

一般口演 | 画像情報・生体信号処理

一般口演11

画像情報・生体信号処理

2019年11月23日(土) 09:00 ~ 11:00 E会場 (国際会議場 3階中会議室301)

[3-E-1-06] MRI画像による入院期間長期化の予測

○信太 圭一¹、岩穴口 孝²、佐々木 雅史、宇都 由美子² (1. 帝京大学 福岡医療技術学部, 2. 鹿児島大学病院 医療情報部)

キーワード : MRI, hospitalization, deeplearning, prediction

現在、入院時の状態に応じて、クリニカルパスを導入している。これにより、医療の標準化が勧められ、入院期間の短縮、ならびに医療の質と安全性の向上が図られている。しかし、患者によっては入院期間が長くなるのは避けられないのも事実である。入院の長期化は医療費を増大させる原因であり、各医療機関では入院時に退院困難事例の抽出を行っているが、医師・看護師等の主観的な判断で行われており、計画的な退院に至らない症例がある。

入院初期に、長期化するか客観的に予測することが出来れば、人員配置の増加などの対策を講じることが出来る。本研究では客観的に予測するために、入院初期に実施される画像検査、血液検査などの結果を用いて、入院期間長期化を予測できるかどうか検討を行った。

データセットは鹿児島大学病院からの提供を受け、対象期間内に脳腫瘍で手術した患者とした。入院時の血液検査結果、生化学検査結果の項目に欠損があるものは除外した。対象となったデータ数は60であった。画像検査はMRI画像を用い、横断像のT2強調画像とした。画像による入院期間長期化の予測は深層学習である事前学習済みネットワークのAlexnet、squeezenetを用いた。血液検査結果、生化学検査結果の項目による入院長期化の予測は機械学習にて行った。結果MRI画像による予測の結果、accuracyは0.750、0.833であった。機械学習の結果は0.721であり、MRI画像を用いた予測が若干ではあるが、精度が良い結果となった。

今後の課題として、学習オプションのさらなる検討、データ数の増加、画像と血液検査、生化学検査結果を合わせた予測を行い、精度を高める必要がある。本研究の結果、入院初期に行う画像検査、血液検査、生化学検査結果を用いて、入院長期化の予測を客観的に予測できる可能性が示唆された。

MRI による入院長期化の予測

信太 圭一^{*1}、岩穴口 孝^{*2,3}、佐々木 雅史^{*3}、宇都 由美子^{*2,3}

*1 帝京大学福岡医療技術学部診療放射線学科、*2 鹿児島大学病院医療情報部、
*3 鹿児島大学大学院医歯学総合研究科

Prediction of Extended Hospital Stays Using a Deep Learning Algorithm Based on MR Images

Keiichi Shida^{*1}, Takashi Iwaanakuchi^{*2,3}, Masashi Sasaki^{*3}, Yumiko Uto^{*2,3}

*1 Dep.of Radiological Technology, Faculty of Fukuoka Medical Technology,
Teikyo University *2 Dep.of Medical Informatics,Kagoshima University Medical and Dental Hospital
*3 Kagoshima University Graduate School of Medical and Dental Sciences

The long-term hospitalization is a cause of increasing medical costs. If it is possible to objectively predict the long-term hospitalization at an early stage, in advance measures that can be. In this study, we investigated whether a deep learning algorithm could be used to predict long-term hospitalization based on patient MR images. Datasets of the target patient were obtained by surgery in brain tumors during the period from April 1, 2017 to March 31, 2018. MR image of transverse was T2-weighted image. We use the Neural Network Toolbox Model of matlab is a soft made of Mathwork Corporation. We used Alexnet and SqueezeNet as transfer learning. Evaluation was performed using accuracy. Machine learning was used to predict the length of hospitalization using patient information. The discriminator was RUSboot. As a result of transfer learning by Alexnet, accuracy was 0.750 and SqueezeNet was 0.833. Accuracy of RUSboo was 0.689. In the future, we need to consider in order to obtain better accuracy.

