多自由度災害対応ロボットの環境適応性に関する研究
～実空間での能動的情報探索と仮想空間での高効率動作探索～

Environmental Adaptability for Multi-Arm Multi-Flipper Disaster Response Robots
-Active Information Search in Real Space and Efficient Motion Search in Virtual Space-

亀﨑 允啓　○上原 悠輔　大久保 覚子　片野 貴裕　東 宏河　菅野 重樹　（早大）

Mitsuhiro KAMEZAKI, Usuke UEHARA, Satoko OKUBO, Takahiro KATANO, Kohga AZUMA, and Shigeki SUGANO (Waseda University)

In this study, we develop an environment adaptability enhancement system with active information search in real space and high efficiency motion search in virtual space for multi-degree of freedom disaster response robot. For such robots to work safely, estimating the work achievability before executing it is important. However, in disaster sites, failed motions such as falls increase the risk of secondary disasters, so it is difficult to learn motions by trial and error. Thus, the robot obtains the environment information in real space and reproduces them in virtual space, and then performs motion search efficiently in virtual space. Due to the limitation of the reproduction accuracy, for finer adjustment, the robot performs active touches to acquire ground properties such as friction and hardness in real space. The experimental results showed that the proposed system could judge work availability by trying robot motions and provide the robot with efficient motions.
Key Words: Disaster response robot, Active information exploration, Virtual space, Motion learning

1. はじめに

近年，地震や異常気象などによる災害発生時に，道路啓開や情報収集などに多様なロボットシステムが活躍している[1]．例えば，Unmanned Ground Vehicle[2]やUnmanned Aerial Vehicle[3]は，現場の状況調査に使用されており，大型の油圧駆動ロボットは瓦礫撤去などの復旧作業で活躍している[4]．一方，次世代の災害対応ロボットには，大型建機が進入できない複雑な形状の地形や狭隘空間においてより安全かつ効率的な作業を行える高機能化が期待されている．そこで，筆者らは，ハードウェア面に着目して，4腕による高度な作業性，6本のクローラ（4本はフリッパ）による優れた走破性を実現することを目的に災害対応ロボット「オクトパス」（図1）を開発した[5]．いくつかの実験から，複雑作業への適用の潜在性を確認できているが，モデルベースでの制御に留まっており，多様な実環境への適応性は十分ではない．

このような適応性の制御システムでは，操作者の入力した動作をいかなる状態でも実行しようとするため，図2に示すように，(a)ロボットの性能が十分でない場合，(b)当該条件で作業可能な制御が導入されていない場合，(c)考慮されていない要因により作業不可能となる場合，(d)地面の摩擦や硬さといった地面性状が悪影響を与える場合などでは，指示に従って実行すると，事故が起きる可能性がある．そのため，動作を実行する前に作業の達成可能性をロボット自身が推定することが効果的である．作業が不可能と判断された場合は，動作を調整することによって作業可能な動作を探索する．しかしながら，災害現場では，転倒などの失敗動作が二次災害などの危険性を高めるため，試行錯誤による動作学習ができない．そこで，実空間で取得した環境情報を仮想空間上に再現し，その中で効率的動作探索を行う方策をとる．しかし，再現精度には限界があるため，より細かな調整を行うためには，摩擦や硬さといった地面性状を取得する必要がある．この場合には，実空間で環境への能動的接触に基づく情報探索を行う．

以上より本研究では，実空間での能動的情報探索と仮想空間での高効率動作探索を行う多自由度災害対応ロボットのための環境適応性強化システムを開発する．

2. 環境適応性強化システム

環境適応性強化システムのブロック線図を図3に示す．本システムは，(1)能動的情報探索，(2)動作確認，(3)動作学習，(4)動作実行で構成されている．システムの流れと各モジュールの関係性をロボットの移動タスクを例に説明する．まず，能動的情報探索により得られた地形情報をヒューマンインタフェースに表示し，操作者がルートを入力する．次に，地形環境を仮想空間内に再現し，その中で入力ルートの移動試行（動作確認）を行い作業の可否を判断する．動作確認で作業不可能と判断された場合，転倒やスタックした地点に移動し，その地点の物性情報を実空間で取得する．その情報を使って仮想空間を更新し，再度動作学習を行う．その結果，作業可能と判断されれば，動作を実行する．以下

