

道路管理の高度化・効率化に資する4次元インフラマネジメント手法の開発

【3次元点群データの道路土工構造物の維持管理への活用マニュアル（案）】



令和5年3月

新都市社会技術融合創造研究会

■参考資料（研究成果）の位置づけ

新都市社会技術融合創造研究会では、社会資本の整備、維持・管理に関わる産・学・官の連携・協力による新しい技術の研究、普及等に関する事業を行い、もって都市再生と地域連携による経済活力の回復に貢献し、国民生活の質の向上、安全で安心できる暮らしの確保、環境の保全・創造に寄与することを目的とし、研究をしています。

そのなかで、技術基準に定められた図書等を補完するものとして、本研究会での調査・研究活動を通じて得られた成果の一部を取りまとめ、公開しております。

現地条件や各管理者のご判断により、参考資料として、ご活用頂けると幸いです。

新都市社会技術融合創造研究会

■研究概要

①研究プロジェクト名

道路管理の高度化・効率化に資する4次元インフラマネジメント手法の開発

②研究期間

令和2年7月～令和5年3月

③プロジェクトリーダー（所属・役職は研究当時）

貝戸 清之（大阪大学大学院 工学研究科 准教授）

④プロジェクトの概要

老朽化インフラ施設群を適切に管理していくための方法論としてアセットマネジメントが注目されている。特に近年のドローン技術や3次元計測技術の急速な発展によって、インフラ施設に対する膨大な点群データの取得が現実的な段階に達し、デジタルツイン、デジタルトランスフォーメーションの実現も現実味を帯びてきている。

本研究は、デジタルツインの実用化を見据え、3次元モデルとその履歴データに基づく4次元インフラマネジメントシステムを構築し、インフラ管理の高度化・効率化を達成する。

目次

第1章 概説	3
1.1 マニュアルの目的と位置づけ	3
1.2 点群データによる土工構造物の維持管理	3
1.2.1 特徴と適用範囲	3
(1) 基本的な考え方	3
(2) 基本的な作業手順	4
1.2.2 点検フロー	4
(1) 各種点検の位置づけ	4
(2) 点検業務フロー	5
1.2.3 維持管理への適用による効果	8
1.2.4 周辺技術との比較	9
第2章 点群データを用いた土工構造物の維持管理手法	11
2.1 目的の設定	11
2.2 適用対象とする異常とスケールの区分	12
2.3 点群計測手法と点群データの選び方	15
2.3.1 点群計測機器の概要	15
2.3.2 MMS 測量	15
2.3.3 航空レーザ測量	16
2.3.4 地上設置型レーザスキャナ・ハンドヘルド LP・UAV による測量	18
2.3.5 各種点群計測機器の比較	18
2.3.6 計測頻度の設定	19
2.3.7 必要な点密度の検討	20
2.4 道路斜面災害リスク箇所の抽出	21
2.4.1 PointAutoEncoder	21
(1) AutoEncoder	21
(2) PointAutoEncoder	22
2.4.2 差分解析手法	22
(1) 差分解析と位置合わせ	22
(2) ICP	23
2.5 点群データを活用するうえでの留意点	24

第 3 章 土工構造物の維持管理への適用事例	26
3.1 法面 A における適用事例	26
3.2 法面 B における適用事例	29
3.3 法面 C における適用事例	32
付録	33
参考文献	44

第1章 概説

1.1 マニュアルの目的と位置づけ

本マニュアルは道路土工構造物¹⁾の維持管理へ取り組む実務者に向けて、主としてレーザー計測機器によって取得された3次元点群データ²⁾の実務的な活用方法を提示し、道路土工構造物の効率的な維持管理手法の一つの有効な手段であることを普及する目的で作成している。3次元点群データによる維持管理は、現在行われている日常点検や各種定期点検を代替するものではなく、これらを効率的に行うための支援技術として位置づけられる。

1.2 点群データによる土工構造物の維持管理

1.2.1 特徴と適用範囲

本マニュアルでは、点群データの取得手法としてMMS 測量³⁾、航空レーザー測量⁴⁾、UAV 測量⁵⁾、地上設置型レーザースキャナ⁶⁾による測量、ハンドヘルド LP 測量⁷⁾等を想定する。現状の我が国における点群データの活用方法は、等高線図や微地形表現図の効率的な作成¹⁾やそれらを用いた災害リスク箇所の抽出²⁾、地形のモデル化ならびに断面図の作成³⁾、出来形管理への活用⁴⁾等に大別される。本マニュアルでは、これらの活用方法とは別に、点群データの土工構造物の維持管理における活用方法として「変状⁹⁾ 検知」を取り上げ、手法ならびに留意点等を提示する。以下、土工構造物の維持管理における変状検知に関して説明する。

(1) 基本的な考え方

点群データを用いた土工構造物の変状検知には、同地点における2時期の点群データが必要となる。通常の間検時等にMMS測量や航空レーザー測量を用いて、点群データを取得しておく(1期目のデータ)。その後、別の時期に同一箇所で点群データを取得した際に(2期目のデータ)、もし1期目の点群の取得後に変状が生じていた場合はその変状が加味された点群データが取得される。そこで、2時期の点群の差分解析を行うことによって、1期目の点群からのずれとして変状が抽出でき、これが点群データによる差分解析を用いた変状検知の原理である。図-1.1には、MMS測量により計測した点群における変状検知の例を示している。

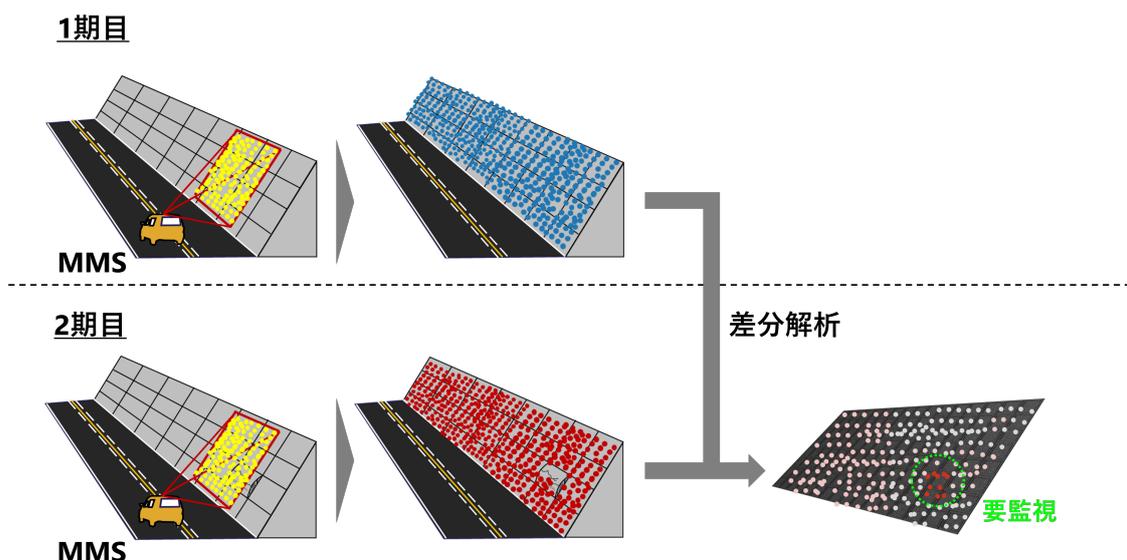


図-1.1 点群データによる差分解析を用いた変状検知の原理

(2) 基本的な作業手順

以下に、点群データによる土工構造物の維持管理手法の基本的な作業手順を示す。

予め解析対象箇所の点群データを取得しておく。

【入力】：解析対象箇所の点群データをレーザ計測機器を用いて取得し、入力データとする。

【処理】：データを解析する（2時期の点群データの位置合わせ→差分解析）。

【出力】：解析データから変化が抽出された箇所の考察を行い、その要因や影響度等を整理する。また、必要があれば現地調査を行い、変状の様子を調査する。

【結果の整理】：変状の影響度等を鑑みて、対象箇所の補修・修繕を行う。必要があれば、周囲の除草等を行う。

1.2.2 点検フロー

(1) 各種点検の位置づけ

道路管理における点検の目的は、図-1.2に示すように防災と維持管理に大別される。防災を目的とした点検として、平成8年度と平成18年度に実施された道路防災点検¹⁰⁾があげられる。すべての道路において自然災害による危険箇所を抽出し、危険度の判定を行う。判定区分としては、(I) 要対策、(II) カルテ対応、(III) 対策不要があり、のいずれかに該当する場合は防災カルテを作成する。1年に1、2回程度の頻度で実施される防災カルテ点検¹¹⁾では、作成された防災カルテに従って危険箇所を監視し、異常が認められた際には速やかに

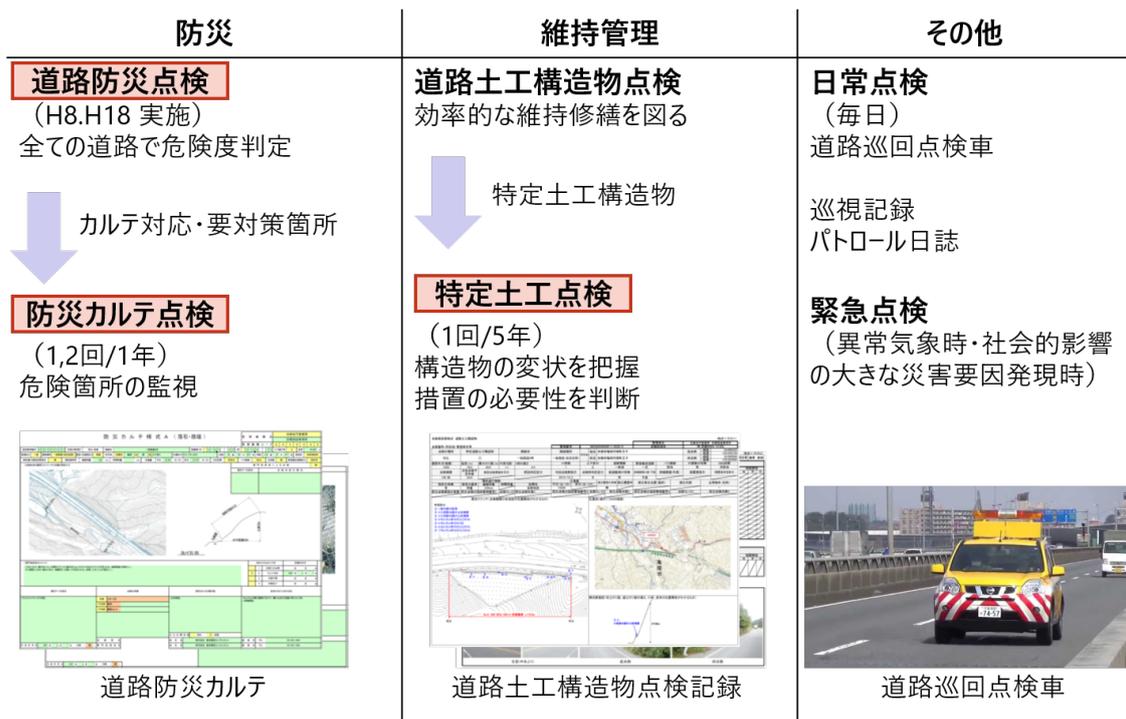


図-1.2 各種点検の概要

防災対策工を実施する。一方、道路土工構造物点検¹²⁾は効率的な維持管理を図るために実施する。長大切土や高盛土のような特定土工構造物に対しては、5年に1回の頻度で特定土工点検を行い、構造物の変状を把握し、措置の必要性を判断する。この他に、道路巡回点検車による日常点検や、異常気象時などに実施される緊急点検などがあり、道路の異常や損傷等の危険要因を調査し、道路の保全管理を担っている。

(2) 点検業務フロー

1.2.2 で紹介した点検のうち、道路防災点検、防災カルテ点検、特定土工点検について、各種点検要領^{5)~10)}に基づいて図-1.3~図-1.6 に示すように点検業務フローを作成した。

まず、道路防災の点検業務フローについて説明する。管理対象道路において過去の道路防災点検結果等の情報を利用して、災害発生履歴等を踏まえた箇所の危険度、防災管理上の必要性に基づいて点検対象区間を選定する。これらの区間について、空中写真や地形図等を用いて地域特性の把握及び災害要因の判読を行う。机上調査による結果を現地で確認をすることにより、安定度調査箇所を選定する。安定度調査では、現地調査を通じて、(I) 要対策、(II) カルテ対応、(III) 対策不要の3段階評価を行い、その調査結果を安定度調査票等に記録する。

道路防災点検で (I) 要対策、(II) カルテ対応と評価された箇所については防災カルテを作成する必要があり、作成のための調査を行う。安定度調査結果等による資料調査と地表踏

査を実施し、必要に応じて測量を行うことにより平面図・横断面図を作成する。防災カルテの作成は、災害の位置規模等の想定が可能であれば道路管理者が行い、想定が困難な場合は地質調査等の詳細調査を踏まえて専門技術者が行う。防災カルテ点検は、作成された防災カルテに記載されている変状等を対象として、対策工実施の必要性について判断する。着目すべき変状を現地で計測・撮影し、変状の時系列変化を把握するために防災カルテ様式Cに記録する。変状箇所に異常が認められる際には必要に応じて応急処置を施し、改めて専門技術者による地表踏査や災害の位置・規模等の想定の見直しを行う。道路防災点検と同様の3段階評価を行い、(I) 要対策の場合は防災対策工を実施し、その他の場合は防災カルテによる変状の監視を継続する。

効率的な維持管理及び構造物の安全性の向上を図る特定土工点検では、全数を5年で一巡するために点検計画を立案する。道路台帳附図等から規模や周辺条件を把握し、現地踏査により点検方法や足場等の資機材の計画立案に必要な情報を得る。点検の手法としては、主に近接目視により変状の有無を確認し、変状があれば計測・撮影し、構造物の安定性や地形・地質、道路機能への影響を踏まえて健全性の診断を行う。判定区分は(I) 健全、(II) 経過観察段階、(III) 早期措置段階、(IV) 緊急措置段階の4段階であり、それぞれの区分に応じた措置を講じる。これらの点検結果と判定は特定土工点検記録に取りまとめる。

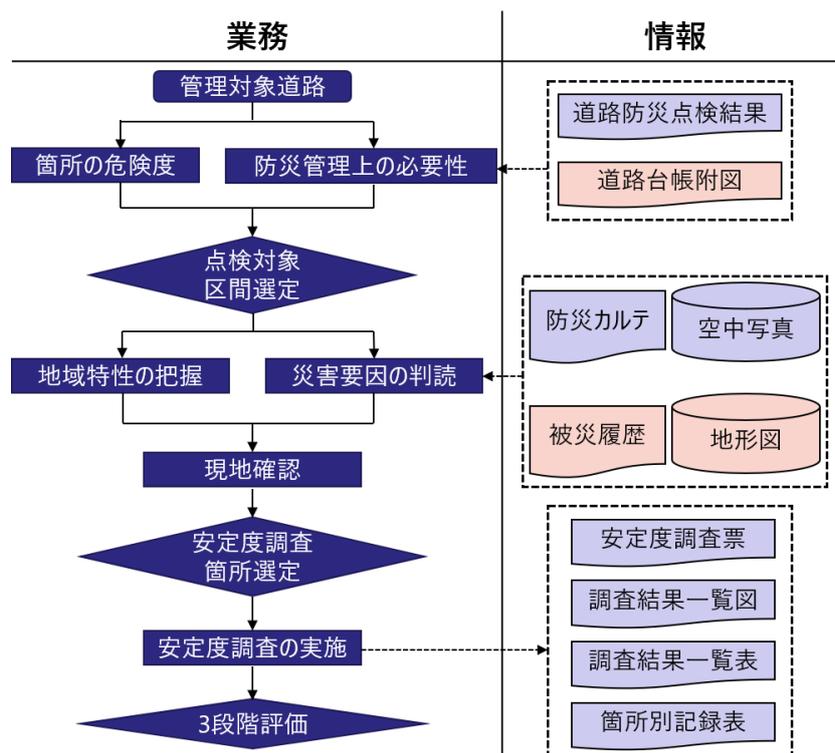


図-1.3 道路防災の点検業務フロー

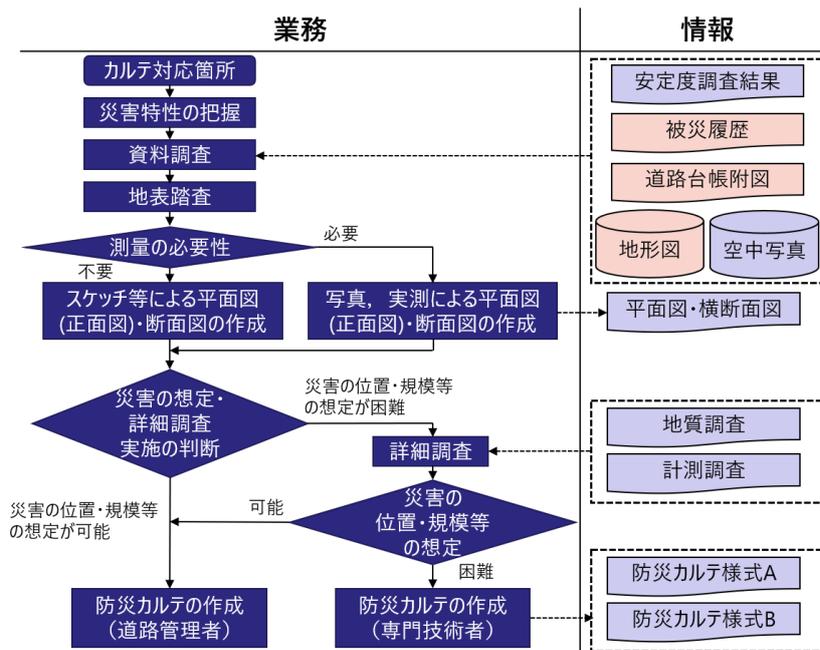


図-1.4 防災カルテ (カルテ作成前)

