる。

久保先生の話にも出てきたが、アルゴリズムなどを開発する上で気を付けるべきポイントは、やはり汎用か専用かということである（図3-2-4 汎用解法と専用解法）。要するに、汎用のものは広く使えるのであるが、全ての問題に対して必ずしもうまく動くわけではないというのがポイントである。数理最適化のソルバーには厳密解法のものが多いが、問題によっては非常に計算時間がかかるようなケースも出てくる。したがって、取りあえずは動くが、必ずしもうまく解いてくれるわけではないということがある。一方で、専用のソルバーを作ったのはいいが、ちょっと問題の定式化などが変わってしまうとすぐ使いものにならないということもある。この折り合いをどう付けるかというのが重要になってくる。

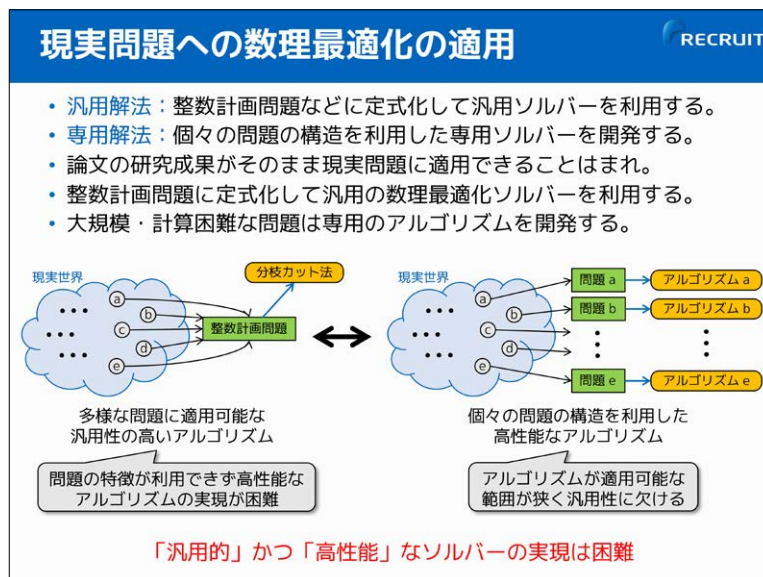


図3-2-4 汎用解法と専用解法

問題解決へのアプローチ

一つのアプローチを図3-2-5に示す。現場からのフィードバックをもらって最適化問題の修正を何度も行う必要が出る。そうすると、最適化問題、定式化を直すたびにアルゴリズムを一から作り直すのかということそれは対応が難しいこれでは、いくら工数が合っても足りないということになる。専用ソルバーの問題点は、このところでアルゴリズムの作り直しが生じるところである。アルゴリズムの修正の手間をいかに減らすかということが重要になる。

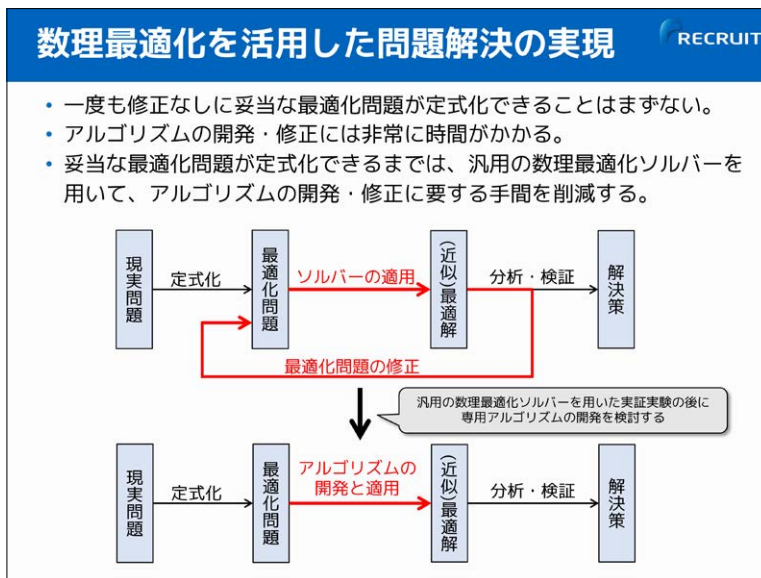


図3-2-5 数理最適化を活用した問題解決の実現

では、汎用ソルバーが良いかということ、汎用ソルバーでは実際に求めるような十分なパフォーマンスが得られないということもよくある。そこでどうするかというと、二段構えでやることになる。初めはパフォーマンスが出ないということは我慢して、とにかく定式化がしっかり固まるまでは汎用ソルバーで回す。そうすることで、アルゴリズムの修正にかかる手間をとにかく減らす。これで納得のいく定式化、モデリングができ、それでもパフォーマンスが足りないというのであれば、専用アルゴリズムの開発に移るといような流れになる。まさに「急がば回れ」ということである。

現実問題における課題と対策

その他にもテクニカルな面以外で気を付けるべきポイントがある（図3-2-6 現実問題における課題と対策）。重要なポイントは目標の設定とデータの整備である。最適化のための計算時間が短くなったといっても、ユーザーが入力データを作成するのにかかる時間がすごく長いというようなことであれば、本末転倒になってしまう。定式化については、1回で定式化できることはまずないということである。これは熟練のコンサルタントでも同じである。現場の人間から情報を引き出すことがいかに難しいかということである。また、先ほども話の出たシミュレーターは重要だと思っている。

現実問題における課題と対策

RECRUIT

- **目標の設定**：コストの最小化や利益の最大がだけが目的か？
計画担当者の自動化・支援を通じて業務プロセスの改革を実現する。
大規模な事業では、意思決定者が増えるため利害の調整が難しくなる。
- **データの整備**：現場の計画担当者がデータ取得/入力/修正の作業に多大な時間を要するのは本末転倒。UXは計算時間や解の質だけではない。
- **最適化問題の定式化**：最適化問題の定式化に必要な情報の多くは、業務に従事する計画担当者には改めて話題にするまでもない常識。インタビューと定式化の再検討の繰り返しが必要。
- **システムの運用**：多様な状況下でのシミュレーション、意思決定者間のすり合わせに、出力データの検証と入力データの修正を何度も繰り返す。

The diagram illustrates the interaction between customer, sales, and planner. On the left, the customer asks questions, and the salesperson provides answers. The planner then takes over, but this process is slow and burdensome. On the right, a system is introduced that automates the planner's tasks, significantly reducing their burden and speeding up the response to the customer.

