

# 令和 3 年度 博士論文

Development and evaluation of a gait feedback training system  
considering individual differences using machine learning

(機械学習による身体的個人差を考慮した  
歩容フィードバック訓練システムの開発と評価)

指導教員 綿貫 啓一 教授

2021 年 9 月

埼玉大学大学院 理工学研究科 博士後期課程  
理工学専攻 人間支援・生産科学コース

18DH002 大澤 優輔

## 要旨

超高齢社会では、QOL 向上のために歩容訓練が重要である。介護施設では理学療法士の主観的歩容分析に基づく指導による歩容訓練が行われる。この利点の一つとして、訓練者個人に適した指導が可能であることが挙げられる。一方、欠点として歩容分析と指導には専門的な知識と経験が必要であること、指導内容が理学療法士によって異なることが挙げられる。要介護になる要因の一つに転倒・骨折が含まれることからアクティブシニアに対しても歩容訓練は必要であり、理学療法士によらない歩容訓練手法が必要である。

この課題に対して、歩容を表す情報（歩容データ）を取得し、リアルタイムに測定値と目標値を訓練者にフィードバックする訓練手法が多数提案されている。しかし、先行研究の多くは片麻痺患者を対象としており、片麻痺患者に対して個人ごとに目標値を設定することは容易である。これに対し、要介護者やアクティブシニアの歩行時の転倒の原因は、筋力低下や関節可動性の低下も含まれ、部位や程度には個人差が存在する。そのため、調整すべき身体部位や調整量は訓練者毎で異なり、個人に適切な目標が必要である。最も簡単な方法として、若年者などの理想的歩容を示す群における多変量歩容データの各代表値を目標値とする方法が考えられる。しかし、高齢者のような筋力低下や関節可動性低下を有する訓練者が若年者群の歩容を模倣することは、訓練者にとって無理のある歩容であり、過度な調整である。このように、従来の手法では、訓練者個人に適した歩容訓練を行うことができない。

本研究では、筋力低下や関節可動性の低下を伴う高齢者を訓練対象とし、理学療法士としての知識や経験を必要とせず、訓練者個人に合わせた歩容訓練が可能な、身体的個人差を考慮した歩容フィードバック訓練システムを開発することを目的とした。ただし、高齢者の歩行中の転倒の原因は多くが「つまずき」であることから、本研究において非理想的歩容を「つまずきやすい歩容」、理想的歩容を「つまずきにくい歩容」とした。

上述したように「つまずきにくい歩容」群の“値”を目標値とするべきではないが、加齢に伴ってつまずきが増加することから、同群の“特徴”を参考に目標値を設定することで適切な歩容訓練が可能であると期待できる。データに含まれる特徴を抽出する方法として機械学習がある。特に多チャンネル深層畳み込みニューラルネットワーク（MC-DCNN）

は、多変量データに対して変量毎に設定された畳み込み層とプーリング層により、各変量の局所領域に含まれる特徴を学習・抽出し、かつその特徴の行列内位置に対するロバスト性を得る。また、全結合層によりこれらの特徴間の関係性を学習する。多変量歩容データは歩容変量と時系列で表される行列であることから、多変量歩容データを入力とし、MC-DCNN を用いて「つまずきにくい歩容」と「つまずきやすい歩容」を分類するモデルを構築することで、歩容分類モデルは歩容変量間あるいは時系列的な特徴を学習すると考えられる。本研究では、2つの機械学習モデルが学習した特徴を可視化する手法を基にして、「つまずき」に関係する特徴を参考にした歩容調整内容提示手法を提案した。

まず、学習に用いるデータセットが必要であるため、筋力負荷と関節可動性低下を再現した「制限歩行」時の多変量歩容データ（関節角度と床反力）と拇指床間距離を測定した。そして、拇指床間距離を動的時間短縮法を用いた k-最近傍クラスタリングによってクラスタリングし、結果を基に多変量歩容データを「つまずきにくい歩容」と「つまずきやすい歩容」にラベル付けした。また、運動学的観点から、ラベル付けの妥当性を確認した。

Gradient-weighted Class Activation Mapping (Grad-CAM) は、任意の行列をモデルに入力した際の特徴マップの出力に対する重要性和特徴マップの出力を乗じることで、入力に含まれる出力に対する影響度が大きい箇所を可視化する手法である。多変量歩容データと MC-DCNN 歩容分類モデルに適用することで、「つまずき」に影響を及ぼす身体部位と歩行位相を提示可能であると考えられる。本研究では、取得したデータセットを用いて高精度な MC-DCNN 歩容分類モデルを構築し、Grad-CAM を歩容分類モデルに適用することによる歩容調整内容提示手法提案し、その妥当性と個人に対する適応性を運動学的観点から確認した。

前述の手法では具体的な目標値を設定しておらず、訓練者は試行錯誤的に調整する必要があった。そこで、多変量歩容データと MC-DCNN 歩容分類モデルに対してモデルの出力の活性を増加 (Activation maximization) させることによる目標多変量歩容データ生成手法を提案した。ただし、一般的な Activation maximization では、歩行運動として不可能・不自然な運動が生成される問題があるため、一度の活性化におけるデータの調整量に対して制約を設ける手法を提案し、その妥当性と個人に対する適応性を運動学的観点から確認した。

最後に、目標多変量歩容データ生成手法を実装した多変量歩容フィードバック訓練システムを構築し、このシステムを用いた一回の歩容訓練による「つまずき」に対する即時訓練効果を、拇指床間距離および多変量歩容データへの影響から確認した。

本学位論文の成果により、歩容に含まれる「つまずき」に関する特徴を参考にすることによる、身体的個人差を考慮した歩容調整内容の提示が可能であり、この手法を実装した歩容フィードバック訓練システムの即時訓練効果および個人に対する適用性を確認した。これらの手法によって、理学療法士の専門的な知識と経験を必要とせず、訓練者の身体的個人差を考慮した歩容訓練が可能であると結論付ける。

# 目次

第1章 緒論	7
1.1 節 研究の背景	7
1.2 節 研究の目的	8
1.3 節 本論文の構成	8
第2章 関節と歩容	10
2.1 節 関節の動き	10
2.1.1 項 関節の動きの表し方	
2.1.2 項 下肢関節および体幹の運動	
2.2 節 歩行周期と歩行位相	15
2.2.1 項 初期接地 (Initial contact: IC)	
2.2.2 項 荷重応答期 (Loading response: LR)	
2.2.3 項 立脚中期 (Mid stance: MSt)	
2.2.4 項 立脚終期 (Terminal stance: TSt)	
2.2.5 項 前遊脚期 (Pre-swing: PSw)	
2.2.6 項 遊脚初期 (Initial swing: ISw)	
2.2.7 項 遊脚中期 (Mid swing: MSw)	
2.2.8 項 遊脚終期 (Terminal swing: TSt)	
2.3 節 歩容の評価指標	21
2.3.1 項 空間的・時間的指標 (temporal-spatial parameter of gait)	
2.3.2 項 運動学的指標 (kinematic parameters of gait)	
2.3.3 項 運動力学的指標 (kinetic parameters of gait)	
2.3.4 項 生理的指標 (physiological parameters of gait)	
第3章 歩行訓練の先行研究と課題	26
3.1 節 歩容フィードバック訓練手法に関する先行研究	26
3.2 節 従来の歩容フィードバック訓練における課題	29
第4章 機械学習の基礎知識	30
4.1 節 教師なし学習 (Unsupervised learning)	30
4.1.1 項 クラスタリング (Clustering)	
4.1.2 項 次元削減 (Dimensionality reduction)	

4.2 節	教師あり学習 (Supervised learning)	32
4.2.1 項	分類問題 (Supervised learning)	
4.2.2 項	回帰問題 (Regression)	
4.3 節	強化学習 (Reinforcement learning)	32
4.4 節	代表的な機械学習手法と要素	34
4.4.1 項	k-means 法	
4.4.2 項	動的時間短縮法 (Dynamic time warping: DTW)	
4.4.3 項	k-shape 法	
4.4.4 項	クラスタ数の決定手法：エルボー法 (Elbow method)	
4.4.5 項	ニューラルネットワーク (Neural Network: NN)	
4.4.6 項	畳み込みニューラルネットワーク (Convolutional neural network: CNN)	
4.4.7 項	CNN の時系列データへの応用	
4.5 節	ニューラルネットワークモデルの評価手法	45
4.5.1 項	ホールドアウト法 (Hold-out method)	
4.5.2 項	k-分割交差検証法 (Cross validation method)	
4.5.3 項	リーブワンアウト法 (Leave-one-out method)	
4.6 節	機械学習の歩行解析への応用研究	47
第 5 章	提案手法の概要	48
5.1 節	歩容変量測定機器	49
5.2 節	本研究における理想的歩容と非理想的歩容の定義	51
5.3 節	訓練者の多変量歩容データの取得	52
5.4 節	リアルタイムな理想的歩容と非理想的歩容の個人差を考慮した分類	53
5.5 節	特徴を参考にした歩容調整内容の可視化	54
第 6 章	多変量歩容データセットの構築	55
6.1 節	多変量歩容データを構成する歩容変量の決定	55
6.2 節	多変量歩容データ測定実験	55
6.2.1 項	実験条件	
6.2.2 項	データの前処理と多変量歩容データの生成	
6.3 節	つまずき易さに関する歩容のラベル付け	59
6.4 節	特徴可視化結果と考察	62

第7章	拇指床間距離を決定する特徴可視化による歩容調整内容提示手法	63
7.1節	拇指床間距離を決定する特徴の可視化手法	63
7.2節	歩容分類モデルの構築と学習結果	65
7.3節	つまずきに関する歩容特徴可視化結果	66
7.4節	考察	70
7.4.1項	歩容分類モデルによるつまずきやすさに関する歩容分類の妥当性	
7.4.2項	歩容特徴可視化の歩容訓練への応用の有用性	
7.4.3項	歩容特徴可視化手法の限界	
第8章	身体的個人差を考慮した目標多変量歩容データの生成	73
8.1節	身体的個人差を考慮した目標多変量歩容データの生成手法	73
8.2節	目標多変量歩容データ生成のための歩容分類モデルの構築と学習結果	74
8.3節	つまずきに関する歩容の特徴を基にしたつまずきにくい歩容の生成	76
8.4節	目標多変量歩容データの生成手法に関する考察	82
8.4.1項	MC-DCNNによるつまずきに関する歩容の学習結果	
8.4.2項	目標多変量歩容データの生成による歩容訓練の有用性と課題	
8.5節	制約付き目標多変量歩容データの生成手法	84
8.6節	制約付き目標多変量歩容データの生成	86
8.7節	調整量に対する制約の有効性に関する考察	89
第9章	身体的個人差を考慮した目標歩容生成による歩容訓練の即時効果	90
9.1節	歩容訓練システムの構成と歩容訓練手順	90
9.2節	実験条件	92
9.3節	実験結果	93
9.4節	つまずきに関する訓練効果と個人差を考慮した歩容調整に関する考察	95
第10章	結論	96
10.1節	本研究で得られた成果	96
10.2節	課題と展望	97
謝辞		98
参考文献		99

# 第1章 緒論

## 1.1 節 研究の背景

超高齢社会である日本において、要介護者の増加が問題となっており、健康寿命の延長や生活の質の向上が緊急の課題である。日本の厚生労働省の調査によると、2016年における65歳以上の要介護者の介護が必要になった原因のうち、転倒・骨折が全体の12.5%、高齢による衰弱が13.8%、関節疾患が10.2%であり、脳卒中、認知症に次いで高いことが報告されている（図 1.1）[1]。また、原因の第一位である脳卒中は後遺症として片麻痺が残る。高齢による衰弱や関節疾患、片麻痺は歩行に障害をもたらし、転倒は歩行障害による結果である。したがって、要介護者、アクティブシニア共に歩容訓練が必要となる。実際に介護施設などの理学療法現場では、理学療法士の指導・監視のもと、歩行器や杖、手すりを用いた歩容訓練が行われている。指導は理学療法士による主観的な観察に基づいて行われるため、訓練者個人に適した歩容調整内容を提示可能である。しかし、指導には歩容に関する専門的な知識と経験が必要であるとともに、理学療法士間で指導内容に差異が生まれる可能性がある。

これらの問題から、近年では歩容を表す情報を取得し、訓練者に実測値と目標値をリアルタイムに提示する歩容フィードバック訓練手法が研究、開発されている。また、このような運動情報フィードバック訓練は、理学療法士の指導による訓練よりも改善効果が大きく、その効果が長期的に維持されることが知られている。しかし、これらの研究の多くは片麻痺を伴う脳卒中患者を対象としている。片麻痺は様々な歩容を表す指標（以後、歩容変量）において麻痺側と健側のバランスが悪くなることが知られていることから、訓練者は麻痺側の歩容変量を、健側を目標値として調整すればよい。また、多くの先行研究では、訓練の対象とする歩容変量を一つに限定している。しかし、要介護者になった原因のうち、高齢による衰弱や関節疾患、あるいは転倒は個人によって個人によって障害が起きている箇所や程度が異なる。このような訓練者に対して歩容訓練を行う場合、数多く存在する歩容変量の中から、調整すべき変量や程度を示す目標歩容の設定が重要となる。目標歩容を設定する方法として、若年健常者の各歩容変量の代表値（例えば平均値）が考えられる。しかし、訓練者間の身体的個人差（例えば関節可動域や筋力）が存在するため、代表値は訓練者にとって必ずしも最適値ではない。例えば、筋力が強く関節可動域の大きい健常者の歩容変量の値を、筋力が弱く関節可動域の小さい訓練者が再現することは、訓練者にとって無理がある。




Fig.1.1 Causes of need for nursing care for persons aged 65 and older.

## 1.2 節 研究の目的

前述の問題から、歩容情報フィードバック訓練手法により、アクティブシニアのように身体的個人差を多く有する人を対象に歩容訓練をする場合、訓練者個人の身体的個人差を考慮し、複数の歩容変量に対して健常若年者のような理想的歩容を示す人の「特徴」を満たす目標歩容を設定する必要がある。データのパターンや特徴を学習する手法として機械学習がある。機械学習技術を用いて理想的歩容と非理想的歩容に含まれる特徴を学習し、訓練者がその特徴を参考に歩容を調整することで、身体的個人差を考慮した歩容訓練を行うことができると期待できる。

本研究の目的は、身体的個人差を考慮した歩容フィードバック訓練システムの開発することである。訓練の対象となる歩容障害は、筋力低下や関節疾患の結果であり、転倒や骨折の原因の一つである「つまずき」とする。まず、身体的個人差を考慮した歩容調整内容の提示手法、目標歩容の設定手法を提案し、その訓練への有用性を検討する。そして、提案手法を実装した歩容フィードバック訓練システムを構築する。最後に、身体的個人差を考慮した歩容フィードバック訓練システムの即時訓練効果を評価する。

## 1.3 節 本論文の構成

第2章で本論文を理解するうえで必要となる関節の運動と歩容に関する知識について述べる。第3章では、近年に開発されている歩容フィードバック訓練手法を紹介し、その問題点について議論する。第4章では、本研究で用いる機械学習手法に関する知識について述べる。そして第5章で、本研究で提案する身体的個人差を考慮した歩容フィードバック訓練システムの概要について述べる。第6章では、つまずきやすさに関する歩容特徴の学習に用いるための、多変量歩容データの取得と歩容のラベル付けについて議論する。また第7章で、歩容分類の根拠となる特徴箇所の可視化による歩容調整内容提示手法について



議論し，第 8 章で訓練者の歩容を基に理想的な歩容の特徴を活性化させた目標歩容設定手法について議論する．第 9 章では，特徴活性による目標歩容設定手法を用いた歩容フィードバック訓練システムの開発と歩容訓練の即時効果について議論する．そして第 10 章では，本研究の結論を述べる．

## 第2章 関節と歩行

本章では、本論文で重要となる関節の運動と歩行に関する一般的な考え方や定義について述べる。

### 2.1 節 関節の動き[2][3]

#### 2.1.1 項 関節の動きの表し方

関節の運動や肢位を表現するためには、共通の用語が必要である。本研究では、以下に示される関節運動の表現方法を用いる。これらの表現方法は日本整形外科学会と日本リハビリテーション医学会が制定する関節可動域表示と測定法においても用いられている。

- ・ 屈曲（flexion）と伸展（extension）

屈曲は矢状面上の動きで、体節同士が近づき、体節間の角度が小さくなるような運動である。伸展は、屈曲とは逆の動きであり、体節同士が遠ざかり、体節間の角度が大きくなるような運動である。ただし、肩関節、頸部、体幹に関しては前方への運動が屈曲、後方への運動が伸展である。また、手関節、手指、足関節、足指に関しては、手掌または足底への運動が屈曲、手背または足背への運動が伸展である。一般的に、足関節の屈曲運動を底屈（plantar flexion）、伸展運動を背屈（dorsiflexion）という。以後、足関節の伸展運動に関しては底屈・背屈で表記する。

- ・ 外転（abduction）と内転（adduction）

外転は前額面上の動きで、体節が身体の中心線から遠ざかる運動である。ただし、肩関節における上肢の外転では、90° を過ぎると身体の中心線に近づくようになる。指については、中指を手の長軸から離れる動きを外転という。内転は、外転と逆の動きであり、体節が身体の中心線に近づく運動である。

- ・ 外旋（external rotation）と内旋（internal rotation）

外旋は水平面上の動きであり、開始肢位での前面が外側へ向く運動である。内旋は、外旋と逆の動きであり、前面が内側に向く運動である。ただし、前腕に関しては、外旋に該当する運動を回外（supination）、内旋に該当する運動を回内（pronation）という。以後、これらを総称した運動を回旋と表記する。

- ・ 分回し（circumduction）

分回しは体節が円錐形を描くような運動である。このとき、円錐形の先端は関節であり、底部は体節の末梢である。分回しは2軸性あるいは多軸関節で起こり、複数の運動が組み合わさることによって起こる。ただし、分回しには回旋は含まれない。

- ・外がえし (eversion) と内がえし (inversion)

外がえしは、足関節の運動であり、足底が外方を向く運動である。これは、足関節の回内と外転、背屈の複合した運動である。内がえしは、測定が内方を向く運動であり、足関節の回外と内転、底屈の複合した運動である。

### 2.1.2 項 下肢関節および体幹の運動

本項では、各関節（特に下肢関節と体幹）の動きと関節可動域表示における参考可動域角度について述べる。関節可動域表示では Neutral Zero Method を採用しているの、Neutral Zero Starting Position が基本肢位であり、概ね解剖学的肢位と一致する。ただし、肩関節水平屈曲・伸展については肩関節が移転  $90^\circ$  の肢位、肩関節外旋・内旋については肩関節外転  $0^\circ$  で肘関節  $90^\circ$  屈曲位、前腕の回外・回内については手掌面が矢状面にある肢位、股関節外旋・内旋については股関節屈曲  $90^\circ$  で膝関節屈曲  $90^\circ$  の肢位をそれぞれ基本肢位としている。

- ・股関節 (hip joint)

股関節は寛骨臼と大腿骨頭との間に作られる臼上関節（球関節の一種）である。運動軸は多軸性であり、屈曲・伸展、内転・外転、内旋・外旋と分回し運動が可能である。参考可動域角度は基本肢位を  $0^\circ$  として、屈曲が  $125^\circ$ 、伸展が  $15^\circ$  である。また、外転が  $45^\circ$  であり、内転が  $20^\circ$  である。さらに、外旋・内旋ともに  $45^\circ$  である。運動の様子を図 2.1 に示す。




Fig.2.1 Hip joint motion (Reference from [2]).

- ・膝関節 (knee joint)

膝関節は脛骨と大腿骨、膝蓋骨と大腿骨の二つの関節の複合体であり、らせん関節（1軸性関節の一種）である。膝関節は屈曲・伸展と外旋・内旋運動を行う。ただし、随意的な外旋・内旋は、膝関節が完全伸展位では不可能であり、屈曲位で靭帯に緊張がないときにおこる。また、膝関節を伸展して、完全伸展位になる直前あるいは完全伸展位から屈曲を始める時期に、大腿骨と脛骨の間にわずかに外旋・内旋運動がおこる。これは終末強制

回旋運動といい、不随意におこる運動である。参考可動域角度は基本肢位を  $0^{\circ}$  として、屈曲が  $130^{\circ}$ ，伸展が  $0^{\circ}$  である。運動の様子を図 2.2 に示す。




Fig.2.2 Knee joint motion (Reference from [2]).

#### ・足の関節 (joints of foot)

足は、7つの足根骨、5つの中足骨、14の指骨からなり、全体重を支持する。足部の関節には、距腿関節、足根間関節（距骨下関節、踵立法関節、楔立法関節、距踵舟関節、楔舟関節）、足根中足関節、中足間関節、中足趾節関節、趾節間関節がある。

##### (a) 距腿関節 (ankle joint)

距腿関節は、脛骨の下関節面と内果および腓骨外果を関節窩、距骨上面の滑車を関節頭とする、らせん関節（蝶番関節）である。距腿関節は底屈・背屈が可能である。また、底屈位では関節の遊びがあり、わずかに内転・外転が可能であるが、背屈位では関節窩が関節頭を固く挟み込むため、内転・外転はできない。

##### (b) 距骨下関節 (subtalar joint)

距骨下関節は、距骨の下面と踵骨上前面との間の関節で、前距踵関節、中距踵関節、後距踵関節の3つの部分で接合する顆状関節である。距骨下関節は外転・内転と外がえし・内がえしが可能である。

##### (c) 横足根関節 (transverse tarsal joint)

横足根関節は、外側の踵立法関節と内側の距舟関節からなる。横足根関節の運動は、距舟関節が主であり、底屈・背屈、外転・内転、外がえし・内がえしが可能であるが、それらの可動域は小さい。

##### (4) 足根中足関節 (tarsometatarsal joints)

足根中足関節は、内側楔上骨と第1中足骨、中間楔上骨と第2中足骨、外側楔上骨と第3中足骨、立方骨と第4中足骨および第5中足骨との間にある関節の総称である。わずかな底屈・背屈と外転・内転が可能である。

(4) 中足間関節 (intermetatarsal joints)

中足間関節は、中足骨相互の半関節であり、足の横アーチが形成される部分である。

(5) 中足趾節関節 (metatarsophalangeal joints : MTP)

中足趾節関節は、中足骨と趾基節骨の間の球関節である。

(5) 趾節間関節 (interphalangeal joints of foot : IP)

趾節間関節には、手指と同じように PIP 関節, DIP 関節がある蝶番関節である。ただし、拇趾については IP 関節が一つのみである。底屈・背屈が可能である。

足関節という用語は解剖学用語にはないが、一般的に用いられ、距腿関節をさすことが多い。本論文では、以後、距腿関節と足根間関節、足根中足関節、中足間関節を合わせて足関節と表記する。参考可動域角度は基本肢位を  $0^{\circ}$  として、底屈が  $45^{\circ}$  , 背屈が  $20^{\circ}$  である。また、外転が  $10^{\circ}$  , 内転が  $20^{\circ}$  である。さらに、外がえしが  $20^{\circ}$  , 内がえしが  $30^{\circ}$  である。運動の様子を図 2.3 に示す。




Fig.2.3 Ankle joint motion (Reference from [2]).

また、拇趾の参考可動域角度は、基本肢位を  $0^{\circ}$  として、MTP 関節の底屈が  $35^{\circ}$  , 背屈が  $60^{\circ}$  である。また、IP 関節の底屈が  $60^{\circ}$  , 背屈が  $0^{\circ}$  である。運動の様子を図 2.4 に示す。拇趾以外の足趾の参考可動域角度は、MTP 関節の底屈が  $35^{\circ}$  , 背屈が  $40^{\circ}$  である。また、PIP 関節の底屈が  $35^{\circ}$  , 背屈が  $0^{\circ}$  である。さらに、DIP 関節の底屈が  $50^{\circ}$  , 背屈が  $0^{\circ}$  である。運動の様子を図 2.5 に示す。




Fig.2.4 Great toe motion (Reference from [2]).




Fig.2.5 Toe joint motion (Reference from [2]).

#### ・体幹 (trunk)

胴骨は、人体の体幹に属する骨であり、椎骨・肋骨・胸骨からなる。椎骨は、全体として脊柱を形成しており、環椎・軸椎・頸椎・胸椎・腰椎・仙椎・尾椎に分けられる。脊柱は、屈曲（前屈）・伸展（後屈）・側屈・回旋が可能である。

頸椎は、脊柱のうちで最も大きな運動の可動域がある。参考可動域角度は基本肢位を 0° として、屈曲が 60°，伸展が 50° である。また、左右ともに回旋が 60° であり、側屈が 50° である。運動の様子を図 2.6 に示す。




Fig.2.6 Cervical spines motion (Reference from [2]).

胸椎は、側屈・回旋とある程度の屈曲・伸展が可能であるが、胸郭という単一構造としての運動であるため、可動域は小さい。腰椎は、屈曲・伸展・側屈が可能であるが、回旋はほとんどできない。胸・腰椎部の屈筋は腹直筋・外腹斜筋・内腹斜筋である。伸筋は脊柱起立筋・短背筋群である。側屈の動筋は外腹斜筋・内腹斜筋・腰方形筋・脊柱起立筋であり、補助動筋は腹直筋・短背筋群である。回旋の動筋は、回旋方向の同側の内腹斜筋・脊柱起立筋と対側の外腹斜筋・短背筋群である。参考可動域角度は基本肢位を  $0^{\circ}$  として、屈曲が  $45^{\circ}$ 、伸展が  $30^{\circ}$  である。また、左右ともに回旋が  $40^{\circ}$  であり、側屈が  $50^{\circ}$  である。運動の様子を図 2.7 に示す。




Fig.2.7 Motion of the thoracic and lumbar spines (Reference from [2]).

## 2.2 節 歩行周期と歩行位相[4]

片側の脚の接地から同側の次の接地までを歩行周期 (walking cycle) という。ランチョ・ロス・アミーゴ国立リハビリテーションセンター (RLANRC) では表 2.1 のように歩行周期の各相について従来の用語とは異なる中立的な概念を用いた用語によって表現している。このランチョ・ロス・アミーゴ方式を用いることで、健常歩行と病的歩行のいずれも記述できるため、多くの歩行分析のためのソフトウェアでもこの表現を用いている。

歩行周期中の各相を細分化した図を図 2.8 に示す。歩行周期はまず立脚期 (stance phase) と遊脚期 (swing phase) に分けられる。立脚期とは歩行周期中の足が地面についている時期のことであり、初期接地で始まる。また、遊脚期とは歩行周期中の足が地面から離れ、振り出しにより脚が前に運ばれている時期のことであり、つま先離地に始まる。立脚期と遊脚期はさらに立脚期は 5 つ、遊脚期は 3 つの相に分けられ、それらすべてにおいて「荷重の受け継ぎ」「単脚支持」「遊脚期の脚の前方移動」の役割を果たしている。また、足底が地面について体重を支持するとき、片脚で支持する時期を単脚支持期 (single supporting period) といい、両脚で支持する時期を両脚支持期 (double supporting period) という。両脚支持期は静的な安定度が高い期間であり、歩行速度の遅い歩行では、両脚支持期の時間が長くなる。

歩行周期の測定では、速度を一定に保つ以外は制限のない自由歩行 (free walk)、普段の好みの速度による自然歩行 (natural walk, preferred walk)、トレッドミルやメトロノームな

どを利用して，速度以外に歩幅あるいは歩行率を統制する強制歩行（forced walk）などを行う．また，臨床現場では，10m 歩行テスト[5, 6, 7]や 3m 歩行テスト[8]が利用される．以下に RLANRC で表現される各歩行位相について，歩行周期中の区間と役割について述べる．

Table 2.1 Conventional term and the RLANRC method.

Conventional term	RLANRC method
Heel strike	Initial contact
Foot flat	Loading response
Mid stance	Mid stance
Heel off	Terminal stance
Toe off	End of pre-swing and beginning of initial swing
Acceleration	Part of initial swing and mid swing
Mid swing	Part of mid swing and terminal swing
Deceleration	Part of terminal swing

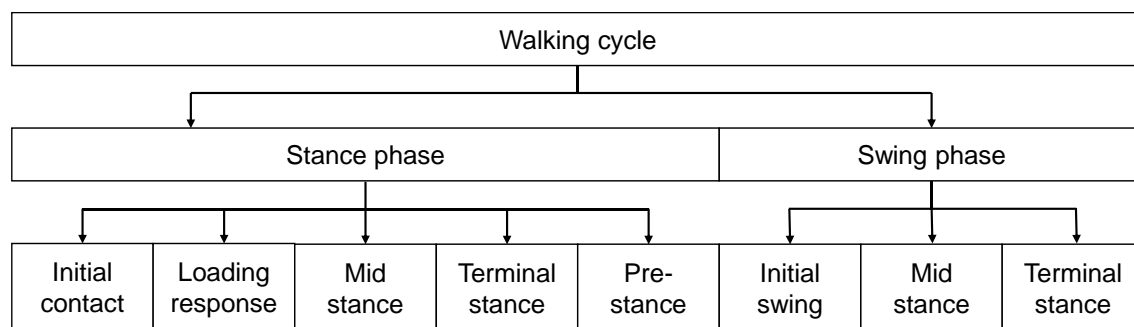


Fig.2.8 Subdivision of the gait cycle.



### 2.2.1 項 初期接地 (Initial contact: IC)

足が地面に接触する瞬間であり，歩行周期の終わりと始まりは初期接地（IC）で定義される（図 2.9）．主な役割としては立脚期をヒールロッカーで始められる脚のポジションにしておき，衝撃吸収の準備をすることである．このタイミングにおける関節のポジションが衝撃吸収の度合いを決定する．



Fig.2.9 Initial contact (Reference from [4]).

