

# 機械学習を用いた電子カルテの解析による院内転倒予測アルゴリズムの作成



学校法人 大阪医科薬科大学  
高槻中学校 高槻高等学校

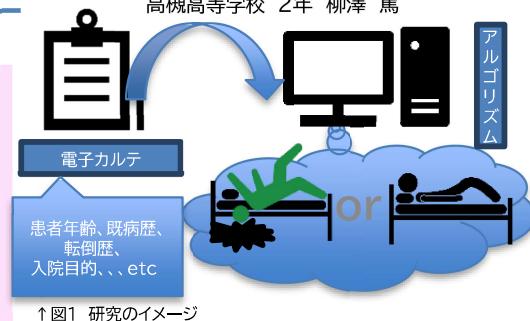
高槻高等学校 2年 柳澤 篤

## 目的

- 入院患者における転倒・転落(以下転倒)は、骨折や死亡などの重大なアクシデントに至る可能性があり、転倒予防対策は医療安全管理上の最重要課題の一つとなっている(参考文献1,2)
- 大阪医科薬科大学病院では、医者と看護師が転倒を防ぐために患者一人一人に対して転倒リスクを評価し防止策を講じているが、転倒リスクが小さいと判断された患者が転倒してしまうケースも少なからずみられる。
- 企業が看護記録を元に自然言語解析AIを用いて転倒予測システムを開発した例はみられるが、1年分の看護記録を提出する等の準備が必要である。
- 今回の研究では、過去の電子カルテデータの蓄積を必要とせず転倒リスクを予測するアルゴリズム<sup>[注1]</sup>の開発を目指した。

目的: 転倒という、様々な要因によって引き起こされる重大なアクシデントを予測するアルゴリズムを電子カルテデータから機械学習を用いて作成する。

[注1]: アルゴリズムとモデルには様々な定義があるが、今回は機械学習で生成された予測器をモデルとし、その予測器を可視化したもの、転倒のリスクを評価するとときに至るプロセスをアルゴリズムと呼ぶこととする。



↑図1 研究のイメージ

## 対象データと研究方法

### ・対象データ

2014年から2018年の5年間で大阪医科薬科大病院で入院した患者の電子カルテ、91423名(うち病院内での転倒者数1162名<sup>[注2]</sup>)  
(①年齢が20歳以下<sup>[注3]</sup>、②電子カルテが作成された当時退院していない患者<sup>[注4]</sup>を除いた)

### ・研究方法

#### I 単变量解析

単变量解析から、予測モデルに用いる変数の検討をする。<sup>[注5]</sup>

I-1離散値の場合:転倒した患者と転倒していない患者に分けてその説明変数に対応する患者の数をカウントする。

I-1連続値の場合:転倒した患者と転倒していない患者に分けて平均値、中央値を求める。分布を可視化する。

I-2以下の条件に基づいて使用する説明変数を選択する。

#### 離散値の場合

①転倒した患者の5%以上が当てはまる。②その説明変数に当てはまる患者のうち2~5%以上が転倒した患者である。<sup>[注6]</sup>

#### 連続値の場合

①転倒した患者と転倒しなかった患者との分布の差が大きい(平均値、中央値、分布図からほかの使用できる連続値と比較し判断した)。

#### II 多变量解析

用いるデータをテストデータ:訓練データ=2:8に分ける。訓練データから、EFS<sup>[注7]</sup>、決定木<sup>[注8]</sup>を用いてモデルを作成する。決定木は、使用する閾数と層の深さを変えた。

使用する説明変数は全て相関がないことを確認した。

また、訓練データに対してはRandom Under Samplingを使用して転倒した患者のデータと転倒していない患者のデータ数が等しくなるように調整した。

これらの実験を用いるデータを変えながら行う。(Ex.立位(まっすぐ立つこと)が出来る患者のみを使用する。)

[注2]: 医療統計では成人している患者での場合と成人していない患者とで分けて解析を行うのがふつうである。(Ex.参考文献3)高齢など起こりやすい転倒を予測する今回の研究では、成人した患者のデータのみを用いて実験を行った。

[注3]: 今回は実際の入院期間を考慮せずに研究を行ったため、本来なら退院しているかどうかはデータを使用するかどうかの条件には組み込まれない。ただ、入院している患者はその後転倒する可能性があり、転倒の有無が本来のものとづれる可能性を排除するために、今回は条件に組み込んだ。

