

中古車査定価格支援システムにおける機械学習モデル改善の取り組み Improving Machine Learning Models in Used Car Appraisal Price Support System

段 裕之¹⁾ 林 雄太郎¹⁾ 西山 佑典¹⁾ Le Binh Thanh¹⁾
Hiroyuki Dan Yutaro Hayashi Yusuke Nishiyama Le Binh Thanh
松下 旦²⁾ 岩崎 敦³⁾
Akira Matsushita Atsushi Iwasaki

1 はじめに

本稿では、中古車価格の査定に機械学習を用いた査定価格の予測を改善する取り組みを述べる。(株)オークネットは BtoB の中古車売買支援サービスを手掛けており、顧客から持ち込まれた中古車の価格を査定する必要がある。従来、査定担当者が車の状態や相場を確認しつつ、手動で価格を査定していた(具体的には査定価格の幅を伝えている)。これに対して、担当者の負担を軽減するため、2020 年より車の状態および直近の取引価格を入力とし、担当者に価格幅を提案するシステムを開発した。担当者は提示された価格幅を確認し、必要があれば調整したうえで、顧客に提供する。これにより、担当者ごとの査定のばらつきを抑えつつ、査定依頼から価格幅の提示までにかかる時間を短縮することに成功した。その背後では、自社で運営している中古車オークションでの入札データから、機械学習(LightGBM)を用いて査定価格を算出するシステムが運用されており、これによって査定の正確性向上や担当者の業務量削減が図られている[1]。

しかしながら、中古車の価格は季節要因や新車の生産状況などによって大きく変動することが知られており、これまでの価格予測システムはそういった時系列にもとづく市場環境の変化への対応が十分でなかった。そこで本研究では、時系列から発生する要因を検討し、データの分割方法や特徴量への重み付けや選択、更新頻度などを調整し、予測精度を改善することを目指す。その結果、実際の成約価格と予測価格との平均二乗誤差を約 3%の改善に成功した。とくに、価格の変動が大きかった 2023 年 3 月のデータでは約 8%もの改善を達成した。

2 中古車価格査定サービス

本節では、オークネットにおける中古車査定サービス及び、機械学習による中古車価格査定支援モデルについて説明する。

まずは、中古車査定サービスについて説明する。中古車販売店は通常、商品となる中古車を、一般顧客や事業者からの依頼を受けて査定する。その後、自社で買い取って販売するか、他の事業者へオークションを通じて販売する。一般顧客から下取りを行う際に、どのような価格で買い取るべきかを判定する際には、査定担当者が市場価格の動向や車の状態をもとに、オークションでどれくらいの価格で売れるかを予想した上で、損をしないレベルで査定価格を決定してきた。ただし、中古車販売

店によっては、自社が詳しくない車種であったり、買い取り価格を正確に判定できない事業者も存在する。そのため、オークネットはそのような事業者向けに、「中古車価格査定サービス」を提供してきた[2, 3]。中古車価格査定サービスではオークネット内の車両と相場価格に熟知したメンバーが、販売店が送ってきた車両の写真・車両状態の情報をもとに、査定価格を返信することで、査定担当者がいない中古車販売店への下取りの仕組みの代行や、その後のオークションへの出品に至るサービスの提供を行ってきた。このような査定価格の決定は、とても属人性の強い業務であり、オークネット内の査定担当者もサービスを運用するのに苦労していた。年間数万件を超える価格査定依頼を全て人力で処理するのは負担がかかっていた。これに対して、機械学習を用いた価格予測を導入した「中古車査定価格決定支援モデル」システムを構築し、属人化の解消と業務効率化を目指した。

