

協調ロボットの実現に向けた人間行動の機械学習による近未来予測にむけて

吉永章太朗¹ 土井祐介¹ 井上創造¹

概要：日本の様々な業界で人手不足が問題となっており、解決策として挙げられるサービスロボットは外食産業、介護分野では十分な導入が行われておらず、特に福祉ロボットは予測できない人の動きには衝突する前提というのが現状である[4]。人間の行動軌跡の予測を目指す先行研究[12]では、単純な反復行動の予測のみを行っているため複雑な行動を対象としていない。本稿では、複数の行動が含まれるデータにおける急激な人間の行動を事前に予測することを目的として行動データを基に軌跡予測モデルを作成し、データセットの行動軌跡から1秒後の行動軌跡を予測した。機械学習手法としてランダムフォレストを用い、ARIMAモデルで軌跡予測を行ったものと比較し評価した。使用したデータセットは、いくつかの異なる行動が連続しているため、予備動作と考えられる値が確認できた。結果として、ランダムフォレストにおける予測時の平均RMSE約85[mm]、ARIMAでは約117[mm]を得ることが出来た。さらに、それぞれの予測結果から予備動作と考えられる変化の予測についてはどのデータもテストデータより1秒程遅れていることが確認出来た。

Toward the near future prediction by machine learning of human behavior toward the realization of cooperative robot

SHOTARO YOSHINAGA¹ YUSUKE DOI¹ SOZO INOUE¹

1. はじめに

近年日本では少子化や少母化の進行により人口が減少し続けており、様々な業界で人手不足が問題となっている。今後も人口減少は進行し続けると考えられており、更なる生産人口の減少が顕著になっていくと予想されている。

その一方でコンピュータの性能向上により、機械学習を用いた多くの実用的なAI技術が世の中に普及し始めている。これらの技術を活用することで、今後深刻化していくと予想されている人手不足の解決が期待されている。

機械学習を用いて行動認識を行うためには、多くの人々から多様な行動データを収集し、個人差に影響を受けずに行動毎の特徴を使用して行動認識モデルを作成する必要がある。本稿では、教師あり機械学習技術を用いた人間の行動における近未来の軌跡予測手法を提案する。

本稿では、人間の行動軌跡データを基に回帰モデルを作成し、データセットの行動軌跡から1秒後の行動軌跡を予測する。今回機械学習における分類器はランダムフォレストを用いた。その後、ARIMAモデルで軌跡予測を行ったものと比較し評価した。

以下の2章で背景及び関連研究について述べ、3章で評価方法について述べ、4章で評価実験の結果について述べる。最後に5章でまとめる。

2. 背景と関連研究

厚生労働省の平成30年版働く女性の実情によると、平成30年における女性の労働力人口は3,014万人と前年に比べ77万人増加している。これは日本の労働力人口総数6,830万人のうち、女性の占める割合は44.1%にのぼる[1]。さらに、2025年において介護人材は現在にも増して37万人供給不足となると予測されている[2]。さらに内閣府の少子化社会対策白書によると、2017年における出生率は9.4万6,065人となり過去70年で最低を記録している一方で、総人口における65歳以上の高齢者人口は過去20年で増加の一途をたどっている[3]。

このように、女性の社会進出や、少子化・高齢化という社会変化を背景に、外食産業及び介護分野における需要が高まっている。

2.1 人手不足の解決策

前述の人手不足及び人間の負担軽減の解決策として、生産の自動化及びサービスロボットの導入が挙げられる。生産の自動化は自動車業界等の製造業では既に浸透しているが、外食産業、介護分野では十分な導入が行われていない。福祉ロボットを例に挙げると、予測できない人の動きには衝突する前提というのが現状である[4]。また、日本工業規格におけるJIS B 8433-1:2015協働運転要求事項では、人が協働作業空間に存在する場合ロボットは停止しなければいけないと定められている[5]。

¹九州工業大学

中食工場では人手不足の深刻化を受けて、コンビニエンスストア向けの弁当・惣菜等の製造を自動化する取り組みが進められている[6]。さらに食品業界における人手不足の解決を目指して、2019年8月に総額約4億円の資金調達を行ったベンチャー企業である株式会社アールティは、同年7月9日に行われた国際食品工業展2019において、おかげ盛り付け人型協働ロボット「Foodly(フードリー)」のプロトタイプを発表しており、2020年中の生産・納入を目標としている[7]。

