

ベイジアンネットワークと行動生起確率による 行動認識方法の提案とその評価

竹中 一秀^{*1}, 撫中 達司^{*2}

Proposal and Evaluation of Life Activity Recognition Method based on a Bayesian Network with Activity Occurrence Probability

by

Kazuhide TAKENAKA^{*1} and Tatsuji MUNAKA^{*2}

(received on Mar. 23, 2020 & accepted on Jun. 8, 2020)

あらまし

認知症患者の増加は大きな社会問題となりつつあるが、初期段階であれば薬の投与により症状進行の遅延が可能であり、早期発見が重要となる。認知症の発症は、同居者が生活の変化により気づくことが多いが、一人住まいの高齢者の場合、その発見は非常に困難となる。本研究は、高齢者の日常生活動作の変化を発見するための行動認識を目的とする。まず、センサデータによってモデル化されたベイジアンネットワークにより行動の候補を推定する。次に、前後の行動の関連性の強さを表現した行動生起確率を用いて行動を特定する。本稿では、ハイブリッド型の行動認識方法の提案と、その評価結果について報告する。

Abstract

The increase in dementia is becoming a social problem. However, early detection is essential because the administration of drugs can delay the progression of symptoms in the early stages. It is often found when a cohabitant notices a change in daily life. However, it is difficult for elderly people who live alone. The purpose of this study is to detect the change by monitoring the daily life of the elderly. We firstly recognize activities by the Bayesian network modeled by collected sensor data. Then, an activity is identified using the activity occurrence probability calculated by daily life. In this paper, we propose the method and show the evaluation results.

キーワード: 認知症の早期発見, ベイジアンネットワーク, オントロジー, 行動生起確率表

Keywords: Early detection of dementia, Bayesian networks, Ontology-based modeling, Activity occurrence probability

1. はじめに

近年、日本の認知症患者は増加傾向にある。2025年には700万人に達すると言われており、65歳以上の人口の約20%になると予想されている¹⁾。認知症は初期の段階であれば薬の投与により症状の進行を遅らせることが可能であり、このため早期発見が重要になる。早期発見のためには、認知症の発症により生じる生活の変化を検知することが重要である。高齢者の身体能力や日常生活レベルを測るための重要な指標としてADL(Activities of Daily Living)とIADL(instrumental ADL)がある。ADLは日常生活における基本的な「食事、更衣、排泄、入浴、起立」などの動作のことを指す。またIADLはADLよりも高い自律した日常生活をするための動作であり、「料理・掃除・買い物などの家事、交通機関の利用、電話対応などのコミュニケーション、趣味」などの複雑な日常生活動作のことを指す。この2つの指標となる生活行動を認識し、評価することは高齢者の生活を見守る上で重要とされている^{2,3)}。例えば、認知症の症状である物忘れの影響で食事の回数が増えるといったケースである。規則正しく日に3回食事を取っていた高齢者が、認知症による物忘れが進み、食事をしたことを忘れることで

食事の回数が増える。本稿ではADLとIADLを対象とした行動認識手段として、日々の生活のセンサデータによってモデル化されたベイジアンネットワークにより行動の候補を推定し、前後の行動の関連性の強さを表現した行動生起確率を用いて、行動の特定を行う方法を提案し、その評価結果につき報告する。

2. 先行研究

Rafferty⁴⁾らは、行動認識手法のアプローチをData driven approachesとKnowledge driven approachesに大別している。Data driven approachesは、Generative approachesとDiscriminative approachesに分類される。Generative approachesは、収集したデータを用いてモデルを作成する方法であり⁵⁻⁹⁾、代表的なものとしてベイジアンネットワークやHMM(Hidden Markov Model)がある。Discriminative approachesは、収集したデータにラベルを付け、識別対象を分類する方法であり¹⁰⁻¹³⁾、代表的なものとしてSVM(Support Vector Machine)やK-NN(K-nearest neighbor algorithm)などがある。

一方、Knowledge driven approachesはLogical based approachesとOntological approachesに分類されており、Logical based approachesはドメインの知識を収集して、行動とそのパフォーマンスを論理表現した知識モデルを定義する。推論アルゴリズムにより、事象を知識モデルにマッピングし、発生する行動を判断する。実現方法として、主にEvent Calculus等の手法が使用される。

*1 情報通信学研究科

Graduate School of Information and Telecommunication Engineering

*2 情報通信学研究科 教授

Graduate School of Information and Telecommunication Engineering, Professor




Fig. 1 Activity Recognition Approaches




Fig. 2 Example of an ontology model for an elderly person

Ontological approaches はドメインの知識を収集して、行動を概念とクラスの階層に構造化する。概念とクラスにはプロパティ、関係、制限事項を設定することができるため、推論と知識抽出が可能である。オントロジーの利点は、行動表現（ルール）の再利用が可能なことであり、Logical based approaches のように厳格な行動表現を用いることにより直面する柔軟性の問題を解決することができる。一方で、不確実性の表現や個人化を提供する比較的厳格なモデリングは難しい (Fig. 1)。

