

オートエンコーダを用いた 退院時のFIMスコアの予測

野村 正和^{1,a)} 森田 良文¹ 田丸 司²

受付日 2020年11月15日, 採録日 2021年5月11日

概要: 日本国内の脳血管疾患の総患者数は約 112 万人と主要な病気の 1 つであることから, 医療・介護制度に大きな負担をかけている. リハビリテーション病院では治療の質の向上が求められており, そのためには正確な予後予測が不可欠となる. 予後予測の指標として FIM スコアがある. 入院時あるいは入院中の患者のデータを利用して, 退院時の FIM スコアを正確に予測することが求められている. 本研究で考える要求予測精度は実測値と予測値の平均絶対誤差が 5 点以下である. 本研究では, リハビリテーション病院の退院時の FIM スコアを予測するための機械学習を用いたモデルを提案する. このモデルは, 次元圧縮部と予測部により構成される. 入力データの質を向上させるために, 次元圧縮部にオートエンコーダを用いて圧縮された特徴量にエンコードした. エンコードされたデータを予測部の入力として 4 層人工ニューラルネットワークにより FIM スコアを予測した. その結果, 平均絶対誤差は, 3.63 点となり, 誤差が 5 点以下となる累積度数は 80.0%であった. また提案する予測モデルによる精度向上を検証するために他手法による予測と比較をした. 従来手法である重回帰分析による予測モデルとの比較から, 提案手法の予測精度が高いことを明らかにした. また次元圧縮部を除いた予測部のみによる予測モデルとの比較から, 次元圧縮部により平均絶対誤差が 5 点以下となる累積相対度数を 4.8%向上させ, 一方, 15 点以上となる度数を 0.65%減少させた.

キーワード: 機械学習, オートエンコーダ, ニューラルネットワーク, FIM スコア, リハビリテーション

FIM Score Prediction at Discharge Using Autoencoder

MASAKAZU NOMURA^{1,a)} YOSHIFUMI MORITA¹ TSUKASA TAMARU²

Received: November 15, 2020, Accepted: May 11, 2021

Abstract: The total number of patients after stroke in Japan is about 1.12 million, which is one of the major diseases and places a great burden on the healthcare system. Hospitals are required to improve the quality of rehabilitation treatment, and accurate prediction of prognosis is essential. FIM score is a prognostic indicator. Data from patients on admission and during their hospitalization should be used to accurately predict FIM scores at discharge. The required accuracy of this study is that the mean absolute error between the measured and predicted values should be less than 5 points. In this study, we propose a model using machine learning for predicting FIM scores of patients after strokes at discharge. The prediction model consists of a dimension compression part and a prediction part. In order to improve the quality of the input data, we extracted the compressed features from the input data by using the autoencoder in the dimension compression part. FIM scores at discharge were predicted by using a 4-layer artificial neural network in the prediction part and using the compression part as an input. As a result, the mean absolute error of the predicted FIM scores was 3.63 points, and the cumulative frequency with an error of 5 points or less was 80.0%. In order to verify the accuracy of the proposed prediction model, we compared it with a conventional prediction model based on multiple regression analysis. Compared with the conventional prediction model, the high prediction accuracy of the proposed method was confirmed. Moreover, we conducted a comparative study with/without the dimension compression part of the proposed methods. As a result, the cumulative relative frequencies with a mean absolute error of less than 5 points increased by 4.8%, while those with a mean absolute error of more than 15 points decreased by 0.65%.

Keywords: machine learning, autoencoder, neural network, FIM score, rehabilitation

1. はじめに

厚生労働省発表の「平成 29 年患者調査の概況」によると日本国内の脳血管疾患の総患者数は約 112 万人とされており [1], 主要な病気の 1 つである。脳血管疾患の多くは脳卒中であり, 高齢者で発症のリスクが高いため超高齢社会の日本では医療・介護制度に大きな負担をかけている。近年の脳卒中の診療は初期治療を行う急性期病院と治療効果を拡大させる回復期リハビリテーション病院の連携がある。リハビリテーションにおける保険制度では各病院へ支払われる診療報酬は, 日常生活活動 (以降, ADL) の評価に直結している [2]。つまりリハビリテーションの治療の成果に応じた報酬が支払われる仕組みであり, これはリハビリテーションの成果主義を意味している。さらに 2020 年の診療報酬改定では, 求める成果の引き上げがなされ, 改定ごとに厳しさを増している。つまり病院にはリハビリテーションの治療の質の向上が求められており, それぞれの患者に合わせた予後予測が不可欠となる。

予後予測が不可欠な理由として, 田中 [3] は脳卒中の患者リハビリテーションにおいて訓練開始時に機能回復のゴールを明確にすることは, 患者の家庭および社会復帰のための適切な計画に必須であるとしている。また正確な予測による目標設定を行い包括的にアプローチすることは脳卒中治療ガイドラインにおいてもグレード B で推奨されている [4]。これらをふまえたうえで, 脳卒中片麻痺患者 (以降, 脳卒中患者) に対しての ADL 再獲得に向けたリハビリテーションの治療が実施される [5]。そして, ADL 能力を数値化したスコアである Functional Impairment Measurement score (以降, FIM スコア) [6], [7] は最も多用されている ADL スコア [8] である。

