

Brief Report

AI 予測分析ツールを用いた回復期リハビリテーション病棟脳卒中症例の退院時運動 FIM 予測について

森田和幸,¹ 安部千秋,^{2,3} 小野圭介,² 高橋良輔,^{2,3}
 荒 洋輔,^{1,3} 阿部正之,^{1,3} 白坂智英⁴

¹社会医療法人北斗十勝リハビリテーションセンターリハビリテーション部作業療法科

²社会医療法人北斗十勝リハビリテーションセンターリハビリテーション部理学療法科

³社会医療法人北斗十勝リハビリテーションセンター先進リハビリテーション推進室

⁴社会医療法人北斗十勝リハビリテーションセンター診療部リハビリテーション科

要旨

Morita K, Abe S, Ono K, Takahashi R, Ara Y, Abe M, Shirasaka T. Predicting Motor FIM at Discharge for Recovery Stroke Patients in a Rehabilitation Ward Using an AI Predictive Analysis Tool. Jpn J Compr Rehabil Sci 2026; 17: 40–45.

【目的】本研究の目的は、AI 予測分析ツール (Prediction One) を用いて退院時運動 FIM の予測モデルを作成し、その精度を明らかにすることである。

【方法】対象は 2020 年 4 月から 2022 年 3 月までに退院した脳卒中症例 457 名を訓練用データ、2022 年 4 から 10 月までに当院を退院した脳卒中症例 43 名の検証用データとした。まず、訓練用データから AI 予測モデルを作成した。次に、検証用データにて予測精度の検証を行った。精度検証として、実際の退院時運動 FIM と AI およびセラピストの予測値との残差、各予測結果の相関係数ならびに決定係数を算出し、統計的な比較を行った。

【結果】作成した予測モデルの決定係数は 0.799 であった。実測値との残差は、AI 予測が 5.43 ± 5.93 点、セラピスト予測が 6.42 ± 5.52 点。予測結果の相関係数ならびに決定係数は AI 予測が $r=0.939$, $R^2=0.881$, セラピスト予測が $r=0.943$, $R^2=0.889$ であり、両者の相関係数に有意差は認められなかった ($z=-0.295$, $p=0.768$)。両者の残差分布では、セラ

ピスト予測が実測値より高い予測をしている傾向を認めた。

【結論】本研究で作成したモデルは、先行研究と比較しても遜色ない精度を示した。また、セラピストと同程度の予測が可能であった。このモデルを臨床で活用すれば、経験年数に関わらず一定の精度で退院時運動 FIM を予測できる可能性があると考え、今後対象疾患を拡大するとともに、外的妥当性についても検証していきたい。

キーワード：回復期リハビリテーション病棟, AI, 予後予測, 脳卒中, FIM

はじめに

1. 背景と先行研究

2016 年の診療報酬改定により、回復期リハビリテーション病棟（以下、回復期リハ病棟）において、機能的自立度評価法 (Functional Independence Measure: FIM) の運動項目の改善度と在院日数を用いた計算式からアウトカムを算出するリハビリテーション実績指数が導入された。これにより、FIM 運動項目の改善度は臨床上的アウトカムというだけでなく、診療報酬上においても重要なアウトカムとなっている。

従来、FIM 予測には重回帰分析が用いられてきた [1–10]。徳永らは、入院時 FIM 点数に加え、年齢や発症からの日数など多要因を考慮する有用性を報告している [1]。一方で山重らは、重回帰分析よりも療法士による予測の方が精度が高いことを示唆している [11]。このように、退院時 FIM の予測は要因が複雑であり、普遍的なモデル作成は困難とされてきた。

2. AI 予測分析ツールの活用

近年、医療分野でも人工知能を活用した予測が報告されている。AI 予測分析ツール「Prediction One」は、自動で最適なアルゴリズムを選択し、予測モデルを構築するツールである。最大の特徴は、各項目が結果に与える影響を「予測寄与度」として可視化できる点にある。実際に脳出血患者の手術 6 か月後の生活自立度を予測した研究では、予後予測モデルの決定係数は

著者連絡先：森田和幸

社会医療法人北斗十勝リハビリテーションセンターリハビリテーション部作業療法科

〒080-0833 北海道帯広市稲田町基線 2 番地 1

E-mail : ot-morita@hokuto7.or.jp

2026 年 5 月 25 日受理

利益相反：今回の論文投稿に関連し、開示すべき COI 関係にある企業等はありません。



This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives International License.

