

# 介護記録自動生成のための記録項目別傾向分析

金子 晴<sup>1</sup> Tahera Hossain<sup>1</sup> 井上 創造<sup>1</sup>

**概要：**現在先進国では高齢化社会が深刻化している。現在の日本でも、他の先進国と同様に高齢化社会が深刻化している [22]。それに伴い介護士不足が社会問題となっており、ICT(Information and Communication Technology) などを用いた介護業務の負担軽減が期待されている。我々の研究室では、介護記録アプリを開発し、介護行動認識や介護記録の自動生成を目指した研究を行なっている [10], [12], [19], [20]。本項では、介護記録の推定精度を向上させるため、特徴量重要度やデータの可視化を用い介護記録データの分析を行う。また、分析をもとに新たな特徴量を提案する。分析でははじめに、介護記録の推定を行う機械学習モデルを作成し、特徴量重要度可視化する。そして、特徴量重要度をもとに記録の種類ごとに混同行列や生データの可視化を行い、データや推定結果の傾向を分析する。結果として新たに 10 個の特徴量を新たに提案した。また提案された特徴量のうち、すでにあるデータから算出できるものを用い推定精度を評価した。

## Analysis of trends by value of record for automatic generation of care records

HARU KANEKO<sup>1</sup> TAHERA HOSSAIN<sup>1</sup> SOZO INOUE<sup>1</sup>

### 1. はじめに

高齢化社会を支えるためには、人間の複雑な行動を理解することが重要であると言われている [1]。研究者たちは、センサや動画などを用いた行動認識を行っており、精度を改善のために日々を研究が行われている [2], [4], [8]。その理由の一つは、世界中で高齢者人口が増加していることである [15]。現在の日本では、他の先進国と同様に高齢化社会が深刻化している [22]。それに伴い介護士不足が深刻化すると予想されている [21]。そのため、ICT(Information and Communication Technology) などを用いた介護仕事の負担軽減が期待されている。

我々はこれまでに、介護記録アプリを開発し実証実験を行なっている [10], [19]。この実証実験では、介護記録データと介護行動中の加速度データを収集した。この介護記録データを用い、我々はこれまでに介護記録の自動生成を目指し機械学習モデルを作成している。

本項ではこの介護記録の推定精度を向上させるため、特徴量重要度やデータの可視化を用い介護記録データの分析を行う。また、分析をもとに新たな特徴量を提案する。

分析でははじめに、介護記録の推定を行う機械学習モデルを作成し、特徴量重要度可視化する。そして、特徴量重要度をもとに記録の種類ごとに混同行列や生データの可視化を行い、データや推定結果の傾向を分析する。

結果として新たに 10 個の特徴量を新たに提案した。また提案された特徴量のうち、すでにあるデータから算出できるものを用い推定精度を評価した。

### 2. 関連研究

介護施設での生産性向上に向けた研究はいくつかある。センサ行動認識とは、センサデータに基づいてユーザが何をしているかを識別するタスクであり、ユビキタス・コンピューティング・コミュニティで活発に研究されている [14], [18], ?。しかし、実世界での行動認識の応用例は少ない。特に病院や介護施設で使われるケースは限られる [5]。

ウェアラブル・センサーを実際の現場で活用するためには、多くの課題がある [7], [11]。近年では、一般的向けの行動認識製品が販売されている。これらは、日常生活での行動や活動量を記録する事ができる製品である。

しかし、医療・看護分野ではセンサ行動認識の技術を用いた市販製品は少ない。その主な理由の一つは、介護や医療

<sup>1</sup> 九州工業大学

などドメイン特有の行動は行動が複雑でありデータの収集が難しい事である。

介護行動認識の応用研究では、行動の種類が介護施設固有の方法で行われる場合が多い。さらにこのような活動には、クラス間のデータ数、行動継続時間などの不均衡データである場合もおおい。このような背景から、実際の介護施設で収集されたデータを用いた行動認識 [17] と、環境制御された実験室で収集されたデータを用いた行動認識 [3], [13] には大きな違いがある。

介護記録や看護記録を用い入居者の健康状態や排泄時刻などを予想する研究はいくつかある [9], [16]。

我々の研究室では、介護記録用アプリを開発しデータ収集実証実験を行なっている [10], [19]。この実験で介護職員は、モバイルアプリを利用し介護記録を入力する。我々はこの実験で、介護記録データと介護行動中の加速度データを収集した。収集された加速度データは、実験室データ(モーションキャプチャデータなど実験室で収集された高精度データ)と組み合わせ、介護行動認識の精度向上のために活用されている。

介護記録データについても、我々はこれまでに自動生成を目指した機械学習推定モデルを作成した [12], [20]。この研究では、前日までの介護記録データから翌日の介護記録の内容を推定している。本項ではこの推定モデルの精度向上を目指し、介護記録データと推定モデルの分析を行う。

### 3. 分析

本章では記録項目別にデータの傾向を分析する。本稿では、特徴量重要度に着目しそれぞれのレコードにどのような特徴があるのかを分析する。また、精度向上のために有用と考えられる新たな特徴量を提案する。本性ではまず、本項で用いる介護記録データについてその概要を述べる。そして、特徴量重要度を得るための機械学習モデルを作成する。特徴量や目的変数は先行研究 [12] と同様である。その後特徴量重要度を可視化し評価する。また、混同行列や生データの可視化を用いレコードごとに傾向を分析する。

