

一般口演 | 医療データ解析

一般口演17 データマイニング

2021年11月20日(土) 16:30 ~ 18:00 F会場 (2号館2階224)

[3-F-3-05] マルチタスク学習を用いた Functional Independence Measureの経時変化予測

*小阪 勇気¹, 荒木 賢志¹ (1. NEC バイオメトリクス研究所)

*Yuki Kosaka¹, Kenji Araki¹ (1. NEC バイオメトリクス研究所)

キーワード: Multi-Task Learning, Progression Prediction, Functional Independence Measure

回復期リハビリテーション病院にとって、入院時の患者情報から、退院時や退院後半年、1年後等の複数時点の Functional Independence Measure（日常生活動作に関わる運動/認知機能の指標）の合計点（以降、FIMスコア）を予測することは、患者個別のリハビリ計画に重要である。この予測は、時点ごとに、入院時の患者情報とその時点の FIMスコアのペアの情報を学習データとして用意し、予測モデルを学習することで実現できる。一方で、近年、複数の予測モデルを同時に学習するマルチタスク学習の研究が進んでおり、このマルチタスク学習を、時点ごとの FIMスコアを予測する予測モデルの学習に用いれば、各時点の予測精度が高まるのではないかと考えられる。そこで本研究では、各時点の予測モデルを1つのタスクとし、複数時点分の予測モデルを同時に学習するマルチタスク学習を FIMスコアの予測に適用する。マルチタスク学習では、タスク間の関係性の定義が重要となるが、本研究では、FIMスコアの経過と発症からの日数が対数関数によく当てはまるという従来研究の知見を、タスク間の関係性に用いる方法を提案する。公開データを用いて、入院時の患者情報（45種類）を入力とし、3時点（退院時、退院半年後、1年後）の FIMスコアを予測する予測モデルを構築、評価した。3時点の学習データ数は、それぞれ、1202、1056、834であった。10-fold交差検定の結果、マルチタスク学習を用いた場合は、マルチタスク学習を用いない場合と比べて、退院半年後と1年後では、予測誤差（二乗平均平方根誤差）がそれぞれ0.33、0.24（ $p<0.05$ ）小さかったが、退院時では差はなかった。この結果から、提案するマルチタスク学習手法を3時点の FIMスコア予測に適用した場合、退院半年後と1年後の FIMスコアの予測精度向上に有効と考えられた。

マルチタスク学習を用いた Functional Independence Measure の経時予測

小阪 勇気^{*1}、荒木 賢志^{*1}、
^{*1} NEC バイオメトリクス研究所

Progression Prediction of Functional Independence Measure Using Multi-Task Learning

Yuki Kosaka^{*1}, Kenji Araki^{*1}

^{*1} Biometrics Research Laboratories, NEC Corporation

By using stroke patients' information recorded upon admission to a rehabilitation hospital, we developed multiple prediction models that predict the patients' functional independence measure (FIM) scores at three points in time: discharge, half a year after discharge, and one year after discharge. Predicting the FIM accurately upon admission will make it possible to develop customized care plans for patients. To improve accuracy, we created multiple models to simultaneously predict the FIM scores at the three time points and leveraged the temporal prior information on a progression of FIM scores using multi-task learning (MTL). Because previous studies suggested that the relationship between FIM scores and the number of days after the stroke onset fit a logarithmic function, we anticipated that the prediction accuracy would improve by integrating the relationship as the temporal prior information into the multiple prediction models. We carried out experiments using a public dataset on stroke patients' recovery to validate our MTL method. The number of data for each time point was 1202, 1056, and 834, respectively, and the dimension of features was 45. We used 10-fold cross validation to evaluate the prediction accuracy. The results showed that the prediction accuracy of our MTL method was higher than when learning each prediction model independently, particularly for two time points (half a year and one year after discharge).

