ホールド形状を考慮したボルダリング課題の難度推定

大西 和歩[*1]　浦西 友樹[*1*2]　Photchara Ratsamee[*1*2]　東田 学[*1*2]
劉 暢[*3]　山本 豪志朗[*3]

Abstract – あらゆるスポーツにおいて、自身の技量を把握することは、上達を実感することや、更なる上達のためにすべきことを理解するうえで重要であり、ボルダリングもその例外ではない。ボウリングやアーチェリーなどの個人競技では、得点を自身の技量として定量的に評価できるが、一方で、ボルダリングも難度という定性的な指標が存在するものの、難度は主観的に決定されるので、一貫性がない。そこで本稿では、ボルダリングの難度決定に一貫性を持たせて信頼度を高めるために、ボルダリングのルートを客観的に分類する方法としてホールドの形状を考慮することのできるホールド難度予測モデルと課題難度予測モデルの 2 つの機械学習モデルを用いた難度分類手法を提案し、その検証結果について報告する。

Keywords ： 画像分類，機械学習，ボルダリング

1　はじめに

ボルダリングとは、クライミングウォールと呼ばれる壁に設置された人工的な突起物であるホールドを支えとして、手足を用いて制限時間内にスタート地点からゴール地点まで登攀できた数を競う競技である。ボルダリングはスポーツクライミングの一種であり、ロープなどの身に着ける安全装置を使用せず、代わりに落下の衝撃をやわらげるマット等を使用する点が特徴として挙げられる。登攀高度は 4 メートル程度に限られている。ボルダリングでは、スタート地点からゴール地点までのルートを課題と呼び、課題ごとに使っても良いホールドがあらかじめ決められている。それぞれの課題を達成する難度は様々であり、課題の難度を左右する要因は複数ある。要因の例として、ホールド間の距離、ホールドの形状、壁の傾斜角などが挙げられる。また、ホールド間を移動する際の動きをムーブと呼ぶ。ムーブには多くの種類があるものの、ホールドの配置によって使用できるムーブは限られる。そのため、使用するムーブも課題の難度を左右する。課題の難度を示す指標として、日本では主に級と段が用いられている。級は大きい数字から 1 級に近づくほど難しくなり、1 級よりも難しいものは段を用いて表され、数字が大きいほど難度が高くなる。

このような課題の難度指標には、登攀者が自身の技術レベルを測る役割と、自分のレベルを大きく上回る危険な課題を回避するという役割があるため、本来は課題の難度には一貫性があることが望まれる。一方で、課題の難度は課題の作成者あるいは最初の登攀者によって主観的に決定されるため、存在するあらゆる課題に対し一貫性のある難度設定を実現することは現状困難である。そこで本研究では、課題の難度に一貫性を持たせることを目的として、ホールド形状を考慮した機械学習モデルを考案し、課題の難度推定を試みる。

本稿の構成は以下の通りである。まず、2 節で関連研究について述べ、次に 3 節で提案手法について述べる。続いて、4 節で提案手法で用いる予測モデルの実装方法について述べる。そして、5 節で実装した予測モデルの実験評価について述べたのちに、最後に 6 節でまとめと今後の課題について述べる。

2　関連研究

本節では、既存のボルダリング課題の難度推定手法を紹介した後、本研究の位置づけについて述べる。

2.1　ウェアラブルセンサによる推定

Ebert らは、登攀時に手足に装着したセンサから得られたデータから、力の使い方や持久力などの特徴を抽出し学習させることで、98%以上の難度分類精度を達成している [1]。しかし、課題の難度の範囲はフレンチグレードの 1 から 4 に限られている。このフレンチグレードは課題の難度を 1 から 9 の間でランク付けしているが、フレンチグレードの 1 から 3 の難度はアメリカで主に利用されている V グレードの中では最も簡単な V0-に属するとされる。そのため、より高難度の課題に対して同様に課題を分類できるとは限らない。また、実験の被験者は 18 名で、のべ 153 回分の登攀データのみが用いられたため、より多くの難度を含む幅広い課題に対しても同様の分類精度を維持できるとは限らない。また、センサの装着を必要とするため、幅広く利用することが困難だと考えられる。