### 2.2.2 項 荷重応答期 (Loading response: LR)

初期接地で始まり，観察肢と対側の脚が地面から離れた瞬間までを荷重応答期（LR）という（図 2.10）．歩行周期の約 0~12%である．この相では体重がすばやくほぼまっすぐに伸ばされた脚に移ってくる．これは一回目の両脚支持期である．役割としては衝撃の吸収，荷重を受け継ぎつつ安定性を確保すること，および前方への動きをキープすることである．床接地と観察肢へ荷重が移行することによって生じる衝撃が，ヒールロッカーの機能によって吸収されるため，身体重量が床へ衝突しても身体は激しく揺れない．



Fig.2.10 Loading response (Reference from [4]).

### 2.2.3 項 立脚中期 (Mid stance: MSt)

観察肢と対側の脚が地面から離れた瞬間に始まり、観察肢の踵が床から離れた瞬間までを立脚中期 (MSt) という (図 2.11)。歩行周期の約 12~31%である。この相の役割は、接地している足を支点とした前方への動き、および脚と体幹の安定性の確保である。MSt の間に全荷重が観察肢にのり、支えている脚の上で身体が制御されつつ動くとともに、動的安定性が膝関節から足関節へと移る。また、LR で起こった股関節と膝関節周りの強い筋の活動は明らかに減少し、MSt の早期で休止する。このとき、下腿三頭筋の遠心性収縮が脚の安定性を制御し、アンクルロッカーによる下腿の前方への動きを可能にする。



Fig.2.11 Mid stance (Reference from [4]).

### 2.2.4 項 立脚終期 (Terminal stance: TSt)

観察肢の踵が床から離れた瞬間に始まり、観察肢と対側の脚の IC の瞬間までを立脚終期といい (図 1.12)、この相の終わりに単脚支持期が終わる。歩行周期の約 31~50%である。この相の役割としては、身体を支持足より前へ運ぶことである。足が MTP 関節を支点として動き、身体重心は前足部の支持面の直上から外れて、遠く前方へ移動する。この相で踵は床から離れ、その際、底屈筋の力強い遠心性収縮が足関節を動的に安定させることにより膝関節と股関節は受動的に安定する。TSt では、身体重心が支持面の直上より前方にあるので、身体は弧を描く自由落下のように前方へ落ち、これにより前方への動きを生じさせる。また、前方への加速は反対側の脚の前方への勢いによってサポートされる。



Fig.2.12 Terminal stance (Reference from [4]).

#### 2.2.5 項 前遊脚期 (Pre-swing: PSw)

観察肢と対側の脚の IC に始まり，観察肢の足尖が床から離れた瞬間までを前遊脚期といい（図 2.13），歩行周期中において二回目の両脚支持期である．歩行周期の約 50~62% である．観測肢は免荷され，膝関節のすばやい屈曲によって遊脚期の準備がされる．身体重量は前足部の直上から外れ，前方へ移動する．




Fig.2.13 Pre-swing (Reference from [4]).

### 2.2.6 項 遊脚初期 (Initial swing: ISw)

観察肢の足尖が床から離れた瞬間に始まり，両側の下腿が矢状面において交差した瞬間までを遊脚初期という（図 2.14）．歩行周期の約 62~75%である．この相の主な役割は床から足を離すことと，観察肢を前に運ぶことである．PSw を終えた足関節は軽度底屈位であるため，足を床から離し前方へ動かすためには足関節の背屈だけでは不十分であり，股関節と膝関節の屈曲によって初めて可能になる．



Fig.2.14 Initial swing (Reference from [4]).

### 2.2.7 項 遊脚中期 (Mid swing: MSw)

両側の下腿が矢状面で交差した瞬間に始まり，観察肢の下腿が床に対し直角になった瞬間までを遊脚中期という（図 2.15）．歩行周期の約 75~87%である．この相の主な役割としては観察肢を引き続き前へ運ぶことと，十分な床と足の間隔の確保がある．大腿は屈曲運動を続けており，膝関節は伸展し始める．足は床から離れたままであり，床と足との間隔は股関節と足関節の角度に依存する．



Fig.2.14 Mid swing (Reference from [4]).

### 2.2.8 項 遊脚終期 (Terminal swing: TSw)

観察肢の下腿が床に対して直角になった瞬間に始まり，観察肢の足が床に触れた瞬間（IC）までを遊脚終期という．歩行周期の約 87~100%である．この相は遊脚期から立脚期への移行期であり，主な役割は，観察肢を前に運ぶことの終了と立脚の準備である．



Fig.2.16 Terminal swing (Reference from [4]).

## 2.3 節 歩容の評価指標[2][3]

歩行は，重力に対して立位姿勢を保持しながら，全身を移動させる複雑な動作であり，下肢の支持力，モーメントおよび慣性力によって，動的バランスの安定性が維持されている．歩行時の姿勢と四肢の運動形態のことを一般的に歩容（gait）という．歩行研究では，様々な種類の歩容評価指標を用いて，年齢による影響や歩行障害，異常歩行の評価を行っている．本節では，先行研究でよく用いられる歩容評価指標について述べる．

### 2.3.1 項 空間的時間的指標 (temporal-spatial parameter of gait)

#### ・歩行速度

歩行速度は，歩容の基本的かつ重要な指標である．個人にはそれぞれ自由歩行（free walk：速さを一定に保つ以外は，歩行者が自由に行う歩行）時の歩行速度があり，それは各々の身体的状況における機能的バランスが最適になるように決められている．歩行速度は歩幅と単位時間当たりの歩数によって決定される．歩行速度を測定することは容易であり，かつ研究者による研究結果の多くが，歩行速度が年齢や歩行障害の影響を受けることを報告していることから，歩行速度の測定は，歩容分析では有意義である．

- ・歩幅 (step length) (図 2.17)

片側の脚が接地し，次に対側の脚が接地するまでの動作をステップ (step) という．一般的に 1 歩はステップを表す．このときの左右の踵間の距離を歩幅という．また，両踵間の横幅を歩隔 (step width, stride width) という．

- ・重複歩長，ストライド長 (stride length) (図 2.17)

片側の脚が接地し，次に同側の脚が接地するまでの動作を重複歩あるいはストライド (stride) という．このときの同側の踵間の距離を重複歩長あるいはストライド長という．




Fig.2.17 How to measure step length and stride length

- ・歩行率 (walking rate)，ケイデンス (cadence)

単位時間当たりの歩数を歩行率あるいはケイデンスという．

- ・歩行比 (walk ratio)

歩幅を歩行率で除したものを歩行比という．

- ・ストライド時間 (stride time)

1 ストライドにかかる時間をストライド時間という．

- ・足尖床間距離 (toe-to-ground distance)，拇指床間距離 (thumb-to-ground distance)

つまずきは，歩行中に足尖が地面あるいは障害物に接触することと定義されることから，つまずきやすさに関する指標として足尖床間距離が用いられる．また，脚を前方に振り出す際の拇指床間距離の極小値を一般的にフットクリアランス (foot clearance) あるいは

はトゥクリアランス (Toe clearance) という。先行研究では、足尖床間距離やフットクリアランスの測定は、第 5 中足指関節の鉛直方向の高さを指標に行われることが多い。一方で相馬ら[9]は、歩行中につまずきが起こる場合、足長の最も長い拇趾からつまづくことが予想されることから、第 1 中足指関節を指標とし、これを拇指床間距離とした。

- ・左右立脚時間比 (stance ratio)

観察肢の立脚期の時間と対側の立脚時間との比を左右立脚時間比といい、歩行の対称性を表す。通常、両側の立脚時間は同じであるが、片麻痺患者などは左右非対称になる。

### 2.3.2 項 運動学的指標 (kinematic parameters of gait)

運動学的分析は、移動減少を力の概念から離れて、動きのパターンを中心にして解析する。運動学的分析では、主に光学式 3 次元動作解析装置 (モーションキャプチャ) やゴニオメータを用い、空間における体節の動きを時間的にサンプリングする。歩行分析にしばしば用いられる運動学的指標には以下のものがある。

- ・関節角度変化

身体の各関節は、歩行周期の各相で、それぞれ伸展・屈曲、外転・内転の運動を行っている。それらの組み合わせはかなり複雑であるが、健常者の歩行には規則性のあるパターンがみられる。歩行は下肢関節 (股関節・膝関節・足関節) の運動によって行われることから、下肢関節角度は歩行評価において重要な指標である。

- ・体節の回旋

自由歩行では、各体節は、その長軸に関して回旋運動を行っている。体幹と骨盤の強調は、自由歩行時に 3 次元空間における重力に対する安定性を維持する。体幹上部と下部では逆方向の回旋運動となる。大腿骨、脛骨も長軸に関して回旋する。

- ・腕の運動

人間は歩行時に腕を振っている。歩行中における肩・腕・手の複合体の機能と意味に関する先行研究によれば、3 次元空間における腕の振りが他の体節と逆の動きをすることが確認されている[10]。また、腕を体幹に固定した状態でも、歩行時のエネルギー消費が増加しないことが確認されている[11]。このことから、Perry らは、腕の振りは歩行をサポートしうが、機械的に必要な構成要素ではないと報告している[12]。また、腕の振りの程度は、人によって大きく異なり、加えて歩行速度に強く影響を受けていることが報告されている[12][13]。

### 2.3.3 項 運動力学的指標 (kinetic parameters of gait)

運動力学的では、動きを生じさせる要因である力との関連において、歩行運動を分析する。歩行による移動は、立位姿勢を保持したまま重心を水平移動させることであり、力学的には、バランスの安定と不安定の連続である。歩行分析に用いられる運動力学的指標には以下のものがある。

- ・ 床反力 (ground reaction force)

歩行運動時、下肢に作用する力は筋力、重力、下肢の運動による慣性力および測定に加わる床反力である。作用・反作用の法則により、立脚相で測定が接地しているとき、体重および下肢の推進力・制動力として足底が地面を圧する力と同等の力が、地面から反力として作用する。これを床反力という。測定には床反力計 (force plate) が用いられる。一般的な床反力計は、歩行板の四隅に歪ゲージや圧電素子を取り付けられており、床反力の三方向分力 (前後分力、側方分力および垂直分力) の測定や作用点、作用トルクを計算により求めることができる。床反力は個人の体重による影響を受けるため、一般的に体重で正規化される。

- ・ 足底圧分布 (plantar pressure distribution)

歩行時に足底に加わる圧力分布を足底圧分布という。足底圧測定には、ガラス歩行板上に圧力によって変形するゴムマットを敷いた足圧痕測定装置、液晶を利用して等圧画像を表示する装置、特殊な圧感光紙などが利用される。

- ・ 関節モーメント (joint moment)

身体運動中において、筋力が床に作用し、その反力として床反力が発生する。このとき動作中の筋力を推定する指標として関節モーメントがある。関節モーメントは身体に加わる外力が関節を回転させようとするモーメントに対抗して身体内部の力が発生する力のモーメントである。運動中であつても床反力ベクトルと各関節の位置関係が分かれば、逆動力学計算により関節モーメントを近似的に考えることができ、関節周りでどの筋群が主に活動しているかを推定することができる。しかし、関節モーメントにより推定できる筋活動はたとえば「膝関節伸筋群のモーメント」という表現しかできず、協同筋や拮抗筋がある場合に具体的にどの筋肉が活動しているかは不明である。また、人体や関節包などの受動要素による値を分離することはできない。



#### 2.3.4 項 生理的指標 (physiological parameters of gait)

上述した空間的・時間的・運動学的・運動力学的指標のほかに、生理的指標による歩行分析方法がある。以下に歩行分析に用いられる主な生理的指標をあげる。

- ・筋活動電位 (electromyography)

筋繊維の化学的興奮に伴う電位を筋活動電位という。皮膚と皮下組織の下の筋活動を直接測定することは不可能であるが、筋活動電位によって筋機能を間接的に測定することができる。歩行時の筋活動には、歩容、歩行速度、履物、年齢、性別などによる個人差があるが、自然歩行における諸筋群の活動する時期、活動量には規則性のあるパターンが認められる。Battye らは健常者の歩行時の筋活動パターンを分析している[14]。歩行中の筋活動電位を測定することで、それぞれの筋が活動している歩行周期中の時期や最大随意収縮に対する活動の比率を知ることができる。筋活動電位の計測方法には、直接筋内に電極針を差し込むタイプと皮膚表面に電極を取り付けるタイプがある。皮膚表面に取り付けるタイプは非侵襲であり安全であるが、深部の筋や近くにある筋活動を厳密に区別することはできない。

- ・酸素消費量 (oxygen consumption)

エネルギー消費と歩行の効率を調べるために、多くの先行研究では歩行中の酸素消費量が指標として用いられる。身体運動におけるエネルギー代謝で扱われるのは化学エネルギーである。必要なエネルギーの大部分は食物として摂取された栄養物が呼吸で取り入れられた酸素と酸化反応を起こすときに発生するエネルギーである。平均的な食物摂取を行っている場合、酸素消費 1L 当たり約 4.83kcal のエネルギーが発生するため、一定時間内にある仕事を行ったときの酸素消費量を測定することで、間接的にエネルギー消費を求められる。計測には呼気ガス分析装置が用いられる。呼気ガス分析では、呼気を集めて、その容量と酸素濃度を測定し、吸気の酸素濃度との差から算出する。

## 第3章 歩行訓練の関連研究と課題

本章では、歩容フィードバック訓練手法の先行研究について述べ、先行研究において解決されていない課題について議論する。

### 3.1 節 歩容フィードバック訓練手法に関する先行研究

通常は認知することが難しい自己の生体現象を、視覚的・聴覚的・触覚的にフィードバックすることをバイオフィードバックといい、フィードバックされた情報を基に制御することを試みる訓練を続けることで、生体現象を自己制御できるようになることが報告されている。このようなフィードバック訓練はリハビリテーションの分野において応用されており、歩容を表す時間的空間的指標、運動学的指標、力学的指標、生理学的指標を測定し、歩行中にリアルタイムに訓練者にフィードバックする訓練手法が多数提案されている。また、このような運動情報フィードバック訓練手法の先行研究を分析することにより、その訓練効果を評価する報告もある[15]。Stanton らは、片麻痺患者の立位、起立、歩行運動を対象とした運動学的、力学的、生理学的指標のフィードバックに関する 22 の無作為化試験を報告した 24 論文を抽出してメタ分析を行い、フィードバック訓練は理学療法士の指導による訓練よりも改善効果が大きく、その効果が長期的に維持されることを確認した[16]。以下に歩容フィードバック訓練手法の関連研究をいくつか紹介する。また、歩容フィードバック訓練手法の関連研究における対象者、取り扱う歩容変量、目標値の設定方法、フィードバック方法をまとめた表を以下に示す(表 3.1)。そのほかの歩容フィードバック訓練システムとしては、義足歩行に着目した歩容訓練に関する研究も行われている[17]。

#### ・左右分離型トレッドミルを用いた歩行相フィードバックシステム[18]

安藤らは、片麻痺患者を対象として、トレッドミル歩行中の接地と離地を検出することで歩行相を取得し、左右脚の立脚時間を計測する歩行訓練システムを開発している(図 3.1)。このシステムでは、測定値として麻痺側脚の立脚時間、目標値として健側脚の立脚時間を設定し、訓練者に提示する。訓練者は測定値が目標値に近づくように歩容を調整する。これにより訓練者は自身の歩容の左右非対称性を緩和することが可能である。

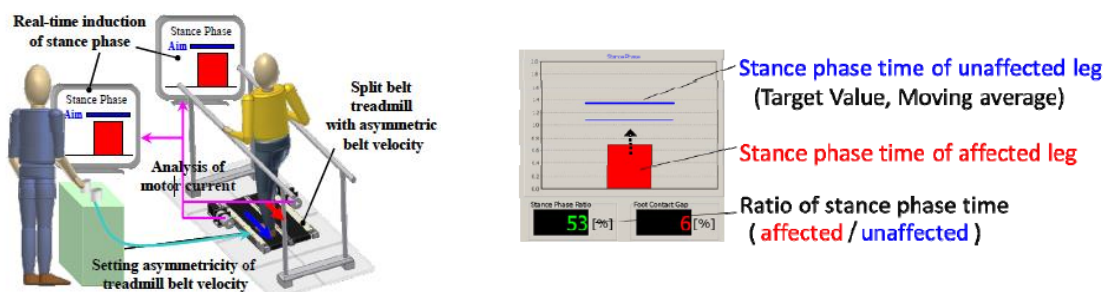


Fig.3.1 Visual Bio-Feedback System of Gait Phase in Split Belt Treadmill (Reference from [18]).

- A wearable system for gait training in subjects with Parkinson's disease [19]

Casamassima らはパーキンソン病患者を対象として、平地歩行時のケイデンス、歩幅、歩行速度、歩行の非対称性、体幹の屈曲、クリアランスを取得し、事前に臨床家が設定した特定の値を目標として歩容調整のためのタスクを計算し、音声合成アプリケーションによって生成された音声メッセージをフィードバックする歩行訓練システムを開発している (図 3.2). これにより、このシステムは歩容のリズムと大きさの改善、非対象性の低減、不安定な姿勢の修正を目的とした訓練を行う。

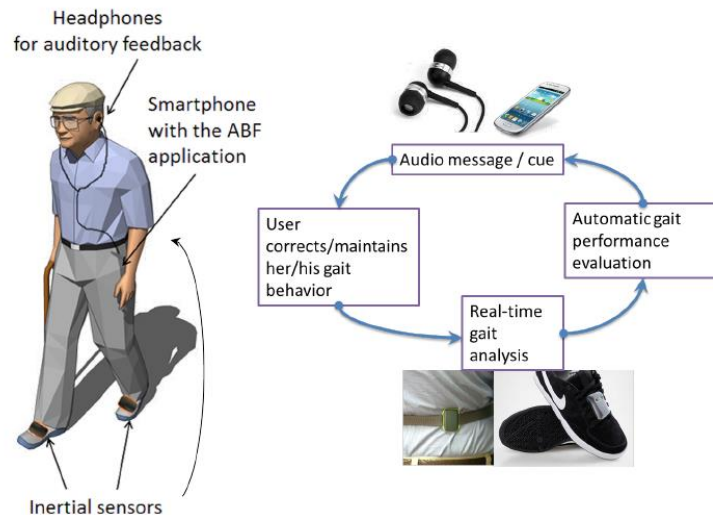


Fig.3.2 A wearable system for gait training in subjects with Parkinson's disease (Reference from [19]).

- Gait retraining using real-time feedback in patients with medial knee osteoarthritis: Feasibility and effects of a six-week gait training program [20]

Richards らは変形性膝関節症患者を対象として、トレッドミル歩行時の足関節水平面角度を取得し、訓練者に視覚的にフィードバックする歩容訓練システムを開発している。このとき、変形性膝関節症患者は歩行時の膝関節内転モーメントが大きいことから、膝関節内外転モーメントの最初のピークを 10%減少させる足関節水平面角度を算出し、これを目標値としている。




Fig.3.2 A wearable system for gait training in subjects with Parkinson's disease (Reference from [20]).

Table 3.1 Visual Bio-Feedback System of Gait Phase in Split Belt Treadmill (Adapted from

Previous study	Training subject	Handled gait variable	Target gait	Feedback method
Hirokawa et al. (1988) [21]	patients with bilateral knee disease	Step length, time of double supporting phase, walking speed	Empirically determined based on current gait	Visual, auditory
Shimada et al. (2000) [22]	Skeletal disorders	Affected foot load measured from pressure distribution	Appropriate load as ordered by physician	Auditory
Ledebt et al. (2005) [23]	Children with hemiplegic	Ground reaction force	Symmetry	Visual
Iwata et al. (2007) [24]	Hemiplegic patient	Foot contact pressures	Presentation of the paralyzed side ground state	Tactile
Banz et al. (2008) [25]	People with neurological gait disorders	Hip joint angle, knee joint angle	Trajectories pre-defined for each individual by physical therapist	Robotic, visual
Krishnamoorthy et al. (2008) [26]	Hemiplegic patient	Lower limb joint angle	Value scaled to the trainee's segment length based on the gait pattern of a healthy person	Visual
Ota et al. (2011) [27]	Hemiplegic patient	Lower limb joint angle	Value of healthy leg (Symmetry)	Robotic
Ando et al. (2011) [18]	Hemiplegic patient	Gait phase	Value of healthy leg (Symmetry)	Visual
Casamassima et al. (2014) [19]	Parkinson's disease	Cadence, step length, gait speed, gait asymmetry, trunk flexion, clearance	A specific target set by a clinician	Auditory
Tomigawa et al. (2016) [28]	Pseudo hemiplegic patient	Lower limb trajectory and gait cycle	Free walking without pseudo hemiplegia	Visual, auditory

Previous study	Training subject	Handled gait variable	Target gait	Feedback method
Fukuyama, Ikeuchi (2016) [29]	Hemiplegic patient	Ground reaction force	Symmetry	Visual, auditory
Kimura (2016) [30]	Hemiplegic patient	Ground contact of the sole	Presentation the timing of foot contact to ground	Auditory
Richards et al. (2018) [20]	Patients with medial knee osteoarthritis	Foot progression angle	Decrease the first peak of knee abduction moment by 10 %	Visual

### 3.2 節 従来の歩容フィードバック訓練における課題

表 3.1 から読み取れるように、歩容フィードバック訓練手法の関連研究では、片麻痺患者を訓練対象としているものが多い。片麻痺患者の歩容障害に関する分析は多数されており、これらのことから片麻痺歩容の特徴として様々な歩容変量の左右非対称性がある。実際に片麻痺患者を対象としたシステムでは、目標値として健側脚の値や左右対称性が目標とされており、健側脚は訓練者自身の身体部位であることから、健側脚の値を目標とすることは訓練者個人の身体的個人差を考慮しているといえる。そのため、片麻痺を対象とした歩容訓練では目標値の設定は容易である。一方、片麻痺以外の歩容障害を訓練の対象とした研究では、歩容に関する知識を有する人物によりあらかじめ設定された値を目標値としているものが多い。そのため、歩容訓練のためには専門的な知識が必要になる。知識を必要とせず目標値を設定する最も簡単な方法は、若年者などの理想的歩容を示す群の代表値（例えば平均）を用いることであるが、非理想的歩容を示す群、例えば高齢者が若年者の平均値を模倣して歩行することは身体的負荷が大きく、適切ではない。この問題から先行研究では、健常者の歩容パターンを基に訓練者のセグメント長に合わせてスケーリングした値を目標としているものがあるが、不特定多数の訓練者全員に対して各セグメント長を測定することは臨床現場での歩容訓練を考慮すると現実的ではない。このように従来の手法では、本研究で目的としている、歩容に関する専門的な知識と経験を必要とせず、訓練者個人に適切な歩容訓練を行うことはできない。よって、訓練者は理想的歩容群の“値”を目標とするのではなく、その歩容に含まれる“特徴”を満たすように歩容を調整する必要がある。

## 第4章 機械学習による特徴の学習

機械学習 (machine learning: ML) とは, 任意の種類のデータに含まれるパターン・特徴を, そのデータから自動的に学習する手法の総称であり, 多くのアルゴリズムが存在する. 機械学習は人工知能 (artificial intelligence: AI) システムを実現するための 1 つの手段である. 機械学習アルゴリズムには, 大きく分けて教師なし学習, 教師あり学習, 強化学習が存在する. ただし, 強化学習は教師なし学習に含まれるという考え方もある. これらの機械学習手法から, 行いたいタスクに応じて適した手法を選択する必要がある. 一般に, 教師なし学習はクラスタリングと次元圧縮, 教師あり学習は分類と回帰, 強化学習は機械の制御などに用いられる (図 4.1). 本章では, 代表的な機械学習アルゴリズムとそれらの重要な要素について述べる[31, 32, 33, 34, 35, 36, 37, 38].

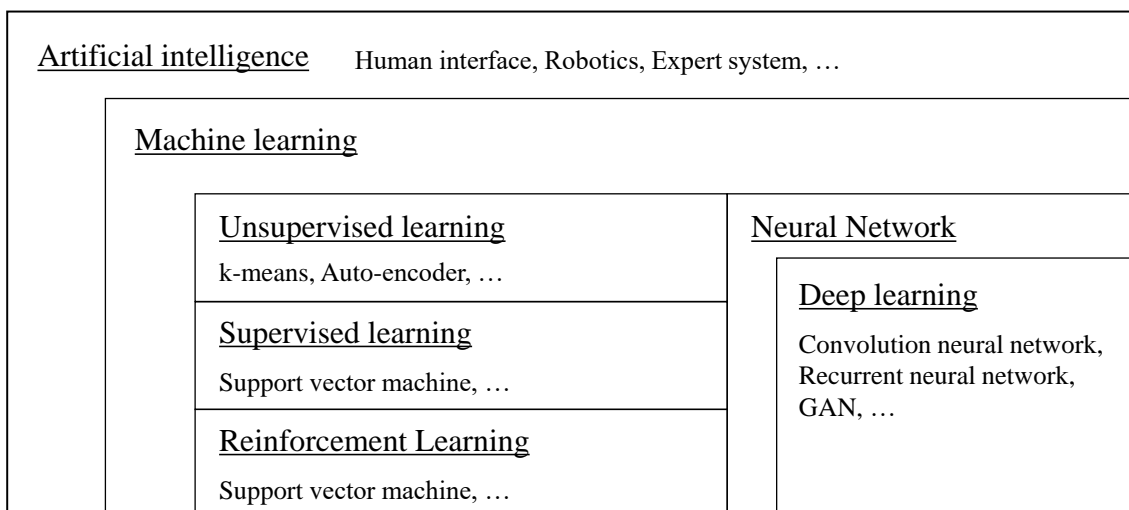


Fig. 4.1 Classification of Artificial Intelligence.

### 4.1 節 教師なし学習 (Unsupervised learning)

学習の対象となる入力データに対して, 対応する出力データ (教師) が与えられておらず, 与えられた入力データのみに基づき学習する手法を教師なし学習という. 教師なし学習では, 任意の種類のデータから本質的な構造を抽出し, 理解しやすい解釈を与えるような使い方をされることが多く, 主にクラスタリングや次元削減に用いられる.

#### 4.1.1 項 クラスタリング (Clustering)

教師データなしで, 任意の種類のデータ間の類似度あるいは非類似度を手掛かりに, それらをいくつかの塊 (クラスタ) にグループ分けする方法をクラスタリングという (図 4.2). クラスタリング手法には, 大きく分けて非階層型クラスタリングと階層型クラスタリングがある. また, 混合正規分布によるクラスタリング手法がある. クラスタリングの手法は

数多く提案されており、非階層型クラスタリングには k-means や k-means++, k-medoids, k-shape, スペクトルクラスタリング, 階層型クラスタリングには単連結法や完全連結法, 群平均法, ウォード法やニューラルネットワークの一種である自己組織化マップなどがある。




Fig. 4.2 Outline of clustering.

#### 4.1.2 項 次元削減 (Dimensionality reduction)

高次元データの情報をできるだけ保ちつつ、低い次元にマッピングすることを次元削減という (図 4.3)。低い次元に写像することで、計算効率が向上するとともに、適切にノイズを除去することができれば予測精度の向上が期待できる。次元削減手法には主成分分析や潜在意味解析, 線形判別分析などがある。




Fig. 4.3 Outline of dimensionality reduction.

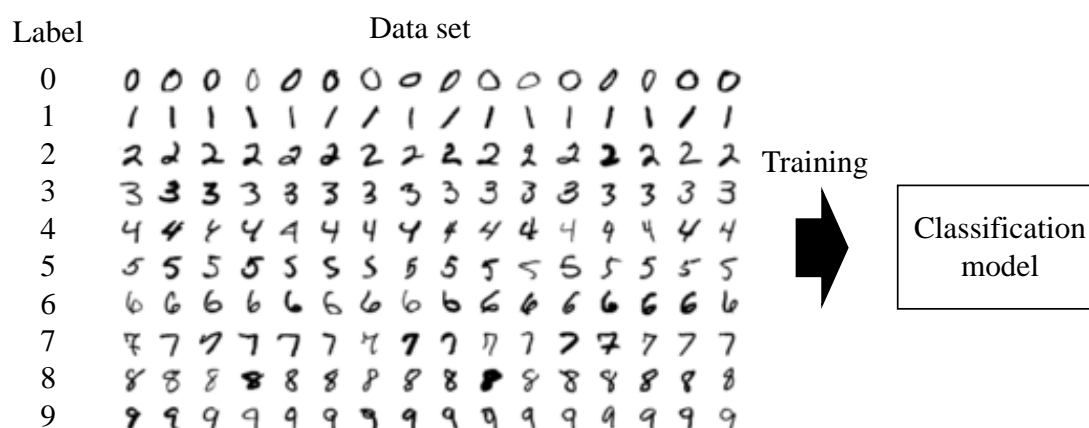
## 4.2 節 教師あり学習 (Supervised learning)

学習の対象となる入力データに対して対応する出力データ（教師）が与えられており，入力と出力の関数関係を学習する方法を教師あり学習という．教師あり学習を大きく分けると，出力が離散値の場合と連続値の場合があり，それぞれ分類問題と回帰問題（予測）に用いられる．


### 4.2.1 項 分類問題 (Classification)

分類問題では，出力データとして入力データに対応する分類クラスが与えられており，入力と出力の関係を学習して，入力データが所属するクラスを推定する分類モデルを構築する．この分類クラスは離散的な値であり，一般的にラベルと呼ばれる．分類問題には k-最近傍法やニューラルネットワーク，ランダムフォレスト，サポートベクトルマシンなどが用いられる．

分類問題の例として，手書き数字の認識があげられる（図 4.4）．0 から 9 までの手書き文字が画像データとして与えられており，画像データから対応する数字に分類したいとする．この場合，分類モデルは画像データを入力，それぞれの数字を出力として学習を行う．分類クラスが 2 つの場合を 2 値分類，3 つ以上の場合を多値分類という．



(a) Building a classification model using machine learning.



(b) Classification of handwritten numbers.

