

日本大学経済学部経済科学研究所研究会

【第211回】

2020年11月14日

**2018～2019年度共同研究A成果報告**  
**「AIがもたらす産業へのインパクト」**

〈発表者〉

日本大学経済学部教授	大 槻	明
日本大学経済学部教授	米 澤	聡 士
日本大学経済学部教授	坂 野	徹
日本大学経済学部特任教授	大 澤	秀 雄
日本大学経済学部非常勤講師	江 上	哲
岐阜協立大学経営学部講師	井 口	詩 織

## 「AIがもたらす産業へのインパクト」

日本大学経済学部教授 大槻 明

それでは定刻になりましたので経科研AIプロジェクト研究成果発表会を行ないたいと思います。

私はこのプロジェクトの代表者の大槻と申します。よろしくお願いします。

今日はzoomで開催ということですが、AIプロジェクトの各メンバーと、陪席として経済科学研究所の酒巻先生と呉先生にご参加いただいています。行武ゼミにもご参加いただいているということで大人数のイベントとなっていますけれども、よろしくお願いいたします。

まずは下の表（資料1）をごらんください。こちらが本日のタイムテーブルになっています。いま私が説明しているのが「はじめに 趣旨説明」という箇所ですが、今日は報告が6件あります。

まず1件目は、大槻・坂野先生の共同研究の発表で、「AIの概要、変遷及び今後の展望」ということで、技術的な側面からAIの歴史などについて体系的に整理した研究成果報告となっています。2件目と3件目はAIの基礎技術に関する研究成果の報告になっています。4件目、5件目はAIの応用的な研究成果の報告になっていまして、それぞれ、人的資源、マーケティングの観点から報告をいただく予定です。6件目はマーケティングの見地からAIの問題と今後の展開についてご報告いただいて、最後にまとめという流れになっています。

発表時間は、1人当たり質疑を含めて15分を目安としています。あくまで目安であり、16時終了を目標時間にしていますけれども、前後するかもしれませんのでその際はご容赦ください。

早速1件目の報告を行います。大槻・坂野先生の共同研究で、「AIの概要、変遷及び今後の展望」というタイトルで、私・大槻がご報告いたします。

## 「AIの概要、変遷及び今後の展望」

日本大学経済学部教授 大槻 明, 坂野 徹

(資料2) スライドをご覧ください。いまAIで最もホットな技術としてDeep Learningが注目されています。このDeep Learningの歴史は浅くて、まずは1950年代にパーセプトロンが提唱されて、これが第1次AIブームと言われています。そして80年代に入ると、パーセプトロンが発展したニューラルネットワークが台頭してきます。これが第2次AIブームと言われています。いまは第3次以降のAIブームと言われていますけれども、2000年以降にDeep Learningが登場したという、簡単な変遷になっています。

(資料3) では、パーセプトロンから説明していきたいと思います。右上の図をご覧ください。パーセプトロンとは、我々の脳細胞の表面的な構造の一部を模倣したものです。我々人間はさまざまな情報伝達物質を樹状突起で吸い上げて、軸索を通るときに（情報学的な表現をすると）重みがつけられて、それによって、次にどこの細胞に行きましょう、どの細胞と結合しましょう、分離しましょう、といった複雑な動きをやっているわけです。このように情報伝達物質をやりとりすることで、我々人間は記憶をしたり考えたり、ということをやっています。この表面的な脳の構造を情報学的にモデル化したものがパーセプトロンというものです。さまざまな入力値に重みをかけて、それを線形結合といいますか、合算をして、その結果をもとに出力をするという簡単なモデルです。このパーセプトロンが登場したことによって、コンピュータが簡単な判断や分類などを行えるようになったと言われています。いわゆる論理演算というものです。その一つがANDゲートというもので、AND論理演算です。

(資料4) この表をご覧ください。入力値が $x_1$ と $x_2$ 、出力が $y$ という簡単な論理演算です。ANDゲートというのは入力値 $x_1$ と $x_2$ がともに1の場合のみ、出力 $y$ に1を出力するというモデルです。その他は0を出力するということですね。ここで、たとえば1をtrue、0をfalseとすれば、コンピュータがtrue、falseの判断をできるようにするというようになります。

(資料5) こちらはもう1つの例のORゲートです。 $x_1$ と $x_2$ のどちらかに1が立っていれば $y$ には1を出力する。両方1の場合も1を出力する、というモデルです。

(資料6) こちらがパイソンでパーセプトロンを実装した例になります。

(資料7) しかし、このパーセプトロンはすぐに限界を迎えました。具体的にはXORゲートをうまく処理することができないという問題に直面したわけです。たとえば先ほどのANDゲートの場合ですと、X軸を入力値 $x_1$ 、Y軸を $x_2$ とした場合に、入力値が1、1のときだけtrueですので、ほかが全部falseとなった場合は、ちょうどこのあたりで線形分離ができるわけです。ORゲートの場合はここで線形分離ができるということです。しかし、XORゲートとORとの違いは、入力値 $x_1$ 、 $x_2$ ともに1の場合は、ORゲートでは1を出力してしまいましたが、XORゲートでは0を出力する。つまり、 $x_1$ か $x_2$ 、どちらかに1が立っているときだけ $y$ に1を出力するという論理演算になりますので、この場合は、左下の図のようなイメージになってしまうので、直線では線形分離ができないという問題に直面したということです。

(資料8) そこで登場したのがニューラルネットワークになります。具体的に先ほどのXORゲートをどのように解決したかという、多層パーセプトロンによって解決をしたということです。これはどういうモデルかという、入力値 $x_1$ 、 $x_2$ のOR値と $x_1$ 、 $x_2$ のNAND値をそれぞれ算出して、この2つのANDをとるというモデルです。NANDというのは $x_1$ 、 $x_2$ 「両方が真」ではないという論理演算になります。つまり、入力値 $x_1$ 、 $x_2$ のNANDとORを算出して、この2つのANDをとったものを出力値にするということで、これが多層パーセプトロンといいます。これがニューラルネットワークの原型になっているということですね。

ここでニューラルネットワークの重要なポイントをまとめておきます。大きくは2つありますが、1つは行列の内積演算によって膨大な入力値（ビッグデータ等）を簡単にまとめることができるようになったということです。もう1つがシグモイド関数です。まずは1つ目の内積ですが、これは行列の形状、shapeの性質をうまく活用しています。

(資料9) スライドをご覧ください。行列1が3行2列、行列2が2行4列で構成されているとします。この場合、1つ目の行列の列の形状と2つ目の行列の行の形状が一致していれば、簡単に言うとこの2つを取り除いて3行4列の行列としてまとめることができるということです。これがshapeの重要な性質です。

(資料10) たとえばこれは片方の行列が2行1列のイメージなんですけれども、こういう形であっても同じ性質が成り立ちます。この場合、1つ目の行列の列と2つ目の行列の行が一致していれば、この2つを取り除いて3行1列の行列としてまとめることができるということです。ニューラルネットワークではこの性質をうまく利用しています。

(資料11) こちらは入力値が $x_1, x_2$ で、値がそれぞれ1と2が与えられていると思ってください。そして、この1, 3, 5が $x_1$ に対する重み。たとえば1というのは $x_1$ が出力の $y_1$ に行く際の重みということです。 $x_2$ は2, 4, 6がそれぞれ重み付けされているというふうに理解してください。そうすると、このような行列演算になるということです。1, 3, 5というのは $x_1$ に対する重み、2, 4, 6は $x_2$ に対する重みということですね。つまり、この掛け算は2行1列と2行3列の掛け算として表されるということです。そしてこの2という形状が一致しているので、結果、1行3列の行列としてまとめることができるということです。これがニューラルネットワークの内積演算です。これをうまく利用すると、たとえば入力値が何万だった場合でも出力のニューロンが何万だった場合でも、このように1つの行列としてまとめることができるということになる。そういうことでビッグデータにも対応できるようになったということです。

(資料12) 二つ目の重要なポイントがシグモイド関数ですが、その前に具体的にニューラルネットワークではどのような計算をしているかということ、こちらの図では、0層が入力層で、第3層が出力層と思ってください。そして、1層、2層が隠れ層というイメージを表示しています。まず0層から1層にかけての計算ですが、入力値 $x_1$ に対する $W$ というのは重みです。 $x_2$ も同様に重みかけられて、最後にバイアスが足されるということです。つまり、重み付き入力値の総和にバイアスが加えられたものが第1層の $a$ になります。さらにこ

の $a$ をシグモイド関数で変換することで $z$ に変えています。次に第2層を計算するときは $z$ が $x_1, x_2$ のような入力値になるということです。そして、同じように重みかけられてバイアスが足されて $a$ を計算して、それをシグモイド変換して $z$ に変えて次に渡すということを繰り返しています。これがニューラルネットワークの原理です。

(資料13) シグモイド変換というのは何かというと、こちらはステップ関数なんですけれども、ステップ関数というのは0か1の値しかとりません。対してシグモイド関数で変換すると、0から1の実数値に変換できます。これが最大の特徴です。つまり、重みつき入力値の総和にバイアスを加えた $a$ を0から1の実数に変換するために、シグモイド関数で変換をしているということです。また $z$ の値を入力値として第2層の $a$ を計算して、それをシグモイド変換して0, 1に変えて次に渡すということをやっています。つまり、情報伝達物質が脳細胞を駆け巡るように、うまく重みとバイアスで調整しながら、最適ルートをとって、最適な出力にたどり着くということをやっているのがニューラルネットワークです。Deep Learningも原理としては同じですので、これが最大の特徴かなと思います。

(資料14) なぜニューラルネットワークやDeep Learningが画像に強いと言われているのかというと、画像というのは輝度値から構成されています。輝度値というのは0から255までの色情報と思っていただければ結構です。色情報というのは光の3原色です。Rでいうと、0だったら白、255だったら赤ということですね。今回例示するのは手書き数字なんですけれども、これは数字の5を手で書いた画像です。これをニューラルネットワークで推論することができるのですが、この手書き数字の5の画像は $28 \times 28$ のサイズです。この場合、 $28 \times 28 = 784$ 個の輝度で構成されているということです。そして、1個1個の輝度に色情報があり、784個の輝度値からこの手書き数字の5の画像は構成されているということです。そして画像の輝度値を入力値に設定して、出力は数字を推論しますので0から9までの10個の出力を設定して、さらに隠れ層第1層はニューロン50個、第2層は100個、こういうモデルのニューラルネットワークモデルを設計すると、これだけでも90%以上の正答率を

出すことができます。これが画像に強いと言われて  
いる1つの理由です。

最後にDeep Learningですけれども、簡単に言う  
と、ニューラルネットワークに2つを加えたもの  
を一般的にはDeep Learningと言われていま  
す。1つは隠れ層を4層以上にすること。もう1つは誤差  
逆伝搬法と言います。

まずは隠れ層=4以上ですけれども、先ほどの  
ニューラルネットワークでは隠れ層2つだけでし  
たね。さらに2つ以上加えたものをDeep Learning  
と呼んでいます。なぜかという、ニューロンの  
数を増やすことに意味があるわけです。もっと言  
うと、重みとバイアスです。

(資料15) まずこの図は重み $w$ を1から100まで  
変化させたイメージですけれども、重みを変化さ  
せるとステップ関数に近づいていきます。

(資料16) 次のこの図のようにバイアスを変化  
させていくと、右に行ったり左に行ったりと位置  
がズレるだけです。

(資料17) そしてこの2つの性質をうまく組み合  
わせると、任意のパルス波を生成することができ  
るということです。これが1つ目の最大の特徴に  
なります。イメージとしてはこういう感じです。  
ニューロンの数を増やすことで任意のパルス波を  
自由に作るようになる。これが中間層の隠れニュー  
ロンを増やすという最大の特徴です。

(資料18) この図がセンサから送られてくる信  
号を使ってロボットがモノを識別するイメージな  
んですけれども、たとえば硬いものに触れたとき  
のセンサの信号はこのような形状、柔らかいもの  
に触れた時はこのような形状だった場合に、  
ニューロンの数を増やせば増やすほど任意のパ  
ルス波を自由につくれますので、任意の信号にか  
ようにも対応できるようになるということです。  
これがニューロンの数を増やすという理由になり  
ます。

次に誤差逆伝搬法ですけれども、これは2つの  
定理によって実現されています。1つ目が連鎖律、  
2つ目が最急降下法と言います。ここでは時間の  
関係もありますので簡単に言いますが、ま  
ず連鎖律というのは、ニューラルネットワークは  
先ほどのニューロンの数を見ていただいて分かる  
通り多変数の合成関数になりますので、多変数の

連鎖律を使うことで各パラメーターが全体に及ぼ  
す影響を求めることができるわけです。式も用意  
しておきましたが、時間の関係でこちらは割愛し  
ます。ここでパラメーターと言っているのは重み  
とバイアスのことです。これは各層の全ニューロ  
ンにつけられています。全体のパラメーターの調  
整をするために使うもの、それが連鎖律というこ  
とです。

