

# 入院病棟における患者センサと環境センサからの室内状況の把握

林田 興祐<sup>1</sup> 戸田 隆道<sup>1</sup> 井上 創造<sup>1</sup> 野原 康伸<sup>2</sup> 中島 直樹<sup>2</sup>

**概要:** 本研究では, 病室に設置された騒音センサのデータ, 照度センサのデータ, ベッドセンサのデータを用いて, 看護師の入退室の認識を行った. 認識には, 実際の病棟において長期間収集した患者の生体データおよび病室の環境データから, 看護師の入室時と退室時, 在室時, 非在室時のデータを 200 件用いて, 特徴量の抽出を行い, さらに抽出した特徴量を用いて, 看護師の入退室の認識を行った. その結果, 看護師が外にいる状態からの遷移を考慮した場合, 昼の時間帯では 74[%], 夜の時間帯では 80[%] の認識精度を得ることが出来た. また, 看護師が中にいる状態からの遷移を考慮した場合, 昼の時間帯では 79[%], 夜の時間帯では 85[%] の認識精度を得ることができた. また, より大規模な現実のデータで評価するため, 最も処理に時間のかかる, センサデータの読み込み処理の部分に, 並列分散処理を試みる.

## Understanding of the Indoor Situation from Environment Sensor and Patient Sensor in Hospital Wards

KOUSUKE HAYASHIDA<sup>1</sup> TAKAMICHI TODA<sup>1</sup> SOZO INOUE<sup>1</sup> YASUNOBU NOHARA<sup>2</sup> NAKASHIMA NAOKI<sup>2</sup>

### 1. 序論

我々は熊本にある済生会熊本病院と連携し, 大規模な行動データの収集を行った. そこで収集された行動データを分析し, より質の高い医療行為を行うために役立てる研究を行っている.

本研究では, 収集された長時間の行動データの中から, 医療行為を行っている区間の行動データを効率よく見つけ, 分割を支援するための手法を提案する. 手法の 1 つとして, 看護師が病室に入室している区間を把握することにより分割を支援する. 現在, 看護師の入退室の認識には RFID を用いているが, RFID は, RFID リーダを入りに 2 つ設置しなければならず, 設置運用コストがかかる. さらに, RFID リーダの動作が不安定なため, 片方しか反応しない場合がある. そこで我々は, RFID を用いずに看護師の入退室の認識を行うことを目的とする. 我々が提案する手法は, 看護師の入退室について相関がみられる, 騒音センサ, 照度センサ, ベッドセンサの 3 つの生体・環境

センサを用いて行う.

環境の状況を示す, 騒音センサや照度センサを用いることで, 看護師の入退室によりおこる病室の環境の変化を知ることができる. さらに, 看護師や患者がセンサを持たなくても, 看護師がどの病室に入ったかを把握することができるようになるということが考えられる. また, 患者の状態を示すベッドセンサを用いることで, 看護師の入退室によりおこる患者の状態の変化を知ることができる. さらに, 看護師の入退室によりおこる, 患者の心理的变化も把握することができるようになるのではないかと考えられる. 以上の 3 つのセンサを用いて, 各センサデータに対して大きく分けて 3 つの分析を行った.

1 つは, 各センサデータの波形の可視化である. 目視により確認できる, 特徴量の有無を確認するため, センサデータごとに, 時系列で波形を描画する. 波形を描画することで視覚的に波形を確認できるため, 特徴量抽出の際に有効な特徴量の有無を目視により確認できる.

次に特徴量の描画を行う. 波形の可視化により, 看護師の入退室の認識に有効な特徴量であると考えられた特徴量を描画することで, 実際に看護師の入退室の認識に有効な

<sup>1</sup> 九州工業大学

<sup>2</sup> 九州大学

特徴量であるかの確認ができる。

次に、複数の特徴量を組み合わせて、クラスタリングを行う。クラスタリングを行うことで、看護師の入退室の認識に対して有効な特徴量の確認ができる。この時、各センサデータ値の、看護師の入室時と退室時、在室時、非在室時での、平均値の変化量と分散値の変化量を特徴量とし、使用するデータは、計 200 件のデータを含むデータセットである。データセットは上記の特徴量を 1 人の患者から、入室時 10 件、退室時 10 件、在室時 10 件、非在室時 10 件の計 40 件を収集し、これを 5 人の患者から抽出し、入室時 50 件、退室時 50 件、在室時 50 件、非在室時 50 件の計 200 件のデータにより構成する。なお、昼を 8 時～18 時、夜を 18 時～8 時までとして、入室時 50 件、退室時 50 件、在室時 50 件、非在室時 50 件のデータに対して、それぞれに、昼と夜のデータが 25 件ずつ含まれるように構成する。その結果、昼と夜に分けてクラスタリングした方が、特定の値でクラスタを生成しやすいたことが分かった。

上記の分析により、求めた特徴量を用いて、実際に看護師の入退室の認識を行う。看護師の入退室の認識を行う際、使用するデータセットは、クラスタリングの際に、作成したデータセットであり、分類器はサポートベクターマシン、検定法は交差検定法を用いる。看護師の入退室の認識の結果、1 つのセンサデータのみを用いるよりも、複数のセンサデータを、組み合わせて用いる方が、有用であることが分かった。