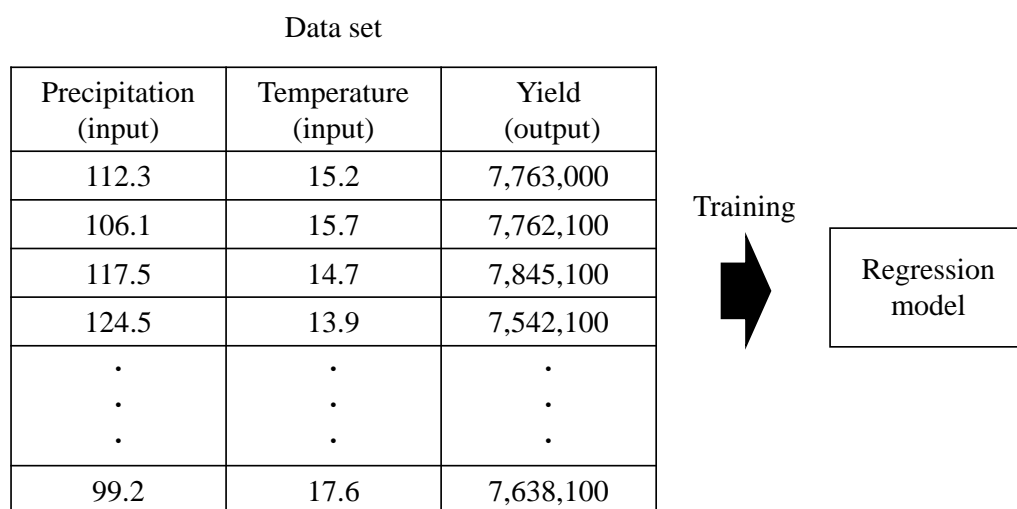
Fig. 4.4 Using machine learning for the classification problem of handwritten numbers.




#### 4.2.2 項 回帰問題 (Regression)

回帰問題では，出力データとして入力データに対応する連続的な実数値が与えられており，入力データに対する出力を精度よく予測する予測モデルを構築する．回帰問題には，最小2乗法やニューラルネットワーク，スパース学習などが用いられる．

回帰問題の例として，降雨量と気温から作物の収穫量を推定する問題が挙げられる（図4.5）．ある月の平均降雨量と平均気温を入力，作物の収穫量を出力として学習を行い，予測モデルを構築することで，それ以降は平均降雨量と平均気温のみを取得することで作物の収穫量を予測することができる．



(a) Building a regression model using machine learning.



(b) Yield prediction.

Fig. 4.4 Using machine learning for the classification problem of handwritten numbers.

#### 4.3 節 強化学習 (Reinforcement learning)

ある与えられた条件下で，設定された報酬を最大にするような行動を見つけるように学習する方法を強化学習という．強化学習では，教師あり学習のように最適な出力は与えられず，試行錯誤を通じて学習アルゴリズム自らがそれを発見する必要がある．代表的な強化学習手法として，Deep Q Network [39]などがある．

## 4.4 節 代表的な機械学習手法と要素

本節では、代表的な教師なし学習，教師あり学習手法とその重要な要素について述べる．

### 4.4.1 項 k-means 法

教師なし学習による非階層型クラスタリングの代表的な手法として k-means 法がある．k-means 法は  $d$  次元  $n$  個のベクトル  $D = \{x_1, \dots, x_n\}$ ,  $x_i \in R_d$  を，データ間の類似性を尺度に，あらかじめ定めた  $k$  個のクラスタに分類する．このベクトル間の類似性の尺度を距離尺度という．

各クラスタの代表となるベクトルの集合を  $M = \{u_1, \dots, u_k\}$  とする． $l$  番目の代表ベクトルが支配するクラスタ（ボロノイ領域）を  $M(u_l)$  とする． $i$  番目のベクトル  $x_i$  が  $M(u_l)$  に帰属するか否かを表す帰属変数  $q_{il}$  は式(4.1)のように定義される．

$$q_{il} = \begin{cases} 1 & (x_i \in M(u_l) \text{ の場合}) \\ 0 & (\text{それ以外の場合}) \end{cases} \dots\dots\dots (4.1)$$

このとき，k-means 法の評価関数は式(4.2)のように定義される．この評価関数の出力のことをクラスタ内誤差平方和（sum of squared Error: SSE）という．

$$J(q_{il}, u_l) = \sum_{i=1}^n \sum_{l=1}^K q_{il} d(x_i, u_l)^2 \dots\dots\dots (4.2)$$

ただし， $d(x_i, u_l)$  は 2 つのベクトル間の距離であり，距離尺度をユークリッド距離とする場合，式(4.3)のように表される．

$$d(x_i, u_l) = \|x_i - u_l\| \dots\dots\dots (4.3)$$

この評価関数には， $q_{il}$  と  $u_l$  に関する最適化が含まれている． $u_l$  に関する最適化は，式(4.4)に従って行う．

$$\frac{\partial J(q_{il}, u_l)}{\partial u_l} = 2 \sum_{i=1}^n q_{il} (x_i - u_l) = 0 \rightarrow u_l = \frac{\sum_{i=1}^n q_{il} x_i}{\sum_{i=1}^n q_{il}} \dots\dots\dots (4.4)$$

すなわち，各クラスタの代表ベクトルは，そのクラスタに帰属するベクトルの平均ベクトルとなる．一般的に，この平均ベクトルのことを重心あるいはセントロイドという．実際には， $q_{il}$  と  $u_l$  を同時に最適化するのは難しいので，以下のようなアルゴリズムで最適化する．ただし，この最適化アルゴリズムの収束先は初期値に依存するので，最適解に近い解を得るためには複数回，初期値を変えて実行する必要がある．

初期化：  $n$  個のベクトルをランダムに  $k$  個のクラスタに振り分け、それぞれのクラスタの重心を求め、  $u_l$  ( $l = 1, \dots, k$ ) とする。

(1)  $q_{il}$  に関する最適化を行う。つまり、  $u_l$  を固定し、帰属変数  $q_{il}$  を式(4.5)に従って決定する。

$$q_{il} = \begin{cases} 1 & (k = \operatorname{argmin}_j d(x_i, u_l)^2 \text{ の場合}) \\ 0 & (\text{それ以外の場合}) \end{cases} \quad (4.5)$$

(2)  $u_l$  に関する最適化を行う。つまり、  $q_{il}$  を固定し、重心  $u_l$  を式(4.4)に従って決定する。

(3) 評価関数の出力が収束するまで（クラスタに帰属するベクトルに変更が発生しなくなるまで）上記の処理を繰り返す。

距離尺度には、ユークリッド距離の他に、マハラノビス距離、チェビシェフ距離、方向余弦（コサイン距離）、DTW 距離などが用いられ、扱うデータの性質に応じて距離尺度を選択する必要がある。

#### 4.4.2 項 動的時間短縮法(Dynamic time warping: DTW)

時系列データを対象として教師なし学習によるクラスタリングを行う場合、以下の項目のいくつかあるいは全てについて考慮する必要がある。

- ・ スケーリングとレベルシフト
- ・ 位相シフト
- ・ 二つの時系列の長さが異なる場合
- ・ 時系列に欠測部が存在する場合
- ・ 系列の形状は似ているが、複雑さが異なる場合

これらの問題のうち位相シフトと二つの時系列の長さが異なる場合を考慮するために、k-means 法において距離尺度として動的時間短縮法（DTW）距離[40]が用いられることがある。

DTW 距離は二つの時系列の全ての点の組み合わせにおける距離に基づいて距離行列を作成したときに、距離行列の両端を結ぶワーピングパスの距離和が最小となるパスの距離和である。つまり、二つの時系列データ  $\mathbf{X}$  と  $\mathbf{Y}$  があるとき、互いの各要素の全ての組み合わせにおける距離行列は式(4.6)で求められ、距離行列の両端を結ぶワーピングパス  $\mathbf{W}$  がつくられる。このとき、DTW 距離は式(4.7)で求められる。

$$\delta(i, j) = |\mathbf{X}_i - \mathbf{Y}_j| \quad (4.6)$$

$$DTW(\mathbf{X}, \mathbf{Y}) = \min \sum_{k=1}^P \delta(\mathbf{W}_k) \quad (4.7)$$

#### 4.4.3 項 k-Shape 法

k-Shape 法[41]は時系列データのスケールリングとレベルシフトおよび位相シフトに対応するクラスタリング手法である。k-Shape 法の主な特徴として、距離尺度に Shape-based distance (SBD)を用いることと、重心ベクトルとして時系列データの形状抽出(Time-Series Shape Extraction)がある。

SBD は式(4.8), (4.9), (4.10)で定義される。

$$CC(x, y) = F^{-1}\{F(x)F(y)\} \dots\dots\dots (4.8)$$

$$NCC_c = \frac{CC(x, y)}{\sqrt{R_0(x, x) \cdot R_0(y, y)}} \dots\dots\dots (4.9)$$

$$SBD(x, y) = 1 - \max(NCC_c) \dots\dots\dots (4.10)$$

二つの時系列の相互相関 (Cross-correlation: CC) を求める。次に相互相関係列をそれぞれの時系列の自己相関の幾何平均で除して正規化された相互相関 $NCC_c$ を求め、 $NCC_c$ の最大となるインデックスとその値を求める。SBD は 0 から 2 の間の値をとり、0 に近いほど二つの時系列は類似している。

クラスタ $k$ の重心ベクトルを求めるための時系列データの形状抽出は以下の式で行われる。

$$CC(x, y) = F^{-1}\{F(x)F(y)\} \dots\dots\dots (4.11)$$

k-Shape は k-means のように反復的な手続きにより各時系列にクラスタを割り当てる。

初期化 :  $n$  個のベクトルをランダムに $k$ 個のクラスタに振り分け、それぞれのクラスの重心を求め、 $u_l$  ( $l = 1, \dots, k$ )とする。

- (1) 各時系列を各クラスタの重心ベクトルと比較し、最も近い重心ベクトルのクラスタに割り当てる。
- (2) クラスタの重心ベクトルを更新する。
- (3) 上記の処理をクラスタに帰属するベクトルに変更が発生しないか、反復回数が設定した値に達するまで繰り返す。

#### 4.4.4 項 クラスタ数の決定手法 : エルボー法 (Elbow method)

k-means 法や k-shape 法などでは、クラスタ数をあらかじめ決定する必要がある。このクラスタ数に最適解はなく、実際にはクラスタ数を変化させていき、適しているクラスタ数を自身で判断する必要がある。このとき、クラスタ数を決定する手法として、エルボー

法[42]やシルエット法などがある．本項では，エルボー法について述べる．

k-means 法や k-shape 法では，クラスタ数が十分に増加すると，SSE は減少し，一定値に落ち着く．そこで，エルボー法では，クラスタ数を増加させたときに SSE の減少が極端に小さくなるクラスタ数を最適クラスタ数として決定する．

#### 4.4.5 項 ニューラルネットワーク (Neural Network : NN)

ニューラルネットワーク (NN) とは，広義には脳の神経回路の一部を模した数理モデルのことであり，教師あり学習と教師なし学習の両方に含まれる．本項では，ニューラルネットワークを構築するにあたって重要な要素について述べる．

##### ・パーセプトロンと順伝播

パーセプトロンはニューラルネットワークの最も基本的なアルゴリズムである．パーセプトロンは図 4.6 のように複数の信号を入力として受け取り，一つの信号を出力する．このとき，入力値の列を入力層といい，出力値の列を出力層という．また，各層を構成する素子をニューロンまたはノードという．パーセプトロンの計算処理は以下の式に示される．

$$u = b + \sum_{i=1}^n x_i w_i \dots\dots\dots(4.12)$$

$$y = f(u) \dots\dots\dots(4.13)$$

$n$ 個の入力値 $x_i$ は，それぞれあらかじめ設定された定数 $w_i$ と乗算されたのちに加算される．その後，定数 $b$ を加算し，任意の関数 $f(\cdot)$ に入力することで出力 $y$ を得る．このとき， $w_i$ を重み (weight) といい， $b$ をバイアス (bias) という．また，関数 $f(\cdot)$ を活性化関数 (activation function) という．重みは各入力信号の出力に対する重要性を表し，バイアスはそのノードの発火のしやすさを表す．図 4.6 のように入力層と出力層の 2 層で構成されるパーセプトロンを単純パーセプトロンという．一般に単純パーセプトロンでは，活性化関数にステップ関数が用いられる．活性化関数にステップ関数を用いた単純パーセプトロンでは線形分離可能な 2 値分類問題を解くことができるが，欠点として線形分離不可能な問題には用いることができない．




Fig.4.6 Structure of a simple perceptron.

線形分離不可能な問題を解くために、単純パーセプトロンの入力層と出力層の間に層を複数追加する方法がある。このとき、追加された層を中間層あるいは隠れ層といい、その全体を多層パーセプトロンという（図 4.7）。また、ある層のノードが次層の全ノードに接続されている層のことを全結合層という。多層パーセプトロンでは、一般的に活性化関数にシグモイド関数などの非線形関数が用いられる。

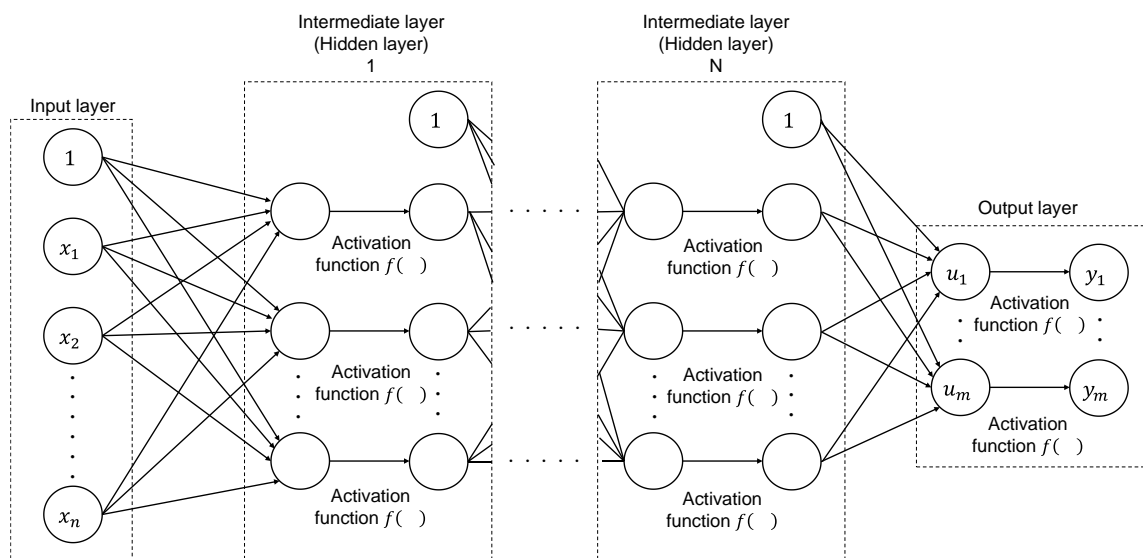


Fig.4.7 Structure of a multilayer perceptron.

上述のように出力を計算する際、各ノードで構成される層に対して1つずつ順番に計算が行われる。したがって、 $N$ 層目のノードの出力信号は、 $N-1$ 層目の各ノードで計算された出力信号を入力として計算される。このように入力から出力に向かって順番に信号が伝搬するような計算を順伝播（feed forward）といい、順伝播で計算されるネットワークを順伝播型ネットワーク（feed forward network）という。順伝播型以外の方法として、再帰型ネットワーク（Recurrent Network）などがある。

前述の方法では、重みとバイアスはあらかじめ決定する必要があるが、対象とする問題、特に線形分離不可能な問題に対して最適な重みとバイアスを手動で決定するのは不可能である。そのため、自動的に最適な重みとバイアスを学習する手法が必要となる。ニューラルネットワークとパーセプトロンは明瞭な区別がされていないが、一般的に適切な重みとバイアスを自動で学習するパーセプトロンのことをニューラルネットワークということが多い。また、ニューラルネットワークにおいて層が多層になったものを一般的に深層学習（deep learning）という。

#### ・活性化関数（activation function）

ニューラルネットワークにおいて、入力信号の総和に対して非線形変換または線形変換を行い出力する関数のことを活性化関数という。非線形な変換を行うことにより、複雑な入出力の関係に対応が可能な柔軟なモデルを作成することが可能となる。また、最終層の活性化関数は出力に整形することが容易な関数が選ばれることが多い。代表的な活性化関数の例として、シグモイド関数、 $\tanh$  関数、ReLU 関数、ソフトマックス関数について以下に述べる。また各活性化関数の入力と出力の関係を表すグラフを図 4.8 に示す。

#### (a) ステップ関数、単位ステップ関数、階段関数（step function）

ステップ関数は、主に単純パーセプトロンの活性化関数として用いられ、式(4.14)、図 4.8(a)で表される。

$$f(u) = \begin{cases} 0 & (u \leq 0) \\ 1 & (u > 0) \end{cases} \dots\dots\dots(4.14)$$

ステップ関数は入力が 0 以下の場合は 0 を出力し、0 より大きい場合は 1 を出力する。つまり、活性化関数の入力はその直前の全結合層における重み付き入力とバイアスの和であることから、全結合層の重み付き入力の総和がある閾値（バイアス）より大きい場合のノード（ニューロン）の発火を表現することができる。しかし、NN における重みとバイアスの最適化では、モデルの誤差関数の出力に対する各層各ノードの勾配を用いられるが、図 4.8(a)から分かるように、ステップ関数はほとんどの入力に対して勾配が 0 であり、微分不可能であるため、重みの更新ができない。そのため、NN ではステップ関数が用いられることは少ない。

(b) シグモイド関数, 標準シグモイド関数 (sigmoid function)

ニューラルネットワークでは, 微分不可能な活性化関数を用いた場合に重みとバイアスの更新が行えないという問題から, 全ての入力値に対して微分可能である標準シグモイド関数が利用される. シグモイド関数は中間層の活性化関数や分類問題における出力層の活性化関数に用いられることが多い. 標準シグモイド関数は式(4.15), 図 4.8(b)で表される.

$$f(u) = \frac{1}{1 + e^{-u}} \dots\dots\dots(4.15)$$

シグモイド関数は入力が小さいほど 0, 大きいほど 1 に漸近する. しかし十分に入力が小さいまたは大きい場合, 勾配が限りなく 0 に近づく. また, 勾配の最大値は 0.25 と小さい. これらのことから, 特に多層の NN では勾配消失問題を引き起こし, 学習が停滞する場合がある.

(c) tanh 関数 (tanh function)

シグモイド関数の勾配の最大値が小さいことによる学習時間の増加の問題から, 中間層の活性化関数に tanh 関数が用いられることがある. tanh 関数はシグモイド関数と同様に全ての入力に対して微分可能である. 標準的な tanh 関数は式(4.16), 図 4.8(c)で表される.

$$f(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}} \dots\dots\dots(4.16)$$

tanh 関数は入力が小さいほど-1, 大きいほど 1 に漸近する. シグモイド関数の勾配の最大値が 0.25 であるのに対し, tanh 関数の勾配の最大値は 1 と大きいため, シグモイド関数と比較して学習の停滞が生じにくいという特徴を持つ.

(d) ReLU 関数 (rectified linear unit function)

シグモイド関数や tanh 関数では勾配消失問題が発生する場合があることから, NN では中間層の活性化関数に ReLU 関数が用いられることが多い. ReLU 関数は式(4.17), 図 4.8(d)で表される.

$$f(u) = \begin{cases} 0 & (u \leq 0) \\ u & (u > 0) \end{cases} \dots\dots\dots(4.17)$$

ReLU 関数は入力が 0 以下の場合は 0 を出力, 0 より大きい場合は入力値を出力する. ただし, 上式では入力が 0 のとき微分不可能であるため, NN では便宜的に入力が 0 のときの勾配を 0 とすることが多い. ReLU 関数は入力が正のときは常に勾配が 1 であるため, 勾配消失問題が発生しにくいという特徴や計算が単純で処理が速いという特徴を持つ.



(e) ソフトマックス関数, 正規化指数関数 (softmax function)

ソフトマックス関数は主に分類問題の最終層に用いられる活性化関数である。ソフトマックス関数は式(4.18)で表される。なお  $i$  は  $i$  番目の人工ニューロンの出力,  $n$  は出力層の人工ニューロンの数を指し, 分子は入力信号の指数関数, 分母は入力信号の指数関数の和を示す。したがってソフトマックス関数の出力は 0 から 1 の値をとり, 全ての出力の和は 1 となる。入力 of 要素数を 2 とし, 一方の要素の値を 0 としたとき of 他方 of 入力要素に対する入出力 of 関係を図 4.8(e) に示す。

分類問題においてネットワーク of 出力層での人口ニューロン数は, カテゴリ数と一致する。したがって, 最終層においてソフトマックス関数を適応することにより, カテゴリ of 確率を算出することが可能となる。

$$f(u_i) = \frac{e^{u_i}}{\sum_{j=1}^n e^{u_j}} \dots\dots\dots(4.18)$$

(f) 恒等関数 (identity function)

恒等関数は主に回帰問題 of 最終層に用いられる活性化関数であり, 式(4.19)で表される。

$$f(u) = u \dots\dots\dots(4.19)$$

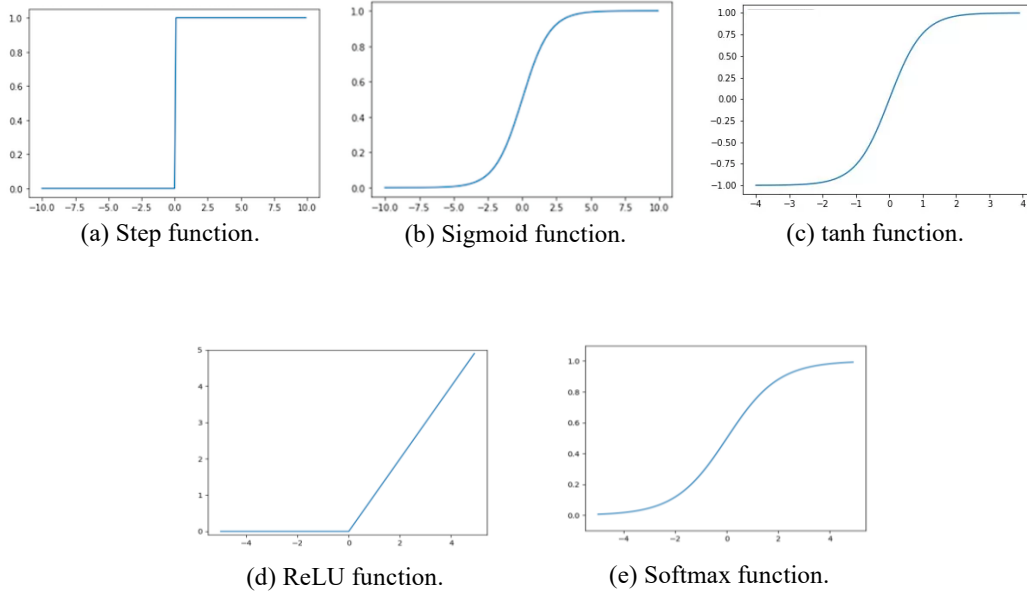


Fig.4.8 Relationship between input and output of activation function.

#### 4.4.6 項 畳み込みニューラルネットワーク (Convolutional neural network: CNN)

前項で述べた全結合層のみのニューラルネットワークでは、データの形状が無視されるという問題がある。例えば、画像データの分類問題について考える場合、画像データは縦・横・チャンネルの 3 次元形状であるのに対し、全結合層では 1 次元形状に変換するため、画像の空間的な特徴を失ってしまう。この問題を解決する手法として CNN がある。CNN の特徴として、畳み込み層 (convolution layer) とプーリング層 (pooling layer) がある。

##### ・畳み込み層

畳み込み層は、画像処理におけるフィルタ処理と同様の処理である、畳み込み演算を行うことで、特徴量の抽出を行う。畳み込み層は重みとバイアスを持ち、この重みをカーネル (kernel) またはフィルタ (filter) という。また、畳み込み層の出力を一般的に特徴マップ (feature map) という。

図 4.9 に畳み込み演算の例を示す。入力データのサイズ (縦, 横, チャンネル) は (4, 4, 1) であり、フィルタサイズは (3, 3, 1) である。畳み込み演算では、入力データ内のフィルタサイズと等しいサイズの領域 (ウインドウ) に含まれる各要素とカーネルの各要素を乗算し、それらの和を求める。その和が出力における 1 つの要素となる。また、入力データにおいてウインドウを移動し、同様の処理を行う。このときの移動量のことをストライドという。入力データ内の全領域でこの処理を行うことにより畳み込み演算の出力が得られる。そして最後に、得られた畳み込み演算の出力の各要素にバイアスを加算することにより、畳み込み層の出力 (特徴マップ) を得る。なお、フィルタサイズやストライドは入力データに合わせて任意に設定が可能である。CNN の学習では、カーネルの重みおよびバイアスを変化させ、特徴量抽出に適切なカーネルになるように最適化が行われる。

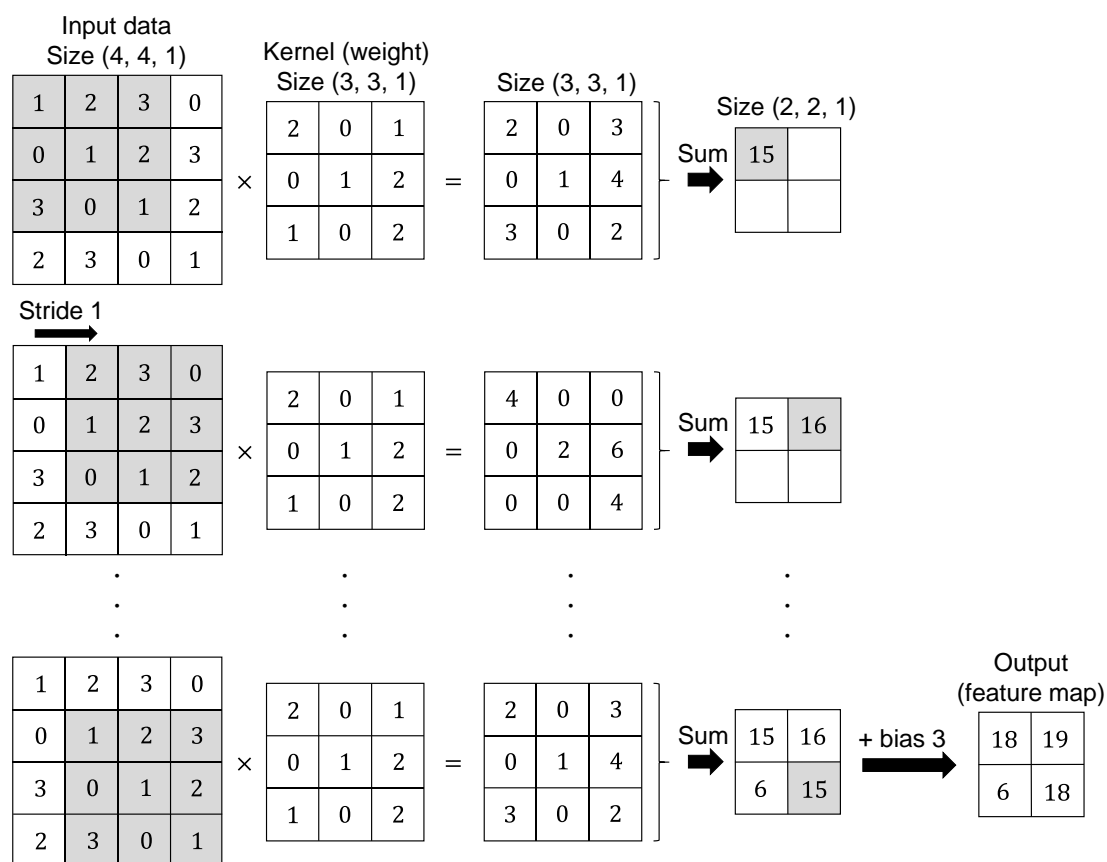


Fig4.9 Processing in the convolutional layer.

#### ・プーリング層

プーリング層は、入力データにおいて、あるサイズの領域の代表値を抽出する層であり、重みやバイアスなどの学習されるパラメータを持たない。プーリング層は、注目領域における代表値の微小な位置の変化に対するロバスト性を確保し、計算時間を短縮する役割を持つ。代表的なプーリング手法に **Max** プーリングや **Average** プーリングがある。

**Max** プーリングによる処理の例を図 4.10 に示す。入力データのサイズは (4, 4, 1) であり、注目領域のサイズは (2, 2, 1) である。また、ストライドは 2 である。**Max** プーリングでは、注目領域内における最大値を代表値として抽出する。注目領域をストライドの分だけ移動させ、同様に最大値を抽出する。入力データの全領域に対して抽出を行った結果が **Max** プーリングの出力である。一方、**Average** プーリングでは、注目領域内における平均値を代表値として抽出する。




Fig.4.10 Processing in the max pooling layer.

