

入院患者の病床スケジューリング—入院数と在院日数予測—

05001602 東京理科大学

05000319 東京理科大学

01308970 東京理科大学

01015653 防衛大学校/海老名総合病院

海老名総合病院

海老名総合病院

海老名総合病院

海老名総合病院

*松林祐加 MATSUBAYASHI Yuka

伊藤真理 ITO Mari

高嶋隆太 TAKASHIMA Ryuta

鵜飼孝盛 UKAI Takamori

小泉正樹 KOIZUMI Masaki

矢野明美 YANO Akemi

松島俊輔 MATSUSHIMA Shunsuke

猪口貞樹 INOKUCHI Sadaaki

1. はじめに

平均寿命の上昇により、病院治療の需要が増している。中でも病床は、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。入院数や在院日数は患者の回復と病院のオペレーションの影響を受け不確実性があり、病床管理者の長年の経験を活かしても予測は難しい。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[1]。

病床スケジューリング問題はこれまで多くの研究が行われてきた。入院数や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 Schäfer et al. [2] は、患者・医師・看護師全ての効用を考慮し、外傷外科及び消化器内科の救急患者の到着予測を行った。

2. モデル

2.1. 入院数予測

本研究では入院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。説明変数は先行研究や病院との打ち合わせを参考に気象データや日時データを用いた。データは海老名総合病院における 2018 年 4 月から 2019 年 3 月までの 365 日分の患者データ 12,840 件を対象とする。全入院患者

(12,840 件)、予定入院患者 (5,603 件)、救急医療入院患者 (4,443 件)、救急医療入院以外の予定外入院患者 (2,794 件) の 4 つについてそれぞれ入院数予測を行う。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。

2.2. 在院日数予測

在院日数も入院数同様ランダムフォレストで予測する。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主要診断群 (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。

2.3. 入院患者の病床スケジューリング

患者を病床に割り当てる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

$$\sum_{b \in B} \sum_{p \in P} \sum_{t \in T} R_p^m s_{bpt} Q_t x_{bpt} + \sum_{r \in R} \sum_{p \in P} \sum_{t \in T} R_p^r Q_t y_{rpt} - \sum_{b \in B} \sum_{p \in P} \sum_{t \in T} C^f Q_t z_{bpt} - \sum_{p \in P} \sum_{t \in T} C^l R_p^r Q_t w_{pt} \quad (1)$$

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} は日 t に病室 r で患者 p が入院中のとき 1 となるバイナリ変数, z_{bpt} は日 t に患者 p が病床 b に転床するとき 1 となるバイナリ変数, w_{pt} は日 t に患者 p が希望室に割り当てられなかったとき 1 となるバイナリ変数である. 定数として 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. 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. 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^f の合計, 第 4 項目は室料差額の機会損失 C^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. 制約式としては, 男女制約や隔離制約など計 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病床スケジューリングモデルを用いて決定し, 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, 入院数と在院日数の予測を Visual Mining Studio ver.8.7 (NTT データ数理システム) を用いて行った. 解析時間は 2 分ほどである. 入院数予測は 4 つの全てにおいて, 精度の高い予測結果を出すことはできなかった. 原因は適切な説明変数が不足していたと考える. Schäfer et al. [2]は救急患者の入院数予測に用いる説明変数の重要度は診療科ごとに異なると結論づけていることから, 診療科ごとに説明変数を決定する必要がある.

機械学習による在院日数予測は, 検証データの的中率が約 60%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の推定を行ううえで参考になっている説明変数となった.

数理最適化ソフト IBM ILOG CPLEX Optimization Studio 20.1 を用いて, 海老名総合病院の循環器内科の病床スケジュールを作成した. 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, 在院日数の予測と病床スケジューリングの両手法の有効性が, 病院の利益の観点から示された.

4. おわりに

本研究では入院数と在院日数の予測と病床スケジューリングモデルの提案を行った. 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, 機械学習を用いた入院数の予測精度の向上とスケジューリング問題への組み込みが挙げられる. 具体的には, 時系列解析や説明変数の見直しを行う.

謝辞

本研究の一部は, 日本科学協会の笹川科学研究助成を受けて実施したものである.

参考文献

- [1] J. Ohara, M. Ito, R. Takashima, T. Ukai, M. Koizumi, A. Yano, S. Matsushima, S. Inokuchi, Scheduling of Inpatient Hospital Beds: A Case Study of Ebina General Hospital, INFORMS Healthcare, 2021.
- [2] F. Schäfer, M. Walther, D.G. Grimm, A. Hübner, Combining Machine Learning and Optimization for the Operational Patient Bed Assignment Problem, Available at SSRN: <https://ssrn.com/abstract=3919282>, 2021.