#### 3.1 データ

まず、本稿で用いる介護記録データの概要を述べる。本稿で用いるデータは先行実験 [10] にて取収された介護記録データである。本稿では、2018年5月1日-6月30日の間の介護士23人・入居者45人分の介護記録データを用いる。この介護記録データには、11の介護行動が含まれておりまた、それぞれの介護行動には複数の詳細記録が紐付いている。本稿では、介護行動をアクティビティ、詳細記録をレコードと呼ぶ。表1にアクティビティとレコードの一覧を示す。

それぞれのレコードには選択肢が定義されており、介護士は選択肢の中から1つを選び記録を作成している。表2

表1 アクティビティとレコードの一覧。アクティビティは11種類あり、それぞれのアクティビティに合計26のレコードが紐付いている。

アクティビティ	レコード
食事・服薬	食事介助
	食事量(主食)
	食事量(副食)
	水分量
排泄	排泄介助
	排泄方法
	排便量
	排尿量
夜間利用者対応	対応内容
	種別
日中利用者対応	対応内容
	種別
活力朝礼・ラジオ体操	ラジオ体操
	活力朝礼
入浴・清掃	入浴介助
	入浴方法
外出対応	外出場所
処置	処置内容
	処置の部位
口腔ケア	口腔内清掃
	義歯洗浄
家族・来客対応	目的
更衣介助	更衣介助

に「食事・服薬」を例にレコードと選択肢の対応を示す。

表2 「食事・服薬」におけるレコードとその値の対応。介護士は選択肢の中から一つを選び記録を作成している。

アクティビティ	レコード	レコードの値
食事・服薬	食事介助	全介助 一部介助 セッティングのみ 自立
	食事量(主食)	0, 1, 2, ..., 10
	食事量(副食)	0, 1, 2, ..., 10
	水分量	0, 50, 100, ..., 500
	服薬	介助 自立 服薬なし

次にデータ数について述べる。図1にレコードごとのデータ数とその内訳を示す。この図から分かるようにレコードごとにデータ数に偏りがある。また、レコードがとる値も同様にデータ数に偏りがある。

#### 3.2 機械学習モデル

ここでは、本稿で用いる機械学習モデルについて述べる。

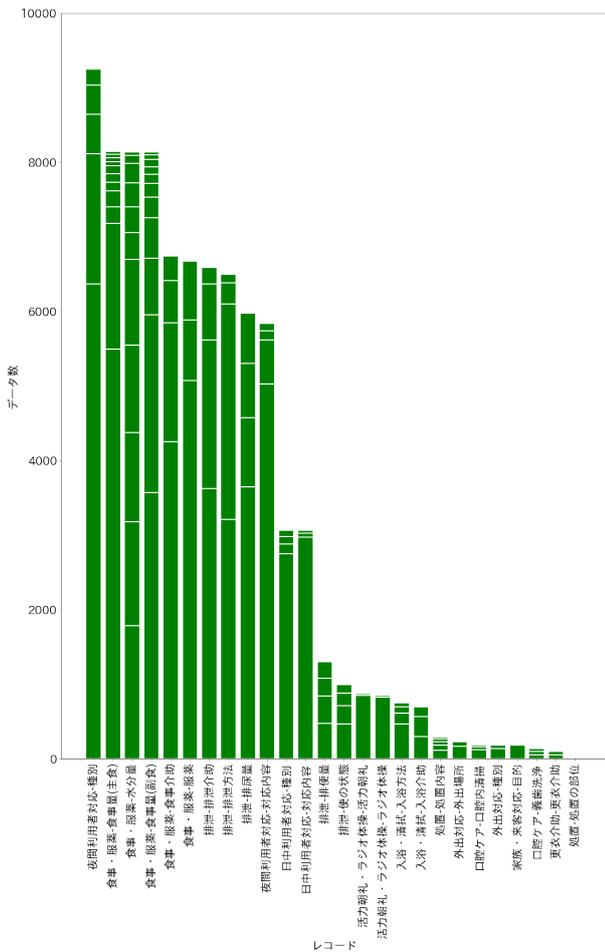


図 1 レコードごとのデータ数とその内訳。横軸はレコード名、縦軸はデータ数。レコードによりデータ数に偏りがあり、またその内訳も同様にデータ数に偏りがある。

本稿で用いる特徴量とその特徴量が取りうる値を表 3 に示す。目的変数は詳細レコードの値である。

特徴量	値
被介護者	
被介護者の居住階	
介護職員	
時刻(時)	0,1,...,23
時刻(時 × 60) + 分	0,1,...,3600
前回の値	
前回の食事・服薬クラスの主食量	null, 0,1,...,10
前回の食事・服薬クラスの副食量	null, 0,1,...,10
前回の食事・服薬クラスの水分量	null, 0,50,100,...,500
前回の排泄クラスの排泄量	null, 少量, 中量, 多量

機械学習アルゴリズムには Random Forest [6] 用いる。Random Forest は決定木を弱学習機とするアンサンブル学習アルゴリズムの一種である [23]。

