

特別研究報告

題目

MAP-Elites アルゴリズムを用いた
予測困難なトラフィック変動に対する適応性を有する
仮想ネットワーク埋め込み手法の提案と評価

指導教員

村田 正幸 教授

報告者

大月 天渡

令和4年2月8日

大阪大学 基礎工学部 情報科学科

MAP-Elites アルゴリズムを用いた予測困難なトラフィック変動に対する適応性を有する
仮想ネットワーク埋め込み手法の提案と評価

大月 天渡

内容梗概

ネットワーク上で様々なサービスが稼働する中で、ユーザーの要求に応じて動的に仮想ネットワークを提供することが求められている。仮想ネットワークを実ネットワーク上の資源にどのように割り当てるかは組み合わせ最適化問題であり、現在の大規模・複雑化したネットワークにおいて既存の最適化手法で現実的な時間で計算するのは困難である。また、ユーザーの要求は動的に変化するため、こうした状況の時間的な変動にも対応可能な最適化手法が求められる。

このような組み合わせ最適化問題をヒューリスティックに解く手法に、生物の進化の仕組みに倣った進化的アルゴリズムがあり、進化的アルゴリズムでは、解を表す個体群を評価値に基づいて選択しながら進化させることで最適化を進める。また、生物の進化においてその個体群の多様性が進化速度に関係していることが知られており、解の多様性を維持するように設計された様々なアルゴリズムが提案されている。

MAP-Elites アルゴリズムはそのようなアルゴリズムの一つであり、本研究では仮想ネットワークへ最適な資源を割り当てる仮想ネットワーク埋め込み問題を MAP-Elites により解く。MAP-Elites の特徴は対象とする問題において注目したい解の特徴量をいくつか選択し、それらを次元とする特徴量空間での多様性を維持する点にある。従来の遺伝的アルゴリズムや多様性に着目したノベルティサーチなどの進化的アルゴリズムを用いた場合と、計算機シミュレーションによる比較を行った。その結果、MAP-Elites アルゴリズムが最も解の探索が速く、また解の探索に成功する割合も高いことが明らかとなった。また、今回対象とした仮想ネットワーク埋め込み問題においては、解の多様性を維持しながら適応度の高い解を探索することが、解の適合度の高さ、発見までの速度にとって重要であることが明らかとなった。

主な用語

ネットワーク仮想化
SDN (Software Defined Networking)
進化的アルゴリズム
遺伝的多様性

目次

1	はじめに	6
2	多様性を維持する進化的アルゴリズム：MAP-Elites	8
3	MAP-Elites アルゴリズムを用いた仮想ネットワーク埋め込み手法	9
3.1	仮想ネットワーク埋め込み問題の定式化	9
3.2	解の符号化	10
3.3	適応度の定義	12
3.4	特徴空間の定義	12
4	シミュレーション評価	14
4.1	比較評価に用いるアルゴリズム	14
4.1.1	遺伝的アルゴリズム	14
4.1.2	局所的な競争を伴うノベルティサーチ	14
4.2	シミュレーション設定	15
4.3	評価指標	18
4.4	評価結果と考察	18
4.4.1	適応度の比較	18
4.4.2	解の多様性と適応度の関係	19
5	おわりに	25
	謝辞	26
	参考文献	27

目 次

1	仮想ネットワーク埋め込みのモデル	9
2	遺伝型の例	11
3	ネットワークモデルの例	16
4	仮想ネットワークの埋め込みの例	17
5	個体群別の適応度の推移	19
6	アルゴリズム別のエントロピーの推移	20
7	特徴空間での個体の分布	22
8	適応度の分布	23
9	資源要求を満たす解の分布	24

表 目 次

1	個体群の設定	17
2	適応度に関する指標	20
3	解の多様性に関する指標	20

1 はじめに

近年、クラウドサービスやIoT技術などの普及が進む中で、ネットワークの仮想化によって柔軟なネットワークをユーザーに提供することが求められている。それに伴い、仮想ネットワークの動的な構築をソフトウェアで制御するSDN (Software-Defined Networking)、およびそれに対応して汎用サーバー上の仮想マシンでネットワーク機能を動作させるNFV (Network Function Virtualization) が重要視されている [1]。一方で、ネットワークの仮想化の実現には複数の技術的課題があり、そのひとつに仮想ネットワーク埋め込み (Virtual Network Embedding:VNE) 問題がある [2]。VNE問題では実ネットワーク上への仮想ノード・リンクの最適な割り当てを考える。正確な最適解を求めるための計算量はネットワークの規模に従って爆発的に増加するため、大規模かつ複雑化した現代のネットワーク上ではヒューリスティックにこの問題を解くことが求められる。さらに、実用上ではユーザーの要求に応じて動的に仮想ネットワークの構造が変動するため、その環境変動に対応して即座に解を導けることが重要である。

このような組み合わせ最適化問題を扱うためのアルゴリズムのひとつに、生物の進化の仕組みをモデル化した進化的アルゴリズムがある。その中でも代表的なものである遺伝的アルゴリズムでは、ランダムに生成された複数の個体に対して、評価値の高い個体を優先的に選択し交叉や突然変異などの操作を繰り返すことで最適化を進める。評価値を算出する関数の特性に依らず最適化問題を扱える特徴から、幅広い分野で応用されている。しかし、このような従来の進化的アルゴリズムでは、多様な生物が見られる自然界と異なり、集団が単一の形態に収束する傾向にあることが知られている。これに対し、自然界の多様性を再現するための手法として、高い新奇性を持つ個体を優先的に選択することで多様性を維持しながら最適化を進めるノベルティサーチが提案されている [3]。新奇性はノベルティと呼ばれる指標で表現され、解空間でその個体に最も近い k 体の別個体に対する距離の平均として定義される。このノベルティと性能の指標が高いものを選択していくことで、解空間上で離れた場所に位置する優れた解をそれぞれ探索することができる [4]。

MAP-Elites (Multi-dimensional Archive of Phenotypic Elites) アルゴリズムは、このノベルティサーチから着想を得た進化的アルゴリズムである [5]。Map-Elitesはその問題において注目したい解の特徴量をいくつか選択し、それらを次元とする特徴量空間で適応度 (評価値) がどのように分布するかを網羅的に計算することを目的としている。特徴量空間をある粒度のセルに分割し、各セルで最も適応度の高い個体 (エリート) をそれぞれ選択していくことで進化計算を進める。セルごとにエリートを計算するため、適応度により淘汰圧がかかるノベルティサーチよりも高い多様性を維持することができ、最終的な適応度の最大値についても比較的高い値が得られることが報告されている。

