



3次元点群データを用いた坑道壁面における不連続面の自動推定に関する研究

メタデータ	言語: jpn 出版者: 公開日: 2018-06-06 キーワード (Ja): キーワード (En): 作成者: 松川, 瞬 メールアドレス: 所属:
URL	https://doi.org/10.15118/00009637

3次元点群データを用いた坑道壁面に
おける不連続面の自動推定に関する研究

博士学位論文

松川 瞬

室蘭工業大学大学院 工学専攻
先端環境創成工学系コース

平成 29 年度

目次

第1章	序論.....	3
1.1	研究背景	3
1.1.1	高レベル放射性廃棄物の地層処分について	3
1.1.2	坑道周辺岩盤の力学的安定性・水理特性の評価について.....	6
1.1.3	不連続面について.....	8
1.1.4	地質観察手法.....	8
1.2	研究課題と目的	13
1.3	本論文の構成.....	14
1.4	参考文献.....	16
第2章	点群データを用いた不連続面取得について	18
2.1	3D レーザースキャナについて	18
2.1.1	3D レーザースキャナの仕様.....	18
2.1.2	3D レーザースキャナの用途.....	20
2.2	先行研究	22
2.2.1	手動での不連続面取得手法	22
2.2.2	半自動での不連続面取得手法	27
2.3	実用面での課題	30
2.3.1	標準化と省力化への寄与.....	30
2.3.2	DiAna の課題	30
2.4	参考文献.....	32
第3章	Variable-Box Segmentation による面の推定について	34
3.1	概要.....	34
3.2	前処理.....	35
3.2.1	前処理の必要性	35
3.2.2	前処理の手順.....	35
3.3	アルゴリズム詳細.....	39
3.3.1	大格子分割プロセス	39
3.3.2	小格子分割プロセス	40
3.3.3	結合プロセス.....	43
3.4	VBS による面の推定実験.....	44
3.4.1	実験内容と手順	44
3.4.2	実験条件	69
3.4.3	実験結果.....	70

3.4.4	結論	79
3.5	参考文献.....	80
第4章	推定された面からの不連続面の判別について	81
4.1	概要.....	81
4.2	推定された面からの不連続面の判別	82
4.2.1	表面粗さについて	82
4.2.2	利用する表面粗さの検討	85
4.3	掘削面・不連続面の判別実験	89
4.3.1	実験内容	89
4.3.1.2	実験手順	92
4.3	実験結果と結論	94
4.4	参考文献.....	96
第5章	畳み込みニューラルネットワークによる特徴抽出と識別	98
5.1	畳み込みニューラルネットワークについて.....	98
5.2	実験.....	100
5.2.1	実験内容	100
5.2.2	実験結果.....	107
5.2.3	結論	109
5.3	参考文献.....	110
第6章	総論.....	111
謝辞		113


第1章 序論

1.1 研究背景

1.1.1 高レベル放射性廃棄物の地層処分について

原子力発電は、既に日本での総発電電力量の3分の1を超える電力を供給し、エネルギー自給率の向上および安定供給に貢献している（NUMO, 2004）。日本では、より一層長期にわたって安定的にエネルギーを供給するため、原子力発電に使用した燃料（使用済燃料）について、有用な資源であるウラン、プルトニウムを分離・回収（再処理）し、再び燃料として利用する「核燃料サイクル」を原子力政策の基本方針としている（NUMO, 2004）。図 1.1.1-1 はそのサイクルを表している。採鉱されたウラン鉱石は製錬・加工され燃料として軽水炉や高速増殖炉に用いられる。その後、各再処理施設にて再処理され、再度燃料として用いられる。

しかし、使用済燃料の再処理の際は廃棄物も発生する。発生する廃棄物の中には、放射能を有するものも存在し、それらは放射性廃棄物と呼ばれる。その中でも、放射能レベルの高いものを高レベル放射性廃棄物と呼ぶ（NUMO, 2004）。高レベル放射性廃棄物は、図 1.1.1-1 のように、高速増殖炉燃料の再処理・軽水炉の運転に伴い発生した使用済燃料の再処理により発生する。高レベル放射性廃棄物は使用済燃料からウラン・プルトニウム等を分離・回収した後の廃液で、取り扱いやすく安定した形態にするため、ガラス固化した形態で保存・処分される（NUMO, 2004）。図 1.1.1-2 はガラス固化体の全体図で、ガラス固化した廃液をステンレス製の容器（キャニスタ）で包んでいる。しかし、製造直後のガラス固化体の放射線量は約 1,500Sv/h で（JNC, 2003）、国際放射線防護委員会（ICRP）の勧告の中で100%の人が死亡するとされている放射線量である約 7Sv をわずか 20 秒弱で浴びる量である。この放射線量が、ウランが本来有しているレベルと同程度まで低下するのは、図 1.1.1-3 に示されるよう数万年掛かる。そのため、長期間にわたり、放射性物質を人間の生活環境から安全に隔離する処分方法が必要である（JNC, 1999）。



1.1.1-1 NUMO による核燃料サイクルの概念図（NUMO, 2004 より転載）



図 1.1.1-2 ガラス固化体の全体図 (経済産業省資源エネルギー庁ホームページより転載)




図 1.1.1-3 ガラス固化体の放射能の経時変化
(経済産業省資源エネルギー庁ホームページより転載)

日本では2000年に「特定放射性廃棄物の最終処分に関する法律」が制定され、高レベル放射性廃棄物を深部の地層中へ隔離し、人間環境に影響が無いよう処分する地層処分にて廃棄物を処分する様に定められる（JAEA, 1999）と同時に、原子力発電環境整備機構（Nuclear Waste Management Organization of Japan, 以下：NUMO）が設立された。図1.1.1-4は地層処分の概念図で、ガラス固化体をオーバーパックと呼ばれる人口バリアで包み、さらにベントナイトを主成分とする緩衝剤で周囲を固めた後、安定した地質環境を持つ地層深くに埋めることを示す。地層処分には、長期にわたる安全性を評価できること・自国の領土内で実現可能であること・人間の継続的な関与なし長期的な安全が確保でき、監視やモニタリングを必要しないことと言った利点が存在し、実現に向けて各国で努力が続けられている（OECD/NEA, 1999）。しかし、処分技術の知識基盤として、特に地上から地下深部の地質環境を体系的に調査・評価するための技術基盤が必要となる。




図 1.1.1-4 地層処分の概念図（JAEA, 1999 より転載）

1.1.2 坑道周辺岩盤の力学的安定性・水理特性の評価について

地下深部では地圧が作用しており、処分場の建設において坑道等を掘削することで、岩盤の強度と地圧のバランスにより坑道等の周囲には掘削影響領域が発生する。この掘削影響領域における岩盤の変化は、放射性核種の移行挙動にも影響すると考えられることから、その領域や経時変化の把握が重要となっている（青柳ほか，2017）。日本において、放射性核種は一般に地下水と接触する事により溶出し輸送されるメカニズムが最も実現性が高く、処分場付近の地下水流動の影響に関する調査が処分の安全性を評価するうえで最も重要である（JNC，1989; JNC，2004）。

地下水流動の解析は、主に水理モデルを作成し、モデルを通して行われる（JNC，1989）。一般に地下水流動解析では差分法，有限体積法，有限要素法といった離散化解析手法が用いられているが（菱谷ほか，2015），坑道周辺の岩盤が亀裂性媒体である場合，水理モデルには割れ目ネットワーク（Discrete Fracture Network：以下 DFN）モデルといった割れ目系モデルが想定される。割れ目ネットワークモデルは，岩盤内の複雑な亀裂構造を確率論的にモデル化して，岩盤構造物の力学的安定性や岩盤の透水性を評価する（井尻ほか，2001）。

DFN モデルの構築にあたっては，岩盤内の割れ目から割れ目特性データを算出する必要がある（大津ほか，2006; 鈴木ほか，2009; 井尻ほか，2001）。割れ目特性データはそれぞれ，

a) 方向分布

割れ目の卓越方向（走向，1.1.4 に詳細）の分布を表す。割れ目ネットワークモデルでは，割れ目はモデル化領域の側面方向（NS および EW 方向）に平行に卓越するとし，それらの方向からの偏向角と方位角の分布を近似する分布を採用する。例としては，Fisher 分布や Bingham 分布がある。

b) 形状

割れ目の形状を表す。Dershowits らにより割れ目形状が多角形であることが指摘されているため（Dershowitz and Einstein，1985），既往の研究では割れ目を多角形でモデル化している場合が多い。割れ目ネットワークモデルでは，c)の割れ目半径分布で表される円盤と等価な面積を有する 6 角形で近似される。

c) 半径分布

Kulatilake らによる割れ目サイズの分布の解析では，割れ目の形状は円盤であると仮定されている（Kulatilake and Wu，1984）。その円盤の半径の分布である。二次元平面状の割れ目のトレース長がべき乗分布に従う場合，三次元空間状の割れ目の半径分布もべき乗分布に従う。

d) 頻度分布

三次元割れ目密度（単位体積あたりの割れ目面積）を表す。

e) 空間分布

一般にせん断破壊により生じた比較的規模の大きな割れ目の周辺には小規模な割れ目が密集することが知られているが、その割れ目の分布を表す。既往のモデル化研究においては、割れ目の中心位置の分布がポアソン過程に基づく Beacher モデルが用いられている（鈴木ほか，2009）。

f) 透水量係数・開口幅

割れ目に関する物性値である。

である（井尻ほか，2001；大津ほか，2006；重野，2003）。割れ目ネットワークモデルの一例を図 1.1.2-1 に示す。これは大津らにより生成された DFN モデルであり，方向分布に確率密度関数

$$f(\theta', \varphi') = C^{-1} \sin \varphi' \exp\{(\kappa_1 \cos^2 \theta' + \kappa_2 \sin^2 \theta') \sin^2 \varphi'\} \quad \dots\dots\dots (1.1)$$

で表される Bingham 分布を，半径分布に

$$f(r) = \frac{b-1}{r_{min}} \left(\frac{r_{min}}{r}\right)^2 \quad \dots\dots\dots (1.2)$$

で表されるべき乗分布を用いている。ここで， θ' は割れ目の卓越方向からの偏向角， φ' は割れ目の卓越方向からの方位角， κ_1, κ_2 は Bingham 分布パラメータ， $C = \int_0^{2\pi} \int_0^\pi \sin \varphi' \exp\{(\kappa_1 \cos^2 \theta' + \kappa_2 \sin^2 \theta') \sin^2 \varphi'\} d\varphi' d\theta'$ ， r は割れ目の半径， r_{min} は最小亀裂半径， b はべき乗指数を表す。

従来，これらの割れ目特性データは，地質専門家による地質観察を含む地質調査により取得された，岩盤中の割れ目面（以下：不連続面）の観察データから算出される。




図 1.1.2-1 割れ目ネットワークモデルの一例（大津ほか，2006 より転載）

1.1.3 不連続面について

不連続面は、断層・節理・層理面など、岩盤の連続性を分割する割れ目面のことである（川越，2006）。割れ目は、地形の変動などによって起こる断層のように、外圧が加わり内部に引っ張り応力が発生し、原子結合が面上に切れることで発生する（蕪木・笹尾，2007）。割れ目面はその開口部に現れた面のことである。

割れ目の形や大きさは、応力（外圧）に依存しており、この割れ目の変位（種類）は、応力の掛かり方により、以下の3つの基本的な形式に分けられる（蕪木・笹尾，2007）。

モードI. 開口型

物体を上と下に引っ張ることで発生する（図1.1.3-1 左）。

モードII. 面内せん断型

物体を奥と手前に引っ張ることで発生する（図1.1.3-1 中）。

モードIII. 面外せん断型

物体を左と右に引っ張ることで発生する（図1.1.3-1 右）。

その他、それぞれの形式が組み合わさった割れ目も存在する。図1.1.3-1は各モードの概念図であり、矢印の方向に応力が加わった結果発生する。図の斜線部分が割れ目面であり、不連続面と呼ぶ。




図 1.1.3-1 割れ目の種類と割れ目面（不連続面）

1.1.4 地質観察手法

1.1.2 で述べたとおり、不連続面は地質専門家の地質観察により取得される。地質観察は、坑道壁面における割れ目の分布位置とトレース長を調査員による目視でのマッピングや写真撮影によって記録し、クリノメーターを使用して簡易的に割れ目方位を測定する手法（以下：従来手法）が今日でも一般的である（早野・板倉，2017）。

クリノメーターとは、図1.1.4-1に示すような傾斜計と水準器が組み込まれた方位磁石で、面の大まかな走向・傾斜を手動で測ることが可能である。走向は地層面と水平面との交線の方で、方位と組み合わせて表記する。図1.1.4-2は走向の一例を示しており、例えば北

を基準として 30° 東の方向にずれて交線が伸びている場合、N30° E の様に記す。傾斜は地層面と水平面とのなす角度を示し、走行に対して直角の向きである。走向と同様に方位と組み合わせて表記する。図 1.1.4-3 は傾斜の一例で、水平面から 50° 傾斜し、北を基準に東側へ傾いている場合、50° SE の様に記す。割れ目面は、この走向・傾斜を用いて記録される。

クリノメーターによる観察手順は、

- 1) 地層面の平らな箇所に直接クリノメーターの長辺を当て、水準器により水平を保つようにする。この時の磁針が示す方位と角度を走向として記録する。
- 2) 走向を測定後、長辺が走向に垂直になるようにクリノメーターの向きを変える。この時の傾斜測定用の振り子が示す方位と角度を傾斜として記録する。

となる(天野・秋山, 2004)。以上の手順は直接岩盤に触れることが出来る場合であり、遠距離での計測の場合、遠くから見通してクリノメーターを傾けることで、平均的な走向・傾斜を得ることができる。(天野・秋山, 2004)

図 1.1.4-4 と図 1.1.4-5 は地質観察結果の一例で、日本原子力研究開発機構 (Japan Atomic Energy Agency : JAEA) による地質観察によって作成されたスケッチと割れ目詳細記載シートである (JAEA, 2012a)。図 1.1.4-4 中ピンクの図形が坑道の形状を表し、図形中に書かれた黒線が観察された不連続面を表す。そのうち、数字が振られている線が断層などの大きい不連続面で、赤い丸が記されている不連続面は、壁面に存在するパラメータを取得すべき主要な不連続面である。図 1.1.4-5 には、観察された不連続面の種類や走向・傾斜、割れ目の開口幅などが記録されている。この地質観察では、動力炉・核燃料開発事業団 (Power Reactor and Nuclear Fuel Development Corporation : PNC) によるスキャンライン法によって主要な不連続面を判別している。




図 1.1.4-1 クリノメーター (ロッククライミング調査協会より転載)




図 1.1.4-2 走向の例 (N30° E)





図 1.1.4-3 傾斜の例 (50° SE)



割れ目詳細記載シート																		
A工区 Step300A_55 : G.L.-297~-300.2m																		
番号	割れ目の種類	割れ目形態		条線の方向		変位 (cm) ・センス ・変位指標	面の方向		断層岩				割れ目の開口					
		主	副	角度	面の向き		走向・傾斜	節理方向	幅 (mm) スパン	最大	分布率 (%)	種類	幅 (mm) スパン	最大	開口率 (%)	形状	特徴	
1	I	P	a	-	-	-	N68E : 81S	左55 手前81	-	-	-	-	-	-	0	C	-	
2	I	P	a	-	-	-	N83E : 72N	左72 奥72	-	-	-	-	-	-	0	C	-	
3	I	P	a	-	-	-	N70E : 75S	左59 手前75	-	-	-	-	-	-	0	C	-	
4	I	P	a	-	-	-	N48E : 74S	左35 手前74	-	-	-	-	-	-	0	C	-	
5	I	P	a	-	-	-	N72E : 85S	左81 手前85	-	-	-	-	-	-	0	C	-	
6	I	C	a	-	-	-	N67E : 78S	左58 手前79	-	-	-	-	3	3	80	G	黄色グラウトを充填 認	
7	I	C	a	-	-	-	N43E : 83E	左32 手前83	-	-	-	-	0	2	20	L	黄色グラウトを充填 認	
8	I	C	a	-	-	-	N58E : 83S	左47 手前83	-	-	-	-	2	2	100	G	黄色グラウトを充填 認	
9	I	P	a	-	-	-	N67W : 63N	右78 奥63	-	-	-	-	0	2	30	L	黄色グラウトを充填 認	

図 1.1.4-4 割れ目詳細記載シート
(IAEA (2012a), 割れ目詳細記載シート_300m アクセス坑道_055(アクセス 055) より抜粋)

1.2 研究課題と目的

2000 年 10 月に策定された国の特定放射性廃棄物の最終処分に関する計画によれば、1999 年末以前の発電用原子炉の運転に伴って生じた使用済燃料の再処理によって生ずるガラス固化体は約 13,300 本と見込まれている。その後 2000 年～2009 年の間は年間約 1,100～1,400 本のガラス固化体に相当する使用済燃料が発生していき、2020 年頃までには、総量約 4 万本のガラス固化体に相当する使用済燃料が発生すると見込まれている (NUMO, 2004)。

40,000 本のガラス固化体を埋設できる処分場は、建設場所により大きく異なるが、総延長 200km 以上となることが想定されている (NUMO, 2004)。図 1.2-1 は結晶質岩、深度 1000 m の場合のレイアウトを示しており、この場合、約 3 km×2km の広さで、すべての坑道の総延長は約 270km になることが想定されている。

以上のように大規模な地下施設の建設に際しても、地下水流動の解析に供するため、膨大な回数据削した坑道の壁面それぞれに対して従来手法を実施し（以下：壁面観察）、坑道壁面に分布する不連続面を取得してモデルを構築することが考えられる。しかし、従来手法による地質観察は、1.1.4 に示すように、目視かつ手動で行われる。また、クリノメーターでの計測は、指針を読み取る時の指針の固定による誤読が起きる (天野・秋山, 2004)、また磁北からの偏角の補正が必要である (日本地質学会地質基準委員会, 2003) など、計測者の技量が求められる。すなわち、従来手法による地質観察を長期間かつ膨大な回数行われる坑道掘削に対して実施する場合、以下の課題が生じることが懸念される (早野・板倉, 2017)。




図 1.2-1 将来想定されている処分場のレイアウト例 (NUMO, 2009 より転載)

a) 建設コスト削減の観点から観察時間が短縮される場合、制限時間内に施設設計や解析評価の要求品質を満たすデータを取得できない

b) 観察毎に調査員が異なる場合、データの品質は調査員の経験や能力などに依存するため、データの品質にバラつきが生じる

c) 労働災害の防止の観点から調査員の露岩部分への立入が制限される場合、岩盤に接近した目視観察やクリノメーターを岩盤に当てた割れ目方位の測定ができないため、データ取得精度が低下する

以上の問題を解決するためには、壁面観察の省力化と、観察結果の品質の標準化が必要である。そのために昨今注目を集めているのが、3D レーザースキャナである。3D レーザースキャナは、スキャン対象の 1 点にレーザーパルスを発射し、反射されたレーザーパルスから対象の 1 点の座標を含めた情報を取得する。レーザーパルスを大量に発射することで、対象の表面形状を膨大な数の点で近似したデータ（以下：点群データ）を取得する。詳細は第 2 章で述べる。

しかし、3D レーザースキャナによる壁面観察作業の省力化と標準化は、未だ十分な研究が成されていない。そこで本研究では、地質観察作業における不連続面の取得作業を自動化し、壁面観察作業の省力化と標準化を試みる。