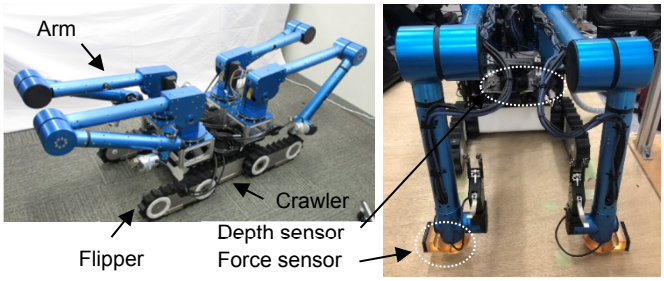

Fig. 1 Disaster response robot OCTOPUS

Table 1 Specification

Degree of freedom	Crawler x 6 / 5 DOF arm x 4
Size [mm]	1015(L) x 508(W) x 562(H)
Weight [kg]	106
Speed [m/s]	0.720
Climbing ability [deg]	45
Maximum loading capacity [N]	175.2

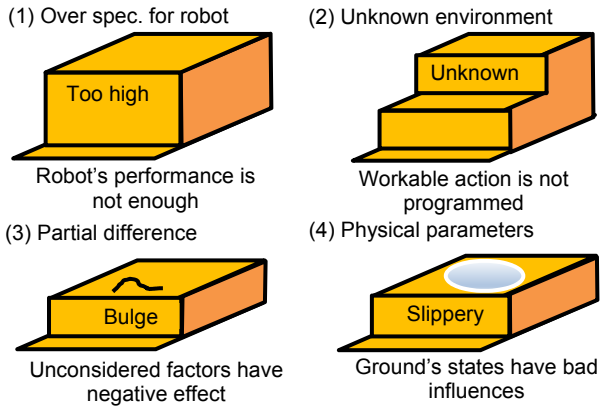

Fig. 2 Causes of trouble in model-based automated control

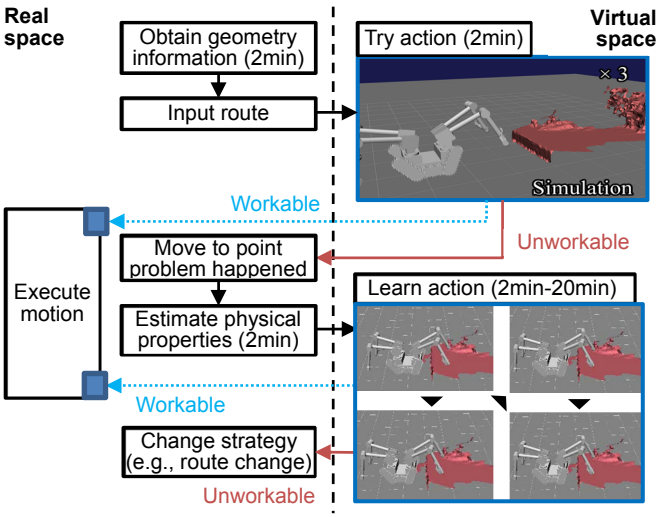

Fig. 3 Environment adaptability enhancement system

に各機能について説明する．

2.1　能動的情報探索

作業の可否を確かめるため，地形情報だけでなく，実際にオクトパスが環境に接触したときの反応を能動的接触によって取得する．この実際に接触する動作を Groping と呼ぶ[6]．

（1）地形情報の取得：深度センサで取得した点群情報を入力として，座標変換後，点群に含まれるノイズの除去や，増えすぎた点群の削減のため，Point cloud library を用いた精緻な面を張り，環境モデルを出力する．

（2）地面性状の取得：災害現場では，積み重なった瓦礫や腐食した木板の上での作業が予想されるため，地面性状の取得が重要になる．地面性状はカメラなどで得られた見た目の様子からだけでは判断できない場合が多いため，環境への能動的接触により摩擦や硬さなどの性状を取得する．本システムでは，アーム手先で環境に触ることで，手先の力センサの値と押し込み変位から，地面や対象物の摩擦，硬さ，重さを推定する．ロボットに搭載した深度センサと力センサを図 1 右に示す．段差登りなどの移動タスクでは，フリッパ前方の地面の摩擦と硬さを測定し，進行方向の地面性状を取得する．手先を押し付ける位置(高さ)は点群情報を基準に決定した(詳細は[6])．