図3-2-6 現実問題における課題と対策

最後に普及と専門家の育成について述べる（図3-2-7 数理最適化の普及と専門家の育成）。産学連携というと大学と企業の共同研究ということになるが、これが長続きしない。いきなり研究するというのが良くなく、併せて専門教育をやるという試みが重要だと思う。専門教育を行って、企業の側にその専門知識を持った人間が増える、そして共同研究も増えるというサイクルを作るのが大事だと思っている。また、最適化のエキスパートだけを育てても駄目で、階層があるので、それぞれの階層で人を増やすということが重要だと思っている。

数理最適化の普及と専門家の育成

RECRUIT

- 大学だけではなく企業にも数理最適化のエキスパートを増やしたいが、研究室から輩出できる学生の数は限られる。
- 大学と共同研究を続けるには企業側にも専門知識を持った人材が必要。専門教育を併せて実施することで取り組みの継続と拡大が期待できる。
- 数理最適化を活用するにはエキスパートだけを育成すれば良いわけではない。Lv1-2の人材を増やし裾野を広げることが普及には不可欠。

- Lv1：数理最適化の概要と応用事例が分かる。
- Lv2：最適化問題の定式化、数理最適化ソルバーの利用ができる。
- Lv3：最適化アルゴリズムの設計・実装ができる。

The diagram shows a career progression model. On the left, a flow goes from 'Specialized Education' to 'Joint Research', with a note that HR and R&D departments should be involved for expansion. On the right, a pyramid represents three levels of expertise: Lv1 (Business Manager/Client), Lv2 (Engineer/Data Scientist/Consultant), and Lv3 (Researcher/Expert). Arrows indicate the progression from Lv1 to Lv2 and then to Lv3.

図3-2-7 数理最適化の普及と専門家の育成

質疑

吉脇：最適化をやっているアカデミアと企業のマッチングはどうすれば実現するか？

梅谷：ICT企業を中心にデータ分析などのエキスパートがいる。そういう人たちがさらに数理最適化にも取り組むというのが最初であろう。それはなぜかということ、データ分析のプレーヤーが増えてこれから

飽和状態になる、そうすると個人としても企業としても差別化が必要になり、その差別化の一つのポイントとして数理最適化もできるというのが重要だと思うからである。

また、データ分析はレポーティングで終わることがある。その後のシステム開発にならないので、収益につなげにくいということがある。数理最適化をやると何らかのシステムを作る話になるので、出口感があり、データ分析をしている個人とか企業には受け入れられやすいと思っている。

3

研究開発の推進方法に ついての話題提供

3.3 最適化技術の普及について

藤井 浩一（株式会社NTTデータ数理システム）

数理最適化ソルバーと事例

今回は、ベーシックなところからお話をさせていただければと思う。数理最適化ソルバーは与えられた数理最適化問題を汎用的に解くソフトウェアである。具体的には、何か問題が与えられたら、その問題を整理し、定式化をして、専用のソフトウェアに付随しているモデリング言語で書き、その後にソルバーで解くという流れがある。重要な点は、モデリングとアルゴリズムの分離が自然に実現されていることである。

弊社が手掛けた数理最適化ソルバーを使ったソリューションを簡単に三つほどご紹介させていただく。一つ目は、遠州鉄道株式会社のバス乗務員シフトスケジュールに関するものである。ベーシックなバスのシフトスケジュール表を自動的に数理最適化の上述と同じプロセスで定式化をして、それでソルバーに解かせるというところまで行き、調整作業の大幅削減に成功した。この件は、国土交通省のからの補助金で遠州鉄道株式会社が作られた経緯がある。デジタルトランスフォーメーション化の手引きに掲載されている事例となる¹⁶。

二つ目は、株式会社ビッグカメラの店舗シフト作成システムである。こちらは、「スケジュールリングシンポジウム2020」で発表させていただいた¹⁷。上述のバスのシフトと同じく、シフトスケジュールであるが、こちらは利益に特化している点が違う。売り上げの予測を立て、どのように配置したら売り上げが上がるかを予測して、それに対してシフトを当て込むということを行っている事例になる。

最後は、最適軌道保守計画の事例である。こちらは、鉄道総合研究所との共同研究、共同開発であり、三和雅史先生、大山達雄先生と一緒に論文も出されているものになる¹⁸。鉄道の保守についてであり、鉄道の線路が時間がたつにつれてゆがんでくることに対して、矯正を行うマルチプルタイタンパー（MTT）と呼ばれる高価な鉄道の保線用機械がある（1台数千万円程度）。高価であるがゆえに、融通し合わないといけなため、どれくらい生かせるかという予測モデルを立て、それに対して計画を立てるという流れになっている。最適化問題としては、これは施設配置計画問題の一つになっている。

数理最適化プロジェクト

数理最適化のプロジェクトプロセスは現実問題があって、問題を整理して、プロトタイプを作成して結果を確認という流れがある。結果を確認した時点で手戻りが発生するという点が、数理最適化プロジェクトでは欠かせないところだと思う。

このような反復的開発がアカデミアとは違う点である。企業という立場でいうと、数理最適化は、非常に強力な手法であるため、インフラに入り込むものである。例えば、上述の最適軌道保守計画も、実はスタートから10年以上も保守をさせていただいている。この10年以上も保守しているという点が企業特有であると思う。

そのような研究開発でも複雑さと保守性のバランスを取る必要がある。そのような場面でも、全てではないが、例えばモデリングとソルバーの分離というのは非常に役に立つと言える。

- 16 国土交通省,「バス・タクシー事業者向け「デジタル化の手引き」について」, 3.導入事例 <https://www.mlit.go.jp/jidosha/content/001479823.pdf> (アクセス2025年7月17日)
- 17 多田明功, 寺岡洋一, 吉沼由紀夫「株式会社ビッグカメラ様への「店舗シフト作成システム」の適用」『スケジュールリング・シンポジウム講演論文集』(2020): 49-50.
- 18 三和雅史, 大山達雄,「最適軌道保守計画作成モデルの実施検証に基づく性能評価と運用実施の汎用化」『土木学会論文集』69巻2号(2013): 160-175.

数理最適化ソルバーの比較

Gurobi Optimizerは米国の商用ソルバーである。混合整数線形計画問題（MILP）においてはデファクトスタンダードとされている。機械学習と連携するオープンソフトウェアもGurobi Optimizerの開発元が提供している。近い将来、Gurobi Optimizerは非線形計画問題（NLP）にも対応するという計画になっている。

中国では、企業が（商用の）COPT Optimizerの開発をしている。MILPにおいて近年急速に性能を伸ばしている。また、NLPについてもベンチマーク性能が良好になっている。

私の所属するNTTデータ数理システムが手掛けているNurorium Optimizerは、古くからMILPだけではなく、半正定値計画問題（SDP）をはじめとするNLPも取り扱いが可能である。また、MILPに対してメタヒューリスティックを搭載している。これはNTTデータ数理システムの独自開発というより、国内のアカデミックの先生方のお知恵を借りて開発をさせていただいている。これに関しては、現在、分枝限定法との融合を目指している。

Solving Constraint Integer Programs (SCIP) はベルリンにあるZIBで開発されているソルバーである。こちらは、混合整数計画問題（MIP）を拡張したクラス制約付き整数計画（constraint integer programming/CIP）が扱えるという柔軟性が特徴になる。NLPも取り扱い可能である。こちらも機械学習と関係するオープンソースソフトウェアが提供されている。近年では多倍長計算といった計算の質を追求している。

英国のエジンバラ大学が開発しているHiGHSがある。こちらについては、高性能なLPプロジェクトからスタートして、MILPにおいて近年急速に性能を伸ばしている。HiGHSとSCIPの二つが無償ということになる。

一つ大事な点は、全てのソルバー開発において、元SCIP開発者が関わっているということである。米国のGurobi Optimizerの開発責任者、開発リーダーもSCIPのデベロッパーである。中国のCOPTもMILPの部分は実質的に3、4名ほどのSCIPの元開発者がスクラッチから作っている。このように、背後には人的ネットワークがある。特にMILPのソルバーの開発における、内部の細かい箇所は論文にはならない。カンファレンスだけで発表したり、あるいは技術者同士のネットワークの中で共有されているような情報がある。そういうつながりがあることで、現時点でのソルバーが生まれているという点が重要な特徴と思っている。

