一般口演

一般口演10
データマイニング・テキストマイニング

2017年11月21日(火) 16:00 〜 17:30 F会場 (10F 会議室1004-1005)

[2-F-3-OP10-4] 患者データに基づく入院患者の不穏予兆検知

大野 友嗣[1], 細井 利憲[1], 久保 雅洋[1], 清水 哲平[2], 森口 真由美[2] （1.日本電気株式会社, 2.医療法人社団KNI北原国際病院）

急性期病院に入院中の患者が不穏になると、看護師を始めとする医療スタッフはその対応に多くの時間を割かれるなど大きな負担が発生する。また、患者自身も、点滴や酸素カニューレの自己抜去で治療が遅延したり、転倒・転落による怪我が発生したりするなどのリスクがある。しかしながら、不穏発生に伴う負担増大やリスクなどの影響は定量化されてこなかったし、不穏の発生を事前に検知することはできなかった。そこで、不穏による影響の定量化と不穏の事前検知技術の確立を目指して、電子カルテデータの分析を行うとともに、患者データに基づく不穏の予兆検知技術の開発を行った。
通常、電子カルテには、不穏の詳細、例えば日々の変化などについては記述されていないことが多いことから、日々必ず記録される別の項目から不穏の発生状況を推定することとした。不穏患者に対しては、自己抜去や怪我のリスクを抑えるため、身体抑制が実施されたり、鎮静剤が投与されたりすることが多い。鎮静剤投与は実施毎に必ず記録されるし、身体抑制も定期的に記録が行われる。そこで、「抑制」や「鎮静剤投与」の実施が「不穏」と相関していると仮定し、その影響を推定することとした。北原国際病院（脳神経外科・循環器内科・神経内科）にて2015/6/1から1年間分の電子カルテデータについて、個々の抑制が実施された患者群、鎮静剤投与が実施された患者群、抑制または鎮静剤投与が実施された患者群を分析した結果、いずれかの抑制または鎮静剤投与が実施された患者群が不穏患者と相関があることがわかった。不穏による影響の一つとして、患者の治療遅延や退院遅延を分析した結果、1週間までの実施による影響は小さいが、1週間を超える実施は大幅な退院遅延に繋がっている。これらの電子カルテデータ分析と合わせて、患者データに基づく入院患者の不穏予兆検知技術を開発した。

©一般社団法人 日本医療情報学会

患者データに基づく入院患者の不穏予兆検知

大野　友嗣[*1]、細井　利憲[*1]、久保　雅洋[*1]、清水　哲平[*2]、森口　真由美[*2]
*1 日本電気株式会社 データサイエンス研究所、*2 医療法人社団ＫＮＩ 北原国際病院

Predictive detection of hospitalized patient agitation based on patient data

Yuji Ohno[*1], Toshinori Hosoi, Masahiro Kubo, Teppei Shimizu, Mayumi Moriguchi
*1 Data Science Research Laboratories, NEC Corporation, *2 Kitahara International Hospital

Medical staff such as nurses are inflicted a heavy burden to treat agitated patients hospitalized in an acute hospital. Also, patients themselves are at risk of delay of treatment due to self-withdrawal of intravenous infusion or oxygen cannula, and injury due to falling to the floor and falling off the bed. However, the burden increase and the injury risk due to the patient agitation have not been quantified, and it was difficult to detect in advance the occurrence of agitation to reduce the burden and the risk. To quantify the influence of the patient agitation and to detect predictively the patient agitation, we analyzed the electronic medical record and examined predictive detection of the agitation based on patient data. As a result, we found that the group of patients who were equipped with any medical restraint or to whom sedative medicines were administered was correlated with agitated patients. As one of the negative effects of the agitation, the agitation exceeding one week leads to discharge delay from hospital. We extracted parameters that correlate with agitation from the electronic medical records by a data mining technique and developed a prediction procedure for the agitation by a machine learning technique, generalized learning vector quantization.