本研究の目的は、ネットワークに関する組み合わせ最適化問題である VNE 問題について、MAP-Elites アルゴリズムの有効性を明らかにすること、および解の多様性を維持することが最適化および環境変動への適応を促進することを示すことである。また、MAP-Elites では問題に対して注目する特徴量を選択する必要があるため、VNE 問題において多様性の維持に効果的な特徴量を明らかにすることも目的の一つである。

2 多様性を維持する進化的アルゴリズム：MAP-Elites

MAP-Elites [5] は最適化アルゴリズムのひとつであり、高次元の探索空間に対して低次元の特徴空間で最大適応度の分布を可視化できる特徴がある。ユーザーは問題の対象から関心のある特徴を複数選択することができ、MAP-Elites はそれらを軸とする次元の特徴空間をある粒度で分割し、それぞれのセルで最も適応度の高い解を出力することを目的とする。これにより、特徴量と適応度に相関があればその分布を捉えることができる。

また、既存の進化的アルゴリズムと比較して適応度の高い解を求める性能が高い場合があることが報告されている。一般的な進化的アルゴリズムでは特徴空間での近傍を逐次探索するため局所最適に陥り、より高い適応度のピークが離れた空間にある場合にそれを発見できないことがある。これに対し、MAP-Elites は特徴空間のより広い領域で適応度の高い個体を並列的に計算し、それぞれの結果を元に新たな解を生成していくため、このような局所最適に陥ることがない。

MAP-Elites は局所的な競争を伴ったノベルティサーチ [4] に影響を受けて開発された。MAP-Elites では各セルに対して単一の最適な解のみを求める（この解を占有者と呼ぶ）ため、新たに生成された解が既に占有者の存在するセルに属する場合は、その占有者と比較してより適応度の高い解が占有者として残る。この性質は自然界において近傍にいる個体との局所的な競争によって選択が行われることを反映している。

MAP-Elites は以下のステップで動作する。

1. 初期値としてランダムな解（遺伝子型）を G 個生成する。
2. 生成した解集団を特徴空間のセルにマッピングし占有者のみを残す。
3. 解集団から無作為に選択した解に突然変異を適用して新たな解を生成する。
4. 新たな解の特徴量と適応度を計算する。
5. その解が属するセルの占有者と比較して適応度が高ければ入れ替える。
6. ステップ 3~5 を繰り返す。

なお、各セルに対応する特徴量の範囲内に解が存在しない場合もあるため、全てのセルが常に解を持つわけではない。また、そのセルに入る解が存在しても実際には探索できない可能性がある。

3 MAP-Elites アルゴリズムを用いた仮想ネットワーク埋め込み手法

3.1 仮想ネットワーク埋め込み問題の定式化

仮想ネットワーク埋め込み (VNE) 問題はネットワーク仮想化における資源割り当て問題であり、物理ネットワークと仮想ネットワークの2つの実体を対象とする。物理ネットワークはサーバやスイッチなど複数の物理ノードと、それらを接続し物理的なトポロジーを形成する物理リンクから構成され、CPU やリンク帯域などの有限な物理資源を持つ。仮想ネットワークは物理ノード上で動作する仮想ノードと、物理的な経路上に確立される仮想リンクから構成され、仮想的なトポロジーを形成する。

VNE 問題では、これらのネットワークのノードとリンクをどのように対応付けるかを決定する。仮想ネットワーク埋め込みは仮想ノード埋め込みと仮想リンク埋め込みの2つの段階に分けられ、仮想ノード埋め込み (図 1 左) では各仮想ノードにどの物理ノードを割り当てるかを決定し、仮想リンク埋め込み (図 1 右) では各仮想リンクについてそれぞれの端点が埋め込まれた物理ノード間の経路のうち、どの経路を割り当てるかを決定する。このとき、仮想ノードと仮想リンクにはそれぞれ要求された物理資源が割り当てられる必要がある。




図 1: 仮想ネットワーク埋め込みのモデル

本研究では、ネットワークの単純なモデル化として、各ノードとリンクに資源量として正の実数値を割り当てた単純無向連結グラフを用いる。物理ネットワークと仮想ネットワークを表すグラフをそれぞれ P, V とし、それぞれのノードの集合を $N_P = \{n_0^P, n_1^P, \dots, n_{|N_P|-1}^P\}$, $N_V = \{n_0^V, n_1^V, \dots, n_{|N_V|-1}^V\}$ と表す。このとき、仮想ノード埋め込みを条件式 (1), (2) を満たす写

像 $f_N : N_V \rightarrow N_P$ として定義する。

$$\forall n, m \in N_V (n \neq m \Rightarrow f_N(n) \neq f_N(m)) \quad (1)$$

$$\forall n \in N_V (d_n \leq r_{f_N(n)}) \quad (2)$$

ここで、 r_n は物理ノード n の物理資源量、 d_n は仮想ノード n の要求資源量を表す。条件式 (1) は仮想ノード埋め込みが単射であることを表し、仮想ネットワークのトポロジー要求を満たすための必要条件である。また、条件式 (2) は各仮想ノードと割り当てられた物理ノードについて、資源要求を満たしていることを表す。

また、仮想ノード $n_i^V, n_j^V (i < j)$ 間のリンクを $l_{i,j}^V$ 、仮想リンクの集合を $L_V \subset \{l_{i,j}^V \mid i < j \wedge n_i^V, n_j^V \in N_V\}$ 、グラフ P 上の任意の頂点間の全経路の集合を $Path_P$ と表すとす。このとき、仮想リンク埋め込みを条件式 (3), (4) を満たす写像 $f_L : L_V \rightarrow Path_P$ として定義する。

$$\forall l_{i,j}^V \in L_V (f_L(l_{i,j}^V) \in Path_{f_N(n_i^V), f_N(n_j^V)}) \quad (3)$$

$$\forall l \in L_V (d_l \leq \min(R_{f_L(l)})) \quad (4)$$

ここで、 $Path_{n,m}$ は物理ノード n, m 間の経路の集合、 d_l は仮想リンク l の要求資源量、 R_p は物理経路 p 上の物理リンクの残余資源量の集合である。ただし、全経路の集合から埋め込む経路を選択するのは現実的でないため、実際には $Path_{n,m}$ を物理ノード n, m 間の $1 \sim k$ 番目に短い経路の集合としている。条件式 (3) は各仮想リンクが端点に対応する物理ノード間の経路上に埋め込まれることを表し、仮想ネットワークのトポロジー要求を満たすための必要条件である。また、条件式 (4) は各仮想リンクと割り当てられた物理経路について、資源要求を満たしていることを表しており、経路上のボトルネックとなる最小資源量と要求資源量を比較している。

