

販売履歴データに基づく中古ファッションアイテムの 出品価格推定モデルの提案

An Estimation Model of Exhibits Price for Second-hand Fashion Items Based on Sales History Data

桑田 和^{*1} 杉崎 智哉^{*1} 三川 健太^{*2} 後藤 正幸^{*1}
Izumi Kuwata Tomoya Sugisaki Kenta Mikawa Masayuki Goto

^{*1}早稲田大学 Waseda University ^{*2}湘南工科大学 Shonan Institute of Technology

In this study, we focus on the second-hand fashion EC site. In this site, the trade-in price is determined according to the exhibition price so that the decision of the appropriate exhibition price is strongly important. However, it is difficult to determine the best exhibition price because there are two types of items such as the items purchased with no discount and that purchased with discount. Therefore, we proposed a method to estimate the maximum exhibition price without discount for each item. In our proposed method, at first, we construct a binary classifier which classifies the item which is purchased with a discount price or not. In addition, we estimate the best price with changing the exhibition price of each item little by little. The effectiveness of our proposed method is clarified using real purchasing history data of this site.

1. 研究背景・目的

本研究では、ユーザからアイテムを買い取り、中古品として再販売する事業を展開する某ファッション EC サイト (以下、サイト A) における出品価格の決定問題を対象とする。出品価格とはアイテムを EC サイト上で出品する際の価格であり、これと連動して買取価格も決まるため、その最適化はビジネス上大変重要な課題の 1 つとなっている。

サイト A では、アイテムの売れ残りを防ぐため、出品から一定期間経過したアイテムの価格を自動的に値下げする仕組みを採用している。収益性の観点からは、可能な限り値下げをせずに販売することが望ましいが、購入の意思決定はユーザ側にあるため、ブランドや季節性といった多様性の高いファッションアイテムは実際に出品するまで購入結果が予想できない場合も多い。一方、サイト A では過去に出品したアイテムの出品価格や購入価格といった販売履歴データが膨大に蓄積されており、それらのデータの分析が各アイテムに対する最適な出品価格の決定につながると考えられる。

しかし、サイト A に蓄積されている販売履歴データには、出品後間もなく出品価格のまま購入されたアイテムと、出品から購入されるまでの期間 (以下、販売期間) が長くなったために、出品価格から値下げされて購入されたアイテムの 2 通りの販売結果が混在している。前者は出品価格を高く設定しても出品価格のまま購入された可能性が、後者は出品価格を低く設定することで出品価格のまま購入された可能性がある。そのため、購入された時点での販売価格がアイテムに対する最適な価格とは限らない。

そこで本研究では、アイテムの出品価格のみを変化させた場合の販売結果を予測し、その結果からアイテムの値下がり不起こらない出品価格の最大値を推定する手法を提案する。提案手法ではまず、過去の販売履歴データによる機械学習モデルを用いて、アイテムの出品価格をもとに、出品価格で購入されるか、値下げされて購入されるかの 2 通りの販売結果を判別する分類器を構築する。次に、推定された分類器を用い、アイテムの出品価格のみを変化させて結果の差異を分析する。そして、

元の販売結果とは異なる結果が得られる変化点の価格を求める。この方法により、値下がり不起こらない範囲での出品価格の最大値を推定することができ、実際の価格決定の基準値となると期待できる。本研究では、サイト A の販売履歴データに提案手法を適用し、分析結果に対する考察を行う。

2. 問題設定

サイト A では、アイテムの出品価格を高価格にすると、それに比例して購入時の価格も高価格になり、売上は増加する [1]。しかし、ユーザに購入されにくくなるため、販売期間が長くなり、在庫費の増加や売れ残り、サイト上に同一アイテムを長期間掲載することによるサイトの魅力低下といった問題が発生する。一方、アイテムを低価格で出品した場合、多くのアイテムはすぐにユーザに購入される反面、より高価格で購入される機会を失う。そのため、販売期間と売上の双方を考慮した出品価格の推定が望まれる。

過去に出品され、購入されたアイテムには、前述のように 2 通りの販売結果が存在する。出品価格のまま購入されたアイテムは、より高い出品価格であってもユーザの購買意欲やアイテムの価値により、その価格で購入され、販売期間に大きな変化が生じなかった可能性がある。一方、値下げされたアイテムは、より低い出品価格であればアイテムに対してユーザが感じる価値より価格が下回り、より早く購入され、販売期間が短縮された可能性がある。このように、サイト A で扱われるアイテムは出品価格によって販売結果が異なるため、販売結果を予測するモデルを構築するだけでは適切な出品価格を推定することはできない。したがって、アイテムの販売結果の差異を考慮に入れて、適切な出品価格を推定する方法を考える必要がある。

