


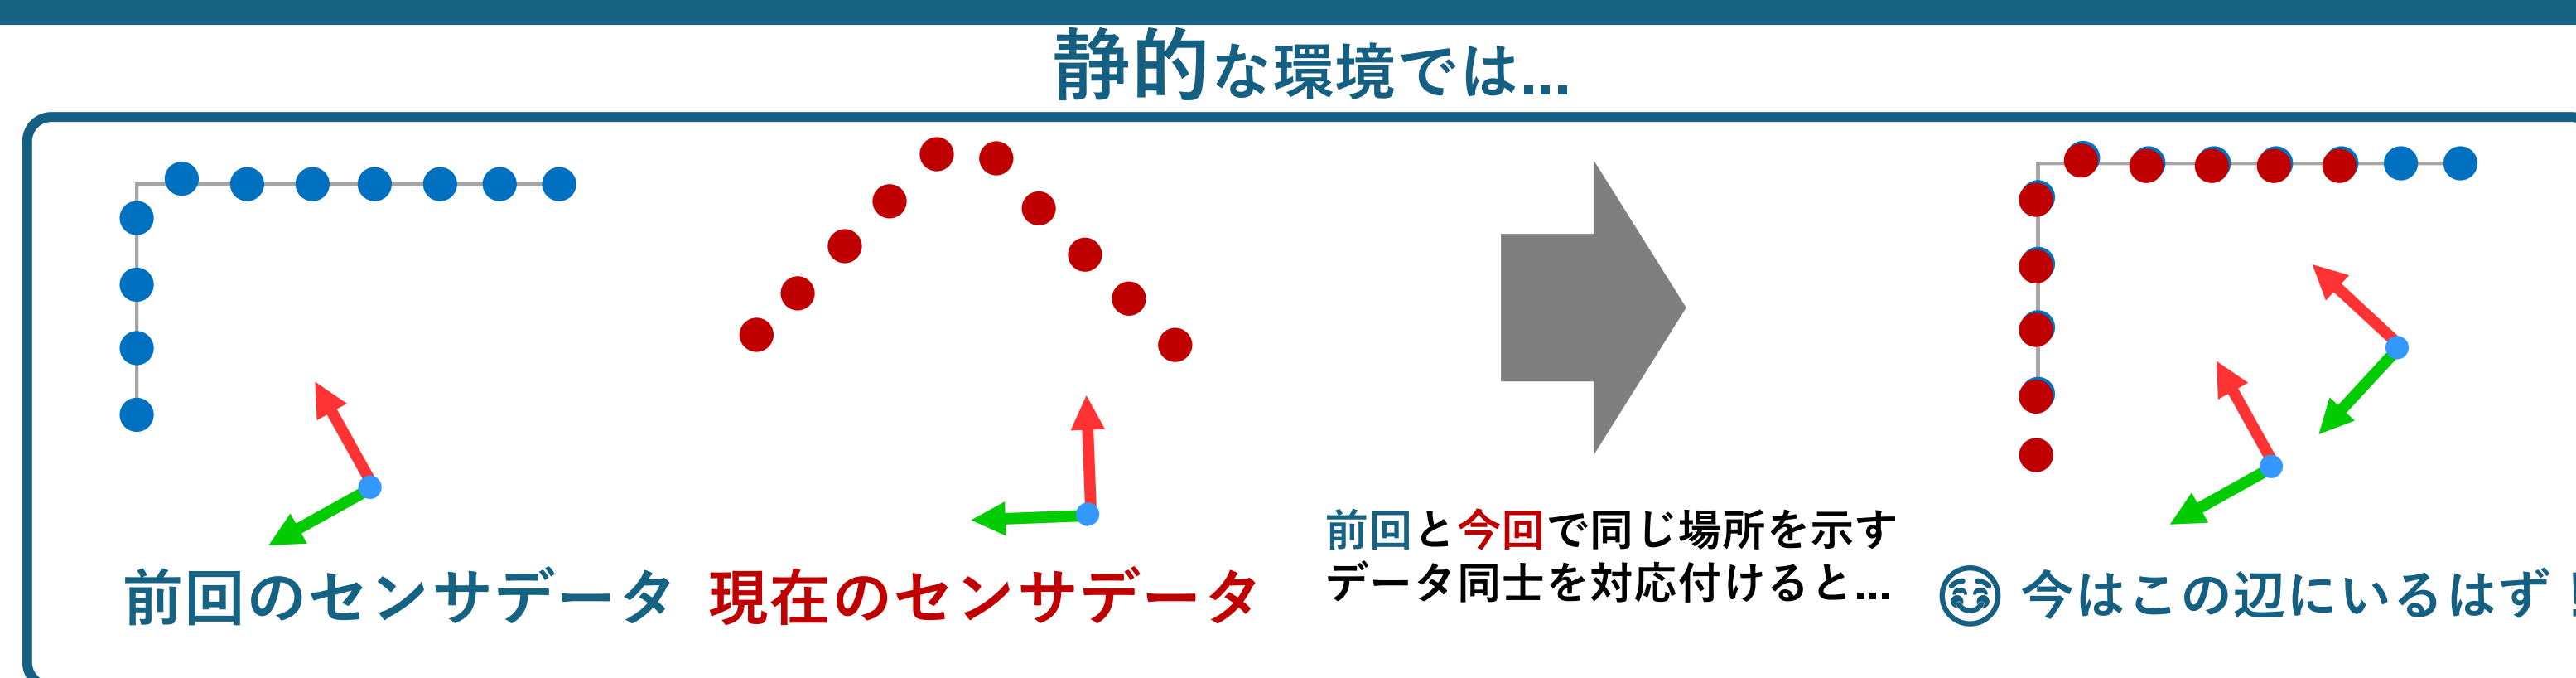
# 動的物体推定とRGB-D・IMU制約の密結合によるオドメトリ推定

## 1. 研究背景・目的

- ロボットの移動には正確な**自己位置推定**が必須！
- 周囲の**環境地図の作成**と其中で**自分の位置を求める**

