

令和4年度老人健康増進等事業  
高齢者の介護の現状に関する調査事業  
報告書

令和5年3月  
PwC コンサルティング合同会社



## 目 次

1. 事業の全体像.....	1
(1) 事業の目的 .....	1
(2) 事業の実施体制.....	1
(3) 事業の実施概要.....	2
2. 令和3年度事業調査データを対象とした深掘分析方法.....	3
(1) 分析方法と AI 活用可能性検証の概要.....	3
(2) 分析・検証方法の詳細.....	4
①施設観点でのケア時間変化の影響要因分析.....	4
(ア) 調査対象施設の類型化.....	4
(イ) 平均ケア時間分布の比較.....	4
②経年による状態像特徴変化の影響要因分析.....	5
(ア) 入所者構成比の比較.....	5
(イ) 状態像調査項目回答結果の分析.....	5
(ウ) 状態像調査項目回答結果内訳の経年比較.....	5
③状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索.....	5
(ア) 現行の樹形モデルによるケア時間の推計.....	5
(イ) 機械学習モデルによるケア時間推計の実行.....	6
(ウ) 機械学習モデルによる推計の改善検証.....	6
④タイムスタディにおける AI 活用可能性検証.....	6
(ア) 一般物体認識 AI による認識対象の拡充.....	6
(イ) ケア行為推定モデルの構築.....	6
(ウ) ケア推定対象の拡張可能性検証.....	7
3. 分析・検証結果.....	8
(1) 施設観点でのケア時間変化の影響要因分析の実施結果.....	8
①ICTの活用有無における平均ケア時間分布の比較.....	8
(ア) 職員負担軽減のためのテクノロジー活用有無.....	8
(イ) 情報共有の工夫実施有無.....	14
(ウ) 記録・報告様式の工夫実施有無.....	20
②スタッフの習熟度別平均ケア時間分布の比較.....	26
③ケアコード中分類別平均ケア時間比較.....	27
(ア) ICTの活用有無.....	27
(イ) スタッフの習熟度別.....	29
④施設観点でのケア時間変化の影響要因分析結果のまとめ.....	30
(2) 経年による状態像特徴変化の影響要因分析.....	30

①入所者構成比比較.....	30
(ア) 年齢階級別.....	30
(イ) 要介護度別.....	31
(ウ) 要介護度・施設類型別.....	32
(エ) 年齢階級・要介護度別.....	34
②状態像調査項目の相関分析.....	40
③状態像調査結果比較.....	42
④経年による状態像特徴変化の影響要因分析結果のまとめ.....	45
(3) 状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索.....	45
①ケア時間の推定比較結果.....	45
(ア) 現行の樹形モデルの推計結果.....	45
(イ) ケア行為ごとの推計結果の詳細.....	48
(ウ) 複数の機械学習手法の比較結果.....	55
(エ) ランダムフォレストモデルと現行モデルでの重視される状態像の違い.....	57
②機械学習モデルにおける推定の改善検証.....	59
(ア) 層化抽出法の検証.....	59
(イ) オーバーサンプリングの検証.....	62
(ウ) 新規特徴量作成の検証.....	63
(エ) ケアコード大分類毎のサブモデル化の検証.....	64
(オ) 状態像毎のサブモデル化のサブモデル化の検証.....	65
(カ) 改善手法の最適な組み合わせおよびハイパーパラメータ調整の検証.....	68
③状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索結果のまとめ.....	68
(4) タイムスタディにおける AI 活用可能性検証.....	69
①一般物体認識 AI による認識対象.....	69
(ア) 新たに認識対象とした物品の初期認識結果.....	70
(イ) 画像データ増加手法による認識精度改善施策と認識結果.....	73
②ケア行為推定モデルの構築.....	74
(ア) 初期モデルの推定結果.....	74
(イ) ケア行為推定モデルの改善.....	75
③ケア行為推定対象の拡張可能性検証.....	76
(ア) 検証対象のケアコードの選定.....	76
(イ) AI による認識対象とする情報の選定.....	77
(ウ) 対象の物品の認識結果.....	77
4. まとめ (考察).....	79
(1) 令和3年度調査におけるケアの特徴について.....	79

(2) タイムスタディ工程への AI 活用可能性検証結果について.....	80
5. 付録.....	81



# 1. 事業の全体像

## (1) 事業の目的

最新の高齢者介護の実態を把握するにあたり、平成 18 年度に実施された「高齢者介護実態調査」で行われたような他計式タイムスタディによる調査手法は膨大な労力を要し、かつ今般の新型コロナウイルス感染症による影響を鑑みて、多人数の外部調査員が介護保険施設等を訪問して調査することは望ましいものではないと考えられた。

加えて、平成 18 年度の調査時期においては、「平成 22 年度介護労働実態調査」で報告されている通り、介護保険施設 855 施設においてロボティクスが活用されているのは約 1%に留まることを踏まえ、先進的な IT 技術の活用は浸透していなかったものと推察できた。一方、「令和元年度介護労働実態調査」で報告されている通り、介護保険施設 1184 施設においてロボティクスが活用されているのは約 44%に増加しており、昨今の IT 技術の活用状況について大きな乖離が発生していることが推察できた。

そこで、令和 3 年度老人保健健康増進等事業（以下「令和 3 年度事業」という）では、平成 18 年度に実施した調査における前提ではなく、IT 活用など先進的な施設を中心に調査を行った。また、調査にあたっては介護スタッフ自身がボディカメラを装着し、そこで録画された動画情報について、画像解析など AI 要素技術を活用した上でのタイムスタディを実施し、入所者の状態像調査データや入所者へのケア時間に係るデータ等を収集・整理した。

本事業では令和 3 年度事業において収集・整理したデータを用いて、どのような状態の高齢者に対して、どのようなケアが、どれくらいの時間にわたって提供されているのかについて深堀分析するとともに、AI 活用による費用削減・時間短縮の効果を最大化させる点から、高齢者介護の実態調査の工程においてタイムスタディ工程を対象に、AI 要素技術の調査活用の検討を行うことを目的として実施した。

## (2) 事業の実施体制

事業事務局は図表 1 のとおりである。

図表 1 事務局一覧

氏名	所属
山崎 学	PwC コンサルティング合同会社 公共事業部
山上 真吾	PwC コンサルティング合同会社 Data & Analytics
植松 祐人	PwC コンサルティング合同会社 Data & Analytics

### (3) 事業の実施概要

本事業では、平成 18 年度調査時との施設入所者の年齢層の変化や (1) で記述した昨今の IT 技術の活用状況を踏まえ、最新の高齢者介護の実態の深堀分析とタイムスタディ調査における AI 活用可能性の評価を目的として、以下 4 つの分析および検証を実施した。

- ・施設観点でのケア時間変化の影響要因分析
- ・経年による状態像特徴変化の影響要因分析
- ・状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索
- ・タイムスタディにおける AI 活用可能性検証

なお、分析および検証には、令和 3 年度事業で収集した施設調査、状態像調査、タイムスタディ調査、スタッフ調査のデータを用いた。(付録：図表 A)



## 2. 令和3年度事業調査データを対象とした深掘分析方法

### (1) 分析方法と AI 活用可能性検証の概要

平成 18 年度に実施された「高齢者介護実態調査」の結果や令和 3 年度事業の収集データを整理の上、各分析および検証は以下の目的を踏まえて実施した。

#### ① 施設観点でのケア時間変化の影響要因分析

- ・ ICT等の導入状況と介護スタッフのスキル習熟度を踏まえ、施設間における同程度の要介護度の入所者に対し、入所者の状態像以外にケア時間の差異に影響を与える特徴的な要素を明確化することを目的とした。

#### ② 経年による状態像特徴変化の影響要因分析

- ・ 平成 18 年度調査からの入所者の年齢や要介護度分布の変化、およびそれに伴う状態像への影響を、入所者情報や状態像調査結果等各調査結果の比較により明確化することを目的とした。

#### ③ 状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索

- ・ 現行の樹形モデルと令和 3 年度事業で収集した実際の介護時間との乖離の度合いを調査のうえ、機械学習アルゴリズムによる推定モデルと現行の樹形モデルの推計結果の比較と解釈を行い、それぞれの推計の特徴を検証した。平成 18 年度調査から施設の ICT 活用や入所者の状態像が変化した前提を踏まえ、状態像調査結果とタイムスタディ結果の関係性を表現するモデルを探索することを目的とした。

#### ④ タイムスタディにおける AI 活用可能性検証

- ・ 令和 3 年度事業にて技術検証を行った AI 要素技術の有用性・課題をもとに、AI 活用による費用削減・時間短縮の効果を最大化させる点から、高齢者介護の実態調査の工程においてタイムスタディ工程における AI の活用を前提に、物体認識のための学習に用いるデータの改善や一般物体認識 AI の構築によりケア行為推定モデルの構築を図り、今後の活用可能性について検討を行うことを目的とした。

## (2) 分析・検証方法の詳細

令和3年度事業で調査対象とした下記の10施設（介護老人福祉施設3施設、介護老人保健施設7施設）に関して収集した施設情報、調査対象者状態情報、施設介護情報のデータを前提に分析を実施した。

なお、本分析では介護老人福祉施設と介護老人保健施設を中心とした施設を対象とした実行結果であることから、全ての介護保険施設をもとにした傾向とは異なることに留意が必要である。

加えて調査対象とした施設数が10施設と限定的な調査であるため、各施設類型（介護老人福祉施設、介護老人保健施設）における代表性を示さない可能性が存在する事にも留意する必要がある。

法人名	施設名	種別	対象人数 (入居者)	対象人数 (スタッフ)
社会福祉法人シルヴァーウィング	新とみ	介護老人福祉施設	4	4
社会福祉法人吉祥会	寒川ホーム	介護老人福祉施設	53	16
公益財団法人積善会	リバーイースト	介護老人保健施設	37	15
社会福祉法人敬英会	特別養護老人ホーム幸楽の里ねや川	介護老人福祉施設	8	25
医療法人敬英会	つるまち	介護老人保健施設	25	18
	さくらがわ	介護老人保健施設	20	14
	グリーンガーデン橋本	介護老人保健施設	10	17
医療法人社団晴山会	晴山会ケアセンター	介護老人保健施設	10	20
	ばらの里	介護老人保健施設	17	39
社会福祉晴山会	晴山苑	介護老人保健施設	12	13

### ①施設観点でのケア時間変化の影響要因分析

#### (ア) 調査対象施設の類型化

ICTの活用による施設間のケア時間の差異とその要因となりうる項目を明確化するため、令和3年度事業で施設に対し調査を行った施設運営方針についての項目のうち、以下3つの観点から調査対象の施設を類型化した。

- ・職員負担軽減のためのテクノロジー（介護ロボット・センサー等）活用有無
- ・情報共有の工夫（インカムの活用によるタイムリーな情報共有等）実施有無
- ・記録・報告様式の工夫（記録の電子化等）実施有無

#### (イ) 平均ケア時間分布の比較

施設運営方針観点においては「(ア) 調査対象施設の類型化」に記述のICT活用有無による類型化を実施の上、施設の入所者単位での平均ケア時間分布の比較を要介護度別に行った。一方で、職員の習熟度の観点での比較においては、1入所者に対してケアを行う職員が複数人紐づくケースがあるため、入所者単位ではなくケア単位での平均ケア時間について、職員の習熟度ごとに要介護度別に比較を行った。なお、職

員の習熟度に関しては、認定介護福祉士になるにあたって介護福祉士資格取得後の実務経験が5年以上必要なことや、養成学校卒業後の介護福祉士資格継続の条件の一つに5年以上の実務経験があることなどから5年を基準とした。

## ②経年による状態像特徴変化の影響要因分析

---

### (ア) 入所者構成比の比較

全国的な高齢化に伴い、調査対象の施設における入所者の状態像も変化しているという想定の下、入所者の年齢や要介護度分布にどのような変化があるのかを把握するため、年齢階級および要介護度別の入所者の人数構成比について平成18年度の調査と令和3年度調査の結果から比較を行った。

### (イ) 状態像調査項目回答結果の分析

状態像の経年による様々な変化のうち、変化の要因となりうる特定の状態像があるという想定の下、状態像調査の項目同士にどのような関連があるのか、他の項目に影響を与えうる重要な項目は何かを明確化するため、状態像項目の相関を分析した。

### (ウ) 状態像調査項目回答結果内訳の経年比較

年齢や要介護度分布の変化に伴い、入所者の状態像にどのような変化があるのか把握するため、状態像調査結果内訳を平成18年度の調査と令和3年度調査の結果を用いて比較した。

## ③状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索

---

令和3年度の状態像調査結果およびケアコードにおけるタイムスタディ結果の関係性を表現するモデルを構築するにあたって以下の2つを検証対象とした。

- ・ 現行の樹形モデル
- ・ 機械学習手法を活用した推計モデル

ただし、データ量により検証可能な機械学習モデルが決まるため、検証対象としたデータ量を踏まえ、本調査ではホワイトボックス手法を中心とした機械学習モデルを適用した。

加えて、機械学習手法を前提とした場合、さらに状態像調査結果およびタイムスタディ結果の関係性を表現するための改善仮説が設定可能で、各改善仮説の検証結果を踏まえて最適な組合せを探索の上、最も表現力を持つ推計モデルの状態を明確化した。

### (ア) 現行の樹形モデルによるケア時間の推計

現行の樹形モデルにより令和3年度調査での状態像調査結果をインプットとして

要介護認定等基準時間を推計し、各樹形モデルとケアコード大分類との割り当てを実施の上、タイムスタディにおける実際のケア時間との差異や樹形モデルの推定の特徴を分析した。

#### (イ) 機械学習モデルによるケア時間推計の実行

実際のケア時間を正解データとして学習を行った機械学習モデルを用いることで推計値との差異が解消されるという想定をした。推定精度や分析結果の解釈性の高さ、調査データの規模等を考慮し、樹形モデルとの比較を行うための複数の機械学習モデルを選定の上、樹形モデルと同様に状態像調査結果をインプットとしてケア時間の推計を実行し、樹形モデルとの推計結果の差異や推計において重視される状態像の違いを分析した。