そこで本研究では、まず、出品価格からの値下がり率 (以下、オフ率) と販売期間を用い、出品価格を設定したアイテムが出品価格で購入されるか、値下げされるかを判別する分類モデルを構築する。次に予測される販売結果を基に、値下がりしない出品価格の最大値を推定する方法を示す。これにより、個々のアイテムに対する値下げを可能な限り回避しつつ、収益性の高い出品価格を見積もることが可能となる。

連絡先: 桑田 和, 早稲田大学, 東京都新宿区 169-8555,
ikdsk14243150@toki.waseda.jp

3. 事前分析

本章では、前述の2通りの販売結果の境界を考えるため、出品価格の決定に大きく依存している要因の1つであるブランドに着目して、出品価格で購入されたアイテムと値下げされたアイテムの特徴について分析を行う。ここでは、前者をオフ率0%かつ販売期間8日未満で購入されたもの、後者をオフ率0%以外かつ販売期間8日以降で購入されたものとする。サイトAでは、ブランドを8つのクラスタ(以下、ブランドクラスタ)に分けられている。各販売結果において、各クラスタでの出品価格の平均値を表1に示す。

表1: 各販売結のブランドクラスタにおける平均出品価格 [円]

ブランド クラスタ	出品価格で購入された アイテム (件数)	値下げされた アイテム (件数)
1	6,703 (10,879)	6,124 (13,724)
2	14,519 (4,946)	17,160 (3,310)
3	10,051 (15,877)	11,389 (15,767)
4	7,235 (43,552)	8,210 (50,692)
5	4,975 (123,973)	5,407 (257,398)
6	3,907 (128,266)	4,026 (473,083)
7	3,327 (2,976)	3,463 (39,693)
8	3,878 (55,021)	4,068 (43,112)

※太字は2つのアイテム群を比較して大きい値

表1より、ほとんどのクラスタにおいて、その平均出品価格は、出品価格で購入されたアイテムの方が低い。このことから、同じような価格帯のアイテムでも、出品価格で購入されたアイテムの出品価格は値下がりしない出品価格の最大値よりも低く、値下げされたアイテムの出品価格は高く設定されている可能性がある。そこで、値下がりしない最大出品価格は、前者の出品価格をより高く、後者の出品価格をより低くすることで得られると考えられる。

4. 提案手法

4.1 概要

サイトAで扱われるアイテムは、出品価格によって2通りの販売結果が得られる。出品価格で購入されたアイテムは出品価格を上げると、ある価格を境に出品価格のまま購入されなくなり、値下げに結び付くと考えられる。一方、値下げされたアイテムは出品価格を下げると、ある価格を境に出品価格で購入されるようになると考えられる。

そこで本研究では、出品価格で購入されるアイテムに対しては、出品価格を上げ、値下げされる直前の価格を見つける。一方、値下げされるアイテムに対しては、出品価格を下げ出品価格で購入される際の価格を見つける。

提案手法ではまず、過去に購入されたアイテムの販売履歴データにおける、オフ率と販売期間を分類基準として学習することで、2通りの販売結果を判別する分類規則を構築する。そして出品価格を設定した新規アイテムに分類規則を適用し、販売結果を予測する。次に、アイテムの値下がりしない出品価格の最大値を推定する。出品価格で購入されると予測されるアイテムに対しては、出品価格を段階的に上げながらオフ率の分類規則を適用し、値下げされると予測される出品価格を値下がりしない出品価格の最大値と推定する。一方、値下げされると予測されるアイテムに対しては、出品価格を段階的に下げながら

らオフ率の分類規則を適用し、出品価格で購入されると予測される出品価格を値下がりしない出品価格の最大値と推定する。

4.2 提案手法のアルゴリズム

N 個の学習データのうち、 n 番目のアイテムの出品価格を p_n 、出品価格以外の特徴量を $\mathbf{x}_n \in \mathbb{R}^D$ 、オフ率に関する分類ラベルを表す離散変数を $o_n \in \{0, 1\}$ 、販売期間に関する分類ラベルを表す離散変数を $d_n \in \{0, 1\}$ と定義する。ただし、 o_n は n 番目のアイテムのオフ率が0%ならば0、0%より高ければ1をとる変数であり、 d_n は n 番目のアイテムの販売期間が k 日未満ならば0、 k 日以降ならば1をとる変数とする。また、オフ率が0%と0%より高いクラスを識別する関数を $f(\cdot, \cdot)$ 、販売期間が k 日未満と k 日以降を識別する関数を $g(\cdot, \cdot)$ とする。