以上から, リハビリテーション病院の退院時の FIM スコアの正確な予測は目標設定および適切な計画を立案するうえで重要でありニーズがある。第 3 著者の所属する偕行会リハビリテーション病院では退院時の FIM スコアの予測値を用いて, 患者へ退院時に獲得する ADL 能力の目標を提示し, リハビリテーションの方針の説明を行いたいというニーズがある。実現するためには第 3 著者の所属する病院の状況に鑑み, 実測値と予測値の平均絶対誤差 (以降, 平均誤差) は 5 点以下が許容範囲だと考えた。そこで本研究で考える要求予測精度を平均誤差が 5 点以下とした。

本研究では, 上記の要求を満たすことを目的としてリハビリテーション病院の退院時の FIM スコアを予測するた

めの手法を提案する。以下, 2 章では予測に関する関連研究について述べ, 3 章では予測対象とデータ, ならびに機械学習を導入した提案予測モデルについて述べ, 4 章で予測精度の検証実験と結果について述べる。5 章で本研究のまとめとする。本研究は偕行会リハビリテーション病院の倫理審査会の承認を得て実施されたものである。

2. 関連研究

退院時の FIM スコアを予測する多くの研究が行われている。徳永ら [9] は, 重回帰分析において年齢で 2 群, 入院時 FIM スコアで 3 群, 計 6 群に層別化して予測することにより, 層別化しない場合に比べて退院時の FIM スコアの実測値と予測値の相関が大きいことを示している (相関係数は前者が 0.893, 後者が 0.863)。また日本リハビリテーション・データベースに登録されている患者データ 2,542 症例を用いて, FIM スコアの運動項目の利得を目的変数とした重回帰分析において, 年齢, 性別, 発症から入院までの日数等の 8 つの要因を層別化することで, 予測精度を高められることも明らかになっている [10]。小山 [11] は, 入院時と 2 から 6 週間後の 2 回の FIM スコアを対数曲線にあてはめ係数を計算し, その後退院までの FIM スコアの経過を予測した。対象 111 症例の FIM 運動項目の合計について検証されたところ相関係数は 0.89 であった。

また機械学習を活用した予後予測や治療提案に関する研究も行われている。Isobe らはリハビリテーションを支援する医療 AI システムを開発した [12]。提案したシステムは, 実際の時系列医療記録をマトリックスまたは画像に積み上げ, 機械学習により患者のアウトカムのパターンを認識し, 類似する患者の統計情報を出力し, 推定された FIM スコアの利得と確率を組み合わせる最適な治療方法を提案するソフトウェアである。このように機械学習を活用したリハビリテーションの支援は増えてはきたが, 事例は少ない。また筆者らが調査したところ, 入院時の情報から退院時の FIM スコアを機械学習により予測し, 平均誤差による評価を行った研究は見当たらなかった。そこで本論文では, 機械学習を導入することによって退院時の FIM スコアの予測手法を提案する。

3. 提案手法

本研究では, 回復期リハビリテーション病院に入院中の脳卒中患者を対象として, 入院時あるいは入院中のデータから, 退院時の FIM スコアを予測する。回復期リハビリテーション病院の入院対象者は脳血管疾患や整形外科疾患, および廃用症候群である。病院の役割として ADL の向上により安全に在宅で生活できるように支援することが求められている。入院期間の制限が設けられており, 最大入院可能日数は 180 日である。しかし, すべての対象者で一律 180 日に定められているわけではなく, 疾患および

¹ 名古屋工業大学大学院工学研究科電気・機械工学専攻
Department of Electrical and Mechanical Engineering,
Nagoya Institute of Technology, Nagoya, Aichi 466-8555,
Japan

² 医療法人偕行会偕行会リハビリテーション病院
Kaikokai Rehabilitation Hospital, Yatomi, Aichi 490-1405,
Japan

^{a)} m.nomura.733@nitech.jp

運動項目										認知項目						
セルフケア					排泄		移乗		移動		コミュニケーション		社会認識			
食事	整容	清拭	更衣（上半身）	更衣（下半身）	トイレ動作	排尿コントロール	排便コントロール	ベッド・椅子・車椅子 トイレ	浴槽・シャワー	歩行・車椅子	階段	理解（聴覚・視覚）	表出（音声・非音声）	社会的交流	問題解決	記憶
計6～42点					計2～14点		計3～21点		計2～14点		計2～14点		計3～21点			
運動項目 計13～91点										認知項目 計5～35点						
合計 18～126点																

図 1 FIM スコア

Fig. 1 FIM score.