#### (ウ) 機械学習モデルによる推計の改善検証

(イ) で特に推定精度が高かった機械学習モデルに対して、さらに推計の精度を高めるための複数の改善施策を実行・検証した。

### ④タイムスタディにおける AI 活用可能性検証

令和 3 年度事業での AI 活用可能性評価における一般物体認識 AI による認識結果を前提に、認識対象とする道具を増加させた。また、令和 3 年度事業における認識結果も含む一般物体認識 AI と音声認識 AI による認識結果の両方の情報を用いてタイムスタディ調査で収集した映像情報から入所者に対する施設職員によるケア行為を推定するモデルの構築を行った。

#### (ア) 一般物体認識 AI による認識対象の拡充

各ケアで用いられる道具の情報を増やしてケア行為を学習することにより推定ができる想定の下、推定のために必要な情報として用いる道具として、各ケアに特有であるが令和 3 年度調査で認識できなかった、あるいは認識対象としていなかった物品を新たに認識対象として選定した。

#### (イ) ケア行為推定モデルの構築

令和 3 年度調査での認識結果を含む物体認識結果と音声認識結果に加え、「(ア) 一般物体認識 AI による認識対象の拡充」で選定した物品の認識結果を学習データとして集約し、映像記録上のケア行為を推定する AI を構築した。

特に AI 活用の利点を最も享受可能と想定されるケア行為を「ケア提供時間が長いケアコード」、「認識すべきケア内容が多いケアコード」の 2 つの観点から評価対象とするケアコードを選定の上、AI による代替可能性評価を行った。

(ウ) ケア推定対象の拡張可能性検証

「(イ) ケア行為推定モデルの構築」でケア行為推定の対象としたケアコード以外に、タイムスタディ効率化の観点から推定の優先度が高いケアコードに対し、AIによる推定の可能性について検証した。

### 3. 分析・検証結果

#### (1) 施設観点でのケア時間変化の影響要因分析の実施結果

同程度の要介護度の入所者に対するICTの活用による施設間のケア時間の差異やスタッフの習熟度によるケア時間の差異の明確化を目的に、令和3年度事業におけるタイムスタディ及び施設調査の実施結果を用いてケア行為に要する時間を分析した。

なお、施設調査の対象とした10施設及び要支援2の1人を除く193人の調査対象者における約204時間の映像記録を集計対象とした。

##### ① ICTの活用有無における平均ケア時間分布の比較

「2-(2)-①-(ア) 調査対象施設の類型化」で選定した施設運営方針観点で対象施設を類型化したところ、(1) (ア)～(ウ)すべて当てはまる、(2) (ア)のみ当てはまる、(3) (ウ)のみ当てはまる (4) (ア)～(ウ)どれも当てはまらない、の4通りのグループに分かれ、図表2に示した通りである。ケア時間の差異の明確化にあたっては、3つの各施設要素の有無によって施設間でケア時間の差異があるかを確認したのち、その差異が他の2つの施設要素の影響を受けてないかを確認するため、同一条件で施設間の比較を行った。

- (ア) 職員負担軽減のためのテクノロジー活用有無
- (イ) 情報共有の工夫実施有無
- (ウ) 記録・報告様式の工夫実施有無

図表2 施設運営方針観点における施設類型化の結果

種別	施設名	(ア) 職員負担軽減のためのテクノロジー活用	(イ) 情報共有の工夫	(ウ) 記録・報告様式の工夫	
介護老人福祉施設	新とみ	●	●	●	(1)
介護老人保健施設	晴山会ケアセンター	●	●	●	
介護老人福祉施設	寒川ホーム	●	●	●	
介護老人保健施設	つるまち	●	●	●	
介護老人保健施設	晴山苑	●			(2)
介護老人保健施設	リバーイースト	●			
介護老人福祉施設	特別養護老人ホーム 幸楽の里ねや川			●	(3)
介護老人保健施設	さくらがわ			●	
介護老人保健施設	グリーンガーデン橋本			●	
介護老人保健施設	ばらの里				(4)

##### (ア) 職員負担軽減のためのテクノロジー活用有無

テクノロジーを活用している施設は、介護ロボットやセンサーなどを導入し、職員負担軽減を図る施設を示し、調査対象10施設のうちの6施設が該当する結果となっ

た。テクノロジーの活用有無による施設間の要介護度別の集計結果を図表 3 に示す。

図表 3 職員負担軽減のためのテクノロジー活用有無別ケア時間集計結果

要介護度	テクノロジーを活用している			テクノロジーを活用していない		
	該当の入所者数合計(人)	1人当たり平均ケア時間の平均値(分)	1人当たり平均ケア時間の標準偏差	該当の入所者数合計(人)	1人当たり平均ケア時間の平均値(分)	1人当たり平均ケア時間の標準偏差
要介護 1	23	0.44	0.14	7	0.66	0.31
要介護 2	24	0.43	0.21	9	0.51	0.10
要介護 3	31	0.54	0.20	15	0.67	0.30
要介護 4	40	0.71	0.42	11	0.68	0.29
要介護 5	20	0.77	0.38	13	0.95	0.52



テクノロジーを活用する施設の入所者(調査対象者数:138)と、活用していない施設の入所者(調査対象者数:55)に対する平均ケア時間の度数分布を要介護度別に図表 4 に示す。横軸は 0.2 分単位で区切った平均ケア時間を示し、縦軸は各階級(平均ケア時間)に含まれるデータ数の割合(%)を示す(以下、同様)。

要介護 1～3 の入所者において、介護ロボットやセンサーなど職員負担軽減のためのテクノロジー活用をしている施設の入所者は、活用していない施設の入所者と比較して平均ケア時間が 0.6 分以上の割合が低く、0.2-0.4 分の割合が高い。また、統計的検定により、要介護 1 と 2 の入所者の平均ケア時間分布に有意差があることがわかった ( $p$  値 $<0.05$ )。なお、分布の差の検定についてはウィルコクソンの順位和検定を用いた(以下、同様)。

このことから、同要介護度の入所者同士で比較した際、特に要介護 1 と 2 の入所者においてはテクノロジーを活用する施設のケア時間が比較的短くなっている傾向が確認できた。


要介護 1 と 2 の入所者に関してはケア時間が短く、要介護 3 から 5 の入所者においては大きな差は見られなかった。比較的要介護度が低い入所者へのケアの方が、テクノロジーで代替できるケアの割合が大きく、介護ロボット・センサー等活用のケア時間短縮への影響が強くなるためと考えられる。

図表4 職員負担軽減のためのテクノロジー活用有無における要介護度別の1人当たり平均ケア時間の分布







### 要介護2




### 要介護2







### 要介護3



### 要介護3







(イ) 情報共有の工夫実施有無

情報共有を工夫している施設は、インカムの活用によるタイムリーな情報共有などを実施している施設を示し、調査対象 10 施設のうちの 4 施設が該当する結果となった。情報共有の工夫実施有無による施設間の要介護度別の集計結果を図表 5 に示す。

図表 5 情報共有の工夫実施有無別ケア時間集計結果


要介護度	情報共有を工夫している			情報共有を工夫していない		
	該当の入所者数合計(人)	1人当たり平均ケア時間の平均値(分)	1人当たり平均ケア時間の標準偏差	該当の入所者数合計(人)	1人当たり平均ケア時間の平均値(分)	1人当たり平均ケア時間の標準偏差
要介護5						



要介護 1	4	0.38	0.04	26	0.51	0.22
要介護 2	10	0.51	0.28	23	0.43	0.14
要介護 3	23	0.57	0.22	23	0.59	0.27
要介護 4	36	0.74	0.43	15	0.62	0.27
要介護 5	20	0.75	0.41	13	0.93	0.46

情報共有を工夫している施設の入所者(調査対象者数:90)と、工夫していない施設の入所者(調査対象者数:103)に対する平均ケア時間の度数分布を図表 6 に示す。


どの要介護度においても情報共有の工夫の実施の有無で大きな差異は見られず、統計的な有意差も見られなかったことから、情報共有の工夫による生産性向上の傾向は見受けられなかった。なお、情報共有を工夫していない施設での要介護 1 に該当する入所者数が 4 人と極小であることから、あくまで参考値として認識いただきたい。

図表 6 情報共有の工夫実施有無における要介護度別の 1 人当たり  
平均ケア時間の分布







要介護2




要介護3





要介護3




要介護4









(ウ) 記録・報告様式の工夫実施有無

記録・報告様式を工夫している施設は、記録の電子化などを実施している施設を示し、調査対象 10 施設のうちの 7 施設が該当する結果となった。記録・報告様式の工夫実施有無による施設間の要介護度別の集計結果を図表 7 に示す。

**図表 7 記録・報告様式の工夫実施有無別ケア時間集計結果**

要介護度	記録・報告様式を工夫している			記録・報告様式を工夫していない		
	該当の入所者数合計 (人)	1人当たり平均ケア時間の平均値 (分)	1人当たり平均ケア時間の標準偏差	該当の入所者数合計 (人)	1人当たり平均ケア時間の平均値 (分)	1人当たり平均ケア時間の標準偏差
要介護 1	9	0.56	0.31	21	0.46	0.15
要介護 2	17	0.52	0.22	16	0.38	0.14
要介護 3	34	0.62	0.26	12	0.45	0.08
要介護 4	44	0.74	0.41	7	0.46	0.08
要介護 5	24	0.88	0.49	9	0.71	0.26

記録・報告様式を工夫している施設の入所者(調査対象者数:128)と、工夫していない施設の入所者(調査対象者数:65)に対する平均ケア時間の度数分布を図表 8 に示す。


どの要介護度の入所者においても、記録の電子化など記録・報告様式の工夫を実施している施設の入所者は、記録・報告様式の工夫を実施していない施設の入所者と比較して平均ケア時間の平均値が大きく、また平均ケア時間が0.6分以上の割合が高い。加えて、統計的検定により要介護 2~4 の入所者の平均ケア時間分布に有意差があることがわかった (p 値<0.05)。

このことから、同要介護度の入所者同士で比較した際、すべての要介護度において記録・報告様式を工夫している施設のケア時間が比較的長くなっており、特に要介護2～4においてその傾向が強いことが確認できた。


差異の要因としては、記録・報告の仕方の工夫により、バックヤード業務が効率化されることで入所者に対するケア業務により時間を割くことができているケースがあると予想される。

また、入所者の記録を後で参照できる形で電子上に残すことで、そうでない施設と比べて各入所者個人に適した必要なケアを時間をかけて行うことができているのではないかと推察される。


図表8 情報共有の工夫実施有無における要介護度別の1人当たり




要介護1




要介護2




要介護2




要介護3




### 要介護3




### 要介護4




要介護4



要介護5





## ②スタッフの習熟度別平均ケア時間分布の比較

スタッフの習熟度による入所者に対するケアの要介護度別の集計結果を図表 9 に示す。

介護経験が 5 年以上のスタッフの方がどの要介護度においてもケア時間が長い傾向がみられた。(図表 9) 介護経験が長いスタッフほど丁寧な介護をしていることや、入所者の自立支援のためサポートの範囲を制限していることなどが推察される。


**図表 9 スタッフの習熟度別ケア時間集計結果**

要介護度	介護経験が 5 年以上		介護経験が 5 年未満	
	ケア回数 (回)	ケア 1 回当たり平均ケア時間 (分)	ケア回数 (回)	ケア 1 回当たり平均ケア時間 (分)
要介護 1	460	0.58	418	0.39
要介護 2	640	0.56	576	0.43
要介護 3	1227	0.63	1039	0.53
要介護 4	1742	0.71	1466	0.66
要介護 5	1342	0.80	864	0.76

介護経験が 5 年以上のスタッフによるケアと、介護経験が 5 年未満のスタッフによるケアにおける、平均ケア時間の分布を図表 10 に示す。どの要介護度においても、介護経験が 5 年以上のスタッフによるケアの方がケア時間が長い傾向がみられた。



図表 10 スタッフの習熟度別平均ケア時間分布



③ケアコード中分類別平均ケア時間比較

「3-(1)-① ICTの活用有無における平均ケア時間分布の比較」、「3-(1)-② スタッフの習熟度別平均ケア時間分布の比較」でケア時間の比較を行った施設運営方針やスタッフの習熟度の観点について、どのようなケアコードにおいてケア時間に差異があるのかを確認することを目的に、ケアコード中分類別に差異が大きかったものを整理した。

上述の差異の比較結果を踏まえ、施設運営方針の観点については職員負担軽減のためのテクノロジーを活用しているなど、該当の観点にあてはまる場合におけるケア時間が長いケアコードと短いケアコードの両方を、スタッフの習熟度の観点については介護経験が5年以上のスタッフによるケアにおいてケア時間が長いケアコードを整理した。

(ア) ICTの活用有無

「3-(1)-① ICTの活用有無における平均ケア時間分布の比較」で比較を行った3つの施設運営方針について、要介護度が比較的低い要介護1～2の入所者と要介護度が比較的高い要介護3～5の入所者において、施設運営方針の有無でケアコード別にケア時間を比較し、ケア時間に差異が見られたケアコードを図表11と12に示す。差異については、ケア時間の平均値を比較するため、該当の施設運営方針を満たす場合とそうでない場合でそれぞれケア回数が5回以上であり、満たす施設でのケアがそうでない場合に比べ20%以上ケア時間に差異が見られたものを抽出した。

ケア時間が短いケアコードの数が最も多いのは職員負担軽減のためのテクノロジー

活用施設であり、「23 起座」や「24 起立」など大分類2の「移動・移乗・体位交換」に属するケアや「57 目覚まし、寝かしつけ就寝」のケアが短い傾向が目立った。また、ケア時間が長いケアコードの数が最も多いのは記録・報告様式の工夫の実施施設であり、要介護1、2と要介護3、4、5の両方で「34 摂食」、「35 水分摂取」、「81 薬剤の使用」の3つでケア時間が長かった。

図表 11 施設運営方針別でケア時間が短かったケアコード

施設運営方針	要介護1・2のみで短い	要介護3・4・5のみで短い	要介護1・2と3・4・5の両方で短い
テクノロジーを活用している	18 更衣、23 起座、35 水分摂取、59 相談・助言・指導を含む会話、その他のコミュニケーション、81 薬剤の使用	25 その他の体位変換、34 摂食、82 呼吸器、循環器、消化器、泌尿器にかかる処置	24 起立、57 目覚まし、寝かしつけ就寝
情報共有を工夫している	18 更衣、24 起立、84 観察・測定・検査	25 その他の体位変換、34 摂食、58 その他の日常生活	57 目覚まし、寝かしつけ就寝
記録・報告様式を工夫している	18 更衣、84 観察・測定・検査	17 整容、58 その他の日常生活	83 運動器・皮膚・眼・耳鼻咽喉科及び手術にかかる処置

