

バイヤーの入札行動を支援する情報提供 フレームワークの提案

桑田 修平, 矢野 順子, 生田目 崇, 関根 純

1. はじめに

情報技術の進展は、市場における取引の形態を大きく変えた。すなわち、インターネットがマーケットプレイスの1つとなり、売買が活発化されると同時に、売買履歴が大量に蓄積されることとなった。現在では、蓄積された履歴データを有効活用し、マーケティング活動に利用しようとする動きが見られ、例えば、Amazon.comでは、利用者の購買履歴を分析することで、利用者の好みに合わせた商品を推薦するサービス（レコメンデーションサービス）などが行われている[4]。

本論文では、B2B（Business to Business：企業間取引）の中古車オークションにおいて蓄積された売買履歴データを用いて、オークション入札者（バイヤー）に対し、入札行動を支援する情報を提供するフレームワークを提案する。なお、本論文で使用した売買履歴データは、経営科学系研究部会連合協議会が主催した「平成19年度データ解析コンペティション」において、システム・ロケーション株式会社¹より提供していただいたデータである。

これまで、オークションの理論的分析については、経済学的なアプローチやゲーム理論によるアプローチなどが従来から利用されてきた[7][11]。これらは、オークションというシステムの中で、どのような価格形成がされるか、もしくは、参加者がどのような行動規範のもとで行動するかが対象となっている。他にも、実際のオークション市場での落札価格の分析[10]や、

各プレイヤーの異質性をエージェントとして表現し、プレイヤーの入札行動を分析するという研究[2]、入札者数を潜在モデルによって表現する研究[6]などが行われている。このように、オークションの原理を説明しようとする研究は数多く行われているが、オークション履歴を元に、バイヤーごとの入札行動をモデル化し、バイヤーの入札行動を支援するようなサービスの立場に立った研究はほとんどない。

2. 支援のフレームワーク

本論文が対象とする中古車オークションでは、入札会形式の“第一価格落札方式”により落札するバイヤーが決定される。すなわち、各オークションにおいて、すべてのバイヤーは同時に1回限りの入札が可能であり、最高入札価格をつけたバイヤーが当該車を落札する権利を得る。したがって、各バイヤーは、どのバイヤーがいくらで入札したのか等、他のバイヤーの入札行動に関する情報を事前に知ることはできない。

そこで本論文では、売買履歴データを活用することで、出品車が提示されたとき、「どのバイヤーが入札しそうか」、また「落札価格はいくらになりそうか」に関する情報を、その情報を必要とするであろうバイヤーに提供するフレームワークを提案する（以降、これらの情報を“入札支援情報”と呼ぶ）。提案法は、入札支援情報を必要としているバイヤーに対して、出品車に対するバイヤーの予想入札状況や、出品車に対する予想落札価格を事前に提供する、いわばプロアクティブなレコメンデーションを目指すものである。図1に、本論文における分析フレームワークを示す（詳細は次節にて述べる）。提案法により、支援情報を提供されたバイヤーは、提供された情報をもとに、どのバイヤーと競合することになりそうか、落札価格の分

くわた しゅうへい, やの じゅんこ, せきね じゅん
（株）NTT データ 技術開発本部
〒135-8671 江東区豊洲3-3-9
なまため たかし
専修大学 商学部
〒214-8580 川崎市多摩区東三田2-1-1
受付 08.7.18 採択 08.12.5

¹ <http://www.slc.jp/>




図1 分析フレームワーク

かれ目がいくらになりそうか、を踏まえた入札行動がとれるようになる。また、中古車提供者（サプライヤー）にとっても、こういった情報を提供することで、自身の出品車を落札したいであろうバイヤーを把握することができ、その結果、オークション市場そのものの活性化にも寄与するものと考えられる。

