

加速度センサデータを用いた看護行動の識別

高木 章裕¹ 木田 竜二¹ 酒井 元気¹

概要：我が国の医療は、高齢者の増加に伴い、患者の病気を「治す医療」から病気の患者を「支える医療」への転換が求められている。「支える医療」では、医療従事者の中でも看護師の数が重要になってくる。しかし、高齢者増加に伴う看護師不足、看護師の身体的多忙と精神面の問題から 2025 年までに国が発表している看護師の就業者数の要求に応えることができないと言われている。このような看護問題に対し、近年人間行動認識技術を応用させ看護行動を認識することによって看護業務支援ツールの開発が行われてきている。そこで、本稿では実際の介護現場で働いている看護師の加速度センサーデータを用いて時間領域での特徴量を算出し、機械学習モデルであるランダムフォレストを用いて、実験室のみのデータ、実験室データと実際の現場データで構成された 2 種類の学習器を作成し、看護行動がどの程度認識可能かどうかを評価することを目的とする。認識目標としている介護現場における全 12 行動の認識結果は学習器 1 では 60.0%、学習器 2 では 55.7%という結果になった。

1. はじめに

我が国は年々人口減少に転じているが、高齢者の数は増え続けている [1]。高齢者の増加に伴い、医療従事者の数がそれに対応しきれていない。高齢者に対応する医療従事者は医者だけでなく看護師もその対象となる。これまでの医療では、「治す医療」が期待されていたが、これからは「支える医療」への転換 [2] が求められている。「支える医療」では看護師が不可欠になってくる。現代における看護師の問題として以下のような問題点が挙げられる。

- 高齢者増加に伴う看護師不足
- 患者とのコミュニケーション
- 看護師の技量の差によっておきる看護サービスの質
- 看護師の身体的多忙と精神面

近年、ウェアラブル機器の発展により人間の行動認識技術が発展してきている。この人間の行動認識技術を利用し、看護行動を認識することによって看護業務支援ツールの開発が行われてきている。

そこで本稿では、はじめになぜ看護行動を認識する必要があるのかについて看護問題に対する背景を述べ、看護行動を認識する目的を明確にする。次に、今回使用したデータセットと認識目標としている看護行動について述べ、使用したデータセットから目標としている看護行動を認識するための学習モデルの作成方法について述べる。最後に、学習モデルを使用した認識結果と結果に対する考察を行い、看護行動認識に対する今後の展望について述べる。

1.1 看護行動を認識する目的

図 1 は平成 29 年に日本看護協会が公開した看護統計資料データ [4] より 2008 年から 2016 年までの各現場で実際に働いている看護師と准看護師の合計人数を棒グラフで表したものである。この結果を参照すると勤務数が右肩上がりとなっており、順調なように思えるが、看護業界の人手不足は深刻化している。その理由は前章で述べた高齢者の数が増加していることと、離職率の高さである。

厚生労働省が発表している 2025 年までに必要になる看護師の人数はおよそ 200 万人と発表している [4]。図 1 より 2016 年での就業者の人数は 156 万人である。今後 3 万人ずつ増加したとしても 2025 年で看護師の就業者数はおよそ 183 万人となり厚生労働省が発表している需要に満たない。

次に、日本看護業界が発表している 2013 年から 2017 年までの病院勤務の看護師の離職率の変化 [5] より熟練看護師と新人看護師の離職率がそれぞれ 10.9%、7.5%となっている。つまり、年々新人看護師が増えるのに対し、熟練看護師が減少しており医療サービスの低下にも繋がっている。看護師が離職してしまう理由について日本医療労働組合連合会が 2017 年に行った看護職員の労働実態調査結果 [6] より看護師の人手不足であることがわかる。

上記の問題を解決するためには、看護業務の効率化を図り、看護師にかかる負担を減らしていくことが重要となる。そこでセンサデータを用いた人間の行動認識技術を看護行動認識に応用させる。行動認識技術は過去多くの報告があり、人間の基本的な行動である「静止」、「歩行」、「走行」

¹ 東京電機大学

について高精度な認識が可能である．本稿で目的としている看護行動認識は前述で述べた人間の基本的な行動が組み合わさった複数行動である．このような複数行動認識が高精度で認識可能になることで看護師の業務記録の自動化が現在可能となってきている．このことから行動認識技術を用いることで現代における看護師の問題を解決できると考える．また，看護師の問題を解決することで他の医療従事者の業務効率上昇につながり，現代医療の求めている「支える医療」の実現が可能となる．