図表 12 施設運営方針別のケア時間が長かったケアコード

施設運営方針	要介護1・2のみで長い	要介護3・4・5のみで長い	要介護1・2と3・4・5の両方で長い
テクノロジーを活用している	58 その他の日常生活	42 排便、83 運動器・皮膚・眼・耳鼻咽喉科及び手術にかかる処置	なし
情報共有を工夫している	なし	42 排便	なし
記録・報告様式を工夫している	21 敷地内の移動	42 排便、57 目覚まし、寝かしつけ就寝、82 呼吸器、循環器、消化器、泌尿器にかかる処置、84 観察・測定・検査	34 摂食、35 水分摂取、81 薬剤の使用

(イ) スタッフの習熟度別

介護経験が5年未満のスタッフと比べて、介護経験が5年以上のスタッフによるケア時間が長いケアコードを整理した。施設運営方針の有無によらない、スタッフの介護経験の違いによるケアコードごとの傾向を確認するため、「3-(1)-① I C Tの活用有無における平均ケア時間分布の比較」で示した施設運営方針による4つの類型ごとにケア時間の長いケアコードを整理し、各類型に共通で該当するケアコードを探索する方針とした。(図表 13)

差異については、ケア時間の平均値を比較するため、介護経験が5年以上のスタッフによるケアと介護経験が5年未満のスタッフによるケアがそれぞれ5回以上であり、5年以上のスタッフによるケアが5年未満のスタッフによるケアの120%以上のケア時間であるケアコードを抽出した。

「21 敷地内の移動」と「34 摂食」においては施設運営方針に関わらず、介護経験が5年以上のスタッフによるケア時間が長いケースが多かった。特に「34 摂食」に関しては、要介護3～5の入所者に対してケア時間が長い傾向があった。

図表 13 介護経験が5年以上のスタッフによる方がケア時間が長かったケアコード

施設類型	要介護1・2のみで長い	要介護3・4・5のみで長い	要介護1・2と3・4・5の両方で長い
(ア)～(ウ)すべてあてはまる (4施設)	21 敷地内の移動、22 移乗、25 その他の体位変換、34 摂食、59 相談・助言・指導を含む会話、その他のコミュニケーション	71 行動上の問題の発生時の対応	なし
(ア)のみあてはまる (2施設)	83 運動器・皮膚・眼・耳鼻咽喉科及び手術にかかる処置	22 移乗、24 起立、25 その他の体位変換、34 摂食、42 排便	21 敷地内の移動、35 水分摂取
(ウ)のみあてはまる (3施設)	18 更衣、23 起座	34 摂食	57 目覚まし、寝かしつけ就寝
(ア)～(ウ)どれも当てはまらない (1施設)	なし	21 敷地内の移動、34 摂食、59 相談・助言・指導を含む会話、その他のコミュニケーション	なし

#### ④施設観点でのケア時間変化の影響要因分析結果のまとめ

---

介護ロボットや見守りセンサーの活用などのテクノロジー活用施設の方が要介護1,2の入所者においてケア時間が短い傾向が確認できた。このことから、比較的要介護度が低い入所者へのケアの方が、テクノロジーで代替できるケアの割合が大きく、介護ロボット・センサー等活用のケア時間短縮への影響が強くなると考えられる。

また、介護経験の5年以上のスタッフの方が、5年未満のスタッフと比べてどの要介護度においてもケア時間が長い傾向が見られ、介護経験が長いスタッフほど丁寧な介護をする、入所者の自立支援のためにあえてサポートの範囲を制限している、などといったことが推察できた。

ケアコード中分類別には、入所者単位で平均ケア時間を比較した際と同様の傾向がケアコード単位でも見られ、ケア時間が短いケースが多いのは職員負担軽減のためのテクノロジー活用をしている施設であり、テクノロジー活用をしている施設では大分類2の「移動・移乗・体位交換」に属するケアや「57 目覚まし・寝かしつけ」のケアが短い傾向が目立ち、ロボットやセンサーなどの活用によりケアを効率的に実施できていると考えられる。

一方で、記録・報告様式の工夫実施施設では、入所者あたりの平均ケア時間もどの要介護度においても長い傾向にあった。ケアコード別にみると、特に要介護1,2と要介護3,4,5の両方で「34 摂食」、「35 水分摂取」、「81 薬剤の使用」の3つでケア時間が長く、各入所者の食事や処方薬・水分摂取のタイミングや方法等、電子上に保存された過去の記録を参照することで時間をかけて適切なケアを行っていると推察できた。

スタッフ観点では、施設運営方針の有無にかかわらず、全体的に介護経験の長い職員の方が介護経験の短い職員と比べ敷地内の移動や食事の際に入所者と十分なコミュニケーションを取るなどのケアをしていると考えられる。

## (2) 経年による状態像特徴変化の影響要因分析

---

入所者の年齢・要介護度の分布や、状態像の内訳の変化などの入所者観点での変化を令和3年度と平成18年度の各調査結果の比較や状態像調査結果の分析により検証した。分析対象は、要支援2の入所者1名を含む194名である。

なお、平成18年度の「高齢者介護実態調査」においては年齢階級に紐づく状態像とケア時間の情報がなかったため、これらの項目については比較を行っていないことに留意いただきたい。

### ①入所者構成比比較

---

#### (ア) 年齢階級別

年齢階級別の令和3年度と平成18年度の入所者数の集計結果を図表14に示す。


なお、令和3年度の調査対象者における平均年齢は86.2歳、平成18年度の調査対象者における平均年齢は84.1歳であった。

図表14 年齢階級別の令和3年度と平成18年度の入所者数集計結果

要介護度	令和3年度		平成18年度	
	入所者数(人)	人数構成比(%)	入所者数(人)	人数構成比(%)
65歳未満	3	1.6	84	2.4
65歳以上70歳未満	1	0.5	105	3.0
70歳以上75歳未満	11	5.7	243	6.9
75歳以上80歳未満	20	10.3	480	13.6
80歳以上85歳未満	36	18.6	776	22.1
85歳以上90歳未満	60	30.9	838	23.8
90歳以上95歳未満	35	18.0	693	19.7
95歳以上100歳未満	23	11.9	255	7.3
100歳以上	5	2.6	45	1.3

年齢階級別の人数構成比の分布を図表15に示す。令和3年度では平成18年度と比べて85歳以上の入所者の割合の増加がみられ、特に85~89歳の割合の増加が大きかった。

図表15 年齢階級別の令和3年度と平成18年度の入所者人数構成比の分布



(イ) 要介護度別


要介護度別の令和3年度と平成18年度の入所者数の集計結果を図表16に示す。

図表 16 要介護度別の令和 3 年度と平成 1 8 年度の入所者数集計結果

要介護度	令和 3 年度		平成 1 8 年度	
	入所者数 (人)	人数構成比 (%)	入所者数 (人)	人数構成比 (%)
要支援 1	0	0.0	2	0.1
要支援 2	1	0.5	10	0.3
要介護 1	30	15.5	271	7.7
要介護 2	33	17.0	461	13.1
要介護 3	46	23.7	816	23.2
要介護 4	51	26.3	974	27.7
要介護 5	33	17.0	985	28.0

要介護度別の人数構成比の分布を図表 17 に示す。令和 3 年度は平成 18 年度と比べ、要介護 1～3 の入所者が占める割合が増加（応じて要介護 4, 5 の割合が減少）している。

図表 17 要介護度別の令和 3 年度と平成 1 8 年度の入所者構成比分布



(ウ) 要介護度・施設類型別

要介護度別の令和 3 年度と平成 1 8 年度の入所者数の集計結果を、さらに施設類型（介護老人福祉施設、介護老人保健施設）で分けたものを図表 18、19 に示す。

図表 18 要介護度別の令和 3 年度と平成 1 8 年度の入所者数集計結果（介護老人福祉施設）


要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
要支援 1	0	0.0	0	0.0
要支援 2	0	0.0	1	0.1
要介護 1	2	3.1	43	3.9
要介護 2	1	1.6	95	8.7
要介護 3	20	31.3	238	21.7
要介護 4	25	39.1	349	31.8
要介護 5	16	25.0	372	33.9

図表 19 要介護度別の令和 3 年度と平成 1 8 年度の入所者数集計結果（介護老人保健施設）


要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
要支援 1	0	0.0	2	0.1
要支援 2	1	0.8	9	0.5
要介護 1	28	21.5	209	11.8
要介護 2	32	24.6	327	18.4
要介護 3	26	20.0	483	27.2
要介護 4	26	20.0	445	25.0
要介護 5	17	13.1	304	17.1

要介護度・施設類型別の人数構成比の分布を図表 20、21 に示す。令和 3 年度は平成 18 年度と比べ、要介護 3～5 の入所者が多くを占める介護老人福祉施設においては、要介護 3,4 の入所者の割合が増加し、要介護 5 の入所者の割合が減少している。また、介護老人保健施設においては、要介護 1,2 の入所者の割合が増加し、要介護 3～5 の入所者の割合が減少している。

図表 20 要介護度別の令和3年度と平成18年度の入所者構成比分布（介護老人福祉施設）



図表 21 要介護度別の令和3年度と平成18年度の入所者構成比分布（介護老人保健施設）



(エ) 年齢階級・要介護度別

年齢階級別の令和3年度と平成18年度の入所者数の集計結果を、さらに要介護1～5の要介護度別で分けたものを図表22～26に示す。



図表 22 年齢階級別の令和 3 年度と平成 1 8 年度の入所者数集計結果（要介護 1）

要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
65 歳未満	0	0	3	1.1
65 歳以上 70 歳未満	0	0	7	2.6
70 歳以上 75 歳未満	0	0	22	8.1
75 歳以上 80 歳未満	4	13.3	40	14.8
80 歳以上 85 歳未満	5	16.7	60	22.1
85 歳以上 90 歳未満	11	36.7	64	23.6
90 歳以上 95 歳未満	6	20.0	56	20.7
95 歳以上 100 歳未満	4	13.3	18	6.6
100 歳以上	0	0.0	1	0.4

図表 23 年齢階級別の令和 3 年度と平成 1 8 年度の入所者数集計結果（要介護 2）

要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
65 歳未満	1	3.03	15	3.25
65 歳以上 70 歳未満	0	0	19	4.12
70 歳以上 75 歳未満	3	9.09	25	5.42
75 歳以上 80 歳未満	0	0	53	11.5
80 歳以上 85 歳未満	7	21.21	109	23.64
85 歳以上 90 歳未満	13	39.39	112	24.3
90 歳以上 95 歳未満	2	6.06	81	17.57
95 歳以上 100 歳未満	5	15.15	40	8.68
100 歳以上	2	6.06	7	1.52

図表 24 年齢階級別の令和 3 年度と平成 1 8 年度の入所者数集計結果（要介護 3）

要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
65 歳未満	2	4.4	12	1.5
65 歳以上 70 歳未満	0	0.0	24	2.9
70 歳以上 75 歳未満	3	6.5	62	7.6
75 歳以上 80 歳未満	5	10.9	110	13.5
80 歳以上 85 歳未満	6	13.0	199	24.4
85 歳以上 90 歳未満	13	28.3	188	23.0
90 歳以上 95 歳未満	10	21.7	157	19.2
95 歳以上 100 歳未満	4	8.7	56	6.9
100 歳以上	3	6.5	8	1.0

図表 25 年齢階級別の令和 3 年度と平成 1 8 年度の入所者数集計結果（要介護 4）


要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
65 歳未満	0	0	22	2.3
65 歳以上 70 歳未満	0	0	27	2.8
70 歳以上 75 歳未満	4	7.8	60	6.2
75 歳以上 80 歳未満	5	9.8	155	15.9
80 歳以上 85 歳未満	12	23.5	185	19.0
85 歳以上 90 歳未満	10	19.6	231	23.7
90 歳以上 95 歳未満	15	29.4	216	22.2
95 歳以上 100 歳未満	5	9.8	67	6.9
100 歳以上	0	0.0	11	1.1

図表 26 年齢階級別の令和 3 年度と平成 1 8 年度の入所者数集計結果（要介護 5）


要介護度	令和 3 年度		平成 1 8 年度	
	入所者数（人）	人数構成比（%）	入所者数（人）	人数構成比（%）
65 歳未満	0	0	31	3.2
65 歳以上 70 歳未満	1	3.0	28	2.8
70 歳以上 75 歳未満	1	3.0	74	7.5
75 歳以上 80 歳未満	6	18.2	122	12.4
80 歳以上 85 歳未満	6	18.2	219	22.2
85 歳以上 90 歳未満	12	36.4	240	24.4
90 歳以上 95 歳未満	2	6.0	181	18.4
95 歳以上 100 歳未満	5	15.2	72	7.3
100 歳以上	0	0.0	18	1.8

年齢階級・要介護度別の人数構成比の分布を図表 27～31 に示す。令和 3 年度は平成 18 年度と比べ、どの要介護度においても 85 歳以上の入所者の割合が増加しており、特に 85 歳以上 90 歳未満の年齢階級については、要介護 1, 2, 3, 5 において入所者の割合が増加している。


図表 27 年齢階級別の令和3年度と平成18年度の入所者構成比分布（要介護1）




図表 28 年齢階級別の令和3年度と平成18年度の入所者構成比分布（要介護2）




図表 29 年齢階級別の令和3年度と平成18年度の入所者構成比分布（要介護3）



図表 30 年齢階級別の令和3年度と平成18年度の入所者構成比分布（要介護4）



図表 31 年齢階級別の令和3年度と平成18年度の入所者構成比分布（要介護5）



## ②状態像調査項目の相関分析

令和3年度における状態像調査の回答結果を「介助が不要（問題なし）」と「何らかの介助が必要（問題あり）」の2つに分類し、各項目の相関係数を算出した。相関係数が0.2以上0.4未満の場合弱い相関が、0.4以上の場合中程度以上の相関があるとされる。各項目で相関が一定上みられた状態像調査項目群ごとの組み合わせを図表32～34に示す。