Keywords: MRI, Deeplearning, Hospitalization, Prediction

1. 緒論

現在、多くの医療機関では、入院時の状態に応じて、クリニカルパスを導入している。これにより、医療の標準化が勧められ、入院期間の短縮、ならびに医療の質と安全性の向上が図られている。しかし、患者によっては、入院期間が長くなるのが避けられないのも事実である。入院の長期化は医療費を増大させる原因であり、各医療機関では入院時に退院困難事例の抽出を行っているが、医師・看護師等の主観的な判断で行われており、計画的な退院に至らない症例がある。入院初期に、長期化する客観的に予測することが出来れば、人員配置の増加などの対策を講じることが出来る。

早期、かつ客観的に入院期間長期化を予測するためには、入院前、入院早期に実施される検査を用いる必要がある。手術を実施する患者は、MRIなどの画像検査を入院前、あるいは入院早期に実施している。このため、MRI画像を用いた入院長期化の予測に用いるのは適している。さらに、MRIなどから得られた情報に基づいて、入院期間を予測した報告は見られない。そこで、本研究では早期、かつ客観的に予測するために、入院初期に実施される画像検査を用いて、入院期間長期化を予測できるかどうか検討を行った。また、入院前、入院早期に得られる患者情報として、血液検査、生化学検査結果などがある。これらを用いて機械学習により入院期間の長期化を予測し、MRI画像による予測結果と比較した。

2. 目的

本研究では、入院初期に実施される画像検査を用いて、入院期間の長期化を、早期ならびに客観的に予測できるかどうか検討した。

3. 方法

データセットは鹿児島大学病院からの提供を受けた。対象は2017年4月1日から2018年3月31日までの間に、脳腫瘍で手術した入院患者とした。入院期間を用いて、中央値により短い群と、長い群の2群に分けた。

3.1 Network Architectuer

本研究では、matlab (R2019a, Mathworks) の Neural Network Toolbox Modelを使用した。

事前に学習された畳み込み Neural Network Architectuer は Alexnet と SqueezeNet を使用した。Alexnet は画像分類でよく知られており、5層の畳み込み層と3つの全結合層からなる全8層の Neural Network を学習している。SqueezeNet は、ImageNet データベースの100万枚を超えるイメージで学習済みの畳み込みニューラルネットワークであり、このネットワークは、深さが18層、イメージを1000個のオブジェクトカテゴリに分類できる¹⁾。本研究では、Alexnet と SqueezeNet による転移学習を行った。

3.2 画像の前処理

本研究に使用したMRI画像は横断像でT2強調画像とし、1シリーズ24枚であった。24枚を1枚の画像に結合し(図1)、入力した。画像サイズは、転移学習では入力サイズは227×227×3とした。MRI画像は、ランダムに Training 用80%、Validation 用20%となるようにした。




図 1 複数枚を一枚に結合

3.3 Training Option

バッチサイズ、エポック数、学習率は表 1 のように組み合わせ決定した。評価には accuracy を用いた(式 1)。

表 1 バッチサイズ、エポック数、学習率

バッチサイズ	4, 8, 16, 32
エポック数	50, 100, 200, 300, 400, 500
学習率	0.1, 0.01, 0.001, 0.0001

$$\text{accuracy} = \frac{\text{number of TP} + \text{number of TN}}{\text{number of TP} + \text{FP} + \text{FN} + \text{TN}} \quad \dots \text{式1}$$

3.4 患者情報を用いた入院期間の予測

血液検査、生化学検査などの患者情報の項目を表1に示す。なお、患者によっては、検査結果に欠損値がある場合があった。欠損値のあった項目を除外したところ、得られた患者情報は 25 項目となった。上記の項目に対し、機械学習による分類を試みた。識別機は決定木、線形 support vector machine (SVM)、k-nearest neighbor (KNN)、random under sampling boost (RUSboost)決定木の 4 つを用いた。また、10 分割交差検証とした。

表 2 患者情報

年齢	身長	体重	ADL	WBC	RBC	Hb	Ht
MCV	MCH	MCHC	Plt	RDW	PDW	MPV	P-LCR
GOT	GPT	T-Bil	BUN	Cr	Na	K	Cl
eGFR							

