

暗黙知に基づく飲食店用不動産の賃料推定システム

Rental fee estimation system of real estate properties

for restaurants based on tacit knowledge

荒川 周造¹ 諏訪 博彦¹ 小川 祐樹² 荒川 豊¹ 安本 慶一¹ 太田敏澄
Shuzo Arakawa¹, Hirohiko Suwa¹, Yuki Ogawa², Yutaka Arakawa¹, Keiichi Yasumoto¹

¹ 奈良先端科学技術大学院大学

¹Nara Institute of Science and Technology

² 立命館大学

² Ritsumeikan University

Abstract: In this paper, we propose a novel rent estimation method of real estate properties for restaurants. Previously determining the rent was based on the tacit knowledge, that is, intuition and experience gained by experienced salespeople. However, this business custom has problems (e.g., no evidence to the determined rent). Therefore, the transference of the knowledge and experience from the experienced salespeople to fresh one, is not effective. We propose a new rent estimation model which solves the above problems, and construct a rent estimation system based on the model. In order to build a model, we focus on the overt information and potential information. The overt information can be classified as follows: static information and dynamic information. The static information and dynamic information can be indexed by the salespeople. However, some parts of the indexing include scoring data manually by the salespeople. On the other hand, potential information can not indexed by the sales people. In this thiesis, we build the rent estimation concept model based on above three factors. In addition, we discuss about the specific challenges in building the proposed system, that are (1) acquisition and indexing of the tacit knowledge and (2) construction of a rent estimation model. To tackle the challenge (1), we interviewed the experienced salespeople of ABC-tenpo Inc., and extracted some factors related to the rent estimation. Based on the result, we determined parameters (variables) representing static information, dynamic information and potential information. To tackle the challenge (2), we developed a rent estimation model by Random Forest algorithm of machine learning. Through experiments, we confirmed that the dynamic information was most effective in estimating basic rents. Also, we confirmed that the potential information was superior in adjusting rents. Finally, the case of using all factors achieved the highest accuracy that coefficient of determination was 0.738.

Keyword: Rental fee estimation, Machine learning, Data mining

1. はじめに

飲食店用不動産物件の賃料は、豊富な経験を持つベテラン営業マンが培ってきた勘や経験からなる暗黙知に基いて決定されている。一方で、経験の浅い新人営業マンにおいてもベテラン営業マンと同様に賃料決定できるようになることが望まれており、ベテラン営業マンからの暗黙知の継承が課題となっている。しかしながら、従来手法では賃料決定に根拠を示せないため、ベテラン営業マンから新人営業マ

ンへの知識伝達ができないという問題を抱えている。そこで我々は、SECI モデル[1]を基にした新たな賃料推定概念モデル[2]を提案している。SECI モデルは、知識は暗黙知を表出化して形式知にし、さらに連結化することで、概念として共有・伝承が可能となることを示したモデルである。言い換えると、ベテラン営業マンの暗黙知は、表出化して形式知にし、さらに連結化することで、共有・伝承が可能となる。賃料を決める要素としては、まず営業マンが指標化できている顕在的情報があり、これらは物件自体

が持つ静的情報、物件の状態と直接関連せず変動する動的情報に分類できる。静的情報は物件固有の情報であり、多くの不動産価格推定に関する先行研究[3][4][5]でも使用されている。また、動的情報は、物件とは独立して変化する情報である。一方で、営業マンは指標化することができないが、物件の特徴を含む潜在的情報も賃料決定に影響していると考えられる。先行研究[3][4][5]では、一般住宅物件を対象としており、静的情報が主に用いられているが、飲食店では動的情報や潜在的情報も重要であるため、3つの要素から賃料を推定する概念モデルを構築する。

