

デジタルツイン・AI 技術と微分幾何学の応用による自律型ロボットの革命的な知能化と効率の向上に関する研究

山梨大学大学院 総合研究部 工学域

孫 瀟

1. はじめに

少子高齢化の傾向が止まらない中、ロボットと AI 技術での人手不足解消に多くの期待が寄せられている。ロボットに期待される未来像も従来のように安全かごの中に囲まれ、人間が指定した単一な動きをひたすら繰り返すのものから、配膳ロボットのように人間と同じ空間で働くサービスロボットや人間と賢くコミュニケーションを行い、直接握手までできる「ペッパー君」のようなインタラクティブロボットにシフトし始めている。また人間と直接関係ない場合においても、スマート農業を代表とするロボット技術の新興分野では農作物などの対象物を正確に認識し、適した位置まで移動し収穫等の作業を実現するには AI 技術の役目は欠かせない。

ところが AI ロボットの実運用において、一つ大きな難関として認識されているのが学習効率である。画像認識など専らデジタルデータのみを対象とする場合、瞬間で大量のデータを処理できるため学習効率が良い。しかしながら現実世界で各種実物を対象とする場合、デジタルデータとして直接扱うことができないため、実物の把持・操作や移動など、各種基本的なタスクにおいても現実世界で成功するまで一回一回実行しながらデータを取得し、そして AI 技術を用いてそのデータを学習しなければいけない。従ってデジタルデータのみを用いた学習と比較した場合、概算で効率が 1/1000 以下になるだけでなく、実験環境の用意・設置にも金銭的・人力的コストが多く必要となる。2016 年に Google が実施したロボットの AI 学習では、図 1 に示す 14 台のロボットアームとグリッパを用いて 800,000 回を超える物体把持を約 3,000 時間内に実行し、物体把持の失敗率を最大で 10% 以下に抑えることに成功した¹⁾と発表した²⁾が、実際に費やした膨大なコストからもロボット実機を動かして AI 学習を行う際どれだけ効率が低下するかが伺える。



図 1 14 台のロボットアームとグリッパによる物体把持の AI 学習の様子

そこで本研究は近年より急速に発展し、頭角を現しつつある技術“デジタルツイン”（以下 DT と略す）を活用する。DT とは、シミュレーションなどにおいて実在するモノのデジタルコピーを作成することで、そのモノの管理やパフォーマンス向上などにおいて様々なデジタル手法が使えるようになる技術である（諸説あり）²⁾。分かりやすい例を挙げると、ロボッ

ト、環境や対象物を含む実物をシミュレータ内にモデルとして構築し、そしてこれらのモデルを本物と同じもしくは近い性質を持つようにすれば、ロボットの AI 学習を現実ではなくシミュレータ内で非常に高速に行うことが可能になる。研究者らも過去の研究にて DT 技術のひな形として等身大四肢型ロボット「WAREC-1」の電動ドリル把持作業に DT を用いることで深層強化学習の効率が概算で 1000 倍以上向上し、またコストも 1/100 以下に抑えた³⁾。以上のように、ロボットへの AI 技術の応用において DT は非常に有用かつ有望であるのにもかかわらず、残念ながら技術ハードル、人的・金銭的リソースや理解の不足により DT の応用はまだ広がっていない。そのため DT の技術的な普及と幅広い日常的なシチュエーションでの運用を目指し、本研究は移動と物体操作が可能な自律型ロボットをプラットフォームとして、DT と相性の良い AI 技術と微分幾何学を統合ことでロボットの革命的な知能化と学習効率の向上を目標とする。

2. ロボットにおけるデジタルツイン(DT)技術と微分幾何学の現状、課題とその対策

DT 技術自体の概念は 2002 年頃に提唱（諸説あり）されたが、実際の応用に関しては NASA「アポロ計画」の 1960 年代まで遡ることができる。産業界では 2012 年頃からその概念が浸透し始めており、2017 年頃より研究と開発が急増している。また世界 GDP 上位 5 か国の米、中、日、独、英も各国のテクノロジー政策の中心として DT を重要視している⁴⁾。

ただし、新興技術分野にありがちな現象の一つとして、DT の基本概念に抽象性と曖昧性が残る。現時点でも業界内では DT に対する定義すら共通認識に至っておらず、また公式に発表された規格や統一したソフトウェアプラットフォームがほとんどなく「未開の地」が多い。以上の事情により、一部の企業や研究機関では実体のシミュレーション、モニタリング、IoT もしくは機械学習いずれかの単体を DT と呼称・認識するケースが散見されるが、少なくとも本研究における DT の定義はこれらとは異なることをまずは断っておきたい。研究者は英国ケンブリッジ大学の Sharma ら⁵⁾の指摘通り、DT は IoT、機械学習やシミュレーションなどのどれか単一の技術ではなく、これらすべてを統合したものであると考えている。




図2 本研究の基本コンセプトと各要素間の関係

また特筆すべき点として、以上の技術を統合することにより、DT 技術は本来の役割であるデジタルコピーを用いた実体の向上を図れるだけでなく、実体から取得したデータをもとにデジタルコピーを随時更新し、実物とデジタルコピーの間で双方向の「自己進化」循環を遂

