

Title	身体部位ごとの特徴が歩容認証精度に与える影響の分析 と視点依存性の検討
Author(s)	YAO, WENBO
Citation	
Issue Date	2026-03
Type	Thesis or Dissertation
Text version	author
URL	https://hdl.handle.net/10119/20491
Rights	
Description	Supervisor:藤波 努, 先端科学技術研究科, 修士(知識 科学)

修士論文

身体部位ごとの特徴が歩容認証精度に与える影響の分析と視点依存性の検討

YAO WENBO

主指導教員 藤波 努

北陸先端科学技術大学院大学
先端科学技術専攻
(知識科学)

令和 8 年 3 月

Abstract

Gait recognition is sensitive to viewpoint variations, and the contribution of different body parts under changing viewpoints remains insufficiently explored. This study addresses the problem of how body-part segmentation influences gait recognition accuracy and viewpoint robustness. Using gait silhouette sequences from the CASIA-B dataset, we adopt part-based segmentation strategies to divide the human body into three parts (head, upper body, and lower body) and five finer-grained regions. Each segmented part is independently trained and evaluated across multiple viewing angles to analyze learning behavior and recognition performance. Experimental results show that the lower body provides the most discriminative gait features across viewpoints, while the upper body contributes complementary information in a viewpoint-dependent manner. The head region exhibits limited contribution. Furthermore, the five-part segmentation improves recognition stability and peak accuracy compared with the three-part configuration. These findings demonstrate the effectiveness of part-based segmentation and highlight the importance of viewpoint-aware analysis in gait recognition.

Keywords:

Gait Recognition; Part-based Segmentation; Viewpoint Dependency; Body Part Contribution; CASIA-B

目次

第 1 章 研究背景・研究目的	1
1.1 歩容認証の概要と応用分野	1
1.2 歩容認証における身体部位別特徴の重要性と課題	1
1.3 研究目的.....	2
第 2 章 先行研究	3
2.1 歩容認証に関する先行研究	3
2.1.1 GEI に基づく従来手法	3
2.1.2 深層学習に基づく歩容認証手法	3
2.1.3 部位分割・時系列拡張・視点不変性に関する研究.....	3
2.1.4 OpenGait フレームワークと本研究の位置づけ	4
第 3 章 研究手法	5
3.1 入力データと前処理.....	5
3.2 人体部位分割方法	5
3.2.1 三分割による人体分割.....	5
3.2.2 五分割による人体分割.....	6
3.2.3 認証実験と比較方法	6

第 4 章 実験設定	7
4.1 基礎実験.....	7
4.1.1 実験目的	7
4.1.2 使用データセット	7
4.1.3 実験手順	8
4.2 部位別実験.....	8
4.2.1 実験目的	8
4.2.2 身体部位の分割方針	9
4.2.3 実験設定	10
4.2.4 評価方法	10
第 5 章 実験結果	11
5.1 基礎実験.....	11
5.1.1 学習過程および収束性の分析	11
5.1.2 視点別 Rank-1 認証精度	14
5.1.3 基礎実験のまとめ	16
5.2 部位別実験.....	16
5.2.1 三分部位実験.....	17
5.2.2 三分部位実験分析.....	29

5.2.3 五分部位実験	34
5.2.4 五分部位実験分析	51
第 6 章 部位特徴の重み付け融合に基づく認証性能分析	56
6.1 三分割部位融合における重み探索	56
6.1.1 Head=0 に固定した場合	57
6.1.2 Head=0.1 に固定した場合	58
6.1.3 Head=0.15 に固定した場合	58
6.1.4 Head 重み設定の意図と妥当性	59
6.1.5 考察	60
6.2 五分割部位融合における重み探索	63
6.2.1 探索設定と評価指標	63
6.2.2 重み探索結果	64
6.2.3 断面分析	67
6.2.4 考察	72
6.3 部位重要性に関する考察	74
6.3.1 下半身部位の高い識別寄与	75
6.3.2 上半身部位の中程度の寄与と補完性	75
6.3.3 Head 部位の限定的かつ補助的役割	76

6.3.4 部位重要性の階層構造.....	76
6.3.5 本章のまとめ	77
第 7 章 結論	77
7.1 研究のまとめ	77
7.2 主な結論.....	78
7.3 本研究の貢献	79
7.4 今後の課題	80

図目次

5.1 : 学習損失の収束過程	12
5.2 : 分類精度の推移.....1 错误!未定义书签。	
5.3 : 学習過程における Triplet Loss 関連指標の推移.1 错误!未定义书签。	
5.4 : NM 条件における視点別 Rank-1 認証精度 (同一視点除外)	15
5.5 : NM 条件における視点依存 Rank-1 認証精度.....	16
5.6 : 三分割条件における部位別シルエット画像の視点別例	18
5.7 : 学習損失の収束過程 (頭部)	19
5.8 : 分類精度の推移 (頭部)	20
5.9 : 学習過程における Triplet Loss 関連指標の推移 (頭部)	21
5.10 : NM 条件における視点別 Rank-1 認証精度 (頭部)	22

未找到图形项目表。

表目次

6.1: 三分割部位融合における重み探索結果 (Top-20)	61
6.2: 五分割部位融合における重み探索結果 (Top-20)	65

第1章 研究背景・研究目的

1.1 歩容認証の概要と応用分野

近年、監視カメラやセンサ技術の発展に伴い、個人を識別するための生体認証技術が広く研究・実用化されている。生体認証は、指紋や顔などの身体的特徴に基づく手法と、歩行動作や瞬きなどの行動的特徴に基づく手法に大別される。その中でも、歩行動作に基づいて個人を識別する歩容認証（Gait Recognition）は、対象者に特別な協力を求めることなく、遠距離かつ非接触で取得可能であるという特徴を有する。

このような特性から、歩容認証は防犯カメラ映像を用いた監視、犯罪捜査支援、公共空間における人物追跡などへの応用が期待されている。実際に、監視映像中の歩行映像を手がかりとして人物を特定した事例も報告されており、歩容認証の実用的価値は年々高まっている。顔認証と比較して、照明条件や撮影距離の制約を受けにくい点も、歩容認証の大きな利点である。

歩容認証においては、人物の歩行中の輪郭情報を用いる手法が広く採用されている。特に、複数フレームのシルエット画像を一步行周期で平均化して得られる Gait Energy Image（GEI）は、服装の色や模様の影響を受けにくく、安定した特徴表現が可能であることから、多くの研究で利用されてきた。一方で、GEI は時間方向の情報を平均化するため、動作に関する詳細な時系列情報が失われるという課題も指摘されている。

このような背景のもと、近年では深層学習を用いた歩容認証手法が主流となり、シルエット系列や GEI を入力とした高精度な識別モデルが多数提案されている。しかしながら、撮影視点の変化や歩行条件の違いによる認証精度の低下といった課題は依然として残されている。

1.2 歩容認証における身体部位別特徴の重要性と課題

歩行動作は、人体全体が一様に動くのではなく、頭部、胴体、上肢、下肢といった各身体部位がそれぞれ異なる運動特性を持つ複合的な動作である。例えば、下肢は歩幅や脚の振りといった周期的で動的な特徴を強く含む一方で、胴体や頭部は比較的安定した姿勢情報を保持している。このような部位ごとの特性の違いは、歩容認証において重要な識別手がかりとなる可能性がある。

この観点から、近年では人体を複数の部位に分割し、部位ごとの特徴を利用する手法が提案されている。代表的な研究としては、人体を水平方向に分割し、各部位の時系列特徴を統合することで認証精度の向上を図る手法などが挙げられる。これらの研究は、身体部位ごとの特徴が歩容認証に有効であることを示している。

しかしながら、多くの既存研究では、部位分割を特徴抽出の一手段として用いるにとどまっており、各身体部位が認証精度にどの程度寄与しているのかを定量的に分析した研究は限られている。また、身体部位ごとの特徴が、撮影視点の変化に対してどの程度安定しているかについても、十分な検討が行われていないと言いき難い。

特に、撮影視点が変わった場合、身体部位ごとに受ける影響が異なると考えられる。下肢の動きは側面視点では顕著に現れる一方、正面や斜め視点では情報が重なりやすいなど、部位ごとに視点依存性が存在する可能性がある。しかし、このような視点依存性と身体部位の関係を体系的に分析した研究は少ない。

以上のことから、歩容認証において身体部位ごとの特徴が認証精度に与える影響を明確化し、さらに視点変化に対する部位別の特性を分析することは、歩容認証の理解を深める上で重要な課題であると考えられる。

1.3 研究目的

本研究の目的は、歩容認証における身体部位ごとの特徴が認証精度に与える影響を明確にし、あわせて各部位の特徴が視点変化に対してどのような依存性を持つかを分析することである。

具体的には、人体輪郭画像を身体部位ごとに分割し、それぞれの部位から抽出される特徴を用いて歩容認証を行うことで、部位単独および複数部位の組み合わせが認証精度に及ぼす影響を定量的に評価する。これにより、歩容認証において有効な身体部位の特定および、視点変化に対して安定した特徴を持つ部位の検討を行う。

本研究を通じて、身体部位に着目した歩容特徴分析の有効性を検証し、将来的な歩容認証モデルの設計や特徴抽出手法の改善に寄与する知見を得ることを目的とする。

第2章 先行研究

2.1 歩容認証に関する先行研究

歩容認証（Gait Recognition）は，被験者に非接触かつ遠距離から適用可能な生体認証技術として注目されており，これまでに多様な手法が提案されてきた。本節では，代表的な従来手法から近年の深層学習に基づく手法までを整理し，本研究の位置づけを明確にする。

2.1.1 GEI に基づく従来手法

歩容認証における代表的な初期手法として，Han と Bhanu により提案された Gait Energy Image（GEI）が挙げられる [1]。GEI は，歩行シーケンス中の輪郭画像を時間方向に重ね合わせて平均化することで，一枚の静的画像として歩容特徴を表現する手法である。この手法は，計算コストが低く実装が容易であることから，長らく歩容認証研究の基盤として用いられてきた。

