

MoCap を用いた力覚スキャンに基づくデータ駆動力覚提示

Data-Driven Haptic Rendering Based on Force Scanning Using MoCap

武田 賢* 佐瀬 一弥**

Ken TAKEDA Kauzya SASE

Abstract: Data-driven methods have been developed to construct a virtual reality environment that enables a user to experience the feel of a flexible object. These methods have the advantage of simulating the reaction force of an object by simple measurements. However, conventional data-driven measurement systems use mechanically constrained measurement probes, making it difficult to measure large objects. Therefore, we developed a measurement system using optical motion capture and applied it to data-driven methods. We constructed a learning model of the reaction force of a relatively large-sized object (300 mm × 120 mm), which was difficult in previous studies. We confirmed that the model can stably simulate the sense of a force. We confirmed that the model can stably simulate the sense of a force.

Keywords: Virtual reality, Regression analysis, Haptics

1 序論

Virtual Reality (VR) 環境における触覚提示技術は、VR 環境において現実に近い身体感覚を実現するために重要な技術であり、広く研究が行われてきた。特に古典的な触覚提示手法として、ペン形状の把持部を持った力覚提示装置 (Fig. 1) による力覚提示の研究が盛んに行われてきた [1]。近年ではその応用が盛んに行われ、医療、教育、エンターテインメント、福祉など幅広く実用化が進められている。VR において触覚が提示できる対象物として、剛体、柔軟物体、流体など多様なものが考えられる。その中で特に柔軟物体の力覚提示に着目すると、剛体のような変形しない物体と比較して実装は複雑となるものの、現実の多様な物体の再現が可能となり有用性が高い。特に代表的な応用例に手術シミュレーションがあり、例えば、手術手技訓練への応用の有用性が示されている [2]。また、布団やまくら、クッション、ぬいぐるみなどの手触りが重要な製品は、VR による再現によって購入前の検討が可能になったり、現実の製品を VR 空間に持ち込んで楽しんだりするような用途が考えられる。著者らの研究グループで



Fig. 1: Haptic device (3D Systems Inc., Touch).

も、力覚提示装置を用いて、柔軟水生生物の触覚を提示する水族館向け触覚 VR [3] や大腸がん予防の啓蒙を目的とした大腸がんなどの触覚がわかる触覚 VR [4] の研究を行ってきた。このように応用が進められているものの、柔軟物体の触覚 VR の開発のハードルは依然として高く、広く普及するには至っていない。したがって、開発コストの側面を含めて実用性が考慮された柔軟物体の力覚提示の方法論の確立が期待されている。

一般的に、柔軟物体の力覚を再現するアプローチは、モデルベース手法とデータ駆動型手法に大別できる。モデルベース手法では、力覚提示の反力値計算のために有限要素モデルなどの力学モデ

*東北学院大学大学院工学研究科機械工学専攻

**東北学院大学工学部機械知能工学科

ルを構築する [5]. モデルベース手法ではモデルに忠実な力覚提示が行える一方, 材料特性同定のための材料試験や, 実時間数値シミュレーションの実装などを行う必要があり, 実験の手間や高性能な PC の導入などにコストがかかる. 一方で, データ駆動型手法では力学モデル構築を必要とせず, 簡易的な計測データに基づいた機械学習により反力を推定するアプローチをとる [6]–[10]. 学習データの収集では, 例えば実物体の表面をまんべんなく測定用プローブで走査 (様々な方向から押し込む) し, プローブの動かし方 (位置・速度など) に対する反力を測定する. 本研究ではこの学習データ収集方法を “力覚スキャン” と呼称する. 本アプローチでは材料試験を必要とせず比較的簡易な測定で力覚提示を行うことができる. また, 力覚提示のために計算コストが高い物理演算を行う必要がなく, 比較的安価な PC を用いてアプリケーションを構築できる. したがって, アプリケーション開発のハードルを下げ, 触覚 VR をより広く普及させる可能性がある.