Keywords: Multi-Task Learning, Progression Prediction, Functional Independence Measure

1. 緒論

回復期リハビリテーション病棟にとって、脳卒中患者の入院時の患者情報から、退院時や退院から半年後、一年後等の複数時点における Functional Independence Measure (日常生活動作に関わる運動/認知機能の指標:FIM) の合計点を予測することは、患者の患者個別性を踏まえたリハビリテーション計画の立案に重要である。

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おり、運動機能 13 項目と、認知機能 5 項目の計 18 項目から構成される[1]。各項目は、介助量に応じて 1 点(全介助)から 7 点(完全自立)の値をとり、FIM の合計点(以降、FIM スコア)は、18 点~126 点の値となる。

この予測は、時点ごとに、入院時の患者情報とその時点の FIM スコアのペアの情報を学習データとして用意し、予測モデルを学習することで実現できる。一方で、近年、複数種類の予測モデルの関係性を考慮しつつ、それらを同時に学習することによって、個々の予測モデルの予測精度の向上を図る、マルチタスク学習の研究が進んでいる[2-5]。このマルチタスク学習を、時点ごとの FIM スコアを予測する予測モデルの学習に用いれば、各時点の予測精度が高まるのではないかと考えられる。

マルチタスク学習では、学習の際に考慮する、タスク間の関係性が重要となる。複数時点の FIM スコアの予測にマルチタスク学習を適用する場合は、1 時点の FIM スコアの予測モデルの学習を 1 つのタスクとして扱うため、時間経過と FIM スコアとの関係性を、タスク間の関係性として扱うことができる。時間経過と FIM スコアの関係性については、発症からの日数と FIM スコアが対数曲線に類似している、ということが報告されており[6]、この関係性を用いたマルチタスク学習によって、予測精度の向上が期待できる。

2. 目的

本研究では、入院時の患者情報を入力として、退院時、退

院から半年後、退院から一年後の予め定めた、将来の複数時点ごとの FIM スコアを出力する、FIM スコアの経時変化予測問題に対して、時間経過と FIM スコアの関係性をタスク間の関係性として用いるマルチタスク学習によって、予測精度が向上するか、明らかにすることを目的とする。

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、退院から半年後、退院から一年後の 3 時点での FIM スコアを予測する問題を、 $(\mathbf{x}_i, \mathbf{y}_{i,j}), (i = 1, \dots, N_j, j = 1, \dots, 3)$ が入力として与えられた場合に、 $\mathbf{y}_{i,j} \sim f_j(\mathbf{x}_i)$ 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、 $\mathbf{x}_i \in R^D$ は、i 番目の患者の入院時の患者情報を表す。 D は、入院時の患者情報の特徴量の次元数を表す。 j は、予測対象の時点を表す。 N_j は、時点 j の FIM スコア $\mathbf{y}_{i,j}$ が測定されている患者の合計数を表す。 $\mathbf{y}_{i,j}$ は、j 番目の時点の FIM スコアが測定されている患者 i の FIM スコアを表し、18 ~ 126 の整数をとる。

3.2 線形回帰モデル

本節では、3.1 節で定義した問題の関数 $f_j(\cdot), (j = 1, \dots, 3)$ に、線形回帰モデル $f_j(\mathbf{x}_i) = \mathbf{w}_j^T \mathbf{x}_i$ を用いて、タスク間の関係性を考慮しない場合について説明する。

タスク間の関係性を考慮せず、各タスク独立に線形回帰モデルを学習する場合は、下記の目的関数を最小化する関数 $f_j(\cdot)$ のモデルパラメータ $\mathbf{w}_j$ を求めればよい。

$$\min_{\mathbf{w}} \{ \mathcal{L}(\mathbf{W}) + \frac{\alpha}{2} \|\mathbf{W}\|_F^2 \} \quad (1)$$

$$\mathcal{L}(\mathbf{W}) = \sum_{j=1}^3 \sum_{i=1}^{N_j} (y_{i,j} - \mathbf{w}_j^T \mathbf{x}_i)^2$$

