

相互制約付き動的計画法による歩行位相分割と足跡検出

安川 洵¹ 楨原 靖¹ 細井 利憲² 久保 雅洋² 八木 康史¹

概要：歩容解析において重要な歩行位相分割と足跡検出の双方を、健常歩行時だけでなく病的歩行時でも頑健に処理できる手法を提案する。歩容解析における歩行位相分割処理は、時間的特徴を抽出する上で非常に重要である。我々は位相分割手法の一つである動的計画法を用いた区分線形近似手法を改良し、歩行周期中に特有な両脚支持期を考慮した、左右足の状態について相互制約を持った歩行位相分割アルゴリズムを考案した。さらにその結果と RGBD 画像から求めた 3D のエッジ点群系列から、つま先部分に対応する点群を床平面上に投票することで足跡を検出し、楕円当てはめにより空間的な歩容特徴を抽出した。本研究では、健常歩行と疑似片麻痺歩行を解析し、提案手法を用いて求めた歩容特徴（単脚支持時間、両脚支持時間、つま先角、ステップ長）と、RGB 画像から手動で求めた各特徴の真値と比較した。その結果、歩き方の違いによる歩容特徴推定精度に大きな差はなく、片麻痺を模した歩容に対する頑健性を示すことができた。またつま先角のように従来手法では推定が難しかった特徴量についても、提案手法により推定が可能となった。

キーワード：歩容解析, 歩行位相分割, 足跡検出, リハビリテーション

1. はじめに

ヒトの動作計測および解析は運動力学やバイオメカニクス、監視、ヒューマンコンピュータインターフェース、ビデオゲームなどの様々な分野で応用されている。高精度なヒトの3次元動作計測・解析において最も一般的なのは、マーカやセンサなどを身体の各部に装着して計測する方法である。ただし、これらの方法は侵襲的であり、被験者の動きを妨げ、準備に時間を要するという問題がある。このような問題は、画像データを用いた人の運動や姿勢を推定する技術を用いることで解決することができる。しかしながら、要求される姿勢パラメータの詳細および推定精度は、アプリケーションごとに異なる。サーベイランスへの応用ではよく、一台のカメラ情報から被験者の位置や人物姿勢の近似推定する技術などが必要とされる。ただししばしば低解像度画像が用いられ、高精度な姿勢推定までは要求されないことが多い。一方で、バイオメカニクス分野では、複数台カメラより得られた画像情報から、様々な関節角度や、身体部位の位置情報などの高精度な推定技術が必要とされる。また、近年はRGBDカメラの普及もすすみ、1台のカメラで三次元的な動作解析を行う技術の研究が進めら

れている。数あるヒト動作の中でも、歩行動作の詳細な解析は、最も関心の高いテーマの一つである。健常歩行だけでなく病的歩行なども対象とすることで、被験者の健康状態や、疾患の症状の進行あるいは回復の程度などの推定に役立てることができる。

歩行パラメータの種類は、大きく次の2つに分類できる。一つ目が空間的パラメータ（例えばステップ長、ストライド長、足の接地角度など）であり、推定するためには歩行中に足を着いた位置・向きに関する情報が必要となる。足の位置・向き情報を推定する手法として、歩行画像列から検出されるコーナー点 [1] やシルエット [2] の累積画像から抽出した足跡を利用する手法がある。ただしこれらの手法では、足の接地時間以外の情報も累積され、足跡の形状にもノイズが多く含んでしまうため、精細な形状の足跡を検出する上で問題が残る。

二つ目に時間的パラメータ（単脚立脚相、両脚支持相など）がある。このパラメータの計算には、歩行イベントのタイミングの情報が必須である。例えば左右膝関節間の距離 [3] や床平面に投影した足部点群の形状 [4]、シルエット画像のバウンディングボックスの横幅 [5] などの時間的な変化の周期性から歩行周期の抽出を行うものが挙げられる。ただしこれらの手法ではヒールストライクしか推定できず、足の接地時間や遊脚時間を厳密に切り分けることはできない。そのため精細な形状の足跡検出という課題の解

¹ 大阪大学
Osaka University
² 日本電気株式会社
NEC Corporation

決するためには、相分割の粒度が不十分である。このような課題を解決するためには、ヒールストライクおよびトゥオフを検出し、歩行の相を少なくとも左右の単脚支持相と両脚支持相に分割する必要がある。Limら [6] は、つま先位置の高さの変化に閾値を設けることで、立脚相と遊脚相の分割を行っているが、対象者が程度左右対称に、左右同じリズムで歩けることを想定しているため、片足を引きずったり、途中で足が出せなくなるなどの病的な歩行への応用が難しい。

そこで本研究では、左右の足部位置データに対して動的計画法による区分線形近似手法を用いて時間セグメンテーションを行うことで、これらの問題を解決する。時間セグメンテーションは一般的に統計や信号処理、機械学習、ロボティクス、動作認識などの様々な分野において応用されている。時間セグメンテーションといっても、様々なアルゴリズムが存在する。中でも動的計画法を用いた区分線形近似手法 [7-9] は、古くから曲線 [10,11] や波形 [12]、多角形 [13] の近似などに用いられたいたアルゴリズムを応用したものであり、そのアルゴリズムの単純さから広く用いられている。

先行研究では、一次元のデータ系列に対してこのアルゴリズムを適用することで、次元削減や区間分割をすることに成功している。しかし歩行位相分割を想定した場合、区分線形近似手法を左右それぞれの足部位置系列データに対して適用すると、相互の歩行周期中の状態を考慮できない。そのため両脚支持相が存在しない、両脚とも中に浮いている時間が存在するなど、現実的には起こりえない状態を推定してしまう恐れがある。そこで我々は、歩行中の左右足の状態について制約条件を加えた上で、両足部の系列データに対して同時に動的計画法による区分線形近似手法適用し、歩行位相分割を行う手法を提案する。

