

精神疾患患者を対象とした不安障害を 緩和させる機械学習を用いた 足元センシングによる歩行支援

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

大森 一輝

富山県立大学 情報基盤工学講座
t915015@st.pu-toyama.ac.jp

December 24, 2022

1 本研究の背景と目的

2/24

背景

- ・高齢者の筋力の低下
→ 口コモの三大疾患 (変形性関節症, 脊柱管狭窄症, 骨粗しょう症)
→ 老化により発生する筋力やバランス感覚の低下による運動器機能不全
- ・精神疾患者の不安全感
うつ病や統合失調症の患者が抱く不安、心配
→ それにより農場などの不安定な足場で歩くことを恐れてしまう。

目的

- ・高齢者や障がいの方々が安心して歩くことができる環境づくり。
- ・福祉を目的とし、障がい者が社会で働くことを目指し、
そのための歩行支援を行う。
- ・安価なセンサで必要なセンシングができます。

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

1.2 研究の概要

概要

足元センサデバイスを開発し、機械学習を用いて歩行時における転倒予防を行う。

- ・人間の内部モデルを数学的に算出する。
→拡張カルマンフィルタを用いて足の状態推定を行う。
- ・ショッカクシューズと自作デバイスの比較。
→自作デバイスの有意性を示す。
- ・*TensorFlow*による機械学習。
→機械学習による行動識別の方法を示す。

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

2.1 内部モデルの作成と獲得

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

内部モデル

内部モデルとは、外界の仕組みを脳の内部でシミュレーション・模倣する神経機構のことであり、この内部モデルにより人間は運動する際にシミュレーションを行い予測する。

PsychoPy による心理実験

刺激画像の表示時間の指定ができたり、刺激画像が表示されてからのボタンを押すまでの反応時間を記録するといったことができる。本実験では上下反転させる設定で星形をなぞる試行をした。

カルマンフィルタ

カルマンフィルタとは、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である。

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

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

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

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

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

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

2.1 内部モデルの作成と獲得

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

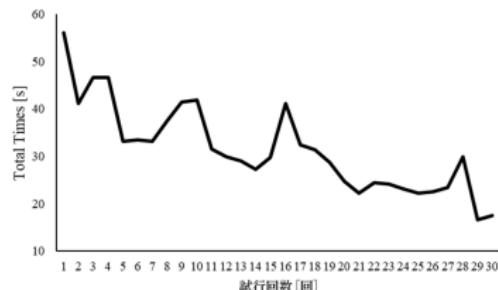


図 1: 試行に要した時間

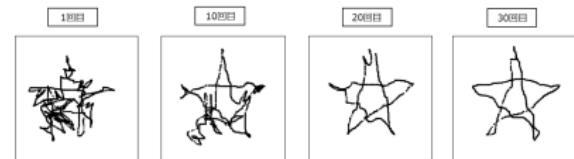


図 2: なぞり運動の軌跡

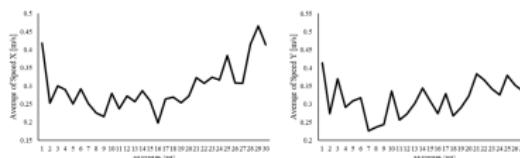


図 3: 平均速度の推移

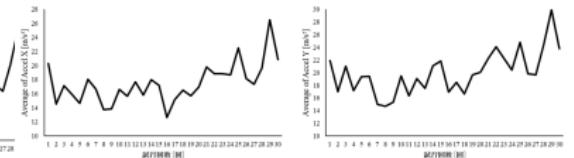


図 4: 平均加速度の推移

今回、20代女性に実験を行っていただき、そのデータをもとに解析を行った。

図 1 → 星形をなぞる1回の試行にかかる時間の推移をグラフ化したもの。

図 2 → 被験者がなぞった星形の軌跡を散布図で表した。

図 3 → 1回の試行における平均の速度。

図 4 → 1回の試行における平均の加速度。

30回の試行を進める中で脳が運動を覚えて動き方を理解していくため、試行回数が増すごとに誤差が減少していき、速度と加速度が上昇することは運動学習が進んだといえる。

2.2 インピーダンス推定

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. 非線形補償の式

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

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.

