

# 飲食店向け不動産営業を支援する 申し込み顧客推薦システムの提案

河村 一輝, 諏訪 博彦, 荒川 豊, 安本 慶一

奈良先端科学技術大学院大学情報科学研究科

*kawamura.kazuki.ka3@is.naist.jp*

**概要** 本研究では、飲食店向けの不動産営業を支援する手法を提案する。飲食店起業を目指す顧客が、物件の成約に至る流れは以下の通りである。①検索サイトで不動産を探す。②実際に内見を行い気に入った物件を閲覧する。③内見に行った物件の内気に入った物件を申し込みする。④物件の貸主と交渉し、成約に至る。①→②の検索から内見に移ることや、②→③の内見から申し込みに移ることは稀なため、不動産会社の営業マンが電話をかけて次のステップに促す。従来では電話営業を行う際、営業マンは長年の感と経験によって、数ある顧客リストからより成約に至りやすい顧客を選定し、電話をかけていた。この時の営業成功確率は、2割から3割程度であり、この精度向上は重要な課題である。さらに、新人の営業マンでは、どの顧客に電話をかけるべきかのノウハウがたまっておらず、どの顧客にかけたらいいいのか分からないといった問題があり、その対応策の創出が課題である。この課題を解決するために、本研究では機械学習を用いて、申込みの可能性の高い顧客を推定し、営業マンに電話をかけるよう推薦するシステムを提案する。内見時のアンケート結果、物件情報の生データ2クラスの他に熱意と地域ポテンシャルという独自の特徴量を加え、RandomForestを用いて機械学習を行ったところ53.8%の精度で申し込み顧客を推薦することが出来た。ベテランの営業マンの営業成功確率が2割から3割程度のため、本システムで推薦された結果は、営業効率をあげることに大いに貢献出来る。

**キーワード** 機械学習, 推薦, 営業支援システム

## 1 背景

近年、様々な実社会の情報を容易に収集出来るようになってきた。また、多くの機械学習に関する研究が行われ、様々な手法が開発されている。それに伴い、それらの情報を使い機械学習を用いて利用者が望む情報を見つける手法[1][2][3]が盛んに提案されている。例えば、Saeideh ら[4]は、新規の飲食店のオンラインレビューのレーティングを予測しようとしている。

また、これらの手法をビジネスの世界に適用しようとする動きもみられる。具体的には、amazon[5]では、ユーザの商品の購入履歴からユーザが次に購入したがる商品を紹介し、提案している。また、ビズリーチが提案している転職サイト「キャリアアトレック」[6]では、ユーザの求人情報の閲覧ログからユーザにあった求人情報を提案している。

さらに、機械学習を用いた営業支援研究やシステムも盛んに提案されている。everstring[7]では、B2B 向けの商品を買ってあげる法人企業をどの法人企業が自社の商品を買ってくれるかを推薦している。また、Yiqing Huang ら[8]は、中国の携帯会社のデータを使い、プリペイド携帯の解約者を予測し、その解約者に電話営業を行うよう促しプリペイド解約を思いとどまらせる

システムも提案されている。このように、機械学習を用いて企業の営業を支援し、利益に貢献しようとする多くの取り組みがある。

本研究では、飲食店不動産探索を行う個人に対して営業を行う飲食店不動産会社を対象とし、不動産契約の申込をすると考えられる候補顧客の推薦を行うことで、営業支援を行うことを目的とする。推薦に関する従来研究の多くは、同じ商品を多くの人が購入出来ることを前提としていた。また、比較的安価で、同じ人が複数の商品を購入できることを前提としていた。しかし、本研究が対象とする商品は不動産であるため、世の中に2つとして同じ商品が存在しない。また、複数の不動産を取得するには多額な費用が必要になるため、同一人物が複数回購入することを前提にできない。そのため、従来の推薦手法で多く使われる協調フィルタリングやコンテンツフィルタリングのように、購買履歴から嗜好を生成することや、その嗜好傾向の類似性から商品を推薦することができず、新たな手法を検討する必要がある。

具体的な研究対象としては、飲食店向けの不動産会社である ABC 店舗1と共同研究を行い、データ提供や営業ノウハウについての情報を得ている。ABC 店舗からの聞き取り調査によれば、飲食店起業を目指す顧客

