

卒業論文

就労継続支援B型事業における作業時の不安を
緩和させる足元センシングによるICT支援

ICT assistance using foot sensing to alleviate work anxiety for
continuous employment support type B services

富山県立大学 工学部 電子・情報工学科

1915015 大森 一輝

指導教員 António Oliveira Nzinga René 講師

提出年月: 令和5年(2023年)2月

目 次

図一覧	ii
表一覧	iii
記号一覧	iv
第1章 はじめに	1
§ 1.1 本研究の背景	1
§ 1.2 本研究の目的	2
§ 1.3 本論文の概要	3
第2章 運動学習における脳の学習とインピーダンスの関連	4
§ 2.1 内部モデルの作成と獲得	4
§ 2.2 インピーダンス推定	7
§ 2.3 内部モデルの信頼度	11
第3章 足裏圧センサデバイス	15
§ 3.1 足裏センサの研究	15
§ 3.2 ショッカクシューズと自作センサデバイス	18
§ 3.3 自作デバイスの有意性	21
第4章 提案手法	24
§ 4.1 就労継続支援B型と福祉的支援デバイス	24
§ 4.2 足元センシングとデータ解析	27
§ 4.3 本研究のシステムの流れ	30
第5章 実験結果ならびに考察	33
§ 5.1 実験概要および結果	33
§ 5.2 考察	33
第6章 おわりに	34
謝辞	34
参考文献	35

図一覧

2.1	PsychoPy の実験作成画面	4
2.2	星形のなぞり運動	5
2.3	試行に要した時間	6
2.4	なぞり運動の軌跡	6
2.5	1回の試行における平均速度の推移	6
2.6	1回の試行における平均加速度の推移	6
2.7	インピーダンス制御 [6]	8
2.8	慣性行列の平均値推移	10
2.9	粘性行列の平均値推移	10
2.10	剛性行列の平均値推移	10
2.11	内部モデルの仕組み [7]	12
2.12	誤差の合計	14
2.13	内部モデルの信頼度	14
3.1	3軸力センサチップ [7]	16
3.2	センサデバイス [7]	16
3.3	水平歩行時のデータ [8]	17
3.4	傾斜路上りおよび下りのセンサデータ [8]	17
3.5	階段昇降時のセンサデータ [9]	17
3.6	ショッカクシューズ [4]	18
3.7	ショッカクチップ 6DoF[4]	18
3.8	ショッカクシューズと自作デバイスの歩行データ	19
3.9	自作デバイスの行動データグラフ	19
3.10	自作デバイスとインソールの内部構造	21
3.11	人間の足の骨格 [14]	21
4.1	システム概要	30
4.2	LINE Bot のテキスト入出力画面	31

表一覧

3.1	自作デバイスの行動識別結果	20
3.2	ショッカクシューズと自作デバイスの歩行データ	23
4.1	標準偏差による注意度の分割とコーピングテキスト	32

記号一覧

以下に本論文において用いられる用語と記号の対応表を示す.

用語	記号	用語	記号
状態ベクトル	\mathbf{x}_k	確率変数	ξ
状態遷移行列	\mathbf{F}, \mathbf{F}_k	共分散行列	D_t
制御行列	\mathbf{B}_k	平均	μ_t
入力ベクトル	\mathbf{u}_k	d_t の観測誤差の分散	σ_d^2
雑音モデルの行列	\mathbf{G}, \mathbf{G}_k	単位行列	\mathbf{I}
k 時点の外乱ベクトル	\mathbf{w}_k	状態推定値	$\hat{\mathbf{z}}$
k 時点の観測ノイズ	\mathbf{v}_k	観測誤差	e
\mathbf{x}_k の推定値	$\mathbf{x}_k^*, \widehat{\mathbf{x}_k}$	観測誤差の共分散	S
観測ベクトル	\mathbf{y}_k	最適カルマンゲイン	K
観測行列	$\mathbf{H}, \mathbf{H}_k, C$	データの取得間隔時間	Δ
k 回目の観測値	Y_k	k の時点での x, y の座標	x_k, y_k
$\widehat{\mathbf{x}}_k$ の分散	\mathbf{P}_k	k の時点での x, y の速度	\dot{x}_k, \dot{y}_k
\mathbf{x}_k^* の共分散行列	Γ	k の時点での x, y の加速度	\ddot{x}_k, \ddot{y}_k
慣性行列	$\mathbf{M}(\theta)$	零行列	$\mathbf{0}$
コリオリ力と遠心力	$\mathbf{h}(\theta, \dot{\theta})$	M_d^{-1} の成分	$c1, c2$
重力トルク	$\mathbf{g}(\theta)$	$M_d^{-1} B_d$ の成分	$b1, b2, b3, b4$
関節角度	θ	$M_d^{-1} K_d$ の成分	$a1, a2, a3, a4$
関節トルク	τ	手先位置	x
ヤコビ行列	$J(\theta)$	目標位置	x_d
転置を表す	$(\cdot)', (\cdot)^T$	モデル式で予測される加速度	\ddot{x}_f, \ddot{y}_f
マニピュレータの手先位置	\mathbf{X}	身体の移動量	d, d_t
対象物の平衡点の位置	\mathbf{X}_e	運動指令	m, m_t
制御入力	\mathbf{F}_{act}	データ数, 行動記録数	n
目標慣性行列	\mathbf{M}_d	電圧	V_x, V_y, V_z
目標粘性行列	\mathbf{B}_d	任意定数	s_{ij}
目標剛性行列	\mathbf{K}_d	3 軸応力	τ_x, τ_y, σ_z
目標起動	\mathbf{X}_d	圧力	P_n
目標手先力	\mathbf{F}_d	足の中心からの距離	r_n
内部モデルの信頼度	β	加速度	a_x, a_y, a_z
時刻	k, t	角速度	$\omega_x, \omega_y, \omega_z$
身体の位置	\mathbf{p}, \mathbf{p}_t		
回転行列	γ_k		
オイラー角	ϕ_k, θ_k, ψ_k		

はじめに

§ 1.1 本研究の背景

歩行は生活に欠かせない重要な人間の行動の一種である。身体活動・運動が不足している状態では消費エネルギーが少ないために、肥満、特に内臓脂肪肥満が起きやすくなる。それにより、高血圧や糖尿病、脂質異常症などの生活習慣病の発症リスクが高くなる。その予防のために人間は運動をしなければならない。保健指導の中で運動習慣を提案するのはハードルが高く、さらに場所や時間、必要な用具を考えるところから始めなければならない。それに比較すると歩行は特別な準備がいらざ動きやすい服装と靴があればいつでもできるという点で非常に優れている運動である。

また、歩行はストレス解消にも役立ち、気分を明るくする作用もある。一定のリズムで体の筋肉を動かす有酸素運動は、脳の神経伝達物質のひとつである「セロトニン」が活性化することが分かっている。セロトニンが増えると気分が落ち着き、集中力も高まるといわれている[1]。歩行による健康が注目されている今日、Apple Watchなどのウェアラブル端末によって歩行時の生体データを解析することにより健康管理を行えるようになった。

しかし、高齢者の筋力の低下や精神疾患者の不安な感情などから歩行に関して難しさを感じている人が一定数存在する。前者について、原因の一つは運動器自体の疾患である変形性関節症、脊柱管狭窄症、骨粗しょう症などであり、ロコモの三大疾患といわれるものである。もう一つは、年を取ることによって自然に起こる、筋力やバランス感覚の低下などによる運動器機能不全、廃用性萎縮、サルコペニアが原因といえる[2]。このことから、転倒の危険性が高まることにより、けがのリスクが上昇する。高齢者の場合、小さなけがでも大きな合併症につながる恐れがあるので気をつける必要がある。

また後者について、うつ病や統合失調症の患者は不安に感じることがよくあるため、歩行が困難なケースがある。例えば土壌が不安定で歩きにくい場所では、その歩きにくさから大きな不安を感じ心のバランスが乱れ精神バランスが崩れてしまい歩くことができなくなってしまう。

上記について様々な研究がなされており、その一つに足裏圧がある。足裏圧を測定することで、様々なシチュエーションにおける歩行にどのような特徴があるかを見出している。しかし、高額なセンサデバイスを用いている点などから一般人が容易に用いるには難しいといった問題があるため実用化には至っていない。そのため、比較的安価なセンサデバイスで歩行実験を行い、歩行支援を工学的な観点から行うことができれば実用化に大きく近づくとされる。

§ 1.2 本研究の目的

背景にも記載したが、足裏センサを用いた歩行研究は様々な方向で行われてはいるが実用化には至っていない。足裏圧について、高額なセンサデバイスを用いた研究は広く行われているがそれは一般の人が用いるには難しい。比較的安価なセンサデバイスで、歩行支援をすることが求められるが、高価なセンサはデータを高精度かつ高性能なものを測ることができると安価なセンサデバイスにするためにはセンサ数の削減やセンサそのものを安いものにするといった費用削減をしなければならない。それだけでなく、一般の人が用いるためにはハードウェアの小型化も欠かせず、なおかつ防水、防塵機能も必要となる。大きい装置であれば歩行に影響が出てしまい、歩行支援にならずデバイスの意味がなくなってしまうことに加え、防水、防塵機能がなければ雨や砂によって故障してしまう。

そこで、本研究はタッチエンス株式会社のショッカクシューズを高額なセンサデバイスとして用い、自作デバイスと比較することで安価なデバイスでも十分にデータ解析ができる事を示すと同時に、高齢者や障害者の歩行支援及び危険予測を行うシステムの提案を行う。また、ハードウェアの小型化を取り入れ、足に装着しても違和感のない設計も行う。これは、一般の人が足につける違和感を軽減させるためでもあるが、精神疾患者が足にデバイスをつけることによって不安や動搖、心労などのストレスになってしまうことを防ぐためである。本研究は福祉支援を目的としているのでユニバーサルデザインに注目し、誰もが使いやすいシステム設計を目指す。ユニバーサルデザインとは、年齢や能力、状況などにかかわらず、できるだけ多くの人が使いやすいうように、製品や建物・環境を「デザインする」という考え方で、誰でも同じように利用できる「公平性」、使い方を選べる「自由度」、簡単に使える「単純性」、欲しい情報がすぐに分かる「明確さ」、ミスや危険につながらない「安全性」、無理なく使える「体への負担の少なさ」、使いやすい広さや大きさの「空間性」の7つを総称して「ユニバーサルデザイン7原則」という[3]。本研究では特に「公平性」、「単純性」、「明確さ」、「安全性」、「体への負担の少なさ」に着目しデバイスを作成する。

本研究は農場で働く精神疾患を持つ方に協力していただき実験を行う。土壌は不安定なため、バランスを崩して転倒してしまう恐れがあるので、作業中の様々なデータと作業中の様子を比較して、転倒しそうなとき、安定しない土壌でふらつきながら作業しているとき、通常通りの様子などを観察する。普段通り作業をしていただき、足裏データを分析することでどのような特徴量があるかを調べる。また、健常者と比較することで障害者との相違点を示す。障害者が何について不安に感じ、歩行などの作業に影響が出るのかが工学的な視点からわかれば、そこについて支援、改善を促すシステムを開発することができるのではないかと考える。

タッチエンス株式会社は独自センサの開発から製品の設計・開発までを行う会社で、主にオリジナルの触覚センサを開発している。例えば、触覚キューブは今までにはない「やわらかい」触覚センサで三次元方向の変位を計測することができる。スポンジ自体がセンサになっているため「やわらかい」感覚をそのまま計測することができ、さらに物に埋め込んでも安全で自然な手触りのままインターフェイスとすることができる。このタッチエンス株式会社のショッカクシューズには世界最小の6軸センサが入っており3軸方向の力とモーメントを計測することができる[4]。

§ 1.3 本論文の概要

本論文は次のように構成される。

第1章 本研究の背景と目的について説明する。背景では歩行に関する一般論と高齢者や障害者の歩行問題、先行研究の方向性、実用化に向けた課題について述べる。目的では高齢者や障害者に向けて安価なセンサや仕組みで歩行支援を行えるシステムデバイスを提案する。

第2章 運動学習における脳の習熟とインピーダンスの関連について先行研究を紹介する。この研究で用いられている内部モデルの作成、インピーダンスパラメータの算出、カルマンフィルタで計算する内部モデルの信頼度について述べる。

第3章 足裏圧に関する先行研究を紹介すると同時に本研究の新規性並びに必要性を述べる。ショッカクシューズと自作デバイスの比較を行い自作デバイスがショッカクシューズと同等な機能を持っていることを確認する。さらにショッカクシューズにはない自作デバイスの有意性を述べる。

第4章 本研究の提案手法であるニューラルネットワークによる機械学習、拡張カルマンフィルタを提唱する。また、精神疾患患者と健常者の足元データを比較し、相違点を挙げる。

第5章 本研究の数値実験および結果を記載する。

第6章

第2章

運動学習における脳の学習とインピーダンスの関連

§ 2.1 内部モデルの作成と獲得

先行研究は、なぞり運動における運動学習は脳にどのようにして学習されるかを、インピーダンスを関連させて示した[5]。その実験データの分析法および結果を以下に示す。

運動学習と内部モデル

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、と定義されており3つの段階からなるとされている。これらの段階は順に認知、連合、自律とよばれる。

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。そのため、内部モデルの精度を高めていくことで運動学習を効率よく行うことができ、予測精度も高めることができる。

PsychoPy

PsychoPyは、PCを用いて心理実験を行うための実験作成ツールで、画像刺激や音声刺激の提示、反応時間の計測、刺激提示順序を自動的に制御することができる。PsychoPyはプログラミングができない人でも簡単に実験を作成できるように、刺激提示や時間計測などの様々な種類のアイコンを用意している。

図2.1はPsychoPyの実験作成画面である。図2.2は今回の試行のイメージ図である。赤い点は被験者がなぞった軌跡を表す。

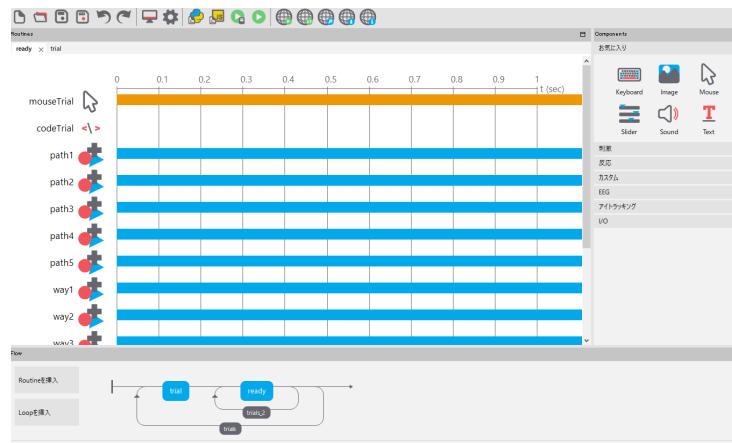


図2.1: PsychoPyの実験作成画面

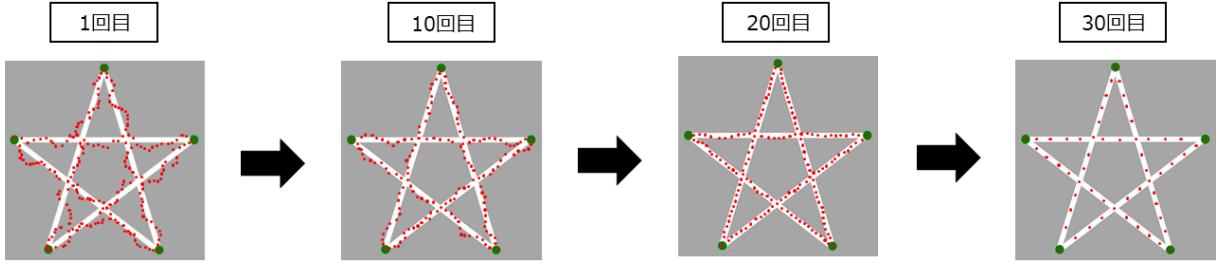


図 2.2: 星形のなぞり運動

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である。カルマンフィルタは複数の不確実な情報から、より正確な情報を推定することを目的として用いられ、位置推定やトラッキング制御などに使用される。目標物の時間変化を支配する法則を活用して目標物の位置を現在(フィルター)、未来(予測)、過去(内挿あるいは平滑化)に推定することができる。