図 1 に特徴量同士の相関を示す。この図から、「被介護者」「被介護者の居住階」「介護職員」の間や、「前回の食事・服薬クラスの主食量」「前回の食事・服薬クラスの副食

量」「前回の食事・服薬クラスの水分量」の間に相関係数が 0.5 以上の正の相関がある事がわかる。

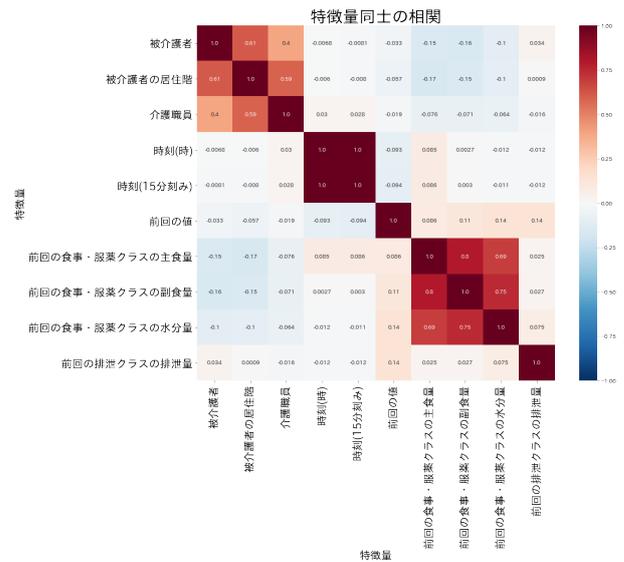


図 2 特徴量同士の相関。「被介護者」「被介護者の居住階」「介護職員」の間や、「前回の食事・服薬クラスの主食量」「前回の食事・服薬クラスの副食量」「前回の食事・服薬クラスの水分量」の間に相関係数が 0.5 以上の正の相関がある。

図 3 にレコードごとに機械学習モデルの正答率と F1 値を示す。この機械学習モデルでは、2018 年 5 月 1 日-6 月 14 日のデータを学習データに、2018 年 06 月 15 日-6 月 30 日のデータをテストデータに使用した。学習は各レコードごとに一つの機械学習モデルを作る形式で行う。学習の結果、平均正答率は 76.3%, 平均 F1 値は 51.1%であった。

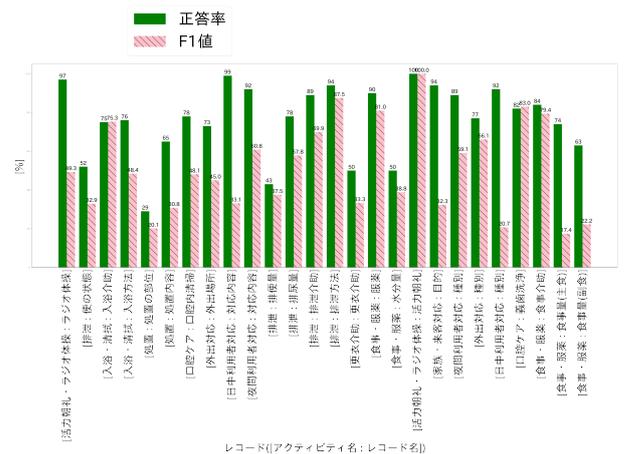


図 3 レコードごとに学習した場合の正答率と F1 値。横軸はレコード名、縦軸は正答率・F1 値 (%)。2018 年 5 月 1 日-6 月 14 日のデータを学習データに、2018 年 06 月 15 日-6 月 30 日のデータをテストデータに使用した。

特徴量重要度とは、その機械学習モデルにおいてどの特徴量が重視されているかを知る事ができる指標の一つである。特徴量重要度には算出方法によりいくつかの種類があ

る。本稿ではジニ重要度を用いる。これは、特徴量ごとにジニ係数の平均的な減少量を算出し求めるものである。

図 4 に学習の結果得られた特徴量重要度を各レコードごとに示す。

### 3.3 重要度を用いた分析

ここでは、図 4 に示した特徴量重要度を元に、介護記録データの分析を行う。また、分析を元に新たな特徴量を提案する。

#### 3.3.1 「時刻 (15 分刻み)」に関する特徴量の検討

「時刻 (15 分刻み)」は多くのレコードで高い重要度を示している。特に日中利用者対応の種別や夜間帯利用者対応の種別、食事・服薬の食事量や水分量の重要度が高い。

図 5 に、食事・服薬の食事量 (主食) を例に「時刻 (15 分刻み)」との関係を示す。この図から分かるように、7 時・12 時・18 時 (朝食夕食) はレコードの値が 10 をとるデータが多いのに対し、15 時 (おやつ) はレコードの値が 0 の割合が増加している。つまり時刻に相関がある。また朝食と夕食の間や 20 時以降など間食や夜食をとる場合も多い事がわかる。

朝食とおやつのように食事の種類が異なることから、「前回の食事量」を「その日の朝食の食事量」や「間食の有無」のように細分化することで新たな特徴量として利用できると考える。

