

地球物理観測による地下モニタリングとAI利用

澤山和貴^{*1}

放射性廃棄物の地層処分において、広大かつ不可視な地下空間の特性やその長期的挙動を把握するために、地球物理的探査によるモニタリングは不可欠な技術である。近年、この分野では人工知能(AI)の活用が急速に進展しており、数値シミュレーションを高速化する代理モデルだけでなく、観測データから地下構造や物性を推定する逆解析においても革新が見られる。本稿では、まず地球物理モニタリングの最新動向として、地震波や電磁気を用いた4次元的な地下環境変化の可視化事例を整理する。そのうえで、AI利用の最新研究成果として、(1) デジタル岩石画像への深層学習適用と説明可能AIによる岩石物理モデルの解釈性向上、(2) 物理法則(保存則等)を学習に組み込み、スパースなデータからでも高精度な逆解析を実現する物理深層学習、(3) Transformerアーキテクチャを応用し、少数のセンサー情報から物理場全体を再構成する新たなフレームワークについて概説する。これらの技術は、観測データが制限される深地層環境において、モニタリングの高度化やデジタルツインの構築に寄与するものである。

Keywords: 機械学習, 地震探査, 電磁探査, 岩石物理

Geophysical monitoring is an essential technology for characterizing deep geological environments and understanding their long-term behavior in the geological disposal of radioactive waste. Recently, the application of Artificial Intelligence (AI) has rapidly progressed in this field. Beyond surrogate modeling for accelerating numerical simulations, significant innovations are emerging in inverse analysis to estimate subsurface structures and properties from observational data. This paper first reviews recent trends in geophysical monitoring, focusing on 4D visualization of subsurface changes using seismic and electromagnetic exploration methods. Subsequently, it reviews the latest research on AI applications, specifically: (1) the improvement of interpretability in rock physics models using Explainable AI applied to digital rock images; (2) Physics-Informed Neural Network, which integrates physical laws (e.g., conservation laws) into the learning process to enable robust inverse analysis even with sparse data; and (3) a novel framework using Transformer architectures to reconstruct entire physical fields from limited sensor data. These technologies contribute to the advancement of monitoring systems and the development of digital twins in deep geological environments where observational data is limited.

Keywords: machine learning, seismic exploration, electromagnetic exploration, rock physics

1 はじめに

放射性廃棄物の地層処分候補地の事前評価ならび閉鎖後の長期安定性能を評価するためには、地下の流体流動挙動の評価が急務である。しかし原位置での浸透率測定は容易ではなく、その時間変化の推定は数値モデリングに頼らざるを得ない[1]。これまでの研究では、原位置の応力条件における岩石の透水性測定や統計的に構築した亀裂ネットワークによる数値シミュレーション(DFN)が主流であったが、瑞浪の試験場では複雑な亀裂パターンが確認され、実際には天然環境の透水性を実験室から予測することは非常に困難であることが明らかとなった。そこで近年、地球物理学的探査手法(弾性波探査や電気比抵抗探査)を活用した、地下の流体流動の間接的評価が注目されている。地震波速度や電気比抵抗は、流動を支配する岩石内部の幾何構造に感度がある。これらの物性値の特性を利用することで、地層処分の候補地となる場所における地下構造の事前評価や、処分場閉鎖後の構造変化モニタリングさえも地上から遠隔に行うことができると期待される。

本稿では、地球物理学的探査手法の概要と動向をまず整理した上で、企画セッションのタイトルにある「AI利用」について最新の研究成果をレビューしていきたい。放射性廃棄物の地層処分分野におけるAI利用というと、数値シミュレーションを高速化するための代理モデル(Surrogate

Modeling)が主流であると思われる[2]。他方、地球物理観測分野でも近年AI利用が進んでいる。この分野では、Surrogate Modelingのように入力モデルをもとに結果を出力する順解析のみならず、観測データから説明モデル(目に見えない地下構造)を推定する逆解析においてもAI利用が進んでいる。本稿では、主に後者に焦点を当ててレビューを行う。

