

日常行動識別のための文字列カーネルを用いた時系列データの分節

Segmentation of Time-Series Data Using String Kernels
for Recognition of Activities of Daily Living佐土原 健*¹

Ken Sadohara

*¹(独) 産業技術総合研究所

National Institute of Advanced Industrial Science and Technology (AIST)

This paper is concerned with the discovery of activities of daily living (ADLs) from time-series data in the smart home applications. Given a sequence of events of motion sensors and door closure sensors, an unsupervised algorithm segments the sequence into blocks relevant to ADLs and creates ADL-related features. Based on the assumption that some salient sub-sequences of the events are useful for recognizing ADLs, the algorithm merges sub-blocks having similar distributions of the sub-sequences. It uses string kernels to efficiently compute the similarity based on all non-contiguous sub-sequences of sensor events. An empirical study shows that the obtained features are effective not only for the classification of predefined ADLs but also for the classification of activities that does not belong to a predefined class, which tend to account for a large amount of data. Moreover, when the annotation of predefined activities is cost-prohibitive, these ADL-related features can be useful for the other unsupervised ADL analyses such as anomaly detection. Thus the presented algorithm and resulting features are a first step toward an ADL analysis system with less intervention.

1. はじめに

高齢化社会の進行に伴って、独り暮らしの高齢者が増加しており、厚生労働省の平成24年度国民生活基礎調査 [厚労省 12] によれば、65歳以上の独居高齢者世帯数は、およそ487万世帯 (全世帯数の23.3%) にのぼっている。こうした独居高齢者の安全かつ健康的で自立した生活を支援するために、情報技術を活用した見守りシステムに関してこれまでに多くの研究開発が行われてきた [Kidd 99, 松岡 05, 美濃 05, Intille 06, Kröse 08, Mori 09, Cook 13]。そのようなシステムでは、居住者のプライバシーに配慮しながらも、住居に多種多様なセンサーを設置し、居住者の日常生活に関するさまざまな情報を吸い上げ分析を行い、異常を検知したり、適切な助言を行ったり、適応的な環境制御を行う等の生活支援サービスを提供することを目指している。

このようなスマートホーム開発の中核技術の一つが、居住者が今何をしているかを判断する日常行動分析であり、センシングデータから行動のモデルを学習する目的でさまざまな機械学習技術 [白石 09, 下坂 10, Krishnan 12, Cook 13] が検討されている。しかしながら、こうした日常行動のモデリングにおいては、生活環境や行動様式の多様性が問題となる [美濃 05, 本村 09]。例えば、ある居住者のために構築した行動モデルは、別の居住者にどの程度再利用可能であろうか？ ある程度再利用可能であるという報告 [Cook 12] がある一方、部屋の間取り、家具の配置、センサーの種類・設置場所、行動の様式等は、居住者毎に大きく異なるのが普通であり、一般論としてモデルの再利用は非常に難しいと考えられる。その場合は、居住者毎にモデルを改めて構築する必要が生じるが、学習データをアノテーションするコストが許容できない場合が多い。さらに、家具の配置が変わったり、居住者の行動が加齢とともに変化したりするので、モデルは時間とともに変化しなければならないが、変化の度に学習データをアノテーションし直すことは非現実的である。従って、システムを箱から出したら黙々と情報を収集し、アノテーションを必要としない教師なし学習を用いて行動

モデルを学習しつつ、環境や行動の変化に追従して自動的にモデルを変化させる必要がある。

あらかじめ想定する日常行動を分類する行動識別 [Krishnan 12] に対して、教師信号を用いずに、データだけから未知の行動を同定することを文献 [Cook 13] では**行動発見**と呼んでいる。現実のスマートホームデータは多種多様な行動を含んでおり、著者らのデータでは、あらかじめ想定した行動に属すセンサーイベントの割合は42%に過ぎず、半分以上のイベントは想定していない行動に関するイベントであった。従って、想定した行動のモデルだけを使って、実際のスマートホームデータを分析すると、大量の誤検出が発生し識別精度を著しく劣化させてしまう。この問題に対処するために、著者らは、データ圧縮率を高めるような頻出パターンを見つけ、得られたパターンを新たな行動ラベルとして用いてモデルを学習することで、識別精度の低下を抑えることができることを報告している。

