

センサ行動認識における Zero-shot 学習法のためのベクトル表現の性質の分析

松木 萌¹ 井上 創造¹

概要：本稿では、センサ行動認識における Zero-shot 学習法において分散ベクトル表現を用いることについて検討する。センサ行動認識は、一般的に教師あり機械学習が用いられ、学習データ収集作業の手間と時間がかかるという問題がある。本研究は、この問題を緩和するために、教師データに存在しないクラス（未知クラス）を推定する Zero-shot 学習法の適応を目指す。我々は、センサ行動認識 Zero-shot 学習に置いて分散ベクトル表現を用いることで既存の属性ベクトルを用いた手法より導入性の高い手法を目指す。本稿では、既存の属性ベクトルを用いた手法と、分散ベクトル表現、分散ベクトル領域を用いた手法の比較を、3つのオープンデータセットを用いて評価する。その結果、分散ベクトル表現からベクトル領域にサンプル拡張することで、属性ベクトルと同等の精度が得られること、領域拡大前に比べて最大で28%推定精度の向上が見られたこと、属性ベクトルとの空間的類似度が高くなること、がわかった。これら結果から、分散ベクトル表現を用いる Zero-shot 学習法は、センサ行動認識に対して実用性の高い手法であることを示した。さらに、センサデータと意味ベクトル、それぞれのベクトルに同じような特徴量が含まれる場合、属性ベクトルより高い精度が得られることがわかった。この知見は、センサ行動認識 Zero-shot を応用する場合のクラス選択や必要なセンサデータの選定にとって重要である。

Analysis of Properties of Vector Representation for Zero-shot Learning Method in Sensor Activity Recognition

MOE MATSUKI¹ SOZO INOUE¹

1. 概要

ウェアラブルセンサを用いた人の行動認識技術は、ユビキタスコンピューティングに必要な技術である [2]。特に、セキュリティ分野、工場 [31]、介護分野 [32] での応用が期待されている [1]。しかし、既存手法のほとんどは教師あり機械学習を用いているため、学習用のデータ収集を行う必要があり、これは手間と時間がかかる作業であるという問題がある。

本研究では、学習データに存在しないクラス（未知クラス）を推定する Zero-shot 学習法をセンサ行動認識に適用することを目的としている。既存手法では、全てのクラスに対していくつかのセンサデータを収集しなければいけな

かったが、未知クラスを設定し、そのクラスに対するセンサデータ収集の手間を省略することで、データ収集の効率化を測る。

Zero-shot 学習法では、推定時、センサデータから得られる特徴ベクトルから意味ベクトルへ投影し、未知クラスを含む意味ベクトル集合空間内でクラス分類を行う。意味ベクトルは、行動クラスを意味的なベクトルで表現したもので、センサデータとは独立に、テキストデータから生成されるため、未知クラスも既知クラスも含んでいる。この意味ベクトル空間上でクラス分類することで既知クラスの意味情報を未知クラスを推定するための意味情報にシェアすることができる。

これまでの既存研究では、以下の2つの意味ベクトルが提案されている。

- 属性ベクトル：クラスに対して、人手で属性を定義し、クラスに属するかどうかを1か0で表現したベクトル

¹ 九州工業大学

- **分散ベクトル表現:** NLP の技術を用いて、テキスト内にある単語に対して意味的なベクトル表現を割り当てられたベクトル

既存のセンサ行動認識 Zero-shot 学習 [11,12,30] は、属性ベクトルを用いた手法しか存在しない。属性ベクトルを用いることは、作成に手間がかかり、さらにオブジェクト認識対象のクラスに比べて、属性の定義も難しいなど問題点がある。本論文では、センサ行動認識の Zero-shot 学習において、属性ベクトルの代わりにテキストから自動生成する分散ベクトル表現を用いることを目指す。我々はこの研究において、環境センサを用いた生活行動認識 [37,38] が可能かどうかを検討したが、本稿では意味ベクトルに着目し、3つの加速度センサデータセットを用いて検証を行う。

本稿で取り上げる問題は、センサ行動認識において、分散ベクトル表現を用いた Zero-shot 学習法を適応させた時の影響である。分散ベクトル表現を用いた Zero-shot 学習法は、オブジェクト認識フィールドで研究が存在するが、人の行動の場合は、より複雑な問題である。[?,20,21,23,40] は“ネコ”や“犬”のような名詞をクラスとして扱うが、我々は、“run”や“walk”など、多くの行動クラスは動詞を扱う。動詞はテキスト内で、原型を変換させた表現、違う意味として扱われる(多義語)、また違う表現での言い回しが多いなど、難しい点がある。そこで、以下のものを提案する。

- **分散ベクトル領域:** クラスの意味的な領域を広げるために、分散ベクトル表現を生成後、k-近傍法を用いて行動クラスに類似するベクトルをそのクラスのサンプルとして増やしたもの

これらの3つの意味ベクトル表現を3つのデータセットを用いて評価する。評価内容は、領域を広げた時のサンプルの分析、未知クラス推定の精度比較、分散ベクトル表現空間と分散ベクトル領域は属性ベクトルとどの程度類似するのかを評価する。

その結果、分散ベクトル表現からベクトル領域にサンプル拡張することで、属性ベクトルと同等の精度が得られること、領域拡大前に比べて最大で28%推定精度の向上が見られたこと、属性ベクトルとの空間的類似度が高くなること、がわかった。これら結果から、センサ行動認識 Zero-shot 学習手法に対して、分散ベクトル表現を用いることは、手動で生成する属性ベクトルに比べて容易に導入可能であり、さらに属性ベクトルと同等の精度は確保できることがわかり、センサ行動認識の実用性の高い新たな手法であることを示した。さらに、センサデータと意味ベクトル、それぞれの特徴量の中に同じような情報が含まれる場合、属性ベクトルより高い精度が得られることがわかった。この知見は、センサ行動認識 Zero-shot を応用する場合のクラス選択や必要なセンサデータの選定にとって重要である。

本稿の貢献は以下である。

- センサ行動認識分野において初めて、分散ベクトル表現を用いた Zero-shot 学習法を用いた新たな手法の提示。特に、人の行動に対する分散ベクトル表現の扱いことの難しさを提示し、分散ベクトル領域という手法を提案。
- 分散ベクトル表現を用いることは、自作で生成する属性ベクトルと比べて、精度的な影響はないことを示し、分散ベクトル表現の有効性を示した。
- Zero-shot 学習法に対して、センサデータと互換性の高い分散ベクトル表現を構築することで精度向上に繋がると言う知見を示す。

以下では、2章で関連研究について述べ、3章で Zero-shot 学習と分散ベクトル表現、そして分散ベクトル領域についてのべる。4章では、手法の比較評価のためのデータセット、評価方法について述べ、5章では比較評価の結果についてのべる。5章では、比較評価を分析、考察を行い、6章でまとめる。

2. 関連研究

2.1 センサ行動認識

人の行動認識の起源は1990年代から始まっており、文献[4]は、人の体に取り付けたセンサのデータは人の動作を検出するのに十分な情報を備えていることを示している。既存手法の多くはベイジアン手法[5]、SVM[6]や決定木[7]などの教師あり機械学習アルゴリズムが用いられている。

これらの手法はクラス分類においてある程度の精度を算出することができるが、学習データに存在する行動クラスしか推定できないという問題点がある。この問題点を言い換えると、推定したい全ての行動クラスに対して、センサデータを収集する必要があるため、時間と手間がかかる。この問題に取り組むため、研究者たちは、教師なし機械学習[8]や、転移学習[9]を用いた手法を提案してきた。しかし、教師なし学習は、確実なクラスを推定するということはしないため、見守りシステムや、転移学習はデータクラスに対するデータは収集する必要があるという欠点がある。この問題は、コンテキストアウェアネス大きな障害となる。センサデータに属する未知クラスを取得する問題を解決するために、以下に論じるゼロショット学習方法が必要とされる。

2.2 Zero-shot Learning

Zero-shot 学習法は、特徴ベクトル空間から意味ベクトル空間に投影する関数を学習し、意味ベクトル空間に存在する未知クラスを推定する手法である。意味ベクトル空間には、既知クラス、未知クラス両方に属するインスタンスがあると仮定される。既知クラスで学習した情報を、未知クラスを推定するために意味ベクトル上で情報共有を行う

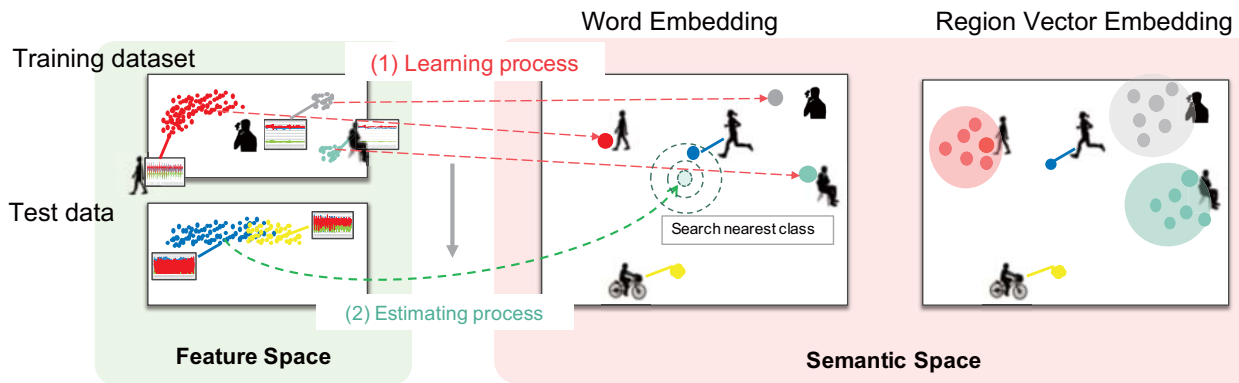


図 1 Zero-shot 学習法の概要. 特徴量ベクトルと意味ベクトルの空間が存在する. 学習過程では特徴量ベクトルから意味ベクトル空間に投影する方法を学習する. テスト過程では, テストデータを意味ベクトルに投影した後, 意味ベクトル空間上でクラス分類を行う. この時, 学習データとテストデータのクラスに重複はない (左側). 本稿では, 意味ベクトルとして, 分散ベクトル表現とそれを拡張した分散ベクトル領域を提案する (右側).

