

機械学習による在院日数予測 -病床スケジューリングへの応用-

05001311	東京理科大学	*小原樹杏 OHARA Juan
05000319	東京理科大学	伊藤真理 ITO Mari
01308970	東京理科大学	高嶋隆太 TAKASHIMA Ryuta
	東京理科大学	大和田勇人 OHWADA Hayato
01015653	防衛大学校/海老名総合病院	鵜飼孝盛 UKAI Takamori
	海老名総合病院	小泉正樹 KOIZUMI Masaki
	海老名総合病院	矢野明美 YANO Akemi
	海老名総合病院	松島俊輔 MATSUSHIMA Shunsuke
	海老名総合病院	猪口貞樹 INOKUCHI Sadaki

1. はじめに

病床は、病院内の人員や救急搬送応需率など様々な要因に影響を与えるため、効率的な管理が求められている。たとえば、病床が不足すると、入院を必要とする重要患者を受け入れることができず、応需率低下に繋がる。救命救急センターを持つ高度急性期病院である海老名総合病院においては、病床使用実績や天候のデータ等を参考に、必要入院数や患者の在院日数を予測し病床管理を行っている。在院日数の予測は患者の回復と病院のオペレーションの影響を受け、病床管理者の長年の経験を活かしても難しい。近年、データ解析技術による精緻な予測が求められている。

病床スケジューリング問題は国外を中心に研究されてきた[1,2]。これらの研究において、在院日数についての精緻な予測は行われていない。在院日数を予測する研究は、機械学習を用いて疾患別に予測したものが多い。たとえば Zolbanin et al.[3]は、入院時の年齢や性別などの変数をもとに、慢性閉塞性肺疾患及び肺炎患者の在院日数を深層学習ニューラルネットワークで予測した。

本研究では、機械学習による在院日数予測を用いた入院患者の病床スケジューリングモデルを提案する。具体的には、患者の病室希望などを考慮しつつ、病院の利益を最大化する病床スケジュールを作成する。スケジュールに用いる患者の在院日数は、機械学習によって予測する。海老名総合病院での実際の病床スケジュールと利益の比較を行う。

2. モデル

2.1. 機械学習による在院日数予測

本研究では在院日数を予測するために、特徴量が非常に多いことや説明変数の重要性を考えられるという点で、ランダムフォレストを用いる。海老名総合病院における2018年4月から2019年3月までの入院患者データのうち、病院で実際に必要とされる在院日数30日以下の11,572件について、一様分布となるように6分割して在院日数の分類予測を行う。説明変数は、入院患者に関する入院症例として患者の年齢やMDCコード等、バイタルとして呼吸数や体温等、検体検査データとして血清総たんぱくや赤血球数等である。学習データ8割、テストデータ2割として5交差検証を行う。

上記の方法で予測した在院日数をスケジューリングのパラメータ値として使用する。

2.2. 入院患者の病床スケジューリング

病床スケジューリング問題を0-1整数計画問題として定式化する。ここでは紙幅の制約のため、制約式の記載を省略する。

Maximize

$$\begin{aligned}
 & \sum_{b \in B} \sum_{p \in P} \sum_{t \in T} R_p^m s_{bpt} Q_t x_{bpt} + \sum_{r \in R} \sum_{p \in P} \sum_{t \in T} \sum_{w \in W} R_p^r Q_t y_{ rpt} \\
 & - \sum_{b \in B} \sum_{p \in P} \sum_{t \in T} C_p^f Q_t z_{bpt} \\
 & - \sum_{r \in R} \sum_{p \in P} \sum_{t \in T} \sum_{w \in W} C_p^l Q_t w_{pt}
 \end{aligned} \tag{1}$$

上記における集合として, B は病床の集合, P は患者の集合, T はスケジューリング期間, R は病室の集合, W は病室の種類の集合である. 変数として, x_{bpt} は患者 p が病床 b に t 日に入院中のとき 1, その他の場合 0 となるバイナリ変数, y_{rpt} は病床 r で入院中のとき 1 となるバイナリ変数, z_{bpt} は転床するとき 1 となるバイナリ変数, w_{pt} は患者希望室に割り当てられなかつたとき 1 となるバイナリ変数である.

目的関数(1)は, 患者が入院した場合の病院の利益を最大化する. 第 1 項目は患者の診療報酬 R_p^m の合計, 第 2 項目は室料差額 R_p^r の合計である. 第 3 項目は転床にかかるコスト C_p^f の合計, 第 4 項目は室料差額の機会損失 C_p^l とした. 病院の利益は, 割引因子 Q_t を目的関数に導入することで, スケジュール期間の早期に患者を割り当てた方が大きくなる. s_{bpt} は患者 p が日 t に病床 b が利用可能な場合に 1, その他の場合 0 となる定数で, 割当前の病院の病床状況と患者の入院診療科や手術日, 男女及び隔離制約の情報を考慮している. 制約式としては, 隔離が必要な患者を隔離する制約など計 12 個の制約がある.

実際のスケジューリングの流れと同様に, 1 段階目でクリニカルパス適応患者をスケジュールし, 2 段階目で一般患者のスケジューリングを行う.

3. 結果

本研究では, Visual Mining Studio ver.8.7 (NTT データ数理システム) を用いて学習モデル構築, 予測を行った. 解析時間は 2 分ほどである. 機械学習による在院日数予測は, 検証データの的中率が 42.9%と病床管理者の予測よりも精度の高い結果を得た. また, 説明変数の重要度についても, 病床管理者が在院日数実予測を行ううえで参考にしている説明変数となった.

数理最適化ソフトを用いて, 海老名総合病院での循環器科でスケジューリングを行った. 具体的には, スケジューリングの対象となる病床数 30 床 11 病室(うち 3 病室が室料差額が発生する病室), スケジューリング期間 7 日, 1 段階目で割り当てるパス適応患者 4 名 (男

性 3 名女性 1 名), 2 段階目で割り当てる一般患者(要隔離患者 1 名男性 3 名)を想定した. 患者の在院日数について, 実際の在院日数を用いてスケジューリングしたものと, 予測した在院日数の 2 パターンでスケジューリングを行い, 実際の病院でのスケジューリング結果と利益などを比較する.

結果として, 患者は早期に割り当てられ, 目的関数に基づく結果となった. また, 実際の在院日数を用いて本モデルでスケジューリングを行ったところ, 病院の利益は実際の結果よりも大きくなつた.

4. おわりに

本研究では, 機械学習による在院日数予測を用いた入院患者の病床スケジューリングモデルを提案した. また, 在院日数を過去のデータから予測し, それらのデータを用いてスケジューリング問題を解いた結果, 本研究のモデルより導出された利益が実際のものよりも大きくなることが示された.

今後の展望として, 在院日数の予測精度を向上させるだけでなく, 入院数の予測を行い, スケジューリングに応用することがあげられる.

参考文献

- [1] He, L., Madathil, S., Oberoi, A., Servis, G., Khasawneh, M., A systematic review of research design and modeling techniques in inpatient bed management, *Computers & Industrial Engineering* 127, 451—466, 2019.
- [2] Abdalkareem, Z., Amir, A., Al-Betar, M., Ekhan, P., Hammouri, A., Healthcare scheduling in optimization context: a review, *Health and Technology* (2021) 11:445-469.
- [3] Zolbanin, H.M., Davazdahemami, B., Delen, D., Zadeh, A., Data analytics for the sustainable use of resources in hospitals: Predicting the length of stay for patients with chronic diseases, *Information & management*, 103282, 2020.