一方で，GEI は時間的変動情報を平均化によって失うため，歩行周期中の動的特徴を十分に表現できないという課題を有する。また，視点変化や外観変動（衣服，携行物など）に対する頑健性にも限界があることが指摘されている。

2.1.2 深層学習に基づく歩容認証手法

近年では，深層学習の発展に伴い，輪郭画像系列を直接入力として扱う高性能な歩容認証手法が多数提案されている。代表的な手法として，歩行シーケンスを順序なし集合として扱う GaitSet[2]が提案されており，視点変化に対する高い汎化性能を示している。

さらに，身体部位ごとの特徴表現に着目した GaitPart [3] では，人体を複数の水平領域に分割し，各部位の時系列特徴を独立に学習することで認証精度の向上を実現している。このような部位分割に基づくアプローチは，歩行動作における局所的な運動特性を効果的に捉える点で有効であることが示されている。

また，空間的・時間的特徴の統合をさらに高度化した GaitGL [4] などの手法も提案されており，高次の特徴表現を通じてさらなる性能向上が報告されている。

2.1.3 部位分割・時系列拡張・視点不変性に関する研究

深層学習型歩容認証の発展に伴い，単なる全身特徴の抽出にとどまらず，部位ごとの運動特性や時間的変形を明示的に扱う研究も進められている。

例えば，時間方向の変形に対応するために可変畳み込みを導入した手法 [6] や，三次元人体モデルを用いて視点変換を行う手法 [7] が提案されている。さらに，RGB 映像と LiDAR 点群を統合する CMGait [8] や，構造振動情報を用いた VibeGait [9] など，異なるモダリティを活用した歩容認証手法も報告されており，歩容特徴の表現可能性は拡張されつつある。

2.1.4 OpenGait フレームワークと本研究の位置づけ

これら多様な歩容認証手法を統一的に扱うためのオープンソースフレームワークとして OpenGait [5] が公開されている。OpenGait は，複数の代表的モデルを共通の評価基盤上で比較可能とする点で有用であり，本研究においても実験基盤として採用する。

以上の先行研究を踏まえると、歩行中の識別情報は身体部位によって寄与度が異なることが示唆されているものの，各部位の相対的重要性や，分割粒度の違いが認証性能に与える影響については，体系的な分析が十分に行われていない。

本研究では，三分割および五分割という異なる部位分割構成に基づき，部位ごとの重み付け融合を通じて識別性能への寄与を定量的に分析することで，歩容認証における部位重要性の理解を深化させることを目的とする。

第3章 研究手法

本研究では、人物の歩行動作に含まれる身体部位ごとの特徴が歩容認証精度に与える影響を分析するため、二値化された人物の動作シーケンスを入力とした実験を行う。特に、人体の分割方法として3分割および5分割の二通りを設定し、それぞれの条件下で認証精度を比較する。

3.1 入力データと前処理

本研究で用いる入力データは、歩行中の人物を撮影した動画から抽出された人物輪郭の二値画像系列である。まず、各フレームに対して人物領域を抽出し、背景を除去した後、人物部分のみを二値化することで、歩行動作を表す輪郭画像を生成する。

このように二値化された輪郭画像系列は、被験者の服装の色や模様、照明条件の影響を受けにくく、歩行動作そのものに起因する形状変化を安定して表現できるという利点を有している。本研究では、この輪郭画像を時系列データとして扱い、歩行周期に基づく人物識別を行う。

3.2 人体部位分割方法

歩行動作における身体部位ごとの運動特性を詳細に分析するため、本研究では人体輪郭画像を縦方向に基づいて分割し、部位別に特徴を抽出する。分割方法として、3分割および5分割の二通りを設定し、分割粒度の違いが歩容認証精度に与える影響を比較する。

3.2.1 三分割による人体分割

三分割では、人体全高を基準として、輪郭画像を以下の三つの部位に分割する。

- 頭部
- 上身部
- 脚部

頭部領域は主に頭部および首周辺を含み、比較的動きの少ない安定した姿勢情報を有する。上身部は胴体および腕の付け根を含み、歩行中の姿勢や腕振りの影響を受ける。一方、脚部は歩幅や脚の振りといった周期的かつ動的な運動を強く反映する領域であり、歩容認証において重要な情報を含むと考えられる。

本三分割は、身体部位ごとの大まかな運動特性を把握するための基本的な分割方法とする。

3.2.2 五分割による人体分割

五分割では、三分割を基礎とし、上身部および脚部をさらに細分化することで、より詳細な部位別特徴の分析を行う。具体的には、以下の五つの部位に分割する。

- 頭部
- 上身部（手肘以上）
- 上身部（手肘以下）
- 脚部（膝以上）
- 脚部（膝以下）

上身部は、腕の付け根から手肘を境界として二つの領域に分割することで、体幹に近い比較的安定した動きと、腕振りに伴う動的な動きを区別する。一方、脚部は膝関節を境界として、上腿部と下腿部に分割することで、歩行周期における脚の振り出し動作と接地動作の違いを捉えることを目的とする。

このように、関節位置を基準とした細分化を行うことで、各部位が持つ運動特性の違いをより明確に分離し、歩容認証精度への寄与を詳細に評価できると考えられる。

3.2.3 認証実験と比較方法

各フレームにおいて分割された人体部位ごとの輪郭画像を用いて、歩容認証モデルによる学習および評価を行う。実験では、人体全体を入力とした場合に加え、各部位単独および複数部位の組み合わせについても認証精度を算出し、比較を行う。

また、三分割と五分割という異なる分割方法において得られた認証結果を比較することで、人体分割の粒度が認証精度に与える影響を分析する。これにより、身体部位ごとの特徴の有効性および、分割方法の違いによる認証性能の変化について考察を行う。

第4章 実験設定

4.1 基礎実験

本章では、提案する部位別歩容分析を行う前段階として、全身シルエット画像を用いた基礎実験の設定について述べる。本実験は、後述する部位別シルエット画像実験との比較を行うための基準性能を取得することを目的とする。

4.1.1 実験目的

本基礎実験の目的は、全身シルエット画像を入力とした歩容認証における基本的な認証性能を確認し、部位別シルエット画像を用いた実験結果と比較するための参照点を得ることである。

これにより、全身情報を用いた場合と、各身体部位に限定した場合との性能差を定量的に評価できるようにする。

4.1.2 使用データセット

本研究では、歩容認証において広く利用されている公開データセットであるCASIA-B データセットを使用する。

CASIA-B は、以下の特徴を有する。

- 被験者数：124 名
- 撮影視点：11 方向（0° から 180° ）
- 各被験者について複数条件下の歩行シーケンスを含む

本実験では、異なる視点条件における歩容認証性能の違いを分析するため、11 視点すべてを対象として評価を行う。

CASIA-B データセットには、歩行条件の違いに基づき、NM(Normal Walking)、BG (Walking with Bag)、CL (Walking with Coat) の 3 種類の状態が含まれている。NM は、荷物や外套などの付加物を持たない自然歩行状態を指し、歩容そのものの運動特性が最も純粋に反映される条件である。一方、BG および CL は、それぞれバッグ携帯やコート着用といった外的要因により、身体輪郭や局所的な動作特性が変化する条件である。

本研究の目的は、人体を複数の身体部位に分割した際に、各部位が歩容認証性能にどの程度寄与するかを分析することであり、服装や携帯物による外観変化の

影響は考慮対象としない。そのため、本実験では歩行条件を NM (Normal Walking) のみに限定し、BG および CL 条件は評価対象から除外した。

4.1.3 実験モデルおよび入力データ

基礎実験における歩容認証モデルとして、既存研究で用いられている GaitBase をベースラインモデルとして採用する。

GaitBase は、歩容認証において安定した基本性能を示すモデルであり、本研究における比較実験の基準として適している。

入力データには、人物の歩行シーケンスから生成された全身のシルエット画像を用いる。

4.1.3 実験手順

基礎実験は、以下の手順で実施する。

まず、GaitBase モデルを用いて、全身 GEI を入力とした学習を行う。

次に、学習済みモデルに対して、各視点条件ごとにテストを実施し、人物識別性能を評価する。

評価指標としては、Rank-1 精度(第 1 位正解率)を用いる。Rank-1 精度は、テストサンプルに対して最も類似度の高い候補が正解人物である割合を示す指標であり、歩容認証において一般的に用いられている。

本実験では、歩行条件および視点条件の組み合わせごとに Rank-1 精度を算出し、条件×視点ごとの認証精度分布を取得する。これにより、視点変化が全身 GEI による歩容認証性能に与える影響を明確にする。

4.2 部位別実験

本章では、身体部位ごとの特徴が歩容認証精度に与える影響を明確にするために実施した部位別実験の設定について述べる。本実験では、GEI を身体部位ごとに分割し、各部位を単独で用いた歩容認証を行うことで、部位別特徴の有効性および視点依存性を分析する。

4.2.1 実験目的

部位別実験の目的は、以下の二点である。

第一に、身体部位ごとに抽出された特徴が、歩容認証における識別精度にどの程度寄与しているかを定量的に評価することである。

第二に、撮影視点の変化に伴い、有効となる身体部位がどのように変動するかを

分析し、部位ごとの視点依存性を明らかにすることである。

これにより、全身情報を用いた場合には把握しにくい、身体部位ごとの役割や特性を詳細に検討する。

4.2.2 身体部位の分割方針

本実験では、歩行動作に含まれる身体部位ごとの特徴を分析するため、シルエット画像を対象として人体を縦方向に分割し、部位別のシルエット画像を生成する。分割対象は、全身のシルエット画像であり、これを複数の身体部位に分割することで、各部位が歩容認証精度に与える影響を評価する。

まず、基本的な分割方法として、人体を以下の三領域に分割する三分割を採用する。

- 頭部
- 上半身
- 下半身

三分割では、人体全高に対する相対的な位置関係に基づき、固定比率で各領域を定義する。この分割は、頭部・体幹部・脚部という大まかな身体構造に対応しており、身体部位ごとの基本的な特徴差を把握することを目的としている。

さらに、本研究では、身体部位をより詳細に分析するため、三分割を基礎として五分割を行う。五分割では、上半身および下半身をそれぞれ関節位置を基準として細分化し、以下の五領域に分割する。