ここで、オントロジーとは「概念化の仕様」として提唱されたデータの表現方法の1つである¹⁴⁾。独立したデータ間の関係をグラフ構造で明らかにすることにより、コンピュータがデータを知識として解釈し、より高度に活用することを実現する。例えば Fig. 2①の様に[人間: Aさん]のサブクラスとして[介護: Aさん]と[病院: Aさん]を紐づけると、それぞれが独立したドメインである介護施設と病院それぞれで管理していた入浴、食事のデータや診察のデータを同一人物のデータであると意味的に表現することができる。また、これにより②の様に診察において食事に関するデータを参照(共有)するといった活用が可能になる。W3CではWeb上でのデータの活用を目的として、オントロジーを記述する為のフレームワーク RDF(Resource Description Framework)¹⁵⁾やRDFで用いる用語や関係を定義したOWL(Web Ontology Language)¹⁶⁾を規格化している。これらは具体的にRDF/XMLやTurtleといった形式で記述され、その処理系としてPythonではRDFLib¹⁷⁾、JavaではApache Jena¹⁸⁾などが提供されている。

行動のオントロジー構築に関する研究として、中村ら¹⁹⁾はライフログサービス向けに高次行動を抽出する基盤の構築を目的として、低次行動や環境音、場所など様々な情報の組合せを高次行動として紐づけ記述するオントロジーを定義している。例えば、“映画を見ている”という高次行動は、低次行動として“座っている”、環境音として“音楽が流れている”、場所として“映画館にいる”という情報と紐付けることで表現される (Fig. 3)。しかし、この場合“映画を見ている”という高次行動は、“寝ながら、立ちながら、




Fig. 3 Example of an ontology model for extracting activities




Fig. 4 Activity Recognition method using a Bayesian network

歩きながら”など様々な状況が想定され、また自宅にいらなくても行えるため必ずしも場所を“映画館”と限定することはできず、高次行動を表現するための低次行動の組合せは、個々の利用者に依存して無数に存在することから実用的なオントロジーを構築するには、その目的に応じて低次行動の組合せの定義を行う必要がある。中村らは、対象者の限定、あるいはADLやIADLなどの行動の限定をしておらず、また概念の提案のみであり、オントロジーの構築までは至っていない。

Wuら²⁰⁾は、スマートホームシステムがユーザを支援するためにどのようなサービスを提供するべきかという問題に対して、ユーザの行動を把握することを目的としてGenerative approachesのベイジアンネットワークを用いた行動認識に取り組んでいる。この方法では、「ある行動の後の行動」、「範囲時間内での行動」、「曜日内での行動」の確率をそれぞれ算出し、それらを条件付確率として用いて3つのベイジアンネットワークを作成する。それぞれに発生する確率が高い行動を抽出し、その結果を合算して、数多く示された行動を選択する (Fig. 4)。評価実験ではCASAS(Center for Advanced Studies in Adaptive Systems)プロジェクト²¹⁾のデータセットを用いて、「日(曜日)」、「時刻」、「場所」の3つのパラメータを追加してモデル構築を行い、ある行動の次に起こる行動の予測において認識率81.3%を達成している。この手法の課題として、記録された情報「日(曜日)」、「時刻」、「場所」が類似する行動、あるいは前後に発生する行動の関係性がなく、習慣として表現できない行動は判別が難しいことがあげられる。例えば、TVを見るという行動は前後に発生する行動とは関連性が少なく、また個人によって発生する日(曜日)、時刻が異なるという特性を持つ。Wuらの結果は、Rafferty⁴⁾らが示している、センサデータを用いた行動認識であるData driven approaches

Table 1 Examples of activities having similar recorded information

	時刻	時間	曜日	場所	月
テレビ視聴	12:00	30分	日	リビング	10月
食事	12:00	30分	日	リビング	11月




Fig. 5 Overview of the proposed method

だけではある程度以上の認識が難しいという指摘に合致した結果となっている。

本研究では、Data driven approaches としてベイジアンネットワークを用い、その結果に対して Knowledge driven approaches として行動間の関係性を数値化した行動生起確率を適用するハイブリッド型の認識方法につき提案する。

3. ベイジアンネットワークと生活行動習慣(行動生起確率)を組合せた行動認識方法

3.1 提案方法の概要

本研究の提案方法では、まず Data driven approaches の一つであるベイジアンネットワークを用いて、発生した可能性が高いと推定される行動の候補を挙げる。次に Knowledge driven approaches である行動の習慣を表現した行動生起確率を用いて、複数の候補の中から行動を特定する (Fig. 5)。例えば、音、加速度などのセンサを用いて収集されたデータを用いてモデル化されたベイジアンネットワークによって「食事をする」、「テレビを見る」という2つの候補が抽出されたとする。この際、「料理した後はすぐに食事をする」という対象者の生活行動習慣を表現した行動生起確率を用いれば、「料理した」後に高い確率で現れる「食事をする」が特定可能となり (Fig. 6, Fig. 7)、行動認識の精度を高めることが期待できる。

3.2 ベイジアンネットワークによる行動認証

「年」、「季節」、「曜日」、「時間」、「時刻」、「場所」、「行動」の情報を持つデータセットを用いて、ベイジアンネットワークを構築し、同じデータセットを入力データとして用いて行動の起こる確率を求め、実験の結果設定した閾値 30%を超えた行動を候補とする。

3.3 日常生活行動のオントロジー

日常生活の行動の習慣を知識とするために、まずは生活において習慣として行なわれる行動をオントロジーとして表現した。公開された生活行動のオントロジーが存在せず、このため本評価では手作業で日常生活行動のオントロジーを作成した。まず ADL に定義されている主要な行動、例え