必要条件の有無により上限日数は異なる．一般的に機能回復においては，脳卒中発症直後から一定期間は顕著に回復が認められる．Lee らの研究 [13] によると発症から 3 カ月で 48% から 91% の神経学的障害と機能的障害の改善が見られ，下肢を除くと 6 カ月後まで継続的な回復が見られると報告している．また Langhorne ら [14] も同様に，6 カ月間はリハビリテーションにより可塑的な変化および機能改善を認め，日常生活の変化があることを示している．しかし機能回復は個人差等により異なり，6 カ月未満で回復が停滞状態（以降，プラトー）に達する場合がある．回復期リハビリテーション病院では入院期間中に ADL がプラトーになった時点で退院となる．そのため本論文では，退院時とは回復がプラトーに達したときと同義であるとする．

3.1 FIM スコア

FIM スコアは個人の身体的，心理的，社会的機能を調査する 18 項目の測定ツールである．図 1 に示すように運動に関する 13 項目と認知に関する 5 項目で構成される．1 つの項目に対して 1~7 点の 7 段階評価であり最低点が 18 点で最高点が 126 点である．このツールは，リハビリテーションまたは医療介入に対して，患者の障害レベルと状態の変化を評価するために使用される [6], [7]．点数の判定は医療従事者が行う．FIM スコアの各項目と点数は厳密に規定されており，判定はマニュアルに則して行われる [15]．それによって判定員内，判定員間の評価の誤差が抑えられることが先行研究によって示されている [16], [17]．FIM スコアは対象者の状態を総評して表すことにより，状態を簡易に示すための指標となる．そのため FIM スコアの合計値を予測することで，状態を総評し対象者のリスクを把握することができる [18]．

3.2 予測対象のリハビリテーション病院と患者データ

予測対象とするリハビリテーション病院は第 3 著者の所属する病院であり，回復期リハビリテーション病院である．患者の電子カルテ情報として，1) 入院時に計測する

表 1 基礎データ 1

Table 1 Basic data 1.

項目	内容	値
入院時年齢	入院時における年齢	70.6 ± 14.6
ADL(mRS)[20]	発症前の生活状態の程度 (7 段階評価であり， 0 は症状なし， 5 は重度障害を意味する.)	0.7 ± 1.1
同居人数	同居している人数 (0 は独居)	1.8 ± 1.4

基礎データ，2) 入院期間中に複数回計測する検査データ，3) 日々の様子を記述した文章を管理している．基礎データと検査データの項目数を合わせると，およそ 90 項目となる．その中から予測において重要であると考えられた 66 項目を用いて，退院時の FIM スコアを予測する．66 項目の内容として表 1 と表 2 に基礎データ，表 3 から表 5 に検査データを記載する．表 4 の項目にある SIAS は，脳卒中機能障害評価セット (Stroke Impairment Assessment Set) であり機能項目別に 0 点から 3，あるいは 5 点満点で評価する [19]．今後データを解析するために，それぞれのデータに対して量的変数とカテゴリ変数に分けて示している．表 2，表 5 のカテゴリ変数については分類基準も記載している．ただし疾患名は 114 種類と多数のため割愛した．2 章の関連研究で記載した徳永らの研究 [10] は，対象患者の疾患を脳梗塞，脳出血，くも膜下出血に絞り込んでいるが，本研究では脳血管疾患に関わる様々な疾患が含まれているデータを対象とする．4 章の予測精度の検証実験では，偕行会リハビリテーション病院の 2016 年から収集された約 3 年分の電子カルテから得られたデータ 1,100 件により行う．それぞれの患者において入院時に計測され，その後約 1 カ月おきに検査データは更新されている．患者数は 314 名であり，入院中に 1 人あたり 3.5 ± 1.5 回，検査データの項目について計測を行っている．量的変数については，表 1 のそれぞれの項目の平均値と標準偏差は 314 名のデータから算出し，表 3 と表 4 は 1,100 件のデータから算出した．また入院中の様々な時点から退院時の FIM スコアの予測において精度を向上させるために，発症から計測までの経過日数を FIM スコアの予測のためのデータとして用いる．図 2 に 1,100 件分の発症から計測までの経過日数のヒストグラムを示す．30 日以下，60 日以下，90 日以下，120 日以下，150 日以下，および 180 日以下はそれぞれ全体の 17%，43%，65%，82%，92%，および 97% である．以上のデータは，匿名化された状態で第 1，2 著者に受け渡された．データを保存している計算機はインターネットには接続せずに，第 1，2 著者が所属する学内の鍵のある部屋にて管理している．

表 2 基礎データ 2
Table 2 Basic data 2.