ここで、モデルパラメータ $\mathbf{w}_j$ は、D次元のベクトルであり、Tは転置を表す。式(1)の第一項目は、予測誤差の二乗和を表す。第二項は、 $\mathbf{W}=[\mathbf{w}_1 \mathbf{w}_2 \mathbf{w}_3]$ 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。 α は、調整パラメータであり、目的関数に与える影響を制御する。この目的関数を最小化する、3個のモデルパラメータを、次式を用いてそれぞれ独立に求めることができる。

$$\mathbf{w}_j = (\mathbf{X}_j^T \mathbf{X}_j + \alpha \mathbf{I})^{-1} \mathbf{X}_j^T \mathbf{y}_j$$

ここで、 $\mathbf{I}$ は、 $D \times D$ サイズの単位行列で、 $\mathbf{X}_j$ は、j番目の時点のFIMスコアが観測されている N_j 人の患者の入院時の患者情報をまとめた、 $N_j \times D$ サイズの行列 $\mathbf{X}_j = [\mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_{N_j}]^T$ とする。また、 $\mathbf{y}_j$ は、 $\mathbf{y}_j = [y_{1j} y_{2j} \dots y_{N_j j}]^T$ の N_j 次元のベクトルである。

3.3 時間経過とFIMスコアの関係性

本節では、本提案手法でタスク間の関係性として用いる、時間経過とFIMスコアの関係性について説明する。

脳卒中による障害がどこまで回復するかは、患者ごとに大きく異なるが、回復の相対的な時間経過は類似している[6]。典型的には、最終的な回復の70%程度以上が発症後おおそ3カ月までに起こり、発症後半を過ぎるころから回復のスピードは遅くなる[6]。この様子は、対数曲線(図1)に類似しており、FIMスコアと発症からの日数を式(2)で表す方法が提案されている[6]。

式(3)は、式(2)を用いて、発症後A日目のFIMスコア($FIM_{(Day A)}$)と発症後B日目($B > A$)のFIMスコア($FIM_{(Day B)}$)の差分を表す。式(2)のパラメータである β は、式(3)を用いて、式(4)により求めることができる。

$$FIM = \beta \ln(Days) + Constant \quad (2)$$

$$\Delta FIM = FIM_{(Day B)} - FIM_{(Day A)} \quad (3)$$

$$= \beta \ln(Day B) - \beta \ln(Day A)$$

$$\begin{aligned} \beta &= \Delta FIM \left(\ln \left(\frac{Day B}{Day A} \right) \right)^{-1} \\ &= (FIM_{(Day B)} - FIM_{(Day A)}) \left(\ln \left(\frac{Day B}{Day A} \right) \right)^{-1} \quad (4) \end{aligned}$$

式(4)のパラメータ β を用いれば、 $FIM_{(Day A)}$ と $FIM_{(Day B)}$ から、第3の時点とする発症後Z日目における、FIMスコア($FIM_{(Day Z)}$)を次式により予測できる。




図1: 時間経過とFIMスコアの関係性: [6]を参考に作成

$$\begin{aligned} \Delta FIM &= FIM_{(Day Z)} - FIM_{(Day A)} \\ &= \beta \ln \left(\frac{Day Z}{Day A} \right) \end{aligned}$$

$$\begin{aligned} \text{Predicted } FIM_{(Day Z)} \\ &= FIM_{(Day A)} + \beta \ln \left(\frac{Day Z}{Day A} \right) \quad (5) \end{aligned}$$

ここで、 β には、式(4)を用いる。このように、従来研究[6]では、発症からの日数とFIMスコアが対数曲線に類似している関係性を用いて、2時点で計測された各FIMスコアから、式(5)の予測式によって、3時点目のFIMスコアの予測値が得られることが提案している。

3.4 時間経過とFIMスコアの関係性を用いたマルチタスク学習

前節で説明した、発症からの日数とFIMスコアが対数曲線に類似しているという、時間経過とFIMスコアの関係性を、3.1節で定義した問題の関数 $f_j(\cdot)$, ($j = 1, \dots, 3$)を学習する方法に組み込んだ、マルチタスク学習について説明する。