以下に本論文の構成を示す。まず、3.で問題設定について説明する。続いて、4.で提案する分析モデルの詳細を述べ、5.でその評価を行う。最後に、6.でまとめる。

3. 問題設定

3.1 本論文が対象とするオークション

本論文が対象とするオークションにおいては、以下のステップで落札バイヤーが決定するものとする。

1. サプライヤーが、中古車 j ($j=1, 2, \dots, M, M \in \mathbb{Z}^+$) を出品する。
2. 落札を希望するバイヤー i ($i=1, 2, \dots, N, N \in \mathbb{Z}^+$) は、車種名やキズの有無など出品車の特徴を表す情報である“特徴量 c_j ” (c_j は G 次元のベクトルで表現されるものとする)、をもとに、入札価格 $w_{i,j}$ ($w_{i,j} \in \mathbb{R}$) を決め入札を行う。ここで、入札した場合 $b_{i,j}=1$ 、入札しなかった場合 $b_{i,j}=0$ とする。
3. 入札価格の集合 $W_j = \{b_{i,j} \times w_{i,j}\}_{i=1}^N$ の中で最高値 $v_j (= \max_i W_j)$ をつけたバイヤー a_j が、出品車 j を落札する権利を得る。
4. 上記3ステップを、サプライヤーが提供する中古車の台数 M 回分繰り返す。

なお、ステップ3において落札価格が決定する際、落札価格は入札数に影響を受けるものとする（図1における「入札者数」から「落札価格」への矢印に該当）。これは、人気の高い（入札数の多い）中古車ほど落札価格が高くなる傾向があることを想定しているためである。つまり、入札価格がある確率分布に従って発生

するとした場合、サンプル数（入札数）が多いほど、入札価格の分散が大きくなる（落札価格が高くなる）傾向があることを念頭に入れている。また、入札の際には、他のバイヤーの入札状況や入札金額を知ることができず、事前に把握可能な情報は、出品車に関する特徴量 c_j のみであるものとする。

3.2 本論文で利用可能なデータ

上記オークションにおいて蓄積された情報のうち、本論文で利用可能な売買履歴データ $O = \{V, C, A, B\}$ は以下のとおりである：

- 落札価格ベクトル V ：オークション j における落札価格 v_j を第 j 要素にもつ、 M 次元ベクトル。
- 出品車特徴量行列 C ：オークション j における出品車の特徴量ベクトル c_j を第 j 行にもつ、 $M \times G$ 行列。
- 落札バイヤーベクトル A ：オークション j において落札したバイヤー番号 $a_j (\in \{1, 2, \dots, N\})$ を第 j 要素にもつ、 M 次元ベクトル。
- 入札数ベクトル B ：オークション j における入札数 $b_j = \sum_{i=1}^N b_{i,j}$ を第 j 要素にもつ、 M 次元ベクトル。

つまり、オークション j における、バイヤーの入札価格集合 $\{w_{i,j}\}_{i=1}^N$ や入札フラグ集合 $\{b_{i,j}\}_{i=1}^N$ は無い。また、オークション j に関する履歴 $\{v_j, c_j, a_j, b_j\}$ を、オークション履歴 o_j と表記する。

3.3 本論文の目的

本論文で提案する入札支援情報提供フレームワークが提供する情報とは、前述の通り、(1)出品車に対するバイヤーの予想入札状況、および、(2)出品車に対する予想落札価格である。したがって、以下の項目を満たす入札支援情報提供フレームワークを提案することを本論文の目的とする。

- (1) 出品車 j^* の特徴量ベクトル c_{j^*} が与えられた下で、バイヤー i の入札フラグを代替する入札確率 q_{i,j^*} を予測する。
- (2) 落札価格の決定には入札数が影響を与えるものと想定し、出品車 j^* の特徴量ベクトル c_{j^*} と入札数 b_{j^*} が与えられた下で、落札価格 v_{j^*} を予測する。

以上より、提案する入札支援情報提供フレームワークとは、売買履歴データ O を用いて、目的(1)、(2)を実現する予測モデルをそれぞれ構築することにより、入札数の予測値 \hat{b}_{j^*} や落札価格の予測値 \hat{v}_{j^*} を算出し、

必要とするバイヤーにそれらを提供する枠組みである。

4. モデルの構築

本論文では、(1)“入札確率を予測するモデル”については確率モデル、(2)“入札数、および、落札価格を予測するモデル”については一般化線型モデルを用いたモデル構築法を提案する。以下、各モデルの詳細を説明する。

