深層予測モデル学習による可変剛性と素材変化を考慮した動的柔軟布操作

Dynamic Cloth Manipulation Considering Variable Stiffness and Cloth Material Change Using Deep Predictive Model Learning

○正　河原塚 健人　(東大)　　三木 章寛　(東大)
正　板東 正祐　(東大)　　岡田 慧　(東大)
稲葉 雅幸　(東大)

Kento KAWAHARAZUKA, The University of Tokyo, kawaharazuka@jsk.imi.i.u-tokyo.ac.jp
Akihiro MIKI, Masahiro BANDO, Kei OKADA, and Masayuki INABA, The University of Tokyo

Dynamic manipulation of flexible objects such as cloth, which is difficult to modelize, is one of the major challenges in robotics. Humans can move their arms at high speed using their flexible bodies skillfully, and even when the material to be manipulated changes, they can manipulate the material after moving it several times and understanding its dynamics. Therefore, in this study, we focus on the following two points: (1) body control using a variable stiffness mechanism for dynamic manipulation, and (2) response to changes in the material of the manipulated object using parametric bias. By incorporating these two approaches into a deep prediction model, we show through experiments that a musculoskeletal humanoid can dynamically manipulate cloth while detecting changes in the physical properties of the manipulated object.

Key Words: Deep Learning, Cloth Manipulation, Musculoskeletal Humanoids

1　序論

モデル化の難しい布のような柔軟物のマニピュレーションはロボットにおける大きな課題の一つである．これら柔軟物体マニピュレーションには大まかに，静的マニピュレーションと動的マニピュレーションが存在する．また，それぞれについて，モデルベースな手法・学習ベースな手法が様々に開発されてきた．静的なマニピュレーションは古くから取り組まれており，様々なモデルベースな手法が存在する [1]．学習ベースな手法も近年盛んに取り組まれており，実機への応用にも成功している [2, 3]．一方，静的マニピュレーションに比べてより難しい動的なマニピュレーションの例は多くはない．モデルベースな手法としては，山川らの研究がよく知られている [4]．学習ベースの手法としては，深層予測モデルを使ったもの [5]，強化学習を使ったもの [6] がある．なお，[5] は最大 2 自由度の実機のみを使っており，[6] は多自由度ロボットを使っているものの，シミュレーションのみでの実行である．本研究ではこれらの中でも，ベッドシーツやレジャーシートを大きく広げるような，より難しい動的マニピュレーションについて扱う．後に述べるモデル化困難な要素を複数扱うため，試行錯誤型の学習ベースな手法を開発する．また，実機への適用を行うため，多数の試行が必要な強化学習ではなく，深層予測モデルによる動的布操作を行う．

これまでの研究において，人間のような動的布操作に足りない点がいくつかある．人間は，その柔軟な身体を使って手先を高速に動かし，また，操作対象の素材が変化しても，少し動かして特性を理解したうえでマニピュレーションを行うことができる．本研究ではこれを踏まえて，(1) 動的なマニピュレーションのための身体制御，(2) 操作対象物体の素材変化への対応，という 2 点に焦点を当てる (図 1)．(1) は，人間のように柔軟かつその柔軟さを自在に操ることのできる可変剛性制御が可能なロボットによるマニピュレーションを目指す．本研究では冗長な筋肉と非線形弾性要素により可変剛性制御可能な筋骨格ヒューマノイド Musashi-W (MusashiDarm [7] に車輪が付いたロボット) により動作を行う．このとき，身体の制御入力として，追加で剛性値を用いることで，どのように動的布操作が変化するかを考察する．(2) は，Parametric Bias [8] を用いた操作対象の素材変化への適応を目指す．Parametric Bias はニューラルネットワークにおける追加のバイアス項であり，様々な動作データについて複数のアトラクターダイナミクスを抽出することを目的として，主に模倣学習に利用されてきた [9]．本研究ではこれを，布の素材・物理特性情報を埋め込むために用いる．新しい布を持ったとき，これを少し操作することで物理特性を同定し，正確に動的布操作を行う．本研究では，この (1) と (2) を組み込んだ深層予測モデルを構築し，より人間らしい動的布操作を行うことでその有効性を示す．

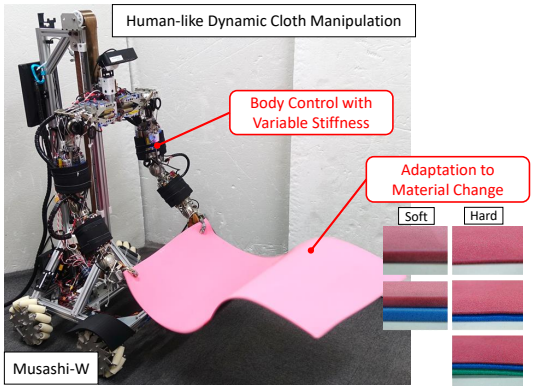

Fig.1: Dynamic cloth manipulation by the musculoskeletal humanoid Musashi-W considering body control with variable stiffness and adaptation to material change.