以上の条件式をすべて満たす写像が VNE 問題の解であり、本研究ではこのような解を MAP-Elites アルゴリズムを用いて求める方法について扱う。

3.2 解の符号化

MAP-Elites アルゴリズムを用いて VNE 問題を扱うにあたり、表現型である埋め込みの解を遺伝型に符号化する必要がある。ノード n_i の添え字 i をノードの番号とする。また、仮想リンク $l_{i,j}^V$ の番号を (i, j) が辞書順となるように並べたときの番号とする。各物理ノード間の経路について、短い順かつ同じ長さの時は辞書順に並べたときの番号を経路の番号とす

る。この時、解 f_N, f_L を遺伝型に符号化する写像 enc を次のように定義する。

$$enc(f_N, f_L) = \sum_{i=1}^{|N_V|} num(f_N(n_i^V)) \cdot 2^{d_N(i-1)} + 2^{d_N \cdot |N_V|} \sum_{i=1}^{|N_V|-1} \sum_{j=i+1}^{|N_V|} num(f_L(l_{i,j}^V)) \cdot 2^{d_k(num(l_{i,j}^V)-1)}$$

ここで、 $num(x)$ は x の番号を表し、 d_N は物理ノードの最大の番号を、 d_k は任意の物理ノード間の経路の番号を2進数で表せる最小の桁数である。符号化の例として、図1の解 f_N, f_L を符号化した遺伝型を2進数に表したものを図2に掲載する。なお、図中 $\{i, j, \dots, k\}$ の表記は物理ノード $n_i^P, n_j^P, \dots, n_k^P$ を順に辿るような経路を表し、左の数字はその経路の番号を表す。




図 2: 遺伝型の例

したがって、解を符号化した遺伝型全体の集合は $G = \{g \in \mathbb{Z} \mid 0 \leq g < 2^{d_N \cdot |N_V| + d_k \cdot |N_V| C_2}\}$ の部分集合となるが、単純化のため以降では G を遺伝型全体の集合とする。このとき、集合 G の要素には復号した場合に3.1節の条件式を満たさないものが存在するため、遺伝型を復号した解に基づいて埋め込みを行う際は次に示す規則に基づくものとする。

- 遺伝型を解に復号したときの各番号が最大の番号を超える場合、最大の番号に1を足した値で割ったときの余りを実際の番号とする。例えば、 $num(f_N(n)) > |N_V| - 1 (n \in N_V)$ であるとき、 $num(f_N(n)) = num(f_N(n)) \bmod |N_V|$ とみなす。
- $f_N(n_i^V) = f_N(n_j^V)$ となるような $i, j (i < j)$ の組がある場合、 $f_N(n_i^V)$ の埋め込みを有効なものとして、 $f_N(n_j^V)$ の埋め込みは行わない。また、このとき n_j^V を端点を持つ仮想リンクについても埋め込みは行わない。
- $l_{i,j}^V \notin L_V$ であるとき、それに対応する遺伝型の部分は無視する。
- 要求資源量に対して物理資源量が不足する場合、可能な限り多くの資源を割り当てる。例えば、仮想ノード n の要求資源量に対し、割り当てられた物理ノード $f_N(n)$ の物理

資源量が不足する（すなわち $d_n > r_{f_N(n)}$ ($n \in N_V$) となる）場合、仮想ノード n には $r_{f_N(n)}$ の物理資源量が割り当てられる。同様に、仮想リンク l の要求資源量に対し、割り当てられた物理経路の物理資源量が不足する（すなわち $d_l > \min(R_{f_N(n)})$ となる）場合、仮想リンク l には $\min(R_{f_N(n)})$ の物理資源量が割り当てられる。

3.3 適応度の定義

進化的アルゴリズムでは、環境に対する表現型の適応度が高くなるように個体群の進化を方向付けることで解の探索を行う。そのため、仮想ネットワーク埋め込み問題の解として適切な表現型ほど高く、そうでないものほど低くなるような値を適応度として定義する必要がある。そこで、解 f_N, f_L の適応度を式 (5) で表される $F(f_N, f_L)$ と定義する。

$$\begin{aligned}
 F(f_N, f_L) &= R(f_N, f_L) - \lambda P(f_N, f_L) \tag{5} \\
 R(f_N, f_L) &= \sum_{n \in N_P} r_n + \sum_{l \in L_P} r_l - \sum_{n \in N_V} \min\{d_n, r_{f_N(n)}\} \\
 &\quad - \sum_{l \in L_V} \min\{d_l, \min(R_{f_L(l)})\} \cdot |f_L(l)| \\
 P(f_N, f_L) &= \sum_{n \in N_V} d_n + \sum_{l \in L_V} d_l - \sum_{n \in N_V} \min\{d_n, r_{f_N(n)}\} \\
 &\quad - \sum_{l \in L_V} \min\{d_l, \min(R_{f_L(l)})\}
 \end{aligned}$$

ここで、 $|f_L(l)|$ は経路 $f_L(l)$ の長さ（経路を構成する辺の数）、 $R(f_N, f_L)$ は残余資源の総量、 $P(f_N, f_L)$ は資源不足に対するペナルティ項を表している。 λ の値を十分に大きくすることで、物理ノード・リンクの資源が不足するような割り当てを行うと適応度の値が大きく低下するため、これを避けるように最適化を進めることができる。また、条件を満たすような解の中でも、残余資源量を最大化するように進化を方向付けることができる。

3.4 特徴空間の定義

MAP-Elites アルゴリズムは各個体の表現型が持つ特徴量からユーザーが選択した複数の特徴量を軸とする次元の特徴量空間上で解を探索するため、解を効率良く探索するにはそれを可能にする特徴量空間を定義する必要がある。遺伝的多様性が進化を促進することが知られている [6] ため、特徴空間での網羅率と遺伝的多様性に正の相関があるような特徴空間を定義したい。本研究では、次のような特徴量を用いて特徴空間を定義した。

