

点群合わせ処理

ICPからGICP・NDTへ — 点群剛体変換アルゴリズムの進化と実践

#LiDAR

#SLAM

#点群処理

#自己位置推定

Nyanziba

本日の流れ

1. **導入** — LiDAR・点群・SLAMとは何か
2. **ICP** — 素朴な定式化と限界
3. **GICP** — 共分散を使った統計的改善
4. **NDT** — 点対分布という新しい表現モデル
5. **VGICP** — GICPの精度 × NDTの速度
6. **比較・まとめ** — 4アルゴリズムの使い分け

Part 1：導入

LiDAR・点群・SLAM

点群とは？

3次元空間における点の集合

- 各点が (x, y, z) の座標を持つ
- 反射強度、RGB等のデータを持つ場合もある

2次元の画像との違い：

- 順序に意味がない（画像のようなピクセル格子がない）
- 密度が不均一（センサーに近い部分は密、遠い部分は疎）
- ノイズと外れ値が多い
- データ量が多い（1スキャンで数万～数十万点）

取得するための機器

LiDAR

Light Detection and Ranging

- レーザーを照射して反射までの時間から距離を計算（ToF形式）
- 精度は **$\pm 1 \sim 3 \text{cm}$**
- ロボティクス、自動運転で使用

深度カメラ

RGB-D Camera

- ToF形式 or **構造化光形式**（赤外線パターンの歪みから距離を計算）
- 近距離(～2m)で **$\pm 1 \sim 2 \text{mm}$**
- 10m以上はそもそも測定できない

点群の使用用途は？ (1/2)

物体検出

- 自動運転での歩行者・車両・自転車のリアルタイム検出
- Amazonの倉庫ロボットによる商品のピッキング
- 港湾クレーンのコンテナ自動積み下ろし

セグメンテーション

- 自動運転の走行可能領域の推定（地面・壁・障害物を分離）
- 森林調査での樹木1本1本の自動識別・材積量計測
- 建物・道路・植生などの地物分類（航空LiDAR測量）

点群の使用用途は？ (2/2)

位置合わせ

- SLAMによる自己位置推定（ロボット・自動運転）
- 工場での製品とCADモデルの寸法検査
- 建設現場の施工前後の地形比較

3D地図構築

- 自動運転用HDマップ（高精度地図）の作成
- 文化財のデジタルアーカイブ
- ゲーム・映画VFXの都市モデル生成

“ 今回は **位置合わせ** と **3D地図構築** で使用されるアルゴリズムについてLTします ”

SLAMとは

Simultaneous Localization and Mapping

地図生成と自己位置推定の同時解決

Localization（自己位置推定）

「自分が地図のどこにいるか」を推定する

→ 点群マッチングが核心！

Mapping（地図生成）

「周囲の環境地図」を同時に構築する

→ 累積した点群を統合

地図がないと位置がわからない、位置がわからないと地図が作れない → SLAMはこれを同時に解く

点群の「位置合わせ」問題

時刻 t の点群 P (ソース) と、時刻 $t+1$ の点群 Q (ターゲット) が与えられたとき

最適な剛体変換 $T = (R, t)$ を求めよ

- R : 3×3 回転行列 — どの方向にどれだけ回転したか
- t : 3次元並進ベクトル — どの方向にどれだけ移動したか


これを解くのが **ICP / GICP / NDT** の役割

Part 2 : ICP

Iterative Closest Point

ICP — 処理の流れ

繰り返しによって2つの点群を段階的に重ね合わせていく




収束していなければ ① に戻る

- ① 最近傍対応付け : 各 p_i に対して最も近い q_i をペアにする
- ② 変換の最適化 : ペア間の距離を最小化する (R, t) を計算
- ③ 点群の更新 : ソース点群を (R, t) で変換
- ④ 収束判定 : 変換量が閾値以下なら終了

ICP — 最近傍対応付けの図示

各ソース点 p_i に対して、ターゲット内で最も近い点 q_i をペアにする



この「ペアの距離の合計」を最小化する変換を求めるのがICPの目的関数

ICP — 目的関数

点間ユークリッド距離の二乗和を最小化する


$$T^* = \arg \min_{R, t} \sum_i \|q_i - (Rp_i + t)\|^2$$

- p_i : ソース点群の各点
- q_i : ターゲット点群の最近傍点
- R, t : 最適化したい剛体変換
- $\|\cdot\|^2$: ユークリッド距離の二乗