が、物件の成約に至る流れは以下の通りである。

- ① 検索サイトにアクセスし不動産物件を探す。
- ② アクセスで気になった物件を内見し、実物件を確認する。
- ③ 内見に行った物件の内、気に入った物件を申し込みする。
- ④ 物件の貸主と交渉し、成約に至る。

しかし、ほとんどの顧客は飲食店を開業することが初めてであり、適切な条件を把握していないケースが多い。こういった顧客が、現行の不動産検索システムを用いて検索を行った場合、適切な条件を入力することが出来ずに、自身に適した不動産を探し成約に至るのは非常に困難である。

そのため、①→②の検索から内見に移る段階や、②→③の内見から申し込みに移る段階で躊躇することがあり、不動産会社の営業マンは電話をかけて次のステップに促している。従来は、電話営業を行う際、営業マンは長年の勘と経験によって、数ある顧客リストからより成約に至りやすい顧客を選定し、電話をかけていた。しかし、新人の営業マンでは、どの顧客に電話をかけるべきかのノウハウがたまっておらず、どの顧客にかけたらいいか分からないといった問題がある。また、対応する顧客数の増加に伴い、すべての顧客を手で検索し続けることは困難である。この問題を解決するために、本研究では機械学習を用いて、申込みの可能性が高い顧客を推定し、営業マンに電話をかけるよう促すシステムを提案する。本稿では、そのために、どのようなデータを収集し、モデルを構築することで、より効率的なマーケティング支援を行えるのか検討する。

## 2 飲食店不動産成約プロセス

飲食店不動産を探す顧客の行動プロセスと、各プロセスで得られる情報を図1に示す。顧客は、まずWeb上の不動産検索サイトにアクセスし様々な不動産を検索・閲覧する。アクセスステップでは、顧客の不動産閲覧履歴であるアクセスログ、気に入った不動産をブックマークするお気に入り、不動産を検索する際の絞り込み条件である検索条件をそれぞれ得ることができる。

内見は実際に不動産を見るステップである。内見ステップでは、実際に見た不動産の履歴である内見ログ、内見を行う際に、営業が顧客から直接話しを聞いたヒアリング情報を得ることができる。営業は、顧客がその物件を気に入ったかどうか、何が申込みの障害になっているのかなどを聴き取りにより把握している。顧客の中には、繰り返し内見を行う顧客も少なくない。

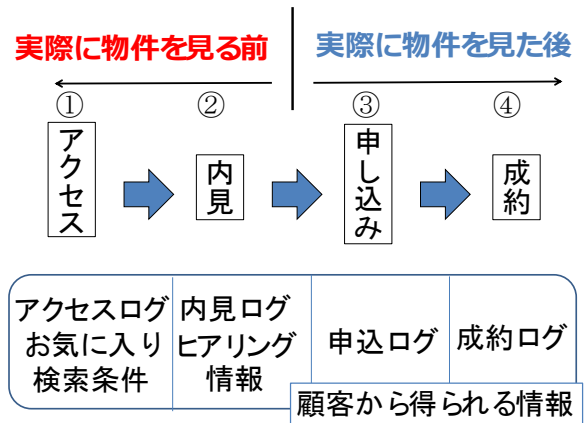


図1 飲食店不動産契約プロセスと得られる情報

申し込みは不動産を成約する為の予約をするステップである。申し込みステップでは、顧客が申し込んだ物件履歴である申し込みログを得ることができる。申し込みのステップで、貸主の意向や他の顧客に先をこされるなどの事情で成約に至らなかった場合、また内見ステップに戻ることになる。

成約は不動産を成約するステップである。申し込みをした不動産貸主と顧客の双方の同意が取れ、手付金を支払うことで漸く成約に至ることのできる。成約ステップで、顧客が成約した不動産履歴である成約ログを得ることができる。

このプロセスの中で、内見・申し込み・成約のステップでは、顧客は実際に不動産を見ている状態にあるが、アクセスステップでは不動産をまだ実際には見ていない状態である。不動産を見る前後で顧客のこだわりが変化する為、アクセスステップにある顧客情報のみから、申し込みや成約に至る顧客を予測するのは困難である。また、内見した印象が良かったからといって申し込みをすとも限らない。本研究では、アクセス、内見の両ステップの情報から機械学習を用いて申し込み顧客を推定することを試みる。次章において、機械学習による人間の行動予測に関する研究を紹介する。

