

AHPに着想を得たゼロショット行動認識手法の一検討

豊増 聖実* 佐藤 公治† 藤波 香織‡

* 東京農工大学 工学部 情報工学科 † 東京農工大学 大学院 工学府 情報工学専攻
‡ 東京農工大学 大学院 工学研究院 先端情報科学部門

1 はじめに

近年小型センサの普及と発展とともに機械学習を用いた行動認識に関するが盛んに行われている。代表的な機械学習の1つである教師あり学習では、学習データそれぞれに行動のラベルをつけその分類の規則を学習する。しかし、教師あり学習は未知クラスの行動を認識することができないという問題がある。そのため、教師あり学習を用いて多くの行動を認識するには、対象になりうる行動のデータ全てにラベル付けを行う必要がある。しかし、日常生活の行動は非常に多く、それら全てに対してラベルを付与するには膨大な労力を要する。この問題点を解決する方法としてゼロショット学習がある[1]。ゼロショット学習ではクラス間で共通する情報である補助情報を用いることで学習データにない未知クラスの推定が行える。しかし、NuActiv[2]のような既存の手法では認識可能な行動の数に制限ができる。本研究ではこの問題を解決する認識手法を提案する。

2 先行研究

ゼロショット学習の代表的なモデルの一つに意味属性性を補助情報に使うDAP(Direct Attribute Predict)モデルがある[1][2]。意味属性とは行動を表すための単位行動であり、「座っている」や「手首が動いている」、「激しい動き」等がある。これらの属性の有無を行動ごとに定めたものを意味属性行列と呼び、事前に人の主観にもとづいて定義しておく。行動の認識には、各属性の有無を属性検出器で判定し、各属性検出器の結果を統合し意味属性行列と比較する。しかしこの場合定義できる行動は属性数をNとして 2^N 個に制限される。以上の問題点を解決するために本研究では、連続な意味属性値を用いた行動認識手法を提案する。これにより定義できる行動の数に制限がなくなる。

3 認識手法概要

図1に示す流れで認識を行う。まず生データから特徴量を計算し、属性毎に用意した属性値算出器で属性の含有程度(属性値)を算出する。そして、その属性値を行動分類器に与え行動を判別する。




図1: 認識の流れ

行動分類器には、代替案選択手法の一つであるAHP(Analytic Hierarchy Process)の考え方を利用する。代

替案を「行動」、評価項目を「属性」とすることで、行動間の属性値を一对比較で簡単に決定できることからAHPの考えを利用した。意味属性行列作成時と、図2の行動得点計算時にこの考えを利用した。属性値算出器は意味属性行列(図2a)に含まれる属性値を目的変数、特徴量を説明変数として回帰式により属性値を算出する。意味属性行列は、属性ごとに行動の一对比較を行い、各行動がもつ属性値を相対的に決め作成する。行動分類器では、属性値算出器で求めた属性値(図2b)を重みとして意味属性行列の各要素に掛け合わせ、行動ごとに要素を合計し「行動得点」を計算し、最終的に合計点が一番高い行動が予測クラスとして選ばれる(図2c)。新しい行動を追加する場合は、追加する行動とすでに定義済みの行動について属性の一对比較を行い、意味属性を定義するだけでよい。

a. 意味属性行列

行動\属性	①	②	③
散歩	0.6	0.5	0.1
読書	0.1	0.2	0.4
料理	0.3	0.3	0.5

b. 属性算出器の出力

属性値	①	②	③
	0.4	0.4	0.2

c. 得点計算

	※1	※2	※3	行動得点
散歩	0.6×0.4	0.5×0.4	0.1×0.2	0.46
読書	0.1×0.4	0.2×0.4	0.4×0.2	0.20
料理	0.3×0.4	0.3×0.4	0.5×0.2	0.34

