2026/4/2

# 動的環境下でのネットワークスライス埋め込み問題に対する量子遺伝子制御ネットワークを用いた最適化手法の評価

関澤 和希[1], 山内 雅明[1], 小南 大智[2], 下西 英之[3], 大歳 達也[4], 村田 正幸[1,3]

[1]大阪大学 大学院情報科学研究科

[2]大阪大学 先導的学際研究機構

[3]大阪大学 D3センター

[4]大阪大学 大学院経済学研究科

大阪大学
THE UNIVERSITY OF OSAKA

# 研究背景



- 環境変動に対して自律的に適応可能なネットワーク制御手法が求められている
  - 5G および Beyond 5G/6G ネットワークでは、多様なサービス要求に対して動的な環境下で通信制御を行うことが求められている[1]
    - 通信帯域や計算資源、遅延制約といった制御条件が継続的に変化
    - 安定した性能を維持することが難しい

- 上記課題に対し、生物の進化適応能力に着想を得た手法の研究を進めてきた
  - 遺伝子制御ネットワーク (GRN: Gene Regulatory Networks) に着目[2]
    - GRN: 遺伝子型から表現型が生成される過程において、両者を結びつけるネットワーク構造
      - 遺伝子型: 生物のDNAに保存された情報
      - 表現型: 細胞や器官といった形態的特徴

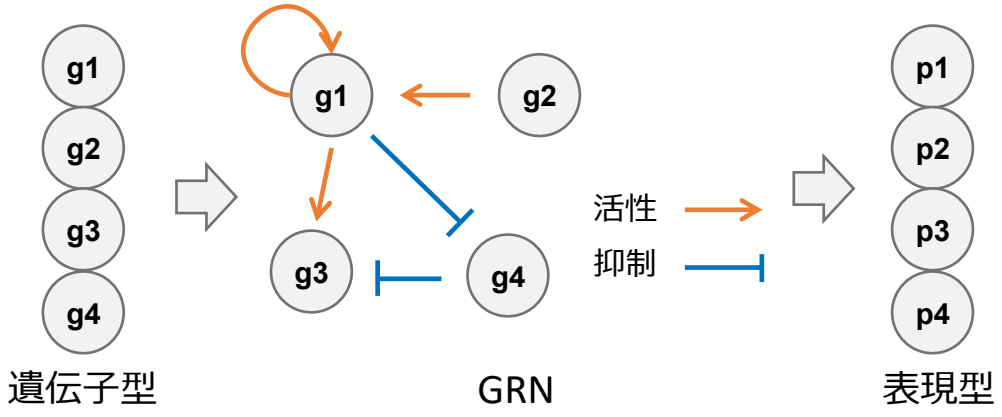


図1: GRNモデル

[1] NGMN, “6G requirements and design considerations,” White paper, NGMNalliance- white paper, Feb. 2023. Accessed: 2025-12-24.
[2]S. Inoue, M. Yamauchi, D. Kominami, H. Shimonishi, and M. Murata, “Genetic algorithm with gene regulatory networks based optimization method for distributed video analysis system,” in Proceedings of 27th Conference on Innovation in Clouds, Internet and Networks (ICIN), pp. 257–264, Mar. 2024.

# GRNの特徴とネットワーク制御への応用



- GRNの生物学的特徴
  - GRNが特定の表現型を高い確率で発現する構造へ変化し、表現型を記憶する
  - 複数の表現型の特徴を構造的に学習する

- ネットワーク制御への応用
  - 最適なネットワーク制御パラメータの記憶を促して環境へ適応させる
  - 複数環境のネットワーク制御パラメータの特徴を学習する
    - 最適制御となるネットワーク制御パラメータを事前に記憶させたGRNを用いて、記憶した環境と類似した環境への高速な再適応が可能[2]

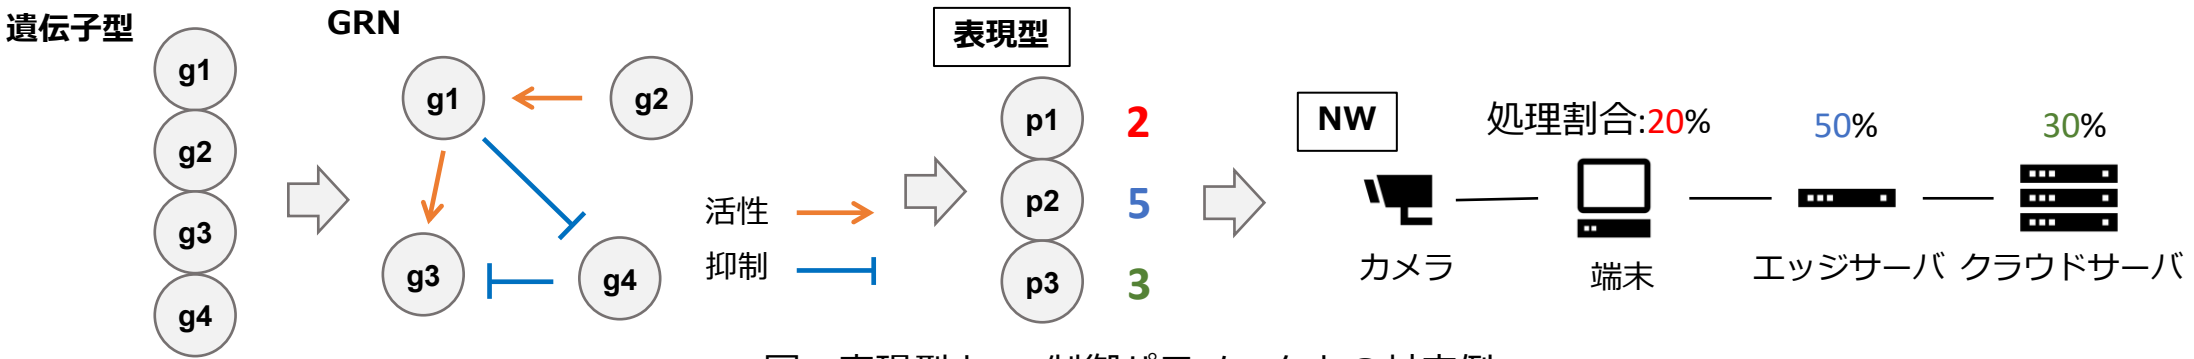


図2: 表現型とNW制御パラメータとの対応例

[2] S. Inoue, M. Yamauchi, D. Kominami, H. Shimonishi, and M. Murata, “Genetic algorithm with gene regulatory networks based optimization method for distributed video analysis system,” in Proceedings of 27th Conference on Innovation in Clouds, Internet and Networks (ICIN), pp. 257–264, Mar. 2024.