ここでは、3.2節と同様に、関数 $f_j(\cdot)$, ($j = 1, \dots, 3$)に、線形回帰モデル $f_j(\mathbf{x}_i) = \mathbf{w}_j^T \mathbf{x}_i$ を用いた場合を例に説明する。

式(5)をタスク間の関係性として用いて、各タスクの線形回帰モデルを同時に学習する場合の目的関数を式(6)に示す。

$$\min_{\mathbf{W}} \left\{ \mathcal{L}(\mathbf{W}) + \frac{\alpha}{2} \|\mathbf{W}\|_F^2 + \frac{\beta}{2} \Omega(\mathbf{W}) \right\} \quad (6)$$

$$\begin{aligned} \Omega(\mathbf{W}) &= \|\mathbf{w}_{DayZ} - (1-c)\mathbf{w}_{DayA} - c\mathbf{w}_{DayB}\|^2 \quad (7) \\ &= \|\mathbf{W}\mathbf{h}\|^2 \end{aligned}$$

ここで、式(6)の第三項目は、関数 $f_j(\cdot)$ の関係性に基づいて、モデルパラメータ $\mathbf{W}$ を学習するための項である。この項は、 $\mathbf{W}$ が式(5)を満たさなければ大きな値をとる。 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。そして、 $\mathbf{W}$ と $\mathbf{h}$ はそれぞれ、 $\mathbf{W} = [\mathbf{w}_{DayA}, \mathbf{w}_{DayB}, \mathbf{w}_{DayZ}]$ と $\mathbf{h} = [-(1-c), -c, 1]$ である。ここで、 c は次式で表す。

$$c = \left(\ln \left(\frac{Day B}{Day A} \right) \right)^{-1} \ln \left(\frac{Day Z}{Day A} \right)$$

式(6)は微分可能であり、式(6)を最小化するパラメータ $\mathbf{W}$ は、解析的に求めることができる。

3.5 実験

公開されている脳卒中患者の FIM データを用いて、本提案手法の有効性を評価した。

3.5.1 データ

公開されている脳卒中患者の FIM データを用いた[7]。このデータには、2005 年から 2006 年に、アメリカのリハビリテーション病院に入院した患者計 1219 名の合計 226 種類の属性情報が含まれている。その属性情報の中には、入院時、退院時、退院後 80-180 日、退院後 365-425 日の 4 時点の FIM スコアが含まれている。

本実験では、本データを用いて、入院時の患者の FIM スコアとその属性情報を入力すると、退院時、退院後 80-180 日、退院後 365-425 日に計測された 3 時点の FIM スコアを予測する予測モデルを構築して、その予測精度を評価した。

提案手法では、タスク間の関係性として、発症から FIM 計測日までの経過日数の情報を必要とするが、本データには発症日の情報が含まれていない。また、退院後 80-180 日、退院後 365-425 日に計測された FIM スコアがデータとして記録されているため、各患者の FIM スコアが計測された正確な日数を特定することができない。そこで、本実験では、アメリカの平均在院日数などの関連研究の情報をを用いて、退院時の FIM スコアの計測日、リハビリテーション病院退院後半年の FIM スコアの計測日、リハビリテーション病院退院後 1 年の FIM スコアの計測日の 3 時点を設定した。

具体的には、アメリカのリハビリテーション病院の平均在院日数を 16.5 日[8]と設定した。そして、Acute hospital を退院してからリハビリテーション病院に入院した脳卒中患者を想定し、発症からリハビリテーション病院に入院するまでの日数を、4.6 日と設定した(Acute hospital の平均入院期間[9]を参考にした)。これらの数値を用いて、退院時の FIM スコアの計測日は、発症から 21.1 日(4.6 日+16.5 日)、リハビリテーション病院の退院から半年後の FIM スコアの計測日は、発症から 151.1 日(80-180 日の中間である 130 に 21.1 日を足した)、リハビリテーション病院の退院から 1 年後の FIM スコアの計測日は、発症から 416.1 日(365-425 日の中間である 395 に 21.1 日を足した)とした。

