

修士論文

IMU センサを用いた足裏荷重予測による 遅延のない下肢外骨格制御

永島 幹久

奈良先端科学技術大学院大学

先端科学技術研究科

情報理工学プログラム

主指導教員: 小笠原 司 教授

ロボティクス研究室（情報科学領域）

令和2年3月13日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士(工学) 授与の要件として提出した修士論文である。

永島 幹久

審査委員：

小笠原 司 教授	(主指導教員, 情報科学領域)
加藤 博一 教授	(副指導教員, 情報科学領域)
高松 淳 准教授	(副指導教員, 情報科学領域)
丁 明 客員准教授	(副指導教員, 情報科学領域)

IMU センサを用いた足裏荷重予測による 遅延のない下肢外骨格制御*

永島 幹久

内容梗概

近年, 外骨格ロボットアシスト装置を用いた動作補助に注目が集まっている. 中でも, 歩行の補助を対象とした下肢外骨格への需要が高まっており, 下肢外骨格の研究開発がなされている. しかし, 下肢外骨格の実用化にはいくつかの問題がある. 問題のうちの1つが外骨格が装着者補助を行う際の外骨格動作の遅延である. 外骨格の遅延は適切な補助力, タイミングの推定やモータの動作時に発生する.

本研究では, 外骨格によるアシスト時に生じる遅れを解消するために慣性計測装置 (IMU: Inertial Measurement Unit) を用いて将来の足裏荷重予測を行う. 足裏荷重は歩行に大きく関係しており, 歩行周期の推定や関節にかかる負担の推定などに用いることが可能である. IMU センサは実際の下肢外骨格にも搭載されており, 装着者や外骨格の加速度や角速度を計測しアシストに利用されている.

足裏荷重の予測手法として時系列データの推定や予測に用いられる Long Short-term Memory (LSTM) を用いた. 提案予測手法の精度検証として実際の外骨格を用いた歩行計測を行い, 自身の歩行データに基づいて将来の足裏荷重が予測が可能であることを示した.

キーワード

動作予測, 足裏荷重, 機械学習, 外骨格, IMU センサ

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和2年3月13日.

Lower-Limb Exoskeleton Control without Delay Based on Plantar Force Prediction by IMU Sensors*

Mikihisa Nagashima

Abstract

In recent years, some exoskeletons were developed. Especially some lower-limb exoskeletons that assist walking are developed. However, exoskeletons have some problems to daily use. One of the problems is a delay. The delay on exoskeleton is that exoskeletons work after human movements. And the delay appear on human motion estimation and control motors.

In this research, we proposed a novel method to predict future plantar force from Inertial Measurement Unit (IMU) sensors data based on machine learning. Plantar force is related to walking. We can estimate the gait cycle and the joint loads from the plantar force. IMU sensors are mounted on some exoskeletons. It measures the wearer and exoskeletons movement.

We used Long Short-term Memory (LSTM) for future plantar force prediction. To LSTM we can predict and estimate something from sequential data. Using LSTM we measured some subjects walking with a lower-limb exoskeleton to evaluate prediction accuracy.

Keywords:

Motion Prediction, Plantar Force, Machine Learning, Exoskeleton, IMU sensor

*Master's Thesis, Graduate School of Science and Technology, Nara Institute of Science and Technology, March 13, 2020.

目次

1. はじめに	1
1.1 研究背景	1
1.2 関連研究	2
1.2.1 動作推定	2
1.2.2 動作予測	2
1.2.3 足裏荷重	3
1.3 研究目的	3
1.4 論文構成	3
2. 足裏荷重予測手法	5
2.1 データ計測手法	5
2.1.1 足裏荷重センサ	5
2.1.2 IMU センサ	6
2.1.3 センサ取り付け位置	7
2.2 LSTM による予測手法	12
2.2.1 LSTM	12
2.2.2 使用したネットワークと設定	13
2.2.3 入力データの作成	14
3. 事前実験	16
3.1 実験条件	16
3.2 予測結果の評価法	19
3.3 事前実験の結果	21
3.3.1 自身の計測データからの予測結果	21
3.3.2 自身の計測データからの予測結果	22
3.3.3 予測に用いる過去データ長による違い	23
3.3.4 事前実験の考察	23
4. 足裏荷重予測による外骨格制御	25
4.1 システム構成	25

4.2 歩行周期におけるアシストタイミング	29
5. 足裏荷重予測実験	31
5.1 非実時間での予測	31
5.1.1 実験内容	31
5.1.2 実験結果	35
5.1.3 考察	38
5.2 実時間での使用実験	39
5.2.1 実験内容	39
5.2.2 実験結果	39
5.2.3 考察	41
6. おわりに	42
6.1 まとめ	42
6.2 今後の課題と展望	42
7. 謝辞	43
参考文献	44

目 次

1	Flow of the proposed method	4
2	Plantar sensor	5
3	IMU sensor	6
4	Mounting positions of sensors	7
5	IMU sensor position	8
6	Measured plantar force	9
7	Measured acceleration	10
8	Measured angular velocity	11
9	LSTM unit	13
10	Network for plantar force prediction	14
11	Shape of the input data	15
12	Example of Measured walking at the experiment	17
13	How to divide cross-validation at preliminary experiment	20
14	One part of the preliminary experiment force prediction result	21
15	Positions of an increased error on future force prediction	24
16	Appearance of the AWN-02	26
17	AWN-02 movement by switch	27
18	Rancho los ammigo gait cycle	29
19	Switch timing	33
20	Result of real time plantar force prediction	40

表 目 次

1	Preliminary experiment subjects data	16
2	Results of plantar force prediction in preliminary experiment	22
3	Results of other subjects plantar force prediction in preliminary ex- periment	22
4	Differences of plantar force prediction result on each input time length	23
5	Time length of required for prediction	28
6	Objectives of each gait phases	30
7	Walking with a exoskeleton experiment subjects data	31
8	Results of plantar force prediction at constrained walking	35
9	Results of plantar force prediction at random walking	36
10	Prediction timing error at constrained walking	37
11	Prediction timing error at random walking	37

1. はじめに

1.1 研究背景

近年, 外骨格ロボットアシスト装置 (以下外骨格) が注目を集めている. 外骨格の目的は多岐にわたり, 荷物運搬や, 摘果作業における姿勢保持などの動作補助 [1], リハビリテーション [2] などがある.