現在収集されている、行動データは約 1,600 件であり、分析には多大な時間が必要となる。したがって、我々は並列分散処理による分析を行うことを試みた。今回、並列分散処理には Dake システムを利用する。Dake システムとは、データとプログラムの依存関係を管理しながら、Hadoop Streaming による並列分散処理を可能とするシステムである。依存関係の管理によって差分処理が適用され、データが追加された際に処理の繰り返しを避けることができる。また、標準入力のコマンドにより、任意の処理に並列分散処理を適用させることができる。

本論文は、6 つの章から構成され、1 章は序論、2 章で背景として医療現場で行動認識を行う必要性、熊本済生会病院での実験について述べ、3 章で、関連研究について述べる。4 章では、本研究で行った分析について述べ、5 章で、並列分散処理について述べる。さらに 6 章で、行った分析に対する考察を述べ、7 章の結論でまとめる。

## 2. 背景

本章では、事前実験として病院で行動データの収集を行った実験や、病院で行動認識を行う目的について記載する。

### 2.1 研究背景

近年、医療分野ではクリニカルパスと呼ばれる医療プロセスの標準化が積極的に行われている。クリニカルパスは、いつ記録されたかや、どのようなケアが患者に行われたかだけでなく、脈拍あるいは心拍数・呼吸(数)・血圧・体温などのバイタルサインや、ケア後の成果を記録することも重要である。我々は、それぞれの看護師に取り付けられたモバイル加速度計から、看護が与える患者への相互作用を取得することを目指しており、以下の 2 つの理由から看護を取得することは重要である。

- (1) いつ、どのような行為を、どのように行った記録する事で、看護が患者に与えるより良い健康の結果を理解する助けになる。
- (2) 看護師の技術の向上の助けになる。我々は看護が与える相互作用と健康結果の証拠を持っている場合、それらの間の相関関係を分析し、より良い相互作用のための重要な要因を見つけることができる。

### 2.2 病院での行動データの収集実験

我々は、熊本にある済生会熊本病院と連携し、大規模な行動データの収集実験を行った。済生会熊本病院の循環器病センターでの私たちの 1 年間の実験では、看護師と患者から大規模なモバイルセンサデータを収集している。データセットには、循環器病センターの患者の看護時のデータが含まれている。我々は 7,400 時間の実際の看護活動と、ラベル付けした 41 の行動クラスに分類した 5,964 個の行動データを 100 時間収集した。我々の知る限り、これらのデータは、実際の病院で取収されたデータで最大の物である。

収集したデータは 2011 年 4 月から 2012 年 3 月にかけて、この実験に同意する 70 人の患者のデータを収集した。表 1 は、収集したデータセットを示す。

表 1 各センサデータの合計取得時間

対象	データ種別	合計取得時間(時間)
患者	加速度センサ	5,600
	心電図	3,900
	ベッドセンサ	2,500
看護師	加速度センサ	7,400
	音声	7,400
病室	RFID	4,600
	環境センサ	5,600

#### 2.2.1 看護師から収集したデータ

我々は病院で実際に行われている看護の加速度データを収集するために、看護師にはほぼ一定の方向に加速度計を持っているモバイルデバイス (iPod touch) を、彼らの胸ポケットに入れてもらい、看護時の音声と加速度データの

取得と、右手首と腰背部にも小さな2つの加速度計を取り付けてもらい加速度データの取得を行った。これらの3つの加速度計は、看護師の行動の時間や行動の種類を認識するために使用する。図1は看護師に取り付けたデバイスを示す。



図1 取り付け図



図2 RFID リーダ

図2はRFIDリーダを示す。看護師は、RFIDタグを携帯し、患者の部屋のそれぞれの入り口には、RFIDリーダを2つ設置した。2つのRFIDリーダは看護師が部屋へ入退室したときに、それぞれ反応し、RFIDリーダの反応する順番で看護師の病室への入退室を把握・管理することができる。私たちは、実際の看護の行動データを計7,400時間、RFIDデータを4,600時間収集した。

### 2.2.2 患者から収集したデータ

実際の病院で、入院期間中の患者の生体データを収集するために、患者の胸部に心電図（ECG）を装着している。心電図はナースステーションに置かれた心電図モニタに無線接続を介して生体データを送信し、心電図モニタは、これらのバイタルデータを一元化する。心拍と、不整脈、STレベルを含む生体データは、心電図モニタに接続されたPCに保存される。私たちは、心電図データを合計3,900時間収集している。また、患者の動きを取得するために、薄く

空気の密封されたクッションを、患者のベッドのマットレス下に置く、ベッドのセンサシステムと、3軸加速度計を手首に着用している。図3はベッドセンサを示す。



図3 ベッドセンサ

図3のベッドセンサは心拍と、呼吸、身体の動きのデータをクッションの空気の圧力の変化を検知することにより、測定しており、計2,500時間を収集している。加速度計は、患者の睡眠中の寝返りから眠りの深さを測る。さらに、加速度計は患者の動きを検出し、2.2.1節で述べた看護師の加速度データと統合することにより、治療行為の認識に役立つ。一般的な患者の医療記録として、年齢や、性別、身長、体重、体温、血圧、診断、医療費や入院期間等の情報も収集している。