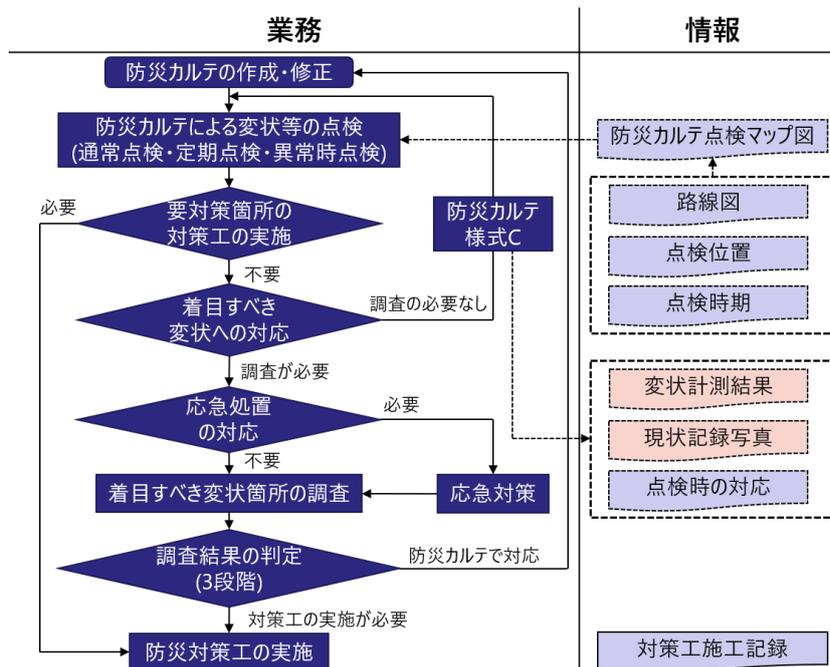


図-1.5 防災カルテ (カルテ作成後)

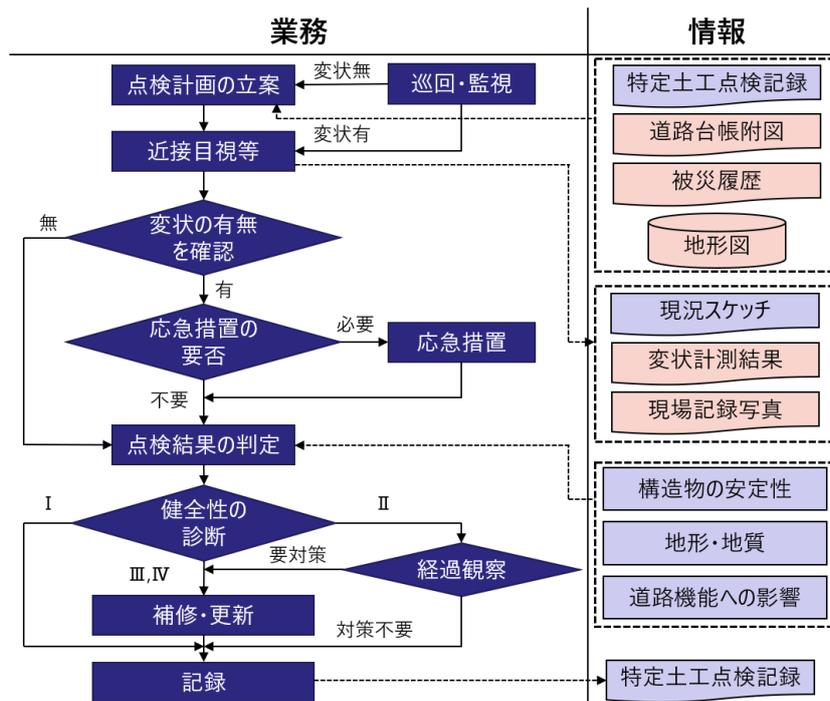


図-1.6 特定土工点検

1.2.3 維持管理への適用による効果

斜面や法面のような道路土工構造物は、背後にある地山が自然公物であるため、橋梁等の人工公物に比べその構造特性や劣化特性等に介在する様々な不確実性の影響が大きい。変状の要因の多くは、周辺の地盤の地盤工学的・地質学的要因に起因することが多いが、その要因も地下水位の上昇から泥濘化、軟弱地盤の存在、流れ盤の存在、断層破碎帯の存在等多岐にわたる。そのため、専門技術者であっても要監視箇所の抽出や劣化予測、変状検知が困難なことがある。また、1.2.2で述べたように、道路土工構造物における点検は防災を目的とした道路防災点検や防災カルテ点検、維持管理を目的とした特定土工点検に大別されており、これまでは前者に軸足が置かれていた。したがって、変状予測や地盤変位量の推定等を目的としたデータや知見が蓄積されていないのが現状である。

以上を踏まえ、道路土工構造物の維持管理における現在の技術的課題については、以下のようなものがあげられる。

- 1) 現在実施している種々の点検は近接目視点検¹³⁾が基本とされ、全道路延長に占める道路土工構造物の割合が8割程度と膨大な量があることや高所や法面においては足場や高所作業車が必要となることから、多大な労力や時間を要する。特に、急傾斜地への立ち入りを行う必要がある場合には安全性の面も問題となる。また、年度ごとに点検技術者が異なることも多く、変状の進行度を定量的に把握することが難しい。

- 2) 近接目視点検は既存の変状の監視に過ぎず、構造物の面的把握による新たな変状の発見は困難である。道路防災点検等では、点検箇所ごとに点検地点を決めてその挙動が経時的に確認されているが、当初決めた点検地点以外に変状が発生した場合には見逃すことがある。
- 3) 点検記録の作成は手書きや手入力が主体となっており、転写や入力ミスなどの恐れがある。
- 4) 道路土工構造物の変状履歴等に関して、築造当時からの定量的かつ時系列的なデータベースが存在しない。

これに対応して、航空レーザ測量や MMS 測量を併用して取得された点群データを用いることにより、以下の効果が期待できる。

- 1) 各種定期点検時、日常点検時に点群データを計測することにより、維持管理の時間短縮・効率性改善が見込める。また、得られたデータの解析により統一的な視点で、変状の定量的評価を行える。
- 2) 点検時に取得された点群データの差分解析により、面的把握による新たな変状の発見が期待できる（変状の面的スクリーニング）。
- 3) 点検記録の作成・活用は点群データの保持のみとなり、人手を要する箇所が削減され、人為的過誤の減少が期待できる。
- 4) 変状箇所の時系列変化を追跡する 4 次元的な維持管理が可能となる。過去からの変状の経時変化により変状の影響領域の変化や進行度合いを評価できる。

1.2.4 周辺技術との比較

点群データを用いた変状検出手法と道路土工構造物の点検に用いられている他の 3 次元計測技術を用いた手法との比較を行う。3 次元計測技術は主に表-1.1 のように大別される。表-1.1 におけるレーザスキャナ（地上型、UAV 搭載型、地上移動体搭載型）という項目がそれぞれ地上設置型レーザスキャナ、UAV による点群測量、MMS 測量等に該当する点群計測手法を示す。

通常測量は現地にターゲットを設置し、トータルステーション (TS) 等を用いて、直接測量を行う手法である。ターゲットを設置した地点の 3 次元的な変動を直接計測することが可能である。また、GNSS₁₄₎ 測量 (RTK-GNSS) は現地に GNSS 測量機器を設置し、衛星データを活用してその地点の変動を測量する手法である。これにより、ターゲットを設置した地点の 3 次元的な変動を自動的に計測することが可能となる。一方、これらは簡易

表-1.1 3次元計測技術の分類 (4) を参考に一部加筆)

	単点計測	多点計測
光波測距技術	通常測量 (TS, ノンプリズム式 TS)	レーザスキャナー (地上型, UAV 搭載型, 地上移動体搭載型)
衛星測位技術	RTK-GNSS	衛星 SAR
写真測量技術		空中写真測量 (UAV), ステレオ写真測量 (地上移動体)
その他		施工履歴データ, 音響測深器

に変動を計測できるが、単点計測であるため面的把握が困難であることやターゲットとなる点が既知である必要があることが欠点となる。

衛星 SAR による測量は電磁波の波長の変化 (干渉解析) から広域の地盤変動を測量する手法である¹¹⁾。この手法は、衛星データを活用して面的な地盤の変動を計測するという点で点群データを用いた変状検出手法に類似している。点群データの計測には一般に LiDAR (Light Detection and Ranging)¹⁵⁾ 技術によって行われる。LiDAR とは、計測範囲にレーザ光を照射し、その反射光が観測されるまでの時間や反射光の反射強度を解析することにより、対象物までの距離や反射特性、座標値を取得する光学リモートセンシングの技術である。反射光から反射点の空間的情報が得られ、このような反射点を無数に集めると点群データとなる。LiDAR では短波を用いるため、高分解能化がしやすいというメリットがある。一方で、衛星 SAR ではマイクロ波が用いられるため、天候の影響を受けにくい、分解能は小さいため局所的な変状の検出には不向きである。また、衛星 SAR による差分干渉解析により地盤の変状等を算出する場合、大気遅延による誤差等を除き高精度な結果を得るには、複数ペアの干渉解析結果を合成して誤差を低減する時系列解析が必要となる。時系列解析には、2 時期のみのデータでなく一般に多時期のデータが必要となるため、必要となるデータ数が多いことが欠点である。これに対し、点群データによる差分解析では 2 時期のデータのみで十分に解析を行うことが可能である。

写真測量は、画像を用いて対象物の幾何学的特性を取得する手法である。従来の写真測量では、計測時のカメラの位置や姿勢を決定するために現地に対空標識を設置するとともに、空中三角測量を実施することが必要となる場合があった。ただし近年では、写真測量においても空中写真撮影時のカメラの位置・姿勢を計測することにより、対空標識を利用せずに空中三角測量を行うことも可能である。写真測量では、撮影対象地域に雲などが存在するとその箇所のデータを取得することができなくなる。点群計測手法である航空レーザ測量でも、大気中に雲や塵があるとレーザ光がそれらに反射してしまうため快晴時の計測が望ましい。一方で、画像を同時取得する必要のない場合や別途に容易できる場合には、太陽高度による影の影響がないことがメリットとなる¹⁾。

第2章 点群データを用いた土工構造物の維持管理手法

2.1 目的の設定

点群データの計測・解析・保持にかかるメカニズムを理解したうえで、点群データを維持管理におけるどの工程に活用するかを明確に定める。維持管理において点群データを活用する目的としては、以下のようなものがあげられる。

- 1) 変状箇所の時系列変化を追跡する定量的な変状のデータベースの作成。
- 2) 各種定期点検における点検・維持作業の効率化・省力化（面的な変状スクリーニング）。
- 3) 災害時の早期変状把握。

変状箇所の時系列的变化を追跡する定量的な変状のデータベースを作成することにより、過去の変状履歴を活用した点検・危険度調査の立案や保全計画の策定を行うことが可能となる。また、各種定期点検における点検・維持作業の効率化として、事前に MMS 等により計測した点群データの解析を行い、変状が抽出された箇所においては近接目視点検を特に注意して行う等、変状のスクリーニング技術としての活用が可能である。災害時の早期変状把握としては、災害が生じた区域の点群データを航空レーザ測量等で取得し、過去に蓄積された同一箇所の点群データとの差分解析を行うことにより、どの箇所でどの程度の変動が生じているかを定量的に把握することが可能となる。

以上のような各種目的に応じた維持管理を行うためには、対象となる構造物に応じて生じる変状を予め想定したうえで、その変状を点群データを用いて検知することが可能であるかを事前に考察する必要がある。また、各種点群計測機器に応じて、取得可能な範囲や得られる点群の特性が異なるため、それらを正しく理解したうえで適切な手法を選択する必要がある。

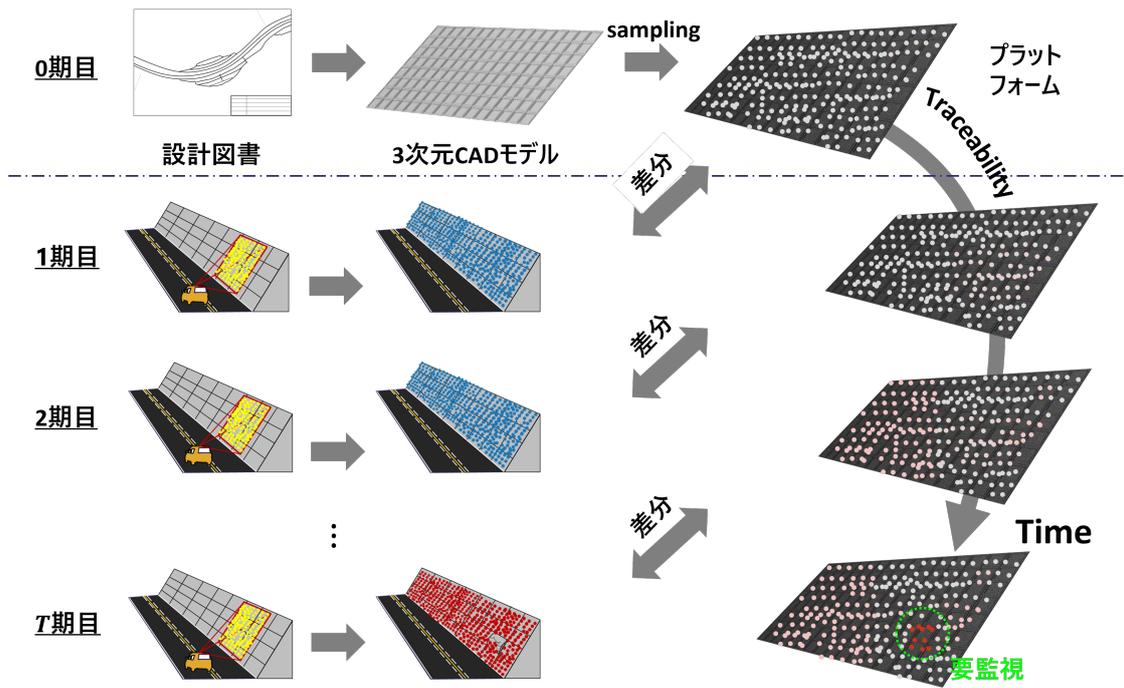


図-2.1 変状箇所の時系列変化を追跡する定量的な変状データベースの作成

2.2 適用対象とする異常とスケールの区分

土工構造物における変状（異常，ハザード）には多種多様なものが存在しており，点群データを用いて各異常の発生を検知することが可能であるかどうかを検討する必要がある。道路土工構造物点検要領⁹⁾によれば，土工構造物における変状の定義は，「切土法面，盛土法面など各道路土工構造物に発生する形状，性状，環境の変化で視認できるもの」とされており，具体的には小崩落，はらみ出し，ひび割れ，うき，剥離，剥落，部材等の変形，変色，さび，湧水の発生，湿潤などがあげられている。このような多種多様の変状を，統一的な手法で検知を行うことは一般に困難であり，その影響度や発生頻度に基づき重要と考えられる変状に対し，変状の性質が似通ったものごとに変状検知手法を考察する必要がある。

切土（道路土工構造物点検要領を元に作成）

切土のり面（亀裂，段差，はらみだし，浸食，湧水，小崩壊等）
 切土直下の路面（亀裂，盛り上がり）
 吹付モルタル（亀裂，剥離，はらみだし，空洞，目地のずれ，傾動，土砂のこぼれだし）
 のり枠（亀裂，剥離，うき，鉄筋の露出）
 グラウンドアンカー（アンカー支圧板，受圧構造物の亀裂，破損，アンカー頭部の破損）
 擁壁（土砂のこぼれだし，擁壁前面地盤の隆起，壁面のクラック等）
 排水施設（排水溝の閉塞，亀裂，破損，目地部分の開口やずれ）
 落石防護施設・落石予防施設・雪崩対策施設（部材の変形，傾動，等）