状態像調査項目の第1群に属する身体機能・起居動作の項目の「座位保持」と第2群に属する生活機能の多くの項目で関連が見られた。また、第5群の社会生活への適応に属する「日常の意思決定」と第2群の生活機能、第3群の認知機能の多くの項目で関連が見られた。

図表32 身体機能と生活機能の項目の相関係数

項目	1-3	1-4	1-5	1-6	1-7	1-8	1-9	1-10	1-11	1-12	1-13
	寝返り	起き上がり	座位保持	両足での立位保持	歩行	立ち上がり	片足での立位保持	洗身	つめ切り	視力	聴力
2-1 移乗	0.31	0.26	0.65	0.42	0.37	0.24	0.07	0.22	0.10	0.23	-0.01
2-2 移動	0.19	0.19	0.60	0.31	0.29	0.21	0.06	0.19	0.08	0.24	0.08
2-3 えん下	0.09	0.06	0.27	0.09	0.08	0.05	0.01	0.05	0.02	0.13	0.00
2-4 食事摂取	0.21	0.17	0.58	0.25	0.21	0.13	0.04	0.12	0.05	0.33	0.11
2-5 排尿	0.21	0.28	0.53	0.39	0.37	0.34	0.10	0.31	0.14	0.14	-0.02
2-6 排便	0.19	0.25	0.52	0.38	0.35	0.31	0.10	0.27	0.03	0.16	-0.04
2-7 口腔清潔	0.15	0.18	0.43	0.25	0.18	0.24	-0.06	0.29	0.13	0.25	0.13
2-8 洗顔	0.15	0.19	0.43	0.31	0.30	0.27	-0.05	0.33	0.14	0.26	0.02
2-9 整髪	0.21	0.26	0.43	0.34	0.36	0.27	-0.05	0.28	0.14	0.26	0.04
2-10 上衣の着脱	0.21	0.22	0.50	0.30	0.28	0.24	-0.06	0.29	0.13	0.16	0.02
2-11 ズボン等の着脱	0.26	0.30	0.46	0.36	0.38	0.30	-0.05	0.36	0.16	0.23	-0.04
2-12 外出頻度	-0.04	0.01	0.15	-0.10	-0.08	-0.05	-0.02	0.05	-0.02	-0.02	0.09

図表 33 生活機能と社会生活への適応の項目の相関係数

項目		5-1	5-2	5-3	5-4	5-5	5-6
		薬の内服	金銭の管理	日常の意思決定	集団への不 適応	買い物	簡単な調理
2-1	移乗	0.10	0.10	0.42	0.35	0.07	-
2-2	移動	0.08	0.08	0.57	0.23	0.06	-
2-3	えん下	0.02	0.02	0.27	-0.02	0.01	-
2-4	食事摂取	0.05	0.05	0.57	0.15	0.04	-
2-5	排尿	0.14	0.03	0.38	0.29	-0.05	-
2-6	排便	0.14	0.03	0.36	0.29	-0.05	-
2-7	口腔清潔	0.02	0.02	0.41	0.06	0.09	-
2-8	洗顔	0.04	0.04	0.37	0.14	0.10	-
2-9	整髪	0.04	0.04	0.37	0.21	0.10	-
2-10	上衣の着脱	0.13	0.13	0.39	0.23	0.09	-
2-11	ズボン等の着脱	0.16	0.16	0.37	0.27	0.11	-
2-12	外出頻度	0.40	0.19	0.15	0.15	-0.02	-

図表 34 認知機能と社会生活への適応の項目の相関係数

項目		5-1	5-2	5-3	5-4	5-5	5-6
		薬の内服	金銭の管理	日常の意思決定	集団への不 適応	買い物	簡単な調理
3-1	意思の伝達	0.08	0.08	0.55	0.28	0.06	-
3-2	毎日の日課を理解すること	0.11	0.11	0.52	0.25	0.08	-
3-3	生年月日や年齢を言うこと	0.09	0.09	0.53	0.25	0.06	-
3-4	短期記憶	0.14	0.14	0.44	0.26	0.10	-
3-5	自分の名前を言うこと	0.04	0.04	0.42	0.20	0.03	-
3-6	今の季節を理解すること	0.10	0.10	0.52	0.26	0.07	-
3-7	場所の理解	0.10	0.10	0.60	0.33	0.07	-
3-8	徘徊	0.04	0.04	0.08	0.23	0.03	-
3-9	外出すると戻れない	0.06	0.06	0.19	0.44	0.04	-

### ③状態像調査結果比較

令和3年度と平成18年度との状態像調査結果の各選択肢の回答の割合に差があるのか、適合度検定を用いて検証を行った。

平成18年度におけるとの回答との有意な差があった項目数（ $p$  値 $<0.05$ ）の要介護度別の結果を図表35に示す。要介護3～5の入所者において、平成18年度より介助の度合いが小さい回答の項目が多かった。

図表35 平成18年度回答結果との有意な差があった項目数

要介護度	差があった項目数	令和3年度の方が状態が悪い項目数	令和3年度の方が状態が良い項目数
要介護1	11	10	1
要介護2	11	5	6
要介護3	16	4	12
要介護4	30	1	29
要介護5	41	7	34

状態像調査項目ごとに、各要介護度で回答結果に差異があったものを図表36に示す。

●が令和3年度の方が状態が悪い傾向、○が令和3年度の方が状態が良い傾向だったものを表す。要介護1～3の入所者では、座位保持の状態が平成18年度より悪い傾向があり、要介護4,5の入所者と比べ生活機能や認知機能において平成18年度より良い状態の傾向の項目が少ない。一方、要介護4,5の入所者においては、認知機能の多くの項目で平成18年度より良い状態の傾向がある。

図表36 状態像調査結果の令和3年度と平成18年度との比較

設問		要介護1	要介護2	要介護3	要介護4	要介護5
1-1-0	麻痺の有無	-	○	○	○	○
1-1-1	麻痺_左上肢	-	-	-	-	○
1-1-2	麻痺_左下肢	-	○	○	○	○
1-1-3	麻痺_右上肢	-	-	○	○	○
1-1-4	麻痺_右下肢	-	○	○	○	○
1-1-5	麻痺_その他	-	-	-	-	-
1-2-0	拘縮の有無	-	-	○	○	○
1-2-1	拘縮_肩関節	-	-	○	-	○
1-2-2	拘縮_股関節	-	-	○	○	○
1-2-3	拘縮_膝関節	-	-	○	○	○
1-2-4	拘縮_その他	-	-	-	-	-
1-3	寝返り	●	-	-	-	○



1-4	起き上がり	●	-	-	-	○
1-5	座位保持	●	-	●	-	○
1-6	両足での立位保持	-	-	-	-	○
1-7	歩行	●	●	-	-	-
1-8	立ち上がり	-	-	-	-	○
1-9	片足での立位保持	-	-	-	-	-
1-10	洗身	-	-	-	○	-
1-11	つめ切り	●	-	-	○	-
1-12	視力	-	-	-	-	-
1-13	聴力	-	-	-	-	○
2-1	移乗	●	-	-	-	○
2-2	移動	○	-	-	○	○
2-3	えん下	-	-	-	○	○
2-4	食事摂取	-	-	-	○	○
2-5	排尿	-	-	-	○	-
2-6	排便	●	-	-	○	-
2-7	口腔清潔	-	-	-	○	○
2-8	洗顔	-	-	-	○	○
2-9	整髪	-	-	-	○	○
2-10	上衣の着脱	-	-	-	○	○
2-11	ズボン等の着脱	-	-	-	○	-
2-12	外出頻度	-	-	-	-	-
3-1	意思の伝達	-	-	-	○	○
3-2	毎日の日課を理解すること	-	-	-	○	○
3-3	生年月日や年齢を言うこと	-	-	-	○	○
3-4	短期記憶	-	●	●	-	○
3-5	自分の名前を言うこと	-	-	-	-	○
3-6	今の季節を理解すること	-	-	-	-	○
3-7	場所の理解	-	-	-	-	○
3-8	徘徊	-	-	-	○	●
3-9	外出すると戻れない	-	-	●	●	-
4-1	物を盗られたなどと被害的になること	-	-	-	-	●
4-2	作話をする	-	-	-	-	●
4-3	泣いたり、笑ったりして感情が不安定になること	●	-	-	-	-
4-4	昼夜逆転	-	-	-	○	○
4-5	しつこく同じ話をすること	-	-	-	-	○

4-6	大声を出すこと	-	-	-	-	●
4-7	介護に抵抗すること	-	-	-	○	-
4-8	「家に帰る」等と言 い落ち着きがないこ と	-	-	-	-	-
4-9	一人で外に出たがり 目が離せないこと	-	●	-	-	-
4-10	いろいろなものを集 めたり、無断でもっ てくること	-	-	-	-	-
4-11	物を壊したり、衣類 を破いたりすること	-	-	-	-	●
4-12	ひどい物忘れ	-	○	○	○	○
4-13	意味もなく独り言や 独り笑いすること	-	-	-	-	-
4-14	自分勝手に行動する こと	-	○	○	○	-
4-15	話がまとまらず、会 話にならないこと	-	○	○	○	-
5-1	薬の内服	●	●	-	-	-
5-2	金銭の管理	●	●	●	-	-
5-3	日常の意思決定	-	-	-	○	○
5-4	集団への不適応	-	-	○	-	●
5-5	買い物	-	-	-	-	-
5-6	簡単な調理	-	-	-	-	-
6-1	点滴の管理	-	-	-	-	-
6-2	中心静脈栄養	-	-	-	-	-
6-3	透析	-	-	-	-	-
6-4	ストーマ（人工肛 門）の処置	-	-	-	-	-
6-5	酸素療法	-	-	-	-	-
6-6	レスピレーター（人 工呼吸器）	-	-	-	-	-
6-7	気管切開の処置	-	-	-	-	-
6-8	疼痛の看護	-	-	-	-	-
6-9	経管栄養	-	-	-	-	●
6-10	モニター測定（血 圧、心拍、酸素飽和 度等）	-	-	-	-	-
6-11	じょくそうの処置	-	-	-	-	-
6-12	カテーテル（コンド ームカテーテル、留 置カテーテル、ウロ ストーマ）	-	-	-	-	-

#### ④経年による状態像特徴変化の影響要因分析結果のまとめ

---

平成18年度と比べ、軽度の要介護度と重度の要介護度の割合の差が縮まっており、85歳以上のより高齢な入所者においても比較的軽度の要介護度でとどまっている層があり、健康寿命の増加の影響が一因として考えられる。

身体機能の高低と生活機能の高低は全体的にやや正の相関が見られ、特に「座位保持」とは中程度以上の相関があり、座っている状態をしっかりと保てるかどうかと生活機能は一定の関連があるといえる。

また、令和3年度での調査対象においては要介護度が高い方が、状態像項目が平成18年度より良い結果となった項目が多かった。背景としては、要介護認定において認知症加算の占める部分が大きくなった、施設におけるリハビリや治療の高度化によって入所者の状態の改善が促進された、などといったことが推察される。

### (3) 状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索

---

現行の樹形モデルは、平成18年度における状態像の調査結果とタイムスタディ調査でのケア時間の関係性を表すモデルとなっている。そこで、この章では上記の介護環境と入所者の状態像経年経過という時代の変化に対して、現行モデルの機能度合いを知るとともに、機械学習を含む推定アルゴリズムが多様化したことを踏まえて、複数の推定手法の比較検証を行った。

令和3年度の観察では平成18年度の観察環境が変化している事を前提に、令和3年度の状態像の調査結果(状態像の各調査項目)とタイムスタディ調査結果(実際のケア時間)の関係性を表現するモデルを構築の上、推定の検証を行い、その特徴をまとめることとした。

#### ①ケア時間の推定比較結果


---

##### (ア) 現行の樹形モデルの推計結果

現行の樹形モデルは「食事」、「排泄」、「移動」、「清潔保持」、「間接生活介助」、「BPSD 関連行為」、「機能訓練関連行為」、「医療関連行為」の8種類の樹形モデルから実際の介護にかかる時間を推定するモデルとなる。行為区分ごとの算出時間と特別な医療の時間(医療関連行為に加算)と認知症高齢者のケア時間を加算した合計値が要介護認定等基準時間となる。なお、各樹形図上での分岐は、認定調査項目の選択と中間項目得点に基づいて選択される。


樹形モデルによる要介護認定基準時間(推定値)とタイムスタディから得られた2日間の平均介護時間(実測値)の比較を行った。これらの比較した結果を図表 37 に示す。図表 37 の横軸が樹形モデルで推計される時間(推計結果)で縦軸がタイムスタディ結果での介護時間(実測結果)である。各点の色は入居者の要介護度を意味しており、要介護度1から5まで表示している。ただし、要支援2の1名は要介護度1として扱った。推定結果と実測結果が等しい場合が図中の点線である。図表 37 より、分布が点線の下側に偏っており、推定結果が実測結果よりも長い傾向にあることを意味している。

図表 37 樹形モデルで算出される介護基準時間とタイムスタディでの介護時間の比較




推計結果と実測結果の分布をヒストグラム上で図表 38、39 に示す。それぞれのヒストグラムで、推定結果の分布は 20~100 分の範囲になだらかに広がっており、その一方で実測結果の分布は 20 分の階級をピークとして以降は減少するという特徴的な違いがみられた。これは、樹形モデルで時間がかかると推定された入居者に対して、実際のケア時間は短いことを意味している。

