

1. はじめに

食品製造工場における総菜等の詰め込み作業は人手で行われており、ピッキングロボットによる自動化が求められている。ポテトサラダ等の総菜は不定形状であるため、把持戦略を事前に設計することは難しい。そこで、データドリブンな深層学習を用いて把持戦略を決定する必要がある。高橋らは、把持位置の選択時に学習不足に基づく不確実性を考慮した把持手法 [1] や食品特有の形状に基づく不確実性を考慮した把持手法 [2] を提案している。不確実性が低い領域を把持位置として選択することで、少数の学習データを用いた場合の把持成功率の向上を実現した。この2つの従来法はそれぞれ1つの観点のみに基づいた不確実性を考慮している。そこで本研究では、複数の観点に基づいた不確実性を同時に考慮した把持位置選択の導入と、把持成功率の向上を目的とした学習データの偏りを抑制する手法を提案する。

2. 従来手法

質量をベースに詰め込む食品を対象とする場合、目標量を正確に把持することが難しい。高橋らは粒状食品（米、豆など）や、絡まりやすい食品（千切りキャベツ、もやしなど）を対象とした目標量把持手法を提案した。

2.1. 粒状食品の目標量把持手法

粒状食品の目標量把持手法 [1] では、少数の学習データでも不定形状の粒状食品に対応するために Random Network Distillation (RND) を用いている。RND は把持時の質量と正解となる質量との差を学習する Predict Network と学習しない Target Network を用いる。この2つのネットワークの出力の差を未知度合いとする。不確実性である未知度合いが低い領域を把持位置として選択する把持戦略となる。

2.2. 絡まりやすい食品の目標量把持手法

絡まりやすい食品の目標量把持手法 [2] では、同一の入力に対して予測把持量にばらつきがある場合に有効な Mixture Density Network (MDN) を用いている。MDN は把持時の質量を確率的に推定するネットワークであり、複数のガウス分布の平均、分散、重みを出力する。これにより、把持量が確率分布として表現され、その分散（把持量のばらつき）を不確実性として定量化できる。把持量のばらつきが小さい領域を把持位置として選択する把持戦略となる。

3. 提案手法

不確実性を考慮する観点は1つとは限らない。そこで、本研究では、複数の観点の不確実性を考慮し、少数の学習データでも不確実性が低い領域を把持できるようにする。その把持戦略として、未知度合いに基づくミニバッチを用いて、学習不足による不確実性と食品特有の不確実性の2つを考慮して把持位置を選択する。

3.1. 未知度合いに基づくミニバッチ作成方法

未知度合いが低い領域を積極的に学習するためのミニバッチ作成方法として、Uncertainty Aware Sampler (UASampler) を提案する。UASampler では、未知度合いが低い学習データほどサンプリング確率を高く設定し、学習に使用する。式 (1)、式 (2) に示すように、各学習データの未知度合い s_i の逆数 \tilde{s}_i を正規化し、これをサンプリング確率 p_i とし、確率分布に基づいてデータをサンプリングする。ミニバッチ作成方法を図 1 に示す。

$$\tilde{s}_i = \begin{cases} \frac{1}{s_i}, & \text{if } s_i \neq 0 \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

$$p_i = \frac{\tilde{s}_i}{\sum_j \tilde{s}_j} \quad \text{for each } i \quad (2)$$

3.2. 複数の不確実性を考慮した把持位置選択

提案手法では、学習データの不足に対応するために RND、食品特有の不確実性に対応するために MDN を用い、両者




図 1：ミニバッチ作成方法

の不確実性を考慮して把持位置を選択する。RND による未知度合いと MDN による把持量のばらつきを予測をし、小さい値から順位付けをする。2つの順位の合計値が最も小さい値を把持位置として選択する。

3.3. データ収集環境

本研究では、図 2 に示す環境でデータを収集する。疑似食品として輪ゴムを把持対象とする。ピッキングロボットは単腕、4軸の MyPalletizer を使用し、カメラは深度センサを搭載した RealSense を用いる。はかりは最小表示 0.01g のものを用いる。

学習用データは輪ゴムの入った箱の中の RGB 画像と深度情報を把持位置を中心として 140×140 ピクセルに切り取った領域とロボットの把持量である。把持位置 x, y はランダムに決定し、手先の高さ z は把持対象の表面から 20mm 下で固定する。このようにして得られたデータを UASampler によりサンプリングすることで、不確実性が低い領域を複数回取得する。

評価時は、輪ゴムの入った箱の中から 75 箇所の固定把持位置を手動で決定する。各把持位置を中心として 140×140 ピクセルの領域の RND による未知度合いと MDN による把持量のばらつきを推定する。



図 2：データ収集環境

4. 評価実験

不確実性を考慮して把持位置の選択をした際の従来手法と提案手法の把持成功率を比較する。MDN の予測把持量と計測した把持量との差から把持成功率を計算し評価を行う。従来手法である RND のみと MDN のみを用いて把持位置選択した場合と両方を用いた場合、提案手法の UASampler と RND と MDN の両方を用いた場合の4つの比較を表 1 に示す。結果から、複数の不確実性を考慮することの有効性と UASampler を用いた効果を確認した。

表 1：従来手法と提案手法の把持成功率 [%]

| | UASampler | ±0.1g | ±0.5g | ±1.0g | ±1.5g | ±2.0g | ±2.5g | ±3.0g |
|-----------|-----------|-------|-------|-------|-------|-------|-------|-------|
| RND | - | 7 | 14 | 29 | 45 | 54 | 58 | 73 |
| MDN | - | 1 | 11 | 23 | 38 | 51 | 61 | 73 |
| RND + MDN | - | 3 | 23 | 35 | 55 | 62 | 68 | 82 |
| RND + MDN | ✓ | 5 | 20 | 47 | 58 | 70 | 77 | 84 |

5. おわりに

本研究では、複数の観点に基づいた不確実性を同時に考慮した把持位置選択を導入することで、把持成功率を向上させるために学習データの偏りを抑制する手法を提案した。評価実験より、提案手法の有効性が確認できた。今後は、把持成功率上昇の詳細な要因分析と目標把持量を設定した場合の追加実験を行う予定である。

参考文献

- [1] K. Takahashi, *et al.*, “Uncertainty-aware self-supervised target-mass grasping of granular foods”, ICRA, 2021.
- [2] K. Takahashi, *et al.*, “Target-mass grasping of entangled food using pre-grasping & post-grasping”, IEEE Robotics and Automation Letters, 2021.