

照度と電力消費量データおよび単語ベクトルを用いた行動推定の試み

松木 萌¹ 井上 創造²

概要：本稿では、行動認識において、自然言語処理によって生成された行動ラベルと単語ベクトルを用意し、zero-shot 学習を適用することで、未知行動データを推測する方法を提案する。行動認識の研究では、収集データから行動ラベルを機械学習する手法が一般的であるが、この方法では行動ラベルが学習されていない未知な行動を推定することが出来ないという問題がある。未知な行動を推定する既存研究として、行動ラベルに対して体の動きを表すコード表を用意しておいて、行動を推定するという手法を提案されている。しかし、この手法だとコード表を用意しておかなければいけないという問題がある。我々はコード表の代わりに、単語ベクトル化ツール word2vec を用いて行動ラベルと単語ベクトルを用意し、zero-shot 学習を適用する方法を提案する。提案手法で行動推定を行った際、既存手法とどの程度変わるのか評価するため、本研究室で過去に生活行動センシング実験を行った際に収集されたデータを用いて行動推定を各手法を用いて行った。そして、各手法の精度を出力し比較を行った。また提案手法を用いて、未知な行動ラベルが推定されるのか評価するため、同様のデータを用いて予備評価を行い精度を出した。予備評価の結果、提案手法が既存手法に比べて、約 5%精度が向上した。そして、提案手法で、7 つの未知行動ラベルを推定することができた。未知行動ラベルの精度は、適合率は最大で約 89%、再現率が最大で、約 1.3%という結果となった。また、特徴量ベクトルと単語ベクトルの互換性があるのかを分析するため、特徴量ベクトルと単語ベクトル、さらに推定された単語ベクトルを行動ラベル毎に 2 次元プロットしベクトルの可視化を行った。結果、特徴量ベクトルと推定された単語ベクトルの互換性はあるが、単語ベクトルとの互換性は低いことがわかった。以上のことから、未知行動の推定精度を向上させることで、行動推定の精度はより向上し、また互換性のずれは単語ベクトルと特徴量ベクトルに含まれる情報の違いにあると考察した。

Activity Recognition of Unknown Labels Using Sensor Data and Word Vectors

MOE MATSUKI¹ SOZO INOUE²

1. はじめに

近年、行動認識の研究が盛んである。行動認識は、家庭内の電力消費の効率化や、高齢者の見守り、健康分野の生活習慣改善のために注目され、需要が高まっている。

しかし、未知のラベルを推定できないという問題がある。未知の対象を推定する手法として、zero-shot 学習という手法がある [3]。zero-shot 学習とは、カテゴリ間の属性における関係を利用することで、一部のカテゴリに関する学習用データがない状態でも、他のカテゴリに関する学習用デー

タを使った学習が可能になるという手法である。zero-shot 学習の既存研究では [1] のような、行動ラベルに対して体の動きを表すコード表を用意しておいて行動を推定するという手法を提案している。しかし、その手法だとコード表を用意しておかないといけないという問題がある。我々はコード表の代わりに自然言語処理を使って行動ラベルと単語ベクトルを用意し、zero-shot 学習を適用する方法を提案する。

行動ラベル、単語ベクトルとは自然言語処理 word2vec という単語ベクトル化ツールを用いて、Wikipedia のデータから単語ベクトルを生成した。我々は、この単語ベクトルと行動ラベルの属性関係を利用することで、行動データ

¹ 九州工業大学大学院工学府

² 九州工業大学大学院工学研究院

のない状態でも、単語ベクトルに関する学習用データを使った推定が可能になると考えた。

本稿では、提案手法で行動推定を行った際、既存手法とどの程度変わるのか評価するため、本研究室で過去に生活行動センシング実験を行った際に収集されたデータを用いて行動推定を各手法を用いて行った。そして、各手法の精度を出力し比較を行った。また提案手法を用いて、未知な行動ラベルが推定されるのか評価するため、同様のデータを用いて予備評価を行い精度を出した。生活行動センシング実験は、35軒の被験者の各家庭に端末を1台ずつ置いてもらい、開発システムを用いて、センサデータおよび電力データを収集した。また、行動ラベルを1日に数分程度入力してもらうことを行った。その結果、約4ヶ月間分、約11,745件の行動入力と約7.14GBのセンサデータと約72,554時間分の消費電力データを得た。今回そのうち、20件のデータを用いた[4]。