# 既存研究の課題とQGRNを用いたアプローチ



- 既存研究の課題[2]
  - 動的な環境変動を伴う問題に適用する際、事前に時間をかけて学習済のGRNモデルを用意
    - 遺伝子型と表現型が一対一に対応する構造を有する
    - 複数の表現型を記憶させるには学習プロセスを繰り返す必要があり、モデル構築に時間を要する

- 量子遺伝子制御ネットワーク (QGRN: Quantum Gene Regulatory Networks)[3]
  - 遺伝子間の相互作用を量子ゲート演算として表現したGRNモデル
    - 一つの遺伝子型に対して、複数の表現型を**確率分布**として扱うことが可能
    - 量子コンピュータに適用可能なモデルであるため、
      将来的には高速な計算が期待できる

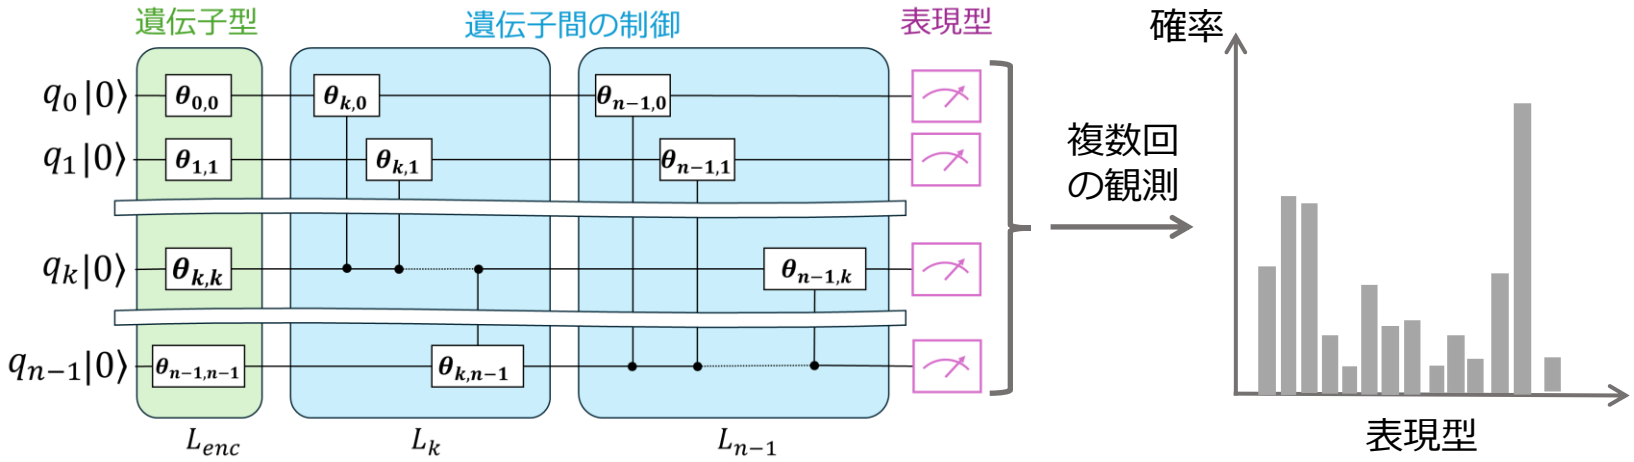


図3: QGRNの数理モデル

[2] S. Inoue, M. Yamauchi, D. Kominami, H. Shimonishi, and M. Murata, “Genetic algorithm with gene regulatory networks based optimization method for distributed video analysis system,” in Proceedings of 27th Conference on Innovation in Clouds, Internet and Networks (ICIN), pp. 257–264, Mar. 2024.
[3]C. Roman-Vicharra and J. J. Cai, “Quantum gene regulatory networks,” npj Quantum Information, vol. 9, July 2023.

# QGRNを用いた最適化アルゴリズム



- 最適化問題に対して適応度の高い表現型を発現するQGRNを構築

遺伝的アルゴリズム (GA)