（3）仮想空間への環境再現：実空間の環境を仮想空間で再現する際，描画プラットフォームとして，動力学シミュレーション機能を備えている Choreonoid，物理エンジンとして AGX Dynamics をそれぞれ利用した．図 3 右に示すように，地形モデルとロボットモデルを仮想空間上に置き，ロボットと地面の摩擦係数を設定することで実空間を再現する．

2.2　動作確認

（1）動作生成：あらかじめ入力した基本動作(学習後は学習による生成動作）を読み込み，操作者が入力した作業を行うための一連の動作を生成する．動作は目標関節角度や関節角速度が設定された複数のフェーズに分かれている．移動タスクでは，平地走行・段差昇降・不整地走行の動作内容を用意し，段差登りなどでは高さの変化に対応できるように複数個用意する．その後，環境を再現した仮想空間にて一連の動作を実行し，機体の位置と姿勢，各関節の角度と角速度，各フェーズに要した時間，フリッパのトルク，手先にかかる力を出力する．

（2）信頼度の算出：動作試行結果から，作業の安定性・効率性・環境の再現性の 3 つの観点に基づき，タスクを達成できる可能性である「信頼度」を算出する．(a)安定性は動作中の機体の最大

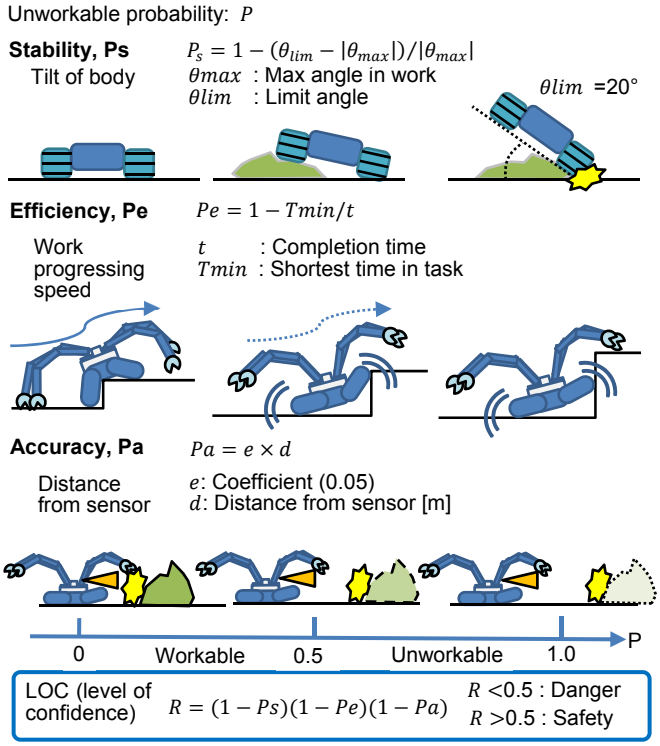

Fig. 4 Level of confidence

ロール角，ピッチ角から算出する．機体性能から，ロール角は 20°，ピッチ角は 45°が許容角であるため，タスク試行中の最大角 θ_{max}[°]が許容角θ_{lim}[°]以上のとき，安定性における作業が不可能である可能性P_s=1 とし，最大角が 0°のときP_s=0 となるようにすると，P_sは次式で得られる．

$$P_s = 1 - \frac{\theta_{lim} - |\theta_{max}|}{|\theta_{max}|} \quad . (1)$$

これを，ロール角とピッチ角それぞれで算出し，大きい値を採用する．(b)効率性は各フェーズにかかった時間から算出する．各フェーズで滞りなく動作が遂行されたときの最小時間を基準時間T_{min}[s]とし，動作時間t[s]が基準時間に近いほど効率性の観点から作業不可能である可能性P_e が 0，動作時間が無限大でP_eが 1 となるようにすると，P_eは次式で得られる．