Keywords: agitation, prediction, data mining, electronic medical records, machine learning

1 緒論

急性期病院に入院中の患者が、せん妄発生[1-4]などで不穏になると、看護師や介護士などの医療スタッフは、その対応に多くの時間を割く必要があるなど大きな負荷が発生する。また、患者自身も、点滴や酸素カニューレの自己抜去により治療が遅延したり、転倒・転落による怪我が発生したりするなどのリスクが大きくなる。しかしながら、不穏は詳細には記録されてはいないことが多いため、不穏発生に伴う負荷やリスクの増大などの影響の定量化は困難であった。また、負荷やリスクを低減させるために、患者の不穏発生を予測し、事前に対応することはできなかった。

そこで、不穏による影響の定量化のために電子カルテデータの分析を行うとともに、不穏予兆検知を検討した。

2 目的

医療スタッフ負荷や患者治療遅延リスクの低減を目指し、不穏による影響の定量化と不穏予兆検知技術の確立を目的とした。

3 方法

電子カルテデータを分析し、不穏の影響を定量化した。また、分析結果を元に不穏に影響を与える指標を抽出し、不穏予兆の検知を検討した。

3.1 不穏による影響の定量化

通常、電子カルテには、不穏の詳細、例えば日々の変化や正確な発生時刻などについては記述されていないことが多い。そこで、日々必ず記録される別の項目から不穏の発生状況を推定することとした。急性期病院に入院中の不穏患者に対しては、自己抜去や怪我のリスクを抑えるため、身体抑制がなされたり、鎮静剤が投与されたりすることがある。鎮静剤投与は実施毎に必ず記録されるし、身体抑制も定期的に（1日に3回）記録される。

そこで、「抑制」や「鎮静剤投与」の実施が「不穏」と相関していると仮定し、その影響を確認した。具体的には、抑制や鎮静剤投与が実施される日数が入院期間や治療期間に与える影響を分析した。

北原国際病院に入院した患者の約1年間分の電子カルテデータについて、抑制や鎮静剤投与が実施された患者群を分析した。抑制の拘束力の違いによる影響があると考え、抑制は種類の異なる複数のケースに分けた。詳細を下記に示す。

・対象施設：医療法人社団 KNI 北原国際病院
　　（脳神経外科・循環器内科・神経内科）
・対象期間：2015/06/01-2016/07/31
・対象データ数：1,586 件
・出力：各ケースにおける「治療期間」の総日数および「入院期間」の総日数
　-ケース1：体幹抑制
　-ケース2：体幹抑制または上肢抑制または下肢抑制
　-ケース3：いずれかの抑制（体幹、上肢、下肢、ミトン等）
　-ケース4：鎮静剤投与
　-ケース5：いずれかの抑制または鎮静剤投与
・除外条件：「治療期間」が 0 日の患者
　　（検査入院などの影響を除外するため）

ここで、各項目の定義を下記に示す。

・実施日数：入院期間中に抑制または鎮静剤投与が実施された総日数
・治療期間：脳疾患治療に関連した薬剤が継続的に投与（24時間以内に再投与）された期間または入院から3日目以内で鎮静剤が投与された期間のうち、長い期間
・平均治療期間：実施日数が同じ患者数で除した治療期間
・入院期間：退院日から入院日を引いた期間
・平均入院期間：実施日数が同じ患者数で除した入院期間

3.2 不穏予兆検知

3.1 で得られた不穏患者群について、データマイニングにより不穏と相関が強いパラメータを抽出した。その後、パラメータを継続的に収集し、解析することで、不穏予兆を検知で

きるかを検討した。

4 結果

4.1 不穏による影響の定量化

電子カルテデータから得られた実施日数と、平均入院期間および平均治療期間との関係のうち、ケース3～5における結果を図1～3に示す。平均入院期間および平均治療期間を丸、平均入院期間、平均治療期間に対する各々の 2 次関数での近似曲線を点線で示している。また、ケース1～5における入院期間と治療期間の抽出結果を表1～表5に示す。ここで、下記のように定義した。

