

## 事例研究 [レター]

# 構造的正則化処方分析による 旅行パックの価格最適化

池田 春之介, 朝倉 希美, 西村 直樹, 高野 祐一

## 1. はじめに

商品やサービスの価格の決定は、企業の売上や利益に大きな影響を与え、経営において極めて重要である。近年では情報通信技術の発展により、需要の情報を価格に適時反映することが可能になり、ますます価格決定の重要性が増している。一方で多くの日本企業では、商品原価や販売個数に依存した価格決定によって、試行錯誤を繰り返している現状がある。このような人間の勘や経験に頼った価格戦略では、売上や利益を最大化することは困難であり、消費者の価格への反応や競合商品の価格の影響などを考慮したうえで、売上や利益の最大化を実現できる価格決定手法の開発が求められている。

近年、そのような価格決定の手法として、処方分析 [1, 2] が注目を集めている。処方分析とは、効果的な意思決定に着目したデータ分析技術であり、最適価格決定のための処方分析は需要予測と価格最適化の二段階で構成される。需要予測では、過去の膨大なデータから、価格弾力性や交差弾力性などの価格と需要の複雑な関係を考慮して、商品ごとに需要予測モデルを構築する。そして価格最適化では、構築した需要予測モデルに基づいて、将来の売上や利益を最大化する最適化問題を解くことで複数商品の最適価格を決定する。複数商品を対象とする各種の価格最適化モデルに関しては、総説論文 [3] を参照されたい。

処方分析による価格決定の課題として、最適化の計算時間が膨大となる可能性、予測モデルの誤差の影響、利益の過剰推定の問題などが指摘されている [2]。計算

時間に関しては、価格最適化問題を 0-1 整数二次最適化問題として定式化し、ネットワーク流最適化 [4] や半正定値緩和 [5] による高速化が実現されている。また、予測モデルの誤差の影響を軽減するためのロバスト最適化モデル [6, 7] や、利益の過剰推定を回避するためのパラメータ摂動法 [8] が提案されている。

これらの先行研究における需要予測では、L1 正則化やエラスティックネットなどの正則化法 [9] を用いて線形回帰モデルを構築することが多いが、正則化法は回帰係数の縮小推定を伴う。これにより、価格の影響が過小評価され、最適化結果に問題が生じる可能性がある。価格が需要に与える影響が非常に小さければ、常に価格の上限値が最適解となり、非現実的な価格設定となってしまう。

この問題に対処するため、処方分析の需要予測に構造的正則化 [9, 10] を適用し、回帰係数の縮小を回避しながら予測モデルの精度向上を目指す。構造的正則化では、説明変数に関する事前知識を制約や罰則項として組み込んで、予測モデルの解釈性や汎化性能を向上させることができる。

本研究では、旅行パック予約サイトの実データを対象として、構造的正則化処方分析による価格最適化の手法を提案する。具体的には、旅行パックの販売元および到着地ごとの需要予測に対して、予測モデル間の回帰係数の類似性に基づく罰則項や回帰係数の符号制約を加える。この予測モデルの構築は、凸二次最適化問題として定式化できるため、最適化ソルバーによって求解が可能である。そして、このように構築した需要予測モデルを利用し、現実的な運用に即した制約を課した価格最適化問題を解くことで、売上や利益を最大化する最適価格を算出する。

数値実験では、エラスティックネットと提案手法の需要予測の精度を比較し、構造的正則化の有効性を示す。さらに、価格最適化問題を解いて最適価格を計算し、その売上を実績値と比較することで価格最適化の有用性を検証する。

いけだ しゅんのすけ, にしむら なおき

株式会社リクルート

〒100-6640 東京都千代田区丸の内 1-9-2

あさくら のぞみ

筑波大学大学院システム情報工学研究群

たかの ゆういち

筑波大学システム情報系

〒305-8573 茨城県つくば市天王台 1-1-1

受付 23.3.23 採択 23.6.19

表 1 使用データと抽出条件

使用データ	抽出条件
価格	特定宿を選択時の 1 名あたりの 2 泊分の価格 (割引は含まない)
予約件数	キャンセルを除く
旅行パック	2 種類: A パック, B パック (2 種類の販売元と対応)
予約日	2019 年 4~12 月の毎週水・金曜日
出発日	予約日の 10 日後 (予約日が水曜日) と 12 日後 (予約日が金曜日) に出発
到着地	4 路線: 福岡, 大阪, 那覇, 札幌 (出発地は羽田空港)
人数	1 名のみを対象

