



携帯デバイスを用いた行動の種類・環境および行動主体の属性の推定

蘇, 彦聡

(Degree)

博士 (学術)

(Date of Degree)

2014-03-25

(Date of Publication)

2015-03-01

(Resource Type)

doctoral thesis

(Report Number)

甲第6154号

(URL)

<https://hdl.handle.net/20.500.14094/D1006154>

※ 当コンテンツは神戸大学の学術成果です。無断複製・不正使用等を禁じます。著作権法で認められている範囲内で、適切にご利用ください。



博士論文

携帯デバイスを用いた行動の種類・
環境および行動主体の属性の推定

平成26年3月

神戸大学大学院国際文化学研究科

蘇 彦聡

博士論文

携帯デバイスを用いた行動の種類・
環境および行動主体の属性の推定

審査委員： 康 敏 教授
玉置 久 教授
村尾 元 教授

平成26年3月

神戸大学大学院国際文化学研究科

蘇 彦聡

携帯デバイスを用いた行動の種類・環境および行動主体の属性の推定

グローバル文化専攻・情報コミュニケーションコース

学生氏名：蘇 彦聡

指導教員氏名：村尾 元

要旨

本研究では、自然な行動に近い状態での身体活動計測の実現と、所望の行動情報を頑健かつ柔軟に推定することを目的とする。行動情報とは、行動の種類・環境および行動主体の属性から成り立つ情報である。

現在、ユーザの行動に合わせて自動制御できる家電、照明、冷暖房や、ユーザの位置情報に応じたグルメ情報や乗換情報の推薦などに関する研究開発が進められており、一部はすでに実用化されている。将来的には、より多様なサービスの登場と、その結果としての新たな産業創出が期待できる。このようなサービスを実現するには、各ユーザの「行動種類」、「行動環境」や「個人属性」、たとえば、「30代男性がグラウンドで走っている」や「70代女性が坂道を上っている」といったような行動情報を把握する必要があると考えられる。ここで、「走行」や「歩行」などが「行動種類」、「グラウンド」や「坂道」などが「行動環境」、「30代」「70代」や「男性」「女性」などが「個人属性」のそれぞれに対応する。

本研究における計測手段として、携帯デバイスに注目した。近年、多様なセンサが安価、小型になっているため、生活用品にこれらのセンサを搭載する機器が増えている。特に、加速度センサや重力センサを搭載した携帯電話は一人一台が所有するという程度に普及している。本研究では、誰もが手軽に利用できることを目標として、センシングに特化したデバイスを利用せず、センサを内蔵した携帯デバイスを利用する。普段と同様にポケットやカバンなどに入れておくだけで、ユーザの行動データの収集を簡単に実現する。

そして、「行動種類」と「行動環境」、「個人属性」を推定の対象とする。本研究では、「行動種類」の検出によって、その「行動環境」と「個人属性」も同時に把握する。人間の基本行動パターンである「歩行」に注目した。歩行は「立つ」や「座る」などとともに非運

動性身体活動の一つとされている。このため、長期安定の計測において、歩行がもっとも多く検出される行動パターンであると考えられる。また、一般的に見られる人間それぞれの「歩き方の癖」が、人間工学、人類学や生理学などの分野において、「行動環境」の影響と「個人属性」の差として確認されている。このため、本研究は、異常パターンの検出を目的とする従来の研究と異なり、定常的な基本パターンを計測することによって、「行動環境」と「個人属性」を含めた行動情報の推定を歩行の検出とともに実現する。

本研究では、以下の三つを研究する。一つ目は、平坦地に限定した歩行を検出するために、3軸の加速度データに対して、それぞれの方向を特徴量として利用する方法を確立する。時系列の方向情報を隠れマルコフモデル（HMM）に適用して、HMMによるモデルの学習と確率的な推定を行う手法を提案する。二つ目は、階段などの複雑な行動環境に対応するために、時系列データを自動組織化する手法を提案する。モデルの構築は単一のHMMから始め、十分に学習・認識できない時系列データが入力された時に、未知の情報として捉え、自動的に新たなモデルを新規追加する手法を検討する。三つ目は、自然で統一的な計測手法を利用して、環境要因以外の個人性や性別などといった個人属性を推定する手法を提案する。人間の歩行信号に環境要因と個人属性が反映されているという仮定のもと、加速度データはそれぞれの畳み込んだ波形信号であるとして、それぞれを分離し抽出する手法を確立する。

以上の提案手法について、それぞれの例題を取り上げ、実験を通じてその有効性を考察した。一つ目は、90%以上の歩行を検出し、消費エネルギー計算での応用を実現し、市販のアプリケーションに遜色のない精度が得られた。二つ目は、「歩行」「階段を上る」「階段を下りる」「走行」の4種類の身体活動について、人間の主観認識と同様な自動分類結果が得られた。三つ目は、「履物」という行動環境と、「個人性」「性別」という行動主体の個人属性について、それぞれを推定できる特徴量を考察した。履物認識と個人認識を一回の計測で同時に実現した。結果、88%の性別推定精度も得られた。

全体として、環境要因や個人差などから由来するゆらぎやノイズなどを含めた生体データに対し、行動情報を頑健かつ柔軟的に推定するという目的を達成した。また、自然な行動に近い状態での身体活動計測を実現し、所望の行動情報が複数であっても、異なる計測を複数回行う必要のない統一的な手法を確立した。

目次

第 1 章	序論	1
1.1	本研究の目的	1
1.2	本研究の背景	3
1.3	本論文の構成	5
第 2 章	歩行と行動情報および関連研究	7
2.1	歩行	7
2.2	行動情報	8
2.2.1	行動種類	8
2.2.2	行動環境	9
2.2.3	個人属性	11
第 3 章	提案システムの構成	15
3.1	システムの概要	15
3.2	HMM によるモデル認識・学習	16
3.2.1	離散分布型 HMM	18
3.2.2	連続分布型 HMM	23
第 4 章	歩行の検出および消費エネルギーの推定	25
4.1	はじめに	25
4.2	提案手法	26
4.2.1	データの収集および前処理	26

4.2.2	加速度方向情報による特徴量抽出	27
4.2.3	METs 換算法による消費エネルギー推定	28
4.3	実験	29
4.4	結果および考察	32
4.5	まとめ	33
第 5 章	データの自動組織化および階段環境の推定	35
5.1	はじめに	35
5.2	競合学習法による自動分類	36
5.3	実験	37
5.4	結果および考察	40
5.5	まとめ	42
第 6 章	周期特性の抽出および個人属性・履物環境の推定	43
6.1	はじめに	43
6.2	提案手法	44
6.2.1	データの収集および前処理	44
6.2.2	LPC ケプストラム分析による特徴量抽出	48
6.2.3	EMD による特徴量間距離評価	54
6.3	実験 1	57
6.4	実験 2	60
6.5	結果および考察	61
6.6	まとめ	65
第 7 章	結論	67
	謝辞	71
	研究業績	73
	参考文献	75

目次

3.1	行動情報を推定するプロセスの基本的な枠組み	15
3.2	マルコフ連鎖の一例	17
3.3	離散分布型 HMM の一例	18
3.4	HMM によるパターン認識	19
3.5	Forward アルゴリズム	20
3.6	Backward アルゴリズム	21
3.7	Baum-Welch アルゴリズム	22
4.1	3 軸加速度データの一例	27
4.2	縦方向の加速度を用いたデータ分節の一例	28
4.3	加速度の大小によるラベル付け	29
4.4	SunSPOT を用いた加速度データ収集	30
5.1	競合学習法適用の流れ	37
5.2	HASC Logger を用いた加速度データ収集	39
5.3	HASC Tool を用いた加速度データ収集	40
6.1	3 軸加速度の合成方法	45
6.2	一つの時間単位フレームの設定	46
6.3	矩形窓とハミング窓を適用した合成加速度の波形	47
6.4	加速度データの時間波形とスペクトラム領域	50
6.5	加速度時間波形から得られたケプストラム	51

6.6	図の例から抽出したスペクトル包絡	52
6.7	ケプストラム分析と LPC ケプストラム分析で抽出したスペクトル包絡 .	54
6.8	LPC 次数 k : 左上 32, 右上 64, 左下 128, 右下 256	55
6.9	LPC ケプストラム分析で抽出した歩行者 4 人の F1F2 分布図	56
6.10	特徴量集合 P と Q の EMD 距離	57
6.11	生データから抽出した特徴空間の分類正答率	64
6.12	ハイパスフィルタを適用したデータの特徴空間の分類正答率	64
6.13	高周波数成分を強調したデータの特徴空間の分類正答率	65

表目次

4.1	観測シンボルの生成例	28
5.1	各身体活動の観測時系列の番号	38
5.2	閾値 $w = 500$ のときの分類結果	40
5.3	閾値 $w = 250$ のときの分類結果	41
6.1	コンテキスト情報認識実験のデータ収集方法詳細	58
6.2	生データの特徴量ごとのクラスタリング正答率	62
6.3	フィルタごとの (F1, F2) を用いたクラスタリング正答率	62

第1章

序論

1.1 本研究の目的

本論文では、コンテキストウェアサービスの向上という目標をめざして、人間の身体活動における情報処理様式に着目する。環境要因と個人差から由来するゆらぎやノイズなどを含めた生体データに対して、行動情報を頑健かつ柔軟に推定することを目的とする。

ここで、行動情報とは、行動の種類・環境および行動主体の属性を指す。たとえば、「30代男性がグラウンドで走っている」や「70代女性が坂道を上っている」といったような行動情報では、「走行」や「歩行」などが「行動種類」、「グラウンド」や「坂道」などが「行動環境」、「30代」「70代」や「男性」「女性」などが「個人属性」のそれぞれに対応する。

本研究の目的を達成するために、携帯デバイスを用いて簡単に収集したシンプルなデータに対して、行動情報を推定するための特徴量抽出およびパターン分類の手法を提案する。自然な行動に近い状態での身体活動計測を実現し、所望の行動情報が複数であっても、異なる計測を複数回行う必要のない統一的な手法を確立する。具体的に本研究では、以下三つの研究を実施し、歩行の加速度という生体データからの特徴量抽出と、行動情報の推定を実現するモデル構築に取り組む。

一つ目は、平坦地に限定した歩行を検出するために、3軸の加速度データに対して、それぞれの方向を特徴量として利用する手法を構築する。時系列の方向情報を離散分布型HMM (Hidden Markov Model, 隠れマルコフモデル) の観測時系列としてラベル化し、

HMMによるモデルの学習と確率的な推定を行う手法を提案する。その推定結果に基づいたアプリケーション応用も試みる。

二つ目は、平坦地だけではなく、階段などといった複雑な行動環境に対応するために、時系列データを自動組織化する手法を提案する。モデルの構築は単一のHMMから始め、十分に学習・認識できない時系列データが入力された時に、未知の情報として捉え、自動的に新たなHMMを新規追加する手法を検討する。また、加速度データの数値が単一のガウス分布に従ったものと仮定し、仮定に基づき、加速度の分布特徴を特徴量として、連続分布型HMMへの適用を試みる。

三つ目は、自然で統一的な計測手法を利用して、環境要因以外の個人性や性別などといった個人属性も把握できる手法を検討する。人間の歩行信号に環境要因と個人属性が反映されているという仮定で、加速度データはそれぞれの畳み込んだ波形信号であるとして、それぞれを分離し抽出する手法を提案する。そして、抽出した信号の有効性について、分類精度から考察する。

まず、簡単でシンプルなデータ収集を実現するために、計測の手段として携帯デバイスに注目する。前述したように、多様なセンサが安価、小型になっている昨今、生活用品にこれらのセンサを搭載する機器が増えている。特に、日常生活に定着した携帯電話は、加速度センサや重力センサを搭載し、直感的に操作でき、これまでなかった機能の数々を実現することにより、ユーザからの注目を浴びて、急速に普及している。時間情報や位置情報に加えて、さらに高速化した通信ネットワークを通じて、時間や場所を選ばず利用できる携帯デバイスは、身近にある一種のユビキタス環境であると考えられる。このため、本研究の基本方針として、その他の特化したデバイスを利用せず、センサを内蔵している携帯デバイスに限定する。普段と同様にポケットやカバンなどに入れておくだけで、ユーザの行動データの収集を簡単に実現する。

そして、本研究では、「行動種類」の検出によって、「行動環境」や「個人属性」といった行動情報を同時に推定することを実現する。このために、検出対象の「行動種類」として、人間の歩行に注目する。歩行は人間の基本行動パターンであり、「立つ」や「座る」などとともに非運動性身体活動の一つとされている。このため、長期安定の計測において、歩行がもっとも多く検出される行動パターンであると考えられる。従来の研究において

も、歩行を継続的に計測することがあったからこそ、転倒などの異常パターンの検出を実現できることが考えられる。また、一般的に見られている人間それぞれの「歩き方の癖」が、人間工学や人類学、生理学などの分野において、「行動環境」の影響と「個人属性」の差として確認されている。このため、本研究は、異常パターンの検出を目的とする従来の研究と異なり、定常的な基本パターンを計測することによって、「行動環境」と「個人属性」を含めた行動情報の推定を歩行の検出とともに実現する。

1.2 本研究の背景

人間の脳は約 300 万年前から進化し続けている。これに対し、言語は 5~30 万年前程度と比較的新しい。この事実から、人間は言語によるコミュニケーション以前に、身振りなどの行動を介して、コミュニケーションをしていたと考えられる。認知心理学の分野では人間の行動認識について、ミメシス理論が提案されている [1]。ミメシスとは他人の行動を認識することと、自らの行動を生成することの循環によるコミュニケーション機能であり、人間の知能の根源であると考えられる。

また、生物学の分野でも行動認識についての事実が発見されている。マカクザルの脳において、他人の行動を観測する時に発火し、自分がその行動を行うときにも発火するミラーニューロンが発見された [2]。この発見から、ミラーニューロンは他人の行動を抽象化したものであり、自分の行動はミラーニューロンを展開したものであると解釈できる [3]。

コンピュータは言語を用いて人間と直接コミュニケーションすることは不可能に近いが、人間より遙かに高度な記憶能力や計算能力を持っている。そのため、ミラーニューロンのような表現形態をうまく設計できれば、人間の行動を学習して認識することが可能であると考えられる [4]。さらに、ミメシス理論のとおり、その認識結果によって、自らの行動を生成することができれば、人間にとって有意義なサービスを知的に提供することが期待できる。このように提供されたサービスは、コンテキストウェアサービスと呼ばれている。

現在、すでに様々な分野において、コンテキストウェアサービスを実現する試み

が数多く行われている。例えば、Doung らの遠隔介護における ADL(Activity of Daily Living) モニタリング [5]，本村らの事故予防のための乳幼児モニタリング [6]，笠らの非運動性活動における消費エネルギー推定 [7] や，大野らのスーパーマーケット客動線に対する行動パターン分析 [8] などのアプリケーションが研究開発されている。このような小規模の研究テスト以外にも，大規模な普及を目指しているものも登場してきた。たとえば，ユーザの行動に合わせて自動制御できる家電，照明，冷暖房や，ユーザの位置情報に応じたグルメ情報や乗換情報の推薦サービスなどがすでに実用化されている。さらに，将来的には，より多様なサービスが登場して，その結果として，新たな産業創出が期待できる。

しかし，大勢の人が暮らす世の中において，コンテキストウェアサービスを実現するには，まず一人ひとりのユーザの「行動種類」，「行動環境」や「個人属性」といった行動情報を把握する必要がある。

近年では，画像，音声，言語などのメディア情報に関する認識技術の精度が向上し，顔検出，音声認識，発話分析などを行動情報の推定に適用する研究が進んでいる。例えば，青木ら [9] は行動の規則性・習慣性といった行動パターンを学習・認識する研究を行った。上から広範囲を観測できる全方位視覚センサを用いて，対象人物の周囲 360 度シーンを撮影した。画像から人物領域と肌色領域を抽出し，それぞれの画素の特徴量を隠れマルコフモデルに適用して，8 種類の動作および 3 種類の行動パターンの学習・認識を行った。田中ら [10] は行動環境の安全性評価について検討するために，いくつかの異なる歩行路環境を設定してモックアップを作り歩行実験を行い，モーションキャプチャで歩行動作を取得した。カオス理論の応用であるリカレンスプロットを用いて，画像から身体のゆらぎを抽出した。平坦路上の安全な歩行動作とのゆらぎの違いを数量化し，行動環境の安全性評価を試みた。西村ら [11] は大人と子供に適応した音声情報案内の実装に必要な話者識別手段として，音声認識結果の対数尤度から求めた音声的特徴と言語的特徴を併用した統計学習に基づく識別手法を提案した。二値分類アルゴリズムであるサポートベクターマシンを識別に用いた実験では 91.8% の識別率を得た。

しかし，これまでの研究の多くは，特殊な環境を設定していた。また，特殊な機械とそれらに関する前提知識が必要であった。サービス提供側としてのプロバイダと，サービス

享受側としてのユーザにとって、決して小さな負担とはいえない。

一方、センシング技術の発展により、加速度センサ、角速度センサ、磁気センサ、気圧計や GPS など、多様なセンサが開発されている。環境や機器にセンサが分散配置されたユビキタスコンピューティング [12] や、日常行動に密着したセンシングを目指すウェアラブルコンピューティング [13] に関する研究が進んでいる。これらによって、コンテキストウェアサービスにおけるプロバイダとユーザの負担が劇的に軽減される。また、多くのセンサを利用することによって、人間の行動に関する時空間データが、従来より豊富に計測できるようになってきた。そして、計測されたデータに基づいて、人間の行動を理解するための研究開発が活発に行われている。たとえば、ウェアラブルセンサを利用して、心拍、体温や加速度などを計測し、健康管理 [14]、運動フォームの推定 [15] や、行動状態の推定 [16–21] などを行い、さらにその結果に基づいてユーザに適した情報を提供するシステムの研究開発が進んでいる [22, 23]。

こうした研究の多くは、行動情報を推定するために、多種類のデータを相補的に分析する技術を追求している。このため、特化したデバイスがまだ必要とされている。たとえば、自動車運転行動のデータベースを構築するために、ハンドル・アクセル・ブレーキなどの操作データに加えて、視線・心拍数・発汗量などの生理データや、カメラ・マイクによる画像・音声データなどといった運転行動に関する多様なデータを収集・蓄積するドライバモニタリングが行われている [24, 25]。また、多くの既存研究の目的は、仕事中の転倒や運転中の脇見などといった特定の異常行動パターンを検出することであった。シンプルに安定で長期にわたって計測された行動データから、多様な状況を理解できるような行動情報を推定することにまだ至っていないのが現状である。

1.3 本論文の構成

本論文は以下のように構成される。

第 1 章では、本研究の背景および目的について述べた。第 2 章では、本研究が対象とする歩行と行動情報について、従来の関連研究を整理するとともに、一般的な基本事項および得られた知見を示す。これによって、本研究のアプローチの位置付けを明確にする。第

3章では、以降の各章において用いられる処理プロセスの基本的な枠組みを示す。第4章では、加速度の方向情報による歩行の検出について、提案手法を説明する。そして、アプリケーション応用の消費エネルギー推定を通じて、提案手法の有効性を確かめる。第5章では、時系列データを自動組織化する手法として、競合学習法の適用と加速度の分布特徴に基づいた連続分布型 HMM モデルの構築を提案し、平坦地と階段における歩行の実験を行い、その有効性を評価する。続く第6章では、行動環境と個人属性を推定するためのケプストラム分析の適用について論じる。例として、履物と個人性、性別に関する特徴抽出を行い、その可能性を検証する。最後に、第7章において、本論文の総括を行い、今後の課題および展望について述べる。

第2章

歩行と行動情報および関連研究

2.1 歩行

動物の本質は位置移動運動の「ロコモーション」にあるとされている。地面に張り付いて生息し、たとえば気温など、環境の好転をじっと待つばかりの植物と違い、動物は文字どおり、よりよい環境を求めるために移動する。その移動手段として、身体内に前進運動器官を有している。身体内のエネルギーをもっとも効率的・経済的に使用して、これらの器官を駆使するのは歩行である。すなわち、歩行は動物にとって、日常生活上でもっとも身近な行動様式であるといえる。このため、歩行に関する研究は、運動学、心理学の分野において、古くから行われてきた。

運動学の分野においては、人間の歩行に関して、以下のように述べられている [26]。人間は歩く際に、前肢に相当する手を用いず、後肢に相当する足の交互運動によって、重心を移動させ、そのうちに左右のどちらかが常に接地しているという直立二足歩行を行う。直立姿勢とともに、常習的に長距離の二足歩行を行えるのは、人類を人類たらしめた最大の特徴である。

また、心理学の分野においても、二足歩行は人間らしく生きるための重要な機能であり、知能を高め、文化を創造する原動力になったと言われている [27]。位置移動運動の遺伝情報として、歩行の成立に必要な中枢プログラムと反射プログラムが生来与えられている [28] が、ひとり歩きができるようになるには、生後約一年間の支持歩行を反復練習する

必要があるといった重要な発達段階とされている [29].