Fig. 6 Activity recognition method based on personal habits




Fig. 7 Activity Occurrence Probability of ontology model

食事	食事	食事	食事	食事	食事
目的	食事	目的	食事をする	目的	洗い物
行為	調理	行為	食事	行為	食器を洗う
前の行為	調理	前の行為	調理、用意	前の行為	食事
後の行為	食事	後の行為	洗い物、歯磨き、排便	後の行為	—
時間	朝、昼、夜	時間	朝、昼、夜	時間	—
場所	キッチン	場所	食卓	場所	キッチン
①冷蔵庫から食材を取り出す		料理を食べる		①水を出す	
目的	食事	目的	食事をする	目的	食事
行為	調理	行為	作業	行為	食器を洗う
作業	①冷蔵庫から食材を取り出す	時間	朝、昼、夜	作業	水を出す
時間	朝、昼、夜	場所	食卓	時間	—
場所	キッチン			場所	キッチン

Fig. 8 Example of an ontology description of daily activities

ば「食事」を階層構造のルートに配置し、その行動の前後に発生する行動となる「調理」、「食事をする」、「洗い物」などを階層化して詳細化した (Fig. 8)。作成に際しては、農作業に関する幅広い知識を持つ農作業オントロジー AAO (Agriculture Activity Ontology)²²⁾を参考とした。AAO は AGROVOC と呼ばれる農林水産、食糧、環境などの専門用語を 32,000 語以上網羅する世界標準のシソーラスデータや内閣府が農作物名称の標準化のために提案したガイドラインをもとに語彙の追加や階層構造の修正を施し構築されたオントロジーである。

3.4 行動生起確率による行動認証

行動生起確率は、一般的な知識として作成したオントロジーから行動の発生順序を抽出し、後述する CASAS のデータセットに記録された行動順序に基づき求めた。行動生起確率は、発生した行動の次に発生する行動の確率を示しており、行動間の関係性の強さを表現したものになる (Fig. 7)。

オントロジーに対応する「全体」の表は過去に行われた行動が記録されているデータセットのすべてを範囲として行動の生起確率を算出した。「時間」の表は一定時間ごとに、「曜日」の表は曜日ごとに行動の生起確率を算出し、それをまとめたものである。Table 2 は CASAS のデータセットすべてを用いて作成した全体の行動生起確率表である。

Table 2 Activity Occurrence Probability Table calculated by CASAS data set

後に起きる可能性のある生活行動

	Bathing	Bed_Toile	Eating	Enter_Hor	Leave_Ho	Meal_Pre	Personal	R1_Sleepi	R2_Sleepi	Wash_Dis	Watch_TV	Work_Bed	Work_Bed	Work_Livi	Work_Tab	Yoga	横合計
Bathing	2.487562	0	5.472637	0	2.487562	5.472637	36.81592	3.482587	1.492537	0	2.985075	5.472637	31.34328	1.492537	0.497512	0.497512	100
Bed_Toile	5.960265	32.45033	3.311258	0	0	7.284768	34.43709	1.986755	0	0.662252	0.662252	11.92053	0.662252	0	0.662252	0	100
Eating	2.985075	0.895522	0.597015	0.298507	5.970149	2.985075	18.80597	0.298507	0	5.970149	12.53731	3.58209	11.64179	20	12.83582	0.597015	100
Enter_Hor	0.917431	0	1.834862	1.834862	1.834862	13.76147	23.85321	0.917431	0	0	11.92661	5.504587	11.00917	12.84404	13.76147	0	100
Leave_Ho	0.877193	0	0	92.10526	0.877193	0	0	0.877193	0.877193	0	0.877193	0.877193	1.754386	0	0.877193	0	100
Meal_Pre	1.36612	0	31.96721	0	0.819672	1.36612	11.20219	0.273224	0	0	7.103825	9.562842	8.469945	16.66667	10.92896	0.273224	100
Personal	5.39484	0.156372	5.00909	0	1.79828	6.645817	24.62862	4.612979	1.016419	1.094605	1.954652	8.9914	29.47615	4.691165	4.222048	0.312744	100
R1_Sleepi	0.729927	0.729927	0	0.729927	0	0.729927	8.029197	0	66.42336	0	0.729927	0.729927	21.16788	0	0	0	100
R2_Sleepi	1.526718	71.75573	0	0	0	1.526718	19.84733	1.526718	0	0	0	0	3.816794	0	0	0	100
Wash_Dis	2.816901	0	0	0	1.408451	2.816901	21.12676	0	0	0	8.450704	5.633803	9.859155	2.816901	45.07042	0	100
Watch_TV	0.938967	0	13.61502	0	3.755869	15.49296	18.30986	1.408451	0.469484	2.347418	0.938967	3.286385	22.06573	1.877934	15.49296	0	100
Work_Bed	1.221996	0	2.03666	0	1.221996	4.887984	25.05092	2.443992	0.203666	0.610998	1.832994	12.42363	36.65988	3.665988	7.739308	0	100
Work_Bed	5.998357	0.164339	3.204601	0	1.396878	4.437141	29.58094	3.697617	1.643385	0.575185	2.711586	13.31142	24.65078	3.122432	5.423172	0.082169	100
Work_Livi	0.905797	0	8.152174	0	2.173913	10.68841	11.41304	0	0	0.543478	4.166667	3.985507	5.072464	37.5	15.03623	0.362319	100
Work_Tab	1.49925	0	1.649175	0	2.548726	7.796102	10.34483	0.149925	0.149925	2.848576	3.298351	7.946027	11.54423	10.94453	39.13043	0.149925	100
Yoga	0	0	0	0	0	15.38462	15.38462	0	0	0	23.07692	0	15.38462	30.76923	0	0	100