さらに、IoTやデバイスなどの先進技術の発展はめざましいものがあり、スマートフォンやスマートウォッチに搭載されたセンサーデータから人間の生体情報を取得し、健康管理や行動認識を行うことが可能になっている。

2.2 人間の行動について

人間は手を前後に移動させるといった単純な反復行動だけでなく、いくつかの行動を同時にしている。特に介護中や料理中は顕著であり、複雑な行動の代表例と言える。このように人間の行動には複雑な動きの中に幾つかの周期性のある動きが混ざっており、余程慣れた行動でない限り作業内容の確認や作業スピードのムラなど、人間の行動は周期的なデータにならないことが多い。

しかし、このような人間の行動データや株価等の時系列データの多くは単位根過程に従うことが多い。単位根過程に従うデータを使用した場合には、見せかけの回帰が生じてしまうことが知られている。そのため、本稿で作成したモデルが見せかけの回帰が生じていないかについても注意して評価を行う必要がある。

2.3 関連研究

これまでに人間とロボットの共同作業を目的とした多くの研究が行われている。これはヒューマンロボットコラボレーション(HRC)やヒューマンロボットインタラクション(HRI)と呼ばれ、高齢者介護、宇宙アプリケーション、救急ロボットとして実用段階のものも存在する[8]。介護ロボットの例として理化学研究所の ROBEAR[9]が挙げられる。これらのロボットは、人間と効率的な作業の実施及び人間の被災を防ぐためにロボット自身における身の回りの状況把握が必要不可欠となる。この状況を把握する方法の一つとして、人間の動きを予測する様々な研究が行われている。

人間の動きを予測する研究では、文献[10], [11]のように動画から軌道予測するものがほとんどである。これらはカメラからの映像が不可欠となるため、使用箇所によってはレンズになんらかの物体が付着してしまい、人間の行動を上手く認識出来なくなるという問題が出てくる。そのため、協働ロボットはカメラからの情報だけでなく、様々なセンサーからのデータを活用してロボット自身の状況を把握する必要がある。

動画以外のセンサーデータを用いたものとして、Wangらは反復行動に対する ARIMA モデルを用いた人間の行動軌道の予測を提案している[12]。これは、腕を前後に移動させるといった単純な反復行動のみを対象としているため、複雑な行動や急激な行動の予測は行われていない。しかし、協働作業空間内で人間と協働するロボットは人間の単純な反復行動やベテランの周期的な行動だけでなく、不意な人間の行動に対しても回避する必要がある。

3. 評価手法

本節では、センサー行動認識及び本稿で使用する2つのアルゴリズムについて述べる。

3.1 センサー行動認識技術

本節では、センサー行動認識についての一連の流れについて述べる。まず、行動認識とはスマートフォンなどのウェアラブルデバイスにより収集されたセンサーデータを用いて機械学習を行い、「歩いている」「立ち上がる」といった人間の行動を推定する技術である[13]。センサー行動認識の分野では、主に教師あり機械学習を用いた人間の行動推定が行われているが、本稿では、センサー行動認識の一環として人間の行動における行動の軌跡予測を予測することが目的である。そのため、本来ウェアラブルデバイスのセンサーデータを使用しているが、今回は行動の軌跡予測を行うためウェアラブルデバイスよりも高精度なモーションキャプチャシステムにより収集された人間の行動センサーデータを使用することにする。

3.2 ランダムフォレスト

機械学習の手法としては、Random Forest を用いる[15]。Random Forest は教師データセット内の学習データから回帰・分類モデル作成に使用するデータをランダムに選択することで、教師データのノイズの影響を受けにくい学習器である。ブートストラップによるデータの抽出、バギングにより作成された多数の決定木を組み合わせることで予測・推定を行う。