図表 38 樹形モデルによる推定ケア時間分布



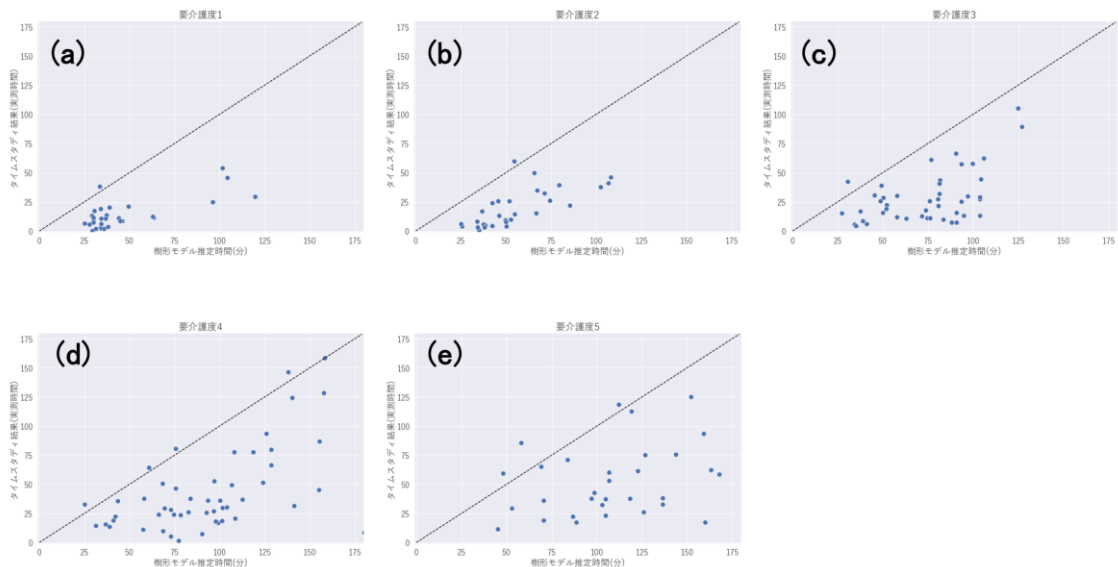
図表 39 タイムスタディ結果の時間分布



要介護度ごとの推定結果と実測結果を図表 40 に示す。(a)から(e)が要介護度 1 から 5 に対応している。推定と実測の結果の差は要介護度が高いほど顕著になるこ

とが図 4 よりわかる。要介護度が 3 以下(図表 40(a)(b)(c))では推定と実測結果は比例関係を保っているが、要介護 4, 5 (図表 40(d)(e))では入居者ごとの結果のばらつきが大きい傾向にある。全ての要介護度に対して、推定結果が実測結果よりも長いという傾向が見られた。

図表 40 要介護度毎の現行モデルの推定結果 (要介護度 1 から 5 までが(a)から(e)に対応)



#### (イ) ケア行為ごとの推計結果の詳細

ここでは、前節でみられた樹形モデルでの傾向をより詳細に調べるために、8 種類の樹形モデルそれぞれの推定の確認を行う。

ケアコード大分類と樹形モデルとの対応関係を図表 41 のような関係があると仮定して、レコード数が他と比較して少ないケアコード大分類 6 の「社会生活支援」を除き、各 8 種類の樹形モデルでの推定結果とケアコード大分類での実測結果の比較を行ったものを図表 42 に示した。推定と実測の時間の差分を計算し、どの程度差異があるかをヒストグラム上で表現している。


「移動」、「間接生活介助」、「医療関連行為」に関しては推定と実測の差が一様に減少しており、誤差が小さいことが確認できる。一方で、「清潔保持」、「食事」、「排泄」に関しては分布が平坦で、大きな差が発生しており推定誤差が確認できる。「食事」に関しては多くの推定の誤差は小さいものの少数の入居者に関しては 30 分以上の大きな誤差が生じている。「BPSD 関連」と「機能訓練」行為は他ケアコードと比較しておよそ 10 分の 1 のサンプルとなるため参考値として提示となる点に注意が必要である。

図表 41 樹形モデルとケアコード大分類の対応関係


樹形モデル	ケアコード大分類
清潔保持	入浴・清潔保持・整容・更衣

移動	移動・移乗・体位交換
食事	食事
排泄	排泄
間接生活介助	生活自立支援
BPSD 関連行為	行動上の問題
医療関連行為	医療
機能訓練関連行為	機能訓練


図表 42 各樹形モデルと推定ケア時間の予実差の分布





### 移動




### 食事



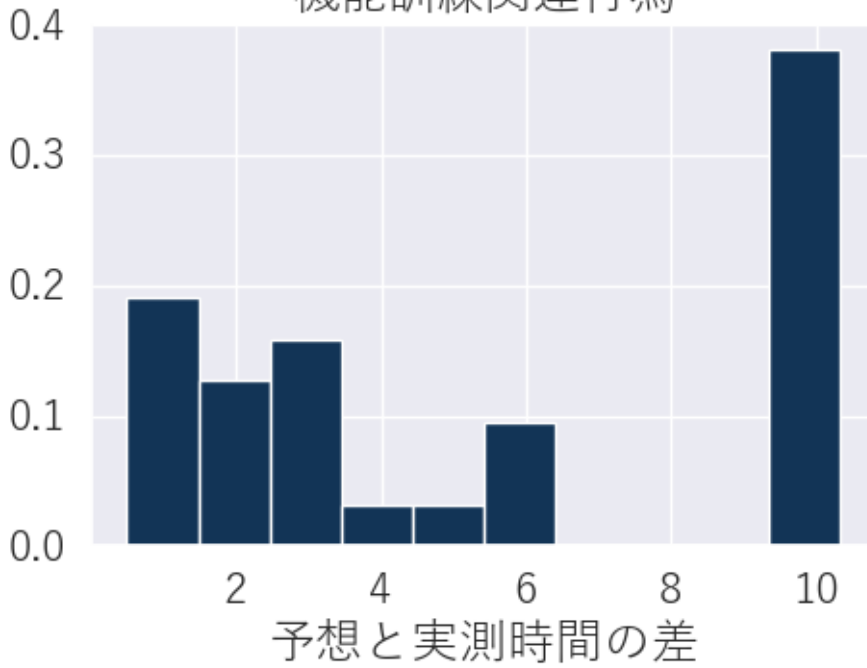




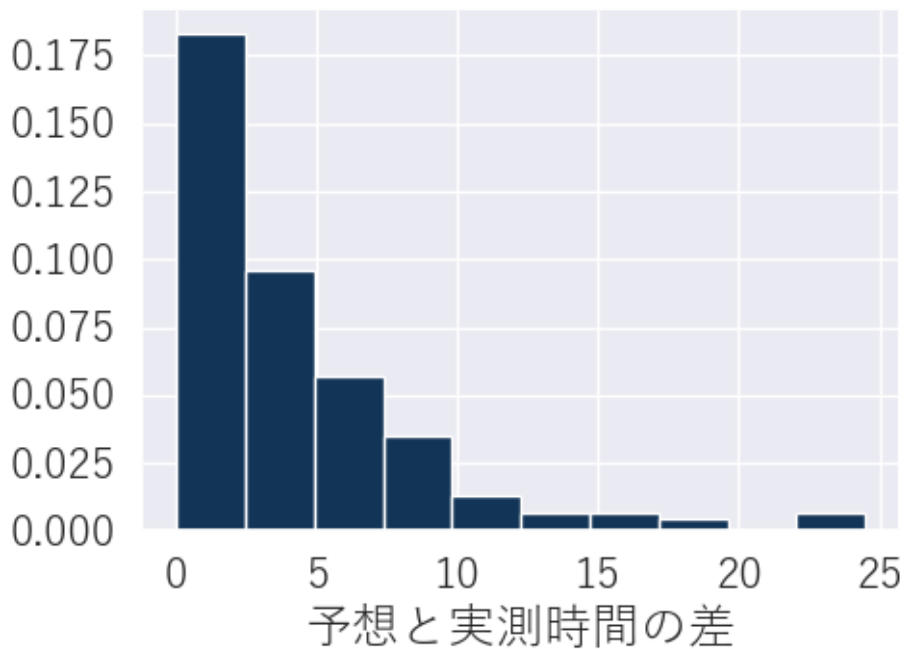
BPSD関連行為



機能訓練関連行為



## 医療関連行為





誤差の生じ方として過剰評価、過小評価の2種類がある。ここで長時間の推定誤差が発生した「清潔保持」、「食事」、「排泄」の3つの推定時間の結果を図表43に示す。なお、「清潔保持」と「排泄」についてはタイムスタディにおいてプライバシーへの配慮が必要なケア行為として当該ケア行為を撮影していないケースがある点に留意いただきたい。


まず「清潔保持」に関する推定結果は実測値の方が長い場合、短い場合のいずれも発生しており、全体的に推定に失敗している。推定結果は10分から20分の範囲に多数を占めているが、実際のケアに必要な時間は5分以下が多い傾向が見られる。実測値の方が推定より長い入居者の要介護度は全て3以上で全対象者の約10%である。

次に、「食事」時間の結果は20分以下での推定結果は実測値との差が小さいものの、30分以上と推定された入所者に関しては実測値との乖離が発生している。これらの乖離が発生した入居者の要介護度は「清潔保持」の際と同様に要介護3以上の入所者である。

最後に、「排泄」に関して5分以上と推定された入所者に関しては実測値より長く推定されるという傾向にある。特に15分以上の介護が必要と推定されても、実際は時間が0分に近い介助が必要でない入居者も存在していることがわかる。

図表 43 「清潔保持」「食事」「排泄」 関連における推定結果





(ウ) 複数の機械学習手法の比較結果

令和3年度状態像調査の表現し得るモデルの検証において、現行の樹形モデルと共に機械学習モデルでの異なる複数のアルゴリズムでの検証を行った。介護時間の推定に用いる機械学習モデルとしては、解釈性の高さを優先して決定木系、重回帰、パターン認識の3種類のアルゴリズムを採用する。採用したモデルと各モデルの特徴を図表44に示す。今回の検証では「決定木モデル」、「ランダムフォレストモデル」、「リッジ回帰モデル」、「サポートベクター回帰モデル」を機械学習モデルの比較対象として選択した。

図表 44 比較対象の機械学習モデルの種類と各モデルの特徴

比較対象の機械学習モデル		各モデルの特徴
決定木分析	決定木モデル	条件分岐を複数回実施しデータを樹形図形式にグループ分け
	ランダムフォレストモデル	学習データのサブセットから複数の決定木を作り、多数決や代表値で集約
重回帰	Ridge回帰モデル	複数の変数から一つの数式として表現
パターン認識	サポートベクター回帰モデル	「カーネル法」で非線形の分類を表現

複数の機械学習モデル間の比較における評価指標として、正答率を以下のように定義する。まず推定で得られた時間を要介護認定等基準時間で用いている、区切り幅である 0～25、25～32 分、32～50 分、50～70 分、70～110 分、110～180 分ごとの時間幅で 7 つのクラスに分ける。テストデータに対してクラスの推定が正解であるレコードをテストデータの全レコード数で割ったものを正答率とした。

ケア時間の推定にあたっては、令和 3 年度事業で収集した、各入所者の状態像（調査回答項目）とタイムスタディでの各介護に要したケア時間のデータをもとに、学習データと検証データを用意した。それぞれのデータには状態像とそれに紐づく介護時間が含まれており、機械学習モデルに対して学習データを与えることで、モデルの学習が進行する。この学習済みモデルに対して検証データとして状態像データのみを与えることで、モデルでの推定値が得られる。この推定時間と正解データである検証データの介護時間を比較することでモデルの推定精度を見積もることが可能となる。このプロセスを各機械学習モデルに対して適用することで、同一データに対しての精度比較を行った。

比較対象の現行モデル（樹形モデル）と機械学習モデル（決定木、ランダムフォレスト、リッジ回帰、サポートベクター回帰）での正答率の結果を図表 45、46 に示す。現行モデルはケア時間が長いものを一部正解しているが、全体的に長めに算出しており、正答率は 0.155 となっている。現行のデータをもとに学習を行った機械学習モデルではケア時間が短いクラスでは相対的に精度が高く、最も精度が高いランダムフォ

レストモデルでは 25 分以下の分類を 2/3 程度正解している。一方で、ケア時間が長いクラスでの予測精度が低い傾向にある。

図表 45 複数の推定モデルでの分類精度比較

時間(分)	要介護度	タイムスタディ(正解)	樹形モデル	ランダムフォレスト	決定木	リッジ回帰
0~25	非該当	29	0	19	19	16
25~32	要支援 1	5	0	1	2	0
32~50	要介護 1	12	0	2	2	2
50~70	要介護 2	4	2	1	0	1
70~90	要介護 3	1	1	1	0	0
90~110	要介護 4	1	0	0	0	0
110~180	要介護 5	6	6	0	0	0

図表 46 複数の推定モデルの正答率比較

樹形モデル	ランダムフォレスト	決定木	リッジ回帰
0.155	0.414	0.397	0.328

(エ) ランダムフォレストモデルと現行モデルでの重視される状態像の違い


令和 3 年度状態像調査の表現し得るモデルの検証において、現行の樹形モデルと共に機械学習モデルでの異なる複数のアルゴリズムでの検証を行った。介護時間の推定に用いるここではランダムフォレストの特徴量と樹形モデルでの分岐項目の比較を行う。

ランダムフォレストはある特徴量(状態像調査項目)によって分離繰り返すことで、目的変数の分類を行うアルゴリズムである。各分岐で用いられる特徴量の閾値のパラメータを学習によって決定している。ランダムフォレストモデルに代表される決定木系アルゴリズムではどの特徴量が目的変数を説明するうえで重要かを知るための、指標の一つとして「重要度」を計算することが可能である。「重要度」とは特徴量での分割が目的変数の分類にどれくらい寄与するかを意味している。

ランダムフォレストでの重要とされる特徴量上位 30 個を図表 47 に示した。異なる 5 個の初期値を与えた際の平均の結果を用いた。図表 47 の 30 個で重要特徴量の 86.5%を占めている。「5-3 日常の意思決定」「2-4 食事摂取」が突出しており、上位 10 個の特徴量で重要度が 58.5%を占めており、これらが、決定木での最

上部の分岐を構成している。

図表 47 ランダムフォレストモデルでの重要度での上位 30 個の特徴量



ランダムフォレストモデルと樹形モデルでの重視される状態像の比較結果を図表 48 に示す。8 種類の樹形モデルに対して第 3 番目までの分岐で使用された回答項目と中間評価得点の項目を対象としている。どちらのモデルも第 2 群の項目を重視している一方で、ランダムフォレストモデルでは第 5 群の「日常の意思決定」と「集団への不適応」を樹形モデルより重視しているという違いが見られた。両者のモデルは分岐を繰り返すという共通の構造を持つものの、各分岐では異なる判定ロジックで介護時間を推定していることが考えられる。

図表 48 ランダムフォレストモデルと樹形モデルでの重視される状態像の比較

群	項目	ランダムフォレスト (上位 30 個)	樹形モデル(第 3 分岐まで)
第 1 群	身体機能・起居動作	23.3%	27.6%
第 2 群	生活機能	40.0%	44.8%
第 3 群	認知機能	6.7%	13.8%
第 4 群	精神・行動障害	20.0%	13.8%
第 5 群	社会生活への適応	6.7%	0.0%
その他	その他	3.3%	0.0%