2　提案手法

提案ネットワークを Dynamic Manipulation Network with Parametric Bias (DMNPB) と呼び，全体システムを図 2 に示す．

2.1　ネットワーク構成

本研究で用いる DMNPB は以下のように数式で表せる．

$$\boldsymbol{s}_{t+1} = \boldsymbol{h}_{dmnpb}(\boldsymbol{s}_t, \boldsymbol{u}, \boldsymbol{p}) \tag{1}$$

ここで，$\boldsymbol{s}$ は操作物体やロボットの状態，$\boldsymbol{u}$ はロボット身体への制御入力，$\boldsymbol{p}$ は Parametric Bias，$\boldsymbol{h}_{dmnpb}$ はロボットと操作物体状態の制御入力による時系列変化を表す関数である．ここで，$\boldsymbol{s}_t^T = (\boldsymbol{z}_t^T \quad \boldsymbol{f}_t^T \quad \boldsymbol{l}_t^T)$ である．なお，$\boldsymbol{z}_t$ は得られた現在の画像 I_t を AutoEncoder で圧縮した布の状態，$\boldsymbol{f}_t$ と $\boldsymbol{l}_t$ は筋骨格ヒューマノイドにおける現在の筋張力・筋長を表す．また，本研究では $\boldsymbol{u}^T = (\boldsymbol{\theta}^{ref,T} \quad \boldsymbol{k}^{ref,T})$ とした．なお，$\boldsymbol{\theta}^{ref}$ は指令関節角度，$\boldsymbol{k}^{ref}$ は指令身体剛性値を表す (詳細については 2.2 章に述べる)．Parametric Bias は暗黙的なダイナミクスの違いを埋め込むことが可能な入力変数であり，同一の素材同士については共通，異なる素材同士については互いに異なる値である．様々な布の素材を使ってマニピュレーションを試すことで，$\boldsymbol{p}$ には操作物体の素材のダイナミクスに関する情報が埋め込まれる．

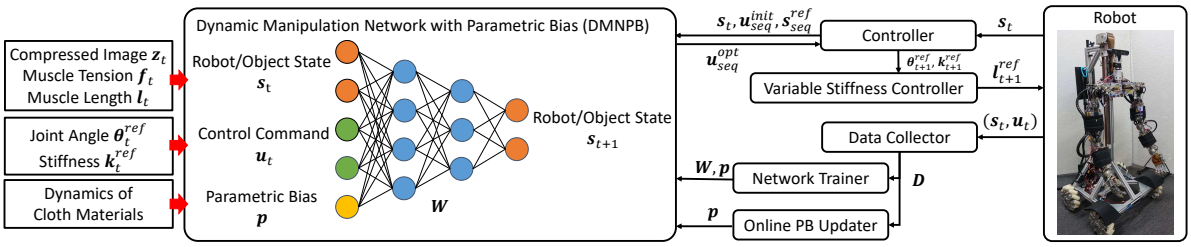

Fig.2: The system overview of dynamic manipulation network with parametric bias (DMNPB).

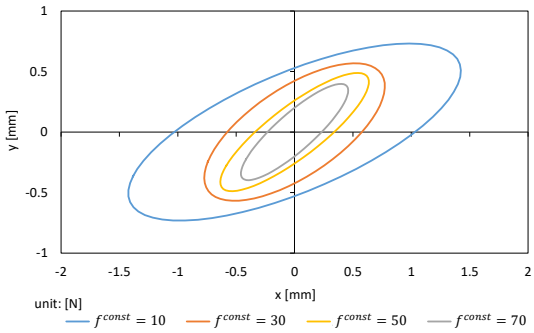

Fig.3: Operational stiffness ellipsoid when adding force of 1 N while changing $f^{const} = \{10, 30, 50, 70\}$ [N].