4.1 入札確率に対する予測モデル

今回利用できるデータは、入札数 B を含むが、各バイヤーの入札フラグ集合 $\{b_{i,j}\}_{i=1, j=1}^{N,M}$ は含まれない。つまり、出品車に対する入札数は既知であるが、落札者以外のどのバイヤーがどの出品車に入札をしたのかは未知である。そこで、入札フラグ集合 $\{b_{i,j}\}_{i=1, j=1}^{N,M}$ の代わりに、落札バイヤーベクトル A を用いて、入札確率を求めるモデルを構築する。具体的には、「少なくとも落札したバイヤーは当該車に入札をしている」ということから、

“落札した車の特徴量が類似しているバイヤーは、特徴量が類似している車に入札をしている”，と仮定し、落札車の傾向が類似したバイヤーごとのオークション履歴同士をまとめる、つまり、履歴に基づいてバイヤーをクラスタリングする。すると、同じクラス k ($k=1, 2, \dots$) に属するバイヤーは、そのクラスを特徴付ける車の特徴量と類似した出品車に対して高い確率で入札する、と見なせる。以上を踏まえ、以下のデータ生成プロセスを仮定する：

1. 落札車の特徴の傾向を表現する“潜在クラス r ($r=1, 2, \dots$)”が、各バイヤーに割り当てられる。
2. 潜在クラス (バイヤークラス) r ごとに定めた確率分布から、オークション j に対して落札車の特徴量ベクトル c_j が定まる。

ここで、本論文では、無限関係モデル[9]を用いたバイヤークラスタリングを行う。無限関係モデルは、与えられた行列を行と列に関してクラスタリングが行える確率モデルであり、本論文で対象とするオークション履歴データをクラスタリング対象とした場合、バイヤーと車の特徴量がそれぞれ行と列に割り当てられ、これらが一括してクラスタリングされる。図2にそのイメージを示す。無限関係モデルの下では、バイヤーのクラス割り当て集合を $Z = \{z_i \in \mathbb{Z}^+; i=1, 2, \dots, N\}$ とし、車の特徴量のクラス割り当て集合を $W = \{w_g \in \mathbb{Z}^+; g=1, 2, \dots, G\}$ と表すものとする、出品車特

	車クラス①			車クラス②			車クラス③				
バイヤークラス	①	落札	落札	落札	-	-	-	-	の車に対する 入札確率	} $P(\text{車} \rightarrow \text{バイヤー}) = 0.7$	
	②	-	落札	落札	-	-	-	-			} $P(\text{車} \rightarrow \text{バイヤー}) = 0.8$
	③	落札	-	落札	落札	落札	-	-			
		-	落札	落札	-	落札	-	-			
		-	-	-	-	-	落札	落札			

図2 バイヤークラスタリングのイメージ

微量行列 C の結合分布は、以下のように表される：

$$p(C, Z, W) = p(C|Z, W)p(Z)p(W). \quad (4.1)$$

ここで、 $p(C|Z, W)$ はバイヤークラスと車の特徴量のクラスから定まる“ブロック”ごとに仮定されるベルヌーイ分布を表す²。図2を用いて説明すると、バイヤークラス1と車クラス1により定まるブロックと、バイヤークラス1と車クラス2により定まるブロックとでは、いずれも「落札」に関する分布ではあるが、「落札」の占める割合が異なる。つまり、異なるパラメータ値を持つベルヌーイ分布がブロックごとに仮定される。さらに、 $p(Z)$ 、 $p(W)$ はクラス割り当てに対する分布をそれぞれ表し、本論文では、Dirichlet Process 事前分布 (DP 事前分布) を仮定する。DP 事前分布は、式(4.2)に示すようなスケールパラメータ α_K (スカラー値、 K はクラス数を表す) と基底分布 H_K により既定される“分布に対する分布”であり、クラス数自体も確率モデルに含めることができる。DP 事前分布を仮定するベイズモデル³ は、特に、ノンパラメトリックベイズモデルと呼ばれる[3][8][9]。

$$p(K) \sim \text{DP}(\alpha_K, H_K). \quad (4.2)$$

無限関係モデルによる、バイヤーと車の特徴量をクラスタリングするアルゴリズム (ギブズサンプラーアルゴリズム[1]) の概要を以下に示す：

1. バイヤーと車の特徴量を適当にクラスタリングする (初期化)。
2. バイヤーを1人選択し、帰属確率の高いバイヤークラスに再割り当てを行う (バイヤークラスの更新)。

² データの特徴に合わせて、ベルヌーイ分布以外にも任意の分布が設定可能である。

³ すべての変数を確率変数と見なしてモデル化を行う。0-1 損失や2乗誤差損失に対して、ベイズ最適な予測が可能となる[5]。

3. 車の特徴量を1つ選択し、帰属確率の高い車の特徴量クラスに再割り当てを行う(車の特徴量クラスの更新).