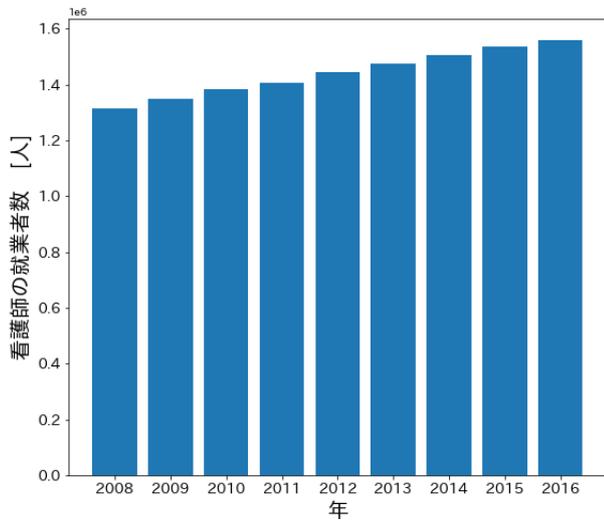


図1 看護師の就業者数

1.2 認識結果を出す目的

看護師の業務を助ける看護業務記録ツールの開発 [8] では病院での看護行動をおよそ 80%以上で認識できるようになって初めて検討できることである．このように看護業務を助けるようなツールの開発には高精度で看護行動が認識できることが必須となってくる．

そこで本稿では，人間の加速度センサを用いて簡単な統計量で作成した学習器でどの程度介護現場での看護行動が認識可能なのかを評価することを目的とし，その結果より今後の看護行動認識方法を検討していく．認識結果を評価するために後に述べる認識目標とした介護現場での 12 行動についてまず，12 行動ではなく大分類 (移動介助，移乗介助，体位交換) でどの程度認識可能であるかを確認するために大分類からさらに細かく分けた各 4 つの行動で交差検証を行い，その検証結果より，大分類と全 12 行動での認識結果を出すことが可能であるかを検討した．

2. 扱ったデータの中身について

本稿で用いたデータセットについて，取得条件や中身である認識目標とする看護行動について述べていく．

2.1 実験室データと現場データ

本稿で用いたデータセットは，実験室データと現場データである．なお，本稿では実験室データを Lab データ，現場データを Field データと呼ぶこととする．以下 Lab データと Field データについて述べていく．

Lab データは日本の九州工業大学びスマートライフケアユニットで収集され実際の現場で働いている 2 人の看護師の加速度データである．センサデバイスとしては，スマートフォンが用いられている．

Field データは，九州にある介護施設で取得された看護師 6 人分の加速度データである．実験室データと同様にセンサデバイスはスマートフォンを用いている．表 1 に Lab データと Field データの概要を示す．

	Lab データ	Field データ
期間	約 3 日間	約 1 ヶ月間
ユーザー数	2 人	6 人
センサデバイス	スマートフォン	スマートフォン
センサデータ	加速度データ	加速度データ

2.2 認識目標とする看護行動

Lab データと Field データは認識目標である看護行動を行ったときの看護師の加速度データで構成されている．以下，認識目標としている看護行動について述べていく．

看護師が介護施設で行う看護行動は大きく分けて 3 つの行動 [7] がある．移動介助は，足腰が不自由で歩行が困難な患者に対応する看護行動である．移乗介助とは患者が車椅子に乗るのを補助する看護行動である．体位交換とは，患者の着替えやベッドのシーツ交換を補助する看護行動である．本稿で，認識目標とするのは表 2 に示したようなこの 3 つの行動について細かく分類した 12 個の看護行動についてである．なお，表 2 の各看護行動名の前に付いている番号は Label 番号である．

移動介助	移乗介助	体位交換
1: 移動手引き (前から)	5: 移乗全介助	9: 側臥位
2: 移動一部介助	6: 移乗一部介助 (前から)	10: 右側臥位
3: 移動歩行器	7: 移乗一部介助 (横から)	11: 臀部の持ち上げ
4: 移動車椅子	8: 移乗一部介助	12: 水平移動

3. 認識結果

本研究では，実験室で取得された Lab データと実際の介護現場で取得された Field データを用いて，Lab データのみで作成した学習器 1 と Lab データと Field データを組み合わせて作成した学習器 2 を作成し，介護現場での主な 12 行動の認識を行った．以下，認識結果を評価するとき用