概念モデルを元に、飲食店用不動産会社である株式会社 ABC 店舗と協力し、賃料推定システムの構築・検証を行う。システム構築における課題は、

- (1)暗黙知の取得及び指標化
- (2)機械学習に基づく賃料推定モデルの構築

である。

課題(1)の実現に向けて、我々は株式会社 ABC 店舗の営業マンにインタビューを行い、賃料推定に係る要素を抽出した。その結果に基づき、静的情報、動的情報、潜在的情報として用いる具体的な変数が決定された。静的情報は、ABC 店舗の HP で顧客に提供されている一般的な物件情報である。動的情報は、周辺地域の価値と物件の見つけやすさの変数である。周辺地域の価値は、エリアごとの平均賃料を用いて指標化する。また、店舗の見つけやすさの指標として、店舗前の通行量と店舗の視認性を営業マンのスコアリングデータを活用する。しかしながら、スコアリングによる指標化作業には個人による差異が生じることから、根拠あるシステムを構築するには望ましいとは言えない。そこで本研究では、通行量を機械的に取得可能な通行量センシングシステム[6]を独自に開発し、実験を通じてその有用性について検証している。さらに、潜在的情報は、物件の営業用キャッチコピーをベースに、自然言語処理技術を用いて指標化する。本稿では、これまで抽出してきた名詞に加え、形容詞についても指標化する。

課題(2)を実現するために、賃料推定モデルをランダムフォレスト[7]を用いて構築した。3つの要素が賃料推定に与える影響を比較した結果、動的情報は基本価格の推定に優れ、潜在的情報は価格調整に優れていることが確認された。また、すべての要素を使用した場合の決定係数は 0.738 となり、最も精度が良くなることを確認した。

以下に本稿の構成について述べる。第 2 章では賃料推定概念モデルについて説明する。第 3 章では、各要素の取得・指標化手法について述べる。第 4 章では機械学習に基づく賃料推定システムについて述べる。第 5 章は考察として、第 6 章はまとめとする。

2. 賃料推定概念モデルの構築

ベテラン営業マンの勘や経験による暗黙知を基にした賃料決定手法では、同じ物件であるにもかかわらず、その賃料は営業マンにより異なる。また、こうした知識の新人営業マンへの伝承は、OJT や共同作業といった非効率な作業によって行われている。暗黙知の伝承をより正しく効率的に行うためには、新人営業マンが賃料決定ルールを概念として取得し、自ら学習できるシステムがあると望ましい。そのために飲食店を対象とした概念モデルが必要となる。

このような暗黙知を伝承するための知識創造モデルとして、野中らの提案している SECI モデルがある。SECI モデルを図 1 の(1)~(4)に示す。野中らによれば、知識創造は、(1)共同化 (暗黙知→暗黙知)→(2)表出化 (暗黙知→形式知)→(3)連結化 (形式知→形式知)→(4)内面化 (形式知→暗黙知)→(1)共同化といったサイクルを繰り返すことによって可能となる。ここで、暗黙知は言語化できない知識を意味し、形式知は言語化できる知識を意味する。SECI モデルでは、知識は暗黙知を表出化して形式知にし、さらに連結化することで、概念として共有・伝承が可能となることを示している。言い換えると、ベテラン営業マンの暗黙知は、表出化して形式知にし、さらに連結化することで、共有・伝承が可能となる。

そこで、本研究ではこの SECI モデルに基づいて、図 1 に示すような賃料推定概念モデルを構築する。まず、ベテラン営業マンの暗黙知が形式知として表出(化)される。そのために、ベテラン営業マンに対するインタビュー調査を実施している。このときベテラン営業マンからは、賃料推定に影響を与える要素が回答され、指標として取得可能な情報を顕在的情報とする。顕在的情報はそれぞれの変数の性質に基づいて整理すると、物件固有の静的情報、物件に直接関連せずに変動する動的情報の 2 種類に分類できる。これらは、営業マン自身が言葉にできているゆえ形式知であるといえるが、それらの指標化に

