

令和元年度 博士論文

介護分野応用を目指した
将来予測と未知行動認識の研究

令和元年 12月 14日

学籍番号 17595901

氏名 松木 萌

指導教員 三浦 元喜 准教授

目次

内容梗概	1
第 1 章 はじめに	4
1.1 介護分野における課題と改善策	4
1.2 課題に対するアプローチ	6
1.3 研究分野と貢献	6
1.4 本論文の構成	7
第 2 章 関連研究	9
2.1 ユビキタスコンピューティング研究	9
2.2 データマイニング	10
2.2.1 データマイニングの概要	10
2.2.2 将来予測モデル	11
2.2.3 アンサンブル学習	12
2.2.4 介護分野におけるデータ分析	13
2.3 未知行動認識	14
2.3.1 行動認識	14
2.3.2 センサ行動認識	15
2.3.3 介護分野におけるセンサ行動認識技術の必要性	16
2.3.4 未知クラス推定	17
第 3 章 介護施設紹介コールセンター記録のアンサンブル学習による傾向分析	19
3.1 はじめに	19
3.2 分析データと手法	20

3.2.1	介護施設紹介コールセンタの記録データ	21
3.2.2	分析の目的	22
3.2.3	分析の概要	23
3.2.4	説明変数の生成方法	24
	「属性項目」の 35 種類のベクトル集合 X_{atr}	24
	相談経緯テキストから生成した単語ベクトル集合 X_{tfidf}	25
3.2.5	目的変数の生成方法	26
	進捗の経路 Y_{status}	27
	相談者が見学, 契約した施設の種別 Y_{type}	27
3.2.6	アンサンブル学習を用いた分析	29
3.3	分析結果	30
3.3.1	学習モデルの精度の概要	30
3.3.2	目的変数「見学したかどうか」の場合の結果	32
3.3.3	目的変数「成約したかどうか」の場合の結果	35
3.3.4	目的変数「見学施設はどのようなタイプか」の場合の結果	38
3.3.5	目的変数「成約施設はどのようなタイプか」の場合の結果	41
3.4	考察まとめ	43
3.5	まとめ	45
第 4 章	高齢者の睡眠と生活行動の相関分析のためのセンシング実験	47
4.1	はじめに	47
4.2	睡眠がもたらす影響と分析する意義	48
4.3	睡眠と生活行動のデータ収集方法	49
4.3.1	介護施設と実験概要	49
4.3.2	被験者の概要	50
4.3.3	非接触生体センサ	50
4.3.4	介護記録アプリ	51
4.4	アンサンブル学習による分析方法	53
4.4.1	睡眠と日中の行動における相関の仮説	53
4.4.2	前処理	55
	焦電センサデータの前処理	56

	介護記録の前処理	57
4.4.3	分析方法	58
4.5	分析結果	60
4.5.1	深夜の睡眠状況と日中の運動に相関があるかどうか	60
	深夜の睡眠状況から日中運動をするかどうかを予測	61
	日中運動の有無から睡眠状態を推定	62
4.5.2	日中の睡眠状況と深夜の睡眠状況に相関があるかどうか	62
	日中の睡眠状況から深夜の睡眠状況を推定	62
	深夜の睡眠状況から日中の睡眠状況を推定	63
4.6	考察	63
4.7	まとめ	65
第 5 章	センサベース行動認識における Zero-shot 学習法	70
5.1	はじめに	70
5.2	分散表現を用いた Zero-shot 学習法	73
5.2.1	Zero-shot 学習法	73
5.2.2	投影モデル	75
5.2.3	クラス探索関数	75
5.2.4	分散表現と拡張分散表現	75
	分散表現	75
	拡張分散表現	76
5.3	評価	76
5.3.1	データセット	76
	センサデータセットと前処理方法	77
	意味的空間	78
5.3.2	分析手法と評価実験	79
	未知クラス推定の評価方法	79
	意味的空間の類似度の評価方法	81
5.4	分析と評価結果	82
5.4.1	投影関数の評価	82
5.4.2	未知クラスの推定結果	82

5.4.3	空間類似度との相関	84
5.4.4	結果のまとめ	86
5.5	考察	87
5.5.1	分散表現の意味的な正当性	87
5.5.2	意味空間の選択とパフォーマンス	88
5.5.3	複合語	88
5.5.4	将来の展望	89
5.6	まとめ	90
第 6 章	全体の考察	92
6.1	将来予測モデルを用いたデータマイニング手法における利点	92
6.2	行動認識における Zero-shot 学習法の実用化	93
6.2.1	介護記録自動化のための行動認識手法への応用を考えて	93
6.2.2	属性ベクトルと単語ベクトルの比較	94
6.2.3	Zero-shot 学習法の未知行動推定以外の可能性	95
6.2.4	行動認識の実用化	95
6.3	介護分野における現在の取り組みと今後の展望	96
第 7 章	まとめ	99
謝辞	101
参考文献	104
第 8 章	Appendics	116
8.0.1	属性ベクトル	116
8.0.2	各行動クラスに対する類似単語	119
8.0.3	空間類似度	123

内容梗概

本博士論文は、ユビキタスコンピューティング研究の概念をもとに、介護分野への応用を目指す。介護分野は少子高齢化に伴い最新技術の応用が必要である。本博士論文では、(課題1) 現場以外で起きる問題、(課題2) 高齢者の見守り、(課題3) 介護士不足、の3つの課題に対し、機械学習を用いた解決を目指す。

1章では、介護分野の課題を定義し、改善策と研究概要を述べる。上記の3つの課題に対して、(研究1) 介護施設利用前の問題調査として、介護施設紹介コールセンターの記録データを用いた将来予測、(研究2) 高齢者の数時間先の行動予測を目指し、現場のデータ収集および夜間と日中の高齢者の行動相関分析、(研究3) センサデータを用いた行動認識技術の応用化を目指した、未知行動クラス推定手法の提案、の3つの研究について、概要と貢献を記述する。

2章では、ユビキタスコンピューティング研究の概要を述べ、それぞれの研究の技術的な立ち位置について述べる。ユビキタスコンピューティング研究とは、実世界のデータを収集し、データを分析し、実世界に応用する、というサイクルがある。研究1と研究2は、「将来予測」モデルを用いたデータ分析の研究分野に該当する。これら研究3は、「未知行動認識」手法を提案し実世界応用としての研究分野に該当する。これらの研究全てに対して機械学習を用いたアプローチを行うが、予測と認識、応用の目的やデータによって用いるモデルを変更させる必要があるため、「将来予測」と「未知行動認識」のそれぞれの関連研究と共にどのようなアプローチなのかを記述する。

3章では、介護施設を紹介するコールセンターサービスの記録データを活用し、相談者の行動予測モデル分析の研究を述べる。行動予測モデルはテキスト分析およびアンサンブル学習アルゴリズムを使用し構築した後、説明変数の重要度を可視化することで予測モデルの中身を分析する。学習モデルの評価の結果、「見学するかどうか」を96.8%の正答率で予測することができた。分析の結果、コールセンターだけでなく、介護施設、相談者に対して、例えば「交通手段がないと見学に行かない傾向にある」といった、全10件ほどの有用な知見を示し、介護

分野への貢献を示した。また技術的な貢献として、分析やアンサンブル学習を用いた記録データの活用方法を示した。

4章では、介護施設に入居する高齢者のベッド上の行動を見守るデバイスのデータを収集し、高齢者の行動予測の研究を述べる。具体的には、日中行動と夜間行動の相関関係を、機械学習を用いて分析をする。予測モデルの評価結果、深夜の睡眠状況から日中の運動をするかどうかを92%の正答率で予測できた。分析の結果、日中の運動の有無と就寝時間に相関があるということ、といった介護士のサービス向上に繋がる知見を得ることができた。技術的な貢献としては、見守り用のベッドIoT製品のデータと介護記録のデータを組み合わせたデータ活用方法を示した。

5章では、行動認識技術の実用化を目指した研究を述べる。既存の行動認識技術は全クラスに対し学習データセットを収集する手間が課題であり、介護記録の自動化応用を目指すための障害であった。そこで、学習データのない未知のクラスを推定する手法を提案する。評価の結果、既存手法より最大で16%予測精度が向上し、生成方法の手間を考慮すると提案する手法の方が有用であることがわかった。この研究は、プライバシーやコストの面で、介護現場で導入が見込まれるセンサデータを用いて行動を認識する技術の実用性の問題に取り組み、さらに行動認識技術の実用化での重要な課題に取り組んでいるものであり、応用面と技術面の両方で貢献した。

6章では、これらの研究に対して全体的な考察をする。まず、介護分野の現在の取り組みと今後の展望を述べる。次に、介護分野に限らず、本論文で述べたような研究の視点でデータ活用をすることを述べ。最後に、展望と今後の課題として、データ量の少なさの課題と人の行動の個人差に対する対策を考察する。7章で全体の博士論文のまとめをして終わる。

論文目録

本博士論文は、以下の論文を参照している。

1. 松木 萌, 井上 創造, 清田 陽司, “介護施設紹介コールセンター記録のアンサンブル学習による将来予測と傾向分析”, 情報処理学会論文誌, 59 巻, 10 号, pp.1837-1852.(2018 年 10 月)
2. Moe Matsuki, Sozo Inoue, “Sensing Experiment in a Caregiving Facility for Correlation Analysis of Sleep and Daytime Activities” (訳: 睡眠と日中行動の相関分析のための介護施設におけるセンシング実験), Proceeding of the ACM International Joint Conference on Pervasive and Ubiquitous Computing, pp.162-165.(2018 年 12 月)
3. Moe Matsuki, Sozo Inoue, “Toward Projection Learning between Sensor Data and Semantic Word Vector for Zero-shot Learning”, (訳: ゼロショット学習のためのセンサデータと意味的ベクトル間の投影学習に向けて), 2019 Joint 8th International Conference on Informatics, Electronics & Vision (ICIEV) and 2019 3rd International Conference on Imaging, Vision & Pattern Recognition (icIVPR). IEEE. pp.108-111. (2019 年 7 月)
4. Moe Matsuki, Paula Lago, Sozo Inoue, “Characterizing Word Embeddings for Zero-shot Sensor-Based Human Activity Recognition”(訳: センサベースの人の行動認識における分散表現の特徴付け), MDPI Sensors, Vol. 19, No. 22, pp. 5043:1-5043:27.(2019 年 11 月)

第1章

はじめに

少子高齢化に伴い、介護分野における課題解決が求められる。本章では、介護分野における課題とどのような改善策をとるべきかについて述べる。

1.1 介護分野における課題と改善策

少子高齢化の進行に伴い、介護分野における課題が深刻化している。厚生労働省の調査(図 1.1)によると、高齢化率は上昇し、2065年には65歳以上1人に対して1.3人の現役世代という比率になる。

そのため、現時点で起きている課題の早期的な解決と、人手不足に向けた現場の効率化に取り組む必要がある。著者は解決すべき課題を、(課題1)現場以外の問題、(課題2)高齢者の見守り、(課題3)介護士不足、の3つにカテゴリ化する。

(課題1) 介護分野の問題は、介護現場の問題に注目されがちであるが、現場以外でも問題様々な課題が存在する。例えば、施設を探す介護難民の増加 [36] や高齢者同士が介護をし合う老老介護問題 [89]、介護に関わる金銭的な家族内トラブル [90]、という問題がある。これらの問題は、一般的に起きていることであると推測できるが知識が一般化されていない。つまり、どのような状態が問題とされているのか、いつ頃準備が必要なのかというような知見が世間一般で認識されていない。そのことが原因で、介護保険に関する詐欺事件 [91] や退去命令 [92] などのトラブルを発生する可能性が潜在している。

(課題2) 介護施設における事故は増加の一途を辿っている [38] ことから、見守りの重要性が増している。しかし、介護士不足や介護士のストレスの増大などの理由もあり見守りの課題は重大なものとなっている。そのため、見守り機器の活用が求められている。主に離床に焦点

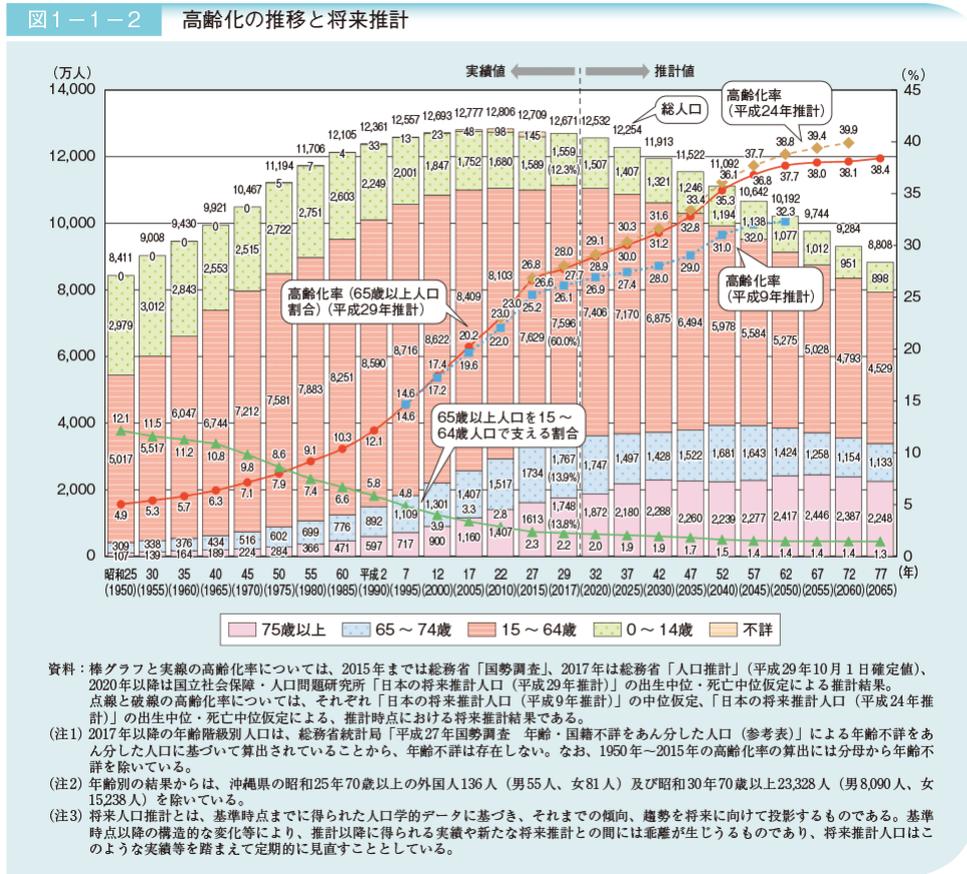


図 1.1 高齢化の過去の推移と予測される推移の可視化。厚生労働省の白書から抜粋 [42].

をおいた見守り機器が多く、例えば、ベッド付近にマット式のセンサ、赤外線センサ、を例としたセンサ搭載の見守り機器がみられる。しかし未だ、機器装置のスイッチの入れ忘れ、複数のセンサが反応した時の優先度がわからない、事故が起きた時の状態がわからない、といった課題が残る。また、高齢者の転倒などの事故は離床時以外にも起きているし、転倒以外の誤嚥や徘徊などの事故も起きている。それらの事故を全てカバーするためには、複数の場にセンサを設置する必要がありコストがかかりで現実的ではない。

(課題 3) 介護士不足の問題の原因は、離職率の増加 [39] と少子高齢化 [40] によるもので今後さらに深刻化していく。そのため、最新技術を応用した業務の効率化が必須である。例えば、介護記録の自動化、転倒検知技術といった取り組みがある。これらの技術には行動認識技術が重要な鍵である。例を挙げると、介護士にウェアラブルセンサを取り付け介護士の動きデータをサーバーに送信し、サーバー内であらかじめ人の行動を認識するよう学習された人工知能を用いて介護士の行動を推定し、介護記録の自動生成をする取り組みをしている [31]。また、部屋にセンサを取り付け同様に学習された AI を用いて高齢者が転倒したかどうかを認識

する取り組みもある [34]. このように、収集されたデータから人の行動を認識する「行動認識技術」が注目を浴びている。しかし、これらのほとんどの手法は教師あり機械学習を用いられている。つまり、データと人の行動が対応する教師データと呼ばれるものが存在することが前提だが、全ての行動に対するデータを収集するのは、時間的な面とコストの面であまり現実的ではない。

1.2 課題に対するアプローチ

以上の3つの課題に対して、将来予測モデルを用いたデータマイニング技術と未知行動推定手法技術を用いた研究を行う。

データマイニングとは、データを分析し新たな仮説を発掘することを目的とした手法で、機械学習を用いたアプローチが主流である。データマイニング技術に機械学習を用いる利点としては、膨大なデータから要因を絞ることができる点である。本博士論文では、介護分野で課題が明確化されていない課題1に対し「相談者」の行動データを用いてデータマイニングを行う研究について述べる。また、より効率的な見守りが必要である課題2に対して「入居中の高齢者」の行動データをセンシングし、そのデータを用いてデータマイニングを行う研究について述べる。

また、行動認識技術のデータ収集が現実的でないという課題3に対し、教師なし機械学習によるアプローチや転移学習によるアプローチが提案されているが、今回目指す介護記録自動化の応用にはテキストを推定されないという点で不十分である。そこで、学習データが一部存在しない設定下でも実現可能な行動認識手法の研究について述べる。

1.3 研究分野と貢献

本博士論文で紹介する研究は、ユビキタスコンピューティング実現に向けた研究分野において重要な研究であると言える。ユビキタスコンピューティングとは、コンピューターが世の中に溶け込んでどこにでも存在する状態、という概念であり、そうすることで世の中がより便利で安全になることを目指すものである。奈良先端大学院大学のユビキタスコンピューティングシステム研究室^{*1}では、ユビキタスコンピューティングの研究フィールドを図1.2のようにまとめている。実世界のデータを収集し、そのデータを分析し、そのデータを用いた応用的な技

^{*1} <http://ubi-lab.naist.jp/>

術によって実フィールドにフィードバックする。

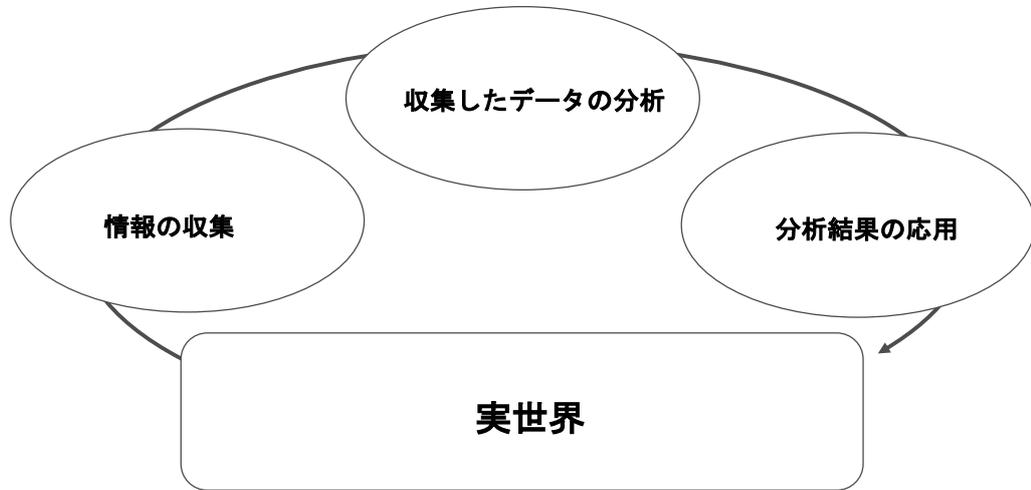


図 1.2 ユビキタスコンピューティング研究分野の概念と 3 つの研究分野。重要な点は、実世界のデータを収集し、実世界にフィードバックすること。

本博士論文では、ユビキタスコンピューティング社会の実現を目指す 1 つのフィールドとして、介護分野に焦点を当てる。既存のユビキタスコンピューティングの研究は、日常生活への応用、ヘルスケアの応用を考えた研究が多く存在する。そのため、研究者自身でデータを収集することで評価を行うことが可能であるが、介護やヘルスケアなどの分野では、現場でのデータ収集が難しいため既存の研究が少なく技術進展が遅い。本博士論文では、介護に関する実際のデータを用いることで、これまで取り組まれていない介護分野の課題に取り組む。

以下表 1.1 に介護分野における貢献と学術的な貢献についてまとめる。

1.4 本論文の構成

本博士論文は、以下の構成で以降記述されている。

2 章では、これらの研究の分野として、ユビキタスコンピューティング研究に属することを説明する。ユビキタスコンピューティングの概念とこれらの研究の技術的なアプローチについて述べる。そして、将来予測と未知行動認識における関連研究を述べる。

3 章では、介護施設を紹介するコールセンターサービスの記録データを活用し、相談者の行動予測モデル分析の研究について述べる。行動予測モデルはアンサンブル学習アルゴリズムを使用し、予測モデルの中身を分析し、説明変数の重要度を可視化する。その結果、コールセンターだけでなく、介護施設、相談者に対して、例えば「交通手段がないと見学に行かない傾向

表 1.1 各研究に対しての介護に対する貢献と技術的な貢献をまとめた表

対応する課題番号	研究概要	介護分野への貢献	学術的な貢献
1	介護施設紹介コールセンターの記録データを用いて、相談者の将来予測モデルの構築しデータマイニングを行う	介護施設に入居する前の相談者のデータを分析し、介護施設や相談者に嬉しい知見を示す。	アンサンブル学習を用いて、データマイニング技術を示す。特に重要項目の可視化方法は新しい。
2	高齢者のベッド上の行動データと介護記録を2ヵ月分収集し、高齢者の夜間行動と日中行動の間で予測モデルをいくつか構築しデータマイニングを行う。	介護施設に入居している高齢者の行動に関する知見を示すことで介護士のサービス向上に繋がる提案をする。	実際の介護施設のデータを収集しデータマイニングした例を示す。特に約1ヶ月という長期的な睡眠と日中の間のデータ分析はこれまでない。
3	センサ行動認識の応用を目指し、学習データに存在しない行動クラスを認識することを目指した研究をする。	介護記録の自動化や見守りといった仕事の効率化に必要な行動認識技術の実用化を目指す研究を一例を示す。	行動認識におけるボトルネックであるデータ収集問題における課題に取り組む。

にあるなど」、全10件ほどの有用な知見を示す。

4章では、介護施設に入居する高齢者のベッド上の行動を見守るデバイスのデータを活用し、高齢者の行動予測を行う研究について述べる。具体的には、日中と夜間の行動の相関関係を機械学習を用いて分析をする。その結果、日中の運動の有無と就寝時間に相関があるということなどの知見を得ることができた。

5章では、介護記録がタブレットやスマートフォン化する動きに伴い得られるセンサデータを活用し、介護記録の自動化を目指す「センサ行動認識」の研究について述べる。特に、データ収集が困難であるという問題に対して、学習データのない未知のクラスを推定する手法を提案する。その結果、自然言語処理を用いてデータを手動で用意しないというアプローチの有用性がわかった。

6章では、これらのデータ活用の研究での展望と今後の課題として、データ量の少なさの課題、そして、人の行動の個人差に対する対策について考察を行う。

第2章

関連研究

本博士論文で紹介する研究は、ユビキタスコンピューティングの研究分野について説明し、その中で特に将来予測と未知行動認識における関連研究について述べる。

2.1 ユビキタスコンピューティング研究

ここでは、ユビキタスコンピューティング実現を目標とした研究分野について例を挙げる。

ユビキタスコンピューティングという概念は、1991年にパロアルト研究所のマーク・ワイザー氏によるサイエンティフィック・アメリカンの記事“The Computer for the 21st Century”で、コンピューターが「環境にすっかり溶け込み消えてしまう」というあり方を示す用語として使われ、現在の日本では、「いつでも・どこでもネットアクセスできる多様性に富んだモバイル・コンピューティングという意味で使用される^{*1*2}。著者の理解としては、「みんながコンピューター手軽に所有し、環境にも自然に溶け込んでいる。そうすることで、世の中が安全かつ便利になる。」という概念と理解している。

ユビキタスコンピューティングの実現のためには、様々な技術の発展が必要とされている。図1.2は、その分野を3つに分けている。1つ目は、「情報の収集」に関する研究分野で、モバイルセンシングやセンサネットワークなどの研究分野がある。今やスマートフォンやスマートウォッチなどが普及したおかげで日常生活内でより自然な状態で加速度データやGPSデータを収集できるようになった。しかし、データの遅延や欠損などの問題が残る。さらに、常に同じ場所に同じように身につけているということでもないため、継続的なデータ収集は難易度が

^{*1} <https://ja.wikipedia.org/wiki/ユビキタスコンピューティング>

^{*2} <https://gigazine.net/news/20180510-the-computer-for-the-21st-century/>

高い。

2つ目は、収集したデータを分析する技術で大量のデータから有用な知見を得る研究分野で、データマイニング技術はこの分野に該当する。人は、データを眺めて相関関係を発掘することは可能だが、大量のデータが存在するときは難しい。そこで、機械学習を用いてデータに隠れたパターンや相関といった仮説を発掘するために生まれたのがデータマイニング技術である。統計や数理モデルなどは、仮説検証を行うために有用な技術であり組み合わせることでより良い分析を可能とする。

3つ目は、利用価値がありそうなデータを実世界に応用する技術で、行動認識やコンテキストウェアネスシステムの開発、ヘルスケアといった技術研究が該当する。介護分野におけるユビキタスコンピューティング応用研究として、高齢者の行動を見守る研究、特に転倒検知システムの研究が多く存在する [95]。また、介護記録を自動化する取り組み [31] や、高齢者の睡眠の効果を分析する研究 [96] などが存在する。

介護の分野は、少子高齢化に伴い最新技術が必須となってきているが、実際のデータの収集が難しいため技術進展が遅い。

2.2 データマイニング

ここでは、データマイニング技術についてと介護における応用について述べる。

2.2.1 データマイニングの概要

データマイニングとは、大量のデータから有用な知識を発掘する技術であり、金融分野やマーケティング分野をはじめ様々な分野で活用事例がある技術である [93]。データマイニングは、1989年に人工知能（機械学習）研究者とデータベース研究者が、「膨大だけど雑多（不均一）なデータから何か有用な知識を見つけることはできないか？」というテーマで開催したワークショップから始まり、インターネットの普及などもありその時期から需要が高まった [94]。起源は、機械学習を用いたアプローチが多く、2002年までの主流は探索アルゴリズム手法を用いたものである。また、データマイニングは自動で分析する技術ではなく、人の介入による考察が重要となってくるため、決定木や帰納論理プログラミング、バスケット分析などの人の理解が容易な手法が主流である。しかし、近年では、複雑なモデル、例えば、SVM(Support Vector Machine) やアンサンブル学習も用いられる。これらは、汎用性の高い推定モデル生成

を目指した機械学習手法であるため、データ内に存在する傾向を探すというよりは、一部のデータからそのデータを包括する全体の事象の傾向を探すことを目的としていると言える。したがって、データマイニングで導き出される結果は、データから得られる結論的な傾向ではなく、あくまで仮説的な知見である。この仮説を導き出すことで、ユビキタスコンピューティング研究の応用への提案や既存システムの改善案として貢献することや、実世界への改善の提案として貢献できる。

本博士論文で紹介するデータマイニングを用いた研究では、人の行動の傾向を分析するために将来予測モデルを用いる。将来予測モデルを用いることにより、人の行動傾向分析に有効である理由について次節で述べる。

2.2.2 将来予測モデル

将来予測モデルを用いることで、結果に対する過去の行動要因を分析する。将来予測と言っても「short-term」「middle-term」「long-term」の3つのカテゴリに分けられる。過去の行動記録から将来の行動を予測するにも、どのくらい先の将来かによって適切な情報が変わってくる。

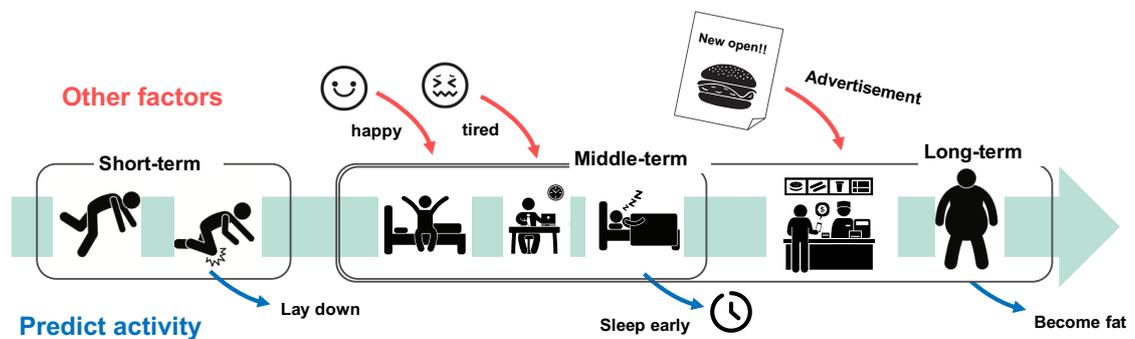


図 2.1 人の将来行動の予測のタイプの概要。

その情報の違いについて、図 2.1 を用いて説明する。数時間後の行動予測 (図の short-term) は、例えば「つまづく」という行動要因から「転ける」ということが予測でき、人の行動の時系列データがあれば予測できそうなことがわかる。Yu Kong らは、行動を予測する研究と軌跡を予測する研究の2つのカテゴリに分けている [12]。行動を予測するタスクは、現在の行動 a_0 から、次に起こる行動 a_1 を予測することを目的としている [11]。また、軌跡を予測する研究は、歩行者の進行方向を予測し衝突防止などでの応用で活躍する [10]。

数時間後の行動予測 (図の Middle-term) は、1 日以内の先の行動を推定することと定義する。例えば、朝起きて、仕事を日中行うという行動から睡眠時刻を推定できるかどうか、もし、他の要因で朝は早く起き、仕事を一生懸命行い疲れたとすると、人はもしかして早く寝るかもしれないと予測できる。下坂らは、家庭内に安価なセンサを設置し、統計的手法で生活リズムを解析し、家庭内のどこにどのくらいの時間滞在するかのパターンを探る研究を行う [8]。この解析は、short-term よりは長いが一日の生活の中の細かい動きに注目することで、パターンを見つけ出し、予測を試みる。しかし、感情やいつもと違う行動などの外的要因も含まれるため、センサデータと他のコンテキストデータが必要である。

数日後の行動予測 (図の Long-term) は、目的が人の選択を予測することで、経済学や心理学に近い部分はある。コンテキストデータから人の状態がどのようになるのかという医学的な観点では重要な予測 [9] であり、ユビキタスコンピューティングでは、予測後、異常予測としてレコメンデーションを行うアプリケーションとして活躍できる。

本博士論文では、高齢者の見守り改善のために、数時間後 (Middle-term) の高齢者の行動を予測するモデルを介護記録データとセンサデータの両方を用いて生成し、その予測モデルを分析する研究について 4 章で述べる。そして、入居前の相談者が数日後に入居するかどうか、どのような施設を選択するかどうかを推定する予測モデルをコンテキストデータを用いて生成し、分析する研究について、3 章で述べる。これらの将来予測モデルを生成するのに、アンサンブル学習手法を用いる。その理由について次節で述べる。

2.2.3 アンサンブル学習

アンサンブル学習とは、複数の機械学習モデルを組み合わせて使用するタイプの機械学習アルゴリズムのことである。有名なアルゴリズムでは、決定木の学習器を複数組み合わせた Random Forest がある [75]。本論文では、教師あり機械学習のアルゴリズムとして述べるが、教師なしあり機械学習 [76] や強化学習 [77] といったアルゴリズムにも適用可能である。アンサンブル学習 (複数の学習モデルを組み合わせること)、特に木構造のモデルを用いたアンサンブルアルゴリズムの利点として、

- 汎用性のあるモデルになる。
- 目的変数への説明変数重要度が分かる。

汎用性のあるモデル、つまり学習データに過度に適応するように学習するのではなく、どの

ようなデータも推定できるようにすることを目指すのに適したアルゴリズムである。将来のデータをテストデータとする、つまり学習データに依存しない推定モデルを生成するため、汎化性は将来予測には大事な要素である。また、本研究では予測精度の向上が主な目的ではなく、既存のデータの活用のための分析であるため、生成されたモデルから重要度を算出することで、データの傾向を分析することができる。これらの2つの理由から、後に述べる将来予測に関する研究(3章と4章)では、アンサンブル学習を用いる。

2.2.4 介護分野におけるデータ分析

介護分野における問題解決のために、介護に関連のあるデータを分析し、現場にフィードバックする取り組みがある[51–57]。文献[56]は、介護の現場における事故防止に向けたデータ収集を行い、収集したデータを分析し、介護施設における事故の傾向についてまとめている。また、介護施設の記録は電子化されていることが少なく、テキスト(自然言語)による記録が多いため、分析するのが難しいとされている。文献[57]は、介護施設の申し送りデータを電子化し収集することを可能にし、アンケート結果の分析を行っている。これらの研究は、一般的に構造化されたデータを用いられている。

しかし、より意外性のある知見を得るためには、テキスト文や自然言語の文章を分析することが重要である。しかし、自然言語は表現の揺らぎ(例えば、「朝ご飯」と「朝食」が混在するなど)や文章構造の統一性がないなど、分析するにおいて難しい点が多くある。しかし、テキスト文は自由な表現が出来るため、大切な情報が潜在しており、分析することで、有用な情報を抽出することができる[58]。文献[55]は、介護施設における事故事例のテキスト文(自然言語)から、テキストマイニング技術を用いて分析を行い、介護施設の職員に有用な情報、改善策の提案を行った。このように介護分野のデータを分析することによって、介護士や高齢者やその家族に有用な情報を抽出する取り組みがあるが、介護現場で収集されたデータを用いた分析がほとんどである。介護業界の全体の問題を解決するためには、入居前のデータを分析し現場以外の問題にも取り組む必要がある。例えば、介護施設入居後のトラブルに関しての事例には、「入居前に想定していた月額費用に比べて高い」、「突然施設側から退去を求められる」のようなトラブルがある。これらの問題を軽減し、満足度の高い介護サービスと高齢者社会を実現するには、介護施設入居前の状況把握をする必要がある。

また、介護施設に入居している高齢者の事故や行動についての分析は上記で述べたように行われているが、介護記録や事故事例テキストを用いたものである。近年では、センサデバイス

を介護施設に導入し高齢者の見守りを効率化する動きがある。特にベッド付近にセンサデータを設置するものは多くあるが、介護施設に入居している高齢者の睡眠データを用いた分析は少ない。

文献 [68] では、手首装着型の活動測定デバイスと移動性ポリグラフシステムを用いて、69歳から77歳の男女10人の被験者協力のもと、高齢者の日中の活動量と睡眠における相関分析をした。その結果、男性被験者に対して、身体定期的な行動が睡眠の質を向上させていることがデータからわかった。また、患者を被験者とし、深夜の睡眠と日中の眠気の相関を分析する研究が行われており、治療の重要性を示している [69,69,70]。これらの研究は、高齢者を対象とした日中行動と睡眠状況を分析し、個人差があるが相関があることを示している。つまり、日中行動と睡眠の関係性を見ることで、高齢者の行動の傾向が見えてくる。