## ②機械学習モデルにおける推定の改善検証

施設調査結果を職員観点から整理・集計した結果を図表 20～22 に示す。

3-(3)-①にて選択した機械学習モデルを初期モデルとして検証を行い、初期モデルの改善を行った。今回の検証対象が少数データであることを踏まえて、改善効果が期待される汎用的な手法として、以下（ア）～（カ）に示す 6 個の改善施策の検証を行う。これらの改善施策は機械学習モデルのいずれに対しても効果が期待し得るが、樹形モデルに関してはルールベースのモデルであるため改善検証の対象とはしないことに留意いただきたい。

- （ア）層化抽出法の実施
- （イ）オーバーサンプリングの実施
- （ウ）新規特徴量の作成
- （エ）ケアコード大分類毎にサブモデル化
- （オ）類型状態像毎にサブモデル化
- （カ）ハイパーパラメータ調整

樹形モデルとランダムフォレストでの違いが生じた要因としてデータ側の要素とモデル側の要素の 2 種類がある。データ側の違いとして令和 3 年度の調査はサンプル数が 194 と少なく、特にケア時間が長いサンプル数が少ない。このような不均衡性を持つデータへの対応として検証（ア）・（イ）を行った。モデル側の違いとしてランダムフォレストモデルは樹形モデルのように複数の推定の組み合わせを行っておらず、状態像から 1 日当たりの合計ケア時間の推定を行った。そのため、ランダムフォレストモデルでは「2-4 食事摂取」や「2-6 移動」、「2-8 洗顔」、「2-9 整髪」といった大分類に対応している特徴量を上位の分岐で使用しているものと考えられた。

樹形モデルのように推定を細分化することで、より適した状態像とケア時間の表現が行える可能性がある。そこで、検証（エ）・（オ）ではそれぞれのケア行為や典型的な状態像に対しての推定モデルの構築を行った。（ウ）の新規特徴量作成と（カ）のハイパーパラメータ調整は機械学習での推定改善の汎用的な手法であるため、それぞれ効果検証を行った。

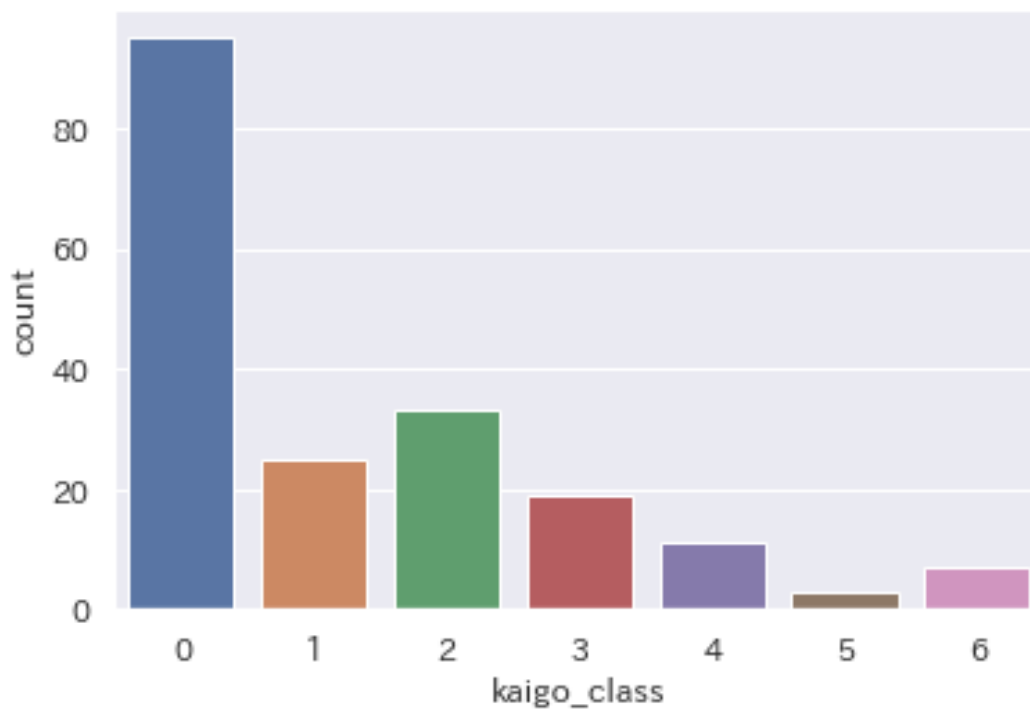
### （ア）層化抽出法の検証

層化抽出法とは異なるクラス（要介護度や介護時間などで分類されたデータの類型群）ごとの偏りを減らすような抽出法である。機械学習モデルでの学習用データを選ぶ際に各クラスに対して無作為抽出を行うことで、学習の際に用いる訓練データとテストデータ同士での不均一性が減少することが期待される。層化抽出を行うにあたって、データに何らかのクラスを付与する必要があるが、推定の目的はケア行為に必要な時間を予測することにあるため、目的変数のケア時間を以下の 2 つ


の方法でクラス分類を行った。

一つ目が要介護認定で用いる介護認定等基準時間で分類したもので、元のデータのケア時間の分布が図表 12 に対して要介護度に相当する 7 クラスに分類したものが図表 49 である。2 つ目がスタージェスの公式 ( $n$  をサンプル数、 $k$  を階級数として  $k=1+\log_2 n$ ) による統計学的に定まったクラス分類である。図表 50 にデータの分布を示した。

図表 49 介護認定等基準時間でクラス分けしたデータの分布



図表 50 ステージェスの公式でクラス分けしたデータの分布



この 2 つのクラス分類に基づいて層化抽出を行いランダムフォレストモデルでの交差検証を実施した結果を図表 51 に示した。前節で検証したランダムフォレストモデルではデータを無作為に選んで学習を行ったのに対して、層化抽出を行った場合の精度が決定係数で 0.244 から介護認定等基準時間でのクラス分類で 0.337、ステージスの公式でのクラス分類で 0.295 といずれも初期モデルからの改善が見られた。

図表 51 無作為抽出と層化抽出での推定結果（決定係数）

交差検証項目	1 回目	2 回目	3 回目	4 回目	平均
無作為抽出	0.228	0.377	0.129	0.241	0.244
層化抽出 基準時間	0.308	0.277	0.503	0.259	0.337
層化抽出 ステージェス	0.175	0.307	0.386	0.312	0.295

交差検証によってもっとも決定係数が高かった介護認定等基準時間での層化抽出法を用いて、テストデータに対する決定係数と正答率の結果を図表 52 に示した。決定係数、正答率ともに改善が見られており、層化抽出によって、不正解だったサンプルがより正解のクラスに近い分類がなされたと解釈できる。

図表 52 層化抽出法を行った際の推定精度比較（テストデータ）


実施前（決定係数）	層化抽出法（決定係数）	実施前（正答率）	層化抽出法（正答率）
0.523	0.525	0.436	0.538

（イ） オーバーサンプリングの検証

サンプルにおける後述するクラスごとの数が均等になるように、少数派クラス内で近接点から k 個の点を選び平均値を用いることで、データのオーバーサンプリングを行った。

元のデータのケア時間分布に対して 60 分未満、60 分以上 90 分未満、90 以上の 3 つのクラスに分けた際に各クラスでのデータ数を均等になるようにオーバーサンプリングを実施した際のケア時間分布の様子を図表 53 に示した。

図表 53 元データ実測ケア時間分布とオーバーサンプリング後の時間分布



オーバーサンプリング法を行った際の推定精度を図表 54 に示した。決定係数、正答率共に精度の低下が見られた実施前よりも、テストデータへの推定は改善しておらず、学習データへの過学習の状態が見られる。

学習に用いる疑似データを作成したことで、学習済みモデルがオーバーサンプリング法を施したデータへ過度に適合するという過学習が起きていると考えられる。

今回のようなケア時間の不均衡性を持つデータに適した手法として「オーバーサンプリング法」の逆の多数派データを縮減する「アンダーサンプリング法」が存在する。「アンダーサンプリング法」であれば、過学習のリスクはないものの多数のデータを学習から除く必要があり、今回のデータ数では学習が困難と判断して検証からは除外した。「アンダーサンプリング法」、「オーバーサンプリング法」はいずれも不均衡な

データに対して汎用的手法であるが、今回の調査結果に関しては精度改善の効果が無いという結果となった。

図表 54 オーバーサンプリングを行った際の推定精度比較（テストデータ）

実施前（決定係数）	オーバーサンプリング （決定係数）	実施前（正答率）	オーバーサンプリング （正答率）
0.523	0.452	0.436	0.436

（ウ）新規特徴量作成の検証

5種類の間接項目得点(0~100)を新規特徴量として加えた際の結果が以下の図表 55 である。交差検証を4分割で行った際の各検証の結果と平均を示している。無作為抽出での中間項目得点の有無を比較した結果、特徴量の追加の精度向上の効果は薄いことが分かった。また、層化抽出の学習においては過学習の傾向が見られ精度が低下した。これはすでにランダムフォレストモデルで中間項目得点に類する構造を学習しており、中間項目得点が特徴量として不要であった可能性が示唆される。

図表 55 中間項目得点を特徴量に加えた際の推定結果

交差検証項目	1回目	2回目	3回目	4回目	平均
初期モデル（無作為抽出）	0.228	0.377	0.129	0.241	0.244
中間項目得点追加（無作為抽出）	0.238	0.397	0.168	0.249	0.263
中間項目得点追加（基準時間）	0.291	0.297	0.524	0.162	0.319
中間項目得点追加（スタージェス）	0.006	0.377	0.385	0.304	0.268

ランダムフォレストモデルで重要特徴量とされた上位5つの「5-3 日常の意思決定」、「2-4 食事摂取」、「4-6 大声を出すこと」、「5-4 集団への不適応」、「2-2 移動」を同回答項目の積を新規特徴量として使用した際の結果を図表 56 に示す。無作為抽出に対して交互作用項を新規特徴量に加えたことで改善が見られたが、層化抽出法と組み合わせた際の精度改善は見られず過学習の傾向を示した。

図表 56 交互作用項を特徴量に加えた際の推定結果

交差検証項目	1回目	2回目	3回目	4回目	平均
初期モデル（無作為抽出）	0.228	0.377	0.129	0.241	0.244
交互作用項追加（無作為抽出）	0.126	0.399	0.265	0.238	0.257

交互作用項追加（基準時間）	0.258	0.262	0.549	0.266	0.334
交互作用項追加（ステージス）	0.078	0.351	0.387	0.346	0.291

樹形モデルでは使用していなかった入所者の「年齢」の項目を追加した。改善施策適用の前後での正答率を図表 57 に示した。「年齢」単体では精度改善は見られなかったが、交互作用項と組み合わせることで改善がみられた。

図表 57 年齢を特徴量に加えた際の推定結果

交差検証項目	1 回目	2 回目	3 回目	4 回目	平均
初期モデル（無作為抽出）	0.228	0.377	0.129	0.241	0.244
年齢追加（無作為抽出）	0.234	0.411	0.096	0.222	0.241
年齢追加（基準時間）	0.343	0.396	0.516	0.335	0.397
年齢追加（ステージス）	0.229	0.398	0.422	0.375	0.356
年齢・交互作用項追加（基準時間）	0.381	0.369	0.545	0.383	0.420
年齢・交互作用項追加（ステージス）	0.233	0.453	0.415	0.430	0.383

新規特徴量の追加のうち、最も交差検証における精度の高かった介護認定基準時間による層化抽出を行って年齢と交互作用項を特徴量に加えたモデルでテストデータに対して推定を実施し、改善施策前後での精度比較を図表 58 に示した。テストデータに対しては大幅な悪化はしていないものの、改善は見られなかった。

図表 58 特徴量追加を行った際の推定精度比較（テストデータ）

実施前（決定係数）	年齢・交互作用項追加（決定係数）	実施前（正答率）	年齢・交互作用項追加（正答率）
0.523	0.501	0.436	0.436

(エ) ケアコード大分類毎のサブモデル化の検証

樹形モデルでは状態像をもとに、一日の複数のケア行為にかかる時間を合算した

時間の推定を行っていた。そのため、各ケア行為（食事や移動、排泄など）にかかる時間を推定はできないという問題があった。そこで樹形モデルでの各ケア行為の推定を行うという形式を機械学習モデルにも活用することで各ケア行為に必要とされる時間を推定するために、ケア行為ごとのモデルを複数作成するサブモデル化を行い、交差検証の結果を図表 59、改善施策適用の前後での正答率を図表 60 に示した。

ここでは、樹形モデルと同様に推定するケア行為の単位として、ケアコード上の 8 個の大分類単位を使用した(入浴・清潔保持、移動・移乗・体位交換、食事、排泄、生活自立支援、行動上の問題、医療、機能訓練)。ただし、社会生活支援に関してはデータ数が 10 個と限られるため推定対象から除外した。

モデルの最適化手法としてケアコード大分類別のサブモデルを作成したところ、正答率、決定係数ともに推定精度の改善が見られた。改善前の初期モデルではケア行為を合算した 1 日当たりの介護時間の推定を行っていた。個々のケアに対応した最適なモデルを複数組み合わせた結果、推定精度の改善に寄与したと考えられる。

理想的にはケアコード中分類の単位でサブモデルを作成することが可能だが、今回の令和 3 年度調査では、ケア回数が限定されデータ量が学習に不十分であるため、大分類単位でのサブモデル化を試みた。

図表 59 ケアコード大分類毎のサブモデル化の推定結果

交差検証項目	1 回目	2 回目	3 回目	4 回目	平均
初期モデル（無作為抽出）	0.441	0.317	0.57	0.168	0.374
大分類毎サブモデル化（無作為抽出）	0.361	0.444	0.573	0.131	0.377
大分類毎サブモデル化（基準時間）	0.537	0.439	0.714	0.469	0.540

図表 60 ケアコード大分類毎のサブモデル化を行った際の推定精度比較（テストデータ）


実施前（決定係数）	大分類毎サブモデル化（決定係数）	実施前（正答率）	大分類毎サブモデル化（正答率）
0.523	0.534	0.436	0.487

(オ) 類型状態像毎のサブモデル化のサブモデル化の検証

入所者の状態像に近いもの同士を、各入所者の状態像を二次元で表現した後も近くなるような次元削減手法を用いて表示した（図表 61）。カラーバーの色はスターリングの公式で実際のケア時間を 8 種類に分類したものに対応する。右側にケア時間が短