- 頭部
- 上肢（手肘以上）
- 上肢（手肘以下）
- 下肢（膝以上）
- 下肢（膝以下）

上肢については、手肘位置を境界として、体幹に近い比較的安定した動作を含む領域と、腕振りに伴う動的な動作を含む領域を分離する。下肢については、膝関節を境界として、大腿部と下腿部を分割することで、歩行周期における脚の振り出し動作および接地動作の違いを捉えることを目的とする。

分割方法としては、三分割および五分割のいずれにおいても、人体全高に対する固定比率による分割を基本とする。これは、人物ごとの姿勢や体格の違いに依存せず、一貫した条件下で部位別比較を行うことを目的としている。関節位置を用

いた Pose 推定に基づく分割方法も参考手法として考えられるが、本研究では処理の単純性および再現性を重視し、固定比率による分割を採用する。

各部位に分割されたシルエット画像は、後続の認証処理において、全身シルエット画像と同一の入力条件を維持するため、 64×44 画素の黒色背景画像上に配置する。具体的には、対象部位以外の領域を黒色で埋め、部位シルエットのみを対応する位置に配置することで、入力画像サイズを全身シルエットと一致させる。この処理により、入力画像サイズの違いによる影響を排除し、モデル構造や学習条件を変更することなく、全身および各部位の認証性能を公平に比較することが可能となる。

4.2.3 実験設定

部位別実験においても、基礎実験と同様に GaitBase をベースラインモデルとして使用する。

ただし、本実験では、各身体部位ごとにシルエット画像を入力とし、部位単独でモデルを独立に学習させる。これにより、異なる部位間での性能差が、モデル構造や学習条件ではなく、入力される部位情報の違いに起因するものとなるようにする。

すべての部位に対して、以下の条件を統一する。

- 同一モデル構造
- 同一ハイパーパラメータ
- 同一分割設定

入力データには、各部位に対応するシルエット画像のみを用い、全身情報は含めない。

4.2.4 評価方法

評価指標としては、基礎実験と同様に Rank-1 精度を用いる。

各身体部位について、学習済みモデルを用いて視点ごとのテストを実施し、状態条件および視点条件ごとの認証精度を算出する。

本評価では、まず各身体部位を単独で入力とし、それぞれについてモデルの学習および識別を行う。学習過程においては、Triplet Loss（同一クラス間距離を縮小し、異クラス間距離を拡大する距離学習用損失関数）、Softmax Loss（クラス分類の確率誤差を最小化する分類用損失関数）、および分類精度などの指標の推移を記録し、学習の収束性や安定性を分析する。これにより、各部位における特

徴の学習難易度や、収束までに要する学習量の違いを比較する。

さらに、最終的に得られた Rank-1 精度と併せて、学習過程における各種パラメータの変化傾向を総合的に評価することで、各身体部位が歩容認証において果たす役割や重要度について検討する。

得られた結果は、基礎実験における全身シルエット画像を用いた認証精度と比較し、身体部位ごとの寄与度および視点依存性について考察を行う。

第5章 実験結果

5.1 基礎実験

本節では、全身シルエット画像を入力とした基礎実験の結果について述べる。本実験では、学習回数を 20,000iteration とし、モデルの学習収束性および視点ごとの歩容認証性能を評価した。

5.1.1 学習過程および収束性の分析

図 5.1 図 5.2 図 5.3 に、学習過程における Triplet Loss、Softmax Loss、および分類精度の推移を示す。

学習初期においては、各損失値が急激に減少しており、モデルが歩容特徴を効率的に学習していることが確認される。その後、おおよそ数千 iteration 以降では、Triplet Loss および Triplet Hard Loss は緩やかな変動を伴いながら安定して推移しており、学習が十分に収束していることが分かる。

また、Softmax Accuracy は学習の進行とともに上昇し、最終的にはほぼ 1.0 に近い値で安定している。このことから、分類タスクとしても高い識別性能が得ら

れており、モデルが訓練データに対して十分な表現能力を獲得していると考えられる。

以上の結果より、本実験における学習設定は適切であり、全身シルエット画像を用いた歩容認証モデルとして安定した学習が行われたことが示された。




図 5.1 学習損失の収束過程




図 5.2 分類精度の推移




図 5.3 学習過程における Triplet Loss 関連指標の推移

5.1.2 視点別 Rank-1 認証精度

次に、NM（通常歩行）条件における全身シルエット（Body）を用いた Rank-1 認証精度を、視点ごとに評価した結果を示す。ここでは、評価の公平性を確保するため、同一視点間のマッチングは除外している。

図 5.4（棒グラフ）および図 5.5（レーダーチャート）に示す結果から、側面に近い視点（ 36° ～ 144° ）では比較的高い認証精度が得られた一方、正面（ 0° ）および背面（ 180° ）に近い視点では精度が低下した。特に、 36° 、 54° 、 126° 、 144° 付近では約 85%を超える高い認証精度が得られており、側面視点における識別性能の優位性が明らかに示されている。

このような視点依存性は、歩行中の脚部および腕部の周期的運動が側面視点においてより明瞭に観測される一方で、正面・背面視点では左右の動作が重なりやすく、運動情報の判別が困難になることに起因すると考えられる。また、正面・背面視点では身体輪郭の変化量が小さく、個人差に基づく特徴が抽出されにくい点も、性能低下の一因である。

本結果は、全身情報のみを用いた場合においても、歩容認証性能が視点条件に大きく依存することを示しており、後続の部位分割および部位別特徴融合の有効性を検証するための重要な基準結果となる。以降の章では、本節で示した全身ベースラインを基準として、三分割および五分割構成における部位別認証特性お

よび視点依存性の変化について詳細に分析する。




図 5.4 NM 条件における視点別 Rank-1 認証精度（同一視点除外）

View-wise Rank-1 Accuracy under NM Condition
(Exclude Identical-View Cases)




図 5.5 NM 条件における視点依存 Rank-1 認証精度

5.1.3 基礎実験のまとめ

以上の結果より、全身シルエット画像を用いた基礎実験において、モデルは安定した学習収束を示し、視点条件に依存した認証性能の変動が示された。本実験で得られた視点別 Rank-1 精度は、後述する部位別実験における認証性能を評価するための基準性能として用いる。

5.2 部位別実験

本研究では、身体部位が歩容認証精度に与える影響を詳細に分析するため、三分割および五分割の二種類の部位分割に基づく部位別実験を実施する。

三分割実験では、全身シルエット画像を縦方向に頭部・上半身・下半身の三領域

に分割し、各部位を単独入力として歩容認証を行う。一方、五分割実験では、三分割を基礎とし、上半身を肘関節付近を基準として上腕部と前腕部に、下半身を膝関節付近を基準として大腿部と下腿部にそれぞれ分割し、より詳細な身体部位単位での分析を行う。

各分割条件においては、各部位ごとに独立した学習および識別を行い、学習過程における損失関数や分類精度の推移を分析することで、収束速度や学習の安定性を比較する。また、最終的な Rank-1 認証精度を用いて、各身体部位が識別性能に与える影響を定量的に評価する。

さらに、視点角度ごとの認証精度を比較することで、身体部位ごとの有効性が視点条件によってどのように変化するかを分析し、異なる分割粒度における部位別特徴の役割について検討を行う。

5.2.1 三分部位実験

図 5.6 に、三分割条件における部位別シルエット画像の視点別例を示す。

上段から順に頭部、上半身、下半身のシルエットを示しており、各列は視点角度（ 0° ～ 180° ）に対応している。

視点角度の変化に伴い、各部位のシルエット形状および可視情報量が変化することが示された。特に、正面視点（ 0° ）および背面視点（ 180° ）では、身体の奥行き方向の情報が制限されるため、部位によっては輪郭形状が単純化してい

る。一方、斜め視点や側面視点においては、四肢の動きや身体形状が比較的明瞭に表れている。

これらの視点による外観の違いは、後述する部位別認証精度の差異を理解するための視覚的補助情報として用いる。




図 5.6 三分割条件における部位別シルエット画像の視点別例

5.2.1.1 三分部位実験（頭部）

5.2.1.1.1 学習過程（頭部）

頭部シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.7～図 5.9 に示す。

図 5.7 に示すように、Triplet Loss および Softmax Loss は学習初期に急激に減

少し、約 6,000~8,000 iteration 以降では変動幅が小さくなり、安定した値に収束した。



図 5.7 学習損失の収束過程（頭部）

分類精度の推移（図 5.8）においても、学習の進行に伴って精度が段階的に向上し、約 7,000 iteration 以降では大きな変動が見られず、安定した状態に到達している。




図 5.8 分類精度の推移（頭部）

また、Triplet Loss 関連指標の推移（図 5.9）から、Triplet Loss, Triplet Hard Loss, および特徴間距離が学習後半においてほぼ一定の値を維持しており、頭部シルエットに基づく特徴表現が学習過程の中で安定的に獲得されていることが分かる。




図 5.9 学習過程における Triplet Loss 関連指標の推移（頭部）

5.2.1.1.2 認証結果（頭部）

頭部シルエット画像を用いた歩容認証における，NM 条件下での視点別 Rank-1 認証精度を図 5.10 に示す。

その結果，正面視点（ 0° ）および背面視点（ 180° ）では認証精度が低く，それぞれ約 25.9%および 28.8%にとどまった。一方で，斜め視点から側面視点（ 36° ～ 144° ）においては，相対的に高い認証精度が得られており，特に 54° ～ 126° の範囲では約 48～50%程度の値を示している。これらの結果から，頭部領域に含まれるシルエット情報は、視点角度によって可視的な形状が大きく変化し、特に正面および背面視点では輪郭情報が限定的になる傾向が見られる。

このような視点による認証精度の差異は、頭部シルエットにおける外観情報の量や形状変化が視点条件に依存している可能性を示唆しており、後続の部位別比較および考察において検討を行う。




図 5.10 NM 条件における視点別 Rank-1 認証精度（頭部）

5.2.1.2 三分部位実験（上半身）

5.2.1.2.1 学習過程（上半身）

上半身シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.11～図 5.13 に示す。

図 5.11 に示すように、Triplet Loss および Softmax Loss は学習初期に大きく減少し、おおよそ 5,000～7,000 iteration 以降では減少傾向が緩やかになり、安定した値に収束していることが確認できる。




