

ゲーム理論的学習による McKibben 型空気圧ゴム人工筋のパラメータ推定

内藤 諒*・小木曾 公尚**

Parameter Estimation of McKibben Pneumatic Artificial Muscle System by Game-theoretic Learning

Ryo NAITO* and Kiminao KOGISO**

This paper discusses about estimating nine parameters of a nonlinear model of a McKibben pneumatic artificial muscle (PAM) system in a game-theoretic learning way. An algorithm for the learning is constructed to find a Nash equilibrium in which the parameters induce transient and output responses close to corresponding experimental reference data. With a practical PAM system we made for validation, then, it is confirmed that the learning algorithm can estimate better parameter values in the sense of how close the computed responses and the reference data are and of how long it takes to acquire the parameter values.

Key Words: McKibben pneumatic artificial muscle, parameter estimation, game-theoretic learning

1. はじめに

McKibben 型空気圧ゴム人工筋は、非伸縮性のメッシュで包まれたゴムチューブ内部に圧縮空気を注入することで膨張させて収縮力を発生させる。このような構造を有する人工筋は、大部分がチューブとメッシュで構成されるために軽量であり、出力荷重比や柔軟性に優れている。ゆえに、ロボットの軽量化や使用者の安全確保が必要なりハビリテーション機器¹⁾、トレーニング用装具²⁾やパワーアシスト装具³⁾、そして、医用機器⁴⁾などのアクチュエータに適している。

その一方で、空気圧ゴム人工筋のモデル化と制御は、挑戦的課題である^{5),6)}。これは、ゴムチューブの形状変化、圧縮空気の断熱変化、メッシュ部分の摩擦力に起因するヒステリシスなどの非線形性^{7)~11)}が存在するためである。空気圧ゴム人工筋のモデル化や制御に関する従来研究では、その多くがヒステリシスの線形近似や人工筋全体を一次や二次の関数で経験的に近似する方法でモデル化を行ない、位置決めや力支援を実現するためのロバスト制御系^{6),12)}、スライディングモード制御系¹³⁾、ゲインスケジューリング制御系¹⁴⁾などで構築している。これらの場合、人工筋内の圧力帯域に応じて




Fig. 1 Illustration of considered PAM system

近似精度が異なるため、低圧域から高圧域において所望の制御仕様を一律に満たすことは難しい。そこで著者らは、一旦、第一原理に基づいて可能な限り非線形性を捉えたいうえで人工筋の妥当な数理モデルを導出し、非線形補償や近似の必要性に関する議論を経たのち、適切な制御系設計を構築する制御工学的手順を踏むこと、これが汎用的な人工筋アクチュエータの開発に繋がると考えている。

このような動機から、われわれは、制御弁への指令値から人工筋の収縮率および内圧を出力とする人工筋システム (Fig. 1) の非線形モデルを提案した^{9),15)}。ただし、そのモデルのパラメータ値は、試行錯誤で決めていた。そこで本稿では、ゲーム理論的学習の枠組みに基づいてパラメータを推定する方法を提案する。事前に取得した参照実験データとパラメータの暫定値を用いた数値予測結果を比較し、その誤差(効用)を評価することでナッシュ均衡に対応するパラメータ値を決定する方法である。ゲーム理論的学習の利点は、個々のパラメータに対して誤差を評価する点にあり、パラメータベクトルに対して一括りに解を確定させる既存手法(準ニュートン法など)に比べ、各パラメータごとに柔軟に探索できる。実際に、あるパラメータ値がほかのパラメータ値に比べて極端に大き

* 奈良先端科学技術大学院大学情報科学研究科
生駒市高山町 8916-5

** 電気通信大学大学院情報理工学研究科 調布市調布ヶ丘 1-5-1

* Graduate School of Information Science, Nara Institute of Science and Technology, 8916-5 Takayama-cho, Ikoma

** Department of Mechanical Engineering and Intelligent Systems, The University of Electro-Communications, 1-5-1 Chofugaoka, Chofu

(Received September 23, 2013)

(Revised January 23, 2014)

な更新が起こる場合、収縮力の時間応答に虚数が現れ、パラメータが推定できないことがある。またもう一つの利点として、提案法は、本来考えたい最適化問題の実行可能領域を有限個の格子点に限定するため、パラメータ推定に係る時間の短縮が期待される。そして最後に、提案法および既存手法を用いて実際の人工筋システムのパラメータ推定を行ない、効用関数値および計算時間を比較し、提案法の有用性を考察する。

本稿の構成は、つぎのとおりである。2章では、人工筋モデルの特徴およびそのパラメータを紹介する。3章では、パラメータ推定のアルゴリズムを提案する。4章では、提案法と既存手法(試行錯誤法, 準ニュートン法, そして, Nelder-Mead シンプレックス法)を用いて実機の人工筋システムのパラメータ推定を行ない, 既存手法との比較を通して提案法の有用性を考察する。そして最後に, 本稿をまとめる。

2. 空気圧ゴム人工筋システムの数理モデル

本稿では, ある質量のおもりが人工筋に吊り下げられた状況 (Fig. 1) において, 比例流量制御弁の開度を調整する司令電圧値を入力, 伸縮する人工筋の長さおよび内圧の計測値を出力とする人工筋モデルを考え, そこに含まれるパラメータを推定する問題を考える。まず本章では, 対象とする人工筋システムのモデルおよびパラメータを紹介する。なお, このモデルを導出する過程などの詳細は, 文献 9), 15) を参照の