予備評価の結果、提案手法が既存手法に比べて、約5%精度が向上した。そして、7つの未知行動ラベルを推定することができた。未知行動ラベルの精度は、適合率は最大で約89%、再現率が最大で、約1.3%という結果となった。

また、提案手法で用いた単語ベクトルと特徴量ベクトルは全く別のデータで生成されたため、2つのベクトルの互換性を調べる必要があった。本稿では、単語ベクトル、特徴量ベクトル、さらに推定された単語ベクトルを2次元プロットすることで、ベクトルを可視化し分析を行った。その結果、特徴量ベクトルと推定単語ベクトルの互換性はあったが、単語ベクトルとの互換性は低いことがわかった。

以上のことから、未知行動の推定精度を向上させることで、行動推定の精度はより向上し、また互換性のずれは単語ベクトルと特徴量ベクトルに含まれる情報の違いにあると考察した。

2. 自然言語処理を用いた zero-shot 学習法

本節では、自然言語処理を用いて行動ラベルと単語ベクトルを用意し、zero-shot 学習を適用する提案手法について述べる。

2.1 準備

ここでは、提案手法の説明にあたって、必要な記号や知識について述べる。

X, Y はベクトル集合を表しており、 X はデータの特徴量ベクトル集合である。 Y は X の特徴量データに対応する行動ラベル集合である。また、 X, Y のそれぞれのドメインを \mathcal{X}, \mathcal{Y} と示す。

図1は一般的な行動認識手法を図に表したものである。行動認識は、一般的に X と Y を機械学習し、推定モデル $f: \mathcal{X} \rightarrow \mathcal{Y}$ を生成する。推定時には、新しい入力 x^{new} から

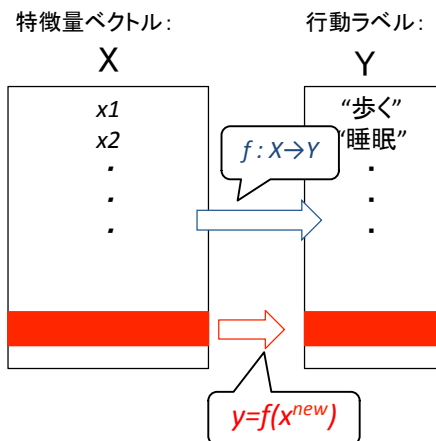


図1 既存手法： X を説明変数、 Y を目的変数とし機械学習を行い、 X から Y を推定する

$$\tilde{y} = f(x^{new})$$

により行動 \tilde{y} を推定する。以上の推定モデル生成と行動ラベル推定の一連の計算を自動で行うアルゴリズムを使用する。

2.2 提案手法

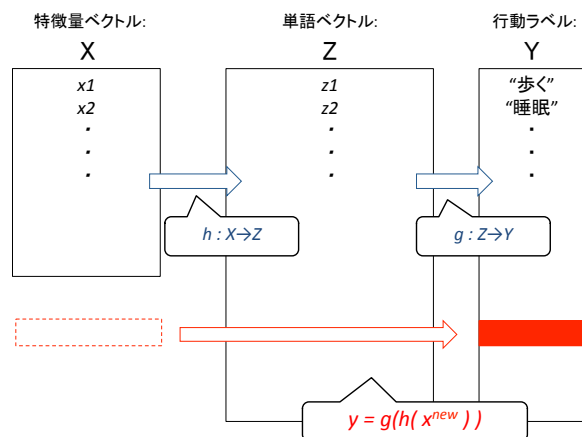


図2 提案手法：単語ベクトル Z を用いて、推測モデル $g: \mathcal{Z} \rightarrow \mathcal{Y}$ と $h: \mathcal{X} \rightarrow \mathcal{Z}$ を生成し、 $\tilde{y} = g(h(x^{new}))$ で推定を行う。

図2は提案手法を図に表したものである。提案手法では、 Y は行動ラベル集合、 Z は Y に対応する単語ベクトル集合とする。単語ベクトルについては2.3章で述べる。