図 5.11 学習損失の収束過程（上半身）

分類精度の推移（図 5.12）においては、学習開始直後から精度が急速に向上し、約 6,000 iteration 以降では 0.98 前後の高い値で安定している。




図 5.12 分類精度の推移（上半身）

また，Triplet Loss 関連指標の推移（図 5.13）より，Triplet Loss，Triplet Hard Loss，および特徴間の平均距離はいずれも学習の進行に伴って減少し，学習後半では変動が小さくなった。




図 5.13 学習過程における Triplet Loss 関連指標の推移（上半身）

これらの結果から，上半身シルエットを用いた場合，比較的早い段階で安定した学習状態に到達していることが分かる。

5.2.1.2.2 認証結果（上半身）

上半身シルエット画像を用いた歩容認証における，NM 条件下での視点別 Rank-1 認証精度を図 5.14 に示す。

その結果、正面視点（0°）および背面視点（180°）では認証精度が低く、それぞれ約 60.6%および 59.9%を示している。

一方で、斜め視点および側面視点（18°～162°）においては、相対的に高い認証精度が得られており、特に 36° および 54° では約 78%前後の値を示している。

また、90° 付近では一時的に精度が低下する傾向が見られるものの、側面から斜め後方視点にかけて再び精度が向上している。




図 5.14 NM 条件における視点別 Rank-1 認証精度（上半身）

これらの結果は、上半身領域に含まれる腕の振りや胴体形状などの情報の可視性が視点条件によって変化することを示しており、視点依存性を有する特徴である。

5.2.1.3 三分部位実験（下半身）

5.2.1.3.1 学習過程（下半身）

下半身シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.15～図 5.17 に示す。

図 5.15 に示すように、Triplet Loss および Softmax Loss は学習初期に急激に減少し、約 5,000～7,000 iteration 以降では減少傾向が緩やかとなり、安定した値に収束した。




図 5.15 学習損失の収束過程（下半身）

分類精度の推移（図 5.16）においては、学習初期から精度が急速に向上し、約 6,000 iteration 前後で 0.99 近傍に到達した後、その後の学習においても高い値

で安定している。




図 5.16 分類精度の推移（下半身）

また，図 5.17 に示す Triplet Loss 関連指標の推移より，Triplet Loss，Triplet Hard Loss，および特徴間距離はいずれも学習の進行に伴って単調に減少し，学習後半では変動幅が小さくなった。




図 5.17 学習過程における Triplet Loss 関連指標の推移（下半身）

これらの結果から、下半身シルエットを用いた場合、比較的安定した学習過程を示し、学習の収束性が良好であることが分かる。

5.2.1.3.2 認証結果（下半身）

下半身シルエット画像を用いた歩容認証における、NM 条件下での視点別 Rank-1 認証精度を図 5.18 に示す。その結果、正面視点 (0°) および背面視点 (180°) では認証精度が低く、それぞれ約 46.0% および 39.6% を示している。一方で、斜め視点から側面視点 ($18^{\circ} \sim 144^{\circ}$) においては高い認証精度が得られており、特に 36° では約 82.3% と最も高い値を示している。また、 90° 付近においても精度の大きな低下は見られず、全体として広い視点範囲において比較的安定し

た認証性能が得られた。




図 5.18 NM 条件における視点別 Rank-1 認証精度（下半身）

これらの結果は、下半身領域に含まれる脚部の運動や歩行周期に関する情報が、多くの視点条件において安定して観測される可能性を示唆しており、視点依存性の分析において重要な比較対象となる。

5.2.2 三分部位実験分析

本節では、三分割条件下における頭部・上半身・下半身の三部位について、学習過程および認証結果の両面から比較分析を行い、各部位の特性と優劣を検討する。

5.2.2.1 学習過程に基づく比較

図 5.19 に示す学習曲線から、各部位における学習の収束挙動には明確な差が見

られる。

まず、上半身および下半身では、Softmax Accuracy が学習初期から急速に上昇し、おおよそ 5,000~6,000 iteration 前後で高い値に到達した後、安定して推移している。一方、頭部では精度の上昇が比較的緩やかであり、安定状態に到達するまでにより多くの学習反復を要している。

損失関数の推移に着目すると、Softmax Loss および Triplet Loss はいずれの部位においても単調減少傾向を示したが、上半身および下半身では損失の減少が速く、収束後の変動幅も小さかった。特に、下半身においては Triplet Loss 関連指標の推移が安定しており、特徴空間の構造が比較的早期に形成されていることが示唆される。




図 5.19 三分割条件における部位別学習過程の比較

これらの結果から、学習過程の観点では、上半身および下半身は頭部と比較して学習の安定性および収束性に優れていることが分かる。

5.2.2.2 認証結果に基づく比較

図 5.20 および図 5.21 に示す視点別 Rank-1 認証精度の比較より、各部位の識別性能および視点依存性には顕著な差が認められた。

頭部では、全体として認証精度が低く、特に正面視点（0°）および背面視点（180°）において著しい性能低下が見られる。

これに対し、上半身では、多くの視点において頭部より高い認証精度が得られており、36°～54°付近の斜め視点では比較的良好な性能を示している。ただし、90°付近では一時的な精度低下が見られ、視点条件による影響を受けていることが分かる。

一方、下半身は三部位の中で最も高い認証精度を示す視点が多く、36°や126°付近では約80%を超える値が得られた。また、側面視点を中心とした広い角度範囲において安定した性能を維持し、視点変化に対する頑健性が比較的高かった。




図 5.20 三分割条件における部位別視点別 Rank-1 認証精度の比較 (NM 条件)




図 5.21 三分割条件における視点依存 Rank-1 認証精度

図 5.22 の重み曲線においても、上半身の重みは中程度の値で推移しており、主識別要素というよりは、下半身情報を補完する役割を担っていることが読み取れる。

一方、下半身 (Lower) は三部位の中で最も高い認証精度を示す視点が多く、36° や 126° 付近では約 80%を超える値が得られている。また、側面視点を中心とした広い角度範囲において安定した性能を維持しており、視点変化に対する頑健性が比較的高い。

この結果は、図 5.21 において Lower の最適重みが多く、多くの視点で最も高く設定されていることと一致しており、脚部運動に由来する動的特徴が歩行認証において支配的な役割を果たしていることを定量的に裏付けている。




図 5.22 三分割部位融合における視点別最適重み曲線

以上より、視点別認証性能と最適重み分布の双方の分析から、下半身＞上半身＞頭部という部位重要性の序列が一貫して確認され、後続の部位融合および重み探索における設計指針の妥当性が示された。

5.2.3 五分部位実験

本節では、人体を五分割した場合の部位別実験結果を示す。

三分割実験と同様に、各部位について同一の学習条件でモデルを学習し、視点角度ごとの認証性能を評価した。

図 5.23 に、各視点角度 (0° , 18° , 36° , 54° , 72° , 90° , 108° , 126° , 144° , 162° , 180°) における五分割後の部位別シルエット画像の例を示す。各列は視点角度を表し、各行は上から順に、頭部、上半身（肘より上）、上半身（肘より下）、下半身（膝より上）、下半身（膝より下）に対応している。

五分割により、三分割では同一部位として扱われていた上肢および下肢が、関節位置を基準として細分化された。特に、下半身では膝関節を境界とすることで、大腿部と下腿部におけるシルエット形状および運動範囲の違いが明確となった。

これらの部位別シルエット画像を用いた学習および認証結果については、次節において、三分割実験との比較を含めて詳細に分析する。




図 5.23 五分割条件における部位別シルエット画像の視点別例

5.2.3.1 五分部位実験（頭部）

五分割実験において定義される頭部領域は、三分割実験における頭部と同一である。そのため、頭部に関する学習過程および認証性能は前節で示した結果と一

致しており，本節では重複を避けるため詳細な記述を省略する。

以下では，上半身および下半身をさらに細分化した各部位について，学習過程および認証結果の分析を行う。

5.2.3.2 五分部位実験（上身部手肘以上）

5.2.3.2.1 学習過程（上身部手肘以上）

上身部（手肘以上）シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.24～図 5.26 に示す。

図 5.24 に示すように，Triplet Loss および Softmax Loss は学習初期に急激に減少し，約 6,000～7,000 iteration 以降では減少傾向が緩やかとなり，安定した値に収束した。




図 5.24 学習損失の収束過程（上半身手肘以上）

分類精度の推移（図 5.25）においては，学習初期から精度が急速に向上し，約 6,000 iteration 前後で 0.99 近傍に到達した後，その後の学習においても高い値で安定している。




図 5.25 分類精度の推移（上半身手肘以上）

また，図 5.26 に示す Triplet Loss 関連指標の推移より，Triplet Loss，Triplet Hard Loss，および特徴間距離はいずれも学習の進行に伴って単調に減少し，学習後半では変動幅が小さかった。




図 5.26 学習過程における Triplet Loss 関連指標の推移（上半身手肘以上）

これらの結果から、上半部（手肘以上）シルエットを用いた場合においても、学習過程は比較的安定しており、収束性は良好であることが分かる。

5.2.3.2.2 認証結果（上半部手肘以上）

上半部（手肘以上）シルエット画像を用いた歩容認証における、NM 条件下での視点別 Rank-1 認証精度を図 5.27 に示す。

その結果、正面視点（ 0° ）および背面視点（ 180° ）では認証精度が低下する傾向が見られ、それぞれ約 60.6%および約 59.9%を示している。一方で、斜め視点から側面視点に相当する $18^{\circ} \sim 144^{\circ}$ においては相対的に高い認証精度が得られており、特に 36° （約 78.0%）および 54° （約 77.7%）で高い値を示して

