

利用者名：コンピュータサイエンス学部 教授 伏見 卓恭



Title:	Meta-learning-Based Integration of Set Encoder Outputs for MoonBoard Difficulty Estimation
論文名（和訳）	MoonBoard の難易度推定のための集合エンコーダ出力のメタ学習に基づく統合
Authors:	パトリック ダルマ（研究室学生）, 伏見 卓恭
Journal:	Machine Learning
掲載年月	2026 年 6 月

研究概要： 本研究は、標準化されたクライミング壁「MoonBoard」の課題難易度を自動推定する機械学習フレームワークを提案しています。従来のように登る手順を順序データとして入力するのではなく、配置されたホールドを順序のない「集合」として扱い、SetTransformer を用いて関係性を学習します。さらにメタ学習を用いたモデルの統合を行うことで、高精度かつ安定した難易度予測を実現しました。

研究背景： インドアクライミングの普及に伴い、客観的な難易度評価やデータ駆動型のトレーニングが求められています。MoonBoard は世界中で同じ課題を共有できるため研究に適していますが、従来の推定モデルは登る手順を手作業でデータ化する必要があり、新しい壁への適用や個人の登り方の違いを反映するのが困難でした。そのため、手順のデータ作成に依存せず、ホールドの配置情報のみから直接難易度を予測する手法が必要とされていました。

研究成果： ホールドの空間座標や形状などの属性を統合し、SetTransformer を用いてホールド間の関係を学習させることで、手順情報を用いなくても従来手法に匹敵する推定精度を達成しました。また、複数のモデルの予測結果や内部表現をメタ学習（スタッキング）によって統合するアンサンブル手法を取り入れることで、予測のばらつきを抑え、より競争力のある高精度な分類が可能になることを実証しました。

図 1 は、各モデルが難易度をどれだけ正確に分類できたかを示しています。

- 左側のグラフ：完全に正解した割合（厳密な正解率）を、性能が低い順に並べた横棒グラフです。オレンジ色の線は予測のばらつき（標準偏差）を表しています。
- 右側のグラフ：実際の難易度から「±1 グレードの誤差」までを正解とみなした場合の正解率を示しています。

図 2 は、「あるグレード以上か、以下か」という境界線（閾値）を判定するタスクの精度を示しています。

- 左側のグラフ：すべての閾値における正解率の平均値を比較した横棒グラフです。
- 右側のグラフ：V4 から V9 までの各閾値における正解率の変化を示す折れ線グラフです。

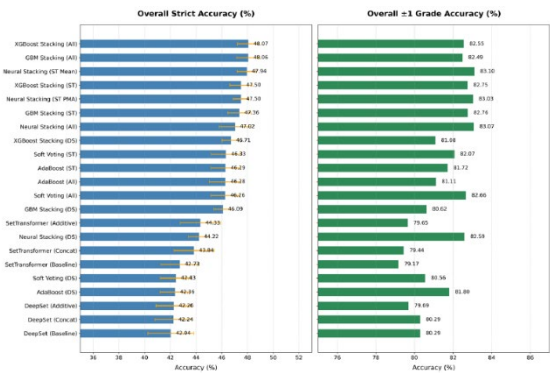


図 1 グレード分類精度




図 2 グレード順序回帰精度

社会への影響：本手法は手作業による手順データ作成を大幅に削減するため、新たなクライミング壁や膨大な課題データへの適用が容易になり、スケーラビリティが向上します。将来的には、クライマー個人の特性に合わせた難易度の推定や、AI による指定難易度の新しいルート自動生成への応用も期待されており、クライミングにおけるデータ駆動型のトレーニング環境の充実に大きく貢献する可能性があります。

専門用語：

MoonBoard：世界共通の規格で作られたインドアクライミング用のトレーニングシステムです。LED で光るホールドの組み合わせで課題が提示され、専用アプリを通じて世界中のクライマーが同じ課題に挑戦できます。

SetTransformer：入力データの順番に依存しない機械学習モデルです。本研究では、順番通りに並んでいない壁の上のホールドを「集合」として捉え、ホールド同士の空間的・意味的な相互関係を効果的に学習するために使用されています。

メタ学習（スタッキング）：複数の AI モデルが出した予測結果や内部データを、さらに別の AI（メタモデル）が学習して最終的な答えを出す手法です。各モデルの長所を組み合わせることで、単独のモデルよりも高い精度と安定性を実現します。

順序回帰：分類手法の一種で、「V4, V5, V6…」のようにクラス間に明確な大小関係（難易度の順序）があるデータを扱う際に用いられます。単純な分類とは異なり、難易度の段階的な変化や境界の曖昧さを考慮して学習できます。