3.3 ARIMA モデル

時系列分析では、自己回帰和分移動平均(ARIMA:auto regressive Integrated Moving Average) モデルは予測に広く使用されており、ARIMA(p, d, q)と表現される[14]。これは自己回帰と移動平均を組み合わせた自己回帰移動平均(ARMA:auto regressive Moving Average) モデルに d 階差分系列を組み合わせたものである。変数は自己回帰(p), 和分(d), 移動平均(q)の次数を表しており、これらを決定する必要がある。

4. 評価実験

本稿では人間の行動全体を予測するのではなく、急激な人間の行動を事前に予測することを目的としている。本手法の応用例として、中食・惣菜工場内の製造ラインや介護施設における協働ロボット導入を想定しているため、複数の行動における人間の急激な動きの予測が求められる。そのため、日常生活における複雑な行動を行っているデータセットを使用して行動軌跡を予測し、異なる手法における予測誤差の比較を行う。解析のためのプログラムは統計解析ソフト R を用いて作成した。本評価手法について以下に詳細を記載する。

4.1 実験データセット

本節では、使用する人間の行動データセットについて述べる。このデータセットは、我々の研究室で主催する Cooking Activity Recognition Challenge[16]のために 3 つのレシピ（サンドイッチ、フルーツサラダ、シリアル）をそれぞれ 5 回ずつ作成した料理行動のデータセットである。このデータセットには 4 人の被験者を含む 29 個のマーカーを用いたモーションキャプチャデータ、スマートフォン及びスマートウォッチによる加速度センサーデータにより構成されている。それぞれのファイルには「サンドイッチ」、「フルーツサラダ」といった対象レシピを意味する主行動と、「切る」、「皮を剥く」などのより詳細なマイクロアクティビティでラベリングされており、モーションキャプチャデータは 30 秒のセグメント毎に、加速度センサーデータは Time stamp により分割されている。

今回は、より高精度な予測を行うためにモーションキャプチャデータを使用する。モーションキャプチャにおけるマーカーの位置は、3D モーション分析に利用される修正されたヘレンヘイズマーカー配置[17]となっている。モーションキャプチャデータセットの詳細を表 1 に示す。

表 1 モーションキャプチャデータセット詳細

| | |
|----------------|---|
| 被験者 | 20 代男性 |
| 人数 | 4 人 |
| 測定場所 | 屋内 |
| 各測定回数 | 5 回 |
| 測定機器 | Motion Analysis Company 製 モーションキャプチャシステム |
| 赤外線カメラの台数 | 16 台 |
| 測定データ | 座標データ |
| マーカー取り付け位置 | 文献[17]における配置 |
| 周波数 | 100Hz |
| マクロアクティビティの種類 | 3 つのレシピ（サンドイッチ、フルーツサラダ、シリアル） |
| マイクロアクティビティの種類 | 8 種類の行動（開ける、切る、混ぜる、置く、加える、皮を剥く、洗う、取る） |
| 各セグメントの長さ | 30 秒 |