1.3 本論文の構成

本論文の構成は、以下のようなになる。まず、第 2 章で 3D レーザースキャナの詳細として、スキャンの機構や取得されたデータについて説明する。また、実際の適用例として、倉内らの工場内のスキャン例、古川らによる雪崩斜面の測定例、また岡本らによる広島市内の計測例について触れ、それぞれの事例から 3D レーザースキャナの特徴と利点について説明する。次に、その利点を地質観察に生かした先行研究について、2000 年代前半から行われてきた 3D レーザースキャナ活用の始まりから、坑道での詳細なデータの取得と活用例、そして日本での活用例について触れる。ここで、データ処理の自動化の状況についても説明し、従来の処理手法が未だ半自動の処理であることから、実用面で残る課題について考える。

第 3 章では、2 章で考察した課題を解決するために開発したアルゴリズム「Variable-Box Segmentation」（以下：VBS）について説明する。ここではまず、VBS アルゴリズムの概要を説明した後、本研究の対象とするデータに必要な前処理から、VBS のアルゴリズム詳細について触れる。また、6 節にて実際の点群データを VBS で処理して坑道壁面の表面形状を推定し、従来処理のアルゴリズムと比べてどの程度精度があるか、また自動化に寄与しているかを実験にて確認する。

第 4 章では VBS で推定した面から不連続面を判別する手法について検討する。地質専門

家による判別について考察し、それに則った判別基準として表面粗さを考える。ここでは本研究で利用する 4 つの表面粗さ、フラクタル次元・算術平均粗さ・最大高さ粗さ・Roughness-length について説明する。また、それらの表面粗さから不連続面を判別できるか、相関比とヒストグラムから調査し、独立した表面粗さからでは判別が難しいことを確認する。ここで、表面粗さを組み合わせた特徴ベクトルを用いて判別する手法について検討し、Support Vector Machine（以下：SVM）による判別を実験にて試みる。実験結果から、特徴ベクトルの次元の追加が必要であることを結論付ける。

第 5 章では、4 章で用いた 4 つの表面粗さの様な定量的な特徴量（ハンドクラフト特徴量）ではなく、Convolutional Neural Network（以下：CNN）を用いた自動的な特徴抽出について検討する。ここでは CNN の仕組みを説明し、実験に応用する。実験では 3D レーザースキャナで得られた点群データをレンジ画像データに変換する処理について説明し、変換した画像を CNN に入力して特徴を抽出した後、SVM で不連続面の判別を試みる。CNN で得られた特徴量で判別精度の増加を確認しつつ、今後の課題について検討する。

最後に、第 6 章で本論文の総論を述べる。

なお、本研究では瑞浪超深地層研究所・深度 300m 研究アクセス坑道での地質観察作業（JAEA, 2012b）を対象とし、同坑道にて 2006 年 10 月 26 日に、気温 12.0°C・気圧 1000.0mbar・湿圧 8.4mbar の環境で、RIEGL 社の 3D Terrestrial Laser Scanner シリーズである LMS-Z360i によって取得された点群データを用いる。坑道の詳細は 3.4.1.1 で述べる。

1.4 参考文献

- 原子力発電環境整備機構 (NUMO) (2004) : 高レベル放射性廃棄物地層処分の技術と安全性－「処分場の概要」の説明資料－, NUMO-TR-04-01, 原子力発電環境整備機構.
- 核燃料サイクル開発機構 (JNC) (1999) : わが国における高レベル放射性廃棄物地層処分の技術的信頼性, JNC TN1400 99-020, 核燃料サイクル開発機構.
- 経済産業省 資源エネルギー庁 ホームページ :
http://www.enecho.meti.go.jp/category/electricity_and_gas/nuclear/rw/hlw/qa/syo/syo03.html, 引用日 平成 29 年 11 月 21 日.
- 核燃料サイクル開発機構 (JNC) (2003) : ガラス固化体からの放射線量に関する検討, JNC TN8400 2003-022, 核燃料サイクル開発機構.
- 経済協力開発機構／原子力機関 (OECD/NEA) (1999) : Progress towards Geologic Disposal of Radioactive Waste: Where do We Stand?, NEA.
- 青柳和平, 窪田健二, 中田英二, 末永弘, 野原慎太郎(2017) : 幌延深地層研究施設における掘削影響領域の評価 (その 2)－深度 250m を対象とした試験－, JAEA-Research-2017-004, JAEA.
- 核燃料サイクル開発機構 (JNC) (1989) : 広域地下水流動評価に関する研究, JNC TJ7400 2005-063, 核燃料サイクル開発機構.
- 核燃料サイクル開発機構 (JNC) (2004) : 幌延深地層研究計画における地下水流動に関する研究, JNC TJ-5400 2003-009, 核燃料サイクル開発機構.
- 菱谷智幸, 鹿島浩之, 櫻井英行, 白石知成(2015) : 有限要素法による地下水流動解析における流れの局所連続性に関する考察, 地下水学会, vol.57(3), pp.319-334.
- 井尻裕二, 澤田淳, 坂本和彦, 内田雅大, 石黒勝彦, 梅木博之, 大西有三(2001) : 割れ目ネットワークモデルの水理特性に及ぼす割れ目スケール効果の影響, 土木学会論文集, vol.694(III-57), pp.179-194.
- 大津宏康, 坂井一雄, 井尻裕二, 下野正人, 本島貴之(2006) : 亀裂性岩盤におけるトンネル掘削に伴う突発湧水リスク評価, Journal of the Society of Materials Science, vol.55(5), pp.464-470.
- 鈴木俊一, 本島貴之, 井尻裕二, 青木広臣(2009) : 確率統計理論による亀裂特性データの相互関係の整理と数値解析モデルによる妥当性検証, 土木学会論文集 C, vol.65(1), pp.185-195.
- Dershowitz, S., Einstein, H. H. (1985) : Rock Joint Systems, Ph.d.Dissertation, Massachusetts Institute of Technology, Cambridge.
- Kulatilake, P. H. S. W., Wu, T. H. (1984) : Estimation of mean trace length of discontinuities, Rock Mechanics and Rock Engineering, vol.17(4), pp.215-232.
- 重野善政(2003) : 亀裂サイズがべき分布に従う場合における亀裂サイズとトレース長との関係について, 第 32 回岩盤力学に関するシンポジウム講演論文集, pp.179-184.

- 川越健(2006)：岩盤斜面と不連続面，RRR，vol.10，pp.38.
- 蕪木秀雄，寺倉清之(2007)：破壊・フラクチャの物理，第一刷，岩波書店，ISBN 978-4-00-011139-3，pp.40，60.
- 早野明，板倉賢一(2017)：三次元レーザスキャナ計測の坑道壁面の割れ目観察への適用性，Journal of MMIJ，vol.133(4)，pp.76-86.
- 鶴田忠彦，笹尾英嗣(2016)：瑞浪超深地層研究所における研究坑道掘削に伴って実施した壁面地質調査，応用地質，vol.56(6)，pp.298-307.
- 日本原子力研究開発機構（JAEA）（2012a）：超深地層研究所計画，瑞浪超深地層研究所；研究坑道の壁面調査データ集 付録 3.5_深度 300m ステージデータ，JAEA-Data-Code-2012-009-appendix(DVD-ROM)-5，日本原子力研究開発機構.
- 日本原子力研究開発機構（JAEA）（2012b）：超深地層研究所計画，瑞浪超深地層研究所；研究坑道の壁面調査データ集，JAEA-Data-Code-2012-009，日本原子力研究開発機構.
- 天野一男，秋山雅彦（2004）：フィールドジオロジー入門，初版1刷，共立出版，pp.50-63.
- 動力炉・核燃料開発事業団（PNC）（1994）：釜石鉱山における地層科学研究-第1フェーズ総括報告書-，PNC ZN7410 94-022，動力炉・核燃料開発事業団.
- 日本地質学会地質基準委員会（2003）：地質学調査の基本—地質基準，初版1刷，共立出版，pp.8-11

第2章 点群データを用いた不連続面取得について

2.1 3D レーザースキャナについて

2.1.1 3D レーザースキャナの仕様

3D レーザースキャナはリモートセンシング技術のひとつである (Slob et al., 2002, 2005, 2007; Fekete et al., 2010; Feng et al., 2004; Sturzenegger et al., 2009; Vöge et al., 2013; Gigli et al., 2012;)。図 2.1.1-1 に示すように、測定対象にレーザーパルスを照射し、対象から反射されたパルスを収集することで、対象の表面形状を 3 次元空間上に存在する点の集合 (以下: 点群) として記録する (Fekete et al., 2010)。現在多くのスキャナが水平方向 360° の範囲を計測でき、また数万点/秒から 100 万点/秒の速度で計測が可能となっている (新発田, 2013)。

レーザー光を利用した測定法としてはいくつか存在するが、3D レーザースキャナではタイムオブフライト法と位相差測定法が多く用いられている (新発田, 2013)。タイムオブフライト法は、非常に短い光パルスを放射し、レーザーの照射方向と対象物で乱反射した戻り光をスキャナの受光部が検知するまでの時間から距離と角度を求める方式である (図 2.1.1-2)。一般的に、タイムオブフライト方式のスキャナは、何百何千メートルと長距離を計測できるため、広範囲に及ぶ遺跡や大型の建築物の計測に適している。位相差測定法は、強度変調を掛けた光を連続放射し、出射光と戻り光との間に生じた移送の差を測定することで距離を求める方式である (図 2.1.1-3)。位相差測定法は、150m 程度の範囲を高精度かつ高速にスキャンすることが可能である (榎本ほか, 2012)。

図 2.1.1-4 は実際に取得された点群の一例で、瑞浪超深地層研究所・深度 300m 研究アクセス坑道 No.54 にて取得されたものである。ただし、吹き付けコンクリートが付与されている箇所を目視で取り除いている。計測サイズは高さが約 3.5m, 幅が約 4.6m, 奥行きが約 1.3m となっている。総点数は 2,726,959 である。面状になっている個所がいくつも見受けられる。

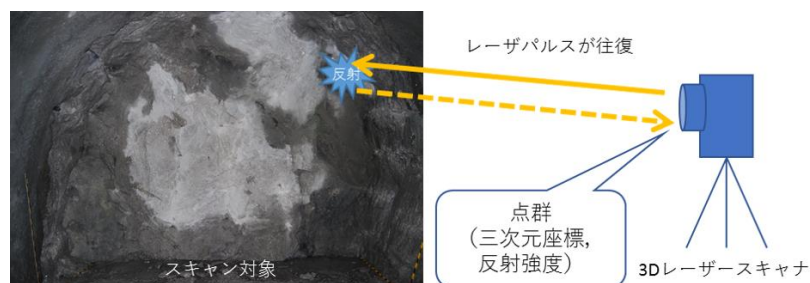


図 2.1.1-1 3D レーザースキャナによるスキャン手順

(図左: 瑞浪超深地層研究所・深度 300m 研究アクセス坑道 No.54)




図 2.1.1-2 タイムオブフライト法の概念図（新発田，2013 より転載）




図 2.1.1-3 位相差測定法の概念図（新発田，2013 より転載）




図 2.1.1-4 瑞浪超深地層研究所・深度 300m 研究アクセス坑道にて取得された点群の一例
（坑道 No.54, Kitware 社の ParaView 3.98 にて描画）

3D レーザースキャナでは、3 次元空間上の x, y, z 座標のほか、反射強度や、カメラを利用することで色情報なども取得する事ができる。しかし、特定の条件・環境・計測対象物によっては計測が難しい場合もある。新発田はレーザースキャナのそのような特性として、

- 1) レーザー光の当たらない箇所の測定ができない
- 2) 極端に反射率の低いあるいは反射率の高い対象物は測定できない
- 3) レーザーの波長によっては補色の対象物は測定できないことがある
- 4) 障害物や草木など、不要なデータも全て計測されてしまう
- 5) 一点を正確に計測することは困難である
- 6) 小さな物体の計測では不向きである

を上げている（新発田，2013）。

2.1.2 3D レーザースキャナの用途

3D レーザースキャナは、対象物の形状など 3 次元座標情報の取得と活用のために、多様な分野において用いられている。倉内らは、位相差測定法を用いたスキャナにより工場内部の 100m ほどの広範囲を高分解能でスキャンし、工場内のレイアウト図の作成や、季節廃刊と親切物との設計段階における干渉チェック、設計図が存在しない構造物の CAD 化などに適用している（倉内ほか，2017）。図 2.1.2-1 は、実際のスキャン結果である。CAD データによる設計データの利用や点群からの構造解析などを通して、倉内らは、3D スキャンは 1 回の計測範囲が非常に広くサンプリングも高速な点から、従来コスト面で全周計測が非現実的であった大型構造物に関連する計測ニーズに幅広く対応できるとしている。




図 2.1.2-1 工場内のスキャン結果とクレーン車の点群データ（倉内ほか，2017 より転載）

また、古川はタイムオブフライト法のスキヤナにより雪面形状の把握を行い(図 2.1.2-2)、危険な雪崩斜面の地形測定、積雪量・積雪形状の測定、人口雪崩による処理量の把握、積雪の時系列的形状変化の把握に利用できるとした(古川, 2006)。またここでは、3D レーザースキヤナによる計測と点群データの特徴を、1) 計測対象を点ではなく面でとらえ、解析が可能、2) 危険箇所には立ち入ることなく安全に計測できる、3) もろく変形しやすい対象でも、そのままの形を正確に計測できる、としている。

他にも、岡本らは、産業廃棄物処分場の容量算出、広島県府中市の崖の調査、広島県広島市の交通量が多い交差点における電鉄のレール高・勾配および架線の位置と高さの計測に利用した(図 2.1.2-3)(岡本ほか, 2010)。活用の結果、3D レーザースキヤナの特徴として、1) レーザー光が届く範囲であれば、危険な場所に立ち入る必要がない、2) 遺跡や文化財など、触ることが出来ないものに対し、形状を得ることが出来る、3) 現状の地形・物体等を残すことができる、などを上げている。

以上より、倉内・古川・岡本らは共通して「測定箇所に立ち入ることなく安全に計測できる」「現状の地形・物体等を正確に計測できる」ことを 3D レーザースキヤナの特徴として挙げている。すなわち、3D レーザースキヤナを用いる最大の利点として、この 2 点が考えられる。3D レーザースキヤナを用いることで、対象の表面形状を高解像度な点群で高速に取得(Gigli, 2011; Slob, 2007)することができ、また機器も小型であるため、例えば崩落の可能性のある岩盤や崖の下など、人間により直接空間情報を得ることが難しい場所でも、安全かつ質の高いデータを取得することができると考えられる。以上のことから、コンピュータの進化も伴い、2000 年代前半から様々な研究が成されている。



図 2.1.2-2 雪崩斜面の点群データ (古川, 2006 より転載)




図 2.1.2-3 産業廃棄物処分場（上）と広島県広島市の交差点（下）
（岡本ほか，2010 より転載）

2.2 先行研究

2.2.1 手動での不連続面取得手法

2.1 で述べたように，3D レーザースキャナは，対象の 3D 形状を素早く一定の精度で取得する事を可能にするため，地質観察においても，従来手法に比べて平準的なデータを少ない労力で点群から取得する事が期待され，2000 年前半から様々な研究が行われてきた。

a) 点群データからの不連続面の取得

Slob らは 2002 年に，露頭における省力かつ高速な観察を目指し，かつレーザースキャナによるより多くの地質情報の取得可能性について調査し，点群データのドロネー三角形分割によるポリゴン（3D Triangulated Irregular Network：3D TIN）の生成と可視化を行い，また生成したポリゴンデータから法線ベクトルを決定することで不連続面が取得できることを明らかにした（Slob et al., 2002）。図 2.2.1-1 はスキャン対象である露頭（図赤枠内）の写真と，スキャン結果から 3D TIN を生成して可視化したもの（図右）である。写真と 3D TIN 図を見比べると，3D TIN がおおそ露頭の形状に近似していることが分かる。図

2.2.1-2 はポリゴンデータから法線ベクトルを決定する手順を示す。図aが空間上に存在する点群を表し、 b が生成されたポリゴンを表す。 c は法線ベクトルを決定する図で、

$$\begin{aligned}\underline{a} &= \begin{pmatrix} X_3 - X_2 \\ Y_3 - Y_2 \\ Z_3 - Z_2 \end{pmatrix} \\ \underline{b} &= \begin{pmatrix} X_1 - X_2 \\ Y_1 - Y_2 \\ Z_1 - Z_2 \end{pmatrix}\end{aligned}\dots\dots\dots (2.1)$$

として

$$\underline{n}_1 = \underline{a} \times \underline{b}\dots\dots\dots (2.2)$$

で求めている。

また、Slob らは 2007 年に同一平面上に存在する点群を領域成長法でグループ化して 285 枚の面を推定し、その傾斜・方位を Fuzzy k-means clustering によりクラスタリングし、図 2.2.1-3 のような 5 つの不連続面を取得している (Slob et al., 2007)。




図 2.2.1-1 露頭のスキャン結果のポリゴン表示 (Slob et al., 2002 より一部改)




図 2.2.1-2 点群データより生成したポリゴンからの法線ベクトルの算出手順
(Slob et al., 2002 より転載)




図 2.2.1-3 点群から求めた不連続面（色の濃い箇所）
 (Slob et al., 2007 より転載)

b) 坑道における 3 次元的特徴の取得

Fekete らは 2010 年に、調査員の計測した不連続面の方位と、点群から取得した不連続面との方位を比較した(Fekete et al., 2010)。図 2.2.1-4 は結果の一例で、2.2.1-4a は 3 回に分けてスキャンした点群データを統合したもの、2.2.1-4b は目視で不連続面を取得し楕円で表示したもの、2.2.1-4c が従来手法による実際の観察結果をステレオネット図に示したもの、2.2.1-4d が 2.2.1-4b の面のステレオネット図である。2.2.1-4c と 2.2.1-4d を見ると、その卓越方位がおおよそ一致していることがわかる。このことから、坑道の点群データから詳細な 3 次元的特徴を取得できる事を明らかにし、不安定な場所の特定や分離した不連続面の結合、表面の粗さの解析に応用した。

Sturzenegger らは鉱山で計測した壁面観察結果・LIDAR データ・写真測量データからそれぞれ手動で不連続面を取得し、不連続面の位置や向き、長さ、粗さ、曲率の違いを調査した(Sturzenegger et al., 2009)。観察データと LIDAR データの傾斜角(図 2.2.1-5a)と傾斜方位(図 2.2.1-5b)の差は 4° から 8° の間と地質観察に十分な精度であり、LIDAR データの活用が非常に重要であると強調している。

c) 日本における利用

日本でも、石濱らが坑道切羽面の点群からメッシュを作成して不連続面を取得する方法を開発し(図 2.2.1-6)、3D レーザースキャナによる計測を地質観察作業へ適用した際のメリット・デメリットについて考察している(石濱ほか, 2016)。石濱らは、測時間を短縮す

る新たな方法を考案しなければ実用化には課題が残るとする一方、高精度かつ後処理の手間が掛からない点から、今後の発展に期待できるとしている。




図 2.2.1-4 Fekete らにより取得された不連続面とその卓越方位
(Fekete et al., 2010 より転載)




図 2.2.1-5 壁面観察データと LIDAR データの差

(Sturzenegger et al., 2009 より転載)

(a)における点線は傾斜角の差が 4° のライン, (b)の点線は傾斜方位の差が 8° のラインを示す。凡例 A~E は傾斜・傾斜方位の計測手法を示す。A が従来手法で B~E がそれぞれ質の異なる点群である。




図 2.2.1-6 切羽の面構造の抽出例（石濱ほか，2016 より転載）

2.2.2 半自動での不連続面取得手法

2.2.1 で述べた研究では，主に専用のソフトウェアを用いて手動で点群を観察し，試行錯誤的に不連続面を決定する手法を用いている。しかし，作業労力を要す上に，処理結果が個人の技量に依存する。そこで，手動の操作を減らし，点群から半自動的に面を推定して表面形状を近似し不連続面を取得する研究もある。