©2026 Kaifukuki Rehabilitation Ward Association

0.997 [12], くも膜下出血患者の発症 6 か月後の生活自立度予測した研究における予後予測モデルの決定係数は 0.994 [13] と非常に精度の高い結果を報告している. そのほか AI を用いた予後予測研究として, 勝木らは入院時および回復期リハビリ病棟転棟時の状態から退院時の生活自立度を予測するモデルを作成し, そのモデルの決定係数が 0.972 であったことを報告している [14]. また, 徳永らは入院時運動 FIM が 40 点未満の脳卒中患者を対象に, 退院時運動 FIM を目的変数とした重回帰分析と Prediction One による機械学習予測を行い, 重回帰分析より機械学習予測の方が決定係数が高く残差の絶対値も少なかったことを報告している [4].

3. 当院の課題と本研究の目的

現在, 当院では担当セラピストが経験則に基づいて退院時 FIM を予測しており, 客観性に欠けるという課題がある. また, これまでセラピストの予測値と AI の予測値を直接比較した研究はほとんど見当たらない.

そこで本研究では, 当院の入院時情報から予測モデルを作成し, その精度を検証した. さらに, AI の予測値とセラピストの予測値を比較検討し, 本ツールの臨床における有用性を明らかにした.

方法

1. 対象と倫理的配慮

対象は 2020 年 4 月から 2022 年 10 月までに当院を退院した脳卒中患者 500 名とした.

本研究は「人を対象とする生命科学・医学系研究に関する倫理指針ガイダンス (厚生労働省・文部科学省・経済産業省, 令和 5 年 3 月 27 日一部改正)」を遵守して実施した. また, 当院倫理委員会の承認を得ており, 利益相反はない.

2. 予測モデルの作成

まず, 2022 年 3 月までに退院した 457 名を「訓練用データ」とした.

訓練用データの入院時評価から先行研究より退院時運動 FIM 予測と関連があり, かつ当院のデータベースに収載されている 58 項目から, 欠損率が 50 % を上回った項目を削除し, 28 項目を採用した.

採用した 28 項目を説明変数とし, 退院時運動 FIM 総得点を目的変数とした予測モデルを構築した.

3. 予測精度の検証と統計解析

2022 年 4 月以降に退院した 43 名を「検証用データ」とした.

作成した AI モデルを用いて, この 43 名の退院時運動 FIM を予測した.

43 名の検証用データについてデータベースより担当セラピストの予測結果を抽出した. 尚, 当院では担当セラピストが入院 1 週間以内に, 経験則に基づいて退院時運動 FIM の予測を行っている. 回帰分析等は使用しておらず, 病棟管理者が予測結果を確認することとしている.

各予測値と実測値の差 (残差) を算出し, 両者の残差の比較には対応のある t 検定を用いた. また, AI およびセラピストの予測精度を評価するため, 各予測値と実測値について相関分析を行い, 相関係数 (r) と決定係数 (R^2) を算出した. 次いで, 各予測値の相関係数に有意性があるかを検討するため, Fisher の z 変換に基づく Steiger の Z 検定を実施し, 統計学的に比較した.

統計解析には R (Ver. 4.4.2) を使用し, 有意水準は 5 % とした.