上述したような従来の知見によって、人間の歩行は、発達過程を通じて習得した常習的な行動であることが分かった。歩行は以下の特徴を有していると考えられる。

1. 歩行は、もっとも多く行われている基本的な身体活動である。
2. 歩行は、外部環境の状況に対して、自然に反射活動を行う。
3. 歩行は、習慣的な身体活動であり、その個人属性が現れている。

2.2 行動情報

2.2.1 行動種類

人間が一日中に行う身体活動は、運動によるものと、家事などの日常生活の生活活動によるものに、大きく分けられる。厚生労働省によると、「身体活動」、「運動」、「生活活動」は、次のように規定されている [30].

- 「身体活動」

安静にしている状態よりも多くのエネルギーを消費する全ての動きであること。

- 「運動」

身体活動のうち、体力の維持・向上を目的として計画的・意図的に実施するもの。たとえば、ジムやフィットネスクラブで行うトレーニングやエアロビクスなど、テニス、サッカー、バスケなどのスポーツ、余暇時間の活発な趣味など。

- 「生活活動」

身体活動のうち、運動以外のものをいい、職業や家事活動上のものも含む。たとえば、買い物、床掃除、通勤、通学、階段昇降や荷物運搬などの移動に伴う活動、オフィスワーク、洗濯、炊事、ピアノなどの立位・座位の活動。

つまり、「身体活動 = 運動 + 生活活動」という関係となる。このうち、歩行に基づいた行動の運動量として、20歳以上成人の平均歩数は、日本人の男性が一日7233歩、女性が一日6437歩であると報告されている [31]。歩行時のエネルギー消費量を求めるためのア

メリカスポーツ医学協会が提示する計算方法 [32] を用いて、1000 歩で約 30kcal と換算すれば、日本人の男性は約 217kcal、女性は約 193kcal のエネルギーが、歩行に伴う活動で消費されていることが分かる。

そもそも、一日のエネルギー消費量は、身体活動、基礎代謝、食事誘発性体熱産生の三種類から構成され、それぞれの構成割合が以下のとおりであるとされている [33]。

- 身体活動量：約 30%
- 基礎代謝量：約 60%
- 食事誘発性熱産生：約 10%

成人男性の基礎代謝量が約 1500kcal/日、成人女性の基礎代謝量が約 1200kcal/日であると概算されている [34]。上記の構成割合で試算すれば、成人男性の身体活動量が約 750kcal/日、成人女性の身体活動量が約 600kcal/日であることが分かる。

したがって、前述した歩行に伴う活動の消費エネルギー量と、試算した成人の身体活動量を比較すると、男女を合わせた全体の平均として、歩行によるエネルギー消費量が一日の身体活動量の約 3 割であることが分かる。このエネルギー消費量は METs という運動強度と運動時間で算出される [35,36] ため、睡眠や座位などの低強度長時間の活動を除いて、スポーツやランニングなどの高強度なエクササイズより、歩行に基づいた行動の時間が長いと考えられる。歩行が長期の計測に適している利点は、本研究で歩行を検出対象とする理由の一つである。

2.2.2 行動環境

人間は環境を操作・改変し、環境は人間の心理・行動あるいは発達に影響を及ぼす。この人間と環境との相互作用によって発生した人間行動は、多様で複雑である。人間行動を理解するには、発達、教育、社会、文化などといった外部環境から、生理、運動、情動、認知などの身体内部にまで、広領域に及ぶ諸相を対象とする必要があり、さまざまな研究が多く行われている。本研究の着目は、行動環境の把握である。把握のためには、直接的に外部の行動環境を計測して状況を把握する方法と、身体内部の信号を利用して間接的に

行動環境を推定する方法の二種類がある。

まず、行動環境を直接に計測する関連研究について述べる。たとえば、位置情報を行動環境の情報の一つとして計測する場合、代表的な方法として GPS(Global Positioning System) が知られている。さらに、GPS の誤差が生じる室内や地下鉄、高層建築物の多い場所などで、より精度の高い位置情報を把握するためには、GPS だけではなく、ほかの情報も計測して位置情報を推定する。田岡ら [37] は、Bluetooth による受信信号強度を用いたユーザの位置推定手法を提案した。ユーザに装着した移動局が複数の固定局から一定時間で得られる受信信号強度の平均値、最大値、最小値、中央値を特徴量として用いて位置推定を行う。2床のベッドを配置した模擬的な病室環境での実験を行い、ベッド際のどの位置にいるか、およびそれ以外にいるかという識別については 80% 以上、どちらのベッドの患者に対するインタラクションかの識別においては 90% 以上の識別率が得られた。庄司ら [38] は音響情報に基づく複数歩行者の位置推定・追跡を検討した。室内において、マイクロホン 4 本からなる基本的マイクロホンアレーを床から 2.5m の高さに設置し、床面上 2 次元における足音の位置推定と追跡について実験を行った。5 人程度の歩行者については、位置情報の同時検出・追跡が可能であることを示した。

位置情報のほか、行動環境の混雑度を推定する研究も行われている。中村ら [39] は「空いている」「混んでいる」という電車内の混雑度を認識するために、応答速度の早い二酸化炭素センサを利用して、空気中の二酸化炭素濃度を計測した。通学時での実験データに対する認識結果が、平均で 80% 以上の精度を果たした。

つぎに、身体の信号を利用して間接的に行動環境を推定する関連研究について述べる。たとえば、混雑度の推定を目的とする同様の研究に関して、上述した行動環境の二酸化炭素濃度を直接に計測する手法と違い、米村ら [40] はユーザの持っているスマートフォンに搭載した加速度センサを用いて、歩幅を検出し、その違いから街中の混雑度を推定する手法を提案した。提案手法を実装したスマートフォンを利用して、実際に街中を歩行した結果、空いている状態を 79.3%、混んでいる状態を 67.6% の精度で推定した。また、この推定精度を向上させるため、歩幅だけでなく、歩行時の足を出す周期も考慮する機能拡充をさらに実装した結果、空いている状態を 83.0%、混んでいる状態を 77.5% の精度精度を向上させた。

上述した直接的な方法のほか、間接的に行動環境を評価する研究も行われている。たとえば、篠田ら [41] は造船場という身体バランスの崩壊を誘発しやすい歩行路環境の安全性評価について、モーションキャプチャを利用し、歩行動作中の身体各部位の位置座標の時系列データを取得して、人体を鋼体のリンクでモデル化した。モデルを用いて、歩行環境が人体のバランス制御に与える影響の定量化を試み、環境要因と歩行動作との因果関係を確認した。

また、近年、ウェアラブルセンサを利用して、生体の機能的な働きから行動まで、人間の身体活動を簡単に観測できるようになってきた。このため、行動環境の評価を目的とする研究では、生体データも利用されている。たとえば、鈴木ら [42] は自転車利用者が多い高松市内の自転車走行空間を調査対象に選び、「ホルター心電計」を装着した被験者による自転車走行実験を実施し、得られた心拍データを用いて、自転車走行空間の安全性および快適性を定量化する評価方法について考察した。

本研究の扱う対象である「歩行」を含めた人間の身体活動は、外部環境の状況に対して、自然に反射活動を行っていることが、上述した関連研究の知見によって明らかになった。このため、本研究において、行動環境を把握するには、環境を直接に計測できる GPS や Wi-Fi, Bluetooth などと、生体データを記録できる加速度センサや角速度センサなどが同時に組み込まれた携帯デバイスを使用する。

2.2.3 個人属性

個人属性を取得する方法として、IC カードなどといった物理的な媒体が、従来から多く利用されている。一枚のカードに様々な属性情報を記憶し、瞬時に読み取ることができるため、各分野に普及している。近年、かざすだけという簡単な動作で利用可能な NFC(Near Field Communication) 技術が、個人情報収集の重要な手段として、注目を集めている。カードは名前や住所などの情報も登録して利用できるが、紛失や偽造の可能性、提示動作の負担、更新の必要性などの制約もある。一方、物理的な媒体を携行する必要のない生体情報を利用して、個人属性を把握するというバイオメトリクス手法の研究が盛んに進められている [43]。生体情報は偽造や盗難の困難さや、常に最新情報が得られる

などの利点がある。しかし、現状では、実用化に至るまで十分な認識精度の得られる技術はまだ少ない。

Jain ら [44] は、ある程度の有効性が示されているバイオメトリクス手法として、「顔」、「指紋」、「手の形状」、「キータッチのリズム」、「手の血管」、「目の虹彩」、「目の網膜」、「サイン」、「声紋」、「体温分布」、「におい」、「DNA」、「歩行」、「耳」といった14種類の対象を挙げた。そして、「一般性」、「固有性」、「普遍性」、「計測しやすさ」、「個人認証の精度」、「受け入れやすさ」、「偽造しやすさ」といった7種類の条件から、各生体情報の特徴を比較した。そのうち、本研究の扱う対象である「歩行」は、「計測しやすさ」と「受け入れやすさ」の観点から高い評価が得られた。つまり、計測者と被計測者の両方にかかる負担が少ないという利点がある。これは「簡単でシンプルなデータ収集」といった本研究の基本方針に適している。

一方、「個人認証の精度」の観点からの「歩行」に対する評価が高くなかった。しかし、人が遠方から歩行者を見て、それが誰であるか、あるいは、男性であるか女性であるかを認識することができるように、歩き方に個性があることは一般的に知られている。このため、歩行から個人属性の推定に十分な特徴が得られると考えられている。現在、個人性の認識に利用しようという試みが増えつつである。たとえば、カメラ映像からウェブレットを用いて歩行者を抽出する手法 [45]、歩行映像の固有空間を求めて識別する手法 [46]、台はかりを用いて測定した床への圧力の時間変化に基づく個人識別 [47] や、圧力センサを用いて得られた足圧の時系列データからの個人識別 [48] などが検討されている。これらの手法では、各実験環境において、約80%から90%の個人識別率が得られた。

また、性別による歩行特徴に関する研究も、古くから行われてきた。Bar ら [49] はマーカーを装着したビデオ映像を用いて、心理物理学的な立場からの歩行特徴の性差について研究した。山崎ら [50] はトレッドミル歩行時の下肢動作を連続観察し、その常同性と歩行速度の関係および性差について検討した。宮本ら [51] は股関節、膝関節と足関節の三次元歩行解析を通じて、健常者における性差による歩行の違いを検討した。西島ら [52] は筋電図法を用いて、平地歩行中の筋放電パターンや活動レベルから男女間差について検討した。金ら [53] は歩容の大きさや体重に影響されない無次元速度の概念を用いて、中高年者の歩行における性差を考察した。これらの研究では、性別による歩行の差異が、そ

それぞれの分析手法によって認められた。

以上の研究から、歩行という習慣的な身体活動にその個人属性が現れていることを確認できた。しかし、これらの研究では識別情報としての可能性が認識されながらも、個人属性の抽出とした利用方法が確立されていない。そこで、本研究では、歩行に着目し、従来の知見を特徴量として、歩行との関連性が指摘されている個人属性の推定を試みる。

本論文では、「行動種類」、「行動環境」と「個人属性」をまとめて「行動情報」とする。歩行という身体活動に着目し、曖昧さやゆらぎなどを含めた計測データに対して、「行動種類」の一つである「歩行」を検出することによって、「歩行」に反映された「行動環境」と「個人属性」の情報を推定する。具体的には、平坦地・階段と各種の履物を「行動環境」の推定対象とし、性別と個人認識に用いられる個人性を「個人属性」の推定対象とする。

第3章

提案システムの構成

3.1 システムの概要

本論文では、行動情報を推定するシステムが、図 3.1 に示す基本的な枠組みで構成される。以降の各章においても、このプロセスを基本とする。

一般的に、前処理部では、データの収集を行い、カメラ・マイク・加速度センサ・GPS などから行動に関する信号が入力され、実世界のアナログ信号であれば、コンピュータで処理可能なデジタル信号に変換される。また、この後の特徴抽出処理を容易にするための作業も行われる。特徴抽出部では、前処理部の出力であるデジタル化されたデータを入力として、これらの中から行動認識に役立つ情報が取り出される。逆に、認識に役立たない情報を無視する。通常、特徴量と呼ばれるいくつかの情報が、ベクトルの形式で抽出される。認識部では、この特徴ベクトルを事前に用意した各標準モデルのパターンと比較し

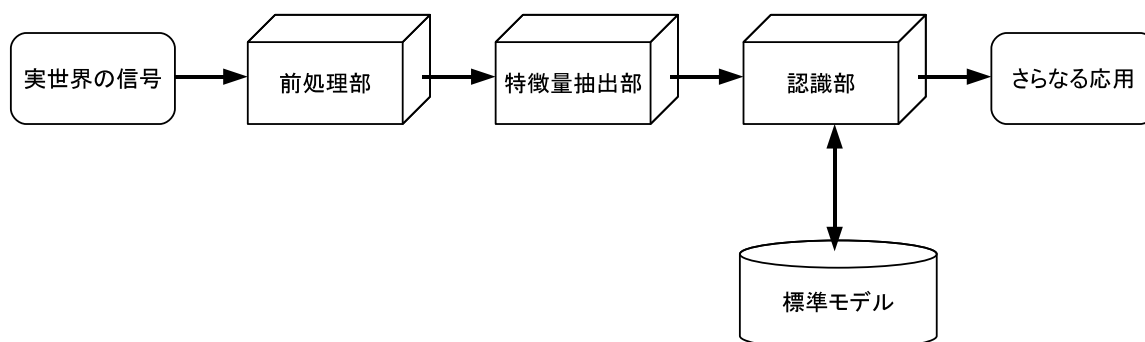


図 3.1 行動情報を推定するプロセスの基本的な枠組み

て、認識結果を決め、さらなる応用につながる。ここで、特徴ベクトルと標準モデルのベクトル要素が実数値であるため、完全に一致することはまれである。このため、何らかの基準を用いて、ベクトルの比較を行い、類似度の高い特徴ベクトルをもっている標準パターンを認識結果として出力し、行動情報の推定を実現する。

3.2 HMM によるモデル認識・学習

隠れマルコフモデル (Hidden Markov Model, HMM) はマルコフ連鎖を基礎として、その確率的な自由度をより拡大したモデルである。マルコフ連鎖は以下のように定義される。

X 個の状態の集合を $S = \{s_1, s_2, \dots, s_X\}$ とする。ある観測された状態系列 $q_1, q_2, \dots, q_t, \dots, q_T$ において、任意の時点 t での状態 q_t がそれ以前の k 個の状態系列 $q_{t-1}, q_{t-2}, \dots, q_{t-k}$ だけを条件として決定するとき、つまり

$$P(q_t) = P(q_t \mid q_{t-1}, q_{t-2}, \dots, q_{t-k}) \quad (3.1)$$

と表現できれば、この確率過程は k 重マルコフ連鎖と呼ばれる。また、(3.1) 式がすべての t において成り立つとき、定常 k 重マルコフ連鎖と呼ばれる。さらに、 $k = 1$ で直前の状態のみ依存するとき、定常 1 重マルコフ連鎖、または単にマルコフ連鎖と呼ばれる。

マルコフ連鎖において、ある状態から別の状態へ移行する確率を状態遷移確率と定義する。状態 s_i から s_j への状態遷移確率を $a_{s_i s_j} (s_i, s_j \in S)$ とすると、 $a_{s_i s_j} = P(q_t = s_j \mid q_{t-1} = s_i)$ となる。 i 行 j 列目の要素を $a_{s_i s_j}$ とする $X \times X$ 行列を遷移確率集合 A とする。

$$A = \begin{bmatrix} a_{s_1 s_1} & \cdots & a_{s_1 s_X} \\ \vdots & & \vdots \\ a_{s_X s_1} & \cdots & a_{s_X s_X} \end{bmatrix} \quad (3.2)$$

図 3.2 にマルコフ連鎖の一例を示す。丸は状態、矢印は状態遷移、アルファベットはその状態での出力を表す。また、矢印の横に状態遷移確率を示した。例えば、太線で表した遷移経路で A, C, D, A と出力される確率は、

$$a_{s_1 s_3} a_{s_3 s_4} a_{s_4 s_5} = 0.4 \times 0.8 \times 1.0 = 0.32 \quad (3.3)$$




図 3.2 マルコフ連鎖の一例

となる。このようにマルコフ連鎖は状態系列と出力系列が 1 対 1 に対応している。

マルコフ連鎖を基本にして、HMM では各状態から出力可能な記号を 1 個以上に拡張する。各状態に複数の記号が割り当てられている場合は、記号の出力は確率的に決定される。複数の状態から同一の記号を出力する可能性があるため、通常は同一の系列を出力する状態系列が複数存在する。したがって、観測される出力記号だけでは状態系列を一意に特定することはできない。すなわち、外部からは状態の遷移は直接的に観測できず、出力記号のみが観測可能となる。このため、“隠れ”マルコフモデルと呼ばれる。状態からの記号出力確率について、以下のように定義される。

Y 個の出力記号の集合を $V = \{v_1, v_2, \dots, v_Y\}$ とする。状態 s_i で記号 $v_k (1 \leq k \leq Y)$ が出力される確率を $b_{s_i}(k)$ とし、 i 行 k 列目の要素を $b_{s_i}(k)$ とする $X \times Y$ 行列を出力確率の集合 B とする。

$$B = \begin{bmatrix} b_{s_1}(v_1) & \cdots & b_{s_1}(v_Y) \\ \vdots & & \vdots \\ b_{s_X}(v_1) & \cdots & b_{s_X}(v_Y) \end{bmatrix} \quad (3.4)$$

また、各状態が初期状態となる確率の集合を $\Pi = \{\pi_1, \pi_2, \dots, \pi_X\}$ とすると、HMM は $\lambda = (\Pi, A, B)$ をパラメータとして、 $\text{HMM} = (S, O, \lambda)$ を用いて定義することができる。さらに、出力記号を有限個のシンボルとして表す場合と、連続値で表現する場合があり、一般的には、