いる。また、90° 付近では一時的に精度が低下する傾向が見られるものの、極端な性能劣化は確認されない。




図 5.27 NM 条件における視点別 Rank-1 認証精度（上半身手肘以上）

以上より、上半部（手肘以上）領域は多くの視点条件で一定の識別情報を提供する一方で、正面・背面視点では性能が低下しやすく、視点依存性を示す可能性がある。

5.2.3.3 五分部位実験（上半身手肘以下）

5.2.3.3.1 学習過程（上半身手肘以下）

上半身（手肘以下）シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.28～図 5.30 に示す。

図 5.28 に示すように、Triplet Loss および Softmax Loss は学習初期に急激に

減少し、約 6,000~8,000 iteration 以降では減少傾向が緩やかとなり、安定した値に収束した。




図 5.28 学習損失の収束過程（上半身手肘以下）

分類精度の推移（図 5.29）においては、学習初期から精度が急速に向上し、約 6,000 iteration 前後で 0.99 近傍に到達した後、その後の学習においても高い値で安定している。




図 5.29 分類精度の推移（上半身手肘以下）

また、図 5.30 に示す Triplet Loss 関連指標の推移より、Triplet Loss, Triplet Hard Loss, および特徴間距離はいずれも学習の進行に伴って単調に減少し、学習後半では変動幅が小さかった。




図 5.30 学習過程における Triplet Loss 関連指標の推移（上半身手肘以下）

これらの結果から、上半身（肘より下）シルエットを用いた場合においても、学習過程は安定しており、良好な収束性を示していることが分かる。

5.2.3.3.2 認証結果（上半身手肘以下）

上半身（手肘以下）シルエット画像を用いた歩容認証における、NM 条件下での視点別 Rank-1 認証精度を図 5.31 に示す。

その結果、正面視点（ 0° ）および背面視点（ 180° ）では認証精度が低く、それぞれ約 31.8%および約 31.3%を示している。一方で、斜め視点から側面視点に相当する $18^{\circ} \sim 144^{\circ}$ においては相対的に高い認証精度が得られており、特に 54° において約 50.7%と最も高い値を示している。また、 90° 付近では一時的

に精度の低下が見られるものの、全体としては視点の変化に応じた緩やかな性能変動に留まっている。




図 5.31 NM 条件における視点別 Rank-1 認証精度（上半身手肘以下）

これらの結果は、上半身（手肘以下）領域に含まれる前腕部の運動が、一定の識別情報を提供する一方で、視点条件によっては輪郭の重なりや遮蔽の影響を受けやすい可能性を示唆している。

5.2.3.4 五分部位実験（下半身膝以上）

5.2.3.4.1 学習過程（下半身膝以上）

下半身（膝以上）シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.32～図 5.34 に示す。

図 5.32 に示すように、Triplet Loss および Softmax Loss は学習初期に急激に

減少し、約 6,000~8,000 iteration 以降では減少傾向が緩やかとなり、安定した値に収束した。




図 5.32 学習損失の収束過程（下肢膝以上）

分類精度の推移（図 5.33）においては、学習初期から精度が着実に向上し、約 6,000 iteration 前後で 0.95 以上に到達した後、その後の学習においても高い値で安定している。




図 5.33 分類精度の推移（下肢膝以上）

また，図 5.34 に示す Triplet Loss 関連指標の推移より，Triplet Loss，Triplet Hard Loss，および特徴間距離はいずれも学習の進行に伴って単調に減少し，学習後半では変動幅が小さかった。




図 5.34 学習過程における Triplet Loss 関連指標の推移（下肢膝以上）

これらの結果から、下半身（膝以上）シルエットを用いた場合においても、学習過程は比較的安定しており、良好な収束性を示していることが分かる。

5.2.3.4.2 認証結果（下肢膝以上）

下半身（膝以上）シルエット画像を用いた歩容認証における、NM 条件下での視点別 Rank-1 認証精度を図 5.35 に示す。

その結果、正面視点（ 0° ）および背面視点（ 180° ）では認証精度が低く、それぞれ約 19.9%および約 18.9%を示している。一方で、斜め視点から側面視点に相当する $18^{\circ} \sim 144^{\circ}$ においては相対的に高い認証精度が得られており、特に 126° において約 49.4%と最も高い値を示している。また、 $36^{\circ} \sim 72^{\circ}$ 付近にお

いても約 45%前後の比較的高い精度が確認されており、視点条件によっては安定した識別性能を示している。




図 5.35 NM 条件における視点別 Rank-1 認証精度（下肢膝以上）

これらの結果は、下半身（膝以上）領域に含まれる大腿部の運動が、一定の識別情報を提供する一方で、正面・背面視点では輪郭の重なりや動きの投影が限定されるため、視点依存性が比較적顯著に現れる可能性を示唆している。

5.2.3.5 五分部位実験（下肢膝以下）

5.2.3.5.1 学習過程（下肢膝以下）

下半身（膝以下）シルエット画像を入力とした場合の学習過程における損失関数および分類精度の推移を図 5.36～図 5.37 に示す。

図 5.36 に示すように、Triplet Loss および Softmax Loss は学習初期に急激に

減少し、約 6,000~8,000 iteration 以降では減少傾向が緩やかとなり、安定した値に収束した。




図 5.36 学習損失の収束過程（下肢膝以下）

分類精度の推移（図 5.37）においては、学習初期から精度が急速に向上し、約 6,000 iteration 前後で 0.95 以上に到達した後、学習後半においても高い値で安定して推移している。このことから、下半身 2 領域を入力とした場合においても、学習は比較的安定して進行していることが分かる。




図 5.37 分類精度の推移（下肢膝以下）

また、Triplet Loss 関連指標の推移（図 5.38）から、Triplet Loss, Triplet Hard Loss, および特徴間距離はいずれも学習の進行に伴って単調に減少しており、学習後半では変動幅が小さくなっている。




図 5.38 学習過程における Triplet Loss 関連指標の推移（下肢膝以下）

これらの結果は、下半身（膝以下）シルエット画像を用いた場合においても、特徴表現の学習が安定して行われていることを示している。

5.2.3.5.2 認証結果（下肢膝以下）

下半身（膝以下）シルエット画像を用いた歩容認証における、NM 条件下での視点別 Rank-1 認証精度を図 5.39 に示す。

その結果、正面視点（ 0° ）および背面視点（ 180° ）では認証精度が低く、それぞれ約 36.1%および 25.9%を示している。一方で、斜め視点から側面視点（ 18° ～ 144° ）においては比較的高い認証精度が得られており、特に 54° では約 69.1%と最も高い値を示している。また、 108° ～ 126° 付近においても約 60%

を超える認証精度が確認されており、側面付近の視点においては安定した識別性能を示していることが分かる。しかしながら、視点が正面または背面に近づくにつれて認証精度が低下する傾向が見られ、下半身 2 領域における識別性能は視点依存性の影響を受けやすいことが示唆される。




図 5.39 NM 条件における視点別 Rank-1 認証精度（下肢膝以下）

これらの結果は、下半身（膝以下）領域に含まれる脚部の部分的な運動情報は有効である一方で、視点変化に対する頑健性には一定の制約が存在することを示しており、他部位との比較において重要な考察対象となる。

5.2.4 五分部位実験分析

本節では、五分割により得られた upper1, upper2, lower1, lower2 の各部位について、学習過程の挙動および認証性能の両観点から横断的な比較を行い、各部

位が歩容認証に与える影響とその特性を分析する。

5.2.4.1 学習過程に基づく比較

図 5.40 に、五分割各部位における Softmax Loss, 分類精度, および Triplet Loss の学習推移を示す。

まず, 学習の収束速度に着目すると, upper1 および upper2 は学習初期において損失の減少が比較的速く, 約 4,000~6,000 iteration 付近で減少傾向が緩やかとなり, 安定した値に収束した。特に upper2 は Softmax Loss および Triplet Loss のいずれにおいても最も早い収束挙動を示し, 上半身中間領域に含まれる輪郭形状が識別に有効な特徴を多く含むことが示唆された。

一方, lower1 および lower2 においても学習過程は安定しているが, upper 系部位と比較すると損失の減少がやや緩やかであり, 収束までに約 6,000~8,000 iteration を要する傾向が見られる。これは, 下半身領域では脚部の運動が大きく, フレーム間変動が比較的強いため, 特徴分布の安定化に時間を要したためと考えられる。分類精度の推移においては, いずれの部位も学習の進行とともに精度が単調に向上し, 最終的には 0.97~0.99 付近で安定している。特に upper2 は学習初期から精度上昇が顕著であり, 学習効率の観点からも優れた特性を示している。

以上より, 五分割においては upper2 → upper1 → lower2 → lower1 の順で

学習の収束性および安定性が高かった。




図 5.40 五分割条件における部位別学習過程の比較

5.2.4.2 認証結果に基づく比較

次に, NM 条件下における視点別 Rank-1 認証精度の比較結果を図 5.41 と図 5.42

に示す。

まず、全体的な傾向として、正面 (0°) および背面 (180°) では、いずれの部位においても認証精度が低下した。特に lower1 では 0° および 180° において約 20～30%台にとどまり、視点依存性の影響を強く受けた。

一方で、 18° ～ 144° の斜め～側面視点においては、lower2 が最も高い認証精度を示し、 36° , 54° , 126° 付近では約 60%以上の安定した性能が得られた。

これは、下半身後半領域に含まれる脚部の振り出しや周期的運動が、多くの視点条件下で安定して観測されるためであると考えられる。upper 系部位では、upper2 が upper1 を全体的に上回る傾向を示し、特に中間視点 (36° ～ 108°) において認証精度の差が顕著であった。

この結果は、上半身中部に含まれる体幹や腕の動きが、歩行者固有の特徴として有効に機能している可能性を示唆している。

以上の結果から、五分割における認証性能は lower2 > upper2 > upper1 > lower1 の順で高かった。また、部位の細分化により、識別に寄与する領域をより明確に抽出できた。




図 5.41 五分割条件における部位別視点別 Rank-1 認証精度の比較 (NM 条件)




図 5.42 五分割条件における視点依存 Rank-1 認証精度

5.2.4.3 まとめ（五分割の示唆）

五分割実験の分析結果より、

- 学習過程の安定性・収束速度の観点では upper2 が最も優れている
- 認証性能の観点では lower2 が最も高い識別能力を示す
- 単純な上下分割では捉えきれない部位内の機能差が明らかになった