2. 関連研究

2.1 足跡検出手法について

足跡は、移動中の人物のステップ長やストライド、移動軌跡などを推定する上で有用な情報であり、主にサーベイランスの分野で検出手法が提案されている。

足跡を検出する手法の一つとして、歩行画像系列における各画素の時間的な累積度合いを利用する方法がある。この手法では、歩行中に足部が地面に着いている領域が最も累積度が高くなる特性を利用しており、Bouchrikaらは検出したコーナー点 [1] を、Jungらはシルエット画像 [2] の累積を計算することで、それぞれ歩行中の足跡を検出している。ただしこれらの手法では、2次元画像上での足の接地位置や接地回数などは分かるが、実空間上でのそれらを推定することはできない。また歩行画像系列の立脚期以外のフレームも扱うため足跡にノイズが含まれてしまう。

Evansら [14] は、歩行ではなく走行を対象にしているも

の、複数カメラを用いることで実空間における床平面上に累積する足跡を検出している。各視点におけるシルエットを計算し、より多くの視点に写っている画素を複数カメラのキャリブレーションにより求めた床平面に投票し、その時間的な累積を計算することで足跡を検出している。このとき累積度に対して実験的に閾値を設定し、遊脚期中のフレームを除外することで、前述の手法よりもより精細なフットプリンを抽出することができている。さらに足跡から各足の接地位置を推定し、ステップ長を算出している。この手法では走行を対象にしているため、累積度に対して閾値を設けることである程度妥当な立脚期と遊脚期を鑑別を行うことができている。しかし地面に足を引きずりながら振り出すような病的な歩行などを対象とする場合、単純な応用は難しくなることが予想される。


2.2 時間セグメンテーション手法について

歩行周期は、研究目的に応じて様々な粒度に分割される。立脚相と遊脚相を含む2相に分かれるモデルが最も一般的であり、[15,16] 他にも3相 [17]、6相 [18] またはそれ以上 [19] に分割されることがある。一般的には、より多くの相に分割するほど、詳細な歩容解析を行うことができる。粒度の高い位相分割を行う場合、慣性センサなどのウェアラブルセンサが使われることが多い [20,21]。さらに地面との接地状況を直接的に検知することができるフットスイッチ、足圧センサなどの併用することもあり [22,23]、より装着物が多く、対象者の動きを阻害することになるため、臨床現場などのより実践的な場面での応用が難しくなる。

時系列信号を用いて歩行周期を分割する研究は古くから行われており、単純な閾値設定ベースによる手法が、最も一般的に使われてきた [24-26]。しかしこの手法は、様々な対象者に対して一貫した閾値を設定することが難しく、多様性のある病的な歩容の解析には、適用が難しい。

閾値ベースとは別の手法として機械学習ベースの手法があり、時系列データを用いた動作認識の分野に広く用いられている。大きく分けて教師あり学習と教師なし学習であり、前者にはK-nearest neighbor (K-NN) 法 [27] やナイーブベイズ分類 [28]、サポートベクターマシン (SVM) [29] などがある。後者には混合ガウスモデル (GMM) [30] や隠れマルコフモデル (HMM) [31,32]、あるいは両者を併せた手法 [33] などがある。

歩行周期の分割についても、動作認識分野と同様に様々な機械学習ベースでの手法が提案されており、教師あり学習手法であるSVMを用いた研究 [34] では、床反力データから歩行周期を5相に分割している。多層ニューラルネットワークを用いた研究 [35] では、踵とつま先に貼付したマーカの3D位置情報から、2相に分割している。Louら [36] は、脳卒中片麻痺患者を対象として、2次判別分析を用いた解析を行っている。しかし教師あり学習では、必



(a) 上方視点の図

(b) 側方視点の図

図. 1 実験環境

ず教師ラベル付けが必要となるため、解析処理において非常に手間がかかってしまうという問題がある。一方、ラベルを必要としない教師なし学習を用いた手法では、その問題点は解消できる。時系列信号処理で一般的に知られるHMMを使った研究が多く、[37,38]では、足部に装着したジャイロセンサの信号を入力として、歩行周期を4相に分割する手法を提案している。また[39]では、足底に装着した圧センサから得た床反力データを使い、歩行周期を6相に分割している。その他には、ニューラルネットワークとHMMを組み合わせた手法[40]や、k-meansクラスタリングアルゴリズムを使った手法[41]なども提案されている。これまでに紹介した手法は、いずれも片足に装着したセンサの信号を入力として歩行周期の分割を行っている。しかし前章ですでに述べたように、歩行には両脚支持相が存在し、走行のような両脚が浮いた状態は存在しないため、両足の状態を考慮しつつ相判別をする必要がある。健常者の歩行を想定した場合は、ほとんどが左右対称で周期的であるため、片足分の信号から相分割をしても大きな問題が生じないかもしれない。しかし病的歩行のように非対称的あるいは非律動的な歩容では、片足の情報のみで位相分割するのは適切ではない。Attalら[42]は、歩行中の両足の状態を考慮し、歩行周期を分割する手法を提案している。彼らの研究では多次元回帰HMMを提案し、左右の足圧センサから取得した鉛直方向の床反力データを入力として、歩行周期を6相に分割している。歩行イベントの推定精度は83%であり、そのほかの教師なし学習を用いた場合の精度よりも高い結果を残している。しかしこれらの学習ベースの手法は、推定精度が学習データに依存する。そのため病的歩行のような多様性の高いデータに対して適用したい場合、そもそも健常者よりも絶対的なデータ数を集めることが難しく、歩容のバリエーションごとにデータの均質性を保つことが大きな課題となる。例えばLouら[36]の研究では脳卒中片麻痺患者を対象としているが、被験者数が5名のみと非常に少なく、十分な学習データを確保できているとは言えない。