「時刻 (15 分刻み)」の重要度が低いレコードは、入浴・清拭の入浴介助や排泄アクティビティの排泄方法などである。これらは被介護者ごとにデータ数に大きな偏りがあり、大抵の場合同じ値をとる。そのため「被介護者」や「前回の値」の重要度が高く、「時刻 (15 分刻み)」の重要度は他に比べて低くなっている。

#### 3.3.2 「前回の値」に関する特徴量の検討

「前回の値」は、排泄の排泄介助や排泄方法、入浴・清拭の入浴介助で重要度が高い。図 6 に、排泄の排泄介助を例に「前回の値」との関係を示す。この図から分かるように、排泄介助のレコード値は、ほとんどの場合「前回の値」と同じ値をとっている。これは、排泄の排泄方法や入浴・清拭の入浴介助でも同様であった。

しかし、被介護者ごとに「前回の値」とレコード値の関係を評価すると、この傾向が当てはまらない被介護者が一部いる事が分かった。図 7 に、入居者 89 における前回の値と排泄の排泄介助の関係を示す。この図のように排泄の排泄介助には、一部介助と全介助のサンプルがどちらも多く「前回の値」との相関が弱まっている被介護者が 8 名いた。また、自立が多い被介護者は全介助や一部介助を行うことは少ない傾向があることが分かった。

この自立して行動が出来るかどうかという考え方は、要介護度区分に似ている。そのため、要介護度も新たな特徴量として有用である可能性がある。

「前回の値」の重要度が低いレコードは、食事・服薬の食事量 (主食) や食事量 (副食)、家族・来客対応の目的などである。これらのレコードは、特徴量重要度が 0.05 以下と低くまた、F1 値も同様に低い傾向にある。

図 8 に食事・服薬の食事量 (主食) を例に混同行列を示す。この混同行列から推定が 10 に偏っており、1-9 はほとんど推定出来ていない事が分かる。これは、食事・服薬の食事量 (副食) や家族・来客対応でも同様である。

この問題を解決するために、これらのレコードと相関があると仮定できる新たな特徴量を提案する。まず、食事・服薬の食事量 (主食) や食事量 (副食) の F1 値を向上するために、新たな特徴量として朝食や昼食の食事摂取量、その日の運動量、睡眠時間、体調を提案する。

#### 3.3.3 「介護職員」に関する特徴量の検討

「介護職員」は、家族・来客対応の目的や日中利用者対応の種別、外出対応の外出場所などで重要度が高い。図 9 に介護職員と日中利用者対応の種別との関係を示す。この図から、定期観察のデータが極端に多い事、介護職員の中には定期観察の入力を行っていない職員がいる事がわかった。このようなデータ数の偏りは、家族・来客対応アクティビティの目的や外出対応の外出場所も同様であった。

図 10 に日中利用者対応の種別の混同行列を示す。この図から分かるように、定期観察に推定が偏っており、その他の値を推定していない。これは、家族・来客対応の目的や外出対応の外出場所などでも同様であった。この事から、これらのレコードはそもそも F1 値が低く、うまく推定できていない事が分かる。

そこで、これらのレコードと相関があると仮定できる特徴量を提案する。まず、家族・来客対応の目的や外出対応の外出場所の F1 値を向上するために、新たな特徴量として曜日提案する。

#### 3.3.4 「被介護者」に関する特徴量の検討

「被介護者」は、食事・服薬の服薬、外出対応の種別、処置の処置の部位、口腔ケアの義歯洗浄の重要度が高い。

図 11 に食事・服薬の服薬を例に「被介護者」との関係を示す。この図から、被介護者ごとにほとんどの場合同じ値を取る事が分かる。また、図 12 に混同行列を示す。この図から、正解ラベルが介助の場合、ほとんどの場合で正答している事が分かる。

しかし、被介護者 31 や 98 のように介助と服薬なしのどちらのデータも多い場合、正解ラベルが服薬なしである場合でも介助と推定されている場合が多い。

つまり、ほとんどの場合、被介護者にごとに 1 つの値を取る事が多く、推定も出来ている。しかし、一部の被介護者は 2 つ以上の値をどちらも取り、これはうまく推定出来ない。これは、外出対応の種別や、処置の処置の部位でも同様であった。

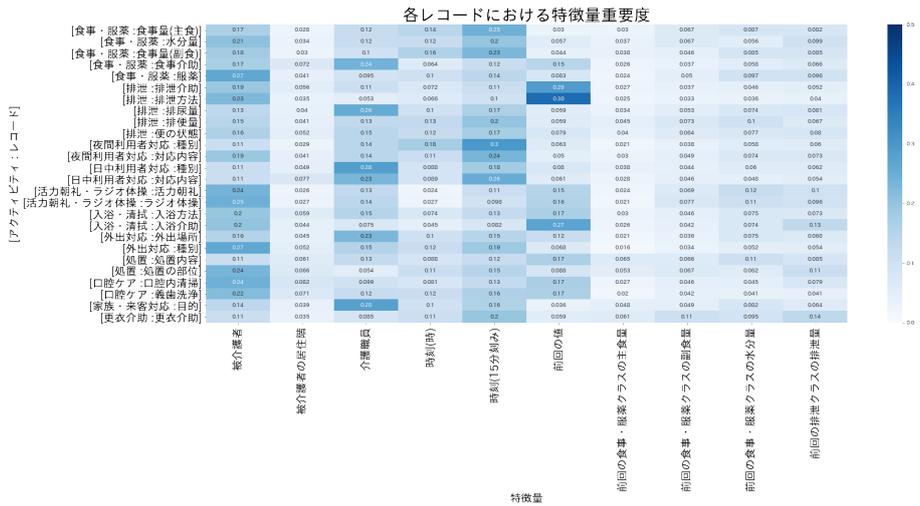


図 4 各レコードごとの特徴量重要度. 横軸は特徴量名, 縦軸はレコード名. 時刻 (15 分刻み)・被介護者の重要度が全体的に高い事が見て取れる.

