

令和2年度大阪大学未来基金「学部学生による自主研究奨励事業」研究成果報告書

ふりがな 氏名	わだ てつや 和田 哲也	学部 学科	工学部 電子情報工学科	学年	3年
ふりがな 共同 研究者氏名	たかしま かずき 高嶋 和貴	学部 学科	工学部 電子情報工学科	学年	3年
	しんざき よしお 新崎 義峰		工学部 電子情報工学科		3年
	チャラン バブプリータ プラタブ Charan Bhavpreeta Pratap		工学部 電子情報工学科		3年
	アドバイザー教員 氏名		やぎ やすし 八木 康史		所属
研究課題名	ディープラーニングを用いた空手の型競技の上手さ判定				
研究成果の概要	研究目的、研究計画、研究方法、研究経過、研究成果等について記述すること。必要に応じて用紙を追加してもよい。(先行する研究を引用する場合は、「阪大生のためのアカデミックライティング入門」に従い、盗作剽窃にならないように引用部分を明示し文末に参考文献リストをつけること。)				

研究目的

空手の型は来年の東京オリンピックの種目であるが、初心者には非常に分かりにくいスポーツである。目の肥えていない素人には「なぜ勝ったのか、負けたのか」「どこで勝負が別れたのか」などが分からず、スポーツとしての盛り上がりに欠けている。そこで、型競技の「上手さ」を可視化して誰でも空手の型競技を楽しめるようにしたいと以前から考えていた。

型の「上手さ」可視化するために、コンピューターが型の「上手さ」を認識できる必要がある。また、そもそも型とは個別の空手技を決まった順番で繰り出してゆく競技である。そこで本研究では、型全体の上手さを推定するためのステップとして、技の動画を読み込み、その「上手さ」を点数で推定することを目的とする。

研究計画

一般的に空手の型は全体で30秒から90秒ほどの長さがあり、1~3秒程度の個別の技が連なったものとして考えることができる。そこで、型の上手さを評価するというタスクを「型の動画を技ごとに分割する」「個別の技の上手さを評価する」という2ステップに分けて考える。

去年の自主研究で作成済みの内容

・空手の型のデータセット

空手教室の生徒15人及び本研究の代表者1人が流派「林拳空手道」の「少林拳1」という型を演じる様子を、選手を取り囲むように21方向から撮影した。カメラの解像度は640×480である。選手1人につき少林拳1の型を合計4回演じてもらった。様々な上手さのデータを作るために、そのうち2回はわざと手を抜いて演じてもらった。カメラの不具合等によりデータの一部が欠損したため、最終的に得られたデータはのべ63人の17視点からの映像となった。

今年取り組んだこと

・データセットのラベル付け

機会学習を行うためには、撮影した型の映像について、それぞれどの程度の上手さかを表すラベルを付与する必要がある。そこで、流派「少林拳空手道」の師範 1 名に、データセットのラベル付けを行ってもらった。

・C3D モデルで上手さを認識

上記のデータセットをニューラルネットワークに学習させ、その後、型に含まれる個別の技の上手さを推定した。型の動画を技ごとに分割する作業は将来的に取り組むものとし、本研究ではすでに技ごとに分割された動画に対して上手さを推定することに取り組んだ。近年、行動認識では、動きに関する特徴と物体や見た目に関する情報を同時に特徴化することができる 3 次元の疊み込みニューラルネットワーク (3DCNN) による手法が注目されている。その中でも、シンプルなアーキテクチャで理解しやすいモデルとして本研究では C3D[1] を利用した。

今後取り組みたいこと

本研究は型競技の上手さを認識するためのステップとして取り組んだ。今後、技の区切りの認識や、Grad-CAM[2]などの CNN に対する可視化技術を利用して上手さの可視化を行うことを検討している。また、今回取り組んだ内容についても認識精度をより向上させるために、オプティカルフローを利用した 2 ストリーム C3D[3] を導入することを検討している。

研究方法

・データセットのラベル付け

流派「少林拳空手道」の師範 1 名に、データセットのラベル付けを行ってもらった。本研究では型の動画を技ごとに分割し、技の動画について上手さを学習・推定した。そのため、型全体の上手さではなく、技ごとに上手さを表すラベルを付与する必要があった。ラベルづけを行う師範には、各選手について全 17 視点からの型全体の映像を見てもらったのち、型に含まれる 5 つの技についてそれぞれ上手さを表すラベルを付与してもらった。

本来の空手の試合では審判が 7 人おり、各審判は「テクニカルパフォーマンス」と「アスレチックパフォーマンス」の 2 項目についてそれぞれ 10 点満点で小数点一桁までの点数をつける。前者は姿勢・美しさ・正確さなどに関する項目であり、後者は力強さやスピードに関する項目である。それぞれの項目に 7 人分の点数が付けられるが、そのうち点数が大きい方から 2 つ、小さい方から 2 つを取り除き、残った 3 人分の点数を合計する。各項目に 30 点満点で得点がつくが、「テクニカルパフォーマンス」の点数（以下 TCH スコア）は 0.7 倍、「アスレチックパフォーマンス」の点数（以下 ATH スコア）は 0.3 倍し、それら 2 つの点数を合計して 30 点満点の得点となる。