4.2 データセットレビュー

本節では、モーションキャプチャデータについて得られた情報について述べる。

4.2.1 マイクロアクティビティと被験者毎のデータ数

まず、モーションキャプチャデータに含まれるマイクロアクティビティの内訳を図 1、被験者毎のデータ数を図 2 に示す。

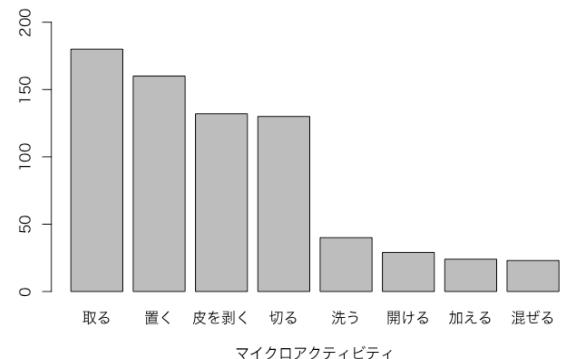


図 1 マイクロアクティビティの内訳

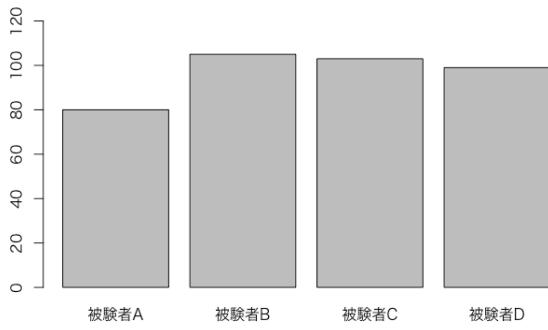


図 2 被験者毎のデータ数

図 1 より、モーションキャプチャデータセットにおけるマイクロアクティビティ「取る」、「置く」はデータ数が多く、「加える」、「混ぜる」はデータ数が少ないということが分かる。また、図 2 より被験者 B, C におけるデータ数はほぼ同程度であるが、被験者 A は他の被験者に比べデータ数が少ないことが分かる。つまり、料理行動におけるマイクロアクティビティにはデータ数の偏りがあるため、データの偏りに注意して評価を行う。

4.2.2 センサーデータの比較

次に、データセットからいくつかのデータを取り出し比較を行う。例として、レシピ「シリアル」におけるマイクロアクティビティ「取る」の右手首 x 軸を図 3、レシピ「フルーツサラダ」のマイクロアクティビティ「皮を剥く」の右手首 x 軸を図 4 に示す。

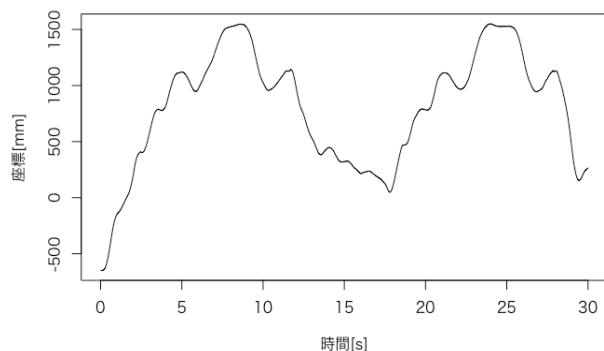


図 3 レシピ「シリアル」におけるマイクロアクティビティ「取る」における右手首 x 軸座標データ

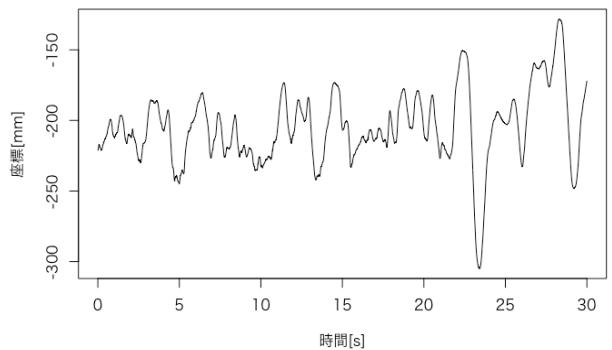


図 4 レシピ「フルーツサラダ」のマイクロアクティビティ「皮を剥く」における右手首 x 軸座標データ

図 3 では約 18 秒の周期性が確認できるため、同一の動作を繰り返していると考えられる。しかし、このデータには別の動作に移行する前の予備動作が含まれていないと考えられる。

また、図 4 では周期は確認できないが、24 秒付近でマイナス方向の大きな動きの前に予備動作と思われる正方向の動きが確認できる。そのため、このデータには別の動作に移行する前の予備動作が含まれていると考えられる。本稿では、このような予備動作が含まれているデータを使用して行動軌跡を予測し、予測モデルの精度評価を行う。

4.2.3 単位根過程の確認

2.2 節で述べたように、時系列データの多くは単位根過程に従うことが多い。そのため、今回使用するデータセットに単位根の有無を検証する必要がある。今回はデータセットの単位根過程を判断するために、ADF 検定により P 値を算出する。このとき、ADF 検定における帰無仮説を「単位根がある」、対立仮説を「単位根がない」とした。よって、ADF 検定により得られた P 値が 0.05 未満であれば帰無仮説が棄却され、「単位根がない」と言えるようになる。表 2 に 4.2.2 節で示した 2 つのマイクロアクティビティにおける ADF 検定の結果を示す。

表 2 ADF 検定の結果

| | |
|---------------------------------------|--------|
| レシピ「シリアル」における マイクロアクティビティ「取る」 | 0.3715 |
| レシピ「フルーツサラダ」における マイクロアクティビティ「皮を剥く」 | 0.01 |