いる学習器の作成手順と学習器によって得られた12行動の認識結果について述べていく。

3.1 学習器の作成

本稿では、学習器作成において教師あり学習法を用いていく。図2に学習器作成手順を示す。

教師あり学習は学習フェーズと推定フェーズに分かれている。認識したい行動の種類を定義し学習と推定を行っていく。学習フェーズでは正解となる行動ラベルを用いて学習モデルの作成を行う。推定フェーズでは作成した学習モデルを用いて行動を推定していく。以下、図2の流れに沿って学習器作成について述べていく。

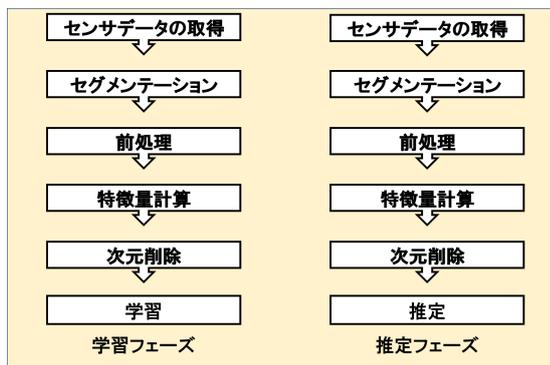


図2 学習器作成手順

3.1.1 センサデータの取得

本稿では、実験室、実際の介護現場で取得した各看護師のセンサデータを使用した。どちらの場所においてもセンサデバイスであるスマートフォンは腕に固定するバンドを利用して左腕に装着されており、各看護師の左腕から取得された加速度センサデータを使用した。

3.1.2 セグメンテーション

セグメンテーションとは、ある特定のデータを取り出すことを言う。本稿では、取得したセンサデータから持続している看護行動データを得ることを指す。以下に、Labデータにおける看護行動抽出方法とFieldデータにおける看護行動抽出方法を述べていく。

Labデータは前章で述べた通り、実験室で得られた加速度センサデータで構成されている。この構成されているデータにはセンサデータとLabelデータが含まれている。Labelデータには実験室における認識目標としている看護行動の時間が示してある。このLabelデータを参考にして図3のような、ある看護行動を行ったときのx軸の加速度センサデータの中から看護行動が持続している箇所(色枠部分)を目視で判断し、センサデータ(各軸の加速度データ)を抽出した。labデータを使って、Fieldデータの改善を目指すため、Labデータではできるだけ認識目標としている看護行動をしている部分だけを抽出するようにした。

Filedデータは実際の現場でのデータのため、認識目標としている看護行動以外の行動が多く含まれていることを考えてLabデータのように目視で抽出する方法は行わなかった。実際の抽出方法は、FieldデータにおけるLabelデータを使用して、Labelデータに示されている時間に即した部分のセンサデータを抽出した。

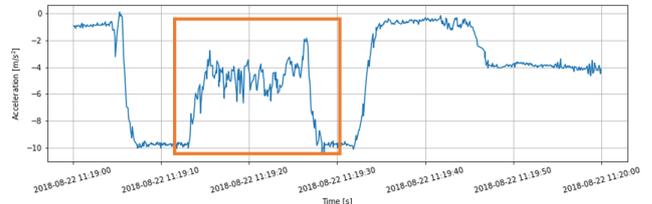


図3 ある看護行動におけるx軸方向の加速度センサデータ

3.1.3 前処理

センサデバイスから得られるデータには多くの場合ノイズや余計な外的要因が多く含まれるので前処理をすることが多い。前処理の方法としては、ノイズや外れ値の除去、単位の変換、正規化、リサンプリングなどの処理がある。このような前処理を行うときには一般性[9]を考慮しておくことが必要である。一般性とは、ある状況下のみで適用できることではなくどんな場合でも行えるという意味である。本稿では、あらかじめ前処理を施したデータを用いているため改めて前処理は行っていない。

3.1.4 特徴量算出

行動認識技術では機械学習を利用して行動を認識していくので、行動データから特徴量を算出する必要がある。本稿では、各軸(x,y,z)の加速度センサデータを用いて時間領域から算出した平均値、分散値、最大値、最小値を特徴量とした。各軸についてそれぞれ特徴量を算出した理由は、看護行動は複数の行動を含む行動データであるため、向きを考慮して特徴量を選択するべきだと考えたからである。

3.1.5 次元削除

特徴量算出において、対象としているデータについて有効性の高いものを選定することが重要である。特徴量が多いからといって高精度な学習モデルができるのではなく有効性の高い特徴量を選定することが機械学習において精度を向上させる方法である。本稿では、次元削除は行わずに各軸の平均値、分散値、最大値、最小値の12次元をそのまま用いた。