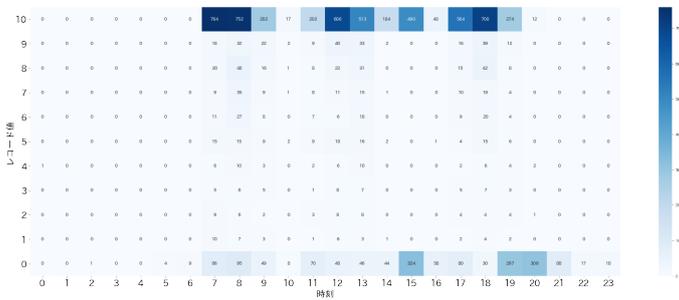


図 5 時刻 (15 分刻み) と食事・服薬の食量 (主食) の関係. 横軸は時刻, 縦軸は食事・服薬の食量 (主食) がとる値. 色が濃いほどサンプル数が多い.

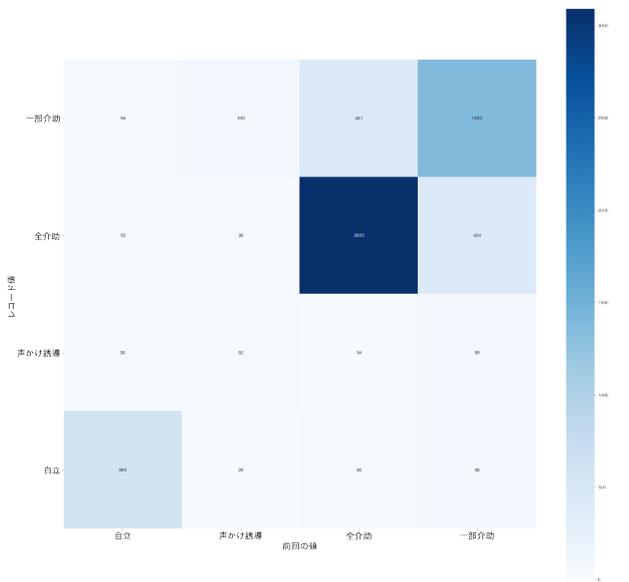


図 6 前回の値と排泄の排泄介助の関係. 横軸は時刻, 縦軸は日中利用者対応の種類がとる値. 色が濃いほどサンプル数が多い.

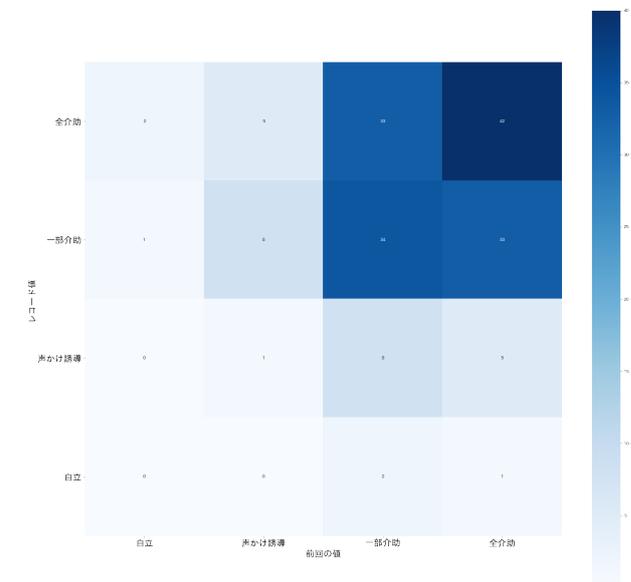


図 7 入居者 89 における前回の値と排泄の排泄介助の関係. 横軸は時刻, 縦軸は日中利用者対応の種類がとる値. 色が濃いほどサンプル数が多い. 全介助排泄介助のデータがどちらも多く, 前回の値との相関が弱い.