表 2 到着地ごとの旅行パックのデータ件数

旅行パック	到着地				総計
	福岡	大阪	那覇	札幌	
A パック	67	68	62	64	261
B パック	67	68	62	64	261

## 2. 使用データ

本研究では、株式会社リクルートの旅行パック予約サイトのデータを分析対象とする。本サイトでは、航空券と宿泊プランを組み合わせて一つの旅行パックとして予約することができ、販売元の異なる 2 種類の旅行パック (A パックと B パック) が存在する。

表 1 に、本研究で使用するデータとその抽出条件を記載する。表 1 に示すように、データは価格や予約件数のほかに、旅行パックの種類、予約日、出発日、到着地、人数から構成される。到着地は予約件数の多い 4 路線とし、それぞれ福岡空港、関西国際空港、那覇空港、新千歳空港と対応している。2 名以上の予約件数は少ないため、本研究では予約人数 1 名のデータのみを対象とした。

表 2 では、2 種類の旅行パックの到着地ごとのデータ件数を示しており、これらは欠損値を補完した後の件数となっている。欠損の理由としては、天候不良による航空機便の欠航などが多く、実際に予約件数が 0 件である場合はほとんど存在しない。そのため、どちらか一方のみ旅行パックのデータが欠損している場合には、欠損データの価格や予約件数は、旅行パックの種類・到着地・人数が同じで同曜日の出発日が最も近いデータの移動平均を計算して補完した。

本研究では、旅行パックの種類・出発日・到着地の組合せを一つの商品として定義する。したがって、「A パック・8 月 1 日・大阪行き」のような商品ごとに、最

適価格を算出することが本研究の目標となる。

## 3. 構造的正則化処方分析

本節では、構造的正則化を用いて各商品の予約件数を予測する需要予測モデルを提案する。次に、その予測モデルに基づいて運用上の制約を考慮して最適価格を決定する最適化モデルを提示する。

### 3.1 需要予測

旅行パックの出発日を  $i \in \mathcal{I}$ 、到着地を  $d \in \mathcal{D}$ 、種類を  $s \in \mathcal{S}$  とし、商品  $(i, d, s)$  の価格を  $p_i^{(d,s)}$ 、予約件数を  $y_i^{(d,s)}$  とする。本研究では出発日は説明変数として利用し、旅行パック (2 種類) と到着地 (4 路線) の組合せごとに 8 種類の予測モデルを構築する。需要予測に用いる説明変数は、価格に関する説明変数 (価格変数) と価格以外の出発日などの説明変数 (外生変数) の 2 種類がある。価格変数の添字集合を  $\mathcal{J}_p$ 、外生変数の添字集合を  $\mathcal{J}_g$  とし、説明変数の添字集合を  $\mathcal{J} = \mathcal{J}_p \cup \mathcal{J}_g$  とする。価格変数  $j \in \mathcal{J}_p$  は、商品価格を任意の関数  $\phi_j^{(s)}(\cdot)$  で変換した値とする。また、商品  $(i, d, s)$  の外生変数  $j \in \mathcal{J}_g$  の値を  $g_{ij}^{(d,s)}$  とする。

このとき、商品  $(i, d, s)$  の予約件数の予測値  $\hat{y}_i^{(d,s)}$  を以下の回帰モデルによって記述する。

$$\hat{y}_i^{(d,s)} = \beta_0^{(d,s)} + \sum_{j \in \mathcal{J}_g} \beta_j^{(d,s)} g_{ij}^{(d,s)} + \sum_{j \in \mathcal{J}_p} \beta_j^{(d,s)} \phi_j^{(s)} \left( (p_i^{(d,s')})_{s' \in \mathcal{S}} \right) \quad (1)$$

ここで、 $\beta_0^{(d,s)}$  は切片、 $\beta_j^{(d,s)}$  は回帰係数を表す。

本研究では、構造的正則化を用いて需要予測モデルを構築する。具体的には、複数の予測モデル間で回帰係数を類似させる罰則項を導入し、さらに価格変数の回帰係数に対して符号制約を加える。これらの方法により、回帰係数の縮小推定を伴うことなく、過剰適合を抑えて予測精度の向上が期待できる。