2 地球物理モニタリング

地球物理学的探査手法を用いたイメージングは、高レベル放射性廃棄物の処分場選定において、目に見えない地下空間を定量化するために有用である。例えば Wynn and Roseboom (1987) は、処分場事前選定において多数のボーリング調査を行うことは、地層のバリア機能を損なうリスクがあること、そのため地球物理探査が大規模な地下岩盤を非破壊で検査できる唯一の手段であるとしている[3]。Juhlin and Palm (1999) は、スウェーデン南東部のエスボ地下研究施設の近くで反射法地震探査を実施し、破碎帯の鮮明なイメージングに成功した[4]。これは地表地質踏査で確認されている破碎帯の位置とよく一致し、地下水の主要な経路となる破碎帯を明確に可視化できることが明らかとなった。また Rucker and Fink (2007) は、米国の Hanford Siteにおいて、核兵器製造拠点で生じた土壤汚染の広がりを3次元電気探査によって可視化した[5]。

さらに近年では、これらの物理探査手法をタイムラプス的に取得し、地震や地熱開発中の時空間変化のモニタリング(4D geophysics)が行われている例もある。Taira et al. (2018) は、米国 California 州の Salton Sea 地熱フィールドにおいて、表面波微動の自己相関を取ることで、地下岩盤

Subsurface monitoring by geophysical observations and its improvement by AI
by Kazuki SAWAYAMA (sawayama@bep.vgs.kyoto-u.ac.jp)

*1 京都大学大学院理学研究科附属地球熱学研究施設

Institute for Geothermal Sciences, Graduate School of Science, Kyoto University.

〒874-0903 大分県別府市野口原 3088-176

本稿は、日本原子力学会 2025 年秋の大会企画セッション「放射性廃棄物処分における AI 利用の展望」における講演内容に加筆したものである。

の表面波速度（S 波速度に相当）の変化を解析した[6]。その結果、地震に伴う地下亀裂の開口で速度が減少していること、また地熱開発に伴う地下亀裂の閉鎖で速度が増加していることを明らかにした。この表面波微動の解析は、地震や特定の震源を必要としないため、低コストのモニタリング手法として注目されている。他方、Tsuji et al. (2021) は、微弱な人工震源装置を利用して最大で約 80km 離れた地点で P 波速度の変化を計測した[7]。その結果、地熱発電所の操業や降雨による地下の間隙水圧の変化に伴うわずかな速度変化を捉えることに成功した。この震源装置は、可搬できるように小型化されたものまで開発されている[8]。山谷ほか (2018) は、奥会津地熱地域において、河川水を地下に注入する涵養試験中に 2 次元電磁探査を実施し、季節変化に伴う地下の水飽和度変化を観測した[9]。Johnson et al. (2021) は、米国 South Dakota 州 Sanford 地下研究施設での能動的地熱開発 (Enhanced Geothermal System; EGS) において、3 次元電気探査を実施し、高圧水注入に伴う岩盤内の亀裂開閉をリアルタイムに可視化した[10]。これらの事例は、地下の状態変化を物理探査手法によって数秒～年単位のリアルタイムで追跡できることを意味している。

同様の探査が幌延試験場でも実施されており、Ozaki (2023) は掘削に伴う P 波速度の低下を明らかにした[11]。このように現在の物理探査技術では、掘削影響領域 (Excavation Damaged Zone) の亀裂の進展までも追跡できている。これらの観測物性値と流体流動挙動の関係を精緻に明らかにすれば、これまで定量的な解釈が不十分であった複雑な地下の現在ないしは将来に渡る流体流動の時空間分布に関する解釈精度の向上が期待できる。実際の地下環境で得られる観測物性値から目に見えない地下の流体流動挙動の時空間変化を予測するには、岩石物理モデルと呼ばれる構成則を構築する必要がある。これまで先行研究は、亀裂同士の相互作用を考慮していない解釈が用いられており[12]、複雑な亀裂パターンを有する地下では直接適用できないという課題があった。これに対して、著者は、近年のデジタル化技術や機械学習モデルを活用することで、地球物理学的探査データを地下の透水性に変換する岩石物理モデルを構築してきた[13,14]。このようなモデルが確立できれば、候補地の物理探査データを解釈する際により定量的な透水性評価が行えるだけでなく、閉鎖後の長期間モニタリングにおいても地上の観測物性値から地下空間の変化を推定することが可能となる。本稿では、まずははじめに岩石物理モデル高度化のための AI 利用として著者の研究を紹介し、その後物理探査データ解析の高度化のための AI 利用について最新研究をレビューする。