表 2 より、レシピ「シリアル」におけるマイクロアクティビティ「取る」には単位根がないと言えないが、レシピ「フルーツサラダ」のマイクロアクティビティ「皮を剥く」には単位根がないと言えることが分かる。

これらより、本データセットにおけるレシピ「シリアル」におけるマイクロアクティビティ「取る」には単位根があ

る可能性が高いが、レシピ「フルーツサラダ」のマイクロアクティビティ「皮を剥く」には単位根がある可能性が低いといえる。そのため、本稿では予測に使用する全てのデータに ADF 検定を行い、レシピ「フルーツサラダ」のマイクロアクティビティ「皮を剥く」と同様の単位根がないということの出来るデータを使用する。

4.3 特徴量抽出

本節では、4.2.3 節で述べた ADF 検定により単位根がないと言えるモーションキャプチャデータを評価実験で使用するための座標変換、特徴量の抽出について述べる。

4.3.1 座標変換

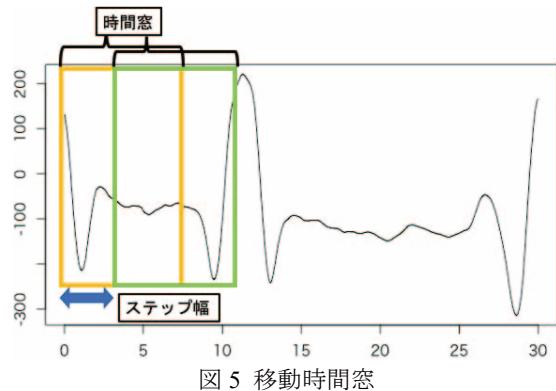
モーションキャプチャデータはワールド座標系であるため、ローカル座標系への三次元座標変換を行う。これはワールド座標系の場合、同じ行動でも異なる位置で行われた行動は異なる行動と判断されてしまうためである。変換するローカル座標系の原点は、上記の文献[17]におけるマーク-3 点骨盤定義に基づいて RightAsis と LeftAsis 及び V.scalar を結んだ平面の重心とした。

4.3.2 センサーデータの加工

評価実験で使用するデータは、モーションキャプチャデータから「皮を剥く」を含む右手首 x 軸のみ 43 データを対象とする。対象としたセンサーデータの中には欠測データも含まれていたため、各列データの平均値で欠測値補完を行う。前述の実験データセットから機械学習に必要な学習データ、テストデータとなるデータを特徴量として抽出する。この特徴量抽出を行うために、移動時間窓によるセグメンテーションを行う[13]。移動時間窓によるセグメンテーションを図 5 に示す。ランダムフォレストで使用するデータセットの加工条件における詳細を表 3 に示す。

表 3 データセットの加工条件

| | |
|----------|-----------|
| 時間窓幅 | 1 秒 |
| 時間窓のシフト幅 | 0.1 秒 |
| 対象データ | 右手首 x 軸座標 |
| 対象データ数 | 43 データ |
| 使用する特徴量 | 平均値、最小値 |



4.4 実験方法

時系列予測を行うために 3.3 節、3.4 節で述べた 2 つのアルゴリズムを使用する。

4.4.1 ランダムフォレストによる予測

4.3.2 で述べた移動時間窓を使用して 28 秒間の予測を行う。予測が 28 秒間となっているのは、移動時間窓によるセグメンテーションの影響で目的変数が存在しないためである。さらに、対象データにクロスバリデーションを行い、それぞれのデータの予測を行う。

4.4.2 ARIMA モデルによる予測

予測する 28 秒間の対象データを 1 秒毎に分割し、1 秒間のデータで次の 1 秒後の値を予測する。その後、予測した 1 秒後の値のみを抽出してデータを結合し、全体の予測結果とした。予測が 28 秒間となっているのは、4.4.1 で述べたランダムフォレストと比較するためである。