## 3 関連研究

機械学習を用いた人間の行動予測に関してこれまでに様々な研究が行われている。Saeideh[4]らは気象条件や人口統計を用いて、飲食店のオンラインレビューを推定する手法を提案している。この研究によると、気温がレイティングに対し大きな影響を及ぼしていることが示されている。気温が中程度の時が最もレイティングに対し正の相関があるのに対し、とても暑い日やとても寒い日にはレイティングに対して負の相関があった。このように、ユーザの心理状態もユーザの行動に大きな影響を

与えている。

Amazon[5]では、EC サイトで商品を購入する顧客に対してユーザの購入ログから、よりユーザが好む商品の予測を行っている。Amazon[5]を利用するユーザは、商品の購入後、5段階(好き、少し好き、普通、少し嫌い、嫌い)の評価を行う。システムは、その評価を元にユーザ間の類似度を求める。ユーザが高い評価を行った商品は、類似度の高い他のユーザにも推薦される。このように、ユーザにおすすめ商品を提案するなど、ビジネスにも機械学習は使用されている。ビズリーチの転職サイト「キャリアトラック」[6]では、会員の基本情報や診断テスト、サイトの利用動向、似ているユーザのサイトの利用状からそのユーザに合った求人情報を提案している。このように、ユーザの基本情報やサイトの利用状況を説明変数に機械学習を行うことは一般的である。本研究では、ユーザのお気に入りログを使用し推薦する。

everstring[7]では、B2B の企業に対して、商品を買ってくれそうな顧客を推薦するサービスを行っている。従業員規模、収益状況、経営者の経歴、地域などを説明変数に用いて、成約確度の高いもしくは低い顧客を判定するモデルを機械学習で構築している。

Yiqing Huang ら[8]の研究では、中国の携帯会社の営業支援システムを提案している。プリペイド携帯の解約者を予測し、営業マンに電話をかけさせることで解約を思い留まらせる仕組みである。ユーザの行動ログ、メッセージログ、パケット、通話の品質等から解約する確率の高いユーザを推定している。

安藤ら[9]の研究では、ABC 店舗において①→②の検索から内見に移るステップを支援するために、顧客のこだわりを抽出する手法を提案している。この手法では、顧客のアクセスログ、お気に入り、検索条件から、顧客が7つの属性(場所、駅徒歩、階数、面積、賃料、居抜き、造作)のうちどの属性にこだわりがあるかを算出し、それにより顧客のプロフィール(こだわり)を作成し、こだわりと物件のマッチ度が高い顧客ほど内見しやすいと考えて推薦している。しかし、実際に申し込みをするかどうかについては検討されていない。そこで、本手法では②→③の内見から申し込みに移るステップを支援する手法を提案する。

#### 4 提案手法

従来手法において、営業は手作業で大量の内見済みの顧客の中から不動産の申し込みの可能性が高い顧客の発掘を行っている。そのため、手間と労力が必要であり、コストがかかっている。また、営業の成功確率は、営業の勘と経験から導き出されるノウハウ(暗黙知)により変化する。そのため、ノウハウ(暗黙知)を形成で

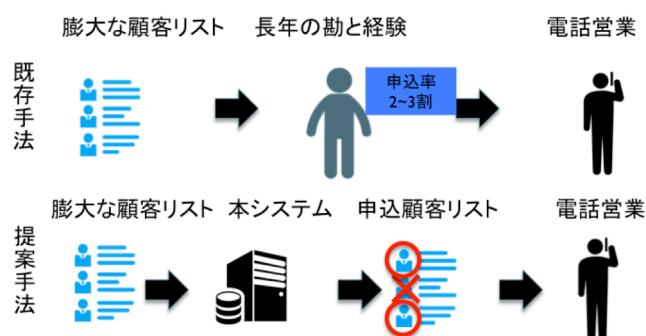


図2 既存手法と提案手法の違い

きていない新人営業は、営業機会を損失していることが考えられる。そこで、提案手法では暗黙知であるノウハウを機械学習によりモデル化することを目的とする。また、その際に、どのようなデータがモデル構築に必要なのか検証する。

モデル構築のためのデータセットとして、大きく3つのクラス(属性群)を用いた。1つ目のクラスは、内見後に顧客に答えてもらったアンケートデータである。アンケートでは、第一印象、立地、月額賃料、譲渡価格、取得総額について顧客がどう感じているかと事前調査の有無について確認した。顧客が申し込みをするか否かは、顧客が持っている物件に対する主観評価が申し込み行動に影響を及ぼすと考え、このクラスをデータに含めることとしている。