Vöge らは点群からメッシュを作成し，平滑化（図 2.2.2-1 ii），エッジ検出・マスクング（図 2.2.2-1 iii），破碎部検出・マスクング（図 2.2.2-1 iv），不連続面識別（図 2.2.2-1 v），不連続面セットのクラスタリング（図 2.2.2-1 vi）の 5 つの処理を通して面を推定し不連続面を取得する PlaneDetect と呼ばれるアルゴリズムを開発した（Vöge et al., 2013）。PlaneDetect では，1）平滑化の重み，2）平滑化の反復回数，3）マスクの領域，4）マスクの閾値，5）法線ベクトルの分散の閾値，6）隣接判定の半径，7）クラスタ数，の 7 つのパラメータを手動で設定する必要があり，それぞれの値が面の推定に影響を及ぼす。図 2.2.2-2 は平滑化の反復回数による点群の表面の違いを表している。反復回数 0（図 2.2.2-2 0 iterations）では存在していた多くの凹凸が，反復回数 500（図 2.2.2-2 500 iterations）ではほとんど見受けられなくなっているため，Vöge らは反復回数 500 では表面の情報が失われていると記している。




図 2.2.2-1 PlaneDetect による不連続面取得の手順 (Vöge et al., 2013 より転載)




図 2.2.2-2 平滑化処理を繰り返した点群の表面形状の例 (Vöge et al., 2013 より転載)

また Gigli らは、メッシュを作らずに点群を立方格子で分割し、各格子内で面を推定し不連続面を取得する Discontinuity Analysis (以下：DiAna) と呼ばれるアルゴリズムを開発した (Gigli et al., 2012)。DiAna では、まず点群を一定の大きさを持つ格子で分割する (図 2.2.2-3a)。その際、点の分散が閾値以上となる格子をノイズ計測誤差) と考え除去する。次に、各格子内の点に対し、最小二乗法で面をフィッティングする (図 2.2.2-3b)。最後に、ある格子内の面の法線に対して、周辺の格子内の面の法線が類似している場合、それらは同一の面を成していると見做して格子を併合する (図 2.2.2-3c)。併合後の格子から 1 枚の面を推定するために、併合後の格子内の点群を用いて再度面をフィッティングする。以上の操作で面を推定し、表面形状を近似した後、不連続面を取得する。図 2.2.2-4a が推定された面で、b が面の向きでクラスタリングした結果、c がそれを領域分割して不連続面を取得したもので、d が各不連続面の輪郭を表している。




図 2.2.2-3 DiAna による点群の格子分割の概念図 (松川ほか, 2017 より一部改)




図 2.2.2-4 DiAna における不連続面推定の手順 (Gigli et al., 2012 より転載)

2.3 実用面での課題

2.3.1 標準化と省力化への寄与

PlaneDetect と DiAna は、どちらもアルゴリズムとして開発されており、専用のソフトウェアや、目視で不連続面を決定する必要がない。よって、2.2.1 で述べた手動での不連続面の取得方法に比べ、地質観察の課題である作業の標準化と省力化を実現できると考えられる。

PlaneDetect と DiAna を比較すると、手動で設定するパラメータの数に違いがみられる。PlaneDetect では 1) 平滑化の重み, 2) 平滑化の反復回数, 3) マスクの領域, 4) マスクの閾値, 5) 法線ベクトルの分散の閾値, 6) 隣接判定の半径, 7) クラスタ数, の 7 つのパラメータを手動で設定する。DiAna は PlaneDetect に比べて手動で設定する必要のあるパラメータの数が少なく, 1) 立方格子のサイズ, 2) ノイズ除去に用いる分散の閾値, の 2 つである。

しかし、パラメータ空間は複雑であり、多くのパラメータを人間の手で同時に最適化するのは非常に困難である。廣安らによると、シミュレーション系であれば、自動的にパラメータを最適化する方法として、パレート的アプローチによる多目的最適化問題として解を求めることは可能である（廣安ほか, 2009）。しかし、パターン認識のような問題においてパラメータを最適化するには、グリッドサーチのような手法が現実的であり、未だ手動でのチューニングの域を出ない。すなわち、膨大な点群データの処理においては、必要なパラメータの少ないアルゴリズムほど有利である。

よって、DiAna は PlaneDetect に比べてパラメータチューニングが容易である利点がある。また面の推定方法についても、手動で設定したパラメータに基づき隣接点同士を結んでメッシュを作成する手法に比べ、最小二乗法は面と点群との誤差の尤度を最大にするため、人間の技量に依存する処理がなく自動的な処理を行っていると言える。

2.3.2 DiAna の課題

DiAna では不連続面を取得する前処理として点群から面を推定するが、面の推定処理を実行する前に手動で適切な格子サイズとノイズ除去の分散の閾値を設定する必要がある。

図 2.3.2-1 は、不適切な格子サイズで推定処理を実行したときの問題について示している。図は、本来階段状の 3 つの面で構成される点群に対して、適切な格子サイズ(図 2.3.2-1a)、大きい格子サイズ(図 2.3.2-1b)、小さい格子サイズ(図 2.3.2-1c)で分割しそれぞれ面を推定した際の概念図である。適切な格子サイズで分割した場合、不連続面の段差を正確に表現できる(図 2.3.2-1a)。しかし、この点群に対し大きい格子を設定して 1 つの面をフィッティングした場合、格子のサイズが大きくなり本来 3 つの格子が必要な点群が 1 つの格子に収まり、3 つの面を 1 枚の面で近似することになる(図 2.3.2-1b)。ここでは、図 2.3.2-1a の様な面が確認できない。また図 2.3.2-1c は小さい格子サイズで分割した図で、Z 軸方向に格子が 2 段作られている。坑道壁面の表面がこの様に複数段存在することは考えにくく、図 2.3.2-1c

では面の適切な近似が行われていないと考えられる。ほかにも、格子サイズが小さいことから格子内の点群の分散が非常に大きくなり、点の分布が一様に近くなることから、最小二乗法で不適切な面が推定されることもある。図 2.3.2-1d では、中央の面は赤い点線で示す適切な面に対して垂直な方向に面が推定されている様子を示している。ここでは、赤い点線で示す面に対し、ノイズの影響により垂直な方向に点が広く分布している。最小二乗法はいくつかの前提条件の下で行われる最尤推定法の一つであり、その前提の 1 つに「推定される面と点との誤差の分布形が正規分布である」事がある（中川ほか，1982）ことから、点が格子の中で一様に分布したような状態になった結果、面の推定が適切に行われなかったと考えられる。

以上の様に、DiAna では適切な格子サイズで点群を分割し、適切な閾値で適切なノイズ除去を行わないと、表面形状を正確に近似する事ができない。しかし、坑道壁面の点群データは、表面形状が複雑な上に埃や塵・湧水による反射などの影響を受けやすく、場所により適切な格子サイズが異なる。また、実際に手で適切なパラメータを設定するには数ミリメートル単位での格子サイズの調節、また数平方ミリメートル単位での閾値の調節が必要で利用者の熟練を要し、長距離の坑道では多くの時間を要する。よって、地質観察の課題である作業の省力化と平準化の現実的な観点からは未だ不十分であり、自動的かつ適切な格子サイズの決定とノイズ除去が必要である。




図 2.3.2-1 適切な格子による面の推定(a)と不適切な格子による面の推定(b, c, d)の概念図

2.4 参考文献

- Slob, S., Hack, R., Turner, A. (2002) : An approach to automate discontinuity measurements of rock faces using laser scanning techniques, ISRM International Symposium - EUROCK 2002 proceedings, pp.87-94.
- Slob, S., van Knapen, B., Hack, R., Turner, K., Kemeny, J. (2005) : Method for Automated Discontinuity Analysis of Rock Slopes with Three-Dimensional Laser Scanning, Transportation Research Record, vol.1913(1), pp.187-194.
- Slob, S., Hack, H. R. G. K., Feng, Q., Roshoff, K., Turner, A. K. (2007) : Fracture mapping using 3D laser scanning techniques, 11th Congress of the International Society for Rock Mechanics proceedings, pp.299-302.
- Fekete, S., Diederichs, M., Lato, M. (2010) : Geotechnical and operational applications for 3-dimensional laser scanning in drill and blast tunnels, Tunnelling and Underground Space Technology, vol.25(5), pp.614-628.
- Feng, Q. H., Roshoff, K. (2004) : In-situ mapping and documentation of rock faces using a full-coverage 3d laser scanning technique, International Journal of Rock Mechanics and Mining Sciences, vol.41(SUPPL. 1), pp.1-6.
- Sturzenegger, M., Stead, D. (2009) : Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts, Engineering Geology, vol.106(3-4), pp.163-182.
- Voge, M., Lato, M. J., Diederichs, M. S. (2013) : Automated rockmass discontinuity mapping from 3-dimensional surface data, Engineering Geology, vol.164, pp.155-162.
- Gigli, G., Casagli, N. (2011) : Semi-automatic extraction of rock mass structural data from high resolution LIDAR point clouds, International Journal of Rock Mechanics and Mining Sciences, vol.48(2), pp.187-198.
- 新発田知哉 (2013) : 地上型レーザースキャナの特長, 写真測量とリモートセンシング, vol.52(6), pp.285-288.
- 榎本昌一, 小栗昇悟, 増田宏, 田中一郎 (2012) : 複数のレーザースキャナによる平面計測精度の比較, 精密工学会学術講演会講演論文集, vol.2012S, pp.547-548.
- 倉内友己, 古川祐太郎, 長坂光高 (2017) : 3D レーザースキャナを用いた計測事例, IIC REVIEW, vol.57, pp.26-29.
- 古川大助 (2006) : 新計測機器の可能性 地上型 3D レーザースキャナーの活用, 第 21 回 北 陸 氷 雪 技 術 シ ン ポ ジ ウ ム 論 文 集 web 版 , http://www.yukicenter.or.jp/whatsnew/061109/ronbun_31.pdf, 引用日 平成 29 年 11 月 21 日.
- 岡本良徳, 横手了 (2010) : 地上型レーザースキャナーによる 3D データ計測, 平成 22 年度

- 中国地方建設技術開発交流会発表論文集 web 版 ,
http://www.cgr.mlit.go.jp/ctc/tech_dev/kouryu/T-Space/ronbun/pdf/22_okayama/22_okayama_5-2.pdf, 引用日 平成 29 年 11 月 21 日.
- 石濱茂崇, 青木宏一, 片山政弘, 手塚仁(2016): 切羽における不連続面の 3 次元計測システムの開発と現場適用事例. 応用地質, vol.56(6), 316-324.
- 松川瞬, 板倉賢一, 早野明, 鈴木幸司 (2017): 岩盤における不連続面の自動推定に向けた 3 次元点群データの可変格子分割法, Journal of MMIJ, vol.133(11), pp.256-263.
- 廣安知之, 渡辺崇文, 中尾昌広, 大塚智宏, 道紘鯉淵 (2009): 多数目的最適化を利用したパラメータチューニング, 数理モデル化と応用, vol.2(3), pp.14-26.
- 中川徹, 小柳義夫(1982): 最小二乗法による実験データ解析: プログラム SALS, 東京大学出版会, 初版 1 刷, pp.30.

第3章 Variable-Box Segmentation による面の推定について

3.1 概要

DiAna の課題は、場所により適切な格子サイズを自動で決定し、適切なノイズ処理を行うことである。そこで本研究では、不連続面を取得する前処理として、点群を分割する格子のサイズを場所によって自動的に変更して点群から面を推定し坑道壁面の表面形状を近似する可変格子分割アルゴリズム(Variable-Box Segmentation Algorithm, 以下：VBS)を開発した。

VBS は、「大格子分割」「小格子分割」「結合」の 3 つのプロセスから成る。図 3.1-1 は VBS の処理の流れ図である。(a)は大格子分割プロセスで、オレンジの点で表される点群を黒の格子で分割した様子を示している。大格子分割にて点群を大きいサイズの立方格子で分割した後、(a)の赤い枠を拡大した図が(b)である。(b)は小格子分割プロセスを示しており、大格子をさらに小さいサイズの小格子で分割した後(図 3.1-1b), 各小格子の中で面をフィッティングする(図 3.1-1c)。フィッティングには最小二乗法を用い、 x , y , z 軸を高さ方向とした際のフィッティング結果のうち、点と面の距離の総和が最も小さい面を最終的なフィッティング結果としている。(c)はフィッティングされた各面を示している。同じ色の面は、法線ベクトルが類似している面を表しており、次の結合プロセスで一枚の面に結合される。(d)で示す結合プロセスでは、各小格子間で類似した面を領域成長法で結合して、結合した格子内に含まれる点群から面を推定し、坑道壁面の表面形状を近似する。図の各色が、最終的に推定された各面を表す。

以上の様に、VBS は点群を分割した後に結合させ、ボトムアップ的に面を推定する。この時、大格子分割に用いる格子サイズのみをパラメータとして必要とする。




図 3.1-1 VBS による点群の格子分割と面推定の概念図 (松川ほか, 2017 より転載)

3.2 前処理

3.2.1 前処理の必要性

1.3 で述べた用に、本研究では瑞浪超深地層研究所・深度 300m 研究アクセス坑道での地質観察作業にて LMS-Z360i を用いて取得された点群データを対象としている。LMS-Z360i にて取得されたデータの座標系は、国土交通省により平成十四年国土交通省告示第九号で定義された平面直角座標系 VII（国土交通省国土地理院ホームページ、<http://www.gsi.go.jp/sokuchikijun/jpc.html>）を原点に置く座標系（以下：グローバル座標系）となっている（RIEGL, 2007）。グローバル座標系は東経 137.10, 北緯 36.0 を原点と定めており、原点からの距離をメートル単位で測定している。しかし、平面直角座標系 VII の原点から瑞浪超深地層研究所までは直線でおおよそ 70000m 程度あるため、グローバル座標系では各軸の値が数万となり、今後データを処理する際に計算値のオーバーフローが起こる可能性がある。そこで、処理の簡便の為、本研究では取得データを一旦トンネル区間の手前中心を原点とした座標系（以下：ローカル座標系）に変換する。

また、坑道壁面は一般的に馬蹄形であるが、点群が曲面状に配置されている箇所では格子サイズを扇状に変える必要があり、VBS による大格子分割プロセスが複雑になる。また曲面上に存在する不連続面においては、法線が曲面に沿って変化するので、結合プロセスが複雑になる。以上の処理を簡便化するため、設計上の掘削断面を基準にして、z 軸方向に凹凸情報を持つ様に引き延ばす形で点群データを座標変換し、直方体に展開する。

なお、以上の変換による取得データへの影響であるが、本研究では全て変換後の点群データを処理し、変換後の点群データ同士で形状の比較を行っているため、考慮していない。

3.2.2 前処理の手順

以下に、まず座標系の変換手順を示す。変換前の座標系は、図 3.2.2-1 の様になっている。上記の座標系において、点群の座標は (X, Y, Z) で表される。 X が東西方向、 Y が南北方向、 Z が深さで、単位はメートルである。図の X 軸と Y 軸が交点平面直角座標系 VII の原点で、赤い矢印が示す先の赤点が瑞浪超深地層研究所である。

座標系の変換の際、まず SOP $\times$ POP の逆行列を掛ける。SOP は SOCS (Scanner's Own Coordinate System) と PRCS (PProject Coordinate System) の間の変換で、スキャナ座標系 (LMS-Z360i 中心の座標系) からプロジェクト座標系 (個々の仕事で利用する座標系) への変換を行う行列である (RIEGL, 2007)。POP は PRCS と GLCS (GLocal Coordinate System) の間の変換で、プロジェクト座標系からグローバル座標系への変換を行う行列である (RIEGL, 2007)。今回用いたデータは PRCS と GLCS が等しく、POP は単位行列であるので、無視する。よって、取得されたデータ (以下：元データ) に SOP の逆行列のみを掛け逆変換する事で、スキャナ中心の座標系に変換出来る (図 3.2.2-2)。

SOP の具体例を、図 3.2.2-3 に示す。これは、瑞浪超深地層研究所・深度 300m 研究アクセス坑道の No.55 における SOP である。



図 3.2.2-1 変換前のトンネルの座標系

(google マップ (<https://www.google.com/maps/>) より一部改)




図 3.2.2-2 グローバル座標系からローカル座標系への変換

$$SOP_{No.55} = \begin{pmatrix} 0.005 & -0.984 & 0.178 & 6478.107 \\ 0.010 & 0.178 & 0.984 & -68937.310 \\ -0.999 & -0.003 & 0.011 & -97.756 \\ 0.000 & 0.000 & 0.000 & 1.000 \end{pmatrix}$$

図 3.2.2-3 瑞浪超深地層研究所・深度 300m 研究アクセス坑道 No.55 における SOP

次に、トンネルの設計上のデータより得たトンネル区間の手前中心点を SOP で逆変換したものを、変換後のデータから引く。これにより、実際に設置されたレーザースキャナの座標と、設計図上の中心点との誤差を修正する（図 3.2.2-4）。最後に、簡便のため x 軸の向きだけを変えるよう、 -1 を掛ける（図 3.2.2-5）。以上で、ローカル座標系への変換は完了である。

次に、図 3.2.2-6 に示すように、設計上の掘削断面を基準にして、 z 軸方向に凹凸情報を持つ様に引き延ばす形で点群データを座標変換し、直方体に展開する。変換前の点の座標を $p = (x, y, z)$ 、トンネル 1 区間における設計上の掘削断面の横幅を $2w$ 、天蓋部と側壁部の境界線であるスキャンラインまでの高さを h 、奥行 y における天蓋部の中心を $q = (h, y, 0)$ 、線分 pq と z 軸とのなす角度 θ (rad) を、直線 pq と天蓋部との交点を $r = (h + w \sin \theta, y, w \cos \theta)$ とする。投影後の座標 (x', y', z') は、スキャンライン下右側壁部(図 3.2.2-6 青部) では

$$(x', y', z') = (x, y, z - w) \quad \dots\dots\dots (3.1)$$

スキャンライン上天蓋部（図 3.2.2-6 橙部）では

$$(x', y', z') = (h + w\theta, y, |r| - |p|) \quad \dots\dots\dots (3.2)$$

スキャンライン下左側壁部（図 3.2.2-6 緑部）では

$$(x', y', z') = (-x + h + w\pi, y, -z - w) \quad \dots\dots\dots (3.3)$$

となる。VBS を用いて処理を行う点群データは、全て以上の様に xy 平面上の座標と z 方向の凹凸情報を持つものとする。以下、全ての点の座標は変換後の座標とする。




図 3.2.2-4 設計図上の中心点との誤差の修正




図 3.2.2-5 最終的なローカル座標系への変換




図 3.2.2-6 トンネル展開の概念図（松川ほか，2017 より転載）

3.3 アルゴリズム詳細

3.3.1 大格子分割プロセス

まず，大格子分割プロセスにて，点群を大格子で分割する(図 3.3.1-1)。分割された格子には， x ， y ， z 軸にそって格子番号 $I = (i, j, k)$ を割り当てる。また，格子番号を正の整数

にするため， $p_{min} = (\min(x), \min(y), \min(z))$ を原点とする。よって，格子サイズを $s =$

(L, M, N) ，点群を P とすると， I 番目の格子に含まれる点群 B_I は

$$B_I = \left\{ p \in P \mid (iL, jM, kN) \leq p - p_{min} < ((i+1)L, (j+1)M, (k+1)N) \right\} \quad \dots\dots\dots (3.4)$$

と表される。




図 3.3.1-1 大格子分割の概念図




図 3.3.1-2 大格子分割におけるノイズ除去処理の概念図

(松川ほか，2017 より一部改)

次に、以降のプロセスへの影響を低減するため、ノイズを除去する。本研究では、各大格子内で計測誤差が大きい点群を取り除く(図 3.3.1-2)。計測誤差は、3D レーザースキャナによる計測時に、真値に対し様々な要因で発生する誤差のことである。