状態空間モデルでは、内部に状態の変化を表す状態方程式と状態から得られた観測値を表す観測方程式の2つの方程式をもち、それらをどのように定義するかによって挙動を大きく変えることができる。

状態方程式はと観測方程式はそれぞれ

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{B}_k \mathbf{u}_k + \mathbf{G}_k \mathbf{w}_k \quad (2.1)$$

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2.2)$$

とする。ここで、 $\mathbf{x}_k \in \Re^{n \times 1}$ は状態ベクトル、 $\mathbf{y}_k \in \Re^{p \times 1}$ は観測ベクトル、 $\mathbf{u}_k \in \Re^{m \times 1}$ は入力ベクトル、 $\mathbf{F}_k \in \Re^{p \times p}$ は状態遷移行列、 $\mathbf{B}_k \in \Re^{p \times m}$ は制御行列、 $\mathbf{H}_k \in \Re^{n \times p}$ は観測行列を表している。添字の k は時刻を表す。 $\mathbf{w}_k \in \Re^{n \times 1}$ 、 $\mathbf{v}_k \in \Re^{p \times 1}$ は雑音を表しており両方ともガウス分布に従い、 $\mathbf{G}_k \in \Re^{n \times m}$ は雑音モデルの行列を表している。

予測のステップを

$$\hat{\mathbf{z}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{z}}_{k-1|k-1} + \mathbf{B}_k \mathbf{u}_k \quad (2.3)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{G}_k \mathbf{Q}_k \mathbf{G}_k^T \quad (2.4)$$

更新のステップを

$$\mathbf{e}_k = \mathbf{y}_k - \mathbf{H}_k \hat{\mathbf{z}}_{k|k-1} \quad (2.5)$$

$$\mathbf{S}_k = \mathbf{R}_k + \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T \quad (2.6)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (2.7)$$

$$\hat{\mathbf{z}}_{k|k} = \hat{\mathbf{z}}_{k|k-1} + \mathbf{K}_k \mathbf{e}_k \quad (2.8)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (2.9)$$

とする。このとき、 $\mathbf{e}_k \in \Re^{n \times m}$ は観測残差、 $\hat{\mathbf{z}}_{k|k-1} \in \Re^{p \times 1}$ は k の時刻の状態推定値、 $\mathbf{S}_k \in \Re^{n \times n}$ は観測誤差の共分散、 $\mathbf{I} \in \Re^{n \times n}$ は単位行列、 $\mathbf{P}_{k|k-1} \in \Re^{p \times p}$ は k の時刻の予測誤差行列、 $\mathbf{K}_k \in \Re^{p \times n}$ は最適カルマンゲイン、 $\hat{\mathbf{z}}_{k|k} \in \Re^{p \times m}$ は更新された状態の推定値、 $\mathbf{P}_{k|k} \in \Re^{p \times p}$ は更新された誤差の共分散を表す。

実験は PsychoPy を用い、PC 上に出現する星形図形を PC のマウスパッドを用いて 30 回、上下反転に動く設定でなぞるものとする。なぞるスピードは被験者の任意によるものとし、実験を行う場合は文字を書く際の利き手で行う。実験の前に練習を 3 回行う。まず、PsychoPy の使い方を覚えるために正方形のなぞり書き 2 周を行う。次に、実験で行う上下反転する動き方を 1 度経験するために正方形のなぞり書きを上下反転でカーソルが動く設定で 2 周行う。最後に、星形のなぞりについて書き順を覚えるために反転なしで 2 周行う。

今回、20 代女性に実験を行っていただき、そのデータを解析した。図 2.3 は星形をなぞる 1 回の試行にかかった時間の推移をグラフ化したものである。図 2.4 は被験者がなぞった星形の軌跡の散布図である。図 2.5 と図 2.6 は 1 回の試行における平均の速度と加速度を算出しそれをグラフ化したものである。x 方向は青、y 方向は橙のグラフである。

1 回目は、ほぼ原形がないほどに誤差が大きい。初めて動かすシステムに慣れていないため、大きくミスをしてしまう。10 回目では少しずつ星形になっていき、20 回目以降で星形になっており誤差が減っている。また、図 2.5 と図 2.6 から試行回数が増すごとに平均速度と平均加速度が上昇傾向にある。これは運動に慣れることで動きを大きくしていく人間の特徴を表しており、何度も同じ運動を繰り返すことで試行を学習している様子がわかる。すなわち 30 回の試行で脳が動き方を理解していくため運動学習したといえる。

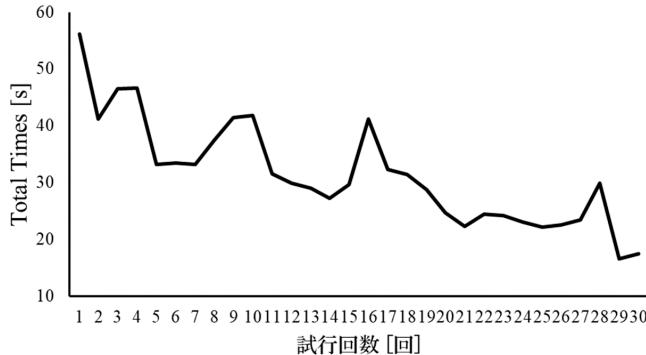


図 2.3: 試行に要した時間

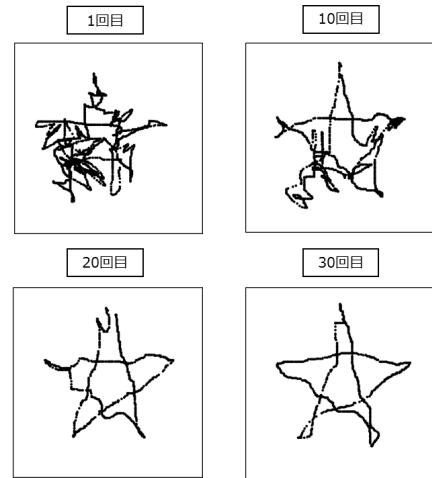


図 2.4: なぞり運動の軌跡

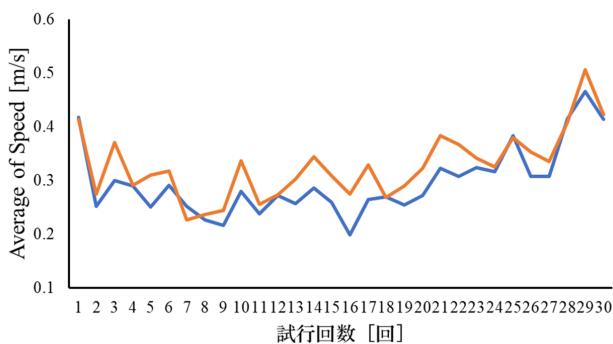


図 2.5: 1 回の試行における平均速度の推移

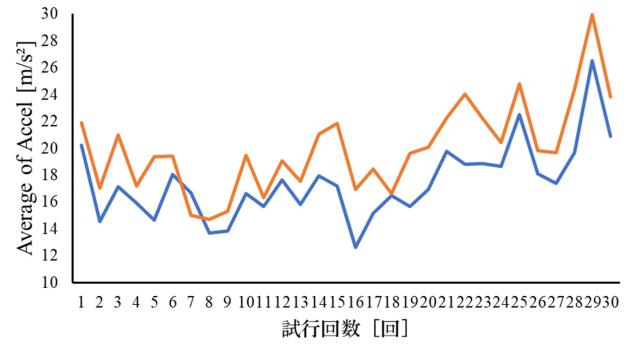


図 2.6: 1 回の試行における平均加速度の推移

§ 2.2 インピーダンス推定

インピーダンスを用いる考え方にはインピーダンス制御がある。これは、機械的なインピーダンス（慣性・粘性・剛性）をアームの手先の柔らかさとして実現しようとするものである。インピーダンス制御は、対象物からみたマニピュレータの手先の動特性であるインピーダンスパラメータを望ましい値に設定しようとするもので、位置と力の制御を必要とする接触作業に有効である。インピーダンスパラメータは慣性行列、粘性行列、剛性行列である。物体の運動は xyz 空間ににおける三次元空間で表されるため、これらは一般的に三次元行列で算出する。本研究は、PsychoPy は xy 平面上での運動を記録するため、算出されるインピーダンスパラメータは二次元となる。

剛体の任意の回転運動は慣性行列で記述することができる。トルク（角運動量）は慣性行列と角加速度の比例関係にあり、トルクや角加速度は正負の値を取りながら変動するが、慣性行列は常に正の値で定数化される。物体は滑る運動をする際に必ず摩擦力が生じる。なのでその力に抗うための力積が必要となる。単位平方メートルあたりの抵抗力である力積を示したものが粘性行列である。この粘性行列の対角成分は正の値しかとらない。すなわち曲げやすさを示す定数である。剛性行列も同様に対角成分は正の値しかとらない。

一般に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、式 2.10 で表される。

$$\mathbf{M}(\theta)\ddot{\theta} + \mathbf{h}(\theta, \dot{\theta}) + \mathbf{g}(\theta) = \boldsymbol{\tau} - \mathbf{J}^T(\theta) \mathbf{F}_{int} \quad (2.10)$$

このとき、 $\mathbf{M}(\theta) \in \Re^{n \times n}$ は慣性行列、 $\mathbf{h}(\theta, \dot{\theta}) \in \Re^{n \times 1}$ はコリオリ力・遠心力、 $\mathbf{g}(\theta) \in \Re^{n \times 1}$ は重力トルク、 θ は関節角度、 $\boldsymbol{\tau} \in \Re^{n \times 1}$ は関節トルク、 $\mathbf{J}(\theta) \in \Re^{m \times n}$ はヤコビ行列、 $\mathbf{F}_{int} \in \Re^{n \times 1}$ はマニピュレータの手先に作用する力、 $(\cdot)^T$ は転置行列を表す。

\mathbf{F}_{int} は次のようにモデル化できる。

$$\mathbf{F}_{int} = \mathbf{M}_e \ddot{\mathbf{X}} + \mathbf{B}_e \dot{\mathbf{X}} + \mathbf{K}_e (\mathbf{X} - \mathbf{X}_e) \quad (2.11)$$

このとき、 $\mathbf{M}_e \in \Re^{m \times m}$ は慣性、 $\mathbf{B}_e \in \Re^{m \times m}$ は粘性、 $\mathbf{K}_e \in \Re^{m \times m}$ は剛性を表し、 $\mathbf{X} \in \Re^{m \times 1}$ はマニピュレータの手先位置、 $\mathbf{X}_e \in \Re^{m \times 1}$ は対象物の平衡点の位置を表す。

式 2.10 に対して、

$$\boldsymbol{\tau} = \mathbf{h}(\theta, \dot{\theta}) + \mathbf{g}(\theta) + \mathbf{J}^T(\theta) \mathbf{F}_{int} + \mathbf{M}(\theta) \mathbf{J}^{-1}(\theta) [\mathbf{F}_{act} - \mathbf{J}(\theta) \dot{\theta}] \quad (2.12)$$

のような非線形補償を行えばマニピュレーターのダイナミクスは $\ddot{\mathbf{X}} = \mathbf{F}_{act}$ ように単純化される。このとき、 $\mathbf{F}_{act} \in \Re^{m \times 1}$ は作業空間で表現した制御入力である。また、マニピュレーターの目標手先インピーダンスは、作業空間上で式 2.13 と記述できるものとする。

$$\mathbf{M}_d d\ddot{\mathbf{X}} + \mathbf{B}_d d\dot{\mathbf{X}} + \mathbf{K}_d d\mathbf{X} = \mathbf{F}_d - \mathbf{F}_{int} \quad (2.13)$$

このとき、 $\mathbf{M}_d \in \Re^{m \times m}$ は目標慣性行列、 $\mathbf{B}_d \in \Re^{m \times m}$ は目標粘性行列、 $\mathbf{K}_d \in \Re^{m \times m}$ は目標剛性行列を表しており、 $d\mathbf{X} = \mathbf{X} - \mathbf{X}_d$ とし、 $\mathbf{X}_d \in \Re^{m \times 1}$ は目標軌道、 $\mathbf{F}_d \in \Re^{m \times 1}$ は目標手先力を表す。

目標インピーダンスを実現する制御入力 \mathbf{F}_{act} は、以下の式 2.14 となる。

$$\mathbf{F}_{act} = -\mathbf{M}_d^{-1}(\mathbf{B}_d d\dot{\mathbf{X}} + \mathbf{K}_d d\mathbf{X}) + \mathbf{M}_d^{-1}(\mathbf{F}_d - \mathbf{F}_{int}) + \ddot{\mathbf{X}}_d \quad (2.14)$$

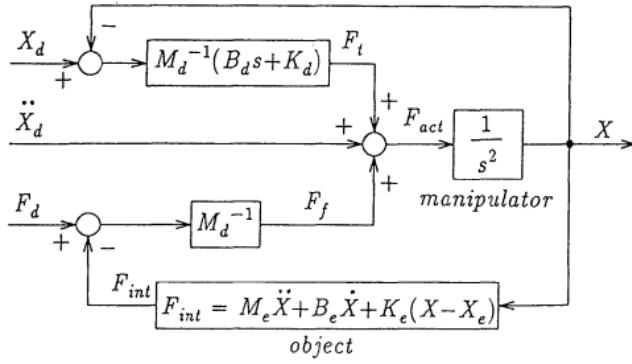


図 2.7: インピーダンス制御 [6]

図 2.7 はインピーダンス制御のブロック線図である。対象物と接触している場合は力制御が同時に行われるため、位置と力の制御を統一的に扱うことが可能となる。よって自由運動時の手先の追従特性と拘束運動時の力制御特性は、インピーダンスパラメータ (M_d , B_d , K_d) によって決定できる。

時間変化を Δt , n をデータ数として $\Delta t_n = t_{n+1} - t_n$ と表し、速度と加速度の式は

$$\dot{x}_{n+1} = \frac{\mathbf{x}_{n+1} - \mathbf{x}_n}{\Delta t_n} \quad (2.15)$$

$$\ddot{x}_{n+1} = \frac{\dot{x}_{n+1} - \dot{x}_n}{\Delta t_n} \quad (2.16)$$

と書ける。インピーダンスパラメータを算出する際は式 2.15 および 2.16 を用いる。

作業に適したインピーダンスを実現する制御入力は式 2.14 より、

$$\mathbf{U} = \ddot{\mathbf{x}}_d + \mathbf{M}_d^{-1}(\mathbf{F}_x) - \mathbf{M}_d^{-1}(\mathbf{K}_d d\mathbf{x} + \mathbf{B}_d d\dot{\mathbf{x}}) \quad (2.17)$$

となる。ただし、 $\mathbf{U} = \mathbf{F}_{act}$, $d\mathbf{x} = \mathbf{x} - \mathbf{x}_d$ で、 \mathbf{x}_d は目標位置、 \mathbf{x} は現在位置である。その結果 $\mathbf{U} = \ddot{\mathbf{x}}$ と単純化でき、この処理を施すと式 2.17 は以下のように変形できる。

$$\ddot{\mathbf{x}} = \ddot{\mathbf{x}}_d + \mathbf{M}_d^{-1}(\mathbf{F}_x) - \mathbf{M}_d^{-1}\mathbf{K}_d(\mathbf{x} - \mathbf{x}_d) - \mathbf{M}_d^{-1}\mathbf{B}_d(\dot{\mathbf{x}} - \dot{\mathbf{x}}_d) \quad (2.18)$$