こと。

人工筋システムの数理モデルは, 状態変数 $x := [\epsilon \dot{\epsilon} P]^T \in \mathbb{R}^3$ で定義される 32 個の非線形なサブシステムを有する切替え系で記述される。

$$\dot{x}(t) = f_{\sigma}(x(t), u_c(t)) \text{ if } x(t) \in \mathcal{X}_{\sigma} \quad (1a)$$

$$y(t) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} x(t) \quad (1b)$$

ここで, 入力変数 $u_c \in \mathcal{U} \subset \mathbb{R}$, 出力変数 $y := [\epsilon P]^T \in \mathbb{R}^2$, サブシステムの指標 $\sigma \in \Sigma := \{1, 2, \dots, 32\}$ とし, 集合 $\mathcal{X}_{\sigma} \subset \mathbb{R}^3$ は, 切替条件を規定する状態の部分集合である。この人工筋モデル (1) に含まれる変数やパラメータの一覧を **Table 1** に示す。この系は, 任意定数の $\bar{u}_c \in \mathcal{U}$ に対してある σ が一意に存在し, $f_{\sigma}([\epsilon 0 \bar{P}]^T, \bar{u}_c) = 0$ を満たす。つまり, \bar{u}_c における平衡状態は, 収縮率 $\bar{\epsilon}$ および内圧 \bar{P} で表わせる。

人工筋モデル (1) は, つぎの特徴を有することが確認されている¹⁵⁾。

[命題] 人工筋モデル (1) に対し, おもり質量 M 上のある実数区間 $[a, b]$ ($0 \leq a \leq b$) が存在し, その区間内で $K, \theta, C_{q1}, C_{q2}, c_c$ が定常特性に影響を, また, A_0, k_1, k_2, c_v が過渡特性に影響を与える。

この命題より, パラメータ推定は, 定常特性と過渡特性の二グループに分けて行なえることがわかる。

3. ゲーム理論的学習による推定アルゴリズム

本章では, 本来扱いたい推定問題を記述した後, 解探索を実行可能領域の格子点上に制限するゲーム理論的学習アルゴリズムを構成する。

パラメータ推定の方針は, 事前に実機より取得した参照データ \mathbb{D}_{exp} ^(注 1) が取得できるとし, モデルより数値的に得られる予測データを比較し, その差が小さくなるパラメータ値を見つけることである。これは, 決定変数をパラメータ $p = (K, \theta, C_{q1}, C_{q2}, c_c, A_0, k_1, k_2, c_v) \in \mathbb{R}^9$ とする, つぎの非線形計画問題で一般的に定式化される。

$$\inf_{p \in \mathbb{R}^9} d(\mathbb{D}_{\text{sim}}(p), \mathbb{D}_{\text{exp}}) \quad (2)$$

s.t. discretized model of (1) generates $\mathbb{D}_{\text{sim}}(p)$

ここで, $\mathbb{D}_{\text{sim}}(p)$ は, あるパラメータ値 p を用いて得られるシミュレーション結果 (\mathbb{D}_{exp} に該当する定常応答および時間応答) であり, $d(\cdot, \cdot)$ は, 与えられた二データ集合間の距離を示す関数である。この最適化問題を一般的に解くことは, 困難であると思われる。

一方, 命題より, 推定手順は, 定常応答および過渡応答に関連するパラメータ群に分けることができるうえ, 各パラメー

(注 1) 本稿では, ステップ入力に対する圧力と収縮率の時間応答 (過渡応答) および定常値 (定常応答) のテストデータを表わす。

Table 1 Variables and parameters of PAM system

l	: length of PAM [m]	variables
$\epsilon = \frac{L-l}{L}$: contraction ratio [-]	
$\dot{\epsilon} = \frac{d\epsilon}{dt}$: velocity of contraction ratio [-]	
P	: absolute internal gas pressure [Pa]	
V	: volume of PAM [m ³]	
m	: mass flow rate [kg/s]	
D_0	: natural diameter of PAM [m]	parameters determined in advance
L_0	: natural length of PAM [m]	
L	: initial length of PAM after weight loaded [m]	
D_1, D_2, D_3	: coefficients of polynomial [m ³]	
M	: mass of the weight [kg]	
g	: gravitational acceleration [m/s ²]	
P_{tank}	: source absolute pressure [Pa]	
P_{out}	: atmospheric pressure [Pa]	
k	: specific heat ratio for air [-]	
R	: ideal gas constant [J/kg·K]	
T	: absolute temperature [K]	
K	: coefficient of elasticity [N/m ³]	parameters to be identified
θ	: initial angle between braided thread and cylinder long axis [deg]	
C_{q1}	: correction coefficients [-]	
C_{q2}	: correction coefficients [1/Pa]	
c_c	: Coulomb friction [N]	
A_0	: orifice area of the valve [m ²]	
k_1, k_2	: polytropic indexes [-]	
c_v	: viscous friction coefficient [Ns/m]	

タが応答に与える影響 (変化傾向) がわかっている⁹⁾. たとえば, 定常特性に影響を与えるパラメータのうち, 低圧域は K , 中圧域は C_{q1} , 中高压域は θ , 高压域は C_{q1} , ヒステリシスループの幅は c_c がそれぞれ影響を与える. このような知見から, 本稿で扱う推定問題に関しては, パラメータベクトルを一括で確定させる勾配法に基づく探索アルゴリズムに比べ, パラメータごとに探索するほうが適切な解に近づくと期待される. そこで本稿では, パラメータがプレイヤ, 効用関数が d となるゲームを繰り返すことでナッシュ均衡に到達させる (解探索を行なう) アルゴリズムを構成する.