睡眠は一般に、大脳や身体の休息と定義できるため、睡眠の客観的状況を正確に知る方法としては、睡眠時の脳波を中心に、筋電や眼電などを同時に計測して解析する睡眠ポリグラフ法が一般的である。しかし、この方法は、機器の操作やデータ判読に専門的知識が必要であり、自宅で手軽に睡眠を計測する目的には使えない。東芝は、寝つき時間や睡眠リズム、眠りの深さなど睡眠指標を算出する腕時計型のセンサモジュールの開発を行った [66]。これは、脈波の情報と加速度センサデータをもとに「覚醒」「レム睡眠」「ノンレム睡眠(浅)」「ノンレム睡眠(深)」を推定するモジュールである。1分ごとの睡眠判定の結果を比較すると、正答率は約75%で、脳は自動判定精度と変わらない精度であった。文献 [67] は、画像情報からベッド上の「無人」「立っている」「寝る」などの9つの行動を推定する提案をし、97.8%の精度で正解している。しかし、カメラや装着型のシステムを用いるのは、プライバシーは不快の感を抱かせ、高齢者にとって使用するのは困難である。そこで、本稿では非接触型生体センサを用いて、介護施設に入居している高齢者の睡眠データを収集し、介護記録データも用いて日中と睡眠の相関分析を行い、高齢者の行動の傾向を分析する。

2.3 未知行動認識

2.3.1 行動認識

行動認識は、ビジョンベースとセンサベースに分類することができる。ビジョンベースは、画像や動画から人がどのような行動をしているのか、姿勢を検出する取り組みがある。センサベースは、ウェアラブルデバイスや環境センサを用いてそのセンサ情報から人の行動を認識す

る技術である。これらの用いるデバイスの選択は、環境や用途によって決定する必要がある。例えば、ビジョンベースは既にカメラが流通している場面、監視カメラや公共の交通機関でよく用いられる。ビジョンベースは、センサベースに比べて情報が多いため、認識精度は高くなる。したがって、高齢者の一人暮らしや仕事場に設置し、見守りや効率化を測る研究もある。しかし、プライバシーの問題や設置コストの問題により、センサベースの行動認識の方が適切な場合がある。この場合は、カメラより推定精度が低下してしまう懸念があるため、異常検知や基本動作の推定、位置推定など推定目的設定を工夫することで、利便性を高める。

本博士論文では、介護施設での環境であるため、低コストとプライバシーの問題を考え、センサベースの行動認識に焦点をおく。

2.3.2 センサ行動認識

一般的に行動認識の分野での大枠の流れは、(1) 目的決定とデバイス選択、(2) データ収集 (3) データの前処理 (4) 推定モデルの構築 となる (図 2.2)。

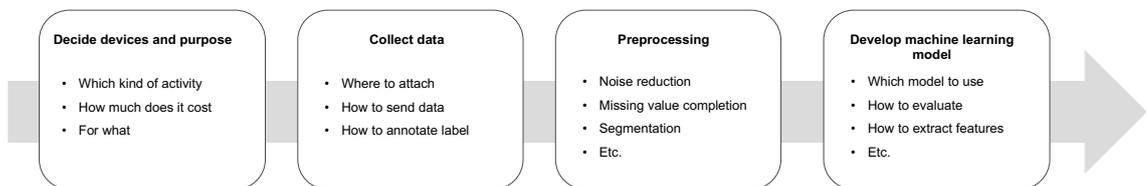


図 2.2 行動認識における一般的なプロセス。

(1) の過程では、まずどのような目的で行動認識技術を行うのかという目的を決定し、目的と環境にあった最適なデバイスを選択する。例えば、個室での高齢者の見守りを目的とする場合、どのような行動をしているのか正確に知りたい場合はカメラを用いるのが望ましいが、プライバシーやコストの問題が懸念される場合、全ての行動ではなく、「ベッドから起き上がる場合のみを検出する」という目的で、ベッドにセンサを取り付け起き上がり検出を目的とするなどの設定を行う。(2) の過程では、先ほどの目的やデバイスをどこに設置するのかを決定し、どのようにデータを収集するのかを決める。また、行動認識の場合、センサと行動ラベルが対となった教師データが必要だが、その教師データをどのように収集するのかということも考える必要がある。(3) の過程では、データのノイズを除去したり、欠損値の補完を行ったり、動画などであると人のみを抽出するセグメンテーションなどの処理が行われる。(4) の過程では、機械学習を用いて推定モデルの構築を行うために、どのような機械学習モデルを用いるのか、

どのような特徴量抽出を行うのかを行う。

以上のように、行動認識にはこのような一貫のプロセスがあるが、この1つ1つのプロセスが大きな研究分野になる。例えば、Sara Amendola らは、(1)の過程のデバイスに焦点をあて、医療の分野において人の見守りや異常検知に用いられる RFID センサの関連研究を40件の参考文献とし、サーベイしている [14]。また、Jindong Wang らは、(4)の過程の機械学習プロセスの中でも、センサデバイスを用いた行動認識における Deep learning モデルにおける77件の参考文献を用いてサーベイをしている [15]。

2.3.3 介護分野におけるセンサ行動認識技術の必要性

介護分野では、今後介護ロボットや介護業務効率化のために、人の行動を理解する技術が必要となる。例えば、人と働くロボットは、人の動きに対して適切な行動をフィードバックする必要がある。工場で働くために、人の作業の支援を行うために、人の腕の行動を把握する研究がある [30]。また、部屋に環境センサを取り付け、高齢者の行動を認識し、見守りに応用することを目的とした研究もある。さらに、介護現場では介護記録を自動化するために、介護士にウェアラブルセンサを取り付け介護士の行動を認識する取り組みもある。

このように、介護分野においてセンサ行動認識は重要な技術であると言える。

ほとんどの一般的な手法は、教師あり機械学習が用いられる。例えば、ベイジアン [114], SVM [115], 決定木 [116], ディープラーニング [117] などの手法が提案されている。

多くの研究が提案され、“run”などのシンプルな行動に対しては高いパフォーマンスで、生活行動などの複雑な行動は精度が向上しつつある。しかし、教師あり機械学習を用いることは、学習データセットを収集することが必要であり、生活行動などの行動種の多い場合は実用性にかける手法である。例えば、介護士の行動をセンシングし、介護記録を自動生成するためのアプリケーションの開発を考えた時、全てのユーザーの全ての行動データを収集する必要がある。新人が入るたび、また環境が変わるたびにデータセットを生成する必要がある、現実的ではない。

この課題に取り組むために、教師なし機械学習 [118] や転移学習 [119, 120] が提案されている。 [118] では、行動クラス数が不明であると仮定し、行動認識の教師なし学習の提案を行っているが、どのクラスかを特定することはできない。転移学習の例として、 [120] は、一部のユーザーのデータから学習したモデルを使用して、他のユーザーの推定に使用する手法を提案している。しかし、環境が違うことや、同じクラスであっても人によって行動が違うこと

は起きうる, という点について解決できていない. そこで, 本研究では, 未知クラスの推定を目的とする Zero-shot 学習法でデータ収集の効率化を目指す.

しかし, 一般的なセンサ行動認識は教師あり機械学習であり, そのためにはデータ収集が必須となる. そこで, 5章では, 未知行動クラス推定を目指した手法の提案する.

2.3.4 未知クラス推定

未知クラス推定を目的とした学習方法を Zero-shot 学習と呼ぶ. Zero-shot 学習への注目が近年急激に高まってきている [121]. Zero-shot 学習法の基本的なアイデアとしては, 既存クラス (学習データに存在するクラス) から未知クラス (学習データにないクラス) へ入力情報とは違う空間で, 情報を共有することである [108]. センサ行動認識での Zero-shot 学習法の既存手法は, 属性ベクトル空間で情報の共有を行うという手法が提案されている. 属性ベクトルとは, 人の定義した属性に対して行動クラスが俗世うるかそうでないかを 1 と 0 の値を用いて表現したベクトルである.

しかし, 属性ベクトルは人の手で生成されるため, 新しい未知クラスの出現の度に属性ベクトルを生成し直さなければいけない問題がある. さらに, クラス毎に違うベクトルを生成しなければいけないため, 属性の決定が難しい問題などの問題もある. これらの問題を緩和するために, 自動でかつ重複のないベクトルを生成する分散表現を用いた手法が, 画像認識の分野で多く提案されている [102–107, 109–112].

分散表現は, 教師なし学習を用いたニューラルネットワークモデルで生成されるツール (word2vec [122, 123] や Glove [124] など) を用いて, 膨大な文章 (Wikipedia など) を学習させて生成することがよく使われる手法である. この手法で, 属性ベクトルの欠点である, 手間と新たな未知クラスに対する対応の問題を解決できる. しかし, 大量の文章を用いて生成される分散表現は, 一般的な知識として扱われ, 「猫」や「いぬ」などの特徴のある比較的共通認識のあるものに対しては, 有効であるが, 人の行動のようにテキストへの記述が曖昧かつ, 文章による定義にゆらぎのあるものに対しては懸念がある. したがって, センサ行動認識において分散表現を用いることに対する調査が必要であると感じこの研究に取り組む.

分散表現を用いたビジョンベース行動認識における Zero-shot 学習法の取り組みについて述べる [109–111]. 人の行動の単語, つまり動詞は, 意味を文章で説明している記述は, 仕事内容などの特化した行動は存在するが, 記述内容や属性の表現などは物体 (名詞) の説明記述より複雑な物と予想される. 例えば, 動物の説明は, 形, 色, 育つ環境などの属性で説明されるこ

とが一般的である。しかし、例えば「走る」という行動は、「足をあげて下げて早く前進する行動」と解釈はできるが、一般的に「自力で移動できる生物または無生物が高速で移動すること^{*3}」と説明され、人の体の動きに焦点を当てた説明は少ない。さらに、動詞の意味は走るという動作以外にも、プログラミングのコードの実行している状態など、意味が複数あるば良いが多く、複雑である。上記の問題を解決するために、意味の拡張を行い意味の曖昧さや揺らぎの軽減を行うアプローチが存在する [110,111]。このアプローチの目的は、本提案手法の拡張分散表現に近く、同意味の単語への拡張を行うことでの言葉の揺らぎや曖昧さの軽減を行う。文献 [111] では、ターゲットのクラスの意味的ベクトルの周辺に存在するベクトルの平均値をとる手法を提案している。文献 [110] は、平均ではなく分散も考慮に入れたアルゴリズムで拡張ベクトルを生成する手法を提案する。本論文での拡張分散表現は、これらの手法に類似するが、平均などで1つのベクトルとするのではなく、周辺に存在する単語ベクトルをそのままターゲットの単語として用いることを提案としている。そうすることで、分析が容易であることや、特徴量空間上の分散を考慮できるという利点がある。

センサーベース行動認識における Zero-shot 学習の研究は、属性ベクトルを用いることに焦点が置かれている [112,125,126]。確かにこの手法は、ある程度の推定精度を得ることに成功はしているが、データセット毎に属性ベクトルを生成しなければいけないという問題点がある。そして、生成される属性ベクトルは、推定精度に大きな影響を与えるため、生成方法の試行錯誤も必要になる。そこで、分散表現を用いた手法は必要であると感じているが、上記で述べるようにただ使用するだけという単純なものではない。しかし、どのように改善すべきかの道筋もないため、本研究では、3つのデータセットを用いて、分散表現と属性ベクトルを用いた手法 (Wang al らの論文 [112] で定義された属性ベクトルを参考に) 比較する研究について5章で述べる。

^{*3} <https://ja.wikipedia.org/wiki/走る>

第3章

介護施設紹介コールセンター記録の アンサンブル学習による傾向分析

ここでは、介護施設紹介コールセンターの記録データを用いて、アンサンブル学習を用いたデータマイニング手法についての研究を紹介する。分析の結果、「交通手段がないと見学に行かない傾向にある」や「見学施設の決定は、お金や距離的な面で選択する人が多い傾向にあること」などの10件ほどの知見を発掘し、今後相談者になる人々にとっての有用な知見であることを示す。

3.1 はじめに

少子高齢化に伴い、介護分野の問題が深刻化している。例えば、介護職員が不足する問題、受け入れ先がない高齢者である介護難民の増加、介護現場での虐待など様々である [35]。

このような問題意識に基づき、介護施設に入居する前の人々に対する相談サービスを行うコールセンターの記録データを分析することで、「コールセンター」「介護施設」「相談者と入居者」の三者にとって有用な知見を取得する。分析に用いたデータは、相談者1名に対し1行、「性別」や「介護度」のような属性を列とした、7,685行106列のデータである。分析方法として、結果に対して重要な要因を算出できるアンサンブル学習を用いて、傾向分析と将来予測を行う。この時、分析目的の設定として、データに関係する「コールセンター」「介護施設」「相談者と入居者」の3者に有力な知見を探索する。そうすることで、

- オペレータの業務の効率化（例：相談の進行方法，アドバイス方法）
- これから入居を考えている「相談者と入居者」にとっての参考（例：準備時期，内容，選

定方法の参考)

- 「介護施設」にとってビジネス上の参考 (例：見学して成約しない理由や、施設選びの決め手)

のためになる知見を得る。さらにこれらの知見から、改善策や解決策を考察する。その結果、(1) 欠損値があると進捗が進まない傾向にあること、(2) 「続柄」や「介護度」属性が成約に対して重要属性であること、(3) 入居決定の決め手は「介護サービス」ではなく、「きれいさ」や「印象」、「距離」であることがわかった。そして、(4) 相談者の情報から「見学するかどうか」を機械学習を用いて推定すると、精度が96.8%であることがわかった。

これらの結果は、ユビキタスコンピューティングの研究においても、有用な知見になりうる。例えば、自動運転やドライブ共有サービスとの連携による送迎の効率化が見学率を向上する可能性や、自宅における見守りシステムなどのセンサ出力から、介護施設に入居する必要があるかどうかを予知出来る可能性、自宅や、コールセンターのサービスにAIチャットボットシステムを組み込む事によるデータ収集および業務効率化の可能性が結果から示唆される。

本論文の貢献をまとめると、以下のようになる。

- 介護施設入居前の状況把握やサービス最適化を目的とし、7,685行106列の介護施設紹介コールセンターのデータを機械学習により傾向分析および将来予測を試みた。
- アンサンブル学習を用いて、重要項目と目的変数に対する相関を同時に可視化し、説明変数の2値化を行うことで、分析結果の理解を容易にした。
- 分析の結果、記録に欠損が多い人は成約に行かないことや、交通手段が見学に行くかどうかの重要な要因であること、「見学するかどうか」は機械学習による精度が96.8%であること、入居決定の決め手は「介護サービス」ではなく、「きれいさ」や「印象」、「距離」であることなど、10件ほどの知見を取得した。

3.2節では、データと分析方法について述べる。3.3節では、4種類のモデルの分析結果と各考察について述べる。3.4節では、全体の考察についてまとめ、3.5節で、この研究をまとめる。

3.2 分析データと手法

介護施設紹介コールセンターの記録データから分析を行う。まず、用いるデータについて3.2.1節で説明する。そして、3.2.2節で分析の目的を述べ、3.2.3節で分析概要を説明する。次

表 3.1 分析対象データの主な項目(カッコ内は因子の例を表す. 表中の ADL は, Activities of Daily Living (日常生活動作) の略称. CM=ケアマネージャー,MSW=メディカルソーシャルワーカー)

本人属性	年齢	数値型 (例: 85)
	性別	因子型 (男性, 女性)
	介護度	因子型 (例: 自立, 要支援 1, 要介護 3, 申請中, 未申請)
	現在地	因子型 (例: 在宅, 入院中, 施設入居中)
本人の状況	認知症有無	因子型 (あり, なし)
	認知症備考	テキスト型 (例: 会話の受け答えは可能だが, 物忘れが激しい)
	ADL 食事	因子型 (例: 自立, 一部介助, 胃ろう)
	ADL 歩行	因子型 (例: 自立, 一部介助, 杖歩行, 車イス)
	ADL 入浴	因子型 (例: 自立, 一部介助, 機械浴)
	ADL 排泄	因子型 (例: 自立, 一部介助, オムツ)
	たん吸引	テキスト型 (例: 1 日 3 回, 希望があるとき, 夜間もあり)
	インスリン	テキスト型 (例: 1 日 2 回)
	透析	テキスト型 (例: 週 3 回)
	主な病歴	テキスト型 (例: 高血圧, 白内障, 脳梗塞)
相談者について	続柄	因子型 (例: 父, 母, 配偶者, 兄弟, 友人知人, おじ, おば, CM, MSW)
	相談経緯	テキスト型 (例: 叔母様の入居相談で姪御様からお電話。いま入居中の施設から移りたいとご本人がおっしゃっている)
入居に関する希望	入居希望時期	因子型 (例: 2 ヶ月以内, 1 年以内, 出来るだけ早く, 未定)
	希望エリア	テキスト型 (例: 東京 23 区内)
	居室要望	テキスト型 (例: 居室では静かに過ごしたい, 2 人部屋希望, 夫婦部屋希望)
相談状況	進捗	因子型 (例: 相談, 資料, 見学, 体験入居, 契約)
	相談備考	テキスト型 (主に申し送り事項がフリーテキストで記録されている)
日時情報	受付日時	日付型
	最終更新日時	日付型

に 3.2.5 節と 3.2.4 節で分析に用いる変数の設定方法や生成方法について説明する。

3.2.1 介護施設紹介コールセンターの記録データ

本研究では, 介護施設探しに関する相談を受け付け, 施設紹介コールセンターの 2016 年中の記録データから, 無作為に抜粋したものを分析対象とした. 本データの内容はオペレーターが相談者から聞き取りを行った各種情報や, 相談者とのやりとりをオペレーター自身が記録したものであり, (1) 相談者 1 名につき 1 行で表され, (2) 106 個の項目をもち, (3) 7,685 行 106 列のデータである. オペレーターによる記録は, 主に次回相談の際の申し送りを目的に行われている. 項目には, 数値型や因子型 (離散的な値の変数), 日付型, テキスト型がある. 個人の特定につながる情報は匿名化されている. 表 3.1 に主な項目を示す. ADL は, Activities of Daily Living (日常生活動作) の略称である.

3.2.2 分析の目的

分析の目的は、表 3.2 に示したような、介護施設、将来の相談者や入居者、コールセンターに有用な情報を抽出することである。施設探しの方法は段階的なものがある。まず、施設や介護施設紹介コールセンターなどへの相談や資料請求がある。そして、実際に施設への見学をし、気に入れば成約をする。つまり、(1) 相談から見学へ進捗を進める段階 (2) 見学から成約に進捗を進める段階があると考えられる。本稿では、この2つの段階まで進捗を進める人がどのくらい存在し、また、どのような人が進めるのかを、相談者の情報から分析を行う。この分析結果、コールセンターの人にとって、効率的な相談進行のヒントになる。例えば、進捗が進まない原因がわかれば、相談方法の改善に役立てることができる。相談者にとっては、いつ頃から準備を行い、どのような準備を行うかの有用な知見となる。介護施設にとっては、見学から、契約しなかった人の傾向を知ることによって、サービスの質の改善につながる。また、(1) 見学施設の種別 (2) 成約施設の種別の2つのことを相談者の情報から推定できるのか、相関はどのようにあるのかを分析する。分析の結果は、コールセンターの人や相談者にとって、入居する際の参考、または、サービスの参考になる知見である。介護施設にとっては、入居者とのマッチング方法の知見になると考えられる。そうすることで、適切なサービスを入居者に提供でき、職員のストレスの負担を減らすことにつながる。相談者にとっては、施設選びの参考になる。これらの分析内容と登場人物（相談者、コールセンター、介護施設）の利点を表 3.2 にまとめる。つまり、本稿では介護施設紹介コールセンターの記録データを分析することで、介護施

表 3.2 介護施設紹介コールセンターに関する登場人物と分析における利点（行は登場人物を表し、列は分析内容を表す）

登場人物 \ 分析内容	進捗過程内に見学、成約が含まれるかの有無	見学施設や成約施設の種別の推定
コールセンター	効率的な相談進行の改善に有用な知見	相談者へのアドバイスの参考
介護施設	見学をして成約しなかった理由	施設と適切な相談者とのマッチング
将来的な相談者・入居者	準備の時期や内容に対する知見	施設選びの際に参考になる知見

設、将来的な相談者、入居者、コールセンターに有用な知見を取得する。さらに、扱うデータは介護施設に入居する前のデータであるため、現場のデータ分析とは違う観点から介護の分野で起きている問題解決に有用な知見を取得し、改善策の提案を試みる。本稿では、「見学したか

どうか」「成約したかどうか」「見学施設は介護付か住宅型か」「成約施設は介護付か住宅型か」の4つを分析目的を設定した。詳しい分析方法は次の節で述べる。まず、「見学したかどうか」「成約したかどうか」を記録データから傾向分析をする。例えば、見学した人は、部屋が綺麗かどうかを気にする人が多い傾向にある、などの知見を習得する。そうすることで、介護施設にとっては、入居してもらうために部屋のきれいさを意識するなどの改善案をすることができる。相談者には介護度が要介護3になったら入居を考える時期である点などの各登場人物にそれぞれの有益な情報の提示を行うことができる。また、「見学施設は介護付か住宅型か」「成約施設は介護付か住宅型か」を記録データから傾向分析する。介護施設には、他にも「サービス付」や「グループホーム」といった種別があるが、2つにした理由は以下の3.2.5節で述べる。介護付と住宅型の入居傾向は、介護サービスの質が異なるため、介護度による選択をする。しかし、「長期的なことを考えて」や「予算の計画設計」の難しさが複雑に混在している。したがって、機械学習による分析によって、コールセンターのサービスのアドバイスのしやすさの助けになると考えられる。もちろんこの知見は、相談者の施設決定に役立つ知見にもなりうる。以下の節では、分析の詳細について説明する。

3.2.3 分析の概要

介護施設紹介コールセンターの記録データから、(a)「見学したかどうか」、(b)「成約したかどうか」、(c)「見学施設は介護付か住宅型か」、(d)「成約施設は介護付か住宅型か」の傾向分析を行うために、アンサンブル学習法を用いて、重要因子と相関を同時に可視化する。分析環境には、R言語を用いて、XGBoost(eXtreme Gradient Boosting)ライブラリ [79] を用いて分析を行う。XGBoostとは、アンサンブル学習の1つで、決定木を弱学習器としたブースティングベースのアルゴリズムである。XGBoostはデータマイニングにおいてデータサイエンティストをつなぐプラットフォーム Kaggle で^{*1}注目を浴びている。さらに、データ分析の国際大会 KDD Cup 2015^{*2}で入賞した上位10チームすべてがXGBoostを用いた。

分析の概要を図3.1に示す。

全体的な分析方法の流れは以下のようなものである。

1. 説明変数集合を生成する (3.2.4節で説明)
2. 目的変数を生成する (3.2.5節で説明)

^{*1} Solutions come from of top-3 teams of each competitions.

^{*2} <https://biendata.com/competition/kddcup2015/>

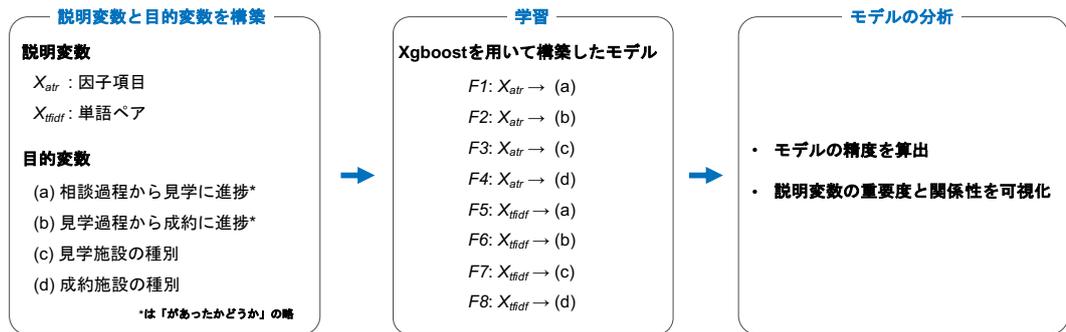


図 3.1 分析までの概要. まず説明変数と目的変数を定義し, 前処理を行う. そして, 全ての変数を用いて全組み合わせに対する学習を行い, 最後に 2 つの方法で分析する.

- 説明変数と目的変数の組み合わせ (図 3.1) を行い, それぞれでアンサンブル学習法を用いる
- 学習によって生成された関数モデル F を用いて変数重要度と相関関係を可視化する.

本章の以下の節では, 各過程について詳しく説明する.

3.2.4 説明変数の生成方法

説明変数集合は 2 つ生成した. 3.2.1 節のデータの中から, 「属性項目」の 35 種類のベクトル集合 X_{atr} と, 「相談経緯」項目からテキスト分析し TF-IDF を用いて生成した単語ベクトル集合 X_{tfidf} の 2 つである. これらを説明変数に設定することで, 目的変数にする重要な属性が分析できる. 以下では, 各説明変数の生成方法について述べる.

「属性項目」の 35 種類のベクトル集合 X_{atr}

3.2.1 節から, 今回用いるコールセンターデータは因子型, 数値型, テキスト型と, 主に 3 つの形式が存在することがわかる. この中で, 因子型を説明変数に設定した. なぜなら, 因子型は, テキストから生成される単語ベクトルと違い, 言葉の揺らぎがなく, また離散的な情報であるため, 決定木を用いた分析において表現の理解が容易であるからである. 以降, 因子型のデータで生成したベクトル集合を「属性項目群」と呼び, 各項目のことを属性と呼ぶ.

属性項目群は, 以下の 35 属性のベクトル集合の集まりである. 「続柄 1」 「性別 1」 「介護度 1」 「ADL. 食事 1」 「ADL. 歩行 1」 「ADL. 入浴 1」 「ADL. 排泄 1」 「続柄 2」 「性別 2」 「介護度 2」 「ADL. 食事 2」 「ADL. 歩行 2」 「ADL. 入浴 2」 「ADL. 排泄 2」 「利用期間」 「入居希望時期」 「移動手手段」 「相談経路」 「現在地 1」 「現在地 2」 「申請. 区

分変更 1」「申請. 区分変更 2」「見込介護度 1」「見込介護度 2」「医療行為有無 1」「医療行為有無 2」「認知症有無 1」「認知症有無 2」「AP ステータス」「AP 担当エリア」「問い合わせ施設以外の資料送付」「運営会社からの資料送付のアナウンス」「送付先」「連絡がいくことを」「資料が届くことを」

相談経緯テキストから生成した単語ベクトル集合 X_{tfidf}

「相談経緯」項目のテキスト部分には、相談者の相談目的や背景など、コールセンターとのやりとりの上で重要な項目が含まれると考えられる。しかし、テキスト型は、自然文で書かれているため、明確な目的や背景を抽出することは困難である。

そこで、先行研究 [29] で、我々は「相談経緯」項目のテキスト分析を行った。その結果、形容詞の表現に相談者の相談内容や、希望する施設の条件が表れやすいということがわかった。例えば、「悪い」という形容詞の前には「足腰が」や「交通の便が」など相談者の悩みと考えられる情報が存在する。また、「良い」という形容詞の前には、「食事が」や「世話の」などの相談者が希望する施設の情報が存在する。この分析結果を参考に、本稿では「相談経緯」テキストから形容詞とそれに係る名詞単語のペアを作成し、そこから単語の特徴量をベクトルで表すことができる。TF-IDF 法を用いて単語ベクトルを作成した。この単語ベクトルを説明変数集合として用いる。

単語ベクトルを作成する概要は以下である。

1. 係り受け解析ツール Cabocha [74] を用いて、「相談経緯」テキストを係り受け解析する。
2. 係り受け解析した結果から、形容詞単語 W_a の抽出、
3. その形容詞単語 W_a に係る節から名詞単語 W_n を抽出
4. その形容詞単語 W_a と名詞単語 W_n のペア W_p を作成し、1つの単語と見なす。(以降ペア単語と呼ぶ。)
5. 形容詞単語 W_a と名詞単語 W_n とペア単語 W_p を並べた単語列を、TF-IDF 法を用いて文章と単語の行列を生成する。
6. 作成された行列からペア単語 W_p のベクトルを抽出した行列を X_{tfidf} とする。

TF-IDF 法とは、単語の特徴量をベクトルで表す単語ベクトル表現である。TF とは Term Frequency の省略語で、各の単語が文書内でどのくらい出現するかの出現頻度を表す。つま

り、同じ文章内に多く出現する単語は重要であると仮定しているもので、式で表すと、

$$tf(t, d) = n_{t,d} / \sum_{s \in d} n_{s,d}$$

となる。 $tf_{t,d}$ は文書 d 内のある単語 t の TF 値、 $n_{t,d}$ は、ある単語 t の文書 d 内での出現回数 $\sum_{s \in d} n_{s,d}$ は文書 d 内のすべての単語の出現回数の和を表している。 IDF (Inverse Document Frequency) は、各単語がどのくらいの文章で出現するのかを表しており、その出現頻度が高い単語は重要でないと仮定している。式で表すと、

$$idf(t) = \log \frac{N}{df(t)} + 1$$

となる。 $idf(t)$ とは、ある単語 t の IDF 値、 N は全文書数 $df(t)$ はある単語 t が出現する文書の数を表している。

アンサンブル学習を用いて重要因子属性を分析する際、重要因子の属性名が単語のみだと分析が難しいことがある。例えば、「難しい」という形容詞単語が「見学するかどうか」を決定するのに重要な属性であるということがわかって、なにが「難しい」のかわからないため、分析は難しい。しかし、「歩行-難しい」というペア単語 W_p が重要項目であるという結果であると、因子項目の意味が容易に理解でき、分析しやすくなる。

また、ペア単語 W_p だけでなく、 W_a と W_n を含めて、1つの単語列とした理由としては、IDF の効果を効かせ、疎な行列表現となるのを防ぐためである。ペア単語 W_p のみの単語列としてしまうと、TF-IDF で生成される行列は1か0の疎な行列表現となってしまう。なぜなら、同じ文章内でも、他の文章でも同じ単語ペア W_p は存在しづらいという問題がある。したがって、IDF の効果を反映させるため、形容詞単語 W_a と W_n と W_p を含ませた単語列とし、TF-IDF 法を用いて行列を作成した。

TF-IDF の処理を行った結果、2793 単語、7683 行の単語行列が作成された。そのうちの単語数の内訳は、 W_p は 1236 単語、 W_a は 265 単語、 W_n は 1292 単語である。そこから、単語ペア W_p だけを抽出したため、1236 個のベクトル集合 X_{tfidf} が生成された。

3.2.5 目的変数の生成方法

目的変数は、(a)「見学したかどうか」、(b)「成約したかどうか」、(c)「見学施設は介護付か住宅型か」、(d)「成約施設は介護付か住宅型か」の4種類ある。以下では、これらの目的変数の生成方法 h について説明するが、(a) と (b)、(c) と (d) は生成方法はほとんど同じである。したがって、以下では (a) と (b) を進捗の経路 Y_{status} と呼び、(c) と (d) を施設の種別 Y_{type}

表 3.3 コールセンターとのやり取りが終了した時点の相談者の進捗状況と相談者の人数

3段階で分類した場合 属性の種類	第一段階		第二段階			第三段階	
	相談	資料	見学	仮申込	体験入居	契約	成約
各属性の件数(件)	497	84	104	7	2	11	207

と呼ぶ。これらの目的変数の設定理由は、3.2.2 で述べた通り、それぞれの目的変数の傾向分析を行うことで、コールセンター、相談者と入居者、介護施設の3人の登場人物に有用な情報を提供する。

以下では、これらの目的変数の生成方法について説明する。

進捗の経路 Y_{status}

進捗経路とは、相談者が相談から契約するまでに行う段取りのことである。段取りの種類は、「相談」、「資料請求」、「見学」、「仮申し込み」、「体験入居」、「契約」、「成約」がある。この段取りを3段階に分類すると、「相談」「資料請求」が第一段階、「見学」「仮申し込み」「体験入居」が第2段階、「契約」「成約」が第三段階である。この段階の定義はコールセンターのオペレーターの方に調査を行った結果である。この場合、最終段階が契約であり、コールセンターの最終目的であると言える。しかし、現実には、契約までいかず途中の段階でコールセンターとのやり取りを終了している状況が発生する。表 3.3 はオペレーターとのやり取りが終了した時点の相談者の進捗状況と相談者の人数を数え上げた結果を示している。

このように、第一段階で終了している相談者が多いことがわかる。また、第2段階で終了している相談者は全体の12%いることがわかる。そこで、相談者の進捗状況の違いの背景にはそのような原因があるのか分析することで、コールセンターのサービスの質の向上や、介護施設の改善などに有用な情報が得ることができると考えられる。

そこで、3.2.1 節から、「見学日付」が欠損値の有無で、(a)「見学したかどうか」を1,0の2値で表し、「成約日付」が欠損値の有無で、(a)「成約したかどうか」を1,0の2値で表す。そうすることで、2値分類の学習モデルを生成し、分析する。

相談者が見学、契約した施設の種別 Y_{type}

相談者が成約した介護施設名、また、見学した施設名は3.2.1 節のデータから抽出することができる。それと合わせて、各介護施設に介護施設種別をラベル付けされたデータが存在する。そのデータを統合させることで、各相談者の介護施設種別をラベル付けすることができる。そ

の介護種別の種類として、「グループホーム」「サービス付」「介護付」「住宅型」が存在する。

見学施設の記入があったサンプル数は7683件中1802件あった。見学施設のラベル割合は、以下となっている。

- グループホーム：5件
- サービス付：1件
- 介護付：1201件
- 住宅型：408件

その他187件は、見学施設はわかっているが、施設種別がラベル付けされていないものであった。

成約施設の記入があったサンプル数は7683件中238件あった。成約施設のラベル割合は、以下となっている。

- グループホーム：0件
- サービス付：0件
- 介護付：152件
- 住宅型：56件

その他30件は、成約施設はわかっているが、施設種別がラベル付けされていないものであった。

このことから、「グループホーム」、「サービス付」の件数は極めて少ないことがわかる。そのため、「介護付」「住宅型」を分類することに需要があると考えられる。介護付と住宅型の違いは、主に介護サービスが施設内に付属しているかどうかである。そのため、介護度が重い高齢者は介護付に入居するが、長期的な目でみたら、介護度が軽い高齢者も介護付に入居したほうがいい場合もある。また、費用的な部分でも、介護度によって月々の支払い額は変わってくるため、絶対的な決定指標にはなりづらい。したがって、相談者の情報から「介護付」か「住宅型」かを決定させる指標として、アンサンブル学習による傾向分析はからの結果は有用となると考えられる。

目的変数は「介護付」を0、「住宅型」を1とし、目的変数 Y_{type} を生成した。

3.2.6 アンサンブル学習を用いた分析

アンサンブル学習とは、弱学習器を多く用いて強学習器にする機械学習の1つの方法である。アンサンブル学習を分析に用いる利点として、目的変数を推定する際に重要な説明変数が可視化できる点である。例えば、文献 [55] は、介護施設の事故事例テキストデータから、事故の要因分析をアンサンブル学習を用いて分析をおこない、事故発生の原因として重要な要因を可視化した。本稿では、アンサンブル学習の中でも、最近データマイニング分野で注目を浴びている XGBoost を用いる。

しかし、重要因子は重要度によって分析できるものの、どのように重要かがわからない。例えば、説明属性「共有スペース」が重要であることがわかったものの、目的変数の「事故が起きること」か「事故が起きない」のかどちらに推定しやすい傾向にあるのかわからない。そこで、本稿では、R 言語の Partial Dependence Plot(PDP) ライブラリ [80] を用いる。PDP とは、説明変数属性が、目的変数を推定するとどのような相関で効いているのかを可視化する。この可視化されたグラフの傾きでどちらに相関が高いか判断できる。また、説明変数を2値にすることで、相関関係を簡単に表す。例えば、説明変数の「続柄」属性の属性値が「母」「父」「祖父」「祖母」の4つの属性値が存在していたら、「続柄.母」「続柄.父」「続柄.祖父」「続柄.祖母」の4つの属性を増やし、属性値を1と0で表現する。そうすると、説明変数「続柄.母」が1のとき、目的変数「見学をした」が1と推定されれば、PDP は右肩上がりの図を出力する。この右肩上がりの相関を「正の相関」と呼ぶ。反対に、目的変数「見学をした」が0と推定されれば、PDP は右肩下がりとなり、これを「負の相関」と呼ぶ。

本稿では、XGBoost を用いて、属性の重要度と正負の相関を同時に可視化し、分析する。その流れを以下に示す。

1. 学習用データの説明変数 x をベクトルに変換 (因子型の場合、因子項目値を分解しブール値に変換する)
2. 学習用データを XGBoost で学習し、関数モデル F を生成する
3. 関数モデル F から目的変数 Y に対する説明変数 X の重要度を出力する。
4. また、PDP を用いて、説明変数 X が正の相関があるのか、負の相関があるのかを出力する。

本稿の分析の特徴は以下である。

- 目的変数 Y と説明変数 X の入力を 2 値に変換することで、相関分析を簡単に表現する。
- 説明変数を 2 値にしたことで、重要項目表現の制限を広げる。
- 重要度とどのように重要かを同じ図に可視化することで分析しやすくする。

3.3 分析結果

本章では、前章で説明した分析方法の結果について述べる。目的変数を、(a)「見学したかどうか」(b)「成約したかどうか」(c)「見学した施設はどのような種別か」(d)「成約施設はどのような種別か」の 4 つ設定し、以下各節で分析結果を述べる。説明変数は、1. 相談経緯テキスト文から生成した形容詞特徴量ベクトル郡と 2. その他の属性郡、2 つの説明変数集合を用いた分析結果について述べる。

3.3.1 学習モデルの精度の概要

評価指標は以下の 2 つの指標を用いる。

- 正解率 *accuracy* : 推定された $\tilde{Y} = \{y_1, \dots, y_n\}$ がどのくらい正解か

$$w_0 + w_1 / w_0 + w_1 + z_1 + z_0$$

- BCR : 目的変数値ごとに精度を計算でき、かつ不均一な正例と負例のサンプル数にも影響されない指標 BCR(Balanced Classification Rate)

$$((w_0/w_0 + z_0) + (w_1/w_1 + z_1))/2$$

上記で w は推定結果が正しかったデータ数で、 z は間違えたデータ数を表している。そして、添字の値は、データの正解値を表している、つまり、正解値と推定値がともに 0 であるサンプル数は w_0 個、ともに 1 のデータ数は w_1 個としている。また、 z_0 は正解値は 0 であるのに、1 と推定したデータ数、 z_1 は正解値は 1 であるのに、0 と推定したデータ数を表している。BCR を用いた理由としては、サンプル数に影響されない精度であるため、今回のサンプル数に偏りのあるデータの評価に適している。この評価指標は、文献 [72] や文献 [73] にも用いられている。

以上の評価指標を用いて、図 3.2 に、各分類器の精度を示す。この評価方法は 3 重交差検証を行った。図 3.2x 軸において、a~d は正解率を、e~h は BCR を用いた精度となっており、目的変数を横軸にし、棒グラフの色を説明変数で表している。

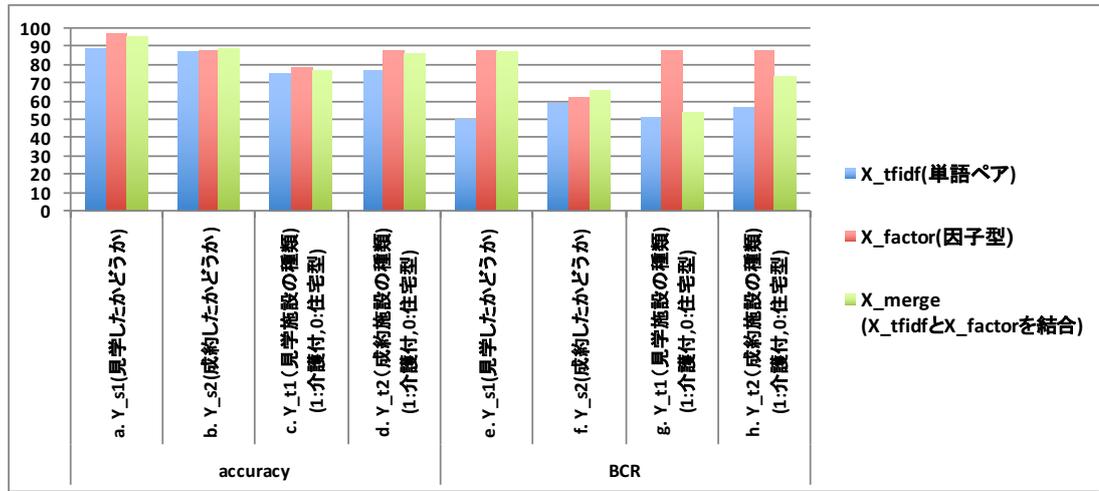


図 3.2 3重交差検証で各分類器を評価した結果 (x 軸において, a~d は正解率を, e~h は BCR, 青色が説明変数 X_{tfidf} , 赤が説明変数 X_{factor} , 緑色が X_{merge} を表す. 横軸は目的変数と, 精度指標を表す. 縦軸は精度 (%) を表す.)