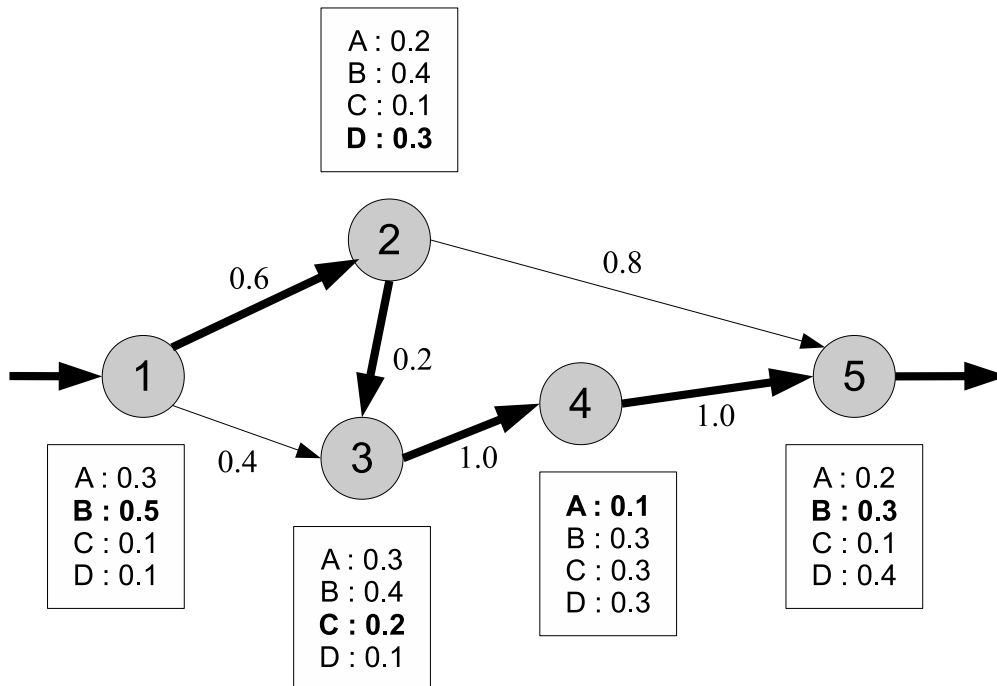


図 3.3 離散分布型 HMM の一例

- 離散分布型 HMM(Discrete HMM)
- 連続分布型 HMM(Continuous HMM)

の 2 種類に分けられる。

3.2.1 離散分布型 HMM

離散分布型 HMM によるパターン認識

離散分布型 HMM では、観測された系列が有限個のシンボルの組み合わせで表現される。ある観測時系列 $O = \{o_1, o_2, \dots, o_T\}$ に対して、シンボルを出力する状態の系列は様々な可能性が考えられ、そのうちの一つを q_1, q_2, \dots, q_T とする。HMM において q_1, q_2, \dots, q_T から o_1, o_2, \dots, o_T が出力される確率は

$$P = \pi_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \cdots a_{q_{T-1} q_T} b_{q_T}(o_T) \quad (3.5)$$

で求められる。図 3.3 に離散分布型 HMM の一例を示す。各状態における出力シンボルの出力確率を四角の中に示す。例えば、太線で表した遷移経路で B, D, C, A, B という

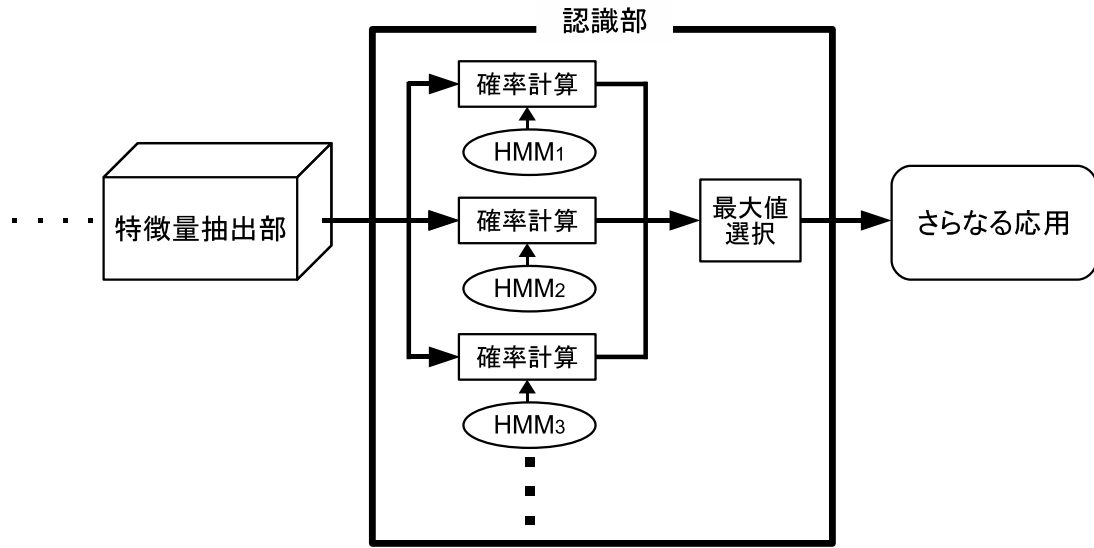


図 3.4 HMM によるパターン認識

配列が観測される確率は

$$\begin{aligned}
 & b_1(B)a_{12}b_2(D)a_{23}b_3(C)a_{34}b_4(A)a_{45}b_5(B) \\
 & = 0.5 \times 0.6 \times 0.3 \times 0.2 \times 0.2 \times 1.0 \times 0.1 \times 1.0 \times 0.3 \\
 & = 0.000108
 \end{aligned} \tag{3.6}$$

となる。

一般的に、認識部において HMM を用いるとき、観測時系列について、各 HMM モデルによって生成される確率を求め、最大確率を与えるモデルを認識結果とする。図 3.4 に HMM を用いたパターン認識の方法を示す。通常、確率を計算するには、Forward アルゴリズムが用いられている。

Forward アルゴリズムは図 3.5 に示されている。Forward アルゴリズムは、 $q_t = s_j$ で t 番目の状態が s_j となったとき、 o_1, o_2, \dots, o_t が観測されている確率を求めるアルゴリズムである。つまり、この確率は、観測時系列 O とこれに対応する状態系列 Q において、 $q_t = s_j$ となるようなあらゆる状態系列に対して、一部分の時系列 o_1, o_2, \dots, o_t が出力される確率を合計したものである。これを Forward 確率 $\alpha_t(s_j)$ と定義して、状態 s_j の直前の状態を s_i とすると、以下の再帰式を立てることができる。

$$\alpha_t(s_j) = \begin{cases} \pi_{s_j} b_{s_j}(o_t) & , \text{if } t = 1 \\ \sum_{i=1}^N \alpha_{t-1}(s_i) a_{s_i s_j} b_{s_j}(o_t) & , \text{if } 1 < t \leq T \end{cases} \tag{3.7}$$




図 3.5 Forward アルゴリズム

t 番目の状態 $q_t = s_j$ のとき、直前の状態を $q_{t-1} = s_i$ とした場合、状態 s_i から状態 s_j に遷移し、 o_t が出力される確率は $\sum_{i=1}^N \alpha_{t-1}(s_i) a_{s_i s_j} b_{s_j}(o_t)$ となる。したがって、式 (3.7) を用いて、 $t = T$ のときの $\alpha_T(s_j)$ 、すなわち、観測時系列全体が HMM モデルによって生成する確率を求めることができる。

離散分布型 HMM によるモデル学習

通常、Baum-Welch アルゴリズムを用いて HMM のパラメータ $\lambda = (\Pi, A, B)$ を最尤決定する。Baum-Welch アルゴリズムは、出力系列 $O = \{o_1, o_2, \dots, o_T\}$ が観測される確率 $P(O | \lambda)$ を最大にするようなパラメータ λ を推定するアルゴリズムである。Baum-Welch アルゴリズムにおけるパラメータ学習は次の手順で行われる。

1. λ を初期パラメータとする。




図 3.6 Backward アルゴリズム

2. 観測された出力系列 O と λ に基づいて、新しいパラメータ $\bar{\lambda}$ を求める。
3. パラメータの変化率や繰り返し回数が終了条件を満たすまで λ を $\bar{\lambda}$ と更新し、2 に戻る。

Backward アルゴリズムを図 3.6 に示す。具体的には、まず、 t 番目の状態として s_i を通過したときに、 $o_{t+1}, o_{t+2}, \dots, o_T$ が観測される確率を Backward 確率 $\beta_t(s_i)$ と定義して、これを Backward アルゴリズムで計算する。前述した Forward アルゴリズムと逆に、Backward アルゴリズムによって求められるのは、 $q_t = s_i$ となったとき、その以降のあらゆる状態系列に対して、一部分の系列 $o_{t+1}, o_{t+2}, \dots, o_T$ が観測される確率を合計したものである。状態 s_i の直後の状態を s_j とすると、以下の再帰式を立てることができる。

$$\beta_t(s_i) = \begin{cases} 1 & , \text{if } t = T \\ \sum_{j=1}^N a_{s_i s_j} b_{s_j}(o_{t+1}) \beta_{t+1}(s_j) & , \text{if } 1 \leq t < T \end{cases} \quad (3.8)$$




図 3.7 Baum-Welch アルゴリズム

t 番目の状態が s_i のとき、 $t+1$ 番目の状態を $q_{t+1} = s_j$ とした場合、状態 s_i から状態 s_j に遷移し、 o_{t+1} が出力される確率は $\sum_{j=1}^N a_{s_i s_j} b_{s_j}(o_{t+1}) \beta_{t+1}(s_j)$ となる。

つぎに、Forward 確率 α および Backward 確率 β を用いて、 t 番目に状態 s_i を通過したあとの $t+1$ 番目に状態 s_j を通過する確率 $\xi(s_i, s_j)$ を次の式で計算することができる。

$$\begin{aligned} \xi_t(s_i, s_j) &= P(q_t = s_i, q_{t+1} = s_j \mid O, \lambda) \\ &= \frac{\alpha_t(s_i) a_{s_i s_j} b_{s_j}(o_{t+1}) \beta_{t+1}(s_j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(s_i) a_{s_i s_j} b_{s_j}(o_{t+1}) \beta_{t+1}(s_j)} \end{aligned} \quad (3.9)$$

この式 (3.9) を満たすパス経路が図 3.7 に示されている。観測時系列全体が与えられたとき、 t 番目に状態 s_i を通過する確率を $\gamma_t(s_i)$ とすると、

$$\gamma_t(s_i) = \sum_{j=1}^N \xi_t(s_i, s_j) \quad (3.10)$$

となる。

本研究のように離散分布型 HMM を適用する場合は、上記の $\xi_t(s_i, s_j)$ および $\gamma_t(s_i)$ を用いて、 t についての総和を求めることにより、モデルの新しいパラメータ $\bar{\lambda} = (\bar{\Pi}, \bar{A}, \bar{B})$

を次のように推定する.

$$\begin{aligned}\bar{\pi}_{s_i} &= \text{時刻 } t = 1 \text{ で状態 } s_i \text{ に存在する回数の期待値} \\ &= \gamma_1(s_i)\end{aligned}\tag{3.11}$$

$$\begin{aligned}\bar{a}_{s_i s_j} &= \frac{\text{状態 } s_i \text{ から状態 } s_j \text{ への遷移が観測される回数の期待値}}{\text{状態 } s_i \text{ を通る回数の期待値}} \\ &= \frac{\sum_{t=1}^{T-1} \xi_t(s_i, s_j)}{\sum_{t=1}^{T-1} \gamma_t(s_i)}\end{aligned}\tag{3.12}$$

$$\begin{aligned}\bar{b}_{s_j}(k) &= \frac{\text{出力記号 } k \text{ が状態 } s_j \text{ で出力される回数の期待値}}{\text{状態 } s_j \text{ を通る回数の期待値}} \\ &= \frac{\sum_{t=1, o_t=k}^T \xi_t(s_i, s_j)}{\sum_{t=1}^T \gamma_t(s_j)}\end{aligned}\tag{3.13}$$

通常, すべてのモデル学習データに対して, 上記の計算を行ってから, 1 回のパラメータを更新するという学習のサイクルが収束するまで繰り返される. 十分に学習した標準モデルがパターンの認識で用いられる.

3.2.2 連続分布型 HMM

連続分布型 HMM は, 出力記号を実数値として表すモデルである. 各状態からの出力確率を表す方法としては, 単一ガウス分布や混合ガウス分布が用いられる. ここで, 本論文で利用した単一ガウス分布の詳細について述べる.

連続分布型 HMM を利用する前提として, 出力確率の集合 B が平均ベクトル μ を共分散行列 Σ を持つ多次元の高ス分布 $N(\mu, \Sigma)$ に従っているとすると, 観測されたベクトルの時系列 $O = \{o_1, o_2, \dots, o_T\}$ に対して, 時刻 t に記号 o_t が状態 s_i によって出力される確率が

$$\begin{aligned}b_{s_i}(o_t) &= N(o_t; \mu_{s_i}, \Sigma_{s_i}) \\ &= \frac{1}{\sqrt{(2\pi)^n |\Sigma_{s_i}|}} \exp\left(-\frac{1}{2}(o_t - \mu_{s_i})^t \Sigma_{s_i}^{-1} (o_t - \mu_{s_i})\right)\end{aligned}\tag{3.14}$$

となる。なお、上記の式では、 n が観測ベクトルの次元数を示すパラメータである。 $(o_t - \mu_{s_i})^t$ は $(o_t - \mu_{s_i})$ の転置行列を表す。 $|\Sigma_{s_i}|$ と $\Sigma_{s_i}^{-1}$ は、共分散行列 Σ_{s_i} の固有値と逆行列である。この式 (3.14) を用いて、出力確率の集合 B を求めることができる。

連続分布型 HMM の場合では、初期確率および状態遷移確率の推定が離散分布型 HMM の場合と同様であるため、式 (3.11) と式 (3.12) がパターンの認識に用いられる。そして、モデルの学習においては、新しい出力確率の多次元の単一ガウス分布 $\bar{N}(\bar{\mu}, \bar{\Sigma})$ を次のように推定する。

$$\bar{\mu}_{s_i} = \frac{\sum_{t=1}^{T-1} \xi_t(s_i, s_j) o_t}{\sum_{t=1}^{T-1} \gamma_t(s_i)} \quad (3.15)$$

$$\bar{\Sigma}_{s_i} = \frac{\sum_{t=1}^{T-1} \xi_t(s_i, s_j) (o_t - \mu_{s_i})(o_t - \mu_{s_i})^t}{\sum_{t=1}^{T-1} \gamma_t(s_i)} \quad (3.16)$$

離散分布型 HMM のモデル学習と同様に、すべてのモデル学習データに対して、パラメータを更新するというサイクルが収束するまで繰り返される。

第4章

歩行の検出および消費エネルギーの推定

4.1 はじめに

近年、日本では食の欧米化や運動量の低下などから、メタボリックシンドロームなどの生活習慣病が社会問題化してきており、それに伴って人々の健康に対する関心も高まっている。健康的な身体を維持するためには、まず摂取エネルギーと消費エネルギーを自ら把握した上で、それに基づいて食事に気をつけたり、毎日の活動の中で積極的に活動量を増やしたりする努力をしなければならない。摂取エネルギーは食事のメニューと量で簡単に算出することができる。これらに加え、正確な消費エネルギーを知ることができれば、消費量に対応して的確な運動や食事のコントロールができるようになる。

本章では、加速度センサを搭載した携帯電話でユーザの身体活動を推定し、消費エネルギーを算出する方法を検討する。携帯電話はユーザの行動をリアルタイムで検出させるための最適なツールである。また日常生活ですでに定着した携帯電話を使うことで、消費エネルギー表示に特化したデバイスを装着するという手間を省くことができ、多くの人が気軽に利用できるツールとなることが期待される。

そもそも消費エネルギーは、基礎代謝、食事誘発性体熱産生、運動による代謝、運動以外の身体活動による代謝から構成される。基礎代謝は全消費エネルギーの50~70%を占

めるが、性別や身長、体重、筋肉量などにより定まる。食事誘発性体熱産生は食事の栄養素によって異なるが、通常の食事では全消費エネルギーの約10%であり、その割合も少ないことから誤差は小さくなると考えられる。そして、運動による代謝は約10%、運動以外の身体活動による代謝は20~30%を占めている。これら4つの要素の中でも、運動以外の身体活動による代謝がもっとも個人差が大きく、1日の全消費エネルギーを大きく左右していると考えられている。特に、もっとも基本的な活動パターンである「歩行」を検出して、その消費エネルギーを推定する必要がある。

そこで、本章では、隠れマルコフモデル (Hidden Markov Model, HMM) を用いた歩行の検出と、その結果に基づいた消費エネルギーの推定を検討する。

第3.1節で述べたプロセスに後述する具体的な方法を加えて、消費エネルギーを推定するシステムを構築する。まず、実世界の信号として、携帯デバイスに搭載した加速度センサから3軸の加速度データを計測する。そして、前処理部では、データの繰り返し点に基づいて、データを一定単位に分節する。つぎに、加速度の方向を特徴量として注目し、対応するラベルを付け、ラベルの観測時系列を生成する。そして、離散分布型 HMM を用いた認識部に、この観測時系列を入力する。最後に、認識の結果に対応する消費エネルギーを算出し、市販のアプリケーションと比較することによって、提案手法の有効性を評価する。

4.2 提案手法

4.2.1 データの収集および前処理

3次元空間中における人間の行動を記録するために、3軸の加速度センサを用いて縦方向、横方向および奥行き方向の加速度データを計測する。収集された加速度データの一例を図4.1に示す。

ここで、横軸は時間、縦軸は方向付きの加速度の大きさ、 $A(X) \cdot A(Y) \cdot A(Z)$ はそれぞれ横方向・縦方向・奥行き方向を表す。なお、この例のサンプリングレートは50Hzである。

同じ身体活動が続ければ、加速度データに同様な変化が見られるため、前処理として、




図 4.1 3 軸加速度データの一例

その繰り返しの時点を検出し、データの分節を行う。図 4.1 のデータに対して分節する方法を図 4.2 に示す。縦方向の加速度 $A(Y)$ の変化に一番規則性があると見られるため、一定の基準値 v について、加速度の値がより小さくなり始める時点から、いったん v より大きくなり、再び v より小さくなる時点までの周期を 1 単位として分節する。

4.2.2 加速度方向情報による特徴量抽出

加速度データを 1 単位ずつに分けた後、加速度の大小およびその方向を特徴量とする。3 方向の加速度 $A(X) \cdot A(Y) \cdot A(Z)$ をそれぞれの閾値と比較し、左右・上下・前後のラベルを付け、組み合わせたものを 1 つの観測シンボルとした。図 4.3 はラベルの付け方をキューブで示したものである。ここで、 $\max(X) \cdot \max(Y) \cdot \max(Z)$ と、 $\min(X) \cdot \min(Y) \cdot \min(Z)$ は、複数回の起立姿勢で静止している時の $A(X) \cdot A(Y) \cdot A(Z)$ の最大値と最小値の平均をそれぞれ表す。3 方向の加速度データが各自の方向において、「閾値以上」・「閾値以下」・「閾値以内」の場合がある。各場合に対応したラベルを付ければ、3 つのラベルによって組み合わせたものが 1 つの観測シンボルとなり、全部で 27 種類の観測シンボルが生成される。観測シンボルの生成例を表 4.1 に示す。




図 4.2 縦方向の加速度を用いたデータ分節の一例

表 4.1 観測シンボルの生成例

X	Y	Z	Symbol
$A > max$	$A > max$	$A > max$	RUF
$A < min$	$A < min$	$A < min$	LDB
$min < A < max$	$A > max$	$A < min$	CUB
$A < min$	$min < A < max$	$A > max$	LCF
$min < A < max$	$min < A < max$	$min < A < max$	CCC

