素因と誘因を考慮した説明可能な高解像度土砂災害リスク評価
－令和 6 年能登半島豪雨への適用－

田中優也*・後藤真太郎**

Explainable High-Resolution Landslide Risk Assessment Considering Predisposing and Triggering Factors
- Application to the 2024 Noto Peninsula Heavy Rainfall Event -

Yuya Tanaka*, Shintaro Goto**

Abstract: This study presents a high-resolution, 50-m landslide-occurrence probability model that integrates 18 static predisposing factors with 2 dynamic triggering factors—high-resolution rainfall (XRAIN) and soil water index (XSWI)—within a machine-learning framework. We apply the model to the 2024 Noto Peninsula heavy-rainfall event to evaluate performance. CatBoost was the best-performing algorithm, achieving a PR-AUC of 0.213 (≈2.7× the random baseline of 0.077). The resulting hazard maps showed good agreement with mapped damage extents. Ten-minute predictions captured the expansion of high-risk areas as rainfall intensified and a post-peak lag consistent with XSWI accumulation. Model interpretability and physical plausibility were supported by SHAP (SHapley Additive exPlanations). The proposed method refines spatial resolution from 1 km to 50 m—yielding roughly a 400-fold increase in grid-cell density—and provides probabilistic risk estimates with associated explanations to support practical decision-making in disaster preparedness.

Keywords: 土砂災害（landslide），素因と誘因（predisposing and triggering factors），リスク評価（risk assessment）

１．はじめに

土砂災害は，地形・地質・土壌・植生など斜面固有の特性（素因）と降雨・地震動・水位変動などの外的要因（誘因）との相互作用によって生じる（Varnes, 1978）．30 mm h^{-1} 以上の激しい降雨事例の増加により，発生件数は過去 10 年間で約 1.6 倍に増加し，経済的損失と人命への深刻な脅威となっている．

現行の土砂災害対策には複数の技術的課題が存在する．警戒情報は 1 km メッシュという粗い空間解像度で設計され，降雨などの誘因のみに基づいており，地形特性や地質構造などの素因が考慮されていない．素因に基づく警戒区域指定は事前の静的評価に留まり，降雨状況に応じた動的更新は行われない．これらの制約により局所的な地形勾配や時々刻々と変化する誘因に対応したリスク評価が困難であり，実運用では適中率 4%に留まる事例が報告されている（太田ほか，2023）．

この課題に対し，機械学習アルゴリズムによるデータ駆動型のリスク評価（桑折ほか，2022; 田中ほか，2024）は，広域かつ同時多発的な土砂災害に対して有効な選択肢となっており，空間的な危険度把握を可能にする．しかしながら，既往研究の多くは誘因に年平均降水量や月間降水量など単一期間の低時空間分解能データを用いており，降雨強度の時間変化，土壌中の水分量変動，浸透による間隙水圧の上昇といった発生メカニズムの動的変化が十分に考慮されていない．気候変動に伴う極端降雨現象の頻発化が予測される状況下では，高頻度・高解像度の降雨データと先進的なモデリング手法を統合し，素因と誘因の動的な相互作用を考慮した手法開発が必要で