#### 4.4.8 項 CNN の時系列データへの応用

CNN は画像分類の問題で優れた性能を持つことが知られている．また，前述の機能（つまり特徴量抽出と特徴のデータ位置に対するロバスト性）を持つことから，時系列データに対して利用する研究がされている．Ji らは，縦・横・時間を持つ動画像に対して CNN を適応し，畳み込み層のカーネルは縦・横・時間方向の 3 次元空間の特徴を抽出することを確認した[43]．また，蛭田らは多変量時系列データの変数間の関連性から特徴量を抽出するために，3 チャンネルのデータをそれぞれ RGB, XYZ 色空間, Lab 色空間を利用した画像変換を行い，CNN を用いて学習する方法を提案した[44]．Zheng らは，多変量時系列データの各変量に対して畳み込み層を設け，それぞれの変数に適した特徴量を抽出するカーネルを個別に学習する multichannel-deep CNN (MC-DCNN) を提案した[45]．

#### ・多チャンネル深層畳み込みニューラルネットワーク (Multichannel-deep CNN: MC-DCNN)

図 4.11 に MC-DCNN モデルの例を示す．MC-DCNN は，多変量時系列の各変量に対して個別に学習した畳み込み層によって特徴量抽出を行い，全結合層で各畳み込み層の出力を結合する．

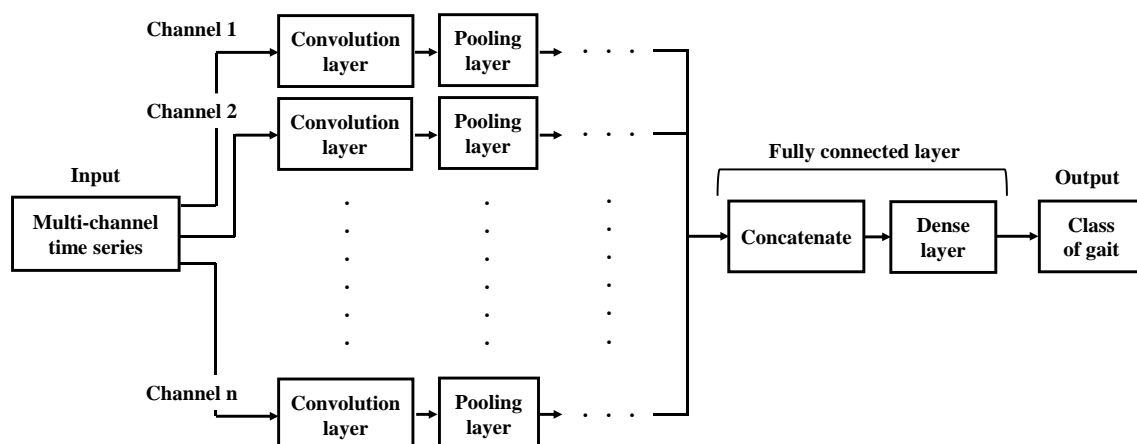


Fig.4.11 Constructure of the MC-DCNN.

## 4.5 節 ニューラルネットワークモデルの評価手法

一般的にニューラルネットワークなどの機械学習モデルの性能評価は、未知のデータに対しての精度を指標として行われる。データが十分にあるときの未知データに対する精度を評価する単純なアプローチは、所有しているデータの一部を使って様々な構造やハイパーパラメータでモデルを学習し、学習に用いていない独立なデータに対する精度を評価する方法である。一般的には、複数の学習済みモデルの中で未知データに対する精度が最も高いモデルや平均的な精度を持つモデルが選ばれる。このとき、学習に用いるデータを訓練用セット（training set）、未知データに対する精度評価用のデータを検証用セット（validation set）という。また、限られたサイズのデータ集合を用いてモデルの設計を繰り返した場合、そのモデルは検証用セットに対して高い精度を持つように構造やハイパーパラメータを調整することと同等であり、検証用セットにも過学習してしまう可能性がある。そこで、訓練用セットと検証用セットとは別にテストセットを用意し、選んだモデルの性能を最終的に評価することが必要となる。本節では、一般的なモデルの性能評価手法について述べる。

### 4.5.1 項 ホールドアウト法（Hold-out method）

所有しているデータが十分に多い場合、ホールドアウト法というデータ分割手法によってモデルの性能評価が行われる（図 4.12）。ホールドアウト法では、データセットを訓練用セットと検証用セット、テストセットに分割してモデルの学習と評価が行われる。分割する割合は厳密に決められた値はないが、一般的には検証用セットとテストセットをそれぞれ全データ数の 1～2 割に設定することが多い。




Fig.4.12 Hold-out method

#### 4.5.2 項 k-分割交差検証法 (Cross validation method)

一般的に良い性能のモデルを構築するためには、できるだけ大きいサイズの訓練用セットを用いて学習を行う必要がある。しかし、所有しているデータ数が少ない場合、ホールドアウト法では検証用セットのサイズが小さくなり、性能の推定の誤差が大きくなる。この問題を解決する手法として k-分割交差検証法がある (図 4.13)。k-分割交差検証法では、所有しているデータのうちテストセットを除いたデータを k 個のデータセットに分割する。そして、1 個のデータセットを検証用セット、k-1 個のデータセットを訓練用セットとして学習を行う。k-分割交差検証法は一般的にホールドアウト法よりも堅牢であるが、訓練を行う回数が分割数 k に比例して大きくなることであり、ハイパーパラメータの最適化を行うことを考慮すると計算時間が大幅に増加することが欠点である。

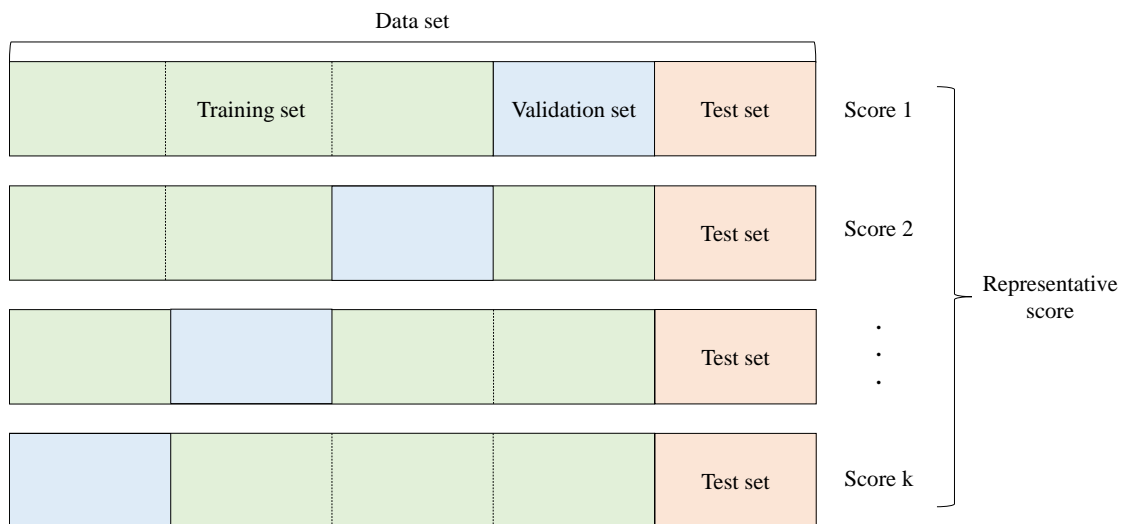


Fig.4.13 Cross validation method

#### 4.5.3 項 リーブワンアウト法 (Leave-one-out method)

所有しているデータが極端に少ない場合、k-分割交差検証法において検証用集合に含まれるデータ数を 1 として評価が行われる。この手法をリーブワンアウト法あるいはジャックナイフ法という。

#### 4.6 節 機械学習の歩行解析への応用研究

人間の運動に対して機械学習を適用する研究は数多くされている。Martinez-Hernandez らはウェアラブル慣性センサの測定値を CNN に入力して歩行活動を検出し、一次マルコフ連鎖を用いて歩行周期の予測を行った[46]。Lau らは歩行中脚部と足部の動きをキネマティックセンサを用いて測定し、サポートベクターマシンを用いて階段上昇、階段下降、平地、上り坂および下り坂の 5 つの歩行条件を分類した[47]。また、Begg らは若年者と高齢者の basic, kinetic and kinematic gait data を測定し、サポートベクターマシンを用いて若年者と高齢者の歩行パターンの分類を行った[48]。しかし、機械学習を人間の運動に適応した研究は運動の検出や分類を目的としたものが多く、本研究で目的としているような運動訓練に応用している研究は少ない。

## 第5章 身体的個人差を考慮した歩容フィードバック訓練システムの概要

機械学習による身体的個人差を考慮した歩容フィードバック訓練システムの概要を図5.1に示す。このシステムは、まず訓練者の運動的指標と力学的指標から構成される多変量歩容データを測定する。次に、事前に学習済みの歩容分類モデルを用いて、多変量歩容データを訓練の必要がない「理想的歩容」、または訓練が必要となる「非理想的歩容」に分類する。そして、歩容分類モデルが分類の根拠とした特徴を解析し、特徴解析結果を基に各訓練者に適した歩容調整内容を決定する。そして、歩容調整内容を画像化し、視覚情報として訓練者にフィードバックする。訓練者はフィードバックされた歩容調整内容を参考に意図的、能動的に自身の歩容を調整する。以上を繰り返すことにより、訓練者は自身の歩容を「理想的歩容」に近づくように調整する。

5.1 節で、歩容訓練システムで用いる計測機器について述べる。5.2 節では、本研究で訓練の対象とする「理想的歩容」と「非理想的歩容」の定義について述べる。また、5.3 節で多変量歩容データの計測・生成について述べ、5.4 節で機械学習を用いた歩容分類について述べる。そして、5.4 節で歩容分類モデルが分類の根拠とした特徴解析による歩容調整内容の決定について述べる。




Fig. 5.1 Outline of gait training system considering physical individual difference.



## 5.1 節 歩容変量測定機器

- ・床反力計内蔵デュアルベルトトレッドミル（テック技販（株），HPT -2200 D）（図 5.2）

提案システムでは，歩行環境および歩行時の床反力を測定するために，左右のベルトの下部に床反力計を内蔵したトレッドミルを用いる．トレッドミルと床反力計の仕様を表 5.1, 5.2 に示す．トレッドミルはベルト速度を左右別に制御可能である．また，床反力計は左右方向（X 軸），前後方向（Y 軸），上下方向（Z 軸）の床反力と 3 軸周りの床反力モーメントを測定可能である．



Fig.5.2 Treadmill with built-in force plate.

Table 5.1 Treadmill Specifications.

Walking surface size	Width 400 mm × Length 1910 mm
Speed range	0.0 – 30.0 km/h
Speed resolution	0.1 km/h

Table 5.2 Specifications of force plate.

Rated capacity	Fx	±3000 N
	Fy	±3000 N
	Fz	±10000 N
	Mx	±5000 Nm
	My	±1500 Nm
	Mz	±1500 Nm
Analog output scale		±10 V
Resolution of the AD conversion		16 bit

- ・光学式三次元動作解析システム（Natural Point Inc., OptiTrack）

提案システムでは，歩行中の訓練者の運動学的指標を計測するために，光学式三次元動作解析システムを用いる．この装置は赤外線カメラ（図 5.3），ハブ（図 5.4），反射マーカ（図 5.5）によって構成されており，複数台の赤外線カメラによって反射マーカを撮影することで，あらかじめ設定された相対座標の原点に対する反射マーカの座標を計測する．表 5.3 に本システムで用いた赤外線カメラの仕様を示す．



Fig.5.3 Infrared camera.



Fig.5.4 Hub for GigE connection type.



Fig.5.5 Reflective marker.

Table 5.3 Infrared camera specifications.

IR LED wavelength	850 nm
Horizontal viewing angle of lens	70°
Vertical viewing angle of lens	49°
Camera resolution	1644 × 1088 pixel
Camera Frame rate	30 - 360 FPS

## 5.2 節 本研究における理想的歩容と非理想的歩容の定義

加齢に伴う筋力低下や身体麻痺は、運動学的には関節角度や拇指床間距離、運動力学的には床反力や関節モーメント、生理学的には筋電位等に影響を及ぼすことが知られている。筋力低下や身体麻痺による歩容への影響が小さければ、個人に適した歩行として認められる。しかし、影響が大きくなって個人の許容範囲を超えると逸脱運動となり、歩行訓練が必要となる。逸脱運動によって生じる不利益の典型的な例には、単脚支持期の立脚安定性の低下、つまずきや転倒のリスクの増大、歩行速度の低下、加速度の低下、エネルギー消費の増大などがある。高齢者の多くの転倒は、歩行中のつまずきに起因することが報告されている[49]。よって、要介護の防止やQOLの向上のためには、つまずきや転倒のリスクの増大が重要な問題であるといえる。本研究では、「つまずきにくい歩容」を訓練の必要がない「理想的歩容」として定義し、「つまずきやすい歩容」を訓練が必要である「非理想的歩行」として定義する。

### 5.3 節 訓練者の多変量歩容データの取得

提案システムは、訓練者の歩容を「つまずきにくい歩容」または「つまずきやすい歩容」に分類する。つまずきは、遊脚期中に足尖が地面または障害物に接触することと定義されるため、拇指床間距離が小さい期間が長いほどつまずきが発生する可能性が高いと考えられる。西澤らは、加齢に伴って拇指床間距離の遊脚初期に表れる極大値と遊脚終期に表れる極大値が低下することが報告し、高齢者の拇指床間距離の低下はつまずきの可能性を高めることを示唆した[50]。このため、歩行中の拇指床間距離を測定することにより、訓練者の歩容をつまずきやすさの観点から分類することができる。しかしながら、歩容分類が拇指床間距離のみに基づく場合、訓練者に提示される歩容調整内容は拇指床間距離のみとなり、訓練者は遊脚期中に拇趾を過度に挙上させること（例えば、股関節と膝関節の過度な伸展）で訓練の必要性を回避できる。過度な拇趾の挙上はつまずきのリスクを減らすことができるが、立脚安定性の低下などの問題があるため適切ではない。したがって、提案システムでは様々な歩容変量から構成される多変量歩行データを用いて、つまずきやすさに関する歩容を分類する。

頻繁に観測される逸脱運動は Perry らによって報告されており[4, 12], 体幹の過度の前後傾, 側屈, 前方後方回旋, 骨盤の過度の持ち上げ, 落ち込み, 前後傾, 前方後方回旋, 不十分な前方後方回旋, 股関節の不十分な屈曲, 過度の屈曲, 内外旋, 内外転, 膝関節の不十分な屈曲, 過度の屈曲伸展, 動揺, 内外反, 足関節の過度の底背屈, 外反, 足趾関節の不十分な伸展, 過度の伸展が認められる。逸脱運動によって示されるように、体幹, 股関節, 膝関節, 足関節角度は歩容を決定する変数として重要である。本研究では訓練の対象変数として、運動学的観点からこれらの関節に着目し、運動力学的観点から床反力に着目した。

図 5.6 に多変量歩容データの測定の概要を示す。歩容訓練中、訓練者は床反力計内蔵トレッドミル上を自由歩行する。そして、歩行中の床反力 3 成分をトレッドミルに内蔵された床反力計を用いて測定する。また、光学式三次元動作解析システムを用いて、訓練者の身体に配置されたマーカの 3 次元座標を計測する。そして、測定された時系列データに対して前処理を行い、歩容分類に用いる歩容変量を算出する。その後、各歩容変量を列方向に連結し、行列を生成する。本研究では、列方向が歩容変量、行方向が時間方向である行列を多変量歩行データと定義する。

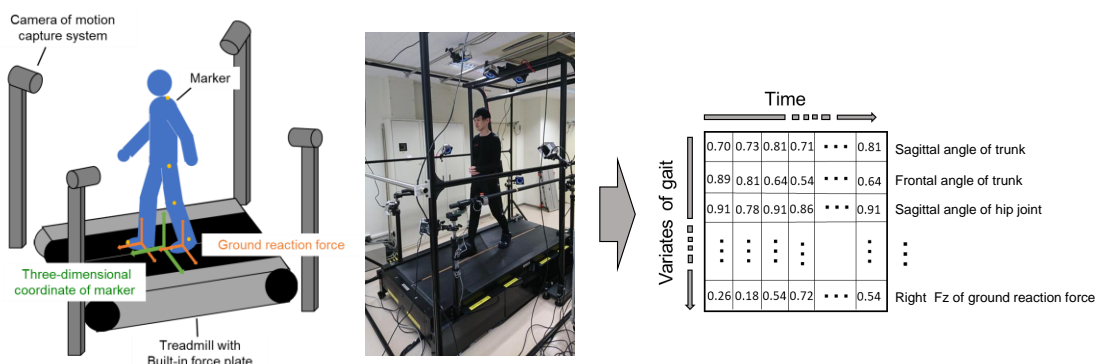


Fig.5.6 Measurement environment of gait variables and generation of multivariate gait data.

## 5.4 節 リアルタイムな理想的歩容と非理想的歩容の個人差を考慮した分類

分類の基準として、「つまずきにくい歩容」群と「つまずきやすい歩容」群の歩容変量毎の代表値（例えば平均値）があるが、訓練者間に身体的個人差が存在するため、代表値が必ずしも適切な基準値であるとは限らない。そのため、身長や筋力量に応じて適切に基準値を調整する必要がある。しかしながら、基準値を決定するためのパラメータの数は膨大であり、訓練前に身体の各部の長さを測定する必要があるため実用的ではない。そこで、本研究では、任意の種類のデータのパターンと特徴量を抽出・学習し、データのクラスを分類する機械学習モデルを用いて歩容を分類する。

第4節で紹介したように、畳み込み層とプーリング層を積層した CNN は特徴抽出機能と特徴の入力データ内の位置に対するロバスト性を持つ。また、MC-DCNN は、多変量時系列である入力データの変量毎に、適した特徴抽出器を学習する。本研究で扱う多変量歩容データは、列方向が歩容変量に対応し、行方向が時間方向に対応する多変量時系列とみなすことができる。CNN の特性から、多変量歩容データを入力として MC-DCNN を用いて歩容の特徴を学習すると、各歩容変量に対応する畳み込み層はそれぞれに適した特徴量を抽出するためのフィルタを学習し、プーリング層はその時間に対するロバスト性を得る。さらに、全結合層は、各歩容変量に対応する最後の畳み込み層の出力における各要素の重み、すなわち歩行位相や歩容変量間の関係を学習する。したがって、MC-DCNN を用いて多変量歩行データを学習することにより、歩行分類モデルは個人差を考慮した分類を行うことが期待される。

本研究では、それぞれのデータポイントが「つまずきにくい歩容」クラスまたは「つまずきやすい歩容」クラスにラベル付けされた多変量歩容データセットを用いて、MC-DCNN 歩容分類モデルを構築する（図 5.7）。歩容訓練時では、訓練者の多変量歩容データを測定し、リアルタイムに MC-DCNN 歩容分類モデルに入力して訓練者の歩容を「つまずきにくい歩容」か「つまずきやすい歩容」クラスに分類する。




Fig.5.7 Model structure of MC-DCNN for classify gait related to stumbling. This model learns the filter of the convolution layer for each channel of the multichannel time series, and combines each output of the convolution layer for

## 5.5 節 歩容の特徴を参考にした歩容調整内容の可視化

深層学習に関する研究のうち特に画像分類の分野において、深層学習モデルが入力データを分類するときに、分類の根拠とした特徴が表れている箇所を説明する手法が開発されている。感度分析[51]や Activation maximization [52, 53, 54], Layer-wise relevance propagation, CNN ベースの顕著性マップ[55]や Guided backpropagation, Gradient-weighted class activation mapping (Grad-CAM) [56]など多数提案されている。これらのような特徴説明手法は近年盛んに行われているが、動画データや時系列画像から運動の特徴を分析する目的で用いられることが多く、運動訓練への応用研究は少ない。画像分類モデルがどのような特徴を学習したかを説明するために使われていることが多い。

CNN モデルが学習した、分類の根拠となる特徴を可視化する手法を、多変量歩容データとつまずきやすさに関する歩容分類モデルに適用した場合、その可視化された出力は「つまずきにくい歩容」あるいは「つまずきやすい歩容」として分類した根拠を意味していることから、それらの特徴箇所を訓練者が調整することで、「つまずきやすい歩容」の特徴を満たさず、「つまずきにくい歩容」の特徴を満たすように訓練が行われると期待できる。本研究では、特徴可視化手法を MC-DCNN 歩容分類モデルに応用することによる、身体的個人差を考慮した歩容調整内容提示手法を提案し、その有用性を検討する。

## 第6章 多変量歩容データセットの構築

教師あり学習であるニューラルネットワークによって、つまずきやすさに関して歩容を分類する場合、入力データとして用いるための多変量歩容データと、各多変数歩容データに対応する出力ラベルが必要である。本章では、学習と評価に用いるための多変量歩容データの測定実験と各データポイントのつまずきやすさに関するラベル付けについて述べる。

### 6.1 節 多変量歩容データを構成する歩容変量の決定

第2節で紹介したように、歩容を表す指標は多数存在する。また、三次元動作解析システムによってマーカ座標を測定することで、歩幅や歩隔、ストライド距離だけでなく速度、加速度、角度、角速度、各加速度、重心を得ることができる。また、床反力計によって床反力や床反力モーメントを測定することで、歩行率や歩行周期、各位相時間、割合を得ることができる。開ループ構造を持つ機構の運動方程式を解くニュートン・オイラー法では、目標運動を実現するための各関節に加えるべき力を求める要素として、角速度、角加速度、加速度が必要となる。そのため、これらのような時系列的特徴を考慮する必要がある。提案システムにおいて、多変量歩容データに含まれる歩容変量は時系列データであり、MC-DCNNの畳み込み層におけるフィルタは、各変量を持つ時間方向の特徴量（例えば微分値）を学習することが期待できる。また、提案する歩容訓練システムでは、歩容調整内容を訓練者にフィードバックし、訓練者は試行錯誤を繰り返しながら「つまずきにくい歩容」となるように歩容を調整することを前提としている。そのため、各関節に発生させる力を事前に決定する必要はない。また、フィードバックする変量が細分化されて増加した場合、訓練者が歩容調整内容を理解することが困難になる。また、理解できたとしても細分化された変量を適切に制御することは難しい。そこで本研究では、運動学的観点から第5章で述べた逸脱運動の原因となる関節である、体幹、股関節、膝関節、足関節の関節角度と、力学的観点から床反力を多変量歩容データを構成する歩容変量として用いた。

### 6.2 節 多変量歩容データ測定実験

#### 6.2.1 項 実験条件

実験協力者は安全を考慮し、健康な日本人男性8名（平均年齢  $23.9 \pm 1.0$  歳）とした。訓練者には事前に実験の趣旨を説明し、インフォームドコンセントを得た。また、本実験は埼玉大学倫理委員会の承認を受けている（承認番号：H29-E-12）。図6.1のように床反力計内蔵トレッドミルの周囲に光学式三次元動作解析装置のカメラ12台を配置した。また、相対座標の原点をトレッドミル歩行面の中心に設定した。学習に用いる歩容の種類を増加させることを目的として、実験条件は(1)「通常歩行」、(2)「制限歩行（筋力負荷および関節可動を制限した歩行）」の2条件とした。反射マーカを実験参加者の頭頂部、左右の肩甲

骨，第一仙骨，左右の腸骨稜，左右の大転子，左右の膝関節外側部，左右の外果，左右の第一中足骨頭に配置した（図 6.2）．条件(2)では，実験協力者は上肢前部および左右の手関節部，足関節部に重りと左右の肘，膝関節部に関節可動を制限する装具を装着した（株式会社三和製作所，高齢者疑似体験教材エキスパートセット III）（図 6.3）．各条件で実験協力者は基準姿勢を 5 秒間とった後，トレッドミル上を 120s 間歩行した．基準姿勢は「背筋を伸ばし，足を肩幅に開き，手を身体から拳一個分離した姿勢」と定義した．各条件において実験協力者の自由歩行を可能にするために，実験協力者の Y 座標がトレッドミル上の中心を維持するようにトレッドミルの速度を自動的に制御した．基準姿勢維持時と歩行時において，各マーカの三次元座標と床反力 3 分力を左右の床反力計と三次元動作解析装置を用いて，それぞれサンプリング周波数 250 Hz で測定した．試行回数は各条件につき一回とした．

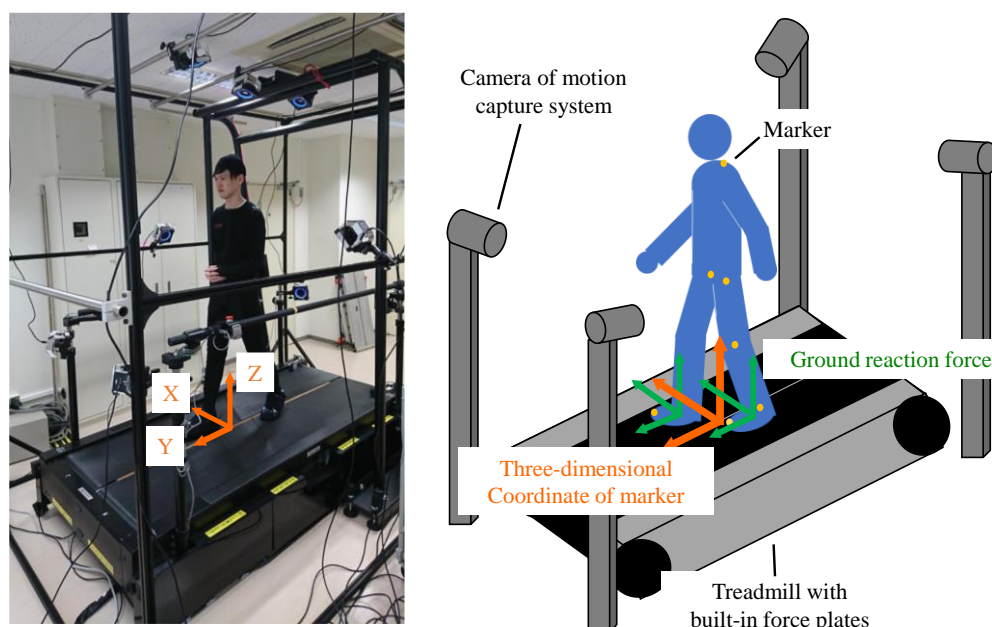


Fig.6.1 Arrangement of infrared cameras and treadmill with built-in force plates.






Fig.6.2 Marker placement.

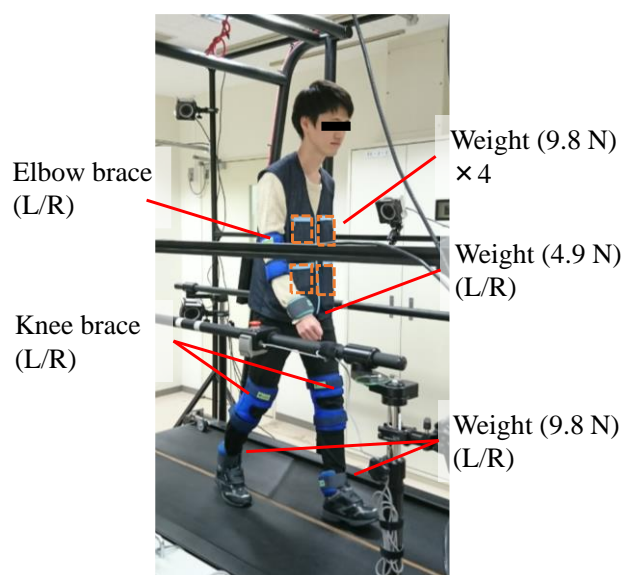


Fig.6.3 Motion restriction orthosis (load applied to muscle and limited joint movement).

### 6.2.2 項 データの前処理と多変量歩容データの生成

外光の影響や、実験協力者の身体により反射マーカが遮られることにより、三次元座標が測定できない瞬間があるため、反射マーカの三次元座標にスプライン補間を行った。一般的な歩行分析では、人体の関節の自由度が常に 1 ではないので、解剖学的角度が用いられる。しかし、本研究では身体部位の回転運動を測定していないため、解剖学的角度で歩行中のすべての姿勢を表現することは不可能である。従って、図 6.4 のように、各関節角度を形成するベクトルを求め、それらの内積および外積を用いて、YZ 平面および ZX 平面

における関節角度（体幹，股関節，膝関節，足関節）を 0 から 360° の範囲で算出した．関節角度と拇指床間距離はマーカ位置の差異の影響を受けるため，歩行中の値と基準姿勢の値の差を用いることにより，基準姿勢からの角度変化および拇指床間距離変化を算出した．

次に，床反力 3 分力を，条件(1)のデータは各実験協力者の体重が，条件(2)のデータは各実験協力者の体重と装着した重りの和が 1 になるように正規化した．本研究では，床反力 Z 成分が 0.05 以上になった瞬間を右足接地として検出した．学習用と検証用の入力データを作成するために，120 s 間の各変量変化を右足接地から次の右足接地までのストライド毎のデータに分割した．これらの変量変化（YZ 平面および ZX 平面における体幹，股関節，膝関節，足関節の角度と X, Y, Z 軸における床反力）を行方向につなげて得られた行列を多変量歩容データとして定義した（図 6.5）．また，右足の第 1 中足骨頭に設置したマーカの Z 座標を対象脚の拇指床間距離として算出し，歩行中の値と基準姿勢の値の差を用いることにより，基準姿勢からの拇指床間距離変化を求めた．

左足の接地も同様に検出し，データを分割した．また，左足接地で分割された多変量歩容データと右足接地で分割された多変量歩容データを同様に扱うために，左足接地で分割されたデータの右脚の行と左脚の行を入れ替え，ZX 平面の関節角度と床反力 X 成分の符号を入れ替えた．その結果，1,548 ストライドの多変量歩容データが得られた．また，各変量を全データ中の各変量の最大値と最小値を用いて 0-1 の範囲に正規化した．また，ストライド毎に分割された各多変量歩容データは列方向の長さが異なるため，歩行周期が 100% になるように各データを時間方向に正規化した．最後に，カットオフ周波数 30 Hz としてローパスフィルタをかけた．




Fig.6.4 Definition of gait variables used for multivariate gait data generated.




Fig.6.5 Structure of multivariate gait data.