ことが分かる。

これらの知見は、今後の歩容認証において部位ごとに重み付けを行う特徴融合や視点に応じた適応的部位選択を設計する上で重要な指針を与えるものである。

第6章 部位特徴の重み付け融合に基づく認証性能分析

6.1 三分割部位融合における重み探索

本節では、三分割部位 (Head・Upper・Lower) に基づく特徴融合において、Head 部位の重みを固定した条件下で、Upper および Lower の重み配分が認証精度に与える影響を分析する。具体的には、式 (1) に示す重み制約条件。

$$w_h + w_u + w_l = 1 \quad w_i > 0 \quad (\text{式 1})$$

の下で、Head の重みを $w_h=0, 0.1, 0.15$ に固定し、残りの重みを Upper (w_u)

および Lower (w_l) に配分した場合の、NM 条件下における平均 Rank-1 認証精度 (mean_fuse) を比較した。

なお、本節において Head 部位の重みを比較的低い範囲 ($w_h=0, 0.1, 0.15$) に限定した理由は、第 5 章の実験結果に基づくものである。

第 5 章で示した部位別認証実験の結果より、Head 部位単独による認証精度は、上半身 (Upper) および下半身 (Lower) と比較して一貫して低い値を示し、識別性能への寄与が相対的に小さかった。

このため、三分割部位融合において Head 部位を主要な情報源として高い重みで扱うことは合理的ではない。そこで、本研究では Head を補助的情報として扱い、低重み領域における影響を重点的に検討する。

6.1.1 Head=0 に固定した場合

Head の重みを $w_h=0$ とし、Upper と Lower のみを用いて融合を行った結果を図に青線で示す。

この条件では、Lower の重み w_l を増加させるにつれて認証精度が向上し、 w_l が 0.40~0.45 の範囲において最大値を示す。その後、 w_l を過度に増加させると精度は低下傾向を示す。

また、本条件における最大精度は、単一全身入力による基準性能 (mean_body) を明確に上回った。さらに、Head 情報を完全に除外した場合でも、上半身およ

び下半身の適切な重み配分により性能向上が可能であることが示された。

この結果は, Head 部位が三分割構成において主要な識別情報を提供していないこと, および歩行動作に強く関連する Upper・Lower の寄与が支配的であることを示唆している。

6.1.2 Head=0.1 に固定した場合

次に, Head の重みを $w_h=0.1$ に設定した結果を橙線で示す。

この条件では, Head=0 の場合と同様に, Lower の重みが中程度 ($w_l \approx 0.35 \sim 0.45$) の範囲で高い認証精度が得られる。

一方で, 最大精度は Head=0 の場合と比較して同程度もしくはわずかに低下しており, Head 情報を少量付与した場合でも, 性能向上への寄与は限定的であることが分かる。

この傾向は, Head 部位に含まれる情報が, 個人識別において補助的な役割に留まり, Upper・Lower による主要な識別情報を強化する効果が小さいことに起因すると考えられる。

6.1.3 Head=0.15 に固定した場合

さらに Head の重みを $w_h=0.15$ に増加させた結果を緑線で示す。この条件では, Lower の重みが比較的低い領域から精度が上昇するものの, 最大精度は Head=0 および 0.1 の場合と比べて明確な改善は見られない。

また、Head の重みが増加するにつれて、高い精度を維持できる重み範囲が狭くなり、Lower 側に過度な重みを割り当てた場合には精度低下が顕著となる。

これは、Head 部位に含まれる情報が視点変化や個人差に対して不安定であり、その重みを増加させることで、Upper・Lower に基づく安定した識別特徴が相対的に弱まるためであると考えられる。

6.1.4 Head 重み設定の意図と妥当性

本研究において $w_h=0$, 0.1 , 0.15 を採用した理由は以下の通りである。

$$w_h=0$$

Head 部位を完全に除外し、Upper・Lower のみで融合した場合の基準性能を確認するため。

$$w_h=0.1$$

Head 情報を補助的に付与した場合に、性能向上の可能性が存在するかを検証するため。

$$w_h=0.15$$

Head の寄与を過度に増加させた場合の性能変化を確認し、最適重み範囲を明確化するため。

これらの結果から、三分割構成においては Head 部位の寄与は限定的であり、Head の重みを増加させることは必ずしも認証性能の向上につながらないこと

が明らかとなった。




図 6.1 三分割部位融合における Head 重み固定時の融合性能比較（NM 条件）

6.1.5 考察

6.1.5.1 重み探索結果

本節では、三分割部位融合（Head・Upper・Lower）における重み探索結果を整理し、上位性能を示した重み組合せについて分析を行う。

表 6.1 に、NM 条件下における平均 Rank-1 認証精度（mean_fuse）に基づき、上位 20 件の重み組合せを示す。

表 1 より、三分割構成における最良性能は

$$(w_h, w_u, w_l) = (0.20, 0.43, 0.37)$$

の組合せであり、平均 Rank-1 認証精度は 0.903 を示した。これは、全身特徴の

みを用いた基準性能（mean_body=0.8035）と比較して、約+9.95%の明らかな性能向上に相当する。

wh	wu	wl	mean_body	mean_fuse	delta_mean
0.2	0.43	0.37	0.803545	0.903	0.099455
0.22	0.41	0.37	0.803545	0.902727	0.099182
0.2	0.47	0.33	0.803545	0.902091	0.098545
0.18	0.45	0.37	0.803545	0.901818	0.098273
0.22	0.45	0.33	0.803545	0.901818	0.098273
0.22	0.43	0.35	0.803545	0.900909	0.097364
0.2	0.41	0.39	0.803545	0.900818	0.097273
0.18	0.47	0.35	0.803545	0.900091	0.096545
0.18	0.43	0.39	0.803545	0.899818	0.096273
0.2	0.45	0.35	0.803545	0.899636	0.096091
0.16	0.47	0.37	0.803545	0.898727	0.095182
0.16	0.45	0.39	0.803545	0.897909	0.094364
0.18	0.41	0.41	0.803545	0.897364	0.093818
0.2	0.49	0.31	0.803545	0.897	0.093455
0.22	0.47	0.31	0.803545	0.897	0.093455
0.18	0.49	0.33	0.803545	0.896727	0.093182
0.2	0.39	0.41	0.803545	0.895545	0.092
0.14	0.47	0.39	0.803545	0.894455	0.090909
0.18	0.39	0.43	0.803545	0.894455	0.090909

表 6.1 三分割部位融合における重み探索結果（Top-20）

6.1.5.2 重み分布の傾向分析

Top-20 の結果全体を俯瞰すると、以下の共通した傾向が認められた。

- Head 重み (w_h)

上位解における Head 重みは 0.14～0.22 の比較的狭い範囲に集中してお

り、大きな値は採用されていない。これは、Head 部位が識別に寄与す

る情報量を有するものの、Upper・Lowerと比較して支配的ではないことを示唆している。

- Upper 重み (w_u)

Upper の重みは 0.39～0.49 に集中しており、三分割構成において最も大きな比重を占めている。上半身の姿勢や腕振りなどの動作特徴が、個人識別に安定して寄与していることが示唆される。

- Lower 重み (w_l)

Lower の重みは 0.31～0.43 の範囲で分布しており、Upper と同程度の重要性を有する部位であった。特に、多くの高精度解において Upper と Lower がほぼ均衡した重み配分となっている点が特徴的であった。

6.1.5.3 三分割構成における最適重み関係

以上の結果から、三分割部位融合においては、

$$w_u \approx w_l > w_h$$

という関係が一貫して成立していることが明らかとなった。すなわち、上半身および下半身が主要な識別情報を担い、Head 部位はそれらを補助する役割を果たす構成が最も高い認証精度を実現している。

この傾向は、第 5 章における単部位識別実験で得られた「Lower $\approx$ Upper>Head」という結果とも整合しており、三分割部位融合における重み探索結果の妥当性

を裏付けるものである。

6.2 五分割部位融合における重み探索

6.2.1 探索設定と評価指標

本節では、五分割された身体部位 (Head, Upper1, Upper2, Lower1, Lower2) に対する特徴融合において、各部位の寄与度を重みとして調整し、識別性能に与える影響を体系的に分析する。

三分割実験 (6.1 節) と同様に、線形加重和による特徴融合を採用し、重み探索を通じて最適な部位構成を検討する。

6.2.1.1 重み制約条件

五分割特徴融合における重みは、以下の制約条件を満たすものとする。

$$w_h + w_{u1} + w_{u2} + w_{l1} + w_{l2} = 1, w_i > 0 \quad (\text{式 2})$$

ここで、 w_h は Head 部位、 w_{u1}, w_{u2} は上半身を二分割した upper1, upper2, w_{l1}, w_{l2} は下半身を二分割した lower1, lower2 に対応する重みを表す。

6.2.1.2 探索手順

重み探索では、Head 部位の寄与が三分割実験において限定的であった結果を踏まえ、Head の重みを比較的低い範囲を中心に設定しつつ、他の部位との組み合わせを広く評価した。具体的には、各重み候補の組合せに対して線形融合特徴を生成し、NM 条件下における識別精度を算出することで性能を評価した。

探索は全組合せに対して一様に行い、得られた結果を平均 Rank-1 精度に基づいて順位付けすることで、高性能な重み構成を抽出した。本研究では、上位 20 組の重み構成 (Top-20) を代表的な結果として整理し、後続節において詳細な分析を行う。

6.2.1.3 評価指標

評価には CASIA-B データセットの NM 条件を用い, gallery を nm-01～nm-04, probe を nm-05～nm-06 とした。識別性能は Rank-1 精度を指標とし, 同一視点間の比較を除外した視点横断評価を行う。

各重み構成に対して, 全視点における Rank-1 精度を算出し, その平均値を mean Rank-1 accuracy として総合的な性能指標とした。また, 全身特徴 (Body) のみを用いた場合の平均 Rank-1 精度を baseline とし, 融合による性能向上量 (Δ mean) を併せて評価した。