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

今回用いる速度, 加速度の式を記述する. 時間変化を Δt として

$$\Delta t_n = t_{n+1} - t_n$$

と表せる. このとき n はデータ数とする. したがって, 速度と加速度の式は

$$\dot{\mathbf{x}}_{n+1} = \frac{\mathbf{x}_{n+1} - \mathbf{x}_n}{\Delta t_n} \quad \ddot{\mathbf{x}}_{n+1} = \frac{\dot{\mathbf{x}}_{n+1} - \dot{\mathbf{x}}_n}{\Delta t_n}$$

と書ける.

はじめに

運動学習における
脳の学習とイン
ピーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

2.2 インピーダンス推定

はじめに

運動学習における
脳の学習とイン
ピーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

$\mathbf{M}_d^{-1} \mathbf{K}_d$, $\mathbf{M}_d^{-1} \mathbf{B}_d$, \mathbf{M}_d^{-1} をそれぞれ

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

と表し, (1) を展開すると

$$\ddot{\mathbf{x}}_{n+1} = a1(\mathbf{x}_{n+1} - \mathbf{x}_n) + a2(\mathbf{y}_{n+1} - \mathbf{y}_n) + b1(\dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n) + b2(\dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n) \quad (2)$$

$$\ddot{\mathbf{y}}_{n+1} = a3(\mathbf{x}_{n+1} - \mathbf{x}_n) + a4(\mathbf{y}_{n+1} - \mathbf{y}_n) + b3(\dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n) + b4(\dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n) \quad (3)$$

となる. 上式を回帰分析にかける.

このとき, 目的変数を $\ddot{\mathbf{x}}_{n+1}$, $\ddot{\mathbf{y}}_{n+1}$, 説明変数を $\mathbf{x}_{n+1} - \mathbf{x}_n$, $\mathbf{y}_{n+1} - \mathbf{y}_n$, $\dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n$, $\dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n$ とし, 偏回帰係数である $a1$, $a2$, $a3$, $a4$, $b1$, $b2$, $b3$, $b4$ を求める. また, 取得したモデル式で予測される加速度をそれぞれ (2) の方は $\ddot{\mathbf{x}}_f$, (3) の方は $\ddot{\mathbf{y}}_f$ と表し偏回帰係数を用いて $c1$, $c2$ を求める. $c1$, $c2$ は $\ddot{\mathbf{x}}_{n+1}$, $\ddot{\mathbf{y}}_{n+1}$ から $\ddot{\mathbf{x}}_f$, $\ddot{\mathbf{y}}_f$ を引いたものとして扱う.

$$\pm c1 = \pm \ddot{\mathbf{x}}_{n+1} - \ddot{\mathbf{x}}_f \quad (4)$$

$$\pm c2 = \pm \ddot{\mathbf{y}}_{n+1} - \ddot{\mathbf{y}}_f \quad (5)$$

取得した偏回帰係数から $\mathbf{M}_d^{-1} \mathbf{K}_d$, $\mathbf{M}_d^{-1} \mathbf{B}_d$ の両方ともに \mathbf{M}_d^{-1} が付いているので, 両方ともに \mathbf{M}_d をかけることで \mathbf{K}_d , \mathbf{B}_d を取得する. 算出した \mathbf{M}_d , \mathbf{K}_d , \mathbf{B}_d をそれぞれ以下の行列で表す.

$$\mathbf{M}_d = \begin{bmatrix} \mathbf{M}_x & 0 \\ 0 & \mathbf{M}_y \end{bmatrix} \mathbf{K}_d = \begin{bmatrix} \mathbf{K}_{xx} & \mathbf{K}_{xy} \\ \mathbf{K}_{yx} & \mathbf{K}_{yy} \end{bmatrix} \mathbf{B}_d = \begin{bmatrix} \mathbf{B}_{xx} & \mathbf{B}_{xy} \\ \mathbf{B}_{yx} & \mathbf{B}_{yy} \end{bmatrix}$$