本研究でも行動発見を行うが、食事、睡眠、調理などの粒度の生活行動を発見することは意図していない。その理由は、生活環境や行動様式の多様性を汎化して、限られたデータだけからこのレベルの行動のモデルを学習することは困難であると考えからである。その代わりに、居住環境や居住者に特化して、それら行動毎に特徴的に現れる**行動素**と呼ぶセンサーイベント系列の部分系列を抽出することを目指している。行動素は、行動のアノテーションが得られる場合には行動識別に寄与するであろうし、そのようなアノテーションが得られない場合であっても、異常な行動の検出や行動の検索等に有用であることが期待できる。

行動素の同定は、センサーイベントの系列を教師信号なしで分割することで行う。日常行動はセンサーイベントの部分系列で特徴づけられると考えられるため、この分割はイベントの部分系列の分布に基づく類似性を用いて計算される。ただし、特徴的な部分系列の途中に無関係な他のセンサーの発火が割り込むことも考えられるし、あるセンサーの代わりに近接する他のセンサーが発火するという状況も考えられる。このような、不連続な部分系列や、センサー間の近さを考慮しつつ、イベン

```

...
2010-11-04 11:41:04.390763 M020 ON
2010-11-04 11:41:04.955255 M018 OFF
2010-11-04 11:41:10.38084 M011 ON
2010-11-04 11:41:11.940985 D001 OPEN
2010-11-04 11:41:12.320499 M020 OFF
2010-11-04 11:41:15.201665 D001 CLOSE
2010-11-04 11:41:17.062821 M011 OFF
...

```

図 1: CASAS Aruba データセット (抜粋)

ト系列間の類似性を効率よく計算する目的で、文字列カーネル [Lodhi 02] を用いていることが本研究の特徴である。このようにして得られた分割のうち、類似した分割が高頻度に現れるようなものが行動素として抽出される。

本稿は、以下のように構成される。まず、次節で、本研究で用いるデータとその前処理の方法について説明する。続く 3. 節では、行動素の抽出アルゴリズムについて説明する。次の 4. 節で、抽出した行動素の有用性を調べるために、行動識別実験を行い、行動素という新たな素性が行動識別に寄与するか否かを検討する。

2. スマートホームデータ

本稿では、ワシントン州立大学の CASAS プロジェクト [Cook 13] で公開しているスマートホームデータレポジトリの内、Aruba データセット [Cook 12] を用いた評価実験の結果を報告する。Aruba データセットは、2010 年 11 月 4 日から 2011 年 6 月 11 日のおよそ 7 か月間にわたり、3LDK の居室で暮らす独居高齢者の生活を、居室に設置したモーションセンサー、ドア開閉センサー、温度センサーを用いてモニタリングしたデータである。モーションセンサーは、合計 31 個の焦電センサーを用いており、1 部屋に 1 つ程度設置して部屋に人がいるかないかを測定する通常の利用法とは異なり、感知範囲を狭めた焦電センサーを 1 部屋に平均 8 個程設置し、部屋内のおおまかな動線も取得可能になっている。ドアセンサーは、玄関、勝手口、ガレージへのドアの 3 か所に設置され、ドアの開・閉を検知できる。温度センサーは居室にはほぼ 1 つずつ合計 5 個設置されているが、本稿での評価には用いていない。このデータには、図 1 のように、モーションセンサーが動きを検知した時刻と検知しなくなった時刻、ドアが開いた時刻と閉じた時刻が記録されている。以降、モーションセンサーが動作を検知している状態とドアが開いている状態を各センサーが発火していると言うことにする。

