

ポスター

[PB1～PB19] ポスター

2018年6月23日(土) 15:00～16:00 ポスター会場 (3階・中会議室302)

---

[PB5] フィードフォワードニューラルネットワークを用いた高齢者の転倒予測モデルの開発と検証

有阪 直哉（北里大学）

# フィードフォワードニューラルネットワークを用いた 高齢者の転倒予測モデルの開発と検証

有阪 直哉<sup>\*1</sup>, 菊地 和則<sup>\*2</sup>, 鶴田 陽和<sup>\*2</sup>, 稲岡 秀検<sup>\*1</sup>, 河合 恒<sup>\*2</sup>, 平野 浩彦<sup>\*3</sup>, 小島  
基永<sup>\*4</sup>, 藤原 佳典<sup>\*2</sup>, 井原 一成<sup>\*2</sup>, 大淵 修一<sup>\*2</sup>

<sup>\*1</sup> 北里大学, <sup>\*2</sup> 東京都健康長寿医療センター研究所, <sup>\*3</sup> 東京都健康長寿医療セン  
ター, <sup>\*4</sup> 東京医療学院大学

## Development and Verification of Prediction Model of Fall for Older Adults using Feedforward Neural Network

Naoya Arisaka<sup>\*1</sup>, Kazunori Kikuchi<sup>\*2</sup>, Harukazu Tsuruta<sup>\*2</sup>, Hidenori Inaoka<sup>\*2</sup>,  
Hisashi Kawai<sup>\*2</sup>, Hirohiko Hirano<sup>\*2</sup>, Motonaga Kojima<sup>\*2</sup>, Yoshinori Fujiwara<sup>\*2</sup>,  
Kazushige Ihara<sup>\*2</sup>, Shuichi Obuchi<sup>\*2</sup>

<sup>\*1</sup> Kitasato University

<sup>\*2</sup> Tokyo Metropolitan Institute of Gerontology

<sup>\*3</sup> Tokyo Metropolitan Geriatric Hospital

<sup>\*4</sup> University of Tokyo Health Sciences

抄録: 高齢者の転倒は寝たきりにつながるなど QOL を著しく低下させる可能性がある。本研究では、データの内部構造や多重共線性など説明変数の関係に影響なく予測モデルを自動的に獲得できるフィードフォワードニューラルネットワーク(FNN)を用いて、2011年コホートデータから翌2012年の転倒の予測が可能か検証を行った。先行研究では感度 0.651、特異度 0.724 に対し FNN ではカットオフ 0.53 で感度 0.778、特異度 0.714 となった。ROC 曲線下面積(AUC)は 0.662(SD:0.067)となり、判別能を有していることが確認された。

キーワード 高齢者、転倒予測、機械学習、ニューラルネットワーク、FNN

## 1. 背景・目的

### 1) 高齢者の転倒を予測する意義

東京消防管内における高齢者の日常生活事故のうち、転倒は 81.5%と高い割合を占める[1]。また骨折・転倒は要介護となった原因のうち 12.2%である[2]。転倒は高齢期の QOL を著しく低下させ、「寝たきり」とさせる可能性があり、予防対策を講じなければならない状況である[3]。

### 2) 機械学習を用いる理由

フィードフォワードニューラルネットワーク(FNN)はデータの多重共線性など説明変数の関係に左右されずにデータの特徴を獲得できる。そのため、データを精査する必要がない上、条件を満たせば高い予測性能が期待できる。しかし、これまで転倒の予測モデルを開発するのに FNN を利用した研究は、私たちの知る限り見当たらない。

## 3) 目的

FNN を用いて高齢者の将来の転倒を予測できるか検討する。本研究では過去のコホートデータから翌年の転倒の有無を予測する。

## 2. 方法

### 1) データセットの作成

解析に用いる「お達者健診 2011年コホートデータ」(以下、解析データ)は身長体重、既往歴や心身の健康調査アンケート、認知機能検査(MMSE、MoCA)など説明変数 357 個のコホートデータである。サンプルサイズは  $N=514$ 、そのうち転倒ありが  $n=108$ 、転倒なしが  $n=406$  である。このデータを、学習用データ( $n=412$ )、学習には用いない評価用データ( $n=102$ )にリサンプリングしたデータセットを 5 パターン作成し(fold 0~4)、5 分割交差検証を行った。

## (1) 比較用データセット

解析データには、目的変数に影響が強いと考えられる「この1年間に転んだことがありますか?」という質問が含まれているため、これを除いたもの(without\_fall データセット, 説明変数 356 個)と含むもの(with\_fall データセット, 説明変数 357 個)の2種類を作成した。