**遺伝子**に対して
遺伝的操作を適用

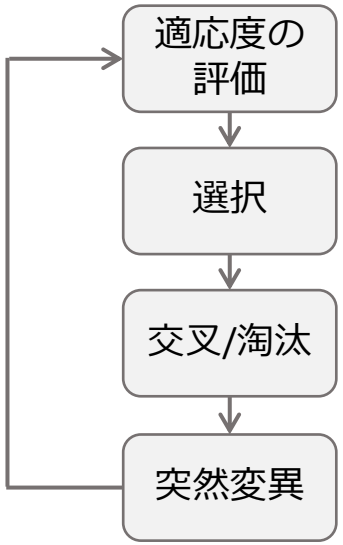


GAの拡張

QGRNアルゴリズム

**QGRN個体**に対して
遺伝的操作を適用

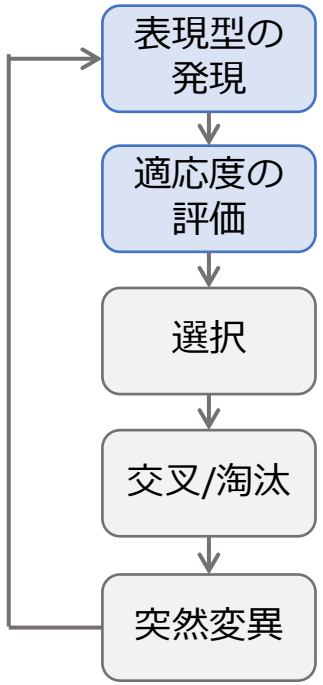


QGRN個体から**表現型確率分布**を取得

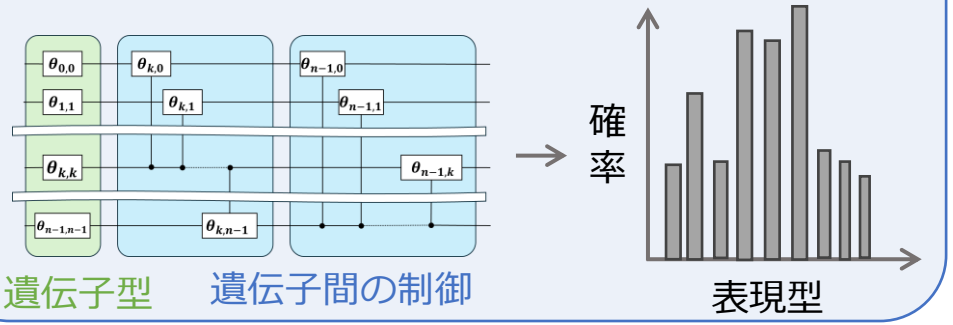


1. 高確率で発現した表現型を目的関数に適用し、表現型の適応度を評価
   - 最良解をNW制御に適用

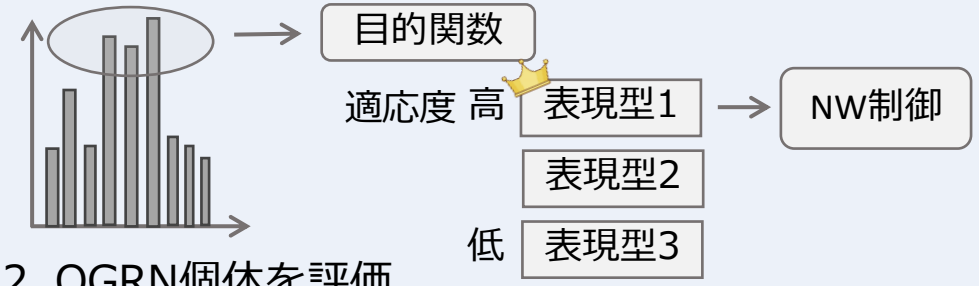


2. QGRN個体を評価
   - Fitness関数を用いる

# 2025年5月NS研究会での発表内容と課題[4]



- 前回の発表内容
  - QGRNに基づく適応アルゴリズムの提案
    - 既存のGRNに対して、QGRNが記憶できる表現型の数が多いことを確認
    - 周期変動するネットワークスライス埋め込み問題へ適用
      - 事前に学習せずに動的環境下の問題に適用
      - 解空間が大きく異なる環境間において、広範な解空間探索が可能

- 課題
  - 過去の環境における解の記憶を、
    次のサイクルまで十分に保持できない
    - 新たなFitness関数の設計など、
      記憶の定着および周期的環境自体への適応を実現する

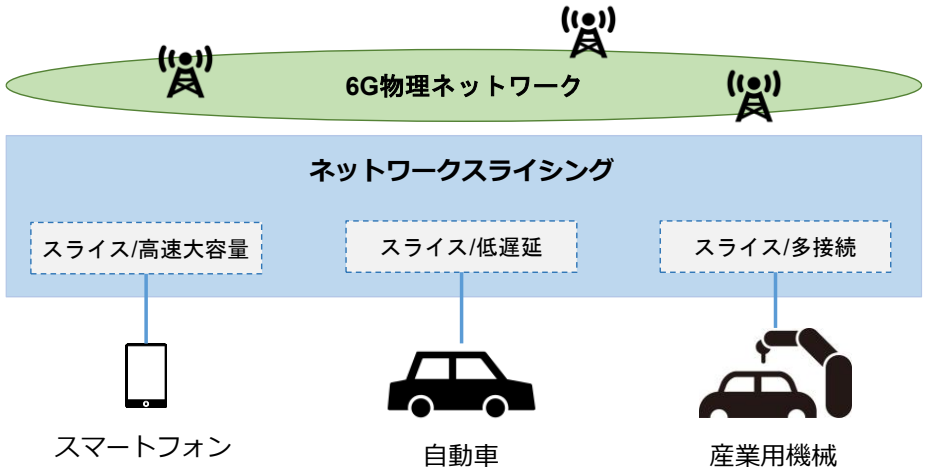


図4: ネットワークスライシング

[4] 関澤和希，山内雅明，小南大智，下西英之，大歳達也，村田正幸，“モバイルネットワークのスライス埋め込み問題を対象とした量 子遺伝子制御ネットワークを用いた最適化手法，”電子情報通信 学会技術研究報告書(NS2025-35)，vol.125，no.24，pp.113–118， May 2025.

# 研究目的とアプローチ



- 研究目的
  - 周期的環境変動下において、環境変動に適応する機構を実現すること

- アプローチ
  - 確率分布型Fitness関数の構築
    - QGRNが過去の環境で有効であった解の情報を、確率分布として保持できる関数を設計
      - QGRNが生成する表現型の確率分布そのものに着目し、
        過去環境で有効な解を含む表現型確率分布への収束を促す
  - 周期的に環境が変動するネットワークスライス埋め込み問題に適用
    - QGRNが内部に過去の環境における解を定着させ、
      動的環境下における最適化挙動および記憶・想起特性を評価

