

車種グループ情報を用いた中古車価格予測に関する研究 Study on prediction of used car prices using car-type group information

林 雄太郎¹⁾ 足立 幸大³⁾ 松下 旦²⁾ 岩崎 敦³⁾
Yutaro Hayashi Kodai Adachi Akira Matsushita Atsushi Iwasaki

1 はじめに

本稿では、中古車価格を予測する機械学習モデルを、車種のグループに関する情報を用いて性能改善する研究について述べる。(株)オークネットは、事業のひとつとして BtoB のオンライン中古車売買支援サービスを手掛けており、業務のひとつに、顧客から販売店に持ち込まれた中古車の価格査定を代行するものがある。従来は当社の査定担当者が、車両の状態や直近の相場を確認しつつすべて手動で査定を行っていたが、担当者の負担減や査定時間の短縮を目的として、2020年に機械学習モデルを活用した「中古自動車の査定価格決定支援システム」を開発し、実運用を開始した。このシステムは、説明変数の追加、最適な更新頻度の探索や区間推定の研究など、さまざまな改修を経て今日に至る [1]。

予測対象になる車両は、さまざまなメーカー、サイズ、価格帯など、条件の異なるものが多数存在する。現在はそれら条件の異なるデータをひとつにまとめたデータセットで構築した、単一の機械学習モデルを運用しているが、より予測精度を高め、業務運営に適したモデルの開発が社内で望まれている。その解決方法のひとつとして、当社が対外的に毎月公表している、車種グループ（ボディタイプ）の分類ルールや車種グループ別の「中古車市場価格指数」 [2] を、機械学習モデルの構築過程で用いることを考案した。

検証の結果、車種グループを用いてデータを分割し、特化型のモデルを複数構築することで、多くの車種グループにて予測性能が向上したことを確認した。一部の課題はありつつも、より合理的な予測を行う機械学習モデルを構築する有効な手法のひとつとして有望である。

2 中古車価格査定サービスの現状

本節では、オークネットにおける「中古自動車価格査定サービス」および、機械学習モデルを用いた「中古自動車の査定価格決定支援システム」について説明する。

まずは、「中古自動車価格査定サービス」について説明する。街中にあるような中古自動車販売店は通常、商品となる中古自動車について、一般顧客や事業者からの依頼を受けて価格査定を行う。その後、自社で買い取って販売するか、オークションを通じて他の事業者へ販売する。中古自動車販売店の担当者は一般顧客から下取りを行う際、市場価格の動向や車の状態をもとに、その車両が将来オークションで出品された場合、どれくらいの価格で落札されるかを予想した上で、損をしない程度に査定価格を決定してきた。ただ、中古自動車販売店のなかには、買取価格を合理的に判定できる査定担当者がい

ないといった場面も存在する。オークネットはそのような事業者向けに、中古自動車価格査定サービスを提供してきた。中古自動車価格査定サービスでは、車両情報と相場価格に熟知したオークネット社員が、販売店から送られてきた車両の写真・車両状態の情報をもとに査定し価格を返信することに加え、査定担当者がいない中古自動車販売店への下取り代行や、その後のオークションへの出品に至るまでのサービスの提供を行ってきた。このような価格査定業務は属人性が強いほか、年間数万件を超える査定依頼を全て人力で処理するのはオークネットの査定担当者にも負担がかかっており、当サービスの運用継続に課題があった。これに対して、機械学習モデルを用いた「中古自動車の査定価格決定支援システム」を構築、運用し、属人化の解消と業務効率化を図った。

オークネットでは2020年にこのシステムを実装し、2025年現在まで運用し続けることで、価格予測の精度向上や査定依頼処理時間の短縮といった KPI を改善することに成功した。ここでは、価格予測の精度を「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、査定依頼処理時間を「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。機械学習モデルの予測性能が低くなると、顧客へのサービスの品質へも影響してしまうということから、より合理的に予測できるよう、機械学習モデルの性能を改善するための試みを続けている。現在は、使用可能なすべての車両データをひとつにしたデータセットを作成し、単一の機械学習モデルを構築、運用している。

しかし、排気量や新車販売時の価格帯など、異なる特性を持つ車両のデータを混在させている現状に課題を感じ、これら車両ごとの属性を考慮したデータセットの設計やモデリングが必要なのではないかと考えた。また、当社は日本市場での中古車価格が実際にどのくらい上下しているのかを客観的に把握、共有することを目的とし