### 6.3 節 つまづき易さに関する歩容のラベル付け

多変量歩容データの測定実験では、「通常歩行」と「制限歩行」の2条件を実施したが、実験協力者の身体的個人差や気分により、必ずしも「通常歩行」における歩容がつまづきにくく、「制限歩行」における歩容がつまづきやすいとは限らない。また、同一実験協力者の同条件の試行であっても、疲労などの影響により各ストライドの歩容が同様であるとは限らない。そこで、教師なし学習によるクラスタリングを用いて対象脚の拇指床間距離をクラスタリングし、その結果に基づいて各拇指床間距離データポイントに対応する多変量歩容データのラベル付けを行った。

時系列データに対応したクラスタリング手法には、SBDを距離尺度としたk-shape法やDTWを距離尺度とした最近傍クラスタリングなどがある。k-shape法は時系列データのスケールリングと位相のずれを考慮したクラスタリング手法であり、DTWは長さが異なる時系列データや位相のずれを考慮したクラスタリング手法である。拇指床間距離の絶対値がつまづきやすさに直接影響するため、スケールリングを考慮するk-shape法は拇指床間距離のクラスタリングには適していない。そこで本研究では、DTWを用いた最近傍クラスタリングを用いた。クラスタ数はエルボー法により決定した。

エルボー法の結果を図6.6に示す。拇指床間距離のクラスタ数を、SSEが収束する2クラスタとした。各クラスタに分類されたすべての拇指床間距離とその平均値および標準偏差を図6.7に示す。クラスタ0には790個のデータポイント、クラスタ1には758個のデータポイントが含まれていた。また、各クラスタに含まれていた拇指床間距離の平均の遊脚初期における極大値、遊脚中期における極小値、遊脚終期における極大値の正規化前の値と標準偏差を表6.1に示す。クラスタ0の拇指床間距離はクラスタ1の拇指床間距離よりも大きく、特に遊脚終期においてその差が大きい。よって、本実験でクラスタ0に分類された拇指床間距離に対応する多変量歩容データを「つまづきにくい歩容」クラス、クラ

スタ 1 に分類された拇指床間距離に対応する多変量歩容データを「つまずきやすい歩容」クラスとラベル付けした。各クラスに分類された拇指床間距離に対応する多変量歩容データの各変量の値と、その平均値および標準偏差を図 6.8 に示す。




Fig.6.6 Results of the elbow method and determination of the number of clusters.

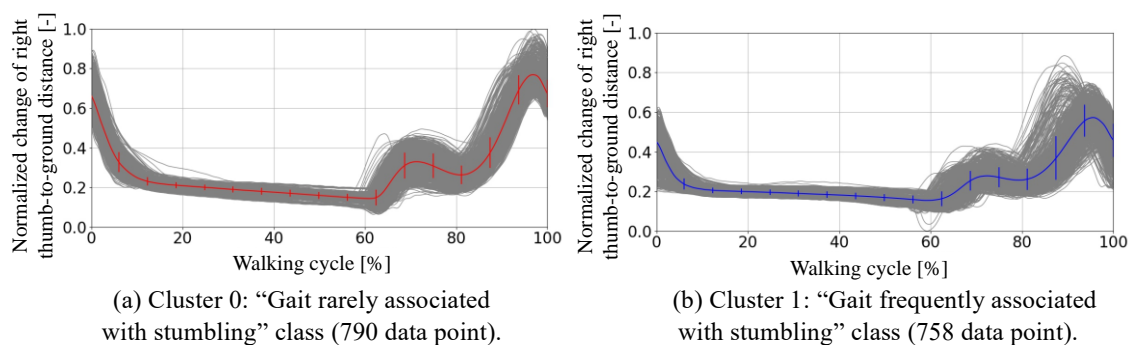


Fig.6.7 All the thumb-to-ground distance classified into each cluster (grey) and their mean and standard deviation (red or blue).

Table 6.1 Representative values in the mean of the thumb-to-ground distance before normalization.

	Cluster 0	Cluster 1
Local maximum value at the initial swing [mm]	22.1±11.2	13.0±9.0
Local minimum value at the mid-swing [mm]	10.2±8.5	9.1±8.0
Local maximum value at the terminal swing [mm]	100.0±10.7	65.2±13.3

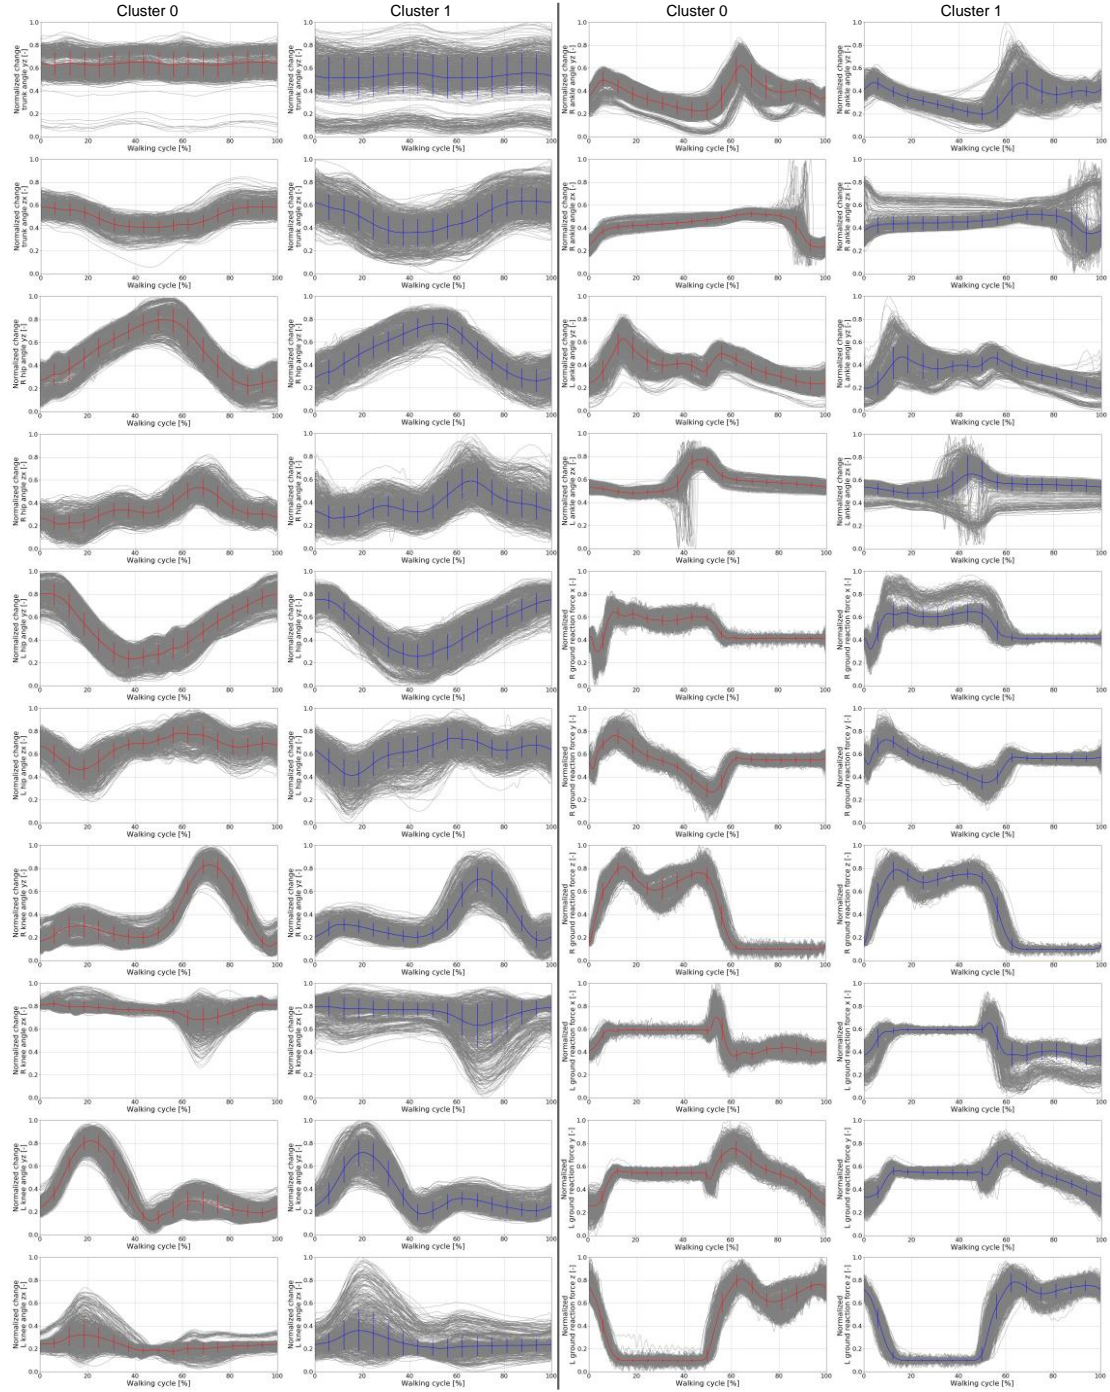


Fig.6.8 All the data of each variable in each cluster (grey) and their mean and standard deviation (red or blue). X axis is walking cycle [%], and y axis is each preprocessed gait variable (left two columns: trunk angle in the YZ plane, trunk angle in the ZX plane, right hip joint angle in the YZ plane, right hip joint angle in the ZX plane, left hip joint angle in the YZ plane, left hip joint angle in the ZX plane, right knee joint angle in the YZ plane, right knee joint angle in the ZX plane, left knee joint angle in the YZ plane, left knee joint angle in the ZX plane) (right two columns: right ankle joint angle in the YZ plane, right ankle joint angle in the ZX plane, left ankle joint angle in the YZ plane, left ankle joint angle in the ZX plane, right ground reaction force X component, right ground reaction force Y component, right reaction force Z component, left ground reaction force X component, left ground reaction force Y component, left ground reaction force Z component).



## 6.4 節 つまづき易さに関する歩容のラベル付けに対する考察

本章では、DTW を用いた最近傍クラスタリングにより拇趾床間距離をクラスタリングして、対応する多変量歩容データを「つまづきにくい歩容」クラス、または「つまづきやすい歩容」クラスとしてラベル付けした。ここで、各クラスに分類された拇趾床間距離の正規化前の平均値と標準偏差を比較すると、「つまづきにくい歩容」クラスの遊脚初期に表れる極大値は  $22.1 \pm 11.2$  mm、遊脚中期に表れる極小値は  $10.2 \pm 8.5$  mm、遊脚終期に表れる極大値は  $100.0 \pm 10.7$  mm であったのに対し、「つまづきやすい歩容」クラスの遊脚初期に表れる極大値は  $13.0 \pm 9.0$  mm、遊脚中期に表れる極小値は  $9.1 \pm 8.0$  mm、遊脚終期に表れる極大値は  $65.2 \pm 13.3$  mm であった。一方で、若年者と高齢者の拇趾床間距離を比較した我々の過去の実験の結果では、若年者群の遊脚初期に表れる極大値は  $26.9 \pm 6.8$  mm、遊脚中期に表れる極小値は  $13.1 \pm 4.8$  mm、遊脚終期に表れる極大値は  $99.9 \pm 7.6$  mm であったのに対し、高齢者群の遊脚初期に表れる極大値は  $26.1 \pm 9.5$  mm、遊脚中期に表れる極小値は  $15.5 \pm 7.3$  mm、遊脚終期に表れる極大値は  $88.0 \pm 20.1$  mm であった[57]。「つまづきにくい歩容」クラスの拇趾床間距離は若年者群と同程度であり、「つまづきやすい歩容」クラスの拇趾床間距離は高齢者群よりも低かった。つまづきの危険性は、拇趾床間距離だけでなく、地面の環境や障害物に気づくための認知能力、自身の運動能力に対する認識誤差にも影響されるため、一概につまづく程度を表現することは不可能であるが、拇趾床間距離の観点からみれば、「つまづきやすい歩容」クラスに含まれる多変量歩容データは、高齢者と同等のつまづきの危険性を有しているといえる。

図 10 から各クラスに含まれる多変量歩容データの各変量の平均値を比較すると、「つまづきやすい歩容」クラスの体幹 YZ 平面角度は歩行周期全体で小さく、このクラスの歩容は前傾姿勢である。また、両脚の膝関節 YZ 平面角度は遊脚中期において小さく、遊脚終期においては大きい。また、両脚の足関節 YZ 平面角度が前遊脚期において小さく、初期接地と遊脚終期において大きい。さらに両脚の床反力 Y 成分が立脚終期において大きい。このことは、「つまづきやすい歩容」クラスの歩容は、遊脚中期において膝関節屈曲が不十分、遊脚終期において膝関節伸展が不十分であり、前遊脚期において足関節底屈量が小さく、遊脚終期において足関節背屈量が小さい、駆動力が弱いことを示している。また、両脚の足関節 ZX 平面角度の変化量が遊脚終期において小さく、一部のデータは歩行周期全体において反転している。これは、「つまづきやすい歩容」クラスに含まれる実験協力者が足関節を外転させていることを示す。また、平均値に大きな差は見られないものの、「つまづきやすい歩容」クラスの各変量（ZX 平面における体幹角度、股関節角度、膝関節角度、地面反力 X 成分など）は標準偏差が大きく、変化量が大きい傾向がある。このことは、「つまづきやすい歩容」クラスでは、体幹を横方向に振り、股関節を外転あるいは外旋させている歩容が多いことを意味している。

## 第7章 拇指床間距離を決定する特徴可視化による 歩容調整内容提示手法

提案手法では、訓練者の歩容を基にした身体的個人差を考慮した歩容調整内容の提示が必要である。本章では、訓練者の多変量歩容データに含まれる CNN モデルが学習した「つまずきにくい歩容」クラスあるいは「つまずきやすい歩容」クラスの特徴を可視化する手法を提案し、その手法の歩容訓練への有用性について議論する。

### 7.1 節 拇指床間距離を決定する特徴の可視化手法

CNN モデルによる分類の根拠を可視化する手法に Grad-CAM がある[56]。Grad-CAM は、入力行列の各要素が各クラスの分類結果に与える影響度をヒートマップで可視化する手法である。分類モデルを用いて、任意のデータをいくつかのクラスに分類した場合、特定のクラス  $c$  に対応する影響度ヒートマップ  $L^c$  は以下の式で得られる。

$$L^c = \text{ReLU}(\sum_k \alpha_k^c \mathbf{A}^k) \quad \dots\dots\dots (7.1)$$

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial \mathbf{O}^c}{\partial \mathbf{A}_{ij}^k} \quad \dots\dots\dots (7.2)$$

$$\text{ReLU}(x) = \max(x, 0) \quad \dots\dots\dots (7.3)$$

ここで、 $\mathbf{O}^c$  はクラス  $c$  に対する出力層の出力である。 $\mathbf{A}$  は任意の畳み込み層の各フィルタの出力である特徴マップであり、 $k$  は対象となる畳み込み層のフィルタ数である。一般的な Grad-CAM では、最後の畳み込み層が対象になることが多い。 $(i, j)$  は特徴マップの行と列の番号、 $Z$  は  $i$  と  $j$  の積である。まず、式(7.2)によってクラス  $c$  の  $k$  番目の特徴マップに対する重み係数  $\alpha_k^c$  を算出する。次に、式(7.1)によって重み係数  $\alpha_k^c$  を乗じた特徴マップ  $\mathbf{A}^k$  を加算する。そして、活性化関数  $\text{ReLU}(\cdot)$  の出力を影響度ヒートマップと定義する。学習モデルが分類時に判断の根拠とした入力行列の要素の位置は、この影響度ヒートマップを用いて視覚的に理解可能である。

図 7.1 に犬と猫を識別する CNN モデルに対して、犬と猫が移った画像を入力、分類し、Grad-CAM を適用した例を示す。「犬」クラスあるいは「猫」クラスに対する出力層の出力における影響度ヒートマップを計算し、入力画像と合成する。その結果、入力画像においてそれぞれの頭部が強調されており、分類モデルは特に鼻や目、口を特徴として抽出、学習し、分類の根拠としていることが分かる。図 7.2 に、この方法を歩容分類に適用したイメージを示す。本研究における歩容分類モデルは MC-DCNN の構造をしており、各歩容変量に対する畳み込み層を有するため、Grad-CAM による計算は、各変量における特徴量抽

出部の最後の層に対して実行し、歩容変量毎に得られた影響度ヒートマップを列方向に接続する。また、一般的な Grad-CAM では、それぞれのヒートマップの最大値で非-t パップ全体を正規化するが、本研究では入力データの歩容変量間の特徴の強さを比較するために、1 つの多変量歩容データを入力した際の「つまずきにくい歩容」クラスと「つまずきやすい」クラス両方の全変量の最大値で正規化を行う。入力行列である多変量歩容データは関節角度と床反力から成る歩容変量の時系列データであるため、生成された影響度ヒートマップの行と列は歩行周期中の各変量と歩行の各相を表す。また、ヒートマップが活性している箇所は、自身の歩容に含まれる「つまずきにくい歩容」クラスの特徴と「つまずきやすい歩容」クラスの特徴を示す。よって、このヒートマップを訓練者に提示することで、訓練者は自身が調整すべき身体部位、関節とそのタイミングが理解できる。また、提示された特徴部位を参考に訓練者が自身の歩容を調整することで、「つまずきにくい歩容」クラスの特徴を満たし、かつ「つまずきやすい歩容」クラスの特徴を満たさないように訓練することができると考えられる。

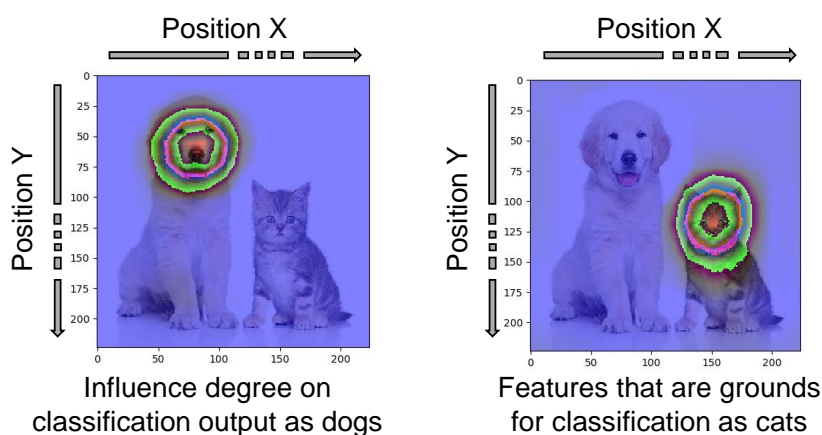



Fig. 7.1 Application of Grad-CAM to dog and cat classification model.



Example of Influence degree on classification output of gait classification

Fig. 7.2 Application of Grad-CAM to the gait classification model.



## 7.2 節 歩容分類モデルの構築と学習結果

多変量歩行データを入力，第 6 章で各多変量歩行データポイントに対応する拇指床間距離のクラスタリング結果を基にしてつけられたクラスラベルを出力とし，MC-DCNN を用いて「つまずきにくい歩容」と「つまずきやすい歩容」の特徴を学習し，歩容分類モデルを構築した．プログラミング言語には python を用い，深層学習ライブラリのひとつである keras を用いてモデルの定義を行った．MC-DCNN 歩容分類モデルの構造と各層におけるハイパーパラメータを図 7.3 と表 7.1 に示す．また，エポック数を 3,000，最適化手法を確率勾配降下法，誤差関数をカテゴリカルクロスエントロピーとした．これらのハイパーパラメータと用いる関数は試行錯誤的に決定した．影響度可視化の検証のために，1,548 個のデータポイントからクラス毎に 10 個のデータポイントを無作為に選択，分割し，これらをテストセットとした．また，テストセットを除く 1,528 個のデータポイントのうち，無作為に 80%を訓練セットとし，残りの 20%を検証セットとした．Keras の model check point 関数を用いて，3,000 エポックの学習の中で検証セットに対する誤差関数の出力が最も低いモデルを保存した．3,000 エポックの学習を 1 回とし，10 回学習を行った．ただし，訓練セットと検証セットの無作為な分割は 1 回の学習毎に行われた．生成した 10 個の歩容分類モデルの検証セットに対する歩容分類の平均正解率は  $97.64 \pm 0.40\%$  であった．

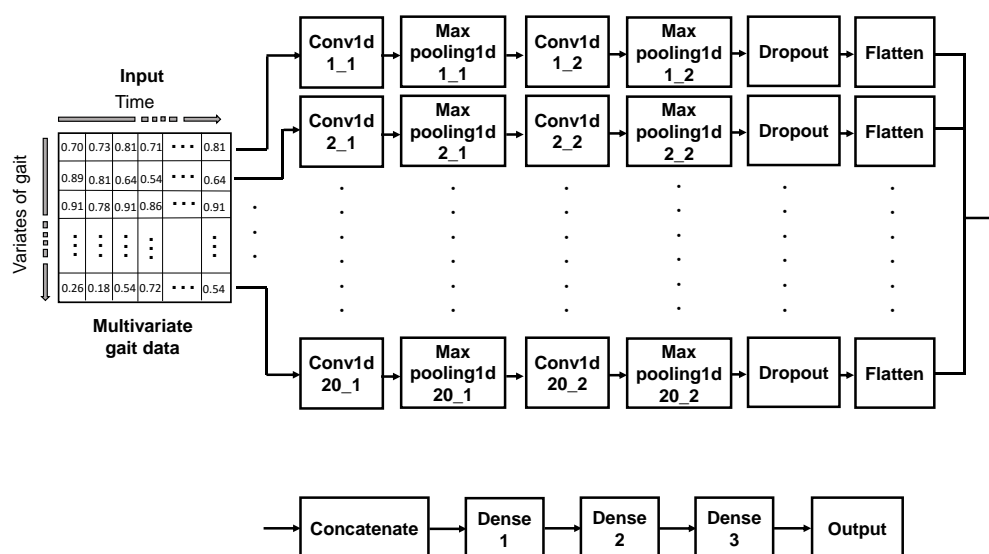


Fig. 7.3 Structure of the MC-DCNN model for gait classification.

Table 7.1 Layer description of the MC-DCNN model for gait classification.

Layer name	Layer description
Input	$20 \times 400 \times 1$ Two-dimensional data
Conv1d n_1	Filters: 32, kernel size: 25, stride: 1, padding: causal, activation: relu
Max pooling1d n_1	pool size: 2, padding: valid
Conv1d n_2	Filters: 64, kernel size: 10, stride: 1, padding: causal, activation: relu
Max pooling1d n_2	pool size: 2, padding: valid
Dropout	Rate: 0.25
Flatten	-
Dense 1	Units: 256, activation: relu
Dense 2	Units: 64, activation: relu
Dense 3	Units: 16, activation: relu
Output	Units: 2, activation: softmax

### 7.3 節 つまづきに関する歩容特徴可視化結果

10 個の学習モデルのうち、検証セットに対する誤差関数の出力が最も低いモデルに対し、テストセットの 20 個のデータポイントを入力し、歩容クラスを分類した。テストセットに含まれる 20 個の多変量歩容データポイントに対する出力層の softmax 関数の出力と分類結果を表 7.2 に示す。つまづきやすさに関する歩容の分類の結果、全てのデータポイントにおいて正しい分類となった。特に、データポイント 3 スとデータポイント 16 の正解クラスに対する softmax 関数の出力は、それぞれのクラスの 10 個のデータポイントの中で最大であった。また、データポイント 4 とデータポイント 17 の正解クラスに対する softmax 関数の出力は、全データポイントの中で中間的な値である。図 7.4 は、これら 4 つのデータポイントの、対象脚の拇指床間距離と各変量の正規化値を示している。ただし、対象脚とは、多変量歩容データをストライド毎に分割する際に参照した脚のことであり、反対の脚を非対象脚と定義した。

図 7.5 は、これらのデータポイントの各要素における、各クラスに対する softmax 関数の出力への影響度ヒートマップの可視化結果である。ヒートマップは各データポイントの両クラスに対する影響度の最大値で正規化されている。この歩容分類モデルは、「つまづきにくい歩容」クラスの分類根拠として、YZ 平面における体幹角度、YZ 平面における非対象脚の股関節角度、ZX 平面における対象脚の膝関節角度および非対象脚の床反力 X 成分に着目している。また、「つまづきやすい歩容」クラスの分類根拠として、ZX 平面における体幹角度、YZ 平面における対象脚の膝関節角度、YZ 平面における非対象脚の膝関節角度、ZX 平面における非対象脚の膝関節角度、YZ 平面における対象脚の足関節角度、ZX 平面における非対象脚の足関節角度、対象脚の床反力 Y 成分、対象脚の床反力 Z 成分、非対

象脚の床反力 Y 成分に着目している.

Table 7.2 Classification result of multivariate gait data and output of softmax function using MC-DCNN model for gait classification.

Class of input data	Data point No.	Result of classification	Output of soft max for the “gait rarely associated with stumbling” class ( $\times 10^{-1}$ )	Output of soft max for the “gait rarely associated with stumbling” class ( $\times 10^{-1}$ )
“Gait rarely associated with stumbling”	1	Correct	9.9987	0.0013
	2	Correct	9.9984	0.0016
	3	Correct	9.9996	0.0004
	4	Correct	5.3405	4.6595
	5	Correct	7.5767	0.4233
	6	Correct	9.9992	0.0008
	7	Correct	9.9987	0.0013
	8	Correct	9.8296	0.1704
	9	Correct	9.9993	0.0007
	10	Correct	8.1583	1.8417
“Gait frequently associated with stumbling”	11	Correct	0.0017	9.9983
	12	Correct	0.0001	9.9999
	13	Correct	3.9809	6.0191
	14	Correct	0.0026	9.9974
	15	Correct	0.0035	9.9965
	16	Correct	0.0001	9.9999
	17	Correct	4.6168	5.3832
	18	Correct	0.0003	9.9997
	19	Correct	0.6475	9.3525
	20	Correct	0.0001	9.9999

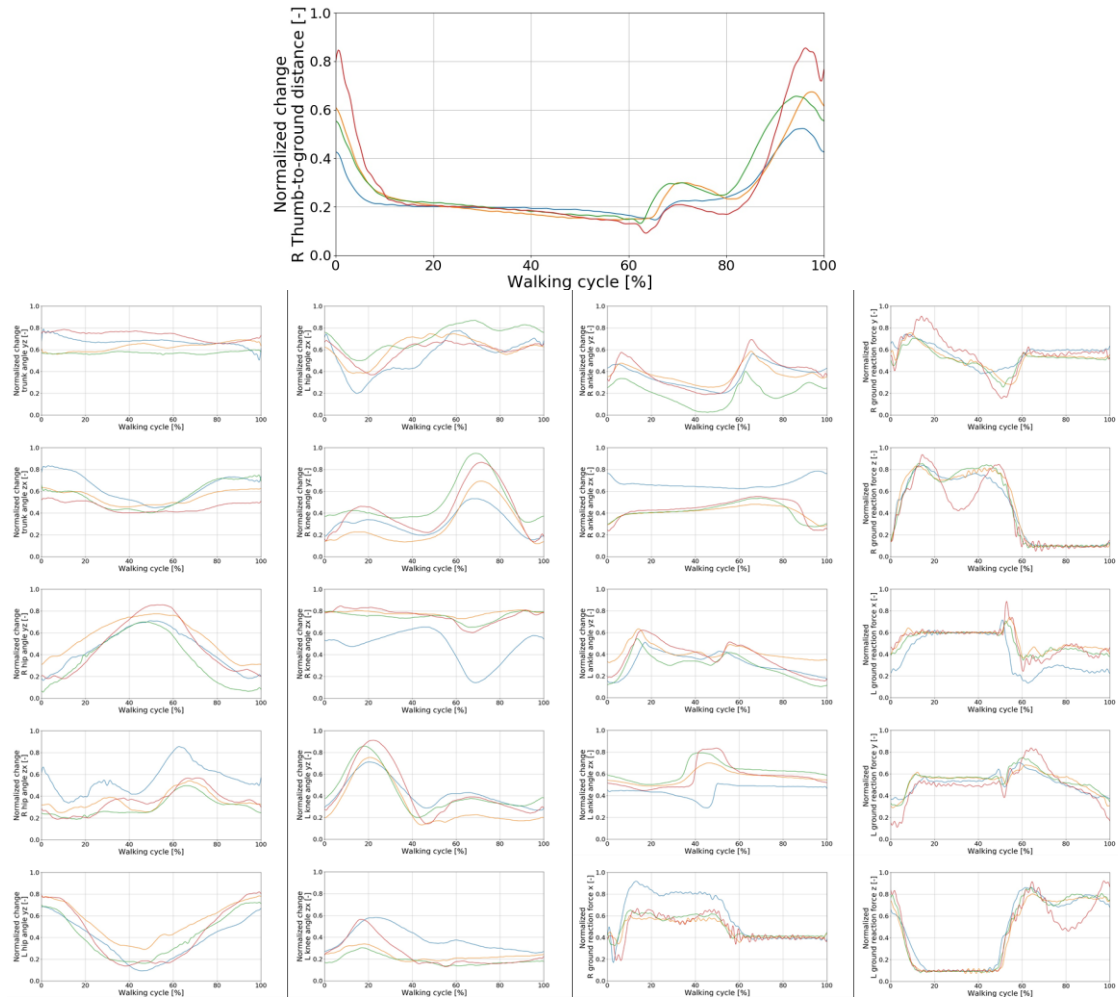





Fig.7.4 Thumb-to ground distance and each variate data for the verification of the influence degree visualization (red is data point 3, orange is data point 4, blue is data point 16, and green is data point 17) (column 1: trunk angle in YZ plane, trunk angle in XZ plane, right hip joint angle in YZ plane, right hip joint angle in XZ plane, left hip joint angle in YZ plane) (column 2: left hip joint angle in XZ plane, right knee joint angle in YZ plane, right knee joint angle in XZ plane, left knee joint angle in YZ plane, left knee joint angle in XZ plane) (column 3: right ankle joint angle in YZ plane, right ankle joint angle in XZ plane, right ground reaction force X component) (column 4: right ground reaction force Y component, right reaction force Z component, left ground reaction force X component, left ground reaction force Y component, left ground reaction force Z component).




(a) Data point 3 with largest output of soft max function for the class "gait rarely associated with stumbling".



(b) Data point 4 with intermediate output of soft max function for the class "gait rarely associated with stumbling".



(c) Data point 16 with largest output of soft max function for the class "gait frequently associated with stumbling".



(d) Data point 17 with intermediate output of soft max function for the class "gait frequently associated with stumbling".

Fig.7.5 Influence degree heatmaps on the output of the soft max function, which is the output layer, for each class of each place in the input multivariate gait data (GRF means ground reaction force). These influence degrees were normalized by the maximum value of each data.