# 確率分布型Fitness関数の設計と更新



- 現環境の最良解と過去環境の解を確率分布として記憶するFitness関数を設計

QGRNアルゴリズム

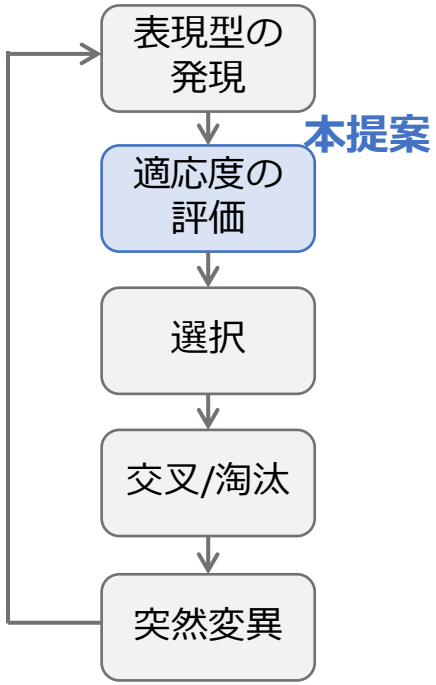


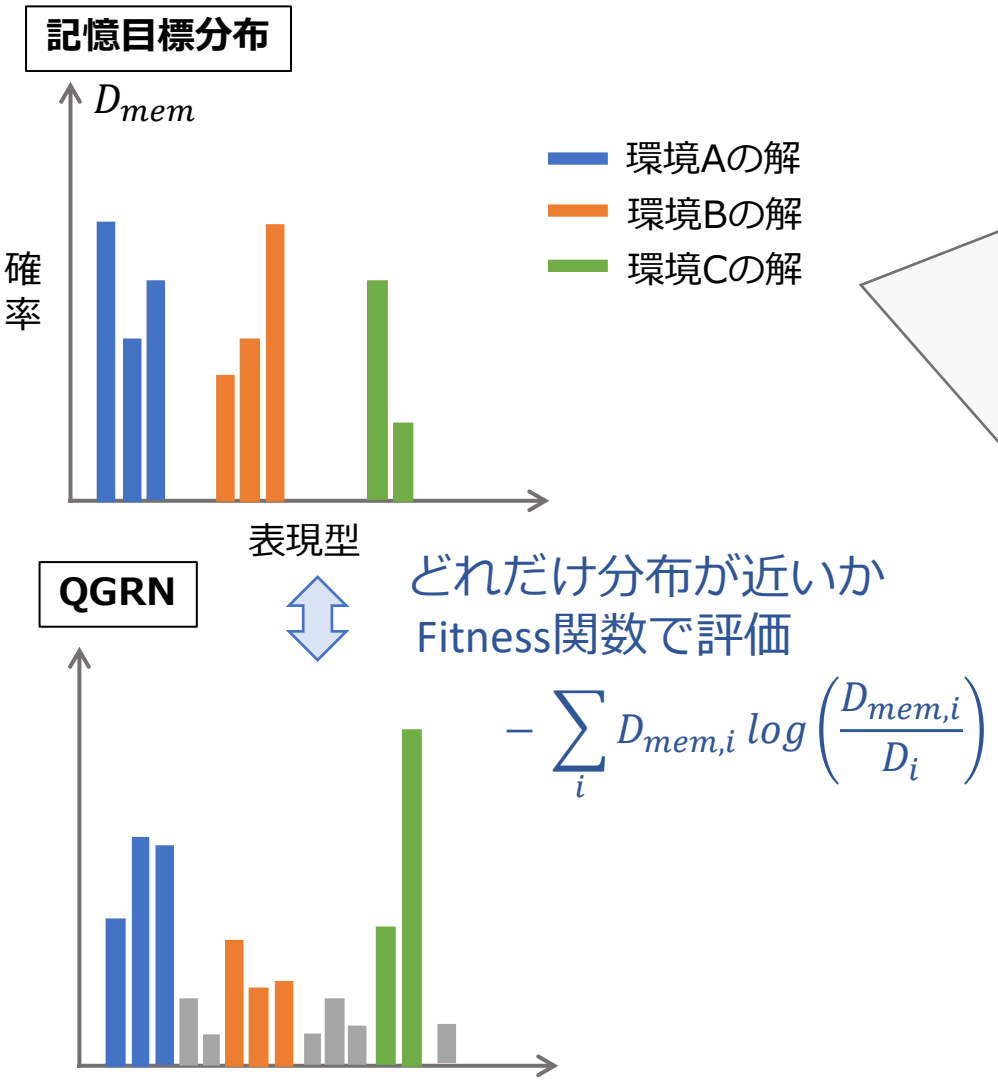


確率分布の更新

1. 現環境の優良解から確率分布を作成

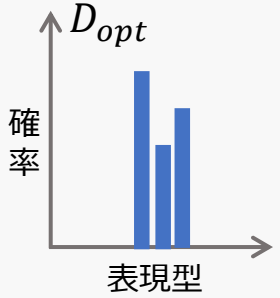


$$D_{opt,i} = \frac{J_i - \min(\mathbf{J_{elites}}) + \epsilon}{\sum_{j=1}^{n_{sel}}(J_j - \min(\mathbf{J_{elites}}) + \epsilon)}.$$

2. 記憶目標分布と混合

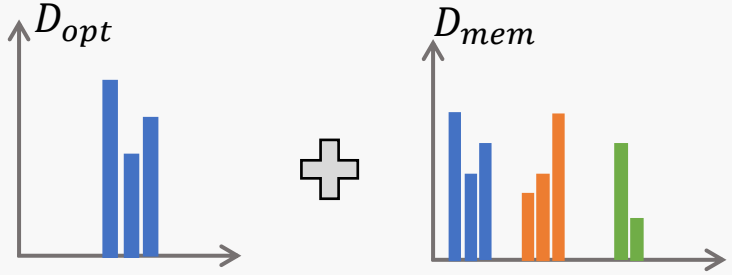


$$D_{mem}(\tau+1) = \alpha D_{opt}(\tau) + (1-\alpha) D_{mem}(\tau).$$

# ネットワーク構成



- 物理ネットワーク構成
  - ユーザ端末2台、エッジサーバ2台、クラウド2台の階層構造
- 仮想ネットワークスライス
  - 3種類のスライス方法を設定
    - 各UE毎に図6の構成を2つ、図7を1つ
  - 仮想リンクとアプリケーションを、制約条件を基に物理ネットワーク上に埋め込む

