

スポーツクライミングにおける ホールドの難易度推定モデルの設計

西野 直登^{1,a)} 桂 大地¹ 棟朝 雅晴^{1,2}

概要: 本研究では、スポーツクライミングにおけるホールドの3次元オブジェクト情報を数値化し、PointNetと呼ばれる3次元形状データに対する深層ニューラルネットワークを用いてホールドの難易度推定を行う。用いるデータセットはクライミング経験者への調査実験と、実物のホールドを3次元スキャンしたデータにより作成され、モデルの学習とテストを行った。提案する一連のアーキテクチャより、3次元オブジェクトの形状情報からホールドの難易度予測を実現する可能性が示唆された。

Design of a model for estimating the difficulty of holds in sport climbing

NISHINO NAOTO^{1,a)} KATSURA DAICHI¹ MUNETOMO MASAHARU^{1,2}

Abstract: In this study, we quantify the 3D object information of holds in sport climbing and estimate their difficulty using a deep neural network for 3D shape data called PointNet. The dataset used was generated by survey experiments with experienced climbers and 3D scans of real holds, which are used to train and test the model. The proposed architecture suggests the possibility of predicting the difficulty of holds from the shape information of 3D objects.

1. はじめに

1.1 背景

スポーツクライミングは様々な傾斜・形状の壁に取り付けられたホールドと呼ばれる突起物を使用し、設定されたスタートからゴールまで自身の肉体のみを用いてどこまで登れるかを競うスポーツである。スポーツクライミングを題材とする研究には、クライミングのコース（スタートからゴールまでの一連の手順）を生成 [1], [2] あるいはコースの難易度を判定 [3] するといったものがある。現状これらのような機械学習等によるクライミングの研究は、ホールドの難易度を直接考慮していないという問題がある。実際のクライミングにおいてホールドの持ちやすさがコースに及ぼす影響は大きく、先行研究 [1] では将来的にホールドの考慮が必要であることについて言及している。

1.2 研究の目的

本研究の目的はホールドに対して難易度（持ちやすさ）という観点での定量化を行うことである。ホールドに取り付けたセンサーによるホールドの難易度に関する研究 [4] は行われているが、形状データによる難易度の推定は行われておらず、アプローチやデータセット等すべて未開拓の領域である。2節で本研究での推定方法とデータセット、モデルの説明を行い、3節で推定の結果を示す。

2. ホールド難易度推定手法

2.1 推定の方法

ホールドの難易度推定には、3次元オブジェクトに対する分類を行うディープニューラルネットワークアーキテクチャの PointNet[5] をベースとしたモデルを用いた。本研究ではホールド実物の3Dデータ化、データに対する教師ラベルの定義、モデルの構築と学習の順に実装した。

¹ 北海道大学大学院 情報科学院
Graduate School of Information & Science, Hokkaido University

² 北海道大学 情報基盤センター

a) n-nishino@eis.hokudai.ac.jp

2.2 データセットの作成

研究に際して、MoonBoard^{*1}の2017年版に使用される198個のホールド実物を用意した。これをAUTODESK社^{*2}が提供するソフトウェアRecapProを利用しoffファイル形式の3Dメッシュデータとした。このデータを1024点の点群データに変換し、モデルの入力として用いた。学習に必要な教師ラベルは、9人のクライミング経験者^{*3}への調査実験により得られた結果の中央値を教師ラベルと定義した。また、難易度の粒度について議論が行われた研究はないため、2,4,8,16の4通りの粒度で分類した。結果のラベルは $[0, (\text{粒度の大きさ}) - 1]$ の範囲で、0に近いほど持ちやすく、値が大きいほど持ちにくいという判断である。

2.3 モデルの構成

推定に用いるモデルはPointNetの出力と損失関数を回帰ベースに変えたものである。元のPointNetは分類器であるが、回帰へと変更する利点は主に2つある。

- (1) 推定したい数値は $[0, (\text{粒度の大きさ}) - 1]$ の範囲の順序尺度であり、数値の大小に意味がある。回帰であれば仮に推定の結果が正解ラベルと一致しなくとも、近い値を出力することが望ましい。分類問題ではラベルの大小に意味はなく、正解ラベルと一致か不一致のみである。
- (2) (1)に関連して、分類問題に用いられる損失関数の交差エントロピー誤差は、ソフトマックス関数を通して得られた確率のうち正解であるラベルのものしか損失として計算されない。一方、回帰の場合、平均二乗誤差等の一般的な損失関数であれば推定が正解ラベルと一致していなくとも、出力の値が近い場合には小さい損失、値が遠い場合には大きい損失であることを適切に表現できる。

回帰の損失関数にはHuber損失を用いた。また、回帰の出力はfloatで得られ、ラベルの範囲外の値が得られることもあるが、四捨五入し、ラベル数値範囲内の最も近い値に丸めた。

今回用意したデータは198個と少なくラベルの偏りもみられたため、層化K分割(Stratified KFold)で(分割数)=18とし、一度の学習で187個を学習、11個をテストデータとして予測した。最終的に198個全てに対して予測結果を求めた。

3. 予測の結果と考察

ホールドの難易度推定の結果について、ヒートマップ形式の混同行列を図1に示す。混同行列はある1回分の結果のうち、粒度8のもののみ示しており、比較のために分類




図1 分類(左)と回帰(右)による粒度8の多クラス混同行列とヒートマップ

Fig. 1 Multiclass confusion matrix and heatmap with granularity 8 using classification (left) and regression (right).

アーキテクチャでの結果も合わせて示す。混同行列は、斜め右下がりの対角線が正解ラベルと予測ラベルの一致を表している。2.2節で作成したデータは、ラベルが4と6のものにデータが偏っており、PointNetの分類アーキテクチャによる結果である図1の左図は、このデータの偏りが影響し順序尺度であるホールドの難易度分布をうまく表現できていない。一方、右図の回帰による結果は分類よりも縦軸の正解ラベルになるべく近い値を予測するという、順序尺度に対してより適切な分布が表現できている。

4. まとめと課題

ホールドに対してどのような定量化を施すかという問題に対して、3次元の形状情報から回帰ベースの深層学習モデルを用いて定量化するという新しい試みを提案した。現状のデータ数が198個と少なく、予測精度を向上させるためデータセットを増強する予定である。さらに得られた難易度をコース作成等の既存の研究に取り入れ、精度の向上を図る予定である。

参考文献

- [1] Naderi K., Rajamäki J., Hämäläinen P.: *Discovering and synthesizing humanoid climbing movements*, ACM Trans. Graph., vol.36, no.4, (2017).
- [2] Dung N. A., Shimada A.: *A path-planning algorithm for humanoid climbing robot using Kinect sensor*, Proceedings of the SICE Annual Conference (SICE), pp.1549-1554, (2014).
- [3] Dobles A., Sarmiento J. C., Satterthwaite P.: *Machine Learning Methods for Climbing Route Classification*, 入手先 (<http://cs229.stanford.edu/proj2017/final-reports/5232206.pdf>), (2017).
- [4] Fuss F. K., Niegl G.: *Quantification of the Grip Difficulty of a Climbing Hold (P142)*, The Engineering of Sport 7 vol.2, Springer (2008).
- [5] Charles R. Q., Su H., Kaichun M., Guibas L. J.: *PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation*, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.77-85, (2017).

*1 <https://www.moonboard.com/>

*2 <https://www.autodesk.co.jp/>

*3 日本段級グレード1級程度を登れる者