げることが可能である。この特徴は構成部品が多く、また複雑な特性を持っている実物であればあるほどデジタルコピーの「自己進化」が必要なため、不可欠であると考える。そこで研究者は上記の「自己進化」循環を活用できる研究を提案する。本研究の基本コンセプトを図2に示す。

図2の通り、ロボットのAI学習効率向上を目的とするDT技術の「自己進化」循環を実現するためにはセンシング技術や実物のモデリングに微分幾何学の知識も用いる。変形しない剛体と比較すると、柔軟物を代表とする非剛体のモデリングは難しく、ゆえにロボットによる把持や操作も決して容易ではない。柔軟物の幾何学的分析の理論基礎⁶⁾はすでに存在するが、生地、濡れ具合、大きさなどの違いで変形の具合や弾性が大きく異なる実際の柔軟物に直接適用できるわけではない。そのため微分幾何学を用いたモデリング、ロボット実機による柔軟物の把持実験とセンシングデータの学習結果に基づいたモデリング修正の三者を繰り返すことで柔軟物のモデリングの精度を高め、柔軟物のDTを構築するとともにDTの「自己進化」循環を目指す。

3. 構築したAIロボット・センシングシステムの構成とDT技術・微分幾何学の応用

本研究で用いるロボットは柔軟物を含む対象物を把持・操作するロボットアーム2台（Elephant Robotics myCobot, Niryo NED）とAGV（無人搬送車）ロボット1台（Elephant Robotics myAGV）を選定した。そのうち1台のロボットアーム（myCobot）はAGVロボットと組み合わせることで移動・把持操作マルチロボットプラットフォームとして運用し、残りの1台（NED）は据え置き型として、柔軟物のセンシングおよびモデリングに必要なロボット実機として用いる。これらロボットの概要を図3に示す。




図3 本研究で用いるロボットの概要

センシングシステムにおいては、採用した各センサの種類、型番と用途をそれぞれ表1にまとめた。

表 1 本研究におけるセンシングシステムの概要

項目	型番	用途
3D スキャナ	Revopoint MINI 2	ロボットおよび環境の静的 3D データの取得
Web カメラ	–	把持・操作対象物認識用
3D デプスカメラ	Astra Pro 2	AGV の移動経路生成と自律移動用
近距離用高精度 デプスカメラ	Intel RealSense D405	柔軟物のセンシング・モデリング用

また、本研究の主なフレームワークとなる DT ソフトの構築においては、ハードウェアのスペックや互換性に最適な ROS2（ミドルウェア）、Gazebo（シミュレータ）と Rviz2（可視化・制御ツール）を採用した。シミュレータ内のロボットモデルの一例を図 4 に示す。




図 4 シミュレータ内のロボットモデルの例




図 5 本研究のロボット・センシングシステムの構成

上記のロボット・センシングシステム構成を図5にまとめる。なお、ロボットの最大ペイロードや可動範囲のデータを考慮し、対象物は主にハンドタオル等の軽量かつ中～小サイズの物とする。

実際の柔軟物のモデリングには高精度デプスカメラと3Dスキャナから取得した柔軟物の3Dデータに基づき、微分幾何学の概念であるガウス曲率を用いた。参考として定義を以下に示す。

領域 D で定義されるパラメータ u, v を用いれば、空間内の曲面を

$$\mathbf{S}(u, v) = (x(u, v), y(u, v), z(u, v)), u, v \in D \quad (1)$$

と表現でき、また曲面の接ベクトルを

$$\mathbf{S}_u(u, v) = \frac{\partial \mathbf{S}(u, v)}{\partial u}, \mathbf{S}_v(u, v) = \frac{\partial \mathbf{S}(u, v)}{\partial v} \quad (2)$$

と表せ ($\mathbf{S}_u$ と $\mathbf{S}_v$ が一次独立であると仮定する), 曲面の法ベクトルを

$$\mathbf{n}(u, v) = \frac{\mathbf{S}_u(u, v) \times \mathbf{S}_v(u, v)}{|\mathbf{S}_u(u, v) \times \mathbf{S}_v(u, v)|} \quad (3)$$

と表せる。これをもとに曲面の第1基本形式

$$I = d\mathbf{S} \cdot d\mathbf{S} = Edu^2 + 2Fdudv + Gdv^2 \quad (4)$$

および曲面の第2基本形式

$$II = -d\mathbf{S} \cdot d\mathbf{n} = Ldu^2 + 2Mdudv + Ndv^2 \quad (5)$$

が定義される。ただし、

$$E = \mathbf{S}_u \cdot \mathbf{S}_u, F = \mathbf{S}_u \cdot \mathbf{S}_v, G = \mathbf{S}_v \cdot \mathbf{S}_v \quad (6)$$

$$L = -\mathbf{S}_u \cdot \mathbf{n}_u, M = -\mathbf{S}_u \cdot \mathbf{n}_v, N = -\mathbf{S}_v \cdot \mathbf{n}_v \quad (7)$$