2.2 筋骨格身体における可変剛性制御

制御入力である $\boldsymbol{\theta}^{ref}$ と $\boldsymbol{k}^{ref}$ の詳細を述べる．本研究では以下のような関節角度 $\boldsymbol{\theta}$, 筋張力 $\boldsymbol{f}$, 筋長 $\boldsymbol{l}$ の関係を用いる [10].

$$\boldsymbol{l} = \boldsymbol{h}_{bodyimage}(\boldsymbol{\theta}, \boldsymbol{f}) \tag{2}$$

この写像 $\boldsymbol{h}_{bodyimage}$ は実機データを使い学習により獲得される．制御の際は，指令関節角度 $\boldsymbol{\theta}^{ref}$, 指令筋張力 $\boldsymbol{f}^{ref}$ を決め，これに対応した筋長 $\boldsymbol{l}^{ref} = \boldsymbol{h}_{bodyimage}(\boldsymbol{\theta}^{ref}, \boldsymbol{f}^{ref})$ を計算する．ただし，この値は測定されるべき筋長であるため，実際には筋剛性制御における筋の伸びを考慮した $\boldsymbol{l}^{send}$ が実機に送られる [10].

ここで，$\boldsymbol{f}^{ref}$ の与え方を考える．[10] では，初めに全筋に対する $\boldsymbol{f}^{ref}$ に一定の値 f^{const} を与え，ある程度指令関節角度を実現した後，その際に発揮されている筋張力 $\boldsymbol{f}$ を $\boldsymbol{f}^{ref}$ としてもう一度入力することでより正確な指令関節角度を実現していた．この最初に送る f^{const} の値によってある程度身体剛性を変化させることができる．また，本研究では最終的に $\boldsymbol{s}$ と $\boldsymbol{u}$ の関係は学習によって獲得されるため，$\boldsymbol{\theta}^{ref}$ は正確に実現する必要はない．よって，本研究の $\boldsymbol{u}$ に含まれる身体剛性値を $\boldsymbol{k}^{ref} = f^{const}$ として，$\boldsymbol{l}^{ref} = \boldsymbol{h}_{bodyimage}(\boldsymbol{\theta}^{ref}, f^{const})$ によりロボットを動作させる．この f^{const} を変化させながら学習用データを取得することで，身体剛性値を考慮した動的布操作が可能となる．

f^{const} による手先の作業空間剛性の変化を図 3 に示す．Musashi-W の左腕の肘を 90 度に曲げた状態の $\boldsymbol{\theta}^{ref}$ において，f^{const} を $\{10, 30, 50, 70\}$ [N] に変化させた際の矢状面における手先の剛性楕円を，全方向から力を 1 N かけた時の手先変位により表している．f^{const} の変化によって手先の剛性楕円の大きさが変化していることがわかる．

2.3 ネットワーク訓練

$\boldsymbol{u}$ をランダムに送る，または人間がロボットを GUI や VR デバイスにより操作し，その際の $\boldsymbol{s}$ と $\boldsymbol{u}$ のデータを集める．同じ布を持った状態で行った，ある一回のまとまったマニピュレーションの試行 k について，データ $D_k = \{(\boldsymbol{s}_1, \boldsymbol{u}_1), (\boldsymbol{s}_2, \boldsymbol{u}_2), \cdots, (\boldsymbol{s}_{T_k}, \boldsymbol{u}_{T_k})\}$ を得る ($1 \leq k \leq K$, K は全試行回数，T_k はその試行 k に関する動作ステップ数とする)．そして，学習に用いるデータ $D_{train} = \{(D_1, \boldsymbol{p}_1), (D_2, \boldsymbol{p}_2), \cdots, (D_K, \boldsymbol{p}_K)\}$ を得る．$\boldsymbol{p}_k$ は試行 k に関する Parametric Bias であり，その一回の試行中については共通の値で，異なる試行については別の値となる変数である．D_{train} を用いて DMNPB を学習させる．通常の学習ではネットワークの重み W が更新されるが，本研究では W と $\boldsymbol{p}_k$ を同時に更新する．これにより，$\boldsymbol{p}_k$ にはそれぞれの試行におけるダイナミクスの違い，つまり，操作した布のダイナミクスが埋め込まれる．

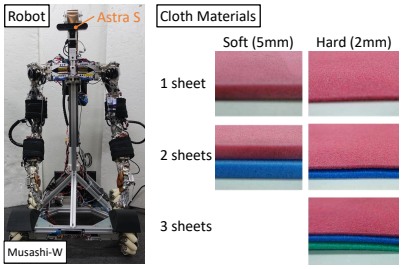

Fig.4: The musculoskeletal humanoid Musashi-W used in this study and cloth materials of soft and hard type polyethylene foam.