### 3.3.5 その他の特徴量に関する検討

ここでは上記以外に新たに特徴量として有用であると考えられる特徴量を提案する

図 2 から分かるように, 「前回の食事・服薬の主食量」

「前回の食事・服薬の副食量」「前回の食事・服薬の水分量」の間には相関がある. そこでこれらを足し合わせ新たな特

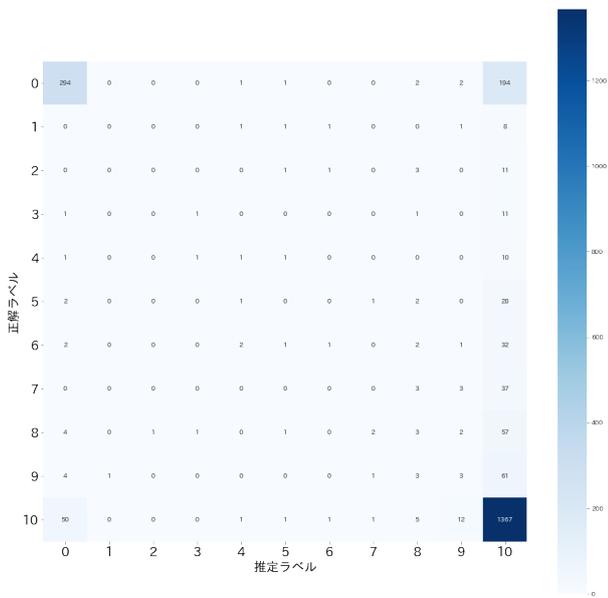


図 8 日中利用者対応の種別の混同行列. 縦軸は推定ラベル, 横軸は正解ラベル.



図 9 介護職員と日中利用者対応の種別との関係. 横軸は時刻, 縦軸は日中利用者対応の種別がとる値. 色が濃いほどサンプル数が多い.

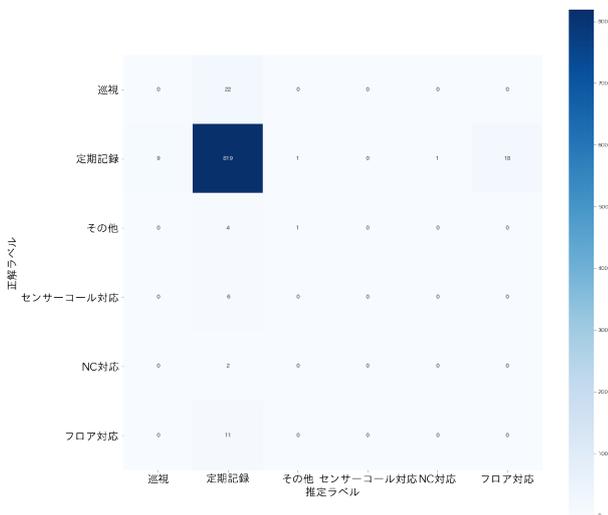


図 10 日中利用者対応の種別の混同行列. 縦軸は推定ラベル, 横軸は正解ラベル.

微量を作る事ができると考える.

### 3.3.6 分析のまとめ

ここでは 3.3 章にて提案した新たな特徴量について整理する.

これまでに新たに提案した特徴量は以下である. このう

ち、「要介護度」「前日の睡眠時間」「その日の運動量」「その日の体調」は新たにデータの収集が必要である. 特に「前日の睡眠時間」や「その日の運動量」はセンサーなどを用いたセンシングが必要である.

- その日の朝食の食事量
- その日の昼食の食事量
- その日の夕食の食事量
- 排泄のレコード値が自立である割合
- その日の間食の有無
- 要介護度
- 前日の睡眠の時間
- その日の運動量
- その日の体調
- 曜日

### 3.4 新機械学習モデル

ここでは, 3.3 章にて提案した新たな特徴量のうち, 「その日の朝食の食事量」「その日の昼食の食事量」「その日の夕食の食事量」「曜日」を特徴量に追加した機械学習モデルを評価する.

図 13 に新たに特徴量を追加した場合の推定結果を示す. 平均正答率は 51.0%, 平均 F1 値は 77.2%であった. レコードごとに F1 値を見ると, 排泄の便の状態で 5%, 外出対応の外出場所で 4%, 処置の処置内容で 3%, 更衣介助の更衣介助で 15%F1 値が向上した. しかし, F1 値が減少したレコードもあり, 平均 F1 値では約 1%の向上となった. 図 14 に新たに特徴量を追加した場合の推定結果を示す. この図から, 外出対応の外出場所, 外出対応の種別は「曜日」の重要度が高い事が分かる.

## 4. まとめ

本稿では, 介護記録の推定精度向上を目指し, 機械学習モデルや介護記録データの可視化・分析をおこなった. 分析では, 特徴量重要度をもとに介護記録の詳細データの傾向を可視化した. また, 混同行列や生データの可視化から, 特徴量と介護記録データの関係や, 機械学習モデルの傾向を分析した. 結果として新たに 10 個の特徴量を提案した.

しかし, そのうちの 6 つ (「その日の間食の有無」「要介護度」「前日の睡眠の時間」「その日の運動量」「その日の体調」) は新たにデータの収集が必要であるため評価できていない.

今後は新たなデータの収集や, 今回提案されていない新たな特徴量の発見を行いたいと考える.