このとき、 $f(\cdot, \cdot)$ 、 $g(\cdot, \cdot)$ の学習アルゴリズムと、新たに出品する新規アイテム $\tilde{\mathbf{x}}$ の販売結果を予測し、値下がりしない出品価格の最大値を推定するアルゴリズムを以下に示す。ここでは、新規アイテムのうち、オフ率が0%かつ販売期間が k 日未満と予測されるアイテムを出品価格で購入されるアイテム ($I_0 \in \mathcal{I}$)、オフ率が0%より高くかつ販売期間が k 日以降と予測されるアイテムを値下げされるアイテム ($I_1 \in \mathcal{I}$) と定義する。ただし、どちらにも含まれないアイテムについては値下がりしない出品価格の最大値は求めない。また、新規アイテム $\tilde{\mathbf{x}}$ の暫定出品価格を \tilde{p} 、出品価格の値上げ幅 s 、値下げ幅 t 、さらに、出品価格を無限に変化させないための上限値と下限値をそれぞれ予め設定しておく。

Step1) 販売結果の予測

Step1-1) $f(\cdot, \cdot)$ は、入力アイテムのオフ率が0%ならば0、0%より高ければ1となるように $\{p_n, \mathbf{x}_n, o_n\}_{n=1}^N$ を学習データとして学習する。

Step1-2) $g(\cdot, \cdot)$ は、入力アイテムの販売期間が k 日未満ならば0、 k 日以降ならば1となるように $\{p_n, \mathbf{x}_n, d_n\}_{n=1}^N$ を学習データとして学習する。

Step1-3) 新規アイテム $\tilde{\mathbf{x}}$ に対し、 $f(\tilde{p}, \tilde{\mathbf{x}}) = 0$ かつ $g(\tilde{p}, \tilde{\mathbf{x}}) = 0$ のとき I_0 へ分類し、Step2へ。
 $f(\tilde{p}, \tilde{\mathbf{x}}) = 1$ かつ $g(\tilde{p}, \tilde{\mathbf{x}}) = 1$ のとき、 I_1 へ分類し、Step3へ。

Step2) 出品価格で購入されるアイテム ($\{\tilde{p}, \tilde{\mathbf{x}}\} \in I_0$) の値下がりしない出品価格の最大値の推定

Step2-1) $j = 0$, $\tilde{p}^{(0)} = \tilde{p}$ とする。

Step2-2) $\tilde{p}^{(j+1)} = \tilde{p}^{(j)} + \tilde{p}^{(j)} \times s$ とする。 $\tilde{p}^{(j+1)}$ が上限値以上の場合、上限値を最大出品価格として終了。

Step2-3) $f(\tilde{p}^{(j+1)}, \tilde{\mathbf{x}}) = 1$ ならば、 $\tilde{p}^{(j)}$ を最大出品価格として終了。 $f(\tilde{p}^{(j+1)}, \tilde{\mathbf{x}}) = 0$ ならば、 $j = j + 1$ とし、Step2-2に戻る。

Step3) 値下げされるアイテム ($\{\tilde{p}, \tilde{\mathbf{x}}\} \in I_1$) の値下がりしない出品価格の最大値の推定

Step3-1) $j = 0$, $\tilde{p}^{(0)} = \tilde{p}$ とする。

Step3-2) $\tilde{p}^{(j+1)} = \tilde{p}^{(j)} - \tilde{p}^{(j)} \times t$ とする。 $\tilde{p}^{(j+1)}$ が下限値以下の場合、下限値を最大出品価格として終了。

Step3-3) $f(\tilde{p}^{(j+1)}, \tilde{\mathbf{x}}) = 0$ ならば、 $\tilde{p}^{(j+1)}$ を最大出品価格として終了。 $f(\tilde{p}^{(j+1)}, \tilde{\mathbf{x}}) = 1$ ならば、 $j = j + 1$ とし、Step3-2に戻る。

5. 実データ分析

サイト A の販売履歴データに提案手法を適用し、2通りの販売結果に判別するための分類規則の学習を行う。そして、分類規則を用いて、新規アイテムの販売結果を予測し、値下がりせずに購入される出品価格の最大値を推定する。得られた結果から、各アイテムと推定出品価格との関係分析を行う。

