

一般口演 | 医療データ解析

一般口演16

医療データ解析

2019年11月23日(土) 14:40 ~ 16:40 B会場 (国際会議場 2階コンベンションホールB)

[3-B-2-03] 入院時の患者情報からの退院時 Functional Independence Measure 予測

○小阪 勇氣¹、細井 利憲¹、久保 雅洋¹、亀田 佳一²、井上 姫花²、奥田 明²、久保 文郁²、伊藤 美由貴² (1. NEC データサイエンス研究所, 2. 医療法人社団 KNI)

キーワード : Functional Independence Measure, Prediction, Regression

回復期リハビリテーション病棟にとって、入院時の患者情報から、退院時の Functional Independence Measure (FIM、日常生活動作に関わる運動/認知機能を測るための指標) のスコアを患者個別に予測することは、患者の個別性を踏まえたリハビリテーション計画を立案するために重要である。FIMは、18項目から構成されるため、素朴には18個のモデルを作り、それらを独立に学習する方法が考えられる。しかし、その18項目には関係性があり、関係性を含めてそれらを同時に学習すれば、予測精度の向上が期待できる。そこで、本研究では、18項目のモデル間の関係性を含めて同時に学習する手法を提案する。データは、医療法人社団 KNI 北原リハビリテーション病院の電子カルテ (2018/1-2019/3) を用いた。この期間に入院し退院した患者のうち413人 (男性229、女性184、年齢40-90才代) を分析対象とした。特徴量は、性別、年齢層、入院時の FIM等、269種類を用いた。モデルにはリッジ回帰、評価方法には10-fold交差検定、評価指標には平均絶対誤差を用いた。提案手法と、18個のモデルを独立に学習する方法の予測精度を比較した結果、18項目の平均絶対誤差の平均は、それぞれ0.903、0.922であった ($p < 0.01$)。この結果から、18項目のモデル間の関係性を含めて同時に学習することによる予測精度向上の効果が示された。

入院時の患者情報からの退院時 Functional Independence Measure 予測

小阪 勇気^{*1}、細井 利憲^{*1}、久保 雅洋^{*1}、亀田 佳一^{*2}、井上 姫花^{*2}
奥田 明^{*2}、久保 文郁^{*2}、伊藤 美由貴^{*2}

*1NEC データサイエンス研究所、*2 医療法人社団 KNI

Prediction of Functional Independence Measure at Discharge using Patient Hospital Admission Data

Yuki Kosaka^{*1}, Toshinori Hosoi, Masahiro Kubo, Yoshikazu Kameda^{*2}, Himeka Inoue^{*2}
Akira Okuda^{*2}, Ayaka Kubo^{*2}, Miyuki Ito^{*2}

*1 Data Science Research Laboratories, NEC Corporation, *2 Kitahara International Hospital

We developed multiple prediction models for predicting the functional independence measure (FIM) at discharge from a rehabilitation hospital using patients' information recorded at admission. Accurately predicting the patient's discharge FIM at admission is important for developing a customized care plan for the patient. Since the FIM consists of 18 items (13 and 5 items representing motor FIM and cognitive FIM, respectively.), a separate prediction model can be made for each FIM item. However, even though previous studies have suggested relationships among motor FIM and cognitive FIM items, this approach lacks the structural information of the FIM. To tackle this issue, our proposed method creates separate prediction models for each FIM item and incorporates the similarities of each FIM item (based on previous studies as domain knowledge) into the learning prediction model simultaneously. We expected that incorporating FIM item similarities into the model would improve prediction accuracy. Experimentation to confirm the utilization of our proposed method was conducted using a real dataset provided by a rehabilitation hospital. The results showed that the prediction accuracy of our proposed method with the incorporated similarities outperformed one without the similarities.

Keywords: Functional Independence Measure, Prediction, Regression

1. 緒論

入院時の患者情報から、退院時の Functional Independence Measure (FIM) を患者個別に予測することは、回復期リハビリテーション病棟業務において、患者の個別性を踏まえたリハビリテーション計画を立案するために重要である。

FIM は、日常生活動作のレベルを測る指標として、一般的に用いられている[1]。FIM は、運動機能 13 項目と、認知機能 5 項目の計 18 項目から構成され、各項目は、介助量に応じて 1 点(全介助)から 7 点(完全自立)の値をとる。

退院時の FIM を患者個別に予測する機能を実現するためには、入院時の患者の情報を入力として、退院時の FIM の値を出力する予測モデルを、FIM の項目ごとに独立に 18 個作ればよい。