従来のデータ駆動型力覚提示では, 高精度な学習データの収集のために, 関節にエンコーダを搭載した測定機構の先端に力覚センサを取り付け, それによって力覚スキャンが行われていた [6, 7]. このような方法は, プローブの位置・速度などが高精度に測定できるが, 機構によってプローブが拘束されるため, 測定範囲が狭い範囲に限られることが課題となっている.

そこで本研究では, 力覚スキャンのための測定用プローブを拘束せず, 光学的計測によってプローブの動作を測定することで, 従来では難しかった大型物体のデータ駆動型力覚提示の実現を目指す. 本研究では, 光学的計測手法として, 多数の赤外線カメラで再帰性反射マーカを取り付けた物体の三次元位置・姿勢を測定可能なモーションキャプチャ (MoCap) システムを用いる. ただし, 一般的にこのような光学式 MoCap システムは, 従来の機構による計測と比較すると精度が低く, かつ, 遅延が大きい. これは学習データの品質の悪化につながり, 大きなデメリットとなりうる. そこで, 本論文ではデータ駆動型力覚提示のための力覚スキャンにおいて MoCap を用いることの有用性について, 実験的に調査することを目的とする. 特に大型物体の力覚提示が可能かどうかに着目して実験を行う.

本論文の第 2 章では, 提案手法の概要を述べ, 第 3 章で大型物体の力覚スキャンおよび機械学習

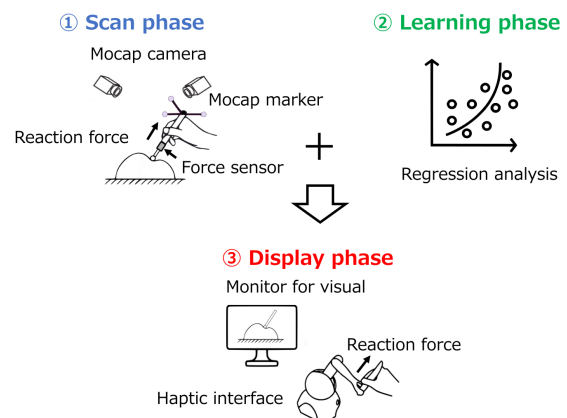


Fig. 2: Outline of our data-driven method.

の結果について述べる. 第 4 章ではユーザ評価により剛性の異なる物体の弁別実験により提案手法の評価を行う.

2 提案手法

2.1 概要

本研究におけるデータ駆動力覚提示手法の概要を Fig. 2 に示す. 本研究におけるデータ駆動力覚提示手法は 3 段階に分けられる. まず, ユーザが力覚センサ, 反射マーカを搭載した測定プローブを操作して, 測定対象表面を様々な方向からまんべんなく押し込むことにより力覚スキャンを行う (図中①). 力覚スキャンにおいては, MoCap システムが測定プローブの三次元位置・姿勢を計測し, 接触座標を算出する. また, 力覚センサによりその接触座標における反力を測定する. 次に, 力覚スキャンの測定データをもとに機械学習を行い, プローブの動作から生じるべき接触反力を推定する学習モデルを構築する (図中②). 最後に, 作成された学習モデルを用い, 実際に力覚提示を行う (図中③). 力覚提示においては, ユーザがペン形状の把持部を有する力覚提示装置を操作する. 把持部の位置姿勢を学習モデルに入力し, その状態における反力値を推定する. 推定反力値を力覚提示装置によって実際に提示することでユーザに感触を提示する.

2.2 MoCap を用いた力覚スキャン

力覚スキャンの様子を Fig. 3 に示す. 測定プローブに搭載する力覚センサはレプトリノ社製 CFS018CA101U (定格容量: $F_x F_y \pm 50 \text{ N}$, $F_z 100 \text{ N}$, 分解能: $\pm \frac{1}{2000} (\text{DC})$) を用いた. 把持部はプラスチックパイプで作成し, 3 つの再帰性反




Fig. 3: Overview of our force scanning system.

