



機械学習を用いたロコモーションインタフェースの 歩行速度推定手法の開発

Development of Walking Speed Estimation Method
using Machine Learning for a Locomotion Interface

久保村尚樹¹⁾, Denielsen Paulus¹⁾, 安藤潤人¹⁾, 大井翔²⁾, 野間春生¹⁾

Naoki KUBOMURA, Denielsen PAULUS, Mitsuhiro ANDO, Sho OOI, and Haruo NOMA

1) 立命館大学 (〒525-8577 滋賀県草津市野路東 1-1-1, nkubomura@mxdlab.net)

2) 大阪工業大学 (〒573-0196 大阪府枚方市北山 1-79-1, SHO.OOI@outlook.jp)

概要 : 我々は人の歩行に合わせて動くトレッドミル型ロコモーションインタフェースを開発している。従来のトレッドミルは、光学測域センサで取得した足の位置から立脚時間を計測することで歩行速度を推定していたが、歩行動作によっては歩行速度を誤推定する場合があった。これは、光学測域センサでデータを取得した際に、両足の位置を正しく判別できていないことが原因だと考えられる。本研究では、足の位置判別する処理を介する必要のない手法として、光学測域センサの計測値から機械学習によって歩行速度を推定する手法を検討した。

キーワード : 機械学習, ロコモーションインタフェース

1. はじめに

我々は、運動を促進させることを目的とした人の歩行に合わせて動くロコモーションインタフェースであるアクティブトレッドミルの開発を行なった[1]。このアクティブトレッドミルは、歩行者の身体に特定の機器を装着する必要なく制御することができる。また、歩行者の歩行速度を推定することで PI 制御のみのロコモーションインタフェースよりも速い速度での歩行への対応を実現した。アクティブトレッドミルは光学センサを用いて身体と足の位置を取得しており、身体的位置を用いた PI 制御だけでなく足の位置から推定した立脚時間を用いて歩行速度推定を行うことで制御している。この歩行速度推定には、取得したデータから足の位置を判別する必要がある。しかし、光学測域センサで足の位置を計測する際に歩行者の歩行動作によっては正しい立脚時間を推定できない場合があり、制御が不安定であった。そこで我々は、光学測域センサから取得したデータを用いて直接に機械学習による歩行速度推定を行う手法を検討する。

2. 関連研究と課題

ロコモーションインタフェースを速度推定で制御している研究として NIH の Jungwon Yoon らは、両足、腰に装着したモーショントラッカーの位置をカメラで取得し、

遊脚時の速度から歩行速度推定を行うロコモーションインタフェースを実装したと報告している[2]。そして我々は、光学測域センサで取得した足の位置を用いて歩行速度推定を行うトレッドミル型のロコモーションインタフェースとしてアクティブトレッドミルを開発した[1]。身体的位置から制御目標との誤差を利用することで制御量を計算する PI 制御を行うと共に、両足の位置の変化量から歩行者の立脚時間を推定し立脚時間と関連のある歩行速度の近似値から歩行速度推定を行うことで実装した。いずれの手法も推定方法に差はあるが、どちらも光学センサを用いて足の位置を検出し、歩行速度を推定することで歩行者の急な速度変化に対応できるように制御を行っている。これらの問題点として、光学センサで足の位置を計測する際の歩行者の歩行動作によっては正しい立脚時間を推定できない場合があった。そして、そのような場合には歩行者が意図しない速度でトレッドミルが動作してしまう。これは光学センサで取得したデータから両足の位置を正しく検出できていないことが原因であると考えた。

本研究の目的は歩行者が意図した速度で動作するロコモーションインタフェースの実現である。そのため我々は立脚遊脚を判定する必要がない直接的な手法を提案する。具体的には光学測域センサから取得したデータを用