2.2 インピーダンス推定

8/24

はじめに

運動学習における
脳の学習とイン
ピーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

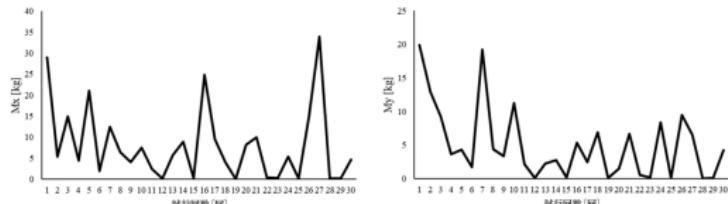


図 5: 慣性行列の平均値推移

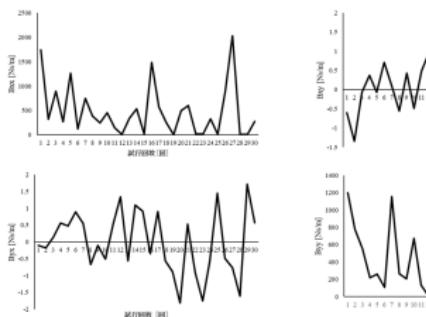


図 6: 粘性行列の平均値推移

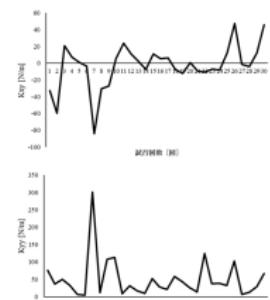


図 7: 剛性行列の平均値推移

図 5 と図 6, 図 7 の対角成分から, 各インピーダンスパラメータについて, 試行回数を重ねるごとに数値がだんだんと小さくなっている傾向にある. またどのグラフも, 1 回目に数値が高く出ており力をかけてなぞり運動をしていることがわかる. これは初めて行う動作に対し, まずはゆっくりとなぞることで動き方を理解しているためと考える. 2 回目には数値が急激に下がっているので動き方を理解してスムーズに運動できていることがうかがえる. そこからは強弱の波を繰り返しながら運動を進めている.

2.3 内部モデルの信頼度

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

内部モデルの信頼度

予測の確実性を扱うには、内部モデルの「値」だけでなくその「確かさ」を同時に表せるようなモデルの記述が必要であり、そのような記述法として確率モデルを用いる。確率モデルを用いたとき、内部モデルの「確かさ」はパラメータ分布の広がりとして表されるので、「確かさ」を表す指標として内部モデルの分散の逆数を用い、これを「内部モデルの信頼度」と呼ぶ。

条件付き確率密度関数は以下の式である。

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

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

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

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

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。

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

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

2.3 内部モデルの信頼度

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

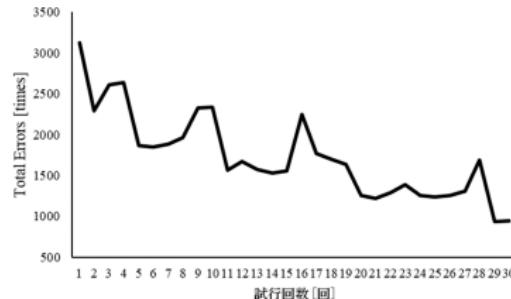


図 8: 誤差の合計

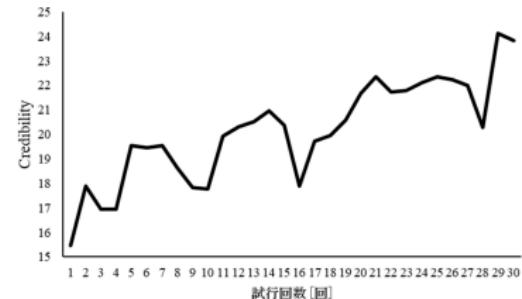


図 9: 内部モデルの信頼度の評価値

図 8 → 1回の試行で星形の枠をはみ出してしまった誤差の回数.

図 9 → 内部モデルの信頼度を算出し, 試行回数に応じて出力された値.

図 1, 図 8 より, 試行回数が増えていくほど誤差が減っており同時に試行に要する時間も減っている. 図 3 より星形を一周なぞる平均の速度が上がっていることから, 1回の試行を速く行えるための運動の方法を脳が学習していることがわかる. さらに図 9 から内部モデルの信頼度も上昇傾向にあるので, このことから脳が運動のシミュレーションを高い精度で行えていることを示している.