4. クラスタリング結果に変化が無くなるまで, 2. と3.を繰り返す(収束判定).

以上より, オークション j^* に対するバイヤー i の入札確率の予測値 \hat{q}_{i,j^*} は,

$$\hat{q}_{i,j^*} \propto \prod_g p(c_{j^*,g}=1|z_i, w_g)^{c_{j^*,g}} \times \{1 - p(c_{j^*,g}=1|z_i, w_g)\}^{1-c_{j^*,g}}, \quad (4.3)$$

と表すことができる. ここで, $p(c_{j^*,g}=1|z_i, w_g)$ は, バイヤークラス z_i , 車の特徴量クラス w_g により規定されるブロックに仮定されるベルヌーイ分布において, 1が出る確率を表す. したがって, 入札支援情報を提供するバイヤーを絞り込む場合には, オークション j^* の出品車の特徴量ベクトル c_{j^*} と類似した特徴量ベクトルの車を落札しているバイヤークラスが, 情報提供すべき(推薦すべき)バイヤークラスとして上位に上がる.

4.2 入札数に対する予測モデル

入札数は正の整数であることから, 本論文ではポアソン回帰による予測を行う. ポアソン回帰における目的変数ベクトルは入札数ベクトル B であり, 説明変数は出品車特徴量行列 C である:

$$E[b_j] = \exp\{\beta_0 + \beta_1 c_{j,1} + \beta_2 c_{j,2} + \dots + \beta_G c_{j,G}\}. \quad (4.4)$$

なお, 未知のモデルパラメータ $\{\beta_0, \beta_1, \dots, \beta_G\}$ を推定する際には, 過剰な当てはまりを防ぐため, 外れ値を除去する⁴とともに, AICに基づく変数選択(ステップワイズ法)を行う.

4.3 落札金額に対する予測モデル

落札金額の予測に関しては, ガウス回帰モデルを用いる. 落札価格ベクトル V を目的変数ベクトルとし, 説明変数は, 出品者特徴量行列 C と入札数ベクトル B である. ただし, 落札価格の予測値が非負の値となるよう, $\log(\text{落札価格})$ を目的変数ベクトルとする:

$$\log v_j = \gamma_0 + \gamma_1 c_{j,1} + \gamma_2 c_{j,2} + \dots + \gamma_G c_{j,G} + \gamma_{G+1} b_j. \quad (4.5)$$

また, 入札数の予測と同様, 未知のモデルパラメータ $\{\gamma_0, \gamma_1, \dots, \gamma_{G+1}\}$ を推定する際には, 外れ値の除去と変数選択を行う.

5. 動作検証

5.1 検証内容

2005年7月から2007年7月の間に落札された全120,571回のオークション履歴データを用いて,

(1) 入札数と落札価格の予測,

(2) 入札支援情報を提供すべきバイヤーの予測,

に関する検証を行う. 検証の目的は, 入札支援情報として有用な, 確度の高い予測が可能かどうかを検証することである. ここで, オークション履歴データは,

- エアコンあり/なし, ナビゲーションシステムあり/なし等の, 中古車の装備に関するデータ(全11変数),
- メーカー, 排気量, 全長, 使用燃料, ミッション方式, 駆動方式等の, 中古車の特徴・構成に関するデータ(全9変数),
- 保証書あり/なし, 亀裂あり/なし, レンタカー履歴あり/なし, 走行距離等の, 中古車の使用状況に関するデータ(全11変数),

から構成される. 本検証では, バイナリ変数によりカテゴリ化された履歴データを動作検証用データとして用いる. 例えば, 連続量で表されている排気量は, 排気量に合わせて, 「軽自動車(〜660cc)」、「小型車(661〜1,500cc)」、「中型車(1,501〜2,000cc)」、「ミドルクラス車(2,001〜2,500cc)」、「大型車(2,501cc〜)」とカテゴリ化している. 以下, 検証内容を具体的に説明する.