物理ノード番号の総和

各仮想ノードに割り当てられた物理ノードの番号の総和。解 f_N, f_L に対して、次式の $Sum_N(f_N, f_L)$ と定義する。

$$Sum_N(f_N, f_L) = \sum_{n \in N_P} num(f_N(n))$$

物理経路の長さの総和

各仮想リンクに割り当てられた物理経路の長さ（経路を構成する辺の数）の総和。解 f_N, f_L に対して、次式の $Sum_P(f_N, f_L)$ と定義する。

$$Sum_P(f_N, f_L) = \sum_{l \in L_V} |f_L(l)|$$

この特徴空間上で異なるセルに属する解は必ず遺伝型も異なるため、この特徴空間上のセルの網羅率と遺伝的多様性にはある程度の正の相関があるものと考えられる。一方で、いずれの特徴量についても単射ではなく、遺伝的多様性を完全に反映する特徴空間として定義できてはいない。

4 シミュレーション評価

4.1 比較評価に用いるアルゴリズム

4.1.1 遺伝的アルゴリズム

遺伝的アルゴリズム (Genetic Algorithm: GA) [7] は生物の進化をモデル化した進化的アルゴリズムのひとつである。集団を構成する個体の持つ遺伝子に変異して環境に適応する過程を模したものであり、具体的には次のようなステップで動作する。

1. 初期値として N 個の個体 (遺伝型) をランダムに生成し、これを現世代とする。
2. 現世代の各個体の適応度を計算する。
3. 適応度に基づいて現世代から個体を選択する。
4. 選択した個体に遺伝的操作 (交叉・突然変異) を適用して新たな個体を生成し、次世代の集団に追加する。
5. ある個体数になるまでステップ 4 を繰り返す。
6. 現世代と次世代を入れ替え、次世代を空にする。
7. ステップ 2~6 を繰り返す。

シミュレーションではステップ 3 での選択は選択確率が適応度の値に比例するルーレット選択方式を適用し、またステップ 4 での交叉は二点交叉、突然変異は無作為に選択した一か所の遺伝子座の値を反転させるものとする。なお、ここで遺伝子座とは遺伝型を 2 進数で表したときの各桁にあたるものとする。また、個体群の最大適応度を安定化させるため、各世代での最初のステップ 3 ではエリート選択を行うものとしている。

4.1.2 局所的な競争を伴うノベルティサーチ

局所的な競争を伴うノベルティサーチ (Novelty Search with Local Competition: NSLC) [4] は、解の新奇性 (ノベルティ) に明示的に報酬を与える進化方法であるノベルティサーチ [3] に、実世界における生物進化の特徴である局所的な競争の仕組みを反映させたアルゴリズムであり、ノベルティと局所的競争力の多目的最適化を行う。解の多様性を高く維持しながら異なるニッチに属する適応度の高い解を複数出力することが知られており、MAP-Elites アルゴリズムと同じ QD (Quality Diversity) アルゴリズムに属するとされる [8]。

ノベルティは行動空間における k 近傍の個体との距離の平均であり、個体 x のノベルティは式 (6) 中の $\rho(x)$ で表される。ここで、 μ_i は個体 x に i 番目に近い個体である。また、本研究では行動空間を MAP-Elites の特徴空間と同一とし、特徴空間上でのユークリッド距離を個体間の距離と定義した。

局所的競争力は行動空間における k 近傍の個体群中での相対的な適応度と定義し、個体 x の局所的競争力は式 (7) 中の $C(x)$ で表す。ここで、 $F(x)$ は個体 x の適応度、 $O_k(x)$ は個体 x の k 近傍の個体の集合を表す。

シミュレーションでは、文献 [9] を参考にエリート選択を行う GA の評価値にノベルティと局所的競争力の重み付け和（式 (8) 中 $E(x)$ ）を用いることで、解の多様性と適応度の多目的最適化を行うモデルを比較対象として用いた。

$$\rho(x) = \frac{1}{k} \sum_{i=1}^k \text{dist}(x, \mu_i) \quad (6)$$

$$C(x) = \frac{F(x) - \min_{i \in O_k(x)} F(i)}{\max_{i \in O_k(x)} F(i) - \min_{i \in O_k(x)} F(i)} \quad (7)$$

$$E(x) = (1 - w)\rho(x) + wC(x) \quad (8)$$

4.2 シミュレーション設定

シミュレーションに用いるネットワークモデルには、各ノード・リンクごとに正の実数値の資源量を割り当てた単純連結無向グラフを用いる。物理ネットワークはノード数を 32 に固定してランダムにトポロジーを生成し、対数正規分布に従う乱数を資源量として各ノード・リンクに割り当てる。仮想ネットワークは資源要求を満たす埋め込みが存在するようにするため、次のような手順で生成する。

1. 仮想ネットワークのトポロジーをランダムに生成する。
2. 各仮想ノード n_i^V について、物理ノードの集合 N_P から無作為に重複なく抽出した物理ノードを $f_N(n_i^V)$ とする。
3. 物理ノード $f_N(n_i^V)$ の資源量を仮想ノード n_i^V の資源要求量とする。
4. 各仮想リンク $l_{i,j}^V$ について、他の仮想リンクに対応する経路との辺の重複がないように $\text{Path}_{f_N(n_i^V), f_N(n_j^V)}$ から選んだ経路を $f_L(l_{i,j}^V)$ とする。
5. 経路 $f_L(l_{i,j}^V)$ 上の物理リンクの資源量のうち最小の値を仮想リンクの資源要求量とする。

この手順に従って生成した仮想ネットワークは少なくとも資源要求を満たす解 f_N, f_L を持つため、シミュレーションにおいて資源要求を満たす解が存在しない場合を排除できる。以下のシミュレーションでは、仮想ノードの数を5に固定した上で上記の手順に従い仮想ネットワークを生成してシミュレーションを行っている。生成されたネットワークの例を図3に、また解として適切な埋め込みの例を図4に示す。