実験には、1219 名のうち、入院時と退院時の FIM スコアが記録されている 1202 名の患者を対象とした。1202 名のうち、リハビリテーション病院を退院してから半年後の FIM スコアが記録されているのは、1056 名、リハビリテーション病院を退院してから 1 年後の FIM スコアが記録されているのは、834 名であった。リハビリテーション病院の退院後に、FIM スコアを計測する患者数は、退院後から時間が経つほど、減少している。

実験で用いた特徴量を表 1 に示す。特徴量は、性別、年齢層、入院時の FIM スコアなど、計 45 種類を用いた(D=45)。

また、式(7)の Day A は退院時、Day B は退院から半年後、Day Z は退院から 1 年後に対応させて、 $h = [-(1-c), -c, 1] = [0.51, -1.51, 1]$ とした。

3.5.2 評価方法

評価方法は、10-fold 交差検定、評価指標には、二乗平均平方根誤差(Root Mean Squared Error: RMSE)を用いた。調整パラメータの α, β は、{0.0, 0.1, 1.0, 10.0, 100.0, 1000}を候補として与えて、5-fold 交差検定で決定した。 $f_j(\cdot)$ が出力する予測値は、実数になるので、予測値を四捨五入した後、予測対象の項目が取りうる値の範囲を下回る場合は、そ

表 1: 特徴量一覧(45 種類)

種類	詳細
基本情報	AGE,FEMALE,RACE,RACE_WHITE,MARRIED,ADMITFROM,LIVSETTING_A,LIVWITH_A,PAYPRIME,PAYSECOND, IAG_MAIN, DIAG_IG
疾患情報	COMORB_ARTHRITIS,COMORB_CANCER,COMORB_RESPIRATORY,COMORB_DIABETES,COMORB_HTN,COMORB_HEART,COMORB_OTHER_CIRC,COMORB_KIDNEY,COMORB_OBESITY,COMORB_MENTAL,OMORB_FRACTURES
合併症	COMPL_ACUTERESPIR,COMPL_INFECTIOUS, COMPL_BEDSORES,COMPL_INFECT_KIDNEY,COMPL_DEHYDRATION
脳卒中の状況	STROKESYM_HEMIP,STROKESYM_PARALYSIS,STROKESYM_APHASIA,STROKESYM_DYSPHAGIA,STROKESYM_NEUROMUSC
その他	SIGNS_OF_DEHYDRATION_A,DISTANCE_WALKED_A,SHORT_BREATH_EXERTION_A,SHORT_BREATH_REST_A,PAIN_A,STANDING_PROBLEM_A
入院時 FIM スコア	FIM_SLFCAR_A,FIM_SPHCTR_A,FIM_TRANSFER_A,FIM_LOCOM_A,FIM_COMMUNICATION_A,FIM_SOCIAL_A

の範囲の最小値(18)に、上回る場合は最大値(126)になるように補正した。

比較手法は、タスク間の関係性を考慮せずに独立に学習する方法(シングルタスク学習)とした。独立に学習する方法とは、式(1)に相当する。マルチタスク学習とシングルタスク学習の予測精度を比較することにより、タスク間の関係性として式(5)を用いることによって、予測精度が向上するかが検証できる。さらに、マルチタスク学習とシングルタスク学習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、対応のある t 検定を用いた。

また、マルチタスク学習を適用するメリットを明らかにするため、学習データ数を段階的に小さくした場合の予測精度を、シングルタスク学習とマルチタスク学習で比較した。3 つのタスク(1)退院時の FIM スコアの予測モデルの学習、2)リハビリテーション病院退院から半年後の FIM スコアの予測モデルの学習、3)リハビリテーション病院退院から 1 年後の FIM スコアの予測モデルの学習、のうち、2)と 3)の学習に用いる学習データの割合 q を、 $q=\{0.8,0.6,0.4,0.2\}$ と変更して、それぞれ、シングルタスク学習とマルチタスク学習で予測精度を比較した。