しかしながら、このように FIM の項目ごとに独立して予測する方法では、FIM の項目間にある関係性を考慮することができない。FIM の項目間には関係性があることが知られているため[2-4]、FIM の 18 項目を独立に扱わずに、18 項目の間にある関係性を予測モデルに取り込むことで、予測精度が向上することが期待できる。

ここで、FIM の項目間関係性としては、バランス機能が、FIM の「更衣」と「トイレ動作」の項目と強い相関があること[2,3]や、スピーチセラピーの時間と、FIM の認知機能の複数項目の間に相関関係があること[4]が例として挙げられる。

そこで、本研究では、従来の研究[2-4]で報告されているドメインナレッジを参考にして、FIM の運動機能 13 項目の間と、認知機能 5 項目のそれぞれの項目の間に関係性があることに着目し、同じ種類の機能に属する項目を予測対象とする予測モデルのパラメータが、互いに類似するように学習する方法を提案する。そして、実データによる評価実験により、その有効性を検証する。

2. 目的

本研究では、患者の個別性を踏まえたリハビリテーション計画を立案できるようにすることを目指し、患者の退院時の FIM の 18 項目を高精度に予測する手法の確立を目的とする。

3. 方法

3.1 問題定義

本研究では、入院時の患者情報から、退院時の FIM18 項目の値を予測する問題を、 $(x_i, y_{i,j}), (i = 1, \dots, N; j = 1, \dots, M)$ が入力として与えられた場合に、 $y_{i,j} \sim f_j(x_i)$ となる関数 $f_j(\cdot)$ を学習する問題として定義する。

ここで、 $x_i \in R^D$ は、患者 i の入院時の患者情報を表す。また、 D と N は、それぞれ、患者情報の特徴量の次元と患者数を表す。 j は、FIM の項目の種類を表し、 M は、FIM の項目数を表す。FIM の項目数は計 18 のため、 $M = 18$ であり、 j は、FIM の 1 項目～18 項目に対応する。 $y_{i,j} \in \{1, 2, 3, 4, 5, 6, 7\}$ は、患者 i の FIM の第 j 項目の値を表す。

3.2 提案手法

提案手法では、関数 $f_j(\cdot), (j = 1, \dots, M)$ の間に、関係性があることを仮定して、運動機能に関する $f_j(\cdot), (j = 1, \dots, 13)$ については、モデルパラメータが似ているように学習する。さらに、認知機能に関する $f_j(\cdot), (j = 14, \dots, 18)$ についても、互いにモデルパラメータが似ているように学習する。

関数 $f_j(\cdot)$ には、任意の予測モデルを採用することができるが、本研究では線形回帰モデルを用いる。線形回帰モデルは、 $f_j(x_i) = w_j^T x_i$ として表されるモデルである。ここで、

w_j^T は、関数 $f_j(\cdot)$ のモデルパラメータ (D 次元のベクトル) を表

す。また、 T は転置を表す。そして、合計 M 個のモデルパラメータをまとめて、 $D \times M$ サイズの行列 $W = [w_1, w_2, \dots, w_M]$ として表す。

3.2.1 FIM の項目間の関係性

関数 $f_j(\cdot)$, ($j = 1, \dots, M$) の間に、関係性があることを仮定して $f_j(\cdot)$ のモデルパラメータを学習するためには、どの関数が運動機能に属して、どの関数が認知機能に属するのかを学習アルゴリズムに組み込むことが必要である。そのため、本研究では、FIM の項目間の関係性を、 $M \times M$ サイズの類似度行列 S を用いて表現する。類似度行列 S の要素 $S(q, p)$ は、FIM の q 項目と p 項目の類似度を表す。したがって、 q と p が互いに運動機能に属する場合は、 $S(q, p) = 1$ とする。また、 q と p が互いに認知機能に属する場合は、 $S(q, p) = 1$ として、それ以外はゼロとする。

3.2.2 目的関数

提案手法では、類似度関数 S を用いて、同じ種類の機能(運動/認知)に属する関数 $f_j(\cdot)$, ($j = 1, \dots, M$) が、互いに類似するようにモデルパラメータ W を学習するために、次の目的関数を最小化する。

$$\min_W \{ \mathcal{L}(W) + \frac{\alpha}{2} \|W\|_F^2 + \beta \Omega(W) \}, \quad (1)$$

$$\mathcal{L}(W) = \sum_{j=1}^M \sum_{i=1}^N (y_{i,j} - w_j^T x_i)^2, \quad (2)$$

$$\Omega(W) = \frac{1}{4} \sum_{q=1}^M \sum_{p=1}^M S_{q,p} \left\| \frac{w_{*,q}}{\sqrt{D_{q,q}}} - \frac{w_{*,p}}{\sqrt{D_{p,p}}} \right\|^2, \quad (3)$$