次に最急降下法ですけれども、これは関数 $f$ が  
最小値をとるときの変数 $x$ の値を、関数の微分を  
使って求めるアルゴリズムになります。簡単に言  
うと、誤差が最小になる値を最急降下法で求め  
ているだけです。つまり、誤差逆伝搬法というの  
は、最初に入力値、重み及びバイアスを設定し  
て、出力までを行い、それが $y$ です。実際の正解の出力  
 $Y$ と比較して誤差を求める。その誤差が最小にな  
るような値をうまく調整するように最急降下法で  
求めて、次に連鎖律を用いて全体のバイアスと重  
みをどのように設定すれば誤差が最小になるか  
ということを計算して、それで最適なバイアスと重  
みを逆伝搬しながら再設定していく、そういうイ  
メージです。これがDeep Learningにおける誤差逆  
伝搬法というもので、原理はニューラルネット  
ワークと同じです。

以上がDeep Learning簡単な変遷と原理の説明に  
なります。次に、このAI技術が社会にどのよう  
なインパクトを与えているか、ということにつ  
いて2019年1月現在の例をいくつかご紹介したい  
と思います。

(資料19) まずは、AR (Augmented Reality) の  
例ですが、このように実際に靴を履かなくても  
AI技術を使うことで実際に靴を履いたイメージ  
が分かるということです。こういった技術は靴だ  
けではなくて服の試着でもできそうですし、ヘア  
をカットした後のイメージが分かるということで  
美容院なんかでも応用できる技術ですので、様  
々な業界に影響を及ぼしそうな技術です。

(資料20) 次の無人店舗です。これは日本でも  
かなり有名になっていますので簡単な説明にとど  
めますけれども、日本では、コンビニはAmazon  
GOとかの全自動、スーパーは半自動が進んで  
いるような気がします。無人店舗になるとレジ打  
ちが要らなくなると言われています。

(資料21) 続いて自動運転です。これは物体認

識技術のAIとIoTを組み合わせて実現されていますが、自動運転がビジネスとして確立すると、配送業に影響が及ぼされると言われています。例えばトラックの運転手が要らなくなると言われています。

(資料22) さらに教育業界にも影響が出そうだとされています。実際に一部の塾ではもう始まっているのですが、たとえばAという定理を構成する数式がBとCだった場合、ある生徒がAを間違っていた場合に、もしBを理解していないから間違っていた場合は、そういったことをAIが認識してBの教材を提示する、といった教材アプリは実際に運用されているそうです。

(資料23) Deep Learningが画像データやビッグデータに強いということで、医療の現場でもインパクトを与えています。それだけではなくて、弁護士の業界においても、過去の膨大な判例データベースから最適な判例を導き出すということは、既に人間よりもAIのほうが優れていると一部では言われています。

このように、2019年時点でも産業界に多大なインパクトを与えているAIですが、AI=Artificial Intelligenceであり、現時点では未だintelligence、知性までは持っていないと私は考えています。先ほどパーセプトロンのイメージを説明しましたが、ニューラルネットワークもそうですが、脳の表面的な構造の一部を模倣しているだけなんです。それだけでもこれだけ産業界にインパクトを

与えている、これが現状なわけです。ただ、intelligenceは知性を意味します。つまり、現状のDeep Learningでは人間のように創造したり、感情を持つたりということはできないと考えられます。

(資料24) 感情とか創造を行っている箇所は脳の大脳であり、人間はこれだけ大きいのでほかの生物よりも創造的で、かつ感情的であると言われています。右側に書いておきましたけれども、この大脳の中にある細胞新皮質が、この感情とかクリエイティブな部分を担っていると言われています。

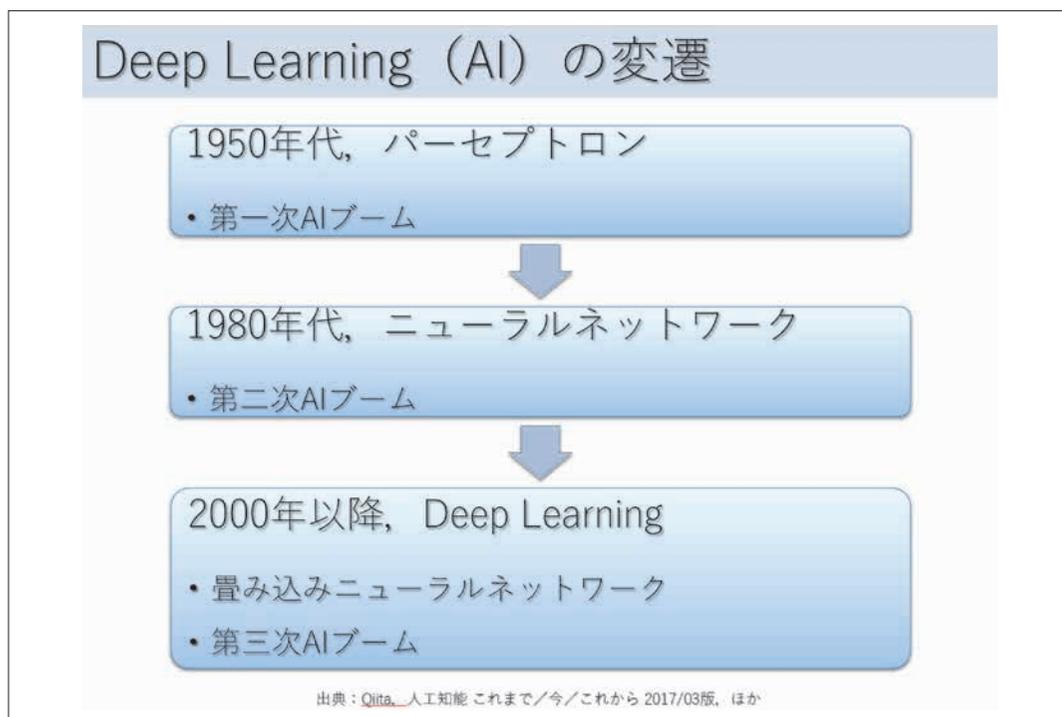
ただ、このメカニズムが先ほどのパーセプトロンやニューラルネットワークとは比べものにならないくらい複雑怪奇であり、現在脳科学者の先生方がこの仕組み、メカニズムを解明しているそうです。もしかしたらすでに解明済みかもしれせんけれども、その解明されたメカニズムがわれわれ情報屋に下りてきて、情報屋が先ほどお見せしたパーセプトロンとかニューラルネットワーク、Deep Learningのようなモデル化することによってはじめて、Artificial Intelligenceができるのではないかと考えます。ただ、その場合、飛行機が鳥と同じように飛べないように、人工知能は人間の脳とは違ったものになると私は考えています。

以上、これで私の発表を終わりたいと思います。ご静聴ありがとうございました。

タイムテーブル（目安）：

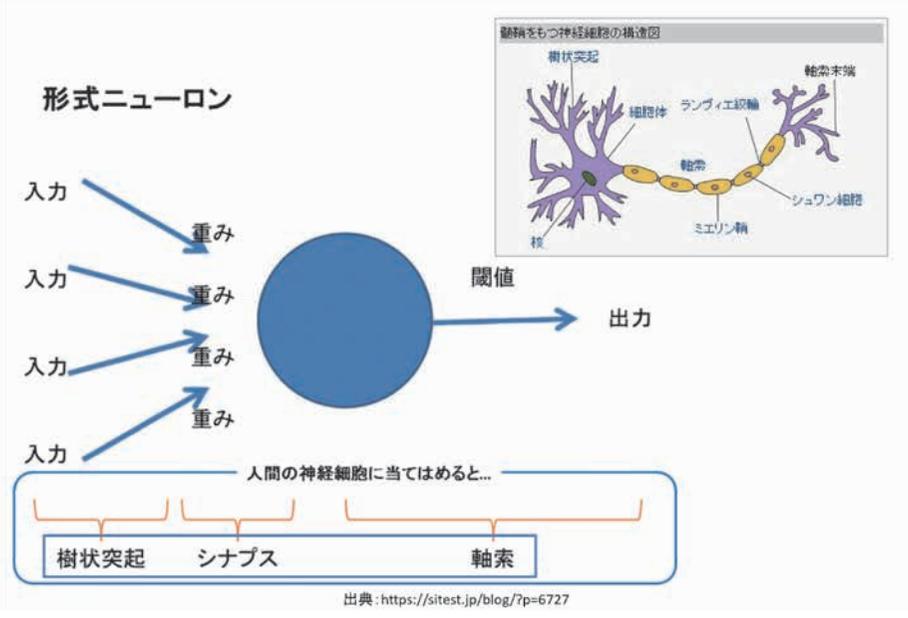
時間	発表者	担当者
14：00～14：10	はじめに、趣旨説明等	大槻
14：10～14：25	報告1件目「AIの概要、変遷及び今後の展望」	大槻、坂野
14：25～14：40	報告2件目「質的変数変換シソーラス及びDice関数によるマッチングアルゴリズム」	大槻
14：40～14：50	休憩	
14：50～15：05	報告3件目「待ち行列システムにおけるAI的制御について」	大澤
15：05～15：20	報告4件目「人的資源のグローバル統合と知識創造」	米澤
15：20～15：35	報告5件目「AIを活用するマーケティングと消費者のプライバシー問題」	井口
15：35～15：50	報告6件目「AI・ビッグデータ活用マーケティングに見る問題性」	江上
15：50～16：00	まとめ	大槻

資料1



資料2

# パーセプトロン



資料3

# ANDゲート

$X_1$ と $X_2$ の入力が共に1の時のみ、 $y$ に1を出力

$X_1$	$X_2$	Y
0	0	0
1	0	0
0	1	0
1	1	1

資料4

## ORゲート

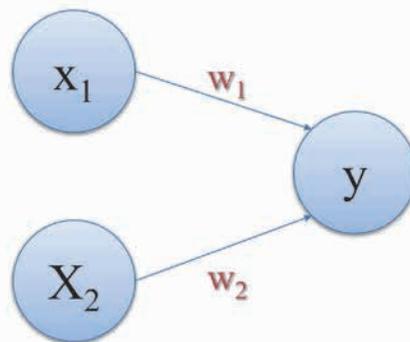
$X_1$ と $X_2$ のどちらかの入力が1の時に、 $y$ に1を出力

$X_1$	$X_2$	$Y$
0	0	0
1	0	1
0	1	1
1	1	1

資料5

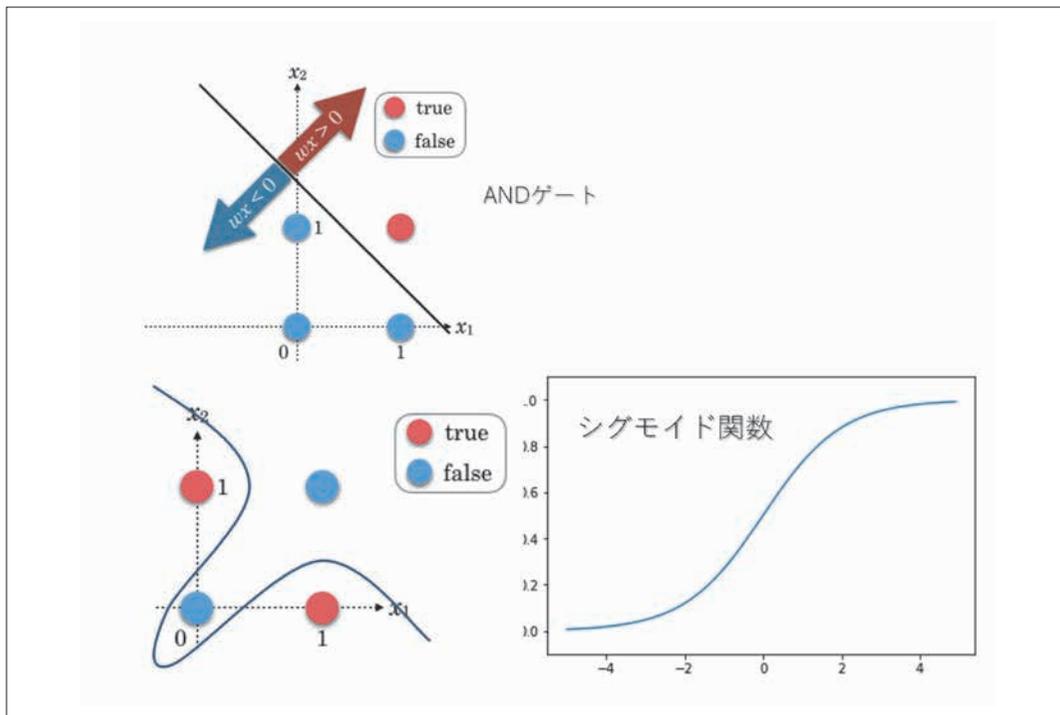
## Perceptron

```
① def AND(x1, x2):  
    w1, w2, theta = 0.5, 0.5, 0.7  
    tmp = x1 * w1 + x2 * w2  
    if tmp <= theta:  
        return 0  
    elif tmp > theta:  
        return 1  
② print(AND(0, 0))  
0  
② print(AND(1, 0))  
0  
② print(AND(0, 1))  
0  
② print(AND(1, 1))  
1
```