### 2.2.3 環境から収集したデータ

患者の病室での環境データを収集するため、温度/湿度、照度、騒音の3つの環境センサを病室に設置し、4種の環境データを収集した。温度と湿度は、5秒ごとに記録され、他のものは毎秒記録されている。環境センサのデータは5,600時間収集された。環境センサの設置状況を図4に示す。



図4 環境センサ

## 2.3 研究目的

本研究は、済生会熊本病院と連携することで収集された、生体データや、環境のデータを含む、種々のセンサデータを用いて、設置運用コストのかかる RFID を用いずに、看護師の入退室の認識を行うことを目的とする。

2.1 節で、看護の取得の重要性を述べたが、看護を得るためには、数時間にわたる長時間のシーケンスデータの中で、看護師が患者に看護を行っている区間を、推定しなければならない。効率よく、看護師が患者に看護を行っている区間を、推定するための手法として、看護師が患者に対して看護を行う時、必ず病室にいる特性を利用する。現在、看護師の入退室の記録は RFID を用いて行われている。しかし RFID は、RFID リーダを入りに 2 つ設置しなければならない。さらに、RFID リーダの動作が不安定なため、片方しか反応しない場合がある。したがって、本研究では種々のセンサデータを組み合わせることで、RFID を用いずに、看護師の入退室の認識を行う手法を提案する。今回の実験では、認識の際 RFID のデータは用いず、正解のラベルとして使用している。

## 3. 関連研究

本章では、行動データの収集で用いた大規模行動情報収集システム ALKAN と、その他の関連する研究について記載する。

### 3.1 大規模行動情報収集システム ALKAN

大規模行動情報収集システム ALKAN [10][11] は、iPhone や iPod Touch, Android 端末などの 3 軸加速度センサを搭載した携帯情報端末を用い、携帯情報端末アプリケーションで行動情報を多くの人から収集することを目的としている。利用者があらかじめ行動内容を指定し、行動種別と照合済み 3 軸加速度データと音声データを蓄積することにより、より正確な行動情報の取得を可能にする。ALKAN システムの構成は、アプリケーションと行動情報収集サーバからなる。被験者は、アプリケーションを用いて行動を行い、行動情報を蓄積する。そして、行動情報を行動情報収集サーバに送信する。また、被験者の動機付けのためにランキング機能などを実装している。

### 3.2 その他の関連研究

次に示す文献では、位置測定の手法や、パターン認識の際のデータ処理に関するものを紹介する。文献 [3] は、看護師の看護区間を求めるために、看護師の入室区間を求めている部分は同様であるが、そのための手法として、看護師の携帯センサを用いて、認識を行う部分において異なっている。文献 [4] は、RFID による位置測定のシステムについて紹介している。文献 [5] では、医療分野において、ク

ロストリジウム・ディフィシルという菌の保菌の有無を認識しており、特徴量抽出法や次元削減法などを含む、データ処理手法についても紹介している。

文献 [4] の研究と我々の研究の違いは、位置測定の際に、RFID を用いず、環境センサや、生体センサなどの、種々のセンサを用いて行うことである。文献 [5] の研究と我々の研究は、認識を行う手法は一緒であるが、用いる特徴量や、認識目標が大きく異なる。

## 4. センサデータを用いた分析

入院病棟における看護師の入室の際、影響を受けるセンサの組み合わせを調べるために、複数のセンサペアの相関関係を出した結果、看護師の入室と騒音センサ間や、看護師の入室と照度センサ間、全患者の体動と騒音間、全患者の心拍と騒音間など、特定のセンサ間に相互相関があることはわかった。しかし、センサ間に何らかの関係があることが分かっただけであり、どのような要因があるため、相互相関が生じたかまではわかっていない。したがって、本章では、病室において、看護師が病室へ入退室を行ったことにより、患者の生体センサと、環境センサが、受ける影響の有無を分析する。そして、看護師の入退室が、種々のセンサに与える影響から、看護師の入退室の認識を、RFID を用いずに行う。分析を行うために使用したデータは、看護師の入退室に対して相関の見られた、騒音のデータ、照度のデータ、ベッドセンサのデータの 3 つである。

### 4.1 相互相関の分析

予備実験として相互相関を求めた。看護師の入室の際に生じる、病室の環境の変化や、患者の生体データの変化について、相関関係が見られれば、看護師の入退室の認識に有効な、センサデータであることが期待できる。そこで、本節では、看護師の入室の際に生じる、病室の環境の変化や、患者の生体データの変化について、相関関係の分析を行う。なお、病室の環境とは、病室で聞こえる騒音の大きさや、病室の明るさ、病室の温度や湿度などのことを示す。病室の環境の変化とは、例えば、看護師が入室する際に、電気を点灯させたならば、部屋の照度が変化する。このように、看護師の入室により起こる、病室の環境の変化を把握することで、看護師の入退室の認識を、環境センサにより行うことができる可能性がある。同様に、看護師の入室の際の、患者の生体データの変化を把握することで、看護師の入退室の認識を、生体センサにより行うことができる可能性がある。RFID を用いずに、看護師の入退室の認識を行うために、まず、看護師の入室に対して、相関が見られるセンサを把握し、次に、相関が見られるセンサデータが、看護師の入室の際、どのような特徴を示すかを調査する。