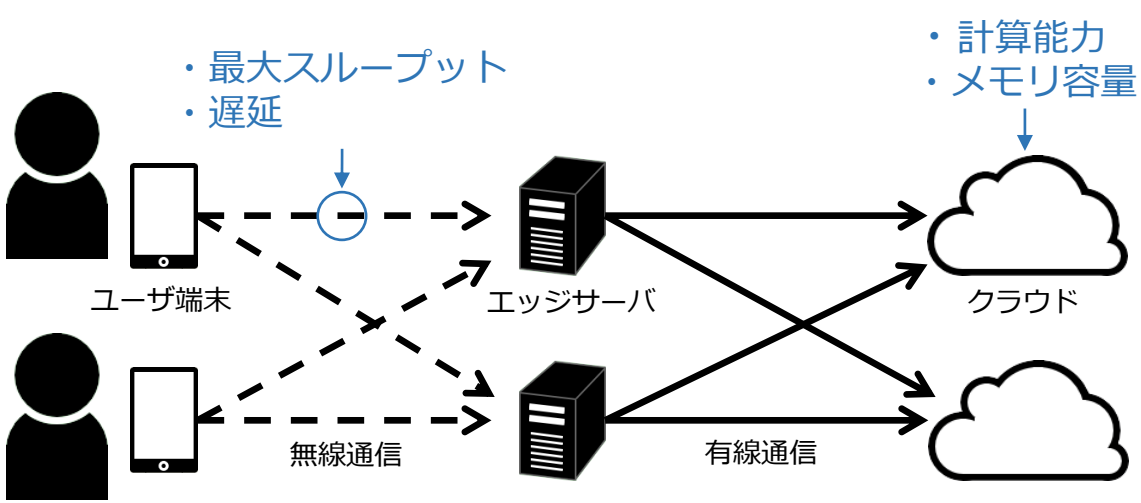


図5 : 物理ネットワークの設定

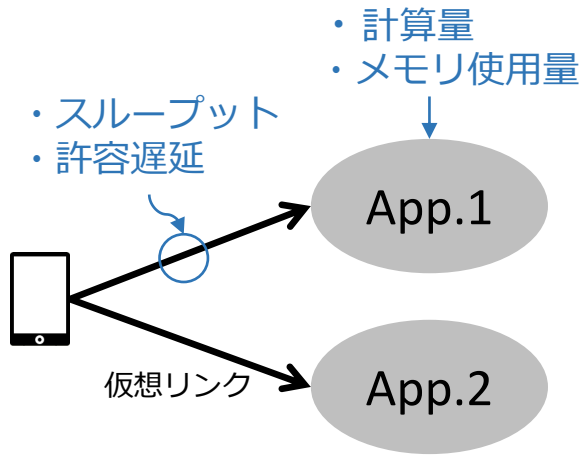


図6 : ネットワークスライス1

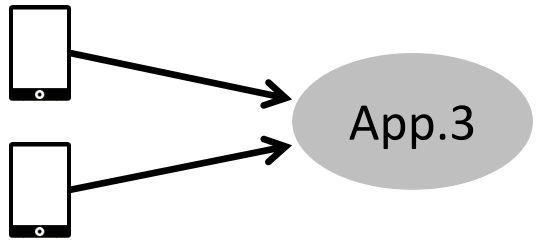


図7 : ネットワークスライス2

# 表現型とスライス埋め込み方法の対応



- 表現型は18bitで表現し、スライスの埋め込み先を決定する
  - 3bitで1つの仮想リンクとアプリケーションの埋め込み方を表現

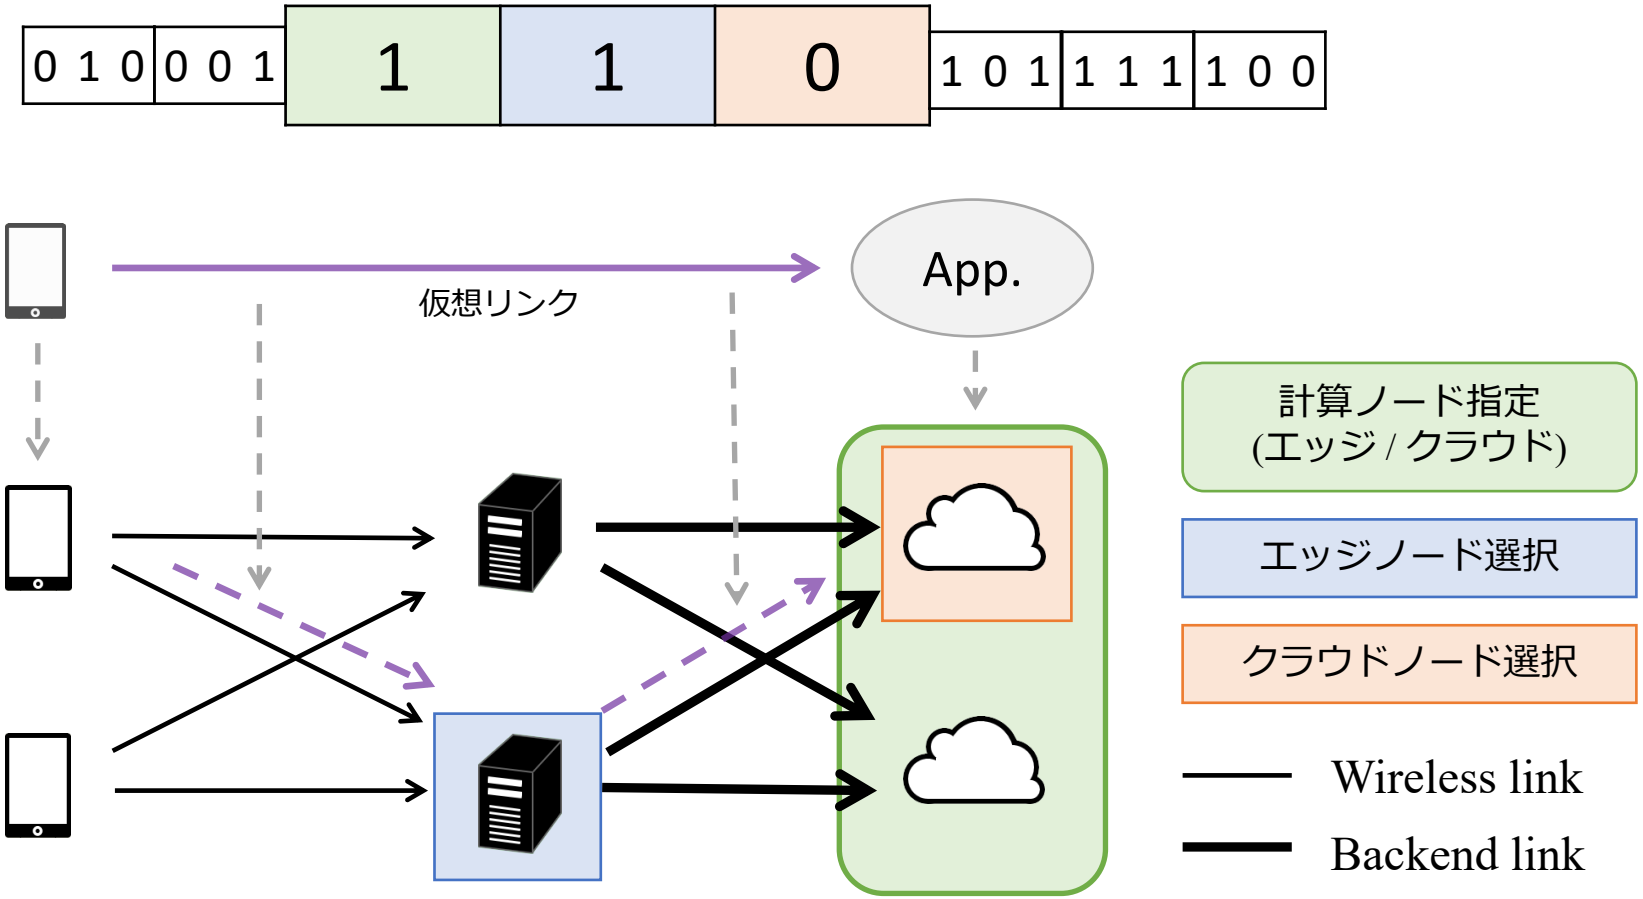


図8 : 表現型とスライス埋め込み方法の対応

# 目的関数と制約条件



- 目的関数
  - ネットワーク全体の消費電力

$$J = \delta\left(E^{thr} + E^{com}\right) + (1-\delta)\,\lambda.$$

送信電力

$$E^{thr} = \sum_k \sum_i \sum_j \omega_j T_i^k .$$

計算電力

$$E^{com} = \sum_k \sum_m \left(\omega_h P_m^k + B_h\right).$$

- 制約条件
  - リンク資源の制約
    - 通信帯域
      - 各物理リンクにマッピングする仮想リンクの総スループットは、物理リンクの最大通信帯域を超えない
    - 通信遅延
      - 各仮想リンクがマッピングされる物理リンクの総通信遅延は、仮想リンクの許容遅延を超えない。
  - 計算ノード資源の制約
    - 各計算ノードに埋め込むアプリケーションノードの総計算量/メモリ使用量は、埋め込み先の計算ノードの計算能力/メモリ容量を超えない