盛土（道路土工構造物点検要領を元に作成）

盛土のり面（亀裂，段差，はらみだし，浸食，湧水，小崩壊，軟弱化等）
 擁壁・補強土壁（土砂のこぼれだし，擁壁前面地盤の隆起，壁面のクラック等）
 排水施設（排水溝の閉塞，亀裂，破損，目地部分の開口やずれ）
 カルバート（化学的浸食による部材断面減少，漏水，継ぎ手のずれ，開き，段差等）

自然斜面（道路防災点検要領を元に作成）

落石・崩壊（亀裂，段差，はらみだし，浸食，湧水，小崩壊，小落石，洗堀，根曲がり，倒木，のり面の変状等）
 岩盤崩壊（亀裂，段差，はらみだし，浸食，湧水，小崩壊等）
 地すべり（亀裂，段差，はらみだし，浸食，湧水，小崩壊，隆起，陥没，斜面安定工の異常と変状等）
 土石流（亀裂，小崩壊，浸食，倒木，溪床堆積物の増加，排水不良等）

図-2.2 各土工構造物において発生しうる変状

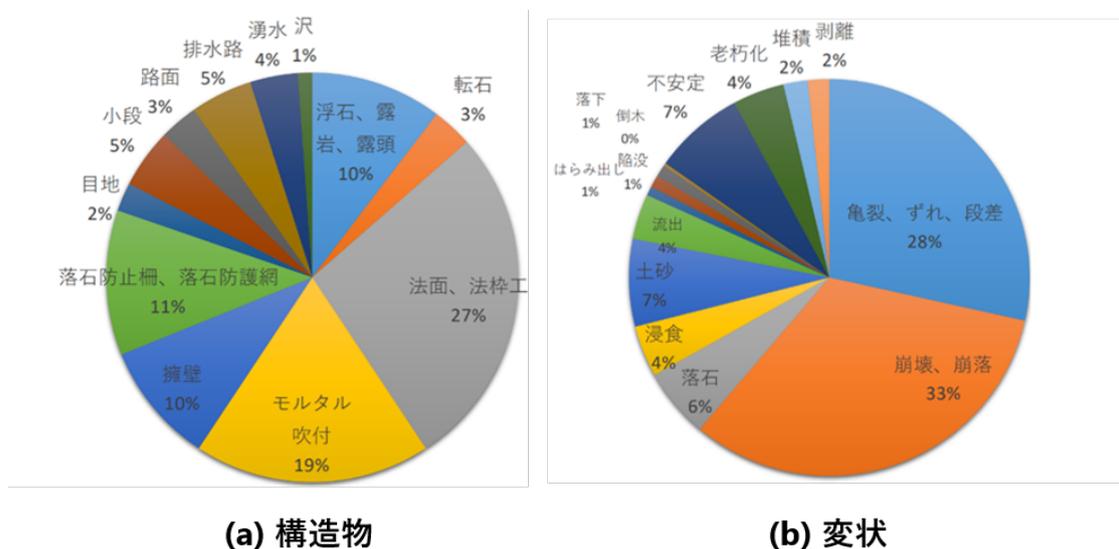


図-2.3 変状の着目すべき点¹³⁾

図-2.2 に，変状を切土，盛土，自然斜面別に発生箇所を分類し，網羅的に抽出したものを示す。図-2.2 を作成するにあたり，道路土工構造物点検要領⁹⁾，道路防災点検要領¹²⁾を参考にした。また，上記で示した斜面における変状のうち，頻度の面からどの変状が重

盛土法面

切土法面

変状	測量種別	変状	測量種別
	LP測量		MMS測量
亀裂	× (画像で分析)	亀裂	× (画像で分析)
段差	△～○	段差	○
はらみだし	○	はらみだし	○
浸食	○	浸食	○
湧水	× (画像で分析)	湧水	× (画像で分析)
小崩壊	○	小崩壊	○
盛り上がり	○	軟弱化	×
空洞	×	地盤の隆起	○
目地のずれ	×	目地のずれ	△～×
傾動	○	土砂のこぼれだし	△～×
土砂のこぼれだし	○	構造物の変形・破損	×
うき	× (画像で分析)	漏水	× (画像で分析)
構造物の変形・破損	○		

図-2.4 分類した変状と点群データによる検知可能性

要であるか検討を行った。久保ら¹³⁾による研究では、防災カルテ点検における着目点の割合について、評価がランクアップした箇所や変状着目点に進行が認められる166事例を抽出して整理を行っている。その結果、図-2.3に示すように、着目箇所としては法面以外にモルタル吹付が多く、変状では崩壊・崩落、亀裂・ずれ・段差が多くなっていることが確認されている。以上より、災害が発生する危険性の高い変状・箇所として、モルタル吹付法面の水平方向の開口亀裂やモルタルの剥離といったものがあげられている。

上記で抽出した変状に対し、実際に点群データによる変状の検知可能性を検証するため、点群計測方法別に変状を整理する必要がある。一般に、点群計測には移動計測車両測量システム(MMS)や航空レーザ測量(LP)が用いられる。MMSやLPは得られる点群の密度、レーザ照射範囲等が大きく異なり、これらを考慮すると自然斜面・盛土法面に対してはLP、道路路面・切土法面に対してはMMSによる計測が有効であると考えられる。以下では、このような計測方法の違いも考慮に入れ、主に盛土法面、切土法面の二つについて生じうる変状と想定される変状検知手法に関して考察を行う。

図-2.4に、盛土法面、切土法面において生じうる変状と想定される変状検知手法を示す。点群データにより検知可能と考えられる異常は、面外方向への変位を生じることが不可欠であるといえる。すなわち、面外方向への変位が生じない目地のずれなどは検知不可能と考えられ、亀裂や湧水、うきといったそもそも変位が生じないようなものは言うまでもなく困難である。しかしながら、亀裂やうきに対しては画像分析により異常を検知する研究

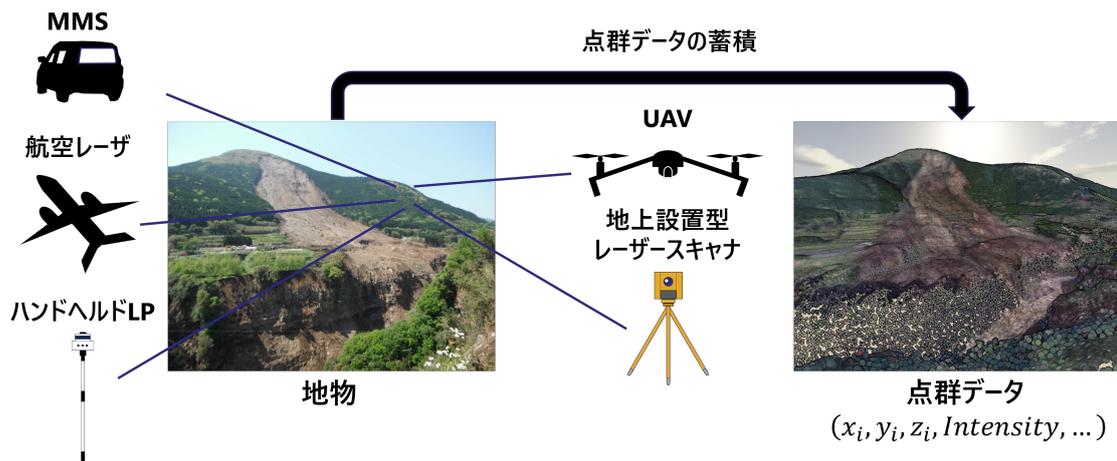


図-2.5 様々な点群計測機器

が多数行われており、将来的にはそれらの手法を併用することにより、効率的な土工構造物の維持管理が可能となると考えられる。

2.3 点群計測手法と点群データの選び方

2.3.1 点群計測機器の概要

社会基盤工学分野においては、図-2.5 に示すように3次元点群データを計測するための様々な点群計測機器が利用されており、それらはMMS測量や航空レーザ測量、地上設置型レーザスキャナによる測量等に大別される。各計測機器は、設置場所の制約や測距距離、点群密度、植生や移動体によるノイズ等に伴う制約等の特性が異なる。

2.3.2 MMS 測量

MMS (mobile mapping system, 移動計測車両測量システム) は車両にレーザ装置とデジタルカメラを搭載した計測システムである。GNSS (global navigation satellite systems) アンテナとオドメータ¹⁷⁾、慣性計測装置 (inertial measurement unit, IMU)¹⁸⁾ などによりレーザ照射時の自己位置や姿勢を計測しながら点群データの取得を行う。各種機器が時間的に同期化されたデータに対して後処理を行うことによって、計測時の観測幾何学性を再現し、点群を生成する。デジタルカメラに関しては、画角の狭い各方向への複数のエリアカメラと全周囲カメラが搭載されていることが一般であり、周辺の画像を取得する機器として目的に応じて使用される。また、レーザスキャナ以外に搭載される機器の組み合わせは様々であり、多様な機種が存在する。

図-2.6 に、MMSによる点群計測フローを示す¹⁴⁾。

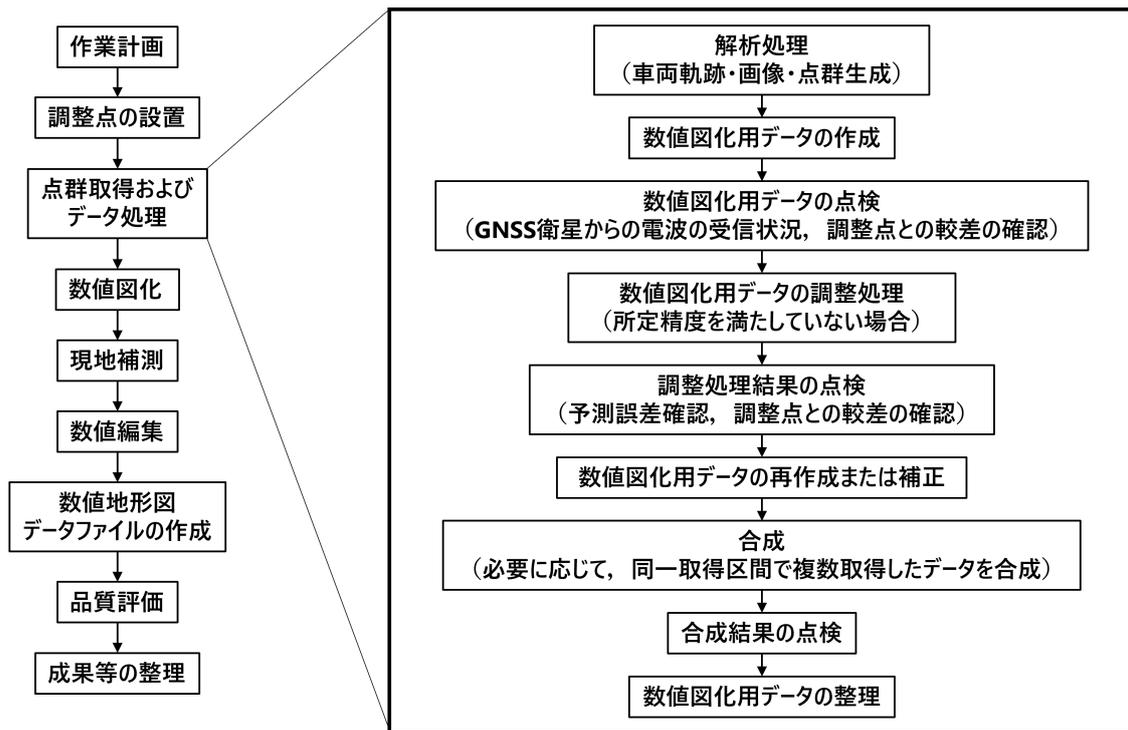


図-2.6 MMS の計測フロー

2.3.3 航空レーザ測量

航空レーザ測量とは、航空機から発射したレーザにより、3次元形状を高密度かつ高精度に取得する測量技術である¹⁾。航空機から測定対象物に照射したレーザの反射光が返ってくるまでの時間を計測することで、対象物の形状を計測する。航空機には、航空機の位置を計測するGNSSアンテナや航空機の姿勢と加速度を計測する慣性計測装置 (inertial measurement unit, IMU)、レーザスキャナが備えられており、レーザ照射時の自己位置や姿勢を計測しながら点群データの取得を行う。また、デジタルカメラが付属されているものもある。航空レーザ測量の利点として、地形形状を含めた面的な把握が可能であることや反射強度により地物が判定可能であること等があげられる。

図-2.7に航空レーザ測量による点群計測フローを示す。計画・準備においては、計測箇所状況や空港の有無、GPS衛星配置状況、天候等を考慮し、要求された点密度が達成できる測量パラメータや飛行コースの設定を行う。レーザスキャナを搭載する航空機をプラットフォームといい、セスナなどの固定翼機とヘリコプターなどの回転翼機がある。一般に、固定翼機は計測可能な高度の範囲が広いことから建物の影による影響を受けにくいため都市部等の計測に適しており、回転翼機は機動性に富むことから河川沿いや道路沿いの計測に適している。また、地上GPS基準局の選定では、なるべく計測箇所に近い箇所を選定する。独立に設置しなくても、1秒間隔でデータを取得できる電子基準データで代用することもある。

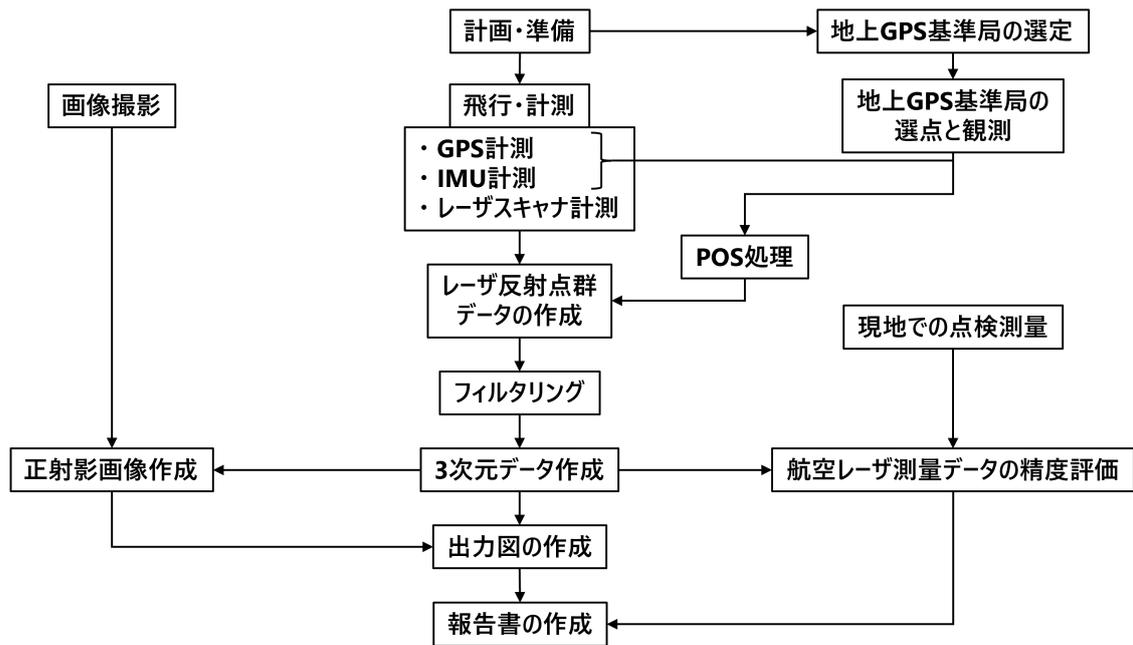


図-2.7 航空レーザ測量の計測フロー

航空レーザ測量では、上空からの計測を行うことに起因して雲や空気中の塵、煙、排気ガスなどに反射するノイズが含まれることがある。そのため、これらに反射した点を計測対象箇所の最高標高や最低標高を基準に除去する必要がある。また、レーザパルスは地表面だけでなく、地物でも反射されてしまうため、航空レーザ測量で取得されたデータには建物や樹木の高さが記録された点も存在している。一般に、建物や樹木を含む地上の表面形状を表したデジタルデータをDSM (Digital Surface Model)¹⁹⁾、建物や樹木を除いた地表面形状を表したデジタルデータをDTM (Digital Terrain Model)²⁰⁾やDEM (Digital Elevation Model)と呼んで区別する。すなわち、航空レーザ測量で取得された生の点群データはDSMデータとなっているため、これに図-2.8に示すようなフィルタリング処理²¹⁾を行うことでDEMデータを取得する必要がある。フィルタリング処理にはラストパルスを使用する手法や統計的手法などが存在する¹⁾。