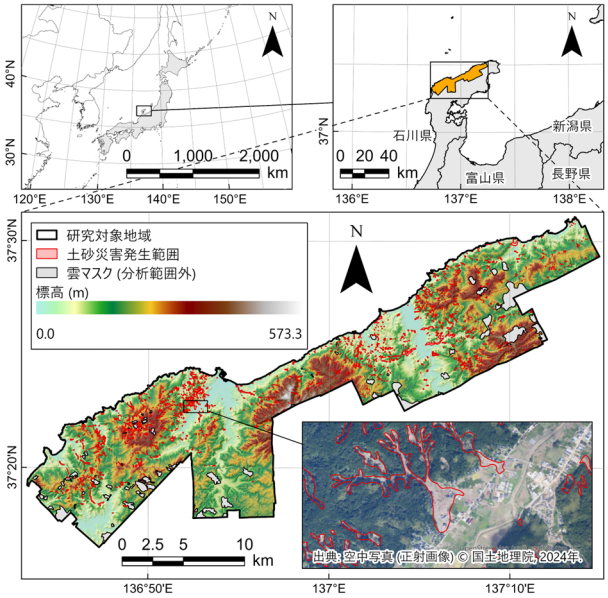


図 1　研究対象地域（石川県能登半島北部）

*　学生会員　立正大学大学院地球環境科学研究科（Rissho University）
〒360-0194　埼玉県熊谷市万吉 1700 番地　E-mail：253h10001@rissho-univ.jp
**　正会員　立正大学地球環境科学部（Rissho University）

ある．

以上を踏まえ，本研究では土砂災害の素因と誘因を統合した機械学習モデルによる高解像度（50 m メッシュ）なリスク評価手法を構築し，令和 6 年（2024 年）能登半島豪雨への適用を通じて実用性を検証する．

2．研究対象地域と解析対象期間

本研究では，令和 6 年 9 月 20 日からの大雨（国土地理院，2024）で土砂災害が多発した石川県能登半島北部を対象とする（図 1）．解析対象期間は 2024-09-20 06:00 UTC から 2024-09-22 11:00 UTC に設定した．輪島市では 24 時間雨量が観測史上最大の 412 mm（2024 年の年間降水量の約 10%）に達する記録的豪雨であった．

本事例は令和 6 年能登半島地震後に発生した豪雨災害であり，先行する地震災害が後発の豪雨災害を拡大させる典型的な複合災害事例である．地震により地盤が緩み，斜面に多数の亀裂や重力性変形が生じていた状況下で，豪雨が浸透し表層崩壊を誘発した（大丸，2025）．

3．研究手法

本研究のフローを図 2 に示す．50 m メッシュ単位で素因と誘因を整備し，9 種類の機械学習モデルで学習および評価を実施した．

3.1　使用データ

目的変数として被災箇所の判読データ（国土地理院，2024）を採用した．素因は地形・地質・土地被覆・水文・人為に分類される計 18 指標を採用した．誘因は高解像度降雨量データの XRAIN（10 分間隔・250 m 格子をバイキュービック補間で 50 m へリサンプリング）と XRAIN Soil Water Index（XSWI）を採用した．XSWI は，XRAIN を入力とする三段直列タンクモデルにより各層の貯留高を積算した指標で，土壌中の水分量を表す．学習データの基準時刻は，石川県災害対策本部会議資料（石川県，2024）に基づき，発災初期時刻の 2024-09-21 01:00 UTC に設定した．

3.2　モデル構築と発生確率の時系列推定

土砂災害の発生・非発生を二値分類問題として定式化し，線形モデル（LR），木系モデル（RF），勾配ブースティング系（CatBoost，HGBoost，LightGBM，XGBoost），不均衡対応アンサンブル手法（BRF，EEC，RUSBoost）を比較検証した．カテゴリ変数の処理には one-hot encoding を適用した．空間的自己相関の影響を排除するため，解析領域を緯度経度で等間隔に分割し，Stratified Group K-Fold 法（5 分割交差検証）を実施した．評価後はモデルごとに危険度分布図を作成し，最適モデルについては 10 分間隔の誘因を用いて時系列発生確率を推定した．最終出力は [0, 1] 区間の確率として算出した．

3.3　説明可能な AI の適用

非線形モデルは高い予測精度を示す反面，ブラックボックス化しやすい．本研究では説明可能な AI の一手法である SHapley Additive exPlanations（SHAP）（Lundberg et al., 2017）を導入し，モデルの予測根拠の可視化を行った．

4．結果と考察

4.1　モデル精度と危険度分布図

単変量相関では，誘因である XSWI が最大（|r|=0.14）を示した．機械学習モデルの精度評価を表 1 に示す．本データは陽性率が 7.77%（発生：10,526 件，非発生：124,997