いもの、左側にケア時間が長いものが位置する傾向が見られる。

図表 61 状態像を2次元上で表現した際のケア時間ごとのデータ分布



入所者の状態像を二次元で表現したものに対し、クラスタリングを行うことで状態像が比較的似た入所者同士のグループを作成した。そのグループごとに推定し、交差検証を行った結果を図表 62 に示した。

無作為抽出の場合、精度が悪化する。これはクラスターごとのモデル化を行う際に学習データが減少し、検証用データとの偏りが発生したことが原因と考えられる。層化抽出と組み合わせた場合も層化抽出単体で行った以上の改善は見られなかった。

テストデータに対する推定結果を図表 63 に示す。決定係数、正答率ともに精度が悪化する傾向となった。

図表 62 状態像類型別のサブモデル化の推定結果

交差検証項目	1 回目	2 回目	3 回目	4 回目	平均
初期モデル（無作為抽出）	0.317	0.515	0.241	0.440	0.358
状態像類型別サブモデル化（無作為抽出）	0.238	0.420	0.279	0.394	0.411




状態像類型別サブモデル化（基準時間）	0.477	0.421	0.387	0.450	0.333
--------------------	-------	-------	-------	-------	-------

図表 63 状態像類型別のサブモデル化を行った際の推定精度比較（テストデータ）

実施前（決定係数）	状態像類型別サブモデル化（決定係数）	実施前（正答率）	状態像類型別サブモデル化（正答率）
0.523	0.416	0.436	0.41

層化抽出を行ったデータに対してサブモデル化を行う際のクラスターの分割数の推定精度への影響を調べたものが図表 64 である。類型状態像ごとのサブモデル化の効果が見られず、クラスター数が増加するほど、正答率が減少している。

図表 64 データ分割のクラスタリング数と推定精度（正答率）の関係



類型状態像に対してのサブモデル化での改善は見られなかった。類型状態像はクラスタリングの手法を用いて状態像を複数のグループ(クラスター)に分離して、それぞれの類型状態像を作成した。

しかしながら、同じグループ内においても実際のケア時間が異なる入居者が含まれており、今回の調査結果では状態像のクラスタリングが上手く行えなかった。クラスタリングにおいてケア時間に応じた分離が行える場合であれば、それぞれのグループごとの最適化されたモデルを作成することは有効であるが、今回の調査においてはデータの性質に適しない結果となった。

#### (カ) 改善手法の最適な組み合わせおよびハイパーパラメータ調整の検証

ランダムフォレストモデルではデータから定まるパラメータの他にハイパーパラメータと呼ばれる外部パラメータが存在する。ハイパーパラメータとして例えば、「分岐の深さ」「最小分割数」「推定器の個数」などが挙げられる。初期モデルではデフォルト値を用いて学習を行ったため、状態像とデータの特性に合わせたパラメータの調整を行うことで精度改善が期待される。

ハイパーパラメータ調整においては、ランダムフォレストモデルでの決定木の個数と決定木の深さ、個々の決定木に使用する特徴量の数に関しての調整を行った。ハイパーパラメータ調整はサブモデルなどの複数のモデルにそれぞれ適応可能であるため、各改善施策の組み合わせで推定精度が良かったものを対象に、最終的なモデル最適化に用いることを目的にした。

最も推定精度の高かった組み合わせは改善施策単体でも効果のあった、改善施策「層化抽出法」と「新規特徴量作成」と「ケアコード大分類毎のサブモデル化」の組み合わせに対して、ハイパーパラメータ調整を適応した結果であり、その結果を図表 65 に示した。なお、改善施策の組み合わせにおける推定精度の比較においては、要介護基準時間のクラス当てはまりの度合いではなく、より詳細に正解データにどれだけ推定全体として近づいたかを比較するため、決定係数を指標とした。

図表 65 改善施策組み合わせの推定結果 (テストデータ)

実施前 (決定係数)	改善結果組み合わせ (決定係数)
0.523	0.675

#### ③状態像調査結果及びタイムスタディ結果の関係性を表現するモデルの探索結果のまとめ

令和3年度調査結果に対して、機械学習モデルにより比較的精度高く推定することができた。しかしながら、機械学習モデルで最も精度が高いランダムフォレストモデルであっても、要介護度基準で要介護4以上に当たる、介護時間が90分以上のクラスに関しての推定には失敗していた。ランダムフォレストモデルで実際の介護時間が90分以上のサンプルは全て90分以下と推定されており、過小評価が行われていた。この原因としては、大きく学習のデータの問題と推定モデルの問題の2種類の要因がある。

まずデータ側の誤差の要因として、今回の調査におけるデータ数が194サンプルと少数でありモデルが学習するには不十分であることが挙げられる。特に推定に失敗している90分以上のサンプル数が11で全体の5%と限られており、介護時間が長い入

居者の特徴をとらえることが難しくなっている。さらに、学習データへの依存性が強く、データの分割を無作為に行うと、学習とテストデータで少数クラスの偏りが生じるという問題が生じる。このデータの課題に対して改善策として3-(3)-②にて検証を行った。「層化抽出法」と「新規特徴量作成」に関しては一定の改善効果が見られた。

次にモデル側の誤差の要因として、モデル間比較に用いた機械学習モデルが今回の状態像と介護時間に対して最適化されておらず、モデルの推定能力を十分に発揮できていないことが挙げられる。これらの課題を解決するために二つのサブモデル化とハイパーパラメータ調整を試みた。「ケア行為に関するサブモデル化」と「ハイパーパラメータ調整」によって推定精度の改善が見られた。

今回個別に改善効果が見られた「層化抽出法」、「新規特徴量」、「ケア行為に関する（ケアコード大分類別）サブモデル化」、「ハイパーパラメータ調整」を組み合わせることでランダムフォレストモデルにおいて最も高い推定精度が得られた。特に効果が大きい「層化抽出法」と「ケア行為に関するサブモデル化」がそれぞれケア時間の短いクラスと長いクラスの改善に影響するために、効果が重複せず組み合わせにより全体の精度改善が可能となった。

#### (4) タイムスタディにおける AI 活用可能性検証

ケアコード推定を行うにあたり、目視にかかる時間が長く、かつ認識すべきケアが多いケアコードの識別が一部 AI 化できればタイムスタディ効率化に繋がる想定のもと、ケアコードを類型化し、優先して推定を行うケアコードの選定を行った。

評価対象のケアコードを選定するにあたって考慮したケア行為の特徴を以下に示す。なお、選定にあたりケア名に「その他」、「など」を含むケアは除いた。

- ・ケア提供時間が長いケアコード

一日あたりのケア提供時間の累計が一日あたり総ケア提供時間の 90%を占めるケアコード

- ・ケア内容が多いケアコード

より詳細なケア内容を示す小分類のケアが 5 種類あるケアコード

上記を満たす入浴、口腔・耳ケア、更衣、敷地内の移動、移乗、摂食、水分摂取、排泄（排便・排尿合計）、目覚まし・寝かしつけ、薬剤の使用の 10 のケアと排便との区別を図るため排尿のケアを加えた計 11 種類のケアを優先して推定すべき対象とした。

#### ①一般物体認識 AI による認識対象

「2-(2)-④-(ア) 一般物体認識 AI による認識範囲の拡充」に記述の観点で、令和 3 年度事業で認識対象とした物品に加え、各ケアに特有であり新たな認識対象とすべき物品候補として歯ブラシ、入れ歯、靴下、錠剤を選定した。また、各ケアの判定のた

めに認識結果を用いる物品としてコップ、スプーン、車いすを令和3年度に認識対象とした情報に加えて選定した。(図表 66)

図表 66 各ケアコードで認識対象とする情報

コード	内容	認識対象とした情報 (令和3年度)	新たに認識する物品候補	ケア判定に用いる追加物品候補
11	入浴	音声：お風呂、脱衣所	-	-
15	口腔・耳ケア	音声：入れ歯、ぶくぶくペー 物体：シンク、蛇口、チューブ入り 商品	歯ブラシ、入れ歯	コップ
18	更衣	-	靴下	-
21	敷地内の移動	物体：車いす	-	-
22	移乗	物体：ベッド、ベビーベッド	-	車いす
34	摂食	音声：ご飯 物体：食べ物	-	-
35	水分摂取	音声：お茶、水、飲み物	-	コップ
41	排尿	音声：おしっこ、トイレ、お手洗い	-	-
42	排便	音声：排泄、トイレ、オムツ	-	-
57	目覚まし、寝かしつけ	音声：おはようございます、起きま しょう、起きてください 物体：ベッド、ベビーベッド、枕	-	-
81	薬剤の使用	音声：薬、点滴 物体：食べ物	錠剤	スプーン

(ア) 新たに認識対象とした物品の初期認識結果

新たに認識対象とした、歯ブラシ、入れ歯、靴下、錠剤の4つの物品の学習にあたっては、各物品単体の画像に加え、タイムスタディで収集したケア動画から実際の介護現場における対象の物品の画像データを用いて、一般物体認識 AI を構築した。

なお、一般物体認識 AI は新規の映像における対象の物品を認識する前提のもと、一般物体認識 AI の認識精度の検証用動画には、物品の認識のための学習に用いていない動画を選定した。検証用動画の中で対象の物品を認識した結果を図表 67 に示した。図表 67 の列に記載の①～③はそれぞれ以下を示す。

- ①：検証用ケア動画の中で該当物品が視認できた動画数
  - ②：①のうち該当物品を AI で認識できた動画数
  - ③：検証用ケア動画の中で該当物品と誤検出された物品の数
- 誤検出が見られたケースがあるものの、多くの場合で該当物品に関して認識漏れが少ない結果となった。

図表 67 一般物体認識 AI による認識結果

物品	①	②	③	誤検出例
歯ブラシ	4 動画	4 動画	0 個	-
入れ歯	3 動画	3 動画	1 個	毛布のリボンの柄
靴下	7 動画	5 動画	4 個	衣類の一部など
錠剤	7 動画	6 動画	9 個	衣類の白い模様など

歯ブラシの認識結果例を図表 68 に示す。口腔・耳ケアの検証対象の動画においては、歯ブラシを用いたすべてのケアについて歯ブラシを認識することができ、他の物を誤って歯ブラシと検出してしまうこともなかった。

図表 68 歯ブラシを正しく認識できた例



入れ歯の認識結果例を図表 69 に示す。口腔・耳ケアの検証対象の動画においては、入れ歯を用いたすべてのケアについて入れ歯を認識することができ、誤検出は似た色や形状のものに対して一部あった。

図表 69 入れ歯を正しく認識できた例



図表 70 入れ歯を正しく認識できなかった例



靴下の認識結果例を図表 71 に示す。更衣の検証対象の動画においては、靴下や靴の着脱があったケアの靴下を概ね正しく認識することができ、誤検出は似た形状のものに対して一部あった。

図表 71 靴下を正しく認識できた例



図表 72 靴下を正しく認識できなかった例




錠剤の認識結果例を図表 73 に示す。薬剤の使用の検証対象の動画においては、錠剤を概ね正しく認識することができ、誤検出は似た形状のものに対して一部あった。

図表 73 錠剤を正しく認識できた例



図表 74 錠剤を正しく認識できなかった例



(イ) 画像データ増加手法による認識精度改善施策と認識結果

「2-(2)-④-(ア)一般物体認識 AI による認識範囲の拡充」に記述の認識対象の誤検出の改善のため、学習に用いた画像データの増加を実施した。

物品の認識結果より、物体の誤検出は色や形が似ているものに対してノイズや明るさの加減によって一部発生する傾向があることが分かった。そのため、本来認識すべき物品と認識すべきではない物品の違いを学習させるため、画像データ増加手法には学習用画像のコントラスト変更とノイズ付加を実施した。それぞれの手法の詳細と検証結果を以下に示す。

コントラスト変更：

入れ歯、靴下、錠剤を対象に、元画像からコントラスト（画像の明るい部分と暗い部分の差）を強くした画像の追加と弱くした画像の追加の 2 パターンで検証した。入れ歯・錠剤や以前の誤検出がなくなった一方、別の物体を誤検出し、靴下は認識漏れ、誤検出ともに精度が低下するなど認識精度の改善は見られなかった。

ノイズ付加：

靴下、錠剤を対象に、正規分布に従ってランダムに発生するガウシアンノイズを利用し画像にノイズを生成したものを追加し、検証した。コントラスト変更の手法と同様、靴下においては認識漏れ、誤検出ともに精度が低下するといった結果になったが、錠剤においては検証用ケア動画における誤検出の物品数が 9 個から 6 個に減少するといった改善が見られた。

## ②ケア行為推定モデルの構築

---

### (ア) 初期モデルの推定結果

11 種類のケアコードのケア動画（計 107 動画）を検証対象に、各ケアコードから 2 動画ずつ推定対象として選定し、それ以外の動画情報を学習データとして用いてケアコードごとに推定を実施した初期モデルの推定結果を以下に示す。

分類に用いるアルゴリズムにおいて推定結果の解釈性を重視して選定した「ロジスティック回帰」、「ランダムフォレスト」、「勾配ブースティング」、「サポートベクターマシン（分類）」のうち、最も精度が高かったのはロジスティック回帰で（正答率 59.1%）、次いでランダムフォレスト（正答率 50.0%）であった。以下に示す推定結果はロジスティック回帰による推定結果である。

また説明変数には、各ケア動画における認識対象の物体と音声の認識回数を用いた。歯ブラシや靴下など、今回新たに認識対象とした物品の情報を用いたケアについては精度高く推定する一方、車いすやベッドが多く登場するなど物品の種類や頻度に共通点があるケアについてはうまく推定できていなかった。

・ 2 動画とも正しく推定できたケアコード

15. 口腔・耳ケア

18. 更衣



- 34.摂食
- 35.水分摂取
- 57.目覚まし・寝かしつけ
- ・1 動画を正しく推定できたケアコード
  - 11.入浴
  - 21.敷地内の移動
  - 81.薬剤の使用
- ・2 動画とも正しく推定できなかったケアコード
  - 22.移乗
  - 41.排尿
  - 42.排便