「中古車査定価格決定支援モデル」では、車両に関する情報をリクエストすることで、その車両の価格を推定する。オークネットで流通した大量の車両情報から、機械学習をしてどのような車両がどのような価格になるのかというモデルを作成した。オークネットの査定担当者はこのモデルの価格を参考価格とすることで、ある程度の価格を自動で算出し、一部定性情報を加味した上で顧客に対して価格を返信する。具体的な定性情報としては、ペットやタバコの匂いの有無など、査定時においてメモ欄に書いてある情報などが含まれる。機械学習モデルに対してこれらの定性的な情報をパラメータに変更して投入するのは難しく、機械学習で算出したデータを人間の手で修正した上で価格を返信している。オークネットでは 2020 年にこのシステムを実装し、2023 年現在まで運用し続けることで、査定業務の属人化解消と業務効率化に成功した。具体的には、査定グループが定義する予測価格の精度や依頼処理時間といった KPI を改善することに成功した。ここで、予測価格幅の精度をオークションで成約した価格と提案システムによる査定価格幅との差として定義し、依頼処理時間を顧客から査定依頼を受けて担当者が作業を始めてから最初の査定価格を返信するまでの時間として定義する。本研究では、予測価格の精度をさらに改善することを目的として、価格査定支援モデルを再構築する。

3 価格査定精度改善の背景

本節では、3 年間の運用を経て顕在化した、価格予測システムの課題について概説する。

価格予測システムの導入がもたらした利点として、以前は担当者の経験と勘に頼っていた価格査定を、機械学

1) 株式会社オークネット
2) 東京大学
3) 電気通信大学




図1 2022年～2023年の中古車落札相場動向




図2 レクサス RX300の短期的な相場下落動向

習モデルを用いることで定量的に判断できるようになったこと、機械学習モデル（人工知能）が、実際の人間の代わりに価格を決めていることを伝えることで、顧客の信頼度が増加したこと、そして予測した査定価格を社内向けの業務だけでなく、一部の顧客には直接伝えるサービスもできるようになったことがある。

これにより、そのモデルが出す価格精度が低くなると、顧客側へのサービスの品質に対しても影響してしまうという状態まで、価格査定システムへの依存が発生していた。そのため精度の向上および、安定的に精度を提供できるように機械学習モデルを改善するためのプロジェクトが組まれた。精度改善のために考えるべき内容として特に重要視したのは、価格変動に対して追従するという点である。具体的には、以下のような変動に対して追従することが求められた。

3.1 長期的価格変動に対する追従

中古車価格は一つの大きな市場となるため、株式市場と同じように常に長期的な波の中で変動している。変動要因としては、為替の影響や半導体不足による中古車需要の増加など様々な要因が複合的に絡みあっており、直接的要因を特定したり、変動予測を行うのは難しい領域である。図1では、オークネットが保有する中古車落札データをもとにした、2022年～2023年の相場動向である。コロナ後、半導体不足の影響などもあり、中古車需要の向上、落札価格も上昇傾向にあったが、2022年後半から中古車相場が冷え込み、価格が下落していることが分かる。

3.2 短期的価格変動に対しての追従

景気のように長期的な変動の波がある一方で、個別株のように一部の車種が特定の要因により相場価格が大きく変動する要因も存在する。分かりやすい例では、新型式が発売されることにより、旧型式の価格において大きな値崩れが起こるなどの事例がある。図2では、レクサス RX300 における平均落札価格を示している。レクサス RX は 2022 年 11 月に新型式が出たために、旧型式である RX300 において値崩れが発生したことが明確に見える。

また、中古車市場においてはレギュレーション・法改正の変更が価格需要に大きく影響を与えるシーンも見ら

れる。すなわち、国の法改正により車ごとの関税比率の変更が起き、輸入車の需要が大きく変わり、値段が大きく変動する場合もある。近年では輸出業者の買い控えがおき、価格が下落傾向にあると言われている。

これまでは、これらの急な価格変動の対応に対してモデルが追いつくことができず、人間の手でチェックし価格修正を行った上で査定価格の返信を行っていた。しかし、中古車査定業務において本システムが求められる領域が大きくなり、更なるモデル改善の要求が高まったことや、機械学習で算出した価格をそのまま顧客へと返信するサービスが生まれ、人間の修正なしで機械学習モデルが出力した値を返信するような事例が現れた。そのため、モデル改善の取り組みを開始する契機となった。