3 AI 研究例の紹介

3.1 説明可能 AI

近年、深層学習の飛躍的な発展により、AI は画像認識や自然言語処理をはじめとする多岐にわたる分野で実用的な性能を示すようになった[15]。しかし、一般に深層学習モデルは、数百万から数十億のパラメータを持つ複雑な非線形関数であり、その内部動作は人間にとって理解困難で

ある。入力に対してなぜその出力が得られたのかという因果関係や論理的プロセスが不透明であるため、これらは一般にブラックボックスと呼ばれる[16]。このようなブラックボックス性は、地層処分分野における規制に対する安全性の論証や、地域住民との合意形成において大きな課題となり得る。

このような背景から、説明可能 AI の研究が近年注目を集めている。説明可能 AI とは、AI の動作や結果を人間が理解し、信頼し、管理できるようにするための一連の技術や手法を指す[16]。例えば畳み込みニューラルネットワーク (CNN) を用いた画像認識分野では、モデルが画像のどこを見て判断したかを可視化する手法 (Class Activation Mapping; CAM) が提案されている[17]。これは、最終畳み込み層の特徴マップと Global Average Pooling (GAP) 層の重みを利用して、特定のクラス判断に寄与した画像領域をヒートマップとして表示する手法である。CAM は GAP 層を持つ CNN に限定されるという制約があったが、これを拡張した Grad-CAM は、勾配情報を用いることであらゆる CNN アーキテクチャへの適用を可能にした[18]。

これらの研究の多くは分類タスクに焦点を当てているが、CAM の概念を回帰問題へと拡張した Regression Activation Mapping (RAM) [19] も近年提案されている。RAM は、出力される連続値の変動に寄与する特徴量を特定し、予測値の大小が画像のどの領域に由来するかを可視化する。Sawayama et al. (2024) は、これをデジタル岩石画像に応用することで、地震波速度 (P 波速度、S 波速度) や電気比抵抗の値がどのような岩石内部構造に感度があるかを可視化した[20]。この研究で使用した入力データはベレア砂岩のデジタル岩石画像である。同一のデジタル岩石画像を元に有限要素法[21,22]で P 波速度 (V_p)、S 波速度 (V_s)、 V_p/V_s 、電気比抵抗の 4 物性を解析し、その結果を教師データとして使用した。なお、それぞれの物性ごとの RAM を得るため、同一の CNN アーキテクチャでそれぞれ 4 パターンの学習を行った。なおこのアーキテクチャは、さまざまな試行錯誤をもとにベストケースを選択した。P 波速度 (V_p)、S 波速度 (V_s)、 V_p/V_s 、電気比抵抗それぞれの学習曲線を Fig.1 に示す。全体的に、先行研究[23]に比べても十分結果が収束していると判断できる。この結果をもとに RAM によるヒートマップを可視化した (Fig.2)。なおヒートマップは最大値に基づいて正規化され、支配的な微細構造を強調するため、重ね合わせ画像では最大値の 10%を超える領域が可視化されている (最大値の 10%未満の領域は透明)。得られた結果から、P 波速度と S 波速度は、機械が大きな粒子を注視し、微細な空隙や小さな粒子があまり重要な構造ではないことが明らかとなった (Figs.2e and f)。粒子は水で満たされた空隙よりも硬いことから、粒子間の連結 (骨格) が地震波速度を支配している可能性が推測される。これは、先行研究で報告されている地震波速度の粒径依存性と整合的である[24]。一方で、 V_p/V_s の RAM は粒子ではなく空隙に焦点を当てている (Fig.2g)。 V_p/V_s は地下の間隙水圧分布推定に広く用いられており、この結果は V_p/V_s が空隙特性を捉え得ることを裏付けている。また電気比抵抗は粒子の縁部と周囲の空隙に焦点を当てており、地震波