射マーカ（Micron シリーズ 15.9mm: Optitrack）を取り付けた。測定プローブの三次元位置姿勢は反射マーカを、NaturalPoint 社製 MoCap カメラ Optitrack Flex3 で撮影し、計測用ソフトウェア Motive によって接触座標の計測する。力覚スキャンではこのプローブを測定対象の表面の様々な位置に対して押し込み、その間のプローブの接触位置と接触反力値を収集する。

2.3 機械学習

力覚スキャンで得られる測定データは離散的であり、連続的な入力（位置姿勢など）に対応する出力（反力値）を生成するには、入出力の関係を数学的なモデルによって表現する必要がある。このようなモデルにより、測定データが疎な領域ではデータの補間を、測定データが測定領域の外側である場合には補外を行うことも考える必要がある。これらの要件を満たすために、本研究では回帰分析を用いて入出力の関係をモデル化する。本研究では説明変数（入力）を位置 x, y, z 、目的変数（出力）を鉛直方向の反力値 f とした。なお、従来研究では説明変数には位置に加えて速度、目的変数には 3 次元反力ベクトルを用いる場合が多いが、本研究では初期検討として上記のように簡略化することにした。回帰分析による推定反力値 \hat{f} は式 (1) で表される。

$$\begin{aligned} \hat{f} &= \begin{pmatrix} \theta_1 & \dots & \theta_n \end{pmatrix} \begin{pmatrix} \phi_1(\mathbf{x}) \\ \vdots \\ \phi_n(\mathbf{x}) \end{pmatrix} + b \\ &= \boldsymbol{\theta}^T \boldsymbol{\phi}(\mathbf{x}) + b \end{aligned} \quad (1)$$

ここで、 $\mathbf{x} = [x, y, z]^T$ は入力となる位置座標、 $\boldsymbol{\phi}(\mathbf{x})$ は基底関数を並べたベクトル、 $\boldsymbol{\theta}$ は基底関数の係数を並べたベクトル、 n は基底関数の数、 b は回帰式の切片を表す。また回帰式を構成する基底

関数はガウスクアーネルを採用した。 i 番目の基底関数のガウスクアーネルの式を式 (2) に示す。

$$\begin{aligned} \phi_i(\mathbf{x}) &= k(\mathbf{x}, \mathbf{x}_{\text{data},i}) \\ &= \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_{\text{data},i}\|^2}{2\sigma^2}\right) \end{aligned} \quad (2)$$

ここで $\mathbf{x}_{\text{data},i}$ は MoCap で計測した位置座標、 σ はガウスクアーネルの幅である。 $\|\cdot\|$ は通常のノルムである。また測定反力値を f とすると、回帰分析ではこの \hat{f} と f の誤差が最も小さくなるような $\boldsymbol{\theta}$ と b を学習によって求めることになる。また過学習を回避するための正則化を行う学習手法として Lasso 回帰と Ridge 回帰がある。本研究ではこれらの回帰手法で学習を行い、最も本手法に適した回帰手法を選択する。式 (3) に Lasso 回帰の目的関数、式 (4) に Ridge 回帰の目的関数を示す。

$$\min_{\boldsymbol{\theta}, b} \frac{1}{2n} \sum_{i=1}^n \|\hat{f}_i - f_i\|^2 + \alpha |\boldsymbol{\theta}| \quad (3)$$

$$\min_{\boldsymbol{\theta}, b} \sum_{i=1}^n \|\hat{f}_i - f_i\|^2 + \alpha \|\boldsymbol{\theta}\|^2 \quad (4)$$

ここで \hat{f}_i 、 f_i はそれぞれ i 番目の反力の推定値、測定値、 α は正則化項の係数を示す。 $|\cdot|$ は L_1 ノルムである。また学習において最適なハイパーパラメータを探索する必要がある。これは学習の挙動を制御するために人間が設定しなければならないパラメータのことであり、本研究では σ と α がそれにあたる。ハイパーパラメータ探索には k 分割交差検証によって行う。

以上の学習の実装は Python の機械学習用ライブラリ scikit-learn を使い、 k 分割交差検証の実装には LassoCV、RidgeCV というメソッドを用いてグリッドサーチを行う。

2.4 学習モデルを用いた力覚提示

力覚提示には 3D Systems 社製の力覚提示装置 Touch を用いる。Touch はペン形状の把持部（スタイラス）を有し、ペンの位置姿勢の 6 自由度の入力が可能であり、3 方向の反力提示が可能である。本研究では、Touch の把持感覚と測定プローブの把持感覚を同一にするため、測定プローブと同様のプラスチックパイプを Touch のスタイラス部に取り付けた。概観を Fig. 1 に示す。Touch の制御は C++ 触覚生成ライブラリ CHAI3D の力覚提示装置制御機能を用いて実装し、取得した現在位置姿勢に基づいて即座に目標反力値を設定しデバイ




Fig. 4: Stuffed toy for measurement.

