

## 論文

# AIを活用したユーザーニーズの探索プロセスにおける 「結果」と「理由」に係る一考察

～ Amazon.com と Google をもとに～

依 田 祐 一\*

水 越 康 介\*\*

本 條 晴一郎\*\*\*

## 要旨

本稿の目的は、AI (Artificial Intelligence : 人工知能) を活用したネットビジネスの発達に注目し、マーケティング実践における「結果」と「理由」の捉え方の変化を示すことにある。

IT (Information Technology : 情報技術) や AI 研究のますますの進展により、ビッグデータを蓄積し、豊富なコンピューティング資源を活用して、データを分析することができるようになってきている。特に、実際のネットビジネスでは、商用サービスを提供すると同時に A/B テストといった手段でダイナミックな実環境においてユーザーの選択結果をリアルタイムに取得し、その結果を分析し、サービスに速やかにフィードバックする実践が散見される。ネットビジネスの実践の現場では、そもそも、ユーザーがなぜその商材を選択したのかについての「理由」は特定しきれない。そして実環境で得た「結果」を重視して、その結果を元にサービスの提供方法を変更してしまえるのである。これらの実践は、これまでのマーケティングリサーチに典型的であったような、商品・サービスの開発段階においてユーザーニーズに関する仮説を設定してアンケートや実験等により仮説を検証してから、商用環境に新たな商品・サービスを投入するといったアプローチとは異なっている。ビッグデータの登場や AI の発達により、これまでマーケティング研究においてはもちろん、実務においても重視されてきた仮説や理由よりも、結果そのものが重要になりつつあると捉えることができるのかも知れない。

本稿では、この研究関心について、まずユーザーニーズの探索局面における理論的な問題の所在について考察する。続いて、AI のビジネス利用という点について、

---

\* 立命館大学経営学部、准教授

\*\* 首都大学東京 ビジネススクール、准教授

\*\*\* 法政大学 イノベーション・マネジメント研究センター、客員研究員

もっとも先進的であろうと思われる 2 つの企業, Amazon.com と Google の特定サービスに焦点を当て, 彼らがどのようにビッグデータや AI を利用し, またニーズを探索し, 捉えようとしてきたのかを明らかにする。

結論として, ネットビジネスにおいてユーザーがなぜ選択したのかの「理由」を特定しきれないまま, 実環境で得た「結果」を重視して, 実際のサービスの提供方法を変更し, 試行を重ねながらユーザーニーズに適応する実践方法の有効性が見出される。

## キーワード

AI, ビッグデータ, ニーズ探索, 結果と理由, ネットビジネス, マーケティング

## 目 次

1. はじめに
2. 先行研究
  - 2.1 仮説と理由の重要性
  - 2.2 仮説は何のために必要なのか
  - 2.3 結果がわかれば理由は要らない?
  - 2.4 論点
3. ネットビジネスにおける ユーザーニーズの探索プロセスの実践事例
  - 3.1 Amazon.com
  - 3.2 Google
4. ディスカッション
5. おわりに

## 1. はじめに

本稿の目的は, AI (Artificial Intelligence : 人工知能) を活用したネットビジネスの発達に注目し, マーケティング実践における「結果」と「理由」の捉え方の変化を示すことにある。ここでは, AI を「人工的につくられた人間のような知能, ないしはそれをつくる技術」(松尾, 2015, p.45) と広義にとらえる。AI における主な技術要素として, 得られたデータから, 隠れたパターンや法則, 規則などを見つけ出すための一連の手続きである機械学習 (Machine Learning)<sup>1)</sup> と新たな機械学習の方法としてデータをもとに自らが特徴量を作り出す深層学習 (ディープラーニング, Deep Learning)<sup>2)</sup> があり, 両者を含めて本稿では AI の意味で用いる。また, 今日の AI ではビッグデータが重要な意味を持つ。このビッグデータ (Bigdata) の定義は数多くあるが, Volume (大容量データ), Variety (多様な種類と発生源を有するデータ), Velocity (データの発生速度), Value (価値あるデータ) の 4 つの頭文字 V の特徴をもつデータという定義が認知されており (Hashem et al., 2015, p.100), 本稿ではこの意味で用いる。

IT（Information Technology：情報技術）やAI研究のますますの進展により、ビッグデータを蓄積し、豊富なコンピューティング資源を活用して、データを分析することができるようになってきている。特に、実際のネットビジネスにおいては、商用環境におけるA/Bテスト<sup>3)</sup>といったダイナミックな実環境において、商用サービスを提供すると同時に、ユーザーの選択結果をリアルタイムに取得し、その結果を分析し、サービスに速やかにフィードバックする実践が散見される。これらの実践は、これまでのマーケティングリサーチに典型的であったような、商品・サービスの開発段階においてユーザーニーズに関する仮説を設定してアンケートや実験等により仮説を検証してから、商用環境に新たな商品・サービスを投入するといったアプローチとは異なっている。新たな実践の現場では、そもそも、ユーザーがなぜその商材を選択したのかについての「理由」は特定しきれない。実環境で得た「結果」を重視して、その結果を元に実際のサービスの提供方法を変更してしまえることができる。もっといえば、ユーザーはなぜ選択したのかの「理由」どころか、AIによりなぜそのようなサービス提供方法に変更されたのかについて、企業側の担当者が理解しきれない場合さえ散見されるのである。

本稿では、この研究関心について、まずユーザーニーズの探索局面における理論的な問題の所在について考察する。続いて、このマーケティング実践を行うネット企業のAmazon.comとGoogleの特定サービスの事例を参照しつつ、考察することとする。

## 2. 先行研究

### 2.1 仮説と理由の重要性

マーケティング実践において理由と結果の関係を考える場合、マーケティングリサーチにおける仮説の重要性を確認することが有用であろう。いうまでもなくマーケティングリサーチでは、リサーチ問題を特定化するためには分析結果に対する論理的な理由を含む仮説の開発が重要であると考えられてきた。『『なにを探しているのかがわからないなら、それを発見することはない』というリサーチの名言がある。仮説はわれわれが探求しているものについてのスタートメントである（Aaker & Day, 1980, 邦訳 p.39)』。Aakerたちが指摘するように、仮説がなければ、どんなに探してみても、それを発見することはできない。仮説はリサーチの目的であり、ある現実がなぜ起きるのかを説明する理由を含んでいる。

仮説を持たない安易なりサーチは、うまくいかないか、むしろ商品の同質化を招くだけである（Levitt, 1960）。創造的な仮説の構築こそが優れたリサーチを可能にし、ひいては独自性のある商品の開発にもつながる。黒岩・水越（2012）といったマーケティングのテキストや西川・廣田編（2012）の商品開発のテキストにもみるとおり、それゆえに仮説の構築が必要とされる。

仮説検証という今ではビジネスにも一般化した言葉でも、「仮説」の重要性は強調されてき

た(勝見, 2006; 内田, 2006)。例えばセブン・イレブンは、仮説と検証を絶えず繰り返すことにより、ビジネスの精度を高めてきたという(勝見, 2006)。この際、仮説はビジネスの道標であるともされる。同様に BCG をはじめとするコンサルタントでも、絶えず「君の仮説は何か」と問われるという(内田, 2006)。仮説がなければ、情報は増える一方で何も判断できなくなってしまう。仮説の重要性は、マーケティングリサーチはもとより、ビジネスそのものにおいても示されてきたことがわかる。

## 2.2 仮説は何のために必要なのか

だが、一方で状況は変わりつつあるようにもみえる。特に期待を集めているのは、ディープラーニングなどの AI の研究成果である。AI については、これまでもビジネスの現場において注目を集めてきた(松尾, 2015)。だが一つにはコンピュータの性能の限界として、人々の期待に十分に応えることができずにきた。

この点については、内田(2006)において、仮説の重要性を示す根拠として主張されている。

「多くのビジネスパーソンは、情報が多ければ多いほど、よい意思決定、間違いのない意思決定ができると信じている。…これはある意味で、コンピュータが将棋を指す場合のやり方に似ている。その時点で考えられるすべての打ち手を読み尽くし、最も優れた手を打とうという考え方である。コンピュータのようにありとあらゆる手を検討し尽くすのが得意な機械でさえ、将棋では人間の名人に勝てない(内田, 2006, p.14)。」