また, データ数の偏りによる考察ができるように, 以下に図 3.2 の基になったコンフュージョンマトリックスを示す (表 3.4, 表 3.5, 表 3.6).

表 3.4 説明変数を属性郡 X_{atr} にした場合の混同行列

目的変数	見学したかどうか		成約したかどうか		見学施設が介護付き (0) か住宅型 (1) か		成約施設が介護付き (0) か住宅型 (1) か	
	0	1	0	1	0	1	0	1
予測値 →	0	1	0	1	0	1	0	1
正解値 = 0	6687	107	748	0	1201	0	152	0
正解値 = 1	193	696	108	33	364	44	26	30

表 3.5 説明変数を単語ペア群 X_{tfidf} にした場合の混同行列

目的変数	見学したかどうか		成約したかどうか		見学施設が介護付き (0) か住宅型 (1) か		成約施設が介護付き (0) か住宅型 (1) か	
	0	1	0	1	0	1	0	1
予測値 →	0	1	0	1	0	1	0	1
正解値 = 0	6794	0	748	0	1201	0	152	0
正解値 = 1	886	3	115	26	398	10	49	7

この結果から, 正解率はすべて 70% 以上であり, (a) 「見学するかどうか」の正解率は X_{atr} を説明変数とした場合, 96.8% と高い精度である. しかし, BCR による評価によると, X_{tfidf} を説明変数とした場合の精度が下がってしまっている. この原因として, 表 3.4 を見ると, 偏った推定をしていることがわかる. つまり, 相談経緯の特徴量ベクトルから, (a) 「見学する

表 3.6 説明変数を結合させたもの X_{merge} にした場合の混同行列

目的変数	見学したかどうか		成約したかどうか		見学施設が介護付き (0)か住宅型(1)か		成約施設が介護付き (0)か住宅型(1)か	
予測値→	0	1	0	1	0	1	0	1
正解値 = 0	6675	119	748	0	1201	0	152	0
正解値 = 1	208	681	97	44	374	34	30	26

かどうか」の分類はほとんど「見学しない」と推定されてしまう傾向にあるということがわかる。また、目的変数が (b)「成約するかどうか」と (d)「見学施設は介護付き (0)か住宅型 (1)か」の場合の精度に注目したとき、3つの説明変数のすべての BCR 精度が低いことがわかる。

また、説明変数が X_{merge} の場合と、それぞれの X_{tfidf} と X_{atr} との比較をすると、 X_{tfidf} が X_{merge} のどちらかが精度が高いという結果になっている。つまり、 X_{tfidf} を説明変数より、 X_{atr} の属性が分類しやすいということがわかる。特に、(a)「見学するかどうか」や (d)「成約施設の種別」に関して、 X_{atr} から推定することは難しいということがわかる。

したがって、重要因子項目の可視化分析は、 X_{tfidf} と X_{atr} の2つの説明変数のみでの結果を用いる。

3.3.2 目的変数「見学したかどうか」の場合の結果

見学したかどうかを分類する分類器を分析した。

結果

見学したかどうかを目的変数とし、説明変数は X_{atr} と X_{tfidf} を用いて重要属性の可視化分析を行い、各結果を図 3.3 と図 3.4 に示す。この結果は、説明変数の文字が多く、図に全体を表すと文字が見えないので、議論に必要な上位 20 項目のみを図 3.3 と図 3.4 に示す。

図 3.3 は「見学したかどうか」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図である。

表 3.3 の結果から、上位の属性の属性値が欠損値であるもの多く、負に相関することがわかる。また、「利用期間」属性に注目すると、属性値が「欠損値」は負に相関するが、「長期」となっているものは正に相関することがわかる。また、「続柄 1」属性に注目すると、属性値が「欠損値」「父」「義母」に関しては負に相関するが、「母」は正に相関することがわかる。そして、「移動手段」属性に注目すると、属性値が「欠損値」「電車」の場合は、負に相関し、「車」

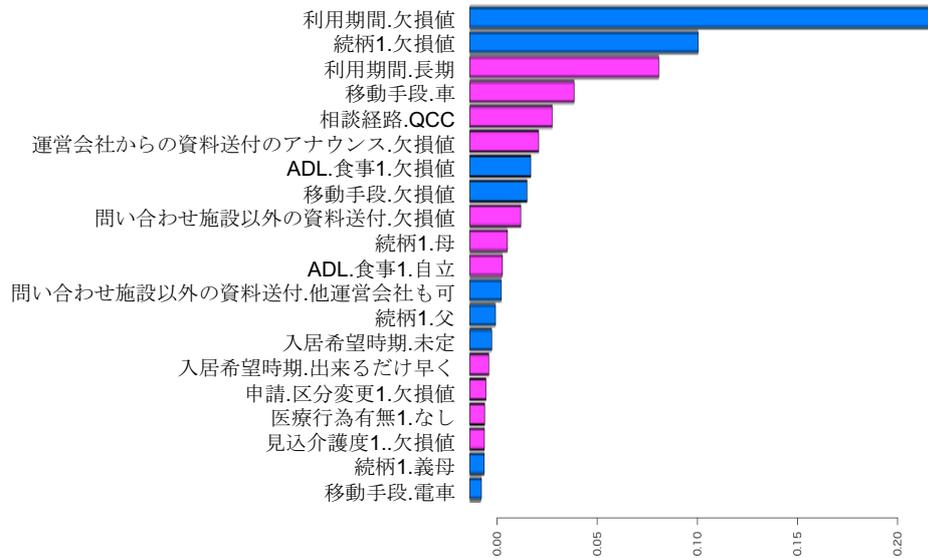


図 3.3 「見学したかどうか」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図 (目的変数:見学したかどうか, 説明変数:その他の属性項目 X_{atr} , 縦軸:属性名, 横軸:重要度, 棒グラフのピンク色の属性が正の相関を示し, 青色の属性は負の相関であることを示している.)

の場合は正に相関することがわかる。

図 3.4 は「見学したかどうか」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図である。図 3.4 と図 3.3 共に、縦軸:属性名, 横軸:重要度, 棒グラフのピンク色の属性が正の相関を示し, 青色の属性は負の相関であることを示している。

表 3.4 において, ほとんどの重要因子が正に相関することがわかる。重要な属性値として, 「一人暮らし-難しい」や「見学-いい」「時間-多い」「検討-難しい」の単語ペアがある。「一人暮らし-難しい」や「検討-難しい」は相談者の相談内容と推測できる。また, 「見学-いい」「時間-多い」などは相談者の希望であると推測できる。とくに, 「見学-いい」という属性値は重要度が高いことは納得できる。

考察

「見学するかどうか」を目的変数とした場合の考察をまとめる。表 3.3 の結果から, 見学をしない人は欠損値が多い傾向にあることがわかった。また, 見学をする人は施設の利用期間を長期に考えている人や移動手段が車である傾向にあることがわかった。これらの知見から, コールセンターは, より情報を聞き出すことで進捗を進ませ, 契約に近づけることが可能であると思われる。提案して, チャットボットで相談者と気軽な質問対応をすることが挙げられる。そ

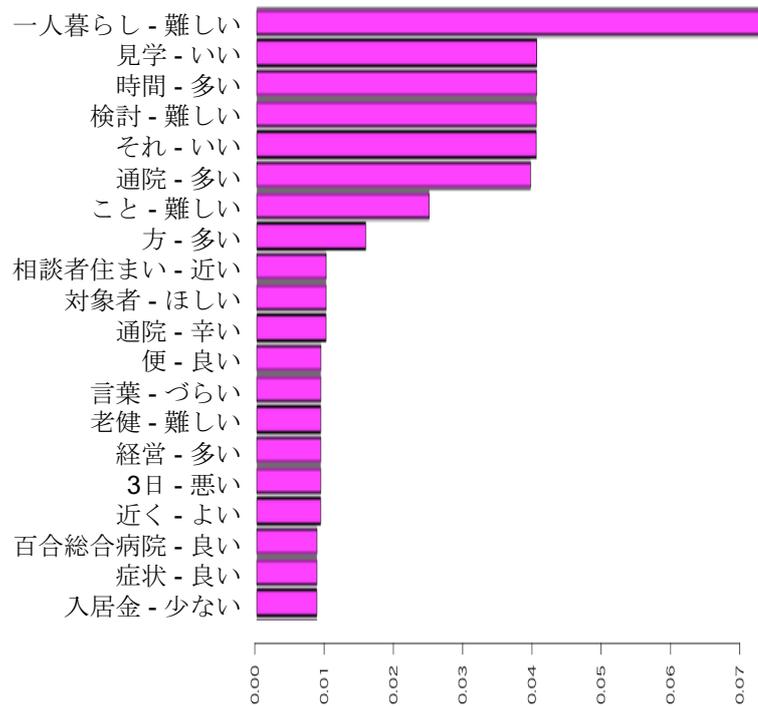


図 3.4 「見学したかどうか」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図（目的変数:見学したかどうか, 説明変数:「相談経緯」テキストから作成したペア単語行列 X_{tfidf} , 縦軸:属性名, 横軸:重要度, 棒グラフのピンク色の属性が正の相関を示し, 青色の属性は負の相関であることを示している.))

うすることで, コールセンターにとって人件費削減, データ収集などのいい点がある. また, 図 3.2 の結果より, 見学するかどうかは属性情報から高い精度で判断できることがわかっている. そこで, 今回生成した関数モデル F を用いて AI チャットボットとし, 「見学をする意思があるか」を自動で判断できる可能性がある. また, 移動手段が車である場合は, 見学に行く傾向であることがわかった. このことより, 送迎バスなどの見学を促す仕組みがあれば, 見学者は増加すると考えられる.

また, 図 3.4 の結果から, 相談経緯から, 「一人暮らし-難しい」という単語ペアが現れると見学する傾向にあることがわかった. しかし, 相談経緯に「一人暮らし-難しい」の現れるサンプルデータの「追客備考」テキスト項目を見てみると, その後成約しない傾向にあることがわかった. その原因は, 入居が本人の意思でないことであった.

3.3.3 目的変数「成約したかどうか」の場合の結果

成約したかどうかを分類する分類器を分析した。

結果

成約したかどうかを目的変数とし、説明変数は X_{atr} と X_{tfidf} を用いて重要因子可視化分析を行い、各結果を図 3.5 と図 3.6 に示す。この結果は、説明変数の文字が多く、図に全体を表すと文字が見えないので、議論に必要な上位 20 項目のみを図 3.5 に表す。

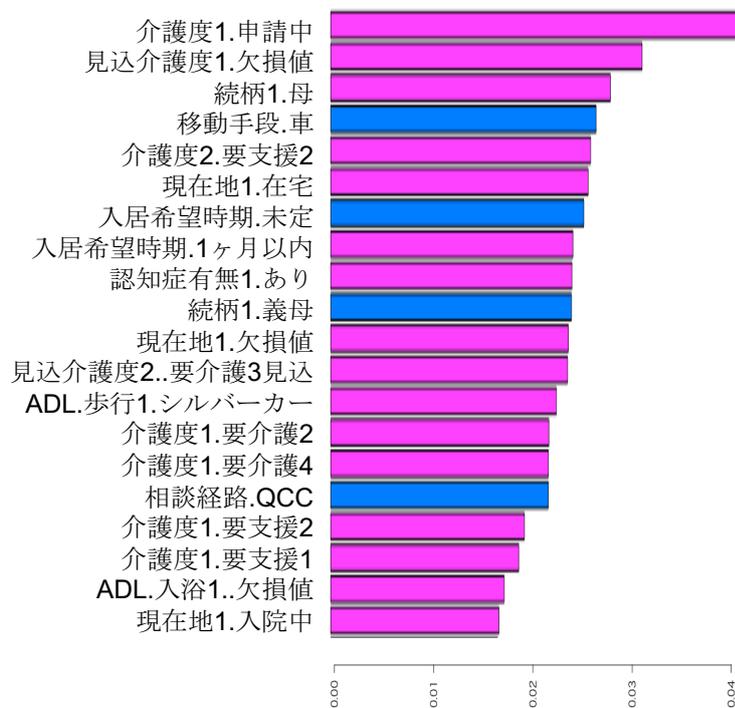


図 3.5 「成約したかどうか」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図 (目的変数:成約したかどうか, 説明変数:その他の属性項目 X_{atr} , 縦軸:属性名, 横軸:重要度, 棒グラフのピンクが正の相関示し, 青色の因子は負の相関であることを示している.)

図 3.5 は「成約したかどうか」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図である。

表 3.5 の結果から、全体的に入居者の状態を表す属性が重要な因子であることがわかる。例えば、「介護度」「現在地」「認知症有無」「ADL.入浴 1」が入居者の状態を表す属性に該当する。この中で、「介護度」属性に注目すると、すべての属性値で正に相関することがわかる。ま

た、「現在地」属性に注目すると、「在宅」「入院中」が成約の正に相関することがわかる。また、「入居希望時期」属性に注目すると、属性値が「未定」であると、負に相関し、「1ヶ月以内」だと、正に相関することがわかる。また、「入居希望時期」属性に注目すると、「できるだけ早く」「1ヶ月以内」は正の相関であり、「2ヶ月以上」「3ヶ月以上」は負に相関することがわかる。図3.5の結果から、「続柄1」属性に注目すると、「義母」「義父」「本人」は負に相関し、「母」「父」「祖母」「祖父」は正に相関することがわかる。



図 3.6 「成約したかどうか」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図 (目的変数:成約したかどうか, 説明変数:その他の属性項目 X_{tfidf} , 縦軸:属性名, 横軸:重要度, 棒グラフのピンク色の属性が正の相関を示し, 青色の属性は負の相関であることを示している.)

図 3.6 は「成約したかどうか」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図である。図 3.6 と図 3.5 共に、縦軸：属性名、横軸：重要度、棒グラフのピンク色の属性が正の相関を示し、青色の属性は負の相関であることを示している。

図 3.6 の結果から、すべての重要因子が正の相関を示している。重要属性を見ると、「介護-難しい」「二人きり-難しい」「身寄り-ない」などの相談内容が上位にきていることがわかる。また、「相場-高い」「資金-厳しい」「入居金-少ない」などのお金の相談が多いことがわかる。

考察

表 3.5 の結果から、上位に「介護度」属性が存在し、すべての属性値に対して正に相関することから、介護度は入居時に必要な情報であると考えられ、実際に介護度を知っておく必要がある。さらに、介護度が低いから入居できないということはないことも示している。介護度について、詳しく考察するため、今回のデータから図 3.7 のような、比較図を作成した。横軸は成約したかどうか、縦軸はサンプル数、棒グラフの色は介護度を示している。「介護度」属性が自立と判定されても入居している人は存在することがわかった。そして、自立の人で成約した人の割合は 5% いることがわかった。この割合は、申請中が一番高く 25% であり、自立の確率は低いが、受け入れてくれる介護施設は存在している。この知見は、今後の相談者や入居者の介護施設を考えるタイミングのアドバイスになると考えられる。

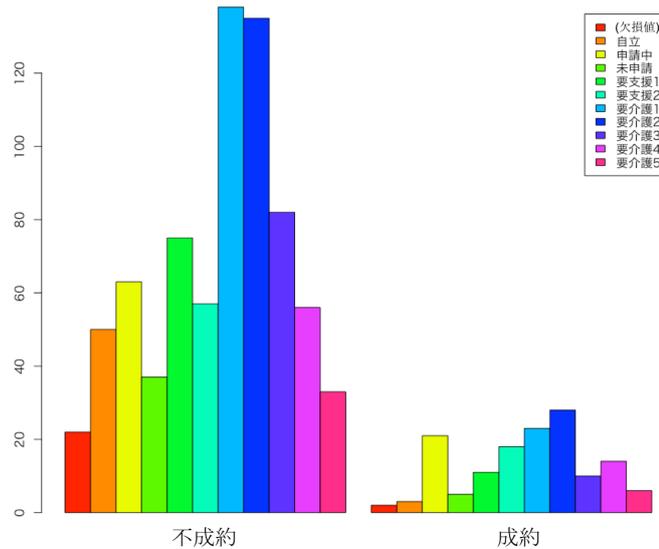


図 3.7 介護度と成約したかどうかの比較図（横軸は成約したかどうか、縦軸はサンプル数、棒グラフの色は介護度）

「現在地」属性に注目すると、「在宅」「入院中」が正に相関することから、家での一人暮らしが寂しい、もしくは、退院後の場所として介護施設に入居したいという背景が伺える。実際に「相談経緯」テキスト項目から、「退院後入居したい」や「一人暮らし」などの単語が含まれると成約する対象者でいることがわかった。

「入居希望期間」属性に注目すると、「2ヶ月以上」を境に契約する傾向かどうかがわかれている。これは、入居者は1ヶ月以内で決めたいという差し迫った状態だと、入居を1ヶ月の間で決めてしまう傾向にあると考えられる。実際にデータの調査を行うと、「入居希望時期」属性が「1ヶ月以内」「出来るだけ早く」としているサンプルの成約率は8%であったのに対して、それ以外のサンプルの成約率は2%と約4倍も違うことがわかった。また、「現在地」属性の考察と「入居希望期間」属性を合わせると、「入院期間が終わるから、1ヶ月以内で入居したい」や、「一人暮らしで心配だから、出来ればすぐ入居させたい」という背景が考えられる。他の介護入居に関する調査 [81] では、十分な準備期間がないままに入居検討を迫られることが多い、ということがわかっている。つまり、もっと介護施設検討時期を設けることが、介護施設入居後も安心した生活が過ごせると思われる。

また、「続柄」属性が、「義母」「義父」「本人」は負に相関し、「母」「父」「祖母」「祖父」は正に相関することから、「続柄」によっても成約に影響があることはわかる。この違いを分析し、提示すること、もしくは類似の相談者状況を提示することで、成約への意識の変化があるかもしれない。例えば、「続柄」が本人である場合、成約した相談内容の提示をすることで、「同じような人がいる」という安心感から、成約に至ることが可能性としてはある。

また、図 3.6 の結果から、「介護-難しい」「二人きり-難しい」「身寄り-ない」などの相談内容をする人の契約率が高いことがわかる。特に、「二人きり-難しい」「身寄り-ない」といった人間関係に悩む背景を持つ相談者が介護施設を必要としていることがわかる。

3.3.4 目的変数「見学施設はどのようなタイプか」の場合の結果

見学施設の種別が「介護付 (0)」か「住宅型 (1)」かを分類する学習器を分析した。

結果

見学施設の種別が「介護付 (0)」か「住宅型 (1)」か、を目的変数とし、説明変数は X_{atr} と X_{tfidf} を用いて重要因子可視化分析を行い、各結果を図 3.8 と図 3.9 に示す。この結果は、説明変数の文字が多く、図に全体を表すと文字が見えないので、議論に必要な上位 20 項目のみ

を図 3.8 に示す。

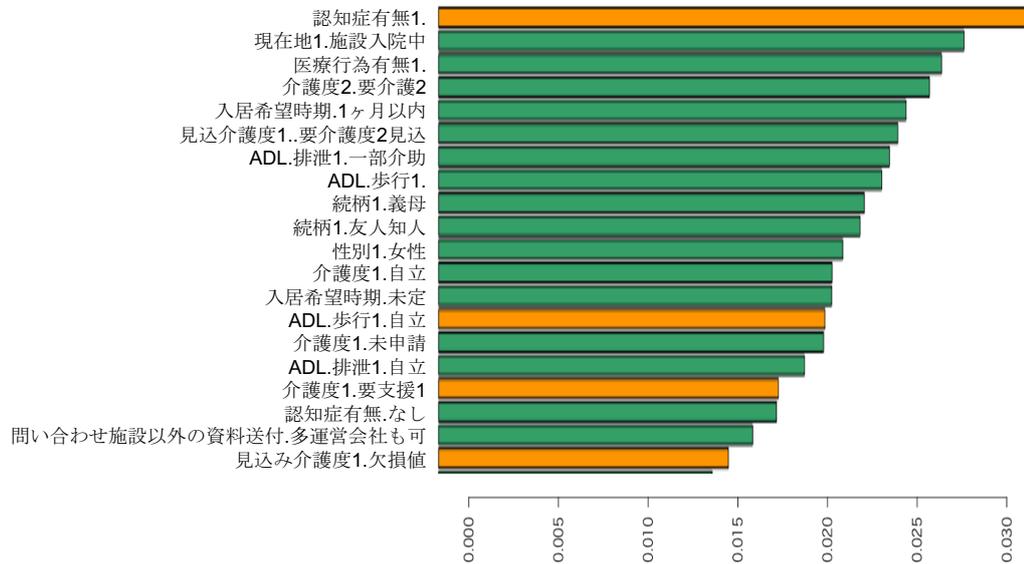


図 3.8 「見学した施設が「介護付き」か「住宅型」か」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図（目的変数:見学した施設が「介護付き」か「住宅型」か，説明変数： X_{atr} ，縦軸：属性名，横軸：重要度，棒グラフの黄色が「介護付」の相関を示し，緑色が「住宅型」の相関を示す）

図 3.8 は、「見学した施設が「介護付き」か「住宅型」か」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図である。

表 3.8 の結果から，入居対象者の状態を表す属性が上位に多く存在することが分かる．とくに、「認知症の有無」に注目すると，属性値が「欠損値」だと介護付きに相関があり，「なし」だと住宅型に相関があることがわかる．他にも「介護度」や「ADL」という単語を含む属性が重要であることがわかる．「介護度 1」に注目すると，要支援は介護付き，自立は住宅型に相関があることがわかる．

図 3.9 は、「見学した施設が「介護付き」か「住宅型」か」に対して X_{tffdf} を説明変数とした時の重要因子と相関を表した図である．図 3.8 と図 3.9 共に，縦軸を項目名，横軸を重要度，棒グラフの黄色が「介護付」の相関を示し，緑色が「住宅型」の相関を示す．

図 3.9 の結果から，まず，「費用」について悩んでいる傾向が見える単語ペアが 4 件存在する．それらの相談者は「介護付」を選択する傾向にあることがわかる．そして，「入居者の状態」について，介護が必要であることが想定できる単語ペアが 7 件存在し，「介護付」を見学していることがわかる．また，「距離」について悩んでいると想定できるのは 3 件存在することが

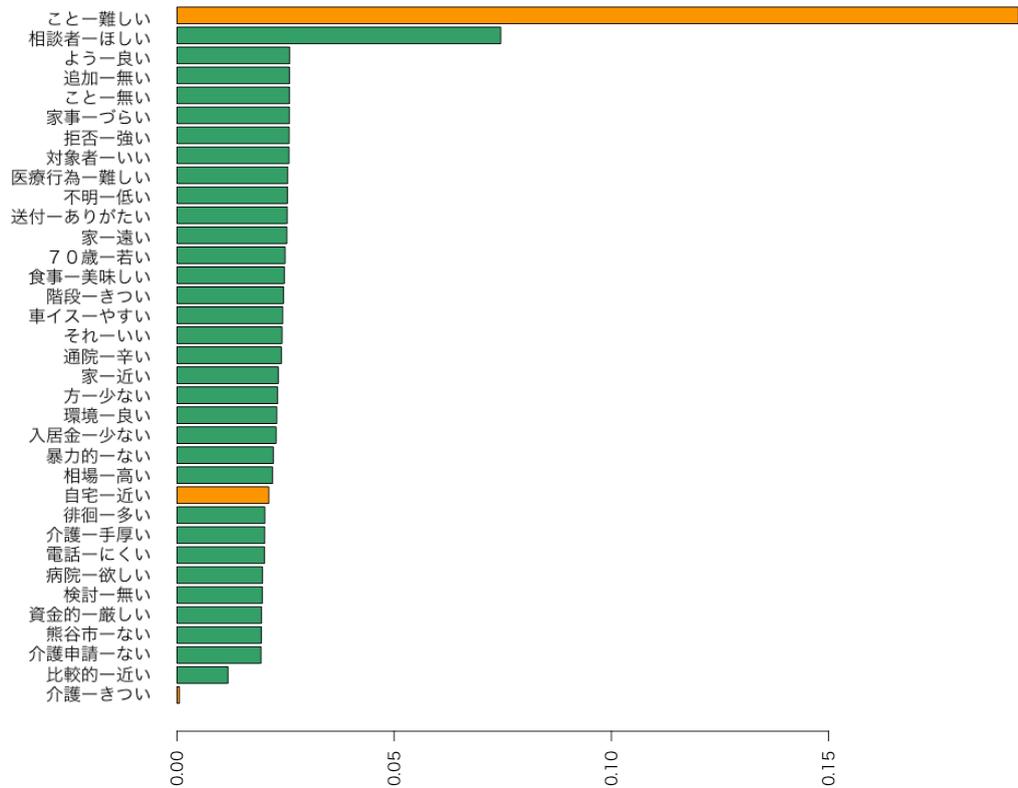


図 3.9 「見学した施設が「介護付き」か「住宅型」か」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図 (目的変数: 見学した施設が「介護付き」か「住宅型」か, 説明変数: X_{tfidf} , 縦軸: 属性名, 横軸: 重要度, 棒グラフの黄色が「介護付」の相関を示し, 緑色が「住宅型」の相関を示す)

わかった。

考察

一般的に、介護度が自立の人は「住宅型」を選択することがわかった。つまり、介護を重要視し、それに対応する施設を見学しているように思える。しかし、介護度によるものだと推定精度が高いと思われるが、図 3.2 によると推定結果は 60% 周辺で、あまり高いとはいえない。この原因として考えられるのは、入居できる施設は変わるわけではなく、「住宅型」も「介護付」も入居可能な介護度は制限がないところがほとんどである。したがって、介護がまだそこまで必要でない高齢者は将来的に「介護付」に入居することも考えられる。一方で、介護付より、住宅型のほうが、入居金が安いなどお金的な面や、図 3.9 の結果にも表れている、「距離」の条件も考慮すると、介護度が高くても「住宅型」に入居することもあり得る。つまりは、「介

「介護度」以外の面から施設種別を選択していることが考えられる。

3.3.5 目的変数「成約施設はどのようなタイプか」の場合の結果

成約施設の種別が「介護付 (0)」か「住宅型 (1)」かを分類する学習器を分析した。

結果

成約施設の種別が「介護付 (0)」か「住宅型 (1)」か、を目的変数とし、説明変数は X_{atr} と X_{tfidf} を用いて重要因子可視化分析を行い、各結果を図 3.10 と図 3.11 に示す。

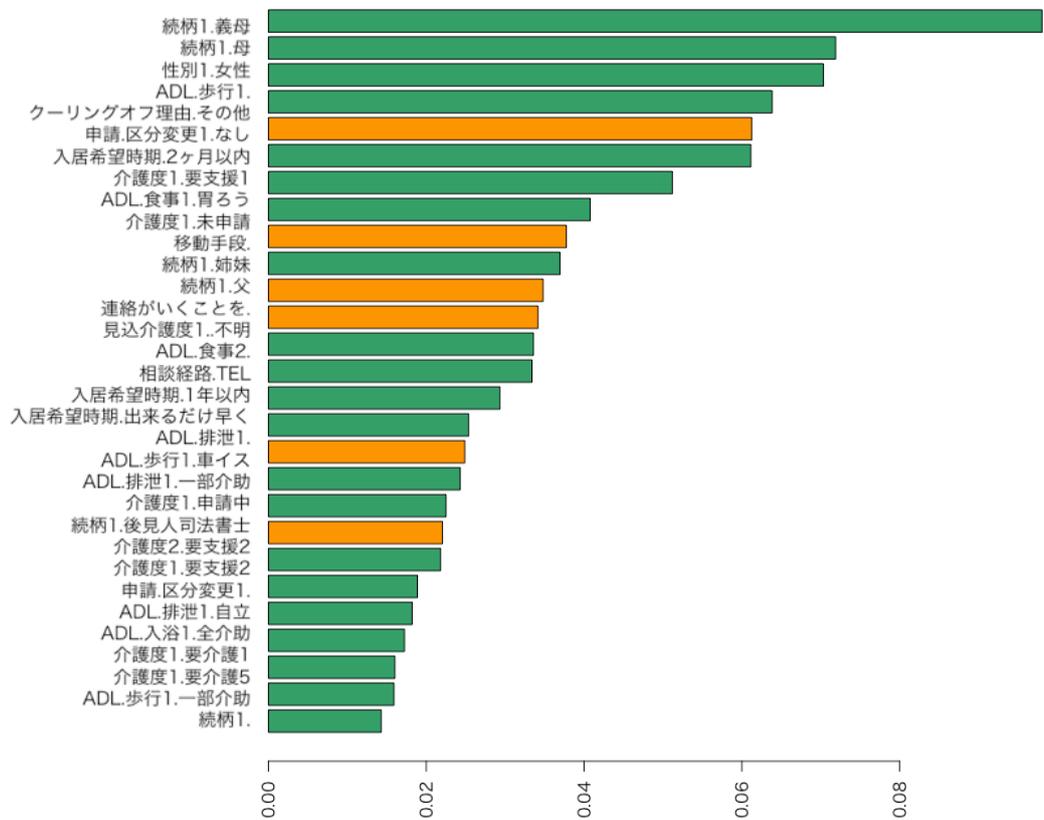


図 3.10 「成約した施設が「介護付き」か「住宅型」か」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図 (目的変数:成約した施設が「介護付き」か「住宅型」か, 説明変数: X_{atr} , 縦軸: 項目名, 横軸: 重要度, 棒グラフの黄色が「介護付」の相関を示し, 緑色が「住宅型」の相関を示す)

図 3.10 は、「成約した施設が「介護付き」か「住宅型」か」に対して X_{atr} を説明変数とした時の重要因子と相関を表した図である。

図 3.11 は、「成約した施設が「介護付き」か「住宅型」か」に対して X_{tfidf} を説明変数とし

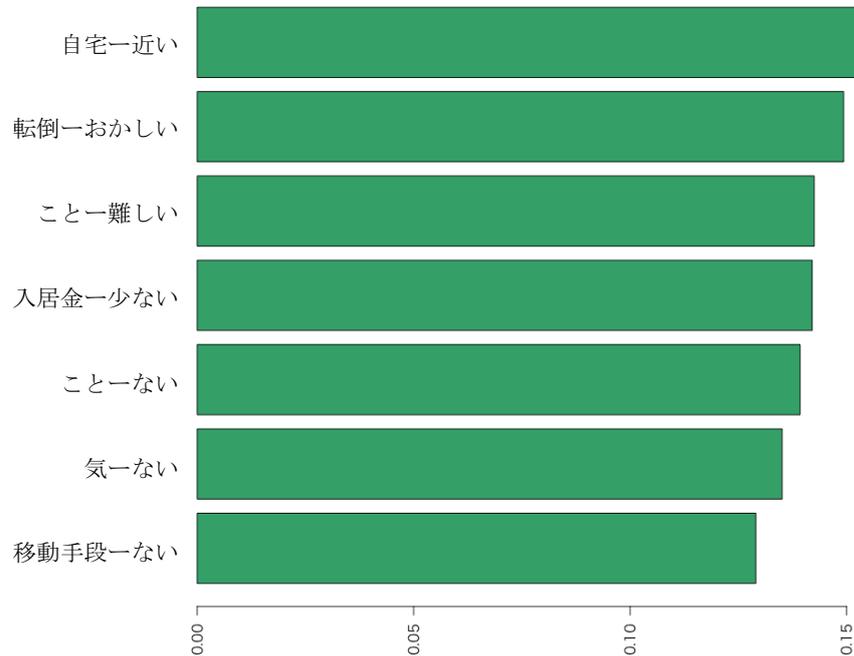


図 3.11 「成約した施設が「介護付き」か「住宅型」か」に対して X_{tfidf} を説明変数とした時の重要因子と相関を表した図（目的変数:成約した施設が「介護付き」か「住宅型」か, 説明変数: X_{tfidf} , 縦軸: 項目名, 横軸: 重要度, 棒グラフの黄色が「介護付」の相関を示し, 緑色が「住宅型」の相関を示す)