SLAM技術が発展

- SLAMは基本的に**静的な環境**を仮定
- 歩行者などの**動的物体は外れ値**となる
- 精度悪化, 推定の破綻につながる



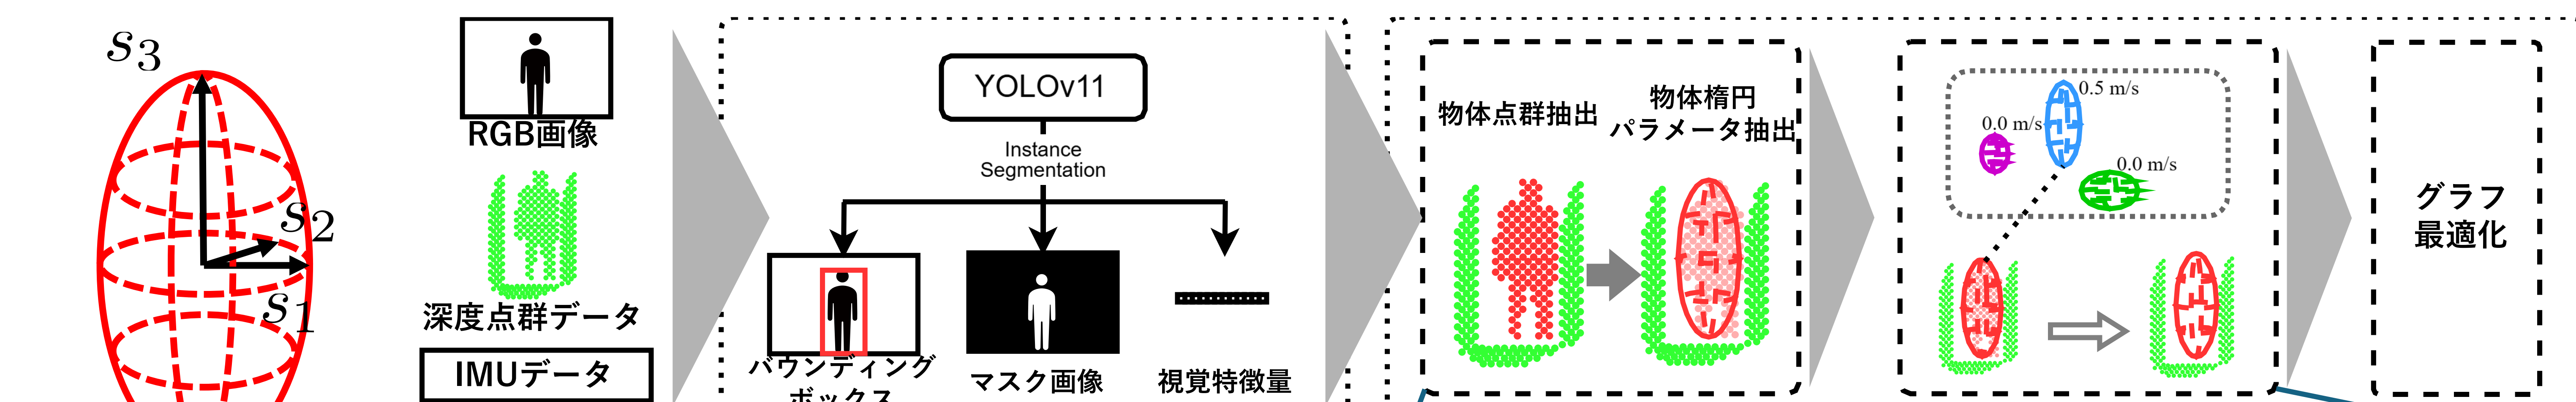
単純な解決策(従来手法) ⇒ ㊟ 動的物体をセンサデータから取り除けば良いのでは？