構造的正則化を課す回帰係数の組合せを定義する到着地と旅行パックと説明変数の添字集合を  $\mathcal{M} \subset \mathcal{D}^2 \times \mathcal{S}^2 \times \mathcal{J}^2$  とし、罰則項の重みパラメータを  $\lambda$  とする。さらに、 $\mathcal{J}_-^s$  は旅行パック  $s$  の (需要に対して負の影響が想定される) 価格変数の添字集合とし、 $\mathcal{J}_+^s$  は競合商品の (需要に対して正の影響が想定される) 価格変数の添字集合とする。

このとき、提案手法は以下のような凸二次最適化問題として定式化できる。

$$\min. \sum_{s \in \mathcal{S}} \sum_{d \in \mathcal{D}} \sum_{i \in \mathcal{I}} \left( y_i^{(d,s)} - \hat{y}_i^{(d,s)} \right)^2$$

$$+ \lambda \sum_{(d,d',s,s',j,j') \in \mathcal{M}} \left( \beta_j^{(d,s)} - \beta_{j'}^{(d',s')} \right)^2 \quad (2)$$

$$\text{s. t. } \hat{y}_i^{(d,s)} = \beta_0^{(d,s)} + \sum_{j \in \mathcal{J}_g} \beta_j^{(d,s)} g_{ij}^{(d,s)} + \sum_{j \in \mathcal{J}_p} \beta_j^{(d,s)} \phi_j^{(s)} \left( (p_i^{(d,s')})_{s' \in \mathcal{S}} \right) \quad (3)$$

$$\beta_j^{(d,s)} \leq 0 \quad (j \in \mathcal{J}_s^-, d \in \mathcal{D}, s \in \mathcal{S}) \quad (4)$$

$$\beta_j^{(d,s)} \geq 0 \quad (j \in \mathcal{J}_s^+, d \in \mathcal{D}, s \in \mathcal{S}) \quad (5)$$

ここで、決定変数は  $\hat{y}_i^{(d,s)}$ ,  $\beta_0^{(d,s)}$ ,  $\beta_j^{(d,s)}$  である。

式 (2) の目的関数では、第 1 項の予測誤差の二乗和に加えて、第 2 項では予測モデル間に対応する回帰係数を類似させる罰則項を導入している。式 (3) は需要予測の回帰モデル (式 (1)) である。式 (4), (5) は回帰係数に対する符号制約であり、予測対象商品の価格が上がると予約件数は減少し、競合商品の価格が上がると予約件数は増加することを表現している。

### 3.2 価格最適化

商品  $(i, d, s)$  の価格  $p_i^{(d,s)}$  は候補集合  $\{P_{ik}^{(d,s)} \mid k \in \mathcal{K}\}$  から選択することとし、価格の選択を表す 0-1 決定変数  $z_{ik}^{(d,s)}$  を以下のように定義する。

$$z_{ik}^{(d,s)} = 1 \iff p_i^{(d,s)} = P_{ik}^{(d,s)}$$

ただし、商品価格を高く設定すると、一時的な売上増加は見込めても将来的に顧客が離反してしまう可能性がある。そこで、旅行パックの到着地  $d \in \mathcal{D}$  と種類  $s \in \mathcal{S}$  の組合せに対して、予約件数の合計に下限値  $A^{(d,s)}$  を課し、顧客の離反 (予約件数の減少) を防ぐ。また、商品  $(i, d, s)$  の実際価格を  $P_{i0}^{(d,s)}$  とし、価格の変化率 (絶対値) を表す定数を  $R_{ik}^{(d,s)} = |P_{ik}^{(d,s)} - P_{i0}^{(d,s)}| / P_{i0}^{(d,s)}$  とする。優先的に価格を変更すべき商品を見つけるため、価格の変化率の合計にも上限値  $B$  を設ける。

これらの運用上の制約を考慮し、商品原価  $C_i^{(d,s)}$  に対する総利益を最大化する価格最適化問題は以下のように定式化できる。

$$\text{min. } \sum_{s \in \mathcal{S}} \sum_{d \in \mathcal{D}} \sum_{i \in \mathcal{I}} (p_i^{(d,s)} - C_i^{(d,s)}) \hat{y}_i^{(d,s)} \quad (6)$$

