

はじめに
バイオミメティクスによる制御
内部モデルによる習熟メカニズム
提案手法
実験結果ならびに考察
おわりに
修正
修正
修正

なぞり運動における習熟メカニズムの バイオミメティクスの応用

Impedance Proficiency and Internal Model Reliability in Motor Learning

清水 豪士

富山県立大学 情報基盤工学講座
t715038@st.pu-toyama.ac.jp

Teams, 14:50-15:05 Monday, February 15, 2021,
Toyama Prefectural University.

1.1 本研究の背景

背景

- 近年、バイオミメティクスといわれる科学技術が発展してきている。
- 主に昆虫や動物、植物に関する模倣が主に行われていて、人間に関する模倣は少ないのが現状である。



図 1: バイオミメティクスの例

1.2 本研究の目的

目的

- 人間の習熟のメカニズムを解明し、工学的に応用する。
- なぞり運動実験で取得したデータを用いて、内部モデルの信頼度を算出する。
- 実験で取得したデータを用いて、インピーダンスパラメータを算出する。

鏡映描写課題

鏡に映った自分の手の像を見ながら図形をペンでなぞる課題

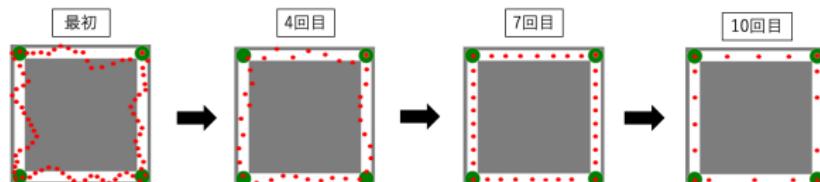


図 2: 鏡映描写課題

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

2.1 知覚運動学習と心理学実験

4/17

知覚運動学習

- 運動学習とは、「運動学習とは熟練した行動を作り出す能力における比較的永続した変化へと続く練習もしくは経験に関連する一連の過程」と定義されている。
- 運動学習では、どのように関節を動かせば効率良く運動ができるか、などといった知識を得ただけでは運動スキルを習得することはできなく、実際に効率良く運動させることができない限り“運動学習した”とはいえない。

PsychoPy によるなぞり実験

- PC を使って心理学実験を行うためのツール。
- 自分でプログラムを書いたり、プログラムが苦手な人はアイコンを配置することで簡単に実験を作成することができる。

2.2 人間制御者の数学モデル

はじめに
人間の推定機能がカルマンフィルタの情報処理機構に非常によく似た傾向を示す。

人間の推定機能の大きな特徴として、人間は過去の値、特に直前の変化率を大きな情報源として推定していることが明らかになっている。

目標点が特定の傾向を持って変化する場合は推定も非常に良いが、変化率が大きく変動する場合には人間はそれを過大評価してしまい、推定精度が低下してしまう¹。

実験の流れ

- 1 : 目標点としてsin波を基本とし、外乱を加えたものを実験対象者に提示する。
- 2 : 実験対象者にあらかじめ目標点の一部を観測させる。
- 3 : それを基に実験対象者は次の点を推定していく。
- 4 : 対象者ごとに外乱である分散を変更させる。
- 5 : この試行を繰り返し、人間の推定機能とカルマンフィルタによるモデルを比較する。

図 3: 実験の流れ

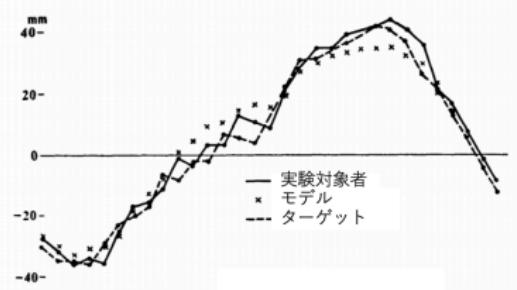


図 4: 刺激・人間御制者・モデル結果の比較 [1]

¹長町 三生、畠 正二、秀衡美代次、中村 正樹、田辺 万巳, “カルマンフィルタと人間の推定機能の比較に関する研究”, 人間工学, Vol. 14, No. 3, pp.133-138, 1978.