## 2) モデルと評価

翌年の転倒あり、なしの2値を予測する分類FNNモデルとした。ハイパーパラメータは、グリッドサーチでチューニングを行った。モデルの評価は評価用データに対するROC曲線とその曲線下面積(AUC)から行なった。また、ROC曲線からYouden Indexでカットオフポイントを求めて感度、特異度を得た。

### (1) 開発環境

モデルの作成、学習、予測にはTensorFlow1.4を使用した(Ubuntu16.04 LTS, GTX-1080Ti)。

Table.1 モデルの予測性能

	Refacence[4]	with_fall	without fall
Cutoff	2/3	0.517	0.530
Sensitivity	0.651	0.854	0.778
Specificity	0.724	0.375	0.714
AUC	-	0.676 (SD:0.021)	0.662 (SD:0.067)

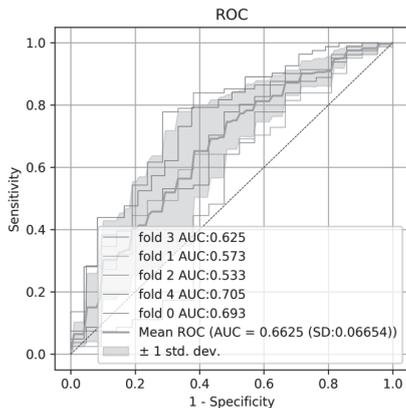
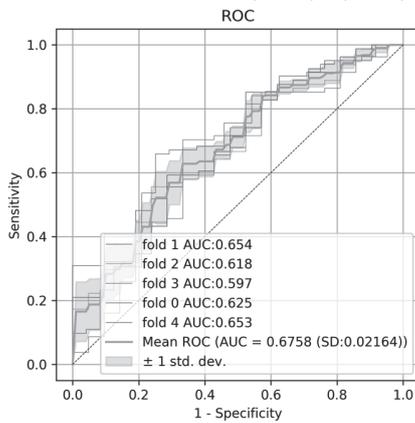


Fig.1 ROC と AUC

## 3. 結果

with\_fall では、fold 3 パターンでカットオフポイント 0.517 で感度 0.854、特異度 0.375、平均 AUC は 0.676 (SD:0.021) となった。without\_fall では、fold 0 パターンでカットオフポイント 0.530 で感度 0.778、特異度 0.714、平均 AUC は 0.662 (SD:0.067) となった (Table.1)。

## 4. 考察

AUC の平均値は、過去の転倒有無データが含まれている with\_fall の方が当然高かったが、どちらのデータセットも平均 0.65 を超え、転倒有無データを含まない without\_fall でも一定の判別能を得た。先行研究[4]と比較し、どちらのデータセットも感度が高い結果を得た。また、with\_fall の方が AUC のばらつきが小さくなった。

今回使用したデータセットは、機械学習の対象としてはデータ数が少ないため別の地区のコホートデータと統合してデータ数を増やすことによりモデルの性能と信頼度を上げること、ならびに、転倒するかどうかは偶然の要素があるため、複数回転倒を目的変数とし、偶然性により左右されない指標をアウトカムとすることを、検討している。

## 参考文献

- [1] 救急搬送データからみる日常生活の事故, "救急搬送データからみる日常生活事故の実態", 東京消防庁, [http://www.tfd.metro.tokyo.jp/lfe/topics/201710/nichijoujiko/data/00\\_5.pdf#page=5](http://www.tfd.metro.tokyo.jp/lfe/topics/201710/nichijoujiko/data/00_5.pdf#page=5), (参照 2018-01-31)
- [2] 平成 28 年版高齢社会白書, "第 2 節 高齢者の姿と取り巻く環境の現状と動向 (3)", 内閣府, [http://www8.cao.go.jp/kourei/whitepaper/w-2016/html/zenbun/s1\\_2\\_3.html](http://www8.cao.go.jp/kourei/whitepaper/w-2016/html/zenbun/s1_2_3.html), (参照 2018-01-31)
- [3] 鈴木隆雄:転倒の疫学, 日本老年医学会雑誌 40(2) 85-94, 2003.
- [4] 鳥羽研二, 大河内二郎, 高橋泰, 他:転倒リスク予測のための「転倒スコア」の開発と妥当性の検証, 日本老年医学会雑誌 42(3) 346-352, 2005