まとめ

数理最適化プロジェクト開発においてソルバーが重要な役割を果たすということ。また、ソルバーの比較は個人的な見解であるが、ソルバー開発、あるいはソルバーを使う立場については、例えば、先ほど久保先生のご講演にあったサプライチェーンのSAPというソフトウェアもSCIPの元開発者が最適化部分の研究開発に携わっているということを考慮すると、開発あるいはソルバーをより活用することについては人的ネットワークが重要になることは確かである。

無償ソルバーの性能は、ここ5年で確実に向上しているところがある。ソルバーだけではなく、社内では、先ほど梅谷先生からご紹介あったが、企業内にそういった良い技術者の居場所があるという点で、近年、数理最適化技術の普及の下地が整いつつあるという実感がある。

質疑

吉脇：実際のプロジェクト開発において、ソルバーは必要だということが伝わってきた。一方で、各国、商用、非商用さまざまにソルバー開発をしているが、性能差からいうと、SCIPがほとんどの数理最適化問題は解けると読めるが、そのあたりいかがか。

藤井：性能差という点では、問題によっては商用ソルバーよりSCIPのほうが上回ることもあるが、商用のほうが上回ることもある。例えばマルチコアをより活用するという点では、SCIPでも不可能ではないが、商用のほうが有利になるケースというのはある。

（発表者補足）実務に現れる数理最適化問題は、まだまだ工夫なしではどのソルバーでも解けな

い問題も多い。

吉脇：Gurobi OptimizerはMILPでのデファクトスタンダードとおっしゃっていたが、SCIPとGurobi Optimizerを比較した時に、例えばMILPだけだったらGurobi Optimizerのほうが良いという感じか。

藤井：なかなか断言できない。技術者としては、問題によるという回答になってしまう。

吉脇：ユーザーが使いやすいソルバーという点について一言だけいただけないか。

藤井：ソルバーにモデリング言語やユーザーインターフェースといったところを統合できる流れがあると、ユーザーにとってより使いやすいと思う。

3.4 情報と数理の融合について

上田 修功（理化学研究所革新知能統合研究センター）

本日は、2019年からのJST戦略的創造研究推進事業CREST¹⁹「数学、数理科学と情報科学の連携・融合による情報活用基盤の創出と社会課題解決に向けた展開」の総括の立場からお話します。2019年からであるので、現時点で6年目に入り、あと2年強あるような状況である。

領域設立の背景

- ビッグデータ活用の有用性が多方面で実証され、そのドライバーとして、近年深層学習に代表される人工知能技術（機械学習技術）が注目されているが、難病、異常現象、大災害などの**データ収集が困難なレアイベントや、情報のデータ化・デジタル化自体が困難な場合、データ駆動型アプローチだけでは十分とは言えない**
- 現状の人工知能技術は**ブラックボックスモデル**と呼ばれ、解析結果に対する説明性や信頼性向上が課題となっている
- サイエンス分野では数学・数理科学による原理の解明という**プロセスモデル**に基づく研究が古くから実践され、**数学・数理科学の力が実証されている**
- 情報科学の分野においても、欧米で生み出された、RSA暗号、ページランク、圧縮センシング、差分プライバシーなどの**革新技術は全て数学を活用した成果**と言える

図3-4-1 領域設立の背景

私自身の専門は統計的な機械学習である。数理最適化と関連はするが、そのものではない。よって、本日は、数理最適化よりももう少し広げて数理と、情報の融合がどのように研究されているのかということをお話提供として紹介したいと思う。

CRESTの領域設立の背景として、現代のデータ駆動型のAIのアプローチについて、説明性がないことや膨大な学習データのため、多くの電力を消費するなど、さまざまな問題が指摘されている。一方、データ駆動型サイエンスもあるが、サイエンスの領域では第一原理計算がベースになっている演繹的な推論が行われている。両者それぞれ長所、短所があり、これらを融合することが非常に重要ではないかと思う（図3-4-1）。例えば、情報科学の分野における暗号研究は数学をベースにしているので、そのような研究開発を促進しようとの動きがある。

当時のCRESTの公募に対して多くの応募があり、なかなかの競争率であった。その中で1期生、2期生、3期生という形で採択をしている。カテゴリーとしては汎用的データ解析分野、医学・医療分野、工学・化学分野に分かれている。

汎用的データ解析分野の成果

- 河原チームでは、再生核ヒルベルトC*加群を土台にしたカーネル平均埋め込みの理論を構築し、機械学習へ展開している。

¹⁹ 戦略的創造研究推進事業のうち、科学技術イノベーションにつながる卓越した成果を生み出すネットワーク型研究（チーム型）のプログラムである。

- ・ 谷口チームは、ハミルトン力学は位置と運動量で運動方程式を立てる学問であり、その位置と運動量はシンプレクティック幾何学における多様体の点として表現できることを用いて、連成系における物理シミュレーションを深層学習でより精緻に行うことができるという研究を行っている。
- ・ 福水チームは、機械学習における確率的勾配法の min-max 最適性を研究している。
- ・ カーンチームは、これはフランスとの連携であり、ベイズ双対性という概念を提示して、適応学習へと適用している。
- ・ 吉田チームは、確率過程の数学の先進的なソフトウェアを研究している。

医学・医療分野の成果

- ・ 樺島チームでは、計算することが非常に難しいとされる、時間的な情報の因果関係を検出するための移動エントロピー (Transfer Entropy) について、それを効率的に計算する研究を行い、発がんに関係する情報伝達経路異常の発見に成功した。
- ・ 杉山チームでは偏微分方程式を土台にして、非侵襲に脳動脈瘤の状態を推定する技術を研究している。
- ・ 李チームでは、同じく偏微分方程式を土台にして、現状ではステロイドで治療するしかない、非常に治療の難しい慢性じんましんに対して、革新的な成果を出している。

工学・化学分野の成果

- ・ 梶原チームでは、「美しい」設計はどのようなということを数学的に研究している。
- ・ 小林チームでは、いわゆる多元混合化学反応という、複数の物質が同時に反応して、同時にいろんなものを生成するという対象を扱っている。代数ホモロジーや一般化勾配流理論を用いて理論構築をすることによって、この反応についての研究をさらに加速させている。
- ・ 末永チームでは、AI-CPS、いわゆるAIでのサイバーフィジカルシステムに関するブラックボックス検証(なぜ安全なのか)についてオートマトンの理論で展開している。
- ・ 野津チームでは、現在深層学習でも問題になっている電力の問題について取り扱っている。これをリザーバー計算によって、低電力というより物理リザーバーを使うことで学習を実現しようという研究である。
- ・ 高木チームで、数学を使った完全に新しい暗号 (QR-UOV 署名) の研究を行っている。
- ・ 田中チームでは、多義性を考慮した単語埋め込み技術の研究を行っている。ご存じのように LLM が台頭しているが、LLM にもう少し論理的な性質を入れて信ぴょう性を高める研究を展開している。

各成果の詳細な説明 (ピックアップ)