[注4]: 今回は、Gibsonの転倒の定義(参考文献4)に該当しなかつて身体的外傷を負った行為を転倒とみなす。これは患者が身体的外傷を負わない、Gibsonの定義に沿った行為をした場合看護師に報告しない可能性等を排除するためである。

[注5]: 使用する説明変数を制限する的是以下の3つの根拠に基づく。1オッカムの剃刀という経験則EFS(後述)を使用する際に約20種類以上の説明変数を用いるとプログラムの処理に時間がかかるという技術的問題が発生するため、3機械学習アルゴリズムを生成する際に使用する説明変数が転倒と相関があるということを統計的に裏付けるため。

[注6]: 転倒した患者が1人、2人だと、転倒したのがその説明変数によるものであるか判断できないため、①の条件を付けた。②の条件は転倒した患者が全体のデータに占める割合はおよそ1.3%であるため、2%以上含まれている説明変数は転倒とある程度相関があると判断した。実験データを分割する中でこの割合は変動するが、2%を超えることはほとんどなかったため、数値を変更しなかった。③に関しては入院するとときに転倒リスクを評価することを目標としているために、この条件を付けた。しかし、①②の具体的な数値は數学的な根拠がなく、先例がないもの実事である。

[注7]: Exhaustive Feature Selectorの略。説明変数の全組み合わせを試して最も性能が高くなった組み合わせを調べる方法。今回EFSを使用した理由としては、①決定木を使用したため過剰適合をする可能性が高く(参考文献5)それを防ぐため、②単变量解析から得られた説明変数を最大限使用するため。[注8]: 決定木を使用したのは、①過学習を防ぐため、②モデルを可視化しやすいため。

## 結果

### 单变量解析で条件を満たした説明変数

#### I すべての説明変数を使用した場合

連続値(5種類):身長、患者年齢、推定期間、など

離散値(8種類):入院目的、病状改善など

#### II-①立位可能な患者のデータ

連続値(5種類):身長、患者年齢、推定期間など

離散値(8種類):入院目的、病状改善など

#### 多变量解析の結果

表1 全ての患者のデータの場合

評価値	結果	比較用
F値(テストデータ) <sup>[注9]</sup>	0.71	0.71
再現値(テストデータ)	0.86	0.90

表2 立位可能な患者のデータの場合① 立位不可能な患者のデータの場合②

評価値	結果	比較用	結果	比較用
F値(テストデータ)	0.74	0.65	0.75	0.43
再現値(テストデータ)	0.88	0.47	0.95	0.61

比較用:病院内で実際に使用されているアルゴリズムにおいて転倒リスクの判断の際に使用される説明変数で構成されたデータで同様の実験を行ったときの結果。

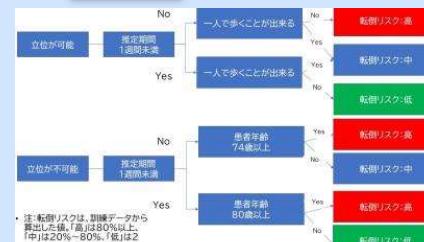
表2での実験で使用された患者のデータは、どちらとも医療者の指示を理解し行動できると判断された患者患者のデータである。

[注9]: これは転倒患者の予測を第一とした訳ではない。転倒患者のうちモードが転倒した患者だと判断した割合を表す再現値を重視する必要がある。しかし、再現値だけでは、モデルが与えられた情報を使用して患者の転倒の有無を判断しているかわからない。そのため、実用的なアルゴリズムの作成と目標とする今回の研究では適合値も重視しなければならない。EFSは一つの評価値を用いて性能の評価を行うので、再現値、適合値の情報を含むF値を主に精度の基準となる評価値とした。

[注10]: こうした分割は大阪医科薬科大学病院で採用されている既存のアルゴリズムに從っている。既存のアルゴリズムに依存するは、転倒患者のリスク別の分布を調べ既存のアルゴリズムがある程度機能していると判断したためである。適切にデータを分割して、比較用のデータ(=既存のアルゴリズム)よりも精度の高いモデルの生成を目指す。医療者の指示を理解し行動できると判断された患者に適切な結果を得るために、基準をあえて高くとった結果と考えられる。

結果: 使用する患者のデータを制限することで、精度が高く、既存のアルゴリズムよりも簡易的なモデルを生成することが出来た。今後は、一つの病院の入院患者だけでなく、複数の病院の入院患者といったもっと多くの人に対応できるアルゴリズムの作成が必要である。

