

人と共存するロボットのためのクラウド・エッジ連携に基づく基盤技術

代表研究者

加藤 由花

東京女子大学 現代教養学部・数理科学科 教授

1 研究の目的

少子高齢化，労働者人口の減少などを背景に，人に寄り添うロボット，人の作業を助けるロボットなど，人を支援/代替する人共存型ロボット技術への期待が高まっている．特に，移動機構（モビリティ）を有するロボットは，運搬，介助，案内・誘導，公共サービスへの配備など，多くのサービスへの展開が期待されている．ここでは，原則として人への接近・接触を禁止している産業用ロボット（工場に配備されるロボットなど）とは異なり，人の存在を前提とした作業空間における，対人安全性と作業性のバランスを考慮したモビリティ技術が必要になる．近年，IoT/ビッグデータ/AI 技術の進展により，人移動を含む作業環境側の状態を機械学習手法等で推定・予測することで，モビリティ機能を強化する試みが活発に行われている．しかし，制約のない環境で動作するサービスロボットには，多様性（コンテキスト依存）と不確実性（実世界性）という根源的な課題が存在し，十分なデータが集まらない，多様な環境に適用できない（環境ごとに学習・調整が必要）という問題，および予測の精度に応じた適切な制御（移動経路生成）が行えないという問題が生じている．

これらの課題の解決を目指して，本研究では，人・ロボット共存社会を実現するために，対人安全性と作業性のバランスを考慮した「移動ロボットのためのモビリティ基盤技術」の研究開発を行った．モビリティは多くのロボットサービスにとって必要不可欠な機能であるが，人の存在を前提とした作業空間では，人との近接関係を具体的に考慮した基盤技術は未だに確立されていない．本研究では，クラウド・エッジ連携により，汎用的な人移動モデルを機械学習とシミュレーションを併用することでクラウド上に構築し，エッジ側で収集するデータを用いて継続的にモデルを更新し，その結果をエッジ側に転移することで，ロボットでの実時間知的制御を実現する技術の開発を目指した．

2 課題の設定

本研究では，モビリティ基盤の開発を目的に，以下の2つの研究課題を設定した：(課題1) 環境を規定・制限できない状況において，どのように適応的に人移動モデルを構築するか；(課題2) 不確実性を伴う未来の人移動軌跡予測結果を，いかにロボットの経路生成に組み込むか．これらの課題を解決できれば，適応的にモデルを更新することで多様な環境での人移動軌跡を精度とともに予測し，その予測結果を経路計画に利用することで，対人安全性と作業バランスを考慮したモビリティ基盤を実現できる．本研究では，これらの課題を解決するために，具体的な研究項目として以下の4つ

を設定した：(A) 環境情報取得手法の開発；(B) 人移動軌跡予測モデルの構築；(C) 経路生成手法の開発；(D) クラウド・エッジ連携基盤の構築．モビリティ基盤の全体像と各研究項目の位置づけを図1に示す．