[谷口チーム] 現在、物理シミュレーションはスーパーコンピューター (スパコン) を用いている。理化学研究所でいうと、京 (けい) から富岳に移行して、それを使った研究が多いが非常に時間がかかる。それを高効率に行うための深層学習モデルが数年前に提案されて、現在その研究が盛んになっているが、まだまだ理論研究が不十分である。それに対して、シンプレクティック幾何学を土台にして理論研究の展開をしている。

[杉山チーム] 脳動脈瘤はなかなか厄介である。非侵襲でその状態が診たい。すなわち、脳動脈瘤を手術によって診ると脳に傷を付ける可能性があり、非常に危険である。よって、放置しておいたほうが良いという状況もあるが、どれだけ症状が進展しているのかを確認したい。そこで、偏微分方程式のモデルを立てて、それを解くことによって、非侵襲に確認するという研究になっている。

[高木チーム] 量子コンピューターが実現したとしても、ショーアのアルゴリズムによると素因数分解は多項式時間で解けてしまう。この問題をどのように対応したら良いかについて、さまざまな世界的な提案がある中で、UOV 署名というものがある。それをさらにコンパクトにした QR-UOV 署名を提案した。現時点でこれは

まだ破られていない。もしこれがあと数年破られなかったら、国際標準になるという研究である。

[野津チーム] 円柱周りのカオス的な流体がリザーバーを生むということを実現できることに加えて、数学的に解明して、どういう状態が良い学習を生み出すのかを解明する理論研究になる。

まとめ

情報と数理の融合に関する重要性は「高度な問題解決能力」、「新技術・アルゴリズムの創出」、「他分野への応用」の三つである（図3-4-2）。今後は、図3-4-2にあるように「AIの高度化」、「データサイエンスと数理モデルの融合」、「教育と人材育成」、「社会的課題への貢献」といった展開が期待されるだろうと考えている。

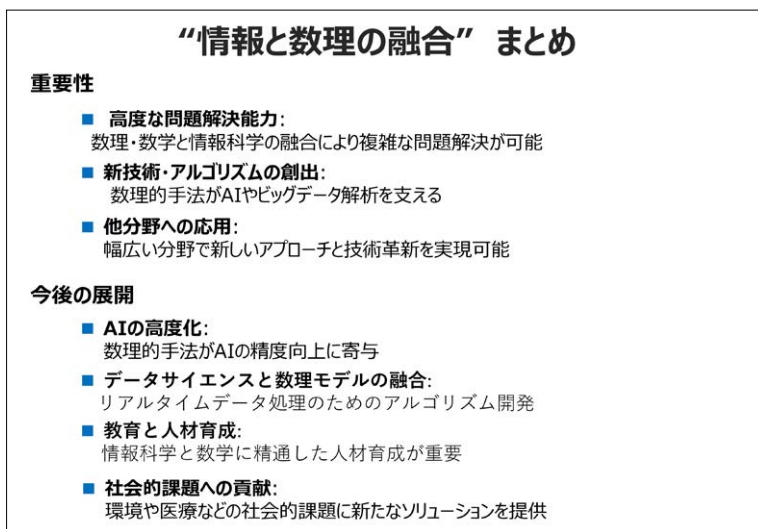


図3-4-2 “情報と数理の融合” まとめ

質疑

吉脇：情報と数理の融合に関して、CRESTでは多くの結果が出ている状況だと思うが、上田先生の考える融合がうまくいったポイントと、うまくいかないとしたらどのような壁を突破したら良いかという点について、コメントをいただけないか。

上田：うまくいっている理由は、企画の段階で問題意識が明確であって、情報の専門家と数理の専門家が丁寧に連携をして、最初からきちんとした計画を立てているからだと思う。やはり「餅は餅屋」なので、情報の研究者が数理を全部分かるわけではなく、数理の研究者が機械学習やAIの話が分かるわけではないので、その点を考慮して相互に連携を図っていることこそが、融合の成功を支えている要因であると言えるのではないかと。それから、問題が非常にクリアで、今まで解けてなかったような実問題に対するチャレンジ性が研究者のモチベーションを高めているのではないかと考えている。

融合がうまく進まない場合、その要因の一つとして、「融合は重要である」といった抽象的な認識にとどまり、具体的なチャレンジのテーマや適切なメンバーの配置が十分に整備されていないことが影響していると考えられる。

3.5 研究開発の推進方法についての総合討議

3.5.1 話題提供：最適化技術の普及について

JST-RISTEX「政策のための科学」プログラムの知見から

黒河 昭雄（神奈川県立保健福祉大学/JST-RISTEX）

「政策のための科学」プログラム

現在は、神奈川県立保健福祉大学に所属しているが、以前は同じJSTで別の部署にある社会技術研究開発センター（RISTEX）でフェローをさせていただいていた。現在も引き続き研究推進委員という立場で、「科学技術イノベーション政策のための科学 研究開発プログラム」というプログラムの推進に携わらせていただいている。今日は、その事例から、どのようにすれば最適化を含む研究開発成果が政策に結びつくのか、あるいは、つかないのかというところをお話しさせていただければと思っている。

専門は、社会科学、その中でも政治学と呼ばれる分野、特に行政学という分野である。よって、公共政策そのものを研究しているという立場になる。

「政策のための科学」というプログラムは、簡単に上げると、最適化問題を含むさまざまなエビデンス、これがどのようにすれば政策に使われるのかを目標としている。今日、エビデンス・ベスト・ポリシー・メイキング（EBPM）という理念が社会に随分と浸透しつつあるが、とはいえ現実の政策形成は依然として経験と勘に依存しているのも事実である。そうしたなかで、どのようにすればエビデンスが使われるのかを基本的な問題関心としている。

本日は、まず「政策のための科学」の狙いをあらためてお話しさせていただいて、その中から幾つかの研究開発のプロジェクトの事例をご紹介させていただく。その上で最後に、それがどのような条件を満たせば実際に政策に使われるのかということをお話しさせていただければと思う。

最初に、なぜ政策なのかという点について。最適化問題、とりわけ社会的な課題を解決するさまざまな問いの設定をした上で、さまざまな手法、アプローチを用いて最適化問題を解くということをお話しさせていただいた。それに対して、政策という観点で申し上げれば、世の中に起きている社会システム上のさまざまな課題、これを特定してその解決手段を考え講じること。それが政策であり、この手段には幾つかパターンがある。例えば罰則などを用いた規制や、経済的なインセンティブの提供、情報提供などが代表的である。こうした政策手段を実際に検討する上で、数理最適化というのが一つの有用なアプローチとなるのではないかと考えている。




図 3-5-1 EBPM

実際、例えば感染症の流行というのは、この点で一つの社会実験としても大きな挑戦であったと思う。そもそもエビデンスをなぜ用いるのかといえば、経験と勘、あるいは度胸で社会的な課題を解決していくというアプローチではなく、一定の客観的な根拠に基づいて不確実性をコントロールしていく、誰もが共有できる情報でそれを解決していく、というのが大きな理由であろう（図 3-5-1）。