取り除く点群は、計測誤差の分布を正規分布と仮定し、分布の平均から標準偏差の範囲外の誤差を持つ点群とする。この時、大きい誤差は生起確率が低い。よってそのような誤差を含む点は少なく、その点周辺の点数も少ない。そこで、大格子を図 3.3.1-2(b)左の様に極小格子で分割し、各極小格子内に含まれる点数の少ない(点密度の低い)格子から順に点数を累積する。正規分布において平均値から標準偏差以内にある確率が 68.27% である事から(榎本ほか, 2012)、累積した点数の総点数に対する割合が 31.73% を超えた際に、それまで累積した極小格子に含まれる点群を計測誤差が大きい点としてすべて取り除く。図 3.3.1-2(b)右は横軸に格子内の点数、縦軸に累積点数を表した概念図で、赤い線が、累積点数の総点数における割合が 31.73% となるラインを表している。この概念図では、極小格子に含まれる点数を昇順に累積していった際、3つ目の極小格子で 31.73% を超える。図 3.3.1-2b 左にある赤い極小格子が点数を累積した格子である。これらの格子に含まれる点を計測誤差が大きい点と見做し、除去する。

3.3.2 小格子分割プロセス

小格子分割プロセスでは、ノイズ除去された大格子を 3×3 個の小格子に分割し、各小格子内にて線形最小二乗法で面をフィッティングする。点群 B_l を分割した小格子内の、小格子番号 J の点群 B_l^J は $B_l^J \subseteq B_l$ かつ $B_l^J \cap B_l^K = \phi$ ($B_l^K \subseteq B_l$, $K \neq J$) である。また、 x, y, z の 3 次元空間上での面の方程式 $F = ax + by + cz + d = 0$ において、フィッティングする面の高さ成分 z は

$$z = -\frac{a}{c}x - \frac{b}{c}y - \frac{d}{c} \quad \dots\dots\dots (3.5)$$

と表せる。最小二乗条件は、ある小格子内の i 番目の点の座標を (x_i, y_i, z_i) 、 B_l^J の要素数を n として

$$f(B_l^J) = \sum_{i=0}^n (z_i - z)^2 = \sum_{i=0}^n \left(z_i - \frac{a}{c}x_i - \frac{b}{c}y_i - \frac{d}{c} \right)^2 \rightarrow \min \quad \dots\dots\dots (3.6)$$

と表すことができ、 $\alpha = -\frac{a}{c}$, $\beta = -\frac{b}{c}$, $\gamma = -\frac{d}{c}$ とすると

$$f(B_l^J) = \sum_{i=0}^n (\alpha x_i + \beta y_i + z_i + \gamma)^2 \rightarrow \min \quad \dots\dots\dots (3.7)$$

となる。(3.7)式を満たす α, β, γ を求め、 $c = \frac{1}{\sqrt{\alpha^2 + \beta^2 + \gamma^2}}$, $a = -c\alpha$, $b = -c\beta$, $d =$

$-c\gamma$ を得る。この時、 $\vec{v} = (a, b, c)$ がフィッティングされた面の法線ベクトル $\vec{n}_z$ である。

(3.7)式は極値を取るため、 $\frac{\delta f(B_l^I)}{\delta \alpha}$, $\frac{\delta f(B_l^I)}{\delta \beta}$, $\frac{\delta f(B_l^I)}{\delta \gamma}$ を解く。それぞれ

$$\begin{aligned}\frac{\delta f(B_l^I)}{\delta \alpha} &= \sum_{i=0}^n 2(\alpha x_i + \beta y_i + z_i + \gamma) \cdot x_i \\ &= 2 \sum_{i=0}^N \alpha x_i^2 + \beta x_i y_i + x_i z_i + x_i \gamma \\ &= 0\end{aligned} \quad \dots\dots\dots (3.8)$$

$$\begin{aligned}\frac{\delta f(B_l^I)}{\delta \beta} &= \sum_{i=0}^n 2(\alpha x_i + \beta y_i + z_i + \gamma) \cdot y_i \\ &= 2 \sum_{i=0}^N \alpha x_i y_i + \beta y_i^2 + y_i z_i + y_i \gamma \\ &= 0\end{aligned} \quad \dots\dots\dots (3.9)$$

$$\begin{aligned}\frac{\delta f(B_l^I)}{\delta \gamma} &= \sum_{i=0}^N 2(\alpha x_i + \beta y_i + z_i + \gamma) \\ &= 2 \sum_{i=0}^N \alpha x_i + \beta y_i + z_i + \gamma \\ &= 0\end{aligned} \quad \dots\dots\dots (3.10)$$

となる。整理すると、




図 3.3.2-1 フィッティング概略図

$$\begin{pmatrix} \sum_{t=0}^N x_i z_i \\ \sum_{t=0}^N y_i z_i \\ \sum_{t=0}^N z_i \end{pmatrix} = \begin{pmatrix} \sum x_i^2 & \sum x_i y_i & \sum x_i \\ \sum x_i y_i & \sum y_i^2 & \sum y_i \\ \sum x_i & \sum y_i & N \end{pmatrix} \begin{pmatrix} \alpha \\ \beta \\ \gamma \end{pmatrix} \dots\dots\dots (3.11)$$

となる。これを解いて α , β , γ を求めた後、法線ベクトルの条件である $a^2 + b^2 + c^2 = 0$ の条件の下 a , b , c , d を求めると

$$\begin{aligned} c &= \frac{1}{\sqrt{\alpha^2 + \beta^2 + 1}} \\ a &= -c\alpha = -\frac{\alpha}{\sqrt{\alpha^2 + \beta^2 + 1}} \\ b &= -c\beta = -\frac{\beta}{\sqrt{\alpha^2 + \beta^2 + 1}} \\ d &= -c\gamma = -\frac{\gamma}{\sqrt{\alpha^2 + \beta^2 + 1}} \end{aligned} \dots\dots\dots (3.12)$$

となる。

同様に x 軸・ y 軸方向でも $\vec{n}_x$, $\vec{n}_y$ を計算し、3つのベクトルの内、 $S = \{S_p | p = x, y, z\}$ として $S_p = \min(S)$ となった軸を $pmin$ とする。面の方程式には $\vec{n}_{pmin}$ を利用する。

ここで、2.3.2 で述べた用に、最小二乗法の前提の1つに「推定される面と点との誤差の分布形が正規分布である」事がある。しかし、小格子分割にて大格子を分割した際に格子サイズが小さ過ぎる場合、点群の水平方向における分散に対し垂直方向における分散が大きくなる箇所がある。つまり、分布系が一様分布に近づき最小二乗法の前提条件を満たさない点群を持つ格子となり、不適切な面が推定される。その様な小格子に対しては、3.3.3 に記す結合プロセスにて、隣接する小格子と領域成長法で結合させ、格子のサイズを大きくすることで適切な面の推定を図る。しかし、適切な面と不適切な面との法線の類似度は大幅に異なる。不適切な面を持つ小格子が適切な面を持つ小格子に囲まれていた場合、不適切な面を持つ小格子の領域が成長しない。よって、適切な面・不適切な面を判別し、領域成長の処理を分岐させて格子を結合する必要がある。

面の適否は、誤差分布の尖度を算出して分布形状の正規分布からの乖離度を計り（池田ほか、2011）判別する。尖度 k は、面と点 p_i の誤差を ε_i 、小格子内の点群の数を n 、標本平均 μ ・標本分散 σ^2 を

$$\mu = \frac{1}{n} \sum_{i=1}^n \varepsilon_i \quad \dots\dots\dots (3.13)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (\varepsilon_i - \mu)^2 \quad \dots\dots\dots (3.14)$$

とした時,

$$k = \frac{n \sum_{i=1}^n (\varepsilon_i - \mu)^4}{\sigma^4} - 3 \quad \dots\dots\dots (3.15)$$

で求まる。

ノイズの分布を正規分布と仮定した場合、誤差分布はベルカーブ状となる。また、ノイズが少ない点群の場合、フィッティングされた面の精度が良く、分布の分散が低く平均値付近での度数が高い。よって、適切な面をもつ小格子の誤差分布の尖度は、正規分布の尖度よりも大きい事が期待される。そこで、 $k \geq 0$ であればその面は適切であると判断し、そうでなければ不適切と判断する。

3.3.3 結合プロセス

結合プロセスでは、面の法線ベクトルの類似度を用い、各大格子内にある小格子同士を領域成長法で結合し、格子サイズを大きくしながらクラスタを形成していく。形成された各クラスタをそれぞれ 1 つの格子として扱うことで、大格子が異なる大きさを持つ複数の格子で分割される。この時、各小格子にフィッティングされた面により、結合処理を分岐させる。小格子分割プロセスにおいて適切とされた面を持つ小格子は、隣接した小格子のうち、どこのクラスタにも所属せず、法線の類似度が閾値以上あるものと結合して、クラスタを形成する。不適切とされた面を持つ小格子は、隣接した面の中で最も類似度の高い法線を持つ格子と結合し、クラスタを形成する。このとき、結合する格子が既にいずれかのクラスタに含まれていた場合、不適切な面を持つ格子もそのクラスタに含ませる。小格子の結合手順は、以下のようになる。

- 1) 結合済みリストを初期化する
- 2) 結合リスト・対象スタックを初期化する
- 3) 結合済みリストに存在しない格子一つを結合リスト・対象スタックに入れる
- 4) 対象スタックから一つの格子を取り出す
- 5) 小格子分割プロセスにおいて適切・不適切の判断がなされた面により、処理を分岐させる
 - a) 小格子分割において適切とされた面
 - a 1) 候補スタックを初期化し、対象とした格子の周囲 4 格子のうち、結合済みリストに存在しない格子を候補スタックに入れる
 - a 2) 候補スタックから格子を一つ取り出す

- a 3) 取り出した格子の面と、対象とした格子の面との類似度を算出する
- a 4) 類似度が閾値以上であれば取り出した格子を結合リスト・対象スタックに追加する
- a 5) 候補スタックが空になるまで a 2～a 4 を繰り返す
- b) 小格子分割において不適切とされた面
 - a 1) 対象とした格子の周囲 4 格子の面と、対象とした格子の面との類似度を算出する
 - b 2) 最も類似度が高い格子に対して、その格子が結合済みリストに存在しない場合は結合リストに追加し、結合済みリストに存在する場合は対象とした格子を同じ結合リストに追加する
- 6) 対象スタックが空になるまで 3～5 を繰り返す
- 7) 結合リストを結合済みリストに追加する
- 8) すべての格子が結合済みリストに入るまで 2～7 を繰り返す

手順 8 を終え、最終的に結合済みリストに存在する各結合リストが、結合された各面を表す。法線ベクトルの類似度は、 $\vec{v}$ と $\vec{u}$ を法線ベクトルとして、コサイン距離で求める。コサイン距離はベクトル間の長さ方向の相似性を計測するもので、

$$d_{cos} = \frac{\vec{v} \cdot \vec{u}}{|\vec{v}||\vec{u}|} \dots\dots\dots (3.16)$$

で求める (Garcia, 2015)。コサイン距離の閾値は試行錯誤的に決定し、おおよそ 15° のずれを許容する 0.93 を用いた。このプロセスにより、最小二乗法で各クラスタ内に求めた面を、VBS により推定された面とする。

3.4 VBS による面の推定実験

3.4.1 実験内容と手順

3.2, 3.3 にて、DiAna における格子分割処理を自動的かつ点群に適切な形状で分割し面を推定する VBS のアルゴリズムについて述べた。ここでは、瑞浪超深地層研究所で取得された点群に対して VBS を用いて面を推定し、既存の手法である DiAna アルゴリズムと比較してどの程度面の推定精度が得られるかを、実験にて比較した。

3.4.1.1 実験機器とデータ

本実験は、日本原子力研究開発機構 (NUMO) の瑞浪超深地層研究所・深度 300m 研究アクセス坑道 (図 3.4.1.1-1) にて、2006 年 10 月 26 日に、気温 12.0°C・気圧 1000.0mbar・湿圧 8.4mbar の環境で、RIEGL 社の 3D Terrestrial Laser Scanner シリーズである LMS-Z360i によって取得された点群データを対象に行う。点群データを取得した LMS-Z360i の詳細な仕様は、以下のとおりである。

表 3.4.1.1-1 LMS-Z360i の仕様

性能名	値
レーザークラス	1
距離	60～200m
精度	±6～12mm
速度	8, 000～12, 000points/sec
垂直計測角	90°
垂直最小稼動角	0.01°
垂直解像度	0.002°
水平計測角	360°
水平最小稼動角	0.01°
水平解像度	0.0025°
波長	赤外線付近
焦点距離	2～∞m
計測方法	time-of-flight
操作	PC による遠隔操作

表 3.4.1.1-2 LMS-Z360i から得られるデータのフォーマット

名前	説明
ID	点の番号
X	x 座標[m]
Y	y 座標[m]
Z	z 座標[m]
Range	距離[m]
Theta	x 軸周りの回転角[deg]
Phi	z 軸周りの回転角[deg]
R	R 成分[0..255]
G	G 成分[0..255]
B	B 成分[0..255]
Intensity	反射強度[-2047..2048]

深度 300m 研究アクセス坑道は 71 回の掘削サイクルによって掘削され、1 回の掘削サイクル毎の掘削長は 1.0～1.7m である。壁面観察も掘削サイクル毎に行われ、それぞれの観

察区間には主立坑側から順に管理番号が振られている（早野ほか，2017）。3D レーザースキャナによる壁面のスキャンニングも，同様に区間毎に行われている。本実験では，地盤工学会の岩盤分類（地盤工学会基準部，2003）に基づき，断層の影響が少なく B 級岩盤と評価される区間(観察区間 No.31～No.71)を対象に VBS を適用した。中でも，掘削前から天然の不連続面が明らかに存在するであろう 8 区間分(No.54～No.61)の LIDAR データを用いて，実験を行った。トンネルの設計上のサイズを，図 3.4.1.1-2 に示す。トンネルの幅は 4.6m，天蓋頂点の高さは 3.5m である。

対象とする不連続面は，地質専門家により観察された不連続面のうち，底盤からの基準線であるスキャンラインと交差し，かつ 1m 以上の長さを持つ主要な不連続面に限定した。この条件は，スキャンライン法（鶴田ほか，2016）で不連続面の大きさと方向および密度の分布を評価するために，必要な不連続面を効率良く標準的に取得する観点から設定された。スキャンラインは，設計上の底盤から 1.2m の高さに設定されている。各区間における対象とする不連続面の地質専門家によるスケッチを，図 3.4.1.1-3 から 3.4.1.1-10 に示す。図中の赤線が対象とする不連続面であり，スケッチに記された不連続面番号を図中に記す。




図 3.4.1.1-1 瑞浪超深地層研究所における研究坑道の概要（上）

深度 300m アクセス坑道の全体図（下）（鶴田ほか，2016; JAEA，2012b より一部改）




図 3.4.1.1-2 坑道の設計上の断面図（単位はミリメートル）




図 3.4.1.1-5 坑道 No.56 のスケッチ

JAEA (2012a), 地質記載シート_300m アクセス坑道_056 より一部改




図 3.4.1.1-6 坑道 No.57 のスケッチ

JAEA (2012a), 地質記載シート_300m アクセス坑道_057 より一部改)




図 3.4.1.1-8 坑道 No.59 のスケッチ

IAEA (2012a), 地質記載シート_300m アクセス坑道_059 より一部改




図 3.4.1.1-10 坑道 No.61 のスケッチ

JAEA (2012a), 地質記載シート_300m アクセス坑道_061 より 一部改)

なお、各区間の点群データは 3.2 に示す前処理を行っている。点数は約 600 万点である。また、点群データ上には、一つ前の区間に塗布された吹き付けコンクリートがスキャンされている個所がある。そのような個所は、目視で点群を確認し、手動で取り除いてある。それらの点を取り除いた後の 1 区間の点群の点数は約 300 万点となる。点群を展開した際の大きさは、横幅約 9.6m、縦幅が各区間の深さと等しく、奥行が約 0.2m の直方体となっている。展開後の点群データを、図 3.4.1.1-11 と図 3.4.1.1-12 に示す。図中の赤枠がスケッチに記された不連続面を含む部分である。




図 3.4.1.1-11 展開後の点群データ (No.54～No.57)




図 3.4.1.1-12 展開後の点群データ (No.58～No.61)

3.4.1.2 実験手順

実験手順は、まず、推定された面の精度を評価する際に用いる面を、手動で作成した。これを参照面と呼ぶ。参照面は、以下の手順で作成する。なお、作成の際には、Kitware 社の点群処理ソフトである ParaView 3.98 (Kitware, 2013) にて点群を表示させ、図 3.4.1.1-3 から図 3.4.1.1-10 の様な地質専門家によるスケッチ・坑道壁面の写真と表示されている点群を照らし合わせながら ParaView の点群分割機能を用いて加工し、出力している。

- 1) ある 1 区間分の点群を $0.2 \times 0.2 \times 0.4\text{m}$ の格子で分割する
- 2) 各格子のうち、主要な不連続面を表していると考えられる点群が含まれている格子を目視で判別する (図 3.4.2.1a)
- 3) 判別した格子に含まれる点群を手動で面を構成するグループに分割する (図 3.4.2.1c)
- 4) 各グループ内にて手動でノイズをカットし (図 3.4.2.1c)、最小二乗法にて面を推定する (図 3.4.2.1d)

次に、VBS アルゴリズムを用いて面を推定した。この時、参照面を作成した際に分割した点群を大格子分割の結果として小格子分割に利用した。その後、推定した面と参照面との類似度を算出した。




図 3.4.1.2 参照面の作成手順 (坑道 No.54 の不連続面 1 : 格子番号 005_007_000)

(a)の青い部分が不連続面 1 を含む格子, (b)が格子番号 005_007_000 の点群,
(c)が手動でグループに分割した後ノイズカットした点群, (d)が推定した面

ここで、VBS と参照面とはノイズ除去手法やクラスタの構成が異なるため、格子内の点群の要素数や面フィッティングに用いられた点も異なると考えられる。すなわち、ほぼ全ての VBS のある小格子内の点群の集合 B_{vbs}^J と参照面のある小格子内の点群の集合 B_{ref}^K について、 $|B_{vbs}^J - B_{ref}^K| > 0$ または $|B_{ref}^K - B_{vbs}^J| > 0$ である。このことから、ある不連続面全体において $B_{share} = B_{vbs}^J \cap B_{ref}^K$ となる共通要素の集合 B_{share} について、 $p_i \in B_{share}$ となる共通点 p_i ごとに B_{vbs}^J による面と B_{ref}^K による面との類似度を算出し、全ての点の類似度の平均値から不連続面単位での類似度 SIM を求めた。

ここで、ある小格子 B_{vbs}^J が成す面と B_{ref}^K が成す面とが類似している時、面の法線のコサイン距離が1に近づくほか、各小格子の共通要素以外の要素の数 $|B_{vbs}^J \cup B_{ref}^K - B_{share}|$ も0に近づく。すなわち小格子に含まれる点が類似しているため、参照面のクラスタと類似したクラスタがVBSにより推定されたと考えられる。従って、線形最小二乗法がただ1つの解を持つことから面の誤差分布も類似しており、その分布上の点の位置も類似している必要がある。よって、分布上の点の位置に近いほど面の類似性が高く、遠いほど類似性が低いと考えられる。そこで、面と点の誤差を考慮した係数 η_i を求め、 η_i を用いて(3.16)式による法線のコサイン距離 d_{cos}^i を補正した。この補正後のコサイン距離を、ある共通点 p_i における面の類似度とした。係数 η_i は、点 p_i における誤差 ε_e と ε_r を各誤差分布の平均と標準偏差で正規化した z_e^i と z_r^i を用いて導出した。この時、 z_r^i を平均値とした正規分布を考えると、 z_e^i と z_r^i の差 $|z_e^i - z_r^i|$ の99.73%は分散3以内にあることから、

$$\eta_i = \begin{cases} 1 - \frac{|z_e^i - z_r^i|}{3} & \text{if } |z_e^i - z_r^i| \leq 3 \\ 0 & \text{others} \end{cases} \dots\dots\dots (3.17)$$