式 2.18 の処理を y 座標にも施し、速度とインピーダンスを考慮すると以下の式になる。

$$\begin{aligned} \begin{bmatrix} \mathbf{x}_{n+1} \\ \mathbf{y}_{n+1} \\ \dot{\mathbf{x}}_{n+1} \\ \dot{\mathbf{y}}_{n+1} \\ \ddot{\mathbf{x}}_{n+1} \\ \ddot{\mathbf{y}}_{n+1} \end{bmatrix} &= \begin{bmatrix} \mathbf{I} & \Delta & \frac{\Delta^2}{2} \\ 0 & \mathbf{I} & \Delta \\ -\mathbf{M}_d^{-1}\mathbf{K}_d & -\mathbf{M}_d^{-1}\mathbf{B}_d & 0 \end{bmatrix} \begin{bmatrix} \mathbf{x}_n \\ \mathbf{y}_n \\ \dot{\mathbf{x}}_n \\ \dot{\mathbf{y}}_n \\ \ddot{\mathbf{x}}_n \\ \ddot{\mathbf{y}}_n \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ \mathbf{M}_d^{-1}\mathbf{K}_d & \mathbf{M}_d^{-1}\mathbf{B}_d & \mathbf{I} & \mathbf{M}_d^{-1} \end{bmatrix} \begin{bmatrix} \mathbf{x}_d \\ \mathbf{y}_d \\ \dot{\mathbf{x}}_d \\ \dot{\mathbf{y}}_d \\ \ddot{\mathbf{x}}_d \\ \ddot{\mathbf{y}}_d \end{bmatrix} \begin{bmatrix} \mathbf{F}_x \\ \mathbf{F}_y \end{bmatrix} \quad (2.19) \end{aligned}$$

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

$$\mathbf{M}_d^{-1}\mathbf{K}_d = \begin{bmatrix} a1 & a2 \\ a3 & a4 \end{bmatrix} \mathbf{M}_d^{-1}\mathbf{B}_d = \begin{bmatrix} b1 & b2 \\ b3 & b4 \end{bmatrix} \mathbf{M}_d^{-1} = \begin{bmatrix} c1 & 0 \\ 0 & c2 \end{bmatrix} \quad (2.20)$$

と表し, 式 2.19 を展開すると

$$\begin{bmatrix} \ddot{\mathbf{x}}_{n+1} \\ \ddot{\mathbf{y}}_{n+1} \end{bmatrix} = \begin{bmatrix} a1 & a2 \\ a3 & a4 \end{bmatrix} \begin{bmatrix} \mathbf{x}_d - \mathbf{x}_n \\ \mathbf{y}_d - \mathbf{y}_n \end{bmatrix} + \begin{bmatrix} b1 & b2 \\ b3 & b4 \end{bmatrix} \begin{bmatrix} \dot{\mathbf{x}}_d - \dot{\mathbf{x}}_n \\ \dot{\mathbf{y}}_d - \dot{\mathbf{y}}_n \end{bmatrix} \\ + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \ddot{\mathbf{x}}_d \\ \ddot{\mathbf{y}}_d \end{bmatrix} + \begin{bmatrix} c1 & 0 \\ 0 & c2 \end{bmatrix} \begin{bmatrix} \mathbf{F}_x \\ \mathbf{F}_y \end{bmatrix} \quad (2.21)$$

となる. このとき, \mathbf{x}_d , \mathbf{y}_d は手先の目標位置なので, \mathbf{x}_{n+1} , \mathbf{y}_{n+1} と表す. $\dot{\mathbf{x}}_d, \dot{\mathbf{y}}_d$ と $\ddot{\mathbf{x}}_d, \ddot{\mathbf{y}}_d$ はそれぞれ目標速度, 目標加速度である. 目標速度は 1 つ前の運動であれば速度が一定であることがいえるので $\dot{\mathbf{x}}_{t-1}$, $\dot{\mathbf{y}}_{t-1}$, 目標加速度は力がかかっていないことが理想なため 0 と設定する. \mathbf{F}_x , \mathbf{F}_y は力を表しており, 1 もしくは -1 で表現する. 正負の判別は $\ddot{\mathbf{x}}_{n+1}$ および $\ddot{\mathbf{y}}_{n+1}$ の正負の合わせて決定する. このとき式 2.21 は以下のように示される.

$$\begin{bmatrix} \ddot{\mathbf{x}}_{n+1} \\ \ddot{\mathbf{y}}_{n+1} \end{bmatrix} = \begin{bmatrix} a1 & a2 \\ a3 & a4 \end{bmatrix} \begin{bmatrix} \mathbf{x}_{n+1} - \mathbf{x}_n \\ \mathbf{y}_{n+1} - \mathbf{y}_n \end{bmatrix} + \begin{bmatrix} b1 & b2 \\ b3 & b4 \end{bmatrix} \begin{bmatrix} \dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n \\ \dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n \end{bmatrix} \\ + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \end{bmatrix} + \begin{bmatrix} c1 & 0 \\ 0 & c2 \end{bmatrix} \begin{bmatrix} \pm 1 \\ \pm 1 \end{bmatrix} \quad (2.22)$$

ここで, 以下の式 2.23 と 2.24 を回帰分析にかける.

$$\ddot{\mathbf{x}}_{n+1} = a1(\mathbf{x}_{n+1} - \mathbf{x}_n) + a2(\mathbf{y}_{n+1} - \mathbf{y}_n) + b1(\dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n) + b2(\dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n) \quad (2.23)$$

$$\ddot{\mathbf{y}}_{n+1} = a3(\mathbf{x}_{n+1} - \mathbf{x}_n) + a4(\mathbf{y}_{n+1} - \mathbf{y}_n) + b3(\dot{\mathbf{x}}_{n-1} - \dot{\mathbf{x}}_n) + b4(\dot{\mathbf{y}}_{n-1} - \dot{\mathbf{y}}_n) \quad (2.24)$$

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. 回帰分析は実験の試行回数だけ繰り返す. このとき取得できる偏回帰係数である $a1, a2, a3, a4, b1, b2, b3, b4$ を用いて $c1, c2$ 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式 2.26 の方は $\ddot{\mathbf{x}}_f$, 式 2.27 の方は $\ddot{\mathbf{y}}_f$ と表す. 取得した $a1, a2, a3, a4, b1, b2, b3, b4$ はそれぞれの試行で固定されているが, $c1, c2$ はそれぞれの試行のデータの数だけ存在する. そのため, $c1, c2$ 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.

$$c1 = \ddot{\mathbf{x}}_{n+1} - \ddot{\mathbf{x}}_f \quad (2.25)$$

$$c2 = \ddot{\mathbf{y}}_{n+1} - \ddot{\mathbf{y}}_f \quad (2.26)$$

また, 取得した $a1, a2, a3, a4$ は $\mathbf{M}_d^{-1}\mathbf{K}_d$ の成分, $b1, b2, b3, b4$ は $\mathbf{M}_d^{-1}\mathbf{B}_d$ の成分となっているように両方ともに \mathbf{M}_d^{-1} が付いている. そのため, 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.

$$\mathbf{M}_d = \begin{bmatrix} \mathbf{M}_x & 0 \\ 0 & \mathbf{M}_y \end{bmatrix} \mathbf{K}_d = \begin{bmatrix} \mathbf{K}_{xx} & \mathbf{K}_{xy} \\ \mathbf{K}_{yx} & \mathbf{K}_{yy} \end{bmatrix} \mathbf{B}_d = \begin{bmatrix} \mathbf{B}_{xx} & \mathbf{B}_{xy} \\ \mathbf{B}_{yx} & \mathbf{B}_{yy} \end{bmatrix} \quad (2.27)$$

実験データからそれぞれのインピーダンスパラメータを計算した際、1回の試行におけるインピーダンスパラメータの平均値をそれぞれ算出する。それを試行回数である30回行い、試行を重ねるごとの平均値の推移をグラフに表す。そのインピーダンスパラメータの解析結果を図2.8、図2.9、図2.10に示す。x方向は青、y方向は橙のグラフである。

各図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。すなわち実験を繰り返す中で、1回目は認知のために特別に力をかけてまずは運動を覚えるための訓練を行い、2回目以降は連合に入り断片的に記憶した1回目の運動を繋ぎ合わせるための訓練を行っている。試行回数を30回でなぞり運動を行ったが、回数を増やせば連合の時間が増えるため、より正確な習熟に近づくと予想できる。しかし、1度に連続して何十回も試行を繰り返すと集中力が途切れてくるため、ミスをすることも推測できる。なので、15回や20回の比較的少ない試行回数を時間をおいて複数セット行うことで認知、連合を完了し自律に促すことができる。

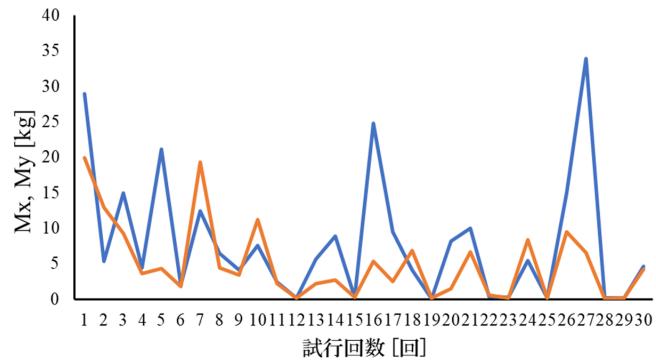


図 2.8: 慣性行列の平均値推移

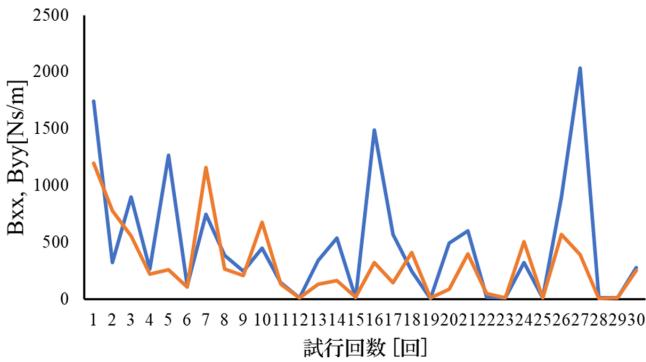


図 2.9: 粘性行列の平均値推移

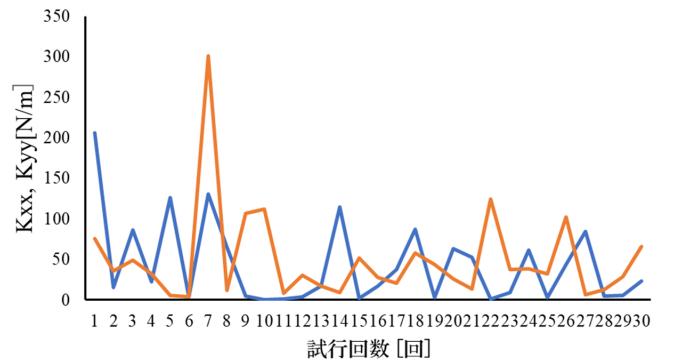


図 2.10: 剛性行列の平均値推移

§ 2.3 内部モデルの信頼度

内部モデルについて阪口らの研究で内部モデルの信頼度に基づく運動計画のアルゴリズムを提唱し、それをなぞり運動に用いた[7].

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.

具体的に、身体が位置 \mathbf{p} にあるとき運動指令 m を発した結果生じる身体の移動量 d を、適当な基底関数 $f_j(\mathbf{x},)$ の線形和で表すモデルである式 2.28 を用いる.

$$d(\mathbf{p}, m; \xi) = \xi \cdot \mathbf{f}(\mathbf{p}, m) = \sum_{j=1}^J \xi_j f_j(\mathbf{p}, m) \quad (2.28)$$

式 2.28において、線形和の荷重を与えるパラメータベクトル ξ が確率変数であり、その確率分布 $\pi(\xi)$ が内部モデルの実体となる. 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.

式 2.28 の設定であれば内部モデルの適応はパラメータの推定に相当する. そこで、この推定にベイズ推定の考え方を用いる. すなわち、パラメータに関する先驗分布 $\pi_{t-1}(\xi)$ (脳の中にあらかじめ保持されている分布) を実際に得られた運動結果を用いて更新し、事後分布 $\pi_t(\xi)$ を得るとする. 身体が位置 \mathbf{p}_t にある状況で運動指令 m_t を発したとき、身体が d_t だけ動いた場合、パラメータベクトルの分布を式 2.29 に従い更新する.

$$\begin{aligned} \pi_t(\xi) &= \frac{P(d_t|\xi)\pi_{t-1}(\xi)}{P(d_t)} \\ &= \frac{P(d_t|\xi; \mathbf{p}_t, m_t)}{\int P(d_t|\xi'; \mathbf{p}_t, m_t)\pi_{t-1}(\xi') d\xi'} \pi_{t-1}(\xi) \end{aligned} \quad (2.29)$$

特に、パラメータベクトルや観測誤差が正規分布に従う場合は、平均 μ_t と共に分散行列 D_t に関する漸化式を用いて式 2.30、式 2.31 のように分布を更新する. このとき、 σ_d^2 は d_t の観測誤差の分散を示す.

$$D_t = \left[D_{t-1}^{-1} + \frac{1}{\sigma_d^2} \mathbf{f}(\mathbf{p}, m) \mathbf{f}^T(\mathbf{p}, m) \right]^{-1} \quad (2.30)$$

$$\mu_t = D_t \left[D_{t-1}^{-1} \mu_t + \frac{d_t}{\sigma_d^2} \mathbf{f}(\mathbf{p}, m) \right] \quad (2.31)$$

これらを用い、内部モデルを更新していくと、式 2.30、式 2.31 からわかるように、内部モデルの分散は一様に減少し、信頼度は向上していく. しかし、対象の真の特性が基底関数の組によって完全に記述できない場合は、分散が過度に小さくなると、真の特性が内部モデルの広がりから逸脱する危険性がある. そこで運動結果に観測値が内部モデルから予測される範囲からはずれた場合、信頼度が過大になったと判断し、分散を増加させる作用を施す. 以上の流れを図 2.11 に示す.