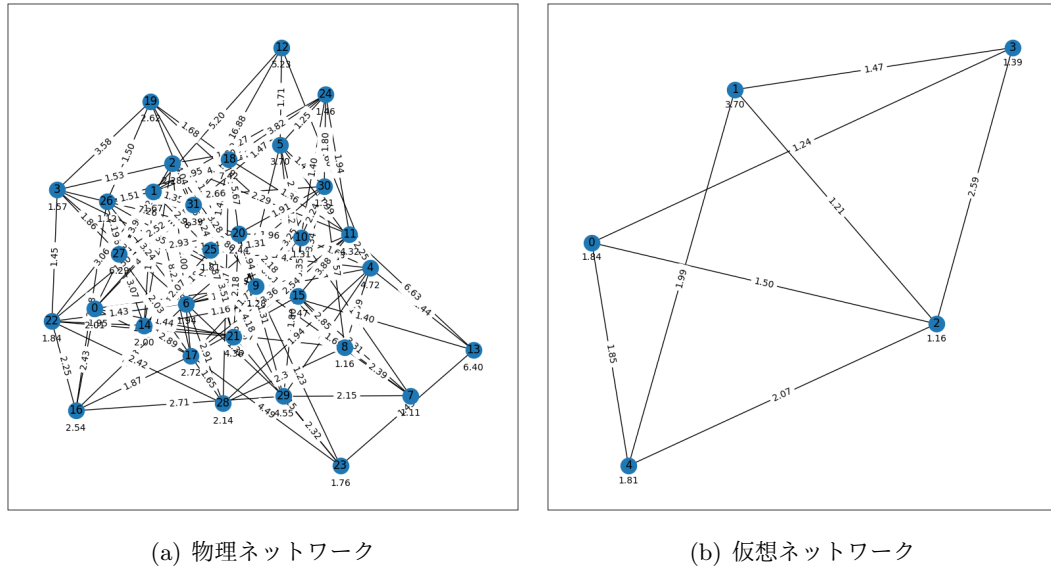


図 3: ネットワークモデルの例

なお、任意の物理ノード間の経路は k -shortest path アルゴリズム [10] を用いて事前に8本計算し、仮想リンク埋め込みではこれらのうちのどの経路を仮想リンクに割り当てるかを決定する。

また、環境変動への適応性を検証するため、100世代ごとに仮想ネットワークを上記の手順に従い繰り返し生成する。各シミュレーションではこの環境変動を9回行うものとし、4.4節では計10回のシミュレーションを行った結果について記す。

シミュレーションでは表1に示す各集団について、同一環境内で並行して進化計算を行う。その際、集団の大きさによる不公平が生じないように、アルゴリズムの都合上集団の大きさが必ず動的になる MAP-Elites の個体数に合わせて GA 群では次世代の生成を行うものとする。また、初期化時にランダムに生成する個体数は100とする。

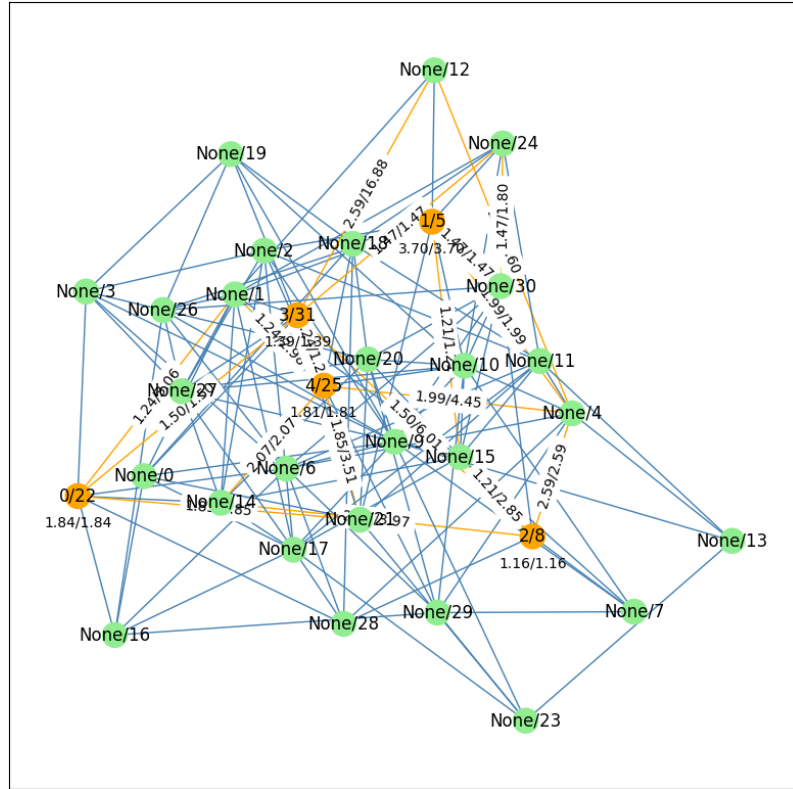


図 4: 仮想ネットワークの埋め込みの例

表 1: 個体群の設定

個体群	アルゴリズム	突然変異率	交叉率	局所的競争力の重み
ME	MAP-Elites	(100%)	-	-
SGA1	GA	1%	90%	-
SGA2	GA	100%	90%	-
NSLC1	NSLC	10%	90%	0.2
NSLC2	NSLC	10%	90%	0.5

4.3 評価指標

解の多様性

今回実施したシミュレーションでは物理ノード数を 32、物理経路の数を 8 としているため、埋め込みの解と遺伝型は一意に対応している。このため、埋め込みの解の多様性は遺伝型の多様性として測ることができ、集団全体の情報エントロピーを指標として用いることができる [6]。しかし、遺伝型全体の集合 G の大きさに対しシミュレーション上での集団の大きさが極めて小さく、通常の情報エントロピーを用いることが難しいため、遺伝子座ごとに計算したエントロピーの総和 [11] を解の多様性の指標として用いることとした。個体群 $X (\subset G)$ の解の多様性は式 (9) 中の $D(X)$ で表される。ここで、 $b_i(x)$ は遺伝子型 x を 2 進数で表したときの i 桁目の数字を表し (すなわち $b_i(x) \in \{0, 1\}$)、 $p_i(X)$ は個体群 X 中で $b_i(x)$ が 1 である確率を表す。

$$D(X) = \sum_{i=1}^{d_N \cdot |N_V| + d_k \cdot |N_V| C_2} \{p_i(X) \log p_i(X) + (1 - p_i(X)) \log(1 - p_i(X))\} \quad (9)$$
$$p_i(X) = \frac{1}{|X|} \sum_{x \in X} b_i(x)$$

