

系列パターンマイニングを利用した看護師の業務手順と インシデントとの関係性分析

Analyzing Relationship between Operation Sequences of Nurses and Medical Incidents using Sequential Pattern Mining Algorithms

西開地 晃司¹ 大原 剛三² 杉山 康彦³ 白水 麻子⁴ 豊田 哲也²
Koji Nishikaichi¹ Kouzou Ohara² Yasuhiko Sugiyama³ Mako Shirouzu⁴ Tetsuya Toyota²

¹ 青山学院大学大学院 理工学研究科

¹ Graduate School of Science and Engineering, Aoyama Gakuin University

² 青山学院大学 理工学部

² College of Science and Engineering, Aoyama Gakuin University

³ 株式会社シーイー・フォックス

³ Cefox Co.,Ltd.

⁴ 熊本県立大学 総合管理学部

⁴ Faculty of Administrative Studies, Prefectural University of Kumamoto

Abstract: In this paper, we attempt to analyze the relationship between operation sequences of nurses and medical incidents by means of sequential pattern mining algorithms. More specifically, we extract frequent sequential patterns of nurses' operations by applying sequential pattern mining algorithms PrefixSpan and Modified PrefixSpan to operation transition data that are constructed from historical data of operations conducted by nurses for each work day. Due to a large number of patterns that are extracted at this step, we select only ones having a good discriminative power among from them by constructing decision trees for each of them. The resulting patterns are used to construct a prediction model such as the one that classifies nurses into two classes: ones who are likely to cause an incident and others. Through the results obtained from the real data collected in a hospital, we will show the possibility that we can reveal operation transition patterns that may lead to an incident by investigating features that appear in the prediction model.

1 はじめに

近年、医療分野において診療データや診療報酬明細書データなどの医療ビッグデータが利活用されている。具体的には、電子カルテシステムやインシデント報告システムの開発・導入、医療画像に対してAIを用いた診療支援などが行われている。その主な目的は、医療サービスの質の向上や医療に携わる人たちの業務支援・業務効率化、インシデント・アクシデントの発生を抑制するための要因分析などである。看護業務の効率化を図るためには、まず看護師の業務を客観的に記録する必要があるため、タイムスタディ調査と呼ばれる観察対象者の行動を観察者が測定する手法を用いた研究がある[1-4]。また、インシデントの発生要因を分析する先行研究では、看護師の属性または心理状態についてのアンケート調査結果の分析やインシデントレポー

トの分析などが行われている[5,6]。

一方、看護師の業務は、患者や他のスタッフの行動・状態を認識して自分の行動を自律的に決定する自律分散型業務であるため、看護師ごとに業務の実施手順は異なる。そのため、医療インシデントの発生につながる業務の実施手順が存在する可能性が考えられる。しかし、既存研究では業務の実施手順と医療インシデント発生の関係性について分析は行われていない。

このような背景の下、本研究では業務の実施手順とインシデント発生の関係性を分析する手法を提案する。具体的には、勤務日ごとに各看護師が実施した業務手順を時系列で保持した業務遷移データに対し、系列パターンマイニング手法であるPrefixSpan[7]とそれを改良したModified PrefixSpan[8]を適用し、一定頻度以上観測される特徴的な業務遷移パターンを抽出し、これらのパターンとインシデントの関係について分析す