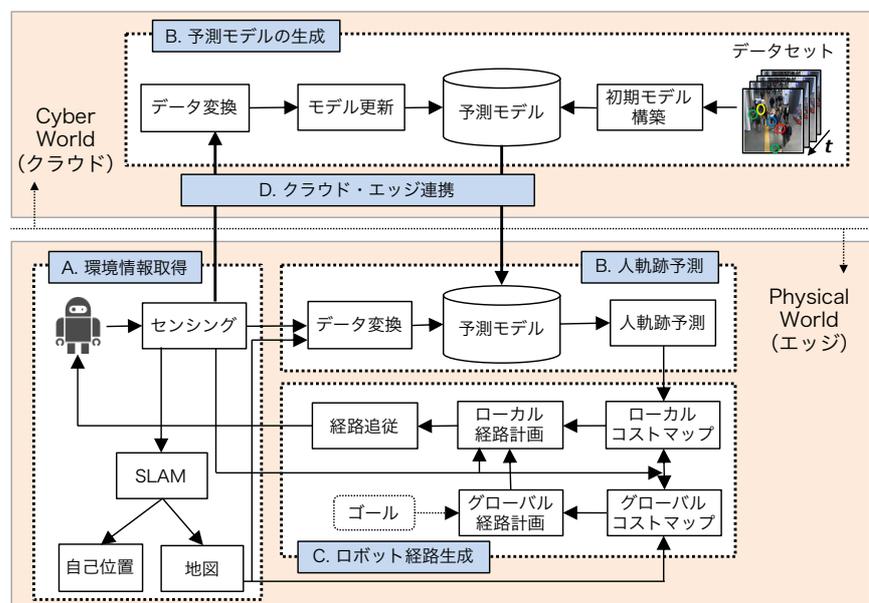


図 1：モビリティ基盤の全体像と各研究項目間の関係

3 研究成果

3-1 環境情報取得手法の開発

研究項目 A として、ロボットに搭載されたセンサーにより環境情報（エッジ側の情報）の取得を行い、センサーの計測範囲に入った人を追跡し、複数人の軌跡データをリアルタイムに計測する手法を開発した。具体的には、単一の LRF（Laser Range Finder）により、計測範囲に入った複数の人物を同時に追跡し、追跡データをリアルタイムに計測する手法、およびその結果を蓄積し、環境側データセットを構成する手法である[1][2]。

LRF による複数移動物体の追跡（Multiple Target Tracking）に関しては、

Rao-Blackwellized Particle Filter を用いる手法やその改良版等、多くの既存手法が存在する[3]。一般には、追跡の失敗を引き起こす要因であるオクルージョンの発生（軌跡の消失）やセグメンテーションの失敗、複数人の軌跡の混じり合い（軌跡のもつれ）等に対応するため、パーティクルの処理に何らかの工夫が施されている。本研究では、人物追跡自体には既存手法を用いるが、出力された各人の位置座標を一観測ごとに入力とし、ガウス過程回帰[4]（入力変数 \mathbf{x} から出力変数である実測値 \mathbf{y} への関数 $\mathbf{y} = f(\mathbf{x})$ を推定するモデルの一種、非線形性があること、ベイズ推定を用いる点に特徴がある）により移動軌跡を出力する手法を開発した。ここでは、少数の入力データから軌跡を予測することで仮想的に情報量を増やし、より精度の高い軌跡結果を出力している。具体的には、以下の2つのステップにより軌跡の補正を行う。

- データの事前処理：時間ステップに対して前後のデータの関係性を考慮することで、混じり合った軌跡を分離する処理（もつれた軌跡をほどく処理）を行う。
- ガウス過程回帰による軌跡の推定：少数の観測されたデータから推論モデルを構築することで、より高精度な軌跡推定を実現する。以下の式に示すように、ノイズを含む観測データ y_t （各時刻における座標）から潜在関数 $h(\cdot)$ を推論し、推論した関数を用いて時刻ごとの状態（軌跡）を推定する。

$$y_t = h(x_t) + \epsilon, \quad \epsilon \sim \mathcal{N}(0, \sigma_\epsilon^2)$$

ここでは、オクルージョン等による追跡失敗時のデータは欠損値またはハズレ値とみなされ、オンラインで追跡結果の予測分布が順次出力されていく。本研究では、5人分の移動軌跡データを、検出範囲4mのLRFで実際に計測し、本手法により経路を推定する評価実験を行った。結果を図2に示す。各点が入力データであり、推定された軌跡が曲線として出力されている。この実験結果から、従来手法では追跡が難しかった軌跡、特に複数人が重なり合い、単一のLRFでは追跡が困難であった軌跡を推定できていることがわかる。なお、実際には予測の分布（精度）が合わせて算出されるが、ここでは表示を省略している。

この出力結果は、環境側（エッジ側）の特性を表現するデータセットを構成するのに利用される他、研究項目 B および研究項目 C の入力として利用される。

3-2 人移動軌跡予測モデルの構築

研究項目 B では、多様な環境に適用可能な人移動軌跡予測モデルについて研究開発を行った。具体的には、環境に適したモデルを構築するための訓練データ構成法（クラウド上で初期モデルを構築する方法、図1クラウド側の研究項目 B に相当）、予測モデルを適応的に更新する手法（クラウド上でソフトウェアの自動チューニングを行う方法、図1クラウド側の研究項目 B に相当）、および予測モデルを用いて一人称視点のデータから移動軌跡を予測する手法（エッジ側で予測モデルを用いて観測データから軌跡を推論する方法、図1エッジ側の研究項目 B に相当）を開発した。