本研究では、加速度の方向情報を特徴量として、時系列データをラベリングする処理によって、離散分布の記号列が生成される。このため、離散分布型 HMM を用いることにする。

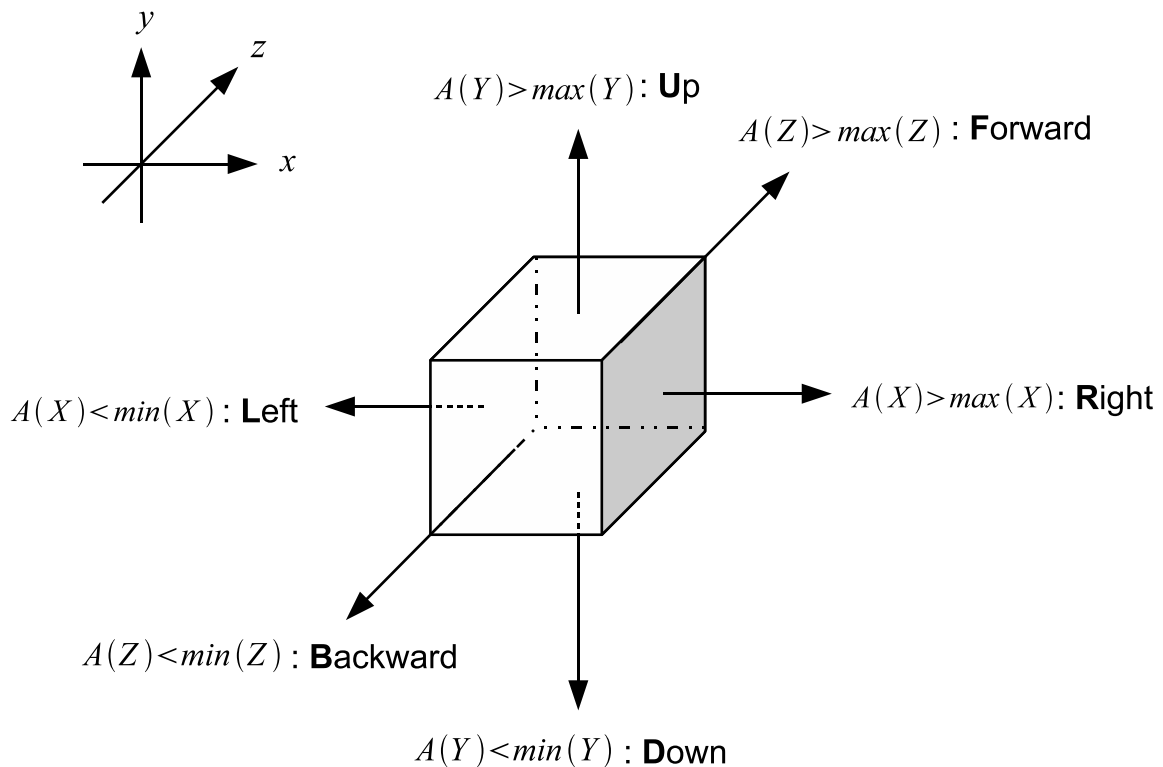


図 4.3 加速度の大小によるラベル付け

4.2.3 METs 換算法による消費エネルギー推定

本研究では、HMM によるパターン認識の結果に基づいて、METs エネルギー換算法による消費エネルギー推定を行う。METs 換算法はアメリカスポーツ医学会により提案された手法で、エネルギーの消費量は次の式で与えられる。

$$\text{消費エネルギー (kcal)} = 1.05 \times \text{運動強度 (METs)} \times \text{運動時間 (h)} \times \text{体重 (kg)}$$

METs 値は、身体運動時の酸素摂取量が安静時の酸素摂取量の何倍に当たるかを表す指標であり、安静時の運動強度を 1.0 とする。年齢や性別によらず、行動種類のみによって決まり、日常の様々な身体活動や運動について、それぞれの METs 値が定められている。このため、一般のユーザでも簡単に消費エネルギーを計算できる。また、市販のカロリー計算機にも METs 換算法が導入されている。

4.3 実験

実験では、検出の目標である「歩行」データのほか、ノイズとして、「走行」のデータも収集して用意する。提案手法で認識された結果に基づいて、それぞれに該当する METs と時間長さにより、消費エネルギーを算出する。そして、市販されるアプリケーションと比較し、「歩行」がどれくらい検出されたかを評価する。

まず、データを収集するために、実験では、携帯電話に搭載した加速度センサでの実装を想定し、加速度センサを搭載した小型携帯デバイス SunSPOT(Sun Small Programmable Object Technology) [54] を使用した。SunSPOT は Sun Microsystems 社によって開発された組み込み機器で、Java のプログラムに基づいて動作する。ARM920T(180MHz) の CPU プロセッサ、512KB の RAM メモリおよび 4MB のフラッシュメモリが搭載されている。充電式で連続動作約 7 時間が可能であり、3 軸加速度センサのほかにも、スイッチ、8 色の LED ライト、温度センサ、光センサや無線ネットワークなどが標準装備されている。実験では、Ron Goldman 氏が作成したサンプルプログラムである SunSPOTTelemetry Demo(Version 1.1) を用いて、加速度データを取得し、無線ネットワークの経由でデータをコンピュータに転送した。コンピュータ上でデータの処理から行動種類の推定、消費エネルギー計算までの処理を行った。実際に使用された SunSPOT と、データ計測の画面が図 4.4 に示されている。

一般的に、携帯電話は一人につき一台の所有が仮定できるため、複数のユーザのデータからパラメータを学習する必要がなく、単一のユーザのデータを利用すれば十分である。したがって、実験では、データの計測対象を単一の人物とした。1 人の被験者に対して、「歩く (時速 3.5Km 未満)」および「走る (時速 3.5Km 以上 5.5Km 未満)」の 2 種類の身体活動について、それぞれ 20 分間の加速度データを収集した。ここで、SunSPOT の装着場所は被験者の右ズボンの前ポケットとした。ポケット内には SunSPOT のみを入れ、SunSPOT は固定されていない状態とした。ポケットに入れるときの向きはすべて同一に設定した。3 軸加速度データのサンプリングレートは 100Hz とした。

取得した加速度データは 1 単位ごとに分節し、15 分間のデータをモデル学習に、残りの

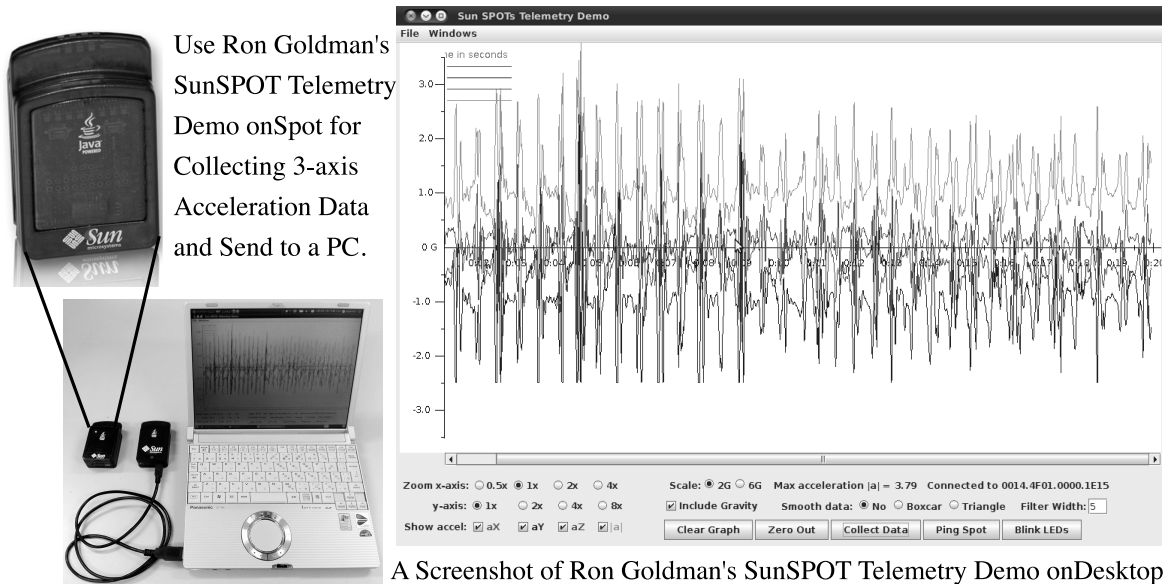


図 4.4 SunSPOT を用いた加速度データ収集

5分間のデータを認識テストに用いた。ここで、分節するための基準値 v は 1.0 とした。すなわち、上下方向の加速度の値が 1.0 より小さくなり始める時点から、いったん 1.0 より大きくなり、再び 1.0 より小さくなる時点までのデータを 1 単位として区切った。分節されたデータの特徴量を抽出して、27 個のシンボルの組み合わせによって観測時系列を生成した。これを離散分布型 HMM に入力して、標本モデルの学習または身体活動の認識を行った。離散分布型 HMM の初期パラメータは以下のように設定した。

状態数： 4

状態遷移確率：

$$A = \begin{bmatrix} 0.25 & 0.25 & 0.25 & 0.25 \\ 0.25 & 0.25 & 0.25 & 0.25 \\ 0.25 & 0.25 & 0.25 & 0.25 \\ 0.25 & 0.25 & 0.25 & 0.25 \end{bmatrix}$$

出力記号数： 27

出力確率：

$$B = \begin{bmatrix} 0.037 & 0.037 & \cdots & 0.037 & 0.038 \\ 0.037 & 0.037 & \cdots & 0.037 & 0.038 \\ 0.037 & 0.037 & \cdots & 0.037 & 0.038 \\ 0.037 & 0.037 & \cdots & 0.037 & 0.038 \end{bmatrix}$$

初期状態分布：

$$\Pi = \begin{bmatrix} 0.7 & 0.1 & 0.1 & 0.1 \end{bmatrix}$$

最後に、上記した HMM による推定の結果に基づいて、以下の METs 値を用いて消費エネルギーを算出した。

- 歩く（時速 3.5Km 未満）：3.0
- 走る（時速 3.5Km 以上 5.5Km 未満）：4.0

4.4 結果および考察

「歩行」および「走行」の 3 軸加速度データを分節化した結果、「歩行」が 2435 セット、「走行」が 3916 セットの観測シンボルの時系列となった。その中の 15 分間の観測時系列となる「歩行」の 1838 セット、「走行」の 2926 セットを学習信号として利用し、標準モデルの学習を行った。残りの 5 分間の観測時系列に対して、認識テストを行った。結果として、「歩行」の 597 セットのテストデータは 98.5%、「走行」の 990 セットのテストデータは 86.8%、全体的には平均 91.2% という精度で正しい認識結果が得られた。

つぎに、この結果に基づいたエネルギーの消費推定量を、iPhone の「歩数計」というアプリケーションで算出された結果と比較した。「歩数計」の計算方法は、ユーザが設定した歩幅と歩数から時速を推定し、その時速に対応した METs 値で消費エネルギーを計算するという方法である [55]。比較の結果では、「歩行」の消費エネルギーには 4.33%、「走行」の消費エネルギーには 25.75% の誤差率があった。

全体の実験結果として、90% 以上の「歩行」が検出され、市販のアプリケーションと比べ、遜色のない精度が得られた。したがって、本研究の提案手法が有効であると確認さ

れた。

一方、「走行」の認識結果は「歩行」の認識結果に比べ、劣っていることが分かった。離散分布型 HMM を適用するために生成された観測時系列には、加速度の方向という情報しか含まれていないことが原因であると考えられる。加速度の方向のみ特徴量として抽出したことにより、加速度の大小という身体活動の激しさを反映する要素が無視された。つまり、加速度の大きさが明らかに異なっているにもかかわらず、同様の閾値範囲に入ると、全く同じ観測シンボルが作成されることとなる。したがって、特徴量を抽出するときに、閾値の設定を見直すことなどが解決策として考えられる。

4.5 まとめ

本章では、もっとも基本的な行動パターンである「歩行」の検出に注目し、消費エネルギーの推定を応用して、行動情報の推定システムを提案した。この提案システムについて、基本的なプロセスの枠組みを示した。以降の各章においても、この処理プロセスを利用する。そして、消費エネルギーを推定するための具体的な方法について記述した。特に、加速度の方向情報を特徴量として抽出する方法と、離散分布型 HMM の適用を提案し、実験を通じてそれらの有効性・可能性を検討した。その結果、90% 以上の「歩行」が検出され、市販のアプリケーションに劣らない消費エネルギー推定精度が得られた。すなわち、本研究の提案手法が有効であることが確認された。

第 5 章

データの自動組織化および階段環境の推定

5.1 はじめに

本章では、第 4 章で示した基本的な提案システムについて、標準パターンモデルの自動組織化を検討する。

一般的には、認識の精度をより高めるために、モデル学習に用いられるデータがより多く必要となる。これまで、モデル学習の方法が提案されたが、所望の行動情報にあわせて、事前に学習データを用意する必要がある [56, 57]。このため、同じ行動種類に対しても、行動環境などが異なるだけで、それらのデータを別々に収集して、モデルを学習しておく必要がある。たとえば、同じ「歩行」という行動について、平坦地の環境から階段の環境に変わると、階段では、「上る」と「下りる」となるため、標準パターンモデルにおいて、「歩行」のカテゴリ化が必要である。

そこで、本章では、センサから得られる時系列データを予め分類せず、自動的なクラスタリングによって、標準パターンモデルを自動組織化する手法を提案する。まず、加速度データの分布特徴を適用することを検討する。そして、データの事前分類を行う労力と恣意性に関する問題の解決を図るために、競合学習法を利用して、単一の HMM から始め、十分に認識できない時系列データが得られた時に、自動的に新たな HMM の学習を行う。

最後に、階段環境の推定実験を通じて、加速度データの分布特徴を用いた認識・学習の有効性を確認し、標準モデルの自動組織化手法として利用する際の可能性を考察する。

5.2 競合学習法による自動分類

本研究の提案手法は、4.2 節において記述した提案手法とほぼ同様な処理の流れである。まず、実世界の信号として、携帯デバイスに搭載した加速度センサから 3 軸の加速度データを計測する。つぎに、連続した加速度データの大きさ情報を保留するため、特別な前処理と特徴抽出をせず、そのまま認識・学習のプロセスに入力する。そして、認識部において、加速度データ数値の大きさ分布特徴を反映させるために、データをそのままの連続値で取り扱える連続分布型 HMM を適用し、競合学習法による認識・学習を行う。

HMM はモデル学習および認識が可能なモデルであり、一般的に、入力された行動パターンがもっとも類似した HMM の学習信号として利用される。このほか、入力データを新規追加する HMM の学習信号として利用することも可能とされる [58,59]。

そこで、本研究では、入力データを自動組織化するために、下記の手順で行う競合学習法を適用する。図 5.1 にその流れを示す。

1. 標準モデルに HMM がまだ一つもない状態であれば、2 および 3 をスキップして、4 に進む。
2. すでに標準モデルに HMM が一つ以上あれば、各 HMM を用いて観測時系列の出力確率の計算を行う。
3. 観測時系列の出力確率が設定した閾値 w の範囲内であれば、その中の最大値となる HMM を認識結果として選び、4 をスキップして、5 に入力する。そうでなければ、既存のどの HMM も選択しない。
4. 初期パラメータをランダムに設定した HMM を 1 つ追加する。
5. 観測時系列を教師信号として、入力された HMM のパラメータを Baum-Welch アルゴリズムにより更新する。
6. すべての観測時系列が学習に利用されたら、モデル学習を終了する。そうではない場合には、次の観測時系列を入力として、1 に戻る。

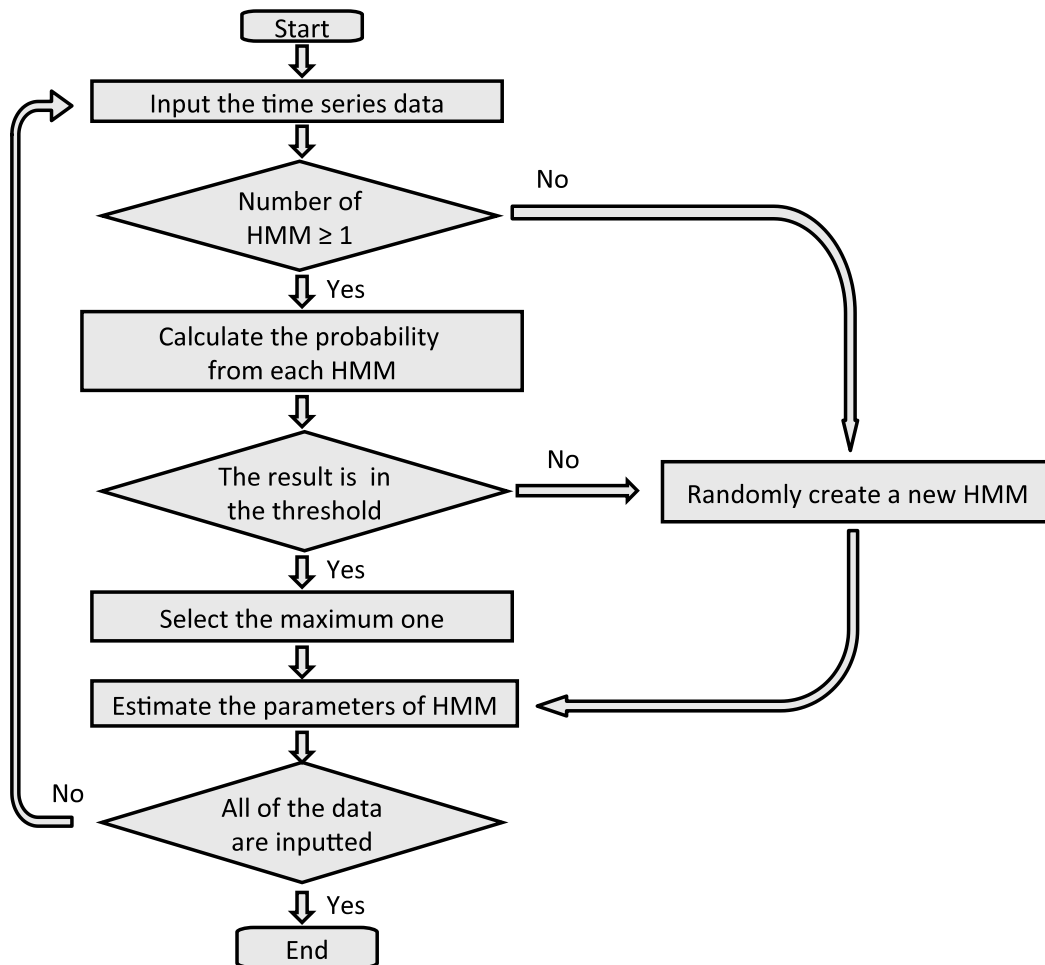


図 5.1 競合学習法適用の流れ

1~6 の手順により，身体活動の自動分類および HMM のパラメータ更新を繰り返しながら，標準モデルを構築していく。

5.3 実験

実験では，カテゴリ化する対象の「歩行」，「階段を上る」，「階段を下りる」とノイズデータの「走る」の 4 種類の行動に対して，離散分布型と連続分布型の 2 種類の HMM を用いて認識実験を行い，データを自動組織化する可能性について検討する。

まず，データを収集するには，3 軸加速度センサを搭載した携帯電話 iPhone [60] を使用した。iPhone は Apple 社製のスマートフォンであり，マルチタッチパネルや加速度センサなどを生かして，従来にはない特徴的なユーザインターフェイスで注目を集めてい