一方で、我々が提案する動的計画法を用いた区分線形近似による時間セグメンテーションでは、学習データを必要としないため、疾患の種類や重症度の影響で多様に変化する病的歩容の解析に適している。区分線形近似手法を用い

表. 1 状態の定義

状態	右足	左足
s_1	遊脚期	単脚支持期
s_2	両脚支持期 (右足前)	両脚支持期 (左足後ろ)
s_3	単脚支持期	遊脚期
s_4	両脚支持期 (右足後ろ)	両脚支持期 (左足前)

て時系列データの次元削減や区間分割を行った研究は数多く存在するが、我々の提案手法のように二次元の信号に対して同時に区分線形近似を行うアルゴリズムは見当たらない。

本論文では、続く3章で処理全体の概要、提案手法のアルゴリズム、歩容特徴の抽出に関する処理の詳細について説明する。さらに4章では実際の歩行データに提案手法を適用し、その結果を用いて推定した歩容特徴の精度について報告する。5章で研究の総括を述べる。

3. 方法

3.1 動的計画法を用いた区分線形近似による歩行位相分割

提案手法では、左右それぞれ T フレームある足部の奥行位置系列 $\mathbf{P}_{(\text{foot})}^{\text{foot_CoG}} = \{p_1, p_2, \dots, p_T\}$ を入力データとして使用する。ここで $\text{foot} \in (\text{right}, \text{left})$ は右もしくは左足のいずれかを示す。歩行周期を S 個の状態の循環的な遷移であると仮定すると、動的計画法は左右の足部位置系列と状態数の3次元空間で計算することができる。本研究では、表. 1のように歩行周期を四つの状態に分割する。ここで遊脚期は s_1 (または s_3) のように一つの状態で完結するのに対し、立脚期は s_2 から s_4 (または s_4 から s_2) のように三つの状態に跨って継続する。

はじめに、入力データ $\mathbf{P}_{(\text{foot},t)}^{\text{foot_CoG}}$ を以下のように定義される。

$$\mathbf{P}_{(\text{foot},t)}^{\text{foot_CoG}} = \frac{1}{N^{\text{cloud}}} \sum_{n=1}^{N^{\text{cloud}}} P_{(\text{foot},t,n)}^z \quad (1)$$

このとき、 $P_{(\text{foot},t,n)}^z$ は t 番目のフレームにおける、足部領域内の n 個目の3次元点群の奥行座標を表す。足部領域は人物の身長の下端10%とする。 N^{cloud} は足部領域点群の点数である。

さて、状態空間における区分線形近似コストの最小化問題を、以下の再帰式を用いた動的計画法によって解く。




図. 2 処理結果：成功例




図. 3 処理結果：失敗例

$$A(t, s) = \arg \min_{t^{\text{start}} \leq j \leq t^{\text{end}}} \sum_{\text{foot}} \{D(\text{foot}, j, \text{prev}(s)) + F(\text{foot}, t, s)\} \quad (2)$$

$$D(\text{foot}, t, s) = \min_{t^{\text{start}} \leq j \leq t^{\text{end}}} (D(\text{foot}, A(t, s), \text{prev}(s)) + F(\text{foot}, A(t, s), s)) \quad (3)$$

ここで $A(t, s)$ は、フレーム t 、状態 s における各足において計算された線分の始点を示す。また $D(\text{foot}, t, s)$ は、その状態までに線分当てはめにかかる最小コストである。線分近似において、遊脚期では足部が後進しないと仮定し、負となる線分を用いる。立脚期では足部位置が動かないと仮定し、 y 切片が近似区間内のデータの平均値、傾きがゼロの線分を当てはめる。prev は入力に対して、その一つ前の状態を返す関数である。 t^{start} と t^{end} は、線分の視点を探索する範囲であり、以下のように決まる。

$$t^{\text{start}} = \begin{cases} 0 & \text{if } (t < l^{\text{min}}) \\ t - l^{\text{min}} & \text{else} \end{cases} \quad (4)$$

$$t^{\text{end}} = \begin{cases} T & \text{if } (t > T - l^{\text{min}}) \\ t & \text{else} \end{cases} \quad (5)$$

ここで l^{min} は線分の最短長を決定するハイパーパラメータである。系列データの始端または終端の状態を推定する際にも線分の長さが l^{min} を満足するように、 t^{start} および t^{end} を計算する。 $F(\text{foot}, j, t, s)$ は、現在の状態で計算している線分当てはめコストを表しており、

$$F(\text{foot}, j, t, s) = -e^2(P_{A'(\text{foot}, j, \text{prev}(s))}, P_j) + e^2(P_{A'(\text{foot}, j, \text{prev}(s))}, P_t) \quad (6)$$

のように定義される。 e^2 は線分の始点から終点までのデータに対する、線分当てはめの二乗誤差の総和を返す関数である。 $A'(\text{foot}, t, s)$ は、現在の状態 s の一つ前の状態において当てはめられた線分の始点のフレーム番号であり、以下のように表す。

$$A'(\text{foot}, t, s) = \begin{cases} A'(\text{foot}, A(t, s), \text{prev}(s)) & \text{if } (\text{isContinue}_{(\text{foot})}) \\ t & \text{else} \end{cases} \quad (7)$$