項目	内容
疾患名	主な疾患名 (114 種類)
性別	性別 0: 女性 1: 男性
トースト分類	脳神経疾患の原因病態の分類 1: アテローム血栓性脳梗塞 2: 心原性脳塞栓 3: ラクナ梗塞 4: その他の原因による脳梗塞 5: 脳出血 6: くも膜下出血 7: 脳静脈塞栓 8: 非脳卒中疾患
病巣の部位	病巣の部位 1: 右大脳 2: 左大脳 3: 小脳 4: 脳幹 5: 脊髄 6: 大脳 びまん性 7: 多発性 8: その他
病巣の大きさ	病巣の大きさ 1: 5 cm 以下 2: 5 cm 以下と動脈分岐領域レベルの中間 3: 動脈分岐領域レベル 4: その他 (多発等)
手術	急性期治療として手術の有無 0: 無 1: 有
HD 有無	慢性腎不全合併による透析治療の有無 0: 無 1: 有
気切/O2	転院時に気管切開状態, 酸素療法状態の有無 0: 無 1: 有
利き手	利き手 1: 右利き 2: 左利き

3.3 退院時の FIM スコアの予測手法

機械学習を導入することによって退院時の FIM スコアの予測をするモデル (以降, 提案予測モデル) について説明する. 提案予測モデルは, 図 3 のようにオートエンコーダのエンコード部 (以降, 次元圧縮部) と 4 層人工ニューラルネットワーク (以降, 予測部) からなる. 66 項目の入院時あるいは入院中に得られたデータを入力とし, 退院時の FIM スコアを出力とした. ただし数値化する必要のあるカテゴリ変数についてはカテゴリに番号を付与し, その

表 3 検査データ 1-1
Table 3 Inspection data 1-1.

項目	内容	値
経過日数	発症日から計測までの経過日数	78.5 ± 46.5
FIM 運動項目 1	セルフケア (食事)	5.4 ± 1.7
FIM 運動項目 2	セルフケア (整容)	5.4 ± 1.7
FIM 運動項目 3	セルフケア (清拭)	4.2 ± 1.8
FIM 運動項目 4	セルフケア (更衣上半身)	5.1 ± 2.1
FIM 運動項目 5	セルフケア (更衣下半身)	4.7 ± 2.3
FIM 運動項目 6	セルフケア (トイレ動作)	4.9 ± 2.1
FIM 運動項目 7	排泄 (排尿コントロール)	5.2 ± 2.4
FIM 運動項目 8	排泄 (排便コントロール)	5.4 ± 2.1
FIM 運動項目 9	移乗 (ベッド・椅子・車椅子)	5.3 ± 1.7
FIM 運動項目 10	移乗 (トイレ)	5.2 ± 1.7
FIM 運動項目 11	移乗 (浴槽・シャワー)	4.1 ± 1.7
FIM 運動項目 12	移動 (歩行・車椅子)	3.9 ± 2.5
FIM 運動項目 13	移動 (階段)	3.2 ± 2.3
FIM 認知項目 1	コミュニケーション (理解 (聴覚・視覚))	5.3 ± 1.6
FIM 認知項目 2	コミュニケーション (表出 (音声・非音声))	5.2 ± 1.7
FIM 認知項目 3	社会認識 (社会的交流)	5.9 ± 1.6
FIM 認知項目 4	社会認識 (問題解決)	4.3 ± 2.0
FIM 認知項目 5	社会認識 (記憶)	4.6 ± 2.0
FIM 運動項目合計	FIM スコア (運動項目) の合計	61.6 ± 22.5
FIM 認知項目合計	FIM スコア (認知項目) の合計	25.2 ± 7.9
FIM 合計	FIM スコアの合計	86.9 ± 28.4
嚥下能力グレード	藤島のグレード による嚥下の 能力 [21] (10 種類)	8.8 ± 2.1
非麻痺側握力	非麻痺側の握力 [kg]	21.2 ± 11.8
麻痺側握力	麻痺側の握力 [kg]	13.4 ± 20.2
MMSE	ミニメンタルテスト (Mini Mental State Examination Test) [22]	21.5 ± 7.9
MNA (栄養)	簡易栄養状態評価 スクリーニング の点数 [23]	7.6 ± 2.4
看護必要度 A 項目	看護師による処置等の 必要性を評価する尺度 (モニタリング および処置等) [24]	0.1 ± 0.3
看護必要度 B 項目	看護師による処置等の 必要性を評価する尺度 (患者の状況等)	4.3 ± 4.2

表 4 検査データ 1-2

Table 4 Inspection data 1-2.