スに送信する。目標反力値の更新速度は 1 kHz と設定した。目標反力値は回帰分析によって作成した学習モデルを用い、式 (1) によって計算した。

3 大型物体の力覚スキャンと学習モデル構築

3.1 目的

本実験では従来の機構による位置計測に基づく方法では難しかった大型対象物に対し力覚スキャンを行い、学習モデルを構築する。また学習モデルによる推定反力値から本手法による反力値の再現性能の評価を行う。なお、ここでは回帰分析による推定値のみを示し、ユーザへの力覚提示は行わない。ユーザへの力覚提示の評価は第 4 章で行う。

3.2 力覚スキャン

測定対象は応用対象として考えられるぬいぐるみとした (Fig. 4)。先行研究 [7] の測定範囲が 200 mm×80 mm だったため、それよりも大きい 300 mm×120 mm を測定範囲とした。また力覚スキャンに偏りがないように赤い油性ペンで縦に 30 mm、横に 50 mm 間隔で印をつけた。力覚スキャンでは、まず印のついた箇所に対し順に測定プローブを押し当て、その後、対象表面をまんべんなく測定した。この作業はデータを 350000 samples 取得するまで行われ、計測時間は約 5 分間であった。

3.3 学習モデル構築


力覚スキャンによって得られた測定データを処理して学習データとして用い、学習モデルを構築する。前述のように説明変数は 3 次元位置、目的変数は鉛直方向の反力値とした。また、本手法では速度を説明変数に加えず、位置のみを考慮することから、物体の粘弾性に起因する反力のヒステリシスの挙動を再現できないことが想定される。す

なわち、実際には物体を押し込んでいく過程と引き返していく過程では反力の軌跡が異なるが、本手法では同じ軌跡となってしまう。そこで、今回の学習では物体を押し込んでいく過程において高い精度で反力生成を行うことを重視することにし、学習データとしてプローブが対象物表面に触れてからから最大押し込み量に達するまでのデータのみを用いることにした。また、MoCap による測定では光学マーカとカメラの間に遮蔽物が入り込むなどにより、マーカの位置測定に失敗し一部が欠損することがある。それに加え、金属面などにおける光の反射などによって予期しない大きい測定誤差が生じることがある。これら为了避免するために可能な限り測定スペースから鏡面反射する材質のものを排除し、適切なカメラ配置を行った。それでも明らかな位置のずれが測定値に見られたので、それらの測定値は外れ値として除去した。また、学習時間の削減のために、接触反力が生じていない測定点のデータは学習データから除去した。

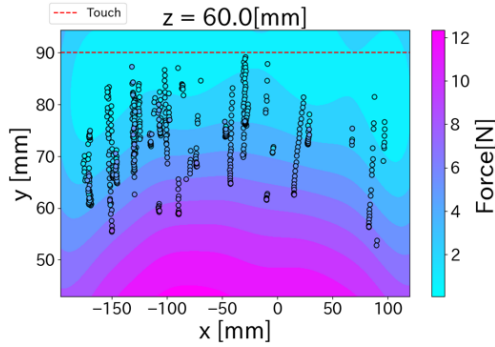
交差検証では学習データとテストデータの比率を 9:1 とし、最終的に学習に用いたデータは説明変数の学習データが 5853 samples, テストデータが 651 samples で、目的変数の学習データが 1951 samples, テストデータが 217 samples だった。k-分割交差検証における分割数は 8 とした。なお、学習データの規模については、Höver ら [6] の手法では物体表面上 1 点の 1 方向押し込み時の粘弾性力の学習データとして 1461 samples を用いていた。それに対し本手法では 35 点で弾性力の学習を行うために 5853 samples を用いることになり、先行研究よりも小規模であるが学習対象が弾性力のみとしているため、妥当な規模であると考えられる。探索する α 値の範囲は scikit-learn の LassoCV メソッドでは自動、RidgeCV メソッドでは 0-10 (0.01 step) を指定した。 σ は、最初は LassoCV メソッド、RidgeCV メソッドともに 0.1-500 (10 step) の範囲を指定し、最適値の目安がいたらその周辺を 0.1 step でさらに探索した。ハイパーパラメータチューニングで用いた PC の構成は以下の通りである: CPU: AMD Ryzen Threadripper3970X (32 cores, 3.69 GHz), RAM: 64 GB.

