

博士論文

人の歩行姿勢推定に関する研究

Dissertation

Doctor of Philosophy

A Study on Estimation of the Human Walking
Posture

劉 子悦

学生番号 205F2001

指導教員 丹上 結乃純 教授

九州工業大学 大学院 工学府
工学専攻 知能制御工学コース

令和4年度

摘要

近年、高齢化は年々深刻な社会問題になっている。年齢に関わらず、健康維持・増進への関心が高まっているという背景の中で、人々は姿勢の悪さによる健康被害を避けたいと考えている。歩行は、人にとって最も一般的な移動手段である。本研究では、歩行時の姿勢に注目する。高齢者では、ちょっとした姿勢の変化が脊椎や下肢に大きな影響を与え、身体のバランスを変化させることがある。歩行姿勢は健康の指標のひとつとして使用できる可能性があるため、人間の歩行姿勢の推定と解析に関する研究は有用である。

本論文では、人に装着したカメラから提供されるビデオ映像の解析により、人の歩行姿勢の推定・解析・認識を行う手法を提案する。ウェアラブルカメラを通して観測される風景の変化からそのカメラの姿勢変化を推定することにより、歩行姿勢を解析する。実験により、提案法の有効性を検証した。

提案法は、屋内屋外を問わず歩行姿勢を判定し、歩行姿勢の悪さを指摘することができる。提案法を利用して人が健康を維持し、安心・安全な生活が実現できるようになることが本研究の目標である。

目次

第1章 序論	1
1.1 本研究の学術的背景	1
1.2 従来研究の動向と位置付け	5
1.3 本研究の位置付けと意義	10
1.4 本研究の学術的特色と独創点	10
1.5 本論文の構成	11
第2章 特徴点検出とマッチング	12
2.1 AKAZE 特徴点検出	12
2.2 LK 法によるオプティカルフローの計算	13
2.3 特徴点マッチング	17
第3章 人の歩行姿勢の推定	18
3.1 基本行列の推定	18
3.2 カメラの相対運動の推定	20
3.3 3次元復元	21
3.4 回転行列の分解	23
第4章 人の歩行姿勢の解析と認識	25
4.1 トレンド除去	25
4.2 波形の補正	26
4.3 人の歩行姿勢の指標	28
4.4 人の歩行姿勢の認識	29
第5章 実験	33
5.1 実験環境	33
5.2 提案法の有効性検証	33
5.3 歩行姿勢推定精度実験	38
5.4 歩行姿勢解析実験	84

5.5 歩行姿勢認識実験	91
第6章 考察	92
第7章 結論	94
参考文献	
謝辞	

第1章 序論

1.1 本研究の学術的背景

総務省統計局の調査[1]によれば，2022年の日本の総人口は2021年と比し約82万人減少している。ただし，65歳以上の高齢者は約3627万人存在し，その割合は総人口の29.1%を占めている。高齢化は年々深刻な社会問題になっている。一方で，転倒が原因で受傷した高齢者の割合は70.8%を占め，転倒による死亡者のうちの高齢者率は88.1%であるため，転倒は高齢者の健康・安全に関する重要な問題である[2][3]。また，年齢に関わらず，健康維持・増進への関心が高まっているという背景の中で，人々は姿勢の悪さによる健康被害を避けたいと考えている。

近年数多くの研究者が，人の姿勢推定と動作認識に注目している。人がどんな動作をしているのか，人の姿勢が何を意味するのかを判断するために，効果的なモニタリング機器，画像情報などを利用している。特に高齢者にとって効果的な姿勢推定や動作認識は，健康と安全の問題解決に有効と思われる。したがって，人の姿勢推定法と動作認識法は重要な技術であり，多くの分野で広く使用されている。たとえば，バーチャルリアリティ，インテリジェントなヒューマンコンピュータインタラクション，インテリジェントなモニタリング，アスリートのトレーニング補助，患者のモニタリングなどである。

1) バーチャルリアリティ

バーチャルリアリティとは，コンピュータシミュレーションの技術を用いて，3次元の仮想空間を生成する技術である。この仮想世界では，ユーザーは視覚，触覚，聴覚，およびその他の感覚機能のシミュレーションを利用するため，ユーザーに没入感を感じさせることができる。同時に，3次元空間上の世界を無制限にリアルタイムで観察する機会をユーザーに提供できる。現在仮想現実は，医療，娯楽，軍事航空宇宙，生体力学などの分野で広く利用されている。例えばバーチャル対テロ演習では，画面内の人の姿勢や動作を効率的に解析し，次の行動の判断を下すことができれば，無駄な損失を回避し，多くの人員と材料を節約できる。また，人の姿勢と動作の解析は，ビデオ会議，アニメーション，仮想スタジオなどの仮想現実に応用すれば，実空間の人の姿勢や動作を仮想世界により正確かつリアリティを持って登場させられる。

2) インテリジェントな監視システム

インテリジェントな監視システムは、主にショッピングモール、銀行、駐車場、空港、バス、密集した交差点など公共の安全を特別に保護する必要がある場合に広く使用されている。現在、暴力的なテロ事件が時折発生しており、米国での「911」事件以来世界中の国々が、公共の安全と人々の財産を損害から守るために一層の注意を払っている。さまざまな国が、インテリジェントなセキュリティ監視に関する研究への投資を増やしている。現在の監視システムの作業のほとんどは人によって行われており、自律的に警察を呼ぶ機能はない。しかし、このような機械的で単調な作業では、人は疲労しがちである。いったん疲労すれば、確率の低い異常なイベントを無視するのは簡単であり、取り返しのつかない損失をもたらす。インテリジェントな監視システムは、人の姿勢をリアルタイムで推定・解析し、異常な行動があるかどうかを判断する。このように早期に認識・警告を発することができれば、異常な行動の発生を軽減または防止でき、監視員や人件費も節約できる。

3) 拡張現実

拡張現実とは、日常の仕事、生活、娯楽に比較的近いアプリケーションである。拡張現実技術は、コンピュータで生成された仮想オブジェクト、シーン、またはシステムプロンプト情報を現実のシーンに重ね合わせることによって、現実世界に対するユーザーの認識を強化する技術である。その最も一般的なアプリケーションの1つはビデオ会議であり、現在のビデオ会議は、音声とビデオの送信のみに基づいているが、拡張現実技術により、各ユーザーの姿勢、動作、表情をリアルタイムで推定、解析、復元、投影することができる。参加者が遠く離れていても、あたかも同じ会議室にいるかのように全員の動きや様子をはっきりと観察でき、距離や障害物のないリアルタイムコミュニケーションを簡単かつ便利に実現できる。また、このような技術を使えば、遠隔手術も実現できる。

4) インテリジェントなヒューマンコンピュータインタラクション

これからは、さまざまな分野で、仕事や研究にコンピュータを利用する人がますます増えていく。人々は、専門的なトレーニングを必要とする現コンピュータによるインタラクション法ではなく、シンプルで高速かつ柔軟な人間とコンピュータのインタラクション法を期待している。将来的には、コンピュータが人間の動作や姿勢の意味を理解し、それらを通じてコンピュータの操作を制御できるようになる。ジェスチャー、うなずき、頭の振り、または人間の目の焦点などを介してコンピュータ操作を制御でき、より柔軟かつ便利で、人間の相互作用の習慣にさらに沿っている。これらはすべて、姿勢推定技術によって実現できる可能性が高い。

5) 患者のモニタリング

現在、医療状況は大幅に改善されているが、患者のモニタリングの問題は十分に解決されていない。その理由は、現代の生活のペースの加速と仕事の多忙により、家族の誰かが病気で入院すると付き添いが必要になるが、多額の人件費がかかる上、付き添い時間のほとんどは何もなく、付き添いは緊急事態の発生を防ぐためだけだからである。付き添いの時間のほとんどは無意味であり、病院には看護スタッフが比較的少なく、プロセス全体で患者に付き添う方法はない。そのため、インテリジェントな患者監視システムの需要は日々高まっている。もし人間の行動を認識し分析することができれば、患者の動作に異常があるかどうかをいつでも判断できる。異常な動きがあれば、すぐにアラームが発出され、医療スタッフはタイムリーな治療が可能になる。この方法により、医療スタッフの仕事の負担を軽減するだけでなく、患者の家族の人件費を大幅に節約できる。

6) アスリートの補助トレーニング

これまで、アスリートのトレーニングとエクササイズは特別なコーチによって指導されていたが、コーチのレベルが不均一であるため、アスリートのトレーニングレベルを効果的に保証することはできない。科学技術の進歩に伴い、人々は科学的で合理的なトレーニング方法にますます注意を払い、過去の非科学的なトレーニング方法を徐々に放棄している。人の動作の認識と解析は、アスリートの補助トレーニングにおいて幅広い応用の可能性を秘めている。関節の位置、姿勢、角度、角速度など、アスリートのさまざまな技術パラメータを抽出することによって、さまざまなスポーツトレーニングに活用できる。これらのデータに含まれる有用な情報を解析し活用することによって、アスリートの欠点や不規則な動きを指摘し、より合理的で標準的な動きになるようにトレーニングを指導できる。例えば、ダンスや体操、飛び込みなどのトレーニングでは、関節の動きを解析してエクササイズの指導や修正を行っており、その過程全体で姿勢を判断・解析する、関節の動きを解析することによって、技術基準を満たせるようになる。また多くの場合、瞬間的な動きは人間の目ではうまく検出できないが、このシステムにより、瞬間的な動きの異常を効率的に指摘できる。トレーニングに対するこの科学的アプローチは、アスリートの成長と進歩に不可欠である。

上記の分析を通じて、人の姿勢の解析は、人をリアルタイムで効果的に監視し、人々が困難な作業を完了するのを支援することさえできることが理解できる。特に高齢者の場合、姿勢解析タスクでの歩行姿勢予測を利用することによって、高齢者の転倒予防や歩行姿勢の改善に効果的な指導計画を提供することができる。

歩行姿勢解析において、歩行は人間の基本動作であり、人の歩行姿勢は、中枢

神経系の制御下にある人の運動システムの協調の結果である。神経システムや運動システムに障害が起こると、人の運動機能も損なわれ、外的な歩行姿勢にも影響が現れ、異常な歩行姿勢として現れる。一般的な異常歩行タイプには、中枢神経系損傷による片麻痺歩行、大殿筋・中殿筋・ふくらはぎ三頭筋の無力による歩行、構造異常、痛みによる支持相異常、四肢不安定、体幹不安定、歩行障害などがある。

病気の臨床診断の観点から、歩行姿勢は専門の医療関係者が歩行異常を診断するのに十分な情報を提供できる。これは観察歩行分析と呼ばれる。歩幅、周期、速度、関節角度、胴体の回転、腕の振りなど、観察的な歩行姿勢解析では多くのパラメータを考慮する必要がある。医療関係者は、患者の歩行ビデオデータまたは患者のセンサデータを通じて歩行姿勢解析を実行し、患者の病気を診断するための基礎として使用することもできる。疾患ごとに歩行性能が異なるため、患者の歩行特性を分析することによって、疾患の種類や体調を判断できる。

歩行姿勢解析とは、人の運動状態を体系的に解析することであり、歩行姿勢解析を通じて人の歩行特性の異常を特定し、対応する治療法を提案することができる。臨床応用における人の歩行機能を評価するための重要な方法とする歩行姿勢解析は、人の動作や姿勢に関連するさまざまな身体的健康問題を特定するために使用でき、さまざまな運動障害を持つ患者のリハビリ状態を監視するためにも使用できる。従来の臨床診療では、患者の歩行障害を判断・評価し、またリハビリテーション治療の効果を評価するために目視観察が利用される。ただし、このアプローチは非常に主観的であり、臨床医の経験的判断に大きく依存する。また、この目視観察法の測定結果はしばしば不正確であり、歩行障害の診断と治療計画の質が大幅に低下する[4]。

現在は、モーションキャプチャシステムと組み合わせた高精度センサ機器を用いて、人の歩行姿勢の特徴をキャプチャし、歩行姿勢解析を行うことができる[5,6]。この客観的な測定方法は、主観的な観察方法と比較して、より正確な姿勢推定結果を得ることができる。最も重要なことは、すべての測定情報と結果が統一された基準と条件の下で得られることである。最も代表的な研究成果はウェアラブル赤外線センサである。被験者のキーポイントにセンサを取り付けることにより、マーカーポイント情報に基づいて人の歩行姿勢の関連測定データを収集する。ただし、このタイプの装置は、データ収集の実験室構成に対する要件が高く、装置と実験のコストが高く、大規模に使用することは困難である。同時に、このようなウェアラブルデバイスはセッティングに時間がかかり、操作には経験豊富な専門家が必要となる。したがって、マーカーを使用しない歩行姿勢推定法は理想的な代替手段になる。使用するセンサの数を減らすことができるため、人の動作情報の取得がマーカーポイント情報に依存しなくなり、被験者は特

別な衣服や機器を着用する必要がなくなり、時間とコストが削減される。最も典型的なアプリケーションは、ウェアラブルビジョンセンサ機器である。

コンピュータビジョンアルゴリズムと視覚センサデバイスを用いて、画像またはビデオデータを使用し、人の関節点の特徴と骨格フレームワーク情報を抽出すれば、人の歩行姿勢が判断できる。特に近年、視覚感知の急速な発展により、視覚に基づく人の姿勢推定は高い精度を達成している。

RGB 画像またはビデオを使用した 2D および 3D 姿勢推定方法は、国内外で集中的に研究されてきたが、現実世界での歩行姿勢推定への適用には多くの制限がある。まず、実際のシーンには低照度が存在し、これらのビデオファイルはほとんどグレースケールファイルの形式で保存され(メモリ使用量が少ない)、画像のコントラストが非常に低く、色情報も欠落しているため、これらのビデオから人関節点を正確に特定することは非常に困難になる。次に、ビデオ画像は実験室の他の光源によっても影響を受ける可能性がある。たとえば、人の関節点の 3 次元座標をキャプチャするために使用される赤外線カメラは、ビデオに明るいスポットとして表示される。これらはノイズとなり、人の歩行姿勢推定に影響を与え、深刻な干渉を引き起こす。また、2D および 3D の人の姿勢推定に関する研究は数多く行われているが、既存の研究はほとんどビデオシーケンスの時間的な関連情報が十分に利用されていない[7,8]。また既存の方法には一定の制限があり、3D 姿勢を予測して歩行分析を完了するには十分な精度がない[9]。また、関節の遮断や急激な運動のぼやけなどの問題に対して、従来法ではこれらの問題を解決することは難しく、最終的な予測姿勢の推定精度はまだ向上する余地がある[10]。

本論文では、1 台のウェアラブルカメラを用いて撮影された映像から、カメラ装着者自身の歩行姿勢を推定し解析する手法を提案する。解析結果をカメラ装着者にフィードバックすることによって、その人の歩行姿勢の改善に役立つ手法となることを目標とする。本論文で提案する方法は、さまざまな高精度センサを利用するのではなく、モーションデータを収集するためにウェアラブルカメラのみを必要とする方法である。このため安価な方法・システムとなり、将来の歩行分析システム研究のための理論および応用の基盤を築くものである。

1.2 従来研究の動向と位置付け

1.2.1 人の歩行姿勢解析

歩行姿勢とは、歩行時の人の姿勢や動作特性を指す。歩行姿勢解析は、人間の歩行規則性の体系的な研究であり[11]、臨床診断、治療効果の評価、およびメカニズム研究に役立つリハビリテーションの評価と治療を導くために、異常な歩

歩行姿勢と影響要因を明らかにすることを目的としている。通常の歩行サイクルにおける歩行姿勢[12]では、各歩行周期は、立脚期と遊脚期の2つの期間に分けることができ、立脚期が歩行周期の約60%、遊脚期が約40%を占める。歩行サイクルは、最初の着地、体重負荷反応、中間立脚、立脚終了、スイング初期、スイング中間、およびスイング終了に分けることができる。研究データのソースの違いによって、歩行姿勢解析方法は、センサベースとビジョンベースの2種類に分けることができる。

センサベースの方法は、さまざまなウェアラブルセンサを介して被験者の歩行特性を収集し、一般的により信頼性の高い測定結果を得ることができる[13,14]。近年、さまざまなセンサが歩行特性の取得に適用されている。例えば、Louら[15]は、靴のワイヤレス足底圧力測定システムを開発した。特殊なプロセスで製造された柔軟な圧力センサが靴に埋め込まれており、人の足裏の動圧分布をリアルタイムで取得し、歩行特性を定量的に分析できる。Campsら[16]は、腰に装着した慣性計測素子を用いてパーキンソン病患者の歩行の凍結特性、つまり動作中の突然の一時停止またはブロックを検出し、ディープラーニングに基づいて歩行異常を特定する方法を提案した。Seifertら[17]は、レーダーセンサを使用して歩行姿勢関連の特徴を収集し、得られた信号によるさまざまな歩行姿勢を分類している。センサベースの方法は、歩行姿勢の測定と解析の分野で広く利用されている。しかし、その一方で限界も多い。高精度センサデバイスは非常に高価であり、購入や破損後の修理費用が非常に高く、普及が難しいという問題がある。すべてのデータ収集プロセスは特定の実験室環境で実行する必要があり、使用場所は限られている。また、測定時には経験豊富な専門家がセンサデバイスを被験者に装着する必要があり、時間と労力がかかる。さらに、被験者の体に取り付けられたセンサデバイスは、被験者の歩行運動状態にもある程度影響を与え[18]、測定結果に一定の偏差をもたらす。

ビジョンベースの歩行姿勢解析方法は、データを収集するためにカメラのみを必要とし、被験者に対して非侵襲的であり、人の運動歩行を妨げない。よって、収集された歩行姿勢特徴はより正確になる[19]。例えば、Nieto-Hidalgoら[20]は、1台のカメラのみで歩行映像を記録する、マーカーを使用しないシステムを提案した。そして、システムをスマートフォンに載せそのカメラで歩行映像を収集し、正常歩行と異常歩行の分類を行っている。Stenumら[21]は、既存の深層学習姿勢推定モデルDeepPose[22]に基づいて歩行特徴を推定し、歩幅、周期、股関節と膝のサジタル角度などの歩行パラメータを推定し、良好な精度を達成した。Liu[23]は、異常な歩行姿勢を検出するためのビデオベースの歩行姿勢解析システムを提案した。測定対象物に触れることなく、一定期間の歩行特性を取得できる。最近、多くの研究では、MicrosoftのKinectカメラを使用して、3D骨格フレームワ

ークや深度画像情報を利用するなど、歩行姿勢解析研究のためのより豊富な姿勢情報を収集している。Junら[24]は、2つのリカレントニューラルネットワークのオートエンコーダを用いて、3D骨格データから特徴を抽出し、異常な歩行姿勢を識別する方法を提案した。

センサベースのモーションキャプチャシステムは、その安定した性能と高精度により、歩行解析におけるモーションキャプチャシステムの一般的なソリューションとして使用されてきた。ただし、このシステムはさまざまなセンサデバイスに大きく依存するため、臨床現場での大規模なアプリケーションが制限される。コンピュータビジョン技術の発展に伴い、ビジョンベースの歩行姿勢解析が徐々に研究のホットスポットになり、ビデオからの歩行姿勢解析に関する研究がますます行われ、いくつかの進歩がみられている。人の姿勢から歩行姿勢特徴を取得するため、画像データから人の姿勢を取得することがキーコンテンツとなる。

1.2.2 人の歩行姿勢推定

人の姿勢推定は、コンピュータビジョンの分野における重要な研究課題である。数十年にわたって開発されてきた人間の姿勢推定の諸技術は、特定の外部センサから人の姿勢を取得し、さまざまな部位の位置と構造を推定することを目的としている[25]。近年は、特に画像やビデオから人の姿勢を推定する研究が多い。人の姿勢推定では、人の姿勢の幾何学的情報と身体運動情報を取得でき、これらの情報は、ヒューマンコンピュータインタラクション、歩行姿勢解析、運動解析、モーションキャプチャ、現実拡張、バーチャルリアリティ、医療リハビリテーションなど多くの分野に適用できる。