◆ 閉形式解（SVD分解）で R と t を解析的に求めることができる

ICP — 収束のイメージ

反復ごとにソース点群がターゲットに近づいていく



繰り返しのたびに対応付けが更新され、変換がより正確になっていく

ICPの課題

課題1：外れ値に弱い

$\|q_i - Rp_i - t\|^2$ はノイズ点の誤差を等しく扱う

→ 1点の外れ値が最適化を大きく歪める

課題2：初期値依存・局所解問題

最近傍対応付けは局所的な操作

→ 初期位置がずれていると間違った局所解に収束


課題3：点对点の対応が「面」を無視する

平面上に並んだ点群を孤立した点として扱う

→ 面・エッジの幾何構造を活かせない

ICPの課題 — 外れ値と面構造の図示

外れ値の影響



1点の外れ値が全体の最適化を引っ張ってしまう

面構造の無視



面上の点は隣の点にも対応できてしまう

→ 面構造を活かせない


Part 3 : GICP

Generalized ICP

GICP — アイデア


「各点を "点" ではなく "局所的な分布" として扱う」

ICPの誤差モデル



全方向の誤差を均等に扱う

GICPの誤差モデル



面に沿った方向の誤差は軽く扱う

共分散行列 C_i は各点の近傍 k 点から局所PCAで推定する

GICP — 共分散行列の意味


近傍点の分布から「面かエッジか孤立点か」を判別できる

平面上の点




$\lambda_1 \approx \lambda_2 \gg \lambda_3$
法線方向の分散が小さい

エッジ上の点



$\lambda_1 \gg \lambda_2 \approx \lambda_3$
1方向にだけ分散が大きい

孤立した点



$\lambda_1 \approx \lambda_2 \approx \lambda_3$
全方向に均等 (ICPと同じ)

$\lambda_1, \lambda_2, \lambda_3$ は共分散行列の固有値 (PCAの主成分)

GICP — 目的関数

マハラノビス距離による重み付き最小化

$$T^* = \arg \min_{R,t} \sum_i d_i^T \left(C_i^Q + R C_i^P R^T \right)^{-1} d_i$$
$$d_i = q_i - (R p_i + t)$$

- d_i : 変換後ソース点とターゲット点の差分
- C_i^Q : ターゲット点の局所共分散行列
- C_i^P : ソース点の局所共分散行列
- $(\cdot)^{-1}$: マハラノビス距離として重み付け