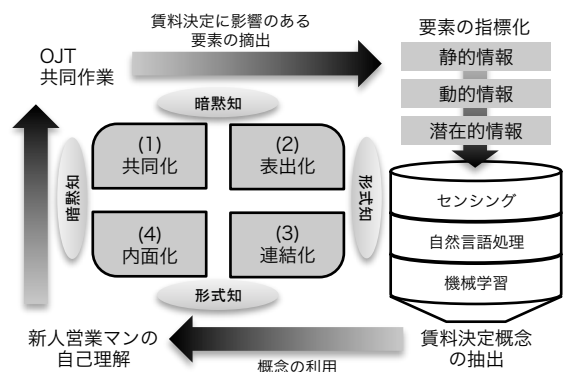


図 1 賃料推定概念モデル

あたり営業マンの主観によるスコアリングを活用しており、一部に個人による差異が生じる。この問題は、センシング技術を活用し、その特定の変数を機械的に取得することで解決する。また、営業マンが回答できなかったものの賃料決定に影響があると考えられる要素として、潜在的情報がある。潜在的情報は、指標化がなされていないため、顕在的情報のように静的情報と動的情報に分類する判断もできない要素である。この要素については、物件に関して記述されているテキストデータに内包されていると考え、自然言語処理技術を活用し指標化する。

次に、機械学習を用いて、指標化された要素と賃料との関係を連結（化）する。機械学習の結果として、賃料推定概念が抽出され、従来の問題は解決される。ここで、暗黙知が形式知として抽出されることは、営業マンはそれらを共有することができることを意味する。また、概念が抽出されることは、新人営業マンへの伝承を可能であることを示している。

3. 要素の取得・指標化

ベテラン営業マンの暗黙知を表出化させるために実施したインタビューによって、顕在的情報として具体的な変数が回答された。本章では、それらの変数の取得・指標化について説明する。

まず、静的情報として、居抜きの有無、駅徒歩時間、階数、坪数が挙げられる。居抜きとは、物件に付帯する什器（テーブル、カウンター、ガスレンジ等の設備）を意味し、その有無を0・1のフラグとして表現する。これらの変数は、株式会社 ABC 店舗が Web 上で公開している物件情報として提供され、改めて指標化を行う必要はない。

次に、動的情報としては、地域ポテンシャル（物件周辺の価値）と、店舗の視認性、店舗周辺の通行量が回答された。地域ポテンシャルは、最寄り駅の平均坪単価を算出し、物件の坪数を掛け合わせた駅推定賃料として定義し、指標化する。店舗の視認性と店舗周辺の通行量は、積を取ることで物件の見つけやすさを表す指標として利用する。本研究では、この2つの変数は営業マンが5段階でスコアリングした数値を使用する。ただし、スコアリングによる指標化には、個人による差異が生じる問題がある。我々は、この問題はセンシングシステムの開発により解決できると考え、実際に通行量を取得可能なセンサを開発し、実験によってその有用性を確認している[6]。一方で、視認性については間口面積や看板の大きさなどを活用すれば指標化できる可能性もあるが、周囲にある植え込みや建造物などの要因を盛り込めないなどの問題があるため、さらなる検討が必要である。

ここまで挙げられた変数は顕在化されている情報であったが、潜在的情報は営業マンが指標化できない情報である。我々は、この情報を営業マンが記述している物件キャッチコピーをもとに取得可能であると仮定し、賃料とキャッチコピー中の名詞との関係から指標化している[2]。キャッチコピーには物件の特徴などが記述されており、本稿では名詞に加えて形容詞を形態素解析によって抽出し、単語と賃料の関係を求める。形容詞を加えた理由として、名詞のみでは意味付けが正反対の理由になるケースがあるためである。キャッチコピーにはポジティブな内容が多いため、「大通り」という名詞があれば、大通りに面していたり近くにあることが連想でき賃料を上げる効果を期待しがちだが、万が一「大通りから遠い」と記述されていれば反対のことが起きる。一方で、キャッチコピーに動詞や副詞はあまり活用されないこと、助詞や助動詞は物件の状態を説明できないことから、本稿では名詞と形容詞を抽出する。また、一般性を確保するために、一つの物件にのみ出現する用語は対象から除外している。また、指標化手法としては、静的情報と動的情報のみを用いて推定した賃料と実際の賃料との比を求める。このとき値が0.9以下（推定賃料<実際の賃料）のものには、賃料を上げる潜在的要因があると仮定し、ポジティブワード群とする。また、1.1以上（推定賃料>実際の賃料）のものは、賃料を下げる要因があるとし、ネガティブワード群とする。さらに、これらの値を物件毎に積をとることで、ポジティブ指標、ネガティブ指標として指標化する。