これはフラグ $\text{isContinue}_{(\text{foot})} \in (\text{true}, \text{false})$ に従って更新される。 $\text{isContinue}_{(\text{foot})}$ は、左右それぞれの系列について、一つ前の状態から同じ線分が継続するとしてコスト計算を行うか否かを決定するフラグである。

3.2 足跡検出

まず T フレームの RGB 画像系列からエッジ画像系列 I^{edge} を求める。次に距離画像から復元した 3 次元点群のうち、床平面から $\pm 3\text{cm}$ の高さよりも低い位置に存在する点群系列 P を定義する。さらに各フレームについて、 $I_{(t)}^{\text{edge}}$ と対応のある $P_{(t)}$ を床平面へ投票した画像 $I_{(t)}^{\text{floor}}$ とし、各画像への投票を以下のように定義する。

$$I_{(t, p_{(t,k)}^x, p_{(t,k)}^z)}^{\text{floor}} = \sum_{k=1}^K I_{(t,k)}^{\text{edge}} \quad (8)$$

ここで床平面画像上のスケールは、 $1\text{pixel} = 1\text{cm}$ とする。 k は各点の番号、 p^x と p^z は、それぞれ点の左右座標と奥行座標を表す。そして $I_{(t)}^{\text{floor}}$ は、両足の点群の重心座標を基準に、左右のつま先エッジ系列 $I_{(\text{foot}, t)}^{\text{toe-edge}}$ に分割される。足

表. 2 各被験者および全体における歩容特徴の平均絶対誤差と標準偏差

被験者		健常歩行												疑似片麻痺歩行											
		単脚立脚時間 (s)			両脚立脚時間 (s)			つま先角 (deg)			ステップ長 (m)			単脚立脚時間 (s)			両脚立脚時間 (s)			つま先角 (deg)			ステップ長 (m)		
		右	左	両側	右	左	両側	右	左	両側	右	左	両側	右	左	両側	右	左	両側	右	左	両側	右	左	両側
1	平均	0.07	0.04	0.05	0.04	0.04	0.04	6.5	11.7	9.1	0.02	0.01	0.01	0.04	0.04	0.04	0.02	0.03	0.03	5.0	2.3	3.6	0.02	0.03	0.02
	標準偏差	0.08	0.01	0.05	0.03	0.02	0.03	2.7	0.9	1.8	0.01	0.01	0.01	0.02	0.02	0.02	0.01	0.03	0.02	3.7	1.9	2.8	0.01	0.01	0.01
2	平均	0.03	0.04	0.03	0.03	0.03	0.03	5.5	8.8	7.1	0.03	0.02	0.02	0.02	0.03	0.03	0.02	0.03	0.03	4.6	3.0	3.8	0.02	0.02	0.02
	標準偏差	0.01	0.02	0.02	0.03	0.01	0.02	3.5	3.9	3.7	0.01	0.01	0.01	0.02	0.02	0.02	0.02	0.02	0.02	4.1	1.2	2.6	0.01	0.01	0.01
3	平均	0.12	0.03	0.08	0.06	0.07	0.06	4.0	6.0	5.0	0.03	0.02	0.02	0.07	0.03	0.05	0.03	0.06	0.04	6.3	3.3	4.8	0.01	0.01	0.01
	標準偏差	0.08	0.03	0.05	0.03	0.08	0.05	2.5	5.2	3.9	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.02	2.2	1.7	1.9	0.01	0.01	0.01
4	平均	0.09	0.05	0.07	0.04	0.03	0.03	5.0	3.0	4.0	0.14	0.07	0.11	0.23	0.06	0.14	0.08	0.12	0.10	4.4	2.8	3.6	0.04	0.04	0.04
	標準偏差	0.07	0.06	0.06	0.02	0.01	0.02	1.5	1.6	1.6	0.18	0.08	0.13	0.05	0.04	0.05	0.06	0.09	0.07	3.4	2.0	2.7	0.01	0.02	0.02
5	平均	0.05	0.04	0.05	0.03	0.03	0.03	2.0	3.5	2.8	0.02	0.00	0.01	0.08	0.04	0.06	0.04	0.04	0.04	6.4	2.8	4.6	0.01	0.02	0.02
	標準偏差	0.03	0.03	0.03	0.01	0.02	0.02	2.0	0.9	1.4	0.01	0.00	0.00	0.03	0.03	0.03	0.01	0.02	0.02	3.5	2.5	3.0	0.01	0.01	0.01
6	平均	0.05	0.08	0.06	0.02	0.03	0.02	5.3	6.5	5.9	0.02	0.02	0.02	0.05	0.04	0.04	0.01	0.02	0.02	2.5	4.0	3.3	0.04	0.04	0.04
	標準偏差	0.03	0.08	0.05	0.01	0.02	0.01	1.6	0.5	1.1	0.01	0.01	0.01	0.10	0.02	0.02	0.01	0.01	0.01	1.3	3.9	2.6	0.01	0.01	0.01
7	平均	0.07	0.06	0.06	0.03	0.04	0.04	4.5	1.0	2.8	-	0.02	0.02	0.10	0.06	0.08	0.03	0.04	0.04	9.8	5.0	7.4	0.03	0.04	0.04
	標準偏差	0.03	0.03	0.03	0.02	0.01	1.5	1.0	1.3	-	0.00	0.00	0.02	0.02	0.03	0.02	0.02	0.02	0.02	8.4	3.4	5.9	0.01	0.01	0.01
8	平均	0.03	0.04	0.04	0.05	0.04	0.04	4.0	4.0	4.0	0.01	0.02	0.02	0.03	0.03	0.03	0.03	0.04	0.03	7.3	3.9	5.6	0.01	0.03	0.02
	標準偏差	0.01	0.04	0.02	0.02	0.01	0.01	2.7	0.8	1.8	0.00	0.01	0.01	0.03	0.03	0.03	0.03	0.02	0.02	5.1	3.9	4.5	0.03	0.02	0.02
9	平均	0.04	0.02	0.03	0.03	0.03	0.03	2.7	3.7	3.2	0.01	0.01	0.01	0.04	0.02	0.03	0.02	0.04	0.03	6.3	3.3	4.8	0.03	0.01	0.02
	標準偏差	0.02	0.01	0.02	0.02	0.01	0.01	1.2	3.3	2.3	0.01	0.01	0.01	0.02	0.01	0.01	0.01	0.02	0.01	5.1	1.7	3.4	0.02	0.01	0.01
10	平均	0.03	0.09	0.06	0.03	0.04	0.04	5.0	5.3	5.1	0.02	0.02	0.02	0.13	0.12	0.12	0.09	0.09	0.09	5.3	3.0	4.1	0.02	0.02	0.02
	標準偏差	0.01	0.15	0.08	0.02	0.03	0.03	1.2	2.3	1.8	0.01	0.01	0.01	0.07	0.09	0.08	0.04	0.07	0.06	3.4	2.4	2.9	0.01	0.02	0.01
全体	平均	0.06	0.05	0.05	0.04	0.04	0.04	4.6	5.5	5.0	0.04	0.02	0.03	0.08	0.05	0.07	0.04	0.05	0.05	5.7	3.3	4.5	0.03	0.03	0.03
	標準偏差	0.05	0.07	0.06	0.03	0.04	0.03	2.4	3.9	3.2	0.08	0.04	0.06	0.08	0.05	0.06	0.04	0.05	0.05	4.7	2.7	3.7	0.02	0.02	0.02