項目	内容	値
SIAS1	運動機能（上肢近位）	3.6 ± 1.6
SIAS2	運動機能（上肢遠位）	3.5 ± 1.7
SIAS3	運動機能（下肢近位（股））	3.9 ± 1.3
SIAS4	運動機能（下肢近位（膝））	4.0 ± 1.2
SIAS5	運動機能（下肢遠位）	3.6 ± 1.5
SIAS6	筋緊張（上肢筋緊張）	2.4 ± 0.8
SIAS7	筋緊張（下肢筋緊張）	2.5 ± 0.7
SIAS8	筋緊張（上肢腱反射）	2.3 ± 0.8
SIAS9	筋緊張（下肢反射）	2.2 ± 0.8
SIAS10	感覚（上肢感覚）	2.2 ± 0.8
SIAS11	感覚（下肢感覚）	2.3 ± 0.8
SIAS12	感覚（上肢位置覚）	2.3 ± 0.8
SIAS13	感覚（下肢位置覚）	2.3 ± 0.8
SIAS14	関節可動域，疼痛（上肢関節可動域）	2.7 ± 0.6
SIAS15	関節可動域，疼痛（下肢関節可動域）	2.3 ± 0.6
SIAS16	関節可動域，疼痛（疼痛）	2.8 ± 0.5
SIAS17	体幹機能（垂直性）	2.7 ± 0.6
SIAS18	体幹機能（腹筋）	2.8 ± 0.5
SIAS19	高次脳機能（視空間認知）	2.7 ± 0.6
SIAS20	高次脳機能（言語）	2.7 ± 0.6
SIAS21	健側機能（握力）	2.2 ± 0.7
SIAS22	健側機能（健側大腿四頭筋力）	2.2 ± 0.8
SIAS 合計	SIAS の合計	60.4 ± 12.0

表 5 検査データ 2

Table 5 Inspection data 2.

項目	内容
失語の有無	失語の状態
	0：失語なし
	1：軽度失語症
	2：重度感覚性失語症
	3：重度運動性失語症
視空間障害の有無	4：全失語
	視空間障害の有無
	0：無
	1：有

番号をそのままの値として解釈する Ordinal encoding を行った。Min-Max Normalization により正規化をした後に次元圧縮部を導入することで、データの次元を削減および圧縮し入力データの質を高めた。そしてエンコードされた 36 項目の値を入力として、再度正規化し、予測部により最小値 0、最大値 1 で表現された退院時の FIM スコアを予測した。最後に非正規化を行い、退院時の FIM スコアの予




図 2 発症から計測までの経過日数のヒストグラム

Fig. 2 Histogram of days since onset.




図 3 提案予測モデル

Fig. 3 Proposed prediction model.

測値を出力した。

3.4 次元圧縮部と予測部の構造

オートエンコーダは入力層，中間層，出力層の 3 層からなり，それぞれのユニット数は 66, 36, 66 である。それぞれの層において Batch Normalization [25]，活性化関数による活性化が行われる。中間層の活性化関数は Relu とし，出力層はシグモイド関数とする。オートエンコーダの特性上，入力層と出力層のデータは同じであり，前節で述べた正規化された入力データである。これによって圧縮された特徴量が中間層の出力として得られる。

予測部は，入力層，3 層の中間層，出力層からなり，それぞれのユニット数は，36, 256, 256, 256, 1 である。それぞれの層において正規化，活性化関数による活性化が行われる。中間層，出力層ともに活性化関数は Relu とする。入力は次元圧縮部により得られた値を正規化した値であり，出力層は最小値 0，最大値 1 で表現された退院時の FIM スコアである。なお，正規化の手法である Min-Max Normalization のパラメータは学習データの最小値と最大値から決定している。

3.5 次元圧縮部と予測部の学習

次元圧縮部と予測部の学習方法は同様である。学習は確率的勾配降下法により行い、損失関数は回帰モデルで一般的に用いられる平均二乗誤差とした。本研究では、mini-batch のサイズを 128 とし、それぞれの mini-batch において誤差逆伝播法で求められた平均二乗誤差の勾配に基づいて Adam によってパラメータを最適化した。なおパラメータ調整は 20,000 回を上限とする。連続で 1,000 回にわたり評価データの平均二乗誤差に変化が見られなかった場合、過学習を防ぐために学習を終了した。

3.6 次元圧縮部と予測部の評価

データは学習および評価のために分割する。全データである 1,100 件を 5 分割し、80% のデータを学習データ、20% のデータを評価データとした。そして分割に起因する偏りを防ぐために、評価に用いるデータを入れ替えることで 5 回繰り返し行った。さらにこのプロセスを 10 回行った。これにより 50 個の提案予測モデルが生成される。それぞれの提案予測モデルに対して、評価データの入力データを用いて FIM スコアを予測し、評価データの退院時の FIM スコアの実測値と予測値との平均誤差を求める。平均誤差 (MAE: Mean Absolute Error) は、 N を評価データの数、 $C_0(n)$ を退院時の FIM スコアの実測値、 $C_p(n)$ を予測値とすると、式 (1) で求められる。

$$MAE = \frac{1}{N} \sum_{n=1}^N |C_0(n) - C_p(n)| \quad (1)$$

プログラミング言語として Python、機械学習ライブラリとして Keras [26] を用いた。前者はデータの前処理に用い、後者は提案予測モデルの構築、学習および評価に用いた。本論文で記述した以外のパラメータはデフォルトとした。