### 参考文献

- [1] Ahad, M.: Vision and Sensor Based Human Activity Recognition: Challenges Ahead, *Advancements in Instrumentation and Control in Applied System Applica-*



図 11 被介護者と食事・服薬の服薬の関係。横軸は時刻、縦軸は食事服薬の服薬がとる値。色が濃いほどサンプル数が多い。

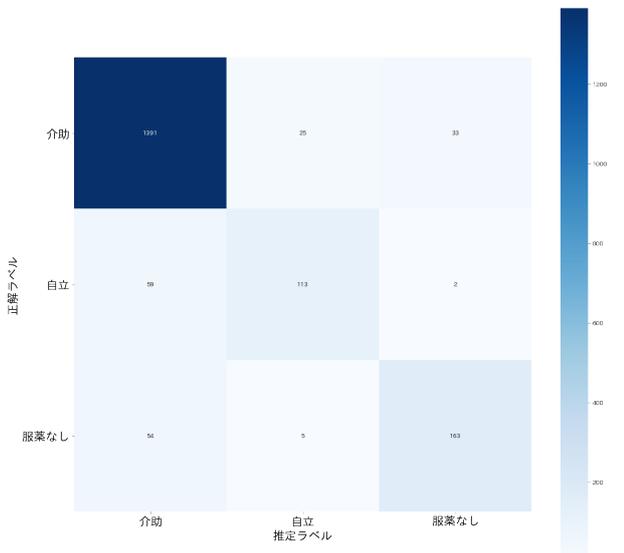


図 12 食事・服薬の服薬の混同行列。縦軸は正解ラベル、横軸は推定ラベル。全入居者のデータを学習に用い、入居者 98 のデータをテストデータとして用いた。

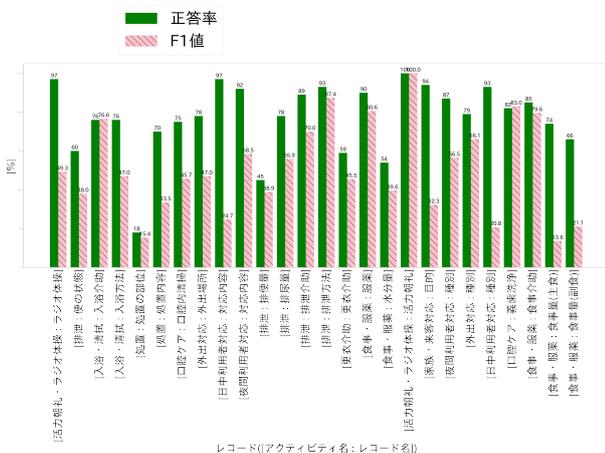


図 13 新たに特徴量を追加した場合の正答率と F1 値。横軸はレコード名、縦軸は正答率・F1 値 (%)。2018 年 5 月 1 日-6 月 14 日のデータを学習データに、2018 年 06 月 15 日-6 月 30 日のデータをテストデータに使用した。

tions (Bhattacharya, S., ed.), Hershey, PA: IGI Global, Oxford, chapter 2, pp. 17–35 (2020).

[2] Ahad, M. A. R., Das Antar, A. and Shahid, O.: Vision-based Action Understanding for Assistive Healthcare: A Short Review (2019).

[3] Alia, S. S., Lago, P., Adachi, K., Hossain, T., Goto, H., Okita, T. and Inoue, S.: Summary of the 2nd Nurse Care Activity Recognition Challenge Using Lab and Field Data, *Adjunct Proceedings of the 2020*

*ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2020 ACM International Symposium on Wearable Computers, UbiComp-ISWC '20*, New York, NY, USA, Association for Computing Machinery, p. 378–383 (online), DOI: 10.1145/3410530.3414611 (2020).

[4] Atiqur Rahman Ahad, M., Das Antar, A. and Shahid, O.: Vision-based Action Understanding for Assistive Healthcare: A Short Review, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops* (2019).

[5] Bahle, G., Gruenerbl, A., Lukowicz, P., Bignotti, E., Zeni, M. and Giunchiglia, F.: Recognizing hospital care activities with a coat pocket worn smartphone, *6th International Conference on Mobile Computing, Applications and Services*, pp. 175–181 (online), DOI: 10.4108/icst.mobicas.2014.257777 (2014).

[6] Breiman, L.: Random Forests, *Mach. Learn.*, Vol. 45, No. 1, p. 5–32 (online), DOI: 10.1023/A:1010933404324 (2001).

[7] Bulling, A., Blanke, U. and Schiele, B.: A Tutorial on Human Activity Recognition Using Body-worn Inertial Sensors, *ACM Comput. Surv.*, Vol. 46, No. 3, pp. 33:1–33:33 (online), DOI: 10.1145/2499621 (2014).

[8] Faisal, M. A. A., Siraj, M. S., Abdullah, M. T., Shahid, O., Abir, F. F. and Ahad, M. A. R.: A Pragmatic Signal Processing Approach for Nurse Care Activity Recognition Using Classical Machine Learning, *Adjunct Proceedings of the 2020 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2020 ACM International Symposium on Wearable Computers, UbiComp-ISWC '20*, New York, NY, USA, Association for Computing Machinery, p. 396–401 (online), DOI: 10.1145/3410530.3414337 (2020).

[9] Fauber, J. and Shelton, C. R.: Modeling “Presentness” of Electronic Health Record Data to Improve Patient State Estimation, *Proceedings of the 3rd Machine Learning for Healthcare Conference* (Doshi-Velez, F., Fackler, J., Jung, K., Kale, D., Ranganath, R., Wallace, B. and Wiens, J., eds.), Proceedings of Machine Learning Research, Vol. 85, Palo Alto, California, PMLR, pp. 500–513 (online), available from <http://proceedings.mlr.press/v85/fauber18a.html> (2018).