表1 : 変数とその役割

| 変数 | 役割 |
|---|---|
| $\delta$ | 埋め込み失敗時のペナルティ定数 |
| $\omega_i$ | 物理リンク$e_i$の消費電力係数 |
| $T_i^k$ | 仮想リンク$l_i^k$に必要なスループット |
| $\omega_m$ | 埋め込み先ノード$c_m$の消費電力係数 |
| $P_m^k$ | アプリケーション$a_m^k$に必要な計算量 |
| $B_h$ | アプリケーション$a_m^k$の埋め込み先ノード$c_m$のベース電力 |

# 評価環境



- 環境変動設定
  - 最適解の異なる3種類の環境A・B・Cを設定
    - 環境A → B → C のサイクルを計100回繰り返す
    - それぞれの環境変動は $Epoch$ 世代 or 180秒ごとに発生

QGRN特性の評価　　ベースラインとの比較

- 実行環境
  - 量子フレームワーク Qiskit と量子シミュレータ Qiskit-Aer を用いて古典コンピュータ上で実行

- 比較手法
  - Simple GA
  - 既存手法 (QGRN)[4]
    - Fitness関数: 発現確率上位10個の表現型の平均目的関数値

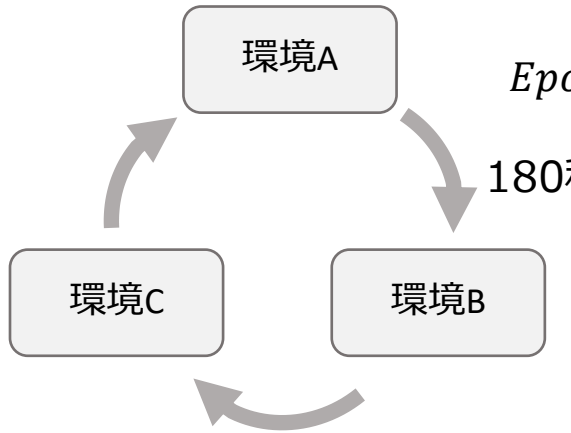


図9: 環境変動の模式図

[4] 関澤和希，山内雅明，小南大智，下西英之，大歳達也，村田正幸，“モバイルネットワークのスライス埋め込み問題を対象とした量子遺伝子制御ネットワークを用いた最適化手法，”電子情報通信 学会技術研究報告書(NS2025-35)，vol.125，no.24，pp.113–118， May 2025.