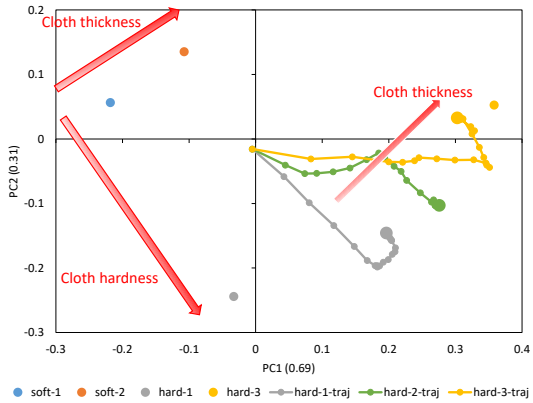

Fig.5: The trained parametric bias for soft-1, soft-2, hard-1, and hard-3, and the trajectory of online updated parametric bias for hard-1, hard-2, and hard-3.

2.4 布素材のオンライン推定

新しい布を操作するとき，そのダイナミクスがわからなければ，正しくマニピュレーションを実行できない．そこで，少し布を動かした際に，どのように布の形状が変化するかのデータを取得し，これを元に布のダイナミクス，つまり $\boldsymbol{p}$ を推定する必要がある．まず，2.3 章と同様にその布をランダムや GUI，後に述べる制御器 (2.5 章) により操作したときのデータ D_{new} を得る．このデータを用いて，学習時とは異なり，W を固定したうえで，$\boldsymbol{p}$ のみ更新していく．つまり，布のダイナミクスに関する項だけを更新することで，DMNPB のダイナミクスを D_{new} に合致させていく．

2.5 動的布マニピュレーション

まず，布の指令状態となる画像 I^{ref} を AutoEncoder により $\boldsymbol{z}^{ref}$ に圧縮する．$\boldsymbol{f}^{ref}$ と $\boldsymbol{l}^{ref}$ は $\boldsymbol{0}$ とし，これらを合わせて $\boldsymbol{s}^{ref}$ を生成する．次に，DMNPB の展開数 $N_{seq}^{control}$ を決め，最適化すべき $\boldsymbol{u}$ の $N_{seq}^{control}$ ステップの時系列 $\boldsymbol{u}_{seq}^{opt}$ ($\boldsymbol{u}_{[t,t+N_{seq}^{control}-1]}^{opt}$ の省略形) に初期値 $\boldsymbol{u}_{seq}^{init}$ を設定する．以下のように損失関数を計算し，W と $\boldsymbol{p}$ は固定した状態で $\boldsymbol{u}_{seq}^{opt}$ を更新していく．

$$L = h_{loss}(\boldsymbol{s}_{seq}^{ref}, \boldsymbol{s}_{seq}^{pred}) \tag{3}$$

$$g = \partial L / \partial \boldsymbol{u}_{seq}^{opt} \tag{4}$$

$$\boldsymbol{u}_{seq}^{opt} \leftarrow \boldsymbol{u}_{seq}^{opt} - \gamma \boldsymbol{g} / ||\boldsymbol{g}||_2 \tag{5}$$

ここで，h_{loss} は損失関数，$\boldsymbol{s}_{seq}^{ref}$ は $\boldsymbol{s}^{ref}$ を $N_{seq}^{control}$ ステップ並べた指令布状態の時系列，$\boldsymbol{s}_{seq}^{pred}$ は現在の状態 $\boldsymbol{s}_t$ に $\boldsymbol{u}_{seq}^{opt}$ を順に入

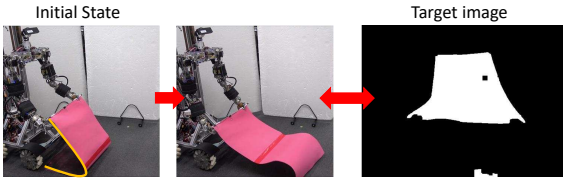

Fig.6: The initial state of cloth and target image of spread-out cloth.