内部モデルの予測範囲内のとき

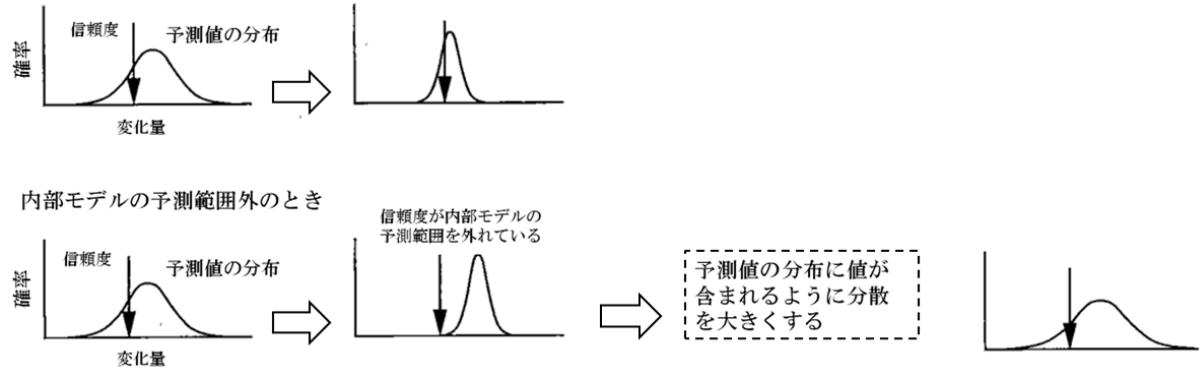


図 2.11: 内部モデルの仕組み [7]

条件付き確率密度関数は内部モデルの信頼度 ($= \beta$) を考慮するため以下のように示す.

$$p(\mathbf{x}|\mathbf{y})^\beta = \frac{p(\mathbf{x}\mathbf{y})^\beta}{\int p(\mathbf{x}\mathbf{y})^\beta d\mathbf{x}} = \frac{p(\mathbf{y}|\mathbf{x})^\beta p(\mathbf{x})^\beta}{\int p(\mathbf{x}\mathbf{y})^\beta d\mathbf{x}} \quad (2.32)$$

$\mathbf{x} \in \Re^{n \times 1}$ は状態ベクトル, $\mathbf{y} \in \Re^{l \times 1}$ は観測ベクトルを表す. このとき,

$$p(\mathbf{y}|\mathbf{x})^\beta = \frac{1}{\sqrt{(2\pi)^{\beta m} |\mathbf{W}|^\beta}} \exp \left\{ -\frac{\beta}{2} (\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}}))^T \mathbf{W}^{-1} (\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}})) \right\} \quad (2.33)$$

$$p(\mathbf{x})^\beta = \frac{1}{\sqrt{(2\pi)^{\beta n} |\mathbf{M}|^\beta}} \exp \left\{ -\frac{\beta}{2} (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \right\} \quad (2.34)$$

と表すことができる. $\bar{\mathbf{x}} \in \Re^{n \times 1}$ は \mathbf{x} の予測値, $\bar{\mathbf{y}} \in \Re^{l \times 1}$ は \mathbf{y} の予測値, $\bar{\mathbf{w}} \in \Re^{p \times 1}$ は観測ノイズ, $\mathbf{W} \in \Re^{n \times n}$ は共分散, $\mathbf{C} \in \Re^{n \times p}$ は観測行列, $\mathbf{M} \in \Re^{m \times m}$ は共分散行列を表す. 式 2.32 の分子部分は以下となる.

$$\begin{aligned} p(\mathbf{x}\mathbf{y})^\beta &= \frac{1}{\sqrt{(2\pi)^{\beta m} |\mathbf{W}|^\beta}} \frac{1}{\sqrt{(2\pi)^{\beta n} |\mathbf{M}|^\beta}} \\ &\times \exp \left[-\frac{\beta}{2} \left\{ (\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}}))^T \mathbf{W}^{-1} (\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}})) + (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \right\} \right] \end{aligned} \quad (2.35)$$

ここで, 式 2.35 の指数部分に着目する.

$$\begin{aligned} &(\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}}))^T \mathbf{W}^{-1} (\mathbf{y} - (\mathbf{C}\mathbf{x} + \bar{\mathbf{w}})) + (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \\ &= ((\mathbf{y} - \bar{\mathbf{y}}) - \mathbf{C}(\mathbf{x} - \bar{\mathbf{x}}))^T \mathbf{W}^{-1} ((\mathbf{y} - \bar{\mathbf{y}}) - \mathbf{C}(\mathbf{x} - \bar{\mathbf{x}})) + (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \\ &= (\mathbf{y} - \bar{\mathbf{y}})^T \mathbf{W}^{-1} (\mathbf{y} - \bar{\mathbf{y}}) + (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{M}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \\ &\quad + \mathbf{C}^T \mathbf{W}^{-1} \mathbf{C} (\mathbf{x} - \bar{\mathbf{x}}) - 2(\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{C}^T \mathbf{W}^{-1} (\mathbf{y} - \bar{\mathbf{y}}) \end{aligned}$$

ここで, \mathbf{P}^{-1} を下記のようにおく.

$$\mathbf{P}^{-1} = \mathbf{M}^{-1} + \mathbf{C}^T \mathbf{W}^{-1} \mathbf{C}$$

$$\begin{aligned}
& \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\}^T \mathbf{P}^{-1} \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\} \\
&= (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{P}^{-1}(\mathbf{x} - \bar{\mathbf{x}}) - 2(\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{P}^{-1} \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}}) \\
&\quad + (\mathbf{y} - \bar{\mathbf{y}})^T \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{P}^{-1} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}}) \\
&= (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{P}^{-1}(\mathbf{x} - \bar{\mathbf{x}}) - 2(\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{C}^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}}) \\
&\quad + (\mathbf{y} - \bar{\mathbf{y}})^T \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})
\end{aligned}$$

逆行列の補助定理を用いると式 2.36 のように書ける。合わせて上式を書き換える。

$$\mathbf{W}^{-1} - \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1} = (\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)^{-1} \quad (2.36)$$

$$\begin{aligned}
& \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\}^T \mathbf{P}^{-1} \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\} \\
&\quad - (\mathbf{y} - \bar{\mathbf{y}})^T \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}}) + (\mathbf{y} - \bar{\mathbf{y}})^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}}) \\
&= \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\}^T \mathbf{P}^{-1} \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\} \\
&\quad + (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{W}^{-1} - \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1})(\mathbf{y} - \bar{\mathbf{y}})
\end{aligned}$$

また、 $\mathbf{z} = \bar{\mathbf{x}} + \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})$ とすると

$$\begin{aligned}
& \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\}^T \mathbf{P}^{-1} \{(x - \bar{x})^T - \mathbf{P}C^T \mathbf{W}^{-1}(\mathbf{y} - \bar{\mathbf{y}})\} \\
&\quad + (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{W}^{-1} - \mathbf{W}^{-1} \mathbf{C} \mathbf{P} \mathbf{C}^T \mathbf{W}^{-1})(\mathbf{y} - \bar{\mathbf{y}}) \\
&= (\mathbf{x} - \mathbf{z})^T \mathbf{P}^{-1}(\mathbf{x} - \mathbf{z}) + (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)^{-1}(\mathbf{y} - \bar{\mathbf{y}})
\end{aligned}$$

と表せる。ここで、 $|\mathbf{Q}|^{-1} = |\mathbf{Q}|^{-1}$ より

$$\begin{aligned}
|\mathbf{P}| &= |\mathbf{M}| |\mathbf{W}| |(\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)^{-1}| \\
|\mathbf{M}|^\beta |\mathbf{W}|^\beta &= |\mathbf{P}|^\beta |(\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)|^\beta = |\mathbf{P}|^\beta |(\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)|^\beta \\
&= \left| \frac{\mathbf{P}}{\beta} \right| \beta |\mathbf{P}|^{(\beta-1)} \left| \frac{\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T}{\beta} \right| \beta |\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T|^{(\beta-1)}
\end{aligned}$$

となる。 $p(xy)^\beta$ に着目すると

$$\begin{aligned}
p(\mathbf{x}\mathbf{y})^\beta &= \frac{1}{\sqrt{(2\pi)^{\beta m} |\mathbf{W}|^\beta}} \frac{1}{\sqrt{(2\pi)^{\beta n} |\mathbf{M}|^\beta}} \\
&\quad \times \exp \left[-\frac{\beta}{2} \{ (\mathbf{x} - \mathbf{z})^T \mathbf{P}^{-1}(\mathbf{x} - \mathbf{z}) + (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T)^{-1}(\mathbf{y} - \bar{\mathbf{y}}) \} \right] \\
&= \frac{1}{\sqrt{(2\pi)^{\beta m} |\mathbf{W}|^\beta}} \frac{1}{\sqrt{(2\pi)^{\beta n} |\mathbf{M}|^\beta}} \\
&\quad \times \exp \left[-\frac{1}{2} \left\{ (\mathbf{x} - \mathbf{z})^T \left(\frac{\mathbf{P}}{\beta} \right)^{-1} (\mathbf{x} - \mathbf{z}) + (\mathbf{y} - \bar{\mathbf{y}})^T \left(\frac{\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T}{\beta} \right)^{-1} (\mathbf{y} - \bar{\mathbf{y}}) \right\} \right] \\
&= \frac{1}{\beta \sqrt{(2\pi)^{(\beta-1)(n+m)} (|\mathbf{P}| |\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T|)^{(\beta-1)}}} \frac{1}{\sqrt{(2\pi)^m \left| \frac{\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T}{\beta} \right|}} \frac{1}{\sqrt{(2\pi)^n \left| \frac{\mathbf{P}}{\beta} \right|}} \\
&\quad \times \exp \left[-\frac{1}{2} \left\{ (\mathbf{x} - \mathbf{z})^T \left(\frac{\mathbf{P}}{\beta} \right)^{-1} (\mathbf{x} - \mathbf{z}) + (\mathbf{y} - \bar{\mathbf{y}})^T \left(\frac{\mathbf{W} + \mathbf{C} \mathbf{M} \mathbf{C}^T}{\beta} \right)^{-1} (\mathbf{y} - \bar{\mathbf{y}}) \right\} \right]
\end{aligned} \quad (2.37)$$

また、式 2.32 の分母部分に着目すると

$$\begin{aligned} \int p(\mathbf{x}\mathbf{y})^\beta d\mathbf{x} &= \frac{1}{\beta\sqrt{(2\pi)^{(\beta-1)(n+m)}(|\mathbf{P}||\mathbf{W} + \mathbf{C}\mathbf{M}\mathbf{C}^T|)^{(\beta-1)}}} \frac{1}{\sqrt{(2\pi)^m \left|\frac{\mathbf{W} + \mathbf{C}\mathbf{M}\mathbf{C}^T}{\beta}\right|}} \\ &\times \exp \left[-\frac{1}{2}(\mathbf{y} - \bar{\mathbf{y}})^T \left(\frac{\mathbf{W} + \mathbf{C}\mathbf{M}\mathbf{C}^T}{\beta} \right)^{-1} (\mathbf{y} - \bar{\mathbf{y}}) \right] \end{aligned} \quad (2.38)$$

よって、式 2.32 は以下のように変形できる。

$$\begin{aligned} p(\mathbf{x}|\mathbf{y})^\beta &= \frac{p(\mathbf{x}\mathbf{y})^\beta}{\int p(\mathbf{x}\mathbf{y})^\beta d\mathbf{x}} \\ &= \frac{1}{\sqrt{(2\pi)^n \left|\frac{\mathbf{P}}{\beta}\right|}} \exp \left[-\frac{1}{2}(\mathbf{x} - \mathbf{z})^T \left(\frac{\mathbf{P}}{\beta} \right)^{-1} (\mathbf{x} - \mathbf{z}) \right] \end{aligned} \quad (2.39)$$

以上より、 β を考慮した場合の確率密度関数は式 2.39 のように変形することができる。式 2.42 の $\frac{P}{\beta}$ のはカルマンフィルタにおける式 2.9 の P_k のである。よって、 β は下記となる。

$$\beta = \frac{|\mathbf{P}_k|}{|\mathbf{P}|} \quad (2.40)$$

図 2.12、図 2.13 はインピーダンスパラメータを算出したときと同様に、実験に協力していただいた 20 代女性の方のデータを解析した結果である。図 2.12 は 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をグラフ化した。図 2.13 は内部モデルの信頼度を式 2.47 から算出し、試行回数に応じて出力された値をグラフ化した。

理論上、内部モデルの信頼度が上昇すれば誤差は減り、運動にかかる時間も減少する。それは、脳が運動のシミュレーションを行っていく過程で、予測精度が向上していくため必然的に運動の誤差は減り、運動学習の 3 つの段階における認知にかかる時間分が減少するので運動にかかる時間も減少するためである。図 2.3、図 2.12 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 2.5 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 2.12 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。

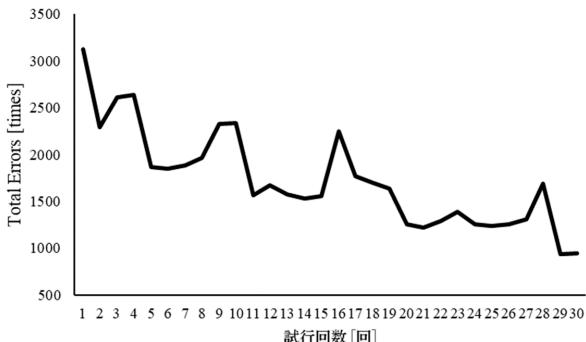


図 2.12: 誤差の合計

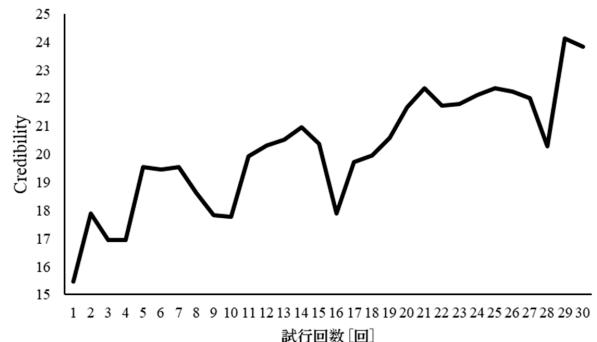


図 2.13: 内部モデルの信頼度

足裏圧センサデバイス

§ 3.1 足裏センサの研究

高齢化が進む日本において、高齢者の健康寿命を延ばすことは極めて重要な課題である。高齢者の歩き方や転倒予防に有効なシステムを開発するにあたり、工学的に人間の歩行を解析する手法が研究されている今日、特に歩行者の足の裏にかかる力を計測するものは国内外で広く実施されている。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[7]。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[8][9]。

MESE(*Micro Electro Mechanical Systems*)技術を用いて試作された2mm角のセンサチップを柔らかいシリコンゴムに埋め込んだ3軸力センサを使用する。図3.1に示すのは今回用いる3軸力センサである。うち、(a)で示すものは取り付けセンサのイメージで(b)で示すものはセンサチップである。3軸力センサのシリコンゴムの表面に加わる力は、面に垂直な方向の力 \mathbf{F}_z と、互いに直交しシリコンゴムの表面と平行な方向の2軸のせん断力 \mathbf{F}_x および \mathbf{F}_y に分解が可能である。 \mathbf{F}_x , \mathbf{F}_y , \mathbf{F}_z をセンサ表面の面積で割り、求めた応力 τ_x , τ_y , σ_z と、アンプ回路で増幅された電圧変化 V_x , V_y , V_z の間には、センサの特性行列を介して式3.1の関係が成り立つ。

$$\begin{pmatrix} \mathbf{V}_x \\ \mathbf{V}_y \\ \mathbf{V}_z \end{pmatrix} = \begin{pmatrix} s_{11} & s_{12} & s_{13} \\ s_{21} & s_{22} & s_{23} \\ s_{31} & s_{32} & s_{33} \end{pmatrix} \begin{pmatrix} \tau_x \\ \tau_y \\ \sigma_z \end{pmatrix} \quad (3.1)$$

実験的に係数 k_{ij} (ただし $i, j = 1, 2, 3$)を求ることで、その逆行列を計算して式3.2を用いれば、センサに加わった応力 τ_x , τ_y , σ_z を算出することができる。

$$\begin{pmatrix} \tau_x \\ \tau_y \\ \sigma_z \end{pmatrix} = \begin{pmatrix} s_{11} & s_{12} & s_{13} \\ s_{21} & s_{22} & s_{23} \\ s_{31} & s_{32} & s_{33} \end{pmatrix}^{-1} \begin{pmatrix} \mathbf{V}_x \\ \mathbf{V}_y \\ \mathbf{V}_z \end{pmatrix} \quad (3.2)$$

図3.2に作成したセンサデバイスを示す。計測部分であるMESEセンサチップを埋め込んだ3軸力センサは靴のインソール部に配置した。バッテリーとCPUが組み込まれた基盤は足首に装着する。バッテリーはスマートフォンなどを充電する際に広く用いられる、モバイルバッテリーを使用する。

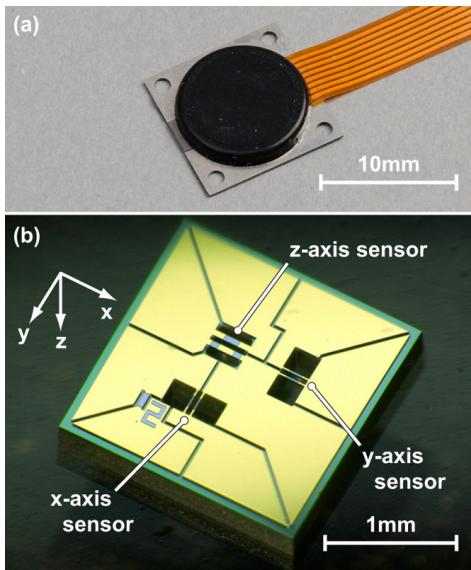


図 3.1: 3 軸力センサチップ [7]