各センサ間の相関を求める際、相関の値には時刻のずれが生じる。これは、センサごとに時刻が設定してあり、こ

のセンサごとの時刻を、常に同期させているわけではなく、日に一度だけ同期させているからである。したがって、各患者、看護師、環境のセンサデータで、相互に影響を受けるペアを、時刻のずれを含めて求める。本実験では、相関関係を示したセンサペアのなかで、入院病棟において、看護師が入室する際、病室の環境に対し影響を受けたセンサを主に用いる。各センサ間の相関関係を分析する。分析の手順は以下のとおりである：各患者に対して、

- 1) 各センサ値で、1分の時間窓を取り、時間窓毎に中央値を取る。
- 2) 1分の時間窓毎に中央値をとったものを、3時間毎に分割する。
- 3) 3時間毎に分割したセンサデータを、様々なセンサデータ間でペアを作り、最大で60分の時間差で相互相関値を計算する。

#### 4.2 分析方法

分析は、各センサデータに対し、大きく3つに分けて行った。1つは、各センサデータの波形の可視化である。目視により確認できる、特徴量の有無を確認するため、センサデータごとに、時系列で波形を描画する。波形を描画することで視覚的に波形を確認できるため、特徴量抽出の際に有効な特徴量の有無を目視により確認できる。次に特徴量の描画を行う。波形の可視化により、看護師の入退室の認識に有効な特徴量であると考えられる特徴量を描画することで、実際に看護師の入退室の認識に有効な特徴量であるかの確認が行える。次に、複数の特徴量を組み合わせ、クラスタリングを行う。

波形の可視化は、看護師の入室時と退室時、在室時、非在室時の4つに対して行い、それぞれ120秒ずつ無作為に取得している。特徴量の描画は、看護師の入室時と退室時、在室時、非在室時の4つに対して、60秒間のセンサデータの値を、無作為に取得し、さらにそれぞれ抽出した値の前半の30秒と後半の30秒で、それぞれ平均値を求め、最後に前半と後半でそれぞれ求めた平均値の差を求め、それを平均値の変化量として描画を行う。クラスタリングを行う際に用いる特徴量は、看護師の入室時と退室時、在室時、非在室時に対して、それぞれ抽出している。特徴量の抽出の手法を以下に示す。

- (1) センサごとに、看護師の入室時と退室時に対しては、看護師の入室した瞬間と退室した瞬間を、看護師の在室時に対しては、看護師の入室している区間において、ある時点、看護師の非在室時に対しては、看護師の入室を含まない区間において、ある時点を定める。
- (2) それぞれの時点の40秒前から10秒前までの値、10秒後から40秒後までのデータの値の、それぞれ平均値と分散値を抽出する。
- (3) 抽出した平均値、分散値でそれぞれ差分を求める。

(4) 求めた差分の絶対値を、特徴量として用いる。

使用するデータは、1人の患者に対して、上記の手法で看護師の入室時を10件、退室時を10件、在室時を10件、非在室時を10件、それぞれ抽出し、さらに、昼の時間を8時～18時、夜の時間を18時～8時として、看護師の入室時、退室時、在室時、非在室時に対して、それぞれ昼のデータが5件、夜のデータが5件、となるようにした。これを、5人の患者に対して行い、看護師の入室時と退室時、在室時、非在室時を50件ずつ、計200件のデータを抽出し、データセットの作成を行った。データセットは、看護師の入室時、退室時、在室時、非在室時のそれぞれの1件のデータにおいて、騒音のデータ、照度のデータ、脈拍波形データ、呼吸波形データ、体動波形データの5つのセンサデータの計10個の特徴量をもつデータセットとなる。脈拍波形データ、呼吸波形データ、体動波形データの3つのデータは、ベッドセンサにより収集されたデータである。

#### 4.3 分析結果

行った分析は3つであり、4.2節で述べた通りである。1つ目に、各センサデータの波形の可視化を行う。次に、特徴量を描画することで、看護師の入退室に有効な特徴量であるかの確認を行う。騒音のデータ、照度のデータに関しては、目視で確認できる特徴量がなかったため、看護師の入室前と入室後では、騒音の大きさや病室の明るさが、変化するのではないかと考え、特徴量の抽出を試みた。抽出を行った特徴量は、看護師の入室時に対しては入室前と入室後の平均値の変化であり、看護師の非在室時に対しては、看護師の入室が含まれない区間から、無作為に取得した時点の前後の平均値の変化である。描画を行った結果、騒音には看護師の入室時と非在室時で差が見られたが、照度には差が見られなかった。この結果を、図5と図6に示す。図5と図6の縦軸は平均値の変化量を示す。さらに、それぞれ(a)の在室は、看護師の入室前後30秒間の10データにおける、平均値の変化を示した箱ひげ図である。(b)の不在は、看護師の入退室を含まない区間より無作為に取得した、10時点の時刻の前後30秒間の、平均値の変化量を示した箱ひげ図である。騒音値の入室時の平均は0.0583[dB](標準偏差3.97)、非在室時の平均は-2.86[dB](標準偏差4.64)であった。照度値の入室時の平均は-0.15[LUX](標準偏差0.373)、非在室時の平均は0.263[LUX](標準偏差0.83)であった。