外骨格の中で, 人の主な行動として歩行に焦点を当て, 補助を行う下肢外骨格 [3][4][5] が研究, 開発されている. 研究開発されている外骨格はそれぞれの目的を達成するために人の動作や力を計測し, 計測されたデータを基に装着者の動きに適切な制御を目指している. しかし, 下肢外骨格の実用化にはいくつかの課題が存在する. その課題の 1 つが補助の遅延問題である. 下肢外骨格の歩行補助における遅延とは, 外骨格の補助タイミングが人の動くタイミングから遅れてしまい, 適切な補助を行うことができない問題である. また, 遅延により動作が阻害され, 装着者の疲労が蓄積してしまうこともある. 遅延問題にはいくつかの原因がある. 例えば外骨格が補助を行うタイミングや力を決定するための計算時間による遅延, 補助する際のモータの遅延などである. 下肢外骨格実用化に向けて, 補助を行う際に発生する遅れを解消する動作予測の研究 [6] が行われている. また, 脳波 (EEG: Electroencephalogram) を用いた動作推定 [7] や筋電図 (EMG: Electromyography) を用いる動作推定 [8] が研究されている. EEG や EMG は動作に先行して発生するため, 事前に動作を予測することが可能となる. そのため, 遅延の無い外骨格制御が可能となる. しかし, 同じ動作でも疲労などによって検出される信号が変化する [9] ことや, 発汗に対する対策 [10] が必要であること, 動作に対して多くの筋が関係するため, 複数の電極を皮膚表面に貼付しなければならないなど, 使用状況が限られる場合がある.

本研究では, 歩行動作に注目し, 外骨格による遅延の少ないアシストを実現するために, 実際の外骨格にも用いられており [4], 取り付けが容易な慣性計測装置 (IMU: Inertial Measurement Unit) から計測されたデータを基に将来の人の状態の予測を行う. 予測するデータとしては, 足裏荷重を対象とした. 足裏荷重は膝のモーメント推測 [11] や, 歩行周期の推測 [12] などに用いられ, 外骨格による補助タイミングや補助力の決定の際に有用である.

1.2 関連研究

本研究では人の足首の加速度情報から将来の足裏荷重推定, 予測を同時に行う. そこで関連の研究として, 計測された情報から他の部位の情報を推定する研究, 計測されたデータから将来の動作予測を行う研究, 足裏荷重に関する研究を示す.

1.2.1 動作推定

Li ら [13] は脛部に取り付けた IMU センサから取得したデータを基に被験者の歩行速度と被験者が歩行している地面の傾斜角度の推定を実現した. また, 歩行を 1 歩ごとに分けることが可能であり, IMU センサの下肢外骨格等への実装の可能性を示唆した. しかし, 実験環境がトレッドミル上であるため, 加速度の値が実際とは異なるなどの問題も含んでいた. Karatsidis ら [14] は IMU 式モーションキャプチャシステムを用いて足裏に発生する床からの反力やせん断力の推定を高い精度で実現した. これらの研究が示すように IMU センサによる動作計測によって動作や発生する力の推定が可能である.

1.2.2 動作予測

堀内ら [15] は Kinect により計測された関節点から Deep Neural Network (DNN) を用いることで 0.5 秒後の関節位置の予測を行っている. Tang ら [16] は光学式モーションキャプチャシステムにより計測された全身の動作から動きの無い関節情報を取り除き, Recurrent Neural Network (RNN) を用いて高速に将来の全身関節位置を予測する手法を提案している. 人の動作は連続的なものであるため, 機械学習などの予測手法を用いると, 計測された動作情報から将来の動作情報を予測できる可能性がある. しかし, このような動作予測の研究の多くは外部に取り付けたカメラからの全身の情報をを用いて将来の動作予測を行うため, 外骨格利用時には環境が制限されてしまう可能性がある. そのため, 外骨格でを使用することを想定する場合は使用場所を選ばないウェアラブルセンサを用いた予測ができることが望ましい.

1.2.3 足裏荷重

足裏荷重を知ることによって、人体の動作や負担を推測する研究がある。Sim ら [17] は足裏の複数点に発生する垂直床反力方向の力から床に発生する足の前後方向、左右方向のせん断力の推定を行った。Favre ら [11] はフォースプレートを使用し足裏荷重を計測することで膝の内転モーメントを推定し、歩行時に発生する膝の負担を算出した。Yu ら [12] は自作した足裏荷重センサを用い、歩行中の足裏荷重を継続して計測することで、歩行を歩行周期における各位相ごとに分割した。Truong ら [18] は足裏荷重と靴内に挿入した IMU センサから取得できる 3 軸の加速度を基に被験者の歩数と移動距離を推定している。

足裏荷重から様々な情報を推定することが可能である。また、足裏荷重から予測可能である床と足裏の間で発生するせん断力や膝に発生するモーメントは人の推進力に関係するため、外骨格でのアシスト力の決定に用いることができ、歩行位相や移動距離は外骨格がアシストを行うタイミングの決定に用いることが可能である。そのため、足裏荷重は外骨格制御において有用な情報である。

1.3 研究目的

本研究の目的は容易に取り付けが可能であり、実際の外骨格にも組み込まれている IMU センサから、外骨格でのアシストタイミング決定に用いることのできる足裏荷重を予測することである。ウェアラブルセンサで装着者の将来の動作などの情報を予測することができれば、外骨格によるアシスト時に発生する遅れを解消できると考えたためである。

1.4 論文構成

提案手法の流れは Fig. 1 に示すように、IMU センサと足裏荷重センサを用いて計測を行い、得られたデータから加速度、角速度による足裏荷重予測モデルを作成する。その後、加速度、角速度から足裏荷重を予測し、予測された足裏荷重が外骨格による歩行補助に利用可能であるかを検証する。本論文において 2 章ではデータの計測法、並びに足裏荷重の予測法について、3 章では事前実験、4 章では足裏荷重予測に基づいた外骨格の制御について、5 章では評価実験について述べる。




Fig. 1 Flow of the proposed method

2. 足裏荷重予測手法

歩行時の足裏荷重をIMU センサを用いて予測するために, IMU センサと足裏荷重センサによる歩行計測を行った. 予測のための計測手法と計測データを用いた予測手法について述べる.

2.1 データ計測手法

2.1.1 足裏荷重センサ

歩行中の足裏荷重計測を行うために用いた足裏荷重センサ (Loadsol, novel Inc.) を Fig. 2 に示す. Loadsol にはいくつかのタイプが存在するが, 今回使用したものは Fig. 2 に示すように, つま先, 中央, かかとの3か所で足裏荷重の計測が可能なものである. Loadsol の計測可能な周波数は 100~200 [Hz] であり, 本研究では 100 [Hz] で計測を行った.