$$\text{s. t. } \hat{y}_i^{(d,s)} = \beta_0^{(d,s)} + \sum_{j \in \mathcal{J}_g} \beta_j^{(d,s)} g_{ij}^{(d,s)} + \sum_{j \in \mathcal{J}_p} \beta_j^{(d,s)} \phi_j^{(s)} \left( (p_i^{(d,s')})_{s' \in \mathcal{S}} \right) \quad (i \in \mathcal{I}, d \in \mathcal{D}, s \in \mathcal{S}) \quad (7)$$

$$\sum_{i \in \mathcal{I}} \hat{y}_i^{(d,s)} \geq A^{(d,s)} \quad (d \in \mathcal{D}, s \in \mathcal{S}) \quad (8)$$

$$\sum_{s \in \mathcal{S}} \sum_{d \in \mathcal{D}} \sum_{i \in \mathcal{I}} \sum_{k \in \mathcal{K}} R_{ik}^{(d,s)} z_{ik}^{(d,s)} \leq B \quad (9)$$

$$p_i^{(d,s)} = \sum_{k \in \mathcal{K}} P_{ik}^{(d,s)} z_{ik}^{(d,s)} \quad (i \in \mathcal{I}, d \in \mathcal{D}, s \in \mathcal{S}) \quad (10)$$

$$\sum_{k \in \mathcal{K}} z_{ik}^{(d,s)} = 1 \quad (i \in \mathcal{I}, d \in \mathcal{D}, s \in \mathcal{S}) \quad (11)$$

$$z_{ik}^{(d,s)} \in \{0, 1\} \quad (k \in \mathcal{K}, i \in \mathcal{I}, d \in \mathcal{D}, s \in \mathcal{S}) \quad (12)$$

ここで、決定変数は  $p_i^{(d,s)}$ ,  $\hat{y}_i^{(d,s)}$ ,  $z_{ik}^{(d,s)}$  である。

式 (6) の目的関数は総利益を表し、本研究では商品原価を  $C_i^{(d,s)} = 0$  と設定して総売上を最大化する。式 (7) は需要予測で構築した予測モデル (式 (1))、式 (8) は旅行パックの予約件数に対する下限制約、式 (9) は価格の変化率の合計に対する上限制約を表す。式 (10)–(12) は商品価格が候補集合から選択されることを表す。

上記の最適化問題は、目的関数に双線形項 (決定変数の積) が含まれる混合整数非線形最適化問題であり、効率的な求解は困難である。そこで、式 (7), (10) を用いて  $\hat{y}_i^{(d,s)}$  と  $p_i^{(d,s)}$  を代入消去することで、 $z_{ik}^{(d,s)}$  の 0-1 整数二次最適化問題に変換できる。さらに、双線形項を表す連続変数と線形制約を追加して双線形項を線形化することで、混合整数線形最適化問題に帰着でき、最適化ソルバーによる求解が可能となる。この変形の詳細は文献 [5] を参照されたい。

## 4. 数値実験

本節では、需要予測と価格最適化の実験結果を報告し、提案手法の有効性を検証する。最適化問題の求解には最適化ソルバー Gurobi Optimizer<sup>1</sup> 9.50 を用いた。

### 4.1 需要予測の説明変数

価格に関する説明変数として、予測対象商品の価格に加えて、予測対象商品に対する競合商品 (出発日と到着地が同一の他方の旅行パック) との価格差と価格比を用いる。本研究ではこれらの数値を 3 種類の関数  $\{x, \sqrt{x}, x^2\}$  で変換して説明変数とする。ただし、値が大きくなり過ぎないように価格は 10,000 で割った値を使用し、価格差が負の値となる場合は  $\{x, -\sqrt{-x}, -x^2\}$  で変換する。

価格以外の外生変数として、出発日の月 (12 月を除く 4~11 月) を 8 種類のダミー変数として用いる。さらに、「出発日が休日であれば 1」となるダミー変数も加える。