各プロジェクトについて

〔西浦プロジェクト〕 新型コロナウイルス（コロナ）が流行する前に本プログラムで採択をしていた。実際に感染症数理モデルを使って予防接種指針の改定やHIVの感染症の感染者数の推定、新型インフルエンザのダメージコントロールのための被害想定改定を行った。多くの研究開発プロジェクトが研究開発成果を政策過程に持ち込み実装（政策実装）を試みるものの、なかなかうまくいかないなかで、実際に政策に反映された成功事例の一例である。そうこうしているうちに、西浦先生はコロナ対応において世の中で非常に有名になったという経緯がある。特に、コロナ対策の初期の、クラスター対策において西浦先生のSIRモデルが活用されたのは記憶に新しいのではないかなと思う。

このコロナSIRモデル²⁰が最適化問題だったのかという点については、感染症の拡大リスクの最小化のみを目的としたシンプルなモデルであったことから、実際には必ずしも最適化という問題を含んでいなかったのではないかなという批判もみられた。経済学者からもそのような批判があり、コロナ対策は感染症の拡大だけを抑止すればいいというわけではなく、経済的なダメージの問題やその他にも影響がある中で、感染リスクの最小化と経済的な影響を統合する視点が求められるようになった。そういう意味で、SIRモデルの修正をする形でSIRマクロモデルが、特に経済学者から提供されたという経緯がある。

〔仲田プロジェクト〕 実際に緊急事態宣言の解除、あるいはオリンピックの開催のダメージの予測という観点で東京大学の仲田先生らが上述のSIRマクロモデルを使って分析をした結果が、実際に内閣官房ほかで使われたという経緯がある。一方で、ユニークな点として、仲田プロジェクトは当初感染症対策と経済活動の統

20 SIRモデルは感染症の流行プロセスを説明する基本的な数理モデルのことである。（横田智巳のホームページ、「感染症の数学予測モデル（SIRモデル）」, <https://www.rs.kagu.tus.ac.jp/~yokota/sir.html>（アクセス2025年7月17日））

合モデルの開発を志向していたが、実際に政策現場との対話のなかでそうした複合的かつ複雑なモデルではなく、より簡便なモデルが期待されていることを認識し、より政策目的ごとの個別的なモデルにシフトしたという経緯がみられた。最適化問題の実装を考える上でこの点は重要な示唆となるのではないかと。

〔貝戸プロジェクト〕インフラマネジメントに関するものである。これまで目と耳で点検していたインフラの補修・管理の点検データをたくさん蓄積しておいて、そうしたビッグデータをもとにある意味で優先順位付けをするようなモデリングをしていく。統計的な劣化予測のモデルに基づいて、実際の点検データの蓄積から解析を行うことで、行政あるいは事業者がどのインフラから優先順位を付けて補修していけばいいのかを実際に判断するための意思決定支援モデルを作るという研究が行われた。こちらも実際に行政や事業者の施策に活用されている状況にある。

〔古田プロジェクト〕複合的相互依存性に基づく復旧シミュレーションに関するものである。大規模災害が発生した時に、個別の事業者がそれぞれの最適な行動を目指して復旧シミュレーションを作るが、電力、石油、道路、上下水道、電話などはいろいろな部分で相互に依存するのである。

とりわけ道路については、例えば水道管を補修しようと思っても、道路が寸断されては補修できないということになるので、当然ネットワークをきちんと理解した上で、どこから優先順位を付けて補修すべきなのかを考えなくてはならない。社会全体でより早く復旧を達成するためには、どこから手を付けるべきなのかをシミュレーションする必要がある。これはシミュレーションモデルとしては非常に面白くもあつたし、社会的にも意義があると思われるものではあつたが、実際にモデルを使用するカウンターパートがみつからないなどの課題もあり、残念ながら実際には政策としては活用されていないという例になっている。

〔香坂プロジェクト〕人口が減少していく中で、農地や林地の耕作放棄地が増えていく。どのようにすれば実際にコミュニティーでその耕作放棄地を使うのか、もしくは使わないのか。戦略的に利用・管理する、あるいは放棄するべき土地を判断していくためのワークフローを実際の都市を取り巻く将来的な環境変化を評価しながら決定していく。実際に、シミュレーションを行った上で、そのモデルに基づいて予測された結果をコミュニティーで共有し、ワークショップを行うことで丹念にコミュニケーションを積み重ねていく。時に感情的な議論に陥りがちなタフな議論において、科学的な知見を提示することで合意形成を可能とする。こちらも実際に現場における新たな課題設定を可能としているプロジェクトである。

科学的知見が活用されるための条件

実際に科学的知見が使われるための条件が幾つか存在することが分かる。「政策のための科学」プログラムでは、以下の六つを条件として整理している²¹。

- ① 「政策」 および政策実務に関する基本的理解の必要性
- ② 信頼感のある良質な関係性の構築
- ③ 政策担当者による研究開発成果の有効性の認知
- ④ 学術的に質の高い研究成果の創出と評価の獲得
- ⑤ 中間人材・中間組織によるコミュニケーションの媒介
- ⑥ 二つの異なる「エビデンス」の認識

21 黒河昭雄「政策実装型研究開発に求められる要件についての研究」研究・イノベーション学会一般講演要旨、第36回、2021年10月。

これについては海外の研究でも同じような結果（八つのアドバイス²²）が得られている。

- (1) 高品質の研究を行う
- (2) 研究を関連性があり、読みやすいものにする
- (3) 政策プロセスを理解する
- (4) 政策立案者にアクセスしやすくなるよう努める
- (5) 問題提起者として振る舞うか、公正な仲介者として振る舞うかを決定する
- (6) 政策立案者との関係を築き、基本的なルールを確立する
- (7) 起業家精神を持つか、そのような人物を見つける
- (8) 自分の関与を継続的に反省する（参加するべきか、参加を望んでいるか、効果があるか）

逆にいうと、こうした条件が満たされていない場合には、どれだけ良い成果、アカデミアの中で高い評価を受けた研究であったとしても、実際には社会において受容されないということになる。ここまでで申し上げたプロジェクトは、成功例4、失敗例1である。「政策のための科学」プログラムでこれまで採択してきたプロジェクトは全件で52件あるが、その中で成功しているのはごくわずかである。

ごくわずか成功例については、上述の八つのアドバイスは全て満たしている。これらを満たしていない場合には、ほとんどが失敗をするということになる。六つの条件と八つのアドバイスで共通することは、研究をステークホルダーが理解可能な形に翻訳することや政策に関する基本的な理解があること、あるいは政策担当者とのリレーションシップマネジメントもしくは能動的に責任を持って関与していく意思があることである。

注意したい点は、受容側にはさまざまな事情やニーズ、資源制約やコンテキストがあるということである。そこには、不確実性やタイムリミット、多様な利害関係や組織資源の限界がある。特に政策という観点になれば、例えばコロナ禍のような危機の場合には、ロバスト性というよりもリアルタイム性のほうが圧倒的に優先をされる。このような場合は、正確な予測よりも取りあえず目の前の判断が可能となるような暫定的な情報のほうが求められるところがある。

そのような意味では、最適化問題を考える時にさまざまな受容側の事情をどれだけ考慮できるかが重要となる。一方で、そもそもこうした要素を最適化問題においてきちんと考慮することができるのかという点は、技術的な問題もあるように思う。例えば、実際の意思決定において、これはおそらく最適化問題の外部要因になることもあると思うが、ゼロベースで意思決定することはほぼない。基本的に意思決定というのは常に経路依存的であり、常に前例を踏襲や増分に対する対応が中心となる（インクリメンタリズム）。これは、実際の意思決定で変更できる幅がごく小さいことを意味する。こうした実際の意思決定を取り巻く環境を理解した上で、それを考慮したデザインをする必要があると思う。

まとめ

最適化技術を普及するためには、問題解決のための科学としての精度を上げていくということだけではなく、これが実際に受容されるためのさまざまな知見が必要である。図3-5-2では、「問題解決のための科学」と「政策コミュニケーションに関するナラティブ」と書いているが、このナラティブも同時に研究を深めていく必要がある。後者のナラティブの部分は、必要十分条件でいけば、十分条件であろうと考えている。最適化問題の実装や普及のためには、それを実践していくような社会実験が同時に今求められるのではないかと考えている。

22 Oliver, Kathryn, and Cairney, Paul. "The dos and don'ts of influencing policy: a systematic review of advice to academics." *Palgrave Communications* 5.1 (2019): 1-11.