表 5.1 各身体活動の観測時系列の番号

Body Motion	Sequence
Walk	0, 1, 2, 3, 4
Climb Up Stairs	5, 6, 7, 8, 9
Go Down Stairs	10, 11, 12, 13, 14
Run	15, 16, 17, 18, 19

る。実験で使用した iPhone は下記の仕様である。

- 機種：iPhone 4
- オペレーティングシステム：iOS 4.2.1
- CPU プロセッサ：Apple A4(1GHz)
- RAM メモリ：512MB
- ストレージ：32GB

3 軸の加速度データを収集して、無線ネットワーク経由でコンピュータに転送するために、iPhone 側では HASC Logger [61]、コンピュータ側では HASC Tool [62] を用いた。実際のデータ収集の様子を図 5.2 および図 5.3 に示す。iPhone 4 の装着場所は被験者の右ズボンの前ポケットとした。ポケット内には iPhone 4 のみを入れておき、特に固定されていない状態とした。ポケットに入れる方向はすべて同様であるようにした。3 軸加速度データのサンプリングレートは 100Hz とした。また、データを分節しないように、短時間でデータを収集することにした。同じ 1 人の被験者に対して、「歩行」「走行」「階段を上る」「階段を下りる」の 4 種類の身体活動について、それぞれ 20 秒間の 3 軸加速度データを 5 セット収集した。これらに表 5.1 の番号を付けておいた。

離散分布型 HMM を適用したパターン認識・学習の場合では、4.2.2 節で述べたように、加速度の方向情報を特徴量とした 27 個のシンボルを組み合わせ、観測時系列を生成した。その離散分布型 HMM の初期設定も第 4 章の実験と同様とした。一方、連続分布型 HMM の場合では、出力記号は連続値であるため、離散分布型 HMM のように観測シン



図 5.2 HASC Logger を用いた加速度データ収集

ボルを生成する必要がなく，加速度データの実数値をそのままモデルの認識と学習に利用した。

2 種類の HMM にそれぞれの観測時系列をランダム順番で入力して，競合学習法に適用し，認識および学習を繰り返しながら，標本モデルを構築した。なお，閾値 w を 500 と 250 の 2 種類に設定して，最大値の選択で利用した。ここで，閾値範囲とは，各既存の HMM において，すでに教師信号とされたすべての観測時系列の出力確率の平均値から $\pm w$ の範囲である。

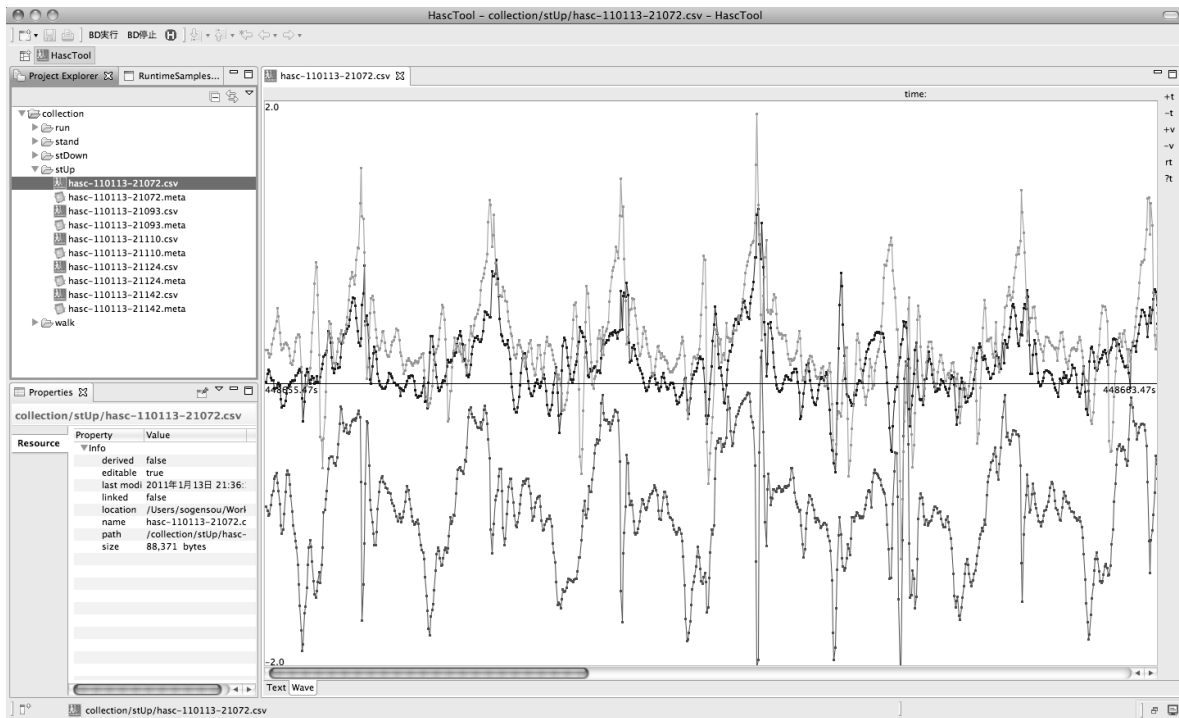


図 5.3 HASC Tool を用いた加速度データ収集

表 5.2 閾値 $w = 500$ のときの分類結果

Resource	by Discrete HMM	by Continuous HMM
HMM ₁	0, 1, 2, 3, 4, 13, 15, 16, 17, 18, 19	15, 16, 17, 18, 19
HMM ₂	5, 6, 7, 8, 9	2, 3, 4
HMM ₃	10, 11, 12, 14	0, 1, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14

5.4 結果および考察

合計 20 セットのデータを観測時系列として、ランダムな順番で離散型 HMM と連続分布型 HMM に入力し、確率計算の結果を設定した閾値と比べながら、データ分類およびモデル学習を行った。

まず、閾値 w を 500 に設定した実験の結果を表 5.2 に示す。この結果を表 5.1 と照合すれば、離散分布型 HMM の場合では、HMM₂ が「階段を上る」であることと、HMM₃ が

表 5.3 閾値 $w = 250$ のときの分類結果

	by Discrete HMM	by Continuous HMM
HMM ₁	0, 1, 17, 18, 19	10, 15, 16, 17, 18, 19
HMM ₂	2, 3, 4, 15, 16	1, 2, 3, 4
HMM ₃	5, 6, 7, 8, 9	0, 5, 6, 7, 8, 9
HMM ₄	10, 11, 12, 13, 14	11, 12, 13, 14

「階段を下りる」であることが考えられる。しかし、HMM₁ では、異なる身体活動の「歩行」と「走行」が同じクラスに分類された。一方、連続分布型 HMM の場合では、HMM₁ が明らかに「走行」で、HMM₂ がおそらく「歩行」であると見られる。ここで、実験のノイズデータである「走行」のパターンが明確された。さらに、HMM₃ では、歩行という同じパターンの身体活動が同じクラスに分類できた。このため、連続分布型 HMM が離散分布型 HMM より、データの自動組織化に適している可能性が高いと考えられる。

また、表 5.3 に閾値を 250 に設定した実験の結果を示す。この結果を表 5.1 と照合した結果、まず、自動分類されたクラスの数、人間の主観的な分類と一致していることが分かった。離散分布型 HMM と連続分布型 HMM の両方の結果において、HMM₁ は「走行」、HMM₂ は「歩行」、HMM₃ は「階段を上る」、HMM₄ は「階段を下りる」である可能性が極めて高いと見られる。クラスの内容が離散分布型 HMM で 80%、連続分布型 HMM で 90% 正確に配置された。競合学習法の適用によって、HMM が逐次的に観測時系列の分類・学習を行ったと考えられる。

これら 2 回の実験結果を比較すると、閾値を小さくすることにより、良好な分類精度が得られることが分かる。離散分布型 HMM の場合では、ただ単純に 4.4 節で考察されたような誤認識を修正した効果として見られた。これに対して、連続分布型 HMM は、「走行」という異なる身体活動パターンを明確に除き、階段の「上り」と「下り」に関係なく、歩行という同じパターンの身体活動を同じクラスに分類した。これは、加速度データの大きさ情報が含まれた分布特徴を利用したことによるものであると考えられる。そして、閾値を小さくしたあと、多少エラーを含みながらも、階段での歩行を「上り」と「下り」の両

方に分離できた。表 5.2 の考察で述べた連続分布型 HMM の適用可能性を支持した。このため、連続分布型 HMM と競合学習法の適用によって、時系列データから逐次的に組織化するというダイナミックなモデル構築が可能であることが明らかになった。この実験の全体を通じて、本研究の提案手法の有効性と可能性を確認することができた。

5.5 まとめ

本章では、標準パターンモデルの自動組織化について検討した。まず、連続分布型 HMM による認識と学習を通じて、平坦地以外の複雑な行動環境への適応を図った。第 4 章において提案した離散分布型 HMM との違いを明確に記述した。そして、競合学習法の適用によって、時系列データを逐次的に組織化することを提案した。その具体的なアルゴリズムを図示しながら、処理の流れを説明した。実験において、「歩行」と「階段における歩行」のカテゴリ化を例題として取り上げた。「歩行」「階段を上る」「階段を下りる」「走行」の 4 種類の身体活動について、離散分布型 HMM と連続分布型 HMM の両方を利用した分類実験を行った。高精度の認識分類率が得られ、それぞれの結果の比較と考察をした。考察によって、提案手法である連続分布型 HMM と競合学習法の適用は、離散分布型 HMM と比べ、ダイナミックに標準モデルを構築するために、有効である可能性が高いことを確認した。

今後の課題として、より有効でサイズの小さい特徴量を検討する。これまでの研究では、加速度の方向情報に注目して、ラベリングによってシンボルの時系列に変換したり、加速度の分布特徴に注目して、数値データをそのまま特徴量として利用したりしてきた。これらの手法は、データの長さに依存しているため、計算量が大きいと考えられる。

第6章

周期特性の抽出および個人属性・履物環境の推定

6.1 はじめに

本章では、第4章で示した基本的な提案システムに従い、特徴量の抽出について検討する。

一般的に、モデル学習と認識のための特徴量によって、その特徴空間におけるモデルの分布に差異が発生する。冗長で大きいサイズの特徴量もあれば、有効で小さいサイズの特徴量もあると考えられる。これは計算量に関わる問題であるため、どの特徴量をもとにモデルの学習と認識を行うのかという検討すべき課題となる。これまで、本論文では、加速度の方向情報および分布特徴を特徴量として利用してきた。その有用性も実験において評価された。これらの方法では、特徴量のサイズが入力データの長さと同様であった。しかし、人間の身体活動が類似したパターンの繰り返しと見られるため、その周期特性を利用すれば、特徴量のサイズを圧縮することができると考えられる。そして、これまでの計測手法と同様であっても、効果の向上として、環境要因以外の個人属性や性別などといった個人属性も同時に把握できる手法を検討する。

また、人間の身体活動について、同じ環境での同じ行動において、行動者の個人差が存在することは容易に考えられる。逆に、同じ行動者でも違う環境においては、行動の差が

発生すると考えられる。

そこで、本章では、人間の歩行信号に環境要因と個人属性が反映されているという仮定で、加速度データがそれぞれの畳み込んだ波形信号であるとして、LPC (Linear Predictive Coding, 線形予測法) ケプストラム分析を利用し、環境要因と個人属性に関する周期情報を特徴量として抽出する手法を提案する。そして、履物と個人属性・性別の推定実験を通じて、提案手法の有効性と可能性を考察する。

6.2 提案手法

6.2.1 データの収集および前処理

本研究の提案手法は、第5章の提案手法と同じように3.1節において記述したプロセスを基本とする。まず、携帯デバイスに搭載した加速度センサから得られる3軸の加速度データに対して、前処理部では、加速度の合成や時間単位フレームの切り出し、窓関数の適用を行う。つぎに、LPC ケプストラム分析を用いて、加速度データの周波数成分に基づいた情報を特徴量として抽出する。そして、この特徴量を分類認識部に入力し、事前に用意した標準パターンの識別辞書と比較することによって、どのパターンに属しているかを推定し、それを認識の結果とする。最後に、この認識結果をさらなる応用の入力情報とする。

データの収集は、これまでの研究と同様に、4.2.1節で述べた3軸の加速度センサを用いた方法に基づいて行われる。これに加えて、LPC ケプストラム分析を適用するために、以下の前処理を施す。

加速度の合成

特定方向の加速度を観察せず、その全体を一つの波形信号として扱う。このために、前処理として、下記の式(6.1)で3軸の加速度を合成する。

$$r = \sqrt{x^2 + y^2 + z^2} \quad (6.1)$$

図6.1に示したように、端末の保持状態に関わらず、周期特性をもっている加速度の大きさ r を利用することになる。




図 6.1 3 軸加速度の合成方法

周波数帯域の強調

そして、周期特性をより明確させるために、合成加速度データの特定の周波数成分を強調する有限インパルス応答 (Finite Impulse Response, FIR) フィルタを適用する。FIR フィルタは

$$y(n) = \sum_{i=0}^N b(i)x(n-i) \quad (6.2)$$

と定義され、 $x(n)$ は入力信号、 $y(n)$ は出力信号、 $b(i)$ は重み係数、 N は利用する過去の信号の数である。つまり、最新の出力信号 $y(n)$ を得るために、最も近い入力信号 $x(n)$ だけでなく、その N 個前までの信号 $x(n-i)$ も重み $b(i)$ を付けて算出に用いられる。過去の信号数 N とそれぞれの重み係数 $b(i)$ の設計によって、低周波数成分だけ通せるローパスフィルタ (Low Pass Filter) と、高周波数成分だけ通せるハイパスフィルタ (High Pass Filter) を作成できる。また、どちらも通過させ、単純に高周波数成分のみ強調するプリアンファシスフィルタ (Pre-emphasis Filter) も実現できる。こうした FIR フィルタの適用によって、たとえば、人間の歩行の基本周波数とされる 2Hz の周辺帯域を強調して、その特性を明確にすることができる。




図 6.2 一つの時間単位フレームの設定

時間単位フレームの切り出し

つぎに、上記の処理を施したデータに対して、データの切り出し作業を行う。フレームとは、特徴量を抽出するために必要なデータ数のことである。実際にサービスを提供するために、可能な限りで短い時間の単位で行動推定を行う必要があると考えられる。図 6.2 に示した一例では、フレーム区間を 1000 ミリ秒間に設定した。データ収集のサンプリングレートは 100Hz であるため、つまり、一つの時間単位フレームにつき 100 個の値が含まれる。そして、各データセットの先頭よりフレームを切り出し、その開始時点を 200 ミリ秒間 (20 個の値) ずつ後方へずらしていく。たとえば、長さ 10 秒でデータ値 1000 個のデータセットがあるとして、この前処理では、計 45 個のフレームが得られる。




図 6.3 矩形窓とハミング窓を適用した合成加速度の波形

窓関数の適用

最後に切り出した合成加速度のフレームに対して窓関数を適用する。周波数分析を行う際に、フーリエ変換が行われる。フーリエ変換の前提は、その対象が周期関数の波形であるとされている。しかし、一般的に、波形信号の両端がきれいにつながらず、周期関数にならないという問題がある。このため、収集したデータに窓関数を適用する、これによって、両端が滑らかにつながる周期関数になり、フーリエ変換を有効に行うことができる。ハニング窓 (Hanning Window) やハミング窓 (Hamming Window) などがよく用いられる。このほか、このような特殊な窓関数を使わない時は、矩形窓 (Rectangle Window) とされている。図 6.3 に矩形窓とハミング窓を適用した合成加速度データの一例を示す。ハミング窓の適用によって、波形信号の両端が滑らかになっていることが分かる。

6.2.2 LPC ケプストラム分析による特徴量抽出

上述した前処理が施されたデータが特徴抽出部に入力され、LPC ケプストラム分析の適用によって、データの周期特性が特徴量として抽出される。以下、このLPC ケプストラム分析について述べる。

ケプストラム分析

ケプストラム (Cepstrum) とは、スペクトラム (Spectrum) からの造語である。波形信号をフーリエ変換して得たスペクトルの対数を取り、さらに逆フーリエ変換した結果を指す。もともとのケプストラム分析は、地震のスペクトル分析において考案された手法で、直接波の成分とエコーの成分を分離することが研究目的であった [63]。その後、ピッチ抽出法として音声信号処理に適用され、その有効性が示された [64]。

音声信号は、声帯の振動や摩擦による乱流などの音源信号に、声道・口腔・鼻腔の形状などといった調音フィルタが畳み込まれたものであると考えられる。一般的に、スペクトル領域では音源信号のパワースペクトルが微細な構造を持っているのに対して、調音フィルタの振幅伝達特性は滑らかな形状をしていることが知られている。ここで、周波数を時間に見立てると、音源信号がスペクトル領域での「高周波数成分」、調音フィルタがその「低周波数成分」にそれぞれ対応する。ケプストラム分析では、この性質を利用して音源信号と調音フィルタの両者を分離する。音源信号のスペクトルを $S(\omega)$ 、調音フィルタを $H(\omega)$ で表すと、この音源信号に調音フィルタが畳み込まれた音声信号のスペクトル $Y(\omega)$ は

$$Y(\omega) = S(\omega)H(\omega) \quad (6.3)$$

となる。この式 (6.3) に対して、対数を取ると、

$$\log |Y(\omega)| = \log |S(\omega)| + \log |H(\omega)| \quad (6.4)$$

となり、音声信号の対数スペクトルが、単純に音源信号と調音フィルタの対数スペクトルの足し合わせた結果となる。

一般的に、スペクトル領域を逆フーリエ変換すると、元の時間波形に戻れるが、ここで

対数を取ったため、元の時間領域に戻らず、ケプストラム領域になる。ケプストラムの変数の次元が、時間ではなく周波数の逆数のようなものとなり、周波数 (Frequency) からの造語でケフレンシ (Quefrequency) と呼ばれる。ここで、スペクトル領域の「高周波数成分」である音源信号 $\log |S(\omega)|$ と、「低周波数成分」である調音フィルタ $\log |H(\omega)|$ に対するフーリエ変換を行うことであると考えれば、音源信号は調音フィルタに比べて、高いケフレンシ次元に集中することが考えられる。つまり、低次のケプストラムに調音フィルタの性質、高次のケプストラムに音源の性質がそれぞれ表れる。したがって、ケプストラムにフィルタを適用すれば、両者を近似的に分離することが可能である。このフィルタをケプストラム係数で表現する。スペクトラム包絡と微細構造を分離するためのケプストラムの範囲を、ケフレンシ次元の昇順に決定するフィルタである。ケプストラム係数が小さいほどにスペクトラム包絡が滑らかなになり、大きいほどに微細構造が多く含まれると考えられる。なお、このフィルタを適用することが、フィルタリング (Filtering) からの造語でリフタリング (Liftering) と呼ばれる。

本研究では、以上の考え方に基づいて、ケプストラム分析を人間の身体活動に適用する。一般的に、人間の身体活動には体内の中枢パターン発生器 (Central Pattern Generator, CPG) によって生成する行動リズムと、外部からの影響や環境条件に対して発生するインパルス応答が含まれるとされる [65, 66]。たとえば、図 6.4 に歩行状態の加速度データとフーリエ変換から得られたスペクトル領域を示す。スペクトル領域にいくつかのピークが存在することが確認できる。歩行の基本周波数は 2Hz 程度であると言われ、図中の最大ピークが現れるところであると考えられる。また、これを比例した倍数のところにもほかのピークが存在する。これらは基本周波数に依存しているものと思われる。特に、基本周波数の約 5 倍は、接地による衝撃加速度のもので、この帯域付近の微細構造成分は接地面の状態や靴・装具の影響を受けたものであるとされる [67]。つまり、人間の身体活動のスペクトル領域とする式 (6.3) では、滑らかな形状をしているスペクトル包絡 $S(\omega)$ が基本リズムに対応して、一方、スペクトル微細構造 $H(\omega)$ が外乱に対するインパルス応答に対応すると考えられる。