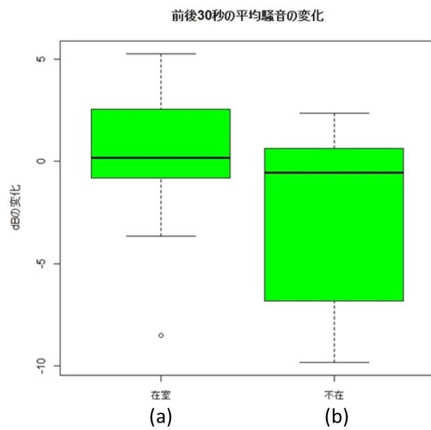


図 5 看護師の入室前後 30 秒の平均騒音の変化

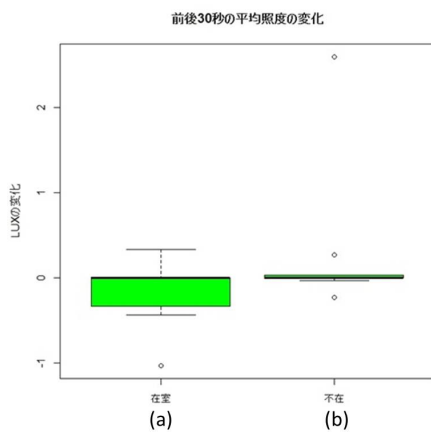


図 6 看護師の入室前後 30 秒の平均騒音値の変化

また、ベッドセンサのデータは、目視により、看護師の入室に影響を受けることがわかったので、看護師の入室による、特定の変化の有無を確認する。確認手法は、看護師の入室前と入室後で、それぞれに対して平均値と分散値を求め、それぞれ描画した。結果の 1 例を図 7 に示す。図 7 は、縦軸を分散、横軸を平均として描画したもので、看護師の入室した瞬間の 40 秒前から 10 秒前までのデータの値の、平均と分散を赤色で示し、看護師の入室した瞬間の 10 秒後から 40 秒後までのデータの値の、平均と分散を青色で示している。結果として、看護師の入室による特定の変化は、見られなかった。したがって、看護師の入室前と入室後で、それぞれに対して平均値と分散値を求めるだけでは、看護師の入室の認識を求める特徴量としては、不十分だとわかった。




図 7 “呼吸波形データ”の平均値と分散値の散布図

次に、新たな特徴量を考え、クラスタリングを行った。センサデータごとに、特徴量の抽出を行った結果、看護師の入室によるセンサデータ値の、特定の変化は見られなかった。したがって、新たな特徴量として、看護師の入退室によりおこる、各センサデータ値の変化の大きさを考えることとした。クラスタリングを行った結果、それぞれのデータの、平均値の差分の絶対値と分散値の差分の絶対値を特徴量とし、昼と夜に分けて用いることで、クラスタが生成し、看護師の入退室に対して、有効な特徴量であることがわかった。

#### 4.4 看護師の入退室の認識

クラスタリングにより得られた特徴量を用いて、看護師の入室時と退室時、在室時、非在室時の認識を行う。使用するデータは、4.2 節で作成したデータセットであり、認識は、計 200 データのデータセットに対して、交差検定を行った。なお、看護師の入退室の認識と評価を行う際、分類器はサポートベクターマシンを用いて行う。

表 2 看護師の入退室の認識結果

センサデータの 組み合わせ	精度		
	全時間	昼 (8 時～18 時)	夜 (18 時～8 時)
騒音・照度・ベッド	55[%]	53[%]	62[%]
・照度・ベッド	49[%]	51[%]	55[%]
騒音・ ・ベッド	57[%]	54[%]	63[%]
騒音・照度・	37[%]	37[%]	40[%]

表 2 は、看護師の入退室の認識を行い、得られた結果である。本実験における精度を求める式を以下に示す。

$$\text{精度} = \frac{\text{認識による予測結果の正解件数}}{\text{使用したデータの合計件数}} \times 100$$

これ以降、精度は上記の式により求めた結果とする。

騒音センサのデータと照度センサのデータ、ベッドセンサのデータを組み合わせて認識を行った結果、55[%]の精



度となった。さらに昼(8時~18時)の時間帯と、夜(18時~8時)の時間帯に分けて認識を行った結果、それぞれ53[%]と62[%]の精度が得ることができた。また、それぞれのセンサデータが認識に与える影響について知るために、照度センサとベッドセンサのデータで認識を行った場合、騒音センサとベッドセンサのデータで認識を行った場合、騒音センサと照度センサのデータで認識を行った場合の、それぞれの精度を求めた。その結果、照度センサは含まない場合の方が、精度が良くなることがわかった。次にシーケンスデータを用いて認識を行う場合、現在の状況からの状態遷移を考慮ることにより、さらに精度を上げることが出来ると考えられる。したがって、看護師が外にいる場合と、中にいる場合の、それぞれからの状態遷移を考慮した看護師の入退室の認識を行った。その結果を、表3と表4に示す。