近年の人工知能技術の発展に伴い、コンピュータビジョンの分野も様々な分野でさらなる進歩を遂げている。ビジョンベースの人間の姿勢推定は、2次元の人の姿勢推定と3次元の人の姿勢推定に分けることができる。2次元の人の姿勢推定の場合、画像や映像の入力情報をもとに、人の関節点位置を推定し、結果としてピクセル座標位置を出力する。通常、正確なラベル付きの2次元データを使用し、2次元の人の姿勢をより正確に予測できる。対照的に、3次元の人の姿勢推定では、より正確な3次元の姿勢のラベル情報を取得することは困難である。したがって、ほとんどの方法はモーションキャプチャを使用し、特定の実験環境で3次元の人の姿勢データを取得する。そのようなデータはすべての自然環境をカバーすることは困難であり、特に環境変化に対処することは困難となる。同時に、人のさまざまな部位の姿勢推定が完全に予測できないという問題もあり、研究結果には比較的大きな制限がある。2次元画像とビデオを使用した3次元人の姿勢推定の場合、それはより困難であり、深度情報は比較的あいまいで

あるため、姿勢を推定するのが困難になる。以下に、2次元の人の姿勢推定法と3次元の人の姿勢推定法の2つの側面から研究状況を紹介する。

1) 人の2D姿勢推定法

人の2D姿勢推定法では、画像またはビデオに基づいて、人のキーポイントの2D座標または空間位置を推定する。従来の2次元の人の姿勢推定法は、手作業で設計された特徴抽出器を使用し、画像から人の特徴情報を抽出する。たとえば、HOG特徴量[26]、SIFT特徴量[27]、BoDW特徴量[28]などである。次に、深層学習に基づく人の2D姿勢推定の開発について、対象が1人の場合と複数人の場合について述べる。

1人の姿勢推定とは、入力画像中の1人の人物の人の姿勢を2次元で推定することである。入力画像に複数の人物が写っている場合、通常は各人物が検出され、1つのフレームに1人だけが写るようにトリミングされてから、1人の人の姿勢推定が実行される。一般的に言えば、深層学習を用いた1人の人の2D姿勢推定法には、主に2つのタイプがある：①直接回帰法、②部位検出法。直接回帰法では、end-to-endのフレームワークを用いて、入力画像から人の関節点座標へのマッピングを学習する。部位検出法は、体の部位や関節点の位置を予測するものである[29]。ヒートマップ[30]は関節点の位置を表すために使用され、ネットワークトレーニングの監視として使用される。ヒートマップ監視に基づくフレームワークは、2D姿勢推定で広く使用されている。

複数人の人間の姿勢推定は、1人の人の姿勢推定よりも困難である。画像上に写っている特定の人数と各人の姿勢を把握する必要があるため、オクルージョンや人のスケールの違いなどの問題がある。これらの問題に対処するために、複数人の人の姿勢推定法は、トップダウン法とボトムアップ法に分類できる。トップダウン法は、主に人物検出モジュールと1人の姿勢推定モジュールという2つの部分で構成される。最初に人物検出ネットワークを使用して画像内の各人物を検出し、次に各人物に対して人の姿勢推定を行う。一方、ボトムアップ法は、すべての人のキーポイントの検出とキーポイントのグループ化という2つの主な手順で構成される。最初に画像内のすべての人のキーポイントを検出し、次にすべてのキーポイントをグループ化し、それらをさまざまな個人に一致させる。

現在の多数の人の2D姿勢推定は良好な予測性能を達成しているが、ほとんどの場合は自然シーンにおけるRGB画像の研究に基づいている。ただし、人の歩行姿勢で発生する低い解像度の画像と情報損失の問題については、これらの方法にはすべて特定のパフォーマンスのボトルネックがある。したがって、これらのシーンデータの姿勢推定モデルの構築が急務であり、本論文では、これらの問題の解決を図る。

2) 人の 3D 姿勢推定法

人の 3D 姿勢推定は、3D 空間における人の関節の位置を予測することを目的としており、映画やアニメーション産業、仮想現実分野、リハビリテーション医学研究において重要なアプリケーションシナリオがある。現在の人の 3D 姿勢推定は、単視点と多視点の 2 種類に分けることができる。

単視点の画像またはビデオから 3D の人の姿勢を再構築することは困難であり、主な問題には、自己オクルージョン、他のオブジェクトのオクルージョン、深度情報のあいまいさ、および弱いモデル表現能力が含まれる。単視点の 3D 姿勢推定法は、2D 画像推定法と 2D 座標推定法に分けられる。

2D 画像から人の 3D 姿勢を推定するために、Sun ら[31]は人の構造を認識する回帰法を提案した。骨格のキャラクター化法は、関節点のキャラクター化法を置き換えるために使用され、全体的な安定性が高くなる。Pavlackos ら[32]は、高度に非線形な 3 次元座標回帰問題を離散空間で制御可能な方法に変換するボリューム表現法を提案し、ニューラルネットワークに基づき 3 次元空間内の各関節点のボクセル確率を予測した。

2 次元座標から 3 次元の人の姿勢を予測する方法については、Martinez ら[33]は、2 次元の関節のピクセル座標を用いて 3 次元座標を回帰させる、全結合残差ネットワークによる表現法を提案した。ただし、この方法はトレーニングデータの量に依存するため、モデルの汎用性が低くなる。さらに、Chen ら[34]は、連続するビデオフレーム間で解剖学的特徴が一貫していることを保証するために、人の骨の方向と長さを特徴付ける時間情報感知ネットワークを提案した。要約すると、単視点の人の姿勢推定は一定の高いレベルを達成したが、人の動きの過程でのオクルージョンの問題を解決することはできない。

多視点推定法では、オクルージョンの問題をある程度解決するが、多くの場合、複数のカメラが必要となり、異なるカメラ間の位置相関の問題が保証される必要がある。Pavlakos ら[35]と Zhang ら[36]は、多視点画像の 2D キーポイントヒートマップを、キャリブレーションされたすべてのカメラパラメータに基づいて 3D グラフ構造モデルに集約する方法を提案している。ただし、学習済みモデルは学習したカメラから撮影したシーンにしか適用できず、カメラが変わるとモデルは適用できなくなる。Qiu ら[37]の提案法は、マルチビューの幾何学的事前分布をモデルに組み込むことにより、マルチビュー画像入力から 3D 姿勢を推定する。マルチビュー情報を利用した人の 3D 姿勢推定法により、最先端のパフォーマンスが実現されている。ただし、これらの方法は、正確にキャリブレーションされたカメラ内部パラメータ情報に大きく依存しているため、実際のアプリケーションシナリオでリアルタイム同期を取得することは困難である。特に、

人とカメラとの距離は、人の移動中に常に変化するため、これらの方法を実際のシーンに直接適用することも困難である。

ビジョンベースのアプローチ[38][40]には、アニメーションのモーションを作成するために利用されるモーションキャプチャ法[41][42]がある。これは、人の周りに複数台のカメラを設置して人の動きを撮影し、人の3Dモデルを作成する手法であるが、この方法は多数のカメラが必要なため、システムは大規模で広いスペースを必要とし、設置には時間と労力がかかる。

他の方法[43][44]では、関節間の関係を表すために確率的グラフィカルモデルが使用されている。これらの方法は、ツリー構造の状態空間を画像観察と人トポロジーに基づいて辞書式の順序で解析するが、手作業で作成される機能に大きく依存するため、一般化とパフォーマンスが制限される。最近では、歩行者にマーカーを付けてディープラーニングで姿勢を推定するなど、歩行者の関節位置を検出する方法[41][45][46]もある。一例として、ニューラルネットワークを使用した一人称画像からの自己姿勢推定法[47]が提案された。この手法は、画像上のオプティカルフローと深度の推定に基づいているが、人の動きにより、安定した正確なオプティカルフローを抽出することは困難である。

1.3 本研究の位置付けと意義

本論文では、人の日常の歩行支援を想定し、人が自分の身体に装着する（自己装着、ウェアラブル）カメラが提供する正面風景画像からカメラ装着者の歩行姿勢を推定し、人の姿勢を解析する手法を提案する。ウェアラブルカメラを使用して自己姿勢を取得するため、提案法は、エピポーラ幾何を用いて2次元の特徴点を3次元空間上に復元し、カメラモーションの推定と、回転行列の分解による人の歩行姿勢の推定及び解析を行う。本論文で提案された方法が完成することによって、屋内外を問わず歩行姿勢を判定して歩行姿勢のずれを改善することができ、人の健康を維持し、安心・安全な生活の実現に貢献することができる。

1.4 本研究の学術的特色と独創点

従来の研究は、外部固定カメラから撮影された人の画像を用いて人の姿勢推定を行ってきた。本論文で提案する方法は、人が装着した単眼ウェアラブルカメラから得られる周囲の風景画像から、人の歩行姿勢を推定しそれを解析するという点に従来法との明確な違いがあり、この点に本研究の主要な学術的特色と独創点がある。本論文で提案した手法を完成させることによって、軽量・コンパクトなカメラで屋内外を問わずカメラ装着者の歩行姿勢を判定できる。提案手

法を使えば歩行姿勢をこまめにチェックできるので、歩行姿勢が改善できるようになる。

1.5 本論文の構成

本論文の構成は以下の通りである。第1章では本研究の学術的背景と従来研究の動向、また本研究の意義・独創点等について述べる。第2章では提案法が用いる特徴点検出法と特徴点マッチング法について述べる。第3章では対応点を用いた人の歩行姿勢推定法を示す。推定された人の歩行姿勢の解析法を第4章で述べ、実験方法と結果を第5章で示す。第6章で提案法について考察を与え、第7章で結論を述べる。

第2章 特徴点検出とマッチング

本研究では、第3章で述べるように、検出された対応点を用いてエピポーラ幾何による人体歩行姿勢推定を行う。そのため対応点の検出は重要である。したがって、対応の取りやすい特徴点の検出は重要である。

特徴点検出と特徴点マッチングのために、Lowe は、SIFT(Scale-Invariant Feature Transform)[49]を提案した。この手法は、元の画像にガウスクアーネルを畳み込むことによってスケール空間を構築し、ガウス差分ピラミッド上のスケール不変の特徴点を検出する。SIFTの計算プロセスにおける速度と計算の複雑さの欠点を補うために、Bayらは、SURF(Speeded Up Robust Features)[50]を提案した。近似 Haar ウェーブレットアルゴリズムを使用して特徴点を抽出することにより、近似 Haar ウェーブレット値は、異なるスケール空間で統合することによって取得される。これにより2次微分テンプレートの構築が削減され、その結果特徴マッチングの効率が向上する。ただし、これら2つの方法で構築されたガウススケール空間は、画像のエッジの詳細情報が無視される。Alcantarillaらは、非線形拡散を用いて非線形スケール空間で特徴を記述することによって、画像のエッジ情報を保存できるAKAZE(Accelerated-KAZE)[51]と呼ばれる新しい2D特徴点検出法を提案した。本研究では、強力な特徴点検出器であるAKAZEを用い、またLK(Lucas-Kanade)追跡法[52]を利用して特徴点間のマッチングを行う。

2.1 AKAZE 特徴点検出器

AKAZE は非線形フィルタリングを用いてスケール空間を構築し、画像のエッジ情報を保存する。非線形フィルタリングの原理は式(2.1)で表される。

$$\frac{\partial L}{\partial x} = \text{div}(c(x, y, t) \cdot \nabla L) \quad (2.1)$$

ここで、 L は画像の輝度、 div と ∇ は発散と勾配、 c は拡散を局所的な画像構造に適応させる関数である。

AKAZE のスケール空間はピラミッド型で、 O オクターブと S サブレベルがある。時間 t_i に応じてスケール空間の構築が拡散関数により実現される。オクターブとサブレベルのインデックスは、次式によって対応するスケール σ (pixels) にマッピングされる。

$$\sigma_i(o, s) = \sigma_0 2^{\frac{o+s}{S}}, o \in [0, 1, \dots, O-1], s \in [0, 1, \dots, S-1], i \in [0, 1, \dots, M] \quad (2.2)$$

ここで、 M はスケール空間内の画像の総数、 σ_0 は初期スケールパラメータである。非線形拡散フィルタリングと時系列の関係により、次式を用いてスケールパラメータ σ_i (pixels)を時間 t_i に変換する。

$$t_i = \frac{1}{2} \sigma_i^2, i = 0, 1, \dots, M \quad (2.3)$$

FED(fast explicit diffusion)を使用すると式(2.1)の解が得られ、画像の非線形スケール空間は次のように得られる。

$$L^{i+1} = (I + \tau A(L^i)) L^i \quad (2.4)$$

ここで、 I は単位行列、 $A(L^i)$ は i 次元の画像の変換行列、 τ はステップサイズ、その値は $t_{i+1} - t_i$ である。

ある点を異なる尺度空間でその近傍にある他の点と比較し、Hessian 行列が最大値になったときに画像の特徴点を見つける。

$$L_{Hessian} = \sigma^2 (L_{xx} L_{yy} - L_{xy}^2) \quad (2.5)$$

ここで、 σ はスケールパラメータ σ_i の整数値である。

次に、テイラー展開に基づいてサブピクセルポイントの正確な位置を求め、特徴点のサブピクセル座標を導出する。

$$L(x) = L + x \left(\frac{\partial L}{\partial x} \right)^T + \frac{1}{2} x x^T \frac{\partial^2 L}{\partial x^2} \quad (2.6)$$

$$x = - \frac{\partial L}{\partial x} \left(x \frac{\partial^2 L}{\partial x^2} \right)^{-1} \quad (2.7)$$

ここで、 x は特徴点の位置座標である。

AKAZE アルゴリズムは、M-LDB (Modified-Local Difference Binary)記述子を使用してピクセルをサンプリングして平均化することによって、リアルタイムのパフォーマンスを確保し、スケールの適応を実現する。

2.2 LK 法によるオプティカルフローの計算

LK 追跡法は目標追跡の分野で広く使用されており、特徴点マッチングへの適用は比較的限られている。特徴点を検出した後、特徴点ペアを見つけるためにマッチング領域を探す必要がある。LK 追跡法を使用して画像の特徴点を追跡し、一致する領域を見つける。

LK 追跡法は2フレーム間の画像を差分し、オプティカルフローを推定するこ

とであり、以下の3つの仮定に基づいている。

① 一定の明るさ。

同じ点が時間とともに変化し、その明るさが変化しない。オプティカルフロー法の基本式を取得するために使用される基本的なオプティカルフロー法の仮定である。(様々なオプティカルフロー法がこの条件に満たされている必要がある。) グレースケール画像の場合、これは、フレームが追跡されてもピクセルのグレースケール値が変化しない。

② 時間の持続性 (小さな動き)。

時間の変化は、位置の劇的な変化を引き起こさないため、グレースケールは位置の偏導関数を計算する。これもオプティカルフロー法の前提条件である。画像上のカメラの動きは時間とともにゆっくりと変化する。

③ 空間の一貫性。

シーン内の同じ表面上の隣接する点は同様の動きをしており、画像平面へのそれらの投影も隣接領域にある。これはLK追跡法の独自の仮定である。条件①により次式が得られる。

$$I(x, y, t) = I(x + \Delta x, y + \Delta y, t + \Delta t) \quad (2.8)$$

ここで、 $I(x, y, t)$ は時刻 t における位置 (x, y) の画素値である。

条件②が成立することから、式(2.8)をテイラー展開して、

$$I(x + dx, y + dy, t + dt) = I(x, y, t) + \frac{\partial I}{\partial x} dx + \frac{\partial I}{\partial y} dy + \frac{\partial I}{\partial t} dt \quad (2.9)$$

となる。移動量は小さいため、第2項以降のテイラー展開を省略する。 t に対して微分すれば、式(2.9)は次式のように変換される。

$$I_x u + I_y v + I_t = 0 \quad (2.10)$$

ただし、

$$u = \frac{dx}{dt}, v = \frac{dy}{dt} \quad (2.11)$$

$$I_x = \frac{\partial I}{\partial x}, I_y = \frac{\partial I}{\partial y}, I_t = \frac{\partial I}{\partial t} \quad (2.12)$$

である。

式(2.10)を行列の形に書き換える。

$$\begin{bmatrix} I_x & I_y \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = -I_t \quad (2.13)$$

条件③により，サイズ $m \times m$ の小さなウィンドウでオプティカルフローが一致していると仮定すれば，画像 $1, 2, \dots, n (n = m^2)$ から次式が得られる．

$$\begin{aligned}
 I_{x_1}u + I_{y_1}v &= -I_{t_1} \\
 I_{x_2}u + I_{y_2}v &= -I_{t_2} \\
 I_{x_3}u + I_{y_3}v &= -I_{t_3} \\
 &\dots\dots \\
 I_{x_n}u + I_{y_n}v &= -I_{t_n}
 \end{aligned} \tag{2.14}$$

ここで，

$$\mathbf{A} = \begin{bmatrix} I_{x_1} & I_{y_1} \\ I_{x_2} & I_{y_2} \\ \vdots & \vdots \\ I_{x_n} & I_{y_n} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} -I_{t_1} \\ -I_{t_2} \\ \vdots \\ -I_{t_n} \end{bmatrix}, \mathbf{V} = \begin{bmatrix} u \\ v \end{bmatrix} \tag{2.15}$$

と置けば，式(2.14)は次のように書ける．

$$\mathbf{AV} = \mathbf{b} \tag{2.16}$$

よって，最小二乗法によるオプティカルフロー \mathbf{V} の解は式(2.17)で与えられる．

$$\mathbf{V} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \tag{2.17}$$

行列の可逆性を考慮すれば，

$$\mathbf{A}^T \mathbf{A} = \begin{bmatrix} \sum I_x^2 & \sum I_x I_y \\ \sum I_x I_y & \sum I_y^2 \end{bmatrix} \tag{2.18}$$

から，次式のように \mathbf{V} が得られる．

$$\mathbf{V} = \begin{bmatrix} \sum I_x^2 & \sum I_x I_y \\ \sum I_x I_y & \sum I_y^2 \end{bmatrix}^{-1} \begin{bmatrix} -\sum I_x I_t \\ -\sum I_y I_t \end{bmatrix} \tag{2.19}$$

LK 追跡法は，オプティカルフローが小さいほど精度が高くなるが，移動量が大きくなれば，特徴点が失われる可能性がある．特徴点の移動速度が速いと誤差が大きくなることを考えると，画像中の特徴点の移動速度を遅くすることが望まれる．直接的なアプローチは，画像サイズを縮小することである．




図 2.1 画像ピラミッド

原画像を大きくスケーリングした後，上記の方法が適用可能になる．したがって，オプティカルフローは，原画像の画像ピラミッドを生成し，それをレイヤーごとに解決し，継続的に正確にすることによって取得できる．LK 追跡法でオプティカルフローを求めた結果の例を図 2.2 に示す．



図 2.2 LK 法によるオプティカルフロー

2.3 特徴点マッチング

マッチング領域は、LK 追跡法を適用して取得され、次のステップで、特徴点マッチングを行う。最もよく使用されるアルゴリズムは、BF(Brute Force)アルゴリズムと FLANN(Fast Library Approximate Nearest Neighbor Search)アルゴリズムである。BF アルゴリズムは、特徴記述子とその他のすべての記述子の距離を計算し、距離が最も小さい記述子を選択して対応点を取得する。FLANN アルゴリズムは最近傍探索を行う。BF アルゴリズムは記述子間の距離のみに基づいて対応点を判断するため、誤対応が発生しやすくなる。したがって、FLANN アルゴリズムを用いて特徴点マッチングを行う。

第3章 人の歩行姿勢推定

本論文で提案する方法は、エピポラ幾何を用いて、ウェアラブルカメラで撮影される映像からカメラ相対運動の推定を行う。カメラの相対運動は、回転行列と並進ベクトルによって記述され、取得された回転行列は各軸周りの回転に分解される。得られた各軸周りの回転角度は人の歩行姿勢の変化として利用される。

本章では、エピポラ幾何を用いた歩行姿勢の推定方法について述べる。

情景撮影に用いるウェアラブルカメラは、キャリブレーションによりその内部パラメータが事前に導出される。ウェアラブルカメラから一定のフレーム間隔で提供されるビデオから連続する2枚の画像が抽出され、第3章で述べた方法によって画像間の対応点が求められる。2画像間のカメラの相対運動パラメータを含む基本行列は、5点アルゴリズム[53]を用いて対応点群から推定される。基本行列からカメラの相対運動を算出し、各軸周りの回転運動を求める。