ことが Zero-shot 学習法の目的である. 例えば, 文献 [10] では, 動物画像から動物未知クラスを推定するため, 「色」や「形」が属するかどうかを 1 と 0 で表した意味ベクトルを用いる. 馬の画像から「たてがみ」の情報を, パンダの画像から「白黒」という情報を推定することができれば, シマウマの画像からそれらの属性を推定しクラス推定の情報に用いることができる. このように, Zero-shot 学習法は, 教師機械学習のように特徴ベクトルから直接クラスを推定する方法を学ぶのではなく, 意味ベクトルを通じ間接的にクラスを推定する. つまり, 図 1 のように 2 つのプロセスがある.

(Process 1) 特徴ベクトルから意味ベクトルに投影する方法を学習し, 投影関数 (式 1) を構築する. 図 1 内では赤色矢印点線を示す.

$$z = g(x) \quad (1)$$

この関数 1 を特徴ベクトルのテストサンプル x' を意味ベクトル空間に投影する.

$$\hat{z} = g(x') \quad (2)$$

\hat{z} はテストデータが投影された意味ベクトルを示す. 図 1 内では緑色矢印点線を示す.

(Process 2) 意味ベクトル空間上で行動クラスの分類を行う.

$$y = h(\hat{z}) \quad (3)$$

図 1 内では緑色サークル点線を示す.

Zero-shot 学習法の研究は, 主に 2 つの研究焦点がある. 1 つ目はどのような投影方法を行うのか, 2 つ目は意味ベクトルにはどのような表現を用いるのか. しかし, この手法の取り扱われる研究分野は画像認識分野 [39] や自然言語処理分野 [33] が多い. 行動認識における Zero-shot 学習の提案もいくつかあるが, 画像を扱う研究と比較するとかな

り少なく, さらにセンサ行動認識に取り組む研究ほとんどない. 文献 [12,30] は, 最初にセンサ行動認識 Zero-shot 学習に取り組んだ研究であり, 人の行動認識における属性は, 行動クラスよりさらに小さな行動と定義できるという仮説で人間行動認識 Zero-shot 学習法を提案した. 文献 [11] は, 意味ベクトルとセンサの特徴量ベクトルの互換性をスコア化し, 未知行動推定を行う手法の提案と同時に, 評価時には文献 [12] を参考に 3 つのオープンデータセットに対する属性ベクトルの提案を行っている. これらの 2 つの手法は, 共に意味ベクトルとして属性ベクトルを用いている. しかし, 人の行動の属性ベクトルを定義するのは手間がかかり, さらに画像の属性を定義するよりも難しい. 例えば, 「とり」のクラスの属性は, 「羽」「くちばし」など定義が容易であるが, 「走る」「歩く」の属性を考えた時, 容易には答えられない. 文献 [12] では, 「足をあげる」「足を下げる」という小さな行動を属性と定義している. しかし, 生活行動レベルの行動になると, 「料理」や「睡眠」のクラスに適切な属性はより抽象的な行動になると想定される. さらに, センサデータから得られる情報の範囲内で推定が容易であるかどうかということも考慮しなければならない. つまり, 人の行動属性を考えること, アノテーションすることは, 容易な作業ではない. そこで, 行動認識 Zero-shot 学習の実用性のためには, 意味ベクトルの自動生成が必要であると考え. 我々は, テキストから自動生成された分散ベクトル表現を属性ベクトルの代わりに用いることを提案する.

2.3 Zero-shot 学習の意味ベクトル

Zero-shot 学習法での意味ベクトルの大事な役割は, 既知クラスと未知クラス間で情報を共有することであり, この役割が未知クラスを推定する上で重要なポイントになる. これまでの研究では, 主に意味ベクトルとしてテキスト

トベースの考えであり、大きく分けて属性ベクトルと単語ベクトルの2つに分類することができる。

(属性ベクトル) 属性ベクトルとは、人の一般的な概念を属性として定義し、各クラスに対して属性が含まれるか含まれないかを定義したベクトルである。この手法は人の理解が容易であるという点から多くの研究に用いられている [10–12,17]. Lampert et al. は Zero-shot 学習法の概念を画像認識において最初にモデル化した論文である [10]. この論文は、動物画像に対する未知クラス推定を行う問題において、色や形を属性とし、各クラスに対し属するかどうかを1か0で表現したベクトルを用いる。この属性ベクトルを生成するのは、大変な作業であるため、属性ベクトルを自動で生成する方法がこれまで試行錯誤されてきた [10,17]. センサ行動認識においては、人の手で生成した属性ベクトルを用いる手法しか提案されていない [11,12]. なぜなら、オブジェクトに比べて人の行動の定義は難しく、自動生成するためには様々な定義が必要である [34,35] という難しさ、さらにセンサデータから推定可能な属性である必要があるため属性の制限があること、が考えられる。しかし、属性ベクトルの生成は、特に人の行動に対しては難しく手間がかかる作業であるため、現実的なアプリケーションとして用いるには現実的ではない。そこで、本研究では属性ベクトルの代わりに分散ベクトル表現を Zero-shot 学習法に用いることを提案する。

(分散ベクトル表現) 分散ベクトル表現とは、自然言語処理の技術を用いてテキスト内の単語に対して意味的なベクトル表現を自動で割り当てられたベクトルそのものを言う。この意味ベクトルを用いた Zero-shot 学習法は画像認識の分野ではいくつか提案されている [19–21,23,40]. 特に、word2vec から生成された分散表現を持った手法が注目を浴びている [24,25].

word2vec で生成された単語ベクトルは、単語の意味的演算が妥当である点で意味ベクトルとして優れていると期待されている [24]. 例えば、「女王」-「女」+「男」を単語ベクトルを用いて計算を行うと、「王」に相当する単語ベクトルが出力される。我々は、この word2vec で生成される分散ベクトル表現を用いることを提案する。コーパスとしては、大規模コーパスである Wikipedia を使用することを考える。大規模データを用いた分散ベクトル表現は、ノイズや表現の揺らぎが多いことがデメリットとして挙げられる。特に人の行動クラスは、画像認識で扱う名詞ではなく、動詞に該当する場合が多い。そのため、[難点1] 原型を変換させた表現、[難点2] 違う意味として扱われる(多義語)、[難点3] 違う表現での言い回しが多い、などの単純に適応するだけでは考慮しないといけな問題が多い。[難点1] は、“walk”という行動クラスは原型であるが、“walked”や“walking”など違う形で使用されることを言う。[難点2] は、例えば“skip”と言う単語に人の行動の“skip”もある

が、物事をスキップする時にも同じ単語が使用される場合である。[難点3] は、“run”という単語は意味的には“jog”も同じ意味であるが、単語が違うので考慮されない。

これらの問題を考慮するために、分散ベクトル領域を本稿で提案する。これは、似た意味の単語は分散ベクトル表現上では、ベクトル距離が近い場所に位置するという仮説をモチベーションとして提案する。こうすることで、[難点1,3]の問題を軽減し、分散ベクトル領域を分析することで [難点2] の影響を確かめる。

3. 分散ベクトル表現を用いた Zero-shot 学習法

この章では、本稿で提案する分散ベクトル表現を用いた行動認識 Zero-shot 学習手法について説明する。はじめに Zero-shot 学習法について 3.1 節で説明し、その詳細部分である投影手法過程、クラス分類過程を 3.2 節と 3.3 節で説明する。最後に、我々の提案する分散表現を用いた Zero-shot 法について 3.4 節で説明する。

3.1 Zero-shot 学習法




図 2 Zero-shot 学習法の大まかな流れ。既存の手法 $y = f(x)$ とは違い、2つの関数 $z = g(x)$ と $y = h(z)$ を用いて間接的にクラス y を推定する。

まず、既存の教師あり機械学習の行動認識について説明する。行動認識で扱う学習データは以下の式で表す。

$$\{(x_i^{tr}, y_i^{tr})\}_{i=1}^{N_{tr}} \subseteq \mathcal{X} \times \mathcal{Y}$$

この時 $\mathcal{X} \in \mathbb{R}^d$ はセンサデータから得られる特徴量ベクトル空間で、 \mathcal{Y} 教師あり機械学習の問題は、テスト時のデータは $\{x_i^{ts}\}_{i=1}^{N_{ts}} \subseteq \mathcal{X}$ からクラス $\{y_i^{ts}\}_{i=1}^{N_{ts}} \subseteq \mathcal{Y}$ を推定するために、学習データから推定関数 $y = f(x)$ を構築することである。

意味ベクトルは以下の式で表す。

$$\{(z_j^{tr}, y_j^{tr})\}_{j=1}^{N_{tr}} \subseteq \mathcal{Z} \times \mathcal{Y}$$