跡 $I_{(foot, c_{foot})}^{fp}$ は、位相分割により求めた各足について C_{foot} 回の単脚支持期 (s_1, s_3) を用い、

$$I_{(foot, c_{foot})}^{fp} = \begin{cases} \sum_{t \in s_1} I_{(left, t)}^{toe_edge} & \text{if(foot = left)} \\ \sum_{t \in s_3} I_{(right, t)}^{toe_edge} & \text{else} \end{cases} \quad (9)$$

のようにして抽出することができる。次に $I_{(foot, c_{foot})}^{fp}$ の重心から 30pixels 四方を切り出し、次式に基づいて投票数の正規化を行う。

$$H_{(foot, c_{foot})}^{clip_fp} = -\exp(-m I_{(foot, c_{foot})}^{fp}) + 1 \quad (10)$$

ここで m は投票数の上限を決定する正の定数である。つぎに足跡内で投票数の局所的な集中を回避するために、各画素 (i, j) に対して、以下のように関数 G を用いて距離によって重みづけされた画像 $H_{(foot, c_{foot})}^{trans_fp}$ を生成する。

$$H_{(foot, c_{foot}), (i, j)}^{trans_fp} = G(H_{(foot, c_{foot}), (i, j)}^{clip_fp}) \quad (11)$$

$$G(H_{(foot, c_{foot}), (i, j)}^{clip_fp}) = \max_{(i, j) \text{ neighbor}(p, q)} (-H_{(foot, c_{foot}), (i, j)}^{clip_fp} \exp(-od((i, j), (p, q)))) \quad (12)$$

関数 d は、以下のように 2 画素間のユークリッド距離を返す関数である。

$$d((i, j), (p, q)) = \sqrt{(i-p)^2 + (j-q)^2} \quad (13)$$

ここで o は重みづけを調整する正の定数である。

3.3 足跡に対する楕円モデル当てはめ

楕円モデル $M(\phi)$ を各足跡 $H_{(foot, c_{foot}), (i, j)}^{trans_fp}$ に当てはめることで、足の位置・姿勢の推定を行う。楕円モデルは五つのパラメータ $\phi = \mathbf{r}, \mathbf{c}, \theta$ で、次式のように表される。

$$M(\phi) = \left\{ \frac{(x - c_x) \cos \theta + (y - c_z) \sin \theta}{r_l} \right\}^2 + \left\{ \frac{(x - c_x) \sin \theta - (y - c_z) \cos \theta}{r_s} \right\}^2 = 1 \quad (14)$$

ここで $\mathbf{r}(r_l, r_s)$ は半長軸および半短軸を、 $\mathbf{c}(c_x, c_z)$ は楕円中心、 θ 楕円の傾きを表す。 $M(\phi)$ は楕円の輪郭を表す離散的な点集合である。次に以下の式を用い、 $I_{(foot, c_{foot})}^{trans_fp}$ に対して、楕円モデルが最も当てはまりの良いときのパラメータ $\hat{\phi}$ を計算する。

$$\hat{\phi} = \arg \max_{\phi} \sum_{(i, j) \in M(\phi)} I_{(foot, c_{foot}), (i, j)}^{trans_fp} \quad (15)$$

尚、つま先角は正面を 0 度とし、体に対して外向きが正、内向きを負とした

4. 実験

本研究では、提案手法を用いて以下の歩容特徴を算出し、その推定精度を検証した。

- (1) 単脚支持時間 (s)
位相分割により求めた状態 s_1 または s_3 の時間
- (2) 両脚支持時間 (s)
位相分割により求めた状態 s_2 または s_4 の時間
- (3) つま先角 (deg)
楕円当てはめにより求めた楕円の傾き角度
- (4) ステップ長 (m)
時間的に隣接する左右の楕円モデルの前端間の距離