3.1 基本行列の推定

2画像間の対応点を $\mathbf{p}=[x, y, 1]^T$, $\mathbf{p}'=[x', y', 1]^T$ で表せば、基本行列 \mathbf{E} と対応点組 \mathbf{p}, \mathbf{p}' の関係は以下の式で与えられる。

$$\mathbf{p}'\mathbf{K}^{-T}\mathbf{E}\mathbf{K}^{-1}\mathbf{p} = 0 \quad (3.1)$$

$$\mathbf{q}'^T\mathbf{E}\mathbf{q} = 0 \quad (3.2)$$

ただし、 \mathbf{K} はカメラの内部パラメータ行列、 \mathbf{E} は基本行列、 \mathbf{q}, \mathbf{q}' は正規化された画像の対応点である。

5点アルゴリズムを用いて基本行列 \mathbf{E} を算出する。

1組の対応点 $\mathbf{q}=[x_N', y_N', 1]^T$, $\mathbf{q}'=[x_N, y_N, 1]^T$ から1つの線形方程式が取得できる。

$$[x_N' \quad y_N' \quad 1] \begin{bmatrix} e_{11} & e_{12} & e_{13} \\ e_{21} & e_{22} & e_{23} \\ e_{31} & e_{32} & e_{33} \end{bmatrix} \begin{bmatrix} x_N \\ y_N \\ 1 \end{bmatrix} = 0$$

$$[x_N x_N' \quad x_N y_N' \quad x_N \quad y_N x_N' \quad y_N y_N' \quad y_N \quad x_N' \quad y_N' \quad 1] \tilde{\mathbf{E}} = 0 \quad (3.3)$$

ただし、

$$\tilde{\mathbf{E}} = [e_{11}, e_{21}, e_{31}, e_{12}, e_{22}, e_{32}, e_{13}, e_{23}, e_{33}]^T$$

5点アルゴリズムを用いた場合、5つの方程式が得られる。

$$\begin{bmatrix} x_{N_1}x_{N_1}' & x_{N_1}y_{N_1}' & x_{N_1} & y_{N_1}x_{N_1}' & y_{N_1}y_{N_1}' & y_{N_1} & x_{N_1}' & y_{N_1}' & 1 \\ x_{N_2}x_{N_2}' & x_{N_2}y_{N_2}' & x_{N_2} & y_{N_2}x_{N_2}' & y_{N_2}y_{N_2}' & y_{N_2} & x_{N_2}' & y_{N_2}' & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{N_5}x_{N_5}' & x_{N_5}y_{N_5}' & x_{N_5} & y_{N_5}x_{N_5}' & y_{N_5}y_{N_5}' & y_{N_5} & x_{N_5}' & y_{N_5}' & 1 \end{bmatrix} \tilde{\mathbf{E}} = \mathbf{0} \quad (3.4)$$

しかし、 \mathbf{E} は9つの要素を持つ 3×3 行列であり、線形方程式は5つしかないため、自由度が4の線形解空間が得られる。線形解空間は

$$\mathbf{E} = C_1\mathbf{X} + C_2\mathbf{Y} + C_3\mathbf{Z} + \mathbf{W} \quad (3.5)$$

となる。

基本行列 \mathbf{E} の性質により、以下の制約方程式が成り立つ。

$$\det(\mathbf{E}) = 0 \quad (3.6)$$

$$\mathbf{E}\mathbf{E}^T\mathbf{E} - \frac{1}{2}\text{trace}(\mathbf{E}\mathbf{E}^T)\mathbf{E} = \mathbf{0} \quad (3.7)$$

ただし、 $\text{trace}(\mathbf{E}\mathbf{E}^T)$ は $\mathbf{E}\mathbf{E}^T$ の対角成分の和である。

式(3.5)を制約方程式に代入して C_1, C_2, C_3 を求めれば、基本行列 \mathbf{E} が確定する。

上述した5点アルゴリズムを用いて基本行列 \mathbf{E} の推定を行うときに、第2章の方法による特徴点マッチングに誤対応が存在する場合、基本行列の推定精度が落ちる。そのため、RANSAC(Random Sample Consensus)[54]を用いて推定精度を向上させる。RANSACは、ロバスト推定のアルゴリズムの1つである。ロバスト推定は、与えられた観測値に外れ値が含まれる可能性を考慮し、その影響を抑える方法である。RANSACは以下の手順に従う。

Step1: 得られた対応点組の中からランダムに5組の対応点を選択し、5点アルゴリズムを用いて基本行列 \mathbf{E} を推定する。

Step2: エピポーラ拘束式 $\mathbf{q}^T\mathbf{l} = 0$ を満たす \mathbf{l} を導出する。

$$\mathbf{l} = [a \quad b \quad c]^T = \mathbf{E}\mathbf{q}$$

Step3: すべての特徴点 \mathbf{q}' と \mathbf{l} 間の距離 d （次式で与えられる）を算出し、距離が閾値以下の場合に投票する。

$$d = \frac{|ax_N + by_N + c|}{\sqrt{a^2 + b^2}}$$

Step4: Step1 から Step3 の処理を数回繰り返す。

Step5: 得票数が最も多い基本行列**E**を最適な結果とする.

3.2 カメラの相対運動の推定

本節では, 基本行列からカメラの相対運動を計算する方法について述べる.
基本行列**E**は式(3.8)のように表示される.

$$\mathbf{E} = [\mathbf{t}]_{\times} \mathbf{R} \quad (3.8)$$

$$\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix}, \mathbf{t} = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix}, [\mathbf{t}]_{\times} = \begin{bmatrix} 0 & -t_3 & t_2 \\ t_3 & 0 & -t_1 \\ -t_2 & t_1 & 0 \end{bmatrix}$$

ただし, **R**は回転行列, **t**は並進ベクトル, $[\mathbf{t}]_{\times}$ は**t**の歪対称行列である.

$[\mathbf{t}]_{\times}$ は歪対称行列であるため, 歪対称行列の性質より, 式(3.9)が得られる.

$$[\mathbf{t}]_{\times} = k\mathbf{U}\mathbf{Z}\mathbf{U}^T$$

$$\mathbf{Z} = \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \mathbf{W} = \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.9)$$

$$[\mathbf{t}]_{\times} = k\mathbf{U} \text{diag}(1,1,0)\mathbf{W}\mathbf{U}^T$$

ただし, **U**は直交行列である.

式(3.9)を式(3.8)に代入すれば

$$\mathbf{E} = [\mathbf{t}]_{\times} \mathbf{R} = k\mathbf{U} \text{diag}(1,1,0)\mathbf{W}\mathbf{U}^T \mathbf{R} \quad (3.10)$$

となる.

基本行列**E**を次式のように特異値分解する.

$$\mathbf{E} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \quad (3.11)$$

ただし, **U**, **V**は直交行列, **Σ**は特異値を持つ対角行列である.

式(3.10)と式(3.11)より,

$$\mathbf{\Sigma} = k \text{diag}(1,1,0)$$

$$\mathbf{W}\mathbf{U}^T \mathbf{R} = \mathbf{V}^T \quad (3.12)$$

これらの行列を用いて**R**と $[\mathbf{t}]_{\times}$ を求めることができる.

$$\mathbf{R} = \begin{cases} \mathbf{U}\mathbf{W}\mathbf{V}^T \\ \mathbf{U}\mathbf{W}^T\mathbf{V}^T \end{cases}, [\mathbf{t}]_{\times} = \begin{cases} \mathbf{U}\boldsymbol{\Sigma}\mathbf{W}\mathbf{U}^T \\ \mathbf{U}\boldsymbol{\Sigma}\mathbf{W}^T\mathbf{U}^T \end{cases} \quad (3.13)$$

式(3.13)から、 \mathbf{R} と $[\mathbf{t}]_{\times}$ の解は4組の組み合わせがある。

3.3 3次元復元

前節で4組の \mathbf{R} と $[\mathbf{t}]_{\times}$ が算出された。本節では、その4組から最も適切な \mathbf{R} と $[\mathbf{t}]_{\times}$ を求める方法について述べる。すなわち、4組の解に対しそれぞれ復元を行い、復元された3次元点群とカメラの位置関係を確認し、適切な \mathbf{R} と $[\mathbf{t}]_{\times}$ を求める。カメラの投影行列は回転行列 \mathbf{R} と並進ベクトル \mathbf{t} から決められる。

2枚の画像の投影行列と投影点をそれぞれ \mathbf{P}, \mathbf{P}' および $\mathbf{m} = [x \ y \ 1]^T, \mathbf{m}' = [x' \ y' \ z']^T$ とすれば、3次元点 \mathbf{X} の投影は次式のように記述できる。

$$\begin{cases} \lambda \mathbf{m} = \mathbf{P}\mathbf{X} \\ \lambda \mathbf{m}' = \mathbf{P}'\mathbf{X} \end{cases}$$

$$\mathbf{P} = \mathbf{K}[\mathbf{I} \ \mathbf{0}] = \begin{bmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{32} & p_{33} & p_{34} \end{bmatrix} \quad (3.14)$$

$$\mathbf{P}' = \mathbf{K}[\mathbf{R} \ \mathbf{t}] = \begin{bmatrix} p'_{11} & p'_{12} & p'_{13} & p'_{14} \\ p'_{21} & p'_{22} & p'_{23} & p'_{24} \\ p'_{31} & p'_{32} & p'_{33} & p'_{34} \end{bmatrix}$$

ただし、 $\mathbf{X} = [X \ Y \ Z \ 1]^T$ は3次元空間内の点、 \mathbf{K} はカメラの内部パラメータ行列、 \mathbf{I} は単位行列、 λ はスケール因数である。

式(3.14)より、次式が得られる。

$$\mathbf{M}\mathbf{X} = \mathbf{b}$$

$$\mathbf{M} = \begin{bmatrix} p_{31}x - p_{11} & p_{32}x - p_{12} & p_{33}x - p_{13} \\ p_{31}y - p_{21} & p_{32}y - p_{22} & p_{33}y - p_{23} \\ p'_{31}x' - p'_{11} & p'_{32}x' - p'_{12} & p'_{33}x' - p'_{13} \\ p'_{31}y' - p'_{t+1,21} & p'_{32}y' - p'_{22} & p'_{33}y' - p'_{23} \end{bmatrix} \quad (3.15)$$

$$\mathbf{b} = \begin{bmatrix} 0 \\ 0 \\ p'_{14} - p'_{34}x' \\ p'_{24} - p'_{34}y' \end{bmatrix}$$




図 3.1 3次元座標点とカメラの位置関係

式(3.15)から 3次元空間内の点 X が算出でき、3次元復元結果を与える。 R と t の4組に対しそれぞれ復元が実行される。3次元座標点とカメラの位置関係は図4.1のように4種類のパターンがあるが、その中で復元された点がカメラ前方に存在する解を与える R と t が適切な R と t である。

バンドル調整を用いて、復元で得られた3次元点群とカメラの相対運動の精度を改善する。3次元点群が画像に再投影されたときに、観察されたデータに最もよく適合するカメラの相対運動 R と t を推定する。Gauss-Newton法[55]を用いて再投影誤差を最小化するような最適な $[R|t]^*$ を次式で計算する。

$$[R|t]^* = \arg \min_{[R|t]} \frac{1}{2} \sum_1^n \| p' - K[R|t]X \|^2 \quad (3.16)$$

ただし、 K はカメラの内部パラメータ行列、 $[R|t]$ はカメラの相対運動行列、 p, p' は対応点である。

3.4 回転行列の分解

得られた最適な回転行列 \mathbf{R} を各軸の周りの回転行列に分解し、各回転行列から各軸の周りの回転角度を算出する．次式に示すように、得られた回転行列 \mathbf{R} はpitch,yaw,roll 軸周りの回転行列 $\mathbf{R}_r, \mathbf{R}_y, \mathbf{R}_p$ に分解される．

$$\mathbf{R} = \mathbf{R}_r \mathbf{R}_p \mathbf{R}_y = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (3.17)$$

$$\mathbf{R}_p = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\theta_p & -\sin\theta_p \\ 0 & \sin\theta_p & \cos\theta_p \end{bmatrix}$$

$$\mathbf{R}_y = \begin{bmatrix} \cos\theta_y & 0 & \sin\theta_y \\ 0 & 1 & 0 \\ -\sin\theta_y & 0 & \cos\theta_y \end{bmatrix} \quad (3.18)$$

$$\mathbf{R}_r = \begin{bmatrix} \cos\theta_r & -\sin\theta_r & 0 \\ \sin\theta_r & \cos\theta_r & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

ただし、 $\theta_p, \theta_y, \theta_r$ はpitch, yaw, roll 軸周りの回転角度である．

\mathbf{R} の各成分は次式で与えられる．

$$\begin{aligned} r_{11} &= \cos\theta_y \cos\theta_r - \sin\theta_p \sin\theta_y \sin\theta_r \\ r_{12} &= -\cos\theta_p \sin\theta_r \\ r_{13} &= \sin\theta_y \cos\theta_r + \sin\theta_p \cos\theta_y \sin\theta_r \\ r_{21} &= \cos\theta_y \sin\theta_r + \sin\theta_p \sin\theta_y \cos\theta_r \\ r_{22} &= \cos\theta_p \cos\theta_r \\ r_{23} &= \sin\theta_y \sin\theta_r - \sin\theta_p \cos\theta_y \cos\theta_r \\ r_{31} &= -\cos\theta_p \sin\theta_y \\ r_{32} &= \sin\theta_p \\ r_{33} &= \cos\theta_p \cos\theta_y \end{aligned} \quad (3.19)$$

上式より、各軸周りの回転角度は次式から求められる．

$$\theta_p = \sin^{-1} r_{32}$$

$$\theta_y = -\tan^{-1} \frac{r_{31}}{r_{33}} \quad (3.20)$$

$$\theta_r = -\tan^{-1} \frac{r_{12}}{r_{22}}$$

式(3.20)より，2 画像間の相対角度変化量が算出でき，それを累積することにより，カメラの運動状況を求めることができる．カメラの運動を人の姿勢変化として解析を行う．

第4章 人の歩行姿勢の解析

第3章で紹介した方法により、2枚の連続する画像を用いて2画像間のカメラ相対運動を求めた。本章では図4.1のように、カメラ初期状態を0[deg]としてカメラの相対運動を累積し、人の歩行姿勢の波形を取得する方法について述べる。波形の不安定性と不規則性により、人の歩行姿勢の波形は比較的複雑であり、そこから直接内部関係を分析することは困難である。そのため波形に処理を行い、その後の分析のために規則的な波形に変換する。また、2画像間の相対運動を累積するため、得られる回転角度の波形は全体的にずれる。よって、人の歩行姿勢の指標を計算する前に、波形から累積誤差を除去する必要がある。

4.1 トレンド除去

得られた歩行波形の累積誤差を除去するため、トレンド除去を行う。トレンド除去により、データ取得時に発生するずれが後の計算に与える影響を取り除くことができる。データからトレンドを除去することによって、データの傾向の変動のみに注目して解析することができる。トレンド除去の原理は、図4.2に示すように、原データから近似直線を引くことによって、データのトレンド変化を除去することである。この方法により、波形の変動特性を得ることができる。最小二乗法により画像トレンドの近似直線を求め、横軸に対応する得られた近似直線の縦座標値を原データの縦座標値から減算する。




図4.1 人の歩行姿勢の波形（通常歩行）




図 4.2 データの傾向（通常歩行）

4.2 波形の補正

トレンド除去により，一般に初期角度が $0[\text{deg}]$ ではなくなり，フーリエ変換を行う場合，両端の値が一致しないため，不連続が生じてしまう．一般に滑らかではない不連続性の波形をフーリエ変換すると，そのスペクトルは低周波数から高周波数まで非常に広い範囲に分散し，本来の周波数成分以外に余分なスペクトルがたくさん出てくる．したがって，本論文で提案する方法では，トレンド除去された歩行姿勢の波形に対し，式(4.1)で記述されるハミング窓関数[56]を用いて波形の両端をほぼ $0[\text{deg}]$ に近似する．

$$g(x) = \begin{cases} 0.54 - 0.46\cos 2\pi x, & \text{if } a \leq x \leq b \\ 0, & \text{otherwise} \end{cases} \quad (4.1)$$

波形の両端を 0 に近似し，不連続性が若干残る分，裾野の広がりはずかには大きくなる．一方，ピークはより鋭くなって，周波数分解能が高まるという特徴を持っている．次に，図 4.4 の波形にフーリエ変換を実行し，振幅スペクトルを取得する．図 4.5 に示すように最大振幅スペクトルを与える波形の極値を見つけ，図 4.6 のように，人の歩行姿勢波形の極値を求める．




図 4.3 トレンド除去後の波形（通常歩行）




図 4.4 ハンミング処理後の波形（通常歩行）

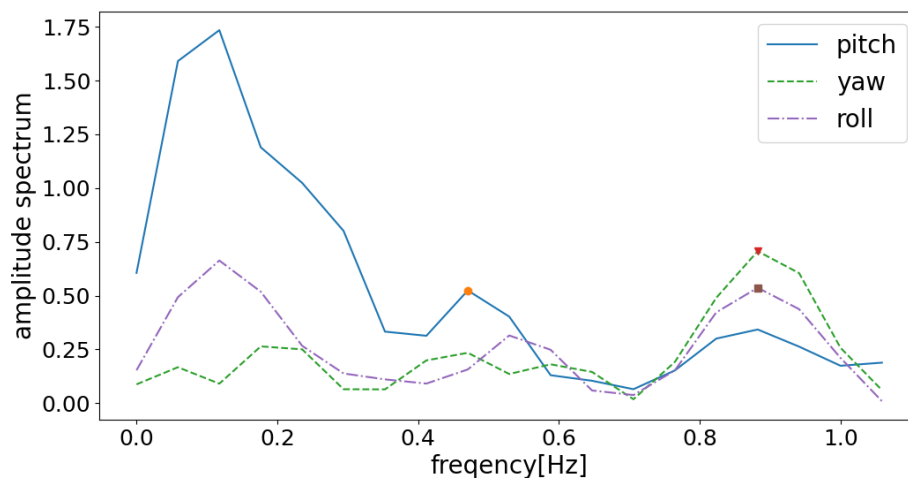


図 4.5 フーリエ変換後の周波数 (通常歩行)




図 4.6 人の歩行姿勢波形の極値 (通常歩行)

4.3 人の歩行姿勢の指標

上述の処理によって得られる人の体歩行姿勢の波形は歩行の開始と終了の区間を含むため、実際に歩行している区間と歩行動作の安定性を考慮し、最初と最後の数秒の区間を除き、残りの区間のデータを使用する。

歩行姿勢を評価する指標として、提案法は図 4.6 のグラフ上の極値を用いる。

まず、pitch, yaw, roll の各軸について、極大値及び極小値の平均値を次式で定義する。

$$\begin{aligned}\bar{P}_{l_max} &= \frac{1}{N} \sum_{i=1}^N a_{i_p}, & \bar{P}_{l_min} &= \frac{1}{N} \sum_{i=1}^N b_{i_p} \\ \bar{Y}_{l_max} &= \frac{1}{N} \sum_{i=1}^N a_{i_y}, & \bar{Y}_{l_min} &= \frac{1}{N} \sum_{i=1}^N b_{i_y}\end{aligned}\quad (4.2)$$

$$\bar{R}_{l_max} = \frac{1}{N} \sum_{i=1}^N a_{i_r}, \quad \bar{R}_{l_min} = \frac{1}{N} \sum_{i=1}^N b_{i_r}$$

ただし、 $a_{i_p}, a_{i_y}, a_{i_r}$ は i 番目 ($i = 1, 2, \dots, N$) の pitch, yaw, roll 軸の極大値、 $b_{i_p}, b_{i_y}, b_{i_r}$ は i 番目 ($i = 1, 2, \dots, N$) の pitch, yaw, roll 軸の極小値、 $\bar{P}_{l_max}, \bar{P}_{l_min}, \bar{Y}_{l_max}, \bar{Y}_{l_min}, \bar{R}_{l_max}, \bar{R}_{l_min}$ は pitch, yaw, roll 軸の極大値の平均値と極小値の平均値である。