ある程度の環境であれば対応可能, 移動物体が多数存在するような場所では十分なセンサデータが残らない

㊟ 動的物体が多数存在する過度な動的環境において従来の対策だけでは不十分

## 2. 提案手法

移動物体の除去 + それらも自己位置推定の手がかりに使用したシステムを提案



### 楕円体モデル

- 周囲物体を3次元楕円体として近似
- 任意クラスの物体を表現

### 2.1. YOLOによる物体検出

- YOLOv11でインスタンスセグメンテーション
- 物体バウンディングボックスとマスク画像および物体の画像特徴量ベクトルを抽出

### 2.2. 物体パラメータ抽出と対応付け

- 物体検出結果と点群を照合し, 各検出物体の楕円パラメータ算出
- 現時点で追跡中の物体データと観測物体を, 物体運動と画像特徴ベクトルの2つを用いて対応付け
- 動的な物体については関連するセンサデータを除去

## 3. グラフ最適化

- 動的点除去後の点群マッチング + IMUによるセンサ運動 + 物体観測を制約とした目的関数を同時に最適化
- センサデータと周囲の物体運動の両方を考慮して最適化ができる

目的関数:

$$e(\mathcal{X}, \mathcal{Q}, \mathcal{U}) = \sum_{\mathbf{x}_t \in \mathcal{X}} \sum_{s=t-N^W}^{t-1} e^M(\mathcal{P}_t, \mathcal{P}_s, \mathbf{T}_t, \mathbf{T}_s) + \sum_{\mathbf{x}_t \in \mathcal{X}} e^{\text{IMU}}(\mathbf{x}_{t-1}, \mathbf{x}_t)$$

物体姿勢・形状を制約

$$+ \sum_{\mathbf{x}_t \in \mathcal{X}} \sum_{\mathbf{q}_{i,t} \in \mathcal{Q}_t} e^{\text{anchor}}(\mathbf{T}_t, \mathbf{q}_{i,t})$$
$$+ \sum_{\mathbf{x}_t \in \mathcal{X}} \sum_{\mathbf{q}_{i,t} \in \mathcal{Q}_t} e^{\text{bbox}}(\mathbf{T}_t, \mathbf{B}_{j,t}, \mathbf{q}_{i,t}) + \sum_{\mathbf{q}_{i,t} \in \mathcal{Q}} e^{\text{shape}}(\mathbf{q}_{i,t-1}, \mathbf{q}_{i,t})$$

物体運動を制約

$$+ \sum_{\mathbf{q}_{i,t}, \mathbf{u}_{i,t} \in \{\mathcal{Q}, \mathcal{U}\}} e^{\text{vel}}(\mathbf{q}_{i,t-1}, \mathbf{q}_{i,t}, \mathbf{u}_{i,t-1}) + \sum_{\mathbf{u}_{i,t} \in \mathcal{U}} e^{\text{cvel}}(\mathbf{u}_{i,t-1}, \mathbf{u}_{i,t})$$