4.4.3 評価方法

4.4.1 節、4.4.2 節による予測結果から平均二乗誤差 (RMSE) を算出し、予測データ全体の精度を比較する。RMSE の式を以下に示す。本稿では下式の c をテストデータの目的変数とする。

$$RMSE(c) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - c)^2}$$

4.5 実験結果

評価実験のランダムフォレスト及び ARIMA の結果をそれぞれ 3 つずつ示す。図 6, 7, 8 にランダムフォレストによる予測結果①～③、図 9, 10, 11 に ARIMA による予測結果①～③を示す。

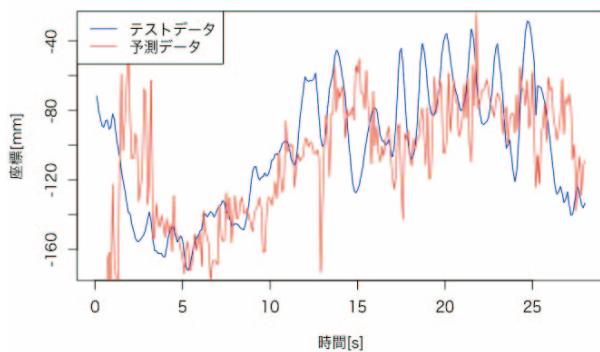


図 6 ランダムフォレストによる予測結果①

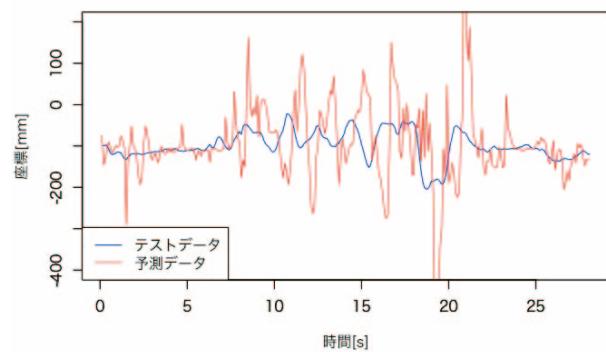


図 10 ARIMA による予測結果②

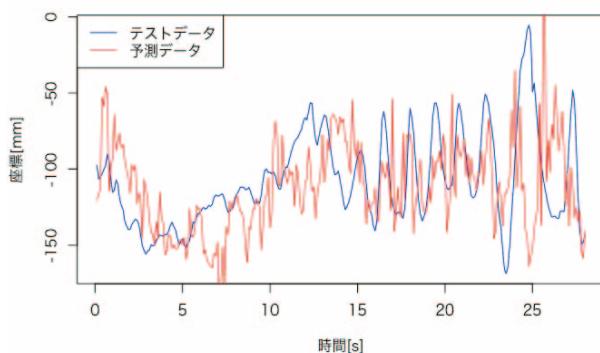


図 7 ランダムフォレストによる予測結果②

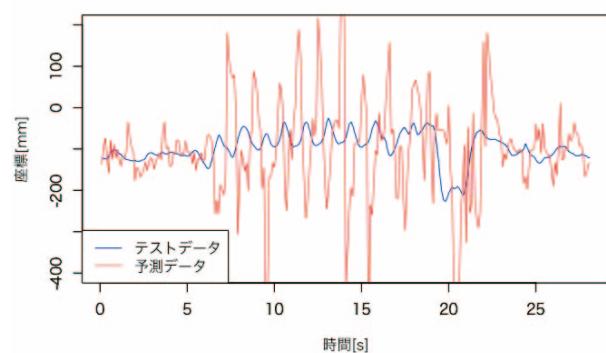


図 11 ARIMA による予測結果③

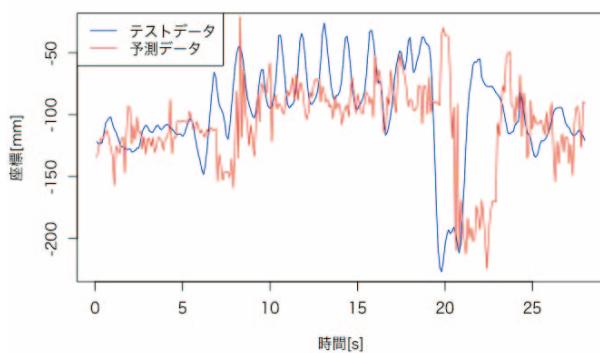


図 8 ランダムフォレストによる予測結果③

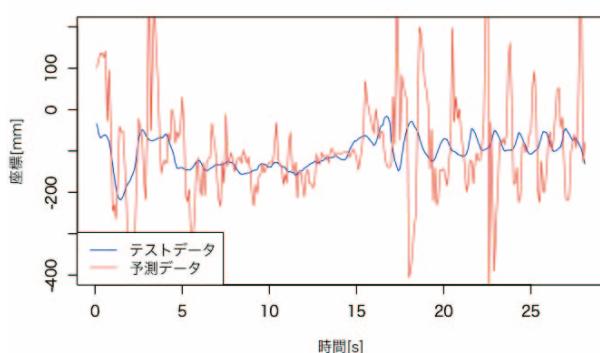


図 9 ARIMA による予測結果①

ランダムフォレストによる予測結果では図6より16秒附近、図7より15秒附近、図8より18秒附近に見られる予備動作と考えられる変化が予測できているように見えるが、どのデータもテストデータより1秒程遅れていることが分かる。

ARIMAによる結果では図9、10、11より、ランダムフォレストと同様に予測データはテストデータより1秒程遅れており、座標の変化が著しい箇所における予測精度が極めて低いことが分かる。

表4にランダムフォレスト及びARIMAによる予測結果①～③のRMSEを示す。

表4 予測データのRMSE [mm]

| | |
|------------|----------|
| ランダムフォレスト① | 85.2438 |
| ランダムフォレスト② | 85.3513 |
| ランダムフォレスト③ | 85.2124 |
| ARIMA① | 129.3787 |
| ARIMA② | 97.4048 |