表3 看護師が外にいる場合からの状態遷移を考慮した看護師の入退室の認識結果

センサデータの組み合わせ	精度		
	全時間	昼(8時~18時)	夜(18時~8時)
騒音・照度・ベッド	74[%]	74[%]	76[%]
・照度・ベッド	71[%]	72[%]	76[%]
騒音・・ベッド	75[%]	74[%]	80[%]
騒音・照度・	66[%]	70[%]	64[%]

表4 看護師が中にいる場合からの状態遷移を考慮した看護師の入退室の認識結果

センサデータの組み合わせ	精度		
	全時間	昼(8時~18時)	夜(18時~8時)
騒音・照度・ベッド	79[%]	79[%]	81[%]
・照度・ベッド	72[%]	79[%]	71[%]
騒音・・ベッド	80[%]	75[%]	85[%]
騒音・照度・	64[%]	65[%]	71[%]

表3から、看護師が外にいる場合からの状態遷移を考慮した場合、昼の時間帯では74[%]、夜の時間帯では80[%]の認識精度を得ることが出来た。表4からは、看護師が中にいる場合からの状態遷移を考慮した場合、昼の時間帯では79[%]、夜の時間帯では85[%]の認識精度を得ることが出来た。また、今回用いたセンサデータの中では、ベッドセンサが、最も看護師の入退室の認識に影響があることがわかった。

## 5. 並列分散処理

精度を向上させるために、より大規模な現実のデータで評価を必要とする。その際、処理時間が多くかかるため、並列分散処理を用いて、処理時間の短縮を試みる。

看護師の入退室の認識のため、特徴量を分類器にかけるが、このとき前処理として、各患者の入退室のデータをまとめてcsv形式で出力するプログラムがある。このプログラムは以下のような順で動作する。

- (1) 患者ごとにフォルダ分けされたcsv形式のセンサデータを読み込む。
- (2) 患者ごとにプログラムの中で行列に格納する。
- (3) 自身で作成したメタデータを基にRFIDのデータと比較する。
- (4) RFIDのデータとの比較で出入退室のデータをcsv形式のファイルにまとめる。

これらの処理の内、□の処理が最もファイル数が多く処理に時間がかかるのでここに並列分散処理を適用させる。実際にプログラムの処理にかかった時間を、表5に示し、プログラムの処理のフロー図を図8に示す。

表5 直列実行時の処理時間[s]

	前処理	データの読み込み		データの比較	csv形式で出力
		センサ	RFID		
1回目	0.15	427.99	0.22	116.85	0.07
2回目	5.22	412.67	0.14	116.6	0.06
3回目	3.05	409.27	0.12	117.15	0.08
平均	2.806667	416.6433	0.16	116.8667	0.07

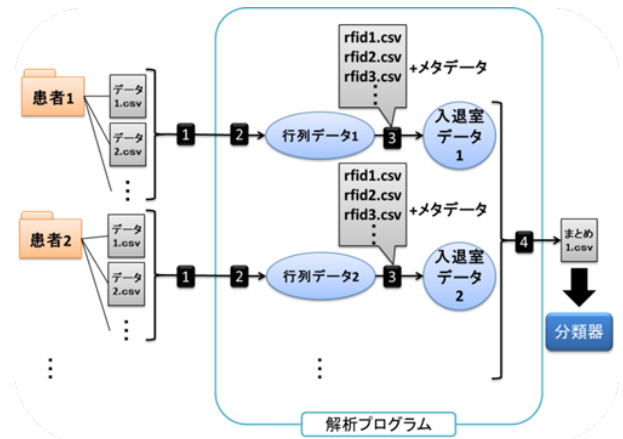


図8 プログラムの処理フロー

## 6. 考察

本研究の実験は、生体・環境センサから看護師の入退室の認識を行うということを目的として行った。その結果として、状態の遷移を考慮し、さらに昼を8時~18時、夜を18時~8時として、場合分けを行い、時間帯ごとに、看護師の入退室の認識を行うのに有効な特徴量を持つセンサデータの把握を行うことができた。以下では、それぞれのセンサデータを確認していく。

騒音のデータは、看護師が病室の中にいる状態からの遷

移を考慮し、夜の時間帯で看護師の入退室の認識を行う際に有効な特徴量を持つことがわかった。このことは、一般の生活環境から考えると、夜の時間帯と昼の時間帯では、夜の時間帯の方が、作業を行うときと行っていないときの騒音の大きさに、はっきりと差が出るためであると考えることができ、そのため、夜の時間帯の騒音センサの値は、看護師の入退室の認識を行う際に、有効な特徴量であると考えられる。

次に照度のデータは、照度のデータのみで、看護師の入室の認識を行うには特徴量が弱く、認識の精度は、非常に低いものとなった。さらに、他のセンサと組み合わせて用いた場合、看護師が中にいる状態からの遷移を考慮した、昼の時間帯における、看護師の入退室の認識を行う場合以外では、照度のデータを、特徴量として含まない方が、精度が高いという結果を得た。