$$+ e^{\text{prior}}(\mathbf{x}_0)$$

## 4. 評価

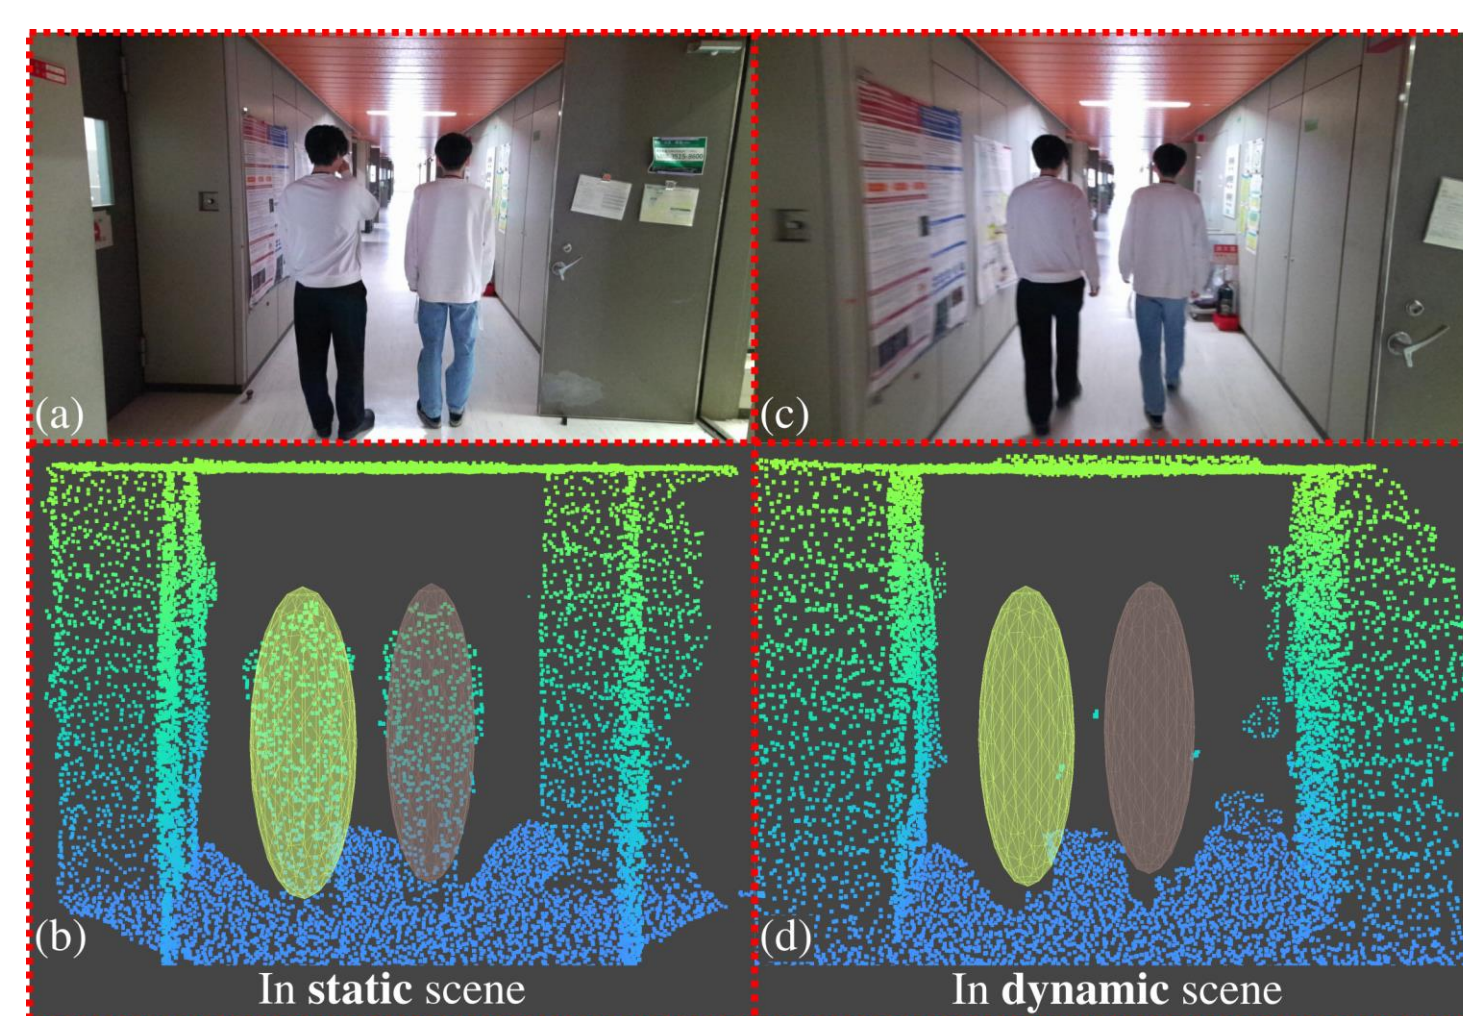
提案手法が**破綻なく高精度な推定**を行えることを確認

- 廊下を一周するデータセットで評価
- 前方に移動物体(歩行者)が常に存在する**継続的な動的環境**

㊟ 最先端のSLAM手法や動的環境に対処した既存手法よりも高精

### 4.1. ノイズ除去精度

物体を**継続的に追跡**し移動物体については**適応的にデータ除去**



### 4.2. 軌跡推定精度

真値(黒破線)に対し提案手法の推定軌跡(赤線)が**高精度に追従**