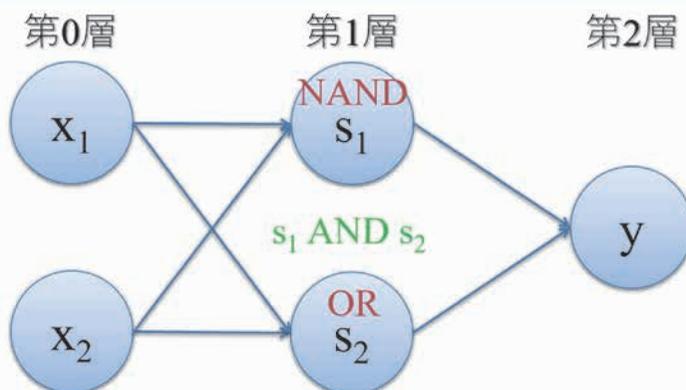
$$y = \begin{cases} 0 & (w_1 x_1 + w_2 x_2 \leq \theta) \\ 1 & (w_1 x_1 + w_2 x_2 > \theta) \end{cases}$$

資料6



資料7

## 2.5 XORパーセプトロンのイメージ



- 第0層のニューロンが信号  $(x_1, x_2)$  を受け取り、第1層のニューロン  $(s_1, s_2)$  へ信号を送る。
- 第1層のニューロンが  $s_1 \text{ AND } s_2$  の結果を第2層のニューロンへ信号を送り、
- 第2層のニューロンが  $y$  を出力

資料8

## 行列の形状 (shape) の性質

- 以下は、行列1と2の積によって、行列3が生成されるイメージ
- 行列3は、**行列1の行数**と**行列2の列数**から構成される。

$$\begin{array}{l} \text{形状：} \end{array} \quad \begin{array}{c} \text{行列1} \\ 3 \times 2 \end{array} \quad \begin{array}{c} \text{行列2} \\ 2 \times 4 \end{array} = \begin{array}{c} \text{行列3} \\ 3 \text{行} 4 \text{列} \end{array}$$

資料9

## 行列の形状 (shape) の性質

なお、行列1が2次元の配列で、  
行列2が1次元の配列でも、

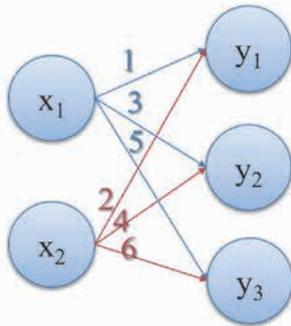
次のように同じ性質が成り立つ

$$\begin{array}{l} \text{形状：} \end{array} \quad \begin{array}{c} \text{行列1} \\ 3 \times 2 \end{array} \quad \begin{array}{c} \text{行列2} \\ 2 \end{array} = \begin{array}{c} \text{行列3} \\ 3 \text{行} \end{array}$$

資料10

## ニューラルネットワークの内積

NNの特徴は**行列の内積**でまとめて計算できる  
(例え、xやyが1000個あっても下記のように内積でまとめて計算可能)



$$X \quad W \quad y$$

$$2 \quad 2 \times 3 = 3$$

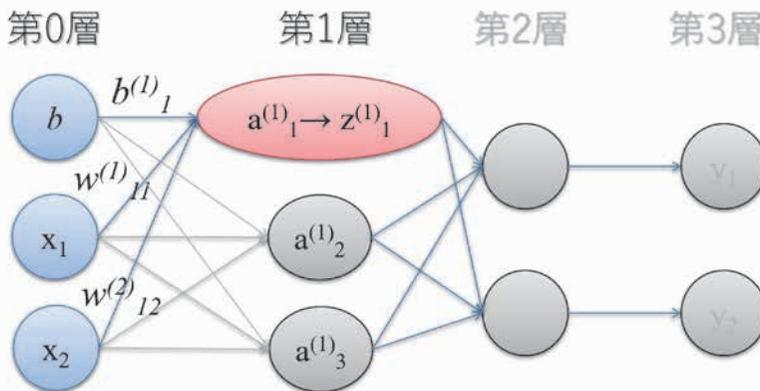
一致

$$1 \times 1 + 2 \times 2 = 5$$

$$\begin{matrix} x_1 \\ x_2 \end{matrix} \begin{pmatrix} 1 \\ 2 \end{pmatrix} \begin{pmatrix} 1 & 3 & 5 \\ 2 & 4 & 6 \end{pmatrix} = \begin{pmatrix} 5 & 11 & 17 \end{pmatrix}$$

資料11

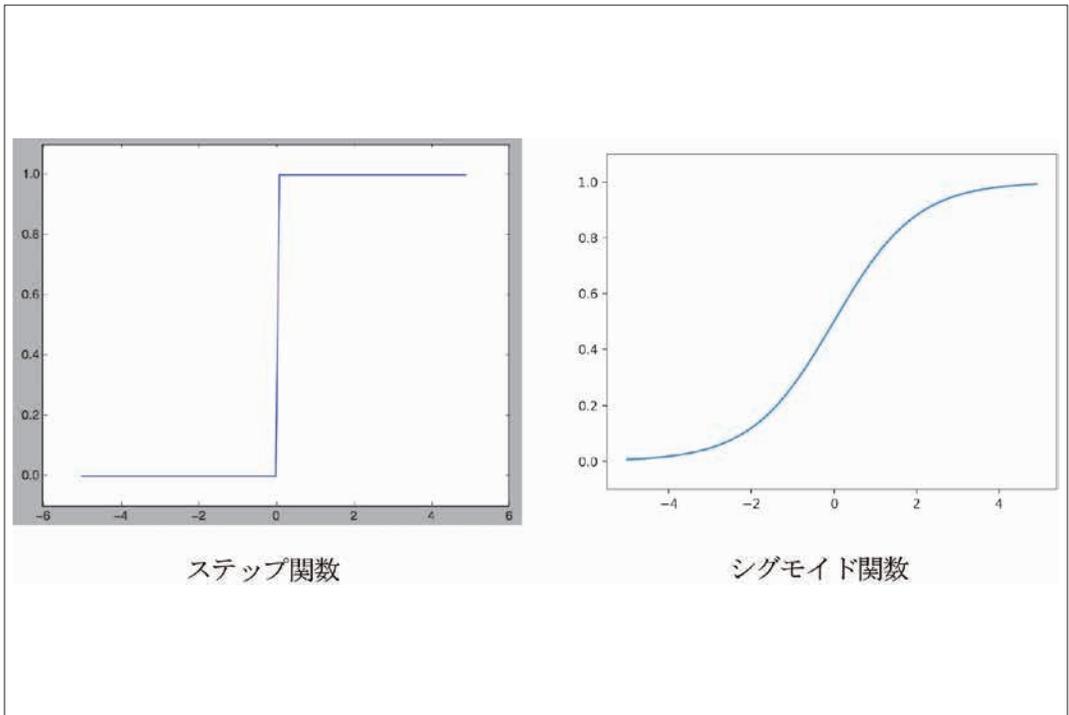
## 第1層の1番目のニューロンへの信号伝達



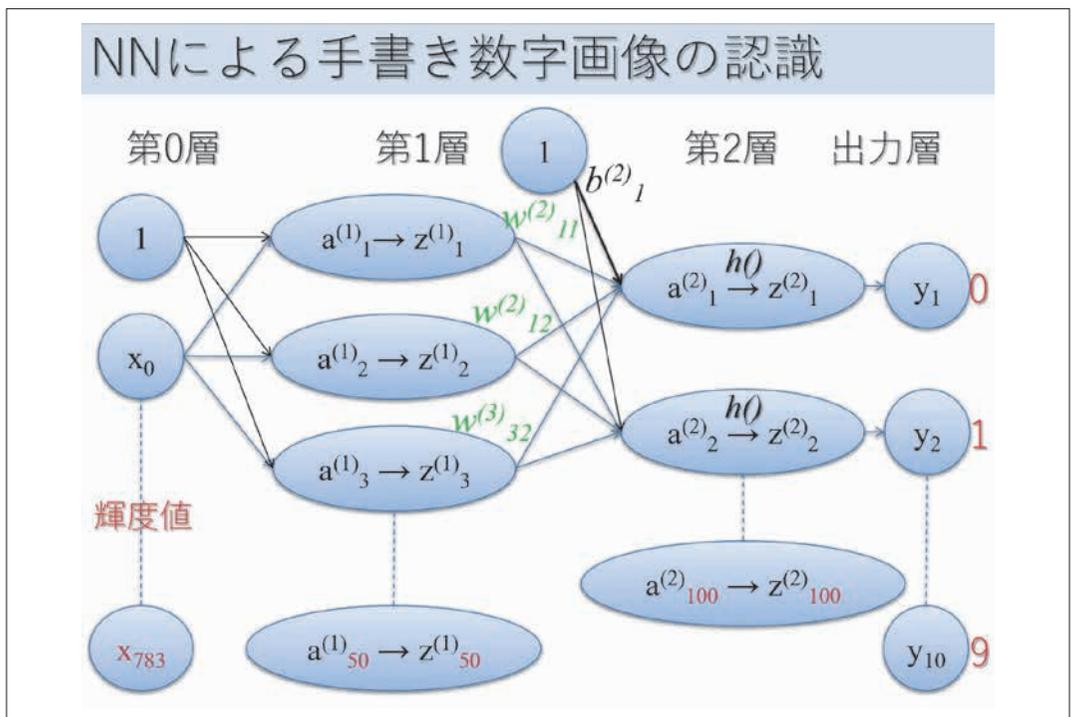
$a^{(1)}_1$ を数式で表すと、次のようになる。

$$a^{(1)}_1 = w^{(1)}_{11} x_1 + w^{(1)}_{12} x_2 + b^{(1)}_1$$

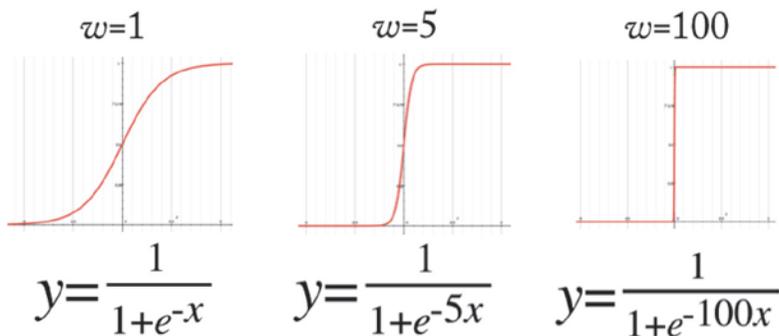
資料12



資料13



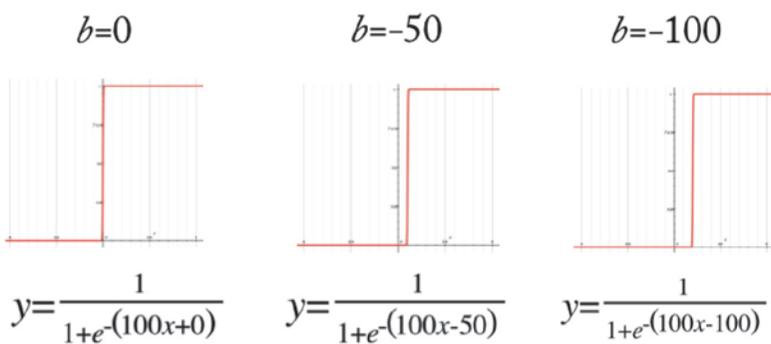
資料14



重み $w$ を変化させたイメージ

出典 : <https://www.yukisako.xyz/entry/neural-network>

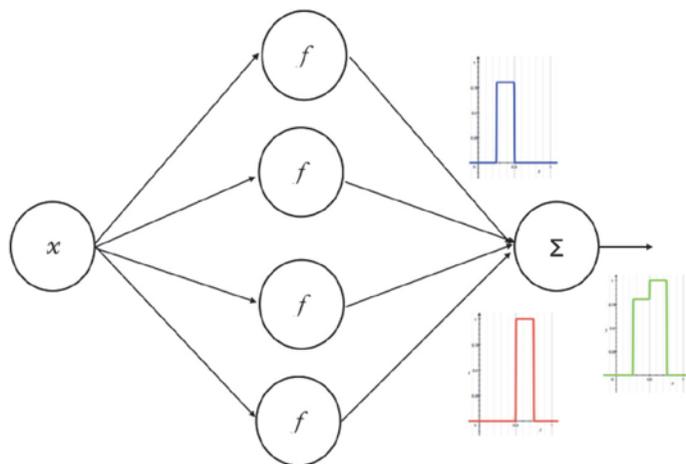
資料15



バイアス $b$ を変化させたイメージ

出典 : <https://www.yukisako.xyz/entry/neural-network>

資料16

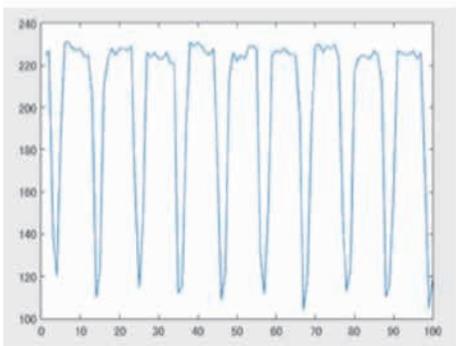


任意のパルス波を生成

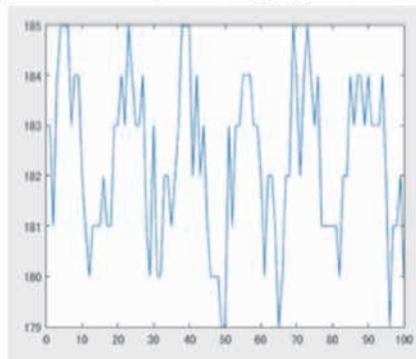
出典 : <https://www.yukisako.xyz/entry/neural-network>