| ARIMA③ | 124.5524 |

表4より、ランダムフォレストにおける予測結果①、②、③の平均RMSEは約85[mm]であるが、ARIMAでは約117[mm]なっていることが分かる。

4.6 考察

本節では、評価実験によってランダムフォレスト及びARIMAによる人間の軌跡予測を行った結果と、その結果を踏まえた上で今後の課題を考察する。

4.6.1 予測結果の比較

4.5節で述べたように、ランダムフォレスト及びARIMAの結果はどれもテストデータと比較して1秒程遅れて予測されていることから、今回のように単純に移動時間窓等の特徴量では予測が難しいといえる。

4.6.2 RMSE の比較

表4におけるランダムフォレストとARIMAのRMSEを比較すると約1.4倍の差が生じている。そのため、この結果を単純に比較した場合、ランダムフォレストの結果がARIMAよりも優れていると言える。

しかし、協働ロボットに搭載された場合を想定してそれぞれのRMSEを見た場合を考える。ランダムフォレストの予測結果では、人間の行動軌跡と協働ロボットが予測した軌道の誤差が85[mm]であることを示している。RMSEの値のみに注目した場合85[mm]の誤差と考えられるが、図6,7,8から分かるように1秒遅れの予測となっているため、実際の誤差はさらに増大すると考えられる。

5. まとめ

本稿では、複数の行動を含むデータから急激な人間の行動の事前予測を目的とした。行動データを基に軌跡予測モデルを作成し、データセットの行動軌跡から1秒後の行動軌跡を予測した。機械学習手法としてランダムフォレストを用い、ARIMAモデルで軌跡予測を行ったものと比較し評価した。本稿で使用したデータセットは、いくつかの異なる行動が連続しているため、行動が切り替わる直前の予備動作と考えられる値が確認できた。データセットにADF検定等を行い、単位根がある可能性が低いデータのみを使用したところ、テストデータと比較して1秒遅れの結果が得られた。予測精度は決して良いとは言えないが、軌跡予測を行っていく上の足がかりになったと言える。

本研究における今後の展開としては、新たな特徴量を使用する必要がある。さらに、今回はx軸座標のみで予測を行ったため、他の座標データも使用して予測を行うことで精度向上が見込まれる。また、使用する座標データを増やすだけでなく、軌跡予測に有効な特徴量についても試行していく必要がある。また、使用したデータセットに問題がある可能性もあるため、データセットの自作も視野に入れて研究を進める。