2つ目のクラスは、物件の情報である。物件の情報には、月額賃料、面積、何階か、駅から徒歩何分か、最寄り駅、居抜き物件かどうかが含まれている。ABC 店舗が扱う物件は多種多様であり、物件立地や価格などの物件自体の特長により、人気・不人気が存在する。このことから、物件自体の特徴が顧客の申し込み行動に影響を及ぼすと考え、このクラスをデータに含めることとしている。

3つ目のクラスは、生データではなく加工した特徴量郡である。開店意欲(量)、開店意欲(期間)、地域ポテンシャルが含まれている。開店意欲をもって真剣に物件を探している顧客は、物件を申し込みの可能性が高い

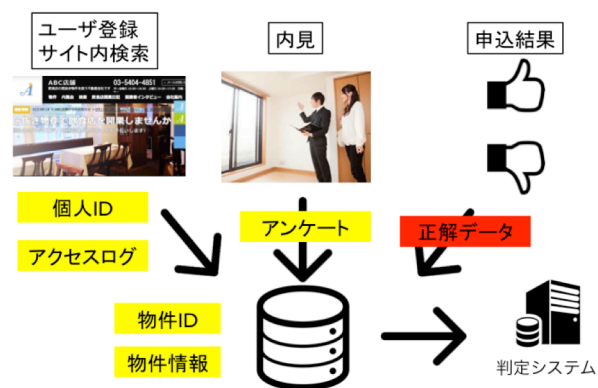


図3 データの取得とモデル構築

という ABC 店舗の知見により、この特徴量を作成する。開店意欲には、2つ種類があると考えている。まずは、意欲の大きさである。これは、どれだけ大きな意欲を持っているかという絶対的な量を表す。より意欲の高い顧客は様々な物件にアクセスするという仮定のもと、ABC 店舗のデータベースからアクセスログを取得し内見日の 14 日前から内見日までの2週間での総アクセス数を開店意欲（量）と定義した。

次に、意欲の継続性である。これは、どれだけ長い時間開店意欲を継続できているかを表す。より長く継続して物件を探索している人ほどより意欲が高いという仮定のもと、ABC 店舗のデータベースからアクセスログを取得し内見日の 14 日前から内見日までの総アクセス日数を開店意欲（期間）と定義した。

地域ポテンシャルについては、物件がある街の人気度は、申し混み行動に影響を及ぼすと考え、街全体の平均賃料が高いほど地域ポテンシャルも高いと仮定し、データベースから物件情報のデータを取得し最寄り駅毎の単位面積当たりの平均賃料を地域ポテンシャルと定義した。

提案システムでは、これら全てのデータを組み合わせることで申し込み推定モデルを構築し、申し込み見込み顧客リストを構築する。

## 5 実験

提案手法で示したデータから申し込み推定モデルについて検証するために、実際にデータを収集して評価実験を行った。本研究で使用するデータセットを表 1 に示す。アンケートデータは、不動産会社の営業の方にとって頂き、顧客が物件を内見した後に構造化インタビュー形式でデータを収集している。2014 年 2 月 3 日から 7 月 10 日まで、計 1146 件のデータを収集している。

これらのデータセット(表1)を用いて、機械学習により申し込み推定モデルを構築し、交差検証法を用いて推定結果の精度を検証した。モデル構築には代表的な機械学習アルゴリズムの一つである RandomForest[10]を用いた。モデル構築に際して、様々な条件下でデータを組み合わせ、計 5 つのモデルを構築している。5 つのモデルは、1. アンケートデータクラスのみを用いたモデル、2. 物件情報クラスのみを用いたモデル、3. 生データ(アンケートデータクラスと物件情報クラスを合わせたもの)を用いたモデル、4. 表1の全てのデータを用いたモデル、5. より重要なファクターのみを抽出した場合モデルである。重要なファクターの抽出は、ジニ係数の平均減少量(mean decrease gini)を用いて行なっている。ジニ係数は下記式で求めた。

$$Gini = \frac{\frac{1}{2} - \int_0^1 L(F)dF}{\frac{1}{2}}$$

表 1 本研究で使用するデータセット

クラス	属性
アンケート	第一印象
	立地
	月額賃料
	譲渡価格
	取得総額
	事前調査
物件情報	月額賃料
	床面積
	駅徒歩
	階数
	居抜き
	お気に入り
加工した特徴量	開店意欲（量）
	開店意欲（期間）
	地域ポテンシャル