4.4 評価結果と考察

4.4.1 適応度の比較

シミュレーションを通じた個体群内の最大の適応度は図 5 のように推移する。100 世代ごとに生じる環境変動によって急激な減少、または増大を繰り返すようなグラフとなっており、各環境内では適応度が徐々に増加していることが確認できる。図中の target は仮想ネットワークの生成時の手順で構成した埋め込みを行った場合の適応度であり、これを超える適応度を持つ解は基本的に資源要求を満たす。MAP-Elites を用いた個体群が target を環境内で超える回数が最も多く、また超えるのにかかる時間が平均的に短いことが分かる。

また、全シミュレーションでの各環境について適応度に関する指標を表 2 にまとめた。max・min は各環境での最大・最小適応度の平均、achievement は各環境内で資源要求を満たす解を出力できた割合、place は資源要求を満たす解を速く出力した順位 (探索できなかった場合は最下位とする) の平均である。動的環境における VNE 問題において資源要求を満たす解の探索効率が重要となるが、max と achievement、place はその指標と見ることができ、いずれも MAP-Elites が最も良い値を得ている。また、min は環境変動に対する耐性の指標と見ることができ、これについても MAP-Elites が最も高い値を得ている。これらのことか

ら、動的環境におけるネットワーク埋め込みを行うアルゴリズムとして、MAP-Elites が比較的有効に働いていることがわかる。




図 5: 個体群別の適応度の推移

4.4.2 解の多様性と適応度の関係

各アルゴリズムでのエントロピーの推移を図6として掲載する。MAP-Elites では解の多様性が高く維持されていることがわかる。また、突然変異率を高く設定したGA と、ノベルティの重みを大きくした NSLC においても解の多様性が比較的高く維持されている。

また、シミュレーションで得られた解の多様性に関する指標を表3に掲載する。entropy は遺伝子座ごとのエントロピーの総和、coverage は特徴空間上のセルの網羅率、achievers は資源要求を満たす解の数を表す。

また、特徴空間で個体がどのように分布しているか表すヒートマップを図7, 8, 9として掲載する。MAP-Elites では他のアルゴリズムと比較して適応度の高い個体が特徴空間で広く分布しており、またその結果として資源要求を満たす解についても広い範囲で探索できて

表 2: 適応度に関する指標

	ME	SGA1	SGA2	NSLC1	NSLC2
max	363.5	223.7	348.3	341.9	335.4
min	256.7	96.9	166.2	140.9	194.9
achievement(%)	78.0	15.0	47.0	31.0	56.0
place	1.7	4.5	3.6	4.3	3.1




図 6: アルゴリズム別のエントロピーの推移

表 3: 解の多様性に関する指標

	ME	SGA1	SGA2	NSLC1	NSLC2
entropy	34.0	3.9	34.1	26.2	15.8
coverage(%)	68.7	1.6	17.1	33.3	15.9
achievers	18.0	14.4	0.6	0.5	11.3

いることがわかる。SGA2については、エントロピーは高いが個体群の全体的な適応度が低く、資源要求を満たす解に近い個体が少ないために解の探索効率が MAP-Elites に比べて低いと考えられる。また、NSLC1 についてはノベルティの重みが大きいため適応度による淘汰圧があまり働かず、特徴空間で解が広く分布しても適応度の高い個体が探索できていない。一方で、NSLC2 は重み付けを 0.5 に設定しているため、適応度とノベルティの両方を高めるよう進化計算が進んだ結果、適応度の高い個体が比較的広く分布している。

以上のことから、特徴空間上の広い範囲で比較的適応度の高い個体を複数求め、それを元に新しい個体を生成することが解の探索効率を高めていると考えられる。しかし、比較対象である単純な GA では選択後に遺伝的操作を行う必要性から、適応度の高い個体をそのままに残すこと自体が難しく、また NSLC は突然変異率が低くとも多様性を維持しやすいため、適応度の高い個体を多く残すことができるが、一方で突然変異率が低い場合多様性を維持する力は弱まる傾向にある。このため、解の多様性を維持しつつ適応度の高い個体を多く残す能力自体が重要である可能性があり、特徴空間上で広く分布していることと解の探索効率の関係については検討する必要がある。