である。さらに式(6)と(7)の結果を用いて下記の通りガウス曲率 K が求められる。

$$K = \frac{LN - M^2}{EG - F^2} \quad (8)$$

4. 研究成果と考察

本研究では、取得した柔軟物の3Dデータから離散的な曲面を構築した上で、その上にある点のガウス曲率を計算する。ガウス曲率が一番高い箇所、すなわち最も突出（なお凹部のガウス曲率はマイナスとなるため除外できる）している箇所を把持した場合最も成功しやすい傾向があるため、その箇所を把持候補位置として座標を取得し、記録する。特筆すべき点としては、研究者の実機実験結果から、センサから見て最も「高い」位置と周囲と比べて最も顕著に「突出」している位置は必ずしも一致しないだけでなく、後者を把持した方が成功率が高いことが判明された。従ってガウス曲率のデータが必須となる。

対象であるハンドタオル（340mm×340mm、綿100%）を机の上にランダムに置き、しわや折りを自然に残した状態で3Dデータを取得する。しわ、折りや撮影の角度などの条件を毎回変化し合計219枚の画像・3Dデータと算出した把持候補位置座標を学習用データセットとする。実物とセンサ上の3Dデータ（ヒートマップ形式）の一例を図6に示す。この場合、白丸で囲った部分が最も高い範囲となったが、全体的に平坦である。一方でガウス曲率では赤丸で囲った部分が最も高いため、最も把持が成功しやすい「把持候補位置」として選ばれた。



*左図のヒートマップでは冷色（青）がより短い距離、暖色（赤）がより長い距離を示す。

図6 ハンドタオルの3Dデータと実物写真の比較

ハンドタオルの大まかな物理学モデルを構築し、シミュレータ内のロボットと環境モデルと統合した。シミュレータ内で深層強化学習を用いて、カメラ画像内のランダムな柔軟物のモデルに対してガウス曲率の最も高い位置までロボットエンドエフェクタを移動させる実験を19,000回以上行った（所要時間：約3時間）、またそのDT内の学習モデルがロボット実機にも適用できることを確認した。

DTにおける学習モデルと前述の「把持候補位置」を特定する手法を合わせて、移動・把持操作ロボットプラットフォームを用いたハンドタオルの把持テストを行った。実機実験の様子を図7に示す。結果としては121回中112回成功し、成功率は約92.6%であった。失敗した9回の内、3回は通信等のソフトウェアトラブルが原因で残りの6回はロボット先端のグリッパの内側素材の摩擦力不足による滑りだった。グリッパ自体の最適化や再設計による問題の改善・解決が期待される。また、ロボットアームの可動域を最大限生かすため、AGVの方でもある程度目標位置に近づけるよう移動できるようにしている。



図7 ロボットプラットフォームによる自律移動と柔軟物把持・操作の様子

5. まとめ

本研究では、AGV とロボットアーム 2 台および各種センサを用いて、比較的到低コストで構築可能な DT の有効性を柔軟物把持・操作のタスクで検証・評価した。小型・廉価 AGV とロボットアームを使用しているため各種ハードウェアのスペックの限界はもちろん存在するが、低コストロボットシステムの知能化のポテンシャルを引き出すための効率の良いロボットの AI 学習を実現した。今後の展望として、微分幾何学分野では測地線距離や Wasserstein 距離の概念の導入と応用、そしてロボットシステムではロボットグリップの改良や新しいロボット・センサの導入によるより複雑なロボット実機タスクの AI 学習に挑みたい。

謝辞

本研究を遂行するにあたり、公益財団法人天野工業技術研究所および共同研究者である山梨大学大学院総合研究部工学域の寺田英嗣教授と寺田研究室の教員と学生の皆様から多大なご支援を頂きました。ここに記して謝意を示します。

参考文献

- 1) Levine, S., Pastor, P., Krizhevsky, A., Ibarz, J., & Quillen, D. (2018). Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. *The International journal of robotics research*, 37(4-5), 421-436.
- 2) Grieves, M., Vickers, J. (2017). Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems. *Transdisciplinary Perspectives on Complex Systems*. Springer.
- 3) Sun, X., Naito, H., Namiki, A., Liu, Y., Matsuzawa, T., & Takanishi, A. (2022). Assist system for remote manipulation of electric drills by the robot “WAREC-1R” using deep reinforcement learning. *Robotica*, 40(2), 365-376.
- 4) デジタルツインに関する国内外の研究開発動向, 国立研究開発法人科学技術振興機構 研究開発戦略センター, <https://www.jst.go.jp/crds/report/CRDS-FY2021-RR-09.html>, 2022 年 3 月.
- 5) Sharma, A., Kosasih, E., Zhang, J., Brintrup, A., & Calinescu, A. (2022). Digital Twins: State of the art theory and practice, challenges, and open research questions. *Journal of Industrial Information Integration*, 30, 100383.
- 6) Kamien, R. D. (2002). The geometry of soft materials: a primer. *Reviews of Modern physics*, 74(4), 953.