次に、隣接する極大値と極小値を用いて、次式のように人の歩行姿勢の揺れ度 $\varphi_{i_p}, \varphi_{i_y}, \varphi_{i_r}$ と人の歩行姿勢の傾斜度 $\rho_{i_p}, \rho_{i_y}, \rho_{i_r}$ から、平均揺れ度 $\bar{\varphi}_p, \bar{\varphi}_y, \bar{\varphi}_r$ 及び平均傾斜度 $\bar{\rho}_p, \bar{\rho}_y, \bar{\rho}_r$ を次式で定義する。

$$\varphi_{i_p} = a_{i_p} - b_{i_p}, \varphi_{i_y} = a_{i_y} - b_{i_y}, \varphi_{i_r} = a_{i_r} - b_{i_r}\quad (4.3)$$

$$\rho_{i_p} = \frac{a_{i_p} + b_{i_p}}{2}, \rho_{i_y} = \frac{a_{i_y} + b_{i_y}}{2}, \rho_{i_r} = \frac{a_{i_r} + b_{i_r}}{2}\quad (4.4)$$

$$\bar{\varphi}_p = \frac{1}{N} \sum_{i=1}^N \varphi_{i_p}, \bar{\varphi}_y = \frac{1}{N} \sum_{i=1}^N \varphi_{i_y}, \bar{\varphi}_r = \frac{1}{N} \sum_{i=1}^N \varphi_{i_r}\quad (4.5)$$

$$\bar{\rho}_p = \frac{1}{N} \sum_{i=1}^N \rho_{i_p}, \bar{\rho}_y = \frac{1}{N} \sum_{i=1}^N \rho_{i_y}, \bar{\rho}_r = \frac{1}{N} \sum_{i=1}^N \rho_{i_r}\quad (4.6)$$

人の歩行姿勢の揺れ度と傾斜度は、主に高齢者の転倒防止や、手術後の回復期における脊椎や下肢へのわずかな姿勢変化の影響、また人のバランス変化を防ぐために利用できる。これらの指標を解析することによって、歩行姿勢の問題点を把握し、歩行姿勢の改善につなげる事が期待できる。

4.4 人の歩行姿勢の認識

4.3 章で述べた人の歩行姿勢の指標を求める。各軸の揺れ度と傾斜度を用いて次式の特徴ベクトルを作成する。

$$\mathbf{v} = [\bar{\varphi}_p, \bar{\varphi}_y, \bar{\varphi}_r, \bar{\rho}_p, \bar{\rho}_y, \bar{\rho}_r] \quad (4.7)$$

本提案法では、SVM(Support Vector Machine)[57][58]に基づいて3人の被験者 H_i ($i=1,2,3$)に対して3箇所(A, B, C)と4種類の歩行姿勢 M_j ($j=1,2,3,4$)を用いて歩行姿勢認識を行う。

1人1箇所4動作を1組とすれば、全部でデータセットは9組となる。4種類の歩行姿勢を区別するため、6個の2クラス分類器 C を次式のように作成する。

$$C \in \{(M_k, M_i) | k = 1, 2, 3, i = 2, 3, 4, k < i\}$$

すべてのクラス分類結果から投票を行い、最大得票数の姿勢を認識結果とする。学習データを L_i ($i=1, \dots, 8$)、テストデータを T ($T \neq L_i$) とすれば、次式のように表される。

$$\begin{aligned} L_i &= (L_{iM_1}, L_{iM_2}, L_{iM_3}, L_{iM_4}) \\ T &= (T_{M_1}, T_{M_2}, T_{M_3}, T_{M_4}) \\ \mathbf{y} &= (y_{M_1}, y_{M_2}, y_{M_3}, y_{M_4}) \end{aligned} \quad (4.8)$$

ただし、 L_{iM_j} 、 T_{M_j} と y_{M_j} はそれぞれ歩行姿勢 M_j ($j=1, 2, \dots, 4$) の式(4.7)のような6次元特徴ベクトルと L_{iM_j} のラベルである。

学習データを次式のように作成する

$$\{(L_{iM_j}, y_{M_j}) | i = 1, 2, \dots, 8, j = 1, 2, \dots, 4\} \quad (4.9)$$

SVM を使用すると、低次元の非線形分離不可能な特徴を高次元の線形分離可能な特徴に変換できる。SVM アルゴリズムは、内積カーネル関数を利用して高次元空間への非線形マッピングを実現し、高次元空間で歩行姿勢分類超平面を構築できる。

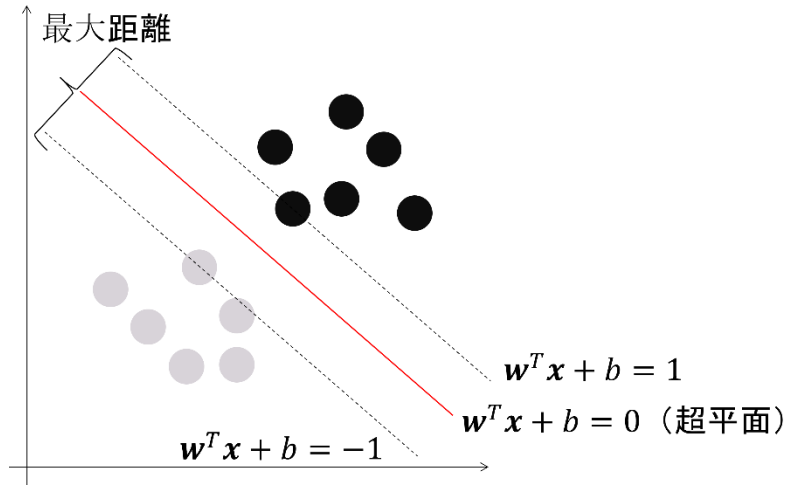


図 4.7 最適な超平面のスキマティック

図 4.7 に示すように, 歩行の非線形性の問題については, 式(4.10)の RBF(Radial Basis Function)マッピングによって得られる歩行姿勢分類超平面がサンプル空間を最大限に近似できるため, 歩行動作と歩行姿勢分類超平面の間の距離が最大化される.

$$K(\mathbf{x}_1, \mathbf{x}_2) = \exp\left\{-\frac{\|\mathbf{x}_1 - \mathbf{x}_2\|^2}{2\sigma^2}\right\} \quad (4.10)$$

ただし, $\|\mathbf{x}_1 - \mathbf{x}_2\|$ はサンプルポイント \mathbf{x}_1 と \mathbf{x}_2 の距離, σ はカーネルの大きさである.

このようにして決定された超平面関数は次のように書ける.

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (4.11)$$

ここで, \mathbf{w} は超平面の法線ベクトル, $\varphi(\mathbf{x})$ は歩行姿勢特徴ベクトル \mathbf{x} をカーネル関数 K によってマッピングした高次元の歩行姿勢特徴ベクトル, b は定数である.

SVM 歩行分類問題は, 歩行動作間の最大距離を求める問題に変換され, 2 種類の歩行動作間の最大距離を与える式は,

$$\max dis = \max_{\mathbf{w}} 2 \frac{y(\mathbf{w}^T \varphi(\mathbf{x}) + b)}{\|\mathbf{w}\|^2} \quad (4.12)$$

となる. ただし, 次式が満足されることを前提とする.

$$y_i(\mathbf{w}^T \varphi(\mathbf{x}) + b) = 1, \forall y_i \in \{-1, 1\} \quad (4.13)$$

したがって, 最適な歩行姿勢分類曲面問題を解くための SVM 問題は, 式(4.14)

に示すように2次計画問題になる．式(4.15)に示すように，歩行姿勢特徴ごとに0より大きいスラック変数 ζ を導入すれば，不等式制約は等式制約に変換される．ラグランジュ乗数アルゴリズムによれば，ラグランジュ関数は式(4.16)で与えられる．

$$\begin{cases} \min dis = \min_{\mathbf{w}} \frac{\|\mathbf{w}\|^2}{2} \\ \|\mathbf{w}\| = \sqrt{w_1^2 + w_2^2 + \dots + w_n^2} \\ y_i(\mathbf{w}^T \varphi(x) + b) \geq 1, \forall i = 1, 2, \dots, n \end{cases} \quad (4.14)$$

$$h_i(\mathbf{w}, \zeta_i) = 1 - y_i(\mathbf{w}^T \varphi(x) + b) + \zeta_i \quad (4.15)$$

$$L(\mathbf{w}, b, \zeta, \lambda, \mu) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \zeta_i + \sum_{i=1}^n (\lambda_i h_i - \mu_i \zeta_i) \quad (4.16)$$

ただし， λ, μ はラグランジュ乗数， C はペナルティ係数である．

\mathbf{w}, b, ζ に関する式(4.16)の微分値を0と置けば，最適な歩行分類超平面が得られ，その関数は式(4.17)で与えられる．

$$f(\mathbf{x}) = \text{sgn}(\sum_{i=1}^N w_i y_i K(\mathbf{x}_i, \mathbf{x}) + b_i) \quad (4.17)$$

以上のようにして，SVMを歩行分類問題に適用できる．

第5章 実験

提案法の有効性を示すために4種類の実験を行った。本章では、提案法の有効性検証、歩行姿勢推定精度、歩行姿勢解析と歩行姿勢認識に関するそれぞれの実験の方法と結果を示す。

5.1 実験環境

実験に用いる装置とカメラ座標系を図 5.1 に示す。本実験ではカメラに Raspberry pi でコントロールされる多軸センサ（9軸 IMU：地磁気センサ，ジャイロセンサ，加速度センサ）（以降，実験装置と称する）を取り付け，映像データと多軸センサのデータを同期させて同時に取得する。

5.2 提案法の有効性検証

5.2.1 実験方法

提案法と多軸センサによる人の姿勢変化の測定精度を確認するために，動作を正確にコントロールできるロボットハンドの動きを再現する実験を行う。カメラと多軸センサを基盤に固定し，それをロボットハンドの先端に固定してロボットハンドに回転運動を行わせる。この運動を提案法（カメラからの映像処理によってカメラ自身の回転運動を復元する）と多軸センサで復元し，どの程度再現できているかを実験的に確かめる。

通常は人の歩行姿勢の変化は $\pm 30[\text{deg}]$ の範囲を超えない。そこで，図 5.2 のようにロボットアームを用いて，実験装置をコントロールし，pitch/yaw/roll 軸の周りの回転を $0[\text{deg}]$ から $30[\text{deg}]$ ，また $0[\text{deg}]$ から $-30[\text{deg}]$ に制御する。ロボットアームの動きを表 5.1 に示す。




図 5.1 実験装置と装置のカメラ座標系

表 5.1 ロボットアームの動き・体幹姿勢と各回転軸の関係

回転軸 回転角度[deg]	pitch(x 軸)	yaw(y 軸)	roll(z 軸)
0 から 30	上向き (ロボットアーム が後ろに曲がる)	ロボットアーム が 0 の位置から 右に回転 (時計回り)	ロボットアーム が 0 の位置から 右回りに回転 (時計回り)
0 から -30	下向き (ロボットアーム が前に曲がる)	ロボットアーム が 0 の位置から 左に回転 (反時計回り)	ロボットアーム が 0 の位置から 左回りに回転 (反時計回り)


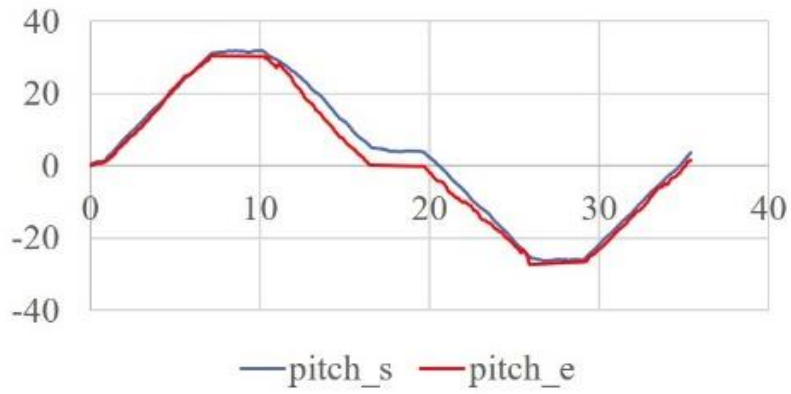


図 5.2 実験装置とロボットアーム

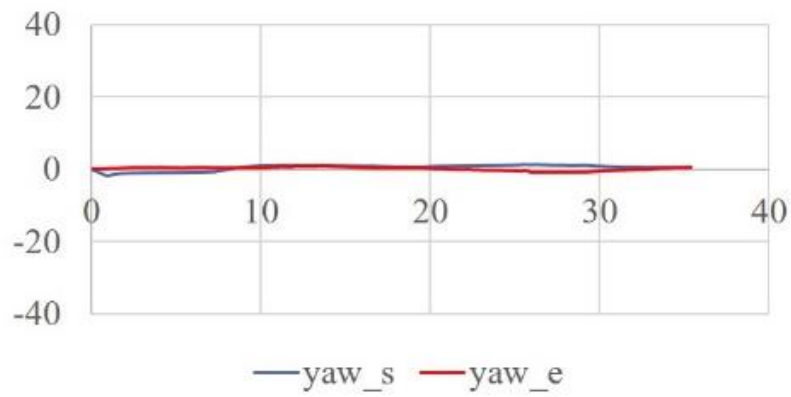
表 5.1 から, pitch(x 軸)周りの回転は前後に曲がるロボットアーム/体幹を表し, yaw(y 軸)周りの回転はロボットアーム/体幹が右(時計回り)/左(反時計回り)に回転することを表し, roll(z 軸)は体幹の右回り(時計回り)/左回り(反時計回り)の回転を表す.

5.2.2 実験結果


提案法を用いて, 各軸の歩行姿勢の変化を求め, 推定値をロボットアームの運動角度と比較する. 多軸センサから得られたデータをロボットアームの運動角度と比較する. それぞれの誤差を計算する. 推定値 $pitch_e$ と多軸センサ $pitch_s$ の結果を図 5.3 から図 5.5 に示す.



(a)

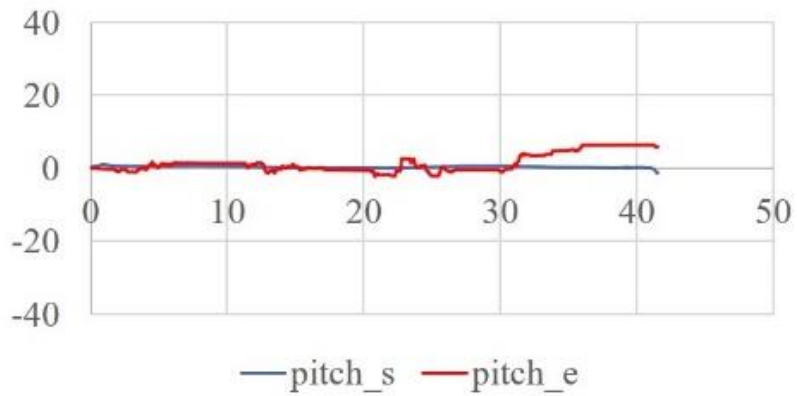


(b)

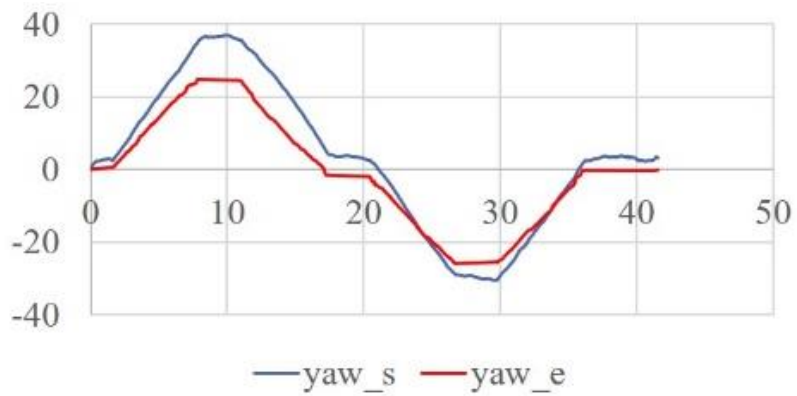


(c)

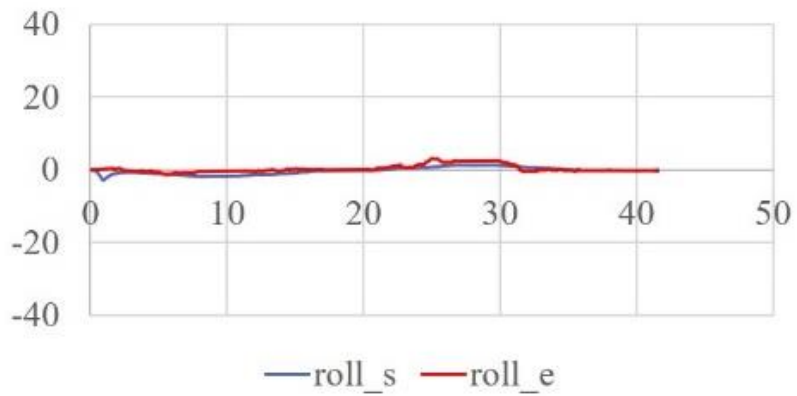
図 5.3 pitch 周りを 0[deg]から 30[deg]に, 0[deg]に, -30[deg]に, 0[deg]に回転
(a)pitch 軸, (b)yaw 軸, (c)roll 軸. (横軸は時間[s], 縦軸は角度[deg])



(a)




(b)

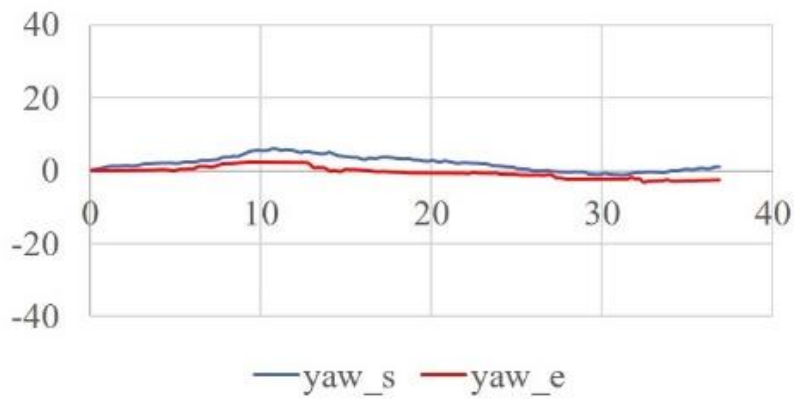


(c)

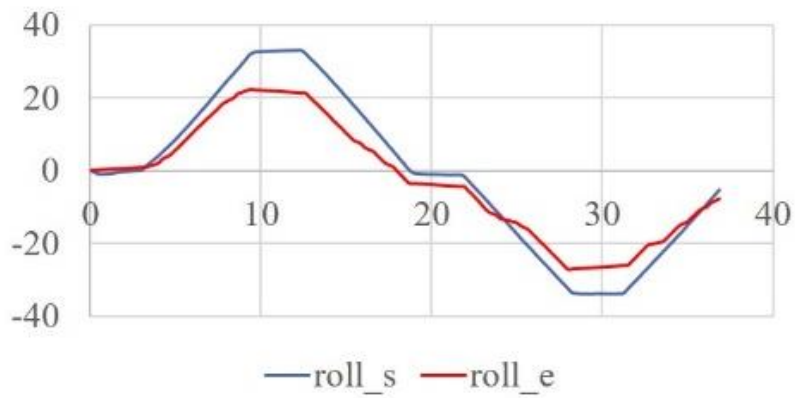
図 5.4 yaw 周りを 0[deg]から 30[deg]に, 0[deg]に, -30[deg]に, 0[deg]に回転
(a)pitch 軸, (b)yaw 軸, (c)roll 軸. (横軸は時間[s], 縦軸は角度[deg])



(a)



(b)



(c)