ここで、式(1)の第一項目に当たる式(2)は、予測誤差を表す。第二項は、 W に関する正則化項であり、 $\|\cdot\|_F$ はフロベニウスノルムを表す。式(1)の第三項目に当たる式(3)は、類似度関数 S で表す関数 $f_j(\cdot)$ の関係性に基づいて、モデルパラメータ W を学習するための項である。類似度関数 S を目的関数に入れて最適化する方法は様々あるが、本研究では、関連研究[5]で提案されている式(3)の形を用いる。 $w_{*,q}$ は行列 W の q 列目のベクトルを表し、 $\|\cdot\|$ は、L2 ノルムを表す。さらに、 D は、対角行列であり、 (q, q) の要素が $D_{q,q} = \sum_p S_{q,p}$ で、それ以外はゼロである。 α, β は、調整パラメータであり、各項が目的関数に与える影響を制御する。

なお、式(1)の最適化は、準ニュートン法等で解くことができる[5]。

3.3 実験

実データを用いて、提案手法の有効性を確認した。

3.3.1 データ

病床数 75 の回復期リハビリテーション病院の 2018 年 1 月～2019 年 3 月までに記録されたデータを用いた。この期間に入院し退院した患者のうち 413 人(男性 229、女性 184、年齢 40-90 才代)を分析対象とした。特徴量は、性別、年齢層、入院時の FIM 等、計 269 種類を用いた ($D = 269$)。

3.3.2 評価方法

評価指標には、平均絶対誤差 (Mean Absolute Error: MAE

表 1 提案手法と比較手法の予測誤差

平均 MAE		差 ①-②
提案手法①	比較手法②	
0.903	0.922	-0.019

)を用いた。評価方法としては、10-fold 交差検定を計 10 回行った。具体的には、1 回の 10-fold 交差検定で、FIM の 18 項目についてそれぞれ MAE を算出した。そして、これを 10 回繰り返して、10 回の平均値(平均 MAE)を予測精度とした。

α, β は、 $\{0.01, 0.01, 1, 10, 100\}$ を候補として与えて、誤差が最も小さかった予測精度を最終的な予測精度として採用した。

さらに、 $f_j(\cdot)$ が 1～7 の離散値をとるようにするため、四捨五入をして予測値とした。

比較手法には、18 項目の関係性を考慮せずに独立に学習する方法を用いた。独立に学習する方法とは、式(1)の第三項目を削除した場合に相当する。提案手法と比較手法の予測精度を比較することで、18 項目の関連性を考慮する提案手法の有効性を検証できる。

さらに、提案手法と比較手法の予測精度の差について統計的に有意な差があるかを確かめるために、 t 検定を用いた。

4. 結果

表 1 に、提案手法と比較手法の予測精度を示す。提案手法と比較手法の平均 MAE は、それぞれ 0.903、0.922 で、統計的に有意な差 ($p < 0.01$) があつた。

5. 考察

この結果から、18 項目の関係性を考慮する提案手法の提案手法の有効性が確認できた。

6. 結論

本稿では、ドメインナレッジに基づく FIM の 18 項目の関係性を考慮して、退院時の FIM18 項目を予測する予測モデルの学習手法を提案した。実データを用いた結果、関係性を考慮することによって、患者の退院時の FIM の 18 項目を高精度に予測できることが確認できた。

参考文献

- 1) Wright, Jerry. Functional Independence Measure. Encyclopedia of Clinical Neuropsychology 2011; 1112-1113.
- 2) Sato A, Ohashi Y, Kawasaki E, Yamamoto Y, Onobe J and Fujita T: Evaluation criteria of excretion motion independence for stroke patients. Annual Report of The Tohoku Section of Japanese Physical Therapy Association 2013; 25: 104-109.
- 3) Fujita, Takaaki and Sato, Atsushi and Tsuchiya, Kenji et al. Relationship between Grooming Performance and Motor and Cognitive Functions in Stroke Patients with Receiver Operating Characteristic Analysis. Journal of Stroke and Cerebrovascular Diseases 2017; 26.
- 4) Sakai, Kotomi and Momosaki, Ryo. Real-world Effectiveness of Speech Therapy Time on Cognitive Recovery in Older Patients with Acute Stroke. Progress in Rehabilitation Medicine 2016; 1.
- 5) Nori, Nozomi and Kashima, Hisashi and Yamashita, Kazuto and Ikai, Hiroshi and Imanaka, Yuich. Simultaneous Modeling of Multiple Diseases for Mortality Prediction in Acute Hospital Care. Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining 2015; 855-864.