Table 2 の実線○で囲った部分は、「Meal_Preparation」の後に発生する「Eating」の確率が約 32%であることを示している。行動生起確率による行動認証は、ベイジアンネットワークにより推定された複数の候補の直前行動との関係性が強い、すなわち行動生起確率の高い行動を選択する。

4. 実験結果と考察

4.1 実験に用いるデータセットとソフトウェア

データセットはワシントン州立大学の CASAS プロジェクト²¹⁾のものを使用した。ベイジアンネットワーク構築はニュージーランドのワイカト大学で開発されたソフトウェアである Weka²³⁾を用いた。CASAS プロジェクトのデータセットには R1, R2 と記載された 2 名が大学内の評価施設に実際に 6 ヶ月間生活した際のデータが記録されており、日付、時刻、センサ名、センサ値、行動ラベル、行動状態 (begin・end) が含まれている。記録された行動ラベルは Table 3 に示す 16 種類である。なお、2 名の行動の区別ができるのは決められたベッドを使用した場合のみであり、その他の行動は区別ができない。データセットの中には、同じ行動が続けて記録されているが、これは異なる人物が順番に行ったのか、ある時間間隔をあけて同一人物が再度行ったのかは区別がつかない。先行研究²⁰⁾ではこの点について言及していないため、本評価でもデータセットに記録されたものを変更することなく使用することとした。

4.2 データセットの前処理

評価を行うために、データセットに記録された情報を「時刻」、「時間」、「場所」に変換する前処理を行った。行動状態が begin の時の時刻を行動が開始された「時刻」、行動状態が begin から end までを行動に要する「時間」とし、「時間」、「時刻」の単位は「秒」とする。また行動が行なわれた「場所」を特定するために、行動状態が begin の時に反応したセンサが設置されている位置を「場所」とした。データセットの情報から作成した行動ごとに要する「時間」の分布を確認した結果、極端に外れた値の存在を確認した。外れ値はモデルの信頼性を欠く要因となるため、これらを除く処理を行った。本評価では、箱ひげ図を用いて外れ値

Table 3 Activities recorded in the CASAS dataset

Bed_Toilet_Transition	Bathing
Eating	Wash_Dishes
Enter_Home	Watch_TV
Leave_Home	Work_BedRm_1
Meal_Preparation	Work_BedRm_2
Pesronal_Hygiene	Work_LivingRm
R1_Sleeping_in_Bed	Work_table
R2_Sleeping_in_Bed	Yoga




Fig. 9 The box-and-whisker plots of shape adjustment




Fig. 10 The box-and-whisker plots except outlier

を確認した。Fig. 9 は「整容」の箱ひげ図の結果である。青い四角で表された部分が、データを昇順で並べた時のデータ数 25%~75%の部分である。つまり、データの中央値付近の 50%が密集した部分であり、行動の傾向を示すのに有効的な部分となり、プロットされている点が外れ値となる。×印は平均時間を示すが、外れ値によって大きく偏っていることがわかる。この外れ値を除いた後の箱ひげ図 (Fig. 10)




Fig. 11 Result of the elbow method to determine the time-division




Fig. 12 Time-division considering time required for each activity

Table 4 Activities belonging to Time-division (sec)

区分	時間範囲	行動
区分1	18488-50000	R1_Sleeping_in_Bed, R2_Sleeping_in_Bed
区分2	4496-18487	WatchTV
区分3	1250-4495	WatchTV, Meal_Preparation, Yoga
区分4	240-1249	Bathing, Eating, Wash_dishes
区分5	135-239	Work_LivingRm, Work_BedRm1
区分6	13-134	Personal_Hygiene, Bed_Toilet_Transition, Work_Table, Work_BedRm2
区分7	0-12	Enter_home, Leave_home

では、×印で示された平均点と、有効的な部分を表す青四角が重なっており、データが一定の範囲に収まっていることが確認できる。外れ値を除去することにより「整容には約30～80秒を要する」といった行動に要する時間を把握することができる。

次に、データセット中では連続値で記録されている「時間」、「時刻」、「日付」をベイジアンネットワークで扱えるようにクラスタリングアルゴリズムを用いて離散化する。行動に要する時間は、「整容」の様に短いもので数秒、「睡眠」の様に長いもので数時間というように時間幅が広く、一定の時間単位で扱うことが難しい。そこで、行動の開始時刻と時間を組合せて2次元のデータとして表し、K-means法を用いてクラスタリングを試みた。例えば、2次元のデータとして(時刻, 時間)で表した時、(早, 短), (早, 長),




Fig. 13 A Bayesian network generated by Waka

(遅, 短), (遅, 長)の結果が得られる。ベイジアンネットワークに用いる場合、クラスタ数が多くなることにより、ノードの状態数が多くなり、適切なモデルとならない場合がある。K-means法はクラスタ数を決定する方法であり、各クラスタの時間や時刻の傾向を視覚的に把握することが容易であることからこの手法を選択した。クラスタ数を適切に設定するため、エルボー法を用いて最適なクラスタ数の評価を行った(Fig. 11)。エルボー法はデータポイントと重心の距離の2乗和(SSE; Sum of Square)をプロットした図であり、グラフがひじの様に曲がる箇所が最適クラスタ数になる。Fig. 11は、縦軸をSSE、横軸をクラスタ数としているが、クラスタ数が7付近で折れ曲がったグラフが収束しているのが確認できる。この結果から本評価ではクラスタ数を7に設定した。