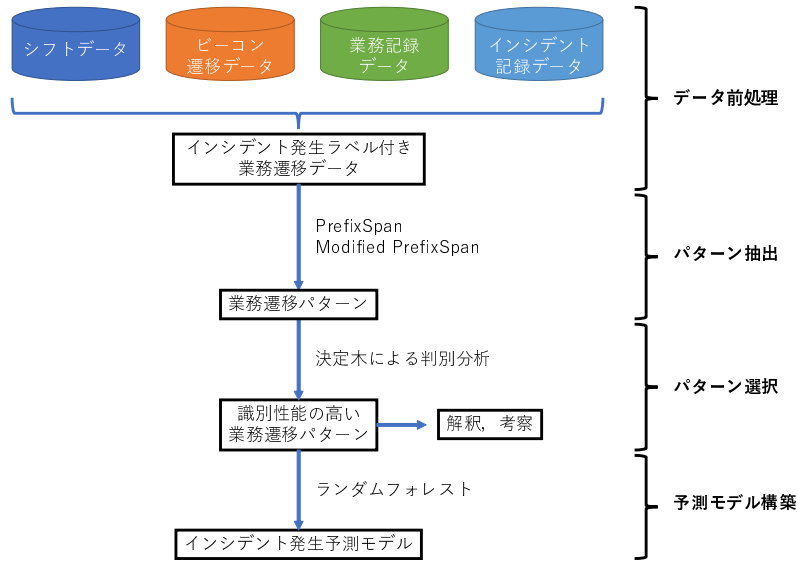


図 1: 提案手法

る。ただし、これらの系列パターンマイニング手法により抽出される業務遷移パターンの数は一般に膨大なものとなるため、事前に定めた分析目的の下での識別性能が一定以上のパターンのみを選別して利用する。抽出した業務遷移パターンとインシデントの関係分析に関しては、選別されたパターンの実施回数の特徴量とし、機械学習アルゴリズムの1つであるランダムフォレストを適用して予測モデルを構築し、その中で利用されたパターンについて考察する。本稿では、東京都内のある病院に勤務する看護師・看護補助者 55 名を対象に、携帯端末と近接センサを用いて約 1ヶ月の期間に収集された業務データを用いた分析事例について報告する。なお、以降では、特に区別する必要のない限り、看護師、看護補助者いずれも単に看護師と表記する。

2 提案手法

2.1 提案手法の概要

本稿で提案する手法の概要を図 1 に示す。分析対象データは、看護師のシフト情報を記録したシフトデータ、看護師の位置情報を記録したビーコン遷移データ、看護師が実施した業務を記録した業務データ、インシデントの発生日時・状況などを記録したインシデント記録データの 4 種類である。提案手法では、データ前処理、パターン抽出、決定木による判別分析によるパターン選択、ランダムフォレストを用いた予測モデルの構築の大きく 4 つの処理で構成される。

まず、データ前処理では、シフトデータとビーコン遷移データを用いて看護師の出退勤時間の修正を行う。ビーコン遷移データは、病棟内に設置された Bluetooth

表 1: インシデント発生ラベル付き業務遷移データ

ID	勤務日	インシデント発生有無	業務遷移データ
03	20171226	1	環境整備, 脈拍...
03	20171227	0	排尿介助, オムツ交換...
03	20171228	0	脈拍, 体温, 血圧....
03	20180103	0	環境整備, 排尿介助...

ビーコンからの信号を看護師がもつ携帯端末が記録したものであり、看護師の病棟内での移動記録となる。今回は、その記録を用いてシフトデータにおける出退勤時間を修正した。業務データは看護師が実施した業務の内容および開始時間と終了時間を記録したものであり、修正した出退勤時間を用いて、さらに各業務の開始・終了時間も修正する。これらの修正後のデータから、勤務日ごとの実施業務の順序を保持した時系列データを作成し、それを業務遷移データと定義する。さらに、インシデント記録データを参照し、業務遷移データに対してインシデント発生ラベル (0: インシデントなし, 1: インシデントあり) を付加し、表 1 に示すようなインシデント発生ラベル付き業務遷移データを作成する。

次に、インシデント発生ラベル付き業務遷移データに対して系列パターンマイニング手法である PrefixSpan [7] と Modified PrefixSpan [8] を適用し、頻出する業務遷移パターンを抽出する。両者は、パターンを構成する要素間に潜在的に存在し得る要素 (以下、ギャップと呼ぶ) の扱いが異なり、PrefixSpan が任意の個数のギャップを許容するのに対し、Modified PrefixSpan は事前に指定された個数までのギャップのみを許容する。