3.1 ゲームの設定

ゲーム $\mathcal{G}(\mathcal{P}, \mathcal{A}, u)$ は, 合理的な^(注 2) N プレイヤの集合 $\mathcal{P} := \{1, 2, \dots, N\}$, プレイヤ i の行動 $a_i \in \mathcal{A}_i := \{0, \Delta p_i\}$ (パラメータの更新幅 $\Delta p_i > 0$), 行動プロファイル $a \in \mathcal{A} := \prod_{i \in \mathcal{P}} \mathcal{A}_i$, 効用関数 $u: \mathcal{A} \rightarrow \mathbb{R}_-$ (\mathbb{R}_- は非正集合) で構成される. そして, 効用関数を $u(a) = -d(\mathbb{D}_{\text{sim}}(a), \mathbb{D}_{\text{exp}})$ とし, その実現は, 3.2 節に示す. なお, 以後は, 予測データ $\mathbb{D}_{\text{sim}}(p)$ の代わりに, $\mathbb{D}_{\text{sim}}(a)$ を用い, 行動プロファイルの記法として $a = (a_1, a_2, \dots, a_N) = (a_i, a_{-i})$ を用いる. 更新幅 Δp_i は適当に与える.

つぎに, ナッシュ均衡と最適反応の定義を示す.

【定義 1】 すべての $i \in \mathcal{P}$ およびすべての $a_i \in \mathcal{A}_i$ に対して $u(a^*) \geq u(a_i, a_{-i}^*)$ を満たすとき, a^* をナッシュ均衡という.

【定義 2】 行動プロファイル a_{-i} に対するプレイヤ i の最適反応 $BR_i(a_{-i})$ は, $BR_i(a_{-i}) = \{a_i \in \mathcal{A}_i \mid u(a_i, a_{-i}) \geq u(a'_i, a_{-i}) \forall a'_i \in \mathcal{A}_i\}$ である.

定義 1 および定義 2 から, すべての $i \in \mathcal{P}$ に対して $a_i^* \in BR_i(a_{-i}^*)$ を満たす a^* は, ナッシュ均衡である¹⁶⁾. 本問題におけるナッシュ均衡は, 評価誤差をさらに小さくさせるパラメータ更新がない状況を意味する. ここでは, プレイヤをナッシュ均衡に到達 (学習) させるための一戦略として, 最適反応に基づき行動を選択する最適反応戦略

$$\begin{aligned} & \arg \max_{a_i \in \mathcal{A}_i} (u(a_i, a_{-i})) \\ & = \arg \max (u(0, a_{-i}), u(\Delta p_i, a_{-i})) \end{aligned}$$

を採用する.

3.2 効用関数の実現

実現したい効用関数は, データ点列 (参照データと予測データ) から, それらを線形補完して得られる図形の差の面積を返す距離関数である. まずは, この効用関数の引数となる \mathbb{D}_{sim} と \mathbb{D}_{exp} のデータ構造を明記する. $\mathbb{D}_{\text{sim}}(a)$ は, 暫定パラメータ値 $p+a$ を用いて得られる圧力と収縮率の定常応答および時間応答 (ステップ応答) を納めた予測データである. そのなかで, 定常応答のデータを $\mathbb{D}_{\text{sim},s}$, 過渡応答のデータを $\mathbb{D}_{\text{sim},t}$ と記す. さらに, 定常応答時には, ヒステリシスループが生じるため, $\mathbb{D}_{\text{sim},s}$ は, 収縮時のデータ $\mathbb{D}_{\text{sim},s}^{\text{dila}}$ と膨張時のデー

タ $\mathbb{D}_{\text{sim},s}^{\text{cont}}$ で構成される. よって,

$$\begin{aligned} \mathbb{D}_{\text{sim}} &= \{\mathbb{D}_{\text{sim},s}, \mathbb{D}_{\text{sim},t}\} = \{\mathbb{D}_{\text{sim},s}^{\text{dila}}, \mathbb{D}_{\text{sim},s}^{\text{cont}}, \mathbb{D}_{\text{sim},t}\} \\ &= \left\{ \left\{ (\bar{P}_{si}^d, \bar{\epsilon}_{si}^d) \right\}_{i=1}^{N_s^d}, \left\{ (\bar{P}_{si}^c, \bar{\epsilon}_{si}^c) \right\}_{i=1}^{N_s^c}, \right. \\ & \quad \left. \left\{ (t_{si}, P_{si}(t_{si}), \epsilon_{si}(t_{si})) \right\}_{i=1}^{N_t^t} \right\} \end{aligned}$$

ただし, N_s^d , N_s^c , N_t^t は, 対応するデータ数を示す. 同様に, 実験データセット \mathbb{D}_{exp} は, $\mathbb{D}_{\text{exp},s}$ と $\mathbb{D}_{\text{exp},t}$ で構成される. また, $\mathbb{D}_{\text{exp},s}$ は膨張時のデータ $\mathbb{D}_{\text{exp},s}^{\text{dila}}$ と収縮時のデータ $\mathbb{D}_{\text{exp},s}^{\text{cont}}$ で構成される.

$$\begin{aligned} \mathbb{D}_{\text{exp}} &= \{\mathbb{D}_{\text{exp},s}, \mathbb{D}_{\text{exp},t}\} = \{\mathbb{D}_{\text{exp},s}^{\text{dila}}, \mathbb{D}_{\text{exp},s}^{\text{cont}}, \mathbb{D}_{\text{exp},t}\} \\ &= \left\{ \left\{ (\bar{P}_{ei}^d, \bar{\epsilon}_{ei}^d) \right\}_{i=1}^{N_e^d}, \left\{ (\bar{P}_{ei}^c, \bar{\epsilon}_{ei}^c) \right\}_{i=1}^{N_e^c}, \right. \\ & \quad \left. \left\{ (t_{ei}, P_{ei}(t_{ei}), \epsilon_{ei}(t_{ei})) \right\}_{i=1}^{N_t^t} \right\} \end{aligned}$$

ただし, N_e^d , N_e^c , N_t^t は, 対応するデータ数を示す.