このようなデータに基づいて日常行動を分析する際には、センサーが発火しているという情報だけでなく、センサーが発火していないという情報も活用するために、時間窓(フレームと呼ぶ)を一定時間で動かし、各フレームの中で発火しているセンサーを記述することにする。もし、フレーム内でどのセンサーも発火していないときには特別な記号“0”を記述する。フレームの幅は 30 秒とし、このフレームを 10 秒間隔で動かすことにする。図 2 は、このようにして元データを前処理し、1 フレーム 1 行で表したデータの一部を示している。各行の 1-2 カラム目はフレーム開始・終了時刻が実験開始からの秒数で表されており、3 カラム目以降が、各フレームで発火中のセンサーを表している。例えば、ドアセンサー“D001”は“63”という

```

...
42050.0 42080.0 33 33 31 33 17 21 63 21 21
42060.0 42090.0 33 31 33 17 21 63 21 21 17 17 15 43
42070.0 42100.0 17 21 63 21 21 17 17 15 43 55 57
42080.0 42110.0 21 17 17 15 43 55 57
42090.0 42120.0 43 55 57
42100.0 42130.0 55 57
42110.0 42140.0 0
...

```

図 2: 前処理を行ったデータ (抜粋)

番号が割り当てられており、1 番目のフレームから 3 番目のフレームにわたって発火していることが分かる。また、1 つのフレームに同じ番号が複数現れている場合は、フレームの開始時刻から終了時刻の間に、そのセンサーが複数回オン・オフを繰り返したことを表している。

3. 行動素の抽出

本研究では、こうしたフレームの列を教師信号なしに分節し、日常行動分析のために意味のあるフレームの部分列(行動素と呼ぶ)の抽出を目指す。特定の日常行動には特徴的なセンサーの部分発火系列が含まれているので、行動素の抽出には、部分発火系列の分析が有効と考えられる。その際、行動の変動やセンサーの配置によって、行動に無関係なセンサーの発火が途中で割り込む可能性があるため、不連続な部分系列を考える必要がある。また、特徴的な部分系列には、特定のセンサーだけではなく、近接する 1 群のセンサー集合が関与すると考えられるので、センサーの近接性を反映した、部分系列の類似性を考慮する必要があるかもしれない。

このような符号の部分列の類似性に基づいて符号列を分節するアルゴリズムとして、文献 [Sadohara 10] で提案されているトピック分割アルゴリズムが知られている。このアルゴリズムは、音素列として認識された会議音声をもトピック毎に分割するために、トピックに特徴的な部分音素列の分布を手がかりとしている。具体的には、音素列から成る各フレーム f_i 毎に、不連続なものも許容した任意の部分音素列の頻度を成分とする特徴ベクトル \mathbf{f}_i を考え、幾つかの前処理の後に、ノルム最大化原理

$$S^* = \operatorname{argmax}_{S=\{s_1, \dots, s_m\}} \sum_{k=1}^m \|\mathbf{s}_k\|^2 \quad (1)$$

に基づいてフレーム列の分割 S^* を得る。ここで、フレームの部分列 $\mathbf{s}_k = f_{k,1} \dots f_{k,\ell_k}$ の特徴ベクトル \mathbf{s}_k は、各フレームの特徴ベクトルの和 $\sum_{j=1}^{\ell_k} \mathbf{f}_{k,j}$ とし、 $\|\mathbf{s}\|$ はユークリッドノルム $\langle \mathbf{s}, \mathbf{s} \rangle^{1/2}$ とする。ノルム最大化原理の下では、部分音素列の分布が類似した特徴ベクトルの和をとろうとするバイアスが働くので、単語の分布が類似したフレーム列を 1 つのブロックとするようなトピック分割が得られる。ただし、長さ ℓ の音素列に含まれる長さ p の部分列は ℓC_p 個存在するので、特徴ベクトルを陽に計算することは計算コストが大きい。幸い、ノルムの計算には特徴ベクトルの内積が計算できれば十分で、音素列 u, v の特徴ベクトルの内積 $\langle \mathbf{u}, \mathbf{v} \rangle$ は、文字列カーネル [Lodhi 02] を用いると $O(p|u||v|)$ で計算できることが知られている。ここで、 $|u|$ は文字列 u の文字数を表す。