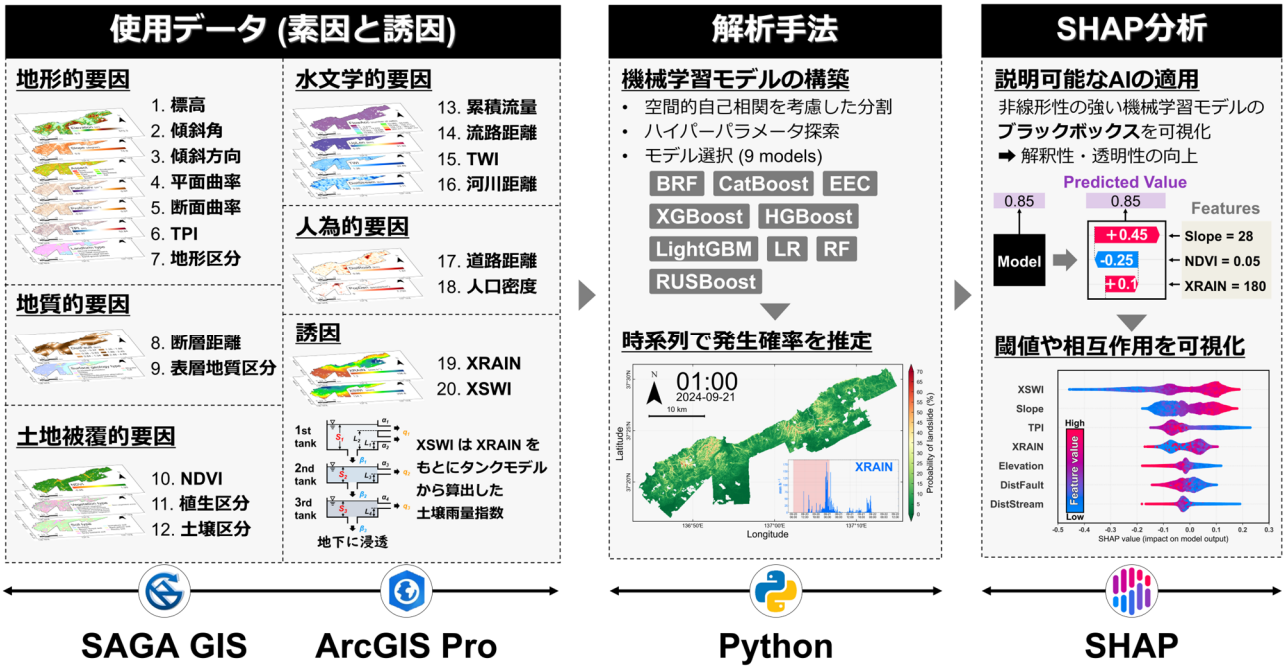


図 2　研究フローチャート

表 2　機械学習モデルの精度評価

Model	PR-AUC	Brier Score	F1	ROC-AUC
(a) CatBoost	0.213	0.065	0.269	0.755
(b) RF	0.210	0.065	0.267	0.756
(c) HGBoost	0.204	0.066	0.256	0.754
(d) LightGBM	0.203	0.065	0.256	0.749
(e) XGBoost	0.198	0.066	0.253	0.751
(f) RUSBoost	0.180	0.066	0.242	0.732
(g) BRF	0.179	0.067	0.238	0.708
(h) LR	0.172	0.067	0.232	0.723
(i) EEC	0.159	0.067	0.237	0.711

件）のクラス不均衡を有している．ランダム分類の基準となる PR-AUC 値 0.077 に対し，CatBoost は 0.213 を達成し，約 2.7 倍の性能を示した．RF, HGBoost, LightGBM, XGBoost も同等の高水準を示した．これらの結果は，素因と誘因の非線形な相互作用を木系モデルおよび勾配ブースティング系が効果的に学習したことを示す．総合評価に基づき，CatBoost を最適モデルとして以降の解析に採用した．