Fig. 2 Plantar sensor

2.1.2 IMU センサ

Fig. 3 に歩行中の脚の動作を計測するために用いた IMU センサ (TSND-151, ATR-Promotions Inc.) を示す. TSND-151 は 3 軸加速度センサ, 3 軸ジャイロセンサ, 3 軸地磁気センサを搭載した 9 軸のセンサユニットである. また, 本センサユニットは加速度と角速度から姿勢クォータニオン値を算出できる. 本研究では加速度と角速度のみを用いた. また, TSND-151 の加速度, 角速度における計測可能な周波数は 4~1000 [Hz] であり, 本研究では 100 [Hz] で計測を行った.



Fig. 3 IMU sensor

2.1.3 センサ取り付け位置

足裏荷重センサとIMUセンサをFig. 4に示すように靴の中と両方の足首にそれぞれ取り付ける。IMUセンサは予測を行う足裏の近くであり、足に伝わる体の傾きなどを計測できる位置であるFig. 5のような前脛骨腱と外果の間にIMUセンサ付属のバンドで固定した。Fig. 4のセンサ位置で計測した歩行時の足裏荷重の分布の例をFig. 6に示す。また、IMUセンサにより計測された加速度と角速度をFig. 7, Fig. 8に示す。Fig. 6～Fig. 8では被験者が直立状態より左足から歩き出し、6歩歩いた後、直立状態で静止した時の計測されたデータを示している。計測された歩行のデータから、計測されるデータが周期的であること、歩き始めにおいて足裏荷重が0 [N]になる前に一度増加すること [19] が見て取れる。




Fig. 4 Mounting positions of sensors




Fig. 5 IMU sensor position




Fig. 6 Measured plantar force




Fig. 7 Measured acceleration




Fig. 8 Measured angular velocity

2.2 LSTM による予測手法

2.2.1 LSTM

本研究では過去 n フレーム分の IMU センサ計測データ $\mathbf{x}[t], \mathbf{x}[t-1], \dots, \mathbf{x}[t-n+1]$ から s フレーム後の足裏荷重センサ計測データ $\mathbf{y}[t+s]$ を予測する.

$$\hat{\mathbf{y}}[t+s] = f(\mathbf{x}[t], \mathbf{x}[t-1], \dots, \mathbf{x}[t-n+1]). \quad (1)$$

式 (1) において $\mathbf{x}$ は 2 つの IMU センサの 3 軸加速度と 3 軸角速度の情報を含む 12 の特徴量を含んでおり, $\hat{\mathbf{y}}$ は両足 3 カ所ずつの足裏荷重情報 6 特徴量を含んでいる. 足裏荷重予測を行うにあたり, Long Short-Term Memory (LSTM)[20][21] を用いた. LSTM は Recurrent Neural Network (RNN)[22] の一種であり, 初期の RNN において問題となっていた勾配消失を解消するために入力ゲート, 出力ゲート, 忘却ゲートの 3 つのゲートを持ち, 出力を調整することができる. LSTM は時系列データの分類, 予測が可能であり, 手書き文字認識 [23] や音声認識 [24], リアルタイムの交通流予測 [25], 動作予測 [26] などに利用されている.

LSTM のユニット内を Fig. 9 に示す. またユニット内部での動作は次のように表される.

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f), \quad (2)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i), \quad (3)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o), \quad (4)$$

$$\mathbf{c}_t = \mathbf{f}_t \otimes \mathbf{c}_{t-1} + \mathbf{i}_t \otimes \tanh(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c), \quad (5)$$

$$\mathbf{h}_t = \mathbf{o}_t \otimes \tanh(\mathbf{c}_t). \quad (6)$$

式 (2)～式 (6) において $\mathbf{x}_t$ は LSTM ユニットへの入力ベクトル, $\mathbf{f}_t$ は忘却ゲートの活性化ベクトル, $\mathbf{i}_t$ は入力ゲートの活性化ベクトル, $\mathbf{o}_t$ は出力ゲートの活性化ベクトル, $\mathbf{h}_t$ は LSTM ユニットの隠れ状態ベクトル, $\mathbf{c}_t$ はセル状態ベクトルをそれぞれ示しており, $\mathbf{W}$ と $\mathbf{b}$ は訓練中に学習される重み行列とバイアスベクトルである.




Fig. 9 LSTM unit

2.2.2 使用したネットワークと設定

本研究ではPythonの機械学習ライブラリであるkerasのLSTMを用いて予測を行った。本研究で使用したネットワークをFig. 10に示す。ネットワークの構造はLSTM層が1層、次元圧縮のための隠れ層が1層である。入力には2つのIMUセンサから取得できる加速度、角速度の12次元のデータである。また、kerasのLSTMでは入力するデータ長を変更できるため、過去30フレーム分(0.3秒分)を入力データとした。出力は両足の足裏荷重センサ計6カ所分の予測される将来計測データ1フレーム分である。

入力データとなる加速度、角速度のデータと出力の正解データとなる足裏荷重計測データに対しては平均0, 分散1となるように標準化を施した。正解データの足裏荷重が標準化されているため、予測される足裏荷重も標準化されている。予測される標準化された足裏荷重を元の足裏荷重と同じスケールに戻すために正解データの標準化を行う際に作成した標準化スケーラを用いて逆変換を施した。LSTM層内のユニット数は100であり、隠れ層のユニット数は50である。活性化関数はランプ関数(ReLU)を用いており、損失関数は平均二乗誤差(MSE)を用いた。




Fig. 10 Network for plantar force prediction

2.2.3 入力データの作成

学習に用いる入力データセットは Fig. 11 に示すようにデータ数 N , 入力する過去データの長さ n , 加速度と角速度のデータ (12 特徴量) として 3 次元配列 $(N, n, 12)$ になるように整形を行う. また, データは 0.01 秒分 (1 フレーム) ずつずらすことで入力するデータを作成した. 予測の正解は入力データ N ごとに予測される時間 s 分先の標準化された足裏荷重データ (6 特徴量) をまとめて 2 次元配列 $(N, 6)$ に整形を行う.




Fig. 11 Shape of the input data

3. 事前実験

足裏荷重の予測が可能であることを確認するために3人の被験者(年齢 24.0 ± 0.81 才, 男性, 体重 71.5 ± 10.1 [kg], 身長 170.2 ± 0.82 [cm])において歩行計測を行った. 被験者の身体情報を Table 1 に示す.

3.1 実験条件

人が歩き出してから4歩目付近までの歩行は安定しない歩行である [19]. 安定しない歩行からの歩行終了と, 安定した歩行からの歩行終了の両方を計測するために以下のような条件で各被験者ごとに10試行の計測を行った.