#### (イ) ケア行為推定モデルの改善

「3-(4)-②-(ア) 初期モデルの推定」に記述のケア行為推定モデルの改善に向けて、ケア行為推定モデルのインプットとなるデータと分析処理のプロセスの両面で計3つの改善施策の検証を行った。

インプット側の改善としては、各ケア動画の長短による認識回数の差異を軽減させるため、各ケア動画における各物体の認識回数を60秒における認識回数に換算(図表75:改善施策①)した。加えて、改善施策①で変換した、物品ごとの認識回数をカテゴリ変数化して学習させた(図表75:改善施策②)。なお、カテゴリ数の決定には物品ごとにスタージェスの公式を利用した。改善施策①では全体の推定精度が向上し、改善施策②では全体の推定精度は低下したものの、一部改善したケアコードがあった。また、改善施策②では連続変数の特徴量では認識が難しかった、入浴、排尿、排泄のケアに関してはカテゴリ変数を用いた分類の方が上手く推定できた結果となった。

プロセス側の改善としては、改善仮説①、②による推定を複数の機械学習モデルで実施の上、ケアコードごとに最も推定精度が高いモデルをサブモデルとして選定した。(図表75:改善施策③)

ケアコードごとの推定結果を図表75に示し、各改善施策の正答率を図表76に示した。図表75において、○は2つとも正解、△は1つ正解、×は正解なしを表す。各改善施策の実行により、初期モデルでは推定が難しかったケアの推定精度が改善した。また、ケアコードごとに最も推定がうまくいったモデルによる推定結果を優先することにより、全体で77.3%の正答率の推定結果となった。

図表 75 機械学習モデルによるケア行為推定結果

コード	内容	初期モデル (ロジスティック回帰)	改善施策① (ロジスティック回帰)	改善施策① (ランダムフォレスト)	改善施策② (ロジスティック回帰)	改善施策② (ランダムフォレスト)	改善施策③ (複数サブモデル)
11	入浴	△	△	×	○	○	○
15	口腔・耳ケア	○	○	△	×	×	○
18	更衣	○	○	○	×	×	○
21	敷地内の移動	△	△	△	×	×	△
22	移乗	×	×	×	×	×	×
34	摂食	○	○	○	△	△	○
35	水分摂取	○	○	○	△	○	○
41	排尿	×	×	×	△	△	△
42	排便	×	△	×	△	○	○
57	目覚まし、寝かしつけ	○	○	○	△	○	○
81	薬剤の使用	△	△	×	△	×	△

図表 76 機械学習モデルによる推定精度（正答率）

	初期モデル (ロジスティック回帰)	改善施策① (ロジスティック回帰)	改善施策① (ランダムフォレスト)	改善施策② (ロジスティック回帰)	改善施策② (ランダムフォレスト)	改善施策③ (複数サブモデル)
正答数	13	14	10	8	10	17
正答率	59.1%	63.6%	45.5%	36.4%	45.5%	77.3%

### ③ケア行為推定対象の拡張可能性検証

#### (ア) 検証対象のケアコードの選定

「3-(4)-① 一般物体認識 AI による認識対象」で選定した 11 種類のケアコード以外のケアコードのうち、ケア提供時間が長く（上位 3 位の 70.0 分）、かつケア内容が多く（ケアコード小分類の数が 5）、そのうちケア提供人数が最も多い（35 名）ケアである、「71 行動上の問題の発生時の対応」をケア行為推定可能性の検証対象とした。

## (イ) AIによる認識対象とする情報の選定

入所者に対するケア行為には、歯磨きなどの直接的なケア行為と他者とのコミュニケーションが発生するケア行為の大きく2つがあると考えられる。直接的なケア行為によって説明できるケアコードだけでなく、BPSD 関連行動に対するケアのような、他者とのコミュニケーションも含めることで説明できるケアコードもあると考えられ、検証対象とした「行動上の問題の発生時の対応」に関しては、後者に該当すると想定した。

コミュニケーションの状態を決めるには心理状態や認知の状態があるが、その状態はコミュニケーションで用いられている物品の有無を確認することで推定が可能であるという想定の下、「行動上の問題の発生時の対応」の推定にあたってはBPSDの対応で一般に用いられると考えられる物品を認識対象とした。

BPSD への療法として代表的なものとして、非薬物療法がある。介護施設で実施されるものとしては認知機能訓練、認知刺激、運動療法、音楽療法、回想法、ドールセラピー、園芸療法などが挙げられるが、そのうち集団で共通で実施されるのではなく、入所者個人とのコミュニケーションが多く実施されるものとして回想法、ドールセラピー、園芸療法を想定し、そこで用いられると考えられる以下の物品を調査対象候補とした。

### ・代表的な療法と調査対象候補物品

回想法：思い出深い過去の写真

ドールセラピー：ぬいぐるみ

園芸療法：観葉植物（花・植物）

なお、今回の検証においては、調査対象の物品において、物品の特徴がある程度共通した物品を用いてその物品の有無の情報を用いた推定を行う想定をした。そのため、入所者の思い出の写真に関しては、被写体が配偶者や子供・孫、あるいは風景など個々人によって多様であり、今回の調査対象においては類型化された傾向の写真はほとんど存在しないと考えられるため、認識対象として写真を除いたぬいぐるみと観葉植物の2点を選定し、一般物体認識AIによる学習を行った。

## (ウ) 対象の物品の認識結果

各入所者に用いられる物品を明確化するため、入所者の居室やベッド周辺などパーソナルスペースにある物品は入所者個人に対して用いられているという想定のもと、各入所者の部屋やベッド周辺で行われるケアのうち、もっともケア提供人数（139名）の多かった「57目覚まし・寝かしつけ」のケアを対象にぬいぐるみと観葉植物の有無とAIの認識の検証を行った。

「57目覚まし・寝かしつけ」のケア動画より、ぬいぐるみに関しては139名の

うち 11 名において、観葉植物に関しては 5 名において、ケア対象の入所者のパーソナルスペースに置かれていたことがわかった。

AI による認識の結果、ぬいぐるみについては 11 名中 8 名、観葉植物については 5 名全員について正しく認識することができ、ケア行為推定に向けて比較的精度高く認識できることがわかった。

## 4. まとめ（考察）

### （1）令和3年度調査におけるケアの特徴について

施設観点でのケア時間変化の影響要因分析の実施結果から、令和3年度調査におけるケアにおいて特徴的な傾向が見られた。

「3-(1)-① ICT の活用有無における平均ケア時間の比較」では、介護ロボットや見守りセンサーの活用などのテクノロジー活用施設の方が要介護1,2の入所者においてケア時間が短い傾向が確認できた。このことから、比較的要介護度が低い入所者へのケアに関して、テクノロジーで代替できるケアの割合が大きく、介護ロボット・センサー等活用のケア時間短縮への影響が強くなると考えられる。

また、介護経験の5年以上のスタッフの方がどの要介護度においてもケア時間が長い傾向が見られ、介護経験が長いスタッフほど丁寧な介護をする、入所者の自立支援のためにあえてサポートの範囲を制限している、などといったことが推察できた。

「3-(1)-③ ケアコード中分類別平均ケア時間比較」では、入所者単位で平均ケア時間を比較した際と同様の傾向がケアコード単位でも見られ、ケア時間が短いケースが多いのは職員負担軽減のテクノロジーを活用している施設であり、テクノロジーを活用施設では大分類2の「移動・移乗・体位交換」に属するケアや「57 目覚まし・寝かしつけ」のケアが短い傾向が目立ち、介護ロボットや見守りセンサーの活用などにより、ケアを効率化できていると推察された。記録・報告様式の工夫を満たす施設では、特に要介護1,2と要介護3～5の入所者の両方で「34 摂食」、「35 水分摂取」、「81 薬剤の使用」の3つのケアにおいてケア時間が長く、各入所者の食事や処方薬・水分摂取のタイミングや方法等、電子上に保存された過去の記録を参照することで時間をかけて適切なケアを実施できているのではないかと推察できた。

上述した令和3年度におけるケアの特徴を踏まえ、令和3年度の状態像調査とケア時間の関係性を表現するモデルの在り方の検証を行った。実際の平均ケア時間が平成18年度調査の85.8分から令和3年度調査で47.8分と減少傾向にあった。このような違いに対して、令和3年度の状態像データからどの程度ケア時間を推定し得るのか、また好ましいモデルの在り方は何かという疑問に対して、複数の機械学習手法を適用することで、令和3年度状態像調査結果を表現するモデルの在り方を検証した。

令和3年度の状態像調査とケア時間の関係性を表現するモデルとして、現行モデルとは別のアルゴリズムである機械学習モデルの一定の可能性を示した。その一方で、今回最も精度が高いランダムフォレストモデルであっても、特定のケア行為での推定精度が低いという課題も見られた。これはデータの絶対数の少なさから特定入居者の影響や、調査期間で偶然特定のケア行為が見られなかったなどの確率の影響が可能性として挙げられる。また、今回の協力対象施設内の多様性が高く、テクノロジー活用などの有無によって、類似する状態像であってもケア時間が異なるといった影響も考えられる。しかしながら、調査における入居者のデータ収集の追加を行うことで、非典型的なサンプル

を外れ値として外す判断も可能となりデータにおける平均的な状態像とケア時間の関係がより明瞭になることが期待される。これも踏まえて、機械学習モデルでさらなる推定精度を上げる余地は十分にあると思われる。より高齢者介護の実態に即した細かな推定を可能とする AI 要素技術に関しての今後の発展も期待される。

## (2) タイムスタディ工程への AI 活用可能性検証結果について

タイムスタディ工程における AI 活用可能性評価結果に対する考察を記載する。

「3-(4)-② ケアコード推定モデルの構築」に記述した評価結果から、評価対象としたケアコード 11 個の内、AI 技術を活用することでケア行為の推定が可能であったケアコードが 7 個、一部推定が可能なケアコードが 3 個、推定できなかったケアコードが 1 個であり、今回の検証対象においては、ケア行為の特定の AI 技術による代替可能性が高いことが分かった。

また、物体認識の改善に向けた施策としてデータ増加手法を用い、今回の調査対象においてはノイズ付加を行うことで、錠剤の検出において検証用ケア動画における誤検出の物品数が 9 個から 6 個に減少するといった改善が見られた。

なお、認識対象の物品の誤検出が発生した際の対応としては、認識対象以外の物品の検出を複層的に実施し、その結果の組み合わせからケアにおいて同時に現れるものかどうか、その可能性を判断することで誤検出かどうかを総合的に判定する方法が挙げられる。今回の検証で誤検出のあった入れ歯、靴下、錠剤の物品のそれぞれについて、同時にケアに現れる可能性が低い物品の例を以下に示す。

- ・ 入れ歯：食べ物、錠剤

(食事や薬剤の摂取と入れ歯の着脱を同時に行うケースは少ないと考えられるため。)

- ・ 靴下：食べ物、食卓、シンク、蛇口、錠剤

- ・ 錠剤：入れ歯、靴下

さらに、推定対象の拡張対象として「71 行動上の問題の発生時の対応」のケアについて、コミュニケーションに用いられると想定したぬいぐるみと観葉植物の各物品について、一定の精度で認識でき、推定対象とした 11 種類ケアコード以外にもケア行為推定の AI による代替可能性があることが示された。

## 5. 付録

図表 A 施設情報として収集した主な項目

観点	項目名	概要	帳票名
施設 基本情報	施設 ID	<ul style="list-style-type: none"> <li>介護老人福祉施設、介護老人保健施設、介護療養型医療施設・介護医療の3系統に分けて施設固有の施設 ID を付与</li> <li>タイムスタディ情報との紐づけ可能</li> </ul>	施設調査票
	法人名・施設名	<ul style="list-style-type: none"> <li>同一法人内から複数施設の調査に協力を得られる場合があるため、法人名、施設名の双方を取得</li> </ul>	
入所者 観点	定員・入所者数	<ul style="list-style-type: none"> <li>施設定員、要介護度別の入所者数</li> </ul>	状態像調査票
	調査対象者の 基本情報	<ul style="list-style-type: none"> <li>要介護度、年齢、性別</li> </ul>	
職員観点	職員配置状況	<ul style="list-style-type: none"> <li>管理者、医師、看護職員・介護職員などの職員人数</li> </ul>	施設調査票
	スタッフ ID	<ul style="list-style-type: none"> <li>個人情報保護の観点から、名前などを用いず入所者固有のスタッフ番号を設定</li> <li>スタッフ ID は施設 ID と紐づけ可能</li> </ul>	スタッフ リスト
	職員基本情報	<ul style="list-style-type: none"> <li>年齢、性別</li> </ul>	
	職種	<ul style="list-style-type: none"> <li>介護職、看護職、リハビリスタッフ（理学療法士/作業療法士/言語聴覚士）・管理栄養士・歯科専門職など</li> </ul>	
	勤務年数	<ul style="list-style-type: none"> <li>他施設を含めた勤務年数、当該施設のみの勤務年数</li> </ul>	
施設運営 方針観点	ユニットケアの 実施の有無	<ul style="list-style-type: none"> <li>全面ユニット型、一部ユニット型、ユニット型でないの中から選択</li> </ul>	施設調査票
	介護報酬で算定 している加算	<ul style="list-style-type: none"> <li>夜間職員配置加算、口腔衛生管理加算、認知症専門ケア加算、短期集中リハビリテーション実施加算、在宅復帰支援機能加算など</li> <li>取得した加算を「体制」、「栄養・口腔」、「認知症」、「リハビリ」、「その他（自立支援・在宅復帰）」の5カテゴリに区分して集計</li> </ul>	
	実施している 生産性向上の取 組	<ul style="list-style-type: none"> <li>「職員の負担軽減のためのテクノロジーの活用」、「記録・報告様式の工夫」、「その他」などを設定し、実施有無を確認</li> <li>「職員負担軽減のためのテクノロジーの活用」と「その他」は直接ケアと間接ケア（事務作業）に区分し、具体的な内容を記述</li> </ul>	
	満足度調査の 実施有無	<ul style="list-style-type: none"> <li>従業員満足度調査、利用者満足度調査の実施有無</li> </ul>	

	建物情報	• フロア数、床面積	
--	------	------------	--





令和4年度老人保健健康増進等事業  
高齢者の介護の現状に関する調査事業  
報告書

発行日：令和5年3月

編集・発行：PwC コンサルティング合同会社