[*1]大阪大学大学院情報科学研究科
[*2]大阪大学サイバーメディアセンター
[*3]京都大学医学部附属病院

2.2　ドメイン固有言語による推定

Kempen らは、課題をドメイン固有言語で表し、機械学習モデルに訓練データとして与えることで、課題の難度分類を行った [2]。ドメイン固有言語では、どちらの手でどのようにホールドを掴むのかを言語化している。また、ホールドの大きさやホールド間の距離を付加情報として与えることができる。ただし具体的な数値は入力できず、“small”や “tiny”などの段階的な入力に限られる。ホールドの掴み方はホールドの形状に依存するため、こちらの手法ではホールドの形状と、ホールド間の距離の 2 つの情報を段階的に入力として用いているといえる。結果として、課題を “Easy” と “Hard”に分けた 2 クラス分類問題で 64%の分類精度を達成している。全課題のうち “Easy”に属する課題が 62%を占めていたため、必ず最も簡単な課題と分類する分類器をわずかに上回る結果となった。

2.3　2 次元配列による推定

Alejandro らは、壁のサイズや使用するホールドが規格化されており、全世界で課題を共有可能な Moonboard の課題をデータセットとして用いた [4, 3]。Moonboard 上では、18 行 ×11 列の格子状に規則正しくホールドが並べられている。これを、課題で利用できるホールドが存在する部分は 1、その他は 0 で埋められた 2 次元配列として機械学習に入力し、難度分類を試みた。すなわち本手法では、ホールド単体の形状は考慮せず、ホールドの配置のみを入力として与えているといえる。結果として、フレンチグレードの 6B+から 8B+までの 13 クラス分類問題で 36.5%の分類精度を達成している。ただし、用いられたのは最も簡単な課題である 6B+の課題が全体の 30%を占めるデータセットであった。

2.4　関連研究のまとめと本研究の位置付け

Ebert らの手法は高い分類精度を達成しているが、難度の低い課題の分類にのみ限られており、より幅広い難度の課題を正しく分類できるかは不明である。また、課題の難度を推定するために、特定のウェアラブルセンサを装着して登攀しなければならないことから、幅広い利用は難しいと考えられる。そこで、本研究では、より幅広い難度の課題を分類可能とし、かつ広く利用可能な分類方法を提案する。ここで、Kempem らの手法は、専用の機器等を使用せず、課題を言語化することのみにより課題の難度を出力でき、また、Alejandro らの手法も、ホールドが格子状に並んでいる課題であれば、簡単に難度を出力できる。そのためいずれの手法も広く利用しやすいといえるが、分類精度は高いとは言えない。Kempem らの手法で高い分類精度を達成できなかった原因は、ホールドの持ちやすさやホールド間の距離などの情報を離散型でしか入力できなかったことにあると仮定し、本研究では、これらの情報を連続型として入力できるように分類モデルを構築する。また、Alejandro らの手法で高い分類精度を達成できなかった原因はホールドの掴みやすさやホールドの形状を考慮せず、ホールドの配置のみを入力として与えたことにあると仮定し、本研究では、ホールドの難度という指標を考案することにより、ホールドの難度とホールドの配置の両方を考慮できる分類手法を提案する。

図 1　予測モデルの構成

3　提案手法

本節では、2 節で述べた要件を満たす提案手法について説明する。まず 3.1 項で予測モデルの全体の流れについて説明し、3.2 項で、予測モデルの前半部分であるホールド難度予測モデルについて述べる。そして、3.3 項で予測モデルの後半部分に当たる課題難度予測モデルについて述べる。

3.1　予測モデルの構成

本研究ではホールド情報と課題全体の情報を一度に与えて学習を行わせることは困難と考え、2 つのモデルを用いて 2 段階での課題の難度を予測する方法を提案する。提案手法では、2 つの機械学習モデルを用いて課題の難度を出力する。1 つ目のモデルは、課題に使用されている個々のホールドの難度をホールドの形状等から予測するモデルであり、これをホールド難度予測モデルと呼ぶ。2 つ目のモデルでは、ホールド難度予測モデルの出力結果とホールド間の距離等の課題全体の情報を受け取り、課題の難度を出力する。この 2 つ目のモデルを課題難度予測モデルと呼ぶ。提案手法である予測モデルの全体像を図 1 に示す。