結果

1. 対象の属性

訓練用データ (457 名) は, 男性 250 名, 女性 207 名, 年齢 74.4 ± 13.3 歳であった. 入院時 FIM は運動項目 41.5 ± 22.0 点, 認知項目 20.1 ± 9.2 点であった. 退院時運動 FIM は 64.5 ± 27.8 点, FIM 運動利得は 22.9 ± 16.8 点であった.

検証用データ (43 名) は, 男性 30 名, 女性 13 名, 年齢 77.8 ± 12.1 歳であった.

入院時 FIM は運動項目 42.7 ± 19.5 点, 認知項目 21.6 ± 6.8 点であった. 退院時運動 FIM は 68.7 ± 23.2 点, FIM 運動利得は 26.0 ± 14.0 点であった (表 1).

2. 予測モデルの精度

作成した AI 予測モデルの決定係数は 0.799 であった (表 2).

3. AI 予測値とセラピスト予測値の比較

検証用データにおける退院時運動 FIM の予測値は, AI 予測が 68.3 ± 20.8 点, セラピスト予測が 71.1 ± 19.3 点であった (図 1). 実測値との残差は, AI 予測が 5.43 ± 5.93 点, セラピスト予測が 6.42 ± 5.52 点であった (図 2). 両者の予測誤差について, 有意差

表 1. 対象の属性

	訓練用データ		検証用データ	
性別 (名)	男性 : 250	女性 : 207	男性 : 30	女性 : 13
年齢 (歳)	74.4 ± 13.3		77.8 ± 12.1	
入院時の FIM 運動項目 (点)	41.5 ± 22.0		42.7 ± 19.5	
入院時の FIM 認知項目 (点)	20.1 ± 9.2		21.6 ± 6.8	
入院時の FIM 総得点 (点)	61.7 ± 29.9		64.3 ± 27.5	
退院時の運動 FIM 項目 (点)	64.5 ± 27.8		68.7 ± 23.2	
FIM 運動項目の利得 (点)	22.9 ± 16.8		26.0 ± 14.0	

表 2. 作成した予測モデルの決定係数と使用した変数

28 の変数を使用した予測モデル	
決定係数	0.799
使用した変数	FIM 食事 FIM 整容 FIM 清拭 FIM 上衣 FIM 下衣 FIM トイレ FIM 排尿 FIM 排便 FIM ベッド移乗 FIM トイレ移乗 FIM 浴槽移乗 FIM 移動 FIM 階段 FIM 運動合計点 FIM 理解 FIM 表出 FIM 交流 FIM 問題解決 FIM 記憶 FIM 認知合計点 FIM 合計点 年齢 入院上限期間 コース立方体テストの IQ Mini Mental State Examination 日本版 (MMSE-J) Functional Assessment for Control of Trunk (FACT) Berg Balance Scale (BBS) 発症から回復期病棟入院までの日数




図 1. 各予測値と実際の退院時運動 FIM の 2 次元プロット

は認められなかった ($t=1.146$, $p=0.258$, $r=0.170$).

相関係数は AI 予測が $r=0.939$, セラピスト予測が $r=0.943$, 決定係数は AI 予測が $R^2=0.881$, セラピスト予測が $R^2=0.889$ であった. また, 両者の相関係数に有意差は認められなかった ($z=-0.295$, $p=0.768$).

両者の予測誤差を残差分布のカーネル密度プロット

にて図示した (図 3). AI 予測は残差 0 点付近に分布が集中したのに対し, セラピスト予測は全体的に実測値より高い予測をしている傾向が認められた.




図 2. AI とセラピストの予測誤差

考察

1. 予測モデルの妥当性

本研究で作成した予測モデルの決定係数は 0.799 であった。

先行研究では、Meyer らは退院時 FIM を目的変数とした複数の予測式の決定係数の平均が 0.65 (0.35–0.82) であることを報告しており [2], 徳永も退院時 FIM を目的とした 12 の予測式の決定係数について中央値が 0.691 であることを報告している [3].