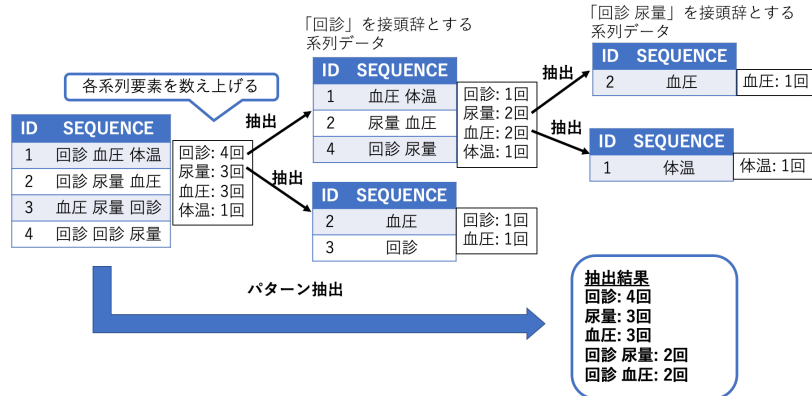


図 2: PrefixSpan によるパターン抽出例

抽出した業務遷移パターンに関して、その実施回数を集計し、それを特徴量として深さ 1 の決定木を構築し、一定以上の識別性能をもつパターンを選択する。ここで、各業務遷移パターンの集計期間および決定木分析における識別対象は事前に決めた分析目的に従って決める。そして、決定木分析により選別した業務遷移パターンを用いて対象となる識別問題に対する予測モデルをランダムフォレストを用いて構築する。以下では、前処理を除く各処理について説明する。

2.2 PrefixSpan の適用

PrefixSpan [7] は、Pei らによって提案された頻出する系列パターンを抽出する手法であり、事前に指定する最小支持度以上の出現回数をもつパターンのみを効率的に抽出する。具体的には、PrefixSpan は以下に示す処理を繰り返すことで多頻度系列パターンを抽出する。

1. 系列データに出現する各系列要素の出現回数を数え上げる
2. 指定した最小頻度を満たす系列要素を接頭辞とする部分系列データを抽出し、接頭辞を更新する

図 2 は、4 つの系列データ「回診 血压 体温」「回診 尿量 血压」「血压 尿量 回診」「回診 回診 尿量」から、パターンの長さが 1 以上かつ最小支持度が 2 回以上のパターンを PrefixSpan を用いて抽出する過程を示したものである。ここで、抽出結果に含まれる「回診 血压」というパターンに注目すると、その出現頻度 2 回のうち 1 つは「回診 尿量 血压」という系列データでの出現となっている。このように、抽出したパターンと実際の系列データのマッチングを取る場合は、パターン中の要素間に任意の個数の任意の要素の存在を許容する必要がある。本稿では、このようにして得られた系列パターンを業務遷移パターンと定義し、PrefixSpan を

用いて抽出したパターンに関しては、「業務名 業務名」というようにパターン中の要素を空白で区切って表記する。

2.3 Modified PrefixSpan の適用

Modified PrefixSpan [8] は、Kitakami らによって開発された PrefixSpan を拡張した系列パターンマイニング手法である。Modified PrefixSpan では、最小支持度に加えて最大ギャップ数を事前に指定する。最大ギャップ数はパターン中の要素間に許容する任意の要素の数の上限値である。Modified PrefixSpan は、次の処理を繰り返すことで系列パターンを抽出する。

1. 系列データの先頭の系列要素を 0 個から最大ギャップ数まで "*" に置換し、ギャップ以外の系列データに出現する各系列要素の出現回数を数え上げる
2. 指定した最小頻度を満たす系列要素を接頭辞とする系列データを抽出し、接頭辞を更新する

図 3 は、4 つの系列データ「体温 血压 脈拍 呼吸」「体温 体温 脈拍 呼吸」「体温 血压 血压 清拭」「体温 体温 血压 血压」から長さが 2 以上、最小支持度が 2、最大ギャップ数が 2 であるようなパターンを抽出する例を示したものである。なお、パターン中の "*" は 1 つのギャップを表す。また、Modified PrefixSpan で抽出したギャップを考慮した業務遷移パターンに関しては、「業務名 / 業務」というように "/" を要素間の区切り記号として表記する。