本研究でも、音素列の代わりにセンサー発火系列を分節する目的で同様のアルゴリズムを用いる。ただし、既に有用な行動素が分かっている場合には、これら行動素に類似した分節を偏好するようにアルゴリズムを拡張する。具体的には、行動素 b_1, \dots, b_m が与えられるとき、ノルム最大化原理 (1) において、 $\|s_k\|^2$ の代わりに、

$$\operatorname{argmax}_{1 \leq j \leq m} \|P(s_k) b_j\|^2 \quad (2)$$

の和の最大化を行う。ここで、 $P(s) b$ は、 s の b への射影であり、

$$\|P(s) b\|^2 = \frac{\langle s \cdot b \rangle^2}{\langle b \cdot b \rangle}$$

のように特徴ベクトルの内積を用いて計算できるので、文字列カーネルを用いることで特徴ベクトルを陽に計算することなく効率良くフレーム列の最適分節を計算することができる。

このような分節アルゴリズムを 1 日分のデータ毎に適用して以下のように行動素の集合 B を抽出する。

1. $B \leftarrow \{b_1, \dots, b_m\}$, b_j は、初日のデータ中のフレーム
2. $c(b_j) = 1$, ($1 \leq j \leq m$).
3. 1 日分のデータ毎に以下を繰り返す。
 - B を用いてフレーム列を分節。
 - 式 (2) で選択された b_j に対して $c(b_j) \leftarrow c(b_j) + 1$.
 - $c(b_j)$ が大きい順に N 個選び新たな B とする。

以降の実験では、2011 年 11 月のデータを用い、 $N = 1,024$ として行動素の抽出を行い、最終的に 2 度以上選択された行動素 624 個を抽出した。

4. 行動素の効用

抽出された行動素が日常行動の分析に有用であるかどうかを検証するために、日常行動の識別問題を考える。

4.1 行動識別問題

Aruba データセットには、睡眠、食事、食事の準備、外出、帰宅、仕事等の 11 の行動ラベルが付与されている。学習データからこれら行動ラベルを予測するモデルを学習し、評価データのラベルを予測する評価実験を行った。学習データは 2011 年 11 月のデータから、ラベリングが不安定な最初の 1 週間を除いたものを用い、評価データは 2011 年 12 月のデータを用いた。

予備実験として、単純ベイズ識別器を用いた文書分類と同様の方法で日常行動識別を行った。この実験では、識別対象のフレーム列 s を文書、各フレームを文、フレームに現れるセンサーの発火を単語 w とみなし、

$$C^* = \operatorname{argmax}_C P(C) * \prod_{w \in s} P(w|C)$$

のように最適な行動ラベル C^* を選択する。 w としては、単語 uni-gram の他、bi-gram, tri-gram をあわせて検討した。 $P(w|C)$ は学習データから推定するが、ゼロ頻度問題に対処するために、

$$P(w|C) = \frac{1 + \operatorname{occ}(w, C)}{|\Theta| + \sum_{w \in \Theta} \operatorname{occ}(w, C)}$$

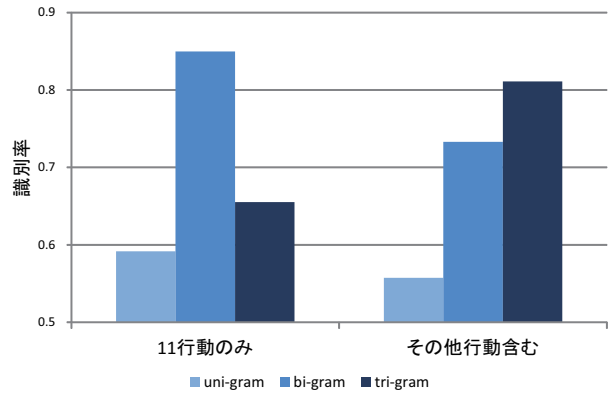


図 3: N-gram 素性を用いた単純ベイズ法による日常行動識別

を用いる。ただし、 $\operatorname{occ}(w, C)$ は、ラベル C が付与されたフレームにおける w の出現頻度を表し、 Θ は素性の集合を表す。