本研究では実際の空手競技の評価手順にならい、2 つの評価項目について各 10 点満点で 0.1 点刻みのラベルをつけた。さらに、各技についての総合点（以下 TOTAL スコア）を TCH スコアの 0.7 倍と ATH スコアの 0.3 倍の和として計算した。この際、ラベルづけする師範には選手が全力で演じているのか、手を抜いて演じているのかはえないことによって、全力か手を抜いているかには関係なく、型の上手さにのみ注目してラベルをつけた。

・C3D モデルで上手さを認識

上記のデータセットを学習させ、型に含まれる個別の技の上手さを推定した。すでに技ごとに分割された動画に対して上手さを推定することに取り組んだ。

C3D とは 3 次元の畳み込みを行うニューラルネットワークのモデルである。前半の特徴抽出器は 8 層の畳み込み層と 5 層のプーリング層の組み合わせで、後半は全結合層である。ネットワーク図を以下に示す。




図 1 C3D のネットワーク図

本研究で扱う空手型のデータセットは量が少ないため十分に学習できない可能性があった。そこで特徴抽出器のパラメータは Sport1M[4] データセットで学習済みのモデルのパラメータをコピーして使用し、学習の際は後半の全結合層のパラメータのみを更新した。10 点のラベルを 0-1 に正規化したものを真値として、C3D を利用し回帰問題として技の「上手さ」を学習した。データセットの数が少ないので、認識精度を評価する際は 16 人の被験者で leave one subject out の交差検証を行った。

経過

研究メンバー 4 人で作業を分担し、それぞれ得意な内容を担当した。作業内容は、本研究に関連する先行研究の調査や、学習に使用するデータの前処理、C3D の実装作業などである。C3D の実装についてはインターネット上に公開されているプログラムを参考にしたが、入力するデータやプログラムを実行する環境などが原因で様々なエラーが発生し、正常に学習できるようになるまでかなりの労力を要した。

2 週間に一度、研究メンバー全員と指導教員の村松先生でミーティングを行い、研究の進め方や実験結果の考察について議論した。

研究成果

・最適なモデル構成

まず、本研究の問題設定に最も適したネットワーク構成を検討するために、全結合層について、層の深さや各層の素子数を様々に変更したネットワークを用意した。技 2 のカメラ 1 からの映像を用い、被験者 4, 14 をテストデータ、それ以外を訓練データとして学習・推定を行った。その後、各ネットワークの推定値について正解値からの平均二乗誤差を計算した。なお、バッチサイズは使用した計算機が対応できる最大値の 64 とし、エポック数は 100 とした。結果を表 1 に示す。

表 1 様々なネットワーク構成における技の上手さの正解値からの推定値の平均二乗誤差

fc6	fc7	平均二乗誤差
32	32	0.67225025
64	32	0.45799172
128	32	0.59152805
64	64	0.44930709
128	64	0.49674745


	256	64	0.49126252	
	128	128	0.46261298	
	256	128	0.49477157	
	256	256	0.47834114	
	512	256	0.46333839	
	512	512	0.40679331	
	1024	512	0.43310637	
	1024	1024	0.46810058	
	4096	4096	0.41332422	

fc6 層、fc7 層の素子数がそれぞれ 512 のネットワークにおいて最も平均二乗誤差が小さくなつた。以降ではこのネットワーク構成で学習を行つた。

・最適な視点

次に、入力する動画の視点によって推定精度がどの程度変化するか確かめるために、各技について 5 つの視点の動画で学習・推定を行つた。これらの学習・推定においては、技と視点以外の条件は全て一致している。その後、各条件における推定値について、正解値からの平均二乗誤差を計算した。被験者 1 をテストデータ、それ以外を訓練データとし、ラベルは tch score を使用した。結果を表 2 に示す。

表 2 各技の各視点における推定値の正解値からの平均二乗誤差

		カメラ 10	カメラ 16	カメラ 18	カメラ 20	カメラ 21
技 1	入力動画の一例					
	平均二乗誤差	0.016188647	0.204276282	0.150594432	0.195018102	0.067065429
技 2	入力動画の一例					
	平均二乗誤差	0.23035774	0.236131906	0.219709996	0.27113468	0.172383575
技 3	入力動画の一例					
	平均二乗誤差	0.194904524	0.258880139	0.273030376	0.15408194	0.173665725

技 4	入力動画の一例					
	平均二乗誤差	0.164972997	0.173882608	0.167448567	0.096982272	0.159568469
技 5	入力動画の一例					
	平均二乗誤差	0.021621271	0.060623025	0.08496228	0.032133186	0.04101096

※各技内で最小の値をグレーで表示

視点によって推定誤差が2倍程度変化することがわかった。また、光の加減で選手の姿が真っ白に写っている視点では推定誤差が大きくなる傾向があった。これは、真っ白に写っている場合だと選手の動きに関する情報が少なくなるためだと考えられる。他に、水平から撮影したカメラの方が推定誤差が小さい傾向にあった。これは、より選手が大きく映るためだと考えられる。