6.2.2 重み探索結果

前節で述べた探索設定に基づき, 五分割部位 (Head, Upper1, Upper2, Lower1, Lower2) の重み探索を行った。本節では, 得られた結果のうち, 平均 Rank-1 精度が高い上位 20 組 (Top-20) の重み構成を中心に, その傾向を整理する。

6.2.2.1 Top-20 重み構成の概要

表 2 に, 平均 Rank-1 精度の高い上位 20 組の重み構成と対応する識別性能を示

す。いずれの構成においても、全身特徴（Body）の baseline（mean Rank-1=0.8035）を大きく上回る性能向上が確認された。

Top-20 における平均 Rank-1 精度（mean_fuse）は 0.9069～0.9085 の範囲に分布しており、baseline に対して約+10.3%～+10.5%の改善が得られている。この結果から、五分割部位特徴の線形融合が歩容認証性能の向上に有効であることが明らかに示された。

mean_body	mean_fuse	delta_mean	w_head	w_upper1	w_upper2	w_lower1	w_lower2
0.803545	0.908545	0.105	0.222132	0.123681	0.244356	0.140123	0.269708
0.803545	0.908455	0.104909	0.191576	0.133231	0.259354	0.140537	0.275301
0.803545	0.908273	0.104727	0.231154	0.136076	0.224087	0.149985	0.258698
0.803545	0.908091	0.104545	0.205994	0.145577	0.234113	0.140512	0.273804
0.803545	0.908	0.104455	0.203753	0.122417	0.247888	0.138637	0.287304
0.803545	0.908	0.104455	0.239963	0.149839	0.234382	0.138242	0.237574
0.803545	0.907818	0.104273	0.228718	0.127436	0.254827	0.155912	0.233108
0.803545	0.907727	0.104182	0.186809	0.138078	0.272324	0.148468	0.25432
0.803545	0.907727	0.104182	0.226842	0.136254	0.229806	0.161358	0.24574
0.803545	0.907636	0.104091	0.203832	0.145958	0.256584	0.136046	0.25758
0.803545	0.907545	0.104	0.191131	0.168413	0.233825	0.154002	0.25263
0.803545	0.907273	0.103727	0.189298	0.187058	0.223386	0.123519	0.276739
0.803545	0.907273	0.103727	0.171606	0.167326	0.252338	0.14447	0.26426
0.803545	0.907182	0.103636	0.218823	0.138549	0.247449	0.111316	0.283864
0.803545	0.907091	0.103545	0.204132	0.163461	0.218097	0.124522	0.289787
0.803545	0.907	0.103455	0.175898	0.155524	0.241828	0.1593	0.26745
0.803545	0.907	0.103455	0.203164	0.134648	0.274419	0.136105	0.251664
0.803545	0.907	0.103455	0.216541	0.154186	0.246775	0.109868	0.27263
0.803545	0.906909	0.103364	0.21754	0.137247	0.218107	0.168291	0.258815

表 6.2 五分割部位融合における重み探索結果（Top-20）

6.2.2.2 最良解の重み構成

探索結果の中で最も高い平均 Rank-1 精度を示した重み構成は以下の通りである。

- Head : 約 0.22
- Upper1 : 約 0.12
- Upper2 : 約 0.24
- Lower1 : 約 0.14
- Lower2 : 約 0.27

この構成において、平均 Rank-1 精度は 0.9085 に達し、baseline と比較して約 +10.5% の性能向上が得られた。

6.2.2.3 重み分布の傾向分析

Top-20 の重み構成を俯瞰すると、以下の共通した傾向が観察される。

1. Head 部位の重みは中程度に抑えられている

Head の重みはおおよそ 0.18~0.23 の範囲に集中しており、支配的な役割を担っていない。

2. 上半身・下半身が識別性能を主導

Upper1・Upper2 および Lower1・Lower2 の合計重みは、全体の大部分

を占めており、特に下半身側（Lower1+Lower2）がやや高い比率を示す構成が多い。

3. 左右（または上下）分割の非対称性

Upper1 と Upper2, Lower1 と Lower2 の重みは必ずしも等分されておらず、細分化された部位ごとに異なる識別寄与が存在することが示唆される。

6.2.2.4 三分割結果との関係

三分割部位融合（6.1 節）と比較すると、五分割構成では上半身および下半身内部の寄与差をより細かく表現でき、重み探索の自由度が向上した。その結果、全体として安定した認証性能の向上が得られた。

特に、下半身を二分割した Lower1 および Lower2 が比較的高い重みを獲得している点は、歩行動作における脚部運動が個人識別において支配的な役割を果たしていることを定量的に示す結果である。

この結果は、単一の下半身特徴として扱う三分割構成では捉えきれなかった脚部内部の運動差が、五分割構成によって有効に活用されていることを示唆している。

6.2.3 断面分析

本節では、五分割部位融合における各部位の寄与関係をより詳細に検討するた

め、一部の部位重みを固定した上で、残りの部位重みを変化させる断面分析を行う。

具体的には、Head 重みを固定した条件、および上半身・下半身の一部重みを固定した条件において認証精度の変化を観察し、各部位の相対的重要性を明らかにする。

6.2.3.1 Head 重み固定時の Upper–Lower バランス分析

その結果、いずれの Head 重み設定においても、認証精度は Lower 系重みの増加に伴って上昇し、特定の範囲で最大値を示した後、過度に Lower 偏重となると再び低下する傾向が観察された。

この挙動は、脚部運動が歩行識別において重要な情報源である一方で、上半身情報との適切なバランスが維持されない場合には識別性能が低下する可能性を示唆している。

また、Head 重みを 0.1～0.15 程度に設定した場合、Head を完全に除外した条件と比較して、最大精度がわずかに向上する傾向が見られた。このことから、Head 部位は単独では支配的な役割を果たさないものの、補助的情報として Upper・Lower の特徴を補完する役割を担っていると考えられる。**6.2.3.2 上半**

身重み固定時の下半身構成比分析

次に、上半身の重み ($w_{upper1} + w_{upper2}$) を一定値に固定し、下半身を構成する

Lower1・Lower2の重み配分を変化させた場合の認証精度を分析した。

その結果、下半身内部においても寄与は一様ではなく、Lower1とLower2の重み配分によって認証精度が変化した。特に、両者に極端な偏りを与えた場合には精度が低下し、一定の比率で分配した場合に高い性能が得られた。

この結果は、下半身内部においても、歩行周期中の異なる運動特性（例：大腿部と下腿部に対応する運動成分）が識別に寄与しており、それらを分離して扱う五分割構成の有効性を裏付けるものである。

6.2.3.3 下半身重み固定時の上半身構成比分析

同様に、下半身重みを固定した条件下で、上半身を構成するUpper1・Upper2の重み配分を変化させた分析を行った。その結果、上半身内部の重み比率による認証精度の変動は、下半身の場合と比較して相対的に小さいことが示された。

この傾向は、上半身が歩行中に比較的安定した姿勢を維持する一方で、識別に寄与する動的情報が下半身ほど顕著ではないことに起因すると考えられる。ただし、上半身を二分割して扱うことで、三分割構成と比較して性能の安定性が向上しており、細粒度な特徴分離自体は有効であることが示された。

6.2.3.4 断面分析のまとめ

以上の断面分析から、五分割部位融合においては、下半身（Lower1・Lower2）が識別性能に対して支配的な役割を果たしつつも、上半身およびHead部位が

適切に補助的役割を担うことで、最適な性能が得られることが明確となった。特に、下半身をさらに分割して扱うことにより、脚部内部の運動差を効果的に反映できる点が、五分割構成の重要な利点であるといえる。

6.2.3.5 視点別最適重み構成の分析

図 6.2 は、各視点において Rank-1 認証精度が最大となる重み組合せを抽出し、五分割部位（Head, Upper1, Upper2, Lower1, Lower2）の最適重み構成を積み上げ棒グラフとして可視化したものである。

また、図 6.2 は同一の最適重みを用い、各部位の重み変化を視点に対する連続曲線として表現した結果である。

まず、図 6.2 より、視点に応じて最適な重み分布には一定の変動が存在するものの、Lower1 および Lower2 が全視点にわたって相対的に高い重みを占める傾向が一貫して確認される。特に側面視点付近（ 72° ～ 126° ）では、下半身二部位の合計重みが全体の過半を占める視点が多く、脚部運動情報が識別性能に強く寄与していることが示唆される。

一方、Head 部位の重みは全体として低い値に留まっており、正面視点（ 0° ）や背面視点（ 144° ， 162° ）など一部の視点においてのみ補助的に増加する傾向が見られる。これは、Head 部位が歩行動作に直接関連する運動情報を多く含まない一方で、特定視点条件下では姿勢や輪郭形状の補完的情報として機能し

ている可能性を示している。




図 6.2 視点別最適重み構成（五分割部位融合）

さらに、図 6.3 の曲線表示から、各部位重みの視点依存的な変動傾向をより明確に観察できる。Lower1・Lower2 は視点変化に対して比較的滑らかな変動を示し、高い重みを安定して維持しているのに対し、Upper1・Upper2 は視点による上下動が大きく、識別への寄与が視点条件に依存していることが分かる。Head 重みは全体として最小であり、大きな視点変動に伴う顕著な増加は確認されない。




図 6.3 五分割部位融合における視点別最適重み曲線

以上より，五分割部位融合においては，下半身を構成する Lower1・Lower2 が視点変化に対して頑健かつ支配的な識別情報を提供しており，上半身および Head 部位はそれを補完する役割を担っていることが明らかとなった。このような視点別最適重み構成の可視化結果は，五分割構成が脚部内部の運動差および視点依存性を適切に反映できていることを定量的に裏付けるものである。

6.2.4 考察

本節では，五分割部位融合実験の結果を基に，各身体部位の識別性能への寄与関係を整理するとともに，三分割構成との比較を通して，五分割構成の有効性について考察する。

6.2.4.1 識別性能における支配的部位の分析

重み探索および断面分析の結果より，五分割構成において最も高い重みを安定して獲得したのは，下半身を構成する Lower1 および Lower2 であった。これ

は、歩行認証において脚部運動が個人差を強く反映する主要な情報源であることを定量的に裏付ける結果である。

特に、下半身を単一部位として扱う三分割構成と比較すると、Lower1・Lower2を分離した五分割構成では、下肢内部の運動差（例：大腿部と下腿部に対応する運動成分）をより細かく反映できるため、認証精度の向上および安定化が達成されている。