[10] Inoue, S., Lago, P., Hossain, T., Mairitha, T. and Mairitha, N.: Integrating Activity Recognition and Nursing Care Records: The System, Deployment, and a Verification Study, Vol. 3, No. 3 (2019).

[11] Inoue, S., Ueda, N., Nohara, Y. and Nakashima, N.: 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*, New York, NY, USA, Association for Computing Machinery, p. 1269–1280 (online), DOI: 10.1145/2750858.2807533 (2015).

[12] Kaneko, H., Hossain, T. and Inoue, S.: *Estimation*

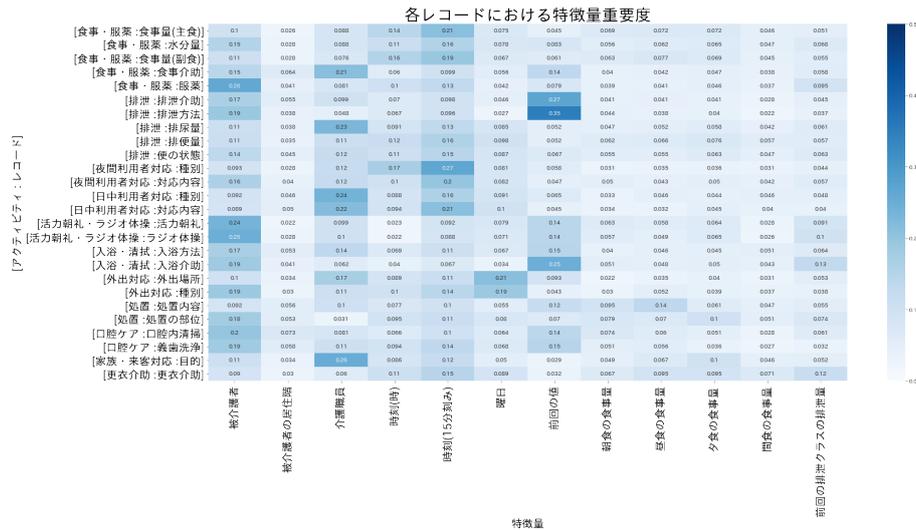


図 14 新たに特徴量を追加した場合の各レコードごとの特徴量重要度。横軸は特徴量名，縦軸はレコード名。

of Record Contents for Automatic Generation of Care Records, Springer Singapore, Singapore (2021).

[13] Lago, P., Alia, S. S., Takeda, S., Mairittha, T., Mairittha, N., Faiz, F., Nishimura, Y., Adachi, K., Okita, T., Charpillat, F. and Inoue, S.: Nurse Care Activity Recognition Challenge: Summary and Results, *Adjunct Proceedings of the 2019 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2019 ACM International Symposium on Wearable Computers*, New York, NY, USA, Association for Computing Machinery, p. 746–751 (online), DOI: 10.1145/3341162.3345577 (2019).

[14] Lester, J., Choudhury, T. and Borriello, G.: A Practical Approach to Recognizing Physical Activities, *Pervasive Computing* (Fishkin, K. P., Schiele, B., Nixon, P. and Quigley, A., eds.), Berlin, Heidelberg, Springer Berlin Heidelberg, pp. 1–16 (2006).

[15] World Health Organization: Ageing (2019).

[16] Saitoh, T., Yamada, I. and Yoshioka, Y.: Excretion Prediction Using Nursing Record System Log Data, *2018 57th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, pp. 1618–1623 (online), DOI: 10.23919/SICE.2018.8492590 (2018).

[17] Toda, T., Inoue, S. and Ueda, N.: Mobile Activity Recognition through Training Labels with Inaccurate Activity Segments, *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services, MOBIQUITOUS 2016*, New York, NY, USA, Association for Computing Machinery, p. 57–64 (online), DOI: 10.1145/2994374.2994378 (2016).

[18] Voicu, R.-A., Dobre, C., Bajenaru, L. and Ciobanu, R.-I.: Human Physical Activity Recognition Using Smartphone Sensors, *Sensors*, Vol. 19, No. 3, p. 458 (2019).

[19] 創造井上, 幸平木村, 百里内野, 誠 大屋: 介護施設における介護スタッフの行動センシング実験, 技術報告 13, 九州工業大学, 株式会社 IDC フロンティア, 九州工業大学, 株式会社 IDC フロンティア (2017).

[20] 晴 金子, 創造井上: 介護記録自動生成のための記録内容の推定の試み, 技術報告 41, 現在, 九州工業大学, 現在, 九州工業大学 (2020).

[21] 厚生労働省: 2025 年に向けた介護人材にかかる需要推計 (確定値) について, <https://www.mhlw.go.jp/stf/>

houdou/0000088998.html (2015).

[22] 内閣府: 令和元年版高齢社会白書, [https://www8.cao.go.jp/kourei/whitepaper/w-2019/zenbun/01pdf\\_index.html](https://www8.cao.go.jp/kourei/whitepaper/w-2019/zenbun/01pdf_index.html) (2019).

[23] 齊 波部: ランダムフォレスト, 技術報告 31, 近畿大学理工学部情報学科 (2012).