た時の重要因子と相関を表した図である。図 3.10 と図 3.11 共に, 縦軸を項目名, 横軸を重要度, 棒グラフの黄色が「介護付」の相関を示し, 緑色が「住宅型」の相関を示す。

図 3.10 の結果から, 上位に「続柄」属性が多く, 次に「介護度」や「ADL」のような入居者の状態を表す属性が多いことがわかる。「続柄」属性に注目すると, 「続柄. 義母」「続柄 1. 母」「続柄. 姉妹」は住宅型を成約し, 「続柄 1. 後見人司法書士」は介護付に契約する傾向にあることがわかる。また, 介護付に成約する傾向にある属性に注目すると, 「移動手段」「ADL 食事 2」「連絡が行くことを」などの属性が欠損値であることがわかる。

図 3.11 の結果から, 「自宅-近い」「入居金-少ない」などの施設の希望や「転倒-おかしい」という入居者の問題点と考えられる単語ペアがあることがわかる。

考察

図 3.10 の結果から, 女性が「住宅型」に成約する傾向があることがわかる。厚生労働省の調査によると, 女性の健康寿命と寿命の差は男性の健康寿命と寿命の差より 3 歳ほど長いことが

平成22年の調査でわかっている [82]。つまり、介護が必要な長さが女性のほうが長いということである。しかし、実際には介護付ではなく、住宅型に相関がある。その理由を「追客備考」テキスト項目から調査した。その結果、女性の施設入居の決め手は、「部屋のきれいさ」や「対応がいい」など直接的に感じる印象で決定しているからであると言える。

3.4 考察まとめ

前章の各節で行った考察をここでまとめ、そのまとめた結果から新たな考察をする。

まず、コールセンターにとって、有用な情報と考えられるのは、

- 見学するかどうかは、属性情報から高い精度で判定することができ、見学しないと判定される要因因子は、欠損値であるため、AIチャットボットのような、相談者が気軽に情報を提供しやすいシステムの導入が望まれる。
- 「二人きり-難しい」「身寄り-ない」という相談背景から成約する傾向があることがわかった。

次に、相談者や入居者に有用な情報であったのは、

- 介護度を調べることは入居時に必要な情報であるため、事前に知っておくのがよい。
- 介護度が「自立」の場合でも介護施設に入居している人は、5%存在する。
- 準備期間が1ヶ月以内に迫って入居をしている人と2ヶ月以上のゆとりをもって入居する人の成約確率は4倍もの差がある。
- 「入院期間が終わりそうだから、」や「一人暮らしになって心配だから」と入居を考えると、入居検討準備期間が短い
- 成約するかどうかは「続柄」属性が重要であることがわかった。

最後に、介護施設にとって、有用な情報であったのは、

- 「介護度」や「住宅型」の違いの面から考えて、見学施設の決定を行うことより、お金や距離的な面で選択する傾向にある人が多い。
- 女性が住宅型に決める傾向にあるが、施設の機能ではなく、「きれいさ」や「印象」が決め手になっている。
- 移動手段が車であると見学に行く傾向にあるため、見学の際の送迎のアクセスの改善が

進捗に効果的かもしれない。

これらの一環の考察として、「続柄」属性や「介護度」属性が成約に重要であることが多いことがわかった。これらのことから、「続柄」では「本人」「義母」「義父」などが成約に負の相関であったことから考察すると、相談できるコミュニティを作り相談し合うことで、同じような人がいる安心感や悩みの軽減が出来る可能性がある。施設決定の決め手として、「施設種別の傾向分析」から共に「距離」が重要であることが挙げられた。これは、入居条件が家族が住んでいる場所と近い場所にある施設で決めていると考えられる。しかし、そのような条件は施設の制限が強制されてしまう。今回の属性情報として、「交通手段」情報があるため、車で行くと簡単な範囲や、電車で行くと簡単な範囲という制限を広げる必要がある。そのため、施設探しとして、距離制限を交通手段によって変わるシステムの導入が望まれる。

また、今回の分析から、入居後のデータ分析では分かり得なかった知見も得られた。「二人きり-難しい」「身寄り-ない」という相談背景から成約を考えているケースがあることや「自立」でも入居している人は5%いるということから、これから「介護」の必要になった時期ではなく、早めの入居を考える人が増えてくることが考えられる。しかし、介護度が「自立」で入居可能な施設は少なく、公的な施設だとほとんどない [83]。

今回は、介護度や認知症の有無から、成約か見学をするかの将来予測を試みたが、コールセンターの業務では、顧客満足度が大切で、顧客の喜怒哀楽を読み取ることが大切な指標である。最近では、テキスト文から感情分析をする API もある [84]。つまり、喜怒哀楽を認識する感情分析をすることは、コールセンター業務改善に有用と考えられ、今後取り組むべき課題の一つである。

また、今回の知見と考察から得られたこととして、突然の一人暮らしや健康状態の悪化による、早急な入居が多いということがわかった。この急いだ入居は、経済的な準備不足や施設の検討が不十分の問題が考えられる。近年では、自宅においてセンサを用いた高齢者の一人暮らしを見守るシステムの研究がある [85]。これらのシステムにより、自宅の見守りシステムなどの出力から介護レベルを測定し、介護施設に入居する必要があるかどうかを予知できる可能性がある。この見守りシステムからの出力には、前述の AI チャットボットを自宅に導入し、そこから会話で得られる情報も含まれる。この研究の方向も、介護分野における重要な研究になると言える。

本研究における分析やその結果の解釈における注意点としては、本分析では、真の相関と偽相関を区別するところまでは立ち入っていない点である。結果につながる真の原因ではないの

に相関があるように見える、偽相関の要因に対して制御をかけても、結果が分析結果通りに影響するとは言えない。真の相関と偽相関を区別するには、また介護分野の専門家が入念にこれらの結果を精査することが必要であるが、少なくとも今回の知見は真の原因の候補を列挙できたと言える。

今回の知見から、介護分野における問題の「突然の退去命令」について考えた際、結果から突然の一人暮らしや健康状態の悪化による準備不足が原因にあると推測される。そのため、準備不足にならないためには、健康管理を日々行うことや、見守りシステムの導入が望まれる。また、「介護士による虐待」などの他の介護分野問題を解決するための考察をするには、まだ課題が残る。なぜなら、今回のデータは入居前の傾向を調べるのが目的で、入居後にトラブルが起きるかどうかの予測はさらなるデータが必要である。そこで、安価で手軽にデータ収集できるクラウドソーシング技術を活用することで、十分なデータが集まる可能性がある [86]。

3.5 まとめ

本稿では、介護施設紹介コールセンターの記録データをアンサンブル学習法を用いて、分析を行った。分析方法は、重要属性を棒グラフで、属性と目的変数の相関を色で、同時に可視化することで、考察を容易にした。また、説明変数を1と0の二値にしたこと、テキスト部分をペア単語としたことの2点も理解を容易にした点である。

分析内容は、(a)「見学したかどうか」(b)「成約したかどうか」(c)「見学する種別が介護付か住宅型か」(d)「成約する種別が介護付か住宅型か」を目的変数とし、1. 相談経緯テキスト文から生成した形容詞特徴量ベクトル郡と2. その他の属性郡、2つの説明変数集合を用いた。そうすることで、この4つの目的変数に対する相談者と入居者の傾向を分析し、「相談者と入居者」、「コールセンター」、「介護施設」の3者それぞれに有用な知見を取得する。

そこで、本稿では、介護施設に入居する前のサービスである介護施設紹介コールセンターのデータを分析し、施設入居前の状況を分析する。このデータは、相談者1名に対し1行、「性別」や「介護度」のような属性を列とした、7,685行106列のビッグデータである。このデータを分析することは、コールセンター、介護施設、相談者と入居者の3人の登場人物にとって有用な知見が得られることが期待される。例えば、「見学、成約する人はどのような人か、どのような傾向にあるのか」を分析することで、コールセンターにとっては、よりよいサービスの改善につながる可能性がある、というような知見が取得出来る。そこで本研究では、介護施設紹介コールセンターのデータを分析し、介護施設、相談者や入居者、コールセンターに有用な

知見を取得する。分析方法は、アンサンブル学習を用いて、説明変数の属性値を2値化し、属性の重要度と目的変数に対する正負の相関を同時に可視化した。

結果、コールセンターにとって、有用な知見として、欠損値が多い相談者は見学にいかない傾向にあること、移動手段が車だと見学に行く傾向にあることがわかった。相談者や入居者に有用な知見であったのは、介護度が「自立」でも入居している人は5%いること、準備期間が1ヶ月以内に迫って入居をしている人と2ヶ月以上のゆとりをもって入居する人の成約確率は4倍もの差があること、などが挙げられる。介護施設にとって、有用な情報であったのは、「二人きり-難しい」「身寄り-ない」という相談背景から成約する傾向があることがわかったこと、「介護度」や「住宅型」の違いの面から考えて、見学施設の決定を行うことより、お金や距離的な面で選択する傾向にある人が多いことなどが挙げられる。

それらの結果から、コールセンターのシステムとしてAIチャットボットシステムの導入の可能性や、施設探しのマップ機能として交通手段で変化する機能の可能性があると期待された。

今回は、実際に介護施設入居後にトラブルがあったのかどうかわからないという課題があるため、今回わかった知見を元に介護現場へのアンケートを作成し、安価で手軽にデータ収集できるクラウドソーシングでデータを活用することが重要であると考えた。

第4章

高齢者の睡眠と生活行動の相関分析 のためのセンシング実験

ここでは、介護施設に入居する高齢者のベッド上の行動を見守るデバイスのデータを活用し、高齢者の行動予測を行う研究について述べる。具体的には、日中と夜間の行動の相関関係を、機械学習を用いて分析をする。予測モデルの評価結果、深夜の睡眠状況から日中の運動を行うかどうかを92%の正答率で予測できた。分析の結果、日中の運動の有無と就寝時間に相関があるということ、などの介護士のサービス向上に繋がる知見を得ることができた。技術的な貢献としては、見守り用のベッドIoT製品のデータと介護記録のデータを組み合わせたデータ活用方法を示す。

4.1 はじめに

介護施設において、高齢者を効率よく見守るために、見守り装置が多く開発されている。しかし、現在のデバイスの多くは、事故が起きた後に発見されるものであり、未然に事故を防ぐことを目的としていない。そこで、既存の見守りシステムのデバイスから収集されるデータと介護記録データを用いて高齢者の行動を将来予測する予測モデルを用いたデータ分析を行う。具体的には、睡眠と日中の行動の相関分析し、入居者の生活改善や見直し、さらには介護士の見守り業務における効率化のために有用な知見を取得する。

データについて、人の動きを検知する非接触型生体センサをベッド付近に設置し、ベッド上の人の動きに関するデータを収集する。また、介護記録用のアプリを開発し、介護記録情報の収集も行う。収集期間は、4月1日から4月26日の26日間行い、被験者は85歳から98歳の

5人の男女に参加の同意を得ることができた。この結果、1人あたり11800サンプル×1440ファイル/日件のセンサデータと28業務種29674サンプルの介護記録を収集することができた。それらのデータから、「日中の運動と睡眠の相関」「日中の睡眠状況と深夜の睡眠の相関」を機械学習を用いて分析した。分析の流れは、原因と結果となり得る仮説の設定を行い、機械学習を用いて原因を入力、結果を出力とする分類モデルの構築を行い、交差検証法による推定精度の算出を行った。

その結果、個人差があるが、睡眠情報から、リハビリ・レクに参加するかを推定するモデルを構築したところ、92%の精度で推定することができた。また、日中の運動から、深夜の1時間毎のベッド上の動きが大きいかどうかの推定をするモデルを構築したところ、就寝時間周辺の推定精度が高く、起床時周辺の推定精度が低いことがわかった。これらのことから、日中の運動は就寝時間に影響し、起床時間には影響しないこと、睡眠状況により、リハビリやレクの参加率が変化することなどの知見が得られた。

本研究は、以下の貢献がある。

- 高齢者の睡眠と日中の生活行動に関して、機会学習を用いた相関分析を行った。その結果、睡眠と日中の運動との相関があることがわかった。このことから、介護士はその入居者に対して、積極的に運動を促すことで、同時にいい睡眠を促すことができると考えられる。
- 睡眠と生活行動における相関分析のための、介護施設に置いてセンシング実験を行った。これは我々が知る限り初めての試みである。

以下では、4.2節で、睡眠がもたらす影響と分析する意義について述べる。4.3節では、データ収集のための介護施設における実験と収集したデータについて述べる。4.4節で分析方法について述べ、4.5節で分析結果について述べ、4.6節で考察について述べる。そして、最後に4.7節でまとめる。

4.2 睡眠がもたらす影響と分析する意義

睡眠は、心身の疲労回復をもたらすとともに、記憶を定着させる、免疫機能を強化するといった役割を持っており、健やかな睡眠を保つことは、活力ある日常生活につながる。逆に、睡眠に障害が生じてしまうと、健康状態、生活習慣病、事故を引き起こす確率が向上する。例えば、アメリカの老人ホームでの実験によると入居者34,163人を対象に、睡眠と転倒の相関

の解析を行った結果、年齢、性別、機能状態、認知状態より不眠が転倒のリスクと関連することがわかっている [88]。さらに、認知症の症状がある人は、昼夜逆転の生活になりやすく、1時間程度の連続した睡眠も出来ないとされている [87]。

現在、日本人の20%は慢性的な不眠症であり、15%の人が日中に眠気を感じているという調査結果がある [63]。特に、高齢者の多くは睡眠障害を抱えており、睡眠不足 (DFA)、連続性障害 (SCD)、早期覚醒 (EMA)、日中の眠気 (DaSom) などの症状のいずれかに悩まされており、日中の眠気を感じる障害に関しては、死亡率との相関があるという調査がある [64]。睡眠障害の原因と考えられるものとして、環境や生活習慣によるもの、精神的・身体的な病気から来るもの、薬によって引き起こされるものなど、様々である [65]。そして、睡眠障害の治療法は、原因によって異なる。したがって適切な治療を受けるためにも、自分の睡眠状態や睡眠の問題を把握しておくことは重要である。

4.3 睡眠と生活行動のデータ収集方法

4.3.1 介護施設と実験概要

本節では、実験場所に使用した介護施設の概要について述べる。今回、北九州にある介護付き有料老人ホームでデータ収集のためのセンシング実験を行った。介護施設は、6階建ての建物で2階から5階までに入居用の部屋が存在する。1フロアには約13部屋から23部屋存在し、65人の人が入居している。平均年齢は、86.5歳で、最年少が53歳、最年長が101歳である。介護度は要支援1から介護度5までの人が入居しており、介護度1の人が最も多い。

分析に使用した睡眠データと生活行動データについて、そして収集方法について述べる。センシング実験概要を以下にまとめる。

- 2018年4月1日から4月26日の26日分のデータ (そのうち、1週間分のデータを分析)
- 85歳から98歳の介護度1以上の男女5人の被験者
- 睡眠の行動を把握するためにベッド付近に非接触生体センサを設置
- 日中の行動を把握するために介護士の介護記録用アプリを開発

結果、非接触生体センサデータを1人あたり11800サンプル×1440ファイル/日件、介護記録データから28業務種29674サンプルの介護記録を収集することができた。以下では、被験者の概要 (介護度などの情報と、1日の基本的な過ごし方)、焦電センサの収集方法、介護記録の

収集方法について詳細を述べる。

4.3.2 被験者の概要

本稿では、5名分の被験者データを分析する。5名の被験者の情報を表4.1に表示する。

表 4.1 被験者の情報 (年齢, 介護度, 入居日)

subject	年齢	介護度	入居日
被験者 1	95	介護 4	2009/6/18
被験者 2	96	介護 4	2010/3/1
被験者 3	85	介護 1	2010/4/29
被験者 4	97	介護 1	2014/6/3
被験者 5	98	介護 2	2012/11/7

入居者の1日の流れは主に以下の行動がある。

- 07時30分：朝食
- 08時30分：活力朝礼
- 12時00分：昼食
- 15時00分：おやつ
- 17時30分：夕食

上記に挙げた行動は全て共有スペースで行われ、それ以外は自由行動である。例えば、テレビを見て過ごしたり、共有スペースで談話をしたりして過ごしている。介護士はこの自由行動時間内で、清掃、介護記録、入浴介助、排泄介助など、多くの業務をこなす。業務内容について詳しくは、4.3.4節で述べる。

4.3.3 非接触生体センサ

本稿では、介護施設の入居者の睡眠状況を把握するため、ベッドの頭部に非接触生体センサを設置し、人の動きに関するデータを収集する。データ収集には、ルナナース*1というベッド上の人の動きを検知する製品を用いているが、本稿では製品としての利用はせず、焦電データ

*1 <https://ls.ipros.jp/product/detail/2000220155/>

を得ることだけを目的として使用する。図 4.1 は非接触生体センサを設置した時の構成図である。非接触生体センサの全長は高さ 1175mm, 横幅 815mm, 奥行き 483mm である。このデバイスをベッドの頭部分に設置し, 24 時間常にデータ収集を行う。

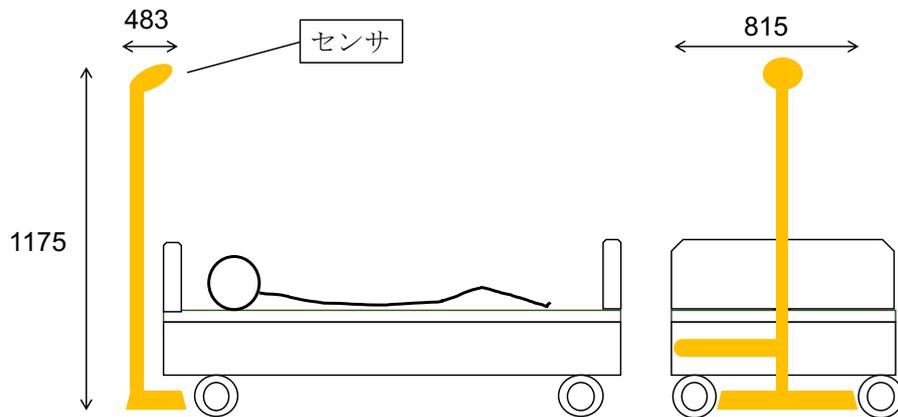


図 4.1 非接触生体センサの設置図

データ収集システムの大まかな流れは、非接触生体センサから焦電データを取得し、ラズベリーパイに保存していく。非接触生体センサは、センサ信号から雑音処理専用の LSI で演算した結果をデジタル出力 (USB) とアナログ出力する。デジタル処理の場合、人の動きを検知することが目的とする情報を出力し、本稿ではこのデジタルデータを収集する。本来製品としては、ベッド上の「起床」「端座位」「離床」のいずれかの行動を検知する見守りシステムであるが、今回の実験では、デジタルデータが収集できるように改造されたものを用いる。ルナナスから取得されるデータは、30Hz の周期で、二局の wav 型で出力される。このデータを、Ubuntu の arecord コマンド^{*2}で、2000Hz(最小値)の周期で、mp3 拡張子ファイルに書き込んでいく。ファイルは 1 分毎に、分けて保存していく。

その結果、118000 サンプル× 1440 ファイル× 3 ヶ月× 5 人分のデータを収集した。本稿では、5 人分の 1 週間のデータを分析に用いる。

4.3.4 介護記録アプリ

本実験では、介護士に介護記録をしてもらうためのアプリ^{*3}を開発し、介護士に使用してもらう。本稿では、その介護記録を分析に用いる。図 4.2 はアプリの画面を示しており、左側に

^{*2} <http://manpages.ubuntu.com/manpages/trusty/man1/arecord.1.html>

^{*3} <http://applion.jp/android/app/jp.sozolab.fonlog/>

業務を打ち込む画面，右側が詳細を打ち込む画面の例である。



図 4.2 介護記録用アプリ (左:介護業務選択画面， 右:詳細打ち込み画面の例 (バイタル業務の詳細))

今回の実験場所である介護施設は，これまで，紙による介護記録業務を行っていた．本研究室では，行動認識技術を活用し，介護記録の自動化を目指した研究に取り組んでいる．今回のセンシング実験では，睡眠データを収集すると並行して，介護記録のデバイス化の実証実験も行っている．介護記録の業務とは，介護士が入居者に対してどのような介助をしたのか，また入居者の状態はどうであったかという内容を事細かく記録するものである．記録する業務内容を表 4.2 にまとめる．

この介護業務記録アプリを用いることで，今まで紙で記録していた方法からスマホ操作に変化し，慣れる必要があった．本実験は，2月から操作に慣れてもらう期間をもうけており，練習として使用してもらっている．そのため，本稿では最も最近収集した4月1日から4月26日までのデータを分析する．

その結果，被験者5名に対するデータは，28種類の業務行動，29674サンプル数収集することができた．

表 4.2 業務内容と書き込む詳細の概要

業務内容	記載内容
バイタル	血圧, 脈拍などの記録の内容を記録
食事・服用	自立, 一部介助などの介助種, 食事量, 水分量などの摂取量, 服薬についての介助内容
口腔ケア	義歯洗浄の内容, 介助種
排泄	排泄方法, 介助種, 種類, 排泄量, 状態
入浴・清拭	入浴方法, 入浴介助
処置	傷や爪切りなどの処理, 部位
活力朝礼・ラジオ体操	参加したかどうか
リハビリ・レク	リハビリの内容, レクの内容
モーニングケア	離床, 洗面などの介助項目
日中利用者対応	フロア対応, センサコール対応などの種別, トイレ介助, コミュニケーションなどの対応内容
ナイトケア	洗面, 居室誘導などの介助内容
夜間利用者対応	巡回, センサコール対応などの種別, トイレ介助, コミュニケーションなどの介助内容
家族・来客対応	利用者面会, 荷物整理などの目的
外出対応	介助タクシーなどの種別, 外出場所
リネン交換	したかどうか
清掃・整理	場所

4.4 アンサンブル学習による分析方法

睡眠と日中の行動における原因と結果の関係について仮説をたて、アンサンブル学習を用いて検証を行う。アンサンブル学習とは、機械学習の一つであり、入力と出力の関係がある。入力部分に当たるデータのことを説明変数と呼び、出力部分に当たるデータのことを目的変数と呼ぶ。機械学習では、説明変数の情報から目的変数を予測するための最適な推定モデルを構築する。本稿では、相関があると考えられる仮説の結果と原因を設定し、それぞれを目的変数と説明変数として機械学習に与えることで、推定モデルの推定精度をもとに仮説の検証を行う。

本稿では、はじめに睡眠と日中の行動における原因と結果の関係について仮説を設定する。そして、アンサンブル学習を用いて、仮説の検証を行う。そして、本章では、4.4.1 節で仮説について説明し、4.4.2 節でアンサンブル学習に用いるデータの前処理方法について述べる。最後に、4.4.2 節で、アンサンブル学習をした結果をどのように分析するのかについて述べる。

4.4.1 睡眠と日中の行動における相関の仮説

表 4.3 では、睡眠と相関があると思われる要因を列挙し、今回のデータによって検証できるかどうかを示したものである。睡眠の質を向上させるためには、規則正しい生活、日中に活発に動くことなどが挙げられる。また、不安やストレスなどの精神状態や、睡眠の環境などにも

表 4.3 分析における仮説

仮説	検証可能かどうか	定義や理由	検証する意義
a) 日中の活動量と深夜の睡眠は相関がある	○	「活力朝礼. ラジオ体操」と「リハビリ・レク」を日中の活動量と定義	入居者や介護士にとって、活力運動などの行事参加に対する意識の変化に影響する知見となる。
b) 規則的な生活と深夜の睡眠は相関がある	△	「食事」や「起床」などの普段する生活行動の時間を元に規則的な生活かどうかを定義	入居者にとって、普段の生活の改善に役立つ知見となる
c) 日中の睡眠量と深夜の睡眠は相関がある	○	ベッド頭部に設置したセンサから得られるデータをもとに抽出した特徴量を睡眠量と定義	介護士にとって入居者の体調を管理する指標となる知見となる
d) 健康面と睡眠は相関がある	△	被験者の介護度や、バイタル情報をもとに健康面の情報を定義	介護の管理に対する指標となる知見となる
e) 精神的な状態と睡眠は相関がある	×	精神的な状態に関するデータの収集をしていないため	睡眠不調の原因かどうかがわかる
f) 痛みや体の不調と睡眠は相関がある	×	痛みや体の不調に関するデータの収集をしていないため	健康管理の指標となる
g) 睡眠場所の環境と睡眠は相関がある	×	睡眠場所の部屋の明るさや温度を睡眠環境情報と定義	部屋の改善に役立つ指標となる

睡眠の質は影響する。そこで、睡眠の質に相関のある要因として考えられるものを以下に列挙する。

まず、表 4.3 の仮説 a についての説明をする。例えば、日中よく運動をすると、深夜はいい睡眠ができ、またいい睡眠をすると、日中の行動は活発に動くことができるのではないかと考えられる。そこで、「活力朝礼. ラジオ体操」と「リハビリ・レク」を日中の活発な行動として定義し、深夜との睡眠との相関を検証する。また、これらの相関関係を検証することで、入居者にとって、「活力朝礼. ラジオ体操」と「リハビリ・レク」をする意識の向上に繋がることが期待できる。また、介護士にとっても、睡眠の管理や、「リハビリ・レク」の参加を促す指標になり、入居者の健康管理の助けになると考えられる。

表 4.3 の仮説 b について説明する。いい睡眠をするためには、規則的な生活を送ることが大事と言われている。そのため、規則的な生活がどれほど深夜の睡眠に相関があるのかを検証する。規則的な生活と判断する指標として、「食事」や「起床」などの普段から行う生活行動の時間を用いる。また、これらの相関関係や、規則的な生活行動について分析することで、入居者の生活行動の改善に有用な知見となる。

表 4.3 の仮説 c について説明する。人は歳をとると、夜の睡眠の質が落ちてしまうとされており、昼間のうたた寝や昼寝が増えてしまう。しかし、質のいい睡眠をとるためには、日中と深夜の睡眠のメリハリをつけることが大事だと言われている。そこで、ベッド周辺から得られたデータから、日中と深夜の睡眠の特徴量を抽出し、分析する。また、睡眠は高齢者にとっ

て健康の指標であるとも言われているため、これらのデータの分析をすることは、病院や診断の際にも有用な知見になると考えられる。

表 4.3 の仮説 d について説明する。精神的な不安やストレスは睡眠の質に影響するとされている。精神的なことが原因で不眠に相関が現れたら、それらの精神的な病気に対する処置が必要である。そのような健康面における観点から有用な知見が得られると考えられる。しかし、本稿では精神的な面に関するデータを収集していないため、今回はこの分析は行わない。

表 4.3 の仮説 e について説明する。体の痛みが原因で睡眠の妨げになっていることも健康状態と同様に相関すると考えられる。この知見を得ることができれば、寝る前の痛み留めの服用の有用な知見となる。しかし、本稿では被験者の痛みに関するデータを収集していないため、今回はこの分析は行わない。

表 4.3 の仮説 f について説明する。睡眠の環境の例としては、部屋の明るさや温度などがある。この相関分析による知見が得られたら、介護施設側にとって、部屋の環境に関する改善案の参考になると考えられる。しかし、本稿では部屋の環境に関するデータを収集していないため、今回はこの分析は行わない。

本稿では、これらの仮説を検証するために、センシング実験で得られたデータを検証に用いることを考える。次節では、これらの検証を行うために実験で得られた、焦電データと介護記録データを検証用データに変換する過程について述べる。

4.4.2 前処理

センシング実験で得られたデータを、前節の仮説項目を検証するためのデータに変換する。データと変換する内容については、図 4.3 に示す。

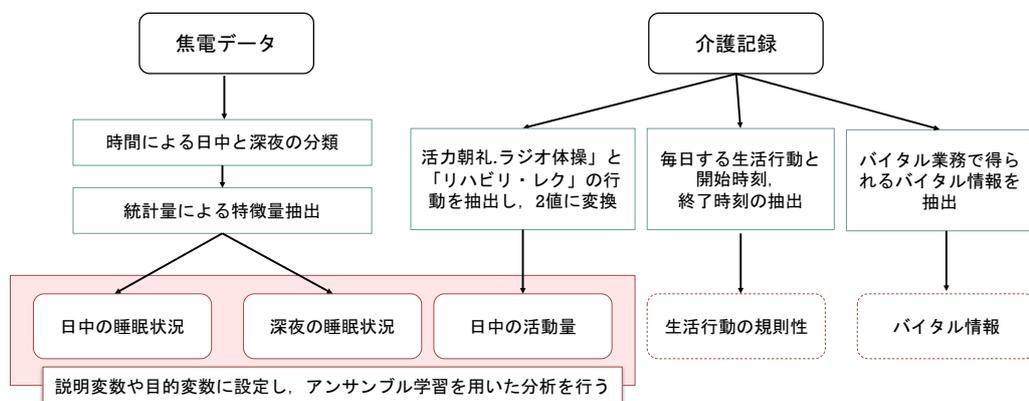


図 4.3 分析に用いるデータと前処理の(検証用データに変換する)流れ

焦電データから、日中の睡眠状態と、深夜の睡眠状態を示すデータに変換する。まず、1日中収集し続けたデータを日にちをもとに、深夜と日中に分類する。そして、睡眠状況における特徴量を抽出する。特徴量は、1時間毎に統計量を計算し、1時間毎の人の動きに関するデータに変換する。その後、中央値を閾値とし、2値のサンプルデータに変換する。

介護記録データから、日中の活動量、生活行動の規則性、バイタル情報を表すデータに変換する。しかし、今回の介護記録データから、生活行動の規則性とバイタル情報についてのデータは、データ不足と判断し、相関分析には用いていない。日中の活動量の前処理方法は、「活力朝礼・ラジオ体操」と「リハビリ・レク」の行動をしたかどうかの2値に変換する。

焦電センサデータの前処理

焦電センサデータは、1. 時間による日中と深夜の分類、2. 特徴量抽出、の順で前処理を行っていく。

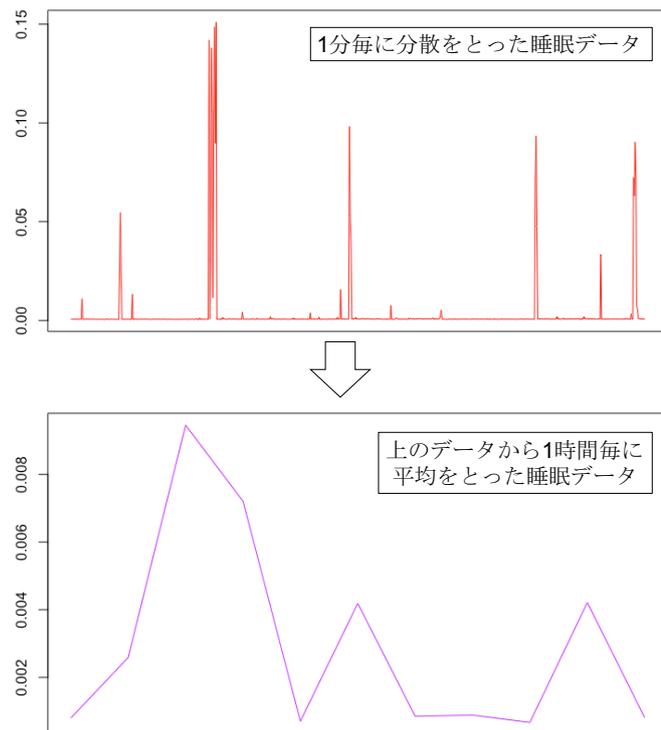


図 4.4 焦電データから特徴量をとったデータの例

まず、日中と深夜の時間の定義を 4.3.2 から、以下のように定義する。

- 夕食後から朝食までの時間を深夜、

- 朝食から夕食までの時間を日中.

そして、特徴量抽出の流れを以下の順で行う.

1. 時系列に並んだ2列のデータを, $-1 \sim 1$ の値に変換
2. 各列で1分毎に分散値を計算し, 足し合せ1列にする.
3. 1時間毎に, 平均値を計算する.

この特徴量抽出で得られたデータを可視化すると, 図4.4のようになる. その結果, 深夜時間帯で, 720次元, 日中時間帯で9732次元の多次元データとなってしまったため, 1時間毎に平均値をとり, 深夜の時間帯11次元, 15次元のデータに変換した.

その結果, 以下のデータが生成された.

- 被験者1:13日×11次元(深夜), 14日×15次元(日中)
- 被験者2:25日×11次元(深夜), 26日×15次元(日中)
- 被験者3:12日×11次元(深夜), 14日×15次元(日中)
- 被験者4:25日×11次元(深夜), 26日×15次元(日中)
- 被験者5:25日×11次元(深夜), 26日×15次元(日中)

介護記録の前処理

介護記録データから「日中の活動量」「生活行動の規則性」「バイタル情報」3つの検証用データを生成する. まず, 「日中の活動量」を表すデータの生成について, 以下の流れで行う,

1. 「活力朝礼.ラジオ体操」と「リハビリ・レク」のデータを抽出
2. 活動があった日は1, なかった日は0と変換する.

図4.5は, 「活力朝礼.ラジオ体操」と「リハビリ・レク」のデータを抽出した時点でのデータである.

また, 今回のデータからでは「生活行動の規則性」「バイタル情報」の検証データを生成することは難しいと判断した.