2.3 インピーダンス制御とインピーダンス

対象物に接触しているマニピュレーターの運動方程式は以下である。

$$\mathbf{M}(\theta)\ddot{\theta} + \mathbf{h}(\theta, \dot{\theta}) + \mathbf{g}(\theta) = \boldsymbol{\tau} - \mathbf{J}^T(\theta)\mathbf{F}_{int}$$

\mathbf{F}_{int} は $\mathbf{F}_{int} = \mathbf{M}_e\ddot{\mathbf{X}} + \mathbf{B}_e\dot{\mathbf{X}} + \mathbf{K}_e(\mathbf{X} - \mathbf{X}_e)$ のようにモデル化できる。
非線形補償

$$\boldsymbol{\tau} = \mathbf{h}(\theta, \dot{\theta}) + \mathbf{g}(\theta) + \mathbf{J}^T(\theta)\mathbf{F}_{int} + \mathbf{M}(\theta)\mathbf{J}^{-1}(\theta)[\mathbf{F}_{act} - \mathbf{J}(\theta)\dot{\theta}]$$

を行うとダイナミクスは $\ddot{\mathbf{X}} = \mathbf{F}_{act}$ のように単純化される。

目標手先インピーダンスは、作業空間上で以下で記述できるものとする。

$$\mathbf{M}_d d\ddot{\mathbf{X}} + \mathbf{B}_d d\dot{\mathbf{X}} + \mathbf{K}_d d\mathbf{X} = \mathbf{F}_d - \mathbf{F}_{int}$$

目標インピーダンスを実現する制御入力 \mathbf{F}_{act} は、以下となる。

$$\mathbf{F}_{act} = -\mathbf{M}_d^{-1}(\mathbf{B}_d d\dot{\mathbf{X}} + \mathbf{K}_d d\mathbf{X}) + \mathbf{M}_d^{-1}(\mathbf{F}_d - \mathbf{F}_{int}) + \ddot{\mathbf{X}}_d$$

$\mathbf{M}(\theta) \in \mathbb{R}^{n \times n}$: 慣性行列	$\mathbf{h}(\theta, \dot{\theta}) \in \mathbb{R}^{n \times 1}$: コリオリ力・遠心力	$\mathbf{g}(\theta) \in \mathbb{R}^{n \times 1}$: 重力トルク
θ : 關節角度	$\boldsymbol{\tau} \in \mathbb{R}^{n \times 1}$: 關節トルク	$\mathbf{J}(\theta) \in \mathbb{R}^{m \times n}$: ヤコビ行列
$\mathbf{F}_{int} \in \mathbb{R}^{n \times 1}$: 手先に作用する力	$\mathbf{M}_e \in \mathbb{R}^{m \times m}$: 慣性	$\mathbf{B}_e \in \mathbb{R}^{m \times m}$: 粘性
$\mathbf{K}_e \in \mathbb{R}^{m \times m}$: 剛性	$\mathbf{X} \in \mathbb{R}^{m \times 1}$: 手先位置	$\mathbf{X}_e \in \mathbb{R}^{m \times 1}$: 対象物の平衡点の位置
$\mathbf{F}_{act} \in \mathbb{R}^{m \times 1}$: 作業空間で表現した制御入力	$\mathbf{M}_d \in \mathbb{R}^{m \times m}$: 目標慣性行列	$\mathbf{B}_d \in \mathbb{R}^{m \times m}$: 目標粘性行列
$\mathbf{K}_d \in \mathbb{R}^{m \times m}$: 目標剛性行列	$\mathbf{X}_d \in \mathbb{R}^{m \times 1}$: 目標軌道	$\mathbf{F}_d \in \mathbb{R}^{m \times 1}$: 目標手先力
$d\mathbf{X} = \mathbf{X} - \mathbf{X}_d$		

3.1 内部モデルの獲得

内部モデルを獲得する運動学習のスキームとして、フィードバック誤差学習というものがある²。

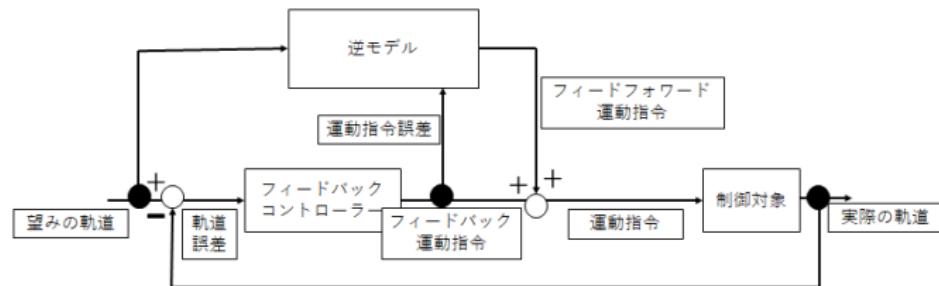


図 5: フィードバック誤差学習

フィードバック誤差学習

- 誤差情報をフィードバックすることによって内部モデルが修正され、徐々に正確なフィードフォワード運動指令を出力する内部モデルが生成される。
- 運動系の逆モデルを脳が学習し、フィードバックのみでは困難な動作をフィードフォワードで実現する仕組みである。