提案手法の流れを以下に記す。

- (1) Y を説明変数、 Z を目的変数とし機械学習を行い、推定モデル $f: \mathcal{Z} \rightarrow \mathcal{Y}$ を生成。
- (2) Z を説明変数、 X を目的変数とし、機械学習を行い、推定モデル $f: \mathcal{X} \rightarrow \mathcal{Z}$ を生成。
- (3) 推定時には、新しい入力 x^{new} から $\tilde{y} = g(h(x^{new}))$ により行動 \tilde{y} を推定する。

こうすることで、我々は行動ラベル Y と単語ベクトル Z に、特徴量ベクトル X に存在しない行動クラスを含ませ

ることで、未知な行動クラスを予測することが出来ると考えられる。

2.3 単語ベクトル

自然言語処理の分野において、word2vec[2] という単語ベクトル化ツールが近年注目を集めている。word2vec とは、リカレントニューラルネットワークを用いて、分かち書きされた単語を、文中の単語を周辺の単語を情報とし、リカレントニューラルネットワークを用いて学習させることで、各単語にベクトルを割り当てるものである。この word2vec を用いて Wikipedia から単語ベクトルを作成し、行動ラベルに対する単語ベクトルを生成した。

また、実験で得られた行動ラベルには、1つの単語ではないラベルも含まれており、例えば、「テレビ・ラジオ・新聞・雑誌」という行動ラベルも含まれている。これらのラベルは、行動ラベルに含まれている単語ベクトルの平均をとるといった対処をした。

3. 予備評価

本節では、提案手法と既存手法の行動推定の精度を比較し、また提案手法で未知行動ラベルが推定されるかを評価するため、簡易センサを用いた生活行動センシング実験で得られたデータを用いて、行動推定を行い精度を出した。また、提案手法で用いた特徴量ベクトルと単語ベクトルと推定された単語ベクトルの互換性について分析を行った。

3.1 データセット

データセットとして、35軒の家庭から4ヶ月間の実験を行い、照度センサ/スマートメータ、および被験者がつけた行動ラベルデータを収集し、そのうちの20件のデータを用いた[4]。端末に搭載された照度センサのデータを持続的にサーバに収集し、簡易的に設置できるスマートメータから、1分に1サンプルの頻度で電力データを収集した。行動ラベルに関しては、図3のような、被験者が新しい行動ラベルを定義して記録できるWebシステムを用いて、システムが推定する行動を確定したり修正したりできるようにした。

3.2 前処理

この実験で得られた照度、電力消費データから、特徴量を計算し特徴量集合 X を生成した。特徴量は1分ごとに次の値を計算した。

- 一日の中の時刻 (0-24時 × 60分)
- 照度の平均値、標準偏差、最大値、最小値
- 一分ごとに得られる消費電力値

この結果、332,499 サンプルの多次元データとなった。単語ベクトル Z は、単語ベクトル化ツール word2vec を用いて Wikipedia のサイトから 100 次元の単語ベクトル生成