内田によれば、すべての打ち手を読み尽くす機械はあたかも理想的であるかのようにみえて、しかし現実にはその情報量の多さゆえに、妥当な分析を行うことができない。逆に優れたビジネスパーソンは、確かな経験に支えられて情報の絞り込みを行い、情報を限定することで優れた分析を可能にするとされる。この絞り込みこそ、理由や仮説にほかならならないと考えられていた。

この理解は、確かに 2006 年の段階において正しかったかもしれない。だが少なくとも 2016 年の段階では、人間はコンピュータに勝つことが容易ではなくなってしまった。ダウンゴが主催したプロ棋士とコンピュータソフトウェアが対戦する将棋電王戦では、2013 年にはプロ棋士が 1 勝 3 敗 1 引き分け、2014 年には 1 勝 4 敗、そして 2015 年には 3 勝 2 敗となった。これをうけ、将棋電王戦のきっかけとなった情報処理学会が将棋連盟の協力を得て 2010 年より行われてきたコンピュータ将棋プロジェクトは、事実上トッププロ棋士に勝つという目標は達成されたとして 2015 年に終了している(小谷, 2014; 松原, 2015)。

コンピュータが人間に勝てない理由、さらには仮説が重要になる理由について、内田は情報

量の多さという点から説明していた。処理しなければならない情報があまりに多いがゆえに、人はもちろんコンピュータですら限界があり、情報を絞り込むという意味で仮説が重要になるというわけである。この考え方は、マーケティングリサーチでも同様であろう。パーソンのサーチライトの例(苅谷, 2002)で知られるように、サーチライト(この場合は概念)は暗闇の中で見えなかった何かに焦点を当て、実際のリサーチを可能にする。

それではコンピュータは、なぜ人間に将棋で勝てるまでになったのか。一つには、情報処理能力の向上があることは間違いない。すべての手を読みつくすまでには至らずとも、人間に将棋で打ち勝つ程度には、多くの手を素早く読みつくせるようになった。仮説の重要性が、もし情報量の多さという問題を解決するためにのみ必要とされてきたのであれば、その重要性は今後ますます薄まっていくことが予想される。

だが、より本質的と思われるもう一つの特徴がある。矢野(2016)では、AIの発展を段階的に説明する中で、「レベル1のシステムでは、アルゴリズムに入力すべきデータ(特徴量)を人間の仮説に基づき設計(pp.42-43)」する必要があるとされ、それゆえに人間の発想を超える結果も出にくいとする。実は先の将棋の成果は、依然としてこの段階にとどまっていた可能性がある。それまで2つの駒の関係に焦点を当てて分析していたのだが、ある時から3つの駒の関係に焦点を当てた分析が行われるようになったのである(松尾, 2015, p.78)。このレベルでは仮説が重要であったということになる。

その一方で、今やここでいう特徴量は必ずしも人間が設計する必要がなくなりつつあるとされる。すなわち「レベル2のAIでは、対象に関する仮説を、人が予め設定する必要がなく(矢野, 2016, p.43)」なり、人が思いもつかなかった解決策が見いだせるようになる。松尾(2015)がAIの新たな可能性として捉える最新技術「ディープラーニング」がそれである。

### 2.3 結果がわかれば理由は要らない?

ディープラーニングに代表されるAIが獲得する特徴量は、これまで人間が用意していた仮説や理由を代替することになりうる。Mayer-Schönberger & Cukier(2013)は、ビッグデータが世界を変えたとしながら大きく3つの変化を指摘する。「すべてのデータを扱う」、「精度は重要ではない」、そして「因果から相関の世界へ」である。これらのうち最初の2つは実質的にビッグデータの特徴を示しており、これらの特徴を元に、AIを中心とした実際的な利用が進むことで、因果から相関の世界への変化が起きると考えられる。

因果から相関の世界への変化では、これまで重視されてきた仮説や理由が不要になることが強調される。冒頭では、Amazon.comによる協調フィルタリング技術が紹介され、専属の書評委員による書評よりも、コンピュータがはじき出した顧客別のおすすめやベストセラーリストのほうが100倍も大きな売上を生み出したことが示される(邦訳 pp.82-83)。コンピュータは、

なぜその書籍が売れるのかを特徴量として把握するかもしれないが、それを根拠づけ、理由づけることはない。だが一緒に売れていることが明らかになったことと、A/B テストのような比較実験を通じて結果が示されたことは事実であり、その事実の積み重ねこそがビッグデータの世界では重要になる。

彼らによれば、仮説と検証を前提とした知識の進化は、あくまでスモールデータの世界だからこそ必要とされてきた (邦訳 p.89)。しかしデータ集合が大きくなれば、特定の変数同士をピックアップして検証するということが非常に困難になる。むしろビッグデータをコンピュータが解析するという作業を通じて、世の中を理解できるというわけである。

ただし因果よりも相関を重視するという説明は、厳密には正しくないかもしれない。ある商品が売れた時、別のある商品も売れる確率が高いといえるのならば、そしておすすめを通じて実際にその結果を促進できるのであれば、そこには一種の因果関係が認められるからである。むしろ彼らという 3 つ目の変化の特徴は、結果がすぐにわかるがゆえに、その前提となる理由の考察が必要とされなくなっているという点になるように思われる。

スモールデータの時代には、データが少ないというよりも結果をたくさん集めるということが困難であった。例えば、製品開発において A 商品と B 商品のどちらが売れるのかを判断する際には、実際に売って判断するというわけにはいかない。生産や販売にかかるコストは大きく、それゆえに生産を始める前に開発の判断をする必要がある。この時、A 商品と B 商品の違いが明示的に示され、理由付けられ、明確な仮説として構築されることによって、事前に予測し制御することがある程度可能になっていた。だがビッグデータを扱えるネットビジネスの場合には、実際にやってみるものの困難性が低いことが多い。画面はすぐに変えられる。サンプルも予算さえあれば集まる。製品サービスであっても、ベータ版として上市して様子をみながらアップデートすればよい。彼らが Amazon.com の事例を通じて説明したように、A/B テストの台頭がこれまで仮説や理由の考察が重要であるとされてきたビッグかスモールかという量的な問題とは異なる別の理由を浮き彫りにしている。

Watts (2011) および本條 (2015) では、A/B テストは測定対応アプローチであるとされ、予測と制御を前提とした旧来の方法と対比されている。なぜそのような結果になるのかがわからなくても、実際にそのようになることがわかれば、まずもってビジネスの打ち手は増える。また学術的な研究としても、実際にそのようになるということ自体が一つの発見となる。それは西垣 (2016, p.40) の言うところの「反知性的」にみえるかもしれないが、これらをさらに精査し、その理由を問う作業を進めることもできる。Mayer-Schönberger たちも述べるように「多くの場合、答えだけで終わりにせず、理由を知ろうと、ビッグデータの作業終了後に因果関係探しが本格化する (Mayer-Schönberger & Cukier, 2013, 邦訳 p.108)」こともある。

## 2.4 論点

ビッグデータの登場やAIの発達により、これまでマーケティング研究においてはもちろん、実務においても重視されてきた仮説や理由よりも、結果そのものが重要になりつつある。そしてその結果を元にして、AIは自らそのデータの特徴量を見いだすことができるようになりつつある。理由を探求することは、もはや情報量の削減という点からは必要とされない。

だが一方で、この変化がどこまで従来のマーケティングリサーチやニーズの探索の方法を刷新するののかについては、まだはっきりとはしていない。そもそもビッグデータやAIによって、具体的にどのように、仮説や理由に拘泥することなくニーズの探索が生まれているのかはまだ定かではない。ただ現状の可能性を明らかにするだけではなく、ニーズの探索を可能にすべく、先進的な企業がどのような開発を進めてきたのかということについての検討が必要であろう。

そこで以下では、AIのビジネス利用という点について、もっとも先進的であろうと思われる2つの企業のAmazon.comとGoogleの特定のサービスに焦点を当て、彼らがどのようにビッグデータやAIを利用し、またユーザーニーズを探索し、捉えようとしてきたのかを明らかにする。