実験では 6m の直線歩行路に対し、RGBD カメラ (Microsoft Kinect v2) 1 台、レンズ (SPACECOM 3.5mm) を接続した USB カメラ (PointGrey Flea3 FL3-U3-13E4C) 3 台を図. 1 のように設置した。Kinect は RGB 画像 (1920x1080 ピクセル) と距離画像 (512x424 ピクセル) を 30fps で、また USB カメラは RGB 画像 (1280x1024 ピクセル) を 60fps で取得した。

1 台は側方から歩行を撮影し、ヒールストライクおよびトゥオフのタイミングを手動で検出することで、単脚支持時間および両脚支持時間の真値を求めた。天井に設置され




図. 4 真値に対する符号付き誤差 (健常歩行)




図. 5 真値に対する符号付き誤差 (疑似片麻痺歩行)

た2台のカメラから得られた画像には、床面に張られたマーカを基準としてホモグラフィ変換を行い、手で足部への楕円当てはめを行うことでつま先角およびステップ長の真値を得た。被験者は、健常歩行と疑似右片麻痺患者の全2種類、各2回の計測を行った。疑似片麻痺歩行では、遊脚でのつま先の引きずり、つま先の外向き接地、右単脚支持時間の短縮を再現して試行を実施した。尚、片麻痺歩行においては、両脚支持時間や単脚支持時間が左右非対称になり、機能回復に応じて対称性が改善することが一般的に知られている。実験では被験者10名(男性8名)について、全特徴の真値に対する推定値の絶対誤差の平均値を、各足について計算した。

4.1 歩行位相分割と足跡検出

提案手法による歩行位相分割結果とそれに基づいて生成された、足跡と楕円モデルの当てはめ結果の成功例(図. 2)と失敗例(図. 3)をに示す。左右の足部位置系列に対して直線近似が行われ、単脚支持期(反対側の遊脚期)、両脚支持期の位相分割できたことが図. 2(a)からわかる。位相分割が適切に行われた場合、尤もらしい足跡検出および楕円モデルの当てはめがなされていることがわかる(図. 3(b), 図. 3(c))。一方で足部の重心位置系列が乱れている被験者においては、尤もらしい直線近似が行われていない図. 3(a)。それに伴い足跡検出、モデル当てはめにも影響をしていることが失敗例(図. 3(b), 図. 3(c))。

4.2 歩容特徴

各被験者および被験者全体における四つの歩容特徴の絶対推定誤差の平均値と標準偏差を表. 2に示す。

単脚支持時間の推定誤差は、健常歩行で $0.06 \pm 0.06s$ 、疑似片麻痺歩行で $0.07 \pm 0.07s$ となった。被験者3, 4などの健常歩行データで誤差が大きくなっているのは、図. 3(a)

のような足部位置系列の乱れによるセグメンテーション誤差の影響である。また疑似片麻痺歩行では全体的に右足データ(図. 2(a))において、推定値が真値よりも長く推定される傾向が見られ、特に被験者4, 7, 10で顕著であった。これは左側の実際の遊脚時間が最短線分長 l^{min} よりも短かった、つまり右単脚支持時間が短かったことで、真値よりも大きく推定されたことが原因と考えられる。また他の要因として、つま先の引きずりで足部位置の変化が緩やかになったことで、立脚期と遊脚期の判別の基準がより複雑化していることが挙げられた。

両脚支持時間では、健常歩行で $0.04 \pm 0.04s$ 、疑似片麻痺歩行で $0.05 \pm 0.05s$ の誤差がみられた。健常歩行データでは、被験者3において推定誤差が特に大きく表れた。これは足部位置系列の形状が乱れによる位相分割の推定誤差が原因であると考えられた。疑似片麻痺歩行データにおける被験者4, 10については、単脚支持時間が真値よりも長く推定された影響で、両脚支持時間が短く推定されたと考えられた。

つま先角の推定では、健常歩行で $5.1 \pm 2.7deg$ 、疑似片麻痺歩行で $4.5 \pm 3.7deg$ となった。健常歩行データにおける被験者1, 2や疑似片麻痺歩行データにおける被験者7, 8などでは7から11deg程度の誤差を示した。また疑似片麻痺歩行においては、麻痺側である右側で推定誤差が大きくなる傾向が見られた。右単脚支持時間が真値よりも長く推定されたことで、実際にはつま先を引きずっている時間のつま先エッジも床平面に投票され、足跡として検出されたことが楕円モデル当てはめの誤差を大きくしたと考えられる。

表. 2に示すように、ステップ長の誤差は健常歩行 $0.03 \pm 0.06m$ と疑似片麻痺歩行 $0.03 \pm 0.02m$ となった。図. 4(c)の健常歩行データの被験者4において、大きな誤差を示すデータが見られた。これは前述したように、足部

位置系列の形状に依存するセグメンテーション誤差が要因と考えられた。疑似片麻痺歩行データについては、健常歩行データと比較してバラツキが小さい結果となった。ただし被験者4を除けば、健常歩行データの方が誤差とバラツキが小さくなるため、つま先角の推定と同様に足跡検出の精度の影響を受けたと考えられる。