本稿では, 定常と過渡ごとに予測データと参照実験データとの面積誤差を台形と三角形に区分けし, その面積和を計算する関数 d を実現したい. これを実現するための手順を以下に示す (Fig. 2 を参照, ただし, 定常応答および過渡応答では, 横軸-縦軸を, 適宜, 圧力-収縮率, および, 時刻-圧力, 時刻-収縮率にそれぞれ読み替えること).

Step 1. 定常応答に関して, 二つのデータセットで表わされる差の面積を測るため, 圧力の範囲を $[0, \alpha_l]$, $[\alpha_l, \alpha_h]$, $[\alpha_h, \infty]$ の低・中・高压域に分割する. Fig. 2 (a) が中圧域, 同図 (d) が低圧域で予測データが参照データより外側にある場合を示し, 高压域も低圧域と同様に分割する. α_l と α_h は, 次式から求まる.

$$\alpha_l = \max \left(\min_i \left(\left\{ \bar{P}_{si}^d \right\}_{i=1}^{N_s^d}, \left\{ \bar{P}_{si}^c \right\}_{i=1}^{N_s^c} \right), \min_i \left(\left\{ \bar{P}_{ei}^d \right\}_{i=1}^{N_e^d}, \left\{ \bar{P}_{ei}^c \right\}_{i=1}^{N_e^c} \right) \right) \quad (3)$$

$$\alpha_h = \min \left(\max_i \left(\left\{ \bar{P}_{si}^d \right\}_{i=1}^{N_s^d}, \left\{ \bar{P}_{si}^c \right\}_{i=1}^{N_s^c} \right), \max_i \left(\left\{ \bar{P}_{ei}^d \right\}_{i=1}^{N_e^d}, \left\{ \bar{P}_{ei}^c \right\}_{i=1}^{N_e^c} \right) \right) \quad (4)$$

たとえば, Fig. 2 (d) の破線が圧力 α_l を表わす.

Step 2. 中圧域のデータ $[\alpha_l, \alpha_h]$ を処理する. ある $i \in \{1, \dots, N_s^d\}$ に対して, $\bar{P}_{ej-1}^d \leq \bar{P}_{si}^d \leq \bar{P}_{ej}^d$ となる適当な $j, j-1 \in \{2, \dots, N_e^d\}$ が存在する. そこで, 数値結果データ $(\bar{P}_{si}^d, \bar{\epsilon}_{si}^d)$ を一次近似した実験データ線分上に写像 Ψ で写す.

$$\Psi: (\bar{P}_{si}^d, \bar{\epsilon}_{si}^d) \mapsto \left(\bar{P}_{si}^d, \frac{\bar{\epsilon}_{ej}^d - \bar{\epsilon}_{ej-1}^d}{\bar{P}_{ej}^d - \bar{P}_{ej-1}^d} (\bar{P}_{si}^d - \bar{P}_{ej}^d) + \bar{\epsilon}_{ej}^d \right)$$

ただし, 写像したすべての点集合を $\Psi(\mathbb{D}_{\text{sim},s})$ とする. 同様に, 実験データも一次近似したシミュレーション結果データ線分上に写像する.

$$\Psi: (\bar{P}_{ei}^d, \bar{\epsilon}_{ei}^d) \mapsto \left(\bar{P}_{ei}^d, \frac{\bar{\epsilon}_{sj}^d - \bar{\epsilon}_{sj-1}^d}{\bar{P}_{sj}^d - \bar{P}_{sj-1}^d} (\bar{P}_{ei}^d - \bar{P}_{sj}^d) + \bar{\epsilon}_{sj}^d \right)$$

ただし, 写像したすべての点群を $\Psi(\mathbb{D}_{\text{exp},s})$ とする. さらに,

(注 2) 効用関数値を最大化するように行動を選択すること.

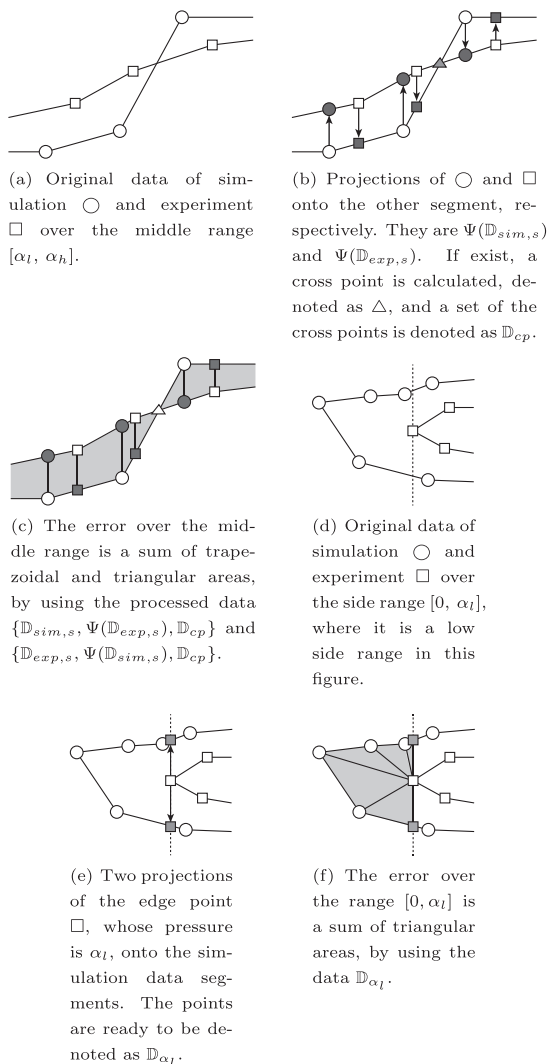


Fig. 2 Procedure of calculating the utility $u(a)$, which provides an accurate area error between $\mathcal{D}_{sim}(a)$, and \mathcal{D}_{exp} , denoted as \circ and \square respectively. (a)-(c) are about processing the data over the middle range and (d)-(f) are about processing over the (low) side range in the steady state. In the case of the transient responses, the similar technique of (a)-(c) is used to calculate error areas

シミュレーション結果と実験結果に交点が存在する場合は、交点の集合を求め \mathbb{D}_{cp} とする (Fig. 2 (e) (f) 参照). 加えて、上記の手順を収縮時も考えるが、本稿では省略する.