## 3. ネットビジネスにおけるユーザーニーズの探索プロセスの実践事例

本節では、ビッグデータを蓄積しAIを活用するネットビジネスのユーザーニーズ探索事例として、Amazon.comとGoogleを取り上げる。両者は、サービス開発においてA/Bテストを活用しており<sup>4)</sup>、またAIの適用に積極的である。それぞれ、各社の概要を簡単に確認した上で、既述のユーザーニーズの探索における「結果」と「理由」の観点から考察する。なお事例の記述においては、公開されている2次資料を幅広く収集している。2次資料としては、企業ホームページの掲載情報、新聞、雑誌記事、プレゼンテーション資料、論文、書籍や動画（対象企業の社員のプレゼンテーション等）などがある。

### 3.1 Amazon.com

まずAmazon.comの主な事業であるEコマースのビジネスモデルと顧客価値を述べる。そして、AI活用の諸サービスを確認しつつ、特に同社のビッグデータを活かした推薦システム(recommender system)について取り上げる。

#### 3.1.1 Amazon.comの概略

ジェフ・ベゾス(Jeff Bazos)によりThe everything storeのコンセプトのもとに設立され

た Amazon.com は、インターネットによるショッピングサービスを提供する企業として、「地球上で最も豊富な品揃え」、「地球上で最もお客様を大切にする企業」というビジョンを掲げ、書籍を最初の商品として 1995 年 7 月に本格サービスを開始した<sup>5)</sup>。オンラインならではのロングテールによる豊富な品揃え、「我々はモノを売って儲けているんじゃない。買い物について顧客が判断する時、その判断を助けていることで儲けているんだ」という顧客価値に基づいた公開型カスタマーレビューの導入など、ビジョンに沿った事業を展開する<sup>6)</sup>。1997 年 5 月に NASDAQ に上場し、この資金調達により、1998 年 6 月にミュージックストア、1998 年 11 月にビデオストア、1999 年の夏に玩具ストアや家電ストア<sup>7)</sup>を展開するなど、書籍に加えて、CD、ビデオ、パソコン関係のソフトウェア・ハードウェアや電化製品など、店舗販売とオンライン販売の差異の少ない商品に着目して、商品カテゴリーを急拡大させた。また 2000 年 11 月には、マーケットプレイスによる古本を取り扱う新たなビジネスモデル<sup>8)</sup>として、顧客としての販売者と購入者をつなぐプラットフォームビジネスを構築した。販売者は、Amazon.com の顧客管理、決済、物流等のしくみを利用することが可能である。一方、2007 年 11 月に電子書籍リーダーの Kindle も展開し、書籍に係る垂直統合型のビジネスモデルも志向している<sup>9)</sup>。

またジェフ・ベゾスは、1990 年代の創業当初より Amazon.com を小売企業でなくテクノロジー企業と規定しており<sup>10)</sup>、例えば、近年の売上高研究開発比率を見ると 2011 年度の 6.1% から 2015 年度の 11.7% と研究開発型の事業運営を継続、加速している<sup>11)</sup>。本稿の関心である AI については、例えばクラウドコンピューティングのプラットフォームである Amazon Web Services 事業において、豊富なコンピューティング資源を構築・利用可能とし、また Amazon Machine Learning のサービスメニューにより契約先企業がサービスとして活用できるようにしている。Amazon.com の説明によると「Amazon Machine Learning は、Amazon がサプライチェーン管理、不正取引の特定、カタログの編成などの重要な機能の実行に使用してきたものと同じ、実証済みの高度にスケーラブルな ML テクノロジーに基づいています。」と述べられており、社内で精力的な利用が行われていることがうかがえる<sup>12)</sup>。また 2014 年 11 月には、AI 搭載のスピーカー型音声アシスタントの Amazon echo が販売され、約 1.5 年間で 300 万台を超えるヒットとなっている<sup>13)</sup>。

### 3.1.2 推薦システムの導入<sup>14)</sup>

既述のとおり、Amazon.com は、顧客の購入判断を支援する点に顧客価値をおいている。例えば、1997 年 1 月頃は New York Times 誌の書評に掲載された本をピックアップし、当該商品を 30% 値引きするといった戦術をとっていた<sup>15)</sup>。また創業時より、独立系書店が持つ文学的な雰囲気醸し出し、顧客が見つげにくい本を推薦するライターと編集者で構成される編



集チームを設置していた<sup>16)</sup>。推薦すべき商品を人間の感性で選び、文章で表現するのである。Amazon.comの転機の一つは、商品の推薦を編集チームの書評によるものから、パーソナライゼーションチームによる推薦システムに変えたことにあった (Mayer-Shönberger & Cukier, 2013, 邦訳 pp.80-83)。顧客が過去に買った本からおすそめを提示するというシンプルなアイデアをジェフ・ベゾスはパーソナライゼーションチームに指示し、チームは顧客の購入履歴データを活用してコンピュータで分析し、顧客が興味を持ちそうな商品を提示する。この機能は購買履歴が似ている顧客をグループ化し、グループ内にアピールする本をお勧めする方法で、シミュラティーズと名付けられ、はっきりと売り上げが上向いたという<sup>17)</sup>。機械学習を用いた推薦システムは次第に改善され、2001年には購入した商品の購入履歴に加え、チェックした商品も分析して推薦する商品を提示するようになった。ジェフ・ベゾスは、2つのチームの成果のみに注目し、試験による比較検討のうえ、最終的にパーソナライゼーションチームのコンピュータによる推薦商品の生成のしくみを採用し、標準化されたレイアウトで画面表示することとなった<sup>18)</sup>。2011年においては、Amazon.comの売上の30%は推薦システムによるおすそめ商品によって生み出されたといわれている<sup>19)</sup>。またAmazon.comマーケットプレイスでは、プラットフォームを利用している販売者が、同社の開発した物流や決済システムに加え、商品の推薦システムを活用可能となるよう水平展開が図られている。

推薦システムとは、ユーザーの嗜好の予測を行った上で、そのユーザーにとって有用な商品、サービスや情報を選び、ユーザーに対して提示するシステムのことである (神鳥, 2007, 2008a, 2008b)。人は、購買行動をしたりサービスを利用したりするとき、しばしばクチコミを参考にしたり、新聞、雑誌やガイドブックなどを参照したりすることで、他者からの推薦に頼っている。推薦システムは、そうした推薦を機械的かつ自動的に実現したものと見える。Amazon.comを利用している際、“Customers Who Bought This Item Also Bought” (日本語版では「この商品を買った人はこんな商品も買っています」) として表示される商品は、推薦システムによって推薦されたものである。

推薦システムが求められる理由として、2つの側面を考えることができる。それは、情報過多 (information overload) への対策としての側面と、個別化 (personalization) のための技術という側面である。

2000年初頭には、情報通信技術やセンサーの発展とともに、大量の情報が生成され、流通されるようになった。ユーザーの探索能力や認識能力を大きく上回る大量の情報を参照できるようになった結果、自分にとって有用な情報を見つけ出せないという状況が生まれた。こうした状況は情報過多といわれる (Eppler & Mengis, 2004)。Eコマースにおいては、物理的な店舗面積に商品数が制限されないため、商品自体についても同じことが成立している。推薦システムには、こうした状況にあって、ユーザーにとって有用な情報を見つけ出す技術という意味合

いがある。

また消費行動自体が、誰もが大量生産された画一的な商品を消費する時代から、自分に合った商品を消費する時代に移り変わっている。少量多品種の商品を、ユーザーの嗜好に合わせて提供するためには、個別化の技術が必要になる。推薦システムには、個別化を実現する技術としての意味合いもある。Amazon.com は推薦システムによって実現される個別化を重視しており、ジェフ・ベゾスは “If I have 3 million customers on the Web, I should have 3 million stores on the Web” (「ウェブに 300 万人の顧客がいるならば、300 万の店舗を持つべきだ」と述べている (Schafer et al., 2001, p.115)。