## 7.4 節 考察

### 7.4.1 項 歩容分類モデルによるつまずきやすさに関する歩容分類の妥当性

本実験で構築した歩容分類モデルは、評価セットに対して  $97.64 \pm 0.40\%$  という高い分類精度を示した。また、データポイント 3 は「つまずきにくい歩容」クラスに対する softmax 関数の出力が最も高く、データポイント 16 は「つまずきやすい歩容」クラスに対する softmax 関数の出力が最も高かった。さらに、データポイント 4 とデータポイント 17 は各クラスに対する softmax 関数の出力が中間的な値を示した。softmax 関数の出力は入力ベクトルの要素の比率を表すため、入力多変量歩容データの各クラスの特徴強度の比率を示している。拇指床間距離を比較すると、データポイント 3 は遊脚終期において最も大きく、データポイント 16 は最も小さい。また、データポイント 4 とデータポイント 17 はそれらの中間的な値である。モデルの学習は、0 と 1 の離散値を出力として、関節角度と床反力から構成される多変量歩行データを用いて行われたにもかかわらず、モデルの最終的な出力である softmax 関数の出力と拇指床間距離は相関していた。これは、MC-DCNN モデルが拇指床間距離を決定する特徴を学習したことを示しており、モデルの出力スコアから訓練者のつまずきやすさの度合いを判断できるといえる。

#### 7.4.2 項 歩容特徴可視化の歩容訓練への応用の有用性

Grad-CAM に入力した 4 つデータの各変量を比較すると、「つまずきやすい歩容」クラスに対する出力が最も高かったデータポイント 16 は、特に遊脚中期で YZ 平面における膝関節角度が小さく、立脚期における床反力 Y 成分の最大値が小さく最小値が大きい。また、歩行周期全体で ZX 平面において体幹角度の変化が大きく、ZX 平面において股関節角度が大きい。加えて、ZX 平面において膝関節角度変化が大きく、ZX 平面における足関節角度が他のデータに対して反転しており、床反力 X 成分が大きい。このことはデータポイント 16 の歩容が、不十分な遊脚中期の膝関節屈曲と股関節の外転および外旋、足関節の外転を有しており、「分回し歩行」をしていることを示す。

訓練時に、「つまずきにくい」歩容クラスの平均を目標値として訓練者に提示する場合、クラス間には 6 章で述べた差異が存在するため、データポイント 16 を示した訓練者は遊脚中期の膝関節屈曲、床反力の駆動力、足関節の外旋を調整する必要がある。また、平均値に顕著な差はなかったものの、「つまずきやすい歩容」には、ZX 平面における体幹角度、股関節角度、膝関節角度、地面反力 X 成分の変化量が大きく、体幹を横方向に振り、股関節を外転あるいは外旋させている歩容が多く含まれていたことから、これらの歩容変量についても調整する必要があるといえる。

しかし、提案手法による各クラスの出力スコアに対する影響度ヒートマップから、YZ 平面における膝関節角度や床反力 Y 成分はモデルの出力に対して影響しているが、ZX 平面における足関節角度は影響していないことが分かる。また、平均値では顕著な差は見られないものの、その変化量が大きかった ZX 平面における体幹角度はモデルの出力に対して影響度がみられる一方で、同様な傾向がみられた ZX 平面における股関節角度や膝関節角度では影響度は見られない。これらのことは、つまずきに関する歩容分類モデルが各クラスの平均値だけでなく、波形の形状や歩容変量間の関係性から拇趾床間距離を決定する特徴を学習したこと表している。また、歩容分類モデルは、不利益としての「つまずき」に着目した場合、足関節の外転、股関節の外転と外旋は許容される運動であり、個人に適した歩容であると判断したことを示している。

一般的に「分回し歩行」は遊脚中期に脚を前方に振り出す際に十分に膝関節を屈曲できないことの代替行為であることから、股関節の外転と外旋は拇趾床間距離を上昇させる運動である。提案手法による影響度ヒートマップでは、これらの運動は許容されていた。また、異なる多変量歩容データの影響度ヒートマップにおいて、各歩容変量、タイミングでモデルの出力に対する影響度が異なることから、システムは訓練者に対して調整すべき身体部位の優先度を示すことができる。以上のことから、提案手法により、訓練者は自身が調整すべき身体部位とタイミングを理解することができ、訓練者の身体的個人差を考慮した歩容調整箇所の提示を行うことができることが示唆された。

#### 7.4.3 項 歩容特徴可視化手法の限界

影響度ヒートマップを比較すると、中間的な歩容であるデータポイント 17 の遊脚中期の YZ 平面における膝関節角度の正規化された影響度は、最もつまずき易い歩容であるデータポイント 16 に比べて大きく示されている。しかし、データポイント 16 において遊脚中期における YZ 平面の膝関節角度はデータポイント 17 よりも小さい。これは Grad-CAM をヒートマップ化する際に、データポイント毎に全変量の影響度の最大値でヒートマップ全体を正規化しているためである。ここで、各データの影響度の最大値は、データポイント 3 が  $1.13 \times 10^{-8}$ 、データポイント 4 が  $6.55 \times 10^{-4}$ 、データポイント 16 が  $2.42 \times 10^{-12}$ 、データポイント 17 が  $6.13 \times 10^{-4}$  であった。よって、いずれかのクラスに対するモデルの出力が大きいデータポイントでは、各入力要素の影響度が小さく、モデルの出力が中間的であったデータポイントでは、各入力要素の影響度が大きいことが分かる。本研究の MC-DCNN モデルのような分類問題では、出力層の活性化関数に softmax 関数やシグモイド関数が使われることが多い。softmax 関数は、入力ベクトルの各要素の指数関数の出力の比を表しており、任意のベクトルを入力すると出力が 0 から 1 の範囲に収まるように正規化する非線形関数である。Grad-CAM は影響度を算出する過程で、任意の畳み込み層における特徴マップの、出力層の出力に対する勾配を計算する。よって、入力が小さくあるいは大きくなるほど勾配は緩やかになり、中間にあるとき勾配が最大となる。そのため、Grad-CAM の非正規化ヒートマップは、モデルの出力が中間的であるデータポイント 4 とデータポイント 17 において大きく、いずれかのクラスに対する出力が最大であるデータポイント 3 とデータポイント 16 は小さくなる。よって、Grad-CAM により得られたヒートマップは、入力データの各要素あるいは部分が持つ特徴の絶対的な強さを示さない。したがって、Grad-CAM では入力データ毎に Grad-CAM の出力の最大値で正規化することで、入力データにおける相対的な特徴の強さを表している。また、Grad-CAM の出力である影響度ヒートマップは、指定した中間層の出力がモデルの出力に対する影響度であるため、訓練者が調整すべき身体部位やタイミングを示すことができるが、具体的な目標値を示すものではない。よって、訓練者は試行錯誤的に歩容を調整し、分類結果を確認することを繰り返す必要がある。



## 第8章 身体的個人差を考慮した目標多変量歩容データの生成

拇指床間距離を決定する特徴の可視化手法によって可視化された影響度ヒートマップは、訓練者が調整すべき身体部位とタイミングを提示可能であったが、調整する方向や程度を示さない。そのため、訓練者は試行錯誤的に歩容を調整する必要性があり、効率的な歩容訓練とはいえなかった。本章では、より具体的な目標を提示するために、歩容分類モデルが学習したつまずきに関する特徴を参考にした目標歩容データの生成手法を提案し、その有効性を議論する。

### 8.1 節 身体的個人差を考慮した目標多変量歩容データの生成手法

Activation maximization は学習済みモデルが分類の根拠とする特徴を可視化する手法の一つである[52, 53, 54]。Activation maximization は学習済みの分類モデルに任意の画像やランダムノイズを入力し、そのモデルの任意の層の出力が大きくなるように、つまり特徴が活性化されるように入力を調整し、最適化する。Activation maximization の最も簡単な方法は以下の式で表される。

$$\mathbf{X}_{ij} = \mathbf{X}_{ij} + w \frac{\partial O}{\partial \mathbf{X}_{ij}} \dots\dots\dots (8.1)$$

$\mathbf{X}$ はモデルの入力を表し、 $(i, j)$ は入力データの行と列の番号、 $O$ は任意の層の出力を表す。また、 $w$ は一回の更新における調整量を決定する重みである。まず、入力行列の各要素における、任意の中間層あるいは出力層の出力に対する勾配を計算し、勾配行列を得る。この勾配行列に重み $w$ を乗じ、元の入力データに加算して入力データを更新する。また、多くの Activation maximization では、重み $w$ を乗じる前に勾配行列を正規化する。この入力データの更新を繰り返し実行することで学習した特徴を活性化させ、元の入力データを基準にした任意の層の出力が大きくなるデータを生成する。CNN の畳み込み層では、フィルタ処理によって特徴量を抽出するように学習が行われるので、Activation maximization を適用する層として畳み込み層を対象とすることで、畳み込み層が学習した特徴量を理解することができる。また、出力層の任意のクラスに対する出力を対象とすることで、入力データを基準として、対象のクラスの特徴が活性化されるように調整されたデータを生成できる。

本研究では、Activation maximization を歩容分類モデルと多変量歩容データに適用することで、訓練者の身体的個人差を考慮した各歩容変量の目標値を設定する手法を提案する(図 8.1)。訓練時に、学習済み MC-DCNN 歩容分類モデルを用いて訓練者の歩容を分類し、分類結果が「つまずきやすい歩容」クラスと判別された場合に Activation maximization を適用する。ただし、MC-DCNN モデルの出力層に用いられる活性化関数に softmax 関数を用い

る. softmax 関数の出力ベクトル  $O^{softmax}$  は入力ベクトルの各要素の指数関数の出力の比を表しており, それらの要素は分類するクラスに対応する. 本研究では, 「つまずきにくい歩容」と「つまずきやすい歩容」クラスを歩容分類のクラスとしている. そこで, これらのクラスに対応する softmax 関数の出力をそれぞれ  $O^{softmax}_{rarely}$  と  $O^{softmax}_{frequently}$  と表す. また, softmax 関数の入力ベクトルは全結合層の出力であり, 入力データが持つ各クラスの学習した特徴の強さを表す. softmax 関数の入力ベクトルは, 全結合層の出力であり, 入力データが有する各クラスの特徴強度を表している. よって, Activation Maximization によって活性化させる層の出力を  $O^{softmax}_{rarely}$  とすることで, 生成された多変量歩容データは「つまずきにくい歩容」クラスの特徴が活性化されるとともに「つまずきやすい歩容」クラスの特徴を非活性化される. この方法により生成された多変量歩容データは, 歩容訓練者の元の多変量歩容データに基づいているため, その訓練者の身体的個人差 (筋力や関節可動性) による歩容特性を考慮しているといえる.

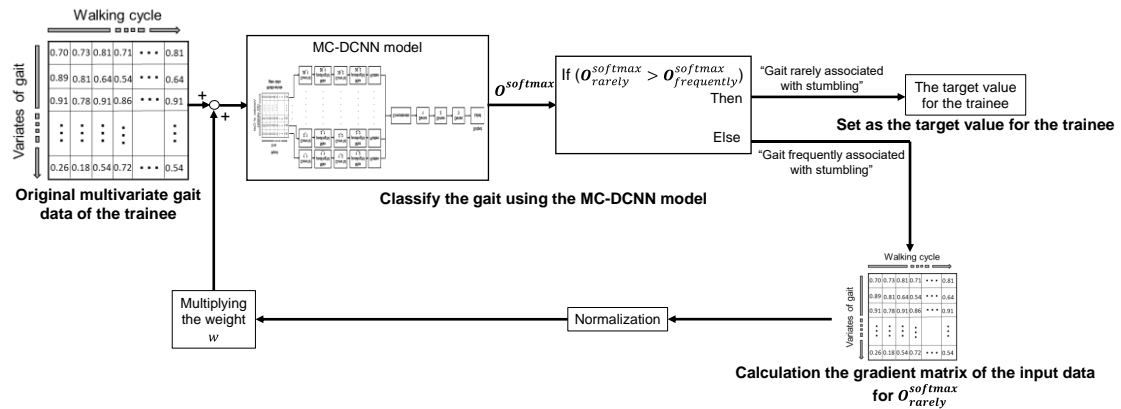


Fig.8.1 Target multivariate gait data setting method using activation maximization.

## 8.2 節 目標多変量歩容データ生成のための歩容分類モデルの構築と学習結果

多変量歩行データを入力, つまずきやすさに関するクラスを出力として, MC-DCNN を用いて「つまずきにくい歩容」クラスと「つまずきやすい歩容」クラスの特徴を学習した歩容分類モデルを構築した. 歩容分類モデルの構造を図 8.2 および表 8.1 に示す. 最適化手法を SGD, 誤差関数を categorical cross entropy, エポック数を 4,000, バッチサイズを 64 とした. 特徴箇所可視化手法の検証のために構築した歩容分類モデルでは, 中間層の活性化関数に ReLU 関数を用いたが, 本モデルでは時系列データの特徴抽出に適しているとされる tanh 関数を用いた. モデルの有用性検証のために, ホールドアウト法を参考にして, 1,548 スライド分の多変量歩容データのうち, テストセットとしてクラス毎に無作為に 10 個のデータポイントを選択した. また, テストセットを除く 1,528 個のデータポイントのうち無作為に 80%を訓練セットとし, 残りの 20%を検証セットとした. Keras の model check point 関数を用いて, 4,000 エポックの学習の中で検証セットに対する誤差関数の出力

が最も低いモデルを保存した．3,000 エポックの学習を 1 回とし，10 回学習を行った．ただし，訓練セットと検証セットの無作為な分割は 1 回の学習毎に行われた．生成した 10 個のモデルの検証セットに対する歩容分類の平均正解率は  $96.04 \pm 0.12\%$  であった．

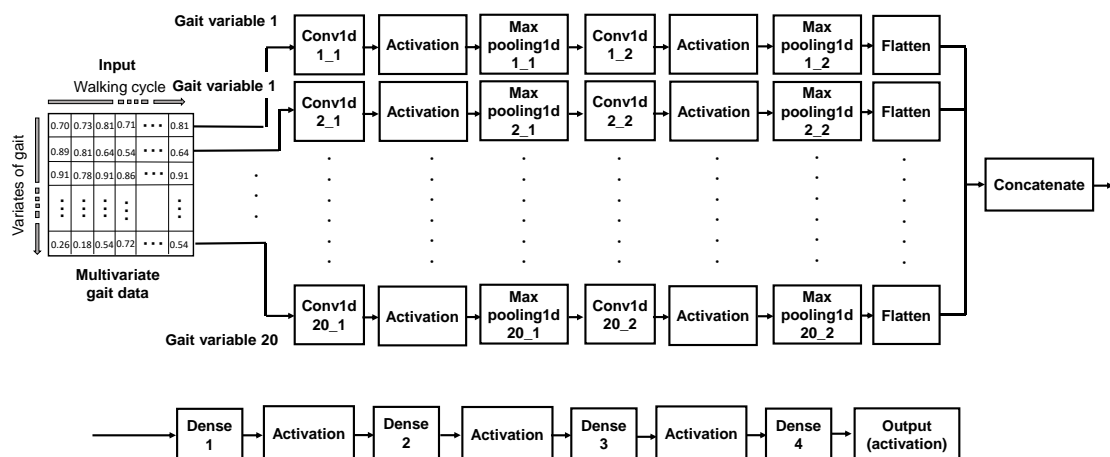


Fig. 8.2 Structure of the MC-DCNN model for gait classification.

Table. 8.1 Layer description of the MC-DCNN model for gait classification.

Layer name	Layer description
Input	$20 \times 400 \times 1$ Two-dimensional データポイント
Conv1d n_1	Filters: 32, kernel size: 25, stride: 1, padding: causal
Activation	Activation function: tanh
Max pooling1d n_1	pool size: 2, padding: valid
Conv1d n_2	Filters: 64, kernel size: 10, stride: 1, padding: causal
Activation	Activation function: tanh
Max pooling1d n_2	pool size: 2, padding: valid
Flatten	-
Dense 1	Units: 256
Activation	Activation function: tanh
Dense 2	Units: 64
Activation	Activation function: tanh
Dense 3	Units: 16
Activation	Activation function: tanh
Dense 4	Units: 2
Output	Activation function: softmax

### 8.3 節 つまづきに関する歩容の特徴を基にしたつまづきにくい歩容の生成

10 個の学習モデルのうち，検証セットに対する誤差関数の出力が最も低いモデルに対して，テストセットの 20 個のデータポイントを入力し，歩容クラスを分類した．テストセットに含まれる 20 個の多変量歩容データポイントに対する出力層の softmax 関数の出力と分類結果を表 8.2 に示す．データポイント 3 は「つまづきにくい歩容」クラスに対する出力が最も大きく (0.999870)，データポイント 16 は「つまづきやすい歩容」クラスに対する出力が最も大きい (0.999841)．また，データポイント 10 と 13 は，それぞれのクラスの手データの中で，「つまづきにくい歩容」クラスと「つまづきやすい歩容」クラスの出力が最も小さい (それぞれ 0.610133 と 0.996495)．ここで，これらの 4 つの多変量歩容データに対応する拇指床間距離を図 8.3 に示し，80%から 100%の範囲における対象脚の非正規化拇指

Table.8.2 Classification result of multivariate gait datapoint and output of softmax function using gait classification mode.

Class of input data point	Data point No.	Result of classification	$O_{rarely}^{softmax}$	$O_{frequently}^{softmax}$
“Gait rarely associated with stumbling”	1	Correct	0.999844	0.000156
	2	Correct	0.999867	0.000133
	3	<b>Correct</b>	<b>0.999870</b>	<b>0.000130</b>
	4	Correct	0.999792	0.000208
	5	Correct	0.999854	0.000146
	6	Correct	0.998480	0.001520
	7	Correct	0.999794	0.000206
	8	Correct	0.999506	0.000494
	9	Correct	0.998228	0.001772
	10	<b>Correct</b>	<b>0.610133</b>	<b>0.389867</b>
“Gait frequently associated with stumbling”	11	Correct	0.001384	0.998616
	12	Correct	0.000224	0.999776
	13	<b>Correct</b>	<b>0.003505</b>	<b>0.996495</b>
	14	Correct	0.000206	0.999794
	15	Correct	0.000281	0.999719
	16	<b>Correct</b>	<b>0.000159</b>	<b>0.999841</b>
	17	Correct	0.000349	0.999651
	18	Correct	0.000455	0.999545
	19	Correct	0.000378	0.999622
	20	Correct	0.003183	0.996817

床間距離の極大値を表 8.3 に示す． 80%から 100%の範囲における拇指床間距離では，データポイント 3 が最も高く，データポイント 16 が最も低い． また，データポイント 10 と 13 はデータポイント 3 とデータポイント 16 の中間的な値である．

「つまずきやすい歩容」クラスに対する出力が最も大きく，遊脚終期における拇指床間距離が最も低いデータポイント 16 に対して特徴活性を適用し，元のデータを基準として「つまずきにくい歩容」クラスの特徴を活性化させた多変量歩容データを生成した．ただし，勾配行列は勾配行列の各要素の絶対値の平均を用いて正規化した． また，一回の更新における調整量を決定する重み $w$ を  $5 \times 10^{-4}$ とした． Activation Maximization によるデータの更新は，各更新で生成されたデータの分類結果が「つまずきにくい歩容」クラスに切り替わった時点で終了した．

元のデータポイント 16 の各歩容変数とデータポイント 16 を基準にして「つまずきにくい歩容」クラスの特徴を活性化させた多変量歩容データの各歩容変数，および各クラスの各歩容変数の平均を図 8.4 に示す． また，それらの各非正規化歩容変数の最大値と最小値，および 80%から 100%の範囲における非正規化対象脚足関節 YZ 平面角度の極小値と 40%から 60%の範囲における非正規化非対象脚足関節 YZ 平面の極小値を表 8.4 に示す． 図 8.4 より，生成した「つまずきにくい歩容」クラスである多変量歩容データでは，データポイント 16 に対して対象脚膝関節 YZ 平面角度と対象脚足関節 YZ 平面角度の調整量が多い． 特に非正規化膝関節 YZ 平面角度の最大値において，元のデータポイント 16 が  $36.34^\circ$  なのに対し，生成された多変量歩容データは  $43.04^\circ$  だった． また，非正規化膝関節 YZ 平面角度の最小値において，元のデータポイント 16 が  $-0.40^\circ$  なのに対し，生成した多変量歩容データは  $-13.27^\circ$  だった． また，非正規化足関節 YZ 平面角度の最大値において，元のデータポイント 16 が  $14.43^\circ$  なのに対し，生成した多変量歩容データは  $19.83^\circ$  であった． 加えて，80%から 100%の範囲における非正規化足関節 YZ 平面角度の極小値において，元のデータポイント 16 が  $1.86^\circ$  なのに対し，生成した多変量歩容データは  $-16.15^\circ$  だった． その他の歩容変数についての調整量は小さかった．




Table. 8.3 The maximum non-normalized thumb-to-ground distance at the terminal swing.

Fig. 8.3 Normalized Thumb-to ground distance for the verification of generation (red is data point 3, orange is data point 10, green is data point 13, and blue is data point 16)

Class of input data point	Non-normalized		Class of input data point	Non-normalized	
	data point No.	thumb-to-ground distance of the peak in the range from 80% to 100% [mm]		data point No.	thumb-to-ground distance of the peak in the range from 80% to 100% [mm]
“Gait rarely associated with stumbling”	3	141.14	“Gait frequently associated with stumbling”	13	80.01
	10	93.91		16	59.84

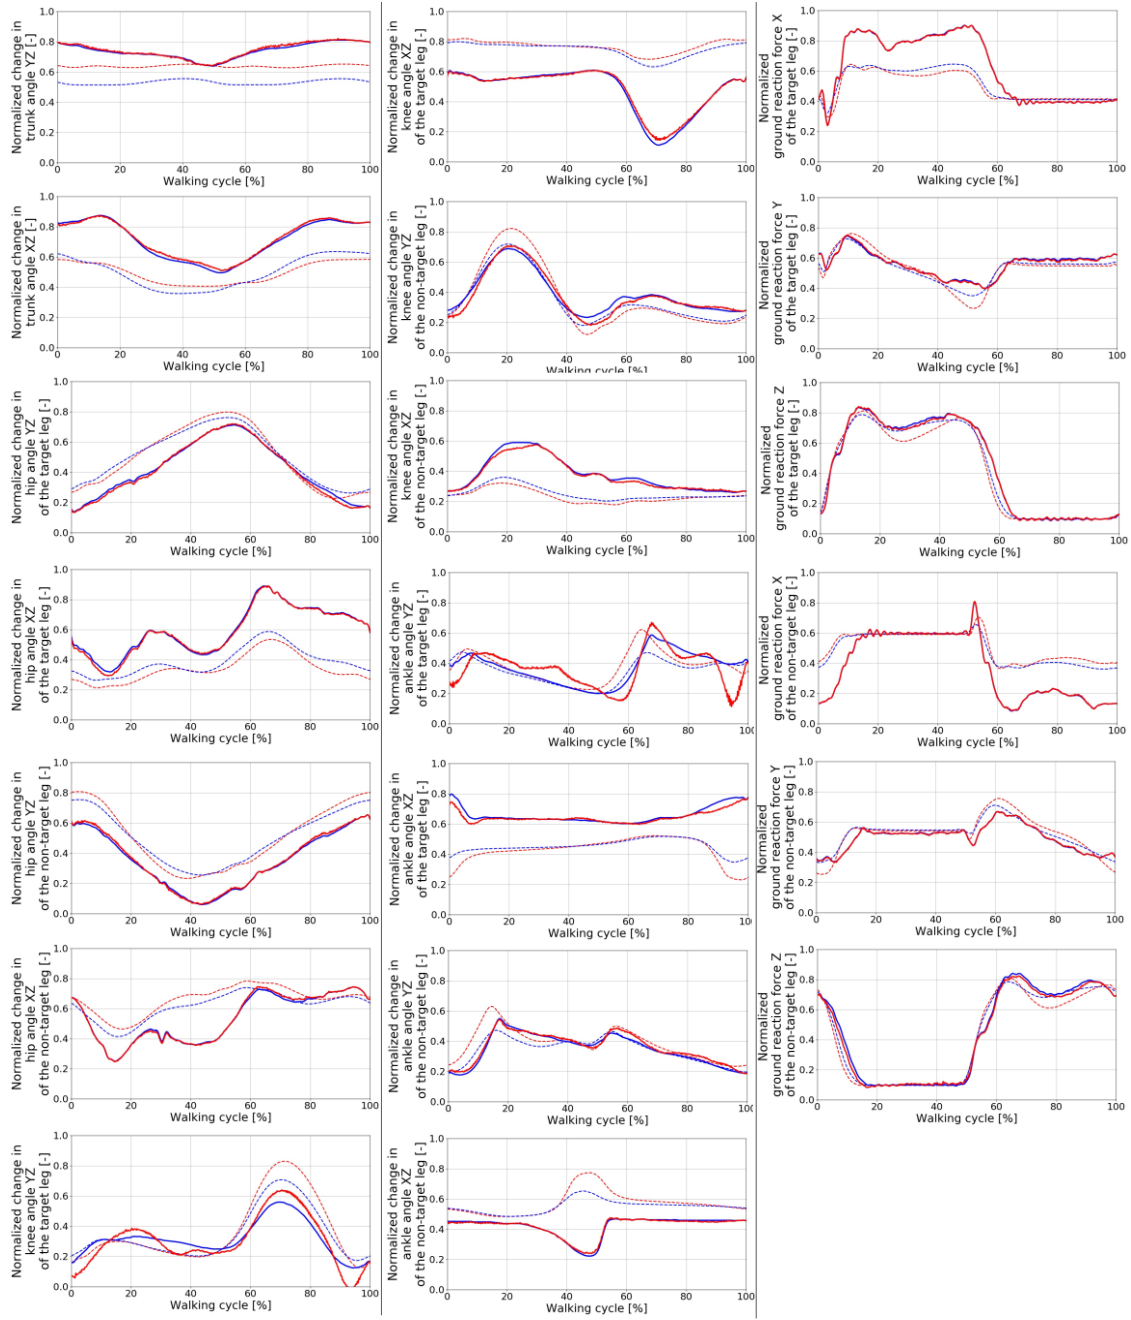


Fig. 8.4 The Mean of each variate of each class (the dotted red line is the mean of the “gait rarely associated with stumbling” class, and the dotted blue line is the mean of the “gait frequently associated with stumbling” class) and the each variate of the original data point 16 (blue line), and each variate data point generated based on the data point 16 (red line) (column 1: trunk angle in the YZ plane, trunk angle in the ZX plane, hip joint angle in the YZ plane of the target foot, hip joint angle in the ZX plane of the target foot, hip joint angle in the YZ plane of the non-target foot, hip joint angle in the ZX plane of the non-target foot, knee joint angle in the YZ plane of the target foot) (column 2:, knee joint angle in the ZX plane of the target foot, knee joint angle in the YZ plane of the non-target foot, knee joint angle in the ZX plane of the non-target foot, ankle joint angle in the YZ plane of the target foot, ankle joint angle in the ZX plane of the target foot, ankle joint angle in the YZ plane of the non-target foot, ankle joint angle in the ZX plane of the non-target foot) (column 3:, ground reaction force X component of the target foot, ground reaction force Y component of the target foot, ground reaction force Z component of the target foot, ground reaction force X component of the non-target foot, ground reaction force Y component of the non-target foot, ground reaction force Z component of the non-target foot).

Table.8.4 The maximum and minimum values of each non-normalized gait variable and the minimum value of the non-normalized ankle joint angle on the YZ plane of the target foot in the range of 80% to 100% and the minimum value of the non-normalized ankle joint angle on the YZ plane of the non-target foot in the range of 40% to 60%.