参考文献

- [1] 厚生労働省: I 平成30年の働く女性の状況、平成30年版働く女性の実情(令和元年6月24日公表)(オンライン), <<https://www.mhlw.go.jp/bunya/koyoukintou/josei-jitsujou/dl/18-01.pdf>> (参照 2020-05-06).
- [2] 厚生労働省: 2025年に向けた介護人材にかかる需給推計(確定値)について、厚生労働省 報道発表資料(オンライン), <<https://www.mhlw.go.jp/stf/houdou/0000088998.html>> (参照 2020-05-06).
- [3] 内閣府: 平成30年度少子化の状況及び少子化への対応施策の概況、内閣府 少子化社会対策白書(令和元年版)(オンライン), <<https://www8.cao.go.jp/shoushi/shoushika/whitepaper/measures/w-2019/r01pdgaiyoh/pdf/01gaiyoh.pdf>> (参照 2020-05-06).
- [4] 生田 幸士, 野方 誠: 福祉ロボットの安全性に関する統一的評価法の提案, 日本ロボット学会誌, Vol 17, No.3, pp.363-370, 1999.
- [5] 日本産業標準調査会: ロボット及びロボティックデバイス -産業用ロボットのための安全要求事項- 第1部: ロボット(オンライン), <<https://www.jisc.go.jp/app/jis/general/GnrJISNumberNameSearchList?toGnrJISStandardDetailList>> (参照 2020-04-30).
- [6] 毎日新聞社: 中食・工場: お弁当や総菜も自動化の波人手不足が深刻、毎日新聞社(オンライン), <<https://mainichi.jp/articles/20180728/k00/00m/020/055000c>> (参照 2019-11-11).
- [7] 株式会社アールティ: 人と一緒に弁当のおかずを盛り付ける、協働型サービスロボットの試作機を発表、株式会社アールティ(オンライン), <https://www.rt-net.jp/news/press_release20181001> (参照 2019-11-11).
- [8] Andrea Maria Bauer, Dirk Wollherr, Martin Buss: Human-Robot Collaboration: a Survey, International Journal of Humanoid Robotics, Vol 5, No.1, pp.44-66, (2008).
- [9] 理化学研究所: 介護支援ロボット研究用プラットフォームROBEAR, 理研-東海ゴム人間共存ロボット連携センター, <<http://rtc.nagoya.riken.jp/ROBEAR/>> (参照 2020-05-11)
- [10] Takuma Yagi, Karttikeya Mangalam, Ryo Yonetani, Yoichi Sato: Future Person Localization in First-Person Videos, IEEE/CVF Conference on Computer Vision and Pattern, (2018).
- [11] Tharindu Fernando, Simon Denman, Sridha Sridharan, Clinton Fookes: Soft + Hardwired attention: An LSTM framework for human trajectory prediction and abnormal event detection, Neural Networks (オンライン), Vol 108, pp.466-478 (2018).
- [12] Yiwei W, Yixuan S, Ji W and Wenlong Z: Optimal Collision-Free Robot Trajectory Generation Based on Time Series Prediction of Human Motion, IEEE ROBOTICS AND AUTOMATION LETTERS, Vol 3, pp.226-233, (2018).
- [13] 井上創造: ウェアラブルセンサを用いたヒューマンセンシング、知能と情報, Vol.28, No.6, pp.170-186, <<http://ci.nii.ac.jp/naid/40021082607/en/>>, (2016).
- [14] Box G.E.P. and G.M.Jenkins: Time Series Analysis, Forecasting and Control, Holden-Day, San Francisco (1970).
- [15] Sozo I, Naonori U, Yasunobu N, and Naoki N: Mobile activity recognition for a whole day, Recognizing real nursing activities with big dataset. Ubi-Comp 2015-Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, p.1269-1280, (2015).
- [16] Paula L, Shingo T, Sozo I, etc.: COOKING ACTIVITY DATASET WITH MACRO AND MICRO ACTIVITIES, <<https://ieeexplore.ieee.org/document/8437710>> (参照 2020-3-17).
- [17] David R. Burnett,1 Naira H. Campbell-Kyureghyan,2 Robert V.Topp,3 and Peter M. Quesad: Research Article Biomechanics of Lower Limbs during Walking among Candidates for Total Knee Arthroplasty with and without Low Back Pain, BioMed Research International, July (2015).