被験者が直立した状態で計測を開始する. 被験者は自身のタイミングで歩き始め, 2歩歩き, その後直立の状態で静止する. また被験者自身のタイミングで歩き始め, 3歩歩き, 直立の状態で静止する. さらに歩く歩数を1歩ずつ増加させ, 8歩歩いた後に立ち止まり, 静止した状態で計測を終了した. この2歩から8歩まで増加する歩行を1試行とした. また計測した10試行のうち前半の5試行では被験者は常に右足から歩き始め, 後半の5試行では左足から歩き始めた. 実験時の歩数のイメージを Fig. 12 に示す. Fig. 12 は右足から歩き出す試行のイメージであり, 橙色の部分歩いた1歩を示している. 黒色は接地し続けていた足を示している.

Table 1 Preliminary experiment subjects data

Subject	Weight [kg]	Height [cm]
A	62.2	169
B	66.8	170
C	85.5	171




Fig. 12 Example of Measured walking at the experiment

IMU センサにより計測されたデータから足裏荷重の予測を行う。事前実験において次の3つの検証を行った。

自身の歩行計測データからの足裏荷重予測

1人の被験者から計測したセンサデータを用いて0.01～0.4秒後の足裏荷重予測を行うモデルを作成し、モデル作成に用いた被験者のIMUセンサ計測データから足裏荷重を予測した。また予測された足裏荷重の精度検証を行った。

他被験者の歩行計測データからの足裏荷重予測

2人の被験者から計測されたセンサデータを用いて0.01～0.4秒後の足裏荷重予測を行うモデルを作成し、モデル作成に用いなかった被験者のIMUセンサ計測データから足裏荷重を予測した。また予測された足裏荷重の精度検証を行った。

提案手法における過去の使用時間長による違い

提案手法による足裏荷重予測を行うにあたり、使用するIMUセンサ計測データの長さによる精度の違いを検証するためにLSTMの短期記憶として過去の0.01～0.4秒間のIMUセンサ計測データを用いて0.2秒後の足裏荷重予測を行った。予測は被験者自身の計測データによって作成されたモデルを用いて行った。

3.2 予測結果の評価法

各被験者ごとに 10 試行のうち 8 試行分の計測データをテストデータとして歩行中の足裏荷重を予測するモデルを提案手法にて作成した。学習したモデルを用いて残り 2 試行分をテストデータとして足裏荷重の予測を行った。また、テストデータとする試行を入れ替え、5 分割交差検定を行った。学習とテストに用いたデータの分け方を Fig. 13 に示す。

各被験者ごとの予測誤差は平均平方二乗誤差 ($RMSE$: Root Mean Squared Error) によって評価した。 $RMSE$ は次の式で求められる。

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\mathbf{y}[t] - \hat{\mathbf{y}}[t])^2}. \quad (7)$$

$RMSE$ の値は計測されるは被験者の体重に影響されるため、各センサの最大値で $RMSE$ を割った $RMSE$ の割合 $RMSEp$ を用いて評価する。 $RMSEp$ は次の式で表される。

$$RMSEp (\%) = \frac{RMSE}{\max(\mathbf{y})} \times 100. \quad (8)$$

また、予測の当てはまりの良さを示す決定係数 (R^2) も算出した。 R^2 は計測値 $y[t]$, 予測値 $\hat{y}[t]$, 計測値の平均 $\bar{y}$ から次の式で表される。

$$R^2 = 1 - \frac{\sum_{t=1}^N (\mathbf{y}[t] - \hat{\mathbf{y}}[t])^2}{\sum_{t=1}^N (\mathbf{y}[t] - \bar{\mathbf{y}})^2}. \quad (9)$$

	Trial 1	Trial 2	Trial 3	Trial 4	Trial 5	Trial6	Trial7	Trial 8	Trial9	Trial 10
Test 1	Test	Train				Test	Train			
Test 2	Train	Test	Train				Test	Train		
Test 3	Train		Test	Train				Test	Train	
Test 4	Train			Test	Train				Test	Train
Test 5	Train				Test	Train				Test

Fig. 13 How to divide cross-validation at preliminary experiment

3.3 事前実験の結果

3.3.1 自身の計測データからの予測結果

提案手法によって予測された足裏荷重の例として, 0.2秒後の予測の一部を Fig. 14 に示す. Fig. 14 は被験者が直立静止状態から6歩歩いてから立ち止まり静止している部分である. Fig. 14 は上から左足つま先部分, 左足中央部分, 左足かかと部分, 右足つま先部分, 右足中央部分, 右足かかと部分の提案手法により予測されたデータと足裏荷重センサによる計測データを示しており, 赤色実線が予測データ, 青色破線が計測データである. 予測された足裏荷重データが計測された足裏荷重データに追従していることが確認できる.




Fig. 14 One part of the preliminary experiment force prediction result

各被験者ごとに被験者自身から計測されたセンサデータを用いた 0.01～0.4 秒後の足裏荷重予測の結果を Table 2 に示す. Table 2 は 3 人の被験者における予測結果の $RSME$ と R^2 の平均, $RMSEp$ の調和平均を示している.

3.3.2 自身の計測データからの予測結果

被験者 2 人の 4 試行ずつ, 計 8 試行の計測データから作成したモデルを用いてモデル作成に用いなかった被験者の足裏荷重予測を行った結果を Table 3 に示す.

Table 2 Results of plantar force prediction in preliminary experiment

Predicted future [s]	$RMSE$ [N]	$RMSEp$ [%]	R^2
0.01	57.8	8.22	0.824
0.1	66.0	9.14	0.789
0.2	70.9	9.86	0.758
0.3	77.0	10.7	0.713
0.4	81.9	11.4	0.673

Table 3 Results of other subjects plantar force prediction in preliminary experiment

Predicted future [s]	$RMSE$ [N]	$RMSEp$ [%]	R^2
0.01	88.6	12.6	0.612
0.1	98.6	13.8	0.544
0.2	110	15.1	0.483
0.3	126	17.6	0.407
0.4	145	20.2	0.253

Table 4 Differences of plantar force prediction result on each input time length

Used past data [s]	$RMSE$ [N]	$RMSE_p$ [%]	R^2
0.1	80.5	11.2	0.712
0.2	73.3	10.2	0.745
0.3	70.9	9.86	0.758
0.4	70.1	9.76	0.771

3.3.3 予測に用いる過去データ長による違い

提案手法では入力としたIMUセンサ計測データの長さによって予測の精度に差が出る。そのため、予測に用いるデータの長さによる予測精度の違いを Table 4 に示す。