$\mathcal{Z} \in \mathbb{R}^l$ は意味ベクトル空間を示す。Zero-shot 学習法の目的は特徴量ベクトルから行動クラスを推定することは教師あり機械学習の目的と同じだが、この時の行動クラスが未知クラスであるとうことである。本稿では、未知クラスを $\{y_j^{ts}\}_{j=1}^{N_{ts}} \subseteq \mathcal{Y}$ と表す。そして、Zero-shot 学習法は、2つの関数(投影関数 $z = g(x)$ と分類関数 $y = h(z)$) を用い

て推定を行う。以下では、Zero-shot 学習法について学習過程とテスト過程に分けて詳しく説明する。

(1) 学習過程 (図 2 の赤色の点線)

投影関数 $z = g(x)$ は、特徴ベクトル $\{(x_i^{tr}, y_i^{tr})\}_{i=1}^{N_{tr}}$ から意味ベクトル $\{(z_j^{tr}, y_j^{tr})\}_{j=1}^{N_{tr}}$ を推定する関数である。それぞれの持っているクラス y_i^{tr} が共通するインスタンス同士をマージし $\{(x_i^{tr}, z_i^{tr})\}_{i=1}^{N_{tr}}$ という学習データを構築し、投影関数を学習させる。特徴ベクトル空間 \mathcal{X} から意味ベクトル空間 \mathcal{Z} へ投影する詳細は 3.2 節で説明する。

(2) テスト過程 (図 2 の緑色の点線)

テスト過程では、2つの関数 $z = g(x)$ と $y = h(z)$ を用いる。最初に、学習過程で構築した $z = g(x)$ を用いて $\{x_i^{ts}\}_{i=1}^{N_{ts}}$ から \hat{z} を推定する。次に、推定関数 $y = h(z)$ を用いて \hat{z} から $\hat{y} \in \mathcal{Y}$ を推定する。この詳細は 3.3 節で説明する。

Zero-shot 学習法の大事な点はテストクラスと学習クラスが重複しないと言う点である。テストクラス $y^{ts} \in \mathcal{U}$ と学習クラス $y^{tr} \in \mathcal{S}$ とした時、

$$\mathcal{U} \cup \mathcal{S} = \emptyset$$

と表すことができる。 \mathcal{U} は学習データに存在しない未知のもの、 \mathcal{S} は学習データに存在する既知のものとする。つまり、学習データ $\{x_i^{tr}\}_{i=1}^{N_{tr}} \in \mathcal{X}$ は $y \in \mathcal{S}$ に属しており $\{x_i^{ts}\}_{i=1}^{N_{ts}} \in \mathcal{X}$ は $y \in \mathcal{U}$ に属している。また、 $z^{tr} \in \mathcal{S} \times \mathcal{U}$ である。

3.2 投影過程

この節では、特徴ベクトル空間から意味ベクトル空間に投影する方法 $\mathcal{X} \rightarrow \mathcal{Z}$ について説明する。

特徴ベクトルインスタンスを d 次元を持つ $x_i \subseteq \mathcal{N}^d$ 、 t 次元を持つ意味ベクトルインスタンスを $z_i \subseteq \mathcal{N}^t$ とする。さらに、 $z_i = z_i^1, z_i^2, z_i^3, \dots, z_i^t$ とも表現できる。同時に、説明変数として x_i を用い、各次元 z_i は目的変数として使われ、線形回帰で学習される。これは、 t 個の回帰モデルができ、 x_i から t 個の実数が推定され、意味ベクトル z を簡単に生成する。

評価実験では、2つの投影モデル “RegBM” [13] と “SVRBM” [12] を回帰モデルとして用意した。Zero-shot 学習法では、 $\mathcal{X} \rightarrow \mathcal{Z}$ に投影する方法以外にも、 $\mathcal{Z} \rightarrow \mathcal{X}$ [16] や Auto-encoder ベースのもの [14] が画像認識手法では提案されているが、センサ行動認識手法の例がないので本稿では取り扱わない。またセンサ行動認識文献 [11] では特徴ベクトル空間と意味ベクトル空間の互換性をスコア化する手法も提案されているが、この手法はスコアが低い場合そのテストデータは切り捨てられるため、本稿の検証のためには合わない手法であると判断し、単純な2つの回帰モデル投影手法のみを用いる。

3.3 クラス分類モデル

本節では、 \hat{z} から \mathcal{Y} から未知行動クラス $y \in \mathcal{U}$ を推定する方法について $y_i \in \mathcal{U}$ について説明する。ここまでで、 \hat{z} の正解クラスが未知クラスであった場合、 \hat{z} は y_i のクラスに対応する意味ベクトル z_i 付近に投影されているものと考えることができる。この場合、最近傍法を用いることで、未知行動の推定が可能となる。つまり、式で表すと以下のように表すことができる。

$$\hat{y} = \arg \min_{y_{ts}} h(\hat{z})$$

3.4 分散表現

分散表現と分散表現の領域サンプルの構築方法について以下で説明する；

3.4.1 分散表現

本稿で述べる分散表現は、Wikipedia をコーパスとして word2vec (教師なし学習ベースの単語ベクトル生成ツール) を用いて生成したベクトル表現をいう。Word2vec を用いる利点としては、自動で生成できる点、同じベクトルができない点、分散表現として優れている点である。既存研究でも word2vec から生成される分散表現を用いているが、本研究のようにセンサ行動認識手法に用いるのは初めての試みである。

本手法に用いる分散表現の生成方法は以下の順で生成される。

- (1) Wikipedia の単語を全て word2vec を用いて単語ベクトル Z_{all} を生成する。
- (2) 必要な行動クラスを $Y = y_1, y_2, \dots, y_n$ とする。
- (3) Z_{all} から $Y = y_1, y_2, \dots, y_n$ に対応する単語ベクトル $Z_s = z_1, z_2, \dots, z_n$ を抽出する

また、行動クラスの中には、“Open door” のような2単語や3単語を組み合わせた行動が存在する。この場合、それぞれの単語 (“Open” と “door”), のベクトルを足し合わせ各次元毎に平均をとる。

3.4.2 分散表現の領域サンプル

上記の分散表現を用いた場合、Wikipedia という膨大なテキストコーパスを用いるため、言葉の揺らぎ、ノイズが意味ベクトルとしての精度に影響することが懸念される。そこで、言葉の揺らぎを考慮するために、各行動クラスの意味ベクトルの領域を広げる提案を行う。この提案のモチベーションは、“run” という行動クラスがあった場合、テキスト内に存在する “running” や “jog” も同等の意味だが、上記の分散表現では考慮されないため、このような言葉の揺らぎを考慮するために、“run” のベクトル z_{run} に近いベクトルを行動クラス “run” の意味ベクトルとして扱うというものである。同様に、複数単語の組み合わせ行動に対する処理は、動詞部分のみの領域を広げ、目的語や形容詞についてはそのまま処理とし、分散表現と同様に足し合わせ

て、各次元毎に平均をとる。本稿では、どのくらい領域を広げるのかについて、つまり、 k 個の類似サンプルを抽出するという点に関して、 $k = 5, 10, 20$ と定めた 3 つの手法を用いた。

4. 評価方法

本稿では、分散表現を用いた行動認識 Zero-shot 学習法において以下の 2 つの分析と 1 つの評価を行う。

- 分散ベクトル領域における分析
- 属性ベクトル手法と分散表現手法の未知クラス推定精度における比較評価
- これらの空間の類似度と推定精度の相関分析

分析は、領域サンプルを 5~20 に広げた場合、どのような単語がサンプルとしてあるのかを表にまとめ、考察を行う。評価 1 つ目は、分散表現を用いることで推定精度に負の影響を与えているのかどうかの調査を行う。評価 2 つ目は、分散表現の中でもどのような分散表現が推定精度がいいのか、人の理解がわかりやすい属性ベクトルに似せるのがいいのかということを検証するために、空間類似度と推定精度の相関を調べる。本章の構成は、4.1 節に評価に用いたデータセット、4.2 節に評価方法の詳細、4.3 節に、空間の類似度の分析方法を説明する。

4.1 センサデータセットとテキストデータセット

本手法を評価するために、2 つのオープンデータセットと 1 つの個人が収集したデータセットを用いる。これらのデータセットは、行動クラスとセンサのポジションという観点で様々な種類のデータセットを用いた 1. これらのデータセットの詳細について以下で説明する。

テキストデータセットについては、属性ベクトルと単語ベクトルの 2 種類を用いて比較する。属性ベクトルは、[11] を参照にし構築する。分散表現は英語 Wikipedia コーパスを word2vec に学習させた学習モデルを用いて構築する [11]。これらのデータセットに関する詳細、前処理、属性ベクトルと単語ベクトルの構築方法に関しては後で述べる。

4.1.1 データセットと前処理方法

分散表現と属性ベクトルを比べるために、本稿では [11] を参考に OPP データセットと PAMAP2 データセットとそれに対する属性ベクトルを用いる。これらのデータセットは生活行動や複雑な行動が含まれる。本稿ではこの 2 つのデータセットに加えて、シンプルな行動での評価も行うために、HASC チャレンジ*1に沿ってデータ収集を行った HASC データを用いる。

それらのデータセットでは、各センサデータ次元に対して、最初に欠損値に対して 0 を埋め、 $[0, 1]$ の範囲で正規化を行う。前処理は [36] を参照に各データセットに対応した