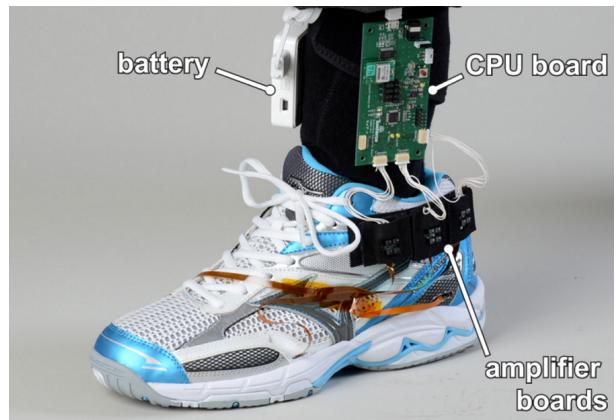


図 3.2: センサデバイス [7]

センサデバイスを左足に装着し、階段昇降時の足裏3軸応力データの計測を行った。計測環境は屋内で床材はリノリウム、階段段数は11段、階段一段の高さと幅はそれぞれ18.5mm, 26.5mmであった。センサに荷重がかからないように左足を上げた状態で計測を始め、両足立ちに遷移した後、右足を踏み出し足として階段を昇る。昇りきったら再度両足立ちになり、開始時と同じように左足を上げた状態で計測を終える。階段を降りる場合も同じ手順で行う。階段を昇る際の踵、母指球、子指球の各点における垂直応力のデータを図3.3(a)に、前後方向のせん断応力のデータを(b)に、左右方向のせん断応力データを(c)に示す。同様に降下時にデータを(d), (e), (f)に示す。(a), (b), (c)のデータから階段上昇時を考えると、足の裏全面で着地して負荷を分散させていること、水平歩行と比較して前後の体重移動があまりないこと、前足部全体を使って蹴り出していることなどが特徴として挙げられる。一方、(d), (e), (f)のデータから階段下降時を考えると、主に前足部で着地していると考えられ、それに応じたせん断応力が計測されていることがわかる。

次に水平歩行と傾斜路上り、下りを行った時の足裏部3軸応力分布の計測を行った。水平歩行の実験は床材にリノリウムを用いた屋内で、傾斜路上りと下りの実験は屋外のコンクリートの地面で行った。傾斜路の斜度は7.4度であった。いずれの実験においても、センサに荷重がかからないように椅子に座って足が地面に付かない状態で計測を開始し、両足立ちの状態になったら動作へと移行した。計測終了時は両足立ちの状態とした。歩行ペースは指定することなく被験者の歩き易いものとした。考察に用いるデータは得られたデータのうち運動中盤の比較的安定した動作時から波形を1つ抽出するものとする。

図3.4は水平歩行時の足裏3軸応力分布の推移を示す。(a)は垂直応力、(b)は前後方向のせん断応力、(c)は左右方向のせん断応力である。また、図3.5は傾斜路上りおよび下りにおける足裏3軸応力分布の推移を示す。(a), (b), (c)は上りのデータで(d), (e), (f)は下りのデータである。図3.5において(a), (d)は垂直応力、(b), (e)は前後方向のせん断応力、(c), (f)は左右方向のせん断応力である。

これらのデータから傾斜路における歩行への影響を考察する。傾斜路を上の際には踵での着地時の衝撃が小さく、また母指を除く前足部での蹴り出しが大きいことがわかった。反対に傾斜路を下る際には踵での着地時の衝撃が大きく、また、母指を除く前足部での蹴り出しが小さいことがわかった。一方で蹴り出しが際の母指の垂直応力は、実験を行った範囲内では220kPa程度とほぼ一定の大きさであることもわかった。

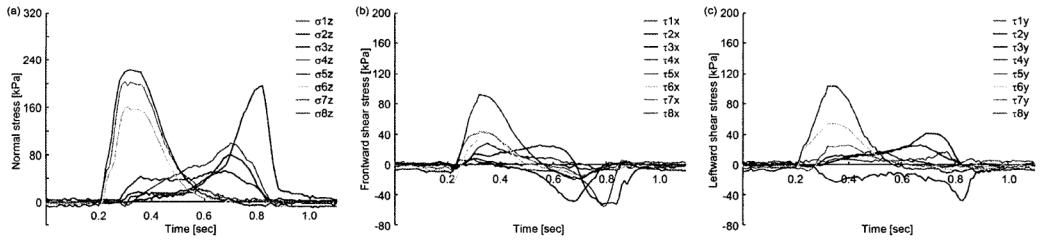


図 3.3: 水平歩行時のデータ [8]

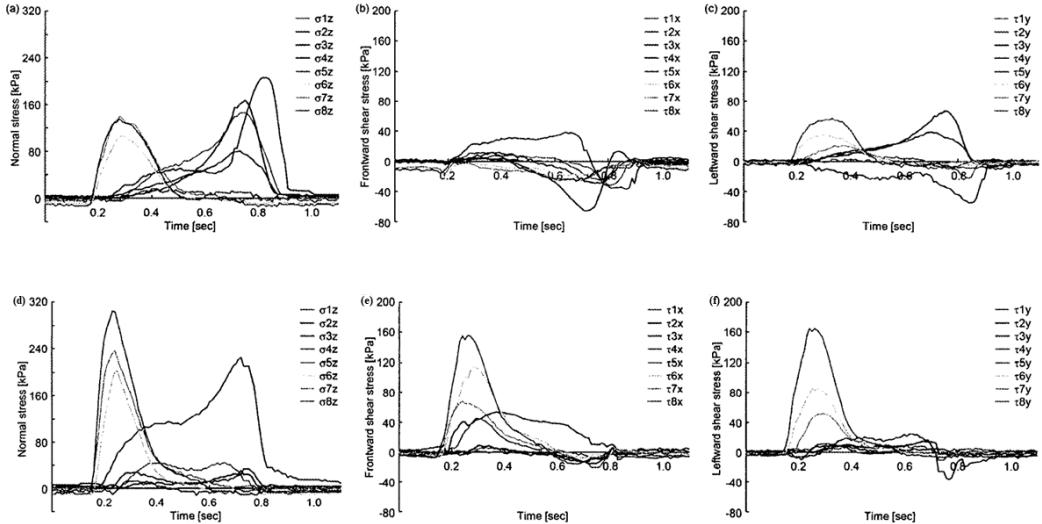


図 3.4: 傾斜路上りおよび下りのセンサデータ [8]

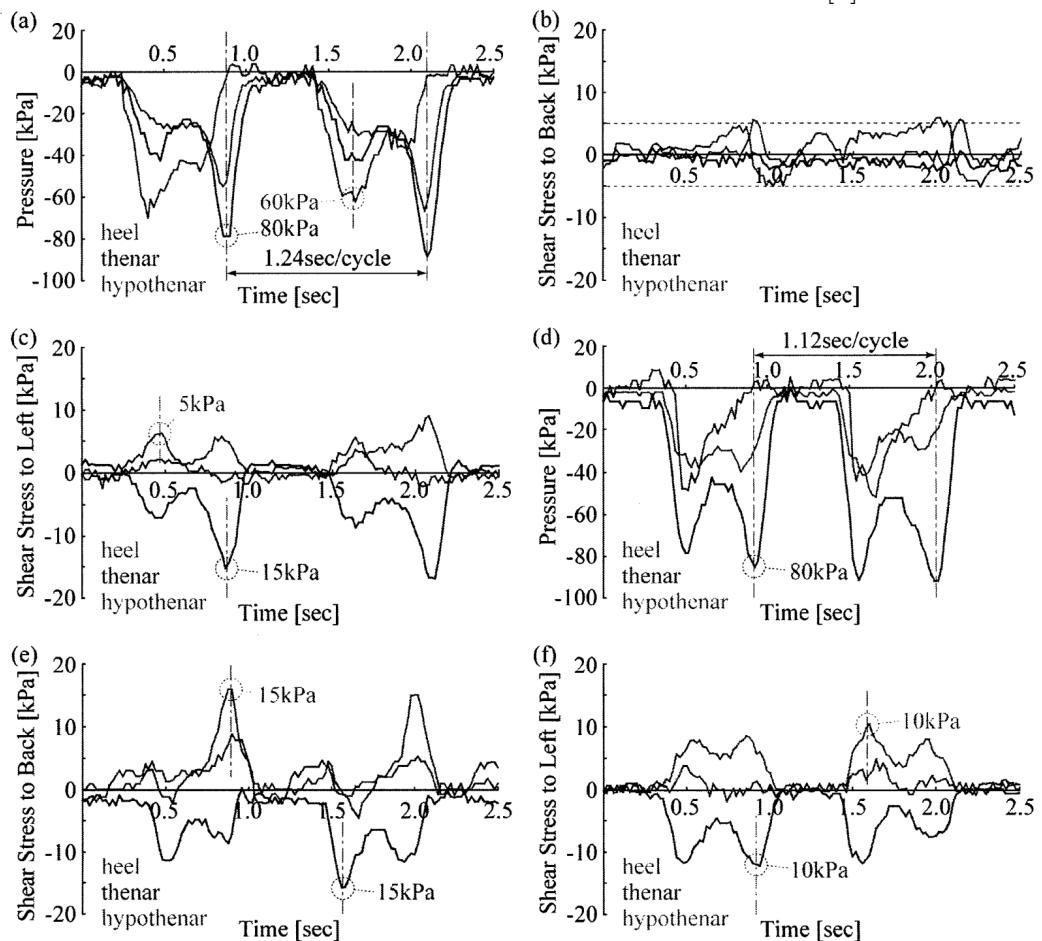


図 3.5: 階段昇降時のセンサデータ [9]

§ 3.2 ショッカクシューズと自作センサデバイス

本研究ではショッカクシューズを高額なセンサデバイス、自作センサデバイスを安価なデバイスとして用いる。

ショッカクシューズ

ショッカクシューズはタッチエンス株式会社の足裏センサで、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である(図3.6, 3.7参照)。ショッカクシューズには母指球、子指球、踵の直下に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、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。組み込まれたセンサで計測された母指球、子指球、踵で発生する各6軸方向の力や重心位置などの足運動データは専用アプリをインストールしたスマートフォンでリアルタイムに確認することができる。このとき、専用アプリはAndroid10以上のバージョンが必要となり、またBluetooth接続をしてショッカクシューズのデータを収集するためBluetooth4.2以上のスペックが必要となる。この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(地面反力、推進力、左右揺動力など)の足運動解析データを算出する。具体的には地面垂直反力、前後方向せん断力、左右方向せん断力、足高さを解析する。足運動データ(計測結果)および足運動解析データは専用WEBサーバからcsv形式でダウンロードが可能である。なお、足運動データは20msec(50Hz)周期で取得できる[10]。

ショッカクチップ 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。付属部品を使わず、このサイズのセンサから直接デジタル信号を出力してデータを収集することができる。ロボットの指先やウェアラブルデバイスなど、限られたスペースに取り付けることを目的とし、今までセンサを搭載できなかった場所に使用可能である。様々なシチュエーションで採用されているこのセンサは、ロボットの指先に搭載し、人間同様の感覚をデータ化するだけでなく医療器具に搭載することで感覚的な動作を数値として具現化することやゲームにおいて立体的な動作を可能にするといった幅広い分野、方向で活躍している[4]。



図 3.6: ショッカクシューズ [4]



図 3.7: ショッカクチップ 6DoF[4]

FSR402 圧力センサと自作デバイス

FSR402 はセンサ表面に加えられた圧力を検知するもので、様々なヒューマンインターフェースに用いられる [12]. 圧力 P_n はセンサデータを kg 単位で表す必要がある. センサデータの圧力を p_n として式 3.3 で定義する [13].

$$\frac{5(1024 - p_n)}{1024} + 2.0269 = 7687 \log P_n \quad (3.3)$$

自作センサデバイスはコンピュータ部を RaspberryPi Zero W, センサデータ取得部を Arduino nano で構成しており、センサは FSR402 圧力センサを 6 つ、MPU9250 を 1 つ搭載している足元センサデバイスである. バッテリーは RaspberryPi Zero W 専用のバッテリーモジュールである PiSugar2 を使用した. 自作デバイスの概要は 3.3 節、システム詳細は 4 章にて記載する.

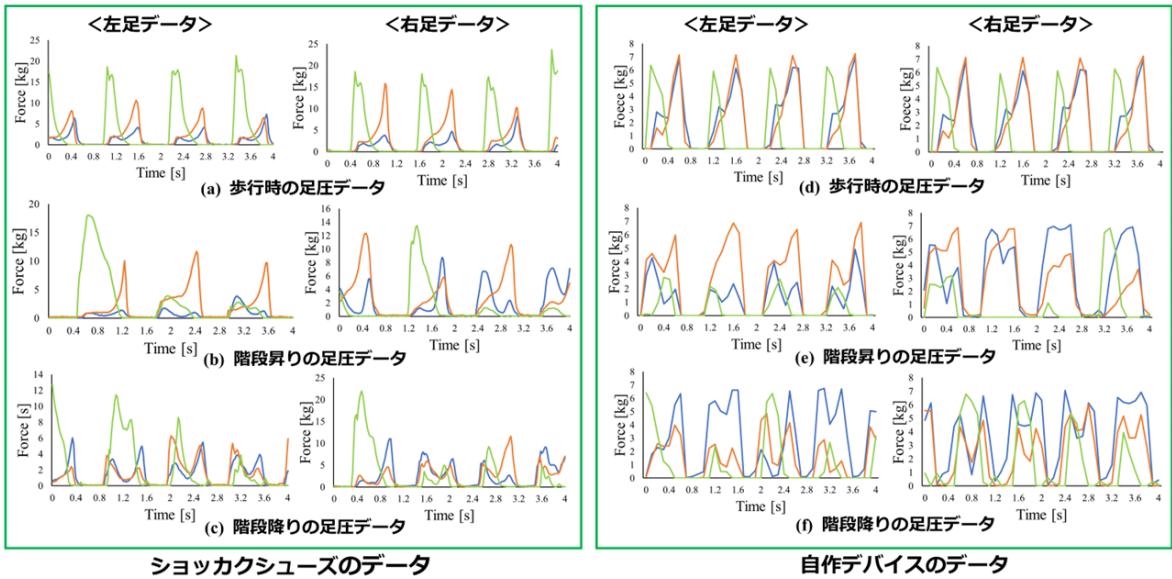


図 3.8: ショッカクシューズと自作デバイスの歩行データ

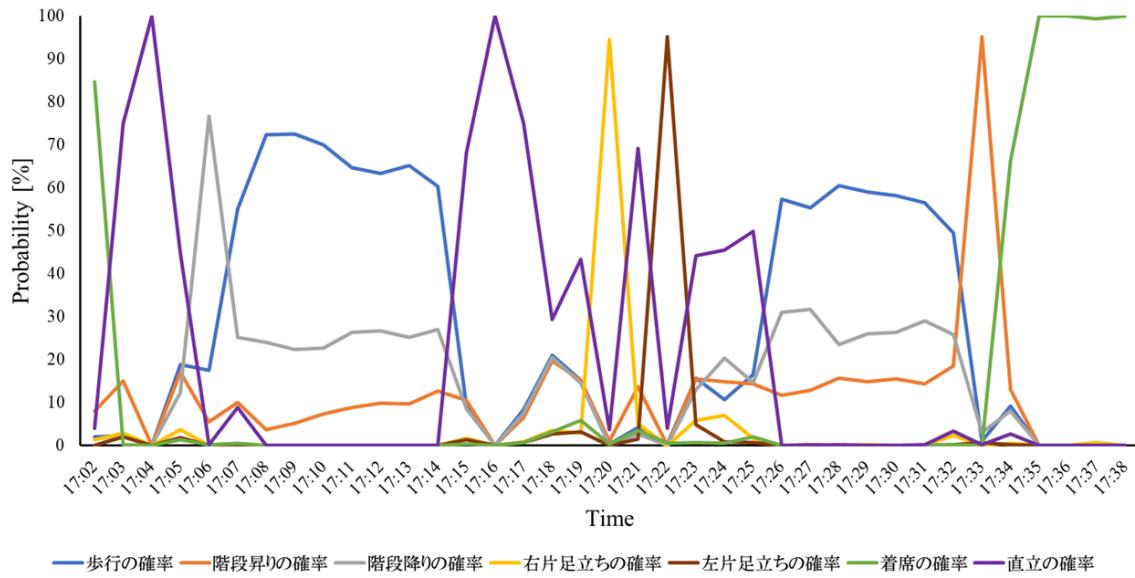


図 3.9: 自作デバイスの行動データグラフ

表 3.1: 自作デバイスの行動識別結果

時刻	機械学習の推定	実際の行動			
17:03	直立	直立	17:21	直立	歩行・直立
17:04	直立	直立	17:22	左片足立ち	左片足立ち
17:05	直立	歩行・直立	17:23	直立	歩行・直立
17:06	階段降り	階段降り	17:24	直立	歩行・直立
17:07	歩行	歩行	17:25	直立	歩行・直立
17:08	歩行	歩行	17:26	歩行	歩行
17:09	歩行	歩行	17:27	歩行	歩行
17:10	歩行	歩行	17:28	歩行	歩行
17:11	歩行	歩行	17:29	歩行	歩行
17:12	歩行	歩行	17:30	歩行	歩行
17:13	歩行	歩行	17:31	歩行	歩行
17:14	歩行	歩行	17:32	歩行	歩行・直立
17:15	直立	直立	17:33	階段昇り	階段昇り
17:16	直立	直立	17:34	着席	歩行・着席
17:17	直立	直立	17:35	着席	着席
17:18	直立	直立	17:36	着席	着席
17:19	直立	直立・右片足立ち	17:37	着席	着席
17:20	右片足立ち	右片足立ち			