## 6 実験結果

本章では、各データセットを用いた際の推定結果について述べる。まずは初期実験として簡単に使用出来る生データを用いて検証をした。表2は、アンケート結果のみを用いて申し込み顧客を推定した結果である。申し込みをすると推定した人数 98 人中、実際に申し込みをした人数は、30 人であり、30.6%の精度で推定できた。

表3は、物件情報のみを用いて申し込み顧客を推定した結果である。申し込みをすると推定した人数 59 人中、実際に申し込みをした人数 12 人であり、20.3%の精度で推定できた。アンケート情報、物件情報で比べた場合、アンケート情報を用いた時に精度が一番高い結果が出た。物件の申し込みには、心理状態が他の要素と比べて大きく影響していることが分かる。

表4は、物件情報とアンケートを用いて申し込み顧客を推定した結果である。申し込みをすると推定した人数 58 人中、実際に申し込みをした人数 22 人であり、37.9%の精度で推定できた。物件情報のみを用いた場合が 20.3%の精度であり、アンケートのみを用いた場合では 30.6%であったため、7.3 ポイント精度を向上することが出来た。

以上の結果、アンケートデータと物件データの両方を

用いた際に、一番良い結果が出る事が確認できた。次に精度を改善するために、ABC店舗の知見に基づいて加工した特徴量である開店意欲(量)、開店意欲(期間)、地域ポテンシャルの3つの属性を加えて推定を実施した。表5は表1の全データを用いて申し込み顧客を推定した結果である。申し込みをするだろうと推定した人数50人中、実際に申し込みをした人数22人であり、44.0%の精度で推定できた。全ての生データを用いて申し込み顧客を推定した結果が37.9%であったため新たな特徴量を作成することにより6.1%精度を向上することが出来た。

更なる改善のために、表1の特徴量の内影響力のある特徴量を調べるためジニ係数の平均減少量を計算した。その結果が図4である。図を見て分かるように新たに作成した特徴量、地域ポテンシャル、開店意欲(量)、開店意欲(期間)の重要度はそれぞれ1番、6番、8番となった。よって、生データだけでなくABC店舗の知見を元に新しい特徴量を作成することは有用であった。この結果を用いて平均ジニ係数の減少量が低い特徴量から1つ1つ要素を削っていき特徴量の数がいくつの時に最大の成果が得られるのかを検証した。その結果6つの要素を削った時、即ち上位9個の特徴量を用いた際に、予測結果が一番高かったため今回は上位9個の変数を使い求めた。

その結果が表6である。申し込みをするだろうと推定した人数52人中、実際に申し込みをした人数28人であり、53.8%の精度で推定できた。初期実験で行った心理状態を表すアンケート結果のみの場合と比べて、最終的に23.2ポイント精度を向上することができた。

表2 アンケートから推定した結果

	申込みない	申込み	
申込してない	889	68	93.0%
申込みした	136	30	18.1%
精度	86.9%	30.6%	

表3 物件情報から推定した結果

	申込みない	申込み	
申込してない	920	47	95.1%
申込みした	153	12	7.2%
精度	85.7%	20.3%	

表4 アンケート、物件情報から推定した結果

	申込みない	申込み	
申込してない	931	36	96.2%
申込みした	143	22	13.3%
精度	86.7%	37.9%	




図4 各特徴量の平均ジニ係数減少量

表5 表1の全データから推定した結果

	申込みない	申込み	
申込してない	939	28	97.1%
申込みした	143	22	13.3%
精度	86.8%	44.0%	

表6 図5の上位9個の特徴量から推定した結果

	申込みない	申込み	
申込してない	943	24	97.5%
申込みした	137	28	17.0%
精度	87.3%	53.8%	

## 7 考察

5つのシナリオに対する推定結果について、データ提供企業であるABC店舗からのフィードバックも踏まえて考察を行う。なお、ABC店舗からのフィードバックは、推定結果の提示・説明および質疑応答の会議形式で取得している。

5つのシナリオを比較した結果、全体としては全てのクラスデータの上位9個のデータを使用した際に最も効率よく申し込み顧客を推定できることが分かった。推定精度は53.8%であり、理論上は、申し込み候補者リストのうち約半分が申し込みをすることとなる。この結果をABC店舗に伝えたところ、従来の営業手法ではベテランの営業マンでも2~3割程度の精度であり、本手法は営業の