前処理を行う。また、それぞれのデータセットに対する時間窓スライド特徴量抽出方法は、[26] を参考にした。

4.1.2 OPP データセット [27]

Opportunity Activity Recognition Data Set (OPP) は朝の職場の人の行動を想定したデータセットである。センサデータの周期は 30Hz で 4 人の被験者から収集した。我々は “middle level activity class labels” という行動ラベル種、全 17 行動存在するものを用いた、そして、時間窓スライド手法を用いて特徴量抽出を行う（時間窓幅：1 秒、スライド幅 0.5 秒）。“drill runs” のデータは用いていない。特徴量抽出の際、分散と平均を各次元に対して抽出する。その結果、特徴量は 484 次元となった。

4.1.3 PAMAP2 データセット [26]

PAMAP2 Physical Activity Monitoring Data Set (PAMAP2) は 9 人の被験者による 18 行動種のデータが含まれている。心拍数モニターセンサの周期は 9Hz で、他のセンサデータは 100Hz である。時間窓は 5.12 秒スライド時間は 1 秒である。データ提供者に推薦されたことを参考に、“3D accelerometers with scale of $\pm 6g$ ” ファイルと orientation readings は削除した。OPP データセット同様に時間窓内で分散と平均値を特徴量とした抽出したところ、69 次元のデータとなった。

4.1.4 HASC データセット

Human Activity Sensing Computing (HASC) は、装着型センサの大規模データベースの構築を目指し、決められた行動に対してスマートフォン内にある加速度計から得られる加速度センサデータを収集するチャレンジである [?]. 本研究室ではこのこのチャレンジに参加し、HASC チャレンジのデータ生成方法*2にしたがってデータを集めた。このデータセットには 6 つの行動が含まれ、sensor reading は 100Hz の 3 軸加速度センサである。1 つの行動に対して 1 セット 20 秒行動する。それを 5 回繰り返す。被験者は 1 人分のデータを用いた。

4.1.5 意味ベクトルデータセット

本稿では、主に 3 種類の意味ベクトル手法（属性ベクトル、意味単語ベクトル、領域ベクトル）を比較評価する。属性ベクトルは、[11] を参考に構築した。分散表現においては、English Wikipedia をコーパスとし、word2vec を用いて全ての単語の 1000 次元ベクトルを作成した*3のち、必要な行動クラスに対する単語ベクトルを抽出する。1000 次元のベクトルでは、計算処理に時間がかかってしまうため、PCA を用いて、圧縮した。

4.2 分析と評価実験の方法

ここでは、4 章で述べた 3 つの分析、評価方法について

*1 <http://hasc.jp/hc2010/HASC2010corpus/hasc2010corpus-en.html>

*2 <http://hasc.jp/hc2010/HASC2010corpus/hasc2010corpus-en.html>

*3 <https://github.com/idio/wiki2vec>

表 1 The type of activity class and sensor on each dataset

Dataset	Activity Class type	Senear type
HASC	Basic activity (Walk, Run, etc)	One sensor on arm
Opp	Middle activity (open door, close door, etc)	Ambient sensor and wearable sensors on 7 points
PAMAP2	Living activity(watching TV, house cleaning, etc)	wearable sensors on 3 points

表 2 Attribute vectors of HASC dataset

	act	motion	static	cyclic.motion	intense.motion	translation.motion	body.up	body.down	body.in.place	arms.motion	arms.static	arms.bent	arms.straight	arm.bent.straight.transform	legs.motion	legs.static	legs.bent	legs.straight	legs.bent.straight.transform	legs.alternate.move.forward	legs.move.up.and.or.down	stairs
1	Stay	0	1	0	0	0	0	0	1	0	1	0	1	0	0	1	0	1	0	0	0	0
2	Walk	1	0	1	0	1	0	0	0	1	0	0	1	1	1	0	1	0	1	1	0	0
3	Jog	1	0	1	1	1	0	0	0	1	0	1	0	1	1	0	1	0	1	1	0	0
4	Skip	1	0	1	1	1	1	1	0	1	0	1	0	1	1	0	1	0	1	1	1	0
5	Stair up	1	0	1	0	0	1	0	0	1	0	1	0	1	1	0	1	0	1	1	1	1
6	Stair down	1	0	1	0	0	0	1	0	1	0	1	0	1	1	0	1	0	1	1	1	1

詳しく説明する。

4.2.1 分散表現の領域サンプルの分析

上記で述べたデータセットそれぞれのクラスに対して、分散表現の領域サンプルの妥当性を検証する。領域サンプルの抽出方法は、1つのクラス y_i に対する意味ベクトル z_i に近いベクトルのクラスを \cos 類似度*4で出力。出力されたクラスを表にまとめる。表には、類似するクラス上位 5, 上位 10, 上位 20 のグループでまとめる。

4.2.2 未知クラス推定の評価

ここでは、分散表現と属性ベクトルを用いた手法を、未知クラス推定の精度を指標に比較評価する。分散表現には、1つのクラスに対して1つの意味ベクトルを割り当てられた意味ベクトルを用いる手法(分散表現)、分散表現内で領域を5サンプル広げた手法(region(k=5)), 10サンプル広げた手法(region(k=10)), 20サンプル広げた手法(region(k=20))の4つの手法に対してそれぞれ精度を算出する。

これらの手法の投影モデルには以下の2つの投影法を用いた。RegBM [13]: 線形回帰モデルによる投影法である。本稿では、これをRegression-based method(RegBM)と呼ぶ。

SVRBM [12]: SVRを用いた回帰モデルである。本稿では、SVR-classifier-based method (SVRBM)。

未知クラスの設定については、OPP データセットと PAMAP2 データセットには文献 [11] を参考に5つの fold

をランダムに設定する。1回の fold は34つの未知クラスが含まれる。HASC データには、参考文献がないため、2クラスを未知クラスとし、全ての組み合わせを未知クラスと設定する。全6クラスあるので、15回の Fold の設定となった。各 fold に設定した未知クラスは表 5, 6, 7 に示す。未知クラスと既知クラスのインスタンス数の平均を表 15 に示す。

表 7 Foldings of HASC classes

Fold	Unknown classes	Fold	Unknown classes
fold 1	Stay, Walk	fold 9	Jog, Stair up
fold 2	Stay, Jog	fold 10	Skip, Stair up
fold 3	Walk, Jog	fold 11	Stay, Stair down
fold 4	Stay, Skip	fold 12	Walk, Stair down
fold 5	Walk, Skip	fold 13	Jog, Stair down
fold 6	Jog, Skip	fold 14	Skip, Stair down
fold 7	Stay, Stair up	fold 14	Skip, Stair down
fold 8	Walk, Stair up	fold 15	Stair up, Stair down

評価指標は、各 fold の正解率の平均値を算出する。正解率の式は以下のように示される:

$$Accuracy = \text{正解したサンプル数} / \text{全体のサンプル数}$$

*4 gensim パッケージの "most_similar" メソッドを使用

表 3 Attribute vectors of PAMAP dataset

act	motion	static	cyclic.motion	intense.motion	translation.motion	free.motion	body.vertical	body.incline	body.horizontal	body.forward	body.backward	body.up	body.down	body.in.place	torso.transform	arms.motion	arms.static	arms.bent	arms.straight	arms.bent.straight.transform	hands.hold.something	legs.motion	legs.static	legs.bent	legs.straight	legs.bent.straight.transform	legs.alternate.move.forward	legs.move.up.and.or.down	seat	bike	pole	television	computer	car	stairs	vacuum	iron	clothes	soccer	rope	indoor	outdoor		
1 lying	0	1	0	0	0	0	0	0	1	0	0	0	0	1	0	1	1	1	1	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1		
2 sitting	0	1	0	0	0	0	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1	0	0	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	1	
3 standing	0	1	0	0	0	0	1	0	0	0	0	0	0	1	0	1	1	1	1	1	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	
4 walking	1	0	1	0	1	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	0	1	0	1	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	
5 running	1	0	1	1	1	0	1	0	0	1	0	0	0	0	0	1	0	1	0	0	0	0	1	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	
6 cycling	1	0	1	0	1	0	0	1	0	1	0	0	0	0	0	0	1	1	1	0	1	1	0	0	1	0	0	1	0	0	1	1	0	0	0	0	0	0	0	0	0	0	1	
7 Nordic walking	1	0	1	0	1	0	1	0	0	1	0	0	0	0	0	1	0	0	0	1	1	1	0	0	1	1	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	1	
8 watching TV	0	1	0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	0	1	1	1	1	1	0	0	1	0	0	1	0	0	0	0	0	0	0	0	1	0	
9 computer work	0	1	0	0	0	0	1	1	0	0	0	0	0	0	1	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	1	0
10 car driving	0	1	0	0	0	1	0	0	1	0	0	0	0	0	0	1	0	0	1	0	0	1	1	1	1	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	1	0
11 ascending stairs	1	0	1	0	0	0	1	1	0	1	0	1	0	0	0	1	0	1	1	1	1	1	0	0	1	1	1	0	0	0	1	1	1	0	0	0	0	0	1	0	0	0	1	1
12 descending stairs	1	0	1	0	0	0	1	1	0	1	0	0	1	0	0	1	0	1	1	1	1	1	0	0	0	1	1	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	1
13 vacuum cleaning	1	0	0	0	1	1	1	0	1	1	0	0	0	1	0	1	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0
14 ironing	1	0	0	0	1	1	1	0	0	0	0	0	0	1	1	0	1	1	1	1	1	1	0	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	1	1	0	0	1	0
15 folding laundry	1	0	0	0	0	1	1	1	0	0	0	0	0	1	1	1	0	1	1	1	1	1	1	1	1	1	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0
16 house cleaning	1	0	0	0	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	0	1	1	0	1	0	0	0	0	0	0	1	0	1	0	0	1	0	
17 playing soccer	1	0	0	1	0	1	1	0	1	0	1	1	0	1	0	1	0	1	1	1	1	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1
18 rope jumping	1	0	0	1	0	0	1	0	0	0	0	1	1	1	0	1	0	1	1	1	1	1	0	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1