図 3.8 は歩行時の足圧データ，階段昇りの足圧データ，階段降りの足圧データの 3 種類の歩行データを，ショッカクシューズと自作センサデバイスを用いてデータを収集しグラフ化して比較した図である。図の青いグラフは母指球，橙は子指球，黄緑は踵のセンサデータである。母指球とは足の親指の付け根にあたる大きな骨周りを指し，子指球は小指の付け根にあたる大きな骨周りを指す。剛体は 3 点存在すれば状態を維持することができる。人間の足はこの母指球，子指球，踵がその 3 点にあたり，自重を支えている。今回，日常生活で起こりうる歩行状態としてこの 3 種類の行動をデータ化し，比較解析を行った。

データを見比べると，それぞれの行動における値の推移がどちらも同じ変化の仕方を示している。例えば歩行時のデータは，踵から地面に接地したんだん地面から離れていくと同時に足先(母指球，子指球)が地面に接地する様子が両者から読み取ることができる。これにより，歩行時の状態をデータグラフから判別することができるので自作デバイスのデータはショッカクシューズと同等のレベルであるといえる。同様に階段昇りと降りについても両者が同様なデータグラフを示している。

図 3.9，表 3.1 は自作デバイスによる行動識別の結果を表したものである。2023 年 1 月 22 日に富山県立大学奥原・レネ研究室からセブンイレブン射水太閤山東店までの道のりを往復したときの行動を解析した。識別のために解析した行動は歩行，階段の昇降，左右片足立ち，着席，直立の 7 種類である。図 3.9 で解析した確率は，1 分間の行動データ csv ファイル(0.0 秒から 60.0 秒までの 600 行)を機械学習により解析し，1 行ずつ行動を 7 種類から予測して最後に全行のうち何行がその行動かを算出した値である。表 3.1 はその行動予測により推定した行動と実際の行動を比較した表である。1 分間で 2 種類の行動を行った場合は，より長く行った行動が推定されたが，1 種類の行動を継続して行った場合は高確率で機械学習の推定行動が実際の行動と一致した。

以上より，自作デバイスで解析可能な生体情報データを得ることを確認した。

§ 3.3 自作デバイスの有意性

自作デバイスの概要

自作デバイスおよびインソールの内部構造を図3.10に示す。自作デバイスはインソール部とデバイス部の2部構成となっている。インソール部は図3.10からわかるように6つの圧力センサが貼り付けられている。3.2節で人間の自重を支える3点は母指球、子指球、踵であることを記したように、圧力センサはショッカクシューズと同じ母指球、子指球、踵の3か所に貼り付けた。加えて中指中節骨、第一楔状骨(けつじょうこつ)、立方骨にそれぞれ1つずつ配置した。デバイス部は $10k\Omega$ 抵抗、MPU9250、Arduino nano、RaspberryPi Zero Wをユニバーサル基盤にはんだ付けしたものである。Arduino nanoでセンサデータを収集し、RaspberryPiにある通信プログラムからサーバにデータを転送する。このシステムの流れについては4.3節にて詳細を記載する。

図3.11に人間の足の骨格を示す。手足の指の骨で爪先の骨を末節骨、付け根の骨を基節骨といい、中節骨はその間に位置する。中指は指の中央に位置し、中節骨も中央に位置する骨なので足先の中央の骨ということで中指中節骨の位置に圧力センサを配置した。母指球、子指球、踵の3点では土踏まずの情報を得ることができない。基本的に土踏まずに体重がかかることはないが、作業によっては体を傾けて行うことがあるとすれば、そのときに土踏まずに体重が偏ることが考えられる。上記の3点ではその場合の計測が不可能なので土踏まずに位置する第一楔状骨にセンサを配置した。同様に考えた場合、土踏まずのある方向とは逆向きに体を傾けた場合の情報が得られにくいので、その場所に位置する立方骨にセンサを配置した。自重を支える3点(母指球、子指球、踵)とは別に体を支える骨を3点(中指中節骨、第一楔状骨、立方骨)にセンサを配置し、足全体の体重のかかり方を詳細に解析することができる。

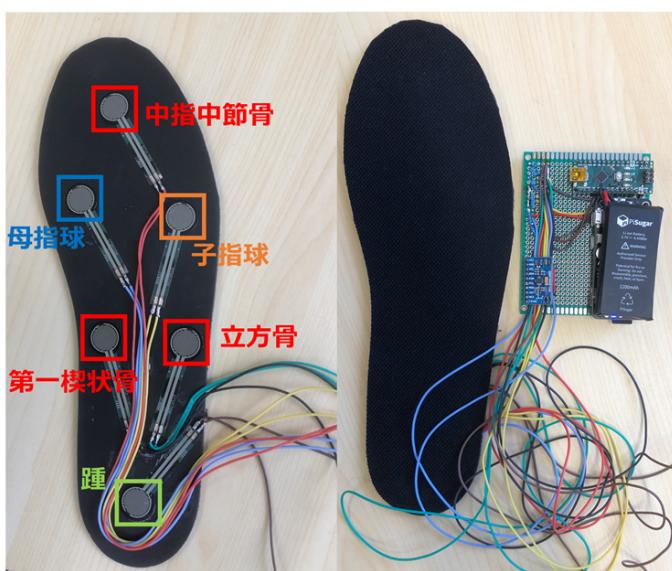


図3.10: 自作デバイスとインソールの内部構造



図3.11: 人間の足の骨格 [14]

ショッカクシューズのメリットとデメリット

ショッカクシューズは、ショッカクチップにより3軸応力および3軸モーメントを計測することができる。さらにタッチエンス独自のAI解析によりせん断力や反力などの解析も可能である。シューズのデザインが黒基調のスニーカーで、一見普通の靴と変わらない見た目をしており、実験で用いる際にもバッテリーを入れて履くだけなのでとても楽である。しかし、このシューズはあくまで研究、実験用なので実用性に欠けるところがあると考える。

デメリットとして5つ意見を述べる。

1つ目はセンサが足に当たり、違和感があることだ。足には複数の神経が通っており、足裏に得られた感覚を敏感に捉えて脳に伝達する。ショッカクチップやリチウムイオンバッテリーが足に当たることで歩行時や直立時といった様々な行動において違和感を抱いてしまう。

2つ目はショッカクシューズを履かないと計測が行えないということだ。この言葉の意味としては、日ごろ使っており履き慣れている靴を使えないということである。靴は私たちが日常生活を送るうえで必要不可欠なものである。その靴は毎日使っていることで慣れていくものであると私は考える。ショッカクシューズを日ごろから使わず実験を行うときにだけ用いるとなると、そもそもその靴の違いから違和感を抱き歩行などの行動に違いが出てしまう。

3つ目は電波環境によっては使えない場合があることだ。3.2節で述べたようにショッカクシューズはショッカクアプリと連携するためにBluetoothを使用する。しかし、非常に強い電波が発生している環境下ではBluetooth接続が途切れてしまい、データの収集ができなくなってしまう。しかし、これはBluetoothを用いる機器すべてに共通していえるので使用者は電波発生機器を避けてシューズを使用しなければならない。

4つ目はバッテリーの使い勝手の悪さである。ショッカクシューズのバッテリーはリチウムイオンバッテリー400mAhである。このバッテリーをショッカクシューズに用いると、実験可能時間はおよそ30分となり、実験的にデータを取得するには十分な時間だが日常生活で永続的にデータを取り続けることができない。さらに充電時間がおよそ3時間しており、日常的に利用するには非常に効率が悪い。

5つ目はコストが高いことである。ショッカクシューズ本体とタッチエンス株式会社のサーバ使用料がとても高く実用性はない。しかし、高額なのはセンサ自体の精度の良さがあるため品質の良さは保証されている。

自作デバイスのメリットとデメリット

自作デバイスはインソール型のセンサデバイスなので靴を選ばない。被験者および利用者が日常で使用している靴に入れてデバイスを使用することができる。またデバイスを作る際、インソールをはさみで切ることによりサイズを調整する。そのサイズは21cmから28cmまで対応が可能である。それにより、デバイス設計のうえでサイズを幅広く対応することができ生産しやすい点がある。このインソールはとても柔らかい素材できていることかつ、FSR402圧力センサの薄さから足と接地したときのごつごつするような違和感を少なく抑えている。さらに、自作デバイスに用いるバッテリーモジュールのPiSugar2はバッテリー容量を1200mAhとしており、駆動時間がおよそ4時間、充電時間がおよそ30分と機能面においてとても優れている。

しかし、自作デバイスはネットワーク環境を必要とするため、屋外での作業で用いる際にポケット Wi-Fi やデザリングでネットワーク環境を作らなければならない。デザリングはスマートフォンからネットワークを共有することで自作デバイスを動かすことができる。だが利用者のスマートフォンのインターネット契約およびパケット使用量に応じてどれだけデバイスを使用できるかが変わってしまう。加えてショッカクシューズと同様に、強力な電波障害があった場合は装置を使うことができない。

ショッカクシューズと比較した自作デバイスの有意性

ショッカクシューズのデメリットとそれを考慮した自作デバイスの改善点を表 3.2 に示す。ショッカクシューズのデメリットを改善、改良した自作デバイスの有意性を大きく 4 つ挙げる。

1 つ目は足への違和感の違いである。ショッカクシューズはセンサやバッテリーが靴の中にすべて格納されているため、足にセンサが当たる違和感を感じる。自作センサは柔らかい素材のインソールを採用しているため、履き心地の向上に成功した。

2 つ目は使用上の柔軟性の向上である。ショッカクシューズは、実験を行う際は必ずショッカクシューズを用いなければならないが、自作デバイスは靴のサイズが合えばどの靴でも使用できる。

3 つ目はバッテリーの使い勝手の良さである。ショッカクシューズのリチウムイオンバッテリーと PiSugar2 を比較すると、PiSugar2 は充電時間の大幅な短縮と駆動時間の大幅な延長を可能にした。これにより実用化に向けた機能面の向上を成功させた。

4 つ目はコスト削減である。自作デバイスは安価なセンサを用いてコストの削減に成功した。しかし、今後の課題としてマイコンの低コスト化などさらなるコスト削減を目指していかなければならない。

表 3.2: ショッカクシューズと自作デバイスの歩行データ

	ショッカクシューズのデメリット	自作デバイスのメリット
足への違和感	ショッカクチップが足に当たる	柔らかい素材のインソールで足への違和感を緩和
使用上の柔軟性	ショッカクシューズを必ず履かなければならぬ	靴のサイズが合えばどの靴でも対応可能
バッテリー	駆動時間約 30 分 充電時間約 3 時間	駆動時間約 4 時間 充電時間約 30 分
コスト	実用性を求めるには非常に値段が高い	安価なセンサを用いているためコスト軽減に成功

提案手法

§ 4.1 就労継続支援B型と福祉的支援デバイス

本研究で対象とする方々に関する就労継続支援B型について説明する。

就労継続支援B型とは、通常の事業所において雇用契約に基づく就労が難しい人々に対し、就労の機会や生産活動などの働く場に関する機会の提供、その他の就労に必要な知識、能力の向上のために必要な訓練や支援を行う事業所またはサービスのことである。すなわち、「雇用契約を結ばずに」生産活動などの就労訓練を行うことができる事が就労継続支援B型の特徴である。この利点として、自分の障害や症状に合わせて、無理のない範囲で比較的軽作業を少しずつ自分のペースで行うことができる点がある。また就労継続支援B型は、身体障害・知的障害・精神障害や難病があり、主治医から事業所利用の了解を得た方の中で、指定された要件に当てはまる方が対象となる。この要件は大きく4つある。それは、就労経験があり、年齢や体力の面で、一般企業に雇用されることが困難になった方、50歳以上の方、障害基礎年金1級を受給している方、就労機構支援事業所等によるアセスメントにより、就労面の課題が把握されていて、かつ就労継続支援B型事業所を利用する方が適切だと判断された方のいずれかに当てはまる人である。ただし、B型事業所の利用は臨機応変に対応されることがあるため、住んでいる自治体の地方自治によって異なる場合がある[15]。

就労継続支援B型に割り当てられた人は上記から一般雇用が難しいため、特別な支援を受けて働く訓練を行わなければならない。その支援を現在では事業所の職員など「人」が行っている。障がい者から目を離すことなく作業を見続け、困惑していれば誘導し、パニックに陥っていれば安心させるよう促すことが職員に求められる支援活動である。この支援をICTで行うことができれば、工学的視点で障がい者を支援することができるだけでなく、拘束される職員の負担を軽減することができる。では、この就労継続支援B型に指定されている方々がICT機器を用いるとどのようなことが想定されるかについて以下に記述する。

iPhoneやスマートフォンなどのICT機器は、携帯電話の中でも主流となり、日常生活で欠かせないものとなっている。それだけでなくApple Watchといったスマートウォッチは生体情報を測り健康状態を知らせる機能が備わっている。これらはショッピングや連絡手段といった人々の生活の根幹に関わる重要な役割を担っているだけでなく、動画視聴やSNSなどのコミュニケーションツールとして、人々の娛樂を与える方面でも活躍している。それは障がい者も例外ではなく日常的に用いられているが、福祉的支援の場で充分活かされているとはいひ難い。上西、望月は福祉的支援の場においてICT活用が進まないことを、何らかの困難さがあるとして考えた。

障害種別を外部変数とした対応分析の結果を以下に記す。障害種別とは身体、知的、精神の3つを指し、これを外部変数とする。知的障害を主としている方の特徴として、基本操作やハード機器の扱い方法、利用場面の設定が難しいという意見回答があることが分かった。一般的に難しさを感じない操作でも知的障がい者にとってはハードルの高いものになることがわかり、これは知的障がい者にとってICT機器を利用する難しさのパターンであることがわかった。また、犯罪に巻き込まれるのではないかといった不安を提示した。