Gait variable	Original multivariate gait data of data point 16		Mean of the multivariate data of “gait rarely associated with stumbling”	
	Non-normalized maximum value	Non-normalized minimum value	Non-normalized maximum value	Non-normalized minimum value
Trunk angle on the YZ plane [°]	9.40	2.71	3.22	2.29
Trunk angle on the XZ plane [°]	12.70	−0.17	2.85	−3.19
<b>Hip angle on the YZ plane of the target leg [°]</b>	3.66	<b>−24.49</b>	7.84	<b>−20.12</b>
Hip angle on the XZ plane of the target leg [°]	15.68	−4.03	3.43	−7.67
Hip angle on the YZ plane of the non-target leg [°]	0.78	−28.32	8.28	−19.82
Hip angle on the XZ plane of the non-target leg [°]	6.14	−10.92	7.50	−3.49
<b>Knee angle on the YZ plane of the target leg [°]</b>	<b>36.34</b>	<b>−0.40</b>	<b>59.19</b>	<b>−0.32</b>
<b>Knee angle on the XZ plane of the target leg [°]</b>	<b>−9.97</b>	<b>−34.12</b>	<b>3.26</b>	<b>−6.39</b>
Knee angle on the YZ plane of the non-target leg [°]	47.20	8.77	58.43	−0.74
Knee angle on the XZ plane of the non-target leg [°]	19.55	3.51	6.53	−0.41
<b>Ankle angle on the YZ plane of the target leg [°]</b>	<b>14.43</b>	−10.49	<b>16.72</b>	−8.84
Ankle angle on the XZ plane of the target leg [°]	152.40	75.18	43.58	−71.20
Ankle angle on the YZ plane of the non-target leg [°]	12.05	−12.04	17.24	−8.32
Ankle angle on the XZ plane of the non-target leg [°]	−48.02	−145.09	72.38	−42.00
Ground reaction force X component of the target leg [%]	20.12	−8.42	8.89	−6.26
Ground reaction force Y component of the target leg [%]	16.98	−8.44	18.22	−18.26
Ground reaction force Z component of the target leg [%]	127.18	−4.15	123.39	−2.90
Ground reaction force X component of the non-target leg [%]	10.61	−20.82	6.18	−8.59
Ground reaction force Y component of the non-target leg [%]	11.27	−13.09	17.78	−19.22
Ground reaction force Z component of the non-target leg [%]	128.27	−3.06	123.04	−2.75



<b>Ankle angle on the YZ plane of the target leg in the range from 80% to 100% [°]</b>	-	<b>1.86</b>	-	<b>-2.21</b>
Ankle angle on the YZ plane of the non-target leg in the range from 80% to 100% [°]	-	0.59	-	-1.20

Gait variable	Generated multivariate gait data	
	Non-normalized maximum value	Non-normalized minimum value
Trunk angle on the YZ plane [°]	9.77	2.75
Trunk angle on the XZ plane [°]	12.67	0.27
<b>Hip angle on the YZ plane of the target leg [°]</b>	4.07	<b>-24.68</b>
Hip angle on the XZ plane of the target leg [°]	15.73	-4.94
Hip angle on the YZ plane of the non-target leg [°]	0.78	-28.32
Hip angle on the XZ plane of the non-target leg [°]	6.22	-11.03
<b>Knee angle on the YZ plane of the target leg [°]</b>	<b>43.04</b>	<b>-13.27</b>
<b>Knee angle on the XZ plane of the target leg [°]</b>	<b>-9.98</b>	<b>-32.55</b>
Knee angle on the YZ plane of the non-target leg [°]	48.88	-4.22
Knee angle on the XZ plane of the non-target leg [°]	18.86	3.67
<b>Ankle angle on the YZ plane of the target leg [°]</b>	<b>19.83</b>	-16.15
Ankle angle on the XZ plane of the target leg [°]	143.36	73.16
Ankle angle on the YZ plane of the non-target leg [°]	11.68	-11.42
Ankle angle on the XZ plane of the non-target leg [°]	-45.16	-138.63
Ground reaction force X component of the target leg [%]	20.09	-8.75
Ground reaction force Y component of the target leg [%]	17.48	-8.61
Ground reaction force Z component of the target leg [%]	128.31	-4.04
Ground reaction force X component of the non-target leg [%]	10.75	-20.67
Ground reaction force Y component of the non-target leg [%]	11.36	-13.32
Ground reaction force Z component of the non-target leg [%]	125.33	-5.00
<b>Ankle angle on the YZ plane of the target leg in the range from 80% to 100% [°]</b>	-	<b>-16.15</b>

## 8.4 節 考察

### 8.4.1 項 MC-DCNN によるつまずきに関する歩容の学習結果

本実験で構築した歩容分類モデルの平均正解率は  $96.04 \pm 0.12\%$  であり、高い分類精度であった。softmax 関数の出力は入力データが持つ各クラスの特徴の強さの指数関数の出力の比を表していることから、最も「つまずきにくい歩容」クラスに対する出力が大きいデータポイント 3 は「つまずきにくい歩容」クラスの特徴を最も有している歩容、最も「つまずきやすい歩容」クラスに対する出力が大きいデータポイント 16 は「つまずきやすい歩容」クラスの特徴を最も有している歩容であると判断された。また、データポイント 10 は「つまずきにくい歩容」クラスであるデータの中で「つまずきにくい歩容」クラスに対する出力が最も小さいことから、データポイント 10 は両クラスの間隔的な歩容であるといえる。同様にデータポイント 13 は「つまずきやすい歩容」クラスであるデータの中で「つまずきやすい歩容」クラスに対する出力が最も小さいことから、データポイント 13 は両クラスの間隔的な歩容であるといえる。拇指床間距離を比較すると、「つまずきにくい歩容」クラスに対する出力が最も高いデータポイント 3 は遊脚終期において最も高く、「つまずきやすい歩容」クラスに対する出力が最も高いデータポイント 16 は拇指床間距離が最も低い。また、各ラベルのスコアが間隔的なデータ 10 とデータ 13 はそれらの中間の高さである。学習は関節角度と床反力から成る多変量歩容データのみを用い、出力として 0 と 1 の 2 値で行ったのにも関わらず、出力層の出力は実際の拇指床間距離に相関していた。これらのことから、7 章と同様に歩容分類モデルは多変量歩容データが持つ拇指床間距離を決定する特徴を学習できたといえる。

### 8.4.2 項 目標多変量歩容データの生成による歩容訓練の有用性と課題

図 8.4 と表 8.4 から、データポイント 16 は遊脚中期において対象脚膝関節 YZ 平面角度が小さく、遊脚終期において対象脚足関節 YZ 平面角度が大きい。また、立脚終期において床反力 Y 成分の絶対値が小さい。さらに、歩行周期全体において体幹、股関節、膝関節において ZX 平面角度の変化量が大きく、足関節 ZX 平面角度は反転した値になっている。また、立脚期における床反力 X 成分が大きい。このことからデータポイント 16 の歩容は遊脚中期の膝関節屈曲と遊脚終期の足関節背屈が不十分であることが分かる。また、股関節が外転、外旋しており、足関節が外転していることが分かる。これらの結果はデータポイント 16 の実験参加者が「分回し歩行」をしていたことを意味する。訓練時に目標値として「つまずきにくい歩容」クラスの平均を訓練者に提示する方法が考えられるが、この場合データポイント 16 の実験参加者は、遊脚中期の膝関節 YZ 平面角度、遊脚終期の足関節

YZ 平面角度、床反力 Y 成分において調整を行うとともに、各関節の ZX 平面角度と床反力 X 分力に対して大きな調整を行う必要がある。しかし、データポイント 16 の歩容にみられた「分回し歩行」は遊脚中期において脚を前方に振り出す際に膝関節屈曲が十分にできないときの代替行為であり、これは拇指床間距離を増加させる動きである。よってデータポイント 16 の実験参加者に対して「つまずきにくい歩容」クラスの平均値を目標値として設定することは、訓練者個人の筋力量や関節可動性を考慮しておらず、その歩容はその実験参加者にとって無理のある歩容といえる。

一方で、図 8.4 のようにデータポイント 16 の多変量歩容データを基準にして「つまずきにくい歩容」クラスの特徴が活性化するように調整した多変量歩容データを目標値とした場合、両脚それぞれの遊脚中期における膝関節 ZX 平面角度の絶対値が小さくなるように調整されているものの、その調整量は小さい。同様にそのほかの関節の ZX 平面角度の調整量も小さい。また遊脚中期における膝関節 YZ 平面角度が大きくなるように調整されているが、その値は平均値に比べて小さい。これらのことから、生成された「つまずきにくい歩容」クラスである多変量歩容データは股関節の外転と外旋、足関節の外転（外反・内反）をデータポイント 16 の実験参加者個人に適した歩容として許容していることを示している。また、データポイント 16 を基準にして生成された多変量歩容データにおいて、遊脚終期における対象脚膝関節 YZ 平面角度が小さくなり、対象脚足関節 YZ 平面角度が小さくなるように調整されている。膝関節 YZ 平面角度の減少は膝関節の伸展を表しており、足関節 YZ 平面角度の減少は足関節の背屈を表しているため、これらの調整は遊脚終期における拇指床間距離を増加させる運動である。しかし、それらの調整量は著しく大きく、非正規化対象脚膝関節 YZ 平面角度の最小値は  $-13.27^{\circ}$  であり、正規化された値は 0 より小さい。正規化は歩容変量毎に全多変量歩容データの最大値と最小値を用いて行われており、生成された膝関節 YZ 平面角度の最小値は人間の関節運動としては不可能である。また、対象脚足関節 YZ 平面角度は関節可動域内であるが、遊脚終期の背屈量であることを考慮すると過度に背屈することを表す。したがって、本実験で生成した多変量歩容データを目標値とすると、歩行運動として不可能なあるいは不自然な歩容になる。

これは出力層の活性化関数に softmax 関数を用いているためである。softmax 関数の入力ベクトルの要素が 2 つで、一方の要素を 0 で一定としたときの他方の要素に対する出力とその導関数は図 8.5 のようになる。「つまずきにくい歩容」クラスの特徴が弱く、「つまずきやすい歩容」クラスの特徴が強いデータでは、全結合層の出力つまり softmax 関数の入力が 0 より小さい値である。データの更新が繰り返され、softmax 関数の入力が 0 に近づくにつれて、その出力に対する勾配の絶対値は非線形的に大きくなる。よって、同一入力データの勾配が大きい要素の正規化値は、勾配が小さい要素の正規化値比べて相対的に大きくなる。Activation Maximization では任意の層の出力に対する勾配を正規化し、重みを乗じて入力に加算するのみであるため、入力データの更新を繰り返すことにより、勾配が大きい要素の調整量は更新のたびに増加し、結果としてその要素は極端に調整される。本研究

で対象とする多変量歩容データが人間の運動であり，歩行は様々な歩容変数が互いに関係している連続的な運動であることを考慮すると，特定の歩行位相における歩容変数を極端に調整した場合，不可能あるいは不自然な歩容となる．そこで，各歩容変数の調整量に制約を設けることで，歩行運動として自然な調整を行う必要がある．




Fig.8.5 Softmax function output  $\mathbf{O}^{softmax}$  versus input and its derivatives. The number of elements of the input vector was 2, and if one element was set to 0, the output of the other element was used.

## 8.5 節 制約付き目標多変量歩容データの生成手法

調整量に制約を設ける方法として，各歩容変数が取り得る範囲内で調整させる方法が考えられる．例えば，多変量歩容データは関節角度を歩容変数に持つので，関節可動域を調整量の限界にすることが考えられる．しかし，関節可動域内であったとしても，歩行運動としては不自然な歩容である場合が考えられる．

そこで本研究では，勾配行列の各要素を正規化した後，制約として活性化関数に用いられることもある  $\tanh$  関数にし，その出力行列に重み  $\mathbf{w}$  を乗じてに加算する（図 8.6）．ただし，次式のように一般的な  $\tanh$  関数にパラメータ  $a$  を導入する．

$$f(x) = \frac{\exp(ax) - \exp(-ax)}{\exp(ax) + \exp(-ax)} \dots\dots\dots (8.2)$$

図 8.7 はパラメータ  $a$  を変化させたときの  $\tanh$  関数のと出力のを表している．  $a$  を大きくすると，原点付近の勾配が大きくなり，出力が 1 に漸近するの絶対値が小さくなる．正規化された勾配の絶対値が十分大きいの要素を  $\tanh$  関数にすると出力が 1 に漸近して相対的に調整量が小さくなり，一方で正規化された勾配の絶対値が小さい要素の調整量が相対的に大きくなる．したがって，この制約手法を用いることで，データの更新を繰り返す過程で十分に調整された特定の歩行位相における歩容変量の調整量

を抑制し、他の歩容変量の調整量を増加させることで、歩行運動として可能かつ自然な目標値を設定することができると思われる。

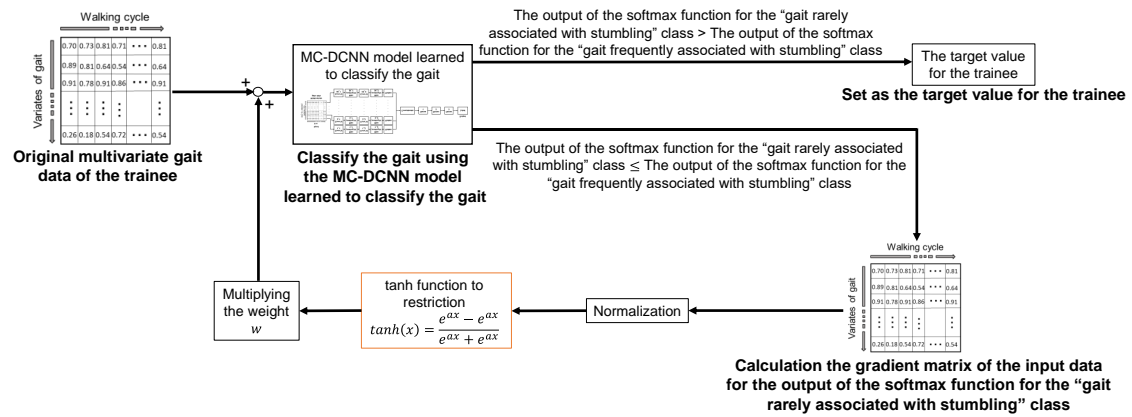


Fig.8.6 Target multivariate gait data setting method using activation maximization with restriction.




Fig.8.7 Tanh function output versus

## 8.6 節 制約付き目標多変量歩容データの生成

前述の Activation maximization の検証時に用いたデータポイントであり、「つまずきやすい歩容」クラスに対する出力が最も大きく、低い遊脚終期における拇指床間距離を有していたデータポイント 16 に対して制約あり特徴活性化手法を適用し、元のデータポイント 16 を基準として「つまずきにくい歩容」クラスの特徴を活性化させた多変量歩容データを生成した。ただし、勾配行列の正規化は勾配行列の全要素の絶対値の平均を用いて行い、一回の更新における調整量の度合いを決定する重み  $w$  を  $5 \times 10^{-4}$  とし、制約量を決定するパラメータ  $a$  を  $4 \times 10^{-1}$  とした。また、データの更新は、生成されたデータの分類結果が「つまずきにくい歩容」クラスに切り替わった時点で終了した。

図 8.8 に元のデータポイント 16 の各歩容変量、データポイント 16 を基準に「つまずきにくい歩容」クラスの特徴を活性化した各歩容変量（制約なし、制約あり）を示す。また、表 8.5 に各非正規化歩容変量の最大値と最小値、80%から 100%の範囲の非正規対象脚足関節 YZ 平面角度の最小値、40%から 60%の範囲の非正規化非対象脚足関節 YZ 平面角度の最小値を示す。制約ありで生成した多変量歩容データの非正規化対象脚足関節 YZ 平面角度の最小値は  $-7.15^\circ$  であり、非正規化対象脚足関節 YZ 平面角度の最大値は  $19.49^\circ$  であった。加えて、80%から 100%の範囲における非正規化対象脚足関節 YZ 平面角度の最小値が  $-3.32^\circ$  であった。また、他の歩容変量については、制約なしで生成した多変量歩容データと比べて調整量が大きかった。

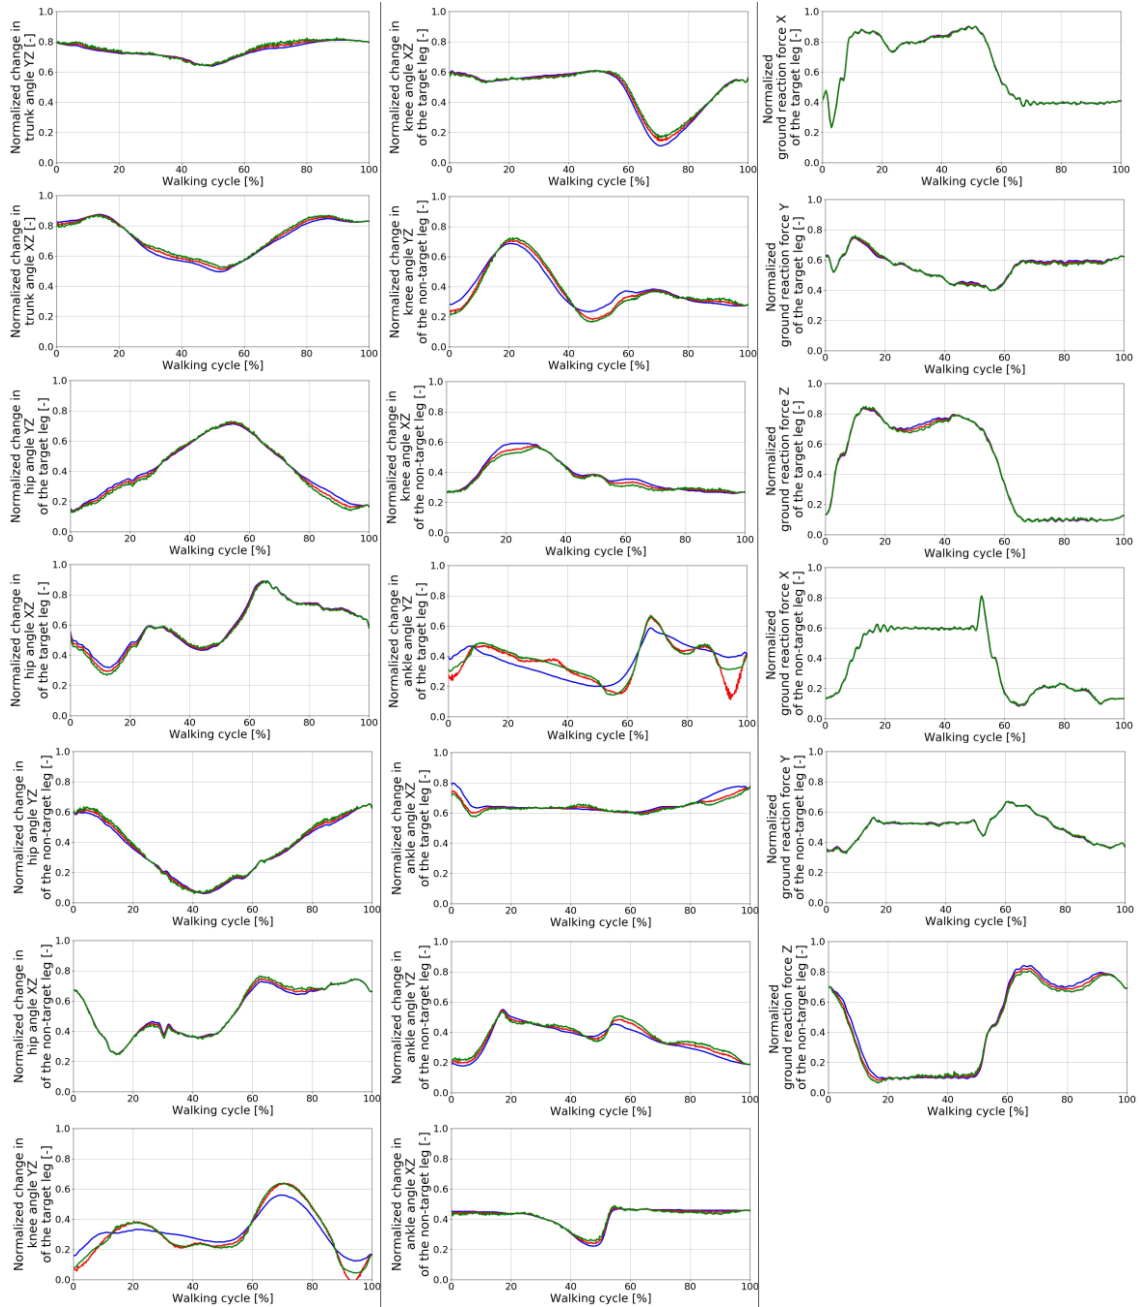


Fig. 8.8 Each variate of the original data point 16 (blue line), and each variate data generated with and without restriction based on data point 16 (red and green lines are data generated without and with restriction, respectively). (column 1: trunk angle in the YZ plane, trunk angle in the ZX plane, hip joint angle in the YZ plane of the target foot, hip joint angle in the ZX plane of the target foot, hip joint angle in the YZ plane of the non-target foot, hip joint angle in the ZX plane of the non-target foot, knee joint angle in the YZ plane of the target foot) (column 2:, knee joint angle in the ZX plane of the target foot, knee joint angle in the YZ plane of the non-target foot, knee joint angle in the ZX plane of the non-target foot, ankle joint angle in the YZ plane of the target foot, ankle joint angle in the ZX plane of the target foot, ankle joint angle in the YZ plane of the non-target foot, ankle joint angle in the ZX plane of the non-target foot) (column 3:, ground reaction force X component of the target foot, ground reaction force Y component of the target foot, ground reaction force Z component of the target foot, ground reaction force X component of the non-target foot, ground reaction force Y component of the non-target foot, ground reaction force Z component of the non-target foot).

Table 8.5 Maximum and minimum values of each non-normalized gait variable, minimum non-normalized ankle joint angle on the YZ plane of the target leg in the range of 80% to 100% and minimum non-normalized ankle joint angle on the YZ plane of the non-target leg in the range of 40% to 60%.

Gait variable	Multivariate gait data generated without limitation		Multivariate gait data generated with limitation	
	Non- normalized maximum value	Non- normalized minimum value	Non- normalized maximum value	Non- normalized minimum value
Trunk angle on the YZ plane [°]	9.77	2.75	9.96	2.77
Trunk angle on the XZ plane [°]	12.67	0.27	12.58	0.78
<b>Hip angle on the YZ plane of the target leg [°]</b>	4.07	<b>−24.68</b>	4.45	<b>−25.03</b>
Hip angle on the XZ plane of the target leg [°]	15.73	−4.94	15.78	−5.81
Hip angle on the YZ plane of the non-target leg [°]	0.78	−28.32	0.76	−28.31
Hip angle on the XZ plane of the non-target leg [°]	6.22	−11.03	6.85	−11.10
<b>Knee angle on the YZ plane of the target leg [°]</b>	<b>43.04</b>	<b>−13.27</b>	<b>42.84</b>	<b>−7.15</b>
<b>Knee angle on the XZ plane of the target leg [°]</b>	<b>−9.98</b>	<b>−32.55</b>	<b>−9.94</b>	<b>−31.39</b>
Knee angle on the YZ plane of the non-target leg [°]	48.88	−4.22	50.34	3.03
Knee angle on the XZ plane of the non-target leg [°]	18.86	3.67	18.39	3.71
<b>Ankle angle on the YZ plane of the target leg [°]</b>	<b>19.83</b>	−16.15	<b>19.49</b>	−14.17
Ankle angle on the XZ plane of the target leg [°]	143.36	73.16	143.49	64.52
Ankle angle on the YZ plane of the non-target leg [°]	11.68	−11.42	11.14	−11.46
Ankle angle on the XZ plane of the non-target leg [°]	−45.16	−138.63	−39.28	−132.58
Ground reaction force X component of the target leg [%]	20.09	−8.75	20.09	−9.06
Ground reaction force Y component of the target leg [%]	17.48	−8.61	18.18	−8.82
Ground reaction force Z component of the target leg [%]	128.31	−4.04	129.63	−4.54
Ground reaction force X component of the non-target leg [%]	10.75	−20.67	10.92	−20.62
Ground reaction force Y component of the non-target leg [%]	11.36	−13.32	11.52	−13.88
Ground reaction force Z component of the non-target leg [%]	125.33	−5.00	122.17	−8.01



Ankle angle on the YZ plane of the target leg in the range from 80% to 100% [°]	-	-16.15	-	-3.32
Ankle angle on the YZ plane of the non-target leg in the range from 80% to 100% [°]	-	-0.55	-	-1.61

## 8.7 節 調整量に対する制約の有効性に関する考察

図 8.8, 表 8.5 の制約ありで生成した多変量歩容データと制約なしで生成した多変量歩容データを比較すると, 制約ありで生成した多変量歩容データは, 遊脚終期における対象脚膝関節 YZ 平面角度が大きく, 元のデータポイント 16 からの調整量は小さい. また, 遊脚終期における対象脚足関節 YZ 平面角度がより大きく, 元のデータポイント 16 からの調整量は小さい. 一方で, 他の歩容変量における調整量が大きい. 例えば, 遊脚終期における対象脚股関節 YZ 平面角度が小さい. 股関節 YZ 平面角度の減少は股関節屈曲を表していることから, この調整は遊脚期における拇指床間距離を増加させる運動である. したがって, データポイント 16 を基準にして制約なしで生成した多変量歩容データを目標値とした場合, 遊脚終期において膝関節を関節可動域を超えて伸展させ, 足関節を過度に背屈させることで拇指床間距離を増加させるように調整するのに対し, 制約ありで生成した多変量歩容データを目標値とした場合, それらの歩容変量の調整量は歩行運動として可能な範囲に抑制され, 代わりに股関節を屈曲させて拇趾床間距離を確保するように調整を加える. よって, 元の訓練者の多変量歩容データを基準にして制約ありで「つまずきにくい歩容」クラスの特徴を活性化させて生成した多変量歩容データを訓練の目標値に設定することで, 訓練者の身体的個人差(筋力や関節の可動性)に起因する歩容特性を考慮することができ, 訓練者に自然な「つまずきにくい歩容」の指導ができると考えられる.

## 第9章 身体的個人差を考慮した目標歩容生成による歩容訓練の即時効果

本章では，第8章で提案した訓練者の身体的個人差を考慮した目標多変量歩容データ生成手法を用いた歩容フィードバック訓練システムの開発を行う．また，訓練システムを用いた一度の歩容訓練の即時効果を評価する．訓練の対象とする歩容は「つまずきやすい歩容」とする．本章では，開発した歩容フィードバック訓練システムの構成と即時効果評価実験の条件，結果を述べ，システムの即時訓練効果について議論する．

### 9.1 節 歩容訓練システムの構成と歩容訓練手順

図9.1に身体的個人差を考慮した歩容フィードバック訓練システムの構成を示し，図9.2に多変量歩容データの実測値と目標値の提示方法を示す．また，図9.3に訓練システムを用いた歩容訓練の手順を示す．このシステムは床反力計内蔵トレッドミルと光学式三次元動作解析システム，コンピュータ，ディスプレイで構成されている．このシステムは歩容訓練中，訓練者がトレッドミルの中心位置を維持するようにトレッドミルのベルト速度を自動的に調整する．また，訓練の始めに基準姿勢の多変量歩容データを測定し，訓練者が歩行中に定期的に1ストライド分の多変量歩容データを測定し，歩容分類のための前処理を行う．そして，多変量歩容データの測定毎に，事前に学習済みの歩容分類モデルを用いて訓練者の歩容を「つまずきにくい歩容」クラスか「つまずきやすい歩容」クラスに分類する．分類結果が「つまずきやすい歩容」クラスであった場合，特徴活性化による目標多変量歩容データ生成手法を用いて訓練者に適した目標値を設定し，訓練者にディスプレイ上で目標値と測定値を視覚的に提示する．訓練者は提示画像を参考に測定値を目標値に近づけるように調整を繰り返す．ただし，多変量歩容データの測定と分類，画像提示の間隔は，訓練開始後および直線の画像提示から60 s毎とし，一度の歩容訓練時間は600 sに設定した．また，提示画像上のグラフの左端は右足の初期接地の瞬間，右端は次の右足の初期接地の瞬間であり，青線は訓練者の測定値，赤線は目標値を示している．基準姿勢の定義および前処理の手順は，第6章の歩容分類モデル構築のための多変量歩容データ測定実験と同様とし，歩容訓練システムに用いる歩容分類モデルは第8章で構築したMC-DCNN歩容分類モデルとした．

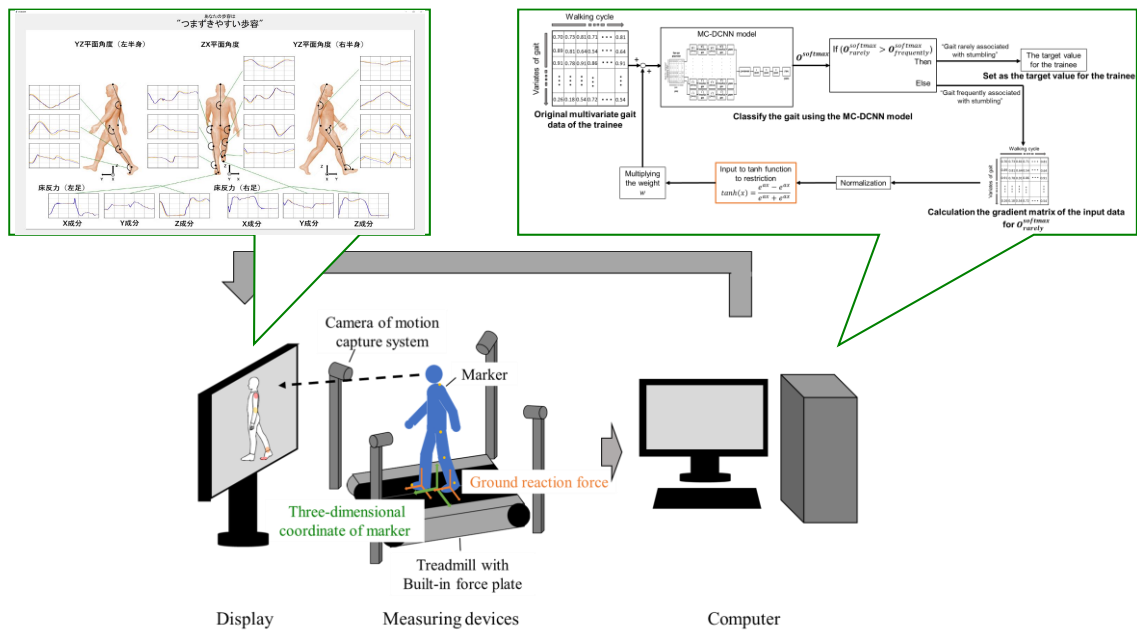


Fig. 9.1 Configuration of the training system.




Fig. 9.2 Images of target and measured values presented to the trainee.

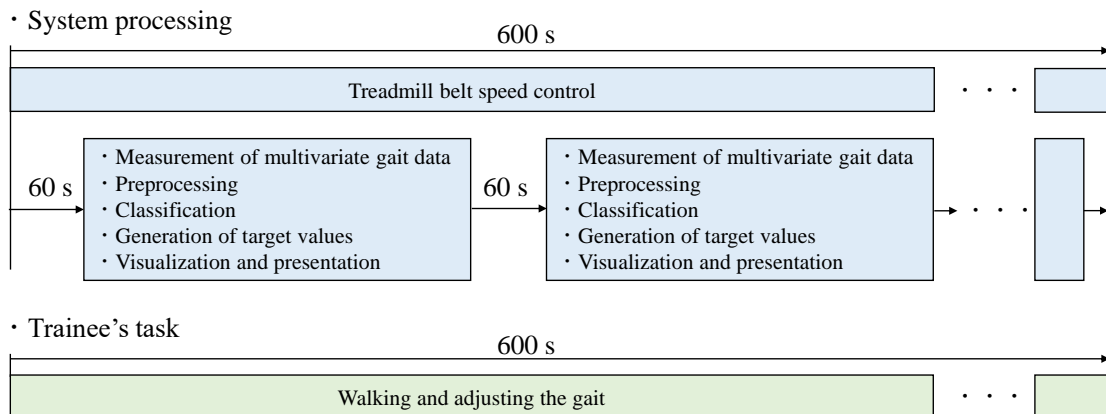


Fig. 9.3 Training setup. Training protocols.