全体の区分数をクラスタ数7とし、それぞれの行動に要する時間をCASASのデータセットから集計し、各行動の時間に合わせて「時間区分」を作成した(Fig. 12)。縦軸が時間(秒)、横軸が行動である。「R1_Sleeping in Bed」と「R2_Sleeping in Bed」が他の行動に比べて、行動に要する時間が非常に長いことが分かる。中でも、「R2_Sleeping in Bed」に要する時間が長いため、これを基準としてSleepingの時間区分を設定した。残りの行動についても同様に時間区分の処理を行った。結果として、すべての行動をその時間幅で分類し、整理したものをTable 4に示す。また、離散化した他のデータとして、「日付」の「月」の3～5月を春、6～8月を夏、9～11月を秋、12～2月を冬とする「季節」に変換し、「日」を対応する「曜日」に変換している。

4.3 ベイジアンネットワークの構築

前節で説明した前処理を行って作成したデータセットには「年」、「季節」、「曜日」、「時間」、「時刻」、「場所」、「行動」が記録されている。これらをノードとしてWakaを用いてベイジアンネットワークを構築した(Fig. 13)。構築の際、Wekaのパラメータは以下を用いた。

- Estimator : SimpleEstimator を使用。
SimpleEstimator はベイジアンネットワークの条件付き確率を推定するために使用され、データから直接確率の推定を行う方式であり、デフォルトに設定された方式である。
- SearchAlgorithm : K2 を使用。
ベイジアンネットワークの構造学習アルゴリズムは良

く知られている K2 アルゴリズムを使用した。K2 アルゴリズムは、あらかじめノード間に全順序関係を与え、その全順序関係の制約を用いて、あるノードに対する親ノードの組合せを探索する方法である。

- maxNrOfParents : 100 に設定。

あるノードの親となるノードの数。親の数に制限を持たせないため、ネットワーク内のノード数よりも十分大きい値として本評価では 100 に設定した。

4.4 ベイジアンネットワークによる行動候補の抽出

Fig. 14 は、場所、時刻、時間、日付（年、季節、曜日）を入力データとしたベイジアンネットワーク（Fig. 13）の結果の出力例を示したものである。この例では、「Eating」と「Watch_TV」が 50%前後の確率で発生すると推定されているが、結果としてベイジアンネットワークでは行動を特定するには至らず、この 2 つ行動が候補となる。なお、複数の候補が推定された場合、本評価では発生確率が 30%を超えた上位 2 つの行動を候補とすることとした。

4.5 ベイジアンネットワークによる行動認識の結果

構築したベイジアンネットワークに、CASAS のデータセットから離散化して作成した時刻、時間、場所、日付（年、季節、曜日）を入力データとして 16 の行動についての交差検証を行った（Fig. 15）。交差する箇所が正しく認証された行動の数を示しており、その他の箇所は誤認識した行動の数が記載されている。約 4,600 件の交差検証の結果、認識率は 89.9%であり、同じ CASAS のデータセットを使用している先行研究²⁰⁾の認識率 81.3%に比べて 8%程度向上している。しかし、時刻、時間、場所といった情報が類似している「d: Enter_Home」と「e: Leave_Home」は半分近く誤認識している（Fig. 15 実線○）。また、「c: Eating」についても、時刻、時間、場所が類似している「j: Watch_TV」や「n: Work_LivingRm」と誤認識している（Fig. 15 破線○）。この結果から、データセットで扱う時刻、時間、場所、日付などの行動に関するデータの前処理を行うことで、Data driven approaches の一つであるベイジアンネットワークによる行動認識率が向上したことは確認できたが、先行研究⁴⁾が示唆している Data driven approaches の課題である認識率の限界は依然として解決されていない結果となっている。

次に、ベイジアンネットワークの結果に対して、行動生起確率を適用する評価を行うが、その際には、各行動の発生数を同じにしておく必要があることから、以後の評価は、データセットの中から各行動についてランダムに 50 の行動を抜き出し、そのデータを用いた結果をもとに考察する。

4.6 行動生起確率表を適用した評価結果

Fig. 16 は、ランダムに選択した 50 の行動に対するベイジアンネットワークの交差検証結果を示したものである。誤認識の傾向などはデータセット全体を用いた交差検証結果である Fig. 15 と同様であることが確認できる。Fig. 17 は、ベイジアンネットワークの結果（Fig. 16）に対して、行動生起確率を適用した交差検証の結果を示している。「d: Enter_Home」、「e: Leave_Home」の認識率は、大きく改善されていることが確認できる（Fig. 17 実線○）。「d: Leave_Home」の後に発生する「e: Enter_Home」は、行動の順序性が明確で、かつ関係性が強いいため、行動生起確率