したがって、説明変数は価格変数 9 種類、外生変数 9 種類の計 18 種類となり、すべて標準化して使用する。

<sup>1</sup> <https://www.gurobi.com/>

表4 提案手法（構造的正則化， $\lambda = 10$ ）の切片と回帰係数の推定値

	$\beta_0$ 切片	$\beta_1$	$\beta_2$ 価格	$\beta_3$	$\beta_4$	$\beta_5$ 価格比	$\beta_6$	$\beta_7$	$\beta_8$ 価格差	$\beta_9$
		$x$	$\sqrt{x}$	$x^2$	$x$	$\sqrt{x}$	$x^2$	$x$	$\sqrt{x}$	$x^2$
福岡・A バック	69.57	0.00	-0.22	0.00	0.16	0.11	0.27	0.13	0.42	0.17
福岡・B バック	65.78	-0.25	-0.52	-0.23	0.40	0.30	0.61	0.00	0.00	0.00
大阪・A バック	17.55	0.00	-0.23	0.00	0.00	0.00	0.07	0.02	0.00	0.19
大阪・B バック	28.54	-0.09	-0.35	-0.04	0.00	0.00	0.00	0.00	0.00	0.03
那覇・A バック	14.24	-0.29	-0.62	-0.13	0.00	0.00	0.08	0.12	0.01	0.39
那覇・B バック	19.94	-0.36	-0.59	-0.38	0.00	0.00	0.00	0.00	0.00	0.12
札幌・A バック	55.76	-0.17	-0.42	-0.18	0.00	0.00	0.00	0.00	0.00	0.00
札幌・B バック	51.35	-0.33	-0.56	-0.34	0.06	0.11	0.00	0.16	0.13	0.26
	$\beta_{10}$ 休日	$\beta_{11}$ 4月	$\beta_{12}$ 5月	$\beta_{13}$ 6月	$\beta_{14}$ 7月	$\beta_{15}$ 8月	$\beta_{16}$ 9月	$\beta_{17}$ 10月	$\beta_{18}$ 11月	
福岡・A バック	-32.42	-0.49	-4.09	2.98	4.04	-8.04	3.59	-2.22	2.26	
福岡・B バック	-29.86	2.16	-4.18	1.29	6.46	-7.75	3.04	-1.11	0.64	
大阪・A バック	-6.54	0.42	0.18	3.38	3.43	-0.06	2.79	-1.35	-0.44	
大阪・B バック	-14.89	0.52	-0.72	2.59	3.73	-2.25	-0.12	-1.31	1.53	
那覇・A バック	-9.93	1.07	-3.03	0.15	-0.04	-3.55	-0.78	-0.63	0.27	
那覇・B バック	-10.85	0.64	-2.54	-0.85	-0.39	-3.70	0.80	-1.28	-0.79	
札幌・A バック	-28.19	0.63	-9.84	-5.58	-4.84	-14.41	-3.00	-3.51	-2.20	
札幌・B バック	-24.35	0.95	-10.03	-2.87	-4.11	-10.86	-5.97	-4.27	-4.43	

表3 検証データに対する決定係数（平均値）

手法	決定係数
エラスティックネット	0.526
構造的正則化， $\lambda = 1$	0.572
構造的正則化， $\lambda = 10$	<b>0.578</b>
構造的正則化， $\lambda = 100$	0.577

#### 4.2 需要予測の評価方法

出発月が予約件数に与える影響の大きさを考慮して、各月のデータが均等に含まれるよう、各月の前半と後半にデータを分割する。これらを訓練データと検証データとして二分割交差確認を実施することで、構築した予測モデルの予測精度を評価する。

需要予測の実験では、エラスティックネット [9] と提案手法（式 (2)–(5)）の予測精度を比較する。3.1 節で述べたように、旅行バック（2 種類）と到着地（4 路線）の組合せごとに 8 種類の予測モデルを作成する。構造的な正則化では、価格変数は 8 種類のモデル間で、外生変数は到着地が同一の 2 種類のモデル間で回帰係数が類似するように罰則項を設定し、重みパラメータの値は  $\lambda \in \{1, 10, 100\}$  とする。エラスティックネットの正則化項の重みパラメータは、訓練データ内の交差確認誤差が最小となる値をグリッド探索で選択する。予測精度の評価指標は検証データに対する決定係数とする。

#### 4.3 需要予測の結果

エラスティックネットと提案手法（構造的な正則化）の予測精度を表 3 に示す。構造的な正則化は  $\lambda \in \{1, 10, 100\}$  のすべての値でエラスティックネットよりも予測精度が優れている。これは、構造的な正則化によって他の旅行バックや到着地のデータも考慮して回帰係数を推定できるために、精度が向上したと考えられる。特に  $\lambda = 10$  の場合に最も予測精度が良く、これは  $\lambda$  の値を大きくしすぎると予測モデル間で回帰係数が同じ値となってしまう、予測精度が却って悪化するためと考えられる。