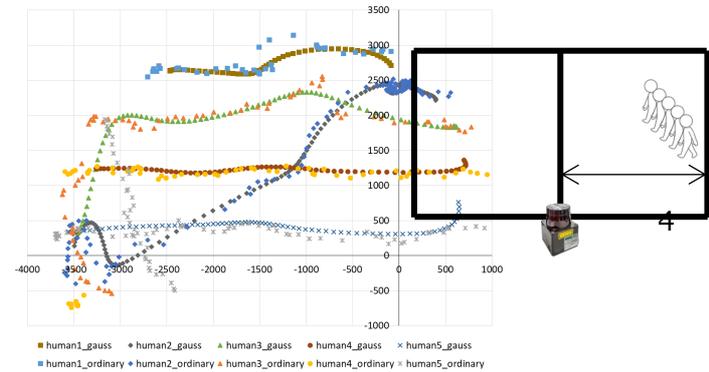


図 2 : ガウス過程回帰による人移動軌跡の追跡

(1) 訓練データ構成法

機械学習アルゴリズムを用いて歩行者の未来の移動軌跡を予測する場合、モデル構築時に訓練用に大量の移動軌跡データが必要である。しかし、一般の公共空間では、サービス提供前に十分な量のデータを収集しておくことは困難である。そこで、本研究では、様々な状況での歩行者移動軌跡を大量に含んでいる大規模データセットから訓練データを構成し、これを用いて学習済モデルを構築する手法を開発した [5][6][7]。これは、移動軌跡予測に転移学習を適用したときの、転移元データの構成法を明らかにすることに対応する。ここではまず、転移元（クラウド上のデータ）と

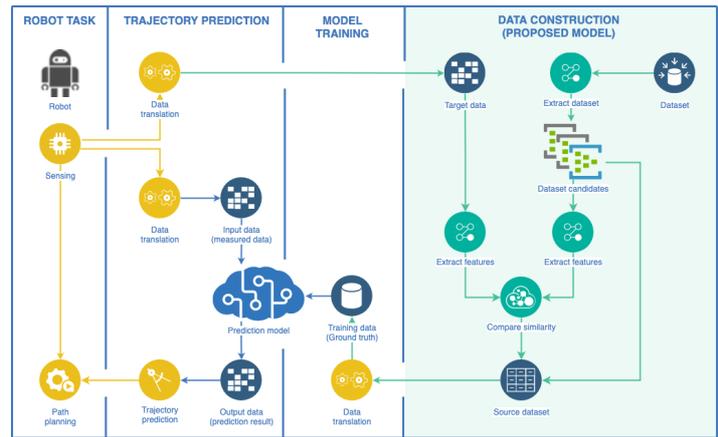


図 3：人移動軌跡予測の全体像

転移先（エッジ側のデータ、ここでは研究項目 A の出力結果）の特徴空間の性質をある関数で表現する。次に、これらの関数間の類似度を比較することで、適切な転移元データ集合を選択する。そして、選択されたデータ集合を用いて構築した学習済モデルを用いて軌跡の予測を行う。手法の全体像を図 3 に示す。

特徴空間の表現法については、歩行軌跡の分類に関する文献 [8] を参考に、歩行の速度ノルムと角速度ノルムを特徴量とする 2 次元の特徴空間を設定した。文献 [8] では、人の歩行軌跡の形態を、Static（静止）、Linear（線形移動）、Non-Linear（非線形移動）の 3 種類に分類し、Non-Linear についてはさらに詳細に分類している。速度ノルムと角速度ノルムによりこれらの分類が可能になるという仮説の下、本研究ではこれらの特徴量を用いることにした。特徴空間の性質の表現には、確率密度関数（多次元ガウス分布、および混合ガウス分布）、または確率質量関数（サンプル値の離散分布）を用いる。関数間の類似度は、相対エントロピーを意味するカルバック・ライブラー情報量 (Kullback-Leibler divergence: KL 情報量) [9] を用いて比較する。つまり、転移先データ集合と最も類似度の高い転移元データ集合を抽出し、そのデータ集合を入力とすることで、学習済モデルを構築する。

本研究では、提案手法の有効性を検証するために、大規模データセット (ATC pedestrian dataset) [10] から複数の転移元データ集合を抽出し、機械学習アルゴリズムによる予測結果の精度を比較する実験を行った。機械学習アルゴリズムとしては、既存の Social LSTM (一人の歩行者ごとに 1 つの LSTM モデルを定義し、近隣の歩行者同士で隠れ層を共有することで複数の歩行者の相互作用をモデルに組み込む手法) [11] を利用することとし、テストデータとしては深川江戸資料館 (<https://www.kcf.or.jp/fukagawa>) で実際に計測したデータから生成されたデータセット (研究項目 A の出力結果) と ETH Dataset [12] の 2 種類を用意した。特徴空間の性質の表現には確率質量関数を用いた。実験結果を表 1 に示す。