4. 機械学習に基づく賃料推定システム

4.1. 賃料推定モデルの構築と評価

本節では、賃料推定モデルの構築と評価について述べる。

4.1.1. 賃料推定モデルの構築

賃料推定システムの実現のためには、機械学習に基づいた推定モデルの構築が必要である。機械学習手法には、ランダムフォレストの回帰分析を用いる。

モデル構築に用いる指標は、静的情報・動的情報・潜在的情報である。これらの要素の賃料推定に対する影響力を確認するために、具体的には、表1に示す7つのデータに基づいてモデルを構築する。

定量的な精度評価は、各データ毎に決定係数 R^2 と推定値の平均二乗誤差 (RMSE: Root Mean Squared Error) を比較することで行う。用いる決定係数の定義は(1)式の通りである。このとき、 y_i は実績値、 \hat{y}_i は推定値、 \bar{y} は実績値の平均を示している。実績値は実際の賃料のことを示し、株式会社 ABC 店舗で実

際に契約に至った賃料である。この値にはベテラン営業マンの暗黙知を含むため、真値にすることに疑問が残る可能性がある。しかしながら、不動産価格は需要と供給のマッチングによって決定されることから、本研究ではその原則に従いこれを真値とする。決定係数の最も良いスコア値は 1.0 であり、この値は負にも成り得る。また、RMSE は(2)式によって求める。ここで、N は全予測対象数を示している。RMSE は推定値の実績値からの乖離度を示しており、モデルの推定精度の悪さを評価する指標である。よって、0 に近い程優れているといえる。

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

学習における対象物件は、東京都内の飲食店用不動産物件である。このうち、推定に使用するデータセットとしては、60 万円以下の 184 物件を対象としている。ここでは、高額物件には特殊なものが多く、推定の外れ値となりえるため排除している。このときの平均賃料は 266,987 円であり、中央値は 250,000 円である。さらに、機械学習に基いて作成されるモデルの汎化性能を評価するために、3-fold 交差検証を行う。モデル構築に用いるパラメータは、木の深さ=15 で固定とし、木の数・用いる特徴量の数をグリッドサーチし、表 1 に示す値が得られた。

表 1 各データの機械学習パラメータ

| 番号 | 用いる要素 | 木の数 | 特徴量の数 |
|-------|--------|-----|-------|
| データ 1 | 静的情報 | 26 | 2 |
| データ 2 | 動的情報 | 26 | 1 |
| データ 3 | 潜在的情報 | 10 | 1 |
| データ 4 | 静的・動的 | 18 | 3 |
| データ 5 | 静的・潜在的 | 18 | 3 |
| データ 6 | 動的・潜在的 | 29 | 3 |
| データ 7 | すべての要素 | 18 | 3 |

表 2 機械学習に基づく賃料推定結果

| 番号 | 決定係数 $R^2 \pm \sigma$ | RMSE |
|-------|-----------------------|--------|
| データ 1 | 0.250±0.0577 | 88212 |
| データ 2 | 0.510±0.00445 | 71314 |
| データ 3 | -0.0445±0.0202 | 102144 |
| データ 4 | 0.638±0.0270 | 62394 |
| データ 5 | 0.447±0.0692 | 75190 |
| データ 6 | 0.734±0.00902 | 52987 |
| データ 7 | 0.738±0.0120 | 52494 |

4.1.2. 賃料推定モデルの評価

構築した推定モデルの評価は 3-fold 交差検証に基いて行う。推定によって求められた結果を表 2 に示す。このとき決定係数は、3 回分のスコアの平均値と標準偏差を求めることで評価し、RMSE についてはデータセットを 3 分の 1 ずつ推定した結果を組み合わせ、全物件に対する推定値に基づき算出する。