その理由として, 現在収集したデータは, 介護士が試験的にアプリを使用している状態であるため, 記録されていない行動が多くあることがわかった. 例えば, 食事の記録は, 毎日記録されているはずだが, 記録がない日がある. また, バイタル情報も同様の理由で, 被験者に対

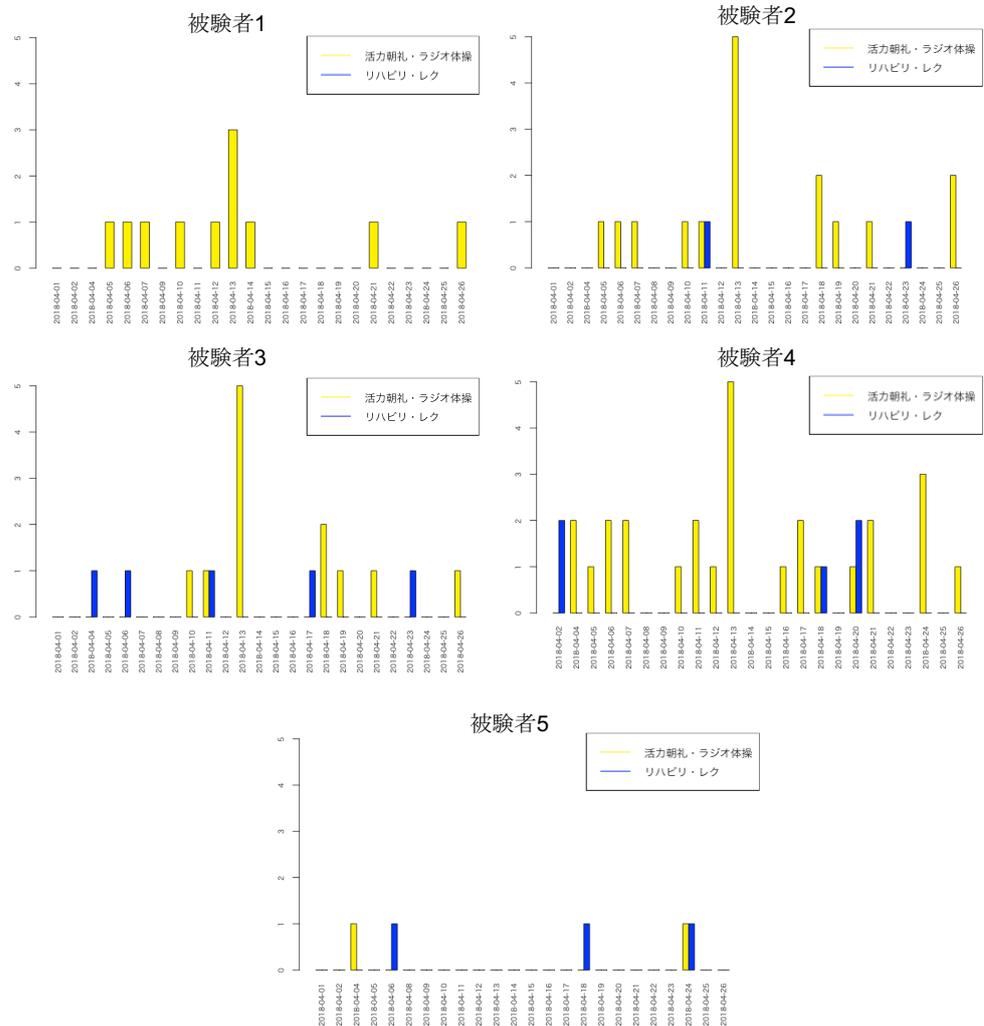


図 4.5 被験者の「リハビリ・レク」「活力・ラジオ体操」の行動回数 (横軸：日付, 縦軸：回数, 青：「活力・ラジオ体操」, 黄：「リハビリ・レク」)

するデータは存在しなかった。

次節では、今回生成することができた3つのデータを用いて、アンサンブル学習を用いた分析をする方法について述べる。

4.4.3 分析方法

上記で生成した、検証用データを用いて、アンサンブル学習を用いた分析を行う。分析目的は、以下の2つの仮説を設定し、それぞれ2つの分析方法を行い検証することである。

- 深夜の睡眠状況と日中の活動量の相関

- 深夜の睡眠状況から日中の活動量を予測し、精度を算出する.
- 日中の活動量から深夜の睡眠状況を予測し、精度を算出する.
- 日中の睡眠状況と深夜の睡眠状況の相関
 - 日中の睡眠状況から深夜の睡眠状況を予測し、精度を算出する.
 - 深夜の睡眠状況から日中の睡眠状況を予測し、精度を算出する.

本稿では、学習アルゴリズムは RandomForest を用いて、推定精度を算出することで、2つの相関仮説についての検証を行う。

表 4.3 の仮説 (a) を検証するために、深夜の睡眠状況を表したデータと、日中の活動を表したデータを用いる。分析方法は、2つのデータを日付を基準に結合させ、交差検証法を用いて、アンサンブル学習における推定精度を算出する。学習における設定は以下である。

- 深夜の睡眠状況を説明変数、日中の活動を目的変数と設定
- 日中の活動を説明変数、深夜の睡眠状況を目的変数と設定

この時、4.4.2 節で生成した 1 時間毎の特徴量を説明変数として用い、4.4.2 節で生成した 2 値のデータを目的変数として用いる。交差検証法は、「リハビリ・レク」をしたかどうか、「活力・ラジオ体操」をしたかどうか、の 2 つそれぞれで行う。また、日中の活動を説明変数とした場合、「リハビリ・レク」をしたかどうか、「活力・ラジオ体操」をしたかどうかの 2 つの特徴量をもつ行列を用いる。目的変数として、1 時間毎のデータに対して、中央値、平均値を閾値として、2 値に分類したデータを用いて、分類問題として交差検証法を用いる。

次に、表 4.3 の仮説 (c) を検証するために、深夜の睡眠状況を表したデータと、日中の睡眠状況を表したデータを用いる。分析方法は、2つのデータを日付を基準に結合させ、交差検証法を用いて、アンサンブル学習における推定精度を算出する。学習における設定は以下である。

- 深夜の睡眠状況を説明変数、日中の睡眠状況を目的変数と設定
- 日中の睡眠状況を説明変数、深夜の睡眠状況を目的変数と設定

この時、4.4.2 節で生成した 1 時間毎の特徴量を説明変数として扱う場合は、1 時間の統計値を特徴量とし、目的変数として扱う場合は、中央値、平均値を閾値として、2 値に分類したデータとし、分類問題として交差検証法を用いる。

評価指標は以下の 2 つの指標を用いる。

- 正解率 ACC : 推定された $\tilde{Y} = \{y_1, \dots, y_n\}$ がどのくらい正解か

$$w_0 + w_1 / w_0 + w_1 + z_1 + z_0$$

- BCR : 目的変数値ごとに精度を計算でき、かつ不均一な正例と負例のサンプル数にも影響されない指標 BCR (Balanced Classification Rate)

$$((w_0/w_0 + z_0) + (w_1/w_1 + z_1))/2$$

上記で w は推定結果が正しかったデータ数で、 z は間違えたデータ数を表している。そして、添字の値は、データの正解値を表している、つまり、正解値と推定値がともに0であるサンプル数は w_0 個、ともに1のデータ数は w_1 個としている。また、 z_0 は正解値は0であるのに、1と推定したデータ数、 z_1 は正解値は1であるのに、0と推定したデータ数を表している。 BCR を用いた理由としては、サンプル数に影響されない精度であるため、今回のサンプル数に偏りのあるデータの評価に適している。この評価指標は、文献 [72] や文献 [73] にも用いられている。

これらの結果を次章で述べ、考察を行う。

4.5 分析結果

本節では、以下の2つのことについて、分析する。

- 分析1 : 深夜の睡眠状況と日中の運動に相関があるかどうか
- 分析2 : 日中の睡眠状況と深夜の睡眠状況に相関があるかどうか

また、今回の分析は個人差を考慮しているため、被験者毎の結果を示して、それぞれの睡眠に相関のある要因を分析する。

4.5.1 深夜の睡眠状況と日中の運動に相関があるかどうか

本節では、深夜の睡眠状況と日中の運動の相関を分析するために、以下の2つの推定モデルを構築する。

- 分析1-1 : 深夜の睡眠状況から日中運動をするかどうかを予測
- 分析1-2 : 日中運動の有無から深夜の睡眠状況を予測

この2つの推定モデルを評価するために、交差検証法を用いて精度を算出する。

深夜の睡眠状況から日中運動をするかどうかを予測

分析 1-1 の結果を，図 4.6 に示す。

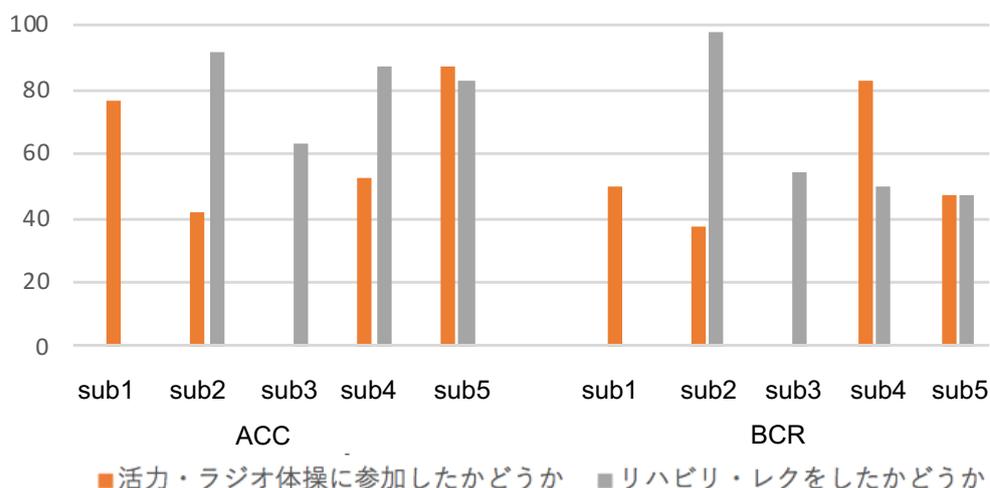


図 4.6 分析 1-1 におけるを推定結果（評価指標 ACC と BCR を使用，横軸被験者名，縦軸精度 (%)）

また，図 4.6 の詳細について，混合表を表 4.4 と表 4.5 に示す。

表 4.4 分析 1-1(目的変数:活力・ラジオ体操に参加したかどうか)における推定結果の混合表 (説明変数：深夜のベッド周りの焦電データを (分散値/分のベクトル) に加工したもの，目的変数：参加したかどうかの 2 値)

被験者	被験者 1		被験者 2		被験者 3		被験者 4		被験者 5	
予測値 \ 正解値	欠席	参加								
欠席	10	0	8	7	欠損	欠損	2	7	20	1
参加	3	0	7	2	欠損	欠損	4	10	2	0

表 4.4,4.5 の結果の欠損値は，参加したサンプルが 1 つ，もしくは存在しなかったため，評価できないと判断した。今回のデータは，参加するサンプルが少なく，偏りがあるデータであるため，BCR に焦点を当てる。図 4.6 から，「被験者 2 がリハビリ・レクに参加するかどうか」と「被験者 4 が活力・ラジオ体操に参加するかどうか」を予測する BCR は 80% 以上であった。表 4.5 を見ると，「被験者 4 が活力・ラジオ体操に参加するかどうか」の推定は全て欠席と答えていることがわかるため，推定精度は疑わしい。したがって，今回の分析結果から，被験者 2 において睡眠状況から「リハビリ・レクをしたかどうか」に向けて相関があると考えら

表 4.5 分析 1-1(目的変数:リハビリ・レクに参加したかどうか)における推定結果の混合表
(説明変数:深夜のベッド周りの焦電データを(分散値/分のベクトル)に加工したもの, 目的変数:参加したかどうかの2値)

被験者	被験者 1		被験者 2		被験者 3		被験者 4		被験者 5	
予測値 正解値	欠席	参加								
欠席	欠損	欠損	22	1	6	2	20	0	19	1
参加	欠損	欠損	1	1	2	1	3	0	3	0

れる。

日中運動の有無から睡眠状態を推定

分析 1-2 の結果を表 4.6 に示す。

表 4.6 から、最も高い精度は、被験者 1 の 20 時 (閾値が平均値) の推定結果であり、最も低い精度は被験者 3 の 5 時 (閾値が平均値) であった。ここで、時間帯に注目すると、20 時は就寝時間で、5 時は起床時間帯と考えられる。このことから、「運動したかどうか」は睡眠の就寝時間に相関があり、起床時間には相関がないと考えられる。また、目的変数を 1 日の平均とした時、被験者 1 の推定精度が一番高く、被験者 3 の推定精度が一番低いことがわかった。

4.5.2 日中の睡眠状況と深夜の睡眠状況に相関があるかどうか

本節では、日中の睡眠状況と深夜の睡眠状況の相関を分析するために、

- 分析 2-1: 日中の睡眠状況から深夜の睡眠状況を推定
- 分析 2-2: 深夜の睡眠状況から日中の睡眠状況を推定

この 2 つの推定モデルを評価するために、交差検証法を用いて精度を算出する。

日中の睡眠状況から深夜の睡眠状況を推定

分析 2-1 の結果を表 4.7 に表す。

4.7 の結果、最も精度の高いのは、被験者 1 の 18 時 (平均値が閾値) の推定結果と、被験者 2 の 21 時 (平均値が閾値)、被験者 3 の 22 時 (中央値が閾値) の推定結果であった。また、最も推定精度の低いのは、被験者 1 の 3 時、4 時 (閾値が平均値) と被験者 3 の 4 時 (閾値が平均

値)であった。また、1日の平均で最も精度の高いのは、被験者1で、最も精度の低いのは、被験者4であることがわかった。

深夜の睡眠状況から日中の睡眠状況を推定

分析2-2の結果について、表4.8にまとめる。4.8から、最も精度の高いのは、被験者3の7時(閾値が平均値)、9時(閾値が中央値)、14時(閾値が中央値)の推定精度であった。最も精度の低いのは、被験者3の15時(閾値が平均値)の推定精度であった。また、1日の平均値について、推定した結果、最も精度の高いのは、被験者5で最も低いのは、被験者3であることがわかった。

4.6 考察

上記の結果から、考察を行う。まず、分析1-1の結果、被験者2が、「リハビリ・レク」をしたかどうかを推定する場合が推定精度が高いことがわかった。なぜ精度が高いのかを考察するため、「リハビリ・レク」をした日の睡眠としていない日の睡眠の違いを図4.7に示す。

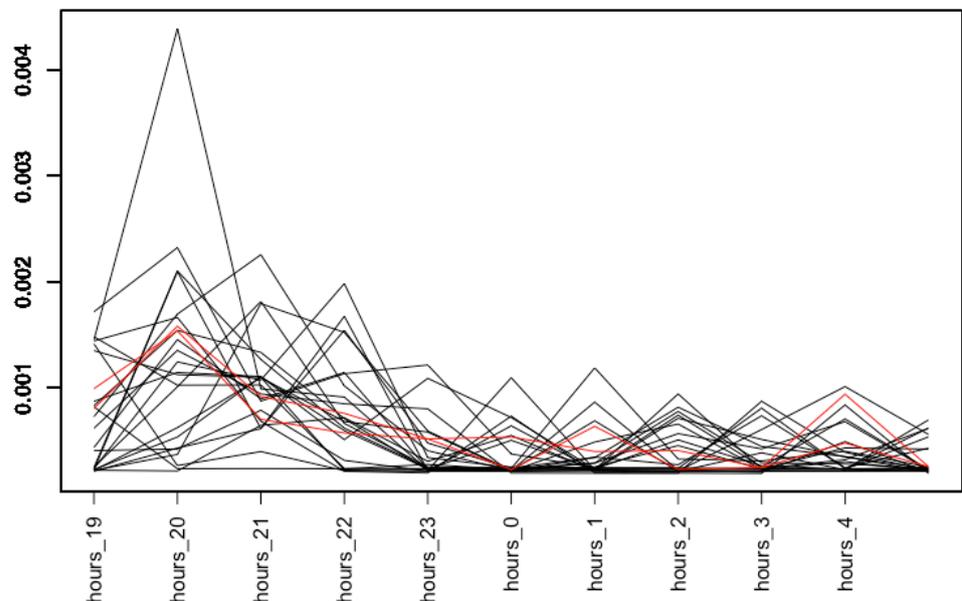


図4.7 被験者2の「リハビリ・レク」を行った日と行っていない日の睡眠の比較 (赤: 行った, 黒: 行っていない)

図4.7の結果から、赤い線は、20時を最大値とし、そのあと落ち着く傾向にあることがわか

る。推測として、20時あたりで睡眠につき、値が小さいことから、激しい動きはないということがわかる。つまり、20時に就寝し、そのあとある程度睡眠ができていると推測でき、しっかり寝たことで次の日の「リハビリ・レク」をする確率は高くなるということが考えられる。

次に、分析2-2の結果から、考察をする。結果より、精度の高かった時間帯と精度の悪かった時間帯の睡眠データをプロットして、比較する。

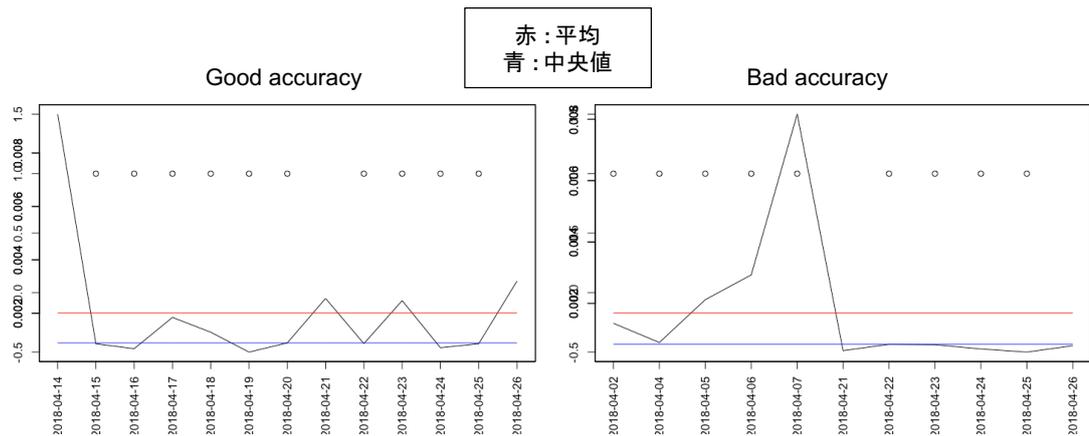


図 4.8 精度の高かった時間帯と精度の悪かった時間帯の睡眠データをプロット (横軸：日付, 縦軸：検証用データ, 赤色：平均値, 青：中央値, 点：活動があった日)

図 4.8 は、被験者 1 の 20 時の睡眠データと、被験者 3 の 5 時の睡眠データで、横軸を日付、縦軸を睡眠データの値としている。また、赤線は平均値、青線は中央値である。点は、活動が行われた日を表す。左側の精度の高い方のデータに注目する。活動をしたかどうかを表す点に注目した時、点がない（活動していない）部分は、閾値を超えている傾向にあることがわかる。このことから、活動をしていない日の睡眠は睡眠に動きがあり、よく眠れていないことが推測できる。

分析 1 の相関についての仮説について、まとめると睡眠状態に動きがないと、次の日は運動をする傾向にあり、運動を行っていない日の睡眠は動きがあり、いい睡眠ができていると推測され、相関関係があると考えられる。このことから、介護士は被験者 3 に運動を積極的に促すことで、健康的でいい睡眠を促すことができると考えられる。

次に、分析 2 についての考察を行う。表から、多くの推定精度は 50% 以下であることがわかる。つまり、今回の検証データでは相関を見つけ出すのは困難であると考えられる。睡眠と生活行動の分析を行う文献 [68] は、センサデータから「覚醒」「レム睡眠」などの睡眠指標に変換して分析を行っている。つまり、本稿と関連研究の分析データとして違う点は、以下の

ことがある。

- 仮説の結果として、1晩の睡眠というタイムスパンでないこと
- 今回の睡眠指標は2値であるが、過去の研究は睡眠指標に「覚醒」「レム睡眠」「ノンレム睡眠」などの指標を用いていること

さらに、日中の睡眠状態に関しては、さらに複雑であり、センサの反応があるから被験者本人なのかどうかを判断するのは難しい。また、ベッドの上にいるのかどうかまでは今回のデータからはわからない。そこで、ベッドに圧力センサを設置し、ベッドにいるのかどうかを判断するデータが必要であると考えられる。図4.9は今回収集した焦電データを日にちで色を変え、プロットしたものである。

ここから、深夜でも動きは一定でなく、よく動き、周期性がないことがわかる。文献[70]によると、睡眠の質の良し悪しをはかる指標として、「規則性」「質」「量」を設定するのがいいとされている。今回の特徴量抽出では、この中で「質」に関する指標のみであったと考えられるため、今後の課題として、「規則性」や「質」を考慮した特徴量抽出を行い、分析する必要があると考えられる。

4.7 まとめ

高齢者の睡眠と日中の生活行動における相関分析をするために、介護施設におけるセンシング実験を行い、収集したデータから「運動と睡眠の相関」「日中の睡眠と深夜の睡眠における相関」の2つの事柄について、機械学習を用いた分析を行った。

その結果、被験者3における分析で

- 日中に運動をすると、深夜の動きが少ない傾向がある
- 深夜の睡眠に動きがないと、次の日に運動する傾向にある

などの知見を得ることができた。このことから、日中の被験者3は運動をすることで、睡眠の質がよくなり、また、睡眠の質がいい日の次の日は運動をする傾向にあるという相関があることがわかった。また、日中の睡眠状況と深夜の睡眠状況の相関分析をするにあたって、今回のデータに加えベッド上に人がいるかどうかの指標となるデータを収集する必要性や、睡眠の指標として、「規則性」「量」を考慮した特徴量を抽出することが必要であることがわかった。

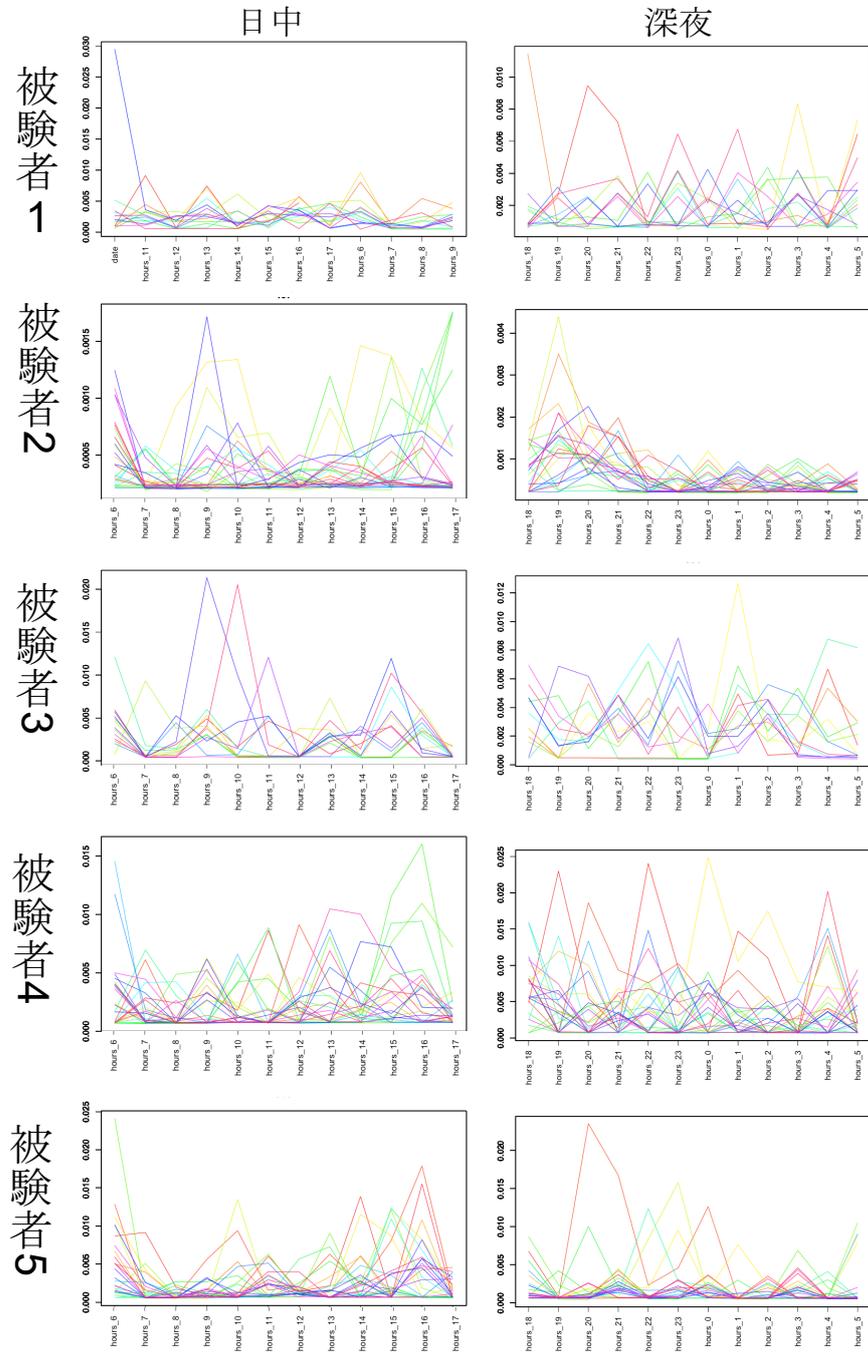


図 4.9 焦電センサの可視化, 左側は日中の睡眠状況, 右側は深夜の睡眠状況を示している。色は日付, 横軸は 1 時間単位の時間, 縦軸は特徴量をとった値を示している。

表 4.6 分析 1-2 における ACC(閾値を平均値と中央値にした場合の 2 パターンで評価, ACC(%))

	閾値	sub1	sub2	sub3	sub4	sub5
18 時	中央値	33.33	18.33	37.50	65.15	
	平均値	84.52	37.50	36.67	54.17	70.08
19 時	中央値	77.38	41.67	36.67	41.67	39.39
	平均値	69.05	29.17	55.00	37.50	86.74
20 時	中央値	76.19	45.83	26.67	33.33	56.44
	平均値	91.67	58.33	55.00	41.67	82.20
21 時	中央値	23.81	37.50	71.67	29.17	26.14
	平均値	29.76	66.67	36.67	37.50	51.89
22 時	中央値	46.43	41.67	45.00	29.17	56.44
	平均値	69.05	66.67	53.33	50.00	78.41
23 時	中央値	76.19	66.67	73.33	45.83	56.44
	平均値	36.90	50.00	55.00	50.00	65.15
1 時	中央値	38.10	25.00	45.00	50.00	65.15
	平均値	53.57	66.67	71.67	54.17	56.44
2 時	中央値	61.90	54.17	45.00	41.67	43.18
	平均値	61.90	45.83	26.67	62.50	74.24
3 時	中央値	45.24	33.33	46.67	62.50	26.14
	平均値	38.10	54.17	73.33	66.67	65.15
4 時	中央値	36.90	33.33	26.67	37.50	34.85
	平均値	76.19	62.50	36.67	54.17	60.98
5 時	中央値	38.10	62.50	55.00	37.50	52.27
	平均値	45.24	62.50	16.67	62.50	78.03
1 日の平均	中央値	76.19	58.33	26.66	58.33	60.60
	平均値	60.71	54.16	16.66	58.33	60.60

表 4.7 分析 2-1 における ACC(閾値を平均値と中央値の 2 パターンで評価, ACC(%))

	閾値	sub1	sub2	sub3	sub4	sub5
18 時	中央値	46.43	67.63	41.67	39.74	39.74
	平均値	91.67	33.33	58.33	39.74	43.91
19 時	中央値	38.10	35.90	25.00	67.95	63.78
	平均値	25.00	50.00	33.33	67.95	59.94
20 時	中央値	53.57	43.91	41.67	35.90	64.10
	平均値	25.00	41.67	41.67	35.90	64.10
21 時	中央値	46.43	60.26	41.67	55.77	44.23
	平均値	33.33	91.67	66.67	51.92	40.06
22 時	中央値	29.76	56.09	91.67	32.05	43.91
	平均値	33.33	50.00	58.33	35.58	47.76
23 時	中央値	38.10	39.74	25.00	48.08	48.08
	平均値	66.67	33.33	16.67	48.08	40.06
24 時	中央値	53.57	19.87	58.33	63.78	39.74
	平均値	50.00	41.67	41.67	59.94	35.90
1 時	中央値	23.81	40.06	33.33	40.06	76.28
	平均値	58.33	50.00	33.33	51.92	64.10
2 時	中央値	38.10	35.90	75.00	32.37	47.76
	平均値	58.33	25.00	33.33	32.05	47.76
3 時	中央値	39.29	40.06	58.33	64.42	59.94
	平均値	16.67	41.67	50.00	64.42	59.94
4 時	中央値	63.10	52.24	33.33	48.08	75.64
	平均値	16.67	33.33	16.67	52.24	75.64
5 時	中央値	69.05	51.92	66.67	39.74	43.59
	平均値	50.00	50.00	25.00	43.59	43.59
1 日の平均	中央値	63.09	59.93	41.66	35.89	47.75
	平均値	63.09	67.62	41.66	35.89	43.91

表 4.8 分析 2-2 における ACC(閾値を平均値と中央値の 2 パターンで評価, ACC(%))

	閾値	sub1	sub2	sub3	sub4	sub5
6 時	中央値	38.10	47.76	33.33	47.76	52.24
	平均値	22.62	43.91	41.67	43.91	72.12
7 時	中央値	38.10	67.95	83.33	56.09	48.08
	平均値	47.62	71.79	83.33	72.12	64.10
8 時	中央値	30.95	35.90	58.33	36.22	55.77
	平均値	30.95	72.12	66.67	64.10	63.78
9 時	中央値	32.14	39.74	83.33	40.06	80.13
	平均値	32.14	68.59	50.00	64.10	75.96
10 時	中央値	53.57	43.91	66.67	39.74	39.74
	平均値	38.10	56.41	66.67	51.92	63.78
11 時	中央値	14.29	39.74	66.67	48.08	43.91
	平均値	69.05	56.09	41.67	72.12	35.90
12 時	中央値	38.10	68.27	25.00	55.77	23.72
	平均値	30.95	88.14	75.00	40.06	43.91
13 時	中央値	46.43	40.38	50.00	36.22	51.92
	平均値	45.24	59.94	41.67	64.42	75.32
14 時	中央値	67.86	59.94	83.33	19.87	47.44
	平均値	60.71	64.10	66.67	64.10	55.77
15 時	中央値	47.62	40.06	50.00	59.94	44.23
	平均値	76.19	76.28	0.00	40.38	76.28
16 時	中央値	53.57	48.08	8.33	56.09	39.74
	平均値	53.57	80.13	25.00	67.63	39.74
17 時	中央値	22.62	75.96	58.33	48.08	59.94
	平均値	22.62	79.81	66.67	63.78	64.42
1 日の平均	中央値	46.42	56.08	33.33	60.57	63.78
	平均値	69.04	59.93	33.33	64.10	75.96

第5章

センサベース行動認識における Zero-shot 学習法

ここでは、行動認識技術の実用化を目指した研究について述べる。既存の行動認識技術は全クラスに対し学習データセットを収集する手間が課題であり、介護記録の自動化応用を目指すための障害であった。そこで、学習データのない未知のクラスを推定する手法を提案する。評価の結果、既存手法より最大で16%予測精度が向上し、生成方法の手間を考慮すると提案する手法の方が有用であることがわかった。この研究は、プライバシーやコストの面で、介護現場で導入が見込まれるセンサデータを用いて行動を認識する技術の実用性の問題に取り組み、さらに行動認識技術の実用化での重要な課題に取り組んでいるものであり、応用面と技術面の両方で貢献する。

5.1 はじめに

センサベースの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 [98]。例えば、介護 [99] や製造 [100] セキュリティ [101] の分野での応用研究がある。一般的に行動認識技術は、教師付き機械学習が使用されるため、学習データとしてセンサデータと行動クラスが対となったデータセットを必要とする。しかし、この学習データを収集することは、大変な作業である。コンテキスト内で可能なすべての行動に対しデータを収集することは、そもそも行動の定義が純粋に主観的であるため、不合理である可能性がある。例えば、日常生活の行動を感変えると、全ての行動に対して、センサデータを収集し、ラベルづけを行うのは非現実的である。

このような手間のかかるデータセットの作成の手間問題の解決法の1つとして、ゼロショット学習と呼ばれる手法が提案されている [102–107]。この手法の目的は、トレーニングデータに存在しないクラス (以降, 未知クラスと呼ぶ) を推定することです。つまり, 推定したい行動クラスの全てのデータを収集せず, 未知クラスを推定するような設定にすることで, 一部のデータ収集タスクを省略することができる。

Zero-shot 学習法は2つの特徴量空間と意味的空間の2つのサンプル空間を用いる。図5.1を参照して Zero-shot 学習法の概要について説明する。特徴量空間には, センサデータから得られる特徴量ベクトルを含んであり, 意味的空間には, 行動クラスの意味を表現する意味ベクトルを含んでおり, このベクトルは辞書のように人の一般知識から生成されるものである。意味表現の例として、「走る」は「足が素早く上下に動き、体が速く進む」と人の知識レベルで説明でき, 意味ベクトルは, この自然言語で説明された文章をベクトル表現に変換されたものである。我々は, この意味ベクトルがどのような表現でベクトル化されると, 推定精度に良い影響を与えるのかについて興味がある。

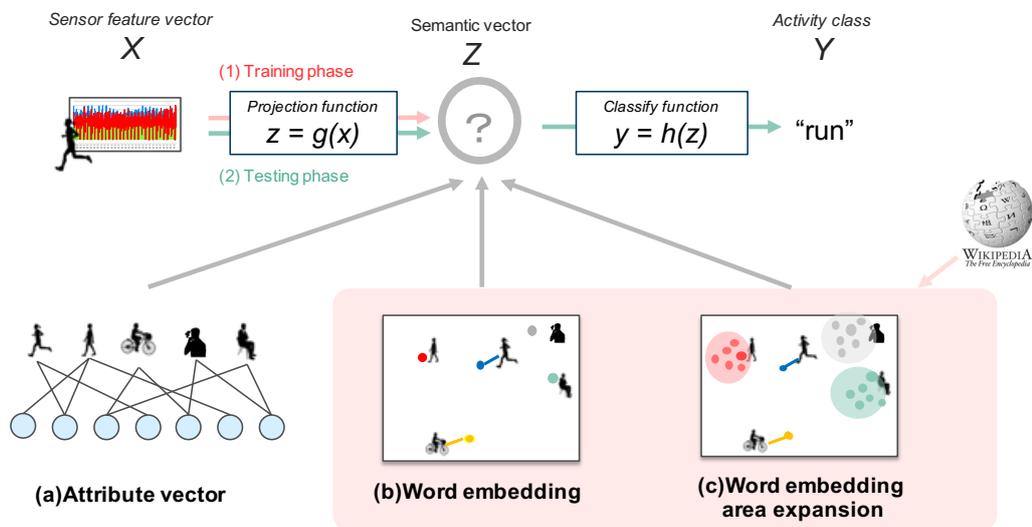


図5.1 本研究の概要図. 上段は Zero-shot 学習法の概要で, 特徴量空間 (X) から意味的空間 (Z) に投影を行い, 意味的空間内で行動クラス (Y) を分類することを示している. 学習フェーズでは赤色矢印が表すように投影方法を学習し, 推定フェーズでは投影関数を用いて意味ベクトルを推定し, 推定された意味ベクトルから行動クラスを探索する. 本研究の目的は, 意味的空間の調査で, (a) 属性ベクトル, (b) 分散表現 (c) 拡張分散表現の3つを比較する。

既存の意味ベクトル表現は, 主に「属性ベクトル」と「分散表現」に分けられる。属性ベクトルは, 専門的な知識や Wordnet を用いて, 一般的に手動で生成される [108]。そのため, ク

ラス数が増えた場合の拡張が困難であったり、手動で生成するため作成者によっては違う属性ベクトルが生成される可能性がある。例えば、「掃除をする」という行動は、「掃除機」という属性が含まれるとするユーザーもいれば、「モップ」という属性が必要であるというユーザーもいる。つまり、生成が困難な上に、属性の一般的化は難しいという欠点がある。一方、分散表現は、Word2vec や Glove などのディープニューラルネットワークモデルなどで自動的に生成される。この分散表現を用いた提案は、画像認識や自然言語処理の分野で多くの既存研究が存在する [102–107, 109–112]。

しかし、センサ行動認識の分野において Zero-shot 学習法の提案をする既存研究は少なく [109, 110]、特に分散表現を用いた手法を提案する研究は我々の知る限り存在しない。分散表現を用いるだけなら、そう難しいことではないが、以下のような懸念点が考えられる。

- 分散表現には、属性のように明確に意味を割り当てていないため、意味の曖昧さと表現の複雑さが含まれている
- 自然言語の文章から自動生成されるため、入力される文章 (コーパス) に依存する点で結果が不安定