3.2 ホールド難度予測モデル

まず本項では、予測モデルの前半部分であるホールド難度予測モデルについて述べる。一般にクライミングにおける難度の指標は、課題ごとに決定されるものである。しかし、本学習モデルにホールドの形状を難度の一部として加味するために、本研究ではホールド難度という指標を新たに提案する。また、ホールド難度には、フレンチグレードや日本の級と段による難度指標と同様の区分けを使用するが、課題の難度との混同を避けるために接頭辞として H を付与し、H1 級等と表記する。

ホールド難度は、各ホールドが使用されている課題の難度をもとに決定されるものであり、各ホールドが多数の課題で用いられている場合は、その課題の難度の平均値や中央値、最頻値等をホールドの難度とする。どの値を用いるべきかは、5 節による実験結果から議論する。各ホールドが数個の課題でしか用いられていない場合は、その中で最も簡単な課題の難度をそのホールドの難度とする。これは、一般に持ちやすく簡単とされるホールドがホールド間の距離を遠くすることで難度の高い課題で利用されることはあっても、逆に持ちにくいホールドが難度の低い課題で使われる事は稀であることに起因する。ホールド難度予測モデルは、ホールドの形状を難度の一部として加味するためのモデルであり、ホールドの形状やホールドの大きさ等の情報を入力として受け取り、ホールドの難度を予測して出力する。図 1 の緑色部分がホールド難度予測モデルに該当する。入力する情報はホールドの画像や大きさ等、入手しやすい情報に限る。具体的な入力形式は 4.1 項にて説明する。

3.3 課題難度予測モデル

次に本項では、予測モデルの後半部分である課題難度予測モデルについて述べる。課題難度予測モデルは、ホールド難度予測モデルによって出力された各ホールドの難度と、ホールド間の距離などの課題の情報を結合したものを入力として受け取り、課題の難度を出力する。図 1 の橙色部分が課題難度予測モデルに該当する。本モデルはホールド難度予測モデルの出力と、ホールドの位置関係の情報のみを入力として用いるため、広く利用しやすいといえる。具体的な入力形式は 4.2 項にて説明する。

4 予測モデルの実装

本節では、3 節で述べた提案手法の実装方法について説明する。まず 4.1 項でホールド難度予測モデルの実装について述べ、次に 4.2 項で課題難度予測モデルの実装について述べる。

4.1 ホールド難度予測モデルの実装

本研究では、Python の機械学習ライブラリである Keras[6] を用いてホールド難度予測モデルを実装した。ホールドの形状を認識させるための画像としてはホールドを正面から撮影した画像を用い、画像サイズは 256x256 ピクセルとした。またホールドの情報として、ホールドの縦幅、横幅、奥行、手で扱うホールドかどうか、スタート地点あるいはゴール地点のホールドであるか、そして壁の傾斜角を入力として与えられるようにした。表 1 に入力するホールドの情報とその入力形式についてまとめている。ホールドの縦幅、横幅、壁面上で、奥行は壁面から垂直な方向に算出する。手で掴む場合と足で踏む場合とではホールドごとの体勢の維持しやすしさが異なるため、手で掴むホールドかどうかを入力として含むことにした。また、一般にスタート地点と、特にゴール地点のホールドは難度が低い傾向にあるので、それを加味できるようにそれらの情報も含む仕様とした。

ニューラルネットワークの構造として、図 1 に示すように、ホールドの画像データに対して畳み込みニューラルネットワーク [5] を用い、1 次元化したのちに、全結合層を経由して同じく全結合層を経由したホールドの情報の入力部分と結合される。その後 Softmax 層によって各難度の確率が出力される。Softmax 層の出力のうち最も確率の高いものを、ホールド難度予測モデルが予測したホールドの難度とする。

4.2 課題難度予測モデルの実装

課題難度予測モデルでは、2 次元配列、座標、ベクトルの計 3 つの入力形式を実装した。それぞれの入力形式と、それらに対するホールド難度の情報の結合方法を説明する。