図 5.5 roll 周りを 0[deg]から 30[deg]に, 0[deg]に, -30[deg]に, 0[deg]に回転
(a)pitch 軸, (b)yaw 軸, (c)roll 軸. (横軸は時間[s], 縦軸は角度[deg])

pitch 軸の周りを回転するとき、roll 軸と yaw 軸はほぼ 0[deg]になった。pitch 軸の回転は 30[deg]と-30[deg]のとき、推定法と多軸センサの精度は同じ、0[deg]の場合、推定法は多軸センサより精度がよかった。

yaw 軸の周りを回転するとき、pitch 軸と roll 軸はほぼ 0[deg]になった。yaw 軸の回転は 30[deg]のとき、推定法と多軸センサの誤差は同じ、-30[deg]の場合、多軸センサは精度がよかった。ただし、0[deg]の場合、推定法は多軸センサより精度がよかった。

roll 軸の周りを回転するとき、pitch 軸と yaw 軸はほぼ 0[deg]になった。roll 軸の回転は 30[deg]の場合、多軸センサの精度がよかった。-30[deg]の場合、推定法と多軸センサは精度が同じようになった。

提案推定法の誤差を多軸センサの誤差と比較すれば、提案推定法はセンサとほぼ同じか、センサよりも精度が高い。ロボットアームを用いた実験により推定法の有効性を確認した。

5.3 歩行姿勢推定精度実験

5.3.1 実験方法

3 人の被験者に対して 3 箇所 4 種類の歩行姿勢の推定を行う。図 5.6 から図 5.41 に示した歩行動作はそれぞれ通常歩行、右足引きずり歩行、左肩下がり歩行、うつむき歩行の 4 種類である。提案法を用いて 2 フレーム間隔で歩行姿勢を推定する。第 3 章と第 4 章で述べた手法を用いて、初期状態の姿勢角度を 0[deg]として、累積する歩行波形を求める。多軸センサから得られた出力を RTQF アルゴリズムによって統合し、その値と推定値 (式 (3.16)) を比較し、次式で示す RMSE(Root Mean Squared Error)を用いて評価を行う。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{e_i} - x_{s_i})^2} \quad (6.1)$$

ただし、 N はデータ数、 x_{e_i}, x_{s_i} は i 番目 ($i = 1, 2, \dots, N$) の推定値とセンサ値である。

多軸センサから得られるデータと提案法により推定されるデータのサンプリング間隔は異なっているため、センサから得られるデータを時間軸に対して線形補間を行う。また、多軸センサから得られるデータは絶対角度のため、センサの初期角度を 0[deg]として補正する。



図 5.6 被験者 1 場所 A 通常歩行



図 5.7 被験者 1 場所 A 右足引きずり歩行



図 5.8 被験者 1 場所 A 左肩下がり歩行



図 5.9 被験者 1 場所 A うつむき歩行



図 5.10 被験者 1 場所 B 通常歩行



図 5.11 被験者 1 場所 B 右足引きずり歩行



図 5.12 被験者 1 場所 B 左肩下がり歩行



図 5.13 被験者 1 場所 B うつむき歩行



図 5.14 被験者 1 場所 C 通常歩行



図 5.15 被験者 1 場所 C 右足引きずり歩行



図 5.16 被験者 1 場所 C 左肩下がり歩行



図 5.17 被験者 1 場所 C うつむき歩行



図 5.18 被験者 2 場所 A 通常歩行



図 5.19 被験者 2 場所 A 右足引きずり歩行



図 5.20 被験者 2 場所 A 左肩下がり歩行



図 5.21 被験者 2 場所 A うつむき歩行



図 5.22 被験者 2 場所 B 通常歩行



図 5.23 被験者 2 場所 B 右足引きずり歩行



図 5.24 被験者 2 場所 B 左肩下がり歩行



図 5.25 被験者 2 場所 B うつむき歩行



図 5.26 被験者 2 場所 C 通常歩行



図 5.27 被験者 2 場所 C 右足引きずり歩行



図 5.28 被験者 2 場所 C 左肩下がり歩行



図 5.29 被験者 2 場所 C うつむき歩行



図 5.30 被験者 3 場所 A 通常歩行



図 5.31 被験者 3 場所 A 右足引きずり歩行



図 5.32 被験者 3 場所 A 左肩下がり歩行



図 5.33 被験者 3 場所 A うつむき歩行



図 5.34 被験者 3 場所 B 通常歩行



図 5.35 被験者 3 場所 B 右足引きずり歩行



図 5.36 被験者 3 場所 B 左肩下がり歩行



図 5.37 被験者 3 場所 B うつむき歩行



図 5.38 被験者 3 場所 C 通常歩行



図 5.39 被験者 3 場所 C 右足引きずり歩行



図 5.40 被験者 3 場所 C 左肩下がり歩行



図 5.41 被験者 3 場所 C うつむき歩行

5.3.2 実験結果

実験結果を図 5.42 から図 5.77 に示す．これらは同じ被験者・同じ場所から得られた結果である．

人の歩行姿勢推定の評価結果を表 5.2 に示す．トレンド除去前のデータの平均 RMSE は 9.238[deg]，ハンミング処理後のデータの平均 RMSE は 1.885[deg]であった．

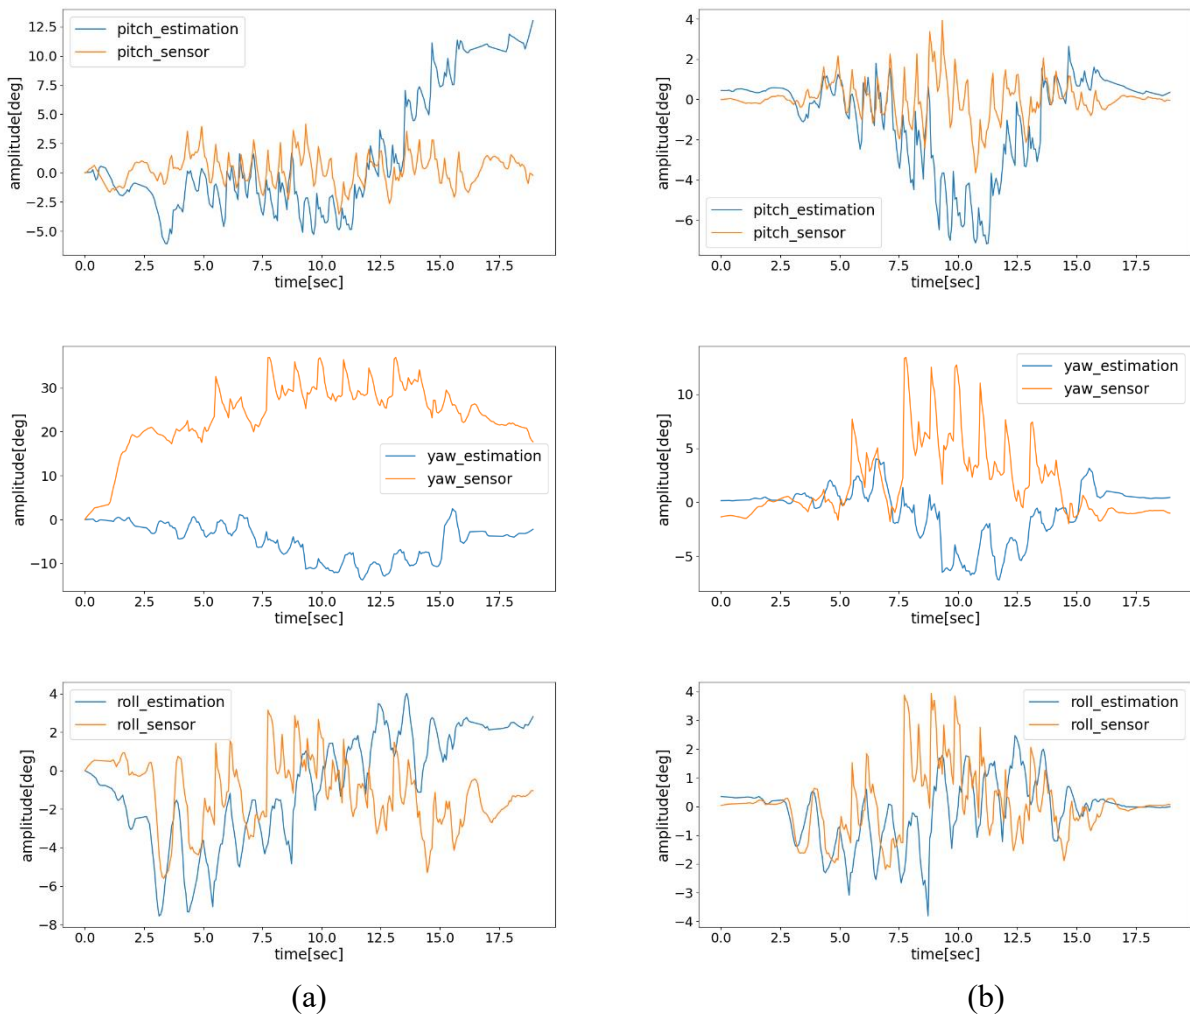


図 5.42 被験者 1 場所 A の通常歩行．(a)原データ，(b)トレンド+ハンミング処理後．

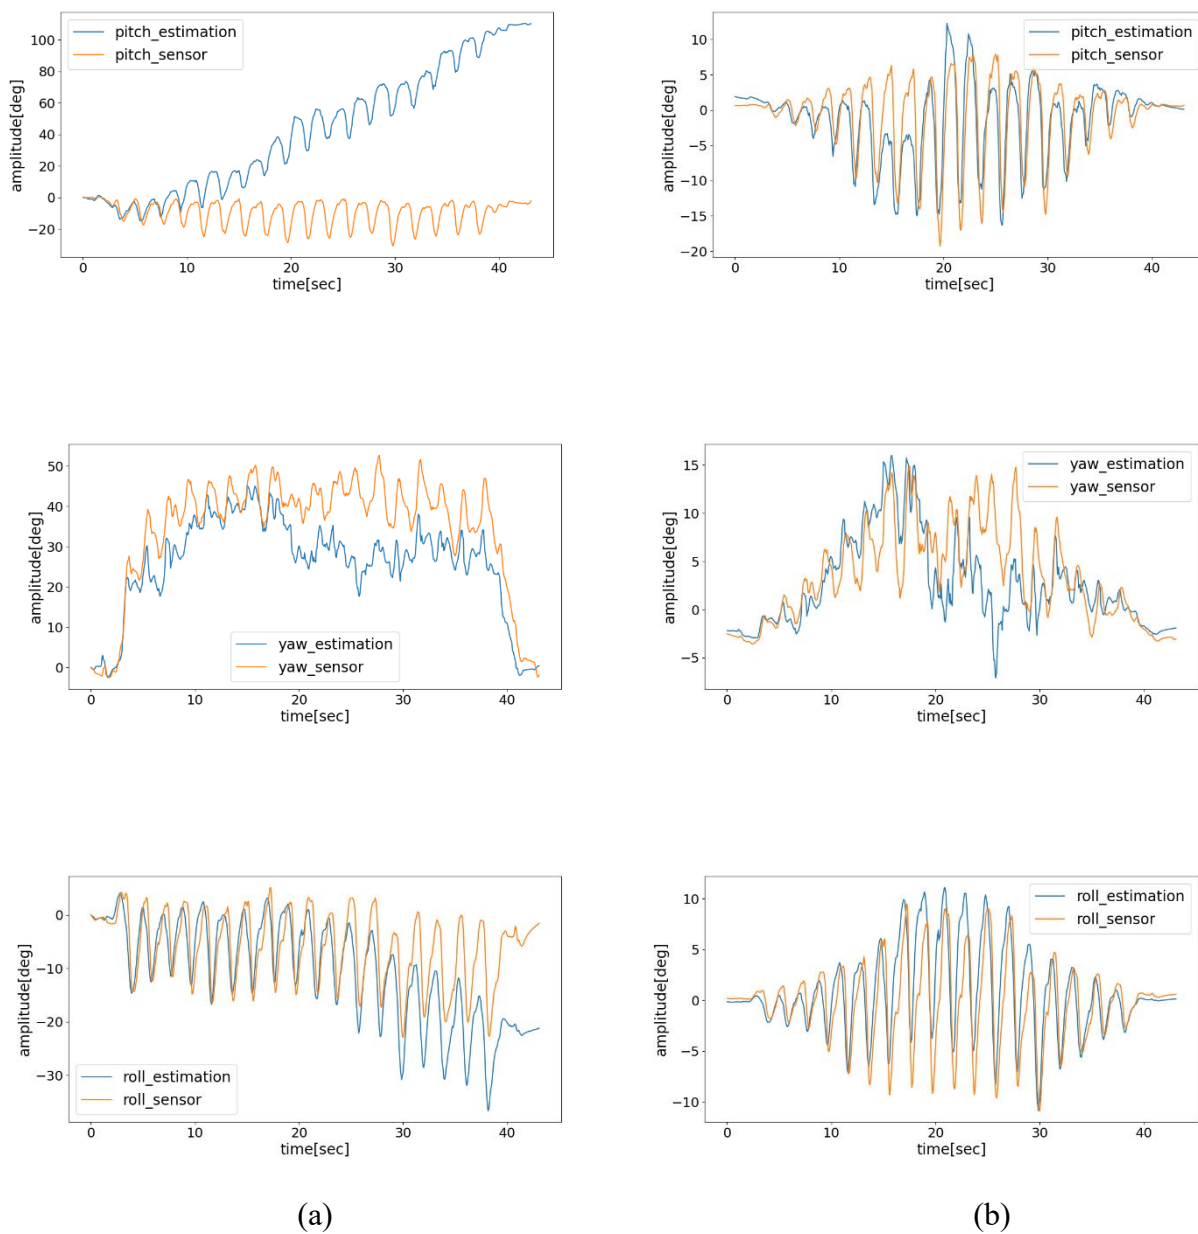














図 5.43 被験者 1 場所 A 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.44 被験者 1 場所 A 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.45 被験者 1 場所 A うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.

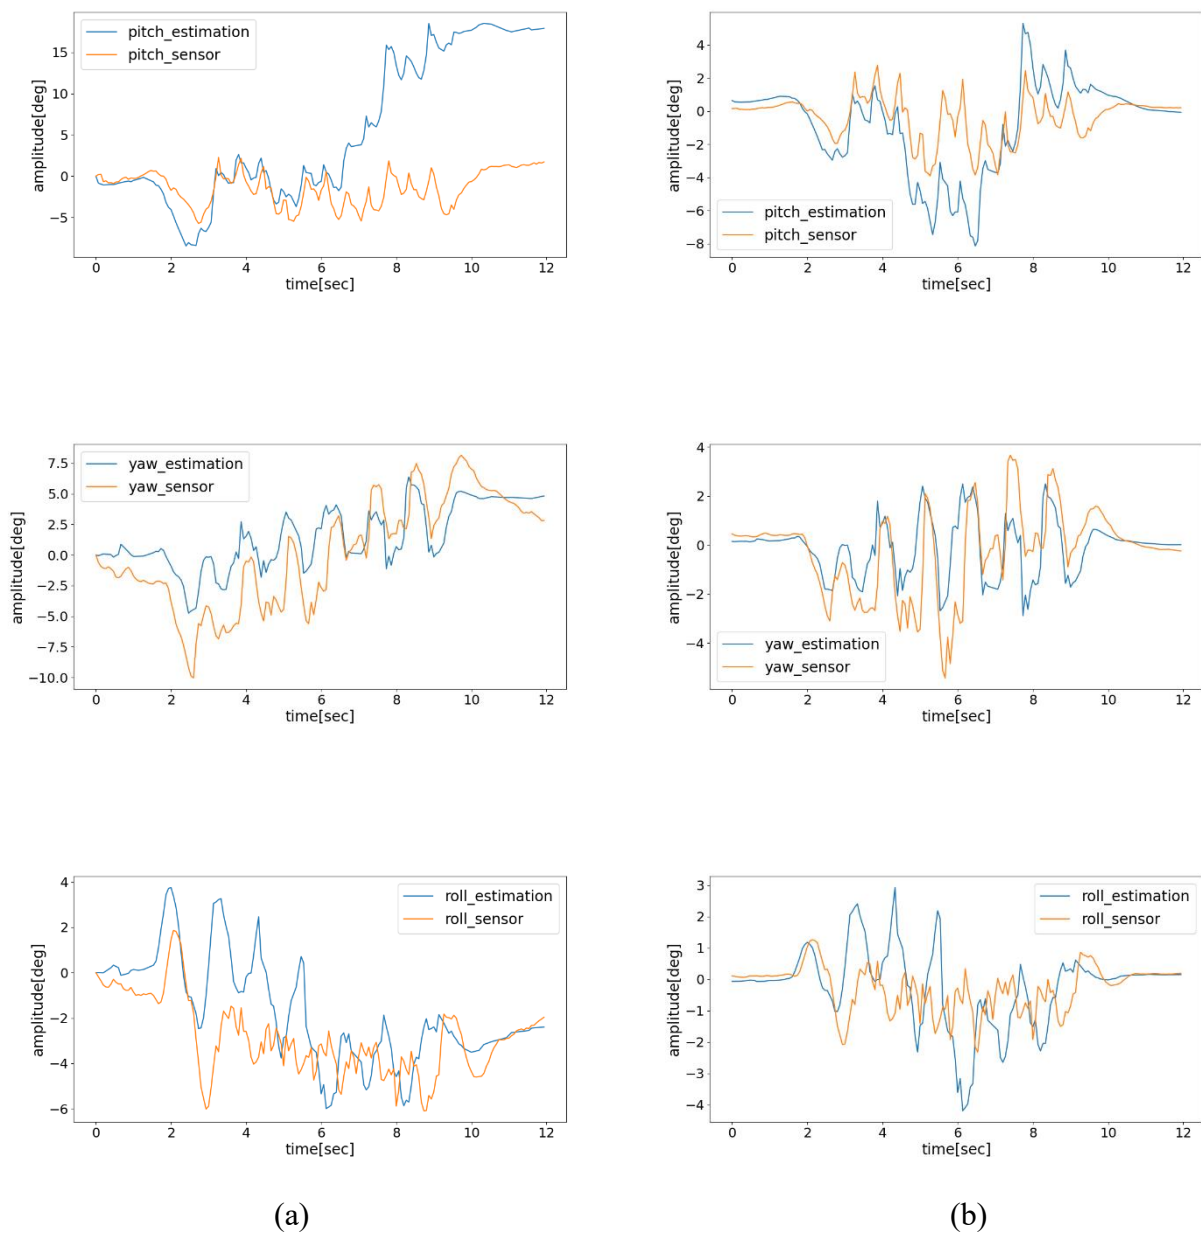


図 5.46 被験者 1 場所 B 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.