3.3.4 事前実験の考察

Table 2, Table 3 に示したように予測される時間が長くなるほど予測の精度は低下する。Fig. 15 に被験者自身のデータを用いた 0.4 秒後の予測の一例を示す。Fig. 15 に示すようなピークの位置ずれや、ピーク時点の大きさに差が発生する部分の出現頻度が増加し $RMSE$, $RMSE_p$ が増加する。また、他人の計測データを用いて作成した足裏荷重予測モデルを用いて予測を行うと、自身の計測データを用いた予測より $RMSE_p$, R^2 が大きく下がり、波形の予測ができているとは言えない。これは人の歩行における動きは大きく見れば共通しているが、脚の振出角度などは異なるためである。多くの被験者において歩行計測を行い、学習データの幅を広げると未知の被験者に対する足裏荷重予測ができる可能性もあるが、本論文では、学習データは被験者自身の計測データを用いることとした。




Fig. 15 Positions of an increased error on future force prediction

4. 足裏荷重予測による外骨格制御

足裏荷重を用いて下肢外骨格を制御する場合, 使用する下肢外骨格の形状や補助を行う目的, 動作などによってタイミングが異なる. また, 外骨格内で発生する遅延によってどれだけ先を予測しなければならないかが変わる.

本研究では株式会社ATOOUNのAWN-02を用いて足裏荷重予測の効果検証を行う.

4.1 システム構成

AWN-02の外観をFig. 16に示す. AWN-02は腰から大腿にかけての動作を補助する外骨格であり, 左右のモータが作動することで装着者の動作補助を行う. AWN-02は左右のモータを同時に動かすことで重量物の持ち上げ動作のアシストを行う製品のプロトタイプである. また, 左右を歩行に合わせて動かすことで大腿部を持ち上げるように力をかけ, 歩行アシストが可能である. AWN-02自体の重量は9.8 [kg]である.

本実験のためにAWN-02外部にスイッチを2つ実装した. スイッチを操作することによってFig. 17の様にAWN-02のモータを動作させることが可能である. このスイッチを用いて自身のアシストが欲しいタイミングで補助を行うことが可能である. AWN-02を使用する際に, AWN-02内部で予測などを行わず, 外部からの信号を受け取り補助を行う場合, 信号を受け取ってから補助力を発生するまでに0.05秒~0.15秒程度の遅延が発生する. この遅延は目標とする力や角度により変化する. 本研究では外部からの信号によって実時間でAWN-02を使用するためにRaspberry Pi 3Bを用いた. Raspberry Pi 3Bを用いて計測, 予測を行い, 予測されるアシストタイミングで信号をAWN-02に送る. その後AWN-02がアシストを行う.



Fig. 16 Appearance of the AWN-02



Fig. 17 AWN-02 movement by switch

本論文で提案する手法での予測に要する時間は, どれだけ過去のデータを入力とするか, どの程度の性能の機器で予測するかによって左右される. 今回, 実際に足裏荷重予測に基づいて AWN-02 を動作させる場合は Raspberry Pi 3B を用いて予測を行う. この環境上での予測にかかる時間を Table 5 に示す. 予測に用いた時間は 0.01 ~ 0.4 秒分であり, 予測される時間は 0.2 秒後である. Table 5 は 20 回予測を行い 1 回の予測にかかった時間の平均値である. AWN-02 内に発生する遅れが 0.05 ~ 0.15 秒程度であるため, 0.2 秒後を予測するとした場合は過去 0.03 秒分を用いた予測を行うことが可能である.

Table 5 Time length of required for prediction

Used time [s]	Prediction time [s]
0.01	0.010
0.1	0.018
0.2	0.024
0.3	0.035
0.4	0.042

4.2 歩行周期におけるアシストタイミング

下肢外骨格による歩行のアシストを考える場合は歩行の中でどのタイミングにアシストをするかを決定する必要がある．歩行解析において広く用いられるランチョ・ロス・アミーゴ方式 [27] では歩行周期を位相ごとに Fig. 18 のように分ける．さらに各位相の目的を Table 6 に示す．Fig. 18 に示すように，Initial swing (ISw) から Terminal swing (TSw) までは遊脚期と呼ばれる．大腿を持ち上げることで歩行を補助する AWN-02 の補助は遊脚を対象としている．遊脚期のうち Table 6 の ISw に示した足を体の後方から振り出す動作を対象とする．遊脚期後半は足を振り下ろす状態に入っているため，MSw や TSw は補助の対象としない．つまり，遊脚期の始まりであるつま先が地面から離れる瞬間にアシストを行うことができればよい．

事前に作成された予測モデルと標準化スケータを用いて実時間で AWN-02 の制御を行う場合，0.2 秒後のつま先荷重が一定以下になった時点で一定時間動作指令を送ればよい．本論文では動作指令を出す長さとして，0.1 秒間信号を出した．




Fig. 18 Rancho los ammigo gait cycle [27]

Table 6 Objectives of each gait phases

Phases	Objectives
Initial contact (IC)	Start stance with a heel rocker Impact deceleration
Loading response (LR)	Shock absorption Weight-bearing stbility Presevation of Preservation of progression
Mid stance (MSt)	Progression over the stationary foot Limb and trunk stability
Terminal stance (TSt)	Progression of the body beyond the supporting foot Limb and trunk stability
Pre-swing (PSw)	Position the limb for swing Accelerate progression
Initial swing (ISw)	Foot clearance of the floor Advancement of the limb from its trailing position
Mid swing (MSw)	Limb advancement Foot clearance of the floor
Terminal swing (TSw)	Complete limb advancement Prepare the limb for stance

5. 足裏荷重予測実験

足裏荷重予測の精度検証のために実験を行った。本章では行った実験の内容と結果について述べる。本実験は奈良先端科学技術大学院大学倫理審査委員会の承認を受け行われた。

5.1 非実時間での予測

5.1.1 実験内容

被験者 9 人 (平均年齢 23.9 ± 1.0 才, 男性, 体重 69.1 ± 9.5 [kg], 身長 173.4 ± 5.5 [cm]) において歩行計測を行った。被験者の身体情報を Table 7 に示す。

Table 7 Walking with a exoskeleton experiment subjects data

Subject	Weight [kg]	Height [cm]
A	56.7	171
B	62.2	169
C	62.3	185
D	66.8	170
E	68.4	174
F	68.9	165
G	70.2	179
H	85.5	171
I	88.8	175

計測した歩行は事前実験と同様の静止と歩行を繰り返し、歩数が増加していく歩行計 8 試行と被験者に歩行と静止を繰り返しながら 30 [m] を歩くようにだけ指示したランダムな歩行 2 試行の計 10 試行である。この 10 試行を次の 3 条件ごとに計測した。