まず、最も賃料決定に影響している要素を抽出するため、それぞれの要素を 1 つのみ用いた場合同士で比較を行う。静的情報を用いた場合（データ 1）の決定係数は 0.250 であり、RMSE は 88212 であった。また、動的情報を用いた場合（データ 2）の決定係数は 0.510、RMSE は 71314 であった。さらに、潜在的情報を用いた場合（データ 3）の決定係数は -0.0445 であり、RMSE は 102144 であった。よって、動的情報のみを用いた場合は、静的情報の約 2 倍の決定係数が得られており、3 つの要素の中で最も精度が良いことが確認できる。ここで、静的情報と動的情報を用いた場合（データ 4）の決定係数は 0.638 であり、RMSE は 62394 である。このことから、2 つの要素は組み合わせることで精度が向上することが確認された。

一方で、潜在的情報は決定係数が負となり、賃料決定能力がないことが分かる。決定係数には複数の異なる定義が存在し、統計ソフトウェアによって使われる定義が異なることは、Eisenhauer[8] が説明している。また、Motulsky ら[9]は、残差平方和が全平方和を上回るような不適切なモデルを選択した場合に、決定係数が負になる可能性があることを説明している。このことから、潜在的情報単独では負の決定係数が出現するため、モデルが不適切であり、賃料を説明する能力がないことが示された。

しかしながら、静的情報と潜在的情報を用いた場合（データ 5）の決定係数は 0.447 であり、RMSE は 75190 である。また、動的情報と潜在的情報を用いた場合（データ 6）の決定係数は 0.734 であり、RMSE は 52987 である。よって、潜在的情報のみでは推定能力はないが、静的情報と組み合わせるときに約 1.8 倍の 0.447、動的情報とでは約 1.4 倍の 0.734 となり、価格調整に優れていることが確認できる。

最後に、すべての情報を用いた場合（データ 7）の決定係数は 0.738 であり、RMSE は 52494 である。この結果、決定係数を基準に考えると、賃料推定には、すべての情報を用いた場合が最もよい精度が得られることが確認できる。また、データ 6 との差はわずかであるが、データ 6 では 29 個もの学習木が必要であり、6 割程度の木の数でも同等以上の性能を実現できることから、静的情報には価値があるこ

とが分かる。逆に言えば、物件の詳細な情報が不鮮明な場合、動的情報と潜在的情報のみでも、推定できないことはないことが分かる。さらに、これらの結果について営業マンに確認した結果、「現場で十分参考になる」との回答を得ている。これらの物件は数万円単位の価格操作は日常的に行われており、数十万円オーダーで決定される賃料に対して十分な精度であるといえる。

4.2. 賃料推定モデルのシステム化

本研究で提案している賃料推定概念モデルに基いて、実際に新人営業マンへの伝承を行うためには、推定モデルを営業現場で利用可能にするシステム化が必要である。具体的には、推定モデルを新人営業マンが自身で活用し、各種条件に対する賃料推定結果を学習していくことで、知識の伝承を行える狙いがある。また、推定モデルは既存のデータセットのみでモデル構築・検証を行っているが、システムの利用によってさらに多くのデータを収集できるようになると、それらを活用し、学習・検証を繰り返すことで、将来的にさらなる精度向上が期待できる。さらに、実際に営業マンに活用してもらうことで、改善点の発見につながることも期待できる。そこで、推定モデルを営業現場で利用可能にするためにWebアプリケーション化を行った。構築した賃料推定システムの利用画面を図2に示す。

本システムは株式会社ABC店舗内に設置しているローカルサーバに導入し、Webアプリケーションとして営業マンの各PCから利用可能にしている。使い方としては、機械学習の入力である賃料推定モデルの各要素を選択または入力し、推定ボタンを押下することで、推定賃料が上部に表示されるようになってきている。また、推定賃料とは別に、地域ポテンシャルである「駅推定賃料」を下部に表示している。さらに、推定には活用していないが、物件の住所を入力すれば、データセット中の最寄り5つの物件をジオコーディングにより抽出し、ページ下部に表示するようにしている。