短期間:3日以内

中期間:4日以上7日以内

長期間:8日以上

R^2:近似曲線の決定係数

$$R^2 = 1 - \frac{\sum_i (y_i - f_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (1)$$

抽出値を y、近似値を f とした。$\bar{y}$は平均値である。

いずれのケースにおいても、実施日数が長くなればなるほど平均入院期間は長くなる傾向がある。一方、実施日数が長くなっても、平均治療期間にはそれほど大きな遅延は見られない。

ケース1～5の平均入院期間の結果を比較すると、決定係数 R^2 の大きさ(近似曲線に対する一致度の高さ)から、ケース5の「いずれかの抑制もしくは鎮静剤投与」の長期間実施が、不穏の発生との関連が強い。すなわちケース5が、不穏発生の検証に適していると考えられる。

結果を以下に整理する。ここで、中期間を誤差とみなした。

不穏患者割合:長期間の抑制や鎮静剤投与が実施される患者、すなわち長期的に不穏になった推測される患者の割合は入院患者全体の 34±5%。

治療遅延:長期不穏患者はその他の患者と比べて 1.6±0.3 日だけ遅延した。長期間の実施による影響は大きくはない。

退院遅延:1 週間以内の実施では入院期間に大きな差異はない。一方、1 週間を超える実施では、退院遅延に繋がる。長期不穏患者はその他の患者と比べて 19.0±2.4 日だけ遅延した。

4.2 不穏予兆検知

長期不穏患者群について、特に夜間帯の不穏発生状況の分析から、不穏と相関が強いパラメータを抽出した。その結果、特に不穏と相関が強いパラメータとして、患者のバイタルデータ(心拍数や血圧など)の変動が挙げられた。そこで、バイタルデータのうち、自律神経や生体リズムと相関があると考えられ、かつ経時的な変化を取得しやすい心拍数と体温を計測対象として、不穏予兆検知の検討を進めた。

以下の手順で分析を進めた。

(1) 患者のバイタルデータ収集

入院患者 9 人分の約 140 時間分のバイタルデータを収集した。

(2) 不穏／静穏ラベル付け

患者の状況に応じて、時間帯毎に不穏ラベルおよび静穏ラベルを付けた。

(3) 特徴量設計

バイタルデータに種々のフィルタ(時区間の平滑化フィルタおよび微分フィルタ等)を通し、30 秒毎に 500 次元の特徴量ベクトルを生成した。

(4) 機械学習による不穏／静穏の識別

500 次元の特徴量ベクトルと不穏／静穏ラベルに基づいて識別器を学習させ、不穏／静穏を識別した。不穏／静穏の識別率の結果を表6に示す。

まず線形ロジスティック回帰を用いて不穏/静穏の 2 クラスを学習・識別した。その結果、特定の患者 A では異なる複数日のデータであっても適切に識別されたが、別の患者 B や、患者数を増やすと識別率が向上しなかった。また、140 時間分のデータを対象とした場合の識別率は 70%程度であった。

ところで、特徴量を可視化して目視分析した結果から、患者個人によって不穏予兆の傾向が異なり、かつ患者グループ別にクラスタを形成しやすい傾向が予想された。そこで、クラスタを内部表現できる一般化学習ベクトル(Generalized Learning Vector Quantization, GLVQ)[5-6]を用いて識別器を学習した。その結果、識別率を向上させることに成功し、140 時間分のデータ数であっても識別率は 94%に達した。