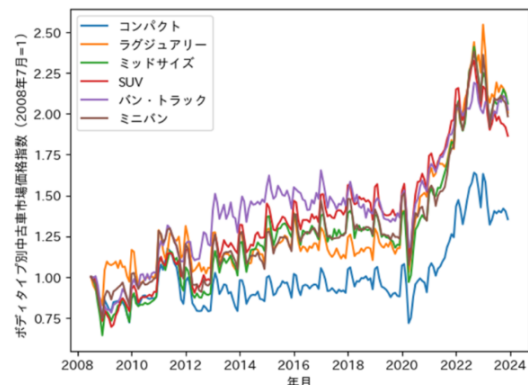


図1 車種グループごとの中古車市場価格指数

- 1) 株式会社オークネット
- 2) 京都大学
- 3) 電気通信大学

表1 車種グループ情報とデータセット内に占める割合

車種グループ	平均割合 (%)
コンパクト	25.63
ミッドサイズ	20.13
ラグジュアリー	3.80
SUV	14.14
ミニバン	28.81
バン・トラック	7.48

図1のように、車種グループ別での「中古車市場価格指数」を毎月発表している。

そこで本研究では、中古車市場価格指数での計算の一環で用いる車種の分類（以下、車種グループ情報）や、車種グループごとの月別の中古車市場価格指数を、説明変数やモデル構築過程に組み込むことで、現在運用している機械学習モデルの性能改善を図ることができないか、調査した。

3 検証データの概観および車種グループ情報の導入

本節ではまず、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。本研究では、当社が保有する「中古車オークション市場での取引データ」の内、トヨタ、ホンダなど16の国内外メーカーを対象としたデータを使用した。中古車オークション市場での取引データとは、メーカー、車種、走行距離、年式、外装色、グレードなど車両に関する情報や、「オークションにて出品された際の落札価格」で構成される。機械学習を行う際は、前者を説明変数として、後者を目的変数として利用した。

次に、従来のモデルにどのように車種グループ情報を導入するかを概観する。車種グループは、車両の種別判定を行うことを目的とした当社規定のコードごとに分類ができるよう、排気量や新車価格など車両の属性ごとに設定した。車種グループの分類ルールとなる、属性ごとの閾値は、業界標準の規格（例：排気量が660cc以下の車両は「軽自動車」）などを参考に決定し、最終的に表1のように6つのグループを規定する。表には、データセット全体で占める平均割合を記載した。これを見ると、コンパクト（25.63%）、ミッドサイズ（20.13%）、ミニバン（28.81%）がそれぞれ全体の20%を超えており、データ分割後も相当量のデータを学習に用いることができるといえる。その一方で、バン・トラック（7.48%）やラグジュアリー（3.80%）のように、全体に占める割合が低く、データを分割すると学習に用いることが可能なデータの量が激減する車種グループも存在する。

4 車種グループ情報を用いた価格予測

本節では、車種グループ情報を用いた価格予測の比較方法の説明や、比較結果について述べる。

4.1 比較方法

本研究では、車種グループ情報や中古車市場価格指数を説明変数として用いなかった場合、用いた場合での予測性能の比較が主題となる。車種グループ情報を用いた

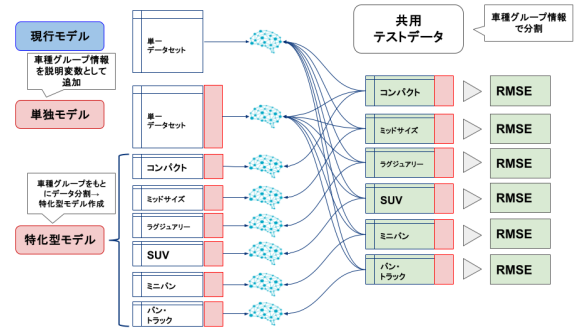


図2 モデルごとの構築、評価、比較イメージ

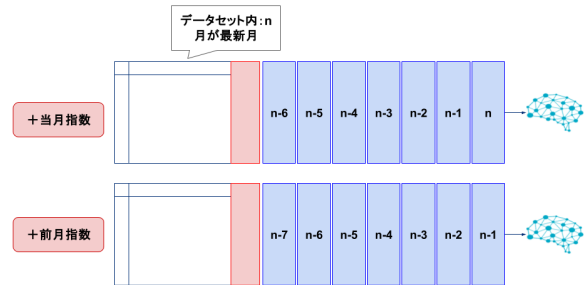


図3 中古車市場価格指数の説明変数追加イメージ

モデルは、説明変数として追加するがデータセットは単一のままである場合（以下、単独モデル）と、車種グループ情報をもとにデータ・モデルを分割する場合（以下、特化型モデル）とで2種のモデルを用意する。具体的には以下の3つのモデルを評価対象とする。図2にその評価方法のイメージを示す。