5. 考察

5.1. 賃料推定システムの利活用について

4.2節で述べたシステムの機能を新人営業マンが活用し、物件やパラメータを変えながら結果を見て学習することによって、ベテラン営業マンの暗黙知の継承につながる。また、入力したこれらの情報は、アクセス元PCのIPアドレスと共に、CSVファイルに記録されるようにしており、新規物件の住所と物件の特徴量を紐付けて収集できる。これにより、これまで営業マンに依頼してスコアリングしてもらっ

物件の推定賃料は 344669 円

駅名
浜松町

視認性 通行量 居抜き 駅徒歩時間
2 3 あり なし 5

坪数 階数
20.0 B2 B1 1 2 3 4 5

キャッチコピー

住所
東京都港区浜松町1-31

リセット 推定

駅推定賃料
最寄り駅推定賃料 123373 円 (駅平均坪単価×坪数)

周辺物件
物件ID, 距離[km], 名称, 最寄駅, 実績値, 通行量, 視認性, 居抜きフラグ, 駅徒歩[min.], 階層, 坪数
46874, 0.055, ロマネビルディング, 浜松町, 258300, 2, 3, 0, 1, 2, 9.28,
47867, 0.079, 浜松町伊那ビル (サブリース), 浜松町, 335000, 2, 3.5, 1, 2, 1, 16.6,
47726, 0.327, 藤和浜松町, 浜松町, 896553, 4, 2, 0, 1, 2, 40.66,
48284, 0.343, 7セントラルビル, 浜松町, 368000, 3, 4, 1, 5, 1, 14.75,
47996, 0.407, 玉川ビル1階店舗 (サブリース), 浜松町, 462000, 4, 4, 1, 2, 1, 11.04,

図2 賃料推定システムの利用画面

ていた視認性・通行量の主観データを自動的に収集できるようになり、今後の精度向上のためのシステムの更新に活用可能となる。さらに、本システムが精度向上を繰り返し、熟成された後に既存物件に対して賃料推定を行えば、既存物件賃料の外れ値の探索にも活用できると考えられる。具体的にはオーナーの意向など、システムで考慮されていない要因によって、値付けされている物件の発見に活用できると期待できる。

5.2. 地域ポテンシャルについて

地域ポテンシャルに路線価を使用せず、駅推定賃料にした理由として、取得が容易で賃料との高い関連性が期待できることが挙げられる。そこで、その正当性を確認するために、路線価を地域ポテンシャルに活用して賃料推定を行い、駅推定賃料を活用した場合との比較を行う。駅推定賃料と同様に、路線価と坪数からなる路線価推定賃料として地域ポテンシャルに組み込む。

また、保有しているデータセットでは、路線価のデータがない物件も含まれるため、それらは予め除外した169物件で比較する。比較するのは動的情報のみと、全ての情報を活用した場合である。表3に推定結果を示す。このとき括弧内の数値はデータ番号を示す。駅推定賃料を使用した際の結果が、表2と異なるのは、モデル構築に活用している物件数が

表3 地域ポテンシャルの比較

| 地域ポテンシャル | 決定係数 $R^2 \pm \sigma$ | RMSE |
|-------------|-----------------------|-------|
| 駅推定賃料 (2) | 0.427±0.0251 | 77960 |
| 路線価推定賃料 (2) | 0.172±0.0835 | 92750 |
| 駅推定賃料 (7) | 0.690±0.0112 | 57925 |
| 路線価推定賃料 (7) | 0.665±0.0175 | 60604 |

異なるためである。結果より、動的情報のみを用いた場合と、全ての要素を用いた場合の両方において、駅推定賃料が賃料の決定に優れていることが分かる。

5.3. 形容詞を用いる効果

キャッチコピーの情報として、名詞のみでなく形容詞も抽出することの必要性について述べた。これについても、名詞のみの場合と名詞+形容詞の場合で賃料推定を行うことで比較を行い、その正当性を確認する。比較は、潜在的情報を用いるデータ5(静的・潜在的)、データ6(動的・潜在的)、データ7(静的・動的・潜在的)について行う。データ3(潜在的情報のみ)については、賃料決定能力がないことが既に判明しているため、ここでは利用しない。