・最適なスコアラベル

次に、使用するラベルによって推定精度がどの程度変化するか確かめるために、各技について TCH スコア、ATH スコア、総合スコアの3種類のスコアを用いて学習・推定を行った。スコアラベルによってばらつきが異なっており、ばらつきが大きいラベルで推定するほど推定値の正解値からの平均二乗誤差は大きくなりやすいため、単純にこの値を比較することはできない。そこで、推定値の正解値からの平均二乗誤差(a)とラベルの平均値を推定値とした時の平均二乗誤差(b)を計算し、a を b で除算した値を比較する。(b)は入力にかかわらず一定の値を出力するモデルである。a が b に対して小さいほど判別性能が良いと考えることができる。結果を表3に示す。

表3 各スコアラベルにおける平均二乗誤差

		平均二乗誤差(a)	平均値を推定値としたときの平均二乗誤差(b)	a/b
技1	TCHスコア	0.016188647	0.246067019	0.06578958464
	ATHスコア	0.013524071	0.175605946	0.07701374186
	総合スコア	0.012795448	0.268271202	0.04769594319
技2	TCHスコア	0.172383575	0.345396825	0.4990884754
	ATHスコア	0.258647038	0.215147392	1.202186326
	総合スコア	0.193212849	0.273614412	0.7061501176
技3	TCHスコア	0.173665725	0.339430587	0.5116384075
	ATHスコア	0.263973215	0.245810028	1.073891157
	総合スコア	0.201473454	0.26711479	0.7542579514

技 4	TCH スコア	0.096982272	0.31766188	0.3053003153
	ATH スコア	0.182636125	0.225704208	0.8091835192
	総合スコア	0.118970571	0.210600504	0.5649111412
技 5	TCH スコア	0.021621271	0.232582514	0.09296172177
	ATH スコア	0.039448433	0.222222222	0.1775179485
	総合スコア	0.024415601	0.183758025	0.1328682165

5つの技のうち4つでTCHスコアが最も推定誤差が小さくなかった。また全ての技においてATHスコアよりTCHスコアの方が推定誤差が小さくなかった。総合スコアはTCHスコアとATHスコアを合算して計算されることを考慮すると、ATHスコアよりTCHスコアの方が推定しやすいと考えられる。

RGBのC3Dネットワークはアビアランスに強い影響を受けると言われている。ATHスコアは動きの緩急に関する評価項目であるため、RGBのC3Dネットワークではうまく特徴抽出できなかったと考えられる。一方、物体の動きを表すオプティカルフローを入力とするC3Dネットワークを用いればATHスコアの推定誤差が小さくなる可能性がある。

・最適な視点とスコアについて交差検証

以上で求めた、推定誤差が最も小さくなるネットワーク構成・視点・スコアラベルにて、学習・推定を行い、推定値について正解値からの平均二乗誤差を計算し、aをbで除算した値を比較した。なお、学習・推定時はleave one subject outの交差検証を行った。結果を表4に示す。また、技2について正解値と推定値の関係をプロットした図を図2に示す。

表4 最適なネットワーク構成・視点・スコアラベルにおける交差検証の平均二乗誤差

	カメラ番号	スコアラベル	平均二乗誤差 (a)	平均値を推定値とした時 の平均二乗誤差(b)	a/b
技1	カメラ10	総合スコア	0.148219307	0.199414412	0.743272792
技2	カメラ21	TCHスコア	0.188003927	0.345396825	0.5443128404
技3	カメラ21	TCHスコア	0.282614012	0.339430587	0.8326120949
技4	カメラ20	TCHスコア	0.231145866	0.31766188	0.7276474793
技5	カメラ10	TCHスコア	0.133427753	0.232582514	0.573679211




図2 技2における正解値と推定値の関係

a/b の値は技によって 0.55~0.85 程度となった。推定値の誤差はおよそ 0.3~0.5 点程度となる。図2からもわかるように、モデルは全く学習していないわけではないが、一方で熟練者の知見を得たとまでは言えない。本研究の目的である、初心者にわからないような型の細かな違いを認識するまでは至っていない。

要因の一つとしてあげられるのはデータセットの不足、特に下手な型のデータの不足である。型競技では、決まったルールから外れた動きをすればどのような動きでも下手だと判定される。今回のデータセットに含まれる下手な型は様々な動きをしており、学習データに含まれていない下手な動きがうまく推定できなかったと考えられる。

参考文献

- [1] Tran, Du, et al. "Learning spatiotemporal features with 3d convolutional networks." *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2015.
- [2] Selvaraju, Ramprasaath R., et al. "Grad-cam: Visual explanations from deep networks via gradient-based localization." *The IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 618-626.
- [3] Feichtenhofer, Christoph, Axel Pinz, and Andrew Zisserman. "Convolutional two-stream network fusion for video action recognition." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016.
- [4] Karpathy, Andrej, et al. "Large-scale video classification with convolutional neural networks." *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*. 2014.