図 7: 特徴空間での個体の分布

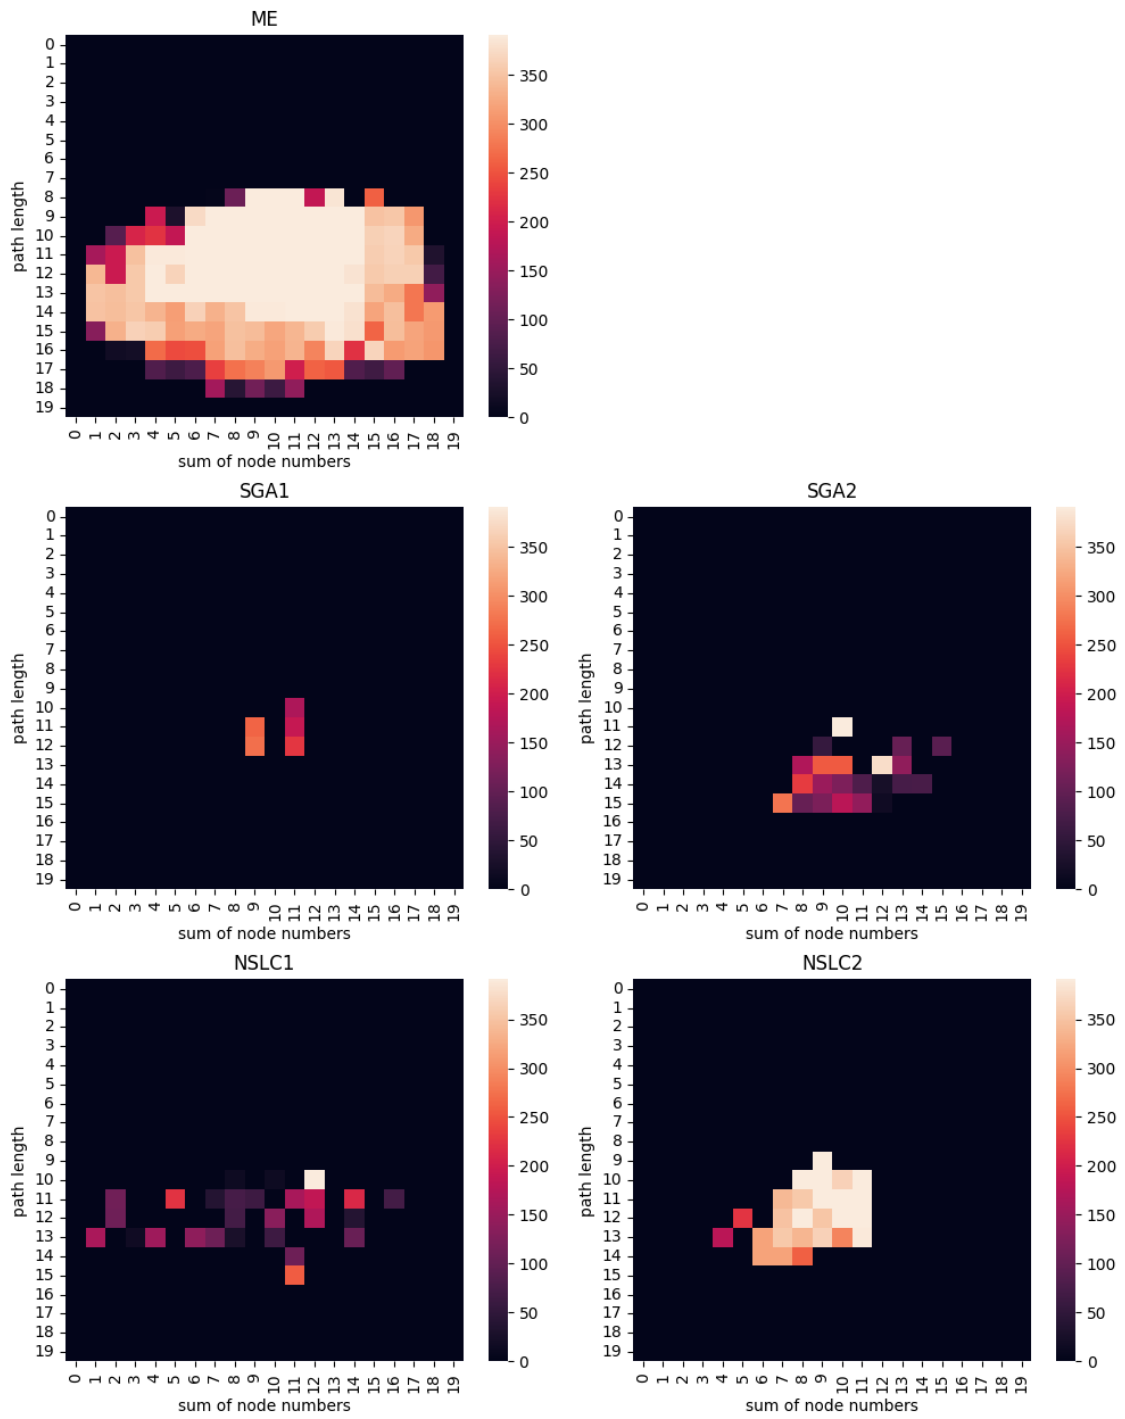


図 8: 適応度の分布

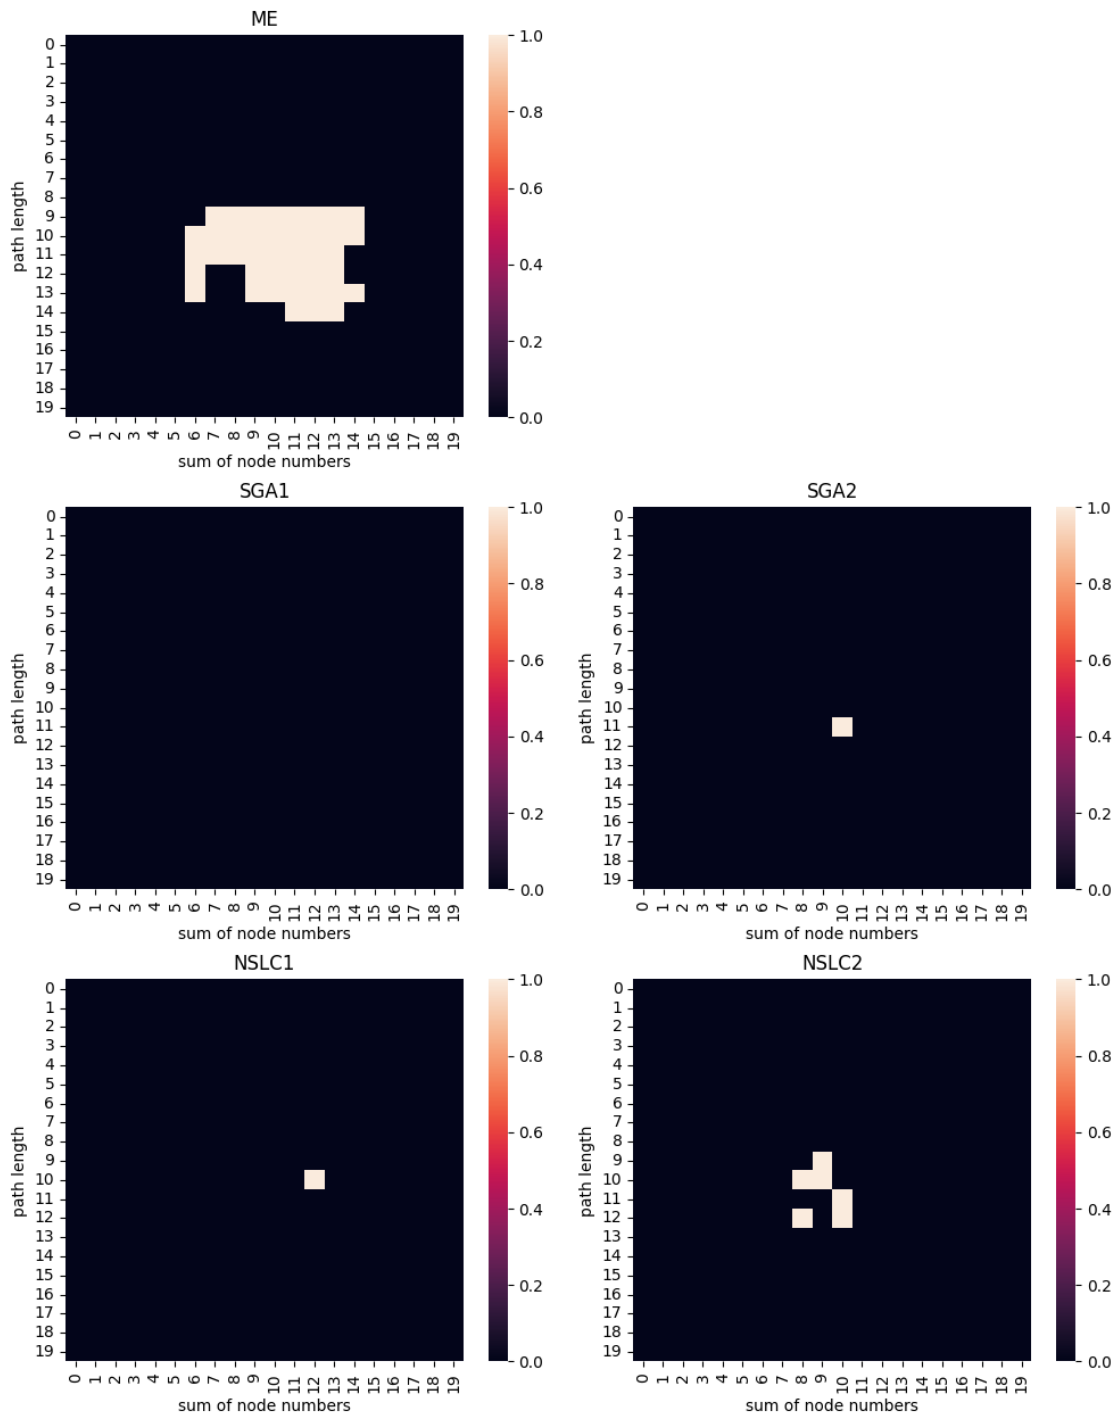


図 9: 資源要求を満たす解の分布

5 おわりに

ネットワーク上で稼働するサービスの普及に伴いネットワーク仮想化技術が重要視されているが、ネットワーク仮想化には様々な実装上の課題がある。その内の一つである VNE 問題について、動的環境に対応できる手法として解の多様性を維持する進化的アルゴリズムである MAP-Elites アルゴリズムを用いた手法を提案した。予測困難なトラフィック変動下で想定されるランダムな仮想ネットワークの要求を行うシミュレーションにおいて、従来の進化的アルゴリズムと比較して MAP-Elites アルゴリズムを用いた手法が環境変動に対する適応性を持ち、有効であることを示した。また、比較対象のアルゴリズムの結果も踏まえ、解の多様性を維持しながら適応度の高い個体を多く残すことが進化的アルゴリズムを用いた手法において重要であることが分かった。一方で、MAP-Elites アルゴリズムの特徴である特徴空間での探索が VNE 問題に対して有効であるかを明らかにすることはできなかった。MAP-Elites アルゴリズムを用いて VNE 問題を扱う上で有効な特徴量を発見し、それらで定義された特徴空間上での探索が有効であるかを明らかにすることが今後の課題である。また、本研究でのシミュレーションでは物理ネットワークおよび仮想ネットワークのトポロジーをランダムに生成したが、より実際のネットワークに近いモデルを用いたシミュレーションによる評価も行う必要があるため、今後の課題とする。

謝辞

本報告を終えるにあたり、大阪大学大学院情報科学研究科の村田正幸教授には、ご多忙の中多大かつ貴重なご指導を賜りましたこと心より感謝いたします。また、平素からご指導くださいました大阪大学大学院情報科学研究科の小南大智助教、大阪大学大学院経済学研究科の大歳達也助教に深く感謝いたします。最後に、様々な面で支えてくださった家族、友人、研究室の皆様には感謝の意を表して謝辞といたします。

参考文献

- [1] I. Jovan, K. Sharif, F. Li, Z. Latif, M. M. Karim, S. Biswas, Y. Wang, and B. Nour, “A survey of network virtualization techniques for internet of things using SDN and NFV,” *ACM Computing Surveys (CSUR)*, vol. 53, no. 2, pp. 1–40, Apr. 2020.
- [2] H. Cao, S. Wu, Y. Hu, Y. Liu, and L. Yang, “A survey of embedding algorithm for virtual network embedding,” *China Communications*, vol. 16, no. 12, pp. 1–33, Dec. 2019.