$$P_e = 1 - \frac{T_{min}}{t} \quad . (2)$$

(c)環境の再現性は，問題が起きた場所の深度センサからの位置から算出する．今回使用する深度センサは，5%の誤差を有するため，遠いほど計測誤差が大きく制御に支障をきたし作業不可能である可能性P_aが向上すると考えられる．そこで，センサからの距離をd[m]とすると，P_a は次式で得られる．

$$P_a = 0.05 \times d \quad . (3)$$

以上から，信頼度Rは，

$$R = (1 - P_s)(1 - P_e)(1 - P_a) \quad , (4)$$

として得られる．$-1 < R < 0$ のとき作業を完遂できないと判断し，$R > 0$ のとき作業可能であると判断するが，Rが 0 に近いほど安定性や効率性に問題がある．そこで，$R > 0.5$ のとき安全に作業可能であると判断する．また，各フェーズの信頼度を算出することで，問題の」あるフェーズを特定して学習の収束を早める．信頼度が 0.5 以上の場合，作業可能と判断し，信頼度とその動作をインジケータに提示し，自動化機能での動作実行を操作者に提案する．一方，信頼度が 0.5 未満の場合，作業不可能と判断し，信頼度とその動作をインジケータに提示し，動作調整の提案を行う．

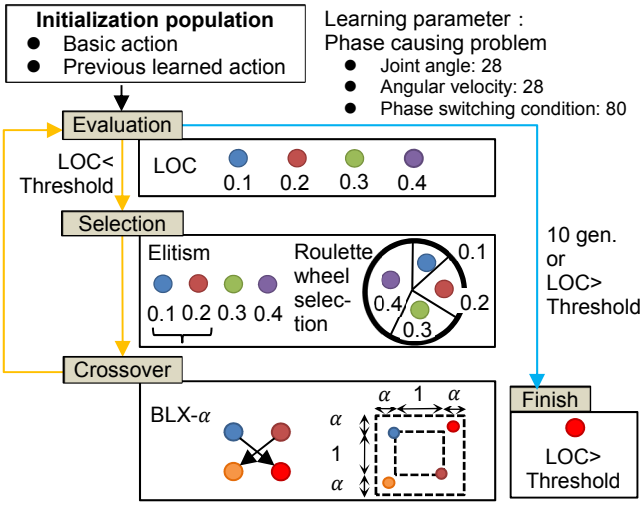

Fig. 5 Genetic algorithm

2.3 動作学習

シミュレーションで生成した動作を実行し，その結果から動作を評価し，より良い動作を獲得している．本システムでは，動作学習の手法として，遺伝的アルゴリズム (Genetic Algorithm: GA) を採用した(図 5)．以下に説明する．

(a) 学習パラメータ：学習パラメータは，各関節角度・角速度(28 関節)，クローラ速度(2 自由度)，フェーズ切り替え条件(関節角・ロボット位置・姿勢・フリッパートルク・手先にかかる力) (80 パラメータ) の合計 138 パラメータとした．

(b) 初期集団の形成：初期集団の個体は通常，無作為生成されるが，動作生成までに時間がかかってしまう．収束を早めるため，基本動作を用いて初期集団を形成した．初期集団で生成する個体数は，学習パラメータの数が多いほど大きな個体群が必要となるため，シミュレーションの速度が極端に低下せずに動作を行うことができる最大数である 60 個とした．

(c) 個体の評価：個体の評価は，信頼度を用いて評価する．作業できない場合も個体間で評価に差をつけるため，進行度合い 0% のとき信頼度-1 となるように信頼度を出力する．

(d) 個体の選択：次世代に残す個体を決める．高評価の個体を残すエリート主義と評価値に比例して選択されやすくなるルーレット方式を用いた．エリート主義は上位個体を変更せずに保存する手法で，学習を打ち切ってもその時点での最良解を出力できる利点がある．ルーレット方式は適応度に比例した割合に基づくルーレットを作成し，それに基づき無作為に選択する手法で，悪評価の個体でも部分調整で優秀な個体に変化することがあるため，その可能性を残せる利点がある．

(e) 交叉・突然変異：選択された個体に対して交叉・突然変異を行い，新しい個体を生成する．本システムでは，突然変異の役割も果たす交叉法 BLX-αを用いる．交叉を行う確率である交叉率は，一般的によいとされている 0.8 に設定した．