3.1 足裏センサの研究

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

下山らは小型・薄型の3軸力センサを靴のインソール部に複数埋め込み、計測データを無線で送信するシステムを提案した。これにより、歩行などの運動に影響を与えることなく、なおかつ計測環境に縛られない、足裏部の3軸応力分布計測システムの実証を行った。このセンサデバイスを用いて通常歩行時と階段昇降時および傾斜路歩行時の比較を行った。

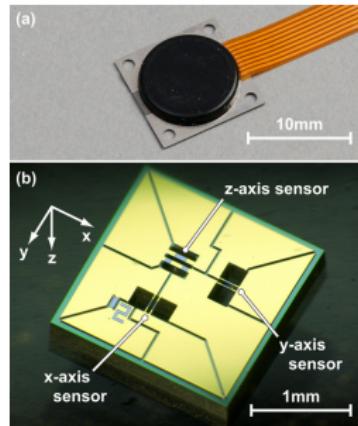


図 10: センサチップ

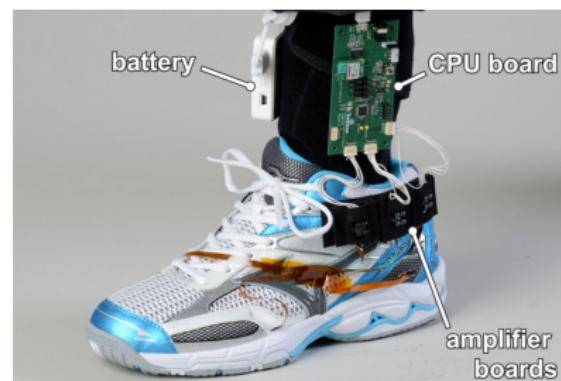


図 11: センサデバイス

3.2 ショッカクシューズと自作センサ

12/24

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

ショッカクシューズ

- タッチエンス独自の 6 軸触覚センサ「ショッカクチップ 6DoF」を内蔵したセンサシューズ(図 12, 図 13 参照)。
- 母指球, 子指球, 趾の直下に 6 軸触覚センサが 1 個ずつと土踏まず付近に 3 軸加速度, 3 軸ジャイロセンサが 1 個の計 4 個のセンサが組み込まれている。
- 足運動データは専用の WEB サーバにアップロードされ, 独自 AI にて処理を行うことで重心や 3 軸情報足運動解析データ(地面垂直反力, 前後方向せん断力, 左右方向せん断力, 足高さ)を算出する。足運動データは 20 msec(50 Hz) 周期で取得できる。

6DoF

ショッカクチップは 6 軸の高感度触覚センサを $9 \times 9 \times 5 \text{ mm}$ に納めた, 最小の多軸触覚センサである。

センサコア部分に, MEMS を用いており, これまでにないほどの小型化を実現している。



図 12: ショッカクシューズ

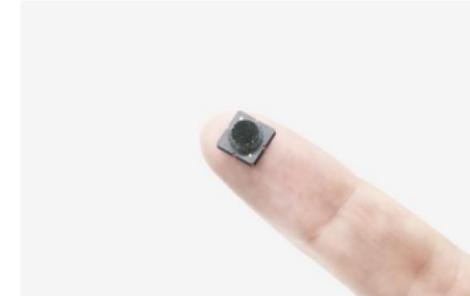


図 13: ショッカクチップ 6DoF

3.2 ショッカクシューズと自作センサ

自作センサ

- FSR402 圧力センサを 6 個設置. 位置はショッカクシューズと同じ場所に加えて中指中節骨, 立方骨, 第一楔状骨に配置した.
- MPU9250 を用いて加速度と角速度をセンシングし, 拡張カルマンフィルタを用いて姿勢状態推定を行う.