さらに、推薦システムには、ユーザー一人一人の嗜好を正しく捉える予測の正確さに加え、目新しいアイテムを推薦する性能が要求される。多くの場合、ユーザーが既知っているアイテムを推薦することの有用性は低い。そこで、推薦には新奇性に思いがけなさ、予見のできなさ、意外性を含むセレンディピティが要求される。

### 3.1.3 推薦システムのしくみ

推薦システムの開発と実装において、Amazon.com は先駆的な企業である。そのことは、Amazon.com が複数の特許を持つことのみならず、商品同士の類似度に基づく推薦システムであるアイテム間型協調フィルタリング (Item-to-Item collaborative filtering) を実装し、それが内容ベースフィルタリング (content-based filtering)<sup>20)</sup>、クラスタリング (cluster models)<sup>21)</sup>、ユーザー間型協調フィルタリング (user-to-user collaborative filtering)<sup>22)</sup> という他の推薦システムに対して優位性をもつことを Amazon.com で同システムの開発を担当した Linden が明らかにしたことから示されている (Linden et al., 2003)。

協調フィルタリング (collaborative filtering) においては、他者の行動を利用して、ユーザーの嗜好の予測が行われる。例えば、映画の趣味が似ている別のユーザーが好んだ映画を推薦するなどのことができる。他者の行動を参照する協調フィルタリングは、機械学習を用いたクチコミの一般化と見なすことができる。そして、他者の意見によってではなく、実際の利用行動や購買行動によって推薦が行われるところにクチコミとのちがいがあがる。協調フィルタリングは、ユーザー自身が知らないアイテムでも、他のユーザーの知識を通じて知ることができるため、セレンディピティの実現において有効性を持つ (神野, 2008a)。Amazon.com が導入したアイテム間型協調フィルタリングにおいては、ユーザーは高く評価するアイテムに似たアイテムにも高い評価を与えるという前提に基づき、アイテム間の類似度が用いられる (神野, 2008a, pp.92-95)。アイテム同士の類似度は、アイテムの内容には依拠せず、合わせて購入されたアイテムの組み合わせ履歴に基づいて計算される。アイテム間型協調フィルタリングは、オフラインで計算できる割合が大きく、なおかつ、商品のうちこれまでに購入されたか評価さ

れたかしたものだけを計算の対象とすれば良いので、計算コストの面で優れていて実用的である。

Amazon.com はアイテム間型協調フィルタリングを導入した上で (Linden et al., 2001), ユーザーのショッピングカート内の情報や (Jacobi et al, 2001), セッション中の閲覧履歴を利用することで (Smith et al., Linden & Zada 2005; Linden et al, 2005), 推薦システムの質を高めてきた。

推薦システムにおいては、推薦するアイテムに加えて推薦の理由を合わせて提示すると、ユーザーが推薦を信用し受け入れやすいということが知られている (Sinha & Swearingen, 2002)。このことは、推薦システムの透明性に関わるものとして重要である。Amazon.com が、“Customers Who Bought This Item Also Bought” などの記載をしていることは、透明性を担保するための1つの方策である。

ただし、推薦システムが透明性を持つことと、推薦する理由自体が明らかなこととは異なる。一般に機械学習によってパラメータが最適化されたモデルは、人間が理解可能な形とはならない。まずパラメータ数が多く、量の問題として人間が理解できる範囲を超えているという理由がある。そしてモデル自体が非線形な数式で書かれているため、単純な因果関係で説明出来ないからである。

## 3.2 Google

続いて、Google を取り上げる。まず Google の諸サービスが提供している顧客価値、同社の収益源である検索連動広告のビジネスモデルとその顧客価値を述べる。そして AI 活用の諸サービスを確認しつつ、特にディープラーニングを活用した新たな検索システムの機能である RankBrain について取り上げる。RankBrain は最近の取り組みといわれるが、これらの AI 活用が同社のビジネスにどのような影響を与えているかについて考察する。

### 3.2.1 Google の概略

Google 社は、1998 年 9 月に設立されたインターネット検索のサービスを提供する企業であり、「世界中の情報を整理し、世界中の人々がアクセスできて使えるようにすること」を企業の使命としている<sup>23)</sup>。創業者のラリー・ページ (Larry Page) とサーゲイ・ブリン (Sergey Brin) は、1995 年にスタンフォード大学の大学院で出会い、当時の複数のインターネット検索エンジンがなかなかユーザーの求める情報を見つけれられないという課題を抱えていた状況下、1996 年に検索エンジン Google (当初の名前は BackRub) を 2 人で完成させた<sup>24)</sup>。

そして 1998 年の会社設立後に検索エンジンは無料でユーザーに利用してもらい、事業運営に必要な利益は広告からあげるというビジネス戦略を策定の後、検索連動広告 (リスティング

広告) サービスを開発し、2000年10月に Google AdWords をサービス開始した<sup>25)</sup>。続いて、Web サイト上に配置した Google の広告がクリックされると Web サイト管理者に報酬が支払われるコンテンツターゲットの広告サービス (Google AdSense) を 2003年3月にリリースした。Google AdWords と AdSense で収益化が実現し、2004年8月に、米国の金融市場 NASDAQ に新規株式公開を行い資金調達の後、Google Map の基となる Keyhole 社を 2004年10月に、Android 社を 2005年8月、そして YouTube 社を 2006年10月にと、積極的な M&A を重ね、携帯端末・スマートフォンからアクセス可能で、位置情報や動画情報を駆使した現在の Google の諸サービスに統合していった<sup>26)</sup>。

また、Google は、AI 領域を戦略的に強化している。Google の研究活動を示す Research at Google における論文では、AI と機械学習 (“Artificial Intelligence and Machine Learning”) の領域において 2001年の論文を皮切りに 2015年までに 460本を蓄積していた<sup>27)</sup>。特筆すべきは、2011年より Google Brain プロジェクトと称してディープラーニングを活用した検討を深め、商用サービスに順次展開していることである。Google Brain チームの Research at Google サイトにおける論文は 2012年のものを皮切りに 96本<sup>28)</sup> と精力的である。また、ディープラーニングに関する研究で著名なカナダのトロント大学のジェフリー・ヒントン (Geoffrey Hinton) 教授らが立ち上げた DNN research 社を 2013年3月に買収し<sup>29)</sup>、続いてデミス・ハサビス (Demis Hassabis) らが英国で創業したディープラーニングの先端的な研究を進めていた DeepMind Technologies 社を 2014年1月に買収した<sup>30)</sup>。同社の開発した AlphaGo (アルファ碁) と名付けられた AI の囲碁プログラムは、そのアルゴリズムが 2016年1月に自然科学論文誌 Nature に掲載され<sup>31)</sup>、また囲碁の世界タイトル獲得経験者である韓国のプロ棋士イ・セドルに 2016年3月に歴史的な勝利をした<sup>32)</sup>。

### 3.2.2 Google 検索システムと広告サービス

1995年当時は、複数の検索エンジンが存在していたが、キーワードによる検索では求める情報を素早く見つけられないという課題をユーザーは抱えていた。実際には、Yahoo! (当時) のようなディレクトリ型と呼ばれる、人手により良質な Web サイトが抽出され、英語の Web サイトは ABC 順、日本語の Web サイトはあいうえお順に、こちらも人手により整理されたポータルサイトがユーザーに利用されていた。

Google 共同創業者のラリー・ページは、インターネット検索において、検索結果の中に含まれるリンク (ハイパーリンク) に着目し、「Web ページに張られているリンクの数を数えれば人気度がわかる」という研究論文の引用・被引用のしぐみに近い発想を得た。「多くの良質な Web サイトからつながっている Web ページはやはり良質な Web ページである」という設計ポリシーの PageRank と名付けられたレーティングシステムを開発した。従来の検索エンジ

ンは、ページの内容と検索された単語の関連性からランキングを決めていたが、Google のイノベーションは、PageRank の導入により新しい指標を検索エンジンの世界に持ち込んだ点である。もう1つのイノベーションは、世界中の Web ページの全てをデスクトップにダウンロードしてしまい、予め分析してインデックス化するという大胆な着想である。これらのしくみは、大量の Web ページのデータに対して、高速に応答できる検索エンジンの下地となった<sup>33)</sup>。