表 4 Attribute vectors of OPP dataset

act	open	close	clean	drink	toggle	door	fridge	dishwasher	drawer	table	cup	switch
1 Open Door	1	0	0	0	0	1	0	0	0	0	0	0
3 Close Door	0	1	0	0	0	1	0	0	0	0	0	0
5 Open Fridge	1	0	0	0	0	0	1	0	0	0	0	0
6 Close Fridge	0	1	0	0	0	0	1	0	0	0	0	0
7 Open Dishwasher	1	0	0	0	0	0	0	1	0	0	0	0
8 Close Dishwasher	0	1	0	0	0	0	0	1	0	0	0	0
9 Open Drawer	1	0	0	0	0	0	0	0	1	0	0	0
10 Close Drawer	0	1	0	0	0	0	0	0	1	0	0	0
15 Clean Table	0	0	1	0	0	0	0	0	0	1	0	0
16 Drink from Cup	0	0	0	1	0	0	0	0	0	0	1	0
17 Toggle Switch	0	0	0	0	1	0	0	0	0	0	0	1

表 5 Foldings of OPP classes

Fold	Unknown classes
fold 1	Close Drawer, Clean Table, Toggle Switch
fold 2	Open Fridge, Open Door, Close Drawer
fold 3	Drink from Cup, Open Drawer, Close Dishwasher
fold 4	Close Drawer, Close Door, Open Door
fold 5	Close Fridge, Open Dishwasher, Close Door

表 6 Foldings of PAMAP2 classes

Fold	Unknown classes
fold 1	watching TV, house cleaning, standing, ascending stairs
fold 2	walking, rope jumping, sitting, descending stairs
fold 3	playing soccer, lying, vacuum cleaning, computer work
fold 4	cycling, running, Nordic walking
fold 5	ironing, car driving, folding laundry

4.3 空間の類似度と推定精度の相関

分散表現空間と属性ベクトル空間はどのくらい似ているのか、そして、類似度と推定精度は相関があるのかの評価を行う。類似度の算出方法は、以下の方法をとる。各空間で、各クラスのベクトルに類似するベクトルを算出し、ベクトルのクラスの一致数を数える。属性ベクトル空間と分散表現空間に対しては、各クラスに1つずつのサンプルしかないため、類似するクラス上位3つを表にまとめる。領域を広げた分散表現に対しては、1つのクラスに最大20個のサンプルがあるため、それらのサンプルの最も類似するベクトルクラスのヒストグラムをグラフで表す。

この手法をとる理由としては、Zero-shot 手法の最終段階は意味ベクトル空間内での最近傍法であることから、クラスの類似度関係が大事な指標となってくるため、ベクトルの位置や、ネットワーク的な形ではなく、クラス間の類似度のみに着目した測定方法をとる。

5. 分析と評価結果

4章で述べた分析と2つの評価の結果を以下で述べる。

5.1 領域サンプルの分析結果

本稿で定義した分散表現の領域を広げた領域サンプルの出力結果を示す。出力結果で、表内に同じ単語があった場合、色を赤色で表示した。

表9はHASCデータセットの出力結果である。HASCデータセットは、6種類の行動クラス、“jog”、“skip”、“stay”、“walk”、“stair down”、“stair up”が含まれている。“stair down”、“stair up”に関しては、4章で説明したように、動詞に関連する単語のみの領域を広げるため、本稿では、“up”と“down”の単語における出力結果を示している。

表9はHASCデータセットの出力結果である。行動クラスから抽出した“down”、“jog”、“skip”、“stay”、“up”、“walk”の6つの単語に対して、類似する単語上位20個を表す。Top5の枠を見ると、“skip”や“stay”などの動詞において、時制の違う単語がtop5内に含まれることがわかる。“down”や“up”の単語に関してもノイズ(記号など)を含む単語が抽出できていることがわかる。また、“skip”のトップ5内の“ignore”や“up”のトップ20内の“quickly”などは、行動としての意味以外が含まれていることがわかる。これらの単語の揺らぎが存在することが問題になると考えられる。“stay”と“skip”に注目すると、各top5内に“go”という同じ単語が含まれている。つまり、“stay”と“skip”の領域は重複していることがわかる。このような重複している赤色単語に着目すると、最も重複の多い単語は“up”であった。また、この結果から、“up”のtop10内に類似する単語として、“down”が含まれる。これは、word2vecのベクトルのコサイン類似度は反対語も抽出されやすい[28]という性質があるためである。

表10はOPPデータセットに存在する行動クラスの単語ベクトルを生成するために、抽出した単語“clean”、“close”、“toggle”、“drink”、“open”の6つの単語に対して、類似する単語上位20個を表す。今回の結果からは重複単語は含まれない。“toggle”や“drink”の類似単語にこの動詞の目的語になりうる“juice”や“button”などの単語が含まれている。この類似性は、“drink”と“drinks”のような「時制による類似性」とは違い、「用途の類似性」として分けることができる。Zero-shot問題を考えた場合「用途の違い」は物体センサや環境センサを用いるとその違いは観測できるが人の動きに関するセンサ(加速度計など)のみを用いた場合判別するのは難しい。つまり、センサとの互換性を考えた場合、これらの単語ベクトルは余計なノイズサンプルになりうると考えられる。

表11はPAMAP2データセットに存在する行動クラスの単語ベクトルを生成するために、抽出した16単語に対して、類似する単語上位20個を表す。重複単語が最も多かった単語は“cleaning”と“ironing”であった。また、“ascending”や“descending”のような反対語でも類似するという性質がこの結果からも見られた。さらに、「用途の類似性」がこの結果からも“ironing”や“driving”のような単語に見られた。

5.1.1 結果のまとめ

ここでは、この分析の結果についてまとめる。これらの結果から、予想されるように動詞の原型が違うものを考慮することができていることがわかった。また、発見としては、類似する単語の中には動詞以外にも、目的語に当たる「用途の類似度」に関する単語が含まれることや、多義語である場合の類似単語は行動の主旨と違う意味の単語が含まれることがわかった。気になる点としては、重複するサンプルがどのように推定精度に影響するのかという点がある。

5.2 未知クラス推定における結果

推定精度を図??にまとめる。HASCデータの結果を見ると、投影手法にSVRBMを用いた場合は、どれも同等な結果が得られた。RegBMを用いた場合、属性ベクトルと領域を広げない分散表現を比較すると12%精度は下がってしまうが、領域を広げることで、約3%の精度を向上し、属性ベクトルとの差は9%に差が減少した。

Oppデータセットの結果を見ると、SVRBMを用いた場合は、分散表現を用いた手法の方がかすかに精度が高いことがわかる。RegBMを用いた場合、領域を広げない分散表現を用いた時、27%の差をつけ精度が向上している。しかし、領域を広げることで精度は徐々に下がっていることがわかる。

PAMAP2データセットの結果を見ると、SVRBMとRegBM両方において、領域を広げていない分散表現を用いた場合、属性ベクトルより29%精度は下がってしまうが、

表 9 Top of 20 similar words to each activity class in HASC dataset

Activity class	Top5	Top10	Top20
down	back, down”, (down), down;, off	away, cut, down?, shut, upside	backwards, dragged, falling, finally, off;, out, slid, slowly, up, up”
jog	jogged, jogging, jogs, stroll, walk	bends, detour, half-mile, north-northwesterly, walking	driveway, eastbound, intersecting, intersects, lope, nap, ramp, straightens, swerves, veers
skip	go, miss, skipped, skipping, skips	Brier, curling, get, ignore, repeat	**the_Brier, Parsoid, Scribunto, append, editpreview, manually, redo, start, try, unwatch
stay	go, leave, remain, staying, stays	continue, settle, spend, wait	agrees, come, decide, decides, get, kept, marry, move, sit, vacation
up	back, up”, up:, up:, up?	down, forth, off, start, up)	0:), aside, carrots →, finally, just, out, quickly, start, them, up!
walk	path, stroll, walked, walking, walks	**20_kilometres_walk, go, jump, trek, wander	barefoot, climb, distance, kilometres, pull, relax, sit, strolling, swim, throw

表 10 Top of 20 similar words to each activity class in OPP dataset

Activity class	Top5	Top10	Top20
clean	cleaning, cleans, messes, tidy, wash	fixing, remove, rinse, scrubbing, washing	bring, clean-up, cleanup, fix, lighten, mess, recycle, soak, tidying, trash
close	closer, closest, closure, proximity, strong	close, closes, contact, relative, ties	another, busy, clear, closing, connection, friend, friends, keep, move, nearer, reopen
toggle	buttons, on/off, switch, toggled, toggles	disable, double-click, knob, right-click, show/hide	”Cite”, Rightclick, button, button;, doubleclicking, joystick, right-clicking, scrollbars, show/hide, tabs, touchpad
drink	beer, beverage, beverages, drinks, nonalcoholic	carbonated, drank, soda, sodas, vodka	**soft_drink, **soft_drinks, caffeinated, coffee, cola, drink, fizzy, juice, juices, lemonade, non-carbonated
open	**open_source, access, enclosed, space, spaces	öpen, allow, doors, **open_plan, **open_source_software	Access, **Open-source_software, **open_content, accessible, create, door, extension, internal, opening, repository

領域を広げることで約 28%(SVRBM) と 27%(RegBM) 精度が向上し、属性ベクトルとの差は 16%向上 (SVRBM), もしくは 3%に差を減少させることができた。

