

クラウドサービス最適化における強化学習的手法と遺伝的アルゴリズムの比較

小田桐 彩人[†] 升井 洋志[‡]
北見工業大学[†] 北見工業大学[‡]

1. はじめに

現在の研究活動では、必要な機能の確保にクラウドサービスを利用することが一般的になっている。例えば、コミュニケーションにはメールや slack[1]、一般的なクラウドサービスでは AWS[2] などを用いることが考えられる。ただし、それらは個別のサービスを必要に応じて利用する状況であり、共通のプラットフォーム上で統合されたサービス融合環境が必要である。

2. URMS

我々はこれまでクラウドサービスを統合し提供する共同研究環境として統合研究管理基盤システム(Universal Research Management System: URMS)を提唱してきた[3]。

URMS における重要な機能の1つは、研究目的や研究者の要求に応じて自動的にサービスの組み合わせを最適化して研究者に提供することである。本研究では、サービスの組み合わせを最適化するための手法として定量化可能なサービスについて遺伝的アルゴリズム (GA) および強化学習 (RL) による最適化を行い、それぞれの結果について比較・議論を展開する。

実際のパブリッククラウドサービスを参考とし[2]、ストレージ利用における、コストや可用性、通信速度などの違いをパラメータ化して4種類のサービスを設定する(表1参照)。これに対してコストを重視した最適化と可用性を重視した最適化の2つの状況を想定し、各々で最適化した場合を比較する。

3. ストレージサービス最適化

URMS におけるサービスの最適化を考える場合、
Comparison of Reinforcement Learning Methods and Genetic Algorithms for Cloud Service Optimization

[†]Ayato Odagiri
Kitami Institute of Technology
[‡]Hiroshi Masui
Kitami Institute of Technology

対象となるサービスが定量化可能かどうかという点から2種類に分けられる。1つ目は定量化可能なサービスの組み合わせ最適化であり、2つ目は定量化できないサービス、例えば slack や discord などのコミュニケーションサービスなど与其他サービスとの組み合わせ、の最適化である。

本研究では、定量化可能なサービスの最適化に焦点を当て、クラウドストレージサービスを研究者の要求に応じて最適化を行う。最適化法には GA と RL を使い、それぞれの結果を比較する。

表1. ストレージサービスの各種性能

	コスト(円/GB)	ダウンロードコスト(円/GB)	可用性(%)
サービスA	3.5(*)	0	99.9
サービスB	1.932	1.4	99
サービスC	1.54	1.4	99
サービスD	0.7	4.2	99

(*)3.36円/GB(>50TB)、3.22円/GB(>500TB)

共同研究における研究者の要求を定量化するため、期間を6か月間とし、各月ごとにおける要求要件を以下の表2のように設定する。この要求に従って各月ごとに使用するサービス組み合わせの割合を GA および RL で最適化する。

表2. ユーザーからの要求要件(例)

	容量(GB)	ダウンロード量(GB)	可用性(%)	コスト上限(円)
1ヶ月目	10,000	2,000	99.1	50,000
2ヶ月目	25,000	3,000	99.2	80,000
3ヶ月目	40,000	10,000	99.2	140,000
4ヶ月目	55,000	30,000	99.3	190,000
5ヶ月目	60,000	30,000	99.3	190,000
6ヶ月目	60,000	5,000	99.2	150,000

4. GA と RL

本研究では GA と RL の2つの手法で最適化を行いその結果を比較した。本章では GA と RL それぞれの最適化手法について解説する。

4.1 GA

ストレージサービスの組み合わせ最適化問題はナップサック問題と捉えることが可能であるため、以下の要領で GA での最適化を行う。研究者が毎月ごとに必要とする容量をそれぞれ100分割し、それらをサービス A から D の4種類のサー

ビスの組み合わせとして表現する. サービス A から D を 2 進数にとることで, 100 分割したサービス割り当ては 200bit の文字列として表現される. この 200bit の文字列に対して GA による最適化を適用する.

GA での最適化にあたっては, 初期個体数を 250, 2 点交叉とし, 交叉確率を 80%, 突然変異確率を 20% とした. 他の値における収束値も, 最終的には同じような値に収束していた.