(f) 学習の終了条件：個体上位 10 個の信頼度の平均が 0.6 を超えるか，10 世代学習を行った時点で終了する．

2.4 動作実行

実空間での機体位置姿勢が仮想空間と大きく異なっている場合，実空間で動作を完遂するのは難しい．そこで機体の位置姿勢をモニタリングし，作業に異常が見られた場合，安全な位置に戻り操作者へ状態を提示する．

3. 評価実験

(1) 実験タスク：第 1 章で述べた従来システムの作業失敗原因を含む環境として，以下の 3 つを用意した．(a) 15cm 用の動作で

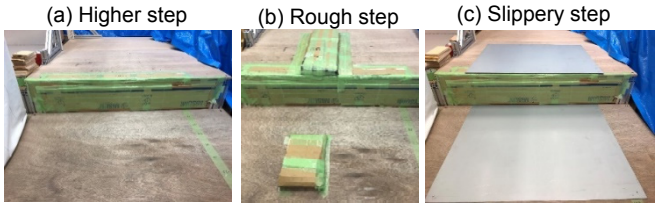

Fig. 6 Experimental tasks

の 25cm の段差登り (図 6(a))．図 2(2) の原因に相当し，フリッパを上げる角度が足りないなどの問題から段差を登れないことが想定される．(b) 凹凸ありの 25cm の段差登り (図 6(b))．図 2(2) の原因に相当し，フェーズ切り替えのタイミングのずれにより，段差を登れないことが想定される．(c) 摩擦係数が低下した 25cm の段差登り (図 6(c))．図 2(3) の原因に相当であり，摩擦係数の低下により推進力が得られなくなり，段差を登れないことが想定される (木板：約 0.7，鉄板：約 0.5)．

(2) 実験条件：段差登りを上記のタスクについて 5 回ずつ遂行する．測定した環境情報を元にルートを入力し，動作確認を行う．動作確認で信頼度が 0.5 以上または，10 世代に達するまで動作学習を行う．評価は，信頼度による作業可否判断の正確性，GA による信頼度の変化，作業時間の 3 種類で行った．

4. 実験結果と考察

4.1 動作学習の結果

3 つの実験条件における，動作学習前および動作学習後の仮想空間および実空間でのロボット動作の様子を図 7 に，LOC の変化を図 8 にそれぞれ示す．

(1) タスク (a)：基本動作ではアーム先端が段差に接触し，段差を登る際にピッチが大きくなり，不安定になっている．一方，学習後動作では前方の肩の関節角が変化し，手先が段差から離れ，アームやフリッパの制御角を調整して機体が水平になるように段差の高さに適応させた動作が得られた．図 8(a) に示すように，5 世代目までは，世代が進むごとに最大信頼度と上位 10 番目までの差が縮まっている．5 世代目以降は，大きく変化しなかった．作業時間は 41.5 秒であった．

(2) タスク (b)：段差から離れている状態でフリッパを下げてスタックする個体や，ロール・ピッチ角が制限角度を越える個体が存在した．仮想空間での動作から，フリッパで凹凸による左右差を減らすことができた個体が成功することが分かった．実機動作において，基本動作では段差の手前の障害物によりピッチ角度が上がり，早くフェーズが切り替わってしまう一方，学習後動作ではアームを広げロール方向に車体を傾けることで，ピッチが早く上がるのを防ぐ動作が得られた．図 8(b) から，世代が進むごとに最大信頼度と上位 10 番目までの差が縮まっている．作業時間は 35.0 秒であった．

(3) タスク (c)：仮想空間では，大半の個体が滑っており，それが作業失敗や時間延長の原因となっていた．動作学習を行い，アームを使って機体を押し上げる動作を取得することで，段差を登ることに成功している．実機動作では，段差に前方フリッパがかかる際に後方フリッパが滑ってしまい，進行方向が安定しなかったが，学習後動作では，アームを地面に付くことで滑りを防ぎ，段差のぼりを成功させている．図 8(c) に示すように，比較的第 1 世代から最大信頼度，上位 10 個の個体平均信頼度，最低信頼度が高いことがわかる．作業時間は 24.3 秒であった．