各モデルのリスク分布図を図 3 に示す．Jenks の自然分類で 5 段階（Very high / High / Moderate / Low / Very low）に区分した．高リスク域は河道周辺に集中し，境界線は尾根線や緩勾配域で区切られ，判読された土砂災害発生範囲と高い整合性を示した．CatBoost（図 3a）では，高リスク域の面積比率が 1.79%となり，重点警戒対象の選定に適した分布特性を示した．

4.2　時系列発生確率の空間推移

解析対象期間のうち降雨量が多かった 6 時間に絞り，CatBoost を用いて 1 時間ごとの発生確率を 50 m メッシュで算出した．発生確率分布図と災害時の XRAIN を図 4 に示す．素因は全時刻で固定値とし，誘因である XRAIN と XSWI は各時刻の観測値を入力データとして使用した．降雨強度の増加に伴い高リスク域が段階的に拡大し，発生確率も継続的に上昇する傾向が見られた．降雨ピーク後も高発生確率が一定時間継続し，XSWI の累積を反映した遅延応答が観察された．この挙動は降雨に対する土壌水分量の時間遅れを反映しており，実際の土砂災害発生メカニズムと一致する．時間変動する動的な誘因と斜面特性を示す静的な素因との相互作用というモデル設計の妥当性を示唆する．実務対策では，危険斜面の特定，発生時刻の予測，危険継続時間の推定を可能とし，警戒情報発令や避難スイッチ等の意思決定を支援できる可能性がある．

4.3　SHAP による特徴量の寄与度分析

使用した特徴量の寄与度分析の結果を図 5 に示す．XSWI が最も高い寄与を示し，特徴量値の増加が発生確率を上昇させていた．続いて傾斜角，地形位置指数（TPI），XRAIN，標高，断層距離，河川距離の順で寄与が高く，誘因および地形的要因が土砂災害発生を支配することが示唆された．この結果は，誘因と地形的素因が支配的に作用するという既往知見と一致し，XSWI の寄与は土壌