5.1.1 入札数と落札価格の予測に関する検証内容

事前実験の結果を踏まえ, 入札数の予測モデルと落札価格の予測モデルを車種ごとにそれぞれ構築する. ただし, 動作検証用データに含まれる車種は全13種類であり, 本検証では特に, 履歴数が比較的多い3車種, BV(ボンネットバン), SD(セダン), HB(ハッチバック)を検証対象とする. 履歴数は, それぞれ, 30,206回, 25,576回, 9,907回である. ここで, 車種ごとの履歴データから, ランダムに選んだ半分の履歴をモデルパラメータ推定用データ, 残りの半分を検証用データとする. なお, 予測した値が, モデルパラメータを推定する際に除去した外れ値を超えた場合, 予測値を, 除去した外れ値の最小値で置き換えるものとする. また, 評価尺度として, 予測した値と実際の値との絶対誤差を, 検証用データに関して平均した値(平均絶対誤差)を用いることで, 入札数と落札価格の予測精度を検証する.

⁴ フリーソフトRの“boxplot”により, 外れ値の判定を行った.

表1 入札数と落札価格の予測精度：外れ値処理有り/無し（外れ値処理を行ったデータ数）

車種名	全履歴数	検証用データ数	入札数の平均絶対誤差 [札]	落札価格の平均絶対誤差 [円]
BV	30,206	15,103	4.16 / 4.17 (32.0)	57,393 / 65,331 (385.8)
SD	25,576	12,788	4.71 / 4.71 (0.0)	129,824 / 11,061,044 (938.0)
HB	9,907	4,953	4.08 / 4.09 (5.0)	75,572 / 82,029 (201.2)

表2 予測精度の内訳（平均絶対誤差）：【 】内は検証用データに占める割合を表す

入札数に対する予測精度

車種名	外れ値以外 [札]	外れ値のみ（外れ値処理有り） [札]	改善したデータ数の割合
BV	4.15 [99.8%]	16.41 (9.74) 【0.2%】	98.6%
SD	4.71 【100%】	- (-) 【0%】	-
HB	4.08 [99.9%]	11.18 (7.86) 【0.1%】	97.5%

落札価格に対する予測精度

車種名	外れ値以外 [円]	外れ値のみ（外れ値処理有り） [円]	改善したデータ数の割合
BV	55,539 [97.4%]	436,821 (128,196) 【2.6%】	95.5%
SD	96,738 [92.7%]	140,037,518 (547,533) 【7.3%】	64.8%
HB	69,836 [95.9%]	370,552 (210,558) 【4.1%】	76.7%

5.1.2 支援情報を提供すべきバイヤーの予測に関する検証内容

落札回数が10回以上のバイヤーの履歴データのみを対象として、ランダムに選んだ100回の履歴データを検証用データ、残りの120,471回の履歴データをバイヤークラスタリング用データとする。ここで、バイヤークラスタリング用データは、バイヤーごとに履歴データの論理和をとった値からなるものとする。例えば、同一のバイヤーが、「軽自動車」2台と「中型車」1台を落札していた場合、該当するベクトルの要素はいずれも1と表される。

バイヤークラスタリング用データを用いたバイヤークラスタリングの終了後、検証用の履歴データを新たな出品車と見なして、出品車ごとに、入札の確度（優先度）の高い順にバイヤークラスを並べる。そして、実際に落札したバイヤーが所属するバイヤークラスの順位を調べることで、確度の高い入札支援情報として適切にバイヤークラスが選択できているかを検証する。

5.2 検証結果

5.2.1 入札数と落札価格の予測結果

車種ごとの入札数と落札価格の予測精度を表1に示す。また、表2に、外れ値処理の対象となった（ならなかった）データに対する予測精度の内訳を示す。ただし、表の各値は、検証用データとして作成した5セットの平均値を表す。車種BVについて見てみると、表1より、入札数と落札金額の平均絶対誤差はそれぞれ4.16札と57,393円であり、予測値が外れ値を超え