図 6.4 の加速度データに対して、ケプストラム分析を行った結果を図 6.5 に示す。ここで、縦軸はケプストラムで、横軸は時間ではなくケフレンシである。低次部分にスペクト




図 6.4 加速度データの時間波形とスペクトラム領域

ル包絡，高次部分にスペクトル微細構造が現れる．ケプストラム係数 50 でリフティングして，スペクトル包絡を抽出した結果を図 6.6 に示す．滑らかなスペクトル包絡は，スペクトル全体の大域特徴を表している．なお，リフティングするケプストラム次数が小さいほどスペクトル包絡は滑らかに，大きいほど細くなる傾向があるとされる．

線形予測法 (LPC)

線形予測法 (Linear Predictive Coding, LPC) は，以下の式 (6.5) を用いて，時間領域においた過去の信号から，未来の信号を予測する手法である．

$$\hat{y}_n = - \sum_{i=1}^k \alpha_i y_{n-i} \quad (6.5)$$




図 6.5 加速度時間波形から得られたケプストラム

ここで、時刻 n の信号の予測値は、LPC 次数と呼ばれる過去 k 個の信号値に線形予測係数 α_i で重み付けして、合計したものである。線形予測係数 α_i は、信号値 y_n と予測値 \hat{y}_n の二乗誤差が最小になるように求められる。誤差関数が

$$\begin{aligned}
 E &= \sum_{n=-\infty}^{\infty} (y_n - \hat{y}_n)^2 \\
 &= \sum_{n=-\infty}^{\infty} (y_n - (-\sum_{i=1}^k \alpha_i y_{n-i}))^2 \\
 &= \sum_{n=-\infty}^{\infty} (\sum_{i=0}^k \alpha_i y_{n-i})^2
 \end{aligned} \tag{6.6}$$

で定義される。ここで、 $\alpha_0 = 1$ と定義し、誤差関数の偏微分と

$$\frac{\partial E}{\partial \alpha_j} = 0, 1 \leq j \leq k. \tag{6.7}$$




図 6.6 図 6.5 の例から抽出したスペクトル包絡

とする時, 信号 y_n の自己相関

$$R_l = \sum_{n=-\infty}^{\infty} y_n y_{n+l} \quad (6.8)$$

を導入し, k 個の連立方程式

$$\sum_{i=0}^k \alpha_i R_{|j-i|} = 0, 1 \leq j \leq k. \quad (6.9)$$

が得られる. 式 (6.9) を行列で書くと,

$$\begin{bmatrix} R_1 & R_0 & R_1 & \cdots & R_{k-1} \\ R_2 & R_1 & R_0 & \cdots & R_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ R_{k-1} & R_{k-2} & \cdots & R_2 & R_1 \\ R_k & R_{k-1} & \cdots & R_1 & R_0 \end{bmatrix} \begin{bmatrix} 1 \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_k \end{bmatrix} = 0 \quad (6.10)$$

変形すると，連立方程式が

$$\begin{bmatrix} R_0 & R_1 & \cdots & R_{k-1} \\ R_1 & R_0 & \cdots & R_{k-2} \\ \vdots & \vdots & \ddots & \vdots \\ R_{k-1} & R_{k-2} & \cdots & R_0 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_k \end{bmatrix} = - \begin{bmatrix} R_0 \\ R_1 \\ \vdots \\ R_{k-1} \end{bmatrix} \quad (6.11)$$

となる．この式 (6.11) は，ユール・ウォーカー方程式 (Yule-Walker Equation) と呼ばれる．この中の行列は，テプリッツ行列 (Toeplitz Matrix) と呼ばれる形式であるため，テプリッツ行列の特性を利用して，レビンソン・ダービン再帰法 (Levinson-Durbin Algorithm) というアルゴリズムで高速に解くことができる [68]．解の集合 $A = \{\alpha_0, \alpha_1, \dots, \alpha_k\}$ を LPC 係数といい， k を LPC 次数と呼ぶ．LPC 次数 k が大きいほど，より過去の信号までさかのぼって予測を行う．

LPC ケプストラム分析では，この予測信号に対してケプストラム分析を行う．図 6.7 に示したように，元の波形信号に対するケプストラム分析と比べて，スペクトルのピーク特徴をより鮮明に抽出することができる．また，図 6.8 に示しているように，LPC 次数 k が大きいほど，より多くの過去信号を用いて予測を行い，抽出したスペクトル包絡のピーク特徴が元の波形に近似していく．

フォルマント情報

フォルマントとは，スペクトル領域で時間的に移動している複数の局所的ピークのことです．周波数の低い順に第一フォルマント F1，第二フォルマント F2 などとする．図 6.8 の左上図に F1F2 の一例を示す．

音声信号におけるフォルマント周波数は，調音フィルタと関係し，人間の個人差や性差もフォルマントの違いを生む原因とされる．発音する音韻が同じであれば，違う人間でもそのフォルマント情報が類似する．このため，スペクトル包絡から抽出したフォルマントが，音声認識や話者識別などによく用いられる [69–71]．

したがって，人間の行動信号を分析する際にも，スペクトル包絡からフォルマントを抽出すれば，その波形信号の行動情報を分類認識することが可能であると考えられる．図 6.9 に LPC ケプストラム分析で抽出した歩行者 4 人の F1F2 分布図を例示する．それぞれの分布特徴が違うことを目視で確認できる．

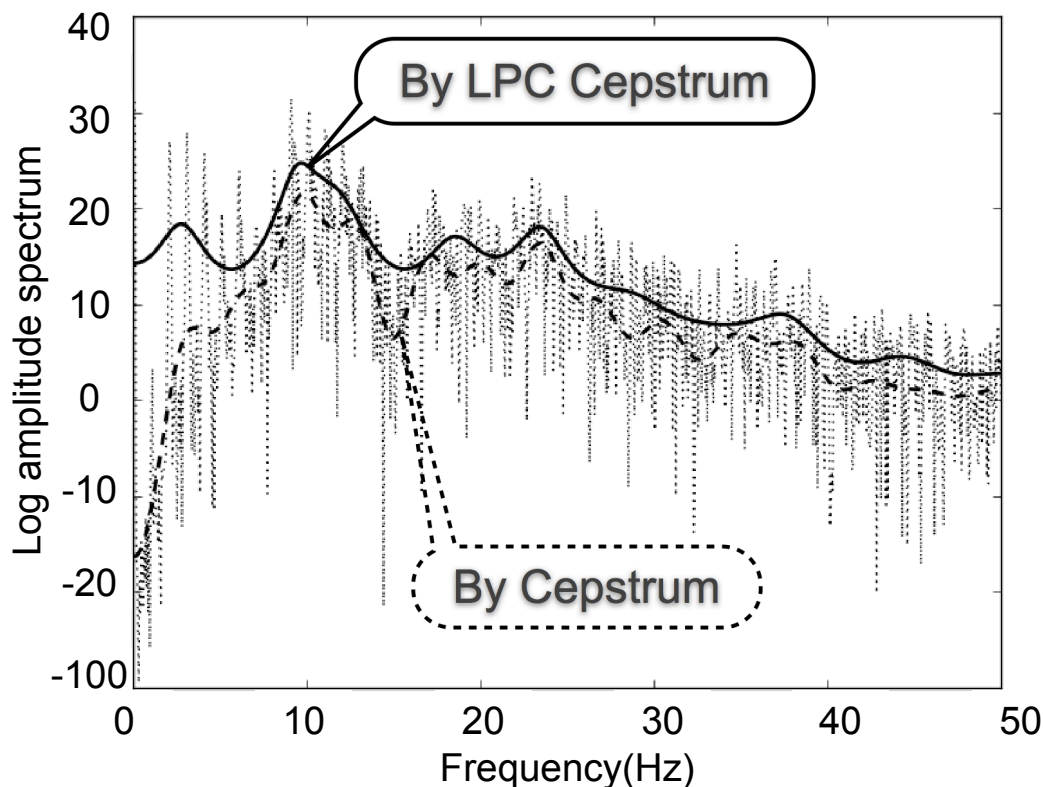


図 6.7 ケプストラム分析と LPC ケプストラム分析で抽出したスペクトル包絡

そこで、本研究では、LPC ケプストラム分析によってスペクトル包絡を抽出し、そのフォルマント情報に着目し、個人属性や行動環境に対する分類認識の可能性を考察する。

6.2.3 EMD による特徴量間距離評価

本研究では、特徴量として抽出されたフォルマントの次元数に相当した特徴空間において、各特徴量間の距離を算出し、距離の近いデータから同じクラスを認識する。距離の計算尺度として、EMD(Earth Mover's Distance)を使用する。

EMD とは、図 6.10 に示したような二つの特徴量集合が与えられた時、両分布間にわたる各特徴量の距離を算出し、これらに基いて特徴量集合間の距離を求める尺度である。EMD のアルゴリズムを以下に示す。

まず、特徴量集合を $P = \{(p_1, w_{p_1}), \dots, (p_m, w_{p_m})\}$ と $Q = \{(q_1, w_{q_1}), \dots, (q_n, w_{q_n})\}$ とする。 p_i と q_j は特徴量の値で、 w_{p_i} と w_{q_j} が対応した重みである。 p_i から q_j までの

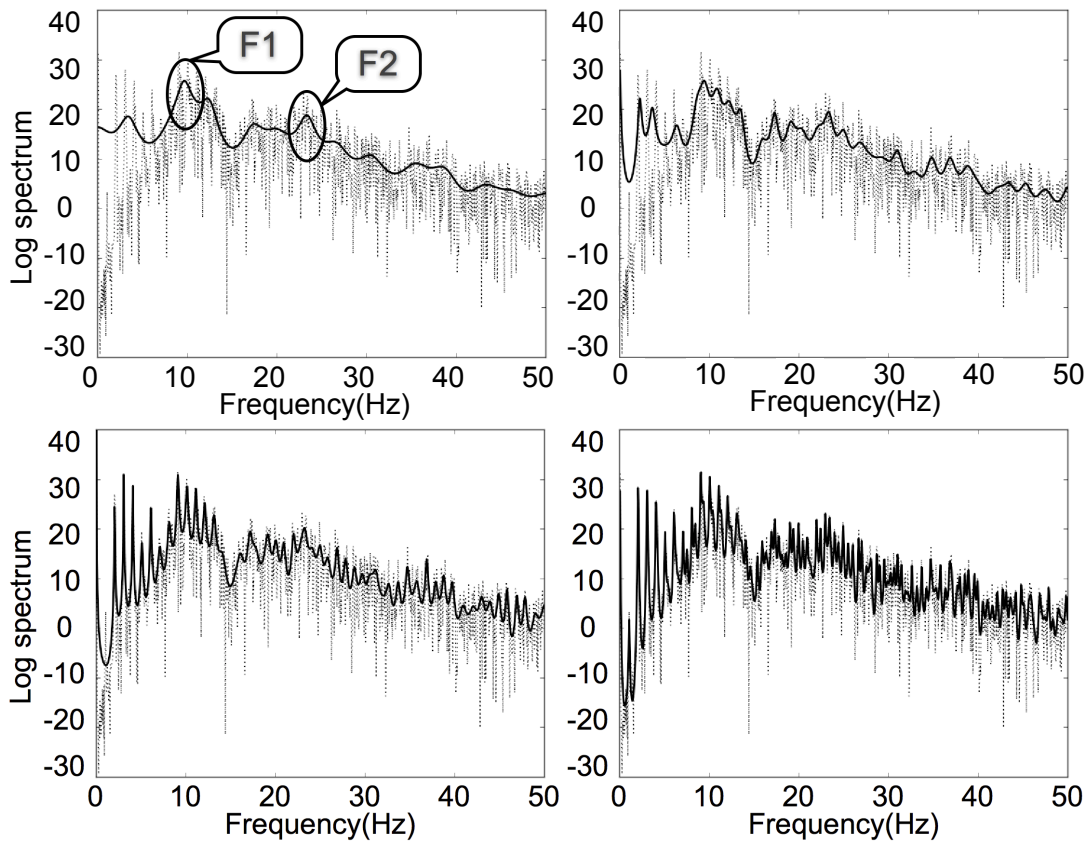


図 6.8 LPC 次数 k : 左上 32, 右上 64, 左下 128, 右下 256

距離を d_{ij} として、重みによるフローを f_{ij} とすると、全コストを

$$W(P, Q, F) = \sum_{i=1}^m \sum_{j=1}^n d_{ij} f_{ij} \rightarrow \min \quad (6.12)$$

で求める。典型的な最適化問題の一つである輸送問題 (Transportation Problem) の考え方から見ると、 P の各場所 P_1, \dots, P_m には、重み w_{p_1}, \dots, w_{p_m} の量だけの荷物が積まれているのに対して、 Q の各場所 Q_1, \dots, Q_n には重み w_{q_1}, \dots, w_{q_n} の量だけを格納できる倉庫がある。 P_i から Q_j へ輸送する距離を d_{ij} とし、 P_i から Q_j へ輸送する荷物量を f_{ij} とすると、 P_i から Q_j への仕事量が $d_{ij} f_{ij}$ となる。この考え方は、距離が遠いところに大量の荷物を運ぶ時、それだけ仕事量が増えるという自然な感覚と一致している。

そして、式 (6.12) のとおり、 P にある荷物をすべて Q に運ぶ時、どこからどこへどれぐらい運べれば、効率が一番良いかを求めるのが問題である。このため、 d_{ij} はユークリッド距離などで簡単に計算できるので、最適化するのには f_{ij} である。 f_{ij} を下記の 4 つの制




図 6.9 LPC ケプストラム分析で抽出した歩行者 4 人の F1F2 分布図

約条件に満たすように最適化する.

1. 必ず P から Q へ輸送しなければいけない.

$$f_{ij} \geq 0, (1 \leq i \leq m, 1 \leq j \leq n).$$

2. P_i にある荷物以上を輸送することができない.

$$\sum_{j=1}^n f_{ij} \leq w_{p_i}, (1 \leq i \leq m).$$

3. Q_j にある倉庫の容量以上の荷物を受けることができない.

$$\sum_{i=1}^m f_{ij} \leq w_{q_j}, (1 \leq j \leq n).$$

4. 輸送される荷物量の上限は荷物総量と倉庫総容量の少ない方である.

$$\sum_{i=1}^m \sum_{j=1}^n f_{ij} = \min(\sum_{i=1}^m w_{p_i}, \sum_{j=1}^n w_{q_j})$$

最適化された f_{ij}^* を利用して, 輸送量によって EMD のスケールが変わらないように正

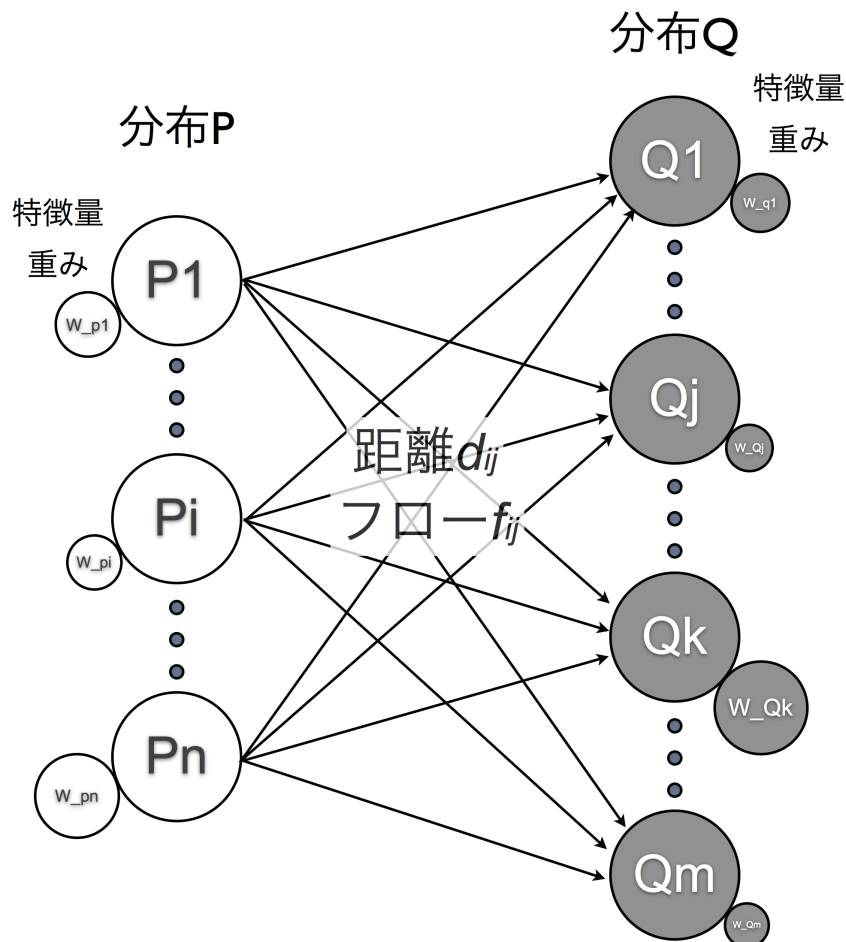


図 6.10 特徴量集合 P と Q の EMD 距離

規化し、特徴量集合 P と Q の EMD 距離を

$$EMD(P, Q) = \frac{\sum_{i=1}^m \sum_{j=1}^n d_{ij} f_{ij}^*}{\sum_{i=1}^m \sum_{j=1}^n f_{ij}^*} \quad (6.13)$$

で算出する。

6.3 実験 1

実験 1 では、6.2.2 節の提案手法である LPC ケプストラム分析を利用して、6.2.2 節で述べたようにフォルマント情報を抽出し、行動者の個人認識および、環境要因の一つとして考えられる履物の認識に適用する。この実験を通じて、個人性や履物環境といった行動情報の分類認識におけるフォルマント情報の有効性を、従来の典型的な特徴量である平均

表 6.1 コンテキスト情報認識実験のデータ収集方法詳細

行動種類	同じ廊下における平地歩行
被験者	20 代～40 代健康男性 7 人
各履物状態 の被験者数	裸足: 4 人, クロックス: 4 人, スリッパ: 4 人, 革靴: 2 人, スニーカー: 5 人, ブーツ: 1 人.
使用端末	iPhone 5
ソフトウェア	iPhone 側: HASC Logger, PC 側: HASC Tool
装着場所	左ズボンポケット
サンプリング	100Hz, $\pm 2.3G$
取得回数	一人につき履物あたり 10 秒間の 10 回

値や最大値・最小値などと比較する。

また、6.2.2 節の図 6.4 で示したように、身体活動の低周波数帯域に基本リズムを表す成分、高周波数帯域に環境要因を表す成分が集中すると考えられる。これを検証するために、両者を強調するように前処理を施し、行動者の個人性と履物の認識実験を行い、その認識への影響を確認する。

まず、データ収集は第 5 章の実験と同様に、iPhone を利用して行った。本実験では、個人差と環境要因の一つである履物に注目するため、平地歩行といった限定された条件で、データの収集を行った。表 6.1 にその詳細を示す。各履物状態の被験者数が同様ではなかったため、合計 20 回のデータ収集を行った。したがって、実験用のデータ数が 200 セットとなった。ここで、「被験者名」というカテゴリに被験者別に 7 つのクラス、「履物種類」というカテゴリに履物種類別に 6 つのクラスを用意して、各データセットに被験者と履物を識別するための「被験者名」と「履物種類」というラベルを付けた。