表 1：KL 情報量と予測精度 (ADE, FDE) との関係

ID	KL 値 (F)	ADE (F)	FDE (F)	KL 値 (E)	ADE (E)	FDE (E)
1	5.57	2.75	3.41	1.01	0.92	1.31
2	4.86	2.02	3.29	3.34	1.96	2.32
3	3.30	1.83	3.17	7.34	4.65	5.11
4	7.65	5.34	6.09	9.34	6.12	6.75

評価の指標としては、予測軌跡と真の軌跡 (Ground Truth) とのフレームごとの誤差 (ユークリッド距離、単位はメートル) の平均値 (ADE: Average Displacement Error)、および最終的な到達地点の予測値と真値の差 (FDE: Final Displacement Error) を用いている。この値が小さいほど精度が高いことを意味する。表 1 中の (F) は、テストデータとして深川資料館での実測値を用いた結果、(E) は ETH Dataset を用いた結果である。

これらの結果からは、(i) KL 値が小さいデータセットを利用することで、軌跡予測の精度が高くなること、つまり適切な学習済モデルが構築されること (F, E どちらも、KL 値が最小となるデータセットで構築した

予測器の精度が最も高い), (ii) 転移先が異なると適した転移元データも異なること (F は ID=3 の精度が最も高く, E は ID=1 の精度が最も高い) がわかる. つまり, 提案手法により, 経路予測の精度が高い適切な学習済モデルの構築が可能であることがわかった. 人移動軌跡の予測結果を可視化した例 (転移先が深川資料館の場合) を図 4 に示す. 緑線で表現した観測データ (入力データ) に対し, 赤線で表現した予測データが出力された. 黒線が真値である. この結果からも, 適切な転移元データを抽出することで, 予測精度の向上が期待できることを読み取れる.

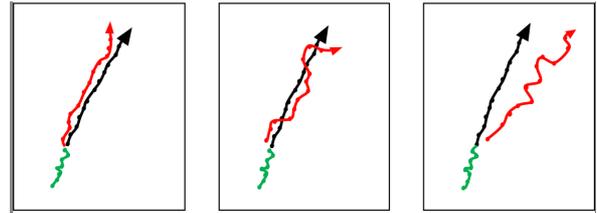


図 4: 人移動軌跡の予測結果を可視化した例 (左: ID3, 中: ID2, 右: ID4)

(2) 予測モデル更新手法

予測モデル更新手法については, HPC 分野の共同研究者と連携し, クラウド環境でのハイパーパラメータ自動チューニング技術の開発を行った[13][14][15][16]. ここでは, プログラムを実行しながら自動で性能パラメータの最適化を行うソフトウェア自動チューニング技術を活用し, 特に, 複数の性能パラメータの取りうる値からなる離散空間上の探索問題として本課題を定式化した. 具体的には, 限られた空間から徐々に探索の範囲を広げ, 離散空間上を効率よく探索する反復 1 次元探索手法[17]を利用し, (1) で提案した軌跡予測プログラムのハイパーパラメータ自動チューニングを実現した. 検証実験により, チューニング時間を大幅に削減できること (並列化の影響もあるが, 今回の実験環境では 1/20 程度に削減), 軌跡の予測精度が向上することを確認している.

本研究では, 機械学習プログラムにおけるハイパーパラメータの自動チューニングにのみ開発手法を適用したが, 同様の仕組みを用いて, またチューニング対象の粒度を変えることで, 予測モデルの適応的な更新が可能になる. さらに, クラウド・エッジ連携については, ssh を利用したデーモン常駐によるシームレス/高速データ転送機能の設計を行っている (実装については今後の課題である). これにより, クラウド側でのチューニング結果をエッジ側に転送可能になる. 今後, これらの機能を組み合わせることにより, 適応的なモデル更新を実現する予定である.