4 検証データの概観

本節では、今回の予測精度改善で使用したデータについて概観する。

4.1 データに関する基本情報

本研究では、オークネットが保有する BtoB の中古車オークション市場での落札データの内、取引量の多い 16 メーカーのデータを使用した。期間は 2022 年 1 月 5 日から 2023 年 5 月 15 日までで、この間に約 220 万件の中古車が取引されている。

データには目的変数であるオークション落札価格に加えて車両に関する定性的な 19 の特徴量が存在し、メーカー、車種、走行距離、経過年数、色、車両のグレード（傷の有無などで決まる）などが含まれている。

4.2 現状のモデル追従傾向

まずは、図3において、オークションの落札価格の変動に対して、モデルの算出価格が追従できているかを確認する。横軸に価格予測をした年月、縦軸に価格をプロットし、オレンジ色の落札価格の下落に対して、青色の予測価格が追従する傾向があるように見て取れる。しかし、これは全車種においての価格を平均化しているものであり、個別の車種や車体の誤差動向を見ると、20%以上の誤差が発生する事例も発生していた。

次に、代表的な車種についての価格変動について確認する。図4についてはトヨタアクアの価格変動に対して、モデル予測価格の変動をプロットしている。オレン




図3 落札平均価格の変動とモデル価格の追従




図4 トヨタアクアの落札価格変動に対するモデル予測価格の追従

ジ色の落札価格下落に対して、青色の予測価格が追従している様子が見取れるが、価格の下落や変動に対して、1ヶ月程度予測価格が合致するタイミングが遅れている。

図5についてはトヨタアルファードの価格変動に対して、モデル予測価格の変動をプロットしている。同じく価格変動が追従していることが見て取れるが、車体価格がアクアと比較して高く、価格差異についても大きく出ていることが分かる。査定価格は、実際に中古車販売店が下取りし、顧客から買い取る価格になるため、車両の価格が高いほど、差異が出た際の販売店への影響も大きくなる。特に高価格帯の車両に対して価格を追従していくことが、強く求められる。

5 改善手法

本節では、本研究で取り入れた価格査定精度の改善手法を概観する。今回は、以下の項目を実施した。

5.1 時系列を考慮したデータの分割

現在の落札価格予測モデルは1ヶ月に1度、直近6ヶ月のオークションデータを用いて、翌月用のモデルをDatabricks AutoML [4]により自動作成している（例えば、2022年6月から11月までのデータを用いて、12月に運用するモデルを作成している）。より具体的には、6ヶ月間のデータをランダムに6:2:2の割合で訓練デー




図5 トヨタアルファードの落札価格変動に対するモデル予測価格の追従




図6 AutoML のテストデータと翌月データで評価の予測精度比較

タ・検証データ・テストデータに分割し、訓練データでモデル（LightGBM [5]）を作成、検証データでの平均二乗誤差（RMSE）を小さくするようにハイパーパラメータを調整し、最終的なモデルの予測精度をテストデータで評価していた。

しかし訓練・検証・テストデータの分割を時系列に関係なく行うことにはいくつかの問題がある。まず、学習時は3つのデータセット全てに同じ期間の落札データが含まれているのに対し、実運用上は過去のデータを使って作成したモデルで未来の落札価格を予測することになるため、前者では発生し得ない予期せぬ需給の変動のモデルが後者では発生し、結果的にモデルの精度を過大評価していた。実際図6のように、AutoMLが算出したテストデータ（6ヶ月間の全データの内、ランダムに選んだ20%）で評価した予測精度と、そのモデルを翌月のデータ全体で評価した予測精度を比較すると、期間平均で5,038となり、後者の方が精度が悪かった。

また検証データによるハイパーパラメータの調整も、データの時系列性を無視して行っていたため、必ずしも未来の予測が最適に行えるように選択されているとは言えなかった。

こういった問題に対処するため、図7で表されるように時系列性を考慮したデータ分割を行った。1組のデータセットは7ヶ月分のデータで構成され、最初の5ヶ月分を学習に使用するデータ、次の1ヶ月分をハイパーパ