速度と異なる構造に感度を持つことが明らかとなった (Fig.2h). これらの領域は空隙の屈曲度と関連している可能性があり、輸送特性の重要な決定因子であることが裏付けられた[25]. さらに、この可視化された RAM は電流の流れ方向に沿った細長い特徴を捉えており、本手法が輸送特性の異方性を重要な特徴として認識できることを示している。全体として、各特性を予測するための RAM は異なる支配的特徴を示したことから、地震波速度と電気比抵抗は内部微細構造に対する感度が異なる可能性が明らかとなり、これは現場データの Joint inversion/interpretation や特性間の相互関係を検討する際に考慮すべきであることが示唆された。

3.2 物理深層学習

地球科学/工学分野のように、深層学習が必要とするビッグデータを用意することが必ずしも容易でない場合もある。また従来のデータ駆動型モデルでは、物理的にあり得ない予測を行う可能性もある [26]. これらの課題を解決するため、事前知識として物理法則を学習プロセスに統合する物理深層学習 (Physics-Informed Neural Network) が近年発展してきている。Karniadakis et al. (2021) は、これを観測データ (Data) と数学モデル (Physics) の融合と定義し、データ不足の解消や物理的整合性の担保、さらには逆問題解析の効率化が可能であると論じている[26]。

Raissi et al. (2019)は、ニューラルネットワークの損失関数に物理法則の残差を組み込むことを提案した[27]. また偏微分方程式に含まれる微分項を数値微分 (差分法) ではなく、深層学習に組み込まれている自動微分を利用している。これにより、メッシュフリーでの学習が可能となり、複雑な計算グリッド生成のコストが削減された。地層処分分野においても、質量保存則やエネルギー保存則といった物理法則を組み込む物理深層学習が、説明可能性の観点からも有望であると考えられる。

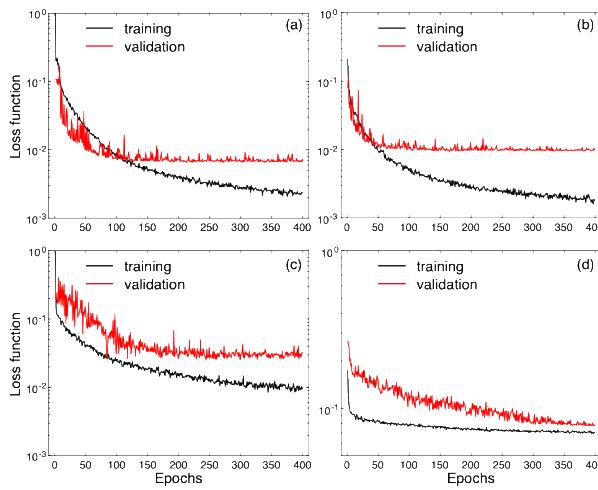


Fig.1 Graphs showing the values of loss function for training and validation steps over the best-performing CNN model of (a) P-wave velocity, (b) S-wave velocity, (c) V_p/V_s ratio, and (d) electrical resistivity. Data from [20].