また、獲得されたDEMデータは非常に多数の点で構成されていることから、計算コストを抑える工夫が必要である。一般には、得られたDEMデータにおいて、各点間を接続することで作成したTIN (不規則三角形網)²²⁾に対し、数m方眼のメッシュをかぶせ中心点の高さを補完する。これにより、各メッシュ内での代表点を作成してその他の点を除くことにより計算コストを抑制する。

フィルタリング：計測点群を地物と地盤面に分類

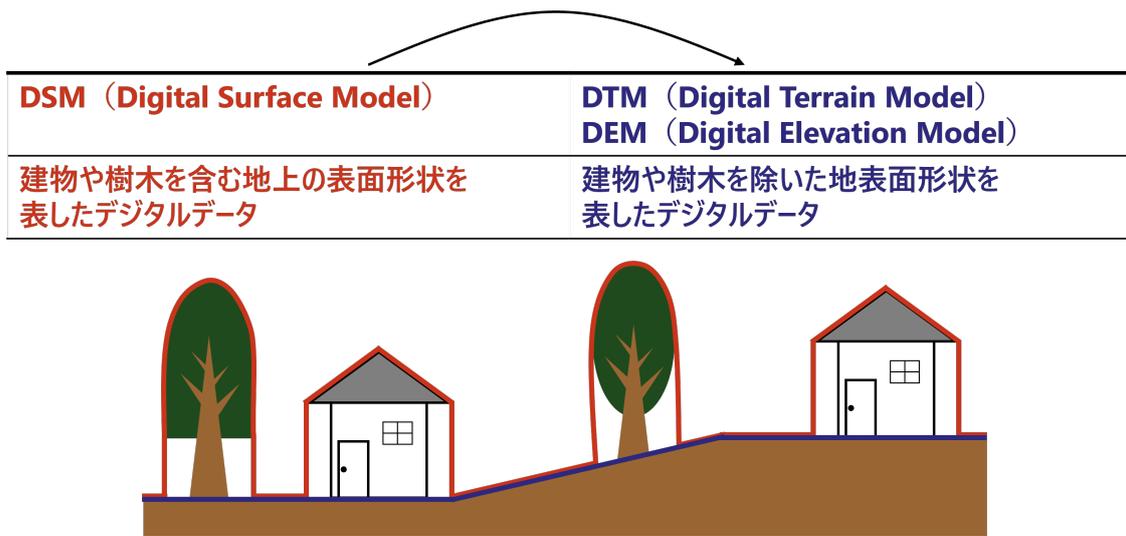


図-2.8 航空レーザ測量により得られる点群のフィルタリング処理

2.3.4 地上設置型レーザスキャナ・ハンドヘルドLP・UAVによる測量

地上設置型レーザスキャナ (terrestrial laser scanner, TLS) は地面に三脚を立ててスキャナを設置し、放射状にレーザを照射して、それを受光をするまでの時間と光の速度から対象物までの距離を計測して周囲の点群データを取得する¹⁵⁾。

ハンドヘルドレーザは衛星からのGNSS信号の受信を必要とせずに計測が可能であり、計測したデータをSLAM (simultaneous localization and mapping) 技術で解析する¹⁶⁾。SLAM技術とは、3次元点群データ作成と自己位置情報を同時に取得する手法で、IMU等の姿勢センサデータに加え、3次元データとリアルタイムのスキャンデータとのマッチングにより自己位置を推定する技術の総称である。

また、UAVの普及により、UAVに搭載されたカメラによる映像や写真を基に、写真測量技術の原理によるSfM (structure from motion) 処理²³⁾により点群データを生成することも行われている。SfMは対象とする物体をカメラの視点を変えながら撮影した複数の画像から対象物の3次元データを構築する技術である。

2.3.5 各種点群計測機器の比較

上記の説明をまとめた各種点群計測機器の比較を、図-2.9に示す。着目すべき点として、MMSやTLSでは得られる点の密度が高いのに対し、航空LPでは得られる点の密度が低いことがあげられる。その一方で、測距範囲としては航空LPが広く、MMS、やTLSでは狭域となる。また、地表面の計測という点では航空LPで得られたオリジナルの点群データにフィルタリング処理を施したDTMが最もノイズが少ないといえる。構造物の計測とい

	航空LP (DSM)	航空LP (DTM)	MMS	TLS	ハンドヘルドLP	UAV (空中写真測量)
計測時間	△ (飛行申請等の準備に手間)	× (人手によるノイズ除去が必要)	◎ (走行するのみ)	○ (可搬の手間)	○ (可搬の手間)	◎ (小型。ただし、天候と風速を考慮する必要)
測距範囲	○ (広域)		△ (やや狭域)	× (狭域)	△ (やや狭域)	△ (やや狭域)
計測可能領域	○ (飛行可能なエリア全域)		× (堤防周辺や障害物のないエリアのみ)	△ (設置可能箇所から可視できる範囲)	△ (人の侵入できる領域)	○ (飛行可能なエリア全域)
計測不可能領域	△ (オーバーハング箇所や構造物側面は不可)		△ (道路から見えない領域は不可)	△ (構造物の上面等は不可)	△ (人の侵入できない領域は不可)	△ (オーバーハング箇所は不可)
測距精度 (理論値)						
点密度	△ (普通)		◎ (非常に高い)	◎ (非常に高い)	○ (高い)	○ (高い)
測距点の分布	○ (一様)		△ (対象物との角度に依存)	× (近距離ほど高い)	× (近距離ほど高い)	△ (ソフトウェアに依存)
地面に対する計測角	90°程度		20~90°	10~90°程度	10~90°程度	90°程度
地表面の計測	○ (ノイズ有)	◎ (地表面のみ)	△ (走行箇所から見える範囲のみ)	○ (ノイズ有)	○ (ノイズ有)	○ (ノイズ有)
構造物の計測	△ (上面のみ)	× (除去済)	○ (路面のすべてを計測できる)	○ (側面を計測できる)	○ (側面を計測できる)	◎ (すべてのエリアを計測できる)
構造物・植生・移動体等のノイズ	×	◎ (地表面以外のデータなし)	×	×	×	×

図-2.9 計測機器による点群データの特性⁽¹⁷⁾を参考に一部加筆

う点では、上空から計測を行う航空LPでは構造物上面の点群のみが取得されるため、用途によってはMMSやTLS等を用いて構造物側面の点群データを取得する方が好ましい。以上のように、点群データの取得という一過程をとっても、計測機器に応じてその特性が大きく異なることを認識し、用途に応じた選択を行う必要がある。

2.3.6 計測頻度の設定

計測頻度の設定は、計測した点群データの利用目的に応じて定める必要がある。2.1で示した目的のうち、変状箇所の時系列変化を追跡する定量的な変状のデータベースの作成や各種定期点検における点検・維持作業の効率化という目的においては、各種定期点検や日常点検時に計測を行うことが合理的である。一方で、災害時の早期変状把握という目的においては、災害後なるべく迅速に航空LP等を用いて点群データを計測し、過去の各種定期点検において蓄積された点群データとの比較・差分解析を行う必要がある。

点群データの計測頻度については、上記のように定めることは必ずしも不可欠ではなく、浸食や堆積等の土砂移動の著しい地域や地形変化の速度がはやい地域等では計測頻度を密にする等の適切な対応が重要である。また、地震や豪雨等の自然災害が発生した地域では臨時的な観測を行う等、災害に対する対応も重要である。

2.3.7 必要な点密度の検討

本節では、実務において点群取得から変状検知までのフローを作成するにあたり、「変状検知のための点群取得時のMMS計測の標準化」を行うことを目的として、土工構造物の変状を検知する際に必要十分な点密度の検討例を示す。一般に、必要な点密度は対象とする土工構造物（ここでは例として、法面を対象とする）のスケールと対象とする変状に依存すると考えられる。ここでは、対象とする法面として、横約50m、斜辺約8mの実長をもつ実際の法面で計測された点群を用いるものとし、変状をはらみ出しとして設定し必要点密度を設定する際の一例を示す。はらみ出しは、地山や盛土の変形に加えて吹付等の構造物自体の劣化や付着の低下によるたわみなど様々な要因で生じ得る。また、雨水が盛土に浸透することにより、地下水位が法面の下部まで上昇し、盛土荷重による過剰間隙水圧により法面に膨らみや亀裂として生じることもある。はらみ出しや変形などの局所の変状は、より大きなスケールの変状に進展する可能性があるため、予防保全の観点から早期の変状検知が必要となる。

点密度の低い点群データを生成するため、十分な密度で取得された2時期の法面点群データから面積当たりの点数を10,000点、50,000点、100,000点、200,000点と変化させランダムにダウンサンプリングを行った。得られた低密度の点群データを用いて2.4で述べるICPにより位置合わせを行い、2時期点群の差分解析を行った。図-2.10に、低密度点群データに対する差分解析手法の結果を示す。

図-2.10より、(a)の10,000点の場合は点密度が低く、差分値の大きい点が点群全体にほぼランダムに散らばっていることがわかる。(b)の50,000点の場合は、点密度は上昇しているが(a)とほぼ同様に差分値の大きい点がランダムに散らばっている。(c)の100,000点の場合では、はらみ出しで差分値が大きくなっていることがうっすらと確認されるが、不明瞭であり事前知識なしでは見逃す可能性が高いと考えられる。(d)の200,000点の場合では、図-2.10中に緑の枠で示すように、はらみ出しで差分値が大きくなっていることが明瞭に確認される。以上のことから、今回対象とした法面では大きさ2,3cmのはらみ出しの変状検知を行うのに約200,000点程度あればよいことが確認された。さらに、今回対象とした法面は横約50m、斜辺約8mの実長をもつことから、上で見積もられた200,000点を法面の面積である400m²で除すことにより、約500点/m²という点密度が得られる。このことから、大きさ2,3cm程度のはらみ出しを検知するのに約500点/m²程度あれば十分であるという点密度に対する一考察事例が得られた。

上記の例では、対象とする変状としてはらみ出しを設定して必要点密度の検討を行った。実際に実務で変状検知を行う際には、対象とする変状を予め計測前のある程度想定するため、変状ごとに必要点群密度を概算しておき、それらを参照して取得する点密度、ひいてはMMSの走行速度やMMSから計測斜面までの距離を設定することが考えられる。

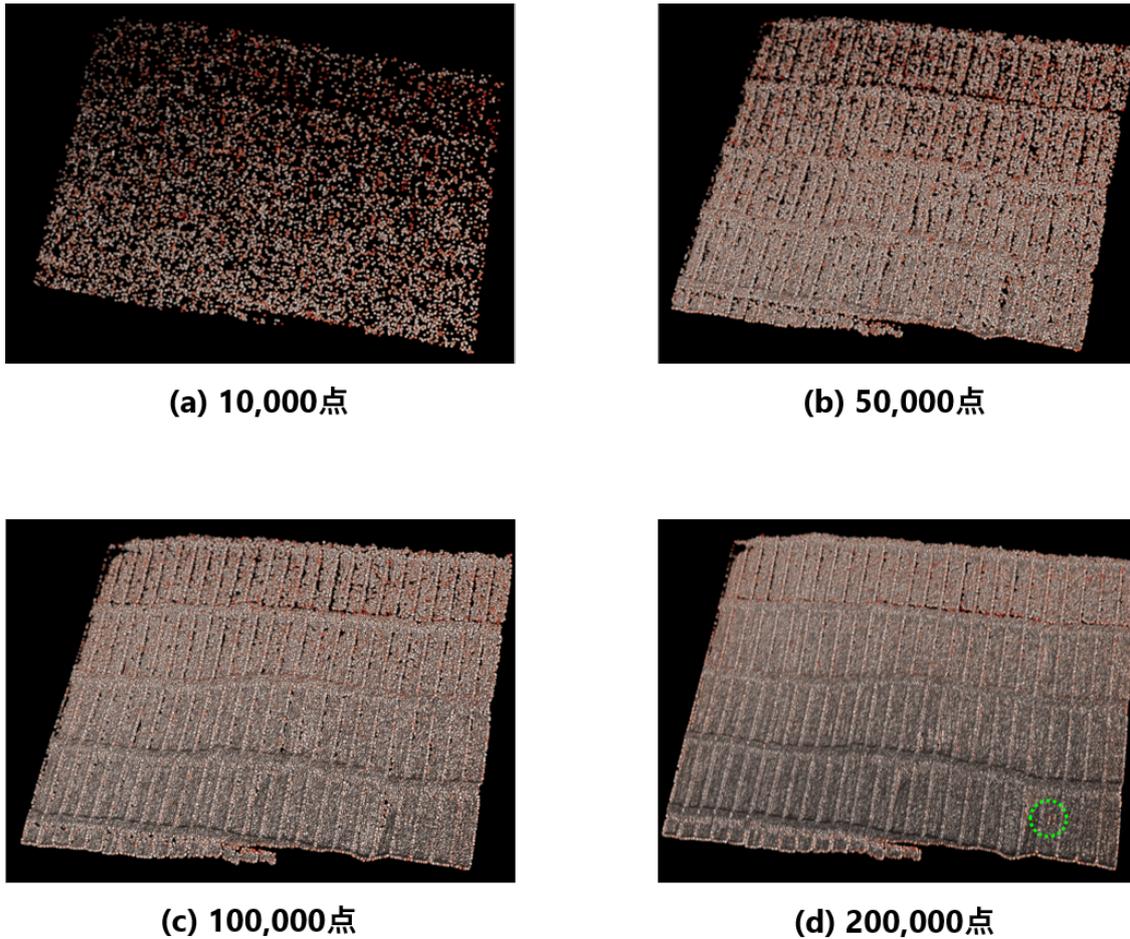


図-2.10 メゾスケール手法における必要点群密度の検討

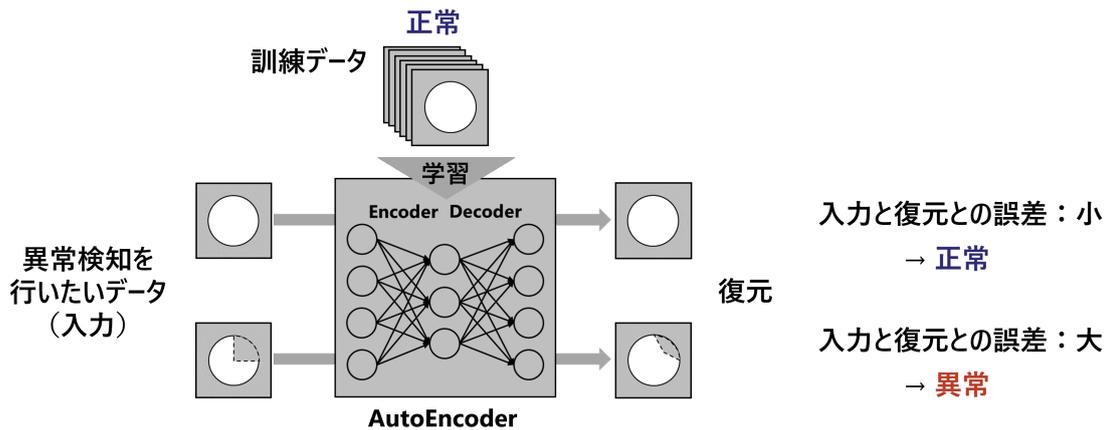
2.4 道路斜面災害リスク箇所の抽出

2.4.1 PointAutoEncoder

(1) AutoEncoder

Auto Encoder（自己符号化器）¹⁸⁾とは目標出力をもたず，入力のみで訓練データを用いた教師なし学習手法であり，データを良く表す特徴表現の獲得を目的としたニューラルネットワークである．特徴表現の良さについては，明確に定められた定義は存在しないが，一般に情報量や独立性，説明性，スパース性，不変性，滑らかさなどを用いて評価されている¹⁹⁾．本手法が提案された当初は深いネットワークの事前学習（重みの良い初期値を得ること）に用いられていたが，近年は次元削減や異常検知，ノイズの除去などに利用されることが多くなっている．

図-2.11は，Auto Encoderによる異常検知の概念を示している．一般的に深層学習手法は選定された特徴量や特定されたネットワーク構造を明確に説明することが困難なブラッ



注) 円が書かれた画像は正常データ、円の一部分が欠損した画像は異常データを表している。

図-2.11 Auto Encoder による異常検知

クボックスであり、その出力に対する工学的解釈が容易でない場合が少なくない。これに対して、Auto Encoder は入力と同じデータを出力として復元するような AI である。Auto Encoder による異常検知では、はじめに正常データのみを用いて Auto Encoder を学習させる。その後、異常検知を行いたいデータを学習済みの Auto Encoder に入力し、入力と復元との誤差を算出する。このとき、入力が正常なものであれば、復元も正常なものであるため入力と復元との誤差が小さくなる。一方で、入力が異常なものであれば、Auto Encoder は正常データの特徴しか学習していないため、異常データを復元することができず、入力と復元との誤差が大きくなり異常値として検出できる。

(2) PointAutoEncoder

上記で述べた AutoEncoder に対し、点群データセットの順不変性の問題に対応するために、順不変性を満たす構造を導入したモデルを PointAutoEncoder と呼ぶ。PointAutoEncoder の詳細については、付録 2 に付している。