身体障害を主としている方の特徴として、記憶の保持が困難であることや視覚障がい者にとってハードルが高いことといった、主に機能面に着目した意見回答があることがわかった。

精神障害を主としている方の特徴として、ゲームの課金などで債務を負い困っているケースがあること、利用者間でSNSを使用する際にトラブルを起こしたこと、インターネットショッピング等でトラブルを抱えたこと、ICTに興味を持つと依存傾向にあると考えるのあまり積極的に活用したくないといった「ゲーム」、「トラブル」、「依存」というキーワードが頻出し、ICT機器を利用することによるトラブルや依存などの弊害を感じたり、心配していることがわかった。

支援者はICT活用の必要性を感じており、さらに利用者がプライベートで利用している様子を見ながらも、支援に有効と思われるアプリケーションがないことや、利用者の身体や精神上の障害や経済状況によって機器を操作すること自体が困難であること、活用することがトラブルに発展して利用者の不利益になると想え、支援の場でICTを積極的に活用する必要性を感じられない。加えて、ICT機器を用いるとなれば事業者にとっては環境整備や費用調達が求められることになり、活用スキルをもつ職員の確保といった金銭的・人的資源が不足する。また、利用者と支援者の距離感を保つためにあえてICT活用を制限している面もある。つまり、ICT活用は利用者と支援者の距離感を崩してしまう一面があるということである[16]。

ICTを利用すれば人間の目視ではわからない工学的観点の気づきを見つけることができる。それにより利用者に何かしらのメリットを生み出すことができる。しかし、上記のような障がい者だからこそ考えられるデメリット存在し、我々技術者はICT機器を開発する際に必ず考慮して製品を作らなければならない。すなわちここでユニバーサルデザインの考え方を用いる。1.2節で述べたように「公平性」、「単純性」、「明確さ」、「安全性」、「体への負担の少なさ」に着目してICT機器を作らなければ、その機器は利用者にとってデメリットでしかなくなってしまう。

本研究は富山県魚津市にある就労継続支援B型の支援施設である「ぶどうの森」の方を対象に研究および実験を行う。ここでは、農作業を通じて働くことを学び、社会的コミュニケーションといった社会活動を経験して就労に必要な知識や経験を得ることができる。そこで用いるためのICT機器の開発ということで足元センサデバイスを開発した。この自作デバイスは上記のユニバーサルデザインを考慮して作られている。具体的に着目した5項目についてどのような点を考慮したかを記述する。

初めに「公平性」について述べる。これを考えるうえで重要なことは身体的・心理的に使う人を選ぶことなく、誰でも公平に操作できることである。自作デバイスではこの公平性について、自分の靴さえあれば誰でも使うことができる設計にし、特定のデバイスや道具を必要とすることなく利用できるようにした。しかし、足のサイズが合うことが前提のため、サイズが合わない人は利用することができない。

次に「単純性」について述べる。自作デバイスはインソールを靴に入れ、デバイス部を足首に装着するだけで装置を利用することができる。結果の応答や行動学習はLINEアプリケーションで行う。その際はエッジトリガを「アレクサ」とし、「結果を見て」や「登録、歩行」など、人に話しかける様と同じように入力すれば機能するように開発した。アレクサが備わっているGoogle HomeやAmazon Echoを利用したことがない人からすると、初めは使い方に慣れないと予想されるが使っていくことで徐々に慣れると考える。LINEアプリケーションについては4.3節に詳しい記載をする。

次に「明確さ」について述べる。使う人すべてがその情報を理解しやすいものであることが求められる。自作デバイスにおいて、取扱説明書の簡潔さやコーピング結果の内容の見やすさを理解しやすいものにした。しかし、この情報の伝達手段が文字でしかないので、読むことが苦手な人にとっては不自由な点である。また、媒体がLINEなので紙媒体に慣れている人からすると扱いにくい点もある。読むことが苦手な人に向けて、文章を短く区切り、かつ簡潔な内容にまとめて説明およびコーピングを行う文章を作成した。

次に「安全性」について述べる。使用時に自己の心配がなく、誰もが安全にデバイスを利用できることを目指す。人間は必ずミスをするので、そのときに安全に処置できるデバイスでなければならない。本研究では農地で自作デバイスを用いることを想定しているため、湿気により人体に感電してしまう危険性を予想した。そのため、防水・防塵機能のあるケースに入れて人体に影響を及ぼさないように配慮した。また、LINEの文字入力で打ち間違いを起こしても、元に戻る機能や誤送信してしまった文字を削除できる機能を搭載した。これは利用者の安心につながるため、デバイスを利用するにおけるストレスを引き起こさないことになる。LINEを用いることはコミュニケーションツールを用いることになるのでメッセージをやり取りする際の人間関係でトラブルになる可能性がある。だが、本研究で用いるのはシステムアプリケーションのみなので利用者が特別にコミュニケーションとして使用しないのであれば、このアプリケーションのみを登録すればよいので人間関係におけるトラブルが起こることはないと予想できる。加えて、課金等の有料システムではないためお金に関する心配をしなくてよい。

最後に「体への負担の少なさ」について述べる。体への負担の少なさとは、無理な姿勢をとらなければならないということではなく、少ない力で使用することができることである。自作デバイスを用いた場合、日常的に使っている靴で足元センシングを行うため、無理な姿勢や不必要な力を要することはなく、普段通りの生活や仕事を行えばよいので体への負担は少ないと考える。なのでデバイスを用いることによる身体的負担より、仕事や作業を継続的に行うことでの引きおこる身体的疲労が負担になると予想できる。その際のコーピングとして休息を促すようにシステムを設計した。

自作デバイスは障がい者が装着してLINEアプリを用いて自身の状態を把握し、生活や仕事を円滑に行うために用いる。そうなると、障がい者がしかし見方を変えれば、支援者がLINEアプリを見れば障がい者の身体および精神状態を工学的結果から見るので、適切なタイミングでより良い声掛けといった対処を施すことができる。自作デバイスを用いることは、利用者(障がい者)と支援者の関係を切り離し距離感を崩すものではなく、距離感をより近くにすることと関係性をより深めることができるための潤滑剤になると私は考える。

§ 4.2 足元センシングとデータ解析

本研究に用いるアルゴリズムを紹介する。デバイスのインソール部にある圧力センサから様々な行動状態のデータを収集する。集めた圧力データから足元の重心を計算する。また、デバイス部にある MPU9250 から得られた加速度、角速度のデータから、足の動きに関する姿勢状態推定を拡張カルマンフィルタにより算出する。

重心

足に負荷がかかることにより体の重心はずれが生じる。安定した歩行状態や直立状態といった行動は周期的な重心移動となるが、疲労や心的外傷などで挙動が不安定になると重心も安定しなくなる。本研究では圧力センサデータから片足にかかる重心を算出し、機械学習の教師用データに用いて行動状態の推定を行う。中節骨の圧力を \mathbf{P}_1 、中心からの距離を r_1 、母指球の圧力を \mathbf{P}_2 、中心からの距離を r_2 、子指球の圧力を \mathbf{P}_3 、中心からの距離を r_3 、第一楔状骨の圧力を \mathbf{P}_4 、中心からの距離を r_4 、立方骨の圧力を \mathbf{P}_5 、中心からの距離を r_5 、踵の圧力を \mathbf{P}_6 、中心からの距離を r_6 とする。

このとき、 r_n^2 は

$$r_n^2 = \mathbf{x}_n^2 + \mathbf{y}_n^2 \quad (4.1)$$

となる \mathbf{x}_n と \mathbf{y}_n が存在すると定義する。 $\mathbf{r} = \mathbf{0}$ はインソールの重心とすると、重心 \mathbf{G}_x 、 \mathbf{G}_y は式 4.2 で表す。ここで用いる \mathbf{P}_n は式 3.3 に基づいてセンサデータ \mathbf{p}_n から算出している。

$$\mathbf{G}_x = \frac{\sum_{n=1}^6 \mathbf{P}_n \mathbf{x}_n}{\sum_{n=1}^6 \mathbf{P}_n} \quad \mathbf{G}_y = \frac{\sum_{n=1}^6 \mathbf{P}_n \mathbf{y}_n}{\sum_{n=1}^6 \mathbf{P}_n} \quad (4.2)$$

拡張カルマンフィルタ EKF(Extended Kalman Filter)

カルマンフィルタは線形関数において用いられる数式である。2章で述べたなぞり運動は星形を 30 回なぞる周期的な運動であるため、線形関数とみなしカルマンフィルタを用いた。しかし、足元データは周期性がないので非線形なデータ群となる。この場合は非線形関数に対応する拡張カルマンフィルタを用いる [17]。

式 2.1 および 2.2 の状態方程式、観測方程式を以下に書き換える。

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_k) + \boldsymbol{\omega}_k \quad (4.3)$$

$$\mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{v}_k \quad (4.4)$$

このとき、状態遷移行列 \mathbf{F}_k および観測行列 \mathbf{H}_k は上式から f および h をヤコビアンで表す。

$$\mathbf{F}_k = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_k} \quad (4.5)$$

$$\mathbf{H}_k = \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k|k-1}} \quad (4.6)$$

本研究における拡張カルマンフィルタの予測および更新式は
予測のステップを

$$\hat{\mathbf{z}}_{k|k-1} = f(\hat{\mathbf{z}}_{k-1|k-1}, \mathbf{u}_k) \quad (4.7)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q}_k \quad (4.8)$$

更新のステップを

$$\mathbf{e}_k = \mathbf{y}_k - h(\hat{\mathbf{z}}_{k|k-1}) \quad (4.9)$$

$$\mathbf{S}_k = \mathbf{R}_k + \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T \quad (4.10)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (4.11)$$

$$\hat{\mathbf{z}}_{k|k} = \hat{\mathbf{z}}_{k|k-1} + \mathbf{K}_k \mathbf{e}_k \quad (4.12)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (4.13)$$

とする。

本研究は状態遷移行列 \mathbf{F}_k を求めることにより、足首の姿勢状態推定を数学的に算出する。まず、状態方程式である $f(\hat{\mathbf{z}}_{k-1}, \mathbf{u}_k)$ を求める。オイラー角を用いて時刻 k の状態推定値 $\hat{\mathbf{z}}_k$ をオイラー角の変化量をそれぞれ δ を用いて式 4.14 で表す。

$$\begin{aligned} \hat{\mathbf{z}}_k &= (\phi_k, \theta_k, \psi_k) \\ \therefore \hat{\mathbf{z}}_k &= (\phi_{k-1} + \delta\phi, \theta_{k-1} + \delta\theta, \psi_{k-1} + \delta\psi) \end{aligned} \quad (4.14)$$

ここで、三次元空間回転行列を γ_k としてオイラー角を用いて式 4.15 で表す。

$$\gamma_k = \begin{pmatrix} 1 & \frac{\sin \phi_{k-1} \sin \theta_{k-1}}{\cos \theta_{k-1}} & \frac{\cos \phi_{k-1} \sin \theta_{k-1}}{\cos \theta_{k-1}} \\ 0 & \cos \phi_{k-1} & -\sin \phi_{k-1} \\ 0 & \frac{\sin \phi_{k-1}}{\cos \theta_{k-1}} & \frac{\cos \phi_{k-1}}{\cos \theta_{k-1}} \end{pmatrix} \quad (4.15)$$

MPU9250 で得られた角速度のデータの微小時間変化 $\omega_k \delta t = (\omega_{k,x} \delta t, \omega_{k,y} \delta t, \omega_{k,z} \delta t)$ は、微小時間 δt で回転行列 γ_k が発生することを表す。

すなわちオイラー角の変化量は

$$(\delta\phi, \delta\theta, \delta\psi) = \gamma_k \omega_k \quad (4.16)$$

と表せる。入力ベクトル \mathbf{u}_k は ω_k と同値であるので式 4.17 で書き表す。

$$\mathbf{u}_k = \begin{pmatrix} \omega_{k,x} \\ \omega_{k,y} \\ \omega_{k,z} \end{pmatrix} = \begin{pmatrix} u_{k,x} \\ u_{k,y} \\ u_{k,z} \end{pmatrix} \quad (4.17)$$

すなわち、状態推定値 $\hat{\mathbf{z}}_k$ は

$$\begin{aligned} \hat{\mathbf{z}}_k &= \begin{pmatrix} \phi_k \\ \delta_k \\ \psi_k \end{pmatrix} = \begin{pmatrix} \phi_{k-1} + \delta\phi \\ \delta_{k-1} + \delta\theta \\ \psi_{k-1} + \delta\psi \end{pmatrix} = \begin{pmatrix} \phi_{k-1} \\ \delta_{k-1} \\ \psi_{k-1} \end{pmatrix} + \gamma_k \omega_k = \begin{pmatrix} \phi_{k-1} \\ \delta_{k-1} \\ \psi_{k-1} \end{pmatrix} + \gamma_k \mathbf{u}_k \\ &= \begin{pmatrix} \phi_{k-1} + u_{k,x} + u_{k,y} \frac{\sin \phi \sin \theta}{\cos \theta} + u_{k,z} \frac{\cos \phi \sin \theta}{\cos \theta} \\ \delta_{k-1} + u_{k,y} \cos \phi - u_{k,z} \sin \phi \\ \psi_{k-1} + u_{k,y} \frac{\sin \phi}{\cos \theta} + u_{k,z} \frac{\cos \phi}{\cos \theta} \end{pmatrix} \end{aligned} \quad (4.18)$$

式 4.7 および式 4.18 より状態方程式 f は式 4.19 となる.

$$f(\hat{\mathbf{z}}_{k-1}, \mathbf{u}_k) = \begin{pmatrix} \phi_{k-1} + u_{k,x} + u_{k,y} \frac{\sin \phi \sin \theta}{\cos \theta} + u_{k,z} \frac{\cos \phi \sin \theta}{\cos \theta} \\ \delta_{k-1} + u_{k,y} \cos \phi - u_{k,z} \sin \phi \\ \psi_{k-1} + u_{k,y} \frac{\sin \phi}{\cos \theta} + u_{k,z} \frac{\cos \phi}{\cos \theta} \end{pmatrix} \quad (4.19)$$

観測方程式 \mathbf{y}_k はロール角とピッチ角を用いて表し, かつ加速度 $\mathbf{a} = (a_x, a_y, a_z)$ を用いて表すと式 4.20 となる. 加えて h は式 4.21 で表す. このとき, ヨー角である ψ_k は加速度センサを用いて表すことができない. それは基準座標平面上において, 重力加速度の方向と z 軸方向は常に平行であるためである.

$$\mathbf{y}_k = (\phi_k, \theta_k) = \left(\tan^{-1}\left(\frac{a_{k,y}}{a_{k,z}}\right), \tan^{-1}\left(\frac{a_{k,y}}{a_{k,z}}\right) \right) \quad (4.20)$$

$$h = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} \quad (4.21)$$

加速度センサのノイズ \mathbf{R}_k , 角速度センサのノイズ \mathbf{Q}_k は

$$\mathbf{R}_k = \begin{pmatrix} \delta t^2 & 0 \\ 0 & \delta t^2 \end{pmatrix} \quad (4.22)$$

$$\mathbf{Q}_k = \begin{pmatrix} 60 & 0 & 0 \\ 0 & 60 & 0 \\ 0 & 0 & 60 \end{pmatrix} \quad (4.23)$$

とする.