いた機械学習による歩行速度推定を行う。提案した手法を使って試作機による実証実験を行った。

3. 計測環境

試作機では図1に示すように2つのLiDARセンサをトレッドミル前方に取り付けることでトレッドミル上の歩行者の歩容を計測している。トレッドミルはLABORDO NEXT（セノー株式会社製品）、身体の位置計測は光学センサであるTFmini（Benewake製品）、両足の位置計測は光学測域センサであるUTM-30LX-EW（北陽電気株式会社製品）を採用している。また、UTM-30LX-EWは歩行者の両足を計測するために必要な63度だけを取得しており、UTM-30LX-EWの角度分解能は0.25度であるため、252次元の特徴をサンプリングレート約30Hzで取得した。そして、取得したデータの横軸をステップ(count)、縦軸を距離(mm)として図2に表示している。図2においての足の位置は50-150ステップ間に検出されている。

4. CNNによる歩行速度推定

第3章で説明した計測方法で、光学測域センサから取得した252次元のデータと身体の位置を特徴量として連結させ、計253次元の特徴量を時系列順に連結させることで機械学習用のデータとした。連結方法は図3に示すように、上記した253次元の特徴量を時間方向に複数フレームを連結させる手法をとった。そして、1名の計測につき歩行者の歩行速度のカテゴリとして(1・2・3・4・5・6km/h)の6種類をそれぞれ4,200個、合計25,200個の機械学習用データを取得した。また、機械学習用のデータを時系列順に(訓練データ・検証データ・テストデータ)の3種類に分



図1：実験環境とセンサ

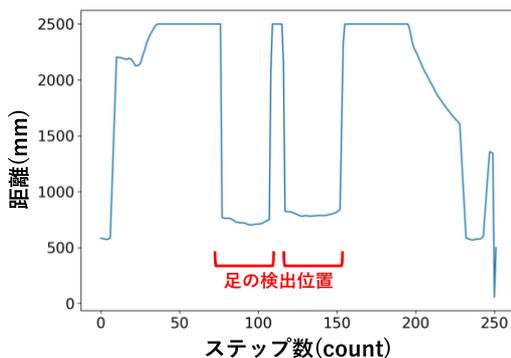


図2：光学測域センサで取得した距離データ

割した。そして、この学習用データをCNN(Convolutional Neural Network)を用いて機械学習を行う。構築した識別モデルを図4に示す。また、畳み込みに使用するカーネルの最小のサイズを3x3とし、学習が収束しなかった場合カーネルサイズを変更させることで収束させた。

5. 実験

5.1 実験内容

我々は、先行研究の手法において光学センサから取得したデータから足の位置を検出が正しく行っていないため、不安定な動作が見られると仮定した。その仮説を証明するため、光学センサから取得した歩容の時系列パターンから機械学習を用いて歩行速度を推定する手法を検討する。

4章で述べたように、機械学習に用いるデータは光学測域センサから取得したデータと身体の位置である253次元の1サンプルデータを1フレームとして、時間方向に複数フレームを連結することで作成している。そして、認識精度が高い学習用データを形成するために連結させるフレーム数による認識精度の変化を調査する。実験での畳み込み処理に用いた最小のカーネルサイズが3x3であることから、連結させる最小のフレーム数は4としている。そして、4~20フレーム連結させた場合それぞれの認識精度について検証する。さらに、ロコモーションインタフェースとしての実装を想定した場合に必要な認識精度について考えるために、誤認識された値の識別結果、誤認識が連続して発生した回数、歩行者の状態と誤認識の関係の3点について調査した。