この実験は、リハビリテーション病院から退院後に、FIM スコアを継続して計測できる患者数が、退院時に計測できた患者数よりも、少なくなった場合を想定したものである。一般的に、同一患者から長期間に渡って、継続してデータを収集することは容易でないため[10,11]、リハビリテーション病院の退院後に、患者の FIM スコアを継続して計測できる患者数が、

退院時に計測できた患者数よりも減った場合でも、マルチタスク学の方が、シングルトask学習よりも予測精度が高いか検証することを目的とした。

4.結果

表 2 に、マルチタスク学習とシングルトask学習を適用した場合について、退院時(D)、退院から半年後(F)、退院から一年後(Y)の予測精度を示す。マルチタスク学習とシングルトask学習で、退院時の RMSE には、差はないが、退院時から半年後と一年後では、それぞれ、0.33 と 0.24 の差があった($p<0.05$)。

また、表 3 に、学習データ数を変化した場合の予測精度を示す。退院時の RMSE は、学習データ数の割合を小さくしても、マルチタスク学習とシングルトask学習で差はなかった。一方で、退院から半年後と、退院から一年後の RMSE は、学習データ数の割合が 0.8~0.2 に変えた全ての場合において、マルチタスク学習の方がシングルトask学習よりも予測誤差が小さかった($p<0.05$)。退院時から半年後の予測誤差は、学習データ数の割合を小さくするほど、マルチタスク学習とシングルトask学習の RMSE の差が増大した。

5.考察

発症からの日数と FIM スコアが対数曲線に類似する、という時間経過と FIM スコアの関係性を、タスク間の関係性としてマルチタスク学習に活用したことによって、退院から半年後(F)、退院から一年後(Y)の FIM スコアの予測では、予測精度が向上する効果があることが示された。

一方で、退院時(D)の FIM スコアの予測では、予測精度向上の効果はみられなかった。時間経過と FIM スコアの関係性を表す式(7)では、退院時(D)、退院から半年後(F)、退院から一年後(Y)の 3 つのモデルパラメータの間の関係性を表しており、退院時(D)のモデルは、3 つのうち最も、 h の重みが小さい。そのため、式(7)の効果が他の 2 つと比べて小さく、退院時のモデルパラメータの学習には、マルチタスク学習の効果が小さいため、結果的に、シングルトaskモデルの予測精度とマルチタスク学習の予測精度に差が表れなかったと考えられる。

リハビリテーション病院の退院から半年後と一年後で、それぞれ、学習データ割合を減らすほど、予測誤差が増加する傾向がみられたが、マルチタスク学習の方が、シングルトask学習よりも、予測精度の低下は小さく抑えられていた。

例えば、退院から半年後(F)の予測では、学習データの割合が 0.4 の場合のマルチタスク学習の予測誤差が、学習データの割合が1の場合のシングルトaskの予測誤差よりも小さかった。この結果は、本来の学習データの 4 割のみ収集してマルチタスク学習を適用すれば、学習データ 10 割を収集してシングルトask学習を適用した場合と、同等の予測精度を達成できることを示唆している。

また、退院から 1 年後(Y)の予測では、学習データの割合が 0.6 の場合のマルチタスク学習の予測誤差が、学習データの割合が1の場合のシングルトaskの予測誤差よりも小さかった。これは、本来の学習データの 6 割のみ収集してマルチタスク学習を適用すれば、学習データ 10 割を収集してシングルトask学習を用いた場合と、同等の予測精度が達成できることを示唆している。

これらの結果から、リハビリテーション病院の退院後に、患者の FIM スコアを継続して計測できる患者数が、退院時に計測できた患者数より減った場合、マルチタスク学習の方が、シングルトaskよりも、予測精度の低下を抑制できることが示さ

表 2: 退院時(D)、退院から半年後(F)、退院から一年後(Y)

の各手法の予測精度(RMSE): *: $P<0.05$

	手法		差
予測対象	シングルトask 学習 1)	マルチタスク 学習 2)	1)-2)
D	13.71	13.70	0.01
F	17.58	17.25	0.33*
Y	17.12	16.88	0.24*