1. 現行モデル：車種グループ情報を説明変数として利用せず、単一モデルを構築する場合
2. 単独モデル：車種グループ情報を説明変数として追加し、単一モデルを構築する場合
3. 特化型モデル：車種グループ情報をもとにデータセットを分割し、車種グループごとにモデルを複数構築する場合

比較の流れとして、まずこれら3つのモデルを比較し、どのモデルがもっとも性能が高くなるかを確認する。その結果、基本的には特化型モデルが高い性能を発揮したため、そのモデルを構築するデータセットに月別の中古車市場価格指数を説明変数として追加し、その効果を評価する。なお、中古車市場価格指数は、当月の指数が次月に算出されるように、データとして取得できるまでに時間差が存在する。よって、当月の指数は当月中の機械学習に用いることができない。このため、図3のように、2種のモデルを新しく構築し、比較する。

1. +当月指数：学習データ内最新日の月を最新月として、以降学習期間の月毎の指数を説明変数として追加する場合
2. +前月指数：学習データ内最新日の月の前月を最新月として、以降学習期間の月毎の指数を説明変数として追加する場合

表2 学習データ、テストデータの期間

期間	種別	開始時期	終了時期
期間①	学習データ	24年7月後半	25年1月後半
	テストデータ	25年2月前半	25年2月前半
期間②	学習データ	24年8月前半	25年2月前半
	テストデータ	25年2月後半	25年2月後半
期間③	学習データ	24年8月後半	25年2月後半
	テストデータ	25年3月前半	25年3月前半

4.2 学習データ・テストデータの用意

本研究では、複数の期間で評価を行う目的から、利用するデータは表2のように2024年7月前半～2025年3月前半の期間を、学習データ/テストデータごとに3種類の期間に分割し用意した。学習データは、6か月間の取引データとする。テストデータには、現在は月に2回、最新の取引データを用いてモデルを更新する運用を敷いていることから、学習データの最新日の翌日から半月間の取引データを用いる。学習期間と比較して将来の取引データを使って評価することで、データリークを回避しつつ、将来のデータへの汎化性能を評価する。

4.3 機械学習モデルの構築

機械学習モデルの構築には、Databricks AutoMLにてハイパーパラメータを探索したあと、すべてのデータで再学習を行う手法を、すべての試行において利用した。今回はインプットとなるデータセットへの変更による予測性能の変化を比較することが目的であるため、モデルの構築方法は共通のものとする。

4.4 評価指標

本研究では、機械学習モデルが出力した予測値と正解値（オークション落札価格）を用いて評価を行う際に、「RMSE」を用いた。RMSEは、テストデータ内の車両の集合を I 、その数を N 、車両 $i \in I$ の予測値を f_i 、正解値を p_i として、以下に定義する：

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

RMSEとは予測値と正解値との誤差を利用した評価指標であるため、その値が小さいほど機械学習モデルがうまく予測していると言える。

4.5 比較結果

上記設定においてモデルを構築し、比較した結果を述べる。まず、表3に記載した現行モデル、単独モデル、特化型モデルの比較結果から見ていく。グレー背景にしているセルは、同一の車種グループ、期間の中で最も低いRMSE、つまり最も予測性能が高いモデルを指す。「コンパクト」グループでは、期間①での結果を見ると現行モデルの出力値で計算したRMSEが80125.83、単独モデルが79481.51、特化型モデルが**74892.25**と、車種グループ情報を説明変数に追加した場合、車種グループ情報をもとにデータ・モデルを分割した場合と順に性能改善していることが分かった。期間②での評価が、現行モデルの出力値で計算したRMSEが81435.13、単

表3 車種グループ、モデル種別、期間、ごとのRMSE比較結果

車種	モデル種別	期間①	期間②	期間③
コンパクト	現行モデル	80125.83	81435.13	76275.59
	単独モデル	79481.51	80859.93	73569.39
	特化型モデル	74892.25	75670.59	72072.43
ミッドサイズ	現行モデル	98267.14	102551.74	103221.06
	単独モデル	96296.53	101262.72	98836.38
	特化型モデル	96519.47	99794.10	101137.22
ラグジュアリー	現行モデル	139389.43	143394.50	157001.91
	単独モデル	135235.54	140106.44	153059.86
	特化型モデル	142185.12	145957.28	167481.71
SUV	現行モデル	163427.61	177367.79	159729.39
	単独モデル	162504.88	178084.40	153931.39
	特化型モデル	159737.32	171530.67	149188.52
ミニバン	現行モデル	126452.43	118717.98	119168.36
	単独モデル	121649.62	116628.14	114614.04
	特化型モデル	131402.96	116444.11	114169.21
バン・トラック	現行モデル	97503.46	93702.33	96940.67
	単独モデル	95190.78	93241.27	91489.42
	特化型モデル	92270.06	87467.84	90442.50