²川人 光男, “小脳の内部モデルと運動学習”, 計測と制御, Vol. 33, No. 4, pp.296-303, 1994.

はじめに

バイオミメティクスによる制御

内部モデルによる習熟メカニズム

提案手法

実験結果ならびに考察

おわりに

修正

修正

修正

3.2 内部モデルの信頼度

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

「内部モデルの信頼度」とは、内部モデルの適応の進み具合をシステム内部で評価したものである。

人間は、目標行動に慣れるに従って身体の動きを大きくしていく。このように、慣れに応じて適切な運動指令を生成するためには、内部モデルの適応の進み具合を評価する必要がある³。

$$\begin{aligned}\pi_t(\xi) &= \frac{P(d_t|\xi)\pi_{t-1}(\xi)}{P(d_t)} \\ &= \frac{P(d_t|\xi; \mathbf{x}_t, m_t)}{\int P(d_t|\xi'; \mathbf{x}_t, m_t)\pi_{t-1}(\xi')d\xi'}\pi_{t-1}(\xi)\end{aligned}$$

\mathbf{x}_t : 身体の位置	m_t : 運動指令
d_t : 身体の移動量	$\pi_{t-1}(\xi)$: パラメータに関する先驗分布
$\pi_t(\xi)$: 更新した事後分布	ξ : パラメータベクトル

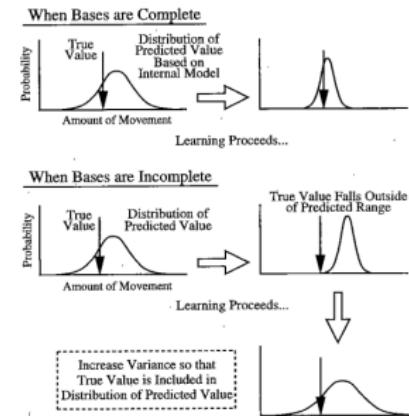


図 6: 内部モデルの分散の制御 [3]

³阪口 豊, “内部モデルの信頼度に基づく運動計画アルゴリズム”, 電子情報通信学会論文誌, D-II, Vol. J79-D-II, No.2, pp.248-256, 1996.

3.3 カルマンフィルタによる状態推定

9/17

カルマンフィルタは、状態空間モデルにおいて、内部の見えない「状態」を効率的に推定するための計算手法のこと。

状態方程式: $\mathbf{x}_k = F_k \mathbf{x}_{k-1} + \mathbf{u}_k + G_k \mathbf{w}_k$

観測方程式: $\mathbf{z}_k = H_k \mathbf{x}_k + \mathbf{v}_k$

予測

$$\hat{\mathbf{x}}_{k|k-1} = F_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{u}_k$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + G_k Q_k G_k^T$$

更新

$$\mathbf{e}_k = \mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1}$$

$$S_k = R_k + H_k P_{k|k-1} H_k^T$$

$$K_k = P_{k|k-1} H_k^T S_k^{-1}$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_k \mathbf{e}_k$$

$$P_{k|k} = (\mathbf{I} - K_k H_k) P_{k|k-1}$$

F_k : 時間遷移に関する線形モデル	\mathbf{x}_k : 状態ベクトル	\mathbf{u}_k : 制御入力
G_k : 雑音モデルの行列	$\mathbf{w}_k, \mathbf{v}_k$: 雑音	H_k : 観測モデル
\mathbf{e}_k : 観測残差	S_k : 観測残差の共分散	K_k : 最適カルマンゲイン
$\hat{\mathbf{x}}_k$: 状態の予測推定値	P_k : 予測誤差行列	