資料17

硬いものに触れたとき



柔らかいものに触れたとき



出典 : <https://www.yukisako.xyz/entry/neural-network>

資料18



出典：<https://www.gizmodo.jp/2018/05/ar-sneaker-vyking.html>

資料19



出典：<http://ventureclef.com/blog2/?p=3458>

資料20



出典：[https://deepage.net/machine\\_learning/2016/08/30/nn\\_examples.html](https://deepage.net/machine_learning/2016/08/30/nn_examples.html)

資料21



出典：<https://withnews.jp/article/f0151221001qq0000000000000000W02h0901qq000012768A>

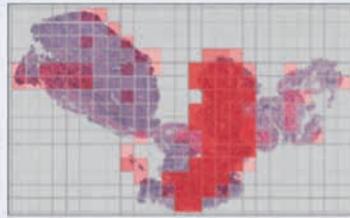
資料22

Theme

1

## 機械学習による 医用画像診断支援

画像認識技術の進化により、機械学習による医用画像診断支援が可能に。ダブルチェックやスクリーニングの手段として用いることで、医師の負担を大きく軽減し、診断精度の向上に寄与できるものと期待されます。具体的には、乳房超音波検査の動画像や病理画像を解析し、異常が疑われる箇所を自動的に検出する支援システムなどを開発中です。



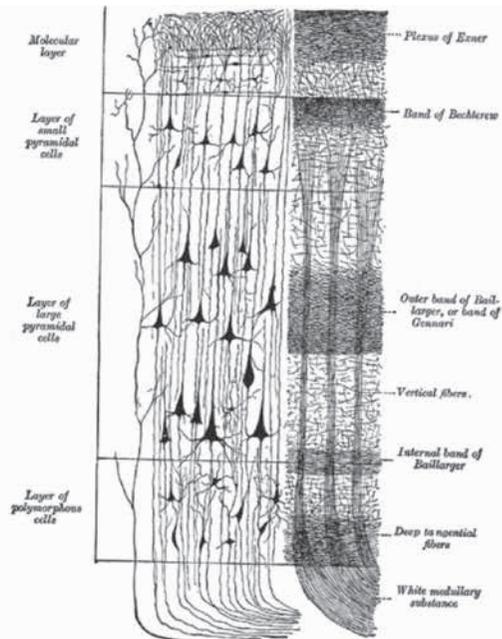
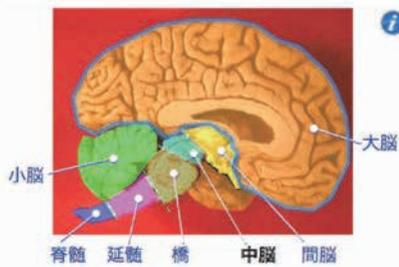
機械学習に基づく病理画像診断支援ソフトにより病変(がん)である疑いの強い部分が赤色で示されている。



乳房超音波検査において、腫瘍と疑われる部位を自動的に検出し、検査者へ提示している様子

出典 : <https://www.airc.aist.go.jp/utility/medical.html>

資料23



出典 : <https://qiita.com/miyamotok0105/items/9ce8d4425768828628c9>

資料24

## 「質的変数変換ソーラス及び Dice関数によるマッチングアルゴリズム」

日本大学経済学部教授 大槻 明

いまはシェアリングエコノミーの時代と言われています。Uberや、airbnb、さらにはLinked Open Data (LOD) と言いますが、官公庁なり企業なり個人が持っているデータをオープンにして、それを有機的にリンクさせる技術であり、具体的にはRDFという技術を用いますが、こういった技術を使うことで、インターネット上に点在するデータを有機的にリンクできるという概念です。LODの出現により、個人や法人が持っているデータとか、車とか家とか資源、そういったものをシェアすることで新たな価値などを生み出せるようになったと言われてます。こういった時代の中で働き方も変わってくると厚生労働省も言っています。いまはテレワークが当たり前になっていますけれども、その前から厚労省は「テレワークも一つの働き方である」ということを提案していました。

このような状況下においては、人と人、人と物、物と物、そういったものをネット上でうまくマッチングさせるアルゴリズムがますます重要になってくるということです。将来的には人と物とか物と物のマッチングの研究までしたいんですけども、まずは人と人のマッチング・アルゴリズムを考えたということです。

具体的には、キャンプファイアーを題材としていまして、お金を出す方と、スキルや技術を提供する方をマッチングさせるようなアルゴリズムをまずは考えたということです。このマッチング問題で有名なものとしてはDA、GAがあります。この応用例としては研修医マッチング制度とか大学院入試制度にかかわるマッチング問題、つまり、新人の医者の方がどの医局に行くのが望ましいかというマッチング問題ですね。どういうアルゴリズムかという、相手同士の選好、希望順位を分析に用います。たとえば新人の医者の方が希望1位がA病院、希望2位がB病院、希望3位がC病院。逆に病院側も、Aさんを第1希望する、Bさんを第2希望するとか、そういったお互いの希望順位をもとにマッチングするアルゴリズムです。しか

し、今回の対象はお金を出す資金提供者1に対して最適な技術提供者をnからマッチングさせるアルゴリズムを考えるということで、1対nのアルゴリズムを新たに考えたということです。他方では二部グラフマッチングというのがあります。これは男女のペアでよく例えられますけれども、例えば男性が5人いて、女性が4人いた場合に、最適なペア数は2ですねとか、そういった最適なペア数を求めるアルゴリズムです。しかし、今回はn対nではなく、先ほど述べたように1対nの場合の最適なマッチングを求めるアルゴリズムが必要ですので、新しいものを今回研究したということです。しかし、DAやGA、さらには二部グラフに関しても、応用すれば1対nのマッチング問題を扱えるようになると思われまので、今後はそういった先行研究手法と比較検証をしていきたいと思っています。今回はアルゴリズムをつくって簡単に動かすだけということになります。

(資料1) こちらがペアアルゴリズムを実証するためのダミーデータになります。緑の個所がアイデアとかスキルを提供で6人います。そして資金提供者として個人、行政、企業の人それぞれ、それぞれに希望を入力してもらっているイメージです。入力している内容は大きく3つに分かれます。もっと大きく分けると2つに分かれます。1つ目が1から5までの階層にしていますけれども、5階層に掘り下げたあたりで内容のマッチングをするということです。簡単に言うと、「ホームページを作れますよ」「ホームページを作ってほしい」という希望する内容ということですね。この内容に関して5階層で掘り下げて完全一致させるということをやっています。第6階層と7階層はマッチング対象に幅があるマッチング項目になります。第6階層は期間です。「ホームページを2~3カ月で作れます」「ホームページを3カ月以内で作ってほしい」といった希望がそれぞれあった場合に、このマッチ度はどうやって算出するのか？ということですね。それが既存技術では分からなかったということです。第7階層も同様にマッチング対象に幅がある項目で金額です。例えば一人目の方は「20万で作りますよ」と言っていて、行政1は「30万から50万で作ってほしい」と言っている。この場合マッチ度はどれぐらいか、それを解くアルゴリズムを今回考案したということです。

(資料2) 提案アルゴリズムは大きくは2つに分かれています。まず階層1~5のマッチング項目ですけれども、ここではユークリッド距離を用いた内容の完全一致を行います。そして、6~7階層はマッチング対象に幅がある場合のマッチング項目ですけれども、ここではDice関数を応用しています。この2つのアルゴリズムを、厳密にはA、B、Cの一途度結果を、線形結合といいます。足し合わせるかたちで最終的な判定を行うというモデルです。

(資料3) まずは1~5階層の完全一致ですけれども、一人目のアイデア提供者は動画コンテンツを作れるとは言っていません。対して資金提供者の個人1は動画コンテンツを作って欲しいと言っている。この場合のマッチ度を求めるケースで説明したいと思います。1階層から4階層までは一致していて、最後の「何をつくってほしい」が一致していないケースだということです。

(資料4) この場合、まずはこれがシソーラスですけれども、このシソーラスでは内容の一致度を階層を掘り下げて重み付けしていますので、階層が掘り下がるほど、重みが増すイメージになっています。この例では5階層までしかありませんけれども、理論的にはn階層までつくれるということです。

(資料5) 次に、こちらがユークリッド距離ですけれども、それに当てはめたものが一番下です。先ほどの例では、1階層~4階層までは一致していて、最後の5階層が一致していないので、こういうかたちになります。0が資金提供者、5が個人ということです。これを解くと、資金提供者1と個人1の一致度は5になるということです。それをこのスライドでは0~1に変換しているだけです。そして、提供者1~6と、個人、行政、企業のそれぞれマッチ度を求めたのがこの白いセルです。その最大値で割ることで全体を相対度数化しています。こうすると、一番近い人は1、一番遠い人は0になるということです。これがこの式の意味ということです。

(資料6) 次にマッチング対象に幅がある場合ですけれども、ケースとしてはアイデア提供者の3人目は動画コンテンツを2~3カ月で作れますよと言っています。対して個人1は動画コンテンツを2カ月以内で作って欲しいと言っています。この場

合に、Dice関数に落とし込む前に工夫をしているということです。

(資料7) 具体的に、提供者3は2~3カ月、個人1は2カ月以内と言っています。これを1カ月単位に分けます。分ける単位はケース・バイ・ケースで、1週間単位でも1日単位でも、状況に応じて設定できます。Dice関数は、まず分子がXとYの共起頻度×2です。この場合は、共起頻度は2カ月だけなので、1×2となります。分母は、XとYそれぞれの要素数を足し合わせたものになります。この場合は、提供者3は2ですね、個人1も2です。つまり2+2=4です。つまり、この提供者3と個人1の一致度は、 $1 \times 2 / (2 + 2) = 50\%$ になるということです。金額も同じようなアルゴリズムでやります。さらに、もし資金提供者とスキル提供者が複数の項目でマッチしていた場合は、それら全てを合算する形で計算をしていきます。

(資料8) 最後に、最終的な一致度判定は、Aがユークリッド距離で求めた1から5階層の完全一致度、BとCがDice関数で求めた一致度ですけれども、Bが期間、Cが金額ということです。これらを単純に線形結合しているイメージなんですが、Aを掛けている理由は、Aが一致していなかった場合に最終的な一致度を0にしたいからです。そもそも希望する内容が一致していない場合一致度は0にしたいのでAを掛けているだけです。足してしまうとBとCの値が残ってしまうので一致度が出てしまうということです。だからAを掛けている、それだけです。

(資料9) こちらが実際に提供者1から6と、個人1から企業1までの最終的なマッチ度を求めたものになります。個人1だと、一番一致するのは提供者5で、一致度は100%ということですね。全ての実証結果の確認もしていますが、今回はそれら全てを報告する時間はありませんので一部だけ説明します。

(資料10) 個人1は動画コンテンツを2カ月以内に30万円以下でつくってほしいと言っています。対して提供者1と2と4の一致度は0なんですけれども、なぜかという動画は提案していないからですね。対して提供者3と5と6は動画を提供しています。

(資料11) ではなぜ提供者5の一致度が一番高かったかということを次のスライドでまとめてみ

ました。6, 7階層のみを比較したものですけれども、提供者5は6階層で2カ月以内につくりますとっていてこれがまず個人1と完全一致している。7階層の金額も提供者は50万円以下で作ると言っていて個人1は30万円以下で作って欲しいとっていて、一致度は3/5で一番一致度が高いですね。つまり、提供者3とか6よりもよいということでの結果になったということが分かりました。その他も確認したんですけれども、同様に有効性は確認できたということです。

最後にまとめと今後の課題ですけれども、今回

はまずクラウドファンディングを対象とした1対nのマッチング・アルゴリズムを考案しました。今後は関連手法との比較検証を行って本アルゴリズムの有効性を検証したいと思っています。さらに、冒頭でも言いましたけれども、いまは人：人のマッチングですけれども、今後は人：物とか物：物まで対応できるように、このアルゴリズムをブラッシュアップしていきたいと考えています。

以上、ご静聴ありがとうございました。

1.1 (何年 何月)	階層						アイデア・スキル提供者						資金等提供者					
	2.1 (何月1)	3.1 (何月2)	4.1 (何月3)	5.1 (何月4)	6.1 (期間、単位：月)	7.1 (合計金額)	1人目	2人目	3人目	4人目	5人目	6人目	個人1	個人2	行政1	行政2	企業1	企業2
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1	1	1	1	1	1	1	1	1	1	1	1
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	2	2	2	2	2	2	2	2	2	2	2	2
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	3	3	3	3	3	3	3	3	3	3	3	3
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	4	4	4	4	4	4	4	4	4	4	4	4
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	5	5	5	5	5	5	5	5	5	5	5	5
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	6	6	6	6	6	6	6	6	6	6	6	6
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	7	7	7	7	7	7	7	7	7	7	7	7
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	8	8	8	8	8	8	8	8	8	8	8	8
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	9	9	9	9	9	9	9	9	9	9	9	9
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	10	10	10	10	10	10	10	10	10	10	10	10
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	11	11	11	11	11	11	11	11	11	11	11	11
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	12	12	12	12	12	12	12	12	12	12	12	12
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	13	13	13	13	13	13	13	13	13	13	13	13
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	14	14	14	14	14	14	14	14	14	14	14	14
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	15	15	15	15	15	15	15	15	15	15	15	15
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	16	16	16	16	16	16	16	16	16	16	16	16
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	17	17	17	17	17	17	17	17	17	17	17	17
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	18	18	18	18	18	18	18	18	18	18	18	18
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	19	19	19	19	19	19	19	19	19	19	19	19
1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	1-1-1	20	20	20	20	20	20	20	20	20	20	20	20