Step 3. 低高圧域 $[0, \alpha_l]$ と $[\alpha_h, \infty]$ における誤差面積を計算する. $[0, \alpha_l]$ の範囲で (3) より求まる α_l を与えるデータ点と α_l 以下の圧力値となるデータ点を結ぶ (Fig. 2 (f) 参照). これらの点集合を \mathbb{D}_{α_l} とする. 同様に, $[\alpha_h, \infty]$ の範囲で (4) より求まる α_h を与えるデータ点と α_h 以上の圧力値となるデータ点を結ぶ. これらの点集合を \mathbb{D}_{α_h} とする.

Step 4. 過渡応答における誤差面積を計算する. 対応するデータ $\mathbb{D}_{sim,t}$ と $\mathbb{D}_{exp,t}$ に Step 2. の手順を適用し, $\{\mathbb{D}_{sim,t}, \Psi(\mathbb{D}_{exp,t})\}$ と $\{\mathbb{D}_{exp,t}, \Psi(\mathbb{D}_{sim,t})\}$ を得る.

Algorithm 1 Parameter Estimation Algorithm

Require: \mathbb{D}_{exp} , $k \leftarrow 0$, $p^s(0) \neq p^s(-1)$, $p^t(0) \neq p^t(-1)$

Ensure: values p^s and p^t .

```

1: while  $p_i^s(k)$  is not  $p_i^s(k-1)$  for some  $i$  do
2:   for  $i = 1$  to 5 do
3:      $a_i^* \leftarrow \arg \max_{a_i \in \mathcal{A}_i^s} -d(\mathbb{D}_{sim,s}(a_i, a_{-i}), \mathbb{D}_{exp,s})$ 
4:      $p_i^s(k) \leftarrow p_i^s(k-1) + a_i^*$ 
5:   end for
6:    $k \leftarrow k + 1$ 
7: end while
8:  $k \leftarrow 0$ 
9: while  $p_i^t(k)$  is not  $p_i^t(k-1)$  for some  $i$  do
10:  for  $i = 1$  to 4 do
11:     $a_i^* \leftarrow \arg \max_{a_i \in \mathcal{A}_i^t} -d(\mathbb{D}_{sim,t}(a_i, a_{-i}), \mathbb{D}_{exp,t})$ 
12:     $p_i^t(k) \leftarrow p_i^t(k-1) + a_i^*$ 
13:  end for
14:   $k \leftarrow k + 1$ 
15: end while

```

Step 5. 定常にかかわるデータ $\{\mathbb{D}_{sim,s}, \Psi(\mathbb{D}_{exp,s}), \mathbb{D}_{cp}\}$, $\{\mathbb{D}_{exp,s}, \Psi(\mathbb{D}_{sim,s}), \mathbb{D}_{cp}\}$, \mathbb{D}_{α_l} , \mathbb{D}_{α_h} を収縮・膨張に注意して整列する. また, 過渡にかかわるデータ $\{\mathbb{D}_{sim,t}, \Psi(\mathbb{D}_{exp,t})\}$ と $\{\mathbb{D}_{exp,t}, \Psi(\mathbb{D}_{sim,t})\}$ を整列する. この結果, 誤差面積は, 最小単位の三角形と台形で構成され, その総和を求めることができる (注 3). そして, 得られた値に -1 をかける.

3.3 ゲーム理論的学習による推定アルゴリズム

これまでに示したゲームに基づくパラメータ推定アルゴリズムを Algorithm 1 に示す. 命題から, 提案アルゴリズムは, 定常および過渡特性に影響を与えるパラメータを探索する二つのゲームで構成される. 一つ目は, プレイヤ $p^s = (K, \theta, C_{q1}, -\frac{1}{C_{q2}}, c_c)$ および行動 $\Delta p^s = (\Delta K, \Delta \theta, \Delta C_{q1}, \Delta C_{q2}, \Delta c_c)$ と零を用いた $\mathcal{G}_s(\mathcal{P}^s, \mathcal{A}^s, u)$ であり, 2 行目から 6 行目で実行される. そして, 二つ目は, プレイヤ $p^t = (A_0, k_1, \frac{1}{k_2}, \frac{1}{c_v})$ および行動 $\Delta p^t = (\Delta A_0, \Delta k_1, \Delta k_2, \Delta c_v)$ と零を用いた $\mathcal{G}_t(\mathcal{P}^t, \mathcal{A}^t, u)$ であり, 10 行目から 14 行目で実行される. ここで, ゲームが最適反応戦略にもとづいてプレイされるたびに, 各パラメータおよび効用関数値は, 単調に増加する. そして, 効用関数が上に有界で, 行動集合が有限かつ非負であるため, \mathcal{G}_s および \mathcal{G}_t の繰り返しは, finite improvement property を満たす有限の非巡回ゲームである. したがって, 提案アルゴリズムは, 有限回で終了し, 終了条件 (1, 9 行目) から得られるパラメータは, ナッシュ均衡である.

提案アルゴリズムでは, 大域的最適解の保証が難しいため, 実際にパラメータ推定を行ない, 提案アルゴリズムの有用性を既存手法と比較して検討する必要がある.

4. 提案アルゴリズムの適用と有用性の確認

本章では, 3.3 節で提案したゲーム理論的学習アルゴリズムを Fig. 3 の実験装置に適用し, パラメータが推定可能なこと, そして, 効用値と計算時間に関する既存手法との比較結果から提案法

(注 3) MATLAB の関数 `polyarea` を用いる.