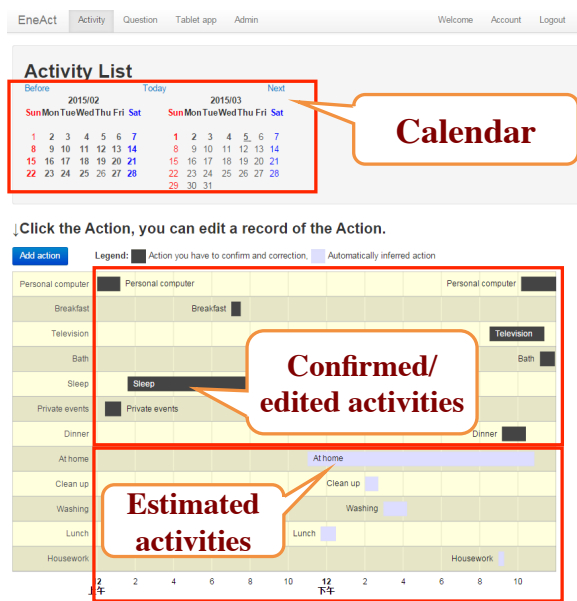


図3 行動ラベルを定義、記録、変更できる Web システム

した。そこから、次元削減のために、ランダムフォレストを用いて10つの大事な次元を抽出した。行動ラベル集合 Y は単語ベクトル Z に対応した単語の集合である。結果 Y は52種類の行動ラベル集合、 Z は 52×10 の単語ベクトル集合となった。行動ラベルを以下に列挙する。「アイロンかけ」、「オープンでケーキ」、「休養・くつろぎ」、「ゲーム」、「資源ゴミだし」、「ごろごろ」、「ショッピング」、「タブレット」、「テレビ」、「テレビ・ラジオ・新聞・雑誌」、「バイク積み込み」、「パソコン」、「ビデオ」、「フラダンス」、「ヨガ」、「優祐ランド」、「衣類乾燥機」、「運動」、「家事」、「身の回りの用事」、「外出」、「外食」、「仕事・学業」、「食器洗乾燥器」、「間食」、「炊飯器」、「陸運局」、「車輛保険の更新」、「在宅」、「弁当作り」、「散歩」、「仕事」、「事務」、「美容室」、「習い事」、「出張」、「弁当準備」、「初午大祭」、「食事」、「炊事」、「睡眠」、「洗濯」、「掃除」、「昼食」、「朝食」、「朝の読み聞かせ」、「通勤・通学」、「読書」、「買い物」、「風呂」、「勉強」、「夕食」。

3.3 評価手法

機械学習の基本的なアルゴリズムとして、 $k=2$ で k 近傍法を適応した。なぜならこのアルゴリズムは、直接サンプル間の距離に適切に反映できると考えたためである。

提案手法が、未知な行動クラスを推定できるかどうか評価するために、以下の流れで、評価実験を行った。

- (1) データから行動クラス y を取り除く
 - (2) そのデータで学習を行う
 - (3) 行動クラス y を取り除く前のデータでテストを行う
- 以上のことを各行動クラス $y \in \mathcal{Y}$ で行う。これにより、取り除いた行動クラス、つまり未知な行動クラスが推測され

るかどうかを評価することが出来る。

評価尺度として、既存手法と提案手法で推定した結果を比較するために正解率の尺度を精度とする。正解率とは全てのデータのうち正しく推定できている割合である。また、既存手法が未知な行動を推定できているかどうかを評価するために、未知な行動の適合率と再現率の2つの尺度を精度とする。適合率とは、正と推定したデータのうち実際に正だったものの割合。再現率とは、実際に正であるもののうち正であると推定されたものの割合である。

また、推定時に行動ラベルのデータの偏りにより、推定にも大きな影響が出てしまうため、行動のバランスをとるアルゴリズムを適用させた。つまり、推定したい行動の有無を同じデータ数になるようにサンプリングするようなアルゴリズムを作成した。

3.4 結果

まず、既存手法と提案手法の精度を比較する。既存手法の精度は約 37.1%、提案手法の精度は約 42.1%となり、精度が約 5%向上していることがわかった。

次に、提案手法で未知な行動ラベルが推定できているかどうかの精度を見る。結果を表 3.4 に示す。未知な行動と推定されたデータ数の精度を見るため、TP sample と適合率、再現率を計算し、以下の表にまとめている。

表 1 提案手法で推定された未知行動ラベルの精度

Activity class	#TP samples	適合率 [%]	再現率 [%]
「パソコン」	94	50.3	0.0
「家事」	1596	57.4	0.4
「外出」	16384	37.9	3.9
「休養・くつろぎ」	8475	41.8	2.0
「在宅」	4760	53.5	1.3
「食事」	5704	89.3	1.3
「習い事」	44	44.9	0.0

表 3.4 より、学習データが存在しないのにも関わらず「家事」、「外出」、「休憩・リラックス」、「在宅」、「食事」、「習い事」の7つの行動ラベルが推定されていることがわかった。

精度については適合率は最大で約 89%、再現率は最大で約 1.3%であった。これは、未知行動ラベルにおいて、推定された行動ラベルの正解率は高いが、推定されていないデータが数多く存在することを示している。