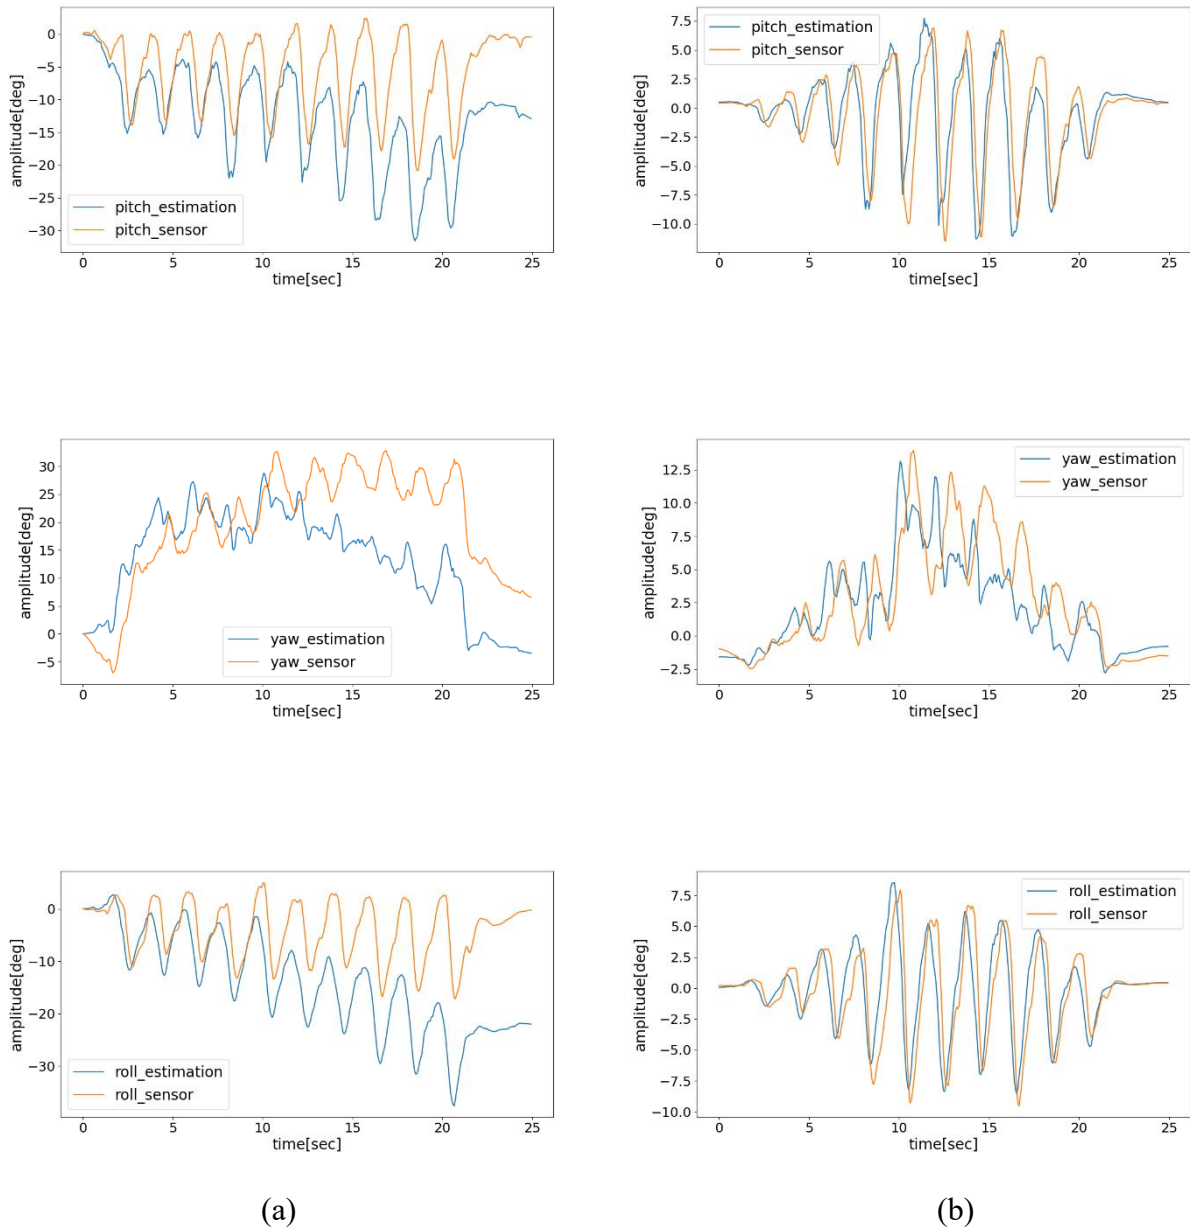








図 5.47 被験者 1 場所 B 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.48 被験者 1 場所 B 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.

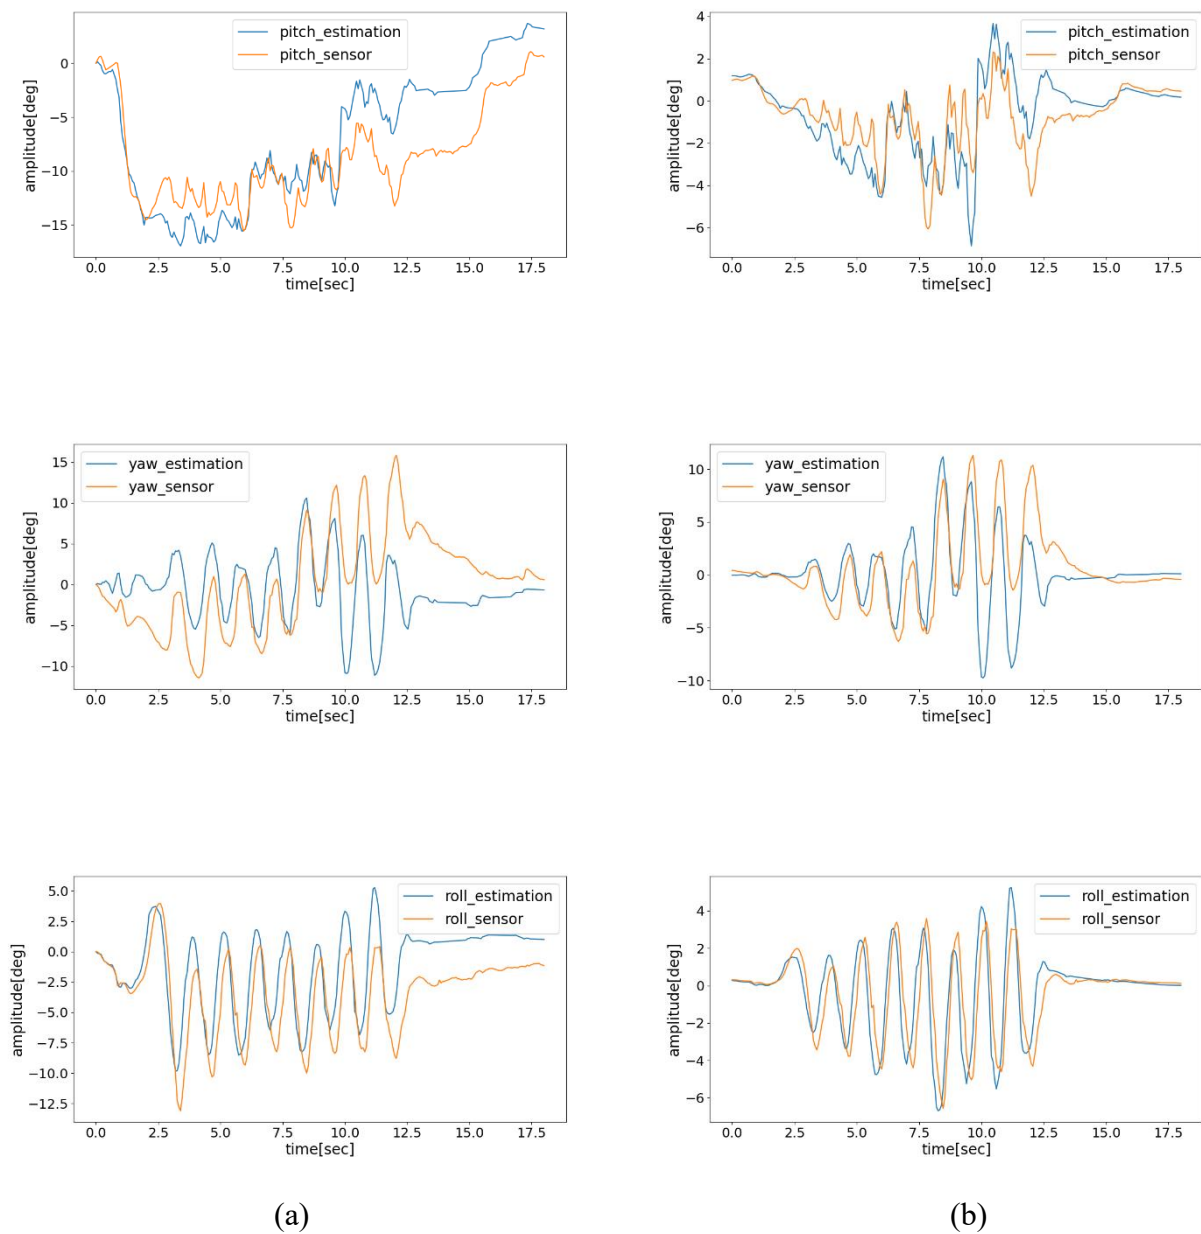














図 5.49 被験者 1 場所 B うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.50 被験者 1, 場所 C 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.51 被験者 1 場所 C 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.52 被験者 1 場所 C 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.

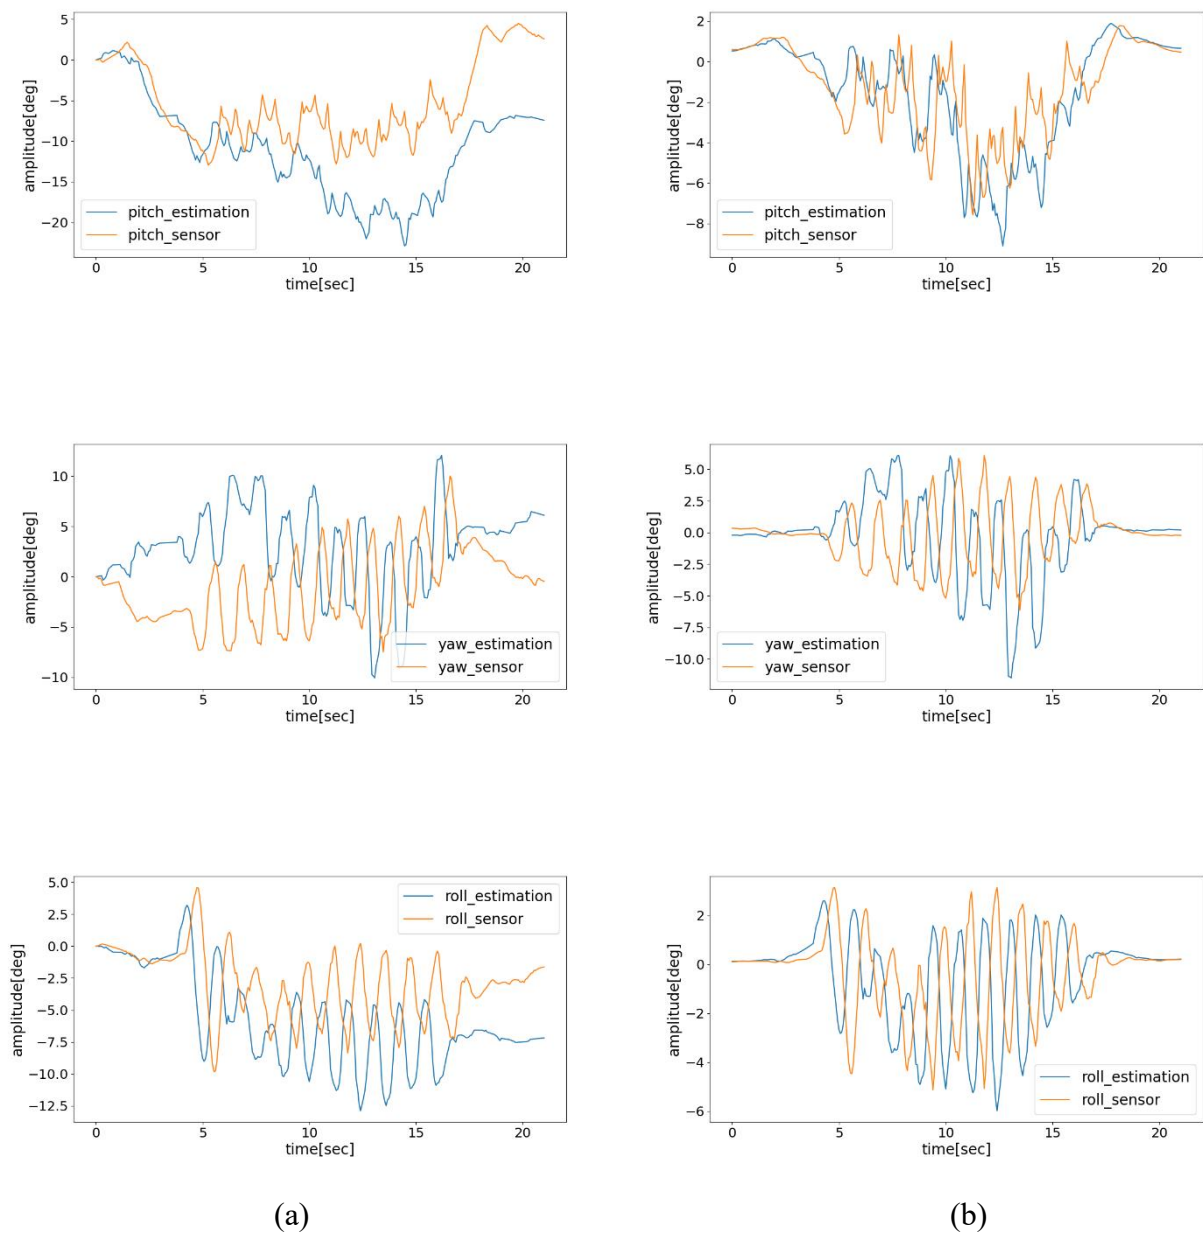














図 5.53 被験者 1 場所 C うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.54 被験者 2 場所 A 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.55 被験者 2 場所 A 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.

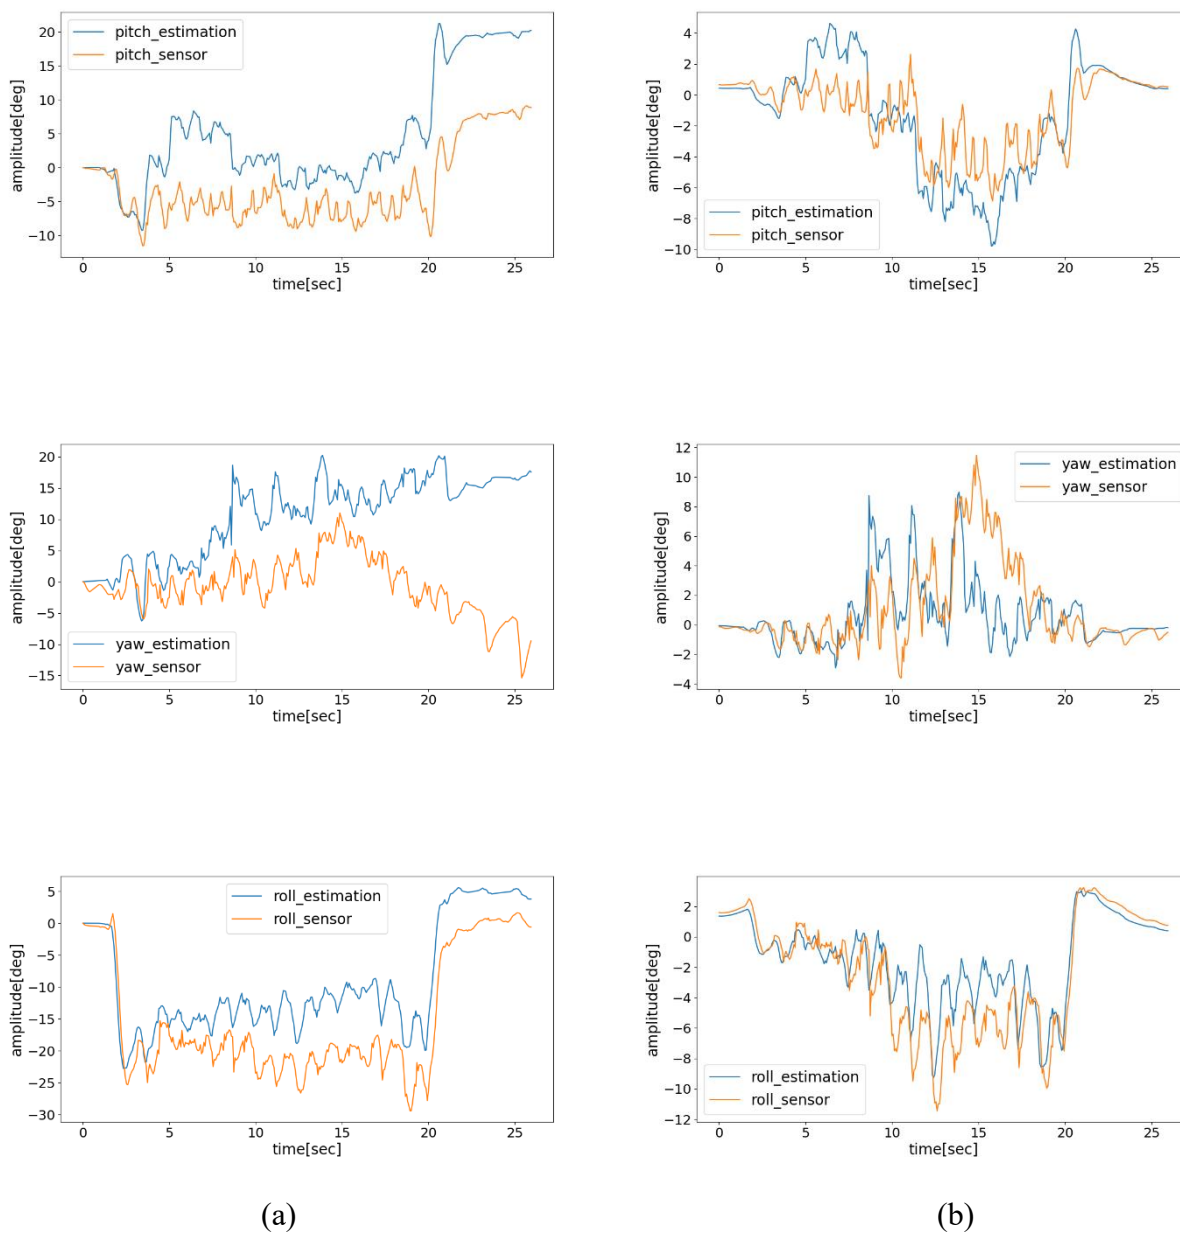


図 5.56 被験者 2 場所 A 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.