これらの結果をまとめると、分散表現を用いることで属性ベクトルと同等かそれ以上の精度を得ることができたことがわかった。ただし、データによってサンプル領域を広げる必要があるが、今回の結果から、領域を広げる提案によって最大で 28%推定精度の向上が見られた。考察では、これらの結果からどのようなデータセットに対して、どのような分散表現が必要であるのかを考察する。

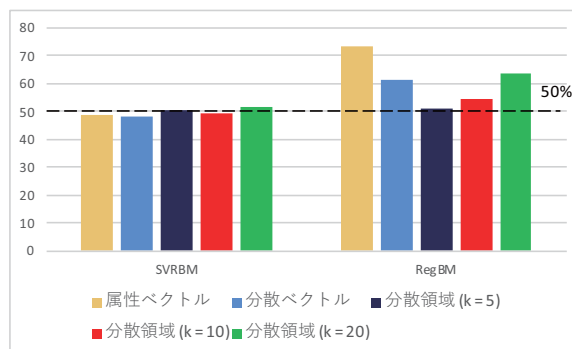


図 3 PHASC データセットを用いた場合の精度

表 11 Top of 20 similar words to each activity class in PAMAP2 dataset

Activity class	Top5	Top10	Top20
ascending	ascend, ascends , descending , dhaivatam, panchamam	ascending, madhyamam, par- allage, pentatonic, phthongos, scale)	(ascending, **chromatic_scale , **swara , arching, kaisiki,nishadham, rishabham, sadharana, shuddha, tetrachord
cleaning	clean, cleaners, cleans, laundry, washing	drying, polishing, repairing, scrubbing, vacuuming	Cleaning, clean, cleanup, cleaner, dishwashers , ironing , plumbing, rinse, tidy, tidying, wash
cycling	Cycling, **2013_in_women's_road_cycling , **2014_in_women's_road_cycling , **Road_bicycle_racing , **track_cycling	**2013_UCI_Road_World_ Championships- _Women's_road_race, **List_of_women's_road_bicycle_ races, **road_cycling , UCI, bicycle	BMX, **BMX_racing , **Moun- tain_bike_racing, **Track_cycling , **cyclocross , **race_stage , **road_bicycle_racing , **stage_race , cycling, cyclocross, cyclocross
descending	ascend, ascending, ascends , de- scend, downwards	climbs, descends, parallage, ph- thongos, scale)	(ascending, climb, descents, dhai- vatam, downward, panchamam, steep, steeper, tetrachord, upward
driving	car, car's, driver, drove, speeding	cars, drive, driver's, drivers, speeding, stickshift	braking, burnouts, cornering, driver' s, drives, driving), motor, parked,vehicle, vehicle's
folding	Folding, fold, folded, removable, sliding	adjustable, backrest, foldable, hinged, onepiece	Dbox, **protein_folding , armrests, chamferboards, folds, footrests, heli- cal, laminated, nonslip, rearwards,
ironing	laundry, pillows, sewing, towels, washing	cleaning, dryer, mattresses, utensils, wash	**clothes_dryer , bathroom, clothes, cloths, dishwashers , dryers, napkins, towel, vacuuming , washable
jumping	**show_jumping , Jumping, dres- sage, ski, skiing	**eventing , **ski_jumping , Ski, downhill, eventing	**Show_jumping , **Ski_jumping , **dressage , **ski_cross , **ski_jumping_hill , jumper, leaping, paraNordic,snowboard, snowboard- ing
lying	bed, crying, dragged, lie, sleep- ing	beside, bluff, hiding, lied, scared	asleep, cheating, dragging, dumped, hugging, knees, pillow, screeching , slept, telling
playing	Playing, performing, play, played, plays	**full_back_(association_football) , footballing, player, semi- professional, singing	**Full_back_(association_football) , **forward_(football) , **midfield , career, club, midfield, playes, profes- sionally, semiprofessionally, touring
running	cross, extending, ran, run, runs	Running, cross, line, operating, stretch, walking	**road_running , **track_running , connecting, parallel, pulling, stretched, stretching, switching, walk, winding
sitting	**168th* , **169th* , **171st* , **172nd* , **176th*	**166th* , **167th* , **170th* , **173rd* , **174th*	165th, 167th, 178th, **164th* , **165th* , **175th* , **177th* , **178th* , **179th* , **180th*
standing	holding, kneeling, seated, stands, stood	crouching, dressed, modified, sit- ting , stand	facing, hands, hangs, hung, ovation, resting, sits, smiling, unless, wearing
walking	jogging, trail, trails, walk, walk- ing, walks	accessible, bicycling, biking, hik- ing, strolling	**walking , barefoot, bike, distance, horseback, picnicing, rollerblading, sidewalk, stroll, walked
watching	enjoy, enjoying, laughing, watch, watched	chatting, crazy, listening, seeing, viewing	crying, enjoys, fun, kid, kids, loved, noticing, scared, screeching , staring
work	work:, work:, working, works, work →	endeavors, job, necessary, stud- ies, work)	Work, creations, efforts, endeavor, en- deavours, experience, expertise, fo- cus, oeuvre, research

5.3 空間の類似度と推定精度の相関分析

空間の類似度を見るために、各空間で類似するクラスを表にまとめたり、ヒストグラムで表したりした。その結果をデータ毎にまとめる。

(1) HASC data classes

表 12 は属性ベクトル空間と分散表現空間の結果を表す。




図 4 OPP データセットを用いた場合の精度

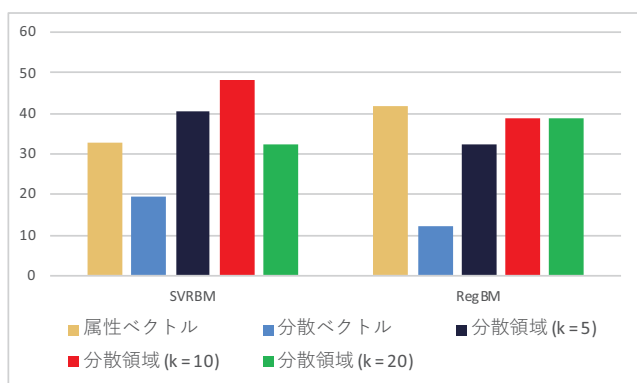


図 5 PAMAP2 データセットを用いた場合の精度

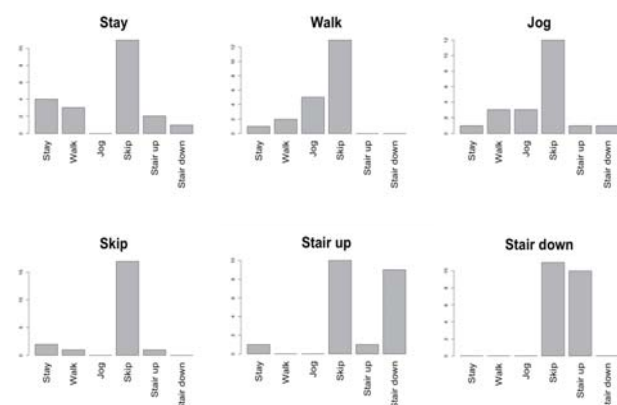


図 6 HASC データセットにおける、分散ベクトル領域内で各クラスに最も類似するクラスのヒストグラム。

表 12 から、属性ベクトル空間と分散表現ベクトル空間の比較を行う。“Stay” と “Walk”, “Stair up”, “Stair down”

において、最も近い単語は一致する。さらに、“Stay” に関しては、2 番目まで近い単語が一致しており、両スペースでの単語間の類似性は高いと考えられる。しかし、“Jog” と “Skip” は類似する単語は似ていないことがわかる。また、類似単語の頻度を見ると、属性ベクトルは “Stay” 以外の単語はほとんど均等に出現していることがわかる。分散表現に関しては、上位に “Walk” または、“Jog” が多く出現しているように感じる。図 6 から、行動クラスによらず、“Skip” に似ている単語ベクトルが多いことがわかる。また、同じ行動クラスが似ている割合が高い単語は “Skip” だけという結果になった。

(2) PAMAP2 data classes

表 13 は属性ベクトルと分散表現ベクトルの結果を表す。図 6 は、領域分散表現の結果を表す。

表 13 から、属性ベクトル空間と分散表現の比較を行う。“descending stairs” と “ascending stairs”, “house cleaning”, “vacuum cleaning”, “ironing”, “cycling” において、最も近い単語は一致する。さらに、“vacuum cleaning” に関しては、2 番目まで近い単語が一致しており、両スペースでの単語間の類似性は高いと考えられる。また、類似単語の頻度を見ると、HASC データセットの場合の分析と同様に属性ベクトルに比べて、分散表現の方が、“descending stairs” のような頻出出現クラスの存在があることがわかる。図 7 から、“vacuum cleaning” と “house cleaning” は行動クラスに関係なく、類似するサンプル数が多いことがわかる。また、同じ行動クラスが似ている割合が高い単語は “sitting” と “running” という結果になった。

(3) OPP data classes

OPP データ内の行動クラスは全部で 11 つ存在する。表 ?? は属性ベクトル空間と分散表現の結果を表す。

表 14 から、属性ベクトル空間と分散表現ベクトルの比較を行う。今回の結果に関して、最も近い単語が一致する単語の存在はなかった。類似単語の頻度を見ると、HASC データセットと PAMAP2 データセットの分析結果の場合と違い、分散表現の方が、属性ベクトル空間に比べて “Open Drawer” や “Close Drawer” などの頻出出現クラスの存在が多く存在することがわかる。図 8 から、“Open Dishwasher” という行動クラスは特に “Open” が含まれる行動クラスにおいて類似する頻度が多いことがわかる。同じ行動クラスが似ている割合が高い単語は “Drink from Cup” だけという結果になった。

また、OPP データの行動クラス “Open” と “Close” を用いた動詞とその目的名詞 (“Door”) がほとんどである。この部分に注目した時、k 近傍法が注目しているのは特徴は、attribute は “Open” などの動詞部分で、embedding は “Door” などの名詞部分であることがわかる。また、embedding region vector は attribute と同様 “Open” などの動詞部分が重要な特徴になっていることが結果から読み取れる。

表 12 HASC データセットにおける, 各クラスに類似するクラス上位 3 つ. 左が属性ベクトル空間内, 右が分散ベクトル表現空間内.