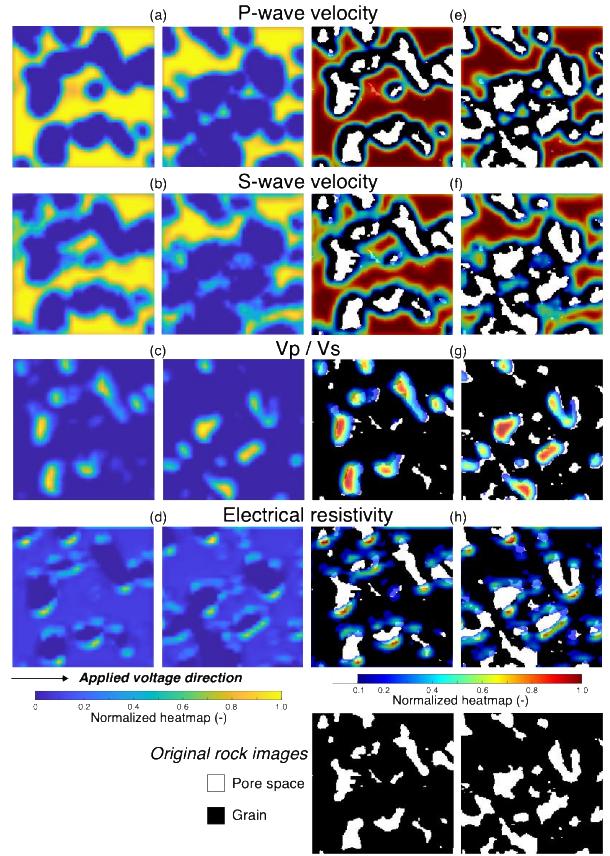


Fig.2 Images showing the representative results of regression activation mapping for (a) P-wave velocity, (b) S-wave velocity, (c) V_p/V_s ratio, and (d) electrical resistivity as well as their overlays on the input rock images (e, f, g, and h, respectively). The overlaid heatmaps are normalized based on their maximum value and regions showing <10% of the maximum are colorless to highlight the important features. The bottom panels are the original rock images. Data from [20].

Ishitsuka et al. (2025) は、物理深層学習を岩手県葛根田地熱フィールドに適用し、地下水流动と熱輸送の連成現象における実用的な逆解析フレームワークを提案した[28]. この研究では、限られたボーリングデータの学習過程において、観測データとの誤差に加え、質量保存則およびエネルギー保存則の残差を最小化するよう拘束を与えた。さらに坑井から離れた領域の不確実性を低減するために、電磁探査データをソフトな拘束条件としてネットワークに入力した。電気比抵抗と温度・空隙率を結びつける岩石物理モデルを仮定することで、従来のデータ駆動型ニューラルネットワークと比較して、坑井データが存在しない領域や深部における温度予測精度を有意に向上させることができた。また逆解析された浸透率分布は、従来の逆解析で見られるような不自然な不連続性を持たず、地質構造と整合的な滑らかな分布を示した。この研究は、物理探査データと物理法則を同時に活用することで、限られた直接観測データからでも信頼性の高い地下3次元モデルが構築可能であることを実証した。このように少ない坑井データから地下

の温度・圧力・浸透率の物理的に妥当な3次元分布が推定できれば、地層処分におけるサイト特性評価の高度化に対しても重要な示唆を与えると考えられる。

3.3 劣決定問題に有効なAI

地球科学/工学分野では、上述のように対象となる物理場（温度・圧力・流速・濃度など）が連続的かつ広大である。その一方で、一般に地上に配置されるセンサーは空間的にきわめて限定的である場合が多い。このような逆問題は、未知数が観測数を圧倒的に上回る劣決定問題として知られている。近年ではCNNの適用も進んでいるが、CNNはセンサー位置が不規則であったり、欠測によって配置が動的に変化したりする実フィールドのデータへの柔軟性に欠けるという構造的な弱点があった。これらの課題に対し、Santos et al. (2023) は、自然言語処理分野で成功を収めているTransformerアーキテクチャ、とくにPerceiver IOを応用した新たなフィールド再構成フレームワーク「Senseiver」を提案した[29]。Senseiverは観測データをグリッドとしてではなく、位置情報と値のセットの点群として扱う。そして入力されたスペースな観測データ（座標および物理量）をクロスアテンション機構を用いて固定サイズの潜在空間へとエンコードする。その後、再びクロスアテンションを用いて、潜在空間から任意の座標（再構成したいグリッド全体）へとデコードする。通常のTransformer（Self-attention）は入力数の二乗の計算量を要するが、Senseiverは潜在配列を介することで線形の計算量に抑えられている。これにより、広大なフィールドに対しても効率的な処理が可能となった。またCNNとは異なり、入力センサーの数や配置が学習時と異なっていてもモデルを再学習する必要がなく、任意のスペース度合いに柔軟に対応できる。彼らは、アメリカ海洋大気庁の海面水温データセットおよび流体シミュレーション（2D渦流、3D乱流、3D多相流、汚染物質の移流）を用いたベンチマークテストにおいて、Senseiverの性能を検証した。その結果、クリギングをはじめとした従来の補間手法と比較して圧倒的に高い精度を達成しただけでなく、欠損補完に用いられる代表的なCNNモデル（U-Netの変種など）と比較しても、とくに観測点が極端に少ない状況下での微細構造の再現性において優位性を示した。さらにSenseiverは、センサーがランダムに配置された場合や、センサー数が変動した場合でも安定した推論が可能であることが確認された。これは、センサーの故障や移動が頻繁に起こる実環境のモニタリングシステムへの適用においてきわめて重要な特性である。さらに特筆すべき結果として、空間全体のわずか0.0006%/全時間ステップの50%のデータ学習でデータセット全体を高精度に再構築できたこと、また観測されたベクトル量（速度）から観測されていないスカラ量（汚染物質濃度）を高い精度で予測できただけが挙げられる。この研究は、劣決定性の強い地球物理データの問題において、物理的な場の相関関係をAttentionマップとして学習することで、スペースな情報から全体像を効率的かつ高精度に復元できることを示した。この技術は、放射性廃棄物処分場のモニタリングのような、観測点の設置が制限される深地層環境など、データの空間密度が