2.4.2 差分解析手法

(1) 差分解析と位置合わせ

2 時期点群の差分解析手法は、1 期目の点群を変状のない点群としておき、それ以降に計測された点群との差分解析を行うことにより変状箇所を差分として見出す手法である。2 時期の計測で得られる点群は一般に同一のものではないうえ、上空の視界や GPS 衛星の配置状況等に起因した相対的・絶対的なずれが生じうる。このようなずれは場合によっては

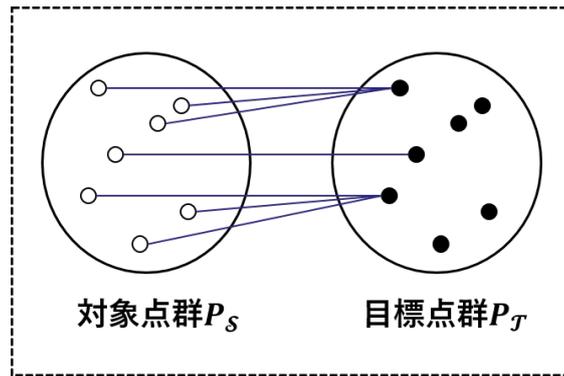


図-2.12 ICP の概念図

数十 cm に達することが報告されており，差分解析をそのままの状態で行うことは困難である．以上の理由から，差分解析手法においては何らかの位置合わせ処理（レジストレーション）が必要となる．

位置合わせ手法は様々な研究がなされており，概略的な位置合わせ手法から精密な位置合わせ手法まで多岐にわたる手法が存在している．概略的な位置合わせ手法には，マニュアル操作により点群の位置を合わせる手法や，何らかのターゲットを利用して位置合わせを行う手法，RANSACなどが存在する．精密な位置合わせ手法で代表的なものとしては，ICP(Iterative Closest Point)²⁰⁾があげられる．ICPでは既知点を必要としないことが特徴的である．リアルタイム性の確保と人手を介さないという変状検知手法への要求を鑑みると，位置合わせ手法にも計算速度の速いものを用いることが必要であり，なおかつ人手で抽出する特徴点を用いないことが望ましいといえる．

(2) ICP

図-2.12に，ICPの概念図を示す．ICPは一方の点群（以下，対象点群）に対して並進と回転という2つの座標変換を繰り返すことにより，他方の点群（以下，目標点群）に位置合わせを行うターゲットレスな手法である．多数の派生手法があるが，ここでは最も単純なものを説明する．はじめに，対象点群の各点に対し，目標点群内の最近傍点をサーチする．このような対象点群の各点に対し，目標点群内のある点と対応がついている場合，変換後の対象点群のうちの各点と目標点群内の対応する点の残差が最小となるように並進と回転の変換を算出することが可能である．このような最近傍点のサーチと変換の推定という2つの操作を逐次的に繰り返すことにより，対象点群を目標点群に位置合わせしていくことが可能である．なお，ICPの数学的詳細については付録3に付している．

ICPを行う際には，事前におおまかな位置合わせを行っておく必要がある．そのため，対照点による位置合わせとして，不動点を数か所選択してその差が十分に小さくなるように

事前位置合わせを行うことや目視によって位置合わせを行うことが必要となる。

また、ICPを行う場合、大きな変状が生じていれば、位置合わせを行う際に変状部に合うように位置合わせが行われてしまい、精度が不十分となりうる。そのため、ICPを行う前に、

- 1) 点群を複製し、変状箇所を除去した後、その点群を用いてICPを実施して変換行列を作成する。
- 2) 得られた変換行列を元の点群に作用させる。

という2段階でICPを行うことが望ましい。実際の土工構造物の位置合わせにICPを用いる場合、変状部が事前に既知であることは多くないため、この点は大きな課題である。これに対する適応策として、点群と同時に取得される画像データを用いて変状のおおよその箇所を把握しておくことがあげられる。また、予期される変状が小さい場合にはICPによる位置合わせに対する変状部の影響は小さく、精度は落ちるが元の点群に対してICPを直接行うことも考えられる。

以上のような位置合わせを行ったうえで、対象点群の各点に対し目標点群内の最近傍点までの距離（差分値）を算出し、これを異常度とする。

2.5 点群データを活用するうえでの留意点

点群データの取得ならびに点群データを用いた解析では、以下に示す適用限界・留意点に注意する必要がある。

- 点群取得時にレーザー照射線方向に障害物（オクルージョン）が存在する場合は当該線方向の点群は取得できない。
- 計測対象の構造物に植生等が存在している場合は構造物の点群データが取得できないことがある。これに対し、法肩や法尻といった傾斜変換点（ブレイクライン）等の重要な箇所については、傾斜変換点箇所のみを高密度に観測することや傾斜変換点箇所に標識を設置して観測すること、傾斜変換点箇所を別途TSで観測すること等の対策を講じる³⁾ことが望ましい。
- 点群データの差分解析を行う場合、面外方向に生じる変状は検知可能であるが、面内方向に生じる変状の検知は難しい。面内方向に生じる変状については、点群データの取得時に同時に取得される画像データを用いて変状を検知することが考えられる。
- 災害時において、変状が生じた前後の差分解析は可能である一方、前兆現象なしの豪雨や地震等で発生する斜面崩壊については検知不可能である。

- 植生に関しては、位置合わせを行う際に除去することが求められる。場合によっては、点群と同時に取得されるデジタル画像を使用して、目視で除去することが望ましい。一方で、植生自体が災害の誘因となるものも存在するため、その取り扱いには注意が必要である。

第3章 土工構造物の維持管理への適用事例

3.1 法面 A における適用事例

実在する法面において、法面の点群データの計測を行い、変状の変化の抽出可能性を検討した。計測した法面の点群データは2時期のデータにより構成される。ただし、1期と2期の計測は同日中に実施したものであり、その間隔は十分に小さい。したがって、2期データについては既知の異常として、特定の法枠内に図-3.1に示す模擬はらみ出しを設けた。はらみ出しとは、主として雨水が盛土に浸透することにより、地下水位が法面の下部まで上昇し、盛土荷重による過剰間隙水圧により法面に膨らみや亀裂が生じる現象であるが、盛土や地山のすべりや盤膨れ、構造物の座屈変形や水圧の作用などさまざまな要因が考えられる。はらみ出しは山側施設の日常巡回における着目点として最重要視すべきであることが報告のある崩壊、崩落へつながる変状形態であり、面外方向へ変位が生じるために点群データで検知可能であると考えられる。図-3.1に示す対象法面は100個の法枠で構成されている。

計測は走行速度15km/hのMMSによって行った。図-3.2に計測に用いたMMSの仕様を示す。当該MMSは、高精度IMU、高密度レーザを搭載しており、レーザやカメラを昇降可能である。これにより、高所からレーザやカメラによる計測を行うことができるため、図-3.2(b)のように走行位置に対し下方や側方のオクルージョン（障害物）を低減することができる。また、高所を対象とした場合でも、相対的に計測距離が短くなるために、密な点間隔の点が取得可能である。

図-3.3に、PointAutoEncoderで変状検知を行った結果を示す。入力点群として用いた全50法枠のうち、6つの法枠（法枠A～F）を例にあげ、PointAutoEncoderによって算出された各点の異常度を異常度マップとして示している。図-3.3において、異常度が高いほど赤く着色されており、異常度がゼロに近いほど白に近い色となっている。法枠A、法枠Bは特定の箇所に隆起点があるような点群である。両点群ともに隆起部分で異常度が高く算出されていることが確認できる。法枠Cは中心下部に歪みをもつ点群、法枠Eもほぼ同様の箇所に歪みをもつ点群である。異常度マップを見ると、歪み付近で異常度が高く算出されていることが確認できる。法枠Dは右側にねじれのような歪みが生じている点群である。ねじれの部分で明瞭な異常が検知されているのが確認される。また、法枠Fは、擬似的に既知の異常としてはらみ出しを与えた点群であるが、3cmはらみ、2cmはらみともに異常として検知できていることが確認される。しかしながら、擬似的に与えたはらみ出しのうち、1cmはらみについては異常として明瞭な着色がされず、事前知識なしで検知すること

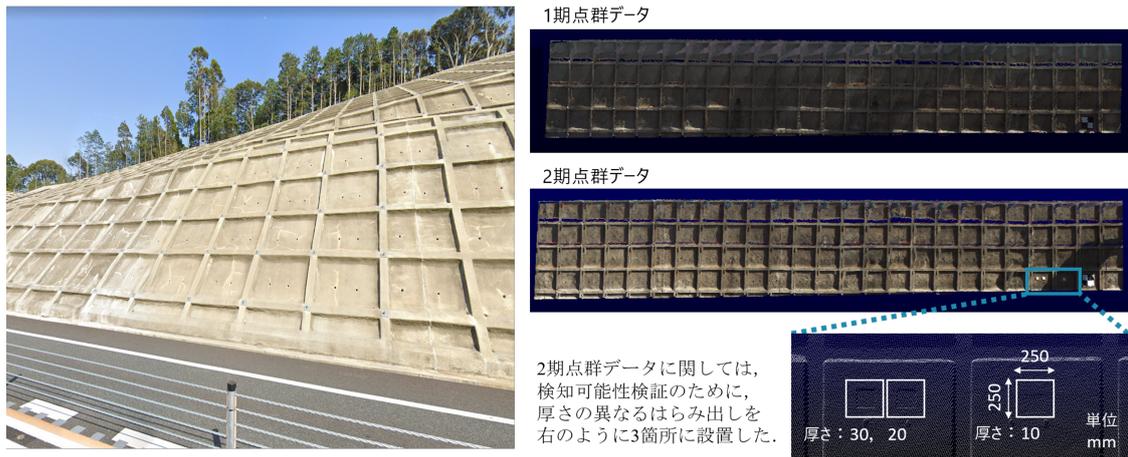


図-3.1 計測対象の法面

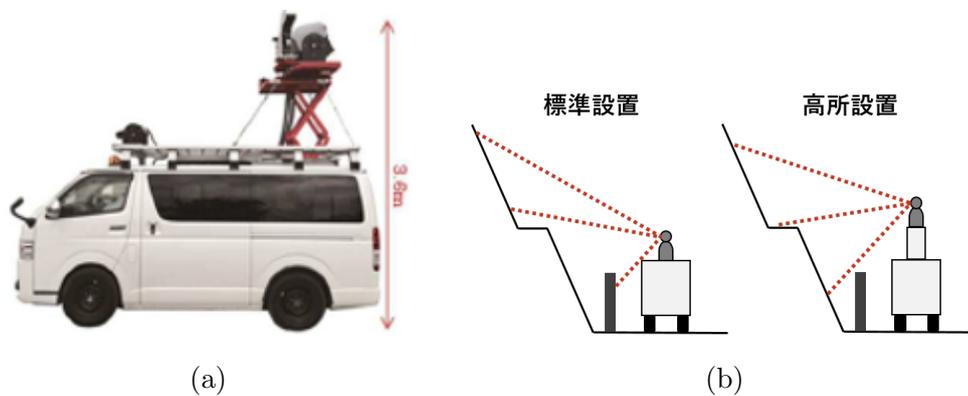


図-3.2 計測に用いられたMMS. (a)MMS MX-5 外観, (b) 高所設置の優位性.

は不可能な結果となることを確認した。なお、図-3.3には示していないが、訓練データに用いた法枠点群は異常度マップがほぼ白色となったことを確認している。図-3.4に、法面全体における異常度マップの算出結果を示す。法面上段点と下段点の異常度マップを比較するため、得られた異常度に対しカラスケールを $[0, 0.005]$ に統一していることに注意を要する。図-3.4より、法面上段点に対する異常度マップも法面下段点とほぼ同様なものが得られており、突出して異常な結果は得られていないことが確認される。すなわち、図-3.4中に緑の枠で示すように、異常度の高い法枠群はある程度分散して生じており、上部に偏るような結果は生じていない。

また、図-3.5に、ICPにより位置合わせを行った後、差分解析を行った結果を示す。図-3.5より、2, 3cm はらみに関しては明瞭に検知できていることが確認され、これはPointAutoEncoderを用いた際と同様な結果となっている。1cm はらみについては、事前知識なしで見つけることは困難であり、検知できているとはいえない結果となった。また、注目す

べき点として、ICPによる差分析結果では法面最上段の部分で誤検知が多く存在していることが確認される。これは、MMSによる計測ではレーザ光の反射を用いて計測するため上段の点ほど取得しにくくなり、得られる点群がスパースとなってしまふことに起因している。

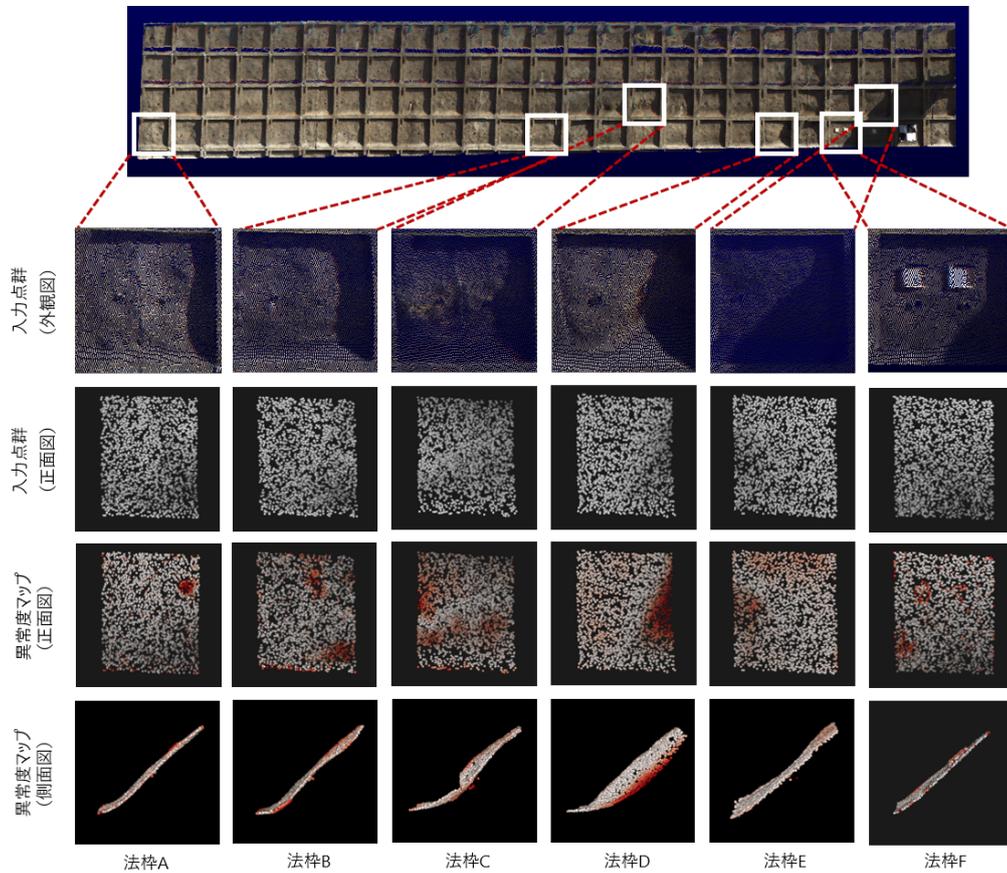
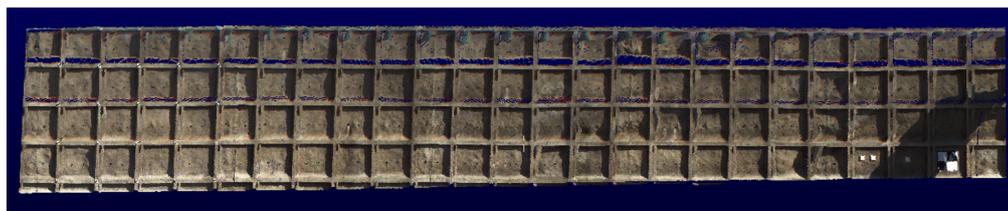
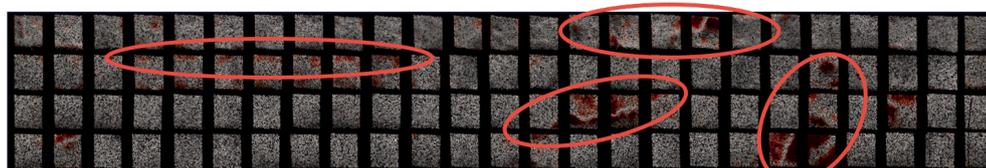


図-3.3 法枠6か所に対する異常度マップ算出結果



(a) 点群データ (法面全体)



注) 異常度に対して、カラースケールを[0, 0.005]に統一して全体表示.