PrefixSpan と Modified PrefixSpan の違いは、抽出するパターンにおけるギャップの扱いが異なる点にある。たとえば、「血压 脈拍」「血压 呼吸 脈拍」「血压 体温 脈拍」という 3 つの系列データに PrefixSpan を適用すると「血压 脈拍」という系列パターンが抽出されるのに対して、Modified PrefixSpan を適用すると「血压 / *

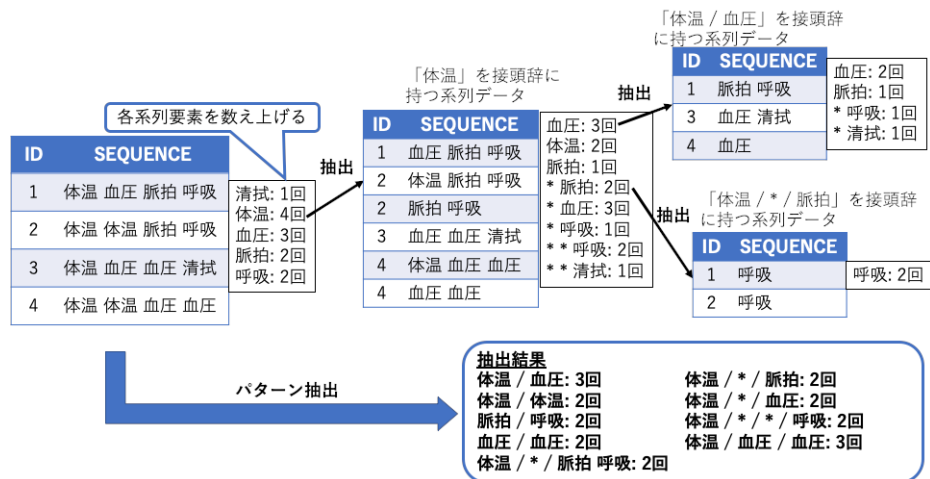


図 3: Modified PrefixSpan によるパターン抽出例

「脈拍」という系列パターンが抽出される。PrefixSpan が抽出した「血压 脈拍」は、「血压 脈拍」だけでなく「血压 呼吸 脈拍」や「血压 体温 体温 脈拍」にもマッチングするため、業務と業務の間に任意の業務が複数含まれ得る。一方、Modified PrefixSpan によって抽出された「血压 / * / 脈拍」は、「血压 呼吸 脈拍」にはマッチングするが、「血压 脈拍」や「血压 体温 体温 脈拍」にはマッチングしない。このように、Prefix Span が抽出した系列パターン中の要素間には任意の個数の任意の業務が存在し得るが、Modified PrefixSpan が抽出した系列パターンにおける要素間のギャップの個数は“*”の個数に明確に限定される。

2.4 決定木による業務遷移パターンの選択

PrefixSpan と Modified PrefixSpan によって得られるパターン数は、最小支持度を小さくした場合、一般に膨大なものとなるため、分析目的に対する識別性能が一定以上のものだけに限定して利用することが望ましい。そのため、ここでは個々のパターンがもつ識別性能を図 4 に示すような深さ 1 の決定木を構築することで評価し、その結果に応じて使用する業務遷移パターンを選択する。具体的には、分析目的がインシデントが発生した日とそうでない日を区別する場合は、勤務日 1 日を 1 つの事例とし、対象とする業務遷移パターンについて勤務日ごとの実施回数を集計した値を説明変数、インシデント発生有無を目的変数とする。また、インシデントを引き起こした看護師とそうでない看護師を区別する場合は、看護師 1 人を 1 つの事例とし、対象とする業務遷移パターンについて看護師ごとにその実施回数を勤務日数で割った平均実施回数を説明変数、インシデント発生有無を目的変数とする。