(3) 移動軌跡予測手法

移動軌跡の予測については, まず, LRF の計測範囲内に入った人の位置追跡およびロボットの自己位置推定を行いながら, データ変換を行うことで (1) で構築した予測モデルに系列データを入力する. その結果, 未来の軌跡データが, 予測系列データとして出力される. 本研究では, 前述した江戸深川資料館において実測した人移動軌跡データを用いて, 軌跡予測実験を行った. 結果を図 5 に示す. 下図が計測対象のフロアであり, 上図と中図が真値 (青点), および予測値 (赤点) である. 計測周期は 10Hz, 系列データとしては, 8 フレーム分の入力データから, 未来軌跡に相当する 12 フレーム分のデータを予測している. 本実験により, (1) で構築したモデルを実環境で利用可能であることが検証できた.

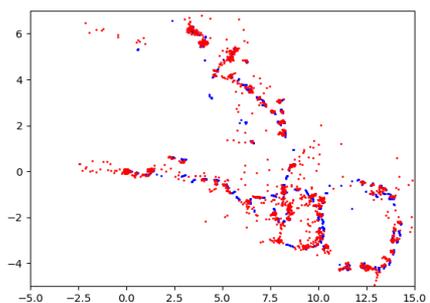
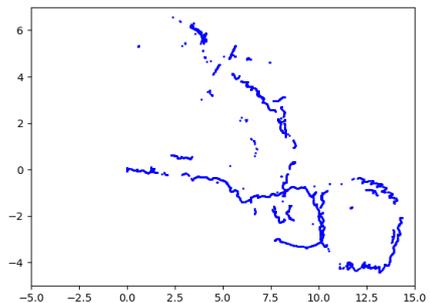


図 5: 江戸深川資料館での実験結果

3-3 経路生成手法の開発

研究項目 C では, 研究項目 A の出力結果を入力とし, 強化学習により構築された予測モデルを用いて経路生成を行う手法を開発した. 強化学習は, 行動の主体であるエージェントが環境

の状態を観測し、何らかの行動により報酬を得るという一連の流れを繰り返すことで、得られる報酬の期待値を最大化する行動を獲得する手法である。本研究では、時間の経過と歩行経路への侵入に対して負の報酬を与えることで、安全性と効率性の双方を考慮した行動をシミュレータ上で学習させた[17]。環境に依存しない行動を学習させるために、状態として、通常利用されることの多い絶対座標系における歩行者・ゴールの位置座標の代わりに、ロボットに設定された相対座標系における位置座標を利用している。また、観測された歩行者の速度と移動方向を状態に組み入れることで、歩行者の移動傾向を考慮している。さらに、構築したモデルを実ロボットに組み込むことで、実環境においても適切な経路が生成されることを確認している[18]。

具体的には、ロボットシステムとして、以下に示す6つの機能からなるシステムを設計した：(i) 環境情報の取得；(ii) 環境地図の構築；(iii) 自己位置推定；(iv) 障害物の検知・追跡；(v) 経路計画；(vi) モータの制御。ロボットシステムの構成を図6に示す。ここでは、SLAMにより予め構築しておいた環境地図と、ロボットに搭載されたセンサーから取得したデータを用いて、自己位置推定を行いながら、障害物（この場合は歩行者）の検知と追跡を行う。それらのデータから状態を把握し、事前学習により獲得しておいた方策を用いて、経路計画を行う。経路計画に従いモータ制御を行うことで、ロボットは歩行者を回避しながらゴールに到着する。ロボットの実装には、ロボット用ソフトウェアプラットフォームであるROS（Robot Operating System）を利用した。ROSでは、提供されている様々なパッケージを組み合わせることでシステムを構築することが可能である。図6中の青字は、実装時に用いたROSパッケージの名称である。