# 評価(a)：QGRNが過去の環境解を記憶可能か



- 過去の解を記憶するようなバイアスをかけることで、複数環境の解を記憶可能

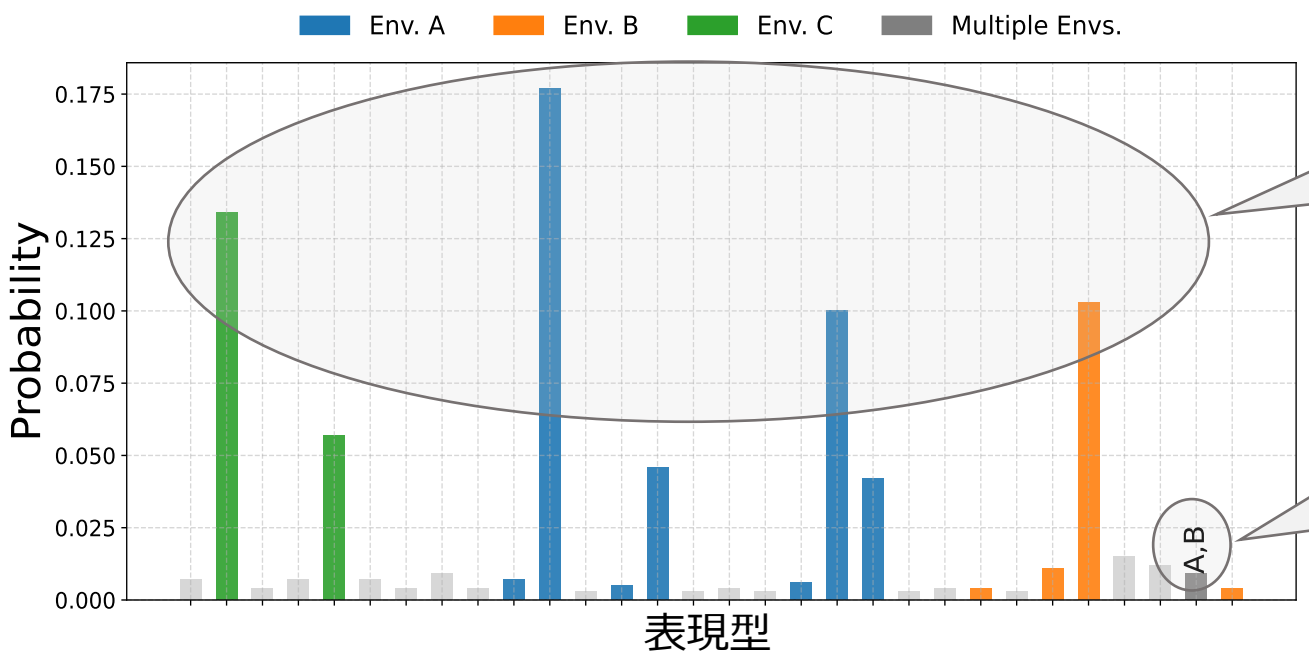


すべての環境の解を一定確率で発現
- QGRNが環境ごとに異なる解を記憶

複数環境に共通する解が一定確率で発現
- 複数環境に共通する特徴を学習し、確率分布として内部表現できる可能性

図10: 提案手法のエリート個体における解の発現分布
(環境変動周期Epoch =12、突然変異率$\mu$=0.02、0.3%以上のみ掲載)