4. 提案予測モデルの予測精度の検証実験

前章で説明した提案予測モデルの予測精度について検証実験を行った。50 個の提案予測モデルの平均誤差の平均値は 3.63 点であり、平均平方二乗誤差の平均値は 6.60 点であった。誤差が 5 点以下となる累積相対度数は 80.0% であり、15 点以上は 3.81% であった。それぞれのモデルに対して評価データは全データの 20% にあたる 220 件存在し、50 個のモデルに対しては 11,000 件となる。評価データ 11,000 件と誤差が 5 点以下を正答例とした 8,949 件のデータについて、それぞれの入力項目の平均値の差を前者に対する割合で比較した。大きい順に看護必要度 A 項目が 14.5%、看護必要度 B 項目が 11.0% であった。差の割合は小さいため、特定の項目が正当例に偏っていないと考えられる。

そして提案予測モデルにおいて欠かすことのできない重

要な項目を確認するために、入力項目のうち 1 項目の値を 0 として予測した。入院時の年齢の値を 0 として予測した場合の平均誤差の平均値は 9.08 点となり最も大きくなった。入院時の年齢は重要な項目であることが考えられ、先行研究でも天井効果がある入院時の FIM スコアが 108 から 126 点の患者を除けば、高齢者では若年者より有意に FIM スコアの利得が低いことが明らかになっている [27]。

実験にあたり手法の違いによる影響も確認した。次元圧縮部としてオートエンコーダの代わりに主成分分析を用いた場合と次元圧縮部の中間層を 2 層とした場合の平均誤差の平均値は、それぞれ 3.96 点、3.88 点であった。平均平方二乗誤差の平均値は、それぞれ 7.12 点、6.90 点であり、精度の向上は見られなかった。そして次元圧縮後の次元数が与える影響を確認するために、次元数を 20 から 40 まで 4 刻みで予測を行ったところ、36 が最も平均誤差の平均値が小さかった。

以降では、提案手法と 2 つの他手法との比較を行った。1 つ目は関連研究でもよく行われている重回帰分析によるモデル（以降、重回帰モデル）との予測精度の比較を行った。2 つ目は次元圧縮部を除いた予測部のみ（以降、単独予測部モデル）との予測精度の比較を行った。次元圧縮部が予測前の前処理として精度向上に寄与しているかどうかを検証した。なお単独予測部モデルは提案予測モデルの予測部と構造、学習方法、および評価方法は同様であるが、入力は 66 項目である。

加えて前述した 2 つの他手法以外の代表的な回帰手法であるサポートベクトル回帰、ランダムフォレストによる予測を行った。平均誤差の平均値は、それぞれ 6.98 点、5.01 点であった。また平均平方二乗誤差の平均値は、それぞれ 9.20 点、8.28 点であった。

4.1 重回帰モデルとの比較

多重共線性を考慮し分散拡大係数の値が 10 未満となるように入力項目数を調整した後に予測を行った。重回帰モデルの平均誤差の平均値は 9.62 点であり、平均平方二乗誤差の平均値は 12.9 点であった。以降では 50 個の平均誤差に対して、重回帰モデルと提案予測モデルとの比較を行う。まず、シャピロ・ウィルク検定により両群ともに正規性は認められなかった。そこで、対応ありのノンパラメトリック検定であるウィルコクソン符号付順位検定を行った。図 4 に重回帰モデルと提案予測モデルの平均誤差の比較結果を示す。有意確率が $p = 7.56 \times 10^{-10}$ ($p < 0.01$) であることから、提案予測モデルとの有意差が認められ提案予測モデルによる精度の向上を確認した。

評価データ 11,000 件について 1 件ずつ重回帰モデルと提案予測モデルで予測した。図 5 に 11,000 件分の実測値と予測値の予測誤差の絶対値のヒストグラムを示す。重回帰分析では 15 点以上の誤差となる可能性が 20.0% と高かつ




図 4 重回帰モデルと提案予測モデルの平均誤差の比較

Fig. 4 Comparison between multiple regression analysis and proposed prediction model.




図 6 単独予測部モデルと提案予測モデルの平均誤差の比較

Fig. 6 Comparison between single predictor and proposed prediction model.




図 5 重回帰モデルと提案予測モデルの予測誤差のヒストグラム

Fig. 5 Histogram of errors in multiple regression analysis and proposed prediction model.




図 7 単独予測部モデルと提案予測モデルの予測誤差のヒストグラム

Fig. 7 Histogram of errors in single predictor and proposed prediction model.

た。提案予測モデルでは、誤差が小さくなるにつれて予測度数が増加しており、1 点以下となる場合は重回帰モデルの 3.8 倍であった。

4.2 単独予測部モデルとの比較

単独予測部モデルの平均誤差の平均値は 4.28 点であり、平均平方二乗誤差の平均値は 7.48 点であった。さらに提案予測モデルとのニューラルネットワークの層数による違いを考慮し、単独予測部モデルに中間層を 1 層増やした場合のモデルにて実験を行った。平均誤差の平均値は 5.04 点、平均平方二乗誤差の平均値は 8.30 点であり、層数が性能に与える影響は小さいことを確認した。4.1 節と同様に検定を行った。図 6 に単独予測部モデルと提案予測モデルの平均誤差の比較結果を示す。有意確率が $p = 4.18 \times 10^{-4}$ ($p < 0.01$) であることから、提案予測モデルとの有意差が認められ次元圧縮部が予測精度の向上に寄与していることを確認した。




図 8 単独予測部モデルと提案予測モデルの予測誤差と累積度数の比較

Fig. 8 Comparison of cumulative frequency between single predictor and proposed prediction model.