これらと比較して、本モデルの決定係数は決して低い結果ではないと考える。

2. 予測精度と先行研究との比較

本モデルの残差は 5.43 ± 5.93 点であった。

Wada ら [15] は、回復期リハ病棟の入院患者 1,502 例を対象に、先行研究をもとに 3 種類の重回帰分析を用いた予測式の精度を検討している。その中で、退院時運動 FIM の実測値から予測式での予測値を引いた残差の絶対値で精度を比較しており、得られた値は、予測式によって異なるが、その値は 7.30–9.38 の範囲であったことを報告している。

この報告からも本結果は、従来の予測式よりも実測値に近い高精度な予測が可能であることを示している。

3. セラピスト予測結果との比較と臨床的意義

セラピストの予測値と比較した結果、統計的な有意差は認められなかった。これは、今回作成した AI 予測モデルを使用する事でセラピストと同程度の精度で予測できることを示唆している。

また今回の結果において、セラピストは実際の退院時運動 FIM や AI 予測より、全体的に予測を高く見積もる傾向がみられた。特に退院時運動 FIM13~70 点の重度から軽度の介助を要する対象者についてその傾向が強い結果であった (図 2, 図 3)。山重ら [11] は回復期リハ病棟における療法士は退院時の FIM 予測値を高く見積もる傾向があることを示し、その理由として、担当療法士が担当患者の回復を期待して希望的に予測している可能性を考えた。本研究でも担当セラピストが予測を行うことで回復を期待した希望的予測により予測値が高い傾向があったと考える。また、山重ら [11] は機械的に予測式を活用することで精度の向上が期待できると考えられると述べている。このことから、本モデルを臨床で活用することにより、経験年数を問わず一定の精度で退院時運動 FIM の予測が行え、予測精度が向上する可能性があると考えられる。

4. 今後の課題

一般的に、機械学習は症例数が増えるほど予測精度が向上する。本研究は訓練用データ 457 名、検証用データ 43 名で行ったが、今後は症例数をさらに蓄積することで、より高精度なモデルの構築が期待できる。

本研究の限界と今後の展望

1. ツールの特性と項目選定の課題

使用した Prediction One は、機械学習の性質上、モデルの構築・選択過程を詳細に追跡することが困難である。また、AI による自動処理の一方で、評価項目の取舍選択には解析者の手作業と試行錯誤が必要であり、相応の労力を要する。今後は外れ値の要因分析や解析手法を再検討し、誤差を縮小させるための項目選定やモデル更新が必要であると考えられる。

2. 対象疾患の拡大や他施設での検証

今回は脳卒中症例のみを対象とした。しかし、回復




図 3. 残差分布のカーネル密度プロット

期リハ病棟には運動器疾患や廃用症候群の患者も多く入院する。今後は対象を全疾患へ拡大し、より汎用性の高い予測モデルの作成を進めていきたい。

今回退院時運動 FIM を入院時データから予測するモデルを作成し、セラピストと同程度の精度が得られたが、これはあくまで当院のデータを用いた単一医療機関での検証である。そのため外的妥当性は保証されないことに留意が必要である。今後、他施設のデータでの検証などを進め、汎用性を検証していく必要があると考える。

謝辞

本論文の作成にあたり、多くの方々にご指導ご鞭撻を賜りました。札幌医科大学保健医療学部作業療法学第一講座の太田久晶教授、並びに齊藤秀和助教には終始適切なご指導を賜りました。ここに深謝の意を表します。