そして、合成加速度データの低周波数成分と高周波数成分を強調するために、下記の 4 種類の FIR フィルタを用いて、前処理を施した。

- 5Hz 以下の低周波数成分のみデータ

- 5Hz 以下の高周波数成分のみデータ
- プリエンファシス係数 0.97 で高周波数成分強調されたデータ

生のデータを加えて、合計 4 種類のデータとなった。

つぎに、周波数解析を行うための窓関数を適用する前に、データに対して時間単位のフレームを切り出した。6.2.1 節で記述した例と同様に、フレーム区間を 1 秒間、後方へのシフト量を 0.2 秒間に設定した。データ収集のサンプリングレートは 100Hz であるため、10 秒間のデータセットに計 1000 個の値が含まれた。したがって、一つの計測データから計 45 個のフレームが得られた。

最後に、この切り出したデータフレームに対して、ハニング窓関数を適用した。このため、窓関数の窓サイズが、切り出したフレームのサイズと同じ 1 秒間で 100 個の値となった。

実験では、上述した前処理が施されたデータから、提案手法である LPC ケプストラム分析の適用によって、第一フォルマント F1 と第二フォルマント F2 を特徴量として抽出した。したがって、各セットから得られた特徴量は、計 45 個の (F1, F2) 二次元特徴ベクトルとなった。

そして、F1 と F2 の重みを単純に均等に設定したうえで、データ間の EMD 距離を算出し、k 最近傍法 (k-Nearest Neighbor Algorithm, k-NN) を用いて、それぞれを被験者別の 7 つのクラスと、履物種類別の 6 つのクラスに分類するクラスタリングを行った。k 最近傍法の手順は以下のとおりである。

1. 入力データと全データとの距離を計算。
2. 距離が近いものから順に k 個のデータを取り出す。
3. 取り出した集合のラベルにより、入力データのクラスを多数決で決める。

実験では、k 値を 9 に設定し、クラス分類の判定に用いた。被験者別のクラスタリングでは、各実験データが被験者数と同じである 7 つの被験者クラスのいずれかに分類される。履物別のクラスタリングでは、各実験データが履物種類数と同じである 6 つの履物クラスのいずれかに分類される。この分類の結果が入力データのラベルと一致するかどうかを確

かめ、正確に認識されたかどうかを判定した。

6.4 実験 2

実験 2 では、性別をもう一つの個人属性として注目した。まず、上述した実験 1 と同様に、従来の典型的な特徴量である平均値や最大値・最小値と比較して、男女の識別分類におけるフォルマント情報の有効性を確認する。そして、どのようにフォルマント情報を利用すれば、典型的な男女の特徴パターンを構成できるのかについて検討する。

データの収集は実験 1 と違い、計 20 人の男女各 10 人の被験者を対象とした。また、履物の状態について、全員でスニーカーにした。このほか、使用端末や取得回数などの収集方法の詳細は、表 6.1 に示されたものと同様である。

また、加速度の合成や、周波数帯域の強調、時間単位フレームの切り出しデータ、窓関数の適用などといったデータの前処理も 6.3 節の実験 1 と同様に施した。

つぎに、フォルマント情報による性別の典型パターンの構成を検討するために、LPC ケプストラム分析を用いて、第一フォルマント F1 から第五フォルマント F5 までを特徴量として抽出した。

そして、性別の認識分類は二値分類となるため、サポートベクターマシン (Support Vector Machine, SVM) を分類器として利用した。サポートベクターマシンは、線形入力素子を利用して 2 クラスのパターン識別器を構成する手法である。入力データから、各データ点との距離が最大となるマージン最大化超平面を求めるという基準で線形入力素子のパラメータを学習する。例えば、3 次元のデータを 2 次元平面で区切ることが可能である。実験では、LIBSVM という Chang ら [73] によって作成された SVM のライブラリを使用した。SVM のタイプをデフォルトの C-SVC に設定し、カーネル関数のタイプを RBF(Radial Basis Function) に設定した。

さらに、SVM を適用するには教師信号が必要となるため、男女の各 100 個のデータをそれぞれ半分の 50 個ずつに、学習データと実験データの役割を変えながら分類実験を行った。こうした交差検定 (Cross Validation) から得られた認識率 (True Positive Ratio,

TPR) は次の式で算出された.

$$TPR = \frac{\text{正確に分類認識できたデータセット数}}{\text{総データセット数}} \times 100(\%) \quad (6.14)$$

6.5 結果および考察

実験 1 では、前処理された実験データについて、LPC 次数を 20 に設定した LPC ケプストラム分析を用いて、切り出したフレームごとの (F1, F2) を特徴量として抽出した。同時に典型的な特徴量として、各フレームごとの下記の統計量を算出し、認識精度評価の比較対象とした。

- 生データの平均値
- 生データの最大値と最小値
- パワースペクトルの平均値
- パワースペクトルの最大値と最小値

特徴量の抽出を行った際に、全 200 セットの各実験データには、そのデータが属するクラスの「被験者名」と「履物種類」ラベルを付けた。これらを基いて、k 最近傍法で推定されたクラスが正解であるかどうかを判定する。したがって、クラスの分類結果から、被験者別の場合では、履物に関係なく同じ被験者としてどれくらい認識されたかが分かる。履物別の場合では、被験者に関係なく同じ履物としてどれくらい認識されたかが分かる。

まず、FIR フィルタを適用しなかった生データから抽出した (F1, F2) を用いた実験の結果を表 6.2 に示す。この結果から、提案手法である LPC ケプストラム分析によって抽出した特徴量 (F1, F2) は、ほかの特徴量に比べて高い正答率を示したことが分かった。歩行状態での行動情報推定に対して、有効な特徴量であると考えられる。そして、すべての特徴量において、被験者別の正答率が履物別の結果より高い正答率が得られたことから、同じ身体活動における個人差が環境要因に左右されることが少ないと考えられる。このため、LPC ケプストラム分析で抽出されたスペクトル包絡には、外乱からの影響と比べ身体活動の基本周期性についての情報が、多く含まれていると考えられる。この結果は、身体活動におけるスペクトル微細構造が外乱に対するインパルス応答を表し、スペク

表 6.2 生データの特徴量ごとのクラスタリング正答率

特徴量	被験者別	履物別
生データの平均値	79.00%	55.50%
生データの最大値と最小値	68.00%	55.00%
パワースペクトル平均値	81.00%	63.00%
パワースペクトル最大値と最小値	78.50%	58.00%
生データの (F1, F2)	83.50%	70.50%

表 6.3 フィルタごとの (F1, F2) を用いたクラスタリング正答率

FIR フィルタ	被験者別	履物別
なし	83.50%	70.50%
ローパスフィルタ ($\leq 5Hz$)	81.50%	43.50%
ハイパスフィルタ ($\geq 5Hz$)	75.50%	67.50%
プリエンファシスフィルタ ($p = 0.97$)	90.00%	77.50%

トル包絡が個人差の存在する基本リズム情報を反映するという考え方を支持した。また、被験者別の実験結果で従来の手法との差は大きく見られなかったが、履物別での正答率は従来の手法より、特に優れていることが確認できた。時間波形またはスペクトル領域において単純な統計量である平均値、最大値と最小値と比べて、スペクトルの大域特徴を表すスペクトル包絡のピーク値であるフォルマント情報から、より豊富な行動情報が得られることが示唆された。

つぎに、身体活動の低周波数成分と高周波数成分に含まれたコンテキスト情報の特徴を確認するため、ローパスフィルタ、ハイパスフィルタとプリエンファシスフィルタを適用したデータセットからも、特徴量の (F1, F2) を抽出して、行動者の個人認識と履物の認識実験を行った。その実験結果を表 6.3 に示す。ローパスフィルタまたはハイパスフィルタを利用する場合において、被験者別と履物別の認識率がどちらもフィルタなし、つまり

生データの場合より劣っていることが分かった。この結果から、身体活動の低周波数成分と高周波数成分の両方とも、環境要因と個人差に関する要素が存在していると考えられる。そして、低周波数成分だけの個人認識率は、生データの結果と僅差であったことが確認できた。これは、身体活動の基本リズムを表す成分が低周波数帯域に集中し、基本リズムには個人差が存在するという考え方と一致する。一方、ローパスフィルタで高周波数成分がカットされたため、環境要因を表す成分が減少し、履物別認識率は生データの結果と比べて悪化したことも分かった。また、ハイパスフィルタを利用した場合の履物別認識率が、ローパスフィルタの結果より良好で、生データの結果と比べても大差はなかった。これは、身体活動に対して、外乱または環境の影響を表す成分が高周波数帯域に集中するという予想と一致する。さらに、高周波数成分だけを使っても、被験者別の正答率が大きく悪化せず、ある程度保たれていた。これは、6.2.2 節の図 6.4 で述べたように、スペクトル領域では身体活動の基本周波数に比例したピークが、高周波数帯域にも存在するからであると考えられる。したがって、身体活動データの高周波数成分を強調すれば、個人差や環境要因といったコンテキスト情報を同時に把握することが可能である。これに対して、プリアンファシスフィルタを適用した実験結果が、被験者別と履物別の認識率のどちらも、これまでの実験で一番良い結果であり、上述した考察を支持した。

実験 2 では、まず、前処理を施した実験データについて、LPC 次数を 32 に設定し、LPC ケプストラム分析を用いて、F1 から F5 までを特徴量として抽出した。同時に典型的な統計量も特徴量として、切り出した各フレームから算出した。これらによって、下記の特徴空間を構成し、評価の比較対象とした。

- 生データの平均値、最大値と最小値からなる 3 次元空間
- パワースペクトルの平均値、最大値と最小値からなる 3 次元空間
- F1, F2, F3 からなる 3 次元空間
- F1~F4 の 4 次元空間
- F1~F5 の 5 次元空間

上記の特徴空間に対して、SVM による男女 2 クラスの分類を 6.4 節で述べた交差検定で行った。




図 6.11 生データから抽出した特徴空間の分類正答率




図 6.12 ハイパスフィルタを適用したデータの特徴空間の分類正答率

まず、生データから抽出した各特徴空間の分類正答率を図 6.11 に示す。典型的な特徴量と同じ 3 次元の空間を有する (F1, F2, F3) の結果は、フォルマント情報が従来の特徴値より効果的であることを示す。また、フォルマントを利用した結果では、平均 80% を超えた分類正答率が得られ、歩行に性差が存在することが確認できた。この差は、基本周波数の変動によって評価される歩行安定性の差であり、下肢筋力の男女差から由来するとされている [74]。したがって、フォルマントは歩行の周期性を反映し、各フォルマントの間隔はその周期に比例した変動を表すという本研究の性差に対する考え方が、この検出によって支持された。このため、将来の応用として、フォルマントを歩行の安定性評価に適用可能であると考えられる。

そして、図 6.12 はハイパスフィルタ (> 5Hz) を適用したデータから構成された各特徴空間の分類正答率を示す。低周波成分がカットされたため、生データの結果より悪い結果となった。このため、低周波数成分と高周波数成分には、どちらも情報を含んでいると




図 6.13 高周波数成分を強調したデータの特徴空間の分類正答率

考えられる。また、低周波数帯域に集中している基本周波数の成分の多くがカットされたにもかかわらず、使用するフォルマントの数を増やすことによって、認識精度がある程度に維持されることがと見られるため、高周波数の帯域に基本周波数と比例した成分が存在すると考えられる。したがって、低周波数成分を残しながら、高周波成分を強調すれば、より良い特徴空間を作成できると考えられる。

高周波数成分を強調する結果を図 6.13 に示す。ここで、プリエンファシスフィルタ ($p = 0.97$) が用いられたデータに対して、LPC 次数を 32, 64, 128 に設定し、それぞれの抽出したフォルマントの結果を比較する。図 6.11 と図 6.12 で示された結果と比較すると、同じ LPC 次数 $k = 32$ の結果では、分類正答率の向上が少々見られた。これは、高周波成分を強調することによって、より多くの有用なフォルマントが抽出されたと考えられる。また、LPC 次数を $k = 64$ に増やすと、88.0% といった高い認識率が得られた。一方、 $k = 128$ にすると、分類の性能が著しく下がった。このため、各フォルマントの間隔に影響する LPC 次数について、実際の応用に適したものを探索する必要があると考えられる。

6.6 まとめ

本章では、歩行において繰り返すパターンの周期特性に注目し、特徴量として抽出する手法について述べた。まず、身体活動の信号発生を線形システムとして、歩行の信号に環境要因と個人属性が反映されていると仮定し、加速度データがそれぞれの畳み込んだ波形

信号であるとした。そして、LPC ケプストラム分析を適用して、環境要因と個人属性に関する周期情報を特徴量として抽出する手法を提案し、提案手法に関連する前処理や特徴量間の距離評価について説明した。履物と個人属性・性別の二つの実験を通して、従来の手法と比較しながら、提案手法の有効性と可能性を考察した。実験の結果から、フォルマント情報が従来の音声処理以外に、人間の身体活動に対しても有効であることが示唆された。

本章を通じて、第4章と第5章と一貫した計測手法を用いて、環境要因と個人属性を同時に把握できる手法を実現した。フォルマント情報を抽出することによって、有効な特徴空間を構築できる可能性を示した。しかし、フォルマントの数と認識性能との関係性を明確に確認できなかった。この関係性は典型的な特徴パターンを構成するための重要なポイントであると考えられ、その解明が今後の課題となる。

第7章

結論

本論文は、高いニーズのあるコンテキストウェアサービスを向上させることを目指して、人間の身体活動情報に関する処理様式に着目した。携帯デバイスを用いてシンプルに収集した簡単なデータに対して、行動情報を推定するための特徴量抽出やパターン分類など一連の手法を提案した。提案した手法は、環境要因と個人差から由来するゆらぎやノイズなどを含めた生体データに対して、行動情報を頑健かつ柔軟に推定し、さらなる応用につながることを目的とした。以下、各章の内容を通じて、得られた知見と結論を整理する。

第1章において、本研究の背景を整理するとともに、本研究の狙いを明確した。機械と人間のコミュニケーションが実現されることにより、現在、人間の行動に適応したサービスの提供が多く求められている。しかし、このようなコンテキストウェアサービスをより豊富に展開するには、特殊な環境や機器だけではなく、その関連の知識も必要であり、サービス側とユーザ側の負担が大きい。複数の低価格で小型のセンサで構築したユビキタスコンピューティングが改善策とされているため、従来の研究では、多モダリティデータを解析するための技術を追求している。また、特定の異常行動パターンを検出するための既存研究も多く行われている。これらの問題に留意しつつ、シンプルに安定で長期にわたって行動データを計測し、多様な状況を理解できるような行動情報の推定にまだ至っていない現状を明確した。こうした現状の背景を受け、第4章から第6章において、歩行の加速度という生体データからの特徴量抽出などと、行動情報の推定を実現するモデル構築に取り組む研究を進めた。

第2章では、本研究が対象とする歩行と行動情報の基本的な事項を明確にするとともに、関連研究の整理や本研究の位置付けを明らかにした。まず、歩行の定義からその特徴について着目し、行動情報との関係性を示した。そして、人間一日の活動量の視点から、統計データを明示しながら、身体活動における歩行の位置付けを行った。つぎに、行動環境の推定について、直接外部の行動環境を計測する方法と、生体信号を利用して間接的に推定する方法の二種類に分けて論じ、携帯デバイスを利用するメリットを示した。最後に、歩行からの個人属性推定に関する研究を挙げて、その可能性を示した。

第3章では、本研究の提案システムについて、以降の各章において利用した基本的なプロセスの枠組みを示した。まず、全体の処理の流れとその各プロセスの内容を述べた。そして、本研究でモデルの認識・学習に適用する隠れマルコフモデル (HMM) について、離散分布型 HMM と連続分布型 HMM に分けて記述した。

第4章では、もっとも基本的な行動パターンで、本研究の対象でもある「歩行」の検出に着目し、「歩行」とその消費エネルギーを推定するための具体的な方法について、それぞれ提案した。特に、特徴量抽出の方法として加速度の3軸の方向情報を利用した。このため、加速度データが離散したシンボルの時系列データに変換され、離散分布型 HMM による認識・学習に適用した。実験を通じて、この提案手法の有効性が確認できた。

第5章では、第3章で示したプロセスの基本枠組みに従い、より多くの身体活動に対応できるような処理手法を提案した。同じ行動種類に対しても、行動環境などが異なるだけで、データの収集とモデルの学習を複数回行う手間に注目した。提案手法は、競合学習法を適用することによって、十分に認識できないデータが得られた時に、自動的に新しいモデルとして追加する。この自動処理によって、データの事前分類を行う労力と恣意性に関する問題を解決した。そして、加速度データの分布特徴を特徴量として、連続分布型 HMM に適用した。実験において、「歩行」と「階段における歩行」のカテゴリ化を例題として取り上げた。人間の主観と一致した組織化過程と、高い精度の認識率が得られたため、連続分布型 HMM と競合学習法が、環境情報を推定しながら、ダイナミックに標準モデルを構築できることが分かった。

第6章では、第4章と第5章と統一したデータ計測を行い、同じ基本的な処理の枠組みを用いながら、新たな特徴量抽出手法とそのための前処理を提案した。加速度データの周

期特性に注目し、大胆で斬新的に音声処理で用いられる解析手法を生体情報データに転用した。人間の歩行信号が線形システムとして、環境要因と個人属性に関する周波数成分が加速度データに畳み込まれたという仮説をたてたうえで、LPC ケプストラム分析を適用するための工夫を行った。履物と個人性・性別の推定実験を通じて、その結果から身体活動のフォルマント情報の意義を論じた。また、身体活動のフォルマントを用いて、有効な特徴空間を構成できる可能性を示した。

以上より、本論文において、行動情報を推定する基本的な処理の流れに沿って、携帯デバイスを用いた歩行における行動情報の推定について、行動種類、行動環境と個人属性といった所望の情報に合わせた推定手法を提案した。応用アプリケーションを含めた例題に対しても、良好な機能を実現した。結果として、自然な行動に近い状態での身体活動計測を実現し、所望の行動情報が複数であっても、異なる計測を複数回行う必要のない統一的な手法の確立に寄与した。一方、本論文で提案した手法の有効性は、全て従来手法と比較して、経験的に確認されたものであり、その理論的な解析を行わなかった。特に、身体活動フォルマントの抽出に関するパラメータの設定指針がほとんどない状況である。これらに関する検討が今後の課題である。そして、実際の応用アプリケーションへの実装についても、今後の研究において進めていきたい。

謝辞

本研究の全般に渡り、終始熱心なご指導・ご助言を頂き、ご高配を賜りました、神戸大学大学院国際文化学研究科グローバル文化専攻情報コミュニケーションコース 村尾 元 教授に、深く感謝の意を表します。国内外の学会シンポジウムに参加する機会を多数賜り、前期課程も合わせて、5年間の充実した勉学・研究生活を過ごすことができました。私の人生観や世界観にも、大変有意義な影響を多々頂きました。心より深く御礼申し上げます。

常に懇切丁寧なご指導を頂き、ご高配を賜りました、神戸大学大学院国際文化学研究科グローバル文化専攻情報コミュニケーションコース 森下 淳也 教授、大月 一弘 教授、康敏 教授、清光 英成 准教授、西田 健志 准教授に、深く感謝致します。研究室の垣根を越えた強い結束と温かく自由な雰囲気の中で、熱心なご指導を頂き、日々の研究室生活を楽しく過ごせました。留学生の私にとって大変恵まれた環境であったと思います。

定例ミーティングへの参加と学位審査の依頼を快く引き受けて頂きました、神戸大学大学院システム情報学研究科情報科学専攻知能情報講座 玉置 久 教授に、的確なご助言および丁寧なご査読を賜りましたことを厚く御礼申し上げます。定例ミーティングにて貴重なご助言を頂きました、同研究室 太田 能 准教授、高木 由美 助手に深く感謝致します。

大学院入学当初より、様々なご助言を頂きました、山梨英和大学人間文化学部人間文化学科 難波 道弘 教授、大阪産業大学工学部電子情報通信工学科 大野麻子 講師、神戸情報大学院大学 孫 一 助手に大変感謝しております。

日々の研究を支えて頂きました、情報コミュニケーションコースの皆様、特に Daniel Moritz Marutschke 氏は同研究室にて博士課程を共に過ごし、お互いの研究を学ぶことによって、視野を広げることができました。加えて、同コース 鄒 亜亨 氏、山本 卓司 氏、文 健 氏、桑野 徹也 氏、中村 将達 氏、他、議論にお付き合い頂き、研究室での充実した

生活を共に送ることができたことに、感謝致します。

Kirjakovski Atanas 氏，程 莉 氏をはじめとした他コースの皆様，大原 誠 氏，杉川 智 氏をはじめとした他研究科の皆様，林 優紀 氏，三宅 修平 氏をはじめとした神戸大学国際文化学部 of 学部生の皆様，そして，苦楽を共にし，現在もお世話になっております OB・OG の皆様に感謝致します。

最後に，私の留学生生活を惜しみなく支持してくれている両親と，長い間にお互いに助け合っている金蘭に感謝しております。

研究業績

学術論文（査読あり）

1. Yancong Su and Hajime Murao, “Study on Human Behavior Recognition using Discrete HMM and Continuous HMM”, ICIC Express Letters, ICIC International, vol.6, no.3, pp.791–796, 2012.
2. Yancong Su and Hajime Murao, “A Study on Feature Extraction from Human Body Motion by using Cepstrum Analysis”, ICIC Express Letters, ICIC International, vol.7, no.3B, pp.1011–1015, 2013.
3. Yancong Su and Hajime Murao, “Extracting Feature Values from Human Gait by using LPC Cepstrum Analysis for Attribute Recognition”, ICIC Express Letters, ICIC International, vol.8, no.3, pp.815–820, in Press, 2014.