図 7 に単独予測部モデルと提案予測モデルの予測誤差の絶対値のヒストグラム, 図 8 に累積度数を示す. 提案予測モデルは単独予測部モデルに比べて誤差が 1 点以下となる累積相対度数が 6.8% 高く, 5 点以下となる度数が 4.8% 高かった. また 15 点以上となる度数は 0.65% 低かった. 予測前に次元圧縮部により入力データを圧縮された特徴量にエンコードすることは退院時の FIM スコアの予測に対しても有効であることが考えられる.

5. おわりに

本論文では, 機械学習の導入によって入院時あるいは入院中のデータから退院時の FIM スコアを予測するために次元圧縮部と予測部の組み合わせによる手法を提案した. 提案予測モデルの平均誤差は 3.63 点, また誤差の絶対値が 5 点以下となる累積度数は 80.0% であったことから有用性を明らかにした. また重回帰分析との比較結果により, 回復期リハビリテーション病院の患者を対象とした退院時の FIM スコアの予測に対しても機械学習が有用であることが明らかになった. そして次元圧縮部により, 退院時 FIM スコアの実測値と予測値の誤差の絶対値が 5 点以下となる累積相対度数が高まることが明らかになった. 提案予測モデルは, 病院が入院時あるいは入院中に患者の退院時のプラトリーに達している FIM スコアを予測することに有用であった.

今後の課題は 2 つある. 1 つ目は, 本論文のデータで予測が大きく外れる場合を解析することで予測精度を向上させることである. 提案予測モデルでは, 誤差が 15 点以上となる場合が 3.81% であり, 大きく予測を外してしまう可能性がある. その条件を発見することで提案予測モデルによる予測が適用可能かどうかを判定するためのフィルタリング, FIM スコアを項目ごとに予測した後に和をとる等のモデルの再構築, 損失関数やハイパーパラメータの再検討を行う予定である. 2 つ目は提案予測モデルの臨床現場への導入である. 医療従事者が実際に活用することで, リハビリテーションの治療の質の向上を目指す. そのためには開発された提案予測モデルの利便性の向上のためのユーザインタフェースの開発を行う予定である. 以上の課題を解決することで, 正確な予測による適切な目標設定および計画の立案につながり, リハビリテーションの治療の質の向上につながると考えられる.