表 3: 学習データ数を変えた場合の退院時(D)、退院から半年後(F)、退院から一年後(Y)の予測精度(RMSE): *: $P<0.05$

		手法		差
予測対象	FとYの学習 データ割合:q	シングルトask 学習 1)	マルチタスク 学習 2)	1)-2)
D	0.8	13.72	13.74	-0.02
D	0.6	13.73	13.72	0.01
D	0.4	13.72	13.73	-0.01
D	0.2	13.72	13.71	0.01
F	0.8	17.58	17.16	0.42*
F	0.6	17.72	17.22	0.50*
F	0.4	18.06	17.45	0.61*
F	0.2	19.18	17.91	1.27*
Y	0.8	17.30	17.04	0.26*
Y	0.6	17.30	17.07	0.23*
Y	0.4	17.49	17.15	0.34*
Y	0.2	19.00	18.38	0.62*

れた。

6.結論

発症からの日数と FIM スコアが対数曲線に類似する、という時間経過と FIM スコアの関係性を、タスク間の関係性として、複数の予測モデルを同時に学習するマルチタスク学習を適用することにより、退院から半年後、退院から一年後の FIM スコアの予測で、予測精度が向上する効果があることが示された。

今後の主な検討課題は、次の 3 つである。1) 今回は 3 時点の予測を対象としたが、3 時点以上の任意の時点数の予測への適用可能性の検討、2)発症日が正確に特定できるデータを用いた検証(本実験では、発症日が正確に特定困難なため、本実験用に事前に設定した)、3) FIM スコアだけではなく、運動 FIMと認知 FIMのそれぞれを予測対象とした場合にも、今回と同様のマルチタスク学習の効果があるか検証すること。

参考文献

- 1) Wright, Jerry. Functional Independence Measure. Encyclopedia of Clinical Neuropsychology 2011; 1112-1113.
- 2) Hunt, X., Emrani, S., Kabul, I. and Silva, J. Multi-Task Learning with Incomplete Data for Healthcare. KDD Workshop on Machine Learning for Medicine and Healthcare 2018.
- 3) Zhou, Jiayu and Yuan, Lei and Liu, Jun and Ye, Jieping A Multi-Task Learning Formulation for Predicting Disease Progression. KDD 2011; 9:814-822.
- 4) Harutyunyan, H.,Khachatrian, H., Kale, D.C., Ver Steeg, G., Galstyan, A. Multitask learning and benchmarking with clinical time series data. Scientific Data 2019; 96:6.
- 5) 小阪 勇気, 細井 利憲, 久保 雅洋ら, 入院時の患者情報か

らの退院時 Functional Independence Measure 予測. 第 40 回医療情報学連合大会 2019.

- 6) Tetsuo KOYAMA Outcome Prediction for Stroke Patients : An Application for Local Healthcare Networking. The Japanese Journal of Rehabilitation Medicine 2009; 46: 2: 108-117
- 7) Ostir, Glenn, Ottenbacher, Kenneth, and Kuo, Yong Fang Stroke Recovery in Underserved Populations 2005-2006 [United States]. Ann Arbor, MI: Inter-university Consortium for Political and Social Research [distributor] 2016-05-03.
- 8) Granger CV, Markello SJ, Graham JE, Deutsch A, and Ottenbacher KJ. The uniform data system for medical rehabilitation: report of patients with stroke discharged from comprehensive medical programs in 2000-2007. Am J Phys Med Rehabil 2009; 88:12: 961-972.
- 9) Hong, Ickpyo et al. Discharge Patterns for Ischemic and Hemorrhagic Stroke Patients Going From Acute Care Hospitals to Inpatient and Skilled Nursing Rehabilitation. American journal of physical medicine & rehabilitation. 2018; 97:9 636-645.
- 10) Bell, Melanie and Fairclough, Diane Practical and statistical issues in missing data for longitudinal patient-reported outcomes. Statistical methods in medical research 2014; 23:5:440-459.
- 11) Rubin DB. Inference and missing data. Biometrika. 1976; 63:3:581-592.