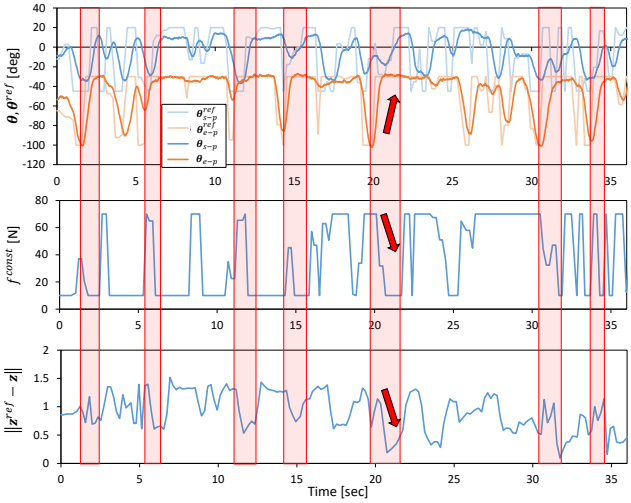

Fig.7: The transition of $\boldsymbol{\theta}^{ref}$, $\boldsymbol{\theta}$, f^{const}, and $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ when conducting an experiment of dynamic manipulation of hard-1.

れた際に予測された $\boldsymbol{s}$ の時系列 $\boldsymbol{s}^{pred}_{[t+1,t+N^{control}_{seq}]}$, $||\cdot||_2$ は L2 ノルム, γ は学習率を表す．つまり，予測される $\boldsymbol{s}$ の時系列を指令値に近づけるように時系列の制御入力を更新する．ここで，複数の γ を使って $\boldsymbol{u}^{opt}_{seq}$ を更新し，その中で最も L の小さかった $\boldsymbol{u}^{opt}_{seq}$ を使う，また，$\boldsymbol{u}^{opt}_{seq}$ の初期値 $\boldsymbol{u}^{init}_{seq}$ に前ステップで最適化された値を用いることで，指令値のより速い収束が得られる．最終的に得られた $\boldsymbol{u}^{opt}_{seq}$ の現在時刻における指令値 $\boldsymbol{u}^{opt}_t$ を実機に送る．

動的布操作は，指令状態に対して制御入力の次元が小さいという特徴がある．そのため，もし一度の動作で指令状態を実現できなかった場合，制御入力の次元が小さいため微修正ができず，最初から布を手前にもってきて一気に開く一連の動作を生成する必要がある．つまり，最初の動作で損失がある程度下がっても，さらに損失を下げるためには一度大きく身体を動かし損失を大きくする状態を経由する必要がある．そのため，$\boldsymbol{s}^{ref}$ を並べたベクトルを $\boldsymbol{s}^{ref}_{seq}$ としただけでは，一度大きく広げようとした後は，ほとんど変化のない $\boldsymbol{u}^{opt}_{seq}$ が生成されてしまう．また，空中で布を広げる状態を $\boldsymbol{s}^{ref}$ とした場合は，その状態が常に実現できるわけではないため，同様の問題が起きる．この特徴を踏まえ，本研究では周期的運動の周期ステップ数 $N^{control}_{periodic}$ を決め，その周期ごとに，以下のように h_{loss} を変化させる．

$$h_{loss}(\boldsymbol{s}^{ref}_{seq}, \boldsymbol{s}^{pred}_{seq}) = ||\boldsymbol{m}_t \otimes (\boldsymbol{z}^{ref}_{seq} - \boldsymbol{z}^{pred}_{seq})||_2 + w_{loss}||\boldsymbol{f}^{pred}_{seq}||_2 \tag{6}$$

ここで，w_{loss} は重み付けの係数である．$\boldsymbol{m}_t$ $(\in \{0,1\}^{N^{control}_{seq}})$ は $N^{control}_{periodic}$ ステップごとに 1 が出現し，その他は 0 のベクトルである．一ステップごとに左へシフトし，右からは $N^{control}_{periodic}$ に応じて 0 または 1 が挿入される．これにより，$N^{control}_{periodic}$ ごとに布の状態 $\boldsymbol{z}$ を指令値に近づけることができ，周期的かつ，一瞬しか実現できない状態を扱う動的布操作が可能となる．式 (6) の右辺第二項は，筋張力の最小化を行う項である．

3 実験

本研究では，筋骨格双腕 MusashiDarm [7] にメカナム台車が追加された Musashi-W を用いて実験を行う (図 4)．ポリエチレンフォームの soft type (厚さ 5 mm) と hard type (厚さ 2 mm) の