II-②立位不可能な患者のデータ  
立位可能  
No  
一人で歩くことが出来る  
Yes  
一人で歩くことが出来る  
No  
患者年齢 74歳以上  
Yes  
患者年齢 80歳以上



↑図2 最終的な転倒予測アルゴリズム  
(表2と同じ条件で生成されたモデルを可視化したもの)  
医療者の指示を理解し行動できると判断された患者に適合される

↑図3:現在大阪医科薬科大学病院で使用されている既存のアルゴリズム(一部抜粋)

## 考察、結論

・アルゴリズムを生成する際に使用された説明変数は全て先行研究で転倒との関連が報告されているものである。そのため医学的にもこのアルゴリズムは現実でも正しく機能すると推測できる。また、推定期間1週間未満(入院期間が短い)なら患者年齢80歳以上だと転倒リスクが高く、推定期間1週間以上(入院期間が長い)なら74歳以上で転倒リスクが高くなる、ようく一般論と比較して矛盾のない結論が導かれた。また、既存のアルゴリズムは独歩が可能か否かや立位可能か否かや転倒の往来といったたくさんの判断基準をと使用したために過剰適合を引き起こし、精度が今回の実験で生成されたアルゴリズムよりも低くなつたと考えられる。

・単变量解析による説明変数の選択により、選択された説明変数が、“リスク薬剤の使用”、“患者年齢”というように転倒と相関があることが分かり、これは参考文献3と一致するため、正しく機能していると考えられる。他の転倒と相関があると考被される説明変数が使用されなかつたのは使用された説明変数より相関がなかつたためだと考えられる。

・既存のアルゴリズムでは65歳以上か否かが転倒リスクの判断基準にかかわっていたが、今回生成されたアルゴリズムにおいては、それが74歳以上、80歳以上か否かになつている。70歳以上の患者が転倒する傾向があると報告する研究(参考文献6)が見られたが、それに比べてもこれは大きい数値である。これは、実際には65~74歳でも転倒する患者が見られたがF1値を訓練データ時の評価値としていたので、適合値を高める為に、基準をあえて高くとつた結果と考えられる。

結論: 使用する患者のデータを制限することで、精度が高く、既存のアルゴリズムよりも簡易的なモデルを生成することが出来た。今後は、一つの病院の入院患者だけでなく、複数の病院の入院患者といったもっと多くの人に対応できるアルゴリズムの作成が必要である。

謝辞: 本研究を行うにあたり、井上敦司先生(三重大学)、上田英一郎先生(大阪医科薬科大学病院)、畠井生先生(大阪医科薬科大学病院)、Chintaka Premachandra先生(芝浦工業大学)、川中 普晴先生(三重大学)らに多大なご助力を頂きました、ありがとうございました。

実験手法に関するアドバイスを下さった三重大学の今村一也さんありがとうございました。本研究は、株式会社スピーディ(<http://spdy.jp/>)の資金援助を受けています。代表取締役社長の福田淳氏に感謝いたします。

SSHの課題研究の一環として支えてくれた高槻高校の大木徹先生、落田綾先生、長尾優子先生、向井透先生ありがとうございました。

参考文献

①Theander E. Activities of daily living decrease similarly in hospital-treated patients with a hip fracture or a vertebral fracture: a one-year prospective study in 151 patients.

②医療事故調査・支援センター「医療事故調査・支援センター第9号、入院中に発生した転倒・転落による頭部外傷による死傷事例の分析」

③鈴木隆司. 2003. 転倒の疫学. 日本老年医学会誌 40: 85-94.

④ラムネオランボンサインを含めた睡眠障害の服用と転倒への影響. 2020. 石川友之.

⑤Gibson MJ. The prevention of falls in later life. A report of the Kelllogg International work group on the prevention of falls by the elderly. Danish Medical Bulletin 1987; 34(Suppl.4):1-24.

⑥Pythonによる機械学習(オライリー社、Andreas C.Muller)⑦当院における院内転倒の現状. 永井 新二, 横山 良樹, 2004

⑧Medical Incident Prediction Through Analysis of Electronic Medical Records Using Machine Learning "Fall Prediction" Atsushi Yanagisawa, Chintaka Premachandra, Hiroharu Kawanaka, Atsushi Inoue Takeo Hata, Eiichiro Ueda