4.1 習熟の検出方法

はじめに
バイオミメティクスによる制御
内部モデルによる
習熟メカニズム
提案手法
実験結果ならびに
考察
おわりに
修正
修正
修正

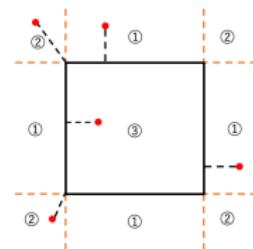


図 7: 誤差の求め方

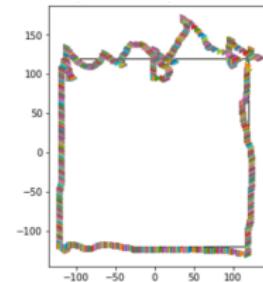


図 8: 実験結果

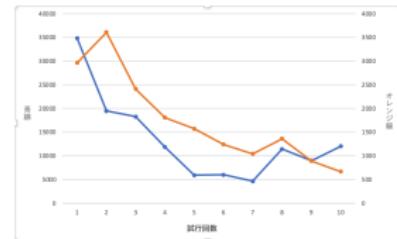


図 9: データ総数と誤差の推移

座標を取得できれば以下の式から速度, 加速度を取得できる.

$$\begin{bmatrix} x_k \\ y_k \\ \dot{x}_k \\ \dot{y}_k \end{bmatrix} = \begin{bmatrix} 1 & 0 & \Delta & 0 & \frac{\Delta^2}{2} & 0 \\ 0 & 1 & 0 & \Delta & 0 & \frac{\Delta^2}{2} \\ 0 & 0 & 1 & 0 & \Delta & 0 \\ 0 & 0 & 0 & 1 & 0 & \Delta \end{bmatrix} \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \dot{x}_{k-1} \\ \dot{y}_{k-1} \\ \ddot{x}_{k-1} \\ \ddot{y}_{k-1} \end{bmatrix}$$

Δ : データの取得間隔時間	x, y : 位置	\dot{x}, \dot{y} : 速度	\ddot{x}, \ddot{y} : 加速度
-----------------------	-------------	-------------------------	----------------------------

4.2 内部モデルの信頼度の算出

条件付き確率密度関数は以下の式である。

$$p(\mathbf{x}|\mathbf{y}) = \frac{p(\mathbf{y}|\mathbf{x})p(\mathbf{x})}{p(\mathbf{y})} = \frac{p(\mathbf{x}\mathbf{y})}{\int p(\mathbf{x}\mathbf{y})dx}$$

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n |\mathbf{M}|}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \right\}$$

$$p(\mathbf{y}|\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^m |\mathbf{W}|}} \exp \left\{ -\frac{1}{2} (\mathbf{y} - (\mathbf{Cx} + \bar{\mathbf{w}}))^T \mathbf{W}^{-1} (\mathbf{y} - (\mathbf{Cx} + \bar{\mathbf{w}})) \right\}$$

$$p(\mathbf{y}) = \frac{1}{\sqrt{(2\pi)^m |\mathbf{W} + \mathbf{CMC}^T|}} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{W} + \mathbf{CMC}^T)^{-1} (\mathbf{y} - \bar{\mathbf{y}}) \right\}$$

$\mathbf{x} \in \Re^{n \times 1}$: 状態ベクトル	$\mathbf{y} \in \Re^{l \times 1}$: 観測ベクトル	$\bar{\mathbf{x}} \in \Re^{n \times 1}$: \mathbf{x} の予測値
$\bar{\mathbf{y}} \in \Re^{l \times 1}$: \mathbf{y} の予測値	$\bar{\mathbf{w}} \in \Re^{p \times 1}$: 観測ノイズ	$\mathbf{W} \in \Re^{n \times n}$: 共分散
$\mathbf{C} \in \Re^{n \times p}$: 観測行列	$\mathbf{M} \in \Re^{m \times m}$: 共分散行列	\mathbf{P}_k : カルマンフィルタの \mathbf{P}_k

条件付き確率密度関数に内部モデルの信頼度 β を考慮する。

$$p(\mathbf{x}|\mathbf{y})^\beta = \frac{1}{\sqrt{(2\pi)^n \left| \frac{\mathbf{P}}{\beta} \right|}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{z})^T \left(\frac{\mathbf{P}}{\beta} \right)^{-1} (\mathbf{x} - \mathbf{z}) \right]$$

$$\mathbf{z} = \bar{\mathbf{x}} + \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1} (\mathbf{y} - \bar{\mathbf{y}}), \quad \beta = \frac{|\mathbf{P}_k|}{|\mathbf{P}|}$$