た場合の処理を施さなかった場合は、それぞれ4.17札と65,331円である。なお、外れ値処理の対象となったデータ数は、それぞれ32.0個、385.8個であり（表1）、検証用データ数に占める割合はそれぞれ、約0.2%、約2.6%であった（表2）。表2より、予測値が外れ値と見なされたデータの予測精度が極端に悪く、それらに対する変換処理の効果があることが分かる。ここで、BVに対する平均絶対誤差について、実際の入札数の平均は12札（最低1札～最高57札）、落札金額については平均16万円（最低1,000円～最高213万円）であることから、極端に予測精度が悪いケースが数%存在してはいるものの、90%以上の検証用データについては概ね精度良く予測できているといえる。さらに、SD/HBについても、それぞれ、実際の入札数の平均は14札（最低1札～最高55札）/12札（最低1札～最高47札）、落札金額については平均40万円（最低1,000円～最高685万円）/平均21万円（最低1,000円～最高245万円）であることから、予測精度は概ね良いといえる。

次に、予測結果を詳細に見るため、車種HBに関する入札数、および、落札価格の予測結果のプロット図の一例を図3に示す。図3より、落札価格の予測について、横軸に並行となるような価格の上限が見られるが、これは予測値が外れ値を超えたケースを示している。一方、入札数の予測について見てみると、予測値が外れ値を超えたケースが5個と少なく、落札価格の予測と比べて、入札数の予測は安定していることが

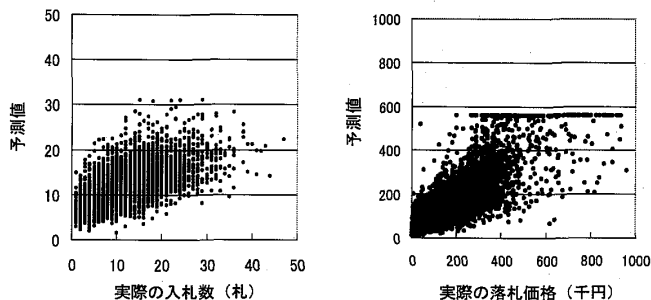


図3 車種HBにおける実際の値と予測値のプロット
図(外れ値処理後)

分かる。また、表1のSDの落札価格に対する平均絶対誤差を見ても、入札数の予測と比べて、落札価格の予測がうまく行えていないケースが多いことが分かる。これより、入札数については、中古車の車種情報からある程度説明することはできるが、落札金額については、車種情報や入札数の他にも影響を与える要因が存在している可能性があるため、と推察できる。他に、今回用いたモデルでは、落札金額の変域の大きさ(SDの場合、1,000円~685万円)をうまく表現できていない、とも推察できることから、これらに対応するためには、外れ値と思えるような値にも対応可能なモデルを構築する(例えばモデルの数を増やす、など)ことも考えられる。ただし、外れ値処理の対象となったデータ数は、多くても約7%に過ぎず、概ね精度良く予測できており、入札支援情報として有益な情報が提供可能であることが確認できた。

5.2.2 支援情報を提供すべきバイヤーの予測結果

提案したモデルの頑健性の検証のために、局所解を考慮して同一のバイヤークラスタリング用データに対してバイヤークラスタリングを5回行い、さらに、検証用データを5セット用意した計25回の検証を行った。その結果、バイヤークラス数の平均は約23クラス、中古車の特徴量のクラス数は約20クラスで安定的であった。得られたクラスタリング結果を用いて、入札支援情報を提供すべきバイヤークラスを予測した結果を図4に示す。ここで、図の値は、計25回の検証結果の平均値を表す。

図4より、入札支援情報を提供する優先順位が最も高い(1位の)バイヤークラスに、実際に落札したバイヤーが含まれている割合は約27%であり、また、優先順位の高い上位5クラスに入札支援情報を提供した場合、実際に落札したバイヤーが80%以上カバーできていることが分かる。以上より、入札支援情報を提供すべきバイヤーを適切に選択できることが確認で