何も持たない状態

事前実験と同様にセンサの装着のみで他に何も持たない状態での歩行

AWN-02 を背負った状態

AWN-02 を背負い、AWN-02 によるアシストは行わない状態での歩行

AWN-02 による補助有りの状態

AWN-02 を背負い、被験者自身がスイッチを押すことで AWN-02 を動作させ、被験者自身の好きなタイミングでアシストが行われる状態での歩行

スイッチを押してアシストされながらの歩行計測を行う前に被験者には AWN-02 のアシストタイミングに慣れてもらうための練習時間を設けた。

スイッチを押しながらの歩行を計測した際に計測されるタイミングの一例を Fig. 19 に示す。黄色くハイライトされている部分がスイッチを押していたタイミングである。タイミングにはばらつきがあるが、被験者はつま先にかかる足裏荷重がなくなる前にスイッチを押していた。このスイッチを押し始める前につま先にかかる荷重が一定以下になることを予測することができていれば遅れのない補助を行うことができる。また、外骨格を用いた動作アシストを行うために事前に歩行計測を行い、予測モデルを作成する場合はより簡単に計測が可能であることが望ましいため、予測精度の検証として上記の条件ごとに計測されたデータを基に訓練したモデルを用いて以下の 5 条件の予測を行った。




Fig. 19 Switch timing

- I AWN-02 無しでの歩行から AWN-02 無しでの歩行の予測
- II AWN-02 を背負った歩行から AWN-02 を背負った歩行の予測
- III 補助ありの歩行から補助ありの歩行の予測
- IV AWN-02 無しでの歩行から AWN-02 を背負った歩行の予測
- V AWN-02 無しでの歩行から補助ありの歩行の予測

このとき, 事前実験同様の条件付き歩行のみを訓練データとして条件付き歩行と距離のみ指定したランダムな歩行の両方の予測を行った.

予測結果の評価は事前実験同様に $RMSE$, $RMSEp$, R^2 を用いて行った. また, つま先荷重が一定以下になるタイミングのずれとスイッチを押したアシストにおけるスイッチを押したタイミングと足裏荷重が一定以下になるタイミングの比較を行う.

5.1.2 実験結果

まず条件付き歩行における足裏荷重予測結果の $RMSE_{co}$, $RMSEp_{co}$, R_{co}^2 を Table 8 に示す. ただし, 予測は被験者自身の歩行計測データを用いた 0.2 秒後の足裏荷重予測である. 次に歩行する距離だけを指示したランダムな歩行における足裏荷重予測結果を Table 9 に示す. Table 9 に示す予測結果は被験者自身の歩行計測データを用いた 0.2 秒後の足裏荷重予測であり, 条件付き歩行 8 試行のうち 6 試行により作成した足裏荷重予測モデルによりランダムな歩行 2 試行分の予測を行った結果である.

Table 8 Results of plantar force prediction at constrained walking

Conditions	$RMSE_{co}$ [N]	$RMSEp_{co}$ [%]	R_{co}^2
I	65.5	9.07	0.749
II	70.1	9.22	0.750
III	87.6	11.5	0.584
IV	105	13.6	0.437
V	113	14.7	0.311

Table 9 Results of plantar force prediction at random walking

Conditions	$RMSE_{ra}$ [N]	$RMSE_{pra}$ [%]	R_{ra}^2
I	73.0	10.1	0.702
II	75.9	10.0	0.712
III	105	13.6	0.422
IV	102	13.2	0.470
V	131	17.0	0.307

次に AWN-02 での使用を考慮し、つま先にかかる荷重が減少するタイミングに注目する。予測において標準化スケーラを事前に作成し予測された値を力に変換している関係上、予測される荷重の最低値は 0 [N] にはならない場合がある。そのため、閾値として 20 [N] 以下になったときをつま先が浮いたとした。

条件付き歩行の 0.2 秒後の予測において、つま先荷重が一定以下になるタイミングと計測された足裏荷重が一定以下になるタイミングとの比較結果 $RMSE_{cot}$ を Table 10 に示す。 $RMSE_{cot}$ の値が 0 に近いほどタイミングの予測ができているといえる。また、予測自体が成功している (S) か失敗している (E) かも同時に示す。ただし、予測タイミングが実際のタイミングから 0.2 秒以上離れていた場合は予測失敗とした。予測の失敗の種類として、足裏荷重の予測値は一定以下になったが、実測値が一定以下にならなかった、もしくは予測値が 0.2 秒以上先行していた場合 (Ep_{co}) と実測値が一定以下になったが、予測値が一定以下にならなかった、もしくは実測値が 0.2 秒以上先行している場合 (Em_{co}) を示している。同様に、歩行距離のみを指示したランダムな歩行についても比較結果 $RMSE_{rat}$, S_{ra} , Ep_{ra} , Em_{ra} を Table 11 に示す。

被験者が求めるアシストタイミングを知るために、スイッチを操作することでアシストを行う試行において、スイッチを押し始めるタイミングとつま先荷重が 20 [N] になるタイミングを比較したところ、被験者は平均 0.166 秒前にスイッチを押し始めていた。また被験者がスイッチを押し始めた時点の平均からの $RMSE$ は 0.174 秒であった。

Table 10 Prediction timing error at constrained walking

Conditions	$RMSE_{cot}$ [ms]	S_{co} [%]	Ep_{co} [%]	Em_{co} [%]
I	71.0	87.6	6.31	6.11
II	72.3	81.6	9.06	9.37
III	58.5	68.9	12.6	18.6
IV	75.1	74.5	20.3	5.16
V	65.2	78.2	13.5	8.33

Table 11 Prediction timing error at random walking

Conditions	$RMSE_{rat}$ [ms]	S_{ra} [%]	Ep_{ra} [%]	Em_{ra} [%]
I	77.4	83.2	7.74	9.05
II	76.3	78.5	10.3	11.2
III	61.4	64.3	15.1	20.6
IV	77.5	71.5	22.2	6.26
V	71.4	74.3	14.6	11.1

5.1.3 考察

Table 8 に示すように 0.2 秒後足裏荷重予測においてはアシストをしない状態では予測誤差 9 % 程度での予測が可能であった。また、 R^2 の値が 0.75 付近であるため、予測値は計測値に追従しているといえる。しかし、補助を行った歩行においては R^2 の値が 0.6 以下まで落ちてしまう。この原因はスイッチを押すタイミングにばらつきがあったことが原因の 1 つであると考えられる。スイッチを押すタイミングの練習は行ったが、人間の反応速度自体に遅れがあるため、被験者の思ったスイッチを押すタイミングと実際に押すタイミングにズレがあると考えられる。