はじめに

バイオミメティクスによる制御

内部モデルによる習熟メカニズム

提案手法

実験結果ならびに考察

おわりに

修正

修正

修正

4.3 インピーダンス推定

5.1 実験結果

12/17

はじめに
バイオミメティクスによる制御
内部モデルによる
習熟メカニズム
提案手法
実験結果ならびに
考察
おわりに
修正
修正
修正

$$\mathbf{M}_d^{-1} \mathbf{K}_d = \begin{bmatrix} a1 & a2 \\ a3 & a4 \end{bmatrix}, \mathbf{M}_d^{-1} \mathbf{B}_d = \begin{bmatrix} b1 & b2 \\ b3 & b4 \end{bmatrix}, \mathbf{M}_d^{-1} = \begin{bmatrix} c1 & 0 \\ 0 & c2 \end{bmatrix}$$

と表す. \mathbf{M}_d : 慣性行列, \mathbf{B}_d : 粘性行列, \mathbf{K}_d : 剛性行列 である.

$$\ddot{x}_{t+1} = a1(x_{t+1} - x_t) + a2(y_{t+1} - y_t) + b1(-\dot{x}_t) + b2(-\dot{y}_t)$$

$$\ddot{y}_{t+1} = a3(x_{t+1} - x_t) + a4(y_{t+1} - y_t) + b3(-\dot{x}_t) + b4(-\dot{y}_t)$$

以上の式を展開した式をそれぞれ回帰分析にかけ, 偏回帰係数を求める.
回帰分析で得られる切片をそれぞれ s_x, s_y とし, 回帰モデルで予測される加速度をそれぞれ \ddot{x}_f, \ddot{y}_f とすると $c1, c2$ を求める指揮は以下になる.

$$c1 = s_x + (\ddot{x}_{t+1} - \ddot{x}_f)$$

$$c2 = s_y + (\ddot{y}_{t+1} - \ddot{y}_f)$$

求めた $c1, c2$ と偏回帰係数を用いて慣性行列, 粘性行列, 剛性行列を算出する.

5.2 考察

実験結果に関する考察

8回目が7回目よりデータ総数が増加してしまった原因として、試行が終わりに近づくにつれて、なぞりの精度より速さを優先してしまった結果ではないかと考える。

内部モデルの信頼度に関する考察

データ総数に伴って変化する。そのため、7回目から8回目におけるデータ総数が増加しているのと同時に内部モデルの信頼度は低下している。試行を重ねていくことで、内部モデルの信頼度は増加していく。

インピーダンスに関する考察

1回目の試行と比べ、各行列の要素は小さくなっている。このことから試行を重ねることで力を抜いてなぞり運動が行えていることがわかる。

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

6. おわりに

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

まとめ

- PsychoPy を用いてなぞり運動実験を作成し、習熟を確認した。
- 実験で取得したデータを用いて内部モデルの信頼度、インピーダンスパラメータを算出した。
- 内部モデルの信頼度の推移、インピーダンスの推移を確認し、習熟とともにどちらも向上することを確認できた。

今後の課題

- 条件（左右反転など）を変えた状態での実験
- 実験の試行回数を増やす
- 確認した内部モデルの信頼度とインピーダンスが正しいのかを機械に適用し、確認する。

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

- 学会発表に向けて卒論で指摘された修正ポイントの修正.

修正ポイント

- インピーダンスパラメータベクトルにマイナスが出ていたので、マイナスをなくす.
- それに伴い、回帰分析の段階で非負の条件を加える.

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

非負条件

- 非負の実装方法で1つでは合っているかわからないので、2つの方法を試した。
- `nlls`といわれる最小二乗問題について非負の条件付き解を求めるものを実装。
- `sklearn`の `LinearRegression` クラスを用いての実装。

結果

- 両方アプローチをした結果、同じような値になったため非負条件の実装はできた。
- その結果をインピーダンスパラメータを求めるプログラムに適用したら、値は変化したのだが、0の部分が多い。

はじめに

バイオミメティクスによる制御

内部モデルによる
習熟メカニズム

提案手法

実験結果ならびに
考察

おわりに

修正

修正

修正

まとめ

- 作成したデータの形式なら非負条件を付け加えることが容易.
- 慣性のマイナス部分は速度, 加速度, 係数の部分の影響を受けやすい.
- 粘性, 剛性の計算に内積を用いているので, 用いるパラメータに0があると, 粘性, 剛性が0になってしまう.

課題

- 速度, 加速度を求める段階で違っているかもしれない, その部分の見直し.