(b) 異常度マップ (法面全体)

図-3.4 法面全体における異常度マップ算出結果

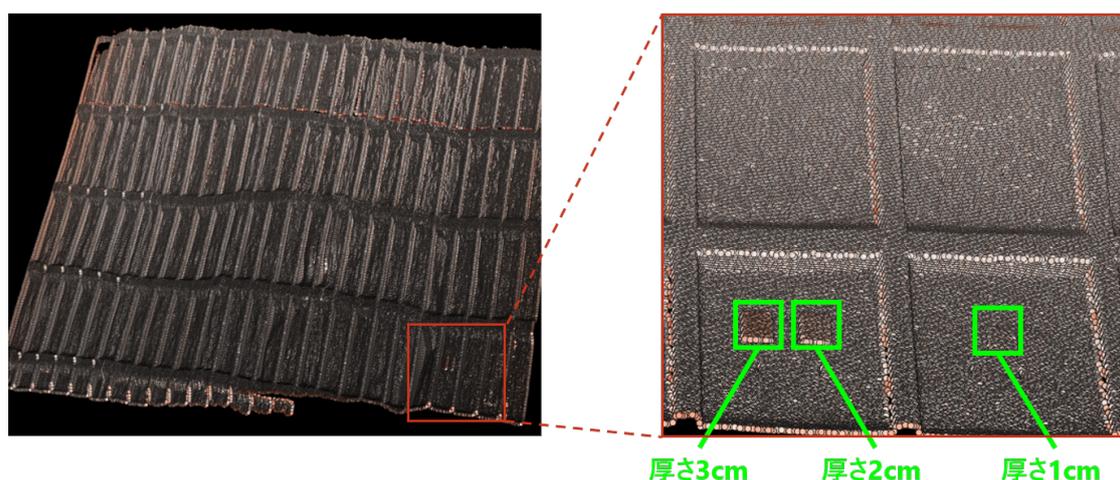


図-3.5 差分解析結果

3.2 法面 B における適用事例

実在する法面において、法面の点群データの計測を行い、変状の変化の抽出可能性を検討した。法面 B は道路形状が曲線であり、走行軌跡が曲線となるような例となっている。計測した法面の点群データは 2 時期のデータにより構成される。ただし、1 期と 2 期の計測は同日中に実施したものであり、その間隔は十分に小さい。したがって、2 期データについては既知の異常として、特定の法枠内に図-3.6 に示す模擬はらみ出しを設けた。法面としては、図-3.6 に示すように、法枠を有する法面と法枠を有さないコンクリート吹付法面の 2 種類に対して計測を行った。法枠を有する法面については、小段上の法面上部に模

擬はらみ出しの設置を行った。

計測は走行速度30km/hのMMSによって行った。計測に用いたMMSの仕様として、レーザーキャナのパルスレートは1000kHz、スキャンレートは200Hzである。計測するMMSの走行軌跡から模擬はらみ設置箇所までの直線距離は約18mであった。

図-3.7、図-3.8に、ICPにより位置合わせを行った後、差分解析を行った結果を示す。図-3.7に緑の枠で示すように、明瞭ではないが2cm、3cmの模擬はらみ出しが検知されていることが確認される。一方で、1cmのはらみ出しは本事例においても検知することが不可能であった。また、それ以外に、本事例では植生部の除去を十分に行っていないため、黄色の枠で示すような植生部での異常度の増大が見られてしまっている。加えて、水色の枠で示すように、道路上のMMSからのレーザー光の届かない箇所でも点密度が疎となり、異常度が高くなってしまっている。また、図-3.8に緑の枠で示すように、コンクリート吹付法面では3cm、2cm、1cm模擬はらみ出しがすべて検知可能であった。一方で、黄色の枠で示すように植生部でも異常度が大きくなっている。

法面Bの事例結果から、法枠付き法面の法枠内のはらみ出しに比べ、吹付法面上のはらみ出しの方が検知しやすいということが確認された。



(a) 法枠付き法面



(b) コンクリート吹付法面

図-3.6 計測対象の法面

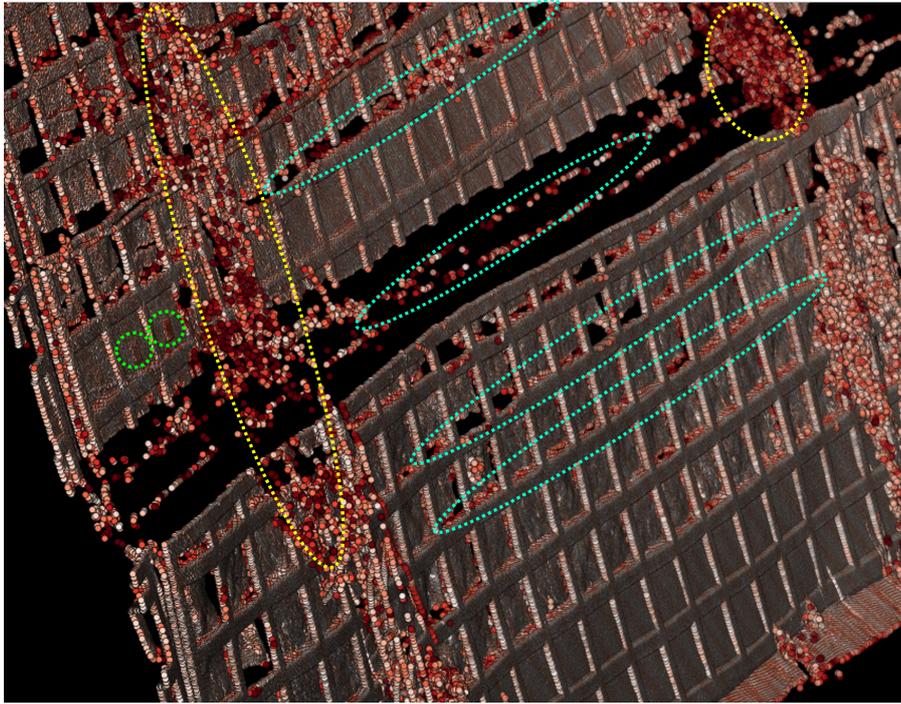


図-3.7 差分解析結果（法枠付き法面）

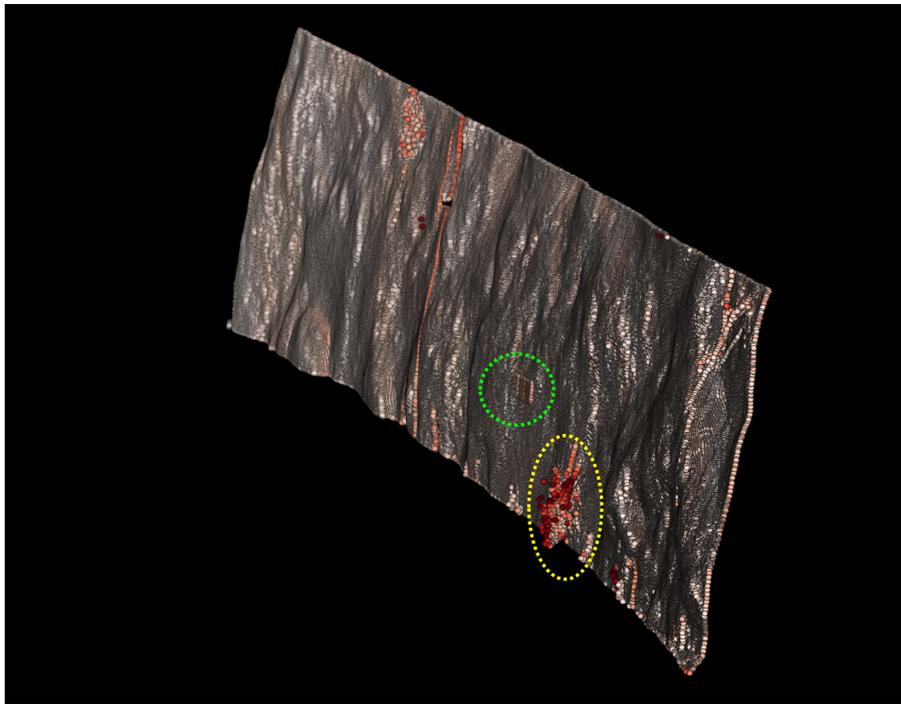


図-3.8 差分解析結果（コンクリート吹付法面）

3.3 法面 C における適用事例



法枠付き法面

図-3.9 計測対象の法面

実在する法面において、法面の点群データの計測を行い、変状の変化の抽出可能性を検討した。計測した法面の点群データは2時期のデータにより構成される。ただし、1期と2期の計測は同日中に実施したものであり、その間隔は十分に小さい。したがって、2期データについては既知の異常として、特定の法枠内に図-3.9に示す模擬はらみ出しを設けた。計測対象の法面は、図-3.9に示すように、アンカーボルト付きの大きな法枠を有する法面となっている。

計測は走行速度 30km/h の MMS によって行った。計測に用いた MMS の仕様として、レーザスキャナのパルスレートは 1000kHz、スキャンレートは 200Hz である。道路形状は直線であり、計測する MMS の走行軌跡から模擬はらみ設置箇所までの直線距離は約 7m であった。

前節までと同様に ICP による差分解析を行った。結果は前節までと同様であるので、割愛する。

法面 A～C までの結果を整理し、はらみ出しの検知が可能な条件に関して整理を行った。図-3.10 に、以上のような分析を踏まえ、はらみ出しの検知が可能な MMS の速度・計測距離の検討結果を示す。図-3.10 に示すように、MMS から計測対象までの距離が近ければ、1cm 程度の小さな変状も検知可能である。また、2cm 程度までのはらみ出しについては、ある程度適切な条件で点群の計測を行えば、検知が可能であることが確認された。

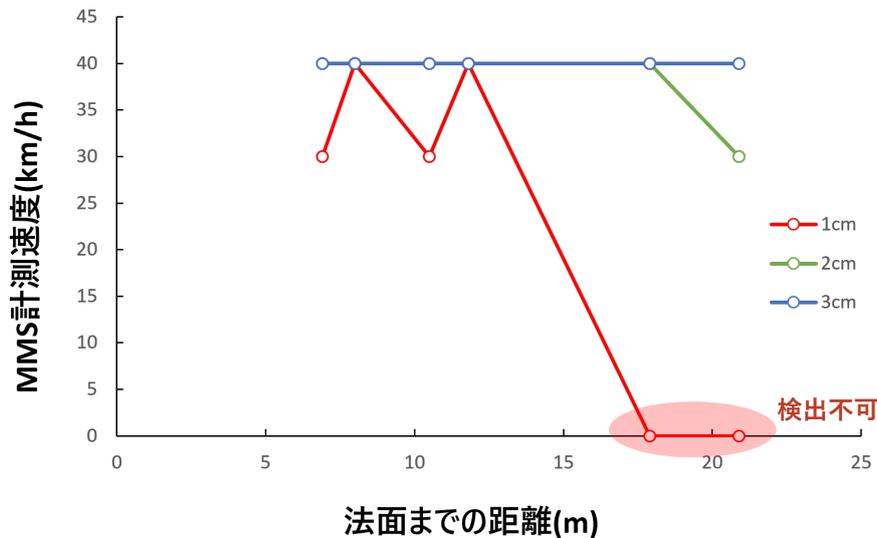


図-3.10 はらみ出しの検知可能条件

付録1：用語の説明

1) 道路土工構造物

道路を建設するために構築する土砂や岩石等の地盤材料を主材料として構成される構造物およびそれらに付帯する構造物の総称であり、切土・斜面安定施設、盛土、カルバートおよびこれらに類するもの。

2) 3次元点群データ

空間座標 (x, y, z) や色情報 (R, G, B) 等を有するレーザによって取得された点の集合で、計算処理が可能な形態で表現されたもの。

3) MMS 測量

車両にレーザ装置とデジタルカメラを搭載した計測システム。GNSS アンテナとオドメータ、慣性計測装置などによりレーザ照射時の自己位置や姿勢を計測しながら点群データの取得を行う。

4) 航空レーザ測量

航空機に搭載したレーザスキャナから地上に向けてレーザパルスを発射し、反射したレーザパルスを解析することにより3次元地形データを獲得する測量手法。

5) UAV 測量

UAV (Unmanned aerial vehicle) (ドローン) による空中写真を用いた数値地形図の作成および3次元点群作成を行う測量手法。

- 6) 地上設置型レーザスキャナ (terrestrial laser scanner, TLS)
特定の位置に機器を据え付け、前方に断面を測量するようにレーザ光を照射すると同時に機器本体を回転させることにより周囲に存在する地形・地物までの方向と距離を面的に観測し、3次元点群データを獲得するもの。
- 7) ハンドヘルド LP 測量
人が手に持った状態で計測対象箇所にレーザ光を照射し、計測したデータを SLAM (Simultaneous Localization and Mapping) 技術で解析することで3次元点群データの作成と自己位置情報を同時に取得する測量手法。
- 8) SLAM (simultaneous localization and mapping) 技術
3次元点群データの作成と自己位置情報を同時に取得する手法で、姿勢センサデータに加え、3次元データとリアルタイムのスキャンデータとのマッチングにより自己位置を推定する技術の総称。
- 9) 変状
切土法面、盛土法面など各道路土工構造物に発生する形状、性状、環境の変化で視認できるもの。
- 10) 道路防災点検
道路法の規定するすべての道路を対象に、主に自然災害による危険箇所を抽出するための防災を目的とした点検。
- 11) 防災カルテ点検
道路防災点検により抽出された災害の可能性のある箇所に対して、道路管理者が災害に至る要因を早期に発見・対応するための点検。
- 12) 道路土工構造物点検
道路構造物の老朽化に起因する災害に対して、防災上および効率的な維持修繕の観点から適切な時期を把握し適切な対策を施すことを目的に、長大切土や高盛土などの特定土工構造物に対し5年に1回の頻度で実施される点検。特定土工点検ともいう。
- 13) 近接目視点検
点検技術者が施設に対して計測、触診、打音検査ができる距離まで近づき、損傷状態や変状を詳細に調べること。
- 14) GNSS (Global navigation satellite system, 全球測位衛星システム)
GPS やロシアの GLONASS, 欧州連合の Galileo 等の衛星測位システムの総称。

- 15) GPS (Global positioning system, 汎地球測位システム)
人工衛星を利用して位置を測定するシステム。レーザスキャナの位置の取得に利用する。
- 16) LiDAR (Light detection and ranging)
計測範囲にレーザ光を照射し、その反射光が観測されるまでの時間や反射光の反射強度を解析することにより、対象物までの距離や反射特性、座標値を取得する光学リモートセンシング技術。
- 17) オドメータ
自動車の走行距離積算計。DMI (Distance measurement indicator, 走行距離計)ともいう。
- 18) IMU (Inertial measurement unit, 慣性計測装置)
ジャイロや加速度計、演算用のコンピュータから構成されており、プラットフォームの位置と姿勢を計測できる。
- 19) DSM (Digital surface model, 数値表層モデル)
地物・植生等を含む地上の表面形状を表すデジタルデータ。
- 20) DTM (Digital terrain model, 数値地形モデル)
地物・植生等を取り除いた地表面形状を表すデジタルデータ。
- 21) フィルタリング処理
航空レーザ測量において取得された点群データに含まれるノイズを除去し、DTMとDSMを分類すること。
- 22) TIN (Triangulated irregular networks, 不規則三角網)
地形や出来形形状などの表面形状を3次元座標の変化点標高データで補間する一般的なデータ構造。各点を直線をつなぎ、三角形を構築することで補間を行う。
- 23) SfM (structure from motion) 処理
対象とする物体をカメラの視点を変えながら撮影した複数の画像から対象物の3次元データを構築する技術。

付録2：PointAutoEncoderの詳細

点群データセットの順不変性の問題に対応するために、順不変性を満たす構造を導入したAuto Encoder (PointAutoEncoder と呼ぶ) モデルに関して説明する。いま、事前時点の点群データセット $S = \{S^n (n = 1, \dots, N)\}$ が与えられたと考えよう。このうち、一般性を損

なうことなく M 個の点群データセット \mathcal{S}^n ($n = 1, \dots, M; M \leq N$) を訓練用データセットとして用いる. 任意の法枠データセット \mathcal{S}^n ($n = 1, \dots, M$) を構成する I 個の点群列ベクトル $\boldsymbol{\delta}^n = \{\boldsymbol{\delta}_1^n, \dots, \boldsymbol{\delta}_I^n\}^T$ に着目する. 記号 T は転置を表す. $\boldsymbol{\delta}_i^n = (x_i^n, y_i^n, z_i^n)$ ($i = 1, \dots, I$) は各点の 3 次元座標値を表す行ベクトルであり, 入力情報 $\boldsymbol{\delta}^n$ は $I \times 3$ 次元行列で表される. ここで, 一般性を損なうことなく添え字 n の表記を省略する. $\boldsymbol{\delta}$ を入力として, $I \times H$ 個の要素を有する行列 $\mathbf{h} = \{\mathbf{h}_1, \dots, \mathbf{h}_I\}^T$ を出力するユニット (ニューロン) で構成される単層の順伝播型ニューラルネットワーク (feedforward neural network) を考える. ただし, \mathbf{h}_i は行ベクトルであり, $\mathbf{h}_i = (h_i^1, \dots, h_i^H)$ ($i = 1, \dots, I$) で表される. この時, 単層のニューラルネットワークは

$$\mathbf{h}(\boldsymbol{\delta}; \boldsymbol{\theta}) = \mathbf{g}(\boldsymbol{\delta}\mathbf{W} + \mathbf{b}) \quad (1)$$