独モデルが80859.93、特化型モデルが**75670.59**との通り、その他期間でも車種グループごとにデータ・モデルを分割した手法が最も性能が高いという同様の結果となった。このような結果は、「SUV」「バン・トラック」グループでも同様に見られた。

「ミッドサイズ」「ミニバン」グループでは、データ期間により違いはあるが、単独モデル、特化型モデルのいずれかがその出力値で現行モデルより低いRMSEを計算するように、車種グループ情報の利用による現行モデルからの性能改善を共通して確認できた。

一方で、「ラグジュアリー」グループでの比較結果は、他の車種グループでの結果とは異なる。期間①では現行モデルの出力値で計算したRMSEが139389.43、単独モデルが**135235.54**、特化型モデルが142185.12と、車種グループ情報を説明変数に追加し、データを分割せず単独モデルとして構築した場合が最も良い性能となった。その他の期間でも共通の結果となっており、データを分割せず単独モデルを用いたほうが予測性能が高い傾向にある車種グループも存在することが分かった。

ここまでの結果から、多くの車種グループにおいては、特化型モデルのようにデータを車種グループ情報で分割し、各車種グループ特化型の機械学習モデルを構築することが、予測性能が改善する傾向にあることが分かった。そこで次に、特化型モデルをベースに、中古車市場価格指数を付与した「特化型+当月指数」、「特化型+前月指数」を別途構築し、評価した結果を述べる。比較結果は、表4に記載した。

「コンパクト」グループにおいて、期間①では特化型モデルでのRMSEが**74892.25**、特化型+当月指数が76124.84、特化型+前月指数が75809.44と、中古車市場価格指数を用いないモデルが最も良い結果となった。期間②では、特化型モデルでのRMSEが75670.59、特化型+当月指数が**75271.41**、特化型+前月指数が76172.87と、中古車市場価格指数を用いたモデルが用いない場合よりも良い結果となったが、その差は399.18/75670.59(0.5%)と、わずかな差であった。以上より、特化型モデルに中古車市場価格指数を導入しても、期間にもよるが性能を大きくは改善できなかった。

表4 車種グループ、モデル種別、期間、ごとのRMSE比較結果-中古車市場価格指数を追加

車種	モデル種別	期間①	期間②	期間③
コンパクト	特化型モデル	74892.25	75670.59	72072.43
	特化型+当月指数	76124.84	75271.41	71505.92
	特化型+前月指数	75809.44	76172.87	71925.14
ミッドサイズ	特化型モデル	96519.47	99794.10	101137.22
	特化型+当月指数	96536.77	100364.36	99082.26
	特化型+前月指数	97893.94	100838.1	100039.14
ラグジュアリー	特化型モデル	142185.12	145957.28	167481.71
	特化型+当月指数	141359.46	142922.30	160183.65
	特化型+前月指数	135533.93	139389.43	166747.79
SUV	特化型モデル	159737.32	171530.67	149188.52
	特化型+当月指数	154795.05	169468.49	156103.38
	特化型+前月指数	153944.54	168577.94	152092.16
ミニバン	特化型モデル	131402.96	110644.11	114169.21
	特化型+当月指数	119094.12	110173.15	112285.91
	特化型+前月指数	119976.69	113544.47	112753.03
バン・トラック	特化型モデル	92270.06	87467.84	90442.50
	特化型+当月指数	92120.16	86798.51	89277.73
	特化型+前月指数	90684.86	89277.73	89360.56

5 考察

本節では、今回の検証内容の結果から得た考察を述べる。最初に現行モデル、単独モデル、特化型モデルの3つを比較したとき、多くの車種グループにおいて、データ・モデルを分割した特化型モデルが最も高い予測性能を発揮した。データを分割したことで、車種グループにおいて異なる属性が適切に分類され、データセットの中での分散が縮小したことで、このような結果になったものと思われる。