国際会議 口頭発表（査読あり）

1. Yancong Su and Hajime Murao, “Study on Human Behavior Recognition using Discrete HMM and Continuous HMM”, The Sixth International Conference on Innovative Computing, Information and Control, Kitakyushu, Japan, ICICIC-2011-405, 12/2011.
2. Yancong Su and Hajime Murao, “A Study on Feature Extraction from Human Body Motion by using Cepstrum Analysis”, The Seventh International Conference on Innovative Computing, Information and Control, Shanghai, China,

- ICICIC-2012-845, 11/2012.
3. Yancong Su and Hajime Murao, "A Study on Human Attribute Recognition by Applying LPC Cepstrum Analysis to Human Gait", The Third Internal Workshop of the Innovations in Information and Communication Science and Technology, Tomsk, Russia, K01, 09/2013.
 4. Yancong Su and Hajime Murao, "Extracting Feature Values from Human Gait by using LPC Cepstrum Analysis for Attribute Recognition", The Eighth International Conference on Innovative Computing, Information and Control, Kumamoto, Japan, ICICIC-2013-819, 09/2013.

国内会議 口頭発表（査読なし）

1. 蘇 彦聡, 村尾 元, "携帯機器の加速度センサ情報を利用した行動認識への連続 HMM の適用", 第 55 回システム制御情報学会研究発表講演会, S0343, 大阪大学コンベンションセンター, 2011 年.
2. 蘇 彦聡, 村尾 元, "HMM を用いた時系列データ自動組織化による行動認識の試み", 第 24 回自律分散システムシンポジウム, 2C1-2, 神戸ファッションマート・コンベンションルーム, 2012 年.
3. 蘇 彦聡, 村尾 元, "加速度データの LPC ケプストラム分析による特徴量抽出に関する考察", 第 25 回自律分散システムシンポジウム, 1C1-3, 東北大学片平さくらホール, 2013.

参考文献

- [1] M. Donald, “Origins of the Modern Mind”, Harvard University Press, 1991.
- [2] V. Gallese and A. Goldman, “Mirror Neurons and the Simulation Theory of Mind-reading”, Trends in Cognitive Sciences, vol.2, no.12, pp.493–501, 1998.
- [3] 小嶋 祥三, “ミラーニューロンと言語の起源”, 科学, vol.69, no.4, pp.404–408, 1999.
- [4] 稲邑 哲也, 中村 仁彦, 戸嶋 巖樹, 江崎 英明, “ミメシス理論に基づく見まね学習とシンボル創発の統合モデル”, 日本ロボット学会誌, vol.22, no.2, pp.256–263, 2004.
- [5] T. V. Duong, H. H. Bui, D. Q. Phung and S. Venkatesh, “Activity Recognition and Abnormality Detection with the Switching Hidden Semi-Markov Model”, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol.1, pp.838–845, 2005.
- [6] 本村 陽一, 西田 佳史, 山中 龍宏, “子供の事故予防のための確率モデル構築の試み”, 電子情報通信学会技術研究報告. NC, ニューロコンピューティング, vol.104, no.759, pp.73–76, 2005.
- [7] 笠 七菜実, 川原 圭博, 小林 亜令, 浅見 徹, “非運動性活動を考慮した加速度センサによる消費エネルギー推定手法”, 情報処理学会研究報告. UBI, ユビキタスコンピューティングシステム, vol.2008, no.40, pp.67–74, 2008.
- [8] A. Ohno, T. Inamoto and H. Murao, “Fundamental Study of Clustering Images Generated from Customer Trajectory by using Self-Organizing Maps”, ICIC Express Letters, vol.4, no.5(B), pp.1979–1984, 2010.
- [9] 青木 茂樹, 岩井 嘉男, 大西 正輝, 小島 篤博, 福永 邦雄, “人物の位置・姿勢に注目した行動パターンの学習・認識と非日常状態検出への応用”, 電子情報通信学会論文誌.

- D-II, 情報・システム, II-パターン処理, vol.87, no.5, pp.1083–1093, 2004.
- [10] 田中 太氏, 篠田 武思, “歩行中の身体のゆらぎ解析による作業・歩行路環境の安全性評価”, 人間工学, vol.46, no.4, pp.287–294, 2010.
- [11] 西村 竜一, 中村 敬介, 李 晃, 猿渡 洋, 鹿野 清宏, “大人・子供に適応した音声情報案内のためのユーザ自動識別”, 電子情報通信学会技術研究報告. SP, 音声, vol.103, no.519, pp.97–102, 2003.
- [12] 安藤 繁, 田村 陽介, 戸辺 義人, 南 正輝, “センサネットワーク技術—ユビキタス情報環境の構築に向けて”, 東京電機大学出版局, 2005.
- [13] 寺田 努, “ウェアラブルセンサを用いた行動認識技術の現状と課題”, コンピュータソフトウェア, vol.28, no.2, pp.43–54, 2011.
- [14] 板生 清, “ウェアラブルセンサによる健康情報モニタリング”, マテリアル インテグレーション, vol.23, no.9, pp.2–7, 2010.
- [15] 峯岸 由佳, 渡邊 高志, 古瀬 則夫, “簡易歩行評価のための足部ジャイロスコープによる健常者の歩行事象の解析”, バイオメカニズム学会誌, vol.34, no.1, pp.63–67, 2010.
- [16] S. W. Lee and K. Mase, “Activity and Location Recognition using Wearable Sensors”, Pervasive Computing, vol.1, no.3, pp.24–32, 2002.
- [17] L. Bao and S. S. Intille, “Activity Recognition from User-Annotated Acceleration Data”, Pervasive Computing, vol.3001, pp.1–17, 2004.
- [18] J. Lester, T. Choudhury and G. Borriello, “A Practical Approach to Recognizing Physical Activities”, Lecture Notes in Computer Science, vol.3968, pp.1–16, 2006.
- [19] F. Naya, R. Ohmura, F. Takayanagi, H. Noma and K. Kogure, “Workers’ Routine Activity Recognition using Body Movements and Location Information”, Proceedings of 2006 10th IEEE International Symposium on Wearable Computers, pp.105–108, Montreux, Swiss, 2006.
- [20] K. H. Chang, M. Y. Chen and J. Canny, “Tracking Free-weight Exercises”, Lecture Notes in Computer Science, vol.4717, pp.19–37, 2007.
- [21] M. Berchtold, M. Budde, D. Gordon, H. R. Schmidtke and M. Beigl, “Actiserv: Activity Recognition Service for Mobile Phones”, Proceedings of 2010 10th IEEE

- International Symposium on Wearable Computers, pp.1–8, Seoul, Korea, 2010.
- [22] A. K. Dey, G. D. Abowd and D. Salber, “A Conceptual Framework and a Toolkit for Supporting the Rapid Prototyping of Context-aware Applications”, *Human-Computer Interaction*, vol.16, no.2, pp.97–166, 2001.
- [23] 林 智天, 川原 圭博, 田村 大, 森川 博之, 青山 友紀, “小型モバイルセンサを用いたコンテキスト適応型コンテンツ配信サービスの設計と実装”, *電子情報通信学会技術研究報告. NS, ネットワークシステム*, vol.104, no.689, pp.149–154, 2005.
- [24] 尾崎 晃, 草川 高志, 西脇 由博, マルタ ルーカス, 宮島 千代美, 西野 隆典, 北岡 教英, 伊藤 克亘, 武田 一哉, “自動車運転のマルチモーダル信号収録装置の開発”, *電子情報通信学会論文誌. D, 情報・システム*, vol.93, no.10, pp.2118–2128, 2010.
- [25] 宮島 千代美, 武田 一哉, “運転行動データベースの構築とその応用”, *システム/制御/情報*, vol.55, no.1, 2011.
- [26] 小学館, “日本大百科全書：ニッポニカ”, 1994.
- [27] 波多野 義郎, “ウォーキング!—元気で10年長生きしたいあなたに”, 株式会社アスペクト, 2001.
- [28] 窪田 俊夫, 大橋 正洋, “歩行障害の診断・評価入門”, 医歯薬出版, 1997.
- [29] T. C. Michaud, “Foot Orthoses and Other Forms of Conservative Foot Care”, Lippincott Williams & Wilkins, 1993.
- [30] 厚生労働省, “健康づくりのための運動指針 2006 ～生活習慣病予防のために～ (エクササイズガイド 2006) ”, 2006.
- [31] 厚生労働省, “平成 23 年国民健康・栄養調査報告”, 2013.
- [32] American college of Sports Medicine, “ACSM’s Guide lines for Exercise Testing and Prescription”, Lippincott Williams & Wilkins, 2009.
- [33] 田中 茂穂, “間接熱量測定法による1日のエネルギー消費量の評価”, *体力科学*, vol.55, no.5, 2006.
- [34] 厚生労働省, “日本人の食事摂取基準 (2010 年版) ”, 2009.
- [35] J. A. Levine, L. M. Lanningham-Foster, S. K. McCrady, A. C. Krizan, L. R. Olson, P. H. Kane, M. D. Jensen, M. M. Clark, “Interindividual Variation in

- Posture Allocation: Possible Role in Human Obesity”, *Science*, vol.307, no.5709, pp.584–586, 2005.
- [36] 国立健康・栄養研究所, “改訂版 身体活動のメッツ (METs) 表”, 2012.
- [37] 田岡 康裕, 納谷 太, 野間 春生, 小暮 潔, 李 周浩, “Bluetooth の電波強度を用いたユーザの位置推定手法”, 電子情報通信学会技術研究報告. USN, ユビキタス・センサネットワーク, vol.108, no.138, pp.147–152, 2008.
- [38] 庄司 正成, 澤田 孝, “音響情報に基づく複数歩行者位置推定, 追跡の検討”, 電子情報通信学会技術研究報告. USN, ユビキタス・センサネットワーク, vol.110, no.378, pp.7–12, 2011.
- [39] 中村 友宣, 小川 剛史, 清川 清, 竹村 治雄, “二酸化炭素センサによる鉄道車内混雑度推定を用いたウェアラブル学習システムのための利用者コンテキスト認識”, 電子情報通信学会技術研究報告. MVE, マルチメディア・仮想環境基礎, vol.107, no.554, pp.49–54, 2008.
- [40] 米村 淳, 大岸 智彦, 井戸上 彰, 小花 貞夫, “スマートフォンを用いた人の混雑度推定手法の提案と評価”, 情報処理学会研究報告. MBL, vol.2013, no.5, pp.1–8, 2013.
- [41] 篠田 岳思, 池田 耕平, 合戸 崇司, 田中 太氏, “造船所における歩行安全評価のためのヒューマンモデルに関する研究”, 日本船舶海洋工学会論文集, no.6, pp.83–89, 2007.
- [42] 鈴木 清, 砂川 尊範, 新田 保次, “心拍変動による自転車走行空間の安全性・快適性評価方法に関する研究”, 福祉のまちづくり研究, vol.14, no.2, pp.1–8, 2012.
- [43] 半谷 精一郎, “バイオメトリクス認証技術の動向とセキュリティシステムへの応用”, 映像情報メディア学会誌, vol.58, no.6, pp.750–752, 2004.
- [44] A. K. Jain, R. Bolle and S. Pankanti, “BIOMETRICS: Personal Identification in Networked Society”, Springer, 1999.
- [45] M. Oren, C. Papageorgiou, P. Sinha, E. Osuna and T. Poggio, “Pedestrian Detection using Wavelet Templates”, *Proceedings of 1997 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.193–199, San Juan, USA, 1997.
- [46] 泉 正夫, 宮本 貴朗, 福永 邦雄, “歩行動作の時空間画像からの人物識別”, 電子情報通

- 信学会総合大会講演論文集, vol.2003, no.2, pp.317, 2003.
- [47] 藤井 崇介, 関 進, 沢田 篤史, 美濃 導彦, “個人識別のためのフットステップ情報利用の検討”, 電子情報通信学会総合大会講演論文集, vol.2005, no.2, pp.177, 2005.
- [48] 山西 利明, 森 武俊, 森下 広, 原田 達也, 佐藤 知正, “時系列床面圧力分布情報を用いた個人識別システムの開発”, 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解, vol.105, no.534, pp.105–110, 2006.
- [49] C. Barclely, “Temporal and Spatial Factors in Gait Perception that Influence Gender Recognition”, *Perception and Psychophysics*, vol.23, no.2, pp.145–152, 1978.
- [50] 山崎 昌廣, 佐々木 隆, 続 修二, 鳥井 正史, “トレッドミル歩行時における下肢動作の常同性とその性差”, *体力科学*, vol.33, no.6, pp.392, 1984.
- [51] 宮本 隆司, 小野 秀文, 菅本 一臣, 米延 策雄, 越智 隆弘, “3次元歩行解析を用いた健康者歩行の性差の検討”, *日本リハビリテーション医学会誌*, vol.35, no.11, pp.834, 1998.
- [52] 西島 吉典, 加藤 達雄, 古澤 正尹, “歩行における動作ならびに筋電図波形からみた性差についての検討”, *体力科学*, vol.53, no.4, pp.471, 2004.
- [53] 金 興烈, 李 成哲, 森 あさか, 安藤 富士子, 下方 浩史, “歩行速度（無次元速度）の性差と年代差に関する考察”, *日本未病システム学会雑誌*, vol.16, no.2, pp.254–257, 2011.
- [54] SunSPOT World: <http://www.sunspotworld.com/>
- [55] 歩数計: <http://itunes.apple.com/jp/app/id318309220?mt=8&ign-mpt=uo%3D6>
- [56] C. Breazeal and B. Scassellati, “Robots that Imitate Humans”, *Trends in Cognitive Sciences*, vol.6, no.11, pp.481–487, 2002.
- [57] A. Billard, S. Calinon, and F. Guenter, “Discriminative and Adaptive Imitation in uni-manual and bi-manual Tasks”, *Robotics and Autonomous Systems*, vol.54, no.5, pp.370–384, 2006.
- [58] 高野 渉, 中村 仁彦, “統計的相関に基づく動作パターンの分節化”, 第19回人工知能学会全国大会論文集, 3F1-02, 2006.

- [59] D. Kulic, W. Takano and Y. Nakamura, “Incremental Learning, Clustering and Hierarchy Formation of Whole Body Motion Patterns using Adaptive Hidden Markov Chains”, *International Journal of Robotics Research*, vol.27, no.7, pp.761–784, 2008.
- [60] iPhone: <http://www.apple.com/jp/iphone/>
- [61] HASC Logger: <http://itunes.apple.com/jp/app/id384897105>
- [62] HASC Tool: <http://hasc.jp/hc2010/hasctool.html>
- [63] B. P. Bogert, M. J. R. Healy and J. W. Tukey, “Thequefreny alanalysis of time series for echoes: Cepstrum, pseudo-autocovariance, cross-cepstrum, and saphe-cracking”, *Proceedings of the Symposium on Time Series Analysis*, pp.209–243, Wiley, New York, 1963.
- [64] A. M. Noll, “Short-Time Spectrum and Cepstrum Techniques for Vocal-Pitch Detection”, *Journal of the Acoustical Society of America*, vol.36, no.2, pp.296–302, 1964.
- [65] 成田 裕司, 関 和彦, 成澤 三雄, “歩行の外乱に対するヒトの姿勢維持機能”, *体力科学*, vol.44, no.6, pp.607, 1995.
- [66] 渡部 琢也, 米田 継武, 柳原 大, “歩行中に加えられた外乱に対する筋電図応答”, *日本運動生理学雑誌*, vol.4, no.1, pp.43, 1997.
- [67] 関根 正樹, 阿部 芳幸, 関本 満義, 藤元 登四郎, 田村 俊世, 福井 康裕, “腓骨頭部加速度波形を用いた片麻痺患者の歩行評価の定量化に関する検討”, *電気学会論文誌. C, 電子・情報・システム部門誌*, vol.120, no.8, pp.1110–1117, 2000.
- [68] C. Collomb, “Linear Prediction and Levinson-Durbin Algorithm”, <http://www.emptyloop.com/technotes/>, 2009.
- [69] 粕谷 英樹, 鈴木 久喜, 城戸 健一, “年令, 性別による日本語 5 母音のピッチ周波数とホルマント周波数の変化”, *日本音響学会誌*, vol.24, no.6, pp.355–364, 1968.
- [70] 稲葉 一紀, 広重 真人, 宮永 喜一, 枋内 香次, “フォルマント軌跡を利用した局所話速変化検出手法”, *電子情報通信学会総合大会講演論文集, 情報・システム*, no.1, pp.228, 1996.

-
- [71] 網野 加苗, “聴覚による話者識別における日本語音韻の特性”, 電子情報通信学会技術研究報告. SP, 音声, vol.104, no.149, pp.49–54, 2004.
- [72] Y. Rubner, C. Tomasi and L. J. Guibas: “The Earth Mover’s Distance as a Metric for Image Retrieval”, *International Journal of Computer Vision*, vol.40, no.2, pp.99-121, 2000.
- [73] C. C. Chang, C. J. Lin, “LIBSVM: A Library for Support Vector Machines”, *ACM Transactions on Intelligent Systems and Technology*, vol.2, no.3, pp.27:1–27:27, 2011.
- [74] 牧浦 大祐, 土井 剛彦, 浅井 剛, 山口 良太, 小松 稔, 小嶋 麻悠子, 小野 くみ子, 小野 玲, 平田 総一郎, “歩行の安定性に性差は存在するのか? : 加速度計を用いた歩行解析による検討”, *理学療法科学*, vol.25, no.6, pp.923–928, 2010.