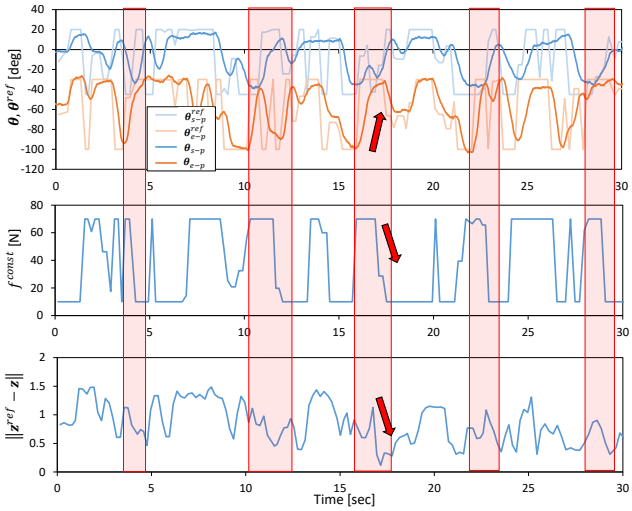

Fig.8: The transition of $\boldsymbol{\theta}^{ref}$, $\boldsymbol{\theta}$, f^{const}, and $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ when conducting an experiment of dynamic manipulation of soft-1.

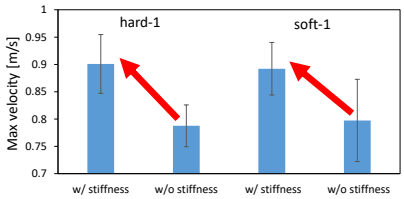

Fig.9: The average and standard deviation of the maximum velocity of end effector when conducting experiments of dynamic manipulation of hard-1 and soft-1.

二種類の素材を布として扱い，soft type は 1 枚または 2 枚，hard type は 1 枚，2 枚，または 3 枚重ねたものを用意する (soft-1, soft-2, hard-1, hard-2, hard-3 と表記する)．Musashi-W の腕は矢状面のみの動作として肩と肘の pitch 軸 2 自由度を動かし，剛性値を含めて制御入力は 3 自由度である．画像は布の赤 (表部分は赤，裏は青や黒の異なる色) を色抽出・2 値化・拡大・縮小・リサイズを施した後，AutoEncoder により圧縮される．

3.1 実機実験

soft-1, soft-2, hard-1, hard-3 の布をそれぞれ持った状態で，$\boldsymbol{\theta}^{ref}$ と $\boldsymbol{k}^{ref}$ をランダムに指令した場合 (Random) を約 80 秒間，GUI (関節角度を GUI で動かし，関節剛性はランダム) で人間が動作させた場合を約 80 秒間行いデータを取得した．なお，ランダムに指令する $\boldsymbol{k}^{ref}$ は [10, 70] [N] の間とした．計 3000 のデータを使い DMNPB を学習させた際に，得られたそれぞれの布に関する Parametric Bias に Principle Component Analysis (PCA) をかけ，2 次元平面内に配置した様子を図 5 に示す．soft-1, soft-2, hard-1, hard-3 のそれぞれが四隅に配置されており，布の厚み・固さ方向が揃っていることがわかる．

ここで，hard-1, hard-2, hard-3 のそれぞれの布を持った状態で，Random の動作と 2.4 章のオンライン素材推定を約 30 秒間走らせる．このときの Parametric Bias の軌跡 (traj) を図 5 に示す．それぞれの PB は最終的に布の厚みに従って直線上に並んだ．hard-3 の PB は訓練時に得られた PB に近い値を示す一方，hard-1 の PB は訓練時に得られたものから少し外れ，hard-3 の PB に寄っていた．訓練時に用いていない hard-2 については，hard-1 と hard-3 の中間程度に位置している．よって，PB の空間が布の厚みや固さに従って自己組織化されていると考える．

次に，PB の値を，操作する物体の訓練時に得られた PB に設定した状態で，2.5 章の制御を行った．図 6 の左図のような布の初期状態から，2.5 章により，図 6 の右図のような，布を空中で広げた状態へと近づける．hard-1 と soft-1 をそれぞれ操作したときの指令関節角度 $\boldsymbol{\theta}^{ref}$，測定された関節角度 $\boldsymbol{\theta}$，指令剛性を表す筋張力 f^{const}，指令画像状態と現在画像状態の誤差 $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ を図 7, 図 8 に示す．なお，θ_{s-p}, θ_{e-p} はそれぞれ肩と肘のピッチ関節の角度を表す．赤い枠で囲った部分は，振り上げた肩と肘

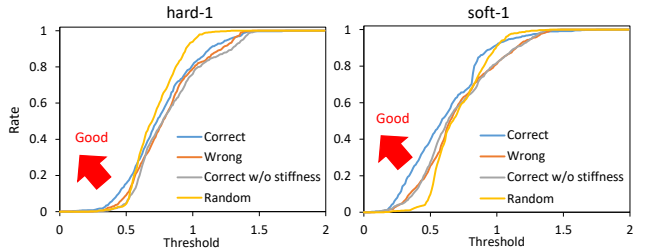

Fig.10: The rate (y-axis) of $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ <threshold (x-axis) when conducting experiments of dynamic manipulation of hard-1 and soft-1 regarding Correct, Wrong, Correct without stiffness, and Random.