不足するあらゆる地球科学的課題に対して、強力なツールとなる可能性がある。

4 おわりに

本稿では、放射性廃棄物処分における地球物理学的モニタリング技術の現状と、そこにおけるAI利用の展望について概説した。物理探査技術は、弾性波速度や比抵抗の時空間変化（4D geophysics）を通じて、地下の流体流動や亀裂開閉をリアルタイムに捉える手段として成熟しつつある。これに加え、近年の深層学習技術の導入は、従来の物理探査が抱えていた「岩石物理モデルの不確実性」や「観測データの空間的制約」という課題に対し、新たな解決策を提示している。とくに、説明可能AI（RAM等）の活用は、ブラックボックスとなりがちな物性評価プロセスを可視化し、説明性を担保する上で重要である。また、物理深層学習やTransformer（Senseiver）を用いたフィールド再構成技術は、物理法則や空間相関を学習に取り入れることで、限られた観測点からでも信頼性の高い地下モデルの構築を可能にする。これらのAI技術と物理探査の融合は、将来的な処分場のデジタルツイン構築に向けた強力な基盤となり、長期間にわたる処分場の安全性監視の高度化に貢献することが期待される。

参考文献

- [1] Xue, L. et al.: Continuous permeability measurements record healing inside the Wenchuan earthquake fault zone. *Science* **340**, pp.1555–1559 (2013).
- [2] Mo, S. et al.: Deep convolutional encoder-decoder networks for uncertainty quantification of dynamic multiphase flow in heterogeneous media. *Water Resources Research* **55** (1), pp.703-728 (2019).
- [3] Wynn, J. C., Roseboom, E. H.: Role of geophysics in identifying and characterizing sites for high-level nuclear waste repositories. *Journal of Geophysical Research: Solid Earth* **92** (B8), pp.7787-7796 (1987).
- [4] Juhlin, C., Palm, H.: 3-D structure below Avro Island from high-resolution reflection seismic studies, southeastern Sweden. *Geophysics* **64** (3), pp.662-667 (1999).
- [5] Rucker, D. F., Fink, J. B.: Inorganic plume delineation using surface high-resolution electrical resistivity at the BC cribs and trenches site, Hanford. *Vadose Zone Journal* **6** (4), pp.946-958 (2007).
- [6] Taira, T. et al.: Monitoring reservoir response to earthquakes and fluid extraction, Salton Sea geothermal field, California. *Sci Adv.* **4** (1), pp.1-10 (2018).
- [7] Tsuji, T. et al.: Continuous monitoring system for safe managements of CO₂ storage and geothermal reservoirs. *Sci. Rep.* **11** (19120), pp.1-15 (2021).
- [8] Tsuji, T., Tsuji, S., Kinoshita, J.: 4 cm Portable Active Seismic Source (PASS) for Meter-to Kilometer-Scale Imaging and Monitoring of Subsurface Structures. *Seismol.*

Res. Lett. **94** (1), pp.149-158 (2023).