提案手法（構造的な正則化， $\lambda = 10$ ）の切片と回帰係数の推定値を表 4 に示す。切片  $\beta_0$  の値は到着地ごとに大きな差があり、特に福岡と札幌の予約件数が多いことがわかる。価格の回帰係数 ( $\beta_1 \sim \beta_3$ ) はほぼ一様に負の値となっており、価格を上げるとその商品の予約件数は減少する傾向が見られる。競合商品との価格比や価格差の回帰係数は価格の回帰係数と比べると絶対値は小さいが、一部の商品の間で競合関係が見られる。

外生変数については、 $\beta_{10}$ （休日）が負の大きな値となった。本研究では利用者 1 名のデータを使用したためビジネス目的の利用が多く、休日の予約件数は減少する傾向がある。また、出発月の回帰係数  $\beta_{12}$ （5 月）、 $\beta_{15}$ （8 月）、 $\beta_{17}$ （10 月）の多くが負の値となっている。これは、5 月にはゴールデンウィーク、8 月にはお盆があるなど、出張の機会が少ないためと考えられる。

表 6 最適価格（平均価格に対する変化率）の結果

	平日									
	4月	5月	6月	7月	8月	9月	10月	11月	12月	
福岡・A バック	+20%	+20%	+20%	+20%	+20%	+20%	+20%	+20%	+20%	+20%
福岡・B バック	+20%	+20%	+20%	+20%	0%	+20%	+20%	+20%	+20%	+20%
大阪・A バック	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
大阪・B バック	0%	0%	0%	+5%	0%	0%	0%	0%	0%	0%
那覇・A バック	0%	0%	0%	+20%	0%	0%	0%	+5%	0%	0%
那覇・B バック	0%	0%	0%	+20%	0%	+10%	0%	+5%	0%	0%
札幌・A バック	0%	+15%	+20%	+20%	0%	+20%	+20%	+20%	+5%	0%
札幌・B バック	0%	0%	+20%	+20%	0%	+10%	+20%	+20%	0%	0%

  

	休日									
	4月	5月	6月	7月	8月	9月	10月	11月	12月	
福岡・A バック	+5%	-20%	+20%	+20%	+20%	-20%	+5%	+20%	0%	0%
福岡・B バック	0%	+20%	+5%	+20%	-20%	+20%	0%	+15%	0%	0%
大阪・A バック	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
大阪・B バック	0%	0%	0%	0%	-5%	0%	0%	0%	0%	0%
那覇・A バック	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
那覇・B バック	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
札幌・A バック	0%	0%	0%	0%	+5%	0%	0%	0%	0%	0%
札幌・B バック	0%	0%	0%	0%	-20%	-20%	-5%	0%	0%	0%

表 5 検証データに対する売上の結果

	実績値に対する 売上の相対値
売上の実績値	100.0%
実際価格の売上	99.7%
平均価格の売上	103.8%
最適価格の売上	<b>113.7%</b>

#### 4.4 価格最適化の評価方法

既存研究 [4, 5] と同様の方法で価格最適化の有効性を評価する。ここでは各月の前半を訓練データ、後半を検証データとし、需要予測には提案手法（構造的正則化,  $\lambda = 10$ ）を用いる。訓練データから構築した予測モデルを用いて式 (6)–(12) の最適化問題を解き、訓練データに対する最適価格を算出する。次に検証データから構築した予測モデルを用いて、最適価格の検証データに対する売上を計算する。

各商品の出発月と平日／休日の組合せに対して平均価格を算出し、平均価格に対する変化率 0%,  $\pm 5%$ ,  $\pm 10%$ ,  $\pm 15%$ ,  $\pm 20%$  の計 9 個を候補価格とする。予約件数の下限  $A^{(d,s)}$  は検証データにおける到着地  $d$  の旅行バック  $s$  の予約件数とし、価格の変化率の合計の上限  $B$  は 900%（制約 (9) を除いて最適化した場合の変化率の合計の約 1/3）とする。

本実験では以下の 4 種類の売上を比較する。

**売上の実績値** 検証データにおける実際の価格と実際  
の予約件数から計算。

**実際価格の売上** 検証データにおける実際の価格と、  
予測モデルで求めた予約件数から計算。

**平均価格の売上** 上述の平均価格（変化率 0% に相  
当する候補価格）と、予測モデルで求めた予約件  
数から計算。

**最適価格の売上** 提案手法で計算した最適価格と、予  
測モデルで求めた予約件数から計算。

#### 4.5 価格最適化の結果

検証データに対する売上の結果を表 5 に示す。実際  
価格の売上は実績値と非常に近く、予測モデルによっ  
て実際の売上が再現されていることがわかる。また、  
平均価格を用いることで実績値と比べて売上が 3.8%  
向上し、さらに最適価格を用いることで実績値と比べ  
て売上を 13.7% 改善できることがわかる。