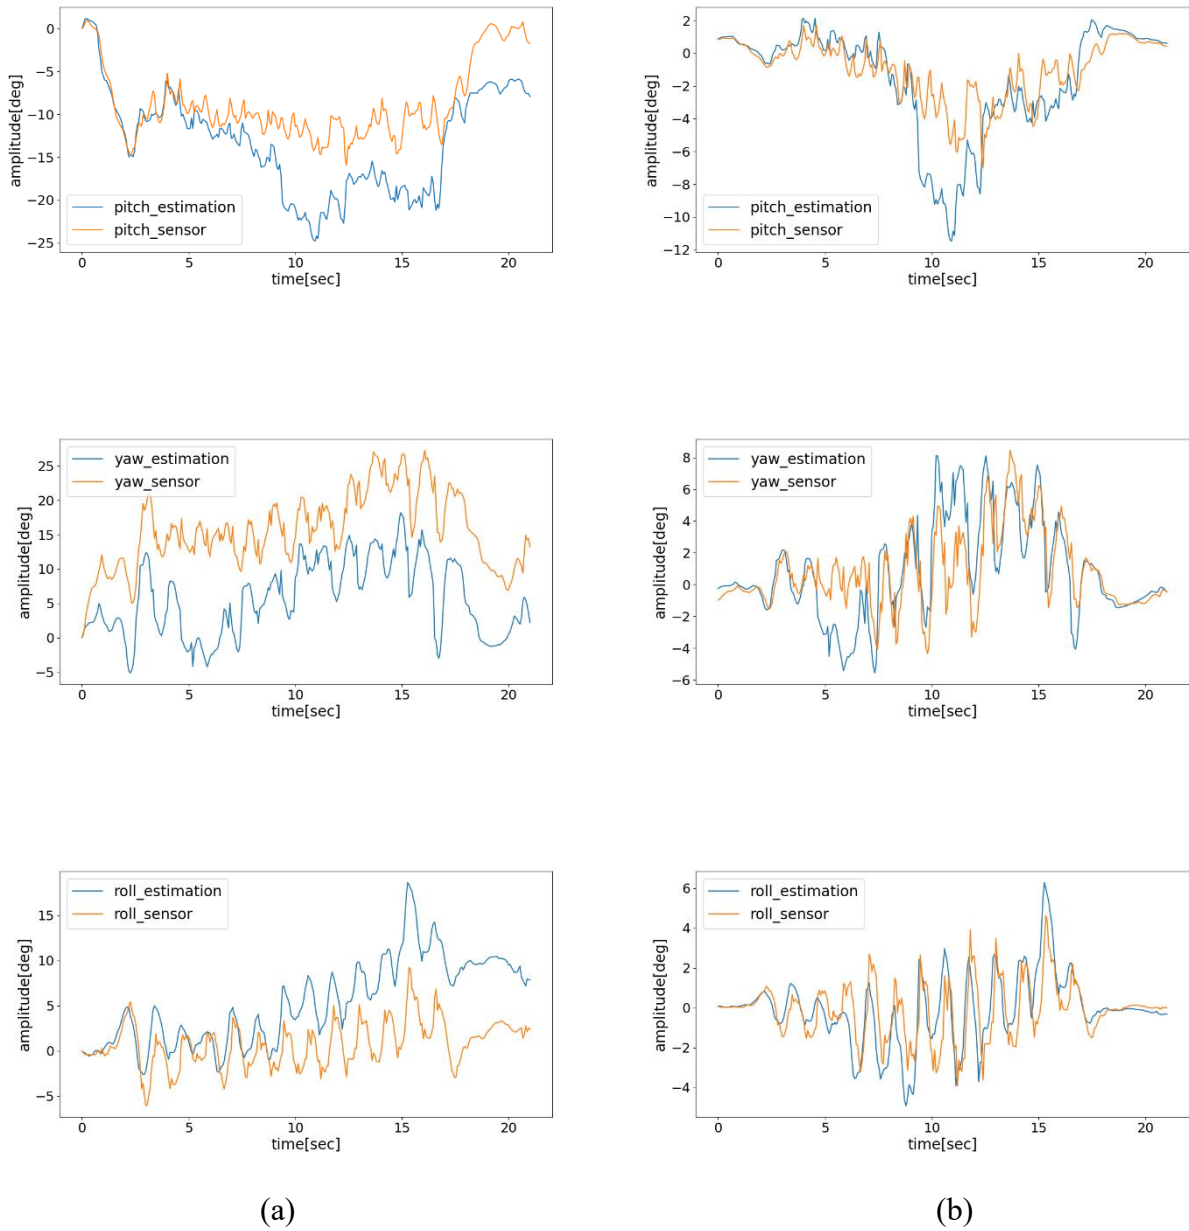














図 5.57 被験者 2 場所 A うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.58 被験者 2 場所 B 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.59 被験者 2 場所 B 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.60 被験者 2 場所 B 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.61 被験者 2 場所 B うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.62 被験者 2 場所 C 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.63 被験者 2 場所 C 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.64 被験者 2 場所 C 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.65 被験者 2 場所 C うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.66 被験者 3 場所 A 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.67 被験者 3 場所 A 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.68 被験者 3 場所 A 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.69 被験者 3 場所 A うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.70 被験者 3 場所 B 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.71 被験者 3 場所 B 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.72 被験者 3 場所 B 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.73 被験者 3 場所 B うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.74 被験者 3 場所 C 通常歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)







図 5.75 被験者 3 場所 C 右足引きずり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.76 被験者 3 場所 C 左肩下がり歩行. (a)原データ, (b)トレンド+ハンミング処理後.



(a)

(b)

図 5.77 被験者 3 場所 C うつむき歩行. (a)原データ, (b)トレンド+ハンミング処理後.

表 5.2 人の歩行姿勢精度実験の評価. (a) 原データ,
(b) トレンド+ハンミング処理後. (続く)

(a)

被験者	場所	歩行動作	pitch 軸周りの RMSE[deg]	yaw 軸周りの RMSE[deg]	roll 軸周りの RMSE[deg]
1	A	通常	5.485	30.40	3.238
		右足引きずり	65.19	10.40	8.381
		左肩下がり	2.473	9.198	5.931
		うつむき	16.10	4.535	3.056
	B	通常	10.59	2.932	2.219
		右足引きずり	8.975	10.66	12.94
		左肩下がり	3.414	4.207	3.140
		うつむき	3.719	5.944	2.981
	C	通常	7.869	5.452	3.861
		右足引きずり	18.15	8.565	10.49
		左肩下がり	7.401	4.856	6.424
		うつむき	7.430	7.555	4.961
2	A	通常	2.544	3.375	6.212
		右足引きずり	34.81	18.76	8.681
		左肩下がり	9.058	13.66	6.823
		うつむき	5.756	10.62	5.742
	B	通常	7.831	13.64	2.203
		右足引きずり	7.902	10.64	3.967
		左肩下がり	18.14	3.755	3.345
		うつむき	3.755	11.35	3.162
	C	通常	2.995	9.347	2.827
		右足引きずり	16.10	24.47	10.40
		左肩下がり	7.892	11.26	2.375
		うつむき	4.420	40.60	5.677
3	A	通常	2.149	4.073	2.271
		右足引きずり	17.34	28.89	3.797
		左肩下がり	4.023	5.469	2.228
		うつむき	4.990	4.340	2.443
	B	通常	3.856	13.68	1.344
		右足引きずり	4.473	25.75	3.821

表 5.2 人の歩行姿勢精度実験の評価. (a) 原データ,
(b) トレンド+ハンミング処理後. (続く)

		左肩下がり	3.933	11.22	2.158
		うつむき	3.861	7.862	2.395
	C	通常	6.883	25.07	2.319
		右足引きずり	3.450	47.51	6.205
		左肩下がり	1.848	18.85	1.685
		うつむき	2.904	27.41	3.741
平均	通常	5.578	11.99	2.944	
	右足引きずり	19.60	20.63	7.633	
	左肩下がり	6.465	9.166	3.790	
	うつむき	5.883	13.35	3.795	

(b)

被験者	場所	歩行動作	pitch 軸周りの RMSE[deg]	yaw 軸周りの RMSE[deg]	roll 軸周りの RMSE[deg]
1	A	通常	2.348	5.480	1.484
		右足引きずり	3.589	3.925	3.030
		左肩下がり	1.276	3.924	1.599
		うつむき	2.372	2.017	2.238
	B	通常	2.139	1.521	1.313
		右足引きずり	2.689	2.805	2.460
		左肩下がり	1.048	1.447	0.970
		うつむき	1.296	3.069	1.425
	C	通常	1.515	1.498	1.064
		右足引きずり	3.485	3.214	2.336
		左肩下がり	1.209	1.827	1.258
		うつむき	1.849	4.685	2.914
2	A	通常	1.060	2.157	1.142
		右足引きずり	3.211	2.517	1.961
		左肩下がり	2.123	2.739	1.929
		うつむき	2.120	2.200	1.335
	B	通常	1.341	1.959	1.009
		右足引きずり	1.816	2.474	1.868
		左肩下がり	2.440	1.371	1.080
		うつむき	0.755	2.277	1.075

表 5.2 人の歩行姿勢精度実験の評価. (a) 原データ,
(b) トレンド+ハンミング処理後.

	C	通常	1.581	2.030	1.010
		右足引きずり	2.337	2.592	2.172
		左肩下がり	1.449	2.104	1.173
		うつむき	2.554	3.936	1.392
3	A	通常	0.665	1.751	0.624
		右足引きずり	2.798	2.806	1.967
		左肩下がり	1.126	2.378	0.965
		うつむき	0.701	1.908	1.011
	B	通常	1.350	1.734	0.697
		右足引きずり	1.763	2.184	1.511
		左肩下がり	1.479	1.649	0.895
		うつむき	1.109	1.336	0.974
	C	通常	1.137	2.169	0.487
		右足引きずり	1.968	2.567	1.507
		左肩下がり	0.705	2.165	0.747
		うつむき	0.909	2.456	0.767
平均	通常	1.460	2.255	0.981	
	右足引きずり	2.628	2.787	2.090	
	左肩下がり	1.428	2.178	1.180	
	うつむき	1.518	2.654	1.459	

5.4 歩行姿勢解析実験

5.4.1 実験方法

3人の被験者に対して3箇所、4種類の人の歩行姿勢の推定と解析を行う。歩行動作は通常歩行、右足引きずり歩行、左肩下がり歩行、うつむき歩行の4種類である。本実験では人の体歩行姿勢は歩行の開始と終了の区間を含むため、実際に歩行している区間と歩行動作の安定性を考慮し、歩行動作開始から2秒後の安定した計測値を使用する。式(4.1)～(4.2)を用いて極大値と極小値を各10個検出し、極大値と極小値の平均値を算出する。4.3章で述べた人の歩行姿勢の指標を求め、歩行姿勢を解析する。

5.4.2 実験結果

実験結果：通常歩行，右足引きずり歩行，左肩下がりに歩行，うつむき歩行の姿勢の指標を表 5.3 から表 5.20 に示す。

右足引きずり歩行を通常歩行と比較すれば，右足が不安定でバランスが良くないため各軸の揺れ度が大きくなっている。右足引きずり歩行では体幹が右に回転するが，それは表 5.3 のように yaw 軸の傾斜度 $\bar{\rho}_y$ が 2.662[deg]となっていることに反映している。左肩下がりに歩行は体幹が左回り(反時計回り)に回転するが，そのため通常歩行 roll 軸の傾斜度 $\bar{\rho}_r$ が-0.489[deg]を-1.397[deg]と変化している。うつむき歩行を通常歩行と比較すれば，上半身の揺れが少なく，pitch 軸の揺れ度 $\bar{\varphi}_p$ が 1.114[deg]と小さくなり，逆に yaw 軸と roll 軸の揺れ度 $\bar{\varphi}_y$ と $\bar{\varphi}_r$ がそれぞれ 9.069[deg]，8.807[deg]と大きくなっている。

表 5.3 被験者 1 の場所 A での歩行姿勢の指標 (提案法)

	通常歩行	右足引きずり歩行	左肩下がりに歩行	うつむき歩行
$\bar{\varphi}_p$ [deg]	1.545	3.493	0.724	1.114
$\bar{\varphi}_y$ [deg]	2.828	1.545	2.817	9.069
$\bar{\varphi}_r$ [deg]	2.449	9.313	1.664	8.807
$\bar{\rho}_p$ [deg]	-0.689	-1.414	-0.431	0.229
$\bar{\rho}_y$ [deg]	-1.676	2.662	-1.020	1.512
$\bar{\rho}_r$ [deg]	-0.489	0.141	-1.397	-1.051

表 5.4 被験者 1 の場所 A での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がりに歩行	うつむき歩行
$\bar{\varphi}_p$ [deg]	1.036	3.743	0.954	0.592
$\bar{\varphi}_y$ [deg]	3.759	1.266	2.859	5.914
$\bar{\varphi}_r$ [deg]	0.016	9.011	-0.304	7.720
$\bar{\rho}_p$ [deg]	0.043	0.613	-0.790	-1.725
$\bar{\rho}_y$ [deg]	3.831	2.500	0.607	1.215
$\bar{\rho}_r$ [deg]	-0.142	-0.930	-2.304	-0.240

表 5.5 被験者 1 の場所 B での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	2.328	9.656	1.214	0.379
$\bar{\varphi}_y[\text{deg}]$	2.102	2.357	3.250	7.743
$\bar{\varphi}_r[\text{deg}]$	2.372	9.787	0.483	5.944
$\bar{\rho}_p[\text{deg}]$	-2.380	-1.578	-0.842	-2.696
$\bar{\rho}_y[\text{deg}]$	-0.392	3.259	-0.074	0.050
$\bar{\rho}_r[\text{deg}]$	-0.809	-0.8241	-1.541	-0.485

表 5.6 被験者 1 の場所 B での歩行姿勢の指標（センサ）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	2.089	8.270	1.108	0.490
$\bar{\varphi}_y[\text{deg}]$	2.714	0.800	2.983	6.264
$\bar{\varphi}_r[\text{deg}]$	-0.234	8.068	0.096	4.223
$\bar{\rho}_p[\text{deg}]$	-0.646	-1.053	-1.353	-1.678
$\bar{\rho}_y[\text{deg}]$	-0.176	3.065	0.941	1.350
$\bar{\rho}_r[\text{deg}]$	-0.734	-0.751	-1.350	-0.410

表 5.7 被験者 1 の場所 C での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.935	9.411	0.889	1.386
$\bar{\varphi}_y[\text{deg}]$	3.364	2.033	4.304	6.278
$\bar{\varphi}_r[\text{deg}]$	2.088	8.975	0.962	4.478
$\bar{\rho}_p[\text{deg}]$	-2.803	-0.673	-0.989	-2.506
$\bar{\rho}_y[\text{deg}]$	-0.130	3.953	-0.227	-0.642
$\bar{\rho}_r[\text{deg}]$	-0.753	-1.738	-0.846	-0.967

表 5.8 被験者 1 の場所 C での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.070	10.07	1.271	-1.681
$\bar{\varphi}_y[\text{deg}]$	2.667	0.593	2.759	-4.868
$\bar{\varphi}_r[\text{deg}]$	0.216	7.613	0.108	-3.851
$\bar{\rho}_p[\text{deg}]$	-1.091	-1.700	-0.238	-2.316
$\bar{\rho}_y[\text{deg}]$	0.147	2.986	0.857	-0.489
$\bar{\rho}_r[\text{deg}]$	-0.599	-1.197	-1.951	-0.756

表 5.9 被験者 2 の場所 A での歩行姿勢の指標 (提案法)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.256	2.367	1.278	0.785
$\bar{\varphi}_y[\text{deg}]$	4.145	3.199	1.507	3.421
$\bar{\varphi}_r[\text{deg}]$	2.451	6.670	1.117	3.618
$\bar{\rho}_p[\text{deg}]$	-0.517	-0.034	0.645	0.198
$\bar{\rho}_y[\text{deg}]$	2.952	1.438	0.357	0.252
$\bar{\rho}_r[\text{deg}]$	-0.166	-0.190	-0.934	-0.504

表 5.10 被験者 2 の場所 A での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.159	2.670	0.302	0.741
$\bar{\varphi}_y[\text{deg}]$	2.413	2.190	1.834	2.795
$\bar{\varphi}_r[\text{deg}]$	0.909	6.118	0.593	3.082
$\bar{\rho}_p[\text{deg}]$	-0.206	-0.565	-0.475	-0.325
$\bar{\rho}_y[\text{deg}]$	1.992	0.235	-0.629	0.603
$\bar{\rho}_r[\text{deg}]$	0.641	-0.264	-1.243	-0.061

表 5.11 被験者 2 の場所 B での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がりに歩行	うつむき歩行
$\bar{\varphi}_p$ [deg]	1.798	3.178	1.880	1.283
$\bar{\varphi}_y$ [deg]	3.737	2.668	2.402	7.034
$\bar{\varphi}_r$ [deg]	2.652	4.720	3.279	2.421
$\bar{\rho}_p$ [deg]	-0.597	-0.023	-0.235	-0.262
$\bar{\rho}_y$ [deg]	0.241	1.622	2.123	-0.801
$\bar{\rho}_r$ [deg]	-0.308	0.435	-4.516	0.243

表 5.12 被験者 2 の場所 B での歩行姿勢の指標（センサ）

	通常歩行	右足引きずり歩行	左肩下がりに歩行	うつむき歩行
$\bar{\varphi}_p$ [deg]	0.793	4.517	1.971	0.433
$\bar{\varphi}_y$ [deg]	3.241	0.429	2.677	6.059
$\bar{\varphi}_r$ [deg]	1.570	4.054	3.193	2.219
$\bar{\rho}_p$ [deg]	-1.092	-1.200	-1.664	-0.366
$\bar{\rho}_y$ [deg]	0.400	0.317	1.627	0.958
$\bar{\rho}_r$ [deg]	0.316	-0.285	-4.215	0.463

表 5.13 被験者 2 の場所 C での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がりに歩行	うつむき歩行
$\bar{\varphi}_p$ [deg]	1.312	4.926	1.693	1.010
$\bar{\varphi}_y$ [deg]	2.245	2.651	1.613	7.578
$\bar{\varphi}_r$ [deg]	2.481	5.515	3.196	3.835
$\bar{\rho}_p$ [deg]	-0.525	-0.635	-1.690	-0.055
$\bar{\rho}_y$ [deg]	-0.417	1.282	1.602	1.044
$\bar{\rho}_r$ [deg]	0.164	0.987	-4.054	0.126

表 5.14 被験者 2 の場所 C での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	0.811	5.777	0.788	0.010
$\bar{\varphi}_y[\text{deg}]$	1.979	1.368	1.761	6.019
$\bar{\varphi}_r[\text{deg}]$	1.598	5.606	2.226	3.881
$\bar{\rho}_p[\text{deg}]$	-1.326	-0.723	-2.135	-0.901
$\bar{\rho}_y[\text{deg}]$	0.757	1.096	-0.434	0.988
$\bar{\rho}_r[\text{deg}]$	0.343	0.095	-4.159	-0.155

表 5.15 被験者 3 の場所 A での歩行姿勢の指標 (提案法)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.039	3.208	0.527	0.910
$\bar{\varphi}_y[\text{deg}]$	4.260	1.514	2.182	5.097
$\bar{\varphi}_r[\text{deg}]$	1.103	4.567	0.888	1.314
$\bar{\rho}_p[\text{deg}]$	-0.137	-0.632	0.422	-0.319
$\bar{\rho}_y[\text{deg}]$	1.851	0.155	0.018	0.041
$\bar{\rho}_r[\text{deg}]$	0.268	0.140	-0.486	0.858

表 5.16 被験者 3 の場所 A での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.570	3.529	0.690	1.591
$\bar{\varphi}_y[\text{deg}]$	2.124	0.504	1.085	3.218
$\bar{\varphi}_r[\text{deg}]$	0.565	4.411	0.275	1.098
$\bar{\rho}_p[\text{deg}]$	-0.139	-0.577	-0.149	-0.135
$\bar{\rho}_y[\text{deg}]$	2.169	0.520	1.982	1.313
$\bar{\rho}_r[\text{deg}]$	0.671	-0.143	-0.143	0.581

表 5.17 被験者 3 の場所 B での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	1.343	1.864	1.266	0.667
$\bar{\varphi}_y[\text{deg}]$	4.997	1.672	2.478	6.599
$\bar{\varphi}_r[\text{deg}]$	1.220	4.312	1.876	1.601
$\bar{\rho}_p[\text{deg}]$	-0.520	-0.315	0.441	-1.021
$\bar{\rho}_y[\text{deg}]$	0.242	-0.805	1.132	1.834
$\bar{\rho}_r[\text{deg}]$	-0.018	-0.225	-1.524	0.131

表 5.18 被験者 3 の場所 B での歩行姿勢の指標（センサ）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	2.096	2.502	2.626	1.423
$\bar{\varphi}_y[\text{deg}]$	4.386	2.032	1.157	7.057
$\bar{\varphi}_r[\text{deg}]$	0.824	5.095	1.097	1.273
$\bar{\rho}_p[\text{deg}]$	-0.242	-1.006	-0.557	-1.518
$\bar{\rho}_y[\text{deg}]$	0.710	-0.603	1.452	1.723
$\bar{\rho}_r[\text{deg}]$	0.074	-0.659	-0.955	0.803

表 5.19 被験者 3 の場所 C での歩行姿勢の指標（提案法）

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	0.851	1.931	1.282	1.189
$\bar{\varphi}_y[\text{deg}]$	4.152	2.076	1.864	5.887
$\bar{\varphi}_r[\text{deg}]$	0.621	3.470	1.035	1.276
$\bar{\rho}_p[\text{deg}]$	0.684	0.082	-0.573	-0.499
$\bar{\rho}_y[\text{deg}]$	0.352	-1.960	4.279	1.067
$\bar{\rho}_r[\text{deg}]$	0.597	0.177	-0.814	-0.314

表 5.20 被験者 3 の場所 C での歩行姿勢の指標 (センサ)

	通常歩行	右足引きずり歩行	左肩下がり歩行	うつむき歩行
$\bar{\varphi}_p[\text{deg}]$	0.980	2.658	1.917	1.685
$\bar{\varphi}_y[\text{deg}]$	4.111	1.523	0.864	6.189
$\bar{\varphi}_r[\text{deg}]$	0.493	3.615	0.252	0.991
$\bar{\rho}_p[\text{deg}]$	0.449	0.917	-0.666	-1.023
$\bar{\rho}_y[\text{deg}]$	0.431	-1.268	1.774	0.956
$\bar{\rho}_r[\text{deg}]$	0.897	-0.330	-1.193	-0.119