		1st	2nd	3rd		1st	2nd	3rd
1	Stay	Walk	Jog	Stair down	Walk	Jog	Stair up	
2	Walk	Jog	Stair down	Stair up	Jog	Stay	Stair down	
3	Jog	Skip	Walk	Stair down	Walk	Stay	Stair up	
4	Skip	Jog	Stair up	Stair down	Walk	Jog	Stay	
5	Stair up	Stair down	Skip	Jog	Stair down	Jog	Stay	
6	Stair down	Stair up	Skip	Jog	Stair up	Jog	Walk	

表 13 PAMAP2 データセットにおける, 各クラスに類似するクラス上位 3 つ. 左が属性ベクトル空間内, 右が分散ベクトル表現空間内.

		1st	2nd	3rd		1st	2nd	3rd
1	lying	standing	sitting	watching TV	descending stairs	car driving	ascending stairs	
2	sitting	standing	computer work	watching TV	descending stairs	ascending stairs	standing	
3	standing	sitting	lying	watching TV	descending stairs	ascending stairs	sitting	
4	walking	Nordic walking	running	descending stairs	descending stairs	watching TV	playing soccer	
5	running	walking	Nordic walking	cycling	standing	descending stairs	sitting	
6	cycling	running	Nordic walking	walking	running	standing	vacuum cleaning	
7	Nordic walking	walking	running	descending stairs	watching TV	descending stairs	walking	
8	watching TV	computer work	sitting	lying	car driving	sitting	computer work	
9	computer work	watching TV	sitting	standing	playing soccer	descending stairs	car driving	
10	car driving	sitting	computer work	standing	descending stairs	ascending stairs	lying	
11	ascending stairs	descending stairs	walking	Nordic walking	descending stairs	folding laundry	sitting	
12	descending stairs	ascending stairs	walking	Nordic walking	ascending stairs	car driving	sitting	
13	vacuum cleaning	house cleaning	folding laundry	ironing	house cleaning	folding laundry	sitting	
14	ironing	folding laundry	vacuum cleaning	house cleaning	folding laundry	ascending stairs	standing	
15	folding laundry	ironing	vacuum cleaning	house cleaning	ascending stairs	ironing	descending stairs	
16	house cleaning	vacuum cleaning	folding laundry	ironing	vacuum cleaning	sitting	folding laundry	
17	playing soccer	rope jumping	vacuum cleaning	house cleaning	descending stairs	computer work	ascending stairs	
18	rope jumping	playing soccer	house cleaning	ascending stairs	standing	sitting	descending stairs	

表 14 OPP データセットにおける, 各クラスに類似するクラス上位 3 つ. 左が属性ベクトル空間内, 右が分散ベクトル表現空間内.

		1st	2nd	3rd		1st	2nd	3rd
1	Open Door	Open Drawer	Open Dishwasher	Open Fridge	Close Drawer	Close Door	Open Fridge	
2	Close Door	Close Drawer	Close Dishwasher	Close Fridge	Open Door	Clean Table	Drink from Cup	
3	Open Fridge	Open Drawer	Open Dishwasher	Open Door	Close Fridge	Open Door	Open Drawer	
4	Close Fridge	Close Drawer	Close Dishwasher	Close Door	Open Fridge	Close Drawer	Open Door	
5	Open Dishwasher	Open Drawer	Open Fridge	Open Door	Close Dishwasher	Open Drawer	Toggle Switch	
6	Close Dishwasher	Close Drawer	Close Fridge	Close Door	Open Dishwasher	Close Drawer	Close Fridge	
7	Open Drawer	Open Dishwasher	Open Fridge	Open Door	Close Drawer	Open Dishwasher	Open Fridge	
8	Close Drawer	Close Dishwasher	Close Fridge	Close Door	Open Drawer	Open Door	Close Dishwasher	
9	Clean Table	Toggle Switch	Drink from Cup	Close Drawer	Close Door	Drink from Cup	Open Fridge	
10	Drink from Cup	Toggle Switch	Clean Table	Close Drawer	Close Door	Open Fridge	Open Door	
11	Toggle Switch	Drink from Cup	Clean Table	Close Drawer	Open Dishwasher	Close Dishwasher	Drink from Cup	




図 7 PAMAP2 データセットにおける、分散ベクトル領域内で各クラスに最も類似するクラスのヒストグラム。




図 8 OPP データセットにおける、分散ベクトル領域内で各クラスに最も類似するクラスのヒストグラム。

また、精度を加えて考察を広げると、semantic vector のみが他の手法に比べて特に精度がいいことがわかる。このことから、“Door” や “Fridge” という情報が教師データから未知行動クラスの情報に伝達されていると考えられる。

表 15 属性ベクトルとそれぞれの空間の類似度。類似度とは、図 8, 7, 6 内から、最も類似するクラスが一致するクラスの割合

	HASC	PAMAP2	OPP
分散ベクトル表現	4/6	5/18	0/11
分散ベクトル領域	1/6	8/18	2/11

表 15 は、属性ベクトル空間とそれ以外の 2 つの空間との空間類似度を表したものである。分散ベクトル表現を見た時、最も精度の高い OPP データを用いた場合の類似度は 0 である。このことから、推定精度と空間類似度の相関はないと考えられる。また、HASC データ以外の 2 つは、領域拡大させた場合、類似度が向上していることがわかる。このことから、領域を広げることで属性ベクトルに近い空間になると言うことが考えられる。

5.4 結果のまとめ

本章の結果をまとめる。センサ行動認識 Zero-shot 学習法において分散表現を用いることは属性ベクトルと比べて、適切な領域範囲を設定をすることで同等の精度もしくはそれ以上の精度を得ることが可能であることがわかった。また、分散表現の精度が属性ベクトルに同等である場合、その原因は属性ベクトルの空間と似ているという理由である可能性があることが空間類似度の分析の結果からわかった。これより、分散表現を用いることは属性ベクトルを用いる場合より、精度を含め行動認識 Zero-shot 学習法の実用化に、より現実的で、精度が向上の可能性があることが期待できることがわかった。

6. 考察

ここでは、本稿の結果より、分散表現を用いた場合、どのような状況である時精度が得られるのかを分析、検討する。

今回の結果より、気になる点として、分散表現の領域を広げることで属性ベクトル空間に似てきているのではないかと、という疑問である。また、今後の展望としてどのような分散表現を用いることで精度の高い未知クラス推定ができるのかについて考察していく。この 2 つの観点进行分析するために、分散表現で属性ベクトル表現より高い精度が得られており、領域を広げることで属性ベクトル空間手法の推定精度と近くなっている OPP データを分析する。

6.1 OPP データセットの結果の考察

まず、これらのデータの結果より、分散表現と領域ベクトルの違う部分について探した結果、??で、類似する行動

クラスの規則が変わっていることに気づいた。詳しい説明の前に、このデータの行動クラスについて説明する。OPP データに含まれる行動クラスは、全てが“動詞” + “オブジェクト”という構成になっている。さらに、動詞が重複している場合、またオブジェクトが重複している場合、など組み合わせが違うだけの行動クラスが多くある。例えば、動詞 “open door” や “close door” はオブジェクトに関して、重複がある。“open door” と “open Fridge” はオブジェクトに関して重複がある。

これを元に説明をすると、分散表現で類似する行動クラスの規則としては、オブジェクトに注目されているパターンが多い。しかし、領域ベクトルは動詞に注目されているパターンが多い。これについて考察した結果を図 9 を用いて説明する。

3.4 節でも述べたように、2 つ以上の単語が組み合わさった単語の場合、意味ベクトルは 2 つの単語ベクトルの平均をとっている。したがって、分散表現においては、“Open Door” と “Close Door” の単語ベクトルは “Door” という単語ベクトルを中心に近くなる。同様に “Fridge” という単語を中心に “Open Fridge” と “Close Fridge” も近くなる。したがって、分散表現空間では“足し合わせるオブジェクト部分が重要特徴量であるということになる (9 の左)。しかし、領域を広げたものは、3.4 節で述べたように動詞部分の領域のみを広げたため、“Close” のような動詞を中心としてのサンプルが増えるため、動詞が重要な特徴として近く単語ベクトルが増える (9 の右)。

また、属性ベクトルも領域ベクトルと同様に動詞に着目され類似クラスが見られていることがわかる。これらのことから、どうしてオブジェクトに注目した分散表現を用いた場合の手法が精度が高いのかについて考察する。その理由として、OPP データセットは、物体センサが含まれており、これは動きセンサに比べ判別するのに重要な特徴量であるからであると考えられる。センサ内で判別するのに重要な特徴量があった場合、その特徴量に関連する属性の推定精度 (投影の精度) が高いと考えられる。今回の場合だと、属性ベクトルの意味ベクトルの k-近傍法の精度はオブジェクトに比べて動詞においてはいい精度であった、つまりモーションの部分での精度はよかった。しかし、センサデータ空間内では、逆に動詞に比べてオブジェクトの分類精度が高いと考えられる。つまり、センサデータ空間内でクラス分類する上で重要な特徴量と意味ベクトル内でクラス分類する上で重要な特徴量が一致する場合が Zero-shot 全体の精度向上に繋がると考えられる。