また Table 9 に示すように、歩行する距離のみを指示したランダムな歩行についても予測誤差 10 % 程度での予測が可能であった。ランダムなアシスト有りの歩行を予測した場合は、 R^2 の値が 0.6 を下回ってしまっている。しかし、つま先荷重の減少しているタイミングに注目すると、全条件を通してボタンを押しながら動く場合よりも $RMSE$ が小さくなることから、人が操作するよりもアシストタイミングのばらつきは小さくなる。また、条件付きの歩行とランダムな歩行の両方の予測において、つま先荷重のタイミング予測において 5 % 以上の低下は見られなかった。そのため、ランダムな歩行においてもアシストタイミングは予測ができている可能性が示された。

5.2 実時間での使用実験

5.2.1 実験内容

あらかじめ作成されたモデルと標準化スケーラを用いて外骨格による補助を行う歩行実験を被験者3名(年齢 24.0 ± 0.81 才, 男性, 体重 71.5 ± 10 [kg], 身長 170.2 ± 0.82 [cm])に対して行った. 予測を行う Raspberry Pi の性能を考慮し, 予測は平均 20 [Hz]でおこなった. 予測されたつま先荷重が 20 [N] 以下になったときに Raspberry Pi が 0.1 秒間動作指令を出した.

AWN-02 による補助を行いながらの歩行における足裏荷重を計測し, 実験終了後に聞き取り調査を行った.

5.2.2 実験結果

実時間での計測された足裏荷重と推定された足裏荷重を Fig. 20 に示す. Fig. 20 では赤色の実線は足裏荷重が予測されたタイミングでの予測値を示しており, 青色破線は計測された足裏荷重が示されている. 予測された足裏荷重が計測される足裏荷重に先行することが見て取れる. しかし, 全体を通して大きさは合致しない.

アシスト有りでの歩行終了後にアシストタイミングについて聞き取り調査を行ったところ, スイッチを押しながらの歩行よりも良かったとの回答が得られた. また, 歩行開始時, 歩行中はほぼ問題なく動作したとの回答も得られた. しかし, 歩行終了後の直立時に予期せず動く誤動作がまれにあったとの回答があった.




Fig. 20 Result of real time plantar force prediction

5.2.3 考察

実時間での使用においては足裏荷重の予測値は計測値に先行することが確認できた。しかし、波形そのものを正確には予測はできておらず、最大値も一致しない。また、Fig. 20 の 36 秒～37 秒付近において被験者は直立しているが、この時の値も大きく外れている。この予測値のずれは事前に作成した標準化スケーラを用いているためであると考えられる。また、IMU センサの取り付け位置に原因があると考えられる。標準化スケーラは予測モデル作成のための歩行計測時に計測された被験者自身の計測データを基に作成しており、実時間での使用時の情報を含んでいない。そのため、スケーリングができていないと考えられる。IMU センサの取り付け位置は全体を通して Fig. 4 に示すように IMU センサ付属のバンドで足首に固定しているため、同じ位置への着用が難しい。そのため、予測モデルおよび標準化スケーラ作成時と実時間利用時でセンサの傾きにずれが生じてしまう。この傾きが予測の誤差につながってしまった。直立時に予期せず動作した原因はセンサのずれによる傾きと歩行終了後の被験者自身の体の揺れによる影響により足が動作すると誤認した可能性がある。

聞き取り調査の結果から、おおむね歩行に合ったタイミングでの補助は達成できていた可能性が示されている。スイッチを被験者が押しながら歩くよりも良かったとの回答があったのは、被験者自身の反応速度によるアシストタイミングのズレが軽減されたからであると考えられる。

6. おわりに

6.1 まとめ

本研究では下肢外骨格による歩行補助における遅延軽減のために足裏荷重の予測手法を提案した。IMU センサのみの情報から将来の足裏荷重の予測を行った。被験者が何も持たない自然な歩行においては誤差 10 %程度での予測が可能であったが、外骨格による補助を行いつつの自由な歩行については 17 %程度の誤差が発生してしまった。この問題を解決するには被験者の動き以外に外骨格の動作情報も入力の一部として組み込むべきである。外骨格の動作するタイミングが分かれば被験者が何も装着していない状態での足裏荷重予測の精度に近づくと考えられる。また、治具に IMU センサを取り付けることで、センサ取り付け位置が同じになるようにすべきである。

6.2 今後の課題と展望

今回計測をおこなった条件は平地での一定のスピードでの歩行のみである。坂道や段差などの条件での計測や、徐々に歩行速度が速くなるなどの歩行の計測も必要である。また、他人の足裏荷重を用いた予測は事前実験のみでしか行わなかった。多数の被験者のいくつかの歩行計測を行うことでより汎用的な予測モデルが作成できる可能性がある。さらに外骨格自体にセンサを組み込むことで実時間での使用においても予測精度が落ちない可能性があり、関連する研究として挙げた足裏荷重を用いた膝の負担推定などの研究を用いることができ、人に適した補助が可能になると期待される。

7. 謝辞

本研究は、奈良先端科学技術大学院大学先端科学技術研究科ロボティクス研究室小笠原司教授のご指導の下で行いました。本研究の遂行にあたり、多岐にわたるご指導やご助言を賜りました小笠原司教授に深く感謝いたします。