3.4 学習結果と考察

ハイパーパラメータ探索の結果、Lasso 回帰では $\alpha = 0.000081$, $\sigma = 31.5$ で、Ridge 回帰では $\alpha = 0.16$, $\sigma = 29$ となった。これらの組み合わせから学習モデルを構築し、反力値の推定を行っ




(a) Lasso regression




(b) Ridge regression

Fig. 5: Contour of force distribution in X-Y plane ($z=60$ mm).



(a) Lasso regression



(b) Ridge regression

Fig. 6: Force history.

Table 1: RMSE.

	Push	Pull	All
Lasso regression	1.08 N	1.21 N	1.14 N
Ridge regression	1.05 N	1.20 N	1.12 N

た. まず, X - Y 平面 ($z = 60$ mm) において推定された反力 f をコンター図としたものを Fig. 5 に示す. 図中の丸印は学習データのサンプルを表す. また, $y = 90$ mm の部分は物体表面の最大高さの位置を表しており, 大まかに物体表面を表現した補助線である. y の値が小さいほど物体に大きい変位を与えたことを表し, コンター図の色濃さは反力の大きさを表している. Fig. 6 には測定データの一部の位置履歴を学習モデルに入力し, その時の推定反力値と実測値の履歴をプロットしたグラフを示す. これは, 物体表面を 6 回押し込んである間の履歴である. またテストデータを用いて推定した場合の推定値と測定値の RMSE を Table 1 に示す. 表中の Push, Pull はそれぞれ押し込み過程の誤差, 引き返し過程の誤差を示す.

Fig. 5 から, Lasso 回帰と Ridge 回帰の両方で次の傾向が認められる. まず, 物体に与えた変位が大きい (y が小さい) ほど反力の推定値が大きくなる傾向が確認できる. 学習に用いたサンプル点の密度と推定値に着目すると, サンプル点が疎な領域であっても, 学習モデルによって補間され連続的な推定が実現できることが示された. また, 測定範囲外のサンプル点が存在しない部分も学習モデルによって補外され, 連続的な推定値が得られたことがわかる. Fig. 6 から, このグラフの範囲では大部分で推定値が反力値にほぼ一致することが見られるが, 押し込みのピークの部分や接触境界の部分で明らかな誤差が見られた. これらの誤差はその周辺での学習データが少ないことが原因の一つと考えられる. また, Table 1 から押し込み時よりも引き返し時の方が誤差が大きくなることわかる. この理由は前述のように学習において押し込み時のデータしか用いていないため, 引き返し時の推定精度が低くなったことが考えられる. そのため, 粘弾性が強い材料などに対しては説明変数に速度も加える必要があると考えられる.

以上の結果から本手法は物体の剛性を大型形状物体の大部分の範囲で大まかに推定できる性能が確認された. また, プローブの押し込み過程では特に高い精度での推定が可能であった. このことから, 粘弾性が小さい物体においては本手法でも

有用な結果が得られると考えられる。

4 力覚提示実験によるユーザ評価

4.1 目的

本実験では、構築した学習モデルを用いた力覚提示を実際にユーザに体験させ、実物体の力覚と比較して同様に感じるかのテストを行う。これにより、提示された感触に違和感がないかの定性的な評価を行うとともに、提案手法によって剛性の異なる物体の感触の違いをユーザが弁別できるかを調査する。