最適価格（平均価格に対する変化率）の結果を表 6 に  
示す。到着地が福岡の商品は変化率が +20% となる場  
合が多く、価格を高く設定することが有効だと考えら  
れる。また、7 月や 11 月の平日は多くの商品で変化率  
が正の値になり、また休日よりも平日に変化率が正の  
値になる場合が多い。

### 5. おわりに

本研究では、処方分析による価格最適化の既存研究  
[4, 5] に対して、構造的正則化を需要予測に用いる処方  
分析手法を提案した。また、現実的な運用に即した制  
約を考慮して価格最適化問題を定式化し、旅行バック予

約サイトの実データを対象として分析を実施した。数値実験において、構造的正則化によって需要予測の精度向上を実現し、その予測に基づく価格最適化によって売上を約 14%改善する結果が得られた。

先行研究では、処方分析に合わせた需要予測の罰則項 [11] や、バギングを用いた回帰木による需要予測 [12]、最適回帰木を用いた需要予測 [13] などが提案されている。今後の研究の方向性として、これらの方法と提案手法を組み合わせることで処方分析の性能を改善することが考えられる。また異なる方向性として、価格を候補集合から選択するのではなく、連続値として扱う場合の解法の検討も考えられる。

主な理由としてコロナ禍の影響で需要の傾向が大きく変化してしまったために、提案手法は実運用には至っていない。このように提案手法は需要の傾向が大きく変化するような局面では対応が難しい。また、異なる旅行パックの間で回帰係数が類似していることを前提としているため、この性質が成り立たない状況では提案手法は有効に機能しない可能性がある。そのため、実際の予約サイトにおける運用による検証も今後の課題である。

#### 参考文献

- [1] K. Lepenioti, A. Bousdekis, D. Apostolou and G. Mentzas, “Prescriptive analytics: Literature review and research challenges,” *International Journal of Information Management*, **50**, pp. 57–70, 2020.
- [2] 矢部顕大, 伊藤伸志, 藤巻遼平, “処方分析に基づく AI の意思決定自動化における技術課題,” 電子情報通信学会通信ソサイエティマガジン, **12**, pp. 46–49, 2018.
- [3] W. Soon, “A review of multi-product pricing models,” *Applied Mathematics and Computation*, **217**, pp. 8149–8165, 2011.
- [4] S. Ito and R. Fujimaki, “Large-scale price optimization via network flow,” *Advances in Neural Information Processing Systems*, **29**, 2016.
- [5] S. Ito and R. Fujimaki, “Optimization beyond prediction: Prescriptive price optimization,” In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1833–1841, 2017.
- [6] A. Yabe, S. Ito and R. Fujimaki, “Robust quadratic programming for price optimization,” In *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, pp. 4648–4654, 2017.
- [7] M. Hamzeei, A. Lim and J. Xu, “Robust price optimization of multiple products under interval uncertainties,” *Journal of Revenue and Pricing Management*, **21**, pp. 442–454, 2022.
- [8] S. Ito, A. Yabe and R. Fujimaki, “Unbiased objective estimation in predictive optimization,” In *Proceedings of the 35th International Conference on Machine Learning*, pp. 2176–2185, 2018.
- [9] 川野秀一, 『スパース推定法による統計モデリング』, 共立出版, 2018.
- [10] 河原吉伸, “構造的な事前情報を用いた機械学習：構造正則化と劣モジュラ性,” 情報処理, **54**, pp. 734–740, 2013.
- [11] A. N. Elmachtoub and P. Grigas, “Smart “predict, then optimize”,” *Management Science*, **68**, pp. 9–26, 2022.
- [12] K. J. Ferreira, B. H. A. Lee and D. Simchi-Levi, “Analytics for an online retailer: Demand forecasting and price optimization,” *Manufacturing & Service Operations Management*, **18**, pp. 69–88, 2016.
- [13] S. Ikeda, N. Nishimura, N. Sukegawa and Y. Takano, “Prescriptive price optimization using optimal regression trees,” *Optimization Online*, <https://optimization-online.org/?p=21778>, 2023.