1998年に営利企業となった Google は、検索エンジンは無料でユーザーに利用してもらい、事業運営に必要な利益は広告からあげるというビジネス戦略に沿い、検索連動広告 (リスティング広告) である Google AdWords を 2000 年 10 月に開始した<sup>34)</sup>。広告も重要な検索結果の情報と位置づけ、広告主の支払う広告料の多寡ではなく、ユーザーの検索の意図に沿う広告を上位から配置することとし、クリック数の多い広告は検索結果に関連性の高い商品やサービスと位置付け、広告もスポンサーリンクと名付けた。

現時点における検索のランキングシステムは、当初に開発された PageRank に加えて数多くのシグナルを活用して、順位づけされている。シグナルは、ランキングのスコア計算に使用される情報であり、検索に使われる語句であるクエリに非依存のものとクエリに依存するものの2種類がある。クエリに非依存のシグナルは、PageRank、使用言語やモバイルとの親和性などである。クエリに依存するのは、キーワード、類義語や近接性 (proximity) である。その際の重要な測定基準 (metrics) は、Web ページのクエリに対する関連性 (relevance)、品質、応答時間 (早い方がベターとされる) であり、Google は、このデータを大別して2つの方法で測定している。商用サービスにおける実験 (Live Experiments) と人間の評価者による実験 (Human Rater Experiments) である。商用サービスにおける実験では、実際のユーザー利用における A/B テストやユーザーのクリックのパターンの変化などである。人間の評価者による実験は、同社が示す評価ガイドラインをもとに、検索結果に対して検索意図としてのニーズに合った Web ページかの7つの尺度 (Fully Meets, Very Highly Meets, Highly Meets, More Highly Meets, Moderately Meets, Slightly Meets, Fails to meet) と、Web ページの品質がよいかの2つの視点で評価する。Web ページの品質は、専門性、権威 (Authoritativeness)、信頼性 (Trustworthiness) の3つの点である。これらの実験による試行錯誤を重ねて、シグナルや測定基準を改版し続け、新たなシグナルの発見や測定基準の開発を続けながら、検索システムを徐々に改善しているのである<sup>35)</sup>。

### 3.2.3 Google Brain プロジェクト

Google Brain プロジェクトは、AI エリアの最先端をいくために、2011年にはじまった。Google Brain チームのミッションは、「コンピュータをより賢くし、人々の生活をより豊かに

する」であり、メンバーの研究者は自由にテーマ設定ができ、企業全体に成果の展開先をもち、進展の早いこの AI の領域でオープンにアイデアを交換する文化を有している<sup>36)</sup>。同チームをリードするシニア・フェローのジェフ・ディーンによれば、当初の力点は、認識や自然言語理解においてどこまでできるのかを見極めるために、Google が蓄積してきた巨大なデータセットと巨大なコンピューティング資源を活用する点にあった。生のデータとして、英語や他言語の言語データ、写真や動画データ、音声データ、ユーザーの検索履歴やマーケティングメッセージなどがあり、これらのデータを真に理解できる情報システムをどのように構築できるかが課題であった。そして AI の重要な特性として、より多くのデータやコンピューティング資源が、結果をより向上させるということであった。基本的な AI のモデルをプロジェクトチームで構築し、水平展開した。例えば音声認識や画像認識の社内チームと協働しており、2012 年からすでに 20 を超える Google のサービスに適用している、あるいはチーム自身の問題解決に同プロジェクトの成果を活用している。適用されたサービスとしては、Google 検索、Google 音声認識、Gmail、Google Maps and Street View、Google Photos、Google 翻訳、YouTube、Google Apps 等があり、領域は、画像認識、自然言語処理、音声認識、ロボティクス研究などである<sup>37)</sup>。例えば、Gmail では、迷惑メールや広告メール等のフィルタリングを AI が自ら学習しながら行う。同社が提供するメーラーアプリの Inbox は、現時点では英語版に限るが、受信したメールの文面を解釈し、返信の文案を 3 件ほどユーザーに提示し、文案を選択して返信する機能を有している。Google Photos では、写真に写っている人物ごとに AI により分類が行われ、後にユーザーが分類された写真をタグ付けすることにより人物別の写真アルバムを整理することができる。加えて、同プロジェクトの成果を TensorFlow と名付けられた AI プラットフォームのオープンソースプロジェクトに展開している。

### 3.2.4 RankBrain の導入

Google Brain プロジェクトは、近年 Google 検索システムに、RankBrain と名付けられたディープラーニングを用いた AI の機能を適用している。換言すると、Google 検索システムの機械学習の一部である。RankBrain は、Bigdata からパターンやデータを発見する AI として検索結果の処理を支援するために使用されており、過去に行われた検索結果からより効果的だった検索を学習し、特定のクエリに対して最適と想定される Web ページを大量にある中から選択する検索アルゴリズムの一部を担っている。ロングテールのクエリや初めてのクエリに特に効果があるといわれており、例えば「スーパーマリオブラザーズで攻略ガイドを使用せずにクリアできるか?」というようなクエリは、「RankBrain 無しでは、ニーズに合わない検索結果となってしまうが、RankBrain があれば、満足いく結果を得られる」という<sup>38)</sup>。

また RankBrain は、ランキング (順位づけ) を検索結果として導き出すためのシグナル (要

素)の1つといえる。新しくユニークなシグナルで、検索結果との関連性を強化する。ランキングでは、Web ページのコンテンツやリンクが重要なシグナルだが、RankBrain も重要なシグナルであり、そもそもシグナルは非常に多数から構成されており、ランキングに重要なシグナルは、クエリごとに違うのである。RankBrain は、シグナルのサブセットをチェックし、どのようにシグナルを結合するか、どのように文章を理解しようとするかといった固有の認識 (ideas) を持つディープラーニングのシステムなのである。そして、「(内部の Google ランキング・エンジニア曰く) 正直なところ、我々からしても、AI がどのように作動しているか、理解するのに長い時間をかけているし、いまだに正確に何をしているか理解しようとしている」という<sup>39)</sup>。

#### 4. ディスカッション

本稿の研究関心は、AI を活用したネットビジネスにおけるマーケティング実践における、「結果」と「理由」の捉え方についてであった。

まず、Amazon.com と Google において、蓄積したビッグデータを分析する AI を活用した商用サービスが提供されている事実が確認された。それぞれの企業は、AI の活用について類似点と相違点を有していた。Amazon.com においては、会員であるユーザーの当該ユーザーの Web サイトがパーソナライゼーションされる。同社の AI を活用した推薦システムにより、同社の過去の商品購入履歴、閲覧履歴などのビッグデータに基づいて、ユーザーごとにダイナミックに商品陳列が行われるのである。同時に、この陳列は、情報システムにより逐次学習されているため、近い属性や行動履歴をもつ他ユーザーの「結果」に基づいており、同社の人間がその陳列の「理由」を必ずしも正確に説明できるわけではない。同様に Google では、各ユーザーの検索ごとのクエリについて、ダイナミックに検索結果を構成して提供している。スポンサーリンクと呼ばれる広告も検索結果の一部であるという同社の検索サービスのコンセプトから、ユーザーの検索の都度、表示される検索結果の中に同社の収益機会が発生していると考えられる。ただし、ユーザーの検索意図に合わない情報システムが判断した場合は、ユーザビリティが最優先されるため、必ずしも広告が表示されるわけではない。既に商用サービスに適用されている RankBrain では、ディープラーニングを活用した AI の特性から、人間がその検索結果の「理由」を把握することが困難であるが、ユーザーの反応としての「結果」を学習させながら、検索の精度を高めようとしている。また同社は Gmail 等の諸サービスにも AI を積極展開している。特に AI を導入することにより、「理由」の重要性が下がるのみならず、「理由」の特定自体がより困難となることが重要である。