3.1.6 学習と推定

学習フェーズでは、機械学習モデルを選ぶ。この選び方は、各データに適したものを選ぶことが重要である。本稿では、RandomForestを選定した。RandomForestはデータセットの中から学習器作成に使うデータをランダムに選択するアルゴリズムを備えているモデルである。本稿で用いているデータは実際の現場でのデータを含むためノイズ

などが含まれていると考えられる。RandomForest を用いることでデータセットのノイズの影響を受けにくくすることが可能となる。また、RandomForest は決定木の数などのパラメータ調整が可能だが本稿ではパラメータの調整は行わずにデフォルトのまま用いた。デフォルトのまま用いた理由としては、本稿で目的としていることが単純な学習器での看護行動認識の結果を得ることだからである。

推定フェーズでは、学習器を用いて未知のデータを認識していく。学習器の目標は未知データに対応することである。本稿では、学習フェーズまでに作成した学習器を用いて後に述べる評価方法を用いて認識目標としている看護行動を推定した。

3.1.7 作成した学習器

現場データの取得時には、データの欠損や識別したい看護行動以外の重複などの問題があり、何かしらの方法を用いて現場データを改善する必要がある。その方法として、理想的な環境で得られた Lab データを用いることで現場データの改善を試みるために Lab データのみで構成された学習器 1 と Lab データと Field データで構成された学習器 2 を作成した。

本稿では、前述のように 2 種類の学習器の作成を行った。両者の学習器は実際の現場で働いている看護師より得られた各軸の加速度センサデータから、各軸の平均値、分散値、最大値、最小値を算出して得られた 12 次元の特徴量で構成されている。

3.2 評価方法

まずは、作成した学習器が未知データに対応できるかどうかを確認するために学習データのみを用いて交差検証を行った。交差検証の方法は学習器 1 と学習器 2 で異なる。学習器 1 の方では、データ数が少ないため交差検証方法として LeaveOneOut 法を用いて、平均値を算出している。学習器 2 の方では交差検証方法として k 分割交差検証を用いて分割数を 5 として 5 回分の検証結果の平均値を算出している。また、未知データに対する汎化性能を評価した後、実際に学習データを 80%、テストデータを 20%に分けて大分類と全 12 行動の混同行列の作成を行った。特徴量の算出及び学習器の実装には python を用いた。

3.3 学習器 1 と学習器 2 の認識結果

3.3.1 学習器 1 での認識結果

学習器 1 は実験室で実際に働いている看護師が行った看護行動データのみで作成された学習器である。以下表 3 に検証結果、学習データ 80%、テストデータ 20%とした大分類と全 12 行動の認識結果及び図 4、図 5 に混同行列を示す。

検証結果より、行動 1,2,3,4 の 4 分類と大分類 (移動介助, 移乗介助, 体位交換) で汎化性能が高いこと、行動

9,10,11,12 の 4 分類で極端に汎化性能が低いことがわかる。検証結果、認識結果、混同行列より現状の学習器の精度を向上させるためには行動 9,10,11,12 の体位交換について分類を考える必要があることがわかる。

認識結果は大分類では 91.7%、全 12 行動では 60.0%という結果を得た。大分類の方では検証結果から予想した通り、高精度での認識が可能であることがわかった。しかし、全 12 行動の分類の方では検証結果から予想できたが 60.0%と低い結果となった。図 5 を参照すると移動介助における行動 3 と 4 に関してはすべて認識できていることがわかる。また、移動介助における各行動と体位交換における各行動の認識が難しいことがわかる。

表 3 学習器 1 における検証結果と認識結果

分類	検証結果	認識結果
行動 1,2,3,4	86.7%	-
行動 5,6,7,8	70.0%	-
行動 9,10,11,12	45.5%	-
大分類	84.6%	91.7%
全 12 行動	62.5%	60.0%

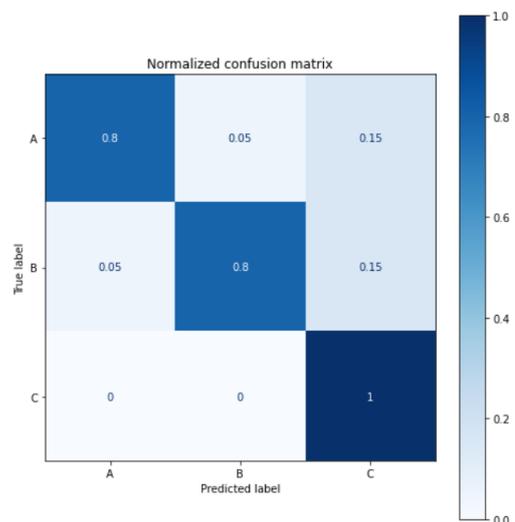


図 4 学習器 1 での混同行列 (大分類)