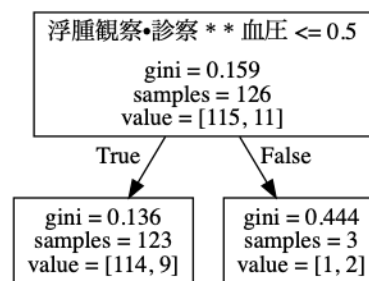


図 4: 決定木の出力例

2.5 ランダムフォレストによる予測モデルの構築

ランダムフォレストは、対象データからブートストラップサンプリングにより複数の訓練データを生成し、それにより多数の決定木を構築し、個々の決定木による分類結果の多数決をとって最終的な予測結果を決定するアンサンブル学習アルゴリズムである。本研究で対象とする医療インシデントの発生件数は全データ数に対して圧倒的に少なく、汎用性の高い少数の判断基準を学習することは困難であることが予想される。そのような場合、複数の判断基準を利用するランダムフォレストなどのアンサンブル学習アルゴリズムが高い予測精度を達成することが期待できる。また、利用する特徴量（業務遷移パターン）の数が多くなる場合、そのすべてを使うことを前提としない決定木のほうが望ましい。これらの理由から、本稿では予測モデルの構築にランダムフォレストを採用している。



図 5: aTimeLogger2 のインターフェース

表 2: 対象データの詳細

実験日数	33 日間
1 日の実験時間	24 時間
対象者	看護師 49 人 看護補助者 6 人
延べ勤務日数	602 日
Bluetooth ビーコン数	297 個
看護業務カテゴリ	24 種類
看護業務数	94 種類
発生したインシデント数	13 件

表 3: 発生したインシデント一覧

発生カテゴリ	発生内容	件数
配膳	配膳に関するミス	1 件
治療	治療行為に関するミス	1 件
その他	書類作成に関するミス	1 件
検査	検査の実施に関するミス	2 件
転倒	患者の転倒	3 件
薬剤	薬剤投与に関するミス	5 件

3 実データを対象とした分析

3.1 対象データ

本研究では、2017 年 12 月から 2018 年 1 月の間の約 1 ヶ月の期間に東京都内のある病院の 2 病棟にて 55 名の看護師を対象に収集した業務行動データを用いた。データ収集時には、ビーコン遷移データを収集するための Bluetooth ビーコンを合計 297 個設置し、対象看護師全員に携帯端末として iPod Touch を所持・利用してもらった。看護師の位置情報は、Bluetooth ビーコンの信号を iPod Touch に内蔵されている iBeacon を用いて記録し、看護師の業務情報は、iPod Touch にあらかじめインストールしておいた aTimeLogger2¹ というアプリケーションを用いて記録した。aTimeLogger2 には、あらかじめ 24 種類の業務カテゴリと 94 種類の業務が設定してあり、図 5 に示すように、看護師が業務を行う前に実施する業務カテゴリと業務名をタップすることで記録が開始され、業務を終了する際に終了ボタンを押すことで記録が終了する。これらの方法で収集したデータの詳細を表 2 に示す。

このように収集したデータに対して、前述のデータ前処理により 55 名の看護師から勤務日数延べ 602 日分

のインシデント発生ラベル付き業務遷移データを作成した。また、表 3 に示すとおりデータ発生期間中に 13 件のインシデントが発生したが、発生カテゴリが転倒のインシデントのうち、患者が自ら行動した結果発生したインシデント 2 件は分析対象外とし、残りの 11 件を分析対象とした。さらに、業務名だけでなく業務カテゴリ名も記録されているため、業務遷移データと同じように業務カテゴリ遷移データを作成し、業務カテゴリ遷移パターンの抽出を行った。

3.2 分析目的

今回は、以下の 3 つの分析目的を設定した。

分析目的 1 インシデントを引き起こした看護師に関して、インシデント発生日とそうでない日を区別する業務遷移パターン、業務カテゴリ遷移パターンの抽出

分析目的 2 インシデント発生日とそうでない日を区別する業務遷移パターン、業務カテゴリ遷移パターンの抽出

分析目的 3 インシデントを引き起こした看護師とそうでない看護師を区別する業務遷移パターン、業

¹<http://www.atimelogger.com/>

表 4: 分析目的 1 における識別性能ごとの業務遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.182	1.000	11 パターン	1 パターン
0.182	0.667	7 パターン	1 パターン
0.091	1.000	1 パターン	8 パターン
0.000	0.000	73 パターン	18 パターン