Latorreら[43]は、Kinectが自動抽出する骨格情報を用いたステップ長、遊脚時間（反対側の単脚支持時間）、両脚支持時間の計算手法を提案し、健常者と片麻痺患者の歩行解析を行っている。我々と同様にビデオベースでの解析を真値として、精度を比較している。健常者と片麻痺患者それぞれについて、ステップ長は0.02mと0.01m、単脚支持時間は0.06sと0.09s、両脚支持時間は0.06sと0.07sと報告している。実験環境が異なるため直接的な比較はできないが、Kinectが自動追跡する骨格情報をベースとした計算方法よりも、提案手法の方が高い精度で歩容特徴を推定できる可能性を示唆した。また彼らの研究では足の向きについての特徴には述べられていないが、Kinectのように距離画像からパタン認識ベースで骨格情報を推定する場合、つま先のように床面と深度値が近い領域については推定精度が低下することが一般的な問題として知られている。提案手法ではRGBDデータを直接的に解析することで、5度程度の誤差の範囲内でつま先の向きを推定することが可能となった。

5. おわりに

本論文では、相互拘束条件を加えた時間セグメンテーションによる歩行位相分割および足跡検出手法を提案し、提案手法を用いた歩容特徴の推定精度について報告した。健常歩行と疑似片麻痺歩行における歩容特徴の推定における平均絶対誤差に大きな差はなく、片麻痺のように非対称な歩容に対する頑健性を示すことができた。また、つま先角のように従来手法では推定が難しかった特徴量についても、提案手法により推定が可能となった。一方で、つま先の引きずりなどによる入力信号の形状変化によって、時間セグメンテーションによる位相分割のタイミングがずれ、結果として歩容特徴の推定精度に影響を与えることが分かった。今後は位相分割アルゴリズムの改良を行い、より片麻痺患者の歩容に頑健な手法を開発する。また提案手法を用いて、片麻痺患者の歩容変化の定量的評価に向けた実用化も進める。

参考文献

[1] Imed Bouchrika and Mark S. Nixon. Model-based feature extraction for gait analysis and recognition. pp. 150–160, 03 2007.
[2] Sung Jung and Mark S. Nixon. Heel strike detection based on human walking movement for surveillance analysis. *Pattern Recognition Letters*, Vol. 34, p. 895?902,

06 2013.
[3] Edouard Auvinet, Franck Multon, Carl-Eric Aubin, Jean Meunier, and Maxime Raison. Detection of gait cycles in treadmill walking using a Kinect. *Gait & posture*, Vol. 41, No. 2, pp. 722–725, 2015.
[4] Erik Stone and Marjorie Skubic. Evaluation of an inexpensive depth camera for in-home gait assessment. *Journal of Ambient Intelligence and Smart Environments*, Vol. 3, No. 4, pp. 349–361, 2011.
[5] Chiraz Benabdelkader, Ross Cutler, and Larry Davis. Stride and cadence as a biometric in automatic person identification and verification. pp. 372 – 377, 06 2002.
[6] Chung Dial Lim, Ching-Ying Cheng, Chia-Ming Wang, Yen Chao, and Li-Chen Fu. Depth image based gait tracking and analysis via robotic walker. In *Robotics and Automation (ICRA), 2015 IEEE International Conference on*, pp. 5916–5921. IEEE, 2015.
[7] Eamonn Keogh, Selina Chu, David Hart, and Michael Pazzani. Segmenting time series: A survey and novel approach. *Data Mining in Time Series Databases*, Vol. 57, , 03 2003.
[8] Antti Koski, Martti Juhola, and Merik Meriste. Syntactic recognition of ecg signals by attributed finite automata. *Pattern Recognition*, Vol. 28, No. 12, pp. 1927–1940, 1995.
[9] Yanchang Zhao and Shichao Zhang. Generalized dimension-reduction framework for recent-biased time series analysis. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 18, No. 2, pp. 231–244, 2006.
[10] Richard Bellman and Bella Kotkin. On the approximation of curves by line segments using dynamic programming. ii. Technical report, RAND CORP SANTA MONICA CALIF, 1962.
[11] Richard Bellman and Robert Roth. Curve fitting by segmented straight lines. *Journal of the American Statistical Association*, Vol. 64, No. 327, pp. 1079–1084, 1969.
[12] Theodosios Pavlidis and Steven L Horowitz. Segmentation of plane curves. *IEEE transactions on Computers*, Vol. 100, No. 8, pp. 860–870, 1974.
[13] Alexander Kolesnikov and Pasi Fr?nti. Polygonal approximation of closed contours. Vol. 2749, pp. 778–785, 06 2003.
[14] Murray Evans, Steffi Colyer, Darren Cosker, and Aki Salo. Foot contact timings and step length for sprint training. In *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, pp. 1652–1660. IEEE, 2018.
[15] Jan M. Jasiewicz, John H.J. Allum, James W. Middleton, Andrew Barriskill, Peter Condie, Brendan Purcell, and Raymond Che Tin Li. Gait event detection using linear accelerometers or angular velocity transducers in able-bodied and spinal-cord injured individuals. *Gait & Posture*, Vol. 24, No. 4, pp. 502 – 509, 2006.
[16] R. W. Selles, M. A. G. Formanoy, J. B. J. Bussmann, P. J. Janssens, and H. J. Stam. Automated estimation of initial and terminal contact timing using accelerometers; development and validation in transtibial amputees and controls. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 13, No. 1, pp. 81–88, March 2005.
[17] J. A. Blaya and H. Herr. Adaptive control of a variable-impedance ankle-foot orthosis to assist drop-foot gait. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 12, No. 1, pp. 24–31, March 2004.
[18] Joonbum Bae and Masayoshi Tomizuka. Gait phase anal-