	2022/01	2022/02	2022/03	2022/04	2022/05	2022/06	2022/07	2022/08	2022/09
No1	訓練					検証	テスト		
No2		訓練					検証	テスト	
No3			訓練					検証	テスト
⋮									

図 7 時系列性を考慮したデータ分割

ラメータの調整に用いる検証データ、最後の 1 ヶ月分のデータを予測精度を測定するテストデータとした。結果として、2022 年 1 月から 2023 年 5 月までのデータで 11 通りのデータセットを作成し、各々でモデルを訓練し予測精度を評価した。

5.2 データの重み付けの調整

LightGBM の学習時にデータに時期に応じた weight を設定できるように改良した。これにより中古車の急激な需要・供給の変動に対応して、直近の時期のデータをより重視したモデルの学習が可能になった。なお weight は他のハイパーパラメータと同様、検証データでの予測精度が良くなるように調整を行った。

5.3 モデル更新頻度の増加

Weight の調整と同様、市場環境の変化に対応するため、モデルの更新頻度を従来の 1 ヶ月単位から半月単位に増やし、テストデータの期間を半分にしたモデルを検証した。なお学習・検証データの期間は従来のモデルと同様である。例えば 2022 年 6 月 16 日～12 月 15 日のデータを学習に用いて 12 月下半期用のモデルを作成し、12 月 16 日～31 日のデータをテストデータとして用いて RMSE を計算した。これにより価格の追従性が高まるかどうかを検証した。

6 結果

本節では、モデルの精度向上の取り組みを行った結果について記載する。

6.1 評価指標について

モデルの改善に伴い目指す指標としては、予測価格とオークション成約価格の平均二乗誤差 (Root Mean Squared Error, RMSE) を最小化するパラメータを目指した。

なお RMSE は、データ内の車の集合を I 、その数を N 、車 $i \in I$ の予測価格を f_i 、実際の価格を p_i として、

$$\text{RMSE} \equiv \sqrt{\frac{1}{N} \sum_{i \in I} (f_i - p_i)^2} \quad (1)$$

と定義される [6]。

加えて、予測価格とオークション成約価格の平均絶対

表 1 更新頻度を倍にしたモデルの予測精度

	従来のモデル	更新頻度を倍にしたモデル
RMSE	191263.65	184160.74
MAE	107185.29	101511.92

誤差 (Mean Absolute Error, MAE)

$$\text{MAE} \equiv \frac{1}{N} \sum_{i \in I} |f_i - p_i| \quad (2)$$

も指標として利用した。

6.2 ベースラインモデルにおける評価

5 節で示した改善手法の結果と比較するため、従来の AutoML により構築されたモデルをベースラインモデルとして構築した結果を示す。より具体的には、6 ヶ月間のデータをランダムに 6:2:2 の割合で訓練データ・検証データ・テストデータに分割し、訓練データでモデル (LightGBM を使用) を作成、検証データでの平均二乗誤差 (RMSE) を小さくするようにハイパーパラメータを調整してモデルを構築した。その後、学習期間の最終月の翌月をテストデータとして使用し、モデルの予測精度を評価した。期間を分け 11 のベースラインモデルを構築し、各モデルのテストデータにおける RMSE の平均値は 185431.12 であった。

6.3 データの重み付けの調整結果

まずは、データの重み付けの調整結果について示す。取引が行われた月の数値を利用し、その月に行われた取引に対して設定すべき最適な重みについて、ハイパーパラメータと同時に探索した。具体的には、ハイパーパラメータの探索に使用するライブラリ Optuna [7] を使用し、データセットを時系列で分割した際に作成した検証データで測定した RMSE を最小化するような設定を探索した。

こちらは、明確に改善の結果は得られなかった。これは、databricks が AutoML を使用しモデルを構築する際にも内部的に最適なパラメータの探索を行っているほか、投入したデータセットの特徴量によっては Hash 化などの前処理を行っており、その結果、今回 Optuna で行った重みの探索をした結果よりも優れていたことが理由であると思われる。