4.2 対象物体

本実験で被験者に触ってもらう実物体を Fig. 7 に示す。本実験においても応用対象として考えられるぬいぐるみを用い、硬さや触感が異なる3種類を用意した。ぬいぐるみ A は市販の高反発まくらであり、手で押し込んだ時の反発が比較的大きい。ぬいぐるみ B はぬいぐるみ A と同じ種類のぬいぐるみであるが、綿の量を半分程度に減らしたもので、ぬいぐるみ A と比べて反発が小さい。ぬいぐるみ C は低反発材料であり、押し込んだ部分が元の形に戻りづらい材料である。

4.3 事前実験に基づく学習方法の修正

本実験で被験者に提示する3つの物体に対し、提案手法により学習モデルを構築する。しかし、著者らが力覚提示の事前実験を行った結果、提案手法による力覚提示では仮想物体に接触する際に急激に大きい反力値が提示される場合があることがわかった。これはユーザに大きな違和感を感じる可能性があったのでこれに対する対策を行うことにした。

この挙動の原因は、回帰式に切片の項があることで、物体が接触していない領域であっても反力が生じてしまうこととであった。この問題は、例えば力覚提示の際は非接触時に提示力を零にするなどの条件分岐を行ったとしても、物体表面で不連続な挙動となり不自然な振動を生じさせてしまう。そこで切片がない回帰式を用いて学習を行うことにした。その回帰式を式 (5) に示す。

$$\begin{aligned}\hat{y} &= \boldsymbol{\theta}^\top \boldsymbol{\phi}(\mathbf{x}) \\ &= k(\mathbf{x}, \mathbf{x}_{\text{data},i}) \boldsymbol{\phi}(\mathbf{x})\end{aligned}\quad (5)$$

Fig. 8 にぬいぐるみ A における式 (5) を用いて学習した場合の、学習モデルによる X - Y 平面

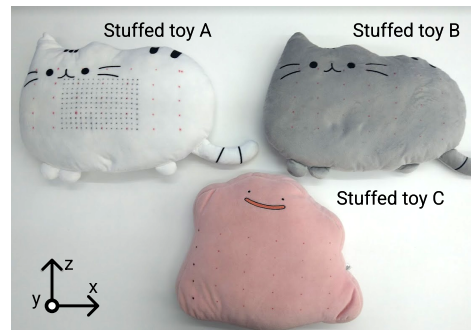


Fig. 7: Stuffed toy to be touched by the subject.


($z = 90$ mm) の推定反力値をコンター図で示している。この結果では $y = 90$ の補助線がだまかに物体表面を表している。今回の場合も物体表面の外側まで反力推定値が非零となっているが、十分に表面から外側に離れば反力推定値は零となる。また、物体表面外側の周辺ではほとんど反力は感じられず、不自然な振動はほとんど生じなかった。したがって、本学習方法で力覚提示実験を行うことにした。

Fig. 8 において Lasso 回帰と Ridge 回帰の再現性能を比較したところ、今回の物体では Ridge 回帰の方が誤差が小さいことが分かった。そこで、力覚提示実験では Ridge 回帰による学習モデルを用いることにした。Touch を制御する PC の構成を以下に示す。: CPU: AMD Ryzen Threadripper3970X (32 cores, 3.69 GHz), RAM: 64 GB.


4.4 実験方法

実験には 15 人の男性が参加した。被験者の年齢は 20—25 歳で、そのうち右利きが 13 名、左利きが 2 名だった。最初に被験者には実験の説明を行い、次に簡単な練習を行った。被験者には実際の物体を触ることと、力覚提示装置 Touch で物体の感触を感じることを両方について練習させた。実際の物体を触る際は、力覚スキャンで用いた測定プローブと同一のものを操作して物体に押し付けさせた。この時、力覚スキャンのときとできるだけ接触条件を同じにするため、プローブを垂直にして押し付けるよう教示した。また Touch の操作方法についても指導し、こちらについてもペン型の把持部を垂直にして持つようにさせた。なお、この練習では視覚を遮断せず自由に操作させた。

物体弁別実験の手順について説明する。まず、被験者には視覚による影響を遮断するために目隠しを装着させた。3つの実対象物を順番に、プローブを介して触らせた。次にそれらの対象物の学習



(a) Lasso regression



(b) Ridge regression

Fig. 8: Contour of force distribution in X-Y plane ($z=90$ mm).