※1 + ※2 + ※3 = 行動得点

①: 立っている, ②: 激しい動き, ③: 手首が動いている

図2: 行動認識手法概要

4 意味属性行列の作成

本研究で使用する意味属性行列は人の主観にもとづき作成をした。8人の協力者に行動の様子を撮影したビデオを見せ、各行動の属性の程度を比較させた。ビデオは5章の評価実験で使用するデータセット[3]で提供されているものを使用した。また意味属性については先行研究[2]で使用された日常行動のための意味属性セットを使用した。また本実験で使用するデータセットは「朝の行動」を集めたものであり、行動が「朝」に限定されるため、時間を表す属性「朝」、「昼」、「晩」の属性は除き、計14属性を使用した。

まず、属性ごとに各行動の属性の程度を10段階で一对比較させた。その後、8人分の結果を属性ごとに幾何平均し、それぞれの評価値を計算し、最後に結果をまとめて意味属性行列を作成する。なお、作成した意味属性行列は、そのままでは理想的な属性が属性値算出器から算出されたとき、つまり意味属性行列で定義された属性値と全く同一な属性値が算出されたとき、誤分類が起こることが事前の調査で分かった。これはある行動の属性値が全て低く、かつ似た意味属性を持つ行動があるときに発生することが分かったため、それらの行動の意味属性が異なるようにした。そのためにまず、意味属性値がすべて低い行動をなくすべく、行動ごとに属性値を正規化した。次に意味属性行列の各要素をそれぞれ2乗し行動ごとに意味属性に差が出るようにした。AHPは評価基準ごとに正規化されていることが前提であるため、最後に属性ごとに正規化を行っ

Toward zero-shot daily activity recognition based on AHP

* Seiji TOYOMASU † Koji SATO ‡ Kaori FUJINAMI

* , † , ‡ Department of Computer and Information Sciences, Tokyo University of Agriculture and Technology

た. 作成した意味属性行列を図3に示す. グレーは意味属性がほかの行動と比較して高い部分を示す. 評価実験ではこの意味属性行列を使用する.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
a	0.12	0.09	0.12	0.11	0.13	0.11	0.12	0.07	0.09	0.11	0.13	0.10	0.12	0.13
b	0.09	0.07	0.12	0.05	0.11	0.10	0.10	0.06	0.06	0.36	0.11	0.08	0.11	0.12
c	0.12	0.09	0.13	0.08	0.14	0.13	0.15	0.08	0.08	0.08	0.13	0.16	0.14	0.06
d	0.14	0.08	0.13	0.17	0.13	0.12	0.12	0.07	0.10	0.08	0.13	0.10	0.13	0.05
e	0.15	0.08	0.13	0.17	0.13	0.12	0.12	0.07	0.10	0.08	0.13	0.10	0.13	0.05
f	0.16	0.09	0.13	0.18	0.13	0.09	0.08	0.09	0.15	0.08	0.13	0.10	0.08	0.05
g	0.09	0.04	0.10	0.07	0.07	0.16	0.18	0.27	0.03	0.09	0.11	0.20	0.18	0.04
h	0.11	0.06	0.08	0.15	0.09	0.10	0.09	0.11	0.20	0.07	0.08	0.09	0.07	0.26
i	0.02	0.39	0.06	0.02	0.08	0.08	0.07	0.17	0.19	0.06	0.07	0.05	0.23	

表 1: 分類器精度の比較

図 3: 意味属性行列

5 評価実験と考察

5.1 実験概要

3章で説明した行動得点を計算して最終的な認識クラスを得る手法と, 最近傍法 (1NN) を用いて最終結果を得る認識手法の2つを実装し, 比較のために DAP モデルである NuActiv[2] を再現し評価実験を行った. その際, 1人抜き交差検証でそれぞれの属性値を算出した結果を用いて, 行動の分類をした. NuActiv に使用する意味属性行列は, 4章で作成した意味属性行列をもとに, 各要素が属性毎の属性値の平均より大きければ1, 小さければ0として作成した.