まとめると、今後分散表現を用いる上で、Wikipedia のような大規模コーパスを用いて、ノイズや表記の揺れを考慮した領域を広げる方法をとることで、人の感覚での行動の属性ベクトルに近いものになると考えられる。しかし、属性ベクトルを超える精度を目指すためには、センサデー

タの重要な特徴量と同様の、重要な特徴量をもつ意味ベクトルにする必要があると考えられる。

7. まとめ

本稿では、センサ行動認識のための Zero-shot 学習法において分散表現を用いることの提案と検討を行った。Wikipedia という大規模コーパスから生成される分散ベクトル表現を用いることの弱点である、表記の揺らぎとノイズを考慮するために、領域を広げた分散ベクトル領域を提案し、領域を広げた時のサンプルの分析、分散表現と属性ベクトルを用いた手法の未知クラス推定比較評価、意味ベクトル空間の類似度分析、を行った。




図 9 分散ベクトル表現空間(左)と分散ベクトル領域(右)の類似クラスが違う原因の考察. 分散ベクトル表現空間では、“open door”と“close door”が近いのに対し、分散ベクトル領域では、“open door”と“open fridge”が近い。

その結果、分散ベクトル表現からベクトル領域にサンプル拡張することで、属性ベクトルと同等の精度が得られること、領域拡大前に比べて最大で 28% 推定精度の向上が見られたこと、属性ベクトルとの空間的類似度が高くなること、がわかった。これら結果から、センサ行動認識 Zero-shot 学習手法に対して、分散ベクトル表現を用いることは、手動で生成する属性ベクトルに比べて容易に導入可能であり、さらに属性ベクトルと同等の精度は確保できることがわかり、センサ行動認識の実用性の高い新たな手法であることを示した。さらに、センサデータと意味ベクトル、それぞれの特徴量の中に同じような情報が含まれる場合、属性ベクトルより高い精度が得られることがわかった。この知見は、センサ行動認識 Zero-shot を応用する場合のクラス選択や必要なセンサデータの選定にとって重要である。これらことから、今後は、より実現に向けた評価と、精度の高い手法を目指す。

参考文献

[1] Perez, Alfredo J., Miguel A. Labrador, and Sean J. Barbeau. “G-sense: a scalable architecture for global sensing and monitoring.” *IEEE Network* 24.4 (2010): 57-64.
 [2] Lara, Oscar D., and Miguel A. Labrador. “A survey on human activity recognition using wearable sensors.” *IEEE communications surveys & tutorials* 15.3 (2013): 1192-1209.
 [3] 武市泰彦. “生活行動の記録ツールを用いた分類別行動の取

集とその年別推移.” *四国大学紀要= Bulletin of Shikoku University* 46 (2016): 123-146.
 [4] Foerster, F., M. Smeja, and J. Fahrenberg. “Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring.” *Computers in Human Behavior* 15.5 (1999): 571-583.
 [5] Tapia, Emmanuel Munguia, et al. “Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor.” 2007 11th IEEE international symposium on wearable computers. IEEE, 2007.
 [6] He, Zhenyu, and Lianwen Jin. “Activity recognition from acceleration data based on discrete cosine transform and SVM.” 2009 IEEE International Conference on Systems, Man and Cybernetics. IEEE, 2009.
 [7] Parkka, Juha, et al. “Activity classification using realistic data from wearable sensors.” *IEEE Transactions on information technology in biomedicine* 10.1 (2006): 119-128.
 [8] Kwon, Yongjin, Kyuchang Kang, and Changseok Bae. “Unsupervised learning for human activity recognition using smartphone sensors.” *Expert Systems with Applications* 41.14 (2014): 6067-6074.
 [9] Yao, Lina, et al. “Learning from less for better: semi-supervised activity recognition via shared structure discovery.” *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. ACM, 2016.
 [10] Lampert, Christoph H., Hannes Nickisch, and Stefan Harmeling. “Learning to detect unseen object classes by between-class attribute transfer.” 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009.
 [11] Wang, Wei, Chunyan Miao, and Shuji Hao. “Zero-shot human activity recognition via nonlinear compatibility based method.” *Proceedings of the International Conference on Web Intelligence*. ACM, 2017.
 [12] Cheng, Heng-Tze, et al. “Nuactiv: Recognizing unseen new activities using semantic attribute-based learning.” *Proceeding of the 11th annual international conference on Mobile systems, applications, and services*. ACM, 2013.
 [13] Palatucci, Mark, et al. “Zero-shot learning with semantic output codes.” *Advances in neural information processing systems*. 2009.
 [14] Kodirov, Elyor, Tao Xiang, and Shaogang Gong. “Semantic autoencoder for zero-shot learning.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017.
 [15] Mishra, Ashish, et al. “A generative model for zero shot learning using conditional variational autoencoders.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2018.
 [16] 重藤優太郎, et al. “Zero-shot learning における線形回帰の影響.” *研究報告自然言語処理 (NL)* 2015.4 (2015): 1-8.
 [17] Lampert, Christoph H., Hannes Nickisch, and Stefan Harmeling. “Attribute-based classification for zero-shot visual object categorization.” *IEEE Transactions on Pattern Analysis and Machine Intelligence* 36.3 (2014): 453-465.
 [18] Fu, Yanwei, et al. “Recent advances in zero-shot recognition.” *arXiv preprint arXiv:1710.04837* (2017).
 [19] Fu, Yanwei, et al. “Transductive multi-label zero-shot learning.” *arXiv preprint arXiv:1503.07790* (2015).
 [20] Zhang, Ziming, and Venkatesh Saligrama. “Zero-shot

- recognition via structured prediction." European conference on computer vision. Springer, Cham, 2016.
- [21] Norouzi, Mohammad, et al. "Zero-shot learning by convex combination of semantic embeddings." arXiv preprint arXiv:1312.5650 (2013).
- [22] Akata, Zeynep, et al. "Label-embedding for attribute-based classification." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2013.
- [23] Bucher, Maxime, Stéphane Herbin, and Frédéric Jurie. "Improving semantic embedding consistency by metric learning for zero-shot classification." European Conference on Computer Vision. Springer, Cham, 2016.
- [24] Mikolov, Tomas, et al. "Efficient estimation of word representations in vector space." arXiv preprint arXiv:1301.3781 (2013).
- [25] Mikolov, Tomas, et al. "Distributed representations of words and phrases and their compositionality." Advances in neural information processing systems. 2013.
- [26] Reiss, Attila, and Didier Stricker. "Introducing a new benchmarked dataset for activity monitoring." 2012 16th International Symposium on Wearable Computers. IEEE, 2012.
- [27] Roggen, Daniel, et al. "Collecting complex activity datasets in highly rich networked sensor environments." 2010 Seventh international conference on networked sensing systems (INSS). IEEE, 2010.
- [28] Rei, Marek, and Ted Briscoe. "Looking for hyponyms in vector space." Proceedings of the Eighteenth Conference on Computational Natural Language Learning. 2014.
- [29] zhang2015zero Zhang, Ziming, and Venkatesh Saligrama. "Zero-shot learning via semantic similarity embedding." Proceedings of the IEEE international conference on computer vision. 2015.
- [30] Cheng, Heng-Tze, et al. "Towards zero-shot learning for human activity recognition using semantic attribute sequence model." Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing. ACM, 2013.
- [31] Aehnel, Mario, and Karoline Wegner. "Learn but work!: towards self-directed learning at mobile assembly workplaces." Proceedings of the 15th International Conference on Knowledge Technologies and Data-driven Business. ACM, 2015.
- [32] Ransing, Rasika S., and Manita Rajput. "Smart home for elderly care, based on Wireless Sensor Network." 2015 International Conference on Nascent Technologies in the Engineering Field (ICNTE). IEEE, 2015.
- [33] Ferreira, Emmanuel, Bassam Jabaian, and Fabrice Lefvre. "Zero-shot semantic parser for spoken language understanding." Sixteenth Annual Conference of the International Speech Communication Association. 2015.
- [34] Zellers, Rowan, and Yejin Choi. "Zero-shot activity recognition with verb attribute induction." arXiv preprint arXiv:1707.09468 (2017).
- [35] Guadarrama, Sergio, et al. "Youtube2text: Recognizing and describing arbitrary activities using semantic hierarchies and zero-shot recognition." Proceedings of the IEEE international conference on computer vision. 2013.
- [36] Hammerla, Nils Y., Shane Halloran, and Thomas Pltz. "Deep, convolutional, and recurrent models for human activity recognition using wearables." arXiv preprint arXiv:1604.08880 (2016).
- [37] Matsuki, Moe, and Sozo Inoue. "Recognizing unknown activities using semantic word vectors and twitter timestamps." Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct. ACM, 2016.
- [38] MATSUKI, Moe, and Sozo INOUE. "Toward Recognizing Unknown Activities Using Word Vectors." (2016).
- [39] Zhang, Ziming, and Venkatesh Saligrama. "Zero-shot learning via semantic similarity embedding." Proceedings of the IEEE international conference on computer vision. 2015.
- [40] Akata, Zeynep, et al. "Evaluation of output embeddings for fine-grained image classification." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015.