モデルを用いた力覚提示をランダムな順番で体験させた (Fig. 9)。その後、3種類の力覚提示がそれぞれの実物体と似ているかを回答させた。なお、被験者の希望があれば、実物体の感触の再確認を許可した。再確認の回数は制限しなかった。力覚提示についても、被験者の希望があれば再度体験させた。この実験では制限時間は設けず、被験者には納得の行くまで体験させた。実験終了後、アンケートとして以下の質問をした：Q.1「力覚提示に違和感があったか」、Q.2「自信をもって回答できたか」、Q.3「どのような触覚的特徴が判別の役に立ったか」、Q.4「力覚提示の改善点はあるか (自由回答)」。また、触覚体験に対する感想を自由に話してもらい記録した。

4.5 実験結果と考察

提示した物体の種類に対し、被験者が回答した種類の割合を混同行列で表したものを Fig. 10 に示す。混同行列の行は実際に提示した力覚提示の種類 (A, B, C) を、列は被験者の回答 (A, B, C) を表している。すべての被験者がすべての弁別に成功した場合、行列の対角成分が 1.0 となる。被験者がランダムに回答した場合の期待値 (チャンスレベル) は 0.33 である。Fig. 10 ではすべての行




Fig. 9: Overview of haptic interaction.




Fig. 10: Confusion table of result ($n=15$).

列成分が 0.27–0.40 の範囲にあり、いずれもチャンスレベルと大きい差が見られなかった。また、全体の正答率は 0.33 である。この結果は被験者が本手法によって材質を判別できなかったことを示している。アンケートにおいて、Q. 1 の回答として「力覚提示の弾力の強さが実際の物体よりも弱い」、「力覚提示の場合、限界なく押し込むことができちゃう」、「触った瞬間が実際と力覚提示で異なる」、「振動があった」などがあつた。Q. 2 では 14 人が「自信をもって判別できなかった」と答えた。Q. 3 では 15 人全員が「押し込んだ時の反力 (弾力)」と答えた。Q. 4 では Q. 1 の改善の他、表面の摩擦感があつたほうが良いなどが挙げられた。

全体として力覚提示は安定的に行われ、被験者全員が弾性感を感じる事ができた。その点で、本手法は柔軟物体の力覚提示を行うことには成功したと言える。ただし、被験者の回答の中で 1 名から振動についての言及があつた。力覚提示では計算・通信遅延や不連続な指令値、高すぎる剛性提示では容易に振動が起きてしまい、今回はこれらを完全に解決することはできなかった。これに

については学習手法の改善だけでなく、装置自体の高性能化や安定化のための目標提示力の修正など、より広い視点での改善が必要となる。

被験者が材質の弁別を行うことができなかったことについて、主な原因は3つ考えられる。1つ目は力覚提示装置の最大出力反力値が3.3 Nと小さいことがあげられる。今回の実験では力覚提示時の操作量に制限は設けていなかったが、大きく押し込んだ場合に目標提示反力は3.3 Nを超える。その場合、ソフトウェアによって3.3 Nを超えないように修正して力覚提示装置の制御が行われる。これにより、被験者はある程度以上押し込むと反力の大きさがそれ以上変わらなくなり、実際に実物体の厚さよりも深く押し込んでいる様子が見られた。2つ目は今回の力覚提示では粘弾性の影響を考慮していなかったことである。前述のように本研究では入力速度の学習をしていない。また、プローブの引き返し時の測定データを学習に用いていない。これらのことは粘弾性のない物体については高精度に感触を再現できると考えられるが、本実験で用いた対象物については粘弾性が無視できないほど存在しており、それが被験者の回答に影響を与えた可能性がある。3つ目は実験のタスク自体が難しかったことである。本実験の後に目隠しを行い、実際の物体（ぬいぐるみ）3種類を識別できるかを、事後実験として行った（被験者数6名）。その結果、全体の正答率は0.67であった。これは、チャンスレベルの0.33を大幅に超えているものの、高い識別率とは言えない。このことから、ぬいぐるみを力覚情報のみで比較するタスク自体が難しかったと考えられる。しかしながら、力覚提示装置を用いた実験では正答率が0.33となり、実物体の場合よりもさらに低い結果となっていることから、本手法の力覚提示が材料の弁別において十分な性能は実現できなかったと言える。