表6に比較結果を示す。表からは全てのデータ番号において、形容詞を用いた場合の方が、名詞のみの場合よりも決定係数が大きいことが読み取れる。これはすなわち、形容詞を使用することは精度向上に貢献しているといえる。したがって、潜在的情報において形容詞も併用することは有意義であることが確認された。

6. おわりに

本研究では、飲食店用不動産向けの賃料推定システムの実現に向けて、機械学習に基づく賃料推定モデルの構築・システム化を行った。定義した各要素の影響について、決定係数を比較した結果、動的情報は基本価格の推定に優れることを確認した。また、潜在的情報は単独では賃料推定能力はないものの、他の要素と組み合わせることによって、価格調整に優れていることを確認した。さらに、キャッチコピー中から名詞に加えて形容詞を抽出することで、精度が向上することを確認した。最終的には、全ての情報を用いることで、0.738と最も高いスコアが得られた。このときの、平均二乗誤差(RMSE)は52494となり、平均賃料が約26万円であるのに対して実用的な精度での推定ができていているといえる。一方で、10万円前後の格安物件に対しては誤差の割合が未だ大きいという点で改善の余地がある。

今後の課題としては、本研究で提案・構築した賃

表4 形容詞の有無による決定係数の比較

| データ番号 | 名詞 決定係数 $R^2 \pm \sigma$ | 名詞+形容詞 決定係数 $R^2 \pm \sigma$ |
|-------|-----------------------------|---------------------------------|
| データ5 | 0.435±0.0695 | 0.447±0.0692 |
| データ6 | 0.726±0.0299 | 0.734±0.00902 |
| データ7 | 0.731±0.0154 | 0.738±0.0120 |

料推定モデルを営業現場で実際に使用してもらうことで、精度向上や実用性に関する評価などに取り組むことがあげられる。

謝辞

本研究の一部は科学研究費補助金 挑戦的萌芽研究 15K12161 の助成を受けたものである。また、研究フィールドの提供にご協力いただいた株式会社ABC店舗の皆様感謝いたします。

参考文献

- [1] Nonaka, I., and Hirotaka, T.: The knowledge-creating company: How Japanese companies create the dynamics of innovation. Oxford university press (1995)
- [2] 荒川周造, 諏訪博彦, 小川祐樹, 荒川豊, 安本慶一, 太田敏澄: 潜在的情報を用いた飲食店用不動産賃料推定モデル, 第23回社会情報システム学シンポジウム (2017)
- [3] Victor Gan, Vaishali Agarwal, Ben Kim: DATA MINING ANALYSIS AND PREDICTIONS OF REAL ESTATE PRICES, Issues in Information System, Volume 16, Issue IV, pp.30-36 (2015)
- [4] Chih-Hung Wu, Chi-Hua Li, I-Ching Fang, Chin-Chia Hsu, Wei-Ting Lin, Chia-Hsiang Wu: HYBRID GENETIC-BASED SUPPORT VECTOR REGRESSION WITH FENG SHUI THEORY FOR APPRAISING REAL ESTATE PRICE, 2009 First Asian Conference on Intelligent Information and Database Systems, pp.295-300 (2009)
- [5] Vincenza Chiarazzo, Leonardo Caggiani, Mario Marinelli, Michele Ottomanelli: A Neural Network based model for real estate price estimation considering environmental quality of property location, Transportation Research Procedia 3, pp.810-817 (2014)
- [6] 荒川周造, 諏訪博彦, 小川祐樹, 荒川豊, 安本慶一: 通行量センサを用いた飲食店用不動産賃料推定システムの提案, 社会システムと情報技術研究ウィーク in ルスツリゾート (2016)
- [7] Leo Breiman: Random Forests, Machine Learning Volume 45 Issue 1, pp5-32 (2001)
- [8] Eisenhauer J. G.: Regression through the Origin, Teaching Statistics 25, pp.76-80 (2003)
- [9] Motulsky H. and Christopoulos A. : Fitting models to biological data using linear and nonlinear regression, Oxford University Press.(2004)