表 5: 分析目的 1 における識別性能ごとの業務カテゴリ遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.182	1.000	2 パターン	0 パターン
0.182	0.182	5 パターン	7 パターン
0.091	1.000	1 パターン	417 パターン
0.000	0.000	45 パターン	169 パターン

務カテゴリ遷移パターンの抽出

なお、PrefixSpan, Modified PrefixSpan のパラメータは最小支持度を 2, 最大ギャップ数を 3 とし、決定木、ランダムフォレストの実装には scikit-learn² を用いた。

3.3 決定木によるパターン選択結果

3.3.1 分析目的 1

インシデントを引き起こした看護師に着目し、インシデントが発生した日とそうでない日を区別することができる業務遷移パターン、業務カテゴリ遷移パターンを抽出した。まず、インシデント発生日 11 日間の業務遷移データから業務遷移パターン、業務カテゴリパターンの抽出を行った。その結果、PrefixSpan によって 92 個の業務遷移パターンと 53 個の業務カテゴリ遷移パターンを抽出し、Modified PrefixSpan によって 28 個の業務遷移パターンと 593 個の業務カテゴリ遷移パターンを抽出した。その後、インシデントを引き起こした人 11 人の勤務日延べ 126 件を対象に、各遷移パターンの勤務日ごとの実施回数を集計し、個々の遷移パターンを用いて 11 日のインシデント発生日と 115 日のそれ以外の勤務日を分類する決定木を構築し、その精度を調べた。その結果を表 4 と表 5 に示す。表中の recall はインシデント発生日 11 日に対して正しく判別できた日数の割合、precision は判別したインシデント発生日のうち実際にインシデントが発生した日であった割合を指す。これらの結果から、業務遷移パターンと業務カテゴリ遷移パターンの両方で、インシデント発生日 11 日中 2 件を正しく判別できるパターン (recall が 0.182) が存在することが確認できる。

²<https://scikit-learn.org/stable/>

3.3.2 分析目的 2

分析目的 1 のインシデントを引き起こした看護師だけでなくそれ以外の看護師も対象とし、インシデントが発生した日とそうでない日を区別することができる業務遷移パターン、業務カテゴリ遷移パターンの抽出を行った。抽出できたパターン数は分析目的 1 と同じであり、分析目的 1 の場合と同様に構築した決定木における精度は表 6 と表 refres22 に示すようになった。これらの結果から、業務遷移パターンと業務カテゴリ遷移パターンの両方で、インシデント発生日 11 日中 2 件判別できるパターン (recall が 0.182) が存在することが確認できる。

3.3.3 分析目的 3

インシデントを引き起こした看護師と、インシデントを引き起こさなかった看護師を区別する業務遷移パターンの抽出を行った。まず、インシデントを引き起こした看護師の勤務日延べ 126 日の業務遷移データを対象に、業務遷移パターン、業務カテゴリ遷移パターンの抽出を行った。その結果、PrefixSpan によって 193,280 個の業務遷移パターンと 57,343 個の業務カテゴリ遷移パターンを抽出し、Modified PrefixSpan によって 4,625 個の業務遷移パターンと 18,588 個の業務カテゴリ遷移パターンを抽出した。そして、看護師ごとに各遷移パターンの実施回数を勤務日数で割った平均実施回数を算出し、インシデントを引き起こした 11 名の看護師と 44 名のその他の看護師を分類する決定木を構築し、その精度を調べた。結果を表 8 と表 9 に示す。表中の recall はインシデント発生者 11 人に対して正しく判別できた人数の割合、precision は判別したインシデント

表 6: 分析目的 2 における識別性能ごとの業務遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.182	1.000	2 パターン	0 パターン
0.182	0.667	1 パターン	0 パターン
0.091	1.000	0 パターン	3 パターン
0.000	0.000	89 パターン	25 パターン

表 7: 分析目的 2 における識別性能ごとの業務カテゴリ遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.182	1.000	0 パターン	0 パターン
0.182	0.667	0 パターン	1 パターン
0.091	1.000	0 パターン	230 パターン
0.000	0.000	53 パターン	362 パターン