文献

1. Tokunaga M, Sannomiya K, Ohashi T, Yonemura M, Sakata D, Imaya M, et al. Three different methods for demonstrating that gain in Functional Independence Measure increases with higher cognitive ability. *Jpn J Compr Rehabil Sci* 2014; 5: 26–32.
2. Meyer MJ, Pereira S, McClure A, Teasell R, Thind A, Koval J, et al. A systematic review of studies reporting multivariable models to predict functional outcomes after post-stroke inpatient rehabilitation. *Disabil Rehabil* 2015; 37: 1316–23.
3. Tokunaga M, Review of multiple regression analysis for stroke patients hospitalized Kaifukuki Rehabilitation Wards. *J Clin Rehabil* 2020; 29: 958–63. Japanese.
4. Tokunaga M, Sannomiya K, Yonemitsu K, Accuracy comparison of neural network and multiple regression analysis in the prediction of motor FIM at Kaifukuki discharge. *J Clin Rehabil* 2022; 31: 599–605. Japanese.
5. Tokunaga M. Review of reports evaluating motor FIM improvement of stroke patients in convalescent rehabilitation wards using logistic regression analysis. *J Clin Rehabil* 2022; 31: 390–4. Japanese.
6. Tokunaga M, Hori K, Ehara K, Murao S, Akase R, Nishi S, Otsuka A, et al. Review of multiple regression analysis for stroke patients hospitalized in Kaifukuki Rehabilitation Ward. *J Clin Rehabil* 2016; 25: 821–6. Japanese.
7. Tokunaga M, Prediction of motor FIM gain by multiplying the effect of factors on standard motor FIM gain predicted by motor FIM score at admission. *J Clin Rehabil* 2021; 30: 1518–25. Japanese.
8. Tokunaga M, Sannomiya K, Nakashima Y, Nojiri S, Tokisato K, Katsura K, et al. Formula for Predicting FIM Gain and Discharge FIM —Methods using Median Values of FIM Gain Stratified by Admission FIM, Age, Cognitive Function, and Transfer Interval—. *Jpn J Compr Rehabil Sci* 2015; 6: 6–13.
9. Tokunaga M, Tori K, Eguchi H, Kado Y, Ikejima Y, Ushijima M, et al. The stratification of motor FIM and cognitive FIM and the creation of four prediction formulas to enable higher prediction accuracy of multiple linear regression analysis with motor FIM gain as the objective variable—An analysis of the Japan Rehabilitation Database. *Jpn J Compr Rehabil Sci* 2017; 8: 21–9.
10. Tokunaga M, Yamanaga H. Comparison of the accuracy of multiple regression analysis using four methods to predict the functional independence measure at discharge. *Jpn J Compr Rehabil Sci* 2020; 11: 65–72.
11. Yamashige T, Kasai R, Furunishi Y, Honma K. Validation of the accuracy of prediction of motor FIM by therapists in a recovery unit. *Phys Ther Niigata* 2022; 25: 11–15. Japanese.
12. Katsuki M, Kakizawa Y, Nishikawa A, Yamamoto Y, Uchiyama T. Postsurgical functional outcome prediction model using deep learning framework (Prediction One, Sony Network Communications Inc.) for hypertensive intracerebral hemorrhage. *Surg Neurol Int* 2021; 12(203): 1–11.
13. Katsuki M, Kawamura S, Koh A. Easily Created Prediction Model Using Automated Artificial Intelligence Framework (Prediction One, Sony Network Communications Inc, Tokyo, Japan) for Subarachnoid Hemorrhage Outcomes Treated by Coiling and Delayed Cerebral Ischemia. *Cureus* 2021; 13(6): e15695
14. Katsuki M, Narita N, Ozaki D, Sato Y, Jia W, Nishizawa T, et al. Deep Learning-Based Functional Independence Measure Score Prediction After Stroke in Kaifukuki (Convalescent) Rehabilitation Ward Annexed to Acute Care Hospital. *Cureus* 2021; 13: e16588
15. Wada Y, Sonoda S, Okamoto S, Watanabe M, Okazaki H, Okuyama Y. Comparison of prediction accuracy of the total score of FIM motor items at discharge in post-stroke patients in a Kaifukuki rehabilitation ward. *Jpn J Compr Rehabil Sci* 2019; 10: 71–6.