ロボットシステムのうちの経路計画は、Q学習による学習フェーズと経路計画フェーズの2段階で構成される。学習フェーズでは、シミュレータ上の環境で人移動軌跡データを使用し、ロボットと歩行者、目標地点の位置関係や歩行者の速度、移動方向などの状態に応じてエージェントがロボットに与える制御指令を学習する。これにはPythonで自作したシミュレータ（文献[19]をベースとしている）を用いた。シミュレータによる学習の例を図7に示す。赤丸はロボット、青丸は歩行者、旗は目標地点（ゴール）である。星印は自己位置推定用のランドマークであり、実験結果に直接影響を及ぼすものではない。歩行者とランドマークには識別用のIDを割り当てている。黒線はロボットの移動軌跡を表し、ピンク色の線分はセンサーによる観測を意味する。青色の楕円はカルマンフィルタによる自己位置推定における信念分布を表し、ロボットの右上に推定姿勢が表示されている。reward/secは時刻 t に獲得した報酬、evalは時刻 t までの累計報酬を表す。シミュレーション環境は、10[m]×10[m]の正方形領域内に、正方形の中心を原点とする二次元直交座標系を設定し、環境内に1台のロボット、1つのゴール、1人の歩行者を配置することで構築した。歩行者は、シミュレータ外部から与える歩行者移動軌跡データを使用して移動し、ロボットはセンサーによりこれを観測できるものとした。ロボットに搭載するセンサーについては、HOKUYO製URG-04LX-UG01の製品仕様を参考に設定した。ロボットへの制御司令は、左回転、直進、右回転に相当する値を設定している。経路計画フェーズでは、事前に学習フェーズで獲得した方策を参照することにより目標地点到達までの経路計画を行う。

本研究では、これらの設計結果に従い、実ロボットに機能を実装し、ナビゲーション手法が有効に機能することを検証した。ここでは、図

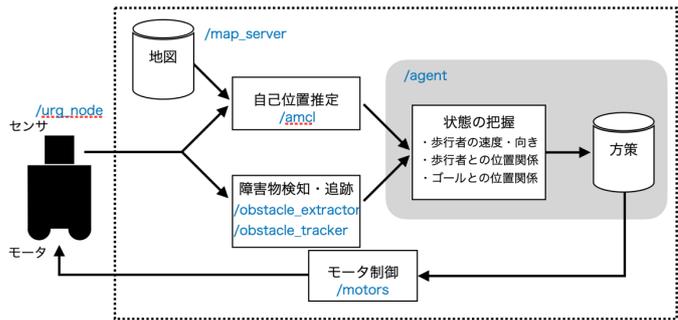


図6：ロボットシステムの構成

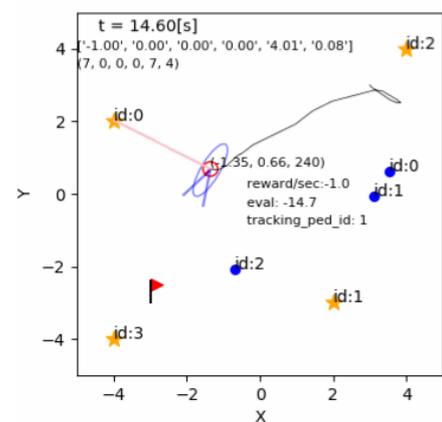


図7：シミュレータによる学習の例



図8：実験に利用したロボット

8に示す小型車輪型ロボット（RT製 Raspberry Pi Mouse に前述した URG-04LX を搭載したロボット）を利用した。シミュレーション環境と同様の正方形の区域において、ロボットの初期位置と目標位置を設定し、対象領域内に歩行者が侵入した際のロボットの行動を観察した。具体的には、ロボットの初期位置を (0.0, 0.0)、目標位置を (2.0, 0.0) に設定し、歩行者が y 軸の負の方向から領域内に侵入する（ロボットの左側から出発し、ロボットの初期位置方向に進む）条件で実験を行った。その結果、ロボットは歩行者を観測した後、歩行者の進行方向と逆向きに回転しながら歩行者の通過を待ち、その後ゴール地点まで到達する行動を取ることが確認できた。ゴール到着の成功率、平均時間等、より詳細な評価実験は今後の課題であるが、本実験により、提案手法が実機において有効に機能することが検証できた。

経路生成は強化学習モデルで実現したが、研究項目 B の結果をマップ生成に組み込むことで手法の拡張が可能である。現在、継続して研究開発を進めている。

3-4 クラウド・エッジ連携基盤の構築

研究項目 D では、研究項目 A~C を統合し、クラウド・エッジ連携に基づくモビリティ基盤を設計した。管理モジュールの設計については、論理センサクラウド（クラウドと IoT の統合システム管理基盤）のシステム構成を設計した[20]。実装までは行えなかったが、これがクラウド・エッジ連携の枠組みとなる。