論文執筆にあたり、丁寧なご検討、ご教示をいただきました加藤博一教授に深く御礼申し上げます。

同研究科の高松淳准教授には、本研究室の研究会などで様々な御指導や御助言を頂き、深く感謝いたします。

研究方針や論文執筆にあたり、さまざまな御指導や御助言をいただきました、同研究科の丁明客員准教授に深く感謝いたします。

同研究科の Garcia Ricardez Gustavo Alfonso 助教には、論文執筆、英文添削など、多くの点で御指導いただき深く感謝いたします。

研究協力として外骨格装置をお貸しく下さいました株式会社 ATOUN 様に深く感謝いたします。

同研究科秘書の大脇美千代氏、池田美輝氏には学生生活を送る上で様々なサポートをして頂きました。深く感謝いたします。

研究活動を行うにあたり、多くのアドバイス、ご指摘を頂きました本研究室博士後期課程の趙崇貴氏に深く感謝いたします。

研究活動や日常生活において、多くのご意見を頂きました本研究室先輩、同輩並びに後輩に深く感謝いたします。

参考文献

- [1] Aaron M Dollar and Hugh Herr: “Lower extremity exoskeletons and active orthoses: Challenges and state-of-the-art,” *IEEE Transactions on Robotics*, Vol. 24, No. 1, pp. 144–158, 2008.
- [2] Tomohiro Hayashi, Hiroaki Kawamoto, and Yoshiyuki Sankai: “Control method of robot suit hal working as operator’s muscle using biological and dynamical information,” In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 3063–3068, 2005.
- [3] Adam Zoss, Hami Kazerooni, and Andrew Chu: “On the mechanical design of the berkeley lower extremity exoskeleton (bleex),” In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 3465–3472, 2005.
- [4] ATOUN: “Tabito 3.0 - atoun,” <http://atoun.co.jp/prototypes/tabito/>.
- [5] Romain Baud, Amalric Ortlieb, Jeremy Olivier, Mohamed Bouri, and H Bleuler: “Hibso hip exoskeleton: Toward a wearable and autonomous design,” In *Proceedings of International Workshop on Medical and Service Robots*, pp. 185–195, 2016.
- [6] Patrik Kutilek and Barbora Farkasova: “Prediction of lower extremities’ movement by angle-angle diagrams and neural networks,” *Journal of Acta of Bioengineering & Biomechanics*, Vol. 13, No. 2, pp. 57–65, 2011.
- [7] Atilla Kilicarslan, Saurabh Prasad, Robert G Grossman, and Jose L Contreras-Vidal: “High accuracy decoding of user intentions using eeg to control a lower-body exoskeleton,” In *Proceedings of international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 5606–5609, 2013.
- [8] Kazuo Kiguchi: “A study on emg-based human motion prediction for power

- assist exoskeletons,” In Proceedings of International Symposium on Computational Intelligence in Robotics and Automation (CIRA), pp. 190–195, 2007.
- [9] Mario Cifrek, Vladimir Medved, Stanko Tonković, and Saša Ostojić: “Surface emg based muscle fatigue evaluation in biomechanics,” *Journal of Clinical biomechanics*, Vol. 24, No. 4, pp. 327–340, 2009.
 - [10] Mohammad Abdoli-Eramaki, Caroline Damecour, John Christenson, and Joan Stevenson: “The effect of perspiration on the semg amplitude and power spectrum,” *Journal of Electromyography and Kinesiology*, Vol. 22, No. 6, pp. 908–913, 2012.
 - [11] Julien Favre, Matthieu Hayoz, Jennifer C Erhart-Hledik, and Thomas P Andriacchi: “A neural network model to predict knee adduction moment during walking based on ground reaction force and anthropometric measurements,” *Journal of biomechanics*, Vol. 45, No. 4, pp. 692–698, 2012.
 - [12] Hui Yu, Dong-hai Wang, Can-Jun Yang, and Kok-Meng Lee: “A walking monitoring shoe system for simultaneous plantar-force measurement and gait-phase detection,” In Proceedings of IEEE/ASME International Conference on Advanced Intelligent Mechatronics, pp. 207–212, 2010.
 - [13] Li Qingguo, Young Ming-Shing, Naing Veronica, and Donelan J Maxwell: “Walking speed estimation using a shank-mounted inertial measurement unit,” *Journal of biomechanics*, Vol. 43, No. 8, pp. 1640–1643, 2009.
 - [14] Angelos Karatsidis, Giovanni Bellusci, H Martin Schepers, Mark De Zee, Michael S Andersen, and Peter H Veltink: “Estimation of ground reaction forces and moments during gait using only inertial motion capture,” *Journal of Sensors*, Vol. 17, No. 1, 75, 2017.
 - [15] Yuuki Horiuchi, Yasutoshi Makino, and Hiroyuki Shinoda: “Computational foresight: Forecasting human body motion in real-time for reducing delays in

- interactive system,” In Proceedings of the 2017 ACM International Conference on Interactive Surfaces and Spaces, pp. 312–317, 2017.
- [16] Yongyi Tang, Lin Ma, Wei Liu, and Weishi Zheng: “Long-term human motion prediction by modeling motion context and enhancing motion dynamic,” In Proceedings of International Joint Conference on Artificial Intelligence (IJ-CAI), pp. 935–941, 2018.
 - [17] Taeyong Sim, Hyunbin Kwon, Seung Eel Oh, Su-Bin Joo, Ahnryul Choi, Hyun Mu Heo, Kisun Kim, and Joung Hwan Mun: “Predicting complete ground reaction forces and moments during gait with insole plantar pressure information using a wavelet neural network,” Journal of biomechanical engineering, Vol. 137, No. 9, 091001, 2015.
 - [18] Phuc Truong, Jinwook Lee, Ae-Ran Kwon, and Gu-Min Jeong: “Stride counting in human walking and walking distance estimation using insole sensors,” Journal of Sensors, Vol. 16, No. 6, 823, 2016.
 - [19] 江原義弘, 山本澄子: ボディダイナミクス入門 歩き始めと歩行の分析. 医歯薬出版, 2002.
 - [20] Sepp Hochreiter and Jürgen Schmidhuber: “Long short-term memory,” Journal of Neural computation, Vol. 9, No. 8, pp. 1735–1780, 1997.
 - [21] Felix A Gers, Jürgen Schmidhuber, and Fred Cummins: “Learning to forget: Continual prediction with lstm,” In Proceedings of International Conference on Artificial Neural Networks (ICANN), pp. 850–855, 1999.
 - [22] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams: “Learning representations by back-propagating errors,” Journal of nature, Vol. 323, No. 6088, pp. 533–536, 1986.
 - [23] Alex Graves, Marcus Liwicki, Santiago Fernández, Roman Bertolami, Horst Bunke, and Jürgen Schmidhuber: “A novel connectionist system for uncon-

- strained handwriting recognition,” *IEEE transactions on pattern analysis and machine intelligence*, Vol. 31, No. 5, pp. 855–868, 2008.
- [24] Tara N Sainath, Oriol Vinyals, Andrew Senior, and Haşim Sak: “Convolutional, long short-term memory, fully connected deep neural networks,” In *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 4580–4584, 2015.
 - [25] Rui Fu, Zuo Zhang, and Li Li: “Using lstm and gru neural network methods for traffic flow prediction,” In *Proceedings of Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, pp. 324–328, 2016.
 - [26] Partha Ghosh, Jie Song, Emre Aksan, and Otmar Hilliges: “Learning human motion models for long-term predictions,” *Proceedings of International Conference on 3D Vision (3DV)*, pp. 458–466, 2017.
 - [27] Jacquelin Perry and Judith M. Burnfield: *Gait Analysis: Normal and Pathological Function*. second ed. SLACK, 2010.