ここで、なぜ Amazon.com と Google は、「結果」をより重視した実践を行うのかを考えた

い。まず第 1 に、マーケティング実践の目的を需要の最大化とするならば、ユーザーニーズとしての「理由」を把握しきれない歯がゆさはあるかも知れないが、「結果」を重視して、この点にフォーカスする企業実践は、合理的な態度と考えられる。加えてビッグデータは蓄積すればするほど情報の多重利用の可能性が広がることから、ユーザーの実際のサービス利用を促進することにフォーカスすることはデータが蓄積されることとなり、将来の需要を伸ばす投資的な実践になっていると考えられる。第 2 に、ネットビジネスならではのユーザーニーズの探索コストの低さがある。物理的な商品をデザインして製造するわけではなく、情報のやりとりに係るコストが大半であるため、商用環境におけるニーズ把握の試行を行いやすい。たとえ試行が効果的に機能しなかった場合でも、これまで培ったアルゴリズムを再適用するなどロールバックすることで大幅な需要減を回避することができるため、リスクを限定的におさえることも可能なのである。第 3 に、ユーザーへの提案に際して、複雑な環境要因を取り込むことのメリットである。伝統的なマーケティングリサーチでは、ユーザーニーズの把握において、検証環境が静的で限定的なものにならざるを得ない。いわゆる調査用パネルデータの利用は、限定的な属性や調査インセンティブの必要性などバイアスを除くことはできず、また購入意図と実際の購入行動の把握におけるギャップも否定しきれない。一方、商用環境において A/B テスト等による検証を行う場合、複雑でダイナミックな環境要因を取り込むことができる。ユーザーの行動は、他者とのコミュニケーションやテレビ、雑誌や Web といったメディア等による時々刻々とした影響も受けており、個人を取り囲む各種イベント等の一過性の状況も数多く想定される。したがって、商用環境における実践では、ユーザーの購入意図といった「理由」は特定しがたいが、複雑な環境要因を取り込んだ「結果」の確からしさが勝るのである。以上の 3 点から、AI を活用したネットビジネスにおいてユーザーがなぜ選択したのかの「理由」を特定しきれないまま、実環境で得た「結果」を重視して、実際のサービスの提供方法を変更し、試行を重ねながらユーザーニーズに適応する実践方法の有効性が見出されるのである。

## 5. おわりに

本稿の目的は、AI (Artificial Intelligence : 人工知能) を活用したネットビジネスの発達に注目し、マーケティング実践における「結果」と「理由」の捉え方の変化を示すことにあった。そして、既述のとおり、「結果」を重視する実践がネットビジネスを中心に発展している可能性を実際のユーザーニーズの探索プロセスやアルゴリズムの詳細を検討しつつ確認した。この傾向は、仮説を重視する従来のマーケティングリサーチと異なっているが、有効性という点では、AI を駆使することにより「理由」よりも「結果」を重視できる時代に入りつつあることが確認された。その主な根拠としては、まずマーケティング実践の目的を需要の最大化と



した場合において、「結果」を重視した企業実践は、合理的な態度と考えられる点である。また Bigdata の蓄積そのものを促進することが将来への投資的活動ともいえる。次に、ネットビジネスならではのユーザーニーズの探索コストの低さである。最後に、ユーザーへの提案に際して、ダイナミックに進行する複雑な環境要因を取り込むことのメリットである。商用環境における実践では、ユーザーの購入意図といった「理由」は特定しがたいが、複雑な環境要因を取り込んだ「結果」の確からしさに勝る点があげられる。これらのメリットが、AIの導入により「理由」を特定する困難さが増すことを補って余りあることを Amazon.com と Google の事例は示しているといえよう。

しかしながら、「結果」重視の実践は、インプリケーションと同時に課題も浮かびあがらせる。第1にビッグデータを蓄積しAIを活用しながら複雑でダイナミックな環境に適応させる実践は、他のネットビジネスへの実践的なインプリケーションと考えられる。しかし、ユーザーニーズの因果を特定しきれないことから、水平展開が容易ではない。特定条件下の実践の「結果」であり、再現させることが難しい。マーケティング研究の側面で見れば、ユーザーニーズに係る因果関係に関する理論蓄積がしづらいついていえるかも知れない。第2に、豊富なビッグデータの蓄積やトラフィックによる検証を前提とするため、一定規模のサービスを確立されるまでの手立てに対する解にはならない。Googleは、現在もなお、人間による検索結果の評価を行い、AIのオフライン学習用のデータ蓄積に余念がない。AIには、良質な学習用のデータがあって初めて、効果的な学習をすることができるのであり、この点が改めて確認される。

#### 謝辞

本研究は、公益財団法人電気通信普及財団「情報通信に関する法律、経済、社会、文化的研究調査への助成（平成28年度）」及び日本マーケティング学会リサーチプロジェクト「AI研究会」の成果の一部である。ここに記して謝意を表したい。

#### <注>

- 1) 機械学習（Machine Learning）は、得られたデータから、主として分類のための隠れたパターンや法則、規則などを見つけ出す一連の手続きを指す。学習の結果として見つけ出されたパターンに新たなデータを当てはめることで、将来の予測を得ることができる。機械学習においては、まず、センサーやデータベースなどからデータが取得される。その上で、それらのデータに適合する形で、解決したい問題を数理的に表現したモデルが構築される。モデルは、入力したデータに対して、次に起こることの予測を行う形で作られる。構築されたモデルには、パラメータが含まれており、パラメータの値によってモデルの性能、つまり、予測の精度が左右される。それらのパラメータの値は、入力データに対してアルゴリズムによる処理が行われることで、自動的に最適化される。データという経験からモデルの性能向上が自動的に実現されるため、パラメータが決められることが学習と見なされる。

- 2) 深層学習 (ディープラーニング, Deep Learning) については, 松尾 (2015) を参照する。ディープラーニングは, 新たな機械学習の方法としてデータをもとに自らがモデルに含まれる特徴量を作り出す。「特徴量は, 機械学習の入力に使う変数のことで, その値が対象の特徴を定量的に表す。この特徴量に何を選ぶかで, 予測精度が大きく変化する」(同, p.135)。従来の機械学習は人間が特徴量を設計する必要があったが, ディープラーニングはコンピュータ自らが高次の特徴量を獲得する (同, p.147)。
- 3) A/B テスト (A/B Test), あるいは, バケットテスト (Bucket Test) は, 2つのバージョン A と B のうち, どちらが優れているかをユーザーの支持を直接測定することでテストする手法である (Kohavi, Longbotham, & Walker, 2010)。近年, 実験室のような理想的な環境における実験ではなく, 現実世界の中で実験の手法を行うフィールド実験に注目が集まっており (Harrison & List, 2004), A/B テストはそのうちのひとつと見なすことができる。A/B テストにおいては A を統制群として扱った上で, B がどの程度優れているか, あるいは劣っているかが調べられる。ウェブページのデザインを変更する際に頻繁に用いられ, 一部のユーザーが新しいデザインを見るようにランダムに割り当てられた上で, 閲覧時間やクリック先などが測定され, 新しいデザインにどのような効果があるのかがリアルタイムで調べられる。企業はその結果に従って, 望ましい効果を持つデザインを採用することができる。A/B テストは企業内の特定の個人の意見に依存するのではなく, 市場の声に意思決定を委ねる方法といえる。そこでは, 個人の意見を支える因果関係の説明よりも, ユーザーの多数決, あるいは, 集合知によって導き出された結果が重視される。
- 4) Christian, B. (2012), "The A/B Test: Inside the Technology That's Changing the Rules of Business", Wired ([http://www.wired.com/2012/04/ff\\_abtesting/](http://www.wired.com/2012/04/ff_abtesting/)) (2016 年 8 月 24 日閲覧)
- 5) Stone (2013, 邦訳 pp.32-52) をもとに作成
- 6) Stone (2013, 邦訳 pp.50-52)
- 7) Stone (2013, 邦訳 p.123) をもとに作成
- 8) Stone (2013, 邦訳 p.164) をもとに作成
- 9) Amazon.com Press Release (<http://phx.corporate-ir.net/phoenix.zhtml?c=176060&p=irol-newsArticle&ID=1079388>) (2016 年 8 月 26 日閲覧)
- 10) Stone (2013, 邦訳 pp.270-272)
- 11) Amazon.com IR 資料 (<http://phx.corporate-ir.net/phoenix.zhtml?c=97664&p=irol-reportsOther>) (2016 年 8 月 21 日閲覧) をもとに作成
- 12) Amazon Machine Learning(<https://aws.amazon.com/jp/machine-learning/>)
- 13) <http://www.geekwire.com/2016/report-amazon-sold-3-million-echo-smart-speakers-awareness-grows/> (2016 年 8 月 21 日閲覧)
- 14) Stone (2013, 邦訳 p.189) をもとに作成
- 15) ジェフ・ベゾス氏の説明映像を確認。CNET. (<http://japan.cnet.com/news/business/35067474/>) (2016 年 8 月 21 日閲覧)
- 16) Stone (2013, 邦訳 p.189) を引用
- 17) Stone (2013, 邦訳 p71) をもとに作成
- 18) Stone (2013, 邦訳 p.190) をもとに作成
- 19) Economist 誌 Web サイト (<http://www.economist.com/node/18741392>) (2016 年 8 月 10 日閲覧)
- 20) 推薦システムのアルゴリズムとして, アイテムそのものの特徴を利用したものが内容ベースフィルタリングである (神寫, 2008a, pp.89-91 ; 2008b, pp.248-249)。例えば, 映画には題名, 監督, ジャンル, 俳優, 制作年数などの情報がある。よって, ユーザーに好きな監督や好きなジャンルを尋ねることで, 条件に合った映画を推薦することができる。内容ベースフィルタリングでは, アイテムそのものの特徴をあらかじめつかんでおき, ユーザーの嗜好に合ったアイテムを推薦する。通常, ユーザーは, 監督名などの自分の好きな情報を検索ワードとして打ち込み, 推薦システムは検索への応答として商品を提示する。よって, 内容ベースフィルタリングは, 検索ベース (search-based methods) のアルゴリズムとも呼ばれる。内容ベースフィルタリングは, 推薦システムとして理解しやすいが, セ