4.2.1 2 次元配列を用いた入力

2 次元配列の入力方法は、[3] において Alejandro らが用いた手法に類似している。この手法では、格子状に並んだホールドに対して使用しても良いホールドの存在する部分を 1 で、その他の部分を 0 で表すことにより、各課題を 2 次元配列で表現する。本研究では、この 1 の部分をホールド難度予測モデルが出力したホールド難度で書き換えることにより、ホールド難度を加味できるようにした。

表 1 入力するホールド情報とデータ形式

ホールド情報	データ型
縦幅、横幅、奥行	float
手で扱うか	bool
スタート地点あるいはゴール地点か	int
壁の傾斜角	float

図 2　実験に用いたクライミングウォール

4.2.2　座標による入力

座標による入力方法では、まず各課題のホールドを使用する順に順序付けし、各ホールドごとに直前のホールドからの相対座標を計算する。この相対座標とホールドの難度をホールドの数だけ羅列したものを入力とする。ただし順序付けられた初めのホールドの座標は原点にあるものとする。

4.2.3　ベクトルによる入力

ベクトルによる入力方法では、座標による入力と同様に各課題のホールドを使用する順に順序付けし、隣り合うホールドを全てペアとし、2 つのホールドの難度、ホールド間の距離、次のホールドの方向の計 4 つの入力をこのペアの数だけ課題難度予測モデルに与える。

5　実験

本節では、作成した各モデルの予測精度を確かめるために行った実験について述べる。ホールド難度予測モデルと課題難度予測モデルの結合は未完であるため、個々のモデルの分類精度を実験した。5.1 項でホールド難度予測モデルに対して行った実験について述べ、5.2 項で課題難度予測モデルに対して行った実験について述べる。

5.1　ホールド難度予測モデル

5.1.1　実験環境

ホールド難度予測モデルの実験には、図 2 に示す研究室に設置された壁を用いた。こちらの壁には計 186 個のホールドが取り付けられており、画像データ作成時に他のホールドの影響を受けにくい 183 個を実験に用いた。課題の難度は 2 級から 6 級までの計 5 種類である。

5.1.2　実験手順と評価方法

ホールドの画像を左右反転してもホールドの難度は変化しないと考え、183 枚のホールドの画像と、それを左右反転した計 366 枚の画像データを実験に用いた。うち 293 枚を学習用データとし、残りの 73 枚を検証用データとした。分類精度を正確に測るため、K を 5 として K 分割交差検証を行った。各ホールドの難度はそのホールドが用いられている課題のうち難度の最も低いものと合わせ、この設定されたホールド難度と同じホールド難度を予測モデルが出力できた場合正しい予測をしたと判断する。

図 3　ホールド難度分類の混同行列

5.1.3　実験結果と考察

実験の結果、ホールドの分類精度は 43.6%となった。分類結果を混同行列で表示したものが図 3 である。

また、表 2 にコース課題が設置してある壁に対し登攀経験のある 4 人の被験者が 183 個のホールドの難度分類を行った際の分類精度を示す。作成したホールド難度予測モデルは、4 人中 3 人の分類精度を上回る結果となった。また、図 3 の混同行列から、異なる分類をした際も 2 級以上異なる級を分類したことは少ないことが分かる。この結果から、現状のホールド難度予測モデルを用いて課題の難度を予測することは可能であると予想している。これは、課題難度予測モデルが、ホールド難度に多少の誤差があっても、ホールド間の距離等の要因も加味して課題の難度を予測するためだと考えられる。