一方で、「ラグジュアリー」グループでは、十分に性能を改善できなかった。これは、データの分割を行ったことで学習に用いるデータ量が少なくなったためでないかと考えられる。同じようにデータ量の少ない「バン・トラック」グループでは、データ・モデルを分割する特化型モデルの性能は改善しているため、データ量の減少により予測性能影響ははっきりしなかった。そこで、図4で、2つのグループのオークション落札価格の外れ値の頻度を確認した。

その結果「ラグジュアリー」グループのオークション落札価格が、「バン・トラック」グループのそれより多くの外れ値を含むことがわかった。実際、「ラグジュアリー」グループはその名の通り高価格帯の車種グループで、オークション落札価格も高額になることが多い。これにより、全体の分布から比較した外れ値も含みやすい性質を持つ。本研究で利用した評価指標である「RMSE」は、こうした外れ値と予測値との誤差を強調して計算する性質があり、これにより「ラグジュアリー」グループではデータ・モデルを分割したことで性能が悪い結果になったものと考えられる。「バン・トラック」グループでも外れ値を含んでいるが、「ラグジュアリー」グループほどではなく、結果として両者の結果の差が顕在したものと考えられる。これまでは観測されたデータのうち、規定のデータクレンジングは行っていたが、説明変数における加工が主であった。今後は、目的変数であるオークション落札価格においても、外れ値の除去を主としたデータクレンジングが必要か否かを検討していきたい。また、このグループはそもそも一般的な説明変数では捉えきれない要因が高いと言える。例えば、ごく少数のプレミアムモデルであったり、買い手独特の嗜好といった集計が難しい要因の影響が強く出たため

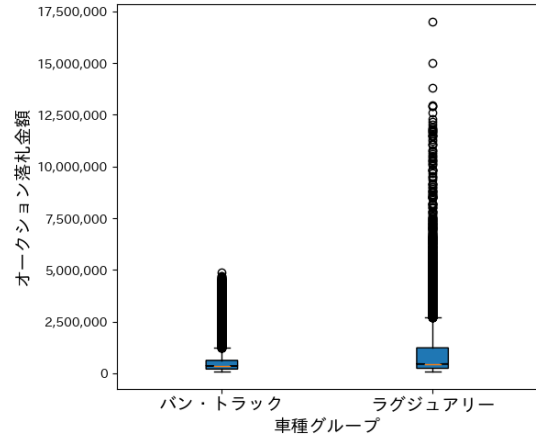


図4 バン・トラック、ラグジュアリーのオークション落札価格の分布

と考えられる。

次に、中古車市場価格指数を用いた検証について考察を述べる。前節で比較結果を確認した通り、指数の説明変数追加による効果はありつつも限定的であると考えられる。指数は、車種グループごとに計算されていることから、特化型モデルに指数を加えても、全行に同じデータを付与することになる。これによりデータの中に分岐が起きず、予測性能の向上にそれほど寄与しなかったのではないかと考える。今後は、単独モデルに指数を付与した場合で検証をし、再度その効果を確認したい。また、指数を構成するデータは当社の保有のオークションに関するデータで、すでに現行モデルの構築に用いていたデータと類似しており、新しい説明変数としての効果が薄かった可能性も考えられる。一案として、指数を構成する説明変数を除外したモデルを用いれば、指数の有効性を検証できるかもしれない。

6 おわりに

本稿では、(株)オークネットの「中古自動車の査定価格決定支援システム」で用いている機械学習モデルの課題を展開し、その改善の取り組みを、車種グループによるデータ・モデルの分割や、「中古車市場価格指数」の説明変数への活用をテーマに述べた。結果として、車種グループ情報の説明変数利用やデータ分割による複数モデル構築は現行モデルと比較して効果があった。また「ラグジュアリー」グループなど一部の車種グループに対して性能の改善は限定的であったが、このグループは外れ値を多く含んでいるなど、そもそも一般的な説明変数では捉えきれない要因が高いと言える。中古車市場価格指数の説明変数への利用は、特化型モデルに利用した結果ではそれほど効果がないことがわかった。今後は本研究の結果を、運用上の懸念点を考慮しつつ、今後の機械学習モデル開発や業務活用に活かしていく。

参考文献

- [1] 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における区間推定モデルの評価, 2024. 2024年度第情報科学技術フォーラム(第23回).
- [2] オークネット. オークネット UTEcon と「リユース流通価格指数」を開発～第1弾として「中古車市場価格指数」を発表～, 2024. <https://www.aucnet.co.jp/news/2024/20240401-1/>.