4. 結果

対象となったデータ数は 60 件であった。入院期間の中央値は、14 日であった。最短入院日数は 7 日、最長入院日数は 42 日であった。また、中央値より短い群 44 件、長い群 16 件であった。Training Option を検討した結果、バッチサイズ 4、エポック数 200、学習率は 0.0001 とした。

Alexnet による転移学習の結果、accuracy は 0.750、SqueezeNet による転移学習の結果は 0.833 であった。

機械学習にて、患者情報を用いた入院期間の予測の精度は、決定木 0.59、KNN0.609、SVM63.9、RUSboot0.689 と最も精度が良かったものは RUSboot であった。

5. 考察

入院期間の長期化には、様々な因子がある²⁾³⁾が、どの場合でも入院期間長期化の兆候を早期に把握することが重要である。

脳腫瘍の治療のために手術を受けている患者において、

長期入院に関連する要因に、年齢、腫瘍のタイプやサイズ、患者の術前要因があるとの報告²⁾や、MRI 画像による年齢の推定の報告⁴⁾がある。本研究は、上記の情報を踏まえて、MRI 画像には年齢情報や腫瘍の情報が含まれており、MRI 画像を使用して、入院期間の長期化の予測が出来ないかを検討した。

Alexnet による転移学習の結果、accuracy は 0.750、SqueezeNet による転移学習の結果は 0.833 であり、患者情報による機械学習で得られた結果は 0.689 であった。MRI 画像を用いた予測のほうが、若干ではあるが精度が良い結果となった。患者情報による予測だけではなく、MRI 画像を用いた予測の可能性が示唆された。

MRI 画像を用いて、入院長期化を予測するには、1 シリーズ複数枚をどのように入力するかが、重要であると考ええる。今回は、複数枚を 1 枚にして入力したが、転移学習の際に入力サイズが 227×227 と小さくしなければならないため、十分な情報を学習させることが出来ていないと考える。GUO, Zhe らによると、特徴マップに変換してから、1 枚の画像にして入力する方法を報告⁵⁾していることから、今後検討していく必要がある。また、MRI 画像はグレースケールであるが、今回は RGB に変換し、入力している。MRI は T2 強調画像のみならず、様々なコントラストがある。それらを用いて、RGB に割り当てるなどの工夫も必要であると考ええる。データ数が少なく、過学習が起きやすい状態であったため、データ数を増やす必要がある。

今回は、MRI 画像による入院長期化、患者情報による入院長期化の予測と2つの手法を比較した。本研究の今後の方針として、MRI 画像に患者情報を付与して予測して行く予定である。

5. まとめ

MRI 画像を用いた入院期間の長期化の予測をしたところ、血液検査、生化学検査などの患者情報を使用した予測と比較して、若干ではあるが予測精度が良かった。今後、さらに予測精度を高めていく必要がある。

参考文献

- 1) <https://jp.mathworks.com/help/deeplearning/deep-learning-with-images.html>
- 2) TOSHIMA, M., NISHIYA, M., & HAGIWARA, R. (2001). Factors affecting length of stay and discharge destination in patients with acute ischemic stroke. The Japanese Journal of Rehabilitation Medicine, 38(4), 268-276.
- 3) 湯浅美千代, 小川妙子, 石塚敦子, 鈴木淳子, 内村順子, 本田淳子, & 本間ヨシミ. (2006). 高齢者専門急性期病棟における入院期間長期化の要因と退院支援の課題: 医療看護研究, 2(1), 73-81.
- 4) Dasenbrock, Hormuzdiyar H., et al. Length of hospital stay after craniotomy for tumor: a National Surgical Quality Improvement Program analysis. Neurosurgical focus 39.6 (2015): E12.
- 5) HUANG, Tzu-Wei, et al. Age estimation from brain MRI images using deep learning. In: 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017). IEEE, 2017. p. 849-852.
- 6) GUO, Zhe, et al. Medical image segmentation based on multi-modal convolutional neural network: Study on image fusion schemes. In: 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). IEEE, 2018. p. 903-907.
- 7) Rezaei, M., Yang, H., & Meinel, C. (2017). Brain abnormality detection by deep convolutional neural network. arXiv preprint arXiv:1708.05206.