3.5 単語ベクトルと特徴量ベクトルの互換性

zero-shot 学習の既存研究では [1] のような、行動ラベルに対して体の動きを表すコード表を用意しておいて行動ラベルを推定するという手法を提案している。このコード表は行動を表すデータを基に人工的に生成されている。しかし我々の提案手法では、Wikipedia で生成した単語ベクトル Z は、特徴量ベクトルやコード表とは違い、行動を表す

データとは無関係である。したがって、特徴量ベクトルと単語ベクトルの互換性があるかどうかの疑問点がある。

ここでは、提案手法で用いている Wikipedia で生成した単語ベクトル Z と特徴量ベクトル X の互換性について調べる。予備評価で用いたデータはラベルが多く、分析が困難なため、ある1家庭のデータサンプルを抽出した結果、行動ラベルは「テレビ」、「テレビ・ラジオ・新聞・雑誌」、「パソコン」、「家事」、「外出」、「休養・くつろぎ」、「仕事・学業」、「食事」、「身の回りの用事」、「睡眠」、「昼食」、「朝食」、「通勤・通学」、「風呂」、「夕食」の15種類、23,490件のデータとなった。このデータを用いて、以下の3つのベクトル集合を用意した。

- 特徴量のベクトル集合
- 行動ラベルに対する単語ベクトル集合
- $X \rightarrow Z$ で推定した単語ベクトル集合

以上の3つのベクトル集合を用いて行動ラベルの互換性を分析する。

まず、特徴量ベクトル集合と $X \rightarrow Z$ で推定した単語ベクトル集合は、行動ラベルに対してベクトル数が多数あったため、行動ラベル毎にベクトルの各次元で平均をとった。そして、ベクトル集合を主成分分析を用いて多次元から2次元にした。こうすることで、多次元のベクトルを2次元のベクトルにしプロットすることで、分析が容易になるようにした。ベクトルを主成分分析し、プロットした結果を図 4 に示す。

左から順に、特徴量ベクトル (featvec), $X \rightarrow Z$ で推定されたベクトル (prevec), 単語ベクトル (wordvec) をプロットした図である。また、「朝食」、「昼食」、「夕食」を赤い丸で囲い、「テレビ」、「パソコン」を青い丸で囲った。赤い丸で囲った行動ラベルについて、単語ベクトルのプロット結果では、近くにあり、特徴量ベクトルと推定単語ベクトルのプロット結果では、離れている。青い丸で囲った行動ラベルについて、特徴量ベクトルと推定単語ベクトルのプロット結果では、近くにあるが、単語ベクトルのプロット結果では、離れている。

以上のことから、特徴量ベクトルと単語ベクトルの互換性は低いと考えられる。しかし、3つの図に共通して、「テレビ」と「テレビ・ラジオ・新聞・雑誌」の行動ラベルは近くにあることから、全く互換性がないとは言えない。

3.6 考察

既存手法と提案手法の行動推定の精度比較の結果、提案手法のほうが約 5%向上していた。また、提案手法である1行動のサンプルを抜いて学習させ、推定を行った結果、7つの未知行動ラベルを推定することができた。未知行動ラベルの推定精度の結果から、適合率が最大で約 89%、再現率は約 1.3%であったことから、未知な行動の精度を向上させることで、全体の精度がより向上することが期待




図 4 左：特徴量ベクトル X (featvec)，中央： $X \rightarrow Y$ で推定されたベクトル (prevec)，右：単語ベクトル Z (wordvec)

される。

また、単語ベクトル Z と特徴量ベクトル Y の互換性が低いことが前説でわかった。単語ベクトルと特徴量ベクトルの互換性のずれについて、「朝食」、「昼食」、「夕食」の行動ラベルと「パソコン」、「テレビ」の行動ラベルを挙げている。これらの行動ラベルのずれの原因として、考えられるのはデータの内容が関係していると考えられる。

特徴量ベクトルは、その行動が行われた「時刻」と「照度」と「消費電力値」の情報がある。したがって、「朝食」、「昼食」、「夕食」の行動ラベルが離れているのは、時刻情報が影響しており、「パソコン」、「テレビ」の行動ラベルが近くにあるのは、消費電力情報の影響があると考えられる。単語ベクトルは、Wikipedia の文中の情報が含まれている結果、「朝食」、「昼食」、「夕食」の行動ラベルが近く、「パソコン」、「テレビ」の行動ラベルが遠いということがわかった。