今回、クラウド側とエッジ側をリアルタイムで連携させ、一気通貫の実験を行うことはできなかった。しかし、モビリティ基盤のベースとなる各要素技術の研究開発は完成した。また、これらの要素技術をオフラインで連携させ、人と共存する環境においても、安全性・効率性を考慮したロボットの自律移動が可能であることが検証できた。具体的には、研究項目 A の出力から、研究項目 B における転移先データセットを生成した。ここでは、歩行の速度ノルムと角速度ノルムを特徴量とする 2 次元の特徴空間を設定することで、環境情報の表現が可能であることを確認した。研究項目 A の出力は、研究項目 B における推論フェーズの入力データ、および研究項目 C における経路計画フェーズの入力データとしても利用された。研究項目 B においてクラウド上に構築された歩行軌跡予測器は、オフラインでエッジ側に転送され、推論フェーズで利用された。リアルタイムでの機能転送については、設計段階であるが、今後検討を進めていく予定である。この歩行軌跡予測器の出力を研究項目 C に取り込むことも今後の課題である。

3 今後の予定

当初の目標である、実時間知的制御を実現するためのソフトウェア実装を目指して、今後引き続き、モビリティ基盤としての拡張、リアルタイム連携を進めていく予定である。将来的な計画としては、研究成果を移動型サービスロボット（VECTOR 社 コンシェルジュ など）に応用することを検討しているが、研究調査期間内では小型ロボット（Raspberry Pi Mouse）への実装が完了した。現在、これを移動型サービスロボットへ実装するための準備を進めているところである。経路計画モジュールは汎用的な ROS パッケージ（ROS ノード）として構築されているため、簡易な調整でサービスロボットへの実装が可能であると考えている。

今後、人の存在を前提とした作業空間におけるモビリティ基盤によって、移動ロボットを様々なサービスに展開することが可能になる。公共施設内での構内誘導や、店舗案内、買い物支援などである。本研究の成果を活用し、人・ロボット共存社会の実現を目指していく。また、ロボットの存在を前提とした人移動モデル等、より一般的な環境への拡張も進める。

【参考文献】

- [1] 田島仁奈, 加藤宏一朗, 黒川大悟, 松日楽信人, 天野可奈子, 加藤由花: 受付など通過歩行時の人数推定 RTC の開発, 計測自動制御学会 SI 部門講演会 (SI2020), 1S1-03, 2020.
- [2] N. Tajima, K. Kato, D. Kurokawa, N. Matsuhira, K. Amano, and Y. Kato: Development of a Walking-Trajectory Measurement System, IEEE International Conference on Mechatronics and Automation (ICMA 2021), 2021. (to appear)
- [3] S. Sarkka, A. Vehtari, and J. Lampinen: Rao-Blackwellized Particle Filter for Multiple Target Tracking, Information Fusion, Vol. 8, No. 1, pp. 2-15, 2007.