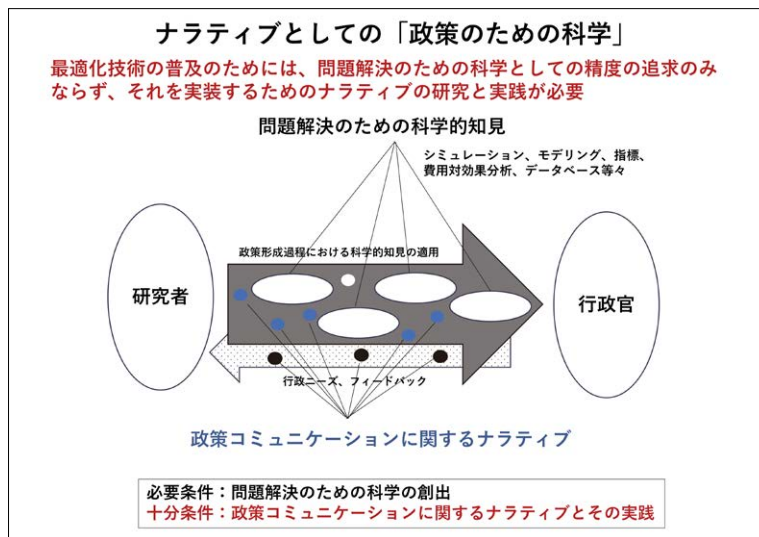


図3-5-2 ナラティブとしての「政策のための科学」

質疑

吉脇：八つのアドバイスのうち、政策立案者とうまく関係を築くということがある。例えば、政策ではなく、社会を相手にうまく関係を築くということに関して、これまで出てきたプロジェクトでは、どのようにされていたか。

黒河：インフラマネジメントのプロジェクトに関して申し上げますと、事業者側がどのようなニーズを持っているのかをあらかじめ聞いておいて、それを研究の初期のデザインから組み込んでしまうことを行った。ただ、その手前には関係性構築としては、どのように関係性を持つのかということがあるが、例えば、さまざまな場面で接点ができた時に、そこでもう一歩踏み出すためには例えばボランティアに解析をしてみて結果をフィードバックするなどの工夫がなされていた。実際に共同研究契約を行う前に、信頼を獲得するためには自分の貢献可能性があるということを相手に手弁当でも示していく必要がある。

これは西浦先生のプロジェクトも同じである。厚労省内において感染症数理モデルがほぼ認知されていなかった中で、予防接種指針の改定などに結びつけるためには、厚労省内を歩き回って感染症数理モデルの貢献可能性を粘り強く説いて回られたと聞いている。場合によっては、ボランティアな協力を行うことで初めて関係性構築につながっていったとのことである。そこまでのエフォートを割けるかという点は、自分で割るか、もしくは自分だけでできなければ、信頼できる仲間にそれをやらせてもらうかということになると思う。

3.5.2 話題提供：最適化研究と国際的観点について

土谷 隆（政策研究大学院大学）

最適化研究について

現在は政策研究大学院大学に所属していて、その前は統計数理研究所に勤めていた。研究としては最適化を中心に行ってきた。ただ、それにとどまらず、新型コロナの流行予測など、モデリング・数理・アルゴリズムについてできるだけ幅広く研究を行うよう心掛けてきたつもりである。そしてそれは、統計数理研究所では、モデリング・数理・アルゴリズムについて幅広く研究を行おうというカルチャーがあったからだと思う。実際、赤池情報量規準（AIC）で知られる赤池先生は「統計科学の研究者は（モデリング・数理・アルゴリズムを研究するという意味で）人の3倍研究しないとイケない」とおっしゃっていた。自分はそれができていると思わないが、そのようなカルチャーがあった。

最適化がJSTのトピックとして取り上げられることは素晴らしいと思っている。統計数理研究所が先端的であったと思う点は、1980年代に予測制御研究系があり、そこで予測と制御と最適化を研究していた。予測については、現在小谷先生が総括をされているCRESTで、その予測中心の数理のものが行われているので、それに続いて、最適化もぜひと思う。

人々が究極的にやりたいことは結局、予測であり、そして予測ができれば最適化である。データサイエンスは予測であるし、最適化はそれを受けてのデザインサイエンスである。したがって、この両者は一体となってきた。両者の間がボーダーレスになってきているということは、自然な流れと思っている。鈴木先生や武田先生が両方について研究されることは、非常に素晴らしいと思っている。互い幅広い興味を持って研究を行うという立ち位置が大事だと思っている。

大規模な最適化という点では、機械学習に加えて、データ同化がある。台風の予測や海流の気候変動の予測に用いられるものである。データ同化は、偏微分方程式の大規模な最適化問題になる。したがって、大規模な最適化問題として、データ同化についても、これが進歩すれば、世の中に大きく貢献し得る分野と思っている。また、日本では今後、医療や介護などの分野で最適化の本格的活用が大事と思っている。

国際的な観点

自分の経験に基づくと、これから米国と中国のサイエンスとどのように日本が関わっていくかは大事だと思う。米国と中国は対立していると取られがちであるが、意外と中国系の教員やポスドクを通じてつながっていることが多いことが、国際的な研究のネットワークの中に入っていると分かる。

中国は何にでも10倍、人数が存在する。例えば、中国の最適化ソフトウェアのCOPTの研究開発である。少し前にYinyu Yeの退職記念ワークショップに参加して得た情報としては、COPTの研究開発は300人が携わっている。日本やヨーロッパとは人数などの規模が違い、層の厚さを感じた。

また、GPUを使った線形計画問題（LP）の解法で3,000行程度のプログラムでGurobi Optimizerといった最高速のソフトウェアに匹敵する成果が出ている。これも、米国に在籍する中国人の若手研究者が行っている研究である。米国などの海外の学会へ行って感じることは、問題設定が新しく本格的で面白いものが多いという点であり、そこは日本に欠けている部分があると感じている。例えば、オンラインのLP問題はここ10年、15年で流行したが、米国での実際のビジネスと結びついて研究が展開されてきた、というようなことである。

日本は知的資源が限られている。その限られている資源をどこに投入するかという点では「理論を頑張ることが大事」ではないか。昔の日本は確かにそうであった。そうでない方向としては、思いっきり現実と向き合っ

て社会を変えていくという方向もある。加えて上述のオンラインのLP問題など、面白い最適化モデルをビジネスと結びつけて作っていくという研究もできると良い。それを支えるのは問題意識を広く持って広範に連携していくという意識と思う。