以上の結果から提案手法の力覚提示により実物体の力覚を再現することは困難であることが分かった。しかし、実験を通して力覚提示に目立った問題や違和感はなかった。材質の弁別においては十分な結果が得られなかったが、今後の実験でタスクの選定から検討しなおし、弁別可能な条件を調査することで本手法が有効に用いられる範囲を明確化していく必要がある。

5 結言

本研究ではMoCapによる手動力覚スキャンを行い、その測定値を学習した学習モデルによるデータ

駆動力覚提示手法を提案し、従来のデータ駆動手法では困難であった大型サイズ（300mm×120 mm）の物体の力覚提示を実現した。さらに提案手法のユーザ評価を行い、力覚提示自体はおおむね安定して行われ実用性が認められた。しかしながら、剛性の弁別は本実験では実現されず、課題が残った。

今後は本手法の有効な範囲を明らかにするために、より多様な条件を検討し、妥当性のあるタスクを用いてユーザ評価を行っていく。また、より忠実性の高い力覚提示を実現するために、粘弾性の影響を考慮した速度を学習データに含めた学習手法の開発や、今回は一方力覚提示であったものを多方向に拡張するなどの改良を行う予定である。

参考文献

- [1] T. Massie and K. Salisbury, "The PHANTOM Haptic Interface: A Device for Probing Virtual Objects," Proc. the ASME Winter Annual Meeting, 1994.
- [2] T.R. Coles, D. Meglan, and N.W. John, "The Role of Haptics in Medical Training Simulators: A Survey of the State of the Art," IEEE Trans. on Haptics, vol. 4, no. 1, pp. 51–66, 2010.
- [3] 佐瀬, 岸本, 熱海, "力覚インタラクションが可能なVRナマコの制作 ～生き物の3Dモデリングとハプティックレンダリング手法～", 日本バーチャルリアリティ学会 ハプティクス研究委員会 第20回研究会予稿集, PI-18-035, 2018.
- [4] 佐瀬, 木野瀬, 岸本, 石井, "排泄ケアの抵抗感軽減を目指した触覚VRシステムの開発", 日本バーチャルリアリティ学会ハプティクス研究委員会第21回研究会予稿集, pp. 23–26, 2018.
- [5] K. Miller, A. Wittek, and G. Joldes, "Biomechanics of the Brain for Computer-integrated Surgery," Acta of Bioengineering and Biomechanics, vol. 12, pp. 25–36, 2010.
- [6] R. Höver, M. Harders, and G. Székely, "Data-Driven Haptic Rendering of Visco-Elastic Effects," in Proc. of the 2008 IEEE Int. Conf. on Haptic Interface For Virtual

Environment and Teleoperator Systems, pp. 201–208, 2008.

- [7] R. Höver, G. Kosa, G. Székely, and M. Harders, “Data-driven Haptic Rendering From Viscous Fluids to Visco-Elastic Solids,” *IEEE Trans. on Haptics*, vol. 2, no. 1, pp. 15–27, 2009.
- [8] R. Höver, M.D. Luca, and M. Harders, “User-Based Evaluation of Data-Driven Haptic Rendering,” *ACM Trans. on Applied Perception*, vol. 8, no. 1, pp. 1–23, 2010.
- [9] 下垣, 水田, 増田, 松田, “3次元反力取得・表示システムを用いた仮想物体と実物体の力覚情報比較”, *日本バーチャルリアリティ学会論文誌*, vol. 8, no. 2, pp. 145–154, 2003.
- [10] A. Abdulali, I.R. Atadjanov, S. Lee, and S. Jeon, “Realistic Haptic Rendering of Hyper-Elastic Material via Measurement-Based FEM Model Identification and Real-time Simulation,” *Computers & Graphics*, vol. 89, pp. 38–49, 2020.