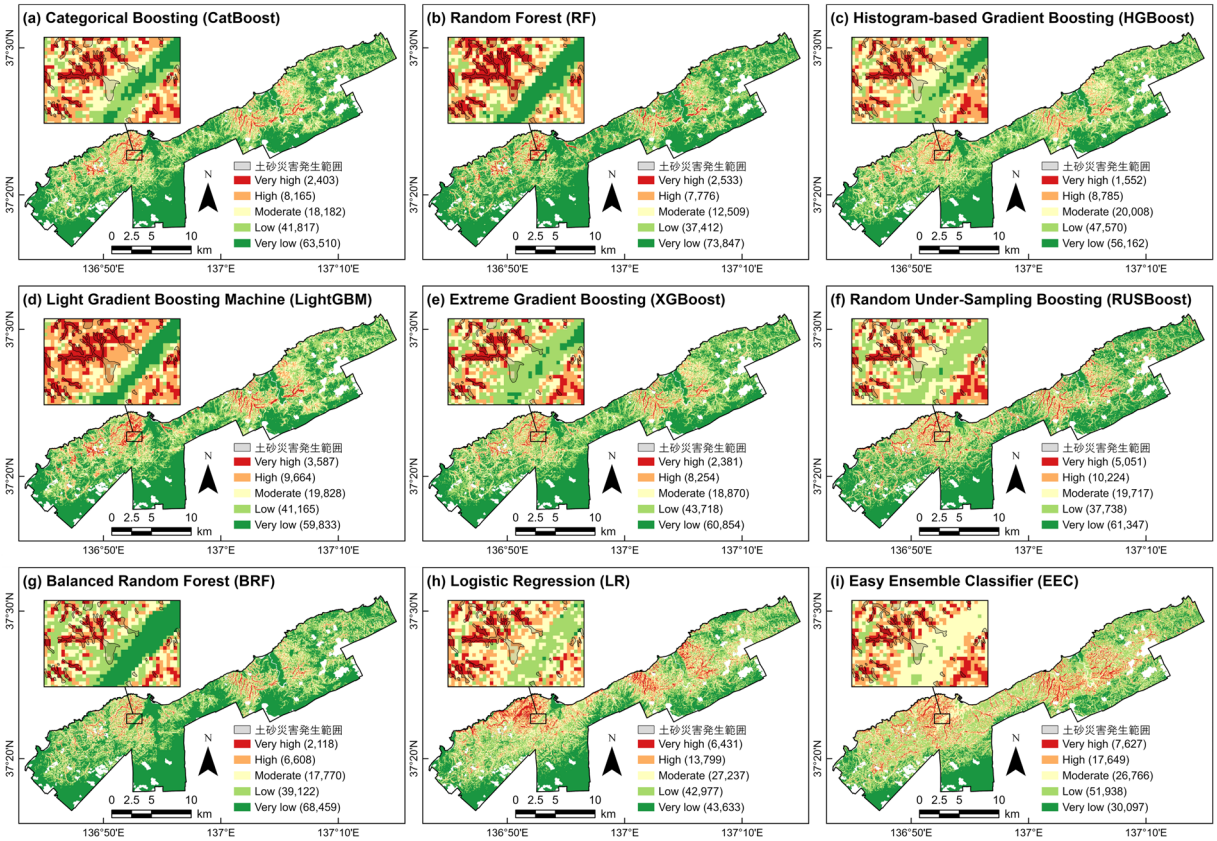


図 3　各モデルの危険度分布図（色分けは Jenks の自然分類による）

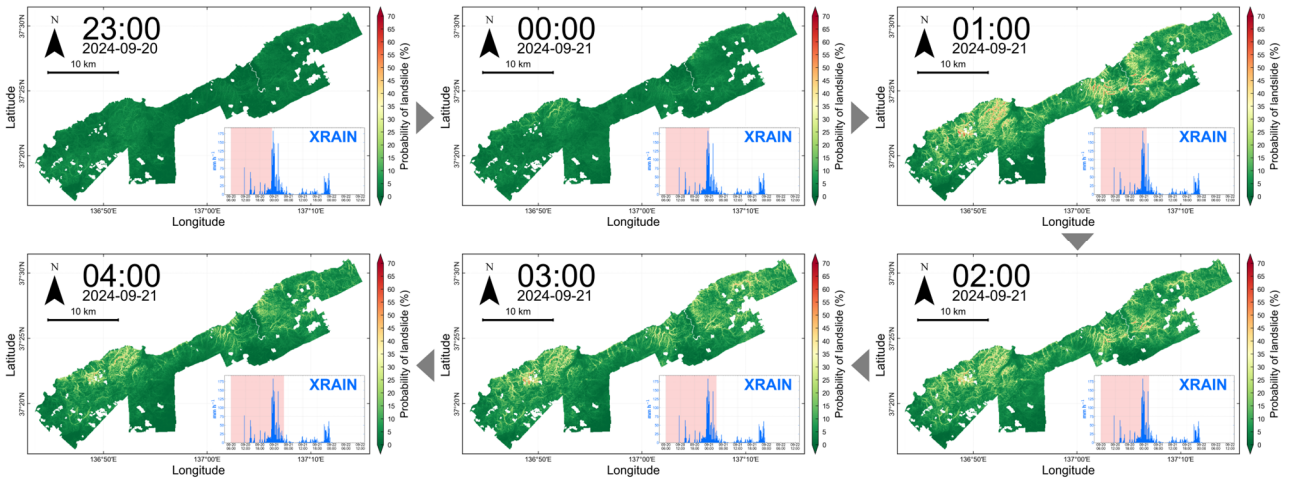


図 4　発生確率の時間変動と空間推移（動画：https://youtu.be/y02su1knl8M ）

中の水分量変動による斜面不安定化を捉えている．断層近傍での地盤脆弱性，河川浸食による斜面基底部の不安定化といった地形学的機構も定量的に確認された．素因と誘因を考慮したモデルの有効性が確認されたことで，類似災害への適用展開も期待される．