資料1

## 提案モデル

1～5階層A	ユークリッド距離による 内容の完全一致度判定 $MatchD(X, Y) = 1 - \frac{D(X, Y)}{\max(D(X, Y))}$
第6層B	Dice関数によるマッチング対象 に幅がある場合の一致度判定
第7層C	$Dice(X, Y) = \frac{2 X \cap Y }{ X  +  Y }$
最終的な 一致度判定	$Match(X, Y) = \frac{A \cdot (B + C)}{\max(A \cdot (B + C))}$

資料2

1: (カテゴリー)	階層						アイデア・スキル提供者					資金等提供者					
	2: (内容1)	3: (内容2)	4: (内容3)	5: (内容4)	6: (期間、単位、月)	7: (合計金額)	個人1	個人2	個人3	個人4	個人5	個人6	個人7	行政1	行政2	企業1	企業2
1まちづくり・地域活性化							1	1	1	1	1	1	1				
1-1 カフェスタンド							2	2	2	2	2	2	2				
1-1-1 プロダクト																	
1-1-2 イベント・広報							3	3	3	3	3	3	3				
1-1-2-1 広報コンテンツ作成							4	4	4	4	4	4	4				
1-1-2-1-1 ボーダルサイト作成							5	5			5			5			
1-1-2-1-1-1 2~3か月						200,000	6										
1-1-2-1-1-1-1 1-1-2-1-1-1-1						200,000	7										
1-1-2-1-1-2 2か月						300,000	6			6							
1-1-2-1-1-2-1 1-1-2-1-1-2-1						300,000	7			7							
1-1-2-1-1-3 3か月以内														6			6
1-1-2-1-1-3-1 1-1-2-1-1-3-1						300,000~500,000								7			
1-1-2-1-1-3-2 1-1-2-1-1-3-2						200,000~300,000											7
1-1-2-1-2 動画コンテンツ作成								5		5	5	5		5			
1-1-2-1-2-1 2~3か月								6		6	6	6					
1-1-2-1-2-1-1 1-1-2-1-2-1-1						300,000		7									
1-1-2-1-2-1-2 1-1-2-1-2-1-2						1,000,000				7	7						
1-1-2-1-2-2 2か月以内													6				6
1-1-2-1-2-2-1 1-1-2-1-2-2-1						300,000以下							7				
1-1-2-1-2-2-2 1-1-2-1-2-2-2						500,000以下								7			
1-1-2-1-3 ロゴ作成										5		5					5
1-1-2-1-3-1 1~2か月										6		6					
1-1-2-1-3-1-1 1-1-2-1-3-1-1						300,000				7							
1-1-2-1-3-1-2 1-1-2-1-3-1-2						500,000					7						
1-1-2-1-3-2 1月以内																	6
1-1-2-1-3-2-1 1-1-2-1-3-2-1						400,000											7

資料3

## 質的変数→重み付き順位尺度変換シソーラス

階層	スコア
第1階層	1
第2階層	2
第3階層	3
第4階層	4
第5階層	5
...	...
第n階層	n

$$D(X, Y) = \sqrt{(X_1 - Y_1)^2 + (X_2 - Y_2)^2 + \dots + (X_n - Y_n)^2}$$

D(スキル等提供者1, 個人1)

$$= \sqrt{(1 - 1)^2 + (2 - 2)^2 + (3 - 3)^2 + (4 - 4)^2 + (0 - 5)^2}$$

$$= 5.00$$

資料4

# ユークリッド距離による完全一致度判定

$D(\text{個人1, スキル等提供者1})$

$$= \sqrt{(1-1)^2 + (2-2)^2 + (3-3)^2 + (4-4)^2 + (0-5)^2}$$

$$= 5.00$$

$$\text{Match}D(X, Y) = 1 - \frac{D(X, Y)}{\max(D(X, Y))}$$

	個人1		行政1		企業1	
提供者1	5.00	0.00	5.00	0.29	5.00	0.29
提供者2	5.00	0.00	5.00	0.29	5.00	0.29
提供者3	0.00	1.00	5.00	0.29	7.07	0.00
提供者4	5.00	0.00	7.07	0.00	5.00	0.29
提供者5	0.00	1.00	0.00	1.00	5.00	0.29
提供者6	0.00	1.00	5.00	0.29	5.00	0.29
max	5.00		7.07		7.07	

資料5

1 (カテゴリー)	階層							アイデア・スキル提供者					資金等提供者			
	2 (内訳1)	3 (内訳2)	4 (内訳3)	5 (内訳4)	6 (期間・単位・月)	7 (金額)	個人 入会	個人 入会	個人 入会	個人 入会	個人 入会	個人 個人	行政 行政	行政 行政	企業 企業	企業 企業
1まちづくり・地域活性化							1	1	1	1	1	1	1	1	1	1
1-1 カフェスタンド							2	2	2	2	2	2	2	2	2	2
1-1-1 プロダクト																
1-1-2 イベント・広報							3	3	3	3	3	3	3	3	3	3
1-1-2-1 広報コンテンツ作成							4	4	4	4	4	4	4	4	4	4
1-1-2-1-1 ポータルサイト作成							5	5		5		5		5		5
1-1-2-1-1-1 2~3か月							6									
1-1-2-1-1-1 200,000							7									
1-1-2-1-1-2 2か月							6			6						
1-1-2-1-1-2 300,000							7			7						
1-1-2-1-1-3 3か月以内												6		6		
1-1-2-1-1-3 300,000~500,000												7		7		
1-1-2-1-1-3-2 200,000~300,000																7
1-1-2-1-2 動画コンテンツ作成									5	5	5	5	5	5	5	5
1-1-2-1-2-1 2~3か月									6	6	6					
1-1-2-1-2-1-1 300,000									7							
1-1-2-1-2-1-2 1,000,000											7	7				
1-1-2-1-2-2 2か月以内												6		6		
1-1-2-1-2-2-1 300,000以下												7		7		
1-1-2-1-2-2-2 500,000以下																7
1-1-2-1-3 ロゴ作成										5		5				5
1-1-2-1-3-1 1~2か月										6		6				
1-1-2-1-3-1-1 300,000										7						
1-1-2-1-3-1-2 500,000												7				
1-1-2-1-3-2 1月以内																6
1-1-2-1-3-2-1 400,000																7

資料6

## 「期間」の類似度Dice係数

$$Dice(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|}$$

提供者3 2~3か月	共起	個人1 2ヵ月以内 1か月
	2か月	
3か月		
Dice	0.50	

$$Diceによる一致度 = \frac{2 \cdot 1}{(2 + 2)} = 0.50$$

資料7

## 最終的な一致度判定

$$Match(X, Y) = \frac{A \cdot (B + C)}{\max(A \cdot (B + C))}$$

- A …1階層～第5階層（内容）のX、Y間的一致度
- B …Dice関数によって求めた第6階層（期間）のX、Y間的一致度
- C …Dice関数によって求めた第7階層（金額）のX、Y間的一致度
- A、B、Cを単純な線結合とはせずに、Aを(B + C)にかけている理由は、Aの内容が不一致の時に0を返すようにするため

資料8

## 最終的な一致度判定

$$Match(X, Y) = \frac{A \cdot (B + C)}{\max(A \cdot (B + C))}$$

	個人1		行政1		企業1	
提供者1	0.00	0%	1.09	42%	1.76	100%
提供者2	0.00	0%	1.29	50%	1.46	83%
提供者3	2.00	73%	1.13	43%	0.00	0%
提供者4	0.00	0%	0.00	0%	0.96	55%
提供者5	2.75	100%	2.61	100%	1.46	83%
提供者6	1.50	55%	0.79	30%	0.96	55%
sum	2.75		2.61		1.76	

資料9

ロール	入力データ
提供者1	ポータルサイト2~3か月20万で作成
提供者2	ポータルサイトを2か月30万で作成
提供者3	動画コンテンツを2~3か月, 30万で作成
提供者4	ロゴを1~2か月30万で作成
提供者5	<ul style="list-style-type: none"> <li>ポータルサイトを2か月30万で作成</li> <li>動画コンテンツを2か月以内, 50万以下で作成</li> </ul>
提供者6	<ul style="list-style-type: none"> <li>動画コンテンツを2~3か月, 100万で作成</li> <li>ロゴを1~2か月50万で作成</li> </ul>
個人1	動画コンテンツを2か月以内, 30万以下で作成できる方を探している

	個人1	
提供者1	0.00	0%
提供者2	0.00	0%
提供者3	2.00	73%
提供者4	0.00	0%
提供者5	2.75	100%
提供者6	1.50	55%
sum	2.75	

資料10

			個人1	
			第6層 (動画2か月以内)	第7層 (動画30万以下)
提供者 3	第6層	(動画2～3か月)	0.50	
	第7層	(動画30万)		0.50
提供者 5	第6層	(HP2か月) (動画2か月以内)	1.00	
	第7層	(HP30万) (動画50万以下)		0.75
提供者 6	第6層	(動画2～3か月) (口ゴ1～2か月)	0.50	
	第7層	(動画100万) (口ゴ50万)		一致無

資料11

## 「待ち行列システムにおける AI的制御について」

日本大学経済学部特任教授 大澤 秀雄

私の話は皆さんのお話と違って、AIに直接結びつくのかどうかも定かではないんですけども、待ち行列において将来的に何らかのAIを用いて制御するようなことがあれば、その方式について考えたということです。

待ち行列というのはこんな形式で、画面だと一番右の赤い丸のところでサービスをしている、グレーの人が待っている、というようなことですが、これは待合室が有限の場合です。ここに新しい呼が到着しますと、待合室に空きがあればこの人は入れるわけです。ところが、下の図のように待合室が満員になっていると、ここに新たに来た人は入れない。呼損になるということです。なんとかこの呼損を減少させるようなAI的制御策と書いたんですけども、これが直接AIに結びつくかどうかまだ分かりませんが、とにかくこの呼損を少なくする方策を考えたいということをやテーマとしました。待ち行列というのは研究が始まって1世紀ぐらいは経っているんですけども、ほとんど理論的にはなされておらず、こういった問題についてはあまりいまだでなかったのではないかと思います。

簡単にまず待ち行列の結果をお話しします。M/M/c/K、これは待合室の代表的なもので、到着の時間間隔が指数分布、これをパラメーター $\lambda$ の指数分布と言います。ポアソン到着とも言います。サービスの時間がパラメーター $\mu$ の指数分布で、 $c$ が窓口の数、まあサーバーの数ですね。サービス中の人も含めて系内の容量がK、これがM/M/c/Kと書かれる待ち行列です。

これは完全に理論的に解析されていて、その結果を紹介しますと、 $\lambda$ が1で、 $\mu$ が0.4で、待合室の数が10に制限されている場合、ここにあるグラフが出てきますけれども、横軸が系内数で、縦軸はその確率分布です。窓口数が1の場合、ほとんど10人近いっぱいのところが確率が高くなって、非常に輻輳状態、混雑な状況を表しています。2の場合でもまだ混雑度は激しい。3になるとだいぶ解消されて、6になると混雑は緩和され

ている状況ですね。

一般には $\rho$ と出てきましたけれども、収入分の $\lambda$ 、これはトラフィック密度という名前もついています。1より大きい場合は、到着のほうがかどんどん来てしまいますので混雑は激しいということは分かっております。

ちなみにグラフのほうで、 $c$ が1の場合 $\rho$ は2.5の場合です。だからサービスの能力よりも来る人が2.5倍いる、単純に言うとそのようなことです。2の場合でも1.25で1を超えていますので混雑度は非常に激しい。1の場合、2の場合は当然呼損が相当出ている状況と思われれます。

先ほど見たように $c$ 1の場合は混雑は非常に激しいですので、ここからはサーバーの数を1に限定して考えていきます。シミュレーションの結果を示しますが、先ほどの $\lambda$ が1で $\mu$ が0.24の場合、横軸が時間の経過、縦軸が系内の数。このようにもうほとんど10にべったりくっついているようなかたちで、10になったときに来た人はもう全部呼損になっている。だから相当な呼損状態が生まれていると考えられます。

そのシミュレーションで示しますと、系内の待合の数を10とした場合、パラメーターは全部ここから統一してこのパラメーターでやっていきますけれども、到着数を400までのパラメーターをやりますと、10回同じようなシミュレーションをやりました。

ここでこの3つの指標について示していきまけれども、EQというのは到着時点における平均の系内数で、それがこのようなことでほとんど10に近い非常な混雑な状況がうかがえます。そして400の到着のうち、呼損になった数は#lossになっていますけれども、シミュレーションによると400のうち60%以上の呼損が起きているという状況です。

この呼損をなるべく少なくするような方式を考えたいということですが、単純に考えると待合室の数を増やせばいいんじゃないかと素人的には考えそうで、それをやってみます。先ほど10から20に待合室の数を増やした場合、先ほどのシミュレーション1から10の状況と同じ呼の到着、サービス要求量も同じものとしてシミュレーションした結果を示します。それがこんなかたちです。