(5) 学習した識別器に基づく不穏予兆検知

学習した識別器とバイタルデータから不穏予測スコアを算出し、不穏予兆検知可能性を検証した。不穏予兆検知の評価結果の事例を図4に示す。実線は患者が実際に不穏となった時間帯である。点線は識別器とバイタルデータから算出した不穏予測スコアである。破線が不穏予測の判定結果である。図4(a)の 4:00-4:30 や、(b)の 1:00-2:30 など実際の不穏時間帯の前に不穏予兆を検知できている時間帯があるという結果を得ることができた。

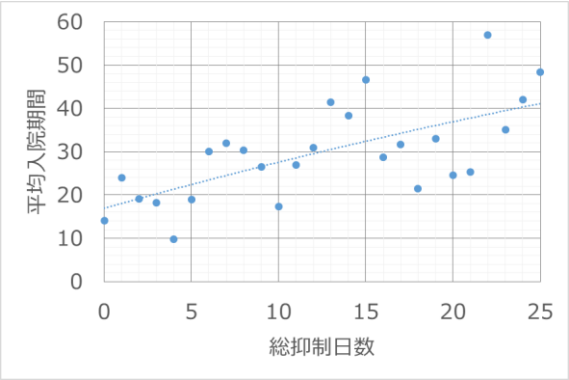

(a)実施日数と平均入院期間との関係

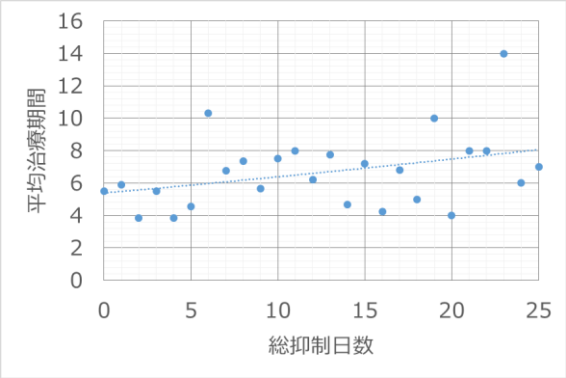

(b)実施日数と平均治療期間との関係

図1 ケース3における入院期間および治療期間

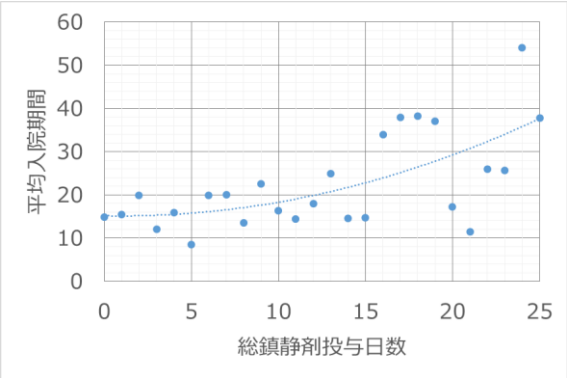

（a）実施日数と平均入院期間との関係

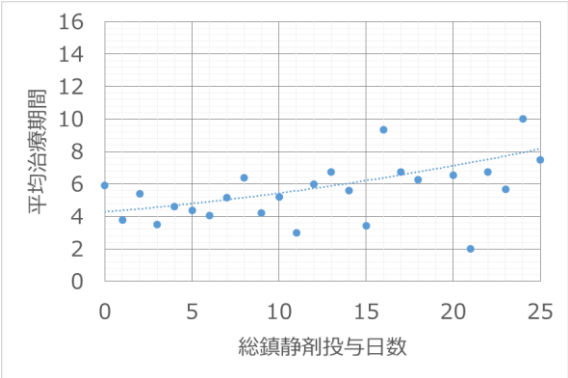

（b）実施日数と平均治療期間との関係

図2　ケース4における入院期間および治療期間

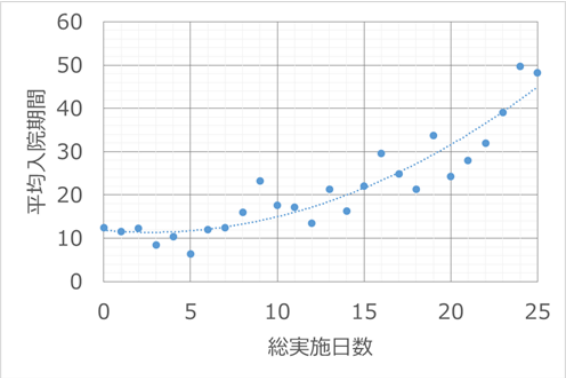

（a）実施日数と平均入院期間との関係

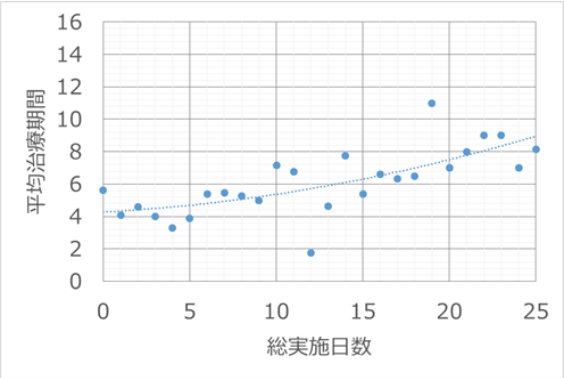

（b）実施日数と平均治療期間との関係

図3　ケース5における入院期間および治療期間

表1　ケース1における入院期間と治療期間の抽出結果

	割合	入院期間(日)	治療期間(日)