図4 実際に落札したバイヤーが情報提供対象クラスに含まれる割合

きた。

5.3 レコメンデーションについて

前節までで、入札確率、入札数、および、落札金額に関するモデルの詳述と評価を行った。本節では、これらのモデルから得られる情報を用いて、各バイヤーへのレコメンデーションを行う方法について述べる。

ここで、入札数は、その出品車に対してどのくらいのバイヤーが興味を持つかを示す指標であり、もし予測される入札数が少なければ、特定のバイヤーのみが出品車に興味を持つことが想定され、逆に、予測入札者数が多ければ幅広いバイヤーが入札の意向があると考えられる。

そこで、予測入札数に応じて落札確率の高い順にバイヤーに出品情報を提供することが考えられる。予測入札数が少ない場合は、レコメンド対象バイヤーを絞ることができ、無駄な情報提供をせずにすむ。また、予測入札者数が多い場合には、その出品車は多くのバイヤーに興味を持つ可能性が高いため、幅広いバイヤーに対して推奨することで、機会損失を食い止めることができる。その際には、価格に関する指標を同時に提示することで、落札価格に関するひとつの目安を与えることもできる。

このように、本論文で提案したフレームワークによって、各出品車に対するバイヤーの入札の意向の強さが入札確率という形式で表現され、予測された入札数に応じたレコメンドを行うことで、効率的かつ効果的なレコメンデーションが実現可能となる。

6. まとめ

本論文では、中古車オークションにおいて蓄積され

た売買履歴データを用いて、他のバイヤーの入札状況や、出品車の落札価格を予測し、それらの情報を入札支援情報として、必要とするバイヤーに提供するフレームワークを提案した。具体的には、バイヤーごとの入札確率を予測するモデルをノンパラメトリックベイズモデルによって、また、出品車の落札価格を予測するモデルを一般化線型モデルによって構築し、実データを用いた動作検証を行うことにより、提案するフレームワークが正しく動作することを確認した。ただし、より正確な予測精度を検証するためには、入札履歴を用いた検証を行う必要がある。他に、ロジット・モデルや回帰モデルなど、本論文で利用したモデルの代替モデルとなり得るモデルの構築、および、比較を行うことも今後の課題として挙げられる。

参考文献

- [1] 伊庭幸人, 種村正美, 大森裕浩, 和合肇, 佐藤整尚, 高橋明彦: 「計算統計 II マルコフ連鎖モンテカルロ法とその周辺」, 岩波書店 (2005).
- [2] 池田欽一: “エージェント理論とオンラインオークション,” オペレーションズ・リサーチ, Vol. 51, No. 12, pp. 740-745 (2006).
- [3] 桑田修平, 上田修功, 山田武士: “ノンパラメトリックベイズモデルによるグラフクラスタリング,” 電子情報通信学会技術研究報告 (PRMU 2007-41), Vol. 107, No. 115, pp. 81-86 (2007).
- [4] Linden, G., Smith, B. and York, J.: “Amazon. com recommendations: item-to-item collaborative filtering,” *IEEE Internet Computing*, Vol. 7, pp. 76-80 (2003).
- [5] 松嶋敏泰: “帰納・演繹推論と予測—決定理論による学習モデル—,” 1998年情報論的学習理論ワークショップ (IBIS '98), pp. 1-8 (1998).
- [6] Paarsch, H. J.: “Deriving an Estimate of the Optimal Reserve Price: An Application to British Columbian Timber Sales,” *Journal of Econometrics*, Vol. 78, No. 2, pp. 333-357 (1997).
- [7] Paarsch, H. J. and Hong, H.: *An Introduction to the Structural Econometrics of Auction Data*, MIT Press (2006).
- [8] Rasmussen, C. E.: “The Infinite Gaussian Mixture Model,” *Proceedings of 12th Conference on Neural Information Processing Systems (NIPS)*, pp. 554-560 (1999).
- [9] 上田修功, 山田武士: “ノンパラメトリックベイズモデル,” 応用数理, Vol. 17, No. 3, pp. 2-20 (2007).
- [10] 渡邊泰典: “ネットオークションにおける評価額分布の構造型実証分析による推定,” MMRC (東京大学 COE ものづくり経営研究センター) Discussion Paper, No. 168 (2007).
- [11] 横尾真: 「オークション理論の基礎」, 東京電機大学出版会 (2006).