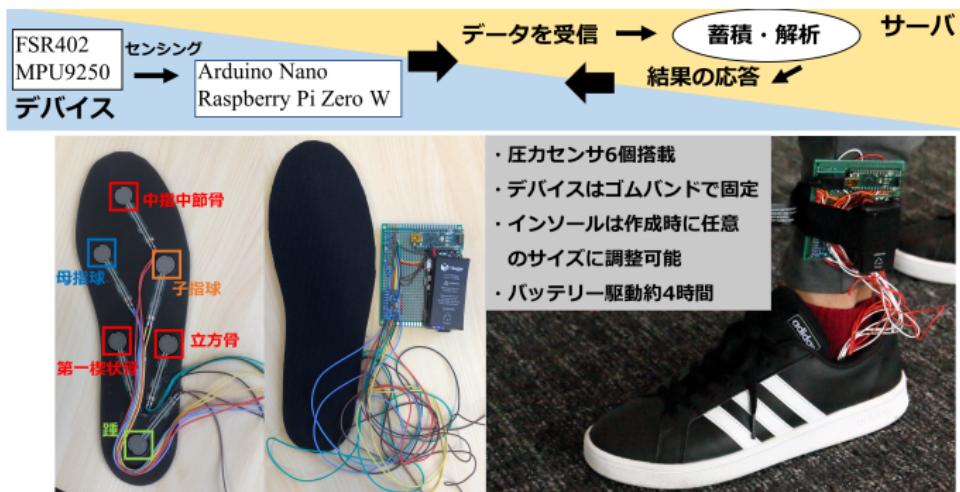


図 14: 自作センサの概要

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

3.3 自作センサの有意性

自作センサデバイスでできること

- 6 個の圧力センサから重心を推定する。

中節骨の圧力を P_1 , 中心からの距離を r_1 , 母指球の圧力を P_2 , 中心からの距離を r_2 , 子指球の圧力を P_3 , 中心からの距離を r_3 , 第一楔状骨の圧力を P_4 , 中心からの距離を r_4 , 立方骨の圧力を P_5 , 中心からの距離を r_5 , 趾の圧力を P_6 , 中心からの距離を r_6 とする。このとき, $r_n^2 = x_n^2 + y_n^2$ となる x_n と y_n が存在し, $\mathbf{r} = \mathbf{0}$ はインソールの重心とする。

重心 G_x , G_y は下式で表す。

$$G_x = \frac{\sum_{n=1}^6 P_n x_n}{\sum_{n=1}^6 P_n} \quad G_y = \frac{\sum_{n=1}^6 P_n y_n}{\sum_{n=1}^6 P_n}$$

- 6 軸 MPU を用いて姿勢状態推定を行う。
拡張カルマンフィルタを用いて足首の姿勢を推定する。
- PiSugar3* によるバッテリーの小型化と持続時間の増加。
ショッカクシューズのバッテリー持続時間はおよそ 30 分ほどであるのに対し, *PiSugar3* は 3 から 4 時間であるので長時間の稼働が可能である。
- 履き心地の向上。
ショッカクシューズはセンサが足に当たり, 履き心地に若干の違和感を感じた。それと比較し, 自作デバイスはセンサをインソールに挟み込むように設計したため足裏に違和感を無くすことに成功した。課題として足首に装着することの仕組みを考える必要がある。

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

3.3 自作センサの有意性

拡張カルマンフィルタ

カルマンフィルタは線形モデルに用いられるが、今回は非線形なデータでも解析を行える拡張カルマンフィルタを用いる。

これによって加速度と角速度から姿勢状態推定を行う。

状態方程式: $\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{w}_k$

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

としたとき、この数式はカルマンフィルタと同じである。この数式をヤコピアンを用いることで非線形である f と h を線形関数に近似する。

$$\mathbf{F}_k = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_k}$$

$$\mathbf{H}_k = \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_k|k-1}$$

予測と更新は通常のカルマンフィルタと同じ式を用いる。
このとき、初期値はともに 0 とする。

有意性

ショッカクシューズと比較し、圧力センサの増加、バッテリー駆動時間の増加、履き心地の向上を取り入れることに成功した。

はじめに

運動学習における
脳の学習とイン
ビデオの関連

足裏センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

機械学習

機械学習はパーセプトロンを用いてニューラルネットワークを構築し、最適化アルゴリズム *Adam* で解析する。

教師用データは圧力センサ 6 種類、6 軸センサのデータ 6 種類 (加速度、角速度) が両足で 24 種類、それを行動別に *csv* 形式で保存する形で用意する。

アプリ開発

今回のデバイスを用いるためにショッカクシューズのショッカクアプリを参考にアプリを開発した。

アプリは *LINEDevelopers* を用いて開発しており、センサデータの解析結果を返す *LINEBot* の役割を担う。プログラムは *Flask* を用いている。このアプリは主に行動登録、コーピング結果の応答を行う。他にも登録した行動の削除、修正ができる。

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

4.2 歩行の比較

今後作成

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

4.3 相転移

今後作成

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

5 今後作成

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

やったこと

- ・サーバを用いたリアルタイム解析の確立
- ・LINEBot アプリ開発
- ・新規デバイスの作成

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

通信プログラム

デバイスからのデータをネットワークを用いてサーバにソケット TCP 通信で集める。その後、サーバにて重心、カルマンフィルタを算出し機械学習の学習モデルを用いて行動を解析しコーピングを行う。
データは 100 ミリ毎秒で取得するため、1 秒間で両足合わせて 240 個を通信でサーバに転送する。