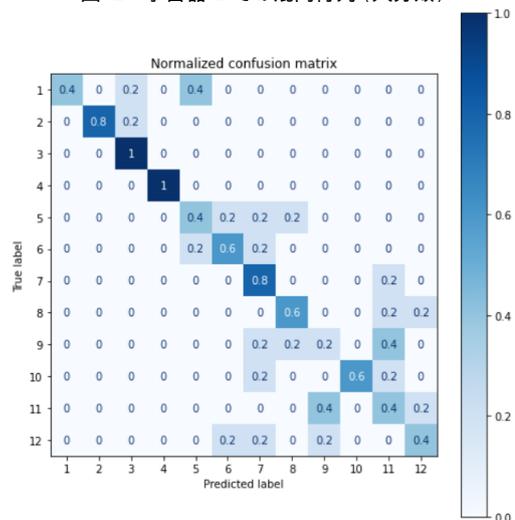


図 5 学習器 1 での混同行列 (全 12 行動)

3.3.2 学習器 2 での認識結果

学習器 2 は実際の現場で働いている看護師が実験室、現場で行った看護行動データで作成された学習器である。以下、表 4 に検証結果、表 5 に学習データ 80%、テストデータ 20%とした大分類と全 12 行動の認識精度及び図 6、図 7 に混同行列を示す。

検証結果より、行動 5,6,7,8 の 4 分類と行動 9,10,11,12 の 4 分類で汎化性能が高いことがわかる。大分類と 12 行動に関しては低い検証結果となった。

認識結果は大分類では、71.9%、全 12 行動では 55.7%となった。また、7 より学習器 1 のときの全 12 行動の認識結果よりも各行動において幅広く誤認識していることがわかる。

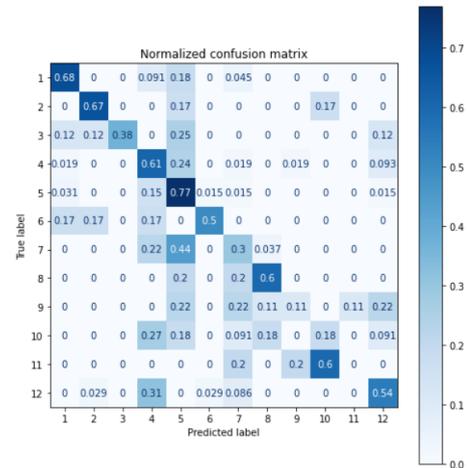


図 7 学習器 2 での混同行列 (全 12 行動)

表 4 学習器 2 での検証結果

分類	1 回目	2 回目	3 回目	4 回目	5 回目	平均
行動 1,2,3,4	51.1%	77.8%	83.3%	82.2%	52.8%	69.5%
行動 5,6,7,8	100%	100%	100%	100%	100%	100%
行動 9,10,11,12	98.3%	84.5%	79.3%	98.3%	72.4%	86.6%
大分類	53.8%	62.8%	68.0%	53.6%	35.7%	54.8%
全 12 行動	32.8%	51.0%	55.3%	47.6%	26.6%	42.7%

表 5 学習器 2 における認識結果

分類	認識精度
大分類	71.9%
全 12 行動	55.7%

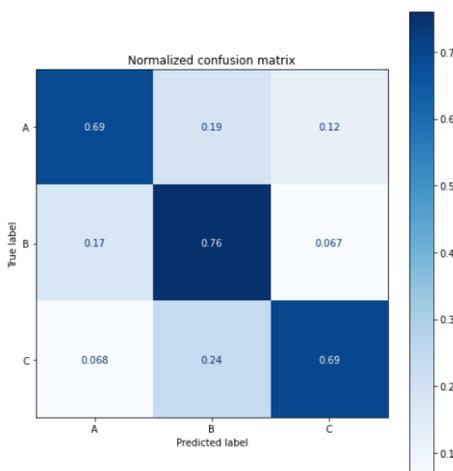


図 6 学習器 2 での混同行列 (大分類)