# 評価(b)：QGRNの記憶が動的環境のネットワーク制御に有効か

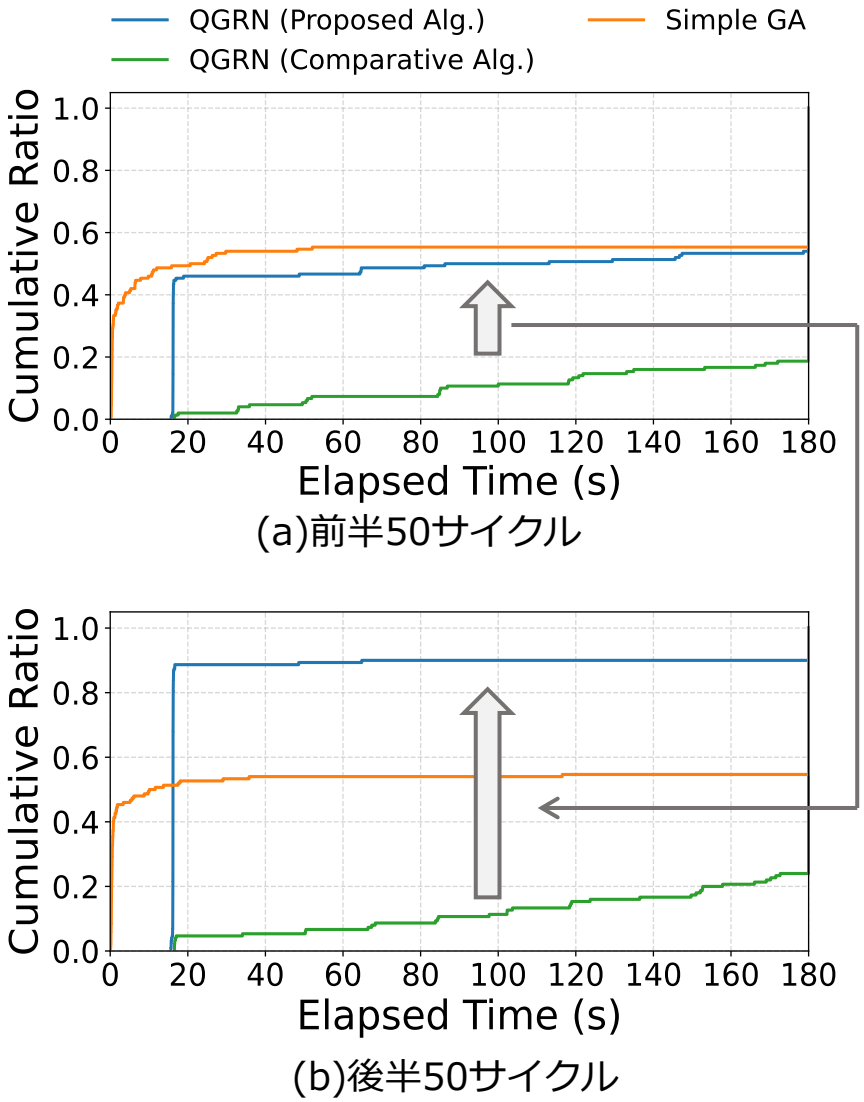


図11:実行時間に対する最適解到達率の累積分布関数

既存手法に対して、大幅な最適解到達率の改善

- QGRNが記憶した過去の最適解を想起し適用できた

Simple GAとの比較

- 図(b): 約16秒経過後は高い最適解到達率
- 図(a): Simple GA が優位
  - 計算コストが主な要因
    - 約16秒: QGRN 1世代 ↔ Simple GA 約12,000世代
  - 今後の量子コンピュータの発展や普及に伴い、この時間差は大幅に縮小されると考えられる

# 評価(c)：パラメータによる影響の調査



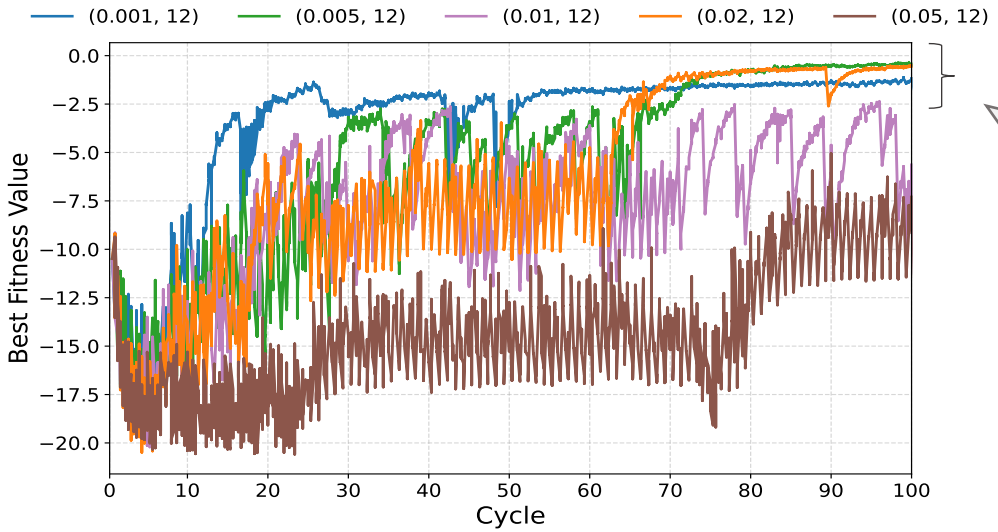


図12: 突然変異率別のFitness値の推移 ($\mu$,Epoch=12)

一定以下の突然変異率において、
QGRNの学習が収束し、動的な環境に対して適応

- 突然変異率 $\mu$ を過剰に低下させると
  最適解到達率が低い状態に収束
  - $\mu$=0.001: 26.3% ↔ $\mu$=0.005: 69.7%
  - 既に獲得した解構造を固定的に保持し、
    精度の高い新たな解構造への遷移が困難

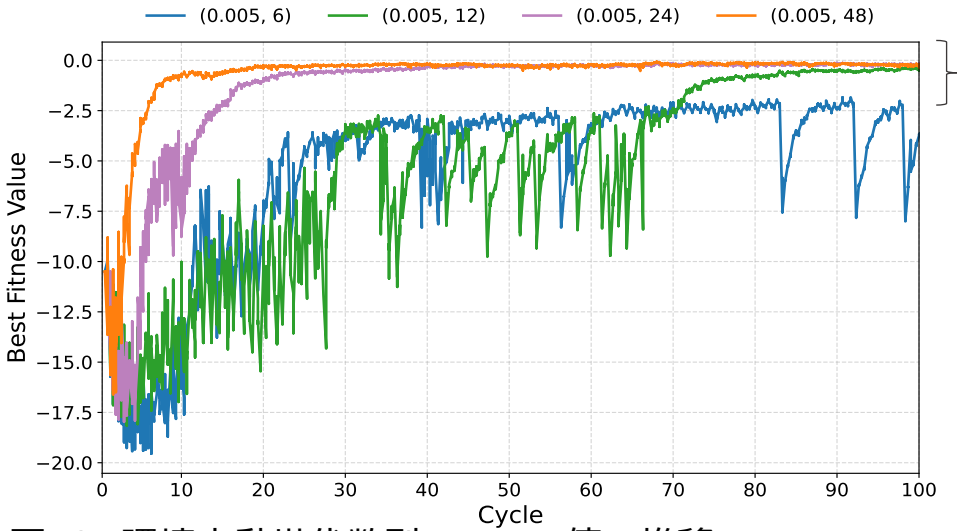


図13: 環境変動世代数別のFitness値の推移 ($\mu$=0.005,Epoch)

一定以上の $Epoch$ でQGRNの学習が収束

- 世代数増加 = 計算コスト増加のため、収束可能かつ
  計算量が過剰でない $Epoch$ 選択が必要

# まとめ



- 確率分布型Fitness関数に基づく最適化手法を提案
  - 目的: 動的環境変動下において有効であった解を確率分布として記憶・想起し、環境変動に適応する機構の実現
  - QGRNが複数環境に対応する解集合を確率分布として保持し、ネットワークの周期変動に適応可能
  - 既に獲得した解構造の保持と新たな解構造の遷移の両立が困難
    - 突然変異率の一時的な増大や、既存手法を併用し新たな解を探索するバイアスをかける

- 今後の課題
  - 量子ビット数の増加に伴う実行時間の指数関数的な増大への対応
    - GPUや実機の量子コンピュータの活用
    - 表現型確率分布を効率的に利用することで必要な量子ビット数を削減する
  - 生物システムにより近い適応機構の実現
    - 解の記憶に加えて、新たな解構造への遷移を両立可能なアルゴリズムの検討