## 9.2 節 実験条件

実験手順と訓練の様子を図 9.4 と図 9.5 に示す。実験参加者は健康な若年男性 7 名（平均年齢  $23.8 \pm 1.4$  歳）とした。歩容訓練を行う前に、実験参加者は第 6 章と同様に筋力負荷と関節可動制限を課す装具を装着した。ただし、これらの制限を課したとしても、その歩容は常に「つまずきやすい歩容」であり、歩容訓練が必要であるとは限らない。そこで予備実験として「制限歩行」時の 30 s 毎 2 ストライド分の多変量歩容データを測定、分類し、歩容が「つまずきにくい歩容」クラスである実験参加者を除外した。その結果、実験参加者は 5 名（平均年齢  $24.2 \pm 1.6$  歳）となった。歩容訓練の前に実験参加者は基準姿勢をとった後に 60 s 間トレッドミル上を歩行し、歩行開始 30 s 後から 10 ストライド分の拇指床間距離と多変量歩容データを測定した。次に個人差を考慮した歩容フィードバック訓練システムを用いてつまずきやすさに関する歩容訓練を一回行った。この間、実験参加者は測定された多変量歩容データが目標多変量歩容データに近づくように自身の歩容を調整した。そして歩容訓練後に、実験参加者は基準姿勢をとった後に 60 s 間トレッドミル上を歩行し、歩行開始 30 s 後から 10 ストライド分の拇指床間距離と多変量歩容データを測定した。全てのタスクにおいて実験参加者は好みの速さにおける自由歩行を行った。事前に、実験参加者に提示画像に関する説明を行い、「無理のない好みの速度で歩くこと」「測定値が目標値に近づくように能動的に考えて歩容を調整すること」と指示を行った。




Fig. 9.4 Training setup. Training protocols.




Fig. 9.5 Scene of training.

### 9.3 節 実験結果

各実験参加者における訓練前後の 10 ストライド分の拇指床間距離最大値の平均を表 9.1 に示す。歩容訓練の結果，全実験訓練者において左右の拇指床間距離が増加しており，右拇指床間距離が 25.23 mm，左拇指床間距離が 19.56 mm であった。また，t 検定の結果，右拇指床間距離において 5 名中 4 名に有意差が認められ，左拇指床間距離において 5 名中 5 名に有意差が認められた。

拇指床間距離の増加量が平均的である実験参加者 4 と 5 の 10 ストライド分の拇指床間距離および右関節角度の平均と，歩容分類モデルの学習に用いた「つまずきにくい歩容」クラスと「つまずきやすい歩容」クラスのそれぞれの平均値を図 9.6 に示す。ただし，グラフの横軸は右足初期接地から次の右足初期接地で区切られる歩行周期を表している。実験参加者 4 は，荷重応答期と遊脚終期の股関節 YZ 平面角度が減少，遊脚初期の膝関節 YZ 平面角度が増加，遊脚終期の膝関節 YZ 平面角度が減少，前遊脚期の足関節 YZ 平面角度が増加していた。また，遊脚初期の股関節 YZ 平面角度が増加，遊脚初期の膝関節 ZX 平面角度が減少，遊脚終期の足関節 ZX 平面角度が減少していた。一方で，参加者 5 は遊脚終期の膝関節 YZ 平面角度が減少，前遊脚期の足関節 YZ 平面角度が増加，遊脚終期の足関節 YZ 平面角度が減少していた。また，歩行周期全体を通して股関節 ZX 平面角度が減少，遊脚中期の足関節 ZX 平面角度が増加，遊脚終期の足関節 ZX 平面角度が減少していた。

Table 9.1 Average and SD of maximum thumb-to-ground distances [mm]  
(\*:  $0.01 < p \leq 0.05$ , \*\*:  $p \leq 0.05$ ).

		Before training	After training	<i>p</i> -value
Participant 1	Right foot	50.85±12.81	77.81±6.75	**
	Left foot	61.15±5.84	64.79±10.75	*
Participant 2	Right foot	52.64±7.16	96.26±4.58	**
	Left foot	39.89±5.59	86.17±11.75	**
Participant 3	Right foot	58.73±4.27	62.2±8.22	
	Left foot	71.18±5.82	82.11±9.80	*
Participant 4	Right foot	30.85±4.79	56.85±13.73	**
	Left foot	45.41±8.10	64.61±5.31	**
Participant 5	Right foot	31.34±7.55	57.44±8.01	**
	Left foot	48.26±7.01	60.99±12.67	*

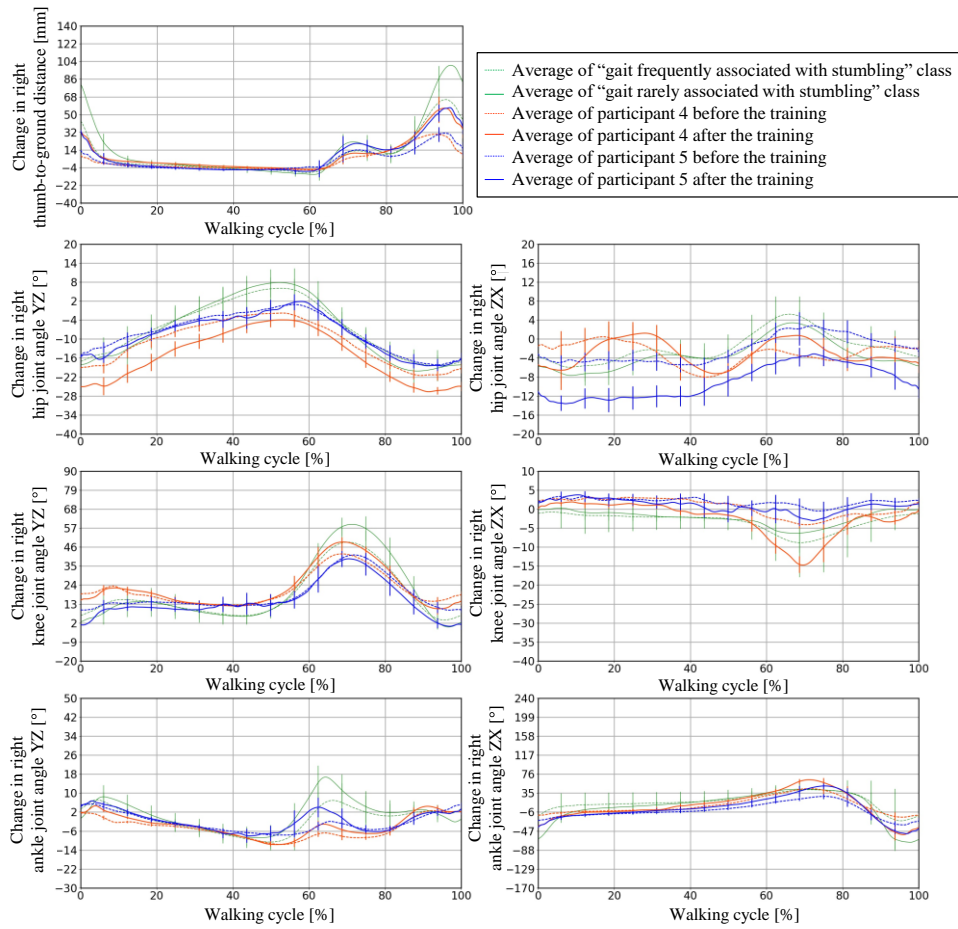


Fig. 9.6 Average right thumb-to-ground distance and right-joint angle of the data sets used in the learning model, and the data before and after training.

### 9.3 節 考察

実験の結果，提案手法を用いたつまずきやすさに関する歩容訓練によって，最大拇指床間距離が増加することを確認した．また，図 9.6 から最大値だけでなく，遊脚期全体を通して拇指床間距離が増加したことが分かる．このことから，提案手法を用いた歩容訓練により，加齢に伴うつまずきの増加のうち拇指床間距離の観点からつまずきに関する即時訓練効果が確認できたといえる．

拇趾床間距離の平均的な増加量を示した実験参加者 2 名（実験参加者 4 と 5）に着目すると，モデルの学習に用いた「つまずきやすい歩容」クラスのデータセットの平均と比較して，参加者 4 と参加者 5 はともに，訓練前の最大右拇指床間距離を示す瞬間である遊脚終期の右膝関節 YZ 平面角度が大きい．これは接地直前の膝関節が十分に伸展していないことを表している．また，遊脚終期の右足関節 YZ 平面角度に着目すると，各クラスの平均や実験参加者 4 は瞬間的に減少しているのに対し，実験参加者 5 は減少することなく右足が接地している．この瞬間的な足関節の減少は接地直前の背屈を表しており，実験参加者 5 は背屈せずに接地していることからつま先から接地していることが分かる．遊脚終期における膝関節，足関節あるいは股関節の YZ 平面角度は最大拇指床間距離を直接決定する要因であるため，股関節の十分な屈曲や膝関節の十分な伸展，足関節の背屈はつまずきやすさにおいて重要な特徴である．これに対し，遊脚終期の右膝関節が十分に伸展していなかった実験参加者 4 と 5 は両名とも膝関節が伸展するように歩容を調整した．また，実験参加者 4 は遊脚終期に股関節が屈曲するように調整した．一方で，遊脚終期の背屈がみられなかった実験参加者 5 は右足関節が背屈するように歩容を調整した．また，実験参加者 4 に着目すると，遊脚初期の右膝関節 YZ 平面角度が増加している．また，遊脚初期の右股関節 ZX 平面角度が増加，右膝関節 ZX 平面角度が減少しており，前遊脚期の右足関節 YZ 平面角度が増加していた．これは，実験参加者 4 が前遊脚期の底屈量を増加，遊脚初期に右膝関節を十分に屈曲，右脚を「分回し」させることで，前述の特徴を満たす歩容を確保していることを意味する．一方で，実験参加者 5 は前遊脚期の右足関節 YZ 平面角度が増加しており，右股関節 ZX 平面角度が歩行周期全体で小さくなっている．これは実験参加者 5 が左脚を「分回し」とするとともに駆動力を増加させることで，前述の特徴を満たす運動を確保していることを意味する．以上のことから，提案システムを用いてつまずきに関する歩容訓練を行うことで，つまずきやすさにおける重要な特徴を満たすように歩容が調整されるとともに，その運動を確保するための手段としての，その他の部位やタイミングには自由度があり，身体的個人差を考慮した歩容訓練を行うことができるといえる．

## 第10章 結論

### 10.1 節 本研究で得られた成果

本研究では、効果的かつ理学療法士を必要としない歩容訓練を行うために、機械学習によりつまずきやすさに関する歩容の特徴を参考にした、身体的個人差を考慮した歩容フィードバック訓練システムを提案した。関節と歩容について解説し、歩容フィードバック訓練システムに関する先行研究を紹介した。また、機械学習の基本的要素について解説し、機械学習の歩容フィードバック訓練への応用の有用性について考察した。そして、2種類の機械学習による身体的個人差を考慮した歩容調整内容提示手法を提案し、提案システムの即時訓練効果を議論した。

まず、つまずきやすさに関する特徴を学習するためのデータセットを作成するために、若年健常者が通常歩行と制限歩行をしている際の多変量歩容データ（関節角度と床反力）と拇指床間距離を測定した。そして、拇指床間距離を、動的時間短縮法を用いた k-means 法によりクラスタリングし、クラスタリング結果を基に対応する多変量歩容データを「つまずきにくい歩容」クラスと「つまずきやすい歩容」クラスにラベル付けした。先行研究における若年者群と高齢者群の拇指床間距離と、各クラスラベルの拇指床間距離の代表値を比較し、妥当なラベル付けであることを確認した。

次に、多変量歩容データと MC-DCNN 歩容分類モデルに特徴部位可視化手法 (Grad-CAM) を適用し、各クラスの特徴を可視化することによる身体的個人差を考慮した歩容調整内容（身体部位と歩行位相）提示手法を提案した。まず、多変量歩容データセットを訓練セットと検証セット、テストセットに分割し、訓練セットと検証セットを用いて特徴可視化による歩容調整内容提示手法の検証のための MC-DCNN 歩容分類モデルを構築し、提案手法をテストセットに適用した。歩容分類モデルは高精度で多変量歩容データを歩容を分類することができた。また、テストセットに含まれるデータの各クラスに対応する出力層の出力値が、それらの最大拇指床間距離と相関していることから、歩容分類モデルは拇指床間距離を決定する特徴を学習したことを確認した。加えて、平均値を参考に歩容訓練を行う場合と比較して、提案手法により可視化された影響度ヒートマップ画像が、身体的個人差を考慮した上で拇指床間距離を決定する重要な特徴を有する身体部位と歩行位相を提示可能であることを確認した。

また、各歩容変量の調整量に制約を設けた特徴活性化手法 (Activation maximization) を多変量歩容データと MC-DCNN 歩容分類モデルに適用し、身体的個人差を考慮した目標多変量歩容データ生成手法を提案した。まず、多変量歩容データセットを訓練セットと検証セット、テストセットに分割し、訓練セットと検証セットを用いて制約付き特徴活性化による目標多変量歩容データ生成手法の検証のための MC-DCNN 歩容分類モデルを構築し、提案手法をテストセットに適用した。歩容分類モデルは高精度で多変量歩容データをいずれかのクラスラベルに分類することができた。また、テストセットに含まれるデータの各



クラスに対応する出力層の出力値が、それらの最大拇指床間距離と相関していることから、歩容分類モデルは拇指床間距離を決定する特徴を学習したことを確認した。また、平均値を参考に歩容訓練を行う場合と比較して、提案手法により生成された多変量歩容データは、歩行として可能かつ自然な運動であり、身体的個人差を考慮した上で拇指床間距離を決定する重要な特徴を有する身体部位と歩行位相および調整量の程度を提示可能であることを確認した。

最後に、制約付き特徴活性化による目標多変量歩容データ生成手法を用いた歩容フィードバック訓練システムを開発し、このシステムを用いた一回の歩容訓練による拇指床間距離と多変量歩容データへの影響を確認した。その結果、5名中4名の実験参加者において右拇指床間距離が増加し、有意差が認められた。また5名中5名の実験参加者において左拇指床間距離が増加し、有意差が認められた。また、平均的な増加量を示した2名の実験参加者において、最大拇指床間距離を決定する重要な特徴である遊脚終期の股関節屈曲、膝関節伸展、足関節背屈が増加している一方で、それらの調整を確保するための運動には実験参加者間で自由度があることを確認した。

以上の結果から、提案システムを用いて歩容フィードバック訓練を行うことで、身体的個人差を考慮した歩容訓練を行うことができ、理学療法士の介入が必要ない歩容訓練を行うことができるといえる。歩行運動を含む運動情報フィードバック訓練システムの先行研究では訓練の対象が限定的であり、アクティブシニアなどの身体的個人差の大きい訓練者に対応できなかったため、本研究は歩容訓練の分野において有益と考えられる。また、機械学習の歩容分析への応用の観点からみても、先行研究では歩容の分類や歩行検知に用いられているのみであり、機械学習を用いることにより人間が介入することなく歩容調整内容の提示を行う本提案システムは有益である。

## 10.2 節 課題と展望

本研究で MC-DCNN 歩容分類モデルの構築とテストに用いた多変量歩容データは、通常歩行あるいは制限歩行中の若年男性 8 名の多変量歩容データを測定したものであり、この歩容分類モデルは高齢者の歩容には適用できない場合が考えられる。MC-DCNN は入力データと出力の各変量における特徴を抽出し、学習することから、多様な高齢者男女の歩容も含めた多変量歩容データを「つまずきにくい歩容」と「つまずきやすい歩容」に妥当にラベル付けし、MC-DCNN 歩容分類モデルを構築することで、アクティブシニアの歩容訓練に対しても適用可能であると期待できる。また、本研究では「つまずき」を歩容訓練の対象としてラベル付けを行ったが、その他の逸脱歩行による歩容障害（例えばエネルギーの増大や歩行速度）に対しても、測定した多変量歩容データを正しく妥当なラベル付けを行うことがすることにより適用可能であると考えられる。同様に、訓練の対象とする問題を決定し、妥当なデータセットの構築をすることで、歩容訓練だけでなく、そのほかの運動（走行やスポーツ）などの幅広い分野における訓練に適用可能であると期待できる。

## 謝辞

本論文の作成にあたり，終始熱心なご指導を頂いた埼玉大学の綿貫啓一教授，楓和憲准教授，早稲田大学の村松慶一准教授に心から感謝を申し上げます．先生方には学部の中から研究の進め方から人間を対象とした実験の組み立て，考慮すべき点などについてご助言頂きました．

早稲田大学の田中英一郎教授には，私の研究の基礎になる歩容に関する知識や歩容解析のための実験の組み立て，研究の進め方など，細部にわたるご指導を頂きました．ここに感謝いたします．

また，副指導教員である埼玉大学の山本浩教授，高崎正也教授には本論文の執筆にあたりご指導，ご助力頂きました．厚くお礼申し上げます．

本研究の趣旨を理解し，快く実験に協力して頂いた埼玉大学の学生の方々，シルバー人材センターの方々に感謝いたします．

そして，埼玉大学ヒューマンインターフェイス研究室の同窓生の皆様，卒業した学生の皆様，在学している皆様には常に刺激的な議論を頂き，精神的にも支えられました．ありがとうございます．

## 参考文献

- [1] 内閣府, 令和 2 年版高齢社会白書 (全体版), [https://www8.cao.go.jp/kourei/whitepaper/w-2020/html/zenbun/s1\\_2\\_2.html](https://www8.cao.go.jp/kourei/whitepaper/w-2020/html/zenbun/s1_2_2.html) (最終閲覧日 2021 年 6 月 4 日).
- [2] 中村隆一, 齋藤宏, 長崎浩, 基礎運動学第 6 版補訂, 医歯薬出版株式会社, 2003.
- [3] 中村隆一, 齋藤宏, 長崎浩, 臨床運動学第 3 版, 医歯薬出版株式会社, 2002.
- [4] Kirsten Götz-Neumann 著, 月城慶一, 山本澄子, 江原義弘, 盆子原秀三 訳, 観察による歩行分析, 医学書院, 2005.
- [5] L. Cohen, J. Morgan, R. Babbs Jr, T. G. Karrison and M. Giacomoni, Fast walking velocity in health and Duchenne muscular dystrophy: a statistical analysis, Arch Phys Med Rehabil, Vol.65, No.10, pp.573-578, 1984.
- [6] R. Nakamura, T. Hosokawa and I. Tsuji, Relationship of muscle strength for knee extension to walking capacity in patients with spastic hemiparesis, The Tohoku Journal of Experimental Medicine, Vol.145, Issue 3, pp.335-340, 1985.
- [7] M. Schenkman, T. M. Cutson, M. Kuchibhatia, J. Chandler and C. Pieper, Reliability of impairment and physical performance measures for persons with Parkinson's disease, Physical Therapy, Vol. 77, Issue 1, pp.19-27, 1997.
- [8] J. M. Simpson, J. Valentine and C. Worsfold, The Standardized Three-metre Walking Test for elderly people (WALK3m): repeatability and real change, Clinical Rehabilitation, Vol.16, Issue 8, pp.843-850, 2002.
- [9] 相馬正之, 吉村茂和, 寺沢泉, 歩行時における最小拇趾・床間距離の加齢の影響について, 理学療法学, Vol.31, No.2, pp.119-223, 2004.
- [10] H. Elftman, The function of the arms in walking, Human Biology, Vol.11, pp.529-535, 1939.
- [11] H. J. Ralston, Effects of immobilization of various body segments on the energy cost of human locomotion, Ergonomics, Vol.12, pp.53-60, 1965.
- [12] J. Perry and J. M. Burnfield, Gait analysis: Normal and pathological function (2nd), Slack Inc, 2010.
- [13] M. L. Ballesteros, F. Buchthal and P. Rosenfalk, The pattern of muscular activity during the arm swing of natural walking, Acta physiol scand, Vol.63, Issue 3, pp.296-310, 1965.
- [14] C. K. Battye and J. Joseph, An investigation by teleentering of the activity of some muscles in walking, Medical and biological engineering, Vol.4, pp.125-135, 1966.
- [15] A. Zijlstra, M. Mancini, L. Chiari and W. Zijlstra, Biofeedback for training balance and mobility tasks in older populations: a systematic review, Journal of NeuroEngineering and Rehabilitation volume, Vol.7, No.58, 2010.

- [16] R. Stanton, L. Ada, C. M. Dean, and E. Preston, Biofeedback improves activities of the lower limb after stroke: A systematic review, *Journal of Physiotherapy* Vol. 57, Issue 3, pp. 145–155, 2011.
- [17] 林祐一郎, 辻内伸好, 小泉孝之, 牧野裕太, 中村匠汰, 土屋陽太郎, 井上喜雄, ウェアラブルセンサとバイオフィードバック機構を統合した歩行訓練システムの評価, 日本機械学会シンポジウム: スポーツ・アンド・ヒューマン・ダイナミクス講演論文集 2013, 2013.
- [18] 安藤健, 大木英一, 中島康貴, 秋田浩, 田中理, 藤江正克, 左右分離型トレッドミルを用いた歩行相フィードバックシステム, 日本機械学会論文集 C 編, Vol.77, No.783, pp.4189-4203, 2011.
- [19] F. Casamassima, A. Ferrari, B. Milosevic, P. Ginis, E. Farella and L. Rocchi, A wearable system for gait training in subjects with Parkinson's disease, *Sensors* 2014, Vol.14, Issue 4, pp.6229-6246, 2014.
- [20] R. Richards, J. C. van den Noort, M. van der Esch, M. J. Booij and J. Harlaar, Gait retraining using real-time feedback in patients with medial knee osteoarthritis: Feasibility and effects of a six-week gait training program, *The knee*, Vol.25, Issue 5, pp.814-824, 2018.
- [21] 広川俊二, 松村公志, 今岡薫, 椿本博久, バイオフィードバックによる歩行訓練システム, *バイオメカニズム*, Vol.9, pp.197-206, 1988.
- [22] 畠田聡, 杉山圭介, 大塚作一, 澤田義則, 新井雅信, リハビリテーションにおける荷重調節歩行の訓練支援システム, 映像情報メディア学会技術報告 Vol.24.51, pp.17-24, 2000.
- [23] A. Ledebt, J. Becher, J. Kapper, R. M. Rozendaal, R. Bakker, I. C. Leenders and G. J. P. Savelsbergh, Balance training with visual feedback in children with hemiplegic cerebral palsy: effect on stance and gait, *Motor control*, Vol.9, Issue 4, pp.459-468, 2005.
- [24] 岩田浩康, 駒形亮吉, 相子文孝, 菅野重樹, 触覚バイオフィードバックに基づく歩行リハビリ支援システム: 第4報: 支持有り歩行リハビリプログラムの開発, 日本機械学会ロボティクス・メカトロニクス講演会講演概要集 2007, 2007.
- [25] R. Banz, M. Bolliger, G. Colombo, V. Dietz and L. Lünenburger, Computerized visual feedback: An adjunct to robotic-assisted gait training, *Physical therapy & Rehabilitation journal*, Vol.88, Issue 10, pp.1135-1145, 2008.
- [26] V. Krishnamoorthy, W. Hsu, T. M. Kesar, D. L. Benoit, S. K. Banala, R. Perumal, V. Sangwan, S. A. Binder-Macleod, S. K. Agrawal and J. P. Scholz, Gait training after stroke: A pilot study combining a gravity-balances orthosis, functional electrical stimulation, and visual feedback, *Journal of neurologic physical therapy*, Vol.32, Issue 4, pp.192-202, 2008.
- [27] 太田玲央, 三好扶, 米田隆志, ゆらぎ実装型健側フィードバック歩行補助装具の開発, 日本機械学会第23回バイオエンジニアリング講演会講演論文集, pp.199-200, 2011.

- [28] 富川繭, 伊藤勇飛, 上杉慎, 紀埜将, 長島拓也, 小林洋平, 武藤剛, 視聴覚情報の提示を用いた歩容フィードバック装置の提案, 情報処理学会第 78 回全国大会講演論文集, pp.345-346, 2016.
- [29] 福山慧, 池内秀隆, 足荷重のリアルタイム呈示による視聴覚フィードバック機構を有した歩行訓練システムの構築~歩行路における荷重値の出力特性について~, LIFE2016 講演予稿集, 2016.
- [30] 木村和樹, 圧力センサのフットスイッチを用いた聴覚フィードバック装置の開発と信頼性, 日本義肢装具学会誌, Vol.32, No.1, pp.45-49, 2016.
- [31] 金森敬文, Python で学ぶ統計的機械学習, オーム社, 2018.
- [32] 平井有三, はじめてのパターン認識, 森北出版株式会社, 2012.
- [33] 加藤公一, 機械学習のエッセンス 実装しながら学ぶ Python, 数学, アルゴリズム, SB クリエイティブ, 2018.
- [34] 斎藤康毅, ゼロから作る Deep Learning Python で学ぶちーぷラーニングの理論と実装, オライリー・ジャパン, 2016.
- [35] Trevor Hastie, Robert Tibshirani, Jerome Fridman 著, 杉山将, 井手剛, 神嶋 敏弘, 栗田多喜夫, 前田英作 監訳, 統計的学習の基礎 データマイニング・推論・予測, 共立出版, 2014.
- [36] 小高知宏, 機械学習と深層学習 C 言語によるシミュレーション, オーム社, 2016.
- [37] C. M. Bishop 著, 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇 監訳, パターン認識と機械学習 上 ベイズ理論による統計的学習, 丸善出版, 2012.
- [38] C. M. Bishop 著, 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇 監訳, パターン認識と機械学習 下 ベイズ理論による統計的学習, 丸善出版, 2012.
- [39] V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. Riedmiller, A. K. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg and D. Hassabis, Human-level control through deep reinforcement learning, Nature, Vol.518, pp.529-533, 2015.
- [40] H. Sakoe and S. Chiba, Dynamic programming algorithm optimization for spoken word recognition, IEEE Transactions on acoustics, speech, and signal processing, Vol. 26, pp. 43-49, 1978.
- [41] J. Paparrizos and L. Gravano, k-shape: Efficient and accurate clustering of time series, Proceedings of the 2015 ACM SIGMOD International conference on management of data, pp. 1855-1870, 2015.
- [42] P. Bholowalia and A. Kumar, EBK-means: A clustering technique based on elbow method and k-means in WSN, International journal of computer applications, Vol. 105, No. 9, pp. 17-24, 2014.

- [43] S. Ji, W. Xu, M. Yang and K. Yu, 3D convolutional neural networks for human action recognition, IEEE Transactions on pattern analysis and machine intelligence, Vol.35, Issue 1, pp.221-231, 2013.
- [44] 蛭田興明, 梁木俊湧, 高屋英知, 伊藤千輝, 荒牧大樹, 稲垣隆雄, 山岸典生, 栗原聡, 多変量時系列変数マルチチャネル変換画像分類における深層学習の適用, 人工知能学会第33回全国大会論文集, 2019.
- [45] Y. Zheng, Q. Liu, E. Chen, Y. Ge, and J. L. Zhao, Time series classification using multi-channels deep convolutional neural networks, International conference on web-age information management, pp. 298–310, 2014.
- [46] U. Martinez-Hernandez, A. Rubio-Soils and A. A. Dehghani-Sanji, Recognition of walking activity and prediction of gait periods with a CNN and first-order MC strategy, 2018 7th IEEE International conference on biomedical robotics and biomechatronics, pp. 897–902, 2018.
- [47] H. Lau, K. Tong and H. Zhu, Support vector machine for classification of walking conditions using miniature kinematic sensors, Medical & Biological Engineering & Computing, Vol. 46, pp. 563–573,
- [48] R. Begg and J. Kamruzzaman, A machine learning approach for automated recognition of movement patterns using basic kinetic and kinematic gait data, Journal of biomechanics, Vol. 38, pp.401–408, 2005.
- [49] A. J. Blake, K. Morgan, M. J. Bendall, H. Dallosso, S. B. J. Ebrahim, T. H. D. Arie, P. H. Fentem, and E. J. Bassey, Falls by elderly people at home: Prevalence and associated factors, Age and Ageing, Vol. 17, Issue 6, pp. 365–372, 1988.
- [50] 西澤哲, 長崎浩, 古名丈人, 奥住秀之, 杉浦美穂, 伊東元, 藤田祐樹, 地域高齢者を対象にした歩行時のフットクリアランスに関する研究, バイオメカニズム, Vol.14, pp.69-79, 1998.
- [51] D. Smilkov, N. Thorat, B. Kim, F. Viegas and M. Wattenberg, SmoothGrad: removing noise by adding noise, arXiv:1706.03825, 2017.
- [52] K. Simonyan, A. Vedaldi. and A. Zisserman, Deep inside convolutional networks: Visualising image classification models and saliency maps, arXiv:1312.6034, 2014.
- [53] A. Mahendran and A. Vedaldi, Visualizing deep convolutional neural networks using natural pre-images, International journal of computer vision, Vol. 120, pp. 233-255, 2015.
- [54] A. Nguyen, A. Dosovitskiy, J. Yosinski, T. Brox, and J. Clune, Synthesizing the preferred inputs for neurons in neural networks via deep generator networks, Advances in neural information processing systems 29, 29th Conference on neural information processing systems, pp. 3395–3403, 2016.
- [55] C. Pan, Y. Xu, Y. Yan, K. Gu and X. Yang, Exploiting neural models for no-reference image quality assessment, IEEE 2016 Visual communications and image processing, 2016.

- [56] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh and D. Batra, Grad-CAM: Visual explanations from deep networks via gradient-based localization, The IEEE international conference on computer vision, pp. 618–626, 2017.
- [57] 大澤優輔，綿貫啓一，楓和憲，下肢歩行軌道の評価によるつまずきの要因解析，年次大会 2017，2017 年度日本機械学会年次大会，2017.