図 3 は、予備実験の結果である。この図から、uni-gram 素性よりも bi-gram 素性の方が有効である一方、tri-gram になると 11 行動の識別性能が劣化することが分かる。これは、ノイズにより各行動を特徴づける tri-gram 素性が正確に再現される確率が減り、事前確率の大きなその他行動に識別が引きずられるため、11 行動識別の再現率が低下することに起因する。

4.2 行動素を用いた識別

ノイズにより tri-gram が正確に再現しない問題は、行動素を用いることで対処可能であると考えられる。文字列カーネルにおいて考慮する部分文字列の最大長を $p = 4$ とすると、長さ 4 までの発火系列を考慮できる。しかも、不連続な部分文字列を考慮できるので、途中に無関係なセンサーが割り込んだ場合でも、部分文字列の識別への寄与が分析可能である。さらに、センサーの近接度を反映した部分文字列の類似性を考慮することも可能であるが、本稿で述べる実験では用いておらず、字面が異なる部分文字列の頻度はカウントしない。

行動素を行動識別に利用する方法は、まず、行動素 $B = \{b_1, \dots, b_M\}$ が与えられるとき、識別対象のフレーム列 s の b_j 毎の成分を計算する。この成分は、 s の特徴ベクトルと b_j の特徴ベクトルとの余弦 s_{b_j}

$$s_{b_j} = \frac{\langle s \cdot b_j \rangle}{\langle s \cdot s \rangle^{1/2} \langle b_j \cdot b_j \rangle^{1/2}}$$

とするが、ここでも文字列カーネルを用いることができる。さらに、成分毎の確率分布 $P(s_{b_j}|C)$ を計算するために、ビン数 10 で離散化する。

このような確率分布に基づいて、

$$C^* = \operatorname{argmax}_C P(C) * \prod_{1 \leq j \leq M} P(s_{b_j}|C)$$

のように、 s の行動ラベル C^* を予測する。また、bi-gram 素性と組み合わせる場合は、

$$C^* = \operatorname{argmax}_C P(C) * \left(\prod_{w \in s} P(w|C) \right) \left(\prod_{1 \leq j \leq M} P(s_{b_j}|C) \right)$$

を用いる。

図 4 は、行動素を用いた識別と、行動素に加えて bi-gram 素性を用いた識別の結果を示している。行動素のみを用いる場合、




図 4: 行動素を用いた日常行動識別

11 行動の識別において bi-gram 素性と有意差はないが、その他行動を含めると有意に識別能力が向上する。また、bi-gram 素性に行動素を加えて識別する場合には、11 行動でも有意な識別性能向上が見られた。なお、識別率の有意差の検定には、McNemar 検定を有意水準 1% で用いた。この結果から、行動素が日常行動識別に有効な素性であること、特に、想定している行動以外の日常行動の特徴を教師信号なしで抽出できていることが分かる。

5. おわりに

スマートホームセンシングデータから日常行動に特徴的な、行動素と呼ばれるデータの部分系列を教師なし学習を用いて抽出するアルゴリズムを提案した。さらに、抽出された行動素を日常行動識別問題に適用して、その有用性を確認した。得られた行動素は、想定された日常行動の識別に有用であるだけでなく、あらかじめ想定されていない(し得ない)多様な日常行動の識別にも有効であることが確認された。このような想定されていない行動は、スマートホームセンシングデータのかなり大きな割合を占めるので、行動素は日常行動識別精度向上に貢献できる。さらに、想定し得る行動であっても、データをアンテーションするコストが許容できない場合も多いので、教師なし学習で得られる行動素は、より導入コストが低い現実的な日常行動分析のための有用な素性となり得る。