レンディビティという観点では劣っている。また、多くの買い物や商品への評価をするユーザーほど嗜好がわかって然るべきであるが、内容ベースフィルタリングでは、ユーザーの行動履歴を生かすににくいという欠点がある。

- 21) クラスタリングは、セグメンテーションを実現するアルゴリズムである (神島, 2008a, p.96)。マーケティングにおいては嗜好や属性の似たユーザーを同じ集団に属するものと見なし、ユーザーをセグメンテーションすることが行われる。しかし、クラスタリングは、数多くのユーザーを同一のセグメントに属する存在と見なすことに優位性があるので、個別化が必要な場合には向いていない。ユーザー数の増加とともにセグメントの数も増やさざるを得ないが、それには大きな計算コストがかかる上に、十分な個別化は実現しにくいという欠点がある。
- 22) 従来型の協調フィルタリング (traditional collaborative filtering) ともいえるユーザー間型協調フィルタリングでは、ユーザー間の類似度に基づいて、不明な評価値を予測することになる (神島, 2008a)。一般に、全てのアイテムに対する全ユーザーの評価が明らかになっているわけではないので、限られた評価を元に不明な評価値の予測を行うことになる。特定のユーザーの特定のアイテムに対する評価は、しばしばコサイン類似度によって計算されるユーザー間の類似度に基づいて求められるか、共通して評価したアイテムのある他のユーザーとの評価値の相関係数を計算することで求められる。ユーザー間型協調フィルタリングは、ユーザーがサービスを利用していないオフラインの時間に計算しておける部分が少なく、毎回の推薦の際に計算が必要になる。とくにユーザー数と商品数が多い場合、その計算量が大きくなる。一方で、計算量を削減しようとデータセットを縮約すると、個別化が失われてしまうという欠点がある。
- 23) Google. (<https://www.google.co.jp/about/company/>) (2016年8月10日閲覧)
- 24) Vise& Malseed (2005, 邦訳) および Google. (<https://www.google.co.jp/about/company/>) (2016年8月10日閲覧) をもとに作成
- 25) Vise& Malseed (2005, 邦訳) および (<https://www.google.co.jp/about/company/>) (2016年8月10日閲覧) をもとに作成
- 26) Vise& Malseed (2005, 邦訳) および (<https://www.google.co.jp/about/company/>) (2016年8月10日閲覧) をもとに作成
- 27) 総務省ホームページ。一般財団法人マルチメディア振興センター (2016) 「欧米における AI ネットワーク化に関連する政策・市場動向」, pp.19-20. ([http://www.soumu.go.jp/main\\_content/000414765.pdf](http://www.soumu.go.jp/main_content/000414765.pdf)) (2016年8月10日閲覧)
- 28) Research at Google (<http://research.google.com/pubs/papers.html>) 参照 (2016年8月10日閲覧)
- 29) トロント大学のリリース (<http://media.utoronto.ca/media-releases/u-of-t-neural-networks-start-up-acquired-by-google/>) (2016年8月21日閲覧)
- 30) REUTER 通信 (<http://www.reuters.com/article/us-google-deepmind-idUSBREA0Q03220140127>) (2016年8月21日閲覧)
- 31) Nature. <http://www.nature.com/nature/journal/v529/n7587/pdf/nature16961.pdf> (2016年8月10日閲覧)
- 32) 日本経済新聞電子版. ([http://www.nikkei.com/article/DGXLASFG15H37\\_V10C16A3000000/](http://www.nikkei.com/article/DGXLASFG15H37_V10C16A3000000/)) (2016年8月10日閲覧)
- 33) Vise& Malseed (2005, 邦訳) および Brin & Page (1998) をもとに作成
- 34) Vise& Malseed (2005, 邦訳) および Google. (<https://www.google.co.jp/about/company/>) (2016年8月10日閲覧) をもとに作成
- 35) Google 社 Ranking エンジニアの Paul Haahr スピーチ動画。Search Marketing Expo, “SMX West 2016 - How Google Works: A Google Ranking Engineer’s Story” ([https://www.youtube.com/watch?v=iJPu4vHETXw&index=8&list=PLirrl2D\\_HdXsTZtx78cFVf8iG7xo-g5Ny](https://www.youtube.com/watch?v=iJPu4vHETXw&index=8&list=PLirrl2D_HdXsTZtx78cFVf8iG7xo-g5Ny)) (2016年8月10日閲覧) をもとに本パラグラフを作成
- 36) Google Brain チーム. (<http://research.google.com/teams/brain/about.html>) (2016年8月10日閲覧)

- 37) Google 社のシニア・フェロー ジェフ・ディーン (Jeff Dean) 氏の研究資料。"Large-Scale Deep Learning for Intelligent Computer Systems" (<http://static.googleusercontent.com/media/research.google.com/ja/people/jeff/BayLearn2015.pdf>) (2016 年 8 月 10 日閲覧), Google Brain チーム。(<http://research.google.com/teams/brain/about.html>) (2016 年 8 月 10 日閲覧), 及び SPARK SUMMIT におけるプレゼン動画 Apache Spark。"Large Scale Deep Learning with TensorFlow" (<https://www.youtube.com/watch?v=XYwIDn00PAo>) (2016 年 8 月 10 日閲覧) をもとに作成。なお, ジェフ・ディーン氏は Google の分散処理のための基盤技術である MapReduce を開発している (<http://static.googleusercontent.com/media/research.google.com/ja/archive/mapreduce-osdi04.pdf>) (2016 年 9 月 12 日閲覧)。
- 38) 米 Google 社 Webmaster Trends Analyst の Garry Illyes スピーチ動画。Growth Crew。"SMX Advanced 2016 Keynote - AMA With Garry Illyes from Google Search" ([https://www.youtube.com/watch?v=SOHle1KY790&index=7&list=PLlrrl2D\\_HdXsTZtx78cFVf8iG7xo-g5Ny](https://www.youtube.com/watch?v=SOHle1KY790&index=7&list=PLlrrl2D_HdXsTZtx78cFVf8iG7xo-g5Ny)) (2016 年 8 月 10 日閲覧) をもとに作成。
- 39) 米 Google 社 Software Engineer の Paul Haahr と Webmaster Trends Analyst の Gary Illyes のスピーチ動画。Google Engineer とのやりとりにおいて, 司会者は「Google でさえ RankBrain が何をしているかわかっていないようです」とまとめている。Search Marketing Expo (SMX)。"How Google Works: A Google Ranking Engineer's Story Q&A." (March 23th 2016) ([https://www.youtube.com/watch?v=eGSGZMI4Z\\_I&list=PLlrrl2D\\_HdXsTZtx78cFVf8iG7xo-g5Ny&index=9](https://www.youtube.com/watch?v=eGSGZMI4Z_I&list=PLlrrl2D_HdXsTZtx78cFVf8iG7xo-g5Ny&index=9)) (2016 年 8 月 10 日閲覧) をもとに作成