待合室の数を20に増やしましたので、平均系内数はほとんど20に近いような状況が続きます。呼損の数も先ほどの例と同じぐらいの呼損を招いているわけです。つまり、単純に待合室の数を増やただけで呼損が減るわけではない。それはなぜかといいますと、一番下に出てきた数が先ほどの待合室が10の場合の呼損率で、ほとんど変わらない状況であると思われま

す。その状況をシミュレーションの1つの結果で見えますと、これは20の場合の1つの例ですが、見ても分かるように、先ほどの10の場合と違うのは最初のほうの段階だけなんです。つまり、いったん待合室が満杯になってしまえば、そこから起こる呼損の状況は変わらないわけです。単純に待合室を増やただけではこの重輻輳の状況はあまり改善されないということが分かります。

そこで呼損を少しでも減らす方式を提案したいというのがこの狙いでありま

す。ここからが私

が考えた新しい方式ですけれども、記号を定義します。Q(t)は時刻tにおける系内呼数とします。tnはn番目の呼が到着する時刻。Qnはn番目の呼の到着時点直前における系内の呼数。Snはn番目の到着呼のサービス要求時間とします。

ここで制御方式Δと呼んでおきますけれども、Kは先ほどありました待合室というか、系内の容量の限度です。それに対してqnはK分のqn+1。これは時刻tnにおける系の稼働率とでも呼ぶような記号ということになります。suと定義しているμ×S、これはn番目の到着呼のサービス時間を平均サービス要求量でその比率になるんですね。qnとsnを用いた制御法を提案したいというのがこの狙いです。

n番目の到着呼を受け入れるか、または受け入れられないか、その制御式Δを提案したいということなんですけれども、いまκというのを先ほどの待合室の限度のKより小さい自然数としまして、κより到着時点直前の系内数が小さければn番目の人を受け入れようということですね。κを超えてκ以上の場合、Kまでの間ですけれども、そこでδ、α、βという、こういう制御式を決めまして、α×qn+β×snとしまして、このδnが1より小さければ受け入れよう。1を超えている、1以上ならば呼損、つまり受け入れを拒否する。こういう制

御方式でうまくいかないかと考えたわけです。

これに対して、先ほどのシミュレーション1からシミュレーション10まででありましたけれども、同じ状況を設定しまして、この制御方式が効果あるかどうかを確認したということです。その結果、まず先ほどのα、βをいろいろ変化したりして効果があるのかどうか確認するために実験をしまして、α、βをいろいろ変化させて、そして先ほどの三つの指標ですけれども、このような結果ができました。平均系内数から見ると、先ほど20に非常に近いところが記録されていたわけですが、それに比べるとかなり緩和されているという状況があります。呼損の数もこのように先ほどの結果よりはだいぶ改善されている。呼損率においても50%以下になる。ただ、この中で特に後半のほうに効果が見られます。αとβがどのくらいになればいいか、理論的なところまで行かなかったんですけれども、大体このへんの値を設定してシミュレーションを行なってみたということで、その効果の確認は行ないました。

まず、パラメーターの設定は全く同じなんですけれども、κを5、Kを20とした場合の結果をここに示します。α、βをシミュレーション1からシミュレーション10までいろいろ変化させまして、一番効果があったらと思う結果をここに示します。それぞれシミュレーション1からシミュレーション10まで、その来方、状況に応じて、最大の効果があったと思われるα、βの値は違ってくるわけですね。それぞれの結果はこのようなかたちになりました。

呼損も最初の状況から見ると非常に少なくなつて、呼損率は30%前後からそれ以下というふう

に、かなり呼損の状況が緩和された、輻輳状況が緩和されたと思

われます。一番下がΔの制御方式を使わない場合の最初の段階です。これから見ると、それぞれ非常に緩和されている状況が見れると思います。

これはM/M/1という特殊な来方の場合ですけど、到着の方法が変わっても効果があるかどうかということを見るために、次のD/M/1の場合についても同じようにシミュレーションをしました。D/M/1というのは、Dというのはdeterministicで同じ間隔で呼が到着するという意味のDです。

これもパラメーターとしては全く同じ設定でやってみますと、この場合は制御方式 $\Delta$ をとらない場合の通常のD/M/1で、系内の限界数容量を20とした場合、先ほどのM/M/1と同じように、ほとんど平均系内人数は20に近いところで、ロスも非常に高い。みな50%を超えて60%前後の呼損率があることが分かります。

このシステムに対しても制御方式 $\Delta$ を当てはめますとその効果がどうかということでシミュレーションした結果がこちらの結果です。平均人数的には、一番最後だけ16をちょっと超えていますけど、みな16以下におさまっています。呼損数も非常に制御されている状況が見てとれるわけですね。このように、ここで考えました制御方式 $\Delta$ というのは非常に効果があるんじゃないかということです。

もうちょっとこの効果についてグラフで見たい

と思いますけれども、これは最初のM/Mの場合の $\Delta$ の制御方式をとらない場合の例です。同じ状況で制御方式 $\Delta$ をとった場合の人数、系内数の変化はこのように非常に呼損が少ない状況がうかがえると思います。

D/M1形においても同じようなことが出てきますので、到着の仕方が変わっても効果が見られると考えられます。

まとめですけれども、今後AIを用いてこういうシステムの制御を行なう場合の一つの材料になるのではないかということを期待して、この方式を提案したということです。実際のシステムでAIを用いてこういう方式で制御するという段階まではまだ全然いきませんが、展望としてはそういうことを期待したいということで、私の発表は以上で終わります。

## 「人的資源のグローバル統合と知識創造」 —外航海運業における 船舶オペレーションのデジタル化—

日本大学経済学部教授 米澤 聡士

今回私は、「人的資源のグローバル統合と知識創造—外航海運業における船舶オペレーションのデジタル化」とのテーマで研究をいたしました。普段私が研究している外航海運企業の船員を対象とする人材のマネジメントに関連することで、経科研のAIプロジェクトに何か関わるテーマはないかと探しまして、この課題を選びました。

イメージとしては、スライドにある大型外航船のブリッジ（操舵室）で、船員が担う船舶オペレーションに関するデジタル化の取り組みを研究対象といたしました。この研究の目的は、外航海運業における船舶オペレーションのデジタル化に焦点を当てて、自律操船技術の開発プロセスとその成功要件は何かを、知識創造の観点から検討することです。

この研究に至った問題意識としては3点あって、1点目がサービス企業による現場オペレーションの自動化がいろいろな業種でいま進展していること。先ほど大槻先生からもAmazon GOの例をご紹介いただきましたけれども、海運企業でも徐々にその動きはあるということ。2点目は、自動化技術の実用化における課題には、業種に固有の制約要因があって、難しい点が多いということ。3点目は、自動化技術の開発プロセスに関する先行研究を見てみると、機械工学とか、この業種の場合は海事システム工学と言いますけれども、そういう観点からの技術レベルの議論がほとんどで、経営学としての研究はほとんど皆無だということ。これらのことから、現場のオペレーションにおける自動化技術をめぐる問題にフォーカスして、業種もしくは職種に固有の要因を踏まえた経営学的な検討をしたいという趣旨です。

研究の方法としては、まず知識創造理論を中心に、先行研究に基づいて一般的なフレームワークとこの研究の論点を整理したうえで、船舶オペレーションのデジタル化に関する先進事例として、外航海運企業と設備機器メーカーによる船舶オペレーションのデジタル化の取り組みを取り上

げています。

今回は、代表的な先進事例として、大手海運会社の日本郵船さんにご協力をいただいて、日本郵船と設備機器メーカーが共同で進めているデジタル化プロジェクトを対象としています。昨年8月に、海運企業にご協力いただいて半構造化インタビューを行なっていますので、そこから得られた質的データに基づいて、船舶オペレーションのデジタル化における知識創造に関するフレームワークを提示すると同時に、それが成功例に進展するための要件とは何かを、帰納的に明らかにしたいという質的研究です。

そこで、船舶オペレーションの自動化というのはどういうことか整理しますと、スライドのとおり4段階あって、最も進んだ形がレベル4ですが、これは大型外航船が全て自動で動くという段階です。つまり、運航システム自体がオペレーションの意思決定と船舶のコントロールをして、もちろん船員は1人も船には乗っていない。これが最も進化した形で、今回の経科研プロジェクトの趣旨からすると、この段階の取り組みにフォーカスできればよかったです。外航海運業ではこの段階が実現するのはかなり先だろうというお話でしたので、今回は最も開発が進んでいるレベル1の取り組みに焦点を当てています。

レベル1というのは、船員の業務プロセスを自動化することによって、システムがオペレーション上の意思決定に関するサポートをする段階です。あくまでも船舶をオペレーションするのは船員で、船舶の運航システムは人間がコントロールする状態です。つまり、船員による操船行動をサポートするシステムをつくるのがレベル1の段階です。海運業全体としては、レベル1からレベル4までの取り組みが現在行なわれていて、各レベルの事例は、昨年の中間報告でご説明しましたので、今回は先へ進ませていただきます。

なぜいま、外航海運業でこのような自動運航技術の開発が重要になってきているのか、その理由が4つあります。まず1つは、船員の職務特性として、船員が船舶のオペレーションを行なっていくうえで、マニュアル化された業務手順やルールといった、形式知はもちろんありますが、マニュアルではカバーできない暗黙知が多くを占めていて、それに基づいて船舶の操船が行われていま

す。この暗黙知をできるだけ形式知化することで、船舶オペレーションの安全性を高める必要があるということです。

2点目は、外航船員の雇用特性です。日本の大手海運企業でも、外航船に乗り組んでいる船員は90%以上が外国人です。外国人船員は、職位にかかわらず全員が3か月から8か月という短期間の契約ベースで雇用されています。さらに、船舶には様々な国の船員が乗り組んでいますから、フィリピンやインドを中心に、東ヨーロッパや東南アジアの各国というように、様々な国籍の船員が同じ船舶に乗り組んでいて、しかも船員は契約期間が終了するごとに頻繁に交代します。このことから、船舶を安全にかつ効率的に運航するためには、オペレーションの質を標準化していく必要があります。つまり、どんな国籍やバックグラウンドの船員が乗り組んでも、船舶を安全かつ効率的に運航できるようにすること。その上でデジタル化は重要だと考えられます。

3点目は、船員市場の動向です。船種によっては、世界レベルで船員が不足していますので、そういう状況に即して海運企業は船員費を削減したり、船員の労働環境を改善したりすることで、船舶のオペレーションをしていく必要があります。

4点目が、船舶のオペレーションコストです。船を運航するための燃料の価格は大きく変動していますので、これに伴って少しでもオペレーションの経済性や効率を向上させるために、できるだけ無駄のない船舶オペレーションをする必要があるということです。

これら4つの課題から、船舶オペレーションの自動化もしくはデジタル化が非常に重要な意味も持っているということです。

それでは、先進事例として、日本郵船と設備機器メーカーが行なっている船舶オペレーションのデジタル化の取り組みを説明します。今回は、このうち「衝突リスク判断と自律操船プロジェクト」を研究の対象としています。この取り組みは、輻輳海域と呼ばれるような海域、たとえば東京湾や香港周辺、あるいはシンガポールとマレーシア、インドネシアの間にあるマラッカ海峡といった、非常に狭い海域に多くの船舶が行き交っているような状況の中で、衝突リスクを回避するためのシステムを開発するものです。

輻輳海域では、船種や船型、速度や針路が異なる多くの船舶が航行していますので、これらの船舶と衝突しないように、オペレーションをサポートするためのシステムを開発します。船舶には、車や電車と違ってブレーキがついていませんので、船員が危険を認知して避航行動をとっても、船はすぐに止まることができません。このような危険な状態で、船舶が安全に航行できるようにするためのシステムを開発するのがこの取り組みです。

具体的に、このシステムのイメージをご説明しますと、船舶の操舵室に設置されているレーダーの画面に、自船の周囲を航行している船舶が表示されます。そこで、自船にとって、周囲の他船がどれだけ危険なのかという危険度を4段階に区分して、周囲の船舶を危険度に応じた色で表示をするというものです。さらに、自船の航行する先で危険が予想される海域があれば、そこを指示したり、操船に関するアドバイスをシステム上で行ったりします。

このようなオペレーションシステムの開発で重要な点は、データ収集のプロセスです。システムにデータを覚え込ませる段階で何をしているかということ、日本郵船の船長クラスの船員20名から30名と、航海機器メーカーの技術者がチームを組んでデータの収集をします。実際にどのように収集しているのかということですが、まず操船シミュレーターという操船訓練用の機器を使って、輻輳海域の状況を再現します。狭い海域に様々な船舶が航行する状況をコンピューターで設定し、その状況下で船長が操船する形で30分間シミュレーションを行います。この過程で、どの船舶がどのタイミングでどの程度の危険とその船長が判断するか、自船から見た相手船の危険度を、都度船長が口頭で指摘します。それを設備機器メーカーの技術者が拾い上げ、この様子がすべて録画・録音されます。シミュレーションが終わると、録画した映像を再生しながら、船長と技術者としてフィードバックが行われます。この流れを繰り返すというのがシステム開発の最も基本的なデータ収集の方法です。詳細は論文に詳述してありますので、そちらをご高覧いただければと思います。