で係数 η_i を求めた。

以上より、ある不連続面に対する類似度 SIM を、共通点の数を n として、各共通点における面の類似度の平均値

$$SIM = \frac{1}{n} \sum_{i=1}^n \eta_i \cdot d_{cos}^i \dots\dots\dots (3.18)$$

で求めた。

次に、DiAna に基づいた3つの処理（点群の立方格子分割・ノイズ除去・最小二乗法による面推定）を行うプログラムを作成し、このプログラムで推定した面と参照面との間での類似度を(3.18)式にて算出した。

最後に、VBS での類似度と DiAna での類似度を比較した。類似度の比較には棒グラフを用いたほか、分散分析と Tukey の HSD 検定を用いて類似度の平均値の有意差を確認した後、不連続面毎に類似度の順位をつけ、順位統計として平均順位を確認した。平均順位は、ウィルコクソンの順位和検定でその有意差を確認した。また、それぞれの不連続面を表す点群を ParaView 上に表示し、目視で不連続面を判別してその形状を比較した。

なお今後、分かりやすさのため、不連続面は「区間番号-アルファベット」の形で記述す

る。アルファベットは、壁面観察シートにて不連続面に割り当てられた番号に対して、昇順に A, B, C…と割り当てる。例えば図 3.4.1.1-3 にある区間 No.54 の不連続面 01 は 54-A, 不連続面 08 は 54-B, 不連続面 12 は 54-C となる。

3.4.1.3 分散分析について

分散分析は、観測データにおける変動を誤差変動と各要因およびそれらの交互作用による変動に分解することによって、要因および交互作用の効果を判定する統計的仮説検定の一手法で、3 つ以上の平均値の相違を検討する場合に用いられる。帰無仮説と対立仮説は、

帰無仮説：全ての水準において平均値が等しい

対立仮説：2 つ以上の水準間において平均値が等しくない

である。

3.4.1.4 Tukey の HSD (honestly significant difference) 検定について

分散分析では対象とする全群に対して一度に検定を行うため、特定の対の比較に関しての有意差は得られない。その場合、各対において各々 t 検定などを行う必要があるが、3 群以上の検定に t 検定を用いる事は妥当ではない (永田, 1998)。例えば A, B, C の 3 群があったとし、それぞれ平均値 $A=B=C$, かつ分散値 $2A=2B=2C$ と仮定する。A と B の差の検定で帰無仮説が採択される事象を AB, 同様に B と C では BC, A と C では AC とする。

AB' , BC' , AC' は背反の事象, すなわち対立仮説が採択される事象とする。ここで A, B, C

に対する t 検定のそれぞれ有意水準の確率を 5% とおくと, $P_{[AB]} = P_{[BC]} = P_{[AC]} = 0.95$,

$P_{[AB']} = P_{[BC']} = P_{[AC']} = 0.05$ である。正しい判定は、全ての場合において「帰無仮説が採択されたとき」である。誤りの判定 Er は、少なくとも一つの検定で「帰無仮説が棄却されたとき」であるから, $P_{[Er]} = P_{[AB \cap BC \cap AC]} = 1 - 0.95^3 = 0.143$ となる。従って、約 3 倍の第 1 種過誤 (Type I error) が生じてしまう。これは検定数によって増加し、一般に $1 - (1 - \alpha)^k$ (α = 検定の有意水準, k = 検定数) で表せる。このことから、3 群以上の比較には t 検定は妥当ではない (対馬, 2001)。

よって、多重比較法を用いる。多重比較法の定義は、平田は「いくつかの水準・群がある。その相互に平均値的な値 (パラメータとして数値で表現出来ればそれでよい) において、差異があるかどうかを検定という推測形式で確認したい。水準・群の各対で検定を行うと多重性のために公称の有意水準に比べて、第 1 種の過誤の確率が大きくなる。この現象を防ぐために多重性を考慮した公称の有意水準、つまり棄却限界値あるいは棄却域の調整を行って検定する。このやり方を多重比較法という。」としている (平田, 2012)。

本研究では多重比較法の一つである Tukey の HSD 法を用いる。Tukey の方法はパラメトリックな群間で全ての対比較を同時に検定するための多重比較法で、1) 母集団分布は

正規分布とする、2) 比較対象となる全ての群の母分散は等しい、の2つの条件を満たす場合に用いられる。よって、本研究で求めた類似度の集合に対しても、以上の条件を満たすものであると仮定している。

群数を p 、各群におけるデータ数を n 、群 i の平均値を μ_i 、全体平均を $\bar{\mu}$ 、群内平均平方和を $MS_{error} = \frac{\sum_{k=1}^p (\mu_k - \bar{\mu})^2}{p}$ とする。この時、検定を行う群 i, j に対し $qT = \frac{\mu_i - \mu_j}{\sqrt{\frac{MS_{error}}{n}}}$ を統計量とす

る。これを、 $Q_{p, df}$ が従うスチューデント化された範囲の分布からの値と比較する（永田・

吉田, 2012)。有意水準を α とした時、 $qT = \frac{\mu_i - \mu_j}{\sqrt{\frac{MS_{error}}{n}}} > Q_{p, df}(\alpha)$ ならば帰無仮説を棄却する。

条件全体にわたる2つの条件間の平均値の差の検定における Type I error の確率を α 以下に抑えることができる。

$Q_{p, df}$ については、以下のようなものである。いま、 p 個の互いに独立な標準正規分布に

従う確率変数を z_i ($i = 1, \dots, p$)、およびそれらと独立に自由度 df の χ^2 分布に従う確率変

数を χ_{df}^2 とした時、 $Q_{p, df}$ は

$$Q_{p, df} = \max_{1 \leq i, 2 \leq p} \frac{|z_i - z_j|}{\sqrt{\frac{\chi_{df}^2}{df}}} \dots\dots\dots (3.19)$$

となる。また、群 i における個々のデータ値 x_k が独立に、平均 μ_i ・分散 σ^2 に従うとすると、 $(np - p) \cdot MS_{error} = \sum_{i, k} (x_k - \mu_i)^2$ を σ^2 で割ったものは、自由度 $df = np - p$ の χ^2 分布に従う。この時、

$$\begin{aligned} \max_{1 \leq i, 2 \leq p} \frac{|\mu_i - \mu_j|}{\sqrt{\frac{MS_{error}}{n}}} &= \max_{1 \leq i, 2 \leq p} \frac{|\mu_i - \mu_j|}{\sqrt{\frac{\sigma^2}{n}} \cdot \sqrt{\frac{MS_{error}}{\sigma^2}}} \\ &= \max_{1 \leq i, 2 \leq p} \frac{\left| \frac{\mu_i}{\sqrt{\frac{\sigma^2}{n}}} - \frac{\mu_j}{\sqrt{\frac{\sigma^2}{n}}} \right|}{\sqrt{\frac{MS_{error}}{\sigma^2}}} \dots\dots\dots (3.20) \\ &\approx \max_{1 \leq i, 2 \leq p} \frac{|z_i - z_j|}{\sqrt{\frac{\chi_{df}^2}{df}}} \end{aligned}$$

$$= Q_{p, df}$$

が成り立っている(岡本, 2002)。

なお, 帰無仮説・対立仮説は

帰無仮説: 2 群間において平均値が等しい

対立仮説: 2 群間において平均値が等しくない

である。

3.4.1.5 ウィルコクソンの順位和検定について

ウィルコクソンの順位和検定(マン・ホイットニーの U 検定)は最も広く使われているノンパラメトリックな統計的検定手法の 1 つで(Kasuya, 2001), 得られた 2 つの群間の中央値に差があるかどうかを検定する。その際, 観測値の大小を順位尺度に直し, 順位を用いて統計的推定を行う。同順位が存在する場合, 順位の平均を計算してそれぞれに割り当てる。

まず, 両群を混ぜ合わせ, 各データに順位を割り当てる。次に, 統計量として群のサイズが小さい方に割り当てられた順位の和

$$\begin{aligned} T_1 &= n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - R_1 \\ T_2 &= n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - R_2 \end{aligned} \quad \dots\dots\dots(3.21)$$

を計算する(Nachar, 2008)。ここで n_i は群 i のデータ数, R_i が群 i の順位の総和を表す。 T_1 と T_2 のうち, 低い方の値を検定に用いる。

ここで, データ数が大きい場合, 棄却限界値は正規分布による近似を用いることが出来る。平均 $\mu_T = \frac{n_1 n_2}{2}$, 分散 $\sigma_T = \sqrt{\frac{n_1 n_2 (n_1 + n_2 + 1)}{12}}$ として, $z = \frac{T - \mu_T}{\sigma_T}$ について, 標準正規分布における p 値を求め, 有意水準を α とした時, $p > \alpha$ ならば帰無仮説を棄却する。帰無仮説・対立仮説は

帰無仮説: 2 群間において順位の平均値が等しい

対立仮説: 2 群間において順位の平均値が等しくない

である。

3.4.1.6 可視化手法について

本研究では平面を可視化する際, 点群を用いて, ParaView 3.98 にて表示する。平面の式

$$F(x, y, z) = ax + by + cz + d = 0 \text{ について, 平面を構成する一点 } (x, y, z) \text{ のうち } (x, y)$$

を(3.5)式に代入する事で、平面上に存在する一点 (x, y, z') を求めることが出来る。しかし、法線ベクトルが xy 平面に対して水平に近い場合、この手法で作られた面は xy 平面に対して垂直に近く、平面を表す点の密度も低くなり、推定された面を目視で確認することが難しい場合がある。そこで、 $|z'|$ が非常に大きく、平面を表す点が大格子の外側に存在する場合は、その点を削除し描画しない。

3.4.1.7 R について

R は R Development Core Team によりマルチプラットフォームで開発されている、オープンソースの統計解析向けのプログラミング言語である (R Development Core Team, 2013)。オープンソースなので無料で使用でき、様々な解析ツールのライブラリも開発されている。図 3.4.1.7-1 は R のスタートアップ画面で、R Console ウィンドウにて対話型のプログラミングを行うことが出来る。また、図 3.4.1.7-2 の様な R-エディタウィンドウを用いてスクリプトファイルを作成する事で、複数の処理を自動的に実行させることが可能である。

本研究では、分散分析・Tukey の HSD 検定において、R version 3.0.2 に実装されている `anova` 関数と `TukeyHSD` 関数を用いて処理を行った。それぞれの関数の仕様を表 3.4.1.7-1 に記す。また、ウィルコクソンの順位和検定において、R の `exactRankTests` パッケージ ver 0.8-28 にある `wilcox.exact` 関数を用いた。関数の仕様を表 3.4.1.7-2 に記す。




図 3.4.1.7-1 R の起動直後の画面




図 3.4.1.7-2 R エディタによるスクリプトの編集画面

表 3.4.1.7-1 R version 3.0.2 における anova 関数と TukeyHSD 関数の仕様

関数名	主な引数	返り値
anova	object : モデルフィッティングの返り値	検定結果
TukeyHSD	x : 分散分析の結果 which : 使用する群の指定 conf.level : 信頼区間 (初期値は 0.95)	検定結果

表 3.4.1.7-2 exactRankTests ver 0.8-28 における wilcox.exact 関数の仕様

関数名	主な引数	返り値
wilcox.exact	x : 群 A y : 群 B mu : 手動指定の中央値 conf.level : 信頼区間 (初期値は 0.95)	検定結果

3.4.1.8 実行環境について

本研究では、VBS の処理に関して、VMWare 社の VMWare Player 6.0.7 による仮想マシン上で Linux ディストリビューションの一つである CentOS 6.8 を起動し、プログラミング言語 Python 2.6.6 に沿ってプログラミングし、GNOME Terminal 2.31.3 上で Python の実行を行った。図 3.4.1.8-1 は、実際の仮想マシンのスクリーンショットで、赤枠内に各ソフトウェアのバージョンが記されているのが分かる。






図 3.4.1.8-1 プログラムの動作環境

プログラムの構成は、以下のようになる。拡張子.py が付くファイルがプログラムファイルで、そうでない名前はモジュールの名前である。





3.4.2 実験条件

実験で用いた格子の大きさは、大格子で $0.2 \times 0.2 \times 0.4(\text{m})$ ，極小格子で $0.02 \times 0.02 \times 0.02(\text{m})$ ，小格子で $0.067 \times 0.067 \times 0.4(\text{m})$ を用いた。大格子の初期値は数回の試行により定めた。DiAna での格子サイズは、大格子と同等の大きさである $0.2 \times 0.2 \times 0.2 \text{ m}$ ，中間程度のサイズの $0.1 \times 0.1 \times 0.1(\text{m})$ ，小格子と同等の大きさである $0.067 \times 0.067 \times 0.067(\text{m})$ の 3 つのサイズを用いた。以下それぞれ DiAna_L, DiAna_M, DiAna_S とする。

分散分析・Tukey の HSD 検定・ウィルコクソンの順位和検定における有意水準 α は全て 0.05 を用いた。

3.4.3 実験結果

はじめに、VBS で推定した面と参照面との類似度と、DiAna で推定した面と参照面との類似度のグラフを 図 3.4.3-1 に示す。また、各類似度を示した表を表 3.4.3-1 に記す。図 3.4.3-1 を見ると、多くの不連続面で VBS（青）が全体的に高く、次いで DiAna_M（緑）と DiAna_S（灰）、DiAna_L（黄）の順となっていた。表 3.4.3-1 を見ても、同様の傾向が見て取れる。




図 3.4.3-1 VBS で推定した面と参照面との類似度と
DiAna で推定した面と参照面との類似度 (松川ほか, 2017 より転載)

表 3.4.3-1 VBS で推定した面と参照面との類似度と
DiAna で推定した面と参照面との類似度の一覧

	No.54				No.55			
	VBS	DiAna_L	DiAna_M	DiAna_S	VBS	DiAna_L	DiAna_M	DiAna_S
A	0.857	0.752	0.762	0.772	0.545	0.518	0.542	0.553
B	0.768	0.718	0.734	0.711	0.641	0.620	0.539	0.564
C	0.700	0.719	0.709	0.677	0.645	0.609	0.660	0.591
D	-	-	-	-	0.648	0.741	0.725	0.702
E	-	-	-	-	0.581	0.629	0.664	0.679
F	-	-	-	-	0.537	0.576	0.537	0.566
G	-	-	-	-	0.726	0.523	0.659	0.590
	No.56				No.57			
	VBS	DiAna_L	DiAna_M	DiAna_S	VBS	DiAna_L	DiAna_M	DiAna_S
A	0.769	0.716	0.735	0.726	0.697	0.572	0.669	0.695
B	0.736	0.690	0.679	0.696	0.691	0.628	0.644	0.669
C	0.753	0.676	0.668	0.700	0.702	0.712	0.729	0.676
D	0.625	0.709	0.713	0.671	0.655	0.637	0.622	0.662
E	0.642	0.623	0.703	0.715	0.720	0.642	0.655	0.674
F	0.710	0.581	0.657	0.680	0.717	0.657	0.665	0.685
G	-	-	-	-	0.674	0.603	0.649	0.672
	No.58				No.59			
	VBS	DiAna_L	DiAna_M	DiAna_S	VBS	DiAna_L	DiAna_M	DiAna_S
A	0.713	0.628	0.636	0.661	0.587	0.543	0.536	0.423
B	0.702	0.624	0.679	0.688	0.546	0.606	0.629	0.668
C	0.553	0.492	0.493	0.578	0.653	0.609	0.580	0.532
D	0.510	0.482	0.535	0.558	0.735	0.705	0.719	0.707
E	-	-	-	-	-	-	-	-
F	-	-	-	-	-	-	-	-
G	-	-	-	-	-	-	-	-
	No.60				No.61			
	VBS	DiAna_L	DiAna_M	DiAna_S	VBS	DiAna_L	DiAna_M	DiAna_S
A	0.614	0.616	0.592	0.648	0.663	0.506	0.663	0.622
B	0.607	0.586	0.661	0.673	0.709	0.580	0.707	0.663
C	0.713	0.710	0.676	0.690	0.613	0.603	0.648	0.683
D	0.611	0.577	0.624	0.622	0.665	0.604	0.669	0.658
E	0.598	0.639	0.604	0.586	0.807	0.607	0.631	0.572
F	-	-	-	-	-	-	-	-
G	-	-	-	-	-	-	-	-

3.4.3.1 分散分析による類似度の平均値における有意差の確認

まず、表 3.4.3-1 に示した類似度の平均値に有意差が存在するか、分散分析を使って確認した。本研究では、1 つの不連続面において推定された面と参照面との共通点の類似度を、ある 1 つの母集団から得られた標本と見做した。よって、要因 1 つ、水準が VBS と DiAna_L, DiAna_M, DiAna_S の 4 つ、共通点の類似度を要素とする一元配置分散分析(対応なし)を実行した。なお、要素数はそれぞれ異なる。帰無仮説と対立仮説は、

帰無仮説：全ての水準において平均値が等しい

対立仮説：2 つ以上の水準間において平均値が等しくない

である。また、計算には統計解析用のソフトウェアである R version 3.0.2 を用いた。

表 3.4.3.1-1 は、得られた p 値である。表では、計 41 個の不連続面のうち 55-F を除く 40 個の不連続面において 5%水準で有意となり、帰無仮説が棄却され平均値に有意差があることが確認できる。また、5%水準を満たさなかった不連続面 55-F については、10%水準で有意傾向があった。以下、不連続面 55-F を除き、有意差が確認できた 40 個の不連続面を比較に用いた。

表 3.4.3.1-1 分散分析によって得られた p 値の一覧

Discontinuity	p-value	Discontinuity	p-value
54-A	2.20E-16	58-A	2.20E-16
54-B	2.20E-16	58-B	2.20E-16
54-C	2.66E-10	58-C	2.20E-16
55-A	1.01E-05	58-D	2.28E-10
55-B	2.20E-16	59-A	2.20E-16
55-C	2.20E-16	59-B	9.87E-14
55-D	2.20E-16	59-C	2.20E-16
55-E	6.43E-14	59-D	2.57E-03
55-F	5.89E-02	60-A	1.24E-04
55-G	1.00E-15	60-B	2.20E-16
56-A	2.20E-16	60-C	3.38E-11
56-B	2.20E-16	60-D	1.69E-04
56-C	2.20E-16	60-E	1.59E-02
56-D	2.20E-16	61-A	2.20E-16
56-E	2.20E-16	61-B	2.20E-16
56-F	2.20E-16	61-C	2.20E-16
57-A	2.20E-16	61-D	2.74E-12
57-B	2.20E-16	61-E	2.20E-16
57-C	4.80E-12		
57-D	9.23E-03		
57-E	2.20E-16		
57-F	1.34E-05		
57-G	2.20E-16		

また、各水準間での有意差を調べるため、Tukey の HSD 検定で多重比較を行った。こちらでは、不連続面 40 個において、VBS と DiAna_L, DiAna_M, DiAna_S のうち 2 つを取る組み合わせ計 240 組について有意差を検定した。表 3.4.3.1-2 は得られた p 値を示す。表では、240 組中約 70%となる 166 組が 5%水準で有意となった。しかし、約 30%となる 74 組においては有意とならなかった。有意とならなかった組は、次節で順位を比較する際、同順位として扱う。