- [3] J. Lehman and K. Stanley, “Abandoning objectives: Evolution through the search for novelty alone,” *Evolutionary Computation*, vol. 19, pp. 189–223, Jun. 2011.
- [4] J. Lehman and K. O. Stanley, “Evolving a diversity of virtual creatures through novelty search and local competition,” in *Proceedings of annual conference on Genetic and evolutionary computation*, Jul. 2011, pp. 211–218.
- [5] J. Mouret and J. Clune, “Illuminating search spaces by mapping elites,” *CoRR*, vol. abs/1504.04909, Apr. 2015. [Online]. Available: <http://arxiv.org/abs/1504.04909>
- [6] T. Day, “Information entropy as a measure of genetic diversity and evolvability in colonization,” *Molecular Ecology*, vol. 24, no. 9, pp. 2073–2083, Jan. 2015.
- [7] D. Whitley, “A genetic algorithm tutorial,” *Statistics and Computing*, vol. 4, pp. 65–85, Oct. 1998.
- [8] J. K. Pugh, L. B. Soros, and K. O. Stanley, “Quality diversity: A new frontier for evolutionary computation,” *Frontiers in Robotics and AI*, vol. 3, Jul. 2016.
- [9] G. Cuccu and F. Gomez, “When novelty is not enough,” in *Proceedings of European Conference on the Applications of Evolutionary Computation*. Springer, Apr. 2011, pp. 234–243.
- [10] J. Y. Yen, “Finding the k shortest loopless paths in a network,” *Management Science*, vol. 17, no. 11, pp. 712–716, Jul. 1971.
- [11] N. Mori, J. Yoshida, H. Kita, and Y. Nishikawa, “A thermodynamical selection rule in the genetic algorithm,” *Transactions of the Institute of Systems, Control and Information Engineers*, vol. 9, no. 2, pp. 82–90, Feb. 1996.