5.1 分析条件

提案手法を、サイト A における 2017 年 1 月 1 日から 12 月 31 日の販売履歴データに適用する。データ件数は 284,112 件 (分類器を構築する際の学習データ: 255,700 件, 新規アイテムとして使うテストデータ: 28,412 件) であり、アイテムの特徴量として、出品価格に加えて、定価、20 種類のアイテムカテゴリ、51 種類の補助変数を用いる ($D = 72$)。また、分類の評価指標として正解率を用いる。

本研究では、事前分析を通じ、販売期間の分類基準を $k = 8$ とし、出品価格の値上げ幅 $s = 0.01$ 、値下げ幅 $t = 0.01$ と設定した。また、オフ率の分類器 $f(\cdot, \cdot)$ と販売期間の分類器 $g(\cdot, \cdot)$ には Random Forests (RF) [2] を用いる。ここで、分類器 $f(\cdot, \cdot)$ 、 $g(\cdot, \cdot)$ における木の数はそれぞれ 200, 700 とし、木の深さの最大値はどちらも 100 とした。さらに、各ノードの分割基準にはジニ係数を用いるものとした。出品価格を変化させる際の制約条件として、出品価格の上限値を各アイテムの定価、出品価格の下限値を各アイテムの定価の 10% と設定した。

5.2 2通りの販売結果への分類精度

2通りの販売結果への分類において、オフ率と販売期間の分類器の正解率を表 2 に、テストデータの各販売結果における正解率を表 3 に示す。

表 2: 各分類器による正解率

	オフ率 $f(\cdot, \cdot)$	販売期間 $g(\cdot, \cdot)$
学習データ	0.999	0.999
テストデータ	0.693	0.703

表 3: テストデータの各販売結果における正解率

	出品価格で購入されるアイテム	値下げされるアイテム
正解率	0.486	0.756

表 2 より、オフ率と販売期間の分類器はテストデータに対して約 7 割の正解率が得られていることが分かる。また表 3 より、出品価格で購入されるアイテムへの分類は約 49%、値下げされるアイテムへの分類は約 76%の精度が得られていることが分かる。以上より、オフ率と販売期間を用いることで、新規アイテムの販売結果をある程度予測できることが示された。

さらに、RF を用いた各分類器においてどの特徴量が分類に影響しているのかを調べるため、各特徴量の重要度を分析した。表 4、5 にオフ率と販売期間の分類器において重要であった特徴量の上位 10 個を示す。

表 4: 重要特徴量 ($f(\cdot, \cdot)$)

特徴量	説明	重要度
前回販売期間	買い取ったアイテムが販売されていた際の販売期間	0.183
在庫日数	アイテムの下取り日から出品日までの日数	0.163
定価	アイテムが未使用の際の出品価格	0.155
出品価格	サイト A でアイテムを出品する際の価格	0.132
コンディション_C	アイテムの状態	0.0190
コンディション_B	アイテムの状態	0.0177
画像使用_有	サイト A に掲載する際に画像使用	0.0175
セールランク_C	セールされている度合	0.0170
新品	買い取ったアイテムが新品で購入されたもの	0.0152
カテゴリ_カットソー	アイテムのカテゴリ	0.0122

表 5: 重要特徴量 ($g(\cdot, \cdot)$)

特徴量	説明	重要度
前回販売期間	買い取ったアイテムが販売されていた際の販売期間	0.175
在庫日数	アイテムの下取り日から出品日までの日数	0.158
定価	アイテムが未使用の際の出品価格	0.158
出品価格	サイト A でアイテムを出品する際の価格	0.140
コンディション_C	アイテムの状態	0.0215
セールランク_C	セールされている度合	0.0191
コンディション_B	アイテムの状態	0.0190
画像使用_有	サイト A に掲載する際に画像使用	0.0173
新品	買い取ったアイテムが新品で購入されたもの	0.0133
カテゴリ_カットソー	アイテムのカテゴリ	0.0111

表 4、5 より、2つの分類器において重要な特徴量にほとんど違いはなく、前回販売期間、在庫日数、定価、出品価格が特に重要な特徴量であることが分かる。これらの特徴量はすべて量的変数であり、質的変数に比べて多様性が高く、それによりこのような結果になったと考えられる。