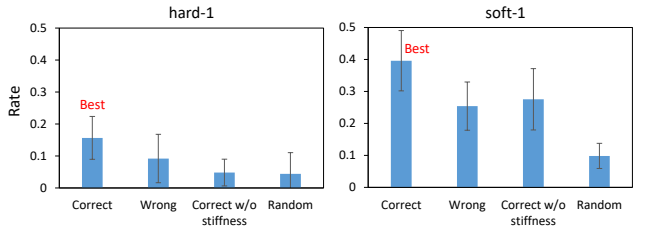

Fig.11: The rate of $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2 < 0.5$ when conducting experiments of dynamic manipulation of hard-1 and soft-1.

を大きく下に降ろしている主要な部分である (関節角度が大きいほど下に手を下ろしている状態である). このとき, f^{const} を見ると, 多くの場合で, 前半は剛性を高くし, 後半は剛性を低くしていることがわかる. これにより, 手先スピードが上がり, 布が広がって浮き上がることで図 6 の右図の状態が実現され, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ の値が低くなっていることがわかる. 実際に, $\boldsymbol{k}^{ref}$ に対して式 (5) を行わず, f^{const} を固定 (10N) として実験を行った場合 (w/o stiffness) と 2.5 章を行った場合 (w/ stiffness) の手先速度の絶対値を比較した図を図 9 に示す. これは, 図 6 の左図の状態から 20 秒の実験を 5 回行い, その間の最大手先速度の平均と分散を表したものである. 剛性変化を使った場合のほうが約 12%程度速度が早くなっていることがわかる. また, 図 7, 図 8 の soft-1 と hard-1 の違いを見ると, hard-1 では θ_{e-p} と θ_{s-p} がほぼ同時に動き, また手を振り上げてから下ろすまでが素早い. 一方, soft-1 では, θ_{s-p} が θ_{e-p} よりも少し後に動き出しており, また手を振り上げてから振り下ろすまでが緩やかな場合が多い. これは, 柔らかい布は最後はゆったりと手をおろしても滞空時間が確保できるのに対して, 固い布はすぐに手を降ろさないと滞空時間が確保できないことが理由であると考える. このように, PB の違いによって対象の操作の仕方が大きく変わる.

最後に, いくつかの条件で布操作を行い, それらを比較した. PB が正しい (soft-1 の操作に対して soft-1, hard-1 の操作に対して hard-1 の PB を用いている) 場合の試行を Correct, PB が間違っている (soft-1 の操作に対して hard-1, hard-1 の操作に対して soft-1 の PB を用いている) 場合の試行を Wrong, ランダムな試行を Random とする. また, PB は正しいが, $\boldsymbol{k}^{ref}$ に対して式 (5) を行わず, f^{const} を固定 (10N) として実験を行った場合を Correct w/o stiffness とする. この 4 つの条件において, hard-1 と soft-1 のそれぞれの布を図 6 の左図の状態から 25 秒の実験を 5 回行う. その際に, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ がある閾値 (x 軸) よりも低い割合 (y 軸) の平均を図 10 に示す. また, 図 10 の一部を取り出した, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2 < 0.5$ の割合の平均と分散を図 11 に, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ の最小値の平均と分散を図 12 に, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ の最大値の平均と分散を図 13 に示す. まず, 図 10 はグラフが左上方向に膨らむほど, より指令画像状態が実現できていることを表す. hard-1, soft-1 のどちらにおいても Correct が最も良く, Random が最も悪い. そして, 図 11 を見ると, その特性が定量的に見て分かる. hard-1 の方がより難しいため全体的に実現率が低いが, Correct に対して Wrong, Correct w/o stiffness の実現率が低いという傾向は一致している. 図 12 を見ると, $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ の最小値の傾向も図 11 と一致しており, 最小値が低いものほど実現率が高い割合も大きい. 一方, 図 13 は Correct が最も高く, Random が最も低い. これは, 指令画像を実現するためには大きく動的に状態