4.2 考察：実際の環境と再現環境との差異

本システムでは，地形と摩擦係数から仮想空間に環境を再現した．地形情報は点群を用いて取得するため，深度センサの精度に大きく依存する．また，深度センサで点群を取る際，凹凸のある段差などでは，凹凸の後ろの点群を取得できず，穴が開いてしま

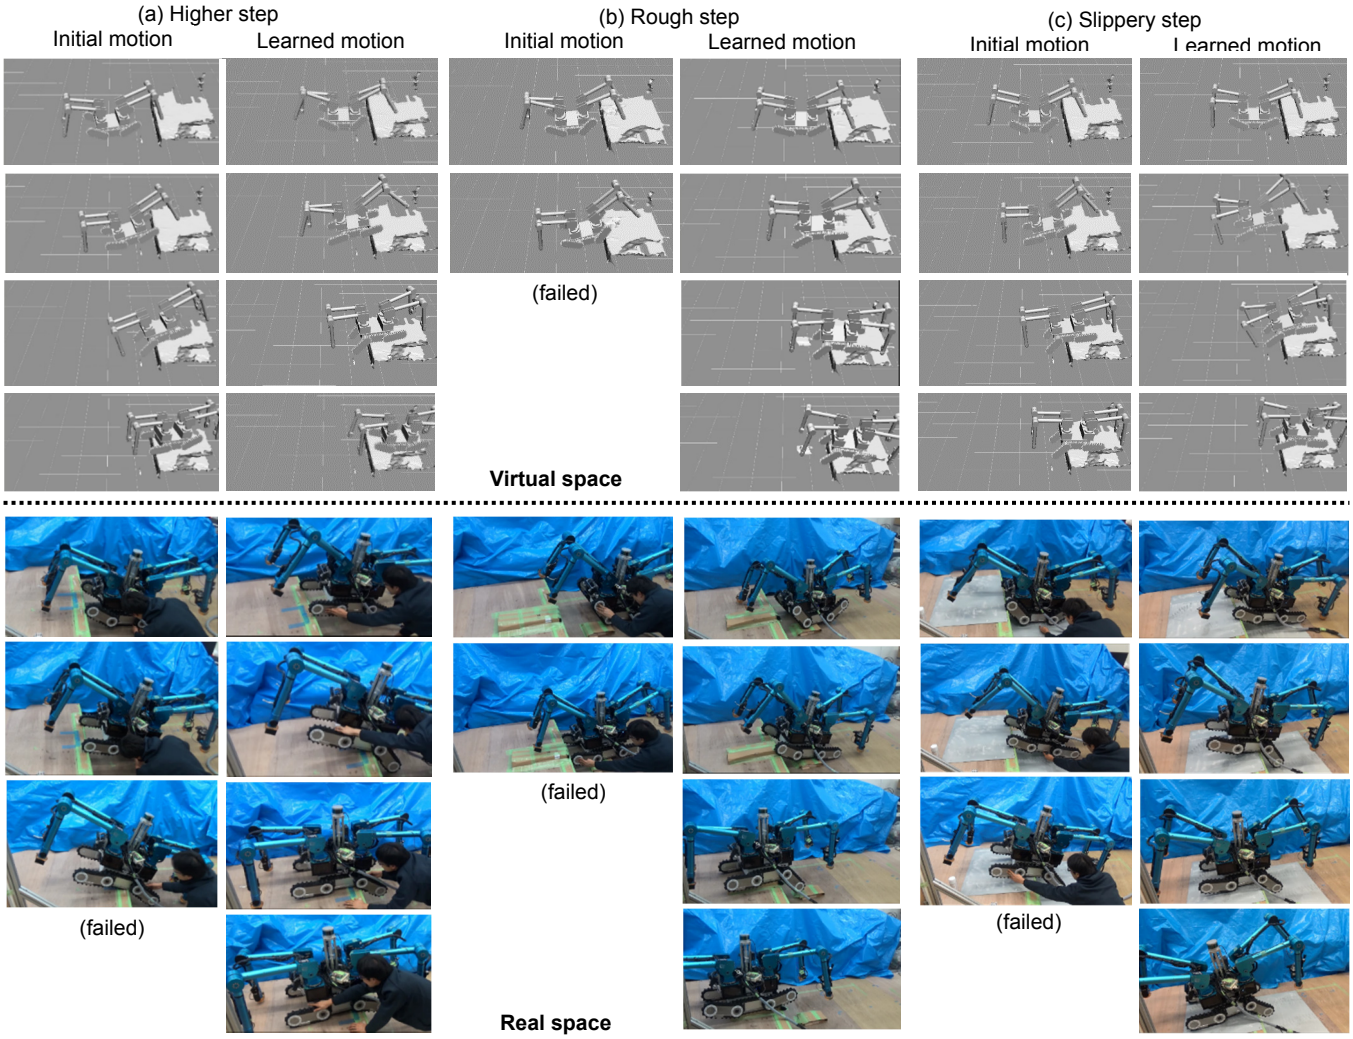

Fig. 7 Robot motion for initial and learned states in virtual and real space

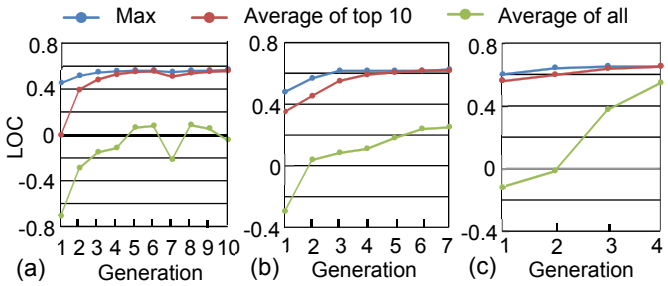

Fig. 8 Updating LOC by genetic algorithm

うことがあった．また，水平面の点群は深度センサで取得できても点群密度が薄くなってしまい，正確に地面を再現することが困難であった．これらの問題を防ぐためには，深度センサを動かして物体の後ろ側の点群を取得することが効果的であると考えられる．実験で用いた段差登りのアルゴリズムでは，位置情報だけでなく機体の傾きをフェーズの切り替えに用いることで，段差の位置が誤差 10cm 以内であれば，段差を登ることが可能である．

5. まとめ

本研究では，実空間での能動的情報探索と仮想空間での高効率動作探索を行う災害対応ロボットのための環境適応性強化システムを開発した．災害現場を模した環境において，作業可否の判断の正確性，学習の前後での信頼度の変化を評価項目として，未知の条件を含む段差登りの実験を行った．その結果，仮想空間上での動作確認により作業可否の判断が可能であり，実空間での能動的情報探索と仮想空間での動作探索により効率的に動作が学習され，作業が可能となることが示された．以上から，提案システムを用いて環境に適応した動作を探索できることが示された．今後は，マニピュレーション作業へ応用展開していく予定である．

謝　辞

本研究の一部は，JSPS 科研費(18KT0063，16K06196)，早大次世代ロボット研究機構，ならびに，早稲田大学理工学術総合研究所の支援を受けて行われました．ここに謝意を表します．

参 考 文 献