実験には日常生活に関する行動18種類を, 身体様々な場所にセンサを装着した4人の被験者に行わせて収集した OPPORTUNITY データセットを用いた [3]. 本実験では腕, 手首, 臀部, 背中に付けた3軸加速度センサのデータを使用し, 行動は「ドアの開け閉め」や「机を拭く」のような単純な短い動作の9つを使用した. 属性値を算出するための特徴量は, 3軸加速度センサ各軸の平均, 分散, 歪度, 尖度, 相関, 平均値交差回数, FFT エネルギー, FFT エントロピーの8種類34個を使用した. 属性値の予測には回帰式を用いた. 回帰の方法として, SMOregression, LinearRegression, M5P, MultilayerPerceptron, RandomForest を比較し, 最良の精度を出した RandomForest を用いた.

5.2 実験結果

本実験の再現率, 適合率および F 値の平均を表1に示す. また, 行動得点を利用した認識手法の混同行列を図4に示す. 行が真のクラスで列が予測されたクラスである. 例えば1行2列目は「冷蔵庫の開け閉め」が「食洗機の開け閉め」に誤分類された割合 (%) を示す. また同時に行動ごとに誤分類が起きた割合の平均値を示す.

表 1: 分類器精度の比較

項目	NuActiv	連続値の意味属性 + 行動得点計算	連続値の意味属性 + 1NN
再現率	0.211	0.235	0.180
適合率	0.247	0.192	0.393
F 値	0.175	0.183	0.143

5.3 考察

表1より行動得点を利用した手法は, 本実験において NuActiv と同程度の F 値になった. またその手法は, 最近傍法で意味属性行列から行動を選ぶ手法よりも高い F 値になった. NuActiv と同程度で, 他の連続値の意味属性を使用した分類器よりも良い精度を出せたことから, 行動得点を利用した手法は連続値の意味属性




図 4: 一人抜き交差検証の混同行列 (行動得点使用した手法)

を使用したゼロショット学習の一手法としての可能性を示唆できたといえる. しかし, 本実験ではすべての手法で [2] で行われた実験の精度以下になった. これには属性値の算出の精度が悪かったことや, 9つの行動のセットに対して14個の意味属性のセットが最適でなかったこと等が考えられる. 今後は, 精度を下げた原因を特定し再度実験をする必要がある. また意味属性行列の作成方法の影響についても調査する必要がある.

図4より, 分類器が誤分類を起こしやすい行動がわかる. 例えば「タンスの開け閉め」に誤分類された平均では27.8%で一番高い. これは多くの行動の意味属性が「タンスの開け閉め」と似ているからであると考えられる. 一方, 「食洗機の開け閉め」や「座って飲む」では正しく分類されるインスタンスの割合が多い. これは「タンスの開け閉め」と属性値が高くなる意味属性の組み合わせが異なるためと考えられる. 「立って飲む」も同様に異なるが, これは「座って飲む」と似ているため正しく分類される割合が少ない. 誤分類を減らすためには意味属性間に差が生じるように意味属性行列を作成することや, 使用する意味属性の変更が必要であると考えられる.

6 おわりに

本研究では連続値の意味属性を用いた DAP ゼロショット行動認識手法を提案した. 現状の提案手法は精度が非常に低いものの, 新たな行動を追加のデータ収集をせずに認識対象に加えられる性質があり, 拡張性がある行動認識手法といえる. 今後は精度をより高めるような分類器や意味属性行列のチューニングや, 精度を下げる属性の特定を進める. そして, 意味属性行列の作成方法を新たに考案し, また行動を増やしての実験を通じて認識手法の有用性を示す.

謝辞

本研究は, (公財) 電気通信普及財団 平成28年度 研究調査助成の支援を受けた.

参考文献

[1] 鈴木, 他. 属性ごとの観測確率を考慮したゼロショット学習, 情報処理学会論文誌 .57 (5) pp.1499-1513 (May 2016)

[2] H.-T. Cheng, et al. NuActiv: Recognizing Unseen New Activities Using Semantic Attribute-Based Learning, In Proc. of MobiSys'13, pp. 361-374 (June 2013)

[3] OPPORTUNITY Activity Recognition Data Set <https://archive.ics.uci.edu/ml/datasets/opportunity+activity+recognition/> (2018/01/05 アクセス)