今後の課題としては、センサーの近接性を考慮した行動素抽出アルゴリズムや生活環境や行動様式の時間変化に追従するアルゴリズムの開発を行わねばならない。また、生活環境や行動様式の異なる多様なセンシングデータを実際に収集して、本手法の適用可能性を検証することも今後の課題である。

謝辞

本研究の一部は、科研費基盤研究(B)「音響的状況認識に基づく高齢者見守り技術の研究開発」(22300203)の支援を受けて実施した。

参考文献

[Cook 12] Cook, D.: Learning setting-generalized activity models for smart spaces, *IEEE Intelligent Systems*, Vol. 27, No. 1, pp. 32–38 (2012)

[Cook 13] Cook, D., Crandall, A., Thomas, B., and Krishnan, N.: CASAS: A smart home in a box, *IEEE Computer*, Vol. 46, No. 6, pp. 26–33 (2013)

[Cook 13] Cook, D., Krishnan, N., and Rashidi, P.: Activity discovery and activity recognition: A new partnership, *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, Vol. 43, No. 3, pp. 820–828 (2013)

[Intille 06] Intille, S., Larson, K., Tapia, E.M., Beaudin, J., Kaushik, P., Nawyn, J., and Rockinson, R.: Using a live-in laboratory for ubiquitous computing research, in *Pervasive Computing*, pp. 349–365 (2006)

[Kidd 99] Kidd, C.D., Orr, R.J., Abowd, G.D., Atkeson, C.G., Essa, I.A., MacIntyre, B., Mynatt, E., Starner, T.E., and Newstetter, W.: The aware home: a living laboratory for ubiquitous computing research, in *Proc. of Workshop on Cooperative Buildings* (1999)

[Krishnan 12] Krishnan, N.C. and Cook, D.: Activity recognition on streaming sensor data, *Pervasive and Mobile Computing* (2012)

[Kröse 08] Kröse, B.J., Kasteren, T.V., Gibson, C., and Dool, T.V.D.: CARE: Context awareness in residences for elderly, in *Proc. of Internat. Society for Gerontechnology* (2008)

[Lodhi 02] Lodhi, H., Saunders, C., Shawe-Taylor, J., Cristianini, N. and Watkins, C.: Text classification using string kernels, *Journal of Machine Learning Research*, Vol. 2, pp. 419–444 (2002)

[Mori 09] Mori, T., Urushibara, R., Shimosaka, M., Sato, T., Fjii, A., Kubo, H., Oshima, K. and Noguchi, H.: Sensing room and its resident behavior mining, In *Proc. of Workshop on Developing Shared Home Behavior Datasets to Advance HCI and Ubiquitous Computing Research*, pp. 1–4 (2009)

[Sadohara 10] Sadohara, K.: Kernel topic segmentation for informal multi-party meetings and performance degradation caused by insufficient lexicon, in *Proc. of Spoken Language Technology*, pp. 430–435 (2010)

[厚生労働省 12] 厚生労働省: 平成 24 年国民生活基礎調査, <http://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa12/>, (2012)

[下坂 10] 下坂 正倫, 佐藤 知正, 森 武俊: 焦電型活動量センサーからの時変パワゾン過程に基づく生活パターンモデリング, 人工知能学会全国大会予稿集 (2010)

[白石 09] 白石 康星, 西田 佳史, 本村 陽一: 大量ライフログデータとベイジアンネットワークを用いた日常生活行動因果分析, デジタルヒューマン・シンポジウム予稿集, (2009)

[松岡 05] 松岡 克典: 住宅内での日常生活行動の理解技術 — 暮らし情報を用いた見守り型生活サービス創出に向けて, システム制御情報学会誌, Vol. 49, No. 5, pp. 193–197 (2005)

[美濃 05] 美濃 導彦: ユビキタスホームにおける生活支援, 人工知能学会誌, Vol. 20, No. 5, pp. 579–586 (2005)

[本村 09] 本村 陽一, 西田 佳史: 計算論的日常行動理解研究の展開: 人工知能学会全国大会予稿集 (2008)