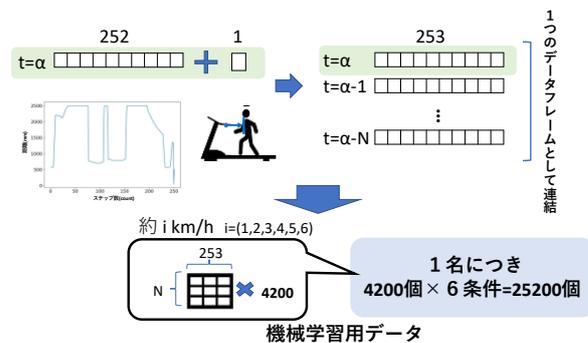


図3：学習用データの形成方法

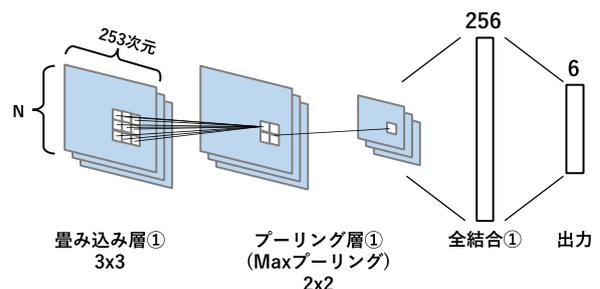


図4：構築した識別モデル

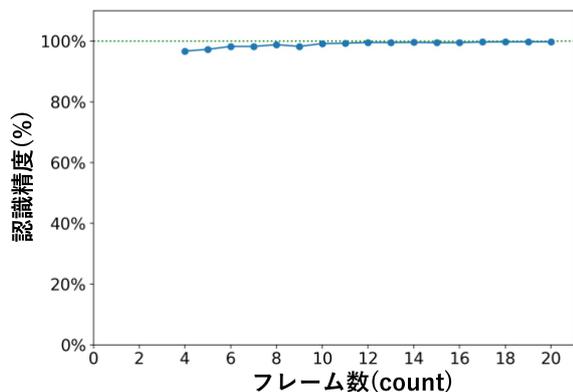


図 5：学習用データの形成方法

5.2 実行結果

学習に用いたフレーム数と歩行速度推定の精度との関係のグラフを図 5 に示す。これは横軸を連結させたフレーム数、縦軸を機械学習モデルの認識精度を示しており、認識精度が 100%の値を点線で表示している。結果として、図 5 に示したようにフレーム数が増加するごとに認識精度が向上した。また、本実験での最小のフレーム数である 4 フレーム用いた学習では認識精度が約 96%であり、10 フレーム用いた学習で認識精度が 99%を超える値となった。

識別結果である 4 フレーム用いた学習の混同行列を図 6 に、10 フレーム用いた学習の混同行列を図 7 に示す。図 6、図 7 より、どちらの場合においても誤認識は正解の値に近い値と認識していた。また、4 フレームを用いた識別結果では 10 フレームを用いた識別結果より、正解に近いカテゴリではあるが誤認識していることが多かった。

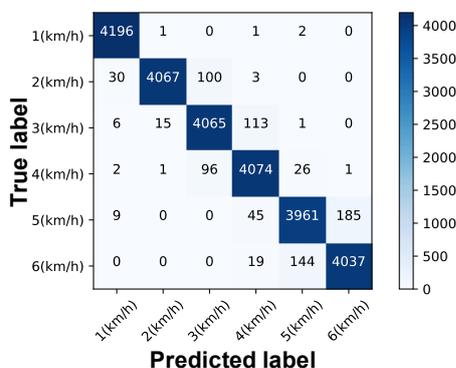


図 6：混同行列 (4frame)

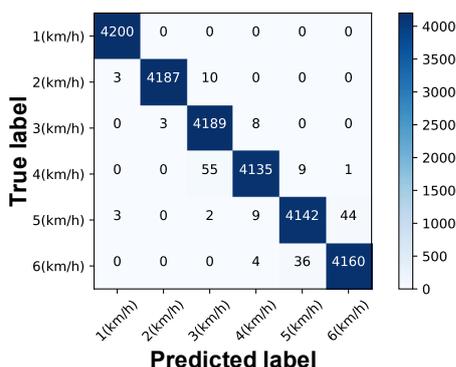


図 7：混同行列 (10frame)

次に、4 フレームと 10 フレームでの学習において誤認識が連続して発生している数を調査した。図 8 に 4 フレームでの結果を、図 9 に 10 フレームの結果を横軸に連続して誤認識が発生した回数、縦軸にカウントを示したヒストグラムに示す。4 フレームと 10 フレームどちらも 2 回以上連続して誤認識されている回数は誤認識全体の約 20%であった。