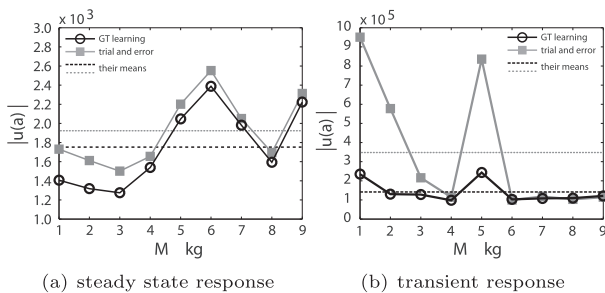


Fig. 3 Experimental PAM system

Fig. 4 Utility values: the proposed algorithm and our previous trial-and-error method¹⁵⁾

の有用性を確認する。本実験装置では、アクティブリンク社製の人工筋 (TAA10, 直径 10 mm) と FESTO 社製の比例流量制御弁 (MPYE-5-M5-010-B) を用いる。実測可能なパラメータ値は, $D_0 = 0.01$ m, $L_0 = 0.250$ m, $D_1 = -347.8 \times 10^{-6} \text{m}^3$, $D_2 = 232.2 \times 10^{-6} \text{m}^3$, $D_3 = 27.69 \times 10^{-6} \text{m}^3$, $P_{\text{tank}} = 0.7013 \times 10^6$ Pa, $P_{\text{out}} = 0.1013 \times 10^6$ Pa, $k = 1.4$, $R = 287$ J/kg·K, $T = 293$ K であり, $M = 1, 2, \dots, 9$ kg の各負荷ごとに実験参照データ \mathbb{D}_{exp} を取得し, パラメータ推定を行なう。なお, $\mathbb{D}_{\text{exp},s}$ は, 加圧・減圧に関して 0 から 6.0 V の範囲で, それぞれ 32 種類のステップ信号を制御弁に入力して得られる内圧と収縮率の定常値である。 $\mathbb{D}_{\text{exp},t}$ は, 制御弁への入力を 4.7 から 4.8 V にステップ状に変化させて得られる時間応答である。数値計算は, ORACLE 社 Sun Blade 6000 Chassis (CentOS5.8, CPU 2.93 GHz, Mem. 24 GB) を用いた。

まず, 提案法と試行錯誤法¹⁵⁾の推定結果から得られる効用関数値を Fig. 4 に図示して比較する。同図 (a) (b) は, それぞれ, 定常応答と過渡応答での効用関数値とその平均を表わす。両図から, 効用関数の意味で試行錯誤法より良好なパラメータが推定できている。ここで, $M = 5$ kg でのパラメータの初期値 $p_5^s(0)$, $p_5^t(0)$ および更新幅 Δp_5^s , Δp_5^t を挙げておく。

$$p_5^s(0) = (1.450 \times 10^7, 0.3537, \\ 0.7613, 5.728 \times 10^4, 6.090) \\ p_5^t(0) = (1.015 \times 10^{-8}, 0.2450, 0.1750, 1.750 \times 10^{-2})$$

$$\Delta p_5^s = (1.375 \times 10^5, 0.1922, \\ 7.219 \times 10^{-3}, 5.431 \times 10^2, 5.775 \times 10^{-2}) \\ \Delta p_5^t = (2.392 \times 10^{-8}, 0.5775, 0.4125, 4.125 \times 10^{-2})$$

このときの更新過程を Fig. 5 に示し, 推定パラメータを用いて得られる圧力と収縮率の定常応答を Fig. 6 に, 内圧と収縮率の時間応答を Fig. 7 に, それぞれ図示する。ここで, 各図中にある灰色の面積が関数 d の値となる。まず, Fig. 5 に関して, 定常特性と過渡特性に影響を与えるパラメータのゲームプレイ回数は, 100 と 3 回であった。各パラメータ値が更新されるたびに増加し, それに従い効用関数値も増加していることがわかる。Fig. 6 に関して, パラメータ推定後と推定前 (パラメータ初期値) の定常応答を Fig. 6 (a) (b) に示す。このとき, 効用値は, Fig. 5 (f) からわかるように, 推定前が -2.201×10^5 なのに対し, 推定後は -1.988×10^3 である。そして, Fig. 7 に関して, 推定後と推定前の過渡応答を Fig. 7 (a) (b) に示す。このとき, 効用値は, Fig. 5 (k) からわかるように, 推定前が -8.437×10^7 なのに対し, 推定後は -2.562×10^5 である。

つぎに, 提案法と準ニュートン法 (qN 法) および Nelder-Mead シンプレックス法 (NM 法)^(注 4)の推定結果から得られる効用関数値を Fig. 8 に図示して比較する。同図 (a) (b) は, それぞれ, 定常応答および過渡応答の効用関数値とその平均値を示す。ただし, qN 法の平均値は, $M = 3, 6$ kg 以外を用いている。これは, 同負荷では, パラメータ更新の途中で圧力と収縮率が虚数となり, 効用値を求められず, 推定ができなかったからである。各手法の平均値は, Fig. 8 (a) では, 提案法が -1.752×10^3 , qN 法が -1.502×10^3 , NM 法が -2.505×10^3 であり, qN 法が比較的良好なパラメータが求まっている。一方, Fig. 8 (b) では, 提案法が -1.417×10^5 , qN 法が -1.388×10^6 , NM 法が -2.246×10^5 であり, 提案法が比較的良好なパラメータが求まっている。