と表される. ただし, \mathbf{W} は $3 \times H$ 次元重み行列, \mathbf{b} は要素をすべてバイアス b で構成される $I \times H$ 次元行列であり, それらをまとめてパラメータ $\boldsymbol{\theta} = \{\mathbf{W}, \mathbf{b}\}$ と表記している. \mathbf{g} は行列 $\boldsymbol{\delta}\mathbf{W} + \mathbf{b}$ を引数とする配列関数操作であり, 行列の各要素に同一の活性化関数 $g(\cdot)$ を適用する操作を表す. 一般に, 活性化関数 $g(\cdot)$ は広義単調増加な非線形関数を用いて表現される. 本研究では既往研究²¹⁾ で利用実績のある正規化線形関数 $\text{ReLU}(z)$ を用いることとし, 活性化関数を次式で定義する.

$$g(z) = \text{ReLU}(z) = \max\{0, z\} \quad (2)$$

多層ニューラルネットワークは, 式 (1) によって表される処理を行う層を重ねることで構成される. いま, L 個の層で構成される多層ニューラルネットワークを考える. l ($l = 1, \dots, L$) 層の出力を $I \times H^{(l)}$ 次元行列 $\mathbf{h}^{(l)} = \{\mathbf{h}_1^{(l)}, \dots, \mathbf{h}_I^{(l)}\}^T$ と表す. ただし, $\mathbf{h}_i^{(l)}$ は行ベクトルであり, $\mathbf{h}_i^{(l)} = (h_i^{1(l)}, \dots, h_i^{H^{(l)}(l)})$ ($i = 1, \dots, I$) で表される. ただし, $\mathbf{h}^{(1)} = \boldsymbol{\delta}$ と定義する. さらに, l ($l = 1, \dots, L-1$) 層の重み行列を $H^{(l)} \times H^{(l+1)}$ 次元行列 $\mathbf{W}^{(l)}$, バイアス行列を $I \times H^{(l)}$ 次元行列 $\mathbf{b}^{(l)}$ を用いて表現すれば, 多層ニューラルネットワークは再帰的に

$$\begin{aligned} & \mathbf{h}^{(l)}(\boldsymbol{\delta}; \{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(l-1)}) \\ &= \mathbf{g}(\mathbf{h}^{(l-1)}(\boldsymbol{\delta}; \{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(l-2)})\mathbf{W}^{(l-1)} + \mathbf{b}^{(l-1)}) \end{aligned} \quad (3)$$

と構成される. ここで, \mathbf{g} は配置関数操作, $\{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(l)}$ は 1 層から l 層までのニューラルネットワークで用いるパラメータの集合を意味する. このような操作を反復することにより, 最終層である L 層の出力を多層ニューラルネットワーク

$$\begin{aligned} \mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e) &= \mathbf{h}^{(L)}(\boldsymbol{\delta}; \{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(L-1)}) \\ &= \mathbf{g}(\mathbf{h}^{(L-1)}(\boldsymbol{\delta}; \{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(L-2)})\mathbf{W}^{(L-1)} + \mathbf{b}^{(L-1)}) \end{aligned} \quad (4)$$

を用いて表現する. ただし, $\boldsymbol{\theta}_e = \{\boldsymbol{\theta}^{(l')}\}_{l'=1}^{(L)}$ である. 出力 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ を入力 $\boldsymbol{\delta}$ の情報を圧縮して構築された符号と呼び, 再帰的に符号化するニューラルネットワーク全体をエンコーダーと呼ぶ.

つぎに、以上で得られた多層ニューラルネットワークを出力 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ に関して折り返す。このことを概念的に説明するために、式 (1) で表される単層ニューラルネットワークを出力層で折り返せば、入力層と出力層に同数のユニットをもつ 2 層のニューラルネットワークとなる。出力 $\hat{\boldsymbol{\delta}} = \{\hat{\delta}_1, \dots, \hat{\delta}_I\}^T$ は、

$$\hat{\boldsymbol{\delta}}(\boldsymbol{\delta}; \boldsymbol{\theta}, \tilde{\boldsymbol{\theta}}) = \tilde{\mathbf{g}}(\mathbf{h}(\boldsymbol{\delta}; \boldsymbol{\theta})\tilde{\mathbf{W}} + \tilde{\mathbf{b}}) \quad (5)$$

で表される。ただし、出力 $\hat{\boldsymbol{\delta}}$ は $I \times 3$ 次元行列であり、 $\hat{\delta}_i = (\hat{x}_i, \hat{y}_i, \hat{z}_i)(i = 1, \dots, I)$ は 3 次元行ベクトルである。記号 $\tilde{\cdot}$ は折り返したニューラルネットであることを表しており、 $\tilde{\boldsymbol{\theta}} = \{\tilde{\mathbf{W}}, \tilde{\mathbf{b}}\}$ はパラメータベクトルであり、 $\tilde{\mathbf{W}}$ は重み行列、 $\tilde{\mathbf{b}}$ はバイアス行列である。また、 $\tilde{\mathbf{g}}$ は $\mathbf{h}\tilde{\mathbf{W}} + \tilde{\mathbf{b}}$ を引数とする配置関数操作である。以上の議論を拡張し、エンコーダーを反転させた L 層の折り返しニューラルネットワークを定式化する。符号 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ を起点 (L 層と呼ぶ) とし、エンコーダーとは逆向きに層の番号づけを行う。折り返しニューラルネットワークの $l(l = 2 \dots, L)$ 層の $I \times \tilde{H}^{(l-1)}$ 次元出力行列 $\tilde{\mathbf{h}}^{(l-1)}(\mathbf{h}_e; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l}^{(L)})$ は再帰的に

$$\begin{aligned} & \tilde{\mathbf{h}}^{(l-1)}(\mathbf{h}_e; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l}^{(L)}) \\ &= \tilde{\mathbf{g}}(\tilde{\mathbf{h}}^{(l)}(\mathbf{h}_e; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l+1}^{(L)})\tilde{\mathbf{W}}^{(l)} + \tilde{\mathbf{b}}^{(l)}) \end{aligned} \quad (6)$$

と構成される。ただし、 $\mathbf{h}_e = \mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ 、 $\tilde{\mathbf{W}}^{(l)}$ は $\tilde{H}^{(l)} \times \tilde{H}^{(l-1)}$ 次元重み行列、 $\tilde{\mathbf{b}}^{(l)}$ は $I \times \tilde{H}^{(l)}$ 次元バイアス行列、 $\{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l}^{(L)}$ は L 層から l 層までの折り返しニューラルネットワークで用いるパラメータの集合を意味する。また、 $\tilde{\mathbf{g}}$ は配置関数操作であり、活性化関数 $\tilde{\mathbf{g}}(\cdot)$ として、式 (2) に示す正規化線形関数 $\text{ReLU}(\cdot)$ を用いる。式 (6) に示す反復操作を繰り返して、2 層の折り返しニューラルネットワークの出力 $\tilde{\mathbf{h}}^{(2)}(\mathbf{h}_e; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=3}^{(L)})$ を用いれば、最終層である 1 層の出力を次式のように表現できる。

$$\begin{aligned} & \tilde{\mathbf{h}}^{(1)}(\mathbf{h}_e; \tilde{\boldsymbol{\theta}}_d) \\ &= \tilde{\mathbf{h}}^{(2)}(\mathbf{h}_e; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=3}^{(L)})\tilde{\mathbf{W}}^{(2)} + \tilde{\mathbf{b}}^{(2)} \end{aligned} \quad (7)$$

ただし、 $\tilde{\boldsymbol{\theta}}_d$ は折り返した多層ニューラルネットワークのパラメータベクトルであり、 $\tilde{\mathbf{W}}^{(2)}$ は $\tilde{H}^{(2)} \times 3$ 次元重み行列、 $\tilde{\mathbf{b}}^{(2)}$ は $I \times 3$ 次元バイアス行列である。2 層のバイアス行列 $\tilde{\mathbf{b}}^{(2)}$ は出力行列の各要素を並行移動させ、法枠点群データセットの中心を法枠の局所座標の原点に一致させる役割を果たす。折り返しネットワーク全体をデコーダーと呼ぶ。Auto Encoder 全体はエンコーダーとデコーダーを合成することにより、 $\boldsymbol{\delta}$ を入力とし $\hat{\boldsymbol{\delta}}(\mathbf{h}_e; \tilde{\boldsymbol{\theta}}_d)$ を出力するニューラルネットワーク

$$\hat{\boldsymbol{\delta}}(\boldsymbol{\delta}; \boldsymbol{\theta}_e, \tilde{\boldsymbol{\theta}}_d) = \tilde{\mathbf{h}}^{(1)}(\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e); \tilde{\boldsymbol{\theta}}_d) \quad (8)$$

として表現できる。

従来の点群に対する深層学習技術では、点群をボクセル（複数点群を一纏まりにしたもの）に変換し、3次元畳み込みニューラルネットワークに入力する手法が研究されていた^{22, 23)}。しかし、点群をボクセルに変換する際に点群個々の位置情報が失われたり、点群の空間特性が必然的に変化するため物体の凹凸表現が失われたりする問題点があった。このような問題点を踏まえ、点群を他の形式に変換せず、点のまま入力する手法の研究が試みられた。そのような手法を実現するためには、座標データの順序を入れ替えても座標データが示す点群の形状は同じであるという点群データ特有の順不変性（Permutation Invariance）の条件を満足する必要がある。前節で定式化した Auto Encoder モデルの順不変性を考慮するために、1) 一定の規則に従い座標データをソートし直す方法、2) データ拡張により座標データの順序付けに影響を受けにくいモデルを作成する方法、3) 対称関数とよばれる座標データの順序を入れ替えても値が不変な関数を学習する方法などが存在する。これらのうち、1) の方法は高次元空間での並び替えという膨大な作業が発生する。また、2) では座標データが N 個ある場合の順列は $N!$ であるため、学習に用いるデータの数が増加してしまう。3) における対称関数は入力変数の置換に対して出力結果に影響を受けない関数を用いる方法である。このような対象関数を用いた PointNet²⁴⁾ に関してもいくつか研究が蓄積されている。たとえば、PointNet++²⁵⁾ では、PointNet を階層的に適用することにより、PointNet が考慮していなかった点群各点の周辺情報に着目している。Xu 等²⁶⁾ は、点と点の距離や角度をもとに重みを算出し畳み込みを行う SpiderCNN を提案している。また、これらの点群に対する分類問題（点群データを入力し、そのデータが属するクラスを予測するタスク）に関する研究のほかに、3次元形状の生成に関する研究も行われている。Yang 等²⁷⁾ は、折りたたみをニューラルネットワークでモデル化し、点群を生成するモデルを提案している。Dai 等²⁸⁾ は、Attention 機構などを用いて人間の複雑な形状を生成するネットワークを提案している。Zhang 等²⁹⁾ は、点群をアップサンプリングして出力する生成ネットワークを提案している。本研究では、伝統的な PointNet の考え方を導入した Auto Encoder モデルを提案する。

いま、式 (4) に示すエンコーダーを用いて最深層である L 層の特徴量を表す出力行列 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ が得られたと考える。出力行列を具体的に

$$\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e) = \begin{pmatrix} h_1^{1(L)} & h_1^{2(L)} & \dots & h_1^{H^{(1)}(L)} \\ \vdots & \vdots & \ddots & \vdots \\ h_i^{1(L)} & h_i^{2(L)} & \dots & h_i^{H^{(L)}(L)} \\ \vdots & \vdots & \ddots & \vdots \\ h_I^{1(L)} & h_I^{2(L)} & \dots & h_I^{H^{(L)}(L)} \end{pmatrix} \quad (9)$$

と表そう。ここで、出力行列 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ に対して対称関数の性質を持つ Global Max Pooling

GMP($\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$) を適用する。Global Max Pooling を

$$\text{GMP}(\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)) = \left[\max\{h_1^{1(L)}, \dots, h_I^{1(L)}\}, \dots, \max\{h_1^{H^{(L)}(L)}, \dots, h_I^{H^{(L)}(L)}\} \right] \quad (10)$$

と定義する。すなわち、Global Max Pooling は $H^{(L)}$ 個の列ベクトル $\mathbf{h}^{k(L)} = (h_1^{k(L)}, \dots, h_I^{k(L)}) (k = 1, \dots, H^{(L)})$ に含まれる I 個の要素の中で最大値を取得する操作である。すなわち、PointNet における処理は、 L 層のエンコーダーにより点ごとに独立に特徴群を抽出した後、特徴群を構成するそれぞれの特徴から Global Max Pooling により情報集約を行う。すなわち、PointAutoEncoder を用いて、エンコーダーによる特徴量の集約（以下、集約特徴量）は

$$\boldsymbol{\omega}(\boldsymbol{\delta}; \boldsymbol{\theta}_e) = \text{GMP}(\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)) \quad (11)$$

と定義できる。以上のプロセスにおいて、エンコーダーは点ごとに独立した特徴抽出を行うためデータ入力の順序に依存しない。また、Global Max Pooling によるデータ集約操作も入力データの順序によらないため、PointAutoEncoder により集約された特徴ベクトル $\boldsymbol{\omega}(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ はデータ入力の順序に依存せず、順不変性の条件を満足する。Zaheer 等³¹⁾ は、関数が順不変性をもつことと上記のような分解ができることが同値な条件であることを数学的に証明している。

式 (11) に示すように、PointAutoEncoder モデルでは、モデルの順不変性の条件を確保するために Global Max Pooling 操作により Auto Encoder モデルの出力行列 $\mathbf{h}_e(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ の情報を集約特徴量 $\boldsymbol{\omega}(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ に集約化した。それに伴って、Auto Encoder モデルのデコーダーで利用する重み行列とバイアスベクトルの次元を修正することが必要となる。デコーダーの入力情報 $\boldsymbol{\omega}(\boldsymbol{\delta}; \boldsymbol{\theta}_e)$ が $1 \times H^{(L)}$ 次元の行ベクトルで表現されることに着目する。式 (6) と同様に、PointAutoEncoder の折り返しニューラルネットワークは再帰的に

$$\begin{aligned} & \tilde{\mathbf{h}}^{(l-1)}(\boldsymbol{\omega}; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l}^{(L)}) \\ &= \tilde{g}(\tilde{\mathbf{h}}^{(l)}(\boldsymbol{\omega}; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l+1}^{(L)})) \tilde{\mathbf{W}}^{(l)} + \tilde{\mathbf{b}}^{(l)} \end{aligned} \quad (12)$$

と構成される。 $\tilde{\mathbf{h}}^{(l-1)}(\boldsymbol{\omega}; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=l}^{(L)}) (l = 3, \dots, L)$ は層 $l-1$ の出力であり $1 \times \tilde{H}^{(l-1)}$ 次元行ベクトルで表される。また、 $\tilde{\mathbf{W}}^{(l)}$ は $\tilde{H}^{(l)} \times \tilde{H}^{(l-1)}$ 次元重み行列、 $\tilde{\mathbf{b}}^{(l)}$ は $\tilde{H}^{(l)}$ 次元バイアスベクトルである。Auto Encoder モデルと同様に折り返しニューラルネットワークの L 層から 3 層までの活性化関数 \tilde{g} として、式 (2) に示す正規化線形関数 $\text{ReLU}(\cdot)$ を用いる。2 層において恒等変換を用いる。このとき、

$$\begin{aligned} & \tilde{\mathbf{h}}^{(1)}(\boldsymbol{\omega}; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=2}^{(L)}) \\ &= \tilde{\mathbf{h}}^{(2)}(\boldsymbol{\omega}; \{\tilde{\boldsymbol{\theta}}^{(l')}\}_{l'=3}^{(L)}) \tilde{\mathbf{W}}^{(2)} + \tilde{\mathbf{b}}^{(2)} \end{aligned} \quad (13)$$