Fig. 14 Example of recognized activities by the Bayesian network

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  m  n  o  p  <-- classified as
190  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  a = Bathing
 145  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  b = Bed_Toilet_Transition
  0  0 212  0  0  0  0  0  0  0  0  0  0  0  0  0  c = Eating
  0  0  0 45 49  0  0  0  0  0  0  0  0  0  0  0  d = Enter_Home
  0  0  0 44 61  0  0  0  0  0  0  0  0  0  0  0  e = Leave_Home
  0  0  0  0  0 310  0  0  0  0  0  0  0  0  0  0  f = Meal_Preparation
  0  0  0  0  0  0 1059  0  0  0  0  0  0  0  0  0  g = Personal_Hygiene
  0  0  0  0  0  0  0 121  0  0  0  0  0  0  0  0  h = R1_Sleeping_in_Bed
  0  0  0  0  0  0  0  0 130  0  0  0  0  0  0  0  i = R2_Sleeping_in_Bed
  0  0  0  0  0  0  0  0  0 148  0  0  0  0  0  0  j = Watch_TV
  0  0  0  0  0  0  0  0  0  0 6  0  0  0  22  0  k = Wash_Dishes
  0  0  0  0  0  0  0  0  0  0  0 329  0  0  0  0  l = Work_Bedroom_1
  0  0  0  0  0  0  0  0  0  0  0  0 636  0  0  0  m = Work_Bedroom_2
  0  0  0  0  0  0  0  0  0  0  0  0  0 282  0  0  n = Work_LivingRm
  0  0  0  0  0  0  0  0  0  0  0  0  0  0 478  0  o = Work_Table
  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0 3  0  p = Yoga
  
```

Fig. 15 Confusion matrix using the Bayesian network with all activities recorded in CASAS data set

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  m  n  o  p  <-- classified as
50  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  a = Bathing
 0 50  0  0  0  0  0  0  0  0  0  0  0  0  0  0  b = Bed_Toilet_Transition
  0 0 32  0  0  0  0  0  0  0  0  0  0  0  0  0  c = Eating
  0  0  0 25 25  0  0  0  0  0  0  0  0  0  0  0  d = Enter_Home
  0  1  0 18 31  0  0  0  0  0  0  0  0  0  0  0  e = Leave_Home
  0  0  0  0  0 43  0  0  0  0  0  0  0  0  0  0  f = Meal_Preparation
  0  0  2  0  0  0 47  0  0  0  0  0  0  0  0  0  g = Personal_Hygiene
  0  0  0  0  0  0  0 48  0  0  0  0  0  0  0  0  h = R1_Sleeping_in_Bed
  0  0  0  0  0  0  0  0 50  0  0  0  0  0  0  0  i = R2_Sleeping_in_Bed
  0  0  0  0  0  0  0  0  0 39  0  0  0  0  0  0  j = Watch_TV
  0  0  0  0  0  0  0  0  0  0 4  0  0  0  0  0  k = Wash_Dishes
  0  0  0  0  0  0  0  0  0  0  0 35  0  0  0  0  l = Work_Bedroom_1
  1  0  3  0  0  0  0  0  0 13  0  0  0 32  0  0  m = Work_Bedroom_2
  0  0 13  0  0  0  0  0  0  0 9  0  0  0 28  0  n = Work_LivingRm
  0  0  0  0  0 16  0  0  0  0  0 2  0  0  0 32  o = Work_Table
  0  0  6  0  0  0  0  0  0  0  0 6  0  0  0  1  p = Yoga
  
```

Fig. 16 Confusion matrix using the Bayesian network with randomly selected activities recorded in CASA data set