次にベッドセンサのデータは、ベッドセンサのデータ以外のセンサデータで看護師の入退室の認識を行った場合、他に比べ最も精度が低くなっていることから、他のセンサデータより、看護師の入退室の認識を行う際に、有効な特徴量を持つことがわかった。

看護師の入退室の認識の際、看護師が外にいる場合からの状態遷移を考慮した場合、昼の時間帯では74[%]、夜の時間帯では80[%]の認識精度を得ることが出来た。また、看護師が中にいる場合からの状態遷移を考慮した場合、昼の時間帯では79[%]、夜の時間帯では85[%]の認識精度を得ることが出来た。しかし、今回の認識は、精度の高いものが得やすい、交差検定法により行ったものである。そのため、分析するデータと、テストに用いるデータを、患者ごとに分けて認識を行った場合、精度が下がると考えられる。汎用性を考えると、分析するデータと、テストに用いるデータは、患者ごとに分けて認識を行う方が好ましい。したがって、今後は、患者ごとに分けて認識を行った場合でも、精度が高い特徴量の組み合わせ、もしくは、新たな特徴量の抽出を、検討する必要がある。また、より高い精度で、看護師の入退室を認識できたならば、さらに汎用性を高めるために、複数のセンサにより行っている、看護師の入退室の認識を、単一のセンサにより、実現できる手法を、検討する必要がある。これらの課題を実現していくためには、より大規模な現実のデータで評価を行う必要がある。その際、大規模なデータを用いるため、処理時間が多くかかる。そこで、最も処理に時間がかかる、センサデータの読み込み処理の部分に、並列分散処理を試みる。

## 7. 結論

本研究では、看護師の入退室の認識を行うことを目的として、騒音のデータ、照度のデータ、ベッドセンサのデータについて分析を行った。看護師の入退室の記録に関しては、現在RFIDセンサを用いている。しかし、RFIDセン

サは、RFIDリーダを、入り口に2つ設置しなければならず、設置運用コストがかかる。さらに、RFIDリーダの動作が不安定なため、片方しか反応しない場合がある。したがって、本研究では、生体・環境センサデータを組み合わせることで、RFIDを用いずに、看護師の入退室の認識を行う手法を提案した。分析に使用した、RFID以外のセンサデータは、騒音のデータ、照度のデータ、ベッドセンサのデータであり、熊本にある、済生会熊本病院と連携し、大規模なデータの収集実験により収集した、長時間のシーケンスデータである。騒音のデータ、照度のデータには、それぞれ病室の騒音と明るさを、数値化したものが記録されており、ベッドセンサのデータには、患者の脈拍、呼吸数、体動数に関するものが、主に記録されている。上記のセンサデータを使用したのは、分析の結果、看護師の入室に対して相関関係を示したためである。各センサデータに対して、大きく3つに分けて分析を行った。

1つは、各センサデータの波形の、可視化である。目視により確認できる、特徴量の有無を確認するために、センサデータごとに、時系列で波形を描画する。波形を描画することで、視覚的に波形を確認できるため、特徴量抽出の際に有効な特徴量の有無を、目視により確認ができる。

次に、特徴量を描画することで、看護師の入退室に有効な特徴量であるかの確認を行う。騒音のデータ、照度のデータに関しては、目視で確認できる特徴量がなかったため、看護師の入室前と入室後では、騒音の大きさや病室の明るさが、変化するのではないかと考え、特徴量の抽出を試みた。抽出を行った特徴量は、看護師の入室時に対しては入室前と入室後の平均値の変化であり、看護師の非入室時に対しては、看護師の入室が含まれない区間から、無作為に取得した時点の前後の平均値の変化である。描画を行った結果、騒音には看護師の入室時と非入室時で差が見られたが、照度には差が見られなかった。また、ベッドセンサのデータは、目視により、看護師の入室に影響を受けることがわかったので、看護師の入室による、特定の変化の有無を確認する。確認手法は、看護師の入室前と入室後で、それぞれに対して平均値と分散値を求め、それぞれ描画した。結果は、看護師の入室による特定の変化は、見られなかった。したがって、看護師の入室前と入室後で、それぞれに対して平均値と分散値を求めるだけでは、看護師の入室の認識を求める特徴量としては、不十分だとわかった。

次に、新たな特徴量を考え、クラスタリングを行った。センサデータごとに、特徴量の抽出を行った結果、看護師の入室によるセンサデータ値の、特定の変化は見られなかった。したがって、新たな特徴量として、看護師の入室によりおこる、各センサデータ値の変化の大きさを、考えることとした。特徴量は、看護師の入室時と退室時、在室時、非入室時に対して、それぞれ抽出している。クラスタリングを行う際、求めた特徴量は、騒音のデータ、照度の