したがって本章では、分散表現を用いた Zero-shot 学習法において、センサ行動認識にどのような影響を与えるのか、どのような効果があるのかを調査する必要がある。

本章では、(a) 属性ベクトル (b) 分散表現 (c) 拡張分散表現 の3つの意味ベクトル表現を比較して、センサ行動認識のための Zero-shot 学習法において以下の疑問に取り組む。

1. 埋め込まれた単語ベクトル空間で、意味のあいまいさと表現の複雑さの問題は、領域を拡大することによって解決されるか？
2. そもそもこの曖昧さなどの問題は、Zero-shot 学習法に影響があるのか？
3. 属性ベクトルのような明確さをもたせることはパフォーマンス向上に繋がるのか？

我々は、3つのデータセットを用意し、評価と分析を行う。結果として、分散表現を使用することは、推定精度はあまり変わらないか、少し高くなるということがわかった。手動で生成する手間を考慮すると、属性ベクトルを使用するよりも分散表現を用いた方が効率的であると考えられる。また、分散表現と属性ベクトルの間での類似性 (空間的類似性) は、精度との相関は見られなかった。

主な貢献は以下である。

- センサベース行動認識の分野で初めて、意味分散表現を用いた Zero-shot 学習法について研究している。センサベースの行動認識に置いて困難である点について述べた上で、分散表現拡張手法の提案を行う。
- 推定精度について、属性ベクトルと分散表現との大きな違いは見られないことがわかった。
- 未知クラス認識の精度と空間類似性の相関関係を調査し、分散表現を属性ベクトルを目標として生成する必要性がないことを示す。
- 拡張分散表現の意味的拡張の正しさを確認し、推定精度との相関があまりないことを示した。パフォーマンスに大事なことは、センサデータとの互換性であることであることを示した。

5.2 節では、Zero-shot 学習法について述べる。5.3 節では、評価方法について述べ、5.4 節では評価結果について述べ、5.5 節では考察について述べる。最後にこの研究を 5.6 節でまとめる。

5.2 分散表現を用いた Zero-shot 学習法

ここでは、単語埋め込みを使用した行動認識のための Zero-shot 学習方法について説明する。5.2.1 節で一般的な Zero-shot 学習法を説明する。5.2.4 節で分散表現を用いた Zero-shot 学習法について説明する。

5.2.1 Zero-shot 学習法

まずはじめに、一般的な手法の教師付き機械学習法を説明する。 $\mathcal{X} \subset \mathbb{R}^d$ を特徴量空間とし、 \mathcal{Y} を行動クラスの集合とする。そして、

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

は学習データとする。 tr は学習時に用いるサンプルを表し、 N^{tr} は学習データのサンプル数を示す。

教師あり機械学習問題の目標は、テストサンプル $\{x_i^{ts}\}_{i=1}^{N^{ts}} \subseteq \mathcal{X}$ から $\{y_i^{ts}\}_{i=1}^{N^{ts}} \subseteq \mathcal{Y}$ を推定する、推定モデル $y = f(x)$ を生成することである。上付き文字 ts はテストデータのサンプルを表し、 N^{ts} はテストデータの数を表す。

Zero-shot 学習では、次の公式の意味ベクトルが存在する。

$$\{(z_i^{tr}, y_i^{tr})\}_{i=1}^{N^{tr}} \subseteq \mathcal{Z} \times \mathcal{Y},$$

ここで、 $\mathcal{Z} \subset \mathbb{R}^t$ は意味ベクトル空間を表す。Zero-shot 学習法は、教師あり機械学習と違い、未知クラスを推定することが目的である点であり、未知クラス $\{y_i^{ts}\}_{i=1}^{N^{ts}} \subseteq \mathcal{Y}$ と表す。Zero-shot 学習法は、2つの段階、 x から z を推定する投影関数 $z = g(x)$ 、そして z から y を出力するクラス探索関数 $y = h(z)$ がある。

(1) 学習過程 (図 5.2 の赤い枠で囲まれる部分)

学習過程では、特微量ベクトル x^{tr} を入力し意味ベクトル z を出力する投影関数 $z = g(x)$ を学習する。 x^{tr} と z は y^{tr} で共通するように学習する。投影方法の詳細は、5.2.2 節で説明する。

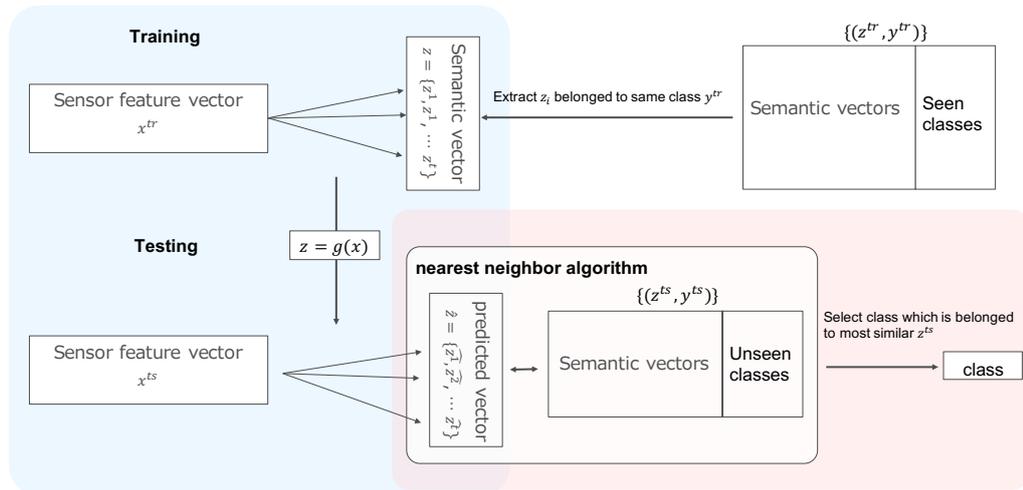


図 5.2 Zero-shot 学習法の概要. 上段が学習フェーズ, 下段が推定フェーズを表す. 青枠で囲われている部分は投影フェーズ, 赤枠で囲われている部分はクラス探索フェーズを示している。

(2) テスト過程 (図 5.2 の緑枠で囲まれる部分)

テスト過程では、学習された投影関数 $z = g(x)$ と $y = h(z)$ を用いる。まず、 $z = g(x)$ を用いて、 x^{ts} から \hat{z} を推定する。次に、クラス探索関数 $y = h(z)$ を使用して、 \hat{z} から $\hat{y} \in \mathcal{Y}$ 推定する。クラス探索関数の詳細は、5.2.3 節で詳しく説明する。

$y^{ts} \in \mathcal{U}$ はテストクラスの集合を示し、 $y^{tr} \in \mathcal{S}$ が学習クラスの集合を示す。Zero-shot 学習法の重要なポイントは学習クラス集合とテストクラス集合が重複していない点である。

$$\mathcal{U} \cap \mathcal{S} = \emptyset.$$

5.2.2 投影モデル

ここでは、特徴量空間から意味空間に投影する方法 $\mathcal{X} \rightarrow \mathcal{Z}$ について説明する。 $x_i \in N^d$ を d 次元の特徴ベクトルとし、 $z_i \in N^t$ を t 次元の意味ベクトル、つまり $z_i = z_i^1, z_i^2, z_i^3, \dots, z_i^t$ とする。学習過程では、それぞれの特徴量ベクトルに対し、共通のクラス y が対応する z が存在するため、 x_i と z_i を対応させることができる。そして、線形回帰アルゴリズムを使用し、特徴量ベクトル x_i から z_i のそれぞれの次元の値を学習する。この論文では、SVR（サポートベクトル回帰）を学習アルゴリズムとして使用する。つまり、 z_i の次元数 t 個の学習器が存在していることを示す。テスト過程では、テストサンプル x_i から各次元の値 z_i^t が推定され、単純に結合することで z_i^t を出力する。

5.2.3 クラス探索関数

ここでは、 \hat{z} から未知行動クラス $y \in \mathcal{U}$ を出力する関数について説明する。学習フェーズで、投影関数 $g(x)$ によって意味空間に投影されたものである \hat{z} に、 y^{ts} の中で一番近いベクトルを探索し、それに対応する y を推定結果として出力する。

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

5.2.4 分散表現と拡張分散表現

分散表現

本論文では、英語ウィキペディアをコーパスとして、単語ベクトルを自動で生成するツール `word2vec` を使用して生成された分散表現を用いる。 `word2vec` を使用することの利点は、単語の埋め込みは自動的に生成でき、同一のベクトルは作成されず、TF-IDF などの伝統的な意味的単語ベクトルに比べて意味表現として優秀であることである。

本論文で用いる分散表現の生成方法について説明すると、

1. まず、 `word2vec` を用いて Wikipedia 内に存在する全ての単語をベクトル化する。この時できた単語ベクトル集合を Z_{all} とする。
2. データセットに含まれる全ての行動クラスを $Y = y_1, y_2, \dots, y_n$ とした時、
3. $Y = y_1, y_2, \dots, y_n$ に対応する単語ベクトル $Z_s = z_1, z_2, \dots, z_n$ を Z_{all} から抽出する。

“Open door” など、2 つ以上の単語を組み合わせた行動クラスがあった場合は、各単語のベクトル（「オープン」と「ドア」）のベクトルを抽出し、平均したベクトルを生成する。

拡張分散表現

拡張分散表現は、 Z_{all} 上で $Z_s = z_1, z_2, \dots, z_n$ の各ベクトルに対して類似するベクトルを抽出し対応するクラスのサンプルとすることで、意味的な領域を広げることで生成する。類似するベクトルの探索方法は、 z_i に対してコサイン類似度で、ベクトル距離が近いものから順番に抽出する。評価時には、抽出するサンプル数を k とし、 $k = 5, 10, 20$ と 3 パターンの拡張分散表現を生成する。

“Open door” のように、2 つ以上の単語が組み合わさっている場合、分散表現と同様 “open” と “door” に分けてベクトルの平均をとるが、“open” などの物体でない単語のみを拡張し、“door” との平均をとるという方法で生成する。Appendix 8.0.2 に抽出されたベクトルに体操する単語を示す。また、一般的に類似しているかどうかを見るために、“Reverso Synonyms” というサイト*¹を参考に、類義語は赤色、反対語は青色というように色付けをする。

5.3 評価

ここでは、Zero-shot 行動認識の意味的空間としての分散表現と分散拡張表現を評価するための実験について説明する。評価は、以下の 2 つのメトリックに基づいている。

- 未知クラスの認識精度を属性ベクトルを用いた手法との比較評価
- 各意味空間同士の類似度とパフォーマンスとの相関を評価

5.3.1 節では評価に使用されるデータセットについて説明する。5.3.2 節では、評価方法について説明する。

5.3.1 データセット

行動認識のために 2 つのパブリックデータセットと 1 つの独自で生成したデータセットを使用する。これらのデータセットは、行動クラスの種類とセンサーの位置や個数が違う。これらのデータセットの概要を表 5.1 に示し、詳細は 5.3.1 節で詳細を述べる。

*¹ <https://synonyms.reverso.net/synonym/>

表 5.1 データセットに対する行動種とセンサの種類.

データセット	行動クラスの種類	センサの種類
HASC	基本的な行動 (Walk, Run, Jog, Skip, Stair up and Stair down)	腕に取り付けたスマートフォンに内臓された 3 軸加速度センサ
OPP	物を対象とした行動 (open door, close door, open fridge, close fridge, open dishwasher, close dishwasher, open drawer, close drawer, clean table, drink from cup and toggle switch)	物体に取り付けたセンサと IMU や加速度計を用いたウェアラブルセンサ
PAMAP2	生活行動 (watching TV, house cleaning, lying, sitting, standing, walking, running, cycling, Nordic walking, computer work, car driving, ascending stairs, descending stairs, vacuum cleaning, ironing, folding laundry, playing soccer and rope jumping)	IMMU を用いたウェアラブルセンサを体の 3 つの箇所に取り付け

最初に 5.3.1 節でセンサデータセットとそれぞれの前処理方法について説明し、次に 5.3.1 節で評価する意味的空間について説明する.

センサデータセットと前処理方法

評価用のデータセットとして、OPP データセット、PAMAP2 データセット、HASC データセットの 3 つのデータセットを利用する (表 5.1 にまとめる). 以下では、前処理について説明する. まず、3 つのデータセット全てに共通の前処理として、欠損値を 0 に変化、各次元ごとに $[0, 1]$ の範囲で正規化を行う. その後、センサ行動認識の分野で一般的に用いられる伝統的な特徴量抽出方法である時間窓スライド方式を用いる.

OPP データセット [127]

Opportunity Activity Recognition Dataset (OPP) は、オフィスでの朝の行動を想定し生成されたデータセットである. センサーデータは、30 Hz の周波数で 4 人の被験者によって収集される. 収集されたセンサデータに対して、行動レベルが異なる 4 つの行動クラスがラベルづけされている. 本論文では、17 個のアクティビティを含む中間レベルの行動ラベルを使用する. 時間窓スライド方式のパラメータは、Hammerla Nils Y. et.al の論文 [128] を参考にし、1 秒の時間窓と 0.5 秒のスライド幅で、窓内のサンプルに対して分散と平均を特徴量として抽出する方法を採用する. データセット内には、1 人の被験者に対して複数のファイルが各行動に対して存在する. そのファイルのうち、“Drill runs” は使用しない. 結果、484 次元の特徴ベクトルを取得した.

PAMAP2 データセット [129]

The Physical Activity Monitoring Data Set (PAMAP2) は、9 人の被験者によって収集された 18 種類の行動クラスが含まれている. 心拍数モニターセンサの周波数は 9Hz で、その他の

ウェアラブルセンサの周波数は 100Hz である。時間窓スライド方式のパラメータは, Roggen Daniel et.al の論文 [129] を参考にし, 5.12 秒の時間窓と 1.0 秒のスライド幅で, 窓内のサンプルに対して分散と平均を特徴量として抽出する方法を採用する。また, データの提唱者の推奨に従い, “3D accelerators with scale of $\pm 6g$ ” ファイルと “orientation readings” の値は削除する。その結果, 69 次元のベクトルとなった。

HASC データセット

The Human Activity Sensing Consortium (HASC) は, ウェアラブルセンサの大規模データベースの構築を目指しており, 6 つの特定のアクションについてスマートフォンから加速度センサーデータを収集するという課題に取り組んでいる [130]。本論文で用いる HASC データセットは, このチャレンジのガイドライン*2に従って本研究室で収集したデータセットを使用する。センサはスマートフォンに内蔵される 3 軸加速度計から周波数 100Hz で収集したものをを用いる。被験者は 1 人分で, 各行動クラスに対して, 20 秒間を 5 セットずつを記録する。時間窓スライド方式のパラメータは, 2.0 秒の時間窓と 0.5 秒のスライド幅で, 窓内のサンプルに対して分散, 平均, 最小値, 最大値を特徴量として抽出する方法を採用する。その結果, 12 次元のベクトルが得られる。

意味的空間

この論文では, 属性ベクトル、分散表現、拡張分散表現の 3 種類の意味的空間を比較評価する。以下では, 評価に使用する属性ベクトルと分散表現 (拡張分散表現を含む) について説明する。

属性ベクトル

属性ベクトルは, 評価用データセットによって違うため, Appendix 8.0.1 内にある表 8.1–8.3 に示す。OPP データセットと PAMAP2 データセットの属性ベクトルは [112] で定義されているものをを用いている。HASC データセットの属性ベクトルは, PAMAP2 データセットの属性を参考に我々が作成する。この時, この属性ベクトルの値は, 1 と 0 の実数値であることに注意する。

分散表現

分散表現は, word2vec を用いて自動生成する。本論文では, コーパスとして英語版ウィキペディアを使用し, すでに 1000 次元で学習された wiki2vec (<https://github.com/idio/>

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

wiki2vec) を使用する。前述のように、このモデルから評価に必要な行動クラスの単語ベクトルのみを抽出して使用する。また、1000次元で学習させるのは時間がかかるため、主成分分析 (PCA) を使用して、次元を減らす前処理を行う。その結果、HASCA データセットは6次元、OPP データセットでは11次元、PAMAP2 データセットは18次元となる。

5.3.2 分析手法と評価実験

次に、評価方法について説明する。ここでは、5.3で説明した2つの評価方法について説明する。

未知クラス推定の評価方法

分散表現と属性ベクトルを使用した Zero-shot 学習のパフォーマンスを比較するために、未知クラス推定の推定精度を算出する。

学習データとテストデータは、未知クラスと既知クラスとして分けられる。それぞれのデータセットで、未知クラスの設定方法が異なるため、以下に示す。OPP データセットと PAMAP2 データセットは、[112] の論文の評価方法に従い、5つの異なる未知クラスの組み合わせを設定する。1つの実験 (fold) につき、未知クラス数は3つから4つとする。HASCA データセットは、存在するクラス数が少ないので、各 fold に対して2つの未知クラスを設定し、全ての組み合わせの場合を評価する。つまり、全クラスが6つなので、15個の組み合わせができる。各未知クラスの設定は表 5.2 から表 5.4 に示す。さらに、OPP データセットと PAMAP2 データセットにおいて、テストデータサンプル数と学習データのサンプル数の割合を見せるために、表 5.5 に示す。HASCA データセットは、fold が多いため、各クラスのサンプル数を簡単に述べる。クラスサンプル数の平均は1945サンプルで、内訳は、stay クラスが2013サンプル、walk クラスは2014サンプル、jog クラスは1608サンプル、skip クラスは2010サンプル、Stair up クラスは2015サンプル、Stair down クラスは2012サンプルである。

また、評価用に拡張分散表現の拡散度を表すパラメータを k とし、その値を 5, 10 および 20 に変化させ、3つの拡張分散表現を生成する。

表 5.2 OPP データセットにおける, 評価するデータの未知クラスと定義したクラス名とそのサンプル数.

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 5.3 PAMAP2 データセットにおける, 評価するデータの未知クラスと定義したクラス名

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

表 5.4 HASC データセットにおける, 評価するデータの未知クラスと定義したクラス名とそのサンプル数.

Fold	Unknown Classes	Fold	Unknown Classes
fold 1	Stay (2013), Walk (2014)	fold 9	Jog, Stair up
fold 2	Stay, Jog (1608)	fold 10	Skip, Stair up
fold 3	Walk, Jog	fold 11	Stay, Stair down (2012)
fold 4	Stay, Skip (2010)	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 (2015)	fold 14	Skip, Stair down
fold 8	Walk, Stair up	fold 15	Stair up, Stair down

表 5.5 Statistics on the number of instances and classes that belong to seen and unseen classes in each fold in the three datasets.

Fold	Number of Instances				Number of classes			
	OPP		PAMAP2		OPP		PAMAP2	
Classes	Seen	Unseen	Seen	Unseen	Seen	Unseen	Seen	Unseen
fold 1	5868	1338	16377	3073	8	3	14	4
fold 2	4986	2220	13661	5789	8	3	14	4
fold 3	4647	2559	15770	3680	8	3	14	4
fold 4	5087	2119	14927	4523	8	3	15	3
fold 5	5525	1681	17065	2385	8	3	15	3

評価指標には、F-1 スコアを使用する。公式は以下に示す。

$$F\text{-score} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall})$$

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}), \quad \text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

True Positive (TP) は、ある一つのクラス (ターゲットクラス) のサンプルに対して、正しく推定されたサンプル数で、偽陽性 (FP) は、ターゲットクラスに属さないがターゲットクラスと誤って推定されたサンプル数、False Negative (FN) は、ターゲットクラスに属さないが、ターゲットクラスと推定されたクラスを示す。

意味的空間の類似度の評価方法

2つ目の評価目的として、分散表現は属性ベクトル表現のような表現に近づけることが、未知推定のパフォーマンスを向上させるのかという疑問に対して、意味空間同士の類似度を算出する。

空間の類似度として、各空間のベクトル位置が類似するのかの測定を試みる。最初に、全意味空間に対して、各クラスのベクトルに近いベクトルのクラスを k 近傍法を用いて計算し、属性ベクトル空間と単語埋め込み空間においては、上位 3 つを表にまとめる。拡張分散表現は、最も類似するクラスを算出し、クラス毎にヒストグラムで可視化する。次に、拡張分散表現を含む分散表現と属性スペースの類似度の指標として、可視化したクラスの一貫率を用いる。

5.4 分析と評価結果

5.4.1 投影関数の評価

まず、未知のクラスのない設定で精度を算出し、投影関数の評価をする。評価方法は、2分割交差検証方法で行い30%をテストデータに用いる。表5.6に結果を示す。

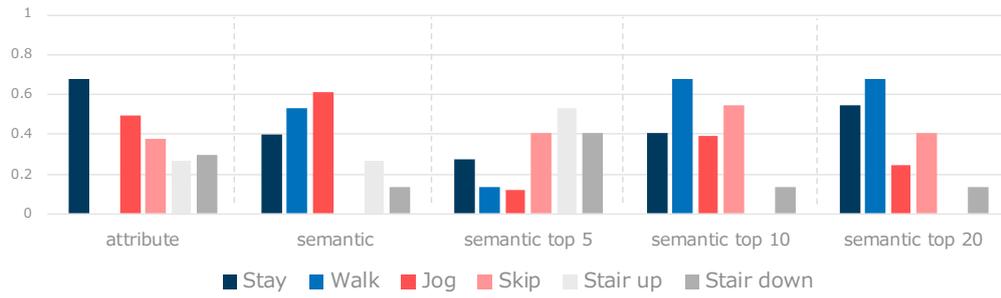
表5.6 未知クラスがない設定下での手法のF1値。supervised_SVMはセンサデータを入力し、行動クラスを出力する一般的なSVMを用いた手法。ZSL_attributeは属性ベクトルを用いた手法、ZSL_embeddingは分散表現を用いた場合の手法。列はデータセットを表す。

	HASC	OPP	PAMAP2
supervised_SVM	0.84	0.85	0.92
ZSL_attribute	0.91	0.78	0.91
ZSL_embedding	0.92	0.92	0.91

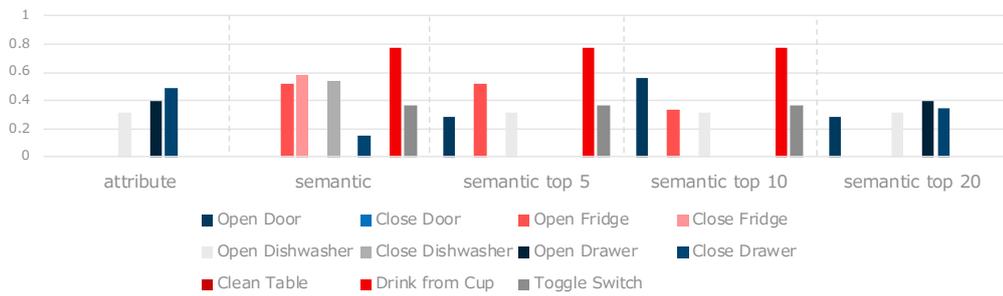
表5.6の結果から、ZSL_embeddingは全体的に精度が高く、ZSL_attributeはOPPデータセットに関して精度が低下していることがわかるが、全体的に推定精度が下がることがないことはわかる。

5.4.2 未知クラスの推定結果

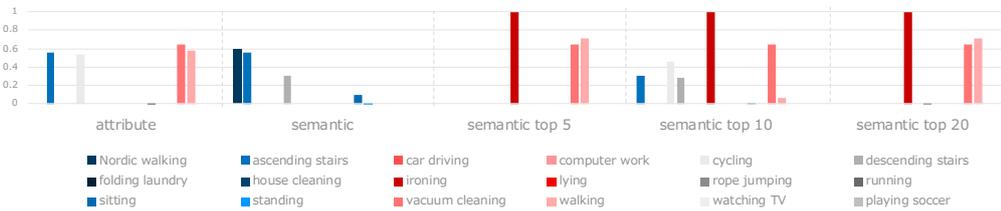
次に、未知クラスが存在する場合の評価を行う。図F5.3は、未知クラス推定のF-1スコアのクラス毎の平均値をグラフにまとめたもので、表5.7は、さらに手法毎で平均してまとめたものである。



(a) HASC dataset



(b) OPP dataset



(c) PAMAP2 dataset

図 5.3 データセット毎に結果を示す．横軸は手法，さらに各クラスを示し，縦軸は各クラス毎の F-1 スコアの全 fold の平均値．

表 5.7 列がデータセット，行が手法を示し，表内の値は F-1 スコアの平均値を示す．

	HASC	OPP	PAMAP2
attribute	0.35	0.11	0.13
semantic	0.32	0.27	0.09
semantic_top5	0.31	0.21	0.13
semantic_top10	0.36	0.21	0.15
semantic_top20	0.33	0.12	0.13

表 5.7 から，属性ベクトルを用いた手法より分散表現を用いた手法の方が精度が高いことが

わかり, OPP データセットに関しては 0.16 向上している. ただし, 拡張のパラメータによっては属性ベクトルの方が精度が高い場合がある.

次に図 5.3 について結果を述べる. 最初に HASCA データセットに注目する. 属性ベクトルを用いた場合, “walk” の推定精度が 0% という結果になっていることがわかる. 一方, 分散表現を用いた手法では, “skip” が 0% となっているが, 拡張分散表現では, “skip” が推定できている. 変化に注目すると, “walk” と “stay” のクラスの精度は, 一旦低下するが, 拡張を大きくすると向上していることがわかる. 一方, “Stair up” と “Stair down” の精度は一旦向上するが, その後低下する.

次に, OPP データセットの結果に注目する. 推定できる未知のクラス数に着目すると, 属性ベクトル手法と分散表現手法では, 分散表現手法の方が 3 クラス分多いことがわかる. 分散表現手法を拡張分散表現に拡張させた時の変化を見ると, 推定可能なクラス数は減少していることがわかる. 面白いことに $k = 20$ の拡張分散表現は, 属性ベクトルの推定可能なクラスがほぼ同じになっていることがわかる. また, 拡張を含む分散表現を用いた手法では, “Drink from Cup” のクラスの推定精度が最も高いことがわかる.

最後に, PAMAP2 データの結果に注目する. これまでの結果と比較して, 推定できるクラスの割合が全体的に低いことがわかる. “vacuum cleaning” と “walking” のクラスに着目すると, 分散表現を用いた手法以外で, 高い推定精度となっていることがわかる. また, 拡張分散表現では, “ironing” クラスの推定精度が高く, 100% の精度で推定できていることがわかる.

これらの結果をまとめると, 拡張を含めた分散表現を用いた手法は属性ベクトルより高い精度を得ることができていることがわかった. また, 属性ベクトルでは推定できていないクラスの推定ができることも確認できる. これらの結果から, 考察パート 5.5 節では, どのようなクラスが推定できて, 傾向があるのかどうかを考える.

5.4.3 空間類似度との相関

ここでは, 空間類似度の評価結果について述べる. HASCA データセットに関して, 表 5.8 は, 属性ベクトルと分散表現の類似ベクトルのクラスの上位 3 つを表にまとめたもの, 図 5.4 は, 拡張分散表現の類似クラスのヒストグラムを表している. 同様に, OPP データセットに関しての結果は, 表 8.8 と図 8.2 に示し, PAMAP2 データセットに関しての結果は, 表 8.7 と図 8.1 に表す. そして, これらの結果から, 一致率を表 5.9 に示し, 空間的類似度の評価を

行う。

表 5.8 属性ベクトル (左) と分散表現 (右) の HASCA データセット空間内で、各クラスで距離が近いベクトルのクラス上位 3 つをまとめたもの

		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

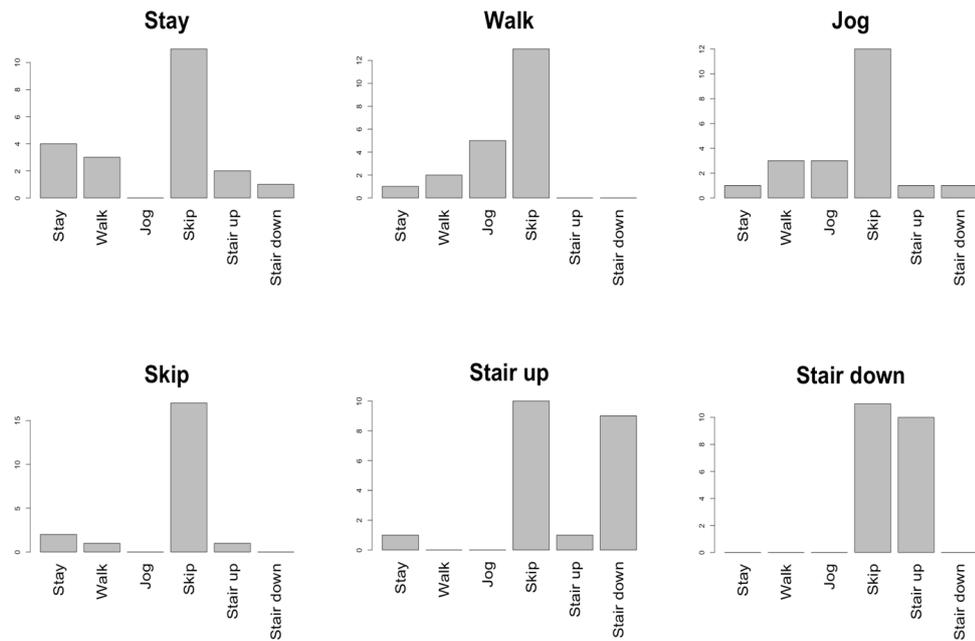


図 5.4 HASCA データにおいて、拡張分散表現の行動クラス間で最も類似する単語ベクトルのヒストグラム

表 5.9 属性ベクトルと比較し、分散表現と拡張分散表現の空間的類似度を図 5.4 と図 8.1, 図 8.2 の結果からの一致率で測定する。

	HASC	OPP	PAMAP2
属性ベクトルと分散表現の一致率	4/6	0/11	5/18
属性ベクトルと拡張分散表現の一致率	1/6	2/11	8/18

まず, HASCA データセットに関する結果に注目する. 表 5.8 から, “Stay”, “Walk”, “Stair up”, “Stair down” のクラスに対する最も距離の近いクラスは一致していることがわかる. 一方, “Jog” と “Skip” は結果が一致しないことがわかる. 図 5.4 から, 全てのクラスに対して, “Skip” クラスに最も近いベクトルが多いことがわかる. クラス間で比較すると, “Stay” と “Walk”, “Stair up” と “Stair down” の単語ペアは, 空間内で近い距離に存在することがわかる.

次に PAMAP2 データセットの結果に注目する. 表 8.7 から, “vacuum cleaning” と “house cleaning” の近いベクトル結果が 2 つ一致することがわかった. 最も近いクラスが 1 つだけ一致するクラスは “descending stairs” と “ascending stairs”, “vacuum cleaning”, “ironing”, “cycling” があつた. 図 8.1 から “vacuum cleaning” と “house cleaning” が一致率が高いクラスであることがわかった.

次に OPP データセットの結果に注目する. 表 8.8 から, 一致するクラスが存在しないことがわかる. 興味深い部分は, OPP データセットのクラスは動詞と物体の組み合わせで構成されていることである. そのことを考慮し, 考察パートでは, なぜ類似度が低いのかという部分について考える.

表 5.9 から, HASC データは分散表現の方が拡張する時に比べて属性ベクトルに似ていることがわかり, その他 2 つは拡張する手法のほうが属性ベクトルに類似した空間になることがわかった.

5.4.4 結果のまとめ

最後に結果をまとめる. まず, 属性ベクトルを用いた手法と拡張を含む分散表現を用いる手法を比べると, 分散表現を用いた手法の方が精度が高いことがわかった. しかし, 拡張のパラメータを変えると, 属性ベクトルより精度が低くなることがあるので, 絶対分散表現を用いることがいいとは断言できない. しかし, 手動で生成する手間を考慮すると, 分散表現を用いた手法が有用であると言える. また, 考察で, 推定精度が高い傾向について考察することで, 分散表現の精度向上を目指す.

また, 意味的空間の類似度に関して, 属性ベクトル空間は, 分散表現と拡張分散表現のどちらに類似するかという疑問に対しては, HASC データセットは分散表現のほうが類似しており, その他 2 つのデータセットは拡張させることで類似度が上がるということがわかった. また, “Walk” と “Stay” というクラスペアと, “Stair up” と “Stair down” のクラスペアのベ

クトル距離が近い, つまり, 意味的に類似する単語であるという結果であるが, 一般的な知識としては, “Walk” と “Stay” は近い意味ではない気がするし, 動きとしても近くはない気がする. このような意味的な近さが正解しているのかどうかということと, Zero-shot 学習のパフォーマンスの相関についても考察する.

5.5 考察

ここでは, センサ行動認識の Zero-shot 学習法に対して, 分散表現はどのように影響するのかについて考察する. 特に, 3つの側面に焦点を当てる: 分散表現の意味的な正当性と精度の未知クラス推定のパフォーマンスの相関, 意味空間の選択と未知クラス推定のパフォーマンスの相関, 複合語とパフォーマンスとの相関.

5.5.1 分散表現の意味的な正当性

ここでは, 意味的な一般知識での正当性と未知クラス認識のパフォーマンスの間で相関関係があるかどうかを考察する. Appendix 8.0.2 節に拡張分散表現と選択された単語を表でまとめてあるものと未知クラス推定との精度を見て考察する.

HASC データセットについて考える. 表 5.4 から, “Skip” のクラス以外, 上位 5 つの類似単語のほとんどは赤い文字であるため, 同義語が元のクラスの周りに配置してあることがわかる. 一方, 拡張分散ベクトルのパラメーターが $k = 5$ の場合, 推定精度が低下していることがわかる. 興味深いことに “Stay” に注目した時, 唯一反対語である “go” と “leave” が含まれる拡張分散表現を用いた手法の推定精度は向上していることがわかる. これは, 分散表現の類似語を増やし, 意味的な曖昧性を緩和することで, 精度向上に繋がるという仮説に反する結果となっている. また, 拡張分散表現を考えた時, 図 5.4 のヒストグラムから, どのクラスに対しても “Skip” のクラスに近い単語ベクトルが多いことも考慮して考えると, 元々の単語ベクトル同士の距離が近いいため, 拡張分散表現の効果が機能していないと考えられる.

OPP データセットについて考えが, ほとんどすべてのアクティビティクラスが複合語であるため, この意味的な正確性の考察に関しては難しいため, ここではこの結果について言及しない.