さらに、歩行者の状態と誤認識との関係を調査した。被験者 1 名の 5 フレームと 10 フレームを用いた学習において誤認識が立脚全体のどの段階で発生したかについて分析した。対象とする範囲内での誤認識の総数が 5 フレームの場合は 62 箇所、10 フレームの場合は 34 箇所であるため、それぞれの立脚時間で正規化を行うことで、立脚のどのフェーズと誤認識の関係を確認した。図 10 に、横軸を立脚開始から終了までの時点、縦軸を誤認識した回数を 5 フレームと 10 フレームそれぞれ正規化したヒストグラムを示した。結果として、5 フレームでは誤認識が立脚前半（踵着地タイミング）に偏っており、10 フレームでは、誤認識が立脚状態後半（つま先離床タイミング）に偏っていた。計測にもちいたフレーム数を考慮すると、サンプリングレートが 30Hz であるため 5 フレームは約 0.15 秒、10 フレームは約 0.3 秒である。そして、立脚時間に用いる時間を 0.3 秒だと仮定した時、5 フレームではグラフの横軸 50%分を取得し、10 フレームではグラフの横軸全体を含んでいると言える。このことから、両結果の共通部分から考えると立脚開始時点つまり、踵着地時点での計測データが学習に悪影響を与えている可能性がある。

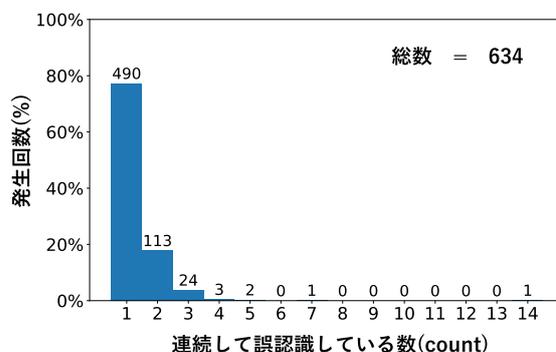


図 8：誤認識が連続して発生した回数 (4frame)

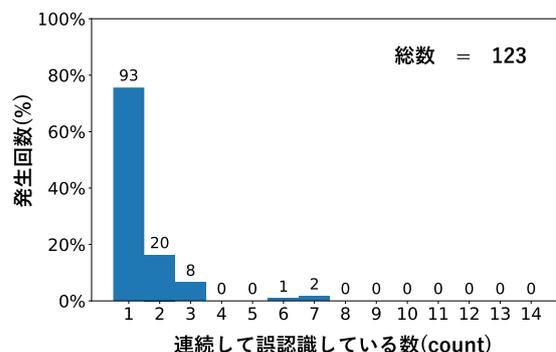


図 9：誤認識が連続して発生した回数 (10frame)

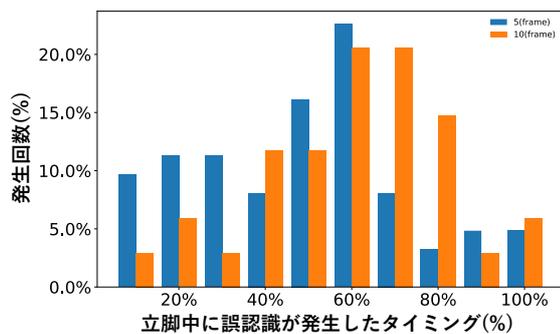


図 10：歩行者の状態と誤認識との関係

5.3 考察

図 6, 図 7 から 4 フレームを用いた識別結果の方が 10 フレームを用いた識別結果より、正解に近いカテゴリではあるが誤認識していることが多かった。これは、4 フレームでは正しいカテゴリに分類できる特徴量を取得できていないことが原因であると考えた。そのため、歩行者の歩行速度のカテゴリをより詳細に分割する場合は 10 フレームを用いた学習が適していると推察した。また、10 フレームを用いた歩行速度推定では光学測域センサである UTM-30LX-EW のサンプリングレートが 30Hz であることから、歩行速度推定の応答には約 0.3 秒の計測時間が必要となる。先行研究では立脚時間の計測を行うことで歩行速度推定を行っているため、立脚開始から立脚終了までの立脚時間が歩行速度推定の応答に最低限必要な時間であるといえる。また立脚時間は歩行速度によって変化し、立脚時間が短い歩行では約 0.3 秒、立脚時間が長い歩行では約 1.5 秒の時間を要していた。そのため、10 フレーム以下で学習を行う場合において、本研究での歩行者の動きに対する歩行速度推定の応答に必要な計測時間は先行研究よりも優れていると言える。