5．まとめ

本研究では，素因と誘因を統合した機械学習モデルにより，50 m メッシュで土砂災害発生確率を推定する枠組みを構築し，令和 6 年能登半島豪雨に適用して実用性を検証した．評価指標では，CatBoost が PR-AUC 0.213 を達成し，最適モデルであることを明らかにした．危険度分布図では，判読被災範囲との整合が高く，発生確率の空間分布を高精度で再現できていた．時系列推定では，降雨強度の増加に伴う高リスク域の段階的拡大と，XSWI の累積を反映する遅延応答が観察された．SHAP による特徴量の寄与度分析では，XSWI が最大の寄与を示し，傾斜角・TPI・XRAIN・標高・断層距離・河川距離が続いた．本手法は，現行システムを 400 倍に高解像度しつつ，説明可能な AI で非線形な相互作用を定量化することで，効果的な早期警戒システムの基盤となり得る．

限界として，単一の豪雨イベント適用に留まる点，誘因の与え方に残る不確実性が挙げられる．今後は，(1) 閾値超過の継続時間をセルごとに集計し，持続ホットスポットとして提示することで，長時間に渡り要監視となる斜面の抽出精度を高める．(2) 複数事例の横断検証で外的妥当性を検証する．(3) 連続時間依存を表現できる時系列モデル（LSTM，時系列畳み込み，Transformer Encoder）の検討を進める．

謝辞

利用した XRAIN データは，国土交通省より提供されたものである．

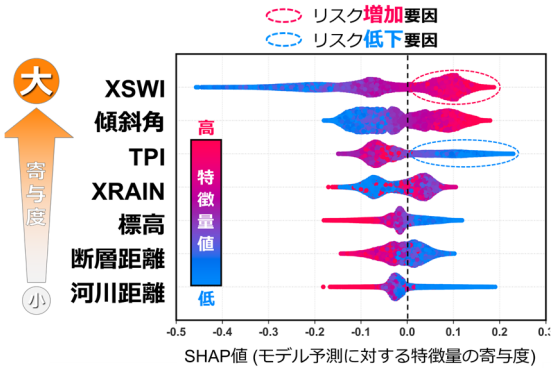


図 5　SHAP による特徴量の寄与度分析結果

参考文献

石川県（2024）令和 6 年（2024 年）奥能登豪雨に関する情報. <https://www.pref.ishikawa.lg.jp/saigai/20240921ooame.html>.

太田琢磨・橋口祥治・堀田純司・傍嶋明・矢野敦久・長岡岳・舘野聡・村上喜章・岡本知也・千々松聡・坪井嘉宏・竹順哉（2023）雨による災害危険度を表す指数と警報の危険度分布．「測候時報」，**90**，1–96.

大丸裕武（2025）能登半島地震で発生した土砂災害の特徴．「日本農学アカデミー会報」，**43**，13–19.

桑折奎吾・劉ウェン・丸山喜久（2022）機械学習に基づく豪雨による土砂崩壊発生地点の予測と説明可能 AI による予測結果の分析．「AI・データサイエンス論文集」，**3**（J2），326–338.

国土地理院（2024）令和 6 年（2024 年）9 月 20 日からの大雨に関する情報. <https://www.gsi.go.jp/BOUSAI/R6_noto_heavyrain.html>.

田中優也・後藤真太郎（2024）素因と誘因を考慮した土砂災害発生確率モデルと深層学習を併用した被災箇所早期検知モデルに関する研究．「写真測量とリモートセンシング」，**63**（3），54–68.

Lundberg, S. and Lee, S-I. (2017) A unified approach to interpreting model predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 4768–4777.

Varnes, D.J. (1978) Slope movement types and processes. *Landslides: Analysis and Control*. **176**, 11–33.