効率化に寄与すると思うとのコメントを得ている。

また、地域ポテンシャルについては、「良い立地の物件は申し込みが殺到する。良い物件は顧客の状況に関わらず申し込みされる」とのコメントが得られており、我々の分析結果と対応していると考ええる。

さらに、内見時の顧客の反応としてどのようなところに注しているかを確認した所、顧客の言葉として「立地」「賃料」という言葉が出てきた時に申し込みの有無が判断しやすいとのコメントが得られている。分析結果では、賃料が2番目、立地が5番目に重要なファクターとして抽出されており、この結果についても整合性が取れていると考える。

今後の課題としては、実営業の中で評価実験を行うことでその効果を定量的に図る必要がある。具体的には、提案手法を用いて抽出した顧客を含めた内見顧客に対して、実際に電話営業を行いその反応結果を取得し、比較する必要がある。その際には、既に申し込みをしている顧客の回避やダブルブッキングの回避などのフィルタリングを行うなど、綿密な実験計画が必要となる。

## 8 まとめ

申し込み見込顧客を営業担当者に推薦することで、営業担当者の時間とコストを省く推薦手法を提案した。申し込みをしたいと思う顧客の行動を予測するためには、地域ポテンシャルや物件の賃料、面積など人間の主観的な気持ちというよりも商品そのものの価値が大きな影響を与えていることが分かった。また、データを取得出来る種類が少ない際には、生データを加工し新しい特徴量(地域ポテンシャル、開店意欲等)を作成することは、有用であった。初期実験のアンケート結果を用いて機械学習を行った精度は、30.6%であったが、全てのデータを用いて機械学習すると53.8%の精度で申し込み顧客を推薦することが出来た。

今後はさらなる精度向上を図るために、顧客が内見に来訪している状態や営業マンの身体データセンシングすることで、申し込み顧客の推定ができないか検討する。また、本システムを使用し実環境で評価実験を行う際、営業マンが使いやすいシステムでないとかえって手間が増えてしまう可能性があるため、使いやすいユーザーインターフェースを検討し改良する。今回は、顧客が物件を申し込むか申し込まないかの2値を予測したが、ABC店舗から2値ではなく申し込み見込確率を知りたいとの要望があったため見込確率が高い順にソートされた顧客リストが出力できるシステムを作成する。

## 謝辞

株式会社ABC店舗の方には、本研究において、データ提供並びに貴重なご意見を頂きました。心より御礼

申し上げます。

## 参考文献

- [1] 神嶋 敏弘,推薦システムー情報過多時代をのりきる,情報の科学と技術,56 卷 10 号, pp.452-457,2006
- [2] J.Ben Schafer,Joseph A.Konstan and John Riedl, "E-Commerce Recommendation Applications," *Data Mining and Knowledge Discovery*, Vol. 5, pp.115-153, 2001
- [3] 土方嘉徳, 情報推薦・情報フィルタリングのためのユーザープロファイリング技術, 人工知能学会誌, Vol.19,No.3,pp.365-372,2004
- [4] Saeideh Bakhshi,Partha Kanuparth, Eric Gilbert "Demographics,Weather and Online Reviews: A Study of Restaurant Recommendations" *Proceedings of the 23rd international conference onWorld wide web* p.p 443-454
- [5] amazon <<http://www.amazon.co.jp/>>
- [6] キャリアトレック<<https://www.careertrek.com/>>
- [7] everstring <<http://www.everstring.com/>>
- [8] Yiqing Huang Fangzhou Zhu Mingxuan Yuan Ke Deng Yanhua Li Bing Ni Wenyuan Dai Qiang Yang and Jia Zeng," Telco Churn Prediction with Big Data", *Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data*, pp 607-618,
- [9] 安藤孝, 小川祐樹, 諏訪博彦, 太田敏澄, 飲食店不動産の営業を支援する内見顧客推薦システムの提案と評価, 第 19 回社会情報システム学シンポジウム学術講演論文集, pp.129-135, 2013.
- [10] Leo Breiman, "Random Forests", *Machine Learning October 2001*, Volume 45, Issue 1, pp5-32, 2001
- [11] J.Ben Schafer,Joseph A.Konstan and John Riedl, "E-Commerce Recommendation Applications," *Data Mining and Knowledge Discovery*, Vol. 5, pp.115-153, 2001