5.3 値下がりしない出品価格の最大値についての分析

(1) カテゴリに着目した分析

出品価格で購入されると予測されたアイテムのうち、出品価格が、上限値に到達しなかったアイテムと上限値に到達したアイテム、値下げされると予測されたアイテムのうち、出品価格が、下限値に到達しなかったアイテムと下限値に到達したアイテムのカテゴリについてそれぞれ分析する。分析結果を表 6 に示す。ただし、全データを分析した際に、20 種類のカテゴリのうち、アイテムの所属割合が 3%未満であったカテゴリはデータ数が非常に少なく、分析する上で偏った特徴が見られると考えたため、今回は分析対象外とした。

表 6: カテゴリ別の各グループの割合 [%]

カテゴリ (割合)	出品価格で購入されるアイテム		値下げされるアイテム	
	上限値未達	上限値到達	下限値未達	下限値到達
全体 (100.00)	5.71	16.82	43.56	33.90
カットソー (15.49)	6.42	12.19	47.06	34.33
コート (3.59)	3.43	41.37	29.31	25.89
シャツ (10.86)	7.90	17.72	45.65	28.73
シューズ (10.42)	2.45	8.04	38.07	51.44
スカート (7.24)	6.81	13.55	50.16	29.49
デニム (4.41)	8.68	17.05	49.07	25.21
ニット (13.25)	3.61	15.07	34.00	47.32
バッグ・ケース類 (10.04)	5.31	24.80	40.55	29.34
パンツ (13.52)	8.00	11.91	50.44	29.66
ワンピース (11.16)	5.93	17.82	49.37	26.89

※太字は割合が大きい上位 3 つのカテゴリ

表 6 より、全アイテムの所属割合を比較すると、上限値に到達しなかったアイテムには、シャツ、デニム、パンツが多く含まれ、それらは出品価格を上げてもオフ率 0% を達成できるアイテムと考えられる。また、上限値に到達したアイテムにはコート、シャツ、バッグ・ケース類が多く含まれ、それらは定価のままでもオフ率 0% を達成できるアイテムであり、他のアイテムに比べて売上増加を見込めると考えられる。

一方、下限値に到達しなかったアイテムには、スカート、パンツ、ワンピースが多く含まれる。これらは出品価格を下げることでオフ率 0% を達成できると考えられ、販売期間の短縮が見込める。また、下限値に到達したアイテムにはカットソー、シューズ、ニットが多く含まれ、これらは出品価格を大きく下げてもオフ率 0% を達成できないアイテムが多く、アイテムの買取自体を検討する必要があると考えられる。

次に、上限に到達しなかったアイテムのカテゴリにおいて、最も割合が大きくなったデニムに対し、提案手法で算出した出品価格とその値上がりした割合 (以下、値上げ度) を式 (1) のように定義し、得られた度数分布を図 1 に示す。また、下限に到達しなかったアイテムのカテゴリにおいて、最も割合が大きくなったパンツに対し、提案手法で算出した出品価格とその値下がりした割合 (以下、値下げ度) を (2) のように定義し、得られた度数分布を図 2 に示す。ただし、図中の % 表示は、 $q\%$ 以上 $q + 10\%$ 未満の値上げ度・値下げ度となったアイテムを

q と表記した。また、アイテムが所属しない値上げ度・値下げ度は省略している。

$$\text{値上げ度} = \left(\frac{\text{最終出品価格} - \text{元の出品価格}}{\text{元の出品価格}} \right) \times 100 \quad (1)$$

$$\text{値下げ度} = \left(\frac{\text{元の出品価格} - \text{最終出品価格}}{\text{元の出品価格}} \right) \times 100 \quad (2)$$




図 1: 値上げ度の分布 (デニム)




図 2: 値下げ度の分布 (パンツ)

図 1 より、値上げ度の分布が 0% から 9%、30% から 39% に多く分布していることから、上限値に到達しなかったデニムの多くは出品価格を 0% から 9% または 30% から 39% 値上げしたとしても出品価格で購入されると考えられ、売上増加が見込める。また図 2 より、値下げ度の分布が 0% から 9% に多く分布していることから、下限値に到達しなかったパンツの多くは出品価格を 0% から 9% 値下げすることで出品価格で購入されると考えられ、販売期間短縮が見込める。

(2) ブランドに着目した分析

予測したアイテムの販売結果に対し、出品価格を変化させて推定した結果をブランドクラスタに着目して分析を行う。分析結果を表 7 に示す。

表 7: ブランドクラスタ別の各グループの割合 [%]