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  j  k  l  m  n  o  p  <-- classified as
50  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  a = Bathing
 0 50  0  0  0  0  0  0  0  0  0  0  0  0  0  0  b = Bed_Toilet_Transition
  0 0 32  0  0  0  0  0  0  0 11  0  0  0  0  0  c = Eating
  0  0  0 50  0  0  0  0  0  0  0  0  0  0  0  0  d = Enter_Home
  0  0  0  0 50  0  0  0  0  0  0  0  0  0  0  0  e = Leave_Home
  0  0  0  0  0 44  0  0  0  0  0  0  0  0  0  0  f = Meal_Preparation
  0  0  2  0  0  0 47  0  0  0  0  0  0  0  0  0  g = Personal_Hygiene
  0  0  0  0  0  0  0 48  0  0  0  0  0  0  0  0  h = R1_Sleeping_in_Bed
  0  0  0  0  0  0  0  0 50  0  0  0  0  0  0  0  i = R2_Sleeping_in_Bed
  0  0  0  0  0  0  0  0  0 38  0  0  0  0  0  0  j = Watch_TV
  0  0  0  0  0  0  0  0  0  0 4  0  0  0  0  0  k = Wash_Dishes
  0  0  0  0  0  0  0  0  0  0  0 37  0  0  0  0  l = Work_Bedroom_1
  1  0  3  0  0  0  0  0  0 13  0  0  0 32  0  0  m = Work_Bedroom_2
  0  0  7  0  0  0  0  0  0  0 9  0  0  0 34  0  n = Work_LivingRm
  0  0  0  0  0 13  0  0  0  0  0 2  0  0  0 35  o = Work_Table
  0  0  6  0  0  0  0  0  0  0  0 6  0  0  0  1  p = Yoga
  
```

Fig. 17 Confusion matrix using the Bayesian network with activity occurrence probability

(Table 2 実線□) を用いることにより、ベイジアンネットワークだけでは識別が難しかった行動が正しく識別できている。また、「d: Enter_Home」の認識率が向上したことにより、「c: Enter_Home」と関係性が強い「n: Working_LivingRm」、「o: Work_Table」、「f: Meal_Preparation」の認識率がわずかながら改善されている (Fig. 16 二重線○, Table 2 破線□)。一方、「c: Eating」は、直前行動の「f: Meal_Preparation」と強い関係性を持つが (Table 2 実線○), 行動生起確率を適用した効果があまり見られない結果となった (Fig. 17 破線○)。

5. 考察

5.1 認識対象の直前行動の行動生起確率を用いて誤認識する例

Table 4 はデータセットの中から「c: Eating」の前後のデータを一部抜き出したものであり、上から順に時系列に行動が起きたことを示している。この例では、「c: Eating」と「o: Work_Table」がベイジアンネットワークにより推定された候補であり、どちらが実際に発生した行動であるかを行動生起確率によって特定する。ここでは「c: Eating」が認識すべき行動と仮定する。Fig. 18 は Table 4 の内容を図示したものであるが、認識すべき行動である「c: Eating」の直前行動は、「c: Eating」と強い関係性をもつ「f: Meal_Preparation」ではなく、「o: Work_Table」と判断したため、「o: Work_Table」と強い関係性を持つ「o: Work_Table」を選択し (Table 2, 二重○), 誤認識したことになる。データセットには、開始した時刻順に行動が記録されているが、「f: Meal_Preparation」の後に「o: Work_Table」が発生しているため、「f: Meal_Preparation」が「c: Eating」の直前に終了しているが、直前行動としては「o: Work_Table」になる。結果として、「o: Work_Table」と関係性の強い「o: Work_Table」が選択され、誤認識となった。なお、「o: Work_Table」は食事の準備や、テーブルでの作業など多くの動作が含まれ、一定の間隔を空けて連続して発生する行動である。また、先にも述べたように、CASAS には 2 人の居住者の行動が区別されず記録されており、本結果もこの点が影響を及ぼしている可能性がある。行動の発生時刻ではなく、終了時刻による行動順の変更などデータセットのデータ処理を行った上での再評価が必要であるが、この例の結果から、データセットに記録された直前行動と関係性の強い行動を選択するという単純な方法では、実際の複雑な環境下では正しく認識することが難しいと考えられる。このような状況はテレビを見ながら料理する等、ある行動の間に別の行動が発生するという日常的に起こり得る現象であり、解決すべき今後の課題である。

5.2 認識対象の行動の前に関係の強い行動がなく、行動生起確率の適用が有効ではない例

本実験で用いたデータセットでは、「p: Yoga」のサンプル数が全体の約 4,600 件に対して、13 件と非常に少なく、ベイジアンネットワークを用いるためのサンプル数が十分ではなかった。また、「p: Yoga」は Table 2 で示されている様に、「p: Yoga」の前に行われるすべての行動との行動生起確率が 1%以下と低く、このため行動生起確率が効率的に働く行動とはならない。直前行動に習慣として強い関係性の

Table 4 Example of discretized activity records

行動	開始 時間	場所	年 曜日	季節	時間区分	時刻
Meal_Preparation	42491	2365 Kitchen	2010 日	冬	区分7	9~11
Work_Table	44464	97 Kitchen	2010 日	冬	区分4	12~14
Eating	44944	1157 LivingRoom	2010 日	冬	区分6	12~14




Fig. 18 Example of a misrecognition estimated using the last activity

持つ行動を持たない場合、本方法で行動を認識することは難しい。しかし、「p: Yoga」などの趣味の行動は、個人の習慣として「時刻」、「場所」、「曜日」が比較的固定されている可能性があり、これら行動はベイジアンネットワークで行動認識できる可能性が高く、今後の評価の中で ADL の行動とは区別して評価を行っていく必要がある。

6. まとめと今後の課題

6.1 まとめ

本研究では、Data driven approaches の一手法であるベイジアンネットワークと Knowledge driven approaches として考案した行動生起確率を組合せた行動認識方法を提案し、その評価を行った。ワシントン州立大学が公開する CASAS データセットを用いて、ADL や IADL に定義された行動を含む 16 種類の行動を対象にした評価実験を行った結果、ベイジアンネットワークに使用するデータセットの前処理を行うことで同じデータセットを用いた先行研究に比べて 8%程度認識率が向上することが確認できた。また、ベイジアンネットワークのみの認識結果では誤認識されていた「d: Enter_Home」と「e: Leave_Home」は、行動の関係性を数値化した行動生起確率によって正しく認識することができた。しかしながら、2 つの行動の間に強い関係性を持つ「f: Meal_Preparation」と「c: Eating」については、比較的行動に要する時間の長い「f: Meal_Preparation」の間に異なる行動が行われた場合、「f: Meal_Preparation」以外の行動と強い関係性を持つ行動が選択され、誤認識という結果になった。この解決方法として、発生した行動の単純な順序を用いるのではなく、最後に終了した行動を直前に発生した行動として順序関係を変更するなどのデータの事前処理を追加すれば、行動生起確率を用いて選択される行動の認識率向上が見込めると考える。

6.2 今後の課題

本稿では、Knowledge driven approaches として、行動生起確率を用いて Data driven approaches で候補として抽出された行動の中から、データセットに記録された直前行動から習慣として関係の強い行動を選択する方法を提案した。この方法では、特定する行動の前に発生した行動との関係性の強さを表現した行動生起確率を用いているが、この際前提となるのは、直前行動が精度高く認識されていることである。今回の評価においても、5.2 節で述べたようにこの問題が明らかとなっている。直前行動だけに限らず、過去の行動の認識率を考慮して、行動生起確率の適用候補となる行動の抽出方法を検討する必要がある。また、本稿では Data driven approaches としてベイジアンネットワークを用いたが、もう一つの代表的な方法である HMM を含めて、先行研究で行われている様々な方法との組み合わせを評価する必要がある。