3.4.3.2 類似度の平均値における順位の比較

次に、55-F を除く 40 個の不連続面について、(3.18)式で求めた各アルゴリズム間での各不連続面における SIM に順位をつけ、順序尺度にて比較を行った。順位付けは、ある不連続面で求めた各アルゴリズムでの SIM について、最も高い値を持つアルゴリズムを 1 位、次に高い値を 2 位、3 位、最も低い値を 4 位とした。また、比較のために順位の積み上げ棒グラフと平均値を求めた。

ここで、3.4.3.1 の多重比較にて有意とならなかった組は、類似度の母平均がほぼ同じであり、すなわち 2 つの面がおおよそ同程度の精度で推定されていたと考えられる。よって本研究では、類似度の順位付けをする際、それらの組は同じ母集団から標準化された値を持つと見做し、同順位として扱った。その際、複数の組で有意とならない場合、例えば VBS - DiAna_M, DiAna_M - DiAna_S, DiAna_S - VBS の間で有意とならない場合は、VBS, DiAna_M, DiAna_S は同順位とした。しかし、DiAna_S - VBS の間では有意となるような場合は、全てを同順位に扱うのは妥当でない。その様な場合、VBS - DiAna_M, DiAna_M - DiAna_S の間での p 値を比べ、大きい数値を持つ組を同順位として扱った。また、例えば VBS が 1 位かつ DiAna_L と DiAna_M が 2 位となる場合、DiAna_S は 4 位とした。

図 3.4.3.2-1 は順位の積み上げ棒グラフで、緑が 1 位の割合、赤が 2 位、紫が 3 位、茶が 4 位の割合を表す。また、横軸がアルゴリズムを、縦軸が順位の割合を表す。図 3.4.3.2-1 を見ると、1 位となる割合が最も大きいのが VBS で、次いで DiAna_S, DiAna_M, DiAna_L と続いていた。VBS とその次に大きい DiAna_S とを比べると、約 2 倍の数の不連続面について、VBS の類似度の方が高い順位となった。また、4 位となる割合は DiAna_L が最も大きく、次いで DiAna_S, VBS, DiAna_M となっていた。また、表 3.4.3.2-1 はその順位となった回数と順位の総和、平均、標準偏差を示している。順位の総和は、順位とその順位となった回数の積から求めた。平均は総和を不連続面の数 40 で割った値であり、標準偏差はこれらの値を用いて求めた。VBS は 1 位の数が最も多く、順位の総和・平均が最も低くなっていた。

表 3.4.3.1-2 Tukey の HSD 検定による p 値の一覧

Discontinuity	DiAna_M & DiAna_L	DiAna_S & DiAna_L	VBS & DiAna_L	DiAna_S & DiAna_M	VBS & DiAna_M	VBS & DiAna_S	Discontinuity	DiAna_M & DiAna_L	DiAna_S & DiAna_L	VBS & DiAna_L	DiAna_S & DiAna_M	VBS & DiAna_M	VBS & DiAna_S
54-A	0.002	0.000	0.000	0.015	0.000	0.000	58-A	0.360	0.000	0.000	0.000	0.000	0.000
54-B	0.004	0.559	0.000	0.000	0.000	0.000	58-B	0.000	0.000	0.000	0.335	0.000	0.047
54-C	0.364	0.000	0.004	0.000	0.366	0.001	58-C	0.999	0.000	0.000	0.000	0.000	0.110
55-A	0.007	0.000	0.174	0.461	0.998	0.918	58-D	0.000	0.000	0.044	0.244	0.127	0.000
55-B	0.000	0.000	0.266	0.022	0.000	0.000	59-A	0.739	0.000	0.000	0.000	0.000	0.000
55-C	0.000	0.076	0.010	0.000	0.534	0.000	59-B	0.049	0.332	0.000	0.725	0.000	0.006
55-D	0.001	0.000	0.000	0.000	0.000	0.000	59-C	0.001	0.004	0.000	0.151	0.000	0.000
55-E	0.000	0.000	0.025	0.208	0.000	0.000	59-D	0.259	1.000	0.001	0.964	0.229	0.699
55-F	0.078	0.936	0.487	0.189	1.000	0.684	60-A	0.231	0.070	0.999	0.000	0.113	0.008
55-G	0.000	0.000	0.000	0.000	0.313	0.002	60-B	0.000	0.000	0.000	0.002	0.000	0.000
56-A	0.000	0.142	0.000	0.312	0.312	0.312	60-C	0.000	0.048	0.987	0.116	0.000	0.000
56-B	0.062	0.621	0.000	0.009	0.000	0.000	60-D	0.000	0.001	0.006	0.996	0.400	0.589
56-C	0.519	0.001	0.000	0.000	0.000	0.000	60-E	0.127	0.013	0.030	0.641	0.972	0.791
56-D	0.860	0.000	0.000	0.000	0.000	0.000	61-A	0.000	0.000	0.000	0.088	1.000	0.045
56-E	0.000	0.000	0.022	0.506	0.000	0.000	61-B	0.000	0.000	0.000	0.000	0.980	0.000
56-F	0.000	0.000	0.000	0.548	0.001	0.223	61-C	0.000	0.000	0.462	0.000	0.000	0.000
57-A	0.000	0.000	0.000	0.000	0.000	0.979	61-D	0.000	0.000	0.000	0.679	0.000	0.854
57-B	0.100	0.000	0.000	0.047	0.000	0.063	61-E	0.256	0.092	0.000	0.001	0.000	0.000
57-C	0.027	0.000	0.173	0.000	0.000	0.001							
57-D	0.593	0.240	0.224	0.041	0.024	0.946							
57-E	0.357	0.012	0.000	0.376	0.000	0.000							
57-F	0.942	0.584	0.000	0.848	0.005	0.483							
57-G	0.000	0.000	0.000	0.006	0.000	0.988							




図 3.4.3.2-1 類似度の順位の積み上げ棒グラフ（松川ほか，2017 より転載）

表 3.4.3.2-1 各順位における回数と順位の総和，平均，標準偏差

	VBS	DiAna L	DiAna M	DiAna S
Number of Rank 1	28	7	14	15
Number of Rank 2	3	8	15	11
Number of Rank 3	5	9	8	10
Number of Rank 4	4	16	3	4
Summation	65	114	80	83
Average	1.625	2.850	2.000	2.075
Standard deviation	1.055	1.145	0.934	1.023

表 3.4.3.2-2 ウィルコクソンの順位和検定における p 値一覧

	DiAna_M & DiAna_L	DiAna_S & DiAna_L	VBS & DiAna_L	DiAna_S & DiAna_M	VBS & DiAna_M	VBS & DiAna_S
p-value	0.002	0.001	0.000	0.640	0.003	0.022

以上の結果から、VBS は平均類似度において DiAna と同等以上の性能であった。しかし DiAna では点群から面を推定する際、点群と推定面との分散の閾値が必要となる。分散の閾値は点群の分割サイズに依存し、手動で試行錯誤的に決める必要がある。本実験においても、値の設定とアルゴリズムの実行を繰り返し、適切であると目視にて判断した値を用いている。VBS では格子サイズの決定のみを必要とし、またボトムアップ的に面を推定する。そのため、手動による試行錯誤的な作業の労力や、判断の依存性もない。すなわち、省力化と平準化を実現しつつ既存の面推定アルゴリズムと同等以上の性能を持つことから、VBS は点群からの面推定において有効なアルゴリズムであると考えられる。

また、統計解析用ソフト R の exactRankTests パッケージ ver 0.8-28³¹⁾を用いてウィルコクソンの順位和検定を行い、VBS, DiAna_L, DiAna_M, DiAna_S のうち 2 つを取る組み合わせそれぞれにおいて平均順位の有意差を検定した。帰無仮説・対立仮説は

帰無仮説：2 群間において平均値が等しい

対立仮説：2 群間において平均値が等しくない

である。その結果、DiAna_M - DiAna_S の間を除く全ての平均値において 5%水準で有意となり、その平均順位に有意差があることが確認できたことから、VBS の優位性が統計的に確認できた。表 3.4.3.2-2 はその p 値を示す。

3.4.3.3 目視での比較

目視比較の一例として、不連続面 54-A を取り上げる。54-A には、格子内の面が図 3.4.3.3-1 の様に単純な階段状となっている大格子が存在する他、斜めに走る面や分岐箇所のように複雑な形状の面を持つ大格子が存在しているため、VBS の近似例を効果的に記載できる。不連続面 54-A に対し、不連続面と判断される面の輪郭線を目視でなぞった図を Fig.10 に示す。図はそれぞれ参照面(図 3.4.3.3-1b), VBS で推定した面(図 3.4.3.3-1c), DiAna_L, DiAna_M, DiAna_S で推定した面(図 3.4.3.3-1d, e, f)を表している。なお、図の面は全て点群で表現されている。

地質観察結果(図 3.4.3.3-1a)を見ると、不連続面 54-A は左端から不連続面が発生しており、途中で分岐してフォーク状に斜めに発達する特徴を持つことがわかる。これについて、参照面は分岐箇所と斜めに発達する不連続面を自然に表現していた。VBS も、大格子から小格子へ分割し小格子を結合した事で、分岐箇所と斜めの不連続面を階段状に表現する事ができた。

しかし、DiAna で推定した面には図 3.3.1.2-1 で示した問題が起き、不適切な面が推定されていた。図 3.4.3.3-1 にて青い楕円で囲んだ箇所がその一例を示している。DiAna_L では格子サイズが大きく、段差や分岐、斜めの面を全て一枚の面で推定するため、格子内に存在する段差や分岐・斜めの面を表現できなかった。また、ノイズが大きく z 軸方向に複数格子ができ、青い楕円内では面の上にも面が推定されていた。DiAna_M は参照面や VBS と類似した線となっていることが分かるが、DiAna_L と同様の問題が起きていた。DiAna_S

では垂直方向に広がる面が推定されている他、 z 軸方向に複数格子ができる問題が発生しており、不連続面の稜線を目視で確認することができなかった。他の不連続面についても、DiAna で不適切に推定された面が VBS では適切に推定されている箇所が存在した。




図 3.4.3.3-1 不連続面 54-A における坑道写真とスケッチ、各アルゴリズムで推定された面の比較（松川ほか，2017 より転載）

3.4.4 結論

本実験では、3D レーザースキャナにより得られた 3 次元点群データから自動的に面を推定し坑道壁面の表面形状を近似するために開発した VBS を用い、VBS による分割結果と既存の手法である DiAna による分割結果とを比較し、VBS の推定精度について確認した。VBS は、点群を大きいサイズの立方格子で分割した後、さらに小さいサイズで分割した格子の中で面をフィッティングし、類似した面を領域成長法で結合していくことで場所に適した格子サイズを自動的に定めて、格子内に含まれる点群から面を推定する。この時、大まかに定めた大格子のサイズのみを処理のパラメータとして必要とし、DiAna に比べパラメータ決定に必要な試行が少ない。

実験では、目視で作成した参照面と VBS で推定した面との類似度と、参照面と DiAna で推定した面との類似度を比較し、VBS の性能を評価した。その結果、目視での比較と類似度の平均値の順位での比較において、VBS が最も参照面と類似していた。

以上より、VBS は大格子サイズのみをパラメータとして定めることで、自動的に点群から面を抽出できる。また、格子を点群の分布により適切なサイズで分割する事により、DiAna アルゴリズムに比べ目視での点群分割・面推定に類似した結果を得ることができた。よって、VBS は 3 次元点群データを用いた地質観察作業の省力化と平準化に有用である事が確認された。

3.5 参考文献

- 国土交通省国土地理院ホームページ：分かりやすい平面直角座標系，
<http://www.gsi.go.jp/sokuchikijun/jpc.html>，引用日 平成 29 年 11 月 21 日
- RIEGL (2007) : RieglLMS.RiSCANPRO.Version1.4.3sp3.SoftwareDocumentation, RIEGL, p.33-34.
- 池田孝博, 青柳領 (2011) : 正規分布からの乖離性に基づく幼児期における運動能力の二極化の検討, 発育発達研究, vol.53, pp.23-35.
- Garcia, E (2015) : Cosine Similarity Tutorial, <http://www.minerazzi.com/tutorials/cosine-similarity-tutorial.pdf>, 引用日 平成 29 年 11 月 21 日.
- 地盤工学会基準部(2003) : 新規制定の地盤工学会基準案「岩盤の工学的分類方法」について, 土と基礎, vol.51(8), pp.67-75.
- Kitware(2013), 2013b Kitware ParaView 3.98, <http://paraview.org/>.
- 永田靖 (1998) : 多重比較法の実際, 応用統計学, vol.27(2), pp.93-108.
- 対馬栄輝 (2001) : 統計的検定資料 ①, <http://www.hs.hirosaki-u.ac.jp/~pteiki/research/stat/multi.pdf>, 引用日 平成 29 年 11 月 21 日.
- 平田篤由 (2012) : 多重比較一過去を振り返れば一, 第 2 期医薬安全研究会第 10 回定例会 web 資料, https://biostat.jp/archive_teireikai_2_download.php?id=35, 引用日 平成 29 年 11 月 21 日.
- 永田靖, 吉田道弘 (2012) : 統計的多重比較法の基礎, サイエンティスト社, 初版 8 刷, pp.145-147.
- 岡本安晴 (2002) : テューキーの方法 Tukey's HSD Test および Tukey-Kramer Test, <http://mcn-www.jwu.ac.jp/~yokamoto/openwww/stat/multicomp/Tukey/readme.pdf>, 引用日 平成 29 年 11 月 21 日.
- Kasuya, E. (2001) : Mann-Whitney U test when variances are unequal, Animal Behaviour, vol.61(6), pp.1247-1249.
- Nachar, N. (2008) : The Mann-Whitney U: A Test for Assessing Whether Two Independent Samples Come from the Same Distribution, Tutorials in Quantitative Methods for Psychology, vol.4(1), pp.13-20.
- R Development Core Team (2013), R version 3.0.2, <https://www.r-project.org/>

第4章 推定された面からの不連続面の判別について

4.1 概要

第3章では、VBSを用いて点群から面を自動的に推定した。しかし、VBSは表面形状を近似した後、推定した平面に対する不連続面と掘削面との判別を行っていない。第1章で述べた3Dレーザースキャナによる壁面観察作業の省力化と標準化を行うためには、点群から面を推定した後、推定した面から不連続面を取得（判別）し、不連続面の特性パラメータを取得する必要がある。

地質専門家による目視での不連続面の判別は、1)面の表面の色、2)面の表面の形状、の2つの特徴を主としつつ、岩盤の特徴や周囲の環境を考慮しながら行っていると考えられる。自動推定においても、この2つの特徴を利用する事を考える。面の色については、1)カメラによるRGB画像は取得精度が低いこと、2)不連続面と掘削面の反射強度による色の差は絶対的なものではなく場所によって変わること、3)湧水などによる表面の濡れが色に影響を及ぼしやすいことから、表面の形状に着目する。

地質専門家の壁面観察結果である割れ目詳細記載シートを見ると、観察時、割れ目の種類や割れ目の形態に注目していることが分かる。図4.1.1は割れ目の形態を分類する画像である(JAEA, 2012a)。それぞれ、

- F) シャープ：鏡面型で、フラットなもの
- R) 凸凹上：凸凹としていて、荒いもの
- S) スリッケンサイドあり：滑動痕跡が在るもの

である。瑞浪超深地層研究所で観察されている不連続面は、そのほとんどがシャープ型であることから、粗い掘削面との表面形状の違いが顕著であることが考えられる。



略称 コード	F (flat)	R (rough)	S (slickensided)
模式図			
記号	シャープ	凸凹状	滑動痕跡在り

図4.1-1 割れ目面の形態割れ目詳細記載シート

(JAEA (2012a), 割れ目詳細記載シート_300m アクセス坑道より抜粋)

そこで本研究では、以上の様に不連続面の表面が鏡肌やスリッケンラインを持つ特徴に着目し、表面形状の違いとしての表面粗さを用いた不連続面と掘削面の判別を試みた。

4.2 推定された面からの不連続面の判別

4.2.1 表面粗さについて

表面粗さとは表面性状の尺度の一つで、物体の表面形状を理想表面と比べたとき、鉛直方向の偏差がどれだけあるかで計られる。偏差が全体に大きければ表面は粗く、小さければ滑らかである。表面粗さの評価方法はいくつか存在している。ISRM (International Society for Rock Mechanics and Rock Engineering) では、表面粗さを定量的に評価する者として、図のような粗さ形状のリストを定義している（岩の力学連合会，1986）。




図 4.2.1-1 JRC プロファイル（岩の力学連合会，1986 より転載）

JRC では、表面粗さの程度により JRC 値を 10 段階に分け、0～20 の値を割り振っている (JRC プロファイルと呼ぶ)。しかし、この値は岩盤表面と JRC プロファイルとを目視で比較して定めるものとなっており、非常に主観的である (村田, 1997)。この問題に対し、Tse らは様々な統計パラメータと JRC との相関を調べ、Z2 と呼ばれる凹凸の勾配の 2 乗平均を表すパラメータと SF (Structure Function) と呼ばれる凹凸の高さの分散を表すパラメータが JRC 評価に有効であることを示した (Tse et al., 1979)。しかしながら、これらの統計パラメータは不連続面の寸法に依存するため、一意的に不連続面の粗さを評価することは不可能である。

定量的な評価として、JIS (Japanese Industrial Standards) 規格の一つである JIS B 0601:2001 がある。JIS B 0601:2001 では、機械加工された表面の粗さを規定している。粗さのパラメータはいくつか定義されているが、そのうち Ra と Rz は頻繁に用いられる。 Ra は算術平均粗さ (calculated average roughness) で、粗さ曲線からその平均線の方に基準長さ l だけを抜き取り、粗さ曲線を $y = f(x)$ で表したときに、

$$Ra = \frac{1}{l} \int_0^l \{f(x)\} dx \quad \dots\dots\dots (4.1)$$

で表される。図 4.2.1-2 の斜線部における高さが Ra であり、水平線 m は粗さの平均を表す。

Rz は最大高さ粗さ (maximum height roughness) であり、粗さ曲線からその平均線の方に基準長さ l だけを抜き取り、図 4.2.1-3 の平均線 m から高さ Rp に描かれる山頂線と、 m から高さ Rv に描かれる谷底線との間隔で

$$Rz = Rp + Rv \quad \dots\dots\dots (4.2)$$

で表される。なお、JIS B 0601:2001 は国際規格である ISO 4287-1997 に準拠している (坂田, 2009)。




図 4.2.1-2 算術平均粗さの概念図 (三菱日立ツール株式会社(2014)より一部改)




図 4.2.1-3 最大高さ粗さの概念図 (三菱日立ツール株式会社(2014)より一部改)

一方、Brown らは岩盤不連続面の表面形状が広い寸法範囲にわたってフラクタル構造となっていることを示した(Brown et al., 1985)。以降、寸法に依存しないパラメータであるフラクタル次元を用いて表面粗さを評価する研究が行われるようになってきた(Lee et al., 1990; Huang et al., 1992; Odling, 1994; Kulatilake, 1995)。Du らは岩盤表面のフラクタル特性とせん断強度との関係について求め(Du ほか, 1997)、大西らは画像処理によって不連続面のフラクタル特性を評価している(大西ほか, 1989)。また、茂野らはフラクチャー(割れ目)の生成シミュレーションにおいて、フラクタル性のある割れ目を複数生成している(茂野ほか, 2005)。以上のことから、フラクタル次元を用いる事で、異なる性質の表面を持つ面の区別ができると考えられる。

フラクタル次元はマンデルブロにより定義された値である。対象とする形が d 次元ユークリッド空間 R^d 内に存在し、対象を半径 ε の d 次元球で被覆した際の球の最小個数を $N(\varepsilon)$ とした時、

$$D = \lim_{\varepsilon \rightarrow 0} \frac{\log \frac{N(\varepsilon)}{\varepsilon}}{\log \frac{1}{\varepsilon}} \dots\dots\dots (4.3)$$