GICP — ICPからの変化を図示


目的関数のどこが変わったのか？

ICP

$$\sum \|d_i\|^2$$

ユークリッド距離²

全方向均等に誤差を評価



GICP

$$\sum d_i^T (C_i^q + R C_i^p R^T)^{-1} d_i$$

マハラノビス距離

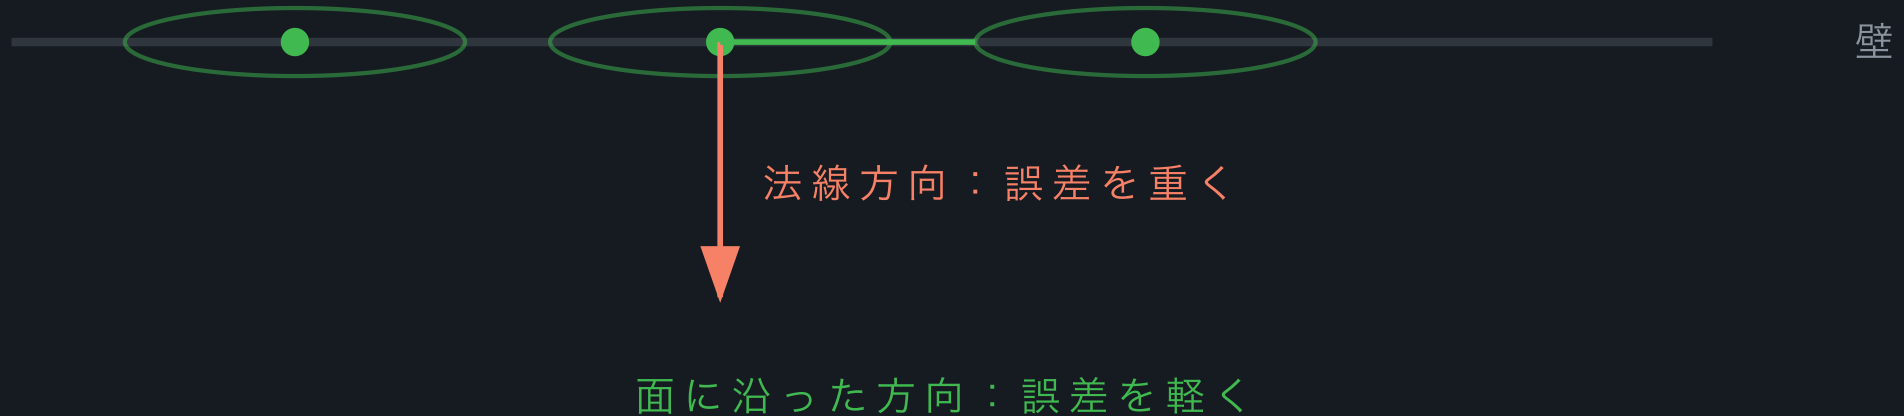
共分散で方向別に重み付け

対応付けの枠組みはICPと同じ。「誤差の測り方」だけを変えたのがGICP

GICP — 直感的な解釈

壁の面を例に考える

- 面の法線方向（垂直）→ 共分散が**小さい** → 誤差を**重く**ペナルティ
- 面に沿った方向 → 共分散が**大きい** → 誤差を**軽く**扱う



面構造に沿った、幾何学的に意味のある位置合わせが実現する

Part 4 : NDT

Normal Distributions Transform

NDT — アイデアの図示


点の集合 → ボクセルに分割 → 各ボクセルを正規分布でモデル化

点群



生の点群データ

ボクセル分割



空間を格子状に区切る

正規分布化



μ_k, Σ_k を計算 (事前計算)

NDT — 数式 (Step 2 : 正規分布推定)

各ボクセルの点群から平均と共分散を計算する

$$\mu_k = \frac{1}{n} \sum_j x_j \quad \Sigma_k = \frac{1}{n} \sum_j (x_j - \mu_k)(x_j - \mu_k)^T$$

- μ_k : ボクセル k 内の点の平均位置
- Σ_k : ボクセル k 内の点の分散共分散行列
- n : ボクセル k 内の点の数

統計学でおなじみの標本平均・標本共分散そのもの

NDT — 数式 (Step 3 : スコア最大化)

変換後のソース点が各ボクセルの分布にどれだけ「ハマるか」を最大化する

$$T^* = \arg \max_{R,t} \sum_i \exp \left(- \frac{(T(p_i) - \mu_{k(i)})^T \Sigma_{k(i)}^{-1} (T(p_i) - \mu_{k(i)})}{2} \right)$$

- 正規分布の確率密度関数の形そのもの
- 変換後の点が分布の中心に近いほどスコアが高い
- 最適化には **Newton法 / 勾配降下法** を使用

◆ ボクセルへの割り当てが「対応付け」の役割を果たす

NDT — スコア計算の図示

変換後の点が分布の中心に近いほど高スコア



点が分布の中心に近い

→ $\exp(\dots)$ が大きい → 高スコア

点が分布から離れている

→ $\exp(\dots)$ が小さい → 低スコア

全点のスコア合計を最大化する T を求める

Part 5 : VGICP

GICPの精度 × NDTの速度

VGICP — 3つの対応付けモデル

GICPとNDTの弱点を同時に解決するハイブリッド手法

GICP

分布 ↔ 分布 (D2D)



✓ 高精度

- ✗ NN探索が遅い
- ✗ GPU不向き

KD木で最近傍探索

NDT

点 ↔ ボクセル分布 (P2D)




✓ 高速・GPU向き

- ✗ 解像度にシビア
- ✗ 少数点で分布が壊れる

点の位置から分布を推定

VGICP ★

分布 ↔ 集約分布 (D2MD)



✓ GICPと同等の精度

- ✓ 高速・GPU向き
- ✓ 少数点でも安定

各点の共分散を集約して分布を推定

VGICP — ボクセル分布の作り方の違い

NDTとVGICPでは「ボクセルの分布をどう作るか」が根本的に異なる

NDT のボクセル分布推定



△ 点が少ないと分布が壊れる
(3Dでは実用上10点以上必要)