また、今回のアルゴリズムは ADL と IADL の行動の区別をせずに同一レベルの行動として扱ったが、ベイジアンネットワークで出力された候補の中に ADL に含まれる行動があった場合には、直前行動だけではなく、ある一定時間の中で行動生起確率を適用する対象となる行動の候補を選択するなど、ADL に対象を限定した決定方法の検討が考えられる。

加えて、考察でも述べたように、実際の生活環境においては、習慣とは異なる行動を取る、あるいは同時に複数の行動を行うなどの状況が発生する。今回の方法ではこの状況においては、行動を正しく認識することができない。改善する一つの方法は、一般的な行動の前後関係を網羅的に構造化し、それぞれに時間や回数などのプロパティを定め、習慣の生起条件を表現する方法が挙げられる。

参考文献

- 1) “高齢者の家族と世帯”，平成 29 年版高齢社会白書(全体版)-内閣府，https://www8.cao.go.jp/kourei/whitepaper/w-2017/zenbun/29pdf_index，2017（最終閲覧日 2020 年 7 月 20 日）
- 2) 総論参考資料 | 厚生労働省，https://www.mhlw.go.jp/www1/topics/kenko21_11/s1.html，2017（最終閲覧日 2020 年 7 月 20 日）
- 3) 自立生活の指標：日常生活動作(ADL)とは 健康長寿ネット，<https://www.tyoju.or.jp/net/kenkou-tyoju/kenkou-undou/jiritu.html>，2019（最終閲覧日 2020 年 7 月 20 日）
- 4) J. Rafferty, C. D. Nugent, J. Liu, and L. Chen, “From Activity Recognition to Intention Recognition for Assisted Living Within Smart Homes,” *IEEE Transaction on human-machine systems*, Vol. 47, No. 3, pp.368-379, 2017
- 5) L. Bao and S. Intille, “Activity recognition from user-annotated acceleration data,” *Pervasive Comput.*, vol. 3001, pp. 1–17, 2004
- 6) E. Tapia, S. S. Intille, and K. Larson, “Activity recognition in the home using simple and ubiquitous sensors pervasive computing,” in *Pervasive Computing*, vol. 3001, A. Ferscha and F. Mattern Eds. Berlin, Germany: Springer, pp. 158–175, 2004
- 7) D. J. Cook and M. Schmitter-Edgecombe, “Assessing the quality of activities in a smart environment,” *Methods Inf. Med.*, vol. 48, no. 5, pp. 480–485, 2009
- 8) T. van Kasteren and B. Krose, “Bayesian activity recognition in residence for elders,” in *Proc. 3rd IET Int. Conf. Intell. Environ.*, vol. 2007, pp. 209–212, 2007
- 9) U. Maurer, A. Rowe, A. Smailagic, and D. Siewiorek, “Location and activity recognition using ewatch: A wearable sensor platform,” in *Ambient Intelligence in Everyday Life*, Y. Cai and J. Abascal Eds. Berlin, Heidelberg: Springer-Verlag, pp. 86–102, 2006
- 10) N. Ravi, N. Dandekar, P. Mysore, and M. L. Littman, “Activity recognition from accelerometer data,” in *Proc. 17th Conf. Innovative Appl. Artif. Intell.*, vol. 3, pp. 1541–1546, 2005
- 11) M. Stikic and B. Schiele, “Activity recognition from sparsely labeled data using multi-instance learning,” *Location Context Awareness*, vol. 5561, pp. 156–173, 2009
- 12) D. L. Vail, M. M. Veloso, and J. D. Lafferty, “Conditional random fields for activity recognition,” in *Proc. 6th Int. Joint Conf. Auton. Agents Multiagent Syst.*, pp. 235:1–235:8, 2007
- 13) C. Sutton, A. McCallum, and K. Rohanimanesh, “Dynamic conditional random fields: Factorized probabilistic models for labeling and segmenting sequence data,” *J. Mach. Learn. Res.*, vol. 8, pp. 693–723, 2007
- 14) T. R. Gruber, “Toward principles for the design of ontologies used for knowledge sharing?” *International Journal of Human-Computer Studies* Volume 43, Issues 5–6, 1995.
- 15) W3C, “RDF - Semantic Web Standards,” Available: <https://www.w3.org/RDF/>（最終閲覧日 2020 年 7 月 20 日）
- 16) W3C, “OWL - Semantic Web Standards,” Available: <https://www.w3.org/OWL/>（最終閲覧日 2020 年 7 月 20 日）
- 17) GitHub, “GitHub - RDFLib/rdfli: RDFLib is a Python library for working with RDF, a simple yet powerful language for representing information,” Available: <https://github.com/RDFLib/rdfli>（最終閲覧日 2020 年 7 月 20 日）
- 18) apache, “Apache Jena,” Available: <https://jena.apache.org/>（最終閲覧日 2020 年 7 月 20 日）
- 19) 中村亮, 石川佳治, 杉浦健人, 脇田佑希子, “ライフログサービスのためのオントロジーに基づく行動イベント処理,” *DEIM Forum*, I5-1, 2017.
- 20) Zong-Hong Wu, Alan Liu, Pei-Chuan Zhou, Yen Feng Su, “A Bayesian Network Based Method for Activity Prediction in a Smart Home System,” *IEEE International Conference on Systems, Man, and Cybernetics (SMC) IEEE*, pp. 1496-1501, 2016
- 21) Washington State University, “The CASAS Smart Home project” <http://casas.wsu.edu/smart-homes>（最終閲覧日 2020 年 7 月 20 日）
- 22) 朱成敏, 武田英明, 法隆大輔, 竹崎あかね, 吉田智一, “農業 IT システム間データ連携のための農作業基本オントロジーの構築,” *信学技報*, vol.115, no. 290, pp. 149-154, 2015
- 23) WEKA, The workbench for machine learning, <https://www.cs.waikato.ac.nz/ml/weka/>（最終閲覧日 2020 年 7 月 20 日）