6.4 モデル更新頻度の増加結果

次に、モデル更新頻度の増加を行った結果を示す。

表 1 に検証した結果を示す。モデルの更新頻度を上げた結果、RMSE の値を 191263.65 から 184160.74 へと下げることに成功した。モデルの更新頻度を上げることはモデル学習を多く行うことになるため、計算資源の稼働コストを上げてしまうというデメリットもあるが、月に 2 回の更新であれば、コストに見合うリターンが得られると判断している。

また図 8 および 9 に、各テストデータごとの RMSE および平均予測価格の推移を示す。更新頻度を倍にしたモデルの方が、大半のテストデータで RMSE が小さく、また実際の平均落札価格に近い予測価格を出していることが見てとれる。

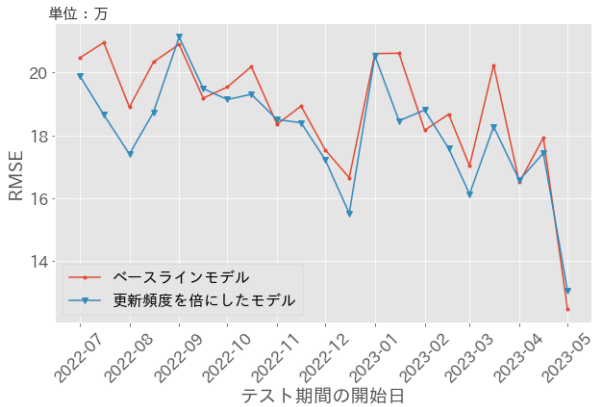


図8 更新頻度の調整による平均二乗誤差の改善




図9 更新頻度の調整による価格への追従性の改善

7 おわりに

本稿では、株式会社オークネットにおける中古車査定価格支援システムにおける査定価格精度の課題を述べた上で、その価格精度改善の取り組みについて紹介した。価格査定精度向上は終わりのない取り組みであり、精度には改善の余地はあるものの、当面の目標である価格の変動に対して柔軟に対応するモデルを構築することができた。

今回は、価格査定精度の改善について、データの分割・重み付けの調整・モデル更新頻度の増加・特徴量の

追加という観点から改善を行った。しかし、あくまでも機械学習モデル上における調整であり、特に特徴量の追加などデータの前処理については、まだまだ精度向上のポテンシャルがあると考えている。例えば、非定量データの特徴量を追加することにはまだまだ精度向上の余地がある。車両のカスタマイズの情報(カーナビのグレード等)は、価格査定に一定の影響が発生するが、構造化データとして取り込みすることができておらず、「メモ欄」などで補記されるにとどまっている。これらのデータをどのような形でカテゴリ化して、機械学習で学習できる形に取り込めるかが今後の改善方針となる。

中古車の価格査定については引き続き精度向上に向けて、定期的な観測と取り組みを続けていきたい。

さらに、株式会社オークネットは、中古車だけでなく、バイクや花卉、電子機器やブランド品といった多様な商材を扱う市場を運営し、その情報を大量のデータとして蓄積している。中古車以外の事業においては本研究のような機械学習の適用はまだまだ十分ではなく、今後さらに研究領域を広げ、データ活用を推進する予定である。

参考文献

- [1] 段裕之, 林雄太郎, 松下旦, 岩崎敦. 中古自動車の査定価格決定支援システムの実装, 2023. 2023年度人工知能学会全国大会(第37回).
- [2] オークネット. 中古車事業者向け査定サービスをフルリニューアル「サテロクプレミアム」を8月1日より本格提供開始, 2018. https://www.aucnet.co.jp/nw/20180801_01/.
- [3] オークネット. サテロクプレミアム, 2023. <https://www.aucnet-nyukai.com/sateroku>.
- [4] データブリックス. データブリックス AutoML, 2023. <https://www.databricks.com/jp/product/automl>.
- [5] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. Lightgbm: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, Vol. 30, , 2017.
- [6] 倉田博史, 星野崇宏. 入門統計解析. 新世社, 2009.
- [7] Preferred Networks, Inc. Optuna – a hyperparameter optimization framework, 2023. <https://optuna.org/>.