最後に式 4.19 にヤコビアンを用いて線形関数に近似する.

$$\begin{aligned} \mathbf{F}_k &= \left. \frac{\partial f}{\partial \mathbf{z}} \right|_{\hat{\mathbf{z}}_{k-1|k-1}, \mathbf{u}_k} \\ &= \begin{pmatrix} \frac{\partial f_\phi}{\partial \phi} & \frac{\partial f_\phi}{\partial \theta} & \frac{\partial f_\phi}{\partial \psi} \\ \frac{\partial f_\theta}{\partial \phi} & \frac{\partial f_\theta}{\partial \theta} & \frac{\partial f_\theta}{\partial \psi} \\ \frac{\partial f_\psi}{\partial \phi} & \frac{\partial f_\psi}{\partial \theta} & \frac{\partial f_\psi}{\partial \psi} \end{pmatrix} \quad \left(\because f(\hat{\mathbf{z}}_{k-1}, \mathbf{u}_k) = \begin{pmatrix} f_\phi \\ f_\theta \\ f_\psi \end{pmatrix} \right) \\ &= \begin{pmatrix} 1 + u_{k,y} \frac{\cos \phi \sin \theta}{\cos \theta} - u_{k,z} \frac{\sin \phi \sin \theta}{\cos \theta} & u_{k,y} \frac{\sin \phi}{\cos^2 \theta} + u_{k,z} \frac{\cos \phi}{\cos^2 \theta} & 0 \\ -u_{k,y} \sin \phi - u_{k,z} \cos \phi & 1 & 0 \\ u_{k,y} \frac{\cos \phi}{\cos \theta} - u_{k,z} \frac{\sin \phi}{\cos \theta} & u_{k,y} \frac{\sin \phi \sin \theta}{\cos^2 \theta} + u_{k,z} \frac{\cos \phi \sin \theta}{\cos^2 \theta} & 1 \end{pmatrix} \quad (4.24) \end{aligned}$$

この三次元行列で表された線形関数 \mathbf{F}_k を本研究の姿勢状態推定における状態方程式として用いる.

以上が本研究におけるデータ解析のアルゴリズムである. 両足で合計 12 種類の圧力データと 12 種類の 6 軸データ, また両足で合計 4 種類の重心データと拡張カルマンフィルタによる状態方程式の三次元行列が両足で 18 種類のデータがある. この合計 46 種類の値を機械学習にかける. 本研究で用いる機械学習の手法はニューラルネットワーク(パーセプトロン)である. このシステムの流れの詳細は次の 4.3 節で説明する.

§ 4.3 本研究のシステムの流れ

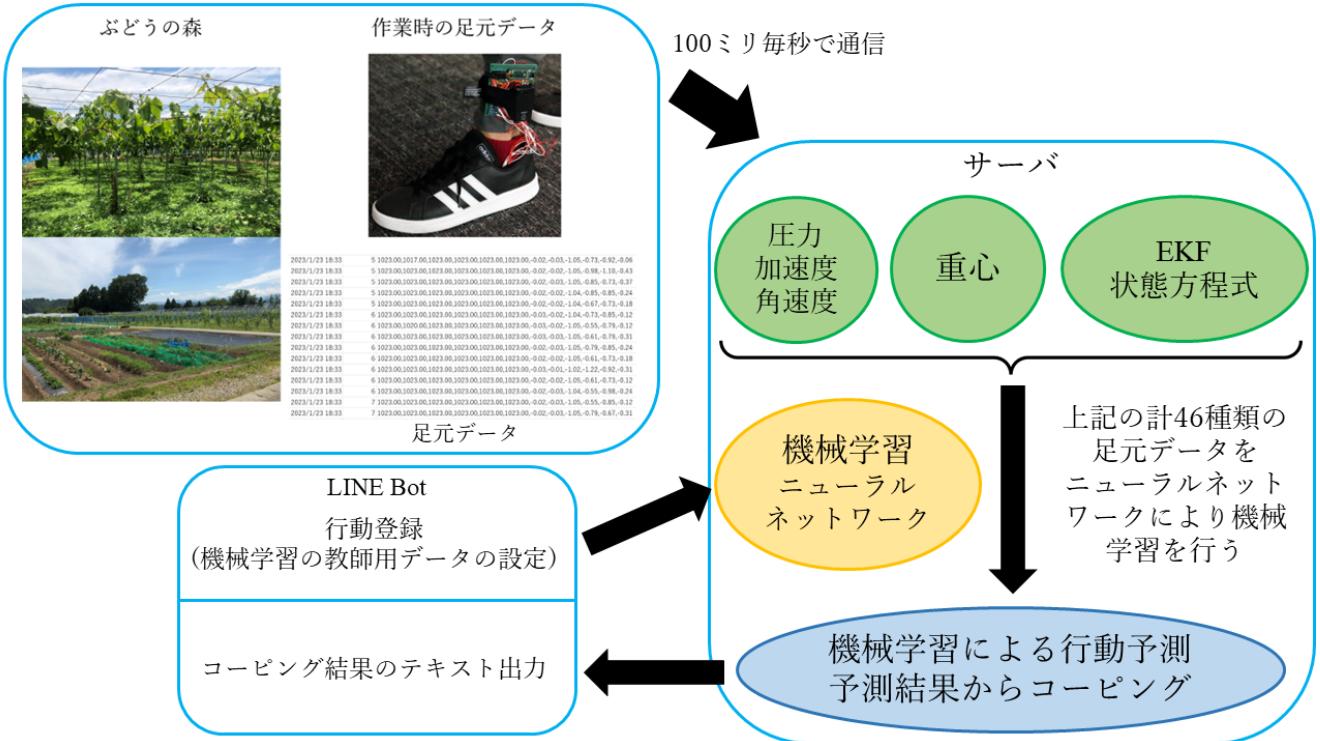


図 4.1: システム概要

本節に提案手法のシステムを紹介する。まず、図 4.1 に本研究のシステムの概要を表す。提案システムは、ネットワーク通信を用いて研究室の学内サーバと自作デバイスを連携させて足元センシングを行うことが特徴である。自作デバイスでのシステムの流れを説明する。自作デバイスは Arduino nano を用いて片足から 6 種類の FSR402 圧力データと MPU9250 から 3 軸加速度、3 軸角速度の計 12 種類、両足合わせて 24 種類のデータを 100 ミリ毎秒の間隔で取得する。取得したデータは RaspberryPi Zero W から Python プログラムより TCP ソケット通信で学内サーバにデータを転送する。上記の流れはプログラムを動かしてセンサデータを取り続けている限り、止まることなくデータ転送が行われる。

サーバでのシステムの流れを説明する。RaspberryPi Zero W から転送されたデータを受け取ったら重心と拡張カルマンフィルタ (EKF) の計算を行う。重心は右足の x, y 座標および左足の x, y 座標の計 4 種類のデータを得る。EKF により 6 軸センサデータから式 4.24 の三次元行列を計算する。これが両足で計 18 種類となる。4.2 節でも記述したように、センサデータが 24 種類と重心が 4 種類、EKF が 18 種類で合計 46 種類のデータを得ることができる。これが 100 ミリ毎秒ごとに収集されるので 1 分間で 27600 個集まるうことになる。ニューラルネットワークによる行動予測は、収集および計算した 1 分間のデータ 27600 個をもとに行う。この行動予測を行うために学習データを用意しなければならない。そのため、機械学習による学習データの作成および教師用データの作成を行うシステムである LINE アプリケーションとして自作デバイスの LINE Bot を開発した。これを用いて任意の教師用データの作成および状態のコーピングを行う。



図 4.2: LINE Bot のテキスト入出力画面

図 4.2 に LINE Bot のシステム詳細を示す。LINE Bot は自作デバイスを用いて行動識別およびコーピングを行うためのアプリケーションである。このアプリケーションでできることは、行動データの登録、解析結果の応答、行動登録データの履歴確認、行動登録データの削除である。(a) 行動データの登録は図 4.1 における機械学習の教師用データの設定を指す。機械学習を行う際に用いる教師用データは、はじめは存在しない状態なのでまずは教師用データを作成しなければならない。登録方法は図にある通り、エッジトリガを「アレクサ」とし、「登録、(行動名)」とすれば行動状態の学習が始まる。図は改行で入力しているが、句読点でも認識される。「登録」だけでなく「記録」や「学習」でも同様に行動学習を行える。このときサーバではニューラルネットワークにより機械学習を行い学習モデルを生成する。最後に「アレクサ、終わり」と送信すれば登録が終わる。登録の終わらせ方は「終了」や「おしまい」でも可能である。(b) 解析結果の応答は図 4.1 におけるコーピング結果のテキスト出力を示す。サーバに蓄積された 46 種類のデータの 1 分間分である 27600 個をニューラルネットワークで解析し、予測された行動状態およびコーピングテキストを指す。図 4.2 にあるように、「アレクサ、結果」と入力するとコーピングテキストが応答される。このコーピングに関するアルゴリズムは後述に解説する。(c) 行動登録データの履歴確認は、現在何の行動を登録したかを見るための機能で、「アレクサ、登録データ」と入力すると履歴が出力される。上記の行動登録の際に入力ミスをしてしまうことがあると想定した。その際に、やり直しができるように (d) 行動登録データの削除機能を導入した。「アレクサ、削除、(行動名)」と入力すれば指定した行動を削除できる。また、「アレクサ、リセット」と入力するとこれまでに登録したすべてのデータを削除でき、新しく行動登録を始められる。他にも取扱説明書の提示や簡単な会話を可能にした。本研究で用いるこの LINE Bot は有料コンテンツを一切含まないので安全に利用できる。

表 4.1: 標準偏差による注意度の分割とコーピングテキスト

小 —————— (S_A の大きさ) —————— 大			
注意	やや注意	やや安定	安定
「疲れていませんか？時には休息も必要です。」	「行動が安定していません。一息ついてはいかがですか？」	「少し行動が不安定です。注意しましょう。」	「いい調子です。そのまま頑張りましょう。」
「作業お疲れ様です。少し休んではいかがですか？」	「歩きにくくはありませんか？足元に注意して作業を行ってください。」	「少し行動にばらつきがあります。」	「安定しています。作業を続けましょう。」
「休憩を入れましょう。好きな音楽を聴いたり温かい飲み物を飲むとリフレッシュできますよ。」	「行動が不安定になってきました。もし疲れていたら休みましょう。」	「足元に注意して作業を行ってください。」	「安心してください。安定していますよ。」
「お疲れ様です。ほっとする時間を持ってはいかがですか？」	「行動が不安定です。休憩してから作業を再開してはいかがですか？」	「焦らずゆっくり1つずつ作業を進めましょう」	「がんばっていますね。その調子です。」

最後にコーピングを行うアルゴリズムについて記述する。本研究では以上から算出された各行動の確率の標準偏差を算出し、その結果からコーピングを行う。

算出した行動確率のデータ群を $\mathbf{A} = A_1, A_2, A_3, \dots, A_n$ とする。この n はデータ軍の個数を表し、同時にシステムに登録した学習データの個数を意味する。このとき \mathbf{A} の分散 S^2_A は、 $\sum_{k=1}^n A_k = 100$ から平均値は $\bar{A} = \frac{100}{n}$ とわかるので

$$S^2_A = \bar{A}^2 - (\bar{A})^2 = \frac{1}{n} \sum_{k=1}^n (A_k)^2 - \left(\frac{100}{n} \right)^2 \quad (4.25)$$

と書ける。ここで2通りの場合分けを行う。まず、 \mathbf{A} がすべて同じ値の場合、 $S^2_A = 0$ となり分散は最小値となる。次に \mathbf{A} のうち1つが 100 で残りは 0 のとき、式 4.25 より

$$\begin{aligned} S^2_A &= \frac{1}{n} \sum_{k=1}^n (A_k)^2 - \left(\frac{100}{n} \right)^2 \\ &= \frac{(100)^2}{n} - \left(\frac{100}{n} \right)^2 = \left(\frac{100}{n} \right)^2 (n - 1) \end{aligned}$$

となり分散は最大値となる。すなわち標準偏差 S_A は

$$0 \leq S_A \leq \frac{100}{n} \sqrt{n - 1} \quad (4.26)$$

の範囲で値をとることがわかる。本研究における分散および標準偏差の値変動は、利用者の行動の安定度を測定している。この値が小さいほどデータ軍はばらついていないことを示し、値が大きいほどデータ軍はばらついており、1つの行動を安定して行えていることを示す。表 4.1 より標準偏差の値範囲を 4 分割し注意度別にテキストを出力する。

実験結果ならびに考察

§ 5.1 実験概要および結果

§ 5.2 考察

おわりに

謝辞

本研究を遂行するにあたり、多大なご指導と終始懇切丁寧なご鞭撻を賜った富山県立大学電子・情報工学科情報基盤工学講座のAntònio Oliveira Nzinga Renè講師、奥原浩之教授に深甚な謝意を表します。また、共同研究でお世話になりました富山県立大学電子・情報工学科4年生の北田真悟氏、数値実験やシステム開発でご協力いただいた富山県立大学情報システム工学科3年生の八十住捺輝氏に感謝の意を表します。最後になりましたが、多大な協力を頂いた、研究室の同輩諸氏に感謝致します。

2023年2月

大森 一輝

参考文献

- [1] “医療法人社団 平成医会 「歩くことで得られる心身の健康」”, <https://heisei-ikai.or.jp/column/walking/>, 閲覧日 2022, 9, 15
- [2] “今井整形外科医院 講演 「老化は足から、予防して元気で長生きの秘」”, <https://imaiseikei.net/>, 閲覧日 2022, 9, 15
- [3] “ミライロ通信 「ユニバーサルデザインとは? ~7原則と実現のヒント~」”, <https://www.mirairo.co.jp/blog/post-2021011502>, 閲覧日 2022, 9, 16
- [4] “タッチエンス株式会社”, <http://touchence.jp/>, 閲覧日 2022, 9, 14
- [5] 清水 豪士, “運動学習におけるインピーダンスの習熟と内部モデルの信頼度”, 富山県立大学学位論文, 2021
- [6] 辻 敏夫, 西田 正孝, 伊藤 宏司, “ニューラルネットによるインピーダンスパラメータの繰返し学習”, 計測自動制御学会論文集, Vol. 28, No. 12, pp. 1461-1468, 1992.
- [7] 阪口 豊, “内部モデルの信頼度に基づく運動計画のアルゴリズム”, 電子情報通信学会論文誌, Vol. J79-D-II, No. 2, pp. 248-256, 1996.
- [8] 中井 亮仁, 永野 顕法, 高橋 英俊, 松本 潔, 下山 真, “インソールに配置したMEMS3軸力センサによる足裏応力分布計測”, No. 13-2, Proceedings of the 2013 JSME Conference on Robotics and Mechatronics
- [9] 中井 亮仁, 森下 康彦, 下山 真, “MEMS3軸力センサを用いた傾斜路歩行時の足裏応力分布計測”, 日本機械学会, No. 14-40, シンポジウム : スポーツ・アンド・ヒューマン・ダイナミクス 2014
- [10] 中井 亮仁, 永野 顕法, 高橋 英俊, 松本 潔, 下山 真, “MEMS3軸力センサを用いた階段昇降時の足裏応力分布計測”, 日本機械学会, No. 13-34, シンポジウム : スポーツ・アンド・ヒューマン・ダイナミクス 2013
- [11] タッチエンス株式会社 ショッカクシューズ取扱説明書
- [12] “インターリンク エレクトロニクス”, <https://www.parashoe.co.jp/shoes/ashi-kokkaku>, 閲覧日 2023, 1, 12
- [13] “Arduino, Bluetooth, MATLAB を使って足裏荷重センシング”, <https://qiita.com/ketaro-m/items/f6d6eb8175f1c845839e>, 閲覧日 2023, 1, 18
- [14] “足の骨格を知ろう（足の骨格、骨の名称、関節、アーチなど）”, <https://www.takachiho-kk.co.jp/prod/semicon/interlink/>, 閲覧日 2023, 1, 13
- [15] “就労継続支援 B型とは？B型事業所や仕事内容・工賃（給料）についても解説”, <https://works.litalico.jp/column/system/021/>, 閲覧日 2023, 1, 18

- [16] 上西一貴, 望月隆之 “障害のある人のICT活用に伴う困難さ 就労継続支援B型事業所における全国調査の自由記述の分析”, 東洋大学 福祉社会開発研究 12号 2020
- [17] “拡張カルマンフィルタで6軸IMUの姿勢状態推定”,
<https://qiita.com/yakiimo121/items/97f3c174e0d0db74535a>, 閲覧日 2023, 1, 19