データ、ベッドセンサのデータの、平均値と分散値の差分の絶対値であり、使用するデータは、計 200 件のデータを含むデータセットである。データセットは、上記の特徴量を 1 人の患者から、入室時 10 件、退室時 10 件、在室時 10 件、非在室時 10 件の計 40 件を収集し、これを 5 人の患者に対して行い、計 200 件のデータにより構成する。なお、昼を 8 時～18 時、夜を 18 時～8 時までとして、入室時 50 件、退室時 50 件、在室時 50 件、非在室時 50 件のデータに対して、それぞれに、昼と夜のデータが、25 件ずつ含まれるように構成する。看護師の入退室に対して、クラスタリングを行った結果、昼と夜に分けてクラスタリングした方が、特定の値で、クラスタを生成しやすいことがわかった。

上記の分析により、求めた特徴量を用いて、実際に看護師の入退室の認識を行う。看護師の入退室の認識を行う際、使用するデータセットは、クラスタリングの際に、作成したデータセットであり、分類器はサポートベクターマシン、検定法は交差検定法を用いる。看護師の入退室の認識の結果、1 つのセンサデータのみを用いるよりも、複数のセンサデータを、組み合わせて用いることで、より精度の高い認識を行うことができることがわかった。また、状態遷移や時間帯を考慮し、使うセンサデータを選択することで、より精度の高い認識を行うことができることもわかった。さらに、今回用いた、3 つのセンサデータの中ではベッドセンサが、最も看護師の入室の認識に影響を与えることがわかった。

今回、看護師の入室の認識を行う際、交差検定法を用いたが、交差検定法は、分析するデータと、テストに用いるデータに同じ患者のデータが、含まれている可能性が高い、そのため高い精度で求めることができる。しかし、汎用性を考えると、分析するデータと、テストに用いるデータは、別々の患者のものである方が好ましい。なので、今後の課題の 1 つとして、患者ごとに分けて認識を行った場合でも、高い精度を出すということが挙げられる。そのためには、より精度の高い結果の得られる特徴量の組み合わせ、もしくは、新たな特徴量の抽出を検討する必要があると考えられる。また、より高い精度で、看護師の入退室を認識できたならば、さらに汎用性を高めるために、複数のセンサにより行っている、看護師の入退室の認識を、単一のセンサにより、実現できる手法を、検討する必要があると考えられる。これらの課題を実現していくためには、より大規模な現実のデータで評価を行う必要がある。その際、大規模なデータを用いるため、処理時間が多くかかる。そこで、最も処理に時間のかかる、センサデータの読み込み処理の部分に、並列分散処理を試みる。

## 参考文献

[1] 野原康伸, 井上創造, 中島直樹, 上田修功, 喜連川優, “A Large-scale Sensor Dataset in a Hospital”, Interna-

- tional Workshop on Pattern Recognition for Healthcare Analytics, 4pages, November 11, 2012, Tsukuba.
- [2] 中島直樹, 若田好史, 野原康伸, 井上創造, 小妻幸男, 副島秀久, 田中雅夫, “アウトカム志向型電子パスと生体センサを用いた探索的なクリティカルインディケータ抽出”, 第 16 回日本医療情報学会春季学術大会, 8pages, June 2, 2012, Hakodate.
- [3] Sozo Inoue, Kosuke Hayashida, Masato Nakamura, Yasunobu Nohara, Naoki Nakashima, “Capturing Nursing Interactions from Mobile Sensor Data and In-room Sensors”, International Conference on Human-Computer Interaction (HCI International), to appear, July 21, 2013, Las Vegas, USA.
- [4] 椎尾一郎, “RFID を利用したユーザ位置検出システム”, 情報処理学会研究報告.HI, ヒューマンインタフェース研究会報告 2000, vol.39, pp.45-50, May 12,2000.
- [5] Jenna Wiens, Fohn Gutttag, Eric Horvitz, “Learning Evolving Patient Risk Processes for C.Diff Colonization”, ICML2012, 8pages, June 2012, Edinburgh, Scotland.
- [6] Kajiro Watanabe, Takashi Watanabe, Harumi Watanabe, Hisanori Ando, Takayuki Ishikawa, Keita Kobayashi, “Noninvasive measurement of heartbeat, respiration, snoring and body movements of a subject in bed via a pneumatic method”, IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, vol.52, Issue:12, pp.2100-2107, December 2005, Tokyo, Japan.
- [7] Simon Wulff, “Indoor Navigation”, In: Mobile Interaction and Mobile Services, vol. 1 of Advances in Media Technology, pp.11-25, February 10,2011.
- [8] Hui Liu, Darabi,H., Banerjee,P., Jing Liu, “Survey of wireless indoor positioning techniques and systems”, IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, vo.37, Issue:6, pp.1067 - 1080, November 2007.
- [9] Joachims T, “Making large-scale svm learning practical”, advances in kernel methods - support vector learning, October 29, 1999.
- [10] 服部祐一, 竹森正起, 井上創造, 平川剛, 須藤修, “携帯情報端末による大規模行動収集システムの運用と基礎評価”, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2010) 予稿集, pp.583 - 590, July 6, 2010, Gifu, Japan.
- [11] 服部祐一, 竹森正起, 井上創造, 平川剛, 須藤修, “携帯情報端末による大規模行動情報収集システム「ALKAN」”, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2010) 予稿集 (デモ), pp.2061 - 2065, July 6, 2010, Gifu, Japan.