で表される。

フラクタル次元は表面粗さのパラメータとして非常によくも陥られている。しかし、岩盤不連続面は Fig.1 に示したように、図形の一部を垂直方向、水平方向ともに等倍で拡大したときに元の図形と統計的に相似な図形となる自己相似のフラクタルとは異なり、図形の一部を拡大したときに元の図形と統計的に相似な図形となるためには垂直方向、水平方向それぞれ異なる倍率で拡大する必要のある自己アフィン性を持つフラクタルとなっていることも知られている(村田ほか, 1997; Rahman et al., 2006)。そこで、フラクタル次元と粗さの最大・最小高さの差を利用して自己アフィン性を持つ表面粗さを算出する Roughness-length 法(Rahman et al., 2006)も存在する。自己アフィン性を持つフラクタルにおいて、表面粗さの標準偏差とサンプリング幅との間には $S(w) = Aw^H$ の関係がある。ここで、 $S(w)$ はサンプリング幅 w における表面粗さの標準偏差、 A は比例定数 $H = E - D$ 、で E がユークリッド空間の次元、 D が自己アフィン性を持つフラクタル次元である。

また、ここで、

$$S(w) = RMS(w) = \frac{1}{n_w} \sum_{i=1}^{n_w} \sqrt{\frac{1}{m_i - 2} \sum_{j \in w_i} (z_i - \bar{z})^2} \dots\dots\dots (4.4)$$

となる。 n_w は被覆幅 w_i における被覆領域数、 m_i は1つの被覆領域に含まれる点数、 z_i が観測値と基準値との差、 $\bar{z}$ は被覆領域 w_i における z_i の平均である。以上より、

$$\begin{aligned}
\log(S(w)) &= \log_e A + H \log_e w \\
&= \log_e A + (E - D) \log_e w \\
D \log_e w &= \log_e A + E \log_e w - \log(S(w)) \\
&= \log_e A + E \log_e w - \frac{1}{n_w} \sum_{i=1}^{n_w} \sqrt{\frac{1}{m_i - 2} \sum_{j \in w_i} (z_i - \bar{z})^2} \dots\dots\dots (4.5)
\end{aligned}$$

にて、 D を求めることが出来る。

4.2.2 利用する表面粗さの検討

本研究では、地質観察作業の省力化と平準化のため、表面粗さを定量的に求める必要がある。そこで、フラクタル次元（以下FD）、算術平均粗さ（以下 R_a ）、最大高さ粗さ（以下 R_z ）、Roughness-length（以下RIM）の4つの表面粗さに着目し、不連続面と掘削面との判別可能性について検討した。まず、第3章で作成した No.54 の不連続面3種類における参照面について、4つの表面粗さを用いて不連続面と掘削面との判別を試みた。正解データとなる参照面の不連続面と掘削面の分別は、ParaView で参照面を表示しつつ、坑道壁面の写真・地質専門家によるスケッチと比較しながら、目視で行った。図 4.2.2-1 から 4.2.2-3 は実際の分別結果で、数字が参照面の ID、その中の赤い数字で書かれた ID の面が不連続面部分である。




図 4.2.2-1 不連続面 54-A にて判別した掘削面（灰字）と不連続面（赤字）




図 4.2.2-2 不連続面 54-B にて判別した掘削面（灰字）と不連続面（赤字）



図 4.2.2-3 不連続面 54-C にて判別した掘削面（灰字）と不連続面（赤字）

次に、これらの参照面各々について、4つの表面粗さを算出した。最後に、各表面粗さに対して掘削面・不連続面を判別する決定境界が引けるかどうか、各表面粗さと参照面の目視による分別結果との間の相関比と、各表面粗さのヒストグラム類似度を用いて確認した。相関比は2変数のうち一方が量的変数、もう一方が名義尺度である場合に、2つの変数間の相関の程度を表す統計量で、

$$R = \frac{SB}{Sw + SB} \dots\dots\dots (4.6)$$

で求めた。ここで $Sw = \sum_{i=1}^C \sum_{j=1}^N (x_j - \bar{x}_i)^2$, $SB = C \sum_{i=1}^C (\bar{x}_i - \bar{x})^2$ で、 C が参照面の総数、 N が点数、 x_j がある点と参照面との距離、 $\bar{x}_i$ がある点と参照面との距離の平均を表す。 R は 0 から 1 までの値をとり、1 に近づくほど相関が強いと言える。

ヒストグラム類似度は 2 つのヒストグラム間の類似性を図る尺度で、本研究ではヒストグラムを確率分布とした時の距離 Bhattacharyya Coefficient (BC) と (Bhattacharyya, 1946)、ヒストグラムの重複部分の大きさを表す Histogram Intersection (HI) (Swain et al, 1991) の 2 種類を用いた。それぞれ、

$$BC = \sum_{i=1}^N \sqrt{p_i q_i} \dots\dots\dots (4.7)$$

$$HI = \sum_{i=1}^N \min(p_i, q_i) \dots\dots\dots (4.8)$$

で求めた。 N はヒストグラムのビン数、 p_i , q_i はビン i における各度数で、 $\sum p_i = \sum q_i = 1$ である。どちらもヒストグラムが完全に一致すると 1、重複箇所がないと 0 となる。

図 4.2.2-4 は、54-A にて実際に求めた表面粗さを各面毎にまとめたグラフで、横軸が掘削面 or 不連続面のラベル、縦軸が表面粗さの値である。左上が FD 、右上が R_a 、左下が R_z 、右下が R_{lm} である。青い点が各掘削面における表面粗さで、オレンジの点が各不連続面における表面粗さを表す。グラフを見ると、どの表面粗さにおいても、掘削面・不連続面で中央値の差があまり見られないことが分かる。よって、掘削面・不連続面の表面粗さの母集団の間に差が無いことが考えられる。




図 4.2.2-4 不連続面 54-A における表面粗さ

表 4.2.2-1 54-A から 54-C における相関比の一覧

	Correlation Ratios			
	FD	Ra	Rz	RIM
54-A	0.021	0.105	0.052	0.137
54-B	0.000	0.028	0.018	0.004
54-C	0.094	0.000	0.000	0.003

また、表 4.2.2-1 に、各不連続面に対して求めた相関比を示す。表を見ると、どの相関比も非常に低く、最大でも 0.137 となり、非常に弱い相関であることが分かる。よって、掘削面・不連続面の判別が難しいことが考えられる。

次に、各表面粗さのヒストグラムとヒストグラム類似度を示す。図 4.2.2-5 はビン数 10 で作成したヒストグラムで、横軸にビン、縦軸に度数 (生起確率) を示している。左上が FD、右上が R_a 、左下が R_z 、右下が R_{lm} である。また、青いビンが各掘削面における表面粗さで、オレンジのビンが各不連続面における表面粗さを表す。図 4.2.2-5 を見ると、どのヒストグラムも重複している個所が大きいことが確認できる。また、算出したヒストグラム類似度を表 4.2.2-2 に示す。どのヒストグラム類似度も大きい値をとり、掘削面・不連続面ともによく似たヒストグラムとなっていることが分かる。

以上より、各表面粗さと掘削面・不連続面との相関は非常に低く、また掘削面・不連続面間の表面粗さのヒストグラムも類似していることから、表面粗さ単体では決定境界を上手く引くことが出来ず、掘削面・不連続面の判別は難しいと考えられる。

しかし、各表面粗さ単体でなく、複数組み合わせでパラメータ空間の次元を増やした場合、次元が増える事により決定境界が引きやすくなることが考えられる。そこで本研究では、表面粗さを組み合わせる表面粗さベクトルを成し、組み合わせによる掘削面・不連続面判別の可否について実験にて確認した。また、定量的な表面粗さを算出するのではなく、点群から自動的に表面の特徴を取得する手法についても検討した。




図 4.2.2-5 算出した表面粗さにおけるビン数 10 のヒストグラム

表 4.2.2-2 各表面粗さにおけるヒストグラム距離

	FD	Ra	Rz	RIM
Bhattacharyya Coefficient	0.767	0.764	0.865	0.772
Histogram Intersection	0.570	0.474	0.611	0.574

4.3 掘削面・不連続面の判別実験

4.3.1 実験内容

本実験では、第 2 節で述べた表面粗さを組み合わせる表面粗さベクトルを成し、機械学習である SVM (Support Vector Machine) を用いてそれぞれを重み付けて学習させることで、掘削面・不連続面の判別を試みた。

4.3.1.1 SVM について

SVM はパターン認識を実現する機械学習法の一種で、1960 年代に Vapnik 等が考案し

た Optimal Separating Hyperplane を起源としている。SVM はカーネルトリックと呼ばれる方法を用いて非線形の識別関数を構成できるように拡張されており、現在知られている機械学習法の中でも最も認識性能の優れた学習モデルの 1 つであると考えられている（栗田， 2014）。SVM は、もっとも単純なニューロンのモデルである線形しきい素子を用いて 2 クラスのパターン識別機を構成する。訓練サンプルの集合に対し決定境界とのマージンを最大化する形でしきい素子のパラメータを学習する。図 4.3.1.1-1 は線形しきい素子の簡単なモデルである。入力データを $\mathbf{x}$ ，ニューロンのシナプス荷重を $\mathbf{w}$ ，出力を y とするとき、

$$y = \text{sign}(\mathbf{w}^t \mathbf{x} - h) \quad \dots\dots\dots (4.9)$$

により 2 値の出力値を算出する。なお、

$$\text{sign}(u) = \begin{cases} 1 & \text{if } u > 0 \\ -1 & \text{else} \end{cases} \quad \dots\dots\dots (4.10)$$

であり、 h は閾値である。以上よりこのモデルは、入力ベクトルとシナプス荷重の内積が閾値を超えれば 1 を出力し、そうでなければ -1 を出力する。この 2 つの値を認識するパターンとし、訓練サンプルを用いて $\mathbf{w}$ と h を求める事で決定境界を定める。

もし訓練サンプルが線型分離可能であれば、訓練サンプル数 N ，正解のクラスラベル $t_i = t_1, \dots, t_N$ に対して

$$t_i(\mathbf{w}^t \mathbf{x}_i - h) \geq 1, \quad i = 1, \dots, N \quad \dots\dots\dots (4.11)$$

を満たすパラメータが存在する。またこの時、決定境界は訓練サンプルにぴったりと沿う形ではなく、なるべく余裕を持っている形が望ましい（栗田， 2014）。そこで、入力データと決定境界との距離であるマージンが最大となるように学習を行う。入力データと決定境界との距離は $\frac{1}{|\mathbf{w}|}$ で求められることから、マージンは $\frac{1}{2} |\mathbf{w}|^2$ と表現できる。以上より、式を制約条件としたうえで、目的関数

$$L(\mathbf{w}) = \frac{1}{2} |\mathbf{w}|^2 \quad \dots\dots\dots (4.12)$$

を最小とするパラメータを求める問題と等価となる。




図 4.3.1.1-1 線形しきい素子の概念図

この問題は，ラグランジュの未定乗数法を用いて双対問題として解く。まず，ラグランジュ乗数 $\alpha_i \geq 0$, $i = 1, \dots, N$ を導入し

$$L(\mathbf{w}, h, \alpha) = \frac{1}{2} |\mathbf{w}|^2 - \sum_{i=1}^N \alpha_i \{t_i (\mathbf{w}^t \mathbf{x}_i - h) - 1\} \quad \dots\dots\dots (4.13)$$

と置き換える。フェルマーの定理より， $\frac{\delta L}{\delta \mathbf{w}} = 0$, $\frac{\delta L}{\delta h} = 0$ を求める。すると $\sum_{i=1}^N \alpha_i t_i = 0$, $\mathbf{w} = \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i$ となる。この結果を式に代入して，

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i^t \mathbf{x}_j \quad \dots\dots\dots (4.14)$$

を最大とする双対問題が得られる。制約条件は，

$$\alpha_i \geq 0, \quad i = 1, \dots, N, \quad \sum_{i=1}^N \alpha_i t_i = 0 \quad \dots\dots\dots (4.15)$$

である。この式について，最急降下法にて解を求めればよい。

しかし，上述の SVM では訓練サンプルが線型分離可能な場合でのみ有効である。現実的には，多少の識別誤りを許容するよう，制約を緩める必要がある。これをソフトマージン SVM と呼ぶ(@mikenov22, 2012)。対して通常の SVM はハードマージンと呼ばれる。ソフトマージン SVM は，マージン $\frac{1}{2} |\mathbf{w}|^2$ を最小化しつつ，誤分類距離であるスラック変数 ξ を考慮する。すなわち，

$$\xi_i \geq 0, \quad t_i (\mathbf{w}^t \mathbf{x}_i - h) \geq 1 - \xi_i, \quad i = 1, \dots, N \quad \dots\dots\dots (4.16)$$

の制約条件の下,

$$L(\mathbf{w}, \boldsymbol{\xi}) = \frac{1}{2}|\mathbf{w}|^2 + C \sum_{i=1}^N \xi_i \quad \dots\dots\dots(4.17)$$

を最小化する。 C はコストを表し、ソフトマージンの影響をコントロールする。以下、ハードマージン SVM と同様の手順で制約条件

$$\gamma \geq \alpha_i \geq 0, \quad i = 1, \dots, N, \quad \sum_{i=1}^N \alpha_i t_i = 0 \quad \dots\dots\dots(4.18)$$

の下での双対問題

$$L_{D(\alpha)} = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i^t \mathbf{x}_j \quad \dots\dots\dots(4.19)$$

を得る。

ソフトマージン SVM によって線型分離可能でない問題に対しても対応できるようになったが、本質的に非線形で複雑な識別問題に対しては未だ対応できない。そこで、データを非線形写像 φ により高次元空間へ非線形変換し、その空間で線形の識別を行う。これをカーネルトリックと呼ぶ (Muller et al., 2001)。非線形変換後のデータを $\varphi(\mathbf{x})$ とすると、ソフトマージン SVM の双対問題は

$$L_{D(\alpha)} = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j t_i t_j \varphi(\mathbf{x}_i)^t \varphi(\mathbf{x}_j) \quad \dots\dots\dots(4.20)$$

となる。ここで $\varphi(\mathbf{x}_i)\varphi(\mathbf{x}_j)$ の内積に対して、 $K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^t \varphi(\mathbf{x}_j)$ となる K を用いる事で、 φ を明示的に求める必要がなくなる。この K をカーネルと呼ぶ。一般に、カーネルには多項式カーネル

$$K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^t \mathbf{x}_j)^p \quad \dots\dots\dots(4.21)$$

や、RBF カーネル

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma|\mathbf{x}_i - \mathbf{x}_j|^2) \quad \dots\dots\dots(4.22)$$

が用いられる。 γ はカーネル幅で、決定境界の複雑さをコントロールする。

4.3.1.2 実験手順

実験手順は以下のようになる。まず、各面において、表面粗さFD, R_a , R_z , RIMを算出する。次に、各表面粗さの組み合わせから、表面粗さベクトルを作成する。表面粗さベクトルは、表 4.3.1.2-1 に記す 13 通りになる。

次に、それぞれの表面粗さベクトルについて、RBF カーネルを用いたソフトマージン SVM に学習させる。その際、ハイパーパラメータとしてソフトマージンのコスト C と RBF カーネルのカーネル幅 γ のチューニングを 5 分割交差検証とグリッドサーチを用いて行う。手順は以下のようになる。

- 1) コスト C とカーネル幅 γ について、いくつかの値の組み合わせを用意する (グリッド)
- 2) 各面で得られた全ての表面粗さベクトルを 5 つのグループにランダムに分割する
- 3) グリッド上の 1 点を表す C , γ の組み合わせをハイパーパラメータとして設定する
- 4) 5 つに分割された表面粗さのうち、4 つのグループを用いて学習を行う
- 5) 残りの 1 つのグループで識別を行い、適合率・再現率・F 値を算出する
- 6) 残すグループを変えつつ、4～5 を 5 回繰り返す
- 7) 適合率・再現率・F 値の平均値を算出し、F 値を C , γ の組み合わせのスコアとする
- 8) C , γ の組を変えつつ、3～7 を繰り返す
- 9) グリッド上の全ての C , γ の組のうち、もっともスコアが高かった適合率・再現率・F 値を最終的な学習・識別結果とする。

以上の手順を、組み合わせられた表面粗さベクトルを変えて、不連続面に対する各々の適合率・再現率・F 値を比較する。適合率・再現率・F 値は、不連続面識別の正負を T or F, 実際の正負を P or N とした時、それぞれ

$$\begin{aligned} \text{適合率} &= \frac{TP}{TP + FP} \\ \text{再現率} &= \frac{TP}{TP + FN} \\ \text{F 値} &= \frac{\text{適合率} \times \text{再現率} \times 2}{\text{適合率} + \text{再現率}} \end{aligned} \quad \dots\dots\dots (4.23)$$

で求める。実験条件となる SVM の条件を、表 4.3.1.2-2 に記す。

また、実験に利用した点群は第 2 節で用いたものと同様、54-A, 54-B, 54-C である。面数は不連続面が 33 枚、掘削面が 103 枚の合計 136 枚である。

表 4.3.1.2-1 表面粗さの組み合わせ一覧

Ra_RIM	FD_Ra_RIM
Ra_Rz	FD_Ra_Rz
Ra_Rz_RIM	FD_Rz
Rz_RIM	FD_RIM
FD_Ra	FD_Ra_Rz_RIM
FD_Rz_RIM	

表 4.3.1.2-2 本実験における SVM の条件

目的関数	$f(x) = \frac{1}{2} \ w^2\ + C \sum_{i=1}^N \xi_i \rightarrow \min$
制約条件	$y_i(w^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0$
RBF カーネル	$K(x_1, x_2) = \exp(-\gamma \ x_1 - x_2\ ^2)$
チューニング	5分割交差検証+グリッドサーチ
グリッド	$C = 10^{-3}, 10^{-2}, 10^{-1}, 10^1, 10^2, 10^3$ $\gamma = 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}$
特徴ベクトル	FD,Ra,Rz,RIMの組み合わせ

4.3 実験結果と結論

それぞれの表面粗さの組み合わせに対する適合率・再現率・F 値の表を、表 4.3-1 に示す。

表 4.3-1 各表面粗さの組み合わせに対する適合率・再現率・F 値の一覧

Combinations	Precisions	recalls	F values
Ra_RIM	1.000	0.011	0.022
Ra_Rz	0.667	0.135	0.224
Ra_Rz_RIM	0.674	0.326	0.439
Rz_RIM	1.000	0.011	0.022
FD_Ra	0.727	0.270	0.393
FD_Ra_RIM	0.741	0.225	0.345
FD_Ra_Rz	0.788	0.292	0.426
FD_RIM	0.783	0.202	0.321
FD_Rz	1.000	0.011	0.022
FD_Rz_RIM	0.792	0.213	0.336
FD_Ra_Rz_RIM	0.784	0.326	0.460

表 4.3-1 を見ると、組み合わせる表面粗さの数が増えるほど、F 値と再現率が上昇していることが分かる。しかし、表 4.3-1 を見ると、適合率には変化がない。よって、本実験にて用いた 4 つの表面粗さがそれぞれ異なる特徴を表しており、組み合わせて特徴ベクトルを構成する事で、互いの表現できていない特徴を補い合っていると考えられる。そのため、特徴空間上で掘削面・不連続面が分離しやすくなったと考えられる。以上より、各表面粗さを全て用い、SVM にて重み付けて学習と識別を行う事で、各表面粗さ単体では実現できなかった掘削面・不連続面の判別を行えるようになったと言える。一方、再現率だけに着目する。再現率は式の通り、実際の不連続面のうち、正しく不連続面だと識別された割合を示す。表 4.3-1 を見ると、最大でも 0.326 と、全体の 3 割程度しか識別できていないことが分かる。これでは、実用的な判別に用いることが難しいと考えられる。