知識創造理論の先行研究によって示された一般的なフレームワークを使って、船舶オペレーショ

ンに関する船員の知識を整理します。DIKWヒエラルキーというフレームワークに依拠して船員知識とは何かを整理すると、次のようになります。つまり、データから情報、情報から知識、知識から技術というように、ナレッジが高度化します。船舶オペレーションのデジタル化は、衝突リスクの認知というデータから、それを言語化してシステム化する一連の知識変換として捉えられます。

この知識の変換を困難にする業種固有性が3つあります。まず1点目が、船員知識の特性として、輻輳海域では、マニュアルでカバーできないような暗黙知に基づいて、船舶オペレーションが行われている場面が多いので、これを形式知化するのは非常に難しいということ。2点目として、船員の多様性・雇用形態として、様々な国籍やバックグラウンドの船員がいる中で、個々の船員がもつ暗黙知としてのデータを形式知化することは非常に難しい点です。船員組織の構造として、小規模なオペレーション現場が世界レベルで物理的に分散しているという点で、同じオペレーション現場でも、メーカーの工場とは性質が違う。大型外航船の場合、1隻当たり20名から30名の船員が乗り組んでいます。この小さな組織が、たとえば日本郵船だと約600隻、世界中に分散して航行しています。この条件下で、すべての船員がもつ知識を集約するのは非常に難しい問題です。これらの要因を所与の条件として、知識創造プロセスを有効に機能させる必要があるということです。

それでは、船舶オペレーションのデジタル化に関する知識創造プロセスがどのようなものであるかということを説明します。知識創造理論の代表的なフレームワークとして、SECIプロセスがあります。知識創造のプロセスが、共同化、表出化、連結化、内面化という4つの段階で構成され、それぞれの段階に知識創造の場が形成されるという一般的なフレームワークです。これを、外航海運業という業種レベルで、あるいは船員職という職種レベルでブレークダウンすると、スライドにある表の通りの説明ができるということです。

次に、この知識創造技術開発のフレームワークが成功裏に機能する要件とは何かを説明します。まず、船舶オペレーションのデジタル化の目的は、海運企業の観点からすると、最終的には自律操船や自動運航船を実用化することですが、その

前の段階として、船舶オペレーションの安全性や効率を向上させる必要があります。これが開発成果による海運企業にとってのベネフィットです。

このベネフィットを獲得するために、操船サポートシステムを開発するのがデジタル化の取り組みで、その開発過程が先ほど説明した知識創造プロセスです。この知識創造プロセスは、2つの前提条件から成り立っていて、1つが外航海運業に固有の要因、つまり船員知識の特性や船員組織の構造、船員の多様性、雇用形態です。もう1つは、海運企業が船員を対象に行う人的資源管理施策、つまり人的資源のグローバル統合です。これら2つの前提条件のもとに、知識創造プロセスが進展します。

そこで、この知識創造プロセスが成功裏に進展するための要件とは何かを、ケース・スタディから帰納的に考察すると、以下の4点と考えられます。つまり、知識統合、場の促進、共同化から表出化へのトランジション、法則性のマネジメントです。

この4つの要件を達成するためには、さらに下位の条件があります。まず、SECIプロセスにおける知識統合が成功裏になされるためには、知識の共通性、ルーティーンの反復と改善、コミュニケーションを促進する組織構造、これらがきちんと成立しているかどうかで、知識統合が成功裏に進展するかどうか左右されると考えられます。

2点目の場の促進に関しては、表出化が行なわれる対話場が効果的に機能するための要件として、船員間で目的や価値観が共有されていること、多様かつ異質な知識が集約されること、対話場にコミットする船員を適正に選抜することが挙げられます。

3点目の共同化から表出化へのトランジションが成功裏に進展する条件として、海運企業の安全管理ポリシーやマニュアルが船員間で共有されていること、海運会社としてのフォーマルな場の設定が必要で、通常は船舶が分散していますから、海運会社の制度によってこれをまとめていかないと、知識創造の場が成り立たないということです。さらに、基盤知識となっている形式知を、このプロセスの前で標準化しておくことも重要だと考えられます。

4点目に、表出化における法則性のマネジメン

トというのは何かというと、データの収集の過程で示される衝突リスクの判断というのは、個々の人間の認知過程ですから、船員個人の価値観や経験によって、問題解決や情報処理のやり方には個人差が生じます。その結果、表出化される暗黙知にはバラツキが発生します。できればこのバラツキを少なく抑えると同時に、バラツキが出てもそれをうまく包摂していく必要があるのです。そのため要件として3つ考えられます。まず、多様なオペレーション環境を設定することで、多様な知識のバラツキを最初に顕在化させること。2つ目が、表出化の担い手となる船員の適切な選抜を行なうこと。3つ目が、表出化の前の段階で、個々の船員がもつ価値観の差異を最小にしておくこと。これらの条件が満たされることで、バラツキの最小化とそれを包摂することによるシステムの構築が、成功裏に進展するのではないかということが考えられます。

この研究の貢献として、3つの点が挙げられま

す。1点目は、船舶オペレーションのデジタル化を対象に、経営学の視点から研究を試みたことです。つまり、機械工学や海事システム工学などの技術レベルの議論とはまた別の視点を提示できたということです。2点目は、知識創造プロセスの概念を、外航海運業という業種、船員職という職種、そして衝突リスク回避というタスクレベルで精緻化できたこと。そして3点目は、海運企業による人的資源管理との関連性を示したことです。

この研究の課題としては、船舶オペレーションのデジタル化が現在進行中の取り組みであることから、今後の進展に伴ってまた新たな議論が必要になってくるといことです。たとえば、船舶オペレーションのデジタル化技術が進展するのに伴って、海運企業の船員戦略が今後どう変化するかという点について、人的資源管理の観点から新たに検討する必要もあると考えられます。

私の研究概要のご説明は以上です。ご清聴ありがとうございました。

## 「AIを活用するマーケティングと消費者のプライバシー問題」

岐阜協立大学経営学部講師 井口 詩織

岐阜協立大学の井口です。

タイトルにもありますように、私はAIを活用するマーケティングと消費者のプライバシー問題について研究いたしましたので、きょうは簡単ではございますが、報告させていただきます。

はじめに研究の目的についてです。この研究の目的は、AIの活用によってマーケティングの実践にはどのような変化が生じているのかを明らかにすることです。そしてその変化が消費者や社会にどのような懸念をもたらしているのか、さらにその懸念を解消するにはどのような議論が必要なのか。これらについて検討しながら、AIを活用するマーケティングについての今後の研究課題についても考察していきます。

ではまずAIの活用によって生じるマーケティングの変化について検討していきます。ここでは主に、マーケティング研究者の依田先生、水越先生、本條先生の議論を取り上げます。この議論では、まずマーケティング・リサーチにおける仮説の重要性が確認されています。

マーケティング・リサーチの基本的な手順は仮説と問いの設定から始まります。たとえば新しいお菓子を開発する場合を考えてみますと、消費者に「あなたはこういったお菓子を求めていますか」と聞いて回ったところで、多種多様な答えが返ってくるだけとなってしまいますので、「お菓子を食べることで、疲れたときにほっと一息したい消費者が一定数存在する」といった仮説を立てます。そうすれば、お菓子を食べることでほっと一息したい消費者がどの程度いるのか、いるとすれば彼らの属性的な特徴は何であるか、さらに彼らはいま現在こうした問題をどのように解決しているのかなど、具体的に質問しなくてはならない問いが見えてくることになります。こうして仮説と問いが設定されると、その仮説の正しさを確認するための調査手法が決定されて、収集されたデータの分析や解釈が行なわれ、マーケティングの意思決定に利用されることになります。

つまり、マーケティング・リサーチには消費の

理由に関する仮説がなければ膨大なデータや貴重な情報も活かされないというのが基本的な考え方でした。ところが、AIを活用するマーケティングでは、消費の理由に関する仮説を立てるということよりも、購買履歴や閲覧履歴といったビッグデータの蓄積をより重視した実践である、ここに特徴があると考えられます。

たとえばアマゾンにおいては、会員であるユーザーのウェブサイトがパーソナライゼーション、個別化されています。すなわち、AIを活用した推薦システムによって、アマゾンでの商品購入履歴、閲覧履歴などのビッグデータに基づいて、ユーザーごとに異なる商品陳列が行なわれているわけです。

同時に、このパーソナライゼーション、個別化というのは、近い属性や近い行動履歴を持つほかのユーザーの行動に基づいているので、アマゾンの社員はなぜそのようにパーソナライゼーションされているのか、その理由を、消費の理由を必ずしも正確に説明できるわけではありません。

スライドにありますように、従来のマーケティングにおいては、創造的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と言われてきました。しかし、AIを活用したマーケティングにおいては、ビッグデータの蓄積が新しいマーケティングの可能性を開くと期待されています。AIはビッグデータをもとに、人が思いつかないようなデータの分け方、特徴量を発見できる。そのため、ビッグデータ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なるということで、こうした変化がAIの活用によって生じるマーケティングの大きな変化であると考えられます。

次に、ビッグデータの蓄積が企業のマーケティングの可能性を開くとすれば、そのことが消費者や社会にはどのような影響を与えるのかについて検討していきます。ここで取り上げたいのはマーケティング研究者の中田先生の議論です。先ほどお話しした依田先生たちがビッグデータの蓄積を「投資」と表現しているのと同様に、中田先生はビッグデータを「資産」と表現しています。年齢や住所、性別、収入、選好、それからアップロードされた文章や画像のような個人データや個人情報「ビジネス資産」と認識されるようになって

いて、この資産の活用によって、推薦システムや検索エンジン、ソーシャルメディアといった新しいサービスが登場して、企業にも消費者にもさまざまなベネフィットがもたらされている。しかしその一方で消費者のプライバシーに対する懸念が拡大しているというのが中田先生の指摘でして、私も注目したい問題です。

その議論の中で特に重要だと思われるのがプライバシーのコンテキスト依存性というものです。これはどういうことかといいますと、消費者にプライバシーが重要かどうかということを探ねると、多くの消費者は「プライバシーを重視する」と答えるんだけど、コンテキスト、文脈によっては、個人はプライバシーを軽視することがあるということです。

たとえば検索エンジンを利用するということは、検索結果と引き換えに検索エンジンに個人データを公開していることになるわけですが、そのように考えている消費者というのはあまりいないと思います。また、個人情報の記入を伴うアンケート調査というのは、対価として金券などを付与すると回答率がはね上がると言われていました。そのように、多くの消費者はプライバシーについて関心を持っているのですが、特定の状況、コンテキストでコストとベネフィットを考えて、プライバシーの保護を求めたり、そうでなかったりするわけです。そこで企業はビッグデータという資産を蓄積していくために、ユーザーの行動的・心理的プロセスを利用して、ユーザーに情報をなるべく公開してもらうような知識を開発していくことになります。

そのように消費者のプライバシーの反応を操作というかコントロールしようとするのを、宮下先生は「プライバシーナッジ」と呼んでいます。つまり、AIを活用するマーケティングというのは、ビッグデータという資産を蓄積していくために、プライバシーのコンテキスト依存性を踏まえて、プライバシーナッジなどを用いて消費者のプライバシーへの反応をコントロールしようとしていく。こうしたことが行なわれている限り、スライドにありますように、企業は消費者のプライバシーを適切に保護しているのか、むしろ侵害しているのではないかと、リクナビの問題やJRがSuicaの個人情報を他社に提供してしまったような問題

がまた生じるのではないかとといったプライバシーへの懸念は拡大していくのではないかと考えられます。

続いてプライバシーへの懸念を解消するにはどのような議論が重要であるかということになりますが、先ほどの中田先生、今川先生、マイケル・ハート氏などが近年論じているのが個人情報の社会的資本化というものです。これは個人情報を一企業が独占して私的に利用するのではなくて、個人情報を社会のために利用できるようにしようといった議論です。

しかし、このような課題に取り組む前に、マーケティング研究には注目しておくべき議論があるのではないかと考えています。その一つが、ビッグデータを蓄積する企業と消費者の間における情報の非対称性についての問題です。岡崎先生はベンサムのパノプティコンを取り上げて、SNSやアマゾンなども消費者を監視できる圧倒的な情報強者になっているのではないかと指摘しておりました。スライドのような問題を提起しています。

スライドを読ませていただくと、「私たちは日々、思考スピードで消費させられている。欲求が生じると、即時にそれを解消するための購入ボタンが提示され、条件反射でクリックする。その欲求すら、データマイニングからはじき出された巧妙なマーケティング戦略によってつくられたのかも知れず、私たちには自分が欲求しているのか欲求させられているのかすら分からない。AIのアルゴリズム、計算手順という名の神に購買欲すら支配されているのかもしれないのだ」ということで、こうした情報の非対称性の問題も踏まえておかないと個人情報の社会的資本化を検討していくのは難しいのではないかと考えています。

もう一つ触れておきたいのが、AI及びビッグデータの時代において、プライバシーそのものとの見え方が変化しているということです。これはチェネリーという研究者が指摘しています。

またスライドを読ませていただくと、1999年、サンマイクロシステムズのスコット・マクニリーCEOは「決してプライバシーなんてものはない。忘れてしまえ」と言った。フェイスブックの創業者マーク・ザッカーバーグは「プライバシーはもう社会規範ではなくなった」と信じている。それにグーグルの元CEO エリック・シュミットは