ブランドクラスタ (割合)	出品価格で購入されるアイテム		値下げされるアイテム	
	上限値未達	上限値到達	下限値未達	下限値到達
全体 (100.00)	5.71	16.82	43.56	33.90
1 (2.01)	1.81	19.92	34.21	44.06
2 (0.56)	0.72	52.90	28.26	18.12
3 (2.27)	2.66	40.32	29.48	27.53
4 (7.43)	4.57	30.67	35.51	29.26
5 (29.25)	5.44	20.47	43.60	30.49
6 (47.42)	5.83	10.89	46.40	36.88
7 (3.40)	3.92	4.16	49.29	42.64
8 (7.66)	10.23	21.45	38.75	29.57

※太字は割合が最も大きいブランドクラスタ

表 7 より、クラスタ 8 は他のブランドクラスタに比べて上限値未達の割合が大きい。このことから、クラスタ 8 に所属するアイテムの多くは出品価格を上げてオフ率 0% を達成できるアイテムと考えられる。また、クラスタ 2 は他のクラスタに比べて上限値到達の割合が大きい。このことから、クラスタ 2 に所属するアイテムの多くは定価のままでもオフ率 0% を達成できるアイテムであり、他のアイテムに比べて売上増加を見込めると考えられる。

一方、クラスタ 7 は他のクラスタに比べて下限値未達の割合が大きい。このことから、クラスタ 7 に所属するアイテムの多くは出品価格を下げることでオフ率 0% を達成できると考えられ、販売期間の短縮が見込める。また、クラスタ 1 は他のクラスタに比べて下限値到達の割合が大きい。このことから、クラスタ 1 に所属するアイテムの多くは出品価格を大きく下げてもオフ率 0% を達成できないアイテムが多く、アイテムの買取自体を検討する必要があると考えられる。

次に、上限値未達の割合が最も大きかったクラスタ 8 に所属するアイテムに対し、式 (1) により値上げ度を求め、その度

数分布を図 3 に示す。また、下限値未達の割合が最も大きかったクラスタ 7 に所属するアイテムに対し、式 (2) により値下げ度を求め、その度数分布を図 4 に示す。




図 3: 値上げ度の分布 (ブランドクラスタ 8)




図 4: 値下げ度の分布 (ブランドクラスタ 7)

図 3 より、値上げ度の分布が 10% から 19% に多く分布していることから、上限値に到達しなかったクラスタ 8 の多くは出品価格を 10% から 19% 値上げしたとしても出品価格で購入されると考えられ、売上増加が見込める。また図 4 より、値下げ度の分布は 0% から 9% に多く分布していることから、下限値に到達しなかったクラスタ 7 の多くは出品価格を 0% から 9% 値下げすることで出品価格で購入されると考えられ、販売期間短縮が見込める。

6. まとめと今後の課題

本研究ではサイト A におけるアイテムの出品価格決定問題を対象とし、新たに出品するアイテムの値下がりせずに購入される出品価格の最大値を推定することを目的とし、アイテムの販売結果を予測することで、値下がりしない出品価格の最大値を推定する手法を提案した。これを実際にサイト A の販売履歴データに適用し出品価格を推定することで、提案手法の有効性を示した。これにより、サイト A において、各アイテムが値下がりせずに購入される出品価格の最大値の推定を可能とした。この推定出品価格はサイト A における出品価格決定の際の新たな基準値となることが期待できる。

今後の課題としては、アイテムの販売結果の予測手法の検討が挙げられる。本研究では分類精度と計算コストを考慮したため RF を用いたが、他の 2 値分類の手法として、Support Vector Machine [3] やニューラルネットワーク [4] といった手法により、予測精度が向上する可能性もある。また、本研究では、新規アイテムの出品価格を推定する際、オフ率が 0% 以下かつ販売期間が k 日以降と予測されたアイテムと、オフ率が 0% より高くかつ販売期間が k 日未満と予測されたアイテムは、推定対象外のアイテムとした。そのため、それらのアイテムを考慮した出品価格の推定モデルも必要である。

参考文献

- [1] 仁ノ平 将人, 三川 健太, 後藤 正幸, “販売履歴データに基づく中古ファッションアイテムの販売価格予測モデルに関する一考察,” 情報処理学会論文誌, Vol. 60, No. 4, (掲載決定)
- [2] L. Breiman, “Random Forests,” *Machine Learning*, Vol. 45, pp. 5–32, 2001.
- [3] J. A. Suykens and J. Vandewalle, “Least Squares Support Vector Machine Classifiers,” *Neural processing letters*, Vol. 9, No. 3, pp. 293–300, 1999.
- [4] 麻生英樹, “ニューラルネットワーク情報処理,” 産業図書, 1998.