PAMAP2 データセットに注目する. “cleaning” と “work” のクラスに対して, 拡張分散表現の中に 13 個の同義語があることがわかる. 割合的に, この個数は多い数となる. 未知行

動推定の推定精度を見ると、精度は低く、他のクラスと比べて特別低いわけでもない。一方、“vacuum cleaning”と“lying”，“walking”の3クラスは未知クラス推定の精度が高いが、同義語の数は少ない。

これらのことをまとめると、意味ベクトルの一般的知識の正確さと未知クラス認識の相関関係はないと考えられる。

5.5.2 意味空間の選択とパフォーマンス

属性ベクトルとの類似度と推定パフォーマンスとの相関を考察するために、表 5.7 と 5.9 に注目する。結果から、OPP データセットは拡張させることで属性空間との類似性が低下すること、PAMAP2 データセットと HASCA データセットは反対に類似性が向上することがわかった。そして、HASC データセットは拡張させることで推定パフォーマンスが低下することがわかった。そして、OPPd データセットと PAMAP2 データセットの場合、推定パフォーマンスは向上することがわかった。しかがって、類似性とパフォーマンスの相関関係はないと考えられる。しかし、これは類似度との相関がないという決定的な根拠という訳ではない。例えば、データセットのクラスのレベルに相関する話かもしれないので、今回はこの検証結果からは、相関がないと考えられるという考察である。

5.5.3 複合語

OPP データセットは、属性ベクトルに比べて分散表現の方が推定精度が良いという結果になった。さらに、拡張を行うと属性ベクトルに似た推定方法になり、属性ベクトルに類似する空間になっていると想定される。その要因について考察する。

まず、OPP データセットの行動クラスについて確認をする。このデータセットのクラスは「動詞」+「オブジェクト」の形式になっており、多くの行動クラスの組み合わせが違う。例えば、「ドアを開く」と「ドアを閉じる」はオブジェクトを共有するクラスであり、「ドアを開く」と「冷蔵庫を開く」は動詞を共有するクラスになっている。次に、分散表現の生成方法について考える。分散表現は、「動詞」の単語ベクトルと「オブジェクト」の単語ベクトルの平均をとる。同様に、拡張単語ベクトルも平均ベクトルを生成するが、「動詞」の単語ベクトルが拡張したサンプル数分存在し、意味ベクトルの価値観が変化していると考えられる。

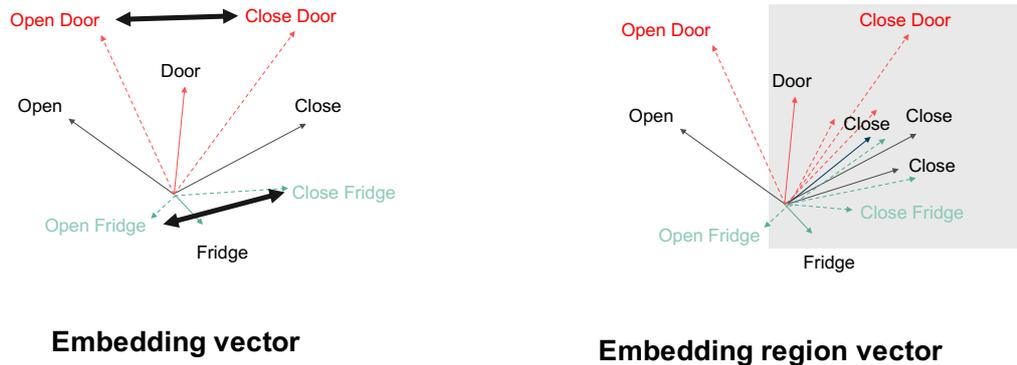


図 5.5 分散表現と拡張分散表現の単語の意味的距離の違いについての考察。

図 5.5 を用いて、このことを説明する。例えば，“Open”と“Close”，“Door”，“Fridge”の4つの単語ベクトルから，“Open Door”，“Close Door”，“Open Fridge”，“Close Fridge”の4つの意味ベクトルを生成することを考える。分散表現では、この4つの単語ベクトルから該当する単語ベクトルの平均をとり、生成されるため、イメージは図 5.5 の左側になると考えられる。この時、共通単語があるが、ベクトル位置によるが、最近傍法の結果が共有される動詞によって決定されるのか、共有される名詞によって決定されるのかわからない。今回の場合を考えると、特徴量ベクトル空間ではオブジェクトセンサが1つの特徴量とされており、動詞の検出よりオブジェクト属性測定の検出の方が容易であるため、オブジェクトに焦点が当たることが考えられる。しかし、拡張分散表現は、動詞部分が拡張されるため、図 5.5 の右側のように意味ベクトルの拡張が行われる。したがって、分散表現と拡張分散表現を用いた場合、分散表現より拡張分散表現の方が、最近傍法の結果が共通の動詞があるかどうかにより焦点が当てられる可能性が高くなる。

また、属性ベクトルを考えた時、0と1で表されるベクトルであるため、ベクトルの距離は決定されづらいが、全体のクラスを考慮すると、オブジェクトより動詞の属性の発生率が高いため、距離を計測される場合動詞に焦点が当てられることが考えられる。つまり、拡張分散表現と似た現象が起きると考えられる。

5.5.4 将来の展望

本研究での評価方法は、テスト時の設定が未知クラスのみでの分類に焦点を当てたものであった。文献 [102] でも述べられるように、既知クラスと未知クラスを両方推定する設定下での評価は、応用で重要な評価方法であるので、今後はこの評価も行なっていきたい。

また、未知クラス推定の全体的な精度はまだ、高くはない。しかし、今後の応用を考えると、Zero-shot のようなアプローチは必要であると考えられる。なぜなら、生活行動や業務行動などの複雑な行動の推定精度が向上したとしても、環境が変わったことによって動きが変わる、身長が低い人は動きが違うなど、行動認識の課題はまだ存在し、教師あり機械学習の精度が高くなったから応用できるということではないからである。

また、分散表現を拡張させることで、特徴量空間でのサンプルの分散が大きい時の対処法になるという利点もあるのではないかと考える。例えば、特徴量空間でのクラスの分散は大きく、入り混じっていることはセンサ行動認識ではある。その空間から、属性ベクトルに変換し、クラス分類することは一般的なセンサ行動認識でも効果があると考えられる。実際表 5.6 でわかるように未知クラス推定でない場合、推定精度の向上が見られる。また、拡張することで、特徴量空間での分散が考慮されるかもしれないということを考えていて、その評価も今後行なっていきたい。

5.6 まとめ

この研究では、センサ行動認識の Zero-shot 学習法において、分散表現の有用性があるかどうかという疑問に対して、3つの意味的空間、属性ベクトル、分散表現、拡張分散表現、を比較する。拡張分散表現は、分散表現の意味的な曖昧さの緩和を行う効果を期待して提案した手法である。この研究では、以下の2点を評価した。a) 属性ベクトルを用いた手法に比べて分散表現を用いた手法は推定精度を低下させるのか？ b) 分散表現は属性ベクトルに似た表現の方が精度にいい影響を与えるのか？

我々の結果は、拡張分散表現を含んだ分散表現を用いることは属性ベクトルを用いた手法より有用であることを示している。なぜなら、推定精度を比較した時、同じくらいか向上している部分が見られたことから、手動で生成する手間を考慮すると、自動生成でき精度があまり変わらない分散表現の方が利点が多い。

また考察の結果、“run”や“walk”などシンプルな行動クラスの場合、分散表現は拡張分散表現に比べて属性ベクトルに意味空間の類似性が高いこと、また“cleaning”などの生活行動クラスにおいては、拡張分散表現のほうが類似度が高いことがわかった。しかし、この知見は未知クラス推定のパフォーマンスとの相関は見られなかった。

つまり、分散表現を属性ベクトルのような意味ベクトルを目指すと未知推定のパフォーマンス向上に繋がるかという回答は、これらの知見を考えてノーと考えられる。重要なのは、セン

サデータと意味空間の相互関係が高い部分にあると考えられる。

第6章

全体の考察

ここでは、全体のまとめについて述べる。論点は3点で、将来予測モデルを用いたデータマイニング手法における利点と行動認識における Zero-shot 学習法の実用化について、そして介護分野におけるユビキタスコンピューティング研究の将来について述べる。

6.1 将来予測モデルを用いたデータマイニング手法における 利点

本博士論文では、介護入居前の相談者の将来予測モデルを分析し、現場以外の課題や傾向を分析する研究と、高齢者の将来予測モデルを分析し、行動の傾向を分析する研究について述べた。

これらの研究では、将来予測モデルを構築し、データマイニングを行った。また、高齢者の行動を分析する研究においては、センサデータの時系列情報をなるべく消さないように、分析を行った。このように、時系列を考慮したデータマイニング手法の利点として、選択すべき分岐点の提案ができると考えている。例えば、説明変数が時系列に並んだ情報だったとき、目的変数に重要な変数を見ることで、どの地点での選択肢が将来の結果に影響するのかがわかる。ここでは、3章と4章のそれぞれの知見の中で、このような分岐点の選択の参考になる知見がどうかについて考察する。

まず、3章の研究について、分岐点的な知見を2つピックアップした。

- 準備期間が2ヶ月あるかどうかで成約率が4倍違う。
- 事前に介護度を知っておく必要がある。

まず1つ目の知見は、今後介護施設に入居するかどうか悩む相談者にとって、2ヶ月を目安に準備しなければいけないという目安にもなる。2つ目の知見は、同様に介護度を知っておくと良いという知見になる。

これらの知見は、介護施設を探すのに重要な知見ではあるが、3章の結果からもわかったように、突然の一人暮らしや病院退院後に突如介護施設を探す必要ができたなど既に気づくのが遅いという場面が多い。そこで、したがって、見守りシステムの1つの機能として、介護施設を探し始めるレコメンド機能を付け加えると良いと考えられる。そのためには、入居の2ヶ月前という知見では足りない。また、今回のデータは既に相談が必要で救急な人が多い。つまり、この機能を実現するためには、このデータより長い期間のデータやより多くの情報が必要となる。そのために、クラウドソーシング [97] を用いたデータ収集が良いと著者は考える。

次に、4章について、1つの知見をピックアップした。「ある高齢者は、運動した日は8時頃に寝る可能性がある」この知見で、介護士は業務の優先順位を選択できると考えられる。これは、個人差と明確な時間帯が含まれた知見であることが重要である。

これから、ますますセンサデータを用いた分析が重要になってくると思われる。そこで、時系列情報をなるべく失わずにデータマイニングする手法が、いい知見やいいユビキタスコンピューティング研究に今後貢献すると考えられる。

6.2 行動認識における Zero-shot 学習法の実用化

本博士論文では、行動認識手法の実用化を目指して Zero-shot 学習法を提案した。ここでは、実際どのような形で Zero-shot 学習法の使用が有用であるか述べる。

6.2.1 介護記録自動化のための行動認識手法への応用を考えて

応用例として、介護記録を自動化するためのシステムを考える [120]。このシステムは介護士にスマートフォンを持って作業してもらい、スマートフォンから得られる3軸加速度データから介護士の行動をAIが認識し、介護記録を自動的に生成することを目的としている。この場合の未知行動を認識する場面は2つあると考えられる。

1. 未知クラスと既知クラスが両方介護行動の場合
2. 未知クラスが介護行動の場合

1つ目の場面は、一部の介護行動の教師データが存在しなくても介護記録の自動化が行えるという設定である。この場面を考えると、以下のことが考えられる。(1) 新人が入ってきて、教師データが存在しない場合。(2) システムが導入されたばかりで、基本的にデータが存在しない場合。(3) 新しい業務ができた場合。これらの全ての場面を考えても、期間は短いと想定される。なぜなら、1日で少しのデータは収集することができるため、もし教師データが1日である程度収集できるのならば、Zero-shot 学習ではなく、Few-shot 学習や one-shot 学習法といった手法も考慮し、比較することが重要であると考えられる。

2つ目の場面は、そもそも介護現場でデータ収集が難しいという仮定である。著者の想定していた設定はこちらに近く、介護施設でセンサデータを収集することは可能であっても、正確な行動ラベルがアノテーションされた教師データの収集は、介護士の協力があっても、普段の業務が忙しい介護士にとっては困難なタスクである。そのため、短時間で素早く収集できる「単純な行動」、例えば「走る」や「座る」、「棚から取る」などの行動を既知クラスとすることが有用な Zero-shot 学習法であると考えられる。今後は、「単純な行動」と「複雑な行動」とで分けて、そのセンサ的な関係とテキストの関係が類似するようなデータの収集方法を考えるべきと思う。

6.2.2 属性ベクトルと単語ベクトルの比較

今回の結果から、単語ベクトルの方が一般的な実用化という面で属性ベクトルに勝っているということを考察で述べた。しかし、行動認識する用途やデータによって違う選択するべきであるとも考えている。確かに、Wikipedia から単語ベクトルを自動で生成されることで未知クラスが推定できるのであれば、万能である。しかし、人の行動、特に動きとして見ると個人差があるため、一般化が難しい分野であり、万能な手法がないと考えるのが自然である。特に単語ベクトルは、単語の類似度の精度を上げることを目的として生成されるため、行動の類似度と言われた時、加速度データと行動の意味的な類似度の相関が一致することは難しいと考えられる。

これらの理由から、単語ベクトルを用いる際には一般的な知識で類似する行動、そしてそれに対応するデータを入力データとして用いることが最適であると考えられる。例えば、環境センサを入力データとした時に、意味的にも単語で表されるため、一般化しやすい。例えば、「料理をする」と「歯磨き」という行動があった時、センサデータ側で同じ水を扱う行動として類似するし、テキスト情報として記載があれば、意味的に類似する。

一方、加速度データを用いる場合は、属性ベクトルを用いる方がいいと思われる。しかし、その場合、属性の決め方に注意が必要である。著者が属性の指標とすると良いと思っている基準が2つあり、1つは体の箇所ごとの動きを属性とする場合、2つ目は時系列的にする動きである。体の箇所に依存する属性例としては、足を上げる、手をふる、というように、体の箇所の名前と動きをセットとした属性を生成し、それに対応する箇所にウェアラブルデバイスを固定させる必要があると思っている。2つ目の時系列に並んだ行動を属性基準とするということは、例えば料理の行動で、野菜をきり、フライパンに油をしき、野菜を入れる、などの一連の行動を属性にするということである。

しかし、属性を重複させるように生成するためには属性の決め方はやはり手間のかかる作業である。このように、データと用途によって、属性ベクトルを使うのか、単語ベクトルを使うのかということを決めるのがいいと考える。

介護現場を考えると、業務の行動には予期しない動作が入ることが多いため、マニュアル通りの動きをすることはないかもしれない。それを考えると、環境センサ + 単語ベクトルを用いることが適切であると考えられ、さらに環境の違いに対してもその施設のマニュアルや過去の介護記録などを単語ベクトル生成のための学習データとして用いればオリジナルの推定ができる可能性がある。

6.2.3 Zero-shot 学習法の未知行動推定以外の可能性

Zero-shot 学習法は、属性を正しく推定することで未知クラス推定を可能にするアプローチである。この考え方は、未知クラス推定だけでなく、一般的な機械学習の特徴量抽出に類似する部分がある。特に Deep learning 手法を評価するために、Zero-shot 学習の考え方を用いることもできる [131]。また、Deep learning 構造の Zero-shot 学習法は画像認識手法で提案されているが、センサ行動認識手法では少なく、今後進めていきたい課題である [132]。画像認識と違って、センサ行動認識の特徴量を抽出することができるのかどうか、人の定義する特徴量と一致するのかどうか、という部分で疑問があるため、その追求をするために、Zero-shot 学習法の評価と同時に Deep learning モデルの特徴量抽出の評価にも繋がると考えている。

6.2.4 行動認識の実用化

本研究では、行動認識手法を介護現場へ応用させることを目的としているが、実際の現場のデータを用いて評価には至っていない。しかし、介護業務の行動認識における行動認識への取

り組み自体が未だ少ない。2019年のUbicomp2019国際会議のHASCAワークショップでは、モーションキャプチャデータとスマートフォン内臓の加速度センサに介護行動をアノテーションしたデータセットを公開し、参加者のモデルを競い合うことをした [32]。また、実際の介護施設でデータセットを収集し、分析する取り組みもある [31]。

これらのデータ収集のとき、よく議論される話題としては、どのような行動ラベルをアノテーションするかということである。介護行動の種類として、「移乗介助」や「食事準備」などの行動があるが、これらの行動には「高齢者をベッドから起こす」、「車椅子に運ぶ」といった動作や「食卓を拭く」、「高齢者の口に食事を運ぶ」といった行動が含まれる。そして、それらの行動は、対応する高齢者によって違ってくる。つまり、介護行動を直接的に推定しようとすると、難しい。そこで、行動のオントロジーを定義し、詳細行動までをアノテーションする必要があると考えられるため、スマートウォッチのような手元で簡単に行動アノテーションの切り替えができるデータ収集方法も今後進めていきたい [33]。

6.3 介護分野における現在の取り組みと今後の展望

ここでは、現在介護施設でのIoT(Internet of Things)化を目指した取り組みと今後の展望について考察したことを述べる。北九州市は、先進的な介護の実現を目指し、介護ロボットの実証に着手している。以下では、主に2019年10月21日の北九州国際会議場で行われた「介護ロボット導入セミナー」で発表された内容に基づいて述べる。北九州市は実証に着手する過程で、まず介護の作業分析を行い、どの作業について効率化を測るかの考察を行なっている。分析の結果は図6.1に示すように、大きく分け、「直接介護」と「間接介護」の2つのタイプに作業を分類している。直接介護とは、介護動作を支援するロボットが必要な作業と定義されており、例えば、食事や、見守りなどの作業が含まれる。つまり、介護というサービスの仕事で自動化できない、介護士が必要な作業を示し、ロボットなどの最新技術での「支援」が必要とされている作業である。間接介護とは、人の代わりにするロボットの導入を検討する作業と定義されており、記録・会議、更衣、清掃などが含まれている。つまり、介護士の代わりにロボットやシステムが自動的に行うことが許される作業である。直接介護は、全体の45.5%で間接介護は54.4%の割合を占めているという調査結果となった。北九州市は間接介護に焦点をあて、いくつかの介護施設で実証実験を行なっている。

実証機器について具体例を述べると、移乗介助を目的としたものは、安川電機の「移乗アシス

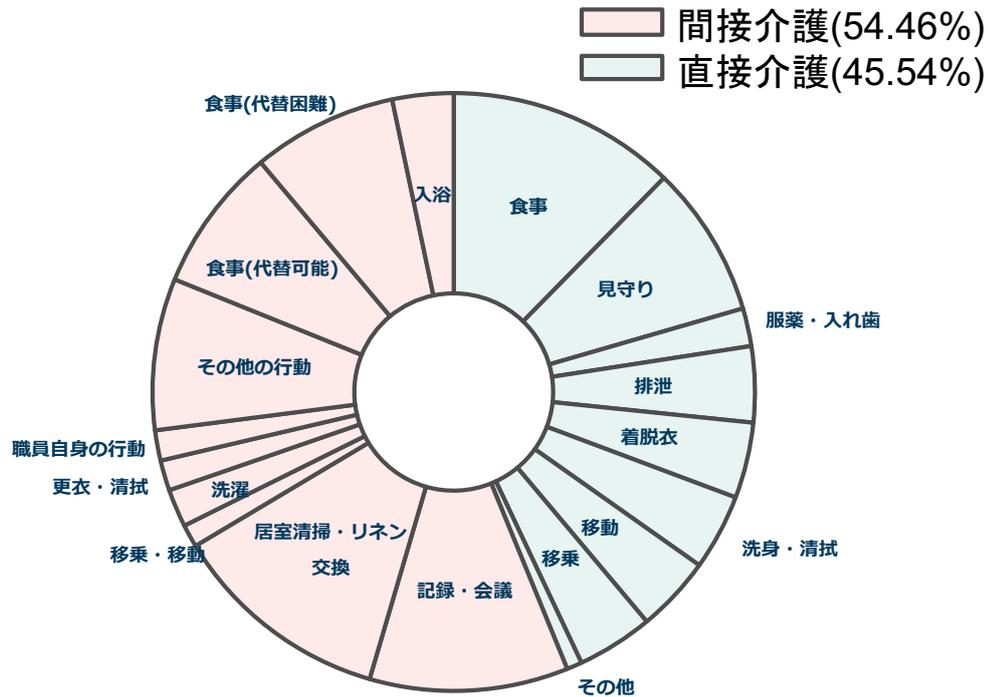


図 6.1 北九州市が分析した介護タスクの種類と分類結果。直接介護とは介護動作を支援するロボットが必要なタスクで、間接介護は人の代わりにするロボット導入を検討しているタスクを指す。

ト装置^{*1}、パラマウントベッドの「SASUKE」^{*2}、富士機械製造の「Hug」^{*3}がある。見守りを目的としたものは、ラムロックの「見守り CUBE」^{*4}、ノーリプレジジョンの「Neos+Care」^{*5}、記録を目的としたものは、インフォメクス「すまー人!Helper」^{*6}、情報共有を目的としたものは、「インカム」、コミュニケーションを目的としたものは、富士ソフトの「パルロ」^{*7}がある。

まず、情報共有「インカム」を用いた結果職員同士の会話の時間が減り、入居者との会話が増えるということがわかった。つまり、情報共有が遠隔でも可能になったため、介護士同士での情報共有のために探し回る手間が減り、その分サービスの向上に繋がっていることがわかる。次に、移乗支援機器の導入後、職員に腰痛の改善が必要かどうかのアンケートをした結果、

*1 https://www.youtube.com/watch?v=X1p_HAPgRyA

*2 <https://www.paramount.co.jp/news/detail/17>

*3 <https://www.fuji.co.jp/about/hug/>

*4 <https://ramrock-eyes.jp/>

*5 <https://www.noritsu-precision.com/neoscare/>

*6 <https://www.infomex.jp/75253.html>

*7 <https://palro.jp/>

「改善の必要なし」と答えた人が24.9%増加した。つまり、介護士への負担が軽減され、さらに入居者の出血や打撲のリスクが低減されたという結果になった。次に、見守り機器を導入した結果、不必要な見守りや訪室が90分減少し、その分寝具の手直し時間が35分増加するということがわかった。つまり、見守り時間の効率化がおこなわれ、寝具の手直しの必要なタイミングがわかるために、時間が増加しサービスの向上が見られた。

これらの取り組みのように、未だ実証実験段階ではあるが、テストし分析し、効果を示したり、課題を示したりする取り組みが必要であり、貴重な財産であると思う。本博士論文の4のように、既に存在する製品のデータを用いて分析する取り組みは重要であると思うが、この研究では生データを収集するためにその製品の機能は使えないようにしている。したがって、今後製品を開発するときに、生データも収集できるような仕組みがあることで、貴重な実データが収集でき、今後の介護分野の技術発展は促進すると考えられる。

第7章

まとめ

本博士論文では、ユビキタスコンピューティング社会の実現を目指すユビキタスコンピューティング研究のシステムをもとに、介護分野における応用に向けた研究を紹介した。特に、データマイニング技術を用いた研究と行動認識技術の研究について述べた。

データマイニング技術を用いることで、実世界から収集されたデータの活用法の検討やフィードバック方法の提案が可能となる。

3章では、あまり焦点を当てられない介護施設に入居する前の相談者のデータを分析し、課題や傾向を発掘する。そうすることで、「準備期期間が2ヶ月違うことで成約率が4倍違うこと」や「突然の入院や一人暮らしによって介護施設を探すことになったこと」のように、今度の相談者に有用な知見、また、「交通手段の有無が見学に行くかどうか重要な要因であること」といった介護施設に有用な知見、合計10件ほど示した。また、現在の入居後の金銭的なトラブルや早期待機の原因となる課題の解決案について、レコメンド機能を考察部分で提案する。

4章では、介護施設に入居する高齢者の見守りをより効率化する必要があるという背景に、高齢者のセンシング実験とデータマイニングを行う研究について紹介した。そうすることで、「運動する日は8時頃入眠する傾向にあること」や「運動した日の前日の睡眠は質がいいこと」といった介護士の業務改善に有用な知見を得ることができた。さらに、今後の介護分野に導入するデバイスに対して、見守り機能を介護施設に提供するだけでなく、生データを収集する機能を付け加えることで、今後の介護分野への技術的な促進に貢献できることを考察として述べた。

また、行動認識技術を用いることで、介護業務の効率化をすることができることを示した。さらに本博士論文では、行動認識技術を応用させるためにはデータ収集問題を解決する必要性について述べ、5章では、未知行動認識手法の研究を紹介した。この研究の結果、これまで

データ収集やデータ作成がボトルネックであった行動認識手法の問題点解決のための、自然言語処理技術を用いた Zero-shot 学習法の有用性を示すことができた。さらに、そこから得られた知見から、今後の行動認識技術を実用化するにはどのようなことが必要か、介護行動を認識するためにはどのようなことを考える必要があるのかについての考察を述べた。

謝辞

本研究を進めるにあたって、学部4年生から博士課程3年までの5年間にわたり、ご指導、ご鞭撻を賜りました九州工業大学大学院工学研究院基礎科学研究系 井上創造准教授に深く感謝申し上げます。

そして、主査である九州工業大学大学院 三浦元喜准教授、副査である、九州工業大学大学院 浅海賢一教授、同大学 西田健准教授に深く感謝申し上げます。

3章の研究にあたりまして、ご指導、執筆に多大な貢献を賜りました、株式会社 LIFULL 主席研究員 清田陽司博士に深く感謝申し上げます。また、データをご提供していただきました株式会社 LIFULL(LIFULL Lab) 様、貴重なご意見をいただきました、株式会社 LIFULL senior の水崎創介氏、泉雅人氏、望月義隆氏、北山典子氏、薄葉元紀氏に感謝申し上げます。

4章の研究にあたりまして、データ収集にご協力いただきました介護施設さわやか海響館様、並びに介護スタッフの皆様方、被験者とそのご家族の皆様方に深く感謝申し上げます。また、デバイスにおいての改造にご協力いただきました、九州工業大学 佐藤寧教授、株式会社ひびきの電子様に深く感謝申し上げます。また、地域イノベーション推進機構の関係者の皆様方に深く感謝申し上げます。

5章の研究にあたりまして、ご指導、執筆に多大な貢献を賜りました九州工業大学大学院 井上研究室所属 博士研究員 Paula Lago 博士に深く感謝申し上げます。

インターンを3ヶ月間受け入れてくださり、貴重なご意見を賜りました、フランス国立研究所 Inria の Larsen チーム代表の François Charpillet 博士とそのチームのメンバーに感謝いたします。

1ヶ月のインターンを受け入れてくださり、貴重なご意見を賜りました大阪大学の原隆浩教授とご指導賜りました前川卓也博士に感謝いたします。

貴重な研究議論の場と研究費を支援していただきました、JST ACT-I の関係者の皆様方、またご指導賜りましたアドバイザーの東京大学川原圭博教授に感謝いたします。

ご指導賜りました，九州工業大学大学院 花沢明俊准教授，同大学 木村広准教授の情報セクション先生方に厚く御礼申し上げます。

様々な場面でお世話していただきました内野百合さん，内野翔さん，河野博光氏，九州工業大学 中尾基教授，松田美智子氏に深く感謝申し上げます。

留学費などの支援をいただきました Prost プログラムの関係者の皆さま，創設者の九州工業大学 米本浩一教授と様々な場面でお世話していただきました，中本泉氏に深く感謝申し上げます。

研究にあたる大事な事務処理のご支援やお世話していただきました，藤森恵美子氏，奥菌浩美氏，白石涼子氏，房前悟氏に深く感謝申し上げます。

研究に携わった1年目の際に，ご指導賜りました谷口淳氏に感謝申し上げます。また，磯田達也氏，潘新程氏，田中翔太氏，本多弘典氏，戸田隆道氏，林田興祐氏，右田尚人氏，亀津達也氏，峯崎智裕氏，中村優斗氏，竹森正起氏，李林氏，服部祐一氏，並びに井上創造研究室を卒業された方々に深く感謝申し上げます。

共に切磋琢磨で研究を論文として形にしてくださった，竹下昌志氏，真子みなみ氏，二宮仁志氏に深く感謝申し上げます。

セミナー等で貴重な議論をしていただきました，Tahera Hossain 氏，Nattaya Mairittha 氏，Tittaya Marittha 氏，武田紳吾氏，朱琳氏，土井祐介氏，後藤広樹氏，Nour Al Bogha 氏，Md. Shafiqul Islam 氏，Sayeda Shamma Alia 氏，Farina Faiz 氏，吉永章太朗氏，西村勇亮氏，金子晴氏，安達康平氏，Brahim Benaissa 氏，Defry Hamdhana 氏，Muhammad Fikry 氏，の井上創造研究室的メンバーに感謝申し上げます。

共同研究してくださった，九州大学 Vasconcellos Vargas Danilo 准教授，藤野慶汰氏，大森雄馬氏に深く感謝申し上げます。

博士論文執筆の際，貴重なご意見をいただきました，神戸大学 大西鮎美博士，大阪府立大学 近藤大嗣博士に深く感謝申し上げます。

研究の楽しさと研究者の議論の場，発表の場を与えてくださいました，WBA 若手の会創設者，大澤正彦氏，WBA 若手の会代表 八木拓真氏，WBA 若手の会九州支部代表 上妻真緒氏，並びに関係者の皆さまに感謝深く感謝申し上げます。

国際会議での運営などでお世話になりました，大阪大学 Md. Atiqur Rahman 准教授に深く感謝申し上げます。

研究に関する申請書の添削とご指導を賜りました，櫻惇志博士，米澤恵一朗博士に深く感謝

申し上げます。

データ収集のアプリケーション開発にご協力いただいた，株式会社 Corpy & Co. CEO 山元浩平，同会社 Iordan Iordanov Marinov 博士に深く感謝申し上げます。

勉強会でお世話になりました，吉田香准教授，大坪正和氏，土田崇弘氏，金津達也氏，宮武順平氏，石川友紀也氏，末松圭史氏，並びに吉田香研究室のメンバーの皆様に深く感謝申し上げます。

学部1年生の頃からお世話していただきました，明専会の方々に深く感謝申し上げます。

最後に，これまでの26年間支えていただいた家族の皆さまに深く感謝を申し上げます。

参考文献

- [1] Hammerla, Nils Y., Shane Halloran, and Thomas Plötz. "Deep, convolutional, and recurrent models for human activity recognition using wearables." arXiv preprint arXiv:1604.08880 (2016).
- [2] Bulling, Andreas, Ulf Blanke, and Bernt Schiele. "A tutorial on human activity recognition using body-worn inertial sensors." *ACM Computing Surveys (CSUR)* 46.3 (2014): 33.
- [3] 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.
- [4] Tamura, Yoshifumi, et al. "Effects of diet and exercise on muscle and liver intracellular lipid contents and insulin sensitivity in type 2 diabetic patients." *The journal of clinical endocrinology & metabolism* 90.6 (2005): 3191-3196.
- [5] Yin, Jie, Qiang Yang, and Jeffrey Junfeng Pan. "Sensor-based abnormal human-activity detection." *IEEE Transactions on Knowledge and Data Engineering* 20.8 (2008): 1082-1090.
- [6] Medjahed, Hamid, et al. "Human activities of daily living recognition using fuzzy logic for elderly home monitoring." *2009 IEEE International Conference on Fuzzy Systems*. IEEE, (2009).
- [7] 大木康頌, 栗原陽介, and 鎬木崇史. "尿意予測システムのための水分代謝系数理モデルの提案." *第79回全国大会講演論文集 2017.1* (2017): 581-582.
- [8] 下坂正倫. "人間行動センシングデータに基づく生活リズム解析." *計測と制御* 53.7 (2014): 611-616.
- [9] 恒川充, et al. "健診データを用いた生活習慣病の発症予測." *人工知能学会全国大会論文*

- 集 一般社団法人 人工知能学会. 一般社団法人 人工知能学会, (2019).
- [10] Takuma Yagi, Karttikeya Mangalam, Ryo Yonetani, Yoichi Sato; "Future Person Localization in First-Person Videos"; The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (2018), pp. 7593-7602
- [11] Lan, Tian, Tsung-Chuan Chen, and Silvio Savarese. "A hierarchical representation for future action prediction." European Conference on Computer Vision. Springer, Cham, (2014).
- [12] Kong, Yu, and Yun Fu. "Human action recognition and prediction: A survey." arXiv preprint arXiv:1806.11230 (2018).
- [13] Hussain, Zawar, Michael Sheng, and Wei Emma Zhang. "Different Approaches for Human Activity Recognition: A Survey." arXiv preprint arXiv:1906.05074 (2019).
- [14] Amendola, Sara, et al. "RFID technology for IoT-based personal healthcare in smart spaces." IEEE Internet of things journal 1.2 (2014): 144-152.
- [15] Wang, Jindong, et al. "Deep learning for sensor-based activity recognition: A survey." Pattern Recognition Letters 119 (2019): 3-11.
- [16] Scholz, Markus, et al. "Challenges for device-free radio-based activity recognition." Proceedings of the 3rd workshop on Context Systems, Design, Evaluation and Optimisation (CoSDEO 2011), in Conjunction with MobiQuitous. Vol. 2011. (2011).
- [17] Mitra, Sushmita, and Tinku Acharya. "Gesture recognition: A survey." IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews) 37.3 (2007): 311-324.
- [18] Aguilera, A.A.; Brena, R.F.; Mayora, O.; Molino-Minero-Re, E.; Trejo, L.A. Multi-Sensor Fusion for Activity Recognition—A Survey. Sensors 2019, 19, (2019), 3808.
- [19] Chen, Liming, et al. "Sensor-based activity recognition." IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews) 42.6 (2012): 790-808.
- [20] Scholz, Markus, et al. "Challenges for device-free radio-based activity recognition." Proceedings of the 3rd workshop on Context Systems, Design, Evaluation and Optimisation (CoSDEO 2011), in Conjunction with MobiQuitous. Vol. (2011). 2011.
- [21] Shoaib, Muhammad, et al. "A survey of online activity recognition using mobile phones." Sensors 15.1 (2015): 2059-2085.

- [22] Herath, Samitha, Mehrtash Harandi, and Fatih Porikli. "Going deeper into action recognition: A survey." *Image and vision computing* 60 (2017): 4-21.
- [23] Poppe, Ronald. "A survey on vision-based human action recognition." *Image and vision computing* 28.6 (2010): 976-990.
- [24] Cheng, Guangchun, et al. "Advances in human action recognition: A survey." *arXiv preprint arXiv:1501.05964* (2015).
- [25] Bhoi, Amlaan. "Spatio-temporal Action Recognition: A Survey." *arXiv preprint arXiv:1901.09403* (2019).
- [26] Kong, Yu, and Yun Fu. "Human action recognition and prediction: A survey." *arXiv preprint arXiv:1806.11230* (2018).
- [27] Aggarwal, Jake K., and Lu Xia. "Human activity recognition from 3d data: A review." *Pattern Recognition Letters* 48 (2014): 70-80.
- [28] Vrigkas, Michalis, Christophoros Nikou, and Ioannis A. Kakadiaris. "A review of human activity recognition methods." *Frontiers in Robotics and AI* 2 (2015): 28.
- [29] 松木萌, 井上創造, and 清田陽司. "介護施設紹介コールセンター記録のアンサンブル学習による傾向分析." *マルチメディア, 分散協調とモバイルシンポジウム 2017 論文集 2017* (2017): 648-655.
- [30] Qingxin, Xia, et al. "Unsupervised Factory Activity Recognition with Wearable Sensors Using Process Instruction Information." *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 3.2 (2019): 60.
- [31] Inoue, Sozo, et al. "Integrating Activity Recognition and Nursing Care Records: The System, Deployment, and a Verification Study." *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 3.3 (2019): 1-24.
- [32] Paula Lago, Sayeda Shamma Alia, 武田 紳吾, Tittaya Marittha, Nattaya Mairittha, Farina Faiz, 西村 勇亮, 安達康平, 大北 剛, François Charpillet, 井上 創造, "Nurse Care Activity Recognition Challenge: Summary and Results", *UbiComp Workshop on Human Activity Sensing Corpus and Applications (HASCA)*, (2019)
- [33] 真子 みなみ, 松木 萌, 井上 創造, "腕時計型入力インタフェースによる介護行動記録の効率化の試み", *日本知能情報ファジィ学会九州支部学術講演会予稿集*, (2019)
- [34] Clemente, Jose, et al. "Indoor person identification and fall detection through non-

- intrusive floor seismic sensing.” 2019 IEEE International Conference on Smart Computing (SMARTCOMP). IEEE, 2019.
- [35] 介護の5つの問題とは？老老介護から虐待まで原因と解決策総まとめ (最終閲覧日：2019年12月20日), <https://www.irs.jp/article/?p=544>.
- [36] 日本創生会議. ”東京圏高齢化危機回避戦略.”, 2015年, (最終閲覧日：2019年12月20日), <http://www.policycouncil.jp/pdf/prop04/prop04.pdf>.
- [37] 公益財団法人 介護労働安定センター, ”「介護サービスの利用に係る事故の防止に関する調査研究事業」報告書”, 2018年,(最終閲覧日：2019年12月20日), http://www.kaigo-center.or.jp/report/pdf/h30_kaigojiko_houkoku_20180402.pdf
- [38] 日本経済新聞, ”介護の死亡事故 1500人 厚労省, 初の全国調査”, 2019年3月 (最終閲覧: 2019年12月), <https://www.nikkei.com/article/DGXMZ042465790U9A310C1CR8000/>
- [39] 厚生労働省” 介護人材の処遇改善について” 社保審－介護給付費分科会 第161回, 2018年9月 (最終閲覧：2019年12月), <https://www.mhlw.go.jp/content/12601000/000349994.pdf>
- [40] 経済産業省 ”将来の介護需給に対する高齢者ケアシステムに関する研究会報告書”, 2018年4月, (最終閲覧：2019年12月), <https://www.meti.go.jp/press/2018/04/20180409004/20180409004-2.pdf>
- [41] 内閣府男女共同参画局 ”男女共同参画白書 平成30年版 I－特－43 図 要介護認定者数と認定率（年齢階級別）”, (最終閲覧：2019年12月), http://www.gender.go.jp/about_danjo/whitepaper/h30/zentai/html/zuhyo/zuhyo01-00-43.html
- [42] 内閣府, ”高齢化の状況（第1節1）” 高齢社会白書 (最終閲覧日：2019年12月20日) \footnote{\a href="https://www8.cao.go.jp/kourei/whitepaper/w\2018/html/zenbun/s1\1\1.html">https://www8.cao.go.jp/kourei/whitepaper/w\2018/html/zenbun/s1\1\1.html}
- [43] 厚生労働省：2025年に向けた介護人材にかかる需給推計（確定値）について, 2015年, (最終閲覧日：2019年12月20日), <http://www.mhlw.go.jp/file/04-Houdouhappyou-12004000-Shakaiengokyoku->.
- [44] 周燕飛. ”介護施設における介護職員不足問題の経済分析.” 医療と社会 19.2 (2009): 151-168.
- [45] 花岡智恵. ”介護労働者の早期離職要因に関する実証分析.” (2010).