以上のことより、単語ベクトルに行動の情報を含ませることで、単語ベクトルと特徴量ベクトルの互換性を持たせることができると考えられる。互換性を持たせるために、単語ベクトルを Wikipedia ではなく、日記やブログのデータを基に生成する、もしくは特徴量を単語ベクトルを生成する際に含ませることを検討している。

4. まとめ

本稿では、行動認識において、自然言語処理を用いて生成した行動ラベルと単語ベクトルを用意し、zero-shot 学習を適用することで、未知行動データを推測する方法を提案した。行動認識の研究では、収集データから行動ラベルを機械学習する手法が一般的であるが、行動ラベルが学習されていない未知な行動を推定することが出来ないという問題がある。

未知な行動を推定する既存研究では、体の動きを表すコード表を用意しておかなければいけないという問題が

ある。我々はそれに対してコード表に代わりに、単語ベクトル化ツール word2vec を用いて行動ラベルと単語ベクトルを用意し、それに zero-shot 学習を適用する方法を提案した。

提案手法で、未知な行動ラベルが推定されるのか評価するため、本研究室で過去、生活行動センシング実験を行った際に収集されたデータを用いて評価実験を行った。センシングデータは 35 軒の被験者の各家庭で 4 ヶ月間行い、7.14GB のセンサデータおよび 72,554 時間分の電力データ、約 11,745 件の行動入力 of データを得た。

この実験で得られた、照度、電力消費データから、特徴量を計算し特徴量集合 X を生成した。また、単語ベクトル Z は、単語ベクトル化ツール word2vec を用いて Wikipedia のサイトから 100 次元の単語ベクトル生成した。そこから、次元削減のために、ランダムフォレストを用いて 10 つの大事な次元を抽出した。行動ラベル集合 Y は単語ベクトル Z に対応した単語の集合である。

未知な行動ラベルが推定されるのか評価するため、データから行動クラス y を取り除いたデータを学習データとし、取り除く前のデータでテストを行う、この流れを各行動クラス $y \in Y$ で行った。

その結果、7 つの未知行動クラス「家事」、「外出」、「休憩/リラックス」、「在宅」、「食事」、「習い事」が推測された。未知行動の推定精度は適合率は最大で約 89%，再現率は最大で約 1.3% となった。

今回提案手法で用いている単語ベクトルと特徴量ベクトルは全く別のデータを用いて生成されている。したがって、2 つのベクトルの互換性を調べる必要があった。そこで、特徴量ベクトルと単語ベクトル、そして推定された単語ベクトルを 2 次元プロットをすることで、可視化、分析を行った。その結果、特徴量ベクトルと推定された単語ベクトルの互換性はあることがわかったが、単語ベクトルとの互換性は低いことがわかった。その原因として、特徴量

ベクトルと単語ベクトルの基になったデータのずれによるものだと考えられる。

したがって、今後の課題として特徴量ベクトルと単語ベクトルの互換性を上げるために、単語ベクトルの生成方法を検討し、また未知行動ラベルの推定精度の向上を目指す。

参考文献

- [1] Cheng, H.-t., Griss, M., Davis, P., Li, J. and You, D.: 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 - UbiComp '13*, No. 2, p. 355 (online), DOI: 10.1145/2493432.2493511 (2013).
- [2] Mikolov, T., Corrado, G., Chen, K. and Dean, J.: Efficient Estimation of Word Representations in Vector Space, *Proceedings of the International Conference on Learning Representations (ICLR 2013)*, pp. 1–12 (online), DOI: 10.1162/153244303322533223 (2013).
- [3] Palatucci, M., Hinton, G., Pomerleau, D. and Mitchell, T. M.: Zero-Shot Learning with Semantic Output Codes, *Neural Information Processing Systems*, pp. 1–9 (2009).
- [4] Pan, X., Minezaki, T., Isoda, T., Tanaka, S., Uchino, Y. and Inoue, S.: Analyzing Daily-life Activities and Power Consumptions Using Tablet Sensors and Activity Annotation Web System, *Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers*, UbiComp/ISWC'15 Adjunct, New York, NY, USA, ACM, pp. 1443–1452 (online), DOI: 10.1145/2800835.2801615 (2015).