6.2.4.2 上半身および Head 部位の補助的役割

一方、上半身（Upper1・Upper2）および Head 部位は、下半身と比較して単独で支配的な重みを獲得することは少なく、全体として補助的な役割にとどまった。

しかしながら、Head 重みを完全に除外した場合と比較して、小さい重み（例： $w_{head} \approx 0.1$ ）を与えた場合に、最大認証精度がわずかに向上するケースが観察された。このことから、Head 部位は識別の主因ではないものの、姿勢や輪郭の安定性に関する情報を通じて、上半身・下半身特徴を補完する役割を果たしていると考えられる。

6.2.4.3 分割粒度の違いによる表現能力の比較

三分割構成では、上半身および下半身がそれぞれ単一部位として扱われるため、内部に存在する異なる運動特性が平均化されやすい。これに対し、五分割構成で

は、上半身・下半身をさらに分割することで、各部位が担う役割の違いを重みとして明示的に反映できる。

その結果、重み探索空間においても最適解が特定の狭い範囲に集中する傾向が見られ、単なるパラメータ増加による不安定化ではなく、より表現力の高い構造化された特徴融合が実現されていることが示された。

6.2.4.4 五分割構成の有効性と限界

以上の考察から、五分割部位融合は、

- 下半身内部の運動差を効果的に活用できる点
- 部位ごとの寄与を定量的に評価可能である点
- 三分割構成と比較して認証性能の向上および安定化が得られる点

において有効であると結論付けられる。

一方で、分割数の増加に伴い重み探索空間が拡大するため、過度な分割は探索効率や解釈性の低下を招く可能性がある。したがって、本研究では、性能向上とモデル解釈性の両立を図るため、五分割構成を現実的かつ有効な分割粒度として採用する。

6.3 部位重要性に関する考察

本節では、三分割および五分割部位融合実験の結果を総合し、歩容認証における

各身体部位の重要性について考察する。特に、各部位が識別性能に与える影響を、運動特性および視点依存性の観点から整理する。

6.3.1 下半身部位の高い識別寄与

すべての実験結果に共通して、下半身に対応する部位 (Lower, Lower1, Lower2) が最も高い識別寄与を示した。これは、歩行動作における脚部の周期的運動が、個人固有の運動パターンを強く反映するためである。

また、下半身は視点変化に対して比較的安定した輪郭変化を示すことから、多視点条件下においても識別性能の低下が抑制される傾向が見られた。

この特性は、三分割構成および五分割構成の双方において一貫して観察されており、下半身部位が歩容認証における支配的要素であることを示している。

6.3.2 上半身部位の中程度の寄与と補完性

上半身部位 (Upper, Upper1, Upper2) は、下半身と比較すると単独での識別性能はやや低いものの、融合時には安定した補助的効果を示した。特に、五分割構成においては、上半身内部を分割することで、腕振りや体幹姿勢といった異なる運動成分が分離され、重みとして適切に反映されている。

この結果は、上半身部位が主識別要因ではないものの、下半身特徴を補完し、全体の識別安定性を高める役割を担っていることを示唆している。

6.3.3 Head 部位の限定的かつ補助的役割

Head 部位は、すべての実験において比較的小さい重みが付与される傾向にあり、識別性能への直接的な寄与は限定的であった。これは、Head 領域に含まれる情報が、歩行周期に伴う動的特徴をほとんど含まないためであると考えられる。

一方、Head 重みを完全に除外した場合と比較して、小さい重みを付与した場合に認証性能がわずかに向上するケースが見られた。この結果から、Head 部位は姿勢の安定性や輪郭位置の基準情報として機能し、他部位の特徴表現を補助する役割を果たしていると解釈できる。

6.3.4 部位重要性の階層構造

以上の考察から、本研究における部位重要性は、

1. 下半身部位（主識別要因）
2. 上半身部位（補完的要因）
3. Head 部位（補助的要因）

という階層構造を有していると整理できる。

この階層性は、三分割および五分割構成の双方において一貫して観察されており、部位分割に基づく特徴融合が、歩容認証における身体運動の本質的構造を反

映していることを示している。

6.3.5 本章のまとめ

本節では、複数の分割構成および重み探索結果を統合的に分析することで、歩容認証における各身体部位の重要性を明らかにした。これにより、単なる精度比較に留まらず、どの部位が、なぜ識別に寄与するのかを定量的かつ構造的に説明可能であることを示した。

第7章 結論

本研究では、シルエット画像に基づく歩容認証において、人体部位の分割粒度および部位別特徴融合が認証性能に与える影響について体系的に検討した。特に、三分割および五分割という異なる分割構成を用い、各身体部位の重要性および重み配分の特性を、視点依存性の観点から定量的に分析することを目的とした。

7.1 研究のまとめ

本研究では、二値化された人物シルエットから抽出された動作シーケンスを入力とし、人体を縦方向に分割した部位別シルエット画像を生成した。

三分割構成では、人体を Head・上半身 (Upper)・下半身 (Lower) の三部位に分割し、各部位単独および重み付き融合による認証性能を評価した。

さらに五分割構成では、上半身および下半身をそれぞれ二分割(Upper1・Upper2, Lower1・Lower2)することで、より細粒度な部位特徴を抽出し、重み探索および断面分析を通じて性能変化を検討した。

その結果、三分割および五分割のいずれの構成においても、最適な重み配分は視点ごとに異なった。一方で、視点が変化しても、各身体部位の相対的重要性の傾向は一貫して維持された。

7.2 主な結論

本研究から得られた主な結論を以下にまとめる。

1. 身体部位に着目した分割分析の有効性が確認された

三分割および五分割構成に基づく部位別特徴分析により、歩容認証における各身体部位の識別寄与度を定量的に評価できることが示された。本結果は、身体部位分割に基づく歩容特徴解析手法の有効性を実証するものである。

2. 下半身部位は歩容認証における最も重要な識別要素である

すべての視点および分割構成において、下半身部位は最も高い重みを獲得し、識別性能への支配的寄与を示した。これは、脚部の周期的運動が個人差を強く反映する主要特徴であることを示唆する。

3. 上半身部位は視点依存的に補完的役割を果たす

上半身部位は、下半身ほど支配的ではないものの、多くの視点において一定の寄

与を示し、認証性能の安定化に寄与した。特に斜め視点および側面視点において寄与度の変動が大きく、視点依存的な特徴を有する部位であった。

4. 頭部部位は限定的ながら補助的情報源として有効である

頭部部位は全体として最も低い重みを示したが、一部の視点条件において性能向上に寄与する補助的特徴として機能した。

5. 分割粒度の細分化は識別表現力と安定性を向上させる

五分割構成は三分割構成と比較して、部位内部の寄与差をより詳細に表現でき、視点変化に対する性能の安定化および最大認証精度の向上を実現した。特に、下半身を細分化することで脚部内部の異なる運動特性を効果的に分離可能であることが示された。

7.3 本研究の貢献

本研究の主な貢献は以下の三点に整理できる。

- 三分割および五分割という異なる分割粒度を用い、人体部位構成と歩容認証性能との関係を視点依存性の観点から体系的に分析した点
- 視点別重み探索および断面分析を通じて、最適重み配分が視点によって変化する一方で、部位重要性の相対関係が安定していることを定量的に示した点
- 単なる精度比較に留まらず、歩行動作の運動特性に基づく解釈可能な知

見を提示し、部位指向型歩容認証モデル設計への指針を与えた点

これらの成果は、今後の歩容認証における視点適応型特徴融合や、効率的な部位重み設計に向けた基礎的知見として有用である。

7.4 今後の課題

今後の課題として、以下の点が挙げられる。本研究では固定比率による部位分割を採用したが、関節推定などを用いた動的分割手法との比較検討が必要である。

また、本研究は NM 条件下での評価に限定しているため、荷物携行や衣服変化などの条件に対する頑健性の検証も今後の重要な課題である。さらに、非線形融合や学習可能な重み推定機構を導入することで、より高度な部位融合手法への拡張が期待される。

参考文献

- H.Fan, Z. Cao, Y. Jiang, Q. Ye, and C. Zhang, "**GaitPart: Temporal Part-Based Model for Gait Recognition**," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 14225–14233, 2020.
- [2] H. Chao, K. Wang, Y. He, J. Zhang, and J. Feng, "**GaitSet: Regarding Gait as a Set for Cross-View Gait Recognition**," *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI)*, vol. 33, no. 01, pp. 8126–8133, 2019.
- [3] Y. Hou, Z. Li, Y. Cao, and J. Zhang, "**Temporally Deformable Convolution for Gait Recognition**," *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 13357–13366, 2021.
- [4] Z. Li, Y. Hou, J. Zhang, and J. Feng, "**Three-Dimensional Human Model-Guided View Morphing for Clothed Gait Silhouettes**," *IEEE Transactions on Image Processing*, vol. 28, no. 8, pp. 3789–3801, 2019.
- [5] Xiling Shi, Wenqiang Zhao, Huandou Pei, Hongru Zhai, Yongxia Gao, "**Research on Gait Recognition Based on GaitSet and Multimodal Fusion**," *IEEE ACCESS*.2025.3533571, 20017 - 20024 ,24 January 2025

[6]Y. Zhang, H. Wang, and X. Li,“**CMGait: Enhancing Cross-Modality Gait Recognition between LiDAR and RGB through Contrastive Identity-Consistent Feature Aggregation**,”*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023.

[7]Y. Wang, L. Wang, and J. Zhang,“**HorGait: Advancing Gait Recognition with Efficient High-Order Spatial Interactions in LiDAR Point Clouds**,”*Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*,2023.

[8]M. Chakraborty, C. Chandan, B. Mukhopadhyay, S. Anchal, and S. Kar,“**VibeGait: Enhancing Structural-Vibration-Based Gait Recognition Using Vision**,”*IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2025.

[9]情報処理学会,「歩容認証に関する研究動向」,*情報処理学会論文誌*