全体	100%	18.7	5.8
短期間	81%	15.9	5.6
中期間	6%	20.4	5.9
長期間	13%	35.0	6.6
R^2		0.604	0.159

表2　ケース2における入院期間と治療期間の抽出結果

	割合	入院期間(日)	治療期間(日)
全体	100%	18.7	5.8
短期間	79%	15.3	5.5
中期間	7%	25.5	6.8
長期間	14%	35.2	6.7
R^2		0.441	0.128

表3　ケース3における入院期間と治療期間の抽出結果

	割合	入院期間(日)	治療期間(日)
全体	100%	18.7	5.8
短期間	75%	13.8	5.4
中期間	6%	16.0	5.0
長期間	19%	38.8	7.5
R^2		0.644	0.283

表4　ケース4における入院期間と治療期間の抽出結果

	割合	入院期間(日)	治療期間(日)
全体	100%	18.7	5.8
短期間	70%	15.2	5.5
中期間	8%	14.7	4.6
長期間	22%	31.7	7.1
R^2		0.421	0.175

表5　ケース5における入院期間と治療期間の抽出結果

	割合	入院期間(日)	治療期間(日)
全体	100%	18.7	5.8
短期間	61%	12.3	5.3
中期間	10%	12.5	4.4
長期間	29%	34.6	7.3
R^2		0.865	0.516

表6 不穏/静穏の識別率の結果

データ時間（対象人数）	GLVQ	線形ロジスティック回帰
30（患者 A）	96%	91%
30（患者 B）	94%	71%
80（3 人）	94%	73%
140（9 人）	94%	71%