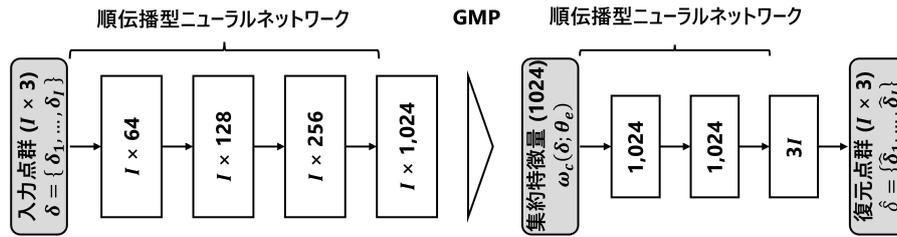


図-11 PointAutoEncoder の層別構造

さらに、PointAutoEncoder 全体は式 (4) に示すエンコーダー、式 (11) に示す Global Max Pooling、式 (13) に示すデコーダーを直列に合成することにより

$$\hat{\delta}(\delta; \theta_e, \tilde{\theta}_d) = \tilde{h}^{(1)}(\omega(\delta, \theta_e); \{\tilde{\theta}^{(l')}\}_{l'=2}^{(L)}) \quad (14)$$

表現できる。なお、図-11 に、使用した PointAutoEncoder モデルの層別構造 (各層の出力行列の次元数の変化) を示している。

付録 3 : ICP の詳細

ICP(Iterative Closest Point)²⁰⁾ は、並進と回転という剛体変換を繰り返すことにより二つの点群の位置合わせを行うターゲットレスな手法である。以下、本手法について数学的な定式化を行う。

ICP のアルゴリズムは、1. 初期化、2. Matching Step、3. Transformation step、4. 収束判定という段階で構成される。点群 $P_S = \{\mathbf{p}_i\}_{i=1}^n \subset \mathbb{R}^3$ に対し剛体変換を施して、点群 $P_T = \{\mathbf{q}_i\}_{i=1}^n \subset \mathbb{R}^3$ に位置合わせを行う状況を考える。

はじめに、並進に用いるベクトルを \mathbf{t} 、回転に用いる行列を \mathbf{R} として、それぞれを $\mathbf{t} = \mathbf{0}$ 、 $\mathbf{R} = \mathbf{O}$ と初期化する。

次に、Matching Step においては、図-12 に示すように、 \mathbf{R} 、 \mathbf{t} を与件として、任意の $\mathbf{p}_i \in P_S$ に対して、最近傍な $\mathbf{q}_i \in C$ を求める。最近傍点の探索において、とりわけ斜面点群データのような膨大な点群では、全探索を行うと計算量が発散してしまう。したがって一般に、ボロノイ分割による手法や kd 木による手法が用いられる。

ボロノイ分割とは、隣り合う点間を結ぶ直線に垂直二等分線を引き、各点の最近傍領域を分割する手法である。ボロノイ分割による手法では、 P_T のボロノイ分割を作成し、各 $\mathbf{p}_i \in P_S$ に対してボロノイ分割上のどこに対応させるかを探索する。

kd 木とは、 k 次元ユークリッド空間における点集合を座標軸に垂直な超平面を用いて分割する手法である。kd 木による手法では、 P_T の kd 木を作成し、kd 木を用いて各 $\mathbf{p}_i \in P_S$ の最近傍点を探索する。図-13 に 2 次元ユークリッド空間における例を示している。図-13

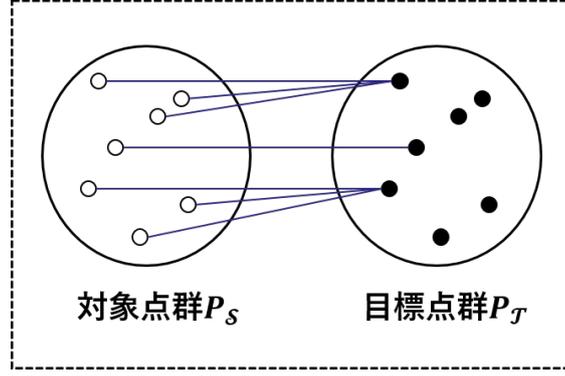


図-12 Matching Step

に示すように、はじめに分散の大きい軸に対し垂直に分割するための閾値を設定し、これを分割された各ノードで繰り返し行うことによって二分木を構築する。その後、構築した二分木を用いて、対象となる点を含む領域を探索し、内部の各点との距離を計算する。最後に、隣接領域でより近傍となる点が存在しないことを確認し、最近傍点の探索を終了する。

本研究では、ボロノイ分割による手法は一般により多くの計算時間を要するということから、kd木による手法を用いることとする。

次に、Transformation Stepにおいて、どのように各点を剛体変換すればよいかを考える。Transformation Stepでは、任意の $p_i \in P_S$ に対して最近傍な点 $q_i \in P_T$ が求まったとして、最適化問題

$$\hat{R}, \hat{t} = \arg \min_{R \in SO(3), t \in \mathbb{R}^3} \sum_{i=1}^n \|R p_i + t - q_i\|^2 \quad (15)$$

を解くことが目的となる。ここで、 $SO(3)$ は3次元特殊直交群（回転群）である。この問題は以下のように解くことができる。はじめに、各点群に対して重心が原点になるよう $\bar{p} = \sum_{i=1}^n p_i$, $\bar{q} = \sum_{i=1}^n q_i$ を用いて、

$$p'_i = p_i - \bar{p} \quad (16)$$

$$q'_i = q_i - \bar{q} \quad (17)$$

なる補正を行う。続いて、目的関数を $J = \sum_{i=1}^n \|R p_i + t - q_i\|^2$ として、

$$J = \sum_{i=1}^n \|R(p'_i + \bar{p}) + t - (q'_i + \bar{q})\|^2 \quad (18)$$

$$= \sum_{i=1}^n \|R p'_i - q'_i + (R \bar{p} - \bar{q} + t)\|^2 \quad (19)$$

と変形できる。このことから、 J を最小化するためには、 $\hat{t} = -R \bar{p} + \bar{q}$ と定めればよく、このとき目的関数は $J = \sum_{i=1}^n \|R p'_i - q'_i\|^2$ となる。これにより、先に R を推定すること

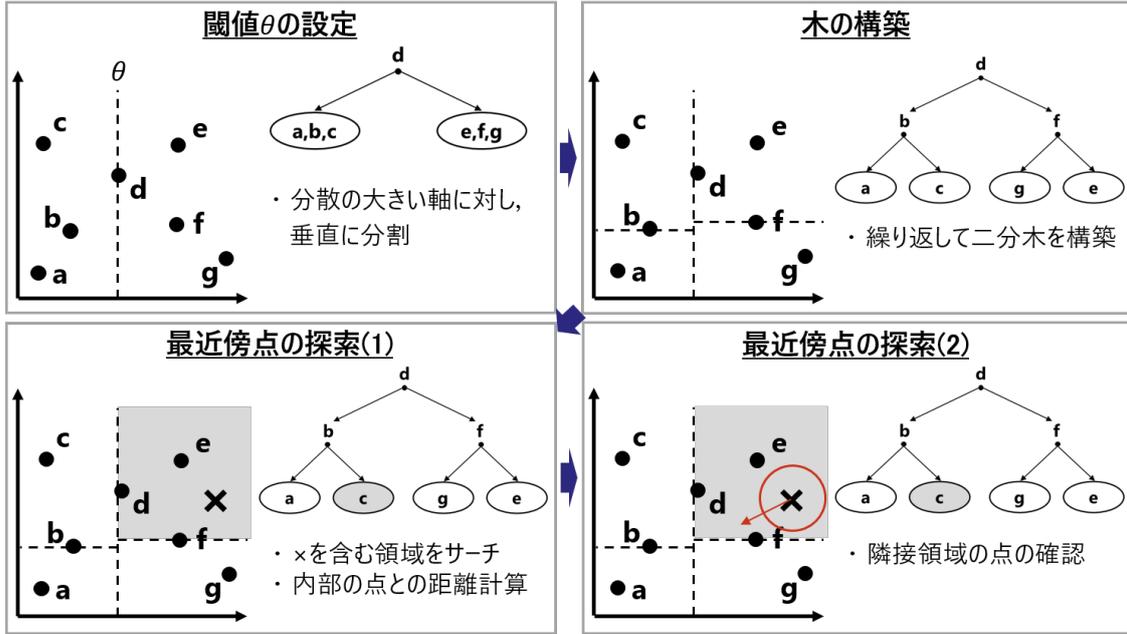


図-13 kd 木による最近傍点の探索

によって t を求めることが可能となるため、 R の推定問題に帰着される。 R の推定には、ラグランジュの未定乗数法による方法、四元数による方法、特異値分解による方法などが考案されている。本研究では、特異値分解による方法を用いることとした。以下、 R の推定方法に関して説明する。 R を決定するために、さらに目的関数を

$$J = \sum_{i=1}^n \|R\mathbf{p}'_i - \mathbf{q}'_i\|^2 \quad (20)$$

$$= \sum_{i=1}^n \|\mathbf{p}'_i\|^2 - 2\text{Tr} \left[R \sum_{i=1}^n \mathbf{p}'_i \mathbf{q}'_i{}^\top \right] + \sum_{i=1}^n \|\mathbf{q}'_i\|^2 \quad (21)$$

と変形する。ここで、 $R \in SO(3)$ は直交行列なので $R^\top R = I$ となることと、一般に二次形式について $\mathbf{x}^\top A \mathbf{x} = \text{Tr}[A \mathbf{x} \mathbf{x}^\top]$ となることを用いた。 I は単位行列である。これにより、式(21)において、第一項、第三項は R によらず定まるため、第二項の $\text{Tr}[R \sum_{i=1}^n \mathbf{p}'_i \mathbf{q}'_i{}^\top]$ を最大化するように R を定めればよい。ここで、 $\sum_{i=1}^n \mathbf{p}'_i \mathbf{q}'_i{}^\top$ を特異値分解することにより、

$$\sum_{i=1}^n \mathbf{p}'_i \mathbf{q}'_i{}^\top = U \Sigma V^\top \quad (22)$$

と表されたとする。ここで、 U, V は直交行列であり、 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \sigma_3)$ ($\sigma_1 \geq \sigma_2 \geq \sigma_3 \geq 0$) である。すると、 $R = VU^\top$ と定めれば、

$$R \sum_{i=1}^n \mathbf{p}'_i \mathbf{q}'_i{}^\top = VU^\top (U \Sigma V^\top) \quad (23)$$

$$= V \Sigma V^\top \quad (24)$$

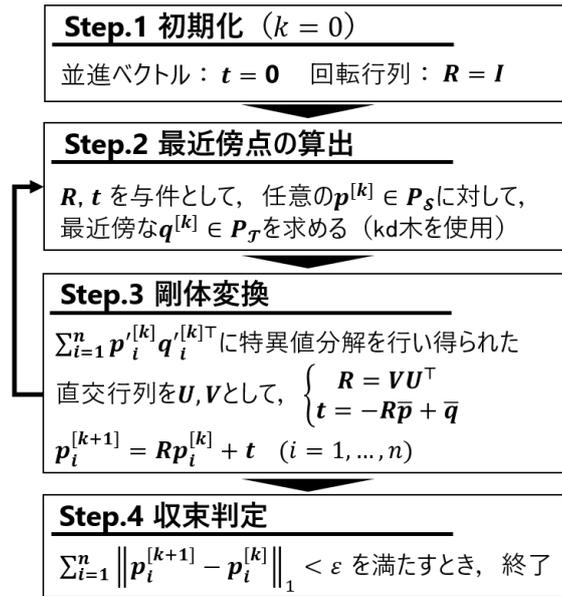


図-14 ICP のアルゴリズム

となり、 Σ が正定値であることから、 $R \sum_{i=1}^n p_i' q_i'^T$ は正定値である。一般に、正定値対称行列 AA^T 、直交行列 B に対し、

$$\text{Tr}[AA^T] \geq \text{Tr}[BAA^T] \quad (25)$$

となるのが簡単な計算からわかるため、正定値対称行列 $R \sum_{i=1}^n p_i' q_i'^T$ と任意の直交行列 B にこれを適用すれば、

$$\text{Tr} \left[R \sum_{i=1}^n p_i' q_i'^T \right] \geq \text{Tr} \left[B R \sum_{i=1}^n p_i' q_i'^T \right] \quad (26)$$

となり、任意の直交行列のうち R が $\text{Tr}[R \sum_{i=1}^n p_i' q_i'^T]$ を最大化することがわかる。したがって、 $\hat{R} = VU^T$ と定めればよい。

収束判定は、 k ステップ目の各点 p_i を $p_i^{[k]}$ としたとき、

$$\sum_{i=1}^n \left\| p_i^{[k+1]} - p_i^{[k]} \right\|_1 < \varepsilon \quad (27)$$

などにより行う。ここで、 $\|\cdot\|_1$ は $L1$ ノルムである。

以上の説明を図-14 にまとめる。

参考文献

- 1) 国土地理院：航空レーザ測量入門，2004.
- 2) 国土交通省：三次元点群データを活用した道路斜面災害リスク箇所の抽出要領，2021.
- 3) 国土地理院：三次元点群データを使用した断面図作成マニュアル（案），2019.
- 4) 国土交通省：3次元計測技術を用いた出来形管理要領（案） 法面工編，2021.
- 5) 財団法人道路保全技術センター：防災カルテ作成・運用要領，1996.
- 6) 財団法人道路保全技術センター：平成8年度道路防災総点検要領（豪雨・豪雪等），1996.
- 7) 財団法人道路保全技術センター：道路防災点検の手引き（豪雨・豪雪等），2007.
- 8) 国土交通省道路局：総点検実施要領（案）【道路のり面工・土工構造物編】，2013.
- 9) 国土交通省道路局：道路土工構造物点検要領，2017.
- 10) 国土交通省道路局国道・技術課：道路土工構造物点検要領，2018.
- 11) 東京大学，基礎地盤コンサルタンツ株式会社：合成開口レーダー（SAR）の道路土工構造物の維持管理への活用マニュアル（案），2021.
- 12) 国土交通省道路局：点検要領，2006.
- 13) 久保和幸，谷川征嗣，榎本忠夫：盛土・切土・軟弱地盤対策工・自然斜面对策工のリスクマネジメント手法に関する調査研究，国総研資料第1006号，平成28年度道路調査費等年度報告，pp.107-110，2018.
- 14) 国土地理院：移動計測車両による測量システムを用いる数値地形図データ作成マニュアル（案），2012.
- 15) 国土地理院：地上レーザスキャナを用いた公共測量マニュアル（案），2017.
- 16) 清水功，秦野輝儀，津田延裕，星野慎司，加藤卓也：無巻トンネル地質リスク調査へのハンドヘルドレーザ計測の適用事例について，応用地質，Vol.58，No.6，pp.395-401，2018.

- 17) 田中成典, 辻光宏, 伊藤俊秀, 窪田諭, 今井龍一, 中村健二: レーザスキャナと UAV 等の計測機器を用いた社会基盤施設の 3 次元データの計測と活用に関する研究, 情報処理学会研究報告, Vol.2017-IS-142, No.3, 2017.
- 18) Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, pp.504-507, 2006.
- 19) 麻生英樹: 多層ニューラルネットワークによる深層表現の学習, 人工知能学会誌, Vol.28, No.4, pp.649-659, 2013.
- 20) P. J. Besl and N. D. McKay: A method for registration of 3-D shapes, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.14, No.2, pp.239-256, 1992.
- 21) 岡谷貴之: 深層学習 改訂第 2 版, 講談社, 2022. [Okatani, T.: Deep Learning 2nd Edition, Kodansya, 2022.]
- 22) Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X. and Xiao, J.: 3D ShapeNets: A Deep Representation for Volumetric Shapes, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1912-1920, 2015.
- 23) Maturana, D. and Scherer, S.: VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition, *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2015.
- 24) Qi, C. R., Su, H., Mo, K. and Guibas, L. J.: PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, *Computer Vision and Pattern Recognition*, pp.652-660, 2017.
- 25) Qi, C. R., Yi, L., Su, H. and Guibas, L. J.: PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, *Advances in Neural Information Processing Systems*, pp.5105-5114, 2017.
- 26) Xu, Y., Fan, T., Xu, M., Zeng, L. and Qiao, Y.: SpiderCNN: Deep Learning on Point Sets with Parameterized Convolutional Filters, *Proceedings of the European Conference on Computer Vision(ECCV)*, 2018.
- 27) Yang, Y., Feng, C., Shen, Y. and Tian, D.: FoldingNet: Point Cloud Auto-encoder via Deep Grid Deformation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2018.
- 28) Dai, H. and Shao, L.: PointAE: Auto-encoder for 3D Statistical Shape and Texture Modelling, *International Conference on Computer Vision*, pp.5410-5419, 2019.

- 29) Zhang, W., Jiang, H., Yang, Z., Yamakawa, S., Shimada, K. and Kara, L. B. : Data-driven Upsampling of Point Clouds, *arXiv preprint arXiv:1807.02740*, 2018.
- 30) Fan, H., Su, H. and Guibas, L.: A Point Set Generation Network for 3D Object Reconstruction from a Single Image, *arXiv preprint arXiv:1612.00603*, 2016.
- 31) Zaheer, M., Kottur, S., Ravanbakhsh, S., Poczos, B., Salakhutdinov, R. and Smola, A.: Deep Sets, *Proceedings of the NIPS 2017*, pp.3391-3401, 2017.