5.5 歩行姿勢認識実験

5.5.1 実験方法

3 人の被験者に対して 3 箇所 で 4 種類の歩行姿勢の認識を行う。歩行動作は通常歩行, 右足引きずり歩行, 左肩下がり歩行, うつむき歩行の 4 種類である。5.3 章で述べた人の歩行姿勢の指標を求める。各軸の揺れ度と傾斜度を用いて次式の特徴ベクトルを作成する。

$$\boldsymbol{v} = [\bar{\varphi}_p, \bar{\varphi}_y, \bar{\varphi}_r, \bar{\rho}_p, \bar{\rho}_y, \bar{\rho}_r]$$

求めた 6 次元ベクトルを SVM に入力し, 歩行姿勢認識を行う。3 人の被験者が 3 箇所 でそれぞれ 4 種類の歩行動作を行うから, 1 人 1 箇所 4 動作を 1 組とすれば, 全部でデータセットは 9 組となる。これに leave-one-out 交差検証を適用し, 8 組をトレーニングデータ, 1 組をテストデータとして SVM で学習と認識を行う。認識結果は正答率で評価する。

5.5.2 実験結果

実験結果を表 5.21 に示す。全体の正答率は 88.9[%] で, 良好な結果が得られた。

表 5.21 歩行姿勢の認識結果

出力 入力	通常	右足引きずり	左肩下がり	うつむき
通常	9	0	0	0
右足引きずり	1	8	0	0
左肩下がり	1	0	8	0
うつむき	2	0	0	7

第6章 考察

本研究では、ウェアラブルカメラを用いた人の歩行姿勢の推定・解析法を提案した。通常歩行、右足引きずり歩行、左肩下がり歩行、うつむき歩行の4種類の歩行動作の映像を利用した実験により、提案法の性能を示した。人の周囲にカメラを設置して姿勢解析を行う従来の手法とは異なり、提案法は、人に装着したカメラで撮影した映像に基づいて解析を行う。これは、従来の手法が人を映した映像を利用しているのに対し、提案法はウェアラブルカメラが撮影した人の前方のシーンの映像を利用していることになる。正面のシーンの異常な変化がカメラ装着者の特定の姿勢変化を表示している。これにより、提案法は、ウェアラブルカメラを利用して間接的に人の歩行姿勢の推定・解析を行うが、場所を選ばずどこでも人の姿勢の推定・解析が可能になるという大きな利点がある。

図 5.3 から図 5.5 に示したように、回転する軸以外の軸周りの回転角度はほぼ $0[\text{deg}]$ である。pitch 軸と yaw 軸周りに回転するとき、LK 追跡法によりより優れた特徴点追跡が可能になる。これにより、検出された対応点の精度が向上する。一方、画面が roll 軸を中心に回転運動を行えば、画像中心から離れた領域では特徴点の追跡が難しくなり、対応点の精度が落ち、3次元復元にも悪影響を及ぼす。幸いなことに人が歩行する場合、通常は roll 軸周りの大きな回転はなく、pitch 軸と yaw 軸の回転も含まれるため、より良い対応点が得られる。

AKAZE による特徴点検出は、スケール不変かつ回転不変であり、照明やその他の状況でのロバスト性にも優れているため、良好に機能する。しかし、うつむき歩行の場合、カメラの視野は道路を捉え、道路上の特徴点を正しくまた多数検出するのは困難である。そのため対応点の総数が減少し、推定精度が落ちる恐れがある。この問題は、路面のテクスチャに焦点を当てるか、より強力な特徴点検出器を開発することによって解決できると考えられる。

人の歩行運動の推定と解析の性能は実験によって示され、将来の実用化のために満足のいく結果が得られた。左肩下がり歩行は体幹が左回り(roll 軸が負になる)に回転し、roll 軸の傾斜度 $\bar{\rho}_r$ は通常歩行より小さくなった。うつむき歩行の場合、上半身の前屈姿勢が大きく動きが少ない。即ち、pitch 軸の傾斜度 $\bar{\rho}_p$ と pitch 軸の揺れ度 $\bar{\varphi}_p$ が小さく、yaw 軸と roll 軸の揺れ度 $\bar{\varphi}_y, \bar{\varphi}_r$ が大きくなった。しかし、うつむき歩行においては被験者 1 と 2 の傾斜度 $\bar{\rho}_p$ は通常歩行とうつむき歩行の 3 箇所の姿勢推定の平均がそれぞれ $-1.957[\text{deg}]$ 、 $-0.486[\text{deg}]$ と $-1.658[\text{deg}]$ 、 $-0.040[\text{deg}]$ となり、通常歩行より大きくなった。一方、被験者 3 の傾斜度 $\bar{\rho}_p$ は通常歩行とうつむき歩行の 3 箇所の姿勢推定の平均がそれぞれ $0.009[\text{deg}]$ と $-0.613[\text{deg}]$ であり、 $0.6[\text{deg}]$ を超える違いが見られた。これは、被験者のうつむき

歩行時，前屈姿勢の傾きの角度が異なり，また，下に向けたカメラから得られた画像は道路になり，特徴点の追跡が失い，抽出された特徴点が少なく人の姿勢推定に誤差が生じる．この問題は，路面のテクスチャに焦点を当てることによって解決できると考えられる．

人の姿勢認識実験より，正答率は 88.9[%]であった．うつむき歩行が通常歩行に認識されたのは，2つが存在した．表 5.3 から表 5.20 を見れば，被験者 3 場所 A と被験者 3 場所 C のうつむき歩行の姿勢指標と通常歩行は似ているためであった．これは被験者 3 の実際のビデオ映像からのうつむき姿勢が通常歩行姿勢との顕著な違いが見られないことが原因と考えられる．精度を向上させるため，人の姿勢指標を追加する，SVM のペナルティパラメータを大きく設定する等の対策が必要と考えられる．

第7章 結論

本論文では、人体の健康に関する問題を発見し、姿勢を改善することを目的として、人の歩行姿勢の推定と解析を行う方法を提案した。提案法は、人が装着したウェアラブルカメラから提供される正面シーンの動画を解析する。これは、人自身の映像を使用する既存の方法と本法を区別するものである。

提案法の有効性を確認するために、ロボットアームを用いて、各軸の周りのみを回転した実験を行った。実験結果によって、提案法の精度は多軸センサより高いことがわかった。提案法による姿勢推定と解析の性能を、3人の被験者に対して3箇所、4種類の歩行姿勢を用いた実験で調べた。提案した人の歩行姿勢の指標から歩行動作も区別できるようになる。これらの指標を用いて個々人の歩行姿勢を解析すれば、人の姿勢推定・認識精度の改善ができると考えられる。人体姿勢認識実験を行い、正答率は88.9[%]になった。歩行動作の認識ができるようになる。その成果は有用で、更なる本研究の深化が期待される。今後の課題としては、実験データを増やすだけでなく、歩行姿勢の推定精度の向上や、より詳細な人の姿勢解析のための指標の追加等が挙げられる。

提案法は、ウェアラブルカメラを用いた間接計測に基づく人の動作・運動解析の研究に道を開いた。この方法は、屋内外を問わず、あらゆる場所で収集された人の前面の映像から人の歩行姿勢や動作を解析することができる。近い将来本研究は、歩行者の首におしゃれなペンダント型カメラを掛けることによって、歩行者の自己姿勢の日常的なチェックを実現するシステムを提案するであろう。

参考文献

- [1] 総務省統計局: “統計トピックス No.132 統計からみた我が国の高齢者—「敬老の日」にちなんで—”, pp.2-4, 2022.
- [2] 東京消防庁: “救急搬送データから見る日常生活事故の実態”, p.69, 2016.
- [3] 厚生労働省: “平成 27 年人口動態統計”, 2016.
- [4] Muro-De-La-Herran, B. Garcia-Zapirain, A. Mendez-Zorrilla: “Gait analysis methods: An overview of wearable and non-wearable systems, highlighting clinical applications”, *Sensors*, Vol.14, Issue 2, pp.3362-3394, 2014.
- [5] R. van der Meer: “Recent developments in computer assisted rehabilitation environments”, *Military Medical Research*, 2014.
- [6] H. El Makssoud, C. L. Richards, F. Comeau: “Dynamic control of a moving platform using the CAREN system to optimize walking in virtual reality environments”, *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp.2384-2387, 2009.
- [7] J. Carreira, P. Agrawal, K. Fragkiadaki, J. Malik: “Human pose estimation with iterative error feed-back”, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.4733-4742, 2016.
- [8] D. C. Luvizon, H. Tabia, D. Picard: “Human pose regression by combining indirect part detection and contextual information”, *Computers & Graphics*, Vol.85, pp.15-22, 2019.
- [9] W. Yang, S. Li, W. Ouyang, H. Li, X. Wang: “Learning feature pyramids for human pose estimation”, *2017 IEEE International Conference on Computer Vision (ICCV)*, pp.1281-1290, 2017.
- [10] D. Pavlo, C. Feichtenhofer, D. Grangier, M. Auli: “3D human pose estimation in video with temporal convolutions and semi-supervised training”, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 7753-7762, 2019.
- [11] H. Qiu, C. Wang, J. Wang, N. Wang, W. Zeng: “Cross view fusion for 3d human pose estimation”, *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, pp.4342-4351, 2019.
- [12] X. Zhou, Q. Huang, X. Sun, X. Xue, Y. Wei: “Towards 3d human pose estimation in the wild: a weakly-supervised approach”, *IEEE International Conference on Computer Vision*, pp.398-407, 2017.

- [13] J. Camps, A. Sama, M. Martin, et al: “Deep learning for freezing of gait detection in parkinsons disease patients in their homes using a waist-worn inertial measurement unit”, *Knowledge-Based Systems*, Vol.139, pp.119-131, 2018.
- [14] D. Mehta, H. Rhodin, D. Casas, P. Fua, O. Sotnychenko, W. Xu, C. Theobalt: “Monocular 3D human pose estimation in the wild using improved cnn supervision”, *2017 International Conference on 3D Vision*, pp.506-516, 2017.
- [15] C. Lou, S. Wang, T. Liang, C. Pang, L. Huang, M. Run, X. Liu: “A graphene-based flexible pressure sensor with applications to plantar pressure measurement and gait analysis”, *Materials*, Vol.10, Issue 9, 2017.
- [16] J. Camps, A. Sama, M. Martin, et al: “Deep learning for freezing of gait detection in parkinson’s disease patients in their homes using a waist-worn inertial measurement unit”, *Knowledge-Based Systems*, Vol.139, pp.119-131, 2018.
- [17] A.-K. Seifert, M. G. Amin, A. M. Zoubir: “Toward unobtrusive in-home gait analysis based on radar micro-doppler signatures”, *IEEE Transactions on Biomedical Engineering*, Vol.66, Issue 9, pp.2629-2640, 2019.
- [18] A. S. Alharthi, S. U. Yunas, K. B. Ozanyan: “Deep learning for monitoring of human gait: A review”, *IEEE Sensors Journal*, Vol.19, Issue 21, pp.9575-9591, 2019.
- [19] N. Dalal, B. Triggs: “Histograms of oriented gradients for human detection”, *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.886-893, 2005.
- [20] M. Nieto-Hidalgo, F. J. Ferrández-Pastor, R. J. Valdivieso-Sarabia, J. Mora-Pascual, J. M. García-Chamizo: “A vision based pro-posal for classification of normal and abnormal gait using rgb camera”, *Journal of Biomedical Informatics*, Vol.63, pp.82-89, 2016.
- [21] J. Stenum, C. Rossi, R. T. Roemmich: “Two-dimensional video-based analysis of human gait using pose estimation”, *bioRxiv*, Vol.17, Issue 4, pp.40-50, 2020.
- [22] A. Toshev, C. Szegedy. Deeppose: “Human pose estimation via deep neural networks”, *IEEE Conference on Computer Vision and Pattern Recognition*, pp.1653-1660, 2014.
- [23] X. Liu: “Video-based gait analysis for health monitoring”, *University of Arkansas at Little Rock ProQuest Dissertations Publishing*, pp.1-50, 2020.
- [24] K. Jun, D.-W. Lee, K. Lee, M. S. Kim: “Feature extraction using an rnn autoencoder for skeleton-based abnormal gait recognition”. *IEEE Access*, Vol.8, pp.19196-19207, 2020.

- [25] M. J. Mathie, A. C. F. Coster, N. H. Lovell, B. G. Celler: “Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement”, *Physiological Measurement*, Vol.25, Num.2, R1-20, 2004.
- [26] F. Sener, C. Bas, N. Ikizler-Cinbis: “On recognizing actions in still images via multiple features”, *Computer Vision-ECCV 2012. Workshops and Demonstrations*, pp.263-272, 2012.
- [27] Y. Wang, D. Tran, Z. Liao, D. Forsyth: “Discriminative hierarchical part-based models for human parsing and action recognition”, *Gesture Recognition*, pp.273-301, 2017.
- [28] H. Ning, W. Xu, Y. Gong, T. Huang: “Discriminative learning of visual words for 3d human pose estimation”, *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-8, 2008.
- [29] X. Chen, A. Yuille: “Articulated pose estimation by a graphical model with image dependent pair-wise relations”, *International Conference on Neural Information Processing Systems*, Vol. 1, pp.1736-1744, 2014.
- [30] J. Tompson, R. Goroshin, A. Jain, Y. LeCun, C. Bregler: “Efficient object localization using convolutional net-works”, *IEEE Conference on Computer Vision and Pattern Recognition*, pp.648-656, 2015.
- [31] X. Sun, B. Xiao, F. Wei, S. Liang, Y. Wei: “Integral human pose regression”, *European Conference on Computer Vision*, pp.529-545, 2018.
- [32] G. Pavlakos, X. Zhou, K. G. Derpanis, K. Daniilidis: “Coarse-to-fine volumetric prediction for single-image 3D human pose”, *IEEE Conference on Computer Vision and Pattern Recognition*, pp.7025-7034, 2017.
- [33] J. Martinez, R. Hossain, J. Romero, J. J. Little: “A simple yet effective baseline for 3d human pose estimation”, *IEEE International Conference on Computer Vision*, pp.2640-2649, 2017.
- [34] T. Chen, C. Fang, X. Shen, Y. Zhu, Z. Chen, J. Lou: “Anatomy-aware 3D human pose estimation in videos”, *arXiv-CS-Computer Vision and Pattern Recognition*, pp.1-11, 2020.
- [35] G. Pavlakos, X. Zhou, K. Daniilidis: “Ordinal depth supervision for 3d human pose estimation”, *IEEE Conference on Computer Vision and Pattern Recognition*, pp.7307-7316, 2018.
- [36] Z. Zhang, C. Wang, W. Qiu, W. Qin, W. Zeng: “Adafuse: Adaptive multiview fusion for accurate human pose estimation in the wild”, *International Journal of Computer Vision*, pp.1-16, 2020.

- [37] H. Qiu, C. Wang, J. Wang, N. Wang, W. Zeng: “Cross view fusion for 3d human pose estimation”, *IEEE International Conference on Computer Vision*, pp.4342-4351, 2019.
- [38] S. Ishikawa, J. K. Tan, H. Kim, S. Ishikawa: “3-D recovery of a non-rigid object from a single camera view by piecewise recovery and synthesis”, *Proc. of the 21st Int. Conf. on Pattern Recognition*, pp.1443-1446, 2012.
- [39] 千原 朋也: MY VISION を用いた歩行者の自己姿勢推定—歩行環境の 3次元情報からの姿勢解析, 平成 30 年度九州工業大学修士論文, 2019.
- [40] Z. Liu, T. Chihara, J. K. Tan: “Ego-posture estimation for a pedestrian using a monocular wearable camera”, *ICCCS*, pp.409-412, 2020.
- [41] B. Bodenheimer, C. Rose, S. Rosenthal, J. Pella: “The process of motion capture: Dealing with the data”, *Computer Animation and Simulation '97*, pp.3-18, 1997.
- [42] T. Shiratori, H. S. Park, L. Sigal, Y. Sheikh, J. K. Hodgins: “Motion capture from body-mounted cameras”, *ACM Transactions on Graphics*, Vol.30, Issue 2, pp.1-10, 2011.
- [43] B. Sapp, A. Toshev, B. Taskar: “Cascaded Models for articulated pose estimation”, *European Conference on Computer Vision*, pp.406-420, 2010.
- [44] X. Zhang, C. Li, X. Tong, W. Hu, S. Maybank, Y. Zhang: “Efficient human pose estimation via parsing a tree structure based human model”, *IEEE*, pp.1349–1356, 2009.
- [45] Z. Cao, T. Simon, S. E. Wei, Y. Sheikh: “Realtime multi-person 2D pose estimation using part affinity fields”, *IEEE*, pp.7291-7299, 2017.
- [46] D. Mehta, S. Sridhar, O. Sotnychenko, H. Rhodin, M. Shafiei, H. P. Seidel, W. Xu, D. Casas, C. Theobalt: “VNect: Real-time 3D human pose estimation with a single RGB camera”, *ACM Transactions on Graphics (TOG)*, Vol.36, Issue 4, Article No. 44, 2017.
- [47] J. K. Tan, T. Kurosaki: “Estimation of self-posture of a pedestrian using MY VISION based on depth and motion network”, *Journal of Robotics, Networking and Artificial Life*, Vol.7, No.3, pp.152-155, 2020.
- [48] 黒崎 倫之: MY VISION に基づくニューラルネットワークを用いた歩行者の自己姿勢推定と解析法, 令和元年度九州工業大学修士論文, 2020.
- [49] D. G. Lowe: “Distinctive image features from scale-invariant keypoints”, *International Journal of Computer Vision*, 2004.
- [50] H. Bay, T. Tuytelaars, L. Van Gool: “SURF: Speeded up robust features”, *European Conference on Computer Vision*, pp.404-417, 2006.

- [51] P. F. Alcantarilla, J. Nuevo, A. Bartoli: “Fast explicit diffusion for accelerated features in nonlinear scale spaces”, *Proceedings of the British Machine Vision Conference*, 2013.
- [52] B. D. Lucas, T. Kanade: “An iterative image registration technique with an application to stereo vision”, *Proc. of Int. Joint Conf. on Artificial Intelligence*, pp. 674-679, 1981.
- [53] D. Nistér: “An efficient solution to the five-point relative pose problem”, *IEEE transactions on pattern analysis and machine intelligence*, Vol.26, Issue 6, pp.756-770, 2004.
- [54] M. A. Fischer, R. C. Bolles: “Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography”, *Comm. ACM*, pp.381-395, 1981.
- [55] S. Gratton, A. S. Lawless, N. K. Nichols: “Approximate Gauss–Newton methods for nonlinear least squares problems”, *SIAM Journal on Optimization*, Vol.18, Issue 1, pp.106-132, 2007.
- [56] P. Podder, T. Z. Khan, M. H. Khan, M. M. Rahman: “Comparative performance analysis of Hamming, Hanning and Blackman window”, *International Journal of Computer Applications*, Vol.96, No.18, pp.1-7, 2014
- [57] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, B. Schölkopf: “Support vector machines”, *IEEE Intelligent Systems and their Applications*, Vol.13, Issue 4, pp.18-28, 1998.
- [58] Y. Liu, J. Bi, Z. Fan: “A method for multi-class sentiment classification based on an improved one-vs-one (OVO) strategy and the support vector machine (SVM) algorithm”, *Information Sciences*, Vol.394-395, pp.38-52, 2017.

謝辞

本研究を進めるにあたり、指導教員の丹上結乃純教授に心から感謝の意を表したいと思います。研究生の時期また大学院在学中、丹上先生には大変熱心にかつ暖かく指導して頂きました。このことに心より感謝申し上げます。丹上先生の適切なお指導があつて、本研究を無事完成させることができました。このことは、私にとって大きな自信となりました。今後はさらに研究・開発に励み、安全・安心な社会の実現のために貢献していきたいと思ひます。誠にありがとうございました。

また、博士課程在学中、大屋勝敬教授、神谷亨教授、張力峰教授には、本研究に対して貴重なご助言をたまわり、研究を進展させることができました。この場を借りてお礼申し上げます。

丹上研究室の皆様には、それぞれの研究で忙しい中、研究と実験に対して多くのご協力を頂きましたことを深く感謝いたします。

最後に、博士前期・後期課程の5年の間、先輩方と後輩の皆様との出会いで大変有意義な時間を過ごさせて頂いた丹上研究室に厚くお礼を申し上げます。

本当にありがとうございました。