そして, 提案法と qN 法および NM 法を用いてパラメータ推定に要する計算時間を Fig. 9 に図示して比較する。同様に, Fig. 9 (a) (b) は, それぞれ, 定常応答および過渡応答での所要時間とその平均値を示し, qN 法に関しては, $M = 3, 6$ kg 以外を用いている。各手法の平均時間は, Fig. 9 (a) では, 提案法が 8.41 h, qN 法が 8.98 h, NM 法が 34.70 h であり, 提案法が比較早く推定が終わることを示している。一方, Fig. 9 (c) では, 提案法が 0.17 h, qN 法が 0.72 h, NM 法が 1.03 h であり, これも提案法が比較早く推定が終わることを示している。提案法の計算時間が短いのは, qN 法や NM 法が実行可能領域全面を対象に解探索するのに対し, 提案法は, 解探索を実行可能領域の格子点上 (有限個) に制限しているためと考えられる。

以上から, 実際の人工筋システムを用いて, 既存手法 (試行

(注 4) qN 法は, MATLAB の関数 `fminunc`, NM 法は, 関数 `fminsearch` に実装されている。

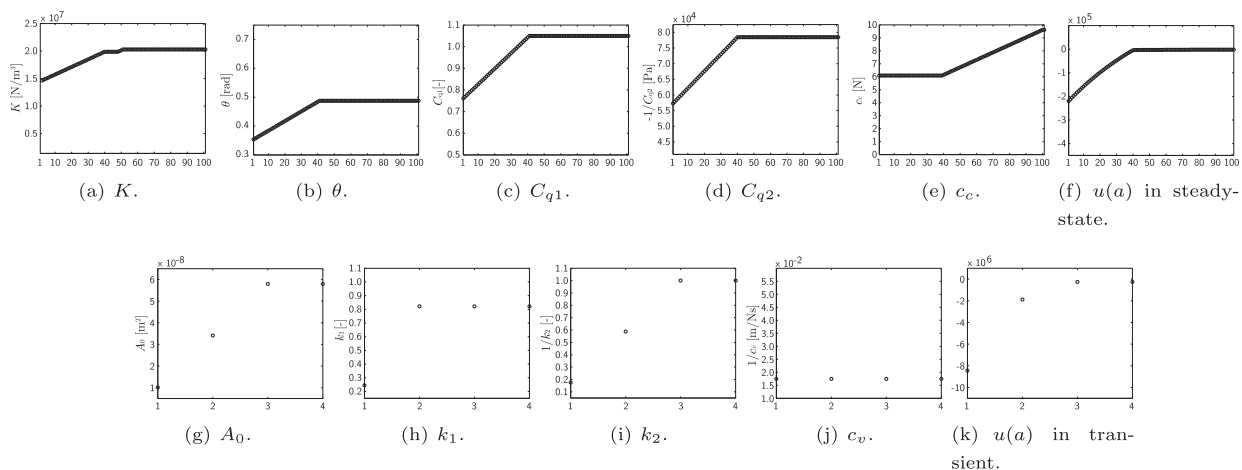




Fig. 5 How the parameters and the utility values are updated during playing the games in the proposed algorithm ($M = 5$ kg)



(a) After the learning, then $u(a^*) = -1.988 \times 10^3$ with $p_5^s(100)$. (b) Before the learning, then $u(a) = -2.201 \times 10^5$ with $p_5^s(0)$. (c) The heuristic algorithm in our work, then $-d_5(\mathbb{D}_{sim,s}, \mathbb{D}_{exp,s}) = -2.201 \times 10^3$.

Fig. 6 Comparison of steady-state responses of experimental data $\mathbb{D}_{exp,s}$ as '□' and simulation data $\mathbb{D}_{sim,s}$ as '○' under $M = 5$ kg, before and after applying the proposed game-theoretic learning algorithm to the parameter estimation. Areas in grey expresses the error, $d(\mathbb{D}_{sim,s}, \mathbb{D}_{exp,s})$



(a) After the learning, then $u(a^*) = -2.562 \times 10^5$ with $p^t(3)$. (b) Before the learning, then $u(a) = -8.437 \times 10^7$ with $p^t(0)$. (c) The heuristic algorithm in our work, then $-d(\mathbb{D}_{sim,t}, \mathbb{D}_{exp,t}) = -8.360 \times 10^5$.

Fig. 7 Comparison of time responses of experimental data $\mathbb{D}_{exp,t}$ as '□' and simulation data $\mathbb{D}_{sim,t}$ as '○' under $M = 5$ kg, before and after applying the proposed game-theoretic learning algorithm to the parameter estimation. Areas in grey expresses the error, $d(\mathbb{D}_{sim,t}, \mathbb{D}_{exp,t})$

錯誤法, qN 法, NM 法) と比較した結果, 提案法は, 効用値の意味でおおむね良好なパラメータを求められることを確認した. さらに, 推定に係る計算時間は, 既存手法より比較的短いことも確認できた. したがって, 提案法は, 人工筋モデルに対して有用なパラメータ推定法である.

5. おわりに

本稿では, McKibben 型空気圧人工筋の非線形モデルに対してパラメータを推定する手順を, ゲーム理論的学習アルゴリズムで構成した. 実機を用いたパラメータ推定により, 提案法では, 既存手法より, 定常応答および過渡応答の参照データ

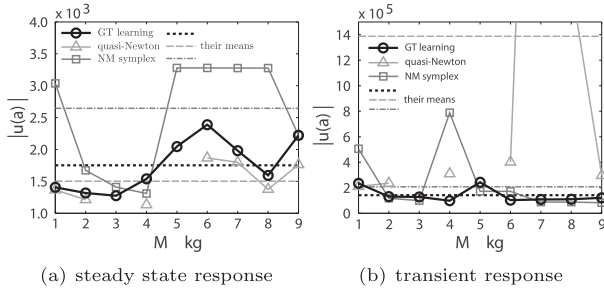


Fig. 8 Utility values: the proposed algorithm, quasi-Newton method, and Nelder-Mead simplex method