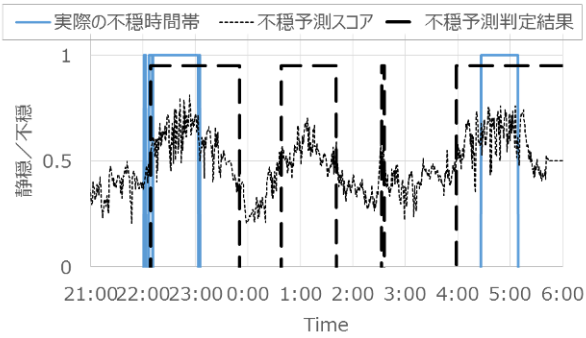

(a) 患者Aの結果

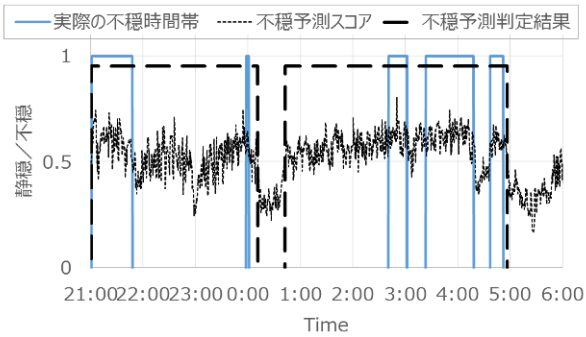

(b) 患者Bの結果

図4 学習した識別器に基づく不穏予兆検知の評価結果

5 考察

電子カルテデータ分析の結果、長期間の抑制または鎮静剤投与が実施される患者、すなわち長期的に不穏になったと推定される患者は、治療とは関係ない理由により、退院が遅延しているという結果になった。不穏が退院遅延に繋がる要因の多くは、転院先候補の受け入れ拒否などで転院調整が長引くことだと思われる。不穏の影響でリハビリが進まず、当初想定よりも体力が低下、転院先の変更のために退院が長引いた事例もあった。不穏を早期に検知し、適切にコントロールすることができれば、転院調整がスムーズに進み、早期退院に繋がる可能性がある。

不穏予兆検知に関しては、学習した識別器とバイタルデータからの検知可能性を示した。本結果では、バイタルデータのみを用いて不穏予兆を検知していることから、看護師が該当患者に接していなくても気付きに繋がることに価値があると考えられる。例えば、看護師が他の患者に対応していたり、消灯後であったりしても、不穏患者の早期発見に繋がる。不穏患者に対して早期にかつ適切に対応することで、問題の発生を抑えられ、医療スタッフ負荷と患者退院遅延の抑制に繋がると考えられる。

今後は、不穏予兆検知率向上に向けて、データ数を増強させていく必要がある。また、今回用いたバイタルデータ（心拍数、体温）以外のデータも用いて識別器を学習することにより、検知率向上に繋がると想定される。

6 結論

北原国際病院（脳神経外科・循環器内科・神経内科）の電子カルテデータの分析の結果、いずれかの抑制または鎮静剤投与が実施される患者群は、不穏患者との相関があると考えられる。長期的に不穏になったと推定される患者の割合は入院患者全体の 34±5%であった。長期不穏による影響は、治療遅延では小さい（長期不穏患者はそれ以外の患者と比べて 1.6±0.3 日遅延）が、退院遅延では大きい（長期不穏患者はそれ以外の患者と比べて19.0±2.4 日遅延）という結果を得た。

長期不穏患者群の分析から、不穏と相関が強いパラメータとして、患者のバイタルデータの変動を確認した。患者のバイタルデータ（心拍数、体温）から特徴量ベクトルを生成し、一般学習ベクトル量子化 GLVQ を用いて不穏/静穏を学習・識別した。この結果、不穏/静穏の識別率が 94%に達した。また、識別器とバイタルデータを用いることでの不穏予兆検知の可能性を示した。本結果は、医療スタッフや入院患者にとって有意義な取組に繋がると考えられる。

文献

1) 粟生田友子. 高齢者せん妄のケア. 日本老年医学会雑誌 2014; 51: 436-444
2) 小田陽彦. せん妄の機序, 臨床麻酔 2015; 39: 1627-1633
3) 加藤弘美, 土井松幸. ICU におけるせん妄. 臨床麻酔 2015; 39: 1636-1642
4) 石田和慶, 山下敦生, 山下理, 歌田浩二, 松本美志也. 術後せん妄. 臨床麻酔 2015; 39: 1645-1652
5) 佐藤敦, 山田敬嗣. 一般学習ベクトル量子化による文字認識. 信学技報 1996; 95: 23-30
6) A. Sato, K. Yamada. Generalized Learning Vector Quantization. NIPS 1995: 423-429