参考文献

- [1] 厚生労働省: 平成 29 年 (2017) 患者調査の概況, 入手先 <https://www.mhlw.go.jp/toukei/saikin/hw/kanja/17/index.html> (参照 2020-11-26).
- [2] 園田 茂: 回復期リハビリテーション医療における機能評価, *The Japanese Journal of Rehabilitation Medicine*, Vol.55, No.4, pp.292–295 (2018).
- [3] 田中健治: 脳卒中のリハビリテーション予後予測に関する研究 重回帰分析を用いて: 重回帰分析を用いて, 脳卒中, Vol.12, No.5, pp.452–462 (1990).
- [4] 日本脳卒中学会: 脳卒中治療ガイドライン 2015 [追補 2019], 入手先 http://www.jsts.gr.jp/img/guideline2015_tuiho2019_10.pdf (参照 2020-11-26).
- [5] 平野恵健, 林 健, 新田 収ほか: 回復期リハビリテーション病棟に入院した脳卒中 重度片麻痺患者の退院時 ADL 能力に及ぼす因子の検討, *理学療法科学*, Vol.30, No.4, pp.563–567 (2015).
- [6] Linacre, J.M., Heinemann, J.W., Wright, B.D., et al.: The structure and stability of the functional independence measure, *Arch Phys Med Rehabil*, Vol.75, pp.127–132 (1994).
- [7] Heinemann, A.W., Linacre, J.M., Wright, B.D., et al.: Relationships between impairment and physical disability as measured by the functional independence measure, *Arch Phys Med Rehabil*, Vol.74, pp.566–573 (1993).
- [8] 浅井 剛, 山口良太: リハビリテーションにおける工学的課題と地域・工学連携への期待, *システム/制御/情報*, Vol.63, No.8, pp.329–334 (2019).
- [9] 徳永 誠, 池田優生, 井上美由紀ほか: 年齢と入院時 FIM で層別化した脳卒中患者の退院時 FIM を予測する重回帰分析—日本リハビリテーション・データベースの分析, *Journal of Clinical Rehabilitation*, Vol.24, pp.828–834 (2015).
- [10] 徳永 誠, 當利賢一, 江口宏ほか: 運動 FIM と認知 FIM を層別化して 4 つの予測式を作ることで運動 FIM 利得を目的変数とした重回帰分析の予測精度が高まる—日本リハビリテーション・データベースを用いた研究, *Japanese Journal of Comprehensive Rehabilitation Science*, Vol.8, pp.1–8 (2017).
- [11] 小山哲男: 脳卒中患者の帰結予測, *The Japanese Journal of Rehabilitation Medicine*, Vol.55, No.9, pp.773–782 (2018).
- [12] Isobe, T. and Okada, Y.: Medical AI System to Assist Rehabilitation Therapy, *Proc. ICDM 2018*, pp.266–271 (2018).
- [13] Lee, K.B., Lim, S.H., Kim, K.H., et al.: Six-month functional recovery of stroke patients: A multi-time-point study, *International Journal of Rehabilitation Research*, Vol.38, pp.173–180 (2015).
- [14] Langhorne, P., Bernhardt, J. and Kwakkel, G.: Stroke rehabilitation, *Lancet*, Vol.377, No.9778, pp.1693–16702 (2011).
- [15] Linacre, J.M.: FIM levels as ordinal categories, *J. Outcome Meas.*, Vol.4, pp.616–633 (2000).
- [16] Ottenbacher, K.J., Hsu, Y., Granger, C.V., et al.: The reliability of the functional independence measure: A quantitative review, *Archives of Physical Medicine and Rehabilitation*, Vol.77, pp.1226–1232 (1996).
- [17] Russo, T., Felzani, G., Giunta, M., et al.: Monitoring recovery by physical therapists using the FIM scale during rehabilitation programs: An inter-rater and intra-rater reproducibility study, *Health*, Vol.5, pp.99–104 (2013).
- [18] Ribeiro, D.K.M.N., Lenardt, M.H., Lourenco, T.M., et al.: The use of the functional independence measure in elderly, *Rev. Gaucha Enferm*, Vol.38, pp.1–8 (2018).
- [19] Chino, N., Sonoda, S., Domen, K., et al.: Stroke Impairment Assessment Set (SIAS), *The Japanese Journal of Rehabilitation Medicine*, Vol.31, No.2, pp.119–125 (2009).
- [20] Swieten, V., Koudstaal, P., Visser, M., et al.: Inter-observer Agreement for the Assessment of Handicap in Stroke Patients, *Stroke*, Vol.19, pp.604–607 (1998).
- [21] 藤島一郎: 嚥下障害リハビリテーション入門 I 嚥下障害入

- 門, *The Japanese Journal of Rehabilitation Medicine*, Vol.50, No.3, pp.202–211 (2013).
- [22] Folstein, M.F., Folstein, S.E. and McHugh, P.R.: Minimal state: A practical method for grading the cognitive state of patients for the clinician, *Journal of Psychiatric Research*, Vol.12, No.3, pp.189–198 (1975).
- [23] Nestle Nutrition Institute: MNA Mini Nutritional Assessment, available from (https://www.mna-elderly.com/mna_forms.html) (accessed 2020-11-26).
- [24] 全国保険医団体連合会：一般病棟用の重症度，医療・看護必要度に係る評価票 評価の手引き，入手先 (https://hodaanren.doc-net.or.jp/iryoukankei/14kaitei/yosiki/b07_2.pdf) (参照 2020-11-26).
- [25] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *ICML*, pp.448–456 (2015).
- [26] Keras, available from (<https://keras.io/>) (accessed 2020-11-26).
- [27] 徳永 誠，米村美樹，井上理恵子ほか：年齢が回復期リハ病棟における脳卒中患者の FIM 利得に及ぼす影響，*Japanese Journal of Comprehensive Rehabilitation Science*, Vol.3, pp.1–4 (2012).



野村 正和 (学生会員)

1996 年 3 月 29 日生。2020 年名古屋工業大学大学院工学研究科電気・機械工学専攻博士前期課程卒業。2020 年同大学大学院博士後期過程在学中。現在，脳卒中患者の予後予測や手指機能のリハビリテーションデバイスの研究

開発に従事。



森田 良文

1964 年 12 月 24 日生。1989 年名古屋工業大学大学院工学研究科博士前期課程修了。同年 (株) 日本電装 (現，(株) デンソー) に入社。1991 年岐阜工業高等専門学校電子制御工学科助手。2000 年名古屋工業大学電気情報

工学科講師。現在，同大学大学院工学研究科教授。博士 (工学)。ロボットの運動制御，人間機械協調系の支援制御，リハビリテーション支援ロボット等の研究に従事。電気学会，日本機械学会，日本ロボット学会，日本生活支援工学会，IEEE 等の会員。



田丸 司

1962 年 6 月 21 日生。1989 年奈良県立医科大学卒業。同大学神経内科，同リハビリテーション部等を経て，2004 年医療法人偕行会入職，2012 年より偕行会リハビリテーション病院院長。日本神経学会専門医・指導医，日本リ

ハビリテーション学会専門医・指導医，日本臨床神経生理学会等の会員。