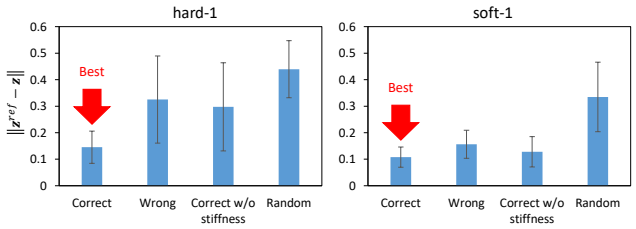

Fig.12: The minimum value of $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ when conducting experiments of dynamic manipulation of hard-1 and soft-1.

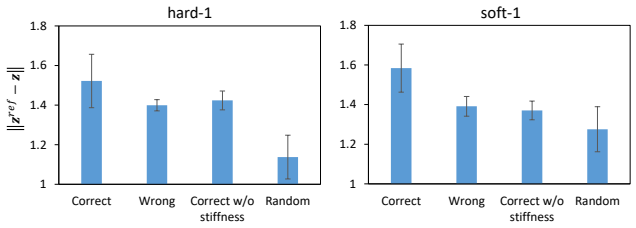

Fig.13: The maximum value of $||\boldsymbol{z}^{ref} - \boldsymbol{z}||_2$ when conducting experiments of dynamic manipulation of hard-1 and soft-1.

を変化させなければならないため, より指令画像を正しく実現できる方法ほど指令画像と離れた状態が起きやすいことを表していると考えられる.

4 Conclusion

本研究では, より人間らしい動的布操作を目指し, 布素材変化への対応・可変剛性を使った素早いマニピュレーションを取り入れた深層予測モデル学習手法を提案した. 布素材変化に対しては Parametric Bias を, 可変剛性については関節角度と剛性値を制御入力として誤差逆伝播を用いて指令値を計算する手法を取り入れた. 訓練データにはない布素材についてもそのダイナミクスが推定でき, また, 素材によって動的布操作の特性が大きく変わることを示した. また, 動作フェーズに応じて適切に剛性値が設定されることで, 可変剛性制御を行わない場合に比べて速度を 12%程度向上させ, より正確に指令状態を実現することが可能であった.

謝辞

本研究の一部は JST ACT-X 課題番号 JPMJAX20A5・JSPS 科研費 JP19J21672 の支援を受けた.

参考文献

[1] M. Inaba, et al. Rope handling by a robot with visual feedback. *Adv. Robot.*, Vol. 2, No. 1, pp. 39–54, 1987.

[2] A. X. Lee, et al. Learning force-based manipulation of deformable objects from multiple demonstrations. In *Proc. IEEE Int. Conf. Robot. Automat.*, pp. 177–184, 2015.

[3] D. Tanaka, et al. EMD Net: An Encode-Manipulate-Decode Network for Cloth Manipulation. *IEEE Robot. Automat. Lett.*, Vol. 3, No. 3, pp. 1771–1778, 2018.

[4] Y. Yamakawa, et al. Motion planning for dynamic knotting of a flexible rope with a high-speed robot arm. In *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst.*, pp. 49–54, 2010.

[5] K. Kawaharazuka, et al. Dynamic Manipulation of Flexible Objects with Torque Sequence Using a Deep Neural Network. In *Proc. IEEE Int. Conf. Robot. Automat.*, pp. 2139–2145, 2019.

[6] R. Jangir, et al. Dynamic Cloth Manipulation with Deep Reinforcement Learning. In *Proc. IEEE Int. Conf. Robot. Automat.*, pp. 4630–4636, 2020.

[7] K. Kawaharazuka, et al. Component Modularized Design of Musculoskeletal Humanoid Platform Musashi to Investigate Learning Control Systems. In *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst.*, pp. 7294–7301, 2019.

[8] J. Tani. Self-organization of behavioral primitives as multiple attractor dynamics: a robot experiment. In *Proc. Int. Joint Conf. Neural Netw.*, pp. 489–494, 2002.

[9] T. Ogata, et al. Extracting multi-modal dynamics of objects using RNNPB. In *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst.*, pp. 966–971, 2005.

[10] K. Kawaharazuka, et al. Online Self-body Image Acquisition Considering Changes in Muscle Routes Caused by Softness of Body Tissue for Tendon-driven Musculoskeletal Humanoids. In *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst.*, pp. 1711–1717, 2018.