- [4] C. E. Rasmussen and C. K. I. Williams: Gaussian Process for Machine Learning, The MIT Press, 2006.
- [5] 赤羽根里奈, 加藤 由花: 人物追従ロボットのための歩行者経路予測における機械学習用データ構成法, 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウム, pp.838-843, 2020.
- [6] 赤羽根里奈, 加藤由花: 人物追従ロボットのための歩行者経路予測における機械学習用訓練データの構成法, 情報処理学会マルチメディア通信と分散処理 (DPS) ワークショップ, pp.203-208, 2020.
- [7] R. Akabane and Y. Kato: Pedestrian Trajectory Prediction Using Pre-trained Machine Learning Model for Human-Following Mobile Robot, 2020 IEEE International Conference on Big Data Workshop (IoTDA 2020), pp.3453-3458, 2020.
- [8] P. Kothari, S. Kreiss, and A. Alahi: Human Trajectory Forecasting in Crowds: A Deep Learning Perspective, arXiv:2007.03639 [cs.CV], 2020.
- [9] S. Kullback and R. A. Leibler: On Information and Sufficiency, The Annals of Mathematical Statistics, Vol. 22, No. 1, pp. 79-86, 1951.
- [10] D. Brscic, T. Kanda, T. Ikeda, and T. Miyashita: Person Position and Body Direction Tracking in Large Public Spaces Using 3D Range Sensors, IEEE Trans. on Human-Machine Systems, Vol. 43, No. 6, pp. 522-534, 2013.
- [11] A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei, and S. Savarese: Social LSTM: Human Trajectory Prediction in Crowded Spaces, IEEE CVPR 2016, pp. 961-971.
- [12] S. Pellegrini, A. Ess, K. Schindler, and L. V. Gool: You'll never walk alone: Modeling Social Behavior for Multi-Target Tracking, IEEE ICCV 2009, pp. 261-268, 2009.
- [13] T. Tabeta, A. Fujii, T. Tanaka, Y. Kato, S. Ohshima and T. Katagiri: Enhancing the Performance of Robot Control Technology by Automatic Tuning Hyperparameters of Machine Learning, Exhibit at SC20 (the International Conference for High Performance Computing, Networking, Storage, and Analysis), 2020.
- [14] 藤家空太郎, 多部田敏樹, 藤井昭宏, 田中輝雄, 加藤由花, 大島聡史, 片桐孝洋: GPU クラスタを用いて並列化した自動チューニングの機械学習プログラムへの適用と安定性の検証, 情報処理学会ハイパフォーマンスコンピューティング研究会, HPC-178, pp.1-8, 2021.
- [15] 多部田敏樹, 藤家空太郎, 藤井昭宏, 田中輝雄, 加藤由花, 大島聡史, 片桐孝洋: マルチ GPU 環境における機械学習ハイパーパラメータの自動チューニング(1), 情報処理学会全国大会, 2H-06, 2021.
- [16] 藤家空太郎, 多部田敏樹, 藤井昭宏, 田中輝雄, 加藤由花, 大島聡史, 片桐孝洋: マルチ GPU 環境における機械学習ハイパーパラメータの自動チューニング(2), 情報処理学会全国大会, 2H-07, 2021.
- [17] 望月大義, 藤井昭宏, 田中輝雄: ソフトウェア自動チューニングにおける複数同時性能パラメータ探索手法の提案と評価, 情報処理学会論文誌, Vol. 11, No. 2, pp. 1-16, 2018.
- [17] 一色春香, 天野加奈子, 加藤由花: 歩行者の移動傾向を考慮した強化学習による自律移動ロボットナビゲーション, 情報処理学会マルチメディア通信と分散処理研究会, DPS-186, pp.1-7, 2021.
- [18] 天野加奈子, 加藤由花: 人と共存する自律移動ロボットにおける安全性と効率性を考慮したナビゲーション手法の評価, 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2021) シンポジウム, 2021. (発表予定)
- [19] 上田隆一: 詳解 確率ロボティクス, 講談社, 2019.
- [20] 串田高幸, 永島寛子, 加藤由花: 論理センサクラウド --クラウドと IoT の統合システム管理--, 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウム, pp.428-437, 2020.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
人物追従ロボットのための歩行者経路予測における機械学習用データ構成法	情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウム	2020年6月
論理センサクラウド -クラウドとIoTの統合システム管理 -	情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウム	2020年6月
Enhancing the Performance of Robot Control Technology by Automatic Tuning Hyperparameters of Machine Learning	Exhibit at SC20 (the International Conference for High Performance Computing, Networking, Storage, and Analysis)	2020年11月
人物追従ロボットのための歩行者経路予測における機械学習用訓練データの構成法	情報処理学会マルチメディア通信と分散処理 (DPS) ワークショップ	2020年11月
受付など通過歩行時の人数推定 RTC の開発	計測自動制御学会 SI 部門講演会 (SI2020)	2020年12月
Pedestrian Trajectory Prediction Using Pre-trained Machine Learning Model for Human-Following Mobile Robot	2020 IEEE International Conference on Big Data Workshop (IoTDA 2020)	2020年12月
GPU クラスタを用いて並列化した自動チューニングの機械学習プログラムへの適用と安定性の検証	情報処理学会ハイパフォーマンスコンピューティング研究会	2021年3月
歩行者の移動傾向を考慮した強化学習による自律移動ロボットナビゲーション	情報処理学会マルチメディア通信と分散処理研究会	2021年3月
マルチ GPU 環境における機械学習ハイパーパラメータの自動チューニング(1)	情報処理学会全国大会	2021年3月
マルチ GPU 環境における機械学習ハイパーパラメータの自動チューニング(2)	情報処理学会全国大会	2021年3月
人と共存する自律移動ロボットにおける安全性と効率性を考慮したナビゲーション手法の評価	情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2021) シンポジウム	2021年7月 (発表予定)
Development of a Walking-Trajectory Measurement System	IEEE International Conference on Mechatronics and Automation (ICMA 2021)	2021年8月 (発表予定)