4. 考察及び今後の展望

本稿では、実際の現場で働いている看護師の加速度センサデータから介護現場における代表的な 12 行動がどの程度認識可能かについて検討した。

Lab データのみで作成した学習器 1 の検証結果を参照すると、大分類における汎化性能は 84.6%と比較的高い精度が出ているため、学習データとテストデータに分けた識別結果においても 91.7%と高い結果を得ることができた。この結果から、大分類 (移動介助, 移乗介助, 体位交換) においては、Field データを補うような学習モデルの作成が可能であることがわかった。

目標としている全 12 行動の識別については、検証結果が 62.5%、識別結果が 60.0%となった。このように精度が落ちてしまった理由としては、体位交換における検証結果の低さによるものだと考えられる。体位交換では、看護行動以外の人間の基本的な行動 (持ち上げる, 下ろす) などが多識別目標としている看護行動と多く遷移していると考えられる。多くの行動が遷移している中から特定の行動を得るためには、その分多くのデータが必要になるが、今回用いている Lab データはユーザー 2 人分のデータなので元々のデータ数が少ない。そのため、体位交換において検証結果が低くなり、全 12 行動の分類に影響を与えたと考える。

Lab データと Field データで構成された学習器 2 の検証結果を参照すると、各大分類における 4 分類においては高い精度で認識できており、行動 5, 6, 7, 8 においては 100%という結果を得ることができている。このことから、各大分類における細かい 4 分類においては Lab データを用いて Field データの改善をすることができると考えられる。

認識結果を参照すると、学習器 1 の方で高精度で認識可能となっていた大分類において 54.8%と低い結果となってしまった。この理由としては、現場では、各看護師が行う行動がその状況に合わせたものとなっており、実験室で行

うような、ある行動を特定の数行うわけではないので、認識目標としている各看護行動データの数に偏りが生じてしまうことが原因として挙げられる。また、実際の現場では認識目標としている看護行動以外の行動データも多く含まれるため全 12 行動の分類においても図 7 のような、各行動において幅広い誤認識を生む結果となってしまったと考察する。

以上本稿では、実験室、実際の現場における加速度センサーデータを用いてどの程度看護行動が認識できるかについて検証を行い、実際の認識結果を評価した。本稿での結果より、目標としている実際の現場での全 12 行動の認識精度を向上させるためには、以下のようなことが必須であることがわかった。

- Lab データのみで構成された学習器 1 の改善
- Field データにおける看護行動抽出方法の改善

本稿で学習器作成に用いた特徴量は、時間領域における平均値、分散値、最大値、最小値のみであったため、周波数領域での特徴量算出も行ってみたいことや、機械学習モデルで用いた RandomForest のパラメータのチューニングなどが挙げられる。これらの改善を施した、学習器 1 を用いることで Field データにおける全 12 行動の認識精度の向上が図れると考える。また、Field データは認識目標とする看護行動データ以外も含まれてしまっているため、Field データにおける認識目標としている看護行動データ抽出法を検討することで全 12 行動の認識精度は向上すると考える。

参考文献

- [1] 総務省，平成 29 年，報道資料，
入手先 <https://www.stat.go.jp/data/topics/pdf/topics113-1.pdf> (2020.08.16).
- [2] 真田弘美，森武俊，看護理工学，1-2，東京大学出版会，東京，2015
- [3] 中島勸，少子高齢化時代における看護理工学の役割，看護理工学学会誌:6-12，2016
- [4] 日本看護協会，平成 29 年，看護関係統計資料，
入手先 <https://www.nurse.or.jp/home/statistics/pdf/toukei04.pdf> (2020.08.16)
- [5] 日本看護協会，2018，病院看護実態調査，
入手先 https://www.nurse.or.jp/up.pdf/20190515134543_f.pdf (2020.08.16)
- [6] 日本医療労働組合連合会，2017，看護職員の労働実態調査結果，
入手先 <http://irouren.or.jp/research/ceb76c47ff9c68138/c8354a71e5d5583adcf9538.pdf> (2020.08.16)
- [7] 無理なく安全に！移乗・移動介助の基本と留意点，
入手先 <https://www.azumien.jp/contents/method/00006.html> (2020.08.16)
- [8] 井上創造，房前悟，相馬功，柴田智広，IoT 行動認識技術の実用化とオープンイノベーションへの取り組み，計測と制御，第 58 巻，第 2 号，(2019)
- [9] 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，Vol. 28，No. 6，pp. 170-186，(2016)

共著者一覧の正誤表

誤	高木 章裕, 木田 竜二, 酒井 元気
正	高木 章裕, 木田 竜二, 酒造 正樹, 酒井 元気