表 8: 分析目的 3 における識別性能ごとの業務遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.455	1.000	3 パターン	1 パターン
0.364	1.000	1,338 パターン	3 パターン
0.273	1.000	15,109 パターン	38 パターン
0.182	1.000	67,516 パターン	777 パターン
0.091	1.000	41,066 パターン	2,161 パターン

表 9: 分析目的 3 における識別性能ごとの業務カテゴリ遷移パターン数

recall	precision	PrefixSpan	Modified PrefixSpan
0.364	1.000	263 パターン	5 パターン
0.273	1.000	2,276 パターン	124 パターン
0.182	1.000	11,983 パターン	3,110 パターン
0.091	1.000	11,228 パターン	8,862 パターン

発生者のうち実際にインシデント発生者であった割合を指す。なお、これらの表では precision が 1.00 以外となったパターンは割愛している。表 8 からインシデント発生者 11 人中 5 人を判別できるパターン (recall が 0.455)、表 9 からインシデント発生者 11 人中 4 人を判別できるパターン (recall が 0.364) が存在することが確認できる。

3.3.4 決定木分析結果の考察

分析目的 1 と分析目的 2 の識別結果を見ると、インシデント発生日 11 日中 2 日を区別することができたパターンが減少することが確認された。これは、インシデント発生日だけではなくそれ以外の日にも実施さ

れる業務遷移パターンが含まれていたことを意味する。分析目的 1 と分析目的 2 で共通するパターンとしては、業務遷移パターンでは「電カル入力・閲覧 申し送り・受け 点滴 輸液・シリンジポンプ 血圧 体温」「配膳・下膳 食事介助 口腔ケア」「尿量 / 血圧 / 体温」、業務カテゴリ遷移パターンでは「測定 測定 測定」「患者管理 / 看護師間調整 / * / 検査」が確認できた。「患者管理 / 看護師間調整 / * / 検査」のようなパターンは、インシデント発生日以外ではほとんど実施されておらず、インシデント発生日に特徴的なパターンと言える。今後、この業務手順とインシデントの発生の関係性をより詳細に調べる必要があると考えられる。また、「尿量 / 血圧 / 体温」や「測定 測定 測定」といったパターンは、インシデント発生日以外でも行われている業務手

順であるため、インシデントの発生にはその実施頻度が影響するものと考えられる。さらに、分析目的1でインシデント発生日11日中2日区別することができたパターン「浮腫観察・診察 / * / * / 血圧」は、浮腫観察・診察という患者の重症度を判断しなければならない緊張感を伴う業務内容であるため、このようなパターンとインシデントが結び付くのは理解ができる。

分析目的3において、インシデント発生者を判別することができたパターンを見ると、「食事の世話 食事の世話 食事の世話 測定 測定 測定 測定 患者管理 安楽 排泄の世話 安楽」「測定 / * / 測定 / * / 与薬 / 排泄の世話」「安楽 / * / 安楽 / * / 安楽」「食事の世話 / 身体の清潔 / * / 患者管理」といった食事の世話などの介護関係の業務を含んでいるパターンが多い傾向が分かった。これらの身体的に負荷の高い介護系業務と測定や与薬などの医療的援助を連続で複数の患者に実施していることがインシデントの発生に何らかの影響があると考えられる。