3.5.3 総合討議

機械学習と数理最適化の壁

久保：機械学習と数理最適化の間にあまり壁を感じていない。機械学習の最適化が基盤にあり、武田先生のように両方を研究している研究者がいるため、数学的な基礎と原理は同じであるといえる。機械学習、特にディープラーニングの研究者は成果をオープンソースとして公開するが、最適化の研究者は商用利用を前提としあまり公開しない。この点で文化的な違いがあるが、基本的な背景は同じと考えている。

梅谷：2024年7月のInternational Symposium on Mathematical Programming (ISMP) という数理最適化の国際会議に参加したが、機械学習のセッションが非常に多く見られた。したがって、連続最適化を主に研究している研究者はあまり壁を感じていないと思う。一方で、離散最適化は分野が細分化されており、それぞれに専門的な知識が必要なため、機械学習の研究者にとっては取り組みにくい現状があるのではないかと感じる。実務でデータ分析を行う研究者の中には、離散最適化の場面では強化学習を用いるという声もあり、この手も含めて知識が広がっていないことにギャップがあるのではないかと感じる。

土谷：ISMPは、数理最適化の中で最も大規模な会議で、3年ごとに開催される。参加者は1500人程度で、2024年度はモントリオールで実施された。機械学習の大規模学会と同時期に開催されたため、参加者が減少したともいわれている。

吉脇：壁は少しずつ低くなっているという見解で良いか。

土谷：機械学習の研究者であれば誰でも知っていて研究の前提となるような基本的な最適化の成果が、連続最適化の研究でこの10～15年で出ている。連続最適化の優れた研究者は機械学習に非常に大きな貢献をしていると考えている。

データ取得

土谷：データの入手方法に関する議論も大切である。日本人はリスクに対して慎重で、データが誤用されることを懸念する。このため、大量に企業で集められているデータがほとんど外部に出てこないという問題がある。これは、最適化と機械学習のいずれの分野でも心配される状況であると思う。

藤井：企業間では契約を結びデータを利用することがあり、最適化の副次的な効果としてデータが整備されることも経験している。最適化は、データ分析に比べると費用対効果が出たり、効果が予測しやすかったりするので、現場によっては最適化が実施されやすい。そうすると、最適化を行う時にデータを整える必要が生じデータが整備される。その結果、データ分析にも利用可能となる。最適化の副次効果としてそういうこともある。

梅谷：私の会社では産学連携を推進しており、その一環としてデータ提供を検討することもある。データは豊富にあるが、大学に提供する際には個人情報や機密情報の隠蔽のためのクレンジングなどが不可欠で、多くの工数が必要だ。そのため、データ提供側への貢献を求められる。事業担当者は貢献がないと工数を割くことが難しいという事情もあり、このような点に配慮しつつ徐々に取り組みを進めている。

土谷：新しい画期的なビジネスモデルが登場し、データが簡単に利用できるようになれば、データが社会的資産として大いに役立つ機会が増えるのではないかと感じる。

黒河：土谷先生からの医療・介護分野の話に関連して、私の専門分野である医療政策、医療イノベーションにおいて、最近ヨーロッパで可決された「European Health Data Space (EHDS)」という法律がある。従来、医療情報は個人の意思で管理されるべきものであったが、この法律では社会にとって価値ある情報として認識され、二次利用を許可する内容となっている。このような考え方のもと、海外では制度変革が進んでいる。日本も海外に倣い、次の法改正でこの考え方の一部が反映される

ことを期待している。

吉脇：データ取得の問題は、最適化を現実の問題に適用する際の課題の一つであると感じた。

実用と理論のギャップ

吉脇：最適化を現実の課題に適用する際のハードルとして考慮すべきことがあれば伺いたい。

梅谷：企業側に数理最適化の専門家が少ないのが大きな問題だと思う。データ分析の専門知識を持つ人材は企業に増えているが、数理最適化に関する専門知識を持った人材は非常に少ない。需要に対して供給が追いつかない現状があるのではないかと。結局、専門家が不足している点に尽きると考えている。

土谷：一般的には、データサイエンスの中に最適化も含まれていると認識されており、そのため、最適化の結果は機械学習で得られると思われている。

上田：数理最適化は、特に連続的なデータの学習において機械学習と密接な関係を持つが、両者は似て異なる分野でもある。両分野ともに長い歴史を有しているが、現代の機械学習は深層学習を基盤とし、従来とは大きく様相が異なる。深層学習においては、学習理論の重要性が高まっており、その進展は数理最適化へのフィードバックを伴いながら、両者が共進化する構図となっている。機械学習の進展は数理最適化の発展を促進し、一方で、数理最適化の古典的手法が機械学習の文脈で再評価される場面も多い。このように、両者は互いに影響を与え合う良き競合関係にあると考えられる。

土谷：最適化が機械学習と同じように思われる例として、富士通が九大の神山さんたちと研究した保育所の児童割り当ての最適化がある。この発表の時、AIを使って保育所問題が解消されたという報道がなされた。私はデータサイエンスとデザインサイエンスというように対のイメージで言うようにしている。

黒河：細かな違いや流派の違いを理解している人はあまりいないのではないかと感じる。一般的な認識の限りでは、ほとんどが大ざっぱな理解にとどまっているように思う。

導入の壁

吉脇：そういった認識のされ方が、最適化の社会実装を難しくしている可能性はあるか。

黒河：誤認が問題とされるかどうかは議論の余地があると思うが、導入時のハードルとしては期待値のコントロールが難しいという問題がある。提供側が提供できる以上の成果を期待されることがあるため、初期のマッチングが重要であり、最初にアウトプットのイメージと解決可能な課題とを整理して、特に導入時には到達点と成果を双方で合意することが必要である。

最適化がAIと呼ばれることで、誤解が生じるかもしれないが、それによって新たな期待値を得るチャンスでもあると考える。

上田：難しい問いではないと思う。NTTの基礎研にいた頃、ジョブショップスケジューリングの研究で遺伝的アルゴリズムを用いていたが、企業との連携の中で、機械を短時間で頻繁に替えてもらっては困る、というような意見が出ていた。藤井先生が指摘したように、数理最適化の研究として定式化するが、そこにおける条件といったものに、一般的な問題として解いている場合と、現実の応用でKPIを設定して解いている場合で大きなギャップがある。現場の状況を把握し、適切な連携を行わないと、いくらアルゴリズムを作成しても実際に使われないことがある。現場の制約も含めて全部最適化されればいいのだが、既存のアルゴリズムは全部を最適化していないので現場では受け入れられないこともあるという、単純にそれだけだと思う。

梅谷：そのとおりだと思う。実務を知る数理最適化プレーヤーがとても少ないからだということに尽きるのではないかと考えている。そのギャップを埋めることが、アカデミックの人間にはなかなか難しい。実務の側に数理最適化などの専門知識を持った人間を増やすことが割と重要だと思う。

機械学習においては、ここ10年ぐらいで、データ分析側にそのようなプレーヤーが増えているが、それは問題解決のプロセスの順番が影響している。データからモデルを作るのが機械学習で、モデルができてから最適化問題を解くというのが最適化という順番なので、どうしてもデータ分析が前段に来る。そのため、データ分析のプレーヤーが先に増えるのは自然なことだろうと思っている。