次に、図 10 での立脚開始時点の計測データを含んでいる学習に誤認識が多く発生している原因として、光学測域センサから取得したデータの変化量が少ないことであると考えた。図 1 に示すように、光学測域センサはトレッドミル前方に固定されているのに対し、歩行者はトレッドミルのベルトと共に後方に移動する。そして、立脚開始時点の足の動きはトレッドミル進行方向とは逆方向に遅い速度で移動する。そのため、光学測域センサから取得する足の位置の変化量はほとんど変化しない。しかし、これらは誤認識が立脚開始時点の計測データが引き起こしているという仮説が前提であるため検証の必要があると考えた。

最後に本提案手法を歩行者位置の保持のフィードバックへの組み込みの可能性について述べる。本研究で開発しているロコモーションインタフェースは PI 制御によるフィードバック制御を主として歩行者の位置を留め、急な歩行速度変更が行われた時に PI 制御の補助として歩行速度推定から制御量を出力する。そのため、認識精度が高い場

合においては歩行速度推定の認識精度が正解の値から大きく離れていることや長い時間誤認識をし続けるなどのことがない限り、制御結果に影響を与えないと仮定した。そして、10 フレームを用いた学習では歩行速度推定の認識精度が 99%以上であったことから判断して、本手法はフィードバックに組み込み可能であると考えられる。

6. おわりに

先行研究で開発した運動を促進させることを目的とした人の歩行に合わせて動くアクティブトレッドミルには、歩行者の歩行動作の個人差によって不安定な動きをするという問題点があった。そして我々は、不安定な動作は LiDAR で取得したデータから足の検出が正しくが行えていないことが原因であると考えた。その解決策として光学測域センサから取得した足の位置データを用いて機械学習によって直接に歩行速度推定を行う手法を検討した。そして過去フレームを取得する数を変更させた結果、最小の値である 4 フレームでは 96%、10 フレームで 99%以上の認識精度が得られた。

我々が開発しているロコモーションインタフェースは、歩行者がどんな速度で移動しても歩行者の位置を一定の位置に留めることを目標としている。そして、歩行速度推定は PI 制御によるフィードバック制御の補助としての役割を想定しているため、必ずしも認識精度が 100%に達する必要はない。これらのことから、歩容全体の時系列パターンから機械学習を用いて歩行速度を推定する手法は足の動きから歩行速度推定することに適していると考えた。

今後の展望として、ロコモーションインタフェースとして実装するためには、テストデータに学習に使用していない被験者のデータを用いる必要がある。さらに、識別のカテゴリを詳細に分割することで、より繊細な歩行速度推定を目標としている。そのため、今後の方針としてカテゴリを分割した際に適したフレーム数を調査すると共に、内股歩きや外股歩きなどの独特な歩行特性だけでなく複数の被験者の歩容データを収集することでロコモーションインタフェースとして実装を目指す。

参考文献

- [1] 久保村 尚樹, Denielsen Paulus, 大井 翔, 松村 耕平, 野間 春生, 歩行速度に合わせた速度を提示する アクティブトレッドミルの開発, インタラクシオン 2021 論文集, 2021, p. 201-204
- [2] Yoon J, Park HS, Damiano DL. A novel walking speed estimation scheme and its application to treadmill control for gait rehabilitation. J Neuroeng Rehabil. 2012 Aug 28;9:62. doi: 10.1186/1743-0003-9-62. PMID: 22929169; PMCID: PMC3546912.