4.2 評価関数

コストと可用性それぞれにおいて評価関数を定義し, GA における個体の評価として利用する. 以下にコストの評価式を示す.

$$cost_eval = 1 - \frac{total_cost}{cost_limit} \cdot \alpha$$

ここで, $cost_eval$, $cost_limit$, $total_cost$ はそれぞれ, コスト評価, コスト上限, 合計コストである. いま α はその評価指数を重要視するかどうかの重み付けとし, コストを重視した評価では $\alpha = 3$, 可用性を重視する場合は $\alpha = 1$ とする. 同様の評価を可用性についても行う.

4.3 RL

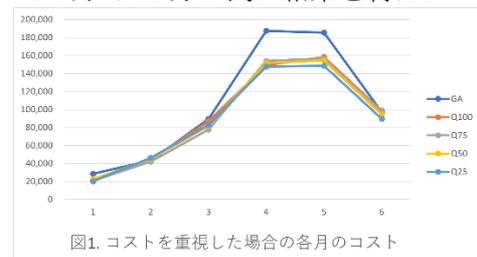
次に RL を用いた最適化手法を考える. RL での学習方法の違いによる変化を見るため, Q-learning, SARSA, Actor-Critic の 3 つの方法を用いて計算し, それぞれの結果を比較した.

RL の環境として, 4 種類のサービスを 6 ヶ月に利用する状況を設定する. これをエージェントが遷移するためのグリッドとして捉え, 4×6 マスのグリッドとして表現する. 縦の 4 コマにサービスの種類を, 横の 6 コマに各月をとるものとする. 研究者の要求する容量は GA と同様に 100 分割する. 分割した各容量を独立したエージェントとしてグリッドを移動させる. 通ったルートはサービスの選択結果とし, 次のエージェントが移動する際の環境として反映される. 100 エージェント分の作業をくり返すことによってサービスの割合を決定する. こうすることで 100 のマルチエージェントではなくシングルエージェントの積み重ねで全体を最適化する. 同様の解析を 25, 50, 75 分割についても行い, 結果を比較する.

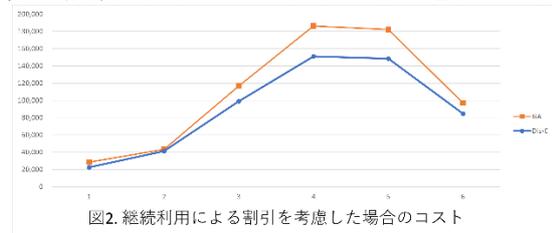
5. 結果と考察

図 1 はコストを重視した最適化を行った場合の結果である. なお図中の Q## は Q-learning による結果で, ## は分割数を表す. コストを重視した場合 2, 6 月を除いて RL による最適化が GA に比べてコストを抑えられていたが, 可用性について

はすべての月で GA 方が良い結果を得た.



次に複数月利用で割引が導入される場合に RL の戦略がどう変化するかを見るため, 「3 か月以上連続で使用する場合コストを 70% に割り引く」という条件を付与する. 単純な GA と比較するため, この条件は RL にのみ実装した. 結果を図 2 に示す. なお Dis-* (* = A, B, C, D) はそれぞれのサービスを 3 ヶ月使用で 70% に割り引くものを表す. 結果として, GA の方がコストが抑えられていた 2 月や 6 月を含め, 全ての月で RL による最適化の結果の方がコストが下回るようになった.



6. まとめ

定量評価可能なサービスに対し GA と RL による最適化を行い, 結果を比較した. 単月ごとの最適化の場合, GA の方がコストならびに可用性の最適化において良い結果となることがあるが, 複数月の割引等, 戦略を立てる上での条件を付与すると, RL が良いという結果を得た. 本研究では RL においてシングルエージェントの積み重ねで最適化を行ったが, マルチエージェントによる相関を考慮した最適化の導入が今後の課題である.

参考文献

- [1] Slack, <https://slack.com/>
- [2] Amazon Web Service (AWS), <https://aws.amazon.com/jp/>
- [3] Hiroshi Masui, Kei Kikuchi, Ren Kurose, Xun Shao, “Concept of a Unified Research Management System and its Application to Data Clustering”. International Journal of Institutional Research and Management. 2019, Vol. 3, No. 2, 2019. 50-61.