[9] 山谷祐介, 高倉伸一, 浅沼宏: AMT 法電磁探査による奥会津地域地熱貯留層の比抵抗モニタリング. *日本地熱学会誌* **40** (3), pp.159-173 (2018).

[10] Johnson, T.C. et al.: 4D proxy imaging of fracture dilation and stress shadowing using electrical resistivity tomography during high pressure injections into a dense rock formation. *J. Geophys. Res. [Solid Earth]* **126**, pp.1-15 (2021).

[11] Ozaki, Y.: First-arrival traveltimes tomography for monitoring the excavation damaged zone in the Horonobe Underground Research Laboratory. *Rock Mechanics Bulletin* **2** (3), pp.1-12 (2023).

[12] O'Connell, R.J., Budiansky, B.: Seismic velocities in dry and saturated cracked solids. *J. Geophys. Res.* **79**, pp.5412-5426 (1974).

[13] Sawayama, K. et al.: Relating Hydraulic-Electrical-Elastic Properties of Natural Rock Fractures at Elevated Stress and Associated Transient Changes of Fracture Flow. *Rock Mech. Rock Eng.* **54**, 2145-2164 (2021).

[14] Sawayama, K. et al.: Relationship between permeability and resistivity of sheared rock fractures: The role of tortuosity and flow path percolation. *Geophys. Res. Lett.* **50** (20), pp.1-12 (2023).

[15] LeCun, Y. et al.: Deep learning. *Nature* **521** (7553), pp.436-444 (2015).

[16] Guidotti, R., et al.: A survey of methods for explaining black box models. *ACM computing surveys (CSUR)* **51** (5), pp.1-42 (2018).

[17] Zhou, B. et al.: Learning deep features for discriminative localization. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.2921-2929. (2016)

[18] Selvaraju, R. R., et al.: Grad-CAM: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision (ICCV)*, pp.618-626 (2017).

[19] Wang, Z., Yang, J.: Diabetic Retinopathy Detection via Deep Convolutional Networks for Discriminative Localization and Visual Explanation. In *AAAI Workshops*, pp.514-521 (2018).

[20] Sawayama, K., Tsuji, T., Shige, K.: Extracting crucial microstructures to characterize the elastic wave velocity and resistivity of Berea sandstone using convolutional neural networks. *Geophysics* **89** (1), pp.117-126 (2024).

[21] Sawayama, K. et al.: Elastic wave velocity changes due to the fracture aperture and density, and direct correlation with permeability: An energetic approach to mated rock fractures. *J. Geophys. Res. [Solid Earth]* **127** (2), pp.1-17 (2022).

[22] Sawayama, K. et al.: Scale-independent relationship between permeability and resistivity in mated fractures with natural rough surfaces. *Geothermics* **94**, pp.1-46 (2021).

[23] Karimpouli, S., Tahmasebi, P.: Image-based velocity estimation of rock using Convolutional Neural Networks. *Neural Netw.* **111**, pp.89-97 (2019).

[24] Peng, J., Wong, L.N.Y., Teh, C.I.: Influence of grain size on strength of polymimetic crystalline rock: New insights from DEM grain-based modeling. *Journal of Rock Mechanics and Geotechnical Engineering* **13**, pp.755-766 (2021).

[25] Walsh, J.B., Brace, W.F.: The effect of pressure on porosity and the transport properties of rock. *J. Geophys. Res.* **89** (B11), pp.9425-9431 (1984).

[26] Karniadakis, G. E. et al.: Physics-informed machine learning. *Nature Reviews Physics*, **3** (6), pp.422-440 (2021).

[27] Raissi, M., et al.: Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics* **378**, pp.686-707 (2019).

[28] Ishitsuka, K. et al.: Reliable and practical inverse modeling of natural-state geothermal systems using physics-informed neural networks: Three-dimensional model construction and assimilation with magnetotelluric data. *Journal of Geophysical Research: Machine Learning and Computation* **2** (3), pp.1-29 (2025).

[29] Santos, J.E. et al.: Development of the Senseiver for efficient field reconstruction from sparse observations. *Nat. Mach. Intell.* **5**, pp.1317-1325 (2023).