再現率が低い原因として、特徴空間上でのデータの重複もしくは決定境界の不備が考えられる。しかし表 4.3-1 より、適合率が高いことから、SVM により不連続面と認識できたものは、おおむね正解であることがわかる。よって、図 4.3-1 の中央の様に、特徴空間上で不連続面の特徴ベクトルと掘削面の特徴ベクトルが重なっており、決定境界はそれぞれの境界に沿う形で定まっていることが予想できる。




図 4.3-1 特徴空間状の特徴ベクトル集合と決定境界の概念図

よって、より大きい次元の特徴ベクトルを成す事で、再現率を上昇させることが出来ると考えられる。

4.4 参考文献

- 岩の力学連合会 (1986) : 岩盤不連続面の定量的記載法, ISRM 指針, vol.3, pp.89-92.
- 村田純彦, 齊藤敏明 (1997) : フラクタルモデルによる岩盤不連続面の表面粗さ評価法について, 資源と素材, vol.113(7), pp.555-560.
- Tse, R., & Cruden, D. M. (1979) : Estimating joint roughness coefficients, International Journal of Rock Mechanics and Mining Sciences, vol.16(5), 303-307.
- 坂田幸寛 (2009) : 表面粗さパラメータの考え方と実例, 素形材, vol.50(11), pp.41-44.
- 三菱日立ツール株式会社 (2014) : 表面粗さ, <http://www.mmc-hitachitool.co.jp/technical/tech-info/pdf/c60.pdf>, 引用日 平成 29 年 11 月 21 日.
- Stephen R. Brown., Christopher H. Scholz (1985) : Broad bandwidth study of the topography of natural rock surfaces, Journal of Geophysical Research: Solid Earth, vol.90, pp.1099-1109.
- Lee Y. H., Carr J. R., Barr D. J., C. J. Hass (1990) : The fractal dimension as a measure of the roughness of rock discontinuity profiles, International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, vol.27(6), pp.453-464.
- Huang S. L., Oelfke S. M., Speck R. C. (1992) : Applicability of fractal characterization and modelling to rock joint profiles, International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, vol.29(2), pp.89-98.
- Odling N. E. (1994) : Natural fracture profiles, fractal dimension and joint roughness coefficients, Rock Mechanics and Rock Engineering, vol.27(3), pp.135-153.
- Kulatilake P. H. S. W., Shou G. Huang T. H., Morgan R. M. : New peak shear strength criteria for anisotropic rock joints, International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, vol.32(7), pp.673-697.
- Du S., 江崎哲郎, Jiang Y., 小林和昭. (1997). 岩盤不連続面表面のフラクタル特性とせん断強度との関係に関する研究. 岩盤力学に関するシンポジウム講演論文集, vol.19, pp.166-172.
- 大西有三, 堀田政国, 大谷司郎 (1989) : 画像処理システムを用いた岩盤割れ目のフラクタル幾何学的特性評価について, 土木学会論文集, 412(III-12), pp.61-68.
- 茂野博, 佐々木宗建 (2005) : 「フラクチャー」と「フラクタル」の関係? — 一次元競争成長モデル数値シミュレーションによる検討, 地質ニュース 612 号, pp.22-31.
- Rahman Z., Slob S., Hack H. R. G. K. (2006) : Deriving roughness characteristics of rock mass discontinuities from terrestrial laser scan data, Proceedings of 10th IAEG Congress: Engineering Geology for Tomorrow's Cities, Paper 437, pp.1-12.
- Bhattacharyya A. (1946) : On a Measure of Divergence between Two Multinomial Populations, The Indian Journal of Statistics, vol.7(4), pp.401-406.

- Swain M. J., Ballard D. H. (1991) : Color indexing, International Journal of Computer Vision, vol.7(1), pp.11-32.
- 栗田多喜男 (2014) : サポートベクターマシン入門 ,
<http://home.hiroshima-u.ac.jp/tkurita/lecture/svm.pdf>, 引用日 平成 29 年 11 月 21 日.
- @mikenov22 (2012) : SVM に つ い て , Slideshare ,
<https://www.slideshare.net/mknh1122/svm-13623887>, 引用日 平成 29 年 11 月 21 日.
- Muller K. R., Mika S., Ratsch G., Koji T., Scholkopf B. (2001) : An Introduction to Kernel-Based Learning Algorithms, IEEE Transactions of Neural Networks, vol.12(2), pp.181-201.

第5章 畳み込みニューラルネットワークによる特徴抽出と識別

5.1 畳み込みニューラルネットワークについて

第4章では定量的な表面粗さを算出し、それらの値から成る特徴ベクトルを識別に用いた。しかし、そのような定量的な特徴量（ハンドクラフト特徴量）により特徴ベクトルを構成するには専門的な知識と熟練した技能が必要である。本章ではハンドクラフト特徴量により特徴ベクトルを構成するのではなく、CNN（Convolutional Neural Network）を用いて点群から自動的に表面の特徴を取得し（Ben et al., 2015）、取得された特徴を用いて掘削面・不連続面の判別を試みた。

CNNは畳み込みニューラルネットワークと言い、一般的な準伝搬型のニューラルネットワークと異なり、全結合層だけでなく畳み込み層とプーリング層から構成されるニューラルネットワークの事である。資格パターン認識に関する階層型神経回路モデルであるネオコグニトロン(福島, 2006)を元に、より複雑・深層のネットワークを扱う。図5.1-1はネオコグニトロンの回路構造であり、細胞の層を何段も階層的に繋いで組み立てた多層の神経回路を成す。入力層から受けた入力を、コントラスト抽出層・エッジ抽出層の様にフィルタリング処理を行って奥の層に出力・プーリングすることで、入力の特徴を抽出していく。

畳み込みニューラルネットワークも、この畳み込みとプーリングを繰り返し入力の特徴を抽出していき、最終的に全結合ネットワークに抽出した特徴を伝え、クラス識別を行う。近年コンピュータの進化も伴い、シーン認識・物体検出・領域分割と言った画像処理分野で非常に高い識別率を誇っている。

本研究では、AlexNetと呼ばれるCNNを利用し(Krizhevsky, 2012)、点群のレンジ画像から特徴を抽出して、SVMで学習と識別を行う。




図5.1-1 ネオコグニトロンのネットワーク構造(福島, 2006 より転載)




図 5.1-2 AlexNet の構造 (Kota, 2017 より転載)

図 5.1-2 は AlexNet の構造である。227×227 の入力画像から 11×11 のフィルタを掛けて 96×96 の畳み込み層を形成する。その後、5×5 のフィルタで 27×27 の畳み込み層、3×3 のフィルタで 18×18 の畳み込み層を 2 つ通り、最終的に 4096 の全結合層を 2 つ通って最終的な識別結果を出力する。

5.2 実験

5.2.1 実験内容

本研究において、点群データの総数が少ない為、数万以上の訓練サンプルが必要な CNN を新たに作成・学習させることは、現実的ではない。そこで本実験では、既存の学習済みネットワークである AlexNet に各参照面の点群のレンジ画像を入力した後、全結合層での活性状態を画像の特徴として、SVM にて学習と識別を試みた。

点群には 3 章・4 章で用いた 54-A, 54-B, 54-C の他, No.36 にある 6 つの不連続面 36-A から 36-F にて作成した参照面を利用する。No.36 にある面数は 435 枚で、内不連続面が 89 枚、掘削面が 346 枚である。図 5.2.1-1 から 5.2.1-6 は、No.36 の各不連続面を ParaView にて描画した図である。数字は大格子内での各面の ID で、赤色が不連続面・灰色が掘削面部分を表す。黄枠は参照面にて作られた不連続面を表す。なお、面の色は見易さのためにつけたものである。




図 5.2.1-1 点群からのレンジ画像作成手順




図 5.2.1-2 点群からのレンジ画像作成手順



図 5.2.1-3 点群からのレンジ画像作成手順




図 5.2.1-4 点群からのレンジ画像作成手順




図 5.2.1-5 点群からのレンジ画像作成手順



図 5.2.1-6 点群からのレンジ画像作成手順

点群のレンジ画像は、以下の手順で作成する。

- 1) 面の法線ベクトルに対し, xy 平面に垂直になるように点群を回転させる (図 5.2.1-1(1))
- 2) 無限遠点から xy 平面に向かい点を射影する (図 5.2.1-1(2))
- 3) z 軸方向に対して, 一定の範囲で正規化し, 色付けする

図 5.2.1-2 は作成したレンジ画像の一例である。このレンジ画像は 36-A から取得したもので, 不連続面部分である。正規化範囲は $-0.025 \sim 0.025\text{m}$ であり, これは試行錯誤的に決定した。




図 5.2.1-8 点群からのレンジ画像作成手順




図 5.2.1-9 作成したレンジ画像の一例

次に、図 5.2.1-10 に記すように、作成したレンジ画像を AlexNet に入力し、2 回目の全結合層を取り出す。これを、その画像の持つ特徴ベクトルとする。AlexNet は、MatConvNet にて配布されている、数値解析ソフトウェア Matlab 用の学習済みネットワークである imagenet-caffe-alex.mat を使用した(MatConvNet)。imagenet-caffe-alex は、画像認識協議会である ImageNet Large Scale Visual Recognition Challenge 2016 (ILSVRC2016)にて用いられた課題のデータを学習したものである(ImageNet, 2016)。また、全結合層は Matlab のモジュールである Neural Network Toolbox に存在する activations 関数を用いて抽出した。使用した Matlab のバージョンは 2017a, Neural Network Toolbox のバージョンは 10.0 である。




図 5.2.1-10 AlexNet を用いたレンジ画像の特徴ベクトルの抽出

次に、図 5.2.1-11 に記すよう、レンジ画像から取得した特徴ベクトルを学習用と識別用に分け、SVM で学習と識別を行い、適合率・再現率を算出する。算出式は、(4.23)式と同様である。

以上の手順による SVM を用いた学習と識別をランダムに 1000 回行い、平均の適合率・再現率を最終的な識別結果とする。実験条件を表 5.2.1-1 と表 5.2.1-2 に記す。




図 5.2.1-11 AlexNet により抽出した特徴量の SVM による学習と識別

表 5.2.1-1 レンジ画像の作成条件

正規化範囲	-0.025~0.025
色	8bitRGB (各値は(z 値-0.025)×255)
特徴ベクトル	AlexNetIにおける2回目の全結合増(4096次元)

表 5.2.1-2 AlexNet の構成

ネットワーク	ImageNetを用いた学習済みAlexNet (imagenet-caffe-alex.mat)
総レイヤー数	23(入力・出力層含む)
レイヤー構成	: ICRNPCRNPCCRRCRPFRRFSO (I:In C:Conv R:ReLU N:Norm P:Pool F:Fully O: Out)
チャンネル数	3→96→256→384→384→256
フィルタサイズ	11-3→5-48→3-256→3-192→3-192
特徴ベクトルのサイズ	150528→290400 ^[2] →186624→64896→64896→43264
全結合層のニューロン数	4096→4096→1000

5.2.2 実験結果

算出した適合率と再現率を表 5.2.2-1 に記す。表 5.2.2-1 を見ると、再現率は 0.595 と、4 つの特徴ベクトルを利用した場合に比べ約 82.5%増加している。これは、AlexNet による特徴抽出が有効に働いた結果であると考えられる。しかし、適合率は 0.594 と、約 12%ほど減少している。これは、特徴ベクトルが未だに特徴空間上で重複していることを示している。

原因としては、本実験では AlexNet に対し処理の最適化を行っていないことが考えられる。例えば、図 5.2.2-1 は AlexNet における 1 つ目の畳み込み層において、レンジ画像が入力された際の各フィルタに対する活性化状況を表している。赤い枠線で囲った部分は、フィルタがうまく反応しておらず、あまり特徴が得られていない。図 5.2.2-2 に示す 1 つ目の畳み込み層におけるフィルタを見てみると、赤枠に相当する部分は白や黒と言った色が少なく、赤緑青が強く出ている。

本実験では入力画像における 1 ピクセルの RGB 値は全て等しい白黒画像としているため、特定の色に強く反応することが出来ず、図 5.2.2-1 の赤枠箇所の様に反応が弱くなってしまっているのだと考えられる。よって、レンジ画像作成時の配色を AlexNet のフィルタに適するよう変更することで、適合率・再現率の改善が期待できる。

表 5.2.2-1 AlexNet で抽出した特徴量を用いた不連続面識別の適合率と再現率

	適合率	再現率
平均	0.594	0.595
標準偏差	0.154	0.309

他にも、フィルタそのものが点群のレンジ画像に最適化されていない事も考えられる。5.1 で述べたように、点群データの総数が足りないため、新たにネットワークを構築・学習させることは現実的ではない。しかし、既存のネットワークを用いることで、少ない学習データでもネットワークを構築させるファインチューニングや、ある領域で学習させたモデルを別の領域のモデルとして転用する転移学習も存在する。今後、そのような技術を利用して、より点群のレンジ画像に適したネットワークを通して特徴を抽出し、SVM で識別させることで適合率・再現率を改善することが期待できる。




図 5.2.2-1 AlexNet における 1 段目の畳み込み層におけるレンジ画像の活性化状況の一例




図 5.2.2-2 AlexNet における 1 段目の畳み込み層における
フィルタの一覧

5.2.3 結論

本実験では、第 4 章における 4 つの表面粗さをを用いた SVM での識別において再現率が低い問題を解決するため、点群のレンジ画像を作成し、CNN を用いてレンジ画像の特徴を自動抽出した後、抽出した特徴を SVM に学習させて、掘削面・不連続面の識別を試みた。その結果、不連続面の再現率は 0.595 まで増加し、点群データからの不連続面の自動抽出に向けて前進したと考えられる。しかし、CNN で取得した特徴による識別では、適合率がわずかに減少していた。原因としては入力データに対する CNN である学習済み AlexNet の最適化が図られていないことが考えられる。本研究で用いた点群はデータ数が少なく、新規に CNN を構築するのは現実的ではないが、既存の学習済みネットワークを転用する技術も存在する。そのため、それらを利用して識別精度を向上させ、VBS により推定された面の掘削面・不連続面の自動判別を行う事が今後の課題として考えられる。

5.3 参考文献

- 福島邦彦 (2006) : 神経回路モデル「ネオコグニトロン」, 発見と発明のデジタル博物館,
<https://dbnst.nii.ac.jp/pro/detail/498>, 引用日 平成 29 年 11 月 21 日.
- Ben A., Keegan K. (2015) : Feature Representation In Convolutional Neural Networks,
arXiv, arXiv:1507.02313.
- Krizhevsky A., Sutskever I., Hinton G. E. (2012) : ImageNet Classification with Deep
Convolutional Neural Networks, Neural Information Processing Systems, vol.1,
pp.1097-1105.
- Kota Y. (2017) : Caffe で始めるディープラーニング, Slideshare ,
<https://www.slideshare.net/KotaYamaguchi1/caffe-71288204>, 引用日 平成 29 年 11
月 21 日.
- MatConvNet : Pretrained CNNs - ImageNet ILSVRC classification ,
<http://www.vlfeat.org/matconvnet/models/imagenet-caffe-alex.mat>, 引用日 平成 29
年 11 月 21 日.
- ImageNet (2016) : Large Scale Visual Recognition Challenge 2016 (ILSVRC2016),
<http://image-net.org/challenges/LSVRC/2016/>, 引用日 平成 29 年 11 月 21 日.

第6章 総論

高レベル放射線廃棄物の処分場設計においては、周辺岩盤の力学的安定性や水理特性等を、モデルを通じて評価する。対象岩盤が亀裂性の特徴を有する場合、モデル化のために岩盤中の不連続面の物理的特性を取得する必要がある。不連続面は地質専門家の目視観察に基づいて取得されるが、その際地質専門家の技量により、観察結果の品質や、制限時間内に取得できるデータ量に差が生じる。

以上の問題を解決するために注目を集めているのが、3D レーザースキャナを用いて得られる点群データである。3D レーザースキャナで坑道の表面形状をスキャンし、取得された3次元の点群データを処理することで、坑道の表面に対する様々な情報を得ることが出来る。本研究では、第2章で3D レーザースキャナの詳細として、スキャンの機構や取得されたデータ、また実際の適用例を通して3D レーザースキャナの特徴と利点について説明した。また、3D レーザースキャナを地質観察に適用した先行研究について、2000年代前半からの進展について説明し、現在の3D レーザースキャナへの期待と、また現状の限界について考えた。特にデータ処理の自動化の状況について触れ、従来の処理手法（DiAna アルゴリズム）が未だ半自動の処理であり、手動で試行錯誤的に設定するパラメータが存在することから、実用面で課題が残ることについて説明した。

第3章では、2章で考察した課題を解決するために開発したアルゴリズム「Variable-Box Segmentation」（以下：VBS）について説明した。VBS アルゴリズムは「大格子分割」「小格子分割」「結合」の3つのプロセスから成る。これらのプロセスにより、VBS は DiAna では固定値だった分割格子のサイズを変え、場所により適切なサイズをボトムアップ的に定める。3.4の実験にて、実際の点群データを VBS で処理して坑道壁面の表面形状を推定し、従来処理のアルゴリズムと比べてどの程度精度があるか、また自動化に寄与しているかを実験にて確認し、手動で作成した正解の面である参照面について、DiAna に比べ類似した面を推定することが出来た。また設定するパラメータが1つしかなく、DiAna の課題であったパラメータを手動で試行錯誤的に設定する問題を解決した。

第4章では VBS で推定した面から不連続面を判別する手法について検討し、地質専門家による判別に則った判別基準として表面粗さを考えた。本論文では4つの表面粗さ、フラクタル次元・算術平均粗さ・最大高さ粗さ・Roughness-length について説明し、また、これらの表面粗さから不連続面を判別できるか、相関比とヒストグラムから調査した。調査結果では、独立した表面粗さからでは判別が難しいことを確認された。しかし、表面粗さを組み合わせた特徴ベクトルを用いて判別する手法について検討し、Support Vector Machine（以下：SVM）による判別を実験にて試みた。しかし、実験結果から、特徴ベクトルの次元の追加が必要であることを結論付けた。

第5章では、4章で用いた4つの表面粗さの様な定量的な特徴量（ハンドクラフト特徴量）ではなく、Convolutional Neural Network（以下：CNN）を用いた自動的な特徴抽出につい

て検討した。ここでは 3D レーザースキャナで得られた点群データをレンジ画像データに変換し、CNN の一種である AlexNet の学習済みネットワークにある全結合層から特徴を抽出することを試みた。実験では変換した画像を CNN に入力して特徴を抽出した後、SVM を用いた不連続面の判別を試みた。その結果、不連続面・掘削面の判別ともに約 6 割の精度で判別することができ、ハンドクラフト特徴量の再現率と比較して判別率が約 82.5% 上昇した。以上のことから、本研究で提案する VBS を用いて点群データから適切な面を自動推定した後、CNN で表面の特徴量を抽出し SVM で不連続面を学習・判別する手法は、地質観察の省力化や平準化に対して有効であると結論付けた。また今後、入力データやネットワークのチューニングにより、判別精度がさらに向上した自動判別が可能になると考えられる。以上より、点群データを用いた不連続面の自動推定は、将来の処分場設計や設置場所の選定等に十分活用が期待される。

謝辞

本研究を進めるにあたり，終始ご指導頂いた指導教官の板倉 賢一教授に，深く感謝いたします。また，多くの時間を割いて助言・指導をして頂いたソフトコンピューティング研究室の鈴木 幸司教授，瑞浪超深地層研究所・深度 300m 研究アクセス坑道に関する様々なデータを提供して下さった，日本原子力研究開発機構・幌延深地層研究センターの早野 明さん，日頃支えてくださった可視化情報処理研究室の皆様に，心から感謝いたします。