VGICP のボクセル分布推定



↓ 集約

✓ 1点でも有効な分布が得られる
解像度変化にもロバスト

VGICP — 目的関数と性能

GICPの式で b_i, C_i^B をボクセル内の集約値に置き換えるだけ

$$T^* = \arg \min_{R,t} \sum_i N_i \cdot \tilde{d}_i^T \tilde{C}_i^{-1} \tilde{d}_i$$
$$\tilde{d}_i = \frac{\sum_j b_j}{N_i} - T a_i \quad \tilde{C}_i = \frac{\sum_j C_j^B}{N_i} + T C_i^A T^T$$


N_i : ボクセル内の点数で重み付け。NN探索不要 → 各点が独立 → GPU並列化が可能

手法	速度 (15,000点)	精度	GPU対応
GICP	8 Hz (1スレッド)	◎	✕
NDT	19 Hz	△ (解像度依存)	○
VGICP (CPU)	30 Hz	◎	—
VGICP (GPU)	120 Hz	◎	◎

Part 6 : 比較とまとめ

4アルゴリズムの使い分け

アルゴリズムの進化の流れ



ICP → GICP → NDT → VGICP は「誤差の測り方」と「対応付けの仕組み」の進化として整理できる

4 アルゴリズムの比較表

比較軸	ICP	GICP	NDT	VGICP
対応付け	点 ↔ 点	分布 ↔ 分布	点 ↔ ボクセル分布	分布 ↔ 集約分布
目的関数	ユークリッド距離 ²	マハラノビス距離	正規分布スコア	マハラノビス距離
外れ値耐性	△	○	◎	○
疎な点群	△	○	◎	◎
速度	低	低～中	中～高	高 (GPU 120Hz)
実装の複雑さ	低	中	中	中～高

まとめ

ICP は基礎

点間距離²の反復最小化。SVDで解ける閉形式解がある

GICP は統計的拡張

共分散行列でマハラノビス距離を導入し、面・エッジ構造を誤差に織り込む

NDT は表現モデルの変革

対応付けの概念自体を変え、点对分布のマッチングに切り替える

VGICP はGICPとNDTの融合

GICPの共分散集約 + NDTのボクセル対応付けで精度と速度を両立

Thank You

点群処理は「最適化問題」 — 他の分野の知識が直結する面白い領域です

ICPからGICP・NDTへ — 点群剛体変換アルゴリズムの進化と実践

Q&A

質疑応答

補足：ボクセルサイズはどう決める？

NDT / VGICPの精度を左右する重要なパラメータ

- **小さすぎる** → ボクセル内の点が少なくなり分布が不安定になる
- **大きすぎる** → 空間の構造が平均化されて位置合わせ精度が落ちる

目安

環境	推奨ボクセルサイズ	理由
屋内（狭い空間）	0.5～1.0 m	壁や家具の構造を残す
屋外（広い空間）	1.0～3.0 m	建物や地形の大きな構造に合わせる
高密度点群	小さめでOK	各ボクセルに十分な点が入る
疎な点群	大きめにする	分布推定に必要な点数を確保

VGICPはNDTよりボクセルサイズの変化に対してロバスト

補足：ICPの初期値問題はどう対処する？

実用上の3つのアプローチ

1. 前フレームの結果を初期値にする

SLAMのように連続フレームで使う場合、前回の変換結果を次回の初期値にする。
フレーム間の移動量が小さければ十分に収束する

2. IMU（慣性センサ）で初期値を補助する

LIO（LiDAR-Inertial Odometry）ではIMUの角速度・加速度から大まかな姿勢変化を予測し、それを初期値として与える

3. 特徴量ベースの粗位置合わせを先に行う


FPFH（Fast Point Feature Histograms）などの3D特徴量でまず大まかに位置を合わせてからICP系の精密位置合わせを行う。2段階アプローチ

補足：どんなライブラリで実装できる？

ライブラリ	言語	特徴
Open3D	Python / C++	GICP実装あり。可視化が簡単
PCL	C++	ICP / NDT 実装あり。ROS連携に強い
small_gicp	C++	koide3作。GICP / VGICP の高速実装
fast_gicp	C++	koide3作。VGICP_CUDA対応

- **Python で試したい** → Open3D がおすすめ。 `pip install open3d` で入る
- **ROS で使いたい** → PCL または small_gicp
- **GPU で高速に回したい** → fast_gicp の VGICP_CUDA

補足：SLAM全体のどこに位置するアルゴリズム？



位置合わせはSLAMパイプラインの中核。この精度がシステム全体の精度を決める