[1] R.R. Murphy, J. Kravitz, S.L. Stover, and R. Shoureshi, “Mobile robots in mine rescue and recovery,” IEEE Rob. & Autom. Mag., vol. 16, no. 2, pp. 91–103, 2009.

[2] L. Molyneaux, D.A. Carnegie, and C. Chitty, “HADES: An underground mine disaster scouting robot,” in Proc. IEEE Int. Symp. Safety, Security, & Rescue Rob., pp. 1–6, 2015.

[3] M. Nagai, C. Tianen, R. Shibasaki, H. Kumagai, and A. Ahmed, “UAV-borne 3-D mapping system by multisensor integration,” IEEE Trans. Geoscience and Remote Sens., vol. 47, no. 3, pp. 701–708, 2009.

[4] Y. Hiramatsu, T. Aono, and M. Nishio, “Disaster restoration work for the eruption of Mt Usuzan using an unmanned construction system,” Adv. Rob., vol. 16, no. 6, pp. 505–508, 2002.

[5] M. Kamezaki, et. al., “Design of four-arm four-crawler disaster response robot OCTOPUS,” in Proc. IEEE Int. Conf. Rob. & Autom., pp. 2840–2845, 2016.

[6] 上原，亀﨑，東，石田，菅野，“災害対応ロボットの能動的環境接触による相互作用パラメータの推定”，計測自動制御学会システムインテグレーション部門講演会論文集，pp, 738-741，2018.