- ysis based on a hidden markov model. *Mechatronics*, Vol. 21, No. 6, pp. 961 – 970, 2011.
- [19] R. T. Lauer, B. T. Smith, and R. R. Betz. Application of a neuro-fuzzy network for gait event detection using electromyography in the child with cerebral palsy. *IEEE Transactions on Biomedical Engineering*, Vol. 52, No. 9, pp. 1532–1540, Sep. 2005.
- [20] Tao Liu, Yoshio Inoue, and Kyoko Shibata. Development of a wearable sensor system for quantitative gait analysis. *Measurement*, Vol. 42, No. 7, pp. 978 – 988, 2009.
- [21] Xiaoli Meng, Haoyong Yu, and Ming Po Tham. Gait phase detection in able-bodied subjects and dementia patients. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 4907–4910. IEEE, 2013.
- [22] Young Soo Suh and Sangkyung Park. Pedestrian inertial navigation with gait phase detection assisted zero velocity updating. In *2009 4th International Conference on Autonomous Robots and Agents*, pp. 336–341. IEEE, 2009.
- [23] C. M. Senanayake and S. M. N. A. Senanayake. Computational intelligent gait-phase detection system to identify pathological gait. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 14, No. 5, pp. 1173–1179, Sep. 2010.
- [24] S. Bonnet and P. Jallon. Hidden markov models applied onto gait classification. In *2010 18th European Signal Processing Conference*, pp. 929–933, Aug 2010.
- [25] Valentina Agostini, Gabriella Balestra, and Marco Knäflitz. Segmentation and classification of gait cycles. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 22, No. 5, pp. 946–952, 2013.
- [26] Nicola Carbonaro, Federico Lorussi, and Alessandro Tognetti. Assessment of a smart sensing shoe for gait phase detection in level walking. *Electronics*, Vol. 5, No. 4, p. 78, 2016.
- [27] F Foerster, M Smeja, and J Fahrenberg. Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring. *Computers in Human Behavior*, Vol. 15, No. 5, pp. 571 – 583, 1999.
- [28] X. Long, B. Yin, and R. M. Aarts. Single-accelerometer-based daily physical activity classification. In *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6107–6110, Sep. 2009.
- [29] Hong yin Lau, Kai yu Tong, and Hailong Zhu. Support vector machine for classification of walking conditions of persons after stroke with dropped foot. *Human Movement Science*, Vol. 28, No. 4, pp. 504 – 514, 2009.
- [30] Felicity R Allen, Eliathamby Ambikairajah, Nigel H Lovell, and Branko G Celler. Classification of a known sequence of motions and postures from accelerometry data using adapted gaussian mixture models. *Physiological Measurement*, Vol. 27, No. 10, pp. 935–951, jul 2006.
- [31] Jonathan Feng-Shun Lin and Dana Kulic. Automatic human motion segmentation and identification using feature guided hmm for physical rehabilitation exercises. In *Robotics for Neurology and Rehabilitation, Workshop at IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2011.
- [32] F. Chamroukhi, S. Mohammed, D. Trabelsi, L. Oukhelou, and Y. Amirat. Joint segmentation of multivariate time series with hidden process regression for human activity recognition. *Neurocomputing*, Vol. 120, pp. 633 – 644, 2013. Image Feature Detection and Description.
- [33] Andrea Mannini and Angelo Maria Sabatini. Machine learning methods for classifying human physical activity from on-body accelerometers. *Sensors*, Vol. 10, No. 2, pp. 1154–1175, 2010.
- [34] Bifu Huang, Meng Chen, Xi Shi, and Yangsheng Xu. Gait event detection with intelligent shoes. In *2007 International Conference on Information Acquisition*, pp. 579–584. IEEE, 2007.
- [35] Adam Miller. Gait event detection using a multilayer neural network. *Gait & posture*, Vol. 29, No. 4, pp. 542–545, 2009.
- [36] Yu Lou, Rongli Wang, Jingeng Mai, Ninghua Wang, and Qi Wang. Imu-based gait phase recognition for stroke survivors. *Robotica*, pp. 1–14, 04 2019.
- [37] Nicole Abaid, Paolo Cappa, Eduardo Palermo, Maurizio Petrarca, and Maurizio Porfiri. Gait detection in children with and without hemiplegia using single-axis wearable gyroscopes. *PLOS ONE*, Vol. 8, No. 9, pp. 1–8, 09 2013.
- [38] A. Mannini and A. M. Sabatini. A hidden markov model-based technique for gait segmentation using a foot-mounted gyroscope. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 4369–4373, Aug 2011.
- [39] Joonbum Bae and Masayoshi Tomizuka. Gait phase analysis based on a hidden markov model. *Mechatronics*, Vol. 21, No. 6, pp. 961–970, 2011.
- [40] Hongyu Zhao, Zhelong Wang, Sen Qiu, Jiixin Wang, Fang Xu, Zhengyu Wang, and Yanming Shen. Adaptive gait detection based on foot-mounted inertial sensors and multi-sensor fusion. *Information Fusion*, Vol. 52, pp. 157–166, 2019.
- [41] Rafael Torrealba, Jose Cappelletto, AlejandroGonz 叩 lez, LeonardoFerm 鱈 n. Detecting human gait cycle sub-phases from lower limb acceleration signals using k-means algorithm. 10 2010.
- [42] F. Attal, Y. Amirat, A. Chibani, and S. Mohammed. Automatic recognition of gait phases using a multiple-regression hidden markov model. *IEEE/ASME Transactions on Mechatronics*, Vol. 23, No. 4, pp. 1597–1607, Aug 2018.
- [43] Jorge Latorre, Roberto Llorens, Carolina Colomer, MarianoAlca 単 iz. Reliability and comparison of kinect-based methods for estimating spatiotemporal gait parameters of healthy and post-stroke individuals. *Journal of Biomechanics*, Vol. 72, pp. 268 – 273, 2018.