<参考文献：欧文献>

- Aaker, David A., & George S. Day (1980), *Marketing Research*, John Wiley & Sons, Inc. (石井淳蔵・野中郁次郎訳『マーケティングリサーチ』白桃書房, 1981年)。
- Brin, Sergey & Lawrence Page (1998) "The anatomy of a Large-Scale Hypertextual Web Search Engine," *Computer Network*, Vol.30, pp.107-117.
- Eppler, Martin J. & Jeanne Mengis (2004) "The Concept of Information Overload: A Review of Literature from Organization Science, Accounting, Marketing, MIS, and Related Disciplines," *The Information Society*, 20(5), pp.325-344.
- Harrison, G.W., & List, J.A. (2004). "Field Experiments". *Journal of Economic literature*, 42(4), 1009-1055.
- Hashem, I.A.T, I. Yaqoob, N.B Anuar, S. Mokhtar, A. Gani, & S.U. Khan (2015) "The rise of "big data" on cloud computing: Review and open research issues," *Information Systems*, Vol.47, pp.98-115.
- Jacobi, J.A., Benson, E.A., & Linden, G.D. (2001), "Use of electronic shopping carts to generate personal recommendations," *U.S. Patent* No.6, 317, 722. Washington, DC: U.S. Patent and Trademark Office.
- Kohavi, R., Longbotham, R., & Walker, T. (2010), "Online experiments: Practical lessons," *Computer*, 43(9), 82-85.
- Levitt, Theodore (1960), "M-R Snake Dance," *Harvard Business Review*, Nov.-Dec.1960. (有賀裕子訳「購買意欲調査をめぐる狂想曲」『T. レビット マーケティング論』ダイヤモンド社, 2007年, 38-58頁)。
- Linden, G.D., Jacobi, J.A., & Benson, E.A. (2001), "Collaborative recommendations using item-to-item similarity mappings," *U.S. Patent* No.6, 266, 649. Washington, DC: U.S. Patent and Trademark Office.
- Linden, G., Smith, B., & J. York (2003) "Amazon.com Recommendations: Item-to-Item Collaborative Filtering," *IEEE Internet Computing*, Vol.7, No.1, pp.76-80.

- Linden, G.D., Smith, B.R., & Zada, N.K. (2005), "Use of product viewing histories of users to identify related products." *U.S. Patent* No.6, 912, 505. Washington, DC: U.S. Patent and Trademark Office.
- Mayer-Schönberger, V., & K. Cukier (2013). *Big data: A revolution that will transform how we live, work, and think*, Houghton Mifflin Harcourt.
- Mayer-Schönberger, V., & K. Cukier (2013). *Big data: A revolution that will transform how we live, work, and think*, Houghton Mifflin Harcourt. 齊藤栄一郎訳『ビッグデータの正体』講談社, 2013年)
- Page, L., Sergey B., R. Motwani, & T. Winograd (1998) "The PageRank Citation Ranking," *Stanford InfoLab*, pp.1-17.
- Schafer, J.B., Konstan, J.A., & J. Riedl (2001) "E-commerce recommendation applications," *Data Mining and Knowledge Discovery*, Vol.5, pp.115-153.
- Sinha, R., & K. Swearingen (2002) "The role of transparency in recommender systems," *Proc. of the SIGCHI Conf. on Human Factors in Computing Systems*, pp.830-831.
- Smith, B.R., Linden, G.D., & Zada, N.K. (2005), "Content personalization based on actions performed during a current browsing session," *U.S. Patent* No.6, 853, 982. Washington, DC: U.S. Patent and Trademark Office.
- Stone, B. (2013). *The Everything Store: Jeff Bezos and the Age of Amazon*, Little, Brown and Company. (井口耕二訳『ジェフ・ベゾス 果てなき野望』日経 BP 社, 2014年)
- Vise, A. David & M. Malseed (2005). *THE GOOGLE HISTORY*, Random House Inc. (田村理香訳『Google 誕生』イーストプレス, 2006年)
- Watts, D.J. (2011), *Everything is Obvious: Once You Know the Answer*, New York, Crown Business. (青木創訳『偶然の科学』早川書房, 2012年)

<参考文献：和文献>

- 内田和成 (2006) 『仮説思考』東洋経済新報社。
- 神嶋敏弘 (2007) 「推薦システムのアルゴリズム (1)」『人工知能学会誌』, 22 (6), 826-837 頁。
- 神嶋敏弘 (2008a) 「推薦システムのアルゴリズム (2)」『人工知能学会誌』, 23 (1), 89-103 頁。
- 神嶋敏弘 (2008b) 「推薦システムのアルゴリズム (3)」『人工知能学会誌』, 23 (2), 248-263 頁。
- 勝見明 (2006) 『鈴木敏文の「統計心理学」』日経ビジネス文庫。
- 苅谷剛彦 (2002) 『知的複眼思考法』講談社。
- 黒岩健一郎・水越康介 (2012) 『マーケティングをつかむ』有斐閣。
- 小谷善行 (2014) 「コンピュータ将棋の棋力の客観的分析—人間のトップに到達したか?」『情報処理』, 55 (8), 851-852 頁。
- 西垣通 (2016) 『ビッグデータと人工知能』中公新書。
- 西川英彦・廣田章光 (2012) 『1からの商品企画』碩学舎。
- 本條晴一郎 (2014) 「災害時の情報支援におけるニーズ発見およびニーズへの対応」『マーケティング・ジャーナル』, 34 (1), 54-72 頁。
- 松尾豊 (2015) 『人工知能は人間を超えるか』KADOKAWA。
- 松原仁 (2015) 「コンピュータ将棋プロジェクトの終了宣言」『情報処理』, 56 (11), 1054-1055 頁。
- 矢野和男 (2016) 「人工知能は組織とコミュニケーションをどう変えるか」『組織科学』, 49 (4), 41-51 頁。

# A Consideration of the “Result” and “Reason” in the Exploration Process of the User Needs utilizing AI: From Cases of Amazon.com and Google

Yuichi Yoda \*

Kosuke Mizukoshi \*\*

Seiichiro Honjo \*\*\*

## Abstract

The purpose of this paper is to show the change of recognition of “result” and “reason” in marketing practice focusing on net business utilizing AI.

Recently it has been possible to analyze Bigdata through the development of information technology, extensive computing resources and advanced AI research. Especially some leading internet companies have tried to provide commercial services and experimental services utilizing dynamic environment called “A/B TEST” simultaneously. And they get the result of user’s choices in real-time, try to analyze the results and renew services and algorithm based on user’s feedback. In the field of internet business practice, the reasons why users selected things clearly and precisely are not provided. It is possible to thereby change the method of providing services based on the result obtained in a real environment. These practices are different from the traditional marketing research methods in the way of survey and experiment based on setting hypothesis and questionnaire in the advance of product development. Through the development of AI and Bigdata thus far, “result” might be regarded more important than hypothesis and “reason” in the field of marketing research and marketing practice.

In this paper, firstly we consider the theoretical issues for this research based on the research interest. Then we consider Amazon.com and Google because of their AI based and advanced internet services. we are interested on how to explore user’s needs utilizing AI and Bigdata.

---

\* Associate Professor, Department of Business Administration, Ritsumeikan University

\*\* Associate Professor, Business school, Tokyo Metropolitan University

\*\*\* Visiting Research Fellow, The Research Institute for Innovation Management, Hosei University

In conclusion it shows the effectiveness of result-based practice than reason-based practice. Specifically, it is effective for internet companies that they get the result of user's choices in real-time, try to analyze the results and renew services and algorithm rapidly based on user's feedback utilizing AI and Bigdata.

**Keywords:**

AI, Bigdata, Exploration of user's needs, Internet business, Marketing