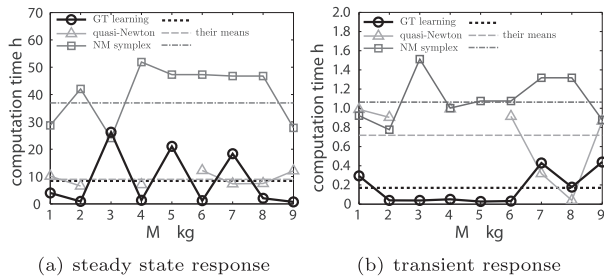


Fig. 9 Computation time: the proposed algorithm, quasi-Newton method, and Nelder-Mead simplex method

に近い応答となるパラメータを、より少ない計算時間で求められることがわかった。今後の課題としては、ほかの人工筋を用いたパラメータ推定や負荷変動時におけるモデルの妥当性検証、拮抗配置のモデル導出、その低次元化法、ハイブリッド制御による人工筋の位置決め/力制御などを検討したい。

謝辞 本研究は、日本学術振興会 科学研究費補助金 25709014 の助成を受けたものです。

参考文献

- 1) T. Noritsugu and T. Tanaka: Application of rubber artificial muscle manipulator as a rehabilitation robot, *IEEE/ASME Trans. Mech.*, **2-4**, 259/267 (1997)
- 2) N.G. Tsagarakis and D.G. Caldwell: Development and control of a 'soft-actuated' exoskeleton for use in physiotherapy and training, *Autonom. Robot.*, **15-1**, 21/33 (2003)
- 3) X. Li, T. Noritsugu, M. Takaiwa and D. Sasaki: Design of wearable power assist wear for low back support using pneumatic actuators, *Int. J. Autom. Technol.*, **7-2**, 228/236 (2013)
- 4) H. Li, K. Kawashima, K. Tadano, S. Ganguly and S. Nakano: Achieving haptic perception in forceps manipulator using pneumatic artificial muscle, *IEEE/ASME Trans. Mech.*, **18-1**, 74/85 (2013)
- 5) C.P. Chou and B. Hannaford: Measurement and modeling of McKibben pneumatic artificial muscles, *IEEE Trans. Robotics Autom.*, **12-1**, 90/102 (1996)
- 6) B. Tondu and P. Lopez: Modeling and control of McKibben artificial muscle robot actuators, *IEEE Contr. Syst. Mag.*, **20-2**, 15/38 (2000)
- 7) E. Richer and Y. Hurmuzlu: A high performance pneumatic force actuator system, Part I: Nonlinear mathematical model, *J. Dynamic Syst., Measure., Contr.*, **122-3**, 416/425 (2000)
- 8) T. Vo-Minh, T. Tjahjowidodo, H. Ramonm and H.V.

Brussel: A new approach to modeling hysteresis in a pneumatic artificial muscle using the Maxwell-slip model, *IEEE Trans. Mech.*, **16-1**, 177/186 (2011)

- 9) K. Kogiso, K. Sawano, T. Itto and K. Sugimoto: Identification procedure for McKibben pneumatic artificial muscle systems, *IEEE/RSJ Int. Conf. Intell. Robots Syst.*, 3714/3721 (2012)
- 10) 香川, 藤田, 山中: 人工筋アクチュエータの非線形モデル, 計測自動制御学会論文集, **29-10**, 1241/1243 (1993)
- 11) 木村, 藤田, 原, 香川: 厳密な線形化を用いた空気圧アクチュエータ駆動系の制御, システム制御情報学会論文誌, **8-2**, 53/60 (1995)
- 12) S. Balasubramanian, J. Ward, T. Sugar and H. Jiping: Characterization of the dynamic properties of pneumatic muscle actuators, *IEEE 10th Int. Conf. Rehabilat. Robotics*, 764/770 (2007)
- 13) A. Pujana-Arrese, A. Mendizabal, J. Arenas, R. Prestamero and J. Landaluz: Modelling in Modelica and position control of a 1-DoF set-up powered by pneumatic muscles, *Mechatronics*, **20-5**, 535/552 (2010)
- 14) D.W. Repperger, C.A. Phillips and M. Krier: Controller design involving gain scheduling for a large scale pneumatic muscle actuator, *IEEE Int. Conf. Contr. Appl.*, 285/290 (1999)
- 15) 小木曾, 内藤: 負荷に依存するパラメータを用いた McKibben 型空気圧ゴム人工筋の数理モデル, システム制御情報学会論文誌, **26-7**, 269/276 (2013)
- 16) Y. Shoham and K. Leyton-Brown: *Multigent Systems: Algorithmic, Game-Theoretic, and Logical Foundations*, Cambridge University Press (2009)


[著者紹介]

内藤 諒 (学生会員)



2012 年関西大学システム理工学部機械工学科卒業, 同年奈良先端科学技術大学院大学情報科学研究科入学, 2014 年修了。同年 (株) デンソー入社, 現在に至る。空気圧ゴム人工筋のモデル化研究に従事。2013 年度奈良先端科学技術大学院大学最優秀学生賞受賞。

小木曾 公尚 (正会員)



2004 年大阪大学大学院工学研究科電子制御機械工学専攻博士後期課程修了。同年奈良先端科学技術大学院大学情報科学研究科 21 世紀 COE 研究員。2005 年同大学院助手, 助教, 2014 年電気通信大学大学院情報理工学研究科知能機械工学専攻准教授, 現在に至る。2010~2011 年ジョージア工科大学客員研究員。拘束システムやハイブリッドシステムの解析と制御, ゲーム理論とその工学応用に関する研究に従事。博士 (工学)。システム制御情報学会, 日本機械学会, IEEE の会員。