表 2　被験者によるホールド難度分類精度

被験者番号	分類精度
被験者 1	**44.8%**
被験者 2	41.0%
被験者 3	36.6%
被験者 4	39.3%
(提案手法)	43.6%

5.2 課題難度予測モデル

5.2.1 実験環境

課題難度予測モデルの実験時には、[3] と同じく Moonboard の課題を用いた。計 11906 個の課題のうち、9524 個を学習用データとし、残りの 2382 個を検証用データとした。このデータセット内の課題の難度はフレンチグレードの 6B+から 8B+までの計 13 段階である。また、2 次元配列を入力データに用いる際は、Moonboard の格子と同じ 18×11 の配列を用いた。座標データを入力として用いる際は、最もホールドを多く用いる課題が 14 個のホールドを使用するため、入力は計 14 個のホールド難度とその座標を入力する仕様とした。ただし使用するホールドが 14 個未満の場合は使用しないホールドの部分のホールド難度と相対座標を全て 0 で表現した。ベクトルを入力として用いる際は、こちらも最も多くホールドを使用する課題のホールドの数が 14 個であることから計 13 個のホールド難度とベクトルを入力する仕様とした。こちらもホールドの個数が 14 個未満の場合は剰余となる部分を 0 で表現した。最終的な予測モデルではホールド難度予測モデルの出力を利用するが、今回は課題難度予測モデル単体の実験評価を行うために、各ホールドの難度はそのホールドが使用されている課題の難度の最頻値、中央値、平均値を用いて算出した。

5.2.2 実験結果と考察

実験結果を表 3 に示す。表 3 の「なし」の部分はホールド難度を含まずに難度分類をさせた場合、「最頻値」、「中央値」、「平均値」はそれぞれの項目を用いてホールド難度を算出した場合の分類精度を表す。結果として、二次元配列入力が最も分類精度が高くなり、その次に座標入力が続く形となった。また、座標入力とベクトル入力では中央値を用いてホールド難度を算出した場合が最も分類精度が高くなり、ホールド難度を含まない場合と比べて 7%程度分類精度が高くなる結果となった。それに対し、二次元配列入力を用いた場合は、ホールド難度の有無に関わらず同程度の分類精度となった。二次元配列入力が他の入力と比べてホールド難度による影響を受けなかったのは、学習時にデータセットから各ホールドが使われる際の傾向を学習し、こちらから与えずともホールド難度を学習していたためだと考えられる。また、ホールド難度を与えた場合と与えない場合でも大きな差が生じなかったのは、ホールド間の距離等の情報のみでもある程度課題の難度を予想できたことが考えられる。また、二次元配列を入力として用いた場合は、特定のホールドが使用されているだけで難度を推定するなどと、Moonboard に過剰に適応している可能性があるため、今後両モデルを結合させて、幅広い課題に対して正しく難度推定を行えるようにする際は、Moonboard に適応しすぎずに課題の難度傾向を学習させる必要がある。

表 3 課題難度予測モデルの分類精度

	なし	最頻値	中央値	平均値
二次元配列	70.1%	70.0%	70.4%	70.1%
座標	60.9%	65.8%	67.8%	66.8%
ベクトル	57.8%	63.9%	65.9%	64.2%

6 おわりに

本研究では、ボルダリング課題の難度推定を行う方法として、機械学習を用いてホールド形状を考慮できる難度予測モデルを提案した。この難度予測モデルは、ホールド難度予測モデルと課題難度予測モデルの 2 つに分かれており、それぞれに対して実験を行い、分類精度を調査したところ、ホールド難度予測モデルは 5 クラス分類問題で 43.6%の分類精度を達成し、課題難度予測モデルは 13 クラス分類問題で 70.4%の分類精度を達成した。

今後の課題としては、まずホールド難度予測モデルと課題難度予測モデルの両モデルを結合することが挙げられる。この際、Moonboard の課題だけでなく、ホールドが格子状に並んでいない課題に対しても難度推定が行えるようにするなど、幅広く利用可能な難度推定モデルとなるようにしたい。また、難度推定を行う際に、各課題のある部分が難度にどれだけ関与しているかを数値化し、それを AR による補助を用いて登攀時に可視化することを最終目標としたい。

参考文献

[1] Ebert André, Schmid Kyrill: Automated recognition and difficulty assessment of boulder routes; HelthyIoT ’17, pp. 62–68 (2017.October)
[2] Kempen Lindsay: A fair grade: assessing difficulty of climbing routes through machine learning; Formal Methods and Tools, University of Twente, (2018)
[3] Alejandro Dobles, Juan Carlos Sarmiento: Machine Learning Methods for Climbing Route Classification; Stanford University, (2017)
[4] https://www.moonboard.com/
[5] Alex Krizhevsky, Ilya Sutskever: ImageNet Classification with Deep Convolutional Neural Networks; Advances In Neural Information Processing Systems ’12, pp. 1097–1105 (2012.December)
[6] https://keras.io/

© 2022 by the Virtual Reality Society of Japan (VRSJ)