「プライバシーは無用で、危険ですらある」と言い、「他人に知られたくないようなことは、そもそもやるべきではないのではないか」と警告した。こうした意見に対しチェネリーは、プライバシーの権利というのはもともとは放っておかれる権利として始まっているけれども、いまこそこれが重要なんだと指摘しています。

かつては買い物とか買い物に必要な情報収集、コミュニケーションといった消費者の活動が企業に監視されるということは当然ありませんでした。しかし今日では、こうした多くの活動がインターネット上で行なわれているため、個人データや個人情報というかたちで企業が監視できるようになっています。その一方、消費者がプライバシー空間を確保することが難しくなっているわけです。そこで、いまこそ放っておかれる権利を求めていくことが重要だというのがチェネリーの指

摘でして、このような視点も今後注目すべきだと思っています。

以上から今後の課題もプライバシー問題にあると考えているのですが、プライバシーの公開というのは多くの人に共有されることによって社会的資本として役立つことは当然ありますが、しかし、プライバシーは無用であるとか他人に知られたくないようなことはやるべきではないといった、そういった主張をそのまま肯定していくわけにはいかないと思います。そこで、マーケティング及び消費生活において消費者のプライバシーの権利、特に放っておかれる権利の重要性をどう位置づけるのか。これがAIとビッグデータが発展していく中で重要な研究課題になるのではないかと考えています。

駆け足になってしまいましたが、私からの報告は以上です。

## 「AI・ビッグデータ活用 マーケティングに見る問題性」

日本大学経済学部非常勤講師 江上 哲

AIとビッグデータはマーケティングと密接に関係しているから、私は「AI・ビッグデータ活用マーケティングに見る問題性」ということでご報告したいと思います。

いまSNS社会でマーケティングは非常に変化しております。有名なコトラーという人の本の中で、アメリカの人たちはこういう説明をするのが非常にうまいんですけども、いままでのマーケティングはボーリングのマーケティングでやっていたんですね。ここにcとあるのは消費者で、企業が直接消費者を狙っていたんですけども、いまはそうじゃないんだ、ピンボールという、われわれちっちゃいときにはこういうのがありましたけれども、いまはもっとあるらしいです。こういうふうにして消費者同士をSNSなんかで交換している。

こういう情報をどう利用するかというのは、どっちかと言うと建設的なマーケティングになっている。そのとき重要なのは、企業の球が返ってくるところ、これがどう打ち返せるかということ。それが打ち返せないようだとかリスクの発生とか問題が起こる。ともかくもボーリングからピンボールのほうに行ってるんだという、これは現代のマーケティングを語るには適切な分かりやすい例だと思います。

そういうことも考えて詰めていきますと、マーケティングをするのは消費者志向はもちろん最初からあったんですけども、無理やり消費者志向になっているんですね。ビッグデータ、それに消費者の持つ情報量いっぱいありますから、それは労働現場とか働く現場にものすごく影響してきている。

そこではインターナル・マーケティングというのがあって、従業員にもマーケティングするんだという……。たとえば昔、大きなレストラン・チェーン店なんかは従業員にビデオを使った社長の生い立ちを見せたりした教育ー違った意味で言うと労働強化でしようけれども、そういうことも導入してやっていくと、それだけ顧客の情報が

集まるから、「ぼくが言うよりも、顧客が言ってるんだ」、そういう論理転換でマネジメントをやっている。つまり、ビッグデータを従業員教育のために取り出してやる。そういうのを基にして従業員にマーケティングをやっている、そういう流れが1つできてきているということです。

そういう事例を2つほどご紹介しておきます。これはカルビーというポテトチップスのオレアイダ経営研究所なんかにも関係があって、カルビーは有名になったかということ、すごい戦略がいろいろあって、中年の女性を700人も雇って、スーパーの売り場などの現場に調査に行くわけですね。その現場の声を聞いていこうとか、それが画期的だったんですね。

もう20年ぐらい前ですけども、携帯電話を彼女たちはもっていて電話で個々に、オペレーターセンターに音声で報告する。普通こういう調査をしたら文章を帰って書いて会社に報告するんですけども、そこが偉かったところは、全専門のオペレーターが全部言葉を打ってやった、これが画期的だったんですね。

文章にするとこぼれ落ちるものがありますから、全部思うようにしゃべらせて、オペレーターが全部打ち込む。そういう中でまさにAI的な分析をして、カルビーのポテトチップスのコンセプトは「鮮度」なんですね。そういうのを見出して、「鮮度」という言葉を取り上げて、いまのポテトチップス・ナンバーワンに持っていったんですね。そういう例として、これもAIとかビッグデータを活用した例ですね。

あと1つは、IBMが営業分野の管理を行なって、モデルがあります。営業部員をテキストマイニングで分析して、ここに丸がついているのはいいほうの従業員で、丸がついていないのはあまり成績がよくない従業員。次に分析するときに如実に出てきたのは、いいほうの従業員のテキスト、メモなんかを分析すると、「お礼」とか「御礼」とかそういう言葉をよく使っている人たちは全体的に成績がいい、そういう分析が行なわれてきているわけです。

もっと言うと、言葉自体が全然違う。英語はこういう言葉を遣っている、日本語はこういう言葉を遣っている。そういうところの分析、これはIBMだからできるようなことなんでしょうけれど

も、将来そういうことをとというか、実際もうやっている企業があるかもしれません。営業報告とか電子データになっているとおもいますが、それを分析しているというのをこっそりやっている可能性はあります。そういうふうにしてビッグデータというかデータ処理が進んでいる。そういう例をここで1つ紹介しておきます。

要するに労働管理というか、顧客による経営管理というのはよく言われてまして、さっきもちょっと言ったように、「顧客が言うからやるので、自分が言っているのではない」という責任逃れみたいなことがあるんですけども、そういうふうにして企業全体が、特に新自由主義的になっていくとそういうふうな合理性を強めていく。その基になっているのは顧客のビッグデータなんですね。データで従業員を管理していく方向、内部でも管理していく方向が強まっていくということが見えています。

これはある大学の先生の『トヨタの労働現場』という本をつくられて、大学の先生になられたんですけども、先生自ら実際現場にトヨタで季節工として働いた本を出したんですね。

いろんなことが書いてあるんですけども、とにかくトヨタの工場で不良品が送り返されてきたら、誰がこれをつくったか分かるようになってるらしいですね。だから、労働現場がお客さまの好みで現場の仕事をしなさい。そういうところで、ある意味、情報社会の1つの極みでしょうけれども、そこまで顧客からの情報でマネジメントが行われる、マーケティングもそうですけれども、そこまでやっている1つの例です。

そういうふうなことからいろんな問題が出てきています。斎藤幸平が編集された本の『未来への大分岐』という本があるんですけども、ベルギーなんかの問題を取り上げているんですが、タクシー運転手にGPSをつけて、熟練の運転手がどういうふうにしてうまく運転してお客さんをつかんでいるかというのを、タクシー会社はデータとして持つようになっている。そういうアルゴリズムをつくっている。そうすると熟練労働者が要らなくなって、これを持っていれば低廉な賃金で雇用していく方向になっていくだろう。

昔、われわれ経営学部の中では有名な話で、テラー・システムというのがあって、知識と肉

体労働を分離した問題が違ったかたちでできてきている。資本とか、また新たな問題にぶち当たっているということになって、ベルギーなんかではどういう労働運動が起こっているかというのと、GPSなんかを使い、アルゴリズムを作るところに労働者も参加させてしてくれという、そういう労働運動が生まれている。これがどうなるかというのはこれからの大きな問題だと思います。企業側はそういう動きで、アルゴリズムが高度化しているということがさまざまな労働現場に問題が生じているということの1つの例です。これもビッグデータを活用して企業がとやっているとということ。

では今度はマーケティングの話に持っていきますと、リップOLDというアメリカのシカゴ大学の先生ですけれども、たとえば旅行サイト「ウォーピック」というサイトがアメリカにあるらしいですけれども、たとえばホテルを予約すると、いまはすぐ何のパソコン使っているか分かるわけですね。たとえばMac Airとか新しいのを使っているということがすぐ分かる、アルゴリズムで「この人はお金持ちだ。じゃあ高いほうを紹介しよう」とか、そうやって瞬時にそういったことがアルゴリズムでできている。

最近私は特に感じるんですけども、私たちが、アマゾンなんかはすぐにお勧めなんか持ってくるようになるし、ヤフーでも、検索していると、検索しているうちにすぐ来るようになってきているという感じが、私だけかどうか分かりませんが、非常にするようになっていきました。非常にうまくなっていると思うんです。

そこでいま問題は、いまのようなMac Airを使っただけでいろんなものを紹介してくるというのは、断片的な情報でマーケティングをやっているんじゃないか。デジタルマーケティングというのがあるけれども、デジタルマーケティングというのは断片的なことという消費者を想定している。これはかっこつきの「消費者」と、かっこつきの消費者をつくっているんだろう。ただ1つの情報だけで消費者をつくり上げている危険性があるんじゃないかなと思うんですけども、情報もかっこつきか、かっこつきじゃないかという、非常にマーケティングの危うさというか、データだけで、彼は「消費者のアイデンティティ」を

「ジャストインタイムアイデンティティ」という用語を使っているんですけども、その都度その都度のアイデンティティを使って、そこで○○○先生なんかは怒っている。私も怒っている。そういうふうなマーケティングをしている。さらにそういうアルゴリズムをつくっているわけです。こういうことがビッグデータであり、AIを使って行なわれている。だから、全体的な消費者像をつかんでないというか、そういう問題が問題性として1つ指摘されるんじゃないかなということです。

社会学者の大澤氏なんかは言うんですけども、自分もここに書いてるんですけども、自分で内的に客観的にいろいろ判断していくというよりも、ほとんど他者の例とかそういうふうなところで購買している例が非常に多くなっているということが、そういうふうな対応が増えている。ということは、まああたりまえと言えばあたりまえでしょうけれども、端的にそういうふうなことが非常に大きな問題を起こす可能性があるのではないかなということですよ。

一方の消費者は防衛するために、クレジットカードをつくる時なんか、自分のデータをうまく「ぼかす」つくり方が書いてある本なんです。

それは何かというと、アメリカなんかではポイントカードなんかの問題があって、もう10年ぐらい前の話ですけど、この本に書いてあるんですけども、あるスーパーでお客さまが転んだ。それで損害賠償の話になったときに何を店側は持ってきたかという、その人のポイントカードから得た客がアルコールを買った購買履歴を持ってきて、「あなたは……」というかたちで、ポイントカードとかそれがいろんなところに使われている可能性がある。

そういうことも含めて、いまの使っているマーケティングというのはいろんな問題をはらんでいる。さっきの井口先生のプライバシーの問題もありますけれども、私は問題性としては、本当の消費者をつかんでいるかどうかということ。

リアルのお店というのがあります。トライアルという店、これは見学に行きたかったんですけども、全部AI化して行って、この買い物かごに全部入れたら計算できて、そういうスーパーがあります。もちろん全部それを、いろんなデータを取られているんです。これは全部カメラですよ。全部カメラで、消費者はどういうものを手に取ったかとか、さまざまにまさに究極的な店なんです。

こういう小売店の売り物は、「うちはアマゾンみたいにああいう通販だけではない。リアルです」と言うんですね。リアルでAIを使っている。でも結局は、最初に言ったAIの断片的な情報によってマーケティングしている。こういう店まであるんじゃないかもっと言えば、こういうビッグデータ・マーケティングって本当に消費者をつかまえているのかどうか、全体的に消費者をつかまえているのかどうかという問題をよく考えないといけないんじゃないかなということ。私はそういうふうにも思っております。

また1つは、こういう店で買うと、これもAIで分析しているから大丈夫だと、逆に逆にAIを無批判に信用する可能性もありますし、そういう問題にマーケティングはどう対処していくか。AI依存というか、ビッグデータマーケティングは消費者をつかまえるAIになっているかどうかということをもう一度考えないといけないんじゃないかなということを少し書きました。そういうことです。以上です。

**大槻** どうもありがとうございました。

ちょっと時間がオーバーして大変申しわけございません。ひとえに私の回しのまずさと私の発表自体がちょっとオーバーしましたので、そこに尽きています。本当に申しわけないと思っています。最後にまとめは簡潔にいきたいと考えております。

きょうさまざまな発表をいただきましたけれども、もう第4次産業革命とも言われるほど、AIというのは社会にインパクトを与えているそうです。経産省が2017年に「新産業構造ビジョン」というものを提唱していますけれども、この中にも「第4次産業革命」というのは明確にうたわれています。

そういうことを踏まえて本研究では、まず技術的な側面からAIの変遷や歴史などを定義づけし

たうえで、私と大澤先生の発表でAIの技術的な側面から成果をご報告して、さらに応用的な側面から米澤先生、井口先生に発表いただいて、さらにはAIとマーケティングの観点から今後の課題・展望についてもお話しいただいたということです。

このようにこのプロジェクトでは、経済学、経営学、統計学、情報学、さまざま専門家が集合して、学術横断的な見地から研究を進めて、知見を示唆することができたと思います。このような機会をいただいた経済科学研究所には多大なお礼を申し上げたいと思います。

以上で私のまとめとさせていただきますと思います。きょうは長い時間お付き合いいただきまして、どうもありがとうございました。