リアルタイム解析

通信プログラムによりデータの解析をサーバで行えるようになったため、リアルタイム解析が可能になった。
現在は十分に解析を行うため 1 分間データを集め、それを解析にかけて結果を出す。

今後の課題

現在は被験者を 1 名と仮定してシステムを作っている。今後は複数人が同時に実験を行うことになるので ID もしくはトークンなど、個人を特定できる何かを作る必要がある。

はじめに

運動学習における
脳の学習とイン
ビデオの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

LINE Developers

LINE におけるアプリケーションを開発することができる開発者向けのポータルサイトである. *https* のアドレスを入力することで外部サーバにあらプログラムを実行させることができる.

アプリ開発

今回、このツールを用いてデバイスと連携した *LINE Bot* を開発した. このアプリでできることは機械学習用の学習データの登録、解析結果の応答、学習登録データの修正が可能.

ショッカクシューズを用いる際に使うショッカクアプリと滝沢さんと清水さんの研究を参考に *Flask* を用いて作った. 現在は一旦システムは動くようを作った状態. 今後はより使いやすさを求めて改良を試みる.

この *Flask* で作ったプログラムは研究室のサーバ上で動いている. 以前は外部サーバの *heroku* を使っていたが 11 月 28 日に有償化されたことで研究室のサーバで実装した.

なので *Apache* を使っていることからポートは 443 番を使っている.

はじめに

運動学習における
脳の学習とイン
ビデオの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

進捗

- ・サーバを用いたリアルタイム解析の確立
- ・LINEBot アプリ開発
- ・新規デバイスの作成

今後の展開

- ・より使いやすいアプリに向けてプログラムの改良
- ・バグ処理・デバイスの増産
- ・本論作成
- ・八十住さんへシステムおよび技術継承

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

はじめに

運動学習における
脳の学習とイン
ビーダンスの関連

足裏圧センサデバ
イス

提案手法

数値実験および実
験結果

進捗

まとめ

記号一覧

$M(\theta) \in \mathbb{R}^{n \times n}$: 慣性行列	$h(\theta, \dot{\theta}) \in \mathbb{R}^{n \times 1}$: コリオリ力・遠心力	$g(\theta) \in \mathbb{R}^{n \times 1}$: 重力トルク
θ : 関節角度	$\tau \in \mathbb{R}^{n \times 1}$: 関節トルク	$J(\theta) \in \mathbb{R}^{m \times n}$: ヤコビ行列
$F_{int} \in \mathbb{R}^{n \times 1}$: 手先に作用する力	$M_e \in \mathbb{R}^{m \times m}$: 慣性	$B_e \in \mathbb{R}^{m \times m}$: 粘性
$K_e \in \mathbb{R}^{m \times m}$: 剛性	$X \in \mathbb{R}^{m \times 1}$: 手先位置	$X_e \in \mathbb{R}^{m \times 1}$: 対象物の平衡点の位置
$F_{act} \in \mathbb{R}^{m \times 1}$: 作業空間で表現した制御入力	$M_d \in \mathbb{R}^{m \times m}$: 目標慣性行列	$B_d \in \mathbb{R}^{m \times m}$: 目標粘性行列
$K_d \in \mathbb{R}^{m \times m}$: 目標剛性行列	$X_d \in \mathbb{R}^{m \times 1}$: 目標軌道	$F_d \in \mathbb{R}^{m \times 1}$: 目標手先力
$dX = X - X_d$	\dot{x} : 速度	\ddot{x} : 加速度
$x \in \mathbb{R}^{n \times 1}$: 状態ベクトル	$y \in \mathbb{R}^{l \times 1}$: 観測ベクトル	$\bar{x} \in \mathbb{R}^{n \times 1}$: x の予測値
$\bar{y} \in \mathbb{R}^{l \times 1}$: y の予測値	$\bar{w} \in \mathbb{R}^{p \times 1}$: 観測ノイズ	$W \in \mathbb{R}^{n \times n}$: 共分散
$C \in \mathbb{R}^{n \times p}$: 観測行列	$M \in \mathbb{R}^{m \times m}$: 共分散行列	P_k : カルマンフィルタの P_k