3.4 インシデント発生者予測モデル構築結果

ここでは、3つの分析目的に対する予測モデルの構築結果のうち、紙面の都合上、インシデントを引き起こした11人の看護師とそうでない44人の看護師を分類する分析目的3に対する結果についてのみ述べる。前述のように、予測モデルの構築にはランダムフォレストを利用した。特徴量としては、表8と9に含まれるパターングループを利用し、leave-one-out交差検証により性能を評価した。その結果、recallとprecisionの調和平均であるF値が最も高くなったモデルは、PrefixSpanにより抽出された業務カテゴリ遷移パターン263パターンを用いたものであり、そのprecisionは1.000、recallは0.545（11人中6人を正しく予測）であった。パターン1つずつのrecallは0.364（11人中4人を正しく予測）であったため、それよりも識別性能が上がったことが確認できる。また、予測モデル中で利用されたパターンを見ると、「食事の世話 食事の世話 食事の世話 測定 測定 測定 測定 測定 患者管理 排泄の世話」や「食事の世話 食事の世話 食事の世話 診療の介助 診療の介助」などのように、ここでも食事の世話や排泄の世話といった介護に関する業務が多く含まれていることが確認できた。これは、身体的に負荷の高い介護系業務と測定や与薬などの医療的援助を連続で複数の患者に実施していることがインシデントの発生に影響し得るという前述の考察と一致する結果であり、今後、これらの業務とインシデント間の関係性についてより詳細に調べる必要があると考えられる。

4 おわりに

本稿では、系列パターンマイニングを利用して抽出した看護師の業務手順とインシデントとの関係性を分析した。対象データが1ヶ月間のものであり、インシデント発生件数も少なかったものの、提案法により、インシデント発生日特有の業務・業務カテゴリおよびその実施順序を抽出し、それによりインシデントを引き越す可能性のある看護師の予測がある程度可能であることを実験的に示した。今後は、より期間の長いデータでの分析を進めるとともに、今回抽出した特徴的なパターンとインシデントの関係をより詳細に調べる必要がある。また、パターン抽出の条件設定や予測モデル構築時の特徴量の見直し、およびバイタルセンサ等を通して得られる看護師のストレス度の利用などが必要であると考えられる。

参考文献

- [1] 清水 佐知子, 大野 ゆう子, 岩佐 真他, 尾島 裕子, 林 剣煌, 富澤 理恵, 大西 喜一郎, 多杉 ふじゑ, 岡田 千鶴: タイムスタディによる看護業務プロセスの可視化, 生体医工学: 日本エム・イー学会誌, Vol. 48, No. 6, pp. 536-541 (2010).
- [2] 山田 憲嗣, 薄 雄斗, 武田 真季, 岡田 志麻, 清水 佐知子, 石井 豊恵, 中川 里恵, 松村 泰志, 野田 裕子, 永倉 俊明, 石原 謙, 大野 ゆう子: 看護業務を測る~無人タイムスタディ~, 生体医工学: 日本エム・イー学会誌, Vol. 48, No. 6, pp. 517-522 (2010).
- [3] 納谷 太, 大村 廉, 野間 春生, 小暮 潔: センサネットワークを用いた業務の計測と分析, 研究報告ユビキタスコンピューティングシステム, Vol. 2009, No. 24, pp. 1-8 (2009).
- [4] 磯田 達也, 井上 創造, 花沢 明俊, 野原 康伸, 白水 麻子, 杉山 康彦, 平田 真理, 町田 京子, 中島 直樹: 携帯センサと近接センサを用いた看護師業務分析, 情報処理学会論文誌, Vol. 57, No. 10, pp. 2197-2209 (2016).
- [5] 中村 美香, 近藤 浩子, 岩永 喜久子, 今井 裕子, 杉田 歩美, 須川 実枝子, 永井 弥生: 看護職がインシデント・アクシデントを繰り返す要因に関する研究, 北関東医学会, Vol. 66, No. 4, pp. 279-288 (2016).
- [6] 桜庭 恵, 河田 宏企子, 岸見 加奈子: 交代制勤務をしている病院勤務看護師のインシデント・アクシデントに影響する要因, 日本看護管理学会, Vol. 14, No. 1, pp. 42-50 (2010).
- [7] Pei, J., Mortazavi-Asl, B., Pinto, H., Chen, Q., Dayal, U. and Hsu, M: PrefixSpan: Mining sequential patterns efficiently by Prefix-Projected pattern growth, *Proc. 2001 Int. Conf. Data Engineering*, pp. 215-224 (2001).
- [8] Kitakami, H., Kanbara, T., Mori, Y., Kuroki, S., and Yamazaki, Y: Modified PrefixSpan Method for Motif Discovery in Sequence Databases, *Proc. of the 7th Pacific Rim International Conference on Artificial Intelligence*, pp.482-491 (2002).