- [46] 金竹香織, 小林一郎, and 橋田浩一. "介護支援システムにおける介護データの構造化と入
力インタフェースの開発." 第 76 回全国大会講演論文集 2014.1 (2014): 161-162.
- [47] Mairittha, Nattaya, Tittaya Mairittha, and Sozo Inoue. "A Mobile App for Nurs-
ing Activity Recognition." Proceedings of the 2018 ACM International Joint Confer-
ence and 2018 International Symposium on Pervasive and Ubiquitous Computing and
Wearable Computers. ACM, (2018).
- [48] 三輪洋靖, et al. "介護プロセスの計測と記述." 日本機械学会論文集 (2015): 14-00207.
- [49] 福原知宏, et al. "情報推薦を用いた高齢者介護施設向け申し送り業務支援システム." 人
工知能学会論文誌 28.6 (2013): 468-479.
- [50] 三田寺裕治, and 赤澤宏平. "介護保険施設における介護事故の発生状況に関する分析." 社
会医学研究 30.2 (2013): 123-130.
- [51] 中野一茂. "特別養護老人ホームにおける排泄時の転倒・転落について: その防止策の考
察." 共栄学園短期大学研究紀要 (2010): 26: 29-38.
- [52] 毛利光伸: 実用的になった介護ロボット,ARC レポート, (2016).
- [53] 厚生労働省: 第 4 章見守り支援機器 (介護施設), (最終閲覧日: 2019 年 12 月
20 日), [http://www.mhlw.go.jp/sinsei/chotatu/chotatu/wto-kobetu/2017/02/
dl/wt0227-04_08.pdf](http://www.mhlw.go.jp/sinsei/chotatu/chotatu/wto-kobetu/2017/02/dl/wt0227-04_08.pdf).
- [54] 北九州市ホームページ 介護ロボット等導入実証事業ワーキンググループ, (最終閲覧
日: 2019 年 12 月 20 日), [http://www.city.kitakyushu.lg.jp/ho-huku/18200090.
html](http://www.city.kitakyushu.lg.jp/ho-huku/18200090.html).
- [55] 峯崎智裕, 松木萌, and 井上創造. "介護サービス向上に向けた介護事故事例テキストの分
析." 情報処理学会論文誌 58.10 (2017): 1701-1711.
- [56] 長谷川大悟, 藤田好彦, 坂本晴美, 巻直樹, 若山修一, 稲田晴彦, & 柳久子. 介護老人保健施
設入所者の転倒発生状況. 日本転倒予防学会誌, 2(3), (2016): 23-32.
- [57] 福田賢一郎, et al. "介護現場における申し送り情報の分析: 業務改善に向けて (言語理解
とコミュニケーション)-(第 5 回テキストマイニング・シンポジウム)." 電子情報通信学
会技術研究報告= IEICE technical report: 信学技報 114.211 (2014): 11-16.
- [58] 那須川 哲哉: コールセンターにおけるテキストマイニング (<特集>「テキストマイニン
グ」), 人工知能学会誌, Vol. 16, No. 2, pp. 219-225 (2001).
- [59] "LIFULL 介護 QA 集".(最終閲覧日: 2019 年 12 月 20 日), <https://kaigo.homes.co>.

- jp/qa_article/92/.
- [60] “LIFULL 介護 老人ホームの費用”, (最終閲覧日: 2019 年 12 月 20 日), https://kaigo.homes.co.jp/manual/facilities_comment/cost/Difficult_payment/.
- [61] “厚生労働省 介護・高齢者福祉政策”.(最終閲覧日: 2019 年 12 月 20 日), https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/hukushi_kaigo/kaigo_koureisha/index.html
- [62] Li, Yue, Xueya Cai, and Matthew Wang. ”Social media ratings of nursing homes associated with experience of care and “Nursing Home Compare” quality measures.” *BMC health services research* 19.1 (2019): 260.
- [63] 日本生活習慣病予防協会, (最終閲覧日: 2019 年 12 月 20 日), <http://www.seikatsusyukanbyo.com/statistics/disease/dyssomnia/>.
- [64] Ganguli, Mary, Charles F. Reynolds, and Joanne E. Gilby. ”Prevalence and persistence of sleep complaints in a rural older community sample: the MoVIES project.” *Journal of the American Geriatrics Society* 44.7 (1996): 778-784.
- [65] 厚生労働省: 知ることから始めよう みんなのヘルスケア, (最終閲覧日: 2019 年 12 月 20 日),http://www.mhlw.go.jp/kokoro/know/disease_sleep.html.
- [66] 亀山研一, 鈴木琢治, and 行谷まち子. ”快眠のための睡眠判定と睡眠モニタシステム.” *東芝レビュー* 61.10 (2006): 41-44.
- [67] 指田岳彦, 工藤雄太, and 青木義満. ”3次元人物姿勢情報を用いた睡眠時行動認識への取り組み.” *Konica Minolta technology report* 12 (2015): 88-92.
- [68] Shirota, Ai, et al. ”Effects of daytime activity on nocturnal sleep in the elderly.” *Psychiatry and clinical neurosciences* 54.3 (2000): 309-310.
- [69] Videnovic, Aleksandar, et al. ”Daytime somnolence and nocturnal sleep disturbances in Huntington disease.” *Parkinsonism & related disorders* 15.6 (2009): 471-474.
- [70] C-oté, K. A., and Harvey Moldofsky. ”Sleep, daytime symptoms, and cognitive performance in patients with fibromyalgia.” *The Journal of rheumatology* 24.10 (1997): 2014-2023.
- [71] Breiman, Leo. ”Random forests.” *Machine learning* 45.1 (2001): 5-32.
- [72] Inoue, Sozo, et al. ”Mobile activity recognition for a whole day: recognizing real nursing activities with big dataset.” *Proceedings of the 2015 ACM International Joint*

- Conference on Pervasive and Ubiquitous Computing. 2015.
- [73] 井上創造. ”ウェアラブルセンサを用いたヒューマンセンシング.” 知能と情報 28.6 (2016): 170-186.
- [74] 工藤 拓、松本 裕治, “チャンキングの段階適用による日本語係り受け解析”, 情報処理学会論文誌, vol.43, num.6, pp 1834-1842, 2002.
- [75] Seni, Giovanni, and John F. Elder. ”Ensemble methods in data mining: improving accuracy through combining predictions.” Synthesis lectures on data mining and knowledge discovery 2.1 (2010): 1-126.
- [76] Elghazel, Haytham, and Alex Aussem. ”Unsupervised feature selection with ensemble learning.” Machine Learning 98.1-2 (2015): 157-180.
- [77] Wiering, Marco A., and Hado Van Hasselt. ”Ensemble algorithms in reinforcement learning.” IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics) 38.4 (2008): 930-936.
- [78] スマート介護: 離床センサー・超音波離床検知システム離床センサ, (最終閲覧日: 2019年12月20日), <https://d11w49g8ylcixs.cloudfront.net/resource/20160629/797.pdf>
- [79] Chen, Tianqi, and Carlos Guestrin. ”Xgboost: A scalable tree boosting system.” Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining. 2016.
- [80] Brandon M. Greenwell, pdp: An R Package for Constructing Partial Dependence Plots, 2017, The R Journal, p.421-436, vol.9,num.1
- [81] ベネッセ: 介護に関する意識調査 報告書 (詳細版). (最終閲覧日: 2019年12月20日), https://www.benesse-style-care.co.jp/lab/research/docs/20160323_report2.pdf
- [82] 厚生労働省: 平均寿命と健康寿命をみる 0416, (最終閲覧日: 2019年12月20日), https://www.mhlw.go.jp/bunya/kenkou/dl/chiiki-gyousei_03_02.pdf
- [83] 厚生労働省: 介護事業所・生活関連情報検索 「平成 27 年度介護報酬改定に向けて (社) 全国有料老人ホーム協会 「有料老人ホーム・サービス付き高齢者向け住宅に関する実態調査研究」 サービス付き高齢者向け住宅情報提供サービス, (最終閲覧日: 2019年12月20日), <http://www.mhlw.go.jp/stf/seisakunitsuite/bunya/hukushikaigo/>

- kaigokoureisha/kouhyou/index.html.
- [84] Google API, available from, (最終閲覧日: 2019年12月20日), <https://cloud.google.com/natural-language/docs/analyzing-sentiment?hl=ja>.
- [85] 田中 仁, 中内 靖: ユビキタスセンサによる独居高齢者見守りシステム (機械力学, 計測, 自動制御), 日本機械学会論文集 (編, Vol.75, No.760, pp.3244-3252(オンライン), DOI: 10.1299/kikaic.75.3244 (2009).
- [86] 鹿島久嗣, 梶野 洗: クラウドソーシングと機械学習 (特集: 知識の転移), 人工知能学会誌, Vol.27, No.4, pp.381-388 (2012).
- [87] 榎本みのり, 有竹さやか, 三島和夫: 認知症の睡眠障害, Vol. 45, pp. 739-743.
- [88] A,A.,B,F.,M,J.,K,S.,G,W.andR,C.: Insomnia and Hypnotic Use, Recorded in the Minimum Data Set, as Predictors of Falls and Hip Fractures in Michigan Nursing Homes, Journal of the American Geriatrics Society, Vol. 53, No. 6, pp. 955-962 (online), DOI: 10.1111/j.15325415.2005.53304.x (2005).
- [89] 厚生労働省: 平成 28 年 国民生活基礎調査の概況,(最終閲覧日: 2019年12月20日), <https://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa16/dl/16.pdf>
- [90] 安心介護: 介護現場でお金のトラブルが起こるケースとその対策,(最終閲覧日: 2019年12月20日), <https://ansinkaigo.jp/knowledge/241>
- [91] 北九州市: 注意! 介護保険料の還付金等詐欺 (詐欺未遂) が発生しています,(最終閲覧日: 2019年12月20日), <https://www.city.kitakyushu.lg.jp/ho-huku/16800181.html>
- [92] シニアの安心相談室: 介護施設の退去理由上位 想定外の事態を防ぐために知っておこう!,(最終閲覧日: 2019年12月20日), <https://kaigo.soudan-anshin.com/news/kaigo/20170920/>
- [93] 元田浩, and 鷺尾隆. "機械学習とデータマイニング (特集: 大規模データベースからの知識獲得)." 人工知能学会誌 12.4 (1997): 505-512.
- [94] 鷺尾隆: データマイニングとは?, (最終閲覧日: 2019年12月20日) <http://www-erato.ist.hokudai.ac.jp/lecture2012/material/washio-1.pdf>
- [95] L. Ren and Y. Peng, "Research of Fall Detection and Fall Prevention Technologies: A Systematic Review," in IEEE Access, vol. 7, pp. 77702-77722, (2019).
- [96] Bağcı, Hazel, and Şebnem Çınar Yücel. "Effect of Therapeutic Touch on Sleep Quality in Elders Living at Nursing Homes." Journal of religion and health (2019): 1-15.

- [97] 鹿島久嗣, 櫻井祐子, and 松原繁夫. "OS-07 「ヒューマンコンピューテーションとクラウドソーシング」." 人工知能学会誌 28.6 (2013).
- [98] Lara, Oscar D., and Miguel A. Labrador. "A survey on human activity recognition using wearable sensors." *IEEE communications surveys & tutorials* 15.3 (2012): 1192-1209.
- [99] Ransing, R.S.; Rajput, M. Smart home for elderly care, based on Wireless Sensor Network. In *Proceedings of the 2015 International Conference on Nascent Technologies in the Engineering Field (ICNTE)*, Navi Mumbai, India, 9–10 January 2015; pp. 1–5.
- [100] Aehnelt, M.; Wegner, K. Learn but work!: Towards self-directed learning at mobile assembly workplaces. In *Proceedings of the 15th International Conference on Knowledge Technologies and Data-driven Business*, Graz, Austria, 21–22 October 2015; p. 17.
- [101] Perez, A.J.; Labrador, M.A.; Barbeau, S.J. G-sense: A scalable architecture for global sensing and monitoring. *IEEE Netw.* **2010**, *24*, 57–64.
- [102] Socher, R.; Ganjoo, M.; Manning, C.D.; Ng, A. Zero-shot learning through cross-modal transfer. In *Advances in Neural Information Processing Systems*; Curran Associates Inc., USA, 2013; pp. 935–943.
- [103] Zhang, Z.; Saligrama, V. Zero-shot recognition via structured prediction. In *European Conference on Computer Vision*, Springer: Cham, Switzerland, 2016; pp. 533–548.
- [104] Fu, Y.; Yang, Y.; Hospedales, T.; Xiang, T.; Gong, S. Transductive multi-label zero-shot learning. *arXiv* **2015**, arXiv:1503.07790.
- [105] Norouzi, M.; Mikolov, T.; Bengio, S.; Singer, Y.; Shlens, J.; Frome, A.; Corrado, G.S.; Dean, J. Zero-shot learning by convex combination of semantic embeddings. *arXiv* **2013**, arXiv:1312.5650.
- [106] Akata, Z.; Reed, S.; Walter, D.; Lee, H.; Schiele, B. Evaluation of output embeddings for fine-grained image classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, USA, 7–12 June 2015; pp. 2927–2936.

- [107] Bucher, M.; Herbin, S.; Jurie, F. Improving semantic embedding consistency by metric learning for zero-shot classification. In *European Conference on Computer Vision*; Springer: Cham, Switzerland, 2016; pp. 730–746.
- [108] Lampert, C.H.; Nickisch, H.; Harmeling, S. Learning to detect unseen object classes by between-class attribute transfer. In *Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 20–25 June 2009; pp. 951–958.
- [109] Guadarrama, S.; Krishnamoorthy, N.; Malkarnenkar, G.; Venugopalan, S.; Mooney, R.; Darrell, T.; Saenko, K. Youtube2text: Recognizing and describing arbitrary activities using semantic hierarchies and zero-shot recognition. In *Proceedings of the IEEE International Conference on Computer Vision*, Sydney, Australia, 1–8 December 2013; pp. 2712–2719.
- [110] Alexiou, I.; Xiang, T.; Gong, S. Exploring synonyms as context in zero-shot action recognition. In *Proceedings of the 2016 IEEE International Conference on Image Processing (ICIP)*, Phoenix, AZ, USA, 25–28 September 2016; pp. 4190–4194.
- [111] Xu, X.; Hospedales, T.; Gong, S. Semantic embedding space for zero-shot action recognition. In *Proceedings of the 2015 IEEE International Conference on Image Processing (ICIP)*, Quebec City, QC, Canada, 27–30 September 2015; pp. 63–67.
- [112] Xian, Y.; Akata, Z.; Sharma, G.; Nguyen, Q.; Hein, M.; Schiele, B. Latent embeddings for zero-shot classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 26 June–1 July 2016; pp. 69–77.
- [113] Vishwakarma, S.; Anupam A. A survey on activity recognition and behavior understanding in video surveillance. *Vis. Comput.* **2013**, *29*, 983-1009.
- [114] Tapia, E.M.; Intille, S.S.; Haskell, W.; Larson, K.; Wright, J.; King, A.; Friedman, R. Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor. In *Proceedings of the 2007 11th IEEE International Symposium on Wearable Computers*, Boston, MA, USA, 11–13 October 2007; pp. 37–40.
- [115] He, Z.; Jin, L. Activity recognition from acceleration data based on discrete cosine

- transform and svm. In Proceedings of the 2009 IEEE International Conference on Systems, Man and Cybernetics, San Antonio, TX, USA, 11–14 October 2009; pp. 5041–5044.
- [116] Parkka, J.; Ermes, M.; Korpipaa, P.; Mantyjarvi, J.; Peltola, J.; Korhonen, I. Activity classification using realistic data from wearable sensors. *IEEE Trans. Inf. Technol. Biomed.* **2006**, *10*, 119–128.
- [117] Peng, L.; Chen, L.; Ye, Z.; Zhang, Y. Aroma: A deep multi-task learning based simple and complex human activity recognition method using wearable sensors. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.* **2018**, *2*, 74.
- [118] Kwon, Y.; Kang, K.; Bae, C. Unsupervised learning for human activity recognition using smartphone sensors. *Expert Syst. Appl.* **2014**, *41*, 6067–6074.
- [119] Cook, D.; Feuz, K.D.; Krishnan, N.C. Transfer learning for activity recognition: A survey. *Knowl. Inf. Syst.* **2013**, *36*, 537–556.
- [120] Inoue, S.; Pan, X. Supervised and unsupervised transfer learning for activity recognition from simple in-home sensors. In Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services, Hiroshima, Japan, 28 November–1 December 2016; pp. 20–27.
- [121] Wang, W.; Zheng, V.W.; Yu, H.; Miao, C. A survey of zero-shot learning: Settings, methods, and applications. *ACM Trans. Intell. Syst. Technol. (TIST)* **2019**, *10*, 13:1–13:37.
- [122] Mikolov, T.; Sutskever, I.; Chen, K.; Corrado, G.S.; Dean, J. Distributed representations of words and phrases and their compositionality. In *Advances in Neural Information Processing Systems*; Curran Associates Inc., USA, 2013; pp. 3111–3119.
- [123] Mikolov, T.; Chen, K.; Corrado, G.; Dean, J. Efficient estimation of word representations in vector space. *arXiv* **2013**, arXiv:1301.3781.
- [124] Pennington, J.; Socher, R.; Manning, C. Glove: Global vectors for word representation. In Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP), in Doha, Qatar, 25–29 October 2014; pp. 1532–1543.
- [125] Cheng, H.T.; Sun, F.T.; Griss, M.; Davis, P.; Li, J.; You, D. Nuactiv: Recognizing unseen new activities using semantic attribute-based learning. In Proceeding of the

- 11th Annual International Conference on Mobile Systems, Applications, and Services, Taipei, Taiwan, 25–28 June 2013; pp. 361–374.
- [126] Cheng, H.T.; Griss, M.; Davis, P.; Li, J.; You, D. Towards zero-shot learning for human activity recognition using semantic attribute sequence model. In Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing, Zurich, Switzerland, 8–12 September 2013; pp. 355–358.
- [127] Roggen, D.; Calatroni, A.; Rossi, M.; Holleczeck, T.; Förster, K.; Tröster, G.; Lukowicz, P.; Bannach, D.; Pirkl, G.; Ferscha, A.; et al. Collecting complex activity datasets in highly rich networked sensor environments. In Proceedings of the 2010 Seventh International Conference on Networked Sensing Systems (INSS), Kassel, Germany, 15–18 June 2010; pp. 233–240.
- [128] Hammerla, N.Y.; Halloran, S.; Plötz, T. Deep, convolutional, and recurrent models for human activity recognition using wearables. *arXiv* **2016**, arXiv:1604.08880.
- [129] Reiss, A.; Stricker, D. Introducing a new benchmarked dataset for activity monitoring. In Proceedings of the 2012 16th International Symposium on Wearable Computers, Newcastle, UK, 18–22 June 2012; pp. 108–109.
- [130] Kawaguchi, N.; Ogawa, N.; Iwasaki, Y.; Kaji, K.; Terada, T.; Murao, K.; Inoue, S.; Kawahara, Y.; Sumi, Y.; Nishio, N. HASC Challenge: gathering large scale human activity corpus for the real-world activity understandings. In Proceedings of the 2nd Augmented Human International Conference, Tokyo, Japan, 13 March 2011; p. 27.
- [131] Danilo Vasconcellos Vargas, Shashank Kotyan, Moe Matsuki, "Uncovering Why Deep Neural Networks Lack Robustness: Representation Metrics that Link to Adversarial Attacks", CoRR, abs/1906.06627, (2019)
- [132] 竹下 昌志, 松木 萌, 井上 創造, "ゼロショット行動認識のための中間表現の探索", 日本知能情報ファジィ学会九州支部学術講演会予稿集, pp. 6-9, (2019)

第 8 章

Appendics

8.0.1 属性ベクトル

ここでは、3つのデータセットに対する属性ベクトルを示す。

表 8.1 HASC データセットの属性ベクトル

	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

表 8.3 OPP データセットの属性ベクトル

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
2 Close Door	0	1	0	0	0	1	0	0	0	0	0	0
3 Open Fridge	1	0	0	0	0	0	1	0	0	0	0	0
4 Close Fridge	0	1	0	0	0	0	1	0	0	0	0	0
5 Open Dishwasher	1	0	0	0	0	0	0	1	0	0	0	0
6 Close Dishwasher	0	1	0	0	0	0	0	1	0	0	0	0
7 Open Drawer	1	0	0	0	0	0	0	0	1	0	0	0
8 Close Drawer	0	1	0	0	0	0	0	0	1	0	0	0
9 Clean Table	0	0	1	0	0	0	0	0	0	1	0	0
10 Drink from Cup	0	0	0	1	0	0	0	0	0	0	1	0
11 Toggle Switch	0	0	0	0	1	0	0	0	0	0	0	1

8.0.2 各行動クラスに対する類似単語

表 8.4 HASC データセットの拡張した時に得られる単語ベクトルの単語の上位 20 個を示す。列は上位 5 つ、10 個、20 個で枠組みを行う。行はターゲットである単語を示す。シンボルの意味として、** は、“DBPEDIA_ID/” を省略したものである。また、同義語を赤色、反対語を青色で単語に色付けしている。

Activity Class	Top 5	Top 10	Top 20
down	back, down ?, down), down ;; off	away, cut , down ?, shut, up- side	backwards, dragged, falling , finally, off ;; out, slid , slowly, up , up ”
jog	jogged , jogging , jogs , stroll, walk	bends, detour, half-mile, north-northwesterly, walk- ing	driveway, eastbound, intersecting, intersects, lope , nap, ramp, straightens, swerves, veers
skip	go , miss , skipped , skip- ping , skips	Brier, curling, get , ignore, repeat	**the_Brier, Parsoid, Scribunto, append, edit- preview, manually, redo, start, try, unwatch
stay	go , leave , remain, stay- ing , stays	continue , settle, spend, wait, stayed	agrees, come , decide, 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 8.5 OPP データセットの拡張した時に得られる単語ベクトルの単語の上位 20 個を示す。列は上位 5 つ、10 個、20 個で枠組みを行う。行はターゲットである単語を示す。シンボルの意味として、** は、“DBPEDIA_ID/” を省略したものである。また、同義語を赤色、反対語を青色で単語に色付けしている。

Activity Class	Top 5	Top 10	Top 20
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	busy, closes, contact, relative, ties	another, clear, closing, connection, friend, friends, keep, move, nearer, re-open
toggle	buttons, on/off, switch, toggled, toggles	disable, double-click, knob, right-click, show/hide	“Cite”, Rightclick, button, button;, doubleclicking, joystick, right-clicking, scrollbars, tabs, touchpad
drink	beer, beverage, beverages, drinks, nonalcoholic	carbonated, drank, soda, sodas, vodka	**soft_drink, **soft_drinks, caffeinated, coffee, cola, fizzy, juice, juices, lemonade, non-carbonated
open	**open_source, access, enclosed, space, spaces	“open, doors, **open_plan, **open_source_software	Access, **Open-source_software, **open_content, accessible, create, door, extension, internal, opening, repository

表 8.6 PAMAP2 データセットの拡張した時に得られる単語ベクトルの単語の上位 20 個を示す。列は上位 5 つ, 10 個, 20 個で枠組みを行う。行はターゲットである単語を示す。シンボルの意味として, ** は, “DBPEDIA_ID/” を省略したもの, * は “_New_York_State_Legislature” を省略したものである。また, 同義語を赤色, 反対語を青色で単語に色付けしている。

Activity Class	Top 5	Top 10	Top 20
ascending	ascend, ascends, descending, dhavitam, panchamam	madhyamam, parallage, pentatonic, phthongos, scale)	(ascending, **chromatic_scale, **swara, arching, kaisiki,nishadham, rishabham, sadharana, shud-dha, tetrachord
cleaning	clean, cleaners, cleans, laundry, washing	drying, polishing, repairing, scrubbing, vacuuming	Cleaning, 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, **Mountain.bike.racing, **Track.cycling, **cyclocross, **race.stage, **road.bicycle.racing, **stage.race, cyclocross, cyclocross
descending	ascend, ascending, ascends, descend, downwards	climbs, descends, parallage, phthongos, scale)	(ascending, climb, descents, dhavitam, downward, panchamam, steep, steeper, tetrachord, upward
driving	car, car’s, driver, drove, speeding	cars, drive, driver’s, drivers, 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, helical, laminated, non-slip, 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, dressage, ski, skiing	**eventing, **ski.jumping, Ski, downhill, eventing	**Show.jumping, **Ski.jumping, **dressage, **ski.cross, **ski.jumping.hill, jumper, leaping, paraNordic.snowboard, snowboarding
lying	bed, crying, dragged, lie, sleeping	beside, bluff, hiding, lied, scared	asleep, cheating, dragging, dumped, hugging, knees, pillow, screaming, 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, mid-field, plays, professionally, semiprofessionally, touring
running	cross, extending, ran, run, runs	Running, 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, sitting, stand	facing, hands, hangs, hung, ovation, resting, sits, smiling, unless, wearing
walking	jogging, trail, trails, walk, walks	accessible, bicycling, biking, hiking, strolling	**walking, barefoot, bike, distance, horseback, picnicking, rollerblading, sidewalk, stroll, walked
watching	enjoy, enjoying, laughing, watch, watched	chatting, crazy, listening, seeing, viewing	crying, enjoys, fun, kid, kids, loved, noticing, scared, screaming, staring
work	work:, work:, working, works, work	endeavors, job, necessary, studies, work)	Work, creations, efforts, endeavor, endeavours, experience, expertise, focus, oeuvre, research

8.0.3 空間類似度

表 8.7 属性ベクトル (左) と分散表現 (右) の PAMAP2 データセット空間内で, 各クラスで距離が近いベクトルのクラス上位 3 つをまとめたもの

	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 8.8 属性ベクトル (左) と分散表現 (右) の OPP データセット空間内で, 各クラスで距離が近いベクトルのクラス上位 3 つをまとめたもの

	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

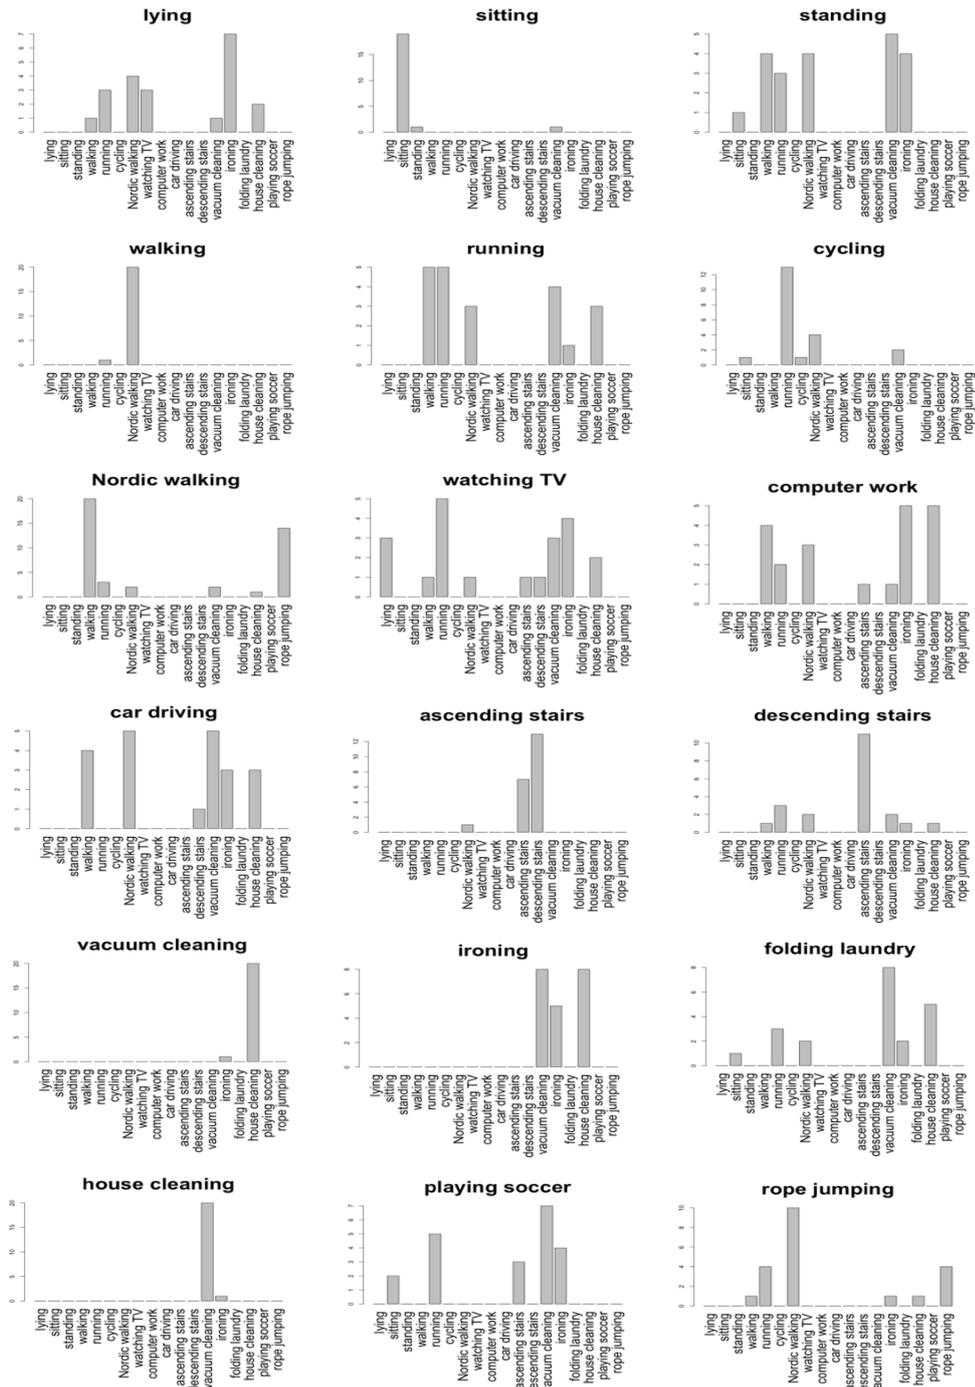


図.8.1 PAMAP2 データセットにおいて、拡張分散表現の行動クラス間で最も類似する単語ベクトルのヒストグラム

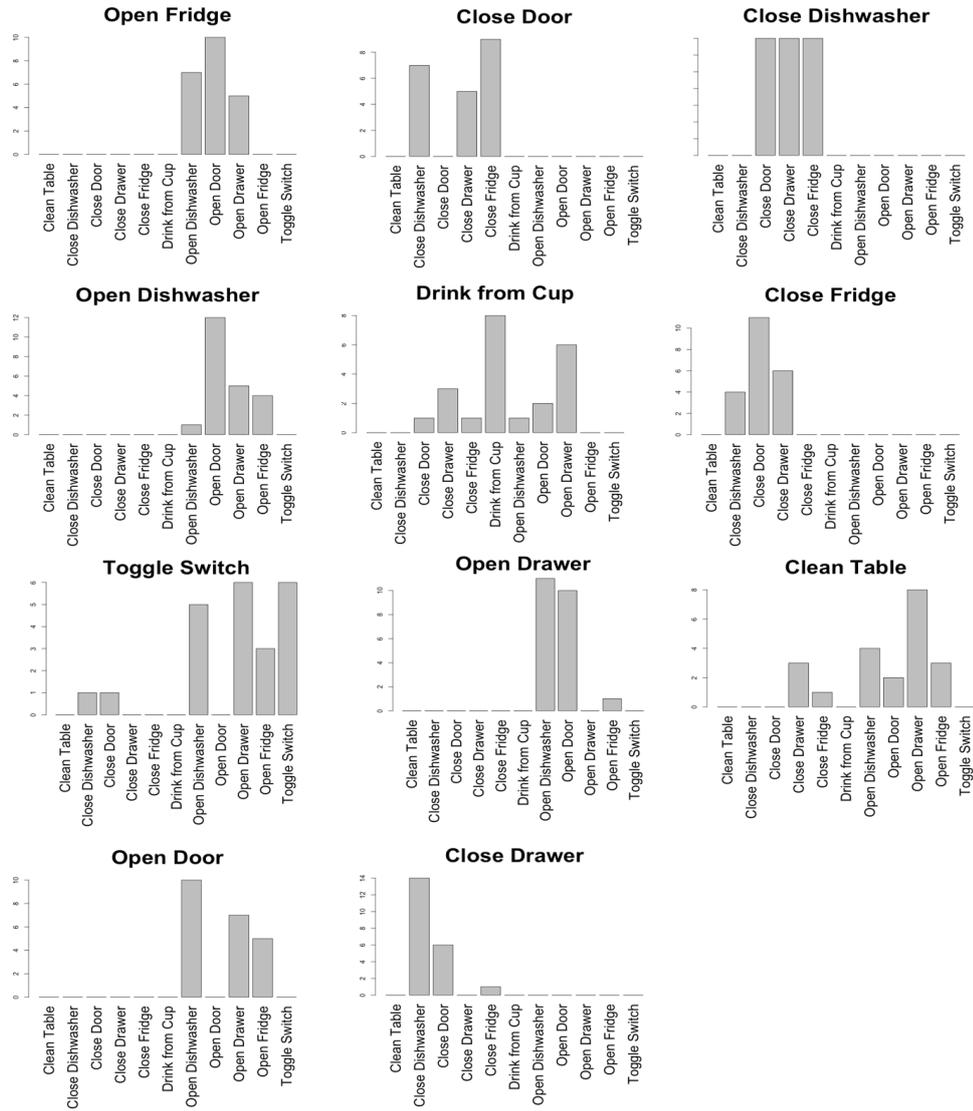


図 8.2 OPP データセットにおいて、拡張分散表現の行動クラス間で最も類似する単語ベクトルのヒストグラム。