土谷：機械学習は予測で評価されるので、予測が当たったか当たらなかったかで済むが、最適化となると最適化されたシステムを実装してその性能で評価されるため、よりハードルが高いと言えるかもしれない。

黒河：もう一つ、受け取り手側の問題もある。最適化に関する知識を持つスタッフがいらないという課題もある。数理モデルを認識し理解できる人も少なく、最適化についての知見が求められている場面でも理解する人がいないことがある。これを克服するには、コミュニケーションの強化が必要である。

実際、今日発表された皆さんも、自分たちの成果である数理モデルを実際に使ってもらおうと思った時に、相当タフなプロセスを経ていると言っている。使う側は、多くの場合、先生方に比べれば素人であるため、そういった人に対してどうコミュニケーションするかが問題である。もちろん、デザインの問題、つまり技術的な問題であると置き換えることもできる。技術的な問題であるとする、現実の複雑な制約条件を全て最適化問題の中に組み入れることができるのかということになる。仮にできないのであれば、できる範囲を明らかにした上で、分かりやすい形でコミュニケーションすることを考えておかなければならない。

藤井：企業においては専門家を入れて解決した後、どう継続するかが課題となる。以前からOR分野でも課題となっているが、機械学習ではMLOpsとして継続的運用が行われている一方、最適化ではそのような例をあまり聞かない。今後、最適化を運用するための知見が必要とされるのではないかと考えている。

久保：最適化のプロジェクトの進め方は、ベテランが自分のノウハウを広めて、いわゆるMLOpsのように最適Opsのような仕組みで進めるべきだと思っている。最初にプロジェクトのゴールを決めたり、マイルストーンを決めたものは最適化しにくい。現実とモデルが違っていたりするので、やってみないと分からない。例えばジョブショップの問題であれば、段取り費用といったセットアップコストを入れてジョブショップを考える必要がある。ジョブショップの研究者ではなく、スケジューリング全般の膨大な論文を読み、ヒアリングした時に段取りの話が出てきたら、それは入れなければいけない、と言えるような幅広い知識を持った最適化の技術者が必要である。

論文を多数書いていてジョブショップに関する研究の世界記録を持っているというのでは、多分駄目である。プロジェクトの進め方についても、古典的なプロジェクトマネジメントでは駄目であり、クライアントを説得しなければならない。決めて進むという昔ながらの方法ではなく、ゴールは途中で変わるということをクライアントのトップ層に理解してもらいながら進めなければ失敗すると感じている。

ラップアップ

吉脇：前半では主に最適化の研究課題について議論し、発表と総合討論が行われた。リアルタイム性、ロバスト性、高次元問題への対応が課題として挙げられたが、課題は複雑に絡み合っていると感じた。一方、安全性など、最適化の範囲を超える問題に対する整備も課題として認識された。後半では導入の壁についての討論が集中し、実用に向けて最適化を導入するには、ゴールが変化する可能性も考慮し、データ取得に対する意識合わせが必要だと感じた。

付録 ワークショップ開催概要

日程：2024年8月31日（土）13:00～16:40

場所：オンライン開催

- (1) 開催挨拶 [5分] 木村 康則 上席フェロー（最適化チーム総括責任者）
- (2) 開催趣旨 [15分] 吉脇 理雄 フェロー（最適化チームリーダー）
- (3) 研究開発課題についての話題提供 [48分 = (発表10分 + 質疑2分) × 4] 招聘者4名
 - ・ハイブリッド最適化1（リアルタイム性）：高野 祐一 氏（筑波大学）
 - ・ハイブリッド最適化2（ロバスト1 + 大規模）：鈴木 大慈氏（東京大学／理化学研究所）、
武田 朗子氏（東京大学／理化学研究所）
 - ・ハイブリッド最適化3（ロバスト2）：小林 和博氏（青山学院大学）
- (4) 研究開発課題についての総合討議 [30分]

招聘者4名 + ディスカッション1名

ディスカッションの話題提供

 - ・産業アプリケーションとアルゴリズム（最適化（量子）、機械学習（ML））藤澤 克樹氏（東京科学
大学）
- (5) 休憩 [20分]
- (6) 研究開発の推進方法についての話題提供 [48分 = (発表10分 + 質疑2分) × 4] 招聘者4名
 - ・先導的研究会について：久保 幹雄氏（東京海洋大学）
 - ・実用に沿った研究開発について：梅谷 俊治氏（株式会社リクルート）
 - ・ソフトウェアツールについて：藤井 浩一氏（株式会社NTTデータ数理システム）
 - ・情報と数理の融合について：上田 修功氏（理化学研究所）
- (7) 研究開発の推進方法についての総合討議 [30分]

招聘者4名 + ディスカッション2名：

ディスカッションからの話題提供

 - ・最適化技術の普及について JST-RISTEX「政策のための科学」プログラムの知見から
黒河 昭雄氏（神奈川県立保健福祉大学/JST-RISTEX）
 - ・最適化研究と国際的観点について 土谷 隆（政策研究大学院大学）
- (8) ラップアップ [5分] 吉脇 理雄 フェロー
- (9) 閉会挨拶 [5分] 木村 康則 上席フェロー

参加者：

本ワークショップを企画・運営するCRDSメンバーと登壇者のほかに19名の参加があった。関係部門に限定したクローズドな開催とし、その内訳は以下のとおり。

- 文部科学省 5名 ● 科学技術振興機構（JST）14名

総括責任者	木村 康則	上席フェロー	システム・情報科学技術ユニット
リーダー	吉脇 理雄	フェロー	システム・情報科学技術ユニット
サブリーダー	高島 洋典	フェロー	システム・情報科学技術ユニット
メンバー	青木 孝	フェロー	システム・情報科学技術ユニット
	の場 正憲	フェロー	システム・情報科学技術ユニット

科学技術未来戦略ワークショップ報告書

CRDS-FY2025-WR-02

社会価値を生み出す最適化の革新

令和 7 年 7 月 July 2025

ISBN 978-4-88890-997-6

国立研究開発法人科学技術振興機構 研究開発戦略センター
Center for Research and Development Strategy, Japan Science and Technology Agency

〒102-0076 東京都千代田区五番町7 K's 五番町

電話 03-5214-7481

E-mail crds@jst.go.jp

<https://www.jst.go.jp/crds/>

本書は著作権法等によって著作権が保護された著作物です。

著作権法で認められた場合を除き、本書の全部又は一部を許可無く複写・複製することを禁じます。

引用を行う際は、必ず出典を記述願います。

なお、本報告書の参考文献としてインターネット上の情報が掲載されている場合、当該情報はURLに併記された日付または本報告書の発行日の1ヶ月前に入手しているものです。

上記以降の情報の更新は行わないものとします。

This publication is protected by copyright law and international treaties.

No part of this publication may be copied or reproduced in any form or by any means without permission of JST, except to the extent permitted by applicable law.

Any quotations must be appropriately acknowledged.

If you wish to copy, reproduce, display or otherwise use this publication, please contact crds@jst.go.jp.

Please note that all web references in this report were last checked on the date given in the link or one month prior to publication.

CRDS is not responsible for any changes in